

**ZAMAN SERİSİ MODELLEMESİNDE  
YAPAY SİNİR AĞLARININ KULLANIMI  
VE BİR UYGULAMA**

Özer ÖZDEMİR  
Yüksek Lisans Tezi

İstatistik Anabilim Dalı  
Temmuz-2008

## JÜRİ VE ENSTİTÜ ONAYI

**Özer Özdemir**'in “**Zaman Serisi Modellemesinde Yapay Sinir Ağlarının Kullanımı ve Bir Uygulama**” başlıklı **İstatistik** Anabilim Dalındaki, Yüksek Lisans Tezi 01.07.2008 tarihinde aşağıdaki jüri tarafından Anadolu Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca değerlendirilerek kabul edilmiştir.

	<b>Adı-Soyadı</b>	<b>İmza</b>
Üye (Tez Danışmanı):	<b>Yard. Doç. Dr. ATILLA ASLANARGUN</b>	.....
Üye	<b>: Prof. Dr. MEMMEDAĞA MEMMEDLİ</b>	.....
Üye	<b>: Yard. Doç. Dr. NAMIK KEMAL ERDOĞAN</b>	.....

**Anadolu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun**  
..... tarih ve ..... sayılı kararıyla onaylanmıştır.

**Enstitü Müdürü**

## ÖZET

**Yüksek Lisans Tezi**

### **ZAMAN SERİSİ MODELLEMESİNDE YAPAY SİNİR AĞLARININ KULLANIMI VE BİR UYGULAMA**

**Özer ÖZDEMİR**

**Anadolu Üniversitesi  
Fen Bilimleri Enstitüsü  
İstatistik Anabilim Dalı**

**Danışman: Yard. Doç. Dr. Atilla ASLANARGUN**

**2008, 110 sayfa**

Bu tezde, zaman serisi modellemesinde yapay sinir ağlarının kullanımı incelenmiştir. Bu amaçla İstanbul Menkul Kıymetler Borsası (İMKB) Ulusal-100 endeksi bir zaman serisi olarak incelenmiştir. İlk olarak, bu zaman serisinin öngörüsü için Box-Jenkins modellerinden biri olan otoregresif entegre hareketli ortalama (ARIMA) modeli kullanılmıştır. En uygun model bulunduğundan sonra öngörü yapılmıştır. İkinci olarak, yapay sinir ağları kullanılarak aynı zaman serisi için en uygun model bulunmuş ve öngörü yapılmıştır. Her iki yöntem için STATISTICA paket programı kullanılmış ve sonuçlar ortalama hata kare (MSE) performans ölçütü kullanılarak karşılaştırılmıştır. Sonunda yapay sinir ağları kullanılarak bulunan doğrusal sinir ağı ile yapılan öngörünün Box-Jenkins ARIMA modeli ile yapılan öngörüden daha iyi performansa sahip olduğu ifade edilmiştir.

**Anahtar Kelimeler:** Yapay Sinir Ağları, Zaman Serisi, Doğrusal Sinir Ağları,  
ARIMA Modeli, MSE Performans Ölçütü

## **ABSTRACT**

**Master of Science Thesis**

### **USING ARTIFICIAL NEURAL NETWORKS IN TIME SERIES MODELING AND AN APPLICATION**

**Özer ÖZDEMİR**

**Anadolu University  
Graduate School of Sciences  
Statistics Program**

**Supervisor: Assist. Prof. Dr. Atilla ASLANARGUN**

**2008, 110 pages**

In this thesis, using artificial neural networks in time series modeling is considered. For this purpose, İstanbul Stock Exchange National-100 index is considered as a time series. Firstly, autoregressive integrated moving average (ARIMA) model which is one of Box-Jenkins models is used for forecasting this time series. Forecasting is done after the most suitable model is found. Secondly, the most suitable model is found and forecasting is done for the same time series by using artificial neural networks. STATISTICA package program is used for both methods and results are compared by using mean square error (MSE) performance measure. Finally, it is expressed that forecasting which is done with linear neural networks finding by using artificial neural networks has better performance than forecasting which is done with Box-Jenkins ARIMA model.

**Keywords:** Artificial Neural Networks, Time Series, Linear Neural Networks, ARIMA Model, MSE Performance Measure

## TEŐEKKÜR

Hazırlamıő olduđum yüksek lisans tezinde beni ynlendiren, srekli yanımnda olan, yođun alıőma programına rađmen bana daima zaman ayırabilen, benden hibir desteđini ve katkısını esirgemeyen, bilgi ve deneyimlerini paylaőmasıyla her konuda ok Őey đrendiđim deđerli hocam ve tez danıőmanım Yard. Do. Dr. Atilla ASLANARGUN'a ok teőekkr ederim.

alıőmam sresince bana yardımcı olan, herhangi bir problemimde yardımını esirgemeyen, Yapay Sinir Ađları konusundaki engin bilgi ve birikimlerini bana aktararak alıőmama byk katkılar sađlayan Prof. Dr. Memmedađa MEMMEDLİ'ye en iten teőekkrlerimi sunarım.

alıőmam sresince bana destek olup her konuda zveride bulunan baőta Blm Baőkanı Prof. Dr. Embiya AđAOđLU olmak zere btn blm elemanları ve arkadaőlarıma teőekkr ederim.

alıőmam boyunca benden maddi desteđini esirgemeyen, katkılarından dolayı memnuniyet duyduđum ve mutlu olduđum, her zaman bilim insanın yanında olan Trkiye Bilimsel ve Teknolojik Araőtırma Kurumu'na (TBİTAK) verdiđi her trl destek ve katkıdan dolayı teőekkrlerimi bir bor bilirim.

Hayatımın her aőamasında bana yardımcı olan, her zaman her trl desteklerini benden esirgemeyen, canım ađabeyim, annem ve babama en iten teőekkrlerimi sunarım.

zer ZDEMİR

Temmuz, 2008

# İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET.....	i
ABSTRACT .....	ii
TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ .....	vii
ÇİZELGELER DİZİNİ .....	viii
<b>1. GİRİŞ .....</b>	<b>1</b>
<b>2. ZAMAN SERİSİ ANALİZİ.....</b>	<b>4</b>
2.1. Zaman Serisi ve Zaman Serisi Analizinin Tanımı .....	4
2.2. Zaman Serisinin Özellikleri .....	5
2.2.1. Dört unsurdan meydana gelme özelliği .....	5
2.2.2. İç bağımlılık özelliği.....	7
2.2.3. Stokastik süreç olma özelliği .....	8
2.3. Box-Jenkins Modelleri .....	8
2.3.1. Doğrusal durağan stokastik modeller .....	9
2.3.2. Durağan olmayan doğrusal stokastik modeller (ARIMA).....	13
2.3.3. Mevsimsel modeller .....	16
2.4. Zaman Serisi Analizinde Kullanılan Araçlar.....	18
2.4.1. Otokovaryans fonksiyonu .....	18
2.4.2. Otokorelasyon fonksiyonu .....	19
2.4.3. Kısmi otokorelasyon fonksiyonu.....	20
2.4.4. Ortalama-standart sapma serpilme grafiği .....	22
2.5. Zaman Serisi Analizinin Aşamaları .....	22
2.5.1. Modelin belirlenmesi .....	23
2.5.2. Belirlenen modelin parametrelerinin tahmini .....	26
2.5.3. Modelin uygunluğunun sınanması .....	29
2.5.4. Modelin tahmin amacıyla kullanımı.....	31

<b>3. YAPAY SINİR AĞLARI.....</b>	<b>34</b>
3.1. Yapay Sinir Ağlarının Tanımı .....	35
3.2. Biyolojik Sinir Ağlarının Fizyolojik Yapısı .....	35
3.3. Yapay Sinir Ağlarının Temel Yapısı.....	38
3.4. Yapay Sinir Ağlarının Temel Elemanları.....	40
3.4.1. Girdiler.....	40
3.4.2. Ağırlıklar.....	40
3.4.3. Transfer(Aktivasyon) fonksiyonu .....	41
3.4.4. Hücrenin çıktısı .....	46
3.5. Yapay Sinir Ağlarının Tarihçesi .....	46
3.6. Yapay Sinir Ağlarının Genel Özellikleri.....	49
3.7. Yapay Sinir Ağlarının Sınıflandırılması.....	51
3.7.1. Bağlantı yapılarına göre ağlar .....	51
3.7.2. Öğrenme şekillerine göre ağlar .....	52
3.7.3. Katman sayısına göre ağlar .....	54
3.8. Bazı Yapay Sinir Ağı Algoritmaları.....	56
3.8.1. Standart geriye yayılım algoritması.....	56
3.8.2. Esnek geriye yayılım algoritması.....	57
3.8.3. Radyal tabanlı fonksiyon algoritması.....	57
3.9. Bazı Yapay Sinir Ağı Mimarileri.....	59
3.9.1. Doğrusal ağlar .....	59
3.9.2. Radyal tabanlı fonksiyon ağları (RBF).....	60
3.9.3. Çok katmanlı algılayıcı (MLP) .....	61
3.9.4. Genelleştirilmiş regresyon sinir ağları (GRNN) .....	61
3.10. Yapay Sinir Ağları, İstatistik ve Ekonomi.....	63
3.11. Yapay Sinir Ağlarının Güçlü Yanları.....	65
3.12. Yapay Sinir Ağlarının Uygulama Alanları.....	66
3.13. Tahmin Değerlendirme Yöntemleri .....	68

<b>4. İMKB ULUSAL-100 ENDEKSİNİN TAHMİN EDİLMESİNDE YAPAY SİNİR AĞLARININ KULLANILMASI.....</b>	<b>69</b>
4.1. Giriş .....	69
4.2. Box-Jenkins Modelleri ile Tahmin.....	70
4.2.1. Box-Jenkins modelinin belirlenmesi .....	71
4.2.2. Box-Jenkins modelinin uygunluğunun sınanması.....	77
4.2.3. Box-Jenkins modelinin ileriye dönük tahmini .....	79
4.3. Yapay Sinir Ağları ile Tahmin.....	81
4.3.1. Yapay sinir ağı modelinin belirlemesi.....	81
4.3.2. Yapay sinir ağı modelinin ileriye dönük tahmini.....	82
<b>5. SONUÇ VE ÖNERİLER .....</b>	<b>86</b>
<b>KAYNAKLAR .....</b>	<b>88</b>
<b>Ek-1 Veri Seti.....</b>	<b>92</b>
<b>Ek-2 Dönüşümü sonucu <math>\ln(X_t)</math> serisi.....</b>	<b>94</b>
<b>Ek-3 YSA modellemesi için veri girişi <math>(X_1 - X_7)</math> .....</b>	<b>95</b>
<b>Ek-4 YSA modellemesi için veri girişi <math>(X_8 - Y)</math> .....</b>	<b>99</b>
<b>Ek-5 YSA modeliyle öngörü için veri girişi <math>(X_1 - X_6)</math> .....</b>	<b>103</b>
<b>Ek-6 YSA modeliyle öngörü için veri girişi <math>(X_7 - X_{12})</math> .....</b>	<b>107</b>



## ŞEKİLLER DİZİNİ

3.1. Biyolojik Sinir Hücresinin Temel Yapısı.....	36
3.2. Tipik Bir YSA Yapısı.....	39
3.3. Özdeşlik Fonksiyonu.....	41
3.4. Tek Kutuplu Eşik Fonksiyonu .....	42
3.5. Çift Kutuplu Eşik Fonksiyonu .....	43
3.6. Parçalı Doğrusal Fonksiyon.....	44
3.7. Sigmoid Fonksiyonu .....	45
3.8. Hiperbolik Tanjant Fonksiyonu .....	46
3.9. Recurrent Ağ Yapısı.....	52
3.10. Danışmanlı Öğrenme Algoritmalarının İşleyişi.....	53
3.11. Tek Katmanlı Bir Yapay Sinir Ağı .....	55
3.12. Radyal tabanlı fonksiyon ağı .....	60
4.1. İMKB Ulusal-100 endeksi aylık kapanış değerleri.....	71
4.2. Standart Sapma-Ortalama Grafiği.....	72
4.3. $\ln(X_t)$ serisi.....	73
4.4. $\ln(X_t)$ serisinin otokorelasyon fonksiyonu (ACF).....	74
4.5. $\ln(X_t)$ serisinin kısmi otokorelasyon fonksiyonu (PACF) .....	74
4.6. Birinci dereceden farkı alınmış $\ln(X_t)$ serisi için ACF.....	75
4.7. Birinci dereceden farkı alınmış $\ln(X_t)$ serisi için PACF.....	76
4.8. ARIMA $(0,1,1)(0,1,0)_{12}$ modelinin artıklarının dağılımı .....	78
4.9. ARIMA $(0,1,1)(0,1,0)_{12}$ modelinin artıklarına ait ACF.....	78
4.10. ARIMA $(0,1,1)(0,1,0)_{12}$ modeliyle belirlenen öngörü değerleri .....	80
4.11. Doğrusal 2:2-1:1 ağıнын yapısı.....	84

## ÇİZELGELER DİZİNİ

2.1. Durağan modellerde anakütle ACF ve PACF hareketleri .....	25
3.1. Biyolojik Sinir Sistemi ile YSA Arasındaki Benzerlikler .....	38
4.1. 1988-2004 için Standart Sapma ve Aritmetik Ortalama değerleri.....	72
4.2. $\ln(X_t)$ serisi için $ARIMA(0,1,1)(0,1,0)_{12}$ parametre kestirimi.....	77
4.3. $ARIMA(0,1,1)(0,1,0)_{12}$ modeli için öngörü değerleri ve güven sınırları.....	79
4.4. Gözlenen değerler ve öngörü değerleri .....	80
4.5. Linear 2:2-1:1 modeliyle hesaplanan öngörü değerleri.....	82
4.6. MLP s3 3:9-1-1:1 modeliyle hesaplanan öngörü değerleri .....	83
4.7. GRNN 5:5-92-2-1:1 modeliyle hesaplanan öngörü değerleri .....	83
4.8. GRNN 7:7-92-2-1:1 modeliyle hesaplanan öngörü değerleri .....	83
4.9. RBF s6 12:72-16-1:1 modeliyle hesaplanan öngörü değerleri .....	83
4.10. En iyi 5 model için MSE .....	84
4.11. Doğrusal 2:2-1:1 ağının ağırlıkları.....	85
5.1. YSA ve B.J. yöntemi için öngörü değerleri.....	86
5.2. YSA ve B.J. yöntemi için MSE .....	86

## 1. GİRİŞ

Kestirim (öngörü) kavramı, bir değişkenin belirli varsayımlar altında gelecekte alabileceği değerlerin önceden yaklaşık olarak belirlenmesi olarak tanımlanır. Zaman serisi çözümlemesi ile öngörü, incelenen bir değişkenin şimdiki ve geçmiş dönemdeki gözlem değerlerini kullanarak ve birtakım varsayımlar altında öngörü değerlerinin hangi sınırlar arasında gerçekleşebileceğini ortaya koymak için yapılan uğraşlardır.

Herhangi bir değişkenin gelecekte alacağı değerlerin kestirimi, değişkenin geçmiş dönemlerdeki gözlem değerleri kullanılarak oluşturulan modeller yardımı ile sağlanır. Kestirim analizi model belirleme ve kestirim aşamasından oluşur. Kestirim modelinin verinin geçmiş değerleri ile en iyi uyumu sağlayan ve geleceği en iyi temsil eden nitelikte olması öngörülerdeki başarıyı artırır.

Model kurma aşamasının başlangıcında ilgili probleme ait veriler sağlıklı bir şekilde toplanır ve toplanan verilere uygun model belirlenir. Belirlenen modelin matematiksel biçimi atanarak, var olan veriler yardımı ile modelin parametreleri belirlenmeye çalışılır. Modelin uyumu hata testleri ile sağlanabilir. Eğer kurulan model uygun bir model ise, gelecek için kestirimler yapılabilir (Biçen, 2006).

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 tahmininde başka bir ifadeyle kestirimde kullanılmasına dayanan bu teknikler, özellikle kısa, orta ve uzun dönem kestirimlerine ihtiyaç duyulan her alanda kullanılmaktadır. Bilinmeyen geleceğin bilimsel yöntemlerle kestirilmesi ve gelecek için önceden hazırlıkların yapılması her alanda olduğu gibi özellikle ekonomide ve finans sektöründe büyük önem taşımaktadır.

Zaman serileri, değişkenlerin gün, hafta, ay, mevsim veya yıl gibi herhangi bir zaman birimine göre dağılımını gösteren serilerdir. Zaman serileri Box-Jenkins (1970) ile önem kazanmıştır. Temel prensipleri Yule tarafından 1920'lerde ortaya atılmıştır. Gelişen bilgisayar olanakları, bu yöntemin yayılmasını kolaylaştırmıştır. Ana prensip her dizinin geçmiş değerleri ile açıklanabileceği fikrine dayanır.

1980'li yılların sonlarından başlamak üzere zaman serilerine ilişkin kestirimler için kullanılmakta olan yöntemlerden biri de Yapay Sinir Ağları

(YSA) yöntemidir. YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye gereksinim duymadan doğrusal ve doğrusal olmayan modellemeyi sağlayabilmektedir. Bu nedenle YSA, kestirim aracı olarak diğer yöntemlere göre daha genel ve esneklerdir.

Geleneksel istatistiksel zaman serileri yöntemleri, performansı iyi olmasına rağmen yapısında pek çok sınırlamalara sahiptir. Uzmanlık olmadan bağımlı ve bağımsız değişken arasındaki ilişkinin fonksiyonel yapısı belirtilmemiş olabilir ve gerekli veri dönüşümlerinin yapılmasında başarısızlık olabilir. Çok çeşitli istatistiksel zaman serisi modelleri tahmin edildiği zaman, insan etkileşimi ve değerlendirmeleri gerektirir. YSA ise bu tür problemlerin üstesinden gelebilir. Ayrıca zaman serisi modellerinden Box-Jenkins yaklaşımı doğrusal yapıya sahip olup, doğrusal olmayan davranışları modellemede zorlanabilir. Bu sınırlamaların, YSA'da daha az söz konusu olacağı, YSA'nın bu açıdan daha başarılı olacağı tartışılmıştır. Buna göre, zaman serileri kestiriminde YSA kullanımı, araştırmacıların daha da ilgisini çekmiştir. Problemlerin giriş verisinin en uygun dönüşümlerle her türlü süreçte kolayca modellenmesi tartışılmış ve YSA'nın yaygın bir şekilde kullanımına olanak sağlamıştır.

Finansal ekonomi problemlerinde YSA ve geleneksel yöntemlerin kullanıldığı çok sayıda çalışma bulunmaktadır. Kohzadi ve Ark. (1996) ürün fiyatlarının kestirimi için sinir ağları ile zaman serileri modellerinin karşılaştırmasını yaptıkları çalışmalarında, YSA kestirimlerinin, ARIMA modeli kestirimlerine göre daha düşük ortalama hata kare, ortalama mutlak hata ve ortalama mutlak yüzde hatalara sahip olduğunu bulmuşlardır. Tang ve Ark. (1991), havayolu yolcu sayısı ve yerli ve yabancı araba satışı verilerini kullandıkları çalışmalarında, YSA ile Box-Jenkins metodunu karşılaştırmışlardır. Uzun dönem kestirimlerinde YSA'nın daha iyi olduğu sonucuna varmışlardır (Erdoğan, 2006).

Aslanargun ve Ark. (2007) yaptıkları çalışmada zaman serisi öngörüsü için yaygın kullanılan ARIMA modellere alternatif olarak farklı yapay sinir ağları ve hibrit modeller önermişlerdir. Bu çalışmada, Türkiye'ye gelen turist sayısının öngörüsü için ARIMA, doğrusal yapay sinir ağları, çok katmanlı algılayıcı ve radyal tabanlı fonksiyon ağı modelleri, bunların çeşitli bileşimleri ile birlikte incelenmiştir. Öngörü performanslarının karşılaştırılması sonucunda, doğrusal olmayan bileşenli modellerin daha iyi performans verdiği gösterilmiştir.

Bu çalışma, beş bölümden oluşmaktadır. İlk bölüm giriş bölümüdür.

İkinci bölümde, dördüncü bölümde ele alınan uygulama için gerekli olan zaman serisi analizi, alt bölümler halinde ifade edilmiştir. İlk önce zaman serisi ve analizi tanımlanmış, özellikleri açıklanmıştır. Sonrasında zaman serisi analizinde kullanılan Box-Jenkins modelleri ele alınmış, zaman serisi analizinde kullanılan araçlar hakkında bilgi verilmiş ve son olarak zaman serisi analizinin aşamaları alt bölümler halinde ifade edilmiştir.

Üçüncü bölümde, dördüncü bölümde yapılan uygulama için gerekli olan yapay sinir ağları hakkında bilgi verilmiştir. Yapay sinir ağları tanımlanmış, fizyolojik ve temel yapısı ifade edilmiştir. Sonrasında yapay sinir ağlarının temel elemanları olan girdiler, ağırlıklar, aktivasyon fonksiyonu ve hücrenin çıktısı hakkında bilgi verilmiştir. Yapay sinir ağlarının tarihçesi ve özellikleri kısaca ifade edilmiş, bağlantı yapıları, öğrenme şekilleri ve katman sayılarına göre yapay sinir ağları sınıflandırılmıştır. Dördüncü bölümde ele alınan uygulamada kullanılan bazı yapay sinir ağı algoritmaları ve mimarileri hakkında bilgi verilmiştir. Yapay sinir ağlarının istatistik ve ekonomi açısından önemi ifade edildikten sonra güçlü ve zayıf yanları hakkında bilgi verilmiştir. Son olarak yapay sinir ağlarının bazı uygulama alanları ifade edilmiş ve zaman serisi ve yapay sinir ağlarında kullanılan bazı tahmin değerlendirme yöntemleri ele alınmıştır.

Dördüncü bölümde, İMKB Ulusal-100 endeksinin tahmin edilmesinde hem Box-Jenkins modelleri hem de yapay sinir ağları, STATISTICA 7.0 paket programı yardımıyla ele alınmıştır. Öncelikle Ocak 1988-Aralık 2004 dönemine ait İMKB Ulusal-100 endeksi aylık kapanış değerleri zaman serisi olarak ele alınmış ve Box-Jenkins ARIMA modeli kullanılarak 2005 yılının ilk 6 ayı için öngöründe bulunulmuştur. Sonrasında yapay sinir ağları kullanılarak uygun model belirlenmiş ve aynı dönem için öngöründe bulunulmuştur. Elde edilen sonuçlar için MSE (Mean Square Error-Ortalama Hata Kare) değerleri hesaplanmış ve zaman serisi modellemesinde yapay sinir ağlarının kullanılabileceği gösterilmiştir.

Son bölümde dördüncü bölümde ele alınan uygulamanın sonuçları ifade edilmiş, hem Box-Jenkins modelleri hem de yapay sinir ağları yardımıyla elde sonuçlar karşılaştırılmış, yorumlanmış ve daha sonraki çalışmalar için önerilerde bulunulmuştur.

## 2. ZAMAN SERİSİ ANALİZİ

Bu bölümde zaman serisi ve analizinin tanımı, zaman serisinin özellikleri, Box-Jenkins modelleri, zaman serisi analiz araçları ve zaman serisi analizinin aşamaları ifade edilmiştir.

### 2.1. Zaman Serisi ve Zaman Serisi Analizinin Tanımı

İstatistiğin temel uğraşlarından biri, değişkenleri farklı yönleriyle incelemede ve gözlemlerden elde edilen verilerden sonuçlar çıkarmada yardımcı olmaktır. Gözlemlerden elde edilen verilerin bazı nitelikleri dikkate alınarak sıralanmasına ya da dizilmesine istatistikte seri ya da dizi adı verilir. Gözlemlerden elde edilen veriler bir değişkenin zaman içinde gösterdiği değişimleri ya da hareketleri gösteriyorsa bu durumda ilgili verilere zaman dizileri ya da zaman serileri adı verilir (Arıcı, 1991). Başka bir tanımla zaman serisi bir sıralı gözlemler serisidir (Wei, 2006). Ayrıca başka bir ifadeyle ilgilenilen zamana bağlı bir olayın, gözlem veya deney sonucu aldığı değerlerin oluşturduğu topluluğa zaman serisi denir (Chatfield, 1989). Örneğin sayım yıllarındaki Türkiye nüfusunu, yıllık ihracat miktarlarını, aylık ortalama sıcaklıkları, haftalık veya günlük gazete satışlarını, günün saatlerine göre trafik yoğunluğunu gösteren seriler bu niteliktedir (Yılmaz, 2004).

Bir zaman serisi ilgili değişken üzerinden bir gözlemler dizisidir. Değişken, genelde eşit aralıklı kesikli zaman noktalarında gözlemlenir (Montgomery ve Ark., 1990). Zaman serileri matematiksel semboller ile birlikte şu şekilde ifade edilebilir;  $X$  bir değişken olmak üzere  $t_1, t_2, \dots, t_k$  gibi zamanlarda yapılan gözlemlerden elde edilen değerler  $X_1, X_2, \dots, X_k$  şeklinde gösterilirler. Bu durumda,  $X$  değişkeni için gözlenen ölçümler zaman değişkeninin bir fonksiyonudur (Arıcı, 1991).

Elde edilen zaman serilerinin unsurlarına ayırma, aralarındaki ilişkiyi açıklama, kontrol amacı ve öngörü amacı ile analiz edilmesine zaman serisi analizi denir. Zaman serisi analizinin en önemli amacı bu serinin öngörü amacıyla analiz edilmesidir (Yılmaz, 2004). Zaman serisi analizi dizi üreten sürecin tanımlanmasını içerir. Zaman serisi öngörüsü için geleceğe uzatılabilen bir

matematiksel model ile sürecin davranışının ortaya konulması gerekir (Montgomery ve Ark., 1990). Başka bir ifadeyle zaman serisi analizi, geçmiş dönemlere ait gözlem değerleri veya kayıtlar yardımıyla, geçmiş ve şimdiki durumu açıklayarak, gelecek hakkında tahminler yapmaya yarayan önemli bir istatistik tekniğidir. Zaman serisi analizi ile gelecek hakkında tahminler yapılırken, geçmişteki hareketlerin gelecekte de aynı eğilim içinde bulunacağı varsayılır.

Zaman serisi değerleri devamlı derleme ile kaydedilen değerlerdir, rassal olarak seçilen örnek değerler değildir. Daha doğrusu, anakütleyi oluşturan verilerden eksiksiz bir kesit (genellikle son yıllardan veya aylardan oluşan) alınarak analiz yapılacak zaman serisi oluşturulur (Atlas, 2000). Zaman serisi için geçerli bir model kurulur kurulmaz uygun bir öngörü tekniği geliştirilebilir (Montgomery ve Ark., 1990).

## **2.2. 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 izleyen alt bölümlerde ele alınmıştır.

### **2.2.1. Dört unsurdan meydana gelme özelliği**

Zaman serilerinin konularından biri olan iktisadi zaman serilerinde, gözlem değerleri düzenli artış veya azalış yerine bazı dalgalanmalar gösterir. Başka bir deyişle seri değerlerinde bir takım inip çıkmalar vardır. Zaman serilerinin değerlerinde görülen bu dalgalanmaların analizi büyük önem taşır. Özellikle de bu dalgalanmaların gelecekte aynen devam edip etmeyeceğinin tahmin edilmesi önemlidir.

Zaman serisi analizinde, gözlem değerlerinde meydana gelen dalgalanmaların dört faktörün etkisinden kaynaklandığı varsayılmaktadır. Bu dört faktör, “Trend, Mevsimsel Dalgalanmalar, Konjonktürel Dalgalanmalar ve Düzensiz (Rassal) Dalgalanmalar” olarak sayılabilir (Atlas, 2000). Bu unsurların her biri kısaca aşağıda ifade edilmiştir.

## **Trend:**

Hemen hemen her zaman serisini etkileyen çeşitli faktörler vardır. Bu faktörlerin etkisiyle seri az çok bir sapma gösterirse de, uzun bir sürede faaliyetin ana eğilimi sabit bir durum gösterebilir. Bir zaman serisinin uzun bir sürede belli bir yöne doğru gösterdiği genel eğilime uzun devre eğilimi (trend) veya ana eğilim adı verilir (Serper, 2000).

Nüfus artışı, teknolojik değişme, sermaye stokunun büyümesi, zevk, tercihler ve tüketim kalıplarında değişmeler gibi faktörlerin etkisi ile seri uzun dönemde artma veya azalma eğilimi gösterebilir. Bu eğilimin ortaya çıkarılabilmesi için zaman serisinin oldukça uzun bir dönemde takibi gerekir (Korum, 1972).

Trendin yön ve şiddet açısından hep aynı kaldığı söylenemez. Bağlı olduğu faktörlerin şiddet derecesindeki değişmelere göre trenddeki artış (veya azalış) bazen yavaşlayabilir. Başka bir deyişle trend doğrusal olabileceği gibi eğrisel de olabilir (Yılmaz, 2004).

## **Mevsimsel Dalgalanmalar:**

Mevsimsel dalgalanmalar, aylık gözlem değerlerinden oluşan zaman serilerinin birbirini izleyen yılların aynı aylarında maksimuma veya minimuma ulaşma eğilimi olarak ifade edilir (Özmen, 1986). Başka bir deyişle bir zaman serisinin, birbirini izleyen yılların aynı aylarında göstermiş olduğu aynı veya benzer dalgalanmalar, mevsimsel dalgalanmalar olarak ifade edilir (Atlas, 2000).

Mevsimsel dalgalanmalar genellikle doğal ve sosyo-ekonomik nedenlerden ortaya çıkar. Bir malın satış, tüketim ve fiyatında hava koşulları ve alışkanlıklar nedeniyle mevsimlik değişmeler meydana gelebilir (Yılmaz, 2004). Örneğin özel şahısların tükettiği elektrik, kış aylarında gündüzlerin kısalığı ve ısınma amacı ile artar. Şemsiye satışları ilkbahar ve sonbaharda artar, yazın azalır. Turist mevsiminde turizm gelirlerinde belli bir artma görülür (Korum, 1972). Dondurma ve kolanın tüketimi dolayısıyla üretimi yaz aylarında çok fazla iken kışın azalır. Buna karşın ısınma giderleri kış aylarında daha çok olur. Mevsimsel dalgalanmalar hem döngüsel hem de periyodiktir (Atlas, 2000).



### **Konjonktürel Dalgalanmalar:**

Zaman serisinin trend doğrusu veya eğrisi etrafındaki uzun dönem dalgalanmalarına konjonktürel dalgalanmalar denir. İktisatta ve işletmecilikte bolluk, durgunluk, depresyon ve yükselme devreleri konjonktürel dalgalanmalar olarak adlandırılır (Atlas, 2000).

Yılın mevsimleri gibi konjonktürel dalgalanmaların da mevsimleri vardır. Sözelimi yatırım artışlarının üretim artışlarına ve üretim artışlarının gelir artışlarına yol açmasıyla iktisadi durumda bir süre bir gelişme görülür. Gelişmenin maksimum aşamasında bir kriz patlak verir. Sonra düşüş başlar. İzleyen aşamada işler belli bir düzeyde bir süre hareketsiz kalır. Daha sonra işler yeniden bir kıvılda ve canlanma gösterir. Bu aşamalar tekrarlanır gider. Konjonktürel dalgalanmalar döngüsel ama periyodik değildir (Serper, 2000).

### **Düzensiz (Rassal) Hareketler:**

Rassal nedenlerle veya geçici olarak ortaya çıkan hareketlere düzensiz hareketler adı verilir. 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. Düzensiz hareketler düzenlilik göstermedikleri ve rassal veya geçici oldukları için, bunların ne zaman ve ne şiddetle ortaya çıktıkları (kabaca bile olsa) önceden tahmin edilemezler (Serper, 2000).

#### **2.2.2. İç bağımlılık özelliği**

Bir zaman serisinde gözlem değerleri birbirine bağlıdır. Zaman değişkeninin konumları bulunulan zamana, geçmişe veya geleceğe ait olabilir. Bu nedenle zaman serisi çözümlemesinde üç dönem söz konusudur. Çözümüne zaman serisindeki en son gözlem değerinin ait olduğu döneme bugünkü dönem denir ve  $t$  ile gösterilir. Bu döneme ait gözlem değerleri  $X_t$  ile simgelenir. Zamana bağlı bu olayın  $t$  dönemine kadar olan tarihsel gelişimi gösteren döneme geçmiş

dönem denir, geçmiş dönem ve geçmiş dönem değerleri sırasıyla  $t-1$ ,  $t-2$ , ... ve  $X_{t-1}$ ,  $X_{t-2}$ , ... şeklinde simgelenir. 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  $t+1$ ,  $t+2$ , ... ve  $X_{t+1}$ ,  $X_{t+2}$ , ... şeklinde ifade edilir.

Zaman serilerinin bu üç dönemde aldığı değerler birbirleriyle ilişkilidir. Bu ilişki zaman serilerinin iç bağımlılık özelliğidir (Yılmaz, 2004).

### 2.2.3. Stokastik süreç olma özelliği

Zamana bağlı olaylar rassal 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 (Box ve Jenkins, 1970).

Başka bir deyişle zaman serileri analizinde, serilerin stokastik süreç olarak kabul edildikten sonra analiz için stokastik modeller kullanılması gerekmektedir. Bu da zaman 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 (Yılmaz, 2004).

### 2.3. Box-Jenkins Modelleri

Box-Jenkins (B.J.) yöntemi, tek değişkenli zaman serilerinin ileriye dönük tahmininde kullanılan yöntemlerden biridir. Bu yöntem, eşit zaman aralıklarıyla elde edilen gözlem değerlerinden meydana gelen kesikli ve durağan zaman serilerinin ileriye dönük tahmin modellerinin kurulmasında ve tahminlerin yapılmasında sistemli yaklaşım göstermektedir (Mabert ve Radeliffe, 1974). Box-Jenkins modelleri incelenen zaman serilerinin durağan olup olmaması ve mevsim unsurunu içerip içermemesi durumlarına göre doğrusal durağan stokastik modeller, durağan olmayan doğrusal stokastik modeller ve mevsimsel modeller olmak üzere izleyen alt bölümlerde ele alınmıştır.

### 2.3.1. Doğrusal durağan stokastik modeller

Uygulamada durağan zaman serilerinin modellenmesinde kullanılan B.J. yönteminin önemli doğrusal durağan stokastik tahmin modelleri otoregresif (AR), hareketli ortalama (MA) ve otoregresif hareketli ortalama (ARMA) modelleridir (Özmen, 1986).

#### Otoregresif Modeller (AR):

Bu modeller bir zaman serisinin herhangi bir dönemindeki gözlem değerini, aynı serinin ondan önceki belirli sayıda dönemin (geçmiş dönemin) gözlem değerlerine ve hata terimine bağlı olarak açıklayan modellerdir. Başka bir deyişle AR modeller bir zaman serisinin herhangi bir dönemindeki gözlem değerini, aynı serinin ondan önceki belirli sayıda dönemin gözlem değerinin ve hata teriminin doğrusal bir bileşimi olarak ifade eden modellerdir.

AR modeller içerdikleri geçmiş dönem gözlem değeri sayısına göre isimlendirilirler. AR modeli bir tane geçmiş dönem gözlem değeri içeriyorsa “birinci dereceden”, iki tane geçmiş dönem gözlem değeri içeriyorsa “ikinci dereceden” ve genel olarak  $p$  tane geçmiş dönem gözlem değeri içeriyorsa  $p$ ’inci dereceden AR modeli söz konusudur (Naylor ve Ark., 1972).

Bir zaman serisinin gözlem değerleri kümesi  $\{X_t\}$  olarak verilsin. Bu durumda hata terimleri kümesi  $\{a_t\}$ ’nin ortalaması sıfır ve varyansı  $\sigma_a^2$  olan rassal bir değişken olduğu varsayalım. Bu varsayım altında bu zaman serisinin herhangi bir  $t$  dönemine ait  $X_t$  gözlem değeri,  $X_{t-1}$ ,  $X_{t-2}$ , ...,  $X_{t-p}$  gibi  $p$  sayıda geçmiş dönem gözlem değeri ve  $a_t$  hata terimi tarafından açıklanıyorsa veya sözü edilen sayıdaki geçmiş dönem gözlem değeri ile  $a_t$ ’nin doğrusal bir bileşimi olarak ifade ediliyorsa, bu model  $p$ ’inci dereceden AR modeldir ve kısaltılarak  $AR(p)$  şeklinde gösterilir.

$AR(p)$  modelinin genel ifadesi şöyledir:

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + a_t. \quad (2.1)$$

Burada  $x_t, x_{t-1}, x_{t-2}, \dots, x_{t-p}$  küçültülmüş gözlem değerleridir. Bu değerler her gözlem değerinin bu değerlerin aritmetik ortalaması olan  $\mu$  'den farkı alınarak ( $x_t = X_t - \mu$  gibi) elde edilir.  $\phi_1, \phi_2, \dots, \phi_p$  modelin parametreleridir. Bu parametreler  $t$  dönemine (bugünkü döneme) ait gözlem değeri  $x_t$  ile geçmiş dönem gözlem değerleri  $x_{t-1}, x_{t-2}, \dots, x_{t-p}$  arasındaki ilişkiyi gösteren “ilişki katsayılarıdır”.  $p$  modelin derecesidir ve  $a_t$  bağımsız bir süreç oluşturan, normal dağılmış hata değişkenidir.

(2.1) numaralı AR( $p$ ) modeli, tahmin edilmesi gereken  $p+2$  sayıda ( $\mu; \phi_1, \phi_2, \dots, \phi_p$  ve  $\sigma_a^2$ ) parametre içerir ve daha çok çoklu regresyon modeline benzer (Chatfield, 1980). Ancak AR( $p$ ) modeli çoklu regresyon modelinde olduğu gibi bağımlı bir değişken ile bu değişkeni açıklayan bağımsız değişkenler arasındaki ilişkiyi ortaya koyan bir model değildir. Aynı değişkenin belirli bir  $t$  dönemine ait gözlem değeri ile ondan önceki dönemlere ait gözlem değerleri arasındaki ilişkiyi açıkladığı için çoklu regresyon modelinden ayrılır ve “otoregresif model” adını alır.

Literatürde sıkça kullanılan AR modelleri birinci ve ikinci dereceden modellerdir ve kısaltılmış olarak sırasıyla AR(1) ve AR(2) şeklinde simgelenir.

AR(1) modelinde bir zaman serisinin  $t$  dönemine ait gözlem değeri  $x_t, t-1$  döneminin gözlem değeri  $x_{t-1}$  ve  $a_t$  hata terimiyle açıklanır:

$$x_t = \phi_1 x_{t-1} + a_t. \quad (2.2)$$

Benzer şekilde AR(2) modeli

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + a_t \quad (2.3)$$

denklemleriyle gösterilir (Özmen, 1986).

## Hareketli Ortalama Modelleri (MA):

MA modeller, bir zaman serisinin herhangi bir dönemdeki gözlem değerini, aynı dönemdeki hata terimi ve ondan önceki belirli sayıda dönemin hata terimine bağlı olarak açıklayan modellerdir. Başka bir deyişle, bir zaman serisinin herhangi bir dönemdeki gözlem değerinin, aynı dönemin hata terimi ve belirli sayıda geçmiş dönemin hata terimlerinin doğrusal bir bileşimi olarak ifade edildiği modeller hareketli ortalama (MA) modelleridir (Naylor ve Ark., 1972).

MA modelleri içerdikleri geçmiş dönem hata terimi sayısına göre birinci dereceden, ikinci dereceden ve genel olarak  $q$ 'uncu dereceden MA modelleri olarak adlandırılırlar.

Bir zaman serisinin gözlem değerleri kümesi  $\{X_t\}$  olarak verilsin. Bu durumda hata terimleri kümesi  $\{a_t\}$ 'nin ortalaması sıfır ve varyansı  $\sigma_a^2$  olan rassal bir değişken olduğu varsayalım. Bu varsayım altında bu zaman serisinin herhangi bir  $t$  dönemine ait  $X_t$  gözlem değeri,  $t$  dönemine ait ve  $q$  sayıda geçmiş döneme ait hata teriminin doğrusal bir bileşimi olarak ifade ediliyorsa bu model  $q$ 'uncu dereceden MA modelidir ve  $MA(q)$  simgesiyle gösterilir.

$MA(q)$  modelinin genel ifadesi şöyledir:

$$x_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}. \quad (2.4)$$

Burada  $x_t = X_t - \mu$  olarak alınmıştır.  $x_t$   $t$ 'inci döneme ait gözlem değerini (küçültülmüş gözlem değerini) gösterir.  $\theta_1, \theta_2, \dots, \theta_q$  modelin parametreleridir, bunlar  $x_t$  ile  $a_t, a_{t-1}, a_{t-2}, \dots, a_{t-q}$  arasındaki ilişkiyi gösteren katsayılardır.  $q$ , MA modelinin derecesini gösterir.  $MA(q)$  modelinde hesaplanması gereken parametre sayısı ( $\mu; \sigma_a^2; \theta_1, \theta_2, \dots, \theta_q$  olmak üzere)  $q+2$  tanedir.

Literatürde sıkça kullanılan MA modelleri birinci derece ( $q=1$  için) ve ikinci derece ( $q=2$  için) modeldir; bu modeller sırasıyla  $MA(1)$  ve  $MA(2)$  şeklinde simgelenir.

MA(1) modelinin yazımı

$$x_t = a_t - \theta_1 a_{t-1} \quad (2.5)$$

şeklinde olur. Bu fark denklemini biçimindeki yazılımdan anlaşılacağı gibi MA(1) modelinde bir zaman serisinin  $x_t$  gözlem değeri  $t$ ,  $t-1$  dönemlerinin hata terimlerinin doğrusal bir bileşimidir.

MA(2) modelinde  $x_t$  gözlem değeri  $t$ ,  $t-1$ ,  $t-2$  dönemlerine ilişkin hata terimlerinin doğrusal bir bileşimi olarak ifade edilir. MA(2) modelinin yazılımı

$$x_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} \quad (2.6)$$

şeklindedir (Özmen, 1986).

### **Otoregresif Hareketli Ortalama Modeller (ARMA):**

ARMA modelleri AR ve MA modellerinin bir birleşimidir. Bu nedenle ARMA modellerine karışık modeller denir. Bu modellerde bir zaman serisinin herhangi bir dönemine ait gözlem değeri, ondan önceki belirli sayıda gözlem değerinin ve hata teriminin doğrusal bir bileşimi olarak ifade edilir. Eğer ARMA modeli  $p$  terimli AR ve  $q$  terimli MA modelinin bir birleşimi ise  $p+q$  terim içerir ve ARMA( $p, q$ ) şeklinde yazılır.

Bir zaman serisinin gözlem değerleri kümesi  $\{X_t\}$  ve hata terimleri kümesi  $\{a_t\}$  olarak verilsin. Bu zaman serisinin herhangi bir  $t$  dönemine ait  $X_t$  gözlem değeri,  $X_{t-1}$ ,  $X_{t-2}$ , ...,  $X_{t-p}$  gibi  $p$  sayıda geçmiş dönem gözlem değeri ve  $a_t$ ,  $a_{t-1}$ ,  $a_{t-2}$ , ...,  $a_{t-q}$  gibi  $q$  sayıda geçmiş dönem hata teriminin doğrusal bir bileşimi olarak ifade ediliyorsa, bu model  $p+q$  sayıda terim içerdiği için ( $p, q$ )'uncu dereceden ARMA modelidir.

ARMA( $p, q$ ) modelinin genel gösterimi fark denklemini biçiminde

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.7)$$

veya

$$x_t - \phi_1 x_{t-1} - \phi_2 x_{t-2} - \dots - \phi_p x_{t-p} = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.8)$$

şeklinde ifade edilir.

Literatürde sık karşılaşılan ARMA model türü ARMA(1,1) modelidir. Bu model birinci dereceden ( $p=1$ ) AR ve birinci dereceden ( $q=1$ ) MA modelinin birleşimidir. ARMA(1,1) modelinin denklemi,

$$x_t - \phi_1 x_{t-1} = a_t - \theta_1 a_{t-1} \quad (2.9)$$

veya

$$x_t = \phi_1 x_{t-1} + a_t - \theta_1 a_{t-1} \quad (2.9)$$

şeklinde yazılabilir (Özmen, 1986).

### 2.3.2. Durağan olmayan doğrusal stokastik modeller (ARIMA)

Buraya kadar ele alınmış olan B.J. modelleri sadece durağan zaman serileri analizinde kullanılan modellerdir. Ancak uygulamada karşılaşılan serilerin çoğu, özellikle ekonomik zaman serileri durağan değildir. Bu serilerin durağanlığı trend, mevsimsel ve konjonktürel dalgalanmalar ve düzensiz hareketler gibi rassal etkenler tarafından bozular. Bu etkenlere rağmen zaman serilerinin çoğunda yine homojenlik görülmektedir (Box ve Jenkins, 1970). Başka bir ifadeyle serinin farklı kısımları benzer eğilim gösterebilir. Homojen durağan olmayan zaman serilerinin modellenmesi, seride durağanlığın sağlanmasına bağlıdır. Durağanlığın sağlanması için söz konusu etkenlerin önce belirlenmesi sonra da arındırılması, kısaca durağan olmayan bir zaman serisinin durağan hale dönüştürülmesi gerekir.

Bir zaman serisinin gözlem değerleri bu serinin ortalama değeri etrafında durağan değilse, serinin uygun derecede farkları alınarak durağanlık sağlanır (Johnson ve Montgomery, 1974). Fark alma derecesi  $d$  ile simgelenir ve uygulamada  $d$  genellikle bir ve en çok iki değerini alır. Bu fark alma derecesi mevsimsel olmayan zaman serileri içindir.

Durağan olmayan ancak fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modellere entegre modeller veya durağan olmayan stokastik modeller adı verilir.

Durağan olmayan doğrusal modeller, belirli sayıda ( $d$  sayıda) farkı alınmış olan serilere uygulanan AR ve MA modellerinin bir birleşimi olan modellerdir. Eğer otoregresyon parametresi olan  $\phi(B)$ 'nin derecesi  $p$ , hareketli ortalama parametresi  $\theta(B)$ 'nin derecesi de  $q$  ise ve  $d$  kez fark alma işlemi yapılmışsa, bu modele  $(p, d, q)$  dereceden otoregresif entegre hareketli ortalama modeli adı verilir ve ARIMA( $p, d, q$ ) şeklinde yazılır (Box ve Jenkins, 1970).

Genel olarak ARIMA( $p, d, q$ ) modeli

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.10)$$

şeklinde ifade edilir. Bu eşitlik, (2.7) eşitliğinde  $x_t$ 'nin yerine bunların farkı olan  $\nabla^d x_t = w_t$  ifadesinin getirilmesiyle elde edilmiştir. Burada;

$\nabla$  = Fark alma işlevi,

$d$  = Fark alma derecesi,

$\{w_t\}$  = Farkı alınmış seridir.

Eğer birinci farklar ( $d = 1$ ) seriyi durağan hale getiriyorsa  $\nabla$

$$\nabla x_t = w_t = x_t - x_{t-1} \quad (2.11)$$

şeklinde gösterilir. Bu gösterim  $B$  işlevi kullanarak



$$\nabla x_t = x_t - x_{t-1} = (1-B)x_t \quad (2.12)$$

şeklinde yazılır.

Eğer  $d$  'inci farklar seriyi durağan hale getiriyorsa  $\nabla$  fark alma işlevi

$$\nabla^d x_t = w_t = (1-B)^d x_t \quad (2.13)$$

şeklinde ifade edilir.

Eğer fark alma derecesi  $d=0$  olduğunda, başka bir ifadeyle seri orijinal değerler itibariyle durağan ise, (2.10) eşitliği, özel bir durum olarak daha önce incelenen AR, MA ve ARMA modellerini içerir (Box ve Jenkins, 1970).

Uygulamada sık karşılaşılan ve  $d \geq 1$  koşulunu sağlayan bazı ARIMA modelleri fark denklemi şeklinde ve  $B$  işlevi kullanılarak ifade edilebilir. Bu modellerden ARIMA(0,1,1) modeli;

$$\nabla x_t = a_t - \theta_1 a_{t-1} \quad (2.14)$$

veya

$$\nabla x_t = (1 - \theta_1 B) a_t \quad (2.15)$$

eşitliğiyle yazılır. Bu modelde  $p=0$ ,  $d=1$ ,  $q=1$ ,  $\phi(B)=1$  ve  $\theta(B)=1 - \theta B$  'dir. ARIMA(0,2,2) modeli;

$$\nabla^2 x_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} \quad (2.16)$$

veya

$$\nabla^2 x_t = (1 - \theta_1 B - \theta_2 B^2) a_t \quad (2.17)$$

eşitliği ile gösterilir. Bu modelde  $p=0$ ,  $d=2$ ,  $q=2$ ,  $\phi(B)=1$  ve  $\theta(B)=1-\theta_1B-\theta_2B^2$ 'dir (Özmen, 1986).

### 2.3.3. Mevsimsel modeller

Aylık veya üç aylık zaman aralıklarına ait gözlem değerlerinden oluşan zaman serilerinin birbirini izleyen yılların aynı aylarında/dönemlerinde maksimuma ve minimuma ulaşma eğilimi mevsimsel dalgalanmaları ifade etmektedir. Doğal ve sosyal nedenler sonucu ortaya çıkan ve her yıl düzenli olarak tekrar eden bu dalgalanmaları içeren serilere mevsimsel zaman serileri adı verilir. Mevsimsel dalgalanmaların dalga uzunluğu  $s$  ile gösterilir, aylık gözlem değerlerinden meydana gelen serilerde genellikle  $s=12$ 'dir. Ancak 6 aylık ( $s=6$ ) periyoda sahip mevsimsel dalgalanmalara rastlanabilir. Üçer aylık aralıklarla yapılan gözlem değerlerinden oluşan serilerde  $s=4$ 'tür.

Mevsimsellik zaman serilerinin durağanlığını bozan unsurlardan biridir, bu serilerde durağanlığın sağlanması için serinin mevsim etkisinden arındırılması gerekir (Kendal ve Ark., 1983). Bu amaçla gözlem değerlerinin  $s$ 'inci dereceden farkı alınması gerektiğinden, mevsimsel serilerin modellenmesinde  $s$ 'nin bilinmesi önemlidir. Bu fark alma işlemi biçiminde gösterilir. Mevsimsel serilerin modellenmesi (2.10) eşitliğindeki genel ARIMA modelinden yararlanarak yapılır. Ancak yapılacak mevsimsel model hem veri düzeyindeki değişimleri hem de mevsimlerin etkisiyle oluşan değişimleri yansıtabilmelidir. Çünkü bir zaman serisi hem trende sahip olabilir, hem de mevsimsel dalgalanmalar içerebilir. Bu tür özellikte bir zaman serisinin gözlem değerleri arasında iki türlü ilişki vardır. Bunlar birbirini izleyen gözlem değerleri arasındaki ilişki ve birbirini izleyen yılların aynı aylarına ait gözlem değerleri arasındaki ilişki, başka bir ifadeyle mevsimsel ilişkidir.

Mevsimsel zaman serilerinin analizinde kullanılan ve bu iki türlü ilişkiye yer veren model,

$$\phi_p(B)\phi_p(B^s)\nabla^d\nabla_s^D x_t = \theta_q(B)\theta_q(B^s)a_t \quad (2.18)$$

şeklinde yazılabilir ve çarpımsal model adı verilir (Naylor ve Ark., 1972). Bu modelde;

- $\phi$ : Mevsimsel otoregresyon parametresini,
- $\theta$ : Mevsimsel hareketli ortalama parametresini,
- $s$ : Mevsimsel dalgalanmaların dalga uzunluğunu,
- $D$ : Mevsimsel fark alma derecesini,
- $p$ : Mevsimsel otoregresif model derecesini,
- $q$ : Mevsimsel hareketli ortalama model derecesini,

$\phi_p(B^s)$  ve  $\theta_q(B^s)$  sırasıyla  $p$  ve  $q$  dereceden  $B$ 'nin polinomlarını gösterir.

Diğer taraftan

- $\nabla_s^D$ : Mevsimsel fark alma operatörü,
- $\nabla^d$ :  $d$ 'inci dereceden fark alma operatörüdür.

Genel mevsimsel modelin derecesi, mevsimsel ve mevsimsel olmayan modellerin derecelerinin çarpımıdır ve  $(p,d,q)(P,D,Q)$  şeklinde gösterilir.  $(p,d,q)$  mevsimsel olmayan modelin derecesini,  $(P,D,Q)$  ise mevsimsel modelin derecesini ifade eder.

İktisadi olaylarla ilgili zaman serilerinin çoğunda tahmin amacıyla kullanılan çarpımsal model, derecesi  $(0,1,1)(0,1,1)_{12}$  olan ARIMA modelidir (Box ve Jenkins, 1970). Derecesi  $(0,1,1)$  olan model, ARIMA modellerinden birinci derece entegre hareketli ortalama modelidir ve

$$\nabla x_t = w_t = (1 - \theta B) a_t \quad (2.19)$$

şeklinde gösterilir. Derecesi  $(0,1,1)_{12}$  olan model, birinci dereceden mevsimsel hareketli ortalama modelidir ve

$$\nabla_{12}x_t = (1 - \theta B^{12})a_t \quad (2.20)$$

şeklinde ifade edilebilir. Denklem (2.19) ve (2.20)'den yararlanarak derecesi  $(0,1,1)(0,1,1)_{12}$  olan çarpımsal modelin yazımı

$$\nabla\nabla_{12}x_t = (1 - \theta B)(1 - \theta B^{12})a_t \quad (2.21)$$

şeklinde olur. Aynı modelin daha açık gösterimi ise,

$$(x_t - x_{t-1}) - (x_{t-12} - x_{t-13}) = a_t - \theta a_{t-1} - \theta a_{t-12} - \theta a_{t-13} \quad (2.22)$$

biçimindedir. Bu modele birinci dereceden çarpımsal mevsimsel hareketli ortalama adı verilir (Özmen, 1986).

## 2.4. Zaman Serisi Analizinde Kullanılan Araçlar

Zaman serisi analizinde kullanılan araçlardan otokovaryans fonksiyonu, otokorelasyon fonksiyonu (A.C.F.), kısmi otokorelasyon fonksiyonu (P.A.C.F.) ve ortalama-standart sapma serpilme grafiği izleyen alt bölümlerde ifade edilmiştir.

### 2.4.1. Otokovaryans fonksiyonu

Bu fonksiyon 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 oluşturan önemli fonksiyonlardan birisidir.

Bir zaman serisinin  $X_t$  ile  $X_{t+k}$  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 adı verilir.

Otokovaryans katsayısı  $k$  gecikmesi için

$$\gamma(k) = Kov(X_t, X_{t+k}) = E[(X_t - E(X_t))(X_{t+k} - E(X_{t+k}))] \quad (2.23)$$

veya

$$\gamma(k) = E[(X_t - \mu)(X_{t+k} - \mu)] \quad (2.24)$$

biçiminde belirlenir.

İncelenen zaman serisine dayanarak  $\gamma(k)$  otokovaryans fonksiyonunun tahmini  $c(k)$  ile gösterilir.  $c(k)$ , (2.27)'de ifade edildiği şekilde hesaplanır (Özmen, 1986).

#### 2.4.2. Otokorelasyon fonksiyonu

Tek değişkenli zaman serisi çözümlemesinde kullanılan en önemli araç, otokorelasyon fonksiyonudur. A.C.F., serinin durağan olup olmadığının ve seri durağan değilse, durağanlığı bozan etkenlerin belirlenmesinde, ARIMA modellerin tanımlama ve uygunluğunun sınanmasında kullanılır.

Bir zaman serisinin,  $X_t$  ve  $X_{t+k}$   $k$  gecikmeli değerleri arasındaki ilişkinin standartlaştırılmış ölçümüne otokorelasyon katsayısı ve bu katsayıların  $k$  gecikmesine bağlı olarak ifadesine de otokorelasyon fonksiyonu denir (Cryer, 1986). A.C.F., anakütle için  $\rho_x(k)$  ile gösterilir ve şöyle tanımlanır:

$$\rho_x(k) = \frac{E[(X_t - \mu_x)(X_{t+k} - \mu_x)]}{E[(X_t - \mu_x)^2]}, \quad k = 0, \pm 1, \pm 2, \dots \quad (2.25)$$

veya

$$\rho_x(k) = \frac{\gamma_x(k)}{\sigma_x^2} = \frac{\gamma_x(k)}{\gamma_x(0)}, \quad k = 0, \pm 1, \pm 2, \dots \quad (2.26)$$

Örnekleme zaman serisine dayanarak, daha sonraki bölümde ele alınan otokovaryans fonksiyonu  $\gamma_x(k)$ 'nin tahmini  $c(k)$  ve  $\rho_x(k)$ 'nin tahmini de  $r(k)$  ile gösterilir. Ayrıca, otokorelasyon fonksiyonu gecikmenin simetrik fonksiyonu olduğundan,  $\rho_x(k) = \rho_x(-k)$ 'dir ve pozitif gecikmeler için aşağıdaki gibi hesaplanır:

$$c_x(k) = \frac{1}{n} \sum_{t=1}^{n-k} (X_t - \bar{X})(X_{t+k} - \bar{X}), \quad k = 0, 1, 2, \dots, n \quad (2.27)$$

$$r_x(k) = \frac{c_x(k)}{c_x(0)}, \quad k = 0, 1, 2, \dots, n. \quad (2.28)$$

A.C.F.'na dayanarak, incelenen zaman serisinin içerdiği etkenlerin belirlenmesi ve bu etkenlerin, rassal etkenden ayırt edilebilmesi için, rassal serinin otokorelasyon katsayılarının örnekleme dağılımından yararlanır. Rassal serinin  $k = 0, 1, 2, \dots$  gecikmeleri için hesaplanan otokorelasyon katsayılarının örnekleme dağılımının ortalaması sıfır ve standart hatası da yaklaşık olarak  $1/\sqrt{n}$ 'dir (Box ve Jenkins, 1970). 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  $z_\alpha$ , kabul edilen anlam düzeyine göre, serinin kritik değerini gösterir. Aynı yolla, belirlenen modelin uygunluğunun sınaması da yapılır. Tek fark,  $X_t$ 'ler yerine  $a_t$ 'ler kullanılır. Burada,  $a_t$ 'ler artık serisi değerleridir (Aslanargun, 1996).

### 2.4.3. Kısmi otokorelasyon fonksiyonu

Zamana bağlı bir değişkenin şimdiki değeri  $X_t$ 'nin, diğer zaman gecikmelerinde etkisi sabit kalmak üzere, önceki  $X_{t-k}$  değerleriyle ilişkisini

tanımlamada kullanılan ölçüme  $k$  gecikmesi için kısmi otokorelasyon katsayısı denir ve  $\phi_{kk}$  ile gösterilir (Makridakis ve Wheelwright, 1978).

Zaman serisi çözümlemesinde, seriye uygun olarak belirlenecek AR modelinin derecesi A.C.F.'na bakılarak belirlenemez. Çünkü çok sayıda gecikme için anlamlı otokorelasyon katsayısı vardır. Oysa  $p$ 'inci dereceden bir AR modeli için, P.A.C.F.'nda  $p$  tane istatistiksel olarak sıfırdan farklı kısmi otokorelasyon katsayısı vardır. Diğer gecikmelerde kısmi otokorelasyon katsayıları sıfırdan farklı değildir. Örneğin, bir zaman serisi için P.A.C.F.'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)'dir.

Genel olarak,  $k$ 'inci dereceden AR sürecinde  $j$ 'inci katsayı  $\phi_{kj}$  ve son katsayı da  $\phi_{kk}$  ile gösterilir.  $\phi_{kk}$ 'ların denklemler kümesi, Yule-Walker denklemler sistemi şeklinde yazılıp çözümlenebilir (Box ve Jenkins, 1970). Bu sistem

$$\rho_j = \phi_{k1}\rho_{j-1} + \dots + \phi_{k(k-1)}\rho_{j-k+1} + \phi_{kk}\rho_{j-k}, \quad j = 1, 2, \dots, k \quad (2.29)$$

şeklinde gösterilir. Daha açık olarak şöyle de yazılabilir:

$$\begin{aligned} \rho_1 &= \phi_{k1} + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1} \\ \rho_2 &= \phi_{k1}\rho_1 + \phi_{k2} + \dots + \phi_{kk}\rho_{k-2} \\ &\dots \\ \rho_k &= \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-1} + \dots + \phi_{kk} \end{aligned} \quad (2.30)$$

Yule-Walker denklemler sisteminde  $\rho$ 'ların yerine örneklem otokorelasyon katsayıları olan  $r$ 'ler kullanılıp çözümlene yapılarak  $k$  gecikmeleri için  $\phi_{kk}$ 'lerin kestirimleri bulunur. Kestirilen bu fonksiyona örneklem P.A.C.F. denir (Cryer 1986; Aslanargun 1996).

#### 2.4.4. Ortalama-standart sapma serpilme grafiđi

Varyans durađanlıđı sađlamak iin uygun veri dnüşümünün belirlenmesinde yararlanılan araç, serinin kısmi paralarının ortalamaları ve standart sapmaları arasındaki  $\sigma = k\mu^{1-\lambda}$  ilişkisine dayandırılan ortalama-standart sapma serpilme grafiđidir. Bu grafiđi oluřturmak iin zaman serisi belli alt kümelere ayrılır, her alt küme iin ortalama ve standart sapma hesaplanır ve alt kümelere iliřkin ortalama ve standart sapmalar karřı karřıya getirilir. Bu yolla elde edilen grafiđe, ortalama-standart sapma serpilme grafiđi denir. Alt kümelerin dađılımı, lokal deđiřimi; ortalaması da lokal seviyesini gösterir. Ele alınan zaman serisinin kaar gözlem deđerlik alt kümelere ayrılacađına řöyle karar verilir: Eđer, seride düzenli mevsimsellik varsa, seri mevsimselliđin periyodu kadar gözlem deđerleri ieren alt kümelere ayrılır. Bu yolla alt kümelere iliřkin hesaplanacak standart sapma, mevsimsellikten bađımsızdır. Eđer, seride mevsimsellik yoksa veya düzensiz mevsimsellik varsa, alt kümelerin büyüklüđu mevsimsellikten bađımsız olarak hesaplanır. Genellikle 4-12 arası gözlem deđerleri ieren alt küme büyüklüđu önerilir (Aslanargun, 1996).

#### 2.5. Zaman Serisi Analizinin Ařamaları

Zaman serileri iin uygun B.J. modellerinin seiminde, geliřtirilmesinde ve tahmin amacıyla kullanılmasında yapılacak iřlemleri Box ve Jenkins (1970) bazı ařamalarla ifade etmektedir. Bunlardan birinci ařamada gözlem deđerlerinden meydana gelen gerek seri incelenerek model grubu karřılařtırılır. Model grubundan hangi model tipinin ilgilenilen seri iin uygun olacađına karar verilir. Üüncü ařamada uygun olabileceđine karar verilen modelin parametreleri tahmin edilir. Drdüncü ařamada bu modelin yeterli olup olmadıđı test edilir. Model yeterli ise tahmin amacıyla kullanılır. Model yeterli deđilse, birinci ařamaya dnülür ve aynı iřlemler yeterli bir model belirleninceye kadar tekrarlanır (Özmen, 1986).

Model belirleme ařamaları; modelin belirlenmesi, belirlenen modelin parametrelerinin tahmini, modelin uygunluđunun sınanması ve modelin tahmin



amacıyla kullanımı olarak ifade edilebilir. Bu aşamalar alt bölümlerde ifade edilmiştir.

### **2.5.1. Modelin belirlenmesi**

B.J. yöntemine dayanarak incelenecek olan bir zaman serisi için uygun model belirleme aşamasında yapılacak ilk iş, serinin durağan olup olmadığının belirlenmesidir. B.J. tahmin modellerinin uygulanabilmesi için serinin durağan olması bir varsayımdır. Bu nedenle durağan olmayan serilerin analiz edilmesinde ve tahmininde B.J. modellerinin uygulanabilmesi için seriler belirli sayıda fark alma yöntemiyle durağan hale dönüştürülür.

Bir zaman serisinin durağan olup olmadığını anlamak için başvurulacak basit yol, serinin grafiğini çizmektir. Grafik trend, mevsimsellik gibi unsurların varlığını gösteriyorsa, incelenen serinin durağan olmadığına karar verilebilir. Ancak bu yolla sağlıklı karar vermek güçtür, ilk bakışta durağan görünümde olan seriler, zaman içinde az da olsa değişiklik gösterebilirler.

Zaman serilerinde durağanlığın incelenmesinde güvenilir bir araç, serilerin otokorelasyon fonksiyonları ve bu fonksiyonların korelogramıdır. Eğer gerçek seri için tahmin edilen gecikmeli otokorelasyon katsayılarının değeri birinci ve ikinci gecikmeden sonra istatistiksel açıdan anlamlı olmayan değerler alma ve hızla sifıra yaklaşma eğiliminde ise bu serinin durağan olduğu kabul edilir. Bu durumda uygun modeli durağan B.J. modeller grubunda aramak gerekir.

Bir zaman serisinin grafiği ya devamlı artma ya da devamlı azalma eğiliminde ise veya bu zaman serisi için hesaplanan örneklem otokorelasyon katsayıları birinci, ikinci, üçüncü ve hatta yüksek gecikmelerde sifıra doğru yaklaşma eğiliminde değilse, bu seri durağan olmayan seridir (Box ve Jenkins, 1970). Bu durumda seri için kullanılacak uygun modeli, durağan olmayan B. J. modeller grubunda aramak gerekir.

Durağan olmayan bir serinin analiz edilmesi için durağan hale getirilmesi zorunludur, bunun için serinin birinci farkları alınır. Fark serinin otokorelasyon katsayıları tahmin edilir. Eğer otokorelasyon değerleri birinci veya ikinci gecikmeden sonra hızla sifıra yaklaşıyorsa veya istatistiksel açıdan anlamlı değilse, birinci farklardan meydana gelen serinin durağan olduğuna karar verilir. Eğer birinci dereceden farklar serisinin otokorelasyon katsayıları ilk iki

gecikmeden sonra sifira yaklařmıyorsa ve istatistiksel aıdan anlamlı ise, seride durađanlıđa ulařılmadıđı anlařılır. Durađanlıđın sađlanması iin birinci derece farklar serisinin tekrar farkı veya gerek serinin ikinci dereceden farkı alınması gerekir.

Durađan olmayan bir seriyi fark alma yoluyla her zaman durađan seriye dnüştürmek mümkün olmayabilir. Örneđin zaman serilerinde serinin ortalaması arttıka gözlemlerin deđiřkenlikleri de artar. Ancak bu gibi durumlarda gözlemlerdeki oransal deđiřme, ortalama bir seviyeye göre bađımsızdır. Bu gibi durumlarda gerek serilerin logaritmalarından meydana gelen serileri incelemek daha yararlı olur (Montgomery ve Johnson, 1976).

Analiz edilecek bir zaman serisine hangi model grubunun uygun olacađına karar verebilmek iin serinin durađanlıđı incelendikten sonra mevsimselliđinin de incelenmesi gerekir.

Mevsimsel dalgalanmalar zaman serilerinin durađanlıđını bozan faktörlerden biridir. Bir zaman serisinin grafiđi birbirini izleyen yılların aynı aylarında veya dönemlerinde benzer davranıřlar gösteriyorsa ve bu seri iin tahmin edilen örneklem otokorelasyon katsayılarının deđeri de aynı řekilde birbirini izleyen yılların aynı aylarında veya dönemlerinde istatistiksel aıdan anlamlı olacak řekilde azalma veya artma gösteriyorsa, bu seriler mevsimsel serilerdir.

Mevsimsel serilerin durađan hale getirilmesi iin mevsimsel fark dikkate alınır. Bazen zaman serileri hem mevsimsellik hem de trend gösterirler. Bu durumda bu özelliđe sahip olan serileri durađan hale getirmek iin öncelikle yapılması gereken trendin yok edilmesidir, bařka bir deyiřle birinci veya ikinci derece farkların alınmasıdır.

Durađanlık ve mevsimsellik incelendikten sonra B.J. modeller grubunda hangi model tipinin uygun olacađına karar verilir. Durađan model grubunda  $AR(p)$ ,  $MA(q)$  ve  $ARMA(p,q)$ , durađan olmayan model grubunda  $ARIMA(p,d,q)$  ve mevsimsel model grubunda  $ARIMA(p,d,q)(P,D,Q)$  tiplerinden uygun olan belirlenir (Özmen, 1986).

Model tiplerinin belirlenmesi her model grubu iin ayrı ayrı izleyen paragraflarda ifade edilmiřtir.

İlk olarak durağan modeller grubu ele alındığında, bu grup için üç tip model söz konusudur. Analiz edilecek serinin yapısına ve belirli kriterlere göre bu modellerden birisi seçilir. Modelin seçiminde serinin otokorelasyon ve kısmi otokorelasyon fonksiyonlarının hareketi kriter olarak kullanılır. Durağan modeller arasında seçim yapabilmek için önce analiz edilecek serinin otokorelasyon ve kısmi otokorelasyon fonksiyonları belirlenir ve bunların korelogramı çizilir (Box ve Jenkins, 1970). Bu korelogramların birlikte hareketleri incelenerek Çizelge 2.1.'deki kriterlere göre uygun modelin tipi belirlenir (Özmen, 1986).

**Çizelge 2.1.** Durağan modellerde anakütle ACF ve PACF hareketleri (Özmen, 1986)

Model	Otokorelasyon Fonksiyonu	Kısmi Otokorelasyon Fonksiyonu
$AR(p)$	Üssel ve/veya sinüzoidal bir biçimde azalır.	$p$ gecikmesinden sonra istatistiksel olarak anlamlı değildir.
$MA(q)$	$q$ gecikmesinden sonra istatistiksel olarak anlamlı değildir.	Üssel ve/veya sinüzoidal bir biçimde azalır.
$ARMA(p,q)$	$q - p$ gecikmesinden sonra üssel ve/veya sinüzoidal bir biçimde azalır.	$p - q$ gecikmesinden sonra üssel ve/veya sinüzoidal bir biçimde azalır.

Durağan zaman serisi için hesaplanan otokorelasyon ve kısmi otokorelasyon fonksiyonlarının hareketi Çizelge 2.1.'deki hareket biçimlerinden hangisine uyuyorsa ilgili hareketin karşısına gelen model tipi uygun model olarak alınır.

Durağan olmayan modeller grubu için model tipinin belirlenmesinde; durağan olmayan, ancak mevsimsellik göstermeyen serilerin modellenmesinde kullanılan  $ARIMA(p,d,q)$  grubu modellerden hangi model tipinin incelenen seri için uygun olabileceği ortaya konulmuştur.

$ARIMA(p,d,q)$  modelinin her zaman hem AR hem de MA unsurlarını birlikte bulundurması şart değildir. Eğer genel model  $MA(q)$  unsurunu içermiyorsa, ARIMA modeli  $ARIMA(p,d,0)$  tipi bir modeldir. Genel model

$AR(p)$  unsurunu içermiyorsa, ARIMA modeli  $ARIMA(0,d,q)$  şeklinde gösterilebilir.

$ARIMA(p,d,q)$  grubu model tiplerinden hangisinin incelenen seri için uygun model olacağı belirlenirken yapılacak ilk iş, fark alma yöntemiyle seriyi durağan hale getirmek,  $d$ 'nin değerini belirlemektir. Eğer birinci farkları alınmış seri ( $d=1$ ) durağan hale gelmişse uygun  $ARIMA(p,1,q)$  model tipi durağan modellerdeki gibi belirlenir. Örneğin  $d=1$  için durağan serinin otokorelasyon fonksiyonunun hareketi üssel ve/veya sinüzoidal bir biçimde azalış gösteriyorsa ve kısmi otokorelasyon fonksiyonunun hareketi de  $p$  gecikmeden sonra istatistiksel olarak sıfırdan anlamsız oluyorsa  $ARIMA(p,d,0)$  model tipi benimsenir.  $d=1$  için durağanlık sağlanmışsa, birinci farklar serisinin tekrar farkı alınır ve ikinci farklar serisinin otokorelasyon ve kısmi otokorelasyon fonksiyonları analiz edilir, durağanlığın sağlandığı sonucuna varılırsa  $d=2$  olur.

Son olarak mevsimsel modeller grubunda model tipinin belirlenmesi incelenmiştir. Mevsimsel modeller grubunda model belirlenmesinde yapılan işlemler, daha önce incelenen model gruplarında model belirlenmesi işlemlerine benzemektedir.

İncelenen bir zaman serisi için uygun modelin mevsimsel model olacağına karar verilirse, otokorelasyon ve kısmi otokorelasyon fonksiyonları analiz edilir. Eğer incelenen serinin grafiği, otokorelasyon katsayıları ve korelogramı sadece mevsimsel unsurların varlığını gösteriyorsa, mevsimsel farklar serisi durağan olacaktır. Otokorelasyon ve kısmi otokorelasyon katsayılarının hareketine göre uygun model belirlenir (Özmen, 1986).

### **2.5.2. Belirlenen modelin parametrelerinin tahmini**

İncelenen zaman serisi için uygun modelin tipi belirlendikten sonra örneklem otokorelasyon katsayılarını kullanarak modelin parametre tahminleri yapılır. Parametre tahminleri otokorelasyon katsayıları ile parametreler arasındaki ilişkiyi gösteren denklem sistemlerinin parametreler açısından çözümüyle elde edilir.

Otoregresif modellerde ( $AR(p)$ ) parametrelerin tahminleri aşağıdaki Yule-Walker denklem sisteminin aşamalı olarak  $\phi_p$  için ortak çözümünden elde edilen değerlerdir (Montgomery ve Johnson, 1976). Bölüm 2.4.3.'de ifade edilen Yule-Walker denklem sisteminin örneklem otokorelasyon katsayıları kullanılarak yazılımı şöyledir:

$$r_k = \phi_1 r_{k-1} + \phi_2 r_{k-2} + \dots + \phi_p r_{k-p}. \quad (2.31)$$

Sistemin açık yazılımı:

$$\begin{aligned} r_1 &= \phi_1 + \phi_2 r_1 + \dots + \phi_p r_{p-1} \\ r_2 &= \phi_1 r_1 + \phi_2 + \dots + \phi_p r_{p-2} \\ &\dots \\ r_p &= \phi_1 r_{p-1} + \phi_2 r_{p-2} + \dots + \phi_p. \end{aligned} \quad (2.32)$$

Bu denklem sistemi  $AR(1)$  modeli için çözüldüğünde tahmin edilmesi gereken  $\phi_1$  parametresinin değeri

$$\phi_1 = r_1 \quad (2.33)$$

şeklinde bulunur (Box ve Jenkins, 1970).

Aynı denklem sistemi  $AR(2)$  modeli için çözüldüğünde, tahmin edilmesi gereken  $\phi_1$  ve  $\phi_2$  parametrelerinin değerleri

$$\phi_1 = \frac{r_1(1-r_2)}{1-r_1^2}, \quad \phi_2 = \frac{r_2-r_1^2}{1-r_1^2} \quad (2.34)$$

şeklinde bulunur.  $r_1$  ve  $r_2$ , birinci ve ikinci gecikmelerdeki otokorelasyon katsayılarının değeridir.

Hareketli ortalama ( $MA(q)$ ) modelinde otokorelasyon katsayıları ile model parametreleri arasındaki ilişkiler doğrusal değildir (Johnson ve Montgomery,

1974). MA( $q$ ) modelinin parametreleri (2.35)'in aşamalı olarak  $\theta_1, \theta_2, \dots, \theta_q$  için çözülmesiyle belirlenebilir.

$$r_k = \begin{cases} \frac{-\theta_k + \theta_1\theta_{k-1} + \theta_2\theta_{k-2} + \dots + \theta_{q-k}\theta_q}{1 + \theta_1^2 + \dots + \theta_q^2} & k = 1, 2, \dots, q \\ 0 & k > q. \end{cases} \quad (2.35)$$

Zaman serilerinin analizinde MA(1) ve MA(2) modelleri genellikle yeterli kabul edilmektedir.

ARMA( $p, q$ ) süreci için  $\phi_1, \phi_2, \dots, \phi_p$  parametre değerleri  $p$  sayıda doğrusal eşitlikten meydana gelen denklem sisteminin çözümüyle elde edilir (Box ve Jenkins, 1970). Bu denklem sistemi

$$\begin{aligned} P_{q+1} &= \phi_1 P_q + \phi_2 P_{q-1} + \dots + \phi_p P_{q-p+1} \\ P_{q+2} &= \phi_1 P_{q+1} + \phi_2 P_q + \dots + \phi_p P_{q-p+2} \\ &\dots \\ P_{q+p} &= \phi_1 P_{q+p-1} + \phi_2 P_{q+p-2} + \dots + \phi_p P_q \end{aligned} \quad (2.36)$$

şeklinde ifade edilir. Bu sistemde  $\phi_1, \phi_2, \dots, \phi_p$  değerlerini elde edebilmek için  $P_j$ 'ler yerine bunların tahmini olan örneklem otokorelasyon katsayıları  $r_j$ 'ler konulur. Hareketli ortalama parametre değerleri ise MA( $q$ ) modelinde olduğu gibi aşamalı çözüm yöntemiyle ve  $r_j$ 'ler ile  $\theta_q$ 'lar arasındaki ilişkileri kullanarak hesaplanabilir.

Durağan olmayan modellerin ve mevsimsel modellerin parametre değerlerinin tahmini, durağan modellerin parametre değerlerinin tahminine benzer şekilde yapılır.

Belirlenen uygun modellerin tahmin amacıyla kullanılabilmesi için, bu modellerin son parametre değerlerinin tahmin edilmesi gerekir. Bu parametrelerin en iyi tahmini, en küçük kareler ve maksimum olabilirlik yöntemleriyle elde

edilen, hata kareler toplamı  $\left(\sum_{t=1}^n a_t^2\right)$  değerini minimum yapan tahminlerdir (Naylor ve Ark. 1972; Özmen 1986).

### 2.5.3. Modelin uygunluğunun sınanması

Parametreleri hesaplanan modelin seri için uygun olup olmadığı, uygunluk testiyle belirlenir. Uygunluk testleri için önce parametre değerlerinin modelde yerine konulmasıyla tahminler yapılır. Tahmin hataları serisi oluşturulur. Sonra hatalar serisi için otokorelasyon katsayıları hesaplanır ve bu katsayılar incelenir.

Her hata otokorelasyon katsayısının kendi standart hatasıyla karşılaştırılması, küçük gecikmelerde otokorelasyon katsayılarının sıfırdan anlamlı olacak şekilde farklı olup olmadığını, başka bir ifadeyle modelin uygunluğunu açıkça ortaya koyamaz. Bu nedenle otokorelasyon katsayılarını tek tek incelemek yerine belirli sayıda hata otokorelasyonunu bir arada incelemek modelin uygunluğunu daha açık ortaya koyabilir. Bu amaçla Box-Pierce tarafından geliştirilen Q istatistiği kullanılır (Box ve Jenkins 1970; Özmen 1986).

Q istatistiği 1970 yılında Box ve Pierce (1970) tarafından geliştirilmiş, 1978 yılında Ljung ve Box (1978) tarafından düzeltilmiştir.  $\chi^2$  dağılımına uyan Q istatistiği, parametre kestirimi yapılmış modelin verdiği artık değerlerini test ederek, modelin geçerliliği hakkında bilgi verir.

Box ve Jenkins (1970) hataların ilk 20-25 otokorelasyonuna bir bütün olarak bakmayı sağlayan Q istatistiğinin kullanımını önermiştir. Ancak, Ljung ve Box gözlem sayısının 100'den küçük olması durumunda  $\chi^2$  dağılımının zayıf bir istatistik olması nedeni ile düzeltilmiş Q istatistiğinin kullanılmasını önermektedir (Akgül, 2003).

Q istatistiği, otokorelasyonların ilk m tanesinin sıfırdan farklı olup olmadığını belirlemektedir. Eğer tüm  $\rho_k = 0$  ise süreç tamamen rassaldır. Box ve Pierce'nin önerdiği Q istatistiği,

$$Q = n \sum_{k=1}^m r_k^2, \quad (2.37)$$

şeklindedir. Düzeltilmiş Ljung-Box istatistiği ise,

$$Q^0 = n(n+2) \sum_{k=1}^m \frac{r_k^2}{n-k}, \quad (2.38)$$

biçimindedir. Bu eşitliklerde,

$r_k$  : Örneklem tahmin hatalarının çeşitli gecikmedeki otokorelasyon katsayıları,

$n$  : Gözlem sayısı ( $N - d$ ),

$N$  : Örneklem hacmi,

$d$  : Fark alma derecesi,

$m$  : Test edilecek otokorelasyon katsayısı,

$p$  : AR modelinin derecesi,

$q$  : MA modelinin derecesi

olarak tanımlanmaktadır.

Q istatistiği, hata terimlerinin aralarında otokorelasyon olmadığına ilişkin aşağıdaki,

$$H_0 : \rho_1(\alpha) = \rho_2(\alpha) = \dots = \rho_k(\alpha) = 0 \quad (2.39)$$

hipotezinin kabul edilip edilmeyeceğine karar vermede kullanılır. Eğer hesaplanan Q değeri,

$$Q > \chi_{m-p-q, 1-\alpha}^2 \quad (2.40)$$

ise,  $H_0$  hipotezi red edilir ve modelin geçerli bir model olmadığına karar verilir.

Hesaplanan Q değerinin,

$$Q \leq \chi_{m-p-q, 1-\alpha}^2 \quad (2.41)$$



olması durumunda ise,  $H_0$  hipotezi kabul edilir ve modelin geçerli bir model olduğuna karar verilir (Biçen, 2006).

Q istatistiği için serbestlik derecesi mevsimsel olmayan modellerde  $m-p-q$ , mevsimsel modellerde  $m-P-p-Q-q$  olur. Test sonunda geçerli olduğuna karar verilen model tahmin amacıyla kullanılır. Modelin geçerli olmadığına karar verilmişse uygun model tipinin belirlenmesi aşamasına geri dönülür (Özmen, 1986).

#### 2.5.4. Modelin tahmin amacıyla kullanımı

Bir zaman serisi için uygun model tanımlanıp parametreler tahmin edildikten sonra yapılan uygunluk testleriyle modelin bu zaman serisinin analizi için uygun, yeterli olduğuna karar verilirse, bu model tahminler yapmak amacıyla kullanılabilir.

İncelenen zaman serisinin analizi için uygun olduğuna karar verilen B.J. modeli AR ve MA unsurlarını ayrı ayrı içermiş olabileceği gibi birlikte de içermiş olabilir. Bu nedenle, uygun B.J. modeli incelenen serinin  $t$  dönemine ait  $X_t$  gözlem değerini (seri normal farklarda durağan hale gelmişse  $\nabla^d X_t = W_t$ , mevsimsel farklarda durağan hale gelmişse  $\nabla_s^D X_t = W_t$  gözlem değerini), aynı serinin  $t$  döneminden önceki belirli sayıda geçmiş dönemin ( $t-1, t-2, \dots$ )  $X_{t-1}, X_{t-2}, \dots$  gözlem değerlerine ve/veya  $a_t, a_{t-1}, \dots$  hata terimlerine bağlı olarak tahmin eden bir modeldir.  $X_t$ 'nin tahmin edilmesi için kullanılan uygun model,  $X_{t+1}$ 'in tahmin edilmesi için de kullanılır. B.J. yönteminde  $X_{t+1}$ 'in tahmin edilmesi amacıyla yazılan modele B.J. ileriye dönük tahmin modeli adı verilir.

B.J. ileriye dönük tahmin modeli, incelenen zaman serisinin  $t+1$  döneminde alacağı  $X_{t+1}$  değerinin tahmini olan  $X_{t+1}$ 'i,  $t+1$  döneminden önceki belirli sayıda dönemin tahmin değerlerine, gözlem değerlerine ve/veya hata terimlerine bağlı olarak tahmin eden bir modeldir. Başka bir deyişle bir zaman serisinin analizi için uygun olduğuna karar verilen model AR unsur içeriyorsa bu serinin  $t+1$  döneminde alacağı değer tahmini  $(\hat{X}_{t+1})$ ,  $t+1$  döneminden önceki belirli sayıda dönemin tahmin ve gözlem değerlerine ve  $a_t$  hata terimine bağlı

olarak yapılır. Eğer uygun model MA unsuru içeriyorsa,  $\hat{X}_{t+1}$ ,  $t+1$  döneminden önceki belirli sayıda dönemin tahmin hatalarına dayanarak yapılır. Uygun model AR ve MA unsurlarını birlikte içeriyorsa, bu modele dayanarak  $\hat{X}_{t+1}$ ,  $t+1$  döneminden önceki belirli sayıda dönemin tahmin değerine, gözlem değerine ve bu değerlerle ilgili hesaplanan hata terimlerine dayanarak yapılır.

Durağan zaman serilerine az rastlanıldığı ve bu serilerin analizinde kullanılacak uygun B.J. modellerinin AR ve MA unsurlarını ayrı ayrı veya birlikte içerdiği bilinmektedir. Bu yüzden ileriye dönük tahmin yapma konusunda açıklama yapmak için genel ARIMA( $p, d, q$ ) modelinin ele alınması uygun olmaktadır. Ayrıca bu modele dayanarak ileriye dönük tahminlerin nasıl yapılacağını göstermek için uygulamada sık kullanılan ARIMA(1,1,1) modeli ele alınmıştır.

B.J. yöntemiyle zaman serileri analiz edilirken kullanılacak ARIMA( $p, d, q$ ) ileriye dönük tahmin modeli

$$\nabla^d X_{t+1} = \hat{W}_{t+1} = \phi_1 W_{t+1-1} + \dots + \phi_p W_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.42)$$

şeklinindedir. İncelenen zaman serisi için uygun model ARIMA(1,1,1) ise, bu modelin  $l=1$ ,  $l=2$  için ileriye dönük tahmin değerleri  $\hat{X}_{t+1}$  ve  $\hat{X}_{t+2}$ , aşağıdaki modeller yardımıyla hesaplanabilir:

$$X_{t+1} = \hat{W}_{t+1} = \phi_1 W_t + a_t - \theta_1 a_{t-1}. \quad (2.43)$$

Bu denklemde  $W_t$  yerine  $(X_t - X_{t-1})$ ,  $W_{t+1}$  yerine de  $(\hat{X}_{t+1} - X_t)$  yazılırsa

$$\hat{X}_{t+1} = (1 + \phi_1) X_t - \phi_1 X_{t-1} + \theta_1 a_t \quad (2.44)$$

denklemini elde edilir. ARIMA(1,1,1) uygun modeline dayanarak  $l=2$  için tahmin yapılması istenirse,  $\hat{X}_{t+2}$ 'nin tahmin modeli

$$\hat{X}_{t+2} = (1 + \phi_1) \hat{X}_{t+1} - \phi_1 X_t + a_{t+2} - \theta_1 a_{t+1} \quad (2.45)$$

şeklinde olur.

Elde edilen ileriye dönük tahmin modellerinde  $\hat{X}_{t+l}$  ( $l=1,2,3,\dots$ ) yapılan tahmin değerlerini,  $X_{t-l}$  ( $l=0,1,2,\dots$ ) gözlem değerlerini,  $a_{t+l}$  ( $l=1,2,\dots$ ) tahmin dönemi tahmin hatalarını ve  $a_{t-l}$  ( $l=0,1,2,\dots$ ) gözlem değerleri tahmin hatalarını gösterir (Özmen, 1986).

### 3. YAPAY SİNİR AĞLARI

Bu bölüm, çalışmanın temel konusunu oluşturan YSA teknolojisine ait temel ve teorik bilgileri kapsamaktadır. Teknolojik gelişmenin önemli boyutlara ulaştığı bugün, insanoğlunun kendisini tanımaya yönelik çalışmaları da önemli aşamalar kaydetmiştir. Yapay zekâ (artificial intelligence) kavramı ile insanın en önemli özellikleri olan düşünebilme ve öğrenebilme yetenekleri önemli araştırma konuları durumuna gelmiştir. Özellikle bilgisayar kullanımının hızla yaygınlaşması sonucunda yapay zekâ çalışmaları da bir ivme kazanmıştır.

“İnsanın düşünme yapısını anlamak ve bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışmak” olarak tanımlanan yapay zekâ, aslında programlanmış bilgisayarlara düşünme yeteneği sağlama girişimidir. İnsan gibi düşünen ve davranan sistemlerin geliştirilmesine yönelik olarak 1950’li yıllardan beri süren yapay zekâ çalışmaları, bir noktada insanı taklit etmeye yönelik olduğundan mühendislik, nöroloji ve psikoloji gibi alanlara da yayılmıştır. İnsan gibi düşünebilen ve davranabilen sistemlerin geliştirilmesi için yapılan çalışmalarda gelinen nokta, henüz yapay zekânın tam olarak geliştirilememiş olmasıdır.

Yapay zekâ çalışmaları kapsamında ortaya çıkan ve bir noktada yapay zekâ çalışmalarına destek sağlamakta olan farklı alanlardan bir tanesi de Yapay Sinir Ağları teknolojisidir. İnsan beyninin temel işlem elemanı olan nöronu (neuron) şekilsel ve işlevsel olarak basit bir şekilde taklit eden YSA, bu yolla biyolojik sinir sisteminin basit bir simülasyonu için oluşturulan programlardır. Bu şekilde, insanoğluna özgü deneyerek (yaşayarak) öğrenme yeteneğini bilgisayar ortamına taşıyabildiği düşünülen YSA teknolojisi bir bilgisayar sistemine inanılmaz bir “girdi veriden öğrenme” kapasitesi sağlamaktadır ve birçok avantajlar sunmaktadır. Çeşitli avantajlar sunan ve gün geçtikçe gelişen bu teknolojiden, günümüzde birçok alanda olduğu gibi ekonomi ve istatistik alanlarında da faydalanılmaktadır. Özellikle, “Evrensel Fonksiyon Yakınsayıcı Yöntem (Universal Function Approximators)” olarak tanınmalarından dolayı tahmin ve öngörü gibi verinin içerdiği yapının tanımlanmasını gerektiren alanlarda sıkça kullanılmaktadırlar (Yurtoğlu,2005).

Bu bölümde YSA ile ilgili genel kavramlar, YSA yapısı, YSA’nın temel elemanları, YSA’nın tarihçesi, YSA’nın özellikleri, YSA’nın sınıflandırılması,

bazı YSA algoritmaları, bazı YSA mimarileri, YSA'nın güçlü yanları, YSA'nın uygulama alanları ve bazı tahmin değerlendirme yöntemleri hakkında bilgi verilmektedir.

### **3.1. Yapay Sinir Ağlarının Tanımı**

YSA, insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarıdır (Elmas, 2003). Bir başka deyişle insan beyninin işleyişini taklit eden sistemlerdir (Sağiroğlu ve Ark., 2003). YSA, biyolojik sinir ağlarından esinlenilerek ortaya çıkarılan ve biyolojik sinir ağlarına benzer bazı performans özellikleri içeren bir bilgi işleme sistemidir (Fausett, 1994). YSA, deneyime dayalı bilgiyi depolamaya ve bu bilgileri kullanıma sunmaya yönelik doğal bir eğilim içerisinde olan yoğun paralel dağılmış bir işlemcidir (Haykin, 1999). YSA, insan beyninin işleyişine benzer bir biçimde, bir girdi seti ile bir çıktı setini doğrusal olmayan bir şekilde eşleştirebilen sistemlerdir (Jain ve Martin, 1998).


Literatürde YSA ya da sinir ağları olarak bahsedilen çalışmalar, başlangıçta insan beyni hesaplamalarını tanıma olarak geleneksel bilgisayarlardan tamamen farklı yollarla harekete geçirilmiştir (Haykin, 1999).

YSA ile ilgili çalışmaların temel amaç olarak biyolojik sinir sistemlerinin anlaşılmasına ve matematiksel olarak modellenmesine yönelik çabaları içermesi, öncelikle YSA'nın tarihi gelişimine ve biyolojik sinir ağlarının fizyolojik yapılarının anlaşılmasını gerektirmektedir (Terence, 1999). Bu nedenle izleyen bölümde, YSA'nın biyolojik sinir sistemleri ile benzerliğini ifade etmek için biyolojik sinir ağlarının fizyolojik yapısı ele alınmıştır.

### **3.2. Biyolojik Sinir Ağlarının Fizyolojik Yapısı**

İnsan sinir sistemi çok karmaşık bir ağıdır. Beyin bu sistemin merkezi elemanıdır ve birbirlerine alt ağlarla bağlı nöronlara (sinir hücresi) sahiptir. Sinir hücreleri elektrokimyasal bir işlemle bilgi taşımak için özelleşmiş hücrelerdir. Bu sinir hücreleri değişik şekil ve büyüklükte dirler. Bazıları sadece 4 mikron (4/1000 milimetre) genişliğinde iken 100 mikron genişliğinde olanlar da vardır. Her ne kadar değişik tipteki sinir hücrelerinin şekil ve işlev açısından farklılıkları bulunsa

da hepsinin ortak özelliği hücre gövdesi, dendrit, akson ve akson terminallerinden olmak üzere 4 farklı kısımdan oluşmalarıdır (Guyton ve Hall, 2006). Biyolojik bir sinir hücresinin temel yapısı Şekil 3.1.'de gösterilmiştir (Diamantaras ve Kung 1996; Haykin 1999).



Şekil 3.1. Biyolojik Sinir Hücresinin Temel Yapısı (Diamantaras ve Kung 1996; Haykin 1999)

Dendritler, hücre gövdesinden dışarıya doğru uzanım gösterirler ve diğer sinir hücrelerinin akson sonlanım noktalarındaki kimyasal sinyalleri almak için özelleşmişlerdir (Guyton ve Hall, 2006). Diğer bir deyişle dendritler, bir hücre için girdi kanallarını oluştururlar (Anderson ve McNeill, 1992). Dendritler bu sinyalleri küçük elektriksel akımlara çevirerek hücre gövdesine iletirler. Dendritlerin yüzeyleri düz değildir ve genellikle bir sinir hücresinde çok sayıda dendrit vardır. Aksonların aksine üzerlerini kaplayan sinir kılıfları (myelin) yoktur.

Hücre gövdesi çekirdeği içerir ve tüm sinir hücre proteinlerinin ve zarların üretim merkezi olma görevini üstlenir. (Guyton ve Hall, 2006). Hücre gövdesi, dendritler aracılığıyla gelen sinyalleri işleyerek çıktıya dönüştürür. Hücre gövdesinin ürettiği bu çıktılar ise aksonlar aracılığıyla diğer nöronlara girdi olmak üzere gönderilir (Anderson ve McNeill, 1992). Tüm sinir hücreleri akson adı verilen çapı 1 mikrometreden 1 milimetreye varabilen uzun kollarla diğer sinir hücreleriyle etkileşime girerler. Aksonlar, aksiyon potansiyeli denen bir çeşit

elektriksel akımın hücre gövdesinden akson terminaline iletimini sağlarlar. Akson yüzeyleri düzdür ve genellikle bir sinir hücresinde bir akson vardır. Aksonlar sinir hücre gövdesinden uzakta dallanırlar. Hücre gövdesinden ayrıldıktan sonra myelin denen bir kılıfla yüzeyleri kaplanır. Bu kılıf aksonun seyri boyunca 0,2-2 milimetrede bir kesintiye uğrar. Bu kesinti noktalarına Ranvier düğümü adı verilir.

Nöronal hücre gövdeleri sinyal alımı için sinapslar oluştururlar. Sinaps, iki sinir hücresi arasındaki fonksiyonel bir ünedir. Sinaps terminaline ulanan akım, nörotransmitter adı verilen belirli kimyasalların açığa çıkmasını sağlar. Bu kimyasal maddeler postsinaptik uçtaki reseptörlere bağlanınca, postsinaptik hücrenin uyarılabilirliğinde bir değişikliğe sebep olur. Bu değişiklik uyarıcı yönde, başka bir ifadeyle sinir hücresinin bir aksiyon potansiyeli oluşturmasını destekleyecek şekilde olabileceği gibi engelleyici yönde de olabilir. Eğer uyarıcı olaylar yeterli sayıda olursa, postsinaptik sinir hücresinde yeni bir aksiyon potansiyeli oluşur ve mesaj iletilmiş olur. Sinapslarda ileti her zaman tek yönde, presinaptik düğümden postsinaptik hücreye doğru iletilir. Sinapslar genellikle sinyalleri tek bir yönde iletirler (presnaptik hücreden postsnaptik hücreye doğru). Bir hücrenin aksonu diğer hücrelerle bu sinapslar sayesinde binlerce bağlantı yapabilir (Guyton ve Hall, 2006).

YSA beyne özellikle iki özelliğiyle benzemektedir. Bu özelliklerden birincisi; bilginin, bir öğrenme işlemi ile ağı çevresinden elde edilmesi, ikincisi; sinaptik ağırlıklar olarak bilinen işlem elemanları (nöron) arasındaki bağlantı ağırlıkları, elde edilen bilgileri depolamak için kullanılmasıdır (Haykin, 1999). Fausett'e göre ise, YSA, insanın kavrama yeteneğinin ya da sinir biyolojisinin matematiksel modellerinin genelleştirilmesi olup aşağıdaki varsayımlara dayandırılarak oluşturulmuştur (Fausett, 1994):

1. Bilgi işleme, işlem elemanı (nöron) adı verilen birçok basit birimlerle gerçekleşir.
2. Sinyaller bağlantılar aracılığıyla işlem elemanları arasında geçiş yapar.
3. Her bağlantının bir ağırlığı vardır. Tipik bir sinir ağında olduğu gibi, iletilen sinyallerle çarpılır.
4. Her işlem elemanı çıktı sinyallerini belirlemek için genellikle doğrusal olmayan bir transfer fonksiyonu uygular.

Tüm bu açıklamaların çerçevesinde biyolojik sinir sisteminin yapısı ile YSA arasındaki benzerlikler Çizelge 3.1.'deki gibi gösterilebilir (Elmas, 2003).

**Çizelge 3.1.** Biyolojik Sinir Sistemi ile YSA Arasındaki Benzerlikler (Elmas, 2003)

Biyolojik Sinir Ağı	YSA
Nöron	İşlem Elemanı (Düğüm) ( $X$ )
Sinaps	İşlem Elemanları Arasındaki Bağlantı Ağırlıkları ( $W$ )
Dendrit	Birleştirme Fonksiyonu ( $\Sigma$ )
Hücre Gövdesi	Transfer Fonksiyonu
Akson	İşlem Elemanının Çıktısı ( $Y$ )

### 3.3. Yapay Sinir Ağlarının Temel Yapısı


Bir YSA'nın temel yapısı, girdiler arasında bağlantı kuran işlem elemanlarından, bağlantı ağırlıklarının belirlenmesini sağlayan öğrenme algoritmalarından ve transfer fonksiyonundan oluşmaktadır. Her bir işlem elemanı, diğer işlem elemanlarıyla bağlantılı olup bir ağırlık değerine ( $W$ ) sahiptir.

Ağırlıklar, işlem elemanları arasındaki bağlantıların kuvvetini gösterir ve gizli katmandaki ve çıktı katmanındaki işlem elemanlarının net girdisinin hesaplanmasında kullanılır. Her işlem elemanın bir ağırlığa ve diğer işlem elemanlarıyla bağlantıya sahip olması, bilginin tüm bu bağlantılar aracılığıyla işlem elemanları ve katmanlar arasında ağın çıkışına kadar iletilmesini ve ağın dağıtılmış bir hafızaya sahip olmasını sağlamaktadır (Fausett, 1999).

Teknik olarak, bir YSA'nın en temel görevi, örnek veri setindeki yapıyı öğrenerek, istenilen görevi yerine getirecek şekilde genelleştirmeler yapmasıdır. Bunu yapabilmesi için ağ, ilgili olayın örnekleri ile eğitilerek genelleme yapılabilecek yeteneğe kavuşturulur. Bu genelleme ile benzer olaylara karşılık gelen çıktı setleri belirlenir. Ağın ürettiği sonuçlar ise; ağa girilen bilgilerin kendi ağırlıkları ile çarpımlarının toplanması sonucu elde edilen net girdinin, bir transfer fonksiyonu ile işlenmesi ile çıktı katmanından alınmaktadır (Öztemel, 2003).



YSA'da ilk katman girdi katmanıdır. Girdi katmanı, çözülmesi istenilen probleme ilişkin bilgilerin YSA'ya alınmasını sağlar. Diğer katman ise ağ içerisinde işlenen bilginin dışarıya iletildiği çıktı katmanıdır. Girdi ve çıktı katmanlarının arasında katman varsa bunlara gizli katman adı verilir. Bir YSA'da gizli katman olması gerekmediği gibi, birden fazla gizli katman da bulunabilir. Her katmanda birden çok işlem elemanı bulunabilir. Literatürde, hemen hemen tüm çalışmalarda girdi katmanı, girdilerin ağa girmesinde bir kapı işlevi görmesi nedeniyle niceliksel olarak katman sayısına dâhil edilmemektedir. Bundan dolayı, girdi katmanı ile birlikte üç katmandan oluşan bir YSA, iki (çok) katmanlı bir ağ olarak kabul edilmektedir. Girdi katmanı ile birlikte iki katmanlı olan bir YSA ise tek katmanlı bir ağ olarak kabul edilmektedir (MacKay, 2003). Tipik bir YSA yapısı Şekil 3.2.'de gösterilmiştir (Smith, 2002).



Şekil 3.2. Tipik Bir YSA Yapısı (Smith, 2002)

Şekil 3.2.'de,  $(x_i; i = 1, \dots, n)$  girdi katmanındaki işlem elemanlarını,  $(y_j; j = 1, \dots, h)$  gizli katmandaki işlem elemanlarını,  $(z_k; k = 1, \dots, p)$  çıktı katmanındaki işlem elemanlarını göstermektedir. Ayrıca  $w_{ij}$ ,  $i$ . girdi işlem elemanından  $j$ . gizli işlem elemanına olan bağlantının ağırlığını ve  $v_{jk}$ ,  $j$ . gizli işlem elemanından  $k$ . çıktı işlem elemanına olan bağlantının ağırlığını

göstermektedir. +1 olarak gösterilen birimler sapma “ $\Theta$ ” (bias term) değerleridir (Smith, 2002).

### 3.4. Yapay Sinir Ağlarının Temel Elemanları

Biyolojik sinir ağlarındaki sinir hücrelerine karşılık, YSA’da da yapay sinir hücreleri vardır. Şekil 3.2. aynı zamanda bir yapay sinir hücresini de göstermektedir. Her yapay sinir hücresinin 4 temel elemanı vardır. Bu elemanlar; girdiler, ağırlıklar, transfer fonksiyonu ve hücrenin çıktısıdır.

#### 3.4.1. Girdiler

Girdiler  $(x_i; i = 1, \dots, n)$  bir yapay sinir hücresine dış dünyadan gelen bilgilerdir. Yapay sinir hücresine dış dünyadan olduğu gibi başka hücrelerden veya kendisinden de bilgiler gelebilir.

#### 3.4.2. Ağırlıklar

Ağırlıklar, bir yapay sinir hücresine gelen bilginin önemini ve hücre üzerindeki etkisini gösterir (Öztemel, 2003). Bir işlem elemanı, genellikle eşanlı olarak birçok girdi almaktadır. Her girdi  $(x_i; i = 1, \dots, n)$  gizli katmandaki işlem elemanına  $(y_j; j = 1, \dots, h)$ ; bağlanırken bir bağlantı ağırlığına  $(w_{ij}; i = 1, \dots, n; j = 1, \dots, h)$  sahip olmaktadır. Gizli katmandaki gizli işlem elemanları diğer bir gizli katmandaki gizli işlem elemanlarına ya da başka bir gizli katman bulunmuyorsa çıktı katmanındaki işlem elemanlarına  $(z_k; k = 1, \dots, p)$ ; bağlanırken de bir bağlantı ağırlığına  $(v_{jk}; j = 1, \dots, h; k = 1, \dots, p)$  sahip olmaktadır. Girdi katmanından gizli katmana gelen girdilerin bu bağlantı ağırlıkları ile çarpılması ile gerekli değerler elde edilir (Anderson ve McNeill, 1992).

### 3.4.3. Transfer(Aktivasyon) fonksiyonu

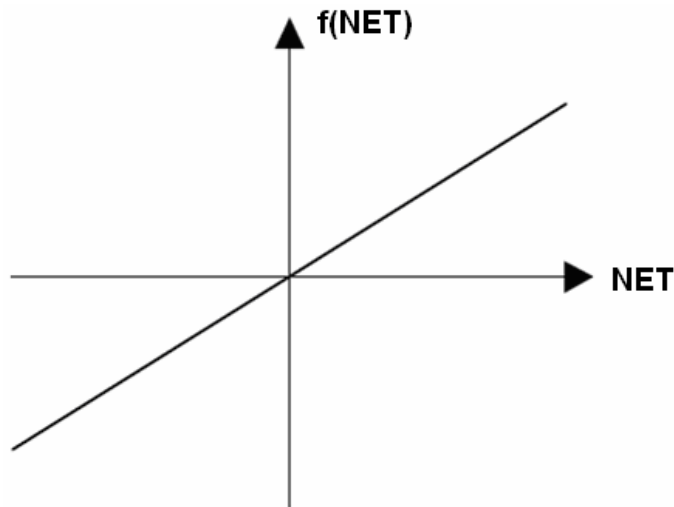
Transfer fonksiyonu, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Transfer fonksiyonu olarak çıktıyı hesaplamak için değişik formüller kullanılmaktadır.

Transfer fonksiyonunda ağın işlem elemanlarının hepsinin aynı fonksiyonu kullanması gerekmez. Bazı elemanlar aynı fonksiyonu diğerleri farklı fonksiyonları kullanabilirler. Bir problem için en uygun fonksiyonunun bulunması, ağın tasarımcısının denemeleri sonucunda belirleyebileceği bir durumdur. Uygun fonksiyonu gösteren bir formül henüz bulunmuş değildir (Öztemel, 2003). En yaygın olarak kullanılan transfer fonksiyonları aşağıda verilmektedir.

**Özdeşlik (identity) Fonksiyonu:** Genellikle girdi değerleri için kullanılan aktivasyon fonksiyonu aşağıda ifade edilen ve Şekil 3.3.'de gösterilen özdeşlik fonksiyonudur (Zilouchian, 2001).

$$F (NET) = NET \quad (3.1)$$

Belirli bir katmandaki tüm nöronlar için aynı aktivasyon fonksiyonu kullanılabilir. Birçok durumda doğrusal olmayan aktivasyon fonksiyonları kullanılır (Fausett, 1999).

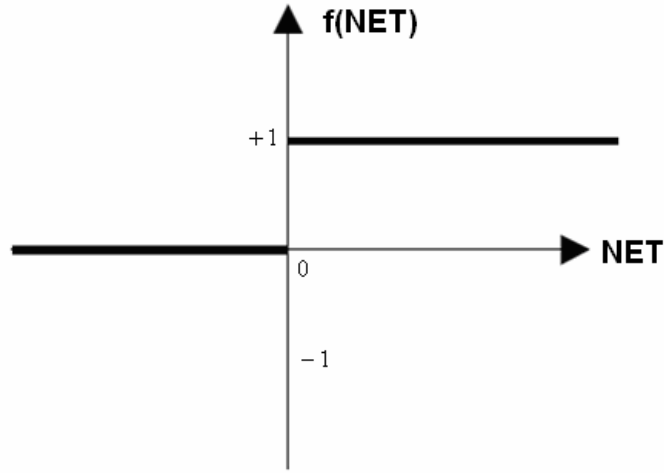


Şekil 3.3. Özdeşlik Fonksiyonu (Zilouchian, 2001)

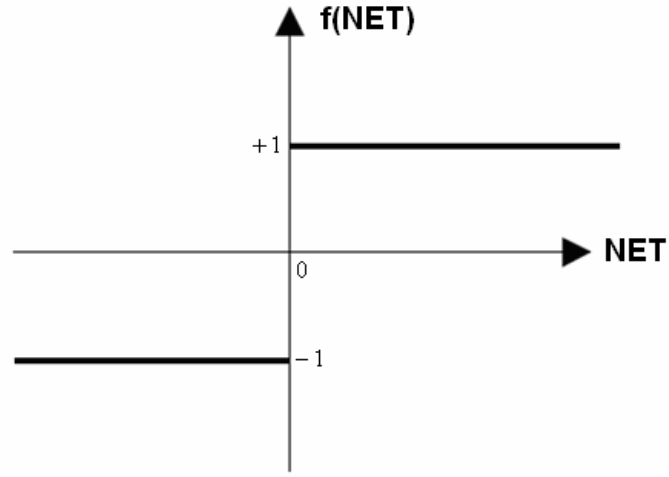
**Eşik Fonksiyonu:** Eşik (threshold) fonksiyonun en önemli özelliği, tüm girdi değerine karşılık sadece iki çeşit çıktı üretmesidir. Eğer giriş değeri, sapma değerini “ $\Theta$ ” aşarsa çıktı olarak  $\alpha$ , aksi takdirde  $\beta$  sabit değerini alır. Eşik fonksiyonun matematiksel ifadesi,

$$f(NE T) = \begin{cases} \alpha & \text{eğer } NE T \geq \Theta \text{ ise} \\ \beta & \text{eğer } NE T \leq \Theta \text{ ise} \end{cases} \quad (3.2)$$

şeklinde olur. Bir YSA’da  $\alpha$ ,  $\beta$  ve  $\Theta$  değerleri yapılan çalışmanın türüne göre belirlenebilir. Literatürdeki birçok çalışmada  $\Theta = 0$  olmak üzere,  $\alpha = 1$  ve  $\beta = 0$  veya  $\alpha = 1$  ve  $\beta = -1$  olarak seçilmektedir (Bayramoğlu, 2007). Şekil 3.4.’te tek kutuplu, Şekil 3.5.’te ise çift kutuplu eşik fonksiyonları gösterilmektedir (Zilouchian, 2001).



**Şekil 3.4.** Tek Kutuplu Eşik Fonksiyonu (Zilouchian, 2001)

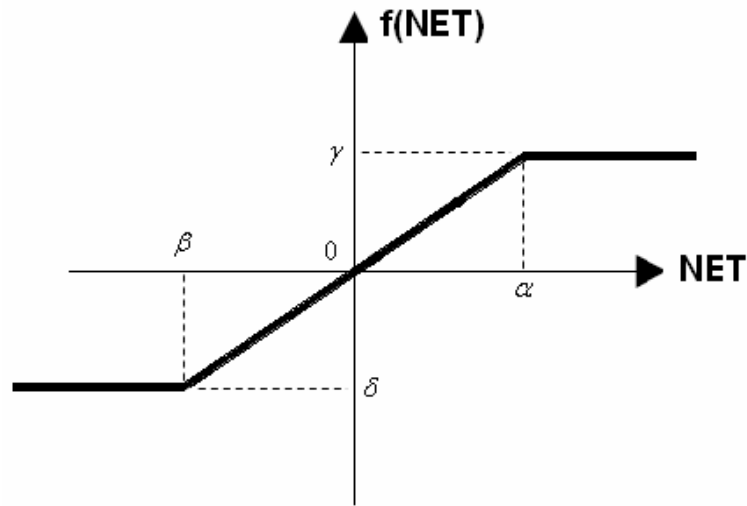


Şekil 3.5. Çift Kutuplu Eşik Fonksiyonu (Zilouchian, 2001)

**Parçalı Doğrusal Fonksiyon (Piecewise Linear Function):** Parçalı doğrusal (piecewise linear) fonksiyon, özdeşlik fonksiyonu ile basamak fonksiyonunun bir araya gelmesi ile oluşur. Bu fonksiyonda  $\beta \leq x \leq \alpha$  aralığında doğrusal işlemci,  $x > \alpha$  ve  $x < \beta$  için de eşik işlemcisi özelliği göstermektedir. Parçalı doğrusal fonksiyonun matematiksel ifadesi,

$$f( NET ) = \begin{cases} \gamma & \text{eğer } NET > \alpha \\ \frac{\gamma - \delta}{\alpha - \beta} NET + \frac{\alpha\delta - \beta\gamma}{\alpha - \beta} & \text{eğer } \beta \leq NET \leq \alpha \\ \delta & \text{eğer } NET < \beta \end{cases} \quad (3.3)$$

şeklindedir. Pratik çalışmalarda  $\gamma$  ve  $\delta$  değerleri genel olarak  $\gamma = +1$  ve  $\delta = 0$  veya  $\delta = -1$ 'dir (Şen, 2004). Şekil 3.6.'da parçalı doğrusal fonksiyon gösterilmektedir (Zilouchian, 2001).




Şekil 3.6. Parçalı Doğrusal Fonksiyon (Zilouchian, 2001)

**Sigmoid Fonksiyonu:** Sigmoid fonksiyonu, doğrusal olmayan bir fonksiyondur. Sigmoid fonksiyonu; matematiksel olarak doğrusal olmayan yapısının olması, kolayca türevinin alınabilmesi, sürekli ve artan olması nedeniyle YSA yapılarının kurulmasında en çok kullanılan fonksiyondur. Bu fonksiyonun matematiksel ifadesi;

$$f(NET) = \frac{1}{1 + e^{-\alpha NET}}, \quad 0 \leq f(NET) \leq 1 \quad (3.4)$$

şeklindedir. İfadedeki  $\alpha$ , sigmoid fonksiyonunun şekil parametresidir. Bu parametre değiştirildiğinde fonksiyonun farklı şekilleri de ortaya çıkar (Zilouchian, 2001). Şekil 3.7.'de sigmoid fonksiyonu gösterilmektedir (Anderson ve McNeill, 1992).

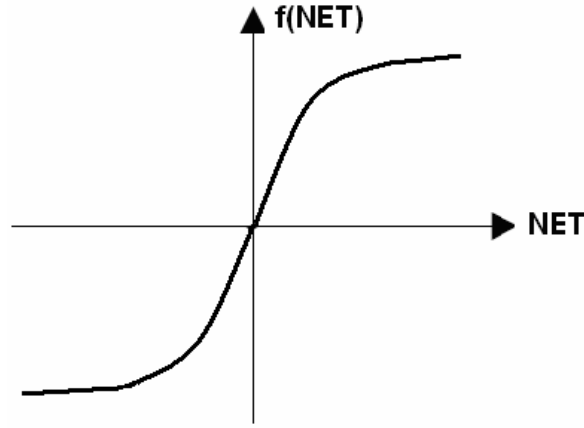


Şekil 3.7. Sigmoid Fonksiyonu (Anderson ve McNeill, 1992)

**Hiperbolik Tanjant Fonksiyon:** Sigmoid fonksiyon ile birlikte hiperbolik tanjant (hyperbolic tangent) fonksiyonu da YSA'da özellikle de çok katmanlı algılayıcı (Multilayer Perceptron) yapılarında sıkça kullanılan bir fonksiyondur. Çift kutuplu (bipolar) fonksiyon olarak da bilinen hiperbolik tanjant fonksiyonu,  $[-1,+1]$  aralığını kullanır. Bu yüzden giriş uzayının genişletilmesinde etkili bir fonksiyondur. Ancak bu fonksiyonun hiçbir parametresi bulunmamaktadır. Bu nedenle sigmoid fonksiyonu kadar elastik değildir. Bu fonksiyonun matematiksel ifadesi,

$$f (NET) = \frac{e^{NET} - e^{-NET}}{e^{NET} + e^{-NET}} \quad (3.5)$$

şeklindedir. Bu transfer fonksiyonunun da türevi kolayca alınabilmektedir (Bayramoğlu, 2007). Şekil 3.8.'de hiperbolik tanjant fonksiyonu gösterilmektedir (Anderson ve McNeill, 1992).



Şekil 3.8. Hiperbolik Tanjant Fonksiyonu (Anderson ve McNeill, 1992)

#### 3.4.4. Hücrenin çıktısı

Transfer fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı, dış dünyaya veya başka bir hücreye gönderilir. Hücre, kendi çıktısını kendisine girdi olarak da gönderebilir. Bir işlem elemanının birden fazla girdisi olmasına rağmen sadece bir çıktısı olmaktadır. Ağ şeklinde gösterildiğinde bir işlem elemanının birden fazla çıktısı varmış gibi görülmektedir. Bu sadece gösterim amacıyladır. Aslında bir işlem elemanından çıkan tek bir çıktı değeri vardır. Aynı değer birden fazla işlem elemanına girdi olarak gitmektedir (Öztemel, 2003).

#### 3.5. Yapay Sinir Ağlarının Tarihçesi

1950’li yılların sonlarında, büyük ölçekli işlemcilerin geliştirilmesiyle, beynin yaptığı işlemleri yapabilecek sinir ağlarının oluşturulabilmesi mümkün hale gelmiştir. Gerçekten de, YSA dijital işlemcilerin geliştirilmesinden sonra işlem yöntemi olarak önemli bir yeni yaklaşım olarak görülmektedir.

YSA simülasyonları nispi olarak yeni bir gelişme olarak görülmektedir. Bununla beraber, bu alan bilgisayarın çıkışından önce ortaya çıkmıştır ve bir bocalama devresi geçirdikten sonra yoluna devam etmiştir.

Bilgisayarların yaygın bir şekilde kullanılmaya başlanmasıyla birlikte, YSA alanında oldukça önemli gelişmeler olmuştur. Bu alandaki araştırmalar ve çalışmalar büyük bir ilgi ile başlamış fakat beklenen gelişmelerin gerçekleşmemesi sonucunda ilgi azalmış ve bir suskunluk dönemi başlamıştır.



Profesyonel ve maddi katkının minimum olduđu bu dönemde, sadece birkaç arařtırmacı tarafından katkı sađlanmıřtır. Bu arařtırmacılar, Minsky ve Papert tarafından tanımlanan sınırlamaları etkisiz kılan bir teknoloji geliřtirmişlerdir. Minsky ve Papert, 1969 yılında bir kitap yayınlamışlardır ve bu kitapta, arařtırmacılar arasında ön plana çıkan ve ekstra analiz yapılmadan kabul gören YSA'ya karşı bazı olumsuzlukları toplamışlardır. Son yıllarda ise, YSA alanı ilgi ve katkı olarak yeniden canlanmaktadır. YSA tarihi, dönemler itibariyle incelenebilir.

**1. İlk Giriřimler:** Bu dönemde, genel mantığı kullanan başlangıç simülasyonları yapılmıştır. McCulloch ve Pitts (1943), kendi nöroloji anlayışları çerçevesinde YSA modelleri geliřtirmişlerdir. Bu modeller, nöronların çalışma şekilleri hakkında bazı varsayımlarda bulunmuştur. Oluřturdukları ađlar, sabit eşiklere sahip ikili (binary) aletler olarak görülen basit nöronları temel almıştır. Modellerinin sonuçları, “a veya b” ve “a ve b” gibi basit mantıksal fonksiyonlardı. Diđer bir girişim, bilgisayar simülasyonları kullanılarak yapılmıştır. Bu noktadaki katkılar iki arařtırmacı grubu tarafından yapılmıştır: Farley ve Clark (1954) ve Rochester, Holland, Haibit ve Duda (1956). Özellikle IBM arařtırmacıları olan ilk grup modellerini çalıştıramamışlar ve McGill Üniversitesinden nörobilimcilerle ortak bir çalışma yapmışlardır. Bu etkileşim, bugüne kadar süren, çok disiplinli bir trend oluřturmuştur.

**2. Umut Verici Geliřmeler:** YSA'nın geliřmesinde tek etkisi olan nörobilim deđildir, psikologlar ve mühendisler de YSA simülasyonundaki ilerlemeye katkı sađlamıştır. Rosenblatt (1958) Perceptron'u tasarlayıp geliřtirdikten sonra, bu alandaki ilgi ve etkinlik canlanmaya başlamıştır. Perceptron üç tabaka içermekteydi ve orta tabaka birleřtirme tabakası olarak adlandırılmaktaydı. Bu sistem, bir veri girdi kümesinin bir rassal çıktıya bağlanma veya birleřme şeklini öğrenebilmekteydi. Burada öğrenme kelimesi bağlantı ađlırlıklarının ilişkiye göre ayarlanması anlamında kullanılmaktadır. Diđer bir sistem (ADALINE – Adaptive Linear Element) ise Stanford Üniversitesinden Widrow ve Hoff tarafından 1960 yılında geliřtirilmiştir. Basit bileşenlerden oluřan bir analog elektronik alet olan ADALINE, kullanılan öğrenme yöntemi ile Perceptrondan farklılaşmıştır. Bu sistemde En Küçük Ortalama Kareler (LMS – Least Mean Squares) öğrenme kuralı kullanılmıştır.

**3. Olumsuz Gelişmeler:** 1969 yılında, Minsky ve Papert bir kitap yazmış ve bu kitapta çok tabakalı sistemlere göre tek tabakalı Perceptronların sahip olduğu sınırlamaları ortaya koymuşlardır. Kitabın ana fikri şu şekilde özetlenebilir: “...bizim sezgisel görüşümüz çok tabakalı sistemlere genişlemenin verimsiz olduğudur.”. Kitapta ortaya konulan bu önemli sonuç sonrasında YSA simülasyonlarına yönelik araştırmalar hem ilgi hem de kaynak kaybına uğramıştır. Sonuç olarak, bu alana yönelik önemli bir önyargı oluşmuştur. Minsky ve Papert tarafından altı çizilen sorun YSA literatüründe XOR Problemi olarak bilinmektedir.

**4. Yenilikler:** İlgi ve kaynağın minimum düzeyde olmasına rağmen bazı araştırmacılar yapı tanımlama (pattern recognition) gibi problemlerin çözümüne yönelik çalışmalarını sürdürmüşlerdir. Bu dönem süresince bazı paradigmalar ortaya çıkmıştır. Grossberg ve Carpenter (1995) tarafından yapılan çalışmalar, yankı (resonating) algoritmaları araştıran bir düşünce okulunun temellerini atmıştır. Bu araştırmacılar, temeli biyolojik olarak kabul edilebilir modellere dayanan ART (Adaptive Resonance Theory – Adaptif Rezonans Teorisi) ağlarını geliştirmişlerdir. Anderson ve Kohonen ise birbirlerinden bağımsız olarak benzer teknikler geliştirmişlerdir. Klopff, 1972 yılında, yapay nöronlarda öğrenme işlemi için, “heterostasis” olarak adlandırılan ve nöronsal öğrenmenin biyolojik prensiplerine dayanan bir temel oluşturmuştur. Werbos (1974) geri-besleme öğrenme metodunu geliştirmiş, kullanmıştır ve bir kaç yıl sonrasında bu metot oldukça popülerite kazanmıştır. Recurrent ağlar, bugün, en çok bilinen ve kullanılan yapay sinir ağlarıdır. Recurrent ağ aslında, yapay nöronunda farklı bir eşik fonksiyonuna sahip ve daha sağlam (robust) ve yetenekli öğrenme kuralı olan bir çok tabakalı Perceptrondur. Amari (1967) teorik gelişmelerle ilgilenmiştir. Adaptif yapı (pattern) sınıflandırması konusu üzerine bir makale yayınlamıştır ve bu makalede bir öğrenme temeli (error-correction method – hata düzeltme metodu) için bir matematiksel teori oluşturmuştur. Fukushima ise el yazısı karakterleri yorumlamak için bir adım adım (stepwise) eğitilmiş çok tabakalı YSA oluşturmuştur. Cognitron olarak adlandırılan bu model 1975 yılında yayınlanmıştır.

**5. Yeniden Canlanma:** 1970’li yılların sonlarında ve 1980’li yılların başlarındaki ilerleme, yapay sinir ağları alanına ilginin yeniden canlanması bakımından önemlidir. Bu hareketi bir kaç faktör etkilemiştir. Örneğin, ayrıntılı kitaplar ve

konferanslar çok farklı alanlarda uzmanlaşmış insanlara bir forum imkânı ve dolayısı ile bir etkileşim sağlamıştır. Akademik programlar oluşturulmuş ve en önemli üniversitelerde dersler açılmıştır. Artan ilgi ile beraber bu alandaki araştırmalara yönelik fonlar da artmış ve enstitüler ortaya çıkmıştır.

**6. Bugün:** Sağlanan önemli ilerleme yapay sinir ağları alanında daha ileri araştırmalar için gerekli ilgi ve bilgi birikimini sağlamıştır. Sinir sistemi tabanlı işlemciler oluşturulmakta ve karışık problemlerin çözümüne yönelik uygulamalar gelişmektedir. Kısacası, bu alan bugün bir geçiş dönemi içinde görülmektedir.

YSA 1950’li yıllarda ortaya çıkmalarına rağmen, ancak 1980’li yılların ortalarında genel amaçlı kullanım için yeterli seviyeye gelmişlerdir (Yurtoğlu, 2005).

### **3.6. Yapay Sinir Ağlarının Genel Özellikleri**

Çok değişik amaçlar için çok sayıda sinir ağı geliştirilmiştir. Yapısı, çalışması ve işlem prensibi bakımından farklılık göstermekle birlikte bazı özellikleri ortaktır.

Genel anlamda YSA tümüyle birbirine bağlantılı pek çok sayıda sinyal ya da bilgi işleme birimlerinden oluşmuş bir hesaplama sistemidir ve aşağıdaki özelliklere sahiptir:

**1. Paralel çalışma:** Yapay sinir ağlarında tüm işlem elemanları eş zamanlı çalışmaları için çok hızlı çıktı üretirler.

**2. Doğrusal olmama:** YSA’nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik tüm ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlere çözüm getirmektedir.

**3. Genelleme:** YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de belirtilen tepkiyi üretme kabiliyetine sahiptir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakteri verirler. Eğitilmiş bir ağa girişin sadece bir kısmı verilse bile, ağ hafızadan bu girişe en yakını seçerek tam bir giriş verisi alıyormuş gibi kabul eder ve buna uygun bir çıkış değeri üretir. Veri YSA’ya, eksik, bozuk veya daha önce hiç karşılaşmadığı şekilde verilse bile, ağ kabul edilebilir en uygun çıkışı üretecektir. Bu özellik ağın genelleştirme özelliğidir.

**4. Öğrenme:** YSA ile bilgisayarlar ve/veya makineler öğrenebilir. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar. Böylelikle kendisine gösterilen örneklerden genellemeler yaparak daha önce görmediği örnekler hakkında bilgiler üretebilirler.

**5. Bilginin saklanması:** YSA'da bilgi ağı bağlantılarında saklanmaktadır. Diğer programlarda ise bir veri tabanında ya da programın içerisinde gömülü olarak bulunur.

**6. Hata toleransı:** YSA, çok sayıda işlemci elemanların bağlantısı paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağdaki tüm bağlantılara dağılmıştır. Giriş verisinde bulunabilecek herhangi bir gürültü, bütün ağırlıklar üzerine dağıtıldığından dolayı, gürültü etkisi tolere edilebilir. Girişlerde eksik bir bilgi sistemin tamamının çalışmasını engellemez. Geleneksel yöntemlere göre hatayı tolere etme yetenekleri daha fazladır.

**7. Uyarlanabilirlik:** YSA ağırlıkları, uygulanan probleme göre değiştirilir. Başka bir deyişle, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir. Değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, işaret işleme, sistem tanımlama ve denetim gibi alanlarda etkin olarak kullanılır.

**8. Kendi ilişkisini oluşturma:** YSA verilere göre kendi ilişkilerini kendisi oluşturabilir. Bünyesinde sabit bir denklem içermez.

**9. Sınırsız sayıda değişken ve parametre kullanımı:** YSA sınırsız sayıda değişken ve parametre ile çalışabilir. Bu durumda çok başarılı bir tahmin ve genel çözümler üretebilmektedir.

**10. Algılamaya yönelik olaylarda kullanılabilirlik:** YSA daha çok algılamaya dönük bilgileri işlemede kullanılırlar. Bilgiye dayalı işlemlerde genellikle uzman sistemler kullanılır. Bazı durumlarda bu iki sistem birleştirilerek daha başarılı sonuçlar üreten bir sistem elde edilebilir.

**11. Dereceli bozulma:** Hatalara karşı toleranslı oldukları için sistemin bozulması da dereceli olur. Başka bir ifadeyle klasik programlarda sistemde bir hata var ise sistem tamamen çalışamaz duruma geçer, yorum yapamayacağı için kısmi de olsa bilgi üretemez. Fakat YSA eldeki verilerle, sağlam olan hücrelerle bilgi üretmeye çalışırlar (Yıldız, 2006).

### 3.7. Yapay Sinir Ağlarının Sınıflandırılması


YSA'yı üç ayrı sınıfa ayırmak mümkündür. Bunlardan birincisi, YSA'nın bağlantı yapıları dikkate alınarak yapılan sınıflandırmadır. İkincisi; YSA'nın öğrenme şekillerine göre sınıflandırılmasıdır. Üçüncüsü ise; YSA'nın katman sayıları dikkate alınarak sınıflandırılmasıdır. Bu sınıflandırmalar izleyen alt bölümlerde ifade edilmiştir.

#### 3.7.1. Bağlantı yapılarına göre ağlar

Bağlantı yapılarına göre YSA, ileri beslemeli ağlar (feedforward networks) ve recurrent ağlar olmak üzere iki bölümde ifade edilebilir. Bu ağlar izleyen paragraflarda incelenmiştir.

**1. İleri Beslemeli Ağlar:** İleri beslemeli (feedforward) bir ağda işlem elemanları genellikle katmanlara ayrılmıştır. İşlemci elemanlar, bir katmandan diğer bir katmandaki tüm işlem elemanlarıyla bağlantı kurarlar ancak; işlem elemanlarının aynı katman içerisinde kendi aralarında bağlantıları bulunmaz. İleri beslemeli ağlarda bilgi akışı, girdi katmanından gizli katmana, gizli katmandan da çıktı katmanına doğru geri besleme olmaksızın tek yönde yapılmaktadır (Zhang, 2003). Şekil 3.2.'de ileri beslemeli bir ağ modeli gösterilmektedir. İleri beslemeli ağlara örnek olarak; Çok Katmanlı Algılayıcı (MLP) ve Learning Vector Quantization Modeli ağları verilebilir (Sağiroğlu ve Ark., 2003).

**2. Recurrent Ağlar:** Bir recurrent yapay sinir ağında, işlem elemanları arasında dönüşler ya da geri besleme bağlantıları bulunmaktadır. Recurrent ağlarda herhangi bir hücrenin çıktısı direkt olarak girdi katmanına gönderilerek tekrar girdi olarak kullanılabilir (Zhang, 2003). Geri besleme, ağın herhangi bir katmanında gerçekleştirilebilir (Gatley, 1996). Bu ağlara örnek olarak; Hopfield, Elman ve Jordan ağları verilebilir. Şekil 3.9.'da, recurrent bir yapay sinir ağı yapısı gösterilmektedir (Haykin, 1999).



Şekil 3.9. Recurrent Ağ Yapısı (Haykin, 1999)

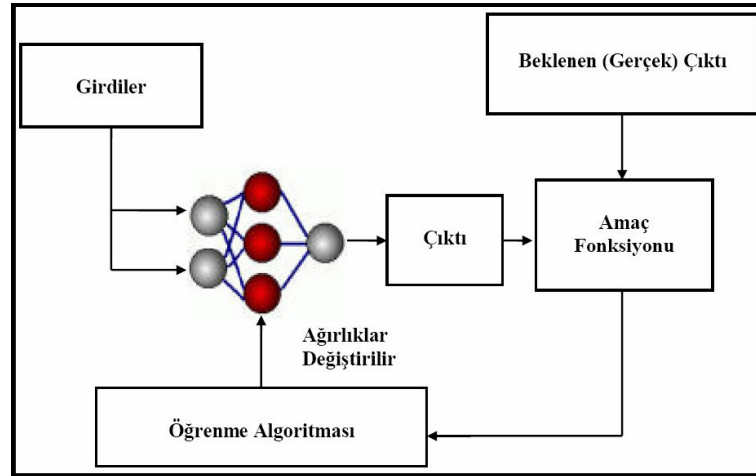
Recurrent YSA'nın kullanımı ile ileri beslemeli YSA'ya göre daha zengin dinamiklere sahip modeller geliştirilebilir. Ancak belirtmek gerekir ki, ileri beslemeli ağlar, recurrent ağlara göre akademik ve pratik alanda daha çok uygulanmaktadır. Bunun nedeni; recurrent ağların pratikte uygulanabilirliğinin zor olmasıdır. Özellikle, recurrent ağların birçok farklı yapıyla oluşturulabilmesi, belirli bir model yapısında uzmanlaşmayı engelleyebilmekte ve eğitim algoritmalarının tutarsız olması nedeniyle eğitiminin güç olmasına neden olabilmektedir (Zhang, 2003). Ayrıca recurrent ağların eğitimi uzun zaman almaktadır. Özellikle, eğitim kümesindeki veri sayısı arttıkça eğitim süresinin daha da uzaması söz konusu olmaktadır. Bu nedenle, recurrent ağlar, çok değişkenli ve uzun zaman serilerine ilişkin problemlerin çözümü için uygun bir ağ yapısı olamamaktadır. Bu yüzden, bu türden problemlerin çözümünde ileri beslemeli ağ yapısı tercih edilmektedir (Gately 1996; Bayramoğlu 2007).

### 3.7.2. Öğrenme şekillerine göre ağlar

Öğrenme şekillerine göre YSA'yı, danışmanlı öğrenme (supervised learning), danışmansız öğrenme (unsupervised learning) ve destekleyici öğrenme

(reinforcement learning) olmak üzere üç bölümde ifade edilebilir. Bu bölümler izleyen paragraflarda ele alınmıştır.

**1. Danışmanlı Öğrenme:** Danışmanlı öğrenme algoritmalarında, ağız eğitimi için ağa örnek olarak girdi değerlerinden ve hedef çıktı değerlerinden oluşan bir örnek veri seti verilir (MacKay, 2003). Verilen hedef çıktı değerleri, YSA literatüründe danışman ya da öğretmen olarak adlandırılır. Danışmalı öğrenme algoritmalarında, genellikle hataların hesaplanması için Ortalama Mutlak Hata ve Hata Kareleri Ortalamasının Karekökü performans ölçütleri kullanılır. Bu performans ölçütleri yardımıyla ağız, kendi ürettiği çıktılar ile hedef çıktılar arasında oluşan hata sinyallerini dikkate alarak kıyaslama yapması sağlanır. Ağız ürettiği çıktılar ile hedef çıktılar arasındaki hata sinyallerini minimize etmek amacıyla, işlem elemanları arasındaki bağlantı ağırlıkları düzenlenir. Diğer bir deyişle, danışmanlı öğrenme ile YSA, örnek girdiyi işleyerek kendi çıktısını üretir ve gerçek çıktı ile karşılaştırır. Öğrenme metodu sayesinde, hatayı en aza indirmek için bağlantı ağırlıkları yeniden düzenlenerek YSA'nın danışmana benzemesi amaçlanır (Haykin, 1999). Böylece hedef çıktı değerlerine en yakın çıktı değerleri YSA tarafından üretilebilir. Şekil 3.10.'da, danışmanlı öğrenme algoritmasının işleyişi gösterilmektedir (Bayramoğlu, 2007).



Şekil 3.10. Danışmanlı Öğrenme Algoritmalarının İşleyişi (Bayramoğlu, 2007)

Danışmanlı öğrenme algoritmalarına örnek olarak; Wihrow-Hoff'un Delta Kuralı (Delta Rule) ve Rumelhart ve McClelland'ın Genelleştirilmiş Delta Kuralı (Generalized Delta Rule) veya geriye yayılım algoritması verilebilir.

**2. Danışmansız Öğrenme:** Danışmansız öğrenmede, öğrenme süresince ağa sunulan bilgiler yalnızca girdi vektörlerinden oluşmakta ve hedef çıkışlar ağa sunulmamaktadır. Bu nedenle, ağın üretmiş olduğu çıktıları karşılaştırarak kontrol işlevini gerçekleştireceği bir danışmanı bulunmamaktadır. Danışmansız öğrenmede ağ, hedef çıktı olmaksızın giriş bilgilerinin özelliklerine göre gruplama yapmak için ağırlık değerlerini ayarlar. Ardından ağ, her küme için örnek bir vektör üretir (Fausett, 1999). Bu tür öğrenmeye örnek olarak; Hebb, Hopfield ve Kohonen öğrenme kuralları verilebilir.

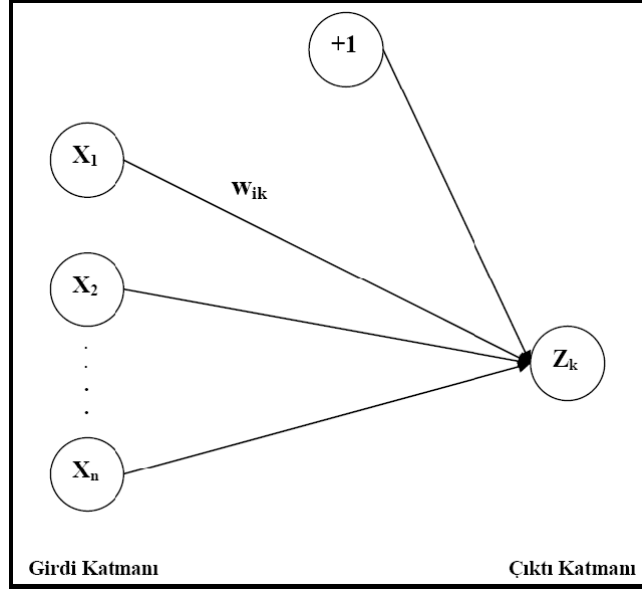
**3. Destekleyici Öğrenme:** Bu tür bir eğitimde, ağa bir danışman yardımcı olur. Fakat danışman, her girdi seti için üretilmesi gereken çıktı setini sisteme göstermek yerine, sistemin kendisine gösterilen girdilere karşılık çıktısını üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu 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 (Öztemel, 2003).

### 3.7.3. Katman sayısına göre ağlar

Katman sayısına göre YSA, tek katmanlı YSA (single layer neural networks) ve çok katmanlı YSA (multilayer neural networks) olmak üzere ikiye ayrılmaktadırlar. Bu YSA izleyen paragraflarda ifade edilmiştir.

**1. Tek Katmanlı YSA:** Tek katmanlı YSA, sadece girdi ve çıktı katmanlarından oluşur. Eğriselliği sağlayacak gizli tabakanın bulunmaması sebebiyle bu türden ağlar daha çok doğrusal problemler için kullanılır. Tek katmanlı ağlarda her ağın bir veya daha fazla girdisi ( $x_i; i=1, \dots, n$ ) ve sadece bir çıktısı ( $z_k; k=1$ ) bulunmaktadır (Şen, 2004). Çıktı birimi, bütün girdi birimlerine bağlanmaktadır. Her bağlantının bir ağırlığı ( $w_{ik}; i=1, \dots, n; k=1$ ) vardır. Şekil 3.11.'deki yapay sinir ağı tek katmanlı yapıya sahiptir (Bayramoğlu, 2007). Bu ağlarda işlem elemanlarının değerlerinin ve dolayısıyla ağın çıktısının sıfır olmasını önleyen bir de sapma değeri ( $\Theta$ ) vardır. Sapma değerinin girdisi daima +1'dir.





Şekil 3.11. Tek Katmanlı Bir Yapay Sinir Ağı (Bayramoğlu, 2007)

Ağın çıktısı ağırlıklandırılmış girdi değerlerinin sapma değeri ( $\Theta$ ) ile toplanması sonucu bulunur. Bu girdi değeri, bir transfer fonksiyonundan geçirilerek ağın çıktısı hesaplanır. Bu işlem, şu şekilde formüle edilmektedir:

$$Y = f \left( \sum_{i=1}^m w_i x_i + \Theta \right) \quad (3.6)$$

Tek katmanlı yapay sinir ağlarından en önemlileri Basit Algılayıcı Modeli (Perceptron), Adaptif Doğrusal Eleman (Adaptive Linear Element - ADALINE) ve Çoklu Adaptif Doğrusal Eleman (Multiple Adaptive Linear Element - MADALINE)'dir (Bayramoğlu, 2007).

**2. Çok Katmanlı YSA:** Çok katmanlı YSA'da, girdi katmanı ile çıktı katmanı arasında bir veya daha fazla gizli katman bulunmaktadır (Fausett, 1994). Çok katmanlı YSA'yı tek katmanlı YSA'dan ayıran özellik, çok katmanlı YSA'da gizli katmanın bulunmasıdır. Çünkü gizli katmanda yapılan bir dizi işlem ile ağ doğrusal olmayan bir yapıya kavuşturulabilmektedir (Smith, 2002).

Bu tip ağ yapıları, tek katmanlı ağ yapılarına göre daha karmaşık problemleri çözebilmektedir. Ancak çok katmanlı ağların eğitilmesi, tek katmanlı ağların eğitilmesine göre oldukça zordur. Buna rağmen birçok problemin

çözümünde çok katmanlı ağların eğitimi, tek katmanlı ağların eğitimine göre daha başarılı olabilmektedir. Bunun nedeni, tek katmanlı ağların problemin çözümü için yetersiz kalmalarından kaynaklanmaktadır (Fausett, 1994). Çok katmanlı YSA'ya örnek olarak; Learning Vector Quantization Modeli ve Çok Katmanlı Algılayıcı (Multilayer Perceptron) Modeli verilebilir (Bayramoğlu, 2007).

### 3.8. Bazı Yapay Sinir Ağı Algoritmaları

Bu bölümde, yaygın olarak kullanılan bazı YSA algoritmaları hakkında bilgi verilmiştir.

#### 3.8.1. Standart geriye yayılım algoritması

Tahmin ve sınıflandırma problemlerinde daha çok kullanılan ileri beslemeli çok katmanlı YSA modelleri (MLP) ele alınsın. Bu ağlarda geniş yayılmış eğitim algoritması, esas fikri hata kareler toplamını adım adım minimize etmeye dayalı, geriye yayılım (Backpropagation (BP)) algoritmasıdır (Bishop 1995; Haykin 1999; Aslanargun ve Ark. 2007). Aslında, bu algoritma değişkenleri ağırlıklar olan hata fonksiyonuna sayısal optimizasyonda yaygın olan gradyan düşümü yönteminin uygulanmasıdır; her adımda, hata fonksiyonunun bulunulan cari noktadaki gradyan vektörü yönünde ağırlık vektörü belirli bir oranla değiştirilir ve hatanın değeri küçültülür:

$$w_{k+1} = w_k - \alpha g_k, \quad (3.7)$$

burada  $w_k$ , cari ( $k$ .) adımdaki ağırlık vektörü;  $g_k$ , hata fonksiyonunun  $w_k$  noktasında gradyan vektörü ve  $\alpha$  öğrenme oranıdır.

Basit gradyan düşümü yönteminde yerel minimum ve yakınsama hızıyla ilgili bir sıra zorluklar meydana çıkmaktadır. Bu nedenle ağırlık değişimi formülüne momentum terimi eklenir:

$$\Delta w_{k+1} = -\alpha g_k + \mu \Delta w_k, \quad (3.8)$$

burada  $\Delta w_k = w_k - w_{k-1}$  ağırlık değişimi,  $\mu$  momentum katsayısıdır. Momentum içeren geriye yayılım algoritmasına standart geriye yayılım (BPM) denir. Bu algoritmada  $\alpha$  ve  $\mu$  katsayılarının seçimine bağlı olarak algoritmanın kararlılık ve yakınsama hızı gibi nitelikleri değişir (Aslanargun ve Ark., 2007).

### 3.8.2. Esnek geriye yayılım algoritması

Çok katmanlı ağlar gizli katmanlarda sigmoid aktivasyon fonksiyonunu kullanırlar. Bu fonksiyonlara sıkıştırılmış fonksiyonlar denir, çünkü sonsuz girdi aralığını sonlu çıktı aralığına sıkıştırırlar. Sigmoid fonksiyonları girdiler genişledikçe sifıra yaklaşma eğiliminde bulunarak karakterize edilirler. Bu da steepest descent sigmoid fonksiyonlu çok katmanlı ağ eğitilirken kullanılırsa problem yaratır; eğim küçük olur, ağırlık ve sapmada küçük değişikliklere sebep olur.

Esnek Geriye Yayılım Algoritması (Resilient Backpropagation (RP)), eğitim algoritmasının amacı kimi türevlerin büyüklüklerinin zararlı etkilerinden arındırmaktır. Sadece türevin işareti güncellenen ağırlıkları belirlemek için kullanılır. Eğer türev sıfır ise güncellenen değerler aynı kalır. Eğer ağırlıklar birçok iterasyonda aynı doğrultuda değişmeye devam ederse, ağırlık değişiminin büyüklüğü artar (Aslanargun ve Ark., 2007).

### 3.8.3. Radyal tabanlı fonksiyon algoritması

Radyal Tabanlı Fonksiyon Ağ (RBF), regresyon ve sınıflama problemlerinde MLP'nin yanı sıra sıklıkla kullanılan bir ağıdır. Katmanlı YSA'nın tasarımında eğiticili geriye yayılım öğrenme algoritması bir en iyileme uygulamasıdır. Radyal tabanlı fonksiyon ağı tasarımı ise çok boyutlu uzayda eğri uydurma yaklaşımıdır ve bu nedenle RBF'nin eğitimi, çok boyutlu uzayda eğitim verilerine en uygun bir yüzeyi bulma problemine dönüşür. RBF'nin genellemesi ise test verilerini interpolate etmek amacıyla, eğitim sırasında bulunan çok boyutlu yüzeyin kullanılmasına eşdeğerdir. Radyal tabanlı fonksiyonlar, sayısal analizde çok değişkenli interpolasyon problemlerinin çözümünde kullanılmış ve YSA'nın gelişmesi ile birlikte bu fonksiyonlardan YSA tasarımında yararlanılmıştır. RBF,

ileri beslemeli YSA yapılarına benzer şekilde Şekil 3.12.'de görüldüğü gibi girdi, ara ve çıktı katmanından oluşur ancak, girdi katmanından ara katmana dönüşüm, radyal tabanlı aktivasyon fonksiyonları ile doğrusal olmayan sabit bir dönüşümdür (Özdemir, 2007). Ara katmandan çıktı katmanına ise uyarlamalı ve doğrusal bir dönüşüm gerçekleştirilir.

Eğri uydurma teorisi, herhangi birçok değişkenli ve sürekli  $f(x)$  fonksiyonunu yaklaştırma ya da interpolate etme problemi ile ilgilidir. İnterpolasyon problemi,  $k = 1, 2, \dots, N$  için  $x_k$  veri noktası ve  $d_k$  gerçek değerler olmak üzere  $F(x_k) = d_k$  interpolasyon koşulunu sağlayan  $F(\cdot)$  fonksiyonunun bulunması olarak tanımlanır. Radyal tabanlı fonksiyonlarla doğrusal  $F(\cdot)$ ; denklem aşağıdaki gibi tanımlanır:

$$F(x) = \sum_{k=1}^N W_k \varphi_k(\|x - x_k\|). \quad (3.9)$$

Burada  $\varphi(\cdot)$  doğrusal olmayan radyal tabanlı fonksiyon,  $\|\cdot\|$  genellikle standart öklit uzaklığıdır. Bilinen veri noktaları, radyal tabanlı fonksiyonların merkezleri olarak söylenir. RBF'nin genel yapısında veri örneği kadar ara katman hücrelerine ve ağırlığa gerek duyulduğundan genel çözümü yakınsayan en iyi çözüm aranır.  $M < N$  olmak üzere RBF çıkışı,

$$F^*(x) = \sum_{i=1}^M W_i \varphi_i(\|x - c_i\|). \quad (3.10)$$

Burada  $c_i$  veri noktalarından belirlenecek olan radyal tabanlı fonksiyonların merkez vektörleridir. RBF'da ara katman aktivasyon fonksiyonu genellikle standart öklit uzaklıklarını üstel fonksiyondan geçiren gaussian fonksiyonudur ve aşağıdaki gibi tanımlanır:

$$\varphi(\|x - c_i\|) = e^{-\left(\frac{1}{2\sigma^2}\|x - c_i\|\right)}. \quad (3.11)$$

RBF’da uyarlanabilecek serbest parametreler; merkez vektörleri, radyal fonksiyonların genişliği ve çıktı katman ağırlıklarıdır. Çıktı katmanı doğrusal olduğundan ağırlıklar, eğim düşme ya da doğrusal en iyileme yöntemleri ile kolayca bulunabilir. Merkezler, girişler arasından rasgele ve sabit olarak seçilebilmekle birlikte RBF’nın performansını iyileştirmek amacıyla merkez vektörlerinin ve genişliğin uyarlanması için çeşitli yöntemler geliştirilmiştir. Merkez vektörleri, eğim düşme yöntemine göre eğiticili öğrenme algoritması ile uyarlanarak, dik en küçük kareler yöntemi ile, ya da kendiliğinden düzenlemeli yöntemle giriş örneklerinden öbikleme yapılarak belirlenebilir (Aslanargun ve Ark., 2007).

### **3.9. Bazı Yapay Sinir Ağı Mimarileri**

Bu bölümde, Bölüm 4’de yapılan uygulamada ele alınan bazı yapay sinir ağı mimarileri hakkında kısa bilgi verilmiştir. Bu yapay sinir ağı mimarileri doğrusal ağlar (Linear networks), radyal tabanlı yapay sinir ağları (Radial Basis Function Networks), çok katmanlı algılayıcı (Multilayer Perceptron) ve genelleştirilmiş regresyon sinir ağları (Generalized regression neural network) olarak ifade edilebilir. Bu mimariler sırasıyla izleyen alt bölümlerde ifade edilmiştir.

#### **3.9.1. Doğrusal ağlar**

Doğrusal ağlar sadece iki katmana sahiptir. Bunlardan biri giriş, diğeri doğrusal aktivasyon fonksiyonuna sahip çıkış katmanıdır. Bazı problemler doğrusal tekniklerle iyi çözülemeyebilir. Ancak birçok problem doğrusal tekniklerle çözülebilmektedir ve karşılaştırma yapmadan basit bir teknik yerine daha karmaşık bir tekniği kullanmak kötü bir çalışmadır. Doğrusal ağ daima daha karmaşık doğrusal olmayan birinin standart bir karşılaştırması gibi eğitilmelidir.

Doğrusal ağlar en iyi Pseudo-Inverse tekniği kullanılarak eğitilir. Bu teknik herhangi bir ağda son katmanı doğrusal bir katman olması şartıyla optimize eder. Pseudo-Inverse hızlıdır ve optimal çözümü bulmayı garanti eder. Ayrıca eğer istenilirse, bir doğrusal ağı optimize etmek için geriye yayılım (Back Propagation), çabuk yayılım (Quick propagation) veya Delta-bar-delta da kullanılabilir. Bazen Pseudo-Inverse tekniği, iterativ eğitimin bir geri düşüm


durumunu sağladığı durum olan nümerik problemlerden zarar görmesine rağmen bu normalde iyi çalışma değildir (Anonim, 2002).

### 3.9.2. Radyal tabanlı fonksiyon ağları (RBF)

Radyal tabanlı fonksiyon ağları, modelleme, yaklaşık fonksiyon belirleme, sınıflandırma amacıyla kullanılan bir ağ tipi olup ağ yapısı girdi, ara ve çıktı katmanlarından oluşur. Bu yapı Şekil 3.12.'de gösterilmiştir (Özdemir, 2007). Ağın ara katmanında yer alan hücrelerin (gauss hücreleri) çıktısı ağın girdi vektörlerine bağlı olarak bir gauss fonksiyonu ile  $c_j$  ve  $\sigma_j$   $j$ . hücre için sırasıyla “merkez değer” ve “bant genişliği” olmak üzere aşağıdaki şekilde verilebilir:

$$\phi_j(X) = \exp\left(-\frac{\|X - c_j\|^2}{2\sigma_j^2}\right) \quad (3.12)$$

Ağın çıktısı ( $y_z$ ) ise Gauss hücrelerine ait çıktıların ağırlık faktörleri ( $w_{zj}$ ) üzerinden toplamı olarak hesaplanır:



Şekil 3.12. Radyal tabanlı fonksiyon ağı (Özdemir, 2007)

Ara katman ve çıktı katmanı arasındaki ağırlık faktörlerinin belirlenmesi ağırlık eğitilmesi sonucunda belirlenir. Radyal tabanlı fonksiyon ağırlık eğitimi genellikle denetimli ve denetimsiz olarak iki aşamada gerçekleştirilir. Denetimsiz eğitme aşamasında gauss hücrelerinin (gauss fonksiyonlarının) parametreleri ( $c_j$  ve  $\sigma$ ) farklı teknikler yardımıyla belirlenirken; denetimli eğitme aşamasında ara katman ve çıktı katmanları arasındaki ağırlık faktörleri uygun bir eğitme algoritması yardımıyla, ileri beslemeli denetimli sinir ağlarında olduğu gibi, belirlenir (Özdemir, 2007).

### 3.9.3. Çok katmanlı algılayıcı (MLP)

Tek katmanlı algılayıcıların doğrusal problemleri çözmekle sınırlı kalmaları sonucunda yapılan araştırmalar, MLP'lerin ve onun öğrenme kuralı olan geriye yayılım algoritmasının ortaya çıkmasıyla sonuçlanmıştır. MLP'ler ve geriye yayılım algoritması ile doğrusal olmayan problemlerin çözümünde başarılı sonuçlar elde edilmesi, işletme bilimi dahil birçok alanda kullanımının artmasına yol açmıştır. Şekil 3.2.'deki YSA, bir MLP'nin yapısına sahiptir. MLP'lerin ilk katmanı girdi katmanıdır. Son katmanı ise, çıktı katmanıdır. Girdi katmanı ile çıktı katmanı arasında ise gizli işlem elemanlarının yer aldığı en az bir tane gizli katman bulunmaktadır. MLP'leri tek katmanlı algılayıcılardan ayıran özellik, MLP'lerde bulunan gizli katmandır. Çünkü gizli katmanda yapılan bir dizi işlem ile ağırlık doğrusal olmayan bir yapıya kavuşturulabilmektedir. Gizli katman sayısı en az bir tane olmak üzere birden fazla da olabilmektedir. Gizli katmandaki her işlem elemanı, doğrusal olmayan bir transfer fonksiyonuna sahiptir ve bu fonksiyonlar aracılığıyla elde edilen sonuçlar bir sonraki işlem elemanlarına girdi sağlamaktadır. MLP'lerde en çok kullanılan transfer fonksiyonları sigmoid fonksiyonu ve hiperbolik tanjant fonksiyonudur (Bayramoğlu, 2007).

### 3.9.4. Genelleştirilmiş regresyon sinir ağları (GRNN)

Genelleştirilmiş regresyon ağları (Generalized Regression Network - GRN), radyal tabanlı fonksiyon ağlarının özel bir durumudur. Ağ yapısı bir radyal tabanlı

katman ile özel bir doğrusal katmandan oluşmaktadır. Radyal tabanlı YSA'da temel fikir, bir grup radyal tabanlı fonksiyonu istenen fonksiyona yaklaşacak şekilde ağırlıklandırarak toplamaktır. Genelleştirilmiş regresyon ağlarında ise radyal tabanlı fonksiyon ağlarının merkez ve bant genişliklerinin eğitime verisinin deterministik fonksiyonları olarak belirlenir ve bu tip ağlarda eğitim için yinelemeli (iteratif) yöntemler kullanılmaz.

Birinci katman, normal bir radyal tabanlı YSA gibi işler. Her nöronun ağırlıklı girişi, giriş vektörü ile bu girişin ağırlık vektörü arasındaki uzaklıktır. Her nöronun net girişi, o nöronun ağırlıklı girişi ile biasının çarpımıyla belirlenir. Her nöronun çıkışı, o nöronun net girişinin radyal tabanlı katmandan geçirilmesiyle hesaplanır.

Genel regresyon ağlarında bir  $x_j$  girişi, ağdaki Gauss çekirdeklerinden birinin merkezi olarak atanır. Herhangi bir giriş vektörü  $x$  için  $i$ . radyal tabanlı biriminin çıkışı

$$\beta_i = \exp \left[ -\frac{(x - x_i)^T (x - x_i)}{2\sigma^2} \right] \quad (3.13)$$

şeklinde hesaplanır. Burada  $\sigma$  kullanıcı tarafından belirlenen yumuşatma parametresidir. Herhangi bir  $x$  girişi için ağın çıkışı  $y$

$$y = \sum_{i=1}^K \alpha_i y_i \quad (3.14)$$

şeklinindedir. Buradaki  $\alpha$  katsayıları aşağıda görüldüğü gibi hesaplanır:

$$\alpha_i = \frac{\beta_i}{\sum_{i=1}^K \beta_i} \quad (3.15)$$

Eğer giriş vektörü  $x$ , herhangi bir  $x_i$  eğitim vektörüne yakın ise  $x_i$ 'ye ilişkin  $\alpha_i$  en büyük olacak ve istenen çıkış  $y$ ,  $x_i$ 'ye ilişkin  $y_i$  çıkışına yaklaşacaktır (Bolat ve Ark., 2004).



### 3.10. Yapay Sinir Ağları, İstatistik ve Ekonomi

İstatistik ile ekonomi arasındaki ilişki sürekli gelişmektedir. Özellikle, ekonomi alanında istatistiksel yöntemlerin kullanımı giderek artmaktadır. Ekonomi bilimindeki teorik ilişkilerin ölçülmesi ve kanıtlanmasından politika oluşturmaya yönelik tahmin ve öngörülerin yapılmasına kadar pek çok konuda istatistiksel araçlar sıkça kullanılmaktadır. Özellikle, son dönemde zaman serileri alanında kaydedilen gelişmeler sayesinde bu ilişki ivme kazanmıştır.

Özellikle, bu çalışmanın da konusunu oluşturan, ekonomik değişkenlerin modellenmesi ve tahmin edilmesi konusu ekonomi alanı için de oldukça önem taşımaktadır ve genellikle istatistiksel yöntemlerin kullanımını gerektirmektedir. Bu ilişkinin öneminin giderek artması istatistik alanındaki, özellikle de zaman serileri alanındaki gelişmelerin itici güçlerinden birini oluşturmaktadır. Durağanlık, ko-entegrasyon ve vektör otoregresyon (Vector Autoregression - VAR) gibi son dönemde zaman serileri alanında ortaya çıkan yeni kavramlar, ağırlıklı olarak bu ilişkinin getirileri olarak ortaya çıkmıştır ve bugün bu kavramlar ekonometri alanında en sık kullanılan yöntemlerdir.

İstatistik alanında yaşanan bu gelişmelerin yanında, başka alanlarda da hızlı bir gelişme süreci görülmektedir. Yapay sinir ağları alanı da gelişme gösteren diğer alanlar içinde en belirgin ve potansiyele sahip olanlardan biridir. YSA, bugün, diğer birçok alanda olduğu gibi ekonomi ve istatistik alanlarında da yoğun bir şekilde kullanılmaktadırlar. İstatistik alanında dağılımların belirlenmesi amaçlı, ekonomi alanında ise öngörü amaçlı olarak başarılı bir şekilde kullanılmaktadırlar. Özellikle, zaman serilerinin tahmin edilmesi ve öngörüsü konusunda sıklıkla kullanılıyor olması nedeniyle, YSA ile İstatistik ve dolayısıyla Ekonomi arasında nasıl bir ilişki olduğunu anlamak önemlidir.

Yapay Sinir Ağları ve İstatistik alanları arasında önemli sayılabilecek bir kesişim kümesi vardır. İstatistik, veri analizi ile uğraşan bir alandır. Benzer şekilde, sinir ağı terminolojisindeki hatalı (noisy) veriden öğrenerek genelleştirme kavramı (veya yeteneği), istatistiksel çıkarım (statistical inference) ile aynı anlamı taşımaktadır. Dolayısıyla, yapay sinir ağları da genelde veri analizi içermektedir. Fakat bazı sinir ağları veri analizi ile ilgilenmezler ve bu yüzden istatistik alanı ile ilişkileri kısıtlıdır. Örneğin, bazı ağlar öğrenme işlemi içermezler ki Hopfield ve

Kohonen ađlar bunlardan bir kaıdır. Bununla beraber, sinir ađlarının byk ođunluđu hatalı veriden genelleme yapabilmeyi renebilmektedir ve bu sayede istatistiksel yntemlerle benzer ya da aynı oldukları sylenebilir.

Bu benzerlik iin birok rnek gsterilebilir. rneđin, gizli tabaka iermeyen ileri besleme sınıfı ađlar temel olarak genelleştirilmiř lineer modellere karřılık gelirler. rnekleri artırmak gerekirse, olasılıkcı ađlar temel fark analizine (kernel discriminant analysis) karřılık gelirken, Hebbian đrenme temel bileřen analizi (principal component analysis) ile olduka iliřkilidir.

İleri besleme ađlar, dođrusal olmayan regresyon ve ayırıtırma (discrimination) modellerinin oluřturduđu sınıfın bir alt kmesidir. Dođrusal olmayan modeller hakkındaki istatistiksel teorilerden elde edilen birok sonu ileri besleme ađlara uygulanmaktadır. Ayrıca, dođrusal olmayan modeller iin kullanılan yntemler, rneđin Levenberg-Marquardt algoritma, ileri besleme ađları eđitmek iin kullanılmaktadır.

Sinir ađları algoritmalarına veya uygulamalarına gre tanımlanırken, istatistiksel yntemler genellikle sonularına gre tanımlanırlar. rneđin, aritmetik ortalama, basit bir geri yayılma ađ ile kolayca hesaplanabilir. Bunun iin, aritmetik ortalama formlnn ađ iinde kullanılması yeterlidir. Sonuta, hesaplanma řekli ne olursa olsun, ıktı olarak aritmetik ortalama elde edilir. Bu yzden, bir istatistiki aynı modeli uygulamak iin deđiřik algoritmalar kullanabilir. Diđer taraftan, bir istatistiki deđiřik eđitme kriterlerini deđiřik istatistiksel zelliklere sahip farklı tahmin yntemleri olarak grr.

YSA da istatistiksel modeller gibi dađılıma ynelik varsayımlara ihtiya duymaktadır. Fakat, istatistik bilimi bu varsayımların sonuları ve nem derecesi ile de ilgilenirken, YSA olayın bu ynn gz ardı etmektedir. rneđin, en kk kareler yntemi hem istatistiksel hem de sinir ađı modellerinde sıklıkla kullanılmaktadır.

İfade edilenlerin gsterdiđi gibi YSA ile istatistik arasında sıkı bir bađlantı kurulabilmektedir. Bu iki alan arasındaki etkileřim YSA tekniđinin birok alanda olduđu gibi ekonomi alanında da kolayca uygulama sahası bulmasına yardımcı olmaktadır (Usta, 2007).

### 3.11. Yapay Sinir Ağlarının Güçlü Yanları

YSA'nın güçlü yanları, özellikle doğrusal olmayan yapılarından ve kendine özgü eğitim sürecinden kaynaklanmaktadır. Genel olarak; YSA'nın diğer modellere göre güçlü yanları; doğrusal olmayan yapıyı modelleyebilme yeteneği, genelleştirme yapabilme yeteneği, uyarlanabilirlik ve esneklik, bilginin saklanması, hata toleransına sahip olması ve istatistik veya başka modelleme tekniklerindeki ön şart ve kabullerin bulunmayışıdır.

YSA, kullandıkları transfer fonksiyonları sayesinde doğrusal olmayan yapıları modelleyebilmektedirler. Gerçek hayattaki birçok öngörü problemi, doğrusal olmayan bir temele dayandığından, YSA'nın bu özelliği etkili bir öngörü aracı olarak tercih edilmelerini sağlamaktadır.

YSA modellerinin ağa sunulan bir eğitim seti ile ağırlıklarının ayarlanması mümkündür. Ayarlanan ağırlıkların tüm ağ için genelleştirilmesi yoluyla girdi ve çıktı değişkenleri arasında en az hatayı veren YSA modellerinin kurulabilmesi, YSA'ya diğer modellere göre üstünlük kazandırmaktadır.

Uyarlanabilirlik ve esneklik özelliği, YSA'nın, bağlantı ağırlıklarını çevrelerindeki değişimlere uyarlayabilme yeteneğinin olmasını ifade etmektedir. Özellikle, bir YSA durağan bir çevrede işlem yapmak için eğitildiyse bu çevrede meydana gelen küçük değişimlere cevap verebilmesi için yeniden eğitilmesi kolay olacaktır. Ayrıca bir YSA'nın işlem yaptığı çevre durağan olmasa bile; değişimin gerçekleştiği anda, ağın bağlantı ağırlıkları değişikliklere göre uyarlanarak yeniden yapılandırılabilir.

YSA'da bilgi, ağın bağlantılarının değeri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlarda olduğu gibi veriler bir veri tabanında veya programın içinde gömülü değildir. Bu yüzden YSA diğer modellere kıyasla bilgiyi saklayabilme gücüne sahiptirler.

YSA, çok sayıda işlem elemanı ile yoğun şekilde paralel bağlanmış olan yapıları sayesinde hatalara karşı toleranslı olabilmektedirler. YSA'nın sahip olduğu bilginin ağdaki tüm bağlantılara dağıtılmış olması, ağda oluşan bir hatanın tüm ağa dağıtılarak hatanın tolere edilmesini sağlamaktadır (Haykin, 1999).

Bir problemin birçok istatistik ve başka modelleme teknikleri ile modellenmesi öncesinde yerine getirilmesi gereken normal dağılıma uyma koşulu, veri sayısı arttıkça ortalama, varyans gibi parametrelerin sabit olması koşulu,

hataların birbirinden doğrusal olarak bağımsız olması koşulu ve yapılan ölçümlerin hatasız olduğu gibi ön şart ve kabuller bulunmaktadır. Oysa aynı sorunun YSA ile modellenmesinde hiçbir ön şart veya kabul yoktur. Ayrıca YSA klasik çözümleme algoritması olmayan durumlarda veya çok karmaşık problemlerin çözülmesinde bile doğrudan kullanılabilir. YSA modellemesi yapmak için olayın fiziğini önceden anlamak gerekmez. Sonuçta YSA modelleri, genelde bir çoklu giriş-çoklu çıkış ilişkisinin kurulmasını sağlar (Bayramoğlu, 2007).

### **3.12. Yapay Sinir Ağlarının Uygulama Alanları**

Yapay sinir ağları henüz yeni bir teknolojidir. Çalışmalar ilk olarak 1940'larda başlamış daha sonra bir duraklama döneminden sonra özellikle son 20–25 yılda hızlı bir şekilde gelişmiştir. YSA özellikle son yıllarda yapılan araştırmalar ve çalışmalar sayesinde birçok alanda kullanılabilir hale gelmişlerdir ve her geçen gün çok farklı YSA uygulaması duyurulmaktadır.

YSA'nın birçok uygulama alanının olmasına rağmen genel olarak aşağıdaki gibi ifade edilebilir.

#### **a. Örüntü tanıma (Pattern recognition):**

- 1. Ses tanıma:** Sesli yanıt sistemlerinde, asansörlerde, otomatik kapılarda ve hatta cep telefonlarında bile kullanılmaktadır.
- 2. Veri iletimi:** Verilerin sayısallaştırıldıktan sonra sıkıştırılarak bir yerden başka bir yere transferinde kullanılmaktadır.
- 3. Hareket tespiti, yüz tanıma, hedef tespiti:** Özellikle askeri uygulamalarda, güvenlik sistemlerinde, akan görüntülerin içerisinden belirli bir nesnenin tespitinde kullanılmaktadır.
- 4. Robotik sistemler:** Robotların öğrenmesinde, göz-el koordinasyonunda kullanılmaktadır.
- 5. Karakter, imza, parmak izi tanıma:** El yazısı tanıma, OCR (Optical Character Recognition) yazılımlarında, parmak izinden ve yüzünden şahıs tanıma, imza analizlerinde kullanılmaktadır.
- 6. Kalite kontrolü:** Üretilen bir ürünün (kumaş, seramik, karo, resim gibi) istenilen özelliklere uygunluğunun tespitinde kullanılmaktadır.

## **b. Verilerin yorumlanması:**

**1. Finans alanı:** Borsa analizinde, döviz kurlarının tahmininde, şirketlerin başarı ve başarısızlık durumlarının önceden tespitinde, kredi verilmesi kararlarında kullanılmaktadır.

**2. Güvenlik Sistemleri:** Özellikle bilgisayarla ağ üzerinden gelen bilgilerin yorumlanarak sisteme bir saldırı olup olmadığının tespitinde. İstenmeyen elektronik postaların (SPAM) ayıklanmasında kullanılmaktadır.

**3. Jet ve roket motorlarının geliştirilmesi:** Yapılan çalışmalarda algılayıcılardan (sensör) toplanan verilerin analizinde kullanılmaktadır.

**4. Tıbbi araştırmalar:** Hastalıkları tanımada, daha önceki hastalardan alınan geri bildirimlerle hastalığın teşhisinde, intihara meyilli kişilerin tespitinde, kalp ve beyin grafiklerinin, kan, idrar örneklerinin analizinde kullanılmaktadır.

**5. Hava durumu tahminleri:** O anki rüzgâr, nem, sıcaklık gibi verilerin değerlendirilmesi ile gelecekteki hava durumunun tahmininde kullanılmaktadır.

## **6. Personel seçimi.**

**c. Optimizasyon işlemleri:** Birçok ticari ve bilimsel konularda incelenen olayın verilen kısıtlar altında hedefin maksimize ya da minimize edilmesi optimizasyon olarak bilinir. Optimizasyon için önceki çalışmalarda klasik birçok yöntem geliştirilmiş olmasına karşılık bunun YSA modellemesi ile yapılması en azından sınırlayıcı matematik kabullerin bulunmaması açısından yararlıdır.

**d. Fonksiyon yaklaşımları:** Matematiksel fonksiyonu bilinmeyen birçok verinin modellenmesinde kullanılmaktadır.

## **e. Diğer uygulama alanları:**

**1. Kontrol:** Özellikle endüstriyel uygulamalarda, tren denetim sistemlerinde, robotik işlemlerde ve motorların hareketlerinde verilen girdilere göre istenilen bir işlemin yapılmasında YSA kullanılmaktadır.

**2. Arama çalışmaları:** Veri madenciliğinde toplanan verilerin içinden istenilene en uygun verilerin bulunmasında kullanılmaktadır.

**3. Verilerin sınıflandırılması ve kümelenmesi:** Örneğin, cümlelerin dilbilgisi kurallarına uygun ya da değil diye ayrılmasında kullanılmaktadır.

**4. Verilerin filtrelenmesi:** Veriler arasından önemli bilgiyi seçip gereksiz bilgilerin ayıklanmasında, örneğin telefon görüşmelerindeki geri plan gürültüsünün süzülmesinde kullanılmaktadır.

**5. Verilerin taklit edilmesi:** Eldeki az bir veri ile daha büyük bir verinin elde edilmesinde kullanılmaktadır. Örnek olarak bir ses sanatçısının ses kaydından alınacak küçük bir parça ile söylemediği bir şarkının üretilmesi, telefonda başkasının sesinin taklit edilmesi verilebilir.

**6.** Elektrik sarfiyatı tahmininde, gelecek turist sayısının belirlenmesinde, bazı elektriksel ve elektronik hesaplamalarda, haritacılık işlemlerinde, trafik kontrol sistemlerinde, enerji tasarrufu için enerji yalıtımında, stok yönetiminde, talep tahmininde kullanılmaktadır (Yıldız, 2006).

### 3.13. Tahmin Değerlendirme Yöntemleri

B. J. modelleri ve yapay sinir ağları arasındaki tahmin performanslarının karşılaştırılmasında, genellikle aşağıdaki ölçütler kullanılır. Tahmin hatasına dayanılarak yapılan karşılaştırmalar için sıklıkla kullanılan bu ölçütler aşağıdaki eşitliklerde verildiği gibidir:

$$\text{Ortalama Hata Kare (MSE)} = \sum (e_t)^2 / N \quad (3.16)$$

$$\text{Ortalama Mutlak Hata (MAE)} = \sum |e_t| / N \quad (3.17)$$

$$\text{Ortalama Mutlak Yüzde Hata (MAPE)} = (1/N) \sum |e_t / y_t| (100) \quad (3.18)$$

$$\text{Hata Kareler Toplamı (SSE)} = \sum (e_t)^2 \quad (3.19)$$

$$\text{Ortalama Hata Karenin Karekökü (RMSE)} = \sqrt{MSE} \quad (3.20)$$

Bu eşitliklerde  $e_t$  tahmin hatasını,  $y_t$   $t$  dönemi gözlem değerini ve  $N$  hata terimleri sayısını göstermektedir (Zhang ve Ark. 1998; Erdoğan 2006).

## 4. İMKB ULUSAL-100 ENDEKSİNİN TAHMİN EDİLMESİNDE YAPAY SİNİR AĞLARININ KULLANILMASI

Bu bölümde İMKB Ulusal-100 endeksinin belirlenen dönemler için tahmin edilmesinde B.J. modellerinin ve yapay sinir ağlarının nasıl kullanıldığı aşamalı olarak ele alınmıştır. Öncelikle uygulamada incelenen İMKB Ulusal-100 endeksi hakkında bilgi verilmiş, ele alınan veri seti için B.J. modelleri ile uygun model belirlenmiş, bu modelin uygunluğu sınıandıktan sonra bu model kullanılarak ileriye dönük tahminde bulunulmuştur. Uygulamanın diğer aşamasında aynı veri seti için yapay sinir ağları ile en iyi 5 model belirlenmiş ve bu modeller kullanılarak ileriye dönük tahminde bulunulmuştur. En iyi model belirlendikten sonra B.J. modelleri ve yapay sinir ağları kullanılarak yapılan öngörüler ortalama hata kare (MSE) performans ölçütü yardımıyla karşılaştırılmıştır. Bu aşamalar izleyen alt bölümlerde detaylı olarak ifade edilmiştir.

### 4.1. Giriş

Uygulamada ele alınan ve ulusal pazar için temel endeks olarak kullanılan İMKB Ulusal-100 endeksi, İMKB Ulusal-30 ve İMKB Ulusal-50 endeksleri kapsamında bulunan hisse senetlerini doğal olarak kapsamaktadır.

İMKB Ulusal-100 kapsamına alınacak hisse senetlerinin İMKB Yönetim Kurulu'nca belirlenen şartları sağlamasının yanında sektörel temsil kabiliyetinin de olması gerekmektedir.

İMKB Endeksleri, endeks kapsamında bulunan şirketlerin, aynen saklamada bulunanlar hariç, Takasbank saklamasında bulunan hisse senetlerinin toplam piyasa değeri ile ağırlıklı olarak hesaplanır.

Endekslerin hesaplanmasında aşağıdaki formül kullanılır:

$$E_t = \frac{\sum_{i=1}^n F_{it} N_{it} H_{it}}{B_t} \quad (4.1)$$

$E_t$ : Endeksin  $t$  zamandaki deęerini,

$n$ : Endekse dâhil olan hisse (şirket) sayısını,

$F_{it}$ : “ $i$ ” nci hisse senedinin  $t$  zamandaki fiyatını,

$N_{it}$ : “ $i$ ” nci hisse senedinin  $t$  zamandaki toplam sayısını (Ödenmiş veya çıkarılmış sermaye/1000),

$H_{it}$ : “ $i$ ” nci hisse senedinin  $t$  zamandaki aynen saklamada bulunanlar hariç, Takasbank saklamasında bulunan miktarının sermayeye göre tamsayıya yuvarlanmış oranını,

$B_t$ : Bölenin (Düzeltilmiş baz piyasa deęeri)  $t$  zamandaki deęerini ifade etmektedir.


İMKB endekslerinin hesaplanmasında en son tescil edilmiş fiyatlar kullanılır ve ayrıca eski ve yeni hisse senetlerinin fiyatları ayrı olarak dikkate alınır (Aslanargun ve Şakar, 2000).

İMKB endeksleri hakkında kısa bir bilgi verildikten sonra ele alınan zaman serisinin öngörüsü yapılmıştır. İlk önce B.J. modelleri kullanılarak öngörüde bulunulmuştur. Bu amaçla ele alınan aşamalar izleyen alt bölümlerde ifade edilmiştir.

## **4.2. Box-Jenkins Modelleri ile Tahmin**

Uygulamanın ilk aşamasında Box-Jenkins ARIMA modeli kullanılarak 2005 yılı için İMKB Ulusal-100 endeksi tahmin edilmiştir. Bu aşamada Ek-1’de verilen Ocak 1988-Aralık 2004 dönemine ait İMKB Ulusal-100 endeksinin aylık kapanış deęerlerine ilişkin zaman serisi grafięi Şekil 4.1.’de verilmiştir.





Şekil 4.1. İMKB Ulusal-100 endeksi aylık kapanış değerleri

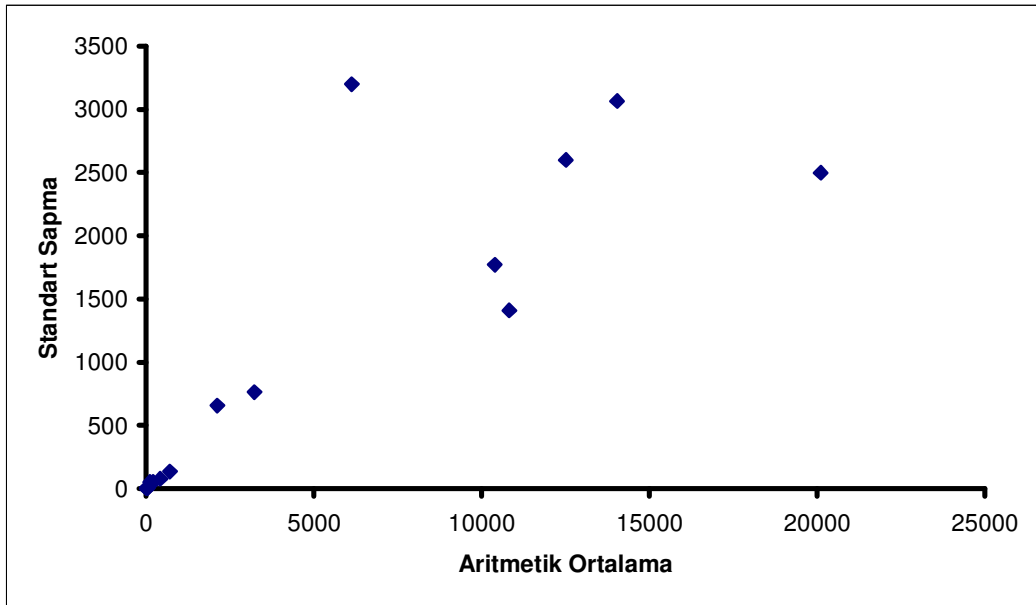
#### 4.2.1. Box-Jenkins modelinin belirlenmesi

Bu bölümde varyans durağanlığın sağlanıp sağlanmadığını belirlemek için bu seriye ait olan Standart Sapma-Ortalama grafiği (Range-Mean Plot) elde edilmiştir. Ocak 1988-Aralık 2004 dönemine ait İMKB Ulusal-100 endeksi aylık kapanış değerleri için her bir yılın Standart Sapma ve Aritmetik Ortalama değerleri Çizelge 4.1.'de gösterilmiştir.

**Çizelge 4.1.** 1988-2004 için Standart Sapma ve Aritmetik Ortalama değerleri

Yıl	Aritmetik Ortalama	Standart Sapma
1988	5,291667	1,455065
1989	9,799167	5,892413
1990	40,50083	7,594793
1991	37,5475	7,11313
1992	39,90667	4,266366
1993	112,3417	52,34344
1994	210,83	53,81748
1995	417,22	78,60107
1996	704,2917	137,5637
1997	2117,583	657,215
1998	3224,661	763,2376
1999	6121,629	3200,034
2000	14044,56	3066,191
2001	10386,3	1771,939
2002	10814,23	1410,5
2003	12507,84	2600,837
2004	20109,26	2499,032

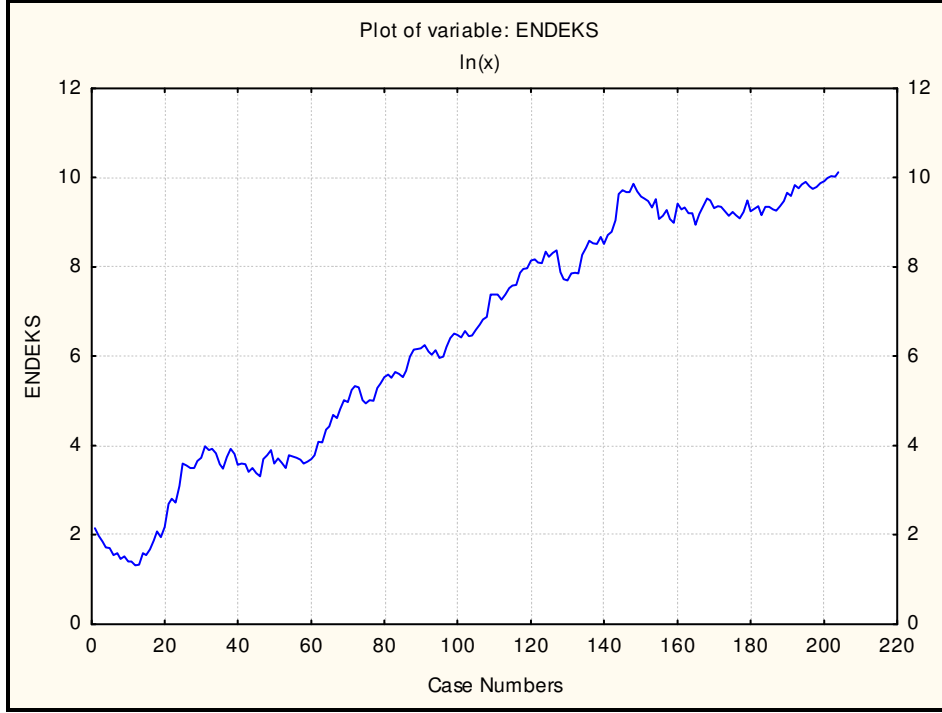
Çizelge 4.1.'de yer alan değerler ve Şekil 4.2.'de bulunan Standart Sapma-Ortalama grafiği Microsoft Office 2003 Excel programı kullanılarak elde edilmiştir.



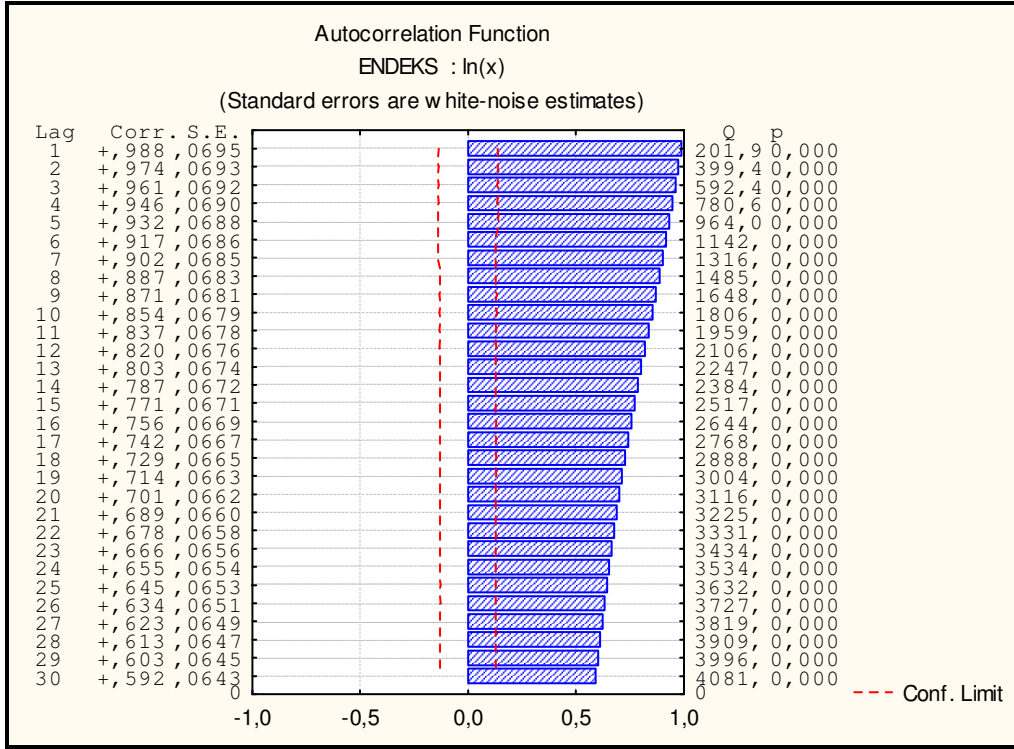
**Şekil 4.2.** Standart Sapma-Ortalama Grafiği

Şekil 4.2.'ye bakıldığında zaman serisinin Bölüm 2.4.4.'de ifade edildiği gibi varyans durağan olmadığı ve seriye doğal logaritma (ln) dönüşümünün

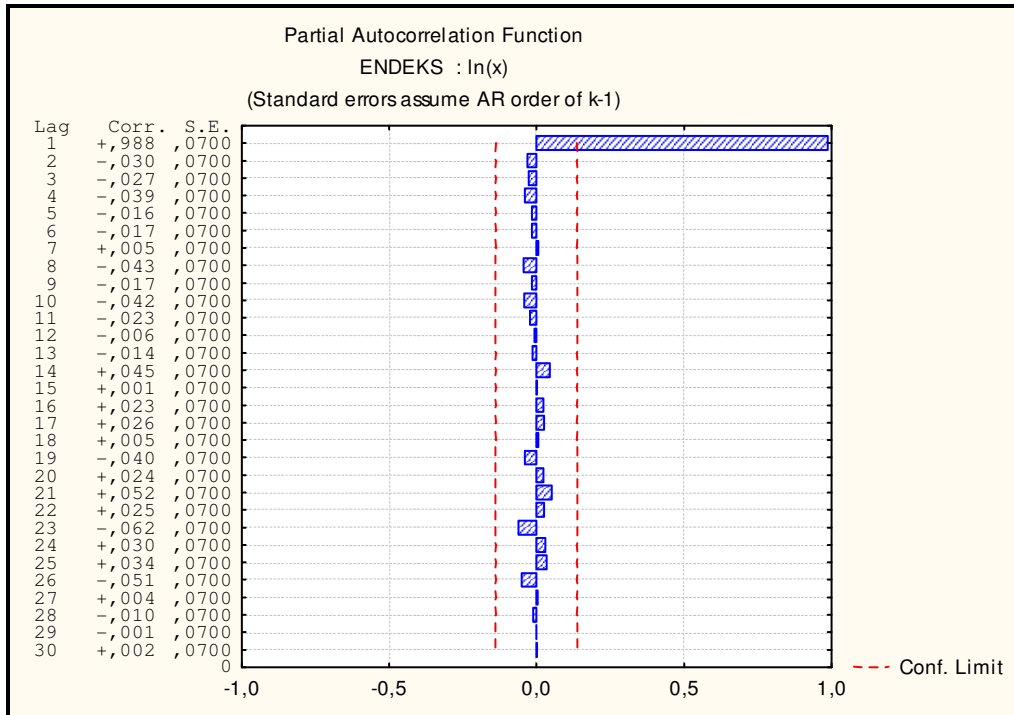
uygulanması gerektiği görülmektedir. Seriyeye doğal logaritma dönüşümü uygulandığında elde edilen  $\ln(X_t)$  serisi Ek-2’de, bu seriyeye ait grafik Şekil 4.3.’de verilmiştir. Bu serinin otokorelasyon fonksiyonu (ACF) Şekil 4.4.’de, kısmi otokorelasyon fonksiyonu (PACF) Şekil 4.5.’de görülmektedir.



Şekil 4.3.  $\ln(X_t)$  serisi



Şekil 4.4.  $\ln(X_t)$  serisinin otokorelasyon fonksiyonu (ACF)




Şekil 4.5.  $\ln(X_t)$  serisinin kısmi otokorelasyon fonksiyonu (PACF)

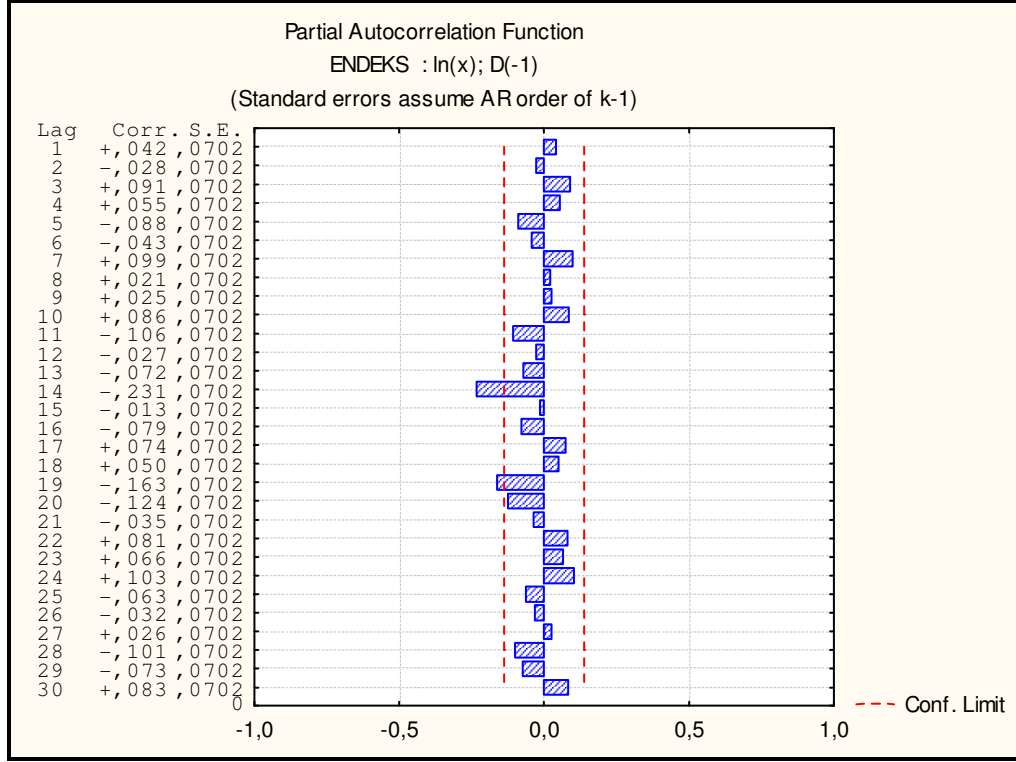
Bu fonksiyonlara bakıldığında seride trend etkeni belirgin olarak görülmekle beraber mevsimselliğin olmadığı görülmektedir. Trend etkisini kaldırmak için seriye mevsimsel olmayan birinci dereceden farklandırma yapılarak

$$x_t = \nabla(\ln(X_t)) = (\ln(X_t) - \ln(X_{t-1})) \quad (4.2)$$

serisi elde edilir. Elde edilen birinci dereceden farkı alınmış  $\ln(X_t)$  serisinin otokorelasyon fonksiyonu (ACF) Şekil 4.6.'de ve kısmi otokorelasyon fonksiyonu (PACF) Şekil 4.7.'de verilmiştir.



Şekil 4.6. Birinci dereceden farkı alınmış  $\ln(X_t)$  serisi için ACF



Şekil 4.7. Birinci dereceden farkı alınmış  $\ln(X_t)$  serisi için PACF

Şekil 4.6.'da elde edilen birinci dereceden farkı alınmış  $\ln(X_t)$  serisinin otokorelasyon fonksiyonu (ACF) ve Şekil 4.7.'de elde edilen kısmi otokorelasyon fonksiyonuna (PACF) bakıldığında bu serinin trend etkini içermediği görülmektedir.

Elde edilen  $\ln(X_t)$  serisi için parametre değerleri anlamlı ve MSE değeri küçük olan  $ARIMA(0,1,1)(0,1,0)_{12}$  modelinin  $\ln(X_t)$  serisi için en uygun model olduğunu karar verilmiştir.

$ARIMA(0,1,1)(0,1,0)_{12}$  modeli parametre kestirimi Çizelge 4.2.'de verilmiştir. Modelde bir MA parametresi vardır ve parametre değeri 0,89'dur. Bu parametre değerinin anlamlılığı t-testi ile sınındığında %95 güvenle anlamlı olduğu görülmüştür.


**Çizelge 4.2.**  $\ln(X_t)$  serisi için  $ARIMA(0,1,1)(0,1,0)_{12}$  parametre kestirimi

Transformations: ln(x),D(1),D(1)						
Model:(0,1,1)(0,1,0) MS Residual= 0,02903						
Paramet.	Param.	Asympt. Std. Err.	Asympt. t(201)	P	Lower 95% Conf	Upper 95% Conf
$q(1)$	0,890715	0,035936	24,78613	0,00	0,819855	0,961575

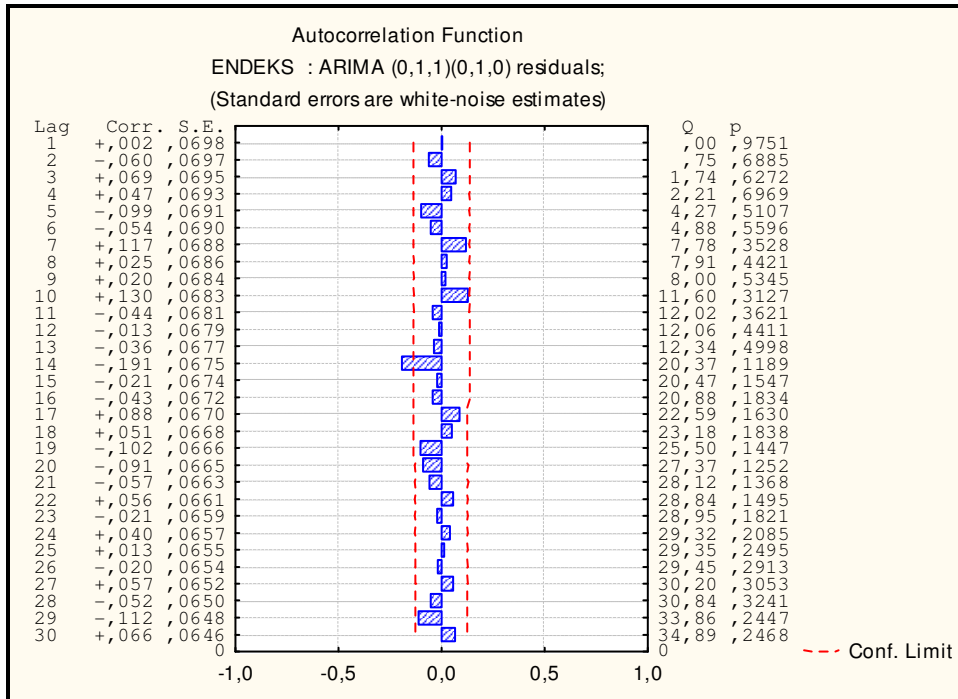
#### 4.2.2. Box-Jenkins modelinin uygunluğunun sınanması

Bu bölümde  $ARIMA(0,1,1)(0,1,0)_{12}$  modelinin uygunluğunun sınanması amaçlanmaktadır.  $ARIMA(0,1,1)(0,1,0)_{12}$  modelinin artıklarının dağılımı Şekil 4.8.'de ve otokorelasyon fonksiyonu (ACF) Şekil 4.9.'da gösterilmiştir. Modelin uygunluğunun sınanması için elde edilen Şekil 4.9.'da modelin artıklarının otokorelasyon fonksiyonuna bakıldığında artık serisi otokorelasyon katsayılarının %95 olasılıkla güven sınırları içinde kaldığı ve sadece 14. gecikmede sınırın aşıldığı görülmektedir. Modelin uygunluk sınaması için s.d. (serbestlik derecesi) =  $k-p-q = 30-0-1 = 29$  olarak hesaplanan Box-Ljung Q istatistiği değeri ile Ki-Kare değeri karşılaştırılır. Box-Ljung Q istatistiği değeri 33,86'dır. Ki-Kare tablo değeri %5 anlam düzeyinde ve 29 serbestlik derecesinde 42,55'dir ve Box-Ljung Q istatistiği değerinden daha büyüktür. Ayrıca Şekil 4.8.'de  $ARIMA(0,1,1)(0,1,0)_{12}$  modelinin artıklarının dağılımına bakıldığında modelin artıklarının normal dağıldığı görülür.

Sonuçta, İMKB Ulusal-100 Endeksi aylık kapanış değerlerinin ileriye dönük tahminlerinin (öngörülerinin) yapılmasında  $\ln(X_t)$  serisi için STATISTICA 7.0 paket programı kullanılarak elde edilen  $ARIMA(0,1,1)(0,1,0)_{12}$  modelinin %95 olasılıkla uygun olduğu kabul edilebilir.



Şekil 4.8. ARIMA  $(0,1,1)(0,1,0)_{12}$  modelinin artıklarının dağılımı



Şekil 4.9. ARIMA  $(0,1,1)(0,1,0)_{12}$  modelinin artıklarına ait ACF



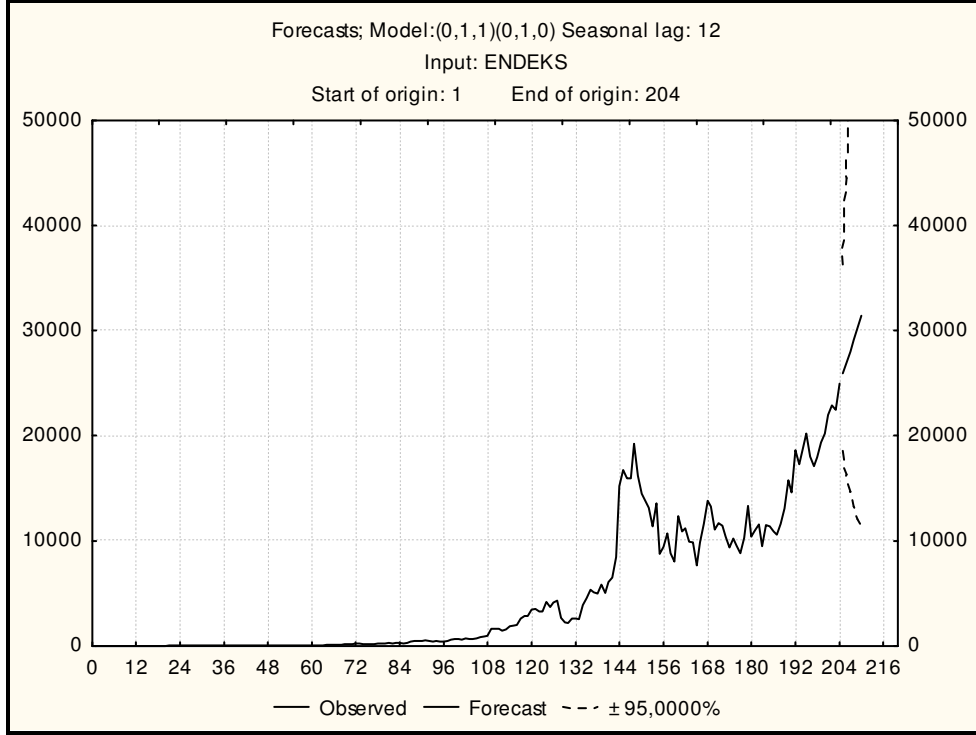
### 4.2.3. Box-Jenkins modelinin ileriye dönük tahmini

İMKB Ulusal-100 Endeksinin Ocak 1988-Aralık 2004 dönemi için ele alınan değerler yardımıyla elde edilen  $ARIMA(0,1,1)(0,1,0)_{12}$  modeli kullanılarak bu serinin  $t = 205, 206, 207, 208, 209, 210$  (Ocak 2005-Haziran 2005) dönemlerine ait öngörü değerleri hesaplanmıştır. Elde edilen öngörü değerleri, dönemler ve güven sınırları ile birlikte Çizelge 4.3.'de gösterilmiştir.

**Çizelge 4.3.**  $ARIMA(0,1,1)(0,1,0)_{12}$  modeli için öngörü değerleri ve güven sınırları

Dönem	Ay-Yıl	Öngörü değeri	Alt Sınır (%95)	Üst Sınır (%95)
205	Ocak-2005	25946,05	18542,78	36305,08
206	Şubat-2005	26958,43	16323,00	44523,49
207	Mart-2005	28010,31	14658,74	53522,88
208	Nisan-2005	29103,24	13257,14	63890,01
209	Mayıs-2005	30238,82	12018,25	76083,15
210	Haziran-2005	31418,70	10897,22	90585,95

İMKB Ulusal-100 Endeksinin geçmiş dönemlere ait değerleri ile birlikte  $ARIMA(0,1,1)(0,1,0)_{12}$  modeliyle belirlenen ve Çizelge 4.3.'de verilen öngörü değerleri, grafiksel olarak Şekil 4.10.'da gösterilmiştir.



Şekil 4.10. ARIMA (0,1,1)(0,1,0)<sub>12</sub> modeliyle belirlenen öngörü değerleri

Son aşamada Çizelge 4.3.'de elde edilen öngörü değerleri ile gözlenen değerler kullanılarak MSE hesaplanmıştır. Microsoft Office 2003 Excel programı yardımıyla Çizelge 4.4.'de yer alan ilgili değerler kullanılarak MSE bulunmuştur.

Çizelge 4.4. Gözlenen değerler ve öngörü değerleri

Ay-Yıl	y (Gözlenen değerler)	$\hat{y}$ (Öngörü değerleri)
Ocak-2005	27330,35	25946,05
Şubat-2005	28396,17	26958,43
Mart-2005	25557,76	28010,31
Nisan-2005	23591,64	29103,24
Mayıs-2005	25236,48	30238,82
Haziran-2005	26957,32	31418,70

$$MSE = \frac{1}{6} \sum_{i=1}^6 (y_i - \hat{y}_i)^2 = 14217239,31 \quad (4.3)$$

olarak hesaplanmıştır.

### 4.3. Yapay Sinir Ağları ile Tahmin

Bu bölümde, birinci aşamada ele alınan zaman serisi ( $X_t$ ) için yapay sinir ağları kullanılarak en uygun 5 model belirlenmiş ve her bir model için 2005 yılının ilk 6 ayına ilişkin öngöründe bulunulmuştur. Son olarak öngörü değerleri ve gözlenen değerler yardımıyla her bir model için MSE hesaplanıp en uygun modele karar verilmiştir. İlk aşamada olduğu gibi bu aşamada da STATISTICA 7.0 paket programı kullanılmıştır.

#### 4.3.1. Yapay sinir ağı modelinin belirlenmesi

Veri setine uygun yapay sinir ağı modeli belirlerken ilk olarak veriler STATISTICA paket programına uygun şekilde hazırlanır. Bu amaçla 12 giriş ve bir çıkış değişkeni olmak üzere Ek-3 ve Ek-4 hazırlanır.

Ek-3'de  $X_1$  giriş değişkeni için Ocak-1988 ile Aralık-2003 arasındaki değerler alınır.  $X_2$  giriş değişkenine gelindiğinde Ocak-1988 yerine bir dönem kaydırılıp Şubat-1988'den başlayarak Ocak-2004'e kadar değerler alınır. Bu şekilde her yeni giriş değişkeni ve en sonunda çıkış değişkeni için bir önceki değişkenden bir ay kaydırılarak veri seti oluşturulur. Sonunda  $Y$  çıkış değişkeni için Ocak-1989 ile Aralık-2004 arasındaki değerler alınır. Veri seti hazırlandıktan sonra paket programın Sinir Ağları menüsüne girilir. Bu aşamada problem tipi "Zaman Serisi" olarak belirlenir ve veri tipi bütün değişkenler için "sürekli" olarak seçilir ve "tamam" denilerek açılan sayfada 1000 adet ağın test edilmesi ve bunlardan en iyi 5 tanesinin seçilmesi istenir. Test edilecek ağ tipi olarak bütün tipler seçilir. Problem zaman serisi olarak alınır ve zaman aralığı olarak minimum 1, maksimum 12 belirlenir. "Tamam" denilerek 1000 adet ağ test edilir ve en iyi 5 tanesi elde edilir. Bu ağlar kaydedilir ve böylece model belirleme aşaması tamamlanır.

### 4.3.2. Yapay sinir ağı modelinin ileriye dönük tahmini

Belirlenen yapay sinir ağı modellerinden en uygunun seçimi için en iyi 5 model kullanılarak öngöründe bulunmuş ve her biri için MSE hesaplanarak en iyisi belirlenmiştir. Bu aşamada ilk olarak veriler Ek-5 ve Ek-6'deki şekilde hazırlanır.

Ek-5'de  $X_1$  giriş değişkeni için Şubat-1988 ile Ocak-2004 arasındaki değerler alınır.  $X_2$  giriş değişkenine gelindiğinde Şubat-1988 yerine bir dönem kaydırılıp Mart-1988'den başlayarak Şubat-2004'e kadar değerler alınır. Bu şekilde her yeni giriş değişkeni için bir önceki değişkenden bir ay kaydırılarak veri seti oluşturulur. Sonunda  $X_{12}$  giriş değişkeni için Ocak-1989 ile Aralık-2004 arasındaki değerler alınır. Veri seti hazırlandıktan sonra paket programın Sinir Ağları menüsüne girilir. Burada daha önce kaydedilmiş en iyi 5 ağ açılır. Problem tipi "Zaman Serisi" olarak belirlenir ve veri tipi bütün değişkenler için "sürekli" olarak seçilir. Bütün modeller seçilerek var olan modeli çalıştır kısmına geçilir. Burada bütün modeller için istenilirse özet değerler alınabilir. Özet değerler elde edildikten sonra her bir model için bir sonraki döneme ilişkin öngöründe bulunulur. İlgili modeller ve bunlara ait öngörü değerleri Çizelge 4.5., Çizelge 4.6., Çizelge 4.7., Çizelge 4.8. ve Çizelge 4.9.'de verilmiştir.

**Çizelge 4.5.** Linear 2:2-1:1 modeliyle hesaplanan öngörü değerleri

Dönem	Ay-Yıl	Öngörü değeri	Gözlenen değerler
205	Ocak-2005	24837,82	27330,35
206	Şubat-2005	27235,23	28396,17
207	Mart-2005	25504,51	25557,76
208	Nisan-2005	27133,13	23591,64
209	Mayıs-2005	26053,71	25236,48
210	Haziran-2005	27154,03	26957,32

**Çizelge 4.6.** MLP s3 3:9-1-1:1 modeliyle hesaplanan öngörü değerleri

<b>Dönem</b>	<b>Ay-Yıl</b>	<b>Öngörü değeri</b>	<b>Gözlenen değerler</b>
205	Ocak-2005	22185,57	27330,35
206	Şubat-2005	23588,34	28396,17
207	Mart-2005	23012,24	25557,76
208	Nisan-2005	22296,46	23591,64
209	Mayıs-2005	22479,03	25236,48
210	Haziran-2005	22376,06	26957,32

**Çizelge 4.7.** GRNN 5:5-92-2-1:1 modeliyle hesaplanan öngörü değerleri

<b>Dönem</b>	<b>Ay-Yıl</b>	<b>Öngörü değeri</b>	<b>Gözlenen değerler</b>
205	Ocak-2005	24883,62	27330,35
206	Şubat-2005	24871,19	28396,17
207	Mart-2005	24839,28	25557,76
208	Nisan-2005	24902,35	23591,64
209	Mayıs-2005	24933,00	25236,48
210	Haziran-2005	24954,44	26957,32

**Çizelge 4.8.** GRNN 7:7-92-2-1:1 modeliyle hesaplanan öngörü değerleri

<b>Dönem</b>	<b>Ay-Yıl</b>	<b>Öngörü değeri</b>	<b>Gözlenen değerler</b>
205	Ocak-2005	24918,12	27330,35
206	Şubat-2005	24929,19	28396,17
207	Mart-2005	24927,33	25557,76
208	Nisan-2005	24957,38	23591,64
209	Mayıs-2005	24965,45	25236,48
210	Haziran-2005	24968,55	26957,32

**Çizelge 4.9.** RBF s6 12:72-16-1:1 modeliyle hesaplanan öngörü değerleri

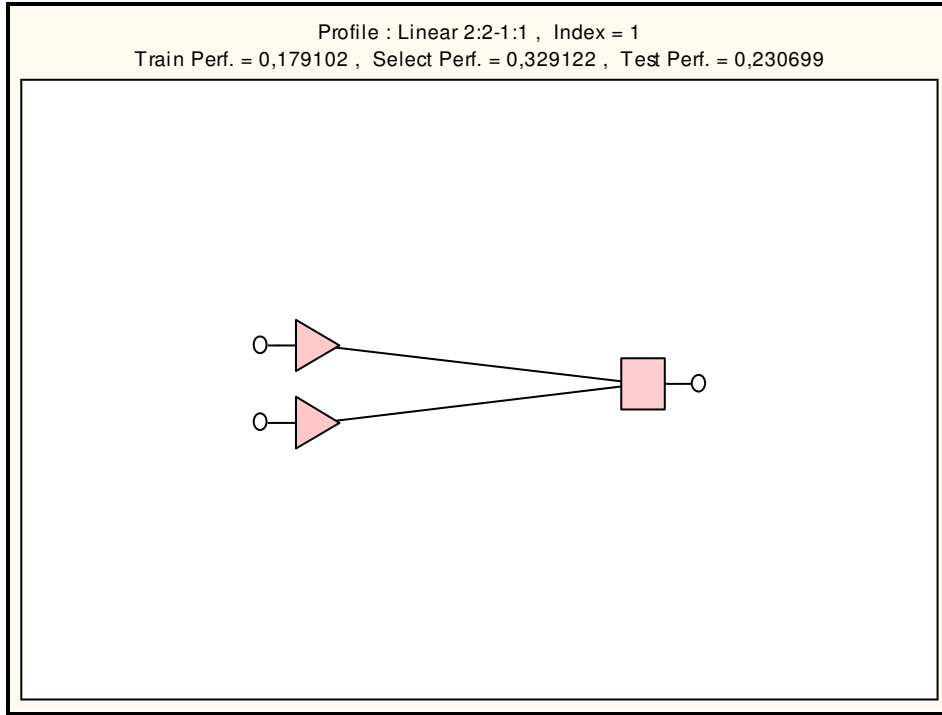
<b>Dönem</b>	<b>Ay-Yıl</b>	<b>Öngörü değeri</b>	<b>Gözlenen değerler</b>
205	Ocak-2005	25812,54	27330,35
206	Şubat-2005	25459,11	28396,17
207	Mart-2005	24357,31	25557,76
208	Nisan-2005	23724,13	23591,64
209	Mayıs-2005	21565,57	25236,48
210	Haziran-2005	18623,48	26957,32

Bütün modeller için öngörü değerleri elde edildikten sonra bu değerler kullanılarak Microsoft Office 2003 Excel programı yardımıyla her bir model için MSE bulunmuştur. Bu değerler Çizelge 4.10.'da verilmiştir.

**Çizelge 4.10.** En iyi 5 model için MSE

Model	MSE
Linear 2:2-1:1	3468672
MLP s3 3:9-1-1:1	14388771
GRNN 5:5-92-2-1:1	4124962
GRNN 7:7-92-2-1:1	4021692
RBF s6 12:72-16-1:1	15886195

Bu sinir ağlarından MSE'si en küçük olan ve dolayısıyla en iyi performans ölçütüne sahip olan ağ Doğrusal 2:2-1:1 sinir ağıdır. Bu ağın yapısı Şekil 4.11.'de gösterilmiştir.



**Şekil 4.11.** Doğrusal 2:2-1:1 ağının yapısı

Elde edilen bu ağa ilişkin bazı özellikleri ifade etmek gerekirse, bu ağ yapısı bir girdi ve çıktı katmanı olmak üzere iki katmana sahiptir. Bu katmanlardan girdi katmanında iki girdi değişkeni ve çıktı katmanında da bir çıktı değişkeni yer almaktadır. Her iki katmanda da kullanılan aktivasyon fonksiyonu Bölüm 3.4.3.'de ifade edilen özdeşlik aktivasyon fonksiyonudur. Bu ağa ilişkin ağırlıklar Çizelge 4.11.'de gösterilmiştir.

**Çizelge 4.11.** Doğrusal 2:2-1:1 ağının ağırlıkları

	<b>2.1</b>
<b>Thresh</b>	-0,002914
<b>1.1</b>	0,147587
<b>1.2</b>	0,762368

## 5. SONUÇ VE ÖNERİLER

Bu çalışmada, İMKB Ulusal-100 endeksi bir zaman serisi şeklinde ele alınarak hem B.J. yöntemiyle hem de yapay sinir ağları kullanılarak incelenmiştir. Endeks değerleri olarak Ocak 1988-Aralık 2004 dönemine ait İMKB Ulusal-100 endeksinin aylık kapanış değerleri alınmış ve Ocak-Haziran 2005 dönemi için öngöründe bulunulmuştur. Her iki yöntemin kullanılmasında STATISTICA paket programından yararlanılmış ve elde edilen sonuçlar ortalama hata kare (MSE) performans ölçütü kullanılarak karşılaştırılmıştır.

B.J. yöntemi ve yapay sinir ağları kullanılarak İMKB Ulusal-100 endeksi değerlerinden oluşan zaman serisi için en iyi modeller belirlenmiştir. Bu modeller yardımıyla öngöründe bulunulmuştur. Bu değerler Çizelge 5.1.'de gösterilmiştir.

**Çizelge 5.1.** YSA ve B.J. yöntemi için öngörü değerleri

Dönem	Ay-Yıl	Öngörü değerleri (YSA)	Öngörü değerleri (B.J.)
205	Ocak-2005	24837,82	25946,05
206	Şubat-2005	27235,23	26958,43
207	Mart-2005	25504,51	28010,31
208	Nisan-2005	27133,13	29103,24
209	Mayıs-2005	26053,71	30238,82
210	Haziran-2005	27154,03	31418,70

Her iki yöntemle elde edilen öngörü değerleri MSE performans ölçütü yardımıyla karşılaştırılmıştır. Bu değerler Çizelge 5.2.'de gösterilmiştir.

**Çizelge 5.2.** YSA ve B.J. yöntemi için MSE

Model	MSE
Linear 2:2-1:1	3468672
ARIMA (0,1,1)(0,1,0) <sub>12</sub>	14217239

Çizelge 5.2.'de doğrusal 2:2-1:1 modeline ait MSE değerinin B.J. yöntemiyle elde edilen ARIMA (0,1,1)(0,1,0)<sub>12</sub> modelinin MSE değerinden küçük olduğu görülmektedir.



Sonuçta Ocak 1988-Aralık 2004 dönemine ait İMKB Ulusal-100 endeksinin aylık kapanış değerleri bir zaman serisi olarak ele alındığında, yapay sinir ağıları kullanılarak elde edilen model yardımıyla yapılan öngörünün Box-Jenkins ARIMA modeli yardımıyla yapılan öngörüden daha iyi performans gösterdiği MSE performans ölçütü yardımıyla söylenebilir.

## KAYNAKLAR

- Akgül, I. (2003), *Zaman serisi analizi ve ARIMA modelleri*, Der Yayınları, İstanbul.
- Anderson, D. ve McNeill, G. (1992), *Artificial neural networks technology*, Kaman Science Corporation, New York, USA.
- Anonim (2002), *Statistica neural Networks version 6.0 with Statistica high performance statistical software training course for version 6*, Statsoft, Tulsa.
- Arıcı, H. (1991), *İstatistik: yöntemler ve uygulamalar*, Geliştirilmiş yeni bs., Ankara.
- Aslanargun, A. (1996), *Transfer fonksiyonu-hata modelleri ve tasarruf mevduatı faiz oranı ile dolar kuru fiyatları arasındaki ilişkinin tanımlanması ve öngörü amacıyla kullanımı*, Doktora Tezi, Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir.
- Aslanargun, A. ve Şakar, S. Ü. (2000), “İMKB Ulusal-100 Endeks’inin Box Jenkins ARIMA modeli kullanılarak tahmin edilmesi”, *Anadolu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, **16** (1-2), 43-58.
- Aslanargun, A., Mammadov, M., Yazıcı, B. ve Yolacan, S. (2007), “Comparison of ARIMA, Neural Networks and Hybrid Models in Time Series Tourist Arrival Forecasting”, *Journal of Statistical Computation and Simulation*, **77** (1), 29-53.
- Atlas, M. (2000), *İstatistik II: çözümlü örnekler*, Birlik Ofset Yayıncılık, Eskişehir.
- Bayramoğlu, M. F. (2007), *Finansal endekslerin öngörüsünde yapay sinir ağı modellerinin kullanılması: İMKB ulusal 100 endeksinin gün içi en yüksek ve en düşük değerlerinin öngörüsü üzerine bir uygulama*, Yüksek Lisans Tezi, Karaelmas Üniversitesi, Sosyal Bilimler Enstitüsü, Zonguldak.
- Biçen, C. (2006), *Box-Jenkins zaman serisi analiz yöntemi ile ileri beslemeli yapay sinir ağları tahminlerinin karşılaştırılması*, Yüksek Lisans Tezi, Hacettepe Üniversitesi, Sağlık Bilimleri Enstitüsü, Ankara.
- Bishop, C. M. (1995), *Neural networks for pattern recognition*, Clarendon Pres, Oxford.

- Bolat, S., Kalenderli, Ö. ve Önal, E. (2004), “Yapay sinir ağı ile gaz karışımında elektrot açıklığına ve karışım yüzdelere bağlı olarak delinme gerilimlerinin belirlenmesi”, *Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu*, Yıldız Teknik Üniversitesi Elektrik-Elektronik Fakültesi.
- Box, G. P. ve Jenkins, G. M. (1970), *Time series analysis: forecasting and control*, Holden-Day Inc., San Francisco.
- Box, G. P. ve Pierce, D. A. (1970), *Distribution of residual autocorrelations in autoregressive-integrated moving average time series models*, *Journal of American Statistical Association*, **65332**:1509-1526.
- Chatfield, C. (1980), *The analysis of the time series an introduction*, Chapman and Hall, London.
- Chatfield, C. (1989), *The analysis of time series: an introduction*, Chapman and Hall Ltd., London.
- Cryer, J. D. (1986), *Time series analysis*, PWS-KENT Publishing Company, Boston.
- Diamantaras, K. I. ve Kung, S. Y. (1996), *Principal component neural networks: theory and applications*, John Wiley and Sons Inc., New York, USA.
- Elmas, Ç. (2003), *Yapay sinir ağları*, Seçkin Yayıncılık, Ankara.
- Erdoğan, G. (2006), *Yapay sinir ağları ile iktisadi ve finansal zaman dizilerinin kestirimi*, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Fausett, L. (1994), *Fundamentals of neural networks*, Prentice Hall, USA.
- Gately, E. (1996), *Neural networks for financial forecasting*, John Wiley and Sons Inc., New York, USA.
- Guyton, A. C. ve Hall, J. E. (2006), *Textbook of medical physiology*, Elsevier Saunders, Pennsylvania, USA.
- Haykin, S. (1999), *Neural networks: a comprehensive foundation*, Pearson Prentice Hall, India.
- Jain, L. C. ve Martin, N. M. (1998), *Fusion of neural networks, fuzzy systems and genetic algorithms: industrial applications*, CRC Press, USA.
- Johnson, L. A. ve Montgomery, D. C. (1974), *Operations research in production planning, scheduling and inventory control*, John Wiley and Sons, Inc., New York, USA.

- Kendal, S. M., Stuart, A. ve Ord, J. K. (1983), *The advanced theory of statistics*, Charles Griffin and Company, Belfast.
- Kohzadi, N., Boyd, M. S., Kermanshahi, B. ve Kaastra, I. (1996), *A comparison of artificial neural network and time series model for forecasting commodity prices*, *Neurocomputing* **10** (2), 169-181.
- Korum, U. (1972), *İstatistik*, Ankara Sevinç Matbaası, Ankara.
- Ljung, G. M. ve Box, G. P. (1978), *On a measure of lack of fit in time series model*, *Biometrika*, **65**:297-303.
- Mabert, V. A. ve Radcliffe, R. C. (1974), *A forecasting methodology as applied to financial time series*, *The Accounting Review*, **49**.
- MacKay, D. J. C. (2003), *Information theory, inference and learning algorithms*, Cambridge University Press, UK.
- Makridakis, S. ve Wheelwright, S. C. (1978), *Interactive forecasting univariate and multivariate methods*, Holden-Day Inc., San Francisco.
- Montgomery, D. C. ve Johnson, L. A. (1976), *Forecasting and time series analysis*, McGraw-Hill Book Company, New York, USA.
- Montgomery D. C., Johnson L. A. ve Gardiner J. S. (1990), *Forecasting and time series analysis*, McGraw-Hill, Inc., Singapore.
- Naylor, T. H., Seaks, T. G. ve Wichern, D. W. (1972), *Box-Jenkins methods: an alternative to econometric models*, *International Statistical Review*, **40** (2).
- Özdemir, Ü. (2007), *Çevre duyarlı hidrojellerin şişme kinetiğinin yapay sinir ağları ile modellenmesi*, Yüksek Lisans Tezi, Cumhuriyet Üniversitesi, Fen Bilimleri Enstitüsü, Sivas.
- Özmen, A. (1986), *Zaman serisi analizinde Box-Jenkins yöntemi ve banka mevduat tahmininde uygulama denemesi*, Doktora Tezi, Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü, Eskişehir.
- Öztemel, E. (2003), *Yapay sinir ağları*, Papatya Yayıncılık, İstanbul.
- Sağiroğlu, Ş., Beşdok, E. ve Erler, M. (2003), *Mühendislikte yapay zeka uygulamaları-1: yapay sinir ağları*, Ufuk Yayıncılık, Kayseri.
- Serper, Ö. (2000), *Uygulamalı istatistik*, Ezgi Kitabevi, Bursa.
- Smith, K. A. (2002), "Neural Networks for Business: An Introduction", *Neural Networks in Business: Techniques and Applications*, (Ed.: Smith, K. A. ve Gupta, J. N. D.) Idea Group Publishing, USA.
- Şen, Z. (2004), *Yapay sinir ağları ilkeleri*, Su Vakfı Yayınları, İstanbul.

- Tang, Z., Almeida, C. ve Fishwick, P. A. (1991), *Time series forecasting using neural networks vs Box-Jenkins Methodology*, Simulation, **575**:303-310.
- Terence, F. L. (1999), *Feedforward neural network methodology*, Springer-Verlag Inc., New York, USA.
- Usta, A. S. (2007), *Yapay sinir ađları uygulaması kullanılarak üretici fiyat endeksi (ÜFE) deđerlerinin öngörü modellenmesi ve analizi*, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Wei, W. W. S. (2006), *Time series analysis univariate and multivariate methods*, Pearson Education, Inc., USA.
- Yıldız, Ö. (2006), *Döviz kuru tahmininde yapay sinir ađlarının kullanımı*, Yüksek Lisans Tezi, Osmangazi Üniversitesi, Sosyal Bilimler Enstitüsü, Eskişehir.
- Yılmaz, A. (2004), *Hava kirliliđi zaman serilerinin öngörü amacıyla analizinde ARIMA modelleri ve bir uygulama*, Yüksek Lisans Tezi, Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü, Eskişehir.
- Yurtođlu, H. (2005), *Yapay sinir ađları metodolojisi ile öngörü modellenmesi: bazı makroekonomik deđişkenler için Türkiye örneđi*, Uzmanlık Tezi, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüđü, <http://ekutup.dpt.gov.tr/>
- Zhang, P. G. (2003), "Business Forecasting with Artificial Neural Networks: An Overview", *Neural Networks in Business Forecasting*, (Ed.: Zhang, G. P.) Idea Group Publishing, USA.
- Zilouchian, A. (2001), "Fundamentals of Neural Networks", *Intelligent Control Systems Using Soft Computing Methodologies*, (Ed.: Zilouchian, A. ve Jamshidi, M.), CRC Press, USA.

## EKLER

### Ek-1 Veri Seti

Tarih	Değer ( $X_t$ )	Tarih	Değer ( $X_t$ )
Ocak 1988	8,58000	Temmuz 1996	633,66000
Şubat 1988	7,21000	Ağustos 1996	645,33000
Mart 1988	6,35000	Eylül 1996	724,53000
Nisan 1988	5,54000	Ekim 1996	820,06000
Mayıs 1988	5,53000	Kasım 1996	917,59000
Haziran 1988	4,69000	Aralık 1996	975,89000
Temmuz 1988	4,93000	Ocak 1997	1605,00000
Ağustos 1988	4,28000	Şubat 1997	1612,00000
Eylül 1988	4,55000	Mart 1997	1613,00000
Ekim 1988	4,04000	Nisan 1997	1427,00000
Kasım 1988	4,06000	Mayıs 1997	1595,00000
Aralık 1988	3,74000	Haziran 1997	1857,00000
Ocak 1989	3,80000	Temmuz 1997	1953,00000
Şubat 1989	4,87000	Ağustos 1997	1980,00000
Mart 1989	4,66000	Eylül 1997	2593,00000
Nisan 1989	5,34000	Ekim 1997	2846,00000
Mayıs 1989	6,54000	Kasım 1997	2879,00000
Haziran 1989	7,96000	Aralık 1997	3451,00000
Temmuz 1989	7,01000	Ocak 1998	3547,18000
Ağustos 1989	8,76000	Şubat 1998	3272,21000
Eylül 1989	14,75000	Mart 1998	3259,06000
Ekim 1989	16,64000	Nisan 1998	4194,50000
Kasım 1989	15,08000	Mayıs 1998	3727,75000
Aralık 1989	22,18000	Haziran 1998	4100,00000
Ocak 1990	36,41000	Temmuz 1998	4322,32000
Şubat 1990	35,16000	Ağustos 1998	2635,14000
Mart 1990	32,94000	Eylül 1998	2265,94000
Nisan 1990	33,08000	Ekim 1998	2196,38000
Mayıs 1990	38,52000	Kasım 1998	2577,54000
Haziran 1990	41,33000	Aralık 1998	2597,91000
Temmuz 1990	53,84000	Ocak 1999	2568,16000
Ağustos 1990	49,39000	Şubat 1999	3890,83000
Eylül 1990	50,85000	Mart 1999	4554,07000
Ekim 1990	45,70000	Nisan 1999	5354,03000
Kasım 1990	36,23000	Mayıs 1999	5069,22000
Aralık 1990	32,56000	Haziran 1999	4950,21000
Ocak 1991	42,13000	Temmuz 1999	5805,45000
Şubat 1991	51,03000	Ağustos 1999	5018,28000
Mart 1991	45,20000	Eylül 1999	6071,12000
Nisan 1991	35,54000	Ekim 1999	6509,92000
Mayıs 1991	36,26000	Kasım 1999	8459,48000
Haziran 1991	35,87000	Aralık 1999	15208,78000
Temmuz 1991	30,41000	Ocak 2000	16715,00000
Ağustos 1991	33,01000	Şubat 2000	15946,00000
Eylül 1991	29,38000	Mart 2000	15920,00000
Ekim 1991	27,47000	Nisan 2000	19206,00000
Kasım 1991	40,58000	Mayıs 2000	16206,00000
Aralık 1991	43,69000	Haziran 2000	14466,00000
Ocak 1992	49,26000	Temmuz 2000	13870,00000

Şubat 1992	36,64000	Ağustos 2000	13132,06000
Mart 1992	40,77000	Eylül 2000	11350,30000
Nisan 1992	36,86000	Ekim 2000	13538,44000
Mayıs 1992	32,97000	Kasım 2000	8747,68000
Haziran 1992	44,07000	Aralık 2000	9437,21000
Temmuz 1992	42,64000	Ocak 2001	10685,07000
Ağustos 1992	41,58000	Şubat 2001	8791,60000
Eylül 1992	39,76000	Mart 2001	8022,72000
Ekim 1992	36,43000	Nisan 2001	12367,36000
Kasım 1992	37,86000	Mayıs 2001	10879,83000
Aralık 1992	40,04000	Haziran 2001	11204,24000
Ocak 1993	43,83000	Temmuz 2001	9914,61000
Şubat 1993	59,24000	Ağustos 2001	9878,88000
Mart 1993	58,64000	Eylül 2001	7625,87000
Nisan 1993	78,08000	Ekim 2001	9848,76000
Mayıs 1993	83,76000	Kasım 2001	11633,93000
Haziran 1993	107,79000	Aralık 2001	13782,76000
Temmuz 1993	100,78000	Ocak 2002	13252,32000
Ağustos 1993	123,57000	Şubat 2002	11055,67000
Eylül 1993	150,80000	Mart 2002	11679,43000
Ekim 1993	145,01000	Nisan 2002	11441,50000
Kasım 1993	189,77000	Mayıs 2002	10413,70000
Aralık 1993	206,83000	Haziran 2002	9379,92000
Ocak 1994	201,05000	Temmuz 2002	10236,46000
Şubat 1994	150,04000	Ağustos 2002	9547,30000
Mart 1994	140,87000	Eylül 2002	8842,24000
Nisan 1994	150,97000	Ekim 2002	10251,92000
Mayıs 1994	147,49000	Kasım 2002	13300,40000
Haziran 1994	197,66000	Aralık 2002	10369,92000
Temmuz 1994	217,52000	Ocak 2003	11032,03000
Ağustos 1994	252,82000	Şubat 2003	11574,44000
Eylül 1994	268,26000	Mart 2003	9475,09000
Ekim 1994	248,90000	Nisan 2003	11509,95000
Kasım 1994	281,81000	Mayıs 2003	11381,41000
Aralık 1994	272,57000	Haziran 2003	10884,43000
Ocak 1995	252,29000	Temmuz 2003	10572,04000
Şubat 1995	291,23000	Ağustos 2003	11611,84000
Mart 1995	398,37000	Eylül 2003	13055,90000
Nisan 1995	466,15000	Ekim 2003	15754,34000
Mayıs 1995	473,71000	Kasım 2003	14617,53000
Haziran 1995	482,33000	Aralık 2003	18625,02000
Temmuz 1995	519,44000	Ocak 2004	17259,25000
Ağustos 1995	451,40000	Şubat 2004	18889,20000
Eylül 1995	417,08000	Mart 2004	20190,83000
Ekim 1995	463,25000	Nisan 2004	18022,69000
Kasım 1995	391,14000	Mayıs 2004	17081,08000
Aralık 1995	400,25000	Haziran 2004	17967,60000
Ocak 1996	494,90000	Temmuz 2004	19380,86000
Şubat 1996	605,47000	Ağustos 2004	20218,37000
Mart 1996	670,45000	Eylül 2004	21953,52000
Nisan 1996	647,23000	Ekim 2004	22889,89000
Mayıs 1996	611,50000	Kasım 2004	22486,20000
Haziran 1996	704,89000	Aralık 2004	24971,68000

**Ek-2 Dönüşüm sonucu  $\ln(X_t)$  serisi**

2,149	3,590	5,016	6,452	8,531	9,366
1,975	3,483	4,977	6,470	8,507	9,345
1,848	3,741	5,246	6,586	8,667	9,251
1,712	3,932	5,332	6,709	8,521	9,146
1,710	3,811	5,304	6,822	8,711	9,234
1,545	3,571	5,011	6,883	8,781	9,164
1,595	3,591	4,948	7,381	9,043	9,087
1,454	3,580	5,017	7,385	9,630	9,235
1,515	3,415	4,994	7,386	9,724	9,496
1,396	3,497	5,287	7,263	9,677	9,247
1,401	3,380	5,382	7,375	9,675	9,309
1,319	3,313	5,533	7,527	9,863	9,357
1,335	3,703	5,592	7,577	9,693	9,156
1,583	3,777	5,517	7,591	9,580	9,351
1,539	3,897	5,641	7,861	9,537	9,340
1,675	3,601	5,608	7,954	9,483	9,295
1,878	3,708	5,531	7,965	9,337	9,266
2,074	3,607	5,674	8,146	9,513	9,360
1,947	3,496	5,987	8,174	9,077	9,477
2,170	3,786	6,145	8,093	9,152	9,665
2,691	3,753	6,161	8,089	9,277	9,590
2,812	3,728	6,179	8,342	9,082	9,832
2,713	3,683	6,253	8,224	8,990	9,756
3,099	3,595	6,112	8,319	9,423	9,846
3,595	3,634	6,033	8,372	9,295	9,913
3,560	3,690	6,138	7,877	9,324	9,799
3,495	3,780	5,969	7,726	9,202	9,746
3,499	4,082	5,992	7,695	9,198	9,796
3,651	4,071	6,204	7,855	8,939	9,872
3,722	4,358	6,406	7,862	9,195	9,914
3,986	4,428	6,508	7,851	9,362	9,997
3,900	4,680	6,473	8,266	9,531	10,038
3,929	4,613	6,416	8,424	9,492	10,021
3,822	4,817	6,558	8,586	9,311	10,125



**Ek-3 YSA modellemesi için veri girişi ( $X_1 - X_7$ )**

$X_1$	$X_2$	$X_3$	$X_4$	$X_5$	$X_6$	$X_7$
8,580	7,210	6,35	5,54	5,53	4,69	4,93
7,210	6,35	5,54	5,53	4,69	4,93	4,28
6,35	5,54	5,53	4,69	4,93	4,28	4,55
5,54	5,53	4,69	4,93	4,28	4,55	4,04
5,53	4,69	4,93	4,28	4,55	4,04	4,06
4,69	4,93	4,28	4,55	4,04	4,06	3,74
4,93	4,28	4,55	4,04	4,06	3,74	3,8
4,28	4,55	4,04	4,06	3,74	3,8	4,87
4,55	4,04	4,06	3,74	3,8	4,87	4,66
4,04	4,06	3,74	3,8	4,87	4,66	5,34
4,06	3,74	3,8	4,87	4,66	5,34	6,54
3,74	3,8	4,87	4,66	5,34	6,54	7,96
3,8	4,87	4,66	5,34	6,54	7,96	7,01
4,87	4,66	5,34	6,54	7,96	7,01	8,76
4,66	5,34	6,54	7,96	7,01	8,76	14,75
5,34	6,54	7,96	7,01	8,76	14,75	16,64
6,54	7,96	7,01	8,76	14,75	16,64	15,08
7,96	7,01	8,76	14,75	16,64	15,08	22,18
7,01	8,76	14,75	16,64	15,08	22,18	36,41
8,76	14,75	16,64	15,08	22,18	36,41	35,16
14,75	16,64	15,08	22,18	36,41	35,16	32,94
16,64	15,08	22,18	36,41	35,16	32,94	33,08
15,08	22,18	36,41	35,16	32,94	33,08	38,52
22,18	36,41	35,16	32,94	33,08	38,52	41,33
36,41	35,16	32,94	33,08	38,52	41,33	53,84
35,16	32,94	33,08	38,52	41,33	53,84	49,39
32,94	33,08	38,52	41,33	53,84	49,39	50,85
33,08	38,52	41,33	53,84	49,39	50,85	45,7
38,52	41,33	53,84	49,39	50,85	45,7	36,23
41,33	53,84	49,39	50,85	45,7	36,23	32,56
53,84	49,39	50,85	45,7	36,23	32,56	42,13
49,39	50,85	45,7	36,23	32,56	42,13	51,03
50,85	45,7	36,23	32,56	42,13	51,03	45,2
45,7	36,23	32,56	42,13	51,03	45,2	35,54
36,23	32,56	42,13	51,03	45,2	35,54	36,26
32,56	42,13	51,03	45,2	35,54	36,26	35,87
42,13	51,03	45,2	35,54	36,26	35,87	30,41
51,03	45,2	35,54	36,26	35,87	30,41	33,01
45,2	35,54	36,26	35,87	30,41	33,01	29,38
35,54	36,26	35,87	30,41	33,01	29,38	27,47
36,26	35,87	30,41	33,01	29,38	27,47	40,58
35,87	30,41	33,01	29,38	27,47	40,58	43,69
30,41	33,01	29,38	27,47	40,58	43,69	49,26
33,01	29,38	27,47	40,58	43,69	49,26	36,64
29,38	27,47	40,58	43,69	49,26	36,64	40,77
27,47	40,58	43,69	49,26	36,64	40,77	36,86
40,58	43,69	49,26	36,64	40,77	36,86	32,97
43,69	49,26	36,64	40,77	36,86	32,97	44,07
49,26	36,64	40,77	36,86	32,97	44,07	42,64
36,64	40,77	36,86	32,97	44,07	42,64	41,58
40,77	36,86	32,97	44,07	42,64	41,58	39,76
36,86	32,97	44,07	42,64	41,58	39,76	36,43

32,97	44,07	42,64	41,58	39,76	36,43	37,86
44,07	42,64	41,58	39,76	36,43	37,86	40,04
42,64	41,58	39,76	36,43	37,86	40,04	43,83
41,58	39,76	36,43	37,86	40,04	43,83	59,24
39,76	36,43	37,86	40,04	43,83	59,24	58,64
36,43	37,86	40,04	43,83	59,24	58,64	78,08
37,86	40,04	43,83	59,24	58,64	78,08	83,76
40,04	43,83	59,24	58,64	78,08	83,76	107,79
43,83	59,24	58,64	78,08	83,76	107,79	100,78
59,24	58,64	78,08	83,76	107,79	100,78	123,57
58,64	78,08	83,76	107,79	100,78	123,57	150,8
78,08	83,76	107,79	100,78	123,57	150,8	145,01
83,76	107,79	100,78	123,57	150,8	145,01	189,77
107,79	100,78	123,57	150,8	145,01	189,77	206,83
100,78	123,57	150,8	145,01	189,77	206,83	201,05
123,57	150,8	145,01	189,77	206,83	201,05	150,04
150,8	145,01	189,77	206,83	201,05	150,04	140,87
145,01	189,77	206,83	201,05	150,04	140,87	150,97
189,77	206,83	201,05	150,04	140,87	150,97	147,49
206,83	201,05	150,04	140,87	150,97	147,49	197,66
201,05	150,04	140,87	150,97	147,49	197,66	217,52
150,04	140,87	150,97	147,49	197,66	217,52	252,82
140,87	150,97	147,49	197,66	217,52	252,82	268,26
150,97	147,49	197,66	217,52	252,82	268,26	248,9
147,49	197,66	217,52	252,82	268,26	248,9	281,81
197,66	217,52	252,82	268,26	248,9	281,81	272,57
217,52	252,82	268,26	248,9	281,81	272,57	252,29
252,82	268,26	248,9	281,81	272,57	252,29	291,23
268,26	248,9	281,81	272,57	252,29	291,23	398,37
248,9	281,81	272,57	252,29	291,23	398,37	466,15
281,81	272,57	252,29	291,23	398,37	466,15	473,71
272,57	252,29	291,23	398,37	466,15	473,71	482,33
252,29	291,23	398,37	466,15	473,71	482,33	519,44
291,23	398,37	466,15	473,71	482,33	519,44	451,4
398,37	466,15	473,71	482,33	519,44	451,4	417,08
466,15	473,71	482,33	519,44	451,4	417,08	463,25
473,71	482,33	519,44	451,4	417,08	463,25	391,14
482,33	519,44	451,4	417,08	463,25	391,14	400,25
519,44	451,4	417,08	463,25	391,14	400,25	494,9
451,4	417,08	463,25	391,14	400,25	494,9	605,47
417,08	463,25	391,14	400,25	494,9	605,47	670,45
463,25	391,14	400,25	494,9	605,47	670,45	647,23
391,14	400,25	494,9	605,47	670,45	647,23	611,5
400,25	494,9	605,47	670,45	647,23	611,5	704,89
494,9	605,47	670,45	647,23	611,5	704,89	633,66
605,47	670,45	647,23	611,5	704,89	633,66	645,33
670,45	647,23	611,5	704,89	633,66	645,33	724,53
647,23	611,5	704,89	633,66	645,33	724,53	820,06
611,5	704,89	633,66	645,33	724,53	820,06	917,59
704,89	633,66	645,33	724,53	820,06	917,59	975,89
633,66	645,33	724,53	820,06	917,59	975,89	1605
645,33	724,53	820,06	917,59	975,89	1605	1612
724,53	820,06	917,59	975,89	1605	1612	1613
820,06	917,59	975,89	1605	1612	1613	1427
917,59	975,89	1605	1612	1613	1427	1595
975,89	1605	1612	1613	1427	1595	1857
1605	1612	1613	1427	1595	1857	1953
1612	1613	1427	1595	1857	1953	1980

1613	1427	1595	1857	1953	1980	2593
1427	1595	1857	1953	1980	2593	2846
1595	1857	1953	1980	2593	2846	2879
1857	1953	1980	2593	2846	2879	3451
1953	1980	2593	2846	2879	3451	3547,18
1980	2593	2846	2879	3451	3547,18	3272,21
2593	2846	2879	3451	3547,18	3272,21	3259,06
2846	2879	3451	3547,18	3272,21	3259,06	4194,5
2879	3451	3547,18	3272,21	3259,06	4194,5	3727,75
3451	3547,18	3272,21	3259,06	4194,5	3727,75	4100
3547,18	3272,21	3259,06	4194,5	3727,75	4100	4322,32
3272,21	3259,06	4194,5	3727,75	4100	4322,32	2635,14
3259,06	4194,5	3727,75	4100	4322,32	2635,14	2265,94
4194,5	3727,75	4100	4322,32	2635,14	2265,94	2196,38
3727,75	4100	4322,32	2635,14	2265,94	2196,38	2577,54
4100	4322,32	2635,14	2265,94	2196,38	2577,54	2597,91
4322,32	2635,14	2265,94	2196,38	2577,54	2597,91	2568,16
2635,14	2265,94	2196,38	2577,54	2597,91	2568,16	3890,83
2265,94	2196,38	2577,54	2597,91	2568,16	3890,83	4554,07
2196,38	2577,54	2597,91	2568,16	3890,83	4554,07	5354,03
2577,54	2597,91	2568,16	3890,83	4554,07	5354,03	5069,22
2597,91	2568,16	3890,83	4554,07	5354,03	5069,22	4950,21
2568,16	3890,83	4554,07	5354,03	5069,22	4950,21	5805,45
3890,83	4554,07	5354,03	5069,22	4950,21	5805,45	5018,28
4554,07	5354,03	5069,22	4950,21	5805,45	5018,28	6071,12
5354,03	5069,22	4950,21	5805,45	5018,28	6071,12	6509,92
5069,22	4950,21	5805,45	5018,28	6071,12	6509,92	8459,48
4950,21	5805,45	5018,28	6071,12	6509,92	8459,48	15208,78
5805,45	5018,28	6071,12	6509,92	8459,48	15208,78	16715
5018,28	6071,12	6509,92	8459,48	15208,78	16715	15946
6071,12	6509,92	8459,48	15208,78	16715	15946	15920
6509,92	8459,48	15208,78	16715	15946	15920	19206
8459,48	15208,78	16715	15946	15920	19206	16206
15208,78	16715	15946	15920	19206	16206	14466
16715	15946	15920	19206	16206	14466	13870
15946	15920	19206	16206	14466	13870	13132,06
15920	19206	16206	14466	13870	13132,06	11350,3
19206	16206	14466	13870	13132,06	11350,3	13538,44
16206	14466	13870	13132,06	11350,3	13538,44	8747,68
14466	13870	13132,06	11350,3	13538,44	8747,68	9437,21
13870	13132,06	11350,3	13538,44	8747,68	9437,21	10685,07
13132,06	11350,3	13538,44	8747,68	9437,21	10685,07	8791,6
11350,3	13538,44	8747,68	9437,21	10685,07	8791,6	8022,72
13538,44	8747,68	9437,21	10685,07	8791,6	8022,72	12367,36
8747,68	9437,21	10685,07	8791,6	8022,72	12367,36	10879,83
9437,21	10685,07	8791,6	8022,72	12367,36	10879,83	11204,24
10685,07	8791,6	8022,72	12367,36	10879,83	11204,24	9914,61
8791,6	8022,72	12367,36	10879,83	11204,24	9914,61	9878,88
8022,72	12367,36	10879,83	11204,24	9914,61	9878,88	7625,87
12367,36	10879,83	11204,24	9914,61	9878,88	7625,87	9848,76
10879,83	11204,24	9914,61	9878,88	7625,87	9848,76	11633,93
11204,24	9914,61	9878,88	7625,87	9848,76	11633,93	13782,76
9914,61	9878,88	7625,87	9848,76	11633,93	13782,76	13252,32
9878,88	7625,87	9848,76	11633,93	13782,76	13252,32	11055,67
7625,87	9848,76	11633,93	13782,76	13252,32	11055,67	11679,43
9848,76	11633,93	13782,76	13252,32	11055,67	11679,43	11441,5
11633,93	13782,76	13252,32	11055,67	11679,43	11441,5	10413,7
13782,76	13252,32	11055,67	11679,43	11441,5	10413,7	9379,92

13252,32	11055,67	11679,43	11441,5	10413,7	9379,92	10236,46
11055,67	11679,43	11441,5	10413,7	9379,92	10236,46	9547,3
11679,43	11441,5	10413,7	9379,92	10236,46	9547,3	8842,24
11441,5	10413,7	9379,92	10236,46	9547,3	8842,24	10251,92
10413,7	9379,92	10236,46	9547,3	8842,24	10251,92	13300,4
9379,92	10236,46	9547,3	8842,24	10251,92	13300,4	10369,92
10236,46	9547,3	8842,24	10251,92	13300,4	10369,92	11032,03
9547,3	8842,24	10251,92	13300,4	10369,92	11032,03	11574,44
8842,24	10251,92	13300,4	10369,92	11032,03	11574,44	9475,09
10251,92	13300,4	10369,92	11032,03	11574,44	9475,09	11509,95
13300,4	10369,92	11032,03	11574,44	9475,09	11509,95	11381,41
10369,92	11032,03	11574,44	9475,09	11509,95	11381,41	10884,43
11032,03	11574,44	9475,09	11509,95	11381,41	10884,43	10572,04
11574,44	9475,09	11509,95	11381,41	10884,43	10572,04	11611,84
9475,09	11509,95	11381,41	10884,43	10572,04	11611,84	13055,9
11509,95	11381,41	10884,43	10572,04	11611,84	13055,9	15754,34
11381,41	10884,43	10572,04	11611,84	13055,9	15754,34	14617,53
10884,43	10572,04	11611,84	13055,9	15754,34	14617,53	18625,02
10572,04	11611,84	13055,9	15754,34	14617,53	18625,02	17259,25
11611,84	13055,9	15754,34	14617,53	18625,02	17259,25	18889,2
13055,9	15754,34	14617,53	18625,02	17259,25	18889,2	20190,83
15754,34	14617,53	18625,02	17259,25	18889,2	20190,83	18022,69
14617,53	18625,02	17259,25	18889,2	20190,83	18022,69	17081,08
18625,02	17259,25	18889,2	20190,83	18022,69	17081,08	17967,6

**Ek-4 YSA modellemesi için veri girişi ( $X_8 - Y$ )**

$X_8$	$X_9$	$X_{10}$	$X_{11}$	$X_{12}$	$Y$
4,28	4,55	4,04	4,06	3,74	3,8
4,55	4,04	4,06	3,74	3,8	4,87
4,04	4,06	3,74	3,8	4,87	4,66
4,06	3,74	3,8	4,87	4,66	5,34
3,74	3,8	4,87	4,66	5,34	6,54
3,8	4,87	4,66	5,34	6,54	7,96
4,87	4,66	5,34	6,54	7,96	7,01
4,66	5,34	6,54	7,96	7,01	8,76
5,34	6,54	7,96	7,01	8,76	14,75
6,54	7,96	7,01	8,76	14,75	16,64
7,96	7,01	8,76	14,75	16,64	15,08
7,01	8,76	14,75	16,64	15,08	22,18
8,76	14,75	16,64	15,08	22,18	36,41
14,75	16,64	15,08	22,18	36,41	35,16
16,64	15,08	22,18	36,41	35,16	32,94
15,08	22,18	36,41	35,16	32,94	33,08
22,18	36,41	35,16	32,94	33,08	38,52
36,41	35,16	32,94	33,08	38,52	41,33
35,16	32,94	33,08	38,52	41,33	53,84
32,94	33,08	38,52	41,33	53,84	49,39
33,08	38,52	41,33	53,84	49,39	50,85
38,52	41,33	53,84	49,39	50,85	45,7
41,33	53,84	49,39	50,85	45,7	36,23
53,84	49,39	50,85	45,7	36,23	32,56
49,39	50,85	45,7	36,23	32,56	42,13
50,85	45,7	36,23	32,56	42,13	51,03
45,7	36,23	32,56	42,13	51,03	45,2
36,23	32,56	42,13	51,03	45,2	35,54
32,56	42,13	51,03	45,2	35,54	36,26
42,13	51,03	45,2	35,54	36,26	35,87
51,03	45,2	35,54	36,26	35,87	30,41
45,2	35,54	36,26	35,87	30,41	33,01
35,54	36,26	35,87	30,41	33,01	29,38
36,26	35,87	30,41	33,01	29,38	27,47
35,87	30,41	33,01	29,38	27,47	40,58
30,41	33,01	29,38	27,47	40,58	43,69
33,01	29,38	27,47	40,58	43,69	49,26
29,38	27,47	40,58	43,69	49,26	36,64
27,47	40,58	43,69	49,26	36,64	40,77
40,58	43,69	49,26	36,64	40,77	36,86
43,69	49,26	36,64	40,77	36,86	32,97
49,26	36,64	40,77	36,86	32,97	44,07
36,64	40,77	36,86	32,97	44,07	42,64
40,77	36,86	32,97	44,07	42,64	41,58
36,86	32,97	44,07	42,64	41,58	39,76
32,97	44,07	42,64	41,58	39,76	36,43
44,07	42,64	41,58	39,76	36,43	37,86
42,64	41,58	39,76	36,43	37,86	40,04
41,58	39,76	36,43	37,86	40,04	43,83
39,76	36,43	37,86	40,04	43,83	59,24
36,43	37,86	40,04	43,83	59,24	58,64
37,86	40,04	43,83	59,24	58,64	78,08

40,04	43,83	59,24	58,64	78,08	83,76
43,83	59,24	58,64	78,08	83,76	107,79
59,24	58,64	78,08	83,76	107,79	100,78
58,64	78,08	83,76	107,79	100,78	123,57
78,08	83,76	107,79	100,78	123,57	150,8
83,76	107,79	100,78	123,57	150,8	145,01
107,79	100,78	123,57	150,8	145,01	189,77
100,78	123,57	150,8	145,01	189,77	206,83
123,57	150,8	145,01	189,77	206,83	201,05
150,8	145,01	189,77	206,83	201,05	150,04
145,01	189,77	206,83	201,05	150,04	140,87
189,77	206,83	201,05	150,04	140,87	150,97
206,83	201,05	150,04	140,87	150,97	147,49
201,05	150,04	140,87	150,97	147,49	197,66
150,04	140,87	150,97	147,49	197,66	217,52
140,87	150,97	147,49	197,66	217,52	252,82
150,97	147,49	197,66	217,52	252,82	268,26
147,49	197,66	217,52	252,82	268,26	248,9
197,66	217,52	252,82	268,26	248,9	281,81
217,52	252,82	268,26	248,9	281,81	272,57
252,82	268,26	248,9	281,81	272,57	252,29
268,26	248,9	281,81	272,57	252,29	291,23
248,9	281,81	272,57	252,29	291,23	398,37
281,81	272,57	252,29	291,23	398,37	466,15
272,57	252,29	291,23	398,37	466,15	473,71
252,29	291,23	398,37	466,15	473,71	482,33
291,23	398,37	466,15	473,71	482,33	519,44
398,37	466,15	473,71	482,33	519,44	451,4
466,15	473,71	482,33	519,44	451,4	417,08
473,71	482,33	519,44	451,4	417,08	463,25
482,33	519,44	451,4	417,08	463,25	391,14
519,44	451,4	417,08	463,25	391,14	400,25
451,4	417,08	463,25	391,14	400,25	494,9
417,08	463,25	391,14	400,25	494,9	605,47
463,25	391,14	400,25	494,9	605,47	670,45
391,14	400,25	494,9	605,47	670,45	647,23
400,25	494,9	605,47	670,45	647,23	611,5
494,9	605,47	670,45	647,23	611,5	704,89
605,47	670,45	647,23	611,5	704,89	633,66
670,45	647,23	611,5	704,89	633,66	645,33
647,23	611,5	704,89	633,66	645,33	724,53
611,5	704,89	633,66	645,33	724,53	820,06
704,89	633,66	645,33	724,53	820,06	917,59
633,66	645,33	724,53	820,06	917,59	975,89
645,33	724,53	820,06	917,59	975,89	1605
724,53	820,06	917,59	975,89	1605	1612
820,06	917,59	975,89	1605	1612	1613
917,59	975,89	1605	1612	1613	1427
975,89	1605	1612	1613	1427	1595
1605	1612	1613	1427	1595	1857
1612	1613	1427	1595	1857	1953
1613	1427	1595	1857	1953	1980
1427	1595	1857	1953	1980	2593
1595	1857	1953	1980	2593	2846
1857	1953	1980	2593	2846	2879
1953	1980	2593	2846	2879	3451
1980	2593	2846	2879	3451	3547,18
2593	2846	2879	3451	3547,18	3272,21

2846	2879	3451	3547,18	3272,21	3259,06
2879	3451	3547,18	3272,21	3259,06	4194,5
3451	3547,18	3272,21	3259,06	4194,5	3727,75
3547,18	3272,21	3259,06	4194,5	3727,75	4100
3272,21	3259,06	4194,5	3727,75	4100	4322,32
3259,06	4194,5	3727,75	4100	4322,32	2635,14
4194,5	3727,75	4100	4322,32	2635,14	2265,94
3727,75	4100	4322,32	2635,14	2265,94	2196,38
4100	4322,32	2635,14	2265,94	2196,38	2577,54
4322,32	2635,14	2265,94	2196,38	2577,54	2597,91
2635,14	2265,94	2196,38	2577,54	2597,91	2568,16
2265,94	2196,38	2577,54	2597,91	2568,16	3890,83
2196,38	2577,54	2597,91	2568,16	3890,83	4554,07
2577,54	2597,91	2568,16	3890,83	4554,07	5354,03
2597,91	2568,16	3890,83	4554,07	5354,03	5069,22
2568,16	3890,83	4554,07	5354,03	5069,22	4950,21
3890,83	4554,07	5354,03	5069,22	4950,21	5805,45
4554,07	5354,03	5069,22	4950,21	5805,45	5018,28
5354,03	5069,22	4950,21	5805,45	5018,28	6071,12
5069,22	4950,21	5805,45	5018,28	6071,12	6509,92
4950,21	5805,45	5018,28	6071,12	6509,92	8459,48
5805,45	5018,28	6071,12	6509,92	8459,48	15208,78
5018,28	6071,12	6509,92	8459,48	15208,78	16715
6071,12	6509,92	8459,48	15208,78	16715	15946
6509,92	8459,48	15208,78	16715	15946	15920
8459,48	15208,78	16715	15946	15920	19206
15208,78	16715	15946	15920	19206	16206
16715	15946	15920	19206	16206	14466
15946	15920	19206	16206	14466	13870
15920	19206	16206	14466	13870	13132,06
19206	16206	14466	13870	13132,06	11350,3
16206	14466	13870	13132,06	11350,3	13538,44
14466	13870	13132,06	11350,3	13538,44	8747,68
13870	13132,06	11350,3	13538,44	8747,68	9437,21
13132,06	11350,3	13538,44	8747,68	9437,21	10685,07
11350,3	13538,44	8747,68	9437,21	10685,07	8791,6
13538,44	8747,68	9437,21	10685,07	8791,6	8022,72
8747,68	9437,21	10685,07	8791,6	8022,72	12367,36
9437,21	10685,07	8791,6	8022,72	12367,36	10879,83
10685,07	8791,6	8022,72	12367,36	10879,83	11204,24
8791,6	8022,72	12367,36	10879,83	11204,24	9914,61
8022,72	12367,36	10879,83	11204,24	9914,61	9878,88
12367,36	10879,83	11204,24	9914,61	9878,88	7625,87
10879,83	11204,24	9914,61	9878,88	7625,87	9848,76
11204,24	9914,61	9878,88	7625,87	9848,76	11633,93
9914,61	9878,88	7625,87	9848,76	11633,93	13782,76
9878,88	7625,87	9848,76	11633,93	13782,76	13252,32
7625,87	9848,76	11633,93	13782,76	13252,32	11055,67
9848,76	11633,93	13782,76	13252,32	11055,67	11679,43
11633,93	13782,76	13252,32	11055,67	11679,43	11441,5
13782,76	13252,32	11055,67	11679,43	11441,5	10413,7
13252,32	11055,67	11679,43	11441,5	10413,7	9379,92
11055,67	11679,43	11441,5	10413,7	9379,92	10236,46
11679,43	11441,5	10413,7	9379,92	10236,46	9547,3
11441,5	10413,7	9379,92	10236,46	9547,3	8842,24
10413,7	9379,92	10236,46	9547,3	8842,24	10251,92
9379,92	10236,46	9547,3	8842,24	10251,92	13300,4
10236,46	9547,3	8842,24	10251,92	13300,4	10369,92

9547,3	8842,24	10251,92	13300,4	10369,92	11032,03
8842,24	10251,92	13300,4	10369,92	11032,03	11574,44
10251,92	13300,4	10369,92	11032,03	11574,44	9475,09
13300,4	10369,92	11032,03	11574,44	9475,09	11509,95
10369,92	11032,03	11574,44	9475,09	11509,95	11381,41
11032,03	11574,44	9475,09	11509,95	11381,41	10884,43
11574,44	9475,09	11509,95	11381,41	10884,43	10572,04
9475,09	11509,95	11381,41	10884,43	10572,04	11611,84
11509,95	11381,41	10884,43	10572,04	11611,84	13055,9
11381,41	10884,43	10572,04	11611,84	13055,9	15754,34
10884,43	10572,04	11611,84	13055,9	15754,34	14617,53
10572,04	11611,84	13055,9	15754,34	14617,53	18625,02
11611,84	13055,9	15754,34	14617,53	18625,02	17259,25
13055,9	15754,34	14617,53	18625,02	17259,25	18889,2
15754,34	14617,53	18625,02	17259,25	18889,2	20190,83
14617,53	18625,02	17259,25	18889,2	20190,83	18022,69
18625,02	17259,25	18889,2	20190,83	18022,69	17081,08
17259,25	18889,2	20190,83	18022,69	17081,08	17967,6
18889,2	20190,83	18022,69	17081,08	17967,6	19380,86
20190,83	18022,69	17081,08	17967,6	19380,86	20218,37
18022,69	17081,08	17967,6	19380,86	20218,37	21953,52
17081,08	17967,6	19380,86	20218,37	21953,52	22889,89
17967,6	19380,86	20218,37	21953,52	22889,89	22486,2
19380,86	20218,37	21953,52	22889,89	22486,2	24971,68



**Ek-5 YSA modeliyle öngörü için veri girişi ( $X_1 - X_6$ )**

$X_1$	$X_2$	$X_3$	$X_4$	$X_5$	$X_6$
7,210	6,35	5,54	5,53	4,69	4,93
6,35	5,54	5,53	4,69	4,93	4,28
5,54	5,53	4,69	4,93	4,28	4,55
5,53	4,69	4,93	4,28	4,55	4,04
4,69	4,93	4,28	4,55	4,04	4,06
4,93	4,28	4,55	4,04	4,06	3,74
4,28	4,55	4,04	4,06	3,74	3,8
4,55	4,04	4,06	3,74	3,8	4,87
4,04	4,06	3,74	3,8	4,87	4,66
4,06	3,74	3,8	4,87	4,66	5,34
3,74	3,8	4,87	4,66	5,34	6,54
3,8	4,87	4,66	5,34	6,54	7,96
4,87	4,66	5,34	6,54	7,96	7,01
4,66	5,34	6,54	7,96	7,01	8,76
5,34	6,54	7,96	7,01	8,76	14,75
6,54	7,96	7,01	8,76	14,75	16,64
7,96	7,01	8,76	14,75	16,64	15,08
7,01	8,76	14,75	16,64	15,08	22,18
8,76	14,75	16,64	15,08	22,18	36,41
14,75	16,64	15,08	22,18	36,41	35,16
16,64	15,08	22,18	36,41	35,16	32,94
15,08	22,18	36,41	35,16	32,94	33,08
22,18	36,41	35,16	32,94	33,08	38,52
36,41	35,16	32,94	33,08	38,52	41,33
35,16	32,94	33,08	38,52	41,33	53,84
32,94	33,08	38,52	41,33	53,84	49,39
33,08	38,52	41,33	53,84	49,39	50,85
38,52	41,33	53,84	49,39	50,85	45,7
41,33	53,84	49,39	50,85	45,7	36,23
53,84	49,39	50,85	45,7	36,23	32,56
49,39	50,85	45,7	36,23	32,56	42,13
50,85	45,7	36,23	32,56	42,13	51,03
45,7	36,23	32,56	42,13	51,03	45,2
36,23	32,56	42,13	51,03	45,2	35,54
32,56	42,13	51,03	45,2	35,54	36,26
42,13	51,03	45,2	35,54	36,26	35,87
51,03	45,2	35,54	36,26	35,87	30,41
45,2	35,54	36,26	35,87	30,41	33,01
35,54	36,26	35,87	30,41	33,01	29,38
36,26	35,87	30,41	33,01	29,38	27,47
35,87	30,41	33,01	29,38	27,47	40,58
30,41	33,01	29,38	27,47	40,58	43,69
33,01	29,38	27,47	40,58	43,69	49,26
29,38	27,47	40,58	43,69	49,26	36,64
27,47	40,58	43,69	49,26	36,64	40,77
40,58	43,69	49,26	36,64	40,77	36,86
43,69	49,26	36,64	40,77	36,86	32,97
49,26	36,64	40,77	36,86	32,97	44,07
36,64	40,77	36,86	32,97	44,07	42,64
40,77	36,86	32,97	44,07	42,64	41,58
36,86	32,97	44,07	42,64	41,58	39,76
32,97	44,07	42,64	41,58	39,76	36,43

44,07	42,64	41,58	39,76	36,43	37,86
42,64	41,58	39,76	36,43	37,86	40,04
41,58	39,76	36,43	37,86	40,04	43,83
39,76	36,43	37,86	40,04	43,83	59,24
36,43	37,86	40,04	43,83	59,24	58,64
37,86	40,04	43,83	59,24	58,64	78,08
40,04	43,83	59,24	58,64	78,08	83,76
43,83	59,24	58,64	78,08	83,76	107,79
59,24	58,64	78,08	83,76	107,79	100,78
58,64	78,08	83,76	107,79	100,78	123,57
78,08	83,76	107,79	100,78	123,57	150,8
83,76	107,79	100,78	123,57	150,8	145,01
107,79	100,78	123,57	150,8	145,01	189,77
100,78	123,57	150,8	145,01	189,77	206,83
123,57	150,8	145,01	189,77	206,83	201,05
150,8	145,01	189,77	206,83	201,05	150,04
145,01	189,77	206,83	201,05	150,04	140,87
189,77	206,83	201,05	150,04	140,87	150,97
206,83	201,05	150,04	140,87	150,97	147,49
201,05	150,04	140,87	150,97	147,49	197,66
150,04	140,87	150,97	147,49	197,66	217,52
140,87	150,97	147,49	197,66	217,52	252,82
150,97	147,49	197,66	217,52	252,82	268,26
147,49	197,66	217,52	252,82	268,26	248,9
197,66	217,52	252,82	268,26	248,9	281,81
217,52	252,82	268,26	248,9	281,81	272,57
252,82	268,26	248,9	281,81	272,57	252,29
268,26	248,9	281,81	272,57	252,29	291,23
248,9	281,81	272,57	252,29	291,23	398,37
281,81	272,57	252,29	291,23	398,37	466,15
272,57	252,29	291,23	398,37	466,15	473,71
252,29	291,23	398,37	466,15	473,71	482,33
291,23	398,37	466,15	473,71	482,33	519,44
398,37	466,15	473,71	482,33	519,44	451,4
466,15	473,71	482,33	519,44	451,4	417,08
473,71	482,33	519,44	451,4	417,08	463,25
482,33	519,44	451,4	417,08	463,25	391,14
519,44	451,4	417,08	463,25	391,14	400,25
451,4	417,08	463,25	391,14	400,25	494,9
417,08	463,25	391,14	400,25	494,9	605,47
463,25	391,14	400,25	494,9	605,47	670,45
391,14	400,25	494,9	605,47	670,45	647,23
400,25	494,9	605,47	670,45	647,23	611,5
494,9	605,47	670,45	647,23	611,5	704,89
605,47	670,45	647,23	611,5	704,89	633,66
670,45	647,23	611,5	704,89	633,66	645,33
647,23	611,5	704,89	633,66	645,33	724,53
611,5	704,89	633,66	645,33	724,53	820,06
704,89	633,66	645,33	724,53	820,06	917,59
633,66	645,33	724,53	820,06	917,59	975,89
645,33	724,53	820,06	917,59	975,89	1605
724,53	820,06	917,59	975,89	1605	1612
820,06	917,59	975,89	1605	1612	1613
917,59	975,89	1605	1612	1613	1427
975,89	1605	1612	1613	1427	1595
1605	1612	1613	1427	1595	1857
1612	1613	1427	1595	1857	1953
1613	1427	1595	1857	1953	1980

1427	1595	1857	1953	1980	2593
1595	1857	1953	1980	2593	2846
1857	1953	1980	2593	2846	2879
1953	1980	2593	2846	2879	3451
1980	2593	2846	2879	3451	3547,18
2593	2846	2879	3451	3547,18	3272,21
2846	2879	3451	3547,18	3272,21	3259,06
2879	3451	3547,18	3272,21	3259,06	4194,5
3451	3547,18	3272,21	3259,06	4194,5	3727,75
3547,18	3272,21	3259,06	4194,5	3727,75	4100
3272,21	3259,06	4194,5	3727,75	4100	4322,32
3259,06	4194,5	3727,75	4100	4322,32	2635,14
4194,5	3727,75	4100	4322,32	2635,14	2265,94
3727,75	4100	4322,32	2635,14	2265,94	2196,38
4100	4322,32	2635,14	2265,94	2196,38	2577,54
4322,32	2635,14	2265,94	2196,38	2577,54	2597,91
2635,14	2265,94	2196,38	2577,54	2597,91	2568,16
2265,94	2196,38	2577,54	2597,91	2568,16	3890,83
2196,38	2577,54	2597,91	2568,16	3890,83	4554,07
2577,54	2597,91	2568,16	3890,83	4554,07	5354,03
2597,91	2568,16	3890,83	4554,07	5354,03	5069,22
2568,16	3890,83	4554,07	5354,03	5069,22	4950,21
3890,83	4554,07	5354,03	5069,22	4950,21	5805,45
4554,07	5354,03	5069,22	4950,21	5805,45	5018,28
5354,03	5069,22	4950,21	5805,45	5018,28	6071,12
5069,22	4950,21	5805,45	5018,28	6071,12	6509,92
4950,21	5805,45	5018,28	6071,12	6509,92	8459,48
5805,45	5018,28	6071,12	6509,92	8459,48	15208,78
5018,28	6071,12	6509,92	8459,48	15208,78	16715
6071,12	6509,92	8459,48	15208,78	16715	15946
6509,92	8459,48	15208,78	16715	15946	15920
8459,48	15208,78	16715	15946	15920	19206
15208,78	16715	15946	15920	19206	16206
16715	15946	15920	19206	16206	14466
15946	15920	19206	16206	14466	13870
15920	19206	16206	14466	13870	13132,06
19206	16206	14466	13870	13132,06	11350,3
16206	14466	13870	13132,06	11350,3	13538,44
14466	13870	13132,06	11350,3	13538,44	8747,68
13870	13132,06	11350,3	13538,44	8747,68	9437,21
13132,06	11350,3	13538,44	8747,68	9437,21	10685,07
11350,3	13538,44	8747,68	9437,21	10685,07	8791,6
13538,44	8747,68	9437,21	10685,07	8791,6	8022,72
8747,68	9437,21	10685,07	8791,6	8022,72	12367,36
9437,21	10685,07	8791,6	8022,72	12367,36	10879,83
10685,07	8791,6	8022,72	12367,36	10879,83	11204,24
8791,6	8022,72	12367,36	10879,83	11204,24	9914,61
8022,72	12367,36	10879,83	11204,24	9914,61	9878,88
12367,36	10879,83	11204,24	9914,61	9878,88	7625,87
10879,83	11204,24	9914,61	9878,88	7625,87	9848,76
11204,24	9914,61	9878,88	7625,87	9848,76	11633,93
9914,61	9878,88	7625,87	9848,76	11633,93	13782,76
9878,88	7625,87	9848,76	11633,93	13782,76	13252,32
7625,87	9848,76	11633,93	13782,76	13252,32	11055,67
9848,76	11633,93	13782,76	13252,32	11055,67	11679,43
11633,93	13782,76	13252,32	11055,67	11679,43	11441,5
13782,76	13252,32	11055,67	11679,43	11441,5	10413,7
13252,32	11055,67	11679,43	11441,5	10413,7	9379,92

11055,67	11679,43	11441,5	10413,7	9379,92	10236,46
11679,43	11441,5	10413,7	9379,92	10236,46	9547,3
11441,5	10413,7	9379,92	10236,46	9547,3	8842,24
10413,7	9379,92	10236,46	9547,3	8842,24	10251,92
9379,92	10236,46	9547,3	8842,24	10251,92	13300,4
10236,46	9547,3	8842,24	10251,92	13300,4	10369,92
9547,3	8842,24	10251,92	13300,4	10369,92	11032,03
8842,24	10251,92	13300,4	10369,92	11032,03	11574,44
10251,92	13300,4	10369,92	11032,03	11574,44	9475,09
13300,4	10369,92	11032,03	11574,44	9475,09	11509,95
10369,92	11032,03	11574,44	9475,09	11509,95	11381,41
11032,03	11574,44	9475,09	11509,95	11381,41	10884,43
11574,44	9475,09	11509,95	11381,41	10884,43	10572,04
9475,09	11509,95	11381,41	10884,43	10572,04	11611,84
11509,95	11381,41	10884,43	10572,04	11611,84	13055,9
11381,41	10884,43	10572,04	11611,84	13055,9	15754,34
10884,43	10572,04	11611,84	13055,9	15754,34	14617,53
10572,04	11611,84	13055,9	15754,34	14617,53	18625,02
11611,84	13055,9	15754,34	14617,53	18625,02	17259,25
13055,9	15754,34	14617,53	18625,02	17259,25	18889,2
15754,34	14617,53	18625,02	17259,25	18889,2	20190,83
14617,53	18625,02	17259,25	18889,2	20190,83	18022,69
18625,02	17259,25	18889,2	20190,83	18022,69	17081,08
17259,25	18889,2	20190,83	18022,69	17081,08	17967,6
18889,2	20190,83	18022,69	17081,08	17967,6	19380,86

**Ek-6 YSA modeliyle öngörü için veri girişi ( $X_7 - X_{12}$ )**

$X_7$	$X_8$	$X_9$	$X_{10}$	$X_{11}$	$X_{12}$
4,28	4,55	4,04	4,06	3,74	3,8
4,55	4,04	4,06	3,74	3,8	4,87
4,04	4,06	3,74	3,8	4,87	4,66
4,06	3,74	3,8	4,87	4,66	5,34
3,74	3,8	4,87	4,66	5,34	6,54
3,8	4,87	4,66	5,34	6,54	7,96
4,87	4,66	5,34	6,54	7,96	7,01
4,66	5,34	6,54	7,96	7,01	8,76
5,34	6,54	7,96	7,01	8,76	14,75
6,54	7,96	7,01	8,76	14,75	16,64
7,96	7,01	8,76	14,75	16,64	15,08
7,01	8,76	14,75	16,64	15,08	22,18
8,76	14,75	16,64	15,08	22,18	36,41
14,75	16,64	15,08	22,18	36,41	35,16
16,64	15,08	22,18	36,41	35,16	32,94
15,08	22,18	36,41	35,16	32,94	33,08
22,18	36,41	35,16	32,94	33,08	38,52
36,41	35,16	32,94	33,08	38,52	41,33
35,16	32,94	33,08	38,52	41,33	53,84
32,94	33,08	38,52	41,33	53,84	49,39
33,08	38,52	41,33	53,84	49,39	50,85
38,52	41,33	53,84	49,39	50,85	45,7
41,33	53,84	49,39	50,85	45,7	36,23
53,84	49,39	50,85	45,7	36,23	32,56
49,39	50,85	45,7	36,23	32,56	42,13
50,85	45,7	36,23	32,56	42,13	51,03
45,7	36,23	32,56	42,13	51,03	45,2
36,23	32,56	42,13	51,03	45,2	35,54
32,56	42,13	51,03	45,2	35,54	36,26
42,13	51,03	45,2	35,54	36,26	35,87
51,03	45,2	35,54	36,26	35,87	30,41
45,2	35,54	36,26	35,87	30,41	33,01
35,54	36,26	35,87	30,41	33,01	29,38
36,26	35,87	30,41	33,01	29,38	27,47
35,87	30,41	33,01	29,38	27,47	40,58
30,41	33,01	29,38	27,47	40,58	43,69
33,01	29,38	27,47	40,58	43,69	49,26
29,38	27,47	40,58	43,69	49,26	36,64
27,47	40,58	43,69	49,26	36,64	40,77
40,58	43,69	49,26	36,64	40,77	36,86
43,69	49,26	36,64	40,77	36,86	32,97
49,26	36,64	40,77	36,86	32,97	44,07
36,64	40,77	36,86	32,97	44,07	42,64
40,77	36,86	32,97	44,07	42,64	41,58
36,86	32,97	44,07	42,64	41,58	39,76
32,97	44,07	42,64	41,58	39,76	36,43
44,07	42,64	41,58	39,76	36,43	37,86
42,64	41,58	39,76	36,43	37,86	40,04
41,58	39,76	36,43	37,86	40,04	43,83
39,76	36,43	37,86	40,04	43,83	59,24
36,43	37,86	40,04	43,83	59,24	58,64
37,86	40,04	43,83	59,24	58,64	78,08

40,04	43,83	59,24	58,64	78,08	83,76
43,83	59,24	58,64	78,08	83,76	107,79
59,24	58,64	78,08	83,76	107,79	100,78
58,64	78,08	83,76	107,79	100,78	123,57
78,08	83,76	107,79	100,78	123,57	150,8
83,76	107,79	100,78	123,57	150,8	145,01
107,79	100,78	123,57	150,8	145,01	189,77
100,78	123,57	150,8	145,01	189,77	206,83
123,57	150,8	145,01	189,77	206,83	201,05
150,8	145,01	189,77	206,83	201,05	150,04
145,01	189,77	206,83	201,05	150,04	140,87
189,77	206,83	201,05	150,04	140,87	150,97
206,83	201,05	150,04	140,87	150,97	147,49
201,05	150,04	140,87	150,97	147,49	197,66
150,04	140,87	150,97	147,49	197,66	217,52
140,87	150,97	147,49	197,66	217,52	252,82
150,97	147,49	197,66	217,52	252,82	268,26
147,49	197,66	217,52	252,82	268,26	248,9
197,66	217,52	252,82	268,26	248,9	281,81
217,52	252,82	268,26	248,9	281,81	272,57
252,82	268,26	248,9	281,81	272,57	252,29
268,26	248,9	281,81	272,57	252,29	291,23
248,9	281,81	272,57	252,29	291,23	398,37
281,81	272,57	252,29	291,23	398,37	466,15
272,57	252,29	291,23	398,37	466,15	473,71
252,29	291,23	398,37	466,15	473,71	482,33
291,23	398,37	466,15	473,71	482,33	519,44
398,37	466,15	473,71	482,33	519,44	451,4
466,15	473,71	482,33	519,44	451,4	417,08
473,71	482,33	519,44	451,4	417,08	463,25
482,33	519,44	451,4	417,08	463,25	391,14
519,44	451,4	417,08	463,25	391,14	400,25
451,4	417,08	463,25	391,14	400,25	494,9
417,08	463,25	391,14	400,25	494,9	605,47
463,25	391,14	400,25	494,9	605,47	670,45
391,14	400,25	494,9	605,47	670,45	647,23
400,25	494,9	605,47	670,45	647,23	611,5
494,9	605,47	670,45	647,23	611,5	704,89
605,47	670,45	647,23	611,5	704,89	633,66
670,45	647,23	611,5	704,89	633,66	645,33
647,23	611,5	704,89	633,66	645,33	724,53
611,5	704,89	633,66	645,33	724,53	820,06
704,89	633,66	645,33	724,53	820,06	917,59
633,66	645,33	724,53	820,06	917,59	975,89
645,33	724,53	820,06	917,59	975,89	1605
724,53	820,06	917,59	975,89	1605	1612
820,06	917,59	975,89	1605	1612	1613
917,59	975,89	1605	1612	1613	1427
975,89	1605	1612	1613	1427	1595
1605	1612	1613	1427	1595	1857
1612	1613	1427	1595	1857	1953
1613	1427	1595	1857	1953	1980
1427	1595	1857	1953	1980	2593
1595	1857	1953	1980	2593	2846
1857	1953	1980	2593	2846	2879
1953	1980	2593	2846	2879	3451
1980	2593	2846	2879	3451	3547,18
2593	2846	2879	3451	3547,18	3272,21

2846	2879	3451	3547,18	3272,21	3259,06
2879	3451	3547,18	3272,21	3259,06	4194,5
3451	3547,18	3272,21	3259,06	4194,5	3727,75
3547,18	3272,21	3259,06	4194,5	3727,75	4100
3272,21	3259,06	4194,5	3727,75	4100	4322,32
3259,06	4194,5	3727,75	4100	4322,32	2635,14
4194,5	3727,75	4100	4322,32	2635,14	2265,94
3727,75	4100	4322,32	2635,14	2265,94	2196,38
4100	4322,32	2635,14	2265,94	2196,38	2577,54
4322,32	2635,14	2265,94	2196,38	2577,54	2597,91
2635,14	2265,94	2196,38	2577,54	2597,91	2568,16
2265,94	2196,38	2577,54	2597,91	2568,16	3890,83
2196,38	2577,54	2597,91	2568,16	3890,83	4554,07
2577,54	2597,91	2568,16	3890,83	4554,07	5354,03
2597,91	2568,16	3890,83	4554,07	5354,03	5069,22
2568,16	3890,83	4554,07	5354,03	5069,22	4950,21
3890,83	4554,07	5354,03	5069,22	4950,21	5805,45
4554,07	5354,03	5069,22	4950,21	5805,45	5018,28
5354,03	5069,22	4950,21	5805,45	5018,28	6071,12
5069,22	4950,21	5805,45	5018,28	6071,12	6509,92
4950,21	5805,45	5018,28	6071,12	6509,92	8459,48
5805,45	5018,28	6071,12	6509,92	8459,48	15208,78
5018,28	6071,12	6509,92	8459,48	15208,78	16715
6071,12	6509,92	8459,48	15208,78	16715	15946
6509,92	8459,48	15208,78	16715	15946	15920
8459,48	15208,78	16715	15946	15920	19206
15208,78	16715	15946	15920	19206	16206
16715	15946	15920	19206	16206	14466
15946	15920	19206	16206	14466	13870
15920	19206	16206	14466	13870	13132,06
19206	16206	14466	13870	13132,06	11350,3
16206	14466	13870	13132,06	11350,3	13538,44
14466	13870	13132,06	11350,3	13538,44	8747,68
13870	13132,06	11350,3	13538,44	8747,68	9437,21
13132,06	11350,3	13538,44	8747,68	9437,21	10685,07
11350,3	13538,44	8747,68	9437,21	10685,07	8791,6
13538,44	8747,68	9437,21	10685,07	8791,6	8022,72
8747,68	9437,21	10685,07	8791,6	8022,72	12367,36
9437,21	10685,07	8791,6	8022,72	12367,36	10879,83
10685,07	8791,6	8022,72	12367,36	10879,83	11204,24
8791,6	8022,72	12367,36	10879,83	11204,24	9914,61
8022,72	12367,36	10879,83	11204,24	9914,61	9878,88
12367,36	10879,83	11204,24	9914,61	9878,88	7625,87
10879,83	11204,24	9914,61	9878,88	7625,87	9848,76
11204,24	9914,61	9878,88	7625,87	9848,76	11633,93
9914,61	9878,88	7625,87	9848,76	11633,93	13782,76
9878,88	7625,87	9848,76	11633,93	13782,76	13252,32
7625,87	9848,76	11633,93	13782,76	13252,32	11055,67
9848,76	11633,93	13782,76	13252,32	11055,67	11679,43
11633,93	13782,76	13252,32	11055,67	11679,43	11441,5
13782,76	13252,32	11055,67	11679,43	11441,5	10413,7
13252,32	11055,67	11679,43	11441,5	10413,7	9379,92
11055,67	11679,43	11441,5	10413,7	9379,92	10236,46
11679,43	11441,5	10413,7	9379,92	10236,46	9547,3
11441,5	10413,7	9379,92	10236,46	9547,3	8842,24
10413,7	9379,92	10236,46	9547,3	8842,24	10251,92
9379,92	10236,46	9547,3	8842,24	10251,92	13300,4
10236,46	9547,3	8842,24	10251,92	13300,4	10369,92

9547,3	8842,24	10251,92	13300,4	10369,92	11032,03
8842,24	10251,92	13300,4	10369,92	11032,03	11574,44
10251,92	13300,4	10369,92	11032,03	11574,44	9475,09
13300,4	10369,92	11032,03	11574,44	9475,09	11509,95
10369,92	11032,03	11574,44	9475,09	11509,95	11381,41
11032,03	11574,44	9475,09	11509,95	11381,41	10884,43
11574,44	9475,09	11509,95	11381,41	10884,43	10572,04
9475,09	11509,95	11381,41	10884,43	10572,04	11611,84
11509,95	11381,41	10884,43	10572,04	11611,84	13055,9
11381,41	10884,43	10572,04	11611,84	13055,9	15754,34
10884,43	10572,04	11611,84	13055,9	15754,34	14617,53
10572,04	11611,84	13055,9	15754,34	14617,53	18625,02
11611,84	13055,9	15754,34	14617,53	18625,02	17259,25
13055,9	15754,34	14617,53	18625,02	17259,25	18889,2
15754,34	14617,53	18625,02	17259,25	18889,2	20190,83
14617,53	18625,02	17259,25	18889,2	20190,83	18022,69
18625,02	17259,25	18889,2	20190,83	18022,69	17081,08
17259,25	18889,2	20190,83	18022,69	17081,08	17967,6
18889,2	20190,83	18022,69	17081,08	17967,6	19380,86
20190,83	18022,69	17081,08	17967,6	19380,86	20218,37
18022,69	17081,08	17967,6	19380,86	20218,37	21953,52
17081,08	17967,6	19380,86	20218,37	21953,52	22889,89
17967,6	19380,86	20218,37	21953,52	22889,89	22486,2
19380,86	20218,37	21953,52	22889,89	22486,2	24971,68
20218,37	21953,52	22889,89	22486,2	24971,68	27330,35