

**T.C.
ULUDAĞ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI
YÖNEYLEM BİLİM DALI**

KESTİRİM YÖNTEMLERİ VE BİR UYGULAMA

(YÜKSEK LİSANS TEZİ)

Cem FİLİZ

BURSA 2010

**T.C.
ULUDAĞ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI
YÖNEYLEM BİLİM DALI**

KESTİRİM YÖNTEMLERİ VE BİR UYGULAMA

(YÜKSEK LİSANS TEZİ)

Cem FİLİZ

Danışman


Prof Dr. H. Kemal SEZEN

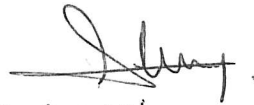
BURSA 2010

T. C.
ULUDAĞ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜNE

F. K. N. M. E. F. İ...... Anabilim/Anasanat Dalı,
Y. S. A. L. E. M...... Bilim Dalı'nda 7.00.2170.1.2..... numaralı
C. E. M. F. İ. T......'nın hazırladığı "K. E. T. Y. M. S. E. N.
T. E. M. L. İ. N. İ. V. E. B. N. M. Y. G. U. C. A. M. A."
konulu Y. S. A. L. E. M. L. İ. A. N...... (Yüksek Lisans/Doktora/Sanatta Yeterlik Tezi/Çalışması) ile
ilgili tez savunma sınavı, 20../1.0./ 20.10 günü 13.00 - 14.00 saatleri arasında yapılmış, sorulan
sorulara alınan cevaplar sonunda adayın tezinin/çalışmasının B. a. s. e. r. l. i...... (başarılı/başarısız)
olduğuna o. y. ç. o. k. l. u. ğ. u. (oy birliği/oy çokluğu) ile karar verilmiştir.


Prof. Dr. Kemal Sezer
Üye (Tez Danışmanı ve Sınav Komisyonu Başkanı)
Akademik Unvanı, Adı Soyadı
Üniversitesi


Prof. Dr. Ahmet Örtök
Üye
Akademik Unvanı, Adı Soyadı
Üniversitesi


M. Doç. Dr. Gökçe KASAP
Üye
Akademik Unvanı, Adı Soyadı
Üniversitesi

Üye
Akademik Unvanı, Adı Soyadı
Üniversitesi

Üye
Akademik Unvanı, Adı Soyadı
Üniversitesi

20../1.0./ 20.10

ÖZET

Yazar : Cem FİLİZ
Üniversite : Uludağ Üniversitesi
Anabilim Dalı : Ekonometri Anabilim Dalı
Bilim Dalı : Yöneylem Bilim Dalı
Tezin Niteliği : Yüksek Lisans Tezi
Sayfa Sayısı : VII + 54
Mezuniyet Tarihi : /..... / 2010
Tez Danışmanı : Prof. Dr. H. Kemal SEZEN

KESTİRİM YÖNTEMLERİ VE BİR UYGULAMA

Bu araştırmanın amacı, metal sektöründe raf imalatı alanında üretim yapan, küçük ölçekli bir firmanın satış verilerinin doğru bir yapıya sahip olup olmadığının araştırılması ve eldeki zaman serisi verileri ile gelecek dönem satış kestirimlerinin doğruluğunun araştırılmasıdır. Çalışma 1 Ocak 2005 – 31 Aralık 2009 tarihleri arasında elde edilen 60 aylık zaman serisi satış verileri örnekleme ele alınarak yapılmıştır.

Kestirim yöntemleri ile ilgili tanımsal bilgilere yer verilmiştir. Uygulamada kullanılan verilerin zaman serisi verileri olmasından dolayı verilerde karşılaşılabilecek problemler ve bu problemin çözümüne yönelik yöntemler uygulanmıştır. Zaman serisi verileri ile oluşturulan modeller Box – Jenkins yöntemleri ile açıklanmıştır. Elde edilen zaman serisi satış verileri, EVIEWS paket programı ile analiz edilmiştir. İstatiksel analiz birim kök test teknikleri kullanılarak yapılmıştır.

Uygulanan program sonucunda zaman serisi verilerinin durağan olmadığı eldeki verilerle kestirimin doğru sonuçlar vermeyeceği belirlendikten sonra birinci dereceden fark alınarak veriler durağanlaştırılmıştır. Hata değerlerini minimum yapan Box – Jenkins yöntemi ARMA (1,1) modeli, kestirim için doğru sonucu veren model olduğu sonucuna varılmıştır.

Anahtar Sözcükler
Kestirim, Zaman serisi

ABSTRACT

Yazar : Cem FİLİZ
Üniversite : Uludağ Üniversitesi
Anabilim Dalı : Ekonometri Anabilim Dalı
Bilim Dalı : Yöneylem Bilim Dalı
Tezin Niteliği : Yüksek Lisans Tezi
Sayfa Sayısı : VII+ 54
Mezuniyet Tarihi : /..... / 2010
Tez Danışmanı : Prof. Dr. H. Kemal SEZEN

FORECASTİNG METHODS AND A CASE STUDY

This paper aims to discover whether a previous sales data of a small scale firm that operates in a shelving industry is in line with the data calculated using time series for forecasting future sales data. Sales data gathered for 60 months between 1st Jan 2005 and 31st December 2009 has been used for this study.

Firstly, number of forecasting methods is discussed; secondly possible errors that may come up due to the nature of the time series data applied is discussed and solutions to those problems are also looked at. Models acquired using time series data is explained through Box-Jenkins technique. Time series data is then analysed with EVIEWS package programme. Analysis is carried out using Augmented Dickey-Fuller Test Statistic.

As a result of the applied programme, time series data first obtained was not stable, therefore could not have resulted accurately. Data is then corrected taking a first degree difference. To conclude, it is found out that Box Jenkins method ARMA (1,1), minimizes the error values therefore it is the precise model for forecasting.

Key Words

Forecasting, Time Series

ÖNSÖZ

Bu çalışma, Uludağ Üniversitesi Sosyal Bilimler Enstitüsü' ne bağlı "Ekonometri Anabilim Dalı Yöneylem Araştırması Bilim Dalı'nda" Yüksek Lisans Tezi olarak hazırlanmıştır.

Tezin konusu; kestirim yöntemleri ve örneklem olarak alınan raf imalatı üzerine çalışan bir firmanın, geçmiş yıllarının verileri ışığında, önümüzdeki dönemin satış tahminin yapılmasıdır.

Tez Prof. Dr. H. Kemal SEZEN' in danışmanlığı altında yapılmıştır.

Bu çalışmada bana, görüş ve önerileri ile yardımcı olan Prof. Dr. H. Kemal SEZEN' e teşekkürlerimi bir borç bilirim.

Bursa, Ekim 2010

Cem FİLİZ

İÇİNDEKİLER

	Sayfa
TEZ ONAY SAYFASI.....	II
ÖZET.....	III
ABSTRACT.....	IV
ÖNSÖZ	V
İÇİNDEKİLER.....	VI
GİRİŞ.....	1
BİRİNCİ BÖLÜM	
KESTİRİM (FORECASTİNG).....	2
Kestirim Tanımı.....	3
1.1. Kestirim Yöntemleri.....	3
1.1.1. Niteliksel Kestirim Yöntemi.....	4
1.1.2. Niceliksel Kestirim Yöntemi.....	4
1.1.2.1. Nedensel Modeller veya Regresyon Yöntemi.....	4
1.1.2.2. Zaman Serisi Yöntemleri ve Özellikleri.....	4
1.2. Zaman Serileri Yöntemlerinin Bileşenleri.....	6
1.2.1. Trend.....	6
1.2.2. Mevsimsel Değişmeler.....	6
1.2.3. Konjonktürel Değişmeler.....	7
1.2.4. Zaman Serilerinde Hata Terimleri.....	7
1.2.5. Zaman Serisinde Otokorelasyon.....	7
1.2.6. Zaman Serilerinde Sapma Değerleri.....	8
1.2.7. Zaman Serilerinde Veri Yaratma Süreci.....	8
İKİNCİ BÖLÜM	
KESTİRİM YÖNTEMLERİ	9
2.1. Üstel Düzeltme Yöntemleri.....	10
2.1.1. Holt Üstel Ağırlıklı Hareketli Ortalamalar Yöntemi.....	11
2.1.2. Holt' un İki Parametrelili Doğrusal Üstel Düzeltme Yöntemi.....	11
2.1.3. Brown' un Tek Parametrelili Doğrusal Üstel Düzeltme Yöntemi.....	12
2.1.4. Brown' un Tek Parametrelili (2. Derece) Karesel Üstel Düzeltme Yöntemi..	14
2.1.5. Winters Mevsimsel Düzeltme Yöntemi.....	14
2.2. Box – Jenkins Yöntemleri.....	17
2.2.1. Otoresif Süreç (AR) İle Kestirim.....	17
2.2.1.1. AR (1) Yöntemi.....	18
2.2.1.2. AR (P) Yöntemi.....	18
2.2.2. Hareketli Ortalama (MA) İle Kestirim.....	19
2.2.2.1. MA (1) Yöntemi.....	19
2.2.2.2. MA (q) Yöntemi.....	20
2.2.3. Otoresif Hareketli Ortalama Süreci (ARMA) İle Kestirim.....	20
2.2.3.1. ARMA (1, 1) Yöntemi.....	20
2.2.3.2. ARMA (p, q) Yöntemi.....	21
2.2.4. ARIMA Yöntemi İle Kestirim.....	22
2.2.4.1. ARIMA (1, 1, 1) Yöntemi.....	22
2.2.4.2. ARIMA (p, d, q) Yöntemi.....	22
2.3. Yapay Sinir Ağları Yöntemi.....	24
2.3.1. Yapay Sinir Ağları Araştırma Metodu.....	28

2.3.2. Yapay Sinir Ağları Kestirim Sonuçlarının Değerlendirme Kriterleri.....	30
---	----

ÜÇÜNCÜ BÖLÜM

UYGULAMA VE SONUÇLAR	33
3.1. Formel Olmayan Grafikselsel Test.....	33
3.2. Birim Kök Test Sonuçları.....	34
3.3. Üstel Düzeltme Yöntemleri ve Sonuçları.....	36
3.3.1. Holt Winters.....	36
3.3.2. Basit ortalama.....	37
3.3.3. Hareketli Ortalama.....	38
3.4. Box – Jenkins Yöntemleri İle Kestirim Sonuçları.....	39
3.4.1. AR (1).....	40
3.4.2. AR (2).....	40
3.4.3. AR (3).....	41
3.4.4. MA (1).....	41
3.4.5. MA (2).....	42
3.4.6. MA (3).....	42
3.4.7. ARMA (1,1).....	43
3.4.8. ARMA (2,1).....	43
3.4.9. ARMA (1,2).....	44
3.4.10. ARMA (2,2).....	45
3.4.11. ARMA (3,2).....	46
3.4.12. ARMA (3,3).....	47
3.4.13. ARMA (4,3).....	48
3.5. Box – Jenkins Yöntemlerine Ait AIC ve SC Değerleri.....	49
SONUÇ.....	50
KAYNAKLAR.....	52
İŞLETMENİN 60 AYLIK SATIŞ VERİLERİ.....	53
ÖZGEÇMİŞ.....	54

GİRİŞ

Son yıllarda zaman serisi verileri ile kestirim yapmanın işletmeler için önemli olduğu gerçeğinden hareket edilerek çalışmaya başlanılmıştır. Metal sektöründe raf imalatı alanında üretim yapan küçük ölçekli bir firmanın 1 Ocak 2005-31 Aralık 2009 tarihleri arasındaki 60 aylık satış verilerinin doğru bir kestirim için uygun bir yapıya sahip olup olmadıkları araştırılmıştır. Kestirim işletmelerin maliyetlerini minimum seviyede oluşturmalarını sağlarken günümüz rekabet ortamında gelecekle ilgili yatırım kararlarını doğru alıp var olma ve büyüme hedeflerine yönelmelerini sağlayacaktır. Ancak kestirimden bir önceki evre olan mevcut verilerin araştırılması işlemi kestirim sonuçlarının doğruluğu için hayati önem taşıdığı inkar edilemez bir gerçektir.

Birinci bölümde kestirim ile ilgili tanımsal bilgilere yer verilmiştir. Kestirimin tanımı, faydaları ve yöntemleri açıklanmaya çalışılmıştır. Uygulamada kullanılacak verilerin zaman serisi verileri olmasından dolayı zaman serisi ve modelleri hakkında açıklamalarda bulunulmuştur.

Çalışmanın ikinci bölümünde elimizdeki verilerde karşılaşılabileceğimiz sorunların ortadan kaldırılabilmesi için kullanacağımız düzeltme yöntemleri ele alınmıştır. Ayrıca kestirimde kullanacağımız modeller hakkında da bilgi verilmiştir.

Üçüncü bölümde yukarıdaki bilgiler neticesinde verilerin analizleri yapıp kestirim için uygun olan modelin tespit işlemi gerçekleştirilmiştir. Son bölümde sonuçlar ayrıntılı bir biçimde yorumlanmıştır.

BİRİNCİ BÖLÜM
KESTİRİM (FORECASTING)

BİRİNCİ BÖLÜM

Kestirim Tanımı

Kestirim, geçmiş ve bugünkü verilere dayanarak gelecekteki olayların belli bir olasılıkla tahmin edilmesidir. Kestirim yaklaşımlarından biri ekonometrik model kurularak geleceği tahmin etme çalışması iken diğer yaklaşım ise zaman serisi ile kestirim veya değişkenin kendi geçmiş değerlerinden hareketle başarılı gelecek kestirim değerlerini elde etme çalışmasıdır.

Kestirimin amacı tanımından da anlaşılacağı üzere bugünkü ve geçmiş değerlerin incelenerek gelecekteki olası en yakın değerini ortaya çıkarma çalışmasıdır. Ancak kestirim her zaman doğru sonuçları vermeyebilir, mutlaka belli bir hata içerirler. Bu hatalar geçmiş değerlerin gelecek değerleri ne kadar açıklayabildiğini bize gösterir. Finansal yatırım kararları açısından geleceğin talep tahminlerinin artış veya azalış şeklinde kestirimi de önemlidir. Yatırım kararlarını alacak olan işletme yöneticilerinin geleceği doğru öngörmesinin yararlarını aşağıda sıralayabiliriz;

- Verimli iş gücü gereksinimini planlama,
- Doğru işletme bütçesini oluşturma,
- Ekonomik satın alma yapabilmesi,
- Sağlıklı nakit akışını planlama,
- Düşük döküm seviyeleri ile daha az stok bulundurma,
- Az sayıda üretim hattı değişiklikleri yapma,
- İyi müşteri hizmet seviyesine ulaşmayı sağlama.¹

1.1. Kestirim Yöntemleri

Kestirim yöntemleri niteliksel kestirim yöntemleri ve niceliksel kestirim yöntemleri olmak üzere iki ana başlıkta ele alınacaktır.

¹ H.Kayım, **İstatistiksel Ön Tahmin Yöntemleri**, Ankara 1985 s.6

1.1.1. Niteliksel Kestirim Yöntemi: Çok az sayıda veri bulunduğu ve mevcut durumun belirgin olmadığı durumlarda üst yöneticilerin ve uzmanların oluşturduğu bir grubun geçmiş deneyimlerini kullanarak gelecekle ilgili, sezgilere dayanarak kestirimde bulunmalarıdır. Bu yöntemde genelde yeterli miktarda veri bulunmamaktadır. Geçmiş deneyimler ve sezgilerin geleceğin kestiriminde sağlıklı sonuçlar vermediği görülmektedir. Niteliksel kestirim yöntemleri;

Müşteri ve Pazar araştırmaları sonucunda veri elde edilmesi ile kestirim,
Şirket üst yönetici ve uzmanlarının deneyim ve sezgilerinin birleştirilmesi ile kestirim,
Saha satış ekibinden bölgesel geri bildirimlerin birleştirilmesi ile kestirim,
Uzman kararları ve şirket yöneticilerinin kararlarının karşılaştırması ile kestirim,
şeklinde olabilir.

1.1.2. Niceliksel Kestirim Yöntemi: Geçmiş verilerin mevcut ve yeterli olması durumunda ve bu verilerin geleceği temsil edebilme özelliğine sahip olabilmesine dayanarak yapılan kestirim için kullanılan yöntemdir. Niceliksel kestirim yöntemleri; nedensel modeller veya regresyon yöntemi ve zaman serisi modelleri olarak sınıflandırılabilir.

1.1.2.1. Nedensel Modeller veya Regresyon Yöntemi: Bir veya daha fazla birbirinden bağımsız nedensel değişken tanımlanarak bağımlı değişkenin kestirimi elde edilir.

$$Y=f(X_1, X_2, \dots, X_n)$$

Yukarıdaki modelde,

X_i ; bağımsız değişkenleri,

Y ; bağımlı değişkeni tanımlar.

1.1.2.2 Zaman Serisi Yöntemleri ve Özellikleri: Belirli bir zaman aralığına göre sıralanmış ve arka arkaya toplanmış gözlem değerlerinin oluşturduğu dizilere zaman serisi verileri denir. Zaman serisi verileri günlük, haftalık, aylık, üç aylık, yıllık ve daha uzun dönemli aralıklarla derlenir. Finansal zaman serisi verileri eşit aralıklı zaman noktalarında ölçülmüş gözlem değerlerinden oluşurlar. Zaman serisi verileri elde edilmiş şekillerine göre sürekli ve kesikli olarak ikiye ayrılır. Gözlem değerleri zaman içerisinde devamlı olarak toplanıyorsa sürekli zaman serisidir. Gözlem değerleri belirli aralıklarla toplanıyorsa, serinin

ait olduđu deęişken zaman içerisinde sürekli olarak bir deęer almıyor sadece belirli zaman aralıklarında bir deęer alıyor ise ve bu deęerler birikimli olarak elde ediliyor ise kesikli zaman serileri denir. ² Başka bir deyişle, bir zaman serisi zaman içerisinde sürekli bir biçimde gözlenebiliyorsa sürekli, yalnızca belirli özel durumlarda gözlenebiliyorsa dizi kesikli zaman serisidir. Zaman serileri ile ilgili incelemeye başlamadan önce özelliklerinin üzerinde durmakta fayda vardır:

Zaman serisi verileri birbiri ile korelasyonludur. Başka bir deyişle gözlem deęerinin gerçekleşmesi dięer gözlem deęerinin gerçekleşmesinden bağımsız deęildir. Bir sonraki dönemin kestirimi kendinden önceki dönemin deęerleri ile bağlantılı olması zaman serilerinin önemli bir özelliđidir.

Zaman serilerinin saçılım grafiklerinde genelde yatay ekseninde zaman faktörü yer alırken dikey ekseninde deęişkenin kendi deęerleri yer alır. Zaman serilerinin grafikleri çoęu zaman artma eğilimi göstermektedir.

Zaman serileri bir matematiksel fonksiyon ile kesin bir biçimde belirlenebiliyorsa deterministik zaman serileri denir. Gözlem deęerleri bir olasılık dağılımı ile açıklanabiliyorsa bu zaman serisine stokastik zaman serisi denir. ³ Finansal zaman serileri kesin bir matematiksel fonksiyon ile tanımlanamazlar. Stokastik zaman serileri şeklinde tanımlanarak çalışmalar yürütülür. Bir zaman serisinin gelecek deęerinin kestiriminde, devamlı olayları etkileyen tüm faktörlerin modele dahil edilerek yapılması mümkün deęildir. Modele dahil edilemeyen faktörleri içinde barındırdığı düşünölen hata terimini modele dahil ederek stokastik model süreci gerçekleşmiş olur.

² M. Sevöktekin ve M. Nargeleçekenler, **Zaman Serileri Analizi**, Ankara 2005, s.5

³ C.Chatfield, **The Analysis of Time Series: An Introduction**, New York: Chapman and Hall, 1980, s.6

Zaman serilerinin modellenmesi ekonometrik modelleme ile birbirinden farklılık göstermektedir. Ekonometrik modellemede bir değişkenin davranışı diğer değişkenler ile arasındaki ilişki dikkate alınarak belirlenirken zaman serilerinin modellenmesinde kestirimi yapılacak değişkenin davranışı kendi geçmiş değerleri tarafından belirlenir.

1.2. Zaman Serileri Yöntemlerinin Bileşenleri

Zaman serileri verileri ile oluşturulan modeller yapısal özellikleri bakımından aşağıda belirtilen bileşenleri içermektedir.

1.2.1. Trend

Zaman serisinin uzun dönemdeki artış veya azalış yönündeki eğilimini gösterir. Eğilimin incelenebilmesi için zaman serisi verilerinin uzun bir dönemi kapsamı gerekir. Zaman serisi değişkenleri artan, azalan veya değişmeyen yapıda bir trend özelliğine sahip olabilir. Zaman serisinde eğilim, zaman serisinin uzun dönemli eğilimini gösterir. Bir seride eğilim değişimleri adeta serinin ortalaması gibidir.⁴

1.2.2. Mevsimsel Değişmeler

Zaman serisi verileri kısa zaman aralıklı ise (aylık veya üç aylık toplanmış), bu halde mevsimsel değişimler gözükülebilir.⁵ Zaman serilerinde mevsimselliğin ortaya çıkışında iklimler, insan alışkanlıkları, bayramlar, bazı sosyal olaylar, kampanyalı satışlar gibi faktörler etkili olur. Mevsimsellik çok farklı şekillerde ortaya çıkabilir. Örneğin; yılın belirli mevsimlerinde belirli aylarında veya daha kısa zaman dilimlerinde ortaya çıkabilir.

Mevsimsel bileşen belirli aralıklarla tekrarlı bir salınım gösterir. Bir zaman serisinin gözlem değerleri trendin altında veya üstünde tekrarlı biçimde değer almasıyla mevsimlik etkiler ortaya çıkar.

⁴ M. Sevüktekin ve M. Nargeleçekenler, **Zaman Serileri Analizi**, Ankara 2005, s.11

⁵ H.Kayım, **İstatistiksel Ön Tahmin Yöntemleri**, Ankara 1985 s.18

1.2.3. Konjonktürel Değişmeler

Genellikle ekonominin veya sektörlerin refah ya da durgunluk dönemlerini içeren değişmelerdir. Ekonomik kriz dönemlerinde kısa süreli olarak ekonomik veriler düşüş gösterirken krizin ardından ekonomideki düzelme neticesinde veriler artış eğilimi gösterir. Konjonktürel hareketlerin ortalama uzunlukları mevsimsel dalgalanmalardan daha uzundur. Konjonktürel dalgalanmalar mevsimlik değişmelere göre daha fazla değişkendir. Mevsimlik dalgalanmalar daha düzenli ve periyodik iken konjonktürel hareketler düzensiz ve periyodik değildir. Konjonktürel hareketler içeren zaman serileri ile kestirim yapmak oldukça zordur. Çünkü gelecek dönemde konjonktürel dalgalanmaların etkilerinin tekrar ortaya çıkması kuvvetli bir olasılıktır. Yinede kestirim yapılacak ise zaman serisinin son dönem ortalamalarından yola çıkılarak artma ve azalma eğilimine bakılarak geçmiş son birkaç dönem verileri ile tahmin yapılır.

1.2.4. Zaman Serilerinde Hata Terimleri

Belirli faktörler dışında kalan ve varlığı daha önceden tahmin edilemeyen ve etkisini devamlı olarak göstermeyen bazı olayların sonucunda ortaya çıkar. Örneğin; grevler, döviz kuru düşüş ve artışları gibi.

1.2.5. Zaman Serisinde Otokorelasyon

Otokorelasyon kavramsal olarak bir serinin herhangi bir dönemdeki değeri ile bir önceki değeri veya bir sonraki dönem değeri arasında birlikte hareket etme ilişkisidir. Eğer bir seride otokorelasyon var ise serinin gözlemleri arasında bir korelasyonun var olduğu söylenebilir. Örneğin; herhangi bir seride yüksek düzeyde bir otokorelasyon var ise ve seri aylık gözlemlerden oluşuyor ise bir ayın gözlem değeri, bir önceki ayın gözlem değeri ile nedensel olmayan bir ilişki veya birlikteliği söz konusu olacaktır. ⁶ Dolayısıyla eğer seri otokorelasyonlu ise trend ve mevsimlik değişme nedeni ile sistematik etkileri göz önünde bulundurmak gerekir. Zaman serisinde ardışık değerler arasında yüksek otokorelasyon olduğunda basit fakat doğru yöntemler ile bir dönem ilerisi için kestirim yapılabilir. Daha ileri dönemler için doğru kestirim elde etmek zorlaşır.

⁶ M. Sevüktekin ve M. Nargeleçekenler, **Zaman Serileri Analizi**, Ankara 2005, s.16

1.2.6. Zaman Serilerinde Sapma Değerleri

Zaman serilerinde bazen anlık ve çoğunlukla tekrarlanmayan sapma değerleri ile karşılaşılır. Sapma değerleri seride var olan gözlem değerlerinden ortalama olarak ya çok küçüktür, ya da çok büyüktür. Dolayısıyla bunlar ne geçmişin ne de geleceğin kalıbını temsil ederler. Sapma değerleri genellikle olağan dışı olaylardan kaynaklanan ve tekrarlanmayan gözlem değerleridir. Zaman serisi analizlerinde sapan değerlerin düzeltilmesi önem arz eder. Özellikle kestirim yapmada sapma değerinin konumu oldukça büyük sorunlar çıkarabilir. Bundan dolayı kestirim öncesi bu tür gözlemlerin düzeltilmesinde fayda vardır.

1.2.7. Zaman Serilerinde Veri Yaratma Süreci

Gözlemler; veri yaratma sürecine dayanarak tek bir gerçekleşme gibi dikkate alınmalıdır. Yalnızca bir gözlem seti bulunsa bile yine de gözlemleri aynı zaman dönemi boyunca sonsuz sayıda gerçekleştirmeleri veri yaratma sürecine dayanarak ortaya çıkması muhtemeldir. Zaman serileri veri yaratan bir istatistiksel bir süreç tarafından karakterize edilmiştir. Zaman serileri analiz edilmeden önce verilerin oluşum süreci hakkında bilgi sahibi olunmalıdır. En basit şekilde veri yaratma süreci aşağıdaki şekilde tanımlanabilir.

$$Y_t = \alpha_1 Y_{t-1} + \varepsilon_t$$

Burada;

Y_t ; Talep serisidir,

$\alpha_1 Y_{t-1}$; Y_t değişkeninin geçmiş değerlerinin birleşimi,

ε_t ; Hata değişkenini tanımlar.

Y_t talep serisi değişkenlerinin değerleri, Y_t ' nin kendi önceki dönem değeri (Y_{t-1}) ve hata değişkeni (ε_t) ile belirlenmektedir. Olağan en küçük kareler yöntemi varsayımlarından hatırlanacağı gibi hata değişkenleri stokastik olduğundan Y_t talep serisi hata değişkeni ve kendi geçmiş değerlerinin doğrusal birleşiminden oluştuğu için stokastik zaman serisi olacaktır. Hata teriminin beklenen değeri (veya ortalaması) sıfır ($E[\varepsilon_t]=0$) ortalama civarında dalgalanmalar gösterir. Hata terimi sabit varyansa ($E[\varepsilon_t^2]= (\sigma^2 \varepsilon)$) sahiptir ve kendi geçmiş değerleri ile korelasyonsuzdur ($E(\varepsilon_t \varepsilon_{t-i})=0$).

İKİNCİ BÖLÜM
KESTİRİM YÖNTEMLERİ

İKİNCİ BÖLÜM

2.1. Üstel Düzeltme Yöntemleri

Üstel düzeltme yöntemleri Holt' un "Üstel Tartılı Hareketli Ortalamalar" ilkelerine dayanmaktadır. Bütün kestirim modellerinde değişkenin ileri dönem değerleri, geçmiş dönem değerleriyle ilişkilendirilmektedir. Bunlardan en basit olanı "Doğrusal Hareketli Ortalamalar" yöntemidir. Bu basit yöntem zaman serisi eğiliminde meydana gelen değişimleri yansıtmakta yeterli olmadığı için kabul edilebilir değildir. Açıkça görülen sakıncası, gelecek dönem kestiriminde doğrusal hareketli ortalamalar yöntemi değişkenin geçmiş dönemdeki verilerine eşit ağırlık vermesidir. Geçmiş dönemlere gidildikçe gelecekteki kestirim döneminin üzerine etki gittikçe azalmaktadır.

Bu yöntem:

$$Y_t = \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_i Y_{t-i-1}$$

Şeklindedir.

Burada;

Y_t ; serinin aritmetik ortalamasını,

Y_{t-1} ; t zamandaki gözlem değeri,

α_i ; üstel düzeltme katsayıdır.

$\alpha_1 > \alpha_2 > \dots > \alpha_i$ (birinci düzeltme katsayısını izleyen her bir katsayı kendinden öncekinin oranıdır)

ve

$$\alpha_1 + \alpha_2 + \dots + \alpha_i = 1$$

Kısa dönem kestirim fonksiyonları üzerine yapılan araştırmalar yukarıdaki ilişkiyi temel alır.

2.1.1. Holt Üstel Ağırlıklı Hareketli Ortalamalar Yöntemi

$$Y_t = \alpha Y_t + (1 - \alpha) Y_{t-1}$$
$$Y = Y_{t-1} + \alpha (Y_t - Y_{t-1})$$

Şeklinde yazılabilir.

Holt' un denkleminde α 0 ile 1 arasındadır. $0 < \alpha < 1$

Eğer; $\alpha = 1$ ise $Y_t = y_t$ ' dir. Yani değişkenin t zamandaki ortalama değerinin kestirimi, t zamandaki değişkenin gerçekleşmiş gözlem değerine eşittir.

Eğer; $\alpha = 0$ ise $Y_t = Y_{t-1}$ ' dir. Yani şimdiki dönem ortalama kestirim değeri bir önceki ortalama kestirimine eşittir. Dolayısıyla ortalama değerlerde herhangi bir değişme olmamıştır.

α ' nın 0 ile 1 arasındaki değerleri, rassal değişmelerden dolayı değişkenin ortalama değerinin değişebileceğini gösterir. Seri ortalaması önemli ölçüde değişmiyorsa, α için seçilecek yüksek değerler yanıltıcı sonuçlar ortaya çıkarabilir. Örneğin $\alpha = 0,2$ olarak belirlenmiş ise seri ortalamasındaki değişmelerin % 20' si gerçek değişmelerden, %80' i rassal değişmelerden ileri geliyor demektir. ⁷

Çalışmalarda kestirim hatasını minimum yapmasından dolayı α ' nın değerinin genellikle 0,01 – 0,3 arasında seçilmesi tavsiye edilir.

2.1.2. Holt' un İki Parametrelili Doğrusal Üstel Düzeltme Yöntemi

Holt' un iki parametrelili doğrusal üstel düzeltme yöntemi kestirim değerlerine serideki eğilimi yansıtır. Bunun için üç denklem kullanmaktadır.

$$S_t = \alpha Y_t + (1 - \alpha) (S_{t-1} + T_{t-1}) \quad \mathbf{1}$$
$$T_t = \beta (S_t - S_{t-1}) + (1 - \beta) T_{t-1} \quad \mathbf{2}$$
$$F_{t+i} = S_t + i T_t \quad \mathbf{3}$$

⁷ H.Kayım, **İstatistiksel Ön Tahmin Yöntemleri**, Ankara 1985 s.32

Bu yöntemde 1 numaralı denklem 2 numaralı denklemin benzeridir. Farkı 1 numaralı denkleme T_{t-1} gibi eğilim terimi eklenmiştir. β eğilim 2 numaralı denklemden hesaplanmaktadır.

Eğilimin kestiriminde birbirini izleyen üstel düzeltilmiş değerler arasındaki fark kullanılır. Çünkü birbirini izleyen üstel düzeltilmiş değerler rassallık için düzeltilmiş olduğundan aralarındaki fark eğilimi verecektir. Bu fark β ile çarpılır ve bir geri dönem için tahmin edilen eğilim de $1 - \beta$ ile çarpılıp toplanırsa, şimdiki dönemde düzeltilmiş eğilim elde edilir. Bunu yapmaktaki amaç, yalnız gerçek veri değerleri üzerinde düzeltme yapmakla kalmayıp aynı zamanda eğilim değerleri üzerinde de düzeltme yapmaktır.

3 numaralı denklem kestirim fonksiyonudur. Burada S_t , 1 numaralı denklemden elde edilen düzeltilmiş değeri, t kestirimi yapılacak geri dönem sayısını ve T_t' de 2 numaralı denklemden elde edilen eğilim değerlerini göstermektedir.

2 numaralı denklemde kullanılan β parametresi α' ya benzer. β eğilimi düzeltmektedir. Çalışmada α ve β parametre değerleri belirlenir. Hata kareler ortalamasını minimum yapacak α ve β parametre değerleri sınama yoluyla belirlenir.⁸

2.1.3. Brown' un Tek Parametrelili Doğrusal Üstel Düzeltme Yöntemi

Brown' un tek parametrelili doğrusal üstel düzeltme yöntemi durağan olmayan zaman serilerindeki eğilimi kestirime dahil eder. Yöntem şu şekilde gösterilmektedir;

$$S'_t = \alpha Y_t + (1 - \alpha) S'_{t-1} \quad 4$$

$$S''_t = \alpha S'_t + (1 - \alpha) S''_{t-1} \quad 5$$

Burada;

S'_t ; t zamandaki basit üstel düzeltme değerini

S''_t ; t zamanındaki ikili üstel düzeltme değerini göstermektedir.

⁸ M. Sevüktekin ve M. Nargeleçekenler, **Zaman Serileri Analizi**, Ankara 2005, s.47

4 ve 5 numaralı denklemlerden elde edilen değerler kullanılarak b_t gibi bir eğilim ve δ_t gibi sabit değer hesaplanır. Kestirim fonksiyonu da b_t ve δ_t lerin doğrusal bileşimi olarak,

$$F_{t-i} = \delta_t - b_{ti} \quad 6$$

Yazılır.

i geçmiş dönemi gösterir. b_t ve δ_t lerde

$$b_t = (\alpha / 1 - \alpha) (S'_t - S''_t) \quad 7$$

$$\delta_t = S'_t + (S'_t - S''_t) = 2 S'_t - S''_t \quad 8$$

Formülleri kullanılarak tahmin edilir.

5 numaralı denklem 4 numaralı denklemde elde edilen değerleri düzeltmekte ve bu değerlerde eğilimin hesaplanmasında kullanılmaktadır.

7 numaralı formülden de görüldüğü üzere eğilim ikili üstel düzeltme ile basit üstel düzeltme değerleri arasındaki farkın $\alpha / 1 - \alpha$ oranı çarpımıyla tahmin edilmektedir. Burada bu oran bir zaman gecikmesini göstermektedir ve bu sürede $S'_t - S''_t$ arasındaki zaman aralığıdır.

8 numaralı formül, sabit değer formülü olup gerçek gözlem değerleriyle veri düzeyi arasında uygunluğu sağlar. Basit üstel düzeltme yöntemiyle hesaplanan S'_t düzeltilmiş değeri, bu düzeltilmiş değerle ikili üstel düzeltme değeri arasındaki fark kadar gerçek gözlem değerlerinin altında bulunabilir. İşte bu fark S'_t ye eklenerek veriyi bugünkü düzeyine ulaştıracak şekilde düzenlemesi yapılmış olacaktır. δ_t düzeltilmiş bir değer olduğundan rassal değişimlerden arınmıştır. Eğer rassal değişimlerin önemli bir etkisi yok ise δ_t yerine Y_t kullanılabilir. Fakat rassal değişimler ekonomik serilerde önemli bir rol oynar. Onun için 6 numaralı denklemin kullanılması doğru olur. Böylelikle kestirim fonksiyonunda sürekli olarak bir eğilim değişkenine yer verilmiş olunacaktır.

Bu yöntemde α ' nın değeri araştırmacı tarafından belirlenir. Tavsiye edilen 0,1 olsa da uygulamalarda $\alpha = 0,01 - 0,3$ değerleri arasında yer alır. Çünkü minimum hata kareler ortalaması bu değerlerde sağlanabilecektir.

2.1.4. Brown' un Tek Parametrelili (2. Derece) Karesel Üstel Düzeltme Yöntemi

Bu yöntem doğrusal eğilimden daha yüksek derecede eğilim gösteren seriler için kullanılır. Matematiksel olarak şöyle tanımlanır;

$$S'_t = \alpha Y_t + (1 - \alpha) S'_{t-1} \quad 9$$

$$S''_t = \alpha S'_t + (1 - \alpha) S''_{t-1} \quad 10$$

$$S'''_t = \alpha S''_t + (1 - \alpha) S'''_{t-1} \quad 11$$

$$\delta_t = 3S'_t - 3S''_t - S'''_{t-1} \quad 12$$

$$b_t = \alpha / 2(1 - \alpha)^2 (6 - 5\alpha) S'_t - (10 - 8\alpha) S''_t + (4 - 3\alpha) S'''_t \quad 13$$

$$C_t = \alpha^2 / (1 - \alpha)^2 (S'_t - 2S''_t + S'''_t) \quad 14$$

$$f_{t-1} = \delta_t + b_{t-1} + \frac{1}{2} C_{t-1}^2 \quad 15$$

Burada; S'_t basit, S''_t ikili ve S'''_t üçsel düzeltme değerleridir. 9 ve 10 numaralı denklem basit ve ikili üstel düzeltme yöntemidir. 11 numaralı denklem ise sisteme yeni eklenen üçlü üstel düzeltme yöntemidir. 12 numaralı denklem verinin t zamandaki düzeltilmiş değerini vermektedir. 13 numaralı denklem doğrusal eğilimi ve 14 numaralı denklem karesel (2. dereceden) eğilimin tahminini vermektedir. 15 numaralı denklem ise kestirim fonksiyonudur. Bu fonksiyon, kestirimde hem doğrusal hem de karesel eğilimi kullanmaktadır. Fonksiyonun son kestiriminin $\frac{1}{2}$ ile çarpılması türev kurallarından ileri gelmektedir.

Brown' un yöntemlerinin esası aynıdır. δ , b ve c modelin parametreleri olup, değerleri sistem tarafından belirlenir ve hata kareler ortalamasını minimum yapar. Karesel üstel düzeltme yöntemi diğer yöntemlere göre daha başarılı sonuç verir. Ancak serideki bu türlü değişmelere karşı çok hassastır. Bu yöntemde de α ' nın değeri deneme yanılma yoluyla belirlenmektedir.

2.1.5. Winters Mevsimsel Düzeltme Yöntemi

Diğer üstel düzeltme yöntemleri kestirim fonksiyonunda mevsimlik değişmelerin kestirim değerlerine etkisini yansıtacak bir parametre içermezler. Winters; Brown' un üstel düzeltme yöntemleriyle aynı ilkeye dayanan ve ilave olarak eğilim ve mevsimlik değişmeleri de modele dahil ederek düzeltme yöntemini daha doğru sonuçlar verecek hale getirmiştir.

İktisadi yaşamın işleyişinde, işletme yöneticilerinin çok sık karşılaştıkları sorunlardan biri de çok sayıda ürettikleri ürünler için kısa dönemli kestirim yapabilmektir. Çok sayıda üretilen ürünler için kısa dönemli kestirimler hazırlamak, bir yönetici için zorunluluktur. Örneğin, bir üretim hattındaki çeşitli ürünler için talep tahminlerine dayanan bir üretim programı yapmak durumunda olan işletme yöneticileri, geçmiş dönemlerde gerçekleşmiş verilere dayanan kısa dönemli kesin anlamlı öngörüler sağlayan ve çeşitli durumların her birine kolayca uygulanabilen yöntemlere ihtiyaç duyarlar. Winters' ın doğrusal ve mevsimsel üstel düzeltme yöntemi yeni veriler karşısında güncelleme kolaylığı olan üçlü bir üstel düzeltme yöntemlerinden biridir.

Bu yöntem Peter Winters tarafından 1960'lı yılların başlarında geliştirilmiş olup çifte üstel düzeltmeye benzer sonuçlar ortaya koymakla birlikte eğilim uyarlamasının yanında mevsimsel uyarlamayı da içerdiğinden, eğilim ve mevsimsel kalıbın bulunduğu bir veri setinin öngörülmesinde kullanılabilir.

Winters' ın doğrusal ve mevsimsel üstel düzeltme yöntemi, bir veri kalıbındaki parçalardan (Rassallık, Doğrusal ve Mevsimsel) her biri ile ilişkilendirilmiş bir parametreyi düzelten üç eşitliğe dayanmaktadır. Bu eşitlikler:

$$S_t = \alpha (X_t / I_t - L) + (1 - \alpha) (S_{t-1} + b_{t-1}) \quad 1$$

$$b_t = \gamma (S_t - S_{t-1}) + (1 - \gamma).b_{t-1} \quad 2$$

$$I_t = \beta (X_t / S_t) + (1 - \beta). I_{t-L} \quad 3$$

Şeklindedir.

Bu eşitliklerdeki α , γ ve β olarak tanımlanacak farklı üstel düzgünleştirme sabitleri içerirler.

α ; modelin düzgünleştirme sabiti,

γ ; eğilim düzgünleştirme sabiti,

β ; mevsim düzgünleştirme sabiti,⁸

⁸ E.Önder ve Ö.Hasgöl, **Box-Jenkins Modeli, Winters Yöntemi ve Yapay Sinir Ağlarıyla Zaman Serisi Analizi** s.65

Bu denklemlerde;

X_t ; mevsimsellikten arındırılmamış serilerdir.

S_t ; mevsimsellikten arındırılmış serilerin mevcut düzeyi

L ; mevsim uzunluğu (bir yıl içindeki ay veya mevsim sayısı),

I ; mevsim düzeltme faktörüdür.

Seriler; Mevsimsellikten arındırılmış serilerin mevcut düzeyi S_t olarak tanımlanmaktadır.

$$S_t = \alpha (X_t / I_{t-L}) + (1 - \alpha) (S_{t-1} + b_{t-1})$$

Birinci denklemde ilk terim mevsim indeksi I_{t-L} ' ye bölünmektedir. Bunun amacı, X_t ' deki mevsim etkisini ortadan kaldırmaktır. S_t ' yi 1' den büyük bir sayıya bölmek, gözlem değerini (X_t) t-L dönemi mevsim etkisi oranında küçültmektedir. Mevsim indeksi 1' den küçük olduğunda ise tam tersi bir durum ortaya çıkmaktadır. I_{t-L} ' nin kullanılma nedeni ise I_t ' nin henüz bilinmemesidir.

Eğilim; İkinci denklem eğilimin düzgünleştirilmesi için kullanılmaktadır. basit olarak, artan eğilim ($S_t - S_{t-1}$) γ ile, önceki eğilim değeri ($1 - \gamma$). b_{t-1} ile ağırlıklandırıldığı için düzeltilmiş eğilimdir.

$$b_t = \gamma (S_t - S_{t-1}) + (1 - \gamma).b_{t-1}$$

Mevsimsel faktörler; En son talep gözleminin mevsimsellikten arındırılmış talebin son tahminine bölümü, mevsimsel faktörün güncel tahminini verir. Bu daha sonra önceki t-L mevsimsel faktör ile ağırlıklandırılır. Her bir mevsimsel faktör güncellendikçe, en son L faktörün toplamının L' yi verecek şekilde düzenlenmesi gereklidir.

X_t , S_t ' den büyükse indeks 1' den büyük, aksi halde 1' den küçük çıkacaktır. X_t değerleri mevsimin etkisini ve rassal etkiyi taşıırken S_t değerleri serinin düzgünleştirilmiş değerleri olduğu için mevsimin etkisini taşımazlar.

$$I_t = \beta (X_t / S_t) + (1 - \beta) \cdot I_{t-L}$$

Bu hesaplamalarda I_t , S_t bilinene kadar hesaplanamadığı için I_{t-L} değeri kullanılır.

X_t ; mevsimsellikten arındırılmamış serilerdir.

S_t ; mevsimsellikten arındırılmış serilerin mevcut düzeyi

L ; mevsim uzunluğu (bir yıl içindeki ay veya mevsim sayısı),

I ; mevsim düzeltme faktörüdür.

Winters yöntemi ile tahmin şu şekilde yapılır.

$$S_{t+m} = (S_t + b_{tm}) I_t = L + m$$

Winters yönteminin uygulanmasındaki sorunlardan biri, hata kareleri ortalamasını minimize edecek şekilde belirlenmesidir. Bunun yapılmasında tek yaklaşım, deneme ve yanılma yöntemidir. En iyi değerlerin araştırılması, hata kareleri ortalamasını azaltan değer, değişme yönünden her parametrenin belirlenmesiyle yapılır. Parametre değerleri, hata kareleri ortalamasını minimum yapacak değer setini bulmak için artan bir şekilde değiştirilerek en uygun değerler bulunmaya çalışılır.

2.2. Box – Jenkins Yöntemleri

Zaman serisi verileri ile oluşturulan modellerin Box - Jenkins kestirim yöntemleri aşağıda belirtilen şekilde açıklanmaktadır.

2.2.1. Otoregrasif Süreç (AR) İle Kestirim

Otoregrasif Süreç (AR) ile elde edilen kestirimler oluşturulan modelin örneklem dönemi dışına uzatılması ile elde edilmektedir. Aşağıda bu süreçler belirtilmektedir.

2.2.1.1. AR (1) Yöntemi

AR (1) yöntemi aşağıdaki gibi tanımlanır.

$$Y_t = m + \alpha Y_{t-1} + \varepsilon_t$$

Zaman serisinin model kalıbı belirlendikten sonra gelecek dönemler için kestirim doğrudan yapılabilir. Ancak modelin geçerli koşulu sağlaması şartı aranmaktadır. Bu hata teriminin beyaz gürültü koşulunu sağladığı $\varepsilon_t \sim \text{iid}(0, \sigma^2)$ sabit varyans ve beklenen değerinin 0 kabul edilmesi yani belirlenen modelin bir dönem sonrası için kestirim hata teriminin beklenen değeri sıfır kabul edilmesidir.

$$\hat{Y}_{t+1} = m + \alpha_1 \hat{Y}_t + \varepsilon_{t+1}$$

Tahmin edilen parametre değerleri hata kareler toplamını minimum yapacak düzeyde belirlenmesidir. Kestirilen modelin hata terimi ε_{t+1} , kestirilen dönemler için bilinmediğinden $E[\varepsilon_{t+1}] = 0$ varsayımına dayandırılarak tüm dönemlerde hata sıfır kabul edilir.

2.2.1.2. AR (P) Yöntemi

$$Y_t = m + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t$$

AR (P) sürecinin bir dönem sonrası kestirim değeri aşağıdaki gibi oluşmaktadır.

$$\hat{Y}_{t+1} = m + \alpha_1 \hat{Y}_t + \alpha_2 \hat{Y}_{t-2} + \alpha_p \hat{Y}_{t-p} + \varepsilon_{t+1}$$

Burada \hat{Y}_{t+1} kestirilen talep serisidir, ε_{t+1} kestirim hatasıdır. Kestirim hatasının beklenen değeri ($E[\varepsilon_{t+1}] = 0$) sıfırdır.

Bir zaman serisinin kestirimi yapılırken bağımlı değişkenin gecikmeli değerlerinin doğrusal birleşimi kullanılarak (otoregresif süreç AR) tanımlaması yeterli olmayabilir. Bundan dolayı serinin hareketli ortalama süreci ile kestirimi yapılacaktır.

2.2.2. Hareketli Ortalama (MA) İle Kestirim

Hareketli ortalama modelleri Y_t serisinin kestirimini geçmiş hataların doğrusal birleşimi olarak ele alır.

2.2.2.1. MA (1) Yöntemi

MA (1) Yöntemi aşağıdaki gibi tanımlanır.

$$Y_t = m + \varepsilon_t + \alpha_1 \varepsilon_{t-1}$$

Burada

Y_t ; talep serisi,

m, α_1 ; regresyon katsayıları,

ε_t ; model tarafından açıklanamayan ve $\varepsilon_t \sim \text{iid} (0, \sigma^2 \varepsilon)$ özelliğine sahip hata terimi,⁹

$\varepsilon_t \sim \text{iid} (0, \sigma^2 \varepsilon)$; ortalaması sıfır ve sabit varyansla bağımsız (korelasyonsuz) hata terimleri.

ε_{t-1} ; hata teriminin gecikmeli değeridir.

MA (1)' in bir dönem sonrası için kestirimi aşağıdaki gibi belirlenir.

$$\hat{Y}_{t+1} = m + \hat{\varepsilon}_{t+1} + \alpha_1 \hat{\varepsilon}_t + 1$$

Eğer değişkenin gerçekleşmiş değeri varsa, gerçekleşen değerden kestirilen değer çıkarılarak kestirim hatası bulunur. Ancak değişkenin gerçekleşen değerleri yok ise, bu durumda modelde yer alan tüm geçmiş hatalar sıfır varsayılır.

⁹ A.C Harvey, **Time Series Models**, New York, Prentice Hall, 1993, s.23

2.2.2.2. MA (q) Yöntemi

MA (q) Yöntemi aşağıdaki gibi tanımlanır.

$$Y_t = m + \varepsilon_t + \alpha_1 \varepsilon_{t-1} + \alpha_2 \varepsilon_{t-2} + \dots + \alpha_q \varepsilon_{t-q}$$

Burada

Y_t ; talep serisi,

m, α_1, α_2 ; regresyon eğilim katsayıları,

ε_t ; model tarafından açıklanamayan ve sabit varyans beklenen değeri 0,
 $\varepsilon_t \sim \text{iid}(0, \sigma^2 \varepsilon)$ özelliğine sahip hata terimi,

$\varepsilon_{t-1}, \varepsilon_{t-2}, \varepsilon_{t-q}$; hata teriminin gecikmeli değeridir.

MA (q) sürecinde bir dönem sonrası için kestirimi aşağıdaki gibi tanımlanır.

$$\hat{Y}_{t+1} = m + \hat{\varepsilon}_{T+1} + \alpha_1 \hat{\varepsilon}_T + \alpha_2 \hat{\varepsilon}_{t-1} + \dots + \alpha_q \hat{\varepsilon}_{t-q} + 1$$

Eğer değişkenin gerçekleşen değerleri varsa, kestirimde yer alan hata teriminin değeri kullanılır, yok ise hata teriminin tüm değerleri sıfır kabul edilir.

2.2.3. Otoregresif Hareketli Ortalama Süreci (ARMA) İle Kestirim

Zaman serileri için oluşturulacak modelin bağımlı değişkeninin, geçmiş değerlerinin ve geçmiş dönem hatalarının doğrusal birleşimi olarak ele alınması ile oluşturulmasıdır.

2.2.3.1. ARMA (1, 1) Yöntemi

ARMA (1, 1) Yöntemi aşağıdaki gibi tanımlanır.

$$Y_t = m + \alpha_1 Y_{t-1} + \beta_1 \varepsilon_{t-1}$$

Burada,

Y_t ; talep serisi,

Y_{t-1} ; açıklayıcı değişkenler,

m, α_1, β_1 ; regresyon katsayıları,

ε_t ; model tarafından açıklanamayan ve $\varepsilon_t \sim iid(0, \sigma^2 \varepsilon)$ özelliğine sahip hata terimi,

ε_{t-1} ; hata teriminin gecikmeli değeridir.

ARMA (1,1) modelinin bir dönem sonrası için kestirimi aşağıdaki gibi tanımlanır.

$$\hat{Y}_{t+1} = m + \alpha_1 \hat{Y}_t + \varepsilon_{t+1} + \beta_1 \hat{\varepsilon}_t$$

Kestirim hatası gerçekleşen değerlerden kestirilen değerlerin farkı alınarak elde edilir. Eğer kestirilen değer yok ise, hata da sıfır kabul edilir.

2.2.3.2. ARMA (p, q) Yöntemi

ARMA (p, q) Yöntemi aşağıdaki gibi tanımlanır.

$$Y_t = m + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \varepsilon_t + \beta_1 \varepsilon_{t-1} + \beta_2 \varepsilon_{t-2} + \dots + \beta_q \varepsilon_{t-q}$$

Burada

Y_t ; talep serisi,

$Y_{t-1}, Y_{t-2}, Y_{t-q}$; açıklanan bağımlı değişkenin önceki dönem değerleri,

$m, \alpha_1, \alpha_2, \alpha_p, \beta_1, \beta_2, \beta_q$; regresyon eğilim katsayıları,

ε_t ; model tarafından açıklanamayan ve sabit varyans beklenen değeri 0, $\varepsilon_t \sim iid(0, \sigma^2 \varepsilon)$ özelliğine sahip hata terimi,

$\varepsilon_{t-1}, \varepsilon_{t-2}, \varepsilon_{t-q}$; hata teriminin gecikmeli değeridir.

ARMA (p,q) yönteminin bir dönem sonrası için kestirimi aşağıdaki gibi tanımlanır.

$$\hat{Y}_t = m + \alpha_1 \hat{Y}_t + \alpha_2 \hat{Y}_{t-1} + \dots + \alpha_p \hat{Y}_{t-p+1} + \varepsilon_{t+1} + \beta_1 \hat{\varepsilon}_t + \beta_2 \hat{\varepsilon}_{t-1} + \dots + \beta_q \hat{\varepsilon}_{t-q+1}$$

Yukarıdaki model kesitleri durağan süreç serileri için geçerlidir. Durağan dışı durum söz konusu ise model durağanlaştırılarak kestirim yapılır.

2.2.4. ARIMA Yöntemi İle Kestirim

Durağan olmayan zaman serisi modellerinin, durağanlaştırma işlemi ile bir arada kestiriminin yapılması işlemidir.

AR ve MA işlemi daha önceki çalışma ile aynıdır. I durağanlaştırma için yapılan gecikme işlemcisini gösterir, gecikme operatörüdür.

2.2.4.1. ARIMA (1, 1, 1) Yöntemi

ARIMA (1, 1, 1) Yöntemi gecikme operatörü ile aşağıdaki gibi tanımlanır.

$$(1 - \alpha_{1L})(1 - L) Y_t = m + (1 - \beta_{1L}) \varepsilon_t$$

açılımı yapılırsa

$$Y_t = m + Y_{t-1} + \alpha_1 (Y_{t-1} - Y_{t-2}) + \varepsilon_t + \beta_1 \varepsilon_{t+1}$$

ARIMA (1, 1, 1) yönteminin bir dönem sonrası için kestirimi aşağıdaki gibi tanımlanır.

$$\hat{Y}_{t+1} = m + \hat{Y}_t + \alpha_1 (\hat{Y}_t - \hat{Y}_{t-1}) + \varepsilon_{t+1} + \beta_1 \varepsilon_t$$

L; mevsim uzunluğu (bir yıl içindeki ay veya mevsim sayısı),

I; mevsim düzeltme faktörüdür.

2.2.4.2. ARIMA (p, d, q) Yöntemi

ARIMA (p, d, q) Yöntemi aşağıdaki gibi tanımlanır.

$$(1 - \alpha_{1L} - \alpha_{2L} - \dots - \alpha_{pL})(1 - L)^d Y_t = m + (1 + \beta_{1L} + \beta_{2L} + \dots + \beta_{qL}) \varepsilon_t$$
$$\alpha(L)(1 - L)^d Y_t = m + \beta(L) \varepsilon_t$$

Burada,

$$\alpha(L) = 1 - \sum_{i=1}^p \alpha_i L^i \quad i=1 \quad \}$$

$$\beta(L) = 1 + \sum_{c=1}^q \beta_c L^c \quad i=1 \quad \} \quad \text{tüm bu formüller sürecin derecesini göstermek}$$

$$(1-L)^d \quad \} \quad \text{için kullanılır.}$$

$d=1$ ise, serinin bir defa farkı alınarak durağanlaştırıldığını gösterir.

$d=2$ ise, iki defa fark işlemi alınmıştır.

ARIMA (p, d, q) yönteminin bir dönem sonrası için kestirimi aşağıdaki gibi tanımlanır.

$$\alpha(L) (1-L)^d \hat{Y}_{t+1} = m + \beta(L) \hat{\varepsilon}_{t+1}$$

$$(1-L) \hat{Y}_{t+1} = m + (1-L) (\alpha_1 \hat{Y}_t + \alpha_2 \hat{Y}_{t-1} + \dots + \alpha_p \hat{Y}_{t-p+1}) + \hat{\varepsilon}_{t+1} + \beta_1 \hat{\varepsilon}_t + \beta_2 \hat{\varepsilon}_{t-1} + \dots + \beta_q \hat{\varepsilon}_{t-q+1}$$

Kestirim hata varyansı hesaplanıp güven aralıkları oluşturulmalıdır. Kestirim hata varyansı örneklemden elde edildiği için örneklem kestirim varyansı da denilir ve aşağıdaki gibi hesaplanır.

$$s^2_f = s^2 \left[1 + 1/T + (F_t - \bar{F}) / \sum_{t=1}^T F_t^2 \right]$$

s^2_f ; örneklemden elde edilen kestirim varyansı

s^2 ; örneklemden elde edilen hata varyansı

F_t ; önraporlama değeri

\bar{F} ; önraporlama ortalaması

2.3. Yapay Sinir Ağları Yöntemi

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgi türetebilme, yeni bilgi oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan doğrudan gerçekleştirmek amacı ile geliştirilen algoritmalarıdır. En kısa ve basit şekilde, bir örnekler kümesi yardımıyla parametrelerin uygulanabilmesini sağlayacak bir matematiksel formül için yazılan bilgisayar programı olarak tanımlanabilir.¹⁰

Yapay sinir ağları ile ilgili çalışmalar 20. yüzyılın ilk yarısında başlamış ve günümüze kadar büyük bir hızla devam etmiştir. Bu çalışmaları 1970 öncesi ve sonrası diye iki kısma ayırmak mümkündür. Zira 1970 yılları yapay sinir ağları için bir dönüm noktasını teşkil etmiş daha önce aşılması imkansız görünen pek çok problem bu dönemlerde aşılmıştır. İlk yapay sinir ağı modeli 1943 yılında, bir sinir hekimi olan Warren McCulloch ile bir matematikçi olan Walter Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağı modellemiştir. Bu tarihten günümüze kadar sayısız uygulama ve çalışma geliştirilmiştir.¹¹

Yapay sinir ağlarının gerçek hayattaki yaygın uygulama alanlarına şu örnekler verilebilir;

Üretim Planlama
Kimya Mühendisliği
İnşaat ve Yapı Mühendisliği
Finansal Öngörü
Elektrik ve Elektronik Mühendisliği
İmalat ve Makine Mühendisliği
Kredi Derecelendirme
İşlem Modelleme ve Yönetimi
Haberleşme Sanayi
Tıp Alanındaki Araştırmalar
Savunma Sanayinde

¹⁰ E.Öztemel, **Yapay Sinir Ağları**, İstanbul 2003 s.29

¹¹ Ç.Elmas, **Yapay Sinir Ağları Kuram, Mimari, Eğitim, Uygulama**, Ankara 2003 s.27-28

Yapay sinir ağlarının işleyişini yönlendiren bileşenler genel olarak aşağıda verilmiştir.

En basit hali ile çok tabakalı ileri beslemeli bir yapay sinir ağı mimari yapısı üç kısımdan oluşur. Bunlar girdi tabakası, gizli tabaka (ya da tabakalar) ve çıktı tabakasıdır. Tabakalar, nöron (düğüm) adı verilen birimlerden oluşmaktadır. Mimarinin tam olarak belirlenmesi tabakalardaki nöron sayısına karar verilmesi ile gerçekleşir. Yapay sinir ağlarında nöronlar birbirlerine ağırlıklar ile bağlıdır. İleri beslemeli ağlarda bu bağlantılar tek yönlü ve ileri doğrudur. Aynı tabakanın birimleri arasında bağlantı yoktur.

Zaman serilerinin gelecek kestiriminde en yaygın kullanılan türü üç tabakalı ileri beslemeli sinir ağıdır. Tek değişkenli zaman serileri için ağın girdileri geçmiş veya gecikmeli değişkenler, çıktısı ise kestirim değeridir. Kestirim problemi için yapay sinir ağı eğrisel otoregresif modele denktir. Girdi tabakasındaki nöronlardan gizli tabakayı atlayarak doğrudan çıktı tabakasına bağlantı yapılması ile elde edilecek yeni yapay sinir ağı modeli ise eğrisel ve doğrusal iki otoregresif modelin toplamına eşit olur.

Yapay sinir ağlarında ağırlıkların belirlenmesinde kullanılan birçok öğrenme algoritması vardır. En yaygın kullanılan öğrenme algoritmalarından biri geri yayılım algoritmasıdır. Geri yayılım algoritması eldeki veri ile ağın çıktısı arasındaki farka dayalı olarak ağırlıkların güncellenmesini gerçekleştirir. Geri yayılım algoritmasında kullanılan öğrenme parametresi optimal sonuca yeterli derecede yaklaşılmasında önemli rol oynar. Öğrenme parametresi sabit olarak alınabileceği gibi, algoritma içinde dinamik olarak da güncellenebilir.¹²

Aktivasyon fonksiyonu girdi ve çıktı birimleri arasındaki doğrusal olmayan eşleşmeyi sağlar. Aktivasyon fonksiyonunun doğru seçilmesi, ağın performansını önemli derecede etkiler. Aktivasyon fonksiyonu genelde tek kutuplu, çift kutuplu ya da doğrusal olarak seçilebilir. Seçilen aktivasyon fonksiyonu doğrusal olmadığında, eğitim parametresinin belirlenmesi gerekmektedir. Eğitim parametresi de en uygun sonuca yeterli derecede yaklaşılmasında önemli rol oynayan bir faktördür.

¹² Ç. Aladağ, **Zaman Serilerinde Öngörü s.2**

Yapay sinir ađları ařađıdaki zellikleri nedeniyle etkin ve geniř uygulama alanları bulmuřtur;

Yapay sinir ađları hem dođrusal hem de dođrusal olmayan yapıyı ğrenebilme yeteneđine sahiptir. Bu nedenle yapay sinir ađları diđer modelleme yntemlerine gre daha iyi kestirim sonuları vermektedir. Yapıları geređi ekonomik verilerin dođrusal olmayan bir yapıda olmaları normaldir. Genellikle tahmin zorlukları nedeniyle analizler dođrusal yntemlerle gerekleřtirilmektedir. Dolayısıyla dođrusal olmayan yapı iermesi durumunda yanlıř sonular elde edilmektedir; ya da en azından analizi yapılan sistemde aıklanamayan bileřenler kalabilmektedir. Sonu olarak, analiz konusunun ierdiđi veri setinin dođrusal veya dođrusal olmayan yapı ieriyor olması, analiz sonularını etkileyecek nemli bir faktrdr. Bu yzden, dođrusal olmayan yapıları da dikkate alabilmesi yapay sinir ađlarının nemli bir zelliđidir.

Yapay sinir ađlarının ğrenme zelliđi: Esin kaynađı insan beyninin alıřma sistemi olan bu yntem, eđitme veya bařlangı tecrbesi sayesinde veriyi kullanarak ğrenme yeteneđine sahiptir. Bu zelliđi sayesinde yapay sinir ađları geleneksel teknikler iin ok karmařık olan problemlere zm retebilmektedir. Ayrıca, insanların kolayca yapabildiđi ama geleneksel metotların uygulanamadıđı basit iřlemler iin de olduka uygundurlar.

Yapay sinir ađlarının gerek zamanlı iřlem yapabilme zelliđi: Yapay sinir ađları hesaplamaları paralel olarak yrtlebildiđinden gerek zamanlı iřlem yapabilir.

Yapay sinir ađlarının genelleme zelliđi: ğrenme yeteneđi sayesinde bilinen rnekleri kullanarak daha nce karřılařılmamıř durumlarda genelleme yapabilmektedir. Yani, hatalı veya kayıp veriler iin zm retebilmektedir. Yapay sinir ađları tanımlanmamıř girdi veriler hakkında karar verirken genelleme yapabildikleri iin iyi birer gidiřat tanımlayıcısı ve sađlam sınıflandırıcılardır.

Yapay sinir ağlarının hafıza özelliği: Bunlara ek olarak, işlem elemanları arasındaki ağırlıklı bağlantılar sayesinde dağıtılmış hafızada bilgi saklayabildikleri söylenebilir.

Yapay sinir ağlarının kendi ilişkisini oluşturma özelliği: Yapay sinir ağları, verilere göre kendi ilişkilerini oluştururlar, denklem içermezler.

Yapay sinir ağlarının sınırsız sayıda değişken ve parametre özelliği: Yapay sinir ağları modelleri sınırsız sayıda değişken ve parametre ile çalışabilmektedir. Bu sayede mükemmel bir kestirim doğruluğu ile genel çözümler sağlanabilmektedir.

Yapay sinir ağlarının yerel işlem ve esneklik özelliği: Yapay sinir ağları geleneksel işlemcilerden farklı şekilde işlem yapmaktadırlar. Geleneksel işlemcilerde, tek bir merkezi işlem elemanı her hareketi sırasıyla gerçekleştirir. Yapay sinir ağları modelleri, her biri büyük bir problemin bir parçası ile ilgilenen çok sayıda basit işlem elemanlarından oluşma ve bağlantı ağırlıklarının ayarlanabilmesi gibi özelliklerinden dolayı önemli derecede esnek bir yapıya sahiptirler. Bu esnek yapı sayesinde ağırlık kısmının zarar görmesi modelde sadece performans düşüklüğü yaratır. Modelin işlevini tamamen yitirmesi söz konusu olmaz. Ayrıca, toplam işlem yükünü paylaşan işlem elemanlarının birbirleri arasındaki yoğun bağlantı yapısı sinirsel hesaplamanın temel güç kaynağıdır. Bu yerel işlem yapısı sayesinde, yapay sinir ağları yöntemi en karmaşık problemlere bile uygulanabilmekte ve tatminkar çözümler sağlayabilmektedir.

Bununla birlikte, Yapay sinir ağlarının kullanımında göz önünde bulundurulması gereken bazı dezavantajlar da bulunmaktadır. Bunlar arasında en önemlisi geniş veri seti gereksinimidir. Sinir ağlarının eğitilebilmesine ve test edilebilmesine yetecek genişlikte veri setine ihtiyaç duyulmaktadır. Yine de, yeterli veri seti genişliği için kesin bir kıstas yoktur, bir noktada uygulamaya bağlıdır. Dezavantaj sayılabilecek diğer bir nokta ise basit olarak görülebilecek modelleme yapılarına rağmen uygulamanın zor ve karmaşık olabilmesidir. Bazı durumlarda, bir yakınsama sağlamak

bile olanaksız olabilmektedir fakat bu durum da uygulama alanına bağlıdır ve genellikle çok karmaşık problemlerde ortaya çıkmaktadır.¹³

Karmaşık veya sorunlu veriden bile anlam çıkarabilmek gibi dikkate değer yetenekleriyle yapay sinir ağları insanlar veya bilgisayarlar tarafından anlaşılması zor eğimleri belirlemek veya yapıları çıkartmak için kullanılabilirler. Tam eğitilmiş bir yapay sinir ağı modeli, analiz ettiği bilgi kümesi (veri tabanı) için uzman olarak düşünülebilir.

2.3.1. Yapay Sinir Ağları Araştırma Metodu

Aylık satış verilerinin tahmin edilmesi amacı güden çalışmamızda metal sektöründe faaliyet gösteren bir firmanın aylık satış verileri ana veri olarak kullanılmıştır. Veri seti, ilgili aylık satış verilerinin 1 Ocak 2005 ile 31 Aralık 2009 tarihleri arasındaki aylık veriler kullanılarak oluşturulmuştur.

Satış verilerinin aylık değerlerinin logaritmik farkı alınarak çalışma yapılmıştır. Hesaplama yönteminin logaritmik fark alınma süreci aşağıdaki formülde gösterilmiştir.

$$Y_t = \ln(Y_t / Y_{t-1})$$

Bu formülde Y_t , t zamandaki aylık talebi, Y_{t-1} ise ilgili satış değerlerinin t ve t-1 ayındaki değerlerini ifade etmektedir.

Satış talebinin hesaplanmasını takiben yapay sinir ağı modellerinin farklı satış dönemlerindeki performanslarını ortaya koymak açısından veri seti 5 alt döneme ayrılmıştır. Her alt dönem 1 Ocak itibariyle başlayıp 31 Aralık tarihi itibariyle bitecek şekilde, birer yıllık veri içermektedir. Birer yıllık analiz dönemlerinin seçilmesinin nedeni yapay sinir ağı modellerinin uzun dönemli analizlerde etkinliğinin kısıtlı olması ve aylık verilerin kullanıldığı analizlerde en fazla on yıllık verilerin kullanılmasına yönelik daha önceki çalışmalarda tespitlerdir. Oluşturulan modellerin eğitilmesi, doğrulanması ve test edilmesi amacı ile her bir

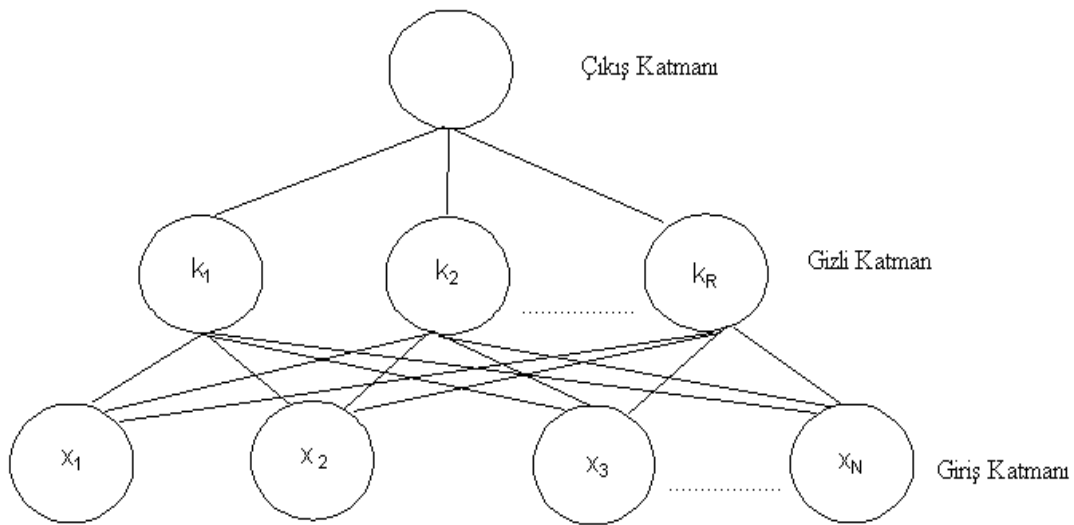
¹³ H.Yurtoğlu, **Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi**, Ankara 2005 s.9

veri seti 3 kısma bölünmüştür. Bu bağlamda veri setlerinde yer alan satış verilerinin ilk %70' lik kısmı modelin eğitilmesinde, geri kalan %20' lik kısmı doğrulamada ve son olarak %10' luk kısmı da modelin test edilmesi için kullanılmıştır. Bağımsız değişkenler aşağıdaki gibi tanımlanmıştır.

- Bir aylık gecikmeli satış verileri
- Altı aylık gecikmeli satış verileri
- On iki aylık gecikmeli satış verileri
- Satış verilerinin altı aylık hareketli ortalaması
- Satış verilerinin on iki aylık hareketli ortalaması

Aylık satış kestiriminde 5 değişken kullanılmıştır. Çalışmada kullanılan değişkenler gecikmeli satış verileri ve bu satış verilerinin hareketli ortalamalarıdır. Bu değişkenlerin seçilmesinin temel nedeni yakın dönemdeki satış verilerinin gelecek kestiriminde kullanılabilirliğini ölçmektir.

Yapay sinir ağı modelleri incelendiğinde geri yayılım algoritması ile çalıştırılan ileri beslemeli yapay sinir ağı modelleri finansal uygulamalarda en çok kullanılan yöntemdir. Bu model aynı zamanda çok katmanlı yapay sinir ağı modeli olarak da adlandırılır.



Söz konusu yapay sinir ağı modeli yukarıdaki şekilde basitleştirilmiş olarak gösterilmektedir. Model birbirine bağlı 3 katmandan oluşmaktadır. Bu katmanlardan birincisi verilerin modele sunulduğu giriş katmanıdır. Giriş katmanında N tane x_i ($i= 1, 2, 3, \dots, N$) bağımsız değişkeni bulunmaktadır. Giriş katmanı çeşitli ağırlıklarla ikinci katmana, gizli katmana bağlıdır. Yukarıdaki şekilde bir tane gizli katman gösterilmekle beraber, gizli katman sayısı birden fazla olabilir. Gizli katmanda R tane k_m ($m=1, 2, 3, \dots, R$) gizli işlem elemanı bulunmaktadır. Gizli katmanda çeşitli ağırlıklarla son katman olan çıktı katmanına bağlıdır. Çıktı katmanındaki eleman sayısı da birden fazla olabilmektedir. Modelin nihai çıktıları aşağıdaki formülde verilen denklem kullanılmak sureti ile elde edilir.

$$y = g \left[\sum_{m=0}^R W_{mdg} \left(\sum_{t=0}^N W_{tm} X_i \right) \right]^f$$

Bu formülde y modelin çıktısını veya kestirim değerini, wtm girdi katmanı ile gizli katman arasındaki bağlantıların ağırlığını, wmd gizli katman ile çıktı katmanı arasındaki bağlantıların ağırlığını, g(.) gizli katmanda kullanılan aktivasyon fonksiyonunu, g(.)^f ise çıktı katmanında kullanılan aktivasyon fonksiyonunu ifade etmektedir. Bu çalışmada bir giriş bir gizli birde çıktı katmanlı olan üç katmanlı ileri beslemeli yapay sinir ağı modeli kullanılmıştır. Üç katmanlı ileri beslemeli yapay sinir ağları modellerinin kullanılmasının temel sebebi, bu modellerde gizli katmanda doğrusal olmayan bir aktivasyon fonksiyonu ile yeterli sayıda işlem elemanı bulunur ise her türlü sürekli fonksiyonun kestiriminin elde edilebileceğinin matematiksel olarak daha önceki çalışmalarda kanıtlanmış olmasıdır.

Gizli katmanda kullanılan işlem elemanları sayısının gereğinden fazla olması durumunda modelin eğitim için kullanılan veri setinin yapısını aşırı öğrenmesi söz konusu olmakta ve bunun sonucunda test verisinin başarı düzeyinin düşük kalmasına sebep olmaktadır. Bu problemi aşmak için üç farklı yapıya sahip geriye beslemeli yapay sinir ağı modeli kullanılabilir.

2.3.2. Yapay Sinir Ağları Kestirim Sonuçlarının Değerlendirme Kriterleri

Yapay sinir ağı modelinin kestirim gücünü ölçmede; ortalama hata kareleri (MSE), normalleştirilmiş ortalama hata kareleri (NMSE), ortalama mutlak hata (MAE) ve trend doğruluğu (TA) kriterleri kullanılabilir. Trend doğruluğu (TA) kriteri yapay sinir ağı modelinin yönünü (yükseliş ya da düşüş) tahmin etmekteki yüzdesel başarısını gösterir.

Bu istatistiksel performans kriterleri modellerin istatistiksel dođruluđu hakkında bilgi vermektedir. Ancak modellerin kararlılıđı hakkında bilgi vermemektedir.


ÜÇÜNCÜ BÖLÜM
UYGULAMA VE SONUÇLAR

ÜÇÜNCÜ BÖLÜM

UYGULAMA VE SONUÇLAR

Bu çalışmada metal sektöründe raf imalatı yapan küçük ölçekli bir firmanın aylık satış verileri kullanılmıştır. 1 Ocak 2005 – 31 Aralık 2009 tarihleri arasındaki 60 aylık satış verileri TL cinsinden dikkate alınmıştır.

3.1. Formel Olmayan Grafikselsel Test



Şekil 1: Aylık Satış Verileri Grafiği

Şekil 1 incelendiğinde, satış serisi grafiğinin zaman boyunca yukarı doğru bir eğilim gösterdiği, dolayısı ile serinin ortalamada durağan olmadığı konusunda bir sinyal vermektedir. Seriyeye ilişkin otokorelasyon ve kısmi otokorelasyonları gösteren korelogram da durağan dışılık sinyali vermektedir. Ancak sadece grafikselsel yöntemle buna karar vermek doğru olmayacağından durağanlığı test etmek için birim kök testleri de yapılmıştır.

3.2. Birim Kök Test Sonuçları

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.477	0.477	14.368	0.000
		2	0.447	0.284	27.209	0.000
		3	0.488	0.281	42.738	0.000
		4	0.360	0.021	51.340	0.000
		5	0.412	0.148	62.811	0.000
		6	0.510	0.267	80.760	0.000
		7	0.353	-0.032	89.488	0.000
		8	0.229	-0.221	93.242	0.000
		9	0.285	-0.021	99.168	0.000
		10	0.193	-0.044	101.93	0.000
		11	0.198	-0.014	104.92	0.000
		12	0.356	0.200	114.72	0.000
		13	0.140	-0.122	116.27	0.000
		14	0.041	-0.179	116.41	0.000
		15	0.078	-0.074	116.91	0.000
		16	-0.093	-0.214	117.65	0.000
		17	-0.065	-0.107	118.02	0.000
		18	0.096	0.153	118.83	0.000
		19	-0.049	0.053	119.05	0.000
		20	-0.078	0.094	119.61	0.000
		21	-0.035	0.072	119.73	0.000
		22	-0.065	0.140	120.14	0.000
		23	-0.037	0.084	120.28	0.000
		24	0.002	-0.162	120.28	0.000
		25	-0.024	-0.016	120.34	0.000
		26	-0.067	0.043	120.83	0.000
		27	-0.001	0.065	120.83	0.000
		28	-0.051	0.072	121.14	0.000

Şekil 2: Satış Verilerinin Korelogramı

Null Hypothesis: SER01 has a unit root

Exogenous: Constant

Lag Length: 5 (Automatic based on AIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.783648	0.8156
Test critical values: 1% level	-3.557472	
5% level	-2.916566	
10% level	-2.596116	

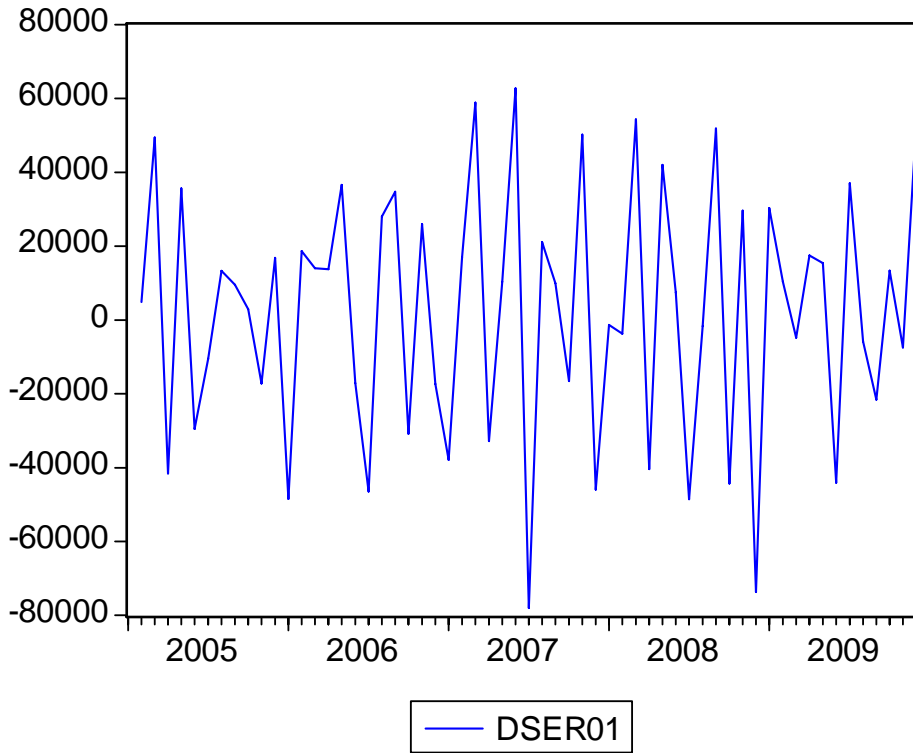
Yukarıda durağanlığı test etmek için yapılan ADF testi sonuçları görülmektedir. Bu sonuçlara göre seride birim kök olduğu yani serinin durağan olmadığını ifade eden sıfır

hipotezi reddedilememektedir. Yani seri durağan değildir. Serinin birinci farkı alındıktan sonra tekrar ADF yapıldığında aşağıdaki sonuç çıkmıştır. (Seri durağandır)

Null Hypothesis: D(SER01) has a unit root
Exogenous: Constant
Lag Length: 4 (Automatic based on AIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-6.680903	0.0000
Test critical values: 1% level	-3.557472	
5% level	-2.916566	
10% level	-2.596116	

Aşağıdaki şekil 3' de farkı alınmış serinin grafiği de durağanlığı gösteriyor.



Şekil 3: Farkı Alınmış Serinin Grafiği

3.3. Üstel Düzeltme Yöntemleri ve Sonuçları

3.3.1. Holt Winters

Date: 04/15/10 Time: 13:20
Sample: 2005M01 2009M12
Included observations: 60
Method: Holt-Winters No Seasonal
Original Series: SER01
Forecast Series: SER01SM

Parameters:	Alpha	0.1000
	Beta	0.0000
	Sum of Squared Residuals	3.80E+10
	Root Mean Squared Error	25170.56

End of Period Levels:	Mean	150131.4
	Trend	1511.433

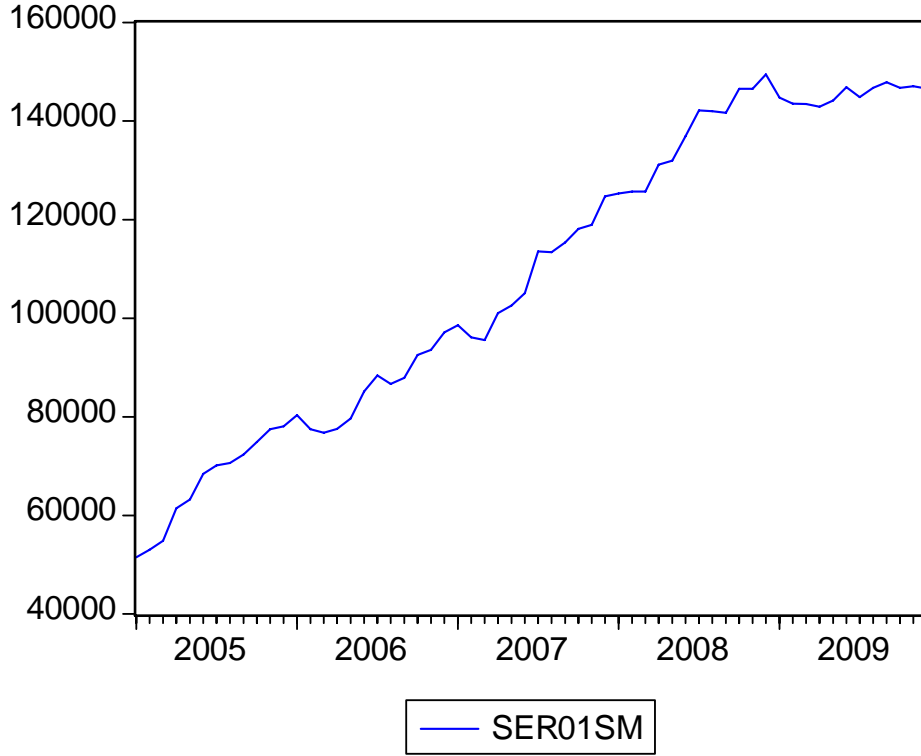
Mevsim faktörleri olarak, mevsimsel ayrıştırma işlemi ile elde edilen mevsim indeks değerleri kullanılmıştır. Modelin düzeltme sabiti α , trend düzeltme sabiti β ve mevsim düzeltme sabiti olan γ parametreleri, modelin hata karelerinin toplamını minimum yapacak şekilde belirlenmiştir. Elde edilen;

$$\alpha = 0.1000$$

$$\beta = 0.0000$$

$$\gamma = 0.0000$$

parametre değerleri modelin düzeltme katsayıları olarak kullanılmıştır.

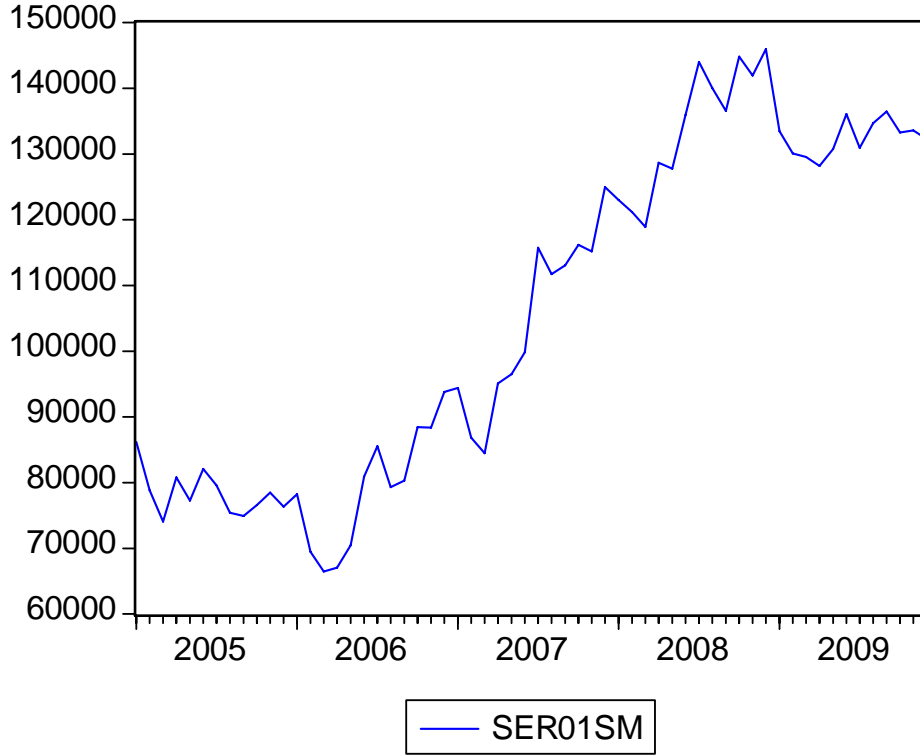


Şekil 4: Holt - Winters Mevsimsel Düzeltme Grafiği

3.3.2 Basit Ortalama

Date: 04/15/10 Time: 13:23
Sample: 2005M01 2009M12
Included observations: 60
Method: Single Exponential
Original Series: SER01
Forecast Series: SER01SM

Parameters: Alpha	0.2120
Sum of Squared Residuals	4.14E+10
Root Mean Squared Error	26253.98
End of Period Levels: Mean	142788.2

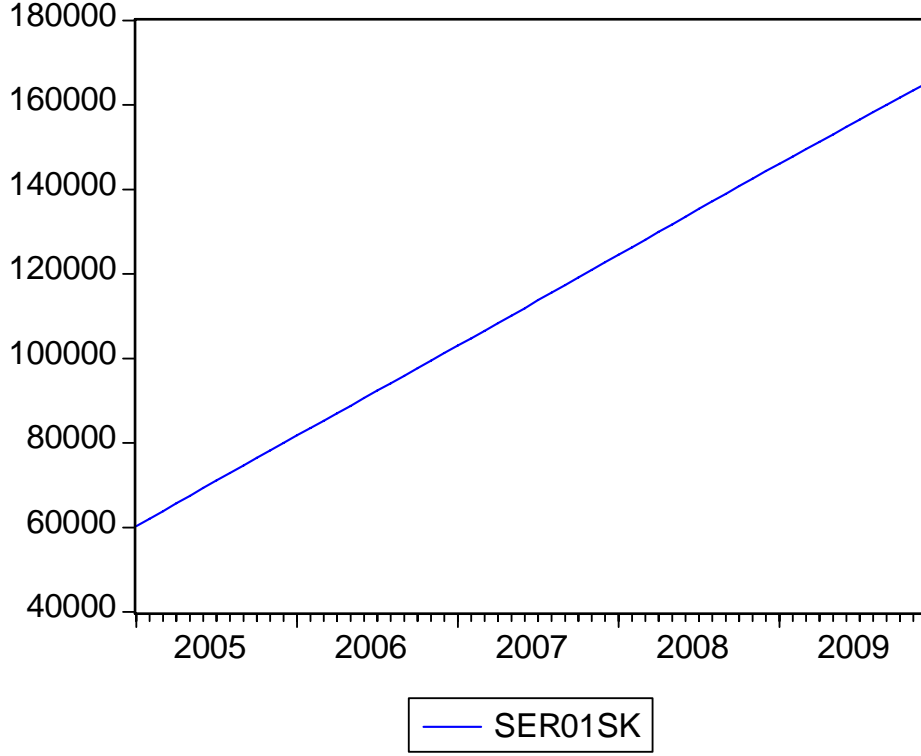


Şekil 5: Basit Ortalama Üstel Düzeltme Grafiği

3.3.3. Hareketli Ortalama

Date: 04/15/10 Time: 13:24
Sample: 2005M01 2009M12
Included observations: 60
Method: Double Exponential
Original Series: SER01
Forecast Series: SER01SK

Parameters:	Alpha	0.0010
	Sum of Squared Residuals	3.75E+10
	Root Mean Squared Error	24990.42
End of Period Levels:	Mean	165213.8
	Trend	1783.423



Şekil 6: Hareketli Ortalama Üstel Düzeltme Grafiği

Veriler üstel düzeltme yöntemlerinden basit ortalama, hareketli ortalama ve Holt – Winters üstel düzeltme yöntemleri ile analiz edildiğinde, hata karelerini minimum yapan yöntem, hareketli ortalama üstel düzeltme yöntemi tercih edilmiştir.

3.4. Box – Jenkins Yöntemleri ve Kestirim Sonuçları

AR, MA ve ARMA yapılarının hangisinin en iyi olduğuna karar verirken Akaike Info Criterion (AIC) ve Schwarz Criterion (SC) ile Sum Squared Resid (SSR) değerlerine bakılır. Bu değerlerin en küçük olduğu modeller seçilir. Ayrıca Box - Jenkins metodolojisinin cimrilik özelliğine göre mümkün olduğunca az gecikme ile çalışılır. Bu modeller için birinci farklar alınarak durağanlaştırma işlemi gerçekleştirilmiştir.

3.4.1. AR (1)

Dependent Variable: SER01
Method: Least Squares
Date: 04/15/10 Time: 13:26
Sample (adjusted): 2005M02 2009M12
Included observations: 59 after adjustments
Convergence achieved after 2 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.975453	0.038955	25.04045	0.0000
R-squared	0.063510	Mean dependent var	111119.5	
Adjusted R-squared	0.063510	S.D. dependent var	35333.70	
S.E. of regression	34193.27	Akaike info criterion	23.73425	
Sum squared resid	6.78E+10	Schwarz criterion	23.76946	
Log likelihood	-699.1603	Durbin-Watson stat	2.862953	
Inverted AR Roots	.98			

3.4.2. AR (2)

Dependent Variable: SER01
Method: Least Squares
Date: 04/15/10 Time: 13:27
Sample (adjusted): 2005M03 2009M12
Included observations: 58 after adjustments
Convergence achieved after 2 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.499731	0.119947	4.166260	0.0001
AR(2)	0.501037	0.121021	4.140098	0.0001
R-squared	0.251901	Mean dependent var	112063.1	
Adjusted R-squared	0.238542	S.D. dependent var	34884.41	
S.E. of regression	30440.69	Akaike info criterion	23.51882	
Sum squared resid	5.19E+10	Schwarz criterion	23.58987	
Log likelihood	-680.0458	Durbin-Watson stat	2.270966	
Inverted AR Roots	1.00	-.50		
Estimated AR process is nonstationary				

3.4.3. AR (3)

Dependent Variable: SER01
Method: Least Squares
Date: 04/15/10 Time: 13:28
Sample (adjusted): 2005M04 2009M12
Included observations: 57 after adjustments
Convergence achieved after 3 iterations

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.307416	0.125471	2.450101	0.0176
AR(2)	0.314344	0.126518	2.484588	0.0161
AR(3)	0.389708	0.126750	3.074617	0.0033
R-squared	0.396081	Mean dependent var		112172.9
Adjusted R-squared	0.373714	S.D. dependent var		35184.38
S.E. of regression	27844.30	Akaike info criterion		23.35784
Sum squared resid	4.19E+10	Schwarz criterion		23.46537
Log likelihood	-662.6984	Durbin-Watson stat		2.000499
Inverted AR Roots	1.01	-.35-.52i	-.35+.52i	
Estimated AR process is nonstationary				

3.4.4. MA (1)

Dependent Variable: SER01
Method: Least Squares
Date: 04/15/10 Time: 13:32
Sample: 2005M01 2009M12
Included observations: 60
Convergence achieved after 33 iterations
Backcast: 2004M12

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.784883	0.078470	10.00228	0.0000
R-squared	-3.261309	Mean dependent var		110126.0
Adjusted R-squared	-3.261309	S.D. dependent var		35868.28
S.E. of regression	74042.67	Akaike info criterion		25.27920
Sum squared resid	3.23E+11	Schwarz criterion		25.31410
Log likelihood	-757.3759	Durbin-Watson stat		0.820612
Inverted MA Roots	-.78			

3.4.5. MA (2)

Dependent Variable: SER01
 Method: Least Squares
 Date: 04/15/10 Time: 13:32
 Sample: 2005M01 2009M12
 Included observations: 60
 Convergence achieved after 28 iterations
 Backcast: 2004M11 2004M12

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	1.038932	0.112195	9.260097	0.0000
MA(2)	0.527681	0.116537	4.528004	0.0000
R-squared	-1.818319	Mean dependent var	110126.0	
Adjusted R-squared	-1.866911	S.D. dependent var	35868.28	
S.E. of regression	60732.01	Akaike info criterion	24.89909	
Sum squared resid	2.14E+11	Schwarz criterion	24.96891	
Log likelihood	-744.9728	Durbin-Watson stat	1.382957	
Inverted MA Roots	-.52-.51i	-.52+.51i		

3.4.6. MA (3)

Dependent Variable: SER01
 Method: Least Squares
 Date: 04/15/10 Time: 13:33
 Sample: 2005M01 2009M12
 Included observations: 60
 Convergence achieved after 19 iterations
 Backcast: 2004M10 2004M12

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.807177	0.094049	8.582504	0.0000
MA(2)	0.881481	0.085986	10.25141	0.0000
MA(3)	0.716289	0.090645	7.902103	0.0000
R-squared	-0.750793	Mean dependent var	110126.0	
Adjusted R-squared	-0.812224	S.D. dependent var	35868.28	
S.E. of regression	48285.47	Akaike info criterion	24.45636	
Sum squared resid	1.33E+11	Schwarz criterion	24.56107	
Log likelihood	-730.6907	Durbin-Watson stat	1.293193	
Inverted MA Roots	.00+.94i	.00-.94i	-.81	

3.4.7. ARMA (1,1)

Dependent Variable: SER01
Method: Least Squares
Sample (adjusted): 2005M02 2009M12
Included observations: 59 after adjustments
Convergence achieved after 15 iterations
Backcast: 2005M01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	1.011162	0.004108	246.1408	0.0000
MA(1)	-0.889159	0.062998	-14.11419	0.0000
R-squared	0.474963	Mean dependent var	111119.5	
Adjusted R-squared	0.465752	S.D. dependent var	35333.70	
S.E. of regression	25826.22	Akaike info criterion	23.18948	
Sum squared resid	3.80E+10	Schwarz criterion	23.25990	
Log likelihood	-682.0896	Durbin-Watson stat	2.017274	
Inverted AR Roots	1.01	Estimated AR process is nonstationary		
Inverted MA Roots	.89			

3.4.8. ARMA (2,1)

Dependent Variable: SER01
Method: Least Squares
Sample (adjusted): 2005M03 2009M12
Included observations: 58 after adjustments
Convergence achieved after 12 iterations
Backcast: 2005M02

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.949958	0.160440	5.920964	0.0000
AR(2)	0.061100	0.161369	0.378633	0.7064
MA(1)	-0.861631	0.082334	-10.46509	0.0000
R-squared	0.458327	Mean dependent var	112063.1	
Adjusted R-squared	0.438630	S.D. dependent var	34884.41	
S.E. of regression	26137.02	Akaike info criterion	23.23043	
Sum squared resid	3.76E+10	Schwarz criterion	23.33701	
Log likelihood	-670.6825	Durbin-Watson stat	1.909560	
Inverted AR Roots	1.01	-.06	Estimated AR process is nonstationary	
Inverted MA Roots	.86			

3.4.9. ARMA (1,2)

Dependent Variable: SER01
 Method: Least Squares
 Date: 04/15/10 Time: 13:42
 Sample (adjusted): 2005M02 2009M12
 Included observations: 59 after adjustments
 Convergence achieved after 12 iterations
 Backcast: 2004M12 2005M01

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	1.010746	0.004567	221.2982	0.0000
MA(1)	-0.929240	0.131084	-7.088865	0.0000
MA(2)	0.057775	0.136383	0.423621	0.6735
R-squared	0.476116	Mean dependent var	111119.5	
Adjusted R-squared	0.457406	S.D. dependent var	35333.70	
S.E. of regression	26027.15	Akaike info criterion	23.22118	
Sum squared resid	3.79E+10	Schwarz criterion	23.32681	
Log likelihood	-682.0247	Durbin-Watson stat	1.947268	
Inverted AR Roots	1.01	Estimated AR process is nonstationary		
Inverted MA Roots	.86	.07		

3.4.10. ARMA (2,2)

Dependent Variable: SER01
 Method: Least Squares
 Date: 04/15/10 Time: 13:44
 Sample (adjusted): 2005M03 2009M12
 Included observations: 58 after adjustments
 Convergence achieved after 17 iterations
 Backcast: 2005M01 2005M02

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.238931	0.476156	0.501792	0.6179
AR(2)	0.781109	0.480432	1.625847	0.1098
MA(1)	-0.084718	0.447380	-0.189365	0.8505
MA(2)	-0.726069	0.382588	-1.897782	0.0631
R-squared	0.462773	Mean dependent var	112063.1	
Adjusted R-squared	0.432927	S.D. dependent var	34884.41	
S.E. of regression	26269.43	Akaike info criterion	23.25667	
Sum squared resid	3.73E+10	Schwarz criterion	23.39877	
Log likelihood	-670.4435	Durbin-Watson stat	2.000634	
Inverted AR Roots	1.01	-.77		
	Estimated AR process is nonstationary			
Inverted MA Roots	.90	-.81		

3.4.11. ARMA (3,2)

Dependent Variable: SER01
 Method: Least Squares
 Date: 04/15/10 Time: 13:45
 Sample (adjusted): 2005M04 2009M12
 Included observations: 57 after adjustments
 Convergence achieved after 14 iterations
 Backcast: 2005M02 2005M03

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.297660	0.359975	0.826891	0.4121
AR(2)	0.596752	0.362545	1.646010	0.1058
AR(3)	0.124400	0.162527	0.765410	0.4475
MA(1)	-0.180194	0.356664	-0.505221	0.6155
MA(2)	-0.548471	0.315528	-1.738263	0.0881
R-squared	0.483191	Mean dependent var	112172.9	
Adjusted R-squared	0.443436	S.D. dependent var	35184.38	
S.E. of regression	26248.67	Akaike info criterion	23.27225	
Sum squared resid	3.58E+10	Schwarz criterion	23.45146	
Log likelihood	-658.2591	Durbin-Watson stat	1.924948	
Inverted AR Roots	1.01	-.29	-.42	
	Estimated AR process is nonstationary			
Inverted MA Roots	.84	-.66		

3.4.12. ARMA (3,3)

Dependent Variable: SER01
 Method: Least Squares
 Date: 04/15/10 Time: 13:46
 Sample (adjusted): 2005M04 2009M12
 Included observations: 57 after adjustments
 Convergence achieved after 44 iterations
 Backcast: 2005M01 2005M03

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.561352	0.073856	-7.600629	0.0000
AR(2)	0.652156	0.036453	17.89047	0.0000
AR(3)	0.945831	0.065320	14.47997	0.0000
MA(1)	0.754506	0.082997	9.090771	0.0000
MA(2)	-0.451802	0.117980	-3.829474	0.0004
MA(3)	-0.836475	0.082379	-10.15399	0.0000
R-squared	0.515524	Mean dependent var		112172.9
Adjusted R-squared	0.468026	S.D. dependent var		35184.38
S.E. of regression	25662.27	Akaike info criterion		23.24273
Sum squared resid	3.36E+10	Schwarz criterion		23.45779
Log likelihood	-656.4179	Durbin-Watson stat		2.000983
Inverted AR Roots	1.01	-.79-56i	-.79+.56i	
	Estimated AR process is nonstationary			
Inverted MA Roots	.87	-.81+.55i	-.81-.55i	

3.4.13. ARMA (4,3)

Dependent Variable: SER01
 Method: Least Squares
 Date: 04/15/10 Time: 13:47
 Sample (adjusted): 2005M05 2009M12
 Included observations: 56 after adjustments
 Convergence achieved after 31 iterations
 Backcast: 2005M02 2005M04

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.722007	0.167191	-4.318464	0.0001
AR(2)	0.825479	0.142477	5.793755	0.0000
AR(3)	0.881765	0.142642	6.181682	0.0000
AR(4)	0.056786	0.166581	0.340893	0.7346
MA(1)	0.939918	0.086698	10.84134	0.0000
MA(2)	-0.624221	0.149517	-4.174915	0.0001
MA(3)	-0.830871	0.092879	-8.945729	0.0000
R-squared	0.503522	Mean dependent var	113029.3	
Adjusted R-squared	0.442728	S.D. dependent var	34898.30	
S.E. of regression	26051.80	Akaike info criterion	23.29003	
Sum squared resid	3.33E+10	Schwarz criterion	23.54320	
Log likelihood	-645.1208	Durbin-Watson stat	1.974408	
Inverted AR Roots	1.01	-.07	-.83+.35i	-.83-.35i
	Estimated AR process is nonstationary			
Inverted MA Roots	.87	-.91+.37i	-.91-.37i	

3.5. BOX – JENKİNS YÖNTEMLERİNE AİT AIC VE SC DEĞERLERİ

TABLO 1

Model	Sum Squared Resid SSR	Akaike Info Criterion AIC	Schwarz Criterion SC
AR1	6.78E+10	23.73425	23.76946
AR2	5.19E+10	23.51882	23.58987
AR3	4.19E+10	23.35784	23.46537
MA1	3.23E+11	25.27920	25.31410
MA2	2.14E+11	24.89909	24.96891
MA3	1.33E+11	24.45636	24.56107
ARMA 1.1	3.80E+10	23.18948	23.25990
ARMA 2.1	3.76E+10	23.23043	23.33701
ARMA 1.2	3.79E+10	23.22118	23.32681
ARMA 2.2	3.73E+10	23.25667	23.39877
ARMA 3.2	3.58E+10	23.27225	23.45146
ARMA 3.3	3.36E+10	23.24273	23.45779
ARMA 4.3	3.33E+10	23.29003	23.54320

Tüm model kombinasyonları denedikten sonra uygun olan modelin seçimine karar verilmiştir. Uygunluk kriteri olarak AIC ve SC kriterleri dikkate alınmıştır. AIC ve SC kriterlerine göre en düşük değeri veren model kestirimin doğruluğu açısından en uygun model olduğundan ARMA1.1 modeli seçilmiştir. Birinci dereceden fark alınarak durağanlaştırma işlemi yapılmasından dolayı ARIMA (1.1.1) modelini tercih etmemizde mümkündür.

SONUÇ

Metal sektöründe raf imalatı yapan bir firmanın altmış aylık satış verilerinin kestirimi sonucunda yapılan çalışmada zaman serileri yaklaşımı dikkate alınarak gerek biçimsel, gerekse biçimsel olmayan yöntemler ile gerekli testler yapılmıştır. Özellikle birim kök testleri aylık satış verilerine uygulanarak testler gerçekleştirilmiştir.

Zaman serileri analizi ile aylık zaman serilerinin biçimsel olmayan grafiği çizilerek serinin zaman içerisinde ortalamasının değiştiği ortaya konulmuştur. Seri için çizilen korelogramların incelenerek serinin durağan olmadığı bu yöntemlerle tespit edilmiştir. Ancak serinin birinci farkı alındıktan sonra tekrar birim kök testi yapıldığında durağanlığın sağlandığı sonucu ortaya çıkmıştır.

Veriler üstel düzeltirme yöntemlerinden basit ortalama, hareketli ortalama ve Holt-Winters yöntemleri ile analiz edildiğinde hata karelerini minimum yapan hareketli ortalama üstel düzeltirme yöntemi tercih edilmiştir. Kullanım alanları dikkate alındığında ne kadar önemli olduğunu düşünerek yapay sınır ağları ile ilgili teorik bilgiye çalışmamızda yer verilmiştir.

Asıl amacımız olan doğru kestirim sonuçlarını elde etmek için en iyi olan otoregresif model yapıları analiz edilmiştir. Bu analiz sonucunda karar verirken Akaike Info Criterion (AIC) ve Schwarz Criterion (SC) ile Sum Squared Resid (SSR) değerlerine bakılır. Bu değerlerin en küçük olduğu modeller seçilir. Ayrıca Box - Jenkins yönteminin cimrilik özelliğine göre mümkün olduğunca az gecikme ile çalışılır.

Tüm model birleşimleri denendikten sonra uygun olan modelin seçimine karar verilmiştir. Uygunluk kistası olarak AIC ve SC kriterleri dikkate alınmıştır. En düşük değeri ARMA1.1 modeli vermektedir.

Bu çalışmanın eksikleri, dolayısıyla bu içeriğe ilişkin yapılabilecek daha ileri çalışmalar şöyle sıralanabilir;

Daha fazla yazın taraması,

Üstel düzeltme yöntemleri, AR, MA... da yer alan parametrelerin(eğilim katsayılarının) keyfi seçimi yerine bu parametrelerin tahminine yönelik teorik irdeleme ve denemeler,

Yapay sinir ağlarına ilişkin uygulama,

İçerikte yer alan tüm kestirim yöntemlerine ilişkin Web tabanlı bir uygulama yazılımı geliştirme.

KAYNAKLAR

- AKGÜL I. Zaman Serilerinin Analizi ve ARIMA Modelleri, İstanbul, 2002,
- CHATFIELD C. The Analysis of Time Series: An Introduction, New York: Chapman and Hall, 1980, s.6
- EĞRİOĞLU Erol, Yapay Sinir Ağları Ve Arıma Modellerinin Melez Yaklaşımı İle
ALADAĞ Çağdaş H. Zaman Serilerinde Öngörü, s. 1-2
- ELMAS Çetin, Yapay Sinir Ağları Kuram, Mimari, Eğitim, Uygulama, Seçkin
Yayıncılık, Ankara, 2003, s. 27-28
- GUJARATI Damodar Temel Ekonometri, 2001, s. 709-738
- HARVEY A.C. Time Series Models, New York 1993 s.23
- KAYIM Halil, İstatistiksel Ön Tahmin Yöntemleri, Ankara 1985, s. 6- 32
- ÖZTEMEL Ercan Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, 2003, s. 29-56
- ÖNDER Emrah Yabancı Ziyaretçi Sayısının Tahmininde Box Jenkins Modeli,
HASGÜL Özlem Winters Yöntemi Ve Yapay Sinir Ağlarıyla Zaman Serisi
Analiz, s. 65-66
- SEVÜKTEKİN M. Zaman Serileri Analizi, Nobel Yayın, Ankara 2005, s. 5-47
NARGELEÇEKENLER
- YURTOĞLU Hasan, Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi,
Ankara, 2005, s. 9
- ZHANG G. Peter Time Series Forecasting Using a Hybrid ARIMA and Neural
Network Model, 2003, s. 159-175

EK. 1		
İŞLETMENİN 60 AYLIK SATIŞ VERİLERİ		
NO	AY	SATIŞLAR
1	Oca.05	51.509 TL
2	Şub.05	56.392 TL
3	Mar.05	105.802 TL
4	Nis.05	64.219 TL
5	May.05	99.894 TL
6	Haz.05	70.350 TL
7	Tem.05	59.838 TL
8	Ağu.05	73.140 TL
9	Eyl.05	82.702 TL
10	Eki.05	85.600 TL
11	Kas.05	68.404 TL
12	Ara.05	85.200 TL
13	Oca.06	36.765 TL
14	Şub.06	55.397 TL
15	Mar.06	69.386 TL
16	Nis.06	83.141 TL
17	May.06	119.712 TL
18	Haz.06	102.592 TL
19	Tem.06	56.114 TL
20	Ağu.06	84.081 TL
21	Eyl.06	118.776 TL
22	Eki.06	88.001 TL
23	Kas.06	113.964 TL
24	Ara.06	96.624 TL
25	Oca.07	58.747 TL
26	Şub.07	75.713 TL
27	Mar.07	134.581 TL
28	Nis.07	101.787 TL
29	May.07	112.118 TL
30	Haz.07	174.891 TL
31	Tem.07	96.852 TL
32	Ağu.07	117.921 TL
33	Eyl.07	127.831 TL
34	Eki.07	111.327 TL
35	Kas.07	161.502 TL
36	Ara.07	115.592 TL
37	Oca.08	114.262 TL
38	Şub.08	110.543 TL
39	Mar.08	164.823 TL
40	Nis.08	124.428 TL
41	May.08	166.431 TL
42	Haz.08	173.910 TL
43	Tem.08	125.339 TL
44	Ağu.08	123.627 TL
45	Eyl.08	175.498 TL
46	Eki.08	131.205 TL
47	Kas.08	160.791 TL
48	Ara.08	87.083 TL
49	Oca.09	117.375 TL
50	Şub.09	127.691 TL
51	Mar.09	122.930 TL
52	Nis.09	140.408 TL
53	May.09	155.794 TL
54	Haz.09	111.757 TL
55	Tem.09	148.795 TL
56	Ağu.09	142.976 TL
57	Eyl.09	121.381 TL
58	Eki.09	134.773 TL
59	Kas.09	127.328 TL
60	Ara.09	181.947 TL

ÖZGEÇMİŞ

Doğum Yeri ve Yılı : İSTANBUL - 1973

Öğr.Gördüğü Kurumlar :

	Başlama Yılı	Bitirme Yılı	Kurum Adı
Lise	1987	1990	SEFAKÖY LİSESİ
Lisans	1992	1996	ULUDAĞ ÜNİVERSİTESİ
Yüksek Lisans	1997	---	ULUDAĞ ÜNİVERSİTESİ
Doktora			
Medeni Durum	EVLİ		
Bildiği Yabancı Diller ve Düzeyi:	: ---		
Çalıştığı Kurum (lar)	Başlama ve Ayrılma Tarihleri	Çalışılan Kurumun Adı	
1.	1997	1999	BAYINDIR HOLDİNG
2.	2001	---	ÖZTÜRK / DİNAMİK RAF
Yurtdışı Görevleri	: ---		
Kullandığı Burslar	: ---		
Aldığı Ödüller	: ---		
Üye Olduğu Bilimsel ve Mesleki Topluluklar	:		
Editör veya Yayın Kurulu Üyelikleri	:		
Yurt İçi ve Yurt Dışında katıldığı Projeler	:		
Katıldığı Yurt İçi ve Yurt Dışı Bilimsel Toplantılar:			
Yayımlanan Çalışmalar	:		
Diğer	:		

01.10.2010

Cem FİLİZ