



Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi Yıl: 2019/2, Sayı:34, s.78-103
Journal of Süleyman Demirel University Institute of Social Sciences Year: 2019/2, Number:34, p. 78-103
Alınış /Received:13.05.2019 Kabul/Accepted: 29.07.2019 Online Yayın/ Online Published: 30.07.2019

KAYNAK GÖSTER: ÇUHADAR, M , DEMİRBAŞ, K , DAYAN, K . (2019). TÜFE Bazlı Reel Efektif Döviz Kurunun Alternatif Yaklaşımlarla Modellenmesi ve Tahminlenmesi. Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, (34)

TÜFE BAZLI REEL EFEKTİF DÖVİZ KURUNUN ALTERNATİF YAKLAŞIMLARLA MODELLENMESİ VE TAHMİNLENMESİ

Murat ÇUHADAR¹
Kerime DEMİRBAŞ²
Kübra DAYAN³

ÖZET

Tüketici Fiyat Endeksi (TÜFE) bazlı reel efektif döviz kuru (REK), para biriminin rekabet gücünü ölçen bir endekstir. Döviz kurunun kısa aralıkları değişmesi ve çoğu zaman inişli çıkışlı olması nedeniyle, yatırımcılar riskleri azaltmak için etkili yöntemlere ihtiyaç duymaktadırlar. Bu çalışmada, farklı mimarilere sahip Yapay Sinir Ağı modelleri, Box-Jenkins ve Üstel Düzleştirme yöntemlerinin tahmin başarıları karşılaştırılarak en yüksek tahmin performansı gösteren yöntemin belirlenmesi ve belirlenen model yardımıyla 2019 yılı için aylık TÜFE bazlı REK tahminlerinin üretilmesi amaçlanmıştır. Çalışmada, Türkiye Cumhuriyet Merkez Bankası tarafından yayınlanan “Döviz Kurları İstatistikleri” bülteninden elde edilen Ocak 2003 - Mart 2019 dönemini kapsayan 195 aylık TÜFE bazlı reel efektif döviz kuru verilerinden yararlanılmıştır. Modellerin tahmin doğrulukları Ortalama Mutlak Yüzde Hata (MAPE) istatistiği ile değerlendirilmiştir. Gerçekleştirilen analizler neticesinde, uygulanan çeşitli

¹ Doç. Dr., Süleyman Demirel Üniversitesi, İ.İ.B.F., Turizm İşletmeciliği Bölümü. E-mail: muratchuhadar@sdu.edu.tr, <https://orcid.org/0000-0003-0434-1550>

² Yüksek Lisans Öğrencisi, Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri ABD. E-mail: kerime.demirbas@gmail.com, <https://orcid.org/0000-0002-5520-4727>

³ Yüksek Lisans Öğrencisi, Mehmet Akif Ersoy Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme ABD. E-mail: kubradayan32@gmail.com, <https://orcid.org/0000-0002-1905-0070>

modeller arasında en başarılı sonucu veren modelin, Box-Jenkins Çarpımsal-mevsimsel ARIMA(0,1,1)(1,0,0)₁₂ modeli olduğu görülmüş, elde edilen model yardımıyla 2019 yılı için aylık tahmin değerleri üretilmiştir.

Anahtar Kelimeler: TÜFE Bazlı Reel Efektif Döviz Kuru, Modelleme, Tahmin Yöntemleri

THE CPI-BASED REAL EFFECTIVE EXCHANGE RATE MODELING AND PREDICTION USING ALTERNATIVE APPROACHES

ABSTRACT

The real effective exchange rate based on the Consumer Price Index (CPI) is a measure of the currency's competitive power. Because exchange rates change over short periods and are often ups and downs, speculators need effective methods to reduce risks. In this study, it was aimed to determine the method with the highest estimation performance by comparing the estimation successes of Artificial Neural Network models with different architectures, Box-Jenkins and exponential smoothing methods and to produce monthly real effective exchange rate based on CPI estimates for 2019 with the help of the determined model. The study benefit 195 monthly data between January 2003 and March 2019 which was obtained from the "Foreign Exchange Rates Statistics" bulletin published by the Central Bank of the Republic of Turkey. Forecasting performances of the models were evaluated by the MAPE statistics. As a result of the analyzes performed, it was found that Box-Jenkins Multiplicative-seasonal ARIMA (0,1,1)(1,0,0)₁₂ model was the most successful one among the alternative models applied. With the help of the selected model, monthly real effective exchange rate forecasts were made for the year 2019.

Keywords: Real Effective Exchange Rate Based on CPI, Modelling, Forecasting Methods

1. GİRİŞ

Ülke ekonomilerinde gerek ekonomik plan ve programların hazırlanmasında, gerekse ekonomik faaliyetlere yön verilmesinde önemli rol oynayan döviz kurları, ülkelerin ekonomik istikrarı hakkında da önemli ipuçları sağlamaktadır. Diğer ülkelerde üretilen mal ve hizmetlerin yurtiçinde üretilen mal ve hizmetler karşısındaki görece fiyatlarını ortaya koyan reel döviz kurları, uluslararası rekabeti değerlendirmede önemli bir gösterge durumundadır (Tatoğlu, 2009: 311). Uluslararası ticari işlemlerde, ülke para birimlerinin ne ölçüde değer kaybettiği ya da değer kazandığı, çoğunlukla reel efektif döviz kurları ve dış ticaret ağırlıklı endeksler aracılığıyla değerlendirilmektedir. Nominal

efektif döviz kuru (NEK), belli ölçütler göz önünde bulundurularak seçilen çift taraflı nominal kurların uygun bir ağırlıklandırma yöntemi ile elde edilen ortalamasına verilen isimdir. Reel Efektif Döviz kuru (REK) ise, NEK'in ülkeler arasındaki nispi maliyet veya fiyat unsurları ile düzeltilmiş şeklidir. Tanımdan da anlaşıldığı üzere, REK, ülkeler arasındaki nispi maliyet ve fiyatların gelişimi ile ilgili bilgi içermektedir. Bundan dolayı iktisadi rekabet güçlerinin değerlendirilmesi için kullanılan anahtar makroekonomik indikatörlerden birisi olarak değerlendirilmektedir (Sayılı vd., 2010).

Türkiye Cumhuriyeti Merkez Bankası (TCMB) ilkeleri perspektifinden, Türkiye'nin dış ticaret işlemlerinde önemli paya sahip ülkelerin para birimlerinden meydana gelen sepete göre Türk Lirası'nın ağırlıklı ortalama değerine NEK, NEK'deki göreceli fiyat etkilerinin arındırılmasıyla elde edilen ortalamaya isde REK adı verilmektedir. REK hesaplaması NEK üzerinden, "Tüketici Fiyatları Endeksi (TÜFE), Üretici Fiyatları Endeksi (ÜFE) ve birim işgücü maliyeti" olmak üzere üç ayrı düzeltme aracı kullanılarak yapılmaktadır. TCMB, döviz kurlarına müdahale için TÜFE'ye bağlı şekilde hesaplanan REK'teki hareketleri göz önünde bulunduracağını piyasalara bildirdiğinden dolayı, ilgili kesimlerin en fazla dikkate aldığı hesaplama TÜFE esas alınarak gerçekleştirilen hesaplamadır (Eğilmez, 2012). Döviz kurunun kısa dönemlerle değişmesi ve çoğu zaman inişli çıkışlı olması nedeniyle, spekülörler riskleri azaltmak için etkili yöntemlere ihtiyaç duymaktadırlar. Genel olarak nominal kur arttıkça reel efektif kur endeksi düşüş eğilimi göstermektedir. Böylece, yerli mal ve varlık fiyatları spekülörlere yatırım avantajı sağlar. Diğer bir ifadeyle spekülörler aynı kurdaki dövizini kullanarak daha fazla TL bazlı mal satın alabilmektedir. Nominal kurlar artmaya başladığında iktisadi dengeler bozulduğundan, ülkelerin merkez bankaları devreye girmektedir. Aşırı değer kazanan dövize müdahale etmek amacıyla, politika faizlerini (ağırlıklı ortalama fonlama maliyetini) yükseltme yoluna gitmektedirler. Ardından spekülörler stoklarını büyümeye yönelik adım atarlar. Reel kur endeksiyle spekülörlerin hisse senedi ve Devlet İç Borçlanma Senetleri (DİBS) işlemleri arasında da yakın bir ilişki vardır. Reel kurun düşük olduğu dönemde (nominal kur yüksek iken) spekülörler, hisse senedi ve DİBS almaya karar verirler. Bir süre sonra nominal kurun zirve yapmaya başlamasıyla enflasyon, faiz gibi diğer makro değişkenleri etkilemektedir. Reel kur endeksinin zirve yaptığını düşündükleri noktada ise davranış değiştirmektedir (Özyıldız, 2017).

Bu çalışmanın amacı; farklı mimarilere sahip Yapay Sinir Ağları, Box-Jenkins ve Üstel Düzleştirme yöntemlerinin tahmin başarılarını karşılaştırılarak Reel Efektif döviz kurlarının modellenmesi en uygun yöntemin belirlenmesi ve elde edilen model yardımıyla 2019 yılı için aylık TÜFE bazlı REK tahminlerinin yapılmasıdır. İlgili alandaki karar vericilerin, özel sektör ve kamu yöneticilerinin ileriye yönelik reel döviz kuru öngörülerinde karar almalarında yardımcı olacak yöntem ve modellerin sunulması çalışmanın diğer bir amacıdır. Ekonometrik modelleme ve tahmin literatüründe genel kabul gören yaklaşımın, her durumda en iyi sonucu veren sabit bir tahmin yönteminin olmaması (Zhang, 2004: 215) nedeniyle, çalışmada kullanılan verilerin modellenmesi ve tahminlerinde alternatif yöntemlerden yararlanılmıştır. Çalışmanın izleyen bölümleri şöyle yapılandırılmıştır. İkinci bölümde, Türkiye’de ve dünyada döviz kurlarının çeşitli yöntemlerle modellenmesi ve tahminine yönelik gerçekleştirilen çalışmaların yer aldığı bir literatür özeti verilmiştir. Üçüncü bölümde, çalışmada kullanılan yöntem ve modeller ele alınmıştır. Yöntem ve analiz başlığı altında, araştırmanın yöntemi ve çalışmada kullanılan verilerin özelliklerine ilişkin bilgi verilmiştir. Bulgular başlığı altında çalışmada kullanılan modellerin uygulanması ile ulaşılan tahminler karşılaştırmalı olarak değerlendirilmiştir. Son bölümde ise, analizler neticesinde ulaşılan bulgular ışığında sonuç ve önerilere yer verilmiştir.

2. LİTERATÜR ÖZETİ

Yapılan literatür incelemesi neticesinde, uluslararası yazında reel efektif döviz kurlarının tahmini ve alternatif yaklaşımlarla modellenmesine yönelik muhtelif çalışmalar yer aldığı görülmüştür. Bununla birlikte, Türkiye’de TÜFE bazlı reel efektif döviz kuru modellenmesi ve tahminine yönelik bir çalışma tespit edilememiştir. Dolayısıyla, bu çalışmanın temel güdüsü, ilgili yazında yapay sinir ağları ve geleneksel yaklaşımlarla döviz kurlarının tahmin ve modellenmesine yönelik gerçekleştirilen çalışma sayısının sınırlı sayıda olmasıdır. İlgili yazın incelendiğinde, konuyla ilgili gerçekleştirilen çalışmaların bir kısmı izleyen satırlarda özetlenmiştir. Kaynar ve Taştan, T.C. Merkez Bankasının elektronik veri dağıtım sisteminden temin ettikleri Ocak 2000 - Haziran 2008 dönemine ait günlük ve aylık döviz kuru (YTL/\$) değerlerini kullanarak Box-Jenkins ve çok katmanlı YSA modellerinin döviz kuru tahmini performanslarını tespit etmeye yönelik bir çalışma gerçekleştirmişlerdir (Kaynar ve Taştan, 2009b). Yazarlar, çalışmada kullandıkları her iki modelin de birbirine yakın sonuçlar verdiğini, bununla birlikte finansal verilerin tahmininde YSA’nın başarılı bir

yöntem olduğunu belirtmişlerdir. Zhang, 2003 yılında gerçekleştirdiği çalışmasında, 1980-1993 yılları arasındaki Amerikan Doları ve İngiliz Sterlini döviz kurlarını, YSA ve ARIMA yöntemlerinin birleşiminden oluşan melez model kullanarak tahmin etmiştir. Yazar tarafından oluşturulan melez modelin, döviz kuru verilerindeki doğrusal ve doğrusal olmayan yapıları içeren karmaşık problemlerin tahmininde etkili bir yöntem olabileceğini ortaya koymuştur (Zhang, 2003). Fat ve Dezsi, ARIMA ve çeşitli üstel düzleştirme modelleri yardımıyla Romen para biriminin (Lev) Amerikan doları, İngiliz sterlini, Japon yeni Avro ve Rus rublesi kurlarını tahmin etmişlerdir. Yazarlar, çalışmada kullandıkları yöntem ve modellerin çoğunlukla birbirine yakın tahmin sonuçlarını ürettiklerini, bazı durumlarda üstel düzleştirme teknikleri, piyasa koşullarındaki en küçük değişikliğe hızlı uyum sağlayarak ARIMA modellerinden daha iyi sonuçlar verdiğini belirtmişlerdir. ARIMA modellerinin, uygulamada bazı zorluklar çıkardığını vurgulayan yazarlar, üstel düzleştirme yöntemlerine dayanan tahmin modellerinin, döviz kurunun değişimi ile ilgilenenler için etkili bir araç olduğunu belirtmişlerdir (Fat & Dezsi, 2011).

Maniatis, ARIMA ve Üstel Düzleştirme yöntemlerini kullanarak Avro ve Amerikan doları kurlarını modellemeye yönelik bir çalışma gerçekleştirmiştir. Ocak 1999 ile 1 Temmuz 2011 tarihleri arasındaki günlük EURO-USD kuru verilerini kullanarak, muhtelif yapıdaki ARIMA ve üstel düzleştirme modellerinin tahmin ve ekonometrik yeterliliklerini araştıran yazar, denenen modellerin hiçbirisinin yeterli performans sergilemediğini belirtmiştir (Maniatis, 2012). Steve, Nijerya döviz kuru sistemindeki düzensiz dalgalanmaları modellemek ve bu sayede ilgililere döviz kurlarının seyrini anlamada yardımcı olmak amacıyla ARIMA yöntemi ile döviz kurlarının tahminine yönelik bir çalışma gerçekleştirmiştir. Çalışmasında, 1982-2011 dönemleri arasındaki döviz kuru verilerini kullanan yazar, AR(1) ve AR(2) modellerinin başarılı tahmin sonuçları ortaya koyduğunu ve önerdiği modellerin karar alıcılara yol göstereceğini ileri sürmüştür (Steve, 2014). Değirmenci ve Akay, borsa, altın, döviz ve petrol fiyatlarının Box-Jenkins modelleri ve ARCH modelleri ile modellenmesi ve tahminine yönelik bir çalışma gerçekleştirmişlerdir. Çalışmada, BIST100 endeksi, petrol fiyatları, altın ve döviz kuru değişkenlerinin 2009 ile 2016 arasındaki haftalık veriler kullanılmıştır. Gerçekleştirilen analizler neticesinde, çalışmada kullanılan altın fiyatları dışındaki diğer değişkenler üzerinde asimetrik tesirin mevcudiyeti tespit edilmiştir. Bu sonuca ilave olarak yazarlar, ARCH modellerinin ürettiği tahminlere

ilişkin theil istatistiklerinin sifıra oldukça yakın bulunduğunu bildirmişlerdir (Değirmenci ve Akay, 2017).

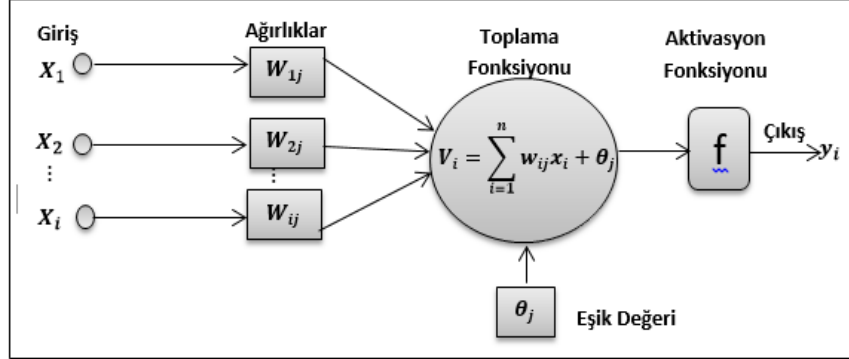
3. ÇALIŞMADA KULLANILAN YÖNTEMLER

Çalışmanın bu bölümünde, verilerin modellenmesi ve tahminlerinde kullanılan Yapay sinir ağları, Üstel Düzleştirme ve Box-Jenkins yöntemleri hakkında açıklamalara yer verilmiştir.

3.1. Yapay Sinir Ağları


Beyin yapısına ilişkin fen, doğa ve mühendislik bilimleri alanında gerçekleştirilen deney ve araştırmalar, insan beyninin bilgi işleme süreçlerini modellenmesinde bir ufuk açmış ve insan beyninin çalışma ilkelerini taklit eden sistemlerin gelişmesine vesile olmuştur. İnsan beyninin en küçük ögesi sinir hücreleridir. Sinir hücreleri bilgi işleme faaliyetlerini tek başına değil bir grup halinde yerine getirirler. Yapay Sinir Ağları (YSA), biyolojik sinir ağlarını taklit eden birbirine bağlı birkaç birimden veya yapay sinir hücrelerinden oluşan bir yapı olarak tanımlanmaktadır (Chen, Wang & Chu, 2007: 2163). Diğer bir tanıma göre YSA, insan beyninde yer biyolojik sinir hücrelerine benzetilmiş yapay sinir hücrelerinin birbirleri ile farklı etki düzeylerinde bağlantılar oluşturması şeklinde meydana getirilmiş kompleks sistemlerdir (Koşalay ve Yılmaz, 2004: 186). Kısaca YSA, birbirleri ile bağlantılı çalışan, her biri kendi bilgi işleme yeteneği ve belleği bulunan dağıtık bilgi işleme teknolojisidir. Yakın geçmişte yapay sinir ağı tabanlı modeller, zaman serileri tahmini için önerilen en önemli parametrik olmayan zaman serisi yöntemlerinden biri olmuştur. (Singh, Mohantry, & Shukla, 2017: 130). YSA, “nöronların” başka bir ifadeyle yapay sinir hücrelerinin bir araya gelmeleri ile meydana gelmektedir. Yapay nöronlar; giriş bağlantıları, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış bağlantıları olacak şekilde beş temel unsurdan meydana gelmektedir. Şekil 1’de örnek bir yapay sinir hücresi modeli verilmiştir.

Şekil 1: Yapay Sinir Hücresi (Nöron)



Şekil 1’de görüldüğü üzere, giriş bağlantılarıyla (x_1, x_2, \dots, x_i) dış ortamdan hücreye bilginin girilmesi sağlanır. Bir nöronun diğerlerinden aldığı bilgiler, ağırlıkların kullanılmasıyla düzenlenir. Bir nöron diğer nöronlardan bilgi aldığı anda, her bilgi parçası (-1) ile $(+1)$ arasında değere sahip bir ağırlık $(w_{1j}, w_{2j}, \dots, w_{ij})$ ile çarpılır, bu da nöronun giriş bağlantılarından aldığı bilginin ne kadar önemli olduğunu yargılamasına izin verir. Sonraki aşamada, nörona gönderilen ve karşılık gelen ağırlıklar ile çarpılan bilgiler bir araya getirilmekte ve bir aktivasyon fonksiyonu (f) içinden geçirilerek çıktı (y_i) elde edilmektedir (Haider & Hanif, 2009: 127-128). Burada; x_i girişleri, w_{ij} ağırlıkları, θ_j eşik değerini, f aktivasyon fonksiyonunu ve y_i ise çıkışı göstermektedir. Bir yapay sinir ağında, birbirleri ile etkileşimli yapay nöronların bulunduğu girdi katmanı, çıktı katmanı ve gizli katman(lar) olacak şekilde genel olarak üç katman bulunmaktadır. YSA’daki ilk katman, girdi (giriş olarak da adlandırılmaktadır) katmanı olup, yapay sinir ağına dışarıdan gelen verilerin alınması işlevini görmektedir. Girdi katmanı, ele alınan problemi etkilediği varsayılan değişkenlere ait veriler ile meydana getirilmekte ve girdi katmanında yer alacak sinir hücresi sayıları, değişken sayılarına göre belirlenmektedir. YSA’daki son katman çıktı katmanı olarak bilinir ve işlenen bilgilerin dış dünyaya aktarılması işlevine sahiptir. Bir yapay sinir ağında bulunan diğer katman ise girdi ve çıktı katmanları arasında yer alan gizli katmandır. Gizli katman(lar)da bulunan yapay sinir hücrelerinin dış dünya ile etkileşimleri mevcut değildir. Gizli katmanda yer alan sinir hücrelerinin işlevi, girdi katmanından gelen sinyalleri alıp çıktı katmanına sinyal iletmek şeklindedir (Çuhadar, Güngör ve Göksu, 2009: 102). Şekil 2.’de örnek bir yapay sinir ağı modeli sunulmuştur.

Şekil 2: Örnek Bir Yapay Sinir Ağı Modeli



YSA'da, işlem elemanlarına ait bağlantı ağırlıklarının en uygun değerlerinin elde edilmesi sürecine ağırlık eğitilmesi, diğer bir ifadeyle öğrenmesi adı verilmektedir. YSA'da öğrenme süreci iki safhada gerçekleşmektedir. İlk aşamada, ağa sunulan örnekler için ağırlık üreteceği çıktılar belirlenmekte, sonrasında ise ağ bağlantılarının ağırlıkları güncellenmektedir. YSA'nın eğitilmesine müteakip, başarı ölçümü testi gerçekleştirilmektedir. Bu işlem için ise, YSA'ya tanımadığı örnekler sunulmakta ve sunulan örnekler için uygun sonuçlar üretmesi beklenmektedir. YSA, bir problemi kendisine gösterilen veri setleri üzerinden öğrenerek eğitilirler. YSA'ların eğitilmesi, ya da diğer bir ifadeyle ağırlık öğrenmesi, kullanıcı tarafından beklenen bir işlevi yerine getirecek biçimde bağlantı ağırlıklarının güncellenmesi sürecidir (Elmas, 2016: 88). YSA parametrelerinin güncellenmesinde literatürde en fazla kullanılan yöntem "hata geriye yayma (Back Propagation)" algoritmasıdır (Keleşoğlu, ve Ekinci, 2008; Kaynar ve Taştan, 2009b; Aladağ, 2010: 192; Abdul Hamid, Nawı, Ghazali & Mohd 2011: 32). Yapılan literatür incelemesi sonucunda, finansal tahminlere yönelik muhtelif çalışmalarda ve uygulamalarda kullanılan YSA modellerinin en az yüzde doksanında, parametre güncelleme işleminin hata geri yayma algoritması ile gerçekleştiğini söylemek mümkündür. Hata geri yayılım eğitimi sırasında YSA, tüm giriş örüntülerini, çıktı katmanındaki sinir hücrelerinde sonuç üretmek amacıyla gizli katman(lar)daki sinir hücrelerinden geçirmekte, sonrasında çıktı katmanındaki öğrenme hataları tespit etmek amacıyla, beklenen sonuçlar ile bulunan sonuçları karşılaştırmaktadır. Daha sonra, çıkış hatalarının türevi çıkış katmanından geriye doğru olacak şekilde gizli katmanlara iletilmektedir. Hata değerleri

elde edildikten sonra, nöronlar kendi hatalarını en aza düşürmek için ağırlık değerlerini güncellemektedir. Ağırlık güncelleme süreci, ağdaki hata kareleri ortalamasını (MSE) en düşük değere yaklaştıracak biçimde gerçekleşmektedir. Geriye yayılım algoritmasında hata, aşağıdaki gibi hesaplanmaktadır.

$$E = \frac{1}{2} \left[\sum_p \sum_k |d_{pk} - y_{pk}|^2 \right]^{1/2}$$

Bu eşitlikte; E hata kareleri ortalamasını, d_{pk} istenen çıktı vektörünü y_{pk} ise gerçek çıktı vektörünü, diğer bir ifadeyle ağırlık çıktısını göstermektedir. Yapay sinir ağlarında yer alan nöronlar, muhtelif biçimlerdeki bağlantılarla bir araya gelebilmektedir. YSA mimarileri, nöronlar arasındaki bağlantı akışına veya yönlerine göre birbirlerinden farklılaşmaktadır. Yıllar içerisinde, muhtelif amaçlara yönelik ve farklı alanlarda kullanıma uygun çeşitli YSA mimari ve modelleri geliştirilmiştir. Bunlar arasında, çok katmanlı ileri beslemeli YSA (Multilayered Perceptron-MLP), radyal tabanlı fonksiyon ağları, Hopfield, Jordan/Elman, öz örgütlemeli harita ağlar, Kohonen vb. YSA modelleri sayılabilir. Sayılan YSA yapıları içerisinde işletmecilik ve finans alanında modelleme ve tahmin amaçlı olarak en yaygın kullanım alanı bulan (Liu & Quek, 2007; Moreno, Pol & Gracia, 2011; Egrioglu, Aladag, Yolcu, Baş ve Dalar, 2017; Bayramoğlu & Başarır, 2018) ve bu çalışmada da kullanılan, çok katmanlı ileri beslemeli (Multilayered Perceptron-MLP) YSA modelidir. Çok katmanlı YSA modellerinin tahmin amacıyla kullanımında, ağ mimarisinin belirlenmesi önem taşımaktadır. İlgili yazında, zaman serilerinin tahminlerinde çoğunlukla tek gizli katmana sahip ağ mimarileri yeterli olduğu belirtilmektedir. Ağa sunulacak girdiler, kullanılan veri setinin gecikmeli gözlem değerlerinden $(y_{t-1}, y_{t-3}, y_{t-12}, \dots, y_{t-k})$, çıktısı ise gecikmesiz değerlerinden (y_t) meydana gelmektedir. Çıkış değeri (y_t) ile girişler arasındaki ilişki ise şöyledir;

$$y_t = w_0 + \sum_{j=1}^p w_j f \left(w_{0j} + \sum_{i=1}^N v_{ij} y_{t-i} \right) + e_t$$

Bu eşitlikte, w_j, v_{ij} nöronlar arasındaki ağırlık değerlerini, p gizli katmandaki nöron sayısını, f ise gizli katmanda kullanılan aktivasyon fonksiyonunu temsil etmektedir. Alan yazın incelendiğinde, en fazla

kullanılan aktivasyon fonksiyonlarının, sigmoid ve hiperbolik tanjant fonksiyonları olduğu görülmektedir (Kaynar, Taştan ve Demirkoparan, 2010: 565).

3.2. Box-Jenkins (ARIMA) Yöntemi

Literatürde çoğu zaman “ARIMA” yöntemi olarak da adlandırılan Box-Jenkins yöntemi, zaman serilerinin modelleme, tahmin ve kontrolünde kullanılan istatistiksel tahmin yöntemlerinden biridir. Kısa ve orta dönem modelleme ve tahmin çalışmalarında başarılı sonuçlar sağlayan bu yöntemde, uygulanana veri setinin eşit zaman aralıklarına sahip gözlem değerlerinden oluşan kesikli ve durağan bir veri seti olması, yöntemin bir varsayımıdır (Bircan ve Karagöz, 2003: 50). Box-Jenkins metodolojisinin temel ilkesi, zaman serilerinin herhangi bir dönemdeki değerini, geçmiş dönemlerdeki gözlem değerleri ve hata terimlerinin bir kombinasyonu ile ortaya çıkarılmasına dayanmaktadır. Box-Jenkins modelleri sadece durağan veya durağanlaştırılmış serilerde kullanılabilirlerinden, uygun model grubunun belirlenmesinde durağanlık şartı önem taşımaktadır. Zaman serilerinin tahmininde yaygın bir şekilde kullanılan istatistik yöntemlerin en kapsamlısı olan Box-Jenkins modelleri arasında yer alan otoregresif (AR) süreç, hareketli ortalama (MA) ve bunların birleşimi olan ARMA modelleri durağan süreçlere uygulanırken, otoregresif bütünleşik hareketli ortalama (ARIMA) modelleri ise durağan olmayan süreçlere uygulanmaktadır (Akdağ, 2015: 22). Modelin genel ifadesi ARIMA (p, d, q) şeklindedir. Burada p, otoregresyon (AR) modelinin, q hareketli ortalama (MA) modelinin mertebesini ifade ederken, d ise mevsimsel olmayan (regular) fark alma derecesini temsil etmektedir (Kaynar ve Taştan, 2009: 142-143).

ARMA(p,q) Modeli, sadece AR(p) veya MA(q) süreçleri tarafından belirtilmediğinde,

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}$$

biçiminde ifade edilmektedir.

Burada $X_t \sim WN(0, \sigma^2)$ 'dir. Denklem daha da kısaltılarak yeniden yazıldığında;

$$\phi(B)(X_t) = \theta(B)e_t, \quad t=0,1,2,\dots$$

şeklinde gösterilebilir. Burada ϕ ve θ değerleri, p. ve q. mertebeden polinomlar olup, gerileme operatörü;

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

ve

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \text{ dir}$$

Uygulamada kullanılan veriler, özellikle de finansal ve ekonomik veriler çoğu zaman durağanlık şartlarını taşımamaktadırlar. Bu tip verilerin durağanlığı trend, mevsim ve konjonktüre bağlı dalgalanmalar ile tesadüfi etkenler tarafından bozulmaktadır. Genel olarak ARIMA(p,d,q) modelinin ifadesi şöyledir:

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}$$

Haftalık, aylık veya çeyrek yıllık zaman dönemlerinde gözlenmiş değerlerden oluşan zaman serilerinin birbirini takip eden yıl ya da ayların aynı dönemlerinde en yüksek ve en düşük seviyeye ulaşma eğilimi, verilerdeki mevsimsel bileşenin mevcudiyetine işaret etmektedir. Mevsimsel ARIMA modelinin gösterimi, ARIMA (p,d,q)(P,D,Q)_s ya da kısaca SARIMA şeklindedir. Burada, P mevsimsel otoregresyon (SAR) derecesini, D mevsimsel fark alma sayısını, Q mevsimsel hareketli ortalama (SMA) modelinin mertebesini ve S mevsim dönemini temsil etmektedir (Çuhadar vd., 2009: 105). Geri kaydırma işlemcisi ile P,D,Q derecelerindeki mevsimsel ARIMA modeli,

$$\Phi_p(B^s)\Delta_s^D y_t = \Theta_q(B^s)\varepsilon_t$$

şeklinde ifade edilmektedir. Modelde yer alan Δ_s mevsimsel fark alma operatörünü, S ise mevsim dönemini ifade etmekte olup, aylık veriler için S=12 olarak alınmaktadır. Modelde yer alan Δ^D operatörü, verilerin D kez mevsimsel farkının alındığı anlamına gelmektedir. Durağan olmayan veriler Δ_s^D ile gösterilen fark alma süreci sonrasında durağanlığı sağlanmış veri şeklinde ifade edilmektedir. Modelde yer alan Φ_p mevsimsel oto regresyon (SAR) parametresini, Θ_q mevsimsel hareketli ortalama (SMA) parametresini ve y_t ise durağan olmayan seriyi göstermektedir (Akgül, 2003: 199-200).

Box-Jenkins yöntemi, aday model seçenekleri içinden uygun bir modeli belirlemek için dört aşamadan oluşan ve itaratif bir süreç kullanmaktadır. Bu aşamalar kısaca; belirleme, tahmin, tanısal kontrol ve yordama şeklindedir. Model seçiminde, verilerin durağanlık şartlarını taşıması ve mevsimsel bileşenin etkisinde olup olmaması gibi unsurlar belirleyici olmaktadır. Dolayısıyla, Box-Jenkins yöntemi ile modelleme

ve tahmin sürecinde ilk olarak kullanılan verilerin zaman serisi özellikleri tespit edilerek, verilerin karakteristiklerine uygun aday modeller ve bunlar içerisinde en uygun ve istatistiksel olarak anlamlı modelin oluşturulması esas olmaktadır.

3.3. Üstel Düzleştirme Yöntemi

Üstel düzeltme yöntemi, verilerde gözlenen yakın dönemdeki değişimleri göz önünde bulundurularak tahminlerin sürekli, güncellendiği farklı uygulama seçeneklerinden meydana gelmektedir. Bu değişimler, tesadüfi, izah edilemeyen etkiler ya da önceden bilinmeyen ve göz ardı edilmiş hareketlerden kaynaklanmaktadır (Kadılar, 2005: 152). Üstel Düzleştirme yöntemlerinde, geçmiş dönem değerlerinin ağırlıklı ortalamaları hesaplanarak gelecek dönemlerin tahmini değeri şeklinde modellerde yer almaktadır. Bu gruptaki model seçenekleri, zaman serisi verilerinin modellenmesi ve tahminlerinde sıklıkla kullanılan yöntemler arasında yer almaktadır. Üstel düzeltme yönteminin sık kullanım alanı bulmuş olmasının en temel nedenleri arasında; açık, anlaşılır, olmaları, çeşitli veri yapılarına uyum yeteneği, kolay uygulanabilir, aynı zamanda düşük maliyetli olmaları ve özellikle kısa dönem tahminlerinde başarılı sonuçlar vermesi gibi faktörler sayılabilir. Bu yöntemin çalışma prensibi, çok eski gözlemlerin ya da verilerin etkisine göre yakın zamanda elde edilen veri ve gözlemlerin daha önemli olmasıdır (Yaffe & McGee, 2000: 43; Yağimli ve Ergin, 2017: 120). Üstel düzeltme yöntemi, verilerin özelliklerine göre belirlenebilen alternatif yöntemler grubundan meydana gelmektedir. Bu yöntemler arasında, Tekli (Basit) Üstel Düzleştirme Yöntemi, Brown'un Tek Parametrelili Doğrusal Üstel Düzleştirme Yöntemi, Holt'un Çift Parametrelili Doğrusal Üstel Düzleştirme Yöntemi, Winters'in Mevsimsel Üstel Düzleştirme Yöntemi sayılabilir. Trende etkisi taşımayan ve mevsimsel dalgalanmaların dönemler boyunca sabit olduğu verilerin modellenmesi ve tahmininde basit mevsimsel üstel düzeltme yöntemi uygun olmaktadır. Basit Mevsimsel Üstel Düzleştirme yönteminin eşitlikleri şöyledir;

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1})$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s}$$

$$F_{t+m} = L_t + S_{t-s+m}$$

Trend ve mevsimsel hareketler içeren verilerin modellenmesi ve tahmininde ise Holt-Winters'in mevsimsel üstel düzeltme yöntemi uygun olmaktadır. Bu yöntem, biri serinin t dönemindeki düzeyini tespit etmek, diğeri trendi yani eğilimi, üçüncüsü ise mevsimsel bileşeni

modellemek amacıyla kullanılan üç ayrı denklem dizisini kullanmaktadır. (Makridakis vd. 1998: 164). Holt Winters yöntemi, Holt tarafından geliştirilen çift parametrelili doğrusal üstel düzleştirme yönteminin, Winters tarafından geliştirilen ve mevsimsel hareketleri de göz önünde bulunduracak şekilde genişletilmiş formudur. Mevsimsellik türüne göre çarpımsal ve toplamsal olmak üzere iki ana modeli bulunmaktadır. İncelenen veri setindeki mevsimsellik, ternd ile düzenli bir artış ya da azalış sergilediğinde Çarpımsal-Mevsimsel, düzensiz bir trend ile birlikte artış ya da azalış gösteriyorsa Toplamsal-Mevsimsel düzleştirme yönteminin kullanılmasını önerilmektedir. Çarpımsal-Mevsimsel Holt-Winter's yönteminin hesaplanmasında kullanılan denklemler aşağıdaki verilmiştir (Al-Hafid & Al-Maamary, 2011: 17-18):

$$\text{Seviye: } L_t = \alpha \frac{Y_t}{S_{t-1}} + (1 - \alpha)(L_{t-1} + m_{t-1})$$

$$\text{Trend: } m_t = \beta(L_{t-1} + L_{t-1}) + (1 - \beta)m_{t-1}$$

$$\text{Mevsim: } S_t(t) = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s}(t)$$

$$\text{Tahmin: } F_{t+m} = (L_t - b_t m)S_{t-s+m}$$

Verilen tüm eşitliklerde;

t= Zaman periyodunu,

S = Mevsim uzunluğunu,

Y_t = Gerçek gözlem değerlerini,

L_t = Serinin t döneminde seviye bileşenini,

m_t = Trend bileşenini,

S_t = Mevsimsel bileşeni,

F_{t+m} = m dönemdeki F tahmin değerini,

α (düzey), β (trend) ve γ (mevsim) düzleştirme sabitlerini temsil etmektedir. Literatürde yukarıda verilenler dışında kalan üstel düzleştirme yöntemleri de mevcuttur. Bunlar arasında; Chow tarafından geliştirilen Uyarlanabilir Kontrol Yöntemi, Harrison'un Harmonik Düzleştirme Yöntemi, Uyarlanabilir Tepki Oranlı Basit Üstel Düzleştirme Yöntemi ve Brown Tek Parametrelili Uyarlanabilir Yöntemi sayılabilir. Ancak, sayılan bu yöntemler oldukça zaman alan yorucu

hesaplamaları kullandıklarından zaman içerisinde yaygın kullanım imkânına sahip olamamışlardır (Orhunbilge, 1999: 119).

4. YÖNTEM VE ANALİZ

Çalışmada kullanılan veriler, Türkiye Cumhuriyeti Merkez Bankası (TCMB) İstatistik Genel Müdürlüğü Elektronik Veri Dağıtım Sistemi (EVDS) tarafından aylık olarak yayınlanan “Döviz Kurları İstatistikleri” bülteninden elde edilmiştir, Ocak 2003 ve Aralık 2018 dönemini kapsayan 192 aylık TÜFE bazlı reel efektif döviz kuru verilerinden yararlanılmıştır.

Çalışmada öncelikle kullanılan verilerin zaman serisi özellikleri analiz edilerek, verileri etkileyen bileşenler analiz edilmiştir. Verilerin özelliklerinin değerlendirilmesine müteakip olarak, Üstel Düzleştirme ve Box-Jenkins yöntemlerinden, çalışmada kullanılan verilerin özelliklerine uygun modeller ve farklı mimarilere sahip yapay sinir ağı modelleri ile en uygun modelin belirlenmesine yönelik analizler gerçekleştirilmiştir. Uygun modelin tespit edilmesi sürecinde, üstel düzleştirme modelleri için hata kareleri ortalamasını minimum yapan düzleştirme sabitleri, Box-Jenkins modelleri için, Otokorelasyon (ACF) ve Kısmi Otokorelasyon fonksiyonları (PACF) ile Bayes Bilgi Kriteri (BIC) göz önünde bulundurulmuştur. Yapay sinir ağı modelleri için ise, modelin ürettiği tahmin hatasını minimum yapacak parametreler ve parametre değerleri denenmiştir. Analizler, IBM SPSS (Sürüm: 22) paket programı yardımıyla gerçekleştirilmiştir. Modellerin ürettikleri tahmin değerleri, gerçekleşmiş olan döviz kuru değerleri ile karşılaştırılarak hangi yöntemin daha başarılı sonuçlar verdiği belirlenmiştir. Uygulanan yöntemlerin tahmin performansları “Ortalama Mutlak Yüzde Hata (MAPE) istatistiği ile değerlendirilmiştir. MAPE kriterinin, öngörü hatalarını oransal olarak ifade etmesi nedeni ile farklı birim değerlere sahip modellerin birlikte değerlendirilmesinde ortaya çıkabilecek sorunları elimine etmesi ve bununla birlikte kendi başına yorumlanabilir olması, diğer tahmin performansı ölçümü istatistiklerine nazaran üstünlükleri olarak bilinmektedir. Alternatif modellerin değerlendirilmesinde MAPE istatistiği değeri % 10'nun altında ise doğruluğu yüksek, % 10-20 arasında doğruluğu iyi, % 20-50 arasında makul doğruluk ve % 50'nin üstünde ise başarısız bir tahmin olarak kabul edilmektedir (Çuhadar, 2013: 5287). Matematiksel ifadesi şöyle ifade edilmektedir;

$$MAPE = \frac{\sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{Y_i}}{n} 100(\%)$$

(13)

\hat{Y}_i = i dönemi için hesaplanan tahmin değeri,


Y_i = i dönemdeki gerçek değeri,

n= tahmin yapılan dönem sayısını ifade etmektedir.

4.1. Çalışmada Kullanılan Verilerin Bileşenlerinin İncelenmesi

Çalışmada kullanılan Ocak 2003 – Mart 2019 dönemine ait TÜFE bazlı reel efektif döviz kuru (2003=100) verilerine ait zaman grafiği Şekil 3.'te verilmiştir. Grafik incelendiğinde, negatif bir trend ile birlikte mevsimsel hareketler ve bazı dönemlerde de düzensiz dalgalanmaların etkisinde olduğu görülmektedir. Genel olarak mevsimsel dalgalanmalar, birbirini takip eden yılların Ocak ve Kasım aylarında en yüksek değerlere ulaşırken, yaz aylarında düşüş eğilimi göstermektedir.

Şekil 3: TÜFE Bazlı Reel Efektif Döviz Kuru Zaman Grafiği
(Ocak, 2003-Mart, 2019)



Uygulanan trend analizi neticesinde, verilerin azalan yönlü ve ikinci dereceden kuadratik bir eğilim sergilediği görülmüştür. Uygulanan trend analizinin bir bütün olarak istatistiksel anlamlılığını ölçmek

amacıyla gerçekleştirilen F testi ve denklem katsayılarının t istatistiklerinin 0,05 önem seviyesinde istatistiki bakımdan anlamlı oldukları görülmüştür. Uygulanan trend analizine ilişkin model özeti, Tablo 1.'de verilmiştir.

Tablo 1: Trend Analizi Model Özeti

Model	R	R ²	Ayarlı R ²	Tahminin Std. Hatası
$y = -3E-06x^2 + 0,2593x - 5063,9$,887	,785	,782	5,789

Çalışmada kullanılan verilerdeki mevsimsel etkileri istatistiksel olarak tespit etmek amacıyla, alan yazında X-12 ARIMA olarak da adlandırılan “hareketli ortalamaya oran” yöntemi kullanılarak mevsimsel ayrıştırma analizi uygulanmış, elde edilen mevsim faktör değerleri Tablo 2.'de verilmiştir. Analiz neticesinde elde edilen mevsim faktör değerleri, verilerin on iki ayda bir tekrarlayan mevsimsel bileşenin tesirinde olduğunu ortaya koymuştur.

Tablo 2: TÜFE Bazlı REK Serisi Mevsim Faktör Değerleri

Aylar	Mevsim Faktör Değerleri (%)	Aylar	Mevsim Faktör Değerleri (%)
Ocak	100,3	Temmuz	100,1
Şubat	100,9	Ağustos	99,1
Mart	100,2	Eylül	98,9
Nisan	101,6	Ekim	99,6
Mayıs	100,5	Kasım	99,8
Haziran	99,8	Aralık	99,2

4.2. Üstel Düzleştirme Yönteminin Uygulanması

Çalışmada kullanılan verilerin mevsimsel dalgalanmanın tesiri altında olması ve mevsimsel dalgalanmaların dönemlere göre farklı büyüklüğe sahip olması nedeniyle uygulamada “Çarpımsal-Mevsimsel” üstel düzleştirme modelleri uygulanmış, toplamsal modeller denenmemiştir. Uygulanan “Basit Mevsimsel, Çarpımsal-Mevsimsel Üstel Trend, Çarpımsal-Mevsimsel, Sönümlü (Damped) Trend ve Çarpımsal-Mevsimsel Doğrusal Trend (Holt-Winter’s)” modellerine ait parametre tahminlerinin t testlerinin istatistiksel anlamlılıkları, hata kareleri toplamları ve MAPE değerleri incelendiğinde, optimum modelin

“Çarpımsal-Mevsimsel Holt-Winter’s” modeli olduğu görülmüştür. Elde edilen modelde, mevsim faktörleri olarak mevsimsel ayrıştırma işlemi ile elde edilen mevsim faktör değerleri kullanılmıştır. Modelin düzleştirme sabitleri, hata kareleri toplamını minimum yapacak şekilde aşağıdaki gibi belirlenmiştir:

$$\text{(Seviye)} \alpha = 0,951000$$

$$\text{(Trend)} \beta = 1,4140000$$

$$\text{(Mevsim)} \gamma = 0,999000$$

Modele ait başlangıç değerleri bilgisayar yardımı ile aşağıda verildiği gibi hesaplanmıştır:

$$L_s = 100,76025 \quad \text{(Seviye başlangıç değeri)}$$

$$b_s = -,12671 \quad \text{(Trend başlangıç değeri)}$$

4.3. Box-Jenkins Yönteminin Uygulanması

Box-Jenkins yönteminin uygulanmasında ilk olarak, Genişletilmiş Dickey-Fuller (ADF) testi ile verilerin durağanlık analizleri gerçekleştirilmiştir. Yapılan analizler sonucunda, verilerin birinci dereceden mevsimsel olmayan (regular) farkının alınarak ($d=1$) durağanlık şartını sağladığı görülmüştür. Verilere ait oto korelasyon (ACF) ve kısmi oto korelasyon (PACF) fonksiyonları incelenmek suretiyle mevsimsel ve mevsimsel olmayan otoregresyon (AR) ve hareketli ortalama (MA) süreçlerinin mertebeleri aşağıda verildiği şekilde belirlenmiştir:

$$\text{(AR) derecesi} \quad p = 0$$

$$\text{(MA) derecesi} \quad q = 1$$

$$\text{Mevsimsel (SAR) derecesi} \quad P = 1$$

$$\text{Mevsimsel (SMA) derecesi} \quad Q = 0$$

Yapılan çeşitli model denemelerinin ardından, birinci dereceden farkı alınmış TÜFE bazlı REK serisi için uygun Box-Jenkins modelinin, “Çarpımsal-Mevsimsel ARIMA Modeli” olarak ifade edilen SARIMA (0,1,1)(1,0,0)₁₂ olduğu tespit edilmiştir. Belirlenen modele ait son parametre tahminleri ve model özeti, Tablo 3.’te verilmiştir. Tablo

incelendiğinde, belirlenen SARIMA modelin parametre tahminlerine ait t-değerlerinin tümünün 0,05 önem seviyesinde istatistiksel olarak önemli oldukları görülmektedir. Bununla birlikte, Box-Jenkis metodolojisinde, mevsimsel gecikmelerin istatistiksel öneminin test edilmesinde ele alınan t-test istatistiği için kritik değer 1,25 olarak alınmakta olup, mevsimsel parametre tahminlerinin $|t| > 1,25$ olmaları nedeniyle anlamlı olduğu tespit edilmiştir

Tablo 3: SARIMA (0,1,1)(1,0,0)₁₂ Tahmin Modeli Özeti

Süreç	Tahmin	Standart Hata	t- istatistiği	Anlamlılık
MA (1)	-,377	0,067	-5,655	0,000
SAR (1)	-,167	0,077	-2,164	0,032
Gözlem Sayısı	195			
Fark Alındıktan Sonraki Gözlem Sayısı	194			
Bayes Bilgi Kriteri (BIC)	2,058			
Fark Alma	Verilerin mevsimsel olmayan ilk farkı			

Gerçekleştirilen analizler neticesinde en uygun model olarak belirlenen SARIMA (0,1,1)(1,0,0)₁₂ modelinin parametre tahminleri istatistiksel açıdan değerlendirildikten sonra, modele ait artıklar serisinin rassal (beyaz gürültü) ve aralarında otokorelasyon olup olmadığını incelemek amacıyla Ljung-Box (Q^*) testi kullanılmıştır. Mevsimsel modeller için;

$$Q^* = n(n+2) \sum \frac{r_k^2}{n-k} \sim \chi^2(k-p-q-P-Q)$$

denklemler ile elde edilen Q^* istatistiği " $H_0 : r_1 = r_2 = \dots r_k = 0$ " hipotezi altında ve (k-p-q-P-Q) serbestlik derecesinde χ^2 dağılımına sahiptir. Modele ait kalıntılar serisine ait 12, 24 ve 36. gecikmeler için yapılan hesaplamalarda, $Q^* < \chi^2$ olduğu görülmüş, dolayısıyla 0,05 önem düzeyinde sıfır hipotezi kabul edilmiştir. Elde edilen Q^* istatistikleri, modele ait kalıntılar arasında önemli oto korelasyon olmadığını, serinin rassal bir sürece sahip olduğunu ve dolayısıyla seçilen modelin uygunluğunu teyit etmektedir. Verilerin Box-Jenkins yöntemi ile modellenmesi ve tahmin sürecinde, değerlendirilen modellere ait otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) fonksiyonları ile

Genişletilmiş Dickey-Fuller (ADF) testleri “E-Views (Sürüm:10)” paket programı ile gerçekleştirilmiştir.

4.4. Yapay Sinir Ağı Uygulaması

Çalışmada kullanılan verilerin YSA ile modellenmesinde, farklı veri setleri kullanılarak oluşturulan alternatif YSA mimarilerinin tahmin performansları analiz edilmiştir. Mevcut 195 aylık verinin 170 gözlemi eğitim, 25 gözlemi ise test verisi şeklinde gruplandırılmıştır. Oluşturulan her bir ağın giriş katmanında aylık seriler için önerilen 12 gecikmeli veri değerleri ($y_{t-12}, y_{t-24}, y_{t-36} \dots$) çıkış katmanında ise gecikmesiz veri değerleri (y_t) kullanılmıştır. Çalışma kapsamında 3, 4 ve 5 katmanlı mimarilerle oluşturulan model alternatifleri denenmiştir. Kurulan ağların eğitime sürecinin durdurma sınırı, her bir deneme için 10.000 iterasyon şeklinde belirlenmiştir. YSA uygulamasında, giriş katmanında 12 gecikmeli veri setlerinin yer aldığı nöron sayıları, gizli katmanında ise farklı nöron (1-7) sayılarındaki modellerin tahmin performansları incelenmiştir. Gizli katmanlardaki nöron sayılarının tespitinde literatürde genel kabul gören kesin bir kural olmaması nedeniyle farklı nöron sayısı alternatifleri ile ağın eğitimi gerçekleştirilmiştir. Verilerin alternatif çok katmanlı YSA yapıları ile modellenmesi sürecinde, müteakip olarak test amacıyla belirlenen veriler kullanılarak, denenen tüm farklı YSA mimarileri test edilmiştir. Test işlemi sonucunda bulunan tahmin değerleri, gerçek değerlerle karşılaştırılarak, değişik mimarilere sahip yapay sinir ağı modellerinin tahmin başarıları incelenmiştir. Farklı mimarilere sahip YSA mimarileri oluşturularak yapılan çok sayıda deneme neticesinde, aday modeller arasından en yüksek tahmin performansını sergileyen YSA modeli [4:3:1] mimarisine sahip çok katmanlı model olarak belirlenmiştir. TÜFE bazlı reel efektif döviz kuru tahmini amacıyla oluşturulan modelde; bir giriş katmanı, bir gizli katman ve bir çıkış katmanı bulunmaktadır. Giriş katmanında 4, gizli katmanında 3 ve çıkış katmanında ise 1 nöron bulunmaktadır. Elde edilen modele ait parametre değerleri Tablo 4.’te verilmiştir.

Tablo 4: YSA Modeline Ait Parametreler

Girdi Katmanındaki Nöron Sayısı	4
Gizli Katman Sayısı	1
Gizli Katmandaki Nöron Sayısı	3
Çıktı Katmanındaki Nöron Sayısı	1
Aktivasyon Fonksiyonu	Logarimik-Sigmoid
Ağırlıkların Güncellenmesi	Back Propagation

Eğitim Fonksiyonu	Levenberg - Marquardt
-------------------	-----------------------

Oluşturulan YSA modelinin eğitimi sürecinde, bağlantı ağırlıklarının güncellenmesi “hata geriye yayma (back propagation) yöntemi ile gerçekleştirilmiştir. Etkinlik fonksiyonu olarak “Logaritmik Sigmoid”, eğitim fonksiyonu olarak ise “Levenberg-Marquardt” algoritması kullanılmıştır.

4.5. Bulgular ve TÜFE Bazlı REK Tahminleri

Uygulanan alternatif yöntem ve modeller ile elde edilen tahmin değerleri ile aynı dönemlerde gerçekleşmiş gözlem değerlerinin birlikte ele alınmasıyla uygulanan tahmin doğruluğu ölçümü sonuçları Tablo 5.'te verilmiştir.

Tablo 5: Modellerin Tahmin Doğrulukları

Yöntem ve Model	MAPE (%)
[4:3:1] Mimarisine Sahip Yapay Sinir Ağı	2,05
Çarpımsal-Mevsimsel SARIMA(0,1,1)(1,0,0) ₁₂	1,85
Çarpımsal-Mevsimsel Üstel Düzleştirme (Holt-Winters)	2,44

Uygulanan her bir yöntemden elde edilen modeller üzerinde yapılan tahmin doğruluğu ölçüm sonuçları incelendiğinde, bunlar içerisinde en düşük hata değerlerini sağlayan modelin, MAPE= 1,85 değeri ile Çarpımsal-Mevsimsel SARIMA(0,1,1)(1,0,0)₁₂ modeli olduğu görülmektedir. Tablo 5. İncelendiğinde, uygulanan her üç yöntemin de oldukça başarılı tahmin sonuçları ürettiği söylenebilir. Bununla birlikte, çarpımsal-mevsimsel SARIMA(0,1,1)(1,0,0)₁₂ modelinden elde edilen MAPE değerinin 1,85 olarak gerçekleşmiş olması, modelin ürettiği tahmin değerleri ile gerçek gözlem değerleri arasındaki sapmaların çok düşük olduğunu göstermektedir.

Box-Jenkins modelleri, tahmin için ilave değişkenlere ait bilgi gerektirmemesi ve özellikle kısa ve orta dönem öngörü performanslarının iyi olduğu, yapılan muhtelif çalışmalarda kanıtlanmış olması nedeni ile yaygın kullanım imkânı bulmuşlardır. Aynı zamanda, alternatif model seçenekleri arasından en uygun olanı seçebilme ve seçilen modelin uygulanmasındaki her safhada verilere uygunluğunu kontrol edebilme gibi avantajlara sahip olduklarını söylemek mümkündür. Gerçekleştirilen analiz ve değerlendirmeler sonucunda, uygulanan alternatif model ve

yöntemler arasında en yüksek tahmin performansını sergileyen çarpımsal mevsimsel Box-Jenkins modeli kullanılarak, 2019 yılı için aylık TÜFE bazlı reel efektif döviz kuru tahminleri üretilmiş, elde edilen tahmin değerleri Tablo 6.'da verilmiştir.

Tablo 6: TÜFE Bazlı Reel Efektif Döviz Kuru Tahminleri (2019)

Aylar	TÜFE Bazlı REK Tahmini	Aylar	TÜFE Bazlı REK Tahmini
Ocak	76,17	Temmuz	74,12
Şubat	75,86	Ağustos	74,20
Mart	76,02	Eylül	74,08
Nisan	73,29	Ekim	72,83
Mayıs	73,72	Kasım	71,87
Haziran	73,92	Aralık	71,75

5. SONUÇ VE ÖNERİLER

Bilimsel temele dayanan yöntemlerle döviz kurlarında meydana gelecek gelişmelerin tahmin edilmesi, yatırımcıların, kamu-özel sektör temsilcilerinin ve hükümetlerin ileriye yönelik reel döviz kuru öngörülerinde karar almalarını kolaylaştırmaya olanak sağlar. Döviz kurları, hemen hemen her uluslararası finansal piyasa kararında önemli değişkenler arasında yer almaktadır. Döviz kurundaki dalgalanma, uluslararası finansal faaliyetlere katılan tüm katılımcı türleri için üzerinde dikkatle durulması gereken konulardan biri haline gelmektedir. Özellikle BrettonWoods sisteminin 1970'li yılların başında çökmesi ile birlikte, döviz kuru piyasaları da volatil bir seyir izlemeye başlamıştır. Dalgalı kur rejiminde döviz kurları, para politikasını, reel faaliyetleri ve enflasyonu etkileyebilen temel mekanizmalardan birisi durumundadır. Nominal döviz kurları, iktisadi açıdan oldukça önemli bir gösterge olmakla beraber, ülkelerin iktisadi faaliyetlerinde reel diğer bir ifadeyle enflasyondan arındırılmış döviz kurları göz önüne alınmaktadır. Reel efektif döviz kurları ekonomide tüketim ve kaynak tahsisinde önemli olan faktörlerin başında gelmektedir. Bunlara ilave olarak, uluslararası işletmecilik ve yatırımlarla ilgili görece fiyatlandırmalarda da önemli bir role sahiptir. Kur riski, çok uluslu şirketlerin karşılaştığı birçok iş riskinden biridir ve başarılı yönetimi genel finansal yönetimde kilit faktörlerden biri haline gelmiştir. Sayılan bu nedenlerden ötürü, ülke ekonomileri açısından reel döviz kurlarının belirlenmesi ve tahminleri önem arz etmektedir TCMB, yapılan reel efektif döviz kuru tahminlerini inceleyerek piyasalara nasıl müdahale etmesi gerektiğine önceden karar vermektedir. Spekülatörler ise kur tahminlerine bakarak reel kurun düşük

olduğu dönemde hisse senedi ve Devlet İç Borçlanma Senetleri almaya yönelmektedir. İşletmeler makroekonomik çevredeki finansal pazarlar yardımıyla kendilerine fon sağlamakta, dış ticaret işlemlerinde döviz alımı ve satımı gerçekleştirmektedirler. İşletmeler için kritik öneme sahip olan bu pazarların gelecekte izleyeceği yönün, trendin tahmin edilmesinin bir gereklilik haline gelmesi, reel efektif döviz kuru tahminlerinin önemini ortaya koymaktadır.

Yapılan analizler neticesinde, uygulanan muhtelif yöntemler içerisinde en yüksek tahmin başarısı sergileyen modelin Çarpımsal-Mevsimsel SARIMA(0,1,1)(1,0,0)₁₂ modeli olduğu tespit edilmiştir. Elde edilen model yardımıyla geleceğe yönelik olarak 2019 yılı için 12 aylık TÜFE bazlı reel efektif döviz kur tahminleri üretilmiştir. Mevsimsellik içeren finansal verilerde Box-Jenkins yönteminin, alternatif yöntemlere nazaran daha iyi sonuçlar verdiği, yapılan muhtelif çalışmalarda da vurgulanmaktadır. İleriye yönelik gerçekleştirilecek çalışmalar için, Bulanık Mantık, Adaptif Sinirsel Bulanık Çıkarma Yöntemi, Genetik Algoritma ve Kaba Setler (Rough Sets) gibi farklı yapay zekâ yöntemleri veya bunların geleneksel tahmin yöntemleri ile birleştirilmesi ile elde edilen melez modeller ile yapılacak tahmin ve modelleme çalışmaları araştırmacılara önerilebilir. Her zaman ve her koşulda geçerli en iyi tek bir tahmin yöntemi olmadığı gerçeğinden hareketle, önerilen çalışmaların bu konuda yapılacak modelleme ve tahmin yazınına katkı sağlayacağı söylenebilir.

KAYNAKÇA

- ABDUL HAMID, N., NAWI, N.M., GHAZALI, R. & MOHD S.N.M. (2011). Accelerating Learning Performance of Back Propagation Algorithm by Using Adaptive Gain Together with Adaptive Momentum and Adaptive Learning Rate on Classification Problems, *International Journal of Software Engineering and Its Applications*, 5(4), 31-44.
- AKDAĞ, M. (2015). Box-Jenkins ve Yapay Sinir Ağı Modelleri İle Enflasyon Tahmini, (Yayınlanmamış Yüksek Lisans Tezi), Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Erzurum.
- AKGÜL, I. (2003). Zaman Serilerinin Analizi ve ARIMA Modelleri, İstanbul: Der Yayınları.
- ALADAĞ, Ç.H. (2010). Farklı Öğrenme Algoritmalarıyla Türkiye'ye Gelen Yabancı Turist Sayısının Tahmini, I. Disiplinler arası Turizm Araştırmaları Kongresi, 27-30 Mayıs 2010, Nevşehir. Bildiriler Kitabı, s. 188-197.

- AL-HAFID, M. S. & AL-MAAMARY, G. H. (2011). Short Term Electrical Load Forecasting Using Holt-Winters Method, *Al-Rafidain Engineering*, 20(6), 15-22.
- BAYRAMOĞLU, M.F. & BAŞARIR, Ç. (2018). “International Diversified Portfolio Optimization With Artificial Neural Networks: An Application With Foreign Companies Listed on NYSE” s. 201-223, Dileep Kumar G. (Ed.), *Machine Learning Techniques for Improved Business Analytics*, IGI-Global.
- BİRCAN, H. VE KARAGÖZ, Y. (2003). Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama, *Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 6(2), 49-62.
- CHEN, B. F., WANG, H. D. & CHU, C. C. (2007). Wavelet and Artificial Neural Network Analyses of Tide Forecasting and Supplement of Tides Around Taiwan and South China Sea, *Ocean Engineering*, 34(16), 2161-2175.
- ÇETİN, E. (2016). *Yapay Zeka Uygulamaları*, Ankara: Seçkin Yayıncılık.
- ÇUHADAR, M. (2013). Türkiye’ye Yönelik Dış Turizm Talebinin MLP, RBF ve TDNN Yapay Sinir Ağı Mimarileri İle Modellenmesi ve Tahmini: Karşılaştırmalı Bir Analiz, *Journal of Yasar University*, 8(31), 5274-5295.
- ÇUHADAR, M., GÜNGÖR, İ., VE GÖKSU, A. (2009). Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama, *Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 99-114.
- DEĞİRMENCİ, N. ve AKAY, A. (2017). Finansal Verilerin ARIMA ve ARCH Modelleriyle Öngörüsü: Türkiye Örneği, *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 12(3), 15-36.
- EĞİLMEZ, M. (2012). Reel Efektif Döviz Kuru Endeksi Nedir? <http://www.mahfiegilmez.com/2012/11/reel-efektif-doviz-kuru-endeksi-nedir.html>. (Alıntılanma Tarihi: 4.011.2018)
- EGRİOĞLU, E., ALADAG, Ç.H., YOLCU, U., BAŞ, E. & DALAR, A.Z. (2017). “A New Neural Network Model with Deterministic Trend and Seasonality Components for Time Series Forecasting”, s. 76-92, Aladağ Ç.H. (Ed.) *Advances in Time Series Forecasting*, Vol. 2, Bentham Science Publishers, Sharjah, UAE.

- ELMAS, Ç. (2016). Yapay Zekâ Uygulamaları, Ankara: Seçkin Yayıncılık.
- FAT, C. M. & DEZSI, E. (2011). Exchange-Rates Forecasting: Exponential Smoothing Techniques And Arima Models, *Annals of Faculty of Economics, University of Oradea, Faculty of Economics*, 1(1), 499-508.
- HAIDER, A. & HANIF, M. N. (2009). Inflation Forecasting in Pakistan Using Artificial Neural Networks, *Pakistan Economic and Social Review*, 47(1), 123-138.
- KAYNAR, O. ve TAŞTAN, S. (2009a). Zaman Serileri Tahmininde ARIMA-MLP Melez Modeli, *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 23(3), 141-149.
- KAYNAR, O. ve TAŞTAN, S. (2009b). Zaman Serisi Analizinde MLP Yapay Sinir Ağları ve ARIMA Modelinin Karşılaştırılması, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Sayı: (33), 161-172.
- KAYNAR, O., TAŞTAN, S. ve DEMİRKOPARAN, F. (2010). Ham Petrol Fiyatlarının Yapay Sinir Ağları İle Tahmini, *Ege Akademik Bakış*, 10(2), 559-573.
- KELEŞOĞLU, Ö ve EKİNCİ, C. (2008). Silis Dumanı Katkılı Betonların Çarpma Dayanımının Yapay Sinir Ağı İle Belirlenmesi, *e-Journal of New World Sciences Academy (Natural And Applied Sciences)*, 3(1): 30-38.
- KOŞALAY, İ ve YILMAZ, E.N. (2004). Güç Transformatorü Uç Empedans Eğrisinin Yapay Sinir Ağları Yardımıyla Kestirimi, *Politeknik Dergisi*, 7(3), 185-189.
- LIU, G.S. & QUEK, C. (2007). RLDDE: A novel reinforcement learningbased dimension and delay estimator for neural networks in time series prediction, *Neurocomputing*, (70), 1331-1341.
- MAKRIDAKIS, S., WHEELWRIGHT, S.C. & HYNDMAN, R.J. (1998). *Forecasting: Methods and Applications* (Third edition), John Wiley and Sons.
- MANIATIS, P. (2012). Forecasting The Exchange Rate Between Euro And USD: Probabilistic Approach Versus ARIMA and Exponential Smoothing Techniques, *The Journal of Applied Business Research*, 28(2), 171-192.

- MORENO J.J., POL, A.P. & GRACIA, P.M. (2011). Artificial neural networks applied to forecasting time series, *Psicothema*, 23(2), 322-329.
- ORHUNBİLGE, N. (1999). Zaman Serileri Analizi Tahmin ve Fiyat Endeksleri, İstanbul Üniversitesi İşletme Fakültesi Yayınları, No: 277, İstanbul.
- ÖZYILDIZ, H. (2017). Sıcak Para Yatırımcıları Reel Kur Endeksi Değişimine göre Karar Veriyor. <https://www.paraanaliz.com/2017/ekonomi/sicak-para-yatirimcileri-reel-kur-endeksi-degisimine-gore-karar-veriyor-13075/> (Alıntılanma Tarihi: 14.08.2018)
- SAYILI, H., SAYILI, M. ve YILMAZ, G. (2010). Türkiye İçin Yeni Reel Efektif Döviz Kuru Endeksleri. Ankara: T. C. Merkez Bankası Çalışma Tebliği No: 10/12.
- SINGH, N., MOHANTY, S. R. & SHUKLA, R. D. (2017). Short Term Electricity Price Forecast Based on Environmentally Adapted Generalized Neuron, *Energy*, (125), 127-139.
- STEVE, N.C. (2014). Autoregressive Integrated Moving Average (ARIMA) Model for Exchange Rate (Naira to Dollar), *Academic Journal of Interdisciplinary Studies*, 3(4), 429-433.
- TATOĞLU, Y. (2009). Reel Efektif Döviz Kurunun Durağanlığının Yapısal Kırılmalı Panel Birim Kök Testleri Kullanılarak Sınanması, *Doğuş Üniversitesi Dergisi*, 10(2), 310-323.
- ULUSOY, T. (2010). İMKB Endeks Öngörüsü İçin İleri Beslemeli Ağ Mimarisine Sahip Yapay Sinir Ağı Modellemesi, *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 2(5), 21-40.
- YAFFEE, R.A. & MCGEE, M. (2000). *Introduction to Time Series Analysis and Forecasting with Applications of SAS and SPSS*, London: Academic Press.
- YAĞIMLI, M. ve ERGİN, H. (2017). Türkiye’de İş Kazalarının Üstel Düzeltme Metodu ile Tahmin Edilmesi, *Marmara Fen Bilimleri Dergisi*, (4) 118-123.
- ZHANG, G. P. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model, *Neurocomputing*, (50), 159 – 175.
- ZHANG, G. P. (2004). “A combined ARIMA and Neural Network Approach for Time Series Forecasting”, s. 213-225, (Ed.)

ZHANG, G.P., Neural Networks in Business Forecasting, Idea Group Publishing.