

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

**Murat AKDAĞ**

**Yüksek Lisans Tezi  
Endüstri Mühendisliği Anabilim Dalı  
Endüstri Mühendisliği Bilim Dalı  
Yrd. Doç. Dr. Vecihi YİĞİT  
2015  
Her hakkı saklıdır**

**ATATÜRK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ**

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

**Murat AKDAĞ**

**ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI  
Endüstri Mühendisliği Bilim Dalı**

**ERZURUM  
2015**

**Her hakkı saklıdır**



T.C.  
ATATÜRK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ



TEZ ONAY FORMU

BOX-JENKINS VE YAPAY SİNİR AĞI MODELLERİ İLE ENFLASYON  
TAHMİNİ

Yrd. Doç. Dr. Vecihi YİĞİT danışmanlığında, Murat AKDAĞ tarafından hazırlanan bu çalışma 15/06/2015 tarihinde aşağıdaki jüri tarafından Endüstri Mühendisliği Anabilim Dalı – Endüstri Mühendisliği Bilim Dalı'nda Yüksek Lisans Tezi olarak **oybirliği/oy çokluğu (.../...)** ile kabul edilmiştir.

Başkan : Doç. Dr. Mehmet AKTAN

İmza

:

Üye : Yrd. Doç. Dr. Gökay AKKAYA

İmza

:

Üye : Yrd. Doç. Dr. Vecihi YİĞİT

İmza

:

Yukarıdaki sonuç;

Enstitü Yönetim Kurulu 18/06/2015 tarih ve 24/806 nolu kararı ile onaylanmıştır.

Prof. Dr. Ertan YILDIRIM  
Enstitü Müdürü

**Not:** Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

## ÖZET

Yüksek Lisans Tezi

### BOX JENKINS VE YAPAY SİNİR AĞI MODELLERİ İLE ENFLASYON TAHMİNİ

Murat AKDAĞ

Atatürk Üniversitesi  
Fen Bilimler Enstitüsü  
Endüstri Mühendisliği Anabilim Dalı  
Endüstri Mühendisliği Bilim Dalı

Danışman: Yrd. Doç. Dr. Vecihi YİĞİT

Enflasyon tahmini ülkeler için büyük bir önem arz etmekte, 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 Box-Jenkins ve Yapay Sinir Ağları olarak bilinen yöntemlerle enflasyon verisine ait zaman serisi analizi kullanılmış ve sonuçlar karşılaştırmalı olarak sunulmuştur.

**2015, 72 sayfa**

**Anahtar Kelimeler:** Zaman serileri, yapay sinir ağları, enflasyon tahmini, Box-Jenkins, Arima, TCMB

## **ABSTRACT**

Master Thesis

### **FORECASTING INFLATION WITH BOX-JENKINS AND ARTIFICIAL NEURAL NETWORK MODELS**

Murat AKDAĞ

Atatürk University  
Graduate School of Natural and Applied Sciences  
Department of Industrial Engineering  
Industrial Engineering Discipline

Supervisor: Asst. Prof. Dr. Vecihi YİĞİT

Inflation forecasting is so important for the countries and it is directly affected the investments. Slow inflation rate is one of the most important target for developing countries. Thus, accurate forecasting with past data is significant. Time series is one of the most suitable method for the short period works. In this study, Box-Jenkins and Artificial Neural Network methods, which are used for the forecasting inflation rate and the results has been served comparative.

**2015, 72 pages**

**Keywords:** Time series, artificial neural networks, inflation forecasting, Box-Jenkins, Arima, CBRT

## **TEŐEKKÜR**

Bu tezin bütn aŐamalarında deęerli fikirleriyle danıŐmanlık yaparak bana yol gsteren hocam Sayın Yrd. Doę. Dr. Vecihi YİęİT baŐta olmak zere, nemli katkılar saęlayan hocam Sayın Prof. Dr. mer Selęuk EMSEN'e, iŐ hayatında yardımlarını esirgemeyen Trkiye Cumhuriyet Merkez Bankası Erzurum Őubesi Kısım Amirim Harun NAL'a, her koŐulda bana destek olan sevgili eŐim Deniz AKDAę'a ve hayatımıza neŐe katan oęlum Yavuz'a en ięten teŐekkrlerimi sunarım.

**Murat AKDAę**

**Mayıs, 2015**

## İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ.....	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ.....	viii
<b>1. GİRİŞ.....</b>	<b>1</b>
<b>2. KAYNAK ÖZETLERİ.....</b>	<b>4</b>
<b>3. MATERYAL ve YÖNTEM.....</b>	<b>8</b>
3.1. Enflasyon ve Önemi.....	8
3.1.1. Enflasyon.....	9
3.1.2. Enflasyon çeşitleri.....	11
3.1.2.a. Talep enflasyonu.....	11
3.1.2.b. Maliyet enflasyonu.....	12
3.1.2.c. Para arzı enflasyonu.....	12
3.1.2.d. Enflasyon beklentisi.....	13
3.2. Türkiye Cumhuriyet Merkez Bankası ve Türkiye’de Enflasyon.....	13
3.2.1. Açık mektup.....	16
3.3. Enflasyon Hesaplama Yöntemleri.....	16
3.3.1. Tüketici fiyat endeksi (TÜFE).....	17
3.3.2. Yurtiçi üretici fiyat endeksi (Yİ-ÜFE).....	19
3.4. Box-Jenkins Metodolojisi.....	22
3.4.1. Durağanlık ve birim kök testleri.....	22
3.4.1.a. Korelogram ve otokorelasyon fonksiyonları (ACF-PACF).....	23
3.4.1.b. Genişletilmiş dickey fuller (ADF).....	24
3.4.2. Box-Jenkins modelleri.....	25
3.4.2.a. Otoregresif modeli (AR).....	25
3.4.2.b. Hareketli ortalama modeli (MA).....	25
3.4.2.c. Otoregresif hareketli ortalama modeli (ARMA).....	26

3.4.2.d. Otoregresif bütünleşik hareketli ortalama modeli (ARIMA) .....	26
3.4.2.e. Mevsimsel otoregresif bütünleşik hareketli ortalama modeli(SARIMA) .....	27
3.4.3. Box-Jenkins yönteminde model kurma süreci .....	28
3.4.3.a. Veri hazırlama .....	28
3.4.3.b. Ayırt edici kontrol .....	30
3.4.3.c. Öngörü .....	31
3.4.4. Box-Jenkins yönteminin üstün ve zayıf yönleri .....	33
3.5. Yapay Sinir Ağları.....	34
3.5.1. YSA'nın özellikleri .....	38
3.5.2. YSA modelleri.....	39
3.5.2.a. İleri beslemeli ağlar .....	39
3.5.2.b. Geri beslemeli ağlar.....	39
3.5.3. YSA'nın üstün ve zayıf yönleri.....	40
<b>4. ARAŞTIRMA BULGULARI ve TARTIŞMA.....</b>	<b>42</b>
4.1. Box-Jenkins ile Modelleme .....	43
4.2. Yapay Sinir Ağları ile Modelleme .....	58
4.3. Modellerin Karşılaştırılması.....	64
<b>5. SONUÇ ve ÖNERİLER.....</b>	<b>67</b>
KAYNAKLAR .....	69
ÖZGEÇMİŞ .....	73



## SİMGELER ve KISALTMALAR DİZİNİ

ACF	Oto Korelasyon Fonksiyonu (Auto Correlation Function)
AIC	Akaike Bilgi Kriteri (Akaike Information Criterion)
AR	Otoregresif (Auto Regressive)
ARMA	Otoregresif Hareketli Ortalamalar (Auto Regressive Moving Average)
ARIMA	Otoregresif Bütünleşik Hareketli Ortalamalar (Auto Regressive Integrated Moving Average)
ADF	Augmented Dickey Fuller Birim Kök Testi
FPE	En Son Kestirim Hatası (Final Prediction Error)
GSMH	Gayri Safi Milli Hasıla
IMF	Uluslararası Para Fonu (International Monetary Fund)
MA	Hareketli Ortalama (Moving Average)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MAPE	Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error)
MLP	Çok Katmanlı Algılayıcılar (Multi Layer Perceptrons)
MSE	Hata Kareler Ortalaması (Mean Squared Error)
MPE	Ortalama Yüzde Hata (Mean Percentage Error)
PACF	Kısmi Oto Korelasyon Fonksiyonu (Partial Auto Correlation Function)
SARIMA	Mevsimsel Otoregresif Bütünleşik Hareketli Ortalamalar (Seasonal Auto Regressive Integrated Moving Average)
SBC	Schwartz Bayes Kriteri (Schwartz Bayesian Criterion)
TCMB	Türkiye Cumhuriyet Merkez Bankası
TÜFE	Tüketici Fiyat Endeksi
TÜİK	Türkiye İstatistik Kurumu
VAR	Vektör Otoregresyon (Vector Autoregression)
Yİ-ÜFE	Yurtiçi Üretici Fiyat Endeksi
YSA	Yapay Sinir Ağları

## ŞEKİLLER DİZİNİ

Şekil 3.1. 1995-2009 yılları arasında Türkiye’de uygulanan para politikası stratejileri ve enflasyon oranları grafiği .....	15
Şekil 3.2. 2013-2014 yılları arasında Türkiye’de enflasyon oranları grafiği.....	15
Şekil 3.3. 2003-2013 yılları arasında Yurtiçi Üretici Fiyat Endeksi grafiği.....	19
Şekil 3.4. 2013-2014 yılları arasında Yurtiçi Üretici Fiyat Endeksi grafiği.....	20
Şekil 3.5. Basit bir yapay sinir ağı fonksiyonu .....	36
Şekil 4.1. 2004-2013 yılları arasında TÜFE serisinin zamana göre değişimi grafiği.....	44
Şekil 4.2. TÜFE serisinin korelogramı .....	45
Şekil 4.3. Birinci derece mevsimsel farkı alınmış TÜFE serisinin zaman grafiği .....	47
Şekil 4.4. Birinci derece mevsimsel farkı alınmış TÜFE serisinin korelogramı .....	48
Şekil 4.5. Birinci derece farkı alınmış STÜFE serisinin zamana göre dağılımı .....	50
Şekil 4.6. Birinci derece farkı alınmış STÜFE serisinin korelogramı .....	51
Şekil 4.7. ARIMA (2,1,1)(1,1,1) modeli gerçek ve teorik ACF ve PACF grafikleri .....	54
Şekil 4.8. ARIMA (2,1,1)(1,1,1) modeline ait hataların ACF ve PACF grafikleri .....	55
Şekil 4.9. ARIMA (2,1,1)(1,1,1) modeline ait kalıntıların korelogramı.....	56
Şekil 4.10. 2013 yılı TÜFE gerçekleşen değerler ile ARIMA modeli grafiği.....	58
Şekil 4.11. Modelde kullanılan yapay sinir ağı algoritması.....	58
Şekil 4.12. Yapay sinir ağı performans- ortalama hata kareleri karşılaştırması .....	60
Şekil 4.13. Hata histogramı grafiği .....	60
Şekil 4.14. Eğitim, deneme, test ve bütün aşamaların ortalama uygunluk grafikleri .....	61
Şekil 4.15. Ağın eğitilmesi sonucundaki zaman serisi tepkisi grafiği .....	62
Şekil 4.16. Hataların otokorelasyon grafiği .....	62
Şekil 4.17. 2013 yılı TÜFE gerçekleşen değerler ile YSA model grafiği .....	63
Şekil 4.18. 2013 yılında gerçekleşen TÜFE değerleri ile YSA ve ARIMA modelleri karşılaştırmalı grafiği .....	64
Şekil 4.19. 2014 yılında gerçekleşen TÜFE değerleri ile YSA ve ARIMA modelleri karşılaştırmalı grafiği .....	65

## ÇİZELGELER DİZİNİ

<b>Çizelge 3.1.</b> Ana harcama gruplarına göre tüketici fiyat endeksi .....	17
<b>Çizelge 3.2.</b> Yurt içi üretici fiyat endeksi .....	20
<b>Çizelge 3.3.</b> Durağan Box-Jenkins Modellerinde ACF ve PACF'lerin seyri .....	29
<b>Çizelge 4.1.</b> 2004-2013 yılları arasındaki aylık TÜFE verileri .....	42
<b>Çizelge 4.2.</b> TÜFE serisinin sabit terimli ADF birim kök testi sonucu.....	46
<b>Çizelge 4.3.</b> TÜFE serisinin sabit terimli ve trendli ADF birim kök testi sonucu.....	46
<b>Çizelge 4.4.</b> TÜFE serisinin sabit terimsiz ADF birim kök testi sonucu.....	46
<b>Çizelge 4.5.</b> Birinci derece mevsimsel farkı alınmış TÜFE serisinin sabit terimli ADF birim kök testi sonucu.....	49
<b>Çizelge 4.6.</b> Birinci derece mevsimsel farkı alınmış TÜFE serisinin sabit terimli ve trendli ADF birim kök testi sonucu .....	49
<b>Çizelge 4.7.</b> Birinci derece mevsimsel farkı alınmış TÜFE serisinin sabit terimsiz ADF birim kök testi sonucu.....	49
<b>Çizelge 4.8.</b> Birinci derece farkı alınmış STÜFE serisinin sabit terimli ADF birim kök testi sonucu .....	52
<b>Çizelge 4.9.</b> Birinci derece farkı alınmış STÜFE serisinin sabit terimli ve trendli ADF birim kök testi sonucu.....	52
<b>Çizelge 4.10.</b> Birinci derece farkı alınmış STÜFE serisinin sabit terimsiz ADF birim kök testi sonucu .....	52
<b>Çizelge 4.11.</b> TÜFE serisi ARIMA model tahmin sonucu .....	53
<b>Çizelge 4.12.</b> 2013 yılı aylık örneklem içi TÜFE gerçek ve öngörü değerleri.....	57
<b>Çizelge 4.13.</b> Yapay sinir ağının eğitim sırasında verdiği hata kareleri sonuçları .....	59
<b>Çizelge 4.14.</b> ARIMA ve YSA ile tahmin edilen TÜFE'nin doğruluk testleri.....	65

## 1. GİRİŞ

Enflasyon yalnızca firmalar ya da bireyler açısından değil, toplumun tamamı açısından da önem taşımaktadır. Enflasyonun maliyetini en kolay, karar alma aşamasındaki yatırımcılar ve tüketiciler görmektedir. Bireyleri yatırım ve tüketim açısından kararsızlığa iten yüksek enflasyon durumu, 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 ya da malzemenin yatırıma başlanmasından sonra alınacak olması durumunda, o dönemki maliyetlerinin ne olacağını hesaplamak kolay olmayacaktır. Aynı şekilde, yatırımın bitmesiyle tüketiciye ulaştırılacak mal veya hizmetin satış fiyatının ne olacağını belirlemek güçleşmektedir.

Enflasyonist ortamın yarattığı belirsizlik, tüketicilerin geleceğe ilişkin planlarını gözden geçirmelerine neden olmakta ve uzun vadeli kararlardan kaçınmalarına yol açmaktadır. Örneğin, fabrika yapmak, üretim yapmak veya kâra geçmek kısa sürede gerçekleşemez. Enflasyon, belirsizliği artırarak bireylerin sağlıklı kararlar almalarını engeller ve uzun vadeli plan yapmaktan kaçınmalarına sebep olur (TCMB 2015).

Endüstri Mühendisliği; ekonominin arz kısmında yer alan iyileştirmeleri inceler. Bunu yaparken; enerji kaynakları, ekipman, bilişim sistemleri, malzeme ve insan unsurlarının oluşturduğu entegre sistemlerin tasarımı ve verimli işleyişi ile uğraşır. Bu iyileştirme ve tasarım ilkeleri enerji, lojistik, finans ve bankacılık, üretim, sağlık gibi değişik sektörlerde uygulanabilir. Endüstri Mühendisleri sistem yaklaşımı, güçlü analitik, sayısal ve iletişim becerilerine sahip olmalıdır.

Endüstri Mühendisliği'nin birçok disiplinden faydalanması nedeniyle günümüzde önemli bir meslek dalıdır. Özellikle karar alıcılara verecekleri bilgilerin tutarlı ve faydalı olması, işletmelerin kârlılıklarını önemli ölçüde etkileyebilmektedir. Endüstri

Mühendisliđi alanında alıřanların finansal anlamda da karar vericilere destek olacak řekilde bir dūřünce yapısı geliřtirmeleri gerekmektedir. Geleceđe ynelik kararların alınması sırasında bazı sistematik yntemlerin kullanılması gerekmektedir. Son dnemlerde kullanılan pratik yntemlerden bazıları zaman serileri analizi ve yapay sinir ađlarıdır.

Zaman serileri geleceđe ynelik tahmin sistemlerinden son dnemde popler olarak kullanılan bir sistemdir. Bir zaman serisi belirli bir zaman aralıđına gre sıralanmıř gzlem deđerlerinden meydana gelir. Yani gzlem deđerleri birbirine bađımlıdır. Zaman serileri kısa dnem tahminlerinde uygun sonular vermektedir. Bir zaman serisinin en nemli noktası durađanlıđıdır. Bir zaman serisinin ortalaması, varyansı ve kovaryansı zaman iinde deđiřmiyorsa veya seri periyodik dalgalanmalardan arınmıřsa seri durađandır ve durađanlık sađlandıktan sonra model kurulur ve tahmin yapılır.

Geleceđe ynelik tahminler yapma ařamasında kullanılan Yapay Sinir Ađları (YSA) ile yapılan alıřmalarda; ađa sunulan verilerden đrenme, genelleme yapma gibi avantajları sayesinde ekonomik zaman serileri gibi dođrusal olmayan serilerin ngrsnde bařarılı ile kullanıldıđı grlmektedir.

Bu alıřmada Yıllık Yzde Deđerim yntemine gre hesaplanan Tketiciler Fiyat Endeksi (TFE) kullanılarak Zaman Serileri Analizi ve Yapay Sinir Ađları'na gre oluřturulan modeller yardımıyla modellerin dođruluđunun llmesi amalanmıřtır.

İkinci blmde Box-Jenkins Modelleri ve Yapay Sinir Ađları ile daha nce yapılan alıřmaların sonuları aıklanmıř ve sonular karřılařtırılmıřtır.

nc blmde enflasyon, enflasyonun nedenleri ve enflasyon hesaplama yntemleri hakkında bilgi verilmiř olup, Trkiye Cumhuriyet Merkez Bankası'nın (TCMB) enflasyon hedefinden sapmalar olması durumunda Hkmete yazmıř olduđu Aık Mektup hakkında aıklama yapılmıřtır. Aynı zamanda; Zaman Serileri Analizi ve

Yapay Sinir Ağları hakkında bilgi verilmiş olup, söz konusu metotların üstün ve zayıf yönleri arasındaki farklar belirtilmiştir.

Dördüncü bölümde, Türkiye İstatistik Kurumu (TÜİK) tarafından açıklanan Tüketici Fiyat Endeksi verileri esas alınarak Box-Jenkins yöntemi ve Yapay Sinir Ağları yöntemi ile tahmin modelleri araştırılmıştır. Tahmin yöntemleri oluşturulduktan sonra hangi yöntemin daha iyi sonuç verdiği karşılaştırılmıştır.

Çalışmanın beşinci bölümünde, çalışmada ulaşılan sonuçlar özetlenmiş ve bu çalışmanın sonrasında yapılabilecek çalışmalara ilişkin önerilere yer verilmiştir.

Çalışmada sunulan görüşler tamamıyla yazara ait olup, doğrudan Türkiye Cumhuriyet Merkez Bankası ve/veya çalışanlarının görüşlerini yansıtmaz.

## 2. KAYNAK ÖZETLERİ

Zaman serileri ve yapay sinir ağıları ile ilgili literatürde birçok çalışma bulunmaktadır. Finans, istatistik ve ekonometri alanlarında yoğunlaşan çalışmalar; borsa endeksi tahmininden, döviz kuru oranlarına kadar birçok alana yayılmaktadır. Bu bölümde yapay sinir ağıları ve zaman serileri kullanılarak yapılan çalışmalara yer verilecektir.

Zaman serisi analizinin amacı genellikle iki noktada toplanır: Birincisi, gözlenen serinin artısını veren stokastik (tahmini) mekanizmayı modellemek ve anlamak, ikincisi ise serinin geçmişine bakarak serinin tahmini veya kestirimidir.

Sharda and Patil (1990), 75 zaman serisi kullanarak YSA ve Otoresif Bütünleşik Hareketli Ortalama (ARIMA) metotlarını karşılaştırmışlar ve çalışmaları sonucunda üç katmanlı yapıya sahip YSA'nın ARIMA metodu kadar iyi öngörüler verdiği sonucu elde edilmiştir.

Tang *et al.* (1991), aylık iş verilerini kullanarak yaptıkları çalışmada, uzun dönemli serilerde YSA ve ARIMA yaklaşık olarak benzer sonuçlar verirken, kısa dönemli serilerde YSA'nın daha iyi sonuçlar verdiği görülmüştür.

Caire *et al.* (1992), günlük elektrik tüketim verilerini kullanarak YSA ve ARIMA öngörü sonuçlarını karşılaştırmışlardır. Çalışmanın sonucuna göre YSA, ARIMA'dan daha iyi sonuçlar verirken, uzun dönemli öngöründe elde edilen sonuçların çok daha iyi olduğu görülmüştür.

Refenes (1993), saatlik döviz kuru zaman serisi verileri ile yaptığı çalışmasında, YSA'nın, üssel düzeltme ve ARIMA modellerinden daha iyi öngörü değerleri verdiği sonucunu elde etmiştir.

Srinivasan *et al.* (1994), kısa dönem elektrik tüketim tahminlemede YSA, doğrusal regresyon ve ARIMA modellerini kullanmıştır. Analizin sonucuna göre YSA, doğrusal regresyon ve ARIMA metotlarına göre daha iyi tahmin performansına sahiptir.

Portugal (1995), aylık toplam sanayi üretimi verileri ile ARIMA ve YSA'nın iktisadi öngörü performanslarını karşılaştırmıştır. Sonuçlara göre YSA'nın, ARIMA modellerinden daha iyi öngörü sonuçları verdiğini göstermektedir.

Callen *et al.* (1996) üç aylık verilerin kullanıldığı çalışmalarında, doğrusal olmayan verilerin öngörüsünde YSA'nın doğrusal modeller kadar iyi öngörü performansı göstermediğini ifade etmişlerdir.

Maier and Dandy (1996), ARIMA modellerinin kısa dönem öngörüler için, YSA'nın ise uzun dönem öngörüler için uygun olabileceğini önermişlerdir.

Swanson and White (1997), ABD ekonomisine ait mevsimsel olarak düzeltilmiş dokuz farklı zaman serisini kullanarak yaptıkları çalışmalarında, YSA'nın ARIMA gibi doğrusal modellerden daha iyi öngörü performansı gösterdiği sonucunu elde etmişlerdir.

Faraway and Chatfield (1998), havayolları satış verileri ile YSA, ARIMA ve Holt-Winters metotları ile yaptıkları öngörü çalışmasında, YSA'ya ait öngörülerin diğer yöntemler ile elde edilen öngörülere göre daha kötü olduğu sonucuna ulaşmışlardır.

Al-Saba and El-Amin'in (1999), elektrik talebi zaman serilerinin kullanıldığı çalışmalarına ait sonuçlar, YSA'nın; AR, ARMA ve ARIMA yöntemlerinden daha iyi sonuçlar verdiğine işaret etmektedir.

Moshiri and Cameron (2000), geri beslemeli bir YSA'yı ARIMA, Vektör Otoregresyon (VAR) ve Bayezyan VAR modelleri ile karşılaştırdığı çalışmalarında, YSA'nın enflasyon öngörüsünde diğer klasik modeller kadar iyi öngörü performansı sergilediği



ve bazı durumlarda klasik modellerden daha iyi öngörü performansına sahip olduğunu ifade etmişlerdir.

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

Montanes *et al.* (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 and Sarker (2003), Avusturya Doları'na ilişkin altı farklı çapraz kurun yapay sinir ağları modelleri ve ARIMA kullanılarak tahmin edildiği bir çalışma yapmışlardır. Çalışma sonucunda YSA ile yapılan tahminlerin ARIMA ile yapılan tahminlere göre daha iyi sonuç verdiğini belirlemişlerdir.

Kihoro *et al.* (2004), aylık mevsimsel zaman serilerinin öngörüsünde YSA'nın ARIMA modellerine nazaran daha iyi performans gösterdiğini, ama sonuçların kullanılan verilere göre değişebileceğini ifade etmişlerdir.

Binner *et al.* (2005), Gayri Safi Milli Hasıla (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.

Türe and Kurt (2006), hepatit A virüsü vakalarının öngörüsü için çok katmanlı, radyal tabanlı ve zaman gecikmeli olmak üzere üç farklı YSA ile ARIMA modellerini kullanmıştır. 13 yıllık zaman serilerinin kullanıldığı analiz sonucunda, çok katmanlı YSA'nın diğer yöntemlerden daha iyi öngörü performansına sahip olduğu görülmektedir.

Zou *et al.* (2007); ARIMA, YSA ve bu iki modelin birleşimi ile elde ettikleri modeller ile Çin ekonomisindeki buğday fiyatlarının öngörüsünü yaparak modellerin öngörü performanslarını karşılaştırmışlar ve çalışmada kullanılan modeller arasında YSA'nın en iyi öngörü performansına sahip olduğunu belirtmişlerdir.

Abdelmouez *et al.* (2007), Amerika hisse senedi piyasasından derlenen 3 429 gözlemden oluşan veri setini kullanarak ARIMA, çoklu regresyon ve YSA yöntemlerini karşılaştırmışlar ve YSA'nın çok daha iyi öngörü sonuçları verdiğini gözlemlemişlerdir.

İnsel and Süalp (2008), 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 Otoregresif Hareketli Ortalama (ARMA) ve YSA modellerinin öngörü performansını karşılaştırmışlardır. Çalışmada yapılan öngörüler sonucunda, enflasyon oranı, döviz kuru ve faiz oranı için YSA ve reel GSMH için ARMA modelinin daha iyi öngörü değerleri verdiği anlaşılmaktadır.

Giovanis (2009), Amerika Birleşik Devletleri'nin GSMH ve işsizlik oranını öngördüğü çalışmasında ARIMA modelleri ve yaygın olarak kullanılan YSA kullanmıştır. Çalışma sonucunda elde edilen sonuçlar söz konusu verilerin öngörüsünde YSA'nın, ARIMA modellerinden çok daha iyi öngörü değerleri verdiğini göstermektedir.

Hamzaçebi *et al.* (2009), yaptıkları öngörü çalışmasında YSA, ARIMA ve kısmi adaptif öngörü tekniklerini karşılaştırmışlardır. Çalışmanın sonuçları YSA'nın diğer metotlardan daha iyi öngörü performansına sahip olduğuna işaret etmektedir.

Bugüne kadar yapılan çalışmalar incelendiğinde, kısa dönemli zaman serileri verileri ele alınarak tahmin yapıldığında yapay sinir ağları ve Box-Jenkins modelleri ile yapılan analizlerin benzer sonuçlara ulaştığı gözlenmekle birlikte serinin zaman içerisinde ne kadar dalgalandığı önem kazanmaktadır. Bununla birlikte uzun dönemli zaman serileri için yapay sinir ağları daha iyi performans göstermektedir.

### 3. MATERYAL ve YÖNTEM

Box-Jenkins yöntemi, özellikle doğrusal olan zaman serilerinin tahminlenmesinde en bilinen ve en çok kullanılan metotlardan birisidir. Durağan ve doğrusal süreçlerde veya durağan olmayan fakat bazı istatistiksel tekniklerle durağanlaştırılabilen serilerde Box-Jenkins yöntemi başarıyla uygulanabilir. Bununla beraber birçok zaman serisi doğrusal ilişki ile beraber doğrusal olmayan ilişki de içerir. Doğrusal olmayan ilişkiyi modelleyebilecek farklı tekniklere ihtiyaç duyulmaktadır. Yapay Sinir Ağları (YSA), yapısında bulunan aktivasyon fonksiyonunun özelliğine bağlı olarak hem doğrusal hem de doğrusal olmayan ilişkileri modelleyebilir. Bu nedenle son yıllarda zaman serilerinin modellemesinde kullanılan önemli yöntemlerden biri haline gelmiştir.

Bu çalışmanın ana amacı, enflasyon verileri ile tahmin yaparken sıklıkla kullanılan ARIMA ve Yapay Sinir Ağı modellerinden yararlanılarak, 2003:1 – 2013:12 döneminin baz alındığı Tüketici Fiyat Endeksi (TÜFE) serisine bağlı olarak TÜFE serisinin tahmininin yapılması ve en başarılı sonucu veren model tipinin belirlenmesidir. Bu çalışma; hem TÜFE'nin yapısal anlamda değişikliğe uğradığı 2003 yılından başlaması ve veri setinin 2013 yılsonuna kadar devam etmesi hem de kısa dönemli veri setinde ARIMA ve YSA modelleri arasındaki farkı gösterecek olması açısından literatürdeki diğer çalışmalardan ayrılmaktadır. Takip eden kısımlarda enflasyondan ve öneminden, nedenlerinden, hesaplama yöntemlerinden ve Türkiye Cumhuriyet Merkez Bankası'nın (TCMB) enflasyonla ilişkisinden bahsedilecektir. Ayrıca enflasyon tahmininde kullanılacak yöntemler tanıtılacaktır.

#### 3.1. Enflasyon ve Önemi

Ekonominin olumsuz yönde etkilenmesinin nedenlerinden birisi enflasyon belirsizliğidir (Özer ve Türkyılmaz 2005). Enflasyona yönelik beklentilerde aynı şekilde enflasyonu yönlendiren bir unsur olduğundan, politika yapıcıları beklentileri yönetme eğilimine girmişlerdir (Lyziak 2003).

Dünyanın önde gelen ekonomistleri ve iktisat profesörleri, bir ülkede beklenen makul enflasyon oranını %2 olarak tanımlamışlardır. Bu nedenle, birçok merkez bankası stratejilerini %2'lik bir enflasyon oranı olarak belirlemektedir. Genellikle, hangi ekonomik yapı içinde olursa olsun, enflasyon oranının %2'nin çok altında veya çok üzerinde olmasının, ilgili ekonomi için sorun olabileceği yönündedir. Para politikalarını yönlendiren merkez bankalarının da ulaşmak istedikleri enflasyon oranı %2 civarında bir fiyat artışının gerçekleşmesidir.

Ekonomik faaliyetlerin devamı için önemli olan; bir ekonomideki insanların içinde buldukları ekonomiye güvenidir. Güvenin sağlanması için fiyat istikrarı da önemli başlıklardan birisidir. Merkez bankalarının öncelikle görevi olan fiyat istikrarının sağlanması ile, üretim ve tüketimin devamlılığı sağlanmaktadır. Ekonomi dinamik bir seyir izlediğinden sürekli değişiklikler görülebilir, fakat yine de asıl amaç değişikliklerin minimum düzeyde tutulması, sert dalgalanmalara izin verilmemesidir. Öngörülebilir ekonomik şartlara göre ayarlamalar yapılması gerekmektedir. Merkez bankaları enflasyon oranı konusunda geleceğe yönelik açıklamalar yaparak beklenti yönetimini de planlamaktadır. Bu noktada merkez bankaları yetkililerinin açıklamaları ile öngörüler oluşturulduğunda daha başarılı tahminlere ulaşılabilir. Böylece merkez bankalarının ve ülkenin kredibilitesini ve saygınlığını artıracaktır.

### **3.1.1. Enflasyon**

Enflasyon, fiyatların genel seviyesindeki sürekli artış olarak tanımlanmaktadır (Samuelson 1992).

Enflasyon ile fiyatların yükselmesi, tüketicilerin taleplerini kısmasına, kısılan talep üretimin düşmesine, düşük üretim hacmi istihdamın azalmasına, istihdamın azalması işsizliğin artmasına ve kişilerin gelirlerinin düşmesine sebep olması sebebiyle ekonomide bir hastalık haline gelmiştir.

Enflasyon kavramı, fiyatlar genel düzeyindeki sürekli artışı ifade etmekte olup, toplam talep ile toplam arz farklılıklarına bağlı olarak değişmektedir. Enflasyonun, toplam arz ve toplam talep arasındaki fark tarafından belirlendiğini ifade etmek mümkündür (Özatay 2011).

Enflasyon, bir ülkedeki toplam talep miktarının, toplam arzdan yüksek olduğunda meydana geldiğinden, enflasyonun düşürülmesi için, toplam talebin düşürülmesine benzer şekilde toplam arzı yükseltici hamlelerinde uygun olabileceği düşünülmektedir. Halbuki her arz, kendi talebini oluşturur düşüncesi ile, toplam arz miktarının yükselmesi, enflasyonu oluşturan talep fazlasının kaybolmasına imkan sağlamamakta ve böylece enflasyonun düşürülmesine yönelik, daraltıcı politikalara başvurulması gerekmektedir (Aren 2007).

Enflasyon, normal bir tüketicinin bir yıl içinde kullandığı bütün mal ve hizmetlerdeki fiyat değişikliklerini içermektedir. Diğer bir ifadeyle, bir ülkede, enflasyon oranı düşerken bazı mal ve hizmetlerin fiyatlarında artış yaşanabilmekte, benzer şekilde enflasyon oranı artarken bazı malların fiyatı düşebilmektedir. Diğer taraftan fiyatlarda yaşanan yükselişin enflasyon olarak tanımlanabilmesi için yalnızca dönemlik değil, sürekli olması gerekmektedir.

Enflasyon, genel anlamda geçmiş yılın aynı dönemine göre (yıllık) yüzdesel değişim olarak ifade edilir. Hizmet ve mal sepetindeki malzemelerin ortalama fiyatlarında 12 ay süresince görülen değişime bakılarak hesaplanmaktadır. Hizmet ve mal sepeti, enflasyonun hesaplanabilmesi için incelenen dönem süresince fiyatları gözlenen hizmet ve mal kalemlerinin toplamına verilen isimdir. İlgili sepette bulunan hizmet ve malların ağırlıkları, hane halkı bütçe anketine konu olan örneklemin ilgili oniki ay süresince yaptığı harcamalar dikkate alınarak belirlenmektedir.

Ekonomistler enflasyonun nedenlerini genellikle talep ya da arz faktörlerine bağlamaktadır. Arz yönlü şoklardan kaynaklanan enflasyonist etkileri incelemek, teknoloji ekonomisi, uzun dönem büyüme teorisi ve döviz kurunu belirleme teorisi ile

yakından ilgilidir. Talep yönlü şokların temel kaynağı genellikle sürekli bütçe açıklarıdır. Çünkü bunlar, ithal edilen hammaddelerle ilgili stagflasyonist nispi fiyat şokları, negatif verimlilik şokları veya milli paranın yanı sıra fiyatlar, ücret/fiyatların rijitliği, ekonomideki beklentiler ve olası indeksleme tecrübeleri tarafından etkilenebilir. Dolayısıyla bu atalet faktörleri enflasyonun açıklayıcı faktörlerinin bir üçüncü grubu olarak düşünülmelidir. Enflasyonun açıklayıcı faktörlerinin sonuncusu ise, politik süreç veya kurumların rolü olarak düşünülmelidir. Kısaca, arz şokları, talep şokları, atalet faktörleri ve politik süreç gibi dört grup faktörün karışık ve dinamik etkileşimi herhangi bir ekonomideki enflasyonu açıklar (Kibritçioğlu 2001).

### **3.1.2. Enflasyon çeşitleri**

İktisat bilimindeki araştırmalarda enflasyonun dört temel türüne vurgu yapılmaktadır. Bunlar; talep enflasyonu, maliyet enflasyonu, para arzı ve enflasyon beklentileridir.

#### **3.1.2.a. Talep enflasyonu**

Talep enflasyonu genellikle, işsizlik oranında azalma gözleendiği durumlarda veya ekonomi toparlanma sürecine girdiğinde meydana gelmektedir. Büyüme sürecindeki bir ekonomide, tüketim yapanlar geleceğe güvenle baktıklarından harcamalarında artış gözlenmektedir. Söz konusu dönemde talep artışı meydana gelmekte, buna rağmen üreticilerin aynı hızda üretim yapmamaları durumunda talep fazlasına dönüşebilmekte ve fiyat artışına neden olabilmektedir. Diğer bir deyişle, hizmet veya malın arz kısmında artış hızı, talebin artış hızını yakalayamadığı durumda fiyat artışına sebep olmaktadır.

Bir ekonomide özel kişilerin yaptıkları tüketim ve yatırım harcamaları ile kamu harcamalarının ve ihracat ithalat farkından oluşan net dış alem harcamalarının toplamı mevcut mal ve hizmet arzını aşıyorsa, ekonomide bir toplam talep fazlası bulunuyor demektir. Bu talep fazlası, birbirine bağlı iki farklı sonuç doğurabilir. Birincisi üretim artışlarıdır. İkincisi ise fiyatlar genel seviyesinde yükselmedir.

Kamu harcamalarının artırılması ya da merkez bankalarının parasal genişlemeye gitmesi gibi genişletici politikaların uygulanması, toplam talebin geçici olarak genişletilmesi ve ekonomik büyüme ile sonuçlanabilmektedir. Bununla birlikte artan talebin ekonominin üretim kapasitesini aştığı durumlarda, kaynaklar üzerinde baskı oluşturmakta, bu durum da talep enflasyonuna neden olmaktadır. Söz konusu durumda politika belirleyiciler, enflasyon ile ekonomik büyüme arasındaki dengeyi sağlamakta zorlanabilmektedir.

### **3.1.2.b. Maliyet enflasyonu**

Maliyet enflasyonu, bir ekonomide emtia fiyatlarının yükselmesi veya doğal afetler gibi nedenlerle üretim maliyetlerinde artış yaşanması sonucunda toplam arzın azalması ve bunu takiben fiyatlar genel seviyesinin yükselmesidir. Bununla beraber, devlet tarafından yapılan düzenlemeler ve vergilendirmeler de maliyet enflasyonuna neden olabilmektedir. Maliyet enflasyonu kendi içinde ücret enflasyonu ve kâr enflasyonu olarak sınıflandırılmaktadır. Buna göre ücret enflasyonu, ücretlerde meydana gelen artışa rağmen verimliliğin paralel bir şekilde artmaması nedeniyle üretim maliyetlerinin yükselmesidir.

### **3.1.2.c. Para arzı enflasyonu**

Belirli bir dönemde, belirli bir ekonomide dolaşımda bulunan toplam para miktarı para arzı olarak isimlendirilmektedir. Uzun dönemde enflasyon oranı, para tabanı tarafından belirlendiğinden ekonomideki para arzı fazlası enflasyonu, para miktarı ise fiyatlar genel seviyesini şekillendirmektedir. Tüketim ve yatırım harcamalarını artırarak fiyatlar üzerinde yukarı yönlü bir baskının oluşmasına para arzının artması yol açmaktadır.

### **3.1.2.d. Enflasyon beklentisi**

Enflasyonun oluşmasında kilit rol oynayan unsurlardan biri de enflasyon beklentileridir. Üreticilerin ve tüketicilerin ileride fiyatların yükseleceğini beklemeleri durumunda,

beklentiler geleceğe yönelik ücret talepleri aracılığıyla mal ve hizmet fiyatlarını yükseltmektedir. Kira artırımını, maaş zammını ve ticari alım-satım sözleşmelerine konu olan ileriye dönük fiyat belirleme gibi talepler söz konusu duruma örnek olarak gösterilebilir. Gelecekteki enflasyonu, beklentiler de belirleyebilmektedir. Bu durum, enflasyon beklentilerinin kendini doğrulaması olarak isimlendirilmektedir. Diğer bir ifadeyle ekonomik birimler, ileriye yönelik enflasyon beklentilerini yakın zamanda yaşanan enflasyon gerçekleştirmelerine göre belirlemeye devam ettikçe, enflasyon oranındaki artış geçmişe benzer bir seyir izleyecektir. Bu süreç enflasyon ataletine sebep olmakta ve bu yüzden merkez bankaları enflasyonla mücadele ederken aynı zamanda enflasyon beklentilerini de düşürmeye odaklanmaktadır.

### **3.2. Türkiye Cumhuriyet Merkez Bankası ve Türkiye'de Enflasyon**

Günümüzde bütün merkez bankaları enflasyonu istikrarlı bir yapıya dönüştürmeye, kontrol altında tutmaya diğer bir ifade ile fiyat istikrarını sağlamaya yönelik çalışmalar yapmaktadır. Vatandaşların tüketim veya tasarruf kararlarında dikkate almayacakları oranda düşük bir enflasyon oranını anlatan fiyat istikrarının sağlanmamasının bir ülkenin ekonomisine, sosyal ve siyasi yapısına verdiği zararın büyüklüğü, ülkemizde ve diğer ülkelerde yaşanan krizler sırasında açık bir biçimde görülmektedir.

Türkiye Cumhuriyeti'nin kurulduğu dönemlerde, para politikalarını yöneten ve bir emisyon bankası olarak faaliyet gösteren bir merkez bankası bulunmaktaydı. Ekonomik bağımsızlıkla güçlendirilmek istenen siyasi bağımsızlık neticesinde para politikasında bağımsız biçimde yönetilmek istenmesi sonucu Türkiye'de de bir merkez bankası kurulması yönünde çalışmalara başlanmıştır. 11 Haziran 1930 tarihinde 1715 sayılı Türkiye Cumhuriyet Merkez Bankası Kanunu kabul edilmiş, Türkiye Cumhuriyet Merkez Bankası (TCMB) 3 Ekim 1931 tarihinde faaliyetlerine başlamıştır.


Türkiye'de enflasyon verisinin geçmiş hareketlerine dair kısa bir özet bilgi vermek gerekirse; 1939'dan bugüne enflasyonla birlikte yaşanmaktadır. Belli süreçlerde sürünen enflasyon terimine benzer bir görünüm olmakla birlikte, genellikle basamaklı




enflasyona uygun olan bir görüntü çizmiştir. İlgili zamanlarda, yüksek bir seyir izleyen enflasyon iki hanelerde görülmesine rağmen, hiperenflasyona geçilmemiştir (Eğilmez ve Kumcu 2005). 1960'lı yılların sonlarını takiben yükselişe geçen enflasyon, 1995'te yıllık enflasyonun yüzde 80-85 düzeyinde atalet kazandığı bir sürece dek, sürekli artış eğilimi göstermiştir. Şekil 3.1'de görüleceği üzere enflasyondaki en önemli düşüş, 2001 yılını takiben olmuştur.

TCMB, para politikası çerçevesinde 1995-1999 yılları arasında döviz kurunun hareketlerini inceleyerek artış hızını kontrol etmeye çalışmıştır. Para politikasının başarısını etkileyen en önemli faktörlerden biri maliye politikaları olmuştur. Kamu yatırımlarının hızlandırıldığı, ekonomik büyümenin desteklendiği ve kamu kesimi borçlanmasının artırıldığı bu dönemde, TCMB tarafından sürekli devam eden bütçe açıklarını karşılamak için Hazine'ye kısa vadeli avanslar kullanılmıştır. "Enflasyonu Düşürme Programı" 2000 yılında uygulanmaya başlanmıştır. Programın başarıya ulaşamamasındaki en büyük etken yapısal reformların yapılamaması olmuştur. Bankacılık reformlarının yapılamaması ve özelleştirme hedeflerine ulaşamaması nedeniyle yaşanan sermaye çıkışlarından dolayı likidite sıkışıklığı yaşanmış, Kasım 2000'de Uluslararası Para Fonu'ndan (IMF) alınan ek yardımla karşılanmıştır. TCMB'nin önlemlerine rağmen likidite sıkışıklığı aşılamamış, bu nedenle döviz kuru hedeflemesi amacına tam olarak ulaşamamıştır. Bunun sonucunda döviz kuru 22 Şubat 2001'de dalgalanmaya bırakılmış ve Türk Lirası önemli ölçüde değer kaybetmiş ve enflasyon %73,2'ye yükselmiştir. Kara ve Orak (2008), 2002 yılında geçilen örtülü enflasyon hedeflemesini "enflasyon hedeflemesi rejimini resmi olarak ilan etmeksizin sayısal enflasyon hedeflerinin açıklanması ve bu hedeflere ulaşmak için TCMB'nin politika araçlarını kullanması" olarak tanımlamaktadır. Bununla birlikte, enflasyon hedeflemesine geçiş süresince, TCMB kısa dönem ve orta dönem enflasyon tahmin modelleri oluşturmuş ama kamuoyu ile paylaşma yönelimine girmemiştir. Bunun nedeni ise ülkedeki yapısal dönüşümün iktisadi değişkenler arasındaki ilişkiyi değiştirerek ekonometrik modellerin tahmin gücünü zayıflatması olarak belirtmiştir. TCMB 2002 ve 2005 yılları arasındaki mali disiplin ve döviz kuru geçişkenliğinde gözlenen olumlu değişimlerin ve iletişim politikaları ile şeffaflığın artmasını takiben

2006 yılında açık enflasyon hedeflemesine geçildiğini belirtmiştir. Açık enflasyon hedeflemesi ile enflasyon tahminleri kamuoyu ile paylaşılmış ve hesap verilebilirlik devreye alınmıştır. Bu çerçevede hedeften 2 puanlık sapma halinde, sapmanın nedenlerini ve önlemleri Hükümete ve kamuoyuna bir rapor ile açıklayacağını duyurmuştur.



**Şekil 3.1.** 1995-2009 yılları arasında Türkiye’de uygulanan para politikası stratejileri ve enflasyon oranları (TCMB 2015; TÜİK 2015)



**Şekil 3.2.** 2013 ve 2014 yıllarında Türkiye’de enflasyon grafiği (TÜİK 2015)

### 3.2.1. Açık mektup

TCMB Kanunu'nun 42. maddesi gereğince, enflasyonun hedeften önemli ölçüde sapması durumunda TCMB'nin söz konusu sapmanın sebeplerini ve alınması gereken önlemleri Hükümete yazılı olarak bildirmesi ve kamuoyu ile paylaşması gerekmektedir. 25 Aralık 2012 tarihinde yayımlanan "2013 Yılında Para ve Kur Politikası" başlıklı temel politika metninde belirtildiği üzere, 2013 yılı için enflasyon hedefi Hükümetle mutabakata varılarak yüzde 5 olarak belirlenmiştir. Yine aynı metinde, yılsonunda enflasyonun hedeften önemli ölçüde (her iki yönde de 2 puandan daha fazla) sapması halinde Hükümete bir açık mektup yazılacağı belirtilmiştir. Şekil 3.2'de görüleceği üzere 2013 yılı sonunda enflasyon yüzde 7,40 seviyesine çıkarak hedefin net olarak üzerinde oluşmuştur. Bu nedenle TCMB tarafından Hükümete enflasyonun hedeften sapmasının sebeplerini ve hedefe ulaşmak için alınan ve alınması gereken önlemleri açıkladığı bir "Açık Mektup" yazmıştır.

28 Ocak 2014 tarihli Hükümet'e gönderilen Açık Mektup'ta; enflasyonun 2013 yılında hedefin net olarak üzerinde gerçekleşmesinde Türk Lirası'ndaki değer kaybı ile gıda fiyatlarının etkili olduğu belirtilmektedir. TCMB enflasyon karşısındaki temkinli duruşunu güçlendirmiş ve likidite politikasını sıkılaştırmıştır. 2014 yılının ikinci yarısında itibaren enflasyonun kademeli olarak düşmesi beklendiği, TCMB'nin fiyat istikrarı yolunda elde edilen kazanımların kalıcı olması için gereken tedbirleri almaya devam edeceği ve enflasyon görünümüne ilişkin gelişmeleri yakından takip edeceği belirtilmektedir.

### 3.3. Enflasyon Hesaplama Yöntemleri

Belirli bir ürünün fiyatındaki değişimler büyük resmi göstermede yetersiz olacağından birden fazla fiyatı belirli düzen içerisinde toplayan endeksler genel olarak kullanılmaktadır (Başol 1994). Söz konusu endeksler, geçmiş dönemlerin yorumunu yapabilmek, ekonomilerin durumunu izlemek, ileriye ait öngörülerini yapabilmek ve uygulanan politikaların başarısını saptamak için kullanılan araçların en önemlilerinden

birisidir. Enflasyon oranı, belirli bir mal sepetinin cari yıl fiyatıyla aynı sepetin temel bir yıl fiyatı arasındaki oranının 100 ile çarpımına eşit olan fiyat endeksindeki değişme oranı ile ölçülür. Ülkemizde en çok kullanılan fiyat endeksleri Tüketici Fiyat Endeksi ve Yurtiçi Üretici Fiyat Endeksidir.

### 3.3.1. Tüketici fiyat endeksi (TÜFE)

Söz konusu endeks tüketim alışkanlığına sahip olan birimlerin satın aldıkları mal veya hizmet fiyatlarındaki farklılığı değerlendiren endekstir. Ölçümde kullanılan endeks hesaplanırken, tüketicilerin kullandığı yiyecek, giyecek, dayanıklı tüketim malı, ulaştırma gibi mal veya hizmetler kullanılır. Bu durumda endeks, Tüketici Fiyat Endeksi (TÜFE) adını alır. Söz konusu endeks, tüketim için alınan belirli hizmet ve mal sepetindeki değişimleri yani belirli bir süredeki değişiklikleri hesaplamaktadır. Bu amaca yönelik olarak hane halkları, kurumsal nüfus ve yabancı ziyaretçiler tarafından yurtiçinde yapılan bütün parasal harcamalar hesaplamaya alınmaktadır.

Aşağıda verilen Çizelge 3.1’de görüleceği üzere Türkiye’de enflasyonun hesaplanması, 12 temel konu başlığı altında, 44 alt grup ile yapılmaktadır. Endekste 432 madde hesaplamaya konu edilmektedir.

**Çizelge 3.1.** Ana harcama gruplarına göre tüketici fiyat endeksi, Nisan 2014

	<b>Harcama Grubu Ağırlıkları</b>	<b>Önceki aya göre değişim</b>	<b>Önceki Aralık ayına göre değişim</b>	<b>Önceki yılın aynı ayına göre değişim</b>	<b>12 aylık ortalamaya göre değişim</b>
<b>Türkiye</b>	<b>100,00</b>	<b>1,34</b>	<b>4,96</b>	<b>9,38</b>	<b>7,97</b>
Ev eşyası	7,52	1,57	5,46	8,84	5,77
Eğlence ve kültür	3,36	0,09	2,68	7,31	4,55

**Çizelge 3.1.** (devam)

Alkollü içecekler	5,29	0,02	7,48	3,13	<b>10,58</b>
Eğitim	2,26	0,97	1,43	10,37	8,74
Lokanta ve oteller	6,58	0,76	5,33	12,48	10,12
Sağlık	2,44	0,93	4,48	7,66	4,33
Ulaştırma	15,54	-0,54	5,20	<b>13,84</b>	9,85
Giyim ve ayakkabı	7,17	<b>13,10</b>	1,69	7,63	6,12
Haberleşme	4,70	0,13	-0,01	0,86	3,22
Çeşitli mal ve hizmetler	4,28	-0,10	4,74	6,11	3,99
Gıda ve alkolsüz içecekler	<b>24,45</b>	1,42	<b>9,02</b>	13,15	10,54
Konut	16,41	0,24	1,42	4,92	5,68


Ağırlıkların kaynağını tüm sosyo-ekonomik gruplardan yaklaşık yıllık 13 250 hane halkı ile yapılan Hane Halkı Bütçe Anketi, kurumsal nüfus anketi, yabancı uyrukluların Türkiye’de yapmış oldukları harcamalar için turizm anketi ve idari kayıtlardan elde edilen harcama ve ciro bilgileri dikkate alınmaktadır. 2003=100 temel yıllık TÜFE’de yurtiçinde mal ve hizmet tüketmek amacıyla yapılan, tüm nihai parasal tüketim harcamaları esas alınmaktadır. Endekste tüm il merkezlerinden ve 74 ilçeden fiyat toplanıp değerlendirilmektedir. Ayda 27 432 işyerinden 389 944 fiyat derlenmekte ve 4 265 kiracı endeks kapsamında takip edilmektedir.

Çizelge 3.1’de belirtilen Nisan 2014 Tüketici Fiyat Endeksine göre “Gıda ve Alkolsüz İçecekler” ana konu başlığı %24,45 ile en yüksek harcama grubunu göstermektedir. 2014 Nisan ayındaki açıklanan verilere göre bir önceki aya göre en yüksek değişim oranı “Giyim ve Ayakkabı” ana kaleminde görülmektedir. Çizelgeye göre 2013 yılı Aralık ayına göre en yüksek değişim yine “Gıda ve Alkolsüz İçecekler” ana konu başlığında görülmektedir. Bununla birlikte 2013 yılı Nisan ayına göre 2014 yılı Nisan ayında en yüksek değişim “Ulaştırma” kaleminde ortaya çıkmaktadır. 12 aylık


değişimlere göre bakıldığında ise en yüksek artış “Alkollü İçecekler” ana konu başlığında tespit edilmiştir.

### 3.3.2. Yurtiçi üretici fiyat endeksi (Yİ-ÜFE)

Yİ-ÜFE, belirli bir referans döneminde ülke ekonomisinde üretimi yapılan ve yurt içine satışa konu olan ürünlerin, üretici fiyatlarını zaman içinde karşılaştırarak fiyat değişikliklerini ölçen fiyat endeksidir. Bu tanıma göre ÜFE endeksi; imalat sanayi, madencilik ve enerji sektörlerindeki üretilen malların fiyatlarındaki değişim oranlarını hesaplamaktadır. Şekil 3.3’de Yİ-ÜFE fiyat endeksi görülmektedir. Bu grafik her ne kadar yurtiçi fiyat endeksini gösteren bir grafik olsa da, ülkemizin enerjide dışa bağımlı bir ülke olması nedeniyle grafiği yurtdışı elektrik ve gaz fiyatlarındaki değişim olarak da yorumlamak mümkündür. 2013 ve 2014 yılları arasındaki Yİ-ÜFE fiyat endeksi grafiği ise Şekil 3.4’te görülmektedir.



Şekil 3.3. 2003-2013 yıllarında yurtiçi üretici fiyat endeksi grafiği (TCMB 2015)



Şekil 3.4. 2013-2014 yılları arasında yurtiçi üretici fiyat endeksi grafiği (TÜİK 2015)

Çizelge 3.2. Yurt içi üretici fiyat endeksi, Nisan 2014

05. Kömür ve Linyit	Nisan 2014	3.92
06. Ham Petrol ve Doğal Gaz	Nisan 2014	18.49
07. Metal Cevherleri	Nisan 2014	7.12
08. Diğer Madencilik ve Taş Ocakçılığı Ürünleri	Nisan 2014	20.85
10. Gıda Ürünleri	Nisan 2014	15.45
11. İçecekler	Nisan 2014	0
12. Tütün Ürünleri	Nisan 2014	1.84
13. Tekstil	Nisan 2014	13.82
14. Giyim Eşyası	Nisan 2014	17.48
15. Deri ve İlgili Ürünler	Nisan 2014	13.45
16. Kereste, Ağaç Ürünleri ve Mantar Ürünleri Mobilya Hariç; Hasır ve Örme Malzemesinden Saz, Saman vb. Ürünler	Nisan 2014	7.02
17. Kağıt ve Kağıt Ürünleri	Nisan 2014	12.68
18. Basım ve Kayıt Hizmetleri	Nisan 2014	5.51
<b>19. Kok ve Rafine Petrol Ürünleri</b>	<b>Nisan 2014</b>	<b>21.14</b>
20. Kimyasallar ve Kimyasal Ürünler	Nisan 2014	10.85

**Çizelge 3.2.** (devam)

21. Temel Eczacılık Ürünleri ve Müstahzarları	Nisan 2014	0.37
22. Kauçuk ve Plastik Ürünler	Nisan 2014	14.33
23. Diğer Metalik Olmayan Mineral Ürünler	Nisan 2014	17.09
24. Ana Metaller	Nisan 2014	13.04
25. Fabrikasyon Metal Ürünler, Makine ve Ekipmanlar Hariç	Nisan 2014	14.44
26. Bilgisayarlar ile Elektronik ve Optik Ürünler	Nisan 2014	14.39
27. Elektrikli Teçhizat	Nisan 2014	11.44
28. Başka Yerde Sınıflandırılmamış Makine ve Ekipmanlar	Nisan 2014	9.46
29. Motorlu Kara Taşıtları, Treyler Römork ve Yarı Treyler Yarı Römork	Nisan 2014	16.33
30. Diğer Ulaşım Araçları	Nisan 2014	11.93
31. Mobilya	Nisan 2014	13.76
32. Diğer Mamul Eşyalar	Nisan 2014	6.58
35. Elektrik, Gaz, Buhar ve İklimlendirme	Nisan 2014	1.9
36. Doğal Su; Suyun Arıtılması ve Temini Hizmetleri	Nisan 2014	9.17
B. Madencilik ve Taş Ocakçılığı	Nisan 2014	12.2
C. İmalat Ürünleri	Nisan 2014	13.51
D. Elektrik, Gaz, Buhar ve İklimlendirme	Nisan 2014	1.9
E. Su Temini; Kanalizasyon, Atık Yönetimi ve İyileştirme Faaliyetleri	Nisan 2014	9.17

Üretici Fiyatı; yurt içinde üretimi yapılan ürünlerin KDV, ÖTV vb. dolaylı vergiler hariç, peşin satış fiyatıdır. Temel veri kaynağı olarak ulusal hesaplar, sanayi ürün ve üretim istatistikleri, sanayi ciro verisi ve yurt içi fiyat endeksi anketi kullanılmaktadır. Çizelge 3.2’de görüleceği üzere 2014 yılı Nisan ayında geçen yılın aynı ayına göre yıllık yüzde değişim oranı en yüksek %21,14 ile Kok Kömürü Ve Rafine Edilmiş Petrol Ürünleri ana kaleminde olmuştur.



### 3.4. Box-Jenkins Metodolojisi

George E.P. BOX ve Gwilym M. JENKINS tarafından durağan tek değişkenli zaman serilerinin analizi için geliştirilen (Yaffee and McGee 2000) ve öngörü uygulamalarında kullanılan Box-Jenkins yöntemi, ARIMA modelleri olarak da adlandırılmaktadır. Tek değişkenli bir model olarak geleceği öngörme yöntemlerinden olan Box-Jenkins yönteminin kısa dönem öngörülerde oldukça başarılı sonuçlar verdiği görülmektedir.

Zaman serilerinin öngörüsünde bilinen ve yaygın bir şekilde kullanılan istatistik yöntemlerinin en kapsamlısı olan Box-Jenkins modelleri kesikli ve doğrusal stokastik süreçlere dayanır. Box-Jenkins modellerinden olan otoregresif (AR) ve hareketli ortalama (MA) modelleri ve bunların birleşimi olan otoregresif hareketli ortalama (ARMA) modelleri durağan süreçlere uygulanırken, otoregresif bütünleşik hareketli ortalama (ARIMA) modelleri durağan olmayan süreçlere uygulanır.

Zamanla değişmeyen olasılık özelliklerine sahip modeller durağan modellerdir. Bu modeller zamanla değişmeyen ortalamaya ve varyansa sahiptir.  $Y_t$  durağan olduğunda tüm  $t$  gözlemlerinde aşağıdaki özellikler geçerli olur:

$$\bullet \quad E(Y_t) = \mu_y, \quad 3.1$$

$$\bullet \quad \text{Var}(Y_t) = E[(Y_t - \mu_y)^2] = \sigma_y^2 = \gamma_0, \quad 3.2$$

$$\bullet \quad \text{Cov}(Y_t, Y_{t-h}) = E[(Y_t - \mu_y)(Y_{t-h} - \mu_y)] = \gamma_h \quad 3.3$$

#### 3.4.1. Durağanlık ve birim kök testleri

Zaman serilerinin durağan olması; zaman içinde varyansın ve ortalamasının sabit olması ve gecikmeli iki zaman periyodundaki değişkenlerin kovaryansının değişkenler arasındaki gecikmeye bağlı olup zamana bağlı olmamasıdır (Gujarati 1995).

Zaman serilerinin belirli bir trend içerdiği durumlarda, ilgili seriler durağan olmamaktadır. Sahte regresyon benzeri durumlar ise, bu gibi zaman serilerinin kullanılacağı regresyon ve öngörümleme denklemlerinde ortaya çıkacaktır. Zaman serileri durağan değillerse, stokastik veya deterministik trend içermektedirler.

Durağan modeller, sürecin zamanla değişmeyen olasılık özelliklerine sahip istatistiksel dengede kaldığı varsayımına dayanır. Durağan modeller zamanla değişmeyen sabit ortalama ve varyansa sahiptirler (Box *et al.* 2009). Eğer otoregresif süreç durağan ise, birinci ve ikinci momentleri zaman ile değişmez.

Durağan olmayan zaman serilerinin regresyon sonuçları anlamsız olduğundan zaman serilerinin durağan olması önemlidir. Durağan bir stokastik sürecin tüm elemanlarına ait ortalama, varyans ve kovaryansı zamanla değişmediğinden sabittir.

#### **3.4.1.a. Korelogram ve otokorelasyon fonksiyonları (ACF-PACF)**

Korelogram grafiği ile zaman serileri etkileyen nedenlerin incelenmesi yapılabilir. İlgili serinin “k” sayıda zaman aralığı için belirlenen otokorelasyon katsayıları ile bu katsayıların “k” gecikme değerlerinin eşleştirilmesiyle belirlenen noktaların hesaplanması suretiyle elde edilir. Trend etkisinin belirlenmesi için “k” sayısının en az on, mevsim etkisinin belirlenmesi için ise en az yirmi dört olması gerekmektedir (Özmen 1988).

Bu durağanlık testi otokorelasyon fonksiyonuna (ACF) dayanır. Otokorelasyon fonksiyonu serinin bazı değerleri ve gecikmeli değerleri arasındaki ilişkinin boyutunu belirler. Değişik zaman aralıkları (k) için bulunacak  $ACF(k)$  katsayısı değerleri ilişkilendirildiğinde, korelogram elde edilir.  $ACF(k)$  değerleri 1 ve -1 arasında yer almaktadır.

Durağanlık tespitinde korelogramdan şu şekilde yararlanır. ACF eğer çok yüksek bir değerden başlayıp çok yavaş küçülüyorsa, bu serinin durağan olmadığına bir göstergesidir. Kısmi otokorelasyon fonksiyonu gecikmeli değişkenler arasındaki ilişkiyi ifade eder. Kısmi otokorelasyon fonksiyonu ile otokorelasyon  $Y$  ve  $Y(t-k)$  arasındaki terimlerin etkisi çıkarılarak bulunur.

AR sürecinin derecesinin ( $p$ ) belirlenmesinde kısmi otokorelasyon fonksiyonundan (PACF) yararlanılabilir (Tsay 2005). Kısmi otokorelasyon katsayısı, zaman serisi içerisindeki  $Y_{t-1}$  ve  $Y_{t-k}$  gibi iki gözlem arasındaki korelasyonu, serinin içerisinde bulunan diğer gözlemlerin bu iki gözlem üzerindeki etkilerinin çıkarılmasıyla hesaplar (Vogelvang 2005). Zaman serisindeki gözlemler arasındaki ilişkiyi ortaya koymak amacıyla otokorelasyon fonksiyonu (ACF) gibi bir istatistiksel ölçü kümesi olan PACF, serinin AR veya MA süreçlerinden hangisine uyduğu konusunda ACF ile birlikte kullanılır.

#### 3.4.1.b. Genişletilmiş dickey fuller (ADF)

İlgili serilerde birim kökün varlığının bulunup bulunmadığının incelenmesinde kullanılan testlerden birisi de Dickey-Fuller testi adı verilen testtir. Bu yöntemin ilk olarak duyurulması, D.A. Dickey ve W.A. Fuller'in 1979'da "Journal of American Statistical Association" adlı dergide yayınlanan makaleleriyle olmuştur. Testin ilk çıktığı dönemden günümüze kadar çeşitli alanlarda yeterli gelmediği ve bundan dolayı eksiklerinin kapatılması için oluşturulan yardımcı yöntemler ortaya çıkmıştır.

Dickey-Fuller'in ortaya koyduğu iç denklem türü bulunmaktadır.

$$\text{Sabit terimsiz trendsiz Dickey-Fuller denklemi} \quad : \Delta Y_t = \delta Y_{t-1} + u_t \quad 3.4$$

$$\text{Sabit terimli trendsiz Dickey-Fuller denklemi} \quad : \Delta Y_t = \beta_0 + \delta Y_{t-1} + u_t \quad 3.5$$

$$\text{Sabit terimli trendli Dickey-Fuller denklemi:} \Delta Y_t = \beta_0 + \beta_1 + \delta Y_{t-1} + u_t \quad 3.6$$

### 3.4.2. Box-Jenkins modelleri

Box-Jenkins modellerinin genel yapısında otoregresif süreç (AR) ve hareketli ortalama süreci (MA) bulunmaktadır. Bu süreçlerin yanına eğer seriyi durağan hale getirmek için farkı alınmış ise Integrated (I) kısmı eklenmektedir. Eğer seri mevsimsel bir seri ise mevsimsellik derecesi de belirtilmelidir (SARIMA).

#### 3.4.2.a. Otoresif modeli (AR)

AR modelde sürecin şimdiki değeri, sürecin geçmiş değerlerinin doğrusal toplamı ve  $\varepsilon_t$  gibi bir rassal şoktan oluşan sonlu değerdir (Box *et al.* 2009). AR(p) olarak gösterilen p derece otoregresif bir model ile aşağıdaki şekilde gösterilebilir (Gujarati 1995):

$$Y_t = \delta + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_p Y_{t-p} + \varepsilon_t \quad 3.7$$

Yukarıdaki denklemde;  $\delta$ : sürecin ortalaması ile ilgili olan sabit terim,  $\phi$ : terimleri bilinmeyen otoregresif parametrelerini,  $\varepsilon_t$  ise hata terimini ifade etmektedir. Hata teriminin ortalaması sıfır ve sabit varyanslı korelasyonsuz rassal değişken olduğu varsayılır. 3.4 denklemde görüldüğü üzere, p derece otoregresif sürece sahip  $Y_t$  zaman serisi, bu serinin p dönem geriye giden ağırlıklı ortalaması ile bozucu terimin toplam değerine eşittir (Pindyck and Rubinfeld 1998).

#### 3.4.2.b. Hareketli ortalama modeli (MA)

İlgili serinin gecikmeli hata değeri mevcut dönemdeki hata değerini etkiliyorsa hareketli ortalama süreci belirlenir. Hareketli ortalama sürecinde değişkenlerin öngörü değeri ile hata değeri arasında bağlantı vardır. Bir hareketli ortalama süreci aşağıdaki gibi tanımlanır:

$$Y_t = \mu + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_q \varepsilon_{t-q} \quad 3.8$$

3.5 denkleminde  $\varepsilon_t$ , ortalaması sıfır ve sabit varyansa sahip olan korelasyonsuz rassal kalıntıları,  $\beta$  ise bilinmeyen parametreleri ifade etmektedir. Genel olarak MA(q) olarak belirtilir. Hareketli ortalama sürecinde, her bir gecikmeli hata terimi onun şimdiki değerini etkilemektedir.

#### 3.4.2.c. Otoregresif hareketli ortalama modeli (ARMA)

Zaman serisi modellerinde esneklik sağlamak için en az sayıda parametre kullanma ilkesini gerçekleştirmek amacıyla bazı hallerde modele hem otoregresif hem de hareketli ortalama parametrelerinin alınması birçok faydalar sağlamaktadır. Bu düşünce ARMA (p, q) modelini ortaya çıkarmıştır (Kayım 1985).

ARMA modelinin genel ifadesi şu şekilde tanımlanır:

$$Y_t = \theta + \alpha_1 Y_{t-1} + \dots + \alpha_p Y_{t-p} + u_t + \beta_1 u_{t-1} + \dots + \beta_q u_{t-q} \quad 3.9$$

3.6 denkleminde görüleceği üzere  $\theta, Y_t$ 'nin ortalaması ile ilgili sabit terimi,  $u_t$  ise ortalamaları sıfır ve varyansı sabit olan korelasyonsuz rassal değişkenler olduğu varsayılan hataları göstermektedir.

#### 3.4.2.d. Otoregresif bütünleşik hareketli ortalama modeli (ARIMA)

Çoğu zaman serisi gerek AR ve gerekse MA sürecini içermektedir. Ayrıca I(integrated) ise seri tarafından içerilen trendi ifade etmektedir. ARIMA olarak ifade edilen süreç değerlendirilecek olursa, ARIMA (p,d,q) bize zaman serisinin p dereceden kendisinin gecikmesi ile ilişkisini ifade eden AR(p) sürecini içerdiğini, q ile ifade edilen ve hata terimlerinin geçmiş değerleri ile ilişkisini ifade eden ve rassal süreci yansıtmaları açısından hata terimlerinin düzleştirilme metodlarından biri olan MA(q) sürecini ifade

etmektedir. Ayrıca eğer zaman serilerinde genelde olduğu gibi bir durağan olmama durumunun olması ya da durağan bir zaman serisi ile karşılaşmamız d ile ifade edilir ve zaman serisi hangi düzeyde durağan (integrated) ise belirtilir. ARIMA modeli aşağıdaki gibi gösterilebilir (Cryer and Chan 2008):

$$(1 - \phi_1 L + \phi_2 L^2 + \dots + \phi_p L^p) \Delta^d Y_t = \delta + (1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q) \varepsilon_t \quad 3.10$$

Burada  $Y_t$  durağan olmayan zaman serisini,  $\Delta^d$  d dereceden fark alma operatörünü,  $\delta$   $Y_t$ 'nin ortalaması ile ilgili sabit terimi ve  $\varepsilon_t$  ortalaması sıfır ve sabit varyansa sahip olan korelasyonsuz rassal kalıntıları göstermektedir.

#### 3.4.2.e. Mevsimsel otoregresif bütünleşik hareketli ortalama modeli (SARIMA)

Belirli bir zaman içerisinde benzer hareketler gösteren düzenli değişimler mevsimsel değişiklikler olarak tanımlanabilir. Bunlar aylık, 3 aylık, 4 aylık, 6 aylık gibi bir yıldan az dönemlerde görülen benzer hareketlerdir. Yaz aylarında ve bayramlarda otobüs ve uçak biletlerinde ve yolcu sayılarındaki artış, kışın doğalgaz fiyatlarındaki yükseliş gibi örnekler verilebilir. Mevsimsellik serinin durağanlığını bozan hareketlerden biri olduğundan mevsimsel fark alarak durağanlığa ulaştırılması sağlanmalıdır.

ARIMA (p,d,q)(P,D,Q)<sub>s</sub> şeklinde gösterilebilir. Aynı şekilde matematiksel gösterimi aşağıda verilmiştir.

$$\phi_p(L) \varphi_p(L^s) \nabla^d \nabla_s^D Y_t = \theta_q(L) \omega_q(L^s) \varepsilon_t \quad 3.11$$

Denklem 3.8'de görüleceği üzere  $Y_t$ , durağan olmayan zaman serisini,  $\phi_p(L)$ , p dereceden otoregresif polinomu,  $\varphi_p(L^s)$ , p dereceden mevsimlik otoregresif polinomunu,  $\nabla^d$ , d dereceden fark alma operatörünü,  $\nabla_s^D$ , D dereceden mevsimlik fark alma operatörünü,  $\omega_q(L^s)$ , Q dereceden mevsimlik hareketli ortalama polinomunu,  $\varepsilon_t$

ise ortalaması sıfır ve sabit bir varyansa sahip korelasyonsuz rassal kalıntıları ifade etmektedir.

### **3.4.3. Box-Jenkins yönteminde model kurma süreci**

Box-Jenkins yönteminin temel adımları aşağıdaki gibi özetlenebilir (Erdoğan 2006):

- i- Serinin yeterli sayıda farkları alınarak durağanlığa ulaşılır.
- ii- Potansiyel bir model tanımı yapılır.
- iii- Potansiyel modelin tahmini yapılır.
- iv- Ayırt edici kontrole başvurulur (eğer model yetersiz ise ikinci adıma tekrar geri dönülerek alternatif modeller dikkate alınır).
- v- Ön raporlama ve kontrol için model kullanılır.

#### **3.4.3.a. Veri hazırlama**

ARIMA sürecinin p,d,q mertebelerinin belirlenmesini kapsayan veri hazırlama süreci, model kurmanın temeli durumundadır. Model kurulması aşamasındaki en zor adım veri hazırlamadır. Bu süreçte araştırmacıların dikkatli model seçimi için verdikleri kararlar çok önemlidir. Veri hazırlama sürecinde öncelikle serinin durağanlık analizi incelenir aynı zamanda seriye mevsimsellik analizi uygulanır. Serinin durağan olup olmadığı sonucuna, söz konusu seriye ait oto korelasyon fonksiyonuna (ACF) ve kısmi oto korelasyon fonksiyonuna (PACF) bakılarak varılabilir. Söz konusu serinin oto korelasyon fonksiyonuna bakılarak, serinin durağanlığa ulaşmış olup olmadığına bakılabilir, aynı zamanda durağanlığın hangi oranda oluştuğuna ve mevsimsellik uzunluğunun ve etkisinin belirlenmesine yardımcı olmaktadır.

Durağanlık testi için, ACF ve PACF yanında Dickey-Fuller (DF), Genişletilmiş Dickey-Fuller (ADF) veya Phillips-Perron (PP) gibi durağanlık testleri de yapılabilir. Yalnız seride durağanlık yoksa sahte otokorelasyonlar modeli belirleme konusunda zorluk

çıkarmaktadır. Bu yüzden serinin hangi düzeyinde durağanlığa ulaşıyorsa o aşamada serinin farkı alınır ve durağanlığa ulaşılır. Sonrasında, model belirleme aşamasında durağanlığa ulaşan serinin ACF ve PACF grafiklerine bakılarak, p ile q değerlerinin derecelerine ulaşılabilir. ACF üstel azalıyorsa ve PACF’de p gecikmelerine ait önemli çıkıntı veya çıkıntılar beliriorsa, model AR(p) olacaktır. ACF’de q gecikmelerine ait önemli çıkıntı veya çıkıntılar var ise ve PACF üstel azalıyorsa, model MA(q) olacaktır. Hem ACF hem de PACF üstel olarak azalıyorsa, model ARMA(p,q) olarak belirlenecektir. Üstel azalma, fonksiyonun yaklaşık olarak sıfır olmayan değerlerle üssel, geometrik ya da sinüsel olarak azalışını ifade eder. Bu çalışmada serinin durağanlığının kontrolü için ACF, PACF ve ADF testleri kullanılacaktır (Bilgili 2001).

Durağan modeller için oto korelasyon ve kısmi oto korelasyon fonksiyonlarının teorik davranışları Çizelge 3.3’te gösterilmektedir.

**Çizelge 3.3.** Durağan Box-Jenkins modellerinde ACF ve PACF seyri (Akgül 2003)

<b>Model</b>	<b>Otokorelasyon Fonksiyonu</b>	<b>Kısmi Otokorelasyon Fonksiyonu</b>
AR (p)	“q” kadar gecikmenin ardından keser.	Üstel şekilde ya da sinüs dalgaları şeklinde azalır.
MA (q)	Üstel şekilde ya da sinüs dalgaları şeklinde azalma gösterir.	“p” kadar gecikmenin ardından keser.
ARMA (p,q)	Üstel şekilde ya da sinüs dalgaları şeklinde azalma gösterir. “p” kadar gecikmenin ardından keser.	Üstel şekilde ya da sinüs dalgaları şeklinde azalma gösterir. “q” kadar gecikmenin ardından keser

Uygulamada ACF ve PACF gecikme sayısı, seriye ait kullanılabilir gözlemin 1/3 veya 1/4 olarak alınır. %95 güven aralığının  $\pm 1,96$  dışında kalan veya mutlak değer içerisinde



iki standart hatadan büyük olan otokorelasyon katsayıları ve kısmi otokorelasyon katsayıları, p ve q derecelerini belirleyecektir. p ve/veya q gecikmelerinin büyümesi, tahmin edilen hataların karelerinin toplamını azaltmaktadır. Ancak, böyle gecikmelerin eklenmesi ilave katsayıların tahmin edilmesini ve bununla ilgili olarak serbestlik derecesinin azalmasını gerektirir. Modele gerektiğinden fazla sayıda katsayının eklenmesi seçilen modelin geleceği tahmin etme etkinliğini düşürecektir. Hata karelerinin toplamını dikkate alan çeşitli model seçim kriterleri sayesinde daha az gecikmeli bir model bulunabilmektedir. En yaygın kullanılan model seçim kriterleri “Akaike Bilgi Kriteri” (Akaike Information Criterion – AIC) ve “Schwartz Bayes Kriteri” (Schwartz Bayesian Criterion – SBC) dir.

Değişik kaynaklarda farklı olarak ifade edilmekle birlikte AIC ve SBC istatistikleri, hata karelerinin toplamına bağlı olarak tanımlanırlar. Burada; modelden elde edilen hataların kareleri toplamı SSE, tahmin edilen parametrelerin sayısı ise r olarak gösterilmektedir. SBC veya AIC olsun pozitif olmayan değerler olabilir ve bunlardan (AIC veya SBC istatistiklerinden birisi) en küçük değeri veren p ve q değerleri model dereceleri olarak seçilir. İstatistiki hesaplamalarda kullanılan paket programları ilgili istatistiklerin değerlerini belirlemektedir. Model seçiminde kullanılan bir başka kriter ise “En Son Kestirim Hatası (Final Prediction Error)” olarak tanımlanan FPE istatistiğidir ve yine FPE istatistiğini en küçük yapan değer model derecesi olarak alınır. Ancak, bu istatistik otoregresif (AR) seriler için geçerli olup uygulamada çok kullanılmamaktadır (Bilgili 2001).

#### **3.4.3.b. Ayırt edici kontrol**

Box-Jenkins yönteminde model kurmanın üçüncü aşaması, teşhis etme testlerini kullanarak modelin yeterliliğini kontrol etmektir. Bir zaman serisi modeli belirlenip parametreleri tahmin edildikten sonra ayırt edici testler yardımıyla yapılan tanımlamanın ne kadar doğru olduğu ortaya konulabilir. Ayırt edici kontrol sürecinde benzetilen serinin otokorelasyon fonksiyonu, orijinal serinin örneklem otokorelasyon fonksiyonu ile karşılaştırılır. Eğer iki otokorelasyon fonksiyonu oldukça farklı

görünüyorsa, modelin geçerliliği üzerinde şüpheyle durulur ve yeniden model belirleme aşamasına geri dönülür. Eğer iki otokorelasyon fonksiyonu bir biçimde farklı değilse, bu durumda modelin kalıntıları analiz edilebilir (Sevüktekin ve Nargeleçekenler 2010).

### 3.4.3.c. Öngörü

Birden fazla tahmin modeli kullanılırken bunlardan birini seçmek için kabul edilen seçeneklerden birisi de, kullanılan modelin tahmin edebilme başarısının mümkün olduğunca yüksek olmasıdır. Örnek vermek gerekirse, iki ARIMA modelimizin olduğunu düşünelim. Bu modellerin geçerliliği ve faydası eşit olduğun durumda, her iki modelin tahmin edebilme başarıları incelenmekte ve daha iyi tahmin doğruluğu sağlayan model tercih edilmektedir. Çeşitli istatistiki teknikler kullanılarak bu modellerin tahmin doğrulukları karşılaştırılmaktadır (Akgül 2003).

Tahminlemenin doğruluk testini görmek için, ilgili öngörü dönemine ait gözlem değerleri yokmuş gibi gözlem dışı bırakılır ve önerilen aday modele dayanarak bu dönemlere ait değerlerin tahminlemesi yapılır. Öngörü değerleri ile mevcut olan gerçek değerler arasındaki farklar, yani öngörü hataları bazı formüllerle modellerin öngörü doğruluğunu karşılaştırmaya yardımcı olabilecek şekilde standartlaştırılır.

Modellerin öngörü doğruluğunun ölçümünde kullanılan istatistikler; Hata Kareler Ortalaması (Mean Squared Error - MSE), Hata Kareler Ortalamasının Karekökü (Root Mean Squared Error - RMSE), Ortalama Mutlak Hata (Mean Absolute Error - MAE),

Ortalama Yüzde Hata (Mean Percentage Error – MPE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE) ve Theil-U istatistiği olarak sıralanabilir (DeLurgio 1998). Bu istatistiklerden yaygın olarak kullanılan üçünün formülü aşağıda verilmiştir:

$$e_t = y_t - \hat{y}_t$$

$$MAPE = \frac{\sum |(y_t - \hat{y}_t)/y_t|}{n} * 100 \quad 3.12$$

$$MAE = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n} \quad 3.13$$

$$MSE = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|^2}{n} \quad 3.14$$

$$MPE = \frac{\%100}{n} \sum_{t=1}^n \frac{y_t - \hat{y}_t}{y_t} \quad 3.15$$

Burada;

- n : tahminde bulunulan dönem sayısını,
- $e_t$  : t dönemindeki tahmin hatasını,
- $y_t$  : t döneminde gerçekleşen değerini,
- $\hat{y}$  : t dönemi için hesaplanan tahmini değerini,

göstermektedir.

İncelenen bütün istatistiklerde arzu edilen sonuç en küçük MAPE, MAE, MSE istatistiklerine sahip tahmin modelini oluşturmaktır.

Öngörü hatalarını yüzde olarak ifade etmesi ile tek başına bir anlamının olması nedeniyle, Ortalama Mutlak Yüzde Hata'nın (MAPE) diğer kriterlere göre üstünlüğü olarak kabul edilmektedir (Akgül 2003).

Witt ve Witt, MAPE deęerleri %10'nun altında olan tahmin modellerini 'yüksek doęruluk' derecesine sahip, %10 ile %20 arasında olan modelleri ise 'doęru tahmin modelleri' olarak sınıflandırmıştır (Witt and Witt 1992). Benzer şekilde Lewis, MAPE deęeri %10'un altında olan modelleri 'çok iyi', %10 ile %20 arasında olan modelleri 'iyi', %20 ile %50 arasında olan modelleri 'kabul edilebilir' ve %50'nin üzerinde olan modelleri ise 'yanlış ve hatalı' olarak sınıflandırmıştır (Lewis 1982).

#### **3.4.4. Box-Jenkins yönteminin üstün ve zayıf yönleri:**

Box-Jenkins modelinin üstün yönleri şu şekilde özetlenebilir:

- Dięer tek deęişkenli yöntemler sadece özel durumlarda kullanılmasına ve istatistiksel dayanakları olmamasına rağmen, Box-Jenkins modellerinin altında geniş bir olasılık teorisi ve matematiksel istatistik yatmaktadır (Pankratz 1983).
- Öngörü amacıyla kullanıldığında, izlenen her aşamada modelin analiz edilecek seriye uygunluęunu denetlemek mümkündür.
- Box-Jenkins modeli ile uygun model belirlendiğinde genelde elde edilen verilerin yapısı analiz edildięi için dięer yöntemlere nazaran daha güvenilir olduęu söylenebilir (Newbold 1975).

Box-Jenkins modelinin zayıf yönleri şu şekilde özetlenebilir:

- Box-Jenkins yöntemi ile yeterli sonuçların elde edilebilmesi için araştırmacının yeterli bilgiye sahip olması ve deneyimli olması gerekirken, yöntem araştırmacıya geniş bir özgürlük imkanı sağladığından araştırmacı uygun olmayan bir model seçebilir (Newbold 1975).
- Box-Jenkins modelleri aynı seriyi analiz eden ve öngörü sonuçları elde eden iki araştırmacının sayısal olarak benzer sonuçlar elde etmesi garanti deęildir.

- Uygun modelin belirlenmesi uzun işlemler gerektirdiğinden, geleneksel yöntemlere nazaran daha fazla zaman almaktadır.

### **3.5. Yapay Sinir Ağları**

Yapay sinir ağlarının geleneksel zaman serisi tahmin modellerine oranla tercih edilmesinin nedeni, spesifik bir modelinin olmamasındandır. Bu nedenle son dönemde tahmin problemlerinde sıkça kullanılmaktadır.

Yapay sinir ağları, insan beyninde bulunan sinir ağlarına benzetilen ve bu biyolojik ağlara benzer performans şekilleri içeren işleme sistemidir (Fausett 1994).

YSA, insan beyninin özelliklerinden olan öğrenme ve bu öğrenilen bilgiler ile yeni fonksiyonlar üretebilme gibi özellikler yardımı ile yeni bilgileri keşfedebilme kabiliyeti olan bilgisayar programlarıdır. (Fausett 1994; Öztemel 2003).

YSA, biyolojik sinir sistemlerine benzetilmek istenen bilgisayar programlarına verilen genel isimdir. Benzetilen hücrelerde nöronlar bulunur. Söz konusu nöronlar farklı şekillerde birbirleri ile iletişim halinde olurlar ve bu bağlantılar sayesinde ağı oluştururlar. Bu ağlar ile bilgiler hafızaya alınır ve veriler arasında ilişkiler ortaya çıkarılır.

Yapay sinir ağları insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilmekte, yeni bilgiler oluşturabilme ve keşfedebilme yetenekleri herhangi bir yardım olmadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek oldukça zor veya mümkün değildir. O nedenle yapay sinir ağlarının programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş adaptif bilgi işleme olduğu söylenebilir (Öztemel 2003).

İnsan beyninin çalışma şekline benzer şekilde sınıflandırma, ilişkilendirme, öğrenme, optimizasyon, özellik belirleme ve genelleme gibi konularda uygulanmaktadır. Yapay sinir ağları örneklerden elde ettikleri bilgiler ile kendi deneyimlerini oluşturur ve daha sonra benzer kararlar verirler.

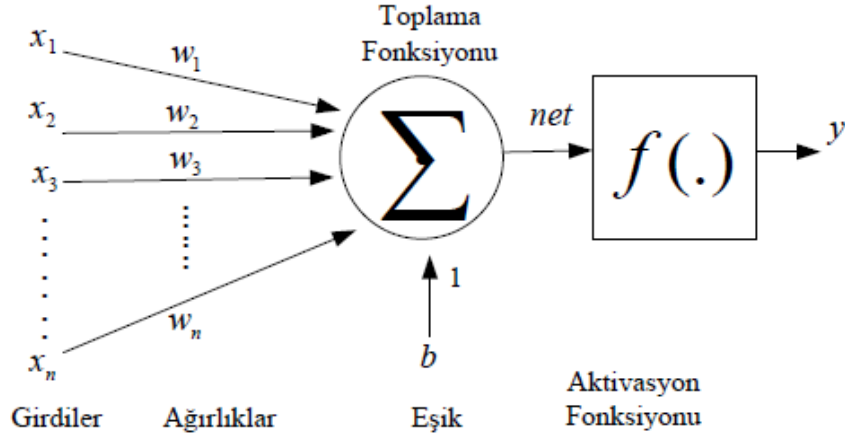
Basit bir şekilde insan beyninin çalışma şeklini taklit eden YSA'lar veriden öğrenebilme, genelleme yapabilme, sınırsız sayıda değişkenle çalışabilme vb. birçok önemli özelliğe sahiptir. YSA'nın çalışmasına esas teşkil eden en küçük birimler yapay sinir hücresi ya da işlem elemanı olarak isimlendirilir.

Birbirleriyle bağlantılı olan nöronlar sayesinde yapay sinir ağları meydana gelir bu nöronlar farklı katmanlarda bulunabilir. Genellikle bu katmanlar giriş, gizli ve çıkış katmanı olarak adlandırılır. Herhangi bir ağda ne kadar katman olacağı ve bu katmanlardaki nöron sayıları ağın mimarisini oluşturur. Bu mimari ağın performansını doğrudan etkilemektedir.

Kohonen (1982), yapay sinir ağını, "yapay sinir ağlar, paralel olarak bağlantılı ve çok sayıda basit elemanın gerçek dünyanın nesnelereyle biyolojik olarak sinir sisteminin benzeri yolla etkileşim kuran, hiyerarşik bir organizasyonudur" şeklinde tanımlamıştır.

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

En basit yapay sinir hücresi Şekil 3.5'te de görüleceği üzere girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış olmak üzere 5 ana bileşenden oluşmaktadır.



**Şekil 3.5.** Basit bir yapay sinir ağı fonksiyonu

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

**Giriş katmanı:** Giriş veri gruplarının ağına sunulduğu terminallerdir. Bu tabakadaki nöron sayısı giriş veri sayısı kadardır ve her bir giriş nöronu bir veri alır. Buradaki veri işlenmeden bir sonraki tabaka olan gizli tabakaya geçer.

**Ağırlıklar:** Ağırlıklar, bir yapay sinir hücresine gelen bilgilerin, hücre önündeki önemini ve etkisini gösteren bileşendir. Her bir girişin kendine ait bir ağırlığı vardır. Bir ağırlığın değerinin büyük ya da küçük olması, o girişin yapay sinir ağı için önemli ya da önemsiz olduğunu göstermez. Ağırlıklar değişken ya da sabit değerler olabilir.

**Gizli katman:** Ağıın temel işlevini gören tabakadır. Bazı uygulamalarda ağıda birden fazla gizli katman bulunabilir. Gizli tabaka sayısı ve gizli tabakadaki nöron sayısı

probleme göre deęiřir. Bu tabaka, girdi tabakasından aldıęı aęırlıklandırılmıř veriyi probleme uygun bir fonksiyonla iřleyerek bir sonraki tabakaya iletir.

**Toplama Fonksiyonu:** Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar. Bunun için deęiřik fonksiyonlar kullanılmaktadır. En yaygın olanı aęırlıklı toplamı bulmaktır. Burada her gelen girdi deęeri kendi aęırlıęı ile çarpılarak toplanır. Böylece aęa gelen net girdi bulunmuř olur.

Yapay sinir aęlarında çok çeřitli aę yapıları ve modelleri vardır. Yapay sinir aęı, bir dizi sinir hücresinin ileri sürümlü ve geri beslemeli baęlantı řekilleri ile birbirine baęlanmasından oluřur. Günümüzde, belirli amaçlarla ve deęiřik alanlarda kullanılmaya uygun birçok yapay sinir aęı modeli (MLP, RBF, LVQ, Hopfield, Recurrent, SOM, ART vb.) geliřtirilmiřtir. Bu aę yapıları içerisinde en yaygın kullanım alanı bulan ve çalıřmamızda da kullanılan çok katmanlı ileri beslemeli yapay sinir aęları (MLP, Multiple Layer Perceptron) aęlarıdır.

Teknik olarak, bir YSA'nın en temel amacı, örnek veri setindeki genel yapıyı öęrenerek, istenilen görevi yerine getirecek řekilde genelleřtirmeler yapmaktır. Aęın bu genelleřtirmeyi yapabilmesi için söz konusu olayın veri seti ile eęitilmesi gerekmektedir. (Öztemel 2003). Söz konusu aęın öęrenme süreci nöronların aęırlıkları ve kullanıcı tarafından deęiřtirilebilen eęitim algoritmaları sayesinde yapılabilmektedir. Çok katmanlı algılayıcılara sahip olan aęların eęitiminde matematiksel olarak ispatlanabilir olmasından ve kolay olmasından dolayı geri yayılım algoritması tercih edilmektedir. Geri yayılım algoritması, hataları geriye doęru yani çıkıřtan giriře doęru azalmaya çalıřmasından dolayı bu ismi almıřtır. En yaygın öęrenme algoritması olan geri yayılım algoritması danıřmanlı öęrenme yapısına sahip olmasından dolayı ilgi görmektedir. Danıřmanlı öęrenme algoritmalarında aęın eęitimi için, aęa örnek olarak girdi ve çıktı deęerlerden oluřan bir örnek veri seti verilir. Verilen hedef çıktı deęerleri, YSA literatüründe danıřman ya da öęretmen olarak adlandırılır.



### 3.5.1. YSA'nın özellikleri

Yapay sinir ağlarında bütün modeller için benzer genel özellikler bulunmaktadır. Bununla birlikte her ağ modelinde karakteristik farklar olduğu unutulmamalıdır (Yıldız 2001, Doğanay ve Aktaş 2003).

- Yapay sinir ağlarında sistemin paralelliği ve toplamsal işlevin yapısal olarak dağılımı benzer özelliklerdendir. Yapay sinir ağları birden fazla nörondan meydana gelir ve bu nöronlar eş zamanlı olarak çalışarak karmaşık işlevleri yerine getirir. Süreç içerisinde bu nöronlardan herhangi biri işlevini yitirse bile sistem güven sınırları içerisinde çalışmasına devam edebilir.
- Diğer bir benzer özellik ise genelleme yeteneğidir. Bu durum ağ yapısının, eğitim esnasında kullanılan nümerik bilgilerden eşleştirmeyi betimleyen kaba özellikleri çıkarması ve böylelikle eğitim esnasında kullanılmayan girdiler için de anlamlı yanıtlar üretebilmesidir.
- Ağ fonksiyonları non-lineer olabilir. Yapı üzerinde dağılmış belli özellikteki non-lineer alt birimler özellikle istenen eşleştirmenin denetim ya da tanımlama işlemlerinde olduğu gibi non-lineer olması durumunda işlevin doğru biçimde yerine getirilebilmesini matematiksel olarak olası kılarlar.
- Sayısal ortamda tasarlanan YSA'ların, donanımsal olarak gerçekleştirilebilir olması günlük hayatta daha fazla kullanılabilceğini göstermektedir.
- Literatürde, verilerin yapay sinir ağının eğitiminde kullanılması için gerekli bir varsayım bulunmamaktadır. Bir başka deyişle her tür veri, sayılarla kodlanması şartıyla eğitim için kullanılabilir. Bu yapay sinir ağı teknolojisinin, bazı varsayımlara dayanan istatistiksel yöntemlere kıyasla sahip olduğu önemli bir avantajdır.

Yukarıda bahsedilen güçlü özellikleri sayesinde yapay sinir ağları tercih edilebilir. Bu güçlü yanlarını nöronların paralel dağıtılmış yapısı sayesinde başardığı söylenebilir. Aynı şekilde öğrenme yapısı ve genelleme yapısı da güçlü olmasının nedeni sayılabilir. Söz konusu özellikleri ve farklılıkları sayesinde ileriye yönelik tahmin çalışmalarında

yapay sinir ađları geleneksel tahmin yöntemlerine göre tahmin aşamasında tercih edilebilir (Venugopal and Baets 1994; Özalp ve Anagün 2003).

### **3.5.2. YSA modelleri**

İşleyiş şekillerine göre yapay sinir ađları, ileri beslemeli ve geri beslemeli ađlar olmak üzere ikiye ayrılırlar.

#### **3.5.2.a. İleri beslemeli ađlar**

İleri beslemeli mimari 1970’li yıllarda geliştirilmiştir. Bu mimarinin geliştirilmesinde birbirlerinden bağımsız olarak birkaç araştırmacının katkıları olmuştur. Asıl katkı ise Rumelhart, Hinton and Williams (1986) tarafından yapılmıştır. Ortaya çıkışından sonra, hem etkili hem de çok kullanışlı olmasından dolayı büyük bir popülerite kazanmıştır ve hala en çok kullanılan ađ türü olarak bilinmektedir. Çok sayıda farklı uygulama alanında kullanılmaktadır ve en büyük özelliđi doğrusal olmayan yapı içeren problemlerde de etkili olabilmesidir.

İleri beslemeli yapay sinir ađlarında sinyaller sadece tek bir yönde, girdi katmanından çıktı katmanına doğru yönelir. Katmanlar şeklinde düzenlenen hücrelerin belirli bir katmandaki çıkışları, takip eden katmana ağırlıkları sayesinde girdi olarak verilir. Giriş katmanı ise kendisine dışarıdan verilen bilgileri herhangi bir deđişiklik yapmaksızın gizli katmandaki hücrelere doğrudan yönlendirir. Söz konusu bilgi seti, orta katmanda ve çıkış katmanında işlemlerden geçirilerek ađın çıkışına iletilir. Bu yapıları nedeniyle ileri beslemeli ađlarda doğrusal olmayan durağan bir yapı vardır denilebilir.

#### **3.5.2.b. Geri beslemeli ađlar**

Geri beslemeli ađlarda bir tür geri besleme işlemi vardır. Bu ađ yapılarında sinyalin yönü girdi katmanından çıktı katmanına doğrudur. Ancak, aynı zamanda bir katman

üzerinde yer alan nöronlar, kendisinden, katmandaki diğer nöronlardan ya da diğer katmanlardaki nöronlardan sinyal alabilmektedir (Elmas 2012; Güneri ve Apaydın 2004).

Zaman serilerinde en yaygın kullanılan yapay sinir ağı türü üç tabaklı ileri beslemeli modeldir. Tek değişkenli zaman serileri için ağın girdileri geçmiş veya gecikmeli değişkenler, çıktısı ise tahmin değerleridir (Eğrioğlu ve Aladağ 2005).

### **3.5.3. YSA'nın üstün ve zayıf yönleri:**

Yapay Sinir Ağları'nın üstün yönleri şu şekilde özetlenebilir:

- YSA'nın eğitiminde yoğun hesaplamalar gerçekleştiğinden, çok zor problemler için özünde paralel bir yapıya sahip olan YSA'nın paralel işlem özelliği sayesinde işlemler çok hızlı gerçekleşir.
- Box-Jenkins modellerinde olduğu gibi seriyi durağanlaştırmak için fark alma işlemi YSA'da yapılmadığından, veri kaybı söz konusu değildir.
- Matematiksel olarak modellenmesi mümkün olmayan veya zor olan karmaşık problemleri kolayca modelleyerek çözebilir. Çünkü doğası gereği YSA, bir problemi çözmek için herhangi bir tanımlamaya ihtiyaç duymamakta ve problem için en uygun çözüme yakınsama eğilimindedir.

Yapay Sinir Ağları'nın zayıf yönleri şu şekilde özetlenebilir:

- YSA yapısının oluşturulmasında belirli bir yöntem olmadığından, ağ yapısı dikkatli bir biçimde oluşturulmadığında, öğrenme işlemi yerel minimum değerde takılabilir ve bu durum kötü öğrenme değerlerine yol açabilir (Zhao 2009).
- Uygun YSA'nın kurulumu ve eğitim süreci oldukça uzun sürebilir.

- Öngörüsü yapılacak olan deęişken için kullanılacak teknik ve ekonomik girdilerin problemi temsil etme yeteneęinin zayıf olduęu durumlarda saęlıklı çözümler üretmek mümkün olmamaktadır (Öztemel 2003).

#### 4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Bu çalışmada yapay sinir ağları ile ARIMA modelleri kullanılarak enflasyon tahmini yapılmıştır. Sonrasında modellerin karşılaştırılması yapılmıştır. Bu karşılaştırmayı yaparken temel veri seti olarak yıllık yüzde değişim yöntemine göre hesaplanan Tüketici Fiyat Endeksi kullanılmıştır. Türkiye’de 2003 yılından itibaren yeni yöntemle göre Tüketici Fiyat Endeksi hesaplanmaya başlanmıştır. Yıllık yüzde değişim olmasından dolayı 2004 yılından itibaren veri setine başlanmıştır. 2004:01 ile 2013:12 dönemindeki aylık TÜFE verileri çalışmanın temel veri setini oluşturmaktadır. Çizelge 4.1’de bu temel veri seti belirtilmiştir. Bu veri seti, Türkiye’de enflasyon olarak tabir edilen fiyat değişim endeksinin en çok kullanılan şeklidir. Kullanılan veriler Türkiye İstatistik Kurumu’ndan alınmıştır. Bununla beraber bu veriler Türkiye’de temel enflasyon göstergesi olduğundan Türkiye Cumhuriyet Merkez Bankası, Hazine Müsteşarlığı gibi kurumlar tarafından da kullanılmakta ve internet sitelerinden yayınlanmaktadır.

**Çizelge 4.1.** 2004-2013 yılları arasındaki aylık TÜFE verileri (TÜİK 2015)

TUFE	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013
<b>Ocak</b>	10.59407	9.23576	7.93082	9.92959	8.17138	9.50048	8.18521	4.90033	10.61336	7.30765
<b>Şubat</b>	9.47729	8.69483	8.14776	10.15827	9.10424	7.73314	10.12785	4.15652	10.43332	7.0254
<b>Mart</b>	8.39788	7.94472	8.16131	10.86326	9.15232	7.88581	9.56082	3.98604	10.42772	7.29065
<b>Nisan</b>	7.87163	8.17663	8.82989	10.71996	9.66052	6.12606	10.19426	4.26461	11.13795	6.13378
<b>Mayıs</b>	7.30708	8.70051	9.86374	9.22777	10.74056	5.23634	9.09982	7.17255	8.28049	6.51469
<b>Haziran</b>	7.0815	8.95439	10.119	8.59831	10.60921	5.73426	8.36751	6.23588	8.86857	8.29752
<b>Temmuz</b>	7.79546	7.81656	11.69278	6.89948	12.06461	5.39254	7.57724	6.31137	9.06519	8.88443
<b>Ağustos</b>	8.4424	7.91413	10.2621	7.3945	11.7664	5.3348	8.33486	6.65348	8.88324	8.16823
<b>Eylül</b>	8.01459	7.99489	10.54678	7.12484	11.12538	5.27228	9.23565	6.15402	9.18512	7.88244
<b>Ekim</b>	9.42567	7.51584	9.97924	7.69986	11.9857	5.07605	8.61925	7.65561	7.79889	7.71194
<b>Kasım</b>	9.47145	7.61233	9.85754	8.39917	10.75971	5.53073	7.28781	9.48465	6.36955	7.3157
<b>Aralık</b>	9.35459	7.72001	9.65349	8.38724	10.0638	6.5258	6.40103	10.44817	6.1638	7.40046

Bu çalışmada Box-Jenkins modellerinin seçilmesindeki ana amaç, kısa dönemli tahminlerde başarılı sonuç sağlamak istenmesidir. Bununla birlikte doğrusal olmayan zaman serilerinde başarılı sonuçlar sağlayan yapay sinir ağları da çalışmanın diğer kısmını oluşturmaktadır. Bu iki yöntemden elde edilen sonuçlar karşılaştırılarak hangisinin Türkiye'deki TÜFE serisi için kısa dönemli tahmin sonuçlarında daha başarılı olduğu bulunmak istenmiştir. Bu karşılaştırmaları yaparken modellerin örneklem içi ve örneklem dışı değerlerden ne kadar değişim gösterdiği incelenmiştir. Bu değişimleri ortaya koyarken Ortalama Mutlak Hata (MAE), Ortalama Mutlak Hata Yüzdesi (MAPE) ve Hata Kareler Ortalaması (MSE) yöntemleri ile farklılıklar değerlendirilmiştir.

#### 4.1. Box-Jenkins ile Modelleme


Ekonomik modeller, iktisat teorisi tarafından öngörülen denge ilişkileri üzerine kurulmaktadır. Bu nedenle, değişkenler arasında ekonometrik olarak anlamlı ilişkiler elde edilebilmesi için, zaman serilerinin durağan seriler olması gerekmektedir. Seriyeye ait otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonlarına (PACF) bakılarak serinin durağan olup olmadığı incelenebilir (Montgomery *et al.* 1990).

Durağanlık testi için, ACF ve PACF fonksiyonlarının yanında Genişletilmiş Dickey-Fuller (ADF) veya Philips-Perron testlerine de başvurulabilir. Bu çalışmada durağanlığın tespiti için Genişletilmiş Dickey-Fuller (ADF) birim kök testi kullanılmaktadır.

Daha sonra durağan serinin ACF ve PACF fonksiyonlarının biçimlerine bakarak, p ve q dereceleri belirlenebilir. ACF üstel azalıyorsa ve PACF'de p gecikmelerine ait önemli çıkıntılar görünüyorsa, model AR(p) olacaktır. ACF'de q gecikmelerine ait önemli çıkıntılar varsa ve PACF üstel azalıyorsa, model MA(q) olacaktır. Hem ACF hem de PACF üstel olarak azalıyorsa, model ARMA(p,q) olarak belirlenecektir. Pratikte ACF ve PACF gecikme sayıları, seriyeye ait kullanılabilir gözlemin üçte biri veya dörtte biri


olarak alınır. Bu çalışmada elimizde 120 veri olduğundan korelogramları dörtte biri olan 30 gecikmeye kadar çizilmiştir.

Box-Jenkins modellerinin tahmini için kısmen uzun serilere ihtiyaç vardır. Chatfield (1996) en az 50 gözlem olması gerektiğini önermiştir. Çoğu araştırmacı ise en az 100 gözlem olması gerektiğini söylemektedir.



**Şekil 4.1.** 2004-2013 yılları arasında TÜFE serisinin zamana göre değişimi grafiği

Yıllara göre çizilmiş olan aylık TÜFE serisini incelediğimizde net bir trend görüntüsü olmamakla birlikte, bir miktar mevsimsellikten etkilenme görülmektedir. Bu durumda veri setinin ACF (otokorelasyon) ve PACF (kısmi otokorelasyon) grafiklerine bakılır.



**Şekil 4.2.** TÜFE Serisinin Korelogramı

Şekil 4.2’de görülebildiği üzere TÜFE serisinin korelogram grafiğine bakıldığında ACF yüksek bir değerden başlayarak yavaş yavaş küçülmekte olduğundan serinin durağan olmadığını söyleyebiliriz.



**Çizelge 4.2.** TUFEE serisinin sabit terimli ADF birim kök testi sonucu

Null Hypothesis: TUFEE has a unit root Exogenous: Constant Lag Length: 0 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.962580	0.0414
Test critical values: 1% level	-3.486064	
5% level	-2.885863	
10% level	-2.579818	

\*MacKinnon (1996) one-sided p-values.

**Çizelge 4.3.** TUFEE serisinin sabit terimli ve trendli ADF birim kök testi sonucu

Null Hypothesis: TUFEE has a unit root Exogenous: Constant, Linear Trend Lag Length: 0 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.986922	0.1403
Test critical values: 1% level	-4.036983	
5% level	-3.448021	
10% level	-3.149135	

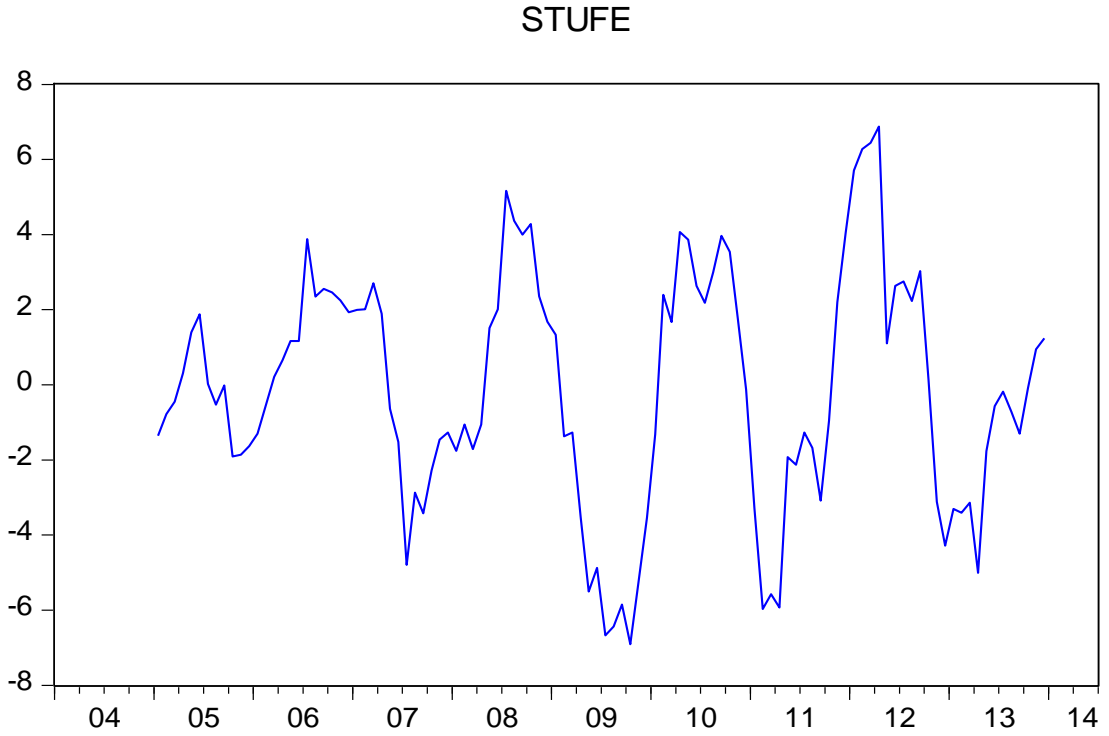
\*MacKinnon (1996) one-sided p-values.

**Çizelge 4.4.** TUFEE serisinin sabit terimsiz ADF birim kök testi sonucu

Null Hypothesis: TUFEE has a unit root Exogenous: None Lag Length: 0 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.914852	0.3181
Test critical values: 1% level	-2.584539	
5% level	-1.943540	
10% level	-1.614941	

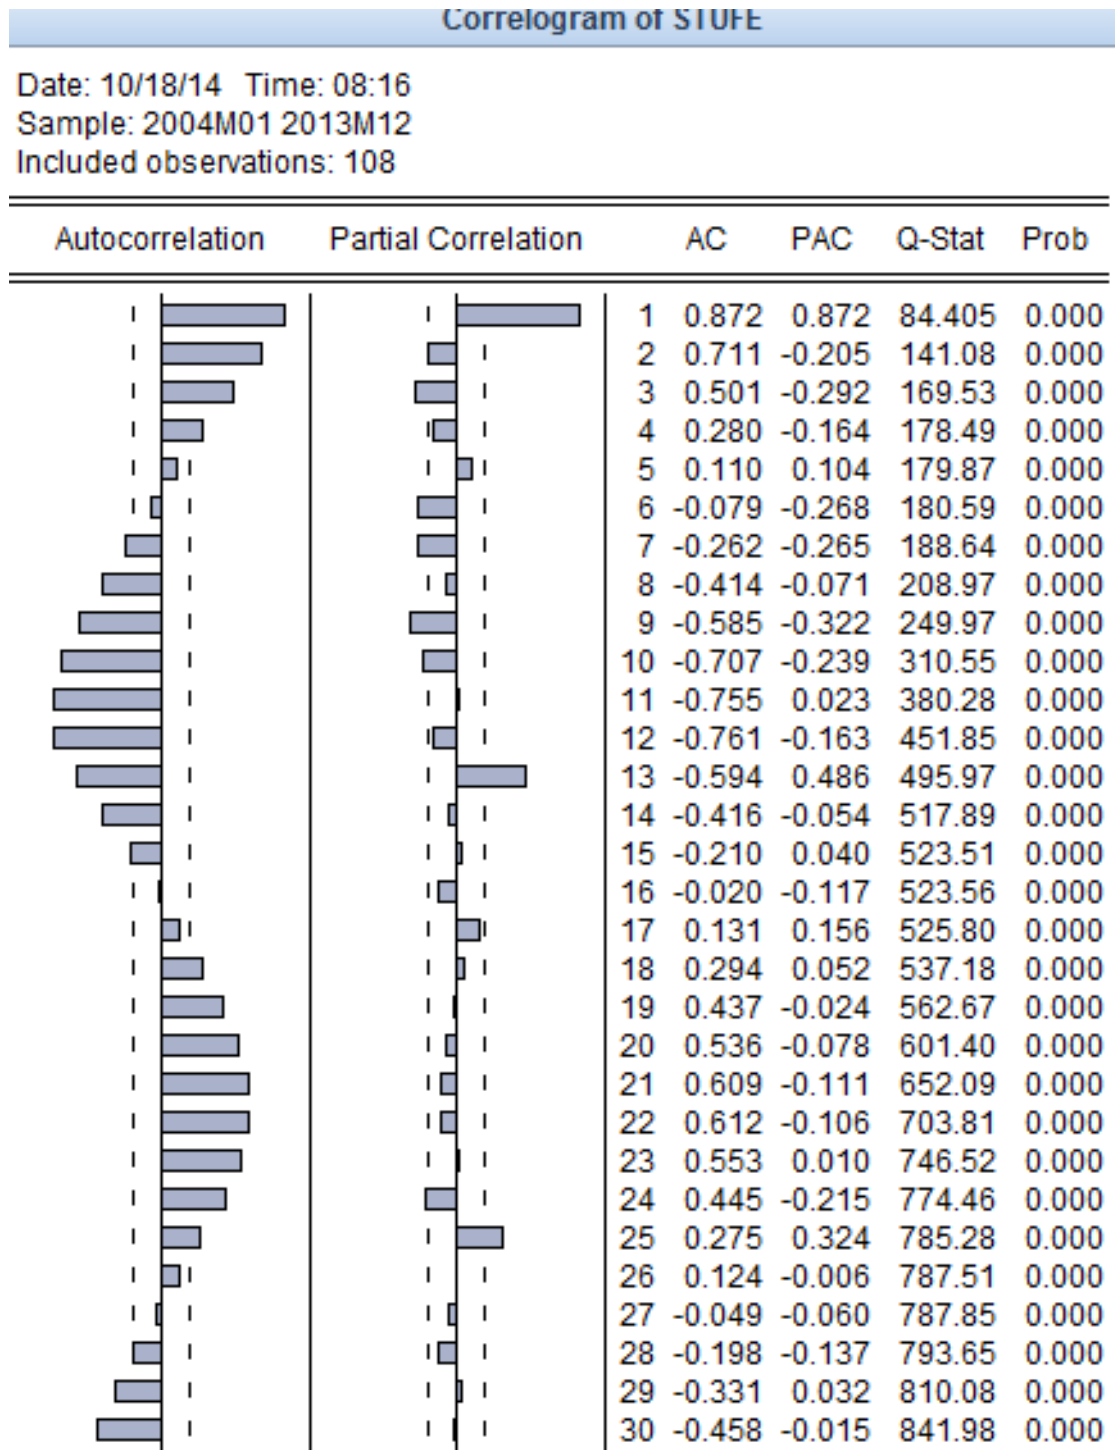
\*MacKinnon (1996) one-sided p-values.

ADF Birim Kök Testi uygulanan TÜFE serisi için sonuçlar Çizelge 4.2, 4.3 ve 4.4'te gösterilmektedir. Bu sonuçlara göre TÜFE serisi düzeyde durağan değildir. Seride 1 ve 13. Gecikmelere baktığımızda ciddi mevsimsel zirveleri görebiliriz. Bu nedenle serinin mevsimsel olarak farkını almamız gerekir.



**Şekil 4.3.** Birinci dereceden mevsimsel farkı alınmış TÜFE serisinin zaman grafiği

TÜFE serisinin birinci dereceden mevsimsel farkı alındığında Şekil 4.3'te görüldüğü üzere serinin durağanlığa ulaşmadığı görülmektedir. Görsel olarak yapılan analiz sonrasında serinin korelogram ve durağanlık testleri ile durağanlığı teyit edilmelidir.



**Şekil 4.4.** Birinci dereceden mevsimsel farkı alınmış TÜFE serisinin korelogramı

**Çizelge 4.5.** Birinci derecede mevsimsel farkı alınmış TÜFE serisinin sabit terimli ADF birim kök testi sonucu

Null Hypothesis: STUFE has a unit root Exogenous: Constant Lag Length: 12 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.493656	0.1202
Test critical values: 1% level	-3.500669	
5% level	-2.892200	
10% level	-2.583192	

\*MacKinnon (1996) one-sided p-values.

**Çizelge 4.6.** Birinci derecede mevsimsel farkı alınmış TÜFE serisinin sabit terimli ve trendli ADF birim kök testi sonucu

Null Hypothesis: STUFE has a unit root Exogenous: Constant, Linear Trend Lag Length: 12 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	<b>-2.515323</b>	0.3203
Test critical values: 1% level	-4.057528	
5% level	<b>-3.457808</b>	
10% level	-3.154859	


\*MacKinnon (1996) one-sided p-values.

**Çizelge 4.7.** Birinci derecede mevsimsel farkı alınmış TÜFE serisinin sabit terimsiz ADF birim kök testi sonucu

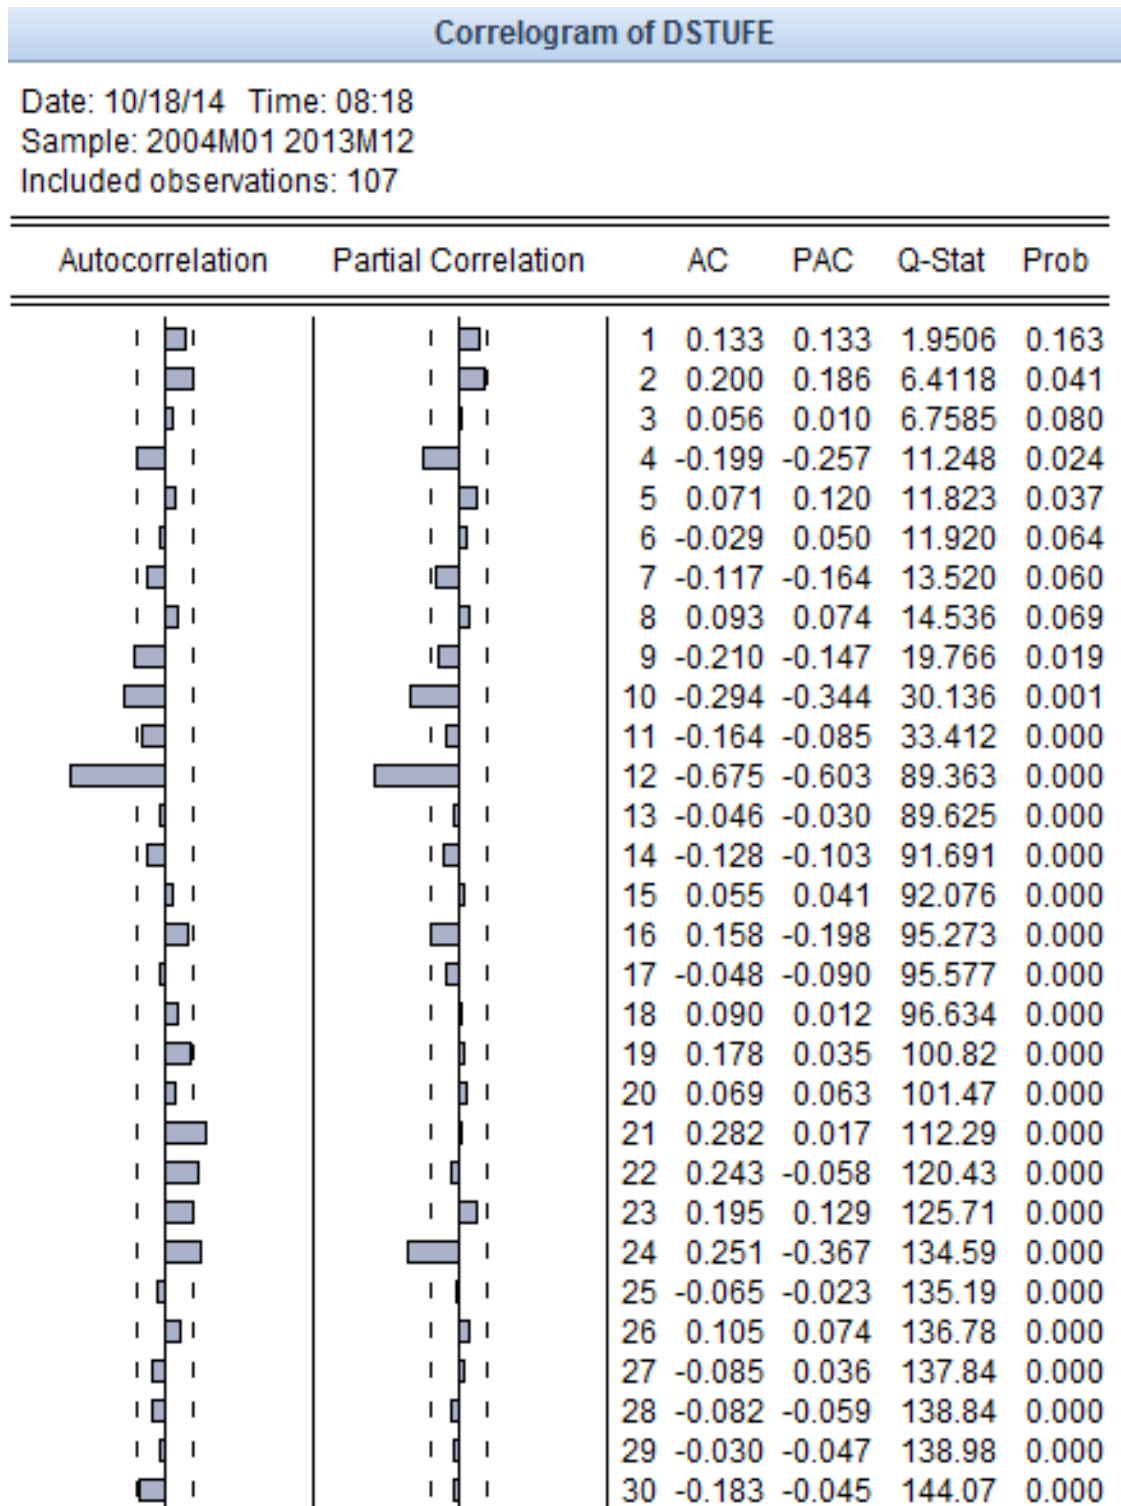
Null Hypothesis: STUFE has a unit root Exogenous: None Lag Length: 12 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.505769	0.0126
Test critical values: 1% level	-2.589531	
5% level	-1.944248	
10% level	-1.614510	

\*MacKinnon (1996) one-sided p-values.

Çizelge 4.6'daki t-istatistiği değeri (-2.515323) %5 hata seviyesindeki tablo değeri olan (-3.457808)'dan büyük olduğundan; mevsimsel farkı alınmış TÜFE serisi, ADF Birim Kök Testi sonuçlarına göre durağan olmadığını görüyoruz. Sonraki aşamada mevsimsel farkı alınmış serinin birinci dereceden farkı alınarak durağanlığı araştırılacaktır.



**Şekil 4.5.** Birinci derece farkı alınmış STUFE serisinin zamana göre dağılımı



**Şekil 4.6.** Birinci derecede farkı alınmış STÜFE serisinin korelogramı

**Çizelge 4.8.** Birinci dereceden farkı alınmış STÜFE serisinin sabit terimli ADF birim kök testi sonucu

Null Hypothesis: DSTUFE has a unit root		
Exogenous: Constant		
Lag Length: 11 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-8.933555	0.0000
Test critical values: 1% level	-3.500669	
5% level	-2.892200	
10% level	-2.583192	

\*MacKinnon (1996) one-sided p-values.

**Çizelge 4.9.** Birinci derecede farkı alınmış STÜFE serisinin sabit terimli ve trendli ADF birim kök testi sonucu

Null Hypothesis: DSTUFE has a unit root		
Exogenous: Constant, Linear Trend		
Lag Length: 11 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-8.953171	0.0000
Test critical values: 1% level	-4.057528	
5% level	-3.457808	
10% level	-3.154859	

\*MacKinnon (1996) one-sided p-values.

**Çizelge 4.10.** Birinci derecede farkı alınmış STÜFE serisinin sabit terimsiz ADF birim kök testi sonucu

Null Hypothesis: DSTUFE has a unit root		
Exogenous: None		
Lag Length: 11 (Automatic - based on SIC, maxlag=12)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	<b>-8.988706</b>	0.0000
Test critical values: 1% level	-2.589531	
5% level	<b>-1.944248</b>	
10% level	-1.614510	

\*MacKinnon (1996) one-sided p-values.

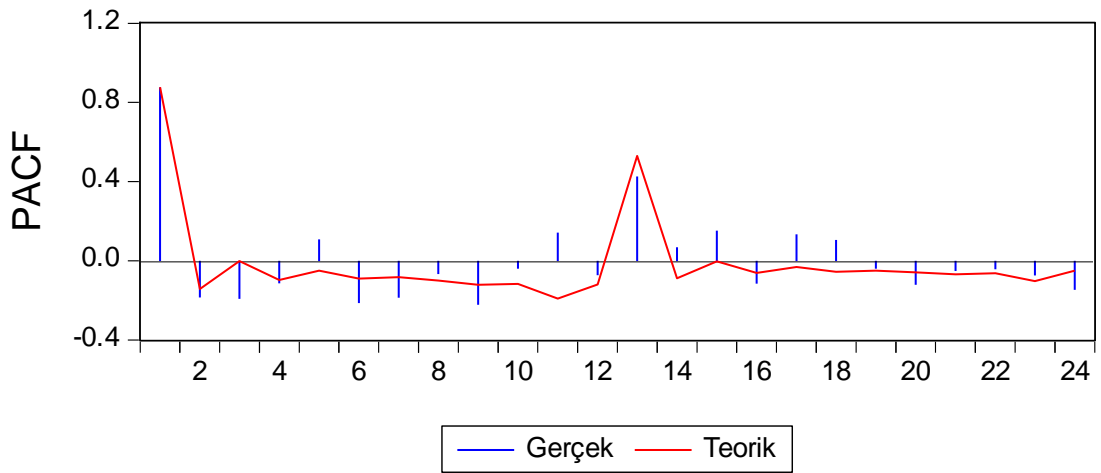
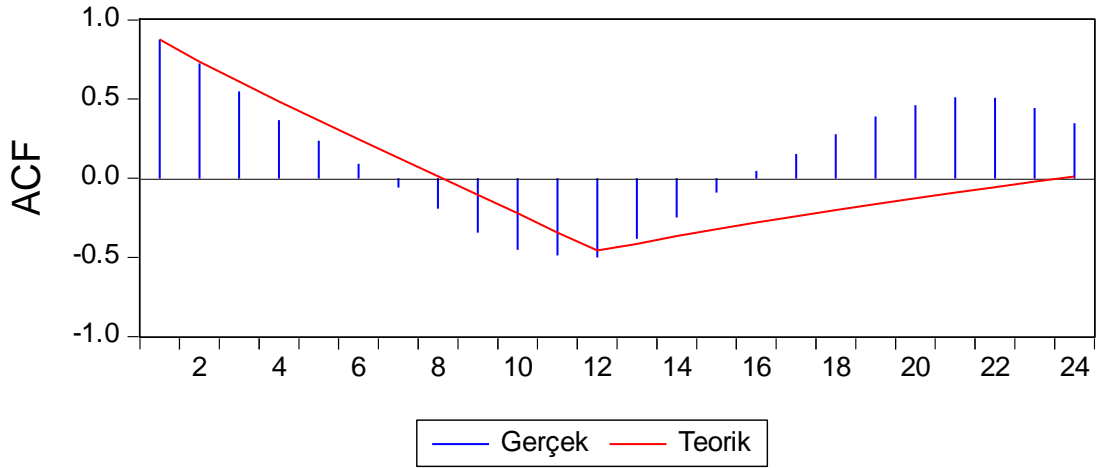
Çizelge 4.10'daki t-istatistiği değeri (-8,995895) %5 hata seviyesindeki tablo değeri olan (-1,944286)'dan küçük olduğundan; 1.dereceden farkı alınmış STÜFE serisi, ADF Birim Kök Testi sonuçlarına göre durağanlığa ulaşmıştır. PACF grafiğini incelediğimizde 2 gecikmeden sonra serinin sıfır eksenini kestiği görülmektedir. Bu nedenle AR(2) olabileceği düşünülmektedir. ACF grafiğini incelediğimizde serinin ilk gecikmede güven sınırları aralığında kaldığından MA(1) olabileceği düşünülmektedir. DSTUFE serisinin korelogramından görüleceği üzere 12. ve 24. gecikmede zirve noktaları bulunmaktadır. Bu gecikmelerde büyük değerler alarak aniden azalması modelin p ve q parametrelerinin 1 olabileceğine işaret etmektedir.

**Çizelge 4.11.** TÜFE serisi ARIMA modeli tahmin sonucu

Dependent Variable: TUFÉ				
Method: Least Squares				
Date: 10/18/14 Time: 12:35				
Sample (adjusted): 2005M03 2013M12				
Included observations: 106 after adjustments				
Convergence achieved after 7 iterations				
MA Backcast: 2004M02 2005M02				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	8.054135	0.291950	27.58738	0.0000
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
R-squared	0.891860	Mean dependent var	8.291731	
Adjusted R-squared	0.886453	S.D. dependent var	1.829478	
S.E. of regression	0.616473	Akaike info criterion	1.925335	
Sum squared resid	38.00393	Schwarz criterion	2.076096	
Log likelihood	-96.04276	Hannan-Quinn criter.	1.986439	
F-statistic	164.9460	Durbin-Watson stat	2.032058	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.92	.85-.23i	.85+.23i	.62+.62i
	.62-.62i	.23+.85i	.23-.85i	-.23+.85i
	-.23-.85i	-.51	-.62-.62i	-.62-.62i
	-.85-.23i	-.85+.23i		
Inverted MA Roots	.99	.86+.49i	.86-.49i	.49+.86i
	.49-.86i	.00-.99i	-.00+.99i	-.49-.86i
	-.49+.86i	-.62	-.86-.49i	-.86+.49i
	-.99			




Yapılan testler sonucunda ARIMA(2,1,1)(1,1,1) modelinin en uygun model olduğu sonucuna ulaşılmıştır.




**Şekil 4.7.** ARIMA (2,1,1)(1,1,1) modelinin gerçek ve teorik ACF ve PACF grafikleri

Şekil 4.7’de görüldüğü üzere, ARIMA (2,1,1)(1,1,1) modeline ait gerçek ve teorik ACF ve PACF katsayıları incelendiğinde, değerler arasında büyük sapmaların olmadığı görülmektedir. Şekil 4.8’de bu modele ait hata grafikleri ve modele uyumunu gösteren grafik yer almaktadır.



**Şekil 4.8.** ARIMA (2,1,1)(1,1,1) modeline ait hataların ACF ve PACF grafiği

İlk kısımda görüleceği üzere tahmin edilen model grafiği, mevcut modele uyumlu görülmektedir. Aynı zamanda modele ait artıkların grafiği incelendiğinde, istenilen güven aralığından kaldığından modelin tercih edilebilirliği artmaktadır.



**Şekil 4.9.** ARIMA (2,1,1)(1,1,1) modeline ait kalıntıların korelogramı

ARIMA (2,1,1)(1,1,1) modeline ait hataların ACF ve PACF grafiği'ni gösteren Şekil 4.9 incelendiğinde ACF ve PACF katsayılarının neredeyse tümünün güven sınırları

içerisinde yer aldığı görülmektedir. Bu durum model yeterliliğinin kabul edilmesinde kullanılan önemli bir kriterdir.

Türkiye'nin 2004:01-2013:12 dönemine ait TÜFE verileri kullanılarak belirlenen ARIMA(2,1,1)(1,1,1) modeli kullanılarak 2013 yılına ait 12 aylık örneklem içi öngörü değerleri Çizelge 4.12'de yer almaktadır.

**Çizelge 4.12.** 2013 yılı aylık örneklem içi TÜFE gerçek ve öngörü değerleri

	Gerçekleşen Değerler	ARIMA (2,1,1)(1,1,1)
2013:01	7.30765	6.489069
2013:02	7.0254	6.475188
2013:03	7.29065	6.771937
2013:04	6.13378	6.03778
2013:05	6.51469	7.456199
2013:06	8.29752	8.034325
2013:07	8.88443	8.192773
2013:08	8.16823	7.866593
2013:09	7.88244	7.696822
2013:10	7.71194	7.960228
2013:11	7.3157	8.850747
2013:12	7.40046	8.657813


\* Bu modele ait tutarlılık göstergeleri:

MAPE: 0,083636

MAE : 0,617318

MSE : 0,567465

MPE : -0,00911




Şekil 4.10. 2013 yılı TÜFE gerçekleşen değerler ile ARIMA modeli grafiği

2004:01-2013:12 dönemine ait TÜFE verileri kullanılarak belirlenen ARIMA(2,1,1)(1,1,1) modeli kullanılarak 2014 yılına ait 6 aylık örneklem dışı öngörü değerleri Çizelge 4.13’de yer almaktadır.

#### 4.2. Yapay Sinir Ağları ile Modelleme

Bu bölümde 2004:01-2013:12 dönemine ait aylık TÜFE (% yıllık değişim) verileri kullanılarak YSA modeli oluşturulmuştur. Veriler TCMB web adresinden elde edilmiştir. Verilerin analizinde Matlab programından faydalanılmıştır.




Şekil 4.11. Modelde Kullanılan Yapay Sinir Ağı Algoritması

2004:1-2013:12 dönemi arasındaki veri seti %70-%15-%15 olacak şekilde ayrılmıştır. İlgili 120 adet veriden 84 tanesi eğitim, 18 tanesi test ve 18 tanesi doğrulama aşamasında kullanılmıştır. Veri seti Levenberg-Marquardt geri yayılım algoritması ile eğitilmiştir. Optimizasyon algoritmaları arasında sıkça tercih edilen Levenberg-Marquardt geri yayılım algoritmasının seçilmesinin nedeni; kısa dönemli veya orta dönemli veri setlerinde hızlı, kararlı ve tutarlı bir sonuca ulaşılmasına yardımcı olmasındandır. Uygulama esnasında kurgulanan ağız gizli katman sayısı kullanıcı tarafından belirlenmektedir. Çalışmada uygulanan gizli katman sayısı, bu katmanlardaki nöron sayısı ve kullanılan aktivasyon fonksiyonu da deneme yanılma ile bulunmaktadır. Yapılan denemeler sonrasında gizli katman sayısının 10, gecikme sayısının 2 olarak alınmasının uygun olacağı değerlendirilmiştir. Az sayıda gizli katman seçilmesi durumunda ağdaki genelleme yeteneğinin yükseldiği görülmektedir. Çok sayıda nöron seçilmesi durumunda ise ağın ezberleme yeteneğinde artma gözlenmektedir. Bununla birlikte ağa çok sayıda gizli nöron veya gizli katman eklenmesi, hesap sayısının olağanüstü biçimde artmasına neden olmaktadır.


**Çizelge 4.13.** Yapay sinir ağının eğitim sırasında verdiği hata kareleri sonuçları

Örneklem İçi			Örneklem dışı	
	MSE	R	MSE	R
Eğitim	0,404546	0,933472	0,452517	0,779905
Doğrulama	0,813346	0,831256		
Test	0,886703	0,862851		



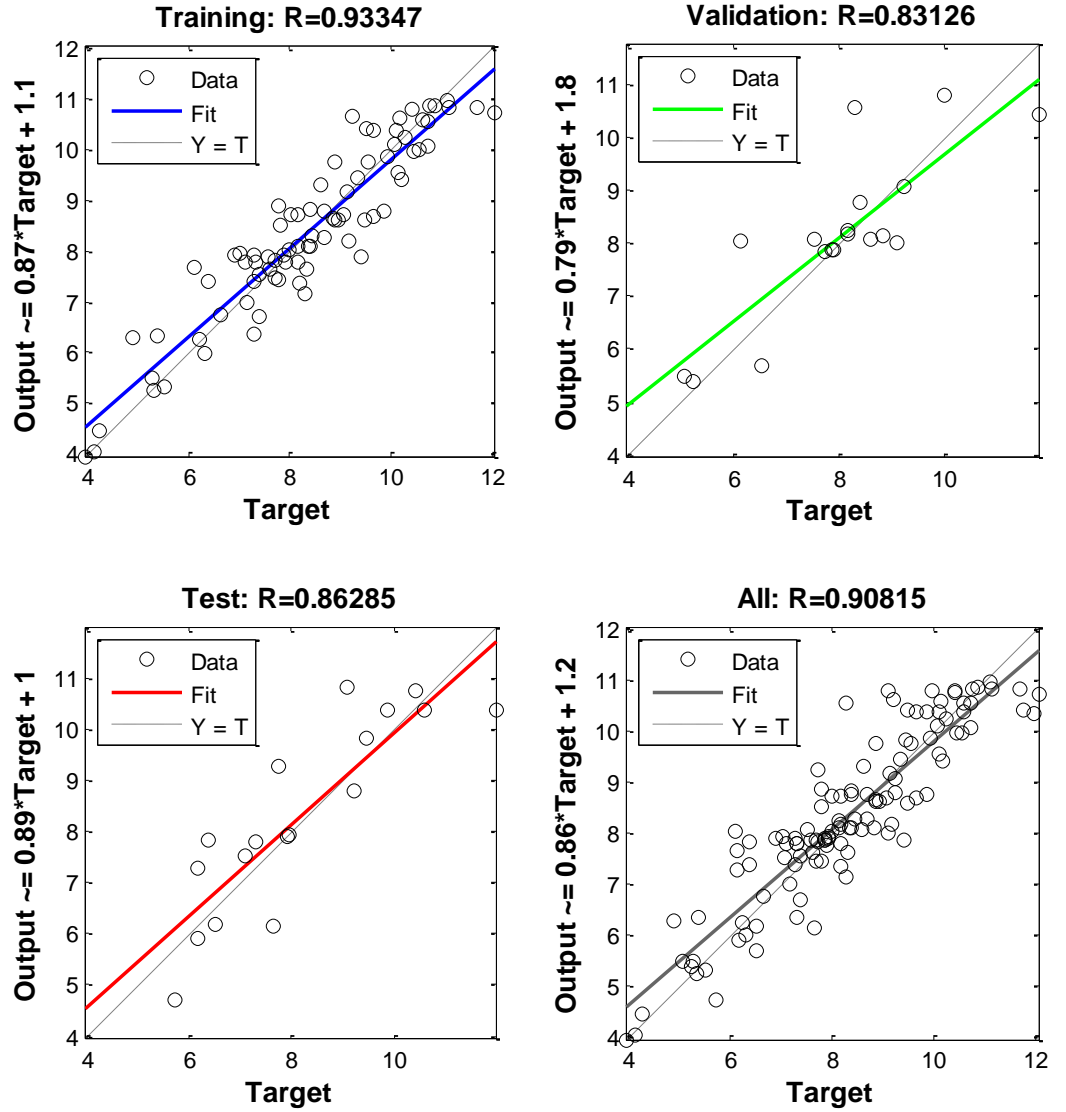
**Şekil 4.12.** Yapay sinir ağı performans – ortalama hata kareleri karşılaştırması

Ağın eğitimi, hata değişkenlerinin çok küçük olmasından sonra, 19 devirden sonra durmuştur. Eğitim sırasındaki hata grafiği Şekil 4.13’de gösterilmiştir.



**Şekil 4.13.** Hata Histogramı Grafiği

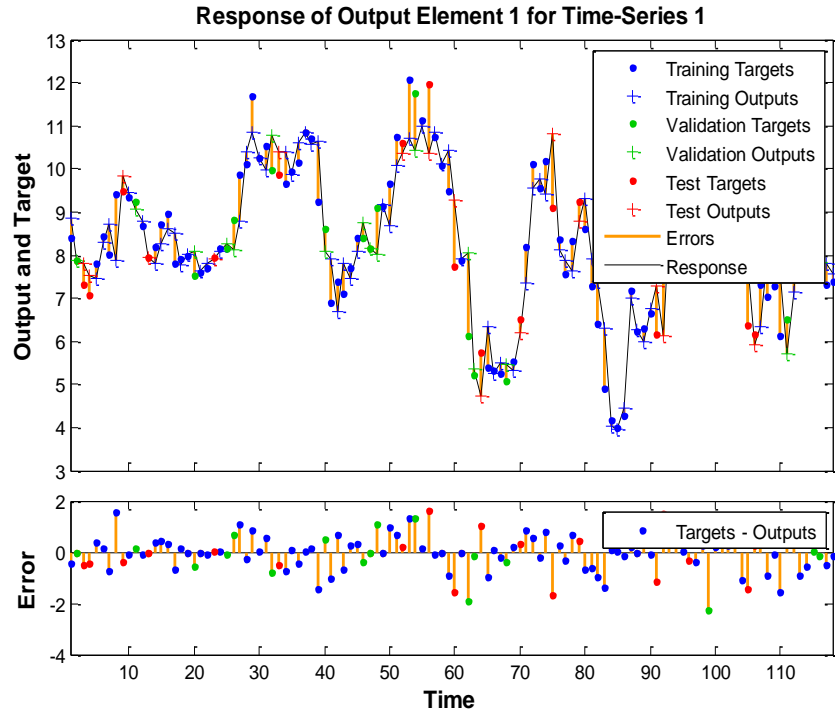
Şekil 4.13'te görülen hata grafiğinden anlaşılacağı üzere eğitim, doğrulama ve test aşamasında hata değerlerinin sıfıra yakınsaması modelin uyumlu olduğunu doğrulamaktadır. Bu hesaplamadaki hatalar hedeflerden çıktılarının çıkarılması sonucu bulunmaktadır.




Şekil 4.14. Eğitim, Doğrulama, Test ve Bütün aşamaların ortalama uygunluk grafikleri

Şekil 4.14'de eğitim, doğrulama ve test aşamalarında verilerin modele uyum grafiği görülmektedir. Verilerin uyum çizgisine yakınsaması modelin doğruluğunu artırmaktadır.






Şekil 4.15. Ağın eğitilmesi sonucundaki zaman serisi tepkisi grafiği



Şekil 4.16. Hataların otokorelasyon grafiği

Şekil 4.15'te ağıın 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 ağıın istenilen performansa ulaştığı görülebilir.

Şekil 4.16'da ise yapay sinir ağı modeline ait hataların otokorelasyon grafiği görülebilir. Burada önemli olan nokta hataların otokorelasyon grafiğinin negatif ya da pozitif noktalardan çok sıfır noktasında toplanması gerektiğidir. Modele ait grafik incelendiğinde hataların otokorelasyonunun sıfır noktasında önemli ölçüde toplandığı görülebilir. Bu da modele ait tutarlılığı artıran bir göstergedir.




**Şekil 4.17.** 2013 yılı TÜFE gerçekleşen değerler ile YSA model grafiği

Bu modele ait tutarlılık göstergeleri:

MAPE	: 0,088565	MAE	: 0,641562
MSE	: 0,621951	MPE	: -0,02251

### 4.3. Modellerin Karşılaştırılması




**Şekil 4.18.** 2013 yılında gerçekleşen TÜFE değerleri ile YSA ve ARIMA modelleri karşılaştırmalı grafiği

Şekil 4.18. incelendiğinde, yapılan çalışma neticesinde ARIMA modelinin seriyi geç yakaladığı ve serinin tepkilerine geç cevap verdiği gözlenmektedir. Bu nedenle kısa süreli tahmin aşamalarında hata düzeyleri gerçekleşen değerler ile gözle görülür biçimde fark çıkarmaktadır. Bununla birlikte Yapay Sinir Ağı ile yapılan modele bakıldığında, modelin seriyi yakalamak için sert hareketleri gözlenmekte ve serinin zaman zaman yapmış olduğu kısa hareketleri uzun vadeli hareketlermiş gibi göstermeye çalışmaktadır. Bu nedenle gerçekleşen değerler ile YSA modeli arasında da fark gözlemlenmiştir.

**Çizelge 4.14.** ARIMA ve YSA ile tahmin edilen TÜFE'nin doğruluk testleri

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

**Şekil 4.19.** 2014 yılında gerçekleşen TÜFE değerleri ile YSA ve ARIMA modelleri karşılaştırmalı grafiği

2014 yılında gerçekleşen TÜFE değerleri ile Yapay Sinir Ağları ve ARIMA modeli ile yapılan sonuçları karşılaştıran yukarıdaki Şekil 4.19 incelendiğinde YSA modeli belirli bir düzen içerisinde yaz aylarında yükseliş öngörmektedir. Bu yükseliş her zaman aynı hacimde olmamasına rağmen YSA modelinde yaz aylarında gerçekleşen değerlerden sapma yüksek olmaktadır. ARIMA modeli gerçekleşen değerleri tam olarak

yakalayamamaktadır. Bununla birlikte belirli bir güven aralığı içerisinde gerçekleşen değerleri önemli ölçüde yakalamaktadır. Bu testte görüleceği üzere her iki modelde birbirlerine çok yakın sonuçlar vermiştir. Her ne kadar ARIMA modeli 2013 yılı verilerinde daha iyi performans göstermiş olsa da, örneklem dışı olan 2014 yılı verileri incelendiğinde YSA modelinin ARIMA modelini yakalamış olduğu dikkat çekmektedir.

## 5. SONUÇ ve ÖNERİLER

Enflasyon tahmini, bütün ülkeler için doğru tahmin edilmesi gereken önemli bir veridir. Yatırımcılar enflasyon verisi gibi önemli verilere dayanarak yatırımlarını şekillendirirler. Düşük enflasyon oranına sahip ülkelerde istikrar oranı yüksek olduğundan sıcak para akışı bu yöndeki ülkelere doğru olur. Türkiye gibi gelişmekte olan ülkelere yapılan yatırımlar ise faiz yüksekliği nedeniyle olmaktadır. Bu bakımdan faiz yüksekliği ülkenin ekonomik değerlerinin faiz olarak yurtdışına çıkmasına neden olmaktadır. Enflasyonun doğru tahmini ise istikrar ve şeffaflık olarak ülke kredibilitelerini artırmakla birlikte kademeli olarak faiz indirimi ile ülke kaynaklarının dışarı çıkması önlenmektedir.

Bununla birlikte enflasyon tahmini konusunda temel hedefte tutarsızlık bulunmaktadır. Enflasyon hedeflemesi için sayısal bir oran belirlenir ve merkez bankasının bu hedefe ulaşması görevi verilebilir. Bunun yanısıra bu hedefe ulaşabilmesi için bağımsızlığının ve şeffaflığının da artırılması gerekir. Ancak, 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 ama TÜFE içerisinde değerlendirilmektedir. Alkol ve tütün fiyatları kamu otoriteleri tarafından ayarlanmaktadır. Maliye Bakanlığı'nın bütçe için gerekli gördüğü takdirde tütün ve alkol fiyatlarında yukarı yönlü oynama yapması, 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 hedefleme bu büyüklük üzerine hedef konularak yapılabilir.

Bu çalışmada, zaman serilerinin tahmininde sıklıkla kullanılan yöntemlerden; yapay sinir ağları ve ARIMA modelleri ile tek değişkenli zaman serilerinin performansı karşılaştırılmıştır. Çalışmanın, 2003'ten itibaren TÜFE endeksinin hesaplama yönteminin değişmesi nedeniyle herhangi bir kırılmalığa uğramamış yeni veri seti ile hazırlanmış olması önem derecesini artırmaktadır. Model hazırlama aşamasında

2004:01 ve 2013:12 aralığındaki Tüketici Fiyat Endeksi verileri kullanılmıştır. Her iki çalışmadan alınan sonuçlar farklı tutarlılık göstergeleri ile karşılaştırılmıştır Her iki model sonuçları birbirine yakın seyretmekle beraber kullanılan ARIMA modelinin başarısı daha yüksek çıkmıştır. Çalışmada paket program olarak Matlab, Eviews 7, Minitab, SPSS ve Excel paket programları kullanılmıştır.

Çalışmadan elde edilen model geleceğe yönelik tahminlerde kullanılabilir. Tahmin aşamasında dikkat edilmesi gereken nokta tahminlerin kısa vadeli (12 aylık) periyotlar için yapılması gerektiğidir. Çünkü zaman serileri ile çalışma yaparken kısa dönemli tahminler verimli sonuçlar verirken, uzun dönemli tahminlerde hata payı ciddi biçimde yükselebilmektedir. Tang *et al.* (1991) ile Shabri (2001) çalışmalarıyla da benzerlik sergileyen bu çalışma sonuçlarına göre, ARIMA modellerinin kısa dönem öngörüler için, YSA'nın ise uzun dönem öngörüler için uygun olabileceğini söylenebilir.

## KAYNAKLAR

- Abdelmouez, G., Hashem, S. R., Atiya, A. F. and El-Gamal, M. A. 2007. Neural network vs. linear models for stock market sectors forecasting. Paper presented at the Neural Networks, 2007. IJCNN 2007. International Joint Conference on.
- Akgül, Ş. I., 2003. Geleneksel Zaman Serisi Yöntemleri. DER Yayınevi İstanbul.
- Al-Saba, T., El-Amin, I. 1999. Artificial neural networks as applied to long-term demand forecasting. *Artificial Intelligence in Engineering*, 13(2), 189-197.
- Aren, S. 2007. Ekonomi dersleri: İmge Kitabevi.
- Başol, K. 1994. Demografi: Anadolu Matbaası.
- Bilgili, F., 2001. Arima ve Var Modellerinin Tahmin Başarılarının Karşılaştırılması, Erciyes Üniversitesi, İ.İ.B.F. Dergisi, Sayı 17:37-53.
- Binner, J. M., Bissoondeal, R. K., Elger, T., Gazely, A. M. and 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), 665-680.
- Box, G. E., Jenkins, G. M. and Reinsel, G. C., 2009. Autocorrelation Function and Spectrum of Stationary Processes. *Time Series Analysis, Fourth Edition*, 21-46.
- Caire, P., Hatabian, G. and Muller, C., 1992. Progress in forecasting by neural networks. Paper presented at the Neural Networks, 1992. IJCNN., International Joint Conference on.
- Callen, J. L., Kwan, C. C., Yip, P. C. and Yuan, Y., 1996. Neural network forecasting of quarterly accounting earnings. *International Journal of Forecasting*, 12(4), 475-482.
- Cryer, J. D. and Chan, K. S. (2008). *Time series analysis: with applications in R*. Springer, 106-107.
- DeLurgio, S. A., 1998. *Forecasting principles and applications*.
- Eğilmez, M. ve Kumcu, E. 2005. *Ekonomi Politikası Teori ve Türkiye Uygulaması, Remzi Kitabevi, İstanbul*.
- Eğrioğlu, E. ve Aladağ, Ç., 2005. Yapay Sinir Ağları ve Arima Modellerinin Melez Yaklaşımı İle Zaman Serilerinde Öngörü, VII. Ulusal Ekonometri ve İstatistik Sempozyumu, İstanbul Üniversitesi.
- Elmas, Ç., 2012. *Yapay Zeka Uygulamaları, Yapay Sinir Ağları – Bulanık Mantık– Genetik Algoritma, Seçkin Yayınevi, Ankara*.
- Erdoğan, E., 2006. *Zaman Serilerinde Arima Modelleri, Yüksek Lisans Tezi, Muğla Sıtkı Koçman Üniversitesi, 142 s, Muğla*,
- Faraway, J. and Chatfield, C., 1998. Time series forecasting with neural networks: a comparative study using the air line data. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 47(2), 231-250.



- Fausett, L., 1994. *Fundamental of neural networks. Architecture, Algorithms, and Applications*, Prentice Hall.
- Giovanis, E., 2009. *Arima and Neural Networks: An Application to the Real GNP Growth Rate and the Unemployment Rate of USA*. Available at SSRN 1368675.
- Gujarati, D. N., 1995. *Basic econometrics, 3rd. International Edition*,(McGraw Hill, USA).
- Güneri N., Apaydın A., 2004. Öğrenci Başarılarının Sınıflandırılmasında Lojistik Regresyon Analizi ve Sınır Ağları Yaklaşımı. *Ticaret ve Turizm Eğitim Fakültesi Dergisi*, Sayı: 1, ss. 170-188.
- Hamzaçebi, C., Akay, D. and Kutay, F., 2009. Comparison of direct and iterative artificial neural network forecast approaches in multi-periodic time series forecasting. *Expert Systems with Applications*, 36(2), 3839-3844.
- Haykin, S., 1999. *Neural Networks A Comprehensive Introduction*: Prentice Hall, New Jersey.
- İnel, A. and Süalp, M. N. 2008. *An Analysis and Estimation of the Turkish Business Cycles by Neural Networks*. Marmara University Scientific Research Projects Unit, SOS-BGS-100105-055, Marmara University, İstanbul
- Kamruzzaman, J. and Sarker, R. A., 2003. Forecasting of currency exchange rates using ANN: A case study. Paper presented at the Neural Networks and Signal Processing, 2003. Proceedings of the 2003 International Conference on.
- Kara, H. and Orak, M. 2008. *Enflasyon Hedflemesi. Krizler, Para ve İktisatçılar*, Ed. Ercan Kumcu, Remzi Kitabevi 81-157, İstanbul
- Kayım, H., 1985. *İstatistiksel ön tahmin yöntemleri: Hacettepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi*.
- Kibritçioğlu, A., 2001. *Türkiye'de Ekonomik Krizler ve Hükümetler, 1969-2001*. <http://80.251.40.59/politics.ankara.edu.tr/kibritci/ytd-kibritcioglu.pdf> (04.05.2014).
- Kihoro, J., Otieno, R. and Wafula, C., 2004. Seasonal time series forecasting: a comparative study of ARIMA and ANN models. *AJST*, 5(2).
- Kohonen, T. 1982. Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 43(1), 59-69.
- Lewis, C. D., 1982. *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*: Butterworth-Heinemann.
- Lyziak, T., 2003. *Consumer inflation expectations in Poland*.
- Maier, H. R. and Dandy, G. C., 1996. The use of artificial neural networks for the prediction of water quality parameters. *Water resources research*, 32(4), 1013-1022.
- Montañés, E., Quevedo, J. R., Prieto, M. M. and Menéndez, C. O., 2002. Forecasting time series combining machine learning and Box-Jenkins time series *Advances in Artificial Intelligence—Iberamia 2002* (pp. 491-499): Springer.

- Montgomery, D. C., Johnson, L. A. and Gardiner, J. S., 1990. Forecasting and time series analysis: McGraw-Hill Companies.
- Moshiri, S. and Cameron, N., 2000. Econometrics versus ANN models in forecasting inflation. *Journal of Forecasting*, 19.
- Newbold, P., 1975. The principles of the Box-Jenkins approach. *Operational Research Quarterly*, 397-412.
- Özalp, A. ve Anagün, S., 2003. Yapay Sinir Ağı Performansına Etki Eden Faktörlerin Analizinde Taguchi Yöntemi: Hisse Senedi Fiyat Tahmini Uygulaması. *İstatistik Araştırma Dergisi*, 2(1), 29-45.
- Özatatay, F., 2011. Parasal iktisat: kuram ve politika: Efil Yayınevi.
- Özer, M. ve Türkyılmaz, S. 2005. Türkiye’de Enflasyon ile Enflasyon Belirsizliği Arasındaki İlişkinin Zaman Serisi Analizi. *İktisat, İşletme ve Finans Dergisi*, Nisan 2005, ss.93-104.
- Özmen, A., 1988. Anadolu Üniversitesi. Fen Edebiyat Fakültesi Dergisi, Eskişehir Cilt: 1.
- Öztemel, E., 2003. Yapay sinir ağları: Papatya Yayıncılık.
- Pankratz, A., 1983. Forecasting with Univariate Box-Jenkins Models: Concepts and Cases. John Wiley and Sons. Inc. USA.
- Pindyck, R. S. and Rubinfeld, D. L., 1998. Econometric models and economic forecasts (Vol. 4).
- Portugal, M. S., 1995. Neural networks versus time series methods: a forecasting exercise.
- Refenes, A. N., Azema-Barac, M., Chen, L. and Karoussos, S., 1993. Currency exchange rate prediction and neural network design strategies. *Neural Computing and Applications*, 1(1), 46-58.
- Rumelhart, D. E., Hinton, G. E. and Williams, R. J., 1986. Learning Internal Representations by Error Propagation, *Parallel Distributed Processing, Explorations in the Microstructure of Cognition*, ed. DE Rumelhart and J. McClelland. Vol. 1. 1986: Cambridge, MA: MIT Press.
- Samuelson, P. A. 1992. Economics: McGraw-Hill New York etc.
- Sevüktekin, M. ve Nargeleçekenler, M., 2010. Ekonometrik Zaman Serileri Analizi EViews Uygulamalı, Geliştirilmiş 3. Baskı, Nobel Yayın Dağıtım, Ankara.
- Shabri, A., 2001. Comparison of time series forecasting methods using neural networks and Box-Jenkins model. *Matematika*, 17(1), 1-6.
- Sharda, R. and Patil, R. 1990. Neural networks as forecasting experts: an empirical test. Paper presented at the Proceedings of the International Joint Conference on Neural Networks.
- Srinivasan, D., Liew, A. and Chang, C., 1994. A neural network short-term load forecaster. *Electric Power Systems Research*, 28(3), 227-234.

- Swanson, N. R. and White, H., 1997. A model selection approach to real-time macroeconomic forecasting using linear models and artificial neural networks. *Review of Economics and Statistics*, 79(4), 540-550.
- TCMB, EVDS, <http://evds.tcmb.gov.tr> (12.07.2014).
- TCMB, 2015. <http://www.tcmb.gov.tr/wps/wcm/connect/33b1cba7-cb43-4dc5-bb5c-e6e3960ef964/enflasyon.pdf?MOD=AJPERES&CACHEID=33b1cba7-cb43-4dc5-bb5c-e6e3960ef964> (06.06.2014)
- Tang, Z., de Almeida, C. and Fishwick, P. A., 1991. Time series forecasting using neural networks vs. Box-Jenkins methodology. *Simulation*, 57(5), 303-310.
- Tsay, R. S., 2005. *Analysis of financial time series (Vol. 543)*: John Wiley and Sons.
- Ture, M. and Kurt, I., 2006. Comparison of four different time series methods to forecast hepatitis A virus infection. *Expert Systems with Applications*, 31(1), 41-46.
- TÜİK, <http://www.tuik.gov.tr/PreHaberBultenleri.do?id=18527> (02.02.2015)
- Venugopal, V. and Baets, W., 1994. Neural networks and statistical techniques in marketing research: A conceptual comparison. *Marketing Intelligence and Planning*, 12(7), 30-38.
- Vogelvang, B., 2005. *Econometrics: theory and applications with Eviews*: Pearson Education.
- Witt, S. F. and Witt, C. A., 1992. *Modeling and forecasting demand in tourism*: Academic Press Ltd.
- Yaffee, R. A. and McGee, M., 2000. *An introduction to time series analysis and forecasting: with applications of SAS® and SPSS®*: Academic Press.
- Yildiz, B., 2001. Use of artificial neural networks in prediction of financial failures. *Journal of IMKB*, 5(17).
- Yıldız, B., Doğanay, M. ve Aktaş, R., 2003. Mali Başarısızlığın Öngörülmesi: İstatistiksel Yöntemler ve Yapay Sinir Ağı Karşılaştırılması. *Ankara Üniversitesi, Siyasal Bilgiler Fakültesi Dergisi*, Cilt: 58, Sayı: 4, s. 1-24
- Zhao, Z. Q., 2009. A novel modular neural network for imbalanced classification problems. *Pattern Recognition Letters*, 30(9), 783-788.
- Zou, H., Xia, G., Yang, F. and Wang, H., 2007. An investigation and comparison of artificial neural network and time series models for Chinese food grain price forecasting. *Neurocomputing*, 70(16), 2913-2923.

## ÖZGEÇMİŞ

21.03.1984 tarihinde Ankara'da doğdu. Ortaokul ve liseyi Yıldırım Beyazıt Anadolu Lisesi'nde tamamladı. 2008 yılında Kocaeli Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü'nden, 2013 yılında Anadolu Üniversitesi Açıköğretim Fakültesi İşletme Bölümü'nden mezun oldu. Aynı yıl Atatürk Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı'nda yüksek lisans öğrenimine başladı. Halen Türkiye Cumhuriyet Merkez Bankası Erzurum Şubesi'nde Şef Yardımcısı olarak görev yapmaktadır. Evli ve bir çocuk babasıdır.