

## DURAĞAN ZAMAN SERİLERİNİN YAPAY SİNİR AĞLARI İLE TAHMİNİNDE GİRDİ NÖRONU VE GİZLİ NÖRON SAYISININ BELİRLENMESİ

Coşkun HAMZAÇEBİ\*

Fevzi KUTAY\*\*

### ÖZET

*Bu çalışmada, yapay sinir ağlarının durağan zaman serileri ile geleceği tahminde performansını etkileyen girdi nöronu sayısı ve gizli nöron sayısı parametrelerinin en iyi değerinin belirlenmesi amacı ile bir deney tasarımı yapılmıştır. Ayrıca, Box-Jenkins modelleri ile yapay sinir ağı tekniğinin geleceği tahmindeki başarısı karşılaştırılmış ve hangi yöntemin daha iyi sonuç verdiği araştırılmıştır.*

*Anahtar Kelimeler: Box-Jenkins modelleri, girdi nöronu sayısı, gizli nöron sayısı Yapay sinir ağı, ,*

### 1. GİRİŞ

Zaman serileri ile tahmin için yaygın olarak kullanılan bazı yöntemler vardır. Doğrusal zaman serileri için başarılı sonuçlar veren Box-Jenkins modelleri bu yöntemlerin en önemlilerindedir. Ancak gerçek zaman serileri nadiren tamamen doğrusal veya tamamen doğrusal olmayan özellik gösterirler. Gerçek hayata ilişkin seriler çoğu kez, hem doğrusal hem de doğrusal olmayan yapıyı birlikte taşırlar (Zhang, 2003). Bu sebeple böyle bir ilişkiyi modellemede farklı tekniklere ihtiyaç vardır. Son 25 yıldır Bilinear Model, Threshold Autoregressive (TAR) Model, Autoregressive Conditional Heteroscedastic (ARCH) Model gibi bir çok doğrusal olmayan zaman serisi modeli geliştirilmiştir. Bu modeller doğrusal olmayan ilişkiyi ortaya çıkarmada doğrusal modellere göre daha başarılı iseler de, uygulaması zor, probleme özgü ve genelleştirmeden uzak modellerdir (Ghiassi vd., 2004). Önerilen bu modeller, veriler arasındaki ilişkinin net olduğu ve bu ilişkiye ait bilginin bilindiği durumda geçerlidir (Zhang vd., 1998). Ayrıca bu modellerden herhangi biri, veri kümesinde saklı bütün doğrusal olmayan yapıyı ortaya çıkarmada başarılı değildir (Zhang vd., 2001).

\* Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Endüstri Mühendisliği Bölümü Maltepe Ankara Türkiye (Haberleşme adresi)

\*\* Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Endüstri Mühendisliği Bölümü Maltepe Ankara Türkiye

1980'li yılların sonlarından itibaren zaman serileri tahmininde kullanılmakta olan tekniklerden biri de Yapay Sinir Ağları (YSA) tekniğidir. YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye ve varsayım ihtiyacı duymadan gerekli modellemeyi sağlayabilmektedir. Bu sebeple YSA, tahmin aracı olarak diğer yöntemlere göre daha genel ve esneklerdir (Zhang vd., 1998).

YSA'nın geleceği tahmin için kullanılması yeni değildir. İlk uygulama 1964 yılında olmuştur. Hu (1964) tezinde Widrow'un uyarlanabilir doğrusal ağını (adaptive linear network) hava durumu tahmini için kullanmıştır. Ancak çok katmanlı ağları eğitecek algoritmanın olmayışından dolayı bu çalışma oldukça sınırlı kalmıştır (Zhang vd., 1998). 1986 yılında geri yayılım algoritmasının tanıtılmasından sonra (Rumelhart vd., 1986), YSA'nın tahminde kullanılmasında bir çok gelişme olmuştur. Lapedes ve Farber (1987) bir benzetim çalışması sonucunda YSA'nın doğrusal olmayan zaman serilerinin modellenmesinde ve tahmininde kullanılabileceğini ifade etmiştir. Jhee vd. (1992), Box-Jenkins modellerinin belirlenmesinde YSA kullanımını araştırmıştır. Hwang ve Ang (2001), ARMA(p,q) zaman serileri için basit bir ağ yapısı önermiş ve girdi nöronu sayısının tespitine yönelik bir deney tasarımı yapmıştır. Sexton vd. (2004), en iyi sonucu verecek en az parametrelili ağ yapısının belirlenmesine yönelik bir optimizasyon algoritması önermiştir.

YSA'nın zaman serileri ile geleceği tahminde kullanımı üzerine yapılan araştırmalar ve çalışmalar oldukça çoktur. Marquez vd. (1992) ve Hill vd. (1994), YSA'yı, zaman serilerinin tahmininde kullanılan istatistiksel metotlarla ve regresyon tabanlı tahmin metodu ile karşılaştırarak literatürü gözden geçirmişlerdir. Zhang vd. (1998), daha kapsamlı bir çalışma ile sinir ağları ile modellemenin önemine odaklanmıştır.

Bu çalışmada, doğrusal olmayan zaman serilerinin tahminde YSA'nın performansında etkili olduğu düşünülen, girdi nöronu sayısı ve gizli nöron sayısının belirlenmesi için bir deney tasarımı yapılmıştır. Çalışma şu şekilde planlanmıştır: 2. bölümde YSA ve YSA ile tahminde önemli parametreler açıklanmıştır, 3. bölümde uygulama çalışması ve 4. bölümde sonuç ve öneriler yer almaktadır.

## 2. YAPAY SİNİR AĞLARI

İnsan beyninin çalışma prensibini taklit eden yapay sinir ağları (YSA), örnek sınıflandırma, örüntü tanıma ve tahminde önemli bir araçtır. YSA, deneme-yanılma yolu ile öğrenebilmekte ve daha sonra da genelleştirme yapabilmektedir.

Tipik bir YSA, nöronlardan oluşan katmanların bileşimidir. En yaygın kullanılan YSA tipi, çok katmanlı algılayıcıdır. Çok katmanlı algılayıcı (ÇKA), dışarıdan verileri alan girdi katmanından, ağın çıktılarını dışarıya veren çıktı katmanından ve bu ikisi arasında genellikle bir ve bazen de daha fazla gizli katmandan meydana gelmektedir. Girdi katmanındaki nöronların girdisi ağın dışarıdan alınırken, gizli katman yada çıktı katmanındaki bir nöronun net girdisi; kendisine gelen bütün girdilerin ( $x_i, i=1,2,\dots,n$ ) ilgili ağırlıklarla ( $w_i, i=1,2,\dots,n$ ) çarpımının toplamından ( $\sum_i w_i \cdot x_i$ ) oluşmaktadır, çıktısı ise net girdinin aktivasyon fonksiyonunda işleme tabi tutulmasıyla oluşur.



Bir ÇKA'nın kendisinden istenen görevi yerine getirebilmesi için probleme ilişkin verilerle ağı eğitilmesi gerekir. Eğitime işlemi öğrenme algoritmaları sayesinde gerçekleştirilir. Girdi ve bu girdilere karşılık gelen çıktılardan meydana gelen eğitim kümesi  $\{x^{(k)}, t^{(k)}\}$ ,  $k=1,2,\dots,p$ , şeklinde ifade edilirse, öğrenme algoritması yardımı ile verilen eğitim seti için en uygun çözümü üretecek ağırlıklar bulunur. Sıklıkla kullanılan öğrenme algoritması geri yayılım algoritmasıdır. Geri yayılım algoritmasında ağırlıkların düzenlenmesi işlemi, basitçe gradyan inişe dayanmaktadır (Kartalopoulos, 1996). Gradyan inişe göre ağırlıkları düzenleyen geri yayılım algoritmasının yavaş ilerlemesi ve yerel minimumlara takılması sebebi ile Newton metodu ve Levenberg-Marquardt algoritmaları gibi ikinci derece metotlarla ağırlıkları düzenlemek üzere algoritmanın farklı modifikasyonları önerilmiştir. Bu metotlar daha hızlı çalışmaktadırlar ve genel minimumu bulmada daha başarılıdırlar (Zhang vd., 1998).

Bir YSA'da öğrenme algoritmasının seçiminin yanısıra mevcut verilerin düzenlenmesi de dikkatlice yapılmalıdır. Zaman serileri tahmini için kurulan ÇKA'da, veri seti genellikle üç kısma ayrılır. Verilerin yaklaşık %80-60'ını içeren birinci kısım eğitim kümesi olarak adlandırılır ve ağı eğitimi için kullanılacak verileri kapsar. İkinci kısım doğrulama kümesidir ve verilerin %10-20'ni kapsar. Doğrulama kümesi, en uygun ağı yapısının belirlenmesinde yardımcı olur. Doğrulama kümesi sayesinde, ezberleme gibi bir hata ile karşılaşmaktan kurtulunur. Son kısım test kümesidir. Test kümesinin amacı, ağı sonuçlarının genelleştirilmesini sağlamaktır. Test kümesi, verilerin yaklaşık olarak %10-20'ni kapsar.

Zaman serileri tahmini için geliştirilecek ÇKA'nın tasarımında, girdi nöronu sayısı, gizli katman ve gizli nöron sayısı, çıktı nöronu sayısı gibi değişkenlerin belirlenmesi oldukça önemlidir. Ancak bu parametrelerin seçimi ilgilenilen probleme göre değişecektir. En iyi ağı yapısının belirlenmesinde sezgisel yaklaşımlar yada deney tasarımı yardımcı olabilir (Zhang vd., 1998).

Tahmin için kurulan ÇKA'da en önemli parametrelerden biri belki de en önemlisi girdi nöronu sayısıdır. Bir zaman serisi tahmin probleminde uygun girdi nöronu sayısını belirlemek kolay değildir. Tang ve Fishwick(1993), tek değişkenli bir zaman serisi için, girdi nöronu sayısının basitçe Box-Jenkins AR(p) modelinin derecesine eşit olduğunu ileri sürmektedir. Bu yaklaşım, bir başlangıç noktası olarak iyi olabilir ancak hiçbir zaman en iyi girdi nöronu sayısını belirlemez. Çünkü Box-Jenkins modelleri doğrusal ilişkinin belirlenmesinde etkilidirler, doğrusal olmayan ilişkiyi ortaya ortaya çıkarmada başarılı olamayabilirler.

Bir diğer önemli parametre de, gizli katman ve gizli nöron sayısıdır. Gizli katman ve gizli nöronlar, YSA'nın başarısında büyük bir öneme sahiptir. Veri içerisindeki belirleyici özellikleri ortaya çıkartan ve girdi ile çıktı arasındaki doğrusal olmayan ilişkinin kurulmasına yardımcı olan, gizli katman ve bu katmanlardaki nöronlardır. Yapılan çalışmalar, tek gizli katmanın, doğrusal olmayan fonksiyon yaklaşımlarında, istenilen herhangi bir doğruluk derecesinde başarılı neticeler verdiğini göstermiştir (Cybenko, 1989; Hornik, 1989). Bir YSA'da birden fazla gizli katman olabilir, ancak bir çok araştırmacı geleceği tahmin için kurdukları ağda tek gizli katman kullanmayı tercih etmişlerdir (Kaastra ve Boyd, 1996). Zhang vd.(1998)'ne göre, bir çok tahmin problemi için tek gizli katman yeterlidir. Ancak, bazı özel problemlerde, iki

gizli katmanlı ağ yapısının tek gizli katmanlı ağ yapısından daha iyi sonuç vermesi muhtemeldir. Kaastra ve Boyd (1996), bütün ÇKA'ların öncelikle bir gizli katman ya da en fazla iki gizli katman kurularak çalıştırılmasını önermektedir.

Bir ağda gizli nöron sayısının belirlenmesi kritik bir karardır. Genelde az sayıda gizli nöron ile çalışma tercih edilir. Çünkü genelleştirme yetenekleri daha yüksektir. Çok sayıda gizli nöron, ağın genelleştirmeden daha çok ezberleme yeteneği kazanmasına sebep olur. Ancak çok az sayıda gizli nöron da ağın öğrenmesi için yeterli değildir. Bu sebeple araştırmacılar gizli nöron sayısını belirlemede deneysel bir çalışmaya başvurabilirler. Ancak sistematik bir yöntem olarak, küçük bir başlangıç değeri ile başlanması ve ağ performansı iyileşene kadar gizli nöron sayısının artırılması önerilmektedir (Kaastra ve Boyd, 1996).

Gizli nöron sayısını belirlemede deneme-yanılma metodu sıklıkla kullanılır. Ancak yine de bazı deneysel çalışmalar gizli nöron sayısını sınırlayıcı öneriler sunmaktadır. Tek gizli katmanlı ağlarda gizli nöron sayısına ilişkin bazı öneriler şunlardır:

- a)  $0,75 * n$  (Baily ve Thompson, 1990)
- b)  $n$  (Tang ve Fishwick, 1993)
- c)  $2n$  (Wong, 1991)
- d)  $2n+1$  (Lippmann, 1987)
- e)  $\sqrt{n * m}$  (Masters, 1993)

Yukarıdaki ifadelerde “n” girdi nöronu ve “m” çıktı nöronu sayısını göstermektedir. Bu yaklaşımlardan hiçbirisinin bütün problemlerde iyi sonuç verdiğini söylemek doğru olmaz.

ÇKA'ların performansında etkili olabilecek bir başka etken de çıktı nöronu sayısıdır. Çıktı nöronu sayısı çalışılan probleme direk bağlıdır. Bir zaman serisi tahmini probleminde, çıktı nöronu sayısı, tahmin döneminin uzunluğuna göre belirlenir. Eğer tek dönemlik tahminde bulunulacak ise çıktı nöronu sayısı 1'e eşittir. Çok dönemli tahminde ise, kullanılan yaklaşıma göre çıktı nöronu sayısı değişir. Eğer iteratif tahmin yöntemi benimsenmişse, çıktı nöronu sayısı 1'e eşittir. Direk tahmin yaklaşımı benimsenmişse, çıktı nöronu sayısı tahmin dönemi uzunluğuna eşit alınabilir. İteratif yöntem, sadece bir dönem tahminde bulunmak üzere kullanılabilir. Bulunan tahmin değeri girdi olarak kullanılır ve bir sonraki dönem tahmin edilir. İteratif tahmin yaklaşımı, Box-Jenkins modellerinin benimsediği yaklaşımdır.

### 3. UYGULAMA

Zaman serileri ile geleceği tahminde Box-Jenkins modelleri ve YSA'nın performansını karşılaştırmak ve iyi bir tahmin için YSA girdi nöronu sayısı ve gizli nöron sayısını belirlemek amacı ile bilgisayar ortamında AR(p) sürecine uyan 100 gözlem değerine sahip 20 farklı seri üretilmiştir. Üretilen seri değerleri için ,

$$Y_t = \mu + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + a_t \quad [1]$$



eşitliği kullanılmıştır. Serilerin üretiminde başlangıç değerleri ve  $\mu$  keyfi olarak seçilirken  $\phi$  parametreleri  $[-1 1]$  aralığında tekdüze dağılımdan rastgele üretilmiştir.  $a_t$  hata terimi,  $N(0, \sigma^2)$  normal dağılmış bir tesadüfi değişkendir.  $a_t$  hata terimi varyansı değişik büyüklüklerde seçilerek gürültü faktörünün tahminin doğruluğu üzerindeki etkisi araştırılmıştır.

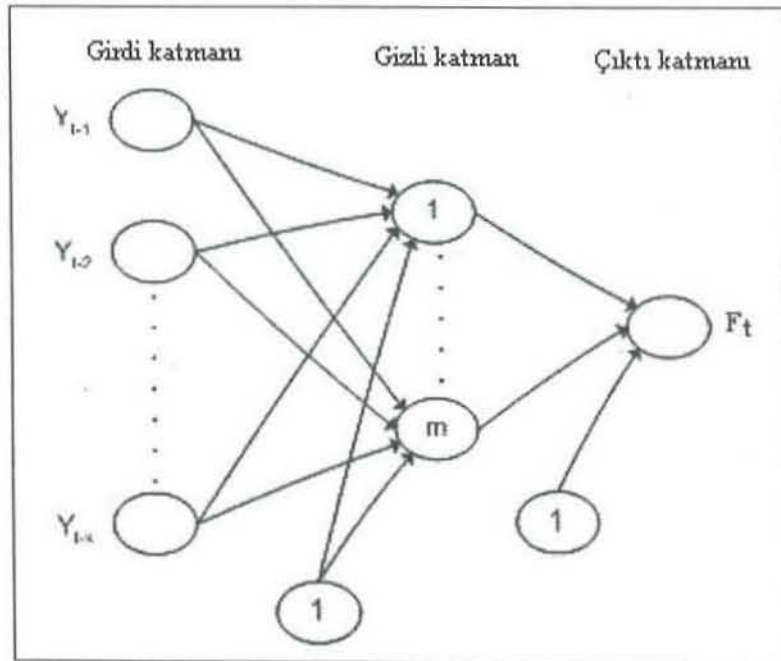
Üretilen serilerin Box-Jenkins yöntemi ile tahmini için MINITAB ve YSA teknikleri ile tahmini için de MATLAB Neural Network ToolBox programları kullanılmıştır.

### 3.1. Ağ Yapısı

Zaman serileri tahmini için kurulacak YSA'nın yapısı, ağın performansında oldukça etkilidir. Bu sebeple etkin bir performans için farklı ağ yapılarının araştırılmasında fayda vardır.

Bu çalışmada, girdi nöronu sayısı, 2,3, ve 4 olacak şekilde farklı ağ yapıları denenmiştir. Gizli nöron sayısı için ise, girdi nöronu sayısının bir eksiğinden 2 fazlasına kadar değerler kullanılmıştır. Örneğin girdi nöronu 3 ise, gizli nöron 2,3,4 ve 5 alınarak farklı ağ yapıları elde edilmiştir. Şekil 2, kullanılan ağ yapısını göstermektedir.

Şekil 2'de gösterilen ağın ürettiği çıktının matematiksel ifadesi Eş. 2'de verilmiştir.



Şekil 2. Zaman serileri ile geleceği tahmini için kurulan YSA

$$F_t = \theta_0 + \sum_{j=1}^m v_j f \left( \sum_{i=1}^k w_{ij} Y_{t-i} + \theta_{0j} \right) \quad (2)$$

Eş. 2’de,  $F_t$ , t dönemi için ağırlık ürettiği seri değerini,  $\{Y_{t-i}, i=1,2,\dots,k\}$  k dönem geçmiş gözlem değerini,  $\{w_{ij}, i=1,2,\dots,k; j=1,2,\dots,m\}$  girdi katman nöronlarından gizli katman nöronlarına olan bağlantıların ağırlıklarını,  $\theta_0$  ve  $\theta_{0j}$ , girdi değeri 1 olan eşik (bias) terimlerinin bağlantılarına ait ağırlıkları,  $\{v_j, j=1,2,\dots,m\}$  gizli katman nöronlarından çıktı katman nöronuna olan bağlantıların ağırlıklarını,  $f$  kullanılan aktivasyon fonksiyonunu ifade etmektedir.

### 3.2. Performans Ölçütü

Kurulan YSA’nın iyi bir tahmin edici olup olmadığının tespiti için test kümesindeki verilerin tahmin değerlerinin doğruluğunun ölçülmesi gereklidir. Bu ölçme işlemi için bir çok ölçüt kullanılabilir. Bu çalışmada ortalama mutlak yüzde hata performans ölçütü hesaplanmıştır:

$$\text{Ortalama Mutlak Yüzde Hata (OMYH)} = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_t - F_t}{Y_t} \right| * 100 \quad (3)$$

Eşitlik 3’te  $Y_t$ , serinin t dönemindeki gerçek değerini,  $F_t$ , serinin t dönemindeki tahmin değerini ve N de serideki gözlem sayısını göstermektedir.

### 3.3. Bulunan Sonuçlar

YSA ile tahminde bulunabilmek için eldeki seriler eğitim, doğrulama ve test olmak üzere üç kısma ayrılmıştır. İlgilenilen serinin, %80’ni eğitim kümesi, %10’nu doğrulama kümesi ve %10’nu test kümesidir. Box-Jenkins tekniği ile model kurulurken serinin %90’nu model kurma ve %10’nu test amaçlı kullanılmıştır. Her iki teknikle test kümesi için bulunan sonuçlar karşılaştırılmış ve hangi tekniğin daha az tahmin hatası verdiği araştırılmıştır. YSA ile tahminde bulunurken en iyi sonucu veren ağ yapısının belirlenmesi amacı ile bir deney tasarımı yapılmıştır.

#### 3.3.1. Girdi ve gizli nöron optimizasyonu

Girdi nöronu ve gizli nöronların performans ölçütü üzerindeki etkisini öğrenmek için deney tasarımı yapılmış ve Şekil 1 ve 2’de gösterilen sonuçlara ulaşılmıştır.

Şekil 2 ve Şekil 3’te sırasıyla, girdi ve gizli nöron sayılarının ve birbirleri ile etkileşimlerinin performans ölçütü üzerindeki etkisi gösterilmiştir. Grafikler incelendiğinde girdi nöronu sayısının ve gizli nöron sayısının 3. düzeyde olduğu durumda en düşük OMYH değerinin elde edildiği görülmektedir. Buradan hareketle, girdi nöronu sayısı arttıkça tahmin doğruluğunun arttığı söylenebilir. Ayrıca gizli nöron

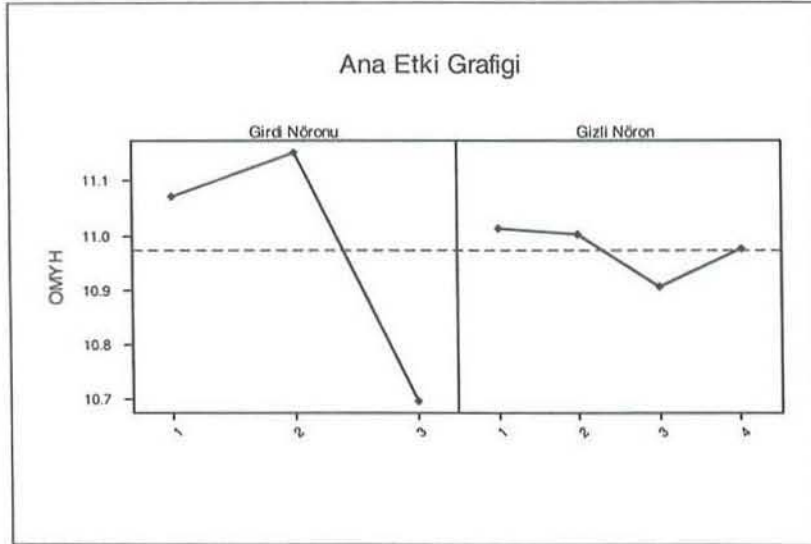
sayısının en iyi değerinin girdi nöronu sayısının bir fazlasına eşit olduğu her iki şekilde de görülmektedir.

### 3.3.2. Box-Jenkins ve YSA karşılaştırması


Box-Jenkins ve YSA tekniklerinden hangisinin daha az tahmin hatası verdiğini söyleyebilmek için Paired t test istatistiğinden faydalanılmıştır. 20 seri için bulunan OMYH değerlerine ait Paired t istatistiği ve Box-Jenkins – YSA farkı için güven aralığı Tablo 1’de verilmiştir. Tablo 1’deki sonuçlar, YSA ile bulunan tahmin hatasının Box-Jenkins tekniği ile bulunan tahmin hatasına göre daha az olduğunu göstermektedir.

Tablo 1. Paired T istatistiği sonucu ve güven aralığı

Box-Jenkins – YSA	
%95 Güven aralığı	(0.088; 0.852)
T testi	T-değeri = 2.43 P-değeri = 0.016



Şekil 2. Girdi ve gizli noron sayılarına göre ana etki grafiği



Şekil 3. Girdi ve gizli noron sayısının etkileşimi



#### 4. SONUÇ

Bu çalışmada YSA ile AR(p) sürecine uyan zaman serileri tahmininde girdi nöronu ve gizli nöron sayılarının tespitine yönelik bir deney tasarımı yapılmıştır. Yapılan analiz sonucunda, girdi nöronu sayısı arttıkça tahmin performansının iyileştiği görülmüştür. Gizli nöron sayısı ise, girdi nöronu sayısının 1 fazlasına eşit olduğu durumda en iyi performans elde edilmektedir. Box-Jenkins modelleri ile YSA tekniğinin hangisinin daha az tahmin hatası verdiği de araştırılan bir başka konudur. Her bir seriye ait test kümesi için her iki teknikte bulunan OMYH değerleri Paired t test istatistiğine tabi tutulmuş ve YSA tekniğinin %95 güven katsayısında daha az tahmin hatası verdiği görülmüştür.

#### KAYNAKLAR

- BAİLY, D. and THOMPSON, D. M. (1990), *Developing Neural Network Applications*, AI Expert, September, 33-41.
- BOX, G.P. and JENKINS, G.M. (1976), *Time Series Analysis Forecasting and Control*, San Francisco, Holden-Day.
- CYBENKO, G. (1989), Approximation by Superposition of a Sigmoidal Function, *Mathematical Control Signal Systems*, 2, 303-314.
- GHIASSI, M., SAİDANE, H., and ZİMBRA, D.K. (2004), A Dynamic Artificial Neural Network Model For Forecasting Time Series Events, *International Journal of Forecasting*, 21(2), 341-362.
- HİLL, T., MARQUEZ, L., O'CONNOR, M. and REMUS, W. (1994) Artificial Neural Networks for Forecasting and Decision Making, *International Journal of Forecasting*, 10, 5-15.
- HORNİK, K., STİNCHCOMBE, M. and WHITE, H. (1989), Multilayer Feed-Forward Networks are Universal Approximators, *Neural Networks*, 2, 359-366.
- HU, M.J.C. (1964), Application of the Adaline System to Weather Forecasting, Master Thesis, Technical Report 6775-1, Stanford Electronic Laboratories, Stanford.
- WARNG, H.B. and ANG, H.T. (2001), A Simple Neural Network for ARMA(p,q) Time Series, *Omega*, 29,319-333.
- KAASTRA, I. and BOYD, M. (1996) Designing A Neural Network For Forecasting Financial And Econometric Time Series, *Neurocomputing*, 10, 215-236.
- KARTALOPOULOS, S.V. (1996), *Understanding Neural Network and Fuzzy Logic*, New York IEEE Pres.
- LAPADES, A. and FARBER, R. (1987), Nonlinear Signal Processing Using Neural Networks: Prediction and System Modeling, Technical Report LA-UR-87-2662, Los Alamos National Laboratory, Los Alamos.



- LİPPMANN, R.P. (1987), An Introduction to Computing With Neural Nets, IEEE ASSP Magazine, April, 4-22.
- MARQUEZ, L., HİLL, T., O'CONNOR, M. and REMUS, W. (1992), Neural Network Models for Forecast a Review, IEEE Proceedings of the 25th Hawaii International Conference on System Sciences, Hawaii, 4, 494-498.
- MASTERS, T. (1993), Practical Neural Network Recipes in C++, New York, Academic Press.
- RUMELHART, D.E., HİNTON and G.E., WILLIAMS, R.J. (1986), Learning Internal Representation by Back-Propagating Errors, The PDP Research Group, Paralel Distributed Processing: Explorations in the Microstructure of Cognition, Rumelhart, D.E. and McClelland, J.L., MA, MIT Pres.
- SEXTON, R.S., DORSEY, R.E. and SİKANDER, N.A. (2004), Simultaneous Optimization of Neural Network Function and Architecture Algoritihm, Decision Support Systems, 36, 283-296.
- TANG, Z. and FİSHWİCK, P.A. (1993), Feedforward Neural Nets as Models for Time Series Forecasting, ORSA Journal on Computing, 5(4), 374-385.
- WONG, F.S. (1991), Time Series Forecasting Using Backpropagation Neural Networks, Neurocomputing, 2, 147-159.
- ZHANG, G., PATUWO, B.E. and HU, M.Y. (1998), Forecasting with Artificial Neural Networks:The State of the Art, International Journal of Forecasting, 14, 35-62.
- ZHANG, G., PATUWO, B.E., Hu, M.Y. (2001), A Simulation Study of Artificial Neural Networks for Nonlinear Time-Series Forecasting, Computers&Operations Research, 28, 381-396.
- ZHANG, G. (2003), Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model, Neurocomputing, 50, 159-175.

## DETERMINING INPUT AND HIDDEN NEURONS NUMBERS IN ARTIFICIAL NEURAL NETWORKS FOR FORECASTING STATIONARY TIME SERIES

### ABSTRACT

*In this study, an experimental design has been conducted for determining the optimum values of input and hidden neurons numbers which are the factors affecting the performance of artificial neural networks used to forecast stationary time series. Furthermore, results of Box-Jenkins models and artificial neural networks are compared and it is also investigated which method gives the better result.*

**Key Words:** *Artificial neural networks, number of input neurons, number of hidden neurons, Box-Jenkins models.*