

**İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ**

**TALEP TAHMİNİNDE YAPAY SİNİR AĞLARININ KULLANILMASI**

**YÜKSEK LİSANS TEZİ  
Fatih ADIYAMAN**

**Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ**

**Programı : MÜHENDİSLİK YÖNETİMİ**

**HAZİRAN 2007**

**TALEP TAHMİNİNDE YAPAY SİNİR AĞLARININ KULLANILMASI**

**YÜKSEK LİSANS TEZİ  
Fatih ADIYAMAN  
(507041207)**

**Tezin Enstitüye Verildiği Tarih : 7 Mayıs 2007  
Tezin Savunulduğu Tarih : 11 Haziran 2007**

**Tez Danışmanı : Yrd. Doç.Dr. Şule ÖNSEL (D.Ü.)**

**Diğer Jüri Üyeleri : Prof. Dr. Füsun ÜLENGİN (D.Ü.)**

**Öğr. Gör. Dr. Cafer Erhan BOZDAĞ (İ.T.Ü.)**

**HAZİRAN 2007**

## ÖNSÖZ

Dünya nüfusunun artan yapısı ile birlikte tüketimde gerçekleşen artış da paralel bir hal aldı. İşletmeler üretim miktarlarını bir çok farklı değişkene göre ayarlamak ve devamlılıklarını bu kapsamda sağlamak için önlem almak zorunda kaldılar. Bu sebeple işletmeler için tüketicilerden ürünler için gelecek olan talep miktarını önceden tahmin edebilmek ve bu amaçla üretimi modellemek bir zorunluluk halini almaya başladı.

Talep tahminini gerçekleştirebilmek talebi etkileyen unsurların ortaya konulması ve bu unsurların her birinin talep üzerindeki etkisinin bilinmesi ile mümkündür. Hem iş çevresinde hem de genel çevrede işletmeyi ve pazarı etkileyen bir çok unsurun olması ise bu işlemi gerçekten zorlu bir hale getirmektedir. Temel parametreler belirlense bile bunların birlikte ürün talep miktarını ne şekilde etkileyeceği karmaşık ve doğrusal olmayan bir denklem halini alabilmektedir. Bu noktada işletmeler için talep tahmin yöntemleri önem kazanmaktadır.

Dünyadaki artan talep ile birlikte teknolojik gelişmeler de bir çok yeniliği getirmiştir. Yenilenen teknolojiler bazı işlemlerin eskisinden daha kolay ve akıllıca yapılması için temel alınmıştır. Bu alanda en büyük gelişmeler bilgisayar ve buna bağlı teknolojilerde gerçekleşmiştir. İnsanların bilgisayarlar üzerindeki etkili çalışmaları ise zamanla bu alanı farklı kollara ayırmış ve bu sayede insan beynini bilgisayar şeklinde modelleme isteği ve yapay zeka modeli yaşamımıza girmiştir. Yapay zeka ile birlikte ilerleyen çalışmalar yapay sinir ağları adı verilen alanı ortaya çıkarmıştır.

Yapay sinir ağları doğrusal olmayan problemlerin çözümünde etkin olarak kullanılmaktadır. Bu çalışma kapsamında yapay sinir ağları ile talep tahmini için model oluşturulmuş ve modelin test edilmesi sonrasında gelecek ile ilgili tahminler yapılmıştır. Ayrıca model içerisindeki her bir değişkenin modele etkisi ve yapay sinir ağlarının mevcut yöntemlerden üstün olduğu gösterilmiştir.

Çalışmam esnasında rehberliği ve yardımları ile yön gösteren Sayın Yrd. Doç.Dr. Şule Önsel'e teşekkür ederim.

Mayıs 2007

Fatih Adıyaman

## İÇİNDEKİLER

<b>KISALTMALAR</b>	<b>v</b>
<b>TABLO LİSTESİ</b>	<b>vi</b>
<b>ŞEKİL LİSTESİ</b>	<b>vii</b>
<b>SEMBOL LİSTESİ</b>	<b>viii</b>
<b>ÖZET</b>	<b>ix</b>
<b>SUMMARY</b>	<b>x</b>

<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. YAPAY SINIR AĞLARI</b> .....	<b>3</b>
2.1 Yapay Sinir Ağları Tanımı ve Tarihçesi .....	3
2.1.1 Yapay Sinir Ağları Tanımı .....	3
2.1.2 Yapay Sinir Ağlarının Genel Özellikleri .....	3
2.1.3 Yapay Sinir Ağlarının Tarihçesi .....	4
2.2 Yapı ve Temel Elemanları.....	6
2.2.1 Biyolojik Sinir Hücreleri.....	6
2.2.2 Yapay Sinir Hücresi (İşlemci Eleman) .....	6
2.2.3 Yapay Sinir Ağları Yapısı .....	8
2.3 Yapay Sinir Ağlarında Öğrenme .....	9
2.3.1 Öğrenme Kuralları .....	10
2.3.1.1 Çevrimiçi Öğrenme Kuralları.....	10
2.3.1.2 Çevrimdışı Öğrenme Kuralları .....	12
2.3.1 Öğrenme Yöntemleri .....	17
2.3.2.1 Gözetimli (Öğretmenli) Öğrenme Yöntemi .....	17
2.3.2.2 Gözetimsiz (Öğretmensiz) Öğrenme Yöntemi .....	18
2.3.2.3 Destekleyici Öğrenme (Reinforcement learning) .....	19
2.3.3 Yapay Sinir Ağının Eğitilmesi .....	19
2.4 Yapay Sinir Ağı Modelleri .....	22
2.4.1 Tek Katmanlı Algılayıcılar .....	22
2.4.1.1 Basit Algılayıcı (Perseptron) Modeli.....	23
2.4.1.2 ADALINE / MADALINE Modeli .....	23
2.4.2 Çok Katmanlı Algılayıcı (Geriye Yayım) Modeli .....	24
2.4.2.1 Çok Katmanlı Algılayıcı Çalışma Prosedürü .....	25
2.4.2.2 Çok Katmanlı Algılayıcı Ağının Eğitilmesi.....	26
2.4.3 LVQ Modeli (Destekleyici Öğrenme).....	37
2.4.3.1 LVQ Ağının Yapısı.....	37
2.4.3.2 LVQ Ağının Çalışma Prosedürü.....	39
2.4.4 Adaptif Rezonans Teori (ART) Ağları Modeli (Öğretmensiz Öğrenme).....	39
2.4.4.1 ART Ağlarının Yapısı.....	39
2.4.4.2 ART Ağlarının Çalışma Prensipleri.....	40
2.4.4.3 ART Ağlarının Diğer Yapay Sinir Ağlarından Farkları .....	42

2.4.4. Diğer Yapay Sinir Ağı Modelleri .....	43
2.4.4.1 Elman Ağı .....	43
2.4.4.2 Hopfield Ağı.....	44
2.4.4.3 Cognitron ve Neocognitron Ağları .....	45
<b>3. TALEP TAHMİNİ.....</b>	<b>46</b>
3.1 Talep Tahmini Kavramı .....	46
3.2 Talep Tahmini Aşamaları:.....	47
3.3 Talep Tahmini Yöntemleri: .....	48
3.3.1 Öznel Tahmin Yöntemleri.....	48
3.3.1 .1 Yönetici ve Satış Elemanlarının Tahminlerini Toplama.....	48
3.3.1 .2 Tüketici Anketleri .....	49
3.3.2 Nesnel Tahmin Yöntemleri .....	49
3.3.2.1 Regresyon Analizi , En Küçük Kareler Yöntemi ve Korelasyon Katsayısı .....	49
3.3.2.2 Basit Ortalama ve Ağırlıklı Ortalama Yöntemi: .....	54
3.3.2.3 Zaman Serileri Yöntemi:.....	55
3.3.2.4 Hareketli Ortalamalar Yöntemi: .....	56
3.3.2.5 AR, MA ve ARIMA Modelleri: .....	58
3.3.2.6 Üssel Ağırlıklı Ortalamalar (Üssel Düzeltme) Yöntemi:.....	59
3.3.2.7 Eğri Uydurma Yöntemi:.....	60
3.3.2.8 Simulasyon Yöntemi:.....	61
3.4 Talep Tahmini ve Yapay Sinir Ağları.....	61
<b>4. TALEP TAHMİNİ UYGULAMASI.....</b>	<b>65</b>
4.1 Talep Tahmini Probleminin Tanımlanması.....	65
4.2 Yapay Sinir Ağı Mimarisi .....	68
4.3 Yapay Sinir Ağının Eğitilmesi .....	71
4.4 Bulunan Sonuçların Test Edilmesi .....	74
4.5 Diğer Talep Yöntemiyle Kıyaslanması.....	79
<b>5. SONUÇ.....</b>	<b>82</b>
<b>KAYNAKLAR</b>	<b>84</b>
<b>EKLER</b>	<b>87</b>
<b>ÖZGEÇMİŞ</b>	<b>98</b>

## **KISALTMALAR**

<b>YSA</b>	: Yapay Sinir Ağları
<b>RTFA</b>	: Radyal Tabanlı Fonksiyon Ağları
<b>ÇKA</b>	: Çok Katmanlı Algılayıcılar

## TABLO LİSTESİ

	<u>Sayfa No</u>
<b>Tablo 2.1.</b>	XOR problemi 24
<b>Tablo 2.2.</b>	Örnek XOR Problemi Tablosu 27
<b>Tablo 2.3.</b>	XOR problemini öğrendikten sonra ağın ürettiği çözümler ve hata oranları 32
<b>Tablo 3.1.</b>	Konya Şeker Fabrikası Üretimi 53
<b>Tablo 3.2.</b>	Konya Şeker Fabrikası Üretimi 53
<b>Tablo 3.3.</b>	Ayçelik A.Ş.'nin Satış Tablosu 55
<b>Tablo 3.4.</b>	AKTAŞ A.Ş. nin 12 Aylık Dönemdeki Satışları 57
<b>Tablo 3.5.</b>	AKTAŞ A.Ş. nin 12 Aylık Dönemdeki Satışların Hesaplanması 57
<b>Tablo 4.1.</b>	Momentum Katsayısının Farklı Değerleri İçin Tahminler 69
<b>Tablo 4.2.</b>	Öğrenme Katsayısının Farklı Değerleri İçin Tahminler 70
<b>Tablo 4.3.</b>	Çevrim Sayısının Farklı Değerleri İçin Tahminler 70
<b>Tablo 4.4.</b>	Çevrim Sayısının Farklı Değerleri İçin Tahminler 71
<b>Tablo 4.5.</b>	Ara Hücre Sayısının Farklı Değerleri İçin Tahminler 71
<b>Tablo 4.6.</b>	2006 Yılı Tahmin Edilen Değerlerle (YSA) Gerçekleşen Değerlerin Kıyaslanması 74
<b>Tablo 4.7.</b>	2006 Yılı (8K-22K) Tahmin Edilen Değerlerle (YSA) Gerçekleşen Değerlerin Kıyaslanması 75
<b>Tablo 4.8.</b>	2006 Yılı (24K) Tahmin Edilen Değerlerle (YSA) Gerçekleşen Değerlerin Kıyaslanması 76
<b>Tablo 4.9.</b>	Regresyon Analizi Ağırlıkları 79
<b>Tablo 4.10.</b>	Regresyon Analizi Sonuçları ile Gerçekleşen Verilerin Kıyaslanması 80 81
<b>Tablo 4.11.</b>	Eğri Uydurma Yöntemi Sonuçları ile Gerçekleşen Verilerin Kıyaslanması
<b>Tablo A.1.</b>	Altın Satış Fiyatları gr/TL 84
<b>Tablo A.2.</b>	Dolar Kurları / TL 84
<b>Tablo A.3.</b>	1997-2006 Arası Enflasyon Verileri 85
<b>Tablo A.4.</b>	1997-2006 Arası Gayri Safi Milli Hasıla 86
<b>Tablo A.5.</b>	1997-2006 Arası 1 Aylık Vadeli Faiz Oranları 87
<b>Tablo A.6.</b>	1997-2006 Arası Aylık IMKB (Tüm) Verileri 88
<b>Tablo A.7.</b>	2003-2005 Arası Aylık Evlenme Sayıları 89
<b>Tablo A.8.</b>	1997-2006 Arası Türkiyeye Gelen Turist Sayısı (Bin) 89
<b>Tablo A.9.</b>	1997-1999 Arası Aylık Bazda Satış Miktarları (gr) 90
<b>Tablo A.10.</b>	2000-2003 Arası Aylık Bazda Satış Miktarları (gr) 91
<b>Tablo A.11.</b>	2004-2006 Arası Aylık Bazda Satış Miktarları (gr) 92
<b>Tablo A.12.</b>	1997-2006 Arası 24K Altın Ürünlerin HAS Değerleri 93
<b>Tablo A.13.</b>	1997-2006 Arası 9K-22K Altın Ürünlerin HAS Değerleri 94

## ŞEKİL LİSTESİ

	<u>Sayfa No</u>
Şekil 2.1 : Biyolojik sinir hücresi.....	6
Şekil 2.2 : Yapay Sinir Hücresinin Yapısı.....	6
Şekil 2.3 : Yapay Sinir Ağları Yapısı.....	8
Şekil 2.4 : Gözetimli Öğrenme Yöntemi.....	18
Şekil 2.5 : Gözetimsiz Öğrenme Yöntemi.....	18
Şekil 2.6 : Destekleyici Öğrenme Yapısı.....	19
Şekil 2.7 : Öğrenmenin Uzaydaki Gösterimi.....	20
Şekil 2.8 : Çok Boyutlu Hata Uzayı.....	20
Şekil 2.9 : Tek Katmanlı Algılayıcı .....	22
Şekil 2.10 : ADALINE ünitesi .....	23
Şekil 2.11 : Çok Katmanlı Algılayıcı modeli.....	25
Şekil 2.12 : Çok Katmanlı Algılayıcı ağının öğrenme eğrisi.....	27
Şekil 2.13 : XOR Problemi İçin Tasarlanmış Çok Katmanlı Algılayıcı Modeli .....	28
Şekil 2.14 : İleri doğru hesaplama.....	29
Şekil 2.15 : XOR Ağının Ağırlıklar Değiştirildikten Sonraki Durumu.....	31
Şekil 2.16 : Problemi Öğrendikten Sonraki Ağırlıklar.....	32
Şekil 2.17 : Çok Katmanlı Algılayıcı Ağlarında Başlangıç Noktasının Etkisi.....	34
Şekil 2.18 : LVQ Ağının Yapısı.....	38
Şekil 2.19 : ART Ağının Genel Yapısı.....	40
Şekil 2.20 : Aşağıdan Yukarıya Bilgi İşleme.....	41
Şekil 2.21 : Yukarıdan Aşağıya Bilgi İşleme.....	42
Şekil 2.22 : Elman Ağının Yapısı.....	43
Şekil 2.23 : Hopfield Ağının Yapısı.....	44
Şekil 2.24 : Cognitron Ağının Yapısı .....	45
Şekil 3.1 : En Küçük Kareler Yöntemi.....	51
Şekil 3.2 : Korelasyon Katsayısı.....	52
Şekil 3.3 : Yapay Sinir Ağları Yöntemi ve Geleneksel Yöntemlerle Talep Tahmini Adımları.....	64
Şekil 4.1 : EasyNN Programı Katman ve Hücre Sayısının Belirlenmesi.....	72
Şekil 4.2 : EasyNN Program Parametre Tanımlama Ekranı.....	72
Şekil 4.3 : Kullanılan Ağın Yapısı .....	73
Şekil 4.4 : Öğrenme Grafiği.....	73
Şekil 4.5 : Tahmin Grafiği.....	74
Şekil 4.6 : Duyarlılık Analizi (8K-22K).....	77
Şekil 4.7 : Duyarlılık Analizi (24K).....	77
Şekil 4.8 : Girdilerin Önem Derecesi .....	77
Şekil 4.9 : Eğri Uydurma Yöntemi Grafikleri.....	81



## SEMBOL LİSTESİ

$\varphi(\cdot)$	: Hücrenin aktivasyon fonksiyonu
$N$	: İşlemci eleman sayısı
$X_i$	: j hücresinin i hücresinden gelen girdisi
$Y_j$	: j hücresinin çıktısı
$W_{ij}$	: i ile j hücreleri arasındaki bağlantı ağırlık değeri
$E(\mathbf{k})$	: k anındaki hata değeri
$\lambda$	: Öğrenme Katsayısı
$\mathbf{d}(\mathbf{k})$	: Ağırlık değişiminin eğim bileşeni

## **SALES FORECASTING USING ARTIFICIAL NEURAL NETWORKS**

### **SUMMARY**

For companies, the possibility of surviving is parallel with the accuracy of predictions in increasing competition environment. In that concept, demand prediction is important for all companies.

Demand prediction is determining the demand level of a product or more than one product of a company for a time in the future.

While having determined strategic and tactical decisions by company management; with the help of demand prediction which is one of the main tools used to achieve short term and long term targets, the functions of a company arise to the optimum profit level with an effective planning and the conflict between strategic targets and operational necessities decreases.

In that study, artificial neural network and demand predictions concepts are explained. In application part of this study, artificial neural networks sales forecasting model for golden products is builded and implemented. On the other hand, prediction models are builded for regresion analysys and curve estimation method. In conclusion, results are compared and shown that artificial neural networks is an efficient tool for forecasting.

## **TALEP TAHMİNİNDE YAPAY SİNİR AĞLARININ KULLANILMASI**

### **ÖZET**

Artan rekabet ortamında şirketlerin gelecek için güvenle yol alabilmeleri tahminlerindeki doğruluklarla paraleldir. Bu kapsamda talep tahminleri tüm işletmeler için önemlidir. Talep tahmini, gelecekteki bir zaman süresi için şirketin bir ürünü veya çeşitli ürünleri için talep düzeyini tespit etmektir.

Şirket yönetiminin stratejik ve taktik kararların alınmasında, kısa dönemli ve uzun dönemli hedeflere ulaşmada kullanılacak en temel araçların başında gelen talep tahmini sayesinde etkin bir talep planlama ile şirket fonksiyonları optimum kar seviyesine doğru ilerler, stratejik hedefler ile operasyonel gereksinimler arasındaki çatışma azalır.

Çalışma içerisinde yapay sinir ağları ve talep tahmini kavramları açıklanmıştır. Uygulama bölümünde yapay sinir ağları kullanılarak altın ürün satışları ile ilgili bir tahmin modeli kurulmuş ve uygulanmıştır. Yapay sinir ağları yönteminin yanısıra regresyon analizi ve eğri uydurma yöntemleri ile de altın ürünlerin talep tahmini yapılmış ve sonuçlar kıyaslanmıştır. Uygulama sonucunda yapay sinir ağı yönteminin etkin bir talep tahmini yöntemi olduğu gösterilmiştir.

## 1. GİRİŞ

Talep tahmini, şirket yönetiminin stratejik ve taktik kararların alınmasında, kısa dönemli ve uzun dönemli hedeflere ulaşmada kullanılacak en temel araçların başında gelir. Etkin bir talep tahmini ile şirket fonksiyonları optimum kar seviyesine doğru ilerler, stratejik hedefler ile operasyonel gereksinimler arasındaki çatışma azalır.

Üretilen mal ve hizmetlerle birlikte tüketici davranışının da farklı oluşu nedeniyle tek bir talep tahmin yönteminden bahsetmek imkansızdır. Talep tahmininde kullanılan yöntemler temel olarak “öznel yöntemler” ve “nesnel yöntemler” olmak üzere ikiye ayrılır. (Bolt, 1994) Öznel yöntemler, matematiksel verilerden daha çok tecrübenin uygulanmasına, yargılama ve zekaya dayanan yöntemlerdir. Nesnel yöntemler ise, istatistiksel ve matematiksel verilere dayanan yöntemlerdir. İdeal olan yöntem bu iki tip yöntemlerin karmasıdır. (Tekin, 1996)

Yapay sinir ağları yöntemi istatistiksel verileri kullanması yönüyle nesnel yöntemlere, faktörler arasındaki ilişki ve derecelerini öğrenmesi yönüyle öznel yöntemlere benzemektedir ve etkin bir talep tahmin yöntemi olarak son yıllarda öne çıkmaktadır. Bu tez kapsamında yapay sinir ağlarının talep tahmininde kullanılan etkin bir yöntem olduğu gösterilmeye çalışılmıştır.

Bu çalışmada Türkiye'nin önde gelen bir kuyum grup şirketinin İstanbul içinde yedi perakende mağazasının verilerinden yola çıkılarak altın ürünler için talep tahmini yapılmaya çalışılmıştır.

İkinci bölümde yapay sinir ağlarına genel bir giriş yapılmıştır. Yapay sinir ağlarında öğrenme ve yapay sinir ağları modelleri hakkında bilgiler verilmiş, bu tez kapsamında kullanılacak ÇKA (Çok Katmanlı Algılayıcılar) modeli ayrıntılı olarak açıklanmıştır.

Üçüncü bölümde talep tahmini hakkında bilgi verilmiştir. Nesnel ve öznel talep tahmin yöntemleri üzerinde durulmuş, ve yapay sinir ağlarının talep tahmininde kullanılması ile ilgili bilgi verilmiştir.

Dördüncü bölümde, uygulama kapsamında yapılan çalışmalar ayrıntılı bir şekilde anlatılmıştır. Yapay sinir ağları kullanılarak talep tahmini yapılmış ve sonuçları incelenmiştir. Ayrıca çoklu regresyon yöntemi ve eğri uydurma yöntemleriyle de talep tahmini yapılmış ve sonuçlar kıyaslanmıştır.

Son bölümde ise uygulama aşamasında elde edilen sonuçlar değerlendirildikten sonra ileriki çalışmalara yön verecek geliştirme önerilerinde bulunulmuştur.

## 2. YAPAY SİNİR AĞLARI

### 2.1 Yapay Sinir Ağları Tanımı ve Tarihçesi

#### 2.1.1 Yapay Sinir Ağları Tanımı

İnsan Beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, oluşturabilme, keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir.

Yapay sinir ağları insan beyninin fonksiyonel özelliklerine benzer şekilde,

- Öğrenme
- İlişkilendirme
- Sınıflandırma
- Genelleme
- Özellik Belirleme
- Optimizasyon

gibi konularda başarılı bir şekilde uygulanmaktadırlar. (Öztemel, 2003)

#### 2.1.2 Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağlarının günümüzde kullanılan diğer bilgi işlem yöntemlerinden farklılıkları aşağıdaki şekilde sıralanabilir: (Seven, 1993; Simpson, 1990: Öztemel, 2003)

*Paralellik:* Yapay sinir ağlarında işlemler doğrusal değildir ve bu bütün ağa yayılmış durumdadır. Bu sayede doğrusal olmayan karmaşık problemlerin de çözümlenmesi mümkündür.

*Öğrenebilirlik:* Yapay Sinir Ağlarının temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer karar vermeye çalışırlar

*Bilginin Saklanması:* Yapay Sinir ağlarında veriler herhangi bir veritabanında ve programın içinde gömülü olarak değil ağ üzerinde saklıdır.

*Hata Toleransı:* Yapay sinir ağlarındaki paralel yapı, ağın sahip olduğu bilginin tüm bağlantılara yayılmasını sağladığı için bazı bağlantıların veya hücrelerin etkisiz hale gelmesi ağın doğru bilgiyi üretmesini önemli derecede etkilemez.

*Genelleme:* Yapay Sinir Ağları kendisine gösterilen örneklerden yola çıkarak görmediği örnekler hakkında da bilgiler üretebilirler.

*Dereceli bozulma:* Ağlar bir eksik ve problem ile karşılaştıklarında hemen bozulmazlar. Hata toleransına sahip oldukları için dereceli bir şekilde bozulurlar.

*Uyarlanabilirlik:* Yapay sinir ağlarında ağırlıkların yeniden yapılandırılabilir olması belirli bir problemi çözmek için eğitilen yapay sinir ağının, problemdeki değişikliklere göre yeniden eğitilebilmesi ve farklı koşullara uyarlanabilmesini sağlamaktadır.

### **2.1.3 Yapay Sinir Ağlarının Tarihçesi**

Yapay Sinir Ağlarının tarihçesi insanların nörobiyoloji konusuna ilgi duymaları ve sonuçları bilgisayar bilimine uygulamaları ile başlamaktadır. Bu çalışmalar aşağıdaki şekilde özetlenebilir:

- 1890: İnsan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması
- 1911: İnsan beyninin bileşenlerinin belirli bir düzenek ile sinir hücrelerinden oluştuğu fikrinin benimsenmesi
- 1943: Yapay Sinir hücrelerine dayalı hesaplama teorisinin ortaya atılması: Warren McCulloch/Walter tarafından Pitts “Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap” teorisi ortaya atılmıştır.
- 1949: Biyolojik olarak mümkün olabilen öğrenme prosedürlerinin bilgisayarlar tarafından gerçekleştirilecek biçimde geliştirilmesi: Hebb Kuralı.
- 1956-1962: Adaline ve Windrow öğrenme algoritmasının geliştirilmesi.

- 1957-1962: Tek Katmanlı Algılayıcının (Perceptron) geliştirilmesi.
- 1965: İlk makine öğrenme kitabının yazılması.
- 1967-1969: Bazı gelişmiş öğrenme algoritmalarının geliştirilmesi: Grosberg öğrenme algoritması.
- 1969: Tek katmanlı algılayıcıların problemleri çözme yeteneklerinin olmadığını gösterilmesi.
- 1969-1972: Çağrışimli Bellek (Associative memory) konusunda çalışmalar: Kohonen ve Anderson çalışmaları.
- 1969-1972: Doğrusal İlişkilendiricilerin geliştirilmesi.
- 1972: Korelasyon ve matriks belleğinin geliştirilmesi.
- 1974: Geri Yayılım modelinin (Çok katmanlı algılayıcıların ilk çalışmaları) geliştirilmesi.
- Öğretmensiz Öğrenmenin geliştirilmesi:
  - 1978: ART Modelinin geliştirilmesi.
  - 1982: Kohonen Öğrenmesi ve SOM modelinin geliştirilmesi.
- 1982: Hopfield Ağlarının geliştirilmesi.
- 1982: Çok Katmanlı algılayıcılarının geliştirilmesi.
- 1984 Boltzman makinesinin geliştirilmesi.
- 1985: Çok katmanlı algılayıcıların Genelleştirilmiş Delta Öğrenme Kuralı ile geliştirilmesi.
- 1988: RBF modelinin geliştirilmesi.
- 1988: PNN modelinin geliştirilmesi.
- 1991: GRNN modelinin geliştirilmesi.

(Öztemel, 2003)




## 2.2 Yapı ve Temel Elemanları

### 2.2.1 Biyolojik Sinir Hücreleri

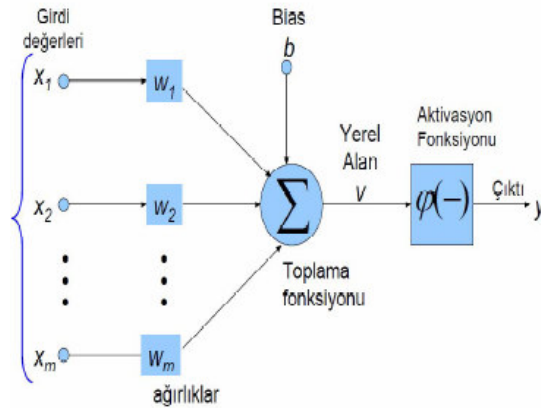
Biyolojik sinir ağı insan beyninin çalışmasını sağlayan en temel taşlardan birisidir. İnsanların bütün davranışlarını ve çevresini anlamasını sağlar.

Bir sinir ağı milyarlarca sinir hüresinin bir araya gelmesi ile oluşmuştur. Şekil 2.1'de gösterildiği gibi bir sinir hücresi sinapslar, akson, soma (hücre gövdesi), ve dentrite'lerden oluşmaktadır. Sinapslar sinir hücreleri arasında elektrik sinyallerinin geçmesini sağlayan bağlantılardır. Bu sinyaller somaya ve dentrite'lere iletilir. Dentriteler ise bu sinyalleri sinaps'lere göndererek diğer sinir hücrelerine iletir.



Şekil 2.1 Biyolojik sinir hücresi

### 2.2.2 Yapay Sinir Hücresi (İşlemci Eleman)



Şekil 2.2 Yapay Sinir Hücresinin Yapısı

Biyolojik sinir ağlarının hücreleri olduğu gibi yapay sinir ağlarının da hücreleri vardır. Yapay sinir ağı hücresi beş elemandan oluşur. Bunlar:

1. *Girdiler*:Yapay sinir hücresine (proses elemanına) dış dünyadan gelen bilgilerdir. Bilgiler dış dünyadan geldiği gibi başka hücrelerden olduğu gibi kendi kendisinden de gelebilir.

2. *Ağırlıklar*:Ağırlıklar hücreye gelen bilginin hücre üzerindeki etki ve önemini gösterir. Ağırlığın küçük ya da büyük olması önemli olup olmadığı anlamına gelmez.

3. *Toplama Fonksiyonu*: Bu fonksiyon hücreye gelen net girdiyi hesaplar. Toplam fonksiyonu için farklı fonksiyonlar kullanılır . En yaygın olarak ağırlıklı toplam fonksiyonu kullanılır. Bu fonksiyon aşağıdaki şekilde formülize edilir.

$$\text{Net} = \sum G_i \cdot A_i \quad (i=1\dots n) \quad (2.1)$$

Burada G girdileri, A ağırlıkları, n ise girdi (proses elemanı) sayısını göstermektedir. Bir problem için en uygun toplama fonksiyonunu belirleyecek bir formül yoktur.

Her proses elemanı bağımsız olarak farklı bir toplama fonksiyonuna sahip olabilecekleri gibi aynı toplama fonksiyonuna da sahip olabilirler.

Toplama Fonksiyonuna aşağıdaki fonksiyonlar örnek olarak verilebilir:

- Çarpım :  $\text{NET} = \prod G_i \cdot A_i \quad (2.2)$

- Maksimum :  $\text{NET} = \text{Max} (G_i \cdot A_i) \quad (2.3)$

- Minimum :  $\text{NET} = \text{Min} (G_i \cdot A_i) \quad (2.4)$

- Çoğunluk :  $\text{NET} = \sum \text{sgn} (G_i \cdot A_i) \quad (2.5)$

- Kümülatif Toplam :  $\text{NET} = \text{NET}_{(\text{eski})} + \sum (G_i \cdot A_i) \quad (2.6)$

4.*Aktivasyon Fonksiyonu*: Bu fonksiyon hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da çıktıyı hesaplamak için değişik fonksiyonlar kullanılır. Bazı modeller ( örneğin ÇKA) bu fonksiyonun türevi alınabilir bir fonksiyon olmasını şart koşmaktadır. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da proses elemanları farklı fonksiyonlar kullanabilir. Çok Katmanlı Algılayıcı modelde en çok sigmoid fonksiyonu kullanılmaktadır.

Sigmoid Fonksiyonu:  $F(\text{NET}) = 1 / (1 + e^{-\text{NET}})$  (2.7)

Burada NET proses elemanına gelen net girdi değerini göstermektedir. Aktivasyon fonksiyonuna aşağıdaki fonksiyonlar örnek olarak verilebilir:

- Lineer Fonksiyon :  $F(\text{NET}) = \text{NET}$  (2.8)

- Step Fonksiyonu :  $F(\text{NET}) = 1 \quad \text{Net} > \text{eşik değeri}$   
 $F(\text{NET}) = 0 \quad \text{NET} \leq \text{eşik değeri}$  (2.9)

- Sinus Fonksiyonu :  $F(\text{NET}) = \text{Sin}(\text{NET})$  (2.10)

- Çoğunluk :  $F(\text{NET}) = 0 \quad \text{NET} \leq 0$   
 $F(\text{NET}) = \text{Net} \quad 0 < \text{NET} < 1$   
 $F(\text{NET}) = 1 \quad \text{NET} > 1$  (2.11)

- Hiperbolik Tanjant Fonksiyonu :

$$F(\text{NET}) = (e^{\text{NET}} + e^{-\text{NET}}) / (e^{\text{NET}} - e^{-\text{NET}})$$
 (2.12)

5. *Hücresinin Çıktısı*: Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı dış dünyaya veya başka bir hücreye gönderilir. Bir proses elemanından sadece tek bir çıktı değeri vardır.

### 2.2.3 Yapay Sinir Ağları Yapısı

Yapay Sinir Ağlarının Yapısı aşağıdaki şekilde gösterilmektedir.



Şekil 2.3 Yapay Sinir Ağları Yapısı

*Girdi Katmanı:* Girdi katmanı en az bir girdi elemanının bulunduğu bölümdür. Bu katmanda veriler herhangi bir işleme tabi tutulmadan girdileri ile aynı değerde çıktı üretirler (Hawley ve Johnson, 1994) .

*Ara Katmanlar:* Girdilerin belirli işlemlere tabi tutulduğu bölgedir. Seçilen ağ yapısına göre işlem katmanının yapısı ve fonksiyonu da değişebilir. Tek bir katmandan oluşabileceği gibi birden fazla katmandan da oluşabilir (Chaudhury ve diğ., 1994) .

*Çıktı Katmanı:* Çıktı katmanı en az bir çıktıdan oluşur ve çıktı ağ yapısında bulunan fonksiyona bağlıdır. Bu katmanda işlem gerçekleştirilir ve üretilen çıktı dış dünyaya gönderilir.

### 2.3 Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağları zaman için öğrenebilmektedirler. Bu bakımdan adaptif özellik taşırlar. Yani, sinir ağları geçmiş deneyimlerine dayanarak problem çözme yeteneklerini geliştirebilir. Yapay sinir ağlarındaki bu olay “öğrenme” olarak adlandırılır. Öğrenme işlemi istenilen çıktıları elde edebilmek amacıyla bağlantıların ağırlıklarının belirlenmesidir.

Hebb, sinir ağlarındaki öğrenme kavramını şu hipotez ile açıklamıştır:

“Bir  $i$  sinir hücresi bir  $j$  sinir hücresi tarafından sürekli bir biçimde uyarılır ise, bu iki sinir hücresi arasında,  $i$  hücresinin  $j$  hücresi tarafından uyarılma etkinliğini artıracak şekilde, bazı metabolik değişmeler ve büyüme süreçleri gözlenir.” (Hebb, 1949) .

Bu hipotezi matematiksel olarak aşağıdaki gibi ifade etmek mümkündür:

$x_i$  :  $j$  hücresinin  $i$  hücresinden gelen girdisi,

$y_j$  :  $j$  hücresinin çıktısı,

$w_{ij}$  :  $i$  ile  $j$  hücreleri arasındaki bağlantı ağırlık değeri,

$\alpha > 0$  : öğrenme hızı parametresi, olmak üzere;

$$w_{ij}^{\text{yeni}} = w_{ij}^{\text{eski}} + \alpha x_i y_j \quad (2.13)$$

Eğitimin amacı istenilen yapay sinir ağı yapısını elde etmek için ağırlıkların kontrol altında tutulmasıdır. Yapay Sinir ağlarında öğrenme belirli kurallara ve yöntemlere göre gerçekleştirilir.

### 2.3.1 Öğrenme Kuralları

Yapay Sinir ağları gibi sistemlerde öğrenme bazı kurallara göre gerçekleşir. Bu kuralların bazıları çevrimiçi (on-line), bazıları çevrimdışı (off-line) çalışmaktadır. (Öztemel, 2003)

#### 2.3.1.1 Çevrimiçi Öğrenme Kuralları

Çevrimiçi kurallar gerçek çalışırlar. Bu kurallara göre çalışan sistemler bir yandan öğrenirken bir yandan da fonksiyonlarını yerine getirirler. Kohonen öğrenme kuralı ve ART ağının öğrenme kuralı çevrimiçi öğrenmeye örnek verilebilir.

##### 1. Kohonen Öğrenme Kuralı:

Bu kural, biyolojik sistemlerdeki öğrenmeden esinlenerek Kohonen tarafından geliştirilmiştir. Hedef çıktıya gereksinim duymaz.

Bu kurala göre hücreler ağırlıklarını değiştirmek (öğrenmek) için birbirleri ile yarışır. Yarışma girdi vektörü ile ağırlık vektörleri (referans vektörleri) arasındaki öklid mesafesinin hesaplanmasına dayanır. Hangi proses elemanın referans vektörü girdi vektörüne en yakın ise yarışmayı o kazanır. Öğrenme sırasında sadece girdi katmanına bağlı ağırlık değiştirilir. Kazanan proses elemanı için iki durum söz konusudur:

- Kazanan proses elemanı doğru sınıfın bir üyesidir. Bu durumda aynı proses elemanının tekrar kazanması için ilgili ağırlıklar girdi vektörüne biraz daha yaklaştırılırlar.  $\Lambda$  öğrenme katsayısı,  $A$  ağırlık vektörü,  $X$  girdi vektörü olmak üzere ağırlıkların değiştirilmesi formülü şu şekilde ifade edilir:

$$A_{\text{yeni}} = A_{\text{eski}} + \Lambda (X - A_{\text{eski}}) \quad (2.14)$$

Girdi vektörünün referans vektörüne çok yaklaşıncaya durması ve aksi yönde uzaklaşmaması için  $\Lambda$  öğrenme katsayısı sıfır değerine kadar zamanla azaltılır. Öğrenme katsayısı ne çok erken ne de çok geç sifıra indirgenmemelidir. Öğrenmenin ne zaman durdurulacağına eğitim süreci ayrıntılı incelenerek karar verilir.

- Kazanan proses elemanı yanlış sınıfın bir üyesidir. Bu durumda aynı proses elemanı tekrar kazanmaması için ilgili ağırlıklar girdi vektöründen biraz daha uzaklaştırılırlar.  $\Lambda$  öğrenme katsayısı,  $A$  ağırlık vektörü,  $X$  girdi vektörü olmak üzere ağırlıkların değiştirilmesi formülü şu şekilde ifade edilir:

$$A_{\text{yeni}} = A_{\text{eski}} - \Lambda (X - A_{\text{eski}}) \quad (2.15)$$

Öğrenme katsayısının zamanla azaltılarak sıfır değerine indirgenmesi bu durum için de geçerlidir. (Kohonen, 1982)

## 2. ART Ağının Öğrenme Kuralı:

Bu kural Grosberg'in 1976'da biyolojik beynin üzerine yaptığı çalışmalar sonucunda Adaptif Rezonans Teori (ART) ağlarını geliştirmesiyle ortaya çıkmıştır.

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'den F2'ye ve F2'den F1'e doğru bilgi işleme olur. Öğrenmeye başlarken F2'den F1'e olan ağırlıklar 1 değerini alır. F1 katmanındaki proses elemana sayısı  $n$  olmak üzere F1'den F2'ye doğru olan başlangıç ağırlıkları ise;

$$A^i_{ij} = 1 / (1+n) \text{ olur.} \quad (2.16)$$

Başlangıç ağırlıkları atandıktan sonra benzerlik katsayısı değeri belirlenir. Bu değer 0 ile 1 arasında bir sayıdır. Bu sayı elemanların birbirlerine ne kadar benzemesi gerektiğini gösterir. Değer 1'e ne kadar yakın olursa sınıf sayısı o kadar az olur. Girdi setinden bir örnek ağa gösterilir. Daha sonra F2 katmanında çıktı değerleri hesaplanır ve kazanan eleman seçilir. En büyük çıktıya sahip proses elemanı kazanan elemandır ve bu elemanın sahip olduğu ağırlık vektörü en uygun ağırlık vektörüdür. Son olarak kazanan elemanın uygunluk testi yapılır. Bu test çıktı vektörü ile girdi vektör değerine göre ne kadar uyduğu benzerlik katsayısı ile kıyaslanarak yapılır. Örnek belirlenmiş bir sınıfa uyuyorsa o kategoride gösterilir, uymuyorsa yeni bir sınıf oluşturulur veya girdinin sınıflandırılması yapılmaz. (Grossberg, 1988)

### 2.3.1.2 Çevrimdışı Öğrenme Kuralları

Çevrimdışı öğrenme kuralı test verisi ile eğitime esasına dayanır. Bu kuralları kullanan sistemler eğitildikten sonra sisteme alındıktan sonra artık öğrenme yapamazlar. Sistemin öğrenmesi gerekirse sistem öğrenimden çıkarılır, çevrimdışı olarak yeniden eğitilir. Eğitim tamamlanınca tekrar kullanıma alınırlar. Çevrimdışı öğrenme kurallarına aşağıdaki kurallar örnek olarak verilebilir:

#### 1. Hebb Öğrenme Kuralı:

Bilinen en eski öğrenme kuralıdır ve diğer öğrenme kurallarının temelini oluşturmaktadır. Hebb öğrenme kuralına göre öğrenme sinyali hücre çıkışına eşittir.

Yani bir hücre aktif ise bağlı olduğu hücreyi aktif, pasif ise bağlı olduğu hücreyi pasif yapmaya çalışmaktadır.

$$\text{Öğrenme sinyali} = f(w_i^t x) \quad (2.17)$$

ile belirtilir.

Ağırlık vektöründeki artış ise;

$$\Delta w_i = c f(w_i^t x) x \quad (2.18)$$

ile veya

$$\Delta w_{ij} = c o_i x_j \quad (2.19)$$

ile belirtilir.

Bu öğrenme kuralında başlangıç olarak sifira yakın değerler ile başlanılmalıdır. Hebb öğrenme kuralına göre giriş ve çıkış değerlerinin çarpımı pozitif ise  $w_{ij}$  ağırlığında bir artış, negatif ise bir azalış gerçekleşir. (Moumin, 1995)

#### 2. Hopfield Öğrenme Kuralı:

Bu kural Hebb Kuralına benzerdir. Yapay sinir ağlarının bağlantılarının ne kadar zayıflatılması veya ne kadar kuvvetlendirilmesi gerektiği belirlenir. Eğer istenilen çıkış ve girişin her ikisi aktif veya her ikisi de aktif değilse öğrenme oranı tarafından bağlantı ağırlığı artırılır. Diğer durumlarda ise azaltılır. Ağırlıkların artırılması veya azaltılması öğrenme katsayısı ile gerçekleştirilir. Genellikle bu katsayı 0 ile 1 arasında değerler almaktadır. (Hopgood, 1991)

### 3. Basit Algılayıcı (Perseptron) Öğrenme Kuralı:

Basit algılayıcılar (perseptron) ağlarında kullanılır. Bu ağlarda sadece girdi ve çıktı katmanı vardır.

Ağa girilen değerler X,

Çıktı Değeri Ç,

Beklenen değerler B,

Girdilerin ağırlıkları W,

Eşik değer (Çıktının sıfırdan farklı olmasını sağlayan değer)  $\Phi$ ,

Öğrenme katsayısı  $\lambda$  olmak üzere;

Ağa girdi seti ve beklenen çıktı gösterilir. Girdi değerleri birden fazla olabilir ( $x_1, x_2, \dots, x_n$ ). Çıktı değeri ise 1 veya 0 değerinden birisini alır.

Perseptron ünitesine gelen net girdi ;

$$NET = \sum w_i x_i \quad (2.20)$$

olur.

Perseptron ünitesinin çıktısı ise;

$$\begin{aligned} \zeta = & \quad 1 \quad \text{Eğer } NET > \Phi \\ & \quad 0 \quad \text{Eğer } NET < \Phi \end{aligned} \quad (2.21)$$

olur.

Çıktı ile beklenen çıktı aynı olursa herhangi bir değişiklik olmaz. Çıktı ile beklenen çıktı farklı ise ağırlık değerleri;

$$\begin{aligned} W_n = W_0 - \lambda X \quad & \text{Eğer } B=0 \text{ ve } \zeta=1 \\ & \text{Eğer } B=1 \text{ ve } \zeta=0 \end{aligned} \quad (2.22)$$

olur. Bu adımlar bütün girdi setindeki örnekler için sınıflandırma yapılabancaya kadar devam eder. (Öztemel, 2003)



#### 4. Delta Öğrenme Kuralı (Windrow-Hoff Kuralı):

Ağa öğretilmesi için eğitim seti adı verilen örnek verilerden oluşan bir sete ihtiyaç vardır. Eğitim seti için hem girdiler hem de hem de ağın üretmesi gereken çıktılar belirlenmiştir. Delta Kuralı iki safhadan oluşur:

a. İleri Doğru Hesaplama Safhası: Ağın çıktısının Hesaplanması safhasıdır.

b Geriye Doğru Hesaplama Safhası: Ağırlıkları değiştirme safhasıdır.

a. İleri Doğru Hesaplama Safhası:

Bilgi işleme eğitim setindeki bir örneğin Girdi Katmanından (G1, G2...) ağa gösterilmesi ile başlar. Gelen girdiler olduğu gibi ara katmana gönderilir. Girdi katmanının k. Proses elemanının çıktısı  $C_k^i$ ,

$$C_k^i = G_k \quad (2.23)$$

k. girdi elemanının j. Ara katmanına bağlayan bağlantının ağırlık değeri  $A_{kj}$ ,

Ara katmandaki proses elemanlarına net girdi  $NET_j^a$

$$NET_j^a = \sum A_{kj} C_k^i \quad (k=1..n) \quad (2.24)$$

j. elemanın çıktısı türevi alınabilir bir fonksiyonla (genellikle sigmoid fonksiyon) hesaplanır.

$\beta_j$  ara katmanda bulunan j. elemana bağlanan eşik değer elemanın ağırlığı,

Sigmoid fonksiyonun kullanılması halinde çıktı;

$$C_j^a = 1 / [1 + e^{-(NET_j^a + \beta_j)}] \quad (2.25)$$

Eşik değer ünitesinin çıktısı sabit olup 1' e eşittir. Ağırlık fonksiyonu sigmoid fonksiyonunun oryantasyonunu belirler ve eğitim esnasında ağ bu değeri kendisi belirler.

Ara katmanın bütün proses elemanları ve çıktı katmanının proses elemanlarının çıktıları aynı şekilde kendilerine gelen NET girdinin hesaplanması ve sigmoid fonksiyonundan geçirilmesi sonucu belirlenirler. Çıktı katmanının çıktıları ( $C_1, C_2...$ ) bulununca ağın ileri hesaplama işlemi tamamlanmış olur.

*b. Geriye Doğru Hesaplama Safhası:*

Ağın çıktıları ( Ç1, Ç2..), beklenen çıktılarla (B1, B2..) ile karşılaştırılır. Aradaki fark hata kabul edilir. Amaç bu hatayı düşürmektir. Geriye hesaplamada bu hata ağın ağırlık değerlerine dağıtılarak bir sonraki iterasyonda hatanın azaltılması sağlanır. Çıktı katmanındaki m. proses elemanı için oluşan hata ( $E_m$ ),

$$E_m = B_m - \zeta_m \text{ olur.} \quad (2.26)$$

Bu bir proses elemanı için oluşan hatadır. Çıktı katmanı için oluşan Toplam hatayı (TH) bulmak için bütün hataların toplanması gerekir. Bazı hata değerleri negatif olacağından toplamın sıfır olmasını önlemek amacı ile ağırlıkların kareleri hesaplanarak sonucun karekökü alınır. Ağın eğitilmesindeki amaç bu hatayı azaltmaktır.

$$TH = \frac{1}{2} \sum E_m^2 \quad (2.27)$$

Toplam hatayı en azlamak için hatanın kendisine neden olan proses elemanlarına dağıtılarak ağırlıklar değiştirilir. Bunun için;

- Ara katman ile çıktı katmanı arasındaki ağırlıklar değiştirilir.
- Ara katmanlar arası veya ara katman girdi katmanı arasındaki ağırlıklar değiştirilir.

*Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi:* Ara katmandaki j. proses elemanını çıktı katmanındaki m. proses elemanına bağlayan bağlantının ağırlığındaki değişim miktarı  $\Delta A^a$  nın, t. iterasyondaki ağırlığın değişim miktarı  $\Delta A^a_{jm}(t)$ ;

m. çıktı ünitesinin hatası  $\delta_m$ ,

Öğrenme katsayısı (ağırlıkların değişim miktarı)  $\lambda$ ;

Momentum katsayısı  $\alpha$  olmak üzere;

$$\Delta A^a_{jm}(t) = \lambda \delta_m \zeta_j^a + \alpha \Delta A^a_{jm}(t-1) \quad (2.28)$$

olur.

Momentum katsayısı ağırlık öğrenme sırasında yerel bir optimuma takılıp kalmaması için ağırlık değişim değerinin belirli bir oranda sonraki değişime eklenmesini sağlarlar.

Aktivasyon fonksiyonunun türevi  $f'(NET)$  olmak üzere ve Sigmoid fonksiyonunun kullanılması durumunda;

$$\delta_m = f'(NET) \cdot E_m; \quad (2.29)$$

$$\delta_m = \zeta_m(1-\zeta_m) \cdot E_m \quad (2.30)$$

olur.

t. iterasyondaki ağırlıkların yeni değerleri;

$$A^a_{jm}(t) = A^a_{jm}(t-1) + \Delta A^a_{jm}(t) \quad (2.31)$$

olur.

Benzer şekilde eşik değer ünitesinin de ağırlıklarını değiştirmek gerekir. Çıktı katmanındaki proses elemanlarının eşik değer ağırlıkları  $\beta^c$ ;

bu ünitenin çıktısının sabit ve 1 olması nedeni ile değişim miktarı;

$$\Delta\beta^c_m(t) = \lambda\delta_m + \alpha\Delta\beta^c_m(t-1) \quad (2.32)$$

olur.

t. iterasyondaki ağırlıkların yeni değeri ise;

$$\beta^c_m(t) = \beta^c_m(t-1) + \Delta\beta^c_m(t-1) \quad (2.33)$$

olur.

*Ara katmanların arası veya ara katman ile girdi katmanı arasındaki ağırlıklar değiştirilmesi:*

Ağırlıklardaki değişim  $\Delta A^i$ ;

Hata terimi  $\delta^a$  olmak üzere;

$$\Delta A^i_{kj}(t) = \lambda\delta^a_j \zeta^i_k + \alpha\Delta A^i_{kj}(t-1), \quad (2.33)$$

$$\delta^a_j = f'(NET) \sum \delta_m A^a_{jm} \text{ olur.} \quad (2.34)$$

Aktivasyon fonksiyonu  $f(\text{NET})$ , sigmoid fonksiyon düşünülürse;

$$\delta_j^a = C_j^a (1 - C_j^a) \sum_m \delta_m A_{jm}^a \quad (2.35)$$

olur.

Ağırlıkların yeni değerleri ise;

$$A_{kj}^i(t) = A_{kj}^i(t-1) + \Delta A_{kj}^i(t-1) \quad (2.36)$$

olur.

Benzer şekilde eşik değer ünitesinin de ağırlıklarını değiştirmek gerekir. Ara katman eşik değer ağırlıkları  $\beta^a$ ;

$$\Delta \beta_j^a(t) = \lambda \delta_m + \alpha \Delta \beta_j^a(t-1) \quad (2.37)$$

olur.

t. iterasyondaki ağırlıkların yeni değeri ise;

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta \beta_j^a(t-1) \quad (2.38)$$

olur.

Böylece bir iterasyonun ileri ve geri hesaplamaları tamamlanmış olur. İkinci bir örnek verilerek sonraki iterasyona başlanır ve aynı işlemler öğrenme tamamlanıncaya kadar yinelenir. (Widrow, 1990)

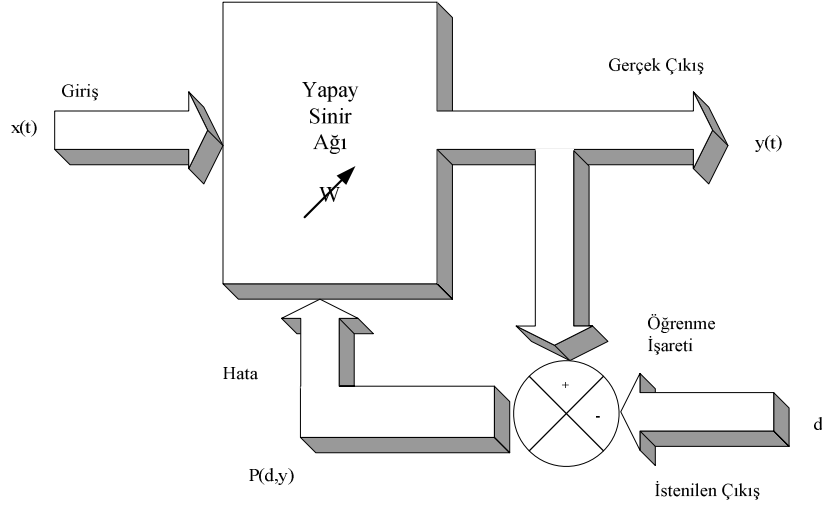
### 2.3.1 Öğrenme Yöntemleri

Yapay Sinir Ağlarında öğrenmeyi gerçekleştirecek olan sistem ve algoritmaların kullanımı çeşitli yöntemlere göre gerçekleştirilir. Genel olarak üç öğrenme yöntemi ve bunların karması yöntemler uygulanır.

#### 2.3.2.1 Gözetimli (Öğretmenli) Öğrenme Yöntemi

Öğrenen sistemin öğrenebilmesi için bir öğretmen yardımcı olmaktadır. Öğretmen öğrenilmesi istenen olay ile ilgili örneklerin hem girdi değerlerini hem de girdiler karşılığında olması gereken çıktı değerlerini verir. Sistemin görevi girdileri öğretmenin belirlediği çıktıları haritalamak ve bu sayede girdiler ile çıktılar


arasındaki ilişkileri öğrenmektedir. En çok kullanılan model olan “Çok Katmanlı Algılayıcılar” Yapay Sinir Ağı modelinde bu yöntem kullanılmaktadır.



Şekil 2.4 Gözetimli Öğrenme Yöntemi

### 2.3.2.2 Gözetimsiz (Öğretmensiz) Öğrenme Yöntemi

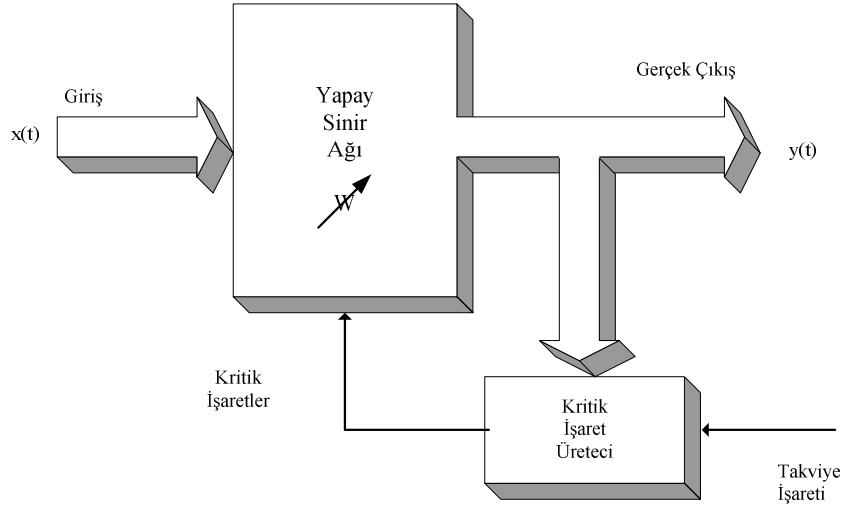
Bu yöntemde sistemin öğrenmesi için herhangi bir öğretmen yoktur. Yani sisteme sadece girdi değerleri gösterilir. Örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendisine öğrenmesi beklenir. Sistemin öğrenmesi bittikten sonra çıktılarının ne anlama geldiği kullanıcı tarafından belirlenmelidir. Bu yöntemler daha çok sınıflandırma için kullanılan yöntemlerdir. En yaygın olarak “Kohonen Ağları” ve “ART Ağları” yapay sinir ağı modellerinde kullanılır.



Şekil 2.5 Gözetimsiz Öğrenme Yöntemi

### 2.3.2.3. Destekleyici Öğrenme (Reinforcement learning)

Gözetimli öğrenme kuralına yakın bir metottur. Bu yöntemde de sisteme bir öğretmen yardımcı olur. Ağ çıkışından alınan değerler karşılaştırma için kullanılmaz fakat üretilen çıktının doğru ya da yanlış olduğunu gönderen bir sinyal ağa geri verilir. Sistem, öğretmenden gelen bu sinyali dikkate alarak öğrenmeyi gerçekleştirir. “LVQ Ağı” yapay sinir ağı modelinde kullanılır. (Masters, 1993)




Şekil 2.6 Destekleyici Öğrenme Yapısı (Masters, 1993)

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.


### 2.3.3 Yapay Sinir Ağının Eğitilmesi

Ağa gösterilen girdinin beklenen çıktıyı üretmesi için ağa başlangıç ağırlık değerleri rasgele verilir ve ağ zaman içinde öğrenerek ağırlıkları belirler. İstenen ağırlıklar bilinmemekle beraber hatanın en az olması istenir. Ağın öğrenmesi istenen olayın bir hata uzayının olduğu varsayılırsa,  $W^*$  en az hatanın olduğu ağırlık vektörünü göstermektedir.



Şekil 2.7 Öğrenmenin hata uzayındaki gösterimi (Öztemel, 2003)

Ağın problem için hatanın en az olduğu nokta olan  $W^*$  değerine ulaşması istenmektedir. O nedenle her iterasyonda  $\Delta W$  kadar değişim yaparak hata düzeyinde  $\Delta E$  kadar bir hatanın düşmesi sağlanmaktadır.



Şekil 2.8 Çok boyutlu hata uzayı (Öztemel, 2003)

Şekil 2.8’de daha karmaşık bir problem uzayı gösterilmektedir.  $W^*$  en iyi çözüm olmasına rağmen bu değeri yakalamak mümkün olmayabilir. Ağ, eğitim sırasında kendisi bu çözümü yakalamaya çalışmaktadır.

Bazen ise farklı bir çözüme takılabilmekte ve performansı daha iyileştirmek mümkün olamamaktadır. Bu nedenle kullanıcılar belirli bir tolerans değerine kadar hatayı kabul etmektedirler. Tolerans değerindeki noktalardaki çözümler için ağ öğrenmiş kabul edilir. Şekil 2.8’de görülen noktalardan  $W_0$  ve  $W_2$  tolerans değerinin üzerindedir, dolayısıyla bu çözümler kabul edilemez. Bunlara *yemel çözümler* denilmektedir.  $W_{11}$  ve  $W_3$  çözümleri ise en iyi çözüm olmamalarına rağmen tolerans değerinin altında bir hataya sahiptirler ve kabul edilebilir yemel çözümlerdir. Yapay sinir ağlarında birden fazla çözüm olabilir ve en iyi çözümün hangisi olduğunu bilmek çoğu zaman mümkün değildir. Bu nedenle yapay sinir ağlarının en iyi çözümü bulunduğu iddia edilemez.

En iyi çözüm bulamamanın sebepleri şunlar olabilir.

- Problem eğitilirken bulunan örnekler problem uzayını %100 temsil etmeyebilir.
- Oluşturulan yapay sinir ağı için doğru parametreler seçilmemiş olabilir.
- Ağın ağırlıkları başlangıçta tam istenildiği şekilde belirlenmemiş olabilir.
- Ağın topolojisi yetersiz seçilmiş olabilir.

Bazı durumlarda da ağın takıldığı yemel çözüm tolerans değerinin üstünde kalabilir. Bu durumda ağın olayı öğrenmesi için bazı değişiklikler yapılarak yeniden eğitilmesi gerekir. Başlıca yapılabilecek değişiklikler:

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

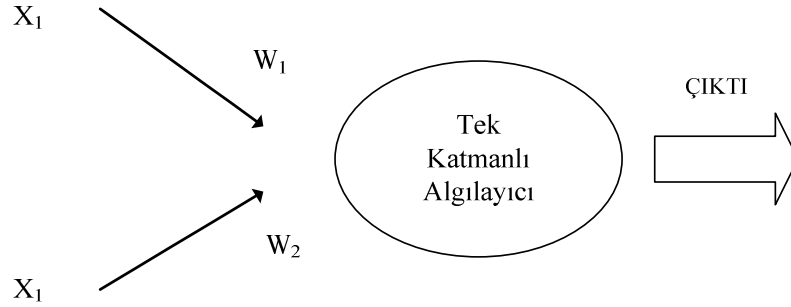


## 2.4 Yapay Sinir Ağı Modelleri

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.

### 2.4.1 Tek Katmanlı Algılayıcılar

Sadece girdi ve çıktı katmanından oluşan ağlardır. Her ağın bir veya daha fazla girdisi ve çıktısı vardır. Çıktı üniteleri (Ç) bütün girdi ünitelerine (X) bağlanmaktadır ve her bağlantının bir ağırlığı (W) vardır. Bu ağlarda proses elemanlarının değerinin sıfırdan farklı olmasını önleyen eşik değeri vardır ve bu daima 1'dir.



Şekil 2.9 Tek Katmanlı Algılayıcı (Öztemel, 2003)

Çıktı fonksiyonu doğrusal fonksiyondur. Ağa gösterilen örnekler iki sınıf arasında paylaştırılarak iki sınıfı ayıran doğru bulunmaya çalışılır. Bunun için eşik değer fonksiyonu kullanılır. Sınıf ayırıcı denilen doğru şu şekilde tanımlanır:

$$W1.X1 + W2. X2 + \Phi = 0 \quad (2.39)$$

Bu ağlarda öğrenmeden kasıt ağın sınıf ayırıcı doğrusunun pozisyonunu her iki grubu en iyi şekilde ayıracak şekilde belirlemektir. Bunun için ağırlık değerlerinin değiştirilmesi gerekir. t zaman biriminde ağırlık değerleri  $\Delta W$  kadar değiştirilir ve yeni ağırlık değeri;

$$W_i(t+1) = W_i(t) + \Delta W_i(t) \quad (2.40)$$

olur.

Ağırlıkların değiştirilmesi doğrunun eğimini değiştirmek anlamına gelir. Bunun yanında eşik değerinin de değiştirilmesi gerekir. t zaman biriminde eşik değeri  $\Delta\Phi$  kadar değiştirilir ve yeni eşik değeri;

$$\Phi(t+1) = \Phi(t) + \Delta\Phi(t) \text{ olur.} \quad (2.41)$$

Tek katmanlı algılayıcılar için önemli iki örnek Basit Algılayıcı (Perseptron) Modeli ve Adaline/Madaline Ünitesi modelidir.

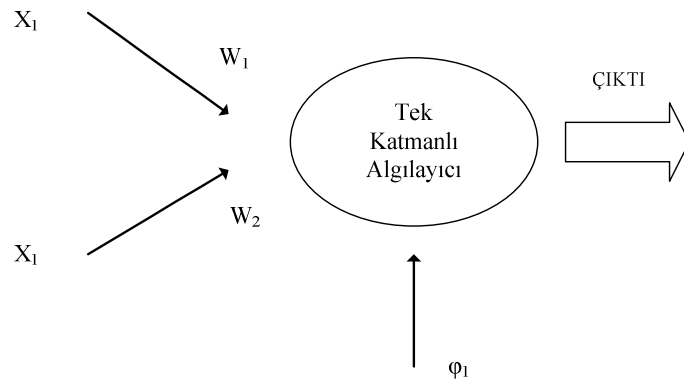
#### 2.4.1.1 Basit Algılayıcı (Perseptron) Modeli

İlk defa 1958 yılında Rosenblat tarafından 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. Öğrenme Basit Algılayıcı (Perseptron) Öğrenme kuralına göre gerçekleşir.

#### 2.4.1.2 ADALINE / MADALINE 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.

Öğrenme Delta Öğrenme Kuralına göre gerçekleşir. ADALINE ünitesini Basit Algılayıcıdan ayıran özellik öğrenme kuralıdır.



Şekil 2.10 ADALINE ünitesi (Öztemel, 2003)

## 2.4.2 Çok Katmanlı Algılayıcı (Geriye Yayım) Modeli

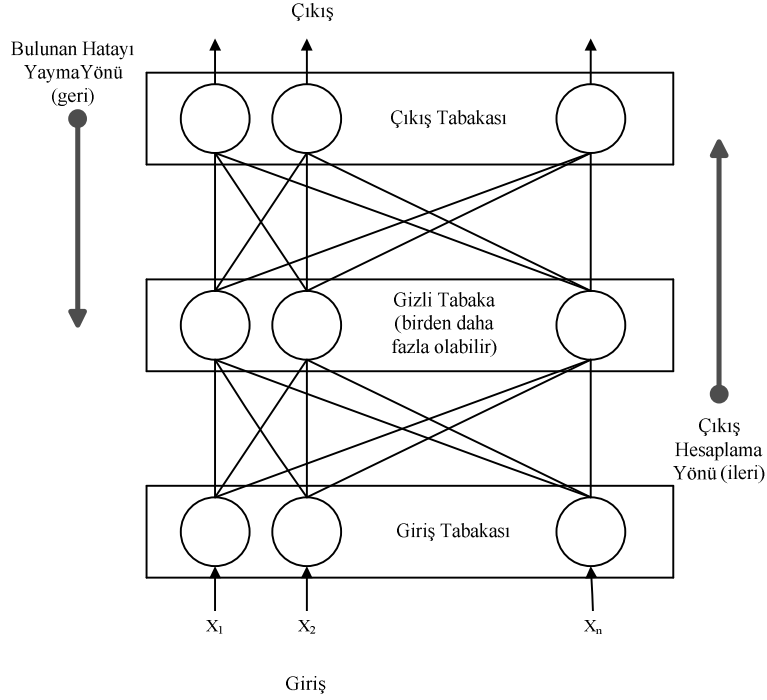
Bir yapay sinir ağının öğrenmesi istenen olayların girdi ve çıktıları arasındaki ilişkiler doğrusal olmayan ilişkiler olursa Tek Katmanlı Algılayıcılar ile öğrenme gerçekleştirmek mümkün değildir.

Günlük olayların çoğu doğrusal olmayan nitelik taşımaktadır ve doğrusal olmayan problemi çözmek için yeni modellerin geliştirilmesine ihtiyaç duyulmuştur. Doğrusal olmayan probleme verilebilecek en temel örnek XOR problemidir. XOR problemini çözmek amacı ile yapılan çalışmalar sonucunda Rumelhart ve arkadaşları Çok katmanlı algılayıcı modelini geliştirmiştir. Bu modele Geriye Yayım modeli (Backpropagation network) de denmektedir.

Tablo 2.1. XOR problemi (Öztemel, 2003)

Girdi 1	Girdi2	Çıktı
0	0	0
0	1	1
1	0	1
1	1	0

Çok Katmanlı Algılayıcı modeli mühendislik problemlerinin hemen hemen hepsine çözüm üretebilecek bir güce sahiptir. Özellikle sınıflandırma, tanıma ve genellemeyi yapmayı gerektiren problemlerin çözümünde kullanılır. Öğrenme olarak Delta Öğrenme Kuralını kullanılarak gerçekleştirilir. Hata ağa yayıldığı için ÇKA'nın kullandığı öğrenme kuralına Genelleştirilmiş Delta Öğrenme Kuralı denir.



Şekil 2.11 Çok Katmanlı Algılayıcı modeli

#### 2.4.2.1 Çok Katmanlı Algılayıcı Çalışma Prosedürü

Çok Katmanlı Algılayıcı ağlarının yapısı şekilde görüldüğü gibi Girdi Katmanı, Ara Katman ve Çıktı Katmanı olmak üzere üç katmandan oluşan bir ağıdır. ÇKA ağlarının çalışması aşağıdaki adımları içerir:

*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 topama 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.

#### **2.4.2.2 Çok Katmanlı Algılayıcı Ağının Eğitilmesi**

Çok katmanlı algılayıcı ağların eğitilmesi genel olarak ağların eğitilmesi ile aynı mantıktadır. Ağa gösterilen girdinin beklenen çıktıyı üretmesi için ağa başlangıç ağırlık değerleri rasgele verilir ve ağ zaman içinde öğrenerek ağırlıkları belirler. Ağ en az hatanın olduğu çözümü yakalamaya çalışır. Ancak bazen yerel çözüme takılabilir.

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

Çok katmanlı 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.



Şekil 2.12 Çok Katmanlı Algılayıcı ağının öğrenme eğrisi (Öztemel, 2003)

Çok Katmanlı ağın öğrenmesi sırasında şekil 2.12’de görüldüğü gibi bir eğri çıkar. Belirli bir iterasyondan sonra ağın öğrenme eğrisinin 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.

#### 2.4.2.3 XOR Probelminin Çözülmesi

XOR Problemi yapay sinir ağlarında bir devrin kapanıp bir devrin açılmasına neden olmuş önemli bir kilometre taşıdır. Çok Katmanlı Algılayıcının çalışma prosedürü XOR probleminde şöyle uygulanır:

##### 1. Adım: Örneklerin Toplanması

Tablo 2.2. Örnek XOR Problemi Tablosu

	Girdi 1	Girdi 2	Çıktı
Önek 1	0	0	0
Önek 2	0	1	1
Önek 3	1	0	1
Önek 4	1	1	0

**2. Adım:** *Ağın Topolojik Yapısının Belirlenmesi:*

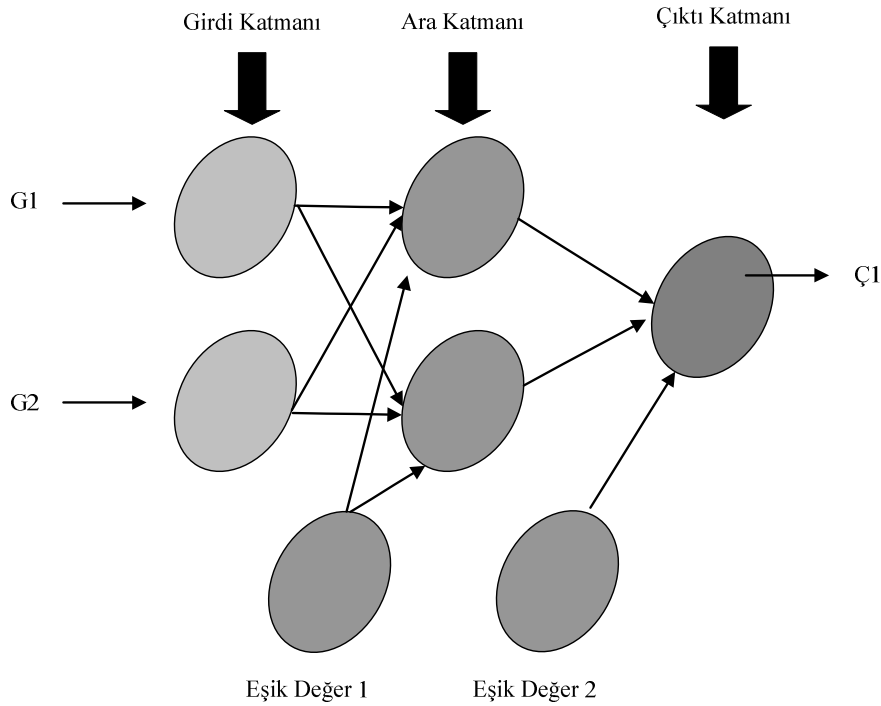
XOR probleminde 2 girdi ve 1 de çıktı olduğundan, oluşturulacak olan ÇKA ağının da 2 girdi ünitesi ve 1 çıktı ünitesi olacaktır.

1 ara katman ve 2 tanede ara katman proses elemanının bu problemi çözebileceği varsayılmaktadır.

**3. Adım:** *Öğrenme Parametrelerinin Belirlenmesi:*

Aktivasyon fonksiyonunun *sigmoid* fonksiyonu, Öğrenme  $\lambda$ , momentum (a) aşağıdaki gibi hesaplandığı varsayılmaktadır..

$$\lambda = 0.5 \quad a=0.8$$



Şekil 2.13 XOR Problemi İçin Tasarlanmış Bir Çok Katmanlı Algılayıcı Modeli (Öztemel, 2003)

**4. Adım:** *Ağırlıkların Başlangıç Değerlerinin Atanması:*

Oluşturulan ağ için ağırlık vektörleri ve başlangıç değerleri de şu şekilde belirlenmiş olsun.

Girdi katmanı ile ara katman arasındaki ağırlıklar  $A^i$  matrisi ile, çıktı katmanı ile ara katman arasındaki ağırlıklar  $A^a$  ile, eşik değer aralıkları ise  $\beta^a$  ve  $\beta^c$  ile gösterilsin,

$$A^i = \begin{vmatrix} 0.129952 & 0.570345 \\ -0.923123 & 0.328932 \end{vmatrix}$$

$$A^a = [0.164732 \quad 0.752621]$$

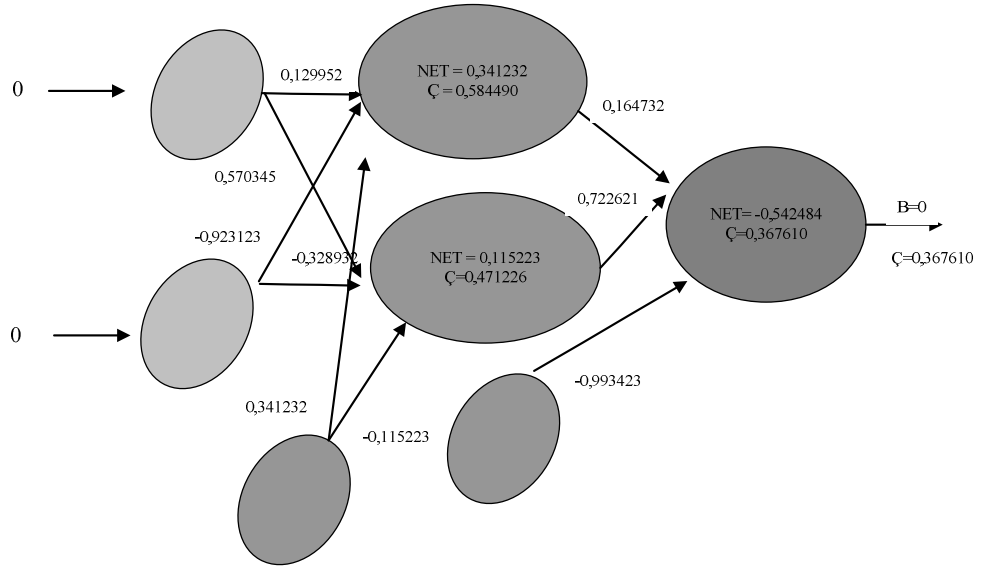
$$\beta^a = [0.341332 \quad -0.115223]$$

$$\beta^c = [-0.993423]$$

**5. Adım:** Örneklerin Ağa Gösterilmesi ve İleri Doğru Hesaplama:

Birinci örnek G1=0, G2=0 ve B=0 olarak belirlenmiştir.

Bu Örnek ağa gösterilirse, ileri doğru hesaplama Şekil-4.6'da gösterildiği gibi olacaktır.



Şekil 2.14 İleri doğru hesaplama (Öztemel, 2003)

Ara katman ünitelerinin NET girdileri (eşik değer ünitesinin ağırlık değerleri eklenmiş olarak) şu şekilde hesaplanır:

$$\text{Net1} = (0 * 0.129952) + (0 * -0.923123) + (1 * 0.341232) = 0.341232$$

$$\text{Net2} = (0 * 0.570345) + (0 * -0.328932) + (1 * -0.115223) = -0.115223$$



Ara katman ünitelerinin çıktıları ise şöyle hesaplanır:

$$\zeta_1 = 1 / [1 + e^{-0,341232}] = 0.584490$$

$$\zeta_2 = 1 / [1 + e^{0,115223}] = 0.471226$$

Çıktı katmanındaki proses elemanının NET girdisi;

$$\text{Net} = (1 * -0.993423) + (0.584490 * 0.164732) + (0.471226 * 0.752621) = -0.542484$$

bulunur. Bu değer ile ağın çıktısı;

$$\zeta = 1 / [1 + e^{0,542484}] = 0.367610$$

Beklenen çıktı 0 olduğuna göre ağın hatası:  $E = 0 - 0.367610 = -0.367610$  olur.

Bu hatanın geriye doğru yayılması sonucu ara katman ile çıktı katman arasındaki ağırlıkların değişim miktarları şu şekilde hesaplanır:

$$\partial_1 = \zeta_1 \cdot (1 - \zeta_1) \cdot E_1$$

$$\partial_1 = 0.367610 * (1 - 0.367610) * (-0.367610)$$

$$\partial_1 = -0.085459$$

$$\Delta A_{11}^a(t) = 0.5 * -0.085459 * 0.584490 + 0.8 * 0 = -0.024875$$

$$\Delta A_{21}^a(t) = -0.020135$$

$$\Delta \beta_1^c(t) = -0.042730$$

Ağırlıklardaki bu değişim miktarları ile ara katman ve çıktı katmanı arasındaki ağırlıklar yeniden hesaplanabilir.

$$A_{11}^a(t) = A_{11}^a(t-1) + \Delta A_{11}^a(t)$$

$$A_{11}^a(t) = 0.164732 - 0.024975 = 0.139757$$

$$A_{21}^a(t) = 0.752621 - 0.020135 = 0.732486$$

$$\beta_1^c(t) = -0.993423 - 0.042730 = -1.036153$$

Benzer şekilde, girdi katmanı ile ara katman arasındaki ağırlıkların değişim miktarları ve yeni ağırlık değerleri hesaplanır. Ara katmandaki hata oranları ve değişim miktarları şu şekilde bulunur:

$$\partial_1^a(t) = \zeta_1 (1 - \zeta_1) \partial_1 A_{11}^a(t-1)$$

$$\partial_1^a = 0.584490 * (1 - 0.584490) * (0.164732) * (-0.085459)$$

$$\delta_1^a = -0.034190$$

$$\delta_2^a = -0.160263$$

$$\Delta A_{11}^i(t) = 0.5 * -0.034190 * 0 + 0.8 * 0 = 0$$

$$\Delta A_{12}^i(t) = 0.5 * -0.034190 * 0 + 0.8 * 0 = 0$$

$$\Delta A_{21}^i(t) = 0$$

$$\Delta A_{22}^i(t) = 0$$

$$\Delta \beta_1^i(t) = 0.5 * 1 * -0.034190 = -0.017095$$


$$\Delta \beta_2^i(t) = 0.5 * 1 * -0.160263 = -0.080132$$

Bu değerleri kullanılarak ağırlıklar değiştirilir. Ağırlıklardaki değişim miktarı 0 olduğundan ağırlık değerlerinde herhangi bir değişiklik olmayacak ancak eşik değeri ağırlıklarında değişiklik olacaktır.

$$\beta_1^i(t) = 0.341232 - 0.017095 = 0.3242038$$

$$\beta_2^i(t) = 0.115223 - 0.081325 = -0.0350905$$

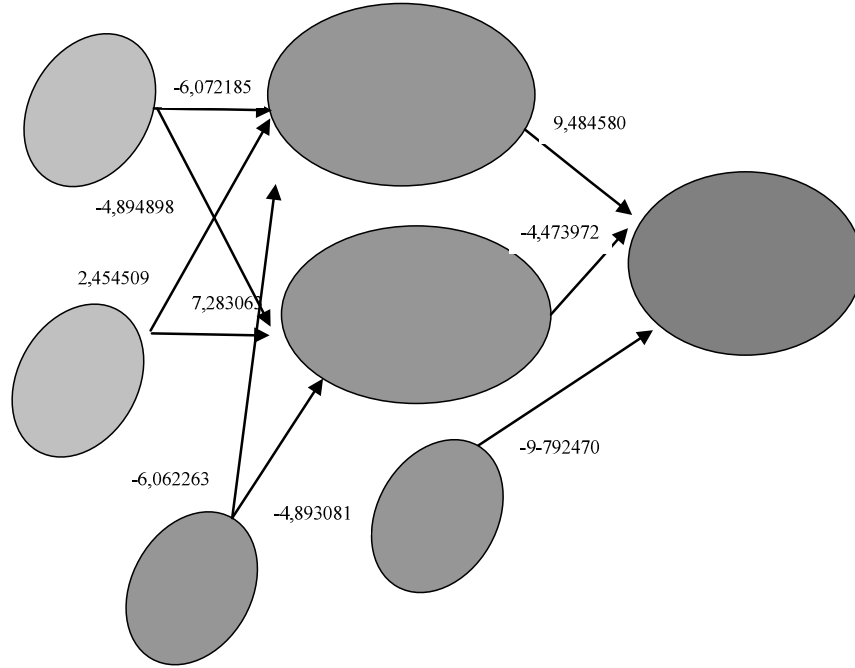
Şekil 1.15'de XOR ağının Ağırlıklar değiştirildikten sonraki durumu görülmektedir.



Şekil 2.15. XOR Ağının Ağırlıklar Değiştirildikten Sonraki Durumu (Öztemel, 2003)

Birinci iterasyon bittikten sonra ikinci iterasyon başlayacaktır. Bu kez ikinci örnek ağı gösterilir. G1=0, G2=1 ve B=1 olacaktır. Yukarıdaki işlemler aynı şekilde

tekrar edilir. Bu iterasyonlar bütün çıktılar doğru cevap verinceye kadar devam etmelidir.



Şekil 2.16 XOR Problemi Öğrendikten Sonraki Ağırlıklar (Öztemel, 2003)

Bu ağırlıklar ile girdiler ağıya tekrar gösterildiğinde o zaman Tablo-4.3'de gösterilen sonuçlar elde edilir. Bu sonuçlar ağıın problemi çok düşük hatalar ile çözebilecek şekilde öğrendiğini göstermektedir.

Tablo 2.3. XOR problemini öğrendikten sonra ağıın ürettiği çözümler ve hata oranları (Öztemel, 2003)

Girdi 1	Girdi 2	Beklenen çıktı	Ağıın çıktısı	Hata
0	0	0	0.017622	-0.017
1	0	1	0.981504	0.018
0	1	1	0.981491	0.018
1	1	0	0.022782	-0.020

#### 2.4.2.4 Çok Katmanlı Algılayıcı Ağıın Performansı

Bir yapay sinir ağıın performansının ölçülmesi öğrenme yeteneğinin ölçülmesidir. Ağıın eğitim setindeki örneklere doğru çözümler vermesi onun sadece

öğrendiğini gösterir ancak iyi öğrendiğini göstermez. İyi öğrenmesi görmedikleri örnekler üzerinde de doğru çalışmasıdır. Bunun için ağı eğitim setinden sonra bir de test seti verilir. Ağın performansı da bu test setine verdiği doğru cevaplara göre ölçülür.


Performans  $P$ , doğru cevap sayısı  $D$ , Test setindeki örnek sayısı  $T$  ile gösterilsin.

$$P = D / T \quad (2.42)$$

olur.

Eğer ağ örnek setine doğru cevaplar veriyor ancak  $P$  kabul edilebilir bir düzeyde değilse eğitimin iterasyonları artırılarak eğitime devam etmek gerekir. İterasyonlara rağmen hala gelişme olmuyorsa ağın öğrenme setini ezberlediği anlaşılır. Ağın günlük kullanıma alınması mümkün olmaz. Bu durumlarda aşağıdaki konular tekrar gözden geçirilerek eğitilmesi sağlanır.

- *Örnekleri seçilmesi* : Seçilen örnekler problem uzayını temsil edebilecek nitelikte olmalıdır.
- *Girdilerin ve çıktılarının nümerik gösterimi*: Yapay sinir ağları daha 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*: Proses elemanlarını birbirine bağlayan ağırlıkların başlangıç değerlerinin atanması ağın performansında önemli etkiye sahiptir. Eğer aralıklar büyük seçilirse ağ yerel çözümler arasında sürekli dolaşır, küçük seçilirse ise ağın öğrenmesi çok uzun sürer. Ağırlıkların başlangıç değerleri rasgele atanır. Tecrübeler -1.0 ile 0.1 arasındaki değerlerin başarılı sonuçlar ürettiğini göstermektedir. Öğrenmeyen bir ağın başlangıç değerlerinin değiştirilmesi ile ağın öğrenmesini sağlayabilir. Örneğin şekil 4.9'da görüldüğü gibi başlangıç değeri  $A$  seçilirse  $W1$  sonucuna,  $B$  seçilirse daha iyi çözüm olan  $W^*$  çözümüne ulaşılabilir.



Şekil 2.17 Çok Katmanlı Algılayıcı Ağlarında Başlangıç Noktasının Etkisi (Öztemel, 2003)

- *Öğrenme katsayılarının belirlenmesi:* Başlangıç değerleri kadar öğrenme ve momentum katsayılarının belirlenmesi de ağırlık öğrenme performansı ile yakından ilgilidir. Öğrenme katsayısı ağırlıkların değişim miktarını belirler ve eğer büyük değerler seçilirse yerel çözümler arasında ağırlık 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 katsayılarının 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 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 göstermektedir
- *Örneklerin ağırlık sunulması:* Genel olarak örnekler ağırlık sıralı sunum ve rastgele sunum olmak üzere iki türlü sunulabilirler. Sıralı sunumda eğitim setindeki örnekler sırayla ağırlık sunulurken, rastgele sunumda örnekler eğitim seti içinden

rasgele seçilerek sunulur. Sıralı sunumda örneklerin ağa gösterilme şansı eşittir. Rasgele sunuda 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 değiştirilme zamanları:* Ağırlıkların değiştirilmesi öğrenme kuralına göre yapılır. Genel olarak üç durumda ağırlıklar değiştirilir. Bu üç durum:
  - *Her örnek ağa gösterildiği durum (pattern based learning):* Ağa 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):* Ağa her örnek gösterildiğinde hatası hesaplanıp ağırlıklar değiştirilmez. Belirli sayıda örnek tek tek ağa gösterilir ve hatalar toplanır. 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. Girdi değeri  $x$ , ölçeklendirilmiş yeni girdi değeri  $x'$ , girdi vektörünün büyüklük (vektörel) değeri

$|x|$  olsun.

$$x' = x / |x|$$

Bazı arařtırmacılar ise ařağıdaki gibi bir formülasyon kullanmakta ve örnekleri oluřturan deęerleri belirli bir aralık içine çekmektedirler. Girdi setin olası en küçük deęeri  $x_{min}$ , girdi setindeki olası en büyük deęeri  $x_{max}$  olsun.

$$x' = [x - x_{min}] / [x_{max} - x_{min}] \quad (2.42)$$

Bazı arařtırmacılar ise kendi problemlerine özgü ölçeklendirme yöntemleri geliřtirmektedirler. Burada önemli olan hangi yöntem kullanıldıęından çok girdiler için olumsuz etkileri önleyecek řekilde ölçeklendirme yapmaktır.

- *Çıktıların Ölçeklendirilmesi* : Çok katmanlı algılayıcı aęlarında genel olarak *sigmoid* aktivasyon fonksiyonu kullanılır ve bu fonksiyon sadece 0 ve 1 arasında bir deęer üretir. Eęer çıktı deęerlerinin 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 deęerlerine dönüřtürülmeleri gerekir.
- *Durdurma Kriterinin belirlenmesi* : Aęın eęitilmesi kadar aęın gereęinden fazla eęitilmesinin önlenmesi de önemlidir. Aę çözümlü bulduktan sonra eęitime devam edilirse aęın aęırlıklarında deęişiklik devam edebilir ve aę daha düşük performanslı bir aęa dönüřebilir. Bu nedenle eęitim belirli bir zaman sonra durdurulmalıdır. Durdurma için iki türlü kriter kullanılır.

- *Hatanın belirli bir deęerin düřmesi durumunda eęitimi durdurma*: Tolerans deęeri probleme göre deęişebilir. Hata belirlenen tolerans deęerlerinin altına indięi zaman eęitim durdurulur.
- *Aęın belirli bir iterasyon sayısını tamamlaması sonucu eęitimi durdurma*: Hata grafikleri çizilerek gerekli iterasyon sayısı tespit edilebilir ve bu sayıya ulařıldıęında eęitim durdurulur. Tolerans deęerinin belirlenmesinin zor olduęu durumlarda kullanılabilir.

*Ara katmanların ve her katmandaki 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 gerektięini 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. (Öztemel, 2003)

### 2.4.3 LVQ Modeli (Destekleyici Öğrenme)

LVQ ağı Kohonen tarafından 1984 yılında geliştirilmiştir.  $n$  boyutlu bir vektörü bir vektörler setine haritalamak (uydurmak) mantığına dayanır. LVQ ağları genel olarak sınıflandırma problemlerinin çözümünde kullanılmaktadırlar.

#### 2.4.3.1 LVQ Ağının Yapısı

Öğrenme, girdi vektörünün hangi vektör seti (referans vektör) tarafından temsil edilmesi gerektiğinin bulunmasıdır. LVQ ağının görevi öğrenme yolu ile vektör setini yani girdi vektörlerinin üyesi olabilecekleri vektör sınıfını belirlemektir. Kohonen öğrenme kuralına göre öğrenir. Çıktılardan sadece birisi 1, diğerleri 0 değerlerini alır ve çıktı değerinin 1 olması girdinin ilgili çıktının temsil ettiği sınıfa ait olduğunu gösterir.

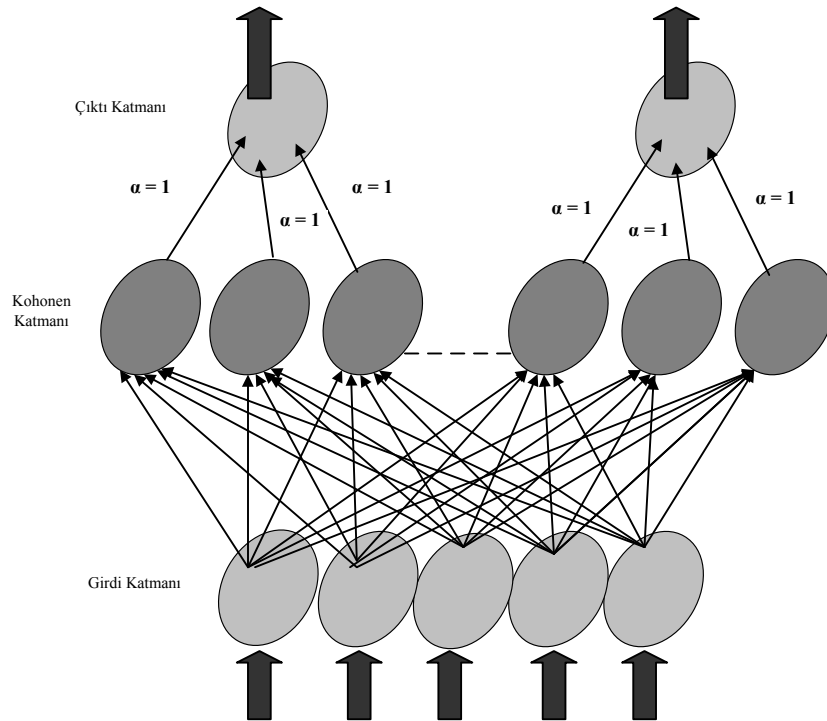
Eğitim sırasında girdilerin sınıflara ayrılması en yakın komşu kuralına göre gerçekleştirilir. Girdi vektörü ile referans vektörleri arasındaki en kısa mesafe aranmakta ve girdi vektörünün en kısa mesafede bulunan vektör grubuna ait olduğu varsayılır ve ağın ağırlıkları değiştirilerek girdileri doğru sınıflara ayıracak referans vektörleri belirlenir. Kullanılan öğrenme stratejisi destekleyici *{reinforcement learning}* öğrenmedir. Çıktı değerlerinin belirlenmesinde ise *"kazanan herşey alır"* (*winner takes all*) stratejisi uygulanmaktadır. Ağ eğitilirken her iterasyonda ağın ürettiği çıktının değeri yerine sadece doğru olup olmadığı söylenir. Sadece girdi vektörüne en yakın olan vektör'ün (kazanan vektör) değerleri (ağın bu vektöre ait ağırlıkları) değiştirilir.



LVQ ağında da ağırlıklar öğrenme katsayısına göre değiştirilir ve öğrenme katsayısının zamanla sıfır olacak şekilde azaltılması istenir. LVQ ağında öğrenme Çok katmanlı algılayıcı ağılara göre daha hızlı gerçekleşir.

LVQ ağıları da üç katmandan oluşur.

- *Girdi katmanı*: Bu katmanda bilgi işleme olmaz, gelen bilgiler girdi vektörünü oluşturur. Bu katmandaki her proses elemanı Kohonen katmanındaki her proses elemanına bağlıdır. Girdi katmanı ve Kohonen katmanındaki ağırlıklar değiştirilerek öğrenme sağlanır.
- *Kohonen katmanı* : Bu katmanda girdi setine en yakın olan ağırlık vektörü belirlenir. Bu katmandaki her eleman bir referans vektörünü gösterir ve girdi değerlerini *Kohonen* katmanındaki proses elemanlarına bağlayan bağlantıların ağırlık değerlerinden oluşur. Referans vektörünün eleman sayısı girdi katmanındaki eleman sayısı kadardır.
- *Çıktı katmanı*: Bu katmanda ise girdinin ait olduğu sınıf belirlenir. *Kohonen* katmanındaki proses elemanları çıktı katmanındaki bir tek proses elemanına bağlıdır. *Kohonen* katmanı ile çıktı katmanı arasındaki ağırlıklar ( $\alpha$ ) sabit olup 1'e eşittir. (Kohonen,1987)



Şekil 2.18 LVQ Ağıнын Yapısı (Öztemel, 2003)

### 2.4.3.2 LVQ Ağının Çalışma Prosedürü

LVQ ağlarını aşağıdaki prosedüre göre çalıştırılır.

1. Örneklerin belirlenir.
2. Ağm topolojisinin belirlenir. (girdi ve çıktı sayısının belirlenmesi, referans vektör sayısının belirlenmesi)
3. Ağın öğrenme parametrelerinin belirlenir. (öğrenme katsayısı ve istenen sabit değerlerin belirlenmesi)
4. Ağırlıkların başlangıç değerlerinin atanır.
5. Öğrenme setinden bir örneğin ağa gösterilir.
6. Kazanan proses elemanını bulunur.
7. Ağırlıkların değiştirilir.
8. Bütün örnekler doğru sınıflandırılıncaya kadar 5-7 arasındaki adımlar tekrarlanır.

### 2.4.4 Adaptif Rezonans Teori (ART) Ağları Modeli (Öğretmensiz Öğrenme)

ART ağları Grosbeg'in 1976 yılında biyolojik beynin fonksiyonlarına yönelik olarak yaptığı çalışmalar neticesinde ortaya çıkmıştır. Ağ dışarıdan herhangi bir destek almaksızın örneklere bakarak bilgileri kendisi keşfetmek ve hafızasında saklamak durumundadır. Öğrenme doğru bilgilerin belirlenerek hafızaya alınması anlamına gelmektedir. Öğrenme sırasında kullanılan örneklerden öğrenilen bilgilere dayanarak daha sonra görülmemiş örnekler hakkında yorumlar yapılabilmektedir.

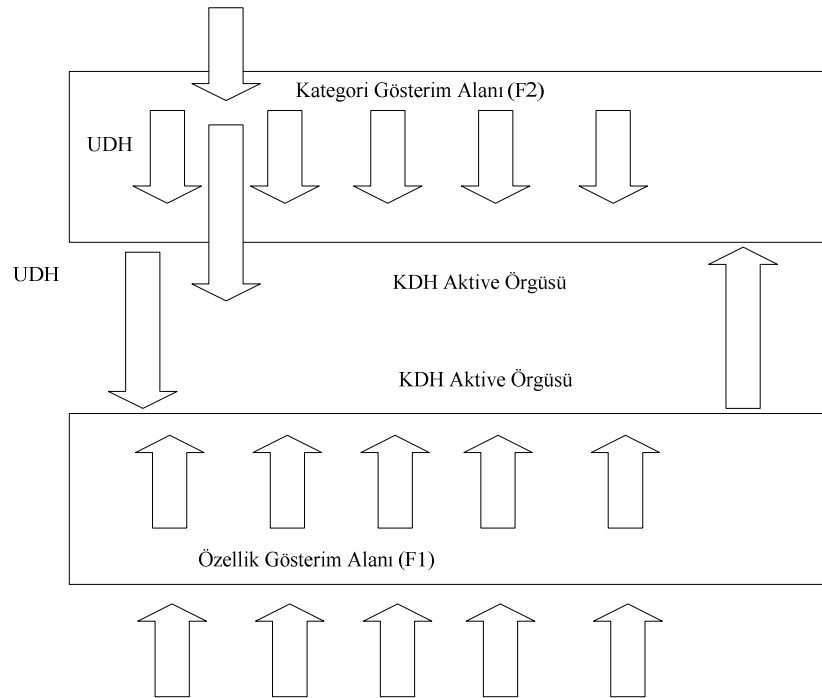
#### 2.4.4.1 ART Ağlarının Yapısı

Bu modelin üç temel özelliği vardır:

- Normalizasyon: Çevredeki büyük değişikliklere karşı adaptif olma durumudur.
- Ayrıştırabilme : Çevredeki ayrıntı seviyedeki değişiklikleri farkedebilme durumudur.
- Ayrıntıların saklandığı kısa dönemli hafıza: Belirlenen farklılıklar önce hafızada saklanır ve sonra davranışa dönüşür. Anlık kararlarda ani

değişimlerin tutulduğu kısa dönemli hafıza etkili olurken uzun karar vermede uzun dönemli hafıza etkili olmaktadır.

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.




Şekil 2.19 ART Ağının Genel Yapısı (Öztemel, 2003)

#### 2.4.4.2 ART Ağlarının Çalışma Prensibi

ART ağlarında F1 katmanından gelen bilgiler F2 katmanındaki kategorilerle eşleşir. Eşleme sağlanmaz ise yeni bir kategori oluşturulur. ART ağlarının çalışması iki yönlü olmaktadır:


- Aşağıdan yukarı (F1'den F2'ye) bilgi işleme: Bir girdi örüntüsü ağa gösterilir. Bu örüntü F1 katmanında kısa dönemli hafızada aktivite örüntüsünü oluşturur ve

yeniden yerleştirme modülünü aktif etmek üzere bir işaret gönderir. Aktivite örüntüsü de yeniden yerleştirme modülüne men edici işaret gönderir ve F1 katmanın çıktısını oluşturur. Çıktı F2 katmanında bir girdi örüntüsüne dönüştürülür. Bu örüntüde F2 katmanının çıktı örüntüsünü oluşturur.



Şekil 2.20 Aşağıdan Yukarıya Bilgi İşleme (Öztemel, 2003)

- Yukarıdan aşağı (F2'den F1'e) bilgi işleme : F2 katmanında oluşturulan çıktı örüntüsü yukarıdan aşağıya bir sinyal gönderir. Bu sinyal daha sonra beklenen şablon örüntüye dönüştürülür. Aynı zamanda kontrol faktörü (kazanç) için men edici bir işaret oluşturur. Şablon örüntü ile girdi örüntüsünün eşlenip eşlenmeyeceği denir. Eşleme mümkün değilse F1 katmanında kısa dönemli hafıza örüntüsü oluşturulur. Bu örüntü de yeniden yerleştirme modülündeki men edici işaretin etkisini azaltır.



Şekil 2.21 Yukarıdan Aşağıya Bilgi İşleme (Öztemel, 2003)

#### 2.4.4.3 ART Ağlarının Diğer Yapay Sinir Ağlarından Farkları

- ART ağları bir çok ağın tersine gerçek zamanlı, hızlı ve kararlı öğrenirler. Diğer ağlar ise çoğu zaman çevrimdışı öğrenirler ve ortama anlık olarak uyum sağlayamazlar.
- ART ağları öğretmensiz öğrenir.
- ART ağları ağa sunulan değişik durumlardaki örnekler karşısında kendi kendilerine kararlı bir yapı oluşturabilirler.
- ART ağlarında öğrenme süreklidir ve Uzun dönemli hafızada bulunan ağırlıklar sürekli güncellenir.
- ART ağları girdi değerlerini otomatik olarak normalize ederler.
- ART ağlarında hem aşağıdan yukarı hem de yukarıdan aşağıya ağırlık değerleri vardır. Aşağıdan yukarı gelen bilgiler ile karşılaştırma kısa zamanlı hafızada (KDH) oluşur. Yukarıdan aşağı ağırlıklar KDH'da yapılan karşılaştırma ile aynı kategoride olmayan girdilerin o kategoriye girmesini önlerler.
- ART ağları yakın eşleme özelliği sayesinde hem hızlı hem de yavaş öğrenebilirler. Hızlı öğrenme uzun dönemli hafızada (UDH) bir denemede yeni

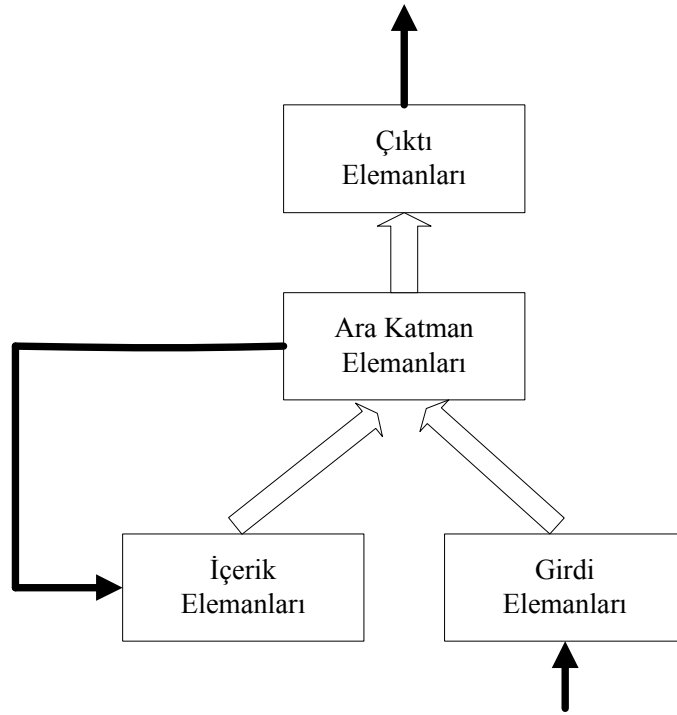
bir dengenin (*equilibrium*) oluşturulması ile gerçekleştirilir. Yavaş öğrenme ise bir dengenin oluşması için birden çok denemenin yapılmasıdır. (Grosberg, 1990)

#### 2.4.4. Diğer Yapay Sinir Ağı Modelleri

##### 2.4.4.1 Elman Ağı

Ağların çoğunluğu ileri beslemeli ağlardır. Proses elemanları çıktıları bir sonraki proses elemanına veya dış dünyaya gönderirler. Geri dönüşümlü ağlarda ise çıktılar ağa bir şekilde girdi olarak gönderilir ve kullanılır. Elman ağı geri dönüşümlü ağlar içinde en yaygın kullanılanıdır. Elman ağı, Çok katmanlı Algılayıcılarda olduğu gibi genelleştirilmiş delta kuralına göre öğrenir. Elman ağının 4 çeşit proses elemanı vardır:

- Girdi elemanları
- Ara katman elemanları
- Çıktı elemanları
- İçerik (*context*) elemanları



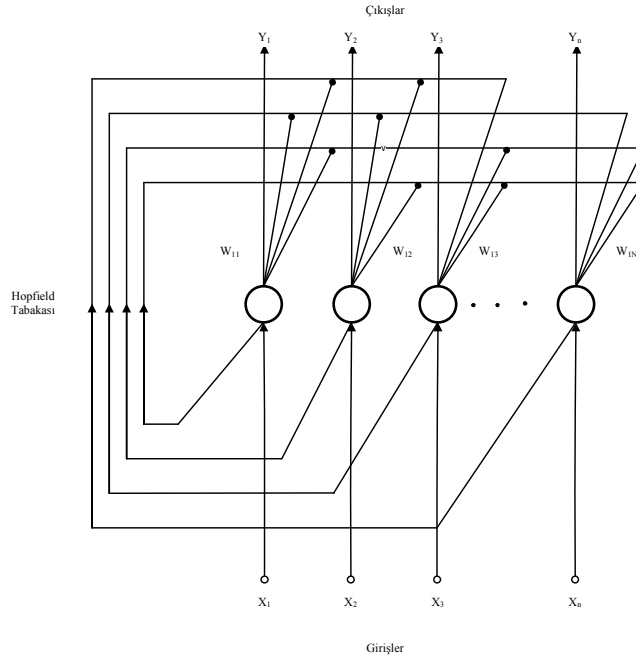
Şekil 2.22 Elman Ağının Yapısı (Öztemel, 2003)

Girdi ve çıktı elemanları dış dünya ile etkileşim halindedir. Girdi elemanları dış dünyadan bilgileri alır ara katmanlara olduğu gibi iletirler. Çıktı ünitelerinin bilgi işleme fonksiyonları doğrusaldır. Ara katman elemanları ise hem doğrusal hem de doğrusal olmayan aktivasyon fonksiyonlarına sahip olabilirler. İçerik elemanları ara katman elemanlarının bir önceki iterasyondaki aktivasyon değerlerini bir sonraki iterasyona girdi olarak taşırlar. İleri beslemeli bağlantıların ağırlıkları eğitim sırasında değiştirilebilirler. Geri dönüşümlerin (bağlantı ağırlıkları ise sabittir. Geri dönüşümlerin ağırlıkları sabit olduklarından Elman ağına kısmı geri dönüşümlü ağ denir.

Elman ağı herhangi bir zamandaki girdi değerleri hem de ara katmanların önceki aktivite değerleri ağı girdi olarak verilirler. Ağın girdileri belirlendikten sonra ağ artık ileri beslemeli bir çok katmanlı algılayıcıya dönüşür. Bu girdiler kullanılarak ileri doğru ağın çıktıları belirlenir. (Elman, 1990)

#### 2.4.4.2 Hopfield Ağı

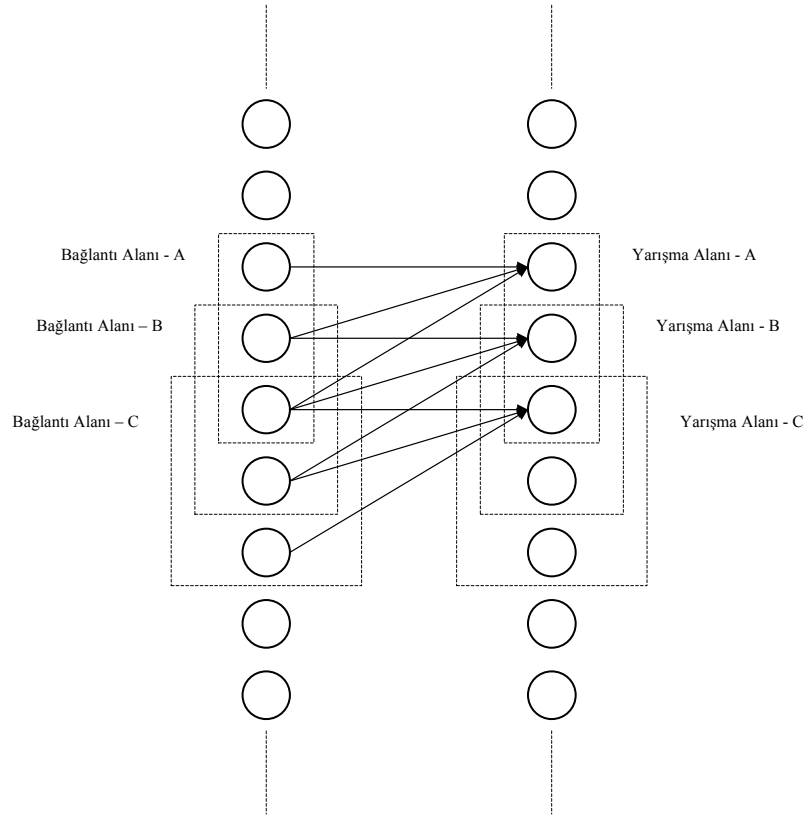
*Hopfield* ağı tek katmanlı ve geri dönüşümlü bir ağıdır. Proses elemanlarının tamamı hem girdi hem de çıktı elemanlarıdır. Proses elemanlarının hepsi birbirine bağlıdır. Ağ bağlantı değerleri bir enerji fonksiyonu olarak saklanır. Kesikli Hopfield Ağı ve Sürekli Hopfield Ağı olmak üzere iki tür modeli vardır. Zor optimizasyon problemlerinin çözümünde kullanılırlar. (Hopfield, 1982)



Şekil 2.23 Hopfield Ağının Yapısı (Öztemel, 2003)

### 2.4.4.3 Cognitron ve Neocognitron Ağları

*Cognitron* ağı Fukushima tarafından insan beyninin görsel sisteminin görevini üstlenmek amacı ile geliştirilmiştir. Neocognitron ağı ise *cognitron* ağının gelişmiş modelidir. Bağlantı alanlarından oluşan birinci katman ve yarışma alanlarından oluşan ikinci katman olmak üzere iki katmandan oluşurlar. Uyarıcı ve men edici olmak üzere iki tür proses elemanı vardır. Çıktı değeri uyarıcı ve men edici işaretler göre belirlenir. Daha çok tanıma problemleri için kullanılmaktadırlar. (Fukushima, 1982)



Şekil 2.24 Cognitron Ağının Yapısı (Öztemel, 2003)



### 3. TALEP TAHMİNİ

#### 3.1 Talep Tahmini Kavramı

Talep, tüketicilerin bir ürün veya hizmeti belirli bir fiyat seviyesinden almaya hazır oldukları miktara denir. (Tekin, 1996). Talep tahmini ise, gelecekteki bir zaman süresi için şirketin bir ürünü veya çeşitli ürünleri için talep düzeyini tespit etmektir. (Acar, 1989) Talep aynı zamanda satış olacağı için “talep tahmini” yerine “satış tahmini” terimi de kullanılabilir.

Talep tahmini, şirket yönetiminin stratejik ve taktik kararların alınmasında, kısa dönemli ve uzun dönemli hedeflere ulaşmada kullanılacak en temel araçların başında gelir. Etkin bir talep planlama ile şirket fonksiyonları optimum kar seviyesine doğru ilerler, stratejik hedefler ile operasyonel gereksinimler arasındaki çatışma azalır (Bolt, 1994).

Talep tahmini belirli ilkelere ve yöntemlere göre yapılır. Ancak hangi yöntem kullanılırsa kullanılsın, yapılan tüm talep tahminlerinin belli bir doğruluk derecesi sözkonusudur ve hiç bir tahmin %100'lük bir doğruluk derecesine sahip olamaz.

Ürün özellikleri ve talep yöntemi, yapılacak tahmin tipi ve kapsayacağı zaman süresini etkiler. Eğer ürüne olan talep genel itibariyle sabit ise, tahminin zaman süresi biraz daha kısa tutulabilir. Ürüne olan talepte dalgalanmalar varsa , tahmin hiç olmazsa bir dönemi kapsamına almalıdır. Talepte uzun dönemde bir eğilim bekleniyorsa, daha uzun dönemli bir tahmin yapmak gerekir. Bazı ürünler için talep değerleri mevsimlere göre azalır veya çoğalır. Böyle durumlar ise talepteki mevsimsel değişmelerin nedenini iyi belirlemek ve mevsimsel tahmin yöntemleri kullanmak gerekir. (Acar, 1999)

Talep tahminleri genellikle dört döneme göre yapılır. Bu dönemler şunlardır: (Tekin, 1996)

- *Çok kısa süreli tahminler:* Günlük ve haftalık tahminler olabilir. Yedek parça kontrolü, stokların kontrolü, yeniden sipariş verme, iş programının hazırlanması amacıyla yapılabilirler.

- *Kısa süreli tahminler:* 1 haftadan 6 aya kadar olan tahminlerdir. Uygun sipariş miktarının belirlenmesi, makine ve işgücü ayarlamaları amacıyla yapılabilirler.
- *Orta süreli tahminler :* 6 aydan 5 yıllık sürelelere kadar yapılan tahminlerdir. Tedarik süresi belirsiz veya uzun olan malzeme alımlarını planlama, sermaye ve nakit bütçeleri hazırlama amacıyla yapılabilirler.
- *Uzun süreli tahminler:* 5 yıl ve daha uzun süreli olarak yapılan tahminlerdir. Tesis yatırımları, sermaye planlaması amacıyla yapılabilirler.

Talep tahminlerinde gözönünde bulundurulması gereken önemli ilkeleri şöyle açıklanabilir: (Acar, 1998)

- Miktar veya çeşit bakımından büyük olan gruplar için yapılan tahminler daha doğrudur.
- Tahminlerin kapsadığı zaman aralığı kısaltıkça doğruluk artar.
- Her talep tahmin araştırmasında kabul edilebilecek bir hata oranı yer almalıdır.
- Herhangi bir talep tahmin araştırmasının sonuçlarını uygulamaya geçmeden önce kullanılan yöntem denenmelidir.

### **3.2 Talep Tahmini Aşamaları:**

Talep tahmini temel olarak beş aşamada gerçekleştirilir. Bu aşamalar:

*1.Talebi Etkileyen etkenlerin belirlenmesi:* Talep tahmini yapmadan önce şirketin hangi çevre ortamında bulunduğu, hangi ürünleri ürettiği, şirketin şimdiki durumu ve gelecekte ulaşmak istediği durum, rakiplerin durumu, fiyat ve talep ilişkisi, iktisadi değişimler, endüstriyel değişimler, teknolojik gelişim, sosyal değişimler, ulusal ve uluslararası eğilimler gibi talebi etkileyen etkenler ve ağırlıkları belirlenmelidir. (Bolt, 1994)

*2.Verilerin Toplanması:* Talep etkenleri gözönünde bulundurularak planlamaya temel olacak veriler toplanır. Veri olarak genellikle geçmiş gerçek veriler, istatistiksel olasılıklar ve hedef verilerden oluşur. Verilerin derlenmesinde iç kaynaklar, şirket tarafından yapılan anket ve tahmin araştırması, yayınlanmış istatistik verileri, yayınlanmış anketler ve iktisadi veriler kullanılabilir. (Bolt, 1994)

3. *Talep tahmin periyodunun tespiti:* Talep araştırması sonuçlarının kullanılış amacı ile periyodun uzunluğu arasında yakın bir ilişki vardır. Örneğin, haftalık yapılan tahminlerin uzun dönemlerde kullanılması son derece yanıltıcı sonuçlar verebilir. (Tekin, 1996)

4. *Tahmin yönteminin seçimi:* Talep Tahmini çevresel ve iç etkenlere bağlı olarak oldukça karmaşık bir problemdir. Talep Tahmini yöntemi olarak Nesnel ve Öznel yöntemler kullanılabilir. Nesnel yöntemler istatistiksel ve matematiksel verilere dayanan yöntemlerdir. Öznel yöntemler ise matematiksel verilerden daha çok tecrübenin uygulanmasına, yargılama ve zekaya dayanan yöntemlerdir. İdeal talep tahmini yöntemi ise Nesnel ve Öznel yöntemlerinin karışımıdır. (Bolt, 1994)

5. *Tahmin sonuçlarının geçerliğinin araştırılması:* Tahmin sonuçlarının gerçek değerlerle karşılaştırılması ve hatanın sistematik bir şekilde tespit edilmesi gerekir.

### **3.3 Talep Tahmini Yöntemleri:**

Talep tahmininde kullanılan veriler genellikle ürüne olan talebin belirli aralıklarla gözlemlenmesi sonucu elde edilir. Genelde tahmin geçmişin geleceğe yansıtılması şeklinde de düşünülebilir. (Acar, 1989)

Üretilen mal ve hizmetlerle birlikte tüketici davranışının da farklı oluşu nedeniyle tek bir talep tahmin yönteminden bahsetmek imkansızdır. Talep Tahmininde kullanılan yöntemler temel olarak Öznel yöntemler ve Nesnel yöntemler olmak üzere ikiye ayrılır. (Bolt, 1994)

#### **3.3.1 Öznel Tahmin Yöntemleri**

Öznel yöntemler matematiksel verilerden daha çok tecrübenin uygulanmasına, yargılama ve zekaya dayanan yöntemlerdir. En çok kullanılan Öznel yöntemler şunlardır: (Tekin, 1996)

##### **3.3.1.1 Yönetici ve Satış Elemanlarının Tahminlerini Toplama**

Üretim, satınalma, mali işler ve idari yöneticiler gibi bölüm yöneticileri ile satış elemanlarının tecrübe ve sezgileri dikkate alınarak talep tahmini yapılır. Araştırmacılar bütün yönetici ve görevlilerle tek tek görüşerek bilgi toplar. Bu değerlerde kişisel değerlendirme ve sezgisel faktörler öne çıktığı için tahmin

sonuçlarının hatalı olma ihtimali yüksektir. İstatistiki yöntemlerle birlikte kullanılarak hata oranı azaltılabilir.

### **3.3.1 .2 Tüketici Anketleri**

Örnekleme yoluyla tüketici gruplarına anket yapılarak talep tahmini yapılabilir. Gelen cevaplar istatistik yöntemleri yardımıyla bütün tüketicileri kapsayacak şekilde analiz edilerek, talep tahmini yapılmaya çalışılır. Tahmin sonuçlarının tutarlı olması için seçilecek tüketici grubu doğru bütün tüketicileri temsil edecek şekilde seçilmeli ve örneklemedeki kişilerin sorulara doğru cevap vermiş olmaları gerekir.

### **3.3.2 Nesnel Tahmin Yöntemleri**

Nesnel yöntemler istatistiksel ve matematiksel verilere dayanan yöntemlerdir. En çok kullanılan yöntemler şunlardır: (Tekin, 1996)

#### **3.3.2.1 Regresyon Analizi , En Küçük Kareler Yöntemi ve Korelasyon Katsayısı**

Regresyon analizi, aralarında sebep-sonuç ilişkisi bulunan iki veya daha fazla değişken arasındaki ilişkiyi belirlemek ve bu ilişkiyi kullanarak konu ile ilgili tahminler ya da kestirimler yapabilmek amacıyla yapılır. Bu analiz tekniğinde iki (basit regresyon) veya daha fazla değişken (çoklu regresyon) arasındaki ilişki açıklamak için matematiksel bir model kullanılır ve bu model regresyon modeli olarak adlandırılır.

Basit regresyon modeli;

a : Sabit Katsayı,

b : Regresyon katsayısı,

X : Bağımsız değişken,

Y: Bağımlı değişken,

e : Hata terimi,

$$Y= a + bX + e \quad (3.1)$$

şeklinde ifade edilir.

Çoklu regresyon modeli ise,

$$Y=a_0 + a_1X_1 + a_2X_2 + a_3X_3 + \dots e \quad (3.2)$$

şeklinde ifade edilir.

En Küçük Kareler Yöntemi, basit doğrusal, çoklu regresyon modellerinin çözümlenmesinde kullanıldığı gibi, çok denklemlı ekonometrik modellerin çözümünde de kullanılan tekniklerin temelidir. Eğilim hesaplamasında en çok kullanılan yöntemdir. İki değişken arasındaki ilişkinin belirlenmesi için en uygun doğrunun çizilmesi esasına dayanır. Doğrunun tanımlanması için doğrunun bağımlı değişken eksenini kestiği noktanın ve doğrunun eğiminin bilinmesi gerekir. Çizilen doğru üzerindeki bağımlı değişken değerleriyle, gerçek değerler arasındaki farkın karelerinin toplamını minimum yapacak doğru bulunmaya çalışılır.

Kurulan regresyon modeli,

$$y= a + bx \text{ olsun.}$$

a : Sabit Katsayı

b : Doğrunun eğimi

x : Bağımsız değişken

y : Bağımlı değişken

n : Gözlem sayısı


olmak üzere basit doğrusal regresyon modelinin a ve b katsayıları şu şekilde hesaplanır:

$$\sum y = na + b\sum x \quad (3.3)$$

$$\sum xy = a\sum x + b \sum x^2 \quad (3.4)$$

$$a = [\sum y \sum x^2 - \sum x \sum xy] / [n\sum x^2 - (\sum x)^2] \quad (3.5)$$

$$b = [n\sum xy - \sum x \sum y] / [n\sum x^2 - (\sum x)^2] \quad (3.6)$$



Şekil 3.1 En Küçük Kareler Yöntemi (Tekin, 1996)

Korelasyon katsayısı ise iki değişken arasındaki ilişkinin derecesini gösterir.

Y: Bağımlı değişkenin gerçek değeri


Y': bağımlı değişkenin hesaplanmış değeri

$\bar{Y}$  : bağımlı değişkenin gerçek değerlerinin ortalaması olmak üzere korelasyon katsayısının (r) formülü aşağıdaki şekilde hesaplanır:

$$r = \sqrt{1 - \frac{(\sum Y - Y')^2}{\sum (Y - Y')^2}} \quad (3.7)$$

veya

$$r = 1 - \frac{[n\sum XY - (\sum X)(\sum Y)]}{[\sqrt{n\sum X^2 - (n\sum X)^2} \sqrt{n\sum Y^2 - (n\sum Y)^2}]} \quad (3.8)$$



Şekil 3.2 Korelasyon Katsayısı (Tekin, 1996)

Korelasyon katsayısı'nın aldığı değerler aşağıdaki şekilde yorumlanır:

0.90 - 1.00 : Çok yüksek korelasyon

0.70 - 0.90 : Yüksek korelasyon

0.40 - 0.70 : Normal korelasyon

0.20 - 0.40 : Düşük korelasyon

0.00 - 0.20 : Çok düşük korelasyon

Korelasyon uygulamasına şöyle bir örnek verilebilir:

Konya Şeker Fabrikasında 10 yıl içinde gerçekleştirilen üretim bilgileri aşağıdaki tabloda verilmiştir:

Tablo 3.1. Konya Şeker Fabrikası Üretimi (Tekin,1996)

Yıllar (x)	Satış Miktarı (Ton) (y)
1981	132.689
1982	124.776
1983	174.210
1984	174.854
1985	122.920
1986	103.047
1987	123.380
1988	117.307
1989	128.270
1990	84.230

Tablo 3.2 Konya Şeker Fabrikası Üretimi (Tekin,1996)

Yıllar (x)	Satış Miktarı (Ton) (y)	xy	$x^2$
1981 (1)	132.689	132.689	1
1982 (2)	124.776	249.552	4
1983 (3)	174.210	552.630	9
1984 (4)	174.854	699.416	16
1985 (5)	122.920	614.600	25
1986 (6)	103.047	618.882	36
1987 (7)	123.380	863.660	49
1988 (8)	117.307	938.456	64
1989 (9)	128.270	1.154.430	81
1990 (10)	84.230	842.300	100



$$\sum x = 55$$

$$\sum y = 1.285.683$$

$$\sum xy = 6.636.015$$

$$\sum x^2 = 385$$

$$(\sum x)^2 = 3025$$

$$a = [\sum y \sum x^2 - \sum x \sum xy] / [n \sum x^2 - (\sum x)^2]$$

$$a = [1.285.683 * 385 - 55 * 6.636.015] / [10 * 385 - 3025]$$

$$a = 157.586 \text{ olur.}$$

$$b = [n \sum xy - \sum x \sum y] / [n \sum x^2 - (\sum x)^2]$$

$$b = [10 * 6.636.015 - 55 * 1.285.683] / [10 * 385 - 3025]$$

$$b = -5276 \text{ olur.}$$

Bu durumda 1991 yılı için talep tahmini;

$$y = a + bx$$

$$y = 157.586 - 5276 * 11$$

$$y = 99.550 \text{ ton olur.}$$

Korelasyon Katsayısı= 0,89 olarak hesaplanır. Bu durumda değişkenler arasında yüksek bir korelasyon olduğu söylenebilir.

### 3.3.2.2 Basit Ortalama ve Ağırlıklı Ortalama Yöntemi:

Ortalama talep, tüm geçmiş verilerin aritmetik ortalamasıdır. Ürünlerin geçmiş yıllardaki talep grafiği ileriki yılların talebine esas teşkil edecek şekilde kullanılır. Geçmiş veriler artma ve azalma yönünde bir eğilim göstermiyorsa bu yöntem kullanılabilir. Geçmiş veriler hesaplanırken son dönemdeki verilere daha fazla ağırlık verilmek istenirse ağırlıklı ortalama yöntemi kullanılabilir. Üç aylık ağırlıklı ortalama şöyle hesaplanır (Acar, 1989):

$a_i$  : Ağırlıklar,

$D_0$  : Son ayın talebi,

$D_1$  : Bir ay evvelki talep,

$D_2$  : İki ay evvelki talep,

$\bar{X}$  : Üç aylık ağırlıklı talep,

olmak üzere;

$$\bar{X} = a_0D_0 + a_1D_1 + a_2D_2 \quad (3.9)$$

Bu şekilde tüm beş yıllık veriler için ağırlıklı ortalama bulunabilir. Son yıllara daha fazla ağırlık verince ilk yıllardaki verilerin ağırlık üzerindeki etkisi daha az hissedilecektir.

### 3.3.2.3 Zaman Serileri Yöntemi:

Zaman Serileri analizinde; geçmiş satışları incelenerek belirli bir eğilim olup olmadığı belirlenerek, gelecekle ilgili talep tahmin işlemi yapılmaya çalışılır.

Bu konuda şöyle bir örnek verilebilir:

Ayçelik A.Ş. için son dört yıllık satış verileri 3'er aylık dönemler olarak aşağıdaki tabloda verilmiştir:

Tablo 3.3 Ayçelik A.Ş.'nin Satış Tablosu (Tekin,1996)

Dönem	Satışlar (1000 Birim)
1	1.0
2	3.0
3	4.0
4	2.0
5	1.0
6	3.0
7	5.0
8	3.0
9	2.0
10	4.0
11	6.0
12	3.0
13	2.0
14	5.0
15	7.0
16	4.0

En küçük kareler yöntemindeki formüller kullanılarak yeni değerler hesaplanır.

$$Y' = a + bX$$

$$a = \frac{[\sum y \sum x^2 - \sum x \sum xy]}{[n \sum x^2 - (\sum x)^2]}$$

$$a = 1.775 \text{ olur.}$$

$$b = \frac{[n \sum xy - \sum x \sum y]}{[n \sum x^2 - (\sum x)^2]}$$

$$b = 0.1956 \text{ olur.}$$

17. dönem için tahmini değer;

$$Y'(17) = 1.775 + 0.1956 (17) = 5100 \text{ birim olur.}$$

#### **3.3.2.4 Hareketli Ortalamalar Yöntemi:**

Talepteki mevsimlik dalgalanmaların da incelenerek mevsimlik dalgalanmaların talep üzerindeki etkisi bilinmek istenirse hareketli ortalama yöntemi kullanılabilir. Geçmiş dönemdeki satışlar incelenir ve satışların zamanla ortaya koyduğu satış eğilimi bulunur. Eğilim doğrusundan yararlanarak gelecek dönemdeki talep tahmini yapılır. Hareketli ortalamalar metoduna göre 3, 4, 6 ve 12 aylık ortalamalara göre değerlendirmeler yapılabilir. En çok 3 aylık ortalamalar kullanılır. (Tekin, 1996)

Hareketli Ortalama için şöyle bir örnek verilebilir:

Aktaş Giyim Sanayi A.Ş.'nin 12 aylık dönemdeki satışları aşağıdaki tabloda verilmiştir:

Tablo 3.4 AKTAŞ A.Ş. nin 12 Aylık Dönemdeki Satışları (Tekin,1996)

Aylar	Satışlar (Birim)
1	1.123
2	1.231
3	916
4	1.095
5	969
6	1.247
7	1.102
8	1.260
9	1.018
10	1.184
11	979
12	1252

Hareketli Ortalamalar Metoduna göre üçer aylık dönemler itibariyle yapılan hesaplama şekli aşağıdaki tabloda yer almaktadır.

Tablo 3.5 AKTAŞ A.Ş. nin 12 Aylık Dönemdeki Satışların Hesaplanması (Tekin,1996)

Aylar	Gerçek Satışlar	Üçer Aylık Hareketli Ort.	Tahmini Değerler	Tahmini Sapma
1	1.123			
2	1.231			
3	916	1.090		
4	1.095	1.081	1.090	5
5	969	993	1.081	-112
6	1.247	1.104	993	254
7	1.102	1.106	1.104	-2
8	1.260	1.203	1.106	154
9	1.018	1.127	1.203	-185
10	1.184	1.154	1.127	57
11	979	1.060	1.154	-175
12	1252	1.138	1.060	192
13			1.138	

3 aylık ortalama, herhangi bir satış değeri yerine, kendisinin ve önceki iki ayı kapsayan ortalama değerın toplanmasıyla bulunmaktadır. Bu duruma göre; 1. dönemin 3. ay (Mart) için Aylık Hareketli Ortalama;

$$(1.123+1.231+916) / 3 = 1.090 \text{ birim olarak bulunur.}$$

Tahmini sapmaların hesaplanması Gerçek Satışlar - Tahmini Değerler farkına göre yapılmakta olup 4. ay için bu değer  $1.095 - 1.090 = + 5$  olur.

### 3.3.2.5 AR, MA ve ARIMA Modelleri:

AR (Oto-regresif) süreç zaman içinde verilerin değişmeyeceği duruma dayanır. Örneğin ayda 100 birim satış varsa bu farkı kapatmak için aylık 100 birim yerine koyulur. Daha fazla veya daha az satış olma durumu olmazsa süreç etkilenmez. Bu durum oto-regresif süreçtir.

AR (p) modeli;

p oto-regresif terimlerin sayısı,

e hata olmak üzere;

$$y_t = b_0 + b_1 y_{t-1} + \dots + b_p y_{t-p} + e \quad (3.10)$$

şeklinde ifade edilir.

MA (Hareketli Ortalama) süreci ise serinin gecikmeli hata terimi, şimdiki hata terimini etkileme durumunda tanımanır. MA(q) modeli;

q hareketli ortalama terimlerinin sayısı,

e hata olmak üzere,

$$y_t = a_0 + a_1 y_{t-1} + \dots + a_q y_{t-q} + e \quad (3.11)$$

şeklinde ifade edilir. (Ong,2004)

Zaman Serileri genellikle her iki durumu birlikte içerir. Box ve Jenkin bu iki modeli birleştirerek 1976 yılında ARIMA modelini önermiştir. (Ediger, 2006) ARIMA yaklaşımı zaman serilerinin durağan olduğu varsayımına dayanır. Zaman serilerinin durağan olmaması belirli bir eğilim (trend) içermesi demektir.

Zaman serileri durağan olmaması durumunda, zaman serilerinin bir yada daha fazla kere farkın alınması ile durağanlaştırılarak ARIMA yapısı oluşturulur. (Zou, 2006)

ARIMA(p,d,q) modelinin genel formu aşağıda verilmiştir.

p otoregressif terimlerin sayısı,

d durağan olmayan farkların sayısı,

q hareketli ortalama terimlerinin sayısı olmak üzere,

$$y_t = b_0 + b_1 y_{t-1} + \dots + b_p y_{t-p} + a_1 u_{t-1} + a_2 u_{t-2} + \dots + u_t - q + v_t \quad (3.12)$$

şeklinde ifade edilir.

### 3.3.2.6 Üssel Ağırlıklı Ortalamalar (Üssel Düzeltme) Yöntemi:

Bu yöntem tüm geçmiş verilere farklı ağırlıklar veren bir ortalama yöntemidir. Kullanılan aralıklar üssel olarak azaldığı için bu yönteme üsse düzeltme yöntemi de denir.

Bu yöntem aşağıdaki formülle açıklanabilir:( Acar, 1999)

$S_t$  = t zamanında (t + 1) periyodu için yapılan talep tahmini,

$D_t$  = t zamanındaki gerçek talep,

$S_{t-1}$  = t-1 zamanında, t periyodu için yapılan talep tahmini,

$\alpha$  = düzeltme katsayısı,

olmak üzere;

$$S_t = S_{t-1} + \alpha (D_t - S_{t-1}) \quad (3.13)$$

olur.

Formül tekrar düzenlenirse

$$S_t = \alpha D_t + (1-\alpha) S_{t-1} \quad (3.14)$$

olur. Bu işlem  $S_{t-i}$ ,  $i=2, 3, \dots$  için yapıldığında,

$$S_t = \alpha \sum \beta^k D_{t-k} + \beta^t S_0 \quad (3.15)$$

olur.

Eski verilere verilen ağırlıklar geometrik olarak azalırlar. Tüm ağırlıklar toplamı büyük t değerleri için 1'e eşittir.

$$\alpha \sum \beta^k = \alpha / (1-\beta) = 1 \quad (3.16)$$

Düzeltilme katsayısı olan  $\alpha$ , 0 ile 1 arasında bir değerdir. Genellikle en çok kullanılan değerler 0,3 ile 0,01 arasındadır. Talep tahmininde kullanılan  $\alpha$ 'nın küçük değerler alması geçmiş verilerin ağırlığının artmasını, büyük değerler alması ise son dönemdeki verilerin ağırlığının artmasını sağlar.

### 3.3.2.7 Eğri Uydurma Yöntemi:

İki değişken arasındaki ilişkinin doğru ile gösterilememesi durumunda, uygun bir eğri seçilerek en küçük kareler yöntemine göre hesaplama yapılır. En uygun eğrinin seçim işleminde bilgisayar paket programlarından yararlanır.

Bağımlı değişken (Y) ve bağımsız değişken (X) arasındaki ilişki parabolik olursa;

$$Y' = a + bx + cx^2 \text{ olur.} \quad (3.17)$$

Bağımlı değişken (Y) ve bağımsız değişken (X) arasındaki ilişki hiperbolik olursa;

$$Y' = 1 / (a + bx) \text{ olur.} \quad (3.18)$$

Bağımlı değişken (Y) ve bağımsız değişken (X) arasındaki ilişki üstel olursa;

$$Y' = ax^b \quad (3.19)$$

$$Y' = ab^x \quad (3.20)$$

olur.

Bağımlı değişken (Y) ve bağımsız değişken (X) arasındaki ilişki logaritmik olursa;

$$\ln Y' = \ln a + b \ln X \quad (3.21)$$

olur.

### 3.3.2.8 Simulasyon Yöntemi:

Simulasyon gerçeğin sembolik olarak temsil edilmesidir. Simulasyon, ekonomi, eğitim , Pazar araştırması, talep tahminleri, sosyal bilimler, davranış bilimleri gibi bir çok alanda kullanılırlar. Simülasyon çeşitleri üç gruba ayrılır:

- Monte Carlo Simulasyonu
- Model Örnekleme
- Oyun Simulasyonu

Talep tahminlerinde Monte Carlo Simulasyonu yaygın olarak kullanılır. Bu yöntemde kullanılırken rastgele örnekleme ve şans faktörü veya ihtimale bağlı olarak hesaplamalar yapılır. Geçmiş dönemdeki talep bilgilerinden yararlanılarak gelecekle ilgili tahminler yapılır. Tahmin beş aşamada gerçekleştirilir: (Tekin, 1996)

- Değişkenler için ihtimal dağılımı hesaplanır,
- Birinci basamaktaki her değişken için ihtimal dağılımının kümülatif toplamı bulunur,
- Her talep düzeyi için rastgele sayı aralığının hesaplanır,
- Rastgele sayılar çekilerek tespit edilir,
- Simulasyon işlemi tamamlanarak gerçek olay simüle edilir.

Bu yöntemde göre talep tahmini işleminde geçmiş dönemdeki talebin ihtimal dağılımı esas alınır. Her bir talep düzeyi için ihtimal değeri, o değişkenle ilgili toplam gözlem sayısına, frekans dağılımına ve talebin muhtemel sonuçlara göre bulunur.

### 3.4 Talep Tahmini ve Yapay Sinir Ağları

Üretici ve perakendeci çoğu satıcı kesin satış tutarlarını tahmin etmek isterler. Özellikle perakende birimleri olanlar stok bazında ve haftalık olarak satışlarını kesin bir şekilde tahmin etmek isterler. Çoğu tedarikçinin geçmişe yönelik detaylı satış bilgileri vardır. Yapay sinir ağları büyük veritabanlarını analiz ederek, veriler arasındaki karışık ilişkileri çözebilen ve stok tutma birimleri bazında kesin satış tahmini yapmaya elveren teknolojilerdir. (Thall,1992)



Yapay sinir ağlarında da talep tahmini yapılırken diğer matematiksel modellerde olduğu gibi geçmiş veriler kullanılır ve parametre değerlerini belirlerken en küçük kare hatasını üretmeye çalışır. Uygun ağırlık değerlerini belirlemek için sinir ağları eğitilir. Uygun bir çözüm bulunana kadar eğitim bir dizi iterasyondan geçirilir.(Denton, 1995) 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 katmanında bağımlı değişken kadar hücre bulunur. (Thall,1992) 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. (Denton, 1995)

Talep tahmininde ideal koşullar altında regresyona dayanan istatistiksel yöntemlerle yapay sinir ağları arasında çok fark yoktur. Ancak ideal koşulların olmadığı durumda Yapay Sinir Ağları daha üstündür. Yapay Sinir Ağlarını'nın başlıca üstünlükler şöyle sıralanabilir: (Denton, 1995)

- Matematiksel modellerde tahmin yapmak isteyen kişi değişkenler arasındaki ilişkileri anlatan bir fonksiyon yapısını varsayım olarak kabul etmesi gerekir. Yapay sinir ağları böyle bir yapıya ihtiyaç duymaz bağımsız değişkenler arasındaki ilişkiyi kendisi öğrenir.
- Özellikler doğrusal regresyon analizlerde bazı varsayımların yapılması gerekir:
  - Değişkenler arasında korelasyon olmamalıdır.
  - Tahmin hataları her deneme için bağımsızdır.
  - Hatalar sabit varyans ve ortalama ile dağılmışlardır.

Yapay sinir ağları ise bağımsız değişkenler arasındaki belirsizliğin giderilmesindeki üstünlüğü, herhangi bir varsayıma ihtiyaç kalmadan öğrenmesini sağlar. Önyargılı veya yanılıgılı bir varsayıma dayalı modelde regresyon sonucu hatalı olurken yapay sinir ağları bu kusurdan etkilenmez.

Yapay Sinir Ağı uygulaması talep tahmini için temel olarak yedi adımda hazırlanır: (Chin&Arthur, 1996)

*1-Problemi tanımlama* : Tahmin yapılacak problemin belirlenmesi sonraki adımlar açısından en temel adımdır.

*2-İlişkili özellikleri tanımlama*: Fiyat talep ilişkisi, çevresel faktörler, içsel faktörler gibi talebi etkileyen özellikler ve aralarındaki ilişkiler veri toplanmadan önce belirlenmelidir.(Bolt, 1994)

*3-Verileri toplama* : Talep tahmininde kullanılacak geçmiş veriler, anketler, makro veriler tahmine baz olacak şekilde toplanmalıdır. (Bolt, 1994)

*4-Veriyi düzenleme* : Veriler yapay sinir ağlarının kullanılacağı şekilde normalize edilmelidir. Veriler [0 1] aralığı yerine [0.1 0.9] aralığına gelecek şekilde normalize etmek yapay sinir ağlarında etkin kullanılan bir yöntemdir. (Tang ve Fishwick, 1993)


*5-Yapay sinir ağını kurma* : Uygun yapay sinir ağı mimarisi, ara katman sayısı, ara proses sayısı, toplama ve aktivasyon fonksiyonlarının belirlenmesi, ilk ağırlıkların ve momentumun atanması ve uygun eğitim algoritmasının atanması yapılmalıdır. (Chin&Arthur, 1996) Talep tahmininde en yaygın kullanılan eğitim algoritması geri yayılım (çok katmanlı algılayıcı) yöntemidir. (Denton, 1995)

*6- Yapay Sinir Ağlarının Eğitilmesi*: Eğitim veri grubu kullanılarak yapay sinir ağlarının eğitilmesi yani uygun ağırlıkların belirlenmesi sağlanmalıdır.


*7- Yapay sinir ağını test etme ve doğrulama*: Eğitilmiş olan ağın, gerçekten etkin tahminler yapıp yapmadığı test veri grubu ile ölçülmeli ve hatanın kabul edilebilir hata düzeyi içinde olup olmadığı kontrol edilmelidir.

Talep Tahmininde Yapay Sinir Ağları yönteminin adımları ile diğer geleneksel yöntemlerin adımlarının kıyaslanması aşağıda Şekil 3.3'de gösterilmiştir.

### GELENEKSEL TAHMİN MODELİ



### YAPAY SİNİR AĞLARI İLE TAHMİN MODELİ



Şekil 3.3 Yapay Sinir Ağları Yöntemi ve Geleneksel Yöntemlerle Talep Tahmini Adımları (Denton, 1995)

## 4. TALEP TAHMİNİ UYGULAMASI

Yapay Sinir Ağları kullanılarak Talep Tahmini uygulaması, Türkiye'nin önde gelen ve perakende mağazalar zinciri olan bir Kuyum Grup şirketinde yapılmıştır. Uzman görüşü olarak grubun merkez şirketinde Genel Müdür'ün, Satış Müdürü'nün ve Finans Müdürü'nün görüşlerine başvurulmuştur. Gruba bağlı Kapalı Çarşı ve İstanbul'da alışveriş merkezlerinde yer alan perakende mağazalardan veriler derlenmiştir. Yapay Sinir Ağları ile talep tahmin aşamaları aşağıdaki gibi uygulanmıştır:

### 4.1 Talep Tahmini Probleminin Tanımlanması

Bu çalışma ile İşçilik değeri düşük altın ürün satışları ve işçilik değeri yüksek altın ürün satışlarının yapay sinir ağları kullanılarak tahmin edilmesi ve iki farklı ürün grubunun talebini etkileyen faktörlerin belirlenmesi hedeflenmektedir.

Kuyum grup şirketinde, Genel Müdür, Satış Müdürü ve Finans Müdürü ile görüşülerek altın ürün satışını etkileyen özelliklerin aşağıdaki gibi olduğu tespit edilmiştir.

- *Altın Fiyatları* : Altın fiyatlarının artmasının genel olarak altın satışlarını düşürdüğü düşünülmektedir.
- *Döviz Fiyatları* : Döviz fiyatlarının durağan ve düşük olması, yatırım amaçlı olarak altın ürünlere talebi artırdığı düşünülmektedir.
- *Enflasyon*: Makro ekonomik değer olarak enflasyonun altın satışı üzerinde etkisi olduğu düşünülmektedir.
- *Gayri Safi Milli Hasıla* : Gayri Safi Milli Hasılanın halkın alım gücünü artırmasıyla altın satışlarını da etkilediği düşünülmektedir.
- *Faiz* : Makro ekonomik değer olarak faiz'in artmasının veya azalmasının altın satışları üzerinde etkisi olduğu düşünülmektedir.

- *İstanbul Menkul Kıymetler Borsası Verileri:* Borsa verilerinin bir yatırım aracı olarak ülkenin ekonomik durumuna bir gösterge olması ve altının da yatırım aracı olarak kullanılması nedenleriyle altın ürün satışlarını etkilediği düşünülmektedir.
- *Evlilik sayısı:* Evlilik sayısının aylar bazında değişmesi, düğün ve nikah merasimlerinde altın ürünlerin takılması altın satışlarını etkilediği düşünülmektedir.
- *Turist sayısı:* Türkiye'ye gelen turistlerin altın ürün satışlarında etkisi olduğu düşünülmektedir.
- *Özel Günler:* Yılbaşı, Sevgililer Günü ve Anneler Günü gibi özel günlerin altın ürün satışlarını etkilediği düşünülmektedir.

1997-2006 arasında aylık bazda veriler toplanmış, 1997-2005 arası veriler eğitim ve doğrulama amaçlı kullanılmıştır. 2006 verileri ise test amacı ile kullanılmıştır. Veriler girdi veriler ve çıktı veriler olmak üzere aşağıdaki gibi toplanmıştır:

Girdi verileri olarak aşağıdaki dokuz veri toplanmıştır:

1. *Altın Fiyatları:* 1997-2006 arasındaki aylık bazda altın fiyatları gr/TL bazında veriler toplanmıştır.(Tablo A.1)
2. *Dolar Kurları:* 1997-2006 arasındaki aylık bazda dolar kur değerleri TL bazında veriler toplanmıştır. (Tablo A.2)
3. *Enflasyon Verileri :* 1997-2006 arasındaki aylık bazda ÜFE enflasyon verileri toplanmıştır. (Tablo A.3)
4. *Gayri Safi Milli Hasıla:* 1997-2006 arasındaki 3 aylık bazda GMSH değerleri toplanmıştır. 3 aylık veriler, üç ay için aylık bazda eşit kabul edilmiştir. (Tablo A.4)
5. *Faiz :* 1997-2006 arasında 1 aylık vadeli faiz değerleri toplanmıştır. (Tablo A.5)
6. *İstanbul Menkul Kıymetler Borsası:* 1997-2006 arası aylık bazda IMKB (Tüm) verileri toplanmıştır.(Tablo A.6)

7. *Evlilik Sayısı*: Bilgi Edinme Kanunu çerçevesinde 2003-2005 arası aylık bazda evlilik sayıları toplanmıştır. (Tablo A.7). Yılların aylık bazda ortalamaları alınarak aylık evlenme oranları elde edilmiştir. 1997-2006 arasındaki bütün aylarda aynı evlilik oranları kullanılmıştır.
8. *Turist Sayısı*: 1997-2006 yılları arasında Türkiye'ye gelen turist sayısı aylık bazda toplanmıştır.

(Tablo A.8)

9. *Özel Gün Sayısı*: Yılbaşı, Sevgililer Günü ve Anneler Günü özel gün olarak ele alınmıştır. Aralık, Şubat ve Mayıs aylarında bu değer 1, diğer aylarda bu değer 0 olarak ele alınmıştır.

Çıktı verileri olarak aşağıdaki iki veri grubu toplanmıştır:

1. *İşçilik Değeri Düşük Altın Ürün Satışları* : 1997-2006 ayları arasında işçilik değeri düşük altın ürün satışları gr bazında toplanmıştır. 24 ayar (24K) altın ürünler işçiliği düşük altın ürün kategorisinde alınmıştır.

2. *İşçilik Değeri Yüksek Altın Ürün Satışları* : 1997-2006 ayları bazında işçilik değeri yüksek altın ürünler kategorisinde 9K-22K arasındaki ürünler ele alınmıştır. Ekteki tablolarda altın ürünlerin ayarlar bazında satışları verilmiştir. (Tablo A.09, Tablo A.10, Tablo A.11)

Kuyum sektöründe 1gr 24K altın değerine HAS adı verilir. Altın ürün satışları gr bazında değil HAS bazında değerlendirilmiştir. Bunun için aşağıdaki çevrim kullanılmıştır.

$$1 \text{ gr } 22\text{K} = 22/24 = 0,9166 \text{ HAS} \quad (4.1)$$

$$1 \text{ gr } 18\text{K} = 18/24 = 0,75 \text{ HAS} \quad (4.2)$$

9K-22K arasındaki bütün altın satış değerleri HAS değerine çevrildikten sonra toplanmıştır. (Tablo A.12, Tablo A.13)

Girdi ve Çıktı verileri ağı sunulmadan önce normalize edilmelidir. Veriler [0 1] aralığı yerine [0.1 0.9] aralığına gelecek şekilde normalize etmek yapay sinir ağlarında etkin kullanılan bir yöntemdir. (Tang ve Fishwick, 1993)

Bu çalışmada veriler 0,1 ile 0,9 arasında normalize edilmiştir. Normalize işlemi bir X verisi için aşağıdaki formül kullanılarak gerçekleştirilmiştir:

$X'$  = Normalize değer;

$X_i$  = Gerçek değerler olmak üzere;

$X' = [(X - \min X_i) \cdot 0,8 / (\max X_i - \min X_i)] + 0,1$

Yapay Sinir Ağları değişkenler arasındaki doğrusal olmayan ilişkileri yakalamakla beraber mevsimsel etkiyi de gidermektedir. (Sadowski, 2001) Bu çalışmada Yapay Sinir Ağları'nın mevsimsel etkiyi gidereceği düşünülerek verilerde mevsimsel etkinin giderilmesi ile ilgilim bir çalışma yapılmamıştır.

#### 4.2 Yapay Sinir Ağı Mimarisi

Talep Tahmininde en çok kullanılan yöntem Çok Katmanlı Algılayıcılar (geri yayılım algoritması) yöntemidir. Talep Tahmininde ağırlıkların 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.

1997-2005 arasındaki 108 adet veri, ağı eğitimi amaçlı kullanılmıştır. Bunlardan 93 tanesi eğitim, 15 tanesi doğrulama için seçilmiştir. Yapay Sinir Ağ yapısı bir çok talep tahmininde kullanıldığı gibi biri gizli katman olmak üzere üç katmanlı yapı seçilmiştir. Girdi katmanı 9 hücreden, çıktı katmanı ise 2 çıktı hücreden oluşmuştur. Gizli katmanda ise herhangi bir sayıda hücre bulunabilir ancak genellikle girdi sayısının iki katını geçmez. (Denton, 1995) Yapay sinir ağı modellemesinde kesinleşmiş bir yöntem olmamakla birlikte optimum gizli hücre sayısını elde etmek için “geometrik piramit kuralı” olarak adlandırılan yöntem kullanılır. Piramit kuralı hücre sayısının bir piramite benzer şekilde girdilerden çıktılara doğru azalması gerektiği varsayımına dayanır.

Girdi hücre sayısının n ve çıktı hücre sayısının m olduğu bir yapay sinir ağı için geometrik piramit kuralına göre gizli hücre sayısı;

$$\sqrt{m \cdot n}$$

denklemleri ile elde edilir. (Yoon ve diğ., 1993).

Bu çalışmada girdi sayısı 9, çıktı sayısı 2 olduğu için  $\sqrt{9 \cdot 2} \approx 3$  değeri ilk denemeler için kabul edilmiştir. Daha sonra 1 ara hücre sayısından girdi sayısının 2 katı olan 18 sayısına göre deneme yapılmıştır.

Momentum katsayısı da öğrenmenin performansını etkiler. 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 göstermektedir. (Öztemel, 2003). Eğitim katsayısı programın öndeğeri olan 0,60 bırakılarak, 1000 çevrim için momentum katsayıları değiştirilerek en uygun momentum katsayısı bulunmaya çalışılmıştır. Aşağıdaki tabloda Ocak ayı verileri için gerçekleşen veriler ile momentum katsayısının farklı değerlerine göre tahmin edilen veriler kıyaslanmıştır. Bu çalışma için en uygun momentum katsayısının 0,5 olduğu görülmüştür.

Tablo 4.1 Momentum Katsayısının Farklı Değerleri İçin Tahminler

Ürün Tipi	Gerçek	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
8.22K	0,5728	0,5889	0,5827	0,5768	0,574	0,5775	0,5845	0,5784	0,4179	0,7595
24K	0,2522	0,2885	0,2887	0,2854	0,277	0,2588	0,214	0,1792	0,4532	0,606

Momentum katsayısı kadar öğrenme katsayılarının belirlenmesi de ağın öğrenme performansı ile yakından ilgilidir. Öğrenme katsayısı ağırlıkların değişim miktarını belirler ve eğer büyük değerler seçilirse yerel çözümler arasında ağın 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. (Öztemel, 2003). Momentum Katsayısı 0,5 alınarak 1000 çevrim için öğrenme katsayıları değiştirilerek en uygun öğrenme katsayısı bulunmaya çalışılmıştır. Aşağıdaki tabloda Ocak ayı verileri için gerçekleşen veriler ile öğrenme katsayılarının farklı değerlerine göre tahmin edilen veriler kıyaslanmıştır. Bu çalışma için en uygun öğrenme katsayısının 0,6 olduğu görülmüştür.



Tablo 4.2 Öğrenme Katsayısının Farklı Değerleri İçin Tahminler

Ürün Tipi	Gerçek	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
8-22K	0,5728	0,7185	0,6319	0,6006	0,5874	0,5796	0,5775	0,5803	0,5789	0,5782
24K	0,2522	0,4854	0,3118	0,3059	0,2928	0,2769	0,2588	0,2339	0,209	0,2018

Belirli bir iterasyondan sonra ağıın öğrenmesinin durduğu gözlemlenir. Bu durum ağıın daha fazla öğrenemeyeceği ve daha iyi bir sonuç bulamayacağı anlamına gelir. (Öztemel, 2003) Momentum katsayısı 0.5, öğrenme katsayısı 0.6 alınmış, çevrim sayıları değiştirilerek en uygun çevrim sayısı bulunmaya çalışılmıştır. Aşağıdaki tabloda Ocak ayı verileri için gerçekleşen veriler ile çevrim sayısının farklı değerlerine göre tahmin edilen veriler kıyaslanmıştır. Öncelikle çevrim sayıları 250'şer artırılmıştır. En uygun çevrim sayısının 1000 civarında olduğu görülmektedir.

Tablo 4.3 Çevrim Sayısının Farklı Değerleri İçin Tahminler

Ürün Tipi	Gerçek	250	500	750	1000	1250	1500	1750	2000	2250
8-22K	0,5728	0,6276	0,5908	0,5787	0,5775	0,5802	0,5779	0,5764	0,5759	0,5759
24K	0,2522	0,4	0,3262	0,2904	0,2588	0,226	0,2052	0,1954	0,1903	0,1877

Daha net bir çevrim sayısı bulmak için 1000 civarında çevrim sayısı 50'şer olarak değiştirilerek en uygun çevrim sayısı bulunmaya çalışılmıştır. En uygun çevrim sayısının 1050 olduğu görülmüştür.

Tablo 4.4 Çevrim Sayısının Farklı Değerleri İçin Tahminler

Ürün Tipi	Gerçek	900	950	1000	1050	1100	1150	1200	1250	1300
8-22K	0,5728	0,5767	0,5769	0,5775	0,5783	0,5791	0,5798	0,5801	0,5802	0,5799
24K	0,2522	0,2719	0,2654	0,2588	0,2521	0,2453	0,2385	0,232	0,226	0,2205

Momentum katsayısı 0.50, öğrenme katsayısı 0.60 ve 1050 çevrim ile ara hücre sayısı 1 ile girdi sayısının iki katı olan 18'e kadar deneme yapılmıştır. En iyi hücre sayısının 3 olduğu görülmüştür.

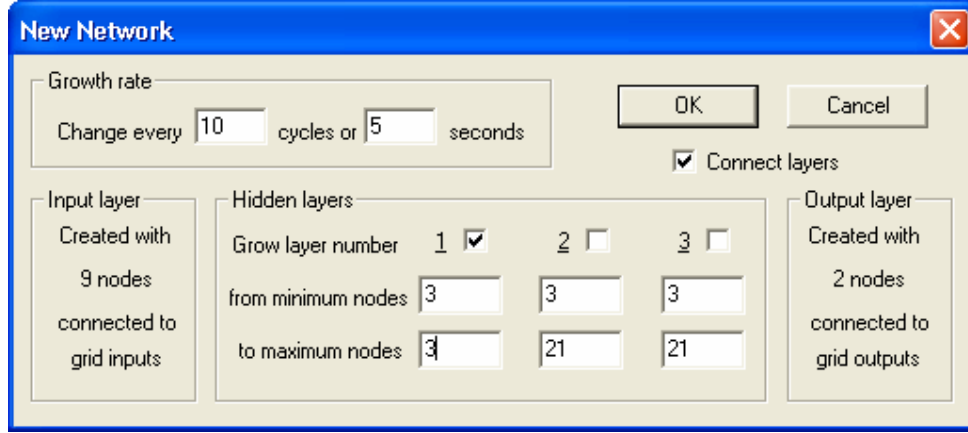
Tablo 4.5 Ara Hücre Sayısının Farklı Değerleri İçin Tahminler

Ürün Tipi	Gerçek	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
8-22K	0,5728	0,5454	0,7116	0,5783	0,549	0,6648	0,504	0,5209	0,4878	0,5869	0,6604	0,4176	0,5633	0,4071	0,5341	0,521	0,5727	0,4116	0,5451
24K	0,2522	0,4535	0,5395	0,2521	0,2562	0,4055	0,2991	0,2698	0,2417	0,3527	0,3108	0,2391	0,2688	0,1778	0,3041	0,2406	0,3374	0,1863	0,207

### 4.3 Yapay Sinir Ağının Eğitilmesi

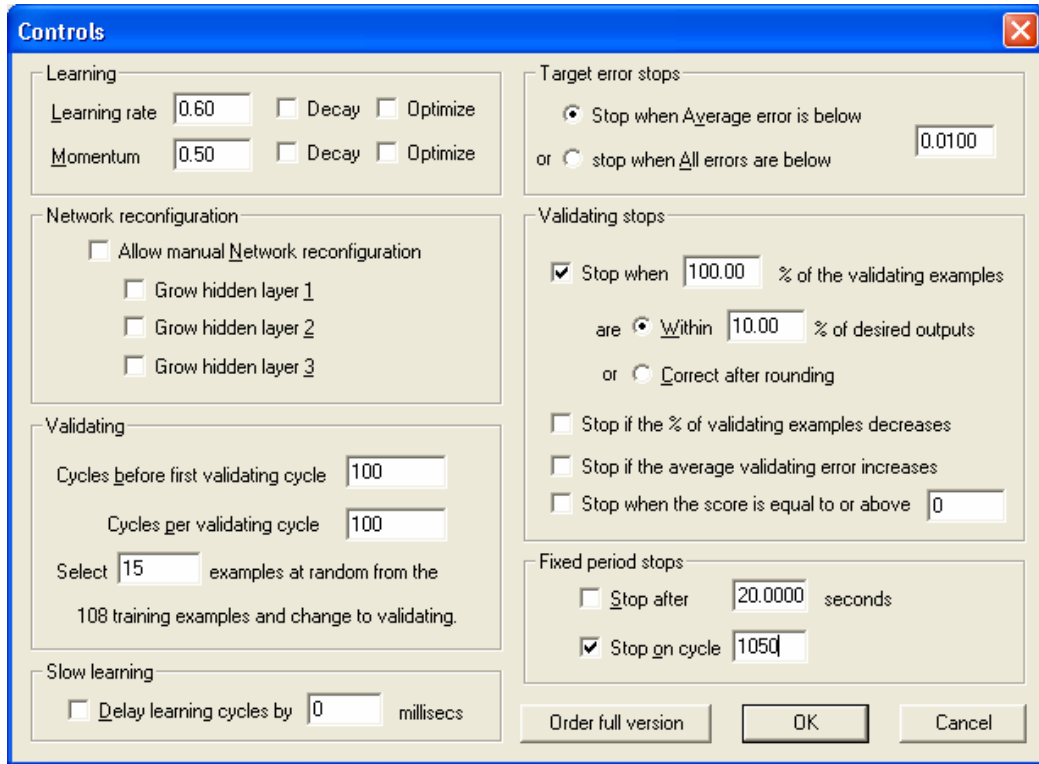
Ağın eğitilmesi için EasyNN programı kullanılmıştır.

- Ara katman olarak 1 gizli katman ve 3 ara hücre seçilmiştir.
- 108 öğrenme verisinden 15 tanesi doğrulama amacı ile ayrılmıştır.
- Momentum katsayısı 0,50 olarak girilmiştir.



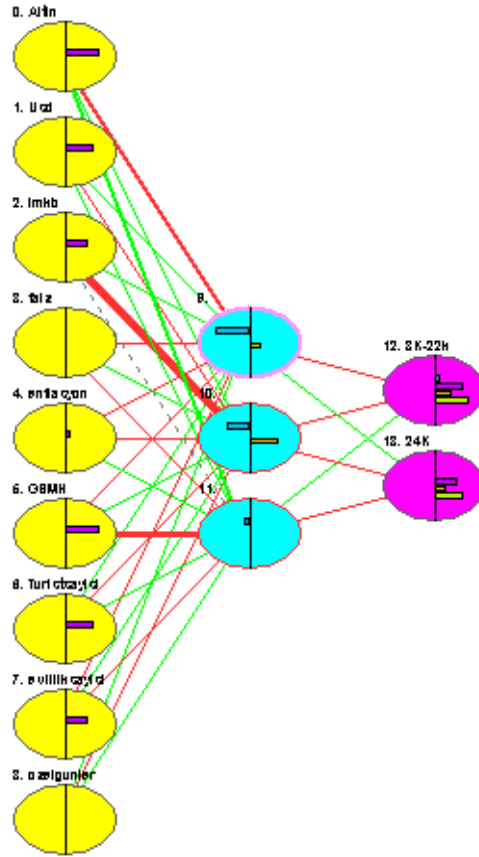
Şekil 4.1 EasyNN Programı Katman ve Hücre Sayısının Belirlenmesi

- d. Hedef hata olarak %1 girilmiştir.
- e. Çevrim sayısı olarak 1050 girilmiştir.



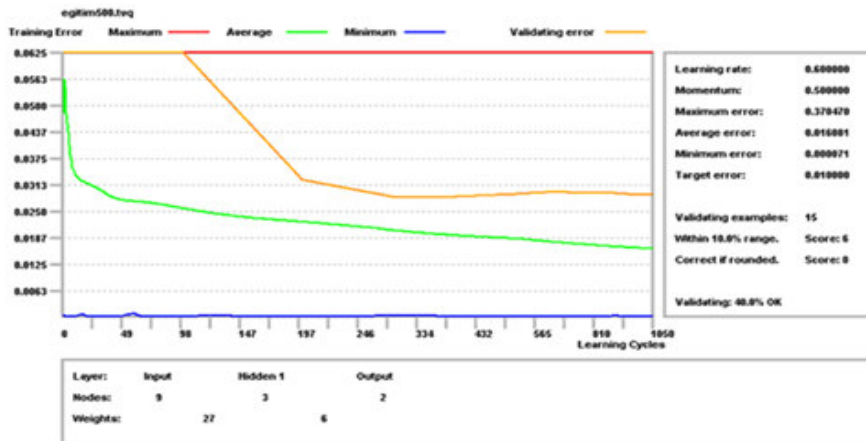
Şekil 4.2 EasyNN Programı Parametre Tanımlama Ekranı

Kullanılan Ağ yapısı aşağıdaki şekilde oluşmuştur.



Şekil 4.3 Kullanılan Ağın Yapısı

Ağın öğrenme grafiği aşağıda verilmiştir. 1050 çevrim yapılmıştır. %40 doğrulama başarısı elde edilmiştir.



Şekil 4.4 Öğrenme Grafiği

Ağın tahmin grafiği ise aşağıdaki gibi gerçekleşmiştir.



Şekil 4.5 Tahmin Grafiği

#### 4.4 Bulunan Sonuçların Test Edilmesi

2006 yılı satış değerleri ile tahmin edilen değerler karşılaştırılmıştır. İşçilik değeri yüksek ürünler için %98,7 oranında bir başarı elde edilirken, işçilik değeri düşük ürünler için %97,7 oranında başarı elde edilmiştir. Ortalama başarı oranı ise %98,2 olarak gerçekleşmiştir. Bu değerler aşağıdaki tabloda verilmiştir:

Tablo 4.6 2006 Yılı Tahmin Edilen Değerlerle (YSA) Gerçekleşen Değerlerin Kıyaslanması

GERÇEKLEŞEN		TAHMİN		HATA %		
8K-22k	24K	8K-22k	24K	8K-22k	24K	Ortalama
0,5720	0,2522	0,5763	0,2462	0,61103352	2,37906423	1,49504888
0,5641	0,2479	0,5635	0,2418	0,10636412	2,40066962	1,28351687
0,7103	0,2284	0,7039	0,2279	0,90102773	0,21891419	0,56997096
0,8285	0,2221	0,8164	0,2303	1,46047073	3,69203062	2,57625067
0,8528	0,1575	0,8382	0,1648	1,7120075	4,63492063	3,17346407
0,8468	0,1743	0,8333	0,1777	1,58423713	1,96066978	1,77244845
0,7949	0,8612	0,7835	0,861	1,43414266	0,03024803	0,73219535
0,777	0,702	0,7649	0,7088	1,56727156	1,11111111	1,33419133
0,7792	0,7225	0,769	0,7219	1,30903491	0,08304498	0,69603995
0,8174	0,3814	0,8045	0,4012	1,5781747	5,1914001	3,3847874
0,8382	0,219	0,8248	0,2305	1,5986638	5,25114155	3,42490268
0,8284	0,3223	0,8157	0,3242	1,53307581	0,58951288	1,06129434
			Hata%	1,28295868	2,29909315	1,79117591
			Başarı%	98,7170413	97,7006069	98,2088241

Yukarıdaki ağ yapısından ayrı olarak çıktı verileri ağa ayrı ayrı sunulmuştur:

- Ara katman olarak 1 gizli katman ve 2 ara hücre seçilmiştir.
- 108 öğrenme verisinden 15 tanesi doğrulama amacı ile ayrılmıştır.
- Momentum katsayısı 0,50 olarak girilmiştir.
- Hedef hata olarak %1 girilmiştir.
- Çevrim sayısı olarak 800 girilmiştir.

Tablo 4.7 2006 Yılı (8K-22K) Tahmin Edilen Değerlerle (YSA) Gerçekleşen Değerlerin Kıyaslanması


GERÇEKLEŞEN	TAHMİN	HATA %
<b>8K-22k</b>	<b>8K-22k</b>	
0,5728	0,5819	1,588687
0,5641	0,5514	2,251374
0,7103	0,7342	3,364775
0,8285	0,8452	2,015691
0,8528	0,8313	2,521107
0,8468	0,8543	0,885687
0,7949	0,7793	1,962511
0,777	0,7849	1,016731
0,7792	0,756	2,977413
0,8174	0,8032	1,737216
0,8382	0,8113	3,209258
0,8284	0,8121	1,967648
	Hata %	2,124842
	Başarı %	97,87516

Tablo 4.8 2006 Yılı (24k) Tahmin Edilen Değerlerle (YSA) Gerçekleşen Değerlerin Kıyaslanması

GERÇEKLEŞEN	TAHMİN	HATA %
<b>24K</b>	<b>24K</b>	
0,2522	0,2464	2,29976209
0,2479	0,2382	3,91286809
0,2284	0,2358	3,23992995
0,2221	0,2324	4,63755065
0,1575	0,1611	2,28571429
0,1743	0,1713	1,7211704
0,6612	0,6412	3,02480339
0,702	0,6926	1,33903134
0,7225	0,7327	1,41176471
0,3814	0,3975	4,22128998
0,219	0,2271	3,69863014
0,3223	0,3424	6,23642569
	Hata %	3,16907839
	Başarı %	96,8309216


Duyarlılık Analizi, verinin sonuç üzerindeki etkisinin ne kadar olduğunu bulmasıdır. Verinin çeşitli değerleri girilerek sonucu nasıl etkilediği gözlemlenir. (Chinneck, J.W., 2000 ) EasyNN programının duyarlılık analizi görünümünde girdilere göre çıktılardan 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. (www.easynn.com)

İşçilik değeri yüksek (8K-22K) ürünler için talebin girdi değerlerine duyarlılığı aşağıdaki şekillerde verilmiştir:




Şekil 4.6 Duyarlılık Analizi (8K-22K)

İşçik değeri düşük ürünler (24K) için talebin girdi değerlerine duyarlılığı aşağıdaki şekillerde verilmiştir:



Şekil 4.7 Duyarlılık Analizi (24K)

Girdilerin önem derecesi aşağıdaki gibi belirlenmiştir.



Şekil 4.8 Girdilerin Önem Derecesi



İşçilik değeri yüksek altın ürünler için duyarlılığı en yüksek, işçiliği düşük altınlar içinse duyarlılıkta ikinci yüksek girdi verisinin İMKB değeri verisi olduğu görülmektedir. İMKB değerlerinin minimum ve maksimum değerleri ile altın ürünlerin satışları karşılaştırıldığında pozitif bir uyum olduğu görülmüştür. Yani borsa arttığı zaman işçilik değeri yüksek altın ürünlerin satışı da artmaktadır. Bu durum İMKB'nin değerinin artması halkın alım gücünün artmasının bir göstergesi olmasıyla açıklanabilir.

İşçiliği düşük altın ürünler için en yüksek, işçiliği yüksek altın ürünler içinse İMKB'den sonra en yüksek duyarlılığa sahip girdi verisinin altın fiyatı verisi olduğu görülmektedir. Altın fiyatı verisinin minimum ve maksimum değerleri ile bu tip ürünün satışları karşılaştırıldığında negatif bir uyum olduğu görülmüştür. Altın fiyatlarının Bu çalışmaya başlarken görüşüne başvuru uzmanlar altın fiyatının artmasının satışları olumsuz yönde etkilediğine inandıklarını söylemişlerdi. Bu durum onları haklı çıkarmaktadır.

GSMH değeri de yine İMKB değeri gibi bir makro gösterge olarak halkın alım gücünü göstermektedir. GSMH değerinin artması bu tip ürünlerin satışını olumlu yönde etkilemektedir.

Evlilik sayısı diğerleri kadar fazla etki etmemekle birlikte altın ürün satışlarına negatif yönde etki etmektedir. Bu durum beklenen sonucun tersi bir durumdur. Evlilik sayısı ile ilgili yeterli veri olmaması nedeniyle 2003-2005 yılı verilerinin aylık bazdaki oranlarının bütün yıllara dağıtılmış olması hatalı bir sonuca neden olmuş olabilir.

Dolar fiyatları işçiliği düşük olan altınlarda üçüncü derece duyarlılığa sahip girdi verisi olduğu görülmektedir. Dolar fiyatlarının artması ile altın satışları arasında pozitif bir uyum olduğu gözlenmiştir. Altın fiyatlarının düşmesinin altın ürün satışlarını artırması gibi dolar karşısında altın fiyatların düşmesi yani doların yükselmesi altın ürün satışlarını artırmaktadır. Özellikle işçilik değeri düşük altınlar üzerinde doların etkili olması, bu tür ürünlerin aynı zamanda yatırım amaçlı olarak kullanılması ve dolara alternatif olması durumuyla açıklanabilir.

Enflasyonun artması bu tip ürünlerin satışında olumlu yönde etki etmektedir. Enflasyonun artmasıyla birlikte paranın değerini korumak isteyen kişiler altın alımına yönelmeleri bu sonucu çıkarmış olabilir.

Faizin artması ise altın ürün satışlarını olumsuz yönde etkilemektedir. Faizin artması alternatif yatırım aracı olması nedeniyle nakit paranın faize yatırılması altın ürünlerini olumsuz yönde etkilemektedir.

Turist sayısı verisi her iki altın ürün grubu için de olumlu yönde etki göstermektedir. Gelen turist sayısının artması altın alışlarını da artırmaktadır.

Özel günlerin altın ürün satışlarını olumlu yönde etkilemekle beraber çok az etkilediği görülmüştür. Anneler günü, sevgililer günü ve yılbaşı'nın olduğu günlerde az da olsa altın satışları artmaktadır. Bu çalışmaya pırlanta ürünlerin dahil edilmemiş olması özel günlerin etkisinin beklenenden daha az olmasına neden olmuş olabilir.

#### 4.5 Diğer Talep Yöntemiyle Kıyaslanması

Aynı veriler diğer kullanılan talep yöntemlerinden ikisiyle de yapılmıştır.

a) Çoklu Regresyon Yöntemi

X girdi verileri

Y çıktı verileri olmak üzere,

$$Y = a_0 + a_1X_1 + a_2X_2 + a_3X_3 + a_4X_4 + a_5X_5 + a_6X_6 + a_7X_7 + a_8X_8 + a_9X_9$$

Formülüne göre SPSS programı kullanılarak aşağıdaki ağırlıklar bulunmuştur.

Tablo 4.9 Regresyon Analizi Ağırlıkları

	a0	a1	a2	a3	a4	a5	a6	a7	a8	a9
8K-22K	-0,05047	0,16105654	-0,33095006	0,21081625	0,06352352	0,10256029	1,049838	-0,02313	0,006651	0,018813
24K	0,05518	-1,46956831	0,9093554	0,8969409	-0,05919347	0,06011151	-0,06653	0,303224	-0,01295	0,018288

Çoklu regresyon analizi sonucu çıkan ağırlıklar kullanılarak 2006 yılı verileri tahmin edilmiş ve gerçekleşen verilerle aşağıdaki tabloda kıyaslanmıştır. İşçilik değeri yüksek ürünler için %91,8 gibi bir başarı elde edilirken, işçilik değeri düşük altın ürünler için başarı oranı % 78,04 olarak gerçekleşmiştir. Ortalama başarı oranı ise %84,94 olarak gerçekleşmiştir.

Tablo 4.10 Regresyon Analizi Sonuçları ile Gerçekleşen Verilerin Kıyaslanması

GERÇEKLEŞEN		TAHMİN		HATA %		
8K-22k	24K	8K-22k	24K	8K-22k	24K	Ortalama
0,5728	0,2522	0,63207368	0,57118862	5,92736829	31,8988622	18,9131152
0,5641	0,2479	0,65334306	0,58804763	8,92430583	34,0147634	21,4695346
0,7103	0,2284	0,61931297	0,51308003	9,09870252	28,4680026	18,7833525
0,8285	0,2221	0,77395898	0,44375033	5,46410169	22,1650329	13,8145673
0,8528	0,1575	0,76048533	0,2847394	7,2314667	12,7239397	9,97770321
0,8468	0,1743	0,72501437	0,37589277	12,1785633	20,1592771	16,1689202
0,7949	0,6612	0,92510524	0,34688209	13,0205245	31,4317908	22,2261576
0,777	0,702	0,92970234	0,36294905	15,2702335	33,9050946	24,5876641
0,7792	0,7225	0,92627585	0,3925973	14,7075849	32,99027	23,8489274
0,8174	0,3814	0,83790324	0,44903428	2,05032432	6,76342807	4,4068762
0,8382	0,219	0,83637653	0,29651427	0,18234677	7,75142709	3,96688693
0,8284	0,3223	0,86541843	0,31054587	3,70184254	1,17541317	2,43862785
			<b>Hata%</b>	8,14644707	21,9539418	15,0501944
			<b>Başarı%</b>	91,8535529	78,0460582	84,9496056

b) Eğri Uydurma Yöntemi

Eğri uydurma Yöntemi kullanılarak sadece geçmiş satış verilerden yola çıkılarak tahmin edilmesi sağlanmıştır.


Parabolik eğri seçilmiştir. Bu durumda

Y çıktı verisi;

X dönem (ay) sayısı olmak üzere ;

$$Y = a_0 + a_1X + a_2 X^2$$

formülüne göre işlem yapılmıştır. Eğriler grafikleri aşağıdaki gibi bulunmuştur.



Şekil 4.9 Eğri Uydurma Yöntemi Grafikleri

Hesaplanan ağırlıklıla göre 2006 verileri tahmin edilerek gerçek verilerle kıyaslanmıştır. İşçilik değeri yüksek ürünler için %89,35 başarı elde edilirken, işçilik değeri düşük altın ürünler için başarı oranı % 53,18 olarak gerçekleşmiştir. Ortalama başarı oranı ise %71,25 olarak gerçekleşmiştir.

Tablo 4.11 Eğri Uydurma Yöntemi Sonuçları ile Gerçekleşen Verilerin Kıyaslanması

GERÇEKLEŞEN		TAHMİN		HATA %		
8K-22k	24K	8K-22k	24K	8K-22k	24K	Ortalama
0,5728	0,2522	0,785152	0,59369548	21,2352	34,149548	27,692374
0,5641	0,2479	0,8006	0,60346914	23,65	35,5569141	29,603457
0,7103	0,2284	0,816232	0,72035902	10,5932	49,1959019	29,894551
0,8285	0,2221	0,832048	0,74795137	0,3548	52,5851373	26,4699687
0,8528	0,1575	0,848048	1,43409524	0,4752	127,659524	64,0673619
0,8468	0,1743	0,864232	1,17085485	1,7432	99,6554848	50,6993424
0,7949	0,6612	0,8806	0,43549607	8,57	22,5703932	15,5701966
0,777	0,702	0,897152	0,47581197	12,0152	22,6188034	17,3170017
0,7792	0,7225	0,913888	0,49617301	13,4688	22,432699	17,9507495
0,8174	0,3814	0,930808	0,06392239	11,3408	31,7477609	21,5442804
0,8382	0,219	0,947912	0,60424658	10,9712	38,5246575	24,7479288
0,8284	0,3223	0,9652	0,07198262	13,68	25,0317375	19,3558688
			<b>Hata%</b>	10,6748	46,8107135	28,7427567
			<b>Başarı%</b>	89,3252	53,1892865	71,2572433

## 5. SONUÇ

Bu çalışma yapay sinir ağlarının talep tahmininde uygulanabilir bir yöntem olmakla birlikte etkin sonuçlar ürettiğini göstermek amacı ile yapılmıştır. Türkiye'nin önde gelen kuyum grup şirketinin istanbul içinde yedi perakende mağazasının verilerinden yola çıkılarak altın ürünler için talep tahmini yapılmaya çalışılmıştır.

1997-2006 yılları arası aylık altın satış verileri ayarlar ve gr bazında derlendikten sonra işçilik değeri düşük ve işçilik değeri yüksek olmak üzere iki gruba ayrılmıştır. Satışların aynı birimden ölçülebilmesi için bütün satış verileri kuyumculuğa özgü ölçübirimi olan HAS ölçübirimine çevrilmiştir. Şirket içinde uzman kişilerle görüşülerek talebi etkileyen faktörler belirlenmiş ve bu faktörlerle ilgili bilgiler derlenmiş, bir kısmı için bilgi edinme kanunu çerçevesinde ilgili kurumlara başvurulmuştur.

Yapay sinir ağlarının uygun mimarisini elde etmek için kaynaklardan yararlanmakla birlikte parametre analizi yapılmış ve en uygun ağ mimarisi bulunmuştur. 1997-2005 yılları arasındaki veriler ağı eğitilmesi ve doğrulama yapılması için ayrılmış, 2006 verileri ise sonucun testi için kullanılmıştır. Yapılan tahmin sonucunda işçilik değeri yüksek ürünler için %98,7 oranında bir başarı elde edilirken, işçilik değeri düşük ürünler için %97,7 oranında başarı elde edilmiştir. Ortalama başarı oranı ise %98,2 olarak gerçekleşmiştir.

Ayrıca çoklu regresyon analizi ve eğri uydurma yöntemleri ile de talep tahmini yapılmıştır. Regresyon analizi sonucunda . İşçilik değeri yüksek ürünler için %91,8 gibi bir başarı elde edilirken, işçilik değeri düşük altın ürünler için başarı oranı % 78,04 olarak gerçekleşmiştir. Ortalama başarı oranı ise %84,94 olarak gerçekleşmiştir. Eğri uydurma yönteminde ise İşçilik değeri yüksek ürünler için %89,35 başarı elde edilirken, işçilik değeri düşük altın ürünler için başarı oranı % 53,18 olarak gerçekleşmiştir. Ortalama başarı oranı ise %71,25 olarak

gerçekleşmiştir. Her iki yöntemde de işçilik değeri yüksek ürünler de nispeten daha iyi sonuç alınırken, işçilik değeri düşük altın ürünlerin talebini tahmin etmedeki başarısı düşük çıkmıştır. Yapay Sinir Ağlarında ise her iki tip ürün grubu için de başarılı bir sonuç elde edilmiştir.

Regresyon analizinde bütün bağımsız değişkenler arasında herhangi bir korelasyon olmadığı varsayımı yapılmıştır. Eğri uydurma yönteminde ise satış verilerinin parabolik bir eğri çizdiği varsayımı yapılmıştır. Yapay sinir ağları modelinde ise herhangi bir varsayıma ihtiyaç duyulmadan veriler arasındaki ilişkileri ve ağırlıkları ağın kendisi öğrenmiştir. Yapılan tahmin sonucunda da en başarılı sonucu ortaya çıkarmıştır.

Bu çalışma büyük bir kuyum şirketinin İstanbul içerisindeki yedi mağazasının dokuz yıllık verileri bütün kuyum sektörünü temsil eder varsayımıyla yapılmıştır. Ayrıca bu çalışmaya pırlanta ürünler dahil edilmemiştir. Bu çalışmanın geliştirilmesi için Türkiye'nin farklı yerlerine dağılmış daha çok mağazadan veriler toplanmalı, pırlanta ürünler çalışmaya dahil edilmeli ve veriler daha büyük tarih aralığını kapsayacak şekilde derlenmelidir.

## KAYNAKLAR

1. **Acar, N.**, 1989. Üretim Planlaması Yöntem ve Uygulamaları, Yeniçağ, Ankara
2. **Bolt, G.**, 1994. Market and sales forecasting : a total approach, Kogan Page, Londra
3. **Chaudhury, A., Stahl, D. O., Whinston, A. B.**, 1994. The Economic Foundation for Neural Computing Systems im, Advances in AI in Economics, Finance and Management. Eds. Johnson J.D.. Whinston A.B.. JAI Pres Inc.
4. **Chin, K., Arthur, R.**, (1996). Neural Networks vs. Conventional methods of forecasting, *The Journal of Business Forecasting Methods & Systems*, **14**, p. 17.
5. **Chinneck, J. W.**, 2000. Practical Optimization: A Gentle Introduction, Ottawa, Canada.
6. **Denton, J. W.**, 1995. How good are neural networks for casual forecasting?, *The Journal of Business Forecasting Methods & Systems*, **14**, p.17
7. **Ediger, Ş., Akar, S.**, 2006. ARIMA forecasting of primary energy demand by fuel in Turkey, *Energy Policy*, **35**, pp1701-1708.
8. **Elman, J.L.**, 1990, Finding Structure in time, *Cognitive Science*, **14**, pp. 179-211.
9. **Fukushima, K., Miyake, S.**, 1982, Necognitron: A new algorithm for pattern recognition tolerant of deformations and shifts in position, *Pattern recognition*, **15**, pp. 455-469.
10. **Gately, E.**, 1996. Neural Networks for Financial Forecasting, John Wiley & Sons, Inc, USA.

11. **Grossberg, S.**, 1988. *Neural Networks and Natural Intelligence*, MIT Press, Cambridge.
12. **Grossberg, S., Carpenter, G.**, 1990. "ART3: Hierarchical search using chemical transmitters in self-organizing pattern recognition architectures, *Neural Networks*, **3**, pp.129-152.
13. **Haykin, S.**, 1999. *Neural Networks: A Comprehensive Foundation* Second Edition, prentice Hall, New Jersey.
14. **Hebb, D. O.**, 1949. *The Organization of behaviour*, Wiley, Newyork.
15. **Hopfield, J.J.**, 1982, *Neural Networks and physical systems with emergent collective computational abilities*, *Proceedings of National Academy of Science*, **79**, pp. 2554-2558
16. <http://www.easynn.com>
17. **Khanna, T.**, 1990. *Foundations of Neural Networks*, Addison-Wesley, Newyork
18. **Kohonen, T.**, 1982. Self-organized formation of topologically correct feature maps, *Biological Cybernetics*, **43**, pp.59-69.
19. **Kohonen, T., Barna, G.**, 1987. Statistical pattern recognition with neural networks: Benchmarking studies, *Proc. of the int. Joint Conf. On Neural Networks*, **1**, pp.1-66
20. **Masters, T.**, 1993. *Practical Neural Network Recipes in C++*, Academic Pres, USA.
21. **Moumin, A.**, 1995, *Yapay Sinir Ağları ve Genetik Algoritmalarının Uçuş Kontrol sistemlerine Uygulanması*, *Yüksek Lisans Tezi*, İTÜ Fen Bilimleri Enstitüsü , İstanbul.
22. **Ong, C. S.**, 2004. Model identification of ARIMA family using genetic algorithms, *Applied Mathematics and Computation*, **164**, pp. 885-912
23. **Öztemel, E.**, 2003. *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul
24. **Sadowski, R.,J.**, 2001. Forecasting aggregate retail sales: A comparison of artificial neural networks and traditional methods, *Journal of Retailing and Consumer Services*, **8**, pp. 147-156.



25. **Tang, Z., Fishwick, P.**, 1993. Feed-Forward Neural Nets as Models for Time Series Forecasting, *ORSA Journal of Computing* **5**, pp. 374-386
26. **Tekin, M.**, 1996. Üretim Yönetimi, Arı Ofset Matbaacılık, Konya
27. **Thall, N.**, 1992. Neural Forecasts: A Retail Sales Booster, *Discount Merchandiser*, **32**, p. 41.
28. **Yoon, Y., Swales, G., Margavio, T.M.**, 1993. A Comparison of Discriminant Analysis Versus Artificial Neural Networks, *Journal of Operational Research*, **44/1**, pp. 51-60.
29. **Widrow, B.**, 1990, 30 Years of adaptif neural networks: Perceptron, Madaline and Backpropogation, **78**, No 9
30. **Zou, H.F, Xia, G.P., Wang, H.Y.**, 2006, An investigation and comparison of artificial neural network and time series models for Chinese food grain price forecasting, neurocomputing.

## EKLER

Tablo A.1. Altın Satış Fiyatları gr/TL (www.iab.gov.tr)

Yıllar	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2006	538,74	553,22	554,48	617,48	676,95	594,48	628	629,43	597,28	587,47	627,9	628,39
2005	425,42	424,07	434,72	428,6	423,98	430,99	424,86	437,8	455,94	466,8	474,65	508,75
2004	415,33	405,22	404,8	405,92	382,59	393,15	398,24	399,49	405,2	418,73	444,16	443,33
2003	356,29	355,33	341,87	328,47	355,25	355,62	349,93	359,62	380,83	378,19	386,47	406,41
2002	281,58	297,6	293,86	302,16	314,87	322,61	311,92	308,9	320,45	315,94	319,38	332,02
2001	267,31	263,59	260,14	258,67	272,01	269,35	268,7	271,86	284,51	283,84	277,26	275,27
2000	286,12	303,82	286,51	280,12	277,19	285,52	282,33	275,53	273,86	268,7	266,1	271,24
1999	288,2	287,94	287,91	282,95	278,9	261,86	256,7	257,17	261,96	307,98	294,32	283,45
1998	289,03	298,69	296,42	309,01	300,1	292,29	293,87	285,73	292,56	298,62	295,61	291,72
1997	354,59	351,68	352,75	346,68	345,37	340,97	325,7	325,02	324,2	324,42	308,1	290,61

Tablo A.2. Dolar Kurları / TL (www.tcmb.gov.tr)

Yıllar	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2006	1327933	1320160	1328726	1330920	1413855	1592855	1550781	1462191	1472143	1476242	1451023	1426400
2005	1350042	1310155	1304957	1353514	1365048	1354682	1334723	1336627	1334209	1351200	1353685	1345709
2004	1343421	1323830	1315858	1351365	1501342	1488745	1448239	1467367	1498343	1484781	1445423	1393340
2003	1655836	1623231	1655387	1627196	1490377	1419100	1397108	1397103	1372345	1421271	1472454	1429116
2002	550057	1346727	1353729	1314568	1386212	1520274	1649121	1635497	1643008	1646897	1603894	1583614
2001	370455	738109	965969	1206954	1129785	1212681	1317329	1397576	1466322	1596308	1517548	1448704
2000	543878	562396	579375	594412	616089	615105	626424	644295	663106	675747	682921	677713
1999	210131	340335	359128	378448	394091	411506	425565	433970	452315	465563	494501	525837
1998	156197	222695	234796	244903	251310	260055	267627	273257	274625	277951	293540	306171
1997	111818	118907	124559	130590	136767	143733	152826	162989	169744	177478	186572	199051

TabloA.3. 1997-2006 Arası Enflasyon Verileri (www.tcmb.gov.tr)

Yıllar	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2006	1,96	0,26	0,25	1,94	2,77	4,02	0,86	-0,75	-0,23	0,45	-0,29	-0,12
2005	-0,41	0,11	1,26	1,21	0,2	-0,48	-0,74	1,04	0,78	0,68	-0,95	-0,04
2004	3,77	0,21	0,59	2,27	4,54	0,8	-0,74	0,97	0,72	2,47	0	-1,08
2003	2,6	2,3	3,1	2,1	1,6	-0,2	-0,4	0,2	1,9	1,4	1,6	0,9
2002	5,3	1,8	1,2	2,1	0,6	0,6	1,4	2,2	3,5	3,3	2,9	1,6
2001	2,5	1,8	6,1	10,3	5,1	3,1	2,4	2,9	5,9	6,1	4,2	3,2
2000	4,9	3,7	2,9	2,3	2,2	0,7	2,2	2,2	3,1	3,1	3,7	2,5
1999	4,8	3,2	4,1	4,9	2,9	3,3	3,8	4,2	6	6,3	4,2	5,9
1998	7,2	4,4	4,3	4,7	3,5	2,4	3,4	4	6,7	6,1	4,3	3,3
1997	5,9	5,7	5,4	6,6	4,7	2,9	6,3	6,2	7,3	8,3	6,6	5,1

Tablo A.4. 1997-2006 Arası Gayri Safi Milli Hasıla (www.tuik.gov.tr)

Yıllar	1. Çeyrek	2. Çeyrek	3. Çeyrek	4. Çeyrek
2006	1,07511E+11	1,34019E+11	1,77707E+11	1,56547E+11
2005	94503069554	1,09509E+11	1,49456E+11	1,32934E+11
2004	80506742680	95649744390	1,3328E+11	119.496.004.828
2003	67587095327	78808940742	1,13108E+11	97176897187
2002	48901455563	56907575158	87072323172	82151012060
2001	25097931170	38008880195	58619263332	54757878325
2000	21407859114	27545147515	40515931629	36127190496
1999	12224184119	16539566960	25962772782	23556442948
1998	8707635377	11283907274	17565775415	15961013514
1997	4234839883	5861494676	9890148649	9406778939

Tablo A.5. 1997-2006 Arası 1 Aylık Vadeli Faiz Oranları (www.tcmb.gov.tr)

Yıllar	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2006	19,62	19,42	19,36	17,96	17,73	22,2	23,5	23,47	23,44	23,59	23,65	23,2
2005	20,89	19,78	19,43	19,26	19,37	20,33	20,41	20,31	20,47	20,14	20,07	20,21
2004	26,06	24,16	22,6	22,49	22,9	23,11	23,35	23,55	22,49	22,48	22,61	21,81
2003	45,4	45,45	45,56	44,84	41,94	39,62	37,75	34,43	31,72	28,14	27,9	27,84
2002	58,72	57,97	53,66	49,63	48,22	48,42	48,73	48,73	48,84	48,84	45,55	45,18
2001	51,54	344,1	124,44	90,23	69,91	67,06	67,32	66,25	65,94	64,6	60,7	59,78
2000	41,85	41,54	38,47	38,85	38,82	43,51	36,08	30,71	42,53	41,49	48,91	81,2
1999	79,01	78,28	79,01	77,69	77,66	77,13	76,9	77,18	71,94	71,03	70,45	72,11
1998	78,19	77,83	77,54	77,83	76,98	72,54	65,98	70,54	79,66	78,98	80,25	78,51
1997	73,59	71,39	70,81	70,95	70,74	70,51	70,6	75,64	75,9	76,14	78,17	78,27

Tablo A.6 1997-2006 Arası Aylık İMKB (Tüm) Verileri (www.imkb.gov.tr)

Yıllar	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2006	42996,2	45593,4	41709,8	42719	37366,3	34644,5	35164,2	36495,2	36329,3	39744,3	37446,1	38355,5
2005	26184	27213,3	24589,4	22641,6	24223,9	25864,4	28455,2	29690	31970,5	30784,5	36527,5	38473
2004	16498,2	17985,9	19268,8	17338	16415,6	17155,7	18568,9	19301,2	20969,5	22044,9	21640,6	23857
2003	10743,1	11257	9298,48	11297,8	11126,2	10633,1	10316,5	11262,6	12561,6	15014,2	13984,7	17715,6
2002	12611,3	10584,4	11137,4	10941,7	10001,6	9098,74	9917,24	9318,16	8609,65	9960,07	12870,5	10086,5
2001	9998,94	8173,85	7578,87	11575,9	10234,9	10588,2	9433,52	9431,17	7329,26	9440,25	11089,2	13055,3
2000	15821,8	15014,4	15055	18097,9	15399	13792,8	13197,2	12484,3	10847,8	12834,7	8307,95	8884,92
1999	2482,86	3675,27	4325,7	5031,12	4801,76	4667,75	5428,53	4748,94	5730,29	6186,28	7920,75	14196,9
1998	3413,77	3142,9	3181,15	4045,4	3662,87	3989,65	4234,59	2586,44	2223,75	2135,81	2474,21	2512,64
1997	1563	1591	1588	1410	1539	1788	1905	1948	2524	2761	2811	3302

Tablo A.7. 2003-2005 Arası Aylık Evlenme Sayıları (www.nvi.gov.tr)

Yıllar	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2003	5,05896	4,65913	5,95334	6,89205	7,9215	9,18824	11,3893	13,7796	12,8779	10,1746	3,72668	8,37869
2004	5,25626	5,15988	7,11501	7,29067	8,11368	9,21096	11,3707	13,7344	13,2796	6,86982	5,99631	6,60273
2005	5,67268	6,28168	6,80722	7,1131	8,4785	9,89007	11,7112	13,7574	12,6308	4,98423	6,86398	5,80906
<b>Ortalama</b>	5,3293	5,3669	6,62519	7,09861	8,17123	9,42976	11,4904	13,7571	12,9295	7,34288	5,52899	6,93016

Tablo A.8 1997-2006 Arası Türkiye'ye Gelen Turist Sayısı (Bin)  
(www.tursab.org.tr)

Yıllar	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2006	667	627	922	1373	1919	2369	3110	2906	2267	1714	1020	927
2005	699	693	1107	1349	2303	2403	3164	2859	2502	2107	1052	862
2004	534	608	784	1104	1799	1898	2591	2493	2125	1842	950	789
2003	364	481	500	669	1146	1511	2131	2275	1874	1658	776	644
2002	307	426	676	853	1326	1458	1897	1900	1771	1420	663	560
2001	359	405	547	885	1232	1388	1777	1601	1440	1066	521	398
2000	334	354	435	721	986	1,079	1,526	1,419	1,369	1,178	602	424
1999	359	372	409	427	691	785	932	1,079	876	801	436	321
1998	350	371	478	642	987	1,039	1,145	1,377	1,164	1,034	502	371
1997	300	315	555	640	1,02	1,045	1,208	1,427	1,207	949	540	500

Tablo A.9 1997-1999 Arası Aylık Bazda Satış Miktarları (gr)

	8K	9K	10K	14K	18K	21K	22K	24K
<b>Oca.97</b>	1786	208	152	26471	331	0	3683	5758
<b>Şub.97</b>	1611	178	133	21094	276	0	3990	5183
<b>Mar.97</b>	2314	255	189	32675	441	0	5279	7486
<b>Nis.97</b>	2284	262	184	29366	386	0	4297	7294
<b>May.97</b>	3221	369	254	41360	552	0	6138	9693
<b>Haz.97</b>	2636	295	210	35983	491	0	5463	8254
<b>Tem.97</b>	2870	332	235	40947	540	0	6015	9405
<b>Ağu.97</b>	2929	339	242	45496	607	0	6752	86376
<b>Eyl.97</b>	2694	302	225	39292	518	0	5770	9117
<b>Eki.97</b>	2372	282	194	33915	474	0	5217	7966
<b>Kas.97</b>	2050	235	121	24816	414	0	4358	6814
<b>Ara.97</b>	2577	312	223	39292	535	0	5647	8925
<b>Oca.98</b>	174	4276	440	137823	9741	0	73217	197280
<b>Şub.98</b>	157	3655	384	109828	8118	0	79319	177552
<b>Mar.98</b>	225	5241	545	170125	12988	0	104945	256464
<b>Nis.98</b>	223	5379	531	152897	11365	0	85420	249888
<b>May.98</b>	314	7586	733	215348	16236	0	122029	332088
<b>Haz.98</b>	257	6069	607	187353	14450	0	108606	282768
<b>Tem.98</b>	280	6828	677	213195	15911	0	119588	322224
<b>Ağu.98</b>	285	6965	698	236883	17859	0	134232	2959200
<b>Eyl.98</b>	262	6207	649	204581	15261	0	114707	312360
<b>Eki.98</b>	231	5793	559	176585	13963	0	103725	272904
<b>Kas.98</b>	200	4828	349	129209	12177	0	86641	233448
<b>Ara.98</b>	251	6414	642	204581	15749	0	112267	305784
<b>Oca.99</b>	2284	8157	10608	44768	2526	0	0	282233
<b>Şub.99</b>	1998	7104	8357	37307	1783	0	0	254920
<b>Mar.99</b>	2855	10788	12536	65660	3047	0	0	373276
<b>Nis.99</b>	3306	14591	9805	82747	4411	0	320376	434449
<b>May.99</b>	4332	21076	13307	116459	5932	0	450900	584259
<b>Haz.99</b>	3534	17293	11206	91941	4867	0	367839	479392
<b>Tem.99</b>	1152	6021	3966	39955	6582	0	116397	520103
<b>Ağu.99</b>	1221	6397	4082	43587	7460	0	109343	551625
<b>Eyl.99</b>	1082	5645	3616	36323	7021	0	105816	472821
<b>Eki.99</b>	16226	19256	12406	417475	218241	0	381039	446703
<b>Kas.99</b>	13768	14725	10582	333980	197781	0	321502	381011
<b>Ara.99</b>	18685	19823	13866	453259	265981	0	440576	499256



Tablo A.10. 2000-2003 Arası Aylık Bazda Satış Miktarları (gr)

	8K	9K	10K	14K	18K	21K	22K	24K
Oca.00	1860	8839	998	294453	370203	0	302433	113972
Şub.00	1628	7699	786	245378	261320	0	265774	102943
Mar.00	2325	11691	1179	431865	446421	0	357420	150738
Nis.00	5325	2644	5316	259146	345772	41731	497988	138286
May.00	6977	3818	7215	364724	465004	59616	700872	185971
Haz.00	5692	3133	6076	287940	381541	49183	571764	152591
Tem.00	7120	3543	4186	282180	189403	32474	56887	199980
Ağu.00	7551	3764	4309	307832	214656	34442	53440	212100
Eyl.00	6688	3321	3817	256527	202029	31490	51716	181800
Eki.00	3275	5629	27361	389128	418366	284582	700278	222116
Kas.00	2778	4305	23338	311302	379145	179736	590860	189452
Ara.00	3771	5795	30580	422482	509884	269604	809696	248247
Oca.01	3432	2938	21980	240875	297579	4323	143846	220850
Şub.01	3003	2559	17318	200729	210056	4169	126411	199478
Mar.01	4290	3885	25977	353284	358845	6021	170000	292092
Nis.01	1232	7574	12189	279036	320494	9394	250616	471128
May.01	1615	10940	16542	392717	431009	13420	352718	633586
Haz.01	1317	8976	13930	310040	353649	11072	287744	519866
Tem.01	3604	11487	13518	279957	403794	12797	449366	421029
Ağu.01	3823	12205	13915	305408	457633	13573	422132	446546
Eyl.01	3386	10769	12325	254507	430714	12410	408515	382754
Eki.01	5394	21769	23671	333683	642946	37889	411661	836081
Kas.01	4577	16647	20190	266946	582670	23930	347339	713128
Ara.01	6211	22409	26456	362284	783590	35895	475983	934443
Oca.02	864	5811	10761	236311	404726	11000	205090	521429
Şub.02	756	5061	8478	196926	285689	10607	180230	470968
Mar.02	1081	7685	12718	346590	488053	15322	242379	689632
Nis.02	1897	14320	19539	278116	453321	0	205329	225646
May.02	2485	20685	26518	391422	609638	0	288982	303455
Haz.02	2028	16972	22331	309017	500216	0	235748	248989
Tem.02	1445	29915	101	330176	297688	0	275425	441631
Ağu.02	1532	31785	104	360192	337380	0	258732	468396
Eyl.02	1357	28045	93	300160	317534	0	250386	401483
Eki.02	13212	43054	5852	299935	353572	0	347698	773369
Kas.02	11210	32923	4991	239948	320424	0	293370	659638
Ara.02	15213	44320	6541	325644	430915	0	402026	864353
Oca.03	1307	14613	161	228186	322094	0	229328	418567
Şub.03	1144	12728	127	190155	227361	0	201530	378060
Mar.03	1634	19327	191	334673	388408	0	271023	553588
Nis.03	555	13968	0	129215	187940	0	100355	351141
May.03	727	20176	0	181857	252746	0	141240	472224
Haz.03	593	16554	0	143572	207382	0	115222	387466
Tem.03	1575	10717	20	204288	164450	0	95172	618936
Ağu.03	1671	11386	20	222860	186376	0	89404	656448
Eyl.03	1480	10047	18	185717	175413	0	86520	562670
Eki.03	2639	14343	9541	222757	170721	0	120185	1170814
Kas.03	2239	10968	8138	178206	154716	0	101406	998635
Ara.03	3039	14765	10664	241850	208066	0	138964	1308557

Tablo A.11. 2004-2006 Arası Aylık Bazda Satış Miktarları (gr)

	8K	9K	10K	14K	18K	21K	22K	24K
Oca.04	1255	7143	0	147838	148436	0	80503	1288704
Şub.04	1098	6221	0	123198	104778	0	70745	1163991
Mar.04	1568	9447	0	216829	178996	0	95140	1704415
Nis.04	4461	4903	241	191717	302724	0	269436	1564669
May.04	5846	7082	327	269823	407112	0	379207	2104210
Haz.04	4769	5811	275	213018	334041	0	309353	1726531
Tem.04	81745	160948	24183	451683	394800	1097	404738	2099065
Ağu.04	86699	171007	24895	492745	447440	1164	380208	2226281
Eyl.04	76791	150889	22050	410621	421120	1064	367944	1908240
Eki.04	15757	66331	16972	369117	327106	0	241864	2527562
Kas.04	13370	50724	14476	295293	296440	0	204073	2155861
Ara.04	18145	68282	18969	400755	398660	0	279656	2824922
Oca.05	1707	8571	0	265578	411173	0	357785	879427
Şub.05	1493	7465	0	34982	32499	0	22214	335684,2
Mar.05	2133	11336	0	72848	43435	0	23391	401945,3
Nis.05	5530	6684	347	414723	943012	0	523244	1068974
May.05	7246	9655	471	252202	591292	0	954936	1081624
Haz.05	5911	7922	396	808581	778496	0	771132	1160736
Tem.05	99028	188548	95757	978146	850729	1024	891150	1366145
Ağu.05	185030	197832	96514	821613	910826	8086	861383	1256513
Eyl.05	111632	167117	65181	721613	876933	19192	935800	1356708
Eki.05	321057	198420	75040	724167	923180	81	850508	1238040
Kas.05	379381	75262	71358	619334	802257	51	945116	1299282
Ara.05	32732	101315	27986	419096	572001	77	635899	1238643
Oca.06	3031	16470	0	275950	309662	0	95246	998897,8
Şub.06	1853	10023	0	110676	582729	0	118852	962956,2
Mar.06	3565	20498	0	220864	351401	0	129836	1190653
Nis.06	7975	9830	415	252851	395616	0	125829	1421965
May.06	9717	13204	524	230901	279762	0	99429	1442647
Haz.06	9671	13217	538	318718	150413	0	87429	1418752
Tem.06	215076	537363	92423	884460	790369	1244	855347	1474372
Ağu.06	115172	537984	71495	898715	917483	1319	955932	1443048
Eyl.06	394456	776777	86769	747786	917904	1447	841225	1479391
Eki.06	19889	53330	18769	353560	334230	202	792711	1370562
Kas.06	12892	31155	12230	116082	211397	128	319475	1388433
Ara.06	25481	61081	23339	427094	353215	192	515947	1384819

Tablo A.12 1997-2006 Arası 24K Altın Ürünlerin HAS Değerleri

Yıllar	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
1997	19802,1	16827,6	25175,2	22294,2	31484,8	27442,9	30983,7	34387,5	29703,1	25899,1	19602,8	29566,7
1998	156663	144446	207448	178328	252911	222296	248855	277620	238619	211043	165947	236818
1999	36249,6	29912,5	50807,3	355914	500600	406800	139235	135759	127436	774293	652387	887187
2000	730997	586510	920023	908482	1262902	1026877	392664	425408	381187	1446300	1177106	1623158
2001	510741	403334	650029	649422	696944	729156	900412	931859	867130	1107191	948234	1288248
2002	645968	509316	812345	704587	970093	787870	680083	712792	653772	781851	667373	906085
2003	590879	471387	742842	313745	432922	351312	334298	366572	323472	378386	321196	435505
2004	274457	217998	352008	589287	615078	662248	1029232	1075957	984949	719555	611161	828678
2005	879427	395684	401945	1068974	1081624	1160736	1366145	1256513	1356708	1238040	1299282	1238643
2006	998898	962956	1190653	1421965	1442647	1418752	1474372	1443048	1479391	1370662	1388433	1384819

Tablo A.13 1997-2006 Arası 9K-22K Altın Ürünlerin HAS Değerleri

Yıllar	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
1997	5758,38	5182,54	7485,89	7293,95	9693,27	8253,68	9405,35	86375,7	9117,44	7965,76	6814,08	8925,49
1998	197280	177552	256464	249888	332088	282768	322224	2959200	312360	272904	233448	305784
1999	282233	254920	373276	434449	584259	479392	520103	551625	472821	446703	381011	499256
2000	113972	102943	150738	138286	185971	152591	199980	212100	181800	222116	189452	248247
2001	220850	199478	292092	471128	633586	519866	421029	446546	382754	836081	713128	934443
2002	521429	470968	689632	225646	303455	248989	441631	468396	401483	773369	659638	864353
2003	418567	378060	553588	351141	472224	387466	618936	656448	562670	1170814	998635	1308557
2004	1288704	1163991	1704415	1564669	2104210	1726531	2099065	2226281	1908240	2527562	2155861	2824922
2005	795013	67216,9	101927	1434927	1484038	1777224	2183770	2144999	2076687	2110289	2015022	1303473
2006	492965	619618	516966	583062	441269	393636	2253559	2376151	2349555	1215222	522505	1009179

## ÖZGEÇMİŞ

1981 yılında, Niğde ilinde doğdu. İlköğrenimini Halil Kitapçı İlköğretim Okulu'nda ve Niğde Anadolu Lisesi'nde, liseyi Meram Fen Lisesi'nde tamamladı. 1999 yılında İ.T.Ü. Endüstri Mühendisliği bölümünü kazandı. 2004 yılında Endüstri Mühendisliği'nden mezun oldu. Aynı yıl İ.T.Ü. Fen Bilimleri Enstitüsü Endüstri Mühendisliği Ana Bilim Dalı Mühendislik Yönetimi Programı'nda Yüksek Lisans eğitimine başladı. 2004 yılından bu yana Kurumsal Kaynak Planlaması danışmanlığı yapmaktadır. Microsoft İşortağı olan LuckyEye firmasında Dynamics AX ve Dynamics NAV programlarının Finans, Ticaret ve Üretim danışmanı olarak çalışmaktadır.