



**T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI**

**BOX-JENKINS VE YAPAY SİNİR AĞI YÖNTEMLERİ İLE
HAVALİMANI YOLCU TALEBİ ÖNGÖRÜLENMESİ:
ANTALYA HAVALİMANI ÖRNEĞİ**

**Hakan BOZDAĞ
YÜKSEK LİSANS TEZİ**

**Tez Danışmanı:
Prof. Dr. Abdullah EROĞLU**

ISPARTA 2011

T.C
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
MÜDÜRLÜĞÜ

TEZ SAVUNMASI ve SÖZLÜ SINAV TUTANAĞI

Gönderen : Ekonometri EABD Başkanlığı

Gönderilen : Sosyal Bilimler Enstitüsü Müdürlüğü

Enstitü Anabilim Dalımız **YÜKSEK LİSANS** Programı öğrencisi Hakan BOZDAĞ tez çalışmalarını sonuçlandırmış ve kurulan jüri önünde tezini savunmuştur. Sınav tutanağı aşağıdadır.
Tez Adı Değişikliği **YAPILDI**

Tarih
07/07/2011

Enstitü Anabilim Dalı Başkanı

SINAV TUTANAĞI:

Jürimiz Lisansüstü Öğretim Yönetmeliği'nin 25./39. maddesi uyarınca 07/07/2011 Perşembe günü saat 10.00 'de toplanmış ve yukarıda adı geçen öğrencinin **BOX-JENKİNS VE YAPAY SİNİR AĞI YÖNTEMLERİ İLE HAVALİMANI YOLCU TALEBİ ÖNGÖRÜLENMESİ: ANTALYA HAVALİMANI ÖRNEĞİ** konulu tezini incelemiş ve yapılan sözlü sınav sonunda **OYBİRLİĞİ / OYÇOKLUĞU** ile aşağıdaki kararı almıştır.

☒ KABUL

☐ RED

☐ DÜZELTME

Tez Sınavı Jürisi	Ünvanı, Adı Soyadı	İmza
Başkan	Prof. Dr. Abdullah EROĞLU	
Üye	Doç. Dr. Şeref KALAYCI	
Üye	Yrd. Doç. Dr. Hakan DEMİRGİL	
Üye		
Üye		

Yukarıda adı geçen öğrenci Sınav Tutanağı'nda belirtildiği üzere mezun olmaya **HAK KAZANMIŞTIR / KAZANMAMIŞTIR.**
Gereğini rica ederim.

ENSTİTÜ YÖNETİM KURULU KARARI :

Tarih:

Karar No:

Enstitü Müdürü

MADDE-25 Tez Sınavının tamamlanmasından sonra Jüri tez hakkında salt çoğunlukla "KABUL", "RED", veya "DÜZELTME" kararı verir. Bu karar, Enstitü Anabilim Dalı Başkanlığınca tez sınavını izleyen üç gün içinde ilgili Enstitüye tutanakla bildirilir. Tezi reddedilen öğrencinin **Enstitü ile ilişkisi kesilir.** Tezi hakkında düzeltme kararı verilen öğrenci en geç **üç ay içinde** gereğini yaparak tezini aynı jüri önünde yeniden savunur. Bu savunma sonunda da tezi kabul edilmeyen öğrencinin Enstitü ile ilişkisi kesilir. Düzeltme alan öğrenci **bir sonraki dönemde kayıt yaptırmak** zorundadır.

Madde-39 Tez Sınavının tamamlanmasından sonra Jüri tez hakkında salt çoğunlukla "KABUL", "RET" veya "DÜZELTME" kararı verir. Bu karar, Anabilim Dalı Başkanlığınca tez sınavını izleyen üç gün içinde ilgili Enstitüye tutanakla bildirilir. Tezi reddedilen öğrencinin Yüksek Öğretim Kurumu ile ilişkisi kesilir. Tezi hakkında düzeltme kararı verilen öğrenci en geç **altı ay içinde** gereğini yaparak tezini aynı jüri önünde yeniden savunur. Bu savunma sonunda da tez kabul edilmeyen öğrencinin Enstitü ile ilişkisi kesilir.



T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
Sosyal Bilimler Enstitüsü Müdürlüğü

YEMİN METNİ

Yüksek Lisans/ Doktora tezi olarak sunduğum

“BOX-JENKINS VE YAPAY SİNİR AĞI YÖNTEMLERİ İLE HAVALİMANI YOLCU TALEBİ ÖNGÖRÜLENMESİ: ANTALYA HAVALİMANI ÖRNEĞİ” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadar ki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim.



İmza

Hakan BOZDAĞ

07/07/2011

ÖZET
BOX-JENKINS VE YAPAY SİNİR AĞI YÖNTEMLERİ İLE HAVALİMANI
YOLCU TALEBİ ÖNGÖRÜLENMESİ:
ANTALYA HAVALİMANI ÖRNEĞİ

Hakan BOZDAĞ

Süleyman Demirel Üniversitesi, Ekonometri Anabilim Dalı

Yüksek Lisans Tezi, 98 Sayfa, Haziran 2011

Danışman: Prof. Dr. Abdullah EROĞLU

Bu çalışmada tek değişkenli zaman serisi yöntemi "Mevsimsel Box- Jenkins (SARIMA)" ve "Yapay Sinir Ağları" yöntemlerinin kestirim doğruluklarını karşılaştırarak en yüksek doğruluğu sağlayan yöntemin belirlenmesi ve belirlenen yöntem yardımıyla 2011 yılı için Antalya Havalimanı' na yönelik kısa dönem uluslararası yolcu talebinin öngörülenmesi amaçlanmıştır. Araştırmada, havalimanının yolcu talebinin ölçüsü olarak havalimanından giriş yapan toplam uluslararası yolcu sayısı alınmış ve Ocak 2004-Aralık 2010 döneminde Antalya Havalimanı dış hatlar terminalinden giriş yapan aylık uluslararası yolcu sayısı verilerinden yararlanılmıştır.

Uygulanan yöntemlerden elde edilen kestirim sonuçlarının değerlendirilmesi sonucunda, "Mevsimlik Çarpımsal-Mevsimsel Box-Jenkins (SARIMA)" yöntemi ile yapılan öngörülerin oldukça iyi sonuçlar verdiği ancak çalışmada kullanılan yöntemler içerisinde en yüksek kestirim doğruluğunu sağlayan ve gerçek değerlere en yakın sonuçlar veren yöntemin "Yapay Sinir Ağları" olduğu görülmüştür. Serinin yapay sinir ağları ile modellenmesinde orjinal serinin farklı ağ yapıları incelenmiştir. Yapılan çok sayıda deneme sonucunda 12 gecikmeli yapay sinir ağı modelinin en yüksek doğruluğu sağladığı görülmüş ve elde edilen model yardımıyla Ocak 2011-Aralık 2011 dönemi için Antalya Havalimanı' na yönelik kısa dönem uluslararası yolcu talebi öngörüsü gerçekleştirilmiştir.

Anahtar Kelimeler: Zaman Serileri, SARIMA Modelleri, Yapay Sinir Ağları, Havalimanı Yolcu Talebi, Öngörü

ABSTRACT**FORECASTING AIR PASSENGER DEMAND BY BOX-JENKINS AND
ARTIFICIAL NEURAL NETWORKS METHODS:
A CASE STUDY OF ANTALYA AIRPORT****Hakan BOZDAĞ****Suleyman Demirel University, Department of Econometrics****Master Thesis 98 Pages, July 2011****Supervising Professor: Prof. Dr. Abdullah EROĞLU**

In this study it is aimed to compare estimation accuracies of univariate time series method "Seasonal Box-Jenkins (SARIMA)" and "Artificial Neural Network" methods and detect which method has the highest accuracy and with this method to foresight the short term international passenger demand of Antalya International Airport for 2011. In this research it is used the total number of international passenger arrivals as a measure of inbound international passengers demand and monthly international passenger arrivals to Antalya in the period of January 2004 – December 2010 data were utilized to build appropriate model.

As a conclusion of the assesment of experimental results, it has been observed that forecasts by the methods “multicaptive-seasonal Box Jenkins (SARIMA)” has provided quite good results and on the other hand artificial neural network model has showed best forecast accuracy with lowest deviation among the techniques applied in this research. In the process of modelling the number of foreign tourist data by artificial neural networks, different network structures of the original series have been analyzed. As a consequence of several attempts it has been observed that 12 lagged artificial neural network model has presented best performance and by the means of this model it has been forecasted the monthly inbound tourism demand to Antalya for January 2011 and December 2011.

Keywords: Time Series, SARIMA Models, Artificial Neural Networks, Airport Passangers Demand, Forecast

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT	ii
İÇİNDEKİLER.....	iii
KISALTMALAR DİZİNİ.....	vii
ŞEKİLLER DİZİNİ.....	ix
TABLolar DİZİNİ.....	x
GİRİŞ	1

BİRİNCİ BÖLÜM

ZAMAN SERİLERİ ANALİZİ

1.1. Zaman Serileri ve Zaman Serileri Analizinin Tanımı	5
1.2. Zaman Serileri Analizinin Tarihsel Gelişimi	6
1.3. Zaman Serisinin Özellikleri	7
1.3.1. Dört Unsurdan Meydana Gelme Özelliği.....	7
1.3.2. İç Bağımlılık Özelliği	9
1.3.3. Stokastik Süreç Olma Özelliği.....	9
1.4. Zaman Serilerinin Sınıflandırılması.....	10
1.4.1. Sürekli ve Kesikli Zaman Serileri	10
1.4.2. Durağan ve Durağan-Dışı Zaman Serileri	11
1.4.2.1. Zayıf Güçlü ve Kesin Durağanlık	11
1.4.2.2. Durağan-Dışı Zaman Serileri.....	13
1.4.3. Mevsimsel ve Mevsimsel Olmayan Zaman Serileri	13
1.5. Zaman Serisi Analizinde Kullanılan İstatistiksel Araçlar	14
1.5.1. Otokovaryans Fonksiyonu.....	14
1.5.2. Otokorelasyon Fonksiyonu	15

1.5.3. Kısmi Otokorelasyon Fonksiyonu	16
1.5.4. Zaman Serisi Grafiği ve Korelogramı.....	17
1.6. Durağan ARIMA Modelleri.....	18
1.6.1. Otoregresif Modeller	18
1.6.2. Hareketli Ortalama Modelleri.....	20
1.6.3. Otoregresif Hareketli Ortalama Modelleri.....	21
1.7. Durağan-Dışı ARIMA Modelleri.....	22
1.8. ARIMA Model Kurma Süreci: Box-Jenkins Yaklaşımı	24
1.8.1. Modelin Belirlenmesi	25
1.8.2. Model Parametrelerinin Tahmini	27
1.8.3. Modelin Uygunluğunun Test Edilmesi.....	28
1.8.3.1. Model Seçim Kriterleri	30
1.8.4. İleriye Yönelik Öngörü (Tahmin)i	28
1.9. Mevsimsel ARIMA Modelleri.....	32
1.9.1. Mevsimsel Otoregresif Modeller	33
1.9.2. Mevsimsel Hareketli Ortalama Modeli.....	34
1.9.3. Mevsimsel Otoregresif Hareketli Ortalama Modeli	35
1.9.4. Mevsimsel Bütünleşik Otoregresif Hareketli Ortalama Modeli	36
1.9.5. Mevsimsel Mevsimsel Box-Jenkins Yaklaşımı Aşamaları.....	38
1.10. Öngörü (Tahmin)	39
1.10.1. Performans Ölçütü.....	40

İKİNCİ BÖLÜM

YAPAY SİNİR AĞLARI

2.1. Yapay Sinir Ağlarının Tanımı	44
2.2. Yapay Sinir Ağlarının Tarihçesi.....	45

2.3. Biyolojik Bir Beyin Sinir Hücresinin Yapısı	46
2.4. Yapay Sinir Hücresi.....	46
2.5. Yapay Sinir Ağlarının Genel Özellikleri	49
2.6. Yapay Sinir Ağlarının Yapısı.....	50
2.7. Yapay Sinir Ağlarının Temel Elemanları	52
2.8. Yapay Sinir Ağlarında Öğrenme.....	54
2.8.1. Danışmanlı Öğrenme	55
2.8.2. Danışmansız Öğrenme.....	57
2.8.3. Takviyeli Öğrenme	58
2.9. Yapay Sinir Ağı Mimarileri.....	58
2.9.1. İleri Beslemeli Yapay Sinir Ağı Mimarileri.....	58
2.9.2. Geri Beslemeli Yapay Sinir Ağı Mimarileri.....	59

ÜÇÜNCÜ BÖLÜM

BOX-JENKİNS VE YSA YÖNTEMLERİ KESTİRİMLERİNİN KARŞILAŞTIRILMASI

ANTALYA HAVALİMANI' NIN KISA DÖNEM ULUSLARARASI YOLCU TALEBİNİN ÖNGÖRÜLENMESİ

3.1. Literatür Araştırması.....	61
3.2. Araştırmanın Amacı ve Araştırma Alanının Seçimi.....	68
3.3. Araştırmada Kullanılan Veriler	69
3.4. Araştırmanın Yöntemi.....	69
3.5. Araştırma Bulguları.....	70
3.5.1. Mevsimsel Box-Jenkins Yönteminin Uygulanması.....	70
3.5.2. Yapay Sinir Ağı Yönteminin Uygulanması.....	81
3.5.3. Yöntemlerin Karşılaştırılması ve Öngörü	84
SONUÇ VE ÖNERİLER.....	86

KAYNAKÇA.....	88
EKLER.....	93
ÖZGEÇMİŞ	98

KISALTMALAR DİZİNİ

a.g.e.	adı geçen eser
ADF	Augmented Dickey – Fuller
AIC	Akaike Information Criterion
ANN	Artificial Neural Networks (Yapay Sinir Ağları)
AR	Otoregresif Süreç
ARMA	Otoregresif Hareketli Ortalama Süreci
ARIMA	Otoregresif Bütünleşik Hareketli Ortalama Süreci
EKK	En Küçük Kareler
KOKF	Kısmi Oto Korelasyon Fonksiyonu
KOKK	Kısmi Oto Korelasyon Katsayısı
MA	Hareketli Ortalama Süreci
OMH	Ortalama Mutlak Hata (Mean Absolute Error)
OMYH	Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
OYH	Ortalama Yüzde Hata (Mean Percentage Error)
HKO	Hata Kareleri Ortalaması (Mean Squared Errors)
OKF	Oto Korelasyon Fonksiyonu
OKK	Oto Korelasyon Katsayısı
KOKH	Kök Ortalama Kare Hata(Root Mean Squared Errors)
s.	Sayfa
SAR	Mevsimsel Otoregresif Süreç
SARMA	Mevsimsel Otoregresif Hareketli Ortalama Süreci
SARIMA	Mevsimsel Otoregresif Entegre Hareketli Ortalama Süreci
SBC	Schwarz Bayesian Criterion
Seri1	Orjinal seri değerlerinin 12 aylık kaydırılması ile elde edilen eğitim seti
Seri2	Orjinal seri değerlerinin 24 aylık kaydırılması ile elde edilen eğitim seti
Seri3	Orjinal seri değerlerinin 36 aylık kaydırılması ile elde edilen eğitim seti

SMA	Mevsimsel Hareketli Ortalama Süreci
YSA	Yapay Sinir Ağları
vd.	ve diğerleri

ŞEKİLLER DİZİNİ

	sayfa no
Şekil 1.1.Box-Jenkins Yöntemi Uygulama Aşamaları.....	25
Şekil 2.1. Biyolojik Sinir Hücresi ve Bileşenleri.....	47
Şekil 2.2.Yapay Sinir Hücresi (Nöron).....	48
Şekil 2.3. Çok Katmanlı Bir Yapay Sinir Ağ Yapısı.....	51
Şekil 2.4. Danışmanlı Öğrenme.....	56
Şekil 2.5. Danışmansız Öğrenme.....	57
Şekil 2.6. Çok Katmanlı İleri Beslemeli Bir Sinir Ağı Yapısı.....	59
Şekil 2.7. Çok Katmanlı Geri Beslemeli Bir Sinir Ağı Yapısı.....	60
Şekil 3.1. Antalya Havalimanı Uluslararası Yolcu Serisi Grafiği.....	71
Şekil 3.2. LnANT Serisi Zaman Grafiği.....	72
Şekil 3.3.ΔΔ 12 LnANT Serisinin Zaman Yolu Grafiği.....	76
Şekil 3.4. Denemeler Sonucunda Elde Edilen YSA Modeli.....	84

TABLOLAR DİZİNİ

	sayfa no
Tablo 1.1. Box-Jenkins Modellerinde OKF ve KOKF'ların Seyri.....	27
Tablo 2.1. Biyolojik Sinir İle Yapay Sinir Ağının Karşılaştırılması.....	54
Tablo 3.1. LnANT Serisinin Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları.....	72
Tablo 3.2. Δ LnANT Serisinin Korelogramı.....	74
Tablo 3.3. Δ LnANT Serisinin Genişletilmiş Dickey-Fuller Testi Sonuçları.....	75
Tablo 3.4. $\Delta\Delta$ 12 LnANT Serisinin Korelogramı.....	77
Tablo 3.5. Belirlenen Aday Modeller.....	78
Tablo 3.6. Aday Modellerin Seçim Kriter Değerleri.....	79
Tablo 3.7. SARIMA (1,1,0) (0,1,1) Model Parametreleri.....	76
Tablo 3.8. Model Artıklarına Ait Korelogramları.....	80
Tablo 3.9. Farklı Mimarilere Sahip YSA Modelleri ile Yapılan Deneme Sonuçları.....	83
Tablo 3.10. Yöntemlerin Öngörü Doğruluklarının Karşılaştırılması.....	81
Tablo 3.11. 2011 Yılı İçin Antalya Havalimanı Uluslararası Yolcu Talebi Öngörüsü Değerleri.....	85

GİRİŞ

Öngörü (kestirim), temelde bir niceliğin zamanın gelecekteki bir noktasında alacağı değerinin kestirimi olarak tanımlanmaktadır.¹ Zaman serileri analizi, istatistik teknikler içinde çok önemli yeri olan kestirim teknikleri arasında geniş yer tutmaktadır. Geçmiş dönemlerin çeşitli yöntemlerle incelenmesiyle elde edilen bilgilerin geleceğin tahminlenmesinde kullanılan teknikler, özellikle kısa, orta ve uzun dönem tahminlerine gereksinim duyulan her alanda kullanılmaktadır. Bilinmeyen geleceğin bilimsel yöntemlerle kestirilmesi ve gelecek için önceden hazırlıkların yapılması her alanda olduğu gibi özellikle ekonomi ve finans sektöründe büyük önem taşımaktadır.

Zaman serileri, değişkenlerin gün, hafta, ay, mevsim veya yıl gibi herhangi bir zaman birimine göre dağılımını belirten serilerdir. Zaman serileri Box-Jenkins (1970) ile önem kazanmıştır. Temel prensipleri Yule tarafından 1920'lerde ortaya atılan yöntem, gelişen bilgisayar olanakları sayesinde yöntemin yaygınlaşmasını kolaylaştırmıştır. Temel prensip her dizinin geçmiş değerleri ile açıklanabileceği mantığına dayanmaktadır.²

Kestirim yöntemleri, nitel kestirim yöntemleri ve nicel kestirim yöntemleri olmak üzere iki şekilde sınıflandırılabilir. Her iki yöntemin çıkış noktası ilgili değişkene ait gözlem değerleridir. Geçmiş ve şimdiki dönem gözlem değerlerinden, gelecek dönem gözlem değerleri belirli kurallar çerçevesinde öngörülür.

Nitel kestirim yöntemleri genellikle öngörü yapılmak istenen konuda geçmişe yönelik yeterli gözlem değerinin olmadığı, öngörünün öznel uzman görüşü ile yapıldığı tekniklerdir.

¹FRETCHLING, D. C., **Forecasting Tourism Demand: Methods and Strategies**, Butterworth-Heinemann, 2001, s. 8

²ORHUNBİLGE, N., **Zaman Serileri Analizi Tahmin ve Fiyat Endeksleri**, İstanbul Üniversitesi İşletme Fakültesi Yayınları, No: 277, İstanbul, 1999, s. 1-2

Nicel kestirim yöntemleri ise istatistiksel yöntemlere dayanır. Nicel kestirim yöntemlerinde nasıl kestirimde bulunulduğu net olarak bellidir ve işlemler matematikselidir. Geçmiş gözlem değerleri kullanılarak sürecin oluşmasına katkıda bulunan ilişkiler belirlenir ve bu ilişkilerin geleceğe yansımaları belirlenmeye çalışılır. Nicel kestirimde bulunabilmek için iki temel yaklaşım kullanılmaktadır. Bunlardan birincisi neden-sonuç ilişkisine dayanan modeller ikincisi ise zaman serileri analizine dayalı modellerdir.³

Neden sonuç ilişkisine dayanan kestirim yöntemleri, regresyon yöntemi ve ekonometrik modellerdir. Regresyon yöntemi, bir ya da daha fazla değişkenin üzerinde etkili olduğu başka bir değişkenle aralarındaki ilişkinin matematiksel olarak ifade edildiği yöntemlerdir. Bu tür yöntemlerde, etkilenen değişkene bağımlı değişken ve etkileyen değişkenlere de bağımsız değişkenler adı verilir. Bağımlı değişken ile bağımsız değişkenler arasındaki neden sonuç ilişkisi geçmiş gözlem değerleri kullanılarak belirlenir. Bağımsız değişkenlerin gelecekteki çeşitli değerleri için bağımlı değişkenin alacağı değer kestirilmeye çalışılır. İlişkiye dayanan tekniklerin uygulanmasında birden çok değişkene ait bilgiye gerek duyulduğu için kullanımı daha güçlü bir tekniktir.⁴

Zaman serileri kullanarak öngörü yapılırken, ilk olarak zaman serisi için uygun bir model belirlenmeye çalışılır. Daha sonra ele alınan seri için en iyi öngörü değerinin nasıl elde edileceği araştırılır. Box-Jenkins, zaman serisinin analizi amacı ile ARIMA modelleri olarak bilinen modellerin kullanımını önermişler; uygun modelin belirlenmesi ve tahmini için bir yaklaşım geliştirmişlerdir.⁵

Öngörü modellemesinde büyük ölçekli yapısal makroekonometrik modeller, asit regresyon modelleri ve VAR modelleme tekniği gibi istatistiksel ve ekonometrik

³MONTGOMERY vd., **Introduction To Time Series Analysis And Forecasting**, John Wiley & Sons. Inc., Hoboken. New Jersey, 2008, s. 3-4

⁴ORHUNBİLGE, N., a.g.e., s. 3

⁵MONTGOMERY vd., a.g.e., s. 3-4

modellerin yanı sıra bazı yeni metodolojiler de ön plana çıkmaktadır. Yapay Sinir Ağları yöntemi bu yeni teknikler arasında en önemlilerinden birisidir.

Yapay Sinir Ağları modelleme tekniği günümüzde bir çok alanda yaygın bir şekilde kullanılan, basit bir şekilde insan beyninin çalınma şeklini taklit eden yapay sinir ağları Yapay Zeka çalışmaları içinde önemli bir yere sahiptir. "Evrensel Fonksiyon Yakınsayıcı Yöntem" olarak tanımlanan yapay sinir ağları metodolojisi verilerden öğrenebilme, genelleme yapabilme, sınırsız sayıda değişkenle çalışabilme gibi pek çok önemli özelliğinden dolayı pek çok alanda kullanım alanı bulan yapay sinir ağları yöntemi öngörü modellemesi alanında da yaygın bir şekilde kullanılmaktadır.⁶

Bu çalışmada Yapay Sinir Ağları metodolojisi ile geliştirilen model ile zaman serileri analizinde kısa dönem öngörü başarısı yüksek olarak kabul edilen, sıklıkla kullanılan Box-Jenkins ARIMA modelleri yönteminin genel tanımlamaları yapılarak, gerçek veri uygulaması üzerinden elde edilen performans istatistikleri yardımı ile modeller karşılaştırılacaktır. YSA ile bulunan sonuçların etkinliği, literatüre uygun şekilde, Box-Jenkins modelleri sonuçları ile karşılaştırılarak araştırılmıştır. Box-Jenkins modellerinin geniş kabul görmesi, geliştirilen her yeni model için iyi bir karşılaştırma aracı olmalarını sağlamıştır.

Çalışma üç ana bölümden oluşmaktadır.

Birinci bölümde, zaman serisi analizi, alt bölümler halinde ifade edilmiştir. İlk olarak zaman serisi ve analizi tanımlanmış, özellikleri ve tarihsel gelişimi açıklanmıştır. Sonrasında zaman serisi analizinde kullanılan araçlar hakkında bilgi verilmiş, Box-Jenkins modelleri ele alınmış ve son olarak zaman serisi ile öngörü ve öngörü performansının değerlendirme ölçütlerine değinilmiştir.

⁶YURTOĞLU, H., **Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği**, Yayınlanmış Uzmanlık Tezi, DPT, 2005, s. 1-2

İkinci bölümde, üçüncü bölümde yapılan uygulama için gerekli olan yapay sinir ağları metodolojisi hakkında bilgi verilmiştir. Yapay sinir ağları tanımlanmış, fizyolojik ve temel yapısı ifade edilmiştir. Sonrasında yapay sinir ağları ile ilgili genel kavramlar, yapay sinir ağları tarihçesi, genel özellikleri, yapay sinir ağlarının yapısı, temel elemanları, yapay sinir ağlarının sınıflandırılması, yapay sinir ağları mimarileri hakkında bilgi verilmiştir.

Üçüncü bölümde, ilk olarak dünyada ve Türkiye’ de bugüne kadar yapılmış olan çalışmaların literatür özetleri verilmiştir. Antalya Havalimanı’ nın kısa dönem uluslararası yolcu talebinin öngörülenmesinde hem Box-Jenkins modelleri hem de yapay sinir ağları yöntemi ele alınmıştır. Öncelikle Ocak 2004-Aralık 2009 dönemine ait Antalya Havalimanı’ nın uluslararası yolcu verisi değerleri zaman serisi olarak ele alınmış ve Box-Jenkins ARIMA modeli kullanılarak Ocak 2010-Aralık 2010 dönemine ait Antalya Havalimanı’ nın uluslararası yolcu talebi kestirimi gerçekleştirilmiştir. Sonrasında yapay sinir ağları yöntemi kullanılarak uygun model mimariye sahip YSA belirlenmiş ve aynı dönem için kestirimde bulunulmuştur. Elde edilen sonuçlar için Kök Ortalama Hata Kare (KOHK) ve Ortalama Mutlak Yüzde Hata (OMYH) değerleri hesaplanmış ve bulunan değerler karşılaştırılarak öngörü için yapay sinir ağlarının kullanılabileceği gösterilmiştir. Son olarak elde edilen bulgular değerlendirilmiştir.

BİRİNCİ BÖLÜM

ZAMAN SERİLERİ ANALİZİ

Bu bölümde zaman serileri ve analizinin tanımı, zaman serileri analizinin tarihsel gelişimi, zaman serilerinin özellikleri, zaman serileri analiz araçları, durağan ARIMA modelleri, durağan-dışı ARIMA modelleri ile Box-Jenkins model kurma stratejisi, ve son olarak da öngörü ve öngörü modelinin performans ölçütlerine değinilmiştir.

1.1. Zaman Serileri ve Zaman Serileri Analizinin Tanımı

Zaman serileri ilgilenilen gözlem değerlerinin belirli bir dönem için gün, hafta, ay, üç ay, yıl gibi birbirini izleyen eşit periyotlarla yapılması ile elde edilen sayısal serilerin tümü zaman serileri olarak adlandırılmaktadır. İncelenen zaman serisi Y_t ile simgelenildiğinde gözlemlerde $t = 1, 2, \dots, T$ olmak üzere $Y_1, Y_2, Y_3, \dots, Y_T$ şeklinde ifade edilebilirler. Burada ilgilenilen değişkenin gözlenen değerleri için t zaman aralığını, Y_t ise değişkenin t . dönemindeki gözlem değerini göstermektedir.⁷

Zaman serilerinin unsurlarına ayırma, aralarındaki ilişkiyi açıklama, kontrol ve öngörü amacı ile analiz edilmesine zaman serisi analizi denir.⁸

Zaman serilerinin analizinde temel olarak, bir tek serinin modellenebilmesi için uygun teknikler üzerinde durulur. Tek değişkenli modellerde incelenecek değişkenin açıklanması, serinin kendi geçmiş değerleri, cari ve geçmiş dönem rassal

⁷ AKGÜL, I., a.g.e., s. 3

⁸ BOX vd. “**Time Series Analysis: Forecasting and Control**”, Prentice-Hall Inc., New Jersey, 1994, s. 1

artıklarının ağırlıklı toplamı kullanılabilmektedir. Zaman serisi modellerinin uygulamalarda veri gereksiniminin ekonometrik modellere göre az olması, model oluşturma daha kolay olması, değişkenlere ait ön bilgilere (tanımlamalara) ihtiyaç duyulmaması ve kısa dönemli tahminler sağlama zaman serisi modellerinin yaygın olarak kullanılmasını sağlamıştır.⁹

1.2. Zaman Serisi Analizinin Tarihsel Gelişimi

Zaman serileri doğa bilimlerinin gelişiminde önemli bir rol oynamıştır. Babıl uygarlığı döneminde yıldızlar ve gezegenlerin hareketleri ve ilgili konumlarını tahmin etmek amacıyla zaman serileri kullanılmıştır. Johannes Kepler tarafından keşfedilen yasalarının temelini oluşturmuştur.

19. yüzyılın ortalarında, astronomi alanında kullanılan zaman serisi metodolojik yaklaşımı, ekonomist Charles Babbage ve William Stanley Jevons tarafından ele alınmıştır. Farklı nedensel faktörlere bağlı, farkedilmemiş bileşenlerine ayrışması, genellikle klasik zaman serileri analizi kullanılan yöntemler WARREN M. PERSONS (1919) tarafından geliştirilmiştir.

1970'li yıllardan bu yana, tamamen farklı bir yaklaşım zaman serilerinin istatistiksel analize uygulanmıştır. Klasik zaman serileri analizindeki tamamen açıklayıcı yöntem terk edilerek, yerine, sonuçlar, olasılık kuramı ve matematiksel istatistik yöntemleri kullanılmaya başlanmıştır. Bu zaman serileri ile ilgili stokastik hareketlerin rolü farklı bir değerlendirmeye yol açmıştır. Klasik zaman serisi yapısında bir önemi olmayan artıklar (kalıntılar) hareketleri, modern yaklaşım bir zaman serisinin tüm bileşenlerine stokastik etkileri olduğunu varsayar.

Bu yönde ilk adımları geçen yüzyılın başında Rus istatistikçi Evgenij Evgenievich SLUTZKY ve İngiliz istatistikçi George Udy YULE tarafından başlatılmış-

⁹ AKGÜL, I., a.g.e., s. XI-XII

tır. Ekonomik zaman serilerinin de diğer zaman serileri ile benzer olarak ağırlıklı veya ağırlıksız toplamalar veya pür rastsal süreçlerin farklılıkları kullanılarak ekonemik zaman seilerinin oluşturulabileceğini gösterdiler. E. E. SLUTZKY ve G.U. YULE tarafından zaman serisi modellerini temsil etmek üzere hareketli ortalamalar ve otoregresif süreç geliştirildi. Herman WOLD (1938) bu yöntemleri sistemleştirdi. GEORGE E.P BOX ve M. Gwilym JENKINS (1970) tarafından yöntemlerin uygulanabilirliğini kolaylaştırmak için yeni bir yaklaşım geliştirilmiştir.

1980' li yıllara kadar dikkate alınmayan zaman serilerinde durağanlık kavramı incelenmeye başlamıştır. Durağanlığın, sadece deterministik değil, aynı zamanda stokastik trende sahip durağan olmayan zaman serileri artık filtre uygulaması ile sabit modellere çevrilerek, durağanlık sorunu çözülmeye başlamıştır.¹⁰

1.3. Zaman Serisinin Özellikleri

Zaman serisinin özellikleri; dört unsurdan meydana gelme, iç bağımlılık ve stokastik süreç olma özellikleri olmak üzere üç grupta ifade edilebilir. Bu özellikler ilerleyen alt bölümlerde açıklanmaya çalışılmıştır.

1.3.1. Dört Unsurdan Meydana Gelme Özelliği

Bir zaman serisi trend (T), konjoktür (K), Mevsim (M) ve Rassal haterketler (R) özellikleri kullanılarak

$$y_t = T.K.M.R \quad (1.1)$$

biçiminde ifade edilebilir. Zaman serisi analizinde, gözlem değerlerinde meydana gelen dalgalanmaların dört faktörün etkisinden kaynaklandığı varsayılmaktadır. Bu dört faktör, "Trend, Mevsimsel Dalgalanmalar, Konjonktürel Dalgalanmalar

¹⁰KIRCHGÄSSNER, G., WOLTERS, J., **Introduction to Modern Time Series Analysis**, Springer-Verlag Inc, Berlin, 2007, s. 2-5

ve Düzensiz (Rassal) Dalgalanmalar” olarak sayılabilir. Bu unsurların her biri kısaca aşağıda ifade edilmiştir.

Trend: Bir zaman serisinin uzun dönem eğilimi veya zaman serisi değişkeninin yapısal özelliklerini kısa dönem aralıklarsa tekrar sergilemesi olarak tanımlanabilir. Trendin gözlemlenebilmesi için 10-15 yıl (10-15 yıllık ay) bazında veriye ihtiyaç duyulur.

Konjonktürel Dalgalanmalar: Konjonktürel dalgalanmalar sektörlerin veya ekonominin refah ve depresyon dönemlerini içeren değişimler (hareketler) olarak adlandırılır. İktisatta ve işletmecilikte bolluk, durgunluk, depresyon ve yükselme devreleri konjonktürel dalgalanmalara örnek olarak verilebilir. Konjektür dalgalanmalarının uzunluğu 3-5-yıl olarak kabul edilmektedir.

Mevsimsel Dalgalanmalar: Mevsimsel dalgalanmalar, aylık veya mevsimlik verilerde ortaya çıkmaktadır. Gözlenen değişkenlerin aylık değerlerinde mevsime bağlı olarak oluşan değişimler mevsimsel dalgalanmalar olarak adlandırılır. Mevsimsel dalgalanmaların uzunluğu sabit ve aylık gözlem değerleri için 12 ay, mevsimlik gözlem değerleri için de dalgalanmanın uzunluğu 4 aydır.

Mevsimsel dalgalanmalar genellikle doğal ve sosyo-ekonomik nedenlerden ortaya çıkar. Bir malın satış, tüketim ve fiyatında hava koşulları ve alışkanlıklar nedeniyle mevsimlik değişimler meydana gelebilir.

Düzensiz (Rassal) Hareketler: Düzensiz hareketlerin nedenleri arasında deprem, su baskını, don veya dolu gibi doğal nedenler ve siyasi karışıklık, savaş, grev ve lokavt, rakip işletmelerin politikalarındaki değişiklik, beklenmeyen bir fiyat hareketi gibi sosyo-ekonomik nedenler sayılabilir. Rassal nedenlerle veya geçici olarak ortaya çıkan hareketlere düzensiz hareketler adı verilir. Düzensiz hareketler düzenlilik göstermedikleri ve rassal veya geçici oldukları için, bunların

ne zaman ve ne şiddetle ortaya çıktıkları önceden tahmin edilemeleri mümkün değildir.¹¹

1.3.2. İç Bağımlılık Özelliği

Bir zaman serisinde gözlem değerleri birbirine bağlıdır. Bu bağımlılık ilişkisi iç bağımlılık olarak adlandırılır. Bu özellik yardımı ile zaman değişkeninin bugünkü ve geçmiş dönem gözlem değerleri kullanılarak gelecek dönemde alacağı değerleri tahmin etme imkanı doğar. Bugünkü dönem gözlem değerinin ait olduğu en son döneme denir ve t ile gösterilir. t dönemine ait gözlem değerleri X_t ile simgelendirilir. Zamana bağlı bu olayın t dönemine kadar olan tarihsel gelişimi gösteren döneme geçmiş dönem denir, geçmiş dönem ve geçmiş dönem değerleri sırasıyla $t-1, t-2, \dots$ ve $X_{t+1}, X_{t+2}, \dots$ şeklinde simgelendirilir. Zaman değişkenini aynı konumlarına göre zamanla açıklanan olayın gelecekteki eğilimini gösterecek olan döneme gelecek dönem adı verilir. Gelecek dönem ve gelecek dönem gözlem değerleri sırasıyla $t+1, t+2, \dots$ ve $X_{t+1}, X_{t+2}, \dots$ şeklinde ifade edilir.¹²

1.3.3. Stokastik Süreç Olma Özelliği

Zamana bağlı olaylar rassal (olasılık) karakterdedir. Bu gibi olaylarla ilgili serilerin gelecek dönem seyrini, bugünkü ve geçmiş dönem değerlerine dayanarak incelemek için değişik bir yaklaşım gerekir. Buna deterministik olmayan stokastik veya istatistiksel yaklaşım denir.¹³

Zaman serileri analizinde, serilerin stokastik süreç olarak kabul edildikten sonra analiz için stokastik modeller kullanılması gerekmektedir. Bu da zaman

¹¹ORHUNBİLGE, a.g.e., s. 7-9

¹²ÖZMEN, A., **Zaman Serisi Analizinde Box-Jenkins Yöntemi ve Banka Mevduat Tahmininde Uygulama Denemesi**, Anadolu Üniversitesi Yayınları, Eskişehir, 1986, s. 2

¹³BOX vd. a.g.e., s. 7

serilerinin analiz edilmesinde göz önünde bulundurulacak önemli özelliklerden biridir.

Stokastik süreç olarak bir zaman serisi, iç bağımlı olan rassal değişkenin zaman aralıklarıyla aldığı değerlerin ardı ardına sıralanmasıyla meydana gelen seri şeklinde tanımlanır. Başka bir ifade ile zaman serisi matematiksel olarak rassal değişkenler topluluğu biçiminde tanımlanabilir ve $\{y_t, t \in T\}$ şeklinde gösterimi yapılır.¹⁴

1.4. Zaman Serilerinin Sınıflandırılması

Zaman serileri gözlem değerlerinin elde ediliş şekline göre sürekli ve kesikli zaman serileri, gözlem değerlerinin serinin ortalamasından büyük sapmalar göstermesine göre durağan ve durağan-dışı zaman serileri ve son olarakda mevsim etkisi taşıyıp taşıyamaması yönünden mevsimsel ve mevsimsel olmayan zaman serileri olarak sınıflandırılır. İlerleyen alt bölümlerde sınıflandırma türlerine yer verilmiştir.¹⁵

1.4.1. Sürekli ve Kesikli Zaman Serileri

Ele alınan zaman serisinin gözlem değerleri zaman içinde devamlılık arz ediyorsa (kesilme yoksa) incelenen zaman serisi sürekli zaman serisi olarak adlandırılır.

Eğer incelenen zaman serisi gözlemleri belirli periyotlarla elde ediliyorsa bu tür zaman serileri kesikli zaman serileri olarak adlandırılır. Kesikli zaman serileri genellikle eşit zaman periyotları ile yapılan gözlemlerden elde edilir. Uygulamalarda en çok kullanılan zaman serisi kesikli zaman serileridir.¹⁶

¹⁴ÖZMEN, A., a.g.e., s. 3

¹⁵ÖZMEN, A., a.g.e., s. 4

¹⁶BOX vd. a.g.e., s. 21

1.4.2. Durağan ve Durağan-Dışı Zaman Serileri

Tek değişkenli zaman serisi modellerinde genel olarak serinin geçmiş değerlerine dayanarak, gelecekte alacağı değerlere ilişkin bilgi sağlamaya ve seri için en iyi öngörü değerini sağlayacak model elde edilmeye çalışılır.

Oluşturulacak modeller serinin durağan ya da durağan-dışı olmasına göre farklılık göstermektedir. Dolayısıyla ilk olarak serinin durağan ya da durağan-dışı olmasının incelenmesi gerekmektedir.

Serilerin durağanlığı "Durağanlık Koşulları" olarak adlandırılan

- Durağan sürecin zaman içinde değişmeyen sonlu ortalamaya ve sonlu varyansa sahip olması
 - Bu sürece ait kovaryansın geçmişten bağımsız olması
- şeklinde ifade edilen iki varsayım altında toplanmaktadır.

İlk varsayım, serinin ortalama ve varyansının zamandan bağımsız olduğu; yani zamanın bir fonksiyonu olmadığını, ikinci varsayım ise kovaryansın zamana bağlı gecikmelerden bağımsız olması ile kovaryansın zamanın fonksiyonu değil; zamanlar arası gecikmelerin bir fonksiyonu olması şeklinde açıklanabilir. Serinin anılan özelliklerin tümüne veya bir kısmına ait olması, "zayıf durağanlık, güçlü durağanlık ve kesin durağanlık" olarak adlandırılan farklı durağanlık tanımlamalarının ortaya çıkmasına neden olmuştur.¹⁷

1.4.2.1. Zayıf Güçlü ve Kesin Durağanlık

Bir stokastik sürece karşılık gelen Y_t zaman serisi, $t = 1, 2, \dots, T$ için

i) $\forall t$ için $E(Y_t) = \mu_Y$ sabit ise

¹⁷ AKGÜL, I., a.g.e., s. 3-9

ii) $\forall t$ için $Var(Y_t) = \sigma_Y^2 = \gamma_0$ sabit ise

iii) $\forall t$ ve $k \neq 0$ için $Cov(Y_t, Y_{t+k}) = \gamma_k$ sabit ise

Y_t zaman serisi zayıf durağan (kovaryans durağan) olarak adlandırılır. Zayıf durağanlıkta ortalama μ_Y , varyans σ_Y^2 ve otokovaryans γ_k t ' den bağımsızdır. Eğer bir süreç zayıf durağan ise Y_t ile Y_{t+k} arasındaki kovaryans sadece gözlemlerin k gecikme uzunluğuna bağlıdır.

Y_t rassal değişkeni, zayıf durağanlık özelliklerinin yanı sıra dağılımın zaman içinde değişmemesi özelliğine de gösteriyorsa Y_t zaman serisi güçlü durağan olarak adlandırılır.¹⁸

Y_t rassal değişkenin yukarıda sıralanan özelliklere sahip olmasının yanı sıra bileşik dağılımının normal dağılım durumu kesin durağanlık olarak adlandırılmaktadır.¹⁹

Kesikli bir rassal süreç Y_t bağımsız özdeş dağılan rassal değişkenlerin bir dizisini içeriyorsa pür rassal süreç olarak kabul edilir. Pür rassal süreç $\forall t$ için

$$\begin{aligned} E(\varepsilon_t) &= 0 & (\text{Ortalaması Sıfır}) \\ Var(\varepsilon_t) &= \sigma^2 & (\text{Varyansı } \sigma^2) \end{aligned}$$

sabit bir ortalamaya ve varyansa sahiptir. Ayrıca pür rassal sürecin kovaryansı $k \neq 0$ ve $\forall t$ için

$$cov(\varepsilon_t, \varepsilon_{t+k}) = 0 \quad (\text{kovaryansı Sıfır})$$

dır. Sürecin otokovaryans fonksiyonu (OKF) $k \neq 0$ ve $\forall t$ için

$$\gamma_k = cov(\varepsilon_t, \varepsilon_{t+k}) = 0$$

¹⁸SEVÜKTEKİN, M., NARGELEÇEKENLER, M., "Ekonometrik Zaman Serileri Analizi", Nobel Yayınları, Ankara, Mart 2010, s. 59-60

¹⁹AKGÜL, I., a.g.e., s. 7

ve otokorelasyon fonksiyonu da

$$\rho(k) = \begin{cases} 1 & , \quad k = 0 \text{ ise} \\ 0 & , \quad k \neq 0 \text{ ise} \end{cases}$$

biçiminde ifade edilir. Pür rassal süreç ayrıca "White Noise (WN)" karşılığı olarak temiz (saf) dizi olarak adlandırılır. Ortalaması sıfır ve sabit varyansla bağımsız (korelasyonsuz) özdeş dağılan rassal değişkenler dizisi $t = 1, 2, \dots, T$ için

$$\varepsilon_t \sim IID(0, \sigma^2)$$

şeklinde gösterilir ve serinin tanımsal olarak durağan olduğu kabul edilir.²⁰

1.4.2.2. Durağan-Dışı Zaman Serileri

Zaman serilerinin önemli bir kısmı durağan-dışı olduğu bilinmektedir. Durağanlık için gerekli varsayımlardan biri veya birkaçı sağlanmıyorsa, zaman serisi durağan-dışı zaman serisi olarak adlandırılır.

Başka bir deyişle incelenen zaman serisi sabit bir ortalama civarında dağılmıyorsa veya varyansı ve kovaryansı zamana bağlı olarak değişim gösteriyorsa durağan-dışı zaman serileri ortaya çıkar.²¹

Bu tür serilerin analiz edilebilmeleri için bir takım dönüşüm yöntemleri ile durağan hale getirilmeleri gerekir. Bu tür dönüşümler zorunludur. Çünkü zaman serileri analizi için geliştirilen ve kullanılan yöntemler durağan zaman serilerine uygulanabilir.

1.4.3. Mevsimsel ve Mevsimsel Olmayan Zaman Serileri

İncelenen zaman serisi birbirini takip eden yılların aynı aylarında benzer tekrar eden hareketler gösteriyorsa seri mevsimsel zaman serisi, göstermiyorsa mevsimsel

²⁰SEVÜKTEKİN, M., NARGELEÇEKENLER, M., a.g.e., s. 61

²¹SEVÜKTEKİN, M., NARGELEÇEKENLER, M., a.g.e., s. 64

olmayan zaman serisi olarak adlandırılır.²²

1.5. Zaman Serisi Analizinde Kullanılan İstatistiksel Araçlar

Zaman serisi analizinde kullanılan istatistiksel araçlar, otokovaryans fonksiyonu (OKVF), otokorelasyon fonksiyonu (OKF), kısmi otokorelasyon fonksiyonu (KOKF), serinin zaman yolu grafiği ve serinin kolerogramı kavramları ilerleyen alt bölümlerde açıklanmıştır.

1.5.1. Otokovaryans Fonksiyonu

Otokorelasyon fonksiyonu zaman serilerine uygulanan, bu serilerin ilişki ve özelliklerini açıklayan, bu nedenle analiz edilecek zaman serilerine uygun olabilecek zaman serisi modelinin seçiminde yardımcı olan ve açıklayıcı bilgi üreten önemli fonksiyonlardan birisidir.

Bir zaman serisinin X_t ile X_{t+1} gibi belirli bir k zaman aralığıyla (gecikmesi) birbirinden ayrı iki değer arasındaki ilişkiye otokovaryans, bu ilişkinin derecesini ölçen ve genel olarak $\gamma_{(k)}$ ile gösterilen katsayıya da otokovaryans katsayısı denir. Otokovaryans katsayılarını k gecikmesine bağlayan fonksiyona ise otokovaryans fonksiyonu (OKVF) adı verilir.

Otokovaryans katsayısı k gecikmesi için

$$\gamma_{(k)} = Kov(X_t, \dots, X_{t+1}) = E[(X_t - E(X_t))(X_{t+1} - E(X_{t+1}))] \quad (1.2)$$

veya kısaca

$$\gamma(k) = E[(X_t - \mu)(X_{t+1} - \mu)] \quad (1.3)$$

şeklinde belirlenir.

²²ÖZMEN, A., a.g.e., s. 6

İncelenen zaman serisine dayanarak $\gamma_{(k)}$ otokovaryans fonksiyonunun tahmini $c(k)$ ile gösterilir. $c(k)$ değeri $k = 0, 1, 2, \dots, n$ için

$$c(k) = \frac{1}{n} \sum_{t=1}^{n-k} (X_t - \bar{X}) (X_{t+k} - \bar{X})$$

şeklinde hesaplanır.²³

1.5.2. Otokorelasyon Fonksiyonu

Tek değişkenli zaman serisi analizinde kullanılan en önemli araçlardan birisi, otokorelasyon fonksiyonudur. OKF, zaman serisinin durağanlığının ve durağan-dışılığının ve seri durağan-dışı ise, durağanlığı bozan etkenlerin belirlenmesinde, ARIMA modellerin belirlenmesi aşamasında ve uygunluğunun araştırılmasında sıklıkla yararlanılan istatistiksel bir araçtır.

Bir zaman serisinin, X_t ve X_{t+k} gecikmeli değerleri arasındaki ilişkinin standartlaştırılmış ölçümüne otokorelasyon katsayısı ve bu katsayıların k gecikmesine bağlı olarak ifadesine de otokorelasyon fonksiyonu denir. OKF, anakütle için $\rho_k(k)$ ile gösterilir ve $k = 0, \pm 1, \pm 2, \dots$ için

$$\rho_k(k) = \frac{E[(X_t - \mu_x)(X_{t+1} - \mu_x)]}{E[(X_t - \mu_x)^2]} \quad (1.4)$$

olarak veya $k = 0, \pm 1, \pm 2, \dots$ için kısaca

$$\rho_k(k) = \frac{\gamma_x(k)}{\sigma_x^2} = \frac{\gamma_x(k)}{\gamma_x(0)} \quad (1.5)$$

biçiminde tanımlanır.

OKF'na dayanarak, incelenen zaman serisinin içerdiği etkenlerin belirlenmesi ve bu etkenlerin, rassal etkenden ayırt edilebilmesi için, rassal serinin otokorelasyon katsayılarının örnekleme dağılımından yararlanılır. Rassal serinin

²³ÖZMEN, A., a. g. e. s. 36

$k = 0, \pm 1, \pm 2, \dots$ gecikmeleri için hesaplanan otokorelasyon katsayılarının örnek-leme dağılımının ortalaması sıfır ve standart hatası da yaklaşık olarak $1/\sqrt{n}$ 'dir.²⁴

İncelenen zaman serisinin otokorelasyon katsayıları $\pm z_\alpha/\sqrt{n}$ sınırları arasında kalıyorsa, serinin rassal olduğuna karar verilir. Aksi durumda, bu sınırların dışında kalan otokorelasyon katsayıları, oluşturulacak modelin derecesinin belirlenmesini sağlar. Burada z_α , kabul edilen anlam düzeyine göre, serinin kritik değerini gösterir. Aynı yolla, belirlenen modelin uygunluğunun sınaması da yapılır. Tek fark, X_t 'lerin yerine ε_t 'ler kullanılır. Burada ε_t 'ler artık serisine ait değerleridir.²⁵

1.5.3. Kısmi Otokorelasyon Fonksiyonu

Kısmi otokorelasyon, değişkenin şimdiki değeri X_t 'nin, diğer zaman gecikmelerinde etkisi sabit kalmak üzere, önceki X_{t+1} değerleriyle ilişkisini tanımlamada kullanılan ölçüme k gecikmesi için kısmi otokorelasyon katsayısı denir ve $\phi_{11}, \phi_{22}, \dots, \phi_{kk}$ ile gösterilir.

Zaman serisi çözümlemesinde, seriye uygun olarak belirlenecek AR modelinin derecesi OKF'na bakılarak belirlenemez. Çünkü çok sayıda gecikme için anlamlı otokorelasyon katsayısı vardır. Oysa p 'inci dereceden bir AR modeli için, KOKF'nda p tane istatistiksel olarak sıfırdan farklı kısmi otokorelasyon katsayısı vardır. Diğer gecikmelerde kısmi otokorelasyon katsayıları sıfırdan farklı değildir. Örneğin, bir zaman serisi için KOKF'na bakıldığında sadece birinci gecikmede sıfırdan farklı kısmi otokorelasyon katsayısı varsa ve diğer gecikmelerdeki katsayılar sıfırdan istatistiksel olarak farklı değilse, seri için belirlenen model $AR(1)$ olarak ifade edilir.

Genel olarak, k 'ıncı dereceden AR sürecinde j 'inci katsayı ϕ_{kj} ve son katsayı

²⁴BOX vd. a.g.e. s. 34-35

²⁵ORHUNBİLGE, N., a.g.e. s.136-138

da ϕ_{kk} ile gösterilir. ϕ_{kk} 'ların denklemler kümesi, Yule-Walker denklemler sistemi şeklinde yazılıp çözümlenebilir.²⁶

Bu sistem $j = 1, 2, \dots, k$ için

$$\rho_j = \phi_{k1}\rho_{j-1} + \dots + \phi_{k(k-1)}\rho_{j-k+1} \quad (1.6)$$

biçiminde gösterilir. Daha açık bir ifade ile $j = 1, 2, \dots, k$ için

$$\begin{aligned} \rho_1 &= \phi_{k1} + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1} \\ \rho_2 &= \phi_{k1}\rho_1 + \phi_{k2} + \dots + \phi_{kk}\rho_{k-2} \\ &\vdots \\ \rho_k &= \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-1} + \dots + \phi_{kk} \end{aligned} \quad (1.7)$$

şeklinde ifade edilebilir.

Yule-Walker denklemler sisteminde ρ 'ların yerine örneklem otokorelasyon katsayıları olan r 'ler kullanılıp çözümleme yapılarak k gecikmeleri için ϕ_{kk} 'larının kestirimleri bulunur. Kestirilen bu fonksiyona örneklem Kısmi Otokorelasyon Fonksiyonu (KOKF) denir.²⁷

1.5.4. Zaman Serisi Grafiği ve Korelogramı

Zaman serisi analizinin ilk aşamasında, serinin seyrine bakılarak durağanlığı ve mevsimselliği hakkında ilk bilgilerin elde edilebilmesi için serinin zaman yolu grafiğinin incelenmesi gerekir.²⁸ Bir zaman serisinin zaman yolu grafiğine bakılarak ortalama da durağanlık, varyans da durağanlık ya da durağan-dışılık kavramlarına karar verilebilir. Zaman serisi analizinde, serinin zaman yolu grafiği, serinin durağanlığı ve yapılması gereken dönüştümlere karar verilmesi açısından önemli bir araçtır.²⁹

²⁶BOX vd. a.g.e., s.54

²⁷BOX vd. a. g. e., s. 64-68

²⁸AKGÜL, I., a.g.e., s. 206

²⁹SEVÜKTEKİN, M., NARGELEÇKENLER, M., a.g.e., s. 229-231

Örneklem otokorelasyonlarının, kısmi otokorelasyonların ve Q -istatistiklerinin incelen serinin özelliğine göre seçilen k sayıda gecikmeye göre işaretlenerek grafiğinin çizilmesine korelogram adı verilir. Korelogram teorik otokorelasyon fonksiyonlarının tahmin edilen örneklem otokorelasyonlarına yer verir. Seçilen gecikme sayısına göre tahmin edilen otokorelasyonlar sıfıra yakınlığı incelen serinin temizdizi ya da durağanlığı hakkında bilgi verir. İncelenen serinin durağan ya da durağan-dışılığına karar vermede serinin modellenmesinde ve belirlenen modelin geçerliliğine karar vermede korelogram yararlı bir araç olarak sıklıkla kullanılmaktadır.³⁰

1.6. Durağan ARIMA Modelleri

Bu bölümde, durağan zaman serilerine uygun olan; Otoregresif $AR(p)$, Hareketli Ortalama $MA(q)$ ve Karma Otoregresif Hareketli Ortalama $ARMA(p, q)$ açıklanmaya çalışılmıştır.

1.6.1. Otoregresif Modeller

Otoregresif $AR(p)$ modelde zaman serisi değişkeninin içinde bulunan dönemdeki (cari) değeri, serinin p dönem geçmiş değerlerinin ağırlıklı toplamına artı rassal hata terimine bağlı olarak açıklanmaktadır. Genel olarak; trend etkisi kaldırılmış seriyi y_t , otoregresif sürecin mertebesini (serinin geçmiş değerlerinin sayısı) p , bugünkü dönem ile geçmiş dönem değerleri arasındaki ilişkiyi gösteren ilişki katsayıları (ağırlıklar) ϕ , ve model tarafından açıklanamayan hata terimini ε_t ile gösterirsek p ' nci mertebeden otoregresif $AR(p)$ süreci

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (1.8)$$

veya

$$y_t - \phi_1 y_{t-1} - \phi_2 y_{t-2} - \dots - \phi_p y_{t-p} = \varepsilon_t \quad (1.9)$$

³⁰SEVÜKTEKİN, M., NARGELEÇEKENLER, M., a.g.e., s. 271-272

şeklinde gösterilir.

(1.8) ve (1.9) nolu denklemlerde ε_t ile simgelenen hata terimi; sıfır ortalama ile sabit varyansa ve temiz dizi (white noise) sürecine sahiptir. Ayrıca, ε_t 'ler, y_{t-p} lerden bağımsız olup herhangi bir dönemdeki hata ile arasında ilişki söz konusu değildir. δ ile simgelenen ve “yığılım parametresi” olarak adlandırılan stokastik sürecin ortalaması ile ilgili sabit parametresine sahip $AR(p)$ süreci;

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \delta + \varepsilon_t \quad (1.10)$$

veya

$$y_t - \phi_1 y_{t-1} - \phi_2 y_{t-2} - \dots - \phi_p y_{t-p} + \delta = \varepsilon_t \quad (1.11)$$

biçiminde ifade edilir.

Modele sabitin eklenmesi ile serinin sıfırdan farklı olmasına izin verilmesi olarak ifade edilebilir. (1.10) ve (1.11) nolu modellerde $\delta, \sigma_\varepsilon^2, \phi_1, \phi_2, \dots, \phi_p$ olacak şekilde $(p+2)$ tane bilinmeyen parametre vardır. Bu parametreler verilerden tahmin edilmektedir. Benzer şekilde (1.8) ve (1.9) nolu modellerde $\sigma_\varepsilon^2, \phi_1, \phi_2, \dots, \phi_p$ olacak şekilde $(p+1)$ tane bilinmeyen parametreler verilerden tahmin edilmektedir.

$AR(p)$ sürecini, B geri kaydırma işlemcisi kullanarak; ($\delta = 0$ varsayımı ile)

$$1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p = \varepsilon_t \quad (1.12)$$

p ' nci mertebeden AR işlemcisi olan $\phi(B)$ ' nin açılımı,

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

biçiminde verilir.³¹

³¹AKGÜL, I., a. g. e., s. 37

1.6.2. Hareketli Ortalama Modelleri

$MA(q)$ modelleriyle tahminlerde, q adet geçmiş dönem hatalarının doğrusal birleşimi (kombinasyonu) kullanılmaktadır. Otoregresif modellerde olduğu gibi hareketli ortalama modellerinde de hata terimlerinin zaman içinde bağımsız ve rassal olduğu, temiz dizi süreci oluşturulduğu varsayılmaktadır. $MA(q)$ modelleri, incelenen zaman serisi değişkenin bugünkü değerini, temiz dizi sürecinin bugünkü ve q -dönem geriye giderek geçmiş değerlerinin ağırlıklı toplamı ile açıklayan modellerdir.³². Yani $MA(q)$ modelleri, değişkenin geçmiş dönem değerlerine gittikçe azalan ağırlıklar verilmesine dayanmaktadır.³³

$MA(q)$ süreci, tanım gereği q durağan temiz dizi teriminin ortalaması olduğu için $MA(q)$ süreçlerinin tümü durağandır. $MA(q)$ süreçleri için araştırılan özellik "çevrilebilirlik koşulu" nun sağlanıp sağlanmadığıdır.

$MA(q)$ süreçleri genel olarak yığılm parametresinin modelde ye alıp almasına bağlı olarak;

$$y_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-p} \quad (1.13)$$

veya

$$y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-p} \quad (1.14)$$

biçiminde gösterilmektedir. θ_i ağırlıkları, y_t durağan seriyi göstermektedir. Ayrıca $\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-p}$ geçmiş dönem öngörü hatalarını ve μ ile sabit terimi, $\theta_1, \theta_2, \dots, \theta_q$ ile de MA parametrelerini simgelemektedir.

Model geri kaydırma işlemcisi B kullanılarak $\mu = 0$ olmak üzere

$$y_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t \quad (1.15)$$

³² AKGÜL, I., a. g. e., s. 67

³³ ORHUNBİLGE, N., a. g. e., s. 165

veya kısaca

$$y_t = \theta(B) \varepsilon_t \quad (1.16)$$

olarak ifade edilmektedir.³⁴

$MA(q)$ süreci için çevrilebilirlik koşulu (1.16) eşitliğinden faydalanarak

$$\varepsilon_t = \theta^{-1} B(y_t) \quad (1.17)$$

olarak ifade edilmektedir. Koşul, karakteristik denkleminin köklerinin birim daire dışına düşmesi ile açıklanmaktadır. $y_t = (1 - \theta_1 B)\varepsilon_t$ ile tanımlı $MA(1)$ süreci için çevrilebilirlik koşulu

$$|\theta_1| < 1$$

şeklinde, $MA(q)$ süreci için ise

$$\sum_{i=1}^n \theta_i < 1 \quad (1.18)$$

biçiminde gösterilmektedir.

AR süreci daima çevrilebilir, MA süreci ise daima durağandır. Ayrıca ϕ_p parametrelerinin durağanlık sınırlarını geçmesi ve θ_q parametrelerinin çevrilebilirlik sınırlarını geçmesi durumunda ilgilenilen zaman serisinin durağan-dışı; aksi takdirde durağan bir süreç olduğu ifade edilmektedir.³⁵

1.6.3. Otoregresif Hareketli Ortalama Modelleri

Durağan serilerin sadece $AR(p)$ veya $MA(q)$ süreçlerinin değil de, her iki sürecin özelliklerine sahip oldukları durumda oluşturulacak olan ve seriler için daha iyi uyum sağlayan modeller “Otoregresif Hareketli Ortalama Modelleri” $ARMA(p, q)$ olarak adlandırılmaktadır. $ARMA(p, q)$ modelleri, en genel durağan stokastik süreç modelleri olup, geçmiş gözlemlerin ve geçmiş hata terimlerinin

³⁴AKGÜL, I., a. g. e., s. 68

³⁵AKGÜL, I., a. g. e., s. 69

doğrusal bir fonksiyondur. p ve q mertebelerine sahip $ARMA(p, q)$ süreci, yığılım parametresinin modelde yer alıp almamasına göre, $\delta \neq 0$ varsayımı ile

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \delta + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-p} \quad (1.19)$$

$\delta = 0$ ve varsayımı ile

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-p} \quad (1.20)$$

veya (1.19) ve (1.20) eşitlikleri düzenlenerek

$$y_t - \phi_1 y_{t-1} - \phi_2 y_{t-2} - \dots - \phi_p y_{t-p} = \delta + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-p} \quad (1.21)$$

$\delta = 0$ ve varsayımı için

$$y_t - \phi_1 y_{t-1} - \phi_2 y_{t-2} - \dots - \phi_p y_{t-p} = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-p} \quad (1.22)$$

biçiminde gösterilmektedir. $ARMA(p, q)$ süreci, geri kaydırma işlemcisi B ile ($\delta = 0$ durumu için);

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) y_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \varepsilon_t$$

veya kısaca

$$\phi(B) y_t = \theta(B) \varepsilon_t \quad (1.23)$$

olarak gösterilebilir.³⁶

1.7. Durağan-Dışı ARIMA Modelleri

Süreçlerin ortalamasının, varyansının ve kovaryansının zamana bağlı olarak değişmemesi durumunda, başka bir deyişle seriler durağan olduklarında $AR(p)$, $MA(q)$ veya $ARMA(p, q)$ modellerinden birinin uygun olacağına değinilmişti.

Ancak zaman serilerinin çoğunda ortalama ve (veya) varyansta zamana bağlı bir eğilim gözlenmektedir. Serilerin sabit bir ortalama etrafında dağılmaması

³⁶ AKGÜL, I., a. g. e., s. 67-70

veya stokastik sürecin karakteristiklerinin zamana bağlı olarak değişmesi nedeni ile durağan olmayan seriler ortaya çıkmaktadır. Bu gibi serilerin durağan hale dönüştürülmesi gerekli olmakta ve genellikle bu özelliklere sahip serilerin durağan olana kadar farkı alınmaktadır.

Durağan-dışı y_t serisinin d 'inci mertebeden farkı alınarak durağan hale getirilen seri w_t ile tanımlanırsa, uygulanan dönüşüm,

$$w_t = \Delta^d y_t = (1 - B)^d y_t \quad (1.24)$$

şeklinde gösterilmektedir.³⁷

Durağan olmayıp, farkı alınarak durağan hale getirilmiş serilere uygulanan modellere “durağan olmayan doğrusal stokastik modeller” veya kısaca “entegre modeller” denir. Bu entegre modeller belirli sayıda farkı alınmış serilere uygulanan AR ve MA modellerinin birleşimidir. Eğer AR modelinin derecesi p , MA modelin derecesi q ve serinin d kez farkı alınmış ise bu modele (p, d, q) dereceden “otoregresif entegre hareketli ortalama modeli” olarak adlandırılır ve $ARIMA$ (p, d, q) şeklinde gösterilir.

$ARIMA$ modelleri kullanılarak durağan olmayan zaman serilerinin (p, d, q) mertebesi ile modellenmesi mümkün olmaktadır. Bu aşamada yapılan fark alma işlemi ise durağan olmayan serilerin durağan hale getirilmesinde dönüşüm aracı olarak kullanılmaktadır. Uygulamada yaygın kullanılan fark alma mertebelerin $d = 1$ ve $d = 2$ olduğu görülmektedir. Serinin mertebesi belirlendikten sonra modeldeki otoregresif terim sayısı p ve gecikmeli hata terim sayısı q belirlenmektedir. Sonuçta $ARIMA$ modelleri, durağan olmayan serilerin durağan olana kadar kaç kere farklarının alındığını gösteren d mertebesine AR terim sayısı p ve MA terim sayısı q 'nın ilave edilmesi ile belirlenmekte ve her üç değerın seçilmesinin $ARIMA$ modellerinde en önemli adımı olduğu ifade edilmektedir.³⁸

³⁷AKGÜL, I., a. g. e., s. 105

³⁸AKGÜL, I., a. g. e., s. 110


1.8. ARIMA Model Kurma Süreci: Box-Jenkins Yaklaşımı

Zaman serisi modeli oluşturmada Box-Jenkins (1976) yöntemi geleneksel ekonometrik modellere göre, durağanlığı, deterministik bileşen bilgisini ve geleceğe ilişkin tahminleri bir arada ortaya koyduğu için sık tercih edilen bir yöntemdir. Yöntem belirlenen birçok model arasından en iyi modeli seçerek zaman serisinin gelecekte alacağı değerleri tahmin etmeye yöneliktir. Bir değişkene ilişkin yapılacak tahmin, kendi gecikmeli değerleri, hata terimleri ya da her ikisinin birleşimi ile yapılmaktadır. Yani değişken, kendi dinamikleri ile açıklanmaya çalışılmaktadır.³⁹

Box-Jenkins yaklaşımın da temel fikir cimrilik (tutumluluk) prensibine dayanmaktadır. Cimrilik (seyreklik-azlık anlamında) prensibi zaman serisi verilerinin özelliklerini ortaya koyan optimal (minimum sayıda parametre veya serbestlik derecesini gözönünde tutan) bir model kurmayı amaçlar. Box-Jenkins tutumlu modellerin çok sayıda parametre içeren modellere göre daha iyi öngörü ürettiklerini öne sürer. Tutumlu bir modelin verilere uyumu, gereksiz herhangi bir parametrenin eklenmesinden daha iyidir. Amaç tam süreci elde etmek olmasa da, doğru veri üretme sürecine yaklaşımdır.

Zaman serisi modeli kurmada Box-Jenkins yaklaşımı şekil 2.1 deki gibi şematik olarak özetlenebilir.

³⁹BOZKURT, H. "**Zaman Serileri Analizi**", Ekin Kitapevi, Ankara, 2007, s.49



Şekil 2. 1. Box-Jenkins Yöntemi Uygulama Aşamaları

Kaynak: Box-Jenkins, 1994: 17

Yaklaşımındaki temel adımlar genel hatlarıyla, zaman serisi modelinin belirlenmesi (tanımlanması), model parametrelerinin tahmin edilmesi, ayırt edici kontrol (test) ve ileri yönelik tahmin (önraporlama-öngörü) olarak dört adımda özetlenebilir.⁴⁰

1.8.1. Modelinin Belirlenmesi

Box-Jenkins yönteminin en önemli aşaması, otokorelasyon ve kısmi otokorelasyon katsayılarının incelenerek uygun $ARIMA(p, q)$ modelinin seçilmesidir. Mekanik olarak belirlenmesi mümkün olmayan bu aşamada araştırmacıların kararı önem kazanmaktadır. Ancak otokorelasyon ve kısmi otokorelasyon katsayılarının

⁴⁰SEVÜKTEKİN, M., NARGELEÇEKENLER, M., a.g.e., s. 178

belirli modeli açıkça ortaya çıkaramamaları ve birden fazla fazla modele uygunluk gösterme eğilimleri sebebiyle tek bir modelin belirlenmesi mümkün olmamaktadır.

Otokorelasyon ve kısmi otokorelasyon katsayılarının ortalaması sıfır, standart sapması $1/\sqrt{n}$ olan normal dağılım gösterdiği bilinmektedir. Bu bilgilerle %95 olasılıkla bu katsayıların tesadüflik sınırları belirlenmekte ve $2/\sqrt{n}$ ' den büyük olanların anlamlı bir şekilde farklı olduğu kabul edilmektedir. Model belirleme süreci üç önemli aşamadan oluşmaktadır.

i) Eğer zaman serisi durağan değilse, suni otokorelasyonlar model belirlemeye engel olacaktır. Bu sebeple hangi düzeyde uygun ise farklar alınır ve seri durağan hale getirilir.⁴¹ Durağanlık testi için, OKF ve KOKF yanında Dickey-Fuller (DF), Genişletilmiş Dickey-Fuller (ADF) veya Phillips-Perron testlerine de başvurulabilir.⁴²

ii) Otokorelasyon ve kısmi otokorelasyon katsayıları dağılımlarının grafikler yardımıyla incelenmesi gerekmektedir.

iii) Sıfırdan anlamlı bir şekilde farklı olan otokorelasyon katsayılarının saptanması AR ve MA modellerinin derecesinin belirlenebilmesi için gerekmektedir. Belirleme işlemi sıfırdan anlamlı bir şekilde farklı olan otokorelasyon katsayılarının sayıları kullanılarak yapılmaktadır.

ARMA modellemesinde *AR*' ın derecesi kısmi otokorelasyon (p) ve *MA*' ın derecesi otokorelasyon (q) katsayılarının sayısı ile belirlenmektedir. Aşağıdaki tablo 1.1' de otokorelasyon ve kısmi otokorelasyon katsayılarının teorik davranışları verilmiştir.

⁴¹ORHUNBİLGE, N., a. g. e., s. 193 - 194

⁴²BOZKURT, H., a.g.e., s. 27-40

Tablo 1.1.Box-Jenkins Modellerinde OKF ve KOKF Seyri

Otokorelasyon Yapısı	Süreç
OKF üssel azalma $AR(p)$ modeli.	p değerini KOKF gecikme sayısı belirler.
KOKF üssel azalma $MA(q)$ modeli.	p değerini OKF gecikme sayısı belirler.
OKF ve KOKF üssel azalma $ARMA(p, q)$ modeli.	p ve q değerini OKF ve KOKF gecikme sayısı belirler.
OKF ve KOKF tüm değerler sıfır	Tesadüfi değişkendir.
Belirli aralıklarla OKF ve KOKF sıfırdan farklı olması (12, 24,...)	Mevsimsel otoregresif terim içerir.
OKF ve KOKF değerlerinin sıfıra doğru azalmaması	Durağan-Dışı süreç.

Kaynak: Bozkurt, 2007: 55

1.8.2. Model Parametrelerinin Tahmini

Uygun bir zaman serisi bir modeli geçici olarak belirlendikten sonra sürecin parametreleri tahmin edilir. Eğer AR süreci belirlenmiş ise parametreler en küçük kareler” (EKK) yöntemi ile tahmin edilir. Eğer herhangi bir MA süreci belirlenmiş ise maksimum benzerlik veya yine en küçük kareler yöntemi uygulanır. Şayet $ARMA$ süreci belirlenmiş ise doğrusal olmayan optimizasyon yöntemine gerek duyulur.⁴³

Tahminin “En Küçük Kareler” (EKK) yöntemi ile yapılması durumunda hata terimlerinde görülen oto korelasyon etkisi nedeniyle, etkin olamayan ve çok büyük varyansa sahip olan parametre tahminleri elde edileceğinden parametrelerin “Doğrusal Olmayan EKK” yöntemi ile tahmin edilmesi uygun olmaktadır. Hata terimleri normal dağılıma sahip olduğunda tahmin yöntemi olarak “En Çok Olabilirlik” yöntemi de kullanılmaktadır. Tahmin işlemi genellikle paket programlar yardımı ile yapılmaktadır. Parametrelerin son nokta tahminlerini elde etmek için çeşitli

⁴³SEVÜKTEKİN, M., NARGELEÇEKENLER, M., a.g.e., s. 182

yaklaşımlar kullanılmakta ve sonuç olarak “en küçük hata kareleri toplamı”na sahip tahmin seçilmektedir. Hesaplama algoritması tekrarlı bir süreç olduğundan, tahminlere ait başlangıç değerlerinin verilmesi gerekmektedir. Bu nedenle tahmin basamağında ilk olarak “deneme” niteliğindeki modelin parametreleri için “başlangıç” değerleri hesaplanmakta, daha sonra paket programlar yardımı ile tekrarlı yöntemle son tahminler elde edilmektedir.⁴⁴

1.8.3. Modelin Uygunluğunun Test Edilmesi

Box-Jenkins model oluşturma yönteminde üçüncü aşama, teşhis etme testlerini kullanarak modelin yeterliliğini kontrol etmektir. Zaman serisi modeli seçilip parametreleri belirlendikten sonra yapılan tanımlamaların doğruluğu ortaya konulabilir. Model uygunluğunun test edilmesi genelde iki aşamayı içerir.

Benzetilen serinin otokorelasyon fonksiyonu orjinal serinin otokorelasyon fonksiyonu ile karşılaştırılır. Eğer iki otokorelasyon fonksiyonu oldukça farklı görünmüyorsa modelin geçerliliği şüphelidir, model belirleme aşamasına geri dönülerek tekrar model belirlenir.

İlk aşamada, eğer iki otokorelasyon fonksiyonu belirgin bir biçimde birbirinden farklı değilse bu durumda modelin kalıntıları (artıkları) analizine geçilir. Modelin kalıntıları test süreci için önemli bilgiler sağlar. Eğer uydurulan model yetrli ise, kalıntılar (artıklar serisi) yaklaşık olarak temiz dizidir. Yani belirlenen $ARIMA(p, d, q)$ modeli veri-üretim sürecini yeterli düzeyde gösteriyorsa, kalıntılar korelasyonsuz ve rassal olacaktır.⁴⁵

İkinci aşamada modelin uygunluğu, kalıntı değerlerinin (artıkların) oto korelasyonları üzerinde uygulanan ve Box-Pierce’in Q istatistiği olarak da bilinen ki-kare (χ^2) testi ile de kontrol edilebilir. $K - p - q$ serbestlik derecesi ile yaklaşık

⁴⁴ AKGÜL, I., a. g. e., s. 122 - 123

⁴⁵ SEVÜKTEKİN, M., NARGELEÇEKENLER, M., a.g.e.,s. 184

olarak ki-kare dağılımına uyan Q istatistiği, durağan serideki gözlem sayısı N , test edilecek birinci oto korelasyon k , test edilecek oto korelasyon sayısı K , k 'inci artık (kalıntı) teriminin örnek oto korelasyon fonksiyonu ρ_k , serinin durağanlaştığı fark alma derecesi d olmak üzere

$$Q(r) = N \sum_{k=1}^K \rho_k^2 \sim \chi_{K-p-q}^2 \quad (1.25)$$

şekilde hesaplanır. Hesaplanan Q değeri, $k - p - q$ serbestlik derecesi için χ^2 değerinden büyükse, model uygun değildir.

Ljung ve Box tarafından tanıtılan Q^* test istatistiği ise, χ^2 dağılımının gözlem sayısının 100'den küçük olması, yani $N < 100$ olması durumunda zayıf bir istatistik olması nedeniyle değiştirilmiş bir Q istatistiğidir. Q^* istatistiği test hipotezleri

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_k$$

$$H_1 : \rho_1 \neq \rho_2 \neq \dots \neq \rho_k$$

olarak oluşturulmakta ve test istatistiği;

$$Q^* = \frac{N(N+2) \sum_{k=1}^K \rho_k^2}{(N-k)} \quad (1.26)$$

formülü ile hesaplanmaktadır. Formülde $k = 1, 2, \dots, K$ gecikme uzunluğunu (veya kullanılan oto korelasyon sayısını), N durağan zaman serinin gözlem sayısını göstermektedir.

Q^* istatistiği de Q istatistiği gibi, hata terimleri arasındaki serisel korelasyonunu ölçmekte olup H_0 hipotezi altında $(K - p - q)$ serbestlik derecesi ile χ^2 dağılımına sahiptir. $Q^* < \chi^2$ olması halinde OKK'larının sıfır olduğunu vurgulayan sıfır hipotezi reddedilmeyecek, $Q^* > \chi^2$ olması halinde ise, OKK'larının sıfır olduğunu vurgulayan sıfır hipotezi reddedilecek ve artıkların "temiz dizi"

özelliği taşımadığı, bu nedenle de modelin geçersiz olduğuna karar verilecektir. Birden çok sayıda deneme niteliğindeki model söz konusu olduğunda, birden fazla modelin “iyi model” olarak kabul edilmesi mümkün olacağından, bu aşamada “en iyi model”in seçilmesi problemi ile karşılaşmaktadır. Bu durumda “uygunluk testleri” sonucunda başarılı bulunan modellerin değerlendirilmesi ve “en iyi model”in belirlenmesi amacıyla çeşitli kriterlerden yararlanılmaktadır.⁴⁶ Bu kriterler ilerleyen alt bölümde açıklanmıştır.

1.8.3.1. Model Seçim Kriterleri

Model belirleme, parametre tahmini ve model uygunluğunun test edilmesi aşamalarından sonra elde edilen model ya da modellerden uygun olanının seçilmesi için aşağıda belirtilen kriterler kullanılmaktadır.

Standart Belirlenim Katsayısı (R^2): Standart belirlenim katsayısı R^2 zaman serisi modellerinin değerlendirmek için çok fazla yararlı olan bir yöntem değildir. ARIMA model belirlemede kullanılabilir. Zaman serisi için belirlenim katsayısı R^2 yalnızca AR parametresine bağlıdır.

F-İstatistiği Yaklaşımı: ARIMA model belirlemede model seçim kriteri olarak başvuru genelde regresyon tekniği olarak bilinen F-istatistiği yaklaşımı, otoregresif zaman serisi modellerinde (AR) uygulama kolaylığı ve basitliğinden ötürü çok sık kullanılan bir kriterdir.

Akaike Bilgi Kriteri (AIC): Akaike bilgi kriteri (AIC) modeldeki terimlerin sayısını dikkate alarak, modelin uyumunun iyiliğini ölçen bir kriterdir. AIC genelde çok değişkenli alternatif modeller arasından iyi uyum sağlayan modelin seçim kriteri olarak kullanılabildiği gibi *ARIMA* modelleri için de uygun model derecesini tanımlamak amacıyla kullanılabilir.

⁴⁶ AKGÜL, I., a. g. e., s. 122 - 123

AIC genel bir cezalı olabilirlik sürecini oluşturur. Modeldeki her ilave terim için olabilirlik bir cezaya tutulur. Eğer olabilirlik ceza miktarından daha fazla olabilirlik sağlamazsa modele dahil edilmez. AIC, olabilirlik L , $m = p + q$ olmak üzere

$$AIC = -2 \log L + 2m$$

formülü veya hata kareler toplamı $\hat{\sigma}_{ML}^2$ olmak üzere

$$AIC = T \log \hat{\sigma}_{ML}^2 + 2m$$

biçiminde tanımlanır. Alternatif modeller arasında en küçük AIC değeri veren ifade için p ve q değerleri veya uygun model seçilir.

Schwarz Bilgi Kriteri (SIC): Schwarz bilgi kriteri (SIC), AIC gibi aynı istatistiksel kuralların uygulandığı bir istatistiktir. SIC aynı zamanda Bayes Bilgi Kriteri (BIC) olarak da adlandırılır. SIC için de iki farklı tanımdan birincisi

$$SIC = T \log \hat{\sigma}_{ML}^2 + 2m + m \log T$$

ve ikincisi

$$SIC = T \ln(SSR) + m \ln(T)$$

biçiminde verilebilir. İyi bir model uyumu için AIC ve SIC değerlerinin mümkün olduğu kadar küçük olanı tercih edilmelidir.⁴⁷

1.8.4. İleriye Yönelik Öngörü (Tahmin)

Seri için oluşturulan modelin belirlenip, kontrol amaçlı testlerden geçmesinden sonra ileriye yönelik öngörü amacıyla kullanılabileceği ifade edilmektedir. Bu aşamada öngörü, modelin parametrelerinin doğru olarak belirlendiği varsayılarak yapılmaktadır.

⁴⁷SEVÜKTEKİN, M., NARGELEÇEKENLER, M., a.g.e., s. 186-190

ARIMA modelleri, tahmin için ek bilgi gerektirmemesi ve özellikle kısa dönemli öngörülerde başarısının yüksek olması nedeni ile zaman serilerinde öngörü amaçlı olarak sıklıkla kullanılmaktadır.⁴⁸

Zaman serileri modelleri ile kestirim, uygun bir modelin parametrelerinin kestirimi yardımı ile sağlanır. Örneğin ilgili modelin

$$Y_t = b_0 + b_1 t + \varepsilon_t \quad (1.27)$$

olduğu varsayılırsa β_0 ve β_1 parametrelerinin bir kestirimi olan b_1 ve b_2 kullanılarak geleceğe yönelik

$$F_t = b_0 + b_1 t$$

ile kestirim yapılabilir.

T gözlem değerine sahip bir seride, T (T periyodunun sonu) zaman diliminden sonra gelecek bir periyoda ($T + a$) yönelik bir kestirim yapılacaksa,

$$F_{T+a} = b_0 + b_1 (T + a) \quad (1.28)$$

eşitliği istenen kestirim değerini verecektir.⁴⁹

1.9. Mevsimsel ARIMA Modelleri

Mevsimselliği modelleme yaklaşımı olarak bilinen “Mevsimsel Box-Jenkins Yöntemi”nin diğer yöntemlere göre üstünlüğünün mevsimselliği modelde tanımlaması olduğu vurgulanmaktadır. Mevsimsel Box-Jenkins modellerinde amaç, geçerli bir modelin bulunmasıdır, ayrıca verideki mevsimselliğin davranışı ile de ilgilenilmektedir. Mevsimsel olmayan seriler için analizin başlangıç noktası kabul edilen durağanlık, mevsimsel seriler için model oluşturmada da gereklidir.

⁴⁸ AKGÜL, I., a. g. e., s.144 - 146

⁴⁹ FRECHTLING, D.,C., a.g.e., s. 145-147

Mevsimsel özellik taşıyan ve durağan-dışı serilerin durağanlığının sağlanması için fark alma işlemi aylık verilerde,

$$\Delta_{12}y_t = y_t - y_{t-12}$$

üçer aylık serilerde

$$\Delta_4y_t = y_t - y_{t-4}$$

olacak şekilde gerçekleştirilmektedir.

Serinin mevsimsel bileşeninin zaman içinde sabit olmadığı görüldüğünde ise, fark alma işlemi uygulamadan serinin mevsimsel değişmesinin sabit bir seriye dönüştürülmesi gerekmektedir. Bu da genellikle seri değerlerinin doğal logaritması alınarak yapılmaktadır. Logaritması alınmışmış serinin yayılmasının artması durumunda ham veri yerine logaritması alınmışmış verinin kullanılması tavsiye edilmektedir.⁵⁰

1.9.1. Mevsimsel Otoregresif Modeller

Durağan bir zaman serisinin t -dönemindeki gözlemlerinin, bir önceki yılın karşı gelen dönemine ait gözlemlerinin artı rassal şokun doğrusal bir fonksiyonu olarak ifade edildiği durumda sürecin “mevsimsel otoregresif” süreç olduğu ifade edilmektedir. Mevsimsel zaman serisi için tanımlanan bağıntı genel olarak, mevsimsel AR parametresi ϕ_1 , durağan zaman serisi y_t , mevsim dönemi sayısı s , geçmiş dönem öngörü hataları ε_t olmak üzere;

$$y_t = \phi_1 y_{t-s} + \varepsilon_t \quad (1.29)$$

veya

$$\varepsilon_t = y_t - \phi_1 y_{t-s} \quad (1.30)$$

biçiminde gösterilir.

⁵⁰ AKGÜL, I., a. g. e., s. 177-182

(1.29) ve (1.30) modelleri “Mevsimsel Otoregresif Modeller” olarak adlandırılmakta ve kısaca $AR(P)_s$ veya $SAR(P)$ şeklinde gösterilmektedir.

Geri kaydırma işlemcisi B kullanılarak

$$(1 - \phi_1 B^s) y_t = \varepsilon_t \quad (1.31)$$

olacak şekilde ifade edilmekte ve (1.31) eşitliği genel olarak;

$$(\phi B^s) y_t = \varepsilon_t \quad (1.32)$$

şeklinde gösterilmektedir. Burada yer alan $\phi(B^s)$ polinomunun açılımı, mevsimsel AR parametresi P olmak üzere

$$\phi(B^s) = 1 - \phi_1 B^s - \phi_2 B^{2s} - \dots - \phi_P B^{Ps}$$

biçimde ifade edilir.⁵¹

1.9.2. Mevsimsel Hareketli Ortalama Modeli

Durağan bir zaman serisinin içinde bulunan dönemdeki gözlemlerinin rassal şokun artı s -dönem önceki rassal şokun doğrusal bir fonksiyonu olarak ifade edilmesi durumunda sürecin “Mevsimsel Hareketli Ortalama” süreci olduğu ifade edilmektedir. Bu gibi serilerin modellenmesinde de “mevsimsel hareketli ortalama” modelleri kullanılmaktadır.

Mevsimsellik özelliği taşıyan zaman serisileri için, temiz dizi (WN) özelliğini taşıyan hata terimi ε_t , mevsimsel MA parametreleri Θ_i , durağan zaman serisi y_t olmak üzere gözlemler arasındaki ilişki;

$$y_t = \varepsilon_t - \Theta_1 \varepsilon_{t-s} \quad (1.33)$$

veya geri kaydırma işlemcisi B yardımı ile

$$y_t = (1 - \Theta_1 B^s) \varepsilon_t \quad (1.34)$$

⁵¹ AKGÜL, I., a. g. e., s.188

şeklinde ifade edilir.

Aylık zaman serisi gözlemleri için mevsimsel MA modeli ise

$$y_t = \varepsilon_t - \Theta_{12}\varepsilon_{t-12} \quad (1.35)$$

şeklinde ifade edilir.

Burada yer alan $\Theta(B^s)$ polinomunun açılımı, mevsimsel MA parametresi Q olmak üzere,

$$\Theta(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_P B^{Ps}$$

biçimde gösterilmektedir.

Yukarıdaki modeller “Mevsimsel Harekerli-Ortalama Modelleri” olarak adlandırılmakta ve kısaca $MA(Q)_s$ veya $SMA(Q)$ şeklinde gösterilmektedir.⁵²

1.9.3. Mevsimsel Otoregresif-Hareketli Ortalama Modeli

Mevsimsel zaman serilerinin hem mevsimsel AR ve hem de mevsimsel MA süreçlerinin etkisini taşıdığı zaman serisi modelleri, "mevsimsel karma modeller" veya "Mevsimsel $ARMA(P, Q)$ " olarak adlandırılmakta ve $ARMA(P, Q)_s$ veya $SARMA(P, Q)$ şeklinde gösterilmektedir. Burada P , mevsimsel AR mertebesini ve Q da mevsimsel MA mertebesini göstermektedir. $SARMA(P, Q)$ modeli

$$y_t = \phi_{1s}y_{t-s} + \phi_{2s}y_{t-2s} + \dots + \phi_{Ps}y_{t-Ps} + \varepsilon_t - \theta_{1s}\varepsilon_{t-s} + \theta_{2s}\varepsilon_{t-2s} + \dots + \theta_{Qs}\varepsilon_{t-Qs} \quad (1.36)$$

veya

$$y_t = \Phi_1 y_{t-s} + \Phi_2 y_{t-2s} + \dots + \Phi_P y_{t-Ps} + \varepsilon_t - \Theta_1 \varepsilon_{t-s} + \Theta_2 \varepsilon_{t-2s} + \dots + \Theta_Q \varepsilon_{t-Qs} \quad (1.37)$$

eşitlikleri tanımlanmaktadır. $SARMA(P, Q)$ modeli geri kaydırma işlemcisi B yardımıyla

$$\begin{aligned} (1 - \phi_{1s}B^s - \phi_{2s}B^{2s} - \dots - \phi_{Ps}B^{Ps}) y_t &= (1 - \theta_{1s}B^s - \theta_{2s}B^{2s} - \theta_{Qs}B^{Qs}) \varepsilon_t \\ (1 - \Phi_{1s}B^s - \Phi_{2s}B^{2s} - \dots - \Phi_{Ps}B^{Ps}) y_t &= (1 - \Theta_{1s}B^s - \Theta_{2s}B^{2s} - \Theta_{Qs}B^{Qs}) \varepsilon_t \end{aligned}$$

⁵²AKGÜL, I., a. g. e., s. 193

veya kısaca

$$\Phi_P(B^s)y_t = \Theta_Q(B^s)\varepsilon_t \quad (1.38)$$

şeklinde ifade edilir. Burada, P mevsimsel AR sürecinin mertebesini, Q da mevsimsel MA sürecinin mertebesini göstermek üzere $\Phi_P(B^s)$ ve $\Theta_Q(B^s)$ P ve Q mertebelerinde B^s nin polinomlarını simgelemektedir.⁵³

1.9.4. Mevsimsel Bütünleşik Otoregresif-Hareketli Ortalama Modeli

Durağan-dışı zaman serisinin mevsimsel AR ve mevsimsel MA süreçlerine sahip olması durumunda oluşturulan modeller, $SARIMA(P, D, Q)$ veya $ARIMA(P, D, Q)_s$ olarak gösterilmektedir. Burada kullanılan P, D, Q simgeleri sırası ile mevsimsel AR mertebesini, mevsimsel fark alma derecesini ve mevsimsel MA mertebesini göstermektedir.

Bu modellerde zaman serisi gözlemleri sadece mevsimsel gecikmelerde ve katlarında bağımlı olmakta, mevsim içindeki gözlemler bağımsız olmaktadır. Mevsim etkisi taşıyan seriler, hem mevsimsel olmayan hem de mevsimsel olan kısım olarak modelde yer alacakları için modellerde bu ayrıma uygun olarak mevsimsel olan parametreler ve mevsimsel olmayan parametreler olarak ifade edilmeleri gerekmektedir.

P, D, Q mertebelerinde mevsimsel $ARIMA$ modeli ($SARIMA(P, D, Q)$) geri kaydırma işlemcisi B yardımı ile

$$\Phi_P(B^s)\Delta_s^D y_t = \Theta_Q(B^s)\varepsilon_t \quad (1.39)$$

şeklinde ifade edilmektedir. Modelde yer alan Δ_s^D mevsimsel fark işlemcisini, s mevsimsel dönemleri göstermekte olup; aylık zaman serisi gözlemleri için $s = 12$ olarak alınmaktadır. Δ^D simgesi serinin D-kere mevsimsel farkının alındığını, Δ^d simgesi ise serinin d-kere mevsimsel olmayan farkının alındığını göstermektedir.

⁵³AKGÜL, I., a. g. e., s.197

(1.39) modelinde yer alan $\Phi_P(B^s)$ ve $\Theta_Q(B^s)$ P ve Q mertebelerinde B^s nin polinomlarıdır. Tüm işlemciler ile yapılan dönüşümler sonrasında serinin durağanlığı sağlanmakta ve durağan-dışı seri, Δ_s^D mevsimsel fark alma işlemleri sonrası durağan seri olarak ifade edilmektedir.

Durağan-dışı y_t serisi için mevsimsel *ARIMA* modeli,

$$\Delta_s^D y_t = \frac{\theta(B^s)}{\phi(B^s)} \varepsilon_t \quad (1.40)$$

veya

$$\Delta_s^D y_t = \frac{\Phi_P(B^s)}{\Theta_Q(B^s)} \varepsilon_t \quad (1.41)$$

şekilde ifade edilebilir. (1.40) (1.41) eşitliklerinde yer alan $\theta(B)$ ve $\phi(B)$ ve $\Phi(B)$ ve $\Theta(B)$ polinomları için uygun gösterimler model belirleme yöntemleri kullanılarak elde edilmektedir.

Mevsimsel *ARIMA*(P, D, Q) modelinin genel açılımı, mevsimsel MA parametreleri θ_{qs} , Θ_q ve mevsimsel AR parametreleri ϕ_{ps} , Φ_P olmak üzere, (1.40) modeli için

$$(1 - B^s)^D y_t = \frac{(1 - \theta_{1s}B^s - \theta_{2s}B^{2s} - \dots - \theta_{qs}B^{Qs})}{(1 - \phi_{1s}B^s - \phi_{2s}B^{2s} - \dots - \phi_{ps}B^{Ps})} \varepsilon_t$$

(1.41) modeli için de

$$(1 - B^s)^D y_t = \frac{(1 - \Theta_1B^s - \Theta_2B^{2s} - \dots - \Theta_qB^{Qs})}{(1 - \Phi_1B^s - \Phi_sB^{2s} - \dots - \Phi_pB^{Ps})} \varepsilon_t$$

olarak yapılmaktadır.⁵⁴

Uygulamalarda genelde mevsimsel *AR* ve *MA* süreçlerinin mertebelri P ve Q , 3' den küçük ve mevsimsel fark alma derecesi D ise sıklıkla 1 olarak alınmaktadır.⁵⁵

⁵⁴ AKGÜL, I., a. g. e., s. 200

⁵⁵ BROCKWELL, P.J., DAVIS, D.A. "Introduction to Time Series and Forecasting", Springer-VerlagInc., New York, 2002, s. 203

1.9.5. Mevsimsel Box-Jenkins Yaklaşımı Aşamaları

Mevsimsel olmayan Box-Jenkins yaklaşımında olduğu gibi, mevsimsel Box-Jenkins yaklaşımında da dört aşamalı bir model kurma stratejisi önermektedirler. Bu aşamalar;

- 1) Model Belirleme
- 2) Model Parametrelerinin Tahmini
- 3) Modelin Uygunluğunun Test Edilmesi
- 4) İleriye Yönelik Öngörü (Tahmin)

olarak adlandırılmakta, ancak mevsimsel bileşenin varlığı nedeni ile modeller daha karmaşık ve alternatif modeller daha çok sayıda olmaktadır.⁵⁶

Model belirleme aşamalarından, Model Parametrelerinin Tahmini, Modelin Uygunluğunun Test Edilmesi, İleriye Yönelik Tahmin (Öngörü) mevsimsel olmayan modellerde olduğu gibi mevsimsel olan model kurmada da geçerlidir.⁵⁷

Model Belirleme aşamasında öncelikle durağanlığın araştırması yapılmaktadır. Mevsimsel olmayan modellerde durağan-dışılık gözlemlendiğinde serinin birinci mertebe (veya ilk regular) farkı (seri durağanlık özelliği gösterene kadar)

$$z_t = y_t - y_{t-1}$$

olacak şekilde farkları alınmaktadır.

Mevsim etkisi taşıyan serilerde durağanlığı sağlamak için mevsimsel farkın alınması ile durağanlık sağlanmaktadır. Bu işlem aylık zaman serisi gözlemleri için

$$z_t = y_t - y_{t-s} = y_t - y_{t-12}$$

şeklinde gerçekleştirilmektedir.

⁵⁶ AKGÜL, I., a. g. e., s. 203

⁵⁷ ORHUNBİLGE, N., a. g. e., s. 208

Durağan hale getirilen zaman serisi için geçici model belirleme aşaması tamamlandıktan sonra, diğer model belirleme aşamaları mevsimsel olmayan model belirleme aşamalarına benzer şekilde yapılır. Mevsim etkisinin gözlemlendiği 12, 24, 36 kaydırmalar için OKF ve KOKF' nin davranışları da dikkate alınarak analizler gerçekleştirilerek, uygun *ARIMA* modeli (veya modelleri) belirlenir.⁵⁸

1.10. Öngörü (Tahmin)

Zaman serileri konusunda önemli kavramlardan biri de, bir zaman serisi değişkeninin gelecekte alacağı değerlerin kestirilmesidir. "Tahmin", "kestirim" ve "öngörü" kavramları birbirine yakın anlamlar içermesine rağmen, aslında bu üç terim birbirinden tamamen farklı anlamlar içermektedir.

Tahmin, bir kitlenin parametresi hakkında elde edilen bir istatistiğin aldığı değerdir. Kestirim ise bir değişkenin seçilen modele göre parametrelerin yerine konulması ile elde edilen (değişkenin almasını beklediğimiz) değerdir.

Öngörü ise gözlemlenen değerlerin dışında (mevcut verilerin haricinde) değişkenin ileriki zamanlarda (bir gün sonraki, bir ay sonraki, bir yıl sonraki, gibi) değişkenin alması beklenen değer olarak açıklanabilir.⁵⁹

Box-Jenkins yöntemiyle zaman serileri analizinde geçerliliği onaylanan *ARIMA* modeli için ilk olarak zaman serisi sürecinin beklenen değeri hesaplanır. Daha sonra beklenen değer beklenen değerler yardımı ile zaman serisinin gelecekte alacağı değerler hesaplanmaya çalışılır. y_t zaman serisinin bugünkü değeri olmak üzere, $y_{t+1}, y_{t+2}, \dots, y_{t+L}$ değerleri elde edilen *ARIMA* model yardımı ile kestirilebilir. y_{t+L} ' nin kestirimi $y_t(L)$ biçiminde simgelenir.

⁵⁸ AKGÜL, I., a. g. e., s. 203-204

⁵⁹ AKDİ, Y., "Zaman Serileri Analizi (Birim Kökler ve Kointegrasyon)", Bıçaklar Kitapevi, Ankara, 2003, s. 94

ARIMA modeli ile kestirim yapılırken ilk olarak bir dönem sonraki kestirim değeri hesaplanmakta, bulunan kestirim değeri iki dönem sonraki kestirim değerinin hesaplanmasında kullanılmaktadır. Bu işlemler kestirilecek dönem sayısına ulaşmaya kadar devam etmektedir.⁶⁰

Çevrilebilir ve durağan bir $ARIMA(p, 0, q)$ stokastik süreci y_t için, $t = n + L$ olmak üzere

$$y_{t+L} = \phi_1 y_{t+L-1} + \dots + \phi_p y_{t+L-p} + \varepsilon_{n+L} - \theta_1 \varepsilon_{n+L-1} - \dots - \theta_q \varepsilon_{n+L-q} \quad (1.42)$$

eşitliği ile verilebilir. Burada, n en son gözlem değeri, L de kestirimi yapılacak dönemi göstermektedir. (1.42) eşitliğinden y_{t+L} 'nin beklenen değeri

- 1) Şimdiki ve geçmiş hata terimleri ε_{n+j} ($j < 0$) için gerçek hata terimleri,
 - 2) Gelecek dönem hata terimlerinin ε_{n+j} ($0 < j < L$) beklenen değeri için sıfır,
 - 3) Şimdiki ve geçmiş gözlem değerleri y_{t+j} ($j \leq 0$) için gerçek gözlem değerleri,
 - 4) Gelecek dönem gözlem değerleri y_{t+j} ($0 < j < L$) için y_{t+L} 'nin yaklaşık kestirimi
- kullanılarak elde edilir.

Durağan olmayan zaman serilerinde önce seri durağanlaştırılır ve daha sonra $ARMA(p, q)$ sürecinde olduğu gibi kestirim yapılmaya çalışılır. Fark alınarak durağanlaştırılmış seri için yapılan kestirimlerden sonra orijinal seriye dönüşüm yapılır.⁶¹

1.10.1. Performans Ölçütü

Çeşitli tahmin modelleri arasından birini seçme sürecinde yaygın kabul gören kriterlerden birisi de, modelin verilere iyi uyum göstermesi yani modelin öngörü

⁶⁰ AKGÜL, I., a.g.e., s.146

⁶¹ MONTEGOMERY vd., a.g.e., s. 275-278

başarısının yüksek olmasıdır. Örneğin iki ARIMA modelinin faydası ve geçerliliği eşit olduğunda, iki modelin tahmin başarıları karşılaştırılmakta ve daha iyi öngörü doğruluğu sağlayan model tercih edilmektedir. Bu anlamda modellerin öngörü doğruluklarının karşılaştırılması amacı ile çeşitli istatistikler kullanılmaktadır.

Bu istatistikler: Ortalama Hata Kare (OHK), Kök Ortalama Hata Kare (KOHK), Ortalama Öngörü Hata Kare (OÖHK), Ortalama Mutlak Yüzde Hata (OMYH), Ortalama Mutlak Hata (OMH), Ortalama Yüzde Hata (OYH), Kök Ortalama Yüzde Hata Kare (KOYHK) olarak sayılabilir.

Bu kriterler; t döneminde gerçekleşen değer Y_t , t dönemi için hesaplanan öngörü değeri $\hat{Y}_t$, öngörülen dönem sayısı n , t dönemindeki öngörü hatası, e_t ve $e_t = Y_t - \hat{Y}_t$ olmak üzere,

$$OHK = \frac{\sum_{n=1}^n e_t^2}{n} \quad (1.43)$$

$$KOHK = \sqrt{\frac{\sum_{n=1}^n e_t^2}{n}} \quad (1.44)$$

$$OMH = \frac{\sum_{n=1}^n |e_t|}{n} \quad (1.45)$$

$$OYH = \frac{\sum_{n=1}^n \frac{e_t}{y_t}}{n} * 100 \quad (1.46)$$

$$KOYHK = \sqrt{\frac{1}{n} \sum_{n=1}^n \frac{e_t^2}{y_t}} \quad (1.47)$$

$$OMYH = \frac{\sum_{n=1}^n \frac{|e_t|}{y_t}}{n} * 100(\%) \quad (1.48)$$

formülleri ile hesaplanır.

Ele alınan bütün istatistiklerde istenen sonuç, en küçük OHK, KOHK, OÖHK, OMYH, OMH ve OYH KOYHK istatistik değerlerine sahip tahmin modelini oluşturmaktır. Ancak hangi istatistiğin kullanılması gerektiği konusunda belirli bazı kriterler takip edilmektedir.

Hata değerlerinin büyüklükleri benzer ise eşitlik (1.43) ile verilen “Ortalama Hata Kare ” (OHK) kullanılabilir. Ancak, tahmin sonrası bir ya da birden fazla ortalamanın üzerinde büyük hata yada hatalar elde edilmiş ise, OHK’ nin kullanımı uygun olmayabilir.

OHK istatistiği, hataların karelerini aldığı için büyük sapmaların olması durumunda abartılı sonuçlar vermektedir. Büyük sapmaların gözlemlendiği durumlarda bu istatistiğin yerine “Ortalama Mutlak Hata” (OMH) kullanılabilir.

Bazen bir tahmin yönteminin yansız olup olmadığının belirlenmesi gerekebilir. Modelden hesaplanan değerler, gerçekleşen değerlerin altında veya üstünde çıkıyorsa yansızlık gerçekleşmez. Bu gibi durumlarda “Ortalama Yüzde Hata”(OYH) kullanılmaktadır.

Hata değerlerinin birim değerleri farklılık gösteriyorsa, örneğin bir tahmin modeli gerçek değerleri kullanıyor iken bir başka tahmin modeli doğal logaritması alınmış değerleri kullanıyorsa, yararlanılabilecek istatistik “Ortalama Mutlak Yüzde Hata” (OMYH)’dır. OMYH istatistiği, farklı birim değerlere sahip modellerin karşılaştırılmasında ortaya çıkabilecek dezavantajları elimine etmektedir.

Sayılan kriterler arasında “Ortalama Mutlak Yüzde Hata” (OMYH)’nın öngörü hatalarını yüzde olarak ifade etmesi nedeni ile tek başına da bir anlamının olması, diğer kriterlere göre üstünlüğü olarak kabul edilmektedir.⁶²

⁶² AKGÜL, I., a. g. e., s.135-139

Witt ve Witt, OMYH deęerleri %10'un altında olan tahmin modellerini "yüksek doęruluk" derecesine sahip, %10 ile %20 arasında olan modelleri ise doęru tahmin modelleri olarak sınıflandırmıştır.

Benzer şekilde Lewis, OMYH 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.⁶³

Song ve Witt ile Song ve Turner'de turizm talebi tahmin modellerinin performanslarının deęerlendirilmesinde en fazla kullanılan kriterlerin, OMYH ve KOHK istatistikleri olduğunu belirtmişlerdir.⁶⁴

⁶³STEPHEN F. WITT ve C. WITT, "Modeling and Forecasting Demand in Tourism", Academic Press: London, 1992, s. 137 aktaran ÇUHADAR vd. "Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleriyle Karşılaştırmalı Bir Analizi : Antalya İline Yönelik Bir Uygulama", Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Yıl: 2009, C: 14, S.1, s.107

⁶⁴SONG, H. ve WITT, S. F., a.g.e., s.185

İKİNCİ BÖLÜM

YAPAY SİNİR AĞLARI

Bu bölümde Yapay sinir ağları ile ilgili genel kavramlar, Yapay sinir ağları'nın tarihçesi, Yapay sinir ağları yapısı, Yapay sinir ağları'nın temel elemanları, Yapay sinir ağları'nın özellikleri, Yapay sinir ağları'nın sınıflandırılması, bazı Yapay sinir ağları mimarileri konularına değinilmektedir.

2.1. Yapay Sinir Ağlarının Tanımı

Yapay sinir ağları, insan beynine ait öğrenme yolu ile yeni bilgi türetebilme, yeni bilgi oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan doğrudan gerçekleştirmek amacı ile geliştirilen algoritmalar olarak tanımlanabilir.⁶⁵

Yapay sinir ağları, deneyime dayalı bilgiyi depolamaya ve bu bilgileri kullanıma sunmaya yönelik doğal bir eğilim içerisinde olan yoğun paralel dağılmış bir işlemcidir. ⁶⁶Yapay sinir ağları (YSA), insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarıdır. Daha açık bir ifade ile biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır.

Yapay sinir ağları bir programcının geleneksel yeteneklerini gerektirmeyen, kendi kendine öğrenme düzenekleri olarak da adlandırılabilir. Yapay sinir ağları öğrenmenin yanı sıra ezberleme ve bilgiler arasında ilişki kurma yeteneğine de

⁶⁵ÖZTEMEL, E., "Yapay Sinir Ağları", İstanbul, 2003, s. 29

⁶⁶HAYKIN, S, "Neural networks: A Comprehensive Foundation", Pearson Prentice Hall, India,1999, s. 23

sahiptir. Yapay sinir ağıları insan beyninin bazı organizasyon ilkelerine benzeyen özellikleri kullanmaktadır.⁶⁷

2.2. Yapay Sinir Ağlarının Tarihçesi

İlk Yapay sinir ağıları modeli 1943 yılında sinir hekimi olan McCulloch ve matematikçi Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağı modellemişlerdir.

Wiener "Cybernetics" isimli kitabında (1948) sinirlerin çalışması ve özelliklerine dinmiştir. Hebb "Organization of Behavior" isimli kitabında (1949) öğrenme ile ilgili temel teoriyi ele almıştır. Hebb öğrenebilen ve uyum sağlayabilen sinir ağıları modeli için Hebb kuralını ortaya koymuştur. Hebb kuralı, sinir ağının bağıntı sayısı değiştirilebilirse, öğrenebileceğini ortaya koymuştur.⁶⁸

Rosentblatt' ın Perceptron' u gerçekleştirmesinden sonra (1957) yapay sinir ağı alanındaki gelişmeler hızlanmıştır. Perceptron, beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar sonucunda ortaya çıkan katmanlı eğitilebilen ve tek çıkışa sahip yapay sinir ağıdır.

Widrow ve Hoff ADALINE VE MADALINA olarak adlandırdıkları ağı modellerini geliştirdiler (1959). MADALINA, telefon hatlarında oluşan yankıları yok eden uyarlanabilir süzgeç olarak kullanılmış, gerçek dünya sorunlarına uyarlanmış ilk sinir ağıdır.

Hopfield 1982 yılında ağların önemli sınıflarının matematik temellerini üretmiştir.

⁶⁷ELMAS, Ç., a.g.e., s. 23

⁶⁸ARBIB, M. A., "The Handbook of Brain Theory and Neural Networks", The MIT Press, England, 2003, s. 10

1984 yılında Kohonen sinirlerin düzenli sıralanışına eşleme özelliği için danışmansız öğrenme ağlarını geliştirmiştir.

1986 yılında Rumelhart ve McClelland karmaşık ve çok katmanlı ağlar için geriye yayılmalı öğrenme algoritması ortaya koymuştur.⁶⁹

1997 yılında "The Deep Blue" isimli satranç programı geniş bir kitlenin izlediği maçta dünya satranç şampiyonu G. Kasparov'u mağlup etti.

1998 yılında internetin yaygınlaşması ile birlikte, yapay zeka tabanlı bir çok bilgisayar programı geniş kitlelere ulaştı.⁷⁰


Güntümüzde Yapay sinir ağları ile ilgili pek çok araştırma yapılmaktadır. Başlıca araştırmalar, Yapay sinir ağları' nın eğitimi üzerine odaklanmıştır. Burada amaç, yeni ve daha verimli öğrenme algoritmaları, zamana bağlı olarak değişen modellere karşılık verebilen ağlar ve silikon sinir ağları geliştirmek şeklinde özetlenebilir.

2.3. Biyolojik Bir Beyin Sinir Hücresinin Yapısı

Yapay sinir ağları nın daha iyi anlaşılabilmesi için örnek teşkil eden doğal sinir ağı olan biyolojik sinir ağlarının yapısının ve çalışma ilkelerinin iyi bilinmesi gerekir. İnsan beyninin korteks kısmında yer alan sinir hücresi sayısı yaklaşık olarak 10^{11} olup her hücre sayısı, 10000 arasında değişen başka hücrelerle karşılıklı ilişki içerisinde. İnsan beyninin çalışma frekansı 100 Hz' dir.

⁶⁹ELMAS, Ç., a.g.e., s. 26-28

⁷⁰DOĞAN, A., "Yapay Zeka", Kariyer Yayıncılık, İstanbul, 2002, s. 51



Şekil 3.1. Biyolojik Sinir Hücresi ve Bileşenleri

Kaynak: Gurney, 1999: 3

Şekilde basitleştirilmiş biyolojik bir sinir hücresi ve bileşenleri ile ilişkisi gösterilmektedir. Tüm doğal sinirlerin dört temel bileşeni vardır. Bunlar, dendritler, soma, akson ve sinaps'tır. Sinir hücresine diğer sinir hücrelerinden gelen uyarımlar, dendritler aracılığıyla hücre gövdesine taşınır ve hücre içi kararlılık halinin bozulmasıyla oluşan bir kimyasal süreç içerisinde diğer hücelere aksonlarla iletilir; uyarımların diğer sinir hücrelerine taşınabilmesinde akson uçları ile dendritler arasındaki sinaptik boşluklar (sinaps) rol oynar.

Matematiksel olarak gerçek değerli etkinlik sinirin yüzey zarında t zamandaki gerilimi temsil eder. Etkinlik pozitif ya da negatif olabildiği gibi terik olarak da sonsuz olabilir.⁷¹

2.4. Yapay Sinir Hücresi

Nöronlar sinir ağlarını oluşturan, tek başına ele alındıklarında çok basit işleve sahip işlemcilerdir. Bir nöron yapısı içerisinde üç ana bölüm bulunmaktadır.


⁷¹ELMAS, Ç., a.g.e., s. 28-30

Bunlar sırasıyla sinapslar, toplayıcı ve aktivasyon fonksiyonudur.⁷²

Yapay sinir ağları, insan beyni gibi öğrenme hatırlama ve genelleme yeteneğine sahiptir. İnsan beyinde öğrenme üç şekilde gerçekleşir;

- 1) Aksonlar üreterek,
- 2) Aksonların uyarılmasıyla,
- 3) Mevcut aksonların güçlerini değiştirerek.

Yapay sinir ağlarının temel birimi işlem elemanı ya da düğüm (sinir) olarak adlandırılan yapay bir sinirdir. Bir yapay sinir, biyolojik sinirlere göre daha basit olmasına karşın, biyolojik sinirlerin dört temel işlevini taklit etme özelliğine sahiptir.



Şekil 3.2. Yapay Sinir Hücresi (Nöron)

Kaynak: Haykin, 1999: 33

Şekil 3.2 de yapay bir sinir (düğüm) gösterilmiştir.

Girişler x_m sembolüyle gösterilmiştir. Bu girişlerin her biri ağırlık w_k ile çarpılır. Basitçe, bu ürünler eşik değeri b_k ile toplanır ve sonucu oluşturmak

⁷²EFE, Ö. ve KAYNAK, O., "Yapay Sinir Ağları ve Uygulamaları", Bogaziçi Üniversitesi Yayınevi, İstanbul, 2000, s. 6

için etkinlik işlevi ile işlem yapılır son olarak y_k çıkışı elde edilir.

Tüm yapay sinir ağları bu temel yapıdan türetilmiştir. Bu yapıdaki farklılıklar Yapay sinir ağları' ların farklı sınıflandırılmasını sağlar. Bir yapay sinirin öğrenme yeteneği, seçilen öğrenme algoritması içerisinde ağırlıklarının uygun bir şekilde uyarlanmasına bağlıdır.⁷³

2.5. Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağlarının karakteristik özellikleri uygulanan ağ modeline göre değişmekle birlikte, bütün modeller için geçerli olan genel özellikleri aşağıdaki gibi sıralanabilir:

Yapay sinir ağları öğrenmenin bir modeli olarak düşümlenebilir. Örneklerden faydalanarak öğrenme işlemini gerçekleştirir.

Yapay sinir ağları yardımıyla bir kararın verilebilmesi için öncelikle ağın eğitilmesi gerekir.

Yapay sinir ağları eksik bilgileri işleyerek sonuca varabilir.

Yapay sinir ağları hatalara karşı toleranslıdır.

Yapay sinir ağlarının yapısına uygun olarak yerel çözümlere takılabilir. Uygun ağ yapısının belirlenmesi genellikle deneme yanılma yoluyla gerçekleştirildiği için bu durum Yapay sinir ağlarının dez avantajı olarak görülebilir.

Yapay sinir ağlarının bir çoğunda öğrenme katsayısının, gerekli katma ve katmanlardaki hücre sayılarının belirlenmesinde kesin bir kural olmamaktadır. Gizli katmandaki sinir sayısı, bir tanıma işleminin doğruluğunu ve eğitim hızını etkilemektedir.

⁷³ELMAS, Ç., a.g.e., s. 30-31

Yapay sinir ağlarının eğitilmesinde kullanılan örnekler önemlidir.

Bilgilerin ağa gömülü olmasından dolayı yorumlanması ve çözümün elde edilebilmesinde yapay sinir ağlarının davranışının takibi zordur.

Yapay sinir ağlarının bu özelliklerinin yanında doğrusal olamayan, çok boyutlu, gürültülü, eksik bilgili ve özellikle problemin çözümünde kesin bir modelin veya algoritmanın elde edilemediği durumlarda başarılı olduğu bilinmektedir. ⁷⁴

2.6. Yapay Sinir Ağlarının Yapısı


Yapay sinir ağları düğüm veya sinir olarak adlandırılan çok sayıdaki elemanların bir araya gelmesinden oluşur. Bir sinir ağı, nöron sıralı bir şekilde (paralel olarak) ard arda bağlanmasından oluşur. Eğer giriş katmanına bir işaret girerse, bu işaret nöronlar arasındaki bağlantılar yoluyla diğer katmana iletilir.

Yapay sinir ağlarının nöronları ve bağlantıları çok değişik şekillerde bir araya getirilebilir. Yapay sinir ağları bu nöron ve bağlantı mimarilerine göre isimlendirilirler. Bu mimariler, nöronlar arasındaki bağlantıların yönlerine göre ileri beslemeli ve geri beslemeli ağlar olarak adlandırılmaktadır.

Ağ içersindeki nöronlar katmanlar halinde yerleştirilir. İlk katmana verilen bilgi ileriye doğru yayılır. Son katmandaki işaretler ağın çıkışıdır.

Sadece giriş ve çıkış katmanı olan, ara (gizli) katmanı olmayan ağlar karmaşık işlemleri hesaplayamaz. Bu nedenle karmaşık hesaplamalar için oluşturulacak ağlarda en az bir katman bulunmalıdır.

⁷⁴NABİYEYEV, N. N., "Yapay Zeka", Seçkin Kitapevi, Ankara, 2010, s. 579-580



Şekil 3.3. Çok Katmanlı Bir Yapay Sinir Ağ Yapısı

Kaynak: Fırat ve Güngör, 2005

Şekil 3.3. de gizli katmana sahip dört katmanlı bir yapay sinir ağı görülmektedir. Bu tür ağlar, giriş katmanı, bir veya birden çok gizli katman ve çıkış katmanından oluşmaktadır. Bir katmandaki her nöron, bir sonraki katmanın bütün nöronları ile bağlantılıdır.

Giriş katmanından alınan girişler, giriş katmanı ve gizli katman arasında bulunan bağlantı ağırlıkları ile çarpılıp gizli katmana iletilmektedir. Gizli katmandaki nöronlara gelen girişler toplanarak aynı şekilde gizli katman ile çıkış katmanı arasındaki bağlantı ağırlıkları ile çarpılarak çıkış katmanına iletilir. Çıkış katmanındaki nöronlar da, kendisine gelen bu girişleri toplayarak uygun bir çıkış üretirler.⁷⁵

⁷⁵ELMAS, Ç., a. g. e., s. 41-43

2.7. Yapay Sinir Ağlarının Temel Elemanları

Yapay sinir ağlarının temel birimi işlem elemanı yada düğüm olarak adlandırılan yapay bir sinirdir. Bir yapay sinir, biyolojik sinir hücrelerinin işlevlerini taklit ederler. Yapay sinir ağlarının temel elemanları, Girişler, Ağırlıklar, Toplama İşlevi, Etkinlik İşlevi, Ölçekleme ve Sınırlama ve Çıkış İşlevi olarak sıralanabilir. Adı geçen temel elemanlar aşağıda açıklanmıştır.

Girişler: Girişler $(x_1, x_2, \dots, x_m)$ çevreden aldığı bilgiyi nörona getirir. Girişler kendinden önceki nöronlardan veya dış ortamdan sinir ağına girebilirler. Bir nöron genellikle gelişmiş güzel bir çok girdileri alır.

Ağırlıklar: Ağırlıklar $(w_1, w_2, \dots, w_k)$, yapay sinir ağları tarafından alınan girişlerin nöron üzerindeki etkisini belirleyen uygun katsayılardır. Her bir giriş kendine ait bir aralığa sahiptir.

Bir ağırlığın büyük değere sahip olması, o girişin yapay nörona güçlü bağlanması (önemli olması), küçük olması ise zayıf bağlanması (önemli olmaması) olarak ifade edilmektedir.

Toplama İşlevi: Toplama işlevi v_i , sinirde herbir ağırlığın ait olduğu girişlerle çarpımının toplamalarını eşik b_k değeri ile toplayarak etkinlik işlevine gönderir.

Etkinlik İşlevi: Toplama işlevi sonuç değeri, etkinlik işlevinden f (etkinlik) geçirilip çıkışa iletilir. Etkinlik işlevinin kullanım amacı, zaman söz konusu olduğunda toplama işlevinin çıkışının değişmesine izin vermektir. Nöron, etkinlik işlevinin eşik seviyesinin altında ise çıkış üretilmez. Etkinlik işlevinin değeri eşik seviyesinin üzerinde ise nöron çıkış üretir.

Etkinlik işlevinin çıkışı y_i , giriş vektörleri x_i tarafından uyarlandığında

$$y_i = \begin{cases} 1, & \text{eğer } w_1x_1 + w_2x_2 + \dots + w_nx_n \geq T \\ 0, & \text{eğer } w_1x_1 + w_2x_2 + \dots + w_nx_n < T \end{cases} \quad (2.1)$$

İkili girişlerin bir örneği verildiğinde, etkinlik işlevi ya 0 ya da 1 çıkış verecektir.

Ölçekleme ve Sınırlama: Nöronlarda, etkinlik işlevinin sonuçları ölçek veya sınır işlemlerin geçebilir. Bu ölçeklendirme basitçe bir ölçek etmeni ile etkinlik değerinin çarpımının sonucudur. Sınıflandırma ise ölçeklenmiş sonuçların en az ve en çok sınırlarını aşamamasını sağlamaktır.

Çıkış İşlevi: Çıkış, $y_i = f(s)$, etkinlik işlevi sonucunun dış dünyaya ve diğer nöronlara gönderildiği yerdir. Bir nöronun bir tek çıkışı vardır. Nöronun bu çıkışı, kendinden sonra gelen herhangi bir sayıdaki diğer nöronlara giriş olabilir.

Her bir nöronda bir çıkış işaretine izin verilir. Bu işaret diğer yüzlerce nöron hücrelerinin girişi olabilir. Bu durum biyolojik sinirde olduğu gibidir. Biyolojik sinirde bir çok giriş varken sadece bir çıkış etkinliği vardır. Nöron çıkışı, etkinlik işlevi sonucuna eşdeğerdir. Fakat bazı ağ yapıları, komşu sinirler arasında yarışma oluşturmak için etkinlik işlevi sonuçlarını düzenleyebilir. Böylece yarışmacı girişler herhangi nöronun öğrenme ya da uyma işlemine katılacağına karar verilmesinde yardımcı olur.

Yukarıdaki anlatılanların ışığında yapay nöron ile biyolojik sinirler arasındaki benzerlikler tablo 3.1' teki gibi gösterilebilir.⁷⁶

⁷⁶ELMAS, Ç., a. g. e., s. 32-35

Tablo 3.1. Biyolojik Sinir İle Yapay Sinir Ağının Karşılaştırılması	
Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel hesaplama Sistemi
Sinir	Nöron (sinir-düğüm, İşlem elemanı)
Sinaps	Sinirler arası bağlantı ağırlıkları
Dentrit	Toplama İşlevi
Hücre Gövdesi	Etkinlik İşlevi
Akson	Nöron Çıkışı

Kaynak: Elmas, 2010: 33

2.8. Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağları, öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. başka bir deyişle, normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretebilmektedirler. Bir insanın düşünme ve gözlemleme yeteneklerini gerektiren problemlere yönelik çözümler üretebilmesinin temel sebebi ise insan beyninin yaşayarak veya deneyerek öğrenme yeteneğidir. Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik (synaptic) bağlantıların ayarlanması ile olmaktadır. Yani, insanlar doğumlarından itibaren bir “yaşayarak öğrenme” süreci içerisine girerler. Bu süreç içinde beyin sürekli bir gelişme göstermektedir. Yaşayıp tecrübe ettikçe sinaptik bağlantılar ayarlanır ve hatta yeni bağlantılar oluşur. Bu sayede öğrenme gerçekleşir. Bu durum yapay sinir ağları için de geçerlidir.⁷⁷

Yapay sinir ağlarında bilgi, ağdaki bağlantıların ağırlıklarında depolanır. Bir ağda öğrenme kısaca, istenen bir işlevi yerine getirecek şekilde ağırlık değerlerinin

⁷⁷YURTOĞLU, H., a.g.e., s. 4-5

ayarlanması süreci olarak özetlenebilir. Bu yaralama işlemi sinirler arasındaki ağırlıkların değiştirilmesi ile gerçekleşmektedir. Buna göre nöronlar arası bağlantılar üzerindeki ağırlıkların, belirli bir öğrenme kuralı uyarınca değiştirilebilen ağırlar eğitilebilir. Eğitilebilen yani öğrenebilen ağırlar, istenen işlevleri (şekil tanıma, sınıflama) yerine getirebilir.

Birçok araştırmacı Hebb' in kurallarını örnek alarak yapay sinir ağlarının nasıl öğreneceği konusun çalışmalarını sürdürmektedirler. Genellikle çalışmalarda Hebb' in ortaya koyduğu nöronlar arasındaki öğrenme değişkenleri ve ağırlıklarının (sinaptik kuvvetin) nasıl ayarlanacağı konusunu ele almışlar ve bunlara uygun öğrenme yöntemleri geliştirmişlerdir. Temelde öğrenme yöntemleri, danışmanlı (öğretmenli) ve danışmansız (öğretmensiz) olmak üzere iki gruba ayrılmıştır.⁷⁸ Öğrenme yöntemleri alt başlıklarda açıklanmıştır.

2.8.1. Danışmanlı Öğrenme

Yapay sinir ağlarında gerçek çıkış, istenen çıkışla kıyaslanır. Rastgele değişen ağırlıklar ağ tarafından öyle ayarlanır ki, bir sonraki döngüde gerçek çıkış ile istenen çıkış arasında daha yakın karşılaştırma üretebilsin. Öğrenme yöntemi, bütün işleme elemanlarının anlık hatalarını en aza indirmeye çalışır. Bu hata azaltma işlemi, kabul edilebilir doğruluğa ulaşana kadar ağırlıklar devamlı olarak derlenir.

Danışmanlı öğrenmede, yapay sinir ağı kullanılmadan önce eğitilmelidir. Eğitim işlemi, nöron ağına giriş ve çıkış bilgileri sunmaktan oluşur. Bu bilgiler genellikle eğitim kümesi olarak tanımlanır. Yani, her bir giriş kümesi için uygun çıkış kümesi ağı sağlanmalıdır.


Birçok uygulamada, ağı gerçek veriler uygulanmak zorundadır. Bu eğitim

⁷⁸ELMAS, Ç., a. g. e., s. 87

safhası uzun zaman alabilir. Sinir ağı, belirli bir sıralamadaki girişler için istenen istatistiksel doğruluğu elde ettiği zaman eğitime işlemi tamamlanmış kabul edilir ve eğitime işlemi bitirilir. Öğrenim aşaması tamamlandıktan sonra ağ kullanılmaya başlandığında, bulunan ağırlıkların değeri sabit olarak alınır ve bir daha değiştirilmezler. Bazı ağ yapılarında ağ çalışırken çok düşük oranda eğitmeye izin verilir. Bu işlem ağların değişen koşullara uyum sağlamasına yardımcı olur.

Giriş ve çıkış bilgilerinin nasıl sunulacağı veya nasıl kodlanacağı, bir ağı başarılı bir şekilde yönlendirmek için önemli bir unsurdur. Yapay sinir ağları sadece sayısal giriş bilgileri ile çalışırlar. Bu yüzden ham bilgiler ölçeklendirilmelidir.

Danışmanlı öğrenmede giriş ve çıkış çiftlerinden oluşan eğitim bilgileri vardır. Ağ giriş bilgisine göre ürettiği çıkış değerini, istenen değerle karşılaştırarak ağırlıkların değiştirilmesinde kullanılacak bilgiyi elde eder. Girilen değerle istenen değer arasındaki fark hata değeri olarak önceden belirlenen değerden küçük oluncaya kadar eğitime devam edilir. Hata değeri istenen değer altına düştüğünde tüm ağırlıklar sabitlenerek eğitim işlemi sonlandırılır. Eğitim işlemi sırasında her bir eğitim bilgisi çifti için oluşan hata değerine göre ağırlıkların değiştirilmesine ‘örüntü kipi’ öğrenme, tüm eğitim kümesi için hataların toplanarak toplam hata değerine göre ağırlıkların değiştirilmesine ise ‘küme kipi’ öğrenme denilmektedir.



Şekil 2.4. Danışmanlı Öğrenme

Kaynak: Elmas, 2010: 89


Şekil 2.4 de Danışmanlı öğrenme gösterilmiştir.

Eğer verilen girişe karşılık istene çıkış üretileniyorsa, ağıın çıkış değerlerindenki hatayı en küçükleyecek şekilde bağlantı ağırlıklarının değıştirilmesi sağlanır.

Danışmanlı öğrenmeye; çok katmanlı perceptron , geriye yayılım, delta kuralı, “Widrow-Hoff” veya en küçük karelerin ortalaması ve uyarlanabilir doğrusal eleman anlamına gelen “ADALINE” örnek olarak verilebilir.⁷⁹

2.8.2. Danışmansız Öğrenme

Danışmansız öğrenmede sistemin doğru çıkış hakkında bilgisi yoktur ve girişlere göre kendi kendisini örnekler. Danışmansız olarak eğitilebilen ağılar, istenen ya da hedef çıkış olmadan giriş bilgilerinin özelliklerine göre ağırlık değerlerini ayarlar. Danışmansız öğrenme ana hatları ile şekil 2.5 de verilmiştir.



Şekil 2.5. Danışmansız Öğrenme

Kaynak: Elmas, 2010: 137

Danışmansız öğrenmeye; “Yarışmacı Öğrenme”; “Kohonen’in Özörgütlemeli Harita Ağları”; “Hebbian Öğrenme” ve “Grossberg Öğrenme” gibi öğrenme kuralları örnek olarak verilebilir. Kohonen tarafından geliştirilen danışmansız öğrenme yönteminin kullanıldığı özörgütlemeli harita ağı, biyolojik sistemlerdeki öğrenmeden esinlenmiştir. Bu yöntemde nöronlar öğrenmek için elverişli durum yada ölçülerini güncellemek için yarışır. En büyük çıkış ile işlenen nöron, kazananı belirler ve komşularına bağlantı boyutlarını güncellemeleri için izin verir. Kazanan

⁷⁹ELMAS, Ç., a. g. e., s. 88-96

nöron ile birlikte, onun topolojik komşuluğunda bulunan belli sayıda nörona gelen ağırlıklar da benzer şekilde değiştirilir.⁸⁰

2.8.3. Takviyeli Öğrenme

Bu tür bir eğitimde, ağa bir danışman yardımcı olur. Fakat danışman, her girdi seti için üretilmesi gereken çıktı setini sisteme göstermek yerine, sistemin kendisine gösterilen girdilere karşılık çıktısını üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu gösteren bir sinyal üretir. Sistem, danışmandan gelen bu sinyali dikkate alarak öğrenme sürecini devam ettirir. Bu öğrenme yönteminin kullanıldığı ağlara örnek olarak; Learning Vector Quantization Modeli verilebilir.⁸¹

2.9. Yapay Sinir Ağı Mimarileri

Yapay sinir ağı mimarileri, sinir ağlarının işaretin akış yönüne bağlı olarak isimlendirilmektedir. Buna göre, ileri beslemeli ve geri beslemeli ağlar olmak üzere iki temel ağ mimarisi bulunmaktadır.⁸² İleri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları ilerleyen alt bölümlerde açıklanmıştır.

2.9.1. İleri Beslemeli Yapay Sinir Ağı Mimarileri

Yapay sinir ağlarında reel değerli n boyutlu özel vektörler; j gizli katman nöronu, i girdisini w_{ij} ($i = 1, 2, \dots, n, j = 1, 2, \dots$) ağırlığına göre alır. j birimi x girdi işaretlerinin ve w_{ij} ağırlıklarının bir işlevini hesaplayıp, sonucu kendinden sonraki tüm komşu nöronlara iletir. Bu işlem çıkış katmanındaki nöronlar tarafından da yapıldıktan sonra tamamlanır. Bu ağlar çok katmanlı ileri beslemeli ağlar olarak isimlendirilirler.⁸³


⁸⁰ELMAS, Ç., a. g. e., s.137

⁸¹ÖZTEMEL, E., a. g. e., s. 36

⁸²NABİYEV, V. V., a.g.e., s. 557

⁸³ELMAS, Ç., a. g. e., s. 56

Girdi işaretlerinin ara sinirlerden geçerek, giriş katından çıkış katına doğru yalnız bir yönde ilerlediği ağlar olarak da tanımlanabilir.⁸⁴



Şekil 2.6 Çok Katmanlı İleri Beslemeli Bir Sinir Ağı Yapısı

Kaynak: Nabiye; 558

Şekil 2.6 de çok katmanlı ileri beslemeli bir yapay sinir ağı görülmektedir.

2.9.2. Geri Beslemeli Yapay Sinir Ağı Mimarileri

Geri beslemeli ağlar herhangi bir nöronun çıkışından girişine işaretin ulaştığı ağlar olarak tanımlanabilir. Geri beslemeli ağ modelleri, gelecek durumlarına etki edebileceğinden danışmansız öğrenmeye dayalı bir modeldir.⁸⁵

Geri beslemeli ağ mimarileri, genellikle danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılmaktadır. Geri beslemeli ağlarda bir tür geri besleme işlemi söz konusudur. Bu tür ağlarda bir nöronun çıkışı diğer her bir nöronun girişine bağlıdır.

Ağın çalışması, i -nci sinirin dış girdisi x_i , çıkışı y_i , j -nci sinirin çıkışı ile i -nci siniri arasındaki bağlantının ağırlığı w_{ij} ile simgelenmek üzere ağın çalışması

$$\frac{du_i}{dt} = -u_i + \sum_{i=1}^n w_{ij}y_i + x_i \quad (2.2)$$


(2.2) eşitliği ile tanımlanır. Burada $y_j = g(u_j)$ ve

$$g(x) = \frac{1}{2} \left[\left(\tanh \frac{x}{\alpha_0} \right) + 1 \right] \quad (2.3)$$

⁸⁴NABİYE, V. V., a.g.e., s. 557

⁸⁵NABİYE, V. V., a.g.e., s. 557

şeklinde tanımlanır. Eşitlik (2.3) de $\alpha_0 = 0$ olması durumu katı kısıtlayıcı transfer işlemine karşılık gelir.⁸⁶



Şekil 2.7 Çok Katmanlı Geri Beslemeli Bir Sinir Ağı Yapısı

Kaynak: Nabiyev; 558

Çok katmanlı ileri beslemeli sinir ağının yapısı şekil 2.7' de gösterimiştir.

⁸⁶ELMAS, Ç., a. g. e., s. 57

ÜÇÜNCÜ BÖLÜM

BOX-JENKINS VE YSA YÖNTEMLERİ KESTİRİMLERİNİN KARŞILAŞTIRMASI

ANTALYA HAVALİMANI' NIN KISA DÖNEM ULUSLARARSI YOLCU TALEBİNİN ÖNGÖRÜLENMESİ

3.1. Literatür Araştırması

Bu bölümde; geçmiş yıllarda literatürde yer almış zaman serisi ARIMA modellemesi yöntemi ve yapay sinir ağlarının tek başına veya diğer yöntemlerle birlikte kullanıldığı havalimanı yolcu talebi öngörülenmesi çalışmalarının bir özeti verilmiştir. Literatürde, havalimanı yolcu talebi ile ilgili yapılmış çalışmalar;

Alan ve Karim, 1991-1996 dönemine ait nüfus, işsizlik, GSMH, havalimanları arası uzaklık değişkenlerinde yararlanarak, oluşturdukları işsizlik modeli ve GSMH modelleri yardımı ile Bangladesh' in yurt içi hava taşımacılığı talebini öngörülemişlerdir. Oluşturdukları iki modelinde istatistiksel olarak anlamlı olduğunu tespit etmişler, iki modeli kullanarak eşleştirdikleri şehir çifti havalimanları için 1996 yılı havayolu taşımacılığı talebini belirlemişlerdir. Yazarlar elde ettikleri sonuçların yakın gelecekte özel hava yolu taşımacılığı yapan şirketler için kapasite belirlemelerine yol göstereceğini belirtmişlerdir.⁸⁷

Profillidis, 1977-1998 dönemine ait yıllık zamam serisi verilerini kullanarak, ekonometrik ve bulanık regresyon yöntemleri ile Rodos Havalimanına yönelik

⁸⁷ ALAM J. B., KARİM D. M ., " *Air Travel Demand Model For Domestic Air Transportation In Bangladesh*", **Journal Of Civil Engineering**, Yıl 1998, Volume: CE 26, No:1, s. 1-13

yolcu talebi öngörü modelini oluşturmuştur. Yazar, yolcu talebini öngörüsünün ekonometrik modelini oluşturmak için Rodos Havalimanına gelen yolcuların ülkelere para biriminin Yunanistan para birimi ile değişim oranını kullanarak ekonometrik model oluşturmuştur. Ayrıca 1991 yılında meydana gelen Körfez savaşının Rodos Havalimanına yönelik yolcu talebine etkilerini araştırmak için bulanık regresyon denkleminde yapay değişken ve döviz değişim oranını kullanarak Körfez savaşının yolcu talebi üzerindeki etkisini modellemiştir.⁸⁸

Abed, Fail ve Jasimuddin 1971-1992 dönemine ait on altı değişkenin yıllık veri setini kullanarak, Suudi Arabistan'ın uluslararası yolcu talep tahminini gerçekleştirmek için en uygun ekonometrik modeli oluşturmaya çalışmışlardır. Ele aldıkları on altı değişkenin birbirleri ile korelasyonunu inceleyerek ekonometrik modelde yer alacak değişken sayısını yedi olarak belirleyerek, bu değişkenler yardımı ile dört farklı regresyon denklemi oluşturmuşlardır. Yazarlar, en uygun ekonometrik model olarak; nüfus büyüklüğü ve toplam harcamalar değişkenlerinin yer aldığı modeli, model regresyon analizinde kullanılan uyum iyiliği ölçütlerinden yararlanarak belirlemişlerdir.⁸⁹

Grubb ve Mason, 1949-1999 dönemine ait 596 aylık gözlem değerine sahip aylık zaman serisi verilerinden faydalananarak, Holt-Winters yöntemini ile Birleşik Krallık' a yönelik uzun dönem hava yocusu talebinin öngörüsünü gerçekleştirmişlerdir. Yazarlar ayrıca ARIMA modeli ile de öngörü gerçekleştirmişler; ancak uzun dönem öngörü için uygun olmadığını vurgulamışlardır. Trend bileşeninin uzun dönem öngörü için çok önemli olduğunu, Holt-Winters yönteminin trendi de öngörü gerçekleştirirken dikkate almasının yöntemin üstünlüğü olduğunu be-

⁸⁸PROFİLLİDİS, V. A., "Econometric And Fuzzy Modeling For The Forecast Of Demand In The Airport Of Rodos", **Journal of Air Transport Management** , Volume: 6, 2000, s. 98-100

⁸⁹ABED, S., Y., BA-FAİ, A. O., JASİMUDDİN, S., M., "An Econometric Analysis of International Air Travel Demand in Saudi Arabia", **Journal of Air Transport Management** , Volume: 7, 2001, s.143-148

lirtmişlerdir. Yazarlar 2000, 2005, 2010 ve 2015 yılları için Birleşik Krallık' a yönelik yıllık öngörülerde bulunmuşlardır.⁹⁰

Güngör ve Çuhadar; 1991–2004 dönemine ait aylık zaman serisi verilerini kullanarak, ileri sürümlü geriye yayınlı yapay sinir ağı ile doğrusal ve doğrusal olmayan çoklu regresyon modellerinin, Antalya'ya gelen Alman turist sayılarını tahmin etme başarılarını karşılaştırmışlardır. Modellerin tahmin başarılarını; R^2 (Belirlilik Katsayısı), OMYH ve KOKH istatistikleri ile değerlendirmişler; en yüksek tahmin doğruluğu ve açıklayıcılığı sağlayan 5-7-1 düzenine sahip yapay sinir ağı modeli ile 2005 ve 2006 yılı aylık kısa dönemi için Antalya iline yönelik Alman turist talebi öngörüsünü gerçekleştirmişlerdir.⁹¹

Medeiros, McAler, Slottje, Ramos ve Maquieria, İspanya' da bulunan Mallorca, Menorca ve Ibiza Havalimanına ait 1 Ocak 2001-31 Aralık 2006 günlük zaman serisi verilerinden faydalanarak, geliştirdikleri yeni bir GARCH-yapay sinir ağı modeli yardımı ile Balerik adalarına yönelik turizm talebini tahmin etmişlerdir. Yazarlar kullandıkları üç havalimanının verisi için GARCH etkisi taşımayan sinir ağı modeli, GARCH etkisini dikkate alan sinir ağı modeli, GARCH etkisi taşımayan lineer model ve GARCH etkisini dikkate alan lineer modeller yardımı ile Mallorca, Menorco ve İbiza havalimanlarına yönelik günlük, haftalık ve aylık uluslararası yolcu talebi öngörüsünü belirlemişlerdir.⁹²

⁹⁰GRUBB, H., MASON, A., "Long Lead Time Forecasting Of UK Air Passengers By Holt-Winters Methods With Damped Trend", **Journal of Air Transport Management** , Volume: 17, 2001, s. 71-82

⁹¹GÜNGÖR, ve ÇUHADAR, M., "Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemiyle Tahmini", **Gazi Üniversitesi Ticaret ve Turizm Eğitim Fakültesi Dergisi**, Yıl: 2005, Sayı: 1, s. 84-99

⁹²MEDEIROS, M., CV., McALER, M., SLOTTJE, D., RAMOS, V., MAQUIERIRA, J., R., "An Alternative Approach To Estimating Demand: Neural Network Regression With Conditional Volatility For High Frequency Air Passenger Arrivals", **Journal Of Econometrics**, Volume: 147, 2008, s. 372-383

Somagaio ve Wolters, Ağustos 1995-2008 Aralık dönemine ait aylık zaman serisi verilerinden yararlanarak, otoregresif (ARIMA) ve üstel düzleştirme (Holt-Winters) yöntemlerini kullanarak Lisbon Havalimanına yönelik uzun dönem yolcu talebinin öngörülemesini yapmışlardır. Yazarlar ARIMA yönteminin kısa dönem öngörü performansının iyi olduğunu vurgulamış; ancak uzun dönem öngörüsü için uygun bir yöntem olmadığını, Holt-Winter metodunun uzun dönem öngörüsünün daha iyi sonuçlar verdiğini KOKYH performans ölçütü ile belirtmişlerdir. 2020 yılı için Lisbon Havalimanına yönelik yolcu talebinin öngörüsünü 18,7 milyon kişi olarak belirlemişlerdir.⁹³

Çuhadar, Güngör ve Göksu, Ocak 1990–Kasım 2008 dönemine ait Antalya iline hava ve deniz yolu (Antalya, Alanya, Kas, Kemer, Finike) ile gelen aylık yabancı turist sayısı verilerinden yararlanılmıştır. Yöntem olarak, yapay sinir ağı, Box-Jenkins ARIMA ve mevsimsel üstel düzleştirme yöntemlerinin kullanmışlardır. Yöntemlerin tahmin doğrulukları OMYH ile karşılaştırılarak en yüksek doğruluğu sağlayan modelin bir giriş katmanı, bir gizli katman ve bir çıkış katmanı bulunan 6:3:1 mimarisine sahip yapay sinir ağı olduğunu tespit etmişlerdir. Belirlenen YSA modeli ile Antalya iline yönelik Ocak 2009- Aralık 2009 dönemine ait aylık dış turizm talebi öngörüsünde bulunmuşlardır.⁹⁴

Abdelghany ve Guzhva Amerikada bulunan 100 havalimanına ait 1998-2009 dönemi çeyrek yıllık veri setlerinden yararlanarak, havalimanına yönelik kısa dönem talep öngörüsü için bir zaman serisi modelleme yaklaşımı oluşturmuşlardır. Yaklaşım için oluşturulan iki modelden ilki, zaman serisi değişkenin çeyrek yıllık değişim oranları, mevsimsellik ve yakıt fiyatı değişkenlerinin yer aldığı çok değişkenli regresyon denklemidir. İkinci model ise, bağımlı değişken Philadelphia

⁹³SOMAGAÍO, A., ve WOLTERS M., "Comparative Analysis Of Goverment Forecast For The Lisbon Airport ", **Journal of Air Transport Management** , Volume: 16, 2010, s. 213-217

⁹⁴ÇUHADAR vd. a.g.e.,s. 99-114

Uluslararası havalimanı yerel talep değişimi ve bağımsız değişkenler ise yakıt fiyatı, çeyrek yıllık talep değişim aronları ARMA (1,2) yapısı ve yapay (kukla) değişkenlerden oluşmuştur. Yazarlar oluşturdukları iki modeli aşamalı olarak öngörüleme yaparken kullanmışlardır. Öngörü, Philadelphia Uluslararası havalimanı üzerinden oluşturmuşlar; elde ettikleri yaklaşımı ABD' nin en büyük 100 havalimanı üzerinde değerlendirilmiştir. Değerlendirme sonuçları, talebin basit bir zaman serisi modeli ile kabul edilebilir doğrulukla öngörüsünün gerçekleştirilebileceğini belirtmişlerdir. Ayrıca yazarlar, 11 Eylül 2001 tarihindeki terörist saldırısının ve 2004 yazında düşük maliyetli taşıyıcıların piyasaya girmesi ile Philadelphia Uluslararası havalimanı yerel yolcu talebinin olumsuz yönde etkilendiğini tespit etmişlerdir.⁹⁵

Aderoma, 1975-2006 dönemine ait yıllık tarımsal üretim endeksi, imalat üretim endeksi, gayri safi yurtiçi hasıla, enflasyon oranı ve tüketici fiyat endeksi verilerinden yararlanarak, çoklu regresyon yöntemi ile Nijerya' nın havayolu taşımacılığı için yurt içi yolcu talebi modelini geliştirmeye çalışmıştır. Kullanılan değişkenlerden, uçak talebini açıklama da; tarımsal üretim endeksi ve tüketici fiyat endeksi değişkenlerinin de yük hareketi talebinin açıklanmasında önemli olduğunu belirlemiştir. Yazar, yolcu ve eşya taşımacılığı talebinin yeterince yüksek olmadığını, bunun sebebi olarak rota, planlama, güvenlik ve genel yönetim sorunlarından kaynaklandığını vurgulamıştır.⁹⁶

Ahmetzade, Ocak 1981-Aralık 2000 dönemi yurt içi yolcu sayısı aylık verilerini ve Ocak 1984-Aralık 2000 dönemi uluslararası aylık yolcu veri setlerinden yararlanarak trend modeli ve E.K.K. yöntemi ile 2001-2005 dönemi için Mehrabad (İran) havalimanına yönelik yurtiçi ve uluslararası yolcu talebini öngörüsünü aylık

⁹⁵ ABDELGHANY, A., ve GUZHVA, V. S., "A Time-Series Modeling Approach For Airport Short-Term Demand Forecasting", **Airport Management** , Volume: 5, 2010, s. 72-87

⁹⁶ ADEROMA, A., J., "Demand For Transport In Nigeria", **Journal Of Economics**, Volume: 1, 2010, s. 23-31

olarak tahmin etmiştir. Yazar zaman serisi analizinde ilk olarak veri setlerinin durağanlık analizini ADF testi ile ve grafik yardımıya gerçekleştirmiş, oluşturduğu iki modelin analizini R^2 , F ve D.W. istatistikleri yardımı ile gerçekleştirmiştir. İran' ın eğitim döneminde yolcu talebinin azaldığını tespit eden yazar havalimanı bakımlarının bu dönemde yapılmasını tavsiye etmiştir. 2005 yılında yurtiçi yolcu talebinin %5,1 ve uluslararası yolcu talebinin de ise %1,5 oranında büyüme yaşanacağını tespit etmiştir.⁹⁷

Coldren, Koppelman, Kasturirangan ve Mukherjee, ele aldıkları on beş değişken üzerinden ABD'de bulunan tüm havaalanları için, şehir çifti düzeyinde multinomial probit tahmin yöntemi ile toplam havayolu seyahat ve yol paylaşımını modellemeye çalışmışlardır. Belirlenen on sekiz şehir çifti için yol seviyesi ve destek taşıyıcı karar verme de havayolu kullanıcılarını etkileyen faktörleri belirleyerek; toplam multinomial logit yöntem ve kapsamlı veri kullanımı ile havayolu talebi için model geliştirmişlerdir. Oluşturdukları onsekiz ayrı model için, hizmet düzeyi, bağlantı kalitesi, taşıyıcı, taşıyıcı pazar varlığı, uçak bileti, uçak boyutu ve türü, ve uçuş günün saati farklı güzergah hizmet özellikleri için bağımsız değişkenler olarak alınmıştır. Yazarlar, elde ettikleri sonuçları sezgisel olarak değerlendirmiş; doğrulama testleri sonucunda modellerin mevcut yöntemlere göre daha iyi performans gösterdiğini tespit etmişlerdir. Yaptıkları detaylı analiz, hizmet, bağlantı kalitesi, uçak tipi ve boyutu, kalkış saati, servis hizmeti, ücretler ve güzergah seçimi taşıyıcı yol düzeyinin göreceli önemi üzerinde gerçekleştirmişlerdir. Ayrıca yol özelliklerinin tüm parametre tahminlerin onsekiz bölgesel kuruluş üzerinde uyumlu olduğunu tespit etmişlerdir.⁹⁸

⁹⁷ AHMETZADE, F., "Model For Forecasting Passanger of Airport", **Proceeding of the 2010 İnternational Engineering Conference on Industrial Engineering and Operations Managment Dhaka**, Bangladesh, January 9-10, 2010

⁹⁸ GİL-ALANA, L., A., "Modelling International Monthly Arrivals Using Seasonal Univariate Long-Memory Processes", **Journal Of Transport Management**, Volume. 9, 2003, s. 361-369

Sinh ve Das, Q4-2006 ve Q3-2008 çeyrek yıllık veri setinden yararlanarak, hareketli ortalamalar, üstel düzleştirme, holts ve Winters yöntemleri ile Lufthansa hava yollarının Q4-2008 ile Q3-2009 dönemi için yolcu trafiğinin hareketliliği öngörüsünü gerçekleştirmiştir. Yazar kullandığı dört yöntemin performanlarını Mape, MSE, AE ve MAD ölçütlerini kullanarak karşılaştırmış; en iyi performansı Winters yönteminin gösterdiğini belirlemiştir. Yazarlar küresel ekonomideki düşüş, terörist saldırılar, güvenlik sorunları gibi olumsuz unsurları göz ardı ederek Lufthansa hava yollarının toplam yolcu trafiğinin hareketliliği bir bütün olarak ele almışlar; elde ettiği bulguların, havayolu yöneticileri için havayolu trafiği konusunda bilgilendirmeyi amaçlamıştır.⁹⁹

Aleksive ve Seixas, 1978-1998 dönemine ait havalimanı yolcu sayısı, GSYİH (Brezilya Gayri Safi Yurtiçi Hasıla), YPD (bilet getirisi -kilometre başına ortalama bilet fiyatları) verileri ve bir kukla değişken kullanarak, ekonometrik model ve Yapay Sinir Ağı yöntemi ile Brezilya' nın havayolu taşımacılığı talebini öngörülmeye çalışılmışlardır. Yazarlar ekonometrik modelde yer alan kukla değişken ile de 1992 ve 1997 döneminde Brezilya ekonomisindeki düşüşü açıklamaya çalışmışlardır. Hava taşımacılığı yolcu analizi için geliştirdikleri Yapay sinir ağı tahmin yönteminin geleneksel ekonometrik yaklaşımdan daha iyi performans sergilediğini göstermişlerdir. Brezilya hava ulaşımı yolcu trafiğine uygulanan YSA model yaklaşımının öngörüsünün klasik modele göre oldukça etkili olduğunu saptamışlardır.¹⁰⁰

⁹⁹SINGH, A. K. ve Das D., "Forecasting The Trafik Movement In Lufthansa Airlines: A Supply Chain Perspective", **Journal Of Services Research** Yıl 2010, Volume: 10, No:2, s. 63-77

¹⁰⁰ALEKSEEV, K.P.G. ve SEIXAS J.M., "A multivariate neural forecasting modeling for air transport – Preprocessed by decomposition: A Brazilian application", **Journal of Air Transport Management**, Yıl: 2009, Volume: 15, s. 212-216

3.2. Araştırmanın Amacı ve Araştırma Alanının Seçimi

Bu araştırmanın amacı; tek değişkenli zaman serisi tahmin yöntemi adı altında ele alınan; "mevsimsel Box-Jenkins metodolojisi" olarak adlandırılan (SARIMA) yöntem ve verilerin yapısına uygun modeller ile farklı mimarilere sahip yapay sinir ağı modellerinin, örnek içi ve örnek dışı geçmişe yönelik kestirim doğruluklarını karşılaştırarak en yüksek doğruluğu sağlayan modelin belirlenmesi ve belirlenen model yardımıyla Ocak 2011 – Aralık 2011 dönemi için Antalya Havalimanı' na yönelik kısa dönemli uluslararası yolcu talebinin aylar itibariyle öngörüsünün oluşturulmasıdır.

Bu konuda daha önce Antalya havalimanına yönelik kısa dönemli uluslararası yolcu talebi öngörüsü ile ilgili bir çalışma bulunmamaktadır.

Fakat Antalya iline yönelik, Güngör ve Çuhadar (2005) ve Çuhadar, Güngör ve Göksu (2009) tarafından yapılan çalışmalarda, turist sayısı tahminleri kısa dönemli aylık olarak öngörülmüştür.

Bu çalışmada Antalya havalimanına yönelik kısa dönemli aylık uluslararası yolcu talebi öngörüsü yapılması planlanmıştır. Yapılacak tahminler ile; merkezi ve yerel kamu yönetimleri tarafından hazırlanan turistik gelişme planları için bir zemin oluşturmak; ilgili işletme yöneticilerinin aylık planlamalarında karar almalarını kolaylaştırmak ve literatüre katkı sağlanması, çalışmanın amaçları arasındadır.

Uygulamanın Antalya Havalimanı' na yönelik olarak belirlenmesindeki amaçlar;

- 1) Antalya ilinin sahip olduğu tarihi, doğal ve kültürel turizm potansiyeli nedeniyle Antalya Havalimanı dış hatlar yolcu sayısının yüksek ve düzenli olması,
- 2) Türkiye'ye gelen ziyaretçilerin başlıca turistik merkezlere göre dağılımı içerisinde Antalya'nın en büyük paya sahip olması olarak sıralanabilir.

3.3. Araştırma Kullanılan Veriler

Araştırmada, Antalya Havalimanı uluslar arası yolcu talebinin ölçütü olarak giriş yapan toplam uluslararası yolcu sayıları kullanılmıştır. Literatürde yolcu talebinin ölçütü olarak gelen yolcu sayıları; iniş yapan uçak sayısı verileri, GSYH, döviz kuru değişim pramları, kullanılmaktadır. Bunlar arasından en fazla kullanılan ölçüt gelen yolcu sayılarıdır.

Song ve Witt, inceledikleri 1990-2004 yılları arasında yapılmış kırk beş çalışmanın otuz yedisinde uluslararası turizm talebinin ölçütü olarak toplam uluslararası yolcu sayılarının kullanıldığını belirtmişlerdir.¹⁰¹

Çalışmada, Antalya Havalimanından Ocak-2004 ile Aralık 2010 döneminde giriş yapan yolcu sayıları kullanılmıştır. Veriler, Devlet Hava Meydanları İşletmesi Genel Müdürlüğünden temin edilmiştir. Aylık veriler, mevsim ve trend bileşenlerinin ele alınarak daha detaylı incelemeler yapılabilmesi için tercih edilmiştir. Araştırmada kullanılan Ocak 2004–Aralık 2010 dönemine ait Antalya Havalimanına gelen aylık uluslararası yolcu sayısı verileri Ek-1’ de verilmiştir.

3.4. Araştırmanın Yöntemi

Çalışmada öncelikle, verilerin yapısına uygun yöntemlerin belirlenebilmesi amacıyla verilerin zaman serisi özellikleri analiz edilerek seriyi etkileyen temel bileşenler incelenecektir. Verilerin bileşenlerinin incelenmesinden sonra, mevsimsel Box-Jenkins yöntemi ve verilerin yapısına uygun modeller ve farklı mimarilere sahip yapay sinir ağı modelleri ile Ocak 2010 ve Aralık 2010 dönemi için Antalya Havalimanı kısa dönem uluslararası yolcu sayısı kestirimleri yapılacaktır. Modellerin ürettikleri kestirim değerleri, gerçekleşmiş Ocak 2010 ve Aralık 2010 dönemi yolcu sayıları ile karşılaştırılarak, hangi yöntemin gerçek değere daha yakın öngöründe bulunduğu belirlenecektir. Her bir yöntemin öngörü doğruluğu, “Kök Ortalama

¹⁰¹SONG, H. ve WITT, S., a. g.e., s. 216


Kare Hata (KOKH)” ve “Ortalama Mutlak Yüzde Hata (OMYH)” istatistikleri yardımıyla değerlendirilecektir. Yapılacak değerlendirmeler neticesinde en yüksek kestirim doğruluğunu sağlayan yöntem ve model kullanılarak, Ocak 2011 ve Aralık 2011 dönemi için aylar itibariyle Antalya Havalimanına yönelik uluslararası yolcu talebi öngörüsü gerçekleştirilecektir.

3.5. Araştırma Bulguları

3.5.1. Mevsimsel Box-Jenkins Yönteminin Uygulanması

Çalışmada kullanılan, Ocak 2004-Aralık 2010 döneminde Antalya Havalimanından giriş yapan aylık uluslararası yolcu sayısı verilerinin, %85’ i (72 ay) olan Ocak 2009-Aralık 2009 gözlem değerleri kestirim için; %15’ i de (12 ay) Ocak 2010-Aralık 2010 kestirim performansının değerlendirilmesi amacı ile test verisi olarak kullanılmıştır.

Öncelikle Ocak 2009-Aralık 2009 dönemi verilerinin, seriyi etkileyen temel bileşenleri betimlemek amacıyla verilerin zaman yolu grafiği incelenmiştir.



Şekil 3.1 Antalya Havalimanı Uluslararası Yolcu Serisi Grafiği


Şekil 3.1 'deki grafikten serinin, artan bir trend ile birlikte mevsimsel dalgalanmaların etkisinde olduğu gözlenmektedir.

Dalgalanma, birbirini izleyen yılların nisan aylarından itibaren artmaya başlayarak Temmuz ve Ağustos aylarında en yüksek değere ulaşması ve Ocak aylarında en düşük değeri alması şeklinde meydana gelmektedir.

Ocak 2004-Aralık 2009 döneminde Antalya iline gelen uluslararası yolcular serisinin (ANT) zamana göre seyrini gösteren şekil 3.1' den; serinin ortalamada ve varyansta durağan olmadığı, ayrıca mevsimsel bileşenin zaman içinde değiştiği görülmektedir.

Serinin mevsimsel bileşenin zaman içinde sabit olmadığı durumda orijinal serinin sabit mevsimsel değişimler içeren bir seriye dönüştürülmesi gerekmekte, bu da genellikle gözlem değerlerinin doğal logaritması alınarak yapılmaktadır. Bu nedenle seri (ANT) logaritmik dönüşüme tabi tutulmuş, logaritması alınan Ocak

2004-Aralık 2010 döneminde Antalya Havalimanına gelen uluslararası yolcular serisinin (LnANT) zaman grafiği, şekil 3.2’de verilmiştir.



Şekil 3.2 LnANT Serisi Zaman Grafiği


Şekil 2.2’de LnANT serisinin ortalamada durağan olmadığı, ancak varyansta durağanlığının sağlandığı, yani mevsimsel bileşenin sabit hale geldiği görülmektedir.

LnANT serisinin durağanlığının sınanması için Genişletilmiş Dickey-Fuller (ADF) testi uygulanmış ve sonuçları aşağıda verilmiştir.

Tablo 3.1. LnANT Serisinin Genişletilmiş Dickey-Fuller (ADF) testi Sonuçları			
		t-İstatistiği	Anlamlılık*
Genişletilmiş Dickey-Fuller İstatistiği		0,187404	0.7372
Test kritik değerleri:	1% level	-2,604073	
	5% level	-1,946348	
	10% level	-1,613293	
*Birim kök mevcut olduğu hipotezini reddetmek için Mc Kinnon kritik değeri			

Tablo 3.1 deki ADF testi sonucuna göre, LnANT serisinin birim köke sahip ($p = 0.7372 > 0,05$) olduğu anlaşılmaktadır. Dolayısıyla bu test, logaritmik dönüşüme tabi serinin “regular farkı”nın alınması gerektiğini göstermiştir. Bu nedenle LnANT serisinin birinci regular farkı alınmış ve elde edilen birinci mertebeden farkı alınmış logaritmik dönüşüme tabi serinin (Δ LnANT) serinin otokorelasyon ve kısmi otokorelasyon fonksiyonu tablo 3.2’ deki korelogramında verilmiştir.

Tablo 3.2 ΔLnANT Serisinin Korelogramı

Otokorelasyon	Kısmi Otokorelasyon	O.K.	K.O.K.	Q-İst.	Olasılık	
		1	0.614	0.614	27.955	0.000
		2	0.307	-0.114	35.030	0.000
		3	-0.021	-0.263	35.064	0.000
		4	-0.359	-0.357	45.042	0.000
		5	-0.518	-0.172	66.079	0.000
		6	-0.599	-0.258	94.694	0.000
		7	-0.495	-0.117	114.53	0.000
		8	-0.316	-0.167	122.76	0.000
		9	-0.035	0.002	122.86	0.000
		10	0.195	-0.091	126.10	0.000
		11	0.436	0.146	142.53	0.000
		12	0.612	0.234	175.45	0.000
		13	0.372	-0.361	187.80	0.000
		14	0.187	-0.066	190.97	0.000
		15	0.004	0.136	190.97	0.000
		16	-0.229	-0.032	195.91	0.000
		17	-0.272	0.140	203.01	0.000
		18	-0.346	-0.057	214.73	0.000
		19	-0.271	0.041	222.05	0.000
		20	-0.163	-0.017	224.76	0.000
		21	-0.021	0.007	224.81	0.000
		22	0.093	-0.044	225.73	0.000
		23	0.225	0.002	231.20	0.000
		24	0.281	-0.073	239.88	0.000
		25	0.128	-0.038	241.73	0.000
		26	0.079	0.039	242.45	0.000
		27	0.001	0.006	242.45	0.000
		28	-0.068	0.069	243.00	0.000
		29	-0.088	-0.102	243.96	0.000
		30	-0.109	0.078	245.48	0.000
		31	-0.067	0.048	246.06	0.000
		32	-0.028	-0.002	246.16	0.000
		33	-0.019	-0.041	246.21	0.000
		34	0.002	-0.016	246.21	0.000
		35	-0.002	-0.138	246.21	0.000
		36	0.000	0.012	246.21	0.000

Tablo 3.2'deki birinci mertebeden regular farkı alınmış LnANT (ΔLnANT) serisine ait korelogram incelendiğinde, gecikme uzunluğu artarken otokorelasyon fonksiyonunun azaldığı ve otokorelasyon katsayısının üçüncü, kısmi otokorelasyon katsayısının da ikinci gecikmede sıfırı kestiği görülmektedir. Bu durumda logaritmik dönüşüme tabi serinin birinci farkının alınması ile elde edilen Fark LnANT


serisinin durağan olduğu söylenebilir. Elde edilen serinin durağanlığının sınanması amacıyla uygulanan ADF testinin sonuçları aşağıda verilmiştir.

Tablo 3.3 ΔLnANT Serisinin Genişletilmiş Dickey-Fuller İstatistiği Sonuçları			
		t-İstatistiği	Anlamlılık
Genişletilmiş Dickey-Fuller İstatistiği		-2,703182	0.0077
Test kritik değerleri:	1% level	-2,604746	
	5% level	-1,946447	
	10% level	-1,613238	
*Birim kök mevcut olduğu hipotezini reddetmek için Mc Kinnon Kritik değeri			

Tablo 3.3’ deki ADF testi sonucuna göre ΔLnANT serisi için birim kökün mevcut olduğu hipotezi reddedilmiş ($p = 0,0077 < 0,05$) ve logaritmik dönüşüme tabi serinin birinci dereceden durağan olduğu sonucuna ulaşılmıştır.

Tablo 3.2’ de verilen ΔLnANT serisine ait korelogram incelendiğinde, mevsimsel gecikmelerde (1, 12, 24, ...) otokorelasyon katsayılarının birbirlerine benzer bir yapı ortaya koydukları ve bu yapıların diğer gecikmelerde de devam ettiği gözlenmektedir. Ayrıca mevsimsel gecikmelerde otokorelasyon katsayılarının büyük oldukları ve yavaş bir şekilde azaldıkları görülmektedir.

Otokorelasyon katsayılarının mevsimsel gecikmelerde zirveye ulaştığının görülmesi ve yavaş bir şekilde azalmaları, “mevsimsel durağan olmamanın” göstergesi olarak kabul edilmektedir. Bu durumda mevsimsel fark almanın uygun olduğuna karar verilmiştir. ΔLnANT serisinin “mevsimsel farkı” alınmış ve elde edilen birinci mertebeden mevsimsel farkı alınmış birinci mertebeden regular farkı alınmış logaritmik dönüşüme tabi ($\Delta\Delta_{12}\text{LnANT}$) serinin zaman yolu grafiği şekil 3.3’de verilmiştir.



Şekil 3.3 $\Delta\Delta_{12}$ LnANT Serisinin Zaman Yolu Grafiği

Şekil 3.3 de serinin mevsimsellikten arındırıldığı ve sabit bir ortalama etrafında rassal olarak dalgalandığı görülmektedir.

$\Delta\Delta_{12}$ LnANT serisine ait otokorelasyon ve kısmi otokorelasyon fonksiyonu değerleri tablo 3.4’ deki korelogramda verilmiştir.

Tablo 3.4 $\Delta\Delta_{12}\text{LnANT}$ Serisinin Korelogramı

Otokorelasyon	Kısmi Otokorelasyon	O.K.	K.O.K.	Q-İst	Olasılık	
		1	-0.462	-0.462	13.266	0.000
		2	0.203	-0.014	15.871	0.000
		3	-0.087	0.003	16.352	0.001
		4	0.142	0.134	17.679	0.001
		5	-0.275	-0.208	22.712	0.000
		6	0.200	-0.026	25.436	0.000
		7	-0.128	-0.015	26.571	0.000
		8	0.025	-0.052	26.616	0.001
		9	0.141	0.223	28.048	0.001
		10	-0.104	-0.025	28.840	0.001
		11	0.165	0.168	30.874	0.001
		12	-0.266	-0.249	36.290	0.000
		13	0.113	-0.162	37.283	0.000
		14	-0.079	0.047	37.780	0.001
		15	0.142	0.127	39.429	0.001
		16	-0.244	-0.027	44.393	0.000
		17	0.243	-0.058	49.443	0.000
		18	-0.199	-0.146	52.909	0.000
		19	0.084	-0.094	53.538	0.000
		20	-0.147	-0.162	55.527	0.000
		21	0.097	0.052	56.416	0.000
		22	-0.145	-0.004	58.456	0.000
		23	0.137	0.067	60.344	0.000
		24	-0.074	-0.095	60.903	0.000
		25	-0.082	-0.329	61.615	0.000
		26	0.058	-0.103	61.981	0.000
		27	-0.017	0.127	62.014	0.000
		28	-0.002	0.157	62.014	0.000
		29	0.002	0.156	62.015	0.000
		30	0.000	-0.234	62.015	0.001
		31	0.000	-0.176	62.015	0.001
		32	0.000	-0.347	62.015	0.001
		33	0.000	0.113	62.015	0.002
		34	0.000	0.470	62.015	0.002
		35	0.000	0.576	62.015	0.003
		36	0.000	0.070	62.015	0.005

Tablo 3.4' deki korelogram incelendiğinde, yapılan dönüşümler neticesinde durağanlık özelliği gösteren seride trend ve mevsimsel etkilerin kalmadığı gözlenmektedir. Güven sınırları dışında kalan otokorelasyon katsayısının olmadığı gözlemlenmiştir.

Box-Jenkins yöntemi ile model kurma sürecinin ilk aşaması, deneme niteliğindeki modellerin belirlenmesidir. Bu aşamada oto korelasyon ve kısmi oto korelasyon fonksiyonları ile seriye uygulanan dönüşümlerden yararlanılmaktadır.

Antalya Havalimanı uluslararası yolcu sayısı verisinin birinci regular farkı ve birinci derece mevsimsel farkı alınarak serinin durağanlığının sağlandığı ve mevsimsel etkilerden arındığı tespit edildiği için,

$$\text{Regular fark için } d = 1; \quad \text{Mevsimsel fark için } D = 1 \ (s = 12)$$

uygun fark alma mertebeleri olarak belirlenmiştir.

Tablo 3.4' deki korelogram analizi incelemesi sonucunda, otokorelasyon ve kısmi otokorelasyon fonksiyonlarında birinci kaydırmalarda güven sınırları dışına çıkıldığı; mevsimsel kaydırmalarda ($k = 12$) ise otokorelasyon fonksiyonlarında birinci kaydırmalarda güven sınırları dışına çıkıldığı görülmektedir. Dolayısı ile aday modellerin;

Tablo 3.5. Belirlenen Aday Modeller
$ARIMA(1, 1, 1) (0, 1, 1)_{12} = SARIMA(1, 1, 1) (0, 1, 1)$
$ARIMA(1, 1, 0) (0, 1, 1)_{12} = SARIMA(1, 1, 0) (0, 1, 1)$
$ARIMA(0, 1, 1) (0, 1, 1)_{12} = SARIMA(0, 1, 1) (0, 1, 1)$

olabileceği kanaatine varılmıştır. En yüksek doğruluk derecesi veren modelin bulunabilmesi için aday modeller denenmiştir. Model belirleme işlemi uzun ve detaylı işlemler gerektirdiği için bilgisayar yazılımlarından faydalanmaktadır. Modellerle ilgili tüm işlemler Eviews 7.0 paket programı ile yapılmıştır.¹⁰²

$SARIMA(1, 1, 1) (0, 1, 1)$ modelinin parametrelerinin istatistiksel olarak anlamsız olduğu, dolayısıyla modelin geçerliliğinin olmadığı tespit edilmiştir.

$SARIMA(1, 1, 0) (0, 1, 1)$ ve $SARIMA(0, 1, 1) (0, 1, 1)$ modellerinin parametrelerinin istatistiksel olarak anlamlı olduğu, dolayısıyla aday model olma durum-

¹⁰²EViews VERSION 7.0, QUANTITATIF MICRO SOFTWARE İNK.

larının devam ettiği için hangi modelin kullanılacağına karar vermek üzere model seçim kriterleri incelenmiştir. Modellere ait evIEWS çıktıları sayısız verileri Ek-2’de verilmiştir.

Tablo 3.6. Aday Modellerin Seçim Kriter Değerleri				
Model	R^2	Düz. R^2	AIC	SIC
$SARIMA(1, 1, 0)(0, 1, 1)$	0.539876	0.531660	-1.559948	-1.488898
$SARIMA(0, 1, 1)(0, 1, 1)$	0.533095	0.524904	-1.556322	-1.485897

Tablo 3.6 incelendiğinde $SARIMA(1, 1, 0)(0, 1, 1)$ modeline ait R^2 , Düz. R^2 , AIC ve SIC değerlerinin $SARIMA(0, 1, 1)(0, 1, 1)$ modeline ait değerlerden daha iyi olduğu görülmektedir. Tablo 3.6 deki sonuçlar, logaritmik dönüşüm uygulanmış Antalya Havalimanına gelen uluslararası yolcular serisi için uygun modelin "Çarpımsal-Mevsimsel ARIMA Modeli" olarak ifade edilen $SARIMA(1, 1, 0)(0, 1, 1)$ olduğunu göstermektedir. Dolayısıyla tahmin modeli olarak $SARIMA(1, 1, 0)(0, 1, 1)$ modeli seçilmiş ve ileri yönelik öngörü bu model yardımı ile yapılmıştır. EvIEWS 7.0 paket programı ile elde edilen son parametre tahminleri ve parametrelere ait istatistiksel değerler tablo 3.7.’de verilmiştir. Modele ait parametreler

Tablo 3.7 $SARIMA(1, 1, 0)(0, 1, 1)$ Model Parametreleri				
Değişken	Tahmin	S. Hata	t-İst	Olasılık
AR(1)	-0.364960	0.124314	-2.935799	0.0048
MA(12)	-0.898903	0.025788	-34.85806	0.0000

biçiminde hesaplanmıştır. Yukarıda elde edilen tahmin sonuçlarından hareketle, Antalya Havalimanına gelen uluslararası yolcular serisi için uygun bulunan $SARIMA(1, 1, 0)(0, 1, 1)$ modelinin açılımı

$$\begin{aligned}
\Delta\Delta_{12}LNT_i &= (1 - B) (1 - B^{12}) LNT_i \\
&= \frac{(1 - (0) B) (1 - (0.89) B^{12})}{(1 - (0.36) B) (1 - (0) B^{12})} \varepsilon_t \\
&= \frac{(1 - 0.89B^{12})}{(1 - 0.36B)} \varepsilon_t
\end{aligned}$$

olarak ifade edilir.

Belirleme ve parametre tahminlerinin belirlenmesinden sonra model artıklarının (residuals) analizine geçilmiştir. Elde edilen $SARIMA(1, 1, 0)(0, 1, 1)$ modelinin artıklarına ait otokorelasyon ve kısmi otokorelasyon fonksiyonu tablo 3.8’ de verilen korelogram yardımı ile incelenmiştir.

Tablo 3.8. Model Artıklarına Ait Korelogram

Otokorelasyon	Kısmi Otokorelasyon	O.K.	K.O.K.	Q-İst	Olasılık	
		1	-0.002	-0.002	0.0004	
		2	0.030	0.030	0.0565	
		3	0.160	0.160	1.6716	0.196
		4	-0.165	-0.169	3.4225	0.181
		5	-0.129	-0.144	4.5137	0.21
		6	0.047	0.037	4.6619	0.324
		7	-0.212	-0.158	7.7318	0.172
		8	-0.002	0.011	7.7323	0.258
		9	0.111	0.080	8.6061	0.282
		10	-0.078	-0.034	9.0442	0.339
		11	0.016	-0.042	9.0635	0.431
		12	-0.053	-0.136	9.2774	0.506
		13	0.032	0.103	9.3576	0.589
		14	0.070	0.065	9.7452	0.638
		15	0.096	0.103	10.486	0.654
		16	-0.067	-0.096	10.862	0.697
		17	0.241	0.221	15.810	0.395
		18	-0.072	-0.094	16.268	0.434
		19	-0.012	0.011	16.281	0.504
		20	-0.103	-0.171	17.259	0.505
		21	-0.108	0.016	18.365	0.498
		22	-0.012	0.055	18.379	0.562
		23	-0.015	-0.052	18.400	0.624
		24	-0.079	-0.047	19.036	0.643
		25	0.011	-0.034	19.048	0.698
		26	-0.029	-0.070	19.140	0.744
		27	-0.006	0.006	19.144	0.790
		28	-0.003	-0.088	19.145	0.830
		29	0.000	0.117	19.145	0.865
		30	0.000	-0.101	19.145	0.894
		31	0.000	-0.015	19.145	0.918
		32	0.000	-0.129	19.145	0.937
		33	0.000	0.121	19.145	0.952
		34	0.000	-0.077	19.145	0.965
		35	0.000	0.091	19.145	0.974
		36	0.000	-0.091	19.145	0.981

Tablo 3.8’deki korelogram, model artıklarına ait OKK ve KOKK’larının, güven sınırları içinde yer aldığı görülmekte, bunun da modelin yeterliliği için önemli bir kriter olduğu kabul edilmektedir. Bu aşamada model artıklarının temiz dizi (W-N) olup olmadığı (aralarında otokorelasyon olup olmadığını) sınamak için Q^* istatistiği değerlerine bakılmıştır. sıfırdan farklı istatistiksel olarak anlamlı 28 otokorelasyon olduğu için $Q^* = 19.145$ ve $\chi^2_{26} = 28,412$ olarak ($\alpha = 0,05$) hesaplanmıştır. Bu sonuç ile

$$\chi^2_{Tablo} > Q^*_{Hesap}$$

olduğu için modele ait artıklar arasında önemli otokorelasyon olmadığını, artıklar serisinin rassal bir süreçte sahip olduğunu dolayısıyla seçilen modelin uygun olduğu tespit edilmiştir.

Öngörü için uygun bulunan $SARIMA(1,1,0)(0,1,1)$ modelinde logaritmik dönüşüme tabi seri değerleri kullanıldığından dolayı, öngörünün orjinal veri cinsinden ifade edilebilmesi için sonuçların anti-logaritmaları alınmıştır. Modelin Antalya Havalimanına gelen turistler serisine uygulanması ile elde edilen Ocak 2010–Aralık 2010 dönemine ait öngörü değerleri ile aynı döneme ait gerçekleşmiş değerler üzerinde yapılan öngörü doğruluğu ölçüm sonuçları

$$OMYH = 10,104$$

$$HKOK = 69701$$

olarak hesaplanmıştır.

3.5.2. Yapay Sinir Ağı Yönteminin Uygulanması

Son yıllarda, zaman serisi tahminlerinde kullanılmaya başlayan yöntemlerden birisi yapay sinir ağlarıdır. Yapay sinir ağları kullanılarak mevsimsel zaman serilerinin tahmini üzerine yapılan uygulamalarda, mevsimsel zaman serilerinin tahmininde iyi sonuç elde etmek için mevsimsel etkinin giderilmesi gerektiğini,

yani mevsimsel etkilerden arındırılmış serinin kullanılması gerektiğini söylenirken, diğer uygulamalarda ise yapay sinir ağlarının mevsimsel etkileri öğrenme kabiliyetine sahip olduğunu ve herhangi bir ön işleme yapmaya gerek olmadığını belirtmişlerdir.

Ocak 2004–Aralık 2009 döneminde Antalya Havalimanına gelen uluslararası yolcular serisinin yapay sinir ağları ile modellenmesinde, orijinal seri (OS) ve veri seti kullanılarak oluşturulan farklı ağ yapılarının öngörü başarıları incelenmiştir. Çalışmada kullanılan 84 aylık verinin, %85'i eğitim (72 ay), %15'i de test verisi (12 ay) şeklinde rassal olarak gruplandırılmış ve (OS) için altı farklı veri seti oluşturulmuştur. Bu veri setlerine yöntemin uygulanması “Matlab 10.0” bilgisayar programı'nın yapay sinir ağları modülü (Neural Network Toolbox) ile gerçekleştirilmiştir.¹⁰³ Veriler, bilgisayara girilmeden önce normalize edilmiş, yani “0 ile 1” arasında bir değer alabilmesi için tüm veriler serideki en büyük sayıdan daha büyük bir sayıya bölünerek elde edilen rakamlar kullanılmıştır.

Orjinal serilerinin yapay sinir ağı ile modellenmesinde, giriş katmanında farklı zaman gecikmelerindeki seri değerleri (y_{t-12} , y_{t-24} ve y_{t-36}), çıkış katmanında ise gecikmesiz seri değerleri (y_t) kullanılmıştır. Oluşturulan üç veri setinin her biri için iki gizli katman ve değişik nöron sayıları (1-32 arasında) ile modeller kurulmuş ve farklı iterasyon (epoch: 200-3000) sayılarında denemeler yapılarak eğitim gerçekleştirilmiştir. Eğitim sonrasında, herbir seri için Ocak 2010- Aralık 2010 yılı için kestirim değerleri elde edilmiştir. Test için ayrılan veriler ile kurulan tüm modellerden elde edilen kestirim değerleri test edilmiştir. Test işlemi sonucunda bulunan öngörü değerleri, gerçek değerlerle karşılaştırılmış ve önce her grup için, daha sonra tüm gruplar arasından hata kareleri ortalamasının karekökü ($HKOK$) ve ortalama mutlak yüzde hata ($OYMH$) ölçüleri dikkate alınarak değişik mimarilere sahip yapay sinir ağı modellerinin öngörü performansları karşılaştırılmıştır.


¹⁰³MATLAB Neural Network Toolbox, Version R2010a, Math Works Inc.

Farklı mimarilere sahip yapay sinir ağı modelleri ile yapılan denemelerden elde edilen öngörü sonuçları tablo 3.9’ da özet olarak verilmiştir.

Tablo 3.9. Farklı Mimarilere Sahip YSA Modelleri İle Yapılan Deneme Sonuçları

Kullanılan Zaman Serisi	<i>Seri 1</i>	<i>Seri 1</i>	<i>Seri 2</i>	<i>Seri 2</i>	<i>Seri 3</i>	<i>Seri 3</i>
Giriş Katmanı	y_{t-12}	y_{t-12}	y_{t-24}	y_{t-24}	y_{t-36}	y_{t-36}
Giriş Katmanı Sayısı	1	1	2	2	3	3
Gizli Katman Sayısı	2	2	2	2	2	2
Gizli Katmandaki Nöron Sayısı	11	32	11	32	11	32
Çıkış Katmanı	y_t	y_t	y_t	y_t	y_t	y_t
<i>OYMH</i> (%)	7,759	17,066	11,231	17,676	24,732	34,163
<i>HKOK</i>	38728	89152	119615	568323	272320	171730

Tablo 3.9 incelendiğinde zaman serisi modellemesinde kullanılan sinir ağı modelinin, gizli katmandaki nöron sayıları arttıkça, kestirim performanslarının düştüğü gözlemlenmiştir. Orijinal seri değerleri kullanılarak oluşturulan $k = 12$ gecikmeli “*Seri 1*” in en düşük *OYMH* sahip olduğu görülmektedir. Modele ait *OYMH* ve *HKOK* değerleri, gerçekleşmiş havalimanı yolcu değerleri ile yapay sinir ağı modelinden elde edilen öngörü sonuçları arasındaki sapmaların çok küçük olduğunu göstermektedir. Modelde bir giriş katmanı, iki gizli katman ve bir çıkış katmanı bulunmaktadır. Giriş katmanında bir, birinci gizli katmanda onbir, ikinci gizli katmanda onbir ve çıkış katmanında ise bir nöron bulunmaktadır. YSA eğitiminde kullanılan Seri 1, Seri 2 ve Seri 3 veri setleri EK-3 de verilmiştir.



Şekil 3.4. Denemeler Sonucunda Elde Edilen YSA Modeli

“Seri 1” verisi kullanılarak elde edilen 1:11:11:1 mimarili yapay sinir ağı modeli şekli 3.4’ verilmiştir.

3.5.3. Yöntemlerin Karşılaştırması ve Antalya Havalimanı Kısa Dönem Uluslararası Yolcu Talebinin Öngörülenmesinin Yapılması

Antalya Havalimanının yönelik uluslararası yolcu talebi tahminlerinde kullanılacak uygun modelin belirlenmesi amacıyla gelen uluslararası yolcular serisine uygulanan yöntemlerden elde edilen öngörü değerleri ile gerçekleşmiş değerler üzerinde yapılan doğruluk ölçümü sonuçları tablo 3.10’ de verilmiştir.

Tablo 3.10 Yöntemlerin Öngörü Doğruluklarının Karşılaştırılması

Yöntem	OYMH (%)	HKOK
<i>SARIMA</i> (1, 1, 0)(0, 1, 1)	10, 104	69701
Yapay Sinir Ağı	7, 759	38728

Tablo 3.10’ da görüldüğü gibi yapay sinir ağları ve zaman serisi mevsimsel Box-Jenkins yöntemleri ile yapılan öngörüler iyi sonuçlar vermiştir. Ancak, denemeler sonucunda elde edilen 1:11:11:1 mimarisine sahip YSA’nın, zaman serisi

$SARIMA(1, 1, 0)(0, 1, 1)$ yöntemi ile elde edilen modele göre daha düşük sapma değerlerine sahip olduğu görülmektedir.

Uygulanan yöntemlerin öngörü doğruluklarının karşılaştırılması neticesinde, 2011 yılı için Antalya Havalimanına yönelik uluslararası yolcu talebi tahminleri için 1:11:11:1 mimarisine sahip YSA modelinin kullanılmasına karar verilmiştir. Analizler sonucunda elde edilen YSA yöntemi ile Ocak 2011-Aralık 2011 döneminde Antalya Havalimanından giriş yapması beklenen aylık uluslararası yolcu sayısı öngörü gerçekleştirilmiş ve elde edilen öngörü değerleri tablo 3.11’ de verilmiştir.

**Tablo 3.11. 2011 Yıllı Antalya Havalimanı
Uluslararası Yolcu Talebi Öngörü Değerleri**

Ocak 2011	123815	Temmuz 2011	1395544
Şubat 2011	155528	Ağustos 2011	1395313
Mart 2011	211149	Eylül 2011	1398994
Nisan 2011	437971	Ekim 2011	900516
Mayıs 2011	1049861	Kasım 2011	184388
Haziran 2011	1261155	Aralık 2011	128578

SONUÇ VE ÖNERİLER

Geleceğe ilişkin kararların alınması probleminde belirsizlikler nedeniyle etkin bir öngörü yapılması zorlaşmaktadır. Belirsizlik giderilemese de azaltılabilmesi mümkündür. Bu da iyi bir şekilde modellenmiş öngörülerle gerçekleştirilebilir. İyi bir öngörü, en az hatayı veren tutarlı sonuçlar üreten öngörüdür.

Doğrusal zaman serileri kısa ve orta dönem öngörüsünde başarılı bir yöntem olduğu bilinen Box- Jenkins modelleri, aynı başarıyı doğrusal olmayan zaman serilerinde gösterememektedir. Diğer taraftan gerçek hayata ilişkin zaman serileri çoğu zaman doğrusal değildir. Bu nedenle, zaman serileri ile kestirimde Box-Jenkins modellerinden daha iyi sonuç verebilecek yeni yöntemler arayışı süregelmektedir. Alternatif yöntemlerden biri de Yapay Sinir Ağı yöntemidir.

Yapay Sinir Ağlarının, başarı ile kullanıldığı alanlardan biri de geleceği kestirim problemleridir. 1980’li yıllardan beri, bir kestirim aracı olarak kullanılmaktadır. Zaman serileri kestiriminde başarılı sonuçlar verip vermediğini araştırmak için bir çok çalışma yapılmıştır. Bu çalışmaların bir kısmı Yapay Sinir Ağı tekniklerinin, geleneksel yöntemlerden daha iyi sonuç verdiğini söylerken bir kısmı da herhangi bir farklılık olmadığını ileri sürmektedir.

Bu çalışmada, Yapay Sinir Ağları’ nın bir öngörü aracı olarak uygulamada geniş kabul gören Box-Jenkins modellerinden farklılığının olup olmadığı araştırılarak çalışmada kullanılan Antalya Havalimanı verileri serisinin trende sahip olması ve mevsimsel bileşenin etkilerini taşıması nedeniyle bu tip seriler için uygun olduğu belirtilen “Çarpımsal – Mevsimsel Box-Jenkins” yöntemi ile yapılan öngörülerin oldukça iyi sonuçlar verdiği gözlemlenmiştir. Box-Jenkins modelleri, çeşitli model seçenekleri arasında uygun olanı seçme ve seçilen modelin her aşamada incelenen seriye uygunluğunu denetleme gibi üstünlüklere sahiptir. “Mevsimsel Box-Jenkins” yönteminin diğer yöntemlere göre üstünlüğünün ise,

mevsimselliği modelde tanımlaması olduğu vurgulanmaktadır. Ancak, çalışmada kullanılan yöntemler içerisinde en yüksek öngörü doğruluğunu sağlayan ve gerçek değerlere en yakın sonuçları veren yöntemin, “Yapay Sinir Ağları” yöntemi olduğu tespit edilmiştir.

Yapay sinir ağlarının, sahip oldukları farklı özellikleri sayesinde talep öngörüsü oluşturmada geleneksel yöntemlere alternatif olarak kullanılabileceği söylenebilir. Yapay sinir ağı algoritmalarının, doğrusal olmayan ve dinamik sistemleri modellemede yararlı olduğu bir çok araştırmacı tarafından kabul edilmektedir. Ancak istatistiksel yöntemler beraberinde sorun alanına ilişkin anlaşılabilir ve yorumlamaya imkan veren parametreler üretmesine karşın, yapay sinir ağlarındaki bağlantı ağırlıklarını henüz yorumlama imkanı bulunmamaktadır. Bu nedenle yapay sinir ağları ile ulaşılan sonuçlarda modelin kapalı bir kutu olarak kaldığı da unutulmamalıdır.

Antalya Havalimanı uluslararası yolcu talep öngörüsünün son zamanlarda Arab ülkelerinde (Mısır, Suriye, Tunus, Libya) yaşanan iç karışıklıklar ve Yunanistan’ da yaşanan ekonomik bunalımın nedeni, bu ülkelerin uluslararası yolcu talebinin Türkiye’ye kayması ihtimali dikkate alınırsa, mevcut Antalya Havalimanı uluslararası yolcu talep öngörüsü değerlerinin üzerinde bir talebe ulaşılacağı söylenebilir. Ancak İnsan davranışlarının önceden kestirilemeyeceği dikkate alınmalıdır.

İleriye yönelik yapılacak çalışmalar için; farklı mimarilere sahip yapay sinir ağı modelleri kullanılarak, havalimanlarına yönelik yurt içi ve uluslararası yolcu talebi çalışmaları önerilebilir.

KAYNAKÇA

Kitaplar:

AGUNG, I., G., N., Time Series Data Analysis Useing Eviews, John Wiley & Sons (Asia) Pre. Ltd., Singapure, 2009

AKDİ, Y., "**Zaman Serileri Analizi (Birim Kökler ve Kointegrasyon)**" Bıçaklar Kitapevi, Ankara, 2003

AKGÜL, I., **Zaman Serilerinin Analizi ve ARIMA Modelleri**, Der Yayınları, İstanbul, 2003

ARBİB, M. A., "**The Handbook of Brain Theory and Neural Networks**" The Mit Press, England, 2003

BOZKURT, H. "**Zaman Serileri Analizi**", Ekin Kitapevi, Ankara, 2007

BOX, G. E .P., JENKINS. G., RREINSEL G. C. "**Time Series Analysis: Forecasting and Control**", Prentice-Hall Inc., New Jersey, Third Editions, 1994

BROCKWELL, P.J., Davis, D.A. "**Introduction to Time Series and Forecasting**", Springer-VerlagInc., New York, 2002

DOĞAN, A., "**Yapay Zeka**", Kariyer Yayıncılık, İstanbul, 2002

EFE, Ö. ve KAYNAK, O., "**Yapay Sinir Ağları ve Uygulamaları**", Bogaziçi Üniversitesi Yayınevi, İstanbul, 2000

ELMAS, Ç., "**Yapay Zeka Uygulamaları**", Seçkin Yayıncılık, Ankara, 2007

EVIEWS VERSION 7.0, QUANTITATIF MICRO SOFTWARE INK.

FRETCHLING, D. C., **Forecasting Tourism Demand: Methods and Strategies**, Butterworth-Heinemann, 2001

HAYKIN, S, "**Neural networks: A Comprehensive Foundation**", Pearson Prentice Hall, India.1999

GURNEY, K., **An Introduction To Neural Networks**, UCL Press Limited, London, 1999

KIRCHGÄSSNER, G., WOLTERS, J., **Introduction to Modern Time Series Analysis**, Springer-Verlag Inc, Berlin, 2007

MATLAB NEURAL NETWORK TOOLBOX, VERSION R2010a, MATH WORKS INK.

MONTGOMERY, D.C., JENNINGS, L.A. ve KÜLAHCI, M., **Introduction To Time Series Analysis And Forecasting**, John Wiley & Sons. Inc., Hoboken. New Jersey, 2008

NABİYEV, N. N., "**Yapay Zeka**", Seçkin Kitapevi, Ankara, 2010

ORHUNBİLGE, N., **Zaman Serileri Analizi Tahmin ve Fiyat Endeksleri**, İstanbul Üniversitesi İşletme Fakültesi Yayınları, No: 277, İstanbul, 1999

ÖZMEN, A., **Zaman Serisi Analizinde Box-Jenkins Yöntemi ve Banka Mevduat Tahmininde Uygulama Denemesi**, Anadolu Üniversitesi Yayınları, Eskişehir, 1986

ÖZTEMEL, E., "**Yapay Sinir Ağları**", Papatya Yayıncılık, İstanbul, 2003

RICHARD S., **Eviews Illustrated For Version 7**, Quantitatif Micro Software, USA, Second Editions, 2009

SEVÜKTEKİN, M., NARGELEÇEKENLER, M., "**Ekonometrik Zaman Seri-**

leri Analizi", Nobel Yayınları, Ankara, Mart 2010

Makale ve Bildiriler:

ABDELGHANY, A., ve GUZHVA, V. S., "*A Time-Series Modeling Approach For Airport Short-Term Demand Forecasting*", **Airport Management** , Volume: 5, 2010

ABED, S., Y., BA-FAİ, A. O., JASİMUDDİN, S., M., "*An Econometric Analysis of International Air Travel Demand in Saudi Arabia*", **Journal of Air Transport Management** , Volume: 7, 2001

ADEROMA, A., J., "*Demand For Transport In Nigeria*", **Journal Of Economics**, Volume: 1, 2010

AHMETZADE, F., "*Model For Forecasting Passanger of Airport*", **Proceeding of the 2010 İnternational Engineering Conference on Industrial Engineering and Operations Managment** Dhaka, Bangladesh, 9-10 January 2010

ALAM J. B., KARİM D. M ., "*Air Travel Demand Model For Domestic Air Transportation In Bangladesh*", **Journal Of Civil Engineering**, Yıl 1998, Volume: CE 26, No:1

ALEKSEEV, K.P.G. ve SEİXAS J.M., "*A multivariate neural forecasting modeling for air transport – Preprocessed by decomposition: A Brazilian application*", **Journal of Air Transport Management**, Yıl: 2009, Volume: 15

ÇUHADAR, M., GÜNGÖR, İ., ve GÖKSU, A., "*Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleriyle Karşılaştırmalı Bir Analizi : Antalya İline Yönelik Bir Uygulama*", **Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, Yıl: 2009, C: 14

GRUBB, H., MASON, A., "*Long Lead Time Forecasting Of UK Air Passengers By Holt–Winters Methods With Damped Trend*", **Journal of Air Transport**

Management , Volume: 17, 2001

GÜNGÖR, . ve ÇUHADAR, M., “*Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemiyle Tahmini*”, **Gazi Üniversitesi Ticaret ve Turizm Eğitim Fakültesi Dergisi**, Yıl: 2005, Sayı: 1

FIRAT, M. ve GÜNGÖR, M., “*Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi*”, **MO Teknik Dergi**, 2004

MEDEIROS, M., CV., McALER, M., SLOTTJE, D., RAMOS, V., MAQUIERIRA, J., R., "An Alternative Approach To Estimating Demand: Neural Network Regression With Conditional Volatility For High Frequency Air Passenger Arrivals", **Journal Of Econometrics**, Volume: 147, 2008

PROFİLLİDİS, V. A., "Econometric And Fuzzy Modeling For The Forecast Of Demand In The Airport Of Rodos", **Journal of Air Transport Management** , Volume: 6, 2000

SINGH, A. K. ve Das D., "Forecasting The Trafik Movement In Lufthansa Airlines: A Supply Chain Perspective", **Journal Of Services Research** Yıl 2010, Volume: 10, No:2

SOMAGAİO, A., M. WOLTERS, "Comparative Analysis Of Goverment Forecast For The Lisbon Airport ", **Journal of Air Transport Management** , Volume: 16, 2010

Diğer:

Tezler:

YURTOĞLU, H., Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi:
Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, Yayınlanmış Uz-
manlık Tezi, DPT, 2005

EKLER

EK-1

Antalya Havalimanı'ndan Giriş Yapan Aylık Uluslararası Yolcu Sayıları
(2004-2010)

	2004	2005	2006	2007	2008	2009	2010
Ocak	124585	154316	121648	104464	123382	88922	88922
Şubat	162929	181818	118177	132576	145458	119193	119193
Mart	215444	312486	204142	223001	260322	193086	193086
Nisan	400132	443696	436646	436428	452217	423508	423508
Mayıs	687994	842834	638682	824075	968322	863106	863106
Haziran	719479	888839	856224	1076113	1196019	1089685	1089685
Temmuz	987592	1160687	1038479	1271735	1342000	1268909	1268909
Ağustos	981158	1033122	1046637	1271235	1319581	1287753	1287753
Eylül	801040	878685	757586	1102143	1103012	1107114	1107114
Ekim	747145	805387	539795	699124	687451	682319	682319
Kasım	289845	225441	153746	253706	203376	217486	217486
Aralık	140644	127760	118418	137719	117546	125656	125656

EK-2

Aday Modellerin Eviews Çıktıları

SARIMA(1, 1, 1)(0, 1, 1) Modeline Ait Eviews Çıktısı

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.538691	0.218260	-2.468115	0.0167
MA(1)	0.237762	0.257308	0.924038	0.3595
SMA(12)	-0.901108	0.026144	-34.46653	0.0000
R-squared	0.545956	Mean dependent var		-0.000741
Adjusted R-squared	0.529445	S.D. dependent var		0.159363
S.E. of regression	0.109318	Akaike info criterion		-1.538766
Sum squared resid	0.657278	Schwarz criterion		-1.432192
Log likelihood	47.62423	Durbin-Watson stat		2.088003
Inverted AR Roots	-.54			
Inverted MA Roots	.99	.86-.50i	.86+.50i	.50-.86i
	.50+.86i	.00+.99i	-.00-.99i	-.24
	-.50+.86i	-.50-.86i	-.86+.50i	-.86-.50i
	-.99			

SARIMA(0, 1, 1)(0, 1, 1) Modeline Ait Eviews Çıktısı

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	-0.324704	0.118749	-2.734377	0.0083
SMA(12)	-0.901901	0.025822	-34.92715	0.0000
R-squared	0.533095	Mean dependent var		-0.002497
Adjusted R-squared	0.524904	S.D. dependent var		0.158558
S.E. of regression	0.109290	Akaike info criterion		-1.556322
Sum squared resid	0.680819	Schwarz criterion		-1.485897
Log likelihood	47.91150	Durbin-Watson stat		2.086449
Inverted MA Roots	.99	.86-.50i	.86+.50i	.50-.86i
	.50+.86i	.32	.00+.99i	-.00-.99i
	-.50+.86i	-.50-.86i	-.86+.50i	-.86-.50i
	-.99			

EK-3

YSA Eğitiminde Kullanılan Veri Setleri

Seri 1	Seri 2		Seri 3		
124585	154316	124585	121648	154316	124585
162929	181818	162929	118177	181818	162929
215444	312486	215444	204142	312486	215444
400132	443696	400132	436646	443696	400132
687994	842834	687994	638682	842834	687994
719479	888839	719479	856224	888839	719479
987592	1160687	987592	1038479	1160687	987592
981158	1033122	981158	1046637	1033122	981158
801040	878685	801040	757586	878685	801040
747145	805387	747145	539795	805387	747145
289845	225441	289845	153746	225441	289845
140644	127760	140644	118418	127760	140644
154316	121648	154316	104464	121648	154316
181818	118177	181818	132576	118177	181818
312486	204142	312486	223001	204142	312486
443696	436646	443696	436428	436646	443696
842834	638682	842834	824075	638682	842834
888839	856224	888839	1076113	856224	888839
1160687	1038479	1160687	1271735	1038479	1160687
1033122	1046637	1033122	1271235	1046637	1033122
878685	757586	878685	1102143	757586	878685
805387	539795	805387	699124	539795	805387
225441	153746	225441	253706	153746	225441
127760	118418	127760	137719	118418	127760
121648	104464	121648	123382	104464	121648
118177	132576	118177	145458	132576	118177
204142	223001	204142	260322	223001	204142
436646	436428	436646	452217	436428	436646
638682	824075	638682	968322	824075	638682
856224	1076113	856224	1196019	1076113	856224
1038479	1271735	1038479	1342000	1271735	1038479
1046637	1271235	1046637	1319581	1271235	1046637
757586	1102143	757586	1103012	1102143	757586
539795	699124	539795	687451	699124	539795
153746	253706	153746	203376	253706	153746
118418	137719	118418	117546	137719	118418
104464	123382	104464			
132576	145458	132576			
223001	260322	223001			
436428	452217	436428			
824075	968322	824075			
1076113	1196019	1076113			
1271735	1342000	1271735			
1271235	1319581	1271235			
1102143	1103012	1102143			

699124	687451	699124			
253706	203376	253706			
137719	117546	137719			
123382					
145458					
260322					
452217					
968322					
1196019					
1342000					
1319581					
1103012					
687451					
203376					

ÖZGEÇMİŞ

Doğum Yeri: Isparta

Doğum Yılı: 1981

Medeni Hali: Bekar

Eğitim Durumu:

Lisans:	Süleyman Demirel Üniversitesi Fen Edebiyat Fakültesi Matematik Bölümü -2008
Yüksek Lisans:	Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı -2011

Yabancı Dil ve Düzeyi:

İngilizce	Orta Düzey
-----------	------------

İş Tecrübesi:

Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Araştırma Görevlisi 2008-Devam Ediyor
--