

ZAMAN SERİLERİ TAHMİNİNDE ARIMA-MLP MELEZ MODELİ

Oğuz KAYNAR^(*)
Serkan TAŞTAN^(**)

Özet: Bu çalışmada zaman serilerinin tahmini için otoregresif hareketli ortalamalar (autoregressive integrated moving average-ARIMA) modeli ve çok katmanlı yapay sinir ağları (multi layer perceptron-MLP) modeli birleştirilerek bir melez model oluşturulmuştur. Melez modelde, zaman serisinin doğrusal bileşeni ARIMA modeli ile doğrusal olmayan bileşeni ise MLP modeli ile tahmin edilmiştir. ARIMA ve MLP modellerinin tek başına kullanılması ile elde edilen tahmin sonuçları Melez modelin tahmin sonuçları ile karşılaştırılarak Melez modelin tahmin performansı ölçülmüştür.

Anahtar Kelimeler: Yapay Sinir Ağları, MLP, ARIMA, Melez Model

Abstract: In this study, a hybrid model was created by combining autoregressive integrated moving average (ARIMA) model and multi layer perceptron (MLP) model for time series forecasting. In hybrid model linear component of time series is forecasted by ARIMA and nonlinear component is forecasted by MLP respectively. Forecasting performance of hybrid model is measured through the forecast results obtained from the model that used only ARIMA and MLP is compared with the forecast results of hybrid model.

Key Words: Artificial Neural Networks, MLP, ARIMA, Hybrid Model

I.Giriş

Geçmiş dönemlere ilişkin gözlem değerleri yardımıyla geleceğe yönelik tahminler yapmayı amaçlayan zaman serisi modelleri tıp, mühendislik, işletme, ekonomi ve finans gibi birçok alanda yaygın bir şekilde kullanılmaktadır. Zaman serileri yardımıyla tahmin yapmak için değişik yöntemler kullanılarak oluşturulan farklı modeller bulunmaktadır. Bu modeller arasında en çok bilinen ve yaygın olarak kullanılan ARIMA modelleridir. Seriyi oluşturan veriler arasında doğrusal bir ilişkinin olduğunu varsayan ve bu doğrusal ilişkiyi modelleyebilen ARIMA modelleri durağan ya da çeşitli istatistiksel yöntemlerle durağan hale getirilen zaman serilerine başarıyla uygulanabilmektedir. Oysa uygulamada karşılaşılan birçok zaman serisi sadece doğrusal ilişki içermemektedir. Yapısı gereği hem doğrusal hem de doğrusal olmayan ilişkileri modelleyebilen yapay sinir ağları (YSA) son yıllarda zaman serilerinin analizinde kullanılan alternatif yöntemlerden biri olmuştur. Yapay sinir ağlarının zaman serilerinin tahmininde kullanıldığı çalışmalara ilişkin geniş bir derleme Zhang vd. tarafından yapılmıştır (Zhang vd, 1998).

Yapay sinir ağlarının en önemli avantajı, veri setine ilişkin fonksiyonel yapının tam olarak belirlenemediği durumlarda, veriden hareketle birçok değişik formdaki fonksiyonel yapıyı başarıyla modelleyebilmesidir. Genel

^(*)Yrd. Doç. Dr. Cumhuriyet Üniv. İİBF Yönetim Bilişim Sistemleri Bölümü

^(**)Arş.Gör. Yönetim Bilişim Sistemleri Bölümü

fonksiyon yaklaşırıcısı olarak da bilinen yapay sinir ađları, istatistiksel yöntemlerin aksine veri seti üzerinde her hangi bir ön varsayıma gerek duymaz.

Pratikte, kullanılan zaman serisindeki ilişkinin, doğrusal ya da doğrusal olmaması konusunda kesin bir sonuca varmak zordur. Bu yüzden tek yöntem kullanılarak oluşturulan modeller her zaman en iyi sonuçları vermezler. Farklı yöntemlerin bir arada kullanılması ile oluşturulan modellerin başka bir deyişle melez modellerin daha iyi tahminler yapması beklenir.

Literatürde zaman serilerinin tahmininde melez yaklaşım kullanımına ilişkin çeşitli çalışmalar bulunmaktadır. Zhang ARIMA ve YSA modellerini birleştirerek melez bir model oluşturmuş, bu melez modeli 3 farklı zaman serisine uygulamış ve YSA, ARIMA ve melez modellerle elde edilen tahmin sonuçlarını karşılaştırmıştır(Zhang, 2003: 159). Hata kareleri ortalaması dikkate alınarak gerçekleştirilen kıyaslamada her üç veri seti içinde melez modelin diğer iki modelden daha iyi sonuçlar verdiğini belirtmiştir. ARIMA ve YSA kullanılarak oluşturulan melez bir model saatlik sıcaklığın tahmin edilmesinde kullanılmıştır (Hippert vd., 2000: 414). Radyal tabanlı sinir ađları ile Box-Jenkins modellerinin birleştirildiđi bir çalışmada Wedding ve Cios tarafından yapılmıştır(Wedding ve Cios, 1996: 149). Diğer bir çalışmada ise, mevsimsel etki içeren iki farklı zaman serisinin tahmini için, mevsimsel ARIMA (SARIMA) ve YSA modelleri birlikte kullanılmıştır(Tseng vd., 2002: 71). Tseng vd. her iki veri seti için de melez modelin tahmin performansının diğer modellerden daha iyi olduğunu göstermişlerdir. Benzer şekilde Hansen ve Nelson da yaptıkları çalışmada melez modelin tek yöntem kullanılarak oluşturulan modellerden daha iyi sonuç verdiğini belirtmişlerdir(Hansen ve Nelson, 2003: 315). ARIMA ve yapay sinir ađlarının birleştirilerek kullanıldığı melez modellerin yanında, tahmin performansını artırmak için farklı yapay sinir ađlarının birleştirilerek kullanıldığı bir çok çalışmada mevcuttur(Pelikan vd.,1992:701; Donaldson ve Kamstra, 1996: 49; Ginzburg ve Horn, 1994: 224).

Bu çalışmada ise ARIMA, MLP ve melez model kullanılarak TEFE (Toptan Eşya Fiyat Endeksi) verileri üzerinde bir uygulama gerçekleştirilmiş ve elde edilen sonuçları karşılaştırılmıştır.

II. Yöntem

A. ARIMA Modelleri

ARIMA modelleri, durađan olmayan ancak fark alma işlemiyle durađan hale dönüştürülmüş serilere uygulanan modellerdir. Durađan olmayan ancak fark alma işlemiyle durađan hale dönüştürülmüş serilere uygulanan modellere “durađan olmayan doğrusal stokastik modeller” denir. Bu modeller d dereceden farkı alınmış serilere uygulanan, deđişkenin t-dönemindeki deđerinin belirli sayıdaki geri dönem deđerleri ile aynı dönemdeki hata teriminin doğrusal bir fonksiyonu olarak ifade edildiđi AR ve deđişkenin t-dönemindeki deđerinin aynı dönemdeki hata terimi ve belirli sayıda geri dönem hata terimlerinin

doğrusal fonksiyonu olarak ifade edildiği MA modellerinin birer birleşimidir. Modellerin genel gösterimi ARIMA (p, d, q) şeklindedir. Burada p ve q sırasıyla otoregresif(AR) modelin ve hareketli ortalama(MA) modelinin derecesi, d ise fark alma derecesidir.

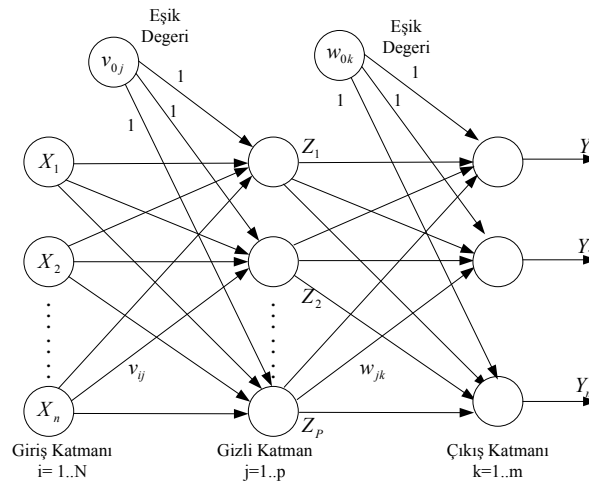
Genel ARIMA(p,d,q) modeli aşağıdaki gibi formüle edilir.

$$Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + \delta + a_t - \Theta_1 a_{t-1} - \Theta_2 a_{t-2} - \dots - \Theta_q a_{t-q} \quad (1)$$

Eşitlikte; $Z_t, Z_{t-1}, \dots, Z_{t-p}$ d dereceden farkı alınmış gözlem değerlerini, $\Phi_1, \Phi_2, \dots, \Phi_p$ d dereceden farkı alınmış gözlem değerleri için katsayıları, δ sabit değeri, $a_t, a_{t-1}, \dots, a_{t-q}$ hata terimlerini ve $\Theta_1, \Theta_2, \dots, \Theta_q$ hata terimleri ile ilgili katsayıları göstermektedir.

B. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları (MLP)

Yapay sinir ağları, biyolojik sinir ağlarından esinlenilerek ortaya çıkarılan ve biyolojik sinir ağlarına benzer bazı performans özellikleri içeren bir bilgi işleme sistemidir(Fausett,1994: 3). YSA 'da nöron adı verilen bir dizi sinir hücresinin ileri sürümlü ve geri beslemeli bağlantı şekilleri ile birbirine bağlanmasından oluşan çok çeşitli ağ yapıları ve modelleri vardır. Bunlar içerisinde en yaygın olarak kullanılanı MLP ağlarıdır.



Şekil 1: Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı

MLP ağlarında nöronlar katmanlar şeklinde organize edilmiştir. MLP' de ilk katman girdi katmanıdır. Girdi katmanı, çözülmesi istenilen probleme ilişkin bilgilerin YSA' ya alınmasını sağlar. Diğer katman ise ağ içerisinde işlenen bilginin dışarıya iletildiği çıktı katmanıdır. Girdi ve çıktı katmanlarının arasında yer alan katmana ise gizli katman adı verilir. MLP ağlarında birden fazla gizli katman da bulunabilir. Şekil 1, tipik bir MLP ağının yapısını göstermektedir.

Teknik olarak, bir YSA'nın en temel görevi, örnek veri setindeki yapıyı öğrenerek, istenilen görevi yerine getirecek şekilde genelleştirmeler yapmasıdır. Bunun yapılabilmesi için ağ, ilgili olayın örnekleri ile eğitilerek genelleme yapılabilecek yeteneğe kavuşturulur(Öztemel, 2003: 30).

MLP ağlarının zaman serisi tahmininde kullanılabilmesi için ağın yapısının belirlenmesi gerekmektedir. Ağ yapısının belirlenme süreci, ağın kaç katmandan oluşacağını, her katmanda kaç işlem elemanı bulunacağını, bu işlem elemanlarının hangi transfer fonksiyonuna sahip olacağını belirlenmesi işlemlerini kapsar. Kaç dönemlik tahmin yapılacağına bağlı olarak çıkış nöron sayısı belirlenir. Girişte kullanılacak nöron sayısını belirlemek çıkış nöron sayısını belirlemek kadar kolay değildir, çünkü serinin t zamandaki değerinin geçmiş kaç gözlem değerinden etkilendiğinin belirlenmesi kritik bir sorudur ve bu sorunun cevabı girdi işlem elemanı sayısının kaç olacağını göstermektedir. Girdi işlem elemanı sayısını belirlenmesine ilişkin çeşitli görüşler olmasına karşın genel bir kural bulunmamaktadır. Zaman serisi modellemede genellikle tek gizli katmana sahip ağ yapıları kullanılmaktadır. Çıkış değeri (y_t) ile geçmiş N gözlem değerlerinden oluşan girişler($y_{t-1}, y_{t-2}, \dots, y_{t-N}$) arasındaki ilişki eşitlik 2' de verilmiştir.

$$y_t = w_o + \sum_{j=1}^p w_j f\left(v_{0j} + \sum_{i=1}^N v_{ij} y_{t-i}\right) + e_t \quad (2)$$

Eşitlikte; w_j, v_{ij} nöronlar arasındaki ağırlık değerlerini, p gizli nöron sayısını, f ise gizli katmanda kullanılan doğrusal olmayan aktivasyon fonksiyonunu göstermektedir. En çok kullanılan aktivasyon fonksiyonları sigmoid(3) ve hiperbolik tanjant(4) fonksiyonlarıdır.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

C. Melez Model

Birçok zaman serisi doğrusal ilişkinin yanında doğrusal olmayan ilişkilerde içermektedir. ARIMA modelleri zaman serisindeki doğrusal ilişkiyi iyi bir şekilde modellerken, doğrusal olmayan ilişkileri modellemede yetersiz kalmaktadır. Yapay sinir ağları ise hem doğrusal hem de doğrusal olmayan ilişkileri modelleyebilmesine karşın, her veri seti için aynı etkinlikte sonuçlar sağlayamamaktadır. Melez modeller zaman serilerindeki doğrusal ve doğrusal olmayan bileşenlerin ayrı ayrı modellenmesi prensibine dayanır. Bir zaman serisi eşitlik 5' de gösterildiği gibi doğrusal ve doğrusal olmayan bileşenlerin toplamı şeklinde ifade edilebilir.

$$y_t = L_t + N_t \quad (5)$$

L_t zaman serisinin doğrusal bileşenini gösterirken, N_t ise doğrusal olmayan bileşeni göstermektedir. Melez yaklaşımda ilk olarak zaman serisinin doğrusal bileşeni L_t ARIMA modeli kullanılarak tahmin edilir. Daha sonra gözlenen değerlerden ARIMA modeliyle elde edilen tahmin değerleri çıkarılarak eşitlik 6 da gösterildiği gibi kalıntılar hesaplanır.

$$e_t = y_t - \hat{L}_t \quad (6)$$

\hat{L}_t , t zamanı için ARIMA modelinden elde edilen tahmin değeridir. Tüm doğrusal bileşenlerin ARIMA tarafından modellendiği varsayımı altında, kalıntılar zaman serisinin doğrusal ilişki içermeyen bölümünü olarak kabul edilir. Modelin ikinci aşamasında doğrusal olmayan ilişkileri içeren kalıntılar uygun yapay sinir ağı modeli kullanılarak tahmin edilir. ARIMA ve YSA modelleri kullanılarak bulunan tahminler birleştirilerek melez modelin tahminleri eşitlik 7 yardımıyla elde edilir

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (7)$$


III. Uygulama ve Sonuçlar

Çalışmada kullanılan veriler, T.C. Merkez Bankasının elektronik veri dağıtım sisteminden alınan ve İstanbul Ticaret Odası'nın (İTO) hazırladığı Ocak 1999 ile Mayıs 2008 tarihleri arasındaki aylık Toptan Eşya Fiyat Endeksi (TEFE) serisidir.

Farklı yöntemlerin tahmin performanslarını karşılaştırmak için veri setinin son 14 gözlemi test verisi olarak kullanılmıştır. Ayrıca ilk 80 veri MLP ağları ileri oluşturulan modellerin eğitimi için, sonraki 19 veri ise ağların eğitimi sırasında oluşabilecek ezberleme problemine karşın doğrulama verisi olarak ayrılmıştır. Veriler düzenlendikten sonra ARIMA, MLP ve Melez modelleri kurularak test verileri tahmin edilmiştir. Tahmin sonuçlarından hareketle Melez model diğer iki modelle karşılaştırılmıştır.

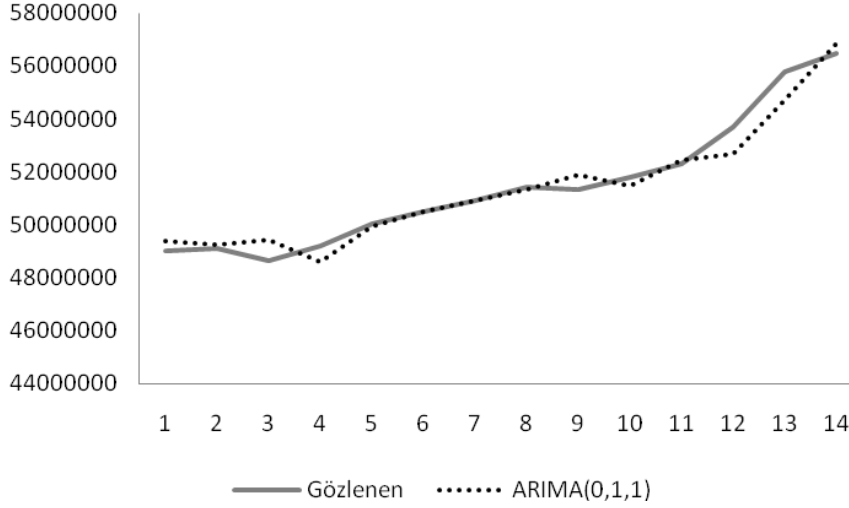
Çalışmamızda iki farklı yöntem için MLP modelleri oluşturulmuştur. İlk yöntem için oluşturulan modeller orijinal zaman serisini tahmin etmek amacıyla, diğer yöntem için oluşturulan modeller ise ARIMA modelinden elde edilen kalıntıları tahmin etmek için kullanılmıştır. Çalışma kapsamında oluşturulan tüm MLP modelleri 1 adet gizli katmandan oluşan 3 katmanlı bir mimariye sahiptir. Matlab ortamında gerçekleştirilen bir yazılımla, giriş ve gizli katmandaki nöron sayıları değiştirilerek 200 farklı yapay sinir ağı modeli elde edilmiştir.

Zaman serisinin YSA kullanılarak tahmin edildiği yöntemde, veriler ağın yapısına uygun hale getirilerek; gerekli giriş ve çıkış vektörleri oluşturulmuş, elde edilen bu vektörler ağa sunularak ağın öğrenme işlemi gerçekleştirilmiştir. Kurulan tüm YSA modelleri içerisinde test verileri için en küçük hata kareleri ortalaması(MSE) ve ortalama mutlak yüzde hata (MAPE) değerini veren MLP modeli seçilmiştir. Sonuçta giriş nöron sayısı 3, gizli nöron sayısı 5 olan MLP modeli en uygun model olarak belirlenmiştir. 3x5x1 MLP ağının tahmin değerleri ile serinin gözlenen değerleri Şekil 2' de verilmiştir.



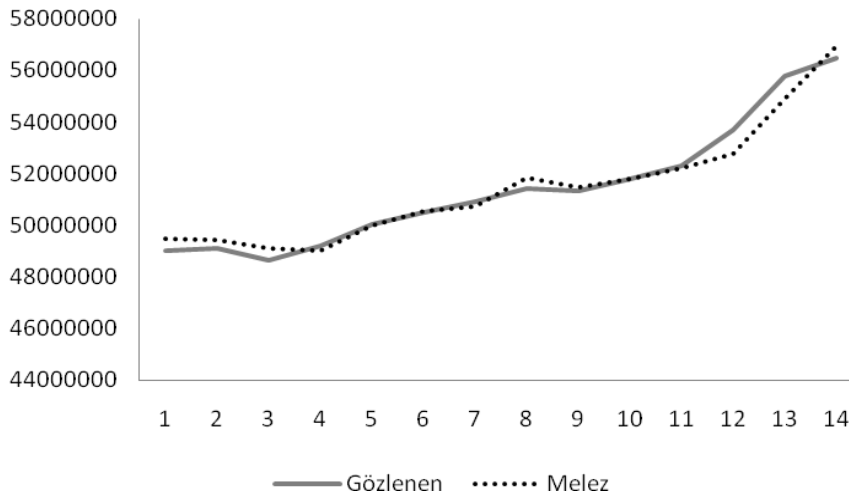
Şekil 2: MLP Modeli Tahminleri ve Gözlenen Değerler

ARIMA modelinin oluşturulması için durağan olmayan veri seti fark alma yöntemiyle durağan hale getirilmiş, AR ve MA terimlerinin belirlenmesi için kısmi-otokorelasyon ve otokorelasyon fonksiyonları kullanılmıştır. Oluşturulan modeller içerisinde MSE ve MAPE kriterleri kullanılarak yapılan karşılaştırma sonucunda veri setine en uygun olan modelin ARIMA(0,1,1) modeli olduğu belirlenmiş ve zaman serisinin tahmini için kullanılmıştır. Elde edilen sonuçlar Şekil 3' de verilmiştir.



Şekil 3: ARIMA Modeli Tahminleri ve Gözlenen Değerler

ARIMA modelinin tahmin değerleri gözlenen değerlerinden çıkarılarak kalıntılar hesaplanmış ve bu değerler melez yöntemde yer alan YSA modeli için kullanılmıştır. Kalıntıların tahmininde giriş nöron sayısı 8, gizli nöron sayısı 5 olan MLP modeli kullanılmıştır. Sonuçta YSA'nın ürettiği kalıntı tahminleri ARIMA(0,1,1) modelinin tahminleriyle toplanarak Melez modelin tahminleri hesaplanmış ve Şekil 4' de gösterilmiştir.



Şekil 4: Melez Model Tahminleri ve Gözlenen Değerler

Uygulama sonuçları Tablo 1’ de verilmiştir. Tablo 1 incelendiğinde MLP, ARIMA ve Melez modellerinin MSE değerleri sırasıyla 311334413593,42, 276874340368,45 ve 190335944395,79 olarak hesaplanmıştır. MSE değerleri dikkate alındığında Melez modelin daha iyi sonuç verdiği görülmektedir. MAPE değerlerine bakıldığında ise MLP için 0,938814, ARIMA için 0,7572957 ve Melez model içinse 0,6279367 olduğu görülmektedir. Benzer şekilde MAPE değerleri açısından yapılan kıyaslamada da Melez modelin diğer iki modele göre daha iyi sonuçlar verdiği gözlemlenmiştir.

Tablo 1: *TEFE Verilerine İlişkin Tahmin ve Gözlenen Değerler*

Gözlenen	MLP	ARIMA(0,1,1)	Melez
49021039.30	49353965.42	49408593.00	49464020.02
49087122.10	48810397.62	49239094.00	49418536.40
48626971.60	49242946.30	49440142.00	49103773.88
49171974.50	48935427.57	48601189.00	49018579.45
50017373.40	50365243.05	49939064.00	49978362.06
50484947.00	50155831.31	50502322.00	50533592.46
50903640.30	50250197.72	50915078.00	50737453.67
51394780.60	51191141.54	51337173.00	51837336.70
51333167.30	51836608.18	51867869.00	51460219.92
51793779.00	51575649.16	51466920.00	51807771.08
52307337.10	52931557.59	52421122.00	52234924.12
53691490.70	52857790.88	52682234.00	52754638.74
55779782.00	54583363.08	54709781.00	54910955.08
56462966.80	55992922.58	56832873.00	56938644.88
MSE	311334413593.42	276874340368.45	190335944395.79
MAPE	0.938814	0.7572957	0.6279367

MSE değerleri dikkate alındığında melez model ARIMA modeli ile yapılan tahminlere göre %45’lik, MLP modeli ile yapılan tahminlere göre de %63’lük bir performans artışı sağlamıştır. Aynı şekilde MAPE kriteri açısından Melez modelden, ARIMA modeline göre %21, MLP modeline göre %50 daha iyi tahmin sonuçları elde edilmiştir.

Literatürdeki çalışmalar zaman serilerini tek bir yöntemle tahmin etmek yerine, veri setindeki farklı fonksiyonel ilişkileri modelleyebilen birden fazla yöntemi birleştirerek tahminler yapmanın daha etkin sonuçlar verdiğini

göstermektedir. Çalışmamız sonucunda elde edilen bulgular da bunu doğrular niteliktedir.

Kaynaklar

- Wedding D.K. ve Cios K.J. (1996), "Time series forecasting by combining RBF networks, certainty factors, and the Box-Jenkins model", *Neurocomputing*, 10, ss.149-168.
- Donaldson, R.G. ve Kamstra, M. (1996), "Forecasting combining with neural networks", *Journal of Forecasting*, 15, ss.49-61.
- Pelikan, E., Groot, C. ve Wurtz, D. (1992) "Power consumption in West-Bohemia: improved forecasts with decorrelating connectionist Networks", *Neural Network World*, 2, ss.701-712.
- Tseng,F.-M.,Yu, H.-C. ve Tzeng, G.-H. (2002),"Combining neural network model with seasonal time series ARIMA model", *Technological Forecasting and Social Change*, 69, ss.71-87.
- Fausett, L. (1994),"Fundamentals of Neural Networks: Architectures, Algorithms and Applications", Prentice Hall.
- Hansen, J. ve Nelson, R. (2003), "Time-series analysis with neural Networks and ARIMA-neural network hybrids", *Journal of Experimental and Theoretical Artificial Intelligence*, 15(3), ss.315-330.
- Hippert, H.S., Pedreira, C.E. ve Souza, R.C. (2001), "Neural networks for short-term load forecasting: a review and evaluation", *IEEE Transactions on Power System*, 16, ss.44-55.
- Ginzburg, I. ve Horn, D. (1994), "Combined neural networks for time series analysis", *Adv. Neural Inf. Process. Systems*, 6, ss.224-231.
- Öztemel, Ercan (2003),"Yapay Sinir Ağları, Papatya Yayıncılık", İstanbul.
- Zhang G. P. (2003) ,"Time series forecasting using a hybrid ARIMA and neural network model", *Neurocomputing*, 50, ss.159-175.
- Zhang, G., Patuwo, B. E. ve Hu, M. Y. (1998) "Forecasting with artificial neural networks: the state of the art", *International Journal of Forecasting*, 14, ss.35-62.