

DÖVİZ KURU ÖNGÖRÜ PERFORMANSI İÇİN ALTERNATİF BİR YAKLAŞIM: YAPAY SİNİR AĞI

Şenol ALTAN*

Öz:

Yapay sinir ağları (YSA) çok değişkenli ve değişkenler arasındaki karmaşık, karşılıklı etkileşimin bulunduğu veya tek bir çözüm kümesinin bulunmadığı durumlarda başarılı sonuçlar üreten bir yapay zekâ teknolojisidir. Yapay sinir ağları, özellikle günümüze kadar çözümü güç ve karmaşık olan ya da ekonomik olmayan çok farklı alanlardaki problemlerin çözümüne uygulanmış ve genellikle başarılı sonuçlar elde edilerek, kendisine geniş bir uygulama alanı bulmuştur.

Öngörü modellemesi, birçok alanda olduğu gibi ekonomi alanı için de büyük bir önem taşımaktadır. Karar birimlerinin (hükümetler, üreticiler, tüketiciler vb.) davranışları ne olursa olsun, geleceğin doğru bir şekilde öngörülebilmesi, alınan kararların başarısı için vazgeçilmez bir zorunluluktur. Son yıllarda yapay sinir ağları öngörü için kullanılmaya başlanmıştır. Bu çalışmada, Ocak 1987 - Eylül 2007 dönemine ait aylık veriler kullanılarak, oluşturulan döviz kuru hem yapay sinir ağı hem de vektör otoregresif (VAR) modeli çerçevesinde öngörülmüş ve her iki yöntem için elde edilen sonuçların öngörü performansları karşılaştırılmıştır. Ayrıca, bu iki yaklaşımdan elde edilen öngörülerin birleştirilmesi yöntemiyle döviz kuru öngörü başarısının arttığı tespit edilmiştir. Bu çalışmada çok katmanlı ileri beslemeli bir yapay sinir ağı mimarisi ve geri yayılım öğrenme metodu uygulanmıştır.

Anahtar Kelimeler: Yapay sinir ağları, VAR yöntemi, döviz kuru, öngörü

AN ALTERNATIVE APPROACH FOR THE PERFORMANCE OF EXCHANGE RATE PROJECTION: ARTIFICIAL NEURAL NETWORK

Abstract:

Artificial neural network (ANN) is an artificial intelligence technology that produces successful outcomes when there is complex and interaction between multivariate and variables or when there is not only one solution set. Artificial

* Yrd. Doç. Dr., Gazi Üniversitesi, İktisadi ve İdari Bilimler Fakültesi,, Ekonometri Bölümü, saltan@gazi.edu.tr

neural network has been applied to the solution of the problems which are difficult and complex or in fields that are not related to economics, and usually successful outcomes have been achieved, hence gained a wide field of application for itself. Whatever the behavior of the decision-makers (governments, producers, consumers, etc..) it is mandatory to envisage the future in an appropriate manner for the success of the decisions made.

Projection modeling is of great importance for the field of economics as in many fields. During the last years, artificial neural networks have been used for the purposes of projection. In this study, exchange rate, based on the monthly data in the period of January 1987 - September 2007, has been projected within the frame of both artificial neural network and vector autoregressive (VAR) model and projection performances of the results obtained from the two methods have been compared. Besides, by combining the projections through the two approaches, it has been found out that the success of the projections for exchange rate has increased. In this study, a multilayered feed forward artificial neural network architecture and back propagation learning method were applied.

Keywords: Neural networks, VAR method, exchange rate, forecast

GİRİŞ

Öngörü modellemesi pek çok alanda kullanılmaktadır. Özellikle ekonomi alanı içinde de büyük bir önem taşımakta ve oldukça yaygın bir biçimde kullanım bulmaktadır. Öngörülen gelecek karşısında, çeşitli karar birimlerinin (hükümetler, üreticiler, tüketiciler vb.) davranışları da farklı olacaktır. Öngörü performansının başarısı, karar birimlerinin doğru politika uygulayabilmesi için çok önemlidir. Bu önem, öngörü modellemesine olan ilginin artmasına neden olmuştur. Artan bu ilgi, öngörü modellerinin çeşitlenmesini de sağlamıştır.

Büyük ölçekli yapısal ekonometrik modeller, basit regresyon modelleri, Box-Jenkins modelleri ve VAR tekniği gibi birçok ekonometrik ve istatistiksel yöntem, öngörü modellemesinde kullanılmaktadır. Bu bilinen öngörü modelleme teknikleri yaygın olarak kullanılırken, son dönemlerde bazı yeni yöntemler de ön plana çıkmaktadır. Bu tekniklerden biri de yapay sinir ağlarıdır.

Yapay sinir ağları, özellikle günümüze kadar çözümü güç ve karmaşık olan ya da ekonomik olmayan çok farklı alanlardaki problemlerin çözümüne uygulanmış ve genellikle başarılı sonuçlar elde edilerek, kendine geniş bir uygulama alanı bulmuştur.

Bu çalışmada, yapay sinir ağı yöntemi kullanılarak döviz kuru öngörü modelinin performansı incelenmiştir. Ayrıca, yapay sinir ağı tekniğinin öngörü başarısını karşılaştırabilmek amacıyla ekonometride öngörü amaçlı yaygın olarak kullanılan yöntemlerden VAR yöntemi kullanılmış ve elde edilen sonuçlar öngörü performansı başarı ölçütleri çerçevesinde karşılaştırılmıştır. Bunlara ilaveten, döviz kuru öngörü

başarısı yüksek olan bu iki modelin birleştirilmesi ile öngörü başarısının arttırılabileceği ortaya konulmuştur.

I) YAPAY SİNİR AĞLARI YÖNTEM BİLİMİ

Yapay sinir ağları; beynin fizyolojik yapısı, düşünme, hatırlama ve problem çözmeye yeteneklerini bilgisayara aktarma mantığına dayalı bir yapay zekâ teknolojisidir. Yapay sinir ağları, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasından oluşur ve genellikle tabakalar şeklinde düzenlenir.

Literatürde çok tanınan Kohonen (1982), yapay sinir ağını, “yapay sinir ağları, paralel olarak bağlantılı ve çok sayıda basit elemanın gerçek dünyanın nesnelileriyle biyolojik sinir sisteminin benzeri yolla etkileşim kuran, hiyerarşik bir organizasyondur” şeklinde tanımlamıştır.

Haykin (1999) ise, “bir sinir ağı, basit işlem birimlerinden oluşan, deneysel bilgileri biriktirmeye yönelik doğal bir eğilimi olan ve bunların kullanılmasını sağlayan yoğun bir şekilde paralel dağıtılmış bir işlem” olarak tanımlamıştır.

Yapay sinir ağları, biyolojik sinir sisteminden esinlenerek geliştirilmiştir. Biyolojik sinir ağlarının sinir hücrelerinden oluştuğu gibi yapay sinir ağları da yapay sinir hücrelerinden oluşur. Yapay sinir ağları ve biyolojik sinir ağları arasında hem mimarileri hem de yetenekleri yönünden büyük farklılıklar vardır (Zurada, 1992). Yapay sinir ağları, matematiksel bir model oluşturur ve genel bir fonksiyon yaklaşıtrıcı olarak bilinir (Zhang, 1998:35).

II) YAPAY SİNİR AĞLARININ BİLEŞENLERİ

Zhang (1998)’e göre yapay sinir ağlarının yapıları, ağın modelleme yeteneğini belirledikleri için oldukça önemlidirler. Yapay sinir ağının tasarımı aşamasında ağ yapıları arasından uygulamaya en elverişli olanı seçilir. Yapay sinir ağlarının işleyişini yönlendiren bileşenler şu şekilde verilebilir:

Mimari Yapı: Yapay sinir ağları, öncelikle yapay sinir ağ mimarileri açısından sınıflandırılır. Yapay sinir ağ mimarileri, sınırlar arasındaki bağlantıların yönlerine göre ileri beslemeli ve geri beslemeli ağlar olarak iki tür yapı içerirler. Genel olarak çok tabakalı ileri beslemeli bir yapay sinir ağı; girdi tabakası, gizli tabaka ve çıktı tabakası kısımlarından oluşmaktadır. Girdi tabakası; dış dünyadan bilgileri alarak bir sonraki tabakaya yani gizli tabakalara iletirler. Girdi tabakasından gelen bilgiler gizli (ara) tabakada işlenerek çıktı tabakasına gönderilirler. Kaastra (1996)’a göre gizli tabakada bulunan nöronların sayısının seçimi, ağın büyüklüğünün tanımlanması ve performansının bilinmesi açısından oldukça önemlidir. Çıktı tabakası ise; gizli tabakadan gelen bilgileri işleyerek, ağın girdi tabakasından sunulan girdi seti için üretmesi gereken çıktıyı üretirler. Tabakalar, nöron (düğüm) adı verilen birimlerden oluşurlar.

Mimarinin tam olarak belirlenmesi, tabakalardaki nöron sayısına karar verilmesi ile gerçekleşir. Yapay sinir ağlarında nöronlar birbirlerine ağırlıklar ile bağlıdır. İleri beslemeli ağlarda bu bağlantılar tek yönlü ve ileri doğrudur. Aynı tabakanın birimleri arasında bağlantı yoktur.

Öğrenme Algoritması: Yapay sinir ağlarının bir diğer sınıflandırılma kriteri ise, sinir ağlarının danışmanlı ve danışmansız öğrenme algoritmalarına göre olmasıdır. En yaygın kullanılan öğrenme algoritmalarından birisi, geri yayılım (back propagation) algoritmasıdır. Geri yayılım algoritması eldeki veri ile ağıın çıktısı arasındaki farka dayalı olarak ağırlıkların güncellenmesini gerçekleştirir.

Aktivasyon Fonksiyonu: Nöronun davranışını belirleyen önemli etmenlerden biridir. Transfer fonksiyonu olarak da adlandırılan aktivasyon fonksiyonu, birleştirme fonksiyonundan elde edilen net girdiyi bir işlemde geçirerek hücre çıktısını belirleyen bir fonksiyondur. Aktivasyon fonksiyonunun seçimi, büyük ölçüde yapay sinir ağı verilerine ve ağıın neyi öğrenmesinin istendiğine bağlıdır. (Minsky ve Papert (1969)'a göre, seçilen aktivasyon fonksiyonu doğrusal değil, doğrusal olmayan bir fonksiyondur. Bu fonksiyonlar arasında en çok kullanılanlar doğrusal fonksiyon, Step fonksiyonu, Sigmoid fonksiyonu ve hiperbolik tanjant fonksiyonudur. Gonzalez (2000)'a göre, yapay sinir ağlarının doğrusal olmayan aktivasyon fonksiyonuna sahip olması, ilgili problemin yapısındaki ilişki doğrusal olmadığı durumlarda daha etkin bir model üretilmesini sağlar.

III) VAR YÖNTEMİ

Sims (1980) tarafından yapılan çalışmaya göre, bir değişken kümesi arasında gerçekten eşanlılık söz konusu ise her bir değişken eşit biçimde ele alınmalıdır. Yani içsel ve dışsal değişkenler arasında önsel bir ayırım yapılmamalıdır.

Sims (1980) tarafından geliştirilen ve granger nedensellik testi modelini Granger (1969)'u temel alan vektör otoregresif modelleri, seçilen serilerin birbirleriyle olan ilişkilerinin analiz edilmesini sağlamaktadır.

VAR modelleri öncelikle makroekonomik değişkenler arasındaki ilişkilerin incelenmesinde ve rastsal şokların değişkenler sistemine olan dinamik etkisinin incelenmesinde kullanılır. Green (1993)'e göre birçok iktisatçı için kısıtsız VAR, öngörü için klâsik yapısal modellemeden daha iyi sonuç verir. VAR modelinin en iyi kullanımının öngörü olduğu şeklindeki görüşler oldukça yaygındır. Bunun nedeni VAR modelinde dışsal değişken olmadığından öngörü periyodu için dışsal değişkenler hakkında herhangi bir varsayım gereklidir. VAR model öngörülere, tüm değişkenlerin gelecekteki davranışlarının örnek periyodundaki ile aynı kalacağı örtülü varsayımı üzerine tesis edilmektedir.

İki değişkenli VAR modelini şu şekilde ifade etmek mümkündür:

$$y_t = a_0 + \sum_{i=1}^k a_{1i} y_{t-i} + \sum_{i=1}^k a_{2i} x_{t-i} + u_{1t} \quad (1)$$

$$x_t = b_0 + \sum_{i=1}^k b_{1i} x_{t-i} + \sum_{i=1}^k a_{2i} y_{t-i} + u_{2t}$$

(1) eşitlik sisteminde k, gecikmelerin uzunluğunu, u ise ortalaması sıfır, kendi gecikmeli değerleriyle olan kovaryansları sıfır ve varyansları sabit, normal dağılıma sahip rastsal hata terimlerini göstermektedir. VAR modelinde hataların kendi gecikmeli değerleriyle ilişkisiz olması varsayımı, modele herhangi bir kısıt getirmez. Çünkü değişkenlerin gecikme uzunluğunun arttırılmasıyla otokorelasyon sorununun üstesinden gelinilir.

IV) MODELLER VE UYGULAMA

Bu bölümde Türkiye ekonomisinde döviz kuru öngörü modelinin parametre tahminine yönelik olarak yapay sinir ağı modeli oluşturulmuştur. Aynı zamanda yapay sinir ağı tekniğinin öngörü performansının başarısını karşılaştırabilmek amacıyla VAR yöntemi kullanılmış ve elde edilen sonuçlar karşılaştırılmıştır.

A) Veri Seti

Ocak 1987 - Eylül 2007 dönemine ait aylık veriler kullanılarak, oluşturulan döviz kuru öngörü modeli şu şekilde tanımlanmıştır:

$$DK_t = f(TEFE_t, F_t, M2Y_t, GSYIH_t, u_t) \quad (2)$$

Burada;

DK_t : Döviz kuru (TL/US\$)

$TEFE_t$: Toptan eşya fiyat endeksi (1987=100),

F_t : Mevduat faiz oranı (%),

$M2Y_t$: Para arzı (Bin YTL),

$GSYIH_t$: Gayrisafi yurt içi hâsıla (Bin YTL)

Tüm bu değişkenlere ait zaman serileri T.C. Merkez Bankası üç aylık bültenlerinden, TCMB ve TÜİK web adreslerinden elde edilmiştir. VAR yönteminde verilerin analizinde Eviews 5.1 programından yararlanılmıştır.

53 B) Yapay Sinir Ağı Modelleri

Bu çalışmada döviz kuru değişkeninin açıklanmasında yapay sinir ağı modelinin nasıl kullanılması gerektiği araştırılmıştır. Zhang, (1998)'e göre; yapılan birçok çalışma, yapay sinir ağlarının en az geleneksel metotlar kadar, hatta daha iyi sonuçlar verdiğini göstermektedir. Yapay sinir ağının özellikle doğrusal olmayan zaman serilerinde gösterdiği başarı, bir tahmin aracı olarak tercih edilmesini sağlamıştır.

1) Verilerin İşlenmesi

Eğitim ve test verilerinden oluşan veri gruplarının yapay sinir ağı tarafından işleme sokulabilmesi için verilerin normalleştirilmesi gerekmektedir. Yapılan bu çalışmada gizli tabaka ve çıktı tabakası için aktivasyon fonksiyonu olarak Sigmoid fonksiyonu seçilmiştir. Bu nedenle $[0;1]$ aralığı göz önüne alınarak veriler,

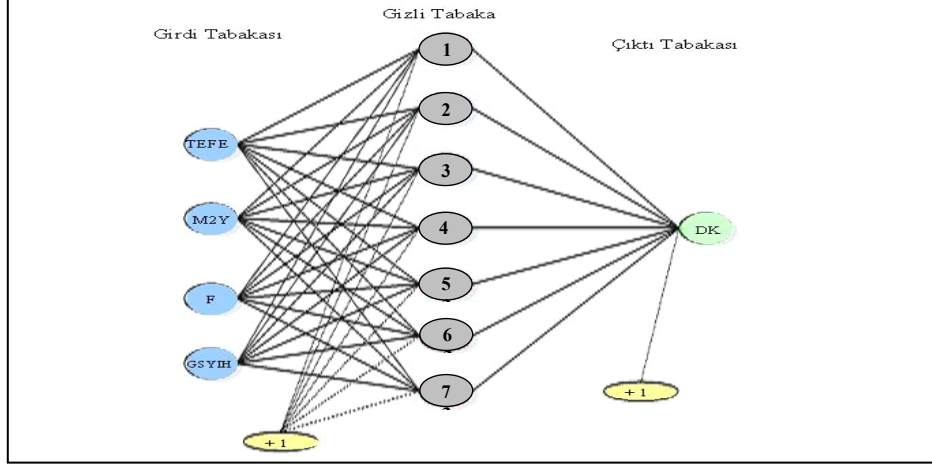
$$x_n = \left(\frac{x_0}{x_{\max}} \right)$$
 formülasyonu kullanılarak normalleştirilmiştir. Burada; x_n : normalleştirilmiş veri, x_0 : orijinal veri ve x_{\max} : satır veya kolon boyunca maksimum değeri ifade etmektedir.

2) Ağ Mimarisi

Döviz kurunu açıklamak için kurulan (2) modelinde (TEFE) Toptan eşya fiyat endeksi serisi, (F) faiz oranı, (M2Y) para arzı serisi ve (GSYIH) gayri safi yurt içi hâsıla serisi giriş veri değeri iken, çıkış değeri olarak (DK) döviz kuru değişkeni kullanılmıştır.

Çalışmada, ileri beslemeli yapay sinir ağı yapısı, hatayı minimize etmek için hatayı geriye yayma algoritması kullanılmıştır. Bu tür geri yayımlı ağlar, çok katmanlı algılayıcılar ile aynı yapıya sahiptirler ve öğrenme yöntemi olarak geri yayılma algoritması kullanırlar. Ağ eğitilirken öğrenme tipi olarak danışmanlı öğrenme seçilmiştir.

Yapay sinir ağı modeli için, Matlab (7.0 sürüm) programında nntool (Neural Network Toolbox) kullanılmıştır. Modelde dört (4) adet bağımsız değişken olduğu için, girdi değişkenlerinin değerlerinin ağa sunulmasını sağlayan dört (4) adet girdi nöronu vardır. Çıktı tabakasında ise bağımlı değişkene ait ağ çıktısının alındığı bir (1) adet nöron bulunmaktadır. Değişik sayıda gizli nöronlarla ve gizli tabaka sayıları ile yapılan denemeler sonunda tek gizli tabakadan oluşan ağ mimarisinin daha iyi sonuçlar verdiği gözlemlenmiştir. Bu gizli tabakada altı (6) tane nöron kullanılarak yapay sinir ağı oluşturulmuştur. Ayrıca, hem gizli tabaka hem de çıktı tabakası için rastsal hata terimi kullanılmıştır. Bu rastsal hata terimi Şekil : 1'de kesikli çizgilerle gösterilmiştir. Oluşturulan YSA modeli Şekil : 1'deki gibidir.



Şekil : 1
Yapay Sinir Ağı Modeli

Oluşturulan yapay sinir ağı modelinde toplama fonksiyonu olarak, doğrusal toplama işlemi tercih edilmiştir. Çalışmada, gizli tabaka ve çıktı tabakasındaki nöronlarda aynı aktivasyon fonksiyonuna yer verilmiştir. Her iki tabakadaki nöronlarda sigmoid fonksiyonu kullanılmıştır.

Yapay sinir ağının performansını etkileyen faktörlerden birisi de eğitim algoritmasıdır. Yapılan denemeler sonucunda eğitim algoritması olarak Levenberg-Marquart (*trainlm*) algoritmasının kullanıldığı ağ yapısı iyi sonuçlar verdiği için eğitim algoritması olarak *trainlm* seçilmiştir. Çeşitli denemeler sonucunda öğrenme oranı olarak 0,2 oranı alınmıştır.

3) Ağın Eğitim ve Test Aşaması


Yapısı belirlenmiş bir yapay sinir ağı eğitilerek yapay sinir ağları ile uygulamalarda kullanılır. Eldeki veriler; eğitim verisi ve test verisi olmak üzere ikiye ayrılırlar. Bu verileri ayırma işlemi yaparken göz önünde bulundurulacak genel bir yöntem bulunmamaktadır. Ancak birçok araştırmacı, veri sayısının %90'ını eğitim veri seti olarak kullanırken, geriye kalan %10'luk kısmı ise test veri seti olarak kullanılmaktadır. Zhang (1998)'a göre ise %80, %20 ya da %70, %30 oranları da verileri dönemlere ayırmak için sıklıkla kullanılan oranlardır.

Veri seti için ilk 234 veri, eğitim seti olarak kullanılmıştır. Eğitim veri seti olarak ayrılan bölüm Ocak 1987- Haziran 2006 dönemini kapsamaktadır.


Kurulan yapay sinir ağının iyi bir tahmin edici olup olmadığının tespiti için, verilerin tahmin değerlerinin doğruluğunun ölçülmesi gerekir. Bu ölçme işlemi için

kullanılabilecek birçok ölçüt bulunmaktadır. Bu çalışmadaki yapay sinir ağı modelinde amaç fonksiyonu olarak Ortalama Hata Kareler (HKO - Mean Squared Errors), Hata Kareler Toplamı (HKT - Sum Squared Errors) ve Karekök Ortalama Hata Kareler (HKOK - Root Mean Squared Errors) kullanılmıştır.

Yapay sinir ağı modeli, 1000 döngü (epoch) kullanılarak eğitilmiştir. Bu eğitime sürecinden sonra gösterilen eğitim verileri ile elde edilen döviz kurunun gerçek değerleri ve eğitim süreci sonrasında elde edilen tahmin değerleri Grafik : 1'de gösterilmiştir. Eğitime işlemi çok küçük bir hata oranı ile tamamlandığı için, döviz kurunun gerçek değerleri ve elde edilen tahmini değerleri aynı grafikte gösterildiğinde, değerler hemen hemen üst üste gelmektedir. Bu durum, eğitime işleminin oldukça minimum hata ile tamamlandığı şeklinde yorumlanabilir.




Grafik : 1
Eğitim Aşamasından Sonra Gerçek ve Tahmini Değerler




Grafik : 2
Eğitim Hatası

Grafik : 2'de eğitim hatası görülmektedir. Hata grafiği incelediğinde öğrenme işleminin iyi bir şekilde tamamlandığı görülmektedir. Eğitim işleminin uygulandığı dönem incelediğinde bu dönem içinde 1994 ve 2001 yıllarında ülkemizde meydana gelen iki kriz döneminin yer aldığı görülmektedir. Bu dönemlerden sonra da hatanın oldukça minimum olduğu saptanmıştır. Bu dönemlerde de diğer dönemlerde olduğundan çok farklı bir sapma meydana gelmemiştir. Yani genel olarak incelendiğinde tüm ağın eğitim işlemi başarıyla tamamlanmıştır.

Eğitim aşaması sonucunda elde edilen yapay sinir ağına ait ağırlıklar ve daha önce ağa gösterilmemiş yani test veri seti olarak ayrılan değerler kullanılarak, oluşturulan yapay sinir ağı test edilir.



Grafik : 3
Test Sonrası Gerçek ve Tahmini Değerler



Grafik : 4
Test Hatası


Eğitim ve test aşamalarından sonra hata kareler toplamı (HKT), ortalama hata kareler (HKO) ve karekök ortalama hata kareler (HKOK) kriterlerine ait sonuçlar elde edilmiştir.

Tablo : 1
Eğitim ve Test Hataları


<i>Eğitim Aşaması Sonrası</i>		<i>Test Aşaması Sonrası</i>	
HKO	0.000764	HKO	0.0008806
HKT	0.178880	HKT	0.0132160
HKOK	0.027600	HKOK	0.0296000

Tablo : 1'deki değerler, oluşturulan yapay sinir ağının oldukça iyi sonuçlar verdiğini göstermektedir. Verilen eğitim ve test grafiklerinden de görüldüğü üzere hem eğitim aşaması hem de test aşaması tamamlandıktan sonra öngörü başarısı bakımından oldukça iyi sonuçlar elde edilmiştir.

Özellikle ağın eğitimi ve test aşaması sırasında da hata payı oldukça küçüktür. Kullanılan yapay sinir ağı gerçek döviz kuru değerlerindeki yapısal kırılmaları dahi iyi bir şekilde öğrenerek eğitimini tamamlamıştır. Hem örneklem içi hem de örneklem dışı dönemde oldukça iyi performans elde edilmiştir. Modelin oluşturulması sırasında herhangi bir kukla değişken kullanılmamasına ya da değişkenlerin mevsimsel etkilerden arındırılmadan kullanılmasına rağmen, yapay sinir ağı modeli oldukça başarılı bir performans sağlamıştır. Özellikle 1994 ve 2001 krizlerinin model tarafından iyi bir şekilde kavrandığı görülmektedir.



Grafik : 5
Yapay Sinir Ağı Modeli Sonuçları



Grafik : 6
Yapay Sinir Ağı Modeli Hatası

C) VAR Modeli

Ekonomik modeller, iktisat teorisi tarafından öngörülen denge ilişkileri üzerine kurulmaktadır. Bu nedenle, değişkenler arasında ekonometrik olarak anlamlı ilişkiler elde edilebilmesi için, zaman serilerinin durağan seriler olması gerekmektedir. Durağanlığın tespiti için, Genişletilmiş Dickey-Fuller (ADF) birim kök testi kullanılmaktadır. Döviz kuru tahmin modelinde kullanılan fonksiyonel yapıda bulunan beş (5) değişken; Döviz Kuru, Toptan Eşya Fiyat Endeksi, Gayri Safi Yurt İçi Hâsıla, Para Arzı ve Faiz Oranıdır. Faiz değişkeni için oransal değerler söz konusu olduğundan bu değişkenin logaritması alınmamıştır. Faiz oranı hariç, tüm değişkenlerin doğal logaritmaları alınmış hem de mevsimsellikten arındırılmıştır. Bu yapı ile tahmin edilen VAR modelinin genel yapısı Eşitlik 3'deki gibi gösterilebilir:

$$\ln DK = f\left(\sum_{i=1}^k \ln DK, \sum_{i=1}^k \ln TEFE, \sum_{i=1}^k \ln GSYİH, \sum_{i=1}^k \ln M2Y, \sum_{i=1}^k F\right) \quad (3)$$

Söz konusu değişkenlerin ADF birim-kök testi sonuçları Tablo 2'de verilmiştir.

Tablo : 2
Birim-kök Test Sonuçları

<i>Değişken</i>	<i>Gecikme Uzunluğu (k)</i>	<i>ADF İstatistiği Düzeyi I (0)</i>
LDK	1	-3.460
LTEFE	1	-3.401
LGSYIH	4	-4.270
LM2Y	3	-2.606
F	1	-7.420

Birim kök denklemleri sabit içermekte olup, gecikme değerleri (k), Akaike bilgi kriteri (AIC) kullanılarak hesaplanmıştır. Kritik değerler $\alpha = 0.01$ için -3.450 , $\alpha = 0.05$ için -2.870 iken $\alpha = 0.10$ için -2.570 'dir. Kullanılan seriler logaritmik ve mevsimsel etkilerden arındırılmış hali ile kullanılmıştır (Hamilton,1994).

VAR modeli için ilk işlem gecikme uzunluğunun belirlenmesidir. VAR yöntemi gecikme sayısına karşı çok duyarlıdır. Sağlıklı sonuçlar veren modellerin oluşturulabilmesi için, gecikme sayısının mutlaka doğru saptanması gerekmektedir. Gecikme sayısının tespitinde kullanılacak; Akaike Bilgi Kriteri (AIC), Schwarz Kriteri (SC), Hannan ve Quinn (HQ) Kriteri, Shibata Kriteri, Hurvich ve Tsai gibi birçok kriter vardır. Uygulamada en çok Akaike ve Schwarz kriterlerinden yararlanılmaktadır. Sınamalara, 12 tane gecikmeyle başlanmış ve gecikmeler birer birer azaltılarak, Schwartz kriteriyle elde edilen değerler sonucunda en uygun gecikme uzunluğu iki olarak belirlenmiştir.

Tablo : 3
Sistem Gecikmesi

<i>Gecikme Sayısı (k)</i>	<i>Schwarz Kriteri</i>	<i>Gecikme Sayısı (k)</i>	<i>Schwarz Kriteri</i>
k=1	-6.218	k=7	-5.228
k=2	-6.378	k=8	-4.750
k=3	-5.957	k=9	-4.334
k=4	-5.635	k=10	-4.083
k=5	-5.603	k=11	-3.752
k=6	-5.618	k=12	-4.283


Tablo : 3'den de görüldüğü gibi Schwarz kriterine göre minimum değere ikinci gecikmede ulaşılmıştır. Bu nedenle, VAR modelinin gecikme sayısı 2'dir.

İki gecikmeli VAR modelinden elde edilen sonuçlar Tablo : 4'deki gibidir.


Tablo : 4
VAR Yöntemi Tahmin Sonuçları

	<i>LDK</i>	<i>LTEFE</i>	<i>LGSYIH</i>	<i>LM2Y</i>	<i>F</i>
LDK(-1)	1.413038	0.133029	0.525316	-0.004963	16.80873
	(0.09730)	(0.04448)	(0.32545)	(0.04486)	(52.2034)
	[14.5223]	[2.99060]	[1.61413]	[-0.11062]	[0.32199]
LDK(-2)	-0.458092	-0.125838	-0.543694	-0.008577	0.390754
	(0.09416)	(0.04305)	(0.31495)	(0.04342)	(50.5201)
	[-4.86483]	[-2.92319]	[-1.72626]	[-0.19755]	[0.00773]
LTEFE(-1)	-0.490292	1.237202	-1.451061	-0.089090	63.94080
	(0.16895)	(0.07724)	(0.56509)	(0.07789)	(90.6423)
	[-2.90204]	[16.0184]	[-2.56786]	[-1.14373]	[0.70542]
LTEFE(-2)	0.487458	-0.250382	1.636261	0.112478	-52.57921
	(0.17029)	(0.07785)	(0.56958)	(0.07851)	(91.3639)
	[2.86248]	[-3.21616]	[2.87273]	[1.43257]	[-0.57549]
LGSYIH(-1)	-0.012672	0.007359	0.821130	0.015306	-18.85697
	(0.01965)	(0.00898)	(0.06572)	(0.00906)	(10.5416)
	[-0.64491]	[0.81927]	[12.4946]	[1.68954]	[-1.78881]
LGSYIH(-2)	0.003176	0.000270	-0.238628	-0.003812	20.70518
	(0.01936)	(0.00885)	(0.06477)	(0.00893)	(10.3892)
	[0.16399]	[0.03052]	[-3.68433]	[-0.42694]	[1.99296]
LM2Y(-1)	0.065780	-0.050247	-0.425463	1.323493	6.926137
	(0.18932)	(0.08655)	(0.63323)	(0.08729)	(101.573)
	[0.34745]	[-0.58055]	[-0.67189]	[15.1623]	[0.06819]
LM2Y(-2)	-0.029184	0.052950	0.310346	-0.334263	-30.23288
	(0.18654)	(0.08528)	(0.62393)	(0.08601)	(100.082)
	[-0.15645]	[0.62090]	[0.49740]	[-3.88648]	[-0.30208]
F(-1)	0.000587	0.000163	-0.000104	0.000401	0.359209
	(0.00013)	(5.8E-05)	(0.00043)	(5.9E-05)	(0.06817)
	[4.62280]	[2.81219]	[-0.24487]	[6.85180]	[5.26907]
F(-2)	0.000177	0.000133	4.36E-05	4.46E-05	0.244239
	(0.00014)	(6.3E-05)	(0.00046)	(6.4E-05)	(0.07397)
	[1.28489]	[2.11456]	[0.09447]	[0.70089]	[3.30171]
C	-0.550409	0.105850	2.869495	-0.303756	235.0423
	(0.33731)	(0.15421)	(1.12822)	(0.15552)	(180.972)
	[-1.63175]	[0.68642]	[2.54337]	[-1.95315]	[1.29878]
R²	0.999779	0.999955	0.772095	0.999969	0.453404
HKT	0.350175	0.073186	3.917524	0.074439	100796.2
F istatistiği	99890.05	486334.7	74.87040	712085.2	18.33203

Tablo : 4'de her değişken için tahmin edilen katsayı değerleri verilmektedir. Bu katsayıların altındaki parantezlerden ilki standart hata değerlerini, ikinci parantez ise, t istatistik değerlerini göstermektedir. Bu modelin içerdiği denklemlere ait R^2 , düzeltilmiş R^2 , hata kareleri toplamı (HKT) ve F istatistiği değerlerine yer verilmiştir. VAR yönteminden elde edilen öngörüler Grafik : 7 ve Grafik : 8'de gösterilmektedir. Grafiklerden görüldüğü gibi VAR yönteminin, eğitim veri seti içerisinde yer alan dönemde meydana gelen 1994 ve 2001 krizlerini yakalamakta yetersiz kaldığı görülmektedir. Bununla birlikte diğer yıllara ait öngörü değerleri gerçek değerlere yakın çıkmıştır.



Grafik : 7
VAR Yöntemi Sonuçları



Grafik : 8
VAR Modeli Hatası

V) ÖNGÖRÜ MODELLERİNİN KARŞILAŞTIRILMASI


Öngörü, gözlemlediğimiz değerlerin dışında (gelecek zamanlarda yani, bir gün sonraki, bir ay sonraki veya bir yıl sonraki gibi rastgele değişkenin alması beklenen değerlerdir (Akdi, 2003).

Kurulan yapay sinir ağının iyi bir öngörü başarısına sahip olup olmadığının tespiti için öngörü başarı ölçütlerinin kullanılması gerekmektedir. Bu nedenle ortalama hata kareler toplamı, hata kareleri toplamı ve karekök ortalama hata kareler performans ölçütleri hesaplanmıştır. Örneklem içi ve örneklem dışı olmak üzere ayrılan dönemde, yapay sinir ağı tekniği ve VAR yöntemi analizleri yapılarak elde edilen sonuçlar Tablo : 5'de verilmektedir.

Tablo : 5
Öngörü Doğruluk Ölçütleri

	ÖRNEKLEM İÇİ		ÖRNEKLEM DIŞI	
	VAR	YSA	VAR	YSA
HKO	0.0015	0.000764	0.0014	0.0008806
HKT	0.3568	0.178880	0.0224	0.0132161
HKOK	0.0390	0.027600	0.0386	0.0296000


Tablo : 5'deki sonuçlara göre, modelin çözümünde kullanılan tekniklerin performans karşılaştırması yapıldığında örneklem dışı dönemde, yapay sinir ağı tekniğinin VAR yöntemine göre, daha iyi bir performans gösterdiği gözlemlenmiştir. En doğru öngörülere sahip model olarak, yapay sinir ağı tekniği kullanılarak oluşturulan model dikkati çekmektedir. Örneklem içi dönemde de elde edilen sonuçlara bakıldığında, hata ölçütleri en iyi model olarak YSA modelini işaret etmektedir. Verilen bu bilgilerden sonra örneklem içi ve örneklem dışı dönemlerde, modellerden elde edilen ve gerçek döviz kuru değerlerinin karşılaştırılması Grafik : 9'da yer almaktadır. Grafik : 10'da ise, örneklem içi ve örneklem dışı dönemlerde meydana gelen hatalara yönelik bir grafik sunulmaktadır. Tablo : 5'den çıkarılan sonuçlar, Grafik : 9 ve Grafik : 10'da görsel olarak daha iyi saptanabilir.



Grafik : 9
Örneklem İçi ve Örneklem Dışı Öngörü Karşılaştırması

Grafik : 9'da da görüldüğü gibi, yapay sinir ağı tekniği ve VAR yöntemi kullanılarak elde edilen değerler, gerçek döviz kuru değerlerine oldukça yakındır. Her iki yöntem kullanılarak örneklem içi ve örneklem dışı dönemlerde oldukça başarılı sonuçlar elde edilmiştir.

1994 yılında meydana gelen krizden sonraki dönemde ani sapma durumlarının ortaya çıkması olasıdır. Grafik : 10'dan da görüldüğü gibi, hatalara bakıldığında, hata oranının diğer dönemlere göre ani bir artış gösterdiği ve dolayısıyla VAR yönteminin bu dönemde tahmin işleminde daha başarısız kaldığı söylenebilir. Ancak yapay sinir ağı, bu dönemde gayet başarılı sonuçlar vermiştir. Ayrıca yine örneklem içi dönemde kalan 2001 krizinden sonra kur politikalarındaki değişim nedeniyle yapısal bir değişiklik söz konusu olmuş, bu sebepten dolayı VAR yönteminde tatmin edici sonuçlar elde edilememiştir. Bu dönem için yapay sinir ağı ile elde edilen sonuçlar ise oldukça minimum hata ile tahmin edilmiştir.



Grafik : 10
Örneklem İçi ve Örneklem Dışı Öngörü Hataları

Öngörü doğruluklarının değerlendirilmesinde ve karşılaştırılmasında örneklem dışı dönemler, örneklem içi dönemlerden daha büyük önem taşımaktadır. Çünkü örneklem dışı dönemler, model tahmininde kullanılmayan yeni verilere ait öngörülerden oluşmaktadır ve bilinmeyen döneme ait tahminleri içermektedir. Grafik : 9 ve Grafik : 10'daki örneklem dışı dönem incelendiğinde, YSA tekniğinin uygulanmasıyla elde edilen sonuçların örneklem içi dönemde olduğu gibi örneklem dışı öngörülerde de oldukça başarılı sonuçlar verdiği görülmektedir.

VI) VAR YÖNTEMİ VE YAPAY SİNİR AĞLARI MODELİ ÖNGÖRÜLERİNİN BİRLEŞTİRİLMESİ

Birleştirme işleminde uygulamada kullanılan yaklaşım ağırlıklandırılmış ortalamanın alınmasıdır. (Granger, 1996; 2000).

P1; yapay sinir ağı modeli öngörü değeri, P2; VAR modeli öngörü değeri ve A; gerçekleşen değerleri temsil etsin. Bu durumda, A* ; ağırlıklandırılmış ortalama öngörüsü, $A^* = wP1 + (1 - w) P2$ olacaktır. Burada w ağırlıklar olup, tahmini ise aşağıdaki formülle hesaplanır:

$$\hat{w} = \frac{\sum (A - P2)^2}{\sum (A - P1)^2 + \sum (A - P2)^2} \quad (4)$$


Çalışmada, w ağırlık katsayısı 0.6299 olarak tahmin edilmiştir. Temmuz 2006 döneminden Eylül 2007 dönemine kadar ki test dönemi olarak da adlandırılan 15 aylık dönem için iki modelin bir dönem sonraki öngörülerinin ağırlıklandırılmış ortalamaları hesaplanmıştır. Bu birleştirme işleminden elde edilen sonuçlar aşağıdaki Tablo : 6'da verilmiştir.

Tablo : 6
Öngörü Modellerinin Ağırlıklandırılmış Ortalamaları


<i>Öngörü Modelleri</i>	<i>HKO</i>	<i>HKT</i>	<i>HKOK</i>
Yapay Sinir Ağı Modeli	0.00088	0.01321	0.0296
VAR Yöntemi Modeli	0.00140	0.02240	0.0386
Birleştirilmiş Öngörüler	0.00055	0.00833	0.0230

Yukarıda Tablo : 6'dan da görüldüğü gibi, HKO, HKT ve HKOK kriterine göre öngörü başarısı birleştirme işlemi sonucunda artmaktadır. Kullanılan tüm modeller içerisinde, döviz kuru öngörüsü başarısı "Yapay sinir ağıları ve VAR yöntemi modelleri" öngörülerinin birleştirilmesi ile sağlanmaktadır. Elde edilen bu sonuç, ekonomik değişkenlerin öngörüsünde tek bir modelin seçimi şeklindeki genel

yaklaşımına ilaveten, kullanılan modellerden öngörü performansları yüksek olanların birleştirilmesi yaklaşımının da dikkate alınması gerektiğine işaret etmektedir. Birleştirilmiş öngörü hatası ile örneklem içi ve örneklem dışı öngörü hatalarına ait grafikler sırasıyla Grafik : 11 ve Grafik : 12'deki gibidir.



Grafik : 11
Birleştirilmiş Öngörü Hatası



Grafik : 12
Örneklem İçi ve Örneklem Dışı Öngörü Hataları

SONUÇLAR

Yapay sinir ağlarının başarı ile kullanıldığı alanlardan birisi de geleceği tahmin problemleridir. Yapay sinir ağı, veriler arasındaki bilinmeyen ve fark edilmesi güç ilişkileri ortaya çıkartabilir. Yapay sinir ağı doğrusal değildir. Doğrusal modeller, önemli detayları anlayabildikleri ve açıklayabildikleri takdirde avantajlı olabilirler.

Yapay sinir ağı teknikleri, VAR modeli tekniğine oranla daha az veri ile çalışmaya müsaade etmektedir. Tahmin aracı olarak kullanıldıklarında, geleneksel metotlar ile bulunan sonuçlar, YSA tekniklerini desteklemede yardımcı olarak kullanılabilir. Problemin yapısına uygun kurulmuş bir ağ, iyi neticeler verir. Bu nedenle incelenen probleme göre uygun ağ yapıları araştırılmalıdır.

Yapılan bu çalışmada, döviz kuru yapay sinir ağı tasarımı ile öngörülmüştür. Tahmin edilen model, hem kendi içinde değerlendirilmiş hem de öngörü gücü yüksek modelleme tekniği olan VAR yöntemi ile karşılaştırılarak performans değerlendirilmesi yapılmıştır. Kurulan döviz kuru modelinin tahmini aşamasında çok sayıda yapay sinir ağı mimarisi arasından geri yayılım algoritmasıyla oluşan hatanın minimum olması sağlanmıştır.

Tahmin edilen yapay sinir ağı modeli, kendi içinde tutarlı bir yapı ve iyi bir öngörü performansı sağlamıştır. Çalışmada, örneklem içi dönem ele alındığında yapay sinir ağı tekniğinin, VAR yöntemine göre oldukça iyi bir performans gösterdiği sonucuna varılmıştır. Aynı zamanda yapay sinir ağlarının örneklem içi döneminde yer alan 1994 ve 2001 krizlerinin tahmini sırasında gösterdiği başarı ise göz ardı edilemeyecek düzeydedir. Yapılan analizin doğrusal olmayan bir modelleme tekniği olan yapay sinir ağı yönteminin doğrusal yöntemlerle karşılaştırılması olarak düşünülmesi durumunda, Türkiye ekonomisine ait değişkenlerin öngörüsü için doğrusal olmayan modellemenin daha etkili olduğu yönünde bir genelleme yapılabilir.

Doğrusal olmayan YSA ve doğrusal VAR model öngörülerinin birleştirilmesi döviz kuru için öngörü başarısını arttırmıştır. Bu durum, doğrusal ve doğrusal olmayan modeller arasında bir seçim yerine, iki yaklaşımdan elde edilen öngörülerin birleştirilmesinin daha iyi sonuçlar verebileceğine işaret etmektedir.

KAYNAKÇA

- AKDİ Yılmaz, (2003), *Zaman Serileri Analizi (Birim Kökler ve Kointegrasyon)*, Bıçaklar Kitabevi, Ankara.
- GONZALEZ, Steven., (2000), *Neural Networks for Macroeconomic Forecasting: A Complementary Approach to Linear Regression Models*, Working Paper, Finance Canada.
- GRANGER, C.W.J., (1969), “Investigating Casual Relations by Econometric Models and Cross-Spectral Methods”, *Econometrica*, Vol. 37, pp. 424 – 438.
- GRANGER, C. W. J., (1981), “Some Properties of Time Series Data and Their Use in Econometric Model Specification”, *Journal of Econometrics*, pp. 121 – 130.
- GRANGER, C.W.J., (1996), “Can We Improve the Perceived Quality of Economic Forecasts”, *Journal of Applied Econometrics*, Vol.11, pp. 455 – 473.
- GRANGER, C.W.J, (2000), “ Thick Modelling and Forecasting”, *METU Conference in Economics*, Ankara.
- GREENE, W. H., (1993), *Econometric Analysis*, Second Edition, Prentice-Hall,
- HAMILTON, J. D. (1994), *Time Series Analysis*, Princeton University Press.
- HAYKINS, S., (1999), *Neural Networks a Comprehensive Foundation*, Prentice Hall International, Inc.
- KAASTRA,I. and BOYD., M., (1996), “Designing A Neural Network For Forecasting Financial and Econometric Time Series”, *Neurocomputing*, p. 10.
- KOHONEN, T., (1982), “Self-organised Formation of Topologically Correct Feature Maps”, *Biological Cybernetics*, Vol. 43, pp. Vol. pp. 59 – 69.
- MINSKY, M and PAPERT, S. (1969), *Perceptrons*, MIT Press, Cambridge, MA.
- SIMS, C., (1980), “Macroeconomics and Reality”, *Econometrica* , Vol. 48, pp. 1 – 49.
- ZHANG,G., Patuwo, B.E. and HU., M., Y., (1998), “Forecasting with Artificial Neural Networks: The State of the Art”, *International Journal of Forecasting*, Vol. 14, pp. 35 – 62.
- ZURADA, J.M., (1992), *Introduction of Artificial Neural Systems*, St. Paul: West Publishing.