

ZAMAN SERİSİ ANALİZİNDE MLP YAPAY SİNİR AĞLARI VE ARIMA MODELİNİN KARŞILAŞTIRILMASI

Oğuz KAYNAR *
Serkan TAŞTAN **

ÖZ

Bu çalışmada zaman serisi analizinde yaygın olarak kullanılan Box-Jenkins modelleri ile ileri beslemeli yapay sinir ağlarının bir karşılaştırması yapılmıştır. Veri seti olarak aylık ve günlük döviz (YTL/\$) kuru verileri kullanılmıştır. Farklı Box-Jenkins ve yapay sinir ağları modelleri oluşturulmuş, her bir teknik için en iyi sonuçları veren modeller seçilerek karşılaştırma yapılmıştır. Elde edilen sonuçlar Yapay sinir ağlarının finansal verilerin tahmininde kullanılabilir bir yöntem olduğunu göstermiştir.

Anahtar kelimeler: Yapay sinir ağları, ARIMA, Zaman serileri, Tahmin.

COMPARASION OF MLP ARTIFICAL NEURAL NETWORK AND ARIMA METHOD IN TIME SERIES ANALYSIS

ABSTRACT

In this study, Box-Jenkins methods commonly used in time series analysis and Artificial neural network were compared. Monthly and daily exchange rates (YTL/\$) were used as data set. Different Box-Jenkins and artificial neural network models were created and best performed models were chosen to compare both techniques. Results show that artificial neural network is a successful method for forecasting financial data.

Keywords: Artificial Neural Network, ARIMA, Time series, Forecasting.

* Yrd. Doç. Dr. Cumhuriyet Üniversitesi, İİBF, Yönetim Bilişim Sistemleri Bölümü

** Arş. Gör., Cumhuriyet Üniversitesi, İİBF, Yönetim Bilişim Sistemleri Bölümü
Makalenin kabul tarihi: Temmuz 2009

GİRİŞ

Zaman serisi herhangi bir olaya ilişkin gözlem değerlerinin zamana göre sıralanmasıyla oluşturulan dizilerdir. Zaman serileri analizi ise, belirli zaman aralıklarında gözlenen bir olay hakkında, gözlenen serinin yapısını veren stokastik süreci modellemeyi ve geçmiş dönemlere ilişkin gözlem değerleri yardımıyla geleceğe yönelik tahminler yapmayı amaçlayan bir metottur. İşletme, ekonomi ve finans alanında yaygın olarak kullanılan zaman serileri analizi ile yapılan tahminler, gerek ülke ekonomisi gerekse işletme temelinde yapılacak geleceğe yönelik planlama çalışmaları açısından son derece önemlidir.

Zaman serileri analizinde kullanılan birçok yöntem vardır. Box-Jenkins yöntemi, doğrusal zaman serilerinin analizinde en bilinen ve en çok kullanılan metotlardan biridir. Doğrusal ve durağan süreçlerde ya da durağan olmayan fakat çeşitli istatistiksel yöntemlerle durağanlaştırılabilen serilerde Box-Jenkins yöntemi başarıyla uygulanabilir. Ancak birçok zaman serisi doğrusal ilişkinin yanı sıra doğrusal olmayan ilişki de içerir. Doğrusal olmayan bu ilişkiyi modelleyebilecek farklı yöntemlere gereksinim duyulmaktadır. Yapısında bulunan aktivasyon fonksiyonun özelliğine bağlı olarak hem doğrusal hem de doğrusal olmayan ilişkileri modelleyebilen yapay sinir ağları (YSA) son yıllarda zaman serilerinin analizinde kullanılan alternatif yöntemlerden biri haline gelmiştir.

Yapay sinir ağlarının döviz kuru tahmininde kullanılmasına ilişkin literatürde birçok çalışma mevcuttur. Weigend ve diğerleri Alman Markı ile Amerikan Doları arasındaki çapraz kur değerini yapay sinir ağları ve rassal yürüyüş modeli ile tahmin etmişler ve yapay sinir ağlarının rassal yürüyüş modelinden daha iyi sonuçlar verdiğini göstermişlerdir (Weigend vd.,1992). Kuan ve Liu Amerikan Dolarına karşı beş değişik çapraz kuru (İngiliz Sterlini, Kanada Doları, Alman Markı Japon Yeni, İsviçre Fransı) ileri ve geri beslemeli yapay sinir ağları kullanarak tahmin etmişlerdir (Kuan ve Liu,1995). Avusturya Dolarına ilişkin altı farklı çapraz kurun ARIMA ve yapay sinir ağları modelleri kullanılarak tahmin edildiği bir çalışma da Kamruzzaman ve Sarker tarafından yapılmıştır. Bu çalışma sonucunda Kamruzzaman ve Sarker, yapay sinir ağları ile yapılan tahminlerin ARIMA modeli ile yapılan tahminlerden daha iyi sonuç verdiğini tespit etmişlerdir. ARIMA ve YSA modellerinin döviz kuru tahminine uygulandığı diğer bir çalışma ise yine yapay sinir ağlarının daha iyi netice verdiğini görmüştür (Wu,1995). Han ve Steurer Amerikan Doları ve Alman Markının çapraz kur tahmininde doğrusal modeller ile yapay sinir ağlarını karşılaştırmışlar; aylık verilerle yapılan uygulamada çok belirgin fark görülmesi de haftalık veriler kullanılarak yapılan uygulamada YSA modellerinin doğrusal modellere göre çok daha iyi sonuçlar verdiğini belirtmişlerdir (Han ve Steurer,1996). Zhang ve Hu giriş nöron sayısı ve gizli nöron sayısını değiştirerek farklı YSA modelleri oluşturmuşlar ve değişik büyüklükteki veri setlerini bu modellere uygulayarak, farklı yapıdaki ağların ve örnek büyüklüğünün tahmin performansı üzerindeki etkilerini incelemişlerdir (Zang ve Hu 1998). Ayrıca, yapay sinir

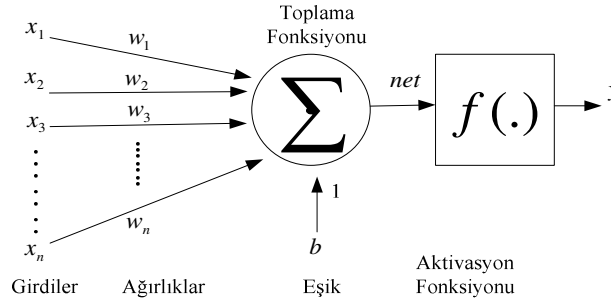
ağlarının zaman serilerinin tahmininde kullanıldığı çalışmalara ilişkin geniş bir derleme Zhang vd tarafından yapılmıştır (Zhang vd., 1998).

Bu çalışmada aylık ve günlük bazda döviz kuru(YTL/\$) verileri kullanılarak farklı ARIMA ve MLP yapay sinir ağı modelleri oluşturulmuş ve her iki veri seti için en iyi sonuçları veren modeller seçilerek iki tekniğin karşılaştırılması için kullanılmıştır.

I. YAPAY SINİR AĞLARI

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). Basit bir şekilde insan beyninin çalışma şeklini taklit eden YSA'lar veriden öğrenebilme, genelleme yapabilme, sınırsız sayıda değişkenle çalışabilme vb. birçok önemli özelliğe sahiptir. YSA'nın çalışmasına esas teşkil eden en küçük birimler yapay sinir hücresi ya da işlem elemanı olarak isimlendirilir. En basit yapay sinir hücresi Şekil 1 de de görüleceği üzere girdiler, ağırlıklar, birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıkış olmak üzere 5 ana bileşenden oluşmaktadır.

Şekil 1: Yapay Sinir Hücresi



Girdiler (x_1, x_2, \dots, x_n), diğer hücrelerden ya da dış ortamlardan hücreye giren bilgilerdir. Bunlar ağıın öğrenmesi istenen örnekler tarafından belirlenir. Ağırlıklar (w_1, w_2, \dots, w_n), girdi kümesi veya kendinden önceki bir tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden değerlerdir. Her bir girdi, o girdiyi işlem elemanına bağlayan ağırlık değeriyle çarpılarak, toplam fonksiyonu aracılığıyla birleştirilir. Toplam fonksiyonu Eşitlik 1 de verildiği şekildedir.

$$net = \sum_{i=1}^n w_i x_i + b \quad (1)$$

Toplam fonksiyonu sonucunda elde edilen değer doğrusal ya da doğrusal olmayan türevlenebilir bir transfer fonksiyonundan geçirilerek işlem elemanının çıktısı hesaplanır.

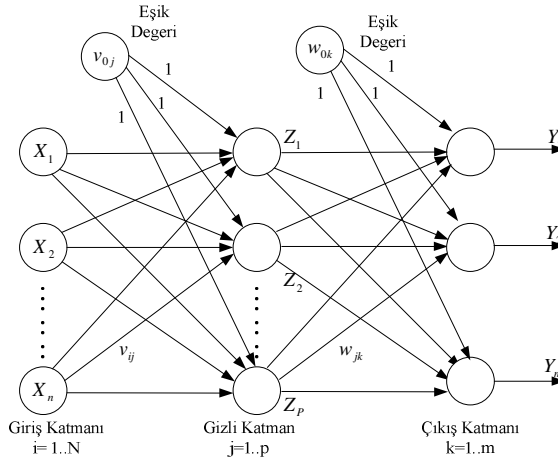
$$y = f(\text{net}) = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (2)$$

Yapay sinir ağlarında çok çeşitli ağ yapıları ve modelleri vardır. Yapay sinir ağı, Şekil 1 de gösterilen bir dizi sinir hücresinin ileri sürümlü ve geri beslemeli bağlantı şekilleri ile birbirine bağlanmasından oluşur. Günümüzde, belirli amaçlarla ve değişik alanlarda kullanılmaya uygun birçok yapay sinir ağı modeli (Perceptron, Adaline, MLP, LVQ, Hopfield, Recurrent, SOM, ART vb.) geliştirilmiştir. Bu ağ yapıları içerisinde en yaygın kullanım alanı bulan ve çalışmamızda da kullanılan çok katmanlı ileri beslemeli yapay sinir ağıdır. (Multiple Layer Perceptron-MLP)

A. ÇOK KATMANLI İLERİ BESLEMELİ YAPAY SİNİR AĞLARI (MLP)

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 2, tipik bir MLP ağının yapısını göstermektedir.

Şekil 2: Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı



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). YSA'nın öğrenmesi, işlem elemanlarının sahip olduğu ağırlıkların, seçilen eğitim algoritmalarıyla değiştirilmesi ile yapılmaktadır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı MLP ağlarının eğitiminde geri yayılım (Backpropagation) algoritması kullanılmaktadır. Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Geri yayılım algoritması danışmanlı öğrenme yapısına sahip ve birçok uygulamada kullanılmış en yaygın öğrenme algoritmasıdır. Danışmanlı öğrenme algoritmalarında ağın eğitimi için, ağa örnek olarak girdi ve çıktı değerlerden oluşan bir örnek veri seti verilir. Verilen hedef çıktı değerleri, YSA literatüründe danışman ya da öğretmen olarak adlandırılır. Danışmanlı öğrenme algoritmalarında öğrenme aşamasında ağırlıklar, Eşitlik 3 de verilen hata fonksiyonunun minimize edilmesiyle düzenlenir.

$$E = \frac{1}{2} \sum_{k=1}^m (y_k - t_k)^2 \quad (3)$$

Eşitlikte y_k ağın ürettiği çıktıyı t_k ise gerçek çıktı değerini göstermektedir. Hatayı en aza indirmek için bağlantı ağırlıkları yeniden düzenlenerek güncellenir. Böylece ağın gerçek çıktı değerlerine en yakın çıktı değerlerini üretmesi amaçlanır. Geri yayılım algoritmasının detayı için (Fauset, 1994:294-296) incelenebilir.

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 belirlemek 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. Tang ve Fishwick, girdi işlem elemanı sayısının ARIMA (p,d,q) modelindeki p derecesine eşit alınması gerektiğini söylemektedir (Tang ve Fishwick, 1993). Fakat Zhang bu yaklaşımın MA modellerinin AR terimi içermemesi ve Box-Jenkins modellerinin doğrusal modeller olması nedeniyle uygun olmadığını, girdi işlem elemanı sayısının deneme yanılma yoluyla belirlenebileceğini ifade etmektedir (Zang vd., 1998). Yapılan çalışmalar incelendiğinde genellikle tek gizli katmana sahip ağ yapılarının tercih edildiği, gizli katmanda farklı nöron sayılarının

kullanıldığı, çıkış katmanında doğrusal aktivasyon fonksiyonun (4) , gizli katmanda ise sigmoid aktivasyon fonksiyonunun(5) kullanıldığı görülmüştür.

$$f(x) = x \quad (4)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

II. BOX-JENKİNS METODOLOJİSİ VE ARIMA MODELLERİ

Box-Jenkins yöntemi tek değişkenli zaman serilerinin ileriye dönük tahmin ve kontrolünde kullanılan istatistiksel öngörü yöntemlerinden biridir. Zamana bağlı olayların rassal karakterde olaylar, bu olaylarla ilgili zaman serilerinin ise stokastik süreç olduğu varsayımına dayanarak geliştirilmiş olan bu yöntemin uygulandığı zaman serisinin eşit aralıklı gözlem değerlerinden oluşan kesikli ve durağan bir seri olduğu varsayılmaktadır. Ancak gerçekte zaman serilerinin ortalama ve varyansında zamana bağlı olarak bir değişim olmaktadır. Durağan olmayan zaman serilerinde görülen bu değişim, genellikle trend, düzenli, düzensiz dalgalanmalar ve tesadüfi dalgalanmaların etkisiyle gerçekleşir. Durağan olmayan zaman serilerinin Box-Jenkins yöntemiyle öngörüsü için seri bazı dönüşüm yöntemleriyle durağan hale getirilmelidir.

Box-Jenkins Yöntemi ile öngörü dört aşamada gerçekleştirilmektedir.

1. Model Belirleme: Zaman serisine uygun Box-Jenkins modeli bu aşamada belirlenir.
2. Parametre Tahmini: Model belirleme aşamasında belirlenen modele ilişkin parametrelerin tahmin edildiği aşamadır.
3. Uygunluğun Testi: Modelin veri setine uygunluğunun istatistiksel yöntemlerle test edildiği bu aşamada model uygun bulunursa son aşamaya geçilir, uygun bulunmazsa başka bir modelin belirlenmesi için ilk aşamaya dönlür.
4. Tahmin: Seçilen en uygun model tahmin için kullanılır.

Box-Jenkins Yöntemi ile tahmin edilen zaman serisi modelleri; Otoregresif (AR) Modeli, Hareketli Ortalama (MA) Modeli, Otoregresif-Hareketli Ortalama (ARMA) Modeli ve Otoregresif Bütünleşik Hareketli Ortalama (ARIMA) Modelidir.

ARIMA modelleri, durağan olmayan ancak fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modellerdir. Durağan olmayan ancak fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modellere “durağan olmayan doğrusal stokastik modeller” denir. Bu modeller d dereceden farkı alınmış serilere uygulanan, değişkenin t-dönemindeki değerinin belirli sayıdaki geri dönem değerleri ile aynı dönemdeki hata teriminin doğrusal bir

fonksiyonu olarak ifade edildiği AR ve değişkenin t-dönemindeki değerinin 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.

$$Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + \delta + a_t - \Theta_1 a_{t-1} - \Theta_2 a_{t-2} - \dots - \Theta_q a_{t-q} \quad (6)$$

Burada $Z_t, Z_{t-1}, \dots, Z_{t-p}$ 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.

UYGULAMA VE SONUÇLAR

Çalışmada kullanılan veriler, T.C. Merkez Bankasının elektronik veri dağıtım sisteminden alınan Ocak 2000 ile Haziran 2008 arasındaki günlük ve aylık döviz kuru (YTL/\$) değerleridir. MLP ve ARIMA modelleri için her iki veri setinin son 10 gözlemi yapılan tahminleri test etmek için kullanılmıştır. MLP modellerinde kalan verinin %80 i eğitim %20 si ise doğrulama verisi olarak ayrılmıştır.

Bu çalışmada yapay sinir ağları modellerinin oluşturulması için Matlab(ver. 2007a) programı kullanılarak bir yazılım geliştirilmiştir. Çalışma kapsamında oluşturulan tüm MLP modelleri giriş katmanı, çıkış katmanı ve 1 adet gizli katmandan oluşan 3 katmanlı bir mimariye sahiptir. Gerçekleştirilen yazılım sayesinde giriş nöron sayısı ve gizli katmanda kullanılan nöron sayıları 1 den 10 ' a kadar değiştirilerek 100 farklı yapay sinir ağı modeli elde edilmiştir. Veriler MLP ile oluşturulan ağlara girilmeden önce ağın yapısına uygun hale getirilerek; gerekli giriş ve çıkış vektörleri oluşturulmuştur. Eğitim verileri ağa sunularak ağın öğrenme işlemi gerçekleştirilmiş bu yüz model içerisinde test verileri için en küçük hata kareleri ortalaması (MSE) ve ortalama mutlak yüzde hata (MAPE) değerini veren yapay sinir ağı modeli seçilmiştir. Aylık veriler için giriş nöron sayısı 1, gizli nöron sayısı 3, günlük veriler için ise giriş nöron sayısı 5, gizli nöron sayısı 10 olan MLP modeli en uygun model olarak seçilmiştir.

Veri setine uygun Box-Jenkins modelinin belirlenmesi için Eviews (ver.5.1) yazılımı kullanılarak serilerin durağanlığı incelenmiş ve sonuçlar Tablo 1 ve Tablo 2' de verilmiştir. Durağanlık testi sonuçlarına göre durağan olmayan seriler fark alma yöntemiyle durağan hale getirilmiştir.

Tablo1: Günlük Döviz Kuru İçin Durağanlık Testi Sonuçları

Augmented Dickey-Fuller Birim Kök Testi Sonuçları							
Günlük Döviz Kuru	Sabit		Sabit ve Trend		Sabitsiz-Trendsiz		
	Seviye	1.Fark	Seviye	1.Fark	Seviye	1.Fark	
Gecikme	2	1	2	1	2	1	
ADF Test istatistiği	-2.6161	-36.874	-1.8550	-36.971	0.4769	-36.857	
MacKinnon Kritik Değerleri	%1	-3.4332	-3.4332	-3.9623	-3.9623	-2.5660	-2.5660
	%5	-2.8627	-2.8627	-3.4119	-3.4119	-1.9409	-1.9409
	%10	-2.5674	-2.5674	-3.1278	-3.1278	-1.6165	-1.6165
Phillips-Perron Birim Kök Testi Sonuçları							
Günlük Döviz Kuru	Sabit		Sabit ve Trend		Sabitsiz-Trendsiz		
	Seviye	1.Fark	Seviye	1.Fark	Seviye	1.Fark	
Bandwidth	1	4	1	6	2	4	
ADF Test istatistiği	-2.5646	-42.379	-1.9270	-42.4589	0.3947	-42.3704	
MacKinnon Kritik Değerleri	%1	-3.4332	-3.4332	-3.9623	-3.9623	-2.5660	-2.5660
	%5	-2.8626	-2.8627	-3.4119	-3.4119	-1.9409	-1.9409
	%10	-2.5674	-2.5674	-3.1278	-3.1278	-1.6165	-1.6165

Tablo2: Aylık Döviz Kuru İçin Durağanlık Testi Sonuçları

Augmented Dickey-Fuller Birim Kök Testi Sonuçları							
Aylık Döviz Kuru	Sabit		Sabit ve Trend		Sabitsiz-Trendsiz		
	Seviye	1.Fark	Seviye	1.Fark	Seviye	1.Fark	
Gecikme	1	0	1	0	1	0	
ADF Test istatistiği	-2.6798	-6.7439	-2.1884	-6.9808	0.1339	-6.7246	
MacKinnon Kritik Değerleri	%1	-3.4977	-3.4977	-4.0533	-4.0533	-2.5885	-2.5885
	%5	-2.8909	-2.8909	-3.4558	-3.4558	-1.9441	-1.9441
	%10	-2.5825	-2.5825	-3.1537	-3.1537	-1.6145	-1.6145
Phillips-Perron Birim Kök Testi Sonuçları							
Aylık Döviz Kuru	Sabit		Sabit ve Trend		Sabitsiz-Trendsiz		
	Seviye	1.Fark	Seviye	1.Fark	Seviye	1.Fark	
Bandwidth	2	2	0	4	3	2	
ADF Test istatistiği	-2.6011	-6.6893	-1.8549	-6.8383	0.3180	-6.6705	
MacKinnon Kritik Değerleri	%1	-3.4970	-3.4977	-4.0524	-4.0533	-2.5882	-2.5885
	%5	-2.8906	-2.8909	-3.4553	-3.4558	-1.9440	-1.9441
	%10	-2.5823	-2.5825	-3.1534	-3.1537	-1.6146	-1.6145

ARIMA modellerinin AR terimlerinin belirlenmesi için kısmi-otokorelasyon, MA terimlerinin belirlenmesi içinse otokorelasyon fonksiyonları kullanılmıştır. MSE, MAPE, AIC ve SBC kriterleri karşılaştırılarak hem günlük hem aylık veriler için oluşturulan modeller içerisinde veri setine en uygun olan model belirlenmiştir. Sonuç olarak bu modeller içerisinde günlük veriler için sabit terim içermeyen ARIMA(2,1,0), aylık veriler içinse yine sabit terim içermeyen doğal logaritmik dönüşüm yapılmış ARIMA(0,1,1) modelinin kullanılması uygun görülmüştür. Modellere ilişkin parametre tahminleri ve istatistikler Tablo 3 ve Tablo 4'de verilmiştir.

Tablo3: ARIMA Modellerine İlişkin Parametre Tahminleri

	Değişken	Katsayı	Standart Hata	t-istatistiği	p
ARIMA(2,1,0)	AR(1)	0,0933	0,0214	4,3571	0,000
	AR(2)	-0,1644	0,0214	-7,6744	0,000
ARIMA(0,1,1)	MA(1)	0,5396	0,0855	6,3081	0,000


Tablo4: ARIMA Modellerine İlişkin İstatistikler


		ARIMA(2,1,0)	ARIMA(0,1,1)
Regresyonun Standart Hatası		0,015089	0,045680
Akaike Bilgi Kriteri (AIC)		-5,548693	-3,324346
Schwarz Kriteri (SBC)		-5,543359	-3,298294
Q İstatistiği	İstatistik	16,493	12,354
	sd	16	17
	p	0,419	0,778

Çalışma sonucunda her iki veri seti için elde edilen sonuçlar Tablo 5'te verilmiştir. Tablo 5 incelendiğinde aylık veriler için ARIMA ve MLP modellerinin MSE ve MAPE değerleri sırasıyla (0.00174176-2.65680133), (0.00182647-3.27050090) ,günlük veriler için ise (0.00008140-0.67077165), (0.00007166-0.61651801) şeklinde bulunmuştur. Her iki veri seti içinde ARIMA ve MLP modelleri MSE ve MAPE performans ölçülerine göre karşılaştırıldığında birbirine yakın sonuçlar vermiştir. Aylık döviz kuru veriler için ARIMA(0,1,1) modeli daha düşük MSE ve MAPE değerlerine sahipken, günlük döviz kuru verileri içinse MLP modeli ARIMA(2,1,0) modelinden daha düşük MSE ve MAPE değerlerine sahiptir. Bu sonuçlar daha önce yapılmış benzer çalışmalarla paralellik sergilemekte ve eğitimde kullanılan veri sayısı artıkça yapay sinir ağlarının daha iyi sonuç verdiğini göstermemektedir. Sonuç olarak uygun ağ yapısı ve yeterli sayıda veri kullanıldığında, finansal verilerin tahmininde yapay sinir ağları istatistiksel yöntemlere alternatif bir yöntem olarak kullanılabilir.

Tablo5: Aylık Döviz Kuru İçin Gözlenen Ve Tahmin Edilen Değerler

AYLIK			GÜNLÜK		
Gözlenen	ARIMA(0,1,1)	MLP	Gözlenen	ARIMA(2,1,0)	MLP
1.31460	1.26873	1.28214	1.25080	1.24292	1.24489
1.26739	1.34199	1.31275	1.24370	1.25050	1.24890
1.20237	1.23113	1.26955	1.24850	1.24182	1.24238
1.19046	1.18915	1.22690	1.24820	1.25011	1.24938
1.17863	1.19307	1.22138	1.23480	1.24738	1.24870
1.17609	1.17285	1.21654	1.22140	1.23360	1.23243
1.19390	1.17972	1.21558	1.21250	1.22235	1.22083
1.23833	1.20349	1.22291	1.22550	1.21387	1.21392
1.30297	1.25942	1.24779	1.23080	1.22817	1.22729
1.25563	1.32904	1.30142	1.23970	1.22916	1.23047
MSE	0.00174176	0.00182647	MSE	0.00008140	0.00007166
MAPE	2.65680133	3.27050090	MAPE	0.67077165	0.61651801

Şekil 3: Aylık Döviz Kuru İçin Gözlenen ve Tahmin Edilen Değerlerin Grafiği

Şekil 4:Günlük Döviz Kuru İçin Gözlenen ve Tahmin Edilen Değerlerin Grafiği

KAYNAKÇA

- FAUSETT, Laurene; (1994), **Fundamentals of Neural Networks: Architectures, Algorithms and Applications**, Prentice Hall.
- HANN, Tae Horn ve STEURER, Elmar; (1996), “Much Ado About Nothing? Exchange Rate Forecasting: Neural Networks Vs. Linear Models Using Monthly And Weekly Data”, **Neurocomputing**, Vol. 10, ss.323–339.
- KAMRUZZAMMAN, Joarder ve SARKER, Ruhul A.; (2003), “Forecasting of Currency Exchange Rates using ANN: A Case Study”, Proc. IEEE **International Conference on Neural Networks & Signal Processing (ICNNSP03)**, Nanjing, China, ss.793-797.
- KUAN, Chung Ming ve LIU, Tung; (1995), “Forecasting Exchange Rates Using Feedforward And Recurrent Neural Networks”, **Journal of Applied Econometrics**, Vol. 10, pp. 347–364.
- ÖZTEMEL, Ercan; (2003), **Yapay Sinir Ağları**, Papatya Yayıncılık, İstanbul.
- TANG, Zaiyong ve FISHWICK, Paul A.; (1993), “Feedforward Neural Nets As Models For Time Series Forecasting”, **ORSA Journal on Computing**, 5(4), ss.374–385.
- WEIGEND, Andreas S., HUBERMAN, Barnardo A. ve RUMELHART, David E.; (1992), “Predicting sunspots and exchange rates with connectionist Networks In Nonlinear modeling and forecasting”, **Addison-Welsey**, ss. 395–432.
- WU, Berlin; (1995), “Model-Free Forecasting For Nonlinear Time Series (With Application to Exchange Rates)”, **Computational Statistics and Data Analysis**, Vol.19, ss. 433–459.
- ZHANG, Gioqinang ve HU, Michael Y. ;(1998), “Neural Network Forecasting of the British Pound/US Dollar Exchange Rate”, **OMEGA: Int. Journal of Management Science**, Vol. 26, ss. 495-506.
- ZHANG, Gioqinang, PATUWO, B. Eddy ve HU, Michael Y., (1998) “Forecasting With Artificial Neural Networks: The State Of The Art”, **International Journal of Forecasting**, Vol.14, ss.35-62.