

**T.C.  
DOKUZ EYLÜL ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ  
İŞLETME ANABİLİM DALI  
ÜRETİM YÖNETİMİ VE ENDÜSTRİ İŞLETMECİLİĞİ PROGRAMI  
YÜKSEK LİSANS TEZİ**

**PETROKİMYA SEKTÖRÜNDE TALEP TAHMİNİNDE  
YAPAY SİNİR AĞLARININ KULLANILMASI  
“ PETKİM A.Ş. ÖRNEĞİ “**






**Fatih KARASU**

**Danışman**

**Doç. Dr. Hilmi YÜKSEL**

**İZMİR - 2012**

## TEZ ONAY SAYFASI

Üniversite	: Dokuz Eylül Üniversitesi	2009800048
Enstitü	: Sosyal Bilimler Enstitüsü	
Adı ve Soyadı	: Fatih KARASU	
Tez Başlığı	: Petrokimya Sektöründe Talep Tahmininde Yapay Sinir Ağlarının Kullanılması: Petkim A.Ş. Örneği	
Savunma Tarihi	: 02.10.2012	
Danışmanı	: Doç.Dr.Hilmi YÜKSEL	
<b><u>JÜRİ ÜYELERİ</u></b>		
<b><u>Ünvanı, Adı, Soyadı</u></b>	<b><u>Üniversitesi</u></b>	<b><u>İmza</u></b>
Doç.Dr.Hilmi YÜKSEL	DOKUZ EYLÜL ÜNİVERSİTESİ	
Yrd.Doç.Dr.Mehmet AKSARAYLI	DOKUZ EYLÜL ÜNİVERSİTESİ	
Prof.Dr.Cengiz ÇELİKOĞLU	DOKUZ EYLÜL ÜNİVERSİTESİ	
Oybirliği 		
Oy Çokluğu ( )		
Fatih KARASU tarafından hazırlanmış ve sunulmuş "Petrokimya Sektöründe Talep Tahmininde Yapay Sinir Ağlarının Kullanılması: Petkim A.Ş. Örneği" başlıklı Tez ( ) / Projesi ( ) kabul edilmiştir. 		
Prof.Dr. Utku UTKULU Enstitü Müdürü		

## YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum “ Petrokimya Sektöründe Talep Tahmininde Yapay Sinir Ağlarının Kullanılması: “Petkim A.Ş. Örneği” ” adlı çalışmanın, tarafımdan, akademik kurallara ve etik değerlere uygun olarak yazıldığını ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve bunu onurumla doğrularım.

Tarih

.../.../...

Fatih KARASU

İmza

## ÖZET

Yüksek Lisans Tezi

Petrokimya Sektöründe Talep Tahmininde Yapay Sinir Ağlarının Kullanılması

“ Petkim A.Ş. Örneği ”

Fatih KARASU

Dokuz Eylül Üniversitesi

Sosyal Bilimler Enstitüsü

İşletme Anabilim Dalı

Üretim Yönetimi ve Endüstri İşletmeciliği Programı

İnsan beyninin çalışma prensibinden esinlenerek geliştirilmiş olan yapay sinir ağları, yapay zeka çalışmaları içerisinde önemli bir yere sahiptir. Yapay sinir ağları, genellikle karmaşık problemlerin analizinde kullanılmaktadır. Bu teknik, günümüze kadar özellikle çözümü güç ve karmaşık olan çok farklı alanlardaki problemlere uygulanmış ve genellikle başarılı sonuçlar elde edilerek, kendisine geniş bir uygulama alanı bulmuştur. Son yıllarda ise talep tahminlemesi alanında sıklıkla tercih edilmektedir.

Bu çalışmada, ülkemizde tek yerli petrokimyasal üretici olan Petkim'de termoplastik ürünlerden PVC talebinin yapay sinir ağları metoduyla tahmin edilmesi amaçlanmıştır. 2005 – 2011 dönemine ait aylık veriler kullanılarak yapay sinir ağları ile talep tahmini için model oluşturulmuştur. Model test edilerek elde edilen sonuçlar değerlendirilmiştir. Ayrıca, klasik yöntemlerden çoklu doğrusal regresyon analizi ile de tahmin yapılarak yapay sinir ağları ile öngörü performansları kıyaslanmıştır. Kıyaslama sonucunda yapay sinir ağlarının daha başarılı sonuçlar verdiği görülmüştür. Sonuç olarak, yapay sinir ağlarının talep tahminlemesinde etkin bir yöntem olduğu gösterilmiştir.

**Anahtar Kelimeler:** Yapay Sinir Ağları, Çoklu Doğrusal Regresyon Analizi, Talep Tahmini, PVC ( Polivinil Klorür) Plastik Hammaddesi.

## **ABSTRACT**

**Master's Thesis**

**Demand Forecasting By Artificial Neural Networks In Petrochemical Industry**

**“ A Case Study On Petkim Petrochemical Corporation “**

**Fatih KARASU**

**Dokuz Eylul University**

**Graduate School of Social Sciences**

**Department of Business Administration**

**Production Management and Industrial Business Administration Program**

Artificial Neural Networks which have an important role in artificial intelligence studies are inspired by the structure and functional aspects of biological neural networks. ANN are usually used to model complex relationships between inputs and outputs. This model has been applied to the problems which are difficult and complex in different fields and successful results have been obtained. This method which has a wide field of applications has been used for demand forecasting area in recent years.

In this study, it is aimed to forecast PVC ( Polyvinyl Chloride ) plastic raw material demand in Petkim which is the sole petrochemical products manufacturer in Turkey by the artificial neural network method. Demand forecasting model with ANN has been built by using the data in the period of January 2005 – December 2011. ANN model has been tested and the results have been evaluated. Additionally, demand forecasting model has been developed by multiple linear regression analysis which is a conventional forecasting technique. Then, forecasting performance of two methods have been compared. The results have demonstrated that ANN model has provide more accurate prediction. In conclusion, it has been determined that ANN is an efficient tool for forecasting.

**Keywords: Artificial Neural Networks, Multiple Linear Regression Analysis, Demand Forecasting, PVC( Polyvinyl Chloride ) Plastic Raw Material.**

**PETROKİMYA SEKTÖRÜNDE TALEP TAHMİNİNDE  
YAPAY SİNİR AĞLARININ KULLANILMASI  
“ PETKİM A.Ş. ÖRNEĞİ “**

**İÇİNDEKİLER**

TEZ ONAY SAYFASI	ii
YEMİN METNİ	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER	vi
KISALTMALAR	ix
TABLolar LİSTESİ	x
ŞEKİLLER LİSTESİ	xi
EKLER LİSTESİ	xii
GİRİŞ	1

**BİRİNCİ BÖLÜM  
TALEP TAHMİNİ**

1.1. TALEP TAHMİNİ KAVRAMI	2
1.2. TALEP TAHMİN PRENSİPLERİ	3
1.3. TALEP TAHMİN AŞAMALARI	4
1.4. TALEP TAHMİN YÖNTEMLERİ	5
1.4.1. Nitel ( Kalitatif ) Talep Tahmin Yöntemleri	6
1.4.1.1. Delphi Tekniği	6
1.4.1.2. Uzmanların Görüşleri Yöntemi	7
1.4.1.3. Pazar Araştırması Yöntemi	8
1.4.1.4. Satış Elemanlarının Görüşleri Yöntemi	8
1.4.1.5. Yaşam Eğrilerinin Benzeşimi Yöntemi	8
1.4.2. Nicel ( Kantitatif ) Talep Tahmin Yöntemleri	10
1.4.2.1. İlişkiye Dayalı ( Nedensel ) Yöntemler	10
1.4.2.2. Zaman Serisi Yöntemleri	13
1.4.3. Yapay Zeka Tabanlı Yöntemler	21

1.5.	TAHMİN DOĞRULUĞUNUN ÖLÇÜMÜ	21
1.6.	TALEP TAHMİN YÖNTEMİNİN SEÇİMİ	22

## **İKİNCİ BÖLÜM**

### **YAPAY SİNİR AĞLARI**

2.1.	YAPAY ZEKÂ	24
2.1.1.	Yapay Zekâ Kavramı	24
2.1.2.	Yapay Zekâ Teknikleri	25
2.2.	YAPAY SİNİR AĞLARINA GİRİŞ	28
2.2.1.	Yapay Sinir Ağları Tanımı	28
2.2.2.	Yapay Sinir Ağları Genel Özellikleri	29
2.2.3.	Yapay Sinir Ağlarının Tarihçesi	30
2.3.	YAPAY SİNİR AĞLARI YAPISI VE TEMEL ELEMANLARI	31
2.3.1.	Biyolojik Sinir Hücreleri	31
2.3.2.	Yapay Sinir Hücresi	32
2.3.3.	Yapay Sinir Hücresinin Çalışma İlkesi	37
2.3.4.	Yapay Sinir Ağının Yapısı	38
2.4.	YAPAY SİNİR AĞLARINDA ÖĞRENME	39
2.4.1.	Öğrenme Yöntemleri	39
2.4.1.1.	Danışmanlı Öğrenme	40
2.4.1.2.	Destekleyici Öğrenme	40
2.4.1.3.	Danışmansız Öğrenme	41
2.4.2.	Öğrenme Kuralları	42
2.4.2.1.	Hebb Kuralı	43
2.4.2.2.	Hopfield Kuralı	43
2.4.2.3.	Delta Kuralı	44
2.4.2.4.	Kohonen Kuralı	44
2.5.	YAPAY SİNİR AĞI MODELLERİ	45
2.5.1.	Tek Katmanlı Algılayıcılar	45
2.5.1.1.	Basit Algılayıcı Modeli ( Perseptron )	46
2.5.1.2.	Adaline/Madaline Modeli	48

2.5.2.	Çok Katmanlı Algılayıcı ( Geriye Yayım ) Modeli	48
2.5.2.1.	Çok Katmanlı Algılayıcı Ağının Çalışma Prosedürü	51
2.5.2.2.	Çok Katmanlı Algılayıcı Ağının Eğitilmesi	52
2.5.2.3.	ÇKA Ağının Oluşturulmasında Önemli Noktalar	54
2.5.3.	LVQ Modeli	58
2.5.4.	ART Ağları Modeli	60
2.6.	YAPAY SİNİR AĞLARININ UYGULAMA ALANLARI	61
2.7.	YAPAY SİNİR AĞLARININ AVANTAJLARI VE DEZAVANTAJLARI	66
2.8.	YAPAY SİNİR AĞLARI VE TALEP TAHMİNİ	69

## ÜÇÜNCÜ BÖLÜM

### UYGULAMA

3.1.	TÜRKİYE'DE PETROKİMYA SANAYİ VE PETKİM	73
3.2.	TALEP TAHMİNİ PROBLEMİNİN TANIMLANMASI	77
3.3.	UYGULAMADA ELE ALINACAK ÜRÜNÜN TANITILMASI	80
3.4.	YAPAY SİNİR AĞI MODELİ VERİ TASARIMI	81
3.5.	YAPAY SİNİR AĞI MİMARİSİ	83
3.6.	YAPAY SİNİR AĞININ EĞİTİLMESİ	86
3.7.	SONUÇLARIN TEST EDİLMESİ	90
3.8.	ÇOKLU DOĞRUSAL REGRESYON ANALİZİ İLE KIYASLAMA	93
	SONUÇ	97
	KAYNAKÇA	99
	EKLER	



## KISALTMALAR

<b>ADALINE</b>	Adaptif Doğrusal Eleman
<b>ARMA</b>	Otoregresif Hareketli Ortalama
<b>ARIMA</b>	Birleştirilmiş Otoregresif Hareketli Ortalama
<b>ART</b>	Adaptif Rezonans Teori
<b>ÇKA</b>	Çok Katmanlı Algılayıcı
<b>DARPA</b>	ABD Savunma Bakanlığı İleri Araştırma Projeleri Ajansı
<b>GRNN</b>	Genel Regresyon Ağları
<b>GSYİH</b>	Gayri Safi Yurtiçi Hasıla
<b>LVQ</b>	Vektör Kuantizasyon Modelleri
<b>MADALINE</b>	Çoklu Adaptif Doğrusal Eleman
<b>MHS</b>	Mamul Hayat Seyri
<b>HKO</b>	Hata Kareleri Ortalaması
<b>OH</b>	Ortalama Hata
<b>OHKK</b>	Ortalama Hata Kareleri Kökü
<b>OMH</b>	Ortalama Mutlak Hata
<b>OMYH</b>	Ortalama Mutlak Yüzde Hata
<b>PE</b>	Polietilen
<b>PNN</b>	Olasılık Tabanlı Yapay Sinir Ağları
<b>PP</b>	Polipropilen
<b>PVC</b>	Polivinil Klorür
<b>RBN</b>	Radyal Temelli Ağlar
<b>SOM</b>	Kendi Kendini Organize Eden Model
<b>TÜİK</b>	Türkiye İstatistik Kurumu
<b>VCM</b>	Vinil Klorür Monomer
<b>YSA</b>	Yapay Sinir Ağları

## TABLolar LİSTESİ

Tablo 1: Nitel Talep Tahmin Yöntemlerinin Karşılaştırılması	s.9
Tablo 2: Toplama Fonksiyonu Örnekleri	s.35
Tablo 3: Momentum Katsayısının Farklı Değerleri için 2011 Yılı Tahmin Sonuçları	s.85
Tablo 4: Öğrenme Katsayısının Farklı Değerleri için 2011 Yılı Tahmin Sonuçları	s.85
Tablo 5: Ara Hücre Sayısının Farklı Değerleri için 2011 Yılı Tahmin Sonuçları	s.86
Tablo 6: Çevrim Sayısının Farklı Değerleri için 2011 Yılı Tahmin Sonuçları	s.86
Tablo 7: 2011 Yılı YSA Öngörü Performansının Ölçümü	s.91
Tablo 8: Regresyon Analizi Anova Testi Sonucu - 1	s.94
Tablo 9: Regresyon Model Özeti - 1	s.94
Tablo 10: Regresyon Analizi Katsayı Anlamlılık Testi Sonuçları	s.94
Tablo 11: Regresyon Analizi Anova Testi Sonucu - 2	s.95
Tablo 12: Regresyon Model Özeti - 2	s.95
Tablo 13: 2011 Yılına İlişkin Modellerin Tahmin Sonuçları	s.96
Tablo 14: Modellerin Doğruluk Ölçüleri	s.96

## ŞEKİLLER LİSTESİ

Şekil 1: Biyolojik Sinir Hücresi	s.32
Şekil 2: Biyolojik ve Yapay Sinir Ağları	s.32
Şekil 3: Yapay Sinir Hücresinin Yapısı	s.33
Şekil 4: Aktivasyon Fonksiyonu Örnekleri	s.36
Şekil 5: Bir Yapay Sinir Hücresinin Çalışması Örneği	s.37
Şekil 6: YSA'ların Genel Yapısı	s.38
Şekil 7: Danışmanlı Öğrenme Yapısı	s.40
Şekil 8: Destekleyici Öğrenme Yapısı	s.41
Şekil 9 : Danışmansız Öğrenme Yapısı	s.42
Şekil 10: Tek Katmanlı Algılayıcı Modeli	s.45
Şekil 11: Basit Algılayıcı Yapısı	s.47
Şekil 12: Adaline Ünitesi	s.48
Şekil 13: ÇKA Modeli	s.50
Şekil 14: Çok Boyutlu Hata Uzayı	s.52
Şekil 15: ÇKA Ağının Öğrenme Eğrisi	s.54
Şekil 16: ÇKA Ağlarında Başlangıç Noktasının Etkisi	s.55
Şekil 17: : LVQ Ağının Topolojik Yapısı	s.59
Şekil 18: ART Ağının Genel Yapısı	s.61
Şekil 19: Yapay Sinir Ağları Yöntemi ve Geleneksel Yöntemlerle Talep Tahmini Adımları	s.72
Şekil 20: 2011 Yılı Satış Miktarlarının Ürün Bazında Dağılımı	s.79
Şekil 21: EasyNN Programı Katman ve Hücre Sayısının Belirlenmesi	s.87
Şekil 22: EasyNN Programı Parametre Tanımlama Ekranı	s.88
Şekil 23: Ağ Yapısı	s.89
Şekil 24: Ağın Öğrenme Grafiği	s.89
Şekil 25: Ağın Tahmin Grafiği	s.90
Şekil 26: Duyarlılık Analizi Sonuçları	s.92

## **EKLER LİSTESİ**

<b>EK 1</b> : Süspansiyon Polimerizasyonu ile PVC Üretim Süreci	ek s.1
<b>EK 2</b> : PVC Ürün Türleri Karakteristik Özellikleri	ek s.2
<b>EK 3</b> : Yapay Sinir Ağı Modeli Veri Seti	ek s.4

## GİRİŞ

İşletmeler artan rekabet koşulları altında ayakta kalabilmek ve rekabet edebilmek için karşılaştıkları çeşitli sorunlara ilişkin etkin kararlar almak zorundadır. Geleceğe ilişkin verilecek kararlar belirsizlikler içerdiğinden, bu kararların alınmasında çeşitli tahminlerin geliştirilmesi gerekir. Bunlardan birisi de talep tahminidir.

Son yıllarda tahminleme alanında bazı yeni teknikler ön plana çıkmaktadır. Yapay sinir ağları ( YSA ), bu yeni teknikler arasında en önemlilerden birisidir. YSA tekniği günümüzde birçok alanda yaygın şekilde kullanılmaktadır. Basit bir şekilde insan beyninin çalışma şeklini taklit eden YSA'lar Yapay Zeka çalışmaları içerisinde önemli bir yere sahiptir. YSA tekniği veriden öğrenebilme, genelleme yapabilme, sınırsız sayıda değişkenle çalışabilme vb. birçok önemli özelliğe sahiptir. Bu özellikleri sayesinde oldukça önemli avantajlar sağlayan YSA tekniği etkin bir talep tahmin yöntemi olarak öne çıkmaktadır.

Bu tez kapsamında yapay sinir ağları tanıtılarak Petkim'de termoplastik ürünlerden Polivinil Klorür ( PVC ) ürünü üzerine tahmin çalışması yapılmıştır.

Birinci bölümde belli başlı tahmin yöntemleri teorik olarak anlatılmıştır. Tahmin yöntemleri nitel, nicel ve yapay zeka tabanlı olmak üzere üç gruba ayrılmıştır. Uygulamada en çok kullanılan tahmin yöntemleri anlatıldıktan sonra, bu yöntemlerin performanslarının ölçüldüğü kriterler, formülleri ve açıklamalarına yer verilmiştir.

İkinci bölümde yapay sinir ağları detaylı bir şekilde yer almıştır. Öncelikle yapay zeka kavramı ve belli başlı yaklaşımlardan genel olarak bahsedilmiştir. Daha sonra yapay sinir ağlarında öğrenme ve yapay sinir ağları modelleri hakkında bilgiler verilmiş, bu tez kapsamında kullanılacak olan Çok Katmanlı Algılayıcı Modeli ayrıntılı olarak açıklanmıştır.

Uygulama bölümünde ise, öncelikle Türkiye'de Petrokimya Sanayi ve Petkim hakkında genel bilgi verilmiştir. Uygulama kapsamında ele alınan PVC ürününün özelliklerinden bahsedilmiş ve yapay sinir ağı tekniği kullanılarak talep tahmini yapılmıştır. Ayrıca, çoklu doğrusal regresyon analizi ile de talep tahmini yapılarak sonuçlar kıyaslanmıştır.

## BİRİNCİ BÖLÜM TALEP TAHMİNİ

### 1.1. TALEP TAHMİNİ KAVRAMI

Talep, piyasalarda belirli bir mal veya hizmete yönelen, gerçek bir satın alma gücüyle desteklenmiş olan mal alma isteğidir. Tek alıcının talebi, belirli bir anda belirli bir maldan muhtemel her fiyattan satın almak istediği mal miktarıdır. Bir malın piyasa talebi ise, tüm alıcıların belirli bir anda söz konusu maldan muhtemel her fiyattan satın almak istedikleri miktarlardır.<sup>1</sup>

Talep tahmini ise, gelecekteki bir zaman süresi için talep edilecek mal ve hizmetlerin düzeyinin önceden kestirilmesidir. Gelecekteki mal ve hizmet talebinin tahminlenmesi, işletmedeki tüm öngörülerin başlangıç noktasını oluşturmakta ve diğer fonksiyonlara temel girdiyi sağlamaktadır.<sup>2</sup>

Üretim/işlemler yönetiminde talep tahmini yapılması, müşteri talebini belirleme ve buna bağlı olarak oluşturulacak üretim planı açısından büyük bir öneme sahiptir. Müşteri talebinin tahmin edilmesi ne kadar ürünün, ne kadar hammadde, işgücü ve diğer üretim faktörleri kullanılarak üretileceğinin planlanması ve ne kadar stok bulundurulacağına tespit edilmesi bakımından işletme yöneticilerine stratejik kararlarında yol gösterici olacaktır.<sup>3</sup>

Talep tahmininin önemini, başarısız bir talep tahminlemesinin sonuçlarına bakarak anlayabiliriz:<sup>4</sup>

- Müşterilerin talebinin, tahmin edilenden daha fazla olması durumunda talep karşılanamayacaktır. Bu durumda hem müşteri kayıpları yaşanabilecek hem de satış gelirlerinde düşüş olacaktır.
- Müşterilerin talebinin, tahmin edilenden daha düşük olması durumunda ise fazladan üretim yapılmış olacaktır. Bu da hem stokları hem de stok tutma maliyetini artırarak, karlılığı düşürecek ve nakit akışını azaltacaktır.

<sup>1</sup> Hasan Eski, **Ekonomiye Giriş**, 4. Baskı, DEÜ Mühendislik Yayınları, İzmir, 2005, s.62.

<sup>2</sup> Muammer Doğan, **İşletme Ekonomisi ve Yönetimi**, Nobel Yayınları, İzmir, 2007, s.104.

<sup>3</sup> Mehmet Soysal ve Mine Ömürganülşen, "Türk Turizm Sektöründe Talep Tahmini Üzerine Bir Uygulama", **Anatolia: Turizm Araştırmaları Dergisi**, Cilt:21, Sayı:1, 2010,s.130.

<sup>4</sup> Colleen Crum ve George E.Palmatier, **Demand Management Best Practices**, J.Ross Publishing, USA, 2003, p.17.

Talep tahminlemede yardımcı olacak birçok yöntem geliştirilmiştir. Ancak, öngörüleme yönteminin kullanılacak duruma göre dikkatlice seçilmesi gerekir. Tüm durumlar için genel bir tahminleme yöntemi yoktur. Ayrıca, hangi yöntem kullanılırsa kullanılsın, yapılan tüm talep tahminlerinin belirli bir doğruluk derecesi söz konusudur ve hiçbir tahmin %100 doğruluk derecesine sahip olamaz. Tahminlemede önemli olan eldeki bilgilerle geleceğe ilişkin kesin öngörülerde değil, geliştirilmiş tahminleme tekniklerinden yararlanarak en az hatalı tahminlerde bulunmaktır.<sup>5</sup>

Talep tahminleri; zaman aralığı, kullanım amacı, mamul cinsi, hesaplama tekniği gibi çeşitli kriterlere göre sınıflandırılır. En çok kullanılan sınıflandırma kriteri ise zaman aralığıdır. Zaman aralığı kriterine göre sınıflandırmada yer alan talep tahmin türleri şunlardır:<sup>6</sup>

- *Çok kısa vadeli tahminler*: Haftalık ve günlük olabilir. Parça, malzeme ve yarı mamul stoklarının kontrolü veya montaj hattı iş programlarının oluşturulması amacıyla yapılır.
- *Kısa vadeli tahminler*: Genellikle 3 - 6 aylık bir süreyi kapsar. En uygun imalat parti hacimleri, tedarik zamanları ve sipariş miktarlarını belirlemede kullanılır. Ayrıca, makinelere iş yükleme ve işgücü ihtiyacını tespit etme amacıyla da hazırlanır.
- *Orta vadeli tahminler*: 6 aydan başlayarak 5 yıla kadar uzanan bir süreyi kapsayabilir. Tedarik süresi belirsiz veya uzun olan malzeme alımlarını yapma, üretim prosesi karmaşık imalat faaliyetlerinin, talebi mevsimsel dalgalanma gösteren mamul stoklarının planlanması amacıyla yapılır.
- *Uzun vadeli tahminler*: 5 yıl ve daha uzun süreler için yapılır. İşletme tesislerini genişletme, yeni makineler alma gibi konularda yapılır.

## 1.2. TALEP TAHMİN PRENSİPLERİ

Talep tahminlerinde göz önünde bulundurulması gereken ilkelerden bazılarını şöyle ifade edebiliriz:<sup>7</sup>

- Miktar veya çeşit bakımından büyük olan gruplar için yapılan talep tahminleri daha duyarlıdır.

---

<sup>5</sup> Doğan, s.105.

<sup>6</sup> Bülent Kobu, **Üretim Yönetimi**, 14. Baskı, Beta Basım, İstanbul, 2008, s.111.

<sup>7</sup> Kobu, s.113.

- Tahminlerin kapsadığı zaman aralığı kısaltıldıkça duyarlık artar.
- Her talep tahmin çalışmasında sapmaları belirlemek üzere hata hesaplamalarının yer alması gerekir.
- Herhangi bir talep tahmin çalışmasının sonuçlarını uygulamadan önce kullanılan talep tahmin yöntemine ilişkin geçerlik testi yapılmalıdır.

### 1.3. TALEP TAHMİN AŞAMALARI

Talep tahmini süreci temel olarak şu aşamalardan oluşmaktadır: <sup>8</sup>

- Talep tahmininin amacının belirlenmesi: Faydalanılacak tahmin metodunun verimli kullanımına yönelik olarak, talep tahminin ne zaman kullanılacağı, istenilen doğruluk derecesi, gerekli detay seviyesi gibi faktörlerin belirlenmesi gerekir. Bu aşamada amaçların net bir şekilde belirlenmesi bundan sonraki aşamalar açısından büyük bir önem taşır. <sup>9</sup>
- Tahmin periyodunun belirlenmesi: Talep araştırması sonuçlarının kullanılış amacı ile periyodun uzunluğu arasında yakın bir ilişki vardır. Örneğin, haftalık yapılan tahminlerin uzun dönemlerde kullanılması yanıltıcı olabilir. <sup>10</sup>
- Verilerin toplanması: Tahminleme çalışmasının geçerliliğini etkileyen çok önemli bir aşamadır. İşe yarayacak bilgilerin toplanması işletmedeki kayıt sistemine bağlıdır. Geçmişe ait satış, tedarik, işlem zamanı ve maliyet kayıtları olmadan geleceği tahmin etmek son derece güçtür. Öte yandan tahminleme amaçları göz önüne alınarak toplanacak verilerin cinsi, kapsamı ve ayrıntısı konusunda doğru karar verilmelidir. <sup>11</sup>
- Tahmin yönteminin seçimi: Talep tahmini, çevresel ve iç etkenlere bağlı olarak oldukça karmaşık bir problemdir. Tahminlemede yardımcı olacak çeşitli yöntemler geliştirilmiştir. Bu yöntemler kalitatif ve kantitatif olmak üzere iki gruba ayrılmaktadır. Kantitatif ( Nicel ) tahmin yöntemleri, istatistiksel ve matematiksel verilere dayanır. Kalitatif ( Nitel ) tahmin yöntemleri ise sayısal

---

<sup>8</sup> Jay Heizer ve Barry Render, **Operations Management**, Seventh Edition, Pearson International Edition, 2004, p.106.

<sup>9</sup> Douglas C. Montgomery ve diğerleri, **Introduction to Time Series Analysis and Forecasting**, John Wiley&Sons Inc., 2008, p.12.

<sup>10</sup> Kobu, s.114.

<sup>11</sup> Kobu, s.114.



verilerden çok tecrübenin uygulanmasına, yargıya ve zekaya dayanır. İdeal talep tahmin yöntemi ise bu iki yöntemin karışımıdır.<sup>12</sup>

- Tahmininin yapılması ve sonuçlarının geçerliliğinin araştırılması: Tahmin sonuçlarının gerçek değerlerle kıyaslanarak aradaki farkların sistematik bir şekilde incelenmesi gerekir. Tahmin modeli, varsayımların ve verilerin geçerliliği araştırılmalıdır. Geçerlilik test edildikten sonra tahmin çalışmasının sonuçları uygulanabilir.<sup>13</sup>

#### 1.4. TALEP TAHMİN YÖNTEMLERİ

Öngörüleme yöntemleri, literatürde farklı şekilde sınıflandırılmasına rağmen temelde iki grupta ele alınmaktadır:<sup>14</sup>

- Nitel ( Kalitatif ) Yöntemler
- Nicel ( Kantitatif ) Yöntemler

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 doğuracağı konusuna yoğunlaşmaktadır.<sup>15</sup> Bazı işletmeler nitel tahmin yöntemlerini kullanırken bazıları ise nicel tahmin yöntemlerini kullanmaktadır. Uygulamada, nitel ve nicel yöntemlerin birlikte kullanılması çoğunlukla daha etkili sonuçlar vermektedir.<sup>16</sup>

Talep tahmini çalışmalarında son zamanlarda karmaşık problemlerin çözümünde yapay zeka tabanlı yöntemler kullanılmaktadır. Yeni nesil tahmin yöntemleri olmaları dolayısıyla tahmin yöntemleri başlığı altında bu tekniklere kısaca değinilecek, ikinci bölümde ise detaylı şekilde ele alınacaktır.

---

<sup>12</sup> Montgomery ve diğerleri, p. 3.

<sup>13</sup> Heizer ve Render, p.106.

<sup>14</sup> Doğan, s.106.

<sup>15</sup> Brian H. Archer, "Forecasting Demand: Quantative and Intuitive Techniques", **International Journal of Tourism Management**, Vol.1, No.1,1980, p.177.

<sup>16</sup> Heizer ve Render, p.106.

### 1.4.1. Nitel ( Kalitatif ) Talep Tahmin Yöntemleri

Nitel tahmin yöntemleri, çalışma alanı konusunda uzman kabul edilen kişilerin yargılarına ve deneyimlerine dayanır. Bu yöntemlerde bilgi işleme süreci uzmanlar veya jüri üyeleri tarafından gerçekleştirilir. Beklentileri ifade etmeleri ve dolayısıyla sübjektif yargılara bağlı olmaları nedeniyle, nicel yöntemler gibi tekrarlanamayan, sonuçları tartışmaya açık yöntemler olsa da, nitel yöntemlerin kullanılmasını zorunlu kılan birtakım nedenler vardır. Bu nedenler şu şekilde sıralanabilir:

- Geçmişe yönelik yeterli verinin bulunmaması
- Mevcut zaman serilerinin güvenilir ya da geçerli olmaması
- Makro çevrenin çok hızlı değişmesi
- Çevresel etkiler bakımından büyük etkiler beklenmesi
- Uzun dönem tahminlerine ihtiyaç duyulması

Yukarıda bahsedilen durumlarda kullanılabilen nitel tahmin yöntemlerinin en önemli avantajlarıdır. Bunlara ilave olarak; genellikle ucuz olmaları ve üstün istatistiksel yeteneklere ihtiyaç duymamaları da nitel yöntemin avantajları arasında sayılabilir. Ancak, seçilen jüri üyelerinin deneyimlerinin yetersizliği, kendi düşüncelerini tahminlere yansıtma olasılığı, geleceğe ilişkin beklentiler nedeniyle tahminlerin etkilenmesi, nitel yöntemlerin dezavantajlarıdır.<sup>17</sup>

#### 1.4.1.1. Delphi Tekniği

Geleceğe ilişkin tahminler yapmada yararlanılan bir yöntemdir. Organizasyonda bir sorunun çözümü için uzman kişilerin yüz yüze görüşmeler ve tartışmalar yapmadan bir konu hakkında karar vermelerine ve uzlaşmalarına imkân sağlar.<sup>18</sup> Örgüt içinden veya dışından birtakım uzmanlar hazırlanmış olan sorulara yazılı olarak fikirlerini belirtmekte ve daha sonra karşılıklı olmayan bir panel şeklinde cevaplar tüm katılımcılara duyurulmakta ve süreç, soru ve cevaplarla uzlaşma sağlanana kadar devam etmektedir. Koordinatör, her katılımcıyla temas kurmakta ve hazırlanmış olan soru formlarını göndermekte ve görüş birliğine varılana kadar turlar

<sup>17</sup> Douglas C. Fretchling, **Forecasting Tourism Demand: Method and Strategies**, Butterworth - Heinemann, 2001, p.212.

<sup>18</sup>Coşkun C. Aktan, "Geleceği Kazanmanın Yolu: Stratejik Yönetim", <http://www.tkgm.gov.tr/turkce/dosyalar/diger%5Cicerikdetaydh278.pdf>, (28.10.2011), s.9.

devam etmektedir. Katılımcılar uzlaşma sağladıklarında yöntem sonuçlanır ve görüş birliği sağlanan öngörü kabul edilir.<sup>19</sup>

Delphi tekniğinin bazı üstünlük ve sınırlılıklarından bahsedebiliriz:<sup>20</sup>

Üstünlükleri:

- Bireylerin yüz yüze gelmelerinden doğabilecek sorunlar en alt düzeye indirilmektedir. Bu şekilde bireyler düşüncelerini, diğerlerinin baskısına maruz kalmadan serbestçe ifade edebilmektedir.
- Bu teknik, katılımcıların zaman, mekan, uzaklık, maliyet gibi faktörler nedeniyle sıklıkla toplanma olasılığının olmadığı durumlarda önemli avantajlar sağlamaktadır.
- Delphi tekniği, farklı bilgi, beceri ve deneyimler yardımıyla bireylerin farklı bakış açılarıyla sorunların ilgili kısımlarına katkıda bulunmalarına fırsat tanımaktadır.

Yöntemin eksik yönleri ise; başarının uzmanların seçimine bağlı olması, sonuçların geri bildiriminin zaman alması, sürecin uzamasıyla birlikte katılımın azalması olarak özetlenebilir.

#### **1.4.1.2. Uzmanların Görüşleri Yöntemi**

İşletmede karar yetkisine sahip üst düzey yöneticilerin, uzmanların, tecrübeli kişilerin düşünceleri ve kişisel değerlendirmeleri birleştirilerek talep tahmini elde edilir. Görüşlerin tahmin sürecine aktarılmasında; kişilerle doğrudan tek tek konuşma, geleneksel toplantılar yaparak ortak bir görüşe varma, beyin fırtınasıyla sonuca ulaşma gibi çeşitli yollar kullanılmaktadır. Bu yöntemin üstünlükleri olarak şunları sayabiliriz:<sup>21</sup>

- Kısa sürede hazırlanabilirler.
- Kantitatif yetenek gerekmez.
- Her ortamda uygulanabilir.
- Bilgisayar desteğine gerek duymaz.
- Geçmişe dayalı veriler kullanılabilir.

---

<sup>19</sup> Doğan, s.109.

<sup>20</sup> Ali E. Şahin, " Eğitim Araştırmalarında Delphi Tekniği ve Kullanımı ", **Hacettepe Üniversitesi Eğitim Fakültesi Dergisi**, Cilt : 21, Sayı:20, 2001, s.219.

<sup>21</sup> Ofer Zwikael ve diğerleri, " Evaluation of Models for Forecasting Sales ", **Project Management Journal**, Vol.31, No.1, 2000, p.27.

### 1.4.1.3. Pazar Araştırması Yöntemi

Pazar koşullarına ilişkin verileri toplamak amacıyla yapılan araştırmalar, paneller, anketler gibi çalışmaları kapsar. Pazar araştırması ve tüketici davranışlarının analizi pazar talebini öngörülmemede önemli bilgiler sağlamaktadır. Bu yöntem sadece tahmin yapma konusunda değil aynı zamanda ürün tasarımını geliştirme ve yeni ürünler planlama çalışmalarında da yardımcı olmaktadır. Diğer taraftan, zaman alıcı ve yüksek maliyetli bir yöntemdir.<sup>22</sup>

### 1.4.1.4. Satış Elemanlarının Görüşleri Yöntemi

Müşteri ile doğrudan temas halinde olduğu ve pazardaki değişimleri yakından izlediği için firmanın satış ekibi sübjektif tahminde etkili bir kaynaktır. Satış elemanlarından belli bir zaman dilimi için tahmin yapmaları istenir. Yapılan tahminler birleştirilerek değerlendirilir ve son tahmin yapılır. Bu yöntemin avantajları; kullanılması ve anlaşılması basittir, kişilere hedef ve sorumluluk vermek kolaydır, bölge, ürün, müşteri ve satışı bazında bölümlendirme yapılabilir. En önemli dezavantajı ise; satış temsilcilerinin iyimser veya kötümser olmalarına bağlı olarak tahmin performansının sapma göstermesidir.<sup>23</sup>

### 1.4.1.5. Yaşam Eğrilerinin Benzeşimi Yöntemi

“Mamulün Hayat Seyri” (MHS) kavramı, bir işletmenin mamullerinin satışlarının zaman içindeki gelişimini, çeşitli dönemler veya aşamalar halinde inceleyen basit yapılı bir model olarak ifade edilebilir. Yaşam süresi, hayat eğrisi vb. isimlerle ifade edilen mamul hayat seyrinin dört ana aşaması vardır. Bunlar; sunuş, büyüme, olgunluk ve gerileme olarak sayılabilir.<sup>24</sup> Bu yöntemde, bir ürünün gelecekteki satışları, benzer ürünlerin yaşam eğrilerindeki çeşitli dönemlerdeki satışlara bakılarak tahmin edilmeye çalışılır. Özellikle, tüketicilere yeni sunulacak ürün veya hizmetlerin talep tahminini elde etmek amacıyla uygulanır.<sup>25</sup>

---

<sup>22</sup> Heizer ve Render, p.107.

<sup>23</sup> Jae K. Shim, **Strategic Business Forecasting**, Washington D.C., St. Lucie Press, 1999, p. 10.

<sup>24</sup> İsmet Mucuk, **Pazarlama İlkeleri**, 17. Baskı, Türkmen Kitabevi, 2009, s.139.

<sup>25</sup> Doğan, s.110.

Tablo 1’de nitel tahmin yöntemlerinin çeşitli kriterler açısından karşılaştırılması gösterilmektedir.

**Tablo 1:** Nitel Talep Tahmin Yöntemlerinin Karşılaştırılması

Kalitatif Yöntemler	Kullanım Alanları	Güvenilirlik			Maliyet
		Kısa Dönem	Orta Dönem	Uzun Dönem	
<i>Delphi</i>	Uzun dönemli satış Kapasite planlama Teknolojik tahmin	Orta İyi	Orta İyi	Orta İyi	Orta
<i>Uzman Görüşü</i>	Toplam satışlar Spesifik ürünler	Zayıf Orta	Zayıf Orta	Zayıf Orta	Düşük
<i>Pazar Araştırması</i>	Toplam satışlar Ürün grupları Spesifik ürünler	Çok iyi	İyi	Orta	Yüksek
<i>Satış Elemanlarının Görüşleri</i>	Toplam satışlar Ürün grupları Spesifik ürünler	Zayıf Orta	Orta İyi	Zayıf Orta	Orta
<i>Yaşam Eğrisi Benzeşimi</i>	Uzun dönemli satış Yeni ürün Tesis planlama	Zayıf Orta	Orta İyi	Orta İyi	Orta

Kaynak: J. Scott Armstrong, **Principles of Forecasting: A Handbook for Researchers and Practitioners**, Kluwer Academic Publishers, 2001, p.237.

### 1.4.2. Nicel ( Kantitatif ) Talep Tahmin Yöntemleri

Nicel yöntemler, geçmiş dönem gözlem değerlerine dayalı analizler yapan tahmin modellerini kapsamaktadır. Kullanılan yöntemler; incelenen değişkende gözlenen gelişmelerin analiz edilmesi, veri serisinin dinamik özelliklerinin belirlenmesi ve bu özelliklerin matematiksel bir fonksiyon ile ifade edilerek geleceğe ilişkin öngörüler türetilmesini içermektedir. Nicel tahmin yöntemleri genel olarak iki gruba ayrılmaktadır:<sup>26</sup>

- İlişkiye Dayalı ( Nedensel ) Yöntemler
- Zaman Serisi Yöntemleri

#### 1.4.2.1. İlişkiye Dayalı ( Nedensel ) Yöntemler

Nedensel ya da diğer adıyla ilişkiye dayalı tahmin yöntemlerinde; tahmini değeri bulunacak değişkenin çeşitli faktörlerden etkilendiği düşünülerek, bağımlı değişkenin etkilendiği ya da bağlı olabileceği diğer değişkenlerin tespitine çalışılmakta ve bu etkilerin formüle edilmesi amaçlanmaktadır. Nedensel yöntemlerde bir değişkenin gelecekteki değerlerini tahmin etmekten çok iki ya da daha fazla değişken arasındaki ilişki açıklanmaya çalışılmaktadır. Bağımlı değişken ile ilişkisi bulunan değişkenlerin tespit edilmesi ve bu ilişkinin matematiksel olarak ifade edilmesi bu yöntemin temel amacını oluşturur. İlişkiye dayalı tahmin yöntemlerinin temelini regresyon analizi ve korelasyon analizi oluşturmaktadır.<sup>27</sup>

Regresyon analizi, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkinin matematiksel olarak ifade edilmesini sağlayan istatistiksel bir tekniktir. Regresyon denklemi yardımıyla bağımlı değişken ile bağımsız değişken veya değişkenler arasında ilişki kuran parametrelerin değerleri tahmin edilir. Bağımlı değişkeni etkileyen bağımsız değişkenlerin tahmin edilmesi, bu değişken üzerinde geliştirilecek plan ve politikalarda hangi değişkenin önem kazandığının belirlenmesine yardımcı olmaktadır. Bu teknik sayesinde, hangi faktörlerde nasıl bir değişiklik yapılarak bağımlı değişkende artış veya azalış meydana gelebileceğini ortaya çıkarılabilmektedir.<sup>28</sup>

<sup>26</sup> Heizer ve Render, p.107.

<sup>27</sup> Neyran Orhunbilge, **Uygulamalı Regresyon ve Korelasyon Analizi**, Avcıol Basım Yayın, İstanbul, 2002, s.3.

<sup>28</sup> Montgomery ve diğerleri, p. 73.

Regresyon analizi, kullanılan bağımsız değişken sayısına göre;

- Basit regresyon analizi ( Tek bağımsız değişken ),
- Çoklu regresyon analizi ( Birden çok bağımsız değişken ),  
Fonksiyon tipine göre;
- Doğrusal regresyon analizi,
- Doğrusal olmayan regresyon analizi,  
Verilerin kaynağına göre;
- Anakütle verileriyle regresyon analizi,
- Örnek verileriyle regresyon analizi olmak üzere üç grupta toplanabilir.<sup>29</sup>

Ana kütle için basit doğrusal regresyon denklemi aşağıdaki gibi yazılır;

$$Y = \beta_0 + \beta_1 x + \varepsilon \quad (1.1)$$

Bu denklemde  $\beta_0$ ,  $x = 0$  olduğunda regresyon doğrusunun dikey eksenini kestiği noktayı göstermektedir.  $\beta_1$  doğrusal fonksiyonun eğimi, yani bağımsız değişken  $x$  ' deki bir birimlik değişiminin bağımlı değişken  $Y$  ' de ne kadar bir değişim meydana getirdiğini gösteren regresyon katsayısıdır.  $\varepsilon$ , rassal ( tesadüfi ) hata terimidir.  $\varepsilon = Y - \hat{Y}$  'dir.  $\hat{Y}$ , tahmini bağımlı değişkenin değerini gösterir. Gerçek hayattaki uygulamalarda  $\beta_0$  ve  $\beta_1$  değerleri bilinmiyorsa, ana kütlede örnekler alınarak bunların tahminçileri olan,  $b_0$  ve  $b_1$  kullanılarak ( 1.1 ) nolu denklem,

$$y = b_0 + b_1 x + \varepsilon \quad (1.2)$$

olarak yazılır.

Anakütle ve örnek için çoklu doğrusal regresyon denklemleri ise sırasıyla,

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (1.3)$$

$$y = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_n x_n + \varepsilon \quad (1.4)$$

şeklinde ifade edilmektedir.<sup>30</sup>

Basit doğrusal regresyon denklemindeki  $b_0$  ve  $b_1$  katsayılarını bulabilmek için en küçük kareler metodundan yararlanılır. En küçük kareler metoduna göre, bir zaman serisine en iyi uyan başka bir deyişle bir değerler serisini en iyi ifade eden doğru veya eğri, geçmiş yıllara ait formülün uygulanması ile bulunacak teorik değerler arasındaki farkların karelerinin toplamını minimum yapan doğru veya eğridir. Denklemdeki  $b_0$  ve  $b_1$  katsayıları aşağıdaki hesaplamalar ile bulunur.<sup>31</sup>

<sup>29</sup> Orhunbilge, s.12.

<sup>30</sup> Bovas Abraham ve Johannes Ledolter, **Statistical Methods for Forecasting**, John Wile&Sons Inc., 2005, p. 10.

<sup>31</sup> Kobu, s.118.

$$b_1 = \frac{n(\sum XY) - (\sum X)(\sum Y)}{n(\sum X^2) - (\sum X)^2} \quad (1.5)$$

$$b_0 = \frac{(\sum Y) - b_1(\sum X)}{n} \quad (1.6)$$

Regresyon analizi değişkenler arasındaki ilişkinin niteliğini saptamayı amaçlarken, korelasyon analizi değişkenler arasındaki ilişkinin derecesi ile ilgilenir. Korelasyon analizi; iki değişken arasındaki doğrusal ilişkiyi veya bir değişkenin iki veya daha çok değişken ile olan ilişkisini test etmek, varsa bu ilişkinin derecesini ölçmek için kullanılan istatistiksel bir yöntemdir. Analizin en önemli varsayımı değişkenler arasındaki ilişkinin doğrusal olduğudur. Korelasyon katsayısı “ r “ ile gösterilir ve “ 1 “ ile “ -1 “ arasında değer alır. Pozitif işaret taşıyan r, bağımlı ve bağımsız değişkendeki artış ve azalışın aynı yönde olduğu, negatif işaret taşıyan r ise biri artarken diğersinin azaldığını gösterir. Korelasyon katsayısının 1’e yaklaşması güçlü, sıfıra yaklaşması ise zayıf ilişki olduğunu belirtir. Korelasyon katsayısı aşağıdaki formül yardımıyla hesaplanır.

$$r = \frac{n(\sum XY) - (\sum X)(\sum Y)}{\sqrt{[n(\sum X^2) - (\sum X)^2][n(\sum Y^2) - (\sum Y)^2]}} \quad (1.7)$$

Korelasyon katsayısının yorumunda düşülen hatalardan biri şudur: Sadece r değerine bakarak iki değişken arasında kuvvetli bir sonuç ilişkisi bulunduğu çıkarılırsa, değişkenlerden birinin neden diğersinin sonuç olarak kabul edilmesi yoluna gidilir. Böyle bir yorum bazen doğru olmakla birlikte, çoğu kez hatalı sonuçlara varmamıza neden olabilir. Burada iki değişken arasında hesaba katılmayan başka değişkenler dikkate alınarak çok değişkenli korelasyon hesaplama yöntemlerine başvurulur.<sup>32</sup>

Korelasyon katsayısının karesine, “ belirlilik ( determinasyon ) katsayısı “ denir. Belirlilik ( determinasyon ) katsayısı, bir değişkenin diğer değişkene hangi oranda bağlı olduğunu gösteren, diğer bir ifadeyle bir değişkendeki değişimlerin yüzde kaçının diğer değişken tarafından açıklanacağını belirten katsayıdır. Bu katsayı, 0 ile 1 arasında değer alır.<sup>33</sup>

<sup>32</sup> Kobu, s.119.

<sup>33</sup> Heizer ve Render, p.129.



### 1.4.2.2. Zaman Serisi Yöntemleri

Zaman serisi yöntemleri, bir olaya ait geçmişteki verilerin incelenmesi ve belirli eğilimlerin ortaya çıkarılarak ileriye yönelik tahminlerin yapılması esasına dayanmaktadır. Bu yöntemlerin amacı, geçmiş gözlem değerlerindeki veri kalıplarını kullanarak istatistiksel modeller kurmak ve bu modellerle geleceği tahmin etmektir. Ekonomi ve iş dünyasındaki belirsizlikler nedeniyle, zaman serilerinin gelecekte göstereceği seyri tahmin etmek planlama ve karar alma açısından çok önemlidir. Zaman serisi yöntemlerinde geleceğin tahmini yanında geçmiş dönemlerin incelenmiş olması; geçmişteki olumlu ve olumsuz gelişmelerin tespit edilmesine, nedenlerinin araştırılmasına ve yapılan yanlışların tekrar edilmemesi için gerekli tedbirlerin alınmasına da imkân sağlar. Bu özellikleri nedeniyle özellikle orta ve kısa vade talep tahminlerine ihtiyaç duyulan her alanda yaygın olarak kullanılır.<sup>34</sup>

Zaman serisi, ardışık ve eşit aralıklı zamanlarda bir bağımsız değişkenin aldığı değerleri gösteren küme olarak tanımlanabilir. Zaman birimi olarak konunun gereğine göre yıl, ay, üç ay, hafta, gün gibi dönemler alınabilir. Örneğin, geçmiş aylık veya üçer aylık dönemler itibarıyla bir işletmenin satış veya üretim miktarları bir zaman serisini oluşturur. Zaman serisi analizinde geleceğin tahmini geçmişe ait bilgilere dayanılarak yapıldığından söz konusu olayda geçmişteki davranış biçiminin gelecekte de devam edeceği varsayılır. Zaman serisinin gözlem değerlerinde, zaman içinde artma veya azalma şeklinde değişimler görülebilir. Bir zaman serisi analizinde kullanılan geçmişe ait bilgilerde değişmelere neden olan dört eleman vardır:<sup>35</sup>

- *Trend bileşeni:* Zaman serisi gözlem değerinin uzun dönemde artma ya da azalma şeklinde gösterdiği genel eğilime "trend" adı verilir. Bu bileşen, zamana bağlı değişken üzerindeki genel eğilime neden olan uzun dönemli etkileri açıklar.
- *Mevsimsel değişimler:* Birbirini izleyen yılların, çeyrek yılların, mevsimlerin ve ayların aynı dönemlerine ait gözlem değerlerindeki artış veya artış şeklinde ortaya çıkan düzenli değişimleri ifade eder. Bu değişimleri oluşturan nedenler arasında iklim, alışkanlıklar, sosyal olaylar vb. sayılabilir.

---

<sup>34</sup> James D. Blocher ve diğerleri, **Forecasting: Including An Introduction To Forecasting Using The SAP R/3 System**, Indiana University Kelly School of Business, Indiana, 2004, p.8.

<sup>35</sup> Kobu, s.122.

- *Devri hareketler:* Mevsimsel deęişimlere göre daha uzun bir zaman periyodunda ortaya çıkan deęişimlerdir. Ulusal ekonomideki hızlı gelişme, depresyon ve durgunluk devreleri bu tür deęişimlere örnek gösterilebilir.
- *Rassal hareketler:* Meydana geliş nedenleri belli olmayan ve sistematik bir deęişim şekli göstermeyen deęişmelerdir. Doğal afetler, grevler, savaşlar vb. olaylar önceden belirlenemeyen rassal hareketlerdir.

#### 1.4.2.2.1. Zaman Serilerinin Analizi

Bir zaman serisi çözümlenmek istendiğinde, zaman serisi bileşenlerinin etkisinin araştırılması gerekmektedir. Çünkü; zaman serileri, rassal bileşenin yanında, diğer üç bileşenin deęişik kombinasyonlarının etkisinde, bunlarına adeta bir sonucu niteliğindedir. Zaman serilerinin açıkladığımız dört bileşeni, birbirine baęlı ve karşılıklı ilişki içindedir. Bunların birbirleriyle ilişkilerini belirleyen farklı modeller bulunmaktadır. Yaygın olan görüşler şu modeller etrafında birleşmektedir:<sup>36</sup>

$$Y_t = T_t * M_t * K_t * R_t \quad (\text{Çarpımsal Model}) \quad (1.8)$$

$$Y_t = T_t + M_t + K_t + R_t \quad (\text{Toplamsal Model}) \quad (1.9)$$

Burada,

$Y_t$  = Zaman serisinin t zaman dönemindeki gözlem deęerini,

$T_t$  = Trend bileşeninin t zaman dönemindeki etkisini,

$M_t$  = Mevsimsel bileşenin t zaman dönemindeki etkisini,

$K_t$  = Konjonktürel bileşenin t zaman dönemindeki etkisini,

$R_t$  = Rassal bileşenin t zaman dönemindeki etkisini,

göstermektedir.

Toplamsal modele göre, zaman serilerinin herhangi bir (t) anındaki deęeri, bu dört unsurun toplamından meydana gelir. Bu modele göre, unsurların birbirlerini etkilemedikleri kabul edilir. Bu model benimsendiğinde herhangi bir unsurun seri içindeki payı mutlak deęer olarak belirlenebilir. Çarpımsal modele göre, zaman serilerinin herhangi bir (t) anındaki deęeri, bu dört unsurun çarpımından meydana gelir. Bu modele göre, unsurların birbirlerini etkiledikleri varsayılır.<sup>37</sup>

<sup>36</sup> Erdoğan Gavcar, **İstatistik Yöntemler-1**, 3. Baskı, Gazi Kitabevi, Ankara, 2005, s.147.

<sup>37</sup> Necmi Gürsakal, **Bilgisayar Uygulamalı İstatistik 2**, Alfa Yayınları, İstanbul, 2002, s.383.

➤ Trendin Belirlenmesi:

Trendin belirlenmesi büyük önem taşımaktadır. Çünkü trendin belirlenmesiyle;

- İncelenen değişkenin geçmiş dönemdeki değişimleri ortaya çıkarılabilir.
- Tahminler yapılarak geleceğin planlanması için gerekli bilgiler elde edilebilir.
- Zaman serilerindeki diğer bileşenlerin etkisi ortaya çıkarılabilir.<sup>38</sup>

Zaman serisindeki trend doğrusal olabileceği gibi eğrisel nitelikte de bulunabilir. Bu nedenle trend analizi yaparken değişik trend kalıplarının araştırılması gerekmektedir. Uygulamalı araştırmalarda en çok kullanılan trend kalıpları aşağıdaki gibidir:<sup>39</sup>

▪  $Y = a + bX$  : Doğrusal bağıntı ( 1.10 )

▪  $Y = a + bX + cX^2$  : Parabolik bağıntı ( 1.11 )

▪  $Y = a + bX + cX^2 + dX^3$  : Kübik eğri ( 1.12 )

▪  $Y = \frac{1}{a+bX}$  : Hiperbolik eğri ( 1.13 )

▪  $Y = aX^b$  : Geometrik bağıntı ( 1.14 )

▪  $Y = ab^x$  : Üstel fonksiyon ( 1.15 )

Trend bileşeninin belirlenmesinde dört yöntem kullanılmaktadır. Bunlar; elle çizme yöntemi, yarı ortalamalar yöntemi, hareketli ortalamalar yöntemi ve en küçük kareler yöntemidir. Trend analizinde en çok kullanılan yöntem, “ En Küçük Kareler Yöntemi” dir. Yöntemin adı veriler ile bu verilerin arasından geçecek trend denklemine göre bulunacak teorik değerler arasındaki farkların kareleri toplamının minimum olmasından ileri gelir. En küçük kareler yönteminin matematiksel ifadesi şu şekildedir:<sup>40</sup>

$$\sum_{t=1}^n e_t^2 = \sum (Y_t - Y'_t)^2 \rightarrow \text{Min} \quad ( 1.16 )$$

$Y_t$  = t zaman dönemindeki seri değeri,

$Y'_t$  = trend analizi ile t zaman dönemi için bulunan değeri,

$e_t$  = t zaman dönemi için hata değeri,

n = dönem sayısını gösterir.

<sup>38</sup> Orhunbilge, s.9.

<sup>39</sup> Kobu, s.116.

<sup>40</sup> Gavcar, s.150.

➤ Mevsim Etkisinin Belirlenmesi: <sup>41</sup>

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” 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 rassal faktörlerden oluşan zaman serisi verilerinde bu yolla trend ve konjonktür bileşenleri elde edilmektedir. Gözlem verilerinin hesaplanan hareketli ortalamalara oranlanmasıyla da mevsimlik ve arıza faktörlerin etkisi ortaya çıkarılmaktadır.

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. Bu yolla tüm aylara ait 12’şerli hareketli ortalamalar elde edildikten sonra gözlem değerlerinden trend ve konjonktürün etkisi arındırılarak mevsim ve arıza 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 toplamının 1200 olması gerekir. Ancak her zaman bu toplama ulaşmak mümkün olmaz. Bu nedenle aşağıdaki işlemle düzeltme yapılmaktadır:

$$\text{Düzeltilmiş Mevsim İndeksi} = \frac{1200}{\sum_{t=1}^{12} M\bar{I}} \quad (1.17)$$

$\sum_{t=1}^{12} M\bar{I}$  = Elde edilen 12 aylık mevsim indeksleri toplamını gösterir.

Konjonktürel ve rassal bileşenlere ilişkin güvenilir öngörüler türetilmediği için, öngörü amacıyla çözümlenmelerde genellikle bu iki bileşenle ilgilenilmez ve çoğunlukla kullanılan çarpımsal öngörü modellerinde bu iki bileşene yer verilmez. <sup>42</sup>

---

<sup>41</sup> Orhunbilge, ss. 64-66.

<sup>42</sup> Gavcar, s.152.

Yukarıda zaman serilerinin bileşenlerine nasıl ayrıldığına ilişkin ayrıntılı bilgi verilmiştir. Bu bilgilerden sonra mevsimsel serilerin çözümlenmesinde çarpımsal modelin uygulanması sürecini aşağıdaki gibi ifade edebiliriz:<sup>43</sup>

- İlk olarak mevsimsel bileşen belirlenerek mevsimsel bileşenden arındırılmış seri değerleri tahminlenmesi yapılır. Bu tahminler  $D_t$  ile gösterilir ve  $D_t = Y_t / M_t$  eşitliğiyle hesaplanır.

- İkinci aşamada trend bileşenin t dönemine ilişkin  $T_t$  tahmini yapılır. Burada trend bileşenin tahmini için gerçek gözlem değerleri değil, mevsimsel bileşenin etkisinden arındırılmış  $D_t$  serisi esas alınır.

- Son aşamada ise öngörü değerleri belirlenir. Daha önce açıklandığı gibi, bileşenlere ayırma yöntemiyle yapılan öngörü amaçlı çözümlenmelerde konjonktürel ve rassal bileşenlerle ilgilenilmemektedir. Bu durumda, t+1 ön dönem için öngörü değeri;  $Y'_{t+1} = T_{t+1} * M_{t+1}$  formülüyle hesaplanır.

#### 1.4.2.2.2. Mekanik ( Naive ) Yöntemi

Mekanik modeller en basit tahmin yöntemleridir. Bir tahminin yanında yapılmış olan bir tahminin üstünlüğünün olup olmadığının tespitinde de kullanılmaktadır. Bu yöntem, gelecek dönem talebinin mevcut talebe eşit olacağı yaklaşımı üzerine kuruludur. Yöntemin matematiksel eşitliği aşağıda gösterilmiştir.

$$F_{t+1} = Y_t \quad ( 1.18 )$$

t = dönem,

$F_{t+1}$  = t +1 dönemi için tahmin değeri,

$Y_t$  = t dönemi için gerçekleşen değerdir.

Bu yöntem, herhangi bir dalgalanma göstermeyen zaman serilerinde tahmin amacıyla kullanılabilen, maliyetsiz ve uğraş gerektirmeyen bir yöntemdir. Zaman serilerinin çoğunda dalgalanmalar olduğu için yöntem pek kullanışlı değildir. Yöntemin en büyük avantajı, gelişmiş zaman serisi yöntemleri için bir başlangıç değeri oluşturmasıdır.<sup>44</sup>

---

<sup>43</sup> Gürsakal, s.384.

<sup>44</sup> Heizer ve Render, p.109.

### 1.4.2.2.3. Hareketli Ortalamalar Yöntemi

Bir zaman serisi ne kadar tesadüfîlik içeriyorsa ortalamadan sapma da o derece fazla olmaktadır. Bu tesadüfîlik durumunu ortadan kaldırmak için son gözlem değerlerinin ortalamasını almak uygun olabilir. Hareketli ortalamalar yöntemi bu amaçla, geçmiş verileri alarak bunların ortalamasını bulmakta ve bu ortalamayı gelecek dönem için öngörü olarak kullanmaktadır. Hareketli ortalamaya dahil edilecek gözlem sayısı öngörü yapacak kişi tarafından belirlenmekte ve sabit kalmaktadır. Hareketli ortalama teriminin kullanılmasının sebebi; seriye eklenen her yeni değer ile birlikte yeni bir ortalamanın hesaplanabilmesi ve bunun öngörü olarak kullanılabilir olmasıdır. Hareketli ortalamalar yöntemini basit ve ağırlıklı hareketli ortalamalar olmak üzere iki grupta incelemek mümkündür: <sup>45</sup>

- **Basit Hareketli Ortalama:** Bu hareketli ortalama tekniğinde son  $n$  dönemin ortalaması tahmini değer olarak kullanılır. Matematiksel gösterim;

$$F_{t+1} = \frac{(Y_t + Y_{t-1} + \dots + Y_{t-n+1})}{n} \quad (1.19)$$

şeklindedir. Burada;

$F_{t+1}$  = t+1 dönemindeki tahmin değeri,

$Y_t$  = t dönemindeki gözlem değeri,

$n$  = hareketli ortalamaya dahil edilen gözlem sayısıdır.

Bu yöntemde hata minimizasyonu için genellikle deneme-yanılma yöntemi kullanılır. Her yeni değer gerçekleşmesinde en eski değer hesaplamadan çıkarılarak son  $n$  dönemin ortalaması alınır. Hesaplanan bu ortalama bir sonraki dönemin tahmini değeridir. <sup>46</sup>

- **Ağırlıklı Hareketli Ortalama:** Basit hareketli ortalama yönteminde tahmin değerinin hesaplanmasında son  $n$  dönemin ortalaması alınırken,  $n$  dönemin her birine eşit ağırlık verilmektedir. Ağırlıklı hareketli ortalama yönteminde ise, her döneme farklı bir ağırlık verilerek  $w_i$  değerleri ağırlıkları göstermek üzere; <sup>47</sup>

$$F_{t+1}^w = \frac{w_n Y_t + w_{n-1} Y_{t-1} + \dots + w_1 Y_{t-n+1}}{w_n + w_{n-1} + \dots + w_1} \quad (1.20)$$

<sup>45</sup> David R. Anderson ve diğerleri, **An Introduction to Management Science: Quantitative Approaches to Decision Making**, 8th Edition, South-Western, 2000, p.762.

<sup>46</sup> Heizer ve Render, p.109.

<sup>47</sup> Anderson ve diğerleri, p. 763.

formülü ile hesaplanmaktadır.

Bu yöntemde her dönem için farklı ağırlıklar seçilerek, özellikle son döneme bir önceki dönemden daha fazla ağırlıklar verilerek hesaplamalar yapılır. Gelecek dönem satışlarının son dönem satışlarından daha fazla etkileneceği kabul edilir.<sup>48</sup>

#### 1.4.2.2.4. Üstel Düzeltim Yöntemi

Üstel düzeltme yöntemleri, geçmiş dönem verilerine eşit ağırlık veren basit hareketli ortalamalar yöntemine benzeyen ancak geçmiş dönem verilerine eşit değil farklı ağırlıkların verildiği yöntemler topluluğudur. Üstel terimi verilen ağırlıkların veriler eskidikçe üstel bir şekilde azalması anlamını taşır. Diğer bir deyişle, tahmin için kullanılan geçmiş dönem verilerinden yakın geçmişte gerçekleşenlere yüksek, veriler eskidikçe ise üstel olarak azalan ağırlıklar verilmektedir. Hareketli ortalamalara göre en önemli üstünlüğü budur. Bu yöntemde en yakın geçmiş verilerin geleceğe etkisi, eski dönem verilerinden daha yüksek olmaktadır. Düzeltme yöntemlerinin en önemli üstünlükleri kolay uygulanabilir ve düşük maliyetli olmalarıdır. Diğer bir üstünlüğü ise her gerçekleşen yeni dönem verilerinin modele hemen dahil edilebilmesi ve yeni dönem tahminlerine hemen katkı sağlayabilmeleridir.<sup>49</sup>

Çeşitli üstel düzeltim yöntemleri geliştirilmiştir. Tez kapsamında bu yöntemlerden sadece basit üstel düzeltim yöntemine değinilecektir.

Basit üstel düzeltim modeli aşağıdaki formülle gösterilebilir:<sup>50</sup>

$$F_{t+1} = \alpha Y_t + (1 - \alpha) F_t \quad ( 1.21 )$$

$F_{t+1}$  = t+1 dönemi için talep tahmin değeri,

$Y_t$  = t dönemi için gerçekleşen talep değeri,

$F_t$  = t dönemi için talep tahmin değeri,

$\alpha$  = düzeltme katsayısıdır.

$\alpha$ , 0 ile 1 arasında değişebilmektedir. Ortalama hata kareyi minimum yapan düzeltme katsayısı tahminlerde kullanılmaktadır. Uygulamada genellikle 0,01 ile 0,3 arasındaki değerlerin genellikle daha uygun olduğu saptanmıştır.<sup>51</sup>

---

<sup>48</sup> Doğan, s.114.

<sup>49</sup> Orhunbilge, s.95.

<sup>50</sup> Anderson ve diğerleri, p. 767.

<sup>51</sup> Orhunbilge, s.96.

#### 1.4.2.2.5. Box - Jenkins Yöntemi

George Box ve Gwilym Jenkins tarafından 1970 yılında geliştirilmiştir. Box-Jenkins metodu, tek değişkenli bir model olarak geleceği tahmin etmeye yarayan metotlardan biridir. Kısa dönem tahminlerinde oldukça başarılı sonuçlar vermektedir. Yöntem birçok alternatif model arasından en iyi modeli seçerek geleceği tahmin etmeye yöneliktir. Bir değişkene ilişkin yapılacak tahmin, kendi gecikmeli değerleri, hata terimleri ya da her ikisinin kombinasyonu ile yapılmaktadır. Bu metodun uygulandığı serinin, eşit zaman aralıklarıyla elde edilen gözlem değerlerinden oluşan kesikli ve durağan bir seri olması önemli bir varsayımdır. Eğer seri durağan değil ise öncelikle bunun tespit edilmesi ve serinin durağan hale getirilmesi gerekir. Durağanlık, serinin periyodik dalgalanmalardan arınmış olması anlamına gelmektedir. Bu nedenle, mevsimsellik ya da trend bileşeni içeren seriler, yöntemin uygulanabilmesi için öncelikle durağanlaştırılmalıdır.<sup>52</sup>

Bu yöntemde üç modelleme söz konusudur. Bunlar; Otoregresif (AR) Süreç, Hareketli Ortalama (MA) Süreci ve bu ikisinin birleşiminden oluşan Otoregresif Hareketli Ortalama (ARMA) Süreci' dir. Durağan olmayan bir seri için fark alınması gerekli olduğunda ise ARMA süreci Birleştirilmiş Otoregresif Hareketli Ortalama (ARIMA) süreci haline dönüşür. Burada I, entegrasyon katsayısını göstermekte ve ARIMA modeli, farkı alınarak durağan hale getirilmiş otogregresif hareketli ortalama sürecini ifade eder. AR(p), MA(q) ve bunların birleşimi olan ARMA(p,q) modelleri durağan süreçlere uygulanırken, ARIMA(p,d,q) modelleri durağan olmayan süreçler için kullanılmaktadır.<sup>53</sup>

Box- Jenkins yöntemi, tüm model kombinasyonları arasından uygun bir modeli belirlemek için dört basamaktan oluşan tekrarlı bir yaklaşım kullanmaktadır. Bu aşamalar sırasıyla; modelin belirlenmesi, parametre tahminlerinin yapılması, modelin uygunluğunun test edilmesi ve ileriye yönelik öngörü şeklindedir. Belirlenen model yeterli değilse, süreç tatmin edici bir model sağlanana kadar devam eder.<sup>54</sup>

---

<sup>52</sup> Hüdaverdi Bircan ve Yalçın Karagöz, " Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama", **Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi**, Cilt:6, Sayı:2, 2003, s.50.

<sup>53</sup> Chris Chatfield, **Time Series Forecasting**, Chapman & Hall / CRC, London, 2000, p.30.

<sup>54</sup> Montgomery ve diğerleri, s. 239.



### 1.4.3. Yapay Zeka Tabanlı Yöntemler

Yapay zeka tabanlı yöntemler özellikle karmaşık problemlerin çözümünde güçlü teknikler olarak öne çıkmaktadır. Literatürde çeşitli yapay zeka algoritmaları, talep tahmini amacıyla kullanılmıştır. Bunlar arasında en sık kullanılanlar; yapay sinir ağları, bulanık mantık ve genetik algoritmalarıdır. Bu çalışmada yapay zeka tabanlı yöntemlerden yapay sinir ağları kullanılarak petrokimya sektöründe talep tahminlemesi yapılmıştır.

### 1.5. TAHMİN DOĞRULUĞUNUN ÖLÇÜMÜ

Hangi yöntem kullanılırsa kullanılsın, yapılan tüm talep tahminlerinin belirli bir doğruluk derecesi söz konusudur ve hiçbir tahmin %100 doğruluk derecesine sahip olamaz. Bu sebeple belirli bir hata oranını baştan kabul etmek gerekir. Bir modelin veya öngörü tekniğinin geleceği ne derece doğrulukla öngörebileceği bazı kriterlerle test edilebilir. Öngörünün doğruluk testi için öngörü dönemine ait gözlem değerleri bilinmiyormuş gibi gözlem dışı bırakılır ve tahmin edilen modele dayanılarak bu dönemler için değişkenlerin alacağı değerler öngörülür. Bu öngörü değerleri ile elimizde mevcut olan gerçek değerler arasındaki farklar, yani öngörü hataları tahmin edilerek bazı formüllerle farklı teknikleri veya modellerin öngörü doğruluğunu karşılaştırmaya yardımcı olabilecek şekilde standartlaştırılır.<sup>55</sup>

En çok kullanılan hata tahmin ölçüleri ve bunları hesaplamaya yarayan formüller şunlardır: <sup>56</sup>

$$e_t = Y_t - F_t \quad ( 1.22 )$$

$Y_t$  = t dönemi için gerçekleşen talep değeri,

$F_t$  = t dönemi için öngörü değeri,

$n$  = öngörülen dönem sayısı,

$e_t$  = t dönemindeki öngörü hatasını göstermek üzere;

---

<sup>55</sup>Mustafa Akal, "Optimum Öngörü Tekniğinin Seçimi", <http://www.sakarya.edu.tr/~hgurak/yazilar/makale/ONGOM.doc>, (31.12.2011),s.3.

<sup>56</sup> Blocher ve diğerleri, pp.11-12.

$$\text{Ortalama Hata(OH)} = \frac{1}{n} \sum_{t=1}^n e_t \quad (1.23)$$

$$\text{Ortalama Mutlak Hata (OMH)} = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (1.24)$$

$$\text{Hata Kareleri Ortalaması(HKO)} = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (1.25)$$

$$\text{Ortalama Hata Kareleri Kökü(OHKK)} = \frac{1}{n} \sqrt{\sum_{t=1}^n e_t^2} \quad (1.26)$$

$$\text{Ortalama Mutlak Yüzde Hata(OMYH)} = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{Y_t} \right| * 100 \quad (1.27)$$

$$\text{İzleme Sinyali} = \frac{\sum_{t=1}^n e_t}{OMH} \quad (1.28)$$

Bir talep tahmin işleminin duyarlılığı hakkında karar verebilmek için yukarıdaki ölçülerden en az ikisini göz önüne almak gerekir. Yalnız bir ölçüye bakarak karar vermek sakıncalı olabilir. Burada ölçüler yorumlanırken aradaki farkların bilinmesi gerekir. Örneğin, OMH mutlak değerlerin ortalaması olduğundan “ortalama hata” miktarını verir. Diğer taraftan, OH artı veya eksi değerler aldığından hataların yönünü belirlemektedir. HKO, ortalama mutlak sapma gibi hataları işaretlerden arındırır ve büyüklüklerine bakar. Hataların büyük olduğu tahminlerde değerlerin karesinin alınması hatayı daha da artıracığından olumlu sonuç vermeyebilir. Bu nedenle düşük hataların gözlemlendiği durumlarda kullanılabilir. OMYH, miktar yerine yüzdesel olarak hatayı gösterir ve yaygın olarak kullanılmaktadır. İzleme sinyali ise, tahmin periyotları boyunca hataların nasıl değiştiğini gösterir.<sup>57</sup>

## 1.6. TALEP TAHMİN YÖNTEMİNİN SEÇİMİ

Talep tahmininde kullanılacak yöntemin seçimi duyarlık, maliyet ve zaman tasarrufu açısından önem taşır. Tahmin yönteminin seçiminde önce tahmin prosesinin amacının iyi belirlenmesi ve daha sonra karar verecek kişinin birtakım faktörleri değerlendirmesi gerekir. Bu faktörler :<sup>58</sup>

<sup>57</sup> Kobu, s.125.

<sup>58</sup> Kobu, s.130; Doğan, s.107.

- *Bilimsellik Derecesi:* Kolay anlaşılabilir ve uygulanabilen yöntemler, yöneticiler tarafından tercih edilmektedir. Bu nedenle kullanılacak metodun, sonuçları yorumlayıp karar verecek olan yöneticinin bilgi ve yeteneği ile bağdaşmasına özen gösterilmelidir.
- *Zaman:* Tahminlerin kapsayacağı zaman aralığı farklı yöntemleri gerektirebilir. Uzun dönem tahminler için nitel yöntemler uygun olduğu halde, kısa ve orta dönem tahminler için nicel yöntemler tercih edilmelidir. İkinci önemli konu ise tahminlerin gelecekteki kaç dönem için yapılmak istenmesidir. Bazıları gelecek bir dönemi öngörebilmekte iken bazıları çok sayıda döneme uygulanabilmektedir.
- *Kararların Niteliği:* Tahmin sonuçlarına dayanılarak verilecek kararların uzun veya kısa vadeli olması, istenilen duyarlılık gibi faktörler seçilen yöntemi belirler. Örneğin, stok kontrolü ve üretim programlama kararlarında duyarlı kısa vadeli tahminler yapılması nedeniyle zaman serileri kullanılırken uzun vadeli yatırım kararlarında nitel tahmin yöntemleri kullanılır.
- *Maliyet:* Farklı tahmin yöntemleri farklı maliyet unsurlarına sahip olabilir. Maliyet faktörünün işletmeler için önemi nedeniyle yöntem seçiminde buna dikkat edilmesi gerekir.
- *Verilerin İzledikleri Yol:* Veriler, doğrusal veya eğrisel trend, mevsimlik veya dönemsel hareketler izleyebilir veya rastgele dağılmış olabilir. Bu nedenle verilerin izledikleri yolun belirlenmesi yöntem seçiminde oldukça önemlidir.
- *Bilgisayar desteği:* Özellikle nicel yöntemlerin uygulanmasında bilgisayar programları çok önemlidir.

## İKİNCİ BÖLÜM YAPAY SİNİR AĞLARI

### 2.1. YAPAY ZEKÂ

Teknolojinin gelişmesi izlendiğinde önceleri sadece elektronik veri transferi yapmak ve karmaşık hesaplamaları gerçekleştirmek üzere geliştirilen bilgisayarların zaman içerisinde büyük miktarlardaki verileri filtreleyerek özetleyebilen ve mevcut bilgileri kullanarak olaylar hakkında yorumlar yapabilen nitelikler kazandığı görülmektedir. Günümüzde ise bilgisayarlar hem olaylar hakkında karar verebilmekte hem de olaylar arasındaki ilişkileri öğrenebilmektedir. Matematiksel olarak formülasyonu kurulamayan ve çözülmesi mümkün olmayan problemler sezgisel yöntemler yoluyla bilgisayarlar tarafından çözülebilmektedir. Bilgisayarları bu özelliklerle donatan ve bu yeteneklerin gelişmesini sağlayan çalışmalar “yapay zekâ” çalışmaları olarak bilinmektedir. İlk defa 1950’li yıllarda ortaya atılan yapay zekâ terimi zaman içinde yoğun ilgi görmüş ve 40-50 yıllık bir zaman diliminde hayatın vazgeçilmez parçası olan sistemlerin doğmasına neden olmuştur.<sup>59</sup>

#### 2.1.1. Yapay Zekâ Kavramı

Her insan doğuştan belirli bir zekâyâ sahiptir. Zekâ, belirli bir konuda çalışılarak, 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 zekâ ile gerçekleştirilebilmektedir. Zekâ, yazılım veya tümleşik parçalarla taklit edilebilmektedir. Bu durumda zekâ, “Yapay Zekâ” olarak adlandırılmaktadır.<sup>60</sup>

Türkçe kaynaklarda Yapay Us veya Suni Zekâ olarak bilinen Yapay Zekânın çağdaş bir bilim dalı olarak gelişmesi, 1956 yılında C.Shannon, M.Minsky ve

---

<sup>59</sup> Ercan Öztemel, **Yapay Sinir Ağları**, 2. Baskı, Papatya Yayıncılık, İstanbul, 2006, s.13.

<sup>60</sup> Çetin Elmas, **Yapay Zeka Uygulamaları/ Yapay Sinir Ağları-Bulanık Mantık-Genetik Algoritma**, 1.Baskı, Seçkin Yayıncılık, Ankara, 2007, s.21.

J.McCarthy' nin çabaları ve katkıları ile başlamıştır. Yapay zekâ adı ilk defa 1956 yılında ABD' de Makine Zekâsı konferansında ortaya konmuş bir kavramdır.<sup>61</sup>

Basit bir yaklaşımla, yapay zekâ doğal canlılarda görüldüğünde zekâ belirtisi olarak algılanan yetenekleri analiz ederek bunların benzeri yapay yönergeleri geliştirmeye çalışmak olarak tanımlanabilir ancak yapay zekâ'nın tam bir tanımını yapmak bu kadar kolay değildir. Çünkü yapay zekâ çok kapsamlı bir konu olup pek çok alt alan içermektedir. Yapay zeka terimini ilk defa 1956 yılında kullanan ve terimin mucidi olan John McCarthy, yapay zekayı "Makineleri zeki yapan mühendislik ve bilim dalı" olarak tanımlamıştır. Diğer tanımları ise şöyle sıralayabiliriz:<sup>62</sup>

- Yapay bir varlığın (genellikle bir bilgisayar) sergilediği zekâ,
- Bilgisayar bilimlerinin, bilgisayarlara insan zekâsına niteliklerinin kazandırılması üzerinde çalışan bir dalı,
- Bir makine ya da insan eliyle üretilmiş otonom bir sistem kullanarak insan zekâsının benzetimini yapmaya çalışan bir araştırma alanı,
- İnsanın düşünme yöntemlerini analiz ederek bunların benzeri yapay yönergeleri geliştirmeye çalışan araştırma alanı,
- İnsan tarafından yapıldığında zekâ belirtisi olarak görülen davranışların (akıllı davranışların) makine tarafından da yapılmasıdır.

Yapay zekâ; öğrenme, gerekçeleme, problem çözme, yabancı bir dili alma v.b gibi insanoğlunun davranışlarını gösterebilen sistemlerle ilgilenen bir bilgisayar bilimidir. Yapay zekânın ana amacı, insanların davranışlarının ve sezgisel yeteneklerinin bilgisayar üzerinde benzetimidir. İnsanoğlu esas olarak bilgiyi kullanmakta ve onu işlemektedir. Bu yüzden bilgi ve bilginin kullanımı yapay zekânın da anahtar karakteristikleridir.<sup>63</sup>

### 2.1.2. Yapay Zekâ Teknikleri

Yapay zekâ çalışmaları değişik teknolojilerin doğmasına neden olmuştur. Çünkü günlük olaylar ve problemler sürekli değişmektedir. Değişik yerlerde olayların

---

<sup>61</sup> " Yapay Zeka ", <http://www.yapay-zeka.org/modules/wiwimod/index.php?page=AI&back=WiviHome>, (15.01.2012).

<sup>62</sup> " Yapay Zeka ", <http://www.yapay-zeka.org/modules/wiwimod/index.php?page=AI&back=WiviHome>, (15.01.2012).

<sup>63</sup> Türkyay Dereli, " Toplam Kalite Yönetiminin Işığında Yapay Zekânın Endüstriyel Problemlerin Çözümünde Kullanılması ", <http://www1.gantep.edu.tr/~dereli/turkce/tky.ppt#256,1>, (15.01.2012),s.5.

farklı yönleri insanları ilgilendirebilmektedir. Bir olay, değişik insanlar tarafından değişik şekillerde yorumlanmaktadır. Karşılaştıkları sorunlar farklı bölge ve kişilerce farklı şekillerde çözülebilmektedir. Bilgisayarların insanların karar verme ve problem çözme mekanizmalarını taklit etmesinin sağlanması da dolayısıyla farklı teknolojilerin doğmasına neden olmaktadır. Günümüzde 60'dan fazla yapay zekâ teknolojilerinden bahsedilmektedir. Bu teknolojilerin çoğu henüz laboratuvar çalışmaları düzeyindedir.<sup>64</sup>

Yapay zekâ tekniklerinden günlük hayatta en yaygın olarak kullanılanları aşağıdaki gibidir:

- Uzman Sistemler: Son yirmi yıl içerisinde Yapay Zekâ tabanlı programlar olan Uzman Sistemler büyük dikkat çekmiştir. Uzman Sistemlerin birçok farklı alandaki zor seviyede sayılabilecek problemleri başarılı bir şekilde çözüme kavuşturması, dikkat çekmelerindeki en önemli unsuru oluşturmuştur. İyi tasarlanmış sistemler belirli problemlerin çözümünde uzman insanların düşünme işlemlerini taklit ederler. Burada Uzman Sistem tabiri kullanılmasının sebebi, sistemin bir veya daha fazla uzmanın bilgilerine sahip olarak onun veya onların yerini almaya yönelmesinden dolayıdır.<sup>65</sup> Bir uzman sistemin 4 temel elemanı vardır:<sup>66</sup>
  - a) Bilginin temin edilmesi: Uzman sistemin uzmanlık alanı ile ilgili bilgilerin toplanması, derlenmesi ve bilgisayarın anlayacağı şekle dönüştürülmesi çalışmalarını kapsar.
  - b) Bilgi tabanı: Uzman sistemin uzmanlık alanı ile ilgili toplanan bilgilerin saklandığı yerdir. Bilgiler genellikle kurallar( Eğer... ise O Zaman...şeklinde), bilgi çatıları, bilgi sınıfları ve prosedürlerden oluşur.
  - c) Çıkarım mekanizması: Bilgi tabanında bulunan bilgileri arayan, filtreleyen, yorumlayan ve sonuçlar çıkaran yani; çözüm üreten bir mekanizmadır.
  - d) Kullanıcı ara birimi: Uzman sistemi kullanan kişiler ile uzman sistemin iletişimini sağlar. Problemlere üretilen sonuçların nasıl üretildiği ve niçin o sonuçlara varıldığını açıklar. Uzman sistemin bir uzman sistem gibi görülmesi bu ara birimi ve açıklama yeteneğinin güçlü olmasına bağlıdır.

---

<sup>64</sup> Öztemel, s.15.

<sup>65</sup> Emin İslam Tatlı, "Uzman Sistemler", <http://th.informatik.uni-mannheim.de/people/tatli/resources/pdf/expertsystems.pdf>, (15.01.2012), s.3.

<sup>66</sup> Öztemel, s.16.

- Genetik Algoritmalar: Fonksiyon optimizasyonu problemlerinin çözümünde, klasik arama yöntemlerine göre önemli üstünlükleri nedeniyle yaygın olarak kullanılmaktadır. Geniş çözüm uzaylarının klasik yöntemlerle taranması hesaplama zamanını artırmaktadır. Ancak bu tip problemlere, genetik algoritmalar ile kabul edilebilir sürede, optimale yakın çözümler bulunabilmektedir. Genetik algoritmalar özellikle çözüm uzayının geniş, süreksiz ve karmaşık olduğu problem tiplerinde başarılı sonuçlar vermektedir. Bir problemi çözmek için öncelikle rastgele başlangıç çözümleri belirlenmektedir. Daha sonra bu çözümler birbirleri ile eşleştirilerek daha iyi çözümler üretilmektedir. Bu şekilde sürekli çözümler birleştirilerek yeni çözümler aranmaktadır. Bu arama iyi sonuç üretilmeyinceye kadar devam etmektedir. Genetik algoritmalar ile problemlerin çözülmesinde arzu edilen sonucu üretecek özelliklerin kalıtım yolu ile başlangıç çözümlerinden elde edilen yeni çözümlere onlardan da daha sonraki çözümlere geçtiği kabul edilmektedir. Genetik algoritmalar; başta üretim/işlemler olmak üzere finans ve pazarlama gibi işletmelerin fonksiyonel alanlardaki birçok farklı iş probleminin çözümü için kullanılmaktadır. Özellikle, kaynak tahsisi, iş atölyesi çizelgelemesi, makine parça gruplaması ve bilgisayar ağı tasarımı gibi çeşitli alanlarda uygulamaları mevcuttur.<sup>67</sup>
- Bulanık Mantık: Bulanık mantık kavramı ilk kez 1965 yılında California Berkeley üniversitesinden Azeri bilim adamı Prof. Lütfü A.Zade'nin bu konu üzerindeki araştırmalarına ait makalelerini yayınlanmasıyla duyuldu. O tarihten sonra önemi gittikçe artarak günümüze kadar gelen bulanık mantık, belirsizliklerin anlatımı ve belirsizliklerle çalışılabilmesi için kurulmuş katı bir matematik düzen olarak tanımlanabilir. Bulanık mantık, insan zekâsında olduğu gibi siyah-beyaz, uzun-kısa gibi iki seçenekli kesin ayrımlar yerine, beyaz-gri-siyah, kısa-orta-uzun-çok uzun gibi değerlere göre de karar verebilen, insanların bilgi ve deneyimlerinden yararlanarak çalışabilen bilgisayar programlarıdır. Sistemin temeli insanın sahip olduğu yetenekleri matematiksel temele dayalı olarak sembolik ifadeler yolu ile program üzerine taşınması esasına dayanır. Bunu yaparken klasik mantığın tersine iki seviyeli değil, çok seviyeli işlemler kullanır. Matematiksel yöntemlerle karmaşık modellemeler yapmak oldukça zordur, çünkü verilerin kesin değerler içeriyor

---

<sup>67</sup> Çağatan Taşkın ve Gül Gökay Emel, **Sayısal Yöntemlerde Genetik Algoritmalar**, Alfa Aktüel Yayınları, Bursa, 2009, s.25.

olması gerekmektedir. Bulanık mantık karmaşık problemlerin çözümünde niteliksel bir tanımlama yapma olanağı sağlar.<sup>68</sup>

- **Yapay Sinir Ağları:** İnsan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek oldukça zor veya mümkün değildir. Bu nedenle, yapay sinir ağlarının, programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş bilgi işleme ile ilgilenen bir bilgisayar bilim dalı olduğu söylenebilir. Tez çalışmasında kullanılan yapay zekâ yöntemi yapay sinir ağları olduğu için bu konuya daha ayrıntılı olarak yer verilecektir.<sup>69</sup>

## 2.2. YAPAY SİNİR AĞLARINA GİRİŞ

### 2.2.1. Yapay Sinir Ağları Tanımı

Yapay sinir ağları, insanlar tarafından gerçekleştirilmiş örnekleri kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üreteceğini belirleyebilen bilgisayar sistemleridir.<sup>70</sup>

Haykin ise YSA'yı şöyle tanımlar:<sup>71</sup>

Yapay sinir ağı; deneyime dayalı bilgiyi depolamaya ve bu bilgiyi kullanıma sunmaya yönelik doğal bir eğilim içinde olan yoğun paralel dağıtılmış bir işlemcidir. YSA iki açıdan insan beynine benzemektedir: Bilgi ağı tarafından bir öğrenme süreci ile elde edilmektedir ve sinir hücreleri arasında snaptik ağırlıklar olarak adlandırılan bağlar bilgiyi depolamakta kullanılmaktadır.

Diğer bir tanıma göre yapay sinir ağları; insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme

---

<sup>68</sup> “ Bulanık Mantık “, <http://www.yapay-zeka.org/modules/wiwimod/index.php?page=Fuzzy+Logic>, (15.01.2012).

<sup>69</sup> Öztemel, s.29.

<sup>70</sup> Öztemel, s.29.

<sup>71</sup> Simon Haykin, **Neural Networks: A Comprehensive Foundation**, Second Edition, Prentice Hall, New Jersey, 1999, p.24.



yapıları; bir başka deyişle, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır.<sup>72</sup>

Yapılan tanımların bazı ortak noktaları bulunmaktadır. Bunların en başında yapay sinir ağlarının birbirine hiyerarşik olarak bağlı ve paralel çalışabilen yapay sinir hücrelerinden oluşmaları gelmektedir. Proses elemanları da denilen bu hücrelerin birbirlerine bağlandıkları ve her bağlantının bir değerinin olduğu kabul edilmektedir. Bilginin öğrenme yolu ile elde edildiği ve proses elemanlarının bağlantı değerlerinde saklandığı, dolayısıyla dağıtık bir hafızanın söz konusu olduğu da ortak noktalardan birisini oluşturmaktadır.<sup>73</sup>

### 2.2.2. Yapay Sinir Ağları Genel Özellikleri

Yapay sinir ağlarının karakteristik özellikleri uygulanan ağ modeline göre değişmektedir. Ancak tüm modeller için genel özellikler şunlardır:<sup>74</sup>

- Yapay sinir ağları makine öğrenmesi gerçekleştirirler.
- Programları çalışma stili bilinen programlama yöntemlerine benzememektedir.
- Bilgiyi saklarlar.
- Örnekleri kullanarak öğrenirler.
- Güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekir.
- Görülmemiş örnekler hakkında bilgi üretirler.
- Algılamaya yönelik olaylarda kullanılabilirler.
- Şekil ilişkilendirme ve sınıflandırma yapabilirler.
- Örüntü tamamlama gerçekleştirebilirler.
- Kendi kendini organize etme ve öğrenebilme yetenekleri vardır.
- Eksik bilgi ile çalışabilmektedirler.
- Hata toleranslarına sahiptirler.
- Belirsiz, tam olmayan bilgileri işleyebilmektedirler.
- Dağıtık belleğe sahiptirler.
- Sadece nümerik bilgiler ile çalışabilmektedirler.

---

<sup>72</sup> Elmas, s.23.

<sup>73</sup> Öztemel, s.30.

<sup>74</sup>Neslihan Bozer, "Yapay Sinir Ağlarında Sınıflandırma", [http://yzgrafik.ege.edu.tr/~aybars/ysa/02\\_1\\_YSA\\_SINIFLANDIRMA/YSA\\_Seminer.ppt,\(16.01.2012\),s.9](http://yzgrafik.ege.edu.tr/~aybars/ysa/02_1_YSA_SINIFLANDIRMA/YSA_Seminer.ppt,(16.01.2012),s.9)

### 2.2.3. Yapay Sinir Ağlarının Tarihçesi

Yapay Sinir Ağlarının tarihçesi insanların nörobiyoloji konusuna ilgi duymaları ve sonuçları bilgisayar bilimine uygulamaları ile başlamaktadır. Bu çalışmalar aşağıdaki gibi özetlenebilir.<sup>75</sup>

- 1890: İnsan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması
- 1911: İnsan beyninin bileşenlerinin belirli bir düzenek ile sinir hücrelerinden oluştuğunun benimsenmesi
- 1943: Yapay sinir hücrelerine dayalı hesaplama teorisinin ortaya atılması ve eşik değerli mantıksal devrelerin geliştirilmesi
- 1949: Biyolojik olarak mümkün olabilen öğrenme prosedürünün bilgisayarlar tarafından gerçekleştirilecek biçimde geliştirilmesi
- 1956-1962: Adaptif Doğrusal Eleman (ADALINE) ve Widrow öğrenme algoritmasının geliştirilmesi
- 1957-1962: Tek katmanlı algılayıcının(perceptron) geliştirilmesi
- 1965: İlk makine öğrenmesi kitabının yayınlanması
- 1967-1969: Bazı gelişmiş öğrenme algoritmalarının(Grosberg öğrenme algoritması gibi) geliştirilmesi
- 1969: Tek katmanlı algılayıcıların problemleri çözme yeteneklerinin olmadığını gösterilmesi
- 1969: DARPA(ABD Savunma Bakanlığı İleri Araştırma Projeleri Ajansı)'nın yapay sinir ağlarını desteklemeyi durdurup diğer yapay zeka çalışmalarına destek vermesi
- 1969-1972: Doğrusal ilişkilendiricilerin geliştirilmesi
- 1972: Korelasyon Matris belleğinin geliştirilmesi
- 1974: Geri Yayılım Modelinin ( Çok katmanlı algılayıcının ilk çalışmaları ) geliştirilmesi
- Öğretmensiz öğrenmenin geliştirilmesi:
- ✓ 1978: ART ( Adaptif Rezonans Teori ) modelinin geliştirilmesi
- ✓ 1982: Kohonen öğrenmesi ve SOM( Kendi kendini organize edene model ) modelinin geliştirilmesi
- 1982: Hopfield ağlarının geliştirilmesi
- 1982: Çok katmanlı algılayıcının geliştirilmesi

---

<sup>75</sup> Öztemel, ss.38-41.

- 1984: Boltzman makinesinin geliştirilmesi
- 1985: Çok katmanlı algılayıcıların ( Genelleştirilmiş Delta öğrenme kuralı ile ) geliştirilmesi
- 1988: RBF (Radyal Tabanlı Fonksiyonlar ) modelinin geliştirilmesi
- 1988: PNN (Probabilistik Ağlar ) modelinin geliştirilmesi
- 1991: GRNN ( Genel Regresyon Ağları ) modelinin geliştirilmesi
- 1991'den günümüze kadar sayısız uygulama ve çalışmalar geliştirilmiştir.

## 2.3. YAPAY SİNİR AĞLARI YAPISI VE TEMEL ELEMANLARI


### 2.3.1. Biyolojik Sinir Hücreleri

Biyolojik sinir ağlarının temel elemanı sinir hücreleridir ve insan beyninin korteks kısmında yer alan nöron (sinir hücresi) sayısı yaklaşık olarak  $10^{11}$  olup her hücre sayısı, 1000-10000 arasında değişen başka hücrelerle karşılıklı ilişki içerisindedir. Şekil 1'de gösterildiği gibi bir sinir hücresinin temel elemanları hücre gövdesi, dendrit ve akson'dur. Sinir hücresine diğer sinir hücrelerinden gelen uyarımlar, dendritler aracılığıyla hücre gövdesine taşınır ve hücre içi aktivasyonun/kararlılık halinin bozulmasıyla oluşan bir kimyasal süreç içerisinde diğer hücrelere aksonlarla iletilir; uyarımların diğer sinir hücrelerine taşınabilmesinde akson uçları ile dendritler arasındaki sinaptik boşluklar (sinaps) rol oynar. Sinaptik boşluk içinde yer alan "sinaptik kesecikler" gelen uyarımların diğer hücrelere dendritler aracılığıyla geçmesini koşullayan elemanlardır. Sinaptik boşluğa, "sinaptik kesecikler" tarafından sağlanan nöro-iletken maddenin dolması uyarımların diğer hücrelere geçişini koşullar. Hücrelere gelen uyarımlarla uyumlu olarak hücreler arasındaki mevcut sinaptik ilişkilerin değişimi veya hücreler arasında yeni sinaptik ilişkilerin kurulması "öğrenme" sürecine karşılık gelir.<sup>76</sup>

---

<sup>76</sup> M.Levent Koç ve diğerleri, " Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı", **İnşaat Mühendisleri Odası Yayını Teknik Dergi**, Cilt:15, Sayı:4, 2004, s.3354.


**Şekil 1:** Biyolojik Sinir Hücresi



Kaynak: Laurene Fausett, **Fundamentals of Neural Networks: Architectures, Algorithms and Applications**, Prentice Hall, New Jersey, 1994, p.6.

Yukarıda bahsedilen özelliklerde milyarlarca sinir hücresi bir araya gelerek sinir sistemini oluşturmaktadır. Yapay sinir ağları biyolojik sinir hücrelerinin bu özelliklerinden yararlanılarak geliştirilmiştir. Biyolojik sinir ağlarının yapay sinir ağlarına bir dayanak olduğu Şekil 2'de gösterilmiştir.

**Şekil 2:** Biyolojik ve Yapay Sinir Ağları



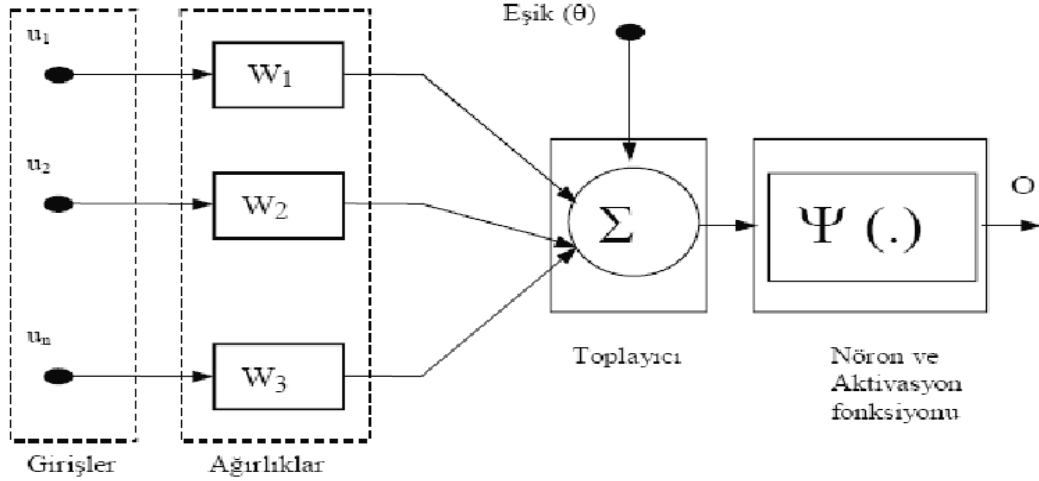
Kaynak: Öztemel, s.48.

### 2.3.2. Yapay Sinir Hücresi

Biyolojik sinir ağlarının hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir hücreleri, *proses elemanları* olarak da adlandırılmaktadır. Yapay sinir hücrelerinin beş temel elemanı vardır. Bunlar:

girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılarıdır. Şekil 3'de yapay sinir hücresinin temel elemanları gösterilmektedir.

**Şekil 3:** Yapay Sinir Hücresinin Yapısı



Kaynak: Okyay Kaynak ve M.Önder Efe, **Yapay Sinir Ağları ve Uygulamaları**, Boğaziçi Üniversitesi Yayınevi, İstanbul, 2000, s.6.

$$S = \sum_{i=1}^n w_i u_i - \theta \quad (2.1)$$

$$O = \Psi(S) \quad (2.2)$$

Her bir girdideki değişim, nöron çıkışında belirli bir değişime neden olmakta ve bu değişimin genliği, girdinin etki derecesini belirleyen bağlantı kazançlarına, toplayıcının eşik değerine ve nöron aktivasyon fonksiyonunun tipine bağlı olmaktadır. Burada  $S$  toplama fonksiyonu;  $w_i$  ile gösterilen kazançlar ağırlık;  $u_i$  girişler;  $\theta$  değeri eşik olarak;  $O$  çıkış;  $\Psi(S)$  fonksiyonu da nöron aktivasyon fonksiyonu olarak isimlendirilmektedir. Yukarıdaki denklemlerden de görülebileceği üzere eşik değerinin girdilerden bağımsız olmasından dolayı bütün girdilerin sıfır olduğu durumlarda nöron çıkışında  $\Psi(0)$  yerine  $\Psi(S)$  değeri gözlenir ki bu da, belirtilen şartlar altında nöron çıkışının sıfır olması zorunluluğunu ortadan kaldırır. Eşik değerinin kullanımı, uygulamada +1 veya -1 değerine sahip bir girdinin  $\theta$  ağırlığına sahip bir bağlantı ile toplayıcıya girdiği şeklinde ele alınır.<sup>77</sup>

<sup>77</sup> Kaynak ve Efe, s.7.

- Girdiler: Bir yapay sinir hücresine dış dünyadan gelen bilgilerdir. Girdiler( $u_1, u_2, \dots, u_n$ ) , kendinden önceki sinirlerden veya dış dünyadan sinir ağına gelebilir.<sup>78</sup>
- Ağırlıklar: Ağırlıklar( $w_1, w_2, \dots, w_n$ ), bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. 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.<sup>79</sup>
- Toplama Fonksiyonu: Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır ve böylece ağa gelen net girdi bulunmuş olur. Toplama fonksiyonu olarak değişik formüllerin kullanıldığı görülmektedir. Tablo 2'de toplama fonksiyonu örnekleri gösterilmiştir. 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 toplama fonksiyonuna da sahip olabilir.<sup>80</sup>

---

<sup>78</sup> Elmas, s.31.

<sup>79</sup> Haykin, p.157.

<sup>80</sup> Fausett, p.269.

**Tablo 2:** Toplama Fonksiyonu Örnekleri

<b>Net Giriş</b>	<b>Açıklama</b>
<i>Toplam</i> $\text{Net Girdi} = \sum_{i=1}^n u_i w_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler toplanarak net girdi hesaplanır.
<i>Çarpım</i> $\text{Net Girdi} = \prod_{i=1}^n u_i w_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır.
<i>Maksimum</i> $\text{Net Girdi} = \text{Max} ( u_i w_i ), i=1 \dots N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
<i>Minimum</i> $\text{Net Girdi} = \text{Min} ( u_i w_i ), i=1 \dots N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en küçüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
<i>Çoğunluk</i> $\text{Net Girdi} = \sum_{i=1}^n \text{sgn}( u_i w_i ), i = 1 \dots N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
<i>Kümülatif Toplam</i> $\text{Net Girdi} = \text{Net}_i (\text{eski} ) + \sum u_i w_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilerle eklenerek hücrenin net girdisi bulunur.

Kaynak: Öztemel, s.50.

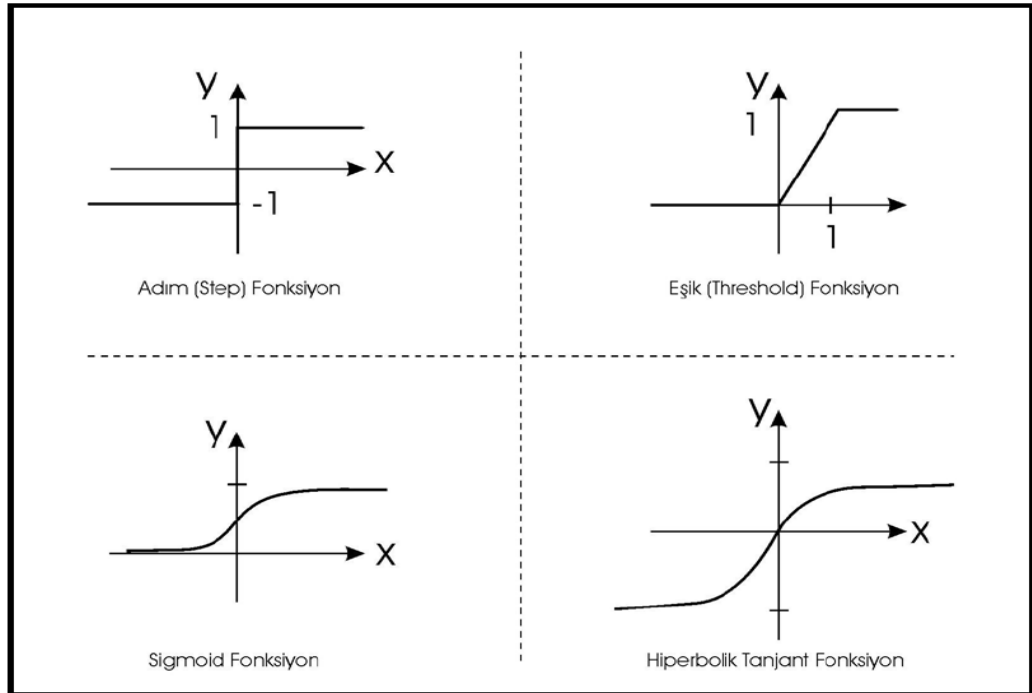
- ***Aktivasyon Fonksiyonu:*** Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak da çıktıyı hesaplamak için değişik formüller kullanılır. Bazı modeller bu fonksiyonunun türevi alınabilir bir fonksiyon olmasını şart koşturmaktadır. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da ağırlık proses elemanları farklı fonksiyonlar kullanabilir. En yaygın olarak kullanılan Çok Katmanlı Algılayıcı modelinde

genel olarak aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılır. Bu fonksiyon şu formül ile gösterilmektedir.

$$F ( NET ) = \frac{1}{1+e^{- NET}} \quad ( 2.3 )$$

Burada NET, proses elemanına gelen NET girdi değerini gösterir. Bu değer toplama fonksiyonu kullanılarak belirlenir.<sup>81</sup> En çok kullanılan aktivasyon fonksiyonları Şekil 4'te gösterilmiştir.

**Şekil 4:** Aktivasyon Fonksiyonu Örnekleri



Kaynak: Hasan Yurtoğlu, **Yapay Sinir Ağları ile Öngörü Modellemesi**, Uzmanlık Tezi, Devlet Planlama Teşkilatı, 2005, s.18.

- **Hücrenin Çıktısı:** 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 amacıyla. Aslında bir proses

<sup>81</sup> Öztemel, s.50.

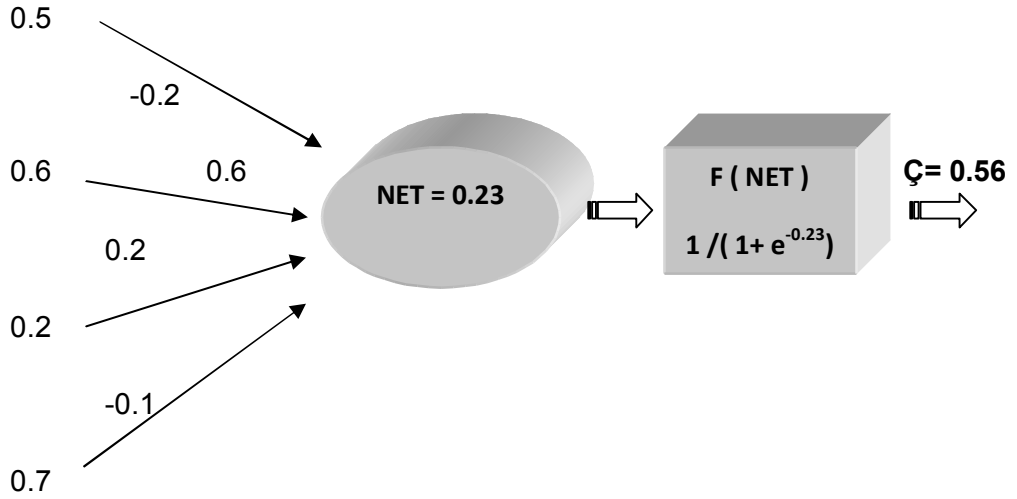


elemanından çıkan tek bir çıktı değeri vardır. Aynı değer birden fazla proses elemanına girdi olarak gitmektedir.<sup>82</sup>

### 2.3.3. Yapay Sinir Hücresinin Çalışma İlkesi

Bir yapay sinir hücresinin nasıl çalıştığı aşağıdaki örnek üzerinde açıklanmıştır. Bir proses elemanına gelen bilgiler ve ağırlıklar Şekil 5'de gösterilmiştir. Görüldüğü gibi yapay sinir hücresinin 4 girdisi ve 4 ağırlık değeri vardır.

**Şekil 5:** Bir Yapay Sinir Hücresinin Çalışması Örneği



Kaynak: Öztemel, s.52.

Hücreye gelen NET bilgi, ağırlıklı toplam alınarak şu şekilde hesaplanır.

$$NET = 0.5 * (-0.2) + 0.6 * 0.6 + 0.2 * 0.2 + 0.7 * (-0.1) = 0.23$$

Hücrenin sigmoid fonksiyonuna göre çıktısı (Ç) hesap edilir ise;

$$\Ç = 1 / ( 1 + e^{-0.23} ) = 0.56$$


Bir ağıdaki bütün proses elemanlarının çıktıların bu şekilde hesaplanması sonucu ağı girdilere karşılık ürettikleri çıktılar hesaplanır.

<sup>82</sup> Elmas, s.33.

### 2.3.4. Yapay Sinir Ağının Yapısı

Yapay sinir hücrelerinin (nöronların) birbirleriyle bağlantılar aracılığıyla bir araya gelmeleri yapay sinir ağını oluşturmaktadır. Genel olarak, sinir hücreleri katmanlar halinde ve her katman içinde paralel olarak bir araya gelerek ağı meydana getirirler. Bir yapay sinir ağında birbirleriyle bağlantılı sinir hücrelerinin yer aldığı girdi katmanı (input layer); çıktı katmanı (output layer) ve gizli katman (hidden layer) olmak üzere temelde üç katman bulunmaktadır. Girdilerden oluşan girdi katmanı ile çıktılardan oluşan çıktı katmanı tektir. Gizli katman sayısı ise YSA' nın yapısına göre bir veya birden çok olabilmektedir. Girdi katmanından alınan girişler, girdi katmanı ve gizli katman arasında bulunan bağlantı ağırlıkları ile çarpılıp gizli katmana iletilmektedir. Gizli katmandaki nöronlara gelen girişler toplanarak aynı şekilde gizli katman ile çıktı katmanı arasındaki bağlantı ağırlıkları ile çarpılarak çıktı katmanına iletilir. Çıktı katmanındaki nöronlar da, kendisine gelen bu girişleri toplayarak buna uygun bir çıkış üretirler. Bağlantıların ağırlık değerleri öğrenme sürecinde belirlenmektedir. Şekil 6' da bir yapay sinir ağını oluşturan katmanlar görülmektedir.<sup>83</sup>

**Şekil 6:** YSA'ların Genel Yapısı



Kaynak: Yurtoğlu, s.20.

<sup>83</sup> Özcan Asilkan ve Sezgin Irmak, "İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin edilmesi", **S.D.Ü İktisadi ve İdari Bilimler Fakültesi Dergisi**, Cilt: 14, Sayı:2, 2009, s. 380.

## 2.4. YAPAY SİNİR AĞLARINDA ÖĞRENME

Yapay sinir ağları, öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. Diğer bir ifadeyle, normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretebilmektedirler. Bir insanın düşünme ve gözleme yeteneklerini gerektiren problemlere yönelik çözümler üretebilmesinin temel sebebi ise insan beyninin ve dolayısıyla insanın sahip olduğu yaşayarak veya deneyerek öğrenme yeteneğidir. Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik bağlantıların ayarlanması ile olmaktadır. Yani, insanlar doğumlarından itibaren bir “yaşayarak öğrenme” süreci içerisine girerler. Bu süreç içinde beyin sürekli bir gelişme göstermektedir. Yaşayıp tecrübe ettikçe sinaptik bağlantılar ayarlanır ve hatta yeni bağlantılar oluşur. Bu sayede öğrenme gerçekleşir. Bu durum yapay sinir ağları için de geçerlidir.<sup>84</sup>

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.<sup>85</sup>

### 2.4.1. Öğrenme Yöntemleri

Yapay sinir ağları gibi örneklerden öğrenen sistemlerde farklı öğrenme yöntemleri kullanılmaktadır. Öğrenmeyi gerçekleştirecek sistem ve kullanılan öğrenme algoritması bu yöntemlere bağlı olarak değişmektedir. Genel olarak üç öğrenme yöntemi ve bunların karması uygulanmaktadır.<sup>86</sup> Bu yöntemler:

---

<sup>84</sup> Elmas, s.87.


<sup>85</sup> Fausett, p.295.

<sup>86</sup> Haykin, p.85.

### 2.4.1.1. Danışmanlı Öğrenme

Bu tür öğrenmede öğrenen sistemin olayı öğrenebilmesine bir öğretmen yardımcı olmaktadır. Danışmanlı öğrenmede, yapay sinir ağı kullanılmadan önce eğitilmelidir. Eğitim işlemi, sinir ağına giriş ve çıkış bilgileri sunmaktan oluşur. Ağ giriş bilgisine göre ürettiği çıkış değerini, istenen değerle karşılaştırarak ağırlıkların değiştirilmesinde kullanılacak bilgiyi elde eder. Girilen değerle istenen değer arasındaki fark hata değeri olarak önceden belirlenen değerden küçük oluncaya kadar eğitime devam edilir. Hata değeri istenen değer altına düştüğünde tüm ağırlıklar sabitlenerek eğitim işlemi sonlandırılır. En çok kullanılan model olan “ Çok Katmanlı Algılayıcı (ÇKA) ” bu öğrenmeyi kullanan ağlara örnek olarak verilebilir.<sup>87</sup> Şekil 7’de danışmanlı öğrenme yapısı gösterilmektedir.

Şekil 7: Danışmanlı Öğrenme Yapısı



Kaynak: Şeref Sağıroğlu ve diğerleri, **Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları**, Ufuk Kitap Kirtasiye Yayıncılık, Kayseri, 2003, s.81.

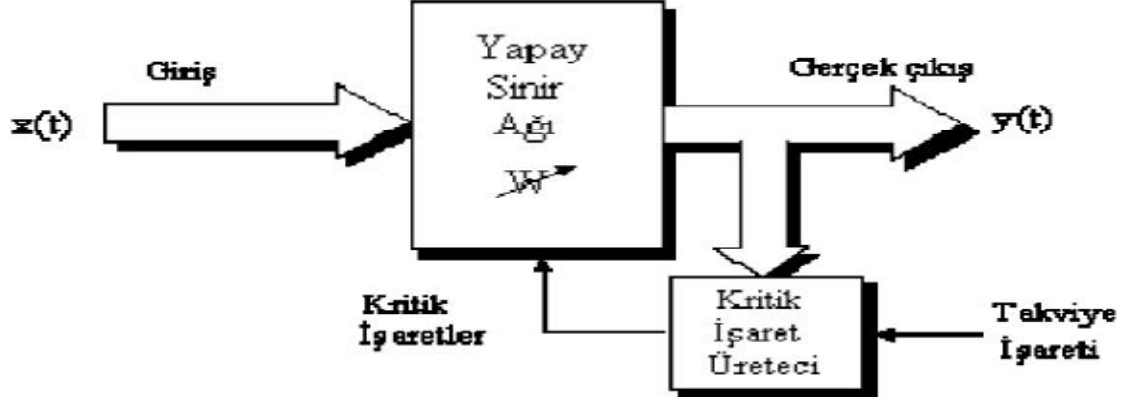
### 2.4.1.2. Destekleyici Öğrenme

Bu tür yöntemde de öğrenen sisteme bir öğretmen yardımcı olmaktadır. Fakat öğretmen her girdi seti için olması gereken çıktı setini sisteme göstermek yerine sistemin kendisine gösterilen girdilere karşılık olarak çıktısını üretmesini bekler. Üretilen çıktının doğru ya da yanlış olduğunu gösteren bir sinyal üretilir. Sistem, öğretmenden gelen bu sinyali dikkate alarak öğrenme sürecini devam ettirir.

<sup>87</sup> Elmas, s.88.

“Vektör Kuantizasyon Modelleri (LVQ)” ağı bu öğrenme yöntemini kullanan sistemlere örnek olarak verilebilir.<sup>88</sup> Şekil 8’de destekleyici öğrenme yapısı gösterilmektedir.

**Şekil 8:** Destekleyici Öğrenme Yapısı



Kaynak: Sağıroğlu ve diğerleri, s.81.

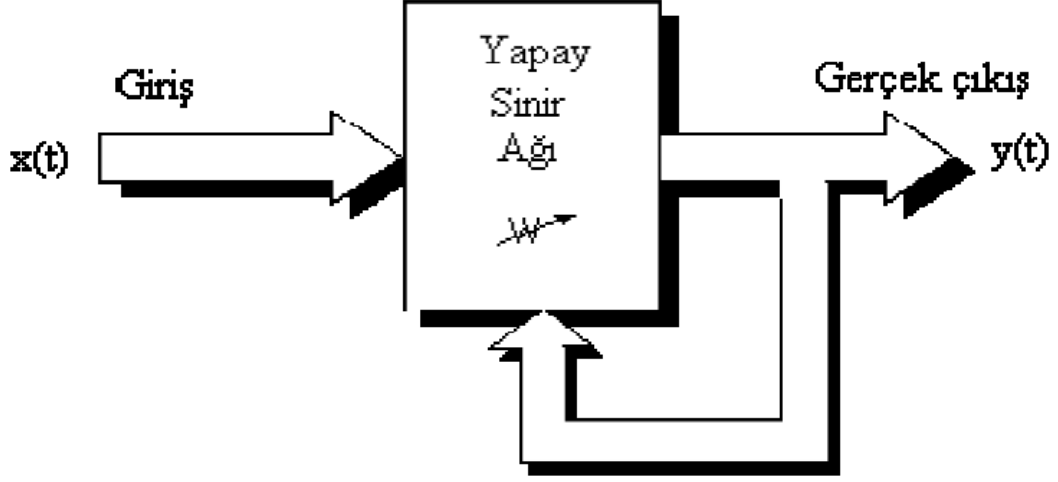
### 2.4.1.3. Danışmansız Öğrenme

Bu öğrenme yöntemine “Kendi Kendine Öğrenen Metot” da denilmektedir. Bu öğrenme yönteminde sistemin öğrenmesine yardımcı olan herhangi bir öğretmen yoktur. Sisteme sadece girdi değerleri gösterilir. Örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendisine öğrenmesi beklenir. Bu, daha çok sınıflandırma problemleri için kullanılan bir öğrenme yöntemidir. Yalnız, sistemin öğrenmesi bittikten sonra çıktıların ne anlama geldiğini gösteren etiketlendirmenin kullanıcı tarafından yapılması gerekmektedir. En yaygın olarak “Kohonen Ağları” ve “Adaptif Rezonans Teorisi Modelleri (ART) Ağları” bu öğrenme yöntemini kullanan sistemlere örnek olarak verilebilir.<sup>89</sup> Şekil 9’da danışmansız öğrenme yapısı gösterilmektedir.

<sup>88</sup> Öztemel, s.25.

<sup>89</sup> Miloslav Hajek, “ Neural Networks” , <http://www.cs.unp.ac.za/notes/NeuralNetworks2005.pdf>, (21.02.2012), p.19.

**Şekil 9** : Danışmansız Öğrenme Yapısı



Kaynak: Sağiroğlu ve diğerleri, s.81.

Yukarıda anlatılan üç temel yöntemin birlikte kullanıldığı karma yöntemler de uygulanmaktadır. Kısmen öğretmenli, kısmen öğretmensiz olarak öğrenme yapan ağlarda kullanılır. “Radyal Tabanlı Yapay Sinir Ağlar (RBN)” ve “Olasılık Tabanlı Yapay Sinir Ağları (PBN)” karma öğrenme yöntemine örnek verilebilir.<sup>90</sup>

#### 2.4.2. Öğrenme Kuralları

YSA' nın veri yapısındaki ilişkiyi öğrenmesi, probleme ait örnekler yardımı ile ağ ağırlıklarının en uygun değerlerinin belirlenmesine dayanır. Yapay sinir ağındaki herhangi bir ağırlık ele ( $W_i$ ) alındığında, öğrenme matematiksel olarak aşağıdaki şekilde ifade edilir:

$$W_{yeni} = W_{eski} \pm \Delta W \quad (2.4)$$

Burada  $\Delta W$ , belirli bir kurala göre hesaplanarak o anki ağırlıklara uygulanacak düzeltme miktarını verir.  $\Delta W$  'yi belirlemek için tanımlanmış kurallara “öğrenme algoritmaları” ya da “öğrenme kuralları” denilmektedir.<sup>91</sup>

Yapay sinir ağları gibi öğrenen sistemlerde öğrenme bazı kurallara göre gerçekleştirilmektedir. Bu kuralların bazıları çevrimiçi ( on-line ) bazıları ise çevrimdışı ( off-line ) olarak çalışmaktadır. Bunlar:<sup>92</sup>

<sup>90</sup> Haykin, p.88.

<sup>91</sup> Asilkan ve Irmak, s.381.

<sup>92</sup> Elmas, s.138.

- Çevrimiçi (On-line) Öğrenme Kuralları: Bu kurallar gerçek zamanlı çalışabilir. Bu kurallara göre öğrenen sistemler gerçek zamanda çalışırken bir taraftan fonksiyonlarını yerine getirmekte diğer taraftan ise öğrenmeye devam etmektedir. *ART* ağının öğrenme kuralı ve *Kohonen* öğrenme kuralı çevrimiçi öğrenmeye örnek olarak verilebilir.
- Çevrimdışı (Off-line) Öğrenme Kuralları: Bu kurallara göre öğrenen sistemler kullanıma alınmadan önce örnekler üzerinde eğitilirler. Eğitildikten sonra gerçek hayatta kullanıma alındıktan sonra öğrenme olmamaktadır. Sistem öğrenmesi gereken yeni bilgiler söz konusu olduğunda kullanımdan çıkarılmakta ve çevrimdışı olarak yeniden eğitilmektedir. Eğitim tamamlanınca sistem tekrar kullanıma alınır. Yapay sinir ağlarında yaygın olarak kullanılan "*Delta Öğrenme Kuralı*" çevrimdışı öğrenmeye örnek olarak verilebilir.

Öğrenme sistemlerinde kullanılan değişik öğrenme kuralları vardır. En çok kullanılan öğrenme kuralları aşağıda açıklanmıştır.

#### **2.4.2.1. Hebb Kuralı**

İlk ve en bilinen öğrenme kuralı olan Hebb kuralı, 1949 yılında Donald Hebb tarafından geliştirilmiştir. Yapay sinir ağlarında öğrenme kurallarının çoğu *Hebb* kuralına dayanmaktadır. Tanımı, "*The Organization of Behavior*" kitabında anlatılmıştır. Kurala göre, bir hücre diğer bir hücreden bilgi alırsa ve her iki hücre de aktif ise her iki hücre arasındaki bağlantı kuvvetlendirilmelidir. Eğer A hücresi B hücreyi uyarmaya yetecek kadar yakınsa ve B hücrenin aktifleştirilmesinde sürekli olarak yer alıyorsa, A hücrenin etkinliği arttırılacak şekilde bir veya her iki hücrede de değişiklikler yapılır. Bu kural şu şekilde özetlenebilir. Bir hücre kendisi aktif ise bağlı olduğu hücreyi aktif yapmaya pasif ise pasif yapmaya çalışmaktadır.<sup>93</sup>

#### **2.4.2.2. Hopfield Kuralı**

Bu kural *Hebb* kuralına benzemektedir. Yapay sinir ağı elemanlarının bağlantılarının ne kadar kuvvetlendirilmesi veya zayıflatılması gerektiği belirlenir. Eğer beklenen çıktı ve girdiler ikisi de aktif/pasif ise öğrenme katsayısı kadar ağırlık değerleri kuvvetlendirilir/zayıflatılır. Yani, ağırlıkların kuvvetlendirilmesi veya

---

<sup>93</sup> Haykin, p.77.

zayıflatılması öğrenme katsayısı ile gerçekleştirilir. Öğrenme katsayısı genelde 0-1 arasında kullanıcı tarafından atanan sabit ve pozitif bir değerdir.<sup>94</sup>

#### 2.4.2.3. Delta Kuralı

Delta kuralı ilk olarak Widrow ve Hoff tarafından geliştirilmiş daha çok mühendislik kökenli bir algoritmadır. Bu kural, nöronun gerçek çıkışı ile istenilen çıkış değerleri arasındaki farkı azaltan, giriş bağlantılarını güçlendiren ve sürekli olarak değiştiren bir düşünceye dayanmaktadır. Delta kuralı, ortalama karesel hatayı, bağlantı ağırlık değerlerinin değiştirilmesi ile düşürme prensibine dayanır. Bu nedenle de bu algoritma en küçük kareler öğrenme kuralı olarak da bilinmektedir. Hata aynı anda bir katmandan bir önceki katmanlara geri yayılarak azaltılır. Ağın hatalarının düşürülmesi işlemi, çıkış katmanından giriş katmanına ulaşıncaya kadar devam eder.<sup>95</sup>

#### 2.4.2.4. Kohonen Kuralı

Teuvo Kohonen (1982) tarafından, biyolojik sistemlerdeki öğrenmeden esinlenilerek geliştirilen bu öğrenme kuralına, *Yarışmacı Öğrenme Kuralı* da denmektedir. Bu kurala göre ağın elemanları ağırlıkları değiştirmek için birbirleri ile yarışır. Hebb kuralından farklı olarak bir seferde yalnız bir işlemci elemanın, yani yalnızca kazanan nöronun bağlantı ağırlıkları değiştirilmektedir. En uygun çıktıya sahip işlemci elemanın kazandığı bu kuralda, kazanan işlemci eleman, kendisine komşu diğer işlemci elemanların ağırlıklarının değiştirilmesine de izin vermektedir. Sadece kazanan elemanın çıktı üretmesine ve komşu hücreleri ile birlikte ağırlıklarının değiştirilmesine izin verilir. Komşu sayısı eğitim süresince değişiklik gösterir. Eğitim süreci boyunca en geniş komşu tanımından en dar komşu tanımına inilir. Kazanan eleman girdi desenini en iyi ifade eden eleman olarak tanımlanır.<sup>96</sup>

---

<sup>94</sup> Fausett, p.49.

<sup>95</sup> Tuğba Saraç, **Yapay Sinir Ağları**, Seminer Projesi, Gazi Üniversitesi Endüstri Mühendisliği Bölümü Anabilim Dalı, Ankara, 2004, s.59.

<sup>96</sup> Saraç, s.67.




## 2.5. YAPAY SİNİR AĞI MODELLERİ

Bir yapay sinir ağında proses elemanlarının bağlanması sonucu oluşan topoloji, proses elemanlarının sahip oldukları toplama ve aktivasyon fonksiyonları, öğrenme stratejisi ve kullanılan öğrenme kuralına göre çeşitli ağ modelleri vardır. Bunlardan en çok kullanılan örnekler aşağıda anlatılmıştır.

### 2.5.1. Tek Katmanlı Algılayıcılar

Tek katmanlı yapay sinir ağları sadece girdi ve çıktı katmanlarından oluşur. Her ağın bir ya da daha fazla girdisi ve çıktısı (  $\Phi$  ) vardır. Çıktı üniteleri, bütün girdi ünitelerine (  $X$  ) bağlanmaktadır. Her bağlantının bir ağırlığı (  $W$  ) vardır.<sup>97</sup> İki girdi ve bir çıktıdan oluşan tek katmanlı ağ yapısı Şekil 10'da verilmiştir.

Şekil 10: Tek Katmanlı Algılayıcı Modeli



Kaynak: Öztemel, s.59.

Bu ağlarda proses elemanlarının değerlerinin sıfırdan farklı olmasını sağlayan bir (  $\Phi$  ) eşik değeri vardır. Eşik değerinin girdisi daima 1'dir. Ağın çıktısı ağırlıklandırılmış girdi değerlerinin eşik değeri ile toplanması sonucu bulunur. Çıktı fonksiyonu doğrusal bir fonksiyondur. Yani, ağa gösterilen örnekler iki sınıf arasında paylaştırılarak iki sınıfı birbirinden ayıran doğru bulunmaya çalışılır. Bunun için eşik değer fonksiyonu kullanılır. Sınıf ayırıcı denilen doğru şu şekilde tanımlanmaktadır.

$$W_1 * X_1 + W_2 * X_2 + \Phi = 0 \quad (2.5)$$

Bu ağlarda öğrenmeden kasıt ağın sınıf ayırıcı doğrusunun pozisyonunu her iki sınıfı en iyi şekilde ayıracak pozisyonu belirlemektir. Bunun için ağırlık

<sup>97</sup> Haykin, p.139.

değerlerinin değiştirilmesi gerekir. Yani  $t$  zaman biriminde ağırlık değerleri  $\Delta W$  kadar değiştirilir ve yeni ağırlık değerleri;

$$W_i(t+1) = W_i(t) + \Delta W_i(t) \quad (2.6)$$

Ağırlıkların değiştirilmesi doğrunun eğimini değiştirmek anlamına gelmektedir. Bu yeterli olmayabilir. Bunun yanında eşik değerin de değiştirilmesi gerekir. Buna göre  $t$  zaman biriminde eşik değeri  $\Delta \Phi$  kadar değiştirilir ve yeni eşik değeri;

$$\Phi_i(t+1) = \Phi_i(t) + \Delta \Phi_i(t) \quad (2.7)$$

olur.<sup>98</sup>

Tek katmanlı algılayıcılarda önemli iki modelden bahsedilebilir. Bunlar:<sup>99</sup>

- Basit Algılayıcı (Perseptron) Modeli
- Adaline / Madaline ünitesidir.

### 2.5.1.1. Basit Algılayıcı Modeli ( Perseptron )

İlk defa 1958 yılında Rosenblat tarafından şekil sınıflandırma amacı ile geliştirilmiştir. Perseptron, bir sinir hücresinin birden fazla girdiyi alarak bir çıktı üretmesi prensibine dayanır. Ağın çıktısı bir veya sıfırdan oluşan mantıksal bir değerdir. Çıktının hesaplanmasında eşik değer fonksiyonu kullanılır. Basit algılayıcılar eğitilebilir tek bir yapay sinir hücresinden oluşur. Eğitilebilirden kasıt ağırlıkların değiştirilebilir olmasıdır. Girdiler işlem elemanına gösterilirler ve her girdi setine karşılık gelen çıktı değerleri de ağa gösterilir. Daha sonra öğrenme kuralına göre ağın çıktı değerleri hesaplanır. Eğer ağın çıktısı olması gereken çıktıdan farklı ise ağırlıklar ve eşik değerleri değiştirilir. Değişikliğin nasıl yapılacağını ise öğrenme kuralı belirler ve girdilere karşılık gelen çıktı değerleri bir veya sıfırdan oluşur.<sup>100</sup>

Şekil 11'de Perseptron'un yapısı gösterilmektedir.


---

<sup>98</sup> Öztemel, ss.60-61.

<sup>99</sup> Haykin, p.157.

<sup>100</sup> Öztemel, s.61.

Şekil 11: Basit Algılayıcı Yapısı



Kaynak: Öztemel, s.61.

Basit algılayıcıların öğrenme kuralı aşağıda açıklanmıştır:<sup>101</sup>

- **Adım 1:** Ağa girdi seti ve beklenen çıktı gösterilir. Burada birden fazla girdi değeri olabilir. Çıktı değeri ise 1 ve 0 değerlerinden birisini alır.
- **Adım 2:** Perseptron ünitesine gelen net girdi şu şekilde hesaplanır:

$$NET = \sum_{i=1}^n w_i x_i \quad (2.8)$$

- **Adım 3:** Perseptron ünitesinin çıktısı hesaplanır.

$$\checkmark = \begin{cases} 1 & NET > \Phi \\ 0 & NET \leq \Phi \end{cases} \quad (2.9)$$

Eğer gerçekleşen çıktı ile beklenen çıktı aynı ise ağırlıklarda değişiklik olmaz.

Ağ, beklenmeyen bir çıktı üretmiş ise o zaman iki durum söz konusudur:

- a) Ağın beklenen çıktısı 0 değeridir. Fakat NET girdi eşik değerinin üstündedir. Yani ağın gerçekleşen çıktısı 1 değeridir. Bu durumda vektörel olarak;

$$W_n = W_0 - \lambda X \quad (2.10)$$

olur. Burada  $\lambda$ , öğrenme katsayısıdır. Ağırlıkların değişim miktarını belirler ve sabit bir değer olarak alınmaktadır.

- b) Beklenen çıktınının 1 olması ve ağın gerçekleşen çıktısınının 0 olması durumudur. Yani NET girdi eşik değerinin altındadır. Bu durumda vektörel olarak;

<sup>101</sup> Öztemel, s.62.


$$W_n = W_0 + \lambda X \text{ olacaktır.} \quad (2.11)$$

- **Adım 4:** Yukarıdaki adımlar bütün girdi setindeki değerler için doğru sınıflandırmalar yapıncaya kadar ilk üç adımdaki işlemler tekrarlanır.

### 2.5.1.2. Adaline/Madeline Modeli

ADALINE, Widrow ve Hoff tarafından 1959 yılında gerçekleştirilmiş olup adaptif doğrusal eleman (Adaptif Linear Element) ağının kısaltılmış halidir. ADALINE bir proses elemanından (Adaline ünitesi) oluşan bir ağıdır. MADALINE ağları ise birden fazla ADALINE ünitesinin bir araya gelerek oluşturdukları ağa verilen isimdir. Şekil 12' de ADALINE ünitesinin yapısı gösterilmiştir. ADALINE ağı en küçük ortalamaların karesi yöntemine dayanmaktadır. Öğrenme kuralına delta kuralı da denilmektedir. Öğrenme kuralı, ağın çıktısının beklenen çıktı değerine göre hatasını en aza indirecek şekilde ağın ağırlıklarının değiştirilmesi prensibine dayanır. MADALINE ağının öğrenme kuralı ADALINE ünitesi ile aynıdır. Basit algılayıcı modeli ile ADALINE/MADALINE modellerini birbirinden ayıran tek şey öğrenme kuralıdır.<sup>102</sup>

**Şekil 12:** Adaline Ünitesi



Kaynak: Öztemel, s.98.

### 2.5.2. Çok Katmanlı Algılayıcı ( Geriye Yayım ) Modeli

Bir yapay sinir ağının öğrenmesi istenen olayların girdi ve çıktıları arasındaki ilişkiler doğrusal olmayan ilişkiler olursa tek katmanlı algılayıcılar ile öğrenme gerçekleştirmek mümkün değildir. Günlük olayların çoğu doğrusal olmayan nitelik

<sup>102</sup> Haykin, p.118.

taşımaktadır ve doğrusal olmayan problemleri çözmek için yeni modellerin geliştirilmesine ihtiyaç duyulmuştur. Bu sorunu çözmek için çok katmanlı algılayıcılar geliştirilmiştir. Bu modele, *hata yayma modeli* veya *geriye yayım modeli* de denmektedir.<sup>103</sup>

Çok Katmanlı Algılayıcılar; günümüzde birçok probleminin çözümünde kullanılmaktadır. Bugün özellikle sınıflandırma işlemlerinde en çok kullanılan yöntemlerin başında gelmektedir. Bunun yanında tanıma ve genelleme yapmayı gerektiren problemler için çok önemli bir çözüm aracıdır. ÇKA'lar; girdi katmanı, gizli katmanlar ve çıktı katmanı olmak üzere 3 katmandan oluşmaktadır. Bilgiler girdi katmanından ağa tanıtılır, gizli katmanlardan çıktı katmanına ulaşır ve çıktı katmanından dış dünyaya aktarılır. ÇKA ağlarının yapısı, Şekil 13'de gösterilmektedir.<sup>104</sup>

ÇKA'larda; öğretmenli öğrenme yöntemi kullanılmaktadır. Ağa hem girdiler, hem de bu girdilerden oluşturulması gereken çıktılar sunulmaktadır. Ağ; örneklere bakarak problem uzayında bir çözüm üretir, bu genellemeye bağlı olarak gelecek yeni örnekler için de çözüm üretebilmektedir. ÇKA ağının öğrenme kuralı en küçük kareler yöntemine dayalı Delta öğrenme kuralının genelleştirilmiş halidir. Bu nedenle öğrenme kuralına Genelleştirilmiş Delta Kuralı da denmektedir. Genelleştirilmiş “Delta Kuralı” iki safhadan oluşur. Bunlar:<sup>105</sup>

- *İleri doğru hesaplama*: Ağın çıktısını hesaplama aşamasıdır. Bu safhada bilgi işleme eğitim setindeki bir örneğin girdi katmanından ağa gösterilmesi ile başlar. Gelen girdiler hiçbir değişiklik olmadan ara katmana gönderilir. Ara katmandaki her proses elemanı girdi katmanındaki bütün proses elemanlarından gelen bilgileri ağırlıklarının etkisi ile alır. Öncelikle ara katmandaki proses elemanlarına gelen net girdi hesaplanır. Bu net girdinin aktivasyon fonksiyonundan ( genellikle sigmoid fonksiyonu ) geçirilmesiyle ara katman elemanlarının çıktısı hesaplanır. Ara katman proses elemanları ve çıktı katmanının proses elemanlarının çıktıları aynı şekilde kendilerine gelen net girdinin hesaplanıp aktivasyon fonksiyonundan geçirilmesi ile belirlenir. Çıktı katmanından çıkan değerler bulununca ağın ileri hesaplama işlemi tamamlanmış olur.

---


<sup>103</sup> Elmas, s.114.

<sup>104</sup> Murat Sazlı ve Haluk Tanrıku, “ Saldırı Tespit Sistemlerinde Yapay Sinir Ağlarının Kullanılması ”, **XII. “Türkiye’de İnternet Konferansı”** , Ankara,2007, s.220.

<sup>105</sup> Öztemel, s.77.

- **Geri doğru hesaplama:** Ağırlıkları değiştirme aşamasıdır. Ağa sunulan girdi için ağın ürettiği çıktı, beklenen çıktılar ile karşılaştırılır. Bunların arasındaki fark hata olarak kabul edilir. Çıktı katmanı için oluşan toplam hatayı bulmak için bütün hataların toplanması gerekir. Bazı hata değerleri negatif olacağından toplamın sıfır olmasını önlemek amacı ile ağırlıkların kareleri toplanarak sonucun karekökü alınır. ÇKA ağının eğitilmesindeki temel amaç bu hatayı en azlamaktır. Bunun için hatanın, kendisine neden olan proses elemanlarına dağıtılması gerekmektedir. Bu ise proses elemanlarının ağırlıklarını değiştirmek demektir. Ağın ağırlıklarını değiştirmede iki durum söz konusudur:
  - ✓ Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi
  - ✓ Ara katmanlar arası veya ara katman girdi katmanı arasındaki ağırlıkların değiştirilmesi şeklindedir.

**Şekil 13:** ÇKA Modeli



Kaynak: Mahmut Fırat ve Mahmut Güngör, "Aski Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağı ile Belirlenmesi", **İMO Teknik Dergi**, Cilt:21, Sayı:9, 2005, s.61.

### 2.5.2.1. Çok Katmanlı Algılayıcı Ağının Çalışma Prosedürü

ÇKA ağlarının çalışması şu adımları içerir:<sup>106</sup>

- *Örneklerin toplanması:* Ağın çözmesi için istenilen olay için daha önce gerçekleşmiş örnekler bulunur. Öğrenmesi için eğitim seti ve test için test seti örnekleri toplanır. Eğitim seti ile ağın öğrenmesi sağlanır ve test seti ile ağın performansı ölçülür.
- *Ağın topolojik yapısının belirlenmesi:* Öğrenilmesi istenen olay için oluşturulacak ağın topolojik yapısı; kaç tane girdi elemanı, kaç tane ara katman, her ara katmanda kaç tane proses elemanı ve kaç tane çıktı elemanı olması gerektiği bu adımda belirlenir.
- *Öğrenme parametrelerinin belirlenmesi:* Ağın öğrenme katsayısı, proses elemanlarının toplama ve aktivasyon fonksiyonları, momentum katsayısı gibi parametreler bu adımda belirlenir.
- *Ağırlıkların başlangıç değerlerinin atanması:* Proses elemanlarını birbirlerine bağlayan ağırlık değerlerinin ve eşik değer ünitesinin ağırlıklarının başlangıç değerlerinin atanması yapılır. Başlangıçta genelde rastgele değerler atanır. Daha sonra uygun değerleri öğrenme sırasında kendi belirler.
- *Öğrenme setinden örneklerin seçilmesi ve ağa gösterilmesi:* Ağın öğrenmeye başlaması için ağa örnekler belirli bir düzeneğe göre gösterilir.
- *Öğrenme sırasında ileri hesaplamaların yapılması:* Sunulan girdi için ağın çıktı değerleri hesaplanır.
- *Gerçekleşen çıktının beklenen çıktı ile karşılaştırılması:* Ağın ürettiği hata değerleri bu adımda hesaplanır.
- *Ağırlıkların değiştirilmesi:* Genelleştirilmiş Delta Kuralına göre hatanın azaltılması için ağırlıkların değiştirilmesi yapılır.

Çok Katmanlı Algılayıcı ağının öğrenmesi tamamlanıncaya kadar yani hatalar kabul edilir düzeye ininceye kadar devam eder. Ağın öğrenmesi için bir durdurma kriterinin olması gerekir. Bu ise genellikle üretilen hatanın belirli bir düzeyin altına düşmesi olarak alınmaktadır.


---

<sup>106</sup> Elmas, s.111.

### 2.5.2.2. Çok Katmanlı Algılayıcı Ağının Eğitilmesi

ÇKA ağlarının eğitilmesi genel olarak diğer ağların eğitilmesi ile aynı mantıktadır. Ağın kendisine gösterilen girdi örneği için beklenen çıktıyı üretmesini sağlayacak ağırlık değerleri bulunmaya çalışılır. Başlangıçta bu değerler rastgele atanmakta ve ağa örnekleri gösterdikçe ağın ağırlıkları değiştirilerek zamanla istenen değerlere ulaşması sağlanmaktadır. İstenen ağırlık değerlerinin ne olduğu bilinmemektedir. Burada amaç problem uzayında en az hata verebilecek ağırlık değerlerine ulaşmaktır. Şekil 14'de görüldüğü üzere problemin çözümü için en az hatayı veren ağırlık vektörü  $W^*$  olmasına rağmen bu hata değerini yakalamak çoğunlukla mümkün olmayabilmektedir. Bu çözüm ağın sahip olabileceği *en iyi çözümdür*. Ağ, bazen farklı bir çözüme takılabilmekte ve performansı iyileştirmek mümkün olmadığından kullanıcılar ağların performansında  $\epsilon$  kadar hatayı kabul etmektedir (tolerans değeri). Tolerans değeri altındaki herhangi bir noktada olay öğrenilmiş kabul edilir.  $W_0$  ve  $W_2$  çözümleri kabul edilebilir hata düzeyinin üzerinde olduğundan kabul edilemez çözümlerken,  $W_1$  ve  $W_3$  çözümleri en iyi çözümler olmamalarına rağmen kabul edilebilir hata düzeyinin altında bir hataya sahiptirler. Bunlara *yerel çözümler* denilir. Görüldüğü üzere bir problem için birden fazla çözüm üretilebilmektedir. Bu nedenle yapay sinir ağlarının en iyi çözümleri ürettikleri söylenemez. Kabul edilebilir bir çözüm ürettiklerini söylemek daha doğrudur. Üretilen çözüm en iyi çözüm olsa bile bunun bilinmesi mümkün değildir.<sup>107</sup>

Şekil 14: Çok Boyutlu Hata Uzayı



Kaynak: Öztemel, s.83.

<sup>107</sup> Öztemel, s.82.



Bazı durumlarda ağın takıldığı yerel çözüm kabul edilebilir hata düzeyinin üstünde kalabilir. Bu durumda ağın öğrenmesi için bazı değişiklikler yapılarak yeniden eğitilmesi gerekir. Bu değişiklikler:<sup>108</sup>

- Başka başlangıç değerleri kullanılabilir,
- Topolojide değişiklikler yapılabilir (ara katman sayısını artırmak, proses elemanı sayısını artırmak veya azaltmak gibi),
- Parametrelerde değişiklik yapılabilir (fonksiyonların başka seçilmesi, öğrenme ve momentum katsayılarının değiştirilmesi gibi)
- Problemin gösterimi ve örneklerin formülasyonu değiştirilerek yeni örnek seti oluşturulabilir,
- Öğrenme setindeki örneklerin sayısı artırılabilir veya azaltılabilir.

Çok katmanlı algılayıcılarda ağların yerel çözümlere takılmaması için momentum katsayısı geliştirilmiştir. Bu katsayının iyi kullanılması yerel çözümleri tolerans değerinin altına çekebilir.<sup>109</sup>

Çok katmanlı algılayıcı ağların eğitilmesinde öğrenme süresinin çok uzun olması da ayrı bir problemdir. Ağırlık değerleri başlangıçta çok büyük verilirse veya ağırlık değerleri arasındaki aralıklar küçük seçilirse öğrenme çok uzun sürebilir. Bu konuya çözüm getirecek bilimsel bir yaklaşım yoktur. Tamamen deneme yanılma yolu ile en uygun başlama koşullarının belirlenmesi gerekmektedir.<sup>110</sup>

Ağın öğrenmesini göstermenin en iyi yolu hata grafiğini çizmektir. Çok Katmanlı Algılayıcı ağın öğrenmesi sırasında Şekil 15'de görüldüğü gibi bir hata grafiği oluşur. Burada hatanın zaman içinde azaldığı görülür Belirli bir iterasyondan sonra ağın öğrenmesinin durduğu gözlemlenir. Bu durum ağın daha fazla öğrenemeyeceği ve daha iyi bir sonuç bulamayacağı anlamına gelir. Eğer çözüm tolerans değerlerinin üstünde ise yerel çözüme takılmış demektir. Bu durumda yukarıda belirtilen değişiklikler yapılarak ağın yeniden eğitilmesi gerekir.<sup>111</sup>

---


<sup>108</sup> Elmas, s.113.

<sup>109</sup> Birgül Kutlu ve Bertan Badur," Yapay Sinir Ağları ile Borsa Endeksi Tahmini", **İstanbul Üniversitesi İşletme İktisadi Yönetim Dergisi**, Yıl:20, Sayı:63, Haziran 2009,s.31.

<sup>110</sup> Yurtoğlu, s.27.

<sup>111</sup> Öztemel, s.84.

**Şekil 15:** ÇKA Ağının Öğrenme Eğrisi



Kaynak: Öztemel, s.84.

### 2.5.2.3. ÇKA Ağının Oluşturulmasında Önemli Noktalar


ÇKA ağının performansını etkileyen unsurlar aşağıda açıklanmaktadır:<sup>112</sup>

- **Örneklerin seçilmesi:** Ağın performansını yakından ilgilendiren bir konudur. Seçilen örneklerin problem uzayını temsil edebilecek nitelikte olması çok önemlidir.
- **Girdi ve çıktıların nümerik gösterimi:** Yapay sinir ağları sadece rakamlar ile çalışırlar. Eğer problem uzayında sayısal (nümerik) olmayan faktörleri dikkate almak gerekiyor ise o zaman onların rakamlar ile temsil edilebilmesi gerekir. Sayısal olmayan faktörlerin nümerik hale getirilmesi sırasında uygulanan yöntemler ağın performansı üzerinde etkili olabilirler.
- **Başlangıç değerlerinin atanması:** ÇKA ağında bağlantı ağırlıklarının başlangıç değerlerinin atanması ya ağın performansını yakından ilgilendirir. Eğer aralıklar büyük seçilirse ağ yerel çözümler arasında sürekli dolaşır, küçük seçilirse ise ağın öğrenmesi çok uzun sürer. Ağırlıkların başlangıç değerleri rastgele atanır. Tecrübeler, -1 ile 0.1 arasındaki değerlerin başarılı sonuçlar ürettiğini göstermektedir. Öğrenemeyen bir ağın başlangıç değerlerinin değiştirilmesi ile ağın öğrenmesi sağlanabilir. Şekil 16'da görüldüğü üzere eğer bir ÇKA ağı öğrenmeye A noktasından başlarsa yerel

<sup>112</sup> Elmas, ss.114-122; Öztemel, ss.91-105.

bir çözüme (  $W_1$  ) takılabilme olasılığı varken B noktasından başlarsa en iyi çözümün (  $W^*$  ) bulunması daha kolaydır.

**Şekil 16:** ÇKA Ağlarında Başlangıç Noktasının Etkisi



Kaynak: Öztemel,s.99.

- **Öğrenme katsayısının belirlenmesi:** Başlangıç değerleri kadar öğrenme katsayısının belirlenmesi de ağırlıkların öğrenme performansı ile yakından ilgilidir. Öğrenme katsayısı ağırlıkların değişim miktarını belirler ve eğer büyük değerler seçilirse yerel çözümler arasında ağırlıkların dolaşması, küçük değerler seçilirse öğrenme zamanının artması söz konusu olur. Tecrübeler genellikle 0.2-0.4 arasındaki değerlerin kullanıldığını göstermektedir. Bazı uygulamalarda ise öğrenme katsayısının 0.6 değerini aldığı zaman en başarılı sonuçları verdiği görülmektedir.
- **Momentum katsayısının belirlenmesi:** Momentum katsayısı da öğrenmenin performansını etkiler. Momentum katsayısı bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesidir. Momentum katsayısı yerel çözümlere takılan ağırlıkların bir sıçrama ile daha iyi sonuçlar bulmasını sağlar. Bu değerinin küçük olması yerel çözümlerden kurtulmayı

zorlaştırırken çok büyük olması tek bir çözüme ulaşmakta sorun çıkartabilir. Tecrübeler bu değer 0.6-0.8 arasında seçilmesinin uygun olacağını göstermektedir.

- Örneklerin ağa sunulma şekli: Genel olarak örnekler ağa sıralı sunum ve rastgele sunum olmak üzere iki türlü sunulabilirler. Sıralı sunumda eğitim setindeki örnekler sırayla ağa sunulurken, rastgele sunumda örnekler eğitim seti içinden rastgele seçilerek sunulur. Sıralı sunumda örneklerin ağa gösterilme şansı eşittir. Rastgele sunumda ise iki durum vardır. Seçilen örnekler ağın eğitim setinin dışına çıkarılır ya da tekrar içine atılır. İlk durumda bütün örneklerin seçilme şansı eşitken ikinci durumda eşitlik bozulur.
- Ağırlıkların değiştirilmesi zamanı: Ağırlıkların değiştirilmesi öğrenme kuralına göre yapılır. Genel olarak üç durumda ağırlıklar değiştirilir. Bu üç durum:
  - ✓ *Her örnek ağa gösterildiği durum (pattern based learning)*: Ağ her örnek gösterildiğinde beklenen çıktı ile ağın gerçekleştirdiği çıktı arasındaki hata bulunur ve bu hata ağın ağırlıklarına öğrenme kuralı gereğince dağıtılır. İkinci örnek ağa sunulduğunda çıktının hatası hesaplanır ve ağırlıklar değiştirilir. Her örnek gösterimi sonucu ağırlıklar değiştirilir.
  - ✓ *Belirli sayıda örnek gösterildiğinde (batch based learning)*: Ağ her örnek gösterildiğinde hatası hesaplanıp ağırlıklar değiştirilmez. Belirli sayıda örnek tek tek ağa gösterilir ve hatalar toplanırlar. İstenen sayıdaki örneğin ağa gösterilmesi bitince toplanan hata ağırlıklara dağıtılır. Genellikle 5-10 örnekten oluşan örnek grupları oluşturulur.
  - ✓ *Bütün örnek seti gösterildiğinde (epoch based learning)*: Bu durumda örnek setindeki bütün örnekler ağa tek tek gösterilir. Hatalar hesaplanır ve eğitim setindeki örneklerin tamamının hataları toplandıktan sonra bu hata ağırlıklara dağıtılır. Yani; ağın ağırlık değerleri örneklerin tamamı ağa gösterilmedikçe değiştirilmez. Örnek sayısının az olduğu durumlarda önerilmektedir.
- Girdilerin ölçeklendirilmesi: Problem örneklerinin hepsinin aynı ölçek üzerine indirgenmesi gerekebilir. Bazı durumlarda problemin girdileri arasında aşırı büyük veya küçük değerler görülebilir ve bunlar ağı yanlış yönlendirebilirler. Bütün girdilerin belirli aralıkta (çoğunlukla 0-1 aralığında) ölçeklendirilmesi hem farklı ortamlardan gelen bilgilerin aynı ölçek üzerine indirgenmesine hem de yanlış girilen çok büyük ve küçük şeklindeki değerlerin etkisinin

ortadan kalkmasına neden olur. Ölçeklendirme değişik şekillerde yapılmaktadır. Bazı araştırmacılar girdi vektörünü normalize etmektedirler. Yani her değeri girdi vektörünün değerine bölerek yeni değerleri bulmaktadırlar. Bu ise şu şekilde gösterilmektedir. Burada  $x$  girdi değerini,  $x'$  ölçeklendirilmiş yeni girdi değerini,  $|X|$  ise girdi vektörünün büyüklük değerini gösterir.

$$x' = \frac{x}{|X|} \quad (2.12)$$

Bazı araştırmacılar ise aşağıdaki gibi bir formülasyon kullanmakta ve örnekleri oluşturan değerleri belirli bir aralık içine çekmektedir. Burada  $x$  girdi değerini,  $x'$  girdi değerinin ölçeklendirilmiş halini,  $x_{min}$  girdi setindeki olası en küçük değeri,  $x_{max}$  ise girdi setindeki olası en büyük değeri gösterir.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.13)$$

Burada önemli olan hangi yöntem kullanıldığından çok girdiler için olumsuz etkileri önleyecek şekilde ölçeklendirme yapmaktır.

- **Çıktıların ölçeklendirilmesi:** Çok katmanlı algılayıcı ağlarında genel olarak *sigmoid* aktivasyon fonksiyonu kullanılır ve bu fonksiyon sadece 0 ve 1 arasında bir değer üretir. Eğer çıktı değerlerinin 1'den büyük veya 0'dan küçük olması isteniyor ise *sigmoid* fonksiyonu kullanılmaz. Sigmoid fonksiyonu kullanılırsa beklenen çıktıların 0-1 arasına indirgenmesi ve çıktılar üretildikten sonra orijinal değerlerine dönüştürülmeleri gerekir.
- **Durdurma kriterinin belirlenmesi:** Ağın eğitilmesi kadar ağın gereğinden fazla eğitilmesinin önlenmesi de önemlidir. Ağ çözümü bulduktan sonra eğitime devam edilirse ağın ağırlıklarında değişiklik devam edebilir ve ağ daha düşük performanslı bir ağa dönüşebilir. Bu nedenle eğitim belirli bir zaman sonra durdurulmalıdır. Durdurma için iki türlü kriter kullanılır.
- ✓ **Hatanın belirli bir değerin altına düşmesi durumunda eğitimi durdurma:** Tolerans değeri probleme göre değişebilir. Hata belirlenen tolerans değerlerinin altına indiği zaman eğitim durdurulur.
- ✓ **Ağın belirli bir iterasyon sayısını tamamlaması sonucu eğitimi durdurma:** Hata grafikleri çizilerek gerekli iterasyon sayısı tespit edilebilir ve bu sayıya ulaşıldığında eğitim durdurulur. Tolerans değerinin belirlenmesinin zor olduğu durumlarda kullanılabilir.

- Ara katman sayısı ve proses elemanlarının sayısının belirlenmesi: Çok katmanlı algılayıcı modelinde herhangi bir problem için kaç tane ara katman ve her ara katmanda kaç tane proses elemanı kullanılması gerektiğini belirten bir yöntem şu ana kadar bulunmuş değildir. Ara katman sayısı ve proses elemanı sayıları da ağın performansını yakından ilgilendirmektedirler. Tasarımcılar kendi tecrübelerine dayanarak bunları belirler. O nedenle bir problem herhangi bir ağ ile kabul edilebilir hata altında çözüm üretse bile daha iyi bir ağ olur mu diye farklı sayıdaki ara katman ve her ara katmanda farklı sayıda proses elemanları ile denemeler yapmak gerekir. Böylece performansı daha yüksek bir ağ bulmak mümkün olabilir. Küçük bir ağdan başlayıp büyük bir ağa doğru eğitim esnasında sürekli proses eleman sayısını artırarak ağlar büyütülebilir veya büyük bir ağdan başlayıp küçük bir ağa doğru eğitim sırasında proses elemanları teker teker ağdan çıkartılarak ağ budanabilir Bu işlemlere örneklerin tamamı öğrenilinceye veya tasarımcı öğrenme performansından memnun oluncaya kadar devam edilmekte ve problem için gerekli ara katman proses elemanı sayısı bulunmaktadır.

### 2.5.3. LVQ Modeli

LVQ ağı Kohonen tarafından 1984 yılında geliştirilmiştir. Öğretmenli öğrenme stratejisini kullanan modellerde eğitim sırasında ağa hem girdi değerleri hem de o girdi değerleri için üretilecek çıktı değerlerinin ne olması gerektiği verilir. Bazı durumlarda ise ağa çıktının ne olduğunu vermek mümkün olmamaktadır. Yalnızca ağın üretmiş olduğu çıktının doğru ya da yanlış olduğu belirtilmektedir. Destekleyici öğrenme olarak belirlenen bu yöntemi kullanan modellerden bir tanesi de LVQ( Linear Vector Quantization) modelidir.<sup>113</sup>


Şekil-17'de bir LVQ ağı verilmiştir. ÇKA'larda olduğu gibi LVQ ağları da üç katmandan oluşur. Görüldüğü gibi bir giriş, bir çıkış ve bir Kohonen katmanı bulunmaktadır. Giriş katmanındaki nöronlar ara katmandaki tüm nöronlarla bağlıdır. Ancak ara katmandaki proses elemanları sadece çıktı katmanındaki bir tek proses elemanına bağlıdır. Kohonen katmanı ile çıktı katmanı arasındaki ağırlıklar ( $\alpha$ ) sabit olup 1'e eşittir. Yani bu ağırlıklar değiştirilmez. Sadece girdi katmanı ile Kohonen katmanı arasındaki ağırlıklar değiştirilir. Öğrenme bu ağırlıklar üzerinden gerçekleşir. Bu ağın temel prensibi n boyutlu bir vektörü, bir vektörler setine haritalamaktır.

---

<sup>113</sup> Saraç, s. 48.

Öğrenme, girdi vektörünün hangi vektör seti (referans vektör) tarafından temsil edilmesi gerektiğinin bulunmasıdır. Referans vektörü, girdi değerlerini Kohonen katmanındaki proses elemanlarına bağlayan bağlantıların ağırlık değerlerinden oluşur. Öğrenme sırasında sadece referans vektörlerinin ağırlık değerleri değiştirilir. Çıktılardan sadece birisi 1, diğerleri 0 değerlerini alır ve çıktı değerinin 1 olması girdinin ilgili çıktının temsil ettiği sınıfa ait olduğunu gösterir.<sup>114</sup>

**Şekil 17:** : LVQ Ağının Topolojik Yapısı



Kaynak: Öztemel, s.120.

LVQ ağları aşağıdaki prosedüre göre çalıştırılır:<sup>115</sup>

- 1) Örneklerin belirlenmesi,
- 2) Ağın topolojisinin belirlenmesi(girdi ve çıktı sayısının belirlenmesi, referans vektör sayısının belirlenmesi),
- 3) Ağın öğrenme parametrelerinin belirlenmesi (öğrenme katsayısı ve istenen sabit değerlerin belirlenmesi),
- 4) Ağırlıkların başlangıç değerlerinin atanması,
- 5) Öğrenme setinden bir örneğin ağa gösterilmesi,
- 6) Kazanan proses elemanın bulunması,
- 7) Ağırlıkların değiştirilmesi,
- 8) Bütün örnekler doğru sınıflandırılıncaya kadar 5-7 arasındaki adımların tekrarlanması şeklindedir.

<sup>114</sup> Öztemel, s.121.

<sup>115</sup> Saraç, s.49.

#### 2.5.4. ART Ağları Modeli

ART ağları, Grosberg'in 1976 yılında biyolojik beynin fonksiyonlarına yönelik olarak yaptığı çalışmalar neticesinde ortaya çıkmıştır. Danışmansız öğrenme ağlarının geliştirilmesine de temel olmuştur. Beynin kullandığı sezgisel yaklaşımları matematiksel bir modele dönüştürmelerinden dolayı da bu ağlar oldukça yoğun bir ilgi görmüştür. ART ağları sınıflandırma problemleri için geliştirilmiş ve başarılı bir şekilde kullanılabilen bir yöntem olarak bilim dünyasında kabul görmüştür. LVQ ağları da sınıflandırma problemi için geliştirilmiştir. ART ağlarının LVQ ağlarından temel farkı, yapılacak olan sınıflandırma ile ilgili olarak ağa herhangi bir bilgi verilmemesidir.<sup>116</sup>

ART ağları genel olarak iki katmandan oluşur. Bu katmanlar girdilerin özelliklerinin gösterildiği F1 katmanı ve ayrıştırılmış sınıfların gösterildiği F2 katmanıdır. Girdi bilgileri F1 katmanından alınır ve sınıflandırma ise F2 katmanında yapılır. F1 katmanının aktivasyonu girdilerin özellikleri incelenerek belirlenir ve uzun dönemli hafızadaki bağlantı değerleri ile gelen bilgiler kategorilere ayrılarak F2 katmanına gönderilir. F2 katmanındaki sınıflandırma ile F1 katmanından gelen sınıflandırma birbirleri ile eşleştirilir. Örnek belirlenmiş bir sınıfa uyuyorsa o kategoride gösterilir uymuyorsa yeni bir sınıf oluşturulur veya girdinin sınıflandırılması yapılmaz. Değişik ART ağları geliştirilmiştir. ART1 ağı geliştirilmiş ilk ART ağıdır. Bu ağ sadece ikili değerlerden oluşan girdi vektörlerini kabul eder. ART2 ağları ise sürekli değerleri de kabul etmektedir. Benzer şekilde ART3, Fuzzy ART, ARTMAP gibi başka modellerde geliştirilmiştir.<sup>117</sup> Şekil 18'de ART ağlarının genel yapısı gösterilmektedir.

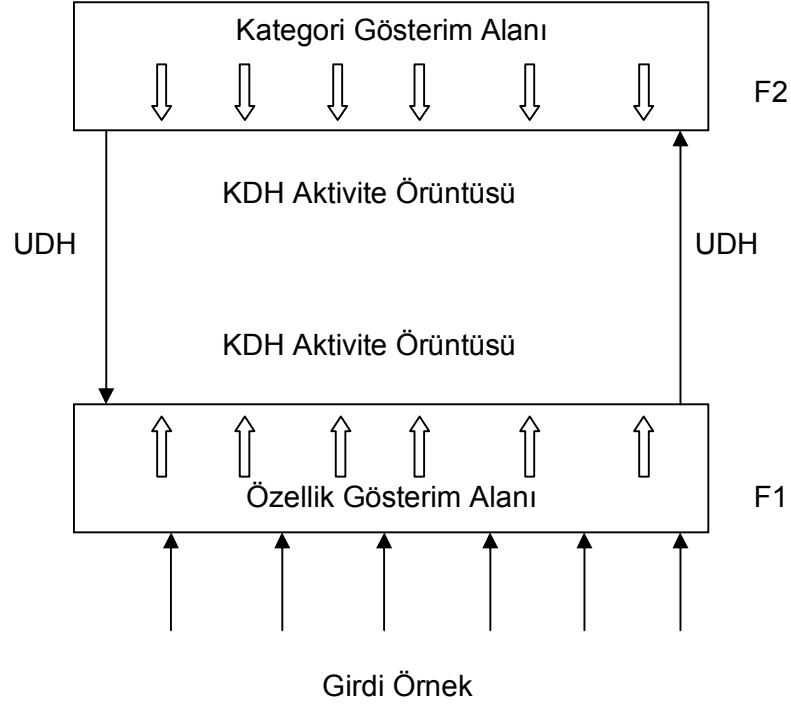
---

<sup>116</sup> Fausett, p. 218.

<sup>117</sup> Fausett, p.219.



**Şekil 18:** ART Ağının Genel Yapısı



Kaynak: Öztemel, s.141.

Yukarıda anlatılan 3 model ( ÇKA, LVQ, ART ) dışında yapay sinir ağlarında çok sayıda değişik model geliştirilmiştir. Bu modeller arasında Elman Ağı, Hopfield Ağı, Counterpropagation Ağı, Cognitron Ağı, SOM, BAM, RBNN, PNN, Boltzman Makinesi, Optik Sinir Ağları, Gerçek Zamanlı Geri Dönüşüm Ağları vb. sayabiliriz.

## 2.6. YAPAY SİNİR AĞLARININ UYGULAMA ALANLARI

YSA'lar gerçek hayatta karşılaşılan problemlerde oldukça geniş bir uygulama alanı kazanmışlardır. Bugün, birçok endüstride başarılı şekilde kullanılmaktadırlar. Uygulama alanları için bir sınır yoktur fakat sınıflandırma, öngörü ve modelleme gibi bazı alanlarda ağırlıklı olarak kullanılmaktadırlar. Bugün, YSA'lar birçok ciddi problem üzerinde uygulanmaktadır ve bu problemlerin sayısı giderek artmaktadır. Verideki trend veya yapıyı (pattern) en iyi tanımlayan yöntem olmaları dolayısıyla, öngörü işlemleri için çok uygundur. Yapay Sinir Ağlarının gerçek hayattaki yaygın uygulama alanlarına şu örnekler verilebilir:<sup>118</sup>

<sup>118</sup> Yurtoğlu, s.9.

- Kalite Kontrol
- Finansal Öngörü
- Ekonomik Öngörü
- Kredi Derecelendirme
- Laboratuar Araştırmaları
- İflas Tahmini
- Petrol ve Gaz Arama
- Sistem Modelleme
- Parmak İzi Tanıma
- Meteorolojik Yorumlama
- Otomatik Araç Denetimleri

Yapay sinir ağlarının uygulama alanları kullanım amaçlarına göre de gösterilebilir.<sup>119</sup>

- Tahmin: Bu amaçla kullanılan yapay sinir ağları, ağa sunulan bilgilerden yararlanılarak karşılık gelen çıktı değerini tahmin ederler. Hava tahmini, borsada hisselerin değerlerinin tahmini, 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 sınıflandırılması buna örnek olarak verilebilir.
- Veri İlişkilendirme: Bu amaçla eğitilen ağlar ağa sunulan verilerin hatalı ve eksik olmadığını belirlerler. Öğrendikleri bilgiler ile eksik olan bilgileri tamamlarlar. Eksik bir resmin tamamlanması bu konuda örnek olarak verilebilir.
- Veri Filtreleme: Bu amaçla eğitilen ağlar, birçok veri arasından uygun verileri belirleme görevini yerine getirirler. Telefon konuşmalarındaki gürültüleri asıl konuşmalardan ayıran ağlar bu konudaki uygulamalara örnek olarak verilebilir.

---

<sup>119</sup> Elmas, s.161.

- 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 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.

Yukarıda belirtildiği gibi YSA'nın başarı ile kullanıldığı alanlardan biri tahminleme problemleridir. Yapay sinir ağlarının geleceği tahminleme amacıyla kullanılmasına yönelik literatürde çok sayıda çalışma vardır. Birçok farklı disiplinden araştırmacılar, bir tahminleme aracı olarak YSA'nın kullanılabilirliğini araştırmışlardır. Yapılan çalışmaların birçoğunda, geleneksel yöntemler ile YSA teknikleri karşılaştırılmış ve hangi yöntemin daha iyi sonuç verdiği araştırılmıştır. YSA'nın bir tahminleme aracı olarak kullanılmasına yönelik literatür taraması, yapılan çalışmaların uygulama alanları ve amacı hakkında bir bilgi verecektir.

Law ve Au; 1967-1996 yıllarına ait yıllık zaman serisi verilerini kullanarak, Hong Kong'a yönelik Japon turizm talebini, mekanik tahmin modeli, çoklu regresyon modeli, üstel düzleştirme modeli, hareketli ortalama ve ileri sürümlü yapay sinir ağı modeli ile tahmin etmişlerdir. Modellerin tahmin performanslarını değerlendirme kriteri olarak OMYH ve Mann-Whitney U istatistiklerini kullanan yazarlar, yapay sinir ağı modelinin anılan diğer modellere göre daha iyi tahmin sonuçları verdiğini ortaya koymuşlardır.<sup>120</sup>

Chang ve Hwang; 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

<sup>120</sup> Robb Law ve Norman Au, " A Neural Network To Forecast Japanese Demand For Travel To Hong Kong", **Tourism Management**, Vol.20, No.1, 1999, pp. 89-97.

katmandaki nöron sayısını belirlemişlerdir. Daha sonra seçtikleri ARIMA modeli ve üstel düzleştirme yöntemi ile yapay sinir ağı modelini “Ortalama Hata Kareleri” (OHK) performans ölçütünü kullanarak karşılaştırmışlardır. Araştırmalarının sonucunda az bir farkla Box-Jenkins modelinin daha uygun olduğuna karar vermişlerdir.<sup>121</sup>

Kandananond; 1986-2010 yıllarına ait yıllık zaman serisi verilerini kullanarak, Tayland ülkesinin elektrik enerjisi tüketimini, yapay sinir ağları, ARIMA ve çoklu doğrusal regresyon modeli ile tahmin etmeyi amaçlamıştır. Modellerin tahmin performansını değerlendirme kriteri olarak OMYH istatistiğini kullanan yazar, yapay sinir ağlarının anılan diğer modellere göre daha üstün bir tahmin başarısına sahip olduğunu göstermiştir.<sup>122</sup>

Ahangar, Yahyazadehfar ve Pournaghshband; Tahran Menkul Kıymetler Borsası’nda işlem gören firmalara ilişkin hisse senedi fiyatlarını tahmin etmek için çalışma yapmışlardır. Bu amaçla; yapay sinir ağı ve çoklu doğrusal regresyon modeli geliştirilerek tahmin performansları kıyaslanmıştır. Modellerin tahmin performansını değerlendirme kriteri olarak OMYH, OHK istatistiklerini kullanan yazarlar, yapay sinir ağlarının regresyon modeline göre daha üstün bir tahmin başarısına sahip olduğunu göstermiştir.<sup>123</sup>

Goyal ve Goyal; yapay sinir ağları ve çoklu doğrusal regresyon modelleri ile süt ürünlerinin raf ömürlerini tahmin etmeye çalışmışlardır. Modellerin tahmin performansını değerlendirme kriteri olarak OMYH, OHKK istatistiklerini kullanan yazarlar, yapay sinir ağlarının regresyon modeline göre daha üstün bir tahmin performansına sahip olduğunu göstermiştir.<sup>124</sup>

Türkiye’ de yapılan çalışmalara baktığımızda ise Hamzaçebi ve Kutay; uzun dönemli elektrik enerjisi tüketimi tahmininde yapay sinir ağlarının kullanılmasını

---

<sup>121</sup> I. Chang ve H. Hwang, “Applying Neural Networks In Time Series Forecasting”, **Information and Management Sciences**, Vol.9, No.3, 1998, pp. 35-43.

<sup>122</sup> Karin Kandananond, “ Forecasting Electricity Demand In Thailand With An Artificial Neural Network Approach”, **Powereng 2nd International Conference**, 2009, pp.1246-1257.

<sup>123</sup> Reza G. Ahangar ve diğerleri, “ The Comparison Of Methods Artificial Neural Network With Linear Regression Using Specific Variables For Prediction Stock Price In Tehran Stock Exchange”, **International Journal Of Computer Science And Information Security**, Vol.7, No.2, 2010, pp. 38-46.

<sup>124</sup> Sumit Goyal ve Gyanendra Kumar Goyal, “ Predicting Shelf Life Of Dairy Product By Using Artificial Neural Networks And Statistical Computerized Methods”, **International Journal Of Computer Engineering Research**, Vol.3, No.2, 2012, pp.20-24.

araştırmışlardır. Bu amaçla 2010 yılına kadar Türkiye'nin elektrik enerjisi tüketimi tahmini için yapay sinir ağları ile model oluşturulmuştur. Yapay sinir ağları modeli ile bulunan sonuçlar, Box-jenkins modelleri ve regresyon tekniği ile karşılaştırılmıştır. Modellerin tahmin performansını değerlendirme kriteri olarak OMYH istatistiğini kullanan yazarlar, yapay sinir ağlarının diğer modellere göre daha üstün bir tahmin başarısına sahip olduğunu göstermiştir.<sup>125</sup>

Güngör ve Çuhadar; Antalya iline yönelik Alman turist talebinin tahmininde kullanılmak üzere yapay sinir ağları, doğrusal ve doğrusal olmayan çoklu regresyon modelleri geliştirerek tahmin performanslarını kıyaslamıştır. Modelin oluşturulabilmesi için 1991-2004 yıllarına ait aylık verilerden yararlanılmıştır. 2005 ve 2006 yılları için tahminler yapılmıştır. Modellerin tahmin performansını belirlemek üzere OMYH ve OHKK kriterleri kullanılmıştır. Elde edilen sonuçlar YSA modelinin, regresyon modellerine göre daha düşük sapma değerlerine sahip olduğunu göstermektedir.<sup>126</sup>

Asilkan; ikinci el otomobillerin pazardaki güncel fiyatlarını tahmin etmek amacıyla yapay sinir ağları ve regresyon analizi ile modeller geliştirerek tahmin performanslarını kıyaslamıştır. Modellerin tahmin performansını değerlendirme kriteri olarak OMYH, OHKK ve OMH istatistiklerini kullanan yazar, yapay sinir ağlarının regresyon modeline göre daha üstün bir tahmin başarısına sahip olduğunu göstermiştir.<sup>127</sup>

Kaynar, Taştan ve Demirkoparan; ham petrol fiyatlarını tahmin etmek için ileri sürümlü yapay sinir ağları ve ARIMA teknikleriyle tahmin modelleri geliştirmişlerdir. Çalışmada, 1986-2009 yıllarına ait aylık verilerden yararlanılmıştır. Elde edilen sonuçlar OMYH kriteri kullanılarak karşılaştırılmıştır. YSA ile ARIMA modeline kıyasla daha üstün tahmin başarısı sağlanmıştır. Böylece, yapay sinir ağlarının geleneksel tahmin yöntemlerine alternatif bir teknik olduğu gösterilmiştir.<sup>128</sup>

---

<sup>125</sup> Coşkun Hamzaçebi ve Fevzi Kutay, "Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini", **Gazi Üniv. Müh. Mim. Fak. Dergisi**, Cilt:19, No:3, 2004, ss.227-233.

<sup>126</sup> İbrahim Güngör ve Murat Çuhadar, "Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemiyle Tahmini", **Ticaret ve Turizm Eğitim Fakültesi Dergisi**, Sayı:1, 2005, ss.84-98.

<sup>127</sup> Özcan Asilkan, "İkinci El Otomobillerin Güncel Pazar Fiyatlarının Veri Madenciliği Yöntemleriyle Modellenmesi", **Akademik Bakış Dergisi**, Sayı:24, 2011, ss. 1-19.

<sup>128</sup> Oğuz Kaynar ve diğerleri, "Ham Petrol Fiyatlarının Yapay Sinir Ağları İle Tahmini", **Ege Akademik Bakış Dergisi**, Cilt:10, Sayı:2, 2010, ss.559-573.

Görüldüğü üzere, tahminleme alanında yapay sinir ağları ile yapılan birçok araştırmada geleneksel tahmin yöntemleri ile karşılaştırmalar yapılmıştır. Genellikle yapay sinir ağları daha iyi sonuçlar vermiştir. Tez kapsamında biz de elde etmiş olduğumuz verileri, hem yapay sinir ağları ile hem de çoklu doğrusal regresyon analizi modeli ile tahmin etmeye çalışacağız ve sonuçları birbirleriyle karşılaştırıp hangi yöntemin tahminlemede daha başarılı olduğunu ortaya koyacağız.

## 2.7. YAPAY SİNİR AĞLARININ AVANTAJLARI VE DEZAVANTAJLARI

YSA'ların üstünlükleri şu şekilde özetlenebilmektedir:<sup>129</sup>

- **Doğrusal Olmama**: Yapay sinir ağlarının en önemli özelliklerinden birisi gerçek hayattaki olası doğrusal olmayan yapıları da dikkate alabilmesidir. YSA'nın temel işlem elemanı olan hücre, doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. YSA'lar bu özellikleri ile doğrusal olmayan karmaşık problemlerin çözümünde önemli araçlardan biri haline gelmiştir.
- **Paralellik**: Günümüzde kullanılan bilgi işleme yöntemleri genelde seri, sıralı işlemlerden oluşmaktadır. Seri işlemcilerde herhangi bir birimin yavaş olması tüm sistemi yavaşlatırken, YSA'ların sahip olduğu paralellik sayesinde yavaş bir birim sistemin çalışması sırasında herhangi bir soruna yol açmamaktadır. Bu durum YSA'ların daha hızlı ve güvenilir olması sonuçlarını doğurmaktadır.
- **Öğrenme**: Geleneksel hesaplama yöntemlerinde bir problemin çözülebilmesi için probleme uygun bir algoritma geliştirilmesi ve programlama yolu ile hesaplama yapılması gerekmektedir. Genellikle bu tür algoritmaların çözüm yeteneği uzmanın kod yazma yeteneği ile sınırlıdır. Bu tür algoritmaların zorluğu ve her problem türüne göre farklı algoritma yazılma ihtiyacı nedeniyle karmaşık problemlerin çözümünde kullanılamazlar. YSA'ların öğrenme sistemi ise insan beyninin çalışma şekline benzemektedir. Öğrenme, özellikleri verilen örnekler yoluyla yapay sinir ağının kendisi tarafından sağlanmakta ve YSA'lar, örnekleri kullanarak probleme ilişkin genelleme yapabilecek yeteneğe ulaşmaktadır. Bu özelliği sayesinde geleneksel yöntemler için karmaşık olan sorunlara çözüm üretilebilmektedir.

---

<sup>129</sup> Yurtoğlu, ss.34-36.

Geleneksel sistemlerden ayrıldığı bir başka nokta ise sürekli öğrenmedir. YSA'lar kendisine gösterilen yeni örnekleri öğrenebilmeleri ve yeni durumlara adapte olabilmeleri sayesinde sürekli olarak yeni olayları öğrenebilmesi mümkündür.

- **Bilginin Saklanması:** Geleneksel hesaplama yöntemlerinde bilgi, veri tabanlarında veya program kodlarının içinde saklanmaktadır. Yapay sinir ağlarında ise bilgi, nöronlar arasındaki ağırlıklı bağlantılarda saklanmaktadır. Yani bilgi ağa dağıtılmış durumdadır ve ağın bütünü, öğrendiği olayın tamamını göstermektedir. Bu nedenle yapay sinir ağlarının dağıtılmış bellekte bilgi saklayabildikleri söylenebilmektedir.
- **Hata Toleransı ve Esneklik:** Yapay sinir ağları, geleneksel işlemcilerden farklı şekilde işlem yapmaktadırlar. Geleneksel işlemcilerde tek bir merkezi işlemci eleman her hareketi sırasıyla gerçekleştirmektedir. Seri bilgi işlem yapan geleneksel bir sistemde herhangi bir birimin hatalı çalışması, hatta tamamen bozulmuş olması tüm sistemin hatalı çalışmasına veya bozulmasına sebep olacaktır. YSA modelleri, her biri büyük bir problemin bir parçası ile ilgilenen çok sayıda basit işlemci elemanlardan oluşmaları ve bağlantı ağırlıklarının ayarlanabilmesi gibi özelliklerinden dolayı önemli derecede esnek bir yapıya sahiptirler. Bu esnek yapı sayesinde ağın bir kısmının zarar görmesi modelde sadece performans düşüklüğü yaratmakta, problemin çözümünde büyük bir soruna yol açmamakta, modelin işlevini tamamen yitirmesi söz konusu olmamaktadır. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.
- **Genelleme:** YSA'lar, kendi kendine öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlar için genelleme yapabilmektedirler. Yani, hatalı (gürültülü) veya kayıp veriler için çözüm üretebilmektedir. YSA'lar, daha önce görmedikleri veriler, veya eksik veriler hakkında karar verirken genelleme yapabildikleri için iyi birer Desen (Örüntü) Tanımlayıcısı (Pattern Recognition Engine) ve Sağlam Sınıflandırıcılardır (Robust Classifier).
- **Uyarlanabilirlik:** Yapay sinir ağları, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlayabilmektedir. Yani belirli bir problemi çözmek amacıyla eğitilen bir yapay sinir ağı, problemdeki değişimlere göre tekrar eğitilebilmekte, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilmektedir. Bu özelliği ile yapay sinir ağları, uyarlamalı (adaptive) örnek

tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılabilir.

- Eksik Verilerle Çalışma: Yapay sinir ağları, geleneksel sistemlerin aksine, kendileri eğitildikten sonra eksik bilgiler ile çalışabilmekte ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilmektedirler. Yapay sinir ağlarının eksik bilgiler ile çalışması performanslarının düşeceği anlamına gelmemektedir. Performansın düşmesi eksik olan bilginin önemine bağlı olmaktadır.
- Sınırsız Sayıda Değişken ve Parametre Kullanma: Yapay sinir ağları istatistikî yöntemlerin aksine sınırsız sayıda değişken ve parametre ile herhangi bir ekstra dönüşüme ihtiyaç duymadan çalışabilmektedir. Bu sayede mükemmel bir tahmin doğruluğu ile genel çözümler sağlanabilmektedir.
- Gerçeklenme Kolaylığı: Yapay sinir ağlarının basit işlemler gerçekleyen türden hücrelerden oluşması ve bağlantıların düzgün olması, ağların gerçeklenmesi açısından büyük kolaylık sağlamaktadır. Yapay sinir ağlarının farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan yapay sinir ağları benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin yapay sinir ağları ile çözümünde önemli bir kolaylık getirmektedir.
- Donanım ve Hız: Yapay sinir ağları paralel yapısı nedeniyle Büyük Ölçekli Entegre Devre Teknolojisi (VLSI) ile gerçekleştirilebilir. Bu özellik, YSA'ların hızlı bilgi işleme yeteneğini arttırmaktadır ve gerçek zamanlı uygulamalarda yaygın olarak kullanılmasının ana sebeplerindendir.

Yapay sinir ağlarının oluşturulmasında ve kullanılmasında avantajlar yanında bazı dezavantajlar da vardır. Bunlardan bazıları şunlardır:<sup>130</sup>

- Yapay sinir ağlarının oluşturulması, model seçimi, ağ topolojisinin belirlenmesinde bir kurallar seti yoktur. Kullanıcı tecrübesine dayanmaktadır.
- Örneklerin tasarlanması için bir kurallar seti yoktur. Kullanıcı yine tecrübesine dayanarak örnekleri formülize etmektedir. Bundan dolayı aynı problem farklı şekillerde gösterilmekte ve her gösterimin kendisine göre performansı da değişmektedir.

---

<sup>130</sup> Öztemel, s.208.



- Ağın davranışlarını açıklayamaması ağa olan güveni azaltmakta ve özellikle insan hayatı ile ilgili problemlerde kullanım alanlarını sınırlandırmaktadır.
- Basit olarak görülebilecek modelleme yapılarına rağmen zaman zaman zor ve karmaşık olabilmektedir.
- Problemlere optimum sonuç garanti etmez. Üretilen sonuçların iyi sonuçlardan biri olduğu söylenebilir. Geleneksel yöntemler ise optimum sonuçlar üretirler.
- Yapay sinir ağlarının eğitilmesine ve test edilebilmesine yetecek genişlikte veri setine ihtiyaç vardır. Problemleri doğru temsil eden örneklerin bulunamaması durumunda sağlıklı sonuçlar üretebilmek mümkün değildir.

## 2.8. YAPAY SİNİR AĞLARI VE TALEP TAHMİNİ

YSA'lar gerçek hayatta karşılaşılan problemlerde oldukça geniş bir uygulama alanı kazanmışlardır. Bugün, birçok alanda başarılı şekilde kullanılmaktadırlar. Uygulama alanlardan birisi de tahminlemedir. İleriye yönelik tahmin çalışmalarında geleneksel tahmin yöntemlerine alternatif olarak kullanılmaktadırlar. Araştırmacılar tarafından yapay sinir ağlarının tahminleme amaçlı kullanılmasının altında yatan birtakım sebepler vardır. Öncelikle, yapay sinir ağları geleneksel tahminleme yöntemlerinin aksine herhangi bir varsayıma ihtiyaç duymaz. Değişkenler arasındaki fonksiyonel ilişkiyi açıklamak mümkün olmasa bile, yapay sinir ağları örneklerden öğrenme yoluyla bu ilişkiyi belirlemektedir. Verideki trend veya yapıyı (pattern) en iyi tanımlayan yöntem olmaları dolayısıyla, öngörü işlemleri için çok uygundur. YSA'nın diğer bir önemli özelliği ise genelleme yapabilmesidir. YSA'lar, kendi kendine öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlar için genelleme yapabilmektedirler. Yapay sinir ağlarının önemli özelliklerinden diğeri de gerçek hayattaki olası doğrusal olmayan yapıları da dikkate alabilmesidir. YSA'lar bu özellikleri ile doğrusal olmayan karmaşık problemlerin çözümünde önemli araçlardan biri haline gelmiştir.<sup>131</sup>

Yapay sinir ağlarıyla talep tahmini diğer geleneksel yöntemlerde olduğu gibi geçmiş veriler kullanılarak yapılır. Talep tahmininde kullanılan tipik bir yapay sinir ağı; bir girdi katmanı, bir gizli katman ve bir çıktı katmanı olmak üzere üç katmandan oluşur. Girdi katmanı bağımsız değişkenlerin her biri için birer tane hücre taşır. Çıktı

<sup>131</sup> Guoqiang Zhang ve diğerleri, "Forecasting with Artificial Neural Networks: The State of The Art", *International Journal of Forecasting*, Vol.5, No.1,1998, p.36.

katmanında bağımlı deęişken kadar hücre bulunur. Gizli katmanda ise herhangi bir sayıda hücre bulunabilir ancak genellikle girdi sayısının iki katını geçmez. Girdi katmanındaki hücreler ile ara katmandaki hücreler arasında ve ara katmandaki hücreler ile çıktı katmanındaki hücreler arasında ağırlıklar bulunur. Uygun ağırlık deęerlerini belirlemek için sinir aęları eęitilir. Uygun bir çözüm bulunana kadar eęitim bir dizi iterasyondan geerilir.<sup>132</sup>

Yapay sinir aęları ile geleneksel yöntemlerin tahmin başarılarının kıyaslanması konusunda literatüre baktığımızda çok farklı sonuçların elde edildiğini görürüz. Bunun temel sebebi, yapay sinir aęlarının performansını etkileyen aę topolojisi, eęitim algoritması, veri setleri vb. çeşitli faktörlerin bulunmasıdır. Bazı durumlarda yapay sinir aęlarının tahminleme başarısı, doğrusal istatistiksel yöntemlere göre düşük çıkmaktadır. Bunun nedeni, veriler arasındaki ilişkinin doğrusal olması ya da uygun aę yapısının oluşturulamaması olabilir. Kıyaslamalarda kullanılacak tahmin yöntemleri seçiminde genelde iki durum söz konusudur. Bağımlı deęişkeni etkileyen bağımsız deęişkenler belirlenmişse yapay sinir aęları ile regresyona dayanan yöntemler kıyaslanırken, zaman serisi analizleri yapılması durumunda yapay sinir aęları ile hareketli ortalamalar, üstel düzleştirme ve Box-Jenkins yöntemleri kıyaslanmaktadır.<sup>133</sup>

Yapay sinir aęı uygulaması talep tahmini için temel olarak yedi adımda hazırlanır:<sup>134</sup>

1. Problemi tanımlama: Tahmin yapılacak problemin belirlenmesi sonraki adımlar açısından en önemli adımdır.
2. İlişkili özellikleri tanımlama: Fiyat talep ilişkisi, çevresel faktörler, içsel faktörler gibi talebi etkileyen özellikler ve aralarındaki ilişkiler veri toplanmadan önce belirlenmelidir.
3. Verileri toplama: Talep tahmininde kullanılacak geçmiş veriler, anketler, makro veriler tahmine baz olacak şekilde toplanmalıdır.
4. Veriyi düzenleme: Veriler yapay sinir aęlarının kullanacağı şekilde normalize edilmelidir.

---

<sup>132</sup> Zhang ve dięerleri, p.38.

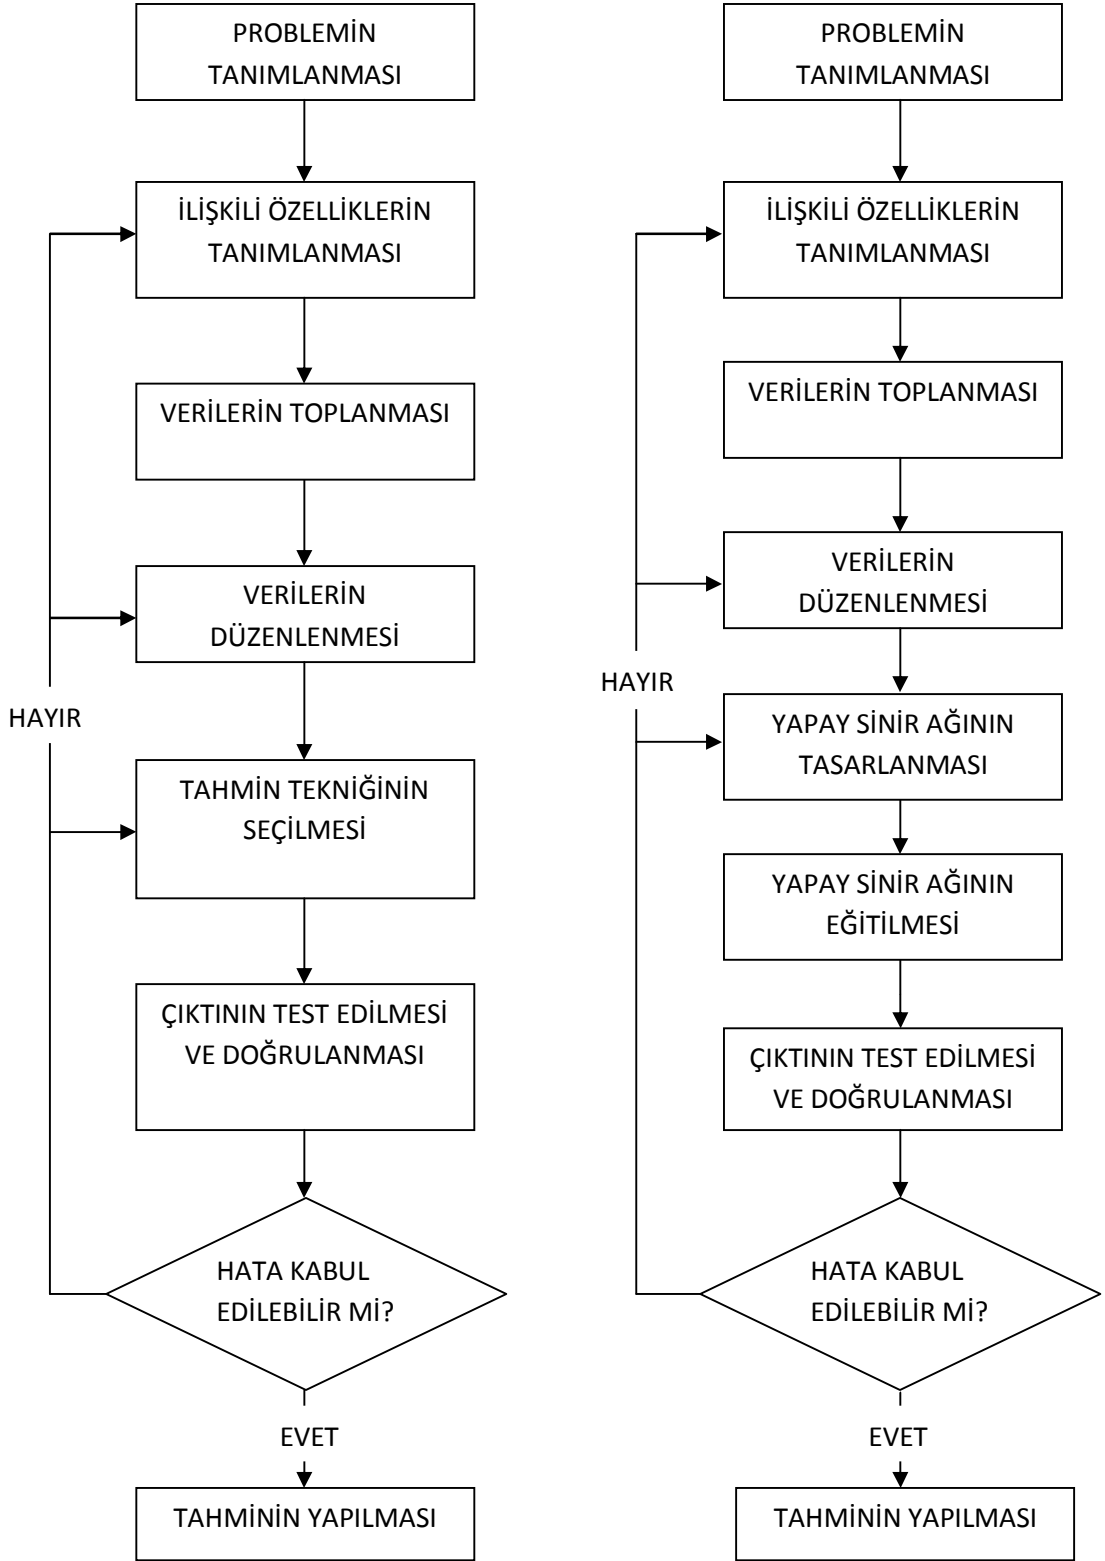
<sup>133</sup> Chin Kuo ve Arthur Reitsch, " Neural Networks vs. Conventional Methods Of Forecasting", **The Journal of Business Forecasting**, Vol.14, 1996, pp.17,19.

<sup>134</sup> Kuo ve Reitsch , p.18.

5. Yapay sinir ađını kurma: Uygun yapay sinir ađı mimarisi, ara katman sayısı, ara katmanlardaki proses sayısı, toplama ve aktivasyon fonksiyonlarının belirlenmesi, ađırlık bařlangıç deđerleri ve momentumun atanması ve uygun eđitim algoritmasının atanması yapılmalıdır. Talep tahmininde en yaygın kullanılan eđitim algoritması geri yayılım (çok katmanlı algılayıcı) yöntemidir.
6. Yapay sinir ađlarının eđitilmesi: Eđitim veri seti kullanılarak yapay sinir ađlarının eđitilmesi yani uygun ađırlıkların belirlenmesi sađlanmalıdır.
7. Yapay sinir ađını test etme ve dođrulama: Eđitilmiş olan ađın, gerçekten etkin tahminler yapıp yapmadıđı test veri seti ile ölçülmeli ve hatanın kabul edilebilir hata düzeyi içinde olup olmadıđı kontrol edilmelidir.

Talep tahmininde yapay sinir ađları yönteminin adımları ile diđer geleneksel yöntemlerin adımlarının kıyaslanması ařađıda Őekil 19'da gösterilmiřtir.

**Şekil 19:** Yapay Sinir Ağları Yöntemi ve Geleneksel Yöntemlerle Talep Tahmini Adımları



Kaynak: Kuo ve Reitsch , p.19.

## ÜÇÜNCÜ BÖLÜM

### UYGULAMA

#### 3.1. TÜRKİYE'DE PETROKİMYA SANAYİ VE PETKİM <sup>135</sup>

Petrokimya sektörü, petrol rafineri ürünleri ve doğal gazdan başlayarak plastikler, lastik, elyaf hammaddeleri ve diğer organik ara malları üreten, geniş bir üretim yelpazesine sahip büyük ölçekli, sermaye ve teknoloji yoğun bir sektördür. Bir başka deyişle petrokimya sektörü diğer sektörlere girdi sağlayan lokomotif bir sektördür. Bu sanayi dalı 1950-1960' lı yıllarda giderek daha fazla üretilmeye başlanan nafta ve doğal gaza bağlı olarak hızlı büyümüş ve kısa zamanda pek çok ülkede temel sanayi sektörü haline gelmiştir. Bugün dünya petrokimya sanayinin, yıllık 500 milyar doların üzerindeki üretim hacmi bu sektörün gücünü vurgulamaktadır. Dünya ticaretinin yaklaşık %8'i ve kimya pazarının yaklaşık %30'unu oluşturan petrokimya sanayi küresel olaylar, ekonomik koşullar ve bölgelerin pazardaki rolüne bağlı olarak inişli-çıkışlı bir büyüme ve dönemsel karlılık eğilimi gösteren bir sektördür. Tarihsel olarak bakıldığında, sektörde 3-4 yılı yüksek karlı, onu takip eden 4-5 yılı düşük karlı veya karsız dönemler görülmektedir.

Petrokimya sanayi, dünya ölçeğinde rekabete açık bir sektör olup hammadde, pazar ve teknolojik avantajlar bu rekabette rol oynayan unsurların başında gelmektedir. Petrokimya endüstrisinde son yıllarda yaşanan ekonomik krizler sonucu meydana gelen talep ve kar marjı daralması nedeniyle rekabet gücünü kaybeden pek çok firma ya piyasadan çekilmekte ya da konsolidasyona gitmektedir. Üreticiler maliyetlerini düşürmek, ekonomik şartlarda ve ölçekte üretim yapmak için birleşme yolunu tercih etmekte, bu birleşmelerle sektörde üretici sayısı azalmakta, üretici başına düşen kapasiteler artmaktadır. Böylece, gerek maliyet yönünden gerekse geniş ürün yelpazesi ve teknoloji platformunda daha avantajlı konuma gelmek hedeflenmektedir.

Petrokimya endüstrisi, gelişmiş ülkelerde doyumluğa ulaşmış, gelişen ekonomilerde ise hızla ilerlemeye devam etmektedir. Kuzey Amerika ve Avrupa pazarı doyumluğa ulaşmış bir pazardır ve son yıllarda yaşanan ekonomik

---

<sup>135</sup> Devlet Planlama Teşkilatı, " Petrokimya Sanayi Özel İhtisas Komisyonu Raporu ", <http://www.dpt.gov.tr/DocObjects/Download/3294/oik579.pdf>, (01.04.2012), ss.13-14; " Türkiye'de Petrokimya Sanayi ve Petkim ", <http://www.petkim.com.tr/Sayfa/1/46/URETİM-TURKIYE-PETROKİMYA-SANAYI-VE-PETKİM.aspx>, (01.04.2012).

duraksamalardan diğere bölgelere göre daha fazla etkilenmiştir. Gelişmekte olan ülkelerde ise petrokimyasal ürünlere olan talep artışı kriz ortamında bile pazarı canlı tutmaya yetmiştir. Petrokimya endüstrisindeki kapasite artışları çoğunlukla Asya Pasifik ve Orta Doğu bölgelerinde gerçekleşmektedir. Bunun nedeni, bu bölgelerdeki üretim ekonomisinin daha uygun olmasıdır. Ortadoğu; Kuzey Amerika ve Avrupa ile kıyaslanamayacak ölçüde hammadde maliyet avantajına sahiptir. Çin ile Hindistan gibi Asya Pasifik ülkeleri ise ucuz işgücü olanaklarına sahiptir. Bu sebeple, Kuzey Amerika ve Avrupa petrokimya endüstrisindeki etkinliğini kaybetmekte ve yeni yatırımlar Asya ve Ortadoğu'ya kaymaktadır.

Türkiye petrokimya sanayi ise henüz pazar doygunluğuna erişmemiştir ve büyük bir gelişme potansiyeline sahiptir. Gelişmiş ülkelerde kişi başına termoplastik tüketimi 75-100 kg arasında iken, yurdumuzda bu oran 30 kg civarındadır. Termoplastiklerin ülkemizdeki talep artış hızları dünya ortalamalarının 2-3 katıdır. Türkiye petrokimya sektörünün en büyük avantajı, yurtiçi talebin dünya ölçeğinde yurtiçi üretim yapılmasını sağlayacak seviyede olmasıdır. Ülkemizde yeni yatırım yapmaya imkan tanıyan geniş arazi olanağı, doğal gaz ve petrol boru hatlarına yakınlık ve kişi başına plastik tüketiminin düşük olması, yeni yatırımlar için oldukça cazip bir ortam sunmaktadır. Ülkemizin kalkınma çabaları, petrokimyasal ürünlerin tüketildiği çeşitli sektörlerdeki mevcut ve beklenen gelişmeler, hızlı nüfus artışı vb. hususlar da göz önüne alınırsa Türkiye petrokimya sanayinin büyük bir gelişme potansiyeline sahip olduğu görülmektedir.

Türkiye'de petrokimya sanayinin kurulması fikri, I. Beş Yıllık Plan döneminin başlangıcı olan 1962 yılında benimsenmiş, yapılan etüt ve araştırmalar sonucunda Petkim Petrokimya A.Ş., 03.04.1965 tarihinde TPAO öncülüğünde kurulmuştur. Petkim, Yarımca Kompleksi'nde 1970 yılında, önce 5 fabrikayı işletmeye açmış daha sonraları da diğere fabrikalar bunu takip etmiştir. III. Beş Yıllık Kalkınma Planı döneminde Petkim'in ikinci kompleksinin Aliğa'da kurulması kararlaştırılmıştır. Aliğa Kompleksi, en ileri teknolojiler ve optimum kapasitelere sahip olarak kurulmuş ve 1985 yılında işletmeye alınmıştır. 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. Özelleştirme Yüksek Kurulu'nun (ÖYK) kararı ile Yarımca Kompleksi 2001 yılında TÜPRAŞ Türkiye Petrol Rafinerileri A.Ş.'ye devredilmiştir. Petkim, 30.05.2008 tarihinde özelleştirilerek %51 hissesi SOCAR&Turcas Petrokimya A.Ş.'ye devredilmiştir. 2011 yılında Turcas ortaklık yapısından ayrılarak Petkim'in %51 hissesi bir SOCAR şirketi olan SOCAR Turkey

Enerji A.Ş.'ye geçmiştir. Devlette kalan son yüzde 10, 32'lik kamu hissesi de, 2012 yılında Socar Turkey Enerji A.Ş. 'ye satılmıştır. Yüzde 61,32'si Socar Turcas Petrokimya A.Ş.'ye ait olan Petkim'in yüzde 38,68 hissesi İMKB'de işlem görmektedir.

Petrokimya sektörü ülkemizdeki toplam kimyasal üretiminin %25'ini temsil etmekte olup, Petkim bugün ülkemizin en büyük petrokimyasal üreticisi olarak Türkiye Kimya sanayinin en büyük oyuncularından biri konumundadır. Petkim' de ürünlerinin kalitesi dünya standartlarında olup satışı olan ürünleri; Etilen, PVC, AYPE, YYPE, PP, ACN, PTA, MEG, PA, DEG, TEG, Benzen, P-X, C5 Karışımı, C4, Aromatik Yağ, Ham Benzin, Sudkostik, Hidrojen , Masterbatch, ve Plastik Mamulleridir. Petkim'in dışında polistiren üreten BASIC Petrokimya ile Di Metil Tereftalat üreten SASA ülkemizin diğer petrokimyasal hammadde üreten kuruluşlarıdır.

Petkim kurulduğundan bu yana ürettiği ürünleri müşterilerine doğrudan pazarlamaktadır. Petkim'in temel satış stratejisi öncelikle iç piyasa talebini karşılamaktır. İç piyasada yeterli talep olmadığında, ihracat yapmaktadır. Pektim, en çok AB ve Uzak Doğu-Asya ülkelerine ihracat yapmaktadır. Benzen, C4, Py-Gas ve P-x ana ihracat ürünleridir.

Türkiye'de petrokimyasal ürün talep artış hızları dünya ortalamalarının çok üzerindedir. Sektördeki büyüme hızının GSMH büyüme hızına oranı ise dünya ortalamasının yaklaşık iki katı düzeyindedir. 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. Aliağa Kompleksi'nin devreye girdiği yıllarda Petkim'in yurtiçi talebi karşılama oranı %85 iken, 2011 yılı sonunda bu oran yaklaşık %25 düzeyine gerilemiştir. Türkiye petrokimyasal talebinin her yıl %10–12 arttığı göz önüne alındığında yeni yatırımların yapılmaması halinde, 2023 yılına kadar yurtiçi pazar payının %10'un altına düşeceği açıkça görülmektedir. Bunun sonucunda petrokimya sektörü tamamen ithalata bağımlı hale gelecektir. Bu durum, yıllardır üretim ve fiyat politikasıyla iç piyasada denge unsuru olan Petkim'i bu işlevini yerine getirmekten alıkoyacak ve sonucunda tüm bağlı sektörler olumsuz etkilenecektir. Bu durumun sürdürülebilmesi mümkün olmadığından özelleştirme sonrası Socar Turkey Enerji

A.Ş., Aliğa Kompleksi'nde Rafineri-Petrokimya-Enerji-Lojistik entegrasyonunu temel alan bir büyüme projeksiyonu ortaya koymuştur. Şirket, Aliğa üssünü 'Value-Site' projesiyle Avrupa'nın en önemli üretim merkezlerinden biri haline dönüştürmeyi hedeflemektedir.

Petkim, 'Value-Site' projesi doğrultusunda, Türkiye'nin en önemli değerlerinden biri olan Petkim yarımadasını, 2020 yılına kadar Rafineri-Petrokimya-Enerji-Lojistik entegrasyonu temel mantığı çerçevesinde, hammadde güvenilirliğini sağlayacak rafineriye sahip, 6 milyon ton petrokimyasal üretebilen, en az 1 milyon TEU kapasiteli konteyner terminali ve entegre liman ve lojistik alana sahip, yarımada'nın enerji ihtiyacının fazlasını üretebilen, yerli yabancı yatırımcıların yer aldığı kümelenme modelini hayata geçirmiş, Avrupa'nın önemli üretim merkezlerinden biri haline dönüştürmeyi hedeflemektedir.

'Value-Site' hedefleri çerçevesinde önemli adımlar atılmaktadır. Petkim'in kapasite artırıcı yatırımlarının itici gücü olan ve hammadde güvenilirliğini sağlayacak rafineri kurma çalışmaları 2011 yılında STAR Rafineri A.Ş. tarafından başlatılmıştır. 2015 yılında devreye alınması planlanan STAR Rafinerisi, SOCAR Turkey Enerji A.Ş'nin Petkim Yarımadası üzerindeki "Value-Site" projesinin ilk ve en önemli basamağını oluşturuyor. Petkim, bugün için temel hammaddesi olan naftada yaklaşık yüzde 85 oranında dışa bağımlıdır. Bu sürdürülebilir bir durum değildir. Bu rafineri ile üretilen ve Petkim'in hammaddede dışa bağımlılığını bitirecek olan nafta miktarı 1.6 milyon ton'dur. Hammadde güvenilirliğini sağlamak ve ithalata bağımlılık zincirini kırmak açısından bu proje büyük önem taşımaktadır. Hem gelişmiş ülkelerde, hem de gelişmekte olan ülkelerde yeni kurulan ve yeniden yapılanan nafta bazlı petrokimya komplekslerinde rafineri-petrokimya entegrasyonu en ileri düzeyde planlanarak rekabet üstünlüğü yaratılmaya çalışılmaktadır. Petkim de, rafinerinin devreye alınmasıyla birlikte rekabetçi bir kimlik kazanacaktır.

Rafineri-Petrokimya-Enerji-Lojistik entegrasyonunu gerçekleştirme yolunda enerji ve lojistik alanlarında da önemli gelişmeler sağlanmıştır. "Value-Site" vizyonu çerçevesinde lojistik hedefleri açısından çok önemli bir adım atılmaktadır. Petkim'in %100 hissedarı olduğu Petlim Limancılık A.Ş ve Hollanda'nın konteyner terminali operasyonlarında ve yönetiminde dünya lideri APM terminals ile konteyner limanı kurulması konusunda anlaşma sağlanmıştır. 2014 yılında tamamlanması planlanan proje ile Petkim Limanı'nın kapasitesi Alsancak Limanı'nın bugünkü kapasitesinden %50 daha fazla olacaktır. Enerji alanında ise kapasite artışıyla birlikte ortaya çıkacak ek enerji ihtiyacını karşılamak amacıyla 25 MW gücünde Rüzgar Enerjisi



kurulum projesi bulunmaktadır. Petkim tesislerinde yenilenebilir enerji kaynaklarından olan rüzgar enerjisine dayalı Rüzgar Enerjisi Santrali (RES) kurulması için Enerji Piyasası Düzenleme Kurulu (EPDK) 'dan Otoprodüktör Lisansı alınmıştır ve bu proje ile ilgili çalışmalar devam etmektedir.

Günümüzde bölgelerin/ülkelerin kalkınmasında ve gelişmesinde, özellikle kimya sanayinde kümelenme modeli uygulamalarının çok önemli rol oynadığı kabul edilmektedir. Kimya kümelerinde, ekonomik aktörler arasında büyük oranda yakın mesafeden kaynaklanan yakın bir ilişki, yoğun bir bilgi alışverişi vardır. Kümelenme modelleriyle küçük ve büyük ölçekli firmaların petro-rafineri olgusu çerçevesinde konuşlanmaları, yardımcı işletmeler, bakım-onarım, teknoloji destek merkezi, Ar-Ge gibi birçok destek hizmetinin ortak kullanımının getirdiği avantajların yanı sıra, bu firmaları hammadde taşıma ve stoklama maliyetinden kurtararak son ürün maliyetini düşürme avantajı sağlamaktadır. Petkim, "stratejik bir sanayi bölgesi" olan Aliağa'da Petkim arazisi üzerinde kümelenme modelini uygulamayı ve bölgedeki en büyük petrokimya ve lojistik merkezi olmayı hedeflemektedir. Bu amaçla, Singapur'da bulunan dünyanın en önemli kümelenme modeli örneklerinden biri olan "Jurong Island" 'ın yaratıcısı ve kırkı aşkın ülkede petrokimya kümesi planlayan Jurong International firmasından danışmanlık hizmeti almaktadır. "Petrokimya Endüstri Parkı" oluşturma stratejisi çerçevesinde 2012 yılında önemli bir adım atılmıştır. Petkim sahasında bulunan sekiz yardımcı ünitelerden biri olan Hava-Azot ünitesi, dünyanın en büyük endüstriyel gaz üreticilerinden Air Liquide firmasına devredilmiştir. Petkim böylece bir yandan Rafineri-Petrokimya-Enerji-Lojistik zinciri ile dikey entegrasyonu gerçekleştirirken, diğer yandan, Air Liquide yatırımıyla yan sanayi ile işbirliği geliştirerek yatay entegrasyona gitmektedir.

### **3.2. TALEP TAHMİNİ PROBLEMİNİN TANIMLANMASI**

Günümüzde oldukça geniş bir kullanım alanı bulunan plastiklerin, gerek ekonomiklikleri, gerekse kolay uygulanabilirlikleri nedeniyle diğer maddelere göre tüketimi hızla artmaktadır. Bugün plastikler, bütün dünyada demir, tahta ve cam gibi materyallerin yerine alternatif bir malzeme olarak kullanılmakta, her geçen gün de yeni uygulama alanları ortaya çıkmaktadır.

Oldukça yaygın kullanım alanı olan plastiklerin üretimi son 61 yılda 160 kattan fazla artış göstermiştir. 1950 yılında 1,7 milyon ton olan dünya plastik üretimi, 2011 yılına gelindiğinde 280 milyon ton olarak gerçekleşmiştir. Son 20 yıllık üretim

verileri incelendiğinde ise, üretimin yıllık ortalama %5 arttığı dikkatleri çekmektedir. Her yıl kişi başı plastik talebinin % 4 oranında arttığı göz önünde bulundurulursa üretim artışının ilerleyen yıllarda daha da artarak devam edeceği tahmin edilmektedir.<sup>136</sup>

Ülkemizde plastik endüstrisinin geçmişi ise 1960 yılı yani sanayileşme yıllarına dayanmaktadır. Ülkemiz plastik endüstrisinde, çoğu küçük ve orta ölçekli olmak üzere 6 binden fazla işletme ile üretim yapılmakta ve 200 binden fazla kişiye istihdam sağlanmaktadır. Türk plastik sektörü yıllık ortalama yüzde 13 gibi büyüme rakamına sahiptir. En hızlı büyüyen pazarlardan biri olarak dikkat çeken plastik endüstrisi, petrokimya sanayine paralel olarak gelişme göstermiştir. Plastik sektörünün temel girdileri termoplastikler, termoset plastikler ve diğer katkı maddeleridir. Plastik sektörü, girdilerinin %90'ını petrokimya sanayisinden temin etmektedir.<sup>137</sup>

Plastik sektöründeki hızlı büyümeye karşın petrokimya sanayimiz aynı ölçüde gelişme sağlayamamıştır. Türkiye'nin tek petrokimya tesisi olan Petkim, yılda ortalama yüzde 13 büyüyen plastik sektörünün hammadde talebini karşılayamamaktadır. Ülkemizde plastik hammaddesinin oldukça az üretilmesi nedeniyle, Türkiye dünyanın önemli plastik hammadde ithalatçısı ülkeleri arasında yer almaktadır. 2011 yılında toplam hammadde arzı içinde yerli üretimin payı %14, ithalatın payı ise %86 olarak gerçekleşmiştir. Önemli bir plastik hammadde ithalatçısı olan Türkiye'nin, 4 milyon ton olan 2007 yılı ithalat miktarı, 2011'de 5,2 milyon tona yükselmiştir. 2011 yılında 5,2 milyon ton plastik hammadde ithalatı için 9.932 milyon \$ ödenmiş olup, hammadde ithalatı için ödenen miktar bir önceki yıla kıyasla %30 artış göstermiştir.<sup>138</sup>

Plastik hammadde üretiminde en büyük pay sahibi olan Petkim'in 2011 yılı satış rakamları Şekil 20'de gösterilmektedir. Satış miktarlarının ürün bazındaki dağılımına baktığımızda, termoplastikler %43 ile en yüksek paya sahiptirler. Termoplastik satışlarında ise AYPE %18, PVC %11, PP %8 ile ilk üç sırayı almaktadır.

---

<sup>136</sup> Gözde Sevilmiş, "Ege Bölgesi Plastik Sektörü Raporu" , **İzmir Ticaret Odası Ar-Ge Bülteni**, [http://www.izto.org.tr/NR/rdonlyres/7475BDA1-95B7-4855-B351-9ADCE4362AFE/19885/EgeBölgesiPlastikSektörüRaporu\\_GözdeSevilmiş.pdf](http://www.izto.org.tr/NR/rdonlyres/7475BDA1-95B7-4855-B351-9ADCE4362AFE/19885/EgeBölgesiPlastikSektörüRaporu_GözdeSevilmiş.pdf), (01.04.2012), İzmir, 2012, s.9.

<sup>137</sup> Hüseyin Kaya ve diğerleri, " Türk Plastik Sektörünün Rekabetçilik Analizi ", **İ.T.Ü Sosyal Bilimler Enstitüsü Dergisi**, Cilt:6, Sayı:11, 2007, s.204.

<sup>138</sup> Sevilmiş, s.21.

**Şekil 20:** 2011 Yılı Satış Miktarlarının Ürün Bazında Dağılımı



Kaynak: <http://www.petkim.com.tr/>, (01.04.2012).

Termoplastikler; ambalajdan inşaata, tarımdan otomotive, tekstilden gıdaya, ekonomiyi sürükleyici birçok sektöre girdi sağlayan petrokimyasal ürün grupları içinde önemli bir yer tutmaktadır. Gelişmiş ülkelerde kişi başına termoplastik tüketimi 75-100 kg arasında iken, yurdumuzda bu oran 30 kg civarındadır. Termoplastiklerin ülkemizdeki talep artış hızları dünya ortalamalarının 2-3 katıdır.<sup>139</sup>

Petkim Satış ve Pazarlama Müdürü ile yapılan görüşmeler sonucunda; ülkemizde en hızlı büyüyen pazarlardan birisi ve şirketin satışlarında büyük pay sahibi olan termoplastikler üzerine talep tahmini çalışması yapılmasına karar verilmiştir. Talep tahmini çalışması için termoplastik ürünlerden bir tanesi baz alınacaktır. Termoplastik ürünler içerisinde son yıllarda Türkiye’de inşaat sektörünün gelişimiyle talebi artan ve şirketin termoplastik satışlarında %11’lik pay ile ikinci sırada yer alan PVC ürünü, talep tahmin çalışması için seçilmiştir. Bu çalışmada PVC ürünü ile PVC plastik hammaddesinden bahsedilmektedir. Bu araştırma ile Petkim’in toplam PVC plastik hammadde satışını tahmin etmek ve talebi etkileyen faktörleri belirlemek hedeflenmektedir. Tahminleme aracı olarak son yıllarda öngörüleme alanında giderek kullanımı artan yapay sinir ağı tekniği kullanılacaktır. Ayrıca, yapay sinir ağlarının tahmin performansını belirlemek için klasik yöntemlerden çoklu doğrusal regresyon analizi ile kıyaslama yapılacaktır.

<sup>139</sup>Devlet Planlama Teşkilatı, “ Petrokimya Sanayi Özel İhtisas Komisyonu Raporu”, <http://www.dpt.gov.tr/DocObjects/Download/3294/oik579.pdf>, (02.04.2012), s.13.

### 3.3. UYGULAMADA ELE ALINACAK ÜRÜNÜN TANITILMASI

Günümüzde plastikler, temel olarak termoplastikler (sanayide yoğun olarak kullanılan), termoset plastikler ve polimer alaşımları olmak üzere üç grupta değerlendirilmektedir. Termoplastikler ısıtılıp tekrar soğutulduğunda eski şeklini alabilirken, termoset plastikler eski şekillerini alamamakta ve bozulmaktadırlar.<sup>140</sup>

PVC, dünyada ilk keşfedilen termoplastiklerden birisidir. PVC'nin monomeri etilenden ve klordan elde edilen vinilklorürdür. Vinil Klorür Monomer'in (VCM) basınç, sıcaklık ve katalizörlerin etkisinde polimerizasyonu ile PVC ürünü toz halinde elde edilmektedir. PVC'nin VCM üretim yöntemlerine göre, kalsiyum karbit ya da asetilen bazlı ve etilen bazlı olmak üzere iki geleneksel üretim yöntemi bulunmaktadır. Asetilen bazlı PVC üretiminde öncelikle, kömürden elde edilen kok ve kalsiyum oksit kullanılarak karbit elde edilmektedir. Sonrasında kalsiyum karbit VCM üretmek üzere hidrojen klorür ile reaksiyona sokulmakta ve VCM'ye geçilmekte, elde edilen VCM daha sonra PVC üretiminde kullanılmaktadır. Etilen bazlı PVC üretiminde ise öncelikle petrolden elde edilen etilenden VCM üretilmekte, daha sonra VCM monomerinden PVC'ye geçilmektedir. PVC üretim süreci Ek 1 'de gösterilmiştir.<sup>141</sup>

Geniş bir kullanım alanı bulunan PVC; boru imalatı, profil imalatı (pencere ve kapı profilleri, bina içi kaplama malzemeleri, fitil, conta, köpük), kablo imalatı, rijid film imalatı (folyo, şeffaf sert filmler, kırtasiye malzemeleri), enjeksiyon kalıplama (terlik ve ayakkabı tabanı, oyuncak), düz plaka imalatı (zemin kaplama malzemeleri), şişe, serum torbaları imalatı gibi alanlarda kullanılmaktadır. PVC ürününün Türkiye'deki tek üreticisi olan Petkim A.Ş., ICI-Solvay lisansı ile üretim yapmaktadır. Geniş bir tüketim sahası olan bu ürünün Aliğa tesislerinde üretimine 1986 yılının Mart ayında başlanmıştır. Petkim A.Ş. tarafından S-23, S-27, S-39, S-65 süspansiyon PVC türleri üretilmektedir. Ek 2'de ise PVC ürünlerine ilişkin karakteristik özellikler gösterilmektedir.<sup>142</sup>

---

<sup>140</sup> Kaya ve diğerleri, s.204.

<sup>141</sup> " PVC İthalatına Yönelik Yapılan Korunma Önlemi Başvurusunun Özeti ",  
[http://www.ekonomi.gov.tr/upload/EF8317F5-D8D3-8566-452028FED6D52922/PVC\\_ozet\\_tr.pdf](http://www.ekonomi.gov.tr/upload/EF8317F5-D8D3-8566-452028FED6D52922/PVC_ozet_tr.pdf),  
(01.04.2012), s.1.

<sup>142</sup> " PVC İthalatına Yönelik Yapılan Korunma Önlemi Başvurusunun Özeti",  
[http://www.ekonomi.gov.tr/upload/EF8317F5-D8D3-8566-452028FED6D52922/PVC\\_ozet\\_tr.pdf](http://www.ekonomi.gov.tr/upload/EF8317F5-D8D3-8566-452028FED6D52922/PVC_ozet_tr.pdf),  
(01.04.2012), s.2.

1986 yılında 105.000 ton/yıl kapasite ile üretime geçen Aliğa PVC fabrikası 1995 yılında tamamlanan tevsii ile 140.000 ton /yıl kapasiteye ulaşmıştır. 2002 yılında 1 adet reaktör ilavesiyle kapasite 150 000 ton/yıl'a ulaşmıştır. Bu üretim kapasitesi iç piyasa talebini karşılamakta yetersiz kalmaktadır. PVC ürünün satışında esas amaç, yurt içi talebin karşılanmasıdır. 2010 yılında iç piyasa talebinin ancak % 17'si, 2011 yılında ise % 15'i karşılanabilmiştir. İç piyasa talebi büyük oranda ithalat yoluyla karşılanmaktadır.<sup>143</sup>

### 3.4. YAPAY SİNİR AĞI MODELİ VERİ TASARIMI

Petkim Satış ve Pazarlama Müdürü ve Satış Uzmanları ile yapılan görüşmeler sonucunda PVC talebini etkileyen başlıca faktörlerin aşağıdaki gibi olduğu tespit edilmiştir. Bunlar:

1. Petkim PVC Satış Fiyatı: Satış fiyatı, PVC ürününün talebini etkileyen başlıca faktör olarak belirlenmiştir. PVC ürününün satış fiyatlarındaki artışın genel olarak ürüne olan talebi azalttığı düşünülmektedir.
2. İnşaat Sektörü: Ülkemizde PVC ürünü, yaklaşık %70 oranında yapı sektöründe kullanılmaktadır. İnşaat sektöründeki büyümenin PVC ürününe olan talebi artıracığı düşünülmektedir.
3. İmalat Sanayi: PVC ürününün kullanıldığı çeşitli sektörlerdeki (otomotiv, elektrik-elektronik, ambalaj sanayi gibi) değişimi göstermesi açısından bu değişken modele dahil edilmiştir. Ülkemiz imalat sanayindeki artışın PVC talebini artıracığı düşünülmektedir.
4. PVC İthalatı: Ülkemizde PVC talebi büyük oranda ithalat yoluyla karşılanmakta ve bunun sonucunda Petkim'in PVC pazar payı giderek azalmaktadır. İthalat artışının Petkim PVC satışlarını azaltacağı düşünülmektedir.
5. GSYİH: Plastik tüketiminin iç pazardaki büyüme potansiyeli, GSYİH' ye paralel olarak gelişmektedir. GSYİH' deki artışın PVC ürününe olan talebi artıracığı düşünülmektedir.

---

<sup>143</sup> Devlet Planlama Teşkilatı, " Petrokimya Sanayi Özel İhtisas Komisyonu Raporu ", <http://www.dpt.gov.tr/DocObjects/Download/3294/oik579.pdf>, (02.04.2012), s.274.

6. Nüfus: Nüfus artışına paralel olarak konut talebi artmaktadır. Bu da inşaat sektörünün büyümesini sağlamaktadır. Nüfus artışının PVC ürününe olan talebi artıracığı düşünülmektedir.

Yapay sınır ağları ile tahmin modeli oluşturulurken açıklayıcı değişkenlerin belirlenmesi konusunda, değişkenlerin açıklayıcılık gücü ve veri kısıtları öncelikli olarak değerlendirilmiştir. Bu amaca yönelik olarak, açıklayıcı değişkenler arasında açıklama gücü yüksek olan ve veri kısıtı en az olan değişkenler tercih edilmiştir. Sonuç olarak, yukarıda sayılan değişkenler PVC talebini etkileyen başlıca faktörler olarak belirlenmiştir.

PVC ürün talebini etkileyen faktörlerden; Petkim PVC Satış Fiyatı, ülkemiz için İnşaat Sektörü Üretim Endeksi, İmalat Sanayi Endeksi, PVC İthalat Miktarı, GSYİH ve Nüfus miktarı yapay sınır ağı modelinde girdi katmanını oluşturmaktadır. Çıktı katmanında ise Petkim PVC Satış Miktarı yer almaktadır.

Faktörlere ilişkin istatistiki verilere baktığımızda zamansal farklılıklar olduğunu görmekteyiz. PVC satış fiyatı, PVC satış miktarı, İmalat sanayi üretim endeksi, PVC ithalatına ilişkin veriler aylık bazda; İnşaat sektörü üretim endeksi, GSYİH üç aylık; nüfus miktarı ise yıllık bazda yayınlanmaktadır.

Yapay sınır ağlarında veri sayısı öğrenme performansını doğrudan etkilediği için zaman biriminin ay olarak seçilmesine karar verilmiştir. Aylık yayınlanmayan verilerin çeşitli varsayımlarla dönüştürülmesi gerçekleştirilmiştir.

Veri düzenlemesi yapılırken inşaat sektörü üretim endekslerine ait istatistikler 2005 yılı baz alınarak yayınlandığından dolayı başlangıç yılı 2005 olarak alınmıştır.

2005-2011 yılları arasındaki veriler toplanmış, 2005-2010 yılları arasındaki veriler eğitim ve doğrulama amaçlı kullanılmıştır. 2011 yılı verileri ise test amaçlı kullanılmıştır. Veriler girdi ve çıktı verileri olmak üzere aşağıdaki gibi düzenlenmiştir:

Girdi verileri;

- Petkim PVC Satış Fiyatı: PVC ürününe ilişkin aylık toplam satış tutarı toplam satış miktarına bölünerek aylık ortalama PVC satış fiyatı ( \$ / ton ) bulunmuştur.
- İnşaat Sektörü Üretim Endeksi: İnşaat sektörü üretim endeksi 2005 yılı baz alınarak üç aylık olarak yayınlanmaktadır(TÜİK). Aylık dönüşüm için 2005-2011 yılı arası üç aylık veriler, üç aylık dönem için aylık bazda eşit olarak kabul edilmiştir.
- İmalat Sanayi Endeksi: İmalat sanayi endeksi, 2005 yılı baz alınarak aylık olarak yayınlanmaktadır( TÜİK ).

- PVC İthalat Endeksi: PVC ithalat değerleri aylık olarak yayınlanmaktadır ( TÜİK ). Aylık yayınlanan verilerden yola çıkılarak 2005 yılı baz olmak üzere ( 2005 = 100 ) ithalat endeksi oluşturulmuştur.
- GSYİH: GSYİH değerleri üç aylık (Bin TL) olarak yayınlanmaktadır(TÜİK). Aylık dönüşüm için 2005-2011 yılları arası üç aylık veriler, üç aylık dönem için aylık bazda eşit olarak kabul edilmiştir.
- Nüfus: Nüfus verileri yıllık olarak yayınlanmaktadır(TÜİK). 2005-2011 arası nüfusa ilişkin verilerin yıllık bazdan aylık baza dönüştürülmesinde; birim zamanda (aylık) nüfus artışının sabit olduğu varsayılarak yıllık nüfus artışları aylara yansıtılmıştır.

Çıktı verisi;

- Petkim PVC Satış Miktarı: 2005-2011 yılları arasında aylık bazda Petkim'in PVC satış miktarı toplanarak aylık toplam PVC satışı (Ton) belirlenmiştir.

Yapay sinir ağı ile oluşturulan modele ilişkin veri seti Ek 3' de gösterilmiştir. Girdi ve çıktı verilerinin ağa sunulmadan önce normalize edilmesi gerekmektedir. Tercih edilen yapay sinir ağı yazılımı, verileri [0,1] aralığına kendisi normalize etmektedir. Sonuç olarak veriler, [0,1] aralığına normalize edilmiştir.

Yapay Sinir Ağları değişkenler arasındaki doğrusal olmayan ilişkileri yakalamakla beraber mevsimsel etkiyi de gidermektedir.<sup>144</sup> Bu çalışmada Yapay Sinir Ağları'nın mevsimsel etkiyi gidereceği düşünülerek verilerde mevsimsel etkinin giderilmesi ile ilgili bir çalışma yapılmamıştır.

### 3.5. YAPAY SİNİR AĞI MİMARİSİ

Tahmin amaçlı en yaygın kullanılan YSA tipi, Çok Katmanlı Algılayıcıdır. Talep tahmininde aktivasyon fonksiyonu olarak da en yaygın kullanılan Sigmoid fonksiyonudur. Bu çalışmada öğrenme için Çok Katmanlı Algılayıcı yöntemini ve Sigmoid fonksiyonunu kullanılan bir program olan EasyNN programı seçilmiştir.

---

<sup>144</sup> Robert J. Sadowski ve diğerleri, "Forecasting Aggregate Retail Sales: A Comparison of Artificial Neural Networks and Traditional Methods", **The Journal of Retailing and Consumer Services**, Vol.8, 2001, p.150.

2005-2010 yılları arasındaki 72 adet veri ağın eğitimi amaçlı kullanılmıştır. Bunlardan 63 tanesi eğitim, 9 tanesi doğrulama için seçilmiştir. 2011 yılı verileri ise test amaçlı kullanılmıştır.

ÇKA modelinde herhangi bir problem için kaç tane ara katman ve her ara katmanda kaç tane proses elemanı kullanılması gerektiğini belirten bir yöntem şu ana kadar bulunmuş değildir. Genellikle deneme yanılma yöntemi etkin olarak kullanılmaktadır. Literatüre baktığımızda tek gizli katman kullanıldığında daha başarılı sonuçlar alındığını görmekteyiz. Bu nedenle çalışmada, birçok talep tahmininde kullanıldığı gibi biri gizli katman olmak üzere üç katmanlı bir yapı seçilmiştir. Yapay sinir ağı modellemesinde kesinleşmiş bir yöntem olmamakla birlikte optimum gizli hücre sayısını elde etmek için “geometrik piramit kuralı” olarak adlandırılan bir yöntem kullanılır. Bu kural kesinlik içermez sadece genelde uygulanan bir yöntemdir. Bu yöntemde göre; 3 katmanlı,  $n$  giriş hücreli ve  $m$  çıkış hücreli bir ağ için gizli katmandaki hücre sayısı **karekök (  $n * m$  )** kadar olabilir.<sup>145</sup>

Deneme yanılma yöntemi kullanılarak en uygun ağ yapısı bulunmaya çalışılmıştır. Bu çalışmada girdi sayısı 6, çıktı sayısı 1 olduğu için karekök (  $n * m$  ) formülüne göre gizli hücre sayısı ilk denemeler için 3 olarak kabul edilmiştir. Öğrenme ve momentum katsayıları için EasyNN programının belirlediği öndeğerler ilk denemeler için kabul edilmiştir. Öğrenme katsayısı için 0.6 ve momentum katsayısı için 0.8 değerleri başlangıç değerleri olarak alınmıştır. Çevrim sayısı için 1000 başlangıç olarak seçilmiştir. Optimum sonuca ulaşmak için gizli hücre sayısı, çevrim sayısı, öğrenme ve momentum katsayıları değiştirilerek denemeler yapılmıştır. 2011 yılı için gerçekleşen değer ile bu parametrelerin farklı değerleriyle tahmin edilen değerler kıyaslanmıştır. Performans ölçütü olarak Ortalama Hata Kareleri ( OHK ) seçilmiştir. En düşük ortalama hata kareye sahip modelin en iyi model olduğu kabul edilmiştir. Buna göre parametreler için en uygun değerler bulunmaya çalışılmıştır.

Momentum katsayısı ağın öğrenme performansını etkilemektedir. Momentum katsayısı bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesidir. Momentum katsayısı yerel çözümlere takılan ağların bir sıçrama ile daha iyi sonuçlar bulmasını sağlar. Bu değer küçük olması yerel çözümlerden kurtulmayı zorlaştırırken çok büyük olması tek bir çözüme ulaşmakta sorun çıkartabilir. Tecrübeler bu değer 0.6-0.8 arasında seçilmesinin uygun olacağını

---

<sup>145</sup> Y.Yoon ve diğerleri,. “A Comparison of Discriminant Analysis Versus Artificial Neural Networks”, **Journal of Operational Research**, Vol.44, No1., 1993, p. 55.



göstermektedir. Fakat problemin niteliğine göre daha küçük değerler ile başarılı sonuçların alındığını gösteren örnekleri de görmek mümkündür.<sup>146</sup> Eğitim katsayısı programın öndeğeri olan 0,6 bırakılarak, 1000 çevrim için momentum katsayısı değiştirilerek en uygun momentum katsayısı bulunmaya çalışılmıştır. Tablo 3'de 2011 yılı için gerçekleşen değerler ile momentum katsayısının farklı değerlerine göre tahmin edilen değerler kıyaslanmıştır. Bu çalışmada en uygun momentum katsayısının 0.6 olduğu görülmüştür.

**Tablo 3:** Momentum Katsayısının Farklı Değerleri için 2011 Yılı Tahmin Sonuçları

Momentum Katsayısı	0,1	0,3	<b>0,6</b>	0,8	0,9
<b>Ortalama Hata Kare</b>	18984445	14938289	<b>14349434</b>	28559991	36955311

Momentum katsayısı kadar öğrenme katsayılarının belirlenmesi de ağıın öğrenme performansı ile yakından ilgilidir. Öğrenme katsayısı ağırlıkların değişim miktarını belirler ve eğer büyük değerler seçilirse yerel çözümler arasında ağıın dolaşması, küçük değerler seçilirse öğrenme zamanının artması söz konusu olur. Tecrübeler genellikle 0.2- 0.4 arasındaki değerlerin kullanıldığını göstermektedir. Fakat bu tamamen ilgili probleme bağlıdır. Bazı uygulamalarda ise öğrenme katsayısının 0.6 değerini aldığı zaman en başarılı sonuçları verdiği görülmektedir.<sup>147</sup> Momentum katsayısı 0.6 olarak alınarak 1000 çevrim için öğrenme katsayıları değiştirilerek en uygun öğrenme katsayısı bulunmaya çalışılmıştır. Tablo 4'de 2011 yılı için gerçekleşen değerler ile öğrenme katsayılarının farklı değerlerine göre tahmin edilen değerler kıyaslanmıştır. Bu çalışmada en uygun öğrenme katsayısının 0.7 olduğu görülmüştür.

**Tablo 4:** Öğrenme Katsayısının Farklı Değerleri için 2011 Yılı Tahmin Sonuçları

Öğrenme Katsayısı	0,1	0,3	0,5	<b>0,7</b>	0,9
<b>Ortalama Hata Kare</b>	23384109	15022769	14454879	<b>14365265</b>	27671814

<sup>146</sup> Öztemel, s.99.

<sup>147</sup> Öztemel, s.99.

Momentum katsayısı 0.6, Öğrenme katsayısı 0.7 ve Çevrim sayısı 1000 seçilip ara katmandaki hücre sayısı 1'den 15'e kadar değiştirilerek en uygun hücre sayısı bulunmaya çalışılmıştır. Tablo 5'de 2011 yılı için gerçekleşen değerler ile gizli hücre sayısının farklı değerlerine göre tahmin edilen değerler kıyaslanmıştır. Bu çalışmada en uygun gizli hücre sayısının 3 olduğu görülmüştür.

**Tablo 5:** Ara Hücre Sayısının Farklı Değerleri için 2011 Yılı Tahmin Sonuçları

Gizli Hücre Sayısı	1	3	7	10	15
Ortalama Hata Kare	14928788	<b>14365265</b>	14603340	15604128	24632680

Belirli bir iterasyondan sonra hatanın daha fazla azalmadığı görülür. Bu ağın öğrenmesini durdurduğu ve daha iyi bir sonuç bulunamayacağı anlamına gelir.<sup>148</sup> Momentum katsayısı 0.6, Öğrenme katsayısı 0.7, Gizli katmandaki hücre sayısı 3 olarak alınmış ve çevrim sayısı değiştirilerek en uygun çevrim sayısı bulunmaya çalışılmıştır. Tablo 6'da 2011 yılı için gerçekleşen değerler ile çevrim sayısının farklı değerlerine göre tahmin edilen değerler kıyaslanmıştır. Sonuçlara göre en uygun çevrim sayısının 1700 olduğu görülmüştür.

**Tablo 6:** Çevrim Sayısının Farklı Değerleri için 2011 Yılı Tahmin Sonuçları

Çevrim Sayısı	200	700	1200	<b>1700</b>	2000
Ortalama Hata Kare	23793063	14446228	14343371	<b>14233876</b>	14421102

### 3.6. YAPAY SİNİR AĞININ EĞİTİLMESİ

Yapay sinir ağının eğitilmesi için Easynn programı kullanılmıştır. Şekil 21 ve Şekil 22'de ağ topolojisi ve parametrelerine ilişkin veri girişleri gösterilmektedir.

- Ara katman olarak 1 gizli katman ve ara hücre sayısı 3 seçilmiştir.
- 72 eğitim verisinden 9 tanesi doğrulama amaçlı seçilmiştir.
- Momentum katsayısı 0.6 ve öğrenme katsayısı 0.7 olarak girilmiştir.

<sup>148</sup> Öztemel, s.85.

- d. Hedef hata %1 olarak belirlenmiştir.
- e. Çevrim sayısı 1700 olarak girilmiştir.

**Şekil 21:** EasyNN Programı Katman ve Hücre Sayısının Belirlenmesi

New Network - Defaults are set

Growth rate  
Change every  cycles or  seconds

Connect layers  
 Set freezes  
 Set trimming  
 Set cloning

OK  
Cancel

Input layer  
Created with  
6 nodes  
connected to  
grid inputs

Hidden layers  
 Create hidden layers  
Grow layer number 1  2  3   
from minimum nodes     
to maximum nodes

Output layer  
Created with  
1 node  
connected to  
grid outputs

Şekil 22: EasyNN Programı Parametre Tanımlama Ekranı

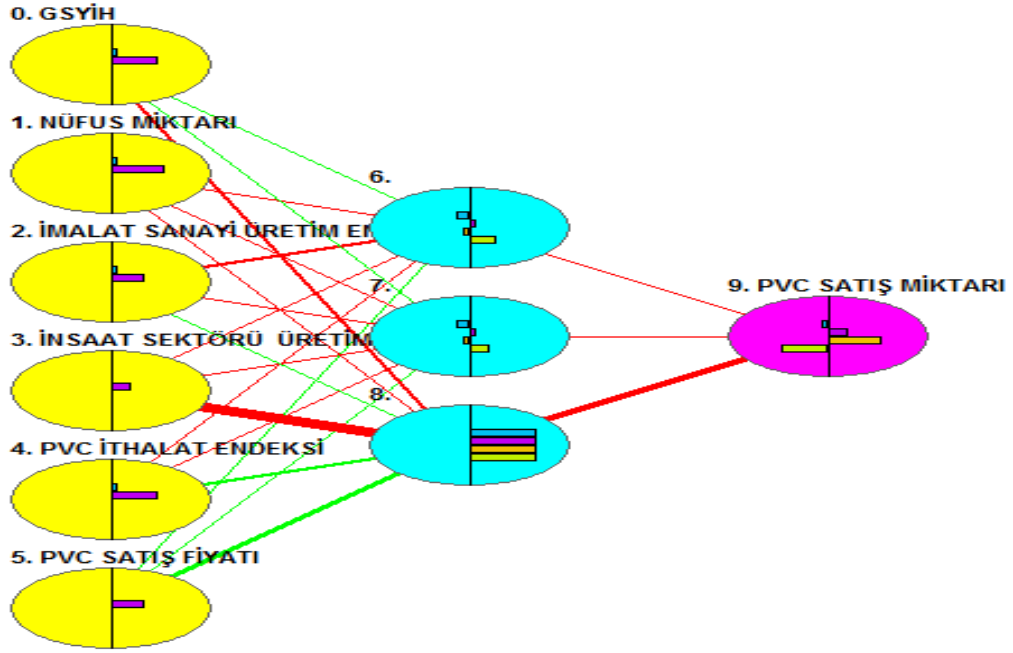
The screenshot shows the 'Controls' dialog box for the EasyNN program. It is divided into several sections:

- Learning:** Learning rate (0.7), Momentum (0.6), Accelerator (0), Threading (1). Each has checkboxes for 'Decay' and 'Optimize'.
- Network reconfiguration:** Checkboxes for 'Allow manual Network reconfiguration', 'Grow hidden layer 1', 'Grow hidden layer 2', and 'Grow hidden layer 3'.
- Validating:** Cycles before first validating cycle (100), Cycles per validating cycle (100), Select 9 examples at random from the Training examples = 72.
- Slow learning:** Checkboxes for 'Delay learning cycles by' (0) milliseconds.
- Stops:** A 'Target' field (0.00999) and several stop conditions:
  - When the average training error is below Target
  - When all the training errors are below
  - When all predictions are in target range of the outputs
  - When the average validating error is below
  - If the average validating error is increasing
  - Stop when 100 % of the validating examples are  Within 10 % of desired outputs or  Correct after rounding
  - Stop if the % of validating examples decreases
  - Stop if the validating score is equal or above 0
  - Stop if the validating score decreases
  - Stop after 20.0000 seconds
  - Stop on 1700 cycles
- Presentation:** Checkboxes for 'Balanced', 'Random', and 'Grouped'.

Buttons for 'OK' and 'Cancel' are at the bottom right.

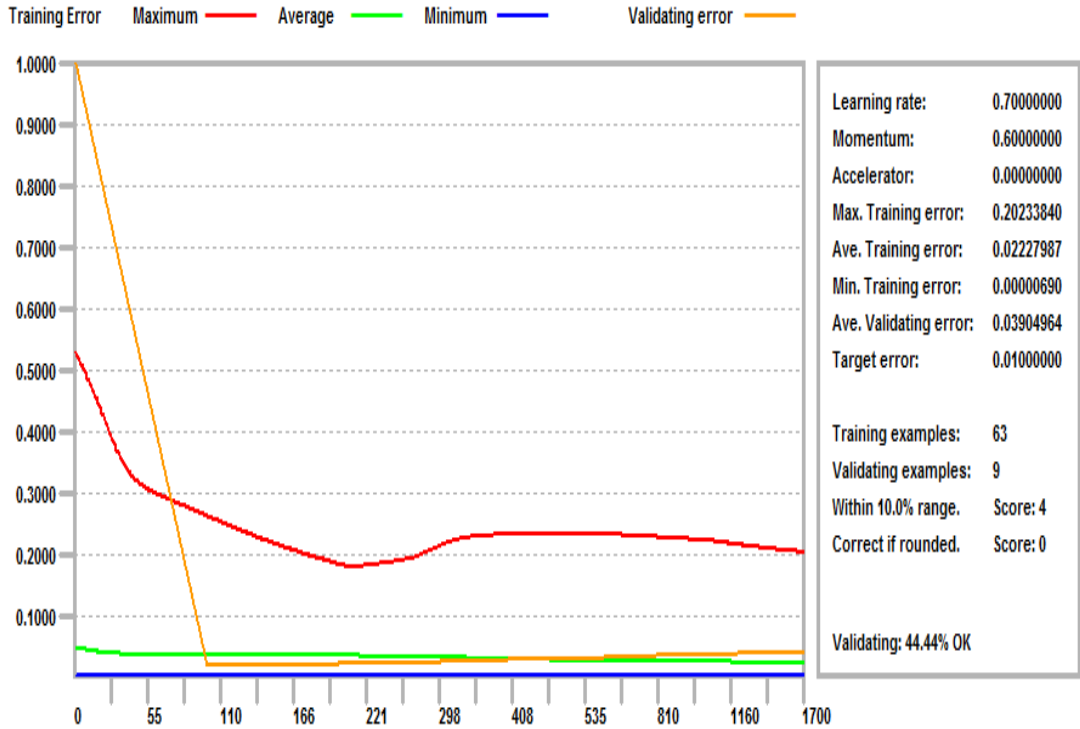
Ağ yapısı Şekil 23'deki gibi oluşmuştur.

Şekil 23: Ağ Yapısı



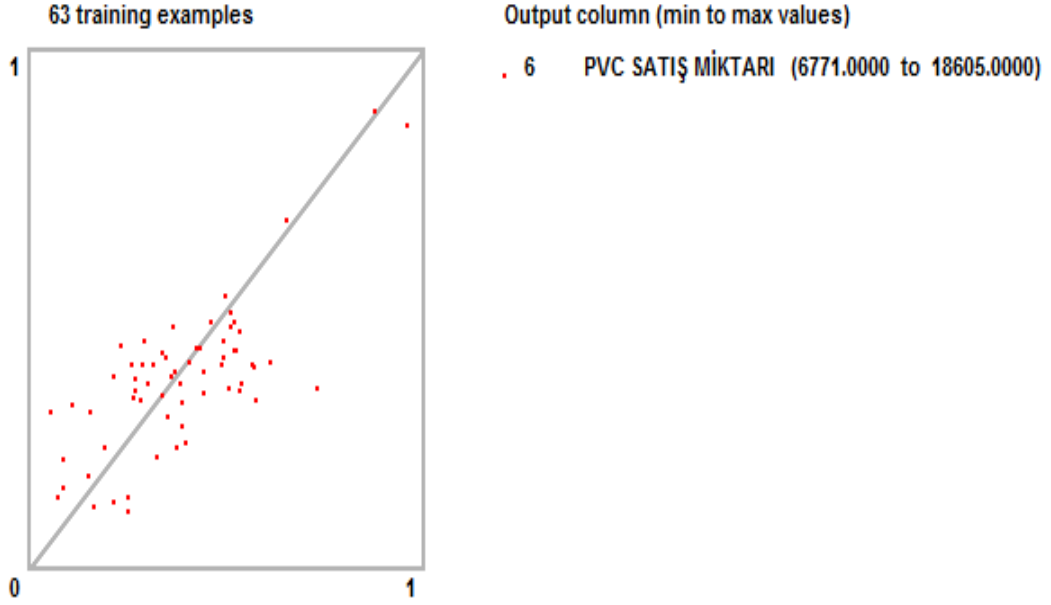
Ağın öğrenme grafiği Şekil 24'de gösterilmiştir. 1700 çevrim yapılmıştır. %44 doğrulama başarısı elde edilmiştir.

Şekil 24: Ağın Öğrenme Grafiği



Ağın tahmin grafiği ise Şekil 25'de gösterilmiştir.

**Şekil 25:** Ağın Tahmin Grafiği



### 3.7. SONUÇLARIN TEST EDİLMESİ

2011 yılına ait satış değerleriyle yapay sinir ağıyla tahmin edilen değerler karşılaştırılmıştır. Modelin öngörü performansının ölçümünde ortalama hata kare kriteri ( OHK ) kullanılmıştır. 2011 yılı PVC satış tahmininde, ortalama hata kare 14233876 olarak gerçekleşmiştir. Tahmin değerleri Tablo 7'de gösterilmektedir.

**Tablo 7:** 2011 Yılı YSA Öngörü Performansının Ölçümü

<b>Aylar</b>	<b>Gerçekleşen ( Ton )</b>	<b>Tahmin ( Ton )</b>	<b>Hata Kare</b>
Ocak	7198	10891	13638611
Şubat	10736	10548	35217
Mart	14975	11609	11329330
Nisan	21833	13867	63453062
Mayıs	12605	15589	8907037
Haziran	20432	18088	5494885
Temmuz	24873	18543	40069761
Ağustos	17966	18416	202276
Eylül	19385	18555	689323
Ekim	18295	13353	24423364
Kasım	12569	13681	1236544
Aralık	11465	12617	1327104
<b>Ortalama Hata Kare</b>			<b>14233876</b>

Duyarlılık Analizi, verinin sonuç üzerindeki etkisinin ne kadar olduğunu bulmasıdır. Verinin çeşitli değerleri girilerek sonucu nasıl etkilediği gözlemlenir. EasyNN programının duyarlılık analizi görünümünde girdilere göre çıktıların ne kadar değiştiği görülmektedir. Girdi değerlerinin tamamı medyan değerlerine ayarlandıktan sonra bir veri en küçük değerden en büyük değere kadar değiştirilerek çıktı üzerindeki değişimi ölçülmektedir.<sup>149</sup>

PVC ürün talebinin girdi değerlerine duyarlılığı Şekil 26 'da gösterilmektedir:

<sup>149</sup> " Easyynn-plus Help The User Interface Manual ", <http://www.easynn.com/108491/EasyNN-plus.pdf>, (12.05.2012), p.50.

**Şekil 26:** Duyarlılık Analizi Sonuçları

Input Name	Change from	to	Sensitivity	Relative Sensitivity
PVC SATIŞ FİYATI	779.0000	1560.0000	0.281599230	
İNŞAAT SEKTÖRÜ ÜRETİM+	78.1000	143.0000	0.279161042	
İMALAT SANAYİ ÜRETİM E+	81.1000	139.7000	0.208585614	
PVC İTHALAT ENDEKSİ	73.4000	202.4000	0.166991703	
GSYİH	47028643.00+	117217855.0+	0.134471285	
NÜFUS MİKTARI	67804667.00+	74724000.00+	0.035925352	

Duyarlılık analizi sonuçlarına baktığımızda duyarlılık derecesi en yüksek değişken olarak PVC satış fiyatı görünmektedir. Talep tahmini öncesinde satış uzmanlarıyla yapılan görüşmelerde fiyatın en önemli değişken olduğu belirtilmişti. Bu durum onları haklı çıkarmaktadır. İç piyasada Petkim'in 2005'te % 33 olan PVC pazar payı 2011 yılında % 15'e düşmüştür. PVC ithalat miktarı yıllar geçtikçe yükselmiş ve ülkemizde gün geçtikçe faaliyet gösteren distribütör sayısı hızla artmıştır. Ülkemizde tek yerli PVC üreticisi olan Petkim'in PVC satış miktarını, fiyat önemli ölçüde etkilemektedir.

Duyarlılık analizi sonuçlarına göre ikinci sırada inşaat sektörü gelmektedir. İnşaat sektörü üretim endeksinin en küçük ve en büyük değerleri ile Petkim PVC satış miktarını karşılaştırdığımızda pozitif bir uyumun olduğunu görmekteyiz. PVC'nin bel kemiği inşaat sektörüdür. Ülkemizde lokomotif sektörlerden biri olan inşaat sektörünün artışıyla birlikte alt sektör olan PVC sektörü de hızla büyümektedir. Bu da PVC satışlarını artırmaktadır.

Duyarlılık analizi sonuçlarına baktığımızda üçüncü sırada İmalat Sanayi endeksi yer almaktadır. İmalat sanayi endeksinin en küçük ve en büyük değerleri ile Petkim PVC satış miktarını karşılaştırdığımızda pozitif bir uyumun olduğunu görmekteyiz. İmalat sanayindeki artışın PVC ürününün tüketildiği çeşitli sektörleri içermesi nedeniyle PVC satışlarını artırdığını söyleyebiliriz.

Dördüncü sırada ise PVC İthalat Endeksi yer almaktadır. İç piyasada Petkim'in 2005'te % 33 olan PVC pazar payı 2011 yılında % 15'e düşmüştür. PVC ithalat miktarı yıllar geçtikçe yükselmiş ve ülkemizde gün geçtikçe faaliyet gösteren



distribütör sayısı hızla artmıştır. PVC ithalatındaki artışın Petkim'in PVC satışlarını azalttığını söyleyebiliriz.

Duyarlılık analizi sonuçlarına baktığımızda üçüncü sırada GSYİH yer almaktadır. Makroekonomik bir gösterege olan bu değişkenin değerleri ile PVC satış miktarının değişimine baktığımızda pozitif bir uyumun olduğunu görmekteyiz. Gelişen ülkelerde plastik sektörü hızla büyümektedir. Türkiye, hem nüfus hem de ekonomi açısından büyüyen ve gelişen bir ülkedir. Ülkemizde termoplastik pazarı, GSYİH'ye paralel olarak gelişme göstermektedir. GSYİH son 10 yılda ortalama %6 civarında gelişme gösterirken, termoplastik pazarı ortalama %11 oranında büyüme göstermiştir.

Duyarlılığın en az olduğu değişken nüfus olarak belirlenmiştir. Ülkemizde nüfus miktarı sürekli bir artış eğilimindedir. Nüfus ve gelir artışına bağlı olarak konut sektörü gelişmektedir. Bu da PVC satışlarını artırmaktadır.

### 3.8. ÇOKLU DOĞRUSAL REGRESYON ANALİZİ İLE KIYASLAMA

Regresyon analizinde yapay sinir ağı modelinde kullanılan veri seti kullanılmıştır. Petkim PVC satış tahminindeki ( Y ) bağımsız değişkenler;

$X_1$ : Nüfus Miktarı ( Kişi ),

$X_2$ : GSYİH ( Bin TL ),

$X_3$ : İmalat Sanayi Endeksi ( 2005 =100 ),

$X_4$ : İnşaat Sektörü Üretim Endeksi ( 2005 =100 ),

$X_5$ : PVC İthalat Endeksi ( 2005 = 100 ),

$X_6$ : Petkim PVC Satış Fiyatı ( Dolar/Ton ) olarak belirlenmiştir.

SPSS 17 programı kullanılarak elde edilen ilk regresyon denklemi aşağıda gösterilmiştir:

$$Y = - 14797 + 0,000311X_1 - 0,000039 X_2 + 34,1X_3 + 71,11X_4 - 7,89X_5 - 3,48X_6 \quad ( 3.1 )$$

Bu regresyon modelinin anlamlı olup olmadığını belirlemek için incelenen ANOVA testi sonuçları Tablo 8'de gösterilmiştir. Ortaya çıkan F değerine karşılık gelen p anlamlılık seviyesinin  $p=0,003 < 0,05$  olması nedeniyle, söz konusu regresyon modelinin açıklayıcılığının istatistiksel açıdan önemli olduğunu ifade edebiliriz.

**Tablo 8:** Regresyon Analizi Anova Testi Sonucu - 1

Model	Sum of Squares	df	Mean Square	F	Sig.
1 Regression	9,703E7	6	1,617E7	3,717	,003
Residual	2,828E8	65	4351029,585		
Total	3,798E8	71			

Regresyon analizine ilişkin Tablo 9'da verilen sonuçlara göre belirlilik katsayısı 0,49'dir. Buna göre, ürün talebindeki değişmelerin %49 'luk bölümünün bağımsız değişkenlerle açıklanabildiği sonucuna ulaşılmaktadır.

**Tablo 9:** Regresyon Model Özeti - 1

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,705	,497	,453	2360,885

Tablo 10'da ise regresyon analizine ilişkin katsayıların anlamlılık düzeyleri gösterilmektedir.

**Tablo 10:** Regresyon Analizi Katsayı Anlamlılık Testi Sonuçları

Model	Unstandardized Coefficients		Standardized Coefficients
	B	Std. Error	Beta
1 (Constant)	-14797,130	45802,898	
NÜFUS	,000	,001	,237
GSYİH	-3,907E-5	,000	-,235
İMALAT	34,099	32,074	,019
İNŞAAT	71,011	29,189	,023
İTHALAT	-7,895	14,585	-,008
FİYAT	-3,479	2,270	-,021

Yukarıdaki tabloya göre %5 anlamlılık düzeyinde Nüfus ve GSYİH değişkenlerinin modele anlamlı katkılarının olmadıkları görülmektedir. Bu nedenle, daha duyarlı bir regresyon denklemi elde edebilmek amacıyla, Nüfus ve GSYİH değişkenleri elimine edilerek yeniden regresyon analizi gerçekleştirilmiştir. Yeni modele ilişkin regresyon denklemi aşağıda görülmektedir:

$$Y = 5606 + 36,06 X_3 + 61,42 X_4 - 6,53 X_5 - 3,97 X_6 \quad (3.2)$$

Bu regresyon modelinin anlamlı olup olmadığını anlamak için incelenen ANOVA testi sonuçları Tablo 11' de yer almaktadır.

**Tablo 11:** Regresyon Analizi Anova Testi Sonucu - 2

Model	Sum of Squares	df	Mean Square	F	Sig.
1 Regression	9,609E7	4	2,402E7	5,672	,001
Residual	2,838E8	67	4235221,241		
Total	3,798E8	71			

Bu testin sonucunda ortaya çıkan F değerine karşılık gelen p anlamlılık seviyesinin 0,05'ten çok küçük olması nedeniyle, söz konusu regresyon modelinin istatistiksel açıdan anlamlı olduğunu ifade edebiliriz.

Regresyon analizine ilişkin Tablo 12' de verilen sonuçlara göre belirlilik katsayısı 0,50'dir. Buna göre, ürün talebindeki değişmelerin %50'lik bölümünün bağımsız değişkenlerle açıklanabildiği sonucuna ulaşılmaktadır.

**Tablo 12:** Regresyon Model Özeti - 2

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,709	,502	,458	2317,915

Regresyon analizi ve yapay sinir ağları ile oluşturulan modellerin 2011 yılına ilişkin tahmin başarısını belirlemek amacıyla literatürde yaygın olarak kullanılan üç istatistiğe başvurulmuştur. Bunlar; Ortalama Mutlak Hata ( OMH ), Ortalama Hata Kareleri Kökü ( OHKK ) ve Ortalama Mutlak Yüzde Hata ( OMYH )'dir. Tablo 13 ve Tablo 14'de modellerin 2011 yılına ait tahmin sonuçları ve performans ölçütlerine ilişkin değerler gösterilmektedir. OMH ve OHKK ölçütlerinde yapay sinir ağlarının

daha üstün olduğu görülmektedir. OMYH kriterinde ise az farkla da olsa ÇDRA modelinin daha başarılı olduğunu görmekteyiz.

**Tablo 13:** 2011 Yılına İlişkin Modellerin Tahmin Sonuçları

Aylar	Gerçekleşen ( Ton )	Çoklu Doğrusal Regresyon Analizi	Yapay Sinir Ağları
Ocak	7198	10321	10891
Şubat	10736	10146	10548
Mart	14975	10233	11609
Nisan	21833	13291	13867
Mayıs	12605	13520	15589
Haziran	20432	14056	18088
Temmuz	24873	15581	18543
Ağustos	17966	15947	18416
Eylül	19385	14618	18555
Ekim	18295	13042	13353
Kasım	12569	12561	13681
Aralık	11465	13031	12617

**Tablo 14:** Modellerin Doğruluk Ölçüleri

Model	OMH	OHKK	OMYH
Çoklu Doğrusal Regresyon Analizi	3933	4917	<b>0,22</b>
Yapay Sinir Ağları	<b>2946</b>	<b>3772</b>	0,23

## SONUÇ

Bu çalışmada öngörüleme alanında son yıllarda giderek kullanımı artan yapay sinir ağları tekniğine yer verilmiştir. Geleneksel talep tahmin yöntemlerine alternatif olarak kullanılan yapay sinir ağları tekniğinin etkin sonuçlar ürettiği gösterilmiştir. Türkiye'nin en büyük ve tek yerli petrokimyasal üreticisi Petkim'de termoplastik ürünlerden PVC ürününe ilişkin talep tahmini yapılmaya çalışılmıştır.

2005 – 2011 yılları arası aylık veriler talep tahmini amacıyla kullanılmıştır. Petkim Satış ve Pazarlama Müdürü ve Satış Uzmanları ile görüşmeler yapılarak PVC ürün talebini etkileyen başlıca faktörler belirlenmiştir. Modele dahil edilecek değişkenlerin belirlenmesi konusunda açıklayıcılık gücü ve veri kısıtı dikkate alınmıştır. Daha sonra modele dahil edilen değişkenlere ilişkin zamansal farklılıkları gidermek için varsayımlar yapılarak aylık dönüşümler gerçekleştirilmiştir.

Yapay sinir ağlarıyla hazırlanan modelde en uygun ağ yapısını belirlemek için parametre analizi yapılmış ve optimum ağ mimarisi elde edilmiştir. 2005 – 2010 yılları arasındaki veriler ağın eğitilmesi ve doğrulanması için ayrılmış, 2011 yılı verileri ise test amaçlı kullanılmıştır. Tahmin başarısını göstermek amacıyla belirlenen ortalama hata karesi değeri 14233876 olarak gerçekleşmiştir.

Ayrıca, klasik yöntemlerden çoklu doğrusal regresyon analizi ile de talep tahmini yapılmıştır. Yapay sinir ağlarının tahmin başarısını belirlemek amacıyla regresyon analizi ile kıyaslama yapılmıştır. Belirlenen performans kriterlerinden OMH ve OHKK 'de yapay sinir ağlarının; OMYH kriterinde ise ÇDRA modelinin daha başarılı sonuçlar verdiği görülmüştür.

Regresyon analizinde çoklu doğrusal bağlantı probleminin ve otokorelasyonun olmadığı kabul edilmiştir. Regresyon varsayımlarıyla ilgili bir test yapılmamıştır. Yapay sinir ağları modelinde ise herhangi bir varsayıma ihtiyaç duyulmadan veriler arasındaki ilişkileri ve ağırlıkları ağın kendisi öğrenmiştir.

Bu çalışmada termoplastik ürünlerden sadece PVC ürünü üzerine talep tahmini yapılmıştır. Modele dahil edilecek değişkenlerin belirlenmesi konusunda açıklayıcılık gücü ve veri kısıtı dikkate alınmıştır. Ayrıca, istatistiksel veri eksikliği nedeniyle 2005 – 2011 yılları arasındaki veriler tahmin amacıyla kullanılmıştır. Örnek sayısının az olması ve değişkenlere ilişkin zamansal farklılıklar nedeniyle çeşitli varsayımlarla verilere ilişkin dönüşümler gerçekleştirilmiştir. Bu dönüşümler modellerin gerçeğe uygunluğunu azaltmakta ve tahmin performanslarının düşmesine yol açmaktadır. Bu çalışmanın geliştirilmesi amacıyla modele dahil

edilecek deęişken sayısı artırılıp veriler daha geniş zaman aralığını kapsayacak şekilde düzenlenebilir. Yapay sinir ağlarının performansını örnek sayısı doğrudan etkilediğinden örnek sayısının artışıyla daha başarılı tahminler gerçekleştirilebilir. Aynı şekilde, regresyon modelinin %50 olan bağımlı deęişkeni açıklama gücünde de örnek sayısı artırılıp deęişken ilave edilerek iyileştirmeler sağlanabilir.

Tahmin modelleri oluşturulurken mevsimsel etkilerin giderilmesi ile ilgili bir analiz yapılmamıştır. İleriki çalışmalarda, veriler mevsimsel etkilerden arındırılarak yapay sinir ağları ve regresyon analizi modelleri ile tahmin yapılabilir. Böylece, mevsimsel etkilerin giderilmesi sonucu oluşturulan tahmin modellerinin başarısı mevsimsel etkiler giderilmeden oluşturulan tahmin modelleriyle kıyaslanabilir.

Bu çalışmada PVC ürünü için toplam talep tahmin edilmeye çalışılmıştır. İleriki çalışmalarda PVC ürün türleri için ayrı ayrı talep tahmin çalışması yapılabilir. Bunların dışında, şirketin termoplastik satışlarında önemli paya sahip olan PE ve PP ürünleri de çalışma kapsamına dahil edilebilir.

## KAYNAKÇA

Abraham, Bovas ve Johannes Ledolter, **Statistical Methods for Forecasting**, John Wile&Sons Inc., 2005.

Ahangar, Reza G., Mahmood Yahyazadehfar ve Hassan Pournaghshband. " The Comparison Of Methods Artificial Neural Network With Linear Regression Using Specific Variables For Prediction Stock Price In Tehran Stock Exchange", **International Journal Of Computer Science And Information Security**, Vol.7, No.2, 2010, pp. 38-46.

Anderson, David R., Dennis J. Sweeney ve Thomas A. Williams. **An Introduction to Management Science: Quantative Approaches to Decision Making**, 8th Edition, South-Western, 2000.

Archer, Brian H. "Forecasting Demand: Quantative and Intuitive Techniques", **International Journal of Tourism Management**, Vol.1, No.1,1980, p.177.

Armstrong, J. Scott. **Principles of Forecasting: A Handbook for Researchers and Practitioners**, Kluwer Academic Publishers, 2001.

Asilkan, Özcan ve Sezgin Irmak. " İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi", **S.D.Ü İktisadi ve İdari Bilimler Fakültesi Dergisi**, Cilt: 14, Sayı:2, 2009, s. 380.

Asilkan, Özcan " İkinci El Otomobillerin Güncel Pazar Fiyatlarının Veri Madenciliği Yöntemleriyle Modellenmesi ", **Akademik Bakış Dergisi**, Sayı:24, 2011, ss.1-19.

Bircan, Hüdaverdi ve Yalçın Karagöz ." Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama", **Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi**, Cilt:6, Sayı:2, 2003, s.50.

Blocher, James D., Vincent A.Mabert, Ashok K.Soni ve Munirpallam A.Venkataramanan, **Forecasting: Including An Introduction To Forecasting Using The SAP R/3 System**, Indiana University Kelly School of Business, Indiana, 2004.

Chang, I. ve H. Hwang. "Applying Neural Networks In Time Series Forecasting", **Information and Management Sciences**, Vol.9, No.3, 1998, pp. 35-43.

Chatfield,Chris. **Time Series Forecasting**, Chapman & Hall / CRC, London, 2000.

Crum, Colleen ve George E.Palmatier. **Demand Management Best Practices**, J.Ross Publishing, USA, 2003.

Dođan, Muammer. **İşletme Ekonomisi ve Yönetimi**, Nobel Yayınları, İzmir, 2007.

Elmas, Çetin. **Yapay Zeka Uygulamaları/ Yapay Sinir Ağları-Bulanık Mantık-Genetik Algoritma**, 1.Baskı, Seçkin Yayıncılık, Ankara, 2007.

Eski, Hasan. **Ekonomiye Giriş**, 4. Baskı, DEÜ Mühendislik Yayınları, İzmir, 2005.

Fausett, Laurene. **Fundamentals of Neural Networks: Architectures, Algorithms and Applications**, Prentice Hall, New Jersey,1994.

Fırat, Mahmut ve Mahmut Güngör. "Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ađı ile Belirlenmesi", **İMO Teknik Dergi**,Cilt:21, Sayı:9, 2005, s.61.

Fretchling, Douglas C. **Forecasting Tourism Demand: Method and Strategies**, Butterworth - Heinemann, 2001.

Gavcar, Erdoğan. **İstatistik Yöntemler-1**, 3. Baskı, Gazi Kitabevi, Ankara, 2005.

Goyal, Sumit ve Gyanendra Kumar Goyal. " Predicting Shelf Life Of Dairy Product By Using Artificial Neural Networks And Statistical Computerized Methods", **International Journal Of Computer Engineering Research**, Vol.3, No.2, 2012, pp.20-24.

Güngör, İbrahim ve Murat Çuhadar. " Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemiyle Tahmini", **Ticaret ve Turizm Eğitim Fakültesi Dergisi**, Sayı:1, 2005, ss.84-98.

Gürsakal, Necmi. **Bilgisayar Uygulamalı İstatistik 2**, Alfa Yayınları, İstanbul, 2002.



Hamzaçebi, Coşkun ve Fevzi Kutay. “ Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini”, **Gazi Üniv. Müh. Mim. Fak. Dergisi**, Cilt:19, No:3, 2004, ss.227-233.

Haykin, Simon. **Neural Networks: A Comprehensive Foundation**, Second Edition, Prentice Hall, New Jersey, 1999.

Heize, Jay ve Barry Render. **Operations Management**, Seventh Edition, Pearson International Edition, 2004.

Kandananond, Karin. “ Forecasting Electricity Demand In Thailand With An Artificial Neural Network Approach”, **Powereng 2nd International Conference**, 2009, pp.1246-1257.

Kaya, Hüseyin, Abdülmecit Karataş ve İ.Hakkı Eraslan. “ Türk Plastik Sektörünün Rekabetçilik Analizi ”, **İ.T.Ü Sosyal Bilimler Enstitüsü Dergisi**, Cilt:6, Sayı:11, 2007, s.204.

Kaynak, Okyay ve M.Önder Efe. **Yapay Sinir Ağları ve Uygulamaları**, Boğaziçi Üniversitesi Yayınevi, İstanbul, 2000.

Kaynar, Oğuz, Serkan Taştan ve Ferhan Demirkoparan. “ Ham Petrol Fiyatlarının Yapay Sinir Ağları İle Tahmini”, **Ege Akademik Bakış Dergisi**, Cilt:10, Sayı:2, 2010, ss.559-573.

Kobu, Bülent. **Üretim Yönetimi**, 14. Baskı, Beta Basım, 2008, İstanbul.

Koç, M.Levent, Can E. Balas ve Abdussamet Arslan. “ Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı”, **İnşaat Mühendisleri Odası Yayını Teknik Dergi**, Cilt:15, Sayı:4, 2004, s.3354.

Kutlu, Birgül ve Bertan Badur. ” Yapay Sinir Ağları ile Borsa Endeksi Tahmini”, **İstanbul Üniversitesi İşletme İktisadi Yönetim Dergisi**, Yıl:20, Sayı:63, Haziran 2009,s.31.

Kuo, Chin ve Arthur Reitsch, “ Neural Networks vs. Conventional Methods Of Forecasting”, **The Journal of Business Forecasting**, Vol.14, 1996, pp.17-19.

Law, Robb ve Norman Au. “ A Neural Network To Forecast Japanese Demand For Travel To Hong Kong”, **Tourism Management**, Vol.20, No.1, 1999, ss. 89-97.

Montgomery, Douglas C., Cheryl L.Jennings ve Murat Kulahci. **Introduction to Time Series Analysis and Forecasting**, John Wile&Sons Inc., 2008.

Mucuk , İsmet. **Pazarlama İlkeleri**, 17. Baskı, Türkmen Kitabevi, 2009.

Orhunbilge, Neyran. **Uygulamalı Regresyon ve Korelasyon Analizi**, Avcıol Basım Yayın, İstanbul, 2002.

Öztemel,Ercan. **Yapay Sinir Ağları**, 2. Baskı, Papatya Yayıncılık, İstanbul, 2006.

Sadowski, Robert J. , Ilan Alon ve Min Qi. “Forecasting Aggregate Retail Sales: A Comparison of Artificial Neural Networks and Traditional Methods”, **The Journal of Retailing and Consumer Services**, Vol.8, 2001, p.150.

Sağiroğlu, Şeref, Erkan Beşdok ve Mehmet Eler. **Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları**, Ufuk Kitap Kırtasiye Yayıncılık, Kayseri, 2003.

Saraç, Tuğba. **Yapay Sinir Ağları**, Seminer Projesi, Gazi Üniversitesi Endüstri Mühendisliği Bölümü Anabilim Dalı, Ankara, 2004.

Sazlı, Murat ve Haluk Tanrıku. “Saldırı Tespit Sistemlerinde Yapay Sinir Ağlarının Kullanılması”, **XII. “Türkiye’de İnternet Konferansı”** , Ankara,2007, s.220.

Shim , Jae K. **Strategic Business Forecasting**, Washington D.C., St. Lucie Press, 1999.

Soysal, Mehmet ve Mine Ömürgönülşen, “Türk Turizm Sektöründe Talep Tahmini Üzerine Bir Uygulama”, **Anatolia: Turizm Araştırmaları Dergisi**, Cilt:21, Sayı:1, 2010,s.130.

Şahin, Ali E. “ Eğitim Araştırmalarında Delphi Tekniği ve Kullanımı ”, **Hacettepe Üniversitesi Eğitim Fakültesi Dergisi**, Cilt:21, Sayı:20, 2001, s.219.

Taşkın, Çağatan ve Gül Gökay Emel. **Sayısal Yöntemlerde Genetik Algoritmalar**, Alfa Aktüel Yayınları, Bursa, 2009.

Yoon, Y., G. Swales ve T.M. Margavio. “A Comparison of Discriminant Analysis Versus Artificial Neural Networks”, **Journal of Operational Research**, Vol.44, No1., 1993, p. 55.

Yurtoğlu, Hasan. **Yapay Sinir Ağları ile Öngörü Modellemesi**, Uzmanlık Tezi, Devlet Planlama Teşkilatı, 2005.

Zhang, Guoqiang, B. Eddy Patuwo ve Michael Y. Hu. “Forecasting with Artificial Neural Networks: The State of The Art”, **International Journal of Forecasting**, Vol.5, No.1,1998, p.36.

Zwikael ,Ofer , T.Raz ve Shlomo Globerson. “ Evaluation of Models for Forecasting Sales “, **Project Management Journal**, Vol.31, No.1, 2000, p.27.

### **İnternet Kaynakları**

Akal, Mustafa. “ Optimum Öngörü Tekniğinin Seçimi “,  
<http://www.sakarya.edu.tr/~hgurak/yazilar/makale/ONGOM.doc>, (31.12.2011).

Aktan, Coşkun C. “ Geleceği Kazanmanın Yolu: Stratejik Yönetim ”,  
<http://www.tkgm.gov.tr/turkce/dosyalar/diger%5Cicerikdetaydh278.pdf>, (28.10.2011).

Bozer, Neslihan. “ Yapay Sinir Ağlarında Sınıflandırma ”,  
[http://yzgrafik.ege.edu.tr/~aybars/ysa/02\\_1\\_YSA\\_SINIFLANDIRMA/YSA\\_Seminer.ppt](http://yzgrafik.ege.edu.tr/~aybars/ysa/02_1_YSA_SINIFLANDIRMA/YSA_Seminer.ppt), (16.01.2012).

“ Bulanık Mantık “ ,  
<http://www.yapay-zeka.org/modules/wiwimod/index.php?page=Fuzzy+Logic>,  
(15.01.2012).

Dereli, Türkyay. “ Toplam Kalite Yönetiminin Işığında Yapay Zekanın Endüstriyel Problemlerin Çözümünde Kullanılması”,  
<http://www1.gantep.edu.tr/~dereli/turkce/ky.ppt#256,1>, (15.01.2012).

Devlet Planlama Teşkilatı, “ Petrokimya Sanayi Özel İhtisas Komisyonu Raporu”,  
<http://www.dpt.gov.tr/DocObjects/Download/3294/oik579.pdf>, (02.04.2012).

“ Easynn-plus Help The User Interface Manual “,  
<http://www.easynn.com/108491/EasyNN-plus.pdf>, (12.05.2012).

Hajek, Miloslav. “ Neural Networks “,  
<http://www.cs.unp.ac.za/notes/NeuralNetworks2005.pdf>, (21.02.2012).

Sevilmiş, Gözde. “Ege Bölgesi Plastik Sektörü Raporu” , **İzmir Ticaret Odası Ar-Ge Bülteni**,  
[http://www.izto.org.tr/NR/rdonlyres/7475BDA1-95B7-4855-B351-9ADCE4362AFE/19885/EgeBölgesiPlastikSektörüRaporu\\_GözdeSevilmiş.pdf](http://www.izto.org.tr/NR/rdonlyres/7475BDA1-95B7-4855-B351-9ADCE4362AFE/19885/EgeBölgesiPlastikSektörüRaporu_GözdeSevilmiş.pdf),  
(01.04.2012).

“ PVC İthalatına Yönelik Yapılan Korunma Önlemi Başvurusunun Özeti”,  
[http://www.ekonomi.gov.tr/upload/EF8317F5-D8D3-8566-452028FED6D52922/PVC\\_ozet\\_tr.pdf](http://www.ekonomi.gov.tr/upload/EF8317F5-D8D3-8566-452028FED6D52922/PVC_ozet_tr.pdf), (01.04.2012).

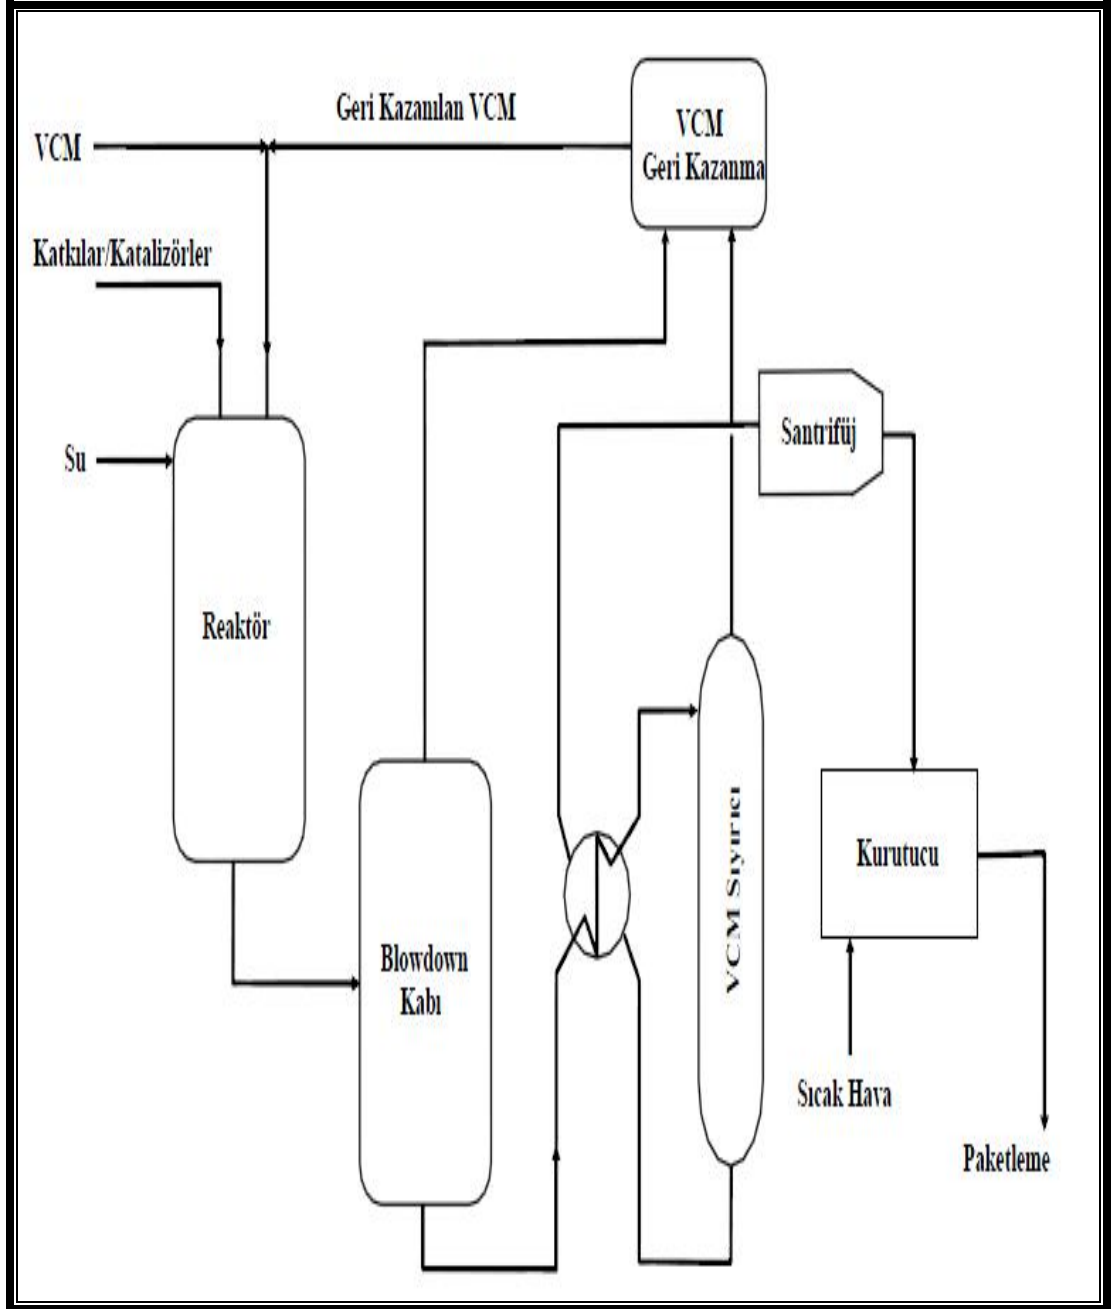
Tatlı, Emin İslam. “ Uzman Sistemler “,  
<http://th.informatik.uni-mannheim.de/people/tatli/resources/pdf/expertsystems.pdf>,  
(15.01.2012).

“ Türkiye’de Petrokimya Sanayi ve Petkim “,  
<http://www.petkim.com.tr/Sayfa/1/46/URETIM-TURKIYE-PETROKIMYA-SANAYI-VE-PETKIM.aspx>, (01.04.2012).

“ Yapay Zeka “,  
<http://www.yapay-zeka.org/modules/wiwimod/index.php?page=AI&back=WiviHome>,  
(15.01.2012).

**EKLER**

**EK 1:** Süspansiyon Polimerizasyonu ile PVC Üretim Süreci



## EK 2: PVC Ürün Türleri Karakteristik Özellikleri

<b>TİCARİ İSMİ</b>	: PETVİNİL S 23/59		
<b>ÜRÜN GARANTİ DEĞERLERİ</b>	:		
<b>DENEY ADI</b>	<b>BİRİMİ</b>	<b>DEĞERİ</b>	<b>METODU</b>
Viskozite Sayısı (Sikloheksanon 25°C)	cm <sup>3</sup> /g	76 - 86	TS EN ISO 1628-2
K sayısı (Sikloheksanon 25°C)	-	56 - 59	TS EN ISO 1628-2
Yığın Yoğunluğu	g/cm <sup>3</sup>	0.56 - 0.62	TS 448 EN ISO 60
Tane Boyut Dağılımı: > 0.250 mm	% wt	Max. 3	ISO 13320
> 0.063 mm	% wt	Min. 90	ISO 13320
Uçucu Madde	% wt	Max. 0.5	TS EN ISO 1269
Kirlilik	adet/9 dm <sup>2</sup>	Max. 60	TS EN ISO 1265
<b>ÜRÜN ŞEKLİ</b>	: Beyaz toz		
<b>AMBALAJ ŞEKLİ</b>	: 25 kg'lık FFS (Form Fill Seal) beyaz renkli PE torbalarda veya 1400 kg'lık big-bag'lerde		
<b>DEPOLAMA ŞARTLARI</b>	: Kapalı ve rutubetsiz ortamlarda depolanmalıdır.		
<b>KULLANIM SAHALARI</b>	: Opak veya şeffaf sert film ve şişe, sert parçalar, opak veya şeffaf sert levhalar ve profiller, boru bağlantı parçaları.		

<b>TİCARİ İSMİ</b>	: PETVİNİL S 27/R 63		
<b>ÜRÜN GARANTİ DEĞERLERİ</b>	:		
<b>DENEY ADI</b>	<b>BİRİMİ</b>	<b>DEĞERİ</b>	<b>METODU</b>
Viskozite Sayısı (Sikloheksanon 25°C)	cm <sup>3</sup> /g	100.0 -112.0	TS EN ISO 1628-2
K sayısı (Sikloheksanon 25°C)	-	63 - 67	TS EN ISO 1628-2
Yığın Yoğunluğu	g/cm <sup>3</sup>	0.54 - 0.62	TS 448 EN ISO 60
Tane Boyut Dağılımı: > 0.250 mm	% wt	Max. 8	ISO 13320
> 0.063 mm	% wt	Min. 90	ISO 13320
Uçucu Madde	% wt	Max. 0.5	TS EN ISO 1269
Kirlilik	adet/9 dm <sup>2</sup>	Max. 60	TS EN ISO 1265
<b>ÜRÜN ŞEKLİ</b>	: Beyaz toz		
<b>AMBALAJ ŞEKLİ</b>	: 25 kg'lık FFS (Form Fill Seal) beyaz renkli PE torbalarda veya 1400 kg'lık big-bag'lerde.		
<b>DEPOLAMA ŞARTLARI</b>	: Kapalı ve rutubetsiz ortamlarda depolanmalıdır.		
<b>KULLANIM SAHALARI</b>	: Soğuk su boruları, pis su boruları, elektrik kablo boruları, sert (rigit) profil.		

<b>TİCARİ İSMİ</b>	: PETVİNİL S 39/71		
<b>ÜRÜN GARANTİ DEĞERLERİ</b>	:		
<b>DENEY ADI</b>	<b>BİRİMİ</b>	<b>DEĞERİ</b>	<b>METODU</b>
Viskozite Sayısı (Sikloheksanon 25°C)	cm <sup>3</sup> /g	121 - 134	TS EN ISO 1628-2
K sayısı (Sikloheksanon 25°C)	-	69 - 72	TS EN ISO 1628-2
Yığın Yoğunluğu	g/cm <sup>3</sup>	0.44 - 0.53	TS 448 EN ISO 60
Tane Boyut Dağılımı: > 0.250 mm	% wt	Max. 3	ISO 13320
> 0.063 mm	% wt	Min. 90	ISO 13320
Uçucu Madde	% wt	Max. 0.5	TS EN ISO 1269
Kirlilik	adet/9 dm <sup>2</sup>	Max. 60	TS EN ISO 1265
<b>ÜRÜN ŞEKLİ</b>	: Beyaz toz		
<b>AMBALAJ ŞEKLİ</b>	: 25 kg'lık FFS (Form Fill Seal) beyaz renkli PE torbalarda veya 1300 kg.lık big-bag'lerde.		
<b>DEPOLAMA ŞARTLARI</b>	: Kapalı ve rutubetsiz ortamlarda depolanmalıdır.		
<b>KULLANIM SAHALARI</b>	: Kablo kılıflama, ayakkabı tabanı, esnek ve yarı sert profil ve boru, yumuşak film, esnek levha, oyuncak.		

<b>TİCARİ İSMİ</b>	: PETVİNİL S 65/R 68		
<b>ÜRÜN GARANTİ DEĞERLERİ</b>	:		
<b>DENEY ADI</b>	<b>BİRİMİ</b>	<b>DEĞERİ</b>	<b>METODU</b>
Viskozite Sayısı (Sikloheksanon 25°C)	cm <sup>3</sup> /g	109.0 - 122.0	TS EN ISO 1628-2
K sayısı (Sikloheksanon 25°C)	-	66 - 70	TS EN ISO 1628-2
Yığın Yoğunluğu	g/cm <sup>3</sup>	0.52 - 0.60	TS 448 EN ISO 60
Tane Boyut Dağılımı: > 0.250 mm	% wt	Max. 8	ISO 13320
> 0.063 mm	% wt	Min. 90	ISO 13320
Uçucu Madde	% wt	Max. 0.5	TS EN ISO 1269
Kirlilik	adet/9 dm <sup>2</sup>	Max. 60	TS EN ISO 1265
<b>ÜRÜN ŞEKLİ</b>	: Beyaz toz		
<b>AMBALAJ ŞEKLİ</b>	: 25 kg'lık FFS (Form Fill Seal) beyaz renkli PE torbalarda veya 1400 kg.lık big-bag'lerde.		
<b>DEPOLAMA ŞARTLARI</b>	: Kapalı ve rutubetsiz ortamlarda depolanmalıdır.		
<b>KULLANIM SAHALARI</b>	: Basınçlı boru.		



EK 3: Yapay Sinir Ağı Modeli Veri Seti

YIL	AY	NÜFUS ( Kişi )	GSYİH ( BİN TL )	İMALAT SANAYİ (2005=100)	İNŞAAT SEKTÖRÜ (2005=100)	PVC İTHALAT ENDEKSİ (2005=100)	PVC SATIŞ MİKTARI ( TON )
2005	1	67804667	47028643	81,8	78,1	73,4	8880
	2	67875333	47028643	84,9	78,1	91,0	10316
	3	67946000	47028643	98,8	78,1	95,5	11143
	4	68016667	51254585	95,5	105,5	101,3	8911
	5	68087333	51254585	99,7	105,5	95,9	10644
	6	68158000	51254585	103,2	105,5	102,7	12983
	7	68228667	60524116	98,7	114,6	96,7	11869
	8	68299333	60524116	98,1	114,6	110,3	14099
	9	68370000	60524116	110,3	114,6	127,0	12932
	10	68440667	57503226	112,8	101,9	116,8	13496
	11	68511333	57503226	102,5	101,9	96,9	9164
	12	68582000	57503226	113,9	101,9	92,3	10018
2006	1	68651917	53357524	82,2	90,3	82,7	8597
	2	68721833	53357524	93	90,3	106,3	9610
	3	68791750	53357524	111,2	90,3	132,4	9159
	4	68861667	61217374	105,8	126,6	109,6	10843
	5	68931583	61217374	112,9	126,6	114,0	12691
	6	69001500	61217374	114	126,6	127,3	13124
	7	69071417	71098465	108,1	136,4	133,7	14617
	8	69141333	71098465	103,6	136,4	98,1	13498
	9	69211250	71098465	114,5	136,4	143,6	12113
	10	69281167	67123565	107,5	120,2	100,1	6771
	11	69351083	67123565	117,5	120,2	111,2	9492
	12	69421000	67123565	115,6	120,2	89,5	11872
2007	1	69490583	62650231	99,2	101,8	109,2	13112
	2	69560167	62650231	101,6	101,8	132,3	11393
	3	69629750	62650231	118,2	101,8	139,2	11766
	4	69699333	67759902	111,3	135,3	141,5	12763
	5	69768917	67759902	120,8	135,3	130,0	13065
	6	69838500	67759902	118,8	135,3	125,7	12530
	7	69908083	77418855	113,7	142,5	108,7	12750
	8	69977667	77418855	111,6	142,5	128,1	12870
	9	70047250	77418855	118,2	142,5	154,4	11640
	10	70116833	73230485	118,4	120,1	152,8	10223
	11	70186417	73230485	127,6	120,1	133,5	12515
	12	70256000	73230485	113	120,1	111,6	9522

<b>2008</b>	<b>1</b>	70361083	71868551	109,9	100	161,8	10784
	<b>2</b>	70466167	71868551	110,1	100	131,4	9616
	<b>3</b>	70571250	71868551	121,7	100	112,9	10490
	<b>4</b>	70676333	79787811	120	128,5	119,4	12038
	<b>5</b>	70781417	79787811	123,7	128,5	121,2	12721
	<b>6</b>	70886500	79787811	120,6	128,5	133,0	13093
	<b>7</b>	70991583	87464057	118,3	128,6	159,2	11166
	<b>8</b>	71096667	87464057	106,2	128,6	151,1	9354
	<b>9</b>	71201750	87464057	112,5	128,6	129,0	8092
	<b>10</b>	71306833	77724331	109,2	105,1	89,2	7547
	<b>11</b>	71411917	77724331	109,2	105,1	81,6	9850
	<b>12</b>	71517000	77724331	90,8	105,1	78,2	9798
<b>2009</b>	<b>1</b>	71604000	69308664	82,7	81,2	128,2	8047
	<b>2</b>	71691000	69308664	81,1	81,2	111,9	7190
	<b>3</b>	71778000	69308664	92,1	81,2	85,3	10683
	<b>4</b>	71865000	76190633	94,7	101,5	79,7	13633
	<b>5</b>	71952000	76190633	100,5	101,5	85,9	15657
	<b>6</b>	72039000	76190633	107,3	101,5	111,1	13525
	<b>7</b>	72126000	87236816	106,1	106,1	128,8	11254
	<b>8</b>	72213000	87236816	98,2	106,1	139,5	8221
	<b>9</b>	72300000	87236816	100,4	106,1	129,3	7045
	<b>10</b>	72387000	84783414	115,9	97,7	144,8	8144
	<b>11</b>	72474000	84783414	105,1	97,7	105,2	7219
	<b>12</b>	72561000	84783414	114,7	97,7	130,3	11110

<b>2010</b>	<b>1</b>	72657833	80626879	95,3	89,3	150,2	9348
	<b>2</b>	72754667	80626879	97,3	89,3	140,2	13629
	<b>3</b>	72851500	80626879	114,5	89,3	146,5	10886
	<b>4</b>	72948333	89048021	112,3	122,5	131,9	10944
	<b>5</b>	73045167	89048021	116,5	122,5	117,5	10613
	<b>6</b>	73142000	89048021	118,6	122,5	123,4	9895
	<b>7</b>	73238833	99061317	115,9	130,2	117,5	18605
	<b>8</b>	73335667	99061317	108,9	130,2	75,4	17536
	<b>9</b>	73432500	99061317	111,3	130,2	131,8	12613
	<b>10</b>	73529333	99180383	129,1	116,4	154,9	12466
	<b>11</b>	73626167	99180383	115,7	116,4	126,9	11005
	<b>12</b>	73723000	99180383	135,9	116,4	177,7	10523
<b>2011</b>	<b>1</b>	73806417	95997047	115	103,6	164,4	7198
	<b>2</b>	73889833	95997047	111,6	103,6	166,5	10736
	<b>3</b>	73973250	95997047	126,7	103,6	202,4	14975
	<b>4</b>	74056667	105164434	122,7	139	165,2	21833
	<b>5</b>	74140083	105164434	126,9	139	129,9	12605
	<b>6</b>	74223500	105164434	127,9	139	113,4	20432
	<b>7</b>	74306917	117217855	124,3	143	113,3	24873
	<b>8</b>	74390333	117217855	114,4	143	142,4	17966
	<b>9</b>	74473750	117217855	125,6	143	142,3	19385
	<b>10</b>	74557167	113251628	138,5	124,7	133,1	18295
	<b>11</b>	74640583	113251628	124,7	124,7	143,1	12569
	<b>12</b>	74724000	113251628	139,7	124,7	164,4	11465