

T.C.
CELAL BAYAR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
YÜKSEK LİSANS TEZİ

SATIŞ ÖNGÖRÜ MODELLEMESİ TEKNİĞİ OLARAK YAPAY SİNİR AĞLARININ
KULLANIMI: “PETKİM’DE UYGULANMASI”

BURÇİN ATASEVEN

DANIŞMAN: YRD. DOÇ. DR. METİN ÖNER

MANİSA
2007

T.C.
CELAL BAYAR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
YÜKSEK LİSANS TEZİ

SATIŞ ÖNGÖRÜ MODELLEMESİ TEKNİĞİ OLARAK YAPAY SİNİR AĞLARININ
KULLANIMI: “PETKİM’DE UYGULANMASI”

BURÇİN ATASEVEN

DANIŞMAN: YRD. DOÇ. DR. METİN ÖNER

MANİSA
2007

YÜKSEK ÖĞRETİM KURULU DOKÜMANTASYON MERKEZİ
TEZ VERİ FORMU

Tez No:

Konu kodu:

Üniversite Kodu:

* Not: Bu bölüm merkezimiz tarafından doldurulacaktır.

Tezin yazarının;

Soyadı: **ATASEVEN**

Adı: **BURÇIN**

Tezin Türkçe Adı: **Satış Öngörü Modellemesi Tekniği Olarak Yapay Sinir Ağlarının Kullanımı: "Petkim'de Uygulanması"**

Tezin Yabancı Dildeki adı: **Using Artificial Neural Networks As A Sales Forecasting Method: "An Application In Petkim"**

Tezin yapıldığı;

Üniversite: **Celal Bayar Üniversitesi** Enstitü: **Sosyal Bilimler**

Yılı: **2007**

Diğer kuruluşlar:

Tezin Türü: 1- Yüksek Lisans **X**
2- Doktora
3- Tıpta Uzmanlık
4- Sanatta Yeterlilik

Dili: **Türkçe**
Sayfa Sayısı: **132**
Referans Sayısı: **91**

Tez Danışmanlarının;

Ünvanı: **Yrd.Doç.Dr.**

Adı: **METİN**

Soyadı: **ÖNER**

Türkçe anahtar kelimeler:

İngilizce anahtar kelimeler:

1- **Yapay Sinir Ağları**
2- **Öngörü Modelleri**
3- **Zaman Serileri Analizi**
4- **Box-Jenkins**
5- **Satış Tahmini**

1- **Artificial Neural Networks**
2- **Forecasting Methods**
3- **Time Series Analysis**
4- **Box-Jenkins**
5- **Sales Forecast**

Tarih:

İmza:

19.09.2007

ÖZET

Gelişen teknolojiye paralel olarak artan işleme ve hesaplama gücü ile birlikte, karmaşık simülasyonların yapılması ve gelişmiş yapay zeka teknolojilerini kullanılarak temel kriterlere dayalı olarak geleceğe dönük öngörüleme modellerinin gerçekleştirilmesi mümkün hale gelmiştir. Bu modellerin gerçekleştirilmesini sağlayan önemli bir uygulama alanı ise “Yapay Sinir Ağları”dır. Yapay sinir ağları insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleri olarak tanımlanabilir.

Bu çalışmada öngörüleme tekniklerinden zaman serisi yöntemlerine giren, “Trendin Bileşenlerine Ayrılması”, “Box-Jenkins (ARIMA) Metodolojisi” ve “Yapay Sinir Ağları” yöntemlerinin öngörü performanslarını karşılaştırarak en yüksek başarıyı sağlayan yöntemin belirlenmesi ve belirlenen yöntem yardımıyla 1996–2006 yılları için Petkim’den rastgele seçilen dört ürünün aylar itibariyle satış rakamlarının tahmin edilmesi amaçlanmıştır. Araştırmada, Petkim’de satışı yapılan dört ürünün Ocak 1996 – Kasım 2006 dönemine ait ton bazında aylık satış rakamlarından yararlanılmıştır.

Çalışmanın amacına yönelik olarak yapılan uygulamada herbir ürüne ait farklı yapılarıdaki Yapay Sinir Ağlarının, karşılaştırılan diğer geleneksel zaman serileri öngörüleme tekniklerine göre daha düşük hatalar vermesinden ötürü, satış öngörüleme tekniği olarak Yapay Sinir Ağlarının kullanımının daha başarılı sonuçlar üreteceği ve Petkim’de üretim planlamalarının yapılmasında yardımcı olacağı sonucuna varılmıştır.

ABSTRACT

Along with the processing and computation power increasing parallel with the developing technology, performing complex simulations and establishing forecasting models using developed artificial intelligence technologies based on the main criterions have been rendered possible. One important application field ensuring the possibility of these models is “Artificial Neural Networks”. Artificial Neural Networks can be defined as computer systems developed for the purpose of practicing the competencies such as producing and exploring new data by learning, which is a characteristic of human brain, automatically without any help.

In this study, it is aimed to determine the method providing the highest success by comparing the forecasting performances of the “Trend Decomposition”, “Box-Jenkins (ARIMA) Methodology” and “Artificial Neural Networks” which are included in the time series methods of the forecasting techniques and to forecast with the determined method the sales values of four products chosen randomly from the products being produced in Petkim for the years 1996-2006 are aimed. In this research, the sales values for the period of January 1996 – November 2006 of four products being sold in Petkim as a value ton are utilized.

In the application part of the study according to the aim of the study it is reached to conclusion that to use Artificial Neural Networks as a sales forecasting method will give more successful results and will help to make production plans in Petkim because Artificial Neural Networks having different structures relative to the given products have given lower errors compared to the other traditional time series forecasting methods.

YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum “Satış Öngörü Modellemesi Tekniğı Olarak Yapay Sinir Ağlarının Kullanımı: Petkim’de Uygulanması” adlı çalışmanın, tarafımdan bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın yazıldığını ve yararlandığım eserlerin bibliyografyada gösterilen eserlerden oluştuğunu, bunlara atıf yapılarak yararlanmış olduğumu belirtir ve bunu onurumla doğrularım.

19.09.2007

Burçin ATASEVEN

*Çalıřmam esnasında ve hayatımın
her döneminde her zaman desteklerini
hissettiđim kıymetli Ailem'e*

TEZ SAVUNMA SINAV TUTANAĞI

Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü 05/09/2007 tarih ve 16/Ek.11 sayılı toplantısında oluşturulan jürimiz tarafından Lisans Üstü öğretim Yönetmeliği'nin 24. Maddesi gereğince Enstitümüz İşletme Anabilim Dalı, Üretim Yönetimi ve Pazarlama Yüksek Lisans programı öğrencisi Burçin ATAŞEVEN'in "Satış Öngörü Modellemesi Tekniği Olarak Yapay Sinir Ağlarının Kullanılması: Petkim'de Uygulanması" Konulu tezi incelenmiş ve aday 19/09/2007 tarihinde saat 11.00'de jüri önünde tez savunmasına alınmıştır.

Adayın kişisel çalışmaya dayanan tezini savunmasından sonra 90 dakikalık süre içinde gerek tez konusu, gerekse tezin dayanağı olan anabilim dallarından jüri üyelerine sorulan sorulara verdiği cevaplar değerlendirilerek tezin

BAŞARILI olduğuna



OY BİRLİĞİ



DÜZELTME yapılmasına

*

OY ÇOKLUĞU



RED edilmesine

**

ile karar verilmiştir.



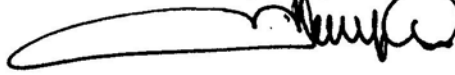
* Bu halde adaya 3 ay süre verilir.

** Bu halde adayın kaydı silinir.

BAŞKAN

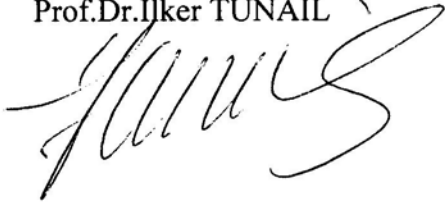
Yrd.Doç.Dr.Metin ÖNER

(Danışman)



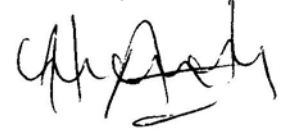
ÜYE

Prof.Dr.İlker TUNAIL



ÜYE

Yrd.Doç.Dr.Hüseyin AVUNDUK



Evet

Hayır

*** Tez, burs, ödül veya Teşvik prog. (Tüba, Fullbright vb.) aday olabilir



Tez, mutlaka basılmalıdır



Tez, mevcut haliyle basılmalıdır



Tez, gözden geçirildikten sonra basılmalıdır.



Tez, basımı gereksizdir.



İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET.....	III
ABSTRACT.....	IV
KISALTMALAR.....	XII
ŞEKİLLER LİSTESİ.....	XIII
TABLOLAR LİSTESİ.....	XV
EKLER LİSTESİ.....	XVI
GİRİŞ.....	XVII

BİRİNCİ BÖLÜM

YAPAY SİNİR AĞLARINA GENEL BAKIŞ

1.1. YAPAY ZEKA VE YAPAY ZEKA TEKNOLOJİLERİ.....	1
1.1.1. Yapay Zeka Kavramı.....	1
1.1.2. Yapay Zeka Teknolojileri.....	2
1.1.2.1. Uzman Sistemler.....	2
1.1.2.2. Yapay Sinir Ağları.....	3
1.1.2.3. Genetik Algoritmalar.....	4
1.1.2.4. Bulanık Önermeler Mantığı.....	4
1.1.2.5. Zeki Etmenler.....	5
1.1.2.6. Tabu Araştırması.....	5
1.1.2.7. Isıl İşlemler.....	6
1.1.2.8. Karınca Algoritması.....	6
1.1.2.9. Yumuşak Programlama.....	7
1.2. YAPAY SİNİR AĞLARININ GENEL TANIMI.....	7

	<u>Sayfa</u>
1.3. YAPAY SİNİR AĞLARININ TARİHSEL GELİŞİMİ.....	8
1.4. YAPAY SİNİR AĞLARININ GENEL ÖZELLİKLERİ.....	11
1.4.1. Biyolojik Sinir Hücresi.....	11
1.4.2. Yapay Sinir Hücresi.....	13
1.4.2.1. Girdiler.....	14
1.4.2.2. Ağırlıklar.....	14
1.4.2.3. Toplama Fonksiyonu.....	14
1.4.2.4. Aktivasyon Fonksiyonu.....	16
1.4.2.4.1. Doğrusal Fonksiyon.....	17
1.4.2.4.2. Basamak Fonksiyonu.....	18
1.4.2.4.3. Kutuplamalı Basamak Fonksiyonu.....	19
1.4.2.4.4. Parçalı Doğrusal Fonksiyon.....	19
1.4.2.4.5. Sigmoid Tipi Fonksiyon.....	20
1.4.2.4.6. Tanjant Hiperbolik Tipli Fonksiyon.....	20
1.4.2.4.7. Sinüs Tipli Fonksiyon.....	21
1.4.2.5. Çıkış İşlevi.....	22
1.4.3. Yapay Sinir Ağının Yapısı.....	22
1.4.4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları.....	24
1.4.4.1. Yapay Sinir Ağlarının Avantajları.....	25
1.4.4.2. Yapay Sinir Ağlarının Dezavantajları.....	27
1.5. YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI.....	28
1.5.1. İleri Beslemeli Ağlar.....	29
1.5.1.1. Çok Katmanlı Algılayıcılar.....	30
1.5.2. Geri Beslemeli Ağlar.....	31
1.6. YAPAY SİNİR AĞLARINDA ÖĞRENME.....	32
1.6.1. Danışmanlı Öğrenme.....	33
1.6.1.1. Geri Yayılım Öğrenme Kuralı.....	35
1.6.1.2. Geri Yayılım Öğrenme Kuralı Algoritması.....	36
1.6.2. Danışmansız Öğrenme.....	40
1.7. YAPAY SİNİR AĞLARININ UYGULAMA ALANLARI.....	42

İKİNCİ BÖLÜM
ÖNGÖRÜMLEME TEKNİKLERİ

	<u>Sayfa</u>
2.1. ÖNGÖRÜMLEME TEKNİKLERİ HAKKINDA GENEL BİLGİ.....	45
2.2. İLİŞKİYE DAYALI YÖNTEMLER.....	46
2.3. ZAMAN SERİLERİ ANALİZİ.....	47
2.3.1. Trendin Bileşenlerine Ayrılması Yöntemi.....	50
2.3.1.1. Trendin Belirlenmesi.....	50
2.3.1.2. Mevsim Etkisinin Belirlenmesi.....	52
2.3.1.3. Konjonktür ve Arızı Faktörlerin Etkilerinin Belirlenmesi.....	54
2.3.2. Box-Jenkins Metodolojisi.....	55
2.3.2.1. Box-Jenkins Modelinin Kurulumu.....	56
2.3.2.1.1. Otokovaryans Fonksiyonu.....	58
2.3.2.1.2. Otokorelasyon Fonksiyonu.....	59
2.3.2.1.3. Kısmi Otokorelasyon Fonksiyonu.....	61
2.3.2.2. Durağan Zaman Serileri.....	63
2.3.2.2.1. AR(p) Modelleri.....	64
2.3.2.2.2. MA(q) Modelleri.....	66
2.3.2.2.3. ARMA(p,q) Modelleri.....	68
2.3.2.3. Durağan Olmayan Zaman Serileri.....	69
2.3.2.3.1. ARIMA(p,d,q) Modelleri.....	70
2.4. YAPAY SİNİR AĞLARININ ÖNGÖRÜMLEMEDE KULLANIMI..	71

ÜÇÜNCÜ BÖLÜM

PETKİM'DE SATIŞ ÖNGÖRÜMLEMESİNE İLİŞKİN UYGULAMA

3.1. PETROKİMYA SANAYİ VE PETKİM HAKKINDA GENEL BİLGİ.....	76
3.2. PETKİM'DE SATIŞ VE SATIŞ ÖNGÖRÜMLEMESİNİN ÖNEMİ..	79

	<u>Sayfa</u>
3.3. PETKİM'DE UYGULAMA.....	83
3.3.1. Uygulamada Ele Alman Ürünlerin Tanıtılması.....	83
3.3.2. Trendin Bileşenlerine Ayrılma Yöntemiyle Satış	
Öngörümlemesi.....	86
3.3.2.1. Trendin Belirlenmesi.....	86
3.3.2.2. Mevsim Etkisinin Belirlenmesi.....	89
3.3.2.3. Konjonktür ve Arızı Faktörlerin Etkisinin Belirlenmesi... 	90
3.3.3. Box-Jenkins Metodolojisi İle Satış Öngörümlemesi.....	90
3.3.4. Yapay Sinir Ağları İle Satış Öngörümlemesi.....	94
3.3.4.1. Geliştirilen YSA'da Levenberg-Marquardt	
Öğrenme Metodu.....	95
3.3.4.2. Geliştirilen YSA'nın Topolojisi.....	97
3.3.5. Kullanılan Yöntemlerin Karşılaştırılması.....	102
SONUÇ VE ÖNERİLER.....	104
KAYNAKÇA.....	106
EK 1: DÖRT ÜRÜNE AİT ÜRÜN KARTLARI.....	116
EK 2: DÖRT ÜRÜNÜN SATIŞ RAKAMLARI.....	118

KISALTMALAR

ADALINE	Adaptif Lineer Eleman (Adaptive Linear Element)
AIC	Akaike Bilgi Kriteri (Akaike Information Criterion)
AR	Otoregresif (Auto-Regressive)
ARIMA	Birleřtirilmiř Otoregresif Hareketli Ortalama (Auto Regressive Integrated Moving Average)
ARMA	Otoregresif Hareketli Ortalama (Auto Regressive Moving Average)
ART	Adaptif Rezonans Teorisi (Adaptive Resonance Theory)
BM	Bulanık Mantık
GA	Genetik Algoritma
KOKF	Kısmi Otokorelasyon Fonksiyonu
LMS	En Küçük Ortalama Kareler (Least Mean Squares)
LVQ	Öğrenme Vektör Nicelendirmesi (Learning Vector Quantization)
MA	Hareketli Ortalama (Moving Average)
MADALINE	Çoklu Adaptif Lineer Eleman (Multiple Adaptive Linear Elements)
MAPE	Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Of Errors)
MLP	Çok Katmanlı Algılayıcılar (Multilayered Perceptrons)
MSE	Hata Kareleri Ortalaması (Mean Squared Error)
OKF	Otokorelasyon Fonksiyonu
OKK	Otokorelasyon Katsayısı
OKVF	Otokovaryans Fonksiyonu
ÖOKF	Örnek Otokorelasyon Fonksiyonu
ÖOKK	Örnel Otokorelasyon Katsayısı
RMSE	Ortalama Hata Karelerinin Karekökü (Root Mean Squared Error)
SARIMA	Mevsimsel Birleřtirilmiř Otoregresif Hareketli Ortalamalar (Seasonal Auto Regressive Integrated Moving Average)
SOM	Kendi Kendini Organize Eden Harita (Self Organizing Map)
TA	Tabu Arařtırması
YSA	Yapay Sinir Ağları
YZ	Yapay Zeka

ŞEKİLLER LİSTESİ

Şekil No	Şeklin Adı	Sayfa No
Şekil 1:	Biyolojik Sinir Hücresi.....	12
Şekil 2:	Yapay Sinir Hücresinin Yapısı.....	13
Şekil 3:	Doğrusal veya Lineer Fonksiyon.....	18
Şekil 4:	Basamak Fonksiyonları.....	18
Şekil 5:	Tek Kutuplamalı Basamak Fonksiyonu.....	19
Şekil 6:	Parçalı Doğrusal Fonksiyon.....	20
Şekil 7:	Sigmoid Fonksiyon.....	20
Şekil 8:	Tanjant Hiperbolik Fonksiyon.....	21
Şekil 9:	Sinüs Tipli Fonksiyon.....	22
Şekil 10:	Yapay Sinir Ağlarının Genel Yapısı.....	23
Şekil 11:	İleri Beslemeli Ağın Blok Gösterimi.....	29
Şekil 12:	Çok Katmanlı Algıyıcının Yapısı.....	30
Şekil 13:	Geri Beslemeli Ağın Blok Gösterimi.....	32
Şekil 14:	Danışmanlı Öğrenme Yapısı.....	34
Şekil 15:	Geri Yayılım Ağ Örneği.....	36
Şekil 16:	Bir Ağda Geri Yayılımlı Öğrenme Algoritmasının Uygulanması.....	39
Şekil 17:	Danışmansız Öğrenme Yapısı.....	41
Şekil 18:	Box-Jenkins Yöntemiyle Model Belirleme Aşamaları.....	57
Şekil 19:	İşletmelerde Öngörümler ve Planlama Süreci.....	82
Şekil 20:	PVC S 39 Ürünün Zaman Yolu Grafiği.....	84
Şekil 21:	PVC S 65 Ürünün Zaman Yolu Grafiği.....	84
Şekil 22:	YYPE S 0464 Ürünün Zaman Yolu Grafiği.....	85
Şekil 23:	PTA Ürünün Zaman Yolu Grafiği.....	85
Şekil 24:	PVC S 39 Ürününe Ait En Uygun Trend Denklemi Gösteren Grafik.....	87
Şekil 25:	PVC S 65 Ürününe Ait En Uygun Trend Denklemi Gösteren Grafik.....	87
Şekil 26:	YYPE S 0464 Ürününe Ait En Uygun Trend Denklemi Gösteren Grafik.....	88
Şekil 27:	PTA Ürününe Ait En Uygun Trend Denklemi Gösteren Grafik.....	88
Şekil 28:	PVC S 39 ve PVC S 65 Ürünlerinin OKF ve KOKF Grafiği.....	92

Şekil No	Şeklin Adı	Sayfa No
Şekil 29:	PTA ve YYPE S 0464 Ürünlerinin OKF ve KOKF Grafiği.....	93
Şekil 30:	Geliştirilen YSA Topoloji.....	98
Şekil 31:	YSA'nın PVC S 39 Ürünün Test Kümesine Ürettiği Değerler.....	100
Şekil 32:	YSA'nın PVC S 65 Ürünün Test Kümesine Ürettiği Değerler.....	100
Şekil 33:	YSA'nın YYPE S 0464 Ürünün Test Kümesine Ürettiği Değerler.....	101
Şekil 34:	YSA'nın PTA Ürünün Test Kümesine Ürettiği Değerler.....	101

TABLolar LİSTESİ

Tablo No	Tablonun Adı	Sayfa No
Tablo 1:	Toplama fonksiyonu örnekleri.....	15
Tablo 2:	Biyolojik Sinir Hücresi ile Yapay Sinir Hücresinin Karşılaştırılması.....	22
Tablo 3:	AR, MA ve ARMA Modelleri için OKF ve KOKF'larının Seyri.....	62
Tablo 4:	Ürünlerin Trend Denklemleri.....	86
Tablo 5:	Herbir Ürüne İlişkin Düzeltilmiş Mevsim İndeksleri Değerleri.....	89
Tablo 6:	Tüm Ürünlerin ADF Birim Kök Test Sonuçları.....	91
Tablo 7:	Tüm Ürünlerin En Uygun Box-Jenkins Modelleri, AIC Değerleri ve Model Denklemleri.....	94
Tablo 8:	Ele Alınan Ürünlere İlişkin Belirlenen En İyi Ağ Topolojileri.....	99
Tablo 9:	Ele Alınan Ürünlere İlişkin Örnek Uygulama Sonuçları.....	99
Tablo 10:	Kullanılan Yöntemlerin Öngörümle Performanslarının Karşılaştırılması....	103

EKLER LİSTESİ

Ek No	Ekin Adı	Sayfa No
EK 1:	Dört Ürüne Ait Ürün Kartları.....	116
EK 2:	Dört Ürünün Satış Rakamları.....	118

GİRİŞ

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.

Doğru tahminin (veya öngörünün) başarılı kararları beraberinde getireceği ve bu şekilde fayda sağlamanın en üst düzeye çıkartılabileceği gerçeği, öngörü modellemesine olan ilgiyi artırmaktadır. Artan ilgi ile birlikte, bu alanda her geçen gün önemli gelişmeler olmaktadır. Öngörü modellemesinde kullanılacak yöntemlerin çeşitliliği, model seçiminde bazı zorlukları da beraberinde getirmiştir.

Öngörümleme teknikleri, nitel öngörümleme yöntemleri ve nicel öngörümleme yöntemleri olmak üzere iki şekilde sınıflandırılabilir. Her iki yöntemin çıkış noktası ilgili değişkene ait gözlem değerleridir. Geçmiş ve şimdiki dönem gözlem değerlerinden, gelecek dönem gözlem değerleri belirli kurallar çerçevesinde öngörümleme yapılır. Nicel öngörümleme yöntemleri, istatistiksel yöntemlere dayanır. Nicel öngörümleme yöntemlerinde nasıl öngörümlemede bulunduğu net olarak bellidir ve işlemler matematikselidir. Geçmiş gözlem değerleri kullanılarak sürecin oluşmasına katkıda bulunan ilişkiler belirlenir ve bu ilişkilerin geleceğe yansımaları belirlenmeye çalışılır. Buna karşılık nitel öngörümleme yöntemleri, konu ile ilgili uzmanların bilgi ve deneyimlerinden yararlanarak bu alandaki gelişmelerin ne yönde olacağı, ne tür ihtiyaçlar ortaya çıkaracağı gibi konularda yoğunlaşmaktadır.

Bir zaman serisi, bir değişkene ilişkin zamana göre sıralanmış gözlem değerleridir. Zaman serisi analizi, öngörümlemede bulunulacak değişkenin geçmiş zaman serisini kullanarak gelecek değerlerin öngörümlemesi için model geliştirmede kullanılır. Model geliştirme, ilgili değişkene ait zaman serisinin analiz edilmesi, serinin ana eğiliminin ve özelliklerinin belirlenmesine dayanır. Serinin ana eğilimini ve özelliklerini yansıtacağı düşünülen bir model seçilir ve var olduğu seri değerleri kullanılarak modelin

parametreleri yaklaşık olarak bulunur. Serinin gelecekte de aynı özellikleri koruyacağı ve aynı eğilimi göstereceği varsayılarak, belirlenen model yardımı ile gelecek dönem değerleri kestirilmeye çalışılır. Zaman serileri analizi için yaygın olarak kullanılan bazı yöntemler vardır. Doğrusal zaman serilerinin analizinde oldukça başarılı sonuçlar veren Box-Jenkins modelleri bu tekniklerin en önemlilerindedir. Doğrusal ve durağan süreçlerde ya da durağan olmayan fakat bazı dönüşümlerle durağanlaştırılabilen serilerde Box-Jenkins yöntemi başarılı sonuçlar verebilir. Ancak, gerçek hayata ilişkin seriler genellikle doğrusal değildir. Bu nedenle doğrusal olmayan zaman serilerini modellemede farklı yöntemlere gereksinim duyulur.

1980'li yılların sonlarından başlamak üzere zaman serilerine ilişkin kestirimler için kullanılmakta olan yöntemlerden biri de Yapay Sinir Ağları (YSA) yöntemidir. YSA öngörümleme tekniği günümüzde birçok alanda yaygın bir şekilde kullanılmaya başlanmıştır. Basit bir şekilde insan beyninin çalışma şeklini taklit eden YSA'lar Yapay Zeka Teknolojileri içinde önemli bir yere sahiptir. YSA kavramı beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri olarak ortaya çıkmış ve ilk çalışmalar beyni oluşturan biyolojik hücrelerin, ya da literatürdeki ismi ile nöronların matematiksel olarak modellenmesi üzerinde yoğunlaşmıştır. “Evrensel Fonksiyon Yakınsayıcı Yöntem (Universal Function Approximators)” olarak tanımlanan YSA metodolojisi veriden öğrenebilme, genelleme yapabilme, sınırsız sayıda değişkenle çalışabilme vb birçok önemli özelliğe sahiptir. Bu özellikleri sayesinde oldukça önemli avantajlar sağlayan YSA metodolojisi diğer alanlarda olduğu gibi öngörü modellemesi alanında da yaygın bir şekilde kullanılmaktadır. YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye gereksinim duymadan doğrusal ve doğrusal olmayan modellemeyi sağlayabilmektedir. Bu nedenle YSA, öngörümleme aracı olarak diğer yöntemlere göre daha genel ve esnektir. YSA'nın bir öngörümleme aracı olarak kullanılmasına ilişkin bir çok araştırmacı tarafından yapılmış çok sayıda çalışma olmasına rağmen, YSA'nın performansını etkileyen anahtar faktörlerin neler olduğu konusunda kesin bir yargı yoktur. Belirtilen bu faktörlere ek olarak, eğitim algoritması, veri kümesinin düzenlenmesi, kestirim dönemi uzunluğu faktörlerinin de YSA performansı üzerinde etkili olduğu düşünülmektedir. Bu nedenle bütün bu faktörlerin etkisini araştırarak bir çalışmanın faydalı olacağına inanılmaktadır.

Bu çalışmada, yeni bir yöntem olan Yapay Sinir Ağları (Artificial Neural Networks) teknolojisi incelenmekte, öngörümleme tekniği olarak Petkim’de ele alınan dört ürünün satış rakamlarına uygulanmakta ve literatürde yer alan başka öngörümleme teknikleri ile karşılaştırmalı olarak performans değerlendirmesi yapılmaktadır. Bu kapsamda, çalışma genel olarak üç ana bölümden oluşmaktadır.

Çalışmanın ilk bölümünde yapay sinir ağları genel olarak açıklanmıştır. Bu kapsamda ilk olarak yapay sinir ağlarının da içine girdiği bir yöntemler bütünü olan Yapay Zeka’dan ve diğer Yapay Zeka Teknolojilerinden bahsedilmiş, daha sonra yapay sinir ağlarının tanımı verilmiş ve tarihçesi incelenmiştir. Yapay sinir ağlarının yapısının daha iyi anlaşılabilmesi için öncelikle biyolojik sinir ağları açıklanmış ve buna bağlı olarak yapay sinir hücresinin yapısı ayrıntılı olarak incelenmiş ve yapay sinir ağının yapısından kısaca bahsedilmiştir. Daha sonra, yapay sinir ağlarının bazı avantajlarından ve dezavantajlarından söz edilmiş ve ardından genel bir sınıflandırılması yapıp YSA’da öğrenmenin nasıl gerçekleştirildiğine değinilmiştir. Yapay sinir ağlarının uygulama alanlarından bahsedilerek bölüm sonlandırılmıştır.

İkinci bölümde ise nitel ve nicel yöntemler olmak üzere literatürde sözü edilen bazı öngörümleme tekniklerine yer verilmiştir. Çalışmanın amacı gereği, nicel öngörümleme tekniklerinden zaman serileri analizi yöntemleri kapsamında “Trendin Bileşenlerine Ayrılması” yöntemine ve “Box-Jenkins Metodolojisi”ne ayrıntılı olarak değinilmiştir. Bu bölümün sonunda ise YSA’nın öngörümlemede kullanılmasına ilişkin yapılan çalışmaların bir özeti verilmiştir.

Üçüncü bölümde ilk olarak, Dünya’da ve Türkiye’de Petrokimya Sanayi’nin yeri ve Petkim hakkında genel bilgi verilmiştir. Petkim’de mevcut olan satış sisteminden ve satış öngörümlemesinin Petkim’deki önemine değinilmiştir. Daha sonra, “Petkim’de Uygulama” başlığı altında çalışmada ele alınan ürünlerin özelliklerinden bahsedilmiş ve önceki bölümlerde sözü edilen öngörümleme teknikleri ile ilgili ürünlerin gelecek satış rakamları öngörülmüştür. Son olarak kullanılan öngörümleme tekniklerinden hangisinin daha iyi bir sonuç verdiği performans ölçüt kriteri kullanılarak belirlenmiştir.

BİRİNCİ BÖLÜM

YAPAY SİNİR AĞLARINA GENEL BAKIŞ

1.1.YAPAY ZEKA VE YAPAY ZEKA TEKNOLOJİLERİ

Hayatımızın en gizemli ve belki de en değerli kavramı olan zekayı tarif etmek gerçekten zordur. Herkes zekanın farkındadır ama açık ve net olarak bir tarifini yapamayabilir. Bazen tanımlar birbirine benzese de çoğu zaman farklılıklar gösterebilir. Türk Dil Kurumu'nun hazırlamış olduğu sözlüğe bakıldığında zekanın, anlama ve kavrama yeteneği olarak tanımlandığı görülebilir. Genellikle, bir şeyi anlama, kavrama veya önemini anlama olarak da ifade edilen zeka bireysel bilgi birikimi ve deneyimlerle ilişkilidir (Sağıroğlu vd., 2003, s. 3).

1.1.1. Yapay Zeka Kavramı

Her insan doğuştan belirli bir zekaya sahiptir. Zeka, belirli bir konuda çalışarak, öğretilerek, eğitilerek, edinilen bilgi ve birikimlerle, deneyimlere dayalı becerilerle geliştirilebilir. İlk kez karşılaşılan ya da ani olarak gelişen bir olaya uyum sağlayabilme, anlama, öğrenme, analiz yeteneği, beş duyunun, dikkatin ve düşüncenin yoğunlaştırılması zeka ile gerçekleştirilebilmektedir. Zeka, yazılım veya tümleşik parçalarla taklit edilebilmektedir. Bu durumda zeka 'Yapay Zeka' olarak adlandırılmaktadır (Elmas, 2003, s.21).

“Yapay Zeka” kavramı ilk duyuşta ister akademisyen, öğretmen, öğrenci olsun ister işadamı olsun birçok kişi üzerinde merak uyandırmaktadır. Neden olduğu sorulacak olursa, bunun cevabı ise, zeka gibi soyut bir kavramın yapay kelimesi ile nitelendirilmesidir. Kavramın uyandırdığı merakla birlikte, içeriği ya da temsil ettiği konular hakkında birçok kişinin ciddi bir bilgisi bulunmamaktadır (<http://joy.yasar.edu.tr/makale/ilksayı/yapayekahp.pdf>).

Yapay zeka (YZ); zeka ve düşünme gerektiren işlemlerin bilgisayarlar tarafından yapılmasını sağlayacak arařtırmaların yapılması ve yeni yöntemlerin geliştirilmesi hususunda çalışılan bilim dalıdır. YZ; “düşünme, anlama, kavrama, yorumlama ve öğrenme yapılarının programlamayla taklit edilerek problemlerin çözümüne uygulanması” olarak da ifade edilebilir. Daha geniş anlamda YZ:

- bilgisayarların bilgi edinme, algılama, görme, düşünme ve karar verme gibi insan zekasına özgü kapasitelerle donatılması bilimi,
- insanların düşünüş sürecini, çeşitli makineler kullanarak taklit etme,
- insanın düşünme yapısını anlama, bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışma,
- programlanmış bir bilgisayarın düşünme girişimi olarak da tarif edilmektedir (Sağirođlu vd., 2003, s. 4).

1.1.2. Yapay Zeka Teknolojileri

Yapay zeka çalışmaları deđişik teknolojilerin doğmasına neden olmuştur. Çünkü günlük olaylar ve problemler sürekli deđişmektedir. Deđişik yerlerde olayların farklı yönleri insanları ilgilendirebilmektedir. Bir olay, deđişik insanlar tarafından deđişik şekillerde yorumlanmaktadır. Karşılaştıkları sorunlar farklı bölge ve kişilerce farklı şekillerde çözülebilmektedir. Bilgisayarların insanların karar verme ve problem çözüme mekanizmalarını taklit etmesinin sağlanması da dolayısıyla farklı teknolojilerin doğmasına neden olmaktadır. Günümüzde 60'dan fazla yapay zeka teknolojisinden bahsedilmektedir. Bu teknolojilerin çođu henüz laboratuvar çalışmaları düzeyindedir. Bunlar arasında; uzman sistemler, yapay sinir ađları, genetik algoritmalar, bulanık önermeler mantığı, zeki etmenler, tabu arařtırması, ısıl işlemler, karınca algoritması ve yumuşak programlama yer almaktadır (Öztemel, 2006, s. 15).

1.1.2.1. Uzman Sistemler

Son yirmi yıl içerisinde YZ tabanlı programlar olan Uzman Sistemler büyük dikkat çekmiştir. Uzman sistemlerin birçok farklı alandaki zor seviyede sayılabilecek

problemleri başarılı bir şekilde çözüme kavuşturması, dikkat çekmelerinde en önemli unsuru oluşturmuştur. Uzman sistemler, belirli bir alanda sadece o alan ile ilgili bilgilerle donatılmış ve problemlere o alanda uzman bir kişinin getirdiği şekilde çözümler getirebilen bilgisayar programları olarak tarif edilebilir. Sistemi geliştiren kişi ile sistemin geliştireceği alandaki uzman kişi ya da kişilerin karşılıklı fikir alışverişleri sonucu ortaya çıkarılan bilgi, sistemin bilgi tabana uygun formatta girilir. Eğer ileride bilgide bir değişiklik yapmak gerekirse bu değişiklik bilgi tabanı üzerinde rahatça yapılabilir. Tamamlanan sistem, bilgi tabanındaki bilgiyi kendisine uç kullanıcılar tarafından belirtilen problemleri çözüme kullanır. Uzman sistemler, özellikle bilgisayar sistem dizaynı, lokomotif tamiri ve gen klonlama konularındaki başarılarıyla ön plana çıkmışlardır (<http://th.informatik.uni-mannheim.de/people/tatli/resources/pdf/expertsystems.pdf>).

1.1.2.2. Yapay Sinir Ağları

İnsan beyninin üstün özellikleri, bilim adamlarını üzerinde çalışmaya zorlamış ve beynin nörofiziksel yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Beynin bütün davranışlarını tam olarak modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesi ile çeşitli yapay hücre ve ağ modelleri geliştirilmiştir. Böylece Yapay Sinir Ağları denen yeni ve günümüz bilgisayarlarının algoritmik hesaplama yönteminden farklı bir bilim dalı ortaya çıkmıştır.

Genel anlamda YSA, beynin bir işlevi yerine getirme yöntemini modellemek için tasarlanan bir sistem olarak tanımlanabilir. YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasından oluşur ve genellikle katmanlar halinde düzenlenir. Donanım olarak elektronik devrelerle veya bilgisayarlarda yazılım olarak gerçekleştirilebilir. Beynin bilgi işleme yöntemine uygun olarak YSA, bir öğrenme sürecinden sonra bilgiyi saklama ve genelleme yeteneğine sahip paralel dağılmış bir işlemcidir

(<http://www.akademiyaapayzeka.com/DesktopDefault.aspx?tabindex=4&tabid=4>).

Yapay sinir ađları, alıřmamızın ana konusu olduđundan, burada sadece yapay zeka teknolojilerinin bir alt sistemi olduđuna deđinilmiř ve detaylı tanımı arařtırmanın diđer blmlerinde verilmeye alıřılmıřtır.

1.1.2.3. Genetik Algoritmalar

Genetik algoritmalar, deđiřik planlama teknikleri ile bir fonksiyonun optimizasyonu veya ardıřık deđerlerin tespitini iine alan birok problem tipleri iin zm arama yntemidir. Genetik algoritmalar, en iyinin korunumu ve dođal seilim ilkesine dayanarak, benzetim yoluyla bilgisayarlaraya uygulanan ve bilgisayarlar zerinde oluřan bir evrim řeklidir. Bu metot uzun alıřmaların sonucunda ilk defa John Holland tarafından uygulanmıřtır. Genetik algoritmaların amacı, hem problemleri zmek hem de evrimsel sistemleri modellemektir (Dař vd., 2006, s.68-69).

1.1.2.4. Bulanık nermeler Mantıđı

Bulanık mantık (Fuzzy Logic) sistemlerin ve modellerin tanımlanmasında ve kontrol edilmesinde geniř apta kullanılan bir sistemdir. Bu yaklařım ilk olarak 1965 yılında L. A. Zadeh tarafından tanımlanmıřtı. Zadeh bu alıřmasında insan dřncesinin byk ođunluđunun bulanık olduđunu, kesin olmadıđını belirtmiřtir. Arařtırmalar bulanık mantık denetimi ile elde edilen sonu performansının klasik yntemlerle elde edilenlere gre daha iyi olduđunu gstermiřtir.

Klasik kmeler olarak bilinen kesin kmeler ait olduđu evrensel kmenin her bir elemanına 1 ya da 0 deđerini atamaktadır. Bir nesne 1 deđerini alırsa kmenin elemanıdır, 0 deđerini alırsa kmenin elemanı deđildir. 0 ve 1 deđerlerini alan kesin kmelere karřılık olarak bulanık mantık kmelerinde 0 ve 1 arasında deđiřebilen deđerler vererek gerekli iřlevleri ortaya koymuřtur. Bulanık mantıkta belirsizlik durumları, bu durumu temsil eden kme elemanlarına yelik fonksiyonlarının verilmesi ile tanımlanır. En byk nem derecesine sahip olan đelere 1 deđeri atanırsa, diđerleri 0 ile 1 arasında deđiřim gsterir. Bu řekilde 0 ile 1 arasındaki

değişimin her bir öge için değerine üyelik derecesi ve bunun bir alt küme içindeki değişimine de üyelik fonksiyonu denilmektedir (Uygunoğlu ve Yurtçu, 2006, s.62).

1.1.2.5. Zeki Etmenler

Zeki etmenler, bağımsız kararlar verebilen bilgisayar sistemleridir. Bu bilgisayar sistemleri hem donanım hem de yazılım olarak geliştirilmektedirler. Öğrenme ve gerçek zamanlı çalışabilme özellikleri vardır. Zeki etmenler birden fazla yapay zeka teknolojisini kullanabilirler. Zeki etmenlerin 3 ana elemanı vardır. Bunlar:

a) Algılama: Dış dünyadan (çevreden) gelen bilgilerin algılanması, yorumlanması, gereksiz bilgilerin ayıklanması, bilgilerin önem derecelerine göre sıralanması ve önceliklendirilmesi gibi işlemleri gerçekleştirir.

b) Kavrama/idrak: Algılamadan gelen bilgilerin işlenmesi, karar verme, muhakeme etme, problem çözme, planlama, öğrenme vb. gibi işlemlerin gerçekleştirildiği birimdir. Problemler çözülürken öncelik ilişkileri göz önünde bulundurulur. Ani olarak çevreden gelen yeni bilgilerin kararlar üzerine etkisi göz önünde bulundurulur.

c) Eylem: Bilgi işleme neticesinde oluşturulan problem, istenilen davranışları belirler. Bu bir robotun yürümesi olabileceği gibi, bir reaktöre çalış komutunun gönderilmesi gibi bir eylem de olabilir. Eylemler neticesinde dış çevrede değişiklikler oluşur. Bu değişiklikler algılama yolu ile yeniden işlenerek yeni eylemlerin oluşturulmasına neden olur (Öztemel, 2006, s. 20-21).

1.1.2.6. Tabu Araştırması

Glover tarafından geliştirilmiş olan bu algoritma, ilk başta ayrık optimizasyon problemlerine uygulanmıştır. Bu yaklaşımda, bütün olasılıkları denemek çok fazla zaman alacağından dolayı, en az hesaplama ile en iyi çözüme ulaşmak için Tabu Arama (TA) algoritması geliştirilmiştir. Arama uzayındaki denenmiş çözümlerin listesinin bellekte tutulmasından dolayı arama sınırlandırılmış ve yerel optimumdan kurtulma bu sayede gerçekleştirilmiştir. Diğer bir tanımla, TA yerel optimuma düşme problemini aşmak için bir bellek fonksiyonu kullanıp, küresel optimumu hızlı bir şekilde aramada bir veya daha

çok yerel arama prosedürünü hiyerarşik olarak yönlendiren bir yapay zeka yaklaşımıdır (Sağırođlu vd., 2003, s.17).

1.1.2.7. Isıl İşlemler

Bu yaklaşım, metalik malzemelerin katı hal sıcaklık deđişmelerinin birbirine bađlı birkaç işleme, amaca uygun özellik deđişmelerinin sağlanması olarak tarif edilir. Kirkpatrick ve ark. (1983) tarafından geliştirilmiş olan bu yaklaşım, metallerin ısıl işlemi (annealing) ile bir optimizasyon probleminin çözümü arasındaki benzerlikleri temel almaktadır. Isıl işlem, bir katının sıcaklığının belirli bir maksimum dereceye kadar artırılarak tekrar eritilmesi şeklinde tanımlanır (Sağırođlu vd., 2003, s. 19).

1.1.2.8. Karınca Algoritması

Bu algoritma, matematiksel olarak karınca koloni davranışlarının modellenmesine dayalı bir yaklaşımdır. İlk çalışma, Dorigo ve arkadaşları tarafından 1991 yılında yapılmıştır. Bu araştırmacılar geliştirdikleri sisteme *karınca sistemi*, ortaya çıkan algoritmaya ise *karınca algoritması* ismini vermişlerdir (Dorigo vd., 1991, s.92). Bu yaklaşım gerçek karınca davranışlarından biraz farklı yapıdadır. Doğal karıncalar kör olduđu halde, yapay karıncalar belirli bir hafızaya sahiptirler ve tamamen kör deđillerdir. Bu yaklaşımda haberleşmenin nasıl sağlandığı önemli bir husustur. Karıncalar arasındaki en kısa yolu keşfetmek için aralarında haberleşmeyi sağlayan temel maddenin feromon (pheromone) olduđu bilinmektedir. Karıncalar hareketleri esnasında takip ettikleri yollara belirli bir miktarda feromon maddesi bırakırlar. Hareket etmek için hangi yönü seçmeleri gerektiği daha önceki karıncalar tarafından bırakılmış feromon miktarına bađlıdır. Dorigo ve arkadaşları, zor problemlerin çözümünde yerel olarak çok sayıda etkileşen bireylerin davranışlarını simüle eden, üç yeni karınca algoritması sunmuşlar ve bu algoritmaları gezgin satıcı problemine uygulayarak test etmişlerdir (Sağırođlu vd., 2003, s.20).

1.1.2.9. Yumuşak Programlama

Uzman sistemler, bulanık mantık, yapay sinir ağları ve genetik algoritma uygulamalarda tek başlarına kullanılabildikleri gibi birçok uygulamada her birinin avantajları ve dezavantajları göz önüne alınarak birlikte kullanılır. Ortaya çıkan bu yaklaşıma da yumuşak programlama adı verilir (<http://joy.yasar.edu.tr/makale/ilksayı/yapayekahp.pdf>).

1.2. YAPAY SİNİR AĞLARININ GENEL TANIMI

Turing makineleriyle temeli atılan yapay zeka üzerinde en fazla araştırma yapılan konu “Yapay Sinir Ağları”dır. Yapay sinir ağları, temelde tamamen insan beyni örneklenerek geliştirilmiş bir teknolojidir (Ergezer vd., 2003, s.14).

Yapay sinir ağı, hayvanlardaki ve insanlardaki sinir hücrelerinin basit bir modelini simüle eden bir bilgisayar yazılımıdır. Bu simülasyonun amacı, sözü edilen sinir hücrelerin zeki özelliklerini elde etmektir (<http://www.tek271.com/articles/neuralNet/IntoToNeuralNets.html>).

Bir sinir ağı, bilgiyi depolamak ve onu kullanışlı hale getirmek için doğal eğilimi olan basit birimlerden oluşan paralel dağıtılmış bir işlemcidir. İnsan beynine iki şekilde benzerlik göstermektedir:

1. Bilgi, öğrenme süreci yoluyla ağ tarafından elde edilir.
2. Sinaptik ağırlıklar olarak bilinen nöronlar arası bağlantı kuvvetlerini, bilgiyi depolamak için kullanır (Haykin, 1999, s.2).

1.3. YAPAY SİNİR AĞLARININ TARİHSEL GELİŞİMİ

İnsan beyninin araştırılması, binlerce yıl öncesine dayanmaktadır. Elektronik alanda ortaya çıkan büyük gelişmelerle birlikte insan beyninin yaptığı işlemleri yapabilecek sinir ağlarının oluşturulabilmesi mümkün hale gelmiştir. Yapay sinir ağları, 1950’li yılların sonlarından itibaren yeni bir yaklaşım olarak görülmeye başlanmıştır.

1970’lerde yaşanan durgunluğa rağmen, bilgisayar teknolojisinde yaşanan gelişmelere paralel olarak 1980’li yıllardan itibaren yapılmış olan araştırmalar sayesinde, yapay sinir ağları en popüler konulardan biri haline gelmiştir. Haykin (1994, s.36-41), Detienne ve diğ. (2003, s.237), Sağırođlu ve diğ. (2003, s.7-10), Pirim (2005, s.3-4), Öztemel (2003, s.37-41), Walczak ve Cerpa (1999, s.5-7), Stergiou ve Siganos (2006, s.3-4), Anderson ve McNeill (1992, s.17-20), Yurtođlu (2005, s.37-41) yararlanarak yapay sinir ağlarının tarihsel gelişiminde yaşanan önemli olaylar aşağıda özetlenmiştir.

Yapay sinir ağları konusunda ilk çalışma 1943 yılında Warren McCulloch ve genç matematikçi Walter Pitts tarafından yapılmıştır. McCulloch ve Pitts, elektrik devreleriyle basit bir sinir ađı geliştirerek sinirlerin nasıl çalıştığını gösteren ilk matematiksel modeli ortaya koymuşlardır. Bu araştırmacıların ortaya koyduğu düşünceler sonucunda yapay sinir hücrelerini kullanan hesaplama modeli, önermeler mantığı, fizyoloji ve Turing hesaplama kuramı (1950) ortaya çıkmıştır. Oluşturulan bu ağlarda, basit eşiklere sahip ikili (binary) basit nöronlar ele alınmıştır. Bu modellerde “a veya b” ve “a ve b” gibi basit mantıksal fonksiyonlara çözüm getirilmiştir.

1949 yılında Donald Hebb, sinir hücrelerinin işleyişini vurgulamak amacıyla ‘*Organization of Behavior*’ adında bir kitap yazmıştır. Kitabında, sinir hücreleri arasındaki bağlantıların, sinir hücreleri kullandıkları sürece güçleneceğini savunmuştur. Öğrenme için geliştirdiđi matematiksel modellerin, sadece matematiksel analizlere bađımlı olmasından dolayı bazı işlemlerde çok büyük zorluklarla karşılaşmıştır.

1950’li yıllarda bilgisayar kullanımının başlaması ile birlikte insanın düşünce yapısını konu alan teoriler gündeme gelmiştir. Nitekim, 1951’de Minsky, sinapsların ayarlanmasıyla belirli bir işi başarabilecek 40 nöronlu bir öğrenme sistemi sunmuştur [bkz. Sağırođlu ve diğ. (2003, s.7)]. İlk yapay sinir ađı sistemlerinden olan SNARC, Minsky ve Edmonds tarafından 1951’de MIT’de geliştirilmiştir.

Yapay zeka konusunda yaşanan önemli gelişmelerden biri de 1952 yılında IBM’in satranç oynayabilen ilk programı geliştirmesidir. McCarthy, 1956 yılında, Dartmouth’da

IBM araştırma laboratuvarlarından Nathaniel Rochester, Minsky ve Shannon ile beraber yapay zeka üzerine yaptığı çalışmaları açıklamış ve ilk kez “Yapay Zeka” kavramını kullanmıştır.

Yapay sinir ağlarının gelişmesinde yapay zeka konusundaki gelişmelere paralel olarak, psikologlar ve mühendisler de bu alandaki ilerlemelere katkı sağlamışlardır. Örneğin, Dartmouth projesini takip eden yıllarda, John Von Neumann, telgraf kontervizörlerini ve vakum tüplerini kullanarak basit sinirlerin işleyişini taklit etmiştir. 1958 yılında, Frank Rosenblatt, bir sineğin gözlerinin işleyişini temel alarak Perceptron’u (Algılayıcı) tasarlamıştır. Rosenblatt çalışmasında, iki katlı bir algılayıcının (perceptron) iki farklı sınıfı ayırt edebileceğini ispatlamıştır. Bu sistem, verilerden oluşan girdi kümesinin bir rassal çıktıya bağlanma veya birleşme şeklini öğrenebilmekteydi. Burada öğrenme kelimesi bağlantı ağırlıklarının ilişkiye göre ayarlanması anlamında kullanılmaktadır. Bu bakımdan perceptron en eski sinir ağı modelidir.

1959 yılında Bernard Widrow ve Marcian Hoff tarafından diğer bir sistem olan ADALINE (Adaptive Linear Element) ve MADALINE (Multiple Adaptive Linear Elements) geliştirilmiştir. ADALINE, en küçük ortalama kareler (LMS – Least Mean Squares) öğrenme kuralını kullanmasıyla perceptrondan farklılaşmaktadır. MADALINE, geçek dünya problemlerine uygulanabilen ilk yapay sinir ağıdır.

1960’larda Grossberg, verileri belirli bir aralığa otomatik olarak çekebilen Yapay Sinir Ağları yapıları üzerinde çalışmalar yapmış ve ART (Adaptive Resonance Theory – Adaptif Rezonans Teorisi), ART-1, ART-2 olarak bilinen yapıları geliştirmiştir.

Bu yıllarda ortaya çıkan başarılar ile birlikte, insanlar Yapay Sinir Ağlarının yapabileceklerinden endişelenmeye başlamışlardır. Asimov’un robotlar üzerine yazdıkları, ‘düşünen makinelerin’ insanın yaptığı tüm işleri yapabileceği ve dolayısıyla insan gücüne ihtiyacın kalmayacağını göstermekteydi.

1969 yılında, Marvin Minsky ve Seymour Papert tarafından yazılan ‘Perceptrons’ adlı kitapta tek katmanlı perceptronların sahip olduğu sınırlamaları ortaya koymuşlar ve perceptronların yapay sinir ağları literatüründe XOR problemini çözümlenemediğini belirtmişlerdir. Bu tarihten sonra YSA’lar konusundaki araştırmalarda büyük bir durgunluk yaşanmıştır.

1970’li yılların sonlarında ve 1980’li yılların başlarındaki ilerleme, YSA’lara olan ilginin yeniden canlanmasına yol açmıştır. Bu dönemlerde, Anderson ve Kohonen birbirinden bağımsız olarak ART ağlarına benzer teknikler geliştirmiş, Klopff ise 1972 yılında yapay nöronlarda öğrenmenin biyolojik prensiplerine dayanan ve ‘heterostasis’ olarak adlandırılan bir temel oluşturmuştur. 1980’li yıllarda YSA’lara karşı olan ilginin artmasının en önemli nedenlerinden biri Rumelhart, Hinton ve McClelland tarafından tanıtılan geriyayılım algoritmasıdır. Geriyayılım algoritması aslında, daha sağlam ve yetenekli öğrenme kuralı olan bir Çok Katmanlı Algılayıcıdır. Geriyayılım ağları (Backpropagation Networks), bugün en çok bilinen ve kullanılan yapay sinir ağlarıdır.

1982 yılında John Hopfield tarafından ortaya atılan Hopfield öğrenme modelinin geliştirilmesiyle matematiksel analizler yardımıyla yapay sinir ağlarının nasıl çalıştığı ve neler yapabileceği ortaya çıkarıldı.

1980’li yıllarda, YSA’lar alanında yaşanan yenilikler sadece bu konuda çıkarılan kitaplar ve çalışmalarla sınırlı kalmamıştır. Aynı zamanda, Kyoto’da, Japonya ve ABD işbirliği ile düzenlenen ‘İşbirlikçi/Rekabetçi Sinir Ağları’ konferansı, 1985 yılında ‘‘American Institute of Physics’’in düzenlediği ‘‘Neural Networks for Computing’’ adında yıllık toplantılar ve 1987 yılında 1800 katılımcının da bulunduğu Elektrik ve Elektronik Mühendisleri Birliğinin (IEEE) düzenlediği ilk uluslararası yapay sinir ağları konferansı gibi toplantılar ve konferanslar, çok farklı alanlarda uzmanlaşmış insanlara bir forum imkanı ve dolayısıyla bir etkileşim sağlamıştır. Artan ilgi ile beraber bu alandaki araştırmalara yönelik fonlar da artmış ve enstitüler ortaya çıkmıştır.

Günümüzde, bilgisayarların karmaşık problemleri çözebilmek için ağları yeterince hızlı eğitebilir hale gelmesi, YSA’lar konusunda daha ileri araştırmalar yapabilmek için

gerekli ilgi ve bilgi birikiminin sağlanmış olması YSA'ların ve uygulamalarının her yerde konuşulmasına neden olmuştur.

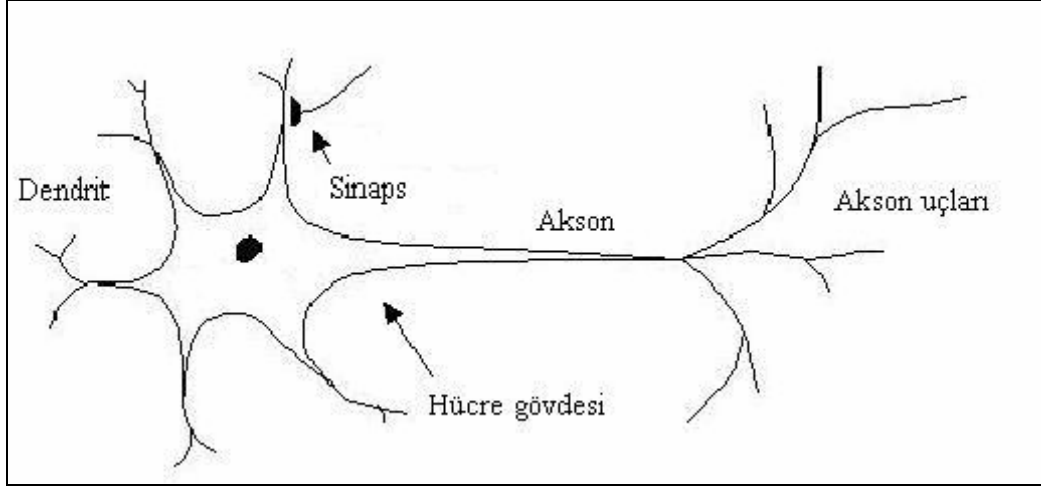
1.4. YAPAY SİNİR AĞLARININ GENEL ÖZELLİKLERİ

1.4.1. Biyolojik Sinir Hücresi

Yapay sinir ağlarının daha iyi anlaşılabilmesi için örnek teşkil eden doğal sinir ağı olan biyolojik sinir ağlarının yapısının ve çalışma ilkelerinin iyi bilinmesi gerekmektedir.

İnsan beyninin 10 milyar sinir hücresinden ve 60 trilyon sinaps bağlantısından oluştuğu düşünülürse son derece karmaşık ve etkin bir yapı olduğu anlaşılır. Diğer taraftan bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş olmakla birlikte duyuşsal bilgileri son derece hızlı değerlendirebilmektedir. Bu nedenle insan beyni; öğrenme, birleştirme, uyarılma ve genelleştirme yeteneđi nedeniyle son derece karmaşık, doğrusal olmayan ve paralel dağıtılmış bir bilgi işleme sistemi olarak tanımlanabilir (Kulkarni, 1994, s.24).

Bir sinir hücresi, bir hücre gövdesi ile dendrit ve akson adı verilen uzantılardan meydana gelir. Sinir hücresi, dendrit adı verilen bir kısım uzantılarla diğer sinir hücrelerinden aldığı işaretleri hücre gövdesine taşır ve hücre gövdesinde toplanan bu işaretler değerlendirilerek bir çıkış işareti üretilir ve bu işaretler akson adı verilen uzantılar vasıtasıyla diğer sinir hücresine gönderilir. Bir sinir hücresinde birçok dendrit olmasına karşın tek bir akson vardır. Yani bir sinir hücresinde birçok giriş bulunmasına rağmen tek bir çıkış vardır. İki sinir hücresi arasında birinin dendriti ile diğerinin aksonu arasında bir bağlantı vardır ve bu bağlantı yerine sinaps adı verilir. Bu bağlantı yerinde sinirler birbirine bağlı değildir. İki hücre arasında küçük bir bağlantı bulunmamasına rağmen iki sinir hücresi darbeleri iletmek için birbirine yeterince yakındır. Canlı bir sinir sisteminin temelini oluşturan bir sinir hücresi Şekil 1'de görülmektedir (Efe ve Kaynak, 2000, s.17).



Şekil 1: Biyolojik Sinir Hücresi

Kaynak: Efe Ö., Kaynak O. (2000); **Yapay Sinir Ağları ve Uygulamaları**, İstanbul: Boğaziçi Üniversitesi Yayınları, s.17.

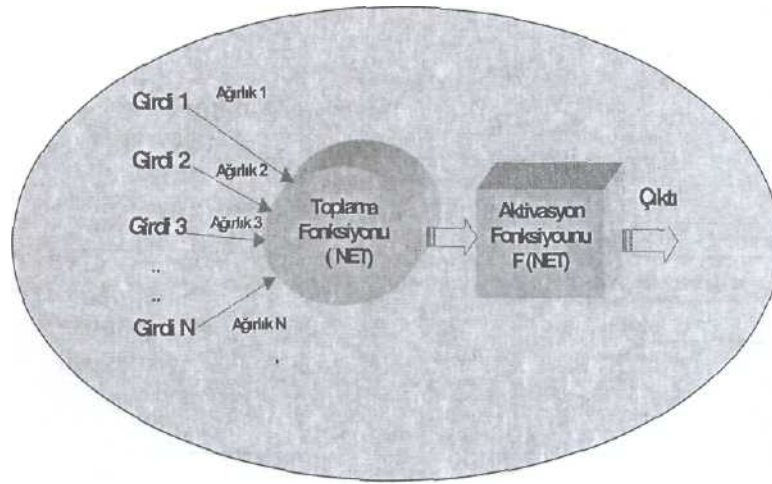
Günümüzde hala, insan beyninin bilgiyi işlemek üzere kendisini nasıl eğittiği bilinmemektedir, böylece de ortaya çok fazla teori atılmıştır. İnsan beyninde, tipik bir sinir hücresi, dendrit olarak adlandırılan bir çok ince yol aracılığıyla diğer hücrelerden sinyalleri toplar. Sinir hücresi, binlerce dala ayrılan ince ve uzun ayaklar olan aksonlar aracılığıyla elektriksel faaliyetlerini yollar. Her bir dalın sonunda, sinaps olarak adlandırılan bir yapı, aksondan aldığı faaliyeti birbirine bağlanmış sinir hücrelerinde yer alan elektriksel etkilere dönüştürür. Öğrenme, sinapsların verimliliğini değiştirerek meydana gelir ve böylece bir sinir hücresinin diğer bir sinir hücresi üzerindeki etkisi değişmiş olur (http://www.doc.ic.ac.uk/nd/surprise_96/journal/vol4/cs11/report.html).

1.4.2. Yapay Sinir Hücresi

Yapay bir sinir hücresi, biyolojik bir sinir hücresinin temel davranışlarından esinlenen matematiksel modeli ortaya koyan bir algoritma veya fiziksel araç olarak tanımlanabilir. Biyolojik sinir hücresinin tanımından hareket ederek, yapay bir sinir hücresinin diğer sinir hücrelerinden aldığı sinyalleri bünyesinde topladığını ve toplam sinyal birikiminin belli bir eşiği aştığı anda, bu yapay sinir hücresinin kendi sinyalini bir başka sinir hücresine iletmediği söylenebilir (http://www.colinfahey.com/2003apr20_neuron/2003apr20_neuron.htm).

Yapay sinir ağı, birbirine bağlı çok sayıda işlem elemanlarından oluşmuş, genellikle paralel işleyen yapılar olarak adlandırılabilir. Yapay sinir ağlarındaki işlem elemanları (düğümler) basit sinirler olarak adlandırılır. Bir yapay sinir ağı, birbirleriyle bağlantılı, çok sayıda düğümden oluşur (Elmas, 2003, s. 31).

Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir hücreleri mühendislik biliminde proses elemanları olarak da adlandırılmaktadır. Şekil 2’de gösterildiği gibi her proses elemanının 5 temel elemanı vardır. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktıdır (Öztemel, 2006, s. 48).



Şekil 2: Yapay Sinir Hücresinin Yapısı

Kaynak: Öztemel E. (2006); **Yapay Sinir Ağları**, 2. Baskı, İstanbul: Papatya Yayıncılık, s. 48.

1.4.2.1. Girdiler

Girişler (x_1, x_2, \dots, x_n) çevreden aldığı bilgiyi sinire getirir. Girişler, kendinden önceki sinirlerden veya dış dünyadan sinir ağına gelebilir. Bir sinir genellikle gelişigüzel bir çok girdileri alır (Elmas, 2003, s.33).

Girdilerin sayısı, yapay sinir ağının çevreyi algılama bağlı olarak değişiklik göstermektedir. Girdiler, yapay sinir ağlarının sensörleri durumundadır. Bir yapay sinir

ağının çevresi, yapay sinir ağının işleyeceği verilerden oluşuyorsa, girdiler de sözü edilen veri değişkeninin yapısıyla tutarlı olmalıdırlar (Buscema, 2002, s.1108).

1.4.2.2. Ağırlıklar

Ağırlıklar (w_1, w_2, \dots, w_i), yapay sinir tararından alınan girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılardır. Her bir giriş kendine ait bir ağırlığa sahiptir. Bir ağırlığın değerinin büyük olması, o girişin yapay sinire güçlü bağlanması ya da önemli olması, küçük olması zayıf bağlanması ya da önemli olmaması anlamına gelmektedir (Elmas, 2003, s.33).

Ağırlıklar bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Şekil 2'deki Ağırlık 1, Girdi 1 'in hücre üzerindeki etkisini göstermektedir. Eksi değerler önemsiz demek değildir. O nedenle artı veya eksi olması etkisinin pozitif veya negatif olduğunu gösterir. Sıfır olması ise herhangi bir etkinin olmadığını gösterir. Ağırlıklar değişken veya sabit değerler olabilirler (Öztemel, 2006, s.49).

1.4.2.3. Toplama Fonksiyonu

Toplama fonksiyonu, bir yapay sinir hücresindeki her bir giriş ile o girişe ait olan ağırlığın çarpılarak bu çarpımların toplanmasıdır.

$$Net\ Toplam = \sum_i^n x_i w_i \quad (1.1)$$

Ancak birçok uygulama aşağıdaki gibi eşik değeri olan θ 'da bu toplamaya katmıştır.

$$Net\ Toplam = \sum_i^n x_i w_i + \theta \quad \text{ya da} \quad Net\ Toplam = \sum_i^n x_i w_i - \theta \quad (1.2)$$

θ eşik değeri girişlerden bağımsız olduğu için bütün girişlerin sıfır olması durumunda çıkış değerinin sıfır değil de eşik değerine eşit olduğu görülüyor ve bu da,

belirtilen şartlar altında nöron çıkışının sıfır olması zorunluluğunu ortadan kaldırır. Eşik değerinin kullanımı, toplama fonksiyonuna +1 ya da -1 değerine sahip sabit bir girişin θ ağırlığına sahip bir bağlantı ile eklendiği şeklinde yorumlanır (Efe ve Kaynak, 2000, s.7).

Ancak yapay sinir ağlarında daima bu formülün kullanılması şart değildir. Uygulanan yapay sinir ağı modellerinden bazıları kullanılacak toplama fonksiyonunu belirleyebilmektedir. Literatürde yapılan araştırmalarda toplama fonksiyonu olarak değişik formüllerin kullanıldığı görülmektedir. Tablo 1’de değişik toplama fonksiyonlarına örnekler verilmektedir. Görüldüğü gibi, bazı durumlarda gelen girdilerin değeri dikkate alınırken bazı durumlarda ise gelen girdilerin sayısı önemli olabilmektedir. Bir problem için en uygun toplama fonksiyonunu belirlemek için bulunmuş bir formül yoktur. Genellikle deneme yanılma yolu ile toplama fonksiyonu belirlenmektedir. Bir yapay sinir ağında bulunan proses elemanlarının tamamının aynı toplama fonksiyonuna sahip olmaları gerekmez. Her proses elemanı bağımsız olarak farklı bir toplama fonksiyonuna sahip olabilecekleri gibi hepsi aynı proses elemanına sahip olabilir. Hatta ağın bazı proses elemanları grup halinde aynı toplama fonksiyonuna sahip olabilir. Diğerleri ise farklı fonksiyonlar kullanabilirler. Bu tamamen tasarımcının kendi öngörüsüne dayanarak verdiği karara bağlıdır (Öztemel, 2006, s.49-50).

Tablo 1: Toplama fonksiyonu örnekleri

Net giriş	Açıklama
<p><i>Çarpım</i> Net Girdi= $\prod_i G_i A_i$</p>	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır.
<p><i>Maksimum</i> Net Girdi= Max ($G_i A_i$), $i=1....N$</p>	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
<p><i>Minimum</i> Net Girdi= Min ($G_i A_i$), $i=1....N$</p>	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en küçüğü yapay sinir hücresinin net girdisi olarak kabul edilir.

<p><i>Çoğunluk</i> Net Girdi= $\sum_i \text{sgn}(G_i A_i)$</p>	<p>N adet girdi içinden ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.</p>
<p><i>Kümülatif toplam</i> Net Girdi = Net (eski)+ $\sum_i (G_i A_i)$</p>	<p>Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.</p>

Kaynak: Öztemel E. (2006); **Yapay Sinir Ağları**, 2. Baskı, İstanbul: Papatya Yayıncılık, s. 50

1.4.2.4. Aktivasyon Fonksiyonu

Nöron davranışını belirleyen önemli faktörlerden biri nöronun aktivasyon fonksiyonudur. Toplama fonksiyonunun sonuçları aktivasyon fonksiyonu diye bilinen bir süreç yardımı ile çıktıya dönüştürülür. Literatürde, sıkıştırma veya eşik fonksiyonu olarak da adlandırılmaktadır (Zhang vd., 1998, s.35).

Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak da çıktıyı hesaplamak içinde değişik formüller kullanılmaktadır. Bazı modeller (mesela çok katmanlı algılayıcı) bu fonksiyonun türevinin alınabilir bir fonksiyon olmasını şart koşmaktadır. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da ağırlık proses elemanlarının hepsinin aynı fonksiyonu kullanması gerekmez. Bazı elemanlar aynı fonksiyonu diğerleri farklı fonksiyonları kullanabilirler. Bir problem için en uygun fonksiyonda yine tasarımcının denemeleri sonucunda belirleyebileceği bir durumdur. Uygun fonksiyonu gösteren bir formül bulunmuş değildir (Öztemel, 2006, s.50).

Aktivasyon fonksiyonu işlemi öncesinde, sisteme tekdüze (uniform) dağılmış bir rassal hata eklenebilmektedir. Bu rassal hatanın kaynağı ve büyüklüğü sistemin öğrenme sürecinde belirlenir ve sebebi, insan beyninin işlevinin, içinde bulunduğu ortamın koşullarından etkilenmesidir. Örneğin ortamın soğuk/sıcak olmasından insan beyni etkilenmektedir. Bu nedenle yapay sinir ağları literatüründe rassal hata ekleme işlemi “sıcaklık (temperature)” olarak da adlandırılmaktadır. Ancak günümüzde rassal

hata işlevi tam olarak kullanılmamakta ve hala bir araştırma süreci içinde bulunmaktadır. Ayrıca bazı yapay sinir ağlarında, aktivasyon fonksiyonunun çıktısı üzerinde başka işlemler, ölçeklendirme ve sınırlandırma yapılabilmektedir (Harvey, 1989, s.63).

Doğrusal olmayan fonksiyonların kullanılması yapay sinir ağlarının çok karmaşık ve farklı problemlere uygulanmasını sağlamıştır. En çok kullanılan aktivasyon fonksiyonları şunlardır: (Öztemel, 2006, s.50-51; Sağıroğlu vd., 2003, s.37-40; Haykin, 1999, s.10-12)


1.4.2.4.1. Doğrusal Fonksiyon

Doğrusal fonksiyon, hücreye gelen girişleri olduğu gibi çıkışa iletir. Doğrusal fonksiyonun şekli Şekil 3’de gösterilmiştir. Çoğunlukla ADALINE olarak adlandırılan doğrusal işlemci eleman, klasik işaret işleme ve istatistiksel regresyon analizinde kullanılır. Formülü ise;

$$Net\ Toplam = v = \sum_i^n x_i w_i \quad veya \quad Net\ Toplam = v = \sum_i^n x_i w_i + \theta \quad olmak\ üzere;$$

$$F(Net) = y = F(v) = Av \quad (1.3)$$

Formüldeki A sabit bir sayıdır.




Şekil 3: Doğrusal veya Lineer Fonksiyon

1.4.2.4.2. Basamak Fonksiyonu


Basamak fonksiyonu tek veya çift kutuplu fonksiyon olabilir. Bu tip fonksiyonların şekli Şekil 4’de, matematiksel ifadeleri de Denklem 1.4 ve 1.5’de gösterilmiştir. Perceptron (Basit Algılayıcı Model) olarak bilinen işlemci elemanları bu fonksiyon ile işlem görür.

$$F(NE\tau) = y = F(v) = \begin{cases} 1 & v \geq 0 \\ 0 & v < 0 \end{cases} \quad (1.4)$$

$$F(NE\tau) = y = F(v) = \begin{cases} +1 & v \geq 0 \\ -1 & v < 0 \end{cases} \quad (1.5)$$



(a) Tek Kutuplu




(b) Çift Kutuplu

Şekil 4: Basamak Fonksiyonları

1.4.2.4.3. Kutuplamalı Basamak Fonksiyonu

Kutuplama değeri, tek kutuplu ve çift kutuplu basamak fonksiyonlarının her ikisinde de eklenmiş olabilir. Aktivasyon fonksiyonu eşik değeri olan θ 'yı aştığı zaman nöron aktiftir denir. Tek kutuplamalı basamak fonksiyonunun matematiksel ifadesi için Denklem 1.6 aşağıda verilmiştir. Tek kutuplamalı basamak fonksiyonunun şekli ise Şekil 5’de gösterilmiştir.

$$F(NE\text{T}) = y = F(v) = \begin{cases} 1 & w \times x \geq \theta \\ 0 & w \times x < \theta \end{cases} \quad (1.6)$$




Şekil 5: Tek Kutuplamalı Basamak Fonksiyonu

1.4.2.4.4. Parçalı Doğrusal Fonksiyon

Bu fonksiyon küçük aktivasyon potansiyeli için, α kazancı olan bir doğrusal toplayıcı (ADALINE) olarak çalışır. Büyük aktivasyon potansiyeli için, nöron doyuma ulaşır ve çıkış işareti 1 olur. Büyük kazançlar için, $\alpha \rightarrow \infty$ iken, parçalı doğrusal fonksiyon basamak fonksiyonu gibi davranır. Parçalı doğrusal fonksiyonun matematiksel ifadesi Denklem 1.7’de, şekli ise Şekil 6’da gösterilmiştir.

$$F(NE\text{T}) = y = F(v) = \begin{cases} 0 & v \leq -1/2\alpha \\ \alpha v + \frac{1}{2} & |v| < 1/2\alpha \\ 1 & v \geq 1/2\alpha \end{cases} \quad (1.7)$$




Şekil 6: Parçalı Doğrusal Fonksiyon

1.4.2.4.5. Sigmoid Tipi Fonksiyon

Yapay sinir ağı uygulamalarında en çok kullanılan aktivasyon fonksiyonudur. Bu fonksiyonun en aktif bölgesinin 0,2 ile 0,8 arasında olduğu bilinmektedir. Literatürde tek kutuplu aktivasyon fonksiyonu olarak ta bilinir. Sigmoid tipi fonksiyonun matematiksel ifadesi Denklem 1.8’de, şekli ise Şekil 7’de gösterilmiştir.

$$F(NE\text{T}) = y = F(v) = \frac{1}{1 + e^{-v}} = \frac{1}{2} [\tanh(v/2) + 1] \quad (1.8)$$




Şekil 7: Sigmoid Fonksiyon

1.4.2.4.6. Tanjant Hiperbolik Tipli Fonksiyon

Yapay sinir ağı uygulamalarında en çok kullanılan aktivasyon fonksiyonlarından bir diğeri ise bu fonksiyon tipidir. Literatürde çift kutuplu fonksiyon olarak da bilinir. Giriş uzayının genişletilmesinde etkili bir aktivasyon fonksiyonudur. Bu fonksiyonun matematiksel ifadesi Denklem 1.9’da, şekli ise Şekil 8’de gösterilmiştir.

$$F(NE\text{T}) = y = F(v) = \frac{1 - e^{-2v}}{1 + e^{2v}} = \tanh(\beta v) \quad (1.9)$$




Şekil 8: Tanjant Hiperbolik Fonksiyon

1.4.2.4.7. Sinüs Tipli Fonksiyon

Öğrenilmesi düşünülen olaylar sinüs fonksiyonuna uygun dağılım gösteriyorsa bu gibi durumlarda sinüs fonksiyonu kullanılır. Bu fonksiyonun matematiksel ifadesi Denklem 1.10'da, şekli ise Şekil 9'da gösterilmiştir.

$$F(NET) = y = F(v) = \text{Sin}(v) \quad (1.10)$$



Şekil 9: Sinüs Tipli Fonksiyon

1.4.2.5. Çıkış İşlevi

Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı dış dünyaya veya başka bir hücreye gönderilir. Hücre kendi çıktısını kendisine girdi olarak da gönderebilir. Bir proses elemanının birden fazla çıktısı olmasına rağmen sadece bir çıktısı olmaktadır. Ağ şeklinde gösterildiğinde bir proses elemanının birden fazla çıktısı varmış gibi görülmektedir. Bu sadece gösterim amacıyladır. Aslında bir proses elemanından çıkan tek bir çıktı değeri vardır. Aynı değer birden fazla proses elemanına girdi olarak gitmektedir (Öztemel, 2006, s.51).

Bütün bu anlatılanların ışığında yapay sinir ile biyolojik sinirler arasındaki benzerlik aşağıda Tablo 2'deki gibi gösterilebilir.

Tablo 2: Biyolojik Sinir Hücresi ile Yapay Sinir Hücresinin Karşılaştırılması


Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir	Düğüm (Sinir, İşlem elemanı)
Sinaps	Sinirler arası bağlantı ağırlıkları
Dendrit	Toplama İşlevi
Hücre Gövdesi	Etkinlik işlevi
Akson	Sinir Çıkışı

Kaynak: Elmas Ç. (2003); **Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)**, 1. Baskı, Ankara: Seçkin Yayıncılık, s.35.

1.4.3. Yapay Sinir Ağının Yapısı

Yapay sinir ağları, yapay sinir hücrelerinin katmanlar şeklinde bağlanmasıyla oluşturulan veri tabanlı sistemler olup insan beyninin öğrenme ve değişik koşullar altında çok hızlı karar verebilme gibi yeteneklerinin, basitleştirilmiş modeller yardımıyla karmaşık problemlerin çözülmesinde kullanılmasını amaçlamaktadır (Koç vd., 2004, s.3351).

Yapay sinir ağlarında, yapay nöronlar basit bir şekilde kümelendirilmektedirler. Bu kümelendirme tabakalar halinde yapılmaktadır ve daha sonra bu tabakalar bir diğerine ilişkilendirilmektedir. Temel olarak, tüm yapay sinir ağları benzer bir yapıya sahiptirler. Böyle bir genel yapı Şekil 10'da gösterilmiştir. Bu yapıda, bazı nöronlar girdileri almak için bazı nöronlar ise çıktılarını iletmek için dış mekan ile bağlantılı haldedirler. Geri kalan tüm nöronlar ise gizli tabakalardadırlar, yani sadece ağ içinde bağlantıları vardır (Anderson ve McNeill, 1992, s.7).



Şekil 10: Yapay Sinir Ağlarının Genel Yapısı

Kaynak: Yurtoğlu H. (2005); **Yapay Sinir Ağları Metodolojisi ile Önörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği**, Uzmanlık Tezi, Devlet Planlama Teşkilatı, s. 20

Tek tabaka veya tek eleman içeren bazı başarılı ağlar oluşturulabilmesine rağmen çoğu uygulamalar en az üç tabaka (girdi tabakası, gizli tabaka ve çıktı tabakası) içeren ağlara ihtiyaç duymaktadır. Girdi tabakası, dışarıdan girdileri alan nöronları içerir. Ayrıca, önemli olan bir nokta, girdi tabakasındaki nöronların girdi değerler üzerinde bir işlem uygulamamasıdır. Sadece girdi değerleri bir sonraki tabakaya iletirler ve bu yüzden de bazı araştırmacılar tarafından ağların tabaka sayısına dahil edilmezler. Çıktı

tabakası ise çıktıları dışarı ileten nöronları içeren tabakadır. Girdi ve çıktı tabakaları tek tabakadan oluşurken bu iki tabaka arasında birden fazla gizli tabaka bulunabilir. Bu gizli tabakalar çok sayıda nöron içerirler ve bu nöronlar tamamen ağ içindeki diğer nöronlarla bağlantılıdır. Çoğu ağ türünde, gizli tabakadaki bir nöron sadece bir önceki tabakanın tüm nöronlarından sinyal alır. Nöron işlemini yaptıktan sonra ise çıktısını bir sonraki tabakanın tüm nöronlarına gönderir. Bu yapı ağın çıktısı için bir ileri besleme patikası oluştururç bu bir nörondan diğerine olan iletişim hattı, sinir ağları için önemli bir parçadır (Anderson ve McNeill, 1992, s.8-9).

Bir yapay sinir ağının yapısı ve sinir hücrelerinin sayısı değişiklik göstermelerine rağmen, yapay sinir ağının oluşumu için kabul görmüş herhangi bir kural bulunmamaktadır. Gerekli gizli katman sayısından az gizli katmana sahip yapay sinir ağları komplike fonksiyonların çözümünde yetersiz kalırken, çok fazla gizli katmana sahip yapay sinir ağları ise istenmeyen kararsızlıklarla karşılaşmaktadır. Gizli katman sayısı belirlendikten sonra karşılaşılan problem ise her bir tabakada kaç tane nöronun yer alacağına karar vermede karşımıza çıkmaktadır. Girdi katmanı için bir sorun bulunmamaktadır; bu sayı sistem içerisindeki girdilerin sayısına eşittir. Aynı şekilde, çıktı katmanı da istenilen çıktı sayısı ile belirlenebilmektedir. Esas sorun, gizli katmanlarda nöron sayısını belirlemektir. Geleneksel matris algoritması, matris boyutlarının ya girdi sayısına ya da çıktı sayısına eşit olması gerektiğini söylemektedir. Ne yazık ki, gizli katmanda en verimli şekilde kaç tane nöronun bulunacağı konusunda herhangi bir matematiksel test bulunmamaktadır. Deneme ve yanılma yöntemi uygulanarak karar verilmelidir (Detienne vd., 2003, s.242-243).

1.4.4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları

Teknolojik gelişme olarak da görülmesi gereken yapay sinir ağları metodolojisi, özellikleri ve yapabildikleri sayesinde önemli avantajlar sunmaktadır. Bu bölümde, öncelikle yapay sinir ağlarının farklılık ve avantaj sağladığı noktalar incelenmiş ve daha sonra yapay sinir ağlarının bazı dezavantajlarına değinilmiştir.

1.4.4.1.Yapay Sinir Ağlarının Avantajları

Yapay sinir ağlarının hesaplama özelliklerini, paralel dağılmış yapısından, öğrenilme ve genelleme yapma yeteneğinden aldığı söylenebilir. Genelleme, eğitim veya öğrenme süresince kullanılmayan girişler için de yapay sinir ağlarının uygun tepkileri üretmesi olarak tanımlanabilir. Bu özellikleri ile yapay sinir ağları karmaşık ve çözümlenmesi güç problemleri de çözebilme yeteneğine sahiptir. Yapay sinir ağlarının klasik sistemlere göre sağladıkları avantajlar aşağıda verilmiştir (<http://www.yapay-zeka.org/modules/icontent/index.php?page=47>).

- **Doğrusal olmayan yapı:** Yapay sinir ağının temel işlem elemanı olan hücre, doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen yapay sinir ağı da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile yapay sinir ağları, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.
- **Öğrenme:** Yapay sinir ağının arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. Yapay sinir ağının karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz. Bu nedenle yapay sinir ağları, istenen davranışı gösterecek şekilde ilgilendiği problemde aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.
- **Genelleme:** Yapay sinir ağları, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir yapay sinir ağı, bozuk karakter girişlerinde de doğru karakterleri verebilir ya da bir sistemin eğitilmiş yapay sinir ağı modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir.
- **Uyarlanabilirlik:** Yapay sinir ağları, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen yapay sinir ağı, problemdeki değişimlere göre tekrar eğitilebilir ve değişimler devamlı ise gerçek

zamanda da eğitime devam edilebilir. Bu özelliği ile yapay sinir ağları, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

- **Hata toleransı:** Yapay sinir ağları, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğu için paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağıdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağına doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.

- **Dağıtılmış birleşik hafıza:** Yapay sinir ağlarının en önemli özelliklerinden biri de bilgiyi depolamalarıdır. Sinirsel hesaplamalarda bilgi ağırlıklar üzerine dağıtılmıştır. Bağlantıların ağırlıkları sinir ağına hafıza birimidir. Bu ağırlıklar o anda sahip olduğu bilgiyi veya uygulanan örneklerden öğrenmiş olduğu davranışı verir. Bu bilgiler, ağıdaki birçok ağırlıklar üzerine dağıtılır. Eğitilmiş ağına, eğitimde kullanılmamış herhangi farklı bir giriş uygulanırsa ağına daha önceki girişlerden öğrenmiş olduğu davranış doğrultusunda beklenen çıkışa uygun bir çıkış değeri üretebilecektir. Yapay sinir ağına uygulanan veri eksik, gürültülü veya daha önce hiç karşılaşmamış olsa bile, ağına kabul edilebilir en uygun çıkışı üretecektir. Bu özelliğe genelleştirme özelliği denir (http://batitrakya.dostweb.com/yapaysinirağları/ek_dokuman.htm).

- **Sınırsız Sayıda Değişken ve Parametre:** Diğer taraftan, yapay sinir ağı modelleri sınırsız sayıda değişken ve parametre ile çalışabilmektedir. Bu sayede mükemmel bir öngörü doğruluğu ile genel çözümler sağlanabilmektedir. Karmaşık veya sorunlu veriden bile anlam çıkarabilmek gibi dikkate değer yetenekleriyle yapay sinir ağları, insanlar veya bilgisayarlar tarafından anlaşılması zor trendleri belirlemek veya yapıları (pattern) çıkartmak için kullanılabilirler. Tam eğitilmiş bir yapay sinir ağı modeli, analiz ettiği bilgi kümesi (veri tabanı) için uzman olarak düşünülebilir. Bu uzman, değişik durumlar ve '... olsa ne olur?' türünde simülasyon problemlerine projeksiyonlar sağlamak için kullanılabilir (Yurtoğlu, 2005, s.36-37).

1.4.4.2.Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağlarının yukarıda belirtilen bir çok avantajlı özelliklerinin yanı sıra bazı dezavantajları da vardır. Bunları kısaca aşağıdaki gibi özetlemek mümkündür: (Öztemel, 2006, s.34-35)

- Yapay sinir ağlarının donanım bağımlı çalışmaları önemli bir sorun olarak görülebilir. Ağların temel varoluş nedenlerinden biriside paralel işlemciler üzerinde çalışabilmeleridir. Ağların özellikle, gerçek zamanlı bilgi işleyebilmeleri paralel çalışabilen işlemcilerin varlığına bağlıdır. Günümüzdeki makinelerin çoğu seri şekilde çalışabilmekte ve aynı zamanda sadece tek bir bilgiyi işleyebilmektedir. Paralel işlemleri seri makinelerde yapmak ise zaman kaybına yol açmaktadır. Bunun yanı sıra bir ağın nasıl oluşturulması gerektiğini belirleyecek kuralların olmaması da başka bir dezavantajdır. Her problem farklı sayıda işlemci gerektirebilir. Bazı problemleri çözebilmek için gerekli olan paralel işlemcilerin tamamını bir arada (paralel olarak) çalıştırmak mümkün olmayabilir.
- Probleme uygun ağ yapısının belirlenmesi genellikle deneme yanılma yolu ile yapılmaktadır bu ise önemli bir problemdir. Çünkü eğer problem için uygun bir ağ oluşturulmaz ise çözümü olan bir problemin çözülememesi veya performansı düşük çözümlerin elde edilmesi söz konusu olabilir. Bu aynı zamanda bulunan çözümün en iyi çözüm olduğunu da garanti etmez. Yani yapay sinir ağları kabul edilebilir çözümler üretebilir. Optimum (en iyi) çözümü garanti etmez.
- Bazı ağlarda ağın parametre değerlerinin (mesela öğrenme katsayısı, her katmanda olması gereken proses elemanı (yapay hücrelerin) sayısı, katman sayısı vb.) belirlenmesinde de bir kural olmaması diğer bir problemdir. Bu, iyi çözümler bulmayı zor durumda bırakan bir etken olarak görülebilir. Bu parametrelerin belirlenmesi de kullanıcının tecrübesine bağlıdır. Her problem için ayrı faktörleri dikkate almayı gerektirmektedir. Bu parametre değerleri için belirli standartların oluşturulması çok zor olduğundan her problem için ayrı ayrı değerlendirmeler yapılması gerektirmektedir. Bu da önemli bir dezavantaj olarak görülebilir.
- Ağın öğreneceği problemin ağa gösterimi de çok önemli bir problemdir. Yapay

sinir ağıları yukarıda belirtildiği gibi sadece nümerik bilgiler ile çalışmaktadırlar. Problemin nümerik gösterime dönüştürülmesi lazımdır. Bu ise kullanıcının becerisine bağlıdır. Örneğin bir olay hem ayrık (binary-ikili) hem de sürekli değerler ile gösterilebilir. Bunun hangisinin daha başarılı bir öğrenme gerçekleştirileceği ise bilinmemektedir. Bu konuda, kullanıcının tecrübesi de yeterli olmayabilir. Bu günümüzde bir çok olayın yapay sinir ağıları ile çözülememesinin en önemli nedenlerinden birisidir.

- Bir diğer sorun ise, belki de yukarıdakilerin en önemlisi daha önce açıklandığı gibi ağın davranışlarının açıklanamamasıdır. Bir probleme çözüm üretildiği zaman bunun nasıl ve neden üretildiği konusunda bir bilgi bulmak mümkün değildir. Bu ise ağın sonucuna olan güveni azaltmaktadır.
- Sonucu dezavantaj ise yapay sinir ağlarının öğrenme süresinin uzun olmasıdır. Bir yapay sinir ağını eğitebilmek için çok fazla denemeye ihtiyaç vardır. Eğitim zamanının kısaltılması ise kritik bir durumdur, çünkü yapay sinir ağıları ile tahminleme bir deneme yanılma sürecidir; bundan dolayı bir araştırmacı sınırlı bir zaman diliminde ne kadar fazla deneme yaparsa sonuçtan o kadar emin olacaktır. Yapay sinir ağı gelecek olaylarla ilgili tahminlerini benzer durumlardaki hafızasına bağlı olarak yapmaktadır. Örneğin finans alanında tahminleme yaparken, yapay sinir ağıları, belli başlı finansal değişkenlerin etkilerini ve hedef pazardaki gelecek fiyat hareketleri ile ilişkilerini miktar olarak belirler (<http://www.econ.upenn.edu/Centers/CARESS/CARESSpdf/02-08.pdf>).

1.5. YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI


Yapay sinir ağıları genel olarak birbirleri ile bağlantılı işlemci birimlerden veya diğer bir ifade ile yapay sinirlerden oluşurlar. Yapay sinir hücreleri arasındaki bağlantıların yapısı ağın yapısını da belirler. İstenilen hedefe ulaşabilmek için bağlantıların nasıl değiştirileceği, öğrenme algoritması tarafından belirlenir. Yapay sinir ağlarını yapılarına ve öğrenme algoritmalarına göre sınıflandırmak mümkündür. Çalışmamızın bu bölümünde yapay sinir ağlarını sadece yapılarına göre sınıflandırıp bir sonraki bölümde öğrenme algoritmaları açıklanmaya çalışılacaktır.

Yapay sinir ağı mimarileri, sınırlar arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre ikiye ayrılmaktadır; ileri beslemeli (feed forward) ve geri beslemeli (feedback, recurrent) ağlardır.

1.5.1.İleri Beslemeli Ağlar

İleri beslemeli ağlarda işlemci elemanlar genellikle katmanlara ayrılmışlardır. İşaretler, girdi katmanından çıktı katmanına tek yönlü bağlantılarla iletilir (Saraç, 2004, s.35). İleri beslemeli YSA'da, hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta (gizli) katmandaki hücrelere iletir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir (Rojas, 1996, s.42).

Şekil 11'de ileri beslemeli ağ blok diyagramı gösterilmiştir. İleri beslemeli ağlara örnek olarak Çok Katmanlı Algılayıcılar (Multilayered Perceptrons-MLP) ve Öğrenme Vektör Nicelendirmesi (Learning Vector Quantization-LVQ) ağları verilebilir (Sağiroğlu vd., 2003, s. 43). Araştırmamızda ileri beslemeli çok katmanlı algılayıcıyı kullanacağımızdan burada sadece Çok Katmanlı Algılayıcıların çalışmasından bahsedilecektir.




Şekil 11: İleri Beslemeli Ağın Blok Gösterimi

Kaynak: Sağiroğlu Ş., Beşdok E., Erler M. (2003); **Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları**, Kayseri: Ufuk Kitap Kıratsiye-Yayıncılık, s.43.

1.5.1.1. Çok Katmanlı Algılayıcılar

Tek bir katmandan oluşan bir algılayıcı sadece doğrusal fonksiyonları tahminleyebilir. Giriş ve çıkış katmanı arasında gizli katmanlara sahip olan ileri beslemeli çok katmanlı algılayıcılar ise tek katmanlı algılayıcıların karşılaştıkları sınırlamaları ortadan kaldırmaktadırlar (Alpaydın, 2004, s.241).

Bir yapay sinir ağından çözmesi istenilen problem doğrusal değilse ilk başta tasarlanmış yapay sinir ağları ile bunu modellemek mümkün değildir. Bu tür problemler için daha gelişmiş bir ağ türüne ihtiyaç duyulmuştur. Çok katmanlı algılayıcı da bu amaçla geliştirilen bir ağdır. Birçok öğrenme algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir.



Şekil 12: Çok Katmanlı Algılayıcının Yapısı

Kaynak: Sağiroğlu Ş., Beşdok E., Erler M. (2003); **Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları**, Kayseri: Ufuk Kitap Kıratsiye-Yayıncılık, s.54.

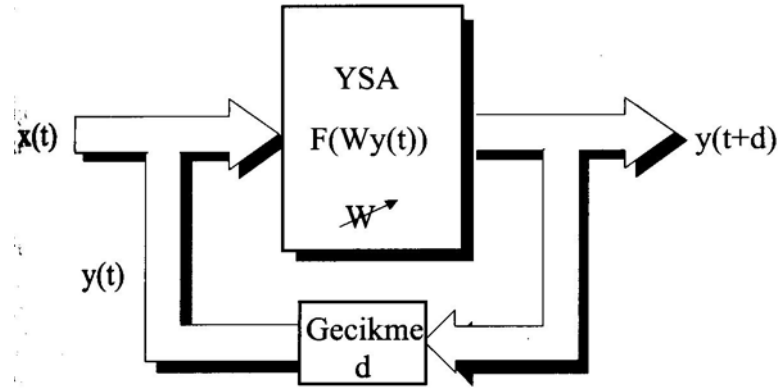
Şekil 12’de bir çok katmanlı algılayıcının yapısı gösterilmiştir. Bir çok katmanlı algılayıcı modeli, bir giriş, bir veya daha fazla gizli ve bir de çıkış katmanından oluşur. Her bir katmanda da bir veya daha fazla sayıda işlem elemanı bulunur. Bir katmandaki

bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileri doğru olup geri besleme yoktur. Bunun için bu tip ağlar ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Giriş ve çıkış katmanındaki işlemci elemanı sayısı tamamen uygulanan probleme bağlıdır. Ara katman sayısı ve ara katmanlardaki işlemci elemanı sayısı ise, deneme yanılma yolu ile bulunur.

Çok katmanlı algılayıcı ağlarında, ağa bir örnek gösterilir ve örnek sonucunda nasıl bir sonuç üretileceği de bildirilir (danışmanlı öğrenme). Örnekler giriş katmanına uygulanır, gizli katmanlarda işlenir ve çıkış katmanından da çıkışlar elde edilir. Kullanılan öğrenme algoritmasına göre, ağın çıkışı ile arzu edilen çıkış arasındaki hata tekrar geriye doğru yayılarak hata minimuma düşünceye kadar ağın ağırlıkları değiştirilir. İleri beslemeli ağlar, en genel anlamıyla giriş uzayıyla çıkış uzayı arasında statik haritalama yapar. Bir andaki çıkış, sadece o andaki girişin bir fonksiyonudur (Sağiroğlu vd., 2003, s.54-55, Lippmann, 1987, s.24-25).

1.5.2.Geri Beslemeli Ağlar

Geri beslemeli ağ mimarileri, genellikle danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılmaktadır. Bu tip ağlarda en az bir hücrenin çıkışı kendisine veya diğer hücrelere giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı üzerinden yapılır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli yapay sinir ağları, doğrusal olmayan dinamik bir davranış göstermektedir. Geri beslemeli ağlara örnek olarak Hopfield, Elman ve Jordan ağları verilebilir. (www.firat.edu.tr/akademik/fakulteler/muhendislik/bilgisayar/balatas/SinirselAglar.pdf)



Şekil 13: Geri Beslemeli Ağın Blok Gösterimi

Kaynak: Sağiroğlu Ş., Beşdok E., Erler M. (2003); **Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları**, Kayseri: Ufuk Kitap Kıratsiye-Yayıncılık, s.43.

Şekil 13’de bir geri beslemeli ağ yapısı görülmektedir. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır (Sağiroğlu vd., 2003, s.43).

1.6. YAPAY SİNİR AĞLARINDA ÖĞRENME

Yapay sinir ağlarının en ayırt edici özelliklerinden birisi de öğrenme yeteneğine sahip olmasıdır. Öğrenme elde bulunan örnekler arasındaki yapının iyi bir davranış göstermesini sağlayabilecek olan bağlantı ağırlıklarının hesaplanması olarak tanımlanır. Yapay sinir ağları öğrenme esnasında elde ettiği bilgileri, sinir hücreleri arasındaki bağlantı ağırlıkları olarak saklar. Bu ağırlık değerleri yapay sinir ağlarının verileri başarılı bir şekilde işleyebilmesi için gerekli olan bilgileri içerir (Şen, 2004, s.90).

Yapay sinir ağları gibi öğrenme yöntemleri örneklerden öğrenmeye dayanmaktadır. Örneklerden öğrenmenin temel felsefesi bir olay hakkındaki gerçekleşmiş örnekleri kullanarak olayın girdi ve çıktıları arasındaki ilişkileri öğrenmek ve bu ilişkilere göre daha sonra oluşacak olan yeni örneklerin çıktılarını belirlemektir. Burada bir olay ile ilgili örneklerin girdi ve çıktıları arasındaki ilişkinin olayın genelini temsil edecek bilgiler içerdiği kabul edilmektedir. Değişik örneklerin olayı değişik

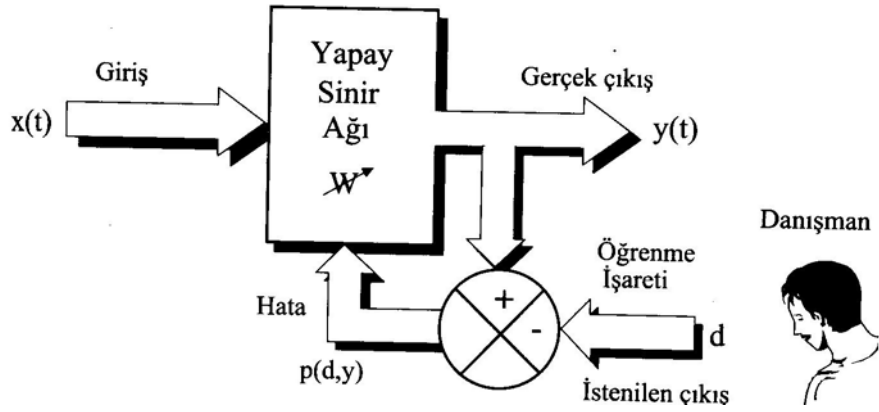
açılardan temsil ettiği varsayılmaktadır. Farklı örnekler kullanarak böylece olay değişik açılardan öğrenilmektedir. Burada bilgisayara sadece örnekler gösterilmektedir. Bunlardan başka herhangi bir ön bilgi verilmemektedir. Öğrenmeyi gerçekleştirecek sistem aradaki ilişkiyi kendi algoritmasını kullanarak keşfetmektedir (Öztemel, 2006, s. 24).

Yapay sinir ağlarının öğrenmesi için iki yaklaşım bulunmaktadır; danışmanlı (supervised) ve danışmansız (unsupervised) öğrenmedir. Danışmalı öğrenme, yapay sinir ağına istenilen çıktılarını, ya elle ağı performansı sınıflandırarak ya da girdilerle birlikte çıktılarını da sisteme girerek gösteren bir mekanizmayı gerektirir. Danışmansız öğrenmede ise yapay sinir ağı dışarıdan herhangi bir yardım almadan girdilere göre çıktılarını vermektedir (Anderson ve McNeill, 1992, s.10).

1.6.1.Danışmanlı Öğrenme

Yapay sinir ağlarında en fazla kullanılan öğrenme metodu olan danışmanlı öğrenmede, yapay sinir ağına örnek olarak bir çıktı (beklenen çıktı) verilir ve bu çıktıyla ağı ürettiği çıktı karşılaştırılır. İki çıktı arasındaki fark hata olarak alınır. Başlangıçta genellikle rassal olarak verilen ağırlıklar ağı tarafından hata minimize edilene kadar döngüler halinde değiştirilir (Anderson ve McNeill, 1992, s.11).

Danışmanlı öğrenmede, yapay sinir ağı kullanılmadan önce eğitilmelidir. Eğitim işlemi, sinir ağına giriş ve çıkış bilgileri sunmaktan oluşur. Bu bilgiler genellikle eğitim kümesi olarak tanımlanır. Yani, her bir giriş kümesi için çıkış kümesi ağına sağlanmalıdır (Elmas, 2003, s.96).



Şekil 14: Danışmanlı Öğrenme Yapısı

Kaynak: Sağiroğlu Ş., Beşdok E., Erler M. (2003); **Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları**, Kayseri: Ufuk Kitap Kıratsiye-Yayıncılık, s.81.

Şekil 14’de danışmanlı öğrenme yapısı gösterilmektedir. Bu öğrenme yönteminde öğrenmeye dışarıdan müdahale eden bir öğretmen, danışman vardır. Öğrenme danışmanın kontrolündedir. Danışman, eğitim kümesini ve hata değerini belirleyerek eğitimin ne kadar devam edeceğine karar verir. Bu yöntemin en önemli özelliği eğitim esnasında gerçek giriş, çıkış değerlerin kullanılmasıdır. Danışmanlı öğrenme kuralları şunlardır: (Şen, 2004, s.98-99)


1. Algılayıcı (Perceptron) Öğrenme Kuralı
2. Delta Öğrenme Kuralı
3. Genişletilmiş Delta Öğrenme Kuralı
4. Geri Yayılımlı Öğrenme Kuralı

Uygulamamızda geri yayılımlı öğrenme kuralını kullanacağımızdan burada danışmanlı öğrenme kurallarından sadece geri yayılımlı öğrenme kuralından bahsetmenin daha yararlı olacağı düşünülmektedir.

1.6.1.1.Geri Yayılım Öğrenme Kuralı

“Geri yayılım” kelimesi gizli katmanlardaki hatanın, çıktı katmanlarında bulunan hatanın geriye doğru yayılmasıyla elde edilmesi sonucu ortaya çıkmıştır (Fu, 1994, s. 81). Geri yayılım öğrenme kuralı, yapay sinir ağları içerisinde hemen hemen her probleme rahatlıkla uygulanabilir bir yapıyı oluşturmaktadır. Geri beslemeli bir öğrenme mekanizması söz konusudur. Burada yapay sinir ağlarının yapısı ileri beslemeli olmasına karşın, hatanın geriye doğru ket vurmasından kaynaklanan bir öğrenme kuralı olduğu için geri besleme söz konusu olmaktadır (Lipmann, 1987, s.5).

Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı en çok tercih edilen öğrenme algoritması olmuştur. Geri yayılım öğrenme yöntemi, sistem hatasını veya maliyet işlevini azaltma esasına dayanan bir eniyileme (optimizasyon) işlemidir. Bu öğrenmeyi gerçekleştiren algortima, hataları çıkıştan girişe geriye doğru azaltmaya çalışmasından dolayı geri yayılım ismini almıştır. Geri yayımlı öğrenen ağlar hiyerarşik yapıdadırlar. Giriş, çıkış ve en az bir gizli katman olmak üzere üç katmandan oluşurlar. Geri yayılım öğrenmesi sırasında ağ, her giriş örüntüsünü, çıkış nöronlarında sonuç üretmek üzere gizli katmanlardaki nöronlardan geçirir. Daha sonra çıkış katmanındaki hataları bulabilmek için, beklenen sonuçla, elde edilen sonuç karşılaştırılır. Bundan sonra, çıktı hatalarının türevi çıkış katmanından geriye doğru gizli katmanlara geçilir. Hata değerleri bulunduktan sonra, nöronlar kendi hatalarını azaltmak için ağırlıklarını ayarlar. Ağırlık değiştirme denklemleri, ağdaki hata kareleri artalamasını (MSE) en küçük yapacak şekilde düzenlenir (Bolat ve Kalenderli, 2003, s. 190).



Şekil 15: Geri Yayılım Ağ Örneği

Kaynak: Elmas Ç. (2003); **Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)**, 1. Baskı, Ankara: Seçkin Yayıncılık, s.124.

Şekil 15’de bir geri yayılım ağ örneği verilmiştir. Geri yayılım ağı, Geoffrey Hinton ve James McClelland tarafından geliştirilmiştir. Giriş, çıkış ve en az bir gizli katmandan oluşur. Gizli katmandaki düğüm sayısı değişebilir. Düğüm sayısı artarsa ağın hatırlama yeteneği artar, ancak öğrenme süresi uzar. Düğüm sayısı az olursa öğrenme süresi kısalmış ancak ağın hatırlama yeteneği azalır. Şekilde de görüldüğü gibi, bir katmandaki her düğüm kendinden sonraki katmandaki her düğüme bağlıdır. Fakat aynı katman içindeki hiçbir düğüm diğerine bağlı değildir. Yine her katmandaki düğümlerin çıkışları kendinden önceki katmana giriş olarak döner (Kartalopoulos, 1997, s.78-80).

1.6.1.1.2. Geri Yayılım Öğrenme Kuralı Algoritması

Yapay sinir ağlarının istenilen giriş-çıkış karakteristiğini ne kadar sağladığının bir ölçüsü olarak, yapay sinir ağının çıkış katmanındaki her sinirine ait hata sinyallerinin karelerinin toplamından oluşan bir uygunluk fonksiyonu tanımlanmıştır. Eğitimin k 'inci iterasyonunda yapay sinir ağının çıkış katmanındaki i 'inci sinirinin çıkış değeri y_i , bu sinirden vermesi istenilen değer d_i ile gösterilirse, i sinirin hata sinyali:

$$e_i = d_i - y_i(k) \quad (1.11)$$

denklemini elde edilir. Uygunluk fonksiyonu

$$E = \frac{1}{2} \sum_i e_i^2(k) = \frac{1}{2} \sum_i (d_i - y_i(k))^2 \quad (1.12)$$

denklemini ile ifade edilmektedir. Geri yayılım algoritmasının amacı uygunluk fonksiyonunu minimum yapmaktır. Uygunluk fonksiyonu yapay sinir ağının ağırlık değerlerine bağlı olduğundan, algoritma yapay sinir ağının ağırlıklarının en uygun biçimde değiştirilmesi işlemlerinden oluşmaktadır. Yapay sinir ağındaki her w_{ij} ağırlık değerinin değişme miktarı gradyan-azalma (gradient-descend) yöntemi olarak adlandırılan

$$\Delta w_{ij} = -\eta \frac{\partial E(\vec{w})}{\partial w_{ij}} \quad (1.13)$$

denkleminde yola çıkarak bulunmaktadır. Burada η öğrenme katsayısıdır.

Geril yayılım algoritmasında her iterasyon, ileri yayılım ve geril yayılım olmak üzere iki aşamadan oluşmaktadır. İleri yayılım aşamasında yapay sinir ağının o andaki durumunda yapay sinir ağına uygulanan giriş sinyallerine karşı yapay sinir ağının çıkışlarında oluşan değerler bulunur. Geril yayılım aşamasında, çıkışlarda oluşan hatalardan yola çıkılarak, devredeki ağırlıkların yeniden düzenlenmesi yapılmaktadır. Yapay sinir ağındaki her ağırlık değişimi

$$\Delta w_{ij} = \eta \delta_j y_i \quad (1.14)$$

denklemini ile yapılmaktadır. δ_j , çıkış katmanını sinirleri için

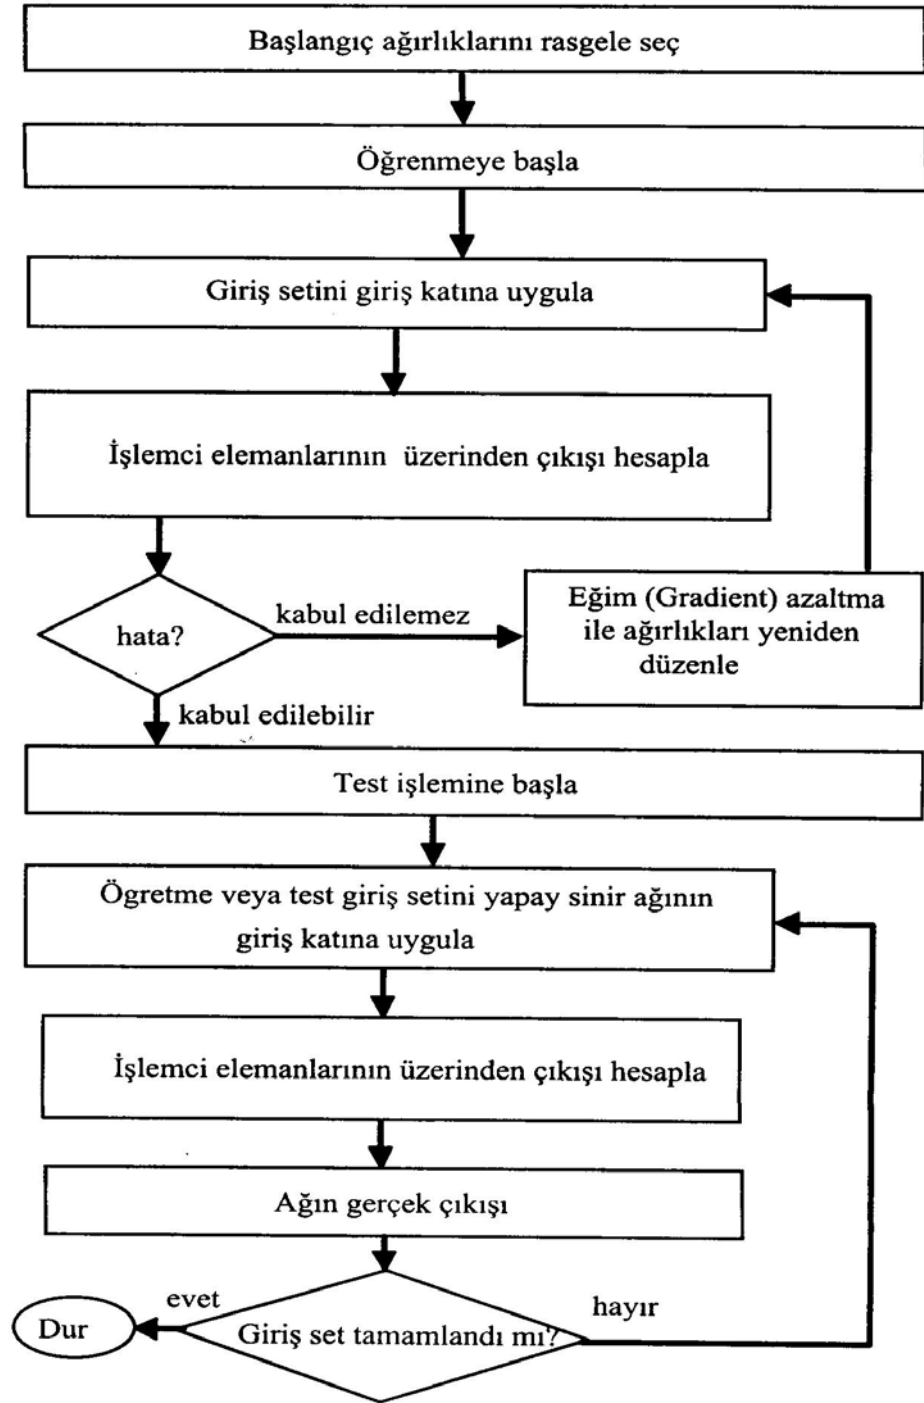
$$\delta_j = e_j(k)f'_j \quad (1.15)$$

gizli katmanlarda bulunan sinirler için,

$$\delta_j = f'_j \sum_m \delta_m w_{mj} \quad (1.16)$$

olarak tanımlanmıştır. f'_j , j sinirinin aktivasyon fonksiyonudur. Bu tanımlar ile hata sinyallerinin devrenin çıkışından girişine doğru akışı, ileri yayılma aşamasında sinyallerin ileri doğru akışına benzetilmektedir (www.fbe.gazi.edu.tr/tr/bolumler/guadek/6.doc).

Geri yayılım algoritmasının daha iyi anlaşılması için, ağıın öğrenme aşamasının akış şeması Şekil 16'da gösterilmiştir. Ağıın eğitilmesinin sağlıklı bir şekilde gerçekleştirilebilmesi için başlangıçta rastgele olarak atanan bağlantı ağırlıkları çok önemlidir. Rastgele olarak atanan bağlantı ağırlıkları eğitime hangi noktadan başlayacağımızı belirlemektedir. Başlanan bu noktanın gerçek çözüme çok yakın veya uzak bir nokta olması tamamen başta belirleyeceğimiz değerlere bağlıdır. Yapay sinir ağlarında önemli noktalardan biri eğitimin ne kadar sürdürüleceğine karar verilmesidir. Eğitime işleminin tamamlanması için iki seçenek mevcuttur. Bunlardan ilki belli bir miktardaki hata toleransını göze almak, o hata değerinden daha düşük hata değerine ulaşmaya kadar eğitmeyi sürdürmektir. Dolayısıyla bu durumda eğitime sayısından ziyade hata miktarı önemlidir. Burada hata toleransının makul sınırlar içerisinde olması gerekmektedir. Diğer seçenek sabit bir eğitim sayısının seçilmesidir. Burada eğitici belirlenen eğitim sayısı sonucunda elde edilecek olan hatayı kabul etmektedir. (Sağıroğlu vd., 2003, s.80).



Şekil 16: Bir Ağda Geri Yayımlı Öğrenme Algoritmasının Uygulanması

Kaynak: Sağiroğlu Ş., Beşdok E., Erler M. (2003); **Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları**, Kayseri: Ufuk Kitap Kıratsiye-Yayıncılık, s.80.

Eđitim esnasında hata deęerinin daima azalması beklenmemelidir. Bazen hatanın arttıęı da gözlenebilir. Bu genellikle çözümden uzaklaştıęımızın belirtisidir. Hata yüzeyi üzerinde yerel bir en küçük noktaya ulaşılmıř iken eđitime devam edilirse, yerel en küçükten kurtuluncaya kadar hata deęeri belli bir miktar artar. Daha sonra diđer bir en küçüęe doęru ilerledięinde hata deęeri yeniden azalmaya başlar. Bununla birlikte hata deęerinin hiç azalmadan artması da o noktanın genel bir en küçük nokta olduęunun göstergesidir. Tüm bunlara raęmen çözümler esnasında hata yüzeyi hakkında bilgimiz olmadıęı için ulařılan noktanın yerel mi, yoksa genel bir en küçük nokta mı olduęuna karar vermek zordur. Bu yüzden yapılan birçok çalıřmada, hata deęerinin artmaya başladıęı anda eđitme iřlemine son verilir (řen, 2004, s.109-111).


YSA eđitimindeki diđer önemli bir parametre de öğrenme katsayısının, η , seçilmesidir. Bu katsayı bağlantı aęırlıklarındaki deęiřme miktarını kontrol eder. Verimli bir öğrenmenin seçilmesi için öğrenme katsayısının uygun seçilmesi önemlidir. Eřitliklerde kullanılan η deęeri, her zaman pozitif ve birden küçük deęerler almalıdır. Eđitim için kullanılan örnekler birbirine çok benzer ise geniş η deęerleri kullanılabilir ve böylece eđitim fazla zaman almaz (0,8 veya 0,9 gibi). Eđer kullanılan örnekler yeterince iyi deęilse, gürültüden doęacak tehlikelerden sakınmak için η deęeri 0,2-0,1 arasında tutulmalıdır. Örnekler hakkında bilgi yoksa, ortalama deęer alınmalıdır (Elmas, 2003, s.133).

1.6.2.Danıřmansız Öğrenme

Bu öğrenme türünde sistemin öğrenmesine yardımcı olan herhangi bir danışman yoktur. Sisteme sadece girdi deęerleri gösterilir. Örneklerdeki parametreler arasındaki iliřkileri sistemin kendi kendisine öğrenmesi beklenir. Bu, daha çok sınıflandırma problemleri için kullanılan bir öğrenme yöntemidir. Yalnız, sistemin öğrenmesi bittikten sonra çıktıların ne anlama geldięini gösteren etiketlendirmenin kullanıcı tarafından yapılması gerekmektedir (Öztemel, 2006, s.25).

řekil 17’de danışmansız öğrenme yapısı gösterilmiřtir. Grossberg tarafından geliřtirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliřtirilen

SOM (Self Organizing Map) öğrenme kuralları danışmansız öğrenmeye örnek olarak verilebilir (Sağıroğlu vd., 2003, s.79-81).



Şekil 17: Danışmansız Öğrenme Yapısı

Kaynak: Sağıroğlu Ş., Beşdok E., Erler M. (2003); **Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları**, Kayseri: Ufuk Kitap Kıratsiye-Yayıncılık, s.81.

Danışmansız öğrenme metodu, yapay sinir ağlarında sürekli araştırılan ve gelişen bir öğrenme metodudur. Bu metod, gelecekte bilgisayarların insan yardımı olmadan öğrenebileceklerinin göstergesidir. Ancak günümüzde sınırlı kullanım alanları bulan ve hala yoğun araştırma konusu olan bir öğrenme metodudur (Anderson ve McNeill, 1992, s.11-12).

Bu iki temel öğrenme metodundan başka literatürde takviyeli öğrenme (reinforcement learning) adı verilen bir metod daha yer almaktadır. Bu metoddan bazı kaynaklarda danışmanlı bazı kaynaklarda ise danışmansız öğrenmenin bir alt türü olarak, bazı kaynaklarda ise kendi başına bir öğrenme metodu olarak bahsedilmektedir. Bu metoda göre, yapay sinir ağına sadece girdiler verilmekte, bu girdilere karşılık çıktıları üretmesi beklenmekte ve bu çıktıların ne derece doğru olduğunu belirten bir skor veya derece bildirilmektedir (Jain vd., 1996, s.19-20).

1.7. YAPAY SİNİR AĞLARININ UYGULAMA ALANLARI

Daha önceki bölümlerde yapay sinir ağlarının özelliklerinden ve işleyişinden bahsedilmiştir. Bu bölümde ise yapay sinir ağlarının genel uygulama alanlarına değinilmeye çalışılacaktır (Öztemel, 2006, s.203-296; Sağırođlu vd., 2003, s.50-52; Elmas, 2003, s.175-178).

Yapay sinir ağlarının uygulamaları gözden geçirildiğinde binlerce uygulamanın yapıldığı ve başarılı sonuçların elde edildiđi görülebilir. Uygulamalar o kadar yaygındır ki, bunların listesini çıkartmak hemen hemen mümkün değildir. İlk YSA çalışmaları yaklaşık elli yıl önce başlamış olmasına karşılık bunların etkin kullanımı ve sürekli gelişimine son 20 yıl içinde rastlanmaktadır. Halbuki, birçok kontrol sistemi ile en iyileştirme (optimizasyon) yöntemlerinin esasları, matematik usulleri, terminolojileri ve kuralları nerede ise çok uzun yıllardır değışmeyecek biçimde kurulmuştur. YSA yöntemleri yüksek eğitim, araştırma, endüstri ve teknolojik gelişmeler için bulanık mantık (BM) ve GA yöntemleri ile beraber çok başarılı bir temel teşkil etmektedir. Herbirinin çok değışik alanlarda uygulamaları vardır.

Çalışmalar eskiden laboratuvarlarda yürütölmekte ve veriler benzetim yolu ile elde edilmekte iken artık yapay sinir ağları günlük hayatımızın vazgeçilmez bir parçası haline gelmiştir. Ağların eğitilmesinde gerçek örnekler kullanılmaktadır. Örnek bulmak eskisi kadar zor olmamaktadır. Evimizdeki aletlerden elimizdeki cep telefonlarına kadar bir çok alanda yapay sinir ağlarının uygulamalarını görmek mümkündür. Burada her türlü uygulamadan örnek vermek imkansızdır. O nedenle burada, yapay sinir ağları uygulamalarının bir sınıflandırılması yapılacaktır. Bu kapsamda, yapay sinir ağları uygulamaları:

- Endüstriyel uygulamalar
- Finansal uygulamalar
- Askeri ve savunma uygulamaları
- Sağlık uygulamaları
- Diğer alanlardaki uygulamalar

şeklinde sınıflandırılarak incelenebilir. Bu alanlardaki uygulamalar incelendiğinde yapay sinir ağlarının genel olarak aşağıdaki fonksiyonları gerçekleştirmek için uygulandıkları görülmektedir:

- **Tahmin:** Bu amaçla kullanılan yapay sinir ağları, ağa sunulan bilgilerden yararlanılarak karşılık gelen çıktı değerini tahmin ederler. Hava tahmini, borsada hisselerin değerlerinin, ileriki satışların, üretim ihtiyacının, pazar performansının, enerji ihtiyacının, at yarışlarının tahmini, kanser riskini belirleme, döviz kurlarının tahmini gibi örnekler vermek mümkündür.
- **Sınıflandırma:** Bu amaçla kullanılan yapay sinir ağları kendilerine sunulan bilgileri kategorize etmek görevini üstlenirler. Bir makine üzerinde görülen hataların, müşteri/pazar profillerinin, imza tetkiklerinin, mal değerinin, hücre tiplerinin sınıflandırılması, borçlanma/risk değerlendirmeleri buna örnek olarak verilebilir.
- **Veri ilişkilendirme:** Bu amaçla eğitilen ağlar ağa sunulan verilerin hatalı ve eksik olup olmadığını belirlerler. Öğrendikleri bilgiler ile eksik olan bilgileri tamamlarlar. Eksik bir resmin tamamlanması bu konuda örnek olarak verilebilir. Bu sınıflandırmaya benzer bir yaklaşım gibi görülmeye buna ilave olarak hatalı olan verileri tanımlar. Örnek olarak taranan bir dokümandaki karakterleri algılamanın yanında tarayıcının düzgün olarak çalışmadığını da algılayabilir.
- **Veri filtreleme:** Bu amaçla eğitilen ağlar, birçok veri arasından uygun verileri belirleme görevini yerine getirirler. Telefon konuşmalarındaki gürültüleri asıl konuşmalardan ayıran ağlar, bir resim üzerindeki istenilmeyen parazitleri temizleme bu konudaki uygulamalara örnek olarak verilebilir. Giriş sinyalleri içerisindeki uygun olmayan verilerin ayıklanmasını sağlar.
- **Tanıma ve eşleştirme:** Değişik şekil ve örüntülerin tanınması, eksik, karmaşık, belirsiz bilgilerin işlenerek eşleştirme ve tanıma fonksiyonları gerçekleştirilebilir. Daha önce örneği verilen kalite kontrol şemaları üzerindeki şekilleri tanıyan ağ, bu konuda örnek olarak verilebilir.

- **Teşhis:** Bu amaçla geliştirilen ağlar sistemlerin olumsuzluklarının ortaya konulması ve problemlerin teşhis edilmesi işlemini yerine getirirler. Makinelerin, süreçlerin arazi durumlarının ve hatalarının teşhis edilmesi buna örnek olarak verilebilir. Tıp alanında da bu tür sistemler yaygın olarak geliştirilmektedir.
- **Yorumlama:** Bir olay hakkında toplanan örneklerden elde edilen ve eğitim sonucu oluşturulan bilgileri kullanarak yeni olayların yorumlanması işlemleri bu kapsamda düşünülmektedir. Bir olay hakkında toplanan verilerin yorumlanarak istatistiksel dağılımlarının belirlenmesi bu konuda örnek olarak verilebilir. Giriş verisindeki gruplar arasındaki ilişkileri analiz etme işlemidir.

İKİNCİ BÖLÜM

ÖNGÖRÜMLEME TEKNİKLERİ

2.1. ÖNGÖRÜMLEME TEKNİKLERİ HAKKINDA GENEL BİLGİ

Geleceği öngörümler sosyo-ekonomik gelişmenin vazgeçilmez bir unsurudur. Karar verme durumunda olan bütün özel veya kamu kuruluşlarının gelecek zamanda durumlarını muhafaza etmeleri ve geliştirebilmeleri, gelecekteki olayları öngörümleyebilmeleri ve iyi bir plan çerçevesinde uygun çözümler bulmaları ile mümkündür (Bircan ve Karagöz, 2003, s.49).

Öngörümler teknikleri, literatürde farklı şekillerde sınıflandırılmış olmakla beraber temelde iki grupta ele alınmaktadır (Özmucur, 1990, s.15; Fretchling, 1996, s.7):

1. Nitel (kalitatif) Yöntemler,
2. Nicel (kantitatif) Yöntmler.

Genel olarak nicel yaklaşımların girdisi, çeşitli zaman aralıklarında toplanmış olan verilerdir. Verilerin iyi bir şekilde analiz edilmesi, bu yöntemlerin temelini oluşturmaktadır. Buna karşılık nitel yaklaşımlar, konu ile ilgili uzmanların bilgi ve deneyimlerinden yararlanarak bu alandaki gelişmelerin ne yönde olacağı, ne tür ihtiyaçlar ortaya çıkaracağı gibi konularda yoğunlaşmaktadır (Archer, 1980, s.177). Uygulamada ileriye dönük öngörümlemelerde nicel ve nitel yöntemlerin bir arada kullanıldığı da görülmektedir. Nicel yöntemlerle elde edilen öngörümler sonuçları tarafsız ve deneyimli uzmanların görüşleri ışığında değerlendirilerek kullanılabilir (Orhunbilge, 1999, s.3).

Nitel öngörümler yöntemleri subjektif nitelikte olup, bilgi, görgü, ihtisas sahiplerinin kanaatleri ve yönetim kararlarına dayanan tüm öngörümler yöntemlerini

kapsar. Bu konuda kullanılan yöntemlerin amacı, ekonomik alanda meydana gelmesi muhtemel deęişmeleri ve/veya gelişmeleri öngörümleyerek, geleceęe dönük kararların alınmasında yardımcı olmaktır. Bu nedenle, ekonomik alanda geçmiş dönemlere ait sayısal verilerin bulunmaması halinde, geleceęe dönük öngörümlemenin yapılmasında, nitel öngörümleme yönteminden yararlanılır. Uygulamada en çok kullanılan nitel öngörümleme yöntemleri; “Delphi Yöntemi”, “Senaryo Analizi”, “Uzman Panalleri”, “İdare Heyeti Görüşleri”, “Nominal Grup Yönerisi”, “Beklentisel (Anticipatory) Analiz”, “Morfolojik Araştırmalar”, “Satış Ekibi Tahminleri” olarak sayılabilir (Fretchling, 2001, s.212).

Öngörümleme ekonomik deęişkenin geçmiş dönemlerde gerçekleşen sayısal deęerleri esas alınarak, bir takım matematik ve istatistik kurallarla gelecekteki deęerlerine bir yaklaşımda bulunmaya çalışan tüm öngörümleme teknikleri, nicel öngörümleme teknięi sınıfına girer. Bu yöntemlerin hepsinde, ele alınan veri setinin belirli bir sisteme göre geliştięi ve ayrıca sistemin yapısında tesadüfi unsurların da mevcut olduęu varsayımından hareket edilir (Montgomery ve Johnson, 1976, s.7). Nicel öngörümleme teknikleri genel olarak iki gruba ayrılmaktadır: (De Lugio, 1998, s.21; Başoęlu ve Parasız, 2003, s.23)

1. İlişkiye Dayalı (Nedensel) Yöntemler,
2. Zaman Serisi Analizleri.

Araştırmamızda esas alınan öngörümleme teknięi, nicel öngörümleme yöntemlerinden zaman serisi analizleri olacaęından, kısaca ilişkiye dayalı yöntemlerden bahsedilerek zaman serisi analizleri yöntemleri daha kapsamlı olarak ele alınacaktır.

2.2. İLİŞKİYE DAYALI YÖNTEMLER

Nedensel dięer adıyla ilişkiye dayalı öngörümleme tekniklerinde; tahmini deęeri bulunacak deęişkenin çeşitli faktörlerden etkilendięi düşünülerek, bağımlı deęişkenin etkilendięi ya da bağılı olabileceęi dięer deęişkenlerin tespitine çalışılmakta ve bu etkilerin formüle edilmesi amaçlanmaktadır (Orhunbilge, 1999, s.3). Nedensel

yöntemlerde bir değişkenin gelecekteki değerlerini öngörümlemeden çok iki ya da daha fazla değişken arasındaki ilişkinin açıklanılmasına çalışılmaktadır. Bağımlı değişken ile ilişkisi olan değişken veya değişkenlerin belirlenmesi ve bu ilişkiye uygun bir matematiksel ifadenin bulunması, nedensel yöntemlerin temel amacını oluşturmaktadır (Fretchling, 2001, s.17). İlişkiye dayalı öngörümleme tekniklerinin temelini regresyon analizleri oluşturmaktadır.

2.3. ZAMAN SERİLERİ ANALİZİ

Zaman serisi, zaman sırasına konmuş gözlem değerleri kümesi olarak tanımlanabilir. Zaman serisinde ilgilenilen özellik bir değişkendir. Bu değişken zaman içerisinde çeşitli nedenlere bağlı olarak farklı değerler alır. Dolayısıyla zaman serisi, zaman sırasına konmuş değişken değer kümesi olarak ifade edilebilir. Başka bir ifadeyle, gözlemlerin belirli bir dönem için gün, hafta, ay, üç ay, yıl gibi birbirini izleyen eşit aralıklarla yapılması ile elde edilen seriler zaman serileri olarak adlandırılmaktadır ve incelenen zaman serisi Y_t ile simgelendiğinde gözlemler de $t=1,2,\dots,T$ olmak üzere Y_1, Y_2, Y_3,\dots, Y_T şeklinde gösterilebilir (Akgül, 2003a, s.3).

Zaman serileri analizinde, öngörülünecek değişkene ilişkin veriler belirli bir veri seyri elde etmek üzere analiz edilmektedir. Bu nedenle öngörümleme sadece geçmiş verilerin bu amaçla analiz edilmesine ve yapılacak tahminlerde kullanılmasına dayanmaktadır. Bu özelliğinden dolayı zaman serileri analizi, değişmeyen koşullar altında daha etkin olmaktadır (Bhattacharya, 1997, s.5).

Son 40-50 yılda zaman serileriyle ilgili analiz tekniği, modeli ve yöntemlerindeki gelişmeler oldukça ilginç ve önemli olmuştur. İstatistikçiler, mühendisler ve iktisatçılar farklı noktalardan hareket ederek gereksinim ve amaçlarına uygun önemli teknikler geliştirmiş ve zaman serisi analizine önemli katkı ve yaklaşımda bulunmuşlardır.

Zaman serisi öngörümleme yöntemlerine geçmeden önce, zaman serisi analizleri ile ilgili bazı temel kavramlardan kısaca bahsetmek gerekmektedir. Zaman serisini oluşturan değerler kümesi sürekli bir küme ise zaman serisinin sürekli olduğu, eğer

küme kesikli ise zaman serisinin kesikli olduğu söylenebilir. Kesikli bir zaman serisinden alınan gözlem değerleri Y_{t1} , Y_{t2} , ..., Y_{tn} olarak gösterilebilir. t_1, t_2, \dots, t_n gözlem zamanlarını göstermektedir. Gözlem zamanları arasındaki fark eşittir ve sabittir. Kesikli zaman serilerinde gözlem zamanları arasındaki fark eşit ve sabit olmayabilir. Kesikli zaman serileri iki şekilde elde edilebilir: (Box ve Jenkins, 1976, s.32)

1. Sürekli bir zaman serisinden örnekleme yapılarak,
2. Bir değişkenin değerini belli bir zaman diliminde gözleyerek.

Bir zaman serisi, serinin ifade ettiği sosyo-ekonomik olayı oluşturan temel ve yapısal faktörlerin etki, yön ve derecelerinin farklı olması nedeniyle dört tür ayrı dalgalanmanın etkisi altında kalır (Hamburg, 1974, s.330). Bu dalgalanmalara serinin unsurları veya bileşenleri denir. Sözü edilen bileşenler, zaman serisini birlikte ve aynı anda etkiler. Bu nedenle, bunların ayrı ayrı ele alınmaması halinde, zaman serilerinde belirli bir eğilim veya gelişmenin saptanması çok zor olur. Bir zaman serisini etkileyen bu dört unsur; Trend (T), Mevsimsel değişimler (M), Konjonktürel değişimler (K) ve Rassal (düzensiz) değişimler (R) olarak gruplandırılır.

Trend, zaman serisinin uzun dönemdeki eğilimini gösterir. Örneğin sermaye stokunun büyümesi, zevk ve tercihlerde ve tüketim kalıplarındaki değişimler gibi faktörlerin etkisi sonunda zaman serisi, uzun dönemde artma veya azalma eğilimi gösterebilir. Zaman serisi eğer kısa zaman aralıklı ise, örneğin aylık veya üç aylık olarak toplanmışsa, bu halde mevsimlik değişimler gözükabilir. Yıllık seriler için bu söz konusu değildir. Mevsimlik değişimler, mevsimlik indekslerin hesaplanmasıyla ortaya konabilir. Genellikle gelişmiş piyasa ekonomileri için toplanmış zaman serilerinde konjonktürel değişimler görülür. Bu gibi değişimlere ekonomilerde ekonomik faaliyetler düzeyinin uzun yıllar aynı düzeyde kalmasını önleyen sistem içindeki faktörler sebep olur. Bunun yanı sıra, belirli faktörler dışında kalan ve varlığı daha önceden tahmin edilemeyen ve etkisini devamlı olarak göstermeyen bazı olayların sonucunda ortaya çıkan değişimlere Rassal (düzensiz) değişimler denir. Örneğin, grevler, devalüasyonlar. Zaman serisi analizleriyle trend, mevsimsel değişimler, konjonktürel değişimler hesaplanabilir. Fakat, rassal değişimler hiç bir şekilde tahmin

edilemez (Korum, 1972, s.203). Zaman serilerinin açıkladığımız dört bileşeni, birbirlerine bağlı ve karşılıklı ilişki içindedirler. Bunların birbirleriyle olan ilişkilerini belirleyen farklı modeller vardır. Yaygın olan görüşler, şu modeller etrafında birleşmektedir (Gilchrist, 1976, s.117-118).

$$Y_t = T + M + K + R$$

Toplamsal Model

$$Y_t = T * M * K * R$$

Çarpımsal Model

Toplamsal modele göre, zaman serilerinin herhangi bir (t) anındaki değeri, bu dört unsurun toplamından meydana gelir. Bu modele göre, unsurların birbirlerini etkilemedikleri kabul edilir. Bu model benimsendiğinde herhangi bir unsurun seri içindeki payı mutlak değer olarak belirlenebilir. Çarpımsal modele göre, zaman serilerinin herhangi bir (t) anındaki değeri, bu dört unsurun çarpımından meydana gelir. Bu modele göre, unsurların birbirlerini etkiledikleri varsayılır.

Zaman serileriyle ilgili olarak üzerinde durulması gereken bir diğer konu ise “durağanlık” (stationarity) kavramıdır. Bir zaman serisinin stokastik bir seri olarak ortalaması, varyansı, kovaryansı ve daha yüksek dereceden momentleri, incelenen zaman süresince değişmiyorsa veya seri periyodik dalgalanmalardan arınırsa bu seriye durağan seri ve bu olaya da durağanlık denir. Başka bir ifadeyle durağanlık serinin istatistiksel olarak dengeye gelmesi de denilebilir (Özmen, 1986, s.4-5). Zaman serisi ile ilgili analizlerde kullanılan tekniklerin bir çoğunun serinin durağan olduğu varsayımına dayanmaları söz konusu iken gözlenen bir çok serinin durağan olmadığı görülmektedir (Akgül, 2003b, s.10). Durağanlık, zaman serilerinde en önemli kavramlardan biridir. Çünkü birçok istatistiki sonuç çıkarımlar, durağan zaman serileri için yapılmaktadır. Ancak özellikle ekonomik zaman serilerinden çok azı durağan serilerdir. Dolayısı ile, eğer seri durağan değil ise çeşitli teknikler kullanılarak önce durağan hale getirmek gerekmekte ve daha sonra analizler yapılabilmektedir (Akdi, 2003, s.2).

Zaman serileri analizinde literatürde yer alan bir çok yöntem bulunmaktadır. Bunlardan bazıları mekanik tahmin yöntemleri, hareketli ortalamalar yöntemi, üstel düzleştirme yöntemleri ve Box-Jenkins modelleridir. Bu bölümde araştırmamızda

kullanılması düşünölen yöntem geređi, önce zaman serilerinin bileşenlerinden trendin bileşenlerine ayrılması yöntemine ve daha sonra Box-Jenkins metodolojisine değinilecektir. En son olarak, çalışmamızın esas yöntemi olan yapay sinir ağlarının öngörümlemede kullanımı hakkında bilgi verilecektir.

2.3.1.Trendin Bileşenlerine Ayrılması Yöntemi

Zaman serilerinin analizi seriyi oluşturan bileşenlerin ayrışımını gerektirir. Bu yöntemde de “Trendin Bileşenlerine Ayrılması” yöntemi (trend decomposition) denmektedir. Bir seriyi bileşenlerine ayırmak için kapsadığı dört bileşen arasında belli bir ilişki bulunduğu varsayılmalıdır. Genellikle izlenen yol bir zaman serisinin birkaç bileşenin toplamı veya çarpımından meydana geldiđi varsayımdır (Say, 2006, s.17)

Yukarıda zaman serilerinin bileşenlerinden ve toplamsal ve çarpımsal modelden bahsedilmiştir. Bu bölümde verilen bir zaman serisinin bileşenlerine nasıl ayrıştırıldığından bahsedilecektir.

2.3.1.1.Trendin Belirlenmesi

Trendin bileşenlerine ayrılması yönteminde öncelikle bir zaman serisinin bileşenlerinden trend bileşeni belirlenir. Trendin belirlenmesi büyük önem taşımaktadır. Çünkü trendin belirlenmesiyle;

1. İncelenen değışkenin geçmiş dönemdeki değışmeleri ortaya çıkarılabilir.
2. Tahminler yapılarak geleceđin planlanması için gerekli bilgiler elde edilebilir.
3. Zaman serilerindeki diđer bileşenlerin etkisi ortaya çıkarılabilir (Orhunbilge, 1999, s.9).

Zaman serisindeki trend (uzun dönemli eğilim) doğrusal olabileceđi gibi eğrisel nitelikte de bulunabilir. Bu nedenle trend analizi yaparken değışik trend kalıplarının araştırılması gerekmektedir. Uygulamalı araştırmalarda en çok kullanılan trend kalıpları aşağıdaki gibidir (Çetinel, 2005, s.101; Yamak, 2001, s.178; Orhunbilge, 1999, s.19-44):

Doğrusal: $Y = a + bx$

Parabol: $Y = a + bx + cx^2$

Kübik: $Y = a + bx + cx^2 + dx^3$

Hiperbol: $Y = \frac{1}{a + bx}$

Üstel: $Y = ab^x$ (doğrusal forma dönüştürüldüğünde ise $\log Y = \log a + x \log b$ veya $\ln Y = \ln a + x \ln b$ şeklinde yazılabilir.)

Modifiye üstel: $Y = k + ab^x$ (k: eğrinin asimptotu, üst veya alt limiti)

Gompertz eğrisi: $Y = ka^{b^x}$

Lojistik eğri: $\frac{1}{Y} = k + ab^x$

Trend bileşeninin belirlenmesinde üç yöntem bulunmaktadır. Bunlar, elle çizme yöntemi, hareketli ortalamalar yöntemi ve en küçük kareler yöntemidir. Elle çizme yönteminde, saptanmış olan noktalar arasından bir eğri/doğru çizilir. Bu yöntem hesaplamada kolaylık göstermekle birlikte, nesnel olmaktan uzaktır ve günümüzde kullanılmamaktadır (Gümüšoğlu ve Demir, 2003, s.508).

Trendin belirlenmesinde kullanılan yöntemlerden biri olan “Hareketli Ortalamalar (Moving Averages) Yöntemi” adından da anlaşılacağı üzere tahminlerde ortalamaların kullanılmasına dayanmaktadır. Geçmiş dönem verilerin (k adet) aritmetik ortalaması alınmakta ve elde edilen tahmini değer ya dönemin ortasındaki değer tahmini (Merkezi Hareketli Ortalamalar-Centered Moving Averages) ya da bir sonraki değer tahmini (Basit Hareketli Ortalamalar-Single Moving Averages) olarak kullanılmaktadır. Sırasıyla merkezi hareketli ortalamalar ve basit hareketli ortalamalar aşağıdaki şekilde hesaplanır (Orhunbilge, 1999, s.11-12):

$$y'_t = \frac{y_{t-(k-1)/2} + \dots + y_{t-1} + y_t + y_{t+1} + \dots + y_{t+(k-1)/2}}{k} \quad (2.1)^*$$

* k çift olduğunda elde edilen değer, dönem (yıl veya ay) ortasına düşeceği için birbirini takip eden iki tahmini değer ortalaması alınmaktadır.

$$y'_{t+1} = \frac{y_t + y_{t-1} + y_{t-2} + \dots + y_{t-(k+1)}}{k} \quad (2.2)$$

k : dönem uzunluğu – ortalamaya giren veri sayısı

y'_t : tahmini değer (incelenen k dönemin tam ortasındaki y_t değerinin tahmini)

y'_{t+1} : henüz gerçekleşmemiş y_{t+1} değerinin tahmini

Trend analizinde en çok kullanılan yöntem “En Küçük Kareler Yöntemi”dir. Bu yöntemde ölçüt uygulanacak trend eğrisi seçenekleri arasında noktaların kendisine uzaklıklarının kareleri toplamını en küçük kılacak eğrinin aranmasıdır. En küçük kareler yöntemiyle doğrusal veya doğrusal olmayan fonksiyonlar denendikten sonra bu fonksiyonların hatalarının kareleri toplamı veya hataların kareleri ortalamaları karşılaştırılır. En küçük değere sahip olan fonksiyon trend fonksiyonu olarak kullanılır. En küçük kareler yönteminin matematiksel ifadesi şu şekildedir (Gümüşoğlu ve Demir, 2003, s.512; Orhunbilge, 1999, s.19,55):

$$\sum_{t=1}^n e_t^2 = \sum (y_t - y'_t)^2 \Rightarrow \min \quad (2.3)$$

2.3.1.2. Mevsim Etkisinin Belirlenmesi

Zaman serileri analizinde trend bileşeni belirlendikten sonra bir diğer aşama mevsim etkisinin belirlenmesidir. Mevsimlik dalgalanmaların incelenmesinin üç önemli nedeni vardır. Bunlardan birincisi, kısa dönem dalgalanmalarının anlaşılması ve açıklanması; ikincisi, kısa dönem tahminlerinin yapılabilmesi; üçüncüsü ise, zaman serilerinden mevsim etkisinin arındırılmasıdır.

Mevsim etkisini ortaya çıkarmak için “Mevsim İndeksi (Seasonal Index)” adı verilen indeksler düzenlenmektedir. Mevsim indekslerinin oluşturulması için değişkenlere ait verilerin ay veya mevsim bazında olması gerekmektedir.

Mevsim indeksinin hesaplanmasında kullanılan en önemli yöntem ‘‘Hareketli Ortalamalara Oran Yöntemi’’dir. Yönteme aylık verilerde 12’şerli, mevsimlik verilerde 4’erli merkezi hareketli ortalamaların hesaplanmasıyla başlanmaktadır. Trend, konjonktür, mevsim ve arızı (rassal) faktörlerden oluşan zaman serisi verilerinde bu yolla trend ve konjonktür bileşenleri elde edilmektedir. Gözlem verilerinin hesaplanan hareketli ortalamalara oranlanmasıyla da mevsimlik ve arızı faktörlerin etkisi ortaya çıkarılmaktadır. Sembolik olarak bu işlem aşağıdaki şekilde gösterilebilir*.

$$\frac{y_t}{y'_t} \times 100 = \frac{T.K.M.R}{T.K} \times 100 = M.A \times 100 \quad (2.4)$$

12’şerli hareketli ortalamalar hesaplanırken kullanılan veri sayısı çift olduğu için birbirini takip eden iki yılın aynı aylarının değerlerinin yarısı ile diğer 11 ayın değerlerinin toplamı 12’ye bölünerek tam ortaya düşen ayın 12’şerli hareketli ortalaması bulunur:

$$y'_{t+6} = \frac{y_t / 2 + y_{t+1} + y_{t+2} + \dots + y_{t+12} / 2}{12} \quad (2.5)$$

Bu yolla tüm aylara ait 12’şerli hareketli ortalamalar elde edildikten sonra gözlem değerlerinden trend ve konjonktürün etkisi arındırılarak mevsim ve arızı faktörlerin etkisi ortaya çıkarılır. Her ay için bu işlem yapıldıktan sonra her ay için n-1 adet yüzdenin aritmetik ortalaması alınarak mevsim indeksi oluşturulur**. 12 aylık mevsim indeksinin toplamınının 1200 olması gerekir. Ancak her zaman bu toplama ulaşmak mümkün olmaz. Bu nedenle aşağıdaki işlemle düzeltme yapılmaktadır (Orhunbilge, 1999, s.64-66).

* Hatırlanacağı üzere, y_t : aylık gözlem değerleri, y'_t : 12’şerli hareketli ortalamalar, T: trend, K: konjonktür, M: mevsimsel, R: rassal (arızı) bileşenlerdir.

** 12’şerli hareketli ortalamalarda serinin başından ve sonundan 6’şar ay değeri kaybedildiği için 12 aylık yani 1 yıllık veri eksilmekte ve ay ortalamaları n-1 ile hesaplanmaktadır.

$$\text{Düzeltilmiş Mevsim İndeksi} = \frac{1200}{\sum_{t=1}^{12} MI} \quad (2.6)$$

$\sum_{t=1}^{12} MI$: elde edilen 12 aylık mevsim indeksleri toplamı

2.3.1.3. Konjonktür ve Arızı Faktörlerin Etkilerinin Belirlenmesi

Konjonktür hareketlerinin ölçülmesinde trend değerleri ve gözlenen değerler kullanılmaktadır. Aylık zaman serilerinde konjonktürün etkisi de arızı faktörlerin etkisiyle birlikte aynı şekilde aşağıdaki işlemler yapılarak saptanmaktadır. Araştırmamızda olduğu gibi aylık zaman serileri söz konusu olduğunda zaman serisinin değerleri:

$y_t = T.K.M.R$ olduğu için konjonktürün etkisi;

$$\frac{y_t}{y'_t.M} \times 100 = \frac{T.K.M.R}{T.M} \times 100 = K.R \times 100 \quad (2.7)$$

işlemiyle arızı faktörlerle birlikte saptanmaktadır.

Aylık değerler mevsim indeksiyle çarpılıp trend değerine bölünerek ay bazında konjonktür ve arızı faktörlerin bileşik etkisi ortaya çıkarılmaktadır. Arızı (rassal) faktörlerin daha önce de belirtildiği gibi önceden tahmin tahmin edilmesi mümkün değildir. Bu nedenle ancak konjonktürün etkisiyle birlikte belirlenebilmektedir (Orhunbilge, 1999, s.70-71).

2.3.2. Box-Jenkins Metodolojisi

Zaman serileri kesikli, doğrusal ve stokastik süreç içeriyorsa Box-Jenkins veya ARIMA modeli olarak adlandırılır. Anılan modeller doğrusal filtreleme modelleri olarak da bilinmektedir. Oto regresif (AR-Auto-Regressive), hareketli ortalama (MA-

Moving Average), AR ve MA modellerinin karışımı olan Otoregresif Hareketli Ortalama (ARMA-Auto Regressive Moving Average) modelleri en genel doğrusal durağan Box-Jenkins modelleridir. Durağan olmayıp fark alma işlemi sonucunda durağanlaştırılan serilere uygulanan modellere Birleştirilmiş Otoregresif Hareketli Ortalama (ARIMA-Auto Regressive Integrated Moving Average) modeli adı verilir. ARIMA modeli Box-Jenkins tekniği olarak adlandırılır. Box-Jenkins modellerinde amaç; zaman serisine en iyi uyan, en az parametre içeren doğrusal modelin belirlenmesidir (Topçuoğlu vd., 2005, s.90).

Box ve Jenkins'e göre zaman serileri durağan veya bazı dönüşümlerle durağan hale dönüştürülebilen kesikli stokastik bir süreç olarak düşünülebilir. Box-Jenkins yönteminin kullanılabilmesi için, bir zaman serisinin ya durağan olması, ya da farkı alındığında durağanlaşması gerekir. Box-Jenkins'in amacı, örneklem verilerini türettiği düşünülebilecek bir istatistik modelini belirlemek ve tahmin etmektir. Tahmin edilen bu model kestirim için kullanılacaksa, modelin özellikleri zaman içinde, özellikle de gelecek dönemlerde değişmemelidir. Yani durağan veri gereksiniminin basit nedeni, bu verilerden çıkarsanan herhangi bir modelin de durağan ya da kararlı olabilmesi, dolayısıyla da kestirim için geçerli bir temel sağlayabilmesi gerektiğidir (Gujarati, 2001, s.738).

Box-Jenkins metodolojisi zaman serileri analizinde, özellikle model belirleme, parametre tahminleme ve model uygunluğu bakımından önemli bir yaklaşımdır. Diğer zaman serisi analizi yöntemlerine göre, bu metodun en büyük avantajı doğruluğunun yüksek olmasından kaynaklanmaktadır. Genel modeli geçmiş değerlerin (AR bölümü) ve hataların (MA bölümü) doğrusal birleşiminden oluşmaktadır ve buna da ARMA modeli denilmektedir (Cortez ve Rocha, 2004, s.4).

2.3.2.1.Box-Jenkins Modelinin Kurulumu

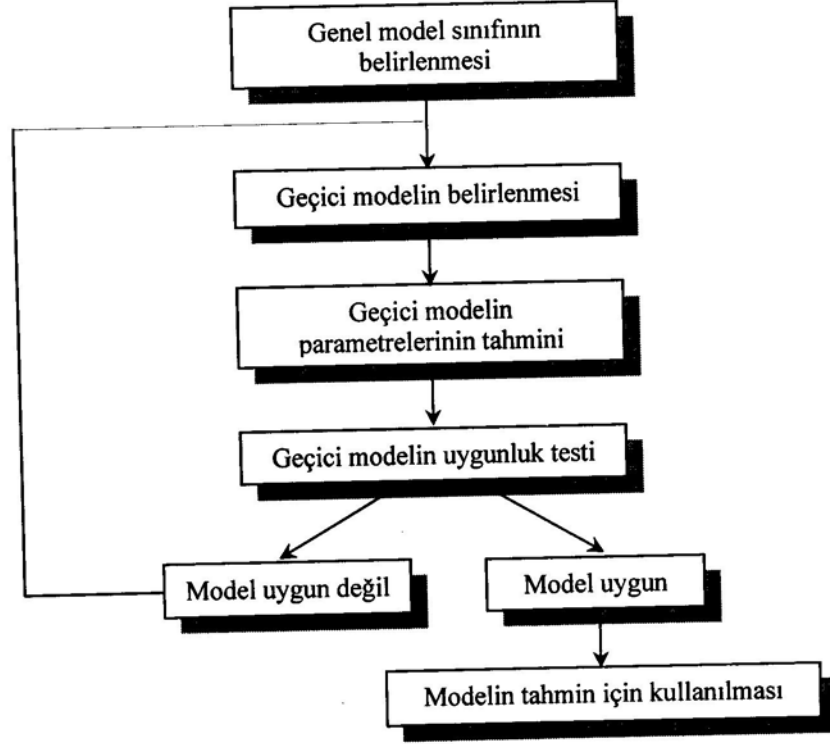
Zaman serisi model kurmada Box-Jenkins yaklaşımı, gerçekleşen verilere en uygun ARIMA veri üretme süreci bulma yöntemidir. 1970'li yıllarda George Box ve Gwilym Jenkins tarafından popüler hale getirilen ve zaman serileri analizleri ile

öngörümlemede uygulanan genel ARIMA modelleri ile onların isimleri eş anlamlı kullanılır olmuştur. Box ve Jenkins tek değişkenli zaman serisi ARIMA modellerinin anlaşılması ve kullanılması için gerekli bilgileri anlaşılır bir biçimde bir araya getirerek ortaya koymuşlardır (Makridakis vd., 1998, s.159)

Box-Jenkins yöntemi ile model kurma stratejisi “cimrilik” (Parsimony) prensibine dayanmaktadır. Bu prensip “verilerin özelliklerini yeterli olarak yansıtan bir model için mümkün olan en az parametrenin kullanılması” olarak ifade edilmektedir. İlave her parametre uyumu artırmasının yanında serbestlik derecesini düşürme maliyeti de dikkate alınmalıdır. Box ve Jenkins, tutumlu modellerin aşırı parametrelilerden daha iyi öngörüler ürettiklerini leri sürmüşler, ayrıca önerdikleri stratejinin bir optimallik kriterine dayanmadığını, pratik bir yöntem olduğunu belirtmişlerdir (Sevüktekin ve Nargeleçekenler, 2005, s.164).

Box-Jenkins yöntemi, tüm model kombinasyonları arasından uygun bir modeli belirlemek için dört basamaktan oluşan tekrarlamalı bir yaklaşım kullanmaktadır. Bu basamaklar sırasıyla; belirleme, parametre tahminleri, uygunluk testleri ve ileriye yönelik öngörü aşamalarıdır. Belirlenen model yeterli değilse, süreç orjinal modeli geliştirmek için oluşturulan bir model kullanılarak tekrarlanır (Hanke ve Reitsch, 1992, s.381). Bu aşamalar Şekil 18’de gösterilmiştir.

Birinci aşama model belirleme, p,d,q derecelerinin belirlenmesi ve böylece geçerli ARIMA modelinin belirlenmesini kapsar. P ve q değerlerinin belirlenmesinde otokorelasyon fonksiyonu ve kısmi otokorelasyon fonksiyonundan yararlanılmakta ayrıca korelogram sonuçları değerlendirilmektedir. Korelogram sonuçları; otokorelasyon fonksiyonu ve kısmi otokorelasyon fonksiyonunun gecikme uzunluklarına davranışlarının şekil üzerinde incelenmesidir. Genel olarak serilerin AR modeline uyumu kısmi otokorelasyon fonksiyonu ile, MA modeline uyumu ise otokorelasyon fonksiyonu ile belirlenmektedir. Box-Jenkins, verinin özelliklerini yeterli olarak yansıtan bir model için mümkün olan en az parametrenin kullanılmasını önermişlerdir (cimrilik “parsimony” prensibi geçerlidir) (Yılmaz ve Susam, 2005, s.137).



Şekil 18: Box-Jenkins Yöntemiyle Model Belirleme Aşamaları

Kaynak: Yaman K., Sarucan A., Atak M., Aktürk N. (2001); “Dinamik Çizelgeleme İçin Görüntü İşleme ve ARIMA Modelleri”, *Gazi Üniversitesi Müh. Mim. Fak. Dergisi*, Cilt 16, No 1, s.27.

Box-Jenkins model belirleme yaklaşımının ikinci aşaması, tahminlemede kullanılacak aday modellerin parametrelerinin hesaplanmasıdır. $AR(p)$, $MA(q)$ ve $ARMA(p,q)$ tipi modellerin parametrelerinin hesaplanması doğrusal olmayan en küçük kareler yöntemi veya maksimum olasılıklar yöntemi ile gerçekleştirilir. Paket program yazılımları aracılığıyla model parametreleri hesaplanabilmekte ve parametrelere ilişkin standart hatalar bulunabilmektedir (Shumway ve Stoffer, 2000, s.125-139).

Üçüncü aşamada; model belirlenip parametreler hesaplandıktan sonra, ayırt edici kontrol yapılır. Bu basamakta orijinal seri ile benzetim serilerinin hem grafikleri hem de otokorelasyon fonksiyonları karşılaştırıp, hata terimlerinin gerçekten ilişkisiz olup olmadığı test edilir. Böylece modelin tahmin başarısı test edilmektedir (Yılmaz ve Susam, 2005, s.137).

Box-Jenkins metodolojisi dahilinde, ARMA modeli belirlendikten, parametreleri hesaplandıktan ve modelin uygunluk analizleri gerçekleştirildikten sonraki aşama ilgili değişkenin örneklem içi ve ötesi değerlerinin model aracılığıyla tahminlenmesidir. Zaman serileri analizleri ile tahminlemede amaç değişkenlerin belli dönemlerde aldıkları veya alacakları gerçek değerlerine “yakın” tahminler elde edebilmektir. Bununla beraber, modellerin belirlenme ve hesaplanma aşamalarındaki teknik hatalara ve gerçek veri yaratım mekanizmasının rassal unsurlar içermesine bağlı olarak yapılan tahminler kaçınılmaz olarak farklı büyüklüklerde hata payı içerir (Giriffiths vd., 1992, s.670).

Model belirleme aşamasında, zaman serisinin otokovaryans, otokorelasyon ve kısmi otokorelasyon fonksiyonlarına başvurulur. Bu fonksiyonlar, sürecin AR(p), MA(q), ARMA(p,q) veya ARIMA(p,d,q) modellerinden hangisine uyduğunun tespitinde önemlidir (Box ve Jenkins, 1976, s.59).

2.3.2.1.1. Otokovaryans Fonksiyonu

Zaman serilerinin analizi sırasında otokovaryans fonksiyonu, örnek momentleri kullanılarak tahmin edilmekte ve iki rassal değişken arasındaki kovaryansın genel gösterimi

$$Kov(x, y) = E\{(x - E(x))(y - E(y))\} \quad (2.8)$$

olarak yapılmaktadır. Benzer şekilde stokastik sürecin y_t, y_{t+k} gibi iki elemanı için otokovaryans teorik olarak

$$\gamma_k = Kov(y_t, y_{t+k}) = E\{(y_t - E(y_t))(y_{t+k} - E(y_{t+k}))\} = E\{(y_t - \mu)(y_{t+k} - \mu)\} \quad (2.9)$$

şeklinde gösterilmekte ve γ_k , otokovaryans fonksiyonu olarak adlandırılmaktadır.

Stokastik sürecin özelliklerini saptamada önemli bir araç olarak kabul edilen OKVF için uygulamada $k=0,1,2,\dots$ için

$$\hat{\gamma}_k = \frac{1}{T} \sum_{t=1}^{T-k} (y_t - \bar{y})(y_{t+k} - \bar{y}) \quad (2.10)$$

formülü kullanılmakta ve \bar{y} , seri değerlerinin ortalamasını simgelemektedir. Örnek hacminin küçük olması durumunda ise paydada yer alan ve gözlem sayısını gösteren T ile T-k, serbestlik derecesi kaybını düzeltmek amacı ile yer değiştirmektedir. Bu aracın zayıf yönü ise otokovaryansların y sürecinin ölçme birimlerine tabi olmasıdır (Akgül, 2003b, s.10-11).

2.3.2.1.2. Otokorelasyon Fonksiyonu

Otokorelasyonlar, farklı zamanlardaki gözlemler arasındaki doğrusal ilişkiyi gösterir. Genel kavram olarak iki veri seri arasındaki korelasyonun ölçülmesi işlemi, zaman serisi otokorelasyonunun ölçülmesi için temel oluşturur. Bir seride herhangi bir k gecikme değeri için otokorelasyon değerinin hesaplanması işlemi, orjinal seri ile orjinal serinin k zaman değeri kadar taşınarak elde edilen yeni seri arasındaki korelasyon değerinin hesaplanmasıdır.

Gecikme değeri k'nın fonksiyonu olarak elde edilen otokorelasyon katsayıları (OKK), otokorelasyon fonksiyonu (OKF) olarak adlandırılmakta ve sürecin bir değerinin ilişkili olduğu daha önceki değerlerinin yayılımını ölçerek sürecin geçmiş dönemlerle doğrusal ilişkisinin gücünü göstermektedir. Gecikmesi k iken ρ_k ile gösterilen otokorelasyon katsayısı şöyle tanımlanır:

$$\rho_k = \frac{E[(y_t - \mu)(y_{t-k} - \mu)]}{\sqrt{E(y_t - \mu)^2 E(y_{t-k} - \mu)^2}} = \frac{Kov(y_t, y_{t-k})}{\sigma_{y_t} \sigma_{y_{t-k}}} \quad (2.11)$$

Durağan bir süreç için varyans, t-k ve t zamanları için eşit olduğundan, otokorelasyon katsayısı,

$$\rho_k = \frac{Kov(y_t, y_{t-k})}{\sigma_y^2} = \frac{\gamma_k}{\sigma_y^2} \quad (2.12)$$

şeklinde gösterilmektedir. Böylece, k gecikmesi için otokorelasyon,

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (2.13)$$

eşitliği ile ifade edilir. Formülde μ serinin teorik ortalamasını, γ_0 varyansını göstermektedir (Akgül, 2003b, s.11-22).

ρ_k , diğer korelasyon katsayıları gibi -1 ile 1 arasında değer almaktadır. Otokorelasyon değerlerinin gecikmelere göre çizimi yapılırsa elde edilen grafiğe “ana kütle korelogramı” denir. Uygulamada olasılıklı bir sürecin yalnızca örnek otokorelasyon fonksiyonu $\hat{\rho}_k$ hesaplanabilmektedir. Bunun için önce, k gecikmeli örnek kovaryansı $\hat{\gamma}_k$ ile örnek varyansının $\hat{\gamma}_0$ hesaplanması gerekir.

$$\hat{\gamma}_k = \frac{\sum (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{n} \quad (2.14)$$

$$\hat{\gamma}_0 = \frac{\sum (Y_t - \bar{Y})^2}{n} \quad (2.15)$$

Burada n örnek büyüklüğü, \bar{Y} örnek ortalamasıdır. Dolayısıyla k gecikmesindeki örnek otokorelasyon fonksiyonu şöyledir:

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} \quad (2.16)$$

Yukarıdaki eşitlik, örnek kovaryansının örnek varyansına oranıdır. $\hat{\rho}_k$ 'nın k'ya göre gösterimi ise örnek korelogramı olarak bilinir (Gujarati, 2003, s.715).

Otokovaryans ve otokorelasyonlarla ilgili olarak,

$$\gamma_k = \gamma_{-k} \quad \text{ve} \quad (2.17)$$

$$\rho_k = \rho_{-k} \quad (2.18)$$

eşitlikleri, otokovaryans ve otokorelasyonların simetrik olduğunu göstermektedir.

OKF zaman serisinin durağan olup olmadığının belirlenmesi amacı ile kullanılmaktadır. Gecikme uzunluğu k arttıkça, serinin örnek otokorelasyon fonksiyonu (ÖOKF) hızla azalıyor ve kısa gecikmelerde ekseni kesiyor ise serinin durağan olduğuna, serinin ÖOKF yavaşça azalıyor ve uzun gecikmelerde ekseni kesiyorsa serinin durağan olmadığına karar verilir (Akgül, 2003b, s.14-15).

2.3.2.1.3. Kısmi Otokorelasyon Fonksiyonu

Box-Jenkins yöntemindeki önemli kavramlardan biri de “kısmi otokorelasyon fonksiyonu”dur. Kısmi otokorelasyon; zaman değişkeninin etkisi sabit kalmak koşuluile bir değişkenin t dönemine ilişkin gözlem değerleri ile t-k dönemine ait gözlem değeri arasındaki ilişkinin ölçüsüdür (Özmen, 1986, s.41).

Otokorelasyon fonksiyonu, bir zaman serisindeki iki nokta arasındaki ilişkiyi araştırmakta yararlı bir ölçüdür. Ancak bazen bu iki nokta arasında ilişki araştırılırken bu noktalar arasında kalan gözlemlerin etkisinin arındırılması zaman serisi hakkında fazla bilgi edinmemizi sağlar. Bu şekilde hesaplanan ilişki iki nokta arasındaki kısmi otokorelasyondur ve ϕ_{kk} veya ρ_{kk} gibi ifadelerle gösterilirler.

Örnek kısmi otokorelasyon katsayısı aşağıdaki formüllerle hesaplanmaktadır:

$$\hat{\phi}_{kk} = \hat{\rho}_1 \quad \text{şayet } k=1 \text{ ise}$$

$$\hat{\phi}_{kk} = \frac{\hat{\rho}_k - \sum_{i=1}^{k-1} (\hat{\phi}_{k-1,i})(\hat{\rho}_{k-i})}{1 - \sum_{i=1}^{k-1} (\hat{\phi}_{k-1,i})(\hat{\rho}_i)} \quad (k = 2,3,\dots,ise) \quad (2.19)$$

$$\hat{\phi}_{ki} = \hat{\phi}_{k-1,i} - \hat{\phi}_{kk}\hat{\phi}_{k-1,k-i} \quad (i = 1,2,\dots,k-1) \quad (2.20)$$

Yukarıdaki formüllerde $\hat{\rho}_k$, k gecikme sonrası ÖOKK'ları, $\hat{\phi}_{ki}$, i'inci gecikmenin etkisi ortadan kaldırıldığında k gecikme için ÖKOK katsayılarını göstermektedir (Akgül, 2003b, s.25-26).

Kısmi otokorelasyon katsayılarının hesaplanmasındaki amaç, otoregresif (AR) ve otoregresif hareketli ortalama (ARMA) modellerinin tanımlanmasını (derecelerinin belirlenmesini) kolaylaştırmaktır (Orhunbilge, 1999, s.147).

Genel olarak OKF ve KOKF'ların seyrine bakılarak Box-Jenkins modelleri ile ilgili bilgi edinilmelidir ve bu bilgiler Tablo 3'de verilmektedir (Akgül, 2003b, s.120).

Tablo 3: AR, MA ve ARMA Modelleri için OKF ve KOKF'larının Seyri

MODEL	OKF	KOKF
MA(q)	q gecikme sonrası keser.	Üstel olarak veya sinüs dalgaları şeklinde azalır.
AR(p)	Üstel olarak veya sinüs dalgaları şeklinde azalır.	p gecikme sonrası keser.
ARMA(p,q)	Üstel olarak veya sinüs dalgaları şeklinde azalır. p gecikme sonrası keser.	Üstel olarak veya sinüs dalgaları şeklinde azalır. q gecikme sonrası keser.

Kaynak: Akgül I. (2003b); **Zaman Serilerinin Analizi ve ARIMA Modelleri**, İstanbul: Der Yayınları, s.120.

Box-Jenkins model kurma aşamalarını ve model belirlemede kullanılan katsayıları ve fonksiyonları gördükten sonra Box-Jenkins modellerinin özellikleri ve fonksiyonları aşağıda özetlenmektedir.

2.3.2.2.Durağan Zaman Serileri

Box-Jenkins modelleri sadece durağan veya durağanlaştırılmış serilerde kullanılabilirlerinden, uygun modellerin belirlenmesinde durağanlık, daha önce de vurgulandığı gibi büyük önem taşımaktadır. Box-Jenkins modellerinde dikkate alınan durağanlık, kovaryans durağanlığıdır. Kovaryans, zamana bağlı bir değişkenin farklı dönemlere ilişkin değerleri arasındaki karşılıklı ilişkinin bir ölçüsüdür (Makridakis vd., 1998, s.615).

Genel olarak ortalamasıyla varyansı zaman içinde değişmeyen ve iki dönem arasındaki kovaryansı, bu kovaryansın hesaplandığı değil de yalnızca iki dönem arasındaki uzaklığa bağlı olan olasılıklı (stokastik) bir süreç durağandır denilir. Belli bir dönem için gözlenen bir seriyi (Y_t) ortaya çıkaran stokastik sürecin durağan olması şartları aşağıdaki gibi ifade edilebilir;

$$\text{Ortalama} \quad E(Y_t) = \mu \quad (2.21)$$

$$\text{Varyans} \quad \text{var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2 \quad (2.22)$$

$$\text{Kovaryans} \quad \gamma_k = E[(Y_t - \mu)(Y_{t+k} - \mu)] \quad (2.23)$$

Burada γ_k , k gecikme değerindeki kovaryans, Y_t ile Y_{t+k} arasındaki, yani aralarında k dönem farkı olan iki Y arasındaki kovaryanstır. Eğer k=0 ise, γ_0 bulunur ki bu Y'nin varyansıdır ($=\sigma^2$); eğer k=1 ise, γ_1 , Y'nin ardışık iki değeri arasındaki kovaryanstır. Eğer bir zaman serisi yukarıdaki anlamda durağansa *durağan zaman serisi* adını alır (Gujarati, 2003, s.713-714).

En basit durağan zaman serisi “Beyaz Gürültü (white noise)” sürecidir. Beyaz gürültü süreci aşağıdaki gibi gösterilir:

$$Y_t = e_t \quad e_t \sim IID(0, \sigma^2) \quad (2.24)$$

Burada e_t sıfır ortalama ve bağımsız olarak dağılmış tesadüfi değişkenlerden oluşur. Seri, ortalaması 0, varyansı σ^2 olan bağımsız ve aynı dağılımlı rastgele değişkenlerden oluşmuştur. Ayrıca serinin ortalaması sıfır olduğu için serinin değerleri sıfır noktasını sık kesen ve o nokta etrafında eşit aralıklı yayılım gösteren sabit varyanslı bir durağan seriye örnek teşkil eder.

Bu bölümde, durağan zaman serilerine uygun olan; “Oto regresif AR(p)”, “Hareketli Ortalama MA(q)” ve “Karma Oto regresif Hareketli Ortalama ARMA(p,q)” modelleri hakkında bilgi verilmiştir.

2.3.2.2.1. AR(p) Modelleri

Bir serinin cari değerlerinin geçmiş dönemlerdeki değerleri ile arasındaki doğrusal bağlantı doğru belirlendiğinde, sistemin kalıntıları rassal değişken özelliği taşıyacaktır. Bunu sağlayacak süreç ise “otoregresif” süreç olarak adlandırılmaktadır. Bu bağlamda p’inci mertebeden oto regresif modelde; AR(p) zaman serisi değişkeninin içinde bulunduğu dönemdeki (cari) değeri, serinin p dönem geçmiş değerlerinin ağırlıklı toplamına artı rassal hata terimine bağlı olarak açıklanmaktadır. Genel olarak;

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + e_t \quad (2.25)$$

veya

$$y_t - \phi_1 y_{t-1} - \phi_2 y_{t-2} - \dots - \phi_p y_{t-p} = e_t \quad (2.26)$$

şeklinde ifade edilen süreç, p'inci mertebeden otoregresif süreç olarak adlandırılmaktadır. Bu denklemde;

y_t = Trend etkisi kaldırılmış seriyi,

p= Otoregresif sürecin mertebesini (serinin geçmiş değerlerinin sayısı),

ϕ = Bugünkü dönem ile geçmiş dönem değerleri arasındaki ilişkiyi gösteren ilişki katsayıları (ağırlıklar),

e_t = Model tarafından açıklanamayan hata terimini göstermektedir.

(2.25) ve (2.26) nolu denklemlerde e_t ile simgelenen hata terimi; sıfır ortalama ile sabit varyansa ve bağımsız, rassal sürece (white noise) sahiptir. Ayrıca, e_t 'ler, y_{t-p} 'lerden bağımsız olup herhangi bir dönemdeki hata ile arasında ilişki söz konusu değildir. δ ile simgelenen yığılım parametresine sahip AR(p) süreci;

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \delta + e_t \quad (2.27)$$

veya

$$y_t - \phi_1 y_{t-1} - \phi_2 y_{t-2} - \dots - \phi_p y_{t-p} + \delta = e_t \quad (2.28)$$

şeklinde ifade edilmektedir. δ , stokastik sürecin ortalaması ile ilgili sabittir ve “yığılım parametresi” olarak adlandırılmaktadır*. Modele sabitin katılması ise, serinin sıfırdan farklı olmasına izin verilmesi şeklinde ifade edilir. (2.27) ve (2.28) nolu denklemlerde $\delta, \sigma_e^2, \phi_1, \phi_2, \phi_3, \dots, \phi_p$ olacak şekilde (p+2) tane; (2.25) ve (2.26) nolu denklemlerde ise, $\sigma_e^2, \phi_1, \phi_2, \phi_3, \dots, \phi_p$ olacak şekilde (p+1) tane bilinmeyen parametre vardır ve bu değerler verilerden tahmin edilmektedirler. σ_e^2 , “white noise” süreci özelliği taşıyan e_t 'nin varyansını simgelemektedir.

* Zaman serisi ekonometrisi kapsamında yığılım, birim köke sahip olan yani durağan olmayan seriler için geçerlidir. Serinin durağan olması durumunda ise 0 ortalama veya sabit olarak adlandırılmaktadır.

AR(p) süreci, $BY_t = Y_{t-1}$, $B^2Y_t = Y_{t-2}$ olarak işleyen geri kaydırma işlemcisi: B kullanıldığında ($\delta = 0$ varsayımı ile)

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)y_t = e_t \quad (2.29)$$

veya kısaca

$$\phi(B)y_t = e_t \quad (2.30)$$

olarak gösterilebilir. p'inci mertebeden AR işlemcisi olan $\phi(B)$ 'nin açılımı ise,

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (2.31)$$

olarak yapılmaktadır (Akgül, 2003b, s. 36-37).

2.3.2.2.2. MA(q) Modelleri

Hareketli ortalama MA(q) süreci bir zaman serisinin t dönemdeki değerini, rastgele bir değişken olan kalıntı (hata) payının cari ve geçmiş dönem değerlerinin ağırlıklı ortalaması ile ifade eden bir süreçtir ve aşağıdaki gibi gösterilir:

$$Y_{t+1} = e_{t+1} + \theta e_t \quad (2.32)$$

Denklem (2.32)'deki istatistik model bir hareketli ortalama sürecidir. Genelde bir hareketli ortalama süreci, 1,2 veya daha fazla dönem geriye doğru rastgele kalıntıların e_t ağırlıklı bir ortalaması olarak ekonomik değişken y_t 'ye ait zaman serisi gözlemlerini gösterir.

Genel bir MA(q) süreci için istatistiksel model aşağıdaki gibidir:

$$y_t = \mu + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (2.33)$$

Burada korelasyonsuz rastgele kalıntılar e_t ortalaması sıfır ve sabit bir varyansa sahiptir, θ_i ($i=1,2,\dots,q$) bilinmeyen parametrelerdir. Denklem (2.33)'e dikkat edilirse AR(p) modelinden farklı olarak “yığılım” parametresi, δ yerine μ ile gösterilmiştir. Bu tanımlamaya göre MA(q) sürecinin ortalaması aşağıdaki gibi gösterilir:

$$E(y_t) = \mu \quad (2.34)$$

Varyansı ise denklem (2.35)'deki gibi yazılır:

$$\begin{aligned} \text{var}(y_t) &= \gamma_0 \\ &= E[(y_t - \mu)^2] \\ &= E[e_t^2 + \theta_1^2 e_{t-1}^2 + \dots + \theta_q^2 e_{t-q}^2 + 2\theta_1\theta_2 e_{t-1}e_{t-2} + \dots] \\ &= \sigma_e^2 + \theta_1^2 \sigma_e^2 + \dots + \theta_q^2 \sigma_e^2 \\ &= \sigma_e^2 (1 + \theta_1^2 + \dots + \theta_q^2) \end{aligned} \quad (2.35)$$

Bütün çarpım terimlerinin beklenen değerleri sıfırdır. Çünkü rastgele kalıntılar e_t bağımsız ve korelasyonsuz olarak varsayılmaktadır (Giriffiths vd., 1992, s.690).

Denklem (2.33) geri kaydırma işlemcisi: B kullanıldığında ise, $\mu = 0$ olması halinde

$$y_t = (1 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3 - \dots - \theta_q B^q) e_t \quad (2.36)$$

veya kısaca

$$y_t = \theta(B) e_t \quad (2.37)$$

olarak ifade edilmektedir. MA(q) işlemcisi olarak adlandırılan $\theta(B)$, B işlemcisinin polinomial fonksiyonudur ve açılımı

$$\theta(B) = (\theta_0 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3 - \dots - \theta_q B^q) \quad (2.38)$$

olarak yapılmaktadır. θ_0 , genellikle $\theta_0=1$ olarak alınmaktadır. Box ve Jenkins MA sürecini, “ y_t çıktısı, e_t girdi iken $\theta(B)$ transfer fonksiyonunun doğrusal filtreden geçmesi ile elde edilmektedir” ifadesi ile tanımlamaktadır (Akgül, 2003b, s.68).

2.3.2.2.3. ARMA(p,q) Modelleri

Zaman serisi modellerinde esneklik sağlamak için en az sayıda parametre kullanma ilkesini gerçekleştirmek amacıyla bazı hallerde modele hem otoregresif hem de hareketli ortalama parametrelerinin alınması birçok fayda sağlamaktadır. Bu düşünce ARMA(p,q) modelini ortaya çıkarmıştır (Kayım, 1985, s.72).

ARMA modelleri en genel durağan stokastik süreç modelleri olup, geçmiş gözlemlerin ve geçmiş hata terimlerinin doğrusal bir fonksiyonudur. ARMA(p,q) modelleri genel olarak aşağıdaki gibi gösterilir:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \delta + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.39)$$

Yığılım parametresinin olmaması durumunda, $\delta = 0$ varsayımıyla Denklem (2.39) şu şekilde yazılır:

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.40)$$

Denklem (2.39)'da, $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ geçmiş gözlem değerlerini, $\phi_1, \phi_2, \dots, \phi_p$ geçmiş gözlem değerleri için katsayıları, δ yığılım parametresini,

$e_t, e_{t-1}, e_{t-2}, \dots, e_{t-q}$ hata terimlerini ve $\theta_1, \theta_2, \dots, \theta_q$ hata terimleri ile ilgili katsayıları temsil etmektedir (Hamzaçebi ve Kutay, 2004, s.228).

Süreç, geri kaydırma işlemcisi: B ile ($\delta = 0$ hali için)

$$(1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3 - \dots - \phi_p B^p) y_t = (1 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3 - \dots - \theta_q B^q) e_t \quad (2.41)$$

ve kısaca

$$\phi(B) y_t = \theta(B) e_t \quad (2.42)$$

olarak gösterilebilir. ARMA(p,q) sürecinde (2.39) nolu denklemde $\delta \neq 0$ varsayımı ile [p+q+2] bilinmeyen söz konusu olup verilerden tahmin edilmektedirler. ARMA modellerinde, p ve q mertebeleri ile ilgili olarak, $p \leq 2$ ve $q \leq 2$ olmasının seriyi yeteri kadar açıklayacağı ifade edilmektedir, ayrıca p ve q mertebelerinin aynı olması da gerekli değildir (Akgül, 2003b, s.87).

2.3.2.3. Durağan Olmayan Zaman Serileri

Zaman serisinin durağan olduğu koşullarda, yani sürecin ortalamasının varyansının ve kovaryansının zamana bağlı değişmediği durumlarda ARMA(p,q) veya ARMA(p,q)'nın özel hali olan AR(p), MA(q) modellerinden uygun olanı kullanılabilir. Ancak, gerçekte zaman serilerinin ortalama ve varyansında zamana bağlı bir değişim olmaktadır. Bu durum, durağan olmayan durum olarak adlandırılır. Bu tip zaman serileri durağan hale dönüştürüldüğünde ARMA(p,q), modelleri tahmin için kullanılabilir. Bu yüzden, durağan olmayan seriler durağan hale getirilir, böylece bu tip serilerin kullanılması daha doğru sonuçlara ulaşmayı mümkün kılar. Zaman serisini durağanlaştırmak fark alınarak yapılmaktadır. Zaman serisinin doğrusal bir trendi var ise, birinci fark serisi durağan olmaktadır. Eğer zaman serisinin eğrisel bir trendi varsa, farkların tekrar farkı alınarak ikinci farklar serisi durağanlaştırılmakta, bu durumda model ARIMA(p,d,q) olarak ifade edilmektedir.

Burada d; serinin durağanlaştırma, fark alma parametresidir (Topçuoğlu vd., 2005, s. 91-92).

2.3.2.3.1. ARIMA(p,d,q) Modelleri

Durağan olmayıp farkı alınarak durağan hale getirilmiş serilere uygulanan modellere “durağan olmayan doğrusal stokastik modeller” veya “kısaca entegre modeller” denir. Bu entegre modeller belirli sayıda farkı alınmış serilere uygulanan AR ve MA modellerinin birleşimidir. Eğer AR modelinin derecesi p, MA modelin derecesi q ve serinin de d kez farkı alınmışsa bu modele (p,d,q) dereceden “Otoregresif Entegre Hareketli Ortalama” modeli denir ve ARIMA(p,d,q) şeklinde gösterilir (Box ve Jenkins, 1976, s. 90).

ARIMA(p,d,q) şeklinde gösterilen otoregresif bütüleşik (entegre) hareketli ortalama modelinin genel ifadesi,

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.43)$$

eşitliği ile verilir.

Denklem (2.43)'deki model, ARMA(p,q) modelindeki y_t teriminin yerine w_t teriminin yazılmış halidir. Bu durum, durağan olmayan y_t sürecinin d derece farkı alınarak durağanlaştırılması sonucu w_t sürecinin elde edilmesinden kaynaklanmaktadır.

$$w_t = \Delta^d y_t \quad (2.44)$$

eşitliğinde,

w_t = fark alma sonucu oluşan seriyi

Δ = fark alma işlemcisini

d = fark alma derecesini

göstermektedir. birinci farklar serisi durağan ise,

$$\Delta y_t = w_t = y_t - y_{t-1} = (1 - B)y_t \quad (2.45)$$

eşitliği yazılabilir. Benzer şekilde serinin durağan hale gelmesi için d defa fark alınmışsa,

$$\Delta^d y_t = w_t = (1 - B)^d y_t \quad (2.46)$$

ifadesi yazılabilir. ARIMA(p,d,q) modelinin orjinal veri cinsinden genel gösterimi, $\delta \neq 0$ varsayımı ile

$$\Delta^d y_t = \delta + \gamma_1 \Delta^d y_{t-1} + \gamma_2 \Delta^d y_{t-2} + \dots + \gamma_p \Delta^d y_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (2.47)$$

olacak şekilde yapılmaktadır. İncelenen y_t serisinin durağan olmaması nedeni ile yapılan (2.44) nolu dönüşümle serinin durağanlığı sağlanmakta ve ardından (2.43) nolu denklemlerle gösterilmektedir.

Bütünleşik ARMA modelleri olarak adlandırılan ARIMA modelleri, durağan olmayan serilerin durağan olana kadar kaç defa farklarının alındığını gösteren d derecesine, AR terim sayısı p ve MA terim sayısı q'nun ilave edilmesi ile belirlenmektedir (Akgül, 2003b, s.105-108).

2.4. YAPAY SİNİR AĞLARININ ÖNGÖRÜMLEMEDE KULLANIMI

Daha önceki bölümlerde de belirtildiği gibi YSA'nın başarı ile kullanıldığı alanlardan biri de öngörüleme (geleceği tahminleme) problemleridir. Yapay sinir ağlarının geleceği öngörüleme kullanılmasına yönelik literatürde çok sayıda çalışma vardır. Bir çok farklı disiplinden araştırmacılar, bir öngörüleme aracı olarak YSA'nın kullanılabilirliğini araştırmışlardır. Yapılan çalışmaların bir çoğunda, geleneksel metotlar ile YSA teknikleri karşılaştırılmış ve hangi yöntemin daha iyi sonuç verdiği

araştırılmıştır. YSA'nın bir öngörümleme aracı olarak kullanılmasına yönelik literatür taraması, yapılan çalışmaların uygulama alanları ve amacı hakkında bir bilgi verecektir.

Chang ve Hwang (1998, s.35-43); araştırmalarında Fransa'daki şampanya satış rakamlarını yapay sinir ağları, üstel düzleştirme yöntemi ve Box-Jenkins modeli olmak üzere üç zaman serisi analizi yöntemi ile öngörümlemeyi amaçlamışlardır. Kurmuş oldukları yapay sinir ağı modelinde deneme-yanılma yöntemi ile katman sayılarını ve her bir katmandaki nöron sayısını belirlemişlerdir. Daha sonra seçtikleri ARIMA modeli ve üstel düzleştirme yöntemi ile yapay sinir ağı modelini "Ortalama Hata Kareleri" (MSE) performans ölçütünü kullanarak karşılaştırmışlardır. Araştırmalarının sonucunda az bir farkla Box-Jenkins modelinin daha uygun olduğuna karar vermişlerdir.

Hobbs vd. (1998, s.71-84); yapmış oldukları araştırmada üç katmanlı ileri beslemeli bir yapay sinir ağı modeli geliştirerek, mülakat sonucu verilerini elde ettikleri 19 tesisin kısa dönemli elektrik ihtiyacını öngörümlemeyi amaçlamışlardır. Yapay sinir ağı modelinde kullanılan nöron sayısını karar vermede deneme-yanılma yöntemini tercih etmişler ve performans ölçütü olarak MAPE'yi kullanmışlardır. Araştırmanın sonucunda, yapay sinir ağlarının tesislerin mevcutta kullandıkları diğer yöntemlere göre daha doğru sonuçlar ürettiği kanısına varmışlardır.

Al-Saba ve El-Amin (1999, s.189-197), yaptıkları çalışmada yapay sinir ağlarının uzun dönem talep öngörümlemelerinde mümkün olduğunca az veri kullanarak gerçeğe en yakın sonuçları verebileceğini göstermeyi amaçlamışlardır. Suudi Arabistan için 1997-2006 tarihleri arasında en yüksek yük istemini öngörümlemeye çalışmışlardır. Al-Saba ve El-Amin de, kurmuş oldukları üç katmanlı ileri beslemeli yapay sinir ağı modelinde geri yayılım algoritmasını kullanmayı tercih etmişler ve buldukları sonuçları Box-Jenkins modelleri ile karşılaştırmışlardır. Araştırmalarında, bir tesisin elektrik talebini veri olarak kullanmışlar ve çıktı nöron sayısını belirlemede iteratif yaklaşımı tercih edip çıktı katmanında tek nöron belirlemişlerdir. Kurmuş oldukları yapay sinir ağı modelinin tahmin sonuçlarını Box-Jenkins modelleri ile karşılaştırma sırasında performans kriteri olarak sadece hata yüzdelerini kullanmışlardır. Araştırmanın

sonucunda, yapay sinir ağlarının Box-Jenkins modellerinden daha üstün olduğunu ortaya koymuşlardır.

Hwang ve Ang (2001, s.319-333); yapmış oldukları çalışmada, yapay sinir ağlarını bir öngörümleme aracı olarak kullanmışlar ve kurmuş oldukları YSA modelinin sonuçlarını ARMA(p,q) modeli ile “Ortalama Mutlak Yüzde Hata” (MAPE) ve “Ortalama Hata Karelerinin Karekökü” (RMSE) performans ölçütlerini kullanarak karşılaştırmışlardır. Kurmuş oldukları iki katmanlı ileri beslemeli yapay sinir ağı modelinde 12 adet girdi nöronu ve 1 adet çıktı nöronu kullanmışlar ve öğrenme algoritması olarak geri yayılım algoritmasını seçmişlerdir. Araştırmalarının amacı, iki katmanlı ileri beslemeli bir yapay sinir ağı modelinin, çok katmanlı ileri beslemeli yapay sinir ağı modellerine ve Box-Jenkins modeline göre daha üstün olabileceğini ortaya koymaktır. Bulmuş oldukları sonuçlar da bu amaçlarına ulaşmış olduklarını göstermektedir.

Zhang vd. (2001, s.381-396); diğer çalışmalardan farklı olarak araştırmalarında, yapay sinir ağı modelinde dikkat edilmesi gereken faktörler, girdi katmanındaki ve gizli katmandaki nöron sayısı, örneklem grubunun büyüklüğü, üzerinde yoğunlaşmışlardır. Bu faktörlerin herhangi bir yapay sinir ağı modeli ile öngörümlemede ne kadar önemli olduklarını ortaya koymak için simüle edilmiş bilgisayar deneylerinden yararlanmışlardır. Sonuç olarak, kurmuş oldukları değişik yapay sinir ağı modellerinin MSE ve MAPE performans ölçüt sonuçlarına bakarak, girdi katmanındaki nöron sayısının, gizli katmandaki nöron sayısından ve örnek grubunun büyüklüğünden daha fazla bir öneme sahip olduğunu ortaya koymuşlardır.

Gareta vd. (2006, s.1770-1778), geliştirmiş oldukları çok katmanlı ileri beslemeli yapay sinir ağı modelinde geri yayılım algoritmasını kullanarak elektrik fiyatlarını öngörümlemeyi amaçlamışlardır. Araştırmalarında, yapay sinir ağının katman sayısını ve katmanlardaki nöron sayısını belirlemede deneme-yanılma yöntemini benimsemişlerdir. Sonuçların geçerliliğini ölçmek için ise hata yüzdelerini ölçüt olarak kullanmışlardır. Araştırmalarının sonucunda, yapay sinir ağlarının kısa dönemli elektrik fiyatlarının öngörümlemesinde başarılı bir yöntem olduğunu ortaya koymuşlar ve

Avrupa’da veya dünyada birçok tesisin elektrik fiyatlarının önceden öngörümleyerek tasarrufta bulunabileceğini önermişlerdir.

Taiwan’da doktora öğrencisi olan Chen (2006, s.183-190); yapmış olduğu araştırmada, geri yayılım algoritmasını kullanarak kurmuş olduğu üç katmanlı ileri beslemeli yapay sinir ağı modelinde girdi katmanında iki, çıktı katmanında bir ve gizli katmanda ise beş nöron bulunmaktadır. Araştırmasının amacı, geri yayılım algoritmasını kullanan ileri beslemeli yapay sinir ağı modelinin, Taiwan’ın makine endüstrisindeki üretim değerlerini öngörümleyerek mevsimsel zaman serilerinde SARIMA modellerine göre geçerliliğini ortaya koymaktır. En uygun SARIMA modelini belirlemek için Akaike Bilgi Kriterini (Akaike Information Criterion (AIC)) kullanmıştır ve yapay sinir ağı modeliyle karşılaştırmada ise RMSE performans ölçütünü benimsemiştir. Araştırmasının sonucunda yapay sinir ağının daha üstün sonuçlar verdiğini ortaya koymuştur.

Türkiye’de yapılan çalışmalara baktığımızda ise Eğrioğlu ve Aladağ’ın (<http://www.ekonometridernegi.org/bildiriler/o15s3.pdf>, s. 1-6) yapmış oldukları araştırmada yapay sinir ağları ve otoregresif hareketli ortalamalar modelinin birleştirildiği bir melez yaklaşımla Ankara hava kirliliği öngörümlemesinde bulunmuşlardır. Yapay sinir ağı modelinin kurumunda deneme-yanılma yöntemini kullanmışlardır ve hata kareler ortalamasına bakarak en iyi sonuç veren melez yaklaşımını belirlemişlerdir.

Aladağ ve Eğrioğlu’nun (2005, s.397-406) yapmış olduğu bir diğer araştırmada ise, yine Ankara hava kirliliği aylık verileri yapay sinir ağları ve Box-Jenkins yöntemleri ile öngörülenmiş ve belli mimariler için yapay sinir ağlarının daha iyi sonuçlar verdiği görülmüştür. Bu araştırmalarında, yapay sinir ağına girecek verinin durağanlaştırılmasına gerek olup olmadığı, aktivasyon fonksiyonunun çıktı katmanında doğrusal mı yoksa eğrisel mi olması gerektiği ve girdi birimlerinin çıktıya bağlanmasına gerek olup olmadığı sorularına cevap aramışlardır.

Hamzaçebi ve Kutay (2005, s.575-580) kullanmış oldukları yapay sinir ağı modelini, Hata Kareleri Toplamı ve Mutlak Hata Toplamı performans ölçütlerine göre diğer zaman serisi öngörümleme teknikleri olan Box-Jenkins modeli ve parçalı adaptif öngörümleme teknikleri ile karşılaştırmışlardır. Araştırmalarında kurmuş oldukları yapay sinir ağı modeli ile hem iteratif hem de direkt yaklaşıma göre öngörümlemede bulunmuşlar ve direkt yaklaşımın daha iyi sonuçlar verdiğini ortaya koymuşlardır. Aynı zamanda yapmış oldukları karşılaştırma sonucunda, yapay sinir ağlarının diğer öngörümleme tekniklerine göre daha iyi sonuçlar verdiğini göstermişlerdir.

Görüldüğü üzere, dünyada yapılmış yapay sinir ağları ile öngörümleme ile ilgili bir çok araştırmada genellikle diğer zaman serisi öngörümleme teknikleri ile karşılaştırmalar yapılmıştır. Birçoğunda yapay sinir ağları daha iyi sonuçlar vermiştir. Bir sonraki bölümde biz de elde etmiş olduğumuz verileri, hem yapay sinir ağları ile hem de bu bölümde bahsedilen Trendin Bileşenlerine Ayrılması ve Box-Jenkins modelleri ile öngörümlemeye çalışacağız ve sonuçları birbirleriyle karşılaştırıp hangi yöntemin verilerim için daha üstün olduğunu ortaya koyacağız.

ÜÇÜNCÜ BÖLÜM

PETKİM'DE SATIŞ ÖNGÖRÜMLEMESİNE İLİŞKİN UYGULAMA

3.1.PETROKİMYA SANAYİ VE PETKİM HAKKINDA GENEL BİLGİ

Yirminci yüzyılın ikinci yarısından itibaren gelişmeye başlayan petrokimya sanayi, geniş ürün yelpazesi ve uygulama alanı sayesinde son elli yılda modern ekonominin temel taşlarından biri haline gelmiştir. Tüketicilerin kullandığı binlerce petrokimya ürünü, insan hayatının vazgeçilmez bir parçası olmuş ve bu sanayideki gelişmeler yaşam standardını önemli oranda yükseltmiştir.

Petrokimya sanayi, nafta, LPG, gas oil gibi petrol ürünleri veya doğal gaza dayalı temel girdileri kullanarak plastikler, lastik ve elyaf hammaddeleri ve diğer organik ara malları üreten ve ambalaj, elektronik, otomotiv, inşaat, tekstil ve tarım gibi birçok sektöre girdi sağlayan bir sanayi koludur.

Petrokimya sanayinin günümüzde sahip olduğu 500 milyar \$'lık pazar değeri, dünya kimya pazarının yaklaşık % 30'nu, dünya toplam ticaret hacminin ise yaklaşık % 8'ni oluşturmaktadır. Petrokimya sanayinde, dünyadaki genel ekonomik gelişmeler paralelinde arz-talep dengelerine bağlı olarak fiyatlar ve karlılık açısından dönemsel değişimler yaşanmaktadır. Bu değişimler 3-4 yılı yüksek karlı, onu takip eden 4-5 yılı düşük karlı veya karsız dönemler şeklinde görülmektedir .

Petrokimya sanayinde, son yıllarda önemli yapısal değişiklikler olmaktadır. Şirketler rekabet güçlerini artırmak ve karlılıklarını yükseltmek amacıyla, tek başlarına veya başka şirketlerle birleşerek faaliyet alanlarını daraltmaya, genişletmeye veya değiştirmeye yönelmektedirler.

Petrokimya sanayi, dünya ölçeğinde rekabete açık bir sektör olup hammadde, pazar ve teknolojik avantajlar bu rekabette rol oynayan unsurların başında gelmektedir.

Yeni yatırımlar için ucuz hammadde kaynakları olan, pazarı yeterince büyük ve hızla büyüyen bölgeler tercih edilmektedir. Önümüzdeki yıllarda yeni yatırımların büyük bölümü Orta Doğu'da ve Asya'da (özellikle Çin'de) gerçekleştirilecektir.

Petrokimya sanayi Türkiye'ye 1960'lı yıllarda gelmiş ve kısa sürede hızlı bir gelişim göstermiştir. 1965 yılında, ülkede petrokimya sanayinin kurulması ve geliştirilmesi amacıyla Petkim kurulmuştur.

Türkiye'de petrokimya sanayinin kurulması fikri I. Beş Yıllık Plan döneminin başlangıcı olan 1962 yılında benimsenmiş, yapılan etüd ve araştırmalar sonucunda Petkim Petrokimya A.Ş. 03.04.1965 tarihinde TPAO öncülüğünde kurulmuştur.

Petkim, Yarımca Kompleksinde 1970 yılında, önce 5 fabrikayı işletmeye açmış daha sonraları da diğer fabrikalar bunu takip etmiştir. Hızla artan talebi karşılamak için, fabrikalarda % 100'lere varan kapasite artırımlarına girişilmişse de karşılanamayan talep karşısında, III. Beş Yıllık Kalkınma Planı döneminde Petkim'in ikinci kompleksinin Aliğa'da kurulması kararlaştırılmıştır. Aliğa Kompleksi projelendirildiği yıllardaki mevcut en ileri teknolojiler ve optimum kapasitelere sahip olarak kurulmuş ve 1985 yılında işletmeye alınmıştır.

Petkim, temel petrokimyasallarda tek ara ürünler ve termoplastiklerde ise en büyük üretici olarak, Türkiye petrokimya sanayinin lider kuruluşudur. Üretimin ilk yıllarında büyük bir ihraç potansiyeli öngörülmüşken 1985 yılından itibaren yurtiçi talebindeki hızlı artış nedeniyle Petkim'in ihracatı giderek düşme göstermiştir. Türkiye'de petrokimyasal ürünlerin, özellikle termoplastiklerin talep artış hızı Dünya ortalamasının en az iki katıdır. Ancak buna rağmen ülkemizde kişi başına termoplastik tüketimi gelişmiş ülkelerin çok gerisinde kalmaktadır. Plastik talebindeki artış hızının GSMH artış hızına oranı Dünya ortalamasının çok üzerindedir. Plastik talep artış hızı genel ekonomik büyümenin çok üzerindedir. Türkiye'de petrokimyasal ürünlere olan talep, gelişmiş ülkeler ve dünya ortalamalarının üzerinde bir hızla artmaktadır.

Türkiye'de petrokimyasal ürünler arzı ise taleple aynı hızda artmamaktadır. Petkim bu hızlı talep artışını kısmen de olsa karşılamak üzere çeşitli fabrikalarında önemli kapasite artışları sağlayacak genişleme ve modernizasyon yatırımları yapmaktadır. Bu yatırımlara rağmen hızla artan yurtiçi talep karşısında yurtiçi arz son derece yetersiz kalmakta, yurtiçi üretimin pazar payı hızla azalmakta ve Türkiye'nin petrokimyasal ürünler ithalatı da hızla artmaktadır. Petkim, 2003 yılında yurtiçi petrokimyasallar talebinin ancak % 30'unu karşılayabilmiştir. Bu durum, Türkiye petrokimya sektörünün rekabet gücünü olumsuz etkilemekte ayrıca, sektörün çok yüksek olan katma değerinin yurtdışında kalmasına neden olmaktadır.

Petkim, 28.5.1986 gün, 3291 sayılı kanunun 13. maddesindeki hükme istinaden 11.9.1987 gün ve 87/12184 sayılı Bakanlar Kurulu Kararı ile özelleştirme kapsamına alınmıştır. Halka açık bir şirket olan Petkim, özelleştirme ile ilgili çalışmalarını sürdürmekte olup ekonomik ömrünü tamamlayan Yarımca Kompleksi'nin TÜPRAŞ Türkiye Petrol Rafinerileri A.Ş.'ne satışı 2001 yılında gerçekleşmiştir.

Ülkemizin en gözde şirketlerinden olan Petkim, 50'yi aşan petrokimyasal ürün yelpazesiyile bugün sanayimizin vazgeçilmez bir hammadde üreticisi durumundadır. Petkim'in ürettiği hammaddelerden plastikler ve sentetik kauçuklar; inşaat, tarım, otomotiv, elektrik, elektronik, ambalaj sektörlerinin önemli girdileridir. Sentetik elyaflar ise tekstil sektöründe kullanılmaktadır. Ayrıca, ilaç, boya, deterjan, kozmetik gibi birçok sanayi için de girdi üretilmektedir.

Türkiye petrokimyasal ürünler pazarı henüz doygunluğa erişmemiştir. Türkiye'de kişi başına termoplastik tüketimi 29 kg civarında iken, bu oran gelişmiş ülkelerde 75-100 kg arasında değişmektedir. Ülkemizin kalkınma çabaları, petrokimyasal ürünlerin tüketildiği çeşitli sektörlerdeki mevcut ve beklenen gelişmeler, hızlı nüfus artışı vb. hususlar da gözönüne alınırsa Türkiye petrokimya sanayinin büyük bir gelişme potansiyeline sahip olduğu görülmektedir. Hammadde zengini büyük üreticilere yakın bir bölgede bulunulmasının dezavantajına rağmen, Türkiye'de petrokimyasal ürünlerde ulaşılan iç pazar büyüklüğü, ülkemizde dünya ölçeğinde yeni tesislerin kurulmasına imkan verecek düzeydedir (www.petkim.com.tr).

3.2. PETKİM'DE SATIŞ VE SATIŞ ÖNGÖRÜMLEMESİNİN ÖNEMİ

Petkim'in sitesinden elde edilen ve orda çalışan satış sorumlusuyla yapılan görüşmeler sonucunda Petkim'de üç çeşit satış şekli olduğunu görmekteyiz. Bunlar; mutad satışlar, istisnai satışlar ve ihaleli satışlardır. Mutad satışlar, kendi içerisinde cari ve kontratlı satışlar, istisnai satışlar ise özel anlaşmalı ve bağlantılı satışlar olmak üzere ikiye ayrılmaktadır. Mutad satışlar; standart ürünlerin, standart dışı ürünlerin ve yan ürünlerin YTL veya Döviz cinsinden belirlenmiş olan fiyat tarifesi üzerinden satışlarını kapsamaktadır. İstisnai satışlar ise; özellikleri müşteri tarafından belirlenmiş bir ürünün tek bir firmaya, şartları şirket ve firma arasında kararlaştırılan bir anlaşma ile "Özel Anlaşmalı Satış"ı, şirket tarafından üretilmekte olan bir ürünün şirketin belirlemiş olduğu esas ve şartlar dahilinde belli bir temin programı çerçevesinde kısmen veya tamamen bir firmaya veya firmalara "Bağlantılı Satış"ı veya kiralamayı, hava, su, buhar, azot, oksijen satışlarını ve fason imalatı kapsamaktadır. İhale suretiyle yapılan satışlar; ürün ve malzemelerin, belirlenen usul ve esaslar çerçevesinde ihaleye çıkılmak suretiyle satışlarını kapsar. Gerekli görüldüğü hallerde Genel Müdür'ün onayı ile mutad ve istisnai satışlar da ihale yoluyla yapılabilmektedir.

Bu üç satış şeklinin yanı sıra direkt olarak yurtdışına yapılan satışlar da mevcuttur. Doğrudan ihracat satışları spot bazda, dönemsel kontrat bazında ve son olarak fason işlemeye ilişkin olarak yapılabilmektedir. Spot bazda ihracat, tespit edilen haftalık fiyatlar baz alınarak sabit veya yüzer fiyatla yapılan satışlardır. Kontrat bazında ihracat ise; üç veya daha uzun süreyi kapsayan, sabit veya formüle dayalı yüzer fiyatla yapılan satışlardır. Fason işlemeye dayalı yapılan ihracat; malzemesi üçüncü şahıslar tarafından temin edilmek suretiyle Petkim tesislerinde yapılan satışlardır. Petkim'de gerekli görüldüğü durumlarda yurtdışı satışlarda da ihale yöntemi uygulanabilmektedir.

1980'li yıllardan itibaren üretim yapan şirketlerin yapıları belirgin ölçüde değişmiştir. Global rekabet ortamı, değişen teknolojiler, kısalan ürün yaşam eğrileri işletmeler için eskisinden çok daha fazla tehditkar hale gelmiş ve işletme yönetimi anlayışı giderek yükselen bir önem kazanmıştır. Müşteri beklentileri; kalite, güvenilirlik, fiyat ve zamanında teslimat yönünde sürekli bir artış göstermiş bunun

neticesinde işletmelerin sahip olduğu kaynakların daha etkin ve daha verimli olarak değerlendirilmesi gereği bir kez daha ortaya çıkmıştır. Rekabetin şiddetlenmesiyle birlikte işletmeler özellikle üretim alanında yeni birtakım yöntemler, teknikler, uygulamalar ve felsefeler geliştirme yoluna gitmişler ve kaliteye verilen önem ivme kazanmıştır (Erdal ve Cengiz, 1999, s.1).

Modern üretim ve yönetim felsefesinin temelinde tüketici istek ve ihtiyaçlarını daha iyi karşılayabilmek olduğu için söz konusu tüketici talep ve beklentilerinin doğru şekilde tahmin ve tespit edilmesi gerekmektedir. Bu bakımdan göz önünde gelecekteki üretim faaliyetlerinin planlanmasında ilk hareket noktası üretilmesi gereken veya istenen miktarlardır. Üretilmesi düşünülen mamule ne kadar talep olacağı bilinmeden herhangi bir planlamaya gitmek mümkün değildir. Hammadde, yedek parça, yarı mamul, makine, insan gücü ve yatırım ihtiyaçlarının saptanmasında temel veri talep tahminleridir (Kobu, 2003, s.79).

Satış ve pazarlamanın üretimle entegrasyonu, bir başka deyişle tam bir uyum içerisinde çalışması ve işletmenin talep odaklı olması rekabetçi avantaj sağlamada ayırt edici faktör olarak işletme yönetimi dünyasında karşımıza çıkmaktadır. Bir işletmenin talep tahminlerine duyduğu ihtiyaç, üretim tipi, üretim araçları ve yöntemleri, mamul çeşidi, tüketici eğilimi, rakiplerin durumu, stoklama olanakları, dağıtım kanalları vb. gibi pek çok faktörün etkisi altında belirir. Bu faktörlerin bir kısmını içeren genel bir kural olarak denilebilir ki; tüketiciden talep geldiği andan başlayarak mamulün istenilen teslim zamanına kadar geçen sürenin uzunluğu talep tahmini ihtiyacını ortaya çıkarır (Kobu, 1996, s.81).

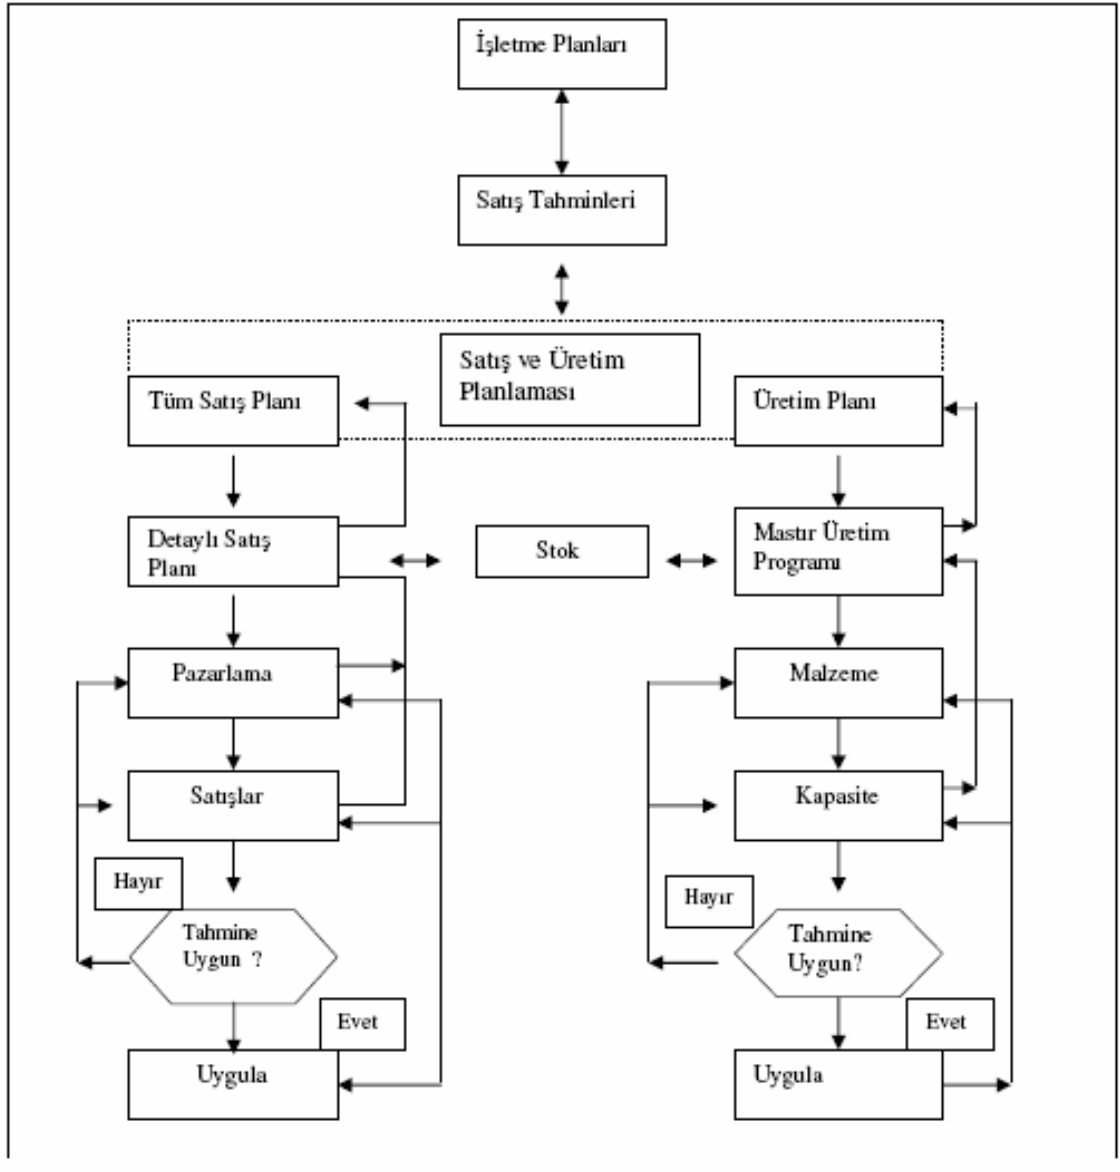
Etkili bir pazarlama yönetimi açısından pazar potansiyeli ve beklenen satışlar çok büyük önem taşımaktadır. Bu yüzden pazarlama yöneticileri planlarını yaparken bir takım öngörümlemelere dayanmak mecburiyetindedir; bir başka deyişle öngörümleme ile pazarlama stratejilerinin planlanması birbirine bağımlıdır (McCarthy, 1987, s.217).

Pazarın tam olarak tanımlanması, hedef tüketici istek ve ihtiyaçlarının istenilen düzeyde saptanması ve talep yönetiminin etkinliğinin artırılması ile mümkündür.

Öngörümleme, gelecekte gerçekleşmesi muhtemel olayların tespiti, hesabı veya kestirilmesidir. Bir diğer ifade ile öngörümleme, geçmişe bakarak geleceği görme sanatıdır (Ferman, 1988, s.59).

Bir işletmenin üretim bölümünün satış öngörümlemeleri ile ilgilenmesinin temel nedeni, satılacağı belirlenen miktarlarda malın belirlenen zamanda hazır olması için gerekli üretim faktörlerinin uygun nitelik ve nicelikte tedarik edilebilmesidir. Üretilen ürünler için miktar yönünden satış öngörümlemeleri yapıldıktan sonra ikinci işlem, bu tahminleri gerek duyulacak üretim faktörleri cinsinden ifade etmektir. Bu aşamada, üretim planlama prosedürü içinde belirli bir ürünün üretimi için gerek duyulacak üretim faktörleri ve bunlardan bir birim ürün için gerekecek miktarlar belirlenebilecektir (Barutçugil, 1988, s.156).

Talep yönetimi pazardaki oluşumları sürekli olarak gözlemler, değişimleri yorumlar, çeşitli kanallardan iletişim kurar. Satış ve pazarlamadan gelen veriler analiz edilerek üretim departmanının oluşturacakları plan ve programlara başlangıç noktası olur. Bu bilgiler özellikle; ana üretim programı, üretim kaynakları planlaması, kaba kapasite planlaması, malzeme ihtiyaç planları, ürün rotalarının hesapları, iş emirleri, atölye programları, satın alma emirlerinin hazırlanmasında temel referans teşkil eder. Düşük envanter düzeyleri, düşük üretim maliyetleri, üretim sevk zamanlarının kısılması bu programların eksiksiz yapılmasıyla mümkündür. İşletmenin satış ve üretim plan ve programlarının hazırlanışı ve bu süreç içerisinde tahminlemenin yeri ve sürece etkisi aşağıda Şekil 19'da gösterilmiştir (Erdal ve Cengiz, 1999, s.6).



Şekil 19: İşletmelerde Öngörümleme ve Planlama Süreci

Kaynak: Erdal M., Cengiz E., Modern Üretim Yönetimi Ve Tahminleme Üzerine Değerlendirmeler, İstanbul Üniversitesi, Siyasal Bilgiler Fakültesi Dergisi, Sayı: 20, Mart 1999, s.8.

Başarılı bir satış öngörümlemesi; iyi satış planlarının hazırlanmasına, iyi üretim planlarının hazırlanmasına, iyileştirilmiş üretim performansına, iyileştirilmiş tüketici hizmetlerine, düşük maliyetlere, iyi rekabetçi avantaja, iyi pazarlama planlarına, iyi finansal performansa, takım çalışmasına, işletmenin etkin kontrolüne yardımcı olur (Emre, 1995, s.7).


Petkim satış sorumlusu ile yapılan görüşmeler sonucunda Petkim’de herhangi bir satış öngörümleme tekniğinin kullanılmadığı, sadece geçmiş satış rakamlarından yola çıkarak gelecek hakkında varsayımlarda bulunulduğu öğrenilmiştir.

3.3. PETKİM’DE UYGULAMA


Araştırmamızın bu bölümünde, birinci ve ikinci bölümde söz edilen yöntemler kullanılarak her bir ürüne ilişkin satış öngörümlemeleri yapılmıştır. Daha sonra kullanılan yöntemlere ilişkin öngörümlemelerin performansları karşılaştırılmıştır.

3.3.1.Uygulamada Ele Alınan Ürünlerin Tanıtılması

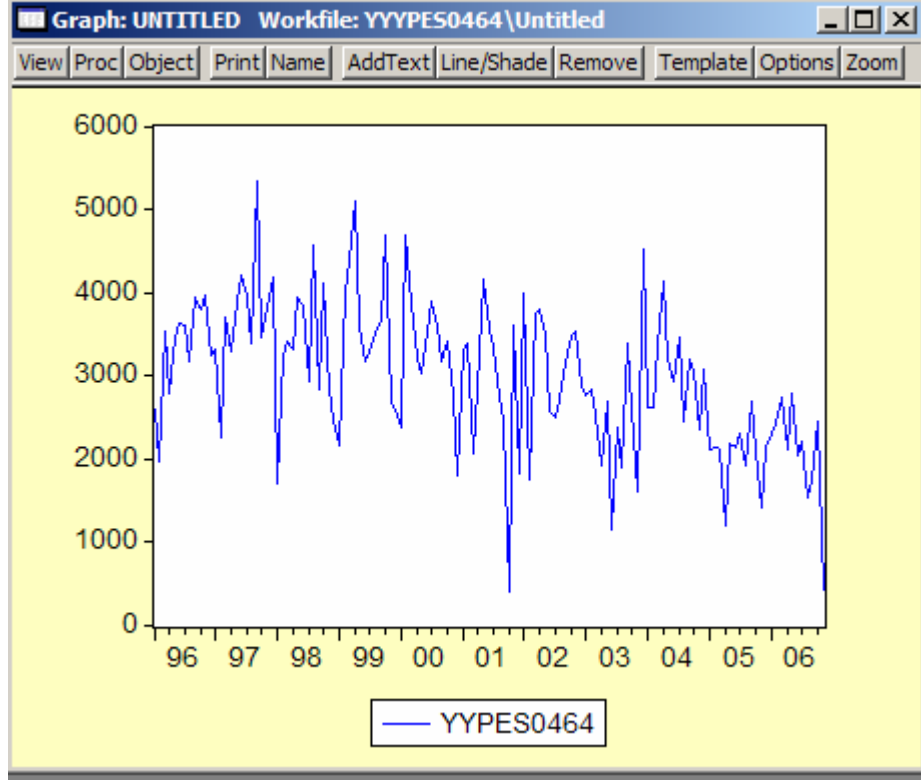
Petkim satış sorumlusu ile yapılan görüşmeler sonucunda Petkim’de toplam 15 adet ürün satışı yapıldığı görülmüştür. Bu ürünler ana başlıklar halinde; ACN, AROM, AYPE-T, AYPE, EG, ETİLEN, Hava Ayırma, KA, Masterbatch, PA, PP, PTA, PVC, Torba ve YYPE’dir. Her bir ana ürün kendi içerisinde yan ürünlere ayrılmaktadır. Çalışmamızda bu ana ürünler içerisinde rastgele olarak dört ürünün Ocak 1996 – Kasım 2006 dönemine ait satış rakamları ton bazında ele alınmıştır. Seçilen bu dört ürünün ürün garanti değerlerini, ürün şeklini, ambalaj şeklini, depolama şartlarını ve kullanım alanlarını gösteren ürün kartları Ek 1’de verilmiştir. Çalışmamızda kullanılan PVC S39, PVC S 65, YYPE S 0464 ve PTA isimli ürünlerin “EViews 5” paket programı kullanılarak çizilen zaman yolu grafikleri aşağıdaki gösterilmektedir.




Şekil 20: PVC S 39 Ürünün Zaman Yolu Grafiği



Şekil 21: PVC S 65 Ürünün Zaman Yolu Grafiği



Şekil 22: YYPE S 0464 Ürünün Zaman Yolu Grafiği



Şekil 23: PTA Ürünün Zaman Yolu Grafiği

3.3.2.Trendin Bileşenlerine Ayrılma Yöntemiyle Satış Öngörülmesi

Bu bölümde seçmiş olduğumuz dört ürünün ikinci bölümde anlatılan trendin bileşenlerine ayrılması yöntemiyle öngörülmesi yapılmıştır. Trendin bileşenlerine ayrılması yönteminin uygulanmasında, en uygun trend denkleminin belirlenmesinde “SPSS 14.0”, belirlenen en uygun trend denkleminde öngörülme değerlerinin elde edilmesinde “MINITAB 14”, mevsimsel indekslerin, konjonktür ve arizi bileşenlerin manuel olarak belirlenmesinde “EXCEL” paket programlarından yararlanılmıştır.


3.3.2.1.Trendin Belirlenmesi

Trendin bileşenlerine ayrılması yönteminde ilk aşama olan en uygun trend denkleminin bulunması amacıyla ele alınan Ocak 1996 – Kasım 2006 dönemine ait dört ürünün satış rakamları “SPSS 14.0” paket programına girilmiştir. En küçük kareler yönteminin uygulanması ile elde edilen trend denklemleri arasından en uygun trend denkleminin belirlenmesinde R^2 değerlerine bakılmıştır. Trend denklemlerinin geçerliliğini test etmek için yapılan F testleri ve zaman değişkeni katsayılarının t testlerinin, 0.05 önem düzeyinde anlamlı oldukları görülmüştür. Bunun sonucunda, dört ürüne ait elde edilen en uygun trend denklemleri aşağıda belirtilmiştir.


Tablo 4: Ürünlerin Trend Denklemleri

Ürünler	En Uygun Trend Denlemi	R^2	F	Sigf.
PVC S 39	$\hat{y}_t = 4016,71 - 50,1342t + 0,3060t^2$	0,363	36,45	0,000
PVC S 65	$\hat{y}_t = 4249,20 + 72,9998t - 0,4867t^2$	0,147	11,04	0,000
YYPE S 0464	$\hat{y}_t = 3397,28 + 5,0686t - 0,1293t^2$	0,298	27,15	0,000
PTA	$\hat{y}_t = 3759,52 + 69,9222t - 0,6154t^2$	0,227	18,83	0,000


Zaman serilerine ait ikinci dereceden trend denklemlerini gösteren grafikler aşağıda verilmiştir.




Şekil 24: PVC S 39 Ürününe Ait En Uygun Trend Denklemini Gösteren Grafik



Şekil 25: PVC S 65 Ürününe Ait En Uygun Trend Denklemini Gösteren Grafik



Şekil 26: YYPE S 0464 Ürününe Ait En Uygun Trend Denklemini Gösteren Grafik



Şekil 27: PTA Ürününe Ait En Uygun Trend Denklemini Gösteren Grafik

3.3.2.2.Mevsim Etkisinin Belirlenmesi

Trendin bileşenlere ayrılması yönteminin ikinci aşaması olan mevsim etkisinin belirlenmesinde literatürde çeşitli yöntemler kullanılmaktadır. Bunlar arasında “Hareketli Ortalamaya Oran (çarpımsal)”, “Hareketli Ortalamadan Fark (toplamsal)”, “Çarpımsal Census X-11” ve “Toplamsal Census X-11” yöntemleri sayılabilir. Bu çalışmada “Hareketli Ortalamaya Oran” yöntemi kullanılmıştır.

Çalışmamızın bu bölümünde öncelikle “MINITAB 14” paket programı yardımıyla her bir ürün için ayrı ayrı 131 aylık satış rakamlarının 12’şerli hareketli ortalamaları hesaplanmıştır. Daha sonra “EXCEL” programında manuel olarak, 119 aylık veri için (12 aylık veri eksildiğinden) satış rakamları, hesaplanan bu 12’şerli hareketli ortalamalara bölünerek yüzde olarak ifade edilmiştir. 11 yıla ait her ay için toplam yüzdeler bulunmuş ve ardından her ay için 10 yüzde değeri olduğundan dolayı bulunan toplam değerler 10’a bölünerek aritmetik ortalamaları alınmış, sonuçta mevsim indeksi ortalama değerlerine ulaşılmıştır*. Son olarak, ikinci bölümde verilen (2.6) nolu denklem ile elde edilen düzeltilmiş mevsim indeksi ile her aya ait bulunan mevsim ortalamaları çarpılarak düzeltilmiş mevsim indeks değerleri bulunmuştur. Her bir ürün için yapılan hesaplamalar sonucu elde edilen düzeltilmiş mevsim indeks değerleri Tablo 5’te verilmiştir.

Tablo 5: Herbir Ürüne İlişkin Düzeltilmiş Mevsim İndeksleri Değerleri

PVC S 39	Mevsim İndeksi Değerleri	PVC S 65	Mevsim İndeksi Değerleri	YYPE S 0464	Mevsim İndeksi Değerleri
Ocak	0,9737	Ocak	0,7857	Ocak	0,8978
Şubat	0,9713	Şubat	0,8562	Şubat	0,9655
Mart	1,1173	Mart	0,8435	Mart	1,0605
Nisan	1,1639	Nisan	0,8461	Nisan	1,0077
Mayıs	1,3388	Mayıs	1,1259	Mayıs	1,1180
Haziran	1,0633	Haziran	1,0412	Haziran	0,9729
Temmuz	0,9776	Temmuz	1,2452	Temmuz	1,0314
Ağustos	0,9818	Ağustos	1,1977	Ağustos	0,9645
Eylül	0,9358	Eylül	1,0470	Eylül	1,1049
Ekim	0,9333	Ekim	1,0969	Ekim	1,0015
Kasım	0,7541	Kasım	0,9983	Kasım	0,9233
Aralık	0,7891	Aralık	0,9162	Aralık	0,9521

* 12’şerli hareketli ortalamaları hesaplariken 2006 yılına ait 11 ay bulunmasından dolayı oluşan veri kaybından ötürü Haziran ayında toplam 9 adet yüzde bulunmuştur. İlk mevsim indeksi değerlerinin hesaplanmasında Haziran ayı için toplam yüzdeler 9’a bölünmüştür.

PTA	Mevsim İndeksi Değerleri
Ocak	0,9412
Şubat	0,8774
Mart	0,9890
Nisan	1,1012
Mayıs	1,0318
Haziran	0,9907
Temmuz	0,9412
Ağustos	0,9394
Eylül	1,1561
Ekim	0,9821
Kasım	1,0346
Aralık	1,0153

Zaman serilerinin mevsim indeksi değerleri bulunduktan sonra “MINITAB 14” paket programı yardımıyla bulunan trend değerleri ile düzeltilmiş mevsim indeks değerleri çarpılarak ilgili ürüne ilişkin öngörümleme rakamları hesaplanmıştır.

3.3.2.3.Konjonktür ve Arızı Faktörlerin Etkisinin Belirlenmesi

Düzeltilmiş mevsim indeksleri hesaplandıktan sonraki aşama zaman serilerindeki konjonktür ve arızı bileşenlerin etkilerinin belirlenmesidir. Bu iki bileşenin etkilerini belirlemek amacıyla ikinci bölümde yer alan (2.7) nolu denklem kullanılır. “EXCEL” programında manuel olarak, herbir ürünün aylık satış rakamları bulunan öngörümleme değerlerine bölünür. Elde edilen değerler bize ilgili ürünün o aydaki konjonktür ve arızı faktörlerinin etkilerini gösterir.

3.3.3.Box-Jenkins Metodolojisi İle Satış Öngörümlemesi


Araştırmamızın bu bölümünde Ocak 1996 – Kasım 2006 dönemine ait her bir ürünün ayrı ayrı ikinci bölümde sözü edilen Box-Jenkins metodolojisi ile öngörümlemesi yapılmıştır. Dört ürüne ait aylık satış rakamlarının Box-Jenkins metodolojisine göre öngörümlemesi yapılırken “EViews 5” paket programından yararlanılmıştır.

Box-Jenkins yöntemin uygulanabilmesi, zaman serisinin hem ortalamada hem de varyansta durağan olmasını gerektirdiği için ilk aşamada serinin durağan olup olmadığına karar vermek gerekmektedir. Bunun için de öncelikle ürünlerin otokorelasyon ve kısmi otokorelasyon fonksiyonlarını gösteren korelogram grafikleri çizilmiştir.

Durağanlığı sınamanın bir başka yolu “Birim Kök (Unit Root)” testleridir. Literatürde birçok birim kök testi yer almaktadır. Elder ve Kennedy’e göre “Genişletilmiş (Augmented) Dickey-Fuller” birim kök testi literatürde var olan testler arasında en yaygın olarak kullanılanıdır (Elder ve Kennedy, 2001, s.138). Bu nedenle ilgili ürünün OKF ve KOKF grafikleri çizildikten sonra, zaman serilerinin durağanlığının sınanması için ADF birim kök testi uygulanmıştır. Çalışmamızda ele alınan ürünlerin OKF ve KOKF grafikleri ve yapılan ADF birim kök testi sonuçları aşağıda verilmiştir.

Tablo 6: Tüm Ürünlerin ADF Birim Kök Test Sonuçları


Ürünler	ADF Birim Kök Test Sonuçları		
		Kesmeli	Kesmeli ve Trend
PVC S 39	ADF Test İstatistiği	-5,051346	-5,627979
	Test Kritik Değerleri		
	1% level	-3,481217	-4,030157
	5% level	-2,883753	-3,444756
	10% level	-2,578694	-3,147221
PVC S 65	ADF Test İstatistiği	-5,678521	-5,673144
	Test Kritik Değerleri		
	1% level	-3,481217	-4,030157
	5% level	-2,883753	-3,444756
	10% level	-2,578694	-3,147221
YYPE S 0464	ADF Test İstatistiği	-7,726793	-10,24053
	Test Kritik Değerleri		
	1% level	-3,481217	-4,030157
	5% level	-2,883753	-3,444756
	10% level	-2,578694	-3,147221
PTA	ADF Test İstatistiği	-7,804964	-8,150338
	Test Kritik Değerleri		
	1% level	-3,481217	-4,030157
	5% level	-2,883753	-3,444756
	10% level	-2,578694	-3,147221



PVC S 39

PVC S 65

Şekil 28: PVC S 39 ve PVC S 65 Ürünlerinin OKF ve KOKF Grafiği



PTA

YYPE S 0464

Şekil 29: PTA ve YYPE S 0464 Ürünlerinin OKF ve KOKF Grafiği

Tüm ürünlerin ADF Birim Kök Test sonuçlarına bakıldığında, ilgili ürünlerin zaman serilerinin durağan olduğu görülmektedir. İlgili ürünlere ait Box-Jenkins modelinin belirlenmesinde, otokorelasyon ve kısmi otokorelasyon fonksiyonlarının grafiklerine bakılır. Model belirleme aşamasında, sadece OKF ve KOKF grafiklerine bakılması ileri düzey AR(p), MA(q) ve özellikle ARMA(p,q) süreçlerinin belirlenmesinde yeterli olmadığından ötürü korelogramların yanında bazı model seçme kriterleri kullanılmaktadır. Akmut vd.'e göre en yaygın kullanılan model seçim kriterleri “Akaike Bilgi Kriteri” (Akaike Information Criterion – AIC) ve “Schwartz Bayes Kriteri” (Schwartz Bayesian Criterion – SBC) dir (Akmut vd., 1999, s.178). İlgili ürünlerin AIC değerlerine bakıldıktan sonra en küçük AIC değerine sahip olan model en uygun model olarak seçilmiş ve bulunan Box-Jenkins modeline göre öngörümlemeleri yapılmıştır.

Tablo 7: Tüm Ürünlerin En Uygun Box-Jenkins Modelleri, AIC Değerleri ve Model Denklemleri

Ürünler	En Uygun Box-Jenkins Modeli	AIC Değeri	Modelin Denklemi
PVC S 39	AR(1)	15,87073	$y_t = 814,8131 + 0,666196y_{t-1}$
PVC S 65	AR(1)	17,50428	$y_t = 2607,895 + 0,582025y_{t-1}$
YYPE S 0464	ARMA(2,2)	16,13837	$y_t = -87,16158 + 0,080173y_{t-1} + 0,940216y_{t-2} + e_t - 0,074506e_{t-1} - 0,887609e_{t-2}$
PTA	AR(1)	17,83586	$y_t = 3178,298 + 0,338054y_{t-1}$

3.3.4.Yapay Sinir Ağları İle Satış Öngörümlemesi

Zaman serileri ile öngörümlemede bulunabilmek için bilinen ve en yaygın kullanılan istatistik yöntemlerin en kapsamlısı Box-Jenkins modelleridir. Otoregresif (AR), Hareketli Ortalama (MA), Otoregresif-Hareketli Ortalama (ARMA) ve Bütünleşik Otoregresif-Hareketli Ortalama (ARIMA), Box-Jenkins öngörümleme modelleridir. Box-Jenkins metodolojisi; kesikli, doğrusal stokastik süreçlere dayanır. Ancak gerçek hayata ilişkin seriler genellikle doğrusal değildir. Bu sebeple doğrusal olmayan zaman serilerini modellemede farklı tekniklere ihtiyaç vardır. Son 25 yıldır Bilinear Model, Threshold Autoregressive Model (TAR), Autoregressive Conditional

Heterocedastic (ARCH) Model gibi bir çok doğrusal olmayan zaman serisi modeli geliştirilmiştir. Bu modeller doğrusal modellere göre daha başarılı iseler de, uygulaması zor, probleme özgü ve genelleştirmeden uzak modellerdir. Önerilen bu modeller, veriler arasındaki ilişkinin net olduğu ve bu ilişkiye ait bilginin bilindiği durumda geçerlidir. Ayrıca bu modellerden herhangi biri, veri kümesinde saklı bütün doğrusal olmayan yapıyı ortaya çıkarmada başarılı değildir.

1980’li yılların sonlarından itibaren zaman serileri öngörümlemesinde kullanılmakta olan önemli yöntemlerden biri de yapay sinir ağları (YSA) tekniğidir. YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye ve varsayıma ihtiyaç duymadan gerekli modellemeyi sağlayabilmektedir. Bu sebeple YSA, öngörümleme aracı olarak diğer yöntemlere göre daha fazla avantaja sahiptir ve daha başarılı sonuçlar ortaya koyabilmektedir. Literatürde YSA’nın zaman serileri öngörümlemesinde kullanımına yönelik bir çok çalışma yapılmıştır.

Zaman serileri geleceği öngörümleme, tek dönemli veya çok dönemli olabilir. Çok dönemli öngörümlemede bulunurken, YSA iki farklı yaklaşımı kullanabilmektedir. Bunlardan birincisi, Box-Jenkins modellerindeki gibi tek dönemli iteratif öngörümlemedir. Diğerisi ise, birden fazla dönemin aynı anda öngörümlemesinin yapıldığı direkt metod olarak adlandırılan durumdur. Çalışmamızda YSA ile öngörümleme yapılırken “MATLAB 7” paket programı kullanılarak iteratif yaklaşım benimsenmiştir. Oluşturulan YSA modelinde öğrenme algoritması olarak, literatürde var olan çalışmalar içerisinde en fazla kullanılan Geri Yayılım (Back-Propagation) Levenberg-Marquardt öğrenme algoritması kullanılmıştır.

3.3.4.1.Geliştirilen YSA’da Levenberg-Marquardt Öğrenme Metodu

Temel olarak, bu algoritma maksimum komşuluk fikri üzerine kurulmuş bir en az kareler hesaplama metodudur. Bu metod, diğer öğrenme algoritmalarının en iyi özelliklerinden oluşur ve diğer metodların kısıtlarını ortadan kaldırır. Genel olarak, bu metod yavaş yakınsama probleminden etkilenmez.

$E(\tilde{w})$ 'nin bir amaç hata fonksiyonu olduğu düşünülürse m tane hata terimi için $e_i^2(\tilde{w})$ aşağıda verilmiştir.

$$E(\tilde{w}) = \sum_{i=1}^m e_i^2(\tilde{w}) = \|f(\tilde{w})\|^2 \quad (3.1)$$

Bu eşitlikte $e_i^2(\tilde{w}) \equiv (y_i - yd_i)^2$ dir.

Burada amaç fonksiyonu $f(\cdot)$ ve onun Jakobiyeni J 'nin bir noktada \tilde{w} olarak bilindiği farzedilir.

LMM'de hedef, parametre vektörü \tilde{w} 'nin $E(\tilde{w})$ minimum iken bulunmasıdır. LMM'nin kullanılmasıyla yeni vektör w_{k+1} , farzedilen vektör w_k 'dan hesaplanır.

$$w_{k+1} = w_k + \delta w_k \quad (3.2)$$

Burada δw_k aşağıdaki şekilde verilir.

$$(J_k^T J_k + \lambda I) \delta w_k = -J_k^T f(w_k) \quad (3.3)$$

Eşitlikte,

J_k : f 'in w_k değerlendirilmiş Jakobyeni,

λ : Marquardt parametresi, ve

I : birim veya tanımlama matrisidir.

Levenberg-Marquardt algoritması aşağıdaki şekilde özetlenebilir:

- (i) $E(\tilde{w}_k)$ 'yi hesapla,
- (ii) küçük bir λ değeri ile başla (mesela $\lambda = 0,01$),
- (iii) $\delta \tilde{w}_k$ için Denklem (3.3)'ü çöz ve $E(\tilde{w}_k + \delta \tilde{w}_k)$ değerini hesapla,
- (iv) şayet $E(\tilde{w}_k + \delta \tilde{w}_k) \geq E(\tilde{w}_k)$ λ 'yı 10 kat arttır ve (iii)'e git,
- (v) şayet $E(\tilde{w}_k + \delta \tilde{w}_k) < E(\tilde{w}_k)$ λ 'yı 10 azalt,
- $\tilde{w}_k : \tilde{w}_k \leftarrow \tilde{w}_k + \delta \tilde{w}_k$ 'yi güncelleştir ve (iii)'e git.

Hedef çıkışı hesaplamak için bir MLP'nin LMM kullanılarak öğretilmesi ağırlık dizisi w_0 'a bir başlangıç değerinin atanması ile başlar ve hatalarının karelerinin toplamı e_i^2 'nin hesaplanmasıyla devam eder. Her e_i^2 terimi, hedef çıkış (y) ile gerçek çıkış (yd) arasındaki farkın karesini ifade eder. Bütün veri seti için e_i^2 hata terimlerinin tamamının elde edilmesiyle, ağırlık dizileri (i)'den (v)'e kadar olan LMM adımlarının uygulanmasıyla adapte edilir (Sağiroğlu vd., 2003, s.97-98).

3.3.4.2. Geliştirilen YSA'nın Topolojisi

Uygulamada kullanılan YSA modeli 1.5.1. başlığı altında anlatılan Çok Katmanlı İleri Beslemeli bir yapay sinir ağıdır. Danışmanlı öğrenme yöntemlerinden Geri Yayılım Algoritmasını kullanan İleri Beslemeli YSA'nın bu çalışmada tercih edilmesinin nedeni, zaman serilerinin modellenmesi ve öngörümleme çalışmalarında en çok kullanılan yöntem olması ve hem doğrusal hem de doğrusal olmayan yapıların modellenmesinde gösterdiği öngörü başarısıdır.


Öngörümlemede kullanılacak bir YSA modelinin tasarımında aşağıdaki değişkenlerin belirlenmesi gerekmektedir:

1. Girdi nöron sayısı,
2. Gizli katman ve gizli katman nöron sayısı,
3. Çıktı nöron sayısı.

Bu deęişkenlerin seçimi ilgilenilen probleme göre deęişiklik göstermektedir. Optimal aę topolojisinin belirlenmesinde önerilen bazı yöntemlerin olmasına rağmen, bu yöntemlerin hiçbirisi gerçek öngörümleme problemleri için en uygun çözümü garanti etmemektedir. Bundan dolayı, bu parametrelerin belirlenmesinde kesin ve açık yöntemler bulunmamaktadır, ancak sezgisel yaklaşımlar ve kısıtlı deneylere dayalı benzetim çalışmaları yardımcı olabilmektedir.

Genellikle literatürde, girdi katmanında 10, 11 ve 12 nöron sayısı kullanılarak YSA'larının geliştirildięi görülmektedir. Bu tez kapsamında geliştirilen ileri beslemeli YSA'da ise 10 adet nörona sahip bir girdi katmanının kullanılması benimsenmiştir.

3.3.4.başlığında belirtildięi gibi geliştirilen YSA'da iteratif öngörümleme yöntemi benimsendiğinden çıktı nöron sayısı birdir. Aynı şekilde literatürde geliştirilen ileri beslemeli YSA'larda genellikle tek gizli katman kullanılmaktadır. Bu nedenle çalışmamızda geliştirilen YSA modelinde tek gizli katman kullanılması uygun görülmüştür. İteratif yaklaşım benimsenerek geliştirilen YSA modeli aşağıdaki şekilde gösterilmektedir.



Şekil 30: Geliştirilen YSA Topoloji

Girdi katmanı ile gizli katman arasında tanjant-sigmoid transfer fonksiyonu kullanıldığından geçmiş döneme ait gerçek satış rakamları, MATLAB’de var olan fonksiyonlar kullanılarak [-1,+1] aralığında yer alacak şekilde ölçeklendirilmiştir. Gizli katman ile çıktı katmanı arasında ise doğrusal transfer fonksiyonu kullanılmıştır.

Gizli katmandaki nöron sayısının belirlenmesinde deneme-yanılma yöntemi benimsenmiştir. Buradan hareketle herbir seri için en iyi yapay sinir ağı modeli doğrulama kümesinde en iyi sonucu veren (en düşük hata kareler toplamını veren) ağ olarak seçilmiştir. Ele alınan herbir ürün serisi için toplam 131 adet satış verisi yer almaktadır. Bu serilerdeki verilerin %80’i eğitim kümesi, %10’u doğrulama kümesi ve kalan %10’u ise test kümesi olarak ele alınmıştır. Bir başka ifade ile, herbir serideki 131 değerden 95 tanesi eğitim kümesine, 13 tanesi doğrulama kümesine, kalan 13 tanesi ise test kümesine tahsis edilmiştir. Yapılan denemeler sonucunda herbir ürün serisi için en iyi ağ topolojileri aşağıdaki tabloda gösterilmiştir.


Tablo 8: Ele Alınan Ürünlere İlişkin Belirlenen En İyi Ağ Topolojileri

Ürün Adı	En İyi Ağ Topolojisi		
	Girdi Katmanı Nöron Sayısı	Gizli Katman Nöron Sayısı	Çıktı Katmanı Nöron Sayısı
PVC S 39	10	8	1
PVC S 65	10	6	1
YYPE S 0464	10	8	1
PTA	10	9	1


Herbir ürünün test kümesi için ilgili YSA’nın doğruluğunu tespit etmek amacıyla “Hata Karelerinin Ortalaması” (Mean Squared Error – MSE) performans ölçütünü kullanan YSA’ların çalıştırılmasına ilişkin rastgele seçilen örnek uygulamalar aşağıdaki tabloda ve takip eden şekillerde gösterilmiştir.

Tablo 9: Ele Alınan Ürünlere İlişkin Örnek Uygulama Sonuçları


Ürün Adı	Hata Kareleri Ortalaması (MSE)
PVC S 39	$2,4268.10^6$
PVC S 65	$6,8424.10^6$
YYPE S 0464	$6,3371.10^6$
PTA	$1,0376.10^7$




Şekil 31: YSA'nın PVC S 39 Ürünün Test Kümesine Ürettiği Değerler



Şekil 32: YSA'nın PVC S 65 Ürünün Test Kümesine Ürettiği Değerler



Şekil 33: YSA'nın YYPE S 0464 Ürünün Test Kümesine Ürettiği Değerler



Şekil 34: YSA'nın PTA Ürünün Test Kümesine Ürettiği Değerler

3.3.4. Kullanılan Yöntemlerin Karşılaştırılması

Öngörü modellerinin performanslarının karşılaştırılması amacı ile çeşitli istatistikler kullanılmaktadır. Öngörünün performansının testi için, öngörü değerleri ile mevcut olan gerçek değerler arasındaki farklar, yani öngörü hataları (kalıntılar-residuals), bazı formüllerle modellerin öngörü performansını karşılaştırmaya yardımcı olabilecek şekilde standartlaştırılır. Modellerin öngörü performansının ölçümünde kullanılan istatistikler; Hata Kareleri Ortalaması (Mean Squared Error – MSE), Ortalama Hata Karelerinin Karakökü (Root Mean Squared Error – RMSE), Ortalama Mutlak Hata (Mean Absolute Error – MAE), Ortalama Yüzde Hata (Mean Percentage Error – MPE), Hata Kareleri Toplamı (Sum of Squared Errors – SSE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error – MAPE) ve Theil-U istatistiği olarak sıralanabilir. Çalışmamızda kullanılan yöntemlerin performanslarının karşılaştırılmasında Hata Kareleri Toplamı (SSE) performans ölçüt kriteri kullanılmıştır. Hata kareleri toplamı performans ölçüt kriterinin denklemi aşağıdaki gibi gösterilmektedir.

e_t : t dönemindeki öngörü hatası,

y_t : t döneminde gerçekleşen değer,

\hat{y}_t : t dönemi için hesaplanan öngörü değeri

n : öngörülen dönem sayısı olmak üzere,

$$SSE = \sum_{t=1}^n (e_t)^2 \quad (3.4)$$

$$e_t = y_t - \hat{y}_t \quad (3.5)$$

Buna göre Hata Kareleri Toplamını ölçüt kabul ederek çalışmamızda kullanılan yöntemlerin öngörü performansları aşağıdaki Tablo 10'da verilmiştir.

Tablo 10: Kullanılan Yöntemlerin Öngörümlerle Performanslarının Karşılaştırılması

Ürün Adı	Öngörümlerle Sonuçları - Hata Kareleri Toplamı (SSE)		
	Trendin Bileşenlerine Ayrılması	Box-Jenkins Metodolojisi	Yapay Sinir Ağları
PVC S 39	45960043,844	57633690	1886100
PVC S 65	284287784,079	29500000	20158000
YYPE S 0464	66521905,757	71327340	1588000
PTA	344547498,960	411000000	5640700

Tablo 10’da görüldüğü üzere öngörümlerle yöntemlerinden Yapay Sinir Ağları, kullanılan diğer yöntemlere göre herbir üründe daha küçük hata kareleri toplamı vererek en iyi sonuçları üretmiştir.

SONUÇ VE ÖNERİLER

Bu çalışmada, öngörümleme teknikleri içerisinde önemli bir yer tutan zaman serileri analizinde, geleceği öngörümlemede kullanılan geleneksel öngörümleme yöntemlerine alternatif olarak öne sürülen, Yapay Sinir Ağları metoduna yer verilmiştir. Yapay sinir ağları, özellikle son 20 yılda büyük gelişme gösteren bir çalışma disiplini.

Öngörümleme yöntemleri, temel olarak nicel ve nitel yöntemler olmak üzere iki grupta ele alınmaktadır. Genel olarak nicel yaklaşımların girdisi, çeşitli zaman aralıklarında toplanmış olan verilerdir. Verilerin iyi bir şekilde analiz edilmesi, bu yöntemlerin temelini oluşturmaktadır. Son yıllarda geleneksel öngörümleme yöntemlerine alternatif olarak kullanılmaya başlanan yöntemlerden birisi de Yapay Sinir Ağlarıdır. Bilim dünyası 1940'lı yıllarda Yapay Sinir Ağları ile tanışmıştır. Bu alanda yapılan ilk çalışmalar beyin hücrelerinin işlevlerinin ve birbirleri ile haberleşme şekillerinin ortaya çıkarılmasını amaçlamaktaydı. O zamandan beri Yapay Sinir Ağları gerek teorik gerekse pratik anlamda dikkate değer miktarda yol katetmiştir. Bugün birçok hücrenin belli bir düzende bir araya getirilmesi ve uygun öğrenme algoritmalarının kullanılması ile sinir ağları kurulabilmekte ve bu ağlar çok karmaşık görevleri başarıyla yerine getirebilmektedir. Ağ, kendisine sunulan veriler arasında bağlantılar kurarak problemi öğrenmekte, deneysel sonuçları depolamakta ve bunları kullanıma hazırlamaktadır. Yapay sinir ağları, insan beyninin temel birimi olan nöronlara benzer olarak düzenlenen yapay nöronların farklı topoloji ve ağ modelleriyle birbirine bağlanmasıyla oluşan karmaşık sistemlerdir. Bu anlamda, bu ağlar insan beyninin biyolojik fonksiyonlarının basit bir modellenmesinden ibarettir. Bir yapay sinir ağı, birbiriyle etkileşim içindeki pek çok yapay nöronun paralel bağlı bir hiyerarşik organizasyonudur. Yapay sinir ağına hesaplama algoritmik programlamaya bir seçenek oluşturan, temel olarak yeni ve farklı bir bilgi işleme tekniğidir. Yapay sinir ağları bilinen hesaplama yöntemlerinden farklı bir hesaplama yöntemi önermektedir. Buldukları ortama uyum sağlayan, adaptif, eksik bilgi ile çalışabilen, belirsizlikler altında karar verebilen, hatalara karşı toleranslı olan bu hesaplama yönteminin hayatın hemen hemen her alanında başarılı uygulamalarını görmek mümkündür. Oluşturulacak

olan ađın yapısının belirlenmesinde, ađ parametrelerinin seçiminde, belirli bir standardın olmaması, problemlerin sadece nümerik bilgiler ile gösterilebilmesi, eğitimin nasıl bitirileceğinin bilinmemesi ve ađın davranışlarının açıklanamamasına rağmen bu ađlara olan ilgi her geçen gün artmaktadır. Özellikle öngörümleme, sınıflandırma, örüntü tanıma, sinyal filtreleme, veri sıkıştırma ve optimizasyon çalışmalarında yapay sinir ađları en güçlü teknikler arasında sayılabilir. Biyolojik sınırlardan esinlenerek elde edilen YSA, doğrusal olmayan ve paralel bilgi işleme özellikleriyle; bulunduğu ortamın değişmesiyle ürettiği sonucu değiştirebilme, giriş parametrelerindeki küçük değişimleri tolere edebilme, değişik bazı veriler karşısında daha önceki veri değerleri içerisinde var olan benzer özellikleri keşfederek, deneyimi olmadığı halde yeni veri değerlerine cevap verebilme gibi üstün özelliklere sahiptir.

Yapay Sinir Ađlarının mevcut olan bu avantajlarından yola çıkarak hazırlanan çalışmamızda Petkim’de üretilmekte olan dört ürüne ilişkin öngörümlemede kullanılan YSA modeli, geleneksel zaman serileri öngörümlemesinde kullanılan Trendin Bileşenlerine Ayrılması ve Box-Jenkins Metodolojisi ile karşılaştırılmış ve sonuç olarak herbir ürüne göre oluşturulan farklı yapıdaki YSA modellerinin daha düşük hatalar vermesinden dolayı daha başarılı olduğu görülmüştür.

Ülkemizde gerek Yapay Sinir Ađları ile gerekse geleneksel zaman serileri öngörümleme yöntemleri ile satış değerlerinin modellenmesi ve öngörümlemesine ilişkin çalışmaların sınırlı sayıda olduğu ve Petkim’de mevcut olan herhangi bir satış öngörümleme yönteminin kullanılmadığı dikkate alındığında, bu çalışmanın Türkiye’deki satış öngörümleme literatürüne ve Petkim’de çalışan yöneticilerin geleceğe yönelik planlama çalışmalarına önemli katkılar sağlayacağı düşünülmektedir.

KAYNAKÇA

KİTAPLAR

Akdi Y. (2003); **Zaman Serileri Analizi: Birim Kökler Ve Kointegrasyon**, Ankara: Bıçaklar Kitabevi.

Akgül I. (a) (2003); **Geleneksel Zaman Serisi Yöntemleri**, İstanbul: Der Yayınları.

Akgül I. (b) (2003); **Zaman Serilerinin Analizi Ve ARIMA Modelleri**, İstanbul: Der Yayınları.

Akmüt Ö., Aktaş R., Binay H. S. (1999); **Öngörü Teknikleri Ve Finans Uygulamaları**, Ankara: Siyasal Kitabevi.

Alpaydın E. (2004); **Introduction To Machine Learning**, Massachusetts London: The MIT Press Cambridge, England.

Barutçugil İ. (1988); **Üretim Sistemi Ve Yönetim Teknikleri**, Bursa: Uludağ Üniversitesi Yayınları.

Başoğlu U., Parasız İ. (2003); **İktisadi Verilerin Analizi Ve Temel Öngörü Yöntemleri**, Bursa: Ekin Kitabevi.

Bhattacharya S. (1997); **A Comparative Study Of Different Methods Of Predicting Time Series**, Canada: Concordia University, Yayınlanmış Yüksek Lisans Tezi.

Box G. P., Jenkins G. M. (1976); **Time Series Analysis Forecasting And Control**, San Francisco: Holden-Day Press.

Çetinel S. (2005); **Pazarlama Planı El Kitabı**, Ankara.

De Lugio S. A. (1998); **Forecasting Principles And Applications**, Boston: Irwin/McGraw-Hill.

Efe Ö., Kaynak O. (2000); **Yapay Sinir Ağları Ve Uygulamaları**, İstanbul: Boğaziçi Üniversitesi Yayınları.

Elmas Ç. (2003); **Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)**, 1. Baskı, Ankara: Seçkin Yayıncılık.

Fu L. (1994); **Neural Networks In Computer Intelligence**, Singapore: McGraw-Hill, Inc.

Gilchrist W. (1976); **Statistical Forecasting**, New York: John Wiley And Sons Inc.

Giriffiths W. E., Hill C. R., Judge G. G. (1992); **Learning And Practicing Econometrics**, New York: John Wiley And Sons Inc.

Gujarati D. N. (2003); **Basic Econometrics**, Fourth Edition, USA: McGraw-Hill Inc.

Demir M. H., Gümüőođlu Ő. (2003); **Üretim Yönetimi**, 6. Baskı, İstanbul: Beta Basım A.Ő.

Fretchling D. C. (1996); **Practical Tourism Forecasting**, Oxford: Butterworth-Heinemann.

Fretchling D. C. (2001); **Forecasting Tourism Demand: Methods And Strategies**, Boston: Butterworth-Heinemann.

Hamburg M. (1974); **Basic Statistics: A Modern Approach**, Chicago: Harcourt Brace Jovanovich Inc.

Hanke J. E., Reitsch A. G. (1992); **Business Forecasting**, Fourth Edition, Boston: Allyn And Bacon.

Harvey A. (1989); **Forecasting, Structural Time Series Models And Kalman Filter**, London: Cambridge University Press.

Haykin S. (1999); **Neural Networks: A Comprehensive Foundation**, New Jersey: Prentice Hall Inc.

Kobu B. (2003); **Üretim Yönetimi**, İstanbul: Avcıol Basım Yayın.

Korum U. (1972); **İstatistik**, Ankara: Sevinç Matbaası.

Kulkarni A. D. (1994); **Artificial Neural Networks For Image Understanding**, New York: Van Nostrand Rein Hold

Makridakis S., Whellwriht S. C., Hyndman R. J. (1998); **Forecasting Methods And Applications**, Third Edition, New York: John Wiley And Sons Inc.

McCarthy E. J. (1987); **Basic Marketing**, 6th Edition, Illinois: Richard D. Irwin Inc., Homewood.

Montgomery D. C., Johnson L. A. (1976); **Forecasting And Time Series Analysis**, New York: McGraw-Hill Book Company.

Orhunbilge N. (1999); **Zaman Serileri Analizi Tahmin Ve Fiyat İndeksleri**, İstanbul: Tunç Matbaacılık A.Ş.

Öztemel E. (2006); **Yapay Sinir Ağları**, 2. Baskı, İstanbul: Papatya Yayıncılık.

Rojas R. (1996); **Neural Networks- A Systematic Introduction**, Berlin: Springer-Verlag.

Sađırođlu Ő., BeŐdok E., Erler M. (2003); **Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları**, Kayseri: Ufuk Kitap Kıratsiye-Yayıncılık.

Sevüktekin M., Nargeleçekenler M. (2005); **Zaman Serileri Analizi**, Ankara: Nobel Yayın Dađıtım Ltd.

Shumway R. H., Stoffer D. S. (2000), **Time Series Analysis And Its Applications**, New York: Springer-Verlag Inc.

Stamatios V. K. (1997); **Understanding Neural Networks And Fuzzy Logic**, New York: The Institute Of Electrical And Electronics Engineers Press.

Ően Z. (2004); **Yapay Sinir Ağları İlkeleri**, İstanbul: Su Vakfı Yayınları.

Yamak O. (2001); **Üretim Yönetimi**, 3. Baskı, İstanbul: Sinerji Yayınları.

Yurtođlu H. (2005); **Yapay Sinir Ağları Metodolojisi ile Önörü Modellemesi: Bazı Makroekonomik Deđişkenler için Türkiye Örneđi**, Uzmanlık Tezi, Devlet Planlama Teşkilatı

MAKALELER

Al-Saba T., El-Amin I. (1999); “Artificial Neural Networks As Applied To Long-term Demand Forecasting”, **Artificial Intelligence In Engineering**, No. 13.

Aladađ Ç. H., Eğriođlu E. (2005); “Yapay Sinir Ağları İle Zaman Serilerinde Öngörü Üzerine Bir Uygulama”, **14. İstatistik Araştırma Sempozyumu Bildirileri**, Ankara.

Archer B. (1980); “Forecasting Demand: Quantitative And Intuitive Techniques”, **International Journal Of Tourism Management**, Vol. 5, March.

Bircan H., Karagöz Y. (2003); “Box-Jenkins Modelleri İle Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama”, **Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi**, 6/2.

Bolat S., Kalenderli Ö. (2003); “Yapay Sinir Ağı İle İzolatör Konum Açısı Optimizasyonu”, **Elektrik, Elektronik, Bilgisayar Mühendisliği 10. Ulusal Kongresi**, İstanbul.

Buscema M. (2002); “A Brief Overview And Introduction To Artificial Neural Networks”, **Substance Use & Misuse**, Vol. 37, Nos. 8-10.

Chang I., Hwang H. (1998); “Applying Neural Networks In Time Series Forecasting”, **Information And Management Sciences**, Vol. 9, Number 3.

Chen K. (2006); “Using Back-Propagation Neural Network To Forecast The Production Values Of The Machinery Industry In Taiwan”, **Journal Of American Academy Of Business**, Cambridge, March, 9, 1; Pharmaceutical News Index.

Daş R., Türkoğlu İ., Poyraz M. (2006); “Genetik Algoritma Yöntemiyle İnternet Erişim Kayıtlarından Bilgi Çıkarılması”, **S.A.Ü. Fen Bilimleri Enstitüsü Dergisi**, Cilt 10, Sayı 2.

Detienne K. B., Detienne D. H., Joshi S. A. (2003); “Neural Networks As Statistical Tools For Business Researchers”, **Organizational Research Methods**, Vol. 6, No. 2, April.

Dorigo M., Maniezzo V., Colomi A. (1991); “Positive Feedback As A Search Strategy”, **Technical Report**, 91-016.

Elder J., Kennedy P. (2001); “Testing For Unit Roots: What Should Students Be Taught?”, **Journal Of Economic Education**, Spring.

Emre A. (1995); “Tam Zamanında Üretim Sisteminin Ülkemizdeki Uygulamaları Ve Sorunları”, **MPM Yayınları**, No. 543, Ankara.

Erdal M., Cengiz E. (1999); “Modern Üretim Yönetimi Ve Tahminleme Üzerine Değerlendirmeler”, **İstanbul Üniversitesi Siyasal Bilgiler Fakültesi Dergisi**, Sayı 20, Mart.

Ergezer H., Dikmen M., Özdemir E. (2003); “Yapay Sinir Ağları Ve Tanıma Sistemleri”, **Pivolka**, 2(6).

Ferman M. (1988); “Uluslararası Pazarlarda Talep Tahmin Yöntemleri”, **İSO Dergisi**, Sayı 4.

Gareta R., Romeo L. M., Gil A. (2006); “Forecasting Of Electricity Prices With Neural Networks”, **Energy Conversion And Management**, No. 47.

Hamzaçebi C., Kutay F. (2004); “Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini”, **Gazi Üniversitesi Müh. Mim. Fak. Dergisi**, Cilt 19, No. 3.

Hamzaçebi C., Kutay F. (2005); “Yapay Sinir Ağları İle Zaman Serileri Tahmini”, **4. İstatistik Kongresi Bildiriler Kitabı**, 08-10 Mayıs Meritim Pine Beach Resort Belek, Antalya.

Hobbs B. F., Helman U., Jitprapaikulsaorn S., Konda S., Maratukulam D. (1998); “Artificial Neural Networks For Short-term Energy Forecasting: Accuracy And Economic Value”, **Neurocomputing**, No. 23.

Hwang H. B., Ang H. T. (2001); “A Simple Neural Network For ARMA(p,q) Time Series”, **Omega The International Journal Of Management Science**, No. 29.

Jain A. K., Mao J., Mohiuddin K. (1996); “Artificial Neural Networks: A Tutorial”, **IEEE Computer Special Issue On Neural Computing**.

Kayım H. (1985); “İstatistiksel Ön Tahmin Yöntemleri”, **Hacettepe Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Yayınları**, No. 11, Ankara.

Koç M. L., Balas C. E., Arslan A. (2004); “Taş Dolgu Dalgakıranların Yapay Sinir Ağları İle Ön Tasarımı”, **İMO Teknik Dergi**, Cilt 15.

Lippmann R. (1987); “An Introduction To Computing With Neural Nets”, **IEEE ASSP Magazine**, Vol. 4, April.

Özmen A. (1986); “Zaman Serisi Analizinde Box-Jenkins Yöntemi Ve Banka Mevduat Tahmininde Uygulama Denemesi”, **Anadolu Üniversitesi Yayınları**, No. 207, Eskişehir.

Özmucur S. (1990); “Geleceği Tahmin Yöntemleri”, **İstanbul Sanayi Odası Araştırma Dairesi Yayınları**, Yayın No: 1990/2, İstanbul.

Saraç T. (2004); “Yapay Sinir Ağları”, Basılmamış Seminer Projesi, Gazi Üniversitesi Endüstri Mühendisliği Bölümü Anabilim Dalı, Ankara.

Say A. (2006); “Türkiye’deki Nehir Akımları Mevsimlik Verilerinin Parametrik Ve Non-Parametrik Yöntemlerle Trend Analizi”, Selçuk Üniversitesi İnşaat Mühendisliği Anabilim Dalı Yüksek Lisans Tezi, Konya.

Topçuoğlu K., Pamuk G., Özgürel M. (2005); “Gediz Havzası Yağışlarının Stokastik Modellemesi”, **Ege Üniversitesi Ziraat Fak. Dergisi**, 42(3).

Uygunoğlu T., Yurtçu Ş. (2006); “Yapay Zeka Tekniklerinin İnşaat Mühendisliği Problemlerinde Kullanımı”, Teknik Not, **Yapı Teknolojileri Elektronik Dergisi**, No. 1.

Walczak S., Cerpa N. (1999); “Heuristic Principles For The Design Of Artificial Neural Networks”, **Information And Software Technology**, 41(2).

Yaman K., Sarucan A., Atak M., Aktürk N. (2001); “Dinamik Çizelgeleme İçin Görüntü İşleme ve ARIMA Modelleri”, **Gazi Üniversitesi Müh. Mim. Fak. Dergisi**, Cilt 16, No. 1.

Yılmaz B. E., Susam N. (2005); “Türkiye’de Yeniden Mali Yapılanma Sürecinde Orta Vadeli Harcama Sistemine Geçişin Bütçe Büyüklükleri Üzerindeki Etkileri: Türkiye Üzerine Bir Tahmin Modeli”, **20. Türkiye Maliye Sempozyumu**, Yayın No: 1, 23-27 Mayıs, Karahayıt, Pamukkale.

Zhang G., Patuwo B. E., Hu M. Y. (1998); “Forecasting With Artificial Neural Networks: The State Of The Art”, **International Journal Of Forecasting**, No. 14

Zhang G., Patuwo B. E., Hu M. Y. (2001); “A Simulation Study Of Artificial Neural Networks For Nonlinear Time-Series Forecasting”, **Computers & Operations Research**, No. 28.

İNTERNET KAYNAKLARI

Alataş B.; Sinirsel Ağlar, <www.firat.edu.tr/akademik/fakulteler/muhendislik/bilgisayar/balatas/SinirselAglar.pdf> (Erişim Tarihi, 16.09.2006).

Altıntaş E.; Yapay Sinir Ağları Ve Tanıma Sistemleri, <<http://www.yapay-zeka.org/modules/icontent/index.php?page=47>> (Erişim Tarihi, 27.04.2007).

Anderson D., McNeill G.; Artificial Neural Networks Technology, <<https://www.thedacs.com/techs/neural/neural.title.php>> (Erişim Tarihi, 11.12.2006).

Batıtrakya; Yapay Sinir Ağları, <http://batitrakya.dostweb.com/yapaysinirağlari/ek_dokuman.htm> (Erişim Tarihi, 03.08.2006).

Cortez P., Rocha M., Neves J.; Evolving Time Seires Forecasting ARMA Models, <<http://citeseer.ist.psu.edu/cache/papers/cs2/208/http:zSzzSzwww.dsi.uminho.ptzSz~pcortezSzmetaarma.pdf/cortez04evolving.pdf>> (Eriřim Tarihi, 10.11.2006).

Eğriođlu E., Aladađ Ç. H.; Yapay Sinir Ađları Ve ARIMA Modellerinin Melez Yaklařımı İle Zaman Serilerinde Öngörü, <<http://www.ekonometridernegi.org/bildiriler/o15s3.pdf>> (Eriřim Tarihi, 07.03.2007).

Fahey C.; Artificial Neural Networks, <http://www.colinfahey.com/2003apr20_neuron/2003apr20_neuron.htm> (Eriřim Tarihi, 17.08.2006).

Habra A.; Neural Networks-An Introduction, <<http://www.tek271.com/articles/neuralNet/IntoToNeuralNets.html>> (Eriřim Tarihi, 07.03.2007).

Karadeniz M., Yüncü S., Aydemir M. T.; Asenkron Motorlarda Stator Direncinin Yapı Sinir Ađları İle Tahmini, <www.fbe.gazi.edu.tr/tr/bolumler/guadek/6.doc> (Eriřim Tarihi, 05.06.2007).

Pirim H.; Yapay Zeka, <<http://joy.yasar.edu.tr/makale/ilksayı/yapayekahp.pdf>> (Eriřim Tarihi, 11.12.2006).

Shachmurove Y.; Applying Neural Networks To Business, Economics And Finance, <<http://www.econ.upenn.edu/Centers/CARESS/CARESSpdf/02-08.pdf>> (Eriřim Tarihi, 10.11.2006).


Stergiou C., Dimitrios S.; Neural Networks, <http://www.doc.ic.ac.uk/nd/surprise_96/journal/vol4/cs11/report.html> (Eriřim Tarihi, 01.07.2006).


Tatlı E. İ.; Uzman Sistemler, <<http://th.informatik.uni-mannheim.de/people/tatli/resources/pdf/expertsystems.pdf>> (Erişim Tarihi, 25.06.2006).

Yapay Sinir Ağları Hakkında, <<http://www.akademiya.gov.tr/Default.aspx?tabindex=4&tabid=4>> (Erişim Tarihi, 17.07.2006).


<www.petkim.com.tr>, (Erişim Tarihi, 03.07.2007).


EK 1: Dört Ürüne Ait Ürün Kartları

 PETKİM PETROKİMYA HOLDİNG A.Ş. GENEL MÜDÜRLÜĞÜ		KALİTE YÖNETİM SİSTEMİ		ÜR.10-SD-Ü1024.0	
		REVİZYON	SAYFA		
		5	1/1		
S 39 POLİVİNİLKORÜR ÜRÜN ÖZELLİĞİ					
TİCARİ İSMİ	: PVC S 39				
ÜRÜN GARANTİ DEĞERLERİ	:				
DENEY ADI	BİRİMİ	DEĞERİ	METODU		
Viskozite Sayısı (Sikloheksanon 25°C)	cm ³ /g	121 - 134	SOLVAY 1A/93		
K sayısı (Sikloheksanon 25°C)	-	69 - 72	SOLVAY 1A/93		
Yığın Yoğunluğu	g/cm ³	0.44 - 0.53	SOLVAY 4A/91		
Elek Analizi					
- 0.250 mm üstü	% wt	Max. 3	SOLVAY 8A/92, 8F/92		
- 0.063 mm üstü	% wt	Min. 90	SOLVAY 8A/92, 8F/92		
Uçucu Madde	% wt	Max. 0.5	SOLVAY 2A/90		
Kirillik	adet/ft ²	Max. 60	SOLVAY 6A/92		
ÜRÜN ŞEKLİ	: Beyaz toz				
AMBALAJ ŞEKLİ	: 25 kg'lık FFS (Form Fill Seal) beyaz renkli PE torbalarda veya 1300 kg.lık big-bag'lerde.				
DEPOLAMA ŞARTLARI	: Kapalı ve rutubetsiz ortamlarda depolanmalıdır.				
KULLANIM SAHALARI	: Kablo kılıflama, ayakkabı tabanı, esnek ve yan sert profil ve boru, yumuşak film, esnek levha, oyuncak.				
GÜVENLİK BİLGİ FORMU NO	: ÜR.10-BF-TE001.0				
Bu ürün, Tarım ve Köyşleri Bakanlığı'ndan alınan 21.02.2007 tarih ve 35-00214-00005-1 sayılı "Gıda ile Temasta Bulunan Materyal Üretim Sertifikası"na haizdir.					

 PETKİM PETROKİMYA HOLDİNG A.Ş. GENEL MÜDÜRLÜĞÜ		KALİTE YÖNETİM SİSTEMİ		ÜR.10-SD-Ü1027.0	
		REVİZYON	SAYFA		
		6	1/1		
S 65 POLİVİNİLKORÜR ÜRÜN ÖZELLİĞİ					
TİCARİ İSMİ	: PVC S 65				
ÜRÜN GARANTİ DEĞERLERİ	:				
DENEY ADI	BİRİMİ	DEĞERİ	METODU		
Viskozite Sayısı (Sikloheksanon 25°C)	cm ³ /g	109.0 - 122.0	SOLVAY 1A/93		
K sayısı (Sikloheksanon 25°C)	-	66 - 70	SOLVAY 1A/93		
Yığın Yoğunluğu	g/cm ³	0.52 - 0.60	SOLVAY 4A/91		
Elek Analizi					
- 0.250 mm üstü	% wt	Max. 8	SOLVAY 8A/92, 8F/92		
- 0.063 mm üstü	% wt	Min. 90	SOLVAY 8A/92, 8F/92		
Uçucu Madde	% wt	Max. 0.5	SOLVAY 2A/90		
Kirillik	adet/ft ²	Max. 60	SOLVAY 6A/92		
ÜRÜN ŞEKLİ	: Beyaz toz				
AMBALAJ ŞEKLİ	: 25 kg'lık FFS (Form Fill Seal) beyaz renkli PE torbalarda veya 1400 kg.lık big-bag'lerde.				
DEPOLAMA ŞARTLARI	: Kapalı ve rutubetsiz ortamlarda depolanmalıdır.				
KULLANIM SAHALARI	: Basıncılı boru.				
GÜVENLİK EMNİYET BİLGİ FORMU NO	: ÜR.10-BF-TE001.0				
Bu ürün, Tarım ve Köyşleri Bakanlığı'ndan alınan 21.02.2007 tarih ve 35-00214-00005-1 sayılı "Gıda ile Temasta Bulunan Materyal Üretim Sertifikası"na haizdir.					

ÜR - 33 - K - 000001

 PETKİM PETROKİMYA HOLDİNG A.Ş. GENEL MÜDÜRLÜĞÜ	KALİTE YÖNETİM SİSTEMİ		ÜR.15-SD-Ü1542.0	
			REVİZYON NO	SAYFA
			3	1/1
S 0464 YÜKSEK YOĞUNLUK POLİETİLEN ÜRÜN ÖZELLİĞİ				
TİCARİ İSMİ	: PETİLEN YY S 0464			
ÜRÜN GARANTİ DEĞERLERİ	:			
DENEY ADI	BİRİMİ	DEĞERİ	METODU	
Erime Akış Hızı (MFR) (2160 g, 190°C)	g/10d	0.25 - 0.45	ASTM D-1238	
Yoğunluk (23°C)	g/cm ³	0.962 - 0.966	ASTM D-1505	
TİPİK DEĞERLER	:			
Gerilme Dayanımı				
-Akmada Ger. Dayanımı	kg/cm ²	270	ASTM D-638	
-Kopmada Ger. Dayanımı	kg/cm ²	375	ASTM D-638	
-Kopmada Uzama	%	1115	ASTM D-638	
Bükülme Dayanımı	kg/cm ²	9850	ASTM D-747	
İzod Darbe Dayanımı	kgcm/cm	60	ASTM D-256	
Çev.Bas.Kır.Day. (F50)	saat	15	ASTM D-1693	
ÜRÜN ŞEKLİ	: Pellet			
AMBALAJ ŞEKLİ	: 25 kg'lık FFS (Form Fill Seal) beyaz renkli PE torbalarda veya 1400 kg'lık big-bag'lerde.			
DEPOLAMA ŞARTLARI	: Sıcaklığı 50°C altında olan, güneş görmeyen kapalı ve kuru yerlerde			
KULLANIM SAHALARI	: Şişirme ile kalıplama (kimyasal maddeler için büyük hacimli kaplar, gaz yağı bidonları, büyük boy oyuncaklar v.s.)			
GÜVENLİK BİLGİ FORMU NO	: ÜR.15-BF-00002.0			
NOT: Tipik Değerler; Petkim Laboratuvarlarında yapılan analizlerin ortalama değerleri olup sadece bilgi içindir. Ürün garanti değerleri değildir.				
Bu ürün, Tarım ve Köyişleri Bakanlığı'ndan alınan 21.02.2007 tarih ve 35-00213-00009-0 sayılı "Gıda ile Temasta Bulunan Materyal Üretim Sertifikası"na haizdir.				

 PETKİM PETROKİMYA HOLDİNG A.Ş. GENEL MÜDÜRLÜĞÜ	KALİTE GÜVENCESİ SİSTEMİ		PETKİM/A-ÜR.24-SD-Ü2421.0	
			REVİZYON	SAYFA
			TARİH	NO
			09.11.1998	1 / 1/1
SAF TEREFTALİK ASİT ÜRÜN ÖZELLİĞİ				
TİCARİ İSMİ	: PTA			
ÜRÜN GARANTİ DEĞERLERİ	:			
DENEY ADI	BİRİMİ	DEĞERİ	METODU	
Tereftalik Asit	% wt	Min. 99.6	ACL-1	
Su	%wt	Max. 0.5	ACC-TA-14	
4-Karboksibenzaldehit	ppm wt	Max. 25	ACL-5,ACC-TA-07	
Ağır Metaller	ppm wt	Max. 10	ACC-TA-13	
Kül	ppm wt	Max. 10	ACC-TA-12	
ÜRÜN ŞEKLİ	: Beyaz kristal toz			
AMBALAJ ŞEKLİ	: 1 tonluk Polipropilen + PE liner'li örgü torbalarda.			
DEPOLAMA ŞARTLARI	: Islak ortamlardan uzak, kuru yerlerde.			
KULLANIM SAHALARI	: Polyester elyaf ve iplik imalatı, PET şişe imalatı.			
TEKNİK EMNİYET BİLGİ FORMU NO : PETKİM/A-ÜR.24-BF-TE00001.0				

EK 2: Dört Ürünün Satış Rakamları

ÜRÜN	AYLAR	1996	1997	1998	1999	2000	2001	2002	2003	2004	2005	2006
PVC S39	1	3.401	3.853	1.352	1.839	2.330	1.995	2.646	2.092	2.217	2.087	2.095
	2	3.044	2.942	3.182	3.051	1.970	1.860	1.837	1.586	1.810	2.608	2.426
	3	5.526	3.609	3.972	3.059	2.613	2.170	1.771	1.989	2.329	2.551	2.791
	4	4.541	3.380	5.244	3.830	2.710	2.075	1.631	1.546	2.702	2.338	2.974
	5	4.196	2.628	6.485	3.764	2.301	4.342	1.886	2.413	2.522	2.248	3.344
	6	3.117	3.034	3.829	2.622	2.635	2.472	1.425	1.546	2.518	2.513	2.544
	7	3.125	2.742	2.563	2.825	2.796	2.304	1.683	1.094	2.121	2.707	2.857
	8	3.679	2.168	2.010	2.811	2.680	2.092	1.766	1.729	1.981	2.831	3.149
	9	4.540	2.161	2.220	2.778	2.327	1.365	1.546	1.602	2.159	2.417	3.309
	10	3.147	2.363	1.704	3.050	2.488	1.711	1.730	1.656	1.860	2.597	1.856
	11	3.201	1.766	2.001	1.362	1.230	1.838	1.401	1.210	2.079	2.099	1.413
	12	2.577	2.823	1.961	1.269	1.216	1.244	1.766	1.880	1.933	2.174	
PVC S65	1	4.507	4.282	2.224	5.909	3.681	4.100	7.118	7.632	6.667	5.000	4.464
	2	2.351	4.850	3.246	7.685	4.511	5.943	8.069	5.344	5.143	5.411	4.855
	3	4.934	3.434	4.303	6.099	3.991	4.469	8.804	6.511	7.648	6.069	3.887
	4	4.706	3.881	5.888	7.290	4.108	4.469	7.505	4.696	8.665	4.650	4.067
	5	5.740	6.737	9.410	8.682	4.161	7.606	7.566	6.718	8.929	5.759	6.115
	6	3.953	5.755	7.705	8.266	5.944	6.840	5.820	5.017	8.065	6.996	6.542
	7	3.978	7.014	7.569	10.102	12.041	9.168	8.364	5.126	9.391	5.913	7.961
	8	5.319	6.166	7.763	6.112	9.679	7.755	9.817	6.933	8.814	7.678	6.824
	9	5.318	6.711	5.886	6.626	6.169	5.920	6.388	8.132	7.730	7.131	5.269
	10	6.411	6.852	6.420	5.944	4.257	7.049	8.565	8.723	7.328	7.811	2.990
	11	6.765	5.868	6.076	5.516	6.144	5.516	7.252	7.554	7.288	4.848	2.169
	12	5.027	4.827	7.295	3.384	2.577	5.211	8.695	10.811	5.247	6.298	
YYPE S0464	1	2.594	3.302	1.709	2.165	2.362	3.309	3.997	2.750	2.623	2.102	2.297
	2	1.959	2.242	3.250	3.997	4.693	3.393	1.736	2.825	2.609	2.137	2.411
	3	3.529	3.688	3.412	4.397	3.861	2.061	3.753	2.514	3.357	2.113	2.743
	4	2.788	3.285	3.317	5.088	3.212	2.825	3.795	1.904	4.123	1.184	2.109
	5	3.469	3.897	3.946	3.610	3.028	4.166	3.499	2.677	3.204	2.169	2.786
	6	3.619	4.213	3.853	3.165	3.539	3.550	2.572	1.145	2.928	2.123	2.025
	7	3.594	3.972	2.923	3.282	3.885	3.344	2.485	2.375	3.466	2.309	2.207
	8	3.174	3.382	4.554	3.515	3.606	2.750	2.715	1.900	2.451	1.917	1.520
	9	3.949	5.346	2.837	3.659	3.171	2.449	3.153	3.384	3.196	2.692	1.743
	10	3.805	3.468	4.115	4.698	3.405	386	3.488	2.617	3.045	2.082	2.457
	11	3.968	3.807	2.824	2.699	2.751	3.610	3.527	1.609	2.355	1.413	402
	12	3.238	4.172	2.471	2.580	1.798	1.830	2.887	4.526	3.072	2.136	
PTA	1	4.516	5.562	6.241	2.601	5.331	5.847	4.500	4.742	5.444	5.501	2.094
	2	2.866	4.676	3.650	10.362	3.552	6.036	4.555	2.930	3.239	1.204	3.790
	3	5.901	5.487	7.098	3.435	4.500	4.356	5.147	3.764	5.365	5.379	3.680
	4	1.039	6.907	6.051	6.789	6.387	8.414	6.004	3.828	3.689	5.661	2.256
	5	2.823	9.135	6.706	5.155	6.801	7.255	5.275	1.754	3.897	2.824	2.744
	6	2.595	7.207	4.999	4.273	5.785	5.311	9.257	5.446	2.515	2.315	1.371
	7	2.717	5.173	5.219	5.610	6.139	3.800	4.406	5.058	3.934	5.263	3.773
	8	2.149	5.009	3.023	5.731	6.018	4.045	2.366	5.777	6.327	6.225	1.309
	9	5.794	3.146	4.917	4.798	5.413	4.506	10.227	7.088	6.427	5.240	1.489
	10	7.323	1.335	7.164	5.381	5.987	4.601	5.218	5.598	4.916	2.187	1.420
	11	5.029	3.892	6.632	6.282	5.429	6.775	4.451	4.439	7.176	2.702	865
	12	4.247	4.574	3.826	5.671	5.968	5.984	4.417	5.614	9.252	2.277	