

BOX-JENKINS VE YAPAY SİNİR AĞI MODELLERİ İLE ENFLASYON TAHMİNİ*

*Murat AKDAĞ**
Vecihi YİĞİT****

Alınış Tarihi: 30 Nisan 2015

Kabul Tarihi: 06 Mart 2016

Öz: Enflasyon tahmini ülkeler için büyük bir önem arz etmektedir ve yatırımlar bu verilere göre yapılmaktadır. Gelişmekte olan ülkeler açısından enflasyon oranının düşük seyretmesi önemli hedeflerden birisidir. Bu nedenle geçmiş verilere bakarak geleceğe yönelik doğru tahminlerde bulunulması önemlidir. Kısa dönemli tahmin çalışmalarında en uygun yöntemlerden birisi zaman serileridir. Bu çalışmada zaman serileri analizinde kullanılan Box-Jenkins ve Yapay Sinir Ağları olarak bilinen yöntemlerle enflasyon verisine ait zaman serisi analizi kullanılmış ve sonuçlar karşılaştırmalı olarak sunulmuştur. Yapılan çalışmada, ARIMA modelinin Yapay Sinir Ağı modeline göre bir miktar daha iyi performans sergilediği gözlenmiştir.

Anahtar Kelimeler: Zaman Serileri, Yapay Sinir Ağları, Enflasyon Tahmini, ARIMA, Box-Jenkins, TCMB.

FORECASTING INFLATION WITH BOX-JENKINS AND ARTIFICIAL NEURAL NETWORK MODELS

Abstract: Inflation forecasting is significantly important for the countries and investments are made according to this data. Slow inflation rate is one of the most important target for developing countries. Thus, accurate forecasting with past data is significant. Time series analysis is one of the most suitable methods for the short period forecasting works. In this study, time series analysis methods known as Box-Jenkins and Artificial Neural Network which are used for inflation rate time series and the results has been served comparative. In this study, ARIMA model shows slightly better performance than Artificial Neural Network model.

Keywords: Time series, Artificial Neural Networks, Inflation Forecasting, ARIMA, Box-Jenkins, CBRT.

I. Giriş

Enflasyon yalnızca firmalar ya da bireyler açısından değil, toplumun tamamı açısından önem taşımaktadır. Enflasyonun maliyetini, karar alma aşamasındaki yatırımcılar ve tüketiciler daha kolay görmektedir. Bireyleri yatırım ve tüketim açısından kararsızlığa iten yüksek enflasyon durumu,

* Bu çalışma, Atatürk Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Yüksek Lisans programında tamamlanan aynı isimli yüksek lisans tezinden üretilmiştir. Çalışmada yer alan görüşler yazarlara aittir ve kurumlarının resmi görüşü olarak değerlendirilemez

** Türkiye Cumhuriyet Merkez Bankası, Erzurum Şubesi

*** Doç. Dr. Atatürk Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü

üreticilerin ve tüketicilerin kararlarını etkilemektedir. Yatırımlar, kârların kısa zamanda elde edileceği, giderlerin ise uzun vadede ödeneceği varsayımıyla yapıldığından, bu yatırımların faydalı olup olmayacağı konusunu tespit etmek zorlaşmaktadır. Örneğin, üretim aşamasında kullanılacak olan makine veya malzemenin yatırıma başlanmasından sonra alınacak olması durumunda, o dönemdeki maliyetlerin ne olacağını hesaplamak kolay olmayacaktır. Aynı şekilde, yatırımın bitmesiyle tüketiciye ulaştırılacak mal veya hizmetin satış fiyatının ne olacağını belirlemek güçleşmektedir.

Ekonomik faaliyetlerin devamı için önemli olan; bir ekonomideki insanların içinde buldukları ekonomiye güvenidir. Bu güvenin sağlanması için fiyat istikrarı da önemli başlıklardan birisidir. Merkez bankalarının öncelikle görevi olan fiyat istikrarının sağlanması ile üretim ve tüketimin devamlılığı sağlanmaktadır (TCMB, 2016). Ekonomi dinamik bir seyir izlediğinden sürekli değişiklikler görülebilmektedir. Bu gibi değişikliklerin minimum düzeyde tutulması, sert dalgalanmalara izin verilmemesi ekonominin güvenilirliğinin işareti olmaktadır. Öngörülebilir ekonomik şartlara göre ayarlamalar yapılması gerekmektedir. Merkez bankaları enflasyon oranı konusunda geleceğe yönelik açıklamalar yaparak beklenti yönetimini de planlamaktadır (Kara ve Orak, 2008). Merkez bankaları yetkililerinin açıklamaları ile öngörüler oluşturulduğunda daha başarılı tahminlere ulaşılabilir. Başarılı tahminler merkez bankalarının ve ülkenin kredibilitesini ve saygınlığını artırmaktadır.

Bununla birlikte enflasyon tahmini konusunda temel hedefte tutarsızlık bulunmaktadır. Enflasyon hedeflemesi için sayısal bir oran belirlenmekte ve merkez bankasının bu hedefe ulaşması görevi verilmektedir. Bunun yanı sıra söz konusu hedefe ulaşabilmesi için bağımsızlığının ve şeffaflığının da artırılması gerekmektedir. Ancak Türkiye Cumhuriyet Merkez Bankası (TCMB) enflasyon hedefini TÜFE olarak belirlemektedir. Tüketici Fiyat Endeksi olarak bilinen TÜFE endeksinde TCMB'nin para politikası araçları ile etkileyemeyeceği koşullar bulunmaktadır. Örneğin enerji fiyatları yurtdışında belirlenmekte ancak TÜFE içerisinde değerlendirilmektedir. Alkol ve tütün fiyatları kamu otoriteleri tarafından ayarlanmaktadır. Maliye Bakanlığı tarafından, bütçe için gerekli gördüğü takdirde tütün ve alkol fiyatlarında yukarı yönlü oynama yapılması, TÜFE'nin yukarı yönlü sapmasına neden olmakta, bu da enflasyon hedeflerine ulaşmayı geciktirici etki yapmaktadır. Bunların önüne geçmek ve tahminlerin doğruluğunu artırmak için yapılması gereken; çekirdek enflasyonu temel enflasyon göstergesi olarak almaktır. Doğru hedeflemenin, bu büyüklük üzerine hedef konularak yapılabileceği değerlendirilmektedir.

Zaman serileri son dönemde geleceğe yönelik tahminlerde sıklıkla kullanılmaktadır. Bir zaman serisi, belirli bir zaman aralığındaki gözlem değerlerinden oluşmaktadır. Bu gözlem değerlerinin zaman içerisinde birbirlerine bağımlı olduğunu göstermektedir (Sevüktekin ve Nargeleşkenler, 2010). Zaman serileri kısa dönem tahminlerinde kullanıldıklarında tutarlı

sonuçlar vermektedir. Bir zaman serisinin en önemli noktası durağan olup olmamasıdır. Bir zaman serisinin varyansı, kovaryansı ve ortalaması, zaman içinde değişmiyorsa ya da seri periyodik dalgalanmalardan arındırılmışsa bu seri durağandır denilebilir. Durağanlığa ulaştıktan sonra model kurulmakta ve tahmin yapılmaktadır. Ancak çoğu zaman serisi, doğrusal ilişki ile birlikte doğrusal olmayan ilişkiyi de içermektedir. Farklı yöntemlerle doğrusal olmayan ilişki modellenebilmektedir. Son yıllarda zaman serilerinin analizinde kullanılan alternatif yöntemlerden biri haline gelen Yapay Sinir Ağları (YSA), karşılaştığı yeni olaylara hızlı adapte olabilmesi sayesinde doğrusal ya da doğrusal olmayan ilişkilerin modellenebileceğini göstermektedir. Yapay sinir ağları ile yapılan analizlerin; ağa sunulan verilerden öğrenme, ilişkilendirme, sınıflandırma, genelleme, optimizasyon gibi faydaları sayesinde, ekonomik zaman serileri gibi doğrusal olmayan serilerin öngörüsünde başarılı olduğu görülmektedir (Öztemel, 2003).

Bu çalışmada yıllık yüzde değişim yöntemine göre hesaplanan Tüketici Fiyat Endeksi (TÜFE) verileri kullanılarak ARIMA ve Yapay Sinir Ağı modelleri oluşturulmuş ve her iki modelin performansı karşılaştırılmıştır.

II. Literatür Özeti

Yapay sinir ağları veya ARIMA modelleri ile geleceğe yönelik tahminlerde bulunulmasına yönelik literatürde birçok çalışma vardır. Bunlardan bazıları; Tang ve diğ. (1991), aylık iş verilerinin kullanarak yaptıkları çalışmada, uzun dönemli serilerde YSA ve ARIMA modellerinin yaklaşık olarak benzer sonuçlar verdiğini, kısa dönemli serilerde ise YSA'nın daha iyi sonuçlar verdiği belirlemişlerdir.

Caire ve diğ. (1992), günlük elektrik tüketim verilerini kullanarak YSA ve ARIMA öngörü sonuçlarını karşılaştırmışlardır. Bu çalışmanın sonucunda YSA, ARIMA'dan daha iyi sonuçlar verirken, uzun dönemli tahminlerde elde edilen sonuçların çok daha iyi olduğu görülmüştür.

Refenes (1993), saatlik döviz kuru zaman serisi verileri ile yaptığı çalışmada, YSA'nın, üssel düzeltme ve ARIMA modellerinden daha iyi öngörü değerleri verdiği sonucuna ulaşmıştır.

Beş farklı konuda derlediği zaman serileri ile yaptığı çalışmada Shabri (2001), mevsimsel zaman serilerinde YSA ve ARIMA modellerinin birbirlerine yakın sonuçlar verdiğini, düzensiz yapıdaki zaman serilerinde ARIMA'nın daha iyi öngörü sonuçları verdiği bulgularını elde etmiştir.

Montanes ve diğ. (2002), nükleer enerji verileri ile yaptıkları analiz sonucunda, YSA'nın daha iyi öngörü performansına sahip olduğu ve ARIMA modellerinin zaman serisindeki sistematik değişiklikleri öngöremediği sonucuna varmışlardır.

Kamruzzaman ve Sarker (2003), Avusturya Doları'na ilişkin altı farklı çapraz kur ile oluşturulan yapay sinir ağları modelleri ve ARIMA kullanılarak tahmin edildiği bir çalışma yapmışlardır. Bu çalışma sonucunda YSA ile

yapılan tahminlerin ARIMA ile yapılan tahminlere göre daha iyi sonuç verdiğini belirlemişlerdir.

Domaç (2004), Türkiye için enflasyonun öngörüsünü ve tanımlanmasını amaçladığı çalışmasında Kar Marjı (Mark-Up) Modelleri, Parasal Açık (Money Gap) Modelleri, Phillips Eğrisi (Phillips Curve) Modeli ve ARIMA Modeli arasında en iyi modelin Phillips Eğrisi Modeli olduğunu ifade etmiştir.

Binner ve diğ. (2005), GSMH ve deflatörü, Divisia Euro M3 verilerini kullanarak yaptıkları çalışmada; VAR, ARIMA ve YSA'lar ile yapılan analizlerde YSA'nın çok daha isabetli öngörüler yaptığı sonucunu elde etmişlerdir.

Zou ve diğ. (2007); ARIMA, YSA ve bu iki modelin birleşimi ile elde ettikleri modeller ile Çin ekonomisindeki buğday fiyatlarının öngörüsünü yaparak bu modellerin öngörü performanslarını karşılaştırmışlardır. Karşılaştırma sonuçları, çalışmada kullanılan modeller arasında YSA'nın en iyi öngörü performansına sahip olduğunu göstermektedir.

Abdelmouez ve diğ. (2007), Amerika hisse senedi piyasasından derlenen 3429 gözlemden oluşan veri setini kullanarak ARIMA, çoklu regresyon ve YSA yöntemlerini karşılaştırmıştır. Yapılan analizler sonucunda, YSA'nın çok daha iyi öngörü sonuçları verdiği gözlemlenmiştir.

İnsel ve diğ. (2010), 1987-2007 yılları arasında Türkiye ekonomisindeki nominal dolar döviz kuru indeksindeki yıllık değişim, yıllık enflasyon oranı, on iki aylık depozitolar üzerindeki nominal faiz oranı ve reel GSMH'nin logaritmasına ait aylık verileri kullanarak ARMA ve YSA modellerinin öngörü performansını karşılaştırmışlardır. Çalışmada yapılan öngörüler sonucunda, enflasyon oranı, faiz oranı ve döviz kuru için YSA ve reel GSMH için ARMA modelinin daha iyi öngörü değerleri verdiği anlaşılmaktadır.

Meçik ve Karabacak (2011), Türkiye'de 2003-2011 yıllarına ait enflasyon zaman serisine ait veri seti kullanarak ARIMA modelleri ile yaptığı enflasyon tahmini çalışmasının, literatürdeki yaygın kanaate paralel şekilde başarılı olduğunu ifade etmişlerdir.

Erilli ve diğ. (2011), ileri ve geri beslemeli yapay sinir ağlarının tahmin sonuçlarının yine yapay sinir ağları kullanılarak birleştirildiği melez yaklaşımın, Türkiye enflasyon oranı tahmininde uygun olacağını değerlendirmektedirler.

Choudhary ve Haider (2012), Ekonomik Kalkınma ve İşbirliği Örgütü'ne (OECD) üye 28 ülke için yaptıkları çalışmada, yapay sinir ağlarının enflasyon tahmini için kısa dönem öngörülerde uygun olacağını belirtmişlerdir.

Uğurlu ve Saraçoğlu (2013), Türkiye'de enflasyon öngörüsü için naive model, üssel düzeltme modeli ve ARIMA modeli kullanmış, ARIMA modelinin uygulama döneminde en iyi başarıya sahip olduğunu belirtmişlerdir.

Türkiye enflasyon verileri kullanılarak yapılan çalışmaların genellikle enflasyon belirsizliği üzerine kurgulanmış olması, tahmin çalışmalarının sınırlı sayıda olması nedeniyle bu çalışmanın literatüre katkı sağlayacağı düşünülmektedir.

III. Box-Jenkins Metodolojisi ve Yapay Sinir Ağları

Box-Jenkins olarak bilinen zaman serisi analiz yöntemi; tek değişkenli zaman serilerinde kullanılan, ileriye yönelik tahminleri istatistiksel yöntemlerle yapan tekniklerden biridir. Bu yöntemin uygulanabilmesi için zaman serisinin; kesikli, durağan ve eşit aralıklı gözlem değerlerinden oluşması gerekmektedir. Bununla birlikte zaman serilerinin varyansında ve ortalamasında zamana bağlı olarak değişim olmaktadır. Durağan olmayan zaman serilerinde görülen bu değişimin oluşmasında; düzenli veya düzensiz dalgalanmalar, trend etkisi veya tesadüfi dalgalanmaların etkisi büyüktür. Durağan olmayan zaman serilerinin geleceğe yönelik tahmini için bazı dönüşüm yöntemleri kullanılarak seri durağan hale getirilmelidir. Box-Jenkins Yöntemi ile öngörüsü yapılan zaman serisi modelleri; Otoregresif Modeli (AR), Hareketli Ortalama Modeli (MA), Otoregresif Hareketli Ortalama Modeli (ARMA) ve Otoregresif Bütünleşik Hareketli Ortalama (ARIMA) Modeli olarak adlandırılır. Durağan olmayan ancak fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modellere ARIMA modelleri adı verilir. Bu modellerin genel gösterimi ARIMA (p, d, q) şeklindedir. Burada “p”; Otoregresif (AR) Modelin, “q” ise Hareketli Ortalama (MA) Modelinin derecesi, “d” ise fark alma derecesidir (Günay vd., 2007) (Sevüktekin ve Nargeleçekenler, 2010)

Yapay sinir ağları, biyolojik sinir ağlarına benzemektedir ve bu ağlara benzer bazı performans özellikleri içeren bir bilgi işleme sistemidir (Fausett, 1994). Yapay sinir ağları, insan beyninin çalışma şeklinde işlem yapar ve aynı zamanda sınırsız sayıda değişkenle çalışabilme, veriden öğrenebilme, genelleme yapabilme gibi birçok önemli özelliğe sahiptir. YSA'nın en küçük birimlerine yapay sinir hücresi veya işlem elemanı adı verilir. Yapay sinir ağı modeli, birbirleriyle ilişkili olan nöronların bulunduğu katmanlardan oluşmaktadır. Ağın kaç katmandan oluştuğu ve bu katmanlarda yer alacak nöron sayıları, ağın mimarisi olarak adlandırılmaktadır. Yapay sinir ağının mimarisi, ağın performansını etkilemektedir (Elmas, 2003) (Öztemel, 2003).

Bir yapay sinir ağının en temel görevi, veri setindeki şablonu öğrenerek istenilen görevi yerine getirecek şekilde genellemeler yapmasıdır. Bunun yapılabilmesi için ağa ilgili olayla ilgili örnekler verilerek eğitilmesi gerekmektedir. YSA'nın öğrenmesi, yapay sinir hücrelerinin sahip olduğu ağırlıkların, belirli eğitim fonksiyonlarıyla değiştirilmesi ile yapılmaktadır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı ağın eğitiminde geri yayılım algoritması kullanılmaktadır. Geri yayılım algoritması birçok uygulamada kullanılmış, danışmanlı öğrenme yapısına sahip olan en yaygın öğrenme algoritmasıdır. Danışmanlı öğrenme algoritmalarında ağın eğitimi için, ağa örnek olarak girdi ve çıktı değerlerden oluşan bir örnek veri seti verilmektedir. Verilen hedef çıktı değerleri, YSA literatüründe danışman ya da öğretmen olarak adlandırılmaktadır. Danışmanlı öğrenme algoritmalarında öğrenme aşamasında ağırlıklar, hata fonksiyonunun minimize edilmesiyle düzenlenmektedir (Hamzaçebi, 2011) (Öztemel, 2003).

IV. Veri Seti ve Yöntem

Bu çalışmada, geçmiş enflasyon verisine ait zaman serisi kullanılarak ARIMA yöntemi ve yapay sinir ağı yöntemi ile söz konusu zaman serisinin geleceğe yönelik tahmin başarısının ölçülmesi amaçlanmıştır. ARIMA ve YSA yöntemleri ile bulunan uygun modellerin, takip eden yıldaki enflasyon zaman serisi ile farklılığı incelenmiştir. Bu farklılıklar literatürde sıklıkla kullanılan; Ortalama Mutlak Hata Yüzdesi (MAPE), Ortalama Mutlak Hata (MAE), Hata Kareler Ortalaması (MSE) ve Ortalama Yüzde Hata (MPE) gibi istatistiksel yöntemlerle değerlendirilmiştir (Zhang ve Hu, 1998) (Cho, 2003) (De Lurgio, 1998). Bu ölçümler sonucuna göre Witt ve Witt (2000) MAPE değerleri %10'un altında olan tahmin modellerinin yüksek doğruluk derecesine sahip olduğunu, %10 ile %20 arasında olan değerlerin ise doğru tahminler olduğunu değerlendirmiştir (Çuhadar ve Kayacan, 2005)

Çalışmada kullanılan veriler, T.C. Merkez Bankası'nın elektronik veri dağıtım sisteminden (<http://evds.tcmb.gov.tr/>) alınmıştır. Ocak 2004 ile Aralık 2013 arasındaki yıllık yüzde değişim yöntemine göre hesaplanan Tüketici Fiyat Endeksi kullanılmıştır. YSA ve ARIMA modelleri için 2013 yılına ait 12 veri örneklem için test için kullanılmıştır. 2014 yılı verileri ise örneklem dışı testi için kullanılmıştır. YSA modelinde ise veri setinin %70'i eğitim, %15'i test, %15'i ise doğrulama verisi şeklinde rassal olarak kullanılmıştır. Çalışmanın analizinde Matlab (ver. 2013a) ve Eviews 7 programı kullanılmıştır. Serilerin durağanlığı incelenmiş ve sonuçlar Tablo 1'de verilmiştir. Durağanlık testi sonuçlarına göre durağan olmayan seriler fark alma yöntemiyle durağan hale getirilmiştir.

V. Bulgular

Seride durağanlık olmadığından durağanlığın sağlanması için öncelikle mevsimsel farkı alınmış (sTÜFE), ardından korelogram ve durağanlığı incelenmiştir. Sonuç olarak seride hala durağanlık bulunmadığına ulaşılmış, ardından birinci derece farkı alınmıştır (dsTÜFE). Bu işlemler sonrasında serinin durağanlığı için yapılan ADF birim kök testi sonucu Tablo 2'de gösterilmiştir.

ARIMA modellerinin AR terimlerinin belirlenmesi için kısmi otokorelasyon, MA terimlerinin belirlenmesi içinse otokorelasyon fonksiyonları kullanılmıştır. MAPE, MSE ve AIC ölçütleri karşılaştırılarak oluşturulan modeller içerisinde veri setine en uygun olan model belirlenmiştir. Sonuç olarak bu modeller içerisinde ARIMA (2,1,1)(1,1,1) modelinin kullanılması uygun görülmüştür. Modele ilişkin parametre tahminleri ve istatistikler Tablo 3 ve Tablo 4'de verilmiştir.

Tablo 1: TÜFE Serisi İçin Durağanlık Testi Sonuçları

Augmented Dickey-Fuller Birim Kök Testi Sonuçları				
TÜFE		Sabit	Sabit ve Trend	Sabitsiz ve Trendsiz
Prob.		0,0414	0,1403	0,3181
ADF Test İstatistiği		-2,962580	-2,986922	-0,914852
MacKinnon Kritik Değeri	%1	-3,486064	-4,036983	-2,584539
	%5	-2,885863	-3,448021	-1,943540
	%10	-2,579818	-3,149135	-1,614941

Tablo 2: dsTÜFE Serisi İçin Durağanlık Testi Sonuçları

Augmented Dickey-Fuller Birim Kök Testi Sonuçları				
dsTÜFE		Sabit	Sabit ve Trend	Sabitsiz ve Trendsiz
Prob.		0	0	0
ADF Test İstatistiği		-8,933555	-8,953171	-8,988706
MacKinnon Kritik Değeri	%1	-3,500669	-4,057528	-2,589531
	%5	-2,892200	-3,457808	-1,944248
	%10	-2,583192	-3,154859	-1,614510


Tablo 3: ARIMA Modeline İlişkin Parametre Tahminleri

Değişken	Katsayı	Standart Hata	t-istatistiği	p
AR(1)	0.408049	0.170467	2.393710	0.0185
AR(2)	0.475304	0.162818	2.919234	0.0043
SAR(12)	-0.222963	0.108140	-2.061807	0.0418
MA(1)	0.616542	0.137419	4.486598	0.0000
SMA(12)	-0.880405	0.047439	-18.55863	0.0000


Tablo 4: ARIMA Modeline İlişkin İstatistikler

	ARIMA (2,1,1)(1,1,1)
Düzeltilmiş R^2	0.886453
Regresyonun Standart Hatası	0.616473
Akaike Bilgi Kriteri (AIC)	1.925335
Schwarz Kriteri (SBC)	2.076096

Grafik 1'de ARIMA modelinin gerçek verilerle uyum sağlamış olduğu aynı zamanda kalıntı grafiğinin de büyük ölçüde modelin güven aralığı içerisinde kaldığı görülmektedir. Artıkların güven aralığı içerisinde kalması modelin güvenilirliğini artırmaktadır.




Grafik 1: $ARIMA(2,1,1)(1,1,1)$ modeline ait hataların ACF ve PACF grafiği




Grafik 2: 2013 yılı TÜFE gerçekleşen değerler ile ARIMA modeli grafiği

2013 yılı gerçekleşen TÜFE verileri ile ARIMA model grafiği Grafik 2’de verilmiştir. Buradan görüleceği üzere ARIMA modeli gerçekleşen değerlere önemli ölçüde yakınsamıştır.

Yapay Sinir Ağı modelinin kurulması sırasında 2004:1-2013:12 dönemi arasındaki 120 adet veriden 84 tanesi eğitim, 18 tanesi test ve 18 tanesi doğrulama aşamasında kullanılmıştır. Veri seti; yapay sinir ağlarının eğitiminde sağlanan kararlılık ve hız nedeniyle sıklıkla tercih edilen Levenberg-Marquardt geri yayılım algoritması ile eğitilmiştir (Önder vd., 2013). Gizli katman sayısı 10, gecikme sayısı 2 olarak alınan modelde, kullanılan algoritma Grafik 3’te verilmiştir.




Grafik 3: Modelde Kullanılan Yapay Sinir Ağı Algoritması



Grafik 4: Ağın eğitilmesi sonucundaki zaman serisi tepkisi grafiği

Grafik 4'te ağın eğitilmesi sonucunda eğitim, doğrulama ve test hedefleri ile çıktıları arasındaki hatalar gösterilmektedir. Eğitim kısmındaki hedef ve çıktılar arasındaki fark biraz fazla iken sonrasında eğitim ve test aşamasında bu hataların daha da azaldığı görülebilir. Hataların toplamının gösterildiği kısım incelendiğinde, modele ait hatalar gerekli güven aralığı sınırları içerisinde kaldığından ağın istenilen performansa ulaştığı söylenebilir.



Grafik 5: 2013 yılı TÜFE gerçekleşen değerler ile YSA model grafiği

Çalışma sonucunda ilgili veri seti için elde edilen sonuçlar Tablo 5'te verilmiştir. Her iki veri seti içinde ARIMA ve YSA modelleri MAPE ve MSE performans ölçülerine göre karşılaştırıldığında ARIMA modelinin daha iyi sonuç verdiği görülebilir. Bunun en önemli nedenlerinden birisi, eğitimde kullanılan veri sayısının modelin tutarlılığını doğrudan etkilemesinden kaynaklanmaktadır.

Tablo 5: TÜFE serisi için gerçekleşen ve tahmin edilen değerler


	Gerçekleşen	ARIMA	YSA
Oca.13	7.30765	6.489069	6.3503
Şub.13	7.0254	6.475188	7.9482
Mar.13	7.29065	6.771937	7.389
Nis.13	6.13378	6.03778	7.6667
May.13	6.51469	7.456199	5.697
Haz.13	8.29752	8.034325	7.1551
Tem.13	8.88443	8.192773	9.7687
Ağu.13	8.16823	7.866593	8.7202
Eyl.13	7.88244	7.696822	7.8654
Eki.13	7.71194	7.960228	7.8547
Kas.13	7.3157	8.850747	7.7969
Ara.13	7.40046	8.657813	7.55
	MAPE	0.083636	0.088565
	MAE	0.617318	0.641562
	MSE	0.567465	0.621951
	MPE	-0.00911	-0.02251

Grafik 6: 2013 yılı TÜFE serisi için gerçekleşen ve tahmin edilen değerlerin grafiği

Grafik 6'da 2013 yılında gerçekleşen TÜFE verileri ile ARIMA ve YSA modelleri arasındaki ilişkiyi gösterilmektedir. Burada görüleceği üzere YSA modeli gerçekleşen verileri daha keskin biçimde tahmin etmeye çalışmakta buna rağmen ARIMA modeli daha yavaş biçimde gerçekleşen değerleri yakalamaya çalışmaktadır.

Tablo 6: 2014 yılı TÜFE Tahmin Sonuçları

2014 YILI TÜFE TAHMİNİ	ARIMA	YSA
MAPE	0.15071	0.144158
MAE	1.347533	1.306314
MSE	2.23562	2.35173
MPE	0.136659	0.109766



Grafik 7: 2014 yılı TÜFE serisi için gerçekleşen ve tahmin edilen değerlerin grafiği

2014 yılında gerçekleşen TÜFE verileri kullanılarak, ARIMA ve YSA modelleri ile yapılan tahminleri gösteren yukarıdaki Grafik 7 incelendiğinde, YSA modelinin yine keskin bir biçimde modeli tahmin etmeye çalışması dikkat çekmekle birlikte ARIMA modeli gerçekleşen verileri yakalamakta yavaş kalmıştır. Her iki modelde birbirine yakın sonuçlar vermekle birlikte ARIMA modeli bir miktar daha iyi performans sergilemiştir.

VI. Sonuç

Türkiye Cumhuriyet Merkez Bankası'nın temel amacı fiyat istikrarını sağlamak ve sürdürmektir. Bu amaca ulaşmak için Ocak 2006 itibarıyla enflasyon hedeflemesi rejimine geçilmiştir. Bununla birlikte temel enflasyon göstergesi olarak anılan veri setinde TCMB'nin kullandığı para politikası araçları ile etkileyemeyeceği kalemler çoğunluktadır. Temel enflasyon göstergesi olan Tüketici Fiyat Endeksi'nin içerisinde 426 adet madde bulunmaktadır (TÜİK, 2015). Bu maddeler içerisinde, tahminlerin sapmasına neden olan en önemli iki kalemden birisi dışa bağlı olunan enerji fiyatları ve Maliye Bakanlığı tarafından kontrol edilen alkol ve tütün fiyatlarıdır. Devlet bütçesine fayda sağlamak adına alkol ve tütün fiyatlarındaki yukarı veya aşağı yönlü hareket, enflasyon göstergesine aynı şekilde ters yönde yansımaktadır. Bu da enflasyonun doğru tahmin edilememesi sonucunu doğurmaktadır. Merkez Bankası'nın enflasyon tahmin göstergelerinde, enflasyonun tahmin aralığı

içinde kalma olasılığının yüzde 70 olarak belirtilmesi de bunun bir göstergesidir (TCMB, 2015). Bu nedenle, tahminlerin daha doğru sonuç vermesi adına, temel enflasyon göstergesi olarak alınan TÜFE veri setinin kullanılmaması gerekmektedir. Aksi takdirde hangi yöntem kullanılırsa kullanılsın, veri setindeki mevsimsel veya konjonktürel hareketlerin olumsuz etkisi nedeniyle, tahmin için kullanılan modellerin ilerleyen dönemlerde kullanıldığında faydalı olmayacağı sonucuna ulaşılmaktadır.

Bu çalışmada, tahmin yöntemlerinin işleyişleri ve tahmin performanslarının karşılaştırılmasına yönelik genel bir bakış açısı sunmak amaçlanmıştır. Bunun için Yapay Sinir Ağları ve Box-Jenkins modelinin başarı performansları karşılaştırılmıştır. YSA modelinin kısa dönemde değişen varyans sorunun çözmede başarılı olmaması durumunda ARIMA modelinin durağan yapısı ile başarılı performans göstermesinden dolayı modeller birbirine yakın performans gösterebilmektedir. Bu nedenle öngörü aşamasında farklı modeller deneyerek veri setine en uygun modelin araştırılması gerekmekte, aynı zamanda veri seti değişikçe modelin gözden geçirilmesi gerekmektedir.

Çalışmadan elde edilen model yardımıyla geleceğe yönelik tahminlerde bulunulabilir. Tahmin aşamasında dikkat edilmesi gereken nokta tahminlerin kısa vadeli (12 aylık) dönemler için yapılması gerektiğidir. Çünkü enflasyona ait zaman serileri ile çalışma yaparken kısa dönemli tahminler verimli sonuçlar verirken, uzun dönemli tahminlerde hata payı ciddi biçimde yükselebilmektedir.

Kaynaklar

- Abdelmouez, G., Hashem, S. R., Atiya, A. F. ve El-Gamal, M. A. (2007) "Neural network vs. linear models for stock market sectors forecasting", *Neural Networks 2007. IJCNN., International Joint Conference on*, Florida, USA, ss.1365 1369.
- Binner, J. M., Bissoondeal, R. K., Elger, T., Gazely, A. M., & Mullineux, A. W. (2005) "A comparison of linear forecasting models and neural networks: an application to Euro inflation and Euro Divisia", *Applied Economics*, 37(6), ss.665 680.
- Caire, P., Hatabian, G. ve Muller, C. (1992) "Progress in forecasting by neural networks", *Neural Networks, 1992. IJCNN., International Joint Conference on*, Baltimore, USA, ss.540 545.
- Cho, V. (2003). A comparison of three different approaches to tourist arrival forecasting. *Tourism Management*, 24(3), 323-330.
- Choudhary, M. A., & Haider, A. (2012). Neural network models for inflation forecasting: an appraisal. *Applied Economics*, 44(20), 2631-2635.
- Çuhadar, M., & Kayacan, C. (2005). Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme. *Anatolia Turizm Araştırmaları Dergisi*, 16(1), 121-126.
- DeLurgio, S. A. (1998). *Forecasting principles and applications*.

- Domaç, İ. (2004). Explaining and forecasting inflation in Turkey. *World Bank Policy Research Working Paper*, (3287).
- Elmas, Ç. (2003). **Yapay Sinir Ağları** (Kuram, Mimari, Eğitim, Uygulama), Seçkin Yayıncılık, Ankara.
- Erilli, N. A., Eğrioğlu, E., Yolcu, U., Aladağ, Ç. H., & Uslu, V. R. (2011). Türkiye’de enflasyonun ileri ve geri beslemeli yapay sinir ağlarının melez yaklaşımı ile öngörüsü. *Doğuş Üniversitesi Dergisi*, 11(1), 42-55.
- Fausett, L. (1994), **Fundamentals of Neural Networks: Architectures, Algorithms and Applications**, Prentice Hall, USA.
- Günay, S., Eğrioğlu, E., Aladağ, Ç. (2007). **Tek Değişkenli Zaman Serileri Analizine Giriş**, Hacettepe Üniversitesi Yayınları, Ankara.
- Hamzaçebi, C. (2011), **Yapay Sinir Ağları**, Ekin Yayınları, Bursa.
- İnsel, A., Karakas, M. ve Süalp, M. N. (2010) “A Comparative Analysis Of The Arma And Neural Networks Models: A Case Of Turkish Economy”, *İktisat İşletme ve Finans*, 25 (290), ss.35-64
- Kamruzzamman, J. ve Sarker, R. A. (2003) “Forecasting of Currency Exchange Rates using ANN: A Case Study”, *Neural Networks & Signal Processing (ICNNSP03)*, Nanjing, China, ss.793 797.
- Kara, H., & Orak, M. (2008). **Enflasyon Hedeflemesi. Krizler, Para ve İktisatçılar**, Ed. Ercan Kumcu, İstanbul: Remzi Kitabevi, 81-157.
- Meçik, O., & Karabacak, M. (2011). ARIMA Modelleri ile Enflasyon Tahminlemesi: Türkiye Uygulaması. *Selçuk Üniversitesi Sosyal ve Ekonomik Araştırmalar Dergisi*, 22, 177-198.
- Montañés, E., Quevedo, J. R., Prieto, M. M., ve Menéndez, C. O. (2002) “Forecasting time series combining machine learning and Box-Jenkins time series Advances in Artificial Intelligence”, *Advances in Artificial Intelligence*, Springer, ss.491 499.
- Önder, E., Bayır, F., & Hepsen, A. (2013). Forecasting Macroeconomic Variables Using Artificial Neural Network and Traditional Smoothing Techniques. *Journal of Applied Finance and Banking*, 3(4), 73-104.
- Öztemel, E. (2003), **Yapay Sinir Ağları**, Papatya Yayıncılık, İstanbul.
- Refenes, A. N., Azema-Barac, M., Chen, L. ve Karoussos, S. (1993) “Currency exchange rate prediction and neural network design strategies”, *Neural Computing & Applications*, Springer, 1(1), ss.46 58.
- Sevüktekin, M. ve Nargeleçekenler, M. (2010), **Ekonometrik Zaman Serileri Analizi**, Geliştirilmiş Üçüncü Baskı, Nobel Yayın, Ankara.
- Shabri, A. (2001) “Comparison of time series forecasting methods using neural networks and Box-Jenkins model”, *Matematika*, 17(1), ss.1 6.
- Tang, Z., de Almeida, C. ve Fishwick, P. A. (1991) “Time series forecasting using neural networks vs. Box-Jenkins methodology”, *Simulation*, 57(5), ss.303 310.
- Türkiye Cumhuriyet Merkez Bankası, www.tcmb.gov.tr (Erişim Tarihi: 10.01.2016)

- Türkiye Cumhuriyet Merkez Bankası Elektronik Veri Dağıtım Sistemi
<http://evds.tcmb.gov.tr> (Erişim Tarihi: 10.12.2015)
- Türkiye Cumhuriyet Merkez Bankası, Enflasyon Raporu 2015-IV
www.tcmb.gov.tr/wps/wcm/connect/7d5801dd-86ad-42e7-8c63-9c36ed201861/enf-ekim2015_tam.pdf?MOD=AJPERES&CACHEID=ROOTWORKSPACE7d5801dd-86ad-42e7-8c63-9c36ed201861
(Erişim Tarihi: 10.12.2015)
- Türkiye İstatistik Kurumu, www.tuik.gov.tr/PreIstatistikTablo.do?istab_id=1345 (Erişim Tarihi: 12.12.2015)
- Uğurlu, E., & Saraçoğlu, B. (2013). Türkiye’de Enflasyon Hedeflemesi ve Enflasyonun Öngörüsü. *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 25(2).
- Zhang, G., & Hu, M. Y. (1998). Neural network forecasting of the British pound/US dollar exchange rate. *Omega*, 26(4), 495-506.
- Zou, H., Xia, G., Yang, F. ve Wang, H. (2007) “An investigation and comparison of artificial neural network and time series models for Chinese food grain price forecasting”, *Neurocomputing*, 70(16), ss.2913-2923.