

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**TEMİZLİK KAĞITLARI SEKTÖRÜNDE
YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ**

YÜKSEK LİSANS TEZİ

Mihriban YÜCESOY

Anabilim Dalı : Endüstri Mühendisliği

Programı : Endüstri Mühendisliği

HAZİRAN 2011

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**TEMİZLİK KAĞITLARI SEKTÖRÜNDE
YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ**

**YÜKSEK LİSANS TEZİ
Mihriban YÜCESOY
(507081121)**

Tezin Enstitüye Verildiği Tarih : 06 Mayıs 2011

Tezin Savunulduğu Tarih : 08 Haziran 2011

**Tez Danışmanı : Doç. Dr. Tufan Vehbi KOÇ (İTÜ)
Diğer Jüri Üyeleri : Prof. Dr. Nahit SERARSLAN (İTÜ)
Doç. Dr. Alev GÜMÜŞ (YTÜ)**

HAZİRAN 2011

Aileme,

ÖNSÖZ

Rekabet koşullarının arttığı, günümüz endüstrilerinde müşterinin seçiciliğini ve davranışlarını yorumlayabilen, üretime konu olacak ürünlerin piyasadaki hareketlerini doğru tahmin edebilen işletmeler hayatta kalabileceklerdir. Doğru talep tahmini bu aşamada başarının anahtarı olarak gösterilebilir.

Talep tahminini gerçekleştirebilmek ise talebi belirleyen unsurların ortaya konulması ve her birinin talep üzerindeki etkisinin tespit edilmesi ile mümkündür. Talebi etkileyen iç ve dış koşullar düşünüldüğünde bir çok unsurun var olması ve bu unsurların talep miktarını ne şekilde etkileyeceğinin belirlenmesi, süreci oldukça zorlu hale getirmektedir. Bu noktada doğru talep tahmin yönteminin seçilmesi oldukça kritik bir karardır.

Bu çalışmada yapay sinir ağları ile Türkiye’de temizlik kağıdı sektöründe parametrelere dayalı talep tahmini için model oluşturulmuş ve modelin test edilmesi sonrasında gelecek ile ilgili değerlendirmeler yapılmıştır. Ayrıca her bir parametrenin talebe olan etkisi gösterilmiş, diğer talep yöntemleri ile karşılaştırma yapılmıştır.

Çalışmam sırasında bana destek olan aileme, hocam Doç. Dr. Tufan Vehbi Koç’a ve her zaman yanımda olan arkadaşlarıma teşekkürlerimi sunarım.

Ayrıca yüksek lisans eğitimim süresince bana maddi anlamda büyük destek sağlayan Tübitak Bilim İnsanı Destekleme Daire Başkanlığı’na teşekkürlerimi sunmayı bir borç bilirim.

Haziran 2011

Mihriban Yücesoy
(Endüstri Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	v
KISALTMALAR	xi
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xv
ÖZET.....	xvii
SUMMARY.....	xix
1. GİRİŞ.....	1
2. TALEP TAHMİNİ.....	3
2.1 Tahmin İhtiyacı	3
2.2 Talep Tahmin Kavramı	4
2.3 Talebi Etkileyen Faktörler	5
2.4 Talep Tahmin Varsayımları ve Özellikleri	5
2.5 Talep Tahmin Araştırmasının Adımları.....	6
3. TALEP TAHMİN YÖNTEMLERİ.....	9
3.1 Nitel Tahmin Yöntemleri.....	9
3.1.1 Uzman görüşü yöntemi.....	9
3.1.2 Delphi tekniği.....	9
3.1.3 Anket yöntemi	10
3.1.4 Satış gücü birleşimi	11
3.1.5 Yaşam eğrisi benzeşimi	11
3.2 Nicel Tahmin Yöntemleri	12
3.2.1 Zaman serileri analizi	13
3.2.1.1 Yalın yaklaşım.....	15
3.2.1.2 Aritmetik ortalama yöntemi.....	15
3.2.1.3 Hareketli ortalamalar yöntemi.....	15
3.2.1.4 Ağırlıklı hareketli ortalamalar yöntemi.....	16
3.2.1.5 Üssel ağırlıklandırılmış hareketli ortalama yöntemi.....	16
3.2.1.6 Basit üssel düzgünleştirme yöntemi.....	17
3.2.1.7 Holt lineer metodu.....	18
3.2.1.8 Holt winter trend ve mevsimsellik metodu.....	19
3.2.2 Nedensel yöntemler	19
3.2.2.1 Regresyon analizi.....	19
3.2.2.2 Korelasyon analizi.....	21
3.3 Box Jenkins Yöntemleri	22
3.3.1 Otoregresif modeller – AR(p) modelleri	23
3.3.2 Hareketli ortalamalar – MA(q) modelleri.....	23
3.3.3 Otoregresif hareketli ortalama yöntemi – ARMA(p,q)	23
3.3.4 Durağan olmayan otoregresif hareketli ortalama yöntemi - ARIMA (p,d,q)	23
3.4 Yapay Zekâ Çözümleri	25

3.4.1 Bulanık mantık.....	25
3.4.2 Yapay sinir ağları.....	27
3.5 Tahmin Yöntemlerinin Doğruluğunun Ölçülmesi	27
3.5.1 Ortalama hata (ME).....	27
3.5.2 Ortalama mutlak hata (MAE)	28
3.5.3. Ortalama hata kare kriteri (MSE).....	28
3.5.4 Ortalama mutlak hata yüzdesi (MAPE)	28
3.5.5 Theil U istatistigi (U)	28
3.5.6 İzleme sinyali.....	29
4. YAPAY SİNİR AĞLARI METODOLOJİSİ.....	31
4.1 Yapay Zekâ Kavramı	31
4.2 Yapay Sinir Ağlarına Giriş	32
4.2.1 Yapay sinir ağlarının tanımı	32
4.2.2 Yapay sinir ağlarının tarihsel gelişimi	33
4.2.2.1 1970 öncesi YSA ile ilgili çalışmalar.....	33
4.2.2.2 1970 sonrası YSA ile ilgili çalışmalar.....	35
4.2.3 Yapay sinir ağlarının avantajları.....	36
4.2.4 Yapay sinir ağlarının dezavantajları.....	38
4.2.5 Yapay sinir ağlarının kullanım alanları	39
4.3 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları	40
4.3.1 Biyolojik sinir hücresi	40
4.3.2 Yapay sinir hücresi.....	43
4.3.2.1 Girdiler.....	44
4.3.2.2 Ağırlıklar.....	44
4.3.2.3 Toplama fonksiyonu.....	44
4.3.2.4 Aktivasyon fonksiyonu.....	45
4.3.2.4 Çıktı.....	47
4.3.3 Yapay sinir hücresinin çalışma prensibi.....	47
4.3.4 Yapay sinir ağının yapısı ve sınıflandırılması	48
4.3.4.1 Katman sayısına göre sınıflandırma.....	48
4.3.4.2 Bağlantı yapılarına göre sınıflandırma.....	49
4.3.4.3 Öğrenme stratejilerine göre sınıflandırma.....	50
4.3.5 Yapay sinir ağlarının eğitimi ve öğrenme kuralları	51
4.3.5.1 Çevrimiçi öğrenme.....	53
4.3.5.2 Çevrimdışı Öğrenme.....	53
4.3.5.3 Öğrenme kuralları.....	53
4.3.6 Çok katmanlı algılayıcılar	54
4.3.6.1 İleri besleme aşaması.....	56
4.3.6.2 Geri yayılma aşaması.....	58
4.3.6.3 ÇKA ağının genelleştirilmiş delta öğrenme kuralı ile eğitimi.....	61
Çıkış Katmanının Bağlantı Ağırlıklarının Ayarlanması.....	63
Gizli Katman 2'nin Bağlantı Ağırlıklarının Ayarlanması.....	66
Gizli Katman 1'in Bağlantı Ağırlıklarının Ayarlanması.....	68
4.3.6.4 Öğrenmenin devamı ve toplam hata fonksiyonu.....	68
4.3.6.5 ÇKA ağlarında öğrenme performansının artırılması.....	69
Dinamik Öğrenme Hızı Ayarlaması.....	69
Momentum Terimi ve Öğrenme Performansına Etkisi.....	71
4.3.6.6 Öğrenme ve ezberleme arasındaki fark.....	73
4.2.6.7 ÇKA ağlarında öğrenmeyi etkileyen faktörler.....	73
4.3.6.8 ÇKA ağlarında kullanılacak verilerin ölçeklendirilmesi.....	76

5. TALEP TAHMİNİ UYGULAMASI	79
5.1 Talep Tahmini Probleminin Tanımlanması	79
5.2 Yapay Sinir Ağı Mimarisi.....	81
5.2.1 Momentum katsayısının belirlenmesi.....	82
5.2.2 Öğrenme katsayısının belirlenmesi	82
5.2.3 Çevrim sayısının belirlenmesi.....	83
5.2.4 Gizli hücre sayısının belirlenmesi	84
5.3 Yapay Sinir Ağı'nın Eğitilmesi	84
5.4 Sonuçların Test Edilmesi ve Değerlendirilmesi.....	87
5.5 YSA Yönteminin Diğer Talep Yöntemleriyle Karşılaştırılması.....	90
5.5.1 Basit regresyon yöntemiyle talep tahmini	90
5.5.2 Çoklu regresyon yöntemiyle talep tahmini	91
6. SONUÇ VE DEĞERLENDİRME	93
KAYNAKLAR.....	95
EKLER.....	99
ÖZGEÇMİŞ	115

KISALTMALAR

ADALINE	: Adaptif Doğrusal Eleman
AR	: Otoregresif
ARIMA	: Bütünlesik Otoregresif Hareketli Ortalama
ARMA	: Otoregresif Hareketli Ortalama
ÇKA	: Çok Katmanlı Algılayıcı
MA	: Hareketli Ortalama
MADALINE	: Çoklu Adaptif Doğrusal Eleman
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Hata Yüzdesi
ME	: Ortalama Hata
MSE	: Ortalama Hata Kare
U	: Theil-U İstatistiği
UMN	: University of Minnesota
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zeka

ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1: Nitel yöntemlerin karşılaştırılması.....	11
Çizelge 4.1: Beynin bölgelere göre fonksiyonları	41
Çizelge 4.2: Biyolojik sinir ağı ve yapay sinir ağının karşılaştırılması.	43
Çizelge 4.3: Toplama fonksiyonu örnekleri	45
Çizelge 4.4: Aktivasyon fonksiyonu örnekleri	46
Çizelge 4.5: Geri yayılma ile hatanın minimizasyonu ve döngü kavramı.	60
Çizelge 5.1: Momentum katsayısının farklı değerleri için tahmin değerleri.	82
Çizelge 5.2: Öğrenme katsayısının farklı değerleri için tahmin değerleri.	83
Çizelge 5.3: Çevrim sayısının farklı değerleri için tahmin değerleri.	83
Çizelge 5.4: Çevrim sayısının farklı değerleri için tahmin değerleri.	83
Çizelge 5.5: Gizli hücre sayısının farklı değerleri için tahmin değerleri.....	84
Çizelge 5.6: Yapay sinir ağı katman ve hücre sayısı.	84
Çizelge 5.7: Yapay sinir ağı parametreleri.	85
Çizelge 5.8: 2010 yılı gerçekleşen ve tahmin edilen değerlerin kıyaslanması.	87
Çizelge 5.9: Çevrim Sayısı=1000'e göre gerçekleşen/tahmin edilen değerler.	87
Çizelge 5.10: Gizli hücre sayısı=12'ye göre gerçekleşen/tahmin edilen değerler.	87
Çizelge 5.11: Gizli hücre sayısı=2'ye göre gerçekleşen/tahmin edilen değerler.	88
Çizelge 5.12: Basit regresyon modeli ağırlık değerleri.	90
Çizelge 5.13: Basit regresyon modeline göre tahmin/gerçekleşen kıyaslaması.	90
Çizelge 5.14: Model-1 regresyon analizi ağırlıkları.....	91
Çizelge 5.15: Model-2 regresyon analizi ağırlıkları.....	91
Çizelge 5.16: Regresyon analizi ile tahmin edilen değerlerin gerçek değer ile karşılaştırılması.	92
Çizelge A.1: Yıllık temizlik kâğıdı üretim miktarı (ton/yıl).....	102
Çizelge A.2: Yıllık temizlik kâğıdı ithalat miktarı (ton/yıl)	103
Çizelge A.3: Toptan eşya fiyat endeksi (1981=100) değerleri	104
Çizelge A.4: Kişi başına düşen yıllık GSYİH değerleri (TL)	105
Çizelge A.5: Yıllık genel nüfus değerleri	106
Çizelge A.6: Yıllık kent nüfusu değerleri.....	107
Çizelge A.7: Yıllık okuryazar oranı değerleri (%)	108
Çizelge A.8: Türkiye'de temizlik kâğıdı yıllık satış miktarı (ton)	109

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Tahmin alanlarının etkileşimi.....	3
Şekil 3.1: İlişkisel tahmin yöntemi akışı	12
Şekil 3.2: Zaman serileri tahmin yöntemi akışı	13
Şekil 3.3: Zaman serilerini etkileyen bileşenler.	14
Şekil 3.4: En küçük kareler yöntemi.	20
Şekil 3.5: Box Jenkins Metodolojisi.....	22
Şekil 3.6: Bulanık mantığın elemanları ve çalışması.	26
Şekil 3.7: Üyelik fonksiyonu örneği.....	26
Şekil 4.1: İnsan beyni.	41
Şekil 4.2: Biyolojik sinir hücresinin yapısı.....	42
Şekil 4.3: Sinir hücreleri arası bilgi alışverişi.	42
Şekil 4.4: Yapay sinir hücresinin yapısı.	44
Şekil 4.5: Sigmoid fonksiyonunun şekilsel gösterimi.	46
Şekil 4.6: Bir yapay sinir hücresinin çalışma örneği.	47
Şekil 4.7:Yapay sinir ağlarında katmanların birbirleri ile ilişkileri.	49
Şekil 4.8: İleri ve geri beslemeli ağ yapıları.	50
Şekil 4.9: Örnek bir ÇKA ağı.....	56
Şekil 4.10: Geri besleme bağlantıları ve hatanın geri yayılması.....	59
Şekil 4.11: Genelleştirilmiş delta öğrenme kuralının uygulanacağı ÇKA.	62
Şekil 4.12: Parametre uzayında optimal ağırlığa yakınsama süreci. a) düşük öğrenme hızı. b) yüksek öğrenme hızı. c) yüksek öğrenme hızı + momentum terimi	72
Şekil 4.13: Örnek hacminin genelleme üzerindeki etkisi.	74
Şekil 4.14: Gizli katman sayısının öğrenme ve genelleme üzerindeki etkisi.	75
Şekil 5.1: EasyNN programı katman ve hücre sayısının tanımlanması.	84
Şekil 5.2: EasyNN programı parametre tanımlama ekranı.	85
Şekil 5.3: Kullanılan ÇKA ağ yapısı.	85
Şekil 5.4: Öğrenme grafiği.....	86
Şekil 5.5: Tahmin grafiği.	86
Şekil 5.6: Duyarlılık analizi.	88
Şekil 5.7: Girdi parametrelerinin önem dereceleri.	89
Şekil B.1: Model-1 çoklu regresyon program çıktısı.....	111
Şekil B.2: Model-2 çoklu regresyon program çıktısı.....	112

TEMİZLİK KÂĞITLARI SEKTÖRÜNDE YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ

ÖZET

Rekabet koşullarının arttığı, ürün yaşam sürelerinin kısaldığı günümüz endüstrilerinde müşterinin seçiciliğini ve davranışlarını yorumlayabilen, üretime konu olacak ürünlerin piyasadaki hareketlerini doğru tahmin edebilen işletmeler hayatta kalabileceklerdir. Doğru talep tahmini bu aşamada başarının anahtarı olarak gösterilebilir.

Sanayinin bu değişen yapısı beraberinde firmalara müşterinin isteyeceği malı, isteyeceği miktarda önceden sunma ve bunun için gerekli hazırlığı yapma zorunluluğu getirmektedir. Bunun için firmalar talep tahmin yöntemlerine yönelmişlerdir ve bu yönelim ile birlikte birçok yöntem gelişmiştir.

Yargısal metotlar, nedensel yöntemler, zaman serileri yöntemleri ve stokastik yöntemlerin yanı sıra yapay zekâ tabanlı tahmin modelleri özellikle son yıllarda öne çıkmıştır. Gelişen teknolojiye paralel olarak artan işleme ve hesaplama gücü ile birlikte, karmaşık simülasyonların yapılması ve gelişmiş yapay zeka teknolojilerini kullanarak temel kriterlere dayalı tahmin modellemelerinin gerçekleştirilmesi mümkün hale gelmiştir. Bu modellemelerin gerçekleştirilmesini sağlayan önemli bir uygulama alanı ise “Yapay Sinir Ağları”dır. Yapay sinir ağları insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleri olarak tanımlanabilir.

Bu çalışmada, yapay sinir ağları ile parametrelere dayalı tahmin modeli oluşturulmuştur. Çalışmada öncelikle talep tahmini ve yapay sinir ağları kavramları açıklanmıştır. Uygulama bölümünde ise Türkiye’de temizlik kağıtları sektöründe yıllık temizlik kağıdı satışları ile ilgili bir model kurulup uygulanmıştır. Ayrıca basit ve çoklu regresyon modeli ile de temizlik kağıdı talep tahmini yapılmış ve sonuçlar karşılaştırılmıştır. Uygulama sonucunda yapay sinir ağı yönteminin etkin bir talep tahmini yöntemi olduğu gösterilmiştir.

SALES FORECASTING WITH ARTIFICIAL NEURAL NETWORKS IN TISSUE PAPER SECTOR

SUMMARY

In today's industries which has hard competition and short product lifecycle, companies who understand behaviour and choices of customers' and forecast the motion of products properly will be alive in the future. Forecast with little error is the key factor of the success in this way.

With this improvement of the industry, companies have to forecast what their customers wants and how much they need to produce before customer demands. So companies bended demand forecasting methods and because of this lot's of forecasting method and tools improved.

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

In this study, a forecasting model with parameters is implemented with using artificial neural networks. First, artificial neural network and demand predictions concepts are explained. In application part of this study, artificial neural networks sales forecasting model for tissue paper in Turkey is builded and implemented. On the other hand, prediction models are builded for simple and multiple regresion analysis. In conclusion, results are compared and shown that artificial neural networks is an efficient tool for forecasting.

1. GİRİŞ

Gelecek, insanlar için olduğu gibi işletmeler için de belirsizlikler ile doludur. Dolayısıyla, rekabetin arttığı ve ürün yaşam sürelerinin kısaldığı günümüz koşullarında piyasayı doğru bir şekilde analiz eden ve talep tahminini doğruya yakın yapmayı başaran işletmeler, faaliyetlerini minimum hata ile planlama olanağına sahip olacaklardır. İşletmelerde her düzeyde alınan yönetsel kararlar, doğrudan ya da dolaylı olarak gelecek hakkında yapılan tahminlere bağlı olmaktadır.

Artan rekabet ortamında yaşanan hızlı gelişmeler, işletmelerin gün geçtikçe daha isabetli, daha az sapma gösteren tahminlere ihtiyacını arttırmaktadır. Bu ihtiyacı, belirlenen amaç ve zaman faktörüne göre karşılayacak farklı talep tahmin yöntemleri bulunmaktadır. Talep tahmininde kullanılan yöntemler temel olarak “nitel yöntemler” ve “nicel yöntemler” olmak üzere ikiye ayrılır (Eski, 2006). Nitel yöntemler, daha çok bireysel tecrübeler ve değerlendirmelere dayanır. Nicel yöntemler ise, istatistiksel ve matematiksel verilere dayanan yöntemlerdir. Uygulamada genellikle, bu iki yöntemin karması tercih edilir (Heizer ve Render, 2004).

Yapay sinir ağı yöntemi istatistiksel verileri kullanması yönüyle nicel yöntemlere, faktörler arasındaki ilişki ve derecelerini öğrenmesi yönüyle nitel yöntemlere benzemektedir ve etkin bir talep tahmin yöntemi olarak son yıllarda öne çıkmaktadır (Adıyaman, 2007).

Çalışmada, Türkiye’de büyümekte olan temizlik kağıtları sektöründe talep tahmini yapay sinir ağı kullanılarak yapılmış ve yapay sinir ağlarının talep tahmininde etkin bir yöntem olarak kullanılabileceği gösterilmeye çalışılmıştır.

İkinci ve üçüncü bölümde, talep tahmini ve talep tahmin yöntemleri hakkında bilgi verilmiştir. Nicel ve nitel yöntemler ile birlikte yapay sinir ağlarının alternatif bir yöntem olarak talep tahmininde kullanılmasına değinilmiştir.


Dördüncü bölümde, yapay sinir ağı konusunda genel bilgi verilerek bu tez kapsamında kullanılacak ÇKA (Çok Katmanlı Algılayıcı) modeli ayrıntılı olarak açıklanmıştır.

Beşinci bölümde, uygulama modeli ve bu kapsamda yapılan çalışmalar ayrıntılı bir şekilde anlatılmıştır. Yapay sinir ağları kullanılarak talep tahmini yapılmış ve sonuçları incelenmiştir. Ayrıca çoklu regresyon modeli ile de talep tahmini yapılmış ve sonuçlar karşılaştırılmıştır.

2. TALEP TAHMİNİ

2.1 Tahmin İhtiyacı

Tahmin, yönetimin karar verme aktivitelerinin bir parçasıdır. Organizasyonun değişikliklere karşı bağımlılığının azalması ve çevresi ile daha bilimsel ilişkiler kurabilmesi için etkin tahminlere ihtiyaç vardır. Bir organizasyon içerisindeki tüm bölümlerin diğer bölümler ile etkileşim halinde olduğu düşünüldüğünde iyi ya da kötü yapılan bir tahmin doğru orantılı olarak tüm organizasyonu etkileyecektir (Makridakis ve diğ.,1998).



Şekil 2.1: Tahmin alanlarının etkileşimi (Makridakis ve diğ.,1998).

Bir organizasyon içerisindeki tahmin alanlarının birbirleri ile etkileşimleri şematik olarak Şekil 2.1 'de gösterilmiştir.

Tahmini, bir yönetim prosesi olarak gören firmalar daha başarılı olabilirler. Bu firmalar üretim ya da pazarlama departmanlarından bağımsız olarak çalışan ve tahmin yapmak ile görevli ayrı departmanlara sahiptirler. Tahminin önemini

kavramış olan bu tür firmalar organizasyonel yapılarını da bu prosesi yönetecek şekilde oluşturmuşlardır (Moon ve diğ., 2003).

Tahminler, işletmelerde alınan bütün seviyedeki kararların temelini oluşturur. Her karar gelecekte bir yerlerde hayata geçecektir, dolayısı ile gelecekte oluşacak koşullar düşünülerek tahmin yapılmalıdır. Bunun yanı sıra tahminlemede önemli bir konu ise sürekliliğin sağlanmasıdır. Zaman içerisinde tahminin etkisi ve performansı ölçülerek tahminler güncellenmeli, kararlar değiştirilmeli ve bu süreç sürekli olarak devam etmelidir (Arsham, 1994).

2.2 Talep Tahmin Kavramı

Talep, tüketicilerin bir ürün veya hizmeti belirli bir fiyat seviyesinden almaya hazır oldukları miktara denir (Tekin, 1996). Talep tahmini ise, üretilen mal ve hizmetlerin piyasada bulunan tüketiciler tarafından ne ölçüde talep edileceğinin önceden kestirilmesi sürecini ifade etmektedir. Talep tahmini, işletmelerde üretim planlama ve kontrol sistemi için temel girdiyi oluşturmaktadır.

Ekonomik istikrarın sağlandığı ortamlarda, piyasa koşullarındaki değişimler yüksek seviyelerde olmamaktadır. Böyle ortamlarda ürünlere olan talep miktarları da çok fazla dalgalanma göstermediğinden, talep tahminlerine fazla bir ihtiyaç duyulmamaktadır. Ancak ekonomik istikrarsızlığın yüksek olduğu ortamlarda piyasa koşullarının nasıl olacağının, ürünlerin ne ölçüde ve hangi fiyattan talep edileceğinin tahmin edilmesi çok büyük önem taşımaktadır (Eski, 2006).

Başarılı bir tahmin ile hammaddelerin doğru zaman ve miktarda alınması sağlanarak maliyetler düşürülebilir. Aynı şekilde lojistik departmanı daha uzun vadeli sözleşmeler yaparak maliyetlerini düşürebilir. Bu tür sözleşmeler ancak talep başarılı bir şekilde öngörülebilir ise uygulanabilir. En önemlisi ise iyi bir tahmin firmanın stok seviyesinin belirlenmesinde önemli rol oynayacaktır. Tahminlerdeki doğruluk seviyesi istenen miktarlarda değil ise stok seviyelerinde bu riski azaltacak güvenlik stokları oluşturulacaktır. Başarılı bir tahmin ile daha az stok bulundurulabilir ve stok taşıma maliyeti azaltılabilir (Moon ve diğ., 1998).

Firmalar, birçok stratejik kararı verirken sistematik ve bilimsel tahminlere ihtiyaç duyarlar. Tahmin sürecinin her bir adımı kritik önem taşımaktadır ve talep tahminleri, çoğu kez tek bir yöntem ile yapılamamaktadır. İyi bir talep tahmini için,

öncelikle talebi etkileyen faktörlerin belirlenmesi ve bu faktörlerin talebe olan etkilerinin açıklanması gereklidir.

2.3 Talebi Etkileyen Faktörler

Ürünün özellikleri ve talep modeli, yapılacak tahmin tipi ve kapsayacağı zaman süresini etkiler. Eğer ürüne olan talep hemen hemen sabit ise, tahminin zaman süresi daha kısa olabilir. Planlama, talebin daima aynı düzeyde kalacağı kabulüne dayanır. Böyle durumlarda var olan kapasite genellikle talep hacminin çoğunu karşılayabilir. Tahmini artırmak çok gerekli değildir (Şengör, 2002).

Ürüne olan talep dalgalanmalar gösteriyorsa, tahmin hiç olmazsa bir dönemi kapsamına almalıdır. Tercih edilen tahmin, iki tepe noktası arasındaki süreyi içine alır. Bu süre, maksimum talebi karşılamak için daha iyi üretim ve stok planlama imkânları sağlar. Eğer talepte dönemsel değişiklikler varsa, talebi karşılamak için fazla mesai ve/veya ek stok gerekli olabilir (Şengör, 2002).

Talepte uzun bir devrede gittikçe artan bir eğilim (trend) bekleniyorsa, zorunlu olacak genişleme veya donanımın sağlanmasını planlamaya imkân veren bir zaman süresi için tahmin yapmak gereklidir. Bu zaman aralığı birkaç aydan, birkaç yıla kadar değişebilir (Şengör, 2002).

Bazı ürünler için talep değerleri mevsimlere göre azalır veya çoğalır. Böyle durumlarda öncelikle talepteki mevsimsel değişimlerin nedenini iyi belirlemek gerekir. Eğer talebin bazı mevsimlerde fazla, bazılarında az olmasını gerektiren geçerli nedenler varsa o zaman mevsimsel tahmin yöntemleri kullanılabilir (Şengör, 2002).

2.4 Talep Tahmin Varsayımları ve Özellikleri

Talep tahmini yaparken göz önüne alınması ve kabul edilmesi gereken önemli unsurlar bulunur. Bu unsurları özetlemek gerekirse;

- Tahminler genellikle yanlıştır, çünkü tahmin yapılan dönemde öngörülemeyen durumlar meydana gelebilir. Planlama sistemi tahmin hatalarına karşı hazırlıklı olmalıdır.

- İyi bir tahmin sadece rakamdan ibaret değildir. Tahminler belli bir rakam değil, bir geçerlilik aralığı olarak veya bir tahmin hatası dağılımı ile verilmelidir.
- Grup tahminleri daha doğrudur. Bir grup için yapılan tahminin hata payı, bireysel tahminlerin hata payından daha küçüktür.
- Tahminlerin doğruluğu, tahmin süresiyle ters orantılıdır (Heizer ve Render, 2004).

Yapılan varsayımlarla birlikte iyi bir tahminin özellikleri;

- Zamanı dikkate almalı. Gereken değişiklikler için yeterli zaman verilmelidir.
- İsabetli olmalı ve isabet derecesi belirtilmelidir.
- Güvenilir olmalı.
- Anlamlı birimler şeklinde ifade edilmeli.
- Yazılı olmalı.
- Anlamada ve kullanımda kolaylık sağlamalı.
- Tahmin maliyeti, sağlanan faydadan daha az olmalıdır (Stevenson, 2005).

2.5 Talep Tahmin Araştırmasının Adımları

Talep tahminlerinin gerçekleştirilmesinde izlenmesi gereken süreç beş aşamadan oluşmaktadır:

1. *Talep Tahminin Amacının Belirlenmesi:* Yapılacak olan tahminlerin hangi amaçla kullanılacağı ve ne zaman gerekli olacağının belirlenmesi aynı zamanda talep tahmininin ne kadar ayrıntılı olması gerektiğini göstermektedir. Tahmin amacı dikkate alınarak, gerekli olan iş gücü, süre, donanım ve benzeri ihtiyaçlar ortaya konmalı ve tahminin ne kadar hassas olacağı belirlenmelidir (Eski, 2006).
2. *Talep Tahmin Döneminin Belirlenmesi:* Talep araştırması sonuçlarının kullanılış amacı ile periyodun uzunluğu arasında yakın bir ilişki vardır. Örneğin, günlük iş emirlerinin hazırlanmasında yararlanılacak tahminlerin aylık dönemler için yapılması son derece yanıltıcı sonuçlar verebilir. Çünkü

günlük değerlerdeki oynamalar, aylık dönemlerde tamamen kaybolur (Tekin, 1996).

3. *Verilerin Toplanması:* Talep tahminlerinin yapılabilmesi için, bu süreçte temel alınacak verilerin toplanması ve derlenmesi gerekmektedir. Toplanan veriler, aynı zamanda kullanılacak talep tahmin yönteminin ne olması gerektiği konusunda yol gösterici olmaktadır. Yapılacak olan tahminlerin doğruluğu ve geçerliliği, eldeki verilerin doğruluğuna ve güvenilirliğine bağlıdır. Eksik veya olması gerekenden daha ayrıntılı veriler, araştırmanın maliyetini ve tahmin sonuçlarını elde etme süresini arttırdığı gibi sonuçların duyarlılığını da, olumsuz olarak etkilemektedir (Eski, 2006).
4. *Tahmin Yönteminin Seçilmesi ve Talebin Tahmin Edilmesi:* Yapılacak olan tahminin amacı ve eldeki verilerin niteliğine bağlı olarak en uygun talep tahmin yöntemi seçilmelidir. Toplanan bilgilerin belirsizlik, duyarlık, değişim biçimi gibi nitelikleri ile uygulama amaçları kullanılacak yöntemin seçiminde göz önüne alınması gereken faktörlerdir (Şengör, 2002).
5. *Tahmin Sonuçlarının Başarısının İzlenmesi:* Tahmin sonuçlarının gerçek değerlerle karşılaştırılması gerekir. Belirgin bir sapma gözleniyorsa, kullanılan yöntemin özellikleri ve varsayımları ile verilerin doğruluğu gözden geçirilmelidir.

3. TALEP TAHMİN YÖNTEMLERİ

Üretilen mal ve hizmetler ile birlikte tüketici davranışları da birbirinden farklı olduğundan dolayı tek bir tahmin yönteminden bahsetmek mümkün değildir. Günümüze kadar birçok tahmin yöntemi geliştirilmiş ve farklı şekillerde gruplandırılmıştır. Tahmin yöntemleri zaman aralıklarına, mevcut durumdaki karar ölçütlerine, sağlanabilir veriye ve daha pek çok ölçüte bağlı olarak çeşitlenmektedir. Talep tahmin yöntemleri temel olarak Nitel ve Nicel Tahmin Yöntemleri olmak üzere ikiye ayrılmaktadır.

3.1 Nitel Tahmin Yöntemleri

Elde yeterli veri olmadığında veya istatistiksel verileri derleyip analiz edecek kadar süre veya kaynak bulunmadığında, alanlarında deneyimli ve uzman kişilerin görüşlerine ve bireysel yargılarına dayanan nitel talep tahminlerine başvurulmaktadır. Bu yöntemlerin en önemli avantajı, istatistiksel tahmin yöntemlerine dâhil edilemeyen sezgisel yargıların talep tahmin sürecine dâhil edilebilmesidir (Hoang, 2006).

3.1.1 Uzman görüşü yöntemi

Mali işler, satın alma, üretim, yönetim kurulu gibi kurullardaki idari görevlilerin ve yöneticilerin tecrübelerine ve bilgilerine dayanılarak yapılan tahminlerdir. Bazı dönemlerde özellikle kısa zamanda karar verilmesi gerekiyorsa verilerle ve formüllerle uğraşmaktansa bu yöntem kullanılabilir. Elbette sorumluluk, kararı birlikte verenlerin olacaktır. Bu yöntemin avantajları basit, uygulaması kolay ve düşük maliyetli olmasıdır. Yöntemin en büyük zayıflığı ise yöntemin tamamen kişisel yargılara ve düşüncelere dayanmasıdır.

3.1.2 Delphi tekniği

Delphi tekniği, bir ürüne ait gelecekte oluşması beklenen talebin tahmin edilmesi amacıyla, uzman kişilerin yüz yüze görüşmeler ve bir arada tartışmalar yapmadan

talebin gelecekte ne olacağı hakkında karar vermelerine ve uzlaşmalarına imkân sağlayan bir yöntemdir (Eski, 2006). Bu yöntem, 1950'lerde Rand firmasında çalışan Olaf Helmer ve Norman Dalkey adındaki iki araştırmacı tarafından geliştirilmiştir. Delphi yönteminin mantığı, birden fazla anket formunun gönderilmesi sonucunda “geri besleme” yoluyla grup üyelerinin ortak bir görüş birliğine varmalarını sağlamaktır (Seaton ve Bennet, 1996).

Bu karar verme tekniğinde önce konunun uzmanı olan kişilere probleme bakış açıları, çözüm önerileri ve gelecek ile ilgili tahminleri hakkında yazılı bir form gönderilir. Formlar uzman kişiler tarafından doldurulduktan sonra geri gönderilir. Tüm grup üyelerinin görüş ve önerileri sınıflandırılır, ortalamadan çok uzakta olan uç görüşler çıkarılır ve geriye kalan tüm bilgiler tekrar yazılı olarak kendilerine gönderilir. Bu işlem, karar alınıncaya ve uzlaşma gerçekleşinceye kadar devam eder.

Dalkey (1972) Delphi tekniğinin 3 ana özellik üzerine kurulu olduğunu belirtmiştir.

Birinci önemli özellik tekniğin katılımı gizlilik ilkesine dayanmasıdır. Bu özellik Delphi'nin başarısının anahtarı olarak görülmektedir. Araştırma süresince öne sürülen düşüncelerin kime ait olduğu gizli tutulur. Bireylerden çok fikirlerin öne çıkması bu şekilde sağlanır. Grup içinde çok iyi tanınan, saygı duyulan kişilerin görüşlerine koşulsuz onay bu şekilde engellenir. Hiçbir çekince olmadan değişik, yeni fikirlerin herkesten gelmesi, katılımı gizlilik özelliği ile güvence altına alınır.

İkinci özellik grup tepkisinin istatistiksel analizidir. Her bir Delphi anketi uygulandıktan sonra istatistiksel olarak analiz edilir. Bu analizlerde kullanılan istatistiklerin neyi ifade ettiği katılımcılar tarafından iyi bilinmelidir.

Son olarak teknik, kontrollü geri besleme üzerine kuruludur. Delphi tekniğinde ardışık anketler kullanılır. Anketlerin istatistiksel analizi tamamlandıktan sonra analiz sonuçları, yani anketi yanıtlayanların genel eğilimleri bir sonraki anketle birlikte katılımcılara iletilir. Bu şekilde bireyler düşüncelerini kendilerine iletilen sonuçlarla, farklı görüş ve yaklaşımlarla karşılaştırarak yeniden gözden geçirirler.

3.1.3 Anket yöntemi

Yeni bir ürün piyasaya sürülürken veya var olan bir ürün için farklılaştırma çalışması yapılırken talebin tahmin edilmesi amacıyla hedef tüketicilere anket yapma yöntemi kullanılmaktadır.

Anket yöntemi, gelişmiş ülkelerde pazarlama araştırması yöntemleri içerisinde en çok kullanılan yöntem olmasına rağmen en az bilimsel olanıdır. Bu yöntemlerle elde edilen bilgilerin, büyük ölçüde, objektiflik ve güvenilir olmaktan yoksun oluşu cevaplayıcıların istenen bilgileri vermeyişi veya vermek istemeyişi, haberleşme hataları söz konusu yöntemin değerini azaltmaktadır. Ancak pazarlama araştırması için gerekli olan bilgileri soru sormak suretiyle sağlama olanağı, anket yöntemini çok yönlü ve sık kullanılır yöntem haline getirmektedir (Makridakis ve diğ., 1998).

3.1.4 Satış gücü birleşimi

Satış elemanlarının kendi bölgelerine ait satışların ne olabileceğini tahminlemelerine dayalı bir yaklaşımdır. Bu tahminler, satıcıların geçmiş öngörülerinde görülen eğilimleri de göz önüne alınarak düzeltilir. Daha sonra birleştirilerek toplam tahmin elde edilir. Ancak henüz oturmamış bir satış örgütünde eğitilmemiş ve tecrübesi az elemanların görüşlerinin toplanması halinde bu yöntem sakıncalıdır (Heizer ve Render, 2004).

3.1.5 Yaşam eğrisi benzeşimi

Piyasalarda genel olarak ürünlerin belli bir yaşamı olduğu ve bu yaşamın belli aşamalardan geçtiği kabul edilmektedir. Bunlar tanınma, büyüme, olgunluk, doygunluk ve gerileme aşamalarıdır. Gerileme aşamasından sonra ürünün piyasadaki yaşamı sona erer. Bu yöntemde genellikle piyasaya yeni çıkacak bir ürünün talep tahminleri piyasadaki benzer ürünlerin yaşam eğrisinden esinlenerek yapılır (Armstrong, 2001).

Çizelge 3.1: Nitel yöntemlerin karşılaştırılması (Armstrong, 2001).

Yöntem	Kullanım Alanları	Güvenilirlik			Maliyet
		Kısa Dönem	Orta Dönem	Uzun Dönem	
Uzman Görüşü	*toplam satışlar	zayıf-orta	zayıf-orta	zayıf-orta	düşük
	*spesifik ürünler				
Anket Yöntemi	*toplam satışlar	çok iyi	iyi	orta	yüksek
	*spesifik ürünler				
	*ürün grupları				
Delphi Tekniği	*uzun dönemli satış	orta-iyi	orta-iyi	orta-iyi	orta
	*kapasite planlama				
	*teknolojik tahmin				


Çizelge 3.1(devam) : Nitel yöntemlerin karşılaştırılması (Armstrong, 2001).

Yaşam Eğrilerinin Benzeşimi	*uzun dönemli satış	zayıf-orta	orta-iyi	orta-iyi	orta
	*yeni ürün				
	*tesis planlam				
Satış Gücü Birleşimi	*toplam satışlar	zayıf-orta	orta-iyi	zayıf-orta	orta

3.2 Nicel Tahmin Yöntemleri


Nicel tahmin yöntemleri, geçmiş zaman dönemlerinde gerçekleşen talep değerlerini temel alan ya da talebin oluşumuna etki eden faktörler ile talep miktarı arasındaki ilişkilerin gelecekte de aynı şekilde devam edeceği varsayımına dayanan ve istatistiksel hesaplama gerektiren yöntemlerdir. Bu yöntemler kendi içerisinde zaman serileri analizi ve nedensel modeller olmak üzere iki gruba ayrılmaktadır.

Nedensel tahminler sistem girdileri ve çıktıları arasında bir neden sonuç ilişkisi olduğu varsayımına dayanır. Nedensel tahminler doğru bir neden sonuç ilişkisi kurarak girdilerdeki değişimlerin çıktılar üzerindeki etkisinin tahmin edilebileceği varsayımına dayanır. Sistem, çıktıların gözlemleri ve sistem girdileri arasındaki neden sonuç ilişkisini kurar (Makridakis ve diğ., 1998).



Şekil 3.1: İlişkisel tahmin yöntemi akışı (Makridakis ve diğ., 1998).

Nedensel yöntemlerin aksine zaman serisi yöntemleri, sistemi bir kara kutu olarak görür ve sistemin davranışına etki eden faktörler ile ilgilenmez. Yöntemin sistemi bu şekilde görmesinin iki ana nedeni vardır. Öncelikle yöntem sistemin mantığını anlamak üzerine kurgulanırsa aradaki ilişkilerin kurulması ve ölçülmesinin zorlaşacağı göz önünde bulundurulmaktadır. İkinci önemli neden, sistemin sadece çıktıların ne olacağına odaklanması ve neden olduğu ile ilgilenmemesidir (Makridakis ve diğ., 1998).



Şekil 3.2: Zaman serileri tahmin yöntemi akışı (Makridakis ve diğ., 1998).

3.2.1 Zaman serileri analizi

Zaman serisi, zaman sırasına konmuş gözlem değerleri kümesi olarak tanımlanabilir. Zaman serisinde ilgilenilen özellik bir değişkendir. Bu değişken zaman içerisinde çeşitli nedenlere bağlı olarak farklı değerler alır. Dolayısıyla zaman serisi, zaman sırasına konmuş değişken değer kümesi olarak ifade edilebilir. Zaman aralıkları her seride farklıdır. Saatlik, günlük, haftalık, aylık, üç aylık, yıllık veya daha farklı zaman aralıklarına göre değer almış zaman serileri olabilir. Bir zaman serisinde bağımsız değişken t , zaman devresini, Y_t ise değişkenin t dönemindeki gözlem değerini gösterir (Kutay, 1989).

Zaman serileri analizinde gelecekteki tahmin miktarının geçmişte gerçekleşmiş talep miktarlarının bir fonksiyonu olduğu varsayıldığı için analiz sürecinin başında gerçekleşen talep miktarlarını gösteren veriler incelenir ve geçmişte talebin nasıl bir davranış gösterdiği, seyrinin nasıl olduğu belirlenmeye çalışılır (Eski, 2006). Zaman serileri analizinde geçmişe ilişkin talep miktarlarının dört bileşenin etkisi altında olabileceği varsayılmaktadır. Bu bileşenler;

- Trend (T)
- Mevsimsel dalgalanmalar (S)
- Devresel dalgalanmalar (C)
- Düzensiz hareketler (I)


Trend, zaman serisindeki belirli bir dönemdeki sürekli artış ya da azalış eğilimidir. Trend zaman serisinde görülen düzenli bir değişimdir. Bir zaman serisinde trend belirlenebilir ise işletmeler trendlerin kırılma noktalarını kestirebilir ve böylelikle doğru hamleleri yapabilirler (Chatfield, 2000).

Mevsimsel dalgalanmalar, zaman serilerinde en fazla bir yıllık dönem içerisinde belli dönemlerde hava durumu, insan alışkanlıkları ve davranışları, gelenekler ve benzeri sosyo-ekonomik etkiler nedeniyle meydana gelen talep miktarındaki oynamalardır. Bu hareketler, belli bir süre içerisinde her defasında aynı veya benzer bir şekilde

tekrarlanırlar. Kış aylarında ısıtma cihazı satışlarının artması, hediyeleş eşya satışlarının özel günler öncesinde artması, gün içerisinde saate göre satılan sinema bileti sayısının değişmesi mevsimsel hareketlere örnek olarak gösterilebilir.

Devresel dalgalanmalar, bir yıldan daha uzun sürelerde serinin benzer özellikler göstermesi ya da kendini tekrar etmesidir. Mevsimsel dalgalanma ile benzeşirler ancak devresel dalgalanmaların kendini tekrar etme periyodu her zaman aynı olmayabilir. Devresel dalgalanmaları, seriden trendin, mevsimselliğin ve tesadüfi hareketlerin çıkarılması sonucu kalan hareketler olarak da tanımlamak mümkündür.

Düzensiz hareketler, zaman serilerinde herhangi bir sistematik ile açıklanamayan, tesadüflerden veya arızı durumlardan meydana gelen değişimlerdir. Arızı olaylara örnek olarak seçim, savaş, grev veya kriz gibi olaylar örnek olarak verilebilir. Düzensiz hareketleri, çoğunlukla tahmin etmek veya önlemek mümkün değildir. Bu nedenle, seride arızı veya tesadüfi olaylardan dolayı sıçrama veya alçalmalar varsa bunları analiz dışı bırakmak en uygun yoldur (Chatfield, 2000).



Şekil 3.3: Zaman serilerini etkileyen bileşenler.

Zaman serileri analizinde, talep verileri ile dört bileşen arasında toplamsal ve da çarpımsal bir ilişki olduğu varsayılmaktadır. Talep miktarı Y ile gösterilirse, bu iki tür ilişki matematiksel olarak aşağıdaki şekilde gösterilmektedir:

$$\text{Toplamsal İlişki} \rightarrow Y = T + S + C + I \quad (3.1)$$

$$\text{Çarpımsal İlişki} \rightarrow Y = T * S * C * I \quad (3.2)$$

3.2.1.1 Yalın yaklaşım

Bu yöntemin temel varsayımı, hiçbir şeyin değişmeyeceği ve geleceğin bugünün aynısı olduğudur. Bu yöntemde, bir zaman serisi değişkeninin son dönemde aldığı değer, bir sonraki dönemin tahmini olarak kullanılır. Tahmin, şu formülle ifade edilir:

$$F_{t+1} = y_t \quad (3.3)$$

Formülde F_{t+1} , t+1 dönemindeki tahmini y_t ise, t dönemindeki gerçekleşen talebi göstermektedir.

3.2.1.2 Aritmetik ortalama yöntemi

Bu varsayım geleceğin, geçmişte olanların ortalamasına doğru eğilim göstereceğine dayanmaktadır. Metot gelecek dönem tahmini için geçmiş dönem verilerinin toplamının ortalamasını alır. Metot tüm dönemleri kullanarak tahminde düzgünleştirme sağlar.

$$F_{t+1} = \frac{\sum_{t=1}^n y_t}{n} \quad (3.4)$$

Aritmetik ortalama yöntemi, trend ve mevsimsel dalgalanmaların etkisinin olmadığı, gerçekleşen talep miktarlarının fazla değişim göstermediği, değişim aralıklarının dar olduğu zaman serileri için uygundur (Eski, 2006).

3.2.1.3 Hareketli ortalamalar yöntemi

Bu metot da aritmetik ortalama metodu gibi kendisinden önceki dönemlerin ortalamasının bir sonraki dönemin ortalamasına eşit olacağı varsayımı üzerine kuruludur. Ancak bu metot yakın geçmişin tahminlerde daha ağırlıklı olacağını göz önüne alır ve belirlenen n adet dönemin ortalamasını alarak yalnızca bir dönem tahmini yapar.

$$F_{t+1} = \frac{y_t + y_{t-1} + \dots + y_{t-n+1}}{n} \quad (3.5)$$

Hareketli ortalamalar yöntemlerinde seçilecek n dönemin belirlenmesi çok önemlidir. Bu dönem sayısı arttıkça seride düzgünleştirme sağlanacaktır, dönem sayısının az seçilmesi durumunda ise tahmin son dönem taleplerinden gereğinden fazla etkilenebilir.

Zaman serilerini oluşturan talep değerleri belirgin bir trende sahip ise bu durumda basit hareketli ortalamalar yönteminin kullanılmasının bazı sakıncaları vardır. Örneğin gerçekleşen talep değerleri yükselen bir trend gösteriyor ise, bu durumda basit hareketli ortalamalar yöntemi ile bulunacak olan tahmin değerleri olması gerekenden küçük olacaktır. Eğer gerçekleşen talep değerleri alçalan bir trend gösteriyor ise, bu durumda basit hareketli ortalamalar yöntemi ile bulunacak olan tahmin değerleri olması gerekenden büyük olacaktır. Bu sebeplerden dolayı, basit hareketli ortalamalar yönteminin, zaman serisini oluşturan veriler üzerinde belirgin bir trend ve mevsimsel dalgalanmanın olmadığı durumlarda kullanılması daha doğrudur (Heizer ve Render, 2004).

3.2.1.4 Ağırlıklı hareketli ortalamalar yöntemi

Bu yöntemde de basit hareketli ortalamalar yönteminde kullanılan sistem geçerlidir. Ancak basit hareketli ortalama alınırken değerlerin etkisi eşitken bu yöntemde değerlere ağırlıklar verilerek etkileri farklılaştırılır. Eğer ürünün talebinde son dönemlerde gerçekleşen değişimlerin etkisinin büyük olduğu düşünülüyorsa son dönemlere daha büyük ağırlıklar verilerek etkisi güçlendirilir. Bunun yanı sıra zaman serisini oluşturan veriler arasından uç değerler yani genel ortalamanın çok üstünde ve altında değerler bulunuyorsa bu değerlerin ağırlıkları düşürülerek tahmin değeri üzerindeki etkisinin azaltılması sağlanabilir.

$$F_{t+1} = \frac{w_1 * y_t + w_2 * y_{t-1} + \dots + w_n * y_{t-n+1}}{w_1 + w_2 + \dots + w_n} \quad (3.6)$$

w_n , n. dönemde gerçekleşen talebe verilen ağırlık olmak üzere bu yöntemde belirlenecek ağırlık değerleri de önem taşımaktadır. Ağırlık değerleri doğrusal olarak belirlenebilir. Bu durumda verilen ağırlıklar, geçmiş taleplere doğru düzgün bir azalış gösterecektir. Son dönemlerin farklı ağırlıklarda olacağının düşünülmesi ya da belirli dönemlerin etkisinin daha fazla olacağının düşünülmesi durumunda bu ağırlıklar sezgisel olarak da verilebilir.

3.2.1.5 Üssel ağırlıklandırılmış hareketli ortalama yöntemi

Bu metot geçmiş zamandaki taleplere belirli ağırlıklar vermek yerine geçmiş dönemlere ait ortalama talep ile mevcut döneme ait talebi belirli oranlarda tekrar ağırlıklandırarak bir sonraki dönemin talebini hesaplar.

Bu metodun üç temel özelliği (Holt, 2004);

- Veri eskidikçe daha az ağırlık vermektedir.
- Hesaplaması kolay bir yöntemdir.
- Yüksek oranda veri gereksinimi yoktur.

Metodun kullanılabilmesi için geçmiş dönemlerin talep ortalaması ve mevcut dönemin talep değeri yeterlidir.

$$X = \frac{1}{\left(\frac{n}{2}\right)-1} \quad (3.7)$$

$$F_{t+1} = \left[(1 - X) * \frac{\sum_{n=1}^{t-1} y_n}{n} \right] + [(1 - X) * y_t] \quad (3.8)$$

X değeri en son dönem ile önceki dönemler arasındaki ağırlıklandırmayı belirleyen katsayıdır. Metot en son dönem ağırlığını önceki dönemlerden ayrı tutarak iki kez ağırlıklandırma yapmaktadır.

3.2.1.6 Basit üssel düzgünleştirme yöntemi

Basit üssel düzgünleştirme yöntemi, basit ve ağırlıklı hareketli ortalamalar yöntemlerinden farklı olarak herhangi bir döneme ilişkin tahmini talep miktarının bu dönemden önce gelen tüm dönemlerde gerçekleşmiş olan talep miktarlarına bağlı olarak belirlenmesini öngörmektedir (Eski, 2006).

Basit üssel düzgünleştirme yöntemi, herhangi bir döneme ait tahmini talep miktarını bulurken, bu dönemden önce gelen dönemlerin talep miktarlarına, gerçekleştikleri zamanla ters orantılı ağırlıklar vermektedir. Böylelikle en yakın geçmişte gerçekleşen talep miktarı, yapılan tahmini en çok etkileyen veri olurken, en uzak geçmişte gerçekleşen talep miktarı da yapılan tahmini en az etkileyen veri olacaktır.

Basit üssel düzgünleştirme yöntemi aşağıdaki şekilde ifade edilebilir;

$$F_{t+1} = F_t + \alpha(y_t - F_t) \quad (3.9)$$

Bu formülde farklı olan, α katsayısı 0 ile 1 arasında değer alan düzgünleştirme katsayısını ifade etmektedir. Burada α değeri dönemlere verilen ağırlığı etkilemektedir. α büyüdükçe son dönemlere daha fazla ağırlık verilmektedir.

$(y_t - F_t)$ ifadesi bir önceki döneme ait tahminin hata değeridir. Eğer bu hata pozitif ise gerçekleşen, tahminden daha büyüktür ve düzgünleştirme bir sonraki tahmini

arttırıcı yönde etki yapacaktır. Tersi durumda hata değeri negatif olur ise tahmin gerçekleşenden fazla olduğundan düzgünleştirme katsayısı tahmini azaltacak yönde çalışır (Mann, 1995).

Basit üssel düzgünleştirme yönteminde düzgünleştirme katsayısının belirlenmesi, yapılan tahminlerin doğruluğu açısından önem taşımaktadır. α katsayısının belirlenmesine yönelik literatürde önerilen iki yöntem aşağıdaki gibidir (Eski, 2006):

- a) n , zaman serisini oluşturan veri sayısını göstermek üzere, düzgünleştirme katsayısı;

$$\alpha = \frac{2}{n+1} \quad (3.10)$$

- b) α değerinin tahmini için en basit yöntem, farklı α değerleri ile deneyler yapıp en uygununu bulmaktır. Uygulamada önerilen, α değerinin 0,05 ile 0,30 arasında seçilmesidir. Kısa dönemli dalgalanmaların yaşandığı ortamlarda α değeri daha büyük olarak seçilebilir.

3.2.1.7 Holt lineer metodu

Basit üssel düzgünleştirme yöntemi, zaman serisinin bir trende sahip olması durumunda uygun olmayan bir yöntemdir. Böyle durumlarda, gelecek dönemlere yönelik tahmin yapmak için Holt Lineer Metodu (Çift Üssel Düzgünleştirme Yöntemi) kullanılmaktadır. Metot, Holt tarafından 1957 yılında basit üssel düzgünleştirme yöntemine trend bileşeninin eklenmesiyle geliştirilmiştir.

Holt Lineer metodunun cebirsel ifadesi şöyledir;

$$F_{t+m} = L_t + T_t m \quad (3.11)$$

$$L_t = \alpha y_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (3.12)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (3.13)$$

Bu yöntemde α düzgünleştirme faktörü ile β trend için düzgünleştirme faktörü kullanılmaktadır. β faktörü de 0 ile 1 arasında değer alır ve büyüklüğü karar verici tarafından belirlenir.

L_t zaman serisinin t anındaki seviyesini ifade eder ve bir önceki dönemin seviye değeri ile trend değerini düzgünleştirir. Böylelikle L_t değeri geçmiş dönemin trend bileşenini de içerir (Aksoy, 2008).

T_t ise zaman serisinin t anındaki eğimini göstermektedir. Son iki dönemin seviye değerleri arasındaki farkı düzgünleştirerek, oluşan fark üzerinden trend bileşenini hesaplar.

F_{t+m} , trende sahip olduğu düşünülen zaman serisinin $t+m$ dönemindeki tahmin değerini ifade eder, t anında hesaplanan seviye ve trend bileşenleri kullanılarak hesaplanır. Formüldeki m değeri, t anından itibaren periyot sayısını ifade eder. Bu durumda, F_{t+m} tahmin değeri t anındaki seviye bileşenine dönem sayısı kadar trend bileşeni eklenmesi ile bulunur.

3.2.1.8 Holt winter trend ve mevsimsellik metodu

Zaman serisinin trend bileşeni ile birlikte mevsimsellik de içerdiği durumlarda kullanılır. Bu durumda talep, doğrusal bir yapı göstermeyecektir. Tahmin eşitliği de seviye ve trend bileşenleri ile birlikte mevsimsellik bileşeni de içerecektir (Aksoy, 2008).

$$F_{t+m} = L_t + T_t m + S_{t-s+m} \quad (3.14)$$

$$L_t = \alpha(y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (3.15)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (3.16)$$

$$S_t = \lambda(y_t - L_t) + (1 - \lambda)S_{t-s} \quad (3.17)$$

3.2.2 Nedensel yöntemler

Nedensel yöntemler, tahmin edilmek istenen bir etkeni, kendisini etkileyen faktörler ile ilişkilendirerek, tahminlerin bu faktörlerdeki değişmelere bağlı olarak yapılmasını amaçlayan yöntemlerdir (Eski, 2006). Nedensel modellerde sistemin çıktıları sistemin girdilerinin matematiksel formülasyonu olarak ifade edilir, talep ile talebi etkileyen faktörler arasında neden-sonuç ilişkisi kurulur.

Nedensel yöntemler arasında en çok tercih edilen metotlar, regresyon analizi ve korelasyon analizidir.

3.2.2.1 Regresyon analizi

Regresyon analizi bir değişken ile ona bağlı diğer değişkenler arasındaki ilişkiyi incelemektedir. Sistem çıktısı, tahmin değeri Y_x ile sistem girdileri $X_1, X_2, \dots, X_n$ arasındaki ilişkiyi inceler. Burada Y_x bağımlı değişken $X_1, X_2, \dots, X_n$ ise bağımsız


değişkenlerdir. Bağımlı değişken ile bağımsız değişkenler arasındaki ilişki doğrusal ya da eğrisel olabilir (Wei, 1990). Temel olarak basit doğrusal regresyon, çoklu doğrusal regresyon ve eğrisel regresyon denklemleri vardır.

Basit doğrusal regresyon modeli, bağımlı değişkenin yalnızca bir bağımsız değişkene bağlı olduğu regresyon modelidir.

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad i = 0, 1, \dots, n \quad (3.18)$$

(3.18)'de Y_i tahmin değeri, X_i bağımsız değişkeninin doğrusal bir fonksiyonu olarak gösterilmektedir. β_0 , doğrunun Y eksenini kestiği noktayı β_1 , doğrunun eğimini ε_i ise i . gözleme ait hata bileşenini vermektedir. Formüldeki β_0 ve β_1 değerleri, en küçük kareler yöntemi ile bulunmaktadır.

En küçük kareler yöntemine göre, bir zaman serisine en iyi uyan başka bir deyişle bir değerler serisini en iyi ifade eden doğru veya eğri, geçmiş yıllara ait gerçek değerlerle formülün uygulanması ile bulunacak teorik değerler arasındaki farkların karelerinin toplamını (sapmaların kareleri toplamını) minimum yapan doğru veya eğridir (Makridakis ve diğ., 1998).



Şekil 3.4: En küçük kareler yöntemi.

ε_i hata bileşenlerinin karesini minimum yapan doğru denkleminin bulunması ile sonraki dönemlerin talep tahmini yapılabilir. β_0 ve β_1 değerleri aşağıdaki hesaplamalar ile bulunur.

$$\beta_1 = \frac{n \sum XY - (\sum X \sum Y)}{n \sum X^2 - (\sum X)^2} \quad (3.19)$$

$$\beta_0 = \frac{\sum Y}{n} - \beta_1 \frac{\sum X}{n} \quad (3.20)$$

Çoklu doğrusal regresyon modelinde bağımlı değişken Y_i birden çok bağımsız değişkenin doğrusal formülasyonu olarak ifade edilir. Modelin genel gösterimi şu şekildedir:

$$Y_i = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_n X_n + \varepsilon_i \quad (3.21)$$

Regresyon denkleminde bağımlı değişken bağımsız değişkenlerin eğrisel bir fonksiyonu olarak da ifade edilebilir. Bu durumda denklemin genel gösterimi aşağıdaki gibidir:

$$Y_i = \beta_0 + \beta_1 X^1 + \beta_2 X^2 + \dots + \beta_n X^n + \varepsilon_i \quad (3.22)$$

3.2.2.2 Korelasyon analizi

Korelasyon analizi ile değişkenler arasındaki ilişkinin derecesi ortaya konur. Korelasyon analizi bir talep tahmin yöntemi olarak kullanılabileceği gibi birçok yöntemin oluşturulması ve sonuçların rassallıklarının ortaya konmasında da kullanılır.

Korelasyon katsayısı R ile simgelenir ve iki değişken arasındaki doğrusal ilişkinin derecesini belirler. Korelasyon katsayısı -1 ve +1 arasında değerler alır ve bu değere bakılarak ilişki yorumlanır. Eğer değişkenler arasında doğrusal ilişki yoksa $R=0$ çıkar (Anderson ve diğ., 2005).

$$R = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}} \quad (3.23)$$

Korelasyon katsayısı pozitif ise ilişki doğru orantılı, negatif ise ters orantılıdır. Değerin 0 veya 1'e yaklaşması aralarındaki ilişkinin kuvvetli veya zayıf olduğunu göstermektedir. Korelasyon değeri +1 veya -1 çıkar ise gerçek değer ile regresyon denklemi ile bulunan değer birebir birbirini tutar.

Korelasyon katsayısının aldığı değerler aşağıdaki şekilde yorumlanır (Tekin, 1996):

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

3.3 Box Jenkins Yöntemleri

Box-Jenkins metodu tek değişkenli bir model olarak, geleceği tahmin etme metotlarından biridir. Kısa dönem tahmininde oldukça başarılı olan bu metodun uygulandığı serinin, eşit zaman aralıklarıyla elde edilen gözlem değerlerinden oluşan kesikli ve durağan bir seri olması bu metodun önemli bir varsayımıdır (Bircan ve Karagöz, 2003).

Zaman serisinin durağan olduğunun söylenebilmesi için, ortalamasında ve varyansında sistematik bir değişim olmaması gerekir. Bir seri sabit bir büyüme ya da genel bir trend gösteriyorsa ya da bir seviyeden bir başka seviyeye geri dönüyorsa, bu yapıdaki seriler durağan bir seriye dönüştürülmeden modellenemezler (Box ve Jenkins, 1976).

Box Jenkins modellerinin metodolojisi şu şekilde gösterilmektedir:



Şekil 3.5: Box Jenkins metodolojisi.

Box – Jenkins modelleri, otoregresif modeller (AR), hareketli ortalama yöntemleri (MA), Oturegresif hareketli ortalama yöntemleri (ARMA) ve durağan olmayan serilerde uygulanan (ARIMA) modellerinden oluşmaktadır.

3.3.1 Otoregresif modeller – AR(p) modelleri

Bu modellerin genel gösterimi AR(p) sekindedir. Burada p değeri geçmiş dönem sayısını verir. Model, geçmiş p dönemdeki zaman serisi değerlerinin ağırlıklı toplamının ve rassal hata değerinin bir fonksiyonudur. AR(p) modelinin genel gösterimi aşağıdaki gibidir:

$$Y_t = \mu + \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \varepsilon \quad (3.24)$$

Formülde μ değeri serinin ortalamasını verirken, $\Phi_1, \dots, \Phi_p$ otoregresif parametreleri göstermektedir. ε değişkeni ise serinin hata değişkenini temsil etmektedir.

3.3.2 Hareketli ortalamalar – MA(q) modelleri

MA(q) modelinde Y_t değeri, serinin geriye doğru q dönem geçmiş hata terimlerinin ve ortalamasının doğrusal fonksiyonudur (Kutlar, 2000). MA(q) modelinin genel gösterimi aşağıdaki gibidir:

$$Y_t = \varepsilon_t - \Theta_1 \varepsilon_{t-1} - \Theta_2 \varepsilon_{t-2} - \dots - \Theta_q \varepsilon_{t-q} \quad (3.25)$$

Formül üzerinde $\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-p}$ hata terimlerini, $\Theta_1, \Theta_2, \dots, \Theta_q$ değerleri de hata terimlerinin katsayılarını göstermektedir.

3.3.3 Otoregresif hareketli ortalama yöntemi – ARMA(p,q)

ARMA modelleri en genel durağan stokastik süreç olup, geçmiş gözlemlerin ve geçmiş hata terimlerinin doğrusal bir fonksiyonudur (Önder ve Hasgöl, 2009). ARMA (p,q) modelleri genel olarak aşağıdaki gibi gösterilebilir:

$$Y_t = \mu + \Phi_1 Y_{t-1} + \dots + \Phi_p Y_{t-p} + \varepsilon_t - \Theta_1 \varepsilon_{t-1} - \dots - \Theta_q \varepsilon_{t-q} \quad (3.26)$$

Model, zaman serisinin t anındaki tahmininin p adet önceki dönem gözlem değeri ile q adet önceki dönem hata değerinin bileşiminden meydana gelir. Tahmin p sayıda içsel bağımlılık parametresi ($\Phi_1, \Phi_2, \dots, \Phi_p$) ve q sayıda hata parametresi ($\Theta_1, \Theta_2, \dots, \Theta_q$) içerir.

3.3.4 Durağan olmayan otoregresif hareketli ortalama yöntemi - ARIMA (p,d,q)

Eğer bir zaman serisi durağan değil ise yani zaman içerisinde artan ya da azalan bir eğilim gösteriyor ise bu durumda ARMA modellerinin kullanılabilmesi öncelikle serinin durağanlaştırılması gerekir. Durağanlaştırma işlemi serinin farkının alınması

ile elde edilir. Eğer zaman serisinin eğilimi doğrusal ise bir kez fark alınması ile seri durağanlaşacaktır. Eğer serinin eğilimi eğrisel ise bu durumda ikinci farkı almak gereklidir. Bu tür modeller ARIMA(p,d,q) şeklinde ifade edilir. Modeldeki d parametresi serinin kaç kez farkının alındığını belirtir (Aksoy, 2008). Fark işlemi aşağıdaki şekilde ifade edilir:

$$\Delta Y_t = Z_t = Y_t - Y_{t-1} \quad (3.27)$$

Eşitlikte Δ fark alma operatörünü ifade eder. Z_t ise farkı alınmış serinin t anındaki tahminini simgeler. Eğer yukarıdaki işlem sonucunda elde edilen Z_t değerleri durağan bir seri oluşturuyor ise bu durumda d=1 olarak gösterilir. Eğer elde edilen seri durağanlaşmamış ise bu durumda bir kez daha fark alınır. Bu işlem aşağıdaki şekilde gösterilir:

$$\Delta^2 Y_t = W_t = Z_t - Z_{t-1} \quad (3.28)$$

$$\Delta^2 Y_t = W_t = (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) \quad (3.29)$$

Box Jenkins modellerinde uygun modelin belirlenmesi yani (p,q,d) parametrelerine karar verilmesi önemli bir süreçtir. Bu değerler arasından d değerini elde etmek kolaydır. Serinin artan ya da azalan bir yapısı var ise bu yapının doğrusal olması durumunda d=1, eğrisel olması durumunda d=2'dir. Ancak p ve q değerlerinin belirlenmesi otokorelasyon ve kısmi otokorelasyon fonksiyonları ile belirlenebilir.

Otokorelasyon fonksiyonu zaman serisindeki iki nokta arasındaki tüm noktaların ilişkisini inceler. Otokorelasyon fonksiyonu şu şekilde gösterilebilir;

$$m = \frac{\sum_{t=1}^T Y_t}{T} \quad (3.30)$$

$$\rho = \frac{\sum_{t=1}^{T-k} (Y_t - m)(Y_{t-k} - m)}{\sum_{t=1}^T (Y_t - m)^2} \quad (3.31)$$

m değeri serinin ortalamasını vermektedir. Korelasyon değeri (ρ) de k dönemin ilişkisini tanımlamaktadır.

Kısmi otokorelasyon fonksiyonu ise zaman serisindeki iki nokta arasındaki diğer noktaları arındırır ve sadece seçilen iki nokta arasındaki ilişkiyi belirler. Kısmi otokorelasyon, otokorelasyondan türetilebilir.

3.4 Yapay Zekâ Çözümleri


İlk defa 1950’li yıllarda ortaya atılan yapay zeka terimi zaman içinde oldukça yoğun ilgi görmüş ve 40-50 yıllık bir zaman diliminde hayatın vazgeçilmez parçası olan sistemlerin doğmasına sebep olmuştur (Öztemel, 2003). Talep tahmini kavramının değişken ve belirsiz yapısı da yapay zekâ yöntemlerinin talep tahmin problemlerinin çözümünde gelişmesini sağlamıştır. Talep tahmininde en çok kullanılan yapay zekâ çözümleri, bulanık mantık ve yapay sinir ağlarıdır.

3.4.1 Bulanık mantık

Bulanık mantık, klasik küme mantığının dışında yeni bir yaklaşım getirmektedir. Klasik küme mantığında nesnelerin üyelik dereceleri $\{0,1\}$ olarak ifade edilmektedir. Bu durumda bir nesne bir kümeye üyedir ya da üye değildir. Örneğin 4 rakamının, 5’ten küçük sayılar kümesine üyelik derecesi 1’dir, 5’ten büyük sayılar kümesine üyeliği ise 0’dır. Bu mantık matematik, fizik gibi temel bilimlerde geçerli olan ve kullanılan bir mantıktır (Aksoy, 2008). Ancak doğal olaylar ve günlük hayatta karşılaşılan durumlar incelendiğinde farklı üyelik derecelerinden söz edilebilir. Örneğin farklı sıcaklık değerlerinin “Sıcak Hava” kümesine üyeliğini $\{0,1\}$ şeklinde ifade etmek mümkün değildir. 18° sıcaklık değerinin bu gruba üyelik derecesi $[0,1]$ aralığında değer alır. Aynı şekilde 5°, 15°, 30° değerlerinin de küme üyelik dereceleri $[0,1]$ aralığında farklı değerler almaktadır.


Bulanık mantık kavramı ilk kez 1965 yılında Zadeh tarafından yapılan çalışmalar ile ortaya atılmıştır. Zadeh bu çalışmasında girdi verilerinin farklı kümelerdeki farklı üyelik derecelerinden bahsetmiş ve girdinin çıktıya dönüşümünün bu kümeler aracılığı ile yapılabileceğinden söz etmiştir. Bu çalışmalar önceleri pek değer kazanmasa da zaman içerisinde önem kazanmış ve bulanık mantık araştırmaları genişletilmiştir. Yöntem özellikle deneyimlere dayalı verilerde ya da sayısal olarak ifade edilemeyen verilerin yorumlanmasında kullanılmaktadır.

Bulanık mantık, Şekil 3.6’ da gösterilen sürece göre çalışmaktadır.



Şekil 3.6: Bulanık mantığın elemanları ve çalışması (Öztemel, 2003).

Bulanıklaştırma, çözülecek problem ile ilgili bulanık önerme değişkenlerinin ve karar verme kurallarının belirlenmesi ve üyelik fonksiyonunun oluşturulması işlemidir. Örneğin, hava sıcaklığının normal olması durumunda değişkenin adı “normal” olabilir. Üyelik fonksiyonu ise herhangi bir sıcaklık değerinin “normal” olma üyeliğini gösterir. Üyelik değeri 0-1 aralığında bir değerdir. 1 değeri, tam üyelik durumunu 0 ise üye olmama durumunu gösterir. 18° sıcaklığın normal olma değeri 1 ise, bu değeri olasılık değeri yerine mümküniyet değeri olarak görmek gerekir (Öztemel, 2003). Normal değişkeninin üyelik fonksiyonu Şekil 3.7’de gösterilmektedir.



Şekil 3.7: Üyelik fonksiyonu örneği.

Bulanık önerme işleme, belirlenen bulanık önerme değişkenlerinin kurallarını kullanarak problemin çözüm alanını belirleme işlemidir. Genellikle üyelik fonksiyonlarının üst üste konulması sonucu kurallara göre ortak alanın belirlenmesidir. Eğer kurallar AND (VE) bağlacı ile bağlanmış ise üyelik fonksiyonlarının en küçük değeri, OR (VEYA) bağlacı ile bağlanmış ise o zaman üyelik fonksiyonlarının büyük değerlerini alarak alan oluşturulur (Öztemel, 2003).

Netleştirme ise bulunan çözüm alanından tek bir değer elde edilmesi işlemidir.

3.4.2 Yapay sinir ağları

Yapay sinir ağları (YSA), talep tahmininde çok yoğun olarak kullanılan bir yöntemdir. Bu çalışmada, yapay sinir ağları kullanılarak temizlik kâğıtları sektöründe talep tahmin problemi çözülmüştür. YSA, 4. bölümde ayrıntılı olarak işlenecektir.

3.5 Tahmin Yöntemlerinin Doğruluğunun Ölçülmesi

Hangi yöntem kullanılırsa kullanılsın tahminler ile gerçekleşen değerler birebir örtüşmez. Yapılan tahminde mutlaka belli bir hata oranı oluşur. Bu nedenle kullanılan yöntemin denetimi gereklidir. Denetim süreci en az tahmin süreci kadar önemlidir (Kobu, 1996).

Tahmin hatası belirli bir t periyotta talep ile tahmin arasında oluşan farkı ifade etmektedir.

$$e_t = Y_t - F_t \quad (3.32)$$

Y_t , t anında gerçekleşen talebi F_t ise t anındaki tahmini göstermektedir. Tahmin hatası talepten tahminin çıkartılması ile bulunur. Genel olarak amaç tahmin hatasını en aza indirecek yöntemin ve parametrelerin seçilmesidir. Tahmin hatasından yola çıkarak tahmin yöntemlerinin doğruluğunun belirlenmesinde birçok yöntem geliştirilmiştir.

3.5.1 Ortalama hata (ME)

Ortalama hata oluşan hata değerlerinin aritmetik ortalamasını alır. Hata değerlerinin negatif ya da pozitif değerler almasına izin verir. Ortalama hata metodu, hata değerleri kullanan en basit doğruluk metodudur. ME (Mean Error) ifadesi ile gösterilir.

$$ME = \frac{1}{n} \sum_{i=1}^n e_i \quad (3.33)$$

3.5.2 Ortalama mutlak hata (MAE)

Ortalama mutlak hata yöntemi ortalama hata yöntemine benzer şekilde hesaplanır ancak hata değerlerinin mutlak değerleri alınarak işaretlerden arındırılır. Böylelikle hata değerleri talep değerlerine uzaklıkları ile hesaplanmış olur. MAE (Mean Absolute Error) ile gösterilir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (3.34)$$

3.5.3. Ortalama hata kare kriteri (MSE)

Hata kareleri ortalaması talep tahminlerinin doğruluk hesaplamasında sıklıkla kullanılır.

Bu yöntem de tıpkı ortalama mutlak hata gibi hataları işaretlerden arındırır ve sadece büyüklüklerine bakar. MSE(Mean Square Error) ile ifade edilir.

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (3.35)$$

3.5.4 Ortalama mutlak hata yüzdesi (MAPE)

Ortalama mutlak hata yüzdesi yöntemi oluşan hataları yüzdesel olarak ifade eder. Böylelikle hataların birbirleri ile kıyaslanmasını sağlar. MAPE (Mean Absolute Percentage Error) ile ifade edilir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|e_i|}{y_i} \times 100 \quad (3.36)$$

3.5.5 Theil U istatistigi (U)

Theil tarafından 1978 yılında geliştirilen bir metottur. Bu metot hesaplanan hata değerlerini, yakınlılaştıkça arttırır. Böylelikle istatistiksel olarak yakın dönemde gerçekleşen hatalar ağırlıklandırılmış olur. Farklı tahmin ufuklarındaki yaklaşımların karşılaştırılmasında sıklıkla kullanılır. U ile gösterilir.

$$U = \sqrt{\frac{\frac{1}{n} \sum_{i=1}^n e_i^2}{\frac{1}{n} \sum_{i=1}^n y_i^2}} \quad (3.37)$$

3.5.6 İzleme sinyali

İzleme sinyali hata değerlerinin genel yapısını inceler. İyi bir tahmin negatif ve pozitif hatalar içerir. Sonuç olarak bu hataların toplamı bir başka deyişle talepten sapmalarının toplamı 0 elde edilmeye çalışılır.

İzleme sinyalinde alt ve üst kontrol limitleri mevcuttur. İzleme sinyalinin istenen değeri 0, alt kontrol limiti -3 ve üst kontrol limiti +3'tür. İzleme sinyali aşağıdaki şekilde gösterilir.

$$\text{İzleme Sinyali} = \frac{\sum_{i=1}^n e_i}{\frac{1}{n} \sum_{i=1}^n |e_i|} \quad (3.38)$$

4. YAPAY SİNİR AĞLARI METODOLOJİSİ

4.1 Yapay Zekâ Kavramı

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

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

- bilgisayarların bilgi edinme, algılama, görme, düşünme ve karar verme gibi insan zekasına özgü kapasitelerle donatılması bilimi,
- insanın düşünme yapısını anlama, bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışma,
- programlanmış bir bilgisayarın düşünme girişimi olarak da tarif edilmektedir (Sağiroğlu ve diğ., 2003).

İnsan beyni ve işleyişinin insanoğlunun ilgisini çekmesi çok eskilere dayansa da bu konuda pratiğe yönelik bilimsel çalışmalar 19. yüzyılın sonlarında yapılmaya başlanmıştır. 1956 yılında Dartmouth College’de yapılan ve pek çok bilim adamının katıldığı iki aylık bir konferansta YZ’nin temellerini oluşturan çalışmalar bilim adamlarınca tartışılmış ve yapay zeka ismi ilk kez kullanılmıştır.

YZ’nin yaygın bir şekilde araştırma ve uygulama alanı bulan belli başlı alt dalları şöyle özetlenebilir (Elmas, 2003);

Uzman Sistemler, temelde insan düşüncelerini geliştirmek amacıyla bilgisayar tarafından işlenen yazılımlardır. Uzman sistemler geliştirilirken, belirli bir konuda uzmanlaşmış olan insanların bilgi ve deneyimlerinin bilgisayara aktarılması amaçlanır.

Bulanık Mantık, bulanık küme teorisine dayanan matematiksel bir disiplindir. Bulanık mantık; bilgisayarın, sadece bir durumun ya da karşıtının olabileceğini kabul eden mantığının yerine, insan mantığındaki gibi ara değerleri de hesaba katarak karar vermesini sağlar. Örneğin bir bilgisayar için sadece uzun-kısa ya da sıcak-soğuk olabilen bir durum, bulanık mantık kullanılarak uzun-ortadan uzun-orta-ortadan kısa-kısa ya da sıcak-ılık-az soğuk-soğuk-çok soğuk gibi ara değerlere sahip olabilir.

Genetik algoritma, Darwin'in evrim kuramı "*doğada en iyinin yaşaması*" kuralından esinlenerek oluşturulan, bir veri kümesinden özel bir veriyi bulmak için kullanılan bir arama yöntemidir. Genetik algoritmalar, geleneksel yöntemlerle çözümü zor veya imkansız olan problemleri sanal olarak evrimden geçirerek en iyi çözümü elde etmeyi amaçlamaktadır.

Yapay sinir ağları, insan beyninde bulunan sinir ağlarının işleyişini modelleyen tekniklerdir. Yapay sinir ağlarına, ilgili olaya ait bilgiler örnekler üzerinde eğitilerek verilmektedir. Böylelikle, örnekler sayesinde açığa çıkarılmış özellikler üzerinde çeşitli genelleştirilmeler yapılarak, daha sonra ortaya çıkacak ya da o ana kadar hiç rastlanmamış olaylara da çözümler üretilmektedir..

4.2 Yapay Sinir Ağlarına Giriş

Çalışmanın bu bölümünde, talep tahmininde kullanılacak olan, Yapay Sinir Ağları (YSA) metodolojisi genel olarak tanıtılacak ve bu çalışmada talep tahmini için kullanılan Geri Yayılma Ağları'nın (Backpropagation Networks) teorik altyapısı incelenmeden önce, yapay sinir ağları hakkında genel bilgilere değinilecektir.

4.2.1 Yapay sinir ağlarının tanımı

Pek çok tanımı bulunan yapay sinir ağları basit olarak, beyindeki sinirlerin çalışmasından esinlenilerek sistemlere öğrenme, hatırlama, bilgiler arasında ilişkiler oluşturma gibi yetenekleri kazandırmayı amaçlayan bilgi işleme algoritmalarıdır. Literatürde karşılaşılan tanımlamalara aşağıda yer verilmektedir.

Yapay Sinir Ağları (YSA), en kısa ve basit şekilde, bir örnekler kümesi yardımıyla parametrelerin uyarlanabilmesini sağlayacak bir matematiksel formül için yazılan bilgisayar programı olarak tanımlanabilir. Bu tanım, YSA'nın en basit şekilde ve teknik detaya girilmeksizin ifade etmektedir (Yurtoğlu, 2005).

YSA, insan 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 (Öztemel, 2003).

Yapay sinir ağları, paralel bağlı çok sayıdaki basit elemanın, gerçek dünyanın nesneleriyle biyolojik sinir sisteminin benzeri yolla etkileşim kuran hiyerarşik bir organizasyondur (Kohonen, 1987).

Haykin (1999) tarafından verilen daha kapsamlı ve genel kabul gören bir tanıma göre ise bir sinir ağı, basit işlem birimlerinden oluşan, deneyimsel bilgileri biriktirmeye yönelik doğal bir eğilimi olan ve bunların kullanılmasını sağlayan yoğun bir şekilde paralel dağıtılmış bir işlemcidir. Bu işlemci iki şekilde beyin ile benzerlik göstermektedir:

1. Bilgi, ağ tarafından bir öğrenme süreciyle çevreden elde edilir.
2. Elde edilen bilgileri biriktirmek için sinaptik ağırlıklar olarak da bilinen nöronlar arası bağlantı ağırlıkları kullanılır.

4.2.2 Yapay sinir ağlarının tarihsel gelişimi

Yapay sinir ağlarının tarihçesi nörobiyoloji konusuna insanların ilgi duyması ve elde ettikleri bilgileri bilgisayar bilimine uygulamaları ile başlamaktadır. YSA ile ilgili çalışmaları 1970 öncesi ve sonrası olarak ikiye ayırmak gerekmektedir. Çünkü 1970 yılında bu bilimin tarihinde önemli bir dönüm noktası başlamış ve o zamana kadar olmaz diye düşünülen bir çok sorun çözülerek yeni bir süreç başlamıştır (Öztemel, 2003).

4.2.2.1 1970 öncesi YSA ile ilgili çalışmalar

İlk yapay sinir ağı modeli 1943 yılında, bir nörolog olan Warren McCulloch ve bir matematikçi olan Walter Pitts tarafından geliştirilmiştir (Elmas, 2003). McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağını modellemişlerdir.

Donald Hebb (1949) tarafından yayımlanan “The Organization of Behavior” adlı kitabı ile öğrenebilen ve uyum sağlayabilen sinir ağları modeli için temel olacak Hebb Kuralı’nı ortaya koymuştur. Hebb kuralı, sinir ağlarının bağlantı sayısının değiştirilebilmesi durumunda ağın öğrenebileceğini ileri sürer (Mehrotra ve diğ., 1997).

Farley ve Clark (1954) tarafından rassal ağlar (random networks) ile uyarlanabilir tepki üretme kavramı ortaya atılmıştır. Bu kavram 1958 yılında Rosenblatt ve 1961 yılında Caianiello tarafından geliştirilmiştir.

Özellikle Rosenblatt (1958) tarafından geliştirilen “Perceptron” yapay sinir ağlarındaki çalışmaları hızlandırmıştır. Perceptron (Algılayıcı), örüntü (şekil) tanıma amacıyla geliştirilen tek katmanlı, eğitilebilen ve tek çıkışa sahip olan bir yapay sinir ağıdır. Perceptron’un daha sonra geliştirilecek ve yapay sinir ağları çalışmalarında devrim kabul edilen çok katmanlı yapay sinir ağlarının temelini oluşturması açısından tarihsel önemi vardır.

Widrow ve Hoff (1959), ADALINE (Adaptive Linear Neuron) modelini ortaya atmışlardır. Yapay sinir ağlarının mühendislik uygulamalarında kullanılmaya başlanması için atılan ilk adımlardan biri sayılmaktadır. Bu model, Rosenblatt’ın algılayıcı modeli ile benzer özelliklere sahip olup sadece öğrenme algoritması daha gelişmiş bir modeldir. 1970’lerin sonlarında ortaya çıkan ve ADALINE modelinin çok katmanlı hali olan MADALINE’nin temelini oluşturur ve telefon hatlarında oluşan yankıları yok eden bir sistem olarak kullanılması ile de gerçek dünya sorunlarına uyarlanmış ilk yapay sinir ağı unvanını alır (Öztemel, 2003).

1960’lı yılların sonunda yapay sinir ağı çalışmaları duraklama devrine girdi. Yapay zekâ çalışmalarının o devirde önde gelen isimleri Minsky ve Pappert (1969) yayımladıkları “Perceptrons” adlı kitaplarında algılayıcı modelin (perceptron) bilimsel bir değerinin olmadığını, doğrusal olmayan problemlere çözüm üretemediğini vurgulamışlar ve buna ispat olarak XOR (exclusive-or) probleminin perceptron ile çözülememesini örnek göstermişlerdir. Bu örnek, pek çok kişiyi tatmin etti ve çalışmalar bir anda kesildi. Perceptron’un XOR problemini çözemeyişi, bütün bilimsel çevreleri yapay bir sinir ağı yapılamayacağına inandırmış ve yapay sinir ağları alanındaki araştırmaların bir anda durmasına neden olmuştur. Amerika Birleşik Devletleri’nde araştırma ve geliştirme çalışmalarını yürüten ve destek

sağlayan DARPA, yapay sinir ağları araştırmalarına verdiği desteği durdurmuş ve diğer yapay zekâ araştırmalarına yönelmiştir (Öztemel, 2003).

4.2.2.2 1970 sonrası YSA ile ilgili çalışmalar

Çalışmaların 1969 yılında sekteye uğraması ve gerekli finansal desteğin sağlanmamasına rağmen bazı bilim adamları YSA ile ilgili çalışmalarına devam ettiler.

Kohonen (1972), Korelasyon Matris Belleği'ni (Correlation Matrix Memories) geliştirmiştir. Bu model özellikle örüntü tanıma ve sınıflandırma gibi verideki benzer davranışların analizi ve veri yapısının ortaya çıkarılması gibi problemlerde kullanılmaktadır.

Fukushima, 1980'lerin başında görsel şekil ve yapıları tanımla amacıyla geliştirdiği NEOCOGNITRON modelini tanıtmıştır. Bu model, önceleri öğretmensiz (unsupervised) öğrenme için geliştirildiyse de daha sonra öğretmenli (supervised) öğrenme yapabilecek düzenlemelere gidilmiştir. Fukushima'nın çalışmaları, bu alandaki mühendislik uygulamalarının sayısını arttırmıştır.

1982 ve 1984 yıllarında John Hopfield tarafından yayımlanan çalışmalar, farklı tipteki yapay sinir ağlarının matematiksel modellerini üretmiş ve özellikle geleneksel bilgisayar programlama ile çözülemeyen problemlerin yapay sinir ağları ile çözülebileceğini göstermiştir. Bu çalışmaların pratikte uygulanabilirliği yapay sinir ağlarına olan ilginin yeniden artmasına neden olmuştur. Bu çalışmadan yola çıkarak Hinton ve arkadaşları Boltzman makinesini geliştirmiştir.

1982 yılında Kohonen “kendi kendine öğrenme nitelik haritaları (selforganizing feature maps-SOM)” konusundaki çalışmasını yayımlayarak öğretmensiz öğrenme modelinin gelişmesine ciddi katkıda bulunmuştur.

1986'da Rummelhart, Hinton, Williams ve McClelland'ın ortaya attıkları, “Geri Yayılma Algoritması” (Backpropagation Algorithm) tekniğiyle, birden çok katmanlı ağların, tek katmanlı ağların çözemeyeceği problemleri çözebildiğini ortaya koymuşlar ve XOR Problemini, bir geri yayılma ağı ile çözerek, yapay sinir ağları araştırmalarının önündeki tüm engelleri ortadan kaldırmışlardır.

1988'de Broomhead ve Lowe, Radyal Tabanlı Fonksiyonlar (Radial Basis Functions - RBF) modelini geliştirmişlerdir. Broomhead ve Lowe (1988) makalelerinde radyal

tabanlı fonksiyon temelli yapay sinir ağlarını, çok katmanlı ağlara alternatif olarak geliştirdiklerini belirtmişlerdir. Radyal tabanlı ağlar özellikle filtreleme ve veri sıkıştırma problemlerinde kullanılmıştır.

1990' da Daniel Spechth Olasılıksal Sinir Ağları'nı (Probabilistic Neural Networks - PNN) geliştirmiştir. Olasılıksal sinir ağları, radyal tabanlı fonksiyonlar modelinin daha gelişmiş bir türüdür. Çalışmalarını sürdüren Specht, 1991 yılında, Genelleştirilmiş Regresyon Ağları'nı (Generalized Regression Neural Networks - GRNN) geliştirmiştir.

1990'lı yılların başlarından itibaren sayısız çalışma ve uygulamalar geliştirilmiş, özellikle yapay sinir ağlarını eğitmek için gerekli süreleri kısaltmak, yeni ve daha verimli öğrenme algoritmaları geliştirmek, zamana bağlı olarak değişen modellere karşılık verebilen ağlar ve silikon sinir ağları geliştirmek, yapılan araştırmaların en önemli amaçlarını oluşturmaktadır.

4.2.3 Yapay sinir ağlarının avantajları

Yapay sinir ağları metodolojisi, özellikleri ve yapabildikleri sayesinde önemli avantajlar sunmaktadır. Bu bölümde, YSA'ların farklılık ve avantaj sağladığı noktalar incelenmektedir.

Doğrusal olmayan yapı: Yapay sinir ağlarının en önemli özelliklerinden birisi gerçek hayatta karşılaşılan doğrusal olmayan yapıları da dikkate alabilmeleridir. Özellikle ekonomik veriler gibi yapıları gereği doğrusal olmayan veriler ile ilgili analizler tahmin zorlukları nedeniyle genellikle lineer yöntemlerle gerçekleştirilmektedir. Hâlbuki bu durum, muhtemel bir doğrusal olmayan yapı içerilmesi durumunda yanlış sonuçlara yol açabilmektedir ya da en azından analizi yapılan sistemde açıklanamayan bileşenler kalabilmektedir. Sonuç olarak, analiz konusunun içerdiği veri setinin doğrusal veya doğrusal olmayan yapı içeriyor olması, analiz sonuçlarını etkileyecek önemli bir faktördür. Bu yüzden, doğrusal olmayan yapıları dikkate alabilmesi YSA'ların önemli bir özelliğidir (Yurtoğlu, 2005).

Paralellik: Günümüzde kullanılan bilgi işleme yöntemleri genelde seri işlemlerden oluşmaktadır. Yapay sinir ağları ise paralel işlemci kullanmaktadır. Seri işlemcilerde herhangi bir birimin yavaş olması tüm sistemi yavaşlatırken, yapay sinir ağlarında yavaş bir birimin etkisi az olmaktadır. Bu durum yapay sinir ağlarının daha hızlı ve güvenilir olması sonuçlarını doğurmaktadır.

Öğrenme: YSA'ların diğer bir önemli avantajı en önemli özelliğinden kaynaklanmaktadır. Esin kaynağı insan beyninin çalışma sistemi olan bu yöntem, eğitime veya başlangıç tecrübesi sayesinde veriyi kullanarak öğrenme yeteneğine sahiptir. Bu özelliği sayesinde ise geleneksel teknikler için çok karmaşık kalan problemlere çözüm sağlayabilmektedirler. Ayrıca, insanların kolayca yapabildiği ama geleneksel metotların uygulanamadığı basit işlemler için de oldukça uygundur (Yurtoğlu, 2005).

Dağıtılmış Hafıza: Yapay sinir ağlarında bilgi, ağa yayılmış durumdadır ve hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir. Diğer programlarda olduğu gibi veriler bir veri tabanında veya programın içinde gömülü değildir. Tek bir bağlantının herhangi bir anlamı yoktur ve ağın tamamı, öğrendiği olayın bütünü karakterize etmektedir. Bu nedenle yapay sinir ağlarının dağıtılmış bellekte bilgi saklayabildikleri söylenebilir (Öztemel, 2003).

Gerçek Zamanlı İşlem Yapabilme: YSA hesaplamaları paralel olarak yürütülebildiğinden gerçek zamanlı işlem yapabilirler. Özellikle suçluların akıllı kameralar kullanılarak belirlenmesi gibi zamanın hayati önem taşıdığı problemlerde, yapay sinir ağları klasik uzman sistemlerden çok daha hızlı tepki verebilirler. Bunun nedeni YSA'nın dağıtılmış paralel yapıları sayesinde, birim zamanda çok daha fazla veriyi işleyebilmeleridir (Çelik, 2008).

Genelleme: YSA, öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlarda genelleme yapabilmektedirler. YSA'lar, gürültülü (noisy) veya kayıp veriler için çözüm üretebilmektedirler. Çoğu klasik yöntem eksik ve gürültülü veri söz konusu olduğunda, etkinliklerini büyük oranda kaybetmektedir fakat yapay sinir ağları, bu gibi olumsuz durumlarda dahi çok iyi bir performansla çalışabilirler (Yurtoğlu, 2005).

Kendi İlişkisini Oluşturma: Yapay sinir ağları, bilgilere (verilere) göre kendi ilişkilerini oluştururlar ve denklem içermezler. Bununla birlikte sistemin içinde ne olduğu tam olarak analiz edilemez. Yapay sinir ağları, bu özellikleri sayesinde, verilen bilgilerden ilişkiler ortaya çıkarabilen bir “akıllı karakutu” olarak tanımlanabilirler (Tenti, 1996).

Sınırsız Sayıda Değişken ve Parametre: Yapay sinir ağları modelleri sınırsız sayıda değişken ve parametre ile çalışabilmektedir. Bu sayede mükemmel bir öngörü

doğruluğu ile genel çözümler sağlanabilmektedir. Yapay sinir ağları, sonsuz sayıda değişkeni, her biri sadece gerektiği anda, gerektiği kadar kullanabilecek şekilde eğitilebilirler (Yurtoğlu, 2005).

Dereceli bozulma: Ağlar bir eksik ve problem ile karşılaştıklarında hemen bozulmazlar. Hata toleransına sahip oldukları için dereceli bir şekilde bozulurlar (Öztemel, 2003).

4.2.4 Yapay sinir ağlarının dezavantajları

Yapay Sinir Ağlarının yukarıda belirtilen birçok avantajlarının yanında bazı dezavantajları da vardır.

Elektronik Kısıtlar: YSA'nın donanım bağımlı çalışmaları önemli bir sorun olarak görülebilir. YSA yöntemiyle etkin bir analiz yapılabilmesi için çok hızlı paralel işlemcilere ihtiyaç duyulmaktadır. Özellikle tepki süresinin hayati önem taşıdığı uygulamalarda, yapay sinir ağlarının üzerlerinde çalıştıkları bilgisayar sistemlerinin çok hızlı olmasının yanında, kullanılan yazılımın da günümüzde kullanılan çok çekirdekli işlemcilere göre programlanmış olması büyük bir avantaj sağlayacaktır (Öztemel, 2003).

Probleme Uygunsuzluk: Probleme uygun ağ yapısının belirlenmesi genellikle deneme yanılma yoluyla yapılmaktadır ve bu da önemli bir problemdir. Çünkü eğer problem için uygun bir ağ modeli oluşturulamaz ise çözümü olan bir problemin çözülememesi veya performansı düşük çözümlerin elde edilmesi durumu söz konusu olabilir. Ayrıca diğer bir konu, YSA, kabul edilebilir çözümler üretir ve optimum çözümü garanti etmez (Öztemel, 2003).

Problem Mimarisi: Problem çözümü için kullanılacak olan yapay sinir ağında nöron sayısı, katman sayısı, öğrenme algoritması gibi değişkenlerin seçimi subjektif olarak yapıldığından, seçilen mimarinin en iyi çözümü verebileceğinin garantisi yoktur (Çelik, 2008).

Problemin Ağa Gösterimi: YSA, sadece nümerik verilerle çalışır ve problemin nümerik gösterime dönüştürülmesi gerekmektedir. Bu ise, kullanıcının becerisine bağlıdır. Uygun bir gösterim mekanizmasının oluşturulamaması problemin çözümünü engelleyebilir veya performansı düşük bir çözüme sebep olabilir (Öztemel, 2003).

Eğitim Problemi: YSA eğitilirken, eğitimin nerede durdurulacağı kesin olarak belli değildir. Eğitim kabul edilebilir bir hata oranına gelindiğinde durdurulur ve bu karar subjektif olarak verilmektedir. Eğitimin erken bitirilmesi durumunda öngörü performansının düşük olması, geç bitirilmesi durumunda ezberleme (overfitting – aşırı uyum) problemi ortaya çıkmaktadır. Overfitting veya Overoptimizing; herhangi bir öngörü sisteminin, örneklem için başarılı sonuçlar vermesi fakat aynı zamanda örneklem dışı veriler söz konusu olduğunda tahmin yeteneğinin bulunmaması durumunu tanımlamaktadır (Pardo, 1992).

Yorumlama Problemi: Geleneksel istatistiksel tekniklerden alınan sonuçlar bir takım testlerle yorumlanabilmesine ve kararlılık analizleri yapılabilmesine rağmen, YSA için böyle bir imkân bulunmamaktadır. Ağın kendi verdiği çıktıya nasıl ulaştığı bilinmemektedir. Özellikle öngörülerin hayati önem taşıdığı uygulamalarda, YSA'nın bu özelliği çok büyük bir problem oluşturmaktadır. Örneğin; biyolojik bir uygulamada, kanserle ilgili bir araştırmada kullanılan yapay sinir ağının, ulaştığı çıktılara nasıl ulaştığının analiz edilememesi, bu tekniğe olan güvenin azalmasına neden olacaktır (Çelik, 2008).

4.2.5 Yapay sinir ağlarının kullanım alanları

YSA'lar gerçek hayatta karşılaşılan problemlerde oldukça geniş bir uygulama alanı kazanmışlardır. Bugün, birçok endüstride başarılı şekilde kullanılmaktadırlar. Uygulama alanları için bir sınır yoktur fakat öngörü, modelleme ve sınıflandırma gibi bazı alanlarda ağırlıklı olarak kullanılmaktadır. Bugün, YSA'lar birçok ciddi problem üzerinde uygulanmaktadır ve bu problemlerin sayısı giderek artmaktadır (Yurtoğlu, 2005).

Başarılı uygulamalar incelendiğinde YSA'ların, doğrusal olmayan, çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek verilerin olması ve problemin çözümü için özellikle bir matematiksel modelin ve algoritmanın bulunmaması hallerinde yaygın olarak kullanıldığı söylenebilir. Bu amaçla geliştirilen ağlar genel olarak şu fonksiyonları yerine getirmektedir (Öztemel, 2003):

- Muhtemel fonksiyon kestirimleri
- Sınıflandırma
- İlişkilendirme veya örüntü eşleştirme
- Zaman serileri analizi

- Sinyal filtreleme
- Veri sıkıştırma
- Örüntü tanıma
- Doğrusal olmayan sistem modelleme
- Optimizasyon


4.3 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

4.3.1 Biyolojik sinir hücresi

Yapay sinir ağları, biyolojik sinir sisteminden esinlenerek geliştirilmiştir. Bu nedenle öncelikle biyolojik sinir sistemi hakkında bilgi verilecektir.

Beynin çalışma sistemi, hala tam olarak çözülmemiş bir sırdır. Özellikle, vücudun diğer organlarındaki hücrelerden farklı olarak yenilenebilme özelliği olmayan beynin, insana hatırlama, düşünme ve her hareketinde geçmiş deneyimlere başvurma yeteneğini sağlayan en temel elemanı olan sinir hücrelerinin çalışma sistemi hala gizliliğini büyük ölçüde korumaktadır. İnsan beyinde ortalama 10^{10} sinir hücresi ve bunların da 6×10^{10} 'ten fazla bağlantısı olduğu bilinmektedir. Beynin gücü bu çok sayıdaki sinir hücresi ve aralarındaki bağlantılardan, genetik yapıları ile öğrenme yeteneklerinden kaynaklanmaktadır (Anderson and McNeill, 1992).

Biyolojik sinir ağları, insan beyninin çalışmasını sağlayan en temel taşlardan birisidir. İnsanın bütün davranışlarını ve çevresini anlamasını sağlarlar. Biyolojik sinir ağları beş duyu organından gelen bilgiler ışığında algılama ve anlama mekanizmalarını çalıştırarak olaylar arasındaki ilişkileri öğrenir (Öztemel, 2003). Şekil 4.1 ve Çizelge 4.1 insan beynini ve temel fonksiyonlarını göstermektedir.




Şekil 4.1: İnsan beyni.

Çizelge 4.1: Beynin bölgelere göre fonksiyonları (Bilim ve Teknik, 2006).


Bölge	Fonksiyon
1	Prefrontal Korteks: Zekâ, öğrenme, kişilik
2	Motor Bölge: Karmaşık hareketlerin eşgüdümü ve istemli hareketler
3	Duyusal Bölge: Dokunma duyusu bilgilerinin işlenmesi
4	Tat bölgesi
5	Görme bölgesi
6	Beyincik: Denge bölgesi
7	Genel yorumlama bölgesi
8	Omurilik
9	Dil Bölgesi
10	İşitsel Bölge
11	Konuşma Merkezi: Konuşmanın üretiminden sorumlu Broca Bölgesi buradadır.

Duyu organlarından gelen bilgiler (sinyaller) beyin sinir sistemi sayesinde beyine taşınır ve beyin oluşturduğu kararlar da yine sinir sistemi tarafından vücudun organlarına eylem olarak gönderilir. Bir sinir hücresinin genel yapısı Şekil 4.2’ de gösterilmektedir.



Şekil 4.2: Biyolojik sinir hücresinin yapısı.

Bir sinir hücresi, bir hücre gövdesi ile *dendrit* ve *akson* adı verilen uzantılardan meydana gelir. Sinir hücresi, dendrit adı verilen bir kısım uzantılarla diğer sinir hücrelerinden aldığı işaretleri hücre gövdesine taşır ve hücre gövdesinde toplanan bu işaretler değerlendirilerek bir çıkış işareti üretilir ve bu işaretler akson adı verilen uzantılar vasıtasıyla diğer sinir hücresine gönderilir. Bir sinir hücresinde birçok dendrit olmasına karşın tek bir akson vardır. Yani bir sinir hücresinde birçok giriş bulunmasına rağmen tek bir çıkış vardır. İki sinir hücresi arasında birinin dendriti ile diğerinin aksonu arasında bir bağlantı vardır ve bu bağlantı yerine *sinaps* adı verilir. (Efe ve Kaynak, 2000). İki hücrenin birbiri ile bilgi alışverişi sinaptik bağlantılarda *neurotransmitter*'ler yolu ile sağlanmaktadır. Şekil 4.3' te sinaptik boşluktaki hücreler arası bilgi alışverişi gösterilmektedir.



Şekil 4.3: Sinir hücreleri arası bilgi alışverişi.

4.3.2 Yapay sinir hücresi


Biyolojik sinir ağlarının sinir hücrelerinden oluşması gibi, yapay sinir ağları da yapay sinir hücrelerinden meydana gelmektedir. Yapay sinir hücreleri ayrıca düğüm (node), birim (unit) veya işlemci eleman (processing unit) olarak da adlandırılmaktadır. Bir yapay sinir ağı, birbiriyle bağlantılı çok sayıda yapay sinir hücresinden meydana gelmektedir. Yapay sinir hücreleri biyolojik sinir hücrelerinin basit bir modelidir (Efe ve Kaynak, 2000)

Çizelge 4.2:Biyolojik sinir ağı ve yapay sinir ağının karşılaştırılması.

Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir Hücresi (Nöron)	İşlemci Eleman (Yapay Sinir Hücresi, Düğüm)
Sinaps	İşlemci Elemanlar Arasındaki Bağlantı Ağırlıkları
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	İşlemci Eleman Çıktısı

Yapay sinir ağlarının içinde bulunan tüm sinir hücreleri bir veya birden fazla girdi alırlar ve tek bir çıktı verirler. Bu çıktı yapay sinir ağının dışına verilen bir çıktı olabileceği gibi başka bir yapay sinir hücresine girdi olarak da verilebilir. Bir yapay sinir hücresi genel olarak beş temel bileşenden oluşmaktadır.

- Girdiler
- Ağırlıklar
- Toplama fonksiyonu
- Aktivasyon fonksiyonu
- Çıktı



Şekil 4.4: Yapay sinir hücresinin yapısı.

4.3.2.1 Girdiler

Bir yapay sinir hücresine dış dünyadan gelen bilgilerdir. Bunlar ağı öğrenmesi istenen örnekler tarafından belirlenir. Yapay sinir hücresine dış dünyadan olduğu gibi başka hücrelerden veya kendi kendisinden de bilgiler gelebilir. (Öztemel, 2003).

4.3.2.2 Ağırlıklar

Ağırlıklar, yapay sinir hücresi tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılarıdır. Her bir giriş kendine ait bir ağırlığa sahiptir. Bir ağırlığın değerinin büyük olması, o girişin yapay sinire güçlü bağlanması ya da önemli olması, küçük olması zayıf bağlanması ya da önemli olmaması anlamına gelmemektedir (Elmas, 2003).

4.3.2.3 Toplama fonksiyonu

Bu fonksiyon, hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağı gelen net girdi bulunmuş olur. Şu şekilde formülize edilmektedir:

$$NET = \sum_{i=1}^n G_i A_i \quad (4.1)$$

Burada G girdileri, A ağırlıkları, n ise hücreye gelen toplam girdi sayısını göstermektedir. Yapay sinir ağlarında daima bu fonksiyonun kullanılması şart değildir. Çizelge 4.3'te literatürde kullanılan toplama fonksiyonlarına örnekler verilmektedir.

Çizelge 4.3: Toplama fonksiyonu örnekleri (Öztemel, 2003).

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

Görüldüğü gibi, bazı durumlarda gelen girdilerin değeri dikkate alınırken bazı durumlarda ise gelen girdilerin sayısı önemli olabilmektedir. Bir problem için en uygun toplama fonksiyonunu belirlemek için bulunmuş bir formül yoktur. Genellikle deneme yanılma yolu ile toplama fonksiyonu belirlenmektedir. Bir yapay sinir ağında bulunan sinir hücrelerinin tamamının aynı toplama fonksiyonuna sahip olmaları gerekmez. Her sinir hücresi bağımsız olarak farklı bir toplama fonksiyonuna sahip olabilecekleri gibi hepsi aynı toplama fonksiyonuna da sahip olabilir (Öztemel, 2003).

4.3.2.4 Aktivasyon fonksiyonu


Aktivasyon fonksiyonu, toplama fonksiyonundan gelen girdiyi işleyerek yapay sinir hücresinin çıkışını belirler. Transfer fonksiyonu olarak da adlandırılan aktivasyon fonksiyonu çeşitli tiplerde ve genellikle doğrusal olmayan bir fonksiyondur. Doğrusal fonksiyonların tercih edilmemesinin nedeni, doğrusal fonksiyonlarda girdi ile çıktının doğru orantılı olmasıdır. Bu durum ilk yapay sinir ağları denemelerinin başarısızlıkla sonuçlanmasının temel nedenidir (Minsky and Papert, 1969).

Uygun aktivasyon fonksiyonunun seçimi tasarımcının farklı fonksiyonları denemeleri sonucunda belirlenmektedir. Ancak çok katmanlı algılayıcılar gibi bazı modeller aktivasyon fonksiyonunun, türevi alınabilir bir fonksiyon olmasını şart koşturmaktadır. Ayrıca fonksiyonun seçimi, yapay sinir ağının verilerine ve neyi öğrenmesinin istendiğine de bağlıdır. Aktivasyon fonksiyonu olarak en çok kullanılanlar sigmoid fonksiyon ve hiperbolik tanjant fonksiyonlarıdır.

Günümüzde en yaygın olarak kullanılan çok katmanlı algılayıcı modelinde genel olarak aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmaktadır. Bu fonksiyon şu formül ile gösterilmektedir (Öztemel, 2003).

$$F(Net) = \frac{1}{1 + e^{-Net \text{ Girdi}}} \quad (4.2)$$

Sigmoid fonksiyonunun şekilsel gösterimi Şekil 4.5'te verilmektedir. Çizelge 4.4'te ise aktivasyon fonksiyonu olarak kullanılan diğer fonksiyonlara örnekler verilmektedir.



Şekil 4.5: Sigmoid fonksiyonunun şekilsel gösterimi.

Çizelge 4.4: Aktivasyon fonksiyonu örnekleri (Öztemel, 2003).

Aktivasyon Fonksiyonu	Açıklama
Lineer Fonksiyon $F(Net) = Net$	Gelen girdiler, olduğu gibi hücrenin çıktısı olarak kabul edilir.
Step Fonksiyonu $F(Net) = \begin{cases} 1 & \text{if } Net > \text{eşik değeri} \\ 0 & \text{if } Net \leq \text{eşik değeri} \end{cases}$	Gelen NET girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 olarak belirlenir.
Sinüs Fonksiyonu $F(Net) = \sin(Net)$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.

Çizelge 4.4 (devam): Aktivasyon fonksiyonu örnekleri (Öztemel, 2003).


Eşik Değer Fonksiyonu $F(NET) = \begin{cases} 0 & \text{if } NET \leq 0 \\ NET & \text{if } 0 < NET < 1 \\ 1 & \text{if } NET \geq 1 \end{cases}$	Gelen bilgilerin 0 veya 1'den büyük olmasına göre bir değer alır.
Hiperbolik Tanjant Fonksiyonu $F(NET) = \frac{e^{NET} + e^{-NET}}{e^{NET} - e^{-NET}}$	Gelen NET girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.

4.3.2.4 Çıktı

Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Bu değer ya başka bir yapay sinir hücresine girdi olarak ya da dış ortama gönderilmektedir. Bir işlemci elemanın birden fazla girdisi olmasına rağmen tek bir çıktısı olmaktadır.

4.3.3 Yapay sinir hücresinin çalışma prensibi

Bir yapay sinir hücresinin çalışma prensibi, aşağıdaki örnek üzerinden özetlenecektir. Bir yapay sinir hücresine gelen bilgiler ve ağırlıklar Şekil 4.6'da verildiği gibi varsayalım. Görüldüğü gibi hücrenin 5 girdisi ve 5 ağırlık değeri bulunmaktadır.



Şekil 4.6: Bir yapay sinir hücresinin çalışma örneği.

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

$$NET = 0,55 * (-0,25) + 0,34 * (0,74) + 0,72 * (0,15) + 0,85 * (-0,44) + 0,95 * (-0,63) \quad (4.3)$$

$$NET = -0,1375 + 0,2516 + 0,1080 - 0,3740 - 0,5985 \quad (4.4)$$

$$NET = -0,7504 \quad (4.5)$$

Hücrenin çıktısı, sigmoid fonksiyonuna göre hesap edilirse;

$$\text{ÇIKTI} = \frac{1}{1+e^{0,7504}} \quad (4.6)$$

$$\text{ÇIKTI} = 0,321 \quad (4.7)$$

4.3.4 Yapay sinir ağının yapısı ve sınıflandırılması

4.3.4.1 Katman sayısına göre sınıflandırma

Yapay sinir hücreleri bir araya gelerek yapay sinir ağını meydana getirirler. Sinir hücreleri, ağ yapısı içerisinde katman halinde ve her katman içinde paralel olarak bir araya gelerek ağı meydana getirirler. Katman sayısına göre yapay sinir ağları şu şekilde sınıflandırılır:

1. *Tek Katmanlı Yapay Sinir Ağları:* Sadece girdi ve çıktı katmanlarından oluşan, doğrusal sistemlerin modellenmesinde başarılı olan ancak doğrusal olmayan problemlerin çözümünde başarısız olan, literatürde geliştirilen ilk yapay sinir ağlarıdır. Tek katmanlı yapay sinir ağlarının en önemlileri Basit Algılayıcı Modeli (Perceptron), Adaptif Doğrusal Eleman (Adaptive Linear Element - ADALINE) ve Çoklu Adaptif Doğrusal Eleman (Multiple Adaptive Linear Element - MADALINE)'dir.

2. *Çok Katmanlı Yapay Sinir Ağları:* En az 1 gizli katman içeren, doğrusal olmayan problemlerin çözümü için geliştirilen ağlardır. Çalışmanın devamında kullanılacak olan ağ yapısı, bu kapsamdadır. Bu tip ağ yapıları, tek katmanlı ağ yapılarına göre daha karmaşık problemleri çözebilmektedir. Ancak çok katmanlı ağların eğitilmesi, tek katmanlı ağların eğitilmesine göre oldukça zordur. Buna rağmen birçok problemin çözümünde çok katmanlı ağların eğitimi, tek katmanlı ağların eğitimine göre daha başarılı olabilmektedir. Bunun nedeni, tek katmanlı ağların problemin çözümü için yetersiz kalmalarından kaynaklanmaktadır (Fausett, 1994).

Şekil 4.7'de çok katmanlı yapay sinir ağlarında katmanlar arasındaki ilişki gösterilmektedir.



Şekil 4.7:Yapay sinir ağlarında katmanların birbirleri ile ilişkileri (Öztemel, 2003).

- *Girdi Katmanı:* Dışarıdan girdileri alan nöronları içerir. Ayrıca, önemli olan bir nokta, girdi tabakasındaki nöronların girdi değerler üzerinde bir işlem uygulamamasıdır. Sadece girdi değerleri bir sonraki tabakaya iletirler ve bu yüzden de bazı araştırmacılar tarafından ağların tabaka sayısına dâhil edilmezler (Yurtoğlu, 2005).
- *Gizli Katman:* 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 dig., 1994) .
- *Çıktı Katmanı:* Bu katmandaki yapay sinir hücreleri, gizli katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan girdi seti (örnek) için üretmesi gereken çıktıyı üretirler. Üretilen çıktı ise dış dünyaya gönderilir (Öztemel, 2003).

4.3.4.2 Bağlantı yapılarına göre sınıflandırma


Bağlantı yapılarına göre YSA, ileri beslemeli ağlar ve geri beslemeli ağlar olmak üzere iki bölümde ifade edilebilir.

1. *İleri Beslemeli Ağlar:* İleri beslemeli bir ağda işlem elemanları genellikle katmanlara ayrılmıştır. İşlemci elemanlar, bir katmandan diğer bir katmandaki tüm işlem elemanlarıyla bağlantı kurarlar ancak işlem elemanlarının aynı katman içerisinde kendi aralarında bağlantıları bulunmaz. İleri beslemeli ağlarda bilgi akışı,

girdi katmanından gizli katmana, gizli katmandan da çıktı katmanına doğru geri besleme olmaksızın tek yönde yapılmaktadır (Zhang, 2003).

2. *Geri Beslemeli Ağlar*: Geri beslemeli bir yapay sinir ağında, işlem elemanları arasında dönüşler ya da geri besleme bağlantıları bulunmaktadır. Geri beslemeli ağlarda herhangi bir hücrenin çıktısı direkt olarak girdi katmanına gönderilerek tekrar girdi olarak kullanılabilir (Zhang, 2003). Geri beslemeli ağların kullanımı ile ileri beslemeli ağlara göre daha zengin dinamiklere sahip modeller geliştirilebilir. Ancak belirtmek gerekir ki, ileri beslemeli ağlar, geri beslemeli ağlara göre akademik ve pratik alanda daha çok uygulanmaktadır. Bunun nedeni; geri beslemeli ağların pratikte uygulanabilirliğinin zor olmasıdır. Özellikle geri beslemeli ağların birçok farklı yapıyla oluşturulabilmesi belirli bir model yapısında uzmanlaşmayı engelleyebilmekte ve eğitim algoritmalarının tutarsız olması nedeniyle eğitiminin güç olmasına neden olabilmektedir (Zhang, 2003).

Şekil 4.8’de ileri ve geri beslemeli ağ yapısına örnek verilmektedir.



Şekil 4.8: İleri ve geri beslemeli ağ yapıları (Yurtoğlu, 2005).

4.3.4.3 Öğrenme stratejilerine göre sınıflandırma

Öğrenme stratejilerine göre yapay sinir ağları, danışmanlı öğrenme (supervised learning), danışmansız öğrenme (unsupervised learning) ve destekleyici öğrenme (reinforcement learning) olmak üzere üç bölümde ifade edilebilir.

1. *Danışmanlı Öğrenme*: Danışmanlı öğrenme algoritmalarında, ağın eğitimi için ağa örnek olarak girdi değerlerinden ve hedef çıktı değerlerinden oluşan bir örnek veri seti verilir (MacKay, 2003). Verilen hedef çıktı değerleri, YSA literatüründe danışman ya

da öğretmen olarak adlandırılır. Danışmanlı öğrenme algoritmalarında, genellikle hataların hesaplanması için Ortalama Mutlak Hata ve Hata Kareleri Ortalamasının Karekökü performans ölçütleri kullanılır. Bu performans ölçütleri yardımıyla ağı, kendi ürettiği çıktılar ile hedef çıktılar arasında oluşan hata sinyallerini dikkate alarak kıyaslama yapması sağlanır. Ağı ürettiği çıktılar ile hedef çıktılar arasındaki hata sinyallerini minimize etmek amacıyla, işlem elemanları arasındaki bağlantı ağırlıkları düzenlenir. Diğer bir deyişle, danışmanlı öğrenme ile YSA, örnek girdiyi işleyerek kendi çıktısını üretir ve gerçek çıktı ile karşılaştırır. Öğrenme metodu sayesinde, hatayı en aza indirmek için bağlantı ağırlıkları yeniden düzenlenerek YSA'nın danışmana benzemesi amaçlanır (Haykin, 1999). Böylece hedef çıktı değerlerine en yakın çıktı değerleri YSA tarafından üretilir. Danışmanlı öğrenme algoritmalarına Delta Kuralı ve Genelleştirilmiş Delta Kuralı örnek olarak verilebilir.

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

3. Destekleyici Öğrenme: Bu tür bir eğitimde, ağı bir danışman yardımcı olur. Fakat danışman, her girdi seti için üretilmesi gereken çıktı setini sisteme göstermek yerine, sistemin kendisine gösterilen girdilere karşılık çıktısını üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu gösteren bir sinyal üretir. Sistem, danışmandan gelen bu sinyali dikkate alarak öğrenme sürecini devam ettirir. Bu öğrenme yönteminin kullanıldığı ağlara örnek olarak; Learning Vector Quantization Modeli verilebilir (Öztemel, 2003).

4.3.5 Yapay sinir ağlarının eğitimi ve öğrenme kuralları

Öğrenme, ağı başlangıçta rastgele olarak atanan ağırlık değerlerinin belirlenmesi işlemidir. Ağ, gördüğü her örnek için bu ağırlık değerlerini değiştirir. Bu işlem ağı doğru ağırlık değerlerine ulaşması, bir başka deyişle, örneklerin temsil ettiği olayla ilgili genelleme yapabilecek duruma gelmesi ile son bulur. Ağırlık değerlerinin

değiştirilmesi işlemi, kullanılan öğrenme stratejisine göre değişen ve öğrenme kuralı olarak adlandırılan belli bazı kurallara göre yürütülür (Efe ve Kaynak, 2000).

İnsan beyni, doğumdan sonraki gelişme sürecinde çevresinden duyu organlarıyla algıladığı davranışları yorumlar ve bu bilgileri diğer davranışlarında kullanır. Yaşadıkça beyin gelişir ve tecrübelenir. Artık olaylar karşısında nasıl tepki göstereceğini çoğu zaman bilmektedir. Fakat hiç karşılaşmadığı bir olay karşısında yine tecrübesiz kalabilir. YSA' nın öğrenme sürecinde de, tıpkı dış ortamdan gözle veya vücudun diğer organlarıyla uyarıların alınması gibi dış ortamdan girişler alınır. Bu girişlerin beyin merkezine iletilerek burada değerlendirilip tepki verilmesi gibi YSA da aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı üretilir. Bu çıkış yine tecrübeyle verilen çıkışla karşılaştırılarak hata bulunur. Çeşitli öğrenme algoritmalarıyla hata azaltılıp gerçek çıkışa yaklaşılmaya çalışılır. Bu çalışma süresince yenilenen, YSA ağırlıklarıdır. Ağırlıklar her bir çevrimde yenilenerek amaca ulaşmaya çalışılır. Amaca ulaşmanın veya yaklaşmanın ölçüsü de yine dışarıdan verilen bir değerdir. Eğer YSA verilen giriş-çıkış çiftleriyle amaca ulaşmış ise ağırlık değerleri saklanır. Ağırlıkların sürekli yenilenip istenilen sonuca ulaşılan kadar geçen zamana öğrenme adı verilir ve YSA için en önemli kavramlardan birisidir. YSA öğrendikten sonra daha önce verilmeyen girişler verilir, sinir ağı çıkışıyla gerçek çıkışın yaklaşımı incelenir. Eğer yeni verilen örneklerle de doğru yaklaşıyorsa sinir ağı işi öğrenmiş demektir. Sinir ağına verilen örnek sayısı optimum değerden fazla ise sinir ağı işi öğrenmemiş ezberlemiştir. Genelde eldeki örneklerin yüzde sekseni ağa verilir ağ eğitilir, daha sonra geri kalan yüzde yirmilik kısım verilir ağın davranışı incelenir diğer bir deyişle ağ böylece test edilir (Öztemel 2003).

Genel olarak ifade etmek gerekirse YSA' lar da bir bebeğin beyninin öğrenmesi gibi deneme yanılmayla, hata yaparak öğrenir. Eğitim sırasındaki amaç, bulunması gereken doğru sonuçlara en yakın çıktıyı üretebilmektir. Bu sebeple ağ, verilen girdilere göre kendi mimarisine de uygun olarak işlem yaptıktan sonra bir çıktı üretir. Çıktı ile hedef değerler arasındaki fark, hatadır. Ağ, bu hatayı kabul edilebilir sınırlar arasına indirebilmek için işlemi tekrarlar. Eğitim setinin ağ içinde bir kez işleminden geçirilmesine devir (epoch) denir. Devir sayısının çok olması ağın öğrenme sürecinde önemli bir etkidir. Fakat devir sayısının yüksek seçilmesi de performansı düşüren bir etkidir. Bu durumda ağın mimarisi, aktivasyon fonksiyonu, öğrenme

yöntemi ve devir sayısı seçilirken optimizasyonun iyi bir şekilde yapılması gerekir (Keleşoğlu, 2005).

Yapay sinir ağlarında kullanılan öğrenme stratejileri, Bölüm 4.2.4.3'te anlatılmıştı. Burada dikkat edilmesi gereken nokta, öğrenme stratejilerinden hangisi uygulanırsa uygulansın eğitimin belli kurallara göre gerçekleştirileceğidir. Bu kuralların bazıları çevrimiçi, bazıları ise çevrimdışı çalışmaktadır.

4.3.5.1 Çevrimiçi öğrenme

Bu kurallar gerçek zamanlı çalışabilmektedirler. Bu kurallara göre öğrenen sistemler gerçek zamanda çalışırken bir taraftan fonksiyonlarını yerine getirmekte diğer taraftan ise öğrenmeye devam etmektedir. Kohonen öğrenme kuralı, bu sınıfa örnek olarak verilebilir (Öztemel, 2003).

4.3.5.2 Çevrimdışı Öğrenme

Çevrimdışı öğrenme kurallarına dayalı öğrenen sistemler kullanıma alınmadan önce örnekler üzerinde eğitilirler. Bu kuralları kullanan sistemler eğitildikten sonra gerçek hayatta kullanıma alındığında artık öğrenme olmamaktadır. Sistemin öğrenmesi gereken yeni bilgiler söz konusu olduğunda sistem kullanımdan çıkarılmakta ve çevrimdışı olarak yeniden eğitilmektedir. Eğitim tamamlanınca sistem tekrar kullanıma alınmaktadır. YSA'nda yaygın olarak kullanılan Delta öğrenme kuralı, bu sınıfa örnek olarak verilebilir (Öztemel, 2003).

4.3.5.3 Öğrenme kuralları

Öğrenme işlemini kolaylaştırmak için birçok öğrenme kuralı (algoritması) geliştirilmiştir. En bilinen ve en yaygın olarak kullanılan öğrenme kuralları şunlardır:

- **Hebb Kuralı:** Öğrenme kuralları arasında en çok bilinen bu kural, Ponaldd Hebb tarafından geliştirilmiş ilk öğrenme kuralıdır. Bu kural, Hebb' in 1949 yılında yayınlanan The Organization of Behavior adlı kitabında ilk kez tanımlanmıştır. Bu kuralın temel tanımı şöyle yapılmıştır: Eğer bir nöron diğer bir nörondan girdi aldığı anda bu iki nöron yüksek aktivitede ise yani matematiksel olarak aynı işarete sahip ise, nöronlar arasındaki ağırlık güçlendirilmelidir (Hebb, 1949). Diğer bir deyişle, eğer ağ içerisinde birbirine bağlı iki hücre (nöron) aynı anda “on” durumunda ise, bu anda bu iki ünite arasındaki ağırlık değerlerinin artması beklenir

ve sinapsislerin gerilimlerinin (ağırlıklarının) ayarlanması ile öğrenmenin oluşacağını ön görür (Elmas, 2003).

- *Hopfield Kuralı:* Hebb kuralına benzer bir kuraldır ancak bir istisnası vardır. Hopfield kuralına göre, ağırlıkların güçlendirilmesi işleminde güçlendirme veya zayıflatma için bir büyüklük tanımlamak gerekmektedir. İstenen çıktı ve girdinin her ikisi de aktif veya pasifse, bağlantı ağırlığı öğrenme oranı kadar artırılır. Ters durumda ise bağlantı ağırlığı öğrenme oranı kadar azaltılır. Hopfield kuralı, Hebb kuralından farklı olarak YSA elemanlarının bağlantılarının ne kadar güçlendirilmesi ya da zayıflatılması gerektiğini de belirler. Eğer beklenen çıktılar ve girdilerin her ikisi de aktif veya pasif ise, öğrenme katsayısı kadar ağırlık değerlerini de güçlendirir veya zayıflatır. Ağırlıkların güçlendirilmesi ya da zayıflatılması, öğrenme katsayısının yardımıyla gerçekleşir. Öğrenme katsayısı, genellikle 0 ile 1 arasında kullanıcı tarafından belirlenen sabit pozitif bir değerdir (Tebelkis, 1995).

- *Kohonen Kuralı:* Bu kural, Kohonen tarafından 1982 yılında geliştirilmiştir. Bu kuralda sinir hücreleri ağırlıkları değiştirmek için birbirleri ile yarışır. En büyük çıktıyı üreten hücre kazanan hücre olur ve bağlantı ağırlıklarını değiştirir. Kazanan hücre, yakınındaki hücelere göre daha kuvvetli hale gelmektedir (Öztemel, 2003). Böylece kazanan hücrenin komşularına bağlantı ağırlıklarını güncellemeleri için izin verilir. Bağlantı ağırlıklarını daha fazla güncelleyebilmek, en büyük çıktıyı üretebilme denemelerindeki şansı artırdığı için, kazanan bir hücre, komşu hücrelerin bağlantı ağırlıklarının güncellenmesine izin vererek onların da şanslarını artırmış olur.

- *Delta Kuralı:* Bu kurala göre hedef çıktı ile elde edilen çıktı arasındaki farkı azaltmak için YSA elemanlarının bağlantılarının ağırlık değerleri sürekli yeniden hesaplanır. Amaç hedef çıktı ile elde edilen çıktı arasındaki hata karelerinin ortalamasını en aza indirebilmektir. Hatalar en son katmandan geriye doğru ardışık iki katman arasındaki bağlantı ağırlıklarına dağıtılır (Çorumluoğlu, 2000).

4.3.6 Çok katmanlı algılayıcılar

Çok Katmanlı Algılayıcılar (ÇKA), katmanları arasında tam bağlantı (full connected) bulunan, ileri beslemeli (feedforward) ve danışmanlı (supervised) olarak eğitilen, çok katmanlı (multilayer) ağlardır (Crochat ve Franklin, 2003).

ÇKA ağları, danışmanlı öğrenme stratejisine göre çalışırlar. Yani, bu ağlara eğitim sırasında hem girdiler hem de o girdilere karşılık üretilmesi gereken (beklenen) çıktılar gösterilir. Ağın görevi her girdi için o girdiye karşılık gelen çıktıyı üretmektir. ÇKA ağının öğrenme kuralı ise, en küçük kareler yöntemine dayalı genelleştirilmiş delta kuralıdır. Genelleştirilmiş delta kuralı iki safhadan oluşur (Öztemel, 2003):

1. İleri Besleme (Feedforward)


2. Geri Yayılma (Backpropagate)

İleri besleme aşamasında, ağın dış dünyadan aldığı girdiler, çıkış katmanına kadar ileri doğru transfer edilirken (forward), geri yayılma aşamasında ise; ağın çıktısı($\hat{y}$) ile istenen çıktı (y) arasındaki fark (e_t), çıkış katmanından başlayarak geriye doğru giriş katmanına kadar transfer edilir (backward). Bu hata; ağın sinaptik ağırlıklarının değiştirilerek hatanın minimize edilmesi için kullanılır.

ÇKA ağları birçok uygulamada kullanılmış olan, en yaygın öğrenme algoritmasıdır ve özellikle iyi tanımlanamayan problemler ve doğrusal olmayan yapı gösteren ilişkilerin analizi için çok iyi bir seçimdir. Geri yayılmalı öğrenme kuralı ağ çıkışındaki mevcut hata düzeyine göre her bir katmandaki ağırlıkları yeniden hesaplamak için kullanılmaktadır. Bir ÇKA modelinde; giriş katmanı, gizli katman ve çıkış katmanı olmak üzere en az üç katman bulunmakla birlikte, problemin özelliklerine göre gizli katman sayısını artırabilmek mümkündür. Gizli katmanların sayısını sınırlandıran herhangi bir teorik limit yoktur fakat tipik olarak bir veya iki gizli katman birçok uygulama için yeterli olabilmektedir. Kimi çalışmalar ise geri yayılma ağında kullanılacak olan katman sayısının en az dört (3 gizli katman + çıkış katmanı) olması gerektiğini savunmaktadırlar (DACS,1992). Katman sayısının artması ağın hatırlama yeteneğini arttırırken, öğrenme süresini uzatır.

ÇKA ağları hiyerarşik yapıda ağlardır. Bir katmandaki sinirler sadece kendilerinden bir sonra gelen katmana veri gönderebilirler. Bir katmanın atlanarak diğer katmana veri gönderilmesi bu tip ağlarda mümkün değildir. Giriş katmanındaki her bir sinir, kendinden sonra gelen gizli katmandaki her bir sinire, eğer birden çok gizli katman bulunuyorsa bir gizli katmandaki her bir sinir kendinden sonra gelen gizli katmandaki her bir sinire, çıkış katmanından önce gelen gizli katmandaki her bir sinir ise çıkış katmanındaki her bir sinire bağlıdır. Bir katmandaki hiçbir sinir kendi

katmanındaki bir sinire bağılı olamaz. Her katmanın çıkış değeri bir sonra gelen katmanın giriş değeridir. Bu şekilde dış dünyadan alınan verinin, her katmanda aktive edilerek ağıın içinde hiyerarşik bir yapıda çıkış katmanına kadar iletilmesine ileri besleme (feedforward) denir.



Şekil 4.9: Örnek bir ÇKA ağı.

4.3.6.1 İleri besleme aşaması

Örnek bir ÇKA ağı Şekil 4.9' da gösterilmiştir. Şekilde, giriş katmanındaki her bir nöron, gizli katman 1 deki her bir nörona $w_{i,j}$ bağlantı ağırlıklarıyla bağlantılıdır. Ayrıca giriş katmanında bulunan hiçbir nöron, gizli katman 1'den bir sonraki gizli katmana (gizli katman 2'ye) veya çıkış katmanına bağlantı bulunmamaktadır (hiyerarşik yapı). Burada giriş katmanında bulunan nöronların çıktı değerleri, gizli katman 1'de bulunan sinirlerin girdi değerlerini oluşturmaktadır.

Bu ifadelerle göre; gizli katman 1'de bulunan $N_{1,1}$ nöronuna ulaşan ağırlıklandırılmış net girdi, (4.8)'de verilen ifadeye eşit olacaktır.

$$v_{1,1} = \sum_{i=1}^3 x_{i,t} w_{i,1} = x_{1,t} w_{1,1} + x_{2,t} w_{2,1} + x_{3,t} w_{3,1} \quad (4.8)$$

Yine gizli katman 1'de bulunan $N_{1,2}$ nöronuna gelen net girdi ise (4.9)'da gösterilmiştir.

$$v_{1,2} = \sum_{i=1}^3 x_{i,t} w_{i,2} = x_{1,t} w_{1,2} + x_{2,t} w_{2,2} + x_{3,t} w_{3,2} \quad (4.9)$$

Bu aşamadan sonra $N_{1,1}$ ve $N_{1,2}$ nöronları kendilerine gelen girdileri aktive edeceklerdir. Bu örnek için seçilen aktivasyon fonksiyonları (4.10)'da verilmiştir.

$$y_{i,j} = f(v_{i,j}) = \frac{1}{1+e^{-v_{i,j}}} \quad (4.10)$$

Bu açıklamaya göre, birinci katmanda bulunan $N_{1,1}$ ve $N_{1,2}$ nöronlarının çıktıları (4.11) ve (4.12)'de gösterilmektedir.

$$y_{1,1} = f(v_{1,1}) = \frac{1}{1+e^{-v_{1,1}}} \quad (4.11)$$

$$y_{1,2} = f(v_{1,2}) = \frac{1}{1+e^{-v_{1,2}}} \quad (4.12)$$

Birinci katmanda bulunan nöronlar, ($N_{1,1}$ ve $N_{1,2}$) ikinci katmanda bulunan nöronlara ($N_{2,1}$, $N_{2,2}$ ve $N_{2,3}$) $a_{i,j}$ sinaptik ağırlıkları ile bağlıdır. Bu durumda ikinci katmanda bulunan $N_{2,1}$, $N_{2,2}$ ve $N_{2,3}$ nöronlarının girdileri (4.13), (4.14), (4.15)'de gösterilmektedir.

$$v_{2,1} = \sum_{i=1}^2 y_{1,i} a_{i,1} = y_{1,1} a_{1,1} + y_{1,2} a_{2,1} \quad (4.13)$$

$$v_{2,2} = \sum_{i=1}^2 y_{1,i} a_{i,2} = y_{1,1} a_{1,2} + y_{1,2} a_{2,2} \quad (4.14)$$

$$v_{2,3} = \sum_{i=1}^2 y_{1,i} a_{i,3} = y_{1,1} a_{1,3} + y_{1,2} a_{2,3} \quad (4.15)$$

Gizli katman 2'de bulunan nöronlar da kendi üzerlerine gelen net girdileri aktive edecek ve kendi çıktıları olan $y_{2,1}$, $y_{2,2}$ ve $y_{2,3}$ 'ü oluşturacaklardır. Her bir nöronun aktivasyon fonksiyonu aynı olmak zorunda değildir ve hangi nöronda hangi aktivasyon fonksiyonunun kullanılacağı uygulayıcının kendi seçimidir. Aktivasyon fonksiyonları nöron bazlı olarak seçilebileceği gibi, katman bazlı da seçilebilir (örneğin 1. katmanda sigmoid, 2.katmanda hiperbolik tanjant, çıktı katmanında doğrusal gibi). Bununla birlikte çoğu uygulamada her katmandaki (dolayısıyla tüm ağdaki) nöronların aktivasyon fonksiyonu aynı olarak seçilmektedir. Gizli katman 2 için seçilen aktivasyon fonksiyonu (4.16)'da verilmiştir.

$$y_{i,j} = f(v_{i,j}) = \frac{1}{1+v_{i,j}} \quad (4.16)$$

Buna göre gizli katman 2'de bulunan nöronların çıktıları ise aşağıda verildiği gibidir.

$$y_{2,1} = f(v_{2,1}) = \frac{1}{1+v_{2,1}} \quad (4.17)$$

$$y_{2,2} = f(v_{2,2}) = \frac{1}{1+v_{2,2}} \quad (4.18)$$

$$y_{2,3} = f(v_{2,3}) = \frac{1}{1+v_{2,3}} \quad (4.19)$$

Gizli katman 2’de bulunan; $N_{2,1}$, $N_{2,2}$ ve $N_{2,3}$ nöronları ise, $b_{i,j}$ sinaptik ağırlıkları ile çıkış katmanına bağlıdır. Dolayısıyla gizli katman 2’nin çıktı değerleri olan; $y_{2,1}$, $y_{2,2}$ ve $y_{2,3}$ çıkış katmanının girdilerini oluşturacaktır. Bu açıklama çerçevesinde çıkış katmanına gelen ağırlıklandırılmış net girdi, (4.20)’de gösterilmektedir.

$$v_{3,1} = \sum_{i=1}^2 y_{2,i} b_{i,1} = y_{2,1} b_{1,1} + y_{2,2} b_{2,1} + y_{2,3} b_{3,1} \quad (4.20)$$

Son bir işlem olarak, çıkış katmanı, üzerine gelen ağırlıklandırılmış net girdiyi aktive edecek ve nihai sonucu (ağın tahmin değeri) dış dünyaya gönderecektir. Çıkış katmanı için seçilen fonksiyonun, (4.21)’de gösterilen fonksiyon olduğu düşünülürse;

$$\hat{y}_t = f(v_{3,1}) = \frac{e^{v_{3,1}} - e^{-v_{3,1}}}{e^{v_{3,1}} + e^{-v_{3,1}}} \quad (4.21)$$

Şekil 4.9’da gösterilen örnek yapay sinir ağının nihai çıktısı; $\hat{y}_t$ olacaktır.

4.3.6.2 Geri yayılma aşaması


ÇKA ağında hatalar, aktivasyon fonksiyonun türevi tarafından, ileri besleme için yapılan bağlantılar üzerinden çıkış tabakasından giriş tabakasına doğru yayılmaktadır. ÇKA ağında hatayı geriye yayma işleminin kullanılabilmesi için, kullanılan aktivasyon fonksiyonunun türevlenebilir olması gerek ve yeter şarttır. ÇKA ağırları genelde öğrenme kuralı olarak genelleştirilmiş delta öğrenme kuralını kullanırlar.

Öğrenme esnasında bağımsız değişkenler $(x_{1,t}, x_{2,t}, x_{3,t} \dots x_{n,t})$ ağa sırasıyla sunulur. Ağ, giriş tabakasından aldığı verileri gizli tabakaya iletir. Başlangıçta rastgele olarak atanan bağlantı ağırlıklarıyla çarpıp, ağırlıklandırılmış net girdiler, gizli tabakada aktivasyon fonksiyonuyla aktive edilirler ($f(v_{i,j})$). Daha sonra gizli tabaka da çıkış değeri olan $y_{i,j}$ ’yi eğer önünde gizli tabaka varsa ona, yoksa çıkış tabakasına gönderir. Çıkış tabakası da $y_{i,j}$ ’yi gizli tabaka ve çıktı tabakası arasındaki bağlantı ağırlıklarıyla çarpıp toplayarak (ağırlıklandırılmış net girdiyi bularak) nihai çıktı olan $\hat{y}_t$ ’yi üretir. Bağımsız değişkenlerden oluşan veri, ağ içinde ileri yönde hareket etmektedir.

Hesaplanan çıktı ($\hat{y}_t$) olması gereken çıktıyla (y_t) karşılaştırılarak hata terimi (E_t) bulunur. Hata teriminin matematiksel ifadesi (4.22)’de verilmektedir.

$$\epsilon_t = (y_t - \hat{y}_t) \quad (4.22)$$

Bulunan hata terimi, katmanlar arası bağlantı ağırlıklarının ayarlamasında kullanılmak üzere, çıkış katmanından bir önce gelen gizli tabakaya (geri besleme bağlantıları aracılığıyla) iletilir. Burada ifade edilen geri besleme bağlantıları aslında katmanlar arası sinaptik bağlantılarla aynı bağlantılardır. Bu bağlantılar; veriyi iletmek için kullanıldığında katmanlar arası bağlantı, hatayı geri iletmek aracılığıyla kullanıldığında, geri besleme bağlantısı (feedforward connection) olarak adlandırılırlar.



Şekil 4.10: Geri besleme bağlantıları ve hatanın geri yayılması.

Şekil 4.10'da çıkış tabakası hatayı, gizli katman 2'ye ($N_{2,1}$, $N_{2,2}$ ve $N_{2,3}$ nöronlarına), gizli katman 2 ise gizli katman 1'e ($N_{1,1}$, $N_{1,2}$ nöronlarına) ve son olarak gizli katman 1'de girdi tabakasına iletmektedir. Şekil 4.9 ve Şekil 4.10 karşılaştırılırsa, veriyi ileriye ileten bağlantılarla (katmanlar arası bağlantı), hatayı geri ileten bağlantıların (geri besleme bağlantıları) aslında aynı bağlantılar olduğu ifade edilebilir. Burada sadece hatanın ve verinin gidiş yönleri değişmektedir.

Şekil 4.10'da gösterilen geri yayılma ağında, çıkış katmanındaki hata kullanılarak gizli katman 2'in bağlantı ağırlıkları, gizli katman 2'deki hata kullanılarak, gizli katman 1'in bağlantı ağırlıkları, gizli katman 1 'deki hatalar kullanılarak ise giriş katmanının bağlantı ağırlıklarında ayarlama yapılacaktır.

İlk ayarlardan sonra, açıklayıcı değişkenleri($x_{1,t+1}, x_{2,t+1}, x_{3,t+1} \dots x_{n,t+1}$) ağa girdi olarak sunulacak ve ağ kendi çıktısı olan $\widehat{y_{t+1}}$ ile gerçek değer y_t 'i karşılaştırarak, bağlantı ağırlıklarını bir kez daha güncelleyecektir. Daha sonra ($x_{1,t+2}, x_{2,t+2}, x_{3,t+2} \dots x_{n,t+2}$) açıklayıcı değişkenleri ağa verilecek ve bu döngü ‘toplam ağ hatası’ en aza indirilene kadar devam edecektir.

Eğitim için kullanılan veri setinde 5 adet örnek ($n=5$) bulunduğu düşünölsün. Bu durumda ilk olarak ($x_{1,1}, x_{2,1}, x_{3,1}$), ($x_{1,2}, x_{2,2}, x_{3,2}$), ($x_{1,3}, x_{2,3}, x_{3,3}$), ($x_{1,4}, x_{2,4}, x_{3,4}$), ($x_{1,5}, x_{2,5}, x_{3,5}$) bağımsız değişken üçlülerinin sırasıyla ağa sunulacağı ifade edilmiştir. Ağ, her bağımsız ve bağımlı değişken ikililerinin sunulmasından sonra bağlantı ağırlıklarını güncelleyecektir. Son veri de işlendiğinde başa dönülecek ve ($x_{1,1}, x_{2,1}, x_{3,1}$) verisi tekrar ağa sunulacaktır. Daha sonra ise sırayla diğer veriler de (($x_{1,2}, x_{2,2}, x_{3,2}$), ($x_{1,3}, x_{2,3}, x_{3,3}$), ($x_{1,4}, x_{2,4}, x_{3,4}$), ($x_{1,5}, x_{2,5}, x_{3,5}$)) eğitimin devamı için ağa girdi olarak verilecek ve tekrar başa dönülecektir. Bu olayların her birine “Döngü” (epoch) denilmektedir. Ağ, her bir döngü boyunca birçok kez bağlantı ağırlıklarını ayarlayacak ve toplam ağ hatasını minimize etmeye çalışacaktır. Ağın sinaptik ağırlıklarının başlangıç değerleri genellikle (-1,1) aralığında seçilen rassal değişkenler olup, döngüler ilerledikçe ağırlık parametrelerinin en uygun düzeye doğru yakınsamasına çalışılacaktır.

Çizelge 4.5: Geri yayılma ile hatanın minimizasyonu ve döngü kavramı.

t=iterasyon	Epoch (Döngü)	Bağımsız Değişkenler	Bağımlı Değişken	Hata	Sinaptik Ağırlık Değişimi
1	0	$x_{1,1}, x_{2,1}, x_{3,1}$	y_1	ϵ_1	Evet
2	0	$x_{1,2}, x_{2,2}, x_{3,2}$	y_2	ϵ_2	Evet
3	0	$x_{1,3}, x_{2,3}, x_{3,3}$	y_3	ϵ_3	Evet
4	0	$x_{1,4}, x_{2,4}, x_{3,4}$	y_4	ϵ_4	Evet
5	0	$x_{1,5}, x_{2,5}, x_{3,5}$	y_5	ϵ_5	Evet
1	1	$x_{1,1}, x_{2,1}, x_{3,1}$	y_1	ϵ_6	Evet
2	1	$x_{1,2}, x_{2,2}, x_{3,2}$	y_2	ϵ_7	Evet
3	1	$x_{1,3}, x_{2,3}, x_{3,3}$	y_3	ϵ_8	Evet
4	1	$x_{1,4}, x_{2,4}, x_{3,4}$	y_4	ϵ_9	Evet

Çizelge 4.5 (devam): Geri yayılma ile hatanın minimizasyonu ve döngü kavramı.

5	1	$x_{1,5}, x_{2,5}, x_{3,5}$	y_5	ϵ_{10}	Evet
1	2	$x_{1,1}, x_{2,1}, x_{3,1}$	y_1	ϵ_{11}	Evet
2	2	$x_{1,2}, x_{2,2}, x_{3,2}$	y_2	ϵ_{12}	Evet
3	2	$x_{1,3}, x_{2,3}, x_{3,3}$	y_3	ϵ_{13}	Evet
4	2	$x_{1,4}, x_{2,4}, x_{3,4}$	y_4	ϵ_{14}	Evet
5	2	$x_{1,5}, x_{2,5}, x_{3,5}$	y_5	ϵ_{15}	Evet
t	n	$x_{1,t}, x_{2,t}, x_{3,t}$	y_t	ϵ_t	Evet

Geri yayılma mantığına göre, yapay sinir ağı her döngüden (epoch) sonra toplam ağ hatasını biraz daha azaltacaktır buna göre;

$$\sum_{t=1}^t \epsilon_{n,t}^2 < \sum_{t=1}^t \epsilon_{n-1,t}^2 < \sum_{t=1}^t \epsilon_{n-2,t}^2 \dots < \sum_{t=1}^t \epsilon_{n-n,t}^2 \quad (4.23)$$

ÇKA ağının toplam hatayı minimize etme ilkesi, (4.23)'de matematiksel olarak ifade edilmiştir. Bu ifadeye göre; ÇKA ağlarında her bir döngüden sonraki toplam ağ hatasının, bir önceki döngüdeki toplam hataya göre daha küçük olması beklenmektedir. Bu durumda toplam hata minimize edilene kadar veya kabul edilebilir bir sınıra gelene kadar döngü çalıştırılacaktır.

4.3.6.3 ÇKA ağının genelleştirilmiş delta öğrenme kuralı ile eğitimi

Çalışmanın bu bölümünde; ÇKA ağlarında, genelleştirilmiş delta öğrenme kuralı kullanılarak, ağın toplam hatasının her bir döngüde nasıl azaltılabileceği teorik olarak anlatılmaya çalışılacaktır.

Şekil 4.11' de yapılacak analiz için kullanılacak olan örnek yapay sinir ağı modeli gösterilmektedir. Kullanılacak olan ağ, 2 gizli katman içeren ve 3 - 2 - 3 - 1 düzeninde seçilen bir ÇKA ağıdır.

Ağ mimarisinde kullanılacak değişken ve tanımları şu şekildedir:


$X_{1,t}$: Birinci bağımsız değişken (t:zaman)

$X_{2,t}$: İkinci bağımsız değişken (t:zaman)

$X_{3,t}$: Üçüncü bağımsız değişken (t:zaman)

y_t : Bağımlı değişken (t:zaman)

$\hat{y}_t$: 3 - 2 - 3 - 1 düzenindeki ÇKA ağının bağımlı değişken tahmin değeri



Şekil 4.11: Genelleştirilmiş delta öğrenme kuralının uygulanacağı ÇKA.

Bu tanımlamalardan sonra, örnek yapay sinir ağı için kullanılacak olan değişkenler arasında (4.24)'de ifade edilen bir ilişkinin olduğu varsayılacaktır.

$$y_t = f(X_{1,t}, X_{2,t}, X_{3,t}) \quad (4.24)$$

$\epsilon_t = y_t - \hat{y}_t$: Ağın t anındaki hatası

ϵ_{top} : Tüm eğitim çiftleri bittikten sonra (1 epoch sonra) toplam ağ hatası

$N_{i,j}$: i. katmandaki j. nöron

$w_{i,j}, a_{i,j}, b_{i,j}$: i. nöronun j. sinaptik ağırlık (bağlantı ağırlığı) değeri

$v_{i,j}$: i. katmandaki j. nörona gelen ağırlıklandırılmış net girdi

$y_{i,j}$: i. katmandaki j. nöronun çıkış değeri ($y_{i,j} = f(v_{i,j})$)

1 döngü (epoch) sonraki toplam ağ hatası olarak tanımlanan (ϵ_{top}) ifadesinin açılımı (4.25)'de verilmektedir.

$$\epsilon_{top} = \frac{1}{2} \sum_{i=1}^t (y_t - \hat{y}_t)^2 \quad (4.25)$$

(4.25)'de verilen toplam ağ hata fonksiyonunun değeri, bir döngü (epoch) içindeki hata kareler toplamının yarısına eşit olmaktadır. Bir döngü ile kastedilen ifade, tüm açıklayıcı değişkenlerin sırasıyla ağa veri olarak sunulduğu (bu sırada ağ parametreleri yani bağlantı ağırlıkları sürekli olarak güncellenmekte ve ağ eğitilmektedir) ve tekrar başa dönme sırasının geldiği noktadır.

Katmanlar arası bağlantı ağırlıkları, bir iterasyon sonunda her katmanın çıkış hatası, bir öncekinden düşük bir değer alacak şekilde güncellenecektir. Dolayısıyla $\mathcal{E}_{top}$ ifadesi de bir önceki döngüde aldığı değerden daha düşük bir değer olacaktır. Bu minimizasyon işlemi herhangi bir iterasyondaki ağ hatasının ($\mathcal{E}_t$) ağ sinaptik ağırlıklarına göre kısmi türevinin negatif bir oranına göre, ağırlıkları değiştirerek sağlanabilecektir. Bu şekilde izlenecek ağırlık güncelleme kuralına genelleştirilmiş delta öğrenme kuralı denilmektedir.

Genelleştirilmiş delta öğrenme kuralına göre katmanlar arası bağlantı ağırlıkları güncellenirken, bağlantı ağırlıkları ayarlanacak olan katmanın çıkış katmanı veya gizli katman olması durumuna göre ayarlama işlemi değişikliğe uğramaktadır.

Çıkış Katmanının Bağlantı Ağırlıklarının Ayarlanması

Bu bölümde; Şekil 4.11’de gösterilen örnek yapay sinir ağının çıkış katmanındaki bağlantı ağırlıklarının ($b_{i,j}$) nasıl ayarlanması gerektiği açıklanacaktır. Çıkış katmanı ile gizli katman 2 arasındaki bağlantıların ağırlıkları, çıkış katmanının bağlantı ağırlıkları olarak kabul edilmektedir.

Genelleştirilmiş delta kuralına göre çıkış katmanındaki $b_{i,j}$ bağlantı ağırlıklarının ayarlanması için gerekli kısmi türev (4.26)’da verilmektedir.

$$\frac{\partial \mathcal{E}_{top}}{\partial b_{i,1}} \quad i=1 \dots 3 \quad (4.26)$$

Örnek YSA’nın çıkış katmanında 1 adet nöron bulunmaktadır. Bu yüzden $b_{i,j}$ bağlantı ağırlıkları için, katmandaki hangi nöron ile ilgili işlem yapıldığını gösteren j indisi kaldırılmış ve bunun yerine; ‘1’ indisi kullanılmıştır. Toplam hata fonksiyonu ($\mathcal{E}_{top}$), ($b_{i,1}$) sinaptik ağırlıklarının bir fonksiyonu olmadığından (4.26) türevi direkt olarak alınamamaktadır.

(4.26)’da verilen ifade ağın toplam hata fonksiyonundaki değişimin, çıkış katmanındaki bağlantı ağırlıklarına göre türevi şeklinde ifade edilebilir. Bu ifade, çıkış katmanındaki bağlantı ağırlıklarını (hata fonksiyonunu minimize edebilecek şekilde) ne kadar değiştirmemiz gerektiğine dair en önemli parametredir. (4.26)’da ifade edilen türevin bulunabilmesi için matematikte “zincir kuralı” olarak bilinen bir dönüşümden yararlanılacaktır. Bu dönüşüm (4.27)’de gösterilmiştir.

$$\frac{\partial \varepsilon_{top}}{\partial b_{i,1}} = \frac{\partial \varepsilon_{top}}{\partial \hat{y}_t} \frac{\partial \hat{y}_t}{\partial b_{i,1}} \quad i=1 \dots 3 \quad (4.27)$$

(4.27)'de verilen ifade genişletilirse

$$\frac{\partial \varepsilon_{top}}{\partial b_{i,1}} = \frac{\partial \varepsilon_{top}}{\partial \hat{y}_t} \frac{\partial \hat{y}_t}{\partial b_{i,1}} = \frac{\partial \varepsilon_{top}}{\partial \hat{y}_t} \left(\frac{\partial}{\partial b_{i,1}} \sum_{i=1}^3 b_{i,1} y_{2,i} \right) \quad (4.28)$$

$$v_{3,1} = \sum_{i=1}^3 b_{i,1} y_{2,i} \quad (4.29)$$

(4.28)'e ulaşılabacaktır. (4.28)'de parantez içinde ifade edilen diferansiyel, çıktı katmanında bulunan nörona gelen ağırlıklandırılmış net girdideki değişimin, gizli katman 2 ile çıkış katmanı arasındaki bağlantı ağırlıklarındaki değişmeye göre türevidir. Bu türev ise;

$$\left(\frac{\partial}{\partial b_{i,1}} \sum_{i=1}^3 b_{i,1} y_{2,i} \right) = y_{2,i} \quad (4.30)$$

(4.30)'da ifade edildiği gibi $y_{2,i}$ 'ye eşit olacaktır. (4.28)'de verilen diferansiyelin parantez içindeki kısmı hesaplandığına göre bu aşamadan sonra geriye kalan ifade (4.31)'deki diferansiyeldir.

$$\frac{\partial \varepsilon_{top}}{\partial \hat{y}_t} \quad (4.31)$$

Bu türevin alınabilmesi için $\hat{y}_t$ 'nin hangi değere eşit olduğu bilinmelidir. $\hat{y}_t$ 'nin matematiksel eşitliği (4.32)'de verilmektedir.

$$\hat{y}_t = f(v_{3,1}) \quad (4.32)$$

YSA' nın nihai çıktısı olan $\hat{y}_t$, çıkış katmanındaki nörona gelen ağırlıklandırılmış net girdinin $(v_{3,1})$ aktivasyon fonksiyonundan $f(v_{i,j})$ geçirilmesiyle elde edilmektedir. Bu durumda (4.32) ifadesi, (4.33)'deki gibi yeniden düzenlenerek yazılabilir.

$$\frac{\partial \varepsilon_{top}}{\partial \hat{y}_t} = \frac{\partial \varepsilon_{top}}{\partial f(v_{3,1})} \quad (4.33)$$

Son olarak ulaşılan diferansiyel de direkt olarak hesaplanamayacağından (toplam hata fonksiyonu, aktivasyon fonksiyonu ile ilgili bir parametre içermediğinden) zincir kuralı yardımıyla (4.34)'e ulaşılır.

$$\frac{\partial \varepsilon_{top}}{\partial f(v_{3,1})} = \frac{\partial \varepsilon_{top}}{\partial \hat{y}_t} \frac{\partial \hat{y}_t}{\partial f(v_{3,1})} \quad (4.34)$$

Bu noktadan sonra gerekli türevler hesaplanabilir duruma gelmiştir. $\frac{\partial \varepsilon_{top}}{\partial \hat{y}_t}$ ifadesi, ağın toplam hatasındaki değişimin, ağ çıktısındaki değişmeye göre türevi olduğundan; bu ifadenin türevi,

$$\frac{\partial \varepsilon_{top}}{\partial \hat{y}_t} = (y_t - \hat{y}_t) = \varepsilon_t \quad (4.35)$$

$\frac{\partial \hat{y}_t}{\partial f(v_{3,1})}$ diferansiyeli ise ağın nihai çıktısının, kullanılan aktivasyon fonksiyonuna göre türevi olduğundan bu ifadenin türevi,

$$\frac{\partial \hat{y}_t}{\partial f(v_{3,1})} = f'(v_{3,1}) \quad (4.36)$$

(4.36) ifadesine eşit olacaktır. (3.46)'da gösterilen $f'(v_{3,1})$ ifadesi, ağın çıktı katmanında kullanılan aktivasyon fonksiyonun türevidir. Daha önceden de değinildiği gibi, ağın her nöronunda ya da her katmanında farklı aktivasyon fonksiyonları kullanılabilir. Burada her bir bağlantı ağırlığı değişiminde, ilgili aktivasyon fonksiyonun türevine ulaşmak gerekmektedir. Bu açıklamalardan sonra, kullanılan aktivasyon fonksiyonunun niçin türevlenebilir olması gerektiği de açığa kavuşmaktadır. Bağlantı ağırlıklarının değiştirilebilmesi için, ilgili aktivasyon fonksiyonun türevine ihtiyaç duyulmaktadır. Aktivasyon fonksiyonu olarak süresiz bir fonksiyon seçildiğinde, bu türev hesaplanamayacağından genelleştirilmiş delta öğrenme kuralı kullanılamaz.

(4.30), (4.35) ve (4.36) ifadeleri birleştirilerek başlangıçta hesaplanması gereken diferansiyelin değerine ulaşılabacaktır. Bu ifade, (4.37)'de gösterilmektedir.

$$\frac{\partial \varepsilon_{top}}{\partial b_{i,1}} = y_{2,i} \varepsilon_t f'(v_{3,1}) \quad i=1 \dots 3 \quad (4.37)$$

(4.37)' de yer verilen ifadenin $\varepsilon_t f'(v_{3,1})$ kısmına, genelleştirilmiş delta eğitim kuralı yazınında δ (delta) hatası denilmektedir. Bu dönüşüme göre (4.37) ifadesinden aşağıdaki ifadeye ulaşılmaktadır.

$$\frac{\partial \varepsilon_{top}}{\partial b_{i,1}} = \delta y_{2,i} \quad i=1 \dots 3 \quad (4.38)$$

$b_{i,1}$ bağlantı ağırlıklarının hatayı minimize etmek üzere değiştirilmesi için gereken diferansiyel bulunduğuna göre, bu aşamadan itibaren değişim kuralının ne olacağına değinilebilir. Bu kural (4.39)'da gösterilmektedir.

$$\Delta b_{i,1} = \eta \frac{\partial \varepsilon_{top}}{\partial b_{i,1}} = \eta \delta y_{2,i} \quad i=1 \dots 3 \quad (4.39)$$

Denklemdaki δ (delta) ifadesi, $b_{i,1}$ yani $b_{1,1}$, $b_{2,1}$ ve $b_{3,1}$ bağlantı ağırlıklarının kaç birim değiştirilmesi gerektiğini ifade etmektedir.

(4.39)'de gösterilen η ifadesi ise; yapay sinir ağırları yazınında öğrenme oranı veya katsayısı olarak bilinen bir sabittir. Bu ifade ilgili bağlantı ağırlığının, δ hatasının kaç katıyla değiştirileceğini göstermektedir. Öğrenme oranı uygulamada $0 < \eta < 1$ olarak seçilmektedir. Katsayının pozitif olması sistemin tutarlılığını sağlarken, 1 den küçük olması ise sistemin yakınsamasını sağlamaktadır (Elmas, 2003). Öğrenme katsayısının çok büyük olarak seçilmesi (0,80 veya 0,90 gibi) ağırların yerel çözümler arasında salınmasına ve en iyi çözüme yakınsayamamasına neden olurken, çok küçük olarak seçilmesi ise (0,01 veya 0,05 gibi) ağırların ilişkileri öğrenebilmesi için gereken döngü sayısının dolayısıyla zamanın artmasına neden olmaktadır (Öztemel, 2003). Fakat zamanın artmasının öğrenme üzerinde hiçbir olumsuz etkisi olmadığı gibi, öğrenme oranının küçük olarak seçilmesi öğrenmenin çok daha hassas bir şekilde gerçekleşmesini sağlayacaktır. Öğrenme oranının doğru bir şekilde seçilmesi, yapay sinir ağırları yöntem biliminde önemli bir yer tutmaktadır. Öğrenme oranı, ağırların ilişkileri ortaya çıkarabilme derecesi üzerinde direkt bir etkisi bulunmaktadır. Genel bir kural olarak, modellenmesi gereken zaman serileri arasındaki ilişki karmaşıklıkça, öğrenme oranının azaltılması yani küçük seçilmesi daha yerinde olacaktır.

Bu açıklamalardan sonra çıkış katmanındaki $N_{3,1}$ nöronunun yeni bağlantı ağırlıklarının değeri (4.40)'da verilmiştir.

$$b_{i,1}^{yeni} = b_{i,1}^{eski} + \Delta b_{i,1} \quad i=1 \dots 3 \quad (4.40)$$

Gizli Katman 2'nin Bağlantı Ağırlıklarının Ayarlanması

Bu bölümde gizli katman 2'in bağlantı ağırlıklarının nasıl ayarlanacağı ele alınacaktır. (Gizli katman 2 ile gizli katman 1 arasındaki bağlantıların ağırlıkları, gizli katman 2'nin bağlantı ağırlıkları olmaktadır.)

Gizli katmanların çıkış değerleri ($y_{i,j}$) için y_t gibi hedeflenen bir çıktı değeri olmadığından, gizli katman için herhangi bir hata da söz konusu değildir. Dolayısıyla gizli katmanların bağlantı ağırlıklarının ayarlanması için ağ toplam hata fonksiyonundan yararlanılacaktır.

Gizli katman 2'nin yeni bağlantı değerlerinin ($a_{i,j}$) hesaplanabilmesi için gereken diferansiyel (4.41)'de verilmektedir.

$$\frac{\partial \varepsilon_{top}}{\partial a_{i,j}} \quad i=1 \dots 2 ; j=1 \dots 3 \quad (4.41)$$

$a_{i,j}$ ağırlıklarının yeni değerlerinin hesaplanması için gereken diferansiyel; ağın toplam hata fonksiyonundaki değişimin, gizli katman 2'nin bağlantı ağırlıklarındaki değişmeye göre kısmi türevi olacaktır. Bu kısmi türev de, çıkış katmanındaki bağlantı ağırlıkların değiştirilmesi için kullanılan yöntemle hesaplanırsa, (4.42) ifadesine ulaşılır.

$$\frac{\partial \varepsilon_{top}}{\partial a_{i,j}} = f'(v_{2,j}) b_{j,1} \delta_{çıkış} \quad i=1 \dots 2 ; j=1 \dots 3 \quad (4.42)$$

(4.42)'de verilen $\delta_{çıkış}$ ifadesi, daha önce çıkış tabakası için hesapladığımız δ hatasıdır. Bu parametre, gizli katman 2 'deki nöronların bağlantı ağırlıklarını ayarlayabilmek için de gerekmektedir. Son olarak ulaşılan ifadelere; 2. Katmanı belirtmek için '2', katmandaki nöronu belirtmek için 'j', değişecek bağlantı ağırlığını belirlemek için ise 'k' indisini kullanarak;

$$\delta_{2,j} = f'(v_{2,j}) b_{j,1} \delta_{çıkış} \quad j=1 \dots 3 \quad (4.43)$$

$$\Delta_{2,j,k} = \eta y_{1,k} \delta_{2,j} \quad j=1 \dots 3 ; k=1 \dots 2 \quad (4.44)$$

önce (4.43)'e, daha sonra da gizli katman 2'deki nöronların bağlantı ağırlıklarının değişim kuralı olan (4.44)'e ulaşılır.

Buna göre gizli katman 2'nin bağlantı ağırlıklarının yeni değerleri (4.45)'deki gibi hesaplanır.

$$a_{j,k}^{yeni} = a_{j,k}^{eski} + \Delta_{2,j,k} \quad j=1 \dots 3 ; k=1 \dots 2 \quad (4.45)$$

Gizli Katman 1'in Bağlantı Ağırlıklarının Ayarlanması

Kısmi türev yöntemi burada da geçerli olacak ve gizli katman 1' in bağlantılarının ayarlanabilmesi için gereken kısmi türev ağırlık toplam hata fonksiyonundaki değişimin, gizli katman 1'in sinaptik ağırlıklarındaki değişmeye göre kısmi türevi olacaktır. Bu ifadenin matematiksel gösterimi ise (4.46)'da yapılmıştır.

$$\frac{\partial \varepsilon_{top}}{\partial w_{i,j}} \quad (4.46)$$

(4.46)'da verilen diferansiyel, zincir kuralı arkaya arkaya kullanılarak hesaplandığında (4.47) ifadesine ulaşılmıştır.

$$\frac{\partial \varepsilon_{top}}{\partial w_{i,j}} = f'(v_{1,j}) \sum_{m=1}^2 \sum_{j=1}^3 a_{m,j} \delta_{2,j} \quad j=1 \dots 3 ; k=1 \dots 2 \quad (4.47)$$

(4.47)'de verilen $\delta_{2,j}$ ifadesi, daha önce gizli katman 2'de bulunan her bir nöron için hesaplanan δ parametreleridir ve gizli katman 1'deki nöronların bağlantı ağırlıklarını değiştirilebilmek için de gerekmektedir. Son olarak ulaşılan ifadelere; 1. katmanı belirtmek için '1', ilgili katmandaki kaçınıcı nöron olduğunu belirtmek için 'r', değişecek bağlantı ağırlığı belirlemek için ise 'p' indisini kullanarak;

$$\delta_{1,r} = f'(v_{1,j}) \sum_{m=1}^2 \sum_{j=1}^3 a_{m,j} \delta_{2,j} \quad j=1 \dots 3; m=1 \dots 2; r=1 \dots 2 \quad (4.48)$$

$$\Delta_{1,r,p} = \eta x_{p,t} \delta_{1,r} \quad r=1 \dots 2; p=1 \dots 3; t=\text{zaman} \quad (4.49)$$

önce (4.48)'e daha sonra da gizli katman 1'de bulunan nöronların bağlantı ağırlıklarının değişim kuralı olan (4.49)'a ulaşılacaktır.

Gizli katman 1'in bağlantı ağırlıklarının yeni değerleri ise (4.50)'de gösterilmiştir.

$$w_{r,p}^{yeni} = w_{r,p}^{eski} + \Delta_{1,r,p} \quad r=1 \dots 2; p=1 \dots 3 \quad (4.50)$$

4.3.6.4 Öğrenmenin devamı ve toplam hata fonksiyonu

Önceki bölümde 1 iterasyon sonucunda, ağırlık bağlantı ağırlıklarının nasıl güncelleneceği açıklanmıştı. İterasyon, eğitim verisindeki bağımlı ve bağımsız veri çiftleri bitene kadar devam ettirilecek ve son veri çifti ağırlık veriliş ağırlıklar tekrar güncellendiğinde, bir döngü (epoch) de sona ermiş olacaktır. Bir döngü bittikten sonra tekrar en başa dönülecek, eğitim verileri en baştan başlayarak tekrar ağırlık verilmeye devam edilecek ve bağlantı ağırlıkları sürekli güncellenmeye devam

edilecektir. Bu şekilde her bir döngüden sonra, ağın toplam hata fonksiyonunun değeri, bir önceki döngüye göre daha düşük olacak ve fonksiyonun değeri minimize edilene kadar döngüler ve güncellemeler sürekli devam edecektir.

Eğitim için kullanılan veri setinde (bağımsız değişkenler ve bağımlı değişken) n adet örnek olduğu varsayalım. Her bir veri sırasıyla ağa girdi olarak verilecek ve ağın bağlantı ağırlıkları ayarlanacak, iterasyon sayısı örneklem hacmine eşitlendiğinde bir döngü tamamlanmış olacak ve başa dönülerek yeni bir döngü başlatılacaktır.

$$\sum_{i=1}^n \text{Güncelleme} = 1 \text{ Döngü} \quad n=\text{örnek hacmi}; i=\text{iterasyon} \quad (4.51)$$

ve her bir döngüden sonra;

$$\varepsilon_{top,n} < \varepsilon_{top,n-1} < \varepsilon_{top,n-2} < \dots < \varepsilon_{top,0} \quad n=\text{döngü sayısı} \quad (4.52)$$

olacaktır. Bu süreç (4.53)'de verilen duruma gelinceye kadar devam ettirilecek ve bu noktadan itibaren ağ bağlantı ağırlıkları sabitlenecektir.

$$\mathbf{z}: \varepsilon_{top,n} = \min(\varepsilon_{top}) \quad n=\text{döngü sayısı} \quad (4.53)$$

4.3.6.5 ÇKA ağlarında öğrenme performansının artırılması

Bu bölümde, ÇKA'larda öğrenme performansı ve yakınsama süresinin nasıl azaltılabileceği anlatılacaktır. Bu performans düzeltilmesi için izlenebilecek yollar;

- Dinamik Öğrenme Hızı Ayarlaması
- Momentum Terimi ve Öğrenme Performansına Etkisi

şeklindedir.

Dinamik Öğrenme Hızı Ayarlaması

Genelleştirilmiş delta öğrenme kuralına göre, ağ bağlantı ağırlıklarının değerleri güncellenirken, ağın toplam hata fonksiyonu olan ε_{top} 'un, her bir katmandaki ağırlık matrislerine göre $(w_{i,j}, a_{i,j}, b_{i,j})$ kısmi türevlerinden yararlanılmaktadır. Bu durum beraberinde şu sorunu getirmektedir. Bağlantı ağırlıkları, en uygun ağırlıklardan çok uzak bir noktada bulunuyorsa ve ağ parametrelerine (bağlantı ağırlıklarına) göre alınan kısmi türevler çok küçük bir genlikte ise (değişimleri çok düşük miktarlarda ise), yapay sinir ağının öğrenme süresi (döngü sayısı) çok uzun bir zaman almaktadır (Efe ve Kaynak, 2000). Bu problem, özellikle öğrenme hızının (η) düşük bir değer seçildiği durumlarda ortaya çıkmaktadır.

Bu sorunun çözümü için kullanılan yaklaşımlardan biri dinamik öğrenme hızı ayarlamasıdır. (4.54)'de ağı toplam hata fonksiyonunun değeri verilmektedir.

$$\varepsilon_{top} = \frac{1}{2} \sum_{i=1}^t (y_t - \hat{y}_t)^2 \quad t=\text{zaman} \quad (4.54)$$

(4.54)'de verilen toplam hata fonksiyonundan hareketle (4.55) ve (4.56) ifadeleri yazılmıştır.

$$\varepsilon_{top,n} = \frac{1}{2} \sum_{i=1}^t (y_t - \hat{y}_t)^2 \quad n=\text{döngü sayısı}; t=\text{zaman} \quad (4.55)$$

$$\varepsilon_{top,n+1} = \frac{1}{2} \sum_{i=1}^t (y_t - \hat{y}_t)^2 \quad n=\text{döngü sayısı}; t=\text{zaman} \quad (4.56)$$

(4.55)'de n. döngü sonrasında, (4.56)'da ise (n+1). döngü sonrasında ağ toplam hata fonksiyonun aldığı değere yer verilmiştir. Hata fonksiyonun (n+1). döngüde aldığı değer ile n. döngüde aldığı değer arasındaki farkı ifade eden $\Delta\varepsilon_{top}$ ifadesi (4.57)'de gösterilmiştir.

$$\Delta\varepsilon_{top} = \varepsilon_{top,n+1} - \varepsilon_{top,n} \quad n=\text{döngü sayısı} \quad (4.57)$$

Dinamik öğrenme hızı ayarlaması; (4.57)'de yer verilen ifadenin pozitif veya negatif değerler alması durumunda, öğrenme oranının (η) her bir döngüden sonra uygun şekilde güncellenmesi şeklinde açıklanabilir.

$\Delta\varepsilon_{top}$ ifadesinin negatif değer alması şu şekilde yorumlanabilir. (n+1). döngüde toplam hata fonksiyonun aldığı değer, n. döngüde aldığı değerden daha düşüktür ve fonksiyonun minimizasyonu için girilen yol doğrudur. Öyleyse bu yolda daha hızlı ilerlemek (başka bir deyişle daha hızlı öğrenmek) için öğrenme hızının (η) değeri arttırılmalıdır.

İfadenin pozitif değer alması ise; (n+1). döngüde toplam hata fonksiyonun aldığı değer, n. döngüde aldığı değerden daha büyüktür ve toplam hata fonksiyonun minimizasyonu için başka çözümler aranmalıdır. Dolayısıyla öğrenme daha hassaslaştırılarak, fonksiyonun minimizasyonu için gereken yol daha dikkatli aranmalıdır. Bu yolun daha dikkatli aranabilmesi için ise, öğrenme hızının değeri azaltılmalıdır, şeklinde yorumlanabilir.

Öğrenme hızını arttırıp azaltmak için seçilebilecek sınırsız sayıda kural oluşturulabilir. Dikkat edilmesi gereken nokta $\Delta\varepsilon_{top}$ ifadesi negatif değer aldığı anda öğrenme hızı (oranı) arttırılmalı, tersi durumda ise azaltılmalıdır. (4.58)'de dinamik

öğrenme hızı ayarlaması için kullanılabilecek bir sistem verilmiştir (Samarasinghe, 2006).

$$\Delta\eta = \begin{cases} +\gamma & \Delta\varepsilon_{top} < 0 \\ -\beta\eta & \Delta\varepsilon_{top} > 0 \\ 0 & \Delta\varepsilon_{top} = 0 \end{cases} \quad (4.58)$$

(4.58)'de öğrenme hızının her bir döngüden sonra nasıl güncelleştirileceğini ifade eden bir sistem gösterilmiştir. Bu sistemde $\Delta\eta$ ifadesi, öğrenme hızının hangi oranda değiştirileceğini ifade etmektedir. (4.58)'de yer alan sisteme göre $\Delta\eta$ ' nün değeri bulunduktan sonra, öğrenme oranının (η) yeni değeri (4.59) ifadesine eşit olacaktır.

$$\eta^{yeni} = \eta^{eski} + \Delta\eta \quad (4.59)$$

Bu yaklaşım sayesinde öğrenme hızı her döngü sonunda toplam hata fonksiyonun aldığı değere göre değiştirilecektir. Hata fonksiyonundaki değişme pozitif ise öğrenme hızı azaltılarak öğrenme hassaslaştırılacak, negatif ise artırılarak hatanın sifıra yakınsama süresi (dolayısıyla döngü sayısı) azaltılmış olacaktır. γ ve β ' nın nasıl seçileceği hakkında bir kısıtlama olmamakla beraber $0.00001 \leq \gamma \leq 0.001$ ve $0.01 \leq \beta \leq 0.1$ aralıklarında seçilmesi uygundur (Orr ve diğ., 1999).

Momentum Terimi ve Öğrenme Performansına Etkisi

Genelleştirilmiş delta öğrenme kuralının işleyebilmesi için gereken kısmi diferansiyeller kanalıyla oluşabilecek bir diğer sorun ise bu diferansiyellerin her bir iterasyonda çok yüksek değişkenlik göstermesi nedeniyle ağ yapısının kararsızlaşmasıdır. Bağlantı ağırlıklarının çok küçük değerlerde seyrettiği durumlarda, sistem en uygun bağlantı ağırlıklarına çok yakın olsa dahi, kısmi türevlerin genliklerinin büyük olması (türev sonuçlarının aşırı derecede büyük çıkması), bağlantı ağırlıklarında çok büyük değişmelere yol açacak ve sistem aniden en uygun noktadan büyük bir sapma gösterecektir. Kısmi türevlerde oluşan bu tür sıçramalar '*Momentum Terimi*' olarak bilinen bir terimin, katmanlar arası bağlantı ağırlıkları güncelleme kuralına dâhil edilmesiyle engellenebilir (Efe ve Kaynak, 2000).

Momentum teriminin açıklanması için, Şekil 4.11'de gösterilen örnek yapay sinir ağının çıkış katmanındaki bağlantı ağırlıklarının ayarlanma kuralı örnek olarak seçilmiştir. Bu kural (4.60)'da yer almaktadır.

$$\Delta b_{i,1} = \eta \frac{\partial \mathcal{E}_{top}}{\partial b_{i,1}} = \eta \delta y_{2,i} \quad i=1 \dots 3 \quad (4.60)$$


Momentum terimi yaklaşımına göre, herhangi bir katmandaki herhangi bir nöronun bağlantı ağırlıkları güncellenirken, güncelleme kuralına, $\Delta b_{i,1}$ ifadesinin, bir önceki iterasyonda aldığı değerin belirli bir oranı eklenmeli ve diferansiyel kaynaklı olası sıçrama ve dengeden uzaklaşma durumu engellenmelidir. (4.61)'de bu ifadenin matematiksel açılımı yapılmıştır.

$$\Delta b_{i,1}^{yeni} = \Delta b_{i,1}^{eski} + \mu \Delta b_{i,1,t-1} \quad t=\text{zaman} \quad (4.61)$$

(4.61)'de momentum teriminin kullanılmasına yer verilmiştir. $\Delta b_{i,1}^{eski}$ değişkeni, ilk adımda hesaplanan değişim oranıdır. Daha başka bir deyişle bu değişken aslında (4.60)'da verilen ifadeye eşittir. $\Delta b_{i,1,t-1}$ ise değişim miktarının (t-1) anında aldığı değeri ifade etmektedir. Buradaki (t) indisi döngü sayısını değil, zamanı göstermektedir. Örneğin (x_t, y_t) çifti ağa girdiğinde bu ifadenin değeri $\Delta b_{i,1,t}$ ise (x_{t-1}, y_{t-1}) değişkenleri analiz için ağa girdiğinde bu ifadenin (t-1) anındaki değeri göreceli olarak $\Delta b_{i,1,t-1}$ olacaktır. (t-1) indisi, bu ifadenin bir döngü önceki değerini değil, bir eğitim çifti önceki değerini göstermektedir.

μ (mü) sabiti ise; “Momentum Terimi” olarak bilinen ve uygulamada çoğunlukla $\mu \geq 0.6$ olarak seçilen bir katsayı olup bir önceki bağlantı ağırlığı değişim miktarının hangi oranda yeni ağırlığı etkileyeceğini göstermektedir.

Şekil 4.12’de bir ÇKA ağının parametre (ağırlık) uzayında, en uygun bağlantı ağırlıklarına yakınsama süreci gösterilmektedir.



Şekil 4.12: Parametre uzayında optimal ağırlığa yakınsama süreci. a) düşük öğrenme hızı. b) yüksek öğrenme hızı. c) yüksek öğrenme hızı + momentum terimi (Kröse ve Smagt, 1996).

Şekil 4.12’de öğrenme hızının küçük seçilmesi (a), sistemin yakınsama süresini dolayısıyla da döngü sayısı ve öğrenme zamanının arttırırken, büyük seçilmesi ise (b), en uygun çözüme doğru yakınsarken salınımlara (osilasyon) neden olmakta ve sistemi kararsızlığa itmektedir. Öğrenme kuralına momentum terimi eklendiğinde ise (c), sistem hem kararlı bir biçimde en uygun çözüme yaklaşmakta hem de yakınsamanın sağlanabilmesi için geçen zaman kısalmaktadır.

4.3.6.6 Öğrenme ve ezberleme arasındaki fark

Yapay sinir ağları eğitilirken genellikle seride bulunan veri hacminin (n) belirli bir yüzde oranını ağı eğitmek için, geri kalanı ise ağı test etmek için kullanılır. Örneğin 100 veri bulunan bir sette (n=100), oranlar %80 ve %20 olarak belirlenirse, ilk 80 veri ağı eğitmek için, geriye kalan 20 veri ise ağı test etmek için kullanılır. (n1=80 ve n2=20) Yapay sinir ağları eğitilirken böyle bir yol seçilmesinin nedeni ağı test veri setiyle eğittikten sonra, eğitim dışı verileri kullanarak performansı gözlemek ve ağıın genelleme yeteneğini ortaya çıkarmaktır.


Yapay sinir ağları eğitim setleriyle eğitilirken, eğitimin en uygun noktada durdurulması gerekmektedir. Eğer belirli bir noktadan sonra ağı eğitmeye devam edilirse, genelleme yapma özelliğini kaybedecek ve eğitim çiftlerini ‘ezberlemeye’ başlayacaktır. Bu durum başka bir deyişle ifade edilirse; ağı aşırı eğitildiğinde *kullanılan eğitim serisinin kitle içinden seçilen bir örnek olduğunu değil, kitlenin kendisi olduğunu zannedecektir*. Bu durumda eğitim veri seti (n1) için çok hassas tahminler veren ağı, eğitim dışı veri seti için (n2) anlamsız tahminler vermeye başlayacaktır. Çünkü ağı aşırı eğitimden dolayı, ilk örneği (n1=80) kitle zannederek ezberleyecek ve aynı kitleye dahil olan ikinci örneği (n2=20) başka bir kitle gibi değerlendirecektir. Yapay sinir ağları yazınında aşırı eğitim (overtraining) sonucu yapay sinir ağının genelleme yeteneğini kaybetmesi ve dolayısıyla ağı tahmin değerlerinin etkinliklerini kaybetmeleri durumuna *ezberleme etkisi* (memorizing effect) denmektedir (Hansel ve diğ., 1992). Ezberleme etkisi sadece aşırı eğitim sonucu ortaya çıkmamaktadır. Eğitim için kullanılan test veri setinin hacminin yeterince büyük olarak seçilmemesinden ve buna bağlı olarak yapay sinir ağının veri setleri arasındaki ilişkileri tam olarak ortaya koyamamasından da oluşabilmektedir.

4.2.6.7 ÇKA ağlarında öğrenmeyi etkileyen faktörler

Öğrenmeyi ve genellemeyi etkileyen faktörler şu şekilde sıralanabilir:

- a) *Öğrenme Algoritması ve Döngü Sayısı*: Bu parametrelerin eğitim veri serisi için toplam ağ hata fonksiyonunun en hızlı biçimde minimize edilebilmesi ve ağın ezberleme (memorizing) yerine genelleyebilmesi üzerinde etkileri vardır.
- b) *Eğitim Veri Setinin Hacmi ve Niteliği*: Bu parametreler ise yapay sinir ağının gerçek fonksiyona (kitle fonksiyonuna) yakınsayabilme yeteneği üzerinde etkileri vardır.
- c) *Gizli Katman Sayısı*: Gizli katmanlar bir yapay sinir ağının en büyük gücünü oluşturmaktadırlar (Kröse ve Smagt, 1996). Yumuşak ve kolayca modellenen fonksiyonların (veya ilişkilerin) modellenmesinde az sayıda gizli katman kullanılabilirken, değişkenlik gösteren fonksiyonlar veya ilişkinin net olarak ortaya koyulması zor olan değişkenler için daha fazla sayıda gizli katman gerekmektedir. En uygun gizli katman sayısının nasıl belirleneceği hakkında teorik bir sınır yoktur ve yapay sinir ağı analizinde kullanılacak gizli katman sayısı sadece araştırmacı veya uygulayıcının seçimine bağlıdır.

İlk olarak eğitim için kullanılacak eğitim veri setinin hacminin, genelleme üzerindeki etkisine değinilecektir. Bu durumun incelenmesi için, Şekil 4.13 kullanılacaktır.



Şekil 4.13: Örnek hacminin genelleme üzerindeki etkisi.


Şekil 4.13'te yer alan panelin (A) ile simgelenen parçasında, y fonksiyonunun modellenmesi için ileri beslemeli bir geri yayılma ağının $n_1 = 4$ hacmindeki eğitim seti ile eğitildiği durum gösterilmektedir. Şekilde kesikli çizgi ile ifade edilen fonksiyon, ağa öğretilmek istenilen fonksiyonun ($y = f(x)$) gerçek değeri iken, sürekli çizgi ile gösterilen fonksiyon, yapay sinir ağının y fonksiyonu için vermiş olduğu tahmin değerlerini ($\hat{y}$) ifade etmektedir. Yapay sinir ağının eğitimi için

kullanılan örneklem, y fonksiyonunun üzerinde içi boş daireler şeklinde gösterilmektedir.

Şekil 4.13'ün (A) ile gösterilen parçası ($y = f(x)$)fonksiyonunu modelleyebilmesi için 4 adet x değeriyle eğitilen YSA'nın ürettiği tahmin değerlerini göstermektedir. Bu şekilde eğitilen ağın ürettiği tahmin değerleri y fonksiyonunu açıklayabilmekten çok uzak kalmış ve y fonksiyonunu genellemeyi başaramamıştır. Şeklin (B) parçasında ise $n_1 = 20$ örneklem (x değeri) ile eğitilen YSA' nın aynı fonksiyon için ürettiği tahmin değerleri gösterilmiştir. 20 adet x değeri ile eğitilen ağ, fonksiyonu mükemmel bir şekilde modelleyebilmektedir.

Sonuç olarak örneklem hacminin 4'den 20'ye yükseltilmesi, ağın ($y = f(x)$) fonksiyonunu öğrenerek genellebilmesini sağlamıştır.

İkinci aşamada gizli katman sayısının, öğrenme ve genelleme üzerindeki etkileri araştırılacaktır. Bunun için Şekil 4.14 kullanılacaktır.



Şekil 4.14: Gizli katman sayısının öğrenme ve genelleme üzerindeki etkisi.

Şekil 4.14'ün (A) ile simgelenen parçasında, 5 adet gizli katman içeren ileri beslemeli bir geri yayılma ağının ($y = f(x)$) fonksiyonunu modellenmesi için $n_1 = 12$ hacmindeki veri ile eğitildiği durum gösterilmiştir. Şekilde kesikli çizgi ile ifade edilen fonksiyon, ağa öğretilmek istenilen fonksiyonun ($y = f(x)$) gerçek değeri iken, sürekli çizgi ile gösterilen fonksiyon yapay sinir ağının y fonksiyonu için vermiş olduğu tahmin değerlerini ($\hat{y}$) ifade etmektedir. Yapay sinir ağının eğitimi için kullanılan örneklem, y fonksiyonunun üzerinde içi boş daireler şeklinde gösterilmektedir.

Şekil 4.14'ün (B) kısmında yer alan ileri beslemeli ağ ise 20 adet gizli katman içeren ileri beslemeli bir geri yayılma ağıdır. Bu YSA, şeklin (A) kısmında gösterilen ve $n_1 = 12$ hacmindeki veri ile eğitilen YSA ile aynı örneklem kullanılarak eğitilmiştir. Kısaca (A) ve (B) ile gösterilen her iki YSA da aynı örneklem hacmi ve örneklerle eğitilmiştir. İki YSA' nın arasındaki tek fark, mimarilerinde kullanılan gizli katman sayısıdır.

Şekil 4.14'e göre, (B) kısmındaki ağın mimarisinde gerekenden fazla gizli katman kullanıldığı için, ağın genelleme yeteneği ortadan kalkmıştır. Şekil 4.14'ün (B) parçasında gösterilen YSA, eğitim seti için kullanılan 12 hacmindeki örneklemin x değerlerine karşılık gelen y değerlerini çok iyi bir şekilde tahmin edebilmesine rağmen, daha önce hiç karşılaşmadığı test veri setindeki x değerlerine karşılık gelen y değerlerini etkin bir şekilde tahmin edememiştir.

4.3.6.8 ÇKA ağlarında kullanılacak verilerin ölçeklendirilmesi

Girdi ve çıktıların ölçeklendirilmesi (normalizasyonu), ağın performansını yakından etkileyen bir faktördür. Ölçeklendirme, örnek değerlerinin dağılımını düzenli hale getirir. Problem için örnekler toplanırken, farklı ölçekler kullanılan ortamlardan toplanmış olabilir. Bu durumda hepsinin aynı ölçek üzerine indirgenmesi gerekecektir. Bazı durumlarda da problemin girdileri arasında aşırı büyük veya küçük değerler olabilir. NET girdiler hesaplanırken bu değerler, aşırı büyük ve küçük değerlerin doğmasına sebep olarak ağı yanlış yönlendirebilir. Bütün girdilerin belirli aralıkta (çoğunlukla 0-1 aralığında) ölçeklendirilmesi hem farklı ortamlardan gelen bilgilerin aynı ölçek üzerine indirgenmesine hem de yanlış girilen değerlerin etkisinin ortadan kalkmasına yardımcı olur (Öztemel, 2003).

Ölçeklendirme değişik şekillerde yapılmaktadır. Bazı araştırmacılar girdi vektörünü normalize etmektedirler. Yani her değeri girdi vektörünün değerine bölerek yeni değerleri bulmaktadırlar. Formülizasyonu aşağıda verilmektedir.

$$x' = \frac{x}{|X|} \quad (4.61)$$

Burada x girdi değerini, x' ölçeklendirilmiş yeni girdi değerini, $|X|$ ise girdi vektörünün büyüklük değerini göstermektedir (Öztemel, 2003).

Ölçeklendirme için bir diğer yol ise (4.62)'de verilmektedir.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (4.62)$$

Burada x girdi değerini, x' ölçeklendirilmiş yeni girdi değerini, x_{max} girdi setindeki en büyük değeri, x_{min} ise girdi setindeki en küçük değeri göstermektedir.

Verilen yöntemler ile birlikte üzerinde durulması gereken nokta, ölçeklendirmede hangi yöntemin kullanılacağından çok girdiler içerisindeki olumsuzlukları giderecek şekilde ölçeklendirme yapmaktır. Her problem için farklı bir ölçeklendirme yöntemi olabileceği gibi problem çözücü kullanacağı yaklaşımı kendisi de geliştirebilir (Öztemel, 2003).

5. TALEP TAHMİNİ UYGULAMASI

Talep tahmini uygulaması, Türkiye’de gelişmekte olan temizlik kâğıdı sektörü yıllık satış verilerinden yola çıkılarak yapılmıştır. Temizlik kâğıdı satışını etkileyen faktörlerin belirlenmesi aşamasında uzman görüşü olarak Türkiye Selüloz ve Kağıt Sanayii Vakfı yöneticileri, Lila Kağıt Tic. A.Ş. Genel Müdür, Satış ve Pazarlama Müdürü’nün görüşlerine başvurulmuştur.

İlerleyen kısımlarda temizlik kâğıdı yıllık talep tahmini probleminin çözüm aşamaları verilmiştir. Yapay sinir ağları ile yapılan tahmin, çoklu regresyon analizi ile karşılaştırılarak tahminleme performansı test edilmiştir.

5.1 Talep Tahmini Probleminin Tanımlanması

Bu çalışma ile Türkiye’de tuvalet kâğıdı, kâğıt havlu, peçete ve mendil gibi tüketim malzemelerinin yer aldığı temizlik kâğıdı yıllık satışlarının yapay sinir ağları kullanılarak tahmin edilmesi ve bu ürün grubunun talebini etkileyen faktörlerin belirlenmesi amaçlanmaktadır.

Türkiye Selüloz ve Kâğıt Sanayi Vakfı yöneticileri, Lila Kağıt Tic. A.Ş. Genel Müdür, Satış ve Pazarlama Müdürü ile yapılan görüşmelerde sektöre olan talebi etkileyen parametrelerin aşağıdaki gibi olduğu tespit edilmiştir.

Üretim Miktarı: Temizlik kâğıdı sektörünün büyüyen bir pazar olduğu ve temizlik alışkanlıklarının değişmesi ile birlikte üretim kapasitesi artışının satışı arttıracığı öngörülmektedir.

İthalat Miktarı: Üretim miktarı ile birlikte pazara sunulan hacmi arttıracığından ithalat tonajının da yıllık talebi olumlu etkileyeceği düşünülmektedir.

Kâğıt ve Basım Sanayi Toptan Eşya Fiyat Endeksi (TEFE): Makro ekonomik bir gösterge olarak TEFE’nin temizlik kâğıdı satışlarına etkisi olduğu düşünülmektedir.

Gayri Safi Yurtiçi Hâsıla: Gayri Safi Yurtiçi Milli Hâsıla’nın halkın alım gücünü arttırmasıyla temizlik kâğıdı satışlarını da etkilediği düşünülmektedir.

Genel Nüfus: Nüfusun yıllara göre artışının temizlik kâğıdı tüketimini dolayısıyla satışını arttırdığı düşünülmektedir.

Kent Nüfusu: Genel nüfusun yanı sıra kentlileşme oran artışının alışkanlıkları da değiştirmesi sebebiyle temizlik kâğıdına olan talebe olumlu etkisinin olduğu düşünülmektedir.

Okuryazar Oranı: Bilinç ve gelişmişlik göstergesi olarak okuryazar oranı artışının kişi başı temizlik kâğıdı kullanım oranını arttırdığı düşünülmektedir. Bu tezi desteklemesi için, 2009 verilerine göre ABD’de yıllık kişi başına düşen temizlik kâğıdı tüketiminin 25 kg iken Türkiye’de bu rakamın 2,5 kg olması gösterilebilir.

1981-2010 arasında yıllık bazda veriler toplanmış, 1981-2009 arasındaki veriler eğitim amaçlı 2010 yılı verisi ise test amaçlı kullanılmıştır. Veriler girdi ve çıktı verileri olarak aşağıdaki gibi toplanmıştır:

Girdi verileri olarak aşağıdaki yedi veri toplanmıştır:

1. **Üretim Miktarı:** 1981-2010 yılları arasında temizlik kâğıdı grubunda üretim miktarı ton/yıl bazında toplanmıştır. (Çizelge A.1)
2. **İthalat Miktarı:** 1981-2010 yılları arasında temizlik kâğıdı grubunda ithalat miktarı ton/yıl bazında toplanmıştır. (Çizelge A.2)
3. **Kâğıt ve Basım Sanayi Toptan Eşya Fiyat Endeksi (TEFE):** 1981-2010 yılları arasındaki TEFE değerleri (1981=100) endeksine göre toplanmıştır. (Çizelge A.3)
4. **Gayri Safi Yurtiçi Hâsıla:** 1981-2010 yılları arasında kişi başına düşen yıllık gayri safi yurtiçi hâsıla değerleri TL/yıl bazında toplanmıştır. (Çizelge A.4)
5. **Genel Nüfus:** 1981-2010 yılları arasında yıllık nüfus verileri TÜİK aracılığıyla toplanmıştır. (Çizelge A.5)
6. **Kentli Nüfus:** 1981-2010 yılları arasında yıllık toplam kent nüfusu verileri TÜİK aracılığıyla toplanmıştır. (Çizelge A.6)
7. **Okuryazar Oranı:** 1981-2010 arasında okuryazar oranı verileri yıllık bazda toplanmıştır. (Çizelge A.7)

Çıktı verisi olarak 1981-2010 arasında temizlik kâğıdı grubuna giren tuvalet kâğıdı, kâğıt havlu, peçete ve mendil satış miktarı yıllık ton bazında verilmiştir. (Çizelge A.8)

Girdi ve çıktı değerleri ağı verilmeden önce normalize edilmelidir. Verileri [0 1] aralığı yerine [0.1 0.9] aralığına gelecek şekilde normalleştirmek yapay sinir ağlarında etkin kullanılan bir yöntemdir. (Tang ve Fishwick, 1993)

Çalışmadaki veriler 0.1 ile 0.9 değerleri arasında normalleştirilmiştir. Normalizasyon işlemi bir X verisi için aşağıdaki şekilde formül kullanılarak gerçekleştirilmiştir. X' normalize değer; X_i gerçek değer olmak üzere;

$$X' = \frac{X - \min X_i}{\max X_i - \min X_i} * 0,8 + 0,1 \quad (5.1)$$

5.2 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.

1981-2009 arasındaki 29 adet veri, ağı eğitimi amaçlı kullanılmıştır. Bunlardan 24 tanesi eğitim, 5 tanesi doğrulama için seçilmiştir. Yapay sinir ağ yapısı için birçok talep tahmininde kullanıldığı gibi biri gizli katman olmak üzere üç katmanlı yapı seçilmiştir. Girdi katmanı 7 hücreden, çıktı katmanı ise 1 çıktı hücreden oluşmaktadır. Gizli katmanda ise herhangi bir sayıda hücre bulunabilir ancak genellikle girdi sayısının iki katını geçmez (Denton, 1995). Yapay sinir ağ yapısında gizli katmandaki hücre sayısının belirlenmesinde piramit kuralı denilen bir 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;

$$\sqrt{m * n} \quad (5.2)$$

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

Çalışmada girdi hücre sayısı 7, çıktı hücre sayısı 1 olduğu için parametrelerin belirlenmesi aşamasında ilk denemeler için, $\sqrt{7 * 1} \approx 3$ değeri kabul edilmiştir. Daha sonra 1 hücre sayısından girdi sayısının 2 katı olan 14 hücreye kadar deneme yapılmıştır.

5.2.1 Momentum katsayısının belirlenmesi

Momentum katsayısı da öğrenmenin performansını etkiler. Momentum katsayısı bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesidir. Momentum katsayısı yerel çözümlere takılan 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). Öğrenme katsayısı programın varsayılan değeri olan 0,60 bırakılarak, 1000 çevrim için momentum katsayıları değiştirilerek en uygun momentum katsayısı bulunmaya çalışılmıştır. Aşağıdaki tabloda 2010 yılı verileri için gerçekleşen değerler ile momentum katsayısının farklı değerlerine göre tahmin edilen değerler kıyaslanmıştır. Buna göre en uygun momentum katsayısının 0,6 olacağına karar verilmiştir.

Çizelge 5.1: Momentum katsayısının farklı değerleri için tahmin değerleri.

	Varsayımlar									
	Öğrenme Katsayısı	0.6								
	Çevrim Sayısı	1.000								
	Gizli Hücre Sayısı	3								
			Momentum Katsayısı							
	Gerçek Değer	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
2010_Temizlik Kağıdı Yıllık Satış Toplamı	0,9	0,8554	0,802	0,8136	0,855	0,8835	0,8855	0,8345	0,8255	0,8115

5.2.2 Öğrenme katsayısının belirlenmesi

Öğrenme katsayısının belirlenmesi de ağın öğrenme performansı açısından oldukça önemlidir. 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 (Öztemel, 2003). Momentum katsayısı 0,6 alınarak 1000 çevrim için öğrenme katsayıları değiştirilerek en uygun öğrenme katsayısı bulunmaya çalışılmıştır. Aşağıdaki tabloda 2010 yılı verileri için gerçekleşen veriler ile öğrenme katsayılarının farklı değerlerine göre tahmin edilen veriler kıyaslanmıştır. Bu çalışma için en uygun öğrenme katsayısının 0,5 olduğu görülmüştür.

Çizelge 5.2: Öğrenme katsayısının farklı değerleri için tahmin değerleri.

	Varsayımlar									
	Momentum Katsayısı	0.6								
	Çevrim Sayısı	1.000								
	Gizli Hücre Sayısı	3								
	Gerçek Değer	Öğrenme Katsayısı								
0,1		0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	
2010 Temizlik Kağıdı Yıllık Satış Toplamı	0,9	0,879	0,8015	0,8245	0,8335	0,889	0,8855	0,8534	0,9443	0,8545

5.2.3 Çevrim sayısının belirlenmesi

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 0.6, öğrenme katsayısı 0.5 alınmış, çevrim sayıları değiştirilerek en uygun çevrim sayısı bulunmaya çalışılmıştır. Aşağıdaki tabloda 2010 yılı verileri için gerçekleşen veriler ile çevrim sayısının farklı değerlerine göre tahmin edilen veriler kıyaslanmıştır. Öncelikle çevrim sayıları 250’şer artırılmıştır. En uygun çevrim sayısının 250 civarında olduğu görülmektedir.

Çizelge 5.3: Çevrim sayısının farklı değerleri için tahmin değerleri.

	Varsayımlar									
	Momentum Katsayısı	0,6								
	Öğrenme Katsayısı	0,5								
	Gizli Hücre Sayısı	3								
	Gerçek Değer	Çevrim Sayısı								
		250	500	750	1000	1250	1500	1750	2000	2250
2010_Temizlik Kağıdı Yıllık Satış Toplamı	0,9	0,89	0,8537	0,8222	0,889	0,8005	0,8669	0,9565	0,9445	0,8774

Daha net değeri bulabilmek için çevrim sayısı değerleri 250 civarında 50’şer artırılmıştır. Bu durumda da en uygun çevrim sayısı değerinin 250 olduğu görülmüştür.

Çizelge 5.4: Çevrim sayısının farklı değerleri için tahmin değerleri.

	Varsayımlar									
	Momentum Katsayısı	0,6								
	Öğrenme Katsayısı	0,5								
	Gizli Hücre Sayısı	3								
	Gerçek Değer	Çevrim Sayısı								
50		100	150	200	250	300	350	400	450	
2010_Temizlik Kağıdı Yıllık Satış Toplamı	0,9	0,8456	0,8775	0,9226	0,8555	0,89	0,81	0,8234	0,8664	0,8535

5.2.4 Gizli hücre sayısının belirlenmesi

Momentum katsayısı 0.6, öğrenme katsayısı 0.5 ve 250 çevrim ile gizli hücre sayısı 1'den giriş hücre sayısının iki katı olan 14'e kadar deneme yapılmıştır. En iyi hücre sayısının 3 olduğu görülmüştür.

Çizelge 5.5: Gizli hücre sayısının farklı değerleri için tahmin değerleri.


	Varsayımlar															
	Momentum Katsayısı	0,6														
	Öğrenme Katsayısı	0,5														
	Çevrim Sayısı	250														
	Gerçek Değer	Gizli Hücre Sayısı														
1		2	3	4	5	6	7	8	9	10	11	12	13	14		
2010_Temizlik Kağıdı Yıllık Satış Toplamı	0,9	0,8556	0,887	0,89	0,8665	0,9178	0,827	0,7967	0,8334	0,811	0,8555	0,8478	0,8876	0,7998	0,8113	

5.3 Yapay Sinir Ağının Eğitilmesi

Ağın eğitilmesi için EasyNN programı kullanılmıştır. Parametreler ise aşağıdaki şekilde oluşturulmuştur.

Çizelge 5.6: Yapay sinir ağı katman ve hücre sayısı.


Girdi Hücre Sayısı	7
Çıktı Hücre Sayısı	1
Gizli Katman Sayısı	1
Gizli Hücre Sayısı	3
Eğitim Veri Sayısı	24
Test Veri Sayısı	5



Şekil 5.1: EasyNN programı katman ve hücre sayısının tanımlanması.


Çizelge 5.7: Yapay sinir ağı parametreleri.

Momentum Katsayısı	0,6
Öğrenme Katsayısı	0,5
Çevrim Sayısı	250
Hata Oranı	1%




Şekil 5.2: EasyNN programı parametre tanımlama ekranı.

Kullanılan ağ yapısı aşağıdaki gibi oluşturulmuştur.




Şekil 5.3: Kullanılan ÇKA ağ yapısı.

Ağın öğrenme grafiği Şekil 5.4'te verilmektedir.



Şekil 5.4: Öğrenme grafiği.

Ağın tahmin grafiği ise aşağıdaki gibi gerçekleşmiştir.



Şekil 5.5: Tahmin grafiği.

5.4 Sonuçların Test Edilmesi ve Değerlendirilmesi

Ağın eğitilmesinin ardından 2010 yılı gerçekleşen satış değeri ile tahmin edilen değer karşılaştırılmıştır. Buna göre % 98,89 başarıyla 2010 yılı toplam satış değeri tahmin edilebilmiştir.

Çizelge 5.8: 2010 yılı gerçekleşen ve tahmin edilen değerlerin kıyaslanması.

	Gerçekleşen Değer	Tahmin Edilen Değer	Hata%
Normalleştirilmiş Değer	0,9	0,89	1,11%
Gerçek Satış Değeri(ton)	335774	331636	

Karşılaştırma amacıyla tahmin edilen en iyi değere yakın ağ yapılarının performanslarına baktığımızda aşağıdaki sonuçları elde edebiliriz.

Çizelge 5.9: Çevrim Sayısı=1000'e göre gerçekleşen/tahmin edilen değerler.

Varsayımlar			
	Momentum Katsayısı	0,6	
	Öğrenme Katsayısı	0,5	
	Çevrim Sayısı	1000	
	Gizli Hücre Sayısı	3	
	Gerçekleşen Değer	Tahmin Edilen Değer	Hata%
Normalleştirilmiş Değer	0,9	0,889	1,22%
Gerçek Satış Değeri(ton)	335774	331222	

Çizelge 5.10: Gizli hücre sayısı=12'ye göre gerçekleşen/tahmin edilen değerler.


Varsayımlar			
	Momentum Katsayısı	0,6	
	Öğrenme Katsayısı	0,5	
	Çevrim Sayısı	250	
	Gizli Hücre Sayısı	12	
	Gerçekleşen Değer	Tahmin Edilen Değer	Hata%
Normalleştirilmiş Değer	0,9	0,8876	1,38%
Gerçek Satış Değeri(ton)	335774	330643	

Çizelge 5.11: Gizli hücre sayısı=2'ye göre gerçekleşen/tahmin edilen değerler.

Varsayımlar			
	Momentum Katsayısı	0,6	
	Öğrenme Katsayısı	0,5	
	Çevrim Sayısı	250	
	Gizli Hücre Sayısı	2	
	Gerçekleşen Değer	Tahmin Edilen Değer	Hata%
Normalleştirilmiş Değer	0,9	0,887	1,44%
Gerçek Satış Değeri(ton)	335774	330395	


Temizlik kâğıdı yıllık satış miktarı, belirlenen parametrelere göre tahmin edilmek istendiğinden bu noktada duyarlılık analizi devreye girmektedir. Duyarlılık analizi, verideki değişimin sonuç üzerinde yarattığı değişimin izlenmesi olarak tanımlanabilir. EasyNN programında girdi değerlerinin tamamı medyan değerlerine ayarlandıktan sonra bir veri en küçük değerden en büyük değere kadar değiştirilerek çıktı üzerindeki değişimi ölçülmektedir.

Temizlik kâğıdı için talebin girdi parametre değerlerine göre duyarlılığı Şekil 5.6'da verilmektedir.



Şekil 5.6: Duyarlılık analizi.

Girdi parametrelerinin önem dereceleri ise Şekil 5.7'de verilmektedir.



Şekil 5.7: Girdi parametrelerinin önem dereceleri.

Temizlik kâğıdı yıllık satış miktarını en çok etkileyen parametrenin üretim kapasitesi ve miktarı olduğu görülmektedir. Üretim miktarının minimum ve maksimum değerleri ile yıllık satış miktarı arasında pozitif bir uyum olduğu söylenebilir. Yani üretim miktarının yıllara göre artışı temizlik kâğıdı satışlarını da arttırmaktadır. Bu durum, Türkiye’ye temizlik kâğıdı pazarının henüz doymamış bir pazar olması ve dünya tüketim ortalaması ile karşılaştırıldığında kat edilecek çok yol olması ile açıklanabilir.

Üretim miktarından sonra ithalat miktarı duyarlılıkta ikinci önemli parametre olarak görülmektedir. Bu durum da, üretim miktarı ile birlikte pazara giren toplam tonajı arttırdığından satış miktarı ile pozitif bir uyum göstermesi beklenen bir durumdur.

Diğer parametrelerin duyarlılıktaki etki dereceleri göreceli olarak üretim ve ithalat miktarına göre daha az olmak ile birlikte okur-yazar oranının bilinç ve alışkanlık değişimi göstergesi olarak temizlik kâğıdı satışlarını olumlu yönde etkilediği görülmektedir. Bu çalışmaya başlanırken görüşüne başvurulmuş uzmanlar, özellikle Doğu ve Güneydoğu Anadolu Bölgesi’ndeki satışların 20 yıllık süreçte okuryazar oranının artışından oldukça fazla etkilendiği yönde fikirlerini beyan etmişlerdi. Bu durum, onları haklı çıkarmaktadır.

Genel nüfus artışının temizlik kâğıdı talep miktarını arttırması beklenen bir durumdur. Nüfus artışı ile birlikte toplam kullanım miktarının artması pazarı ve dolayısıyla talebi arttırıcı yönde etki yapmaktadır.

GSYİH değeri, yıllık makro bir gösterge olarak halkın alım gücünü göstermektedir. GSYİH değerinin artması, duyarlılıkta beşinci etki düzeyinde olmak ile birlikte temizlik kâğıdı satışlarını arttırıcı yönde etki yaratmaktadır.

Kâğıt ve basım sanayi toptan eşya fiyat endeksi (TEFE)'nin artışı üretime konu olan maliyetler dolayısıyla fiyatlar genel seviyesinin artışını temsil ettiğinden normal koşullar altında ilgili ürün grubunun satışını düşürücü yönde etkisi olacağı düşünülmektedir. Ancak kâğıdın ana hammaddesi ve ana maliyet kalemi olan, ithal selülozun fiyat artışlarının pazardaki rekabet dolayısıyla ürün fiyatlarına yansıtılamaması bu genellenin piyasa koşullarında uygulanabilir olmadığını göstermektedir. Bu durum da, TEFE'nin temizlik kâğıdı talep miktarının değişimine duyarlılık anlamında az etki göstermesi ile paralellik arz etmektedir.

Son olarak kentli nüfusun temizlik kâğıdı satışlarına etkisine bakıldığında pozitif yönde ancak düşük duyarlılıkta etki yarattığı söylenebilir. Bu durumun sebebinin, temizlik kâğıdı talep değişkenliğinin daha yüksek oranda genel nüfus değişimi ile açıklanması ve bu nedenle kentli nüfusun daha az etki yaratması olarak gösterilebilir.

5.5 YSA Yönteminin Diğer Talep Yöntemleriyle Karşılaştırılması

Gerçek veriler kullanılarak aşağıdaki yöntemler ile talep tahmini yapılarak sonuçlar karşılaştırılmıştır.

5.5.1 Basit regresyon yöntemiyle talep tahmini

Basit regresyon yöntemi kullanılarak sadece geçmiş satış verilerinden yola çıkılarak tahmin yapılması sağlanmıştır. Bağımsız değişken (X) yıl olmak üzere $Y = a_0 + a_1X$ denklemindeki katsayılar aşağıdaki şekilde bulunmuştur.

Çizelge 5.12: Basit regresyon modeli ağırlık değerleri.

	a0	a1
Toplam Satış	-1,68E+07	8461,748

Hesaplanan ağırlıklara göre 2010 yılı tahmin edilerek gerçekleşen değer ile karşılaştırılmıştır. Buna göre 2010 yılı temizlik kâğıdı talebinin tahmin edilmesinde %61,98 başarı elde edilmiştir.

Çizelge 5.13: Basit regresyon modeline göre tahmin/gerçekleşen kıyaslaması.

	Gerçekleşen Değer	Tahmin Edilen Değer	Hata%	Başarı %
Toplam Satış Değeri(ton)	335774	208113	38,020%	61,980%

5.5.2 Çoklu regresyon yöntemiyle talep tahmini

Çoklu regresyon analizinde öncelikle tüm parametrelerin bağımsız değişken olarak yer aldığı Model-1 analiz edilmiş; sonrasında YSA duyarlılık analizinde en etkili girdiler olarak belirlenen üretim ve ithalat miktarlarının bağımsız değişken olarak yer aldığı Model-2 çalıştırılmıştır.

X girdi verilerini (bağımsız değişkenler) ve Y çıktı verisini (bağımlı değişken) temsil etmek üzere;

a_0 = sabit değer

X_1 = üretim miktarı

X_2 = ithalat miktarı

X_3 = TEFE

X_4 = GSYİH

X_5 = Genel Nüfus

X_6 = Kentli Nüfus

X_7 = Okuryazar oranı

$$Y = a_0 + a_1X_1 + a_2X_2 + a_3X_3 + a_4X_4 + a_5X_5 + a_6X_6 + a_7X_7 \quad (5.3)$$

formülüne göre SPSS 18.0 istatistik programı kullanılarak bulunan ağırlıklar aşağıdaki gibidir.

Çizelge 5.14: Model-1 regresyon analizi ağırlıkları.

MODEL-1	a0	a1	a2	a3	a4	a5	a6	a7
Toplam Satış	97831,279	0,813	1,403	-0,014	22,449	0,668	0,791	-2516,939

Çizelge 5.15: Model-2 regresyon analizi ağırlıkları.

	a0	a1	a2
Toplam Satış	-3552,739	0,829	0,313

Model-1 ve Model-2 çalıştırılarak çoklu regresyon analizi sonucu çıkan ağırlıklar kullanılarak 2010 yılı tahmin edilmiş ve gerçekleşen verilerle aşağıdaki tabloda kıyaslanmıştır. Model-1'e göre tüm parametrelerin Çizelge 5.11'deki ağırlıklar ile yer aldığı denklem kullanılarak 2010 yılı tahmini %92,985 başarı ile gerçekleştirilmiştir.

Bunun yanı sıra, sadece üretim miktarı ve ithalat miktarı bağımsız değişkenlerinin yer aldığı Model-2'ye göre yapılan 2010 yılı tahmin başarı oranı %91,742 çıkmıştır.

Çizelge 5.16: Regresyon analizi ile tahmin edilen değerlerin gerçek değer ile karşılaştırılması.

		Gerçekleşen Değer	Tahmin Edilen Değer	Hata%	Başarı %
Toplam Satış Değeri(ton)	MODEL-1	335774	312218	7,015%	92,985%
	MODEL-2	335774	308046	8,258%	91,742%

6. SONUÇ VE DEĞERLENDİRME

Bu çalışma özellikle talep tahmininde uygulanan bir yöntem olan yapay sinir ağlarının parametreye bağlı tahminde etkin sonuçlar verdiğini göstermek amacıyla hazırlanmıştır. Türkiye’de alışkanlıkların değişmesi ve çeşitli faktörlerin de etkisiyle gelişmekte olan bir sektör olan temizlik kâğıtları alanında son 30 yılın verilerinden yola çıkılarak talep tahmini yapılmaya çalışılmıştır.

1981-2010 yılları arasında yıllık temizlik kâğıdı satış verileri ton bazında toplanmıştır. Yıllık satışları etkileyen faktörler, çalışma öncesinde görüşülen uzman kişiler ve yapılan araştırmalar neticesinde ortaya konulmuş, gerekli bilgiler çeşitli kurum kaynaklarından (TÜİK, SKSV vb.) elde edilmiştir. Toplanan veriler, (0.1 0.9) aralığında normalleştirilerek eğitim ve test amacıyla ağı sunulmuştur.

Yapay sinir ağlarının uygun mimarisini elde etmek için kaynaklardan yararlanmakla birlikte parametreler analiz edilmiş ve en uygun ağ mimarisi bulunmuştur. 1981-2009 yılları arasındaki veriler ağın eğitilmesi ve doğrulama yapılması için kullanılmış, 2010 ise sonucun testi için ayrılmıştır. Yapılan tahmin sonucunda %1,11’lik bir hatayla %98,89 başarı elde edilmiştir.

Ayrıca tahmin performansının ölçülmesi amacıyla basit ve çoklu regresyon modelleriyle de talep tahmini yapılmıştır. Basit regresyon modelinde temizlik kâğıdı talebinin yıllara göre değiştiği varsayımından yola çıkılarak bağımsız değişken, zaman olarak alınmıştır. Bu model ile yapılan tahmin sonucunda %61,89’luk bir başarı elde edilmiştir. Çoklu regresyonda iki model oluşturularak başarı test edilmek istenmiştir. Model-1’de YSA ağında girdi hücresi olarak alınan tüm faktörler bağımsız değişken olarak kabul edilmiş olup yapılan tahmin neticesinde %92,985’lik başarı elde edilmiştir. Model-2’de ise YSA’da yapılan duyarlık analizi sonucunda en etkili faktörler olarak çıkan üretim miktarı ve ithalat miktarı değerleri bağımsız değişken olarak alınıp talep tahmini yapılmıştır. Bu model ile yapılan tahmin sonucunda ise %91,74 başarı elde edilmiştir.

Çoklu regresyon analizi yapılırken bağımsız değişkenler arasında korelasyon olmadığı varsayımı yapılmıştır. Basit regresyon modelinde ise talebin sadece zamandaki değişimden etkilendiği varsayılmıştır. 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 makro seviyede Türkiye'deki toplam temizlik kağıdı talebinin değişimini yıllık bazda almıştır. Bu konu ile ilgili kurumların yapmış olduğu çalışmalarda veriler yıllık analiz edildiğinden toplam bazda aylık verilere ulaşamamıştır. Ayrıca 1980 öncesinin verilerine sağlıklı bir şekilde ulaşamadığı için zaman aralığı sınırlandırılmıştır. Çalışmanın geliştirilmesi ve detaylandırılması için veriler aylık bazda ve daha geniş bir tarih aralığını kapsayacak şekilde derlenmelidir. Makro parametreler, temizlik kağıtları sektöründe şirket bazında talep tahmini yaparken de dikkate alınmalı ve bu sayede modelin genelden özele indirgenmesi sağlanmalıdır. Ayrıca yapay sinir ağlarında model parametrelerinin bulunması aşamasında yapılan denemelerin sayısı ve hassasiyeti arttırılarak ilgili aralıklarda daha az tahmin hatası içeren sonuçlara ulaşılabilir.

KAYNAKLAR

- Adıyaman, F.**, 2007. Talep Tahmininde Yapay Sinir Ağlarının Kullanılması, *Yüksek Lisans Tezi*, İTÜ Fen Bilimleri Enstitüsü, İstanbul.
- Aksoy, S. Z.**, 2008. Kurumsal Kaynak Planlaması Yazılımlarında Talep Tahmin Yöntemleri ve Uygulamaları, *Yüksek Lisans Tezi*, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Anderson, D., and McNeill, G.**, 1992: Artificial Neural Networks Technology. Kaman Sciences Corporation, New York.
- Anderson, D. R., Sweeney, D. J., and Williams, T. A.**, 2005: An Introduction to Management Science. BookMasters Inc., USA.
- Armstrong, J.**, 2001: Principles of Forecasting: A Handbook for Researchers and Practitioners. Kluwer Academic Publishers, Hingham, MA.
- Bircan, H. ve Karagöz, Y.**, 2003: Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama. *Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (6), pp.49-62.
- Bolt, G.**, 1994: Market and Sales Forecasting : a total approach. Kogan Page, Londra.
- Box, G. E. P., and Jenkins, J. M.**, 1976: Time Series Analysis: Forecasting and Control. Holden-Day, San Francisco, CA.
- Broomhead, D., and Lowe, S.**, 1988. Radial Basis – Functions, Multi – Variable Functional Interpolation and Adaptive Networks, *Royal Signals and Radar Establishment Memorandum*, No.4148.
- Chatfield, C.**, 2000: Time-series forecasting. Chapman & Hall/CRC, USA.
- Chaudhury, A., Stahl, D. O., and Whinston, A. B.**, 1994: The Economic Foundation for Neural Computing Systems in, Advances in AI in Economics, Finance and Management. Eds. Johnson J.D.. Whinston A.B.. JAI Pres Inc.
- Crochat, P., and Franklin, D.**, 2003: Backpropagation Neural Network Tutorial. From http://ieee.uow.edu.au/~daniel/software/libneural/BPN_tutorial/BPN_English/BPN_English/
- Çelik, B.**, 2008. Yapay Sinir Ağları Metodolojisi İle Zaman Serisi Analizi: Teori ve Uygulama, *Yüksek Lisans Tezi*, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Çorumluoğlu Ö., ve Özbay Y.**, 2005. GPS Yüksekliklerinden Ortometrik Yüksekliklerin Elde Edilmesinde Yapay Sinir Ağı (YSA) Tekniğinin Kullanımı, *İTÜ Har. ve Kad. Müh.Odası, Mühendislik Ölçmeleri STB Komisyonu 2. Mühendislik Ölçmeleri Sempozyumu*, İTÜ, İstanbul, 23-25 Kasım.

- Dalkey, N. C.**, 1972: Studies In the Quality Of Life: Delphi and Decision Making. Lexington Books, Lexington, MA.
- Data and Analysis Center for Software** , 1992. *Detailed Artificial Neural Networks Technology, Network Selection*, F30602-89-C-0082, from <https://www.dacs.dtic.mil/techs/neural/neural6.php>
- Denton, J. W.**, 1995: How good are neural networks for casual forecasting?. *The Journal of Business Forecasting Methods&Systems*, vol.14, no.2 , pp.17.
- Efe M. Ö., ve Kaynak O.**, 2000: Yapay Sinir Ağları ve Uygulamaları. Boğaziçi Üniversitesi Yayınevi, İstanbul.
- Elmas Ç.**, 2003: Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama). Seçkin Yayıncılık, Ankara.
- Eski, H., ve Armaneri, Ö.**, 2006: Mühendislik Ekonomisi. Gazi Kitabevi, Ankara.
- Farley, B. G., and Clark, W. A.**, 1954: Simulation of Self - Organizing Systems by Digital Computers. *IEE Transactions of Professional Group of Information Theory*, (PGIT-4), pp.76-84.
- Fausett, L.**, 1994: Fundamentals of Neural Networks. Prentice Hall, USA.
- Hansel, D., Mato, G., and Meunier, C.**, 1992: Memorization Without Generalization in a Multilayered Neural Network. *Centre de Pysique Theorique, Ecole Polytechnique, Europhysics Letters*, vol.20, no.5, pp.471-476.
- Haykin, S.**, 1999: Neural Networks: A Comprehensive Foundation. Prentice Hall, New Jersey.
- Hebb, D.O.**, 1949: The Organization of Behaviour, A Neuropsychological Theory. John Wiley & Sons Inc, New York.
- Hoang P.**, 2006: Springer Handbook of Engineering Statistics. Springer- Verlag London Limited, Germany.
- Holt, C. C.**, 2004: Forecasting seasonals and trends by exponentially weighted moving averages. *International Journal of Forecasting*, vol.20, no.1, pp.5-10.
- Hosseini A.**, 1994. *Time-Critical Decision Making for Business Administration*, University Of Baltimore, from <http://home.ubalt.edu/ntsbarsh/stat-data/Forecast.htm>
- Hyndman, R. J., Koehler, A. B., Snyder, R. D., and Simone G.**, 2002: A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting*, vol.18, no.3, pp.439-454.
- Keleşoğlu Ö., Ekinci C.E., and Fırat A.**, 2005: The Using Of Artificial Neural Networks In Insulation Computations. *Journal of Engineering and Natural Sciences*, vol.3, pp.58-66.
- Kobu, B.**, 1996: Üretim Yönetimi. Avcıol Basım-Yayın, İstanbul.
- Kohonen, T.**, 1987: State Of The Art In Neural Computing. *IEEE First International Conference on Neural Networks*, vol.1, pp.79-90.

- Kohonen, T.**, 1972: Correlation Matrix Memories. *IEEE Transactions on Computers*, vol.21, pp.353-359.
- Kröse, B., and Smagt, P.**, 1996: An Introduction to Neural Networks, 8th.Edition. The University of Amsterdam, Holland.
- Kutay F.**, 1989: Zaman Serilerinde Kestirim Teknikleri ve Box-Jenkins Modelleri. Gazi Üniversitesi Yayınları, Ankara.
- Kutlar, A.**, 2000: Ekonometrik Zaman Serileri Teori ve Uygulama. Gazi Kitabevi, Ankara.
- Mackay, D. J. C.**, 2003: Information Theory, İnference and Learning Algorithms. Cambridge University Press, UK.
- Makridakis, S., Wheelwright S.C., and McGee V. E.**, 1998: Forecasting: Methods and Applications. John Wiley & Sons Inc., USA.
- Mann, P. S.**, 1995: Statistics for Bussiness and Economics. John Wiley & Sons Inc, USA.
- Moon, M., A., Mentzer, J., T., Smith, C., D., and Garver, M., S.**, 1998: Seven Keys to Better Forecasting. *Business Horizons*, vol. 41, no.5, pp.44-52.
- Moon, M., A., Mentzer, J., T., and Smith, C., D.**, 2003: Conducting A Sales Forecasting Audit. *International Journal of Forecasting*, vol. 19, no.1, pp.5-25.
- Mehrotra K., Mohan C.K., and Ranka S.**, 1997: Elements of Artificial Neural Networks. MIT Press, London.
- Minsky, M., and Pappert, S.**, 1969: Perceptrons, An Introduction to Computatioanal Geometry. MIT Press, Cambridge.
- Orr G., Schraudolph N., and Cummins F.**, 1999. CS – 449 Neural Network, Willamette University, from <http://www.willamette.edu/~gorr/classes/cs449/intro.html>
- Önder, E., ve Hasgöl, Ö.**, 2009: Yabancı Ziyaretçi Sayısının Tahmininde Box Jenkins Modeli, Winters Yöntemi ve Yapay Sinir Ağlarıyla Zaman Serisi Analizi. *İstanbul Üniversitesi İşletme İktisadı Enstitüsü Dergisi*, sy.62, syf.42-63.
- Öztemel, E.**, 2003: Yapay Sinir Ağları. Papatya Yayınevi, İstanbul.
- Pardo, R.**, 1992: Design Testing and Optimization of Trading Systems, 1.Basım. John Wiley & Sons Inc, USA.
- Rosenblatt, B.**, 1958: The Perceptron : A Probabilistic Model for Information Storage and Organization in the Brain. *Psychoanalytic Review*, no.65, pp.386 -408.
- Sağıroğlu Ş., Beşdok E., ve Erler M.**, 2003: Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları. Ufuk Kitap Kırtasiye-Yayıncılık, Kayseri.
- Samarasinghe, S.**, 2006: Neural Networks for Applied Sciences and Engineering: From Fundementals to Complex Pattern Recognition. CRC Pres, USA.

- Seaton A.V. and Bennet M. M.**, 1996: Marketing Tourism Products – Concepts, Issues, Cases. International Thomson Business Pres, London.
- Stevenson, W. J.** 2005: Operations Management. McGraw-Hill Irwin, Boston.
- Tang, Z., and Fishwick, P.**, 1993: Feed-Forward Neural Nets as Models for Time Series Forecasting. *ORSA Journal of Computing*, vol.5, no.4, pp. 374-386.
- Tebelkis J.**, 1995. Speech Recognition using Neural Networks, *Thesis (PhD)*, School of Computer Science Carnegie Mellon University, Pennsylvania.
- Tekin, M.**, 1996: Üretim Yönetimi. Arı Ofset Matbaacılık, Konya.
- Tenti, P.**, 1996: Forecasting Foreign Exchange Rates Using Recurrent Neural Networks. *Applied Artificial Intelligence*, vol.10, pp. 567-581.
- Wei, W. W. S.**, 1990: Time Series Analysis: Univariate and Multivariate Methods. Addison-Wesley Publishing Co. Inc., New York.
- Widrow, B., and Hoff, M.E.**, 1960. Adaptive Switching Circuits, *IRE WESCON Convention Record*, IV, pp. 96-104, August.
- Yoon, Y., Swales, G., and Margavio, T.M.**, 1993: A Comparison of Discriminant Analysis Versus Artificial Neural Networks. *Journal of Operational Research*, vol.44, no.1, pp.51-60.
- Yurtoğlu, H.**, 2005. Yapay Sinir Ağları ile Öngörü Modellemesi : Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, *DPT Yayınları*, (DPT-2683), 8, Ankara.
- Zhang, P. G.**, 2003: Neural Networks in Business Forecasting. Idea Group Publishing, USA.

EKLER

EK A : Kullanılan Veriler

Çizelge A.1: Yıllık temizlik kâğıdı üretim miktarı (ton/yıl) (www.skssv.org.tr).

	Üretim Miktarı (ton)	Normalleştirilmiş Değerler
1981	11300	0,106918536
1982	10218	0,104539809
1983	8153	0,1
1984	14934	0,11490772
1985	16789	0,118985853
1986	22543	0,13163576
1987	20119	0,126306706
1988	22660	0,131892979
1989	31669	0,151698856
1990	37452	0,164412518
1991	41520	0,173355831
1992	60462	0,214998956
1993	61008	0,216199312
1994	57774	0,20908951
1995	58466	0,210610841
1996	65377	0,22580436
1997	72199	0,240802216
1998	79098	0,255969354
1999	85311	0,269628351
2000	108394	0,320375276
2001	115597	0,336210744
2002	146015	0,403083332
2003	165714	0,446390687
2004	167868	0,451126158
2005	195472	0,511812296
2006	238438	0,606271091
2007	270668	0,67712728
2008	322500	0,791077572
2009	354205	0,860779572
2010	372045	0,9

Çizelge A.2: Yıllık temizlik kâğıdı ithalat miktarı (ton/yıl) (www.sksv.org.tr).

	İthalat Değerleri (ton)	Normalleştirilmiş Değerler
1981	0	0,10000
1982	0	0,10000
1983	0	0,10000
1984	1370	0,16835
1985	3368	0,26802
1986	950	0,14739
1987	0	0,10000
1988	1430	0,17134
1989	1112	0,15548
1990	1739	0,18675
1991	554	0,12764
1992	862	0,14300
1993	4747	0,33682
1994	4164	0,30773
1995	4014	0,30025
1996	2612	0,23031
1997	2078	0,20367
1998	2424	0,22093
1999	3643	0,28174
2000	5895	0,39409
2001	6145	0,40656
2002	8394	0,51876
2003	11991,68	0,69824
2004	14624	0,82956
2005	12818	0,73946
2006	16036	0,90000
2007	12392	0,71821
2008	7559	0,47710
2009	7840	0,49112
2010	10140	0,60586

Çizelge A.3: Toptan eşya fiyat endeksi (1981=100) değerleri (www.tuik.gov.tr).

	TEFE (1981=100)	Normalleştirilmiş Değerler
1981	100	0,1
1982	136,9	0,100017014
1983	187,2	0,100040206
1984	275,2	0,100080781
1985	391,1	0,100134221
1986	536,2	0,100201124
1987	783,3	0,100315057
1988	1499,8	0,100645422
1989	2545,7	0,101127667
1990	3342,5	0,101495057
1991	5853,2	0,102652694
1992	10658,5	0,104868328
1993	20512,4	0,109411779
1994	41742,8	0,119200722
1995	65126,4	0,129982459
1996	87272,7	0,140193702
1997	156563,2	0,172142273
1998	232233,6	0,207032497
1999	404517,7	0,286469506
2000	543368,0	0,35049077
2001	1038684,8	0,578872169
2002	1282870,6	0,691461717
2003	1304648,4	0,701503051
2004	1361206,1	0,727580732
2005	1281756,2	0,690947859
2006	1596626,9	0,836128922
2007	1458242,4	0,772322386
2008	1629740,5	0,851396963
2009	1628219,5	0,850695683
2010	1735151,4	0,9

Çizelge A.4: Kişi başına düşen yıllık GSYİH değerleri (TL) (www.tuik.gov.tr).

	Kişi Başına GSYİH (TL)	Normalleştirilmiş Değerler
1981	1.158	0,10000
1982	1.170	0,10855
1983	1.198	0,12888
1984	1.247	0,16446
1985	1.268	0,17968
1986	1.327	0,22266
1987	1.422	0,29145
1988	1.421	0,29069
1989	1.394	0,27108
1990	1.487	0,33900
1991	1.472	0,32804
1992	1.531	0,37076
1993	1.624	0,43818
1994	1.508	0,35386
1995	1.588	0,41227
1996	1.671	0,47235
1997	1.803	0,56825
1998	1.830	0,58792
1999	1.720	0,50788
2000	1.761	0,53787
2001	1.601	0,42205
2002	1.704	0,49625
2003	1.775	0,54785
2004	1.904	0,64192
2005	2.037	0,73831
2006	2.134	0,80899
2007	2.251	0,89371
2008	2.237	0,88411
2009	2.101	0,78517
2010	2.259	0,90000

Çizelge A.5: Yıllık genel nüfus değerleri (www.tuik.gov.tr).

	Nüfus (x1000)	Normalleştirilmiş Değerler
1981	45.540	0,10000
1982	46.688	0,13344
1983	47.864	0,16770
1984	49.070	0,20283
1985	50.306	0,23883
1986	51.480	0,27303
1987	52.370	0,29896
1988	53.268	0,32512
1989	54.192	0,35203
1990	55.120	0,37907
1991	56.055	0,40630
1992	56.986	0,43342
1993	57.913	0,46043
1994	58.837	0,48734
1995	59.756	0,51411
1996	60.671	0,54077
1997	61.582	0,56731
1998	62.464	0,59300
1999	63.364	0,61921
2000	64.252	0,64508
2001	65.133	0,67075
2002	66.008	0,69623
2003	66.873	0,72143
2004	67.723	0,74619
2005	68.566	0,77075
2006	69.395	0,79490
2007	70.215	0,81879
2008	71.095	0,84442
2009	72.050	0,87224
2010	73.003	0,90000

Çizelge A.6: Yıllık kent nüfusu değerleri (www.tuik.gov.tr).

	Kentli Nüfus (x1000)	Normalleştirilmiş Değerler
1981	20821	0,10000
1982	22195	0,13160
1983	23626	0,16451
1984	25114	0,19874
1985	26865	0,23901
1986	27877	0,26228
1987	29119	0,29085
1988	30403	0,32038
1989	31728	0,35085
1990	33326	0,38760
1991	34613	0,41720
1992	36111	0,45166
1993	37664	0,48737
1994	39267	0,52424
1995	39987	0,54080
1996	40753	0,55842
1997	41552	0,57679
1998	42574	0,60030
1999	43200	0,61470
2000	44006	0,63323
2001	45555	0,66886
2002	47479	0,71311
2003	48774	0,74289
2004	49876	0,76824
2005	50641	0,78583
2006	51286	0,80067
2007	52482	0,82817
2008	53605	0,85400
2009	54807	0,88165
2010	55605	0,90000

Çizelge A.7: Yıllık okuryazar oranı değerleri (%) (www.tuik.gov.tr).

	Okur-Yazar Oranı (%)	Normalleştirilmiş Değerler
1981	66,9	0,10000
1982	68,8	0,17103
1983	70,1	0,21963
1984	70,9	0,24953
1985	72,4	0,30561
1986	73,2	0,33551
1987	74,4	0,38037
1988	76,5	0,45888
1989	78,1	0,51869
1990	78,4	0,52991
1991	79,9	0,58598
1992	82	0,66449
1993	85	0,77664
1994	84,4	0,75421
1995	85,2	0,78411
1996	85,1	0,78037
1997	85,3	0,78785
1998	85,9	0,81028
1999	86,3	0,82523
2000	86,4	0,82897
2001	86,3	0,82523
2002	87,5	0,87009
2003	88,3	0,90000
2004	87,4	0,86636
2005	88,1	0,89252
2006	88,1	0,89252
2007	87,9	0,88505
2008	86,71	0,84056
2009	87,8	0,88131
2010	88	0,88879

Çizelge A.8: Türkiye’de temizlik kâğıdı yıllık satış miktarı (ton) (www.sksv.org.tr).

	Toplam Satış (ton)	Normalleştirilmiş Değerler
1981	11186	0,117336912
1982	9418	0,112585453
1983	4735	0,100000000
1984	15258	0,128280317
1985	18497	0,136985054
1986	18826	0,137869234
1987	18119	0,135969188
1988	15340	0,12850069
1989	21415	0,144827111
1990	25893	0,156861632
1991	30906	0,170333953
1992	39892	0,194483618
1993	46755	0,212927771
1994	39779	0,194179933
1995	44658	0,207292132
1996	52314	0,227867454
1997	57695	0,242328766
1998	63789	0,258706249
1999	64234	0,259902176
2000	80554	0,303761796
2001	88645	0,325506169
2002	110703	0,38478653
2003	125516	0,424596123
2004	142093	0,469146424
2005	168212	0,539340628
2006	205393	0,639263699
2007	235399	0,719904124
2008	263348	0,79501641
2009	294574	0,878935558
2010	335774	0,900000000

EK B : SPSS 18.0 Program Görüntüleri

Variables Entered/Removed^b

Model	Variables Entered	Variables Removed	Method
1	retim, Okuryazar, ithalat, GSYIH, TEFE, Nfus, Kentli ^a	.	Enter

a. All requested variables entered.

b. Dependent Variable: Satıř

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics					Durbin-Watson
					R Square Change	F Change	df1	df2	Sig. F Change	
1	,999 ^a	,999	,998	3201,53317	,999	2582,274	7	21	,000	2,725

a. Predictors: (Constant), retim, Okuryazar, ithalat, GSYIH, TEFE, Nfus, Kentli

b. Dependent Variable: Satıř

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	1,853E11	7	2,647E10	2582,274	,000 ^a
	Residual	2,152E8	21	1,025E7		
	Total	1,855E11	28			

a. Predictors: (Constant), retim, Okuryazar, ithalat, GSYIH, TEFE, Nfus, Kentli

b. Dependent Variable: Satıř

řekil B.1: Model-1 oklu regresyon program ıktısı.

Variables Entered/Removed ^b			
Model	Variables Entered	Variables Removed	Method
1	üretim, ithalat ^a	.	Enter

a. All requested variables entered.

b. Dependent Variable: Satış

Model Summary ^b										
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics					Durbin-Watson
					R Square Change	F Change	df1	df2	Sig. F Change	
1	,998 ^a	,996	,995	5591,48517	,996	2953,445	2	26	,000	,857

a. Predictors: (Constant), üretim, ithalat

b. Dependent Variable: Satış

ANOVA ^b						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	1,847E11	2	9,234E10	2953,445	,000 ^a
	Residual	8,129E8	26	3,126E7		
	Total	1,855E11	28			

a. Predictors: (Constant), üretim, ithalat

b. Dependent Variable: Satış

Şekil B.2: Model-2 çoklu regresyon program çıktısı.

ÖZGEÇMİŞ

Ad Soyad: Mihriban Yücesoy

Doğum Yeri ve Tarihi: Kırcaali / 30.11.1985

Adres: Emniyetevleri Mah. Çelebi Mehmet Sok. No:13 D:2 Kağıthane / İstanbul

Lisans Üniversitesi: Dokuz Eylül Üniversitesi