

Türkiye’de Vadeli İşlem ve Opsiyon Piyasası’nın Etkinliği ve Sözleşmelerin Karşılaştırmalı Fiyat Öngörüsü*

Effectiveness of Turkish Derivatives Market and Forecasting Comparative Prices for the Contracts

Taner TAŞ¹
Sibel SELİM²

<http://orcid.org/0000-0002-2861-5467>

<http://orcid.org/0000-0002-8464-588X>

ÖZET

Finansal piyasalarda oluşan belirsizliğin ve riskin giderilmesi amacıyla geliştirilmiş olan türev piyasalarda, piyasaya duyulan güven, doğru bilginin piyasaya dahil olan tüm unsurlara aynı anda ulaşması sayesinde piyasanın etkin olarak işlemesi durumunda gerçekleşebilmektedir. Böylece, geçmiş dönem fiyat hareketlerinden yararlanarak gelecek döneme ilişkin öngörüler yapmak mümkün olmamaktadır. Bu bağlamda çalışmada öncelikle, Türkiye’de faaliyet gösteren Vadeli İşlem ve Opsiyon Piyasası’nın etkinliği; Genişletilmiş (Augmented) Dickey-Fuller (ADF), Phillips-Perron (PP) ve Kwiatkowski vd. (KPSS) doğrusal birim kök testleri ve Kapetanios vd. (KSS) doğrusal olmayan birim kök testi uygulanarak sınanmıştır. Rassal yürüyüş sergilemediğine karar verilen seriler sebebiyle piyasanın etkin olmadığı sonucuna ulaşılmıştır. Ardından, Vadeli İşlem ve Opsiyon Piyasası’nda işlem gören TL/Dolar ve Bist-30 sözleşmelerinin gün sonu uzlaşma fiyatının öngörüsünde en yüksek performansı gösteren yöntemin belirlenmesi amaçlanmıştır. Bu amaçla, Borsa İstanbul A.Ş.’den temin edilen ve 04.02.2005 – 31.12.2015 tarihleri arasında kapsayan veriler kullanılmıştır. Analiz bulgularına göre, TL/Dolar sözleşme serisi için ARMA(4,4) modeli, RBF-1-B-L yapay sinir ağı modeli ve ARCH(1) modeline kıyasla daha yüksek öngörü performansı gösterirken, Bist-30 sözleşme serisi için ise TDNN-1-B-L yapay sinir ağı modeli, ARMA(4,5) ve ARCH(1) modeline kıyasla daha yüksek öngörü performansı gösteren model olmuştur.

Anahtar Kelimeler: Türev Piyasalar, Etkin Piyasalar Hipotezi, Birim Kök Testi, ARIMA Modelleri, ARCH/GARCH Modelleri, Yapay Sinir Ağları

Jel Kodu: C45, C22, D53

ABSTRACT

Derivative markets developed for eliminating uncertainty and risk arising from financial markets can make predictions about the future by using past price movements in case the market is not effective. In this context, in this study, firstly, the effectiveness of the Turkish Derivatives Market was tested by applying the Augmented Dickey-Fuller (ADF), Phillips-Perron (PP) and Kwiatkowski et al. (KPSS) linear unit root tests and Kapetanios et al. (KSS) nonlinear unit root test. As a result of all unit root tests, it was concluded that the series did not show random walk, so that the market was not effective. Then, the method that shows the highest performance is tried to be determined when forecasting the end of day settlement price of the TL/Dollar and Bist-30 contracts which is traded in the Derivatives Market. For this purpose, the forecasting results produced by the time series analysis methods are compared with the results of the artificial neural network model which has the best performance by employing different architectures, layer numbers, cell numbers in layers, activation functions and learning methods using the data which is provided from Borsa Istanbul Inc. and covering the dates between 04.02.2005 and 31.12.2015. According to the results of analysis, ARMA (4,4) model performed better than RBF-1-BL artificial neural network model and ARCH (1) model for TL/Dollar contract series. For the Bist-30 contract series, TDNN-1-B-L artificial neural network model has higher predictive performance than ARMA (4.5) and ARCH (1) models.

Keywords: Derivatives Markets, Efficient Market Hypothesis, Unit Root Test, ARIMA Models, ARCH/GARCH Models, Artificial Neural Networks

Jel Codes: C45, C22, D53

*“Türkiye’de Vadeli İşlem ve Opsiyon Piyasası’nın Etkinliği ve Sözleşmelerin Karşılaştırmalı Fiyat Öngörülmesi” adlı doktora tezinden üretilmiştir. Ayrıca bu çalışma Manisa Celal Bayar Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından 2015-175 no’lu proje ile 04.01.2016-29.12.2016 tarihleri arasında desteklenmiştir.

¹Dr. Öğr. Üyesi, Manisa Celal Bayar Üniversitesi, İşletme Fakültesi, Ekonomi ve Finans Bölümü, taner.tas@gmail.com

²Prof. Dr., Manisa Celal Bayar Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Ekonometri Bölümü, sibel.selim@cbu.edu.tr 469

Giriş

Belirsizliğin giderilmesi ve risk yönetimi konusunda önemli bir yere sahip olan türev piyasalarda, herhangi bir varlığın bugün belirlenen fiyat ve miktar üzerinden alım satımı yapılmakta ancak teslimat ileri bir tarihte gerçekleşmektedir. BrettonWoods sabit kur sisteminin yerine dalgalı kur sisteminin kullanılmaya başlanması ile döviz kurlarında ve faiz oranlarında meydana gelen oynaklıklardan en az düzeyde etkilenmek için forward sözleşmeleri (alivire işlem sözleşmeleri), futures sözleşmeleri (vadeli işlem sözleşmeleri), opsiyon sözleşmeleri ve swap sözleşmeleri (takas sözleşmeleri) gibi çeşitli türev ürünler kullanılmaya başlanmıştır.

Tüm finansal piyasalarda olduğu gibi, risk yönetimi ve geleceğe dönük fiyat oluşumu gibi iki temel fonksiyonu bulunan türev piyasalar açısından da güvenilirlik kavramı işlevselliği önemli ölçüde etkilemektedir. Piyasaların güvenilirliği de, piyasaya dahil olan tüm unsurların doğru bilgiye aynı anda ulaşabilmeleri ve bunun sonucunda doğru kararlar alabilmelerine bağlıdır ve bu durum ancak piyasaların etkin olarak işlemesi ile gerçekleşebilmektedir. Piyasa etkinliği kavramı, bilgi (enformasyon) etkinliği, kaynak dağılımı etkinliği ve faaliyet etkinliği olmak üzere üçe ayrılmaktadır. Bilgi (fiyatlama) etkinliği kavramı ile ilgili olan Etkin Piyasalar Hipotezi (EPH), Fama (1965) tarafından geliştirilmiş ve o tarihten günümüze kadar geçen sürede iktisadi anlamda ilgi çeken konular arasındaki yerini korumuştur. Hipotezin temelinde yatan düşünce, piyasada bulunan tüm bilgilerin finansal varlıkların fiyatlarına tam ve doğru olarak yansımış olması sebebiyle, herhangi bir yöntem kullanılarak uzun dönemde piyasa ortalama getirisinin üzerinde getiri sağlamak mümkün değildir. Fama (1970), bilgi etkinliği olarak da tanımlanabilen ve temel hipotezi, fiyatların piyasaya gelen yeni bilgiler doğrultusunda ve rassal olarak belirlenmesi üzerine kurulu olan piyasa etkinlik türlerini bilgi girişinin çeşidine göre, Zayıf Formda, Yarı Güçlü Formda ve Güçlü Formda Piyasa etkinliği olmak üzere üç gruba ayırmaktadır. Zayıf formda piyasa etkinliğinde, gelecek dönem fiyatlarının geçmiş dönem fiyatları kullanılarak öngörülemediği, yarı güçlü formda piyasa etkinliğinde, kamuya açıklanan tüm bilgilerin finansal varlık fiyatlarına çok hızlı bir şekilde yansıdığı, güçlü formda piyasa etkinliğinde ise finansal varlık fiyatlarının kamu ile henüz paylaşılmamış özel bilgileri de içerdiği varsayılmaktadır.

Etkin piyasalar hipotezi genel olarak rassal yürüyüş kavramı ile ilişkilendirilmektedir. Bu durumun en önemli nedeni, etkin piyasalar hipotezi gereği

rassal olarak oluşan bir bilginin finansal piyasalardaki fiyatlara yansımalarının da aynı şekilde rassal olduğu varsayımdır. Bu varsayımın arkasında, birbiri ardından gelen fiyat değişimlerinin veya getirilerin birbirinden bağımsız olması ve bu fiyat değişimi veya getirilerin benzer dağılım göstermesi şeklinde rassal yürüyüş hipotezinin temelini oluşturan iki varsayım bulunmaktadır. Rassal yürüyüş hipotezini ve dolayısıyla piyasaların zayıf formda etkinliğini sınavabilmek için kullanılan birim kök testlerinde, rassal yürüyüş boş hipotezi durağanlık alternatifine karşı test edilmekte ve birim kökün varlığı durumunda, piyasanın zayıf formda etkin olduğu sonucuna ulaşılmaktadır. Eğer seride birim kök yoksa yani seri I(0) durağan ise geçmiş dönem fiyatlar kullanılarak gelecek dönemdeki fiyatları öngörebilmenin mümkün olabileceği ihtimali kabul edilmekte ve piyasanın zayıf formda etkin olmadığı sonucuna ulaşılmaktadır. Zayıf formda etkin olmayan piyasalarda yer alan ekonomik ve finansal değişkenlerin gelecek dönem değerlerinin öngörülebilmesi için geliştirilen modeller ve bu modellerin gelecek dönem öngörü performanslarının kıyaslandığı çalışmalara ekonomi ve finans literatüründe sıkça karşılaşılmaktadır. Ancak ekonomik ve finansal zaman serileri kullanılarak oluşturulacak öngörü modelleri, bu alanda çok sayıda bağımlı ve bağımsız değişkenin mevcut olması sebebiyle oldukça karmaşık ve zor bir süreç olarak karşımıza çıkmaktadır.

Bu çalışmanın literatüre katkısı, Türkiye’de faaliyet gösteren Vadeli İşlem ve Opsiyon Piyasası’nın zayıf formda etkinliğinin birim kök testleri ile sınanması ve sözleşme verilerinin öngörüsü gerçekleştirilirken kullanılan yapay sinir ağları ve zaman serileri modelleri karşılaştırılarak en iyi yöntemin belirlenmesidir. Türkiye ekonomisi için Vadeli İşlem ve Opsiyon Piyasası’nda işlem gören sözleşmelerin gün sonu uzlaşma fiyatları için üç ayrı yöntemin öngörü performanslarını karşılaştırarak öngörü işleminde en iyi yöntemi ortaya çıkaran bu çalışma, literatürde bulunan ve finansal değişkenlerin gelecek dönem değerini öngören diğer çalışmalardan farklılaşmaktadır. Bu çalışma ile zaman serisi analizi yöntemlerine karşı yapay sinir ağları yönteminin öngörü performansı başarısının, zayıf formda etkin olmadığı belirlenen Vadeli İşlem ve Opsiyon Piyasası’nda işlem gören TL/Dolar ve Bist-30 endeks sözleşmelerinde de gerçekleşip gerçekleşmediği belirlenerek literatüre katkı sağlanmaya çalışılmıştır.

Bu çalışmanın izleyen bölümleri şu şekilde düzenlenmiştir. İkinci bölümde konuyla ilgili literatür araştırması ele alınmıştır. Üçüncü bölümde çalışmada

kullanılan veriler ve yöntem sunulmuştur. Çalışmanın dördüncü bölümünde ise, analizlerden elde edilen bulgulara ve modellerin performanslarının karşılaştırılmasına yer verilmiştir. Son olarak, sonuç bölümünde model tahminlerinden elde edilen bulgular literatürdeki çalışmalarla desteklenerek yorumlanmıştır.

Literatür Araştırması

Bu çalışmanın literatür araştırması iki ayrı kısımdan oluşmaktadır. İlk kısımda zayıf formda etkinlik çalışmaları incelenmiş, ikinci kısımda ise finansal ve iktisadi değişkenlerin gelecek dönem değerlerinin öngörüldüğü çalışmalara yer verilmiştir. Zayıf formda piyasa etkinliğini birim kök testleri yardımıyla inceleyen çalışmalar genel olarak ele alındığında, piyasalara ilişkin verilerin birim kök içermediği yani piyasaların zayıf formda etkin olmadığı görüşü daha kuvvetli olsa da, bu konuda net bir fikir birliği söz konusu değildir. Fakat ülkelerin gelişmişlik düzeyleri ile birlikte finansal piyasalarının derinliğinin artması ile orantılı olarak piyasa etkinliğinin de arttığı görülmektedir.

İstanbul Menkul Kıymetler Borsası için zayıf formda piyasa etkinliğinin analiz edildiği çalışmalardan, Buguk ve Brorsen (2003), Taş ve Dursunoğlu (2005), Özcan ve Yılcı (2009)’da, elde edilen birim kök testi sonuçlarına göre rassal yürüyüş hipotezinin desteklediği ve sonuç olarak İMKB’nin zayıf formda etkin olmadığı kanıtlanmaktadır. Ancak aksi yönde kanıtlar elde eden çalışmalardan, Zengin ve Kurt (2004), Pınar (2009)’da ise İMKB’ye ilişkin serilerin birim kök içerdiği bu sebepten piyasanın zayıf formda etkin olduğu sonucu ortaya koyulmaktadır. İzmir Vadeli İşlem ve Opsiyon Borsası’nda işlem gören İMKB 30, İMKB 100, Dolar ve Euro vadeli işlem (future) sözleşmelerinin zayıf formda etkinliğini test eden Durmuşkaya (2011) ise çalışmasında sözleşme serilerinin rassal yürüyüş göstermediği ve İzmir Vadeli İşlem ve Opsiyon Borsası’nın zayıf formda etkin olmadığı bulgusuna ulaşmıştır.

Aralarında Türkiye’nin de bulunduğu gelişmekte olan ülke borsalarının piyasa etkinliğine ilişkin olarak yapılan çalışmalardan, Çelik (2007), Marashdeh ve Wilson (2005), Erdem (2011) inceledikleri serilerin birim kök içerdiğini tespit etmişler ve piyasaların zayıf formda etkin olduğunu kanıtlamışlardır. Ancak benzer şekilde, Worthington ve Higgs (2003b), Chang vd. (2004), Calomfir (2015), Shaikh (2016), Stakicvd (2016), gelişmekte olan ülkeler şeklinde nitelendirilebilecek ülkelerin borsalarını incelemişler ve piyasaların zayıf formda etkin olmadığını ispatlamışlardır. Son olarak, gelişmiş ülkelerin borsalarına ait verilerle gerçekleştir-

dikleri zayıf formda etkinlik çalışmalarında Worthington ve Higgs (2003a), Demireli vd. (2010) piyasaların rassal yürüyüş hipotezini gerçekleştirdiğini belirlemişler ve bundan dolayı zayıf formda etkin piyasalar olduğu sonucuna ulaşmışlardır.

Finansal ve iktisadi değişkenlerin gelecek dönem değerlerinin öngörülmesi ile ilgili literatür incelendiğinde, herhangi bir yöntem kullanılarak örneklem içi ve örneklem dışı öngörüler üretilen çalışmalar olduğu gibi, öngörü işleminde birden fazla yöntem kullanan ve bu yöntemler içerisinde en yüksek performans göstereni belirleyen çalışmaların çoğunluğu oluşturduğu göze çarpmaktadır. Öngörü yöntemi olarak yalnızca otoregresif hareketli ortalama (ARIMA) modelini kullanan çalışmalardan olan Subaşı (2005), Erdoğan (2006), Özkan (2006), Türkiye ekonomisine ilişkin olarak enflasyon, ithalat, dış borç gibi değişkenlerin farklı dönemler için öngörülerini gerçekleştirmişlerdir. Çörtük (2007) ve Adlığ (2009) döviz kurlarına ilişkin olarak, Çolak (2013) ise İstanbul Menkul Kıymetler Borsası (İMKB) verileri ile otoregresif koşullu değişen varyans modellerini (ARCH, GARCH...) kullanarak öngörü çalışmalarında bulunmuşlardır. Öngörü işleminde yalnızca yapay sinir ağı modellerinin kullanıldığı çalışmalardan, Avcı (2007), Dumlu (2011) ve Akcan ve Kartal (2011), İMKB endeksine, Qi ve Zhang (2008), ABD ekonomisine, Zahedi ve Rounaghi (2015) ise İran ekonomisine ilişkin verileri kullanarak öngörü çalışmaları gerçekleştirmişlerdir.

Birden çok öngörü yöntemi kullanarak performans karşılaştırmasının yapıldığı çalışmalardan Kaynar ve Taştan (2009) ve Polat (2009) haricindeki çalışmalarda yapay sinir ağlarının üstünlüğü göze çarpmaktadır. Eğrioğlu ve Aladağ (2005), Ataseven (2007), Özdemir (2008), İnel ve diğerleri (2010), Uslu (2011), Bozdağ (2011), Akdağ (2010), Türkiye ekonomisine ilişkin veriler kullanarak yapay sinir ağları ile ARIMA modellerinin öngörü sonuçlarını karşılaştırmış ve öngörü işleminde yapay sinir ağlarının daha yüksek performans gösterdiğini ortaya koymuşlardır. Benzer şekilde, dünya ekonomisine ilişkin farklı veriler kullanarak gerçekleştirilen çalışmalardan, Kihoro vd. (2004), Panda ve Narasimhan (2007), Zou vd. (2007), Adebıy vd. (2014), Lasheras vd. (2015)’de, yapay sinir ağlarının üstünlüğü kanıtlanmıştır.

Aydın ve Cavdar (2015), Usta (2007) ve Yıldız (2009) gelecek dönem öngörü işleminde vektör otoregresif (VAR), ARIMA ve yapay sinir ağları modellerini kullanmışlar ve Morali (2011), Aygören vd. (2012)’nin ARIMA, nümerik arama modelleri ve yapay sinir ağlarını kul-

lanarak üç ayrı yöntemi karşılaştırdıkları çalışmalarına benzer şekilde, yapay sinir ağları yönteminin daha başarılı olduğunu göstermişlerdir. Yine, Kadılar vd. (2009), yapay sinir ağlarına alternatif olarak kullanılan ARIMA ve ARCH yöntem karşılaştırması sonucunda, doğrusal olmayan zaman serisi yöntemlerine karşı yapay sinir ağlarının performansını, son olarak Arabacı (2007) ve Godarzi vd. (2014)'de aynı şekilde yapay sinir ağları yöntemini daha başarılı bulmuşlardır.

Veri ve Yöntem

Veri

Bu çalışmada kullanılan veriler Borsa İstanbul A.Ş'den elde edilmiştir. Veriler 4 Şubat 2005 ile 31 Aralık 2015 tarihleri arasında kapsamaktadır. Analizde kullanılan TL/Dolar sözleşme serisi ile BİST-30 sözleşme serisi, her gün itibarıyla en yakın vadeye sahip vadeli işlem sözleşmesinin gün sonu uzlaşma fiyatı verisinden oluşmaktadır. Uygulamada serilerin logaritmik birinci farkları alınarak elde edilen getiri serileriyle çalışılmıştır. Getirilerin hesaplanmasında kullanılan formül aşağıdaki şekildedir;

$$r_t = \ln(d_t/d_{t-1})r_t = \ln d_t - \ln d_{t-1} \quad (1)$$

Bu formülde r_t ilgili sözleşme serisinin t dönemindeki getirisini, d_t t dönemindeki sözleşmenin gün sonu uzlaşma fiyatını, d_{t-1} ise t-1 dönemindeki gün sonu uzlaşma fiyatını göstermektedir. Bu çalışmada getiri serileri için kullanılan kısaltmalarda *rusd*; VİOP – TL/DOLAR sözleşmesini, *rbist30*; VİOP – BİST-30 sözleşmesini ifade etmektedir.

Yöntem

Zaman serisi analizinin ilk aşaması, analizde kullanılacak serilerin durağanlığının belirlenmesidir. Çünkü herhangi bir zaman serisine ait geçmiş değerler kullanılmak suretiyle serinin sabit parametrelili modeline ulaşabilmek için, bu zaman serisi modelinden elde edilen stokastik sürecin niteliğinin zaman boyunca değişmiyor olması gerekmektedir. Üç çeşit durağanlık tipi vardır, ilki zayıf durağanlık veya diğer adı ile kovaryans durağanlıktır.

Ortalamanın ve varyansın zaman içinde değişmesi kovaryansın gecikmeye bağlı olup zamana bağlı olmamasıdır. Özetle ortalama, varyans ve kovaryans zamana bağlı değildir (Sevüktekin ve Nargeleçekenler, 2005). Literatürde zaman serilerinin doğrusallığını test eden çeşitli testler bulunsun da, seriler için doğrusal olmamaya sebebiyet veren şeylerin farklı olmasından

dolayı testler arasında birbirlerine karşı belirli bir üstünlük söz konusu değildir (Guhathakurta, 2011). Bu çalışmada parametrik olmayan bir yöntem olan BDS (Brock-Dechert-Scheinkman) testi kullanılmış olup bu yöntem, modelin hatalarının birbirinden bağımsızlığını ve hatalara ilişkin dağılımın aynı olup olmadığını incelemektedir. Yöntemin boş hipotezi, modelin hatalarının birbirinden bağımsız ve dağılımlarının aynı olması durumudur (Brock vd. 1987).

Otoregresif Hareketli Ortalama (ARMA/ARIMA) Modelleri

Bir zaman serisi kendi gecikmeli değerlerinin bir fonksiyonu olarak tanımlanıyorsa buna otoregresif (AR- Autoregressive) süreç, t dönemindeki değerinin, hata teriminin (e_t) cari ve gecikmeli değerleri tarafından belirlendiği sürece de hareketli ortalama (MA-Moving Average) süreci adı verilmektedir. Durağan rassal süreçlerin sadece otoregresif veya sadece hareketli ortalama ile modellenememesi durumunda ise bu iki süreç aynı anda dikkate alınmaktadır. Bu durumda otoregresif hareketli ortalamalar modelinin (ARMA) kullanılması önerilmektedir (Tsay, 2010). Böylece zaman serisi modeli p ve q'uncu dereceden AR ve MA bileşenleri ile birlikte ARMA(p,q) olarak tanımlanmaktadır. ARMA(p,q) modeli Denklem (2)'teki gibidir.

$$Y_t = \delta + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + e_t + \theta_1 e_{t-1} + \dots + \theta_q e_{t-q} \quad (2)$$

Burada kesme terimi δ , Y_t 'nin ortalamasını ilgilendirmekte iken, hataların e_t , $E(e_t)=0$ ve varyansın $\text{Var}(e_t)=\sigma_e^2$ birbiri ile korelasyonu olmayan rassal değişkenler olduğu varsayılmaktadır. Zaman serisinin durağan olmadığı durumlarda ise ARIMA(p,d,q) modeli kullanılmaktadır. Bu modelde d, zaman serisinin durağanlaştırılması için alınması gereken fark sayısını göstermektedir. Bu modele aynı zamanda d. dereceden entegre bir ARIMA(p,d,q) modeli denir.

Koşullu Değişen Varyans Modelleri

Hata terimlerinin varyansının zaman içinde değişmediği varsayımı klasik doğrusal regresyon modelinin temelini oluşturan birkaç unsurdan bir tanesidir. Engle (1982) tarafından geliştirilen model sayesinde, hata terimlerinin sabit varyansa sahip olduğu yönündeki ortak görüşün geçerli olmadığı kanıtlanmıştır. Burada ki temel mantık, bir sonraki döneme ait varyans tahmininin önceki dönemler ile ilişkili olmasıdır. Engel (1982) koşullu değişen varyansı basit bir AR(1) modelinden yola çıkarak tanımlamıştır.

$$y_t = b_0 + b_1 y_{t-1} + \varepsilon_t \quad (3)$$

$$\varepsilon_t = z_t h_t^{1/2} z_t, \text{ iid, } E(z_t)=0, \text{ Var}(z_t)=1 \quad (4)$$

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 \quad (5)$$

Denklem (3)'deki modelde y_{t-1} , bağımlı değişkeni açıklayan gecikme değerini, ε_t hata terimini, b_0 ile b_1 bilinmeyen parametreleri ve Denklem (4)'deki z_t ortalaması 0, varyansı 1 olan rassal hata sürecini temsil etmektedir. Bu sayede finansal verilerin modellenmesinde görülen değişen varyans ve oynaklık kümelenmesi bu model içerisinde yer almaktadır.

ARCH modeli oynaklık sürecini açıklarken gecikme sayısının fazla olduğu durumlarda çok fazla parametreye ihtiyaç duyar ve bu durum tahmincilerin etkinliğini düşürmektedir. Ayrıca gecikmelerin uzun olduğu durumlarda koşullu varyans denklemindeki parametrelerin negatif olmama kısıtı da sağlanamamaktadır. Bundan dolayı Bollerslev (1986: 308), ARCH modelinin genişletilmiş hali olan, içerisinde daha fazla geçmiş bilgi barındıran ve gecikme yapısı daha esnek olan bir model geliştirmiştir. Bu modele genelleştirilmiş ARCH veya GARCH modeli denilmektedir. Bu model ARCH modelinin bir alternatifi değildir sadece ARCH modelinin eksikliklerini gidermeyi amaçlamaktadır.

Varyansın etkisinin simetrik olduğu kabul edilen ARCH ve GARCH modellerinde, pozitif veya negatif olduğuna bakılmaksızın büyüklüğü mutlak değerce eşit olan şokların oynaklık üzerinde aynı etkiye sahip olduğu varsayılmaktadır. Ayrıca bu modeller oynaklığın sadece büyüklüğünü ele almaktadır. Oysa finansal piyasaların algılama şekillerine göre, olumlu ve olumsuz bir haberin oynaklık üzerindeki etkisi farklı olmakta, azalış yönündeki dalgalanmalar artış yönündeki dalgalanmalardan daha fazla oynaklığa sebep olmaktadır (Nelson, 1991). Bu sebeple, asimetrik ilişkinin varlığının yanında kaldıraç etkisi olarak bilinen etkinin de belirlenmesine imkan tanıyan EGARCH modeli geliştirilmiştir.

Volatilitiyi açıklamada asimetrik etkiyi dikkate alan bir diğer modelde eşik değerli ARCH (TARCH) modelidir (Zakoian, 1994). Bu çalışmada kullanılan ve koşullu varyans üzerindeki asimetriklik etkisini hesaba katan son model ise, Ding vd. (1993) tarafından geliştirilen asimetrik üslü ARCH (Asymmetry Power ARCH-APARCH) modelidir.


Yapay Sinir Ağları

Yapay sinir ağları, insan beynine ait biyolojik sinir ağlarından esinlenerek geliştirilen, birbirlerine

belirli ağırlıklar ile bağlı öğrenme algoritmalarından ve transfer fonksiyonlarından oluşmaktadır (Elmas, 2003). Daha açık bir ifadeyle yapay sinir ağlarının yapısı, girişi yapılan verilerden çıktılar üretebilen, basit bir matematiksel fonksiyonu ifade eden bir kara kutu olarak tanımlanmaktadır. Yapay sinir ağları işlem süreci Şekil 1'de gösterilmiştir. Sistemin ilk adımı olan veri girişlerinin ardından işlemci elemanlar (nöronlar) ve bağlantı elemanları (aksonlar) işlemi çıkışa doğru devam ettirmektedir.

Yapay sinir hücresi, biyolojik sinir hücresinin gösterdiği davranışlar temel alınarak geliştirilen matematiksel kalıbı çalıştıran bir algoritma şeklinde tanımlanabilir. X_1, X_2, \dots, X_n gibi girdilerin ağırlıklarıyla çarpılıp toplanmasının ardından doğrusal veya doğrusal olmayan bir aktivasyon (transfer) fonksiyonundan $f(\text{net})$ geçilmektedir. Bu durum, W_{ni} ve W_{n0} 'in ağırlıkları ifade ettiği Denklem (6)'da görülmektedir (İnan ve Aras, 2005).

$$y_n = f(\text{net}_n) = f\left(\sum_{i=1}^n w_{ni} x_i + w_{n0}\right) \quad (6)$$



Şekil 1: Yapay Sinir Ağları İşlem Süreci (Kaynak: Öztemel, 2012:30)

Transfer (aktivasyon) fonksiyonu, hücreye ulaşan net girdiyi işleme tabi tutarak bu girdiden elde edilecek çıktıyı oluşturmaktadır. Bunun için farklı formüller kullanılmaktadır. Transfer fonksiyonu seçiminde dene-yanılma yöntemi kullanılır. Çünkü uygun fonksiyonu gösteren bir formül yoktur. Yapay sinir ağları, ileri beslemeli (feedforward) ve geri beslemeli (feedback veya recurrent) ağlar olmak üzere ikiye ayrılmaktadır. İleri beslemeli ağlarda katmanlar halinde bulunan işlem elemanları tüm katmanlardaki işlem elemanları ile bağlantı kurarlar. İleri beslemeli ağlarda sinyallerin iletimi girdi katmanından çıktı katmanına doğru olarak yalnızca tek yönde gerçekleşmektedir. Ayrıca gizli katmandaki nöronların doğrusal olmayan davranışları, ileri beslemeli ağlarında doğrusal olmayan bir yapı göstermesine neden olmaktadır (Efe ve Kaynak, 2000).

Çok Katmanlı Algılayıcı (Multilayer Perceptrons) ve Doğrusal Vektör Parçalama Modeli (Learning Vector Quantization) ileri beslemeli ağ örneklerindendir (Sağıroğlu vd. 2003). Zaman serilere ait yapılan öngörülerde oldukça başarı sağlayan geri beslemeli ağların, ileri beslemeli ağlardan temel farkı hücrelerin ürettiği çıktılarının girdi katmanına gönderilerek yeniden girdi olarak kullanılabilmesidir (Zhang, 2003). Bu duruma geri besleme denmektedir ve katman içinde bulunan hücreler arasında olabildiği gibi, katmanlar arasında bulunan hücreler arasında da olabilmektedir.

Yapay sinir ağlarının eğitimi konusunda kullanımı en yaygın olan öğrenme algoritması geri yayılım (backpropagation) algoritmasıdır. Ancak standart geri yayılım algoritmasının hesaplama zamanının çok uzun olması ve yerel minimumda yakınsama riski gibi bazı zayıf noktaları vardır. Bu çalışmada bahsedilen sebeplerden dolayı, çeşitli optimizasyon yöntemleri ile geliştirilen daha yüksek performanslı Levenberg-Marquardt yöntemi kullanılmıştır (Aşkın vd. 2011).

BULGULAR

Bu çalışmada ilk olarak, doğrusal bir yapı sergilemediği Brock vd. (BDS) testiyle belirlenen Vadeli İşlem ve Opsiyon Piyasası'nın etkinliği, çeşitli birim kök testleri uygulanarak sınanmıştır. Ardından serilere, tek değişkenli zaman serisi yöntemi olan Box-Jenkins (1976) (ARMA – Otoregresif Hareketli Ortalama), otoregresif koşullu değişen varyans modelleri (ARCH, GARCH, EGARCH...) ve son olarak yapay sinir ağları yöntemi uygulanarak gelecek dönem öngörü işlemi gerçekleştirilmiştir.

Vadeli İşlemler ve Opsiyon Piyasası'nın Zayıf Formda Etkinliğinin Test Edilmesi

BDS testinin boş hipotezi olan serinin bağımsız ve özdeş dağılıma sahip olması durumunun reddedilmesi halinde seride doğrusal bağımlılığın olduğu, serinin durağan olmadığı ve son olarak seride doğrusal olmayan bağımlılık olduğu anlamlarından herhangi birisi oluşabilmektedir. En genel haliyle doğrusal olmayan yapının sorgulandığı bu testte, Tablo 1'de de görüldüğü gibi, getiri serilerinin tüm boyutlarında doğrusal olmayan bir yapının var olduğu ortaya çıkmaktadır.

Getiri serisinin zayıf formda etkinliğinin sınılabilmesi serinin birim kök içerip içermediğini araştırabilmek amacıyla, Genişletilmiş (Augmented) Dickey-Fuller (ADF), Phillips-Perron (PP), Kwiatkowski vd. (KPSS) doğrusal birim kök testleri ve Kapetanios,

Shin ve Snell (KSS) doğrusal olmayan birim kök testi uygulanmıştır. ADF, PP ve KSS testleri serinin birim kök içerdiğini savunan boş hipotezi test ederken, KPSS testi ise serinin durağan olduğunu savunan boş hipotezi test etmektedir.

Tablo 1: BDS Testi Sonuçları

	Boyut	BDS istatistiği	Standart Hata	Z-istatistiği
rusd	2	0.0214	0.0017	12.1029
	3	0.0395	0.0028	14.0281
	4	0.0530	0.0033	15.7551
	5	0.0598	0.0035	17.0427
	6	0.0619	0.0033	18.2748
	rbist30	2	0.0119	0.0016
3		0.0280	0.0026	10.5254
4		0.0406	0.0031	12.8214
5		0.0475	0.0032	14.4335
6		0.0500	0.0031	15.7664

Tablo 2: Getiri Serilerinin Durağanlık Testi Sonuçları

ADF test istatistiği			
	Sabitli	Sabitli, Trendli	Sabitsiz
rusd	-51.44	-51.46	-51.40
rbist30	-51.04	-51.03	-51.02
PP test istatistiği			
	Sabitli	Sabitli, Trendli	Sabitsiz
rusd	-51.44	-51.46	-51.40
rbist30	-51.03	-51.02	-51.02
KPSS test istatistiği			
	Sabitli	Sabitli, Trendli	
rusd	0.18	0.02	
rbist30	0.04	0.03	
KSS Birim Kök Testi			
rusd		-8.244	
rbist30		-4.085	

Not: KPSS testi için kritik değerler, %1, %5 ve %10 için sabitli ve trendli modeller için sırasıyla, 0.73, 0.46, 0.34 ve 0.21, 0.14, 0.11'dir. KPSS testi için ise, -3.48, -2.93 ve -2.66'dir.

Tablo 2'deki birim kök testleri sonuçlarına göre, getiri serisi düzeyde durağandır yani birim kök içermemektedir. Bu sonuçlara dayanarak Türkiye'de faaliyet gösteren Vadeli İşlem ve Opsiyon Piyasası'nın zayıf formda etkin bir piyasa olmadığı sonucuna ulaşılmakta ve geçmiş dönemlerde oluşan fiyatlar kullanılarak gelecek dönemlerde oluşacak olan fiyatları öngörme ihtimali söz konusu olmaktadır. Bundan dolayı, tek değişkenli zaman serisi yöntemi olan Box-Jenkins (ARMA – Otoregresif Hareketli Ortalama), otoregresif koşullu değişen varyans modelleri (ARCH, GARCH, EGARCH...) ve yapay sinir ağları yöntemi, getiri serisinin gelecek

dönem değerini öngörmek için kullanılacak ve bu yöntemler arasından öngörü performansı en yüksek olan yöntem belirlenebilecektir.

Getiri Serilerinin Fiyat Öngörüsü

Getiri serilerinin tanımlayıcı istatistiklerine ilişkin bilgiler Tablo 3'de görülmektedir.

Tablo 3: Getiri Serilerinin Tanımlayıcı İstatistikleri

	Rusd	Rbist30
Ortalama	0.000126	0.000167
Medyan	-0.000146	0.000195
Maksimum	0.035784	0.041940
Minimum	-0.027607	-0.043563
Standart Sapma	0.003810	0.008066
Çarpıklık	0.806074	-0.165997
Basıklık	11.09327	6.109282
Jarque-Bera	7706.663	1106.527
Olasılık	0.0000	0.0000

Ortalama değerleri düşük olan getiri serilerinin basıklık değerlerinin normal dağılım için kritik değer olan 3'den oldukça büyük olduğu görülmektedir. Getiri serilerinin sıfırdan farklı olan çarpıklık değerleri Jarque-Bera istatistiğini büyütme ve bu durum normal dağılım hipotezinin reddedilmesi anlamına gelmektedir. Ayrıca Jarque-Bera testine göre, getiri serilerinin normal dağılımı üzerine kurulu olan boş hipotez tüm getiri serileri için %1 anlamlılık düzeyinde reddedilmektedir. Çarpıklık değerinin negatif olması serinin soldan çarpık dağılıma sahip olduğu anlamına geldiği için, Tablo 3'deki değerlere göre, *Rusd* serisi sağa çarpık, *Rbist30* serisi ise sola çarpıktır. Basıklık değeri ise normal dağılımda 3 değerini alırken getiri serilerinde 3'den oldukça büyük olduğu için, seriler normal dağılıma göre daha sivri bir tepeye (leptokurtik) ve daha kalın kuyruk (thick-tail) yapısına sahip olduğu görülmektedir.

En uygun otoregresif hareketli ortalama modelinin bulunabilmesi için Box-Jenkins metodolojisi izlenerek model parametrelerinin anlamlılığı, belirlilik katsayısı, bilgi kriterleri, hata karelerinin toplamı (SSE), modelin F istatistiği ve olabilirlik oranı gibi değerler dikkate alınmış ve uygulanan modellerin korelogramlarından otokorelasyon ve kısmi korelasyon katsayıları incelenmiştir. Öncelikle getiri serileri düzey değerlerinde durağan olduğu için, ARIMA modelinde bütünleşme derecesini gösteren kısım olan "I" sıfır değerini alır ve model ARIMA(p,0,q) yani ARMA(p,q) olur. AR(p), MA(q) ve ARMA(p,q) modellerine ait p ve q terimlerinin

belirlenebilmesi için p,q=1,2,3,4,5 modelleri tahmin edilmiştir. Öncelikle farklı p ve q kombinasyonları ile kurulan modellerde katsayıların istatistiksel olarak anlamlılığı %1 anlamlılık düzeyinde test edilmiştir. Sonra ki aşamada katsayıların istatistiksel olarak anlamlı olan ARMA(p,q) modellerinin kontrolü F testi yardımıyla yapılmıştır. Son olarak, diğer iki koşulun sağlanması şartıyla en düşük Akaike Bilgi Kriteri (AIC) değerine sahip olan model uygun model olarak seçilmiştir. Tablo 4'de yer alan sonuçlara göre, rusd için ARMA(4,4), rbist30 için ise ARMA(4,5) uygun model olarak belirlenmiştir.

Tablo 4: rusd ve rbist30 Getiri Serileri İçin Bulunan Uygun ARMA Modellerinin Öngörü Performansı

	rusd – ARMA(4,4)	rbist30 – ARMA(4,5)
RMSE	0.003786	0.008001
MAE	0.002615	0.005795
MAPE	110.0826	112.2808
TIC	0.886945	0.875445

Getiri serilerini koşullu varyans modelleri ile modelleyebilmek ve bu modellerle öngörü yapabilmek için öncelikle bulunan ortalama modellerinin hata terimlerinin karesinde ARCH etkisinin olup olmadığı araştırılmalıdır. Bu nedenle serilere önce ARCH-LM testi uygulanmış ardından hata terimlerinin korelogramlarından ARCH etkisinin varlığı araştırılmıştır.

Tablo 5 incelendiğinde, rusd ve rbist30 getiri serilerinin olasılık değerleri %1'den küçük olduğu için bu serilerde ARCH etkisinin olmadığını ifade eden sıfır hipotezi reddedilmiştir. Yani ARCH etkisinin varlığı tespit edilmiş olup bu etkinin giderilmesi gerekmektedir.

Tablo 5: Getiri Serisine Uygulanan ARCH-LM Testi Sonuçları

	rusd ARMA(4,4)	rbist30 ARMA(4,5)
F-İstatistiği	13.2028	49.5573
Olasılık F	0.0000	0.0000
Gözlem sayısı*R²	537.1757	48.7030
Olasılık Ki-Kare(1)	0.0000	0.0000

Bu aşamadan sonra varlığı tespit edilen ARCH etkisini giderecek en uygun modeli belirleyebilmek için, normal dağılım, student-t dağılımı ve GED dağılımları için ayrı ayrı olarak, ARCH(1,2,3,4), GARCH(1,1), GARCH(1,2), GARCH(2,1), GARCH(2,2), EGARCH(1,1), TGARCH(1,1), APARCH(1,1) modelleri kurulmuştur. Model sonuçlarına göre, rusd getiri serisi için yalnızca ARCH(1), ARCH(2), ARCH(3), ARCH(4), GARCH(2,1) ve

GARCH(2,2) modellerinde, rbist30 getiri serisi için ise tüm modellerde ARCH etkisinin giderildiği görülmüştür. Bu çalışmada, üç ayrı dağılım için hesaplanan 11 ayrı koşullu değişen varyans modelinin öngörü işlemi gerçekleştirilmiş ve en iyi öngörü performansı gösteren modellere ilişkin sonuçlar Tablo 6'da sunulmuştur. Elde edilen sonuçlara göre, ortalama hata karesinin kökü (root mean squared error – RMSE), kriterine göre yapılan sıralamada, normal dağılım ARCH(1) modeli her iki getiri serisi için de en yüksek performansı gösteren model olmuştur.

Bu çalışmada kullanılan TL/Dolar ve Bist30 endeksi veri setinden elde edilen getiri serilerinin (-1,1) aralığında yer alması ve durağan olması sebebiyle serilere herhangi bir normalizasyon işlemi uygulanmamıştır. Veri seti, %70-15-15, %70-20-10 ve %80-10-10 olmak üzere üç farklı veri ayırma yüzdesi kullanılarak, eğitim, geçerlilik ve test kısımlarına ayrılmış ve farklı girdi katman nöron sayılarına göre performansları ölçülmüştür. Farklı yüzdelik kısımlara ayrılan veri setleri, 1,2,3,4,5 ve 10 girdi katmanı nöron sayıları ile çok

katmanlı algılayıcılar (Multilayer perceptrons - MLPs), genelleştirilmiş ileri beslemeli ağlar (Generalized feed forward networks – GFF), temel bileşenler analizi ağları (Principal component analysis networks – PCAs), radyal tabanlı fonksiyon (Radial basis function – RBF), zaman gecikmeli geri beslemeli ağlar (Time lagged recurrent networks – TLRNs), geri beslemeli ağlar (Recurrent network) türündeki yapay sinir ağı modelleri kullanılarak analiz edilmiştir. Bu işlemlerin amacı, kullanılacak olan en iyi yapay sinir ağına ilişkin veri setini ve bu veri seti kullanılarak oluşturulan ağdaki en düşük RMSE değerine sahip girdi katmanı nöron sayısını belirleyebilmektir.

Tablo 7'de yer alan sonuçlara göre, rusd getirisi serisi için, %70 eğitim, %15 geçerlilik ve %15 test veri seti ve girdi katmanında 2 adet nöron bulunan, gizli katmanında Linear Sigmoid Axon, çıktı katmanında LinearTanhAxon aktivasyon fonksiyonlarının kullanıldığı RBF-1-B-L modeli en düşük RMSE değerine sahip model olarak belirlenmiştir.

Tablo 6: rusd ve rbist30 Getiri Serileri İçin En İyi Öngörü Performansı Gösteren Koşullu Değişen Varyans Modelleri

rusd	Model	Dağılım	RMSE	MAE	MAPE	TIC
1	ARCH(1)	Normal	0.003795	0.002622	110.0102	0.892563
2	ARCH(1)	Student-t	0.003806	0.002601	102.7311	0.925485
3	GARCH(1,2)	GED	0.003811	0.002599	101.1398	0.932783
rbist30	Model	Dağılım	RMSE	MAE	MAPE	TIC
1	ARCH(1)	Normal	0.008027	0.005823	112.2579	0.882351
2	ARCH(4)	GED	0.008032	0.005796	109.9203	0.891834
3	ARCH(1)	Student-t	0.008041	0.005799	107.0116	0.905711

Tablo 7: Getiri Serileri İçin En İyi Performans Gösteren Yapay Sinir Ağı Modelleri

	Rusd	Rbist30
Ağın Türü	RBF-1-B-L	TDNN-1-B-L
Veri Sayısı (Eğitim-Test-Doğrulama)	%70 (1932) - %15 (407) - %15 (407)	%70 (1932) - %15 (407) - %15 (407)
Ağdaki Toplam Katman Sayısı	3	3
Girdi Katmanındaki Nöron Sayısı	2	2
Gizli Katmandaki Nöron Sayısı	18	18
Çıktı Katmanındaki Nöron Sayısı	1	1
Gizli Katmandaki Aktivasyon Fonksiyonu	Linear Sigmoid Axon	LinearTanhAxon
Çıktı Katmanındaki Aktivasyon Fonksiyonu	LinearTanhAxon	Sigmoid Axon
Öğrenme Algoritması	LevenbergMarquardt	LevenbergMarquardt
Eğitim Türü	Batch	Batch
Döngü (epoch) Sayısı	1000	1000
RMSE	Eğitim	0.004094
	Doğrulama	0.012020
	Test	0.003138
MAE	Eğitim	0.002832
	Doğrulama	0.002841
	Test	0.002346

Rbist30 getirisi serisi için ise benzer şekilde, %70 eğitim, %15 geçerlilik ve %15 test veri seti ve girdi katmanında 2 adet nöron bulunan, gizli katmanında LinearTanhAxon, çıktı katmanında Sigmoid Axon aktivasyon fonksiyonlarının kullanıldığı TDNN-1-B-L modeli en düşük RMSE değerine sahip model olarak belirlenmiştir.

Modellerin Performanslarının Karşılaştırılması

Bu çalışmada kullanılan modellere ilişkin bir performans karşılaştırması yapabilmek amacıyla modellerin ortalama hata karesinin kökü (RMSE) kullanılarak sıralama yapılmıştır. Yapay sinir ağı modelleri için kullanılan RMSE değeri eğitim, doğrulama ve test setine ait değerlerin ortalamasından oluşmaktadır. Tablo 8'de sonuçları görülmekte olan bu sıralama sonucunda, rusd getiri serisi için, ARMA(4,4) modeli bu çalışmada ele alınan tüm modeller içerisinde en yüksek performansı göstermiştir. Bu modeli ARCH(1) modeli ile yapay sinir ağlarına ilişkin RBF-1-B-L modeli izlemiştir. Benzer şekilde rbist30 getiri serisi için yapılan sıralamada ise yapay sinir ağlarına ilişkin TDNN-1-B-L modeli bu çalışmada kullanılan tüm modeller içerisinde en yüksek performansı göstermiş ve bu modeli ise ARMA(4,5) ve ARCH(1) modeli izlemiştir. Böylece yapay sinir ağları modellerinin doğrusal olmayan serilerdeki öngörü başarısı (Sterbaand ve Hilovska, 2010) rbist30 getiri serisi için geçerli olurken, rusd getiri serisi için ise ARIMA modellerinin yapay sinir ağı modellerine kıyasla daha yüksek performans gösterdiği ortaya çıkmıştır (Lee vd. 2007; Merh vd. 2010). Bu sonuçlar çalışmayı geleneksel zaman serileri yöntemlerine karşı öngörü işleminde yapay sinir ağlarının daha üstün olduğu sonucuna ulaşan çalışmalardan (Moralı, 2011; Adebıy vd. 2014; Kadılar vd. 2009; Panda ve Narasimhan, 2007; Akdağ, 2010) kısmen farklılaşmaktadır.

Tablo 8: rusd ve rbist30 Getiri Serileri için Tüm Modeller Açısından Performans Karşılaştırması

rusd			
	Model	RMSE	MAE
1	ARMA(4,4)	0.003786	0.002615
2	ARCH(1)	0.003795	0.002622
3	RBF-1-B-L	0.006417	0.002673
rbist30			
	Model	RMSE	MAE
1	TDNN-1-B-L	0.007289	0.005351
2	ARMA(4,5)	0.008001	0.005795
3	ARCH(1)	0.008027	0.005796

SONUÇ

Bu çalışmada amaç, Türkiye'de faaliyet gösteren Vadeli İşlem ve Opsiyon Piyasası'nın zayıf formda etkinliğinin hem doğrusal hem de doğrusal olmayan birim kök testleri ile sınanması ve sözleşme verilerinin öngörüsü gerçekleştirilirken yapay sinir ağları ve zaman serileri modellerinin karşılaştırılarak en iyi yöntemin belirlenmesidir.

Bu sebepten, öncelikle Türkiye'de faaliyet gösteren Vadeli İşlem ve Opsiyon Piyasası'nın etkinliği; Genişletilmiş (Augmented) Dickey-Fuller (ADF), Phillips-Perron (PP) ve Kwiatkowski vd. (KPSS) doğrusal birim kök testleri ve Kapetanios vd. (KSS) doğrusal olmayan birim kök testi uygulanarak sınanmıştır. Uygulanan tüm birim kök testleri sonucunda serilerin birim kök içermediğine yani rassal yürüyüş sergilemediğine karar verilmiş, böylece piyasanın etkin olmadığı sonucuna ulaşılmıştır. Ardından, zayıf formda etkin olmadığı belirlenen Vadeli İşlem ve Opsiyon Piyasası'nda işlem gören TL/Dolar ve Bist-30 sözleşmelerinin gün sonu uzlaşma fiyatının öngörülmesinde en yüksek performansı gösteren yöntemin belirlenmesi amaçlanmıştır. Bu amaçla, Borsa İstanbul A.Ş'den temin edilen ve 04.02.2005 – 31.12.2015 tarihleri arasını kapsayan veriler kullanılmış ve farklı öngörü sonuçları elde edilmiştir. Son olarak, zaman serileri analizi yöntemlerinin ürettiği öngörü sonuçları ile farklı mimariler, katman sayıları, katmanlardaki hücre sayıları, aktivasyon fonksiyonları ve öğrenme yöntemleri denenerek ulaşılan yapay sinir ağı modeli sonuçları karşılaştırılmıştır. Bu çalışmadan elde edilen bulgulara göre, TL/Dolar sözleşme serisi için, ARMA(4,4) modeli, RBF-1-B-L yapay sinir ağı modeli ve ARCH(1) modeline kıyasla daha yüksek öngörü performansı göstermiştir. Bist-30 sözleşme serisi için ise TDNN-1-B-L yapay sinir ağı modeli, ARMA(4,5) ve ARCH(1) modeline kıyasla daha yüksek öngörü performansı gösteren bir model olmuştur.

Türkiye'de faaliyet gösteren Vadeli İşlem ve Opsiyon Piyasası'nın zayıf formda etkin olmadığını kanıtlayıp, sözleşme serilerinin öngörü işlemini gerçekleştirerek literatüre katkı sağlayan bu çalışmanın sonuçlarına göre, türev piyasalara ilişkin finansal verilerin gelecek dönem değer öngörüsü yapılırken yapay sinir ağları, zaman serileri analizine bir alternatif olarak kullanılmıştır. Finansal varlık fiyatlarının rassal olarak hareket etmediği yani zayıf formda etkin olmadığı kanıtlanan piyasalarda geleceğe ilişkin risk ve belirsizliği ortadan kaldırmak için finansal varlıkların fiyatlarına ilişkin öngörülerde bulunmak isteyen karar alma birimlerinin

ARIMA modelleri ve yapay sinir ağıları modellerini kullanmasının daha uygun olduğu görülmektedir. Ancak bu çalışmanın sonuçlarına göre öngörü işleminde iki yöntemin birbirine karşı kesin bir üstünlüğü olmamakla birlikte modellerin öngörü performansı da analizde kullanılan seriye göre değişmektedir.

KAYNAKÇA

- Adebiyi, A. A., Adewumi, A., O. ve Ayo, C. K. (2014). Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction. *Journal of Applied Mathematics*. <http://dx.doi.org/10.1155/2014/614342>.
- Akcan, A. ve Kartal, C. (2011). İMKB Sigorta Endeksi Oluşturan Şirketlerin Hisse Senedi Fiyatlarının Yapay Sinir Ağları ile Tahmini. *Muhasebe ve Finansman Dergisi*, Temmuz, 27-40.
- Akdağ, Y. (2010). *Vadeli İşlem ve Opsiyon Borsası'nda TL/ Dolar Vadeli İşlem Sözleşmelerinin Gün Sonu Uzlaşma Fiyatının Yapay Sinir Ağları ile Tahmini*. (Yayınlanmamış Yüksek Lisans Tezi). Marmara Üniversitesi/ Bankacılık ve Sigortacılık Enstitüsü, İstanbul.
- Arabacı, Ö. (2007). *Makroekonomik Zaman Serisi Analizi ve Yapay Sinir Ağı Uygulamaları*. (Yayınlanmamış Doktora Tezi). Uludağ Üniversitesi/ Sosyal Bilimler Enstitüsü, Bursa
- Aşkın, D., İskender, İ. ve Mamizadeh, A. (2011). Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformatör Sargısının Termal Analizi. *Gazi Üniv. Müh. Mim. Fak. Dergisi*, 26(4), 905-913.
- Avcı, E. (2007). Forecasting Daily and Sessional Returns of the ISE-100 Index with Neural Network Models. *Doğuş Üniversitesi Dergisi*, 8(2), 128-142.
- Aydın, A. D. ve Çavdar, S. Ç. (2015). Comparison of Prediction Performances of Artificial Neural Network (ANN) and Vector Autoregressive (VAR) Models by Using the Macroeconomic Variables of Gold Prices, Borsa İstanbul (BIST) 100 Index and US Dollar-Turkish Lira (USD/TRY) Exchange Rates. *Procedia Economics and Finance*, 30, 3-14.
- Aygören, H., Sarıtaş, H. ve Moralı, T. (2012). İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini. *International Journal of Alanya Faculty of Business*, 4(1), 73-88.
- Box, G. ve Jenkins G. (1976). *Time Series Analysis, Forecasting and Control*. San Francisco: Holden Day.
- Çelik, B. (2008). *Yapay Sinir Ağları Metodolojisi İle Zaman Serisi Analizi: Teori ve Uygulama*. (Yayınlanmamış Yüksek Lisans Tezi). Marmara Üniversitesi/Sosyal Bilimler Enstitüsü, İstanbul.
- Dickey, D. A. ve Fuller, W. A. (1979). Distribution of Estimators for Time Series Regressions with a Unit Root. *Journal of the American Statistical Association*, 74, 427-431.
- Efe, M. Ö. ve Kaynak O. (2000). *Yapay Sinir Ağları ve Uygulamaları*. İstanbul: Boğaziçi Üniversitesi.
- Elmas, Ç. (2003). *Yapay Sinir Ağları*. Ankara: Seçkin.
- Engel, R. F. (1982). Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of U.K Inflation. *Econometrica*, 50, 987-1008.
- Kadılar, C., Şimşek, M. ve Aladağ Ç., H. (2009). Forecasting the Exchange Rate Series with ANN: The Case of Turkey. *Ekonometri ve İstatistik Dergisi*, 9, 17-29.
- Kapetanios, G., Shin, Y. ve Snell, A. (2003). Testing for a Unit Root in the Nonlinear STAR framework. *Journal of Econometrics*, 112(2), 359-379.
- Kaynar, O. ve Taştan, S. (2009). Zaman Serisi Analizinde MLP Yapay Sinir Ağları ve ARIMA Modelinin Karşılaştırılması. *Erciyes Üniversitesi İktisadi İdari Bilimler Dergisi*, 33, 161-172.
- Kwiatkowski, D., Phillips, P. C. B., Schmidt, P. ve Shin, Y. (1992). Testing the Null Hypothesis of Stationarity Against the Alternative of a Unit Root, How Sure Are We That Economic Time Series Have a Unit Root?. *Journal of Econometrics*, 54, 159-178.
- Lee, C. K., Sehwan, Y. ve Jongdae, J. (2007). Neural Network Model Versus SARIMA Model in Forecasting Korean Stock Price Index (KOSPI). *Issues in Information System*, 8(2), 372-378.
- Merh, N., Saxena, V. P. ve Pardasani, K. R. (2010). A Comparison Between Hybrid Approaches of ANN and ARIMA for Indian Stock Trend Forecasting. *Journal of Business Intelligence*, 3(2), 23-43.
- Moralı, T. (2011). *İMKB 100 Endeksinin yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini ve Sonuçlarının Karşılaştırılması*. (Yayınlanmamış Yüksek Lisans Tezi). Pamukkale Üniversitesi/ Sosyal Bilimler Enstitüsü, Denizli.
- Özdemir, Ö. (2008). *Zaman Serisi Modellemesinde Yapay Sinir Ağlarının Kullanımı ve Bir Uygulama*. (Yayınlanmamış Yüksek Lisans Tezi). Anadolu Üniversitesi/ Fen Bilimleri Enstitüsü, Eskişehir.
- Öztemel, E. (2012). *Yapay Sinir Ağları*. İstanbul: Papatya.
- Panda, C. ve Narasimhan, V. (2007). Forecasting Exchange Rate Better with Artificial Neural Network. *Journal of Policy Modelling*, 29, 227-236.
- Phillips, P. C. B. ve Perron, P. (1988). Testing for a Unit Root in Time Series Regressions. *Biometrika*, 75, 335-346.
- Qi, M. ve Zhang, G.,P. (2008). Trend Time-Series Modelling and Forecasting with Neural Networks. *Ieee Transactions on Neural Networks*, 19(5), 808 – 816.

- Sađırođlu, Ő., BeŐdok, E. ve Erler, M. (2003). *Mühendislikte Yapay Zeka Uygulamaları-1: Yapay Sinir Ağları*. Kayseri: Ufuk.
- Servüktekin, M. ve Nargeleçekenler, M. (2005). *Zaman Serileri Analizi*. Ankara: Nobel.
- Shazly, M. R. ve Shazly, H. E. (1999). Forecasting Currency Prices Using a Genetically Evolved Neural Network Architecture. *International Review of Financial Analysis*, 8(1), 67-82.
- Sterbaand, J. ve Hilovska, K. (2010). The Implementation of Hybrid ARIMA Neural Network Prediction Model for Aggregate Water. *Aplimat Journal of Applied Mathematics*, 3(3), 123-131.
- Tsay, R. ve S. (2010). *Analysis of Financial Time Series*. New York: Wiley Series in Probability and Statistics.
- Yavuz, N. Ç. (2014). *Finansal Ekonometri*. Der.
- Zahedi, J. ve Rounaghi, M. M. (2015). Application of Artificial Neural Network Models and Principal Component Analysis Method in Predicting Stock Prices on Tehran Stock Exchange. *Physica A*, 438, 178-187.
- Zhang, P. G. (2003). *Business Forecasting with Artificial Neural Networks: An Overview, Neural Networks in Business Forecasting*. (Ed.: Zhang, G. P.) Idea Group Publishing.

EKLER:**EK 1:** Rusd için Normal Dağılıma Göre Öngörü Performansı

Model	RMSE	MAE	MAPE	TIC
ARCH(1)	0.003795	0.002622	110.0102	0.892563
GARCH(2.1)	0.003799	0.002613	103.7832	0.924174
EGARCH(1.1)	0.003799	0.002617	106.1735	0.91882
GARCH(1.2)	0.003802	0.00262	103.4306	0.920226
GARCH(2.2)	0.003802	0.00262	103.0366	0.921508
ARCH(4)	0.003806	0.002617	102.1267	0.941749
GARCH(1.1)	0.003808	0.002622	104.07	0.919991
ARCH(2)	0.003809	0.002623	102.5257	0.939764
ARCH(3)	0.003809	0.002616	100.2623	0.094826
TGARCH(1.1)	0.003809	0.002624	104.822	0.934761
APARCH(1.1)	0.003809	0.002619	101.6738	0.942717

EK 2: Rusd için Student-t Dağılımına Göre Öngörü Performansı

Model	RMSE	MAE	MAPE	TIC
ARCH(1)	0.003806	0.002601	102.7311	0.925485
ARCH(2)	0.003811	0.002603	102.3651	0.937056
GARCH(2.1)	0.003811	0.0026	100.1716	0.939353
APARCH(1.1)	0.003812	0.002606	99.22791	0.956989
GARCH(1.1)	0.003813	0.002599	100.255	0.935775
GARCH(1.2)	0.003813	0.002611	98.47579	0.09724
ARCH(3)	0.003814	0.002605	100.453	0.953414
GARCH(2.2)	0.003814	0.002601	98.84675	0.094983
EGARCH(1.1)	0.003814	0.002605	98.65923	0.959763
TGARCH(1.1)	0.003814	0.002604	99.07964	0.957599
ARCH(4)	0.003819	0.002602	101.4962	0.092836

EK 3: Rusd için GED Dağılımına Göre Öngörü Performansı

Model	RMSE	MAE	MAPE	TIC
GARCH(1.2)	0.003811	0.002599	101.1398	0.932783
GARCH(2.2)	0.003813	0.002598	101.765	0.92453
APARCH(1.1)	0.003813	0.002599	100.9585	0.92889
EGARCH(1.1)	0.003815	0.002605	100.7931	0.948106
ARCH(1)	0.003817	0.002605	99.30509	0.955436
GARCH(1.1)	0.003818	0.002605	99.89437	0.953384
TGARCH(1.1)	0.003818	0.002605	99.70433	0.954711
ARCH(2)	0.003819	0.002605	99.757	0.952182
ARCH(3)	0.003819	0.002605	99.93614	0.951113
GARCH(2.1)	0.003819	0.002599	100.0343	0.942208
ARCH(4)	0.003821	0.002605	100.4317	0.947654

EK 4: Rbist30 için Normal Dağılıma Göre Öngörü Performansı

Model	RMSE	MAE	MAPE	TIC
ARCH(1)	0.008027	0.005823	112.2579	0.882351
ARCH(2)	0.00803	0.005824	112.4953	0.883779
ARCH(3)	0.008041	0.005822	111.5436	0.897498
ARCH(4)	0.008046	0.005827	114.6397	0.882846
GARCH(1,1)	0.008063	0.005836	108.3833	0.915173
GARCH(2,1)	0.008063	0.005836	108.5376	0.91464
APARCH(1,1)	0.008063	0.005838	107.2363	0.91569
TGARCH(1,1)	0.008071	0.005846	107.2359	0.916984
GARCH(1,2)	0.008073	0.005849	109.4991	0.910945
GARCH(2,2)	0.008073	0.005849	109.5196	0.910893
EGARCH(1,1)	0.008077	0.005849	105.4851	0.926817

EK 5: Rbist30 için Student-t Dağılımına Göre Öngörü Performansı

Model	RMSE	MAE	MAPE	TIC
ARCH(1)	0.008041	0.005799	107.0116	0.905711
ARCH(2)	0.008043	0.005799	108.8764	0.907338
APARCH(1,1)	0.008048	0.005811	106.7911	0.907693
GARCH(2,1)	0.008054	0.005816	106.048	0.925921
EGARCH(1,1)	0.008058	0.005823	104.2293	0.933836
GARCH(1,1)	0.008059	0.005822	105.454	0.929945
GARCH(1,2)	0.008059	0.005822	105.5028	0.929686
GARCH(2,2)	0.00806	0.005822	105.5692	0.929318
ARCH(3)	0.008062	0.005804	106.363	0.913994
ARCH(4)	0.008078	0.00584	105.7233	0.932666
TGARCH(1,1)	0.008082	0.005833	108.6424	0.90705

EK 6: Rbist30 için GED Dağılımına Göre Öngörü Performansı

Model	RMSE	MAE	MAPE	TIC
ARCH(4)	0.008032	0.005796	109.9203	0.891834
GARCH(1,2)	0.008041	0.005801	108.3312	0.910859
TGARCH(1,1)	0.008047	0.005811	104.8247	0.921901
EGARCH(1,1)	0.008049	0.005806	107.5018	0.913988
ARCH(1)	0.008054	0.005797	105.3116	0.903912
GARCH(1,1)	0.008059	0.005819	105.359	0.927399
GARCH(2,1)	0.008059	0.005819	105.5089	0.9267
GARCH(2,2)	0.008059	0.005819	105.5128	0.926665
APARCH(1,1)	0.00806	0.005825	106.5053	0.912698
ARCH(2)	0.008061	0.005804	104.9472	0.915003
ARCH(3)	0.008063	0.005803	105.795	0.909505

EK 7: Rusd Getiri Serisi İçin %70-%15-%15 Modele Ait Sonuçlar

Model Adı	Girdi Katmanındaki Nöron Sayısı	Eğitim		Geçerlilik		Test	
		RMSE	MAE	RMSE	MAE	RMSE	MAE
RBF-1-B-L (RadialBasisFunction)	2	0.004077	0.002798	0.012024	0.002795	0.003133	0.002313
RBF-1-B-L (RadialBasisFunction)	3	0.004079	0.002805	0.01201	0.002791	0.003147	0.002342
RBF-1-B-L (RadialBasisFunction)	1	0.00408	0.002795	0.012017	0.002806	0.003149	0.002345
MLPR-1-B-L (Regression MLP)	1	0.004065	0.002818	0.012356	0.00299	0.003152	0.002357
RBF-1-B-L (RadialBasisFunction)	4	0.004078	0.002797	0.012006	0.00279	0.003156	0.002337
MLPR-1-B-L (Regression MLP)	2	0.004095	0.002833	0.012013	0.002833	0.00316	0.002365
GFFR-1-B-R (Reg Gen Feedforward)	2	0.004092	0.002815	0.012037	0.002848	0.00316	0.002348
MLPCPC-1-B-L (Class MLP with PCA)	4	0.004088	0.002827	0.012016	0.002814	0.003161	0.002361
LogR-0-B-R (LogisticRegression)	4	0.004093	0.002808	0.012047	0.002866	0.003162	0.002351
MLPCPC-1-B-R (Class MLP with PCA)	5	0.004091	0.002815	0.012011	0.0028	0.003163	0.002353
GFFC-1-O-M (Class Gen Feedforward)	1	0.004095	0.002813	0.012032	0.002845	0.003163	0.002352
MLPC-1-O-M (Classification MLP)	5	0.004091	0.002813	0.012004	0.002806	0.003163	0.002356
MLPR-2-B-L (Regression MLP)	3	0.004087	0.002808	0.012012	0.002797	0.003164	0.002349
MLPRPC-1-B-R (Reg MLP with PCA)	3	0.004084	0.002804	0.012014	0.00281	0.003164	0.002348
MLPC-2-O-M (Classification MLP)	5	0.004091	0.002817	0.012012	0.002801	0.003166	0.002355
MLPC-2-O-M (Classification MLP)	10	0.00409	0.002814	0.012014	0.002798	0.003167	0.002353
MLPCPC-1-B-L (Class MLP with PCA)	10	0.004085	0.002823	0.012018	0.002821	0.003168	0.00236
MLPC-1-B-R (Classification MLP)	10	0.004088	0.002806	0.012022	0.00281	0.003169	0.002349

EK 8: Rbist30 Getiri Serisi İçin %70-%15-%15 Modele Ait Sonuçlar

Model Adı	Girdi Katmanındaki Nöron Sayısı	Eğitim		Geçerlilik		Test	
		RMSE	MAE	RMSE	MAE	RMSE	MAE
MLPR-2-B-R (Regression MLP)	5	0.008445	0.006182	0.007754	0.005627	0.005486	0.004165
TLRN-1-O-M (Time-Lag Recurrent Network)	3	0.008452	0.006202	0.007947	0.00573	0.005489	0.004158
TDNN-1-B-L (Time-Delay Network)	2	0.008338	0.006121	0.007762	0.005547	0.005513	0.004179
MLPCPC-1-B-L (Class MLP with PCA)	4	0.008504	0.006192	0.007818	0.005657	0.005516	0.004201
RBF-1-B-R (Radial Basis Function)	4	0.008533	0.006226	0.007868	0.005648	0.005517	0.004209
MLPR-2-B-R (Regression MLP)	10	0.008375	0.006141	0.007732	0.005561	0.005517	0.004165
RBF-1-B-R (Radial Basis Function)	10	0.008508	0.006204	0.007924	0.00572	0.005517	0.004193
GFFR-1-B-R (Reg Gen Feedforward)	4	0.008482	0.006198	0.007845	0.005642	0.005519	0.004193
MLPR-1-B-R (Regression MLP)	5	0.008361	0.006171	0.007693	0.005558	0.005522	0.004197
GFFR-1-B-L (Reg Gen Feedforward)	5	0.008349	0.006152	0.007799	0.005602	0.005523	0.004199
MLPC-1-B-R (Classification MLP)	10	0.008556	0.006228	0.007854	0.005652	0.005523	0.004193
LinR-0-B-R (Linear Regression)	3	0.008549	0.006223	0.007868	0.00565	0.005531	0.004195
MLPR-1-B-L (Regression MLP)	1	0.008545	0.006218	0.007869	0.005662	0.005533	0.004203
MLPRPC-1-B-L (Reg MLP with PCA)	3	0.008541	0.006213	0.007839	0.00565	0.005533	0.004204
GFFC-1-O-M (Class Gen Feedforward)	2	0.008548	0.006224	0.007873	0.005659	0.005537	0.004209
MLPRPC-1-B-L (Reg MLP with PCA)	1	0.008544	0.006221	0.007876	0.005669	0.005537	0.004211
MLPRPC-1-B-R (Reg MLP with PCA)	1	0.008547	0.006225	0.00788	0.005671	0.005537	0.004211
MLPC-1-B-R (Classification MLP)	2	0.008555	0.006222	0.007851	0.005638	0.005537	0.004206
MLPR-2-B-R (Regression MLP)	5	0.008445	0.006182	0.007754	0.005627	0.005486	0.004165
TLRN-1-O-M (Time-Lag Recurrent Network)	3	0.008452	0.006202	0.007947	0.00573	0.005489	0.004158
TDNN-1-B-L (Time-Delay Network)	2	0.008338	0.006121	0.007762	0.005547	0.005513	0.004179

EK 9: Rusd Getiri Serisi İçin %70-%20-%10 Modele Ait Sonuçlar

Model Adı	Girdi Katmanındaki Nöron Sayısı	Eğitim		Geçerlilik		Test	
		RMSE	MAE	RMSE	MAE	RMSE	MAE
RBF-1-B-R (RadialBasisFunction)	2	0.004073	0.002798	0.01052	0.002593	0.00323	0.002477
RBF-1-B-L (RadialBasisFunction)	2	0.004082	0.002801	0.010492	0.002594	0.003269	0.002496
MLPRPC-1-B-L (Reg MLP with PCA)	4	0.004081	0.002853	0.010905	0.002901	0.003274	0.002537
RBF-1-B-L (RadialBasisFunction)	1	0.004081	0.002798	0.010497	0.002609	0.003276	0.002514
RBF-1-B-L (RadialBasisFunction)	4	0.004074	0.002798	0.010495	0.002588	0.003279	0.00251
RBF-1-B-R (RadialBasisFunction)	3	0.004078	0.002806	0.010482	0.0026	0.003283	0.002531
MLPRPC-1-B-R (Reg MLP with PCA)	3	0.004093	0.002826	0.010498	0.002606	0.003286	0.002534
TDNN-1-B-R (Time-Delay Network)	3	0.004007	0.002795	0.010578	0.002741	0.003286	0.002512
RBF-1-O-M (RadialBasisFunction)	2	0.004115	0.002794	0.010535	0.002625	0.00329	0.0025
RBF-1-O-M (RadialBasisFunction)	4	0.004145	0.002827	0.010455	0.002623	0.00329	0.002475
RBF-1-B-R (RadialBasisFunction)	1	0.004077	0.002794	0.010477	0.002592	0.003297	0.002535
MLPCPC-1-B-R (Class MLP with PCA)	5	0.004091	0.002816	0.010498	0.002594	0.003299	0.002536
MLPR-2-B-R (Regression MLP)	1	0.004088	0.002806	0.010498	0.002593	0.0033	0.002533
MLPC-1-O-M (Classification MLP)	5	0.004093	0.002811	0.010489	0.002592	0.003302	0.002532
RBF-1-B-R (RadialBasisFunction)	5	0.004069	0.002798	0.010498	0.002593	0.003303	0.002528
MLPC-2-O-M (Classification MLP)	10	0.004091	0.002817	0.010495	0.002594	0.003305	0.002539
MLPC-2-B-R (Classification MLP)	10	0.004092	0.002809	0.010499	0.002589	0.003305	0.002536
MLPCPC-1-O-M (Class MLP with PCA)	10	0.004094	0.002822	0.010494	0.002598	0.003307	0.002544

EK 10: Rbist30 Getiri Serisi İçin %70-%20-%10 Modele Ait Sonuçlar

Model Adı	Girdi Katmanındaki Nöron Sayısı	Eğitim		Geçerlilik		Test	
		RMSE	MAE	RMSE	MAE	RMSE	MAE
TDNN-1-B-L (Time-Delay Network)	5	0.008254	0.006099	0.007255	0.005235	0.005613	0.004257
TDNN-1-B-L (Time-Delay Network)	3	0.008408	0.006159	0.007258	0.005162	0.005622	0.004235
RBF-1-B-R (Radial Basis Function)	5	0.008496	0.006213	0.007309	0.005257	0.005638	0.004253
MLPRPC-1-B-L (Reg MLP with PCA)	10	0.008465	0.006211	0.007319	0.005278	0.005638	0.004261
TDNN-1-B-R (Time-Delay Network)	4	0.008346	0.00614	0.007247	0.005199	0.005638	0.004231
GFFR-1-B-R (Reg Gen Feedforward)	10	0.008332	0.00615	0.007316	0.005203	0.005644	0.004262
GFFC-1-B-L (Class Gen Feedforward)	10	0.008472	0.006194	0.007329	0.005237	0.005646	0.004247
TLRN-1-B-R (Time-Lag Recurrent Network)	3	0.008397	0.006149	0.007281	0.005256	0.005651	0.004253
MLPR-2-B-L (Regression MLP)	5	0.008428	0.006189	0.007225	0.005266	0.005653	0.00424
TDNN-1-B-R (Time-Delay Network)	3	0.008463	0.006181	0.007296	0.005261	0.005659	0.004249
MLPRPC-1-B-L (Reg MLP with PCA)	1	0.00855	0.006226	0.007298	0.005269	0.005671	0.00426
TLRN-1-B-R (Time-Lag Recurrent Network)	1	0.008549	0.006224	0.007299	0.005262	0.005671	0.004258
GFFR-1-B-R (Reg Gen Feedforward)	4	0.008494	0.006204	0.007311	0.005254	0.005672	0.004297
MLPR-2-O-M (Regression MLP)	4	0.008479	0.006203	0.007274	0.00525	0.005673	0.004275
RBF-1-B-L (Radial Basis Function)	1	0.008536	0.006225	0.007323	0.005277	0.005678	0.004297
TDNN-1-B-L (Time-Delay Network)	2	0.008364	0.006146	0.00718	0.005171	0.005684	0.004297
GFFC-1-B-R (Class Gen Feedforward)	2	0.008549	0.006226	0.007298	0.005259	0.005684	0.004276
LinR-0-B-L (Linear Regression)	2	0.008545	0.006224	0.007311	0.00527	0.005685	0.004283

EK 11: Rusd Getiri Serisi İçin %80-%10-%10 Modele Ait Sonuçlar

Model Adı	Girdi Katmanındaki Nöron Sayısı	Eğitim		Geçerlilik		Test	
		RMSE	MAE	RMSE	MAE	RMSE	MAE
RBF-1-B-L (RadialBasisFunction)	2	0.003933	0.002666	0.014599	0.003448	0.003258	0.002488
GFFC-1-O-M (Class Gen Feedforward)	5	0.003985	0.00272	0.014689	0.003719	0.003269	0.002513
GFFC-1-B-L (Class Gen Feedforward)	4	0.003959	0.00269	0.014669	0.003628	0.003277	0.002527
TDNN-1-B-L (Time-Delay Network)	4	0.003974	0.002747	0.014576	0.003659	0.00328	0.002514
RBF-1-B-L (RadialBasisFunction)	3	0.003937	0.00268	0.014585	0.003444	0.003281	0.002518
RBF-1-O-M (RadialBasisFunction)	2	0.003996	0.002789	0.014639	0.003546	0.003281	0.002522
MLPRPC-1-B-R (Reg MLP with PCA)	3	0.003957	0.002689	0.014586	0.003498	0.003283	0.002529
GFFC-1-O-M (Class Gen Feedforward)	2	0.003952	0.00269	0.014634	0.003566	0.003287	0.002526
MLPRPC-1-B-L (Reg MLP with PCA)	5	0.003918	0.002661	0.01634	0.00442	0.003291	0.002532
RBF-1-O-M (RadialBasisFunction)	4	0.004	0.002814	0.014594	0.003558	0.003295	0.002557
MLPC-2-B-L (Classification MLP)	3	0.003947	0.002701	0.01458	0.003448	0.003298	0.002545
MLPC-1-B-R (Classification MLP)	5	0.003944	0.002677	0.014594	0.003478	0.003301	0.002539
MLPC-1-B-R (Classification MLP)	10	0.00395	0.002676	0.014574	0.003516	0.003303	0.002537
MLPC-2-B-R (Classification MLP)	10	0.003945	0.002683	0.014582	0.003459	0.003304	0.00254
MLPC-2-O-M (Classification MLP)	10	0.003944	0.00268	0.014585	0.003469	0.003306	0.002541
MLPR-2-B-R (Regression MLP)	1	0.003945	0.002688	0.014467	0.003378	0.003346	0.002571
TDNN-1-B-R (Time-Delay Network)	1	0.003985	0.002738	0.014528	0.003604	0.003352	0.002573
GFFR-1-B-L (Reg Gen Feedforward)	1	0.003938	0.002684	0.014548	0.003493	0.003355	0.002576

EK 12: Rbist30 Getiri Serisi İçin %80-%10-%10 Modele Ait Sonuçlar

Model Adı	Girdi Katmanındaki Nöron Sayısı	Eğitim		Geçerlilik		Test	
		RMSE	MAE	RMSE	MAE	RMSE	MAE
TDNN-1-B-R (Time-Delay Network)	3	0.008257	0.006022	0.006839	0.005145	0.005609	0.004208
GFFR-1-B-R (Reg Gen Feedforward)	10	0.008452	0.006117	0.007009	0.005319	0.00563	0.004246
TLRN-1-O-M (Time-Lag Recurrent Network)	3	0.008351	0.006065	0.007	0.005278	0.005632	0.004258
TDNN-1-B-L (Time-Delay Network)	4	0.008164	0.005995	0.007059	0.005259	0.005634	0.004244
TLRN-1-O-M (Time-Lag Recurrent Network)	2	0.008375	0.006071	0.006956	0.005191	0.00564	0.004254
GFFR-1-B-L (Reg Gen Feedforward)	5	0.008287	0.006041	0.006918	0.005183	0.005648	0.00426
RBF-1-O-M (Radial Basis Function)	5	0.008402	0.0061	0.006987	0.005218	0.005649	0.004276
TDNN-1-B-L (Time-Delay Network)	10	0.008281	0.00602	0.007016	0.005253	0.005651	0.004251
MLPR-2-B-L (Regression MLP)	5	0.008317	0.006047	0.006927	0.005171	0.005655	0.00427
TLRN-1-B-R (Time-Lag Recurrent Network)	4	0.008428	0.006103	0.006936	0.005249	0.005656	0.00424
MLPR-2-B-R (Regression MLP)	4	0.008303	0.00605	0.00688	0.005167	0.005658	0.004261
RBF-1-B-R (Radial Basis Function)	10	0.008459	0.006116	0.006914	0.005227	0.005659	0.004266
RBF-1-O-M (Radial Basis Function)	1	0.008434	0.006113	0.006986	0.005254	0.005661	0.004294
RBF-1-O-M (Radial Basis Function)	3	0.008418	0.006098	0.006984	0.005229	0.005662	0.004269
MLPCPC-1-B-L (Class MLP with PCA)	2	0.008435	0.006111	0.006986	0.00523	0.005671	0.004268
MLPR-1-B-L (Regression MLP)	1	0.008436	0.006107	0.006975	0.00522	0.005672	0.004266
MLPRPC-1-B-L (Reg MLP with PCA)	1	0.008432	0.006107	0.006987	0.005232	0.005676	0.004269
TDNN-1-O-M (Time-Delay Network)	2	0.008436	0.006099	0.006977	0.00521	0.00568	0.004278