

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY SINIR AĞLARI İLE TALEP TAHMİNİ VE GIDA
SEKTÖRÜNDE UYGULANMASI**

MÜZEYYEN TUĞBA BALLI

**YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
ENDÜSTRİ MÜHENDİSLİĞİ PROGRAMI**

**DANIŞMAN
DOÇ. DR. SELİN SONER KARA**

İSTANBUL, 2014

ÖNSÖZ

Bu çalışmada görüş ve önerileriyle katkıda bulunan, yol gösteren, bilgi ve deneyimlerini paylaşan değerli danışman hocam Sayın Doç. Dr. Selin SONER KARA'ya; yüksek lisans eğitimim boyunca göstermiş olduğu desteği, önerileri, bilgi ve deneyim paylaşımları ve rehberliği için Sayın Doç. Dr. Alev TAŞKIN GÜMÜŞ'e teşekkürlerimi sunarım. Endüstri Mühendisliği Bölümü'nde bulunan ve ilk günden beri desteğini esirgemeyen, fikirleri ile bizleri daima ileriye taşıyan hocalarıma teşekkürlerimi bir borç bilirim.

Lisansüstü eğitimim boyunca yüksek lisans bursiyeri olduğum TÜBİTAK'a teşekkürlerimi sunarım.

Çalışmam sırasında, bilgi, deneyim ve yardımlarını esirgemeyen iş arkadaşlarıma ve lisansüstü eğitimim boyunca aynı yolda ilerlediğim arkadaşlarıma teşekkürlerimi sunarım.

Ayrıca, bu günlere başarıyla gelmemde büyük payı olan, tüm lisans ve lisansüstü çalışmam süresince, büyük özverilerde bulunarak bana sabır ve anlayış gösteren sevgili anneme, babama, ablama ve tüm aileme sonsuz teşekkürlerimi sunarım.

Haziran, 2014

M.Tuğba BALLI

İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER	iv
SİMGE LİSTESİ	vii
KISALTMA LİSTESİ	viii
ŞEKİL LİSTESİ.....	ix
ÇİZELGE LİSTESİ	xi
ÖZET	xiii
ABSTRACT	xv
BÖLÜM 1	
GİRİŞ	1
1.1 Literatür Özeti	3
1.1.1 Talep Tahmini Literatür Özeti	3
1.1.2 Yapay Sinir Ağları Literatür Özeti	7
1.2 Tezin Amacı	15
1.3 Hipotez	17
BÖLÜM 2	
ÜRETİM PLANLAMASI VE TEMEL KAVRAMLAR.....	19
2.1 Üretim Planlama ve Kontrol	19
2.2 Tahmin Teorileri ve Tahminleme Yöntemleri	23
2.2.1 Tahmin İlkeleri	25
2.2.2 Tahmin Yönteminin Seçimi	26
2.2.3 Tahminleme Teknikleri	28
2.2.4 Tahmin Maliyetleri	29
2.2.5 Talep Tahmini	30
2.2.5.1 Talep Tahminlerinin Sınıflandırılması (Tahmin Dönemleri) ...	31
2.2.5.2 Talep Tahmini İlke ve Yöntemleri.....	34
2.2.5.3 Talep Araştırmasında Yapılacak İşlemler.....	35
BÖLÜM 3	
TALEP TAHMİNİ.....	37
3.1 İstatistiksel Yöntemlerle Talep Tahmini	37
3.1.1 Regresyon Analizi Yöntemi	40
3.1.2 Korelasyon Yöntemi.....	41

3.1.3	Zaman Serileri Analizine Dayanan Talep Tahmin Yöntemleri.....	43
3.1.3.1	Basit Ortalamalar Yöntemi	45
3.1.3.2	Son Dönem Talebi Yöntemi	45
3.1.3.3	Hareketli Ortalamalar Yöntemi	45
3.1.3.4	Ağırlıklı Ortalama Yöntemi.....	46
3.1.3.5	Ağırlıklı Hareketli Ortalama Yöntemi.....	47
3.1.3.6	Üssel Düzeltme Yöntemi	47
3.1.3.7	Box-Jenkins Yöntemi	48
3.1.3.8	Otoregresif Hareketli Ortalamalar (AR-MA) Yöntemi	48
3.1.3.9	Otoregresif Bütünleşik Hareketli Ortalamalar (ARIMA) Yöntemi	49
3.1.4	Simülasyon (Benzetim) Yöntemiyle Talep Tahmini.....	49
3.2	Yapay Sinir Ağları Yöntemiyle Talep Tahmini.....	51

BÖLÜM 4

YAPAY SİNİR AĞLARI.....	52
4.1 Yapay Sinir Ağı Tanımları.....	52
4.2 Yapay Sinir Ağlarının Genel Özellikleri.....	54
4.3 Yapay Sinir Ağlarının Tarihçesi	57
4.4 Yapay Sinir Ağları Yönteminin Diğer Yöntemlerle Karşılaştırılması...	58
4.5 Yapay Sinir Ağlarının Avantajları	62
4.6 Yapay Sinir Ağlarının Dezavantajları	63
4.7 Yapay Sinir Ağlarının Uygulama Alanları	65
4.8 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları	68
4.8.1 Yapay Sinir Ağlarının Yapısı	68
4.8.2 Yapay Sinir Ağlarının Temel Elemanları.....	70
4.8.2.1 Biyolojik Sinir Hücreleri	70
4.8.2.2 Yapay Sinir Hücreleri	72
4.8.2.3 Biyolojik Sinirler ile Yapay Sinirlerin Karşılaştırılması	75
4.8.3 Yapay Sinir Ağlarının Sınıflandırılması (YSA Mimarileri).....	77
4.8.3.1 İleri Beslemeli Yapay Sinir Ağları	78
4.8.3.2 Geri Beslemeli Yapay Sinir Ağları	79
4.8.3.3 Geri Beslemeli Geri Yayılmalı Sinir Ağları	80
4.8.4 Yapay Sinir Ağlarının Temel Öğrenme Kuralları	81
4.8.4.1 Hebb Öğrenme Kuralı.....	82
4.8.4.2 Hopfield Öğrenme Kuralı	83
4.8.4.3 Delta Öğrenme Kuralı.....	83
4.8.4.4 Kohonen Öğrenme Kuralı.....	83
4.8.4.5 Basit Algılayıcı (Perseptron) Öğrenme Kuralı	84
4.8.4.6 Delta Öğrenme Kuralı (Windrow-Hoff) Kuralı.....	84
4.8.4.7 Gözetimli (Öğretmenli) Öğrenme Yöntemi.....	87
4.8.4.8 Gözetimsiz (Öğretmensiz) Öğrenme Yöntemi	88
4.8.4.9 Destekleyici Öğrenme.....	89
4.9 Yapay Sinir Ağlarının Geliştirilmesi ve Eğitilmesi	89
4.10 Tahminin Hata Testi.....	99

BÖLÜM 5

YAPAY SİNİR AĞLARI KULLANILARAK ÜRÜN TALEP TAHMİNİ UYGULAMASI.....	102
--	-----

5.1	Uygulamada Ele Alınan Şarküteri Ürünleri	102
5.2	ABC Analizi ile Ürün Grubu Seçimi	103
5.3	Yapay Sinir Ağları ile Yöntemiyle Sucuk Grubu Ürün Talep Tahmini Uygulaması	105
5.3.1	Tahmin Sürecinin Tasarımı	105
5.3.2	Veri Setinin Hazırlaması	108
5.4	Yapay Sinir Ağı Modelinin Kurulması ve Uygulama.....	116
5.4.1	Modelin Tasarımı	116
5.4.2	Yapay Sinir Ağı ile Talep Tahmini Uygulaması	117
5.4.3	Yapay Sinir Ağı Tahmin Sonuçları	137
5.4.4	Gerçekleşen Talep ile Tahminlenen Talebin Karşılaştırılması	141
5.4.5	Modelde Üretilen Talep Tahminlerinin Hata Testleri	142
5.4.6	Gerçekleşen Talepler ile Yapay Sinir Ağı Modeli ve Diğer Tahminlerin Karşılaştırılması	145
5.4.7	Uygulama Sonuçlarının Değerlendirilmesi	146
 BÖLÜM 6		
SONUÇ VE ÖNERİLER.....		149
KAYNAKÇA		156
EK-A.....		163
ÖZGEÇMİŞ		165

SİMGE LİSTESİ

x	Ağa girilen değerler
$\checkmark$	Çıktı değeri
B	Beklenen değerler
w	Girdilerin ağırlıkları
ϕ	Eşik değeri
λ	Öğrenme katsayısı
α	Düzeltilme katsayısı
r	Korelasyon katsayısı
$x(t)$	Tahmini değeri
$f(t)$	Gerçekleşen değeri
$e(t)$	Basit hata
$p(t)$	Tahminin hata yüzdesi
R^2	Regresyon katsayısı
X_{ij}	i ürününden j vardiyasında gerçekleştirilen üretim miktarı
C_i	i . 'nci ürün çeşidinin birim maliyeti (işçilik, üretim ve stok maliyeti toplamı)
T_i	i . 'nci ürün çeşidinin planlanan dönemde müşterinin talep ettiği ürün miktarı
M_j	j . 'inci vardiyanın üretim kapasitesi
S_i	i . 'nci ürününden tutulabilecek stok miktarı
i	Ürün çeşidi
j	Vardiya sayısı
(f)	Gerçekleşen talep
(x)	Tahminlenen talep
(e)	Sapma miktarı
(p)	Yüzde hata
$ p $	Yüzde mutlak hata

KISALTMA LİSTESİ

ANN	Artificial Neural Networks
AE	Mutlak Hata
ARIMA	Otoregresif Bütünleşik Hareketli Ortalamalar
ARMA	Otoregresif Hareketli Ortalamalar
ART	Adaptive Resonance Theory
BM	Bulanık Mantık
ÇKA	Çok Katmanlı Algılayıcı
EKK	En Küçük Kareler
ERP	Enterprise Resource Planning
GA	Genetik Algoritmalar
GHSYA	Genetik Hücresel Yapay Sinir Ağı
GRNN	Genelleştirilmiş Regresyon Sinir Ağı
LQV	Sayısallaştırılmış Öğrenme Vektörü
MAPE	Ortalama Mutlak Yüzde Hata
MLP	Çok Katmanlı Perseptron Sinir Ağı
MSE	Ortalama Hata Kareleri
PNN	Probablistic Neural Networks
PPP	Purchasing Power Partiy
RBF	Radial Basis Function
SC	Tedarik Zinciri
TH	Toplam Hata
US	Uzman Sistem
VLSI	Büyük Ölçekli Bütünleşmiş Devre
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

	Sayfa
Şekil 1.1 Literatür özeti	37
Şekil 1.2 Literatür özeti (devamı).....	15
Şekil 1.3 Literatür özeti (devamı).....	15
Şekil 2.1 Üretim planlama ve kontrol faaliyetleri	22
Şekil 2.2 Tahmin maliyetleri grafiği.....	29
Şekil 3.1 Büyüme eğilimi ve mevsimsel talep eğrilerinin gösterimi.....	39
Şekil 3.2 Regresyon doğrusu	41
Şekil 3.3 Korelasyon katsayısı eğrisi.....	42
Şekil 3.4 Korelasyon katsayısının yorumlanması.....	43
Şekil 3.5 Zamana göre çeşitli talep düzenleri.....	44
Şekil 4.1 Yapay sinir ağları ile geleneksel yöntemlerin işlem süreci olarak karşılaştırılması.....	79
Şekil 4.2 Yapay sinir ağlarının kara kutu benzetimi	68
Şekil 4.3 Yapay sinir ağları yapısı blok gösterimi.....	69
Şekil 4.4 Yapay sinir ağları işlem süreci	70
Şekil 4.5 Biyolojik sinir hücresi	71
Şekil 4.6 Sinir sisteminin blok gösterimi.....	71
Şekil 4.7 Yapay sinir hücrelerinin matematiksel yapısı	73
Şekil 4.8 Yapay sinir ağları mimarileri	77
Şekil 4.9 İleri beslemeli yapay sinir ağları	78
Şekil 4.10 İleri beslemeli çok katmanlı yapay sinir ağları.....	79
Şekil 4.11 Geri beslemeli yapay sinir ağları	79
Şekil 4.12 Geri beslemeli geri yayılmalı sinir ağı modeli mimarisi	80
Şekil 4.13 Gözetimli öğrenme yöntemi	88
Şekil 4.14 Gözetimsiz öğrenme yöntemi.....	88

Şekil 4.15 Destekleyici öğrenme yapısı.....	89
Şekil 4.16 İleri beslemeli bir sinir ağının eğitim ve test aşamaları.....	95
Şekil 4.17 Yapay sinir ağlarının öğrenme eğrisi	96
Şekil 4.18 Öğrenmenin hata uzayındaki gösterimi	97
Şekil 4.19 Çok boyutlu hata uzayı	97
Şekil 4.20 Verileri ezberleyen ve iyi genellemeye ulaşan ağlardaki hata eğrileri.....	99
Şekil 4.21 Tahminler için kontrol sınırları	101
Şekil 5.1 ABC analizi grafik örneği	104
Şekil 5.2 ABC analizi grafiği.....	105
Şekil 5.3 Yapay sinir ağları talep tahmini süreci akış şeması	107
Şekil 5.4 Birinci ürün grubu veri analizi	117
Şekil 5.5 Veri seti dağılımı	118
Şekil 5.6 Ağ mimarisi arama ayarları	125
Şekil 5.7 En İyi Ağ Yapısı.....	145
Şekil 5.8 Öğrenme algoritmaları.....	129
Şekil 5.9 Eğitim sonuç özeti	131
Şekil 5.10 Eğitim sonuç grafiği	132
Şekil 5.11 Doğrulama sonuç özeti	133
Şekil 5.12 Doğrulama grafiği	133
Şekil 5.13 Test sonuçları özeti.....	134
Şekil 5.14 Test grafiği.....	135
Şekil 5.15 Eğitim, doğrulama ve test sonuçları özeti	137
Şekil 5.16 Eğitim, doğrulama ve test grafiği	137
Şekil 5.17 Manuel Sorgu	138
Şekil 5.18 Ürün gruplarına göre aşama değerleri	139
Şekil 5.19 Gerçekleşen talep ve tahminlenen talebin karşılaştırılması.....	142

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2.1 Planlama dönemleri ve kullanım amaçları	32
Çizelge 3.1 Korelasyon katsayısı değerleri ve yorumlamaları	42
Çizelge 4.1 Yapay sinir ağları ve geleneksel talep tahmin metotlarının karşılaştırılması	59
Çizelge 4.2 Uzman sistemler ve yapay sinir ağlarına karşılık gelen elemanlar	61
Çizelge 4.3 Uzman sistemler ve yapay sinir ağları arasındaki farklılıklar	61
Çizelge 4.4 Biyolojik sinirler ile yapay sinirlerin karşılaştırılması	76
Çizelge 4.5 Biyolojik sinir hücresi ile yapay sinir hücresinin karşılaştırılması	76
Çizelge 4.6 Ağ türleri ve başarılı oldukları alanlar	91
Çizelge 4.7 Uygulama tipleri ve kullanılabilir yapay sinir ağları	92
Çizelge 5.1 ABC analizi özet tablosu	104
Çizelge 5.2 Aylık satış miktarı verileri	109
Çizelge 5.2 Aylık satış miktarı verileri (devamı)	110
Çizelge 5.3 Aylık ortalama satış fiyatı verileri	111
Çizelge 5.3 Aylık ortalama satış fiyatı verileri (devamı)	112
Çizelge 5.4 Rakip firma sayısı	112
Çizelge 5.4 Rakip firma sayısı (devamı)	113
Çizelge 5.5 Aylık satış yapılan müşteri sayısı	114
Çizelge 5.5 Aylık satış yapılan müşteri sayısı (devamı)	115
Çizelge 5.6 Özel tarih verileri	115
Çizelge 5.7 Normalizasyon değerleri	119
Çizelge 5.7 Normalizasyon değerleri (devamı)	120
Çizelge 5.8 Aylık satış miktarı normalizasyon verileri	121
Çizelge 5.8 Aylık satış miktarı normalizasyon verileri (devamı)	122
Çizelge 5.9 Aylar için normalizasyon	123

Çizelge 5.9 Aylar için normalizasyon (devamı)	124
Çizelge 5.10 Özel günler için normalizasyon	124
Çizelge 5.10 Özel günler için normalizasyon (devamı)	125
Çizelge 5.11 Yapay sinir ağları uygunluk değerleri	126
Çizelge 5.11 Yapay sinir ağları uygunluk değerleri (devamı).....	127
Çizelge 5.12 Önem yüzdeleri	128
Çizelge 5.13 Eğitim algoritma sonuçları	129
Çizelge 5.13 Eğitim algoritma sonuçları (devamı).....	130
Çizelge 5.14 Eğitim sonuçları	130
Çizelge 5.14 Eğitim sonuçları (devamı)	131
Çizelge 5.15 Doğrulama sonuçları	132
Çizelge 5.16 Test sonuçları.....	134
Çizelge 5.17 Uygulama değerleri	135
Çizelge 5.17 Uygulama değerleri (devamı).....	136
Çizelge 5.18 Birinci ürün grubu için yapılan talep tahmin sonuçları	138
Çizelge 5.19 İkinci ürün grubu için yapılan talep tahmin sonuçları.....	139
Çizelge 5.20 Üçüncü ürün grubu için yapılan talep tahmin sonuçları.....	140
Çizelge 5.21 Dördüncü ürün grubu için yapılan talep tahmin sonuçları	140
Çizelge 5.22 Beşinci ürün grubu için yapılan talep tahmin sonuçları	140
Çizelge 5.22 Beşinci ürün grubu için yapılan talep tahmin sonuçları (devamı).....	141
Çizelge 5.23 Gerçekleşen talep ve tahminlenen talep verileri.....	141
Çizelge 5.23 Gerçekleşen talep ve tahminlenen talep verileri (devamı)	142
Çizelge 5.24Talep tahminin hata testleri Excel çözümü	143
Çizelge 5.24 Talep tahminin hata testleri Excel çözümü (devamı).....	144
Çizelge 5.25 Model tarafından yapılan talep tahmininin hata ve güvenilirlik sonuçları	145
Çizelge 5.26 Talep tahmin yöntemlerinin karşılaştırılmalı hata analizi	146

ÖZET

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ VE GIDA SEKTÖRÜNDE UYGULANMASI

Müzeyyen Tuğba BALLI

Endüstri Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Doç. Dr. Selin SONER KARA

İşletmeler, mevcut durumlarını koruyabilmek ve geliştirebilmek için olayları doğru anlayabilmeli ve iyi bir plan çerçevesinde uygun çözümler üretmelidirler. Artan rekabet ortamında şirketlerin gelecek için güvenle yol alabilmeleri tahminlerindeki doğruluk ve tutarlılıkla paraleldir. Bu doğrultuda talep tahminleri tüm işletmeler için hayati önem taşımaktadır. Tahminin amacı işletmelerin gelecekte karşılaşılabilecekleri durumları önceden öngörmek, çeşitli veri ve teknikleri kullanarak önceden önlemler alınmasını sağlamaktır. Talep tahmini, gelecekteki bir zaman süresi için şirketin bir ürünü veya çeşitli ürünleri için talep düzeyini tespit etmektir.

İşletmeler için kritik öneme sahip olan talep tahmininde kullanılan birçok yöntem bulunmaktadır. Yapay sinir ağları, doğrusal olmayan problemlerin çözümünde etkin olarak kullanılan ve oldukça güvenilir sonuçlar sunan istatistiksel bir yöntemdir. Bu yöntemin talep tahminlerinde kullanımını gittikçe yaygınlaştırmıştır.

Çalışmada istatistiksel talep tahmin tekniklerinden yapay sinir ağı modeli kullanılarak, hızlı tüketim sektörü olan taze gıda sektöründe, şarküteri grubu ürünlerine ait talep tahmini uygulaması yapılmıştır. Uygulama sonrası yapılan hata testleri sonucuna göre, modelin yaptığı tahminlerin güvenilir ve tutarlı olduğu gözlenmiştir. Yapay sinir ağı

yöntemi dışında başka yöntemlerle de talep tahmini yapılmış ve yapay sinir ağlarının mevcut yöntemlerden üstün olduğu gösterilmiştir.

Yapılan bu çalışma ile, taze gıda sektörlerinden biri olan şarküteri sektöründeki diğer firmalara talep tahmini konusunda bir örnek sunulmaktadır.

Anahtar Kelimeler: Talep tahmini, yapay sinir ağları, hata testleri, gıda sektörü

ABSTRACT

DEMAND FORECASTING WITH ARTIFICIAL NEURAL NETWORKS AND IMPLEMENTATION IN THE FOOD INDUSTRY

Müzeyyen Tuğba BALLI

Department of Industrial Engineering

MSc. Thesis

Adviser: Assoc. Prof. Dr. Selin SONER KARA

Companies should understand the events correctly and produce appropriate solutions within the framework of a good plan to protect and develop their current situation. For companies, the possibility of surviving is parallel with the accuracy of these predictions in increasing competition environment. According to this idea, demand forecast has vital importance for all companies. The purpose of the forecast is to predict situations companies may face in the future, using different data and techniques and take action in advance. Demand forecasting is to determine the demand level of a product or some products of a company for a specific time in the future. There are many methods used to forecast demand which are critical for companies. Artificial neural networks are a statistical methods which are efficiently used in solution of nonlinear problems and providing highly reliable results. Use of this method has increasingly spread in the demand forecasting.

In this study, demand forecasting practice is made on delicatessen products from fresh food industry in FMCG industry using artificial neural network model. According to error test results, it has been observed that the forecasts of the model are reliable and consistent. Demand forecasts are prepared with also other methods and the results are compared. It's been shown that artificial neural networks is above existing methods. This study presents an example of demand forecast for other firms in the delicatessen fresh food industry.

Keywords: Demand forecasting, artificial neural networks, error tests, food industry

BÖLÜM 1

GİRİŞ

Üretim, doğada var olan çeşitli faktörlerin insanların gereksinimlerini karşılayacak ürün ve hizmetlere dönüştürülmesi faaliyetlerinin bütünü olarak tanımlanabilmektedir. Üretilen ürünlerin istenilen miktar, kalite, zaman ve maliyet faktörlerinin belirlenmesi bir planlı bütün halinde incelenmekte olup, üretim yönetiminin konusunu oluşturmaktadır. Üretim yönetimi fonksiyonlarının en önemlilerinden birisi planlama fonksiyonudur. İşletmeler karar süreçlerinde hızlı ve başarılı olabilmek için bir sisteme ve planlamaya ihtiyaç duyarlar.

Üretim planlaması, işletmelerin amaçları doğrultusunda, üretim alt sistemleri organizasyonu, üretim politikaları, üretim programları ve üretimle ilgili gerekli tüm işlemlerin planlanmasıdır. Üretim planlaması sürecinde, üretimi yapılacak olan ürünün talep durumu dikkate alınarak, tüketicilerin istediği ürün özellikleri, fiyat, kalite ve ürün miktarları ile ilgili bilgiler toplanarak, gerekli değerlendirmelerin yapılması gerekmektedir. Üretim planlaması yapılırken, tüketici taleplerinde meydana gelen değişiklikler sürekli takip edilmeli, tüketici taleplerine uygun üretim yapılmalıdır. Üretim planlamasının amacı önceden belirlenen üretim hedeflerine ulaşmak olduğundan, mevcut satış olanaklarından faydalanmak ve kaynakları en uygun şekilde kullanmak üzere planlar yapılmalıdır. Bunun için üretimi yapılacak ürüne ait talep tahminlerinin yapılması çok önemlidir. Çünkü üretilmesi düşünülen ürüne ne kadar talep olacağı bilinmeden, herhangi bir planlamaya faaliyeti gerçekleştirilemez.

Stratejik ve işlemsel kararların verilmesinde uzun, orta ve kısa süreli tahminlerden yararlanılmaktadır. Tahminlerin doğruluğu işletmeler açısından çok önemlidir ve bunların sağlıklı olabilmesi için, bilimsel çalışma temellerine dayandırılmaları gerekmektedir. Tahmin, geçmiş dönemlerde meydana gelmiş olayların sonuçlarını

değerlendirerek gelecek dönemlerde meydana gelebilecek olayların sonuçlarını önceden görebilmektir. Tahminler esas alınarak, mevcut olanak ve işgücü çerçevesinde personel, malzeme ve kapasitenin yer aldığı bir üretim programı hazırlanacağından, bu tahminlerin gerçeğe en yakın şekilde, işletme amaçlarına ve durumuna uygun yapılması gerekmektedir. Tahminler olmadan planlama ve kontrol, etkili bir şekilde yapılamaz [1].

Talep tahmini, şirket ve yönetiminin stratejik ve taktik kararlarda, kısa, orta ve uzun dönemli hedeflere ulaşmada kullanılan en temel faaliyettir. Etkin bir talep tahmini ile işletme fonksiyonları minimum maliyet ile optimum kar seviyesine doğru ilerlerken, stratejik ile operasyonel gereksinimler arasındaki çatışma azalır.

İşletmelerin temel amacı, piyasada ürünlere olan talebini karşılamak üzere ürün ve hizmet üretmek ve pazarlamak olduğundan, işletmeler tüketici talebini karşılamak amacıyla faaliyette bulunurlar. Talep tahmini ise, işletmenin üretmiş olduğu mal ve hizmetlere olan talebin, gelecek dönemler için tahmin edilmesidir. Hammaddeler, yedek parça, yarı mamul, makine, insan gücü ve yatırım ihtiyaçlarının saptanmasında temel veri talep tahminleridir. Üretim işletmelerinde yapılacak çalışmaların tamamının oluşan talep miktarına bağlı olması, talep tahmininin önemini ortaya koymaktadır.

Talep tahminlerinin yapılması sırasında kullanılan çok sayıda mevcut yöntem bulunmaktadır. Bilgisayarlar üzerinde yapılan uzun süreli çalışmalar, zamanla insan beynini modelleme ve yapay zeka modelini yaşamımıza sokmuştur. Bunu izleyen çalışmalar, son yıllarda talep tahminlerinde etkin olarak kullanılan yapay sinir ağları adı verilen yeni bir metodu ortaya çıkarmıştır.

Yapay sinir ağları, insanların sezgi ve deneyime dayalı tahmin yeteneğinin bilgisayar ortamında modellenmesi sonucu ortaya çıkmıştır. Yapay sinir ağları modeli, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan otomatik olarak gerçekleştirebilmektedir. Modelin bu üstün yeteneklerinden dolayı, doğrusal olmayan problemlerin çözümünde etkin olarak kullanılması ve oldukça güvenilir sonuçlar sunması, günümüzde metodun kullanımını gittikçe yaygınlaştırmıştır.

Yapay sinir ağları modelinin neredeyse tüm alanlarda kullanılmakta olması ve tahmin modellemesi için geliştirilen en yeni yöntemlerden birisi olmasına rağmen, bu alanda Türkiye'deki çalışmalara dünya literatürüne göre daha az rastlanmaktadır. Ülkemizde de araştırmacıların yapay sinir ağları üzerinde yoğunlaşmaları ve bu yöntem ile

sınıflandırma, tahmin, veri kavramlaştırma ve kontrol problemlerinin çözümü gibi daha birçok konuda çözümler geliştirmeleri, ülkemiz bilimine önemli katkılar sağlayacaktır. Ayrıca daha yeni mimarilerin geliştirilmesi, bulanık mantık ve genetik algoritmalar yardımıyla yapay sinir ağı yönteminin daha da iyileştirilmesi konusunda da çalışmalar yapılması, yine önemli katkılar sağlayabilecektir.

1.1 Literatür Özeti

Literatür özeti, talep tahmini literatür özeti ve yapay sinir ağları literatür özeti olmak üzere iki bölümde incelenmiştir.

1.1.1 Talep Tahmini Literatür Özeti

Talep tahmini, yönetim bilimi, üretim planlaması ve kontrolü gibi birçok alanda kullanılan ve işletmeler için stratejik anlamda oldukça önemli bir konudur. Talep tahmini, üretim, envanter yönetimi, tedarikçi koordinasyonu, nakliye, dağıtım, yenileme, ambalajlama, bakım-onarım, birçok iş operasyonunda geniş bir yelpazede kullanılmaktadır [2], [3]. Etkili kullanıldığında talep tahmini, şirketlerin ya da tedarik zincirlerinin değişen pazar şartlarına kolayca ayak uydurabilmelerine ve operasyonda kolaylık sağlanabilmesine yardımcı olur [4], [5], [6], [7].

Talep tahmini konusunda önemli gelişmeler 1960'lı yıllardan itibaren yaşanmakta olup bu konuda her geçen gün daha yeni metotlar denenmektedir. Günümüze kadar geçen süreçte yaşanan bu gelişmelerin en azından bir kısmını yansıtmak üzere, yurt içinde ve yurt dışında istatistiksel yöntemlerle yapılan talep tahmini çalışmalarından bazıları aşağıda özetlenmiştir.

Kirby [8], kısa ve orta periyotlu istatistiksel talep tahmin metotlarının karşılaştırmasını yapmıştır. IBM 7094 model bilgisayar kullanılarak yapılan Singer dikiş makinesi üretimi uygulamasında, beş farklı ülkeden alınan farklı dikiş makinelerine ait 7,5 yıllık satış verilerinden oluşan 23 farklı seri kullanılarak bir talep tahmini yapmıştır. Çalışmada, üstel düzeltme, hareketli ortalamalar ve zaman serileri analizinde, en küçük kareler yöntemleri kullanılmıştır. Çalışma sonucunda trend analizi ve mevsimsellik içeren üstel düzeltme yönteminin daha iyi sonuçlar ürettiği sonucuna varılmıştır. Çalışmada, tahmin doğruluğunun, verilerin özelliklerine ve tahminin yapıldığı zaman dilimine (kısa-orta-uzun süreli) göre değiştiği tespit edilmiştir.

1960-1969 yılları arasındaki verileri ile İngiltere pazarındaki otomobil talebi, üstel düzeltme ve hareketli ortalamalar yöntemi ile tahmin edilmiştir. Tahminin yapılabilmesi için iç pazardaki toplam otomobil üretimi, ihracat için toplam otomobil üretimi ve yeni kayıt olmuş otomobillerin verileri kullanılmıştır.

Bhattacharya [9], Avusturalya’da Matematik ve İstatistik Bölümü’nde yapılan bir yüksek lisans tezinde doğrusal regresyon ve hareketli ortalamalar yöntemleri kullanılarak telefon talebi tahmini yapmıştır.

Carlson ve Umble [10], Amerika’da, standart ve lüks otomobil kategorisinde beş farklı tür otomobilin, gelecek beş yıllık talep tahminini belirlemek üzere yaptığı araştırmada, tahmin tekniği olarak çoklu regresyon analizi yöntemi kullanılmıştır. Çalışmada, tüketici gelirleri, otomobil fiyatları, benzin fiyatları, benzin kıtlığının piyasaya etkileri ve Amerikan otomotiv sanayi işçilerinin grevlerinin, talebi etkileyen faktörler olduğu tespit edilmiştir.

Akbay vd. [11], yapmış oldukları Türkiye’deki gıda ürünlerine olan talebin tahmini çalışmasında, kalitatif bir talep tahmin modeli olan Tobit modeli ile bir tahmin çalışması yapmışlar ve sonucunda konsantre meyve suyu üreten firmalar için önemli bilgiler sağlamışlardır. Bu bilgiler ışığında, firmalar pazar taleplerini artırmak istediklerinde, yoğunlaşmaları gereken tüketici yaş grubunun 12-17 arasında olması gerektiği ve özellikle eğitim düzeyi yüksek olan annelerin, ürüne olan olumsuz tutumlarının değiştirilmesi gerektiği ortaya çıkmıştır.

Gavcar vd. [12], yaptıkları bir araştırmada, SEKA kağıt fabrikasında üretilen sekiz farklı kağıt ürününe gelecekte olması muhtemel talebin tahminini yapmışlardır. Çalışmada kağıt talebini etkilediği kabul edilen; kağıt ürünleri ve basım sanayisine ait toplam eşya fiyat endeksi, ithalat ve ihracat miktarları, Gayri Safi Milli Hasıla ve nüfus faktörleri dikkate alınmıştır. Tahminler, çoklu regresyon analizi ile yapılmış ve değişkenler arasındaki ilişki, korelasyon analiziyle belirlenmiş ve kağıt-karton türlerinin 2000 yılına talep tahminleri yapılmıştır.

Chen [13], turizm ve eğlence sektörüne olan talebi belirlemek üzere, Amerikan Kuzey Carolina Devlet Üniversitesi’nde bir doktora tez çalışması yapmıştır. Çalışmada, Amerikan milli parklarından üç tanesi örnek olarak seçilmiş ve bu parklardan elde edilen, ziyaretçi sayıları gibi verilerle talep tahminleri yapmıştır. Çalışmada istatistiksel tahmin yöntemlerinden ARIMA (Otoregresif Bütünleşik Hareketli

Ortalamalar) metodu ile diğer istatistiksel metotlar karşılaştırılmış ve ARIMA metodunun diğer metotlara göre daha doğru tahminler ürettiği, hem yıllık hem de mevsimsel verilere göre yapılan tahminlerde yüksek performans sergilediği gözlenmiştir.

Armstrong vd. [14], talep tahmini için karşılaştırmayı sağlayan ekstrapolasyon yöntemini seçmişlerdir. Geçmiş satışların ekstrapolasyonunu sağlayan bu yöntemi seçmelerindeki amaç, yöneticilerin geçmiş satış bilgilerine sahip olmaları, zaman serileri ile tahmin yapabilmeleri, yöntemin kolay anlaşılır ve kullanışlı olmasıdır.

ZhoumcMahon vd. [15], zaman serileri analizi metodunu kullanarak Avustralya su tedarik sisteminin Melbourne şehri bölgesine ait altı yıllık günlük su tüketim verilerini kullanarak gelecekteki su talebini tahmin etmişlerdir.

Cahow [16], yaptığı çalışmada, evde tedavi edilen kronik hastalara bakan hemşirelere olan talebi, Çoklu Regresyon ve Monte Carlo simülasyon metotlarını kullanarak tahmin etmiştir. Çalışmada kullanılan sağlık ve emeklilik anketlerinden elde edilen verilerle yapılan tahmin sonuçlarına göre, 2025 yılına kadar Amerika’da bu hizmete olan ihtiyaç hızla artması beklenmektedir.

Satır ve Köksal [17], entegre tavuk üretimi yapan bir organizasyonun finansal planlaması için yaptıkları talep tahmini çalışmasında, geçmiş iki senelik verileri kullanılarak organizasyonun ürettiği 90 çeşit ürün için zaman serisi analizi metotlarından ARIMA modeli ile bir talep tahmini uygulaması yapmışlardır. Çalışma sonuçlarına göre, model tatmin edici bulunarak bazı küçük düzenlemelerle diğer entegre tavuk üretimi organizasyonlarında da kullanılarak yaygınlaştırılabileceği ileri sürülmüştür.

Matuyama vd. [18], envanter seviyesinin belli olduğu, ancak talebin kesin olmadığı durumlar için yaptıkları çalışmada iki farklı geribildirim politikasıyla iki farklı tahmin formülü kullanarak, envanter sistemine periyodik bir bakış geliştirmişlerdir. Periyot boyunca envanter seviyesindeki değişimi göz önüne alarak, fark eşitliğiyle sipariş miktarını belirleyebilmişlerdir. Çalışmadan çıkan sonuca göre, yakın gelecekte talep yaklaşık olarak beklenen değerde ise geribildirim önem kazanmaktadır. Buna karşılık talep tam olarak beklenen değerde ise geribildirim önemi de azalmaktadır.

Fildes vd. [2], yaptıkları çalışmada herhangi bir bilgisayar tabanlı tahminin ardından çıkan sonuçların tahmin ve planlama uzmanlarının eleştirel ve iyileştirici müdahaleleri

ile hata oranının azalıp azalmadığını tespit etmeye çalışmışlardır. İsbetli tahmin yapabilme konusunda, sistemin hazırladığı veriler ile uzman görüşlerine dayanan tahmin hipotezlerini irdelemişlerdir. Çalışmada dört tedarik zinciri şirketi incelenmiş ve bilgisayar sistemleriyle belirlenen tahmin üzerine, daha etkin bir uzman iyileştirilmesinin nasıl yapılabileceğini tespit etmeye çalışmışlardır. Çalışma sonunda zaman görüşünün etkinliğinin firmanın hizmet verdiği sektör ve iyileştirmeyi yapan takımın başarısına bağlı olduğu sonucuna ulaşılmıştır.

Avcı [19], yaptığı çalışmada, yapay sinir ağı modeli ile IMKB-30 endeksi içinden seçilmiş bazı hisse senetlerinin günlük getirilerinin tahminlemesini yapmıştır. Çalışma bulguları, yapay sinir ağları modelinin hisse senedi getirileri tahmininde etkili ve yararlı olduğunu göstermiştir.

Tsai vd. [20], Tayland'daki medikal turizm talebi ve yabancı hastalardan elde edilecek gelirlerin tahmini çalışmasında, yeni geliştirdikleri bir istatistiksel model ile zaman serisi modelinin tahmin performanslarını karşılaştırmışlardır. Sonuçlar geliştirilen yeni modelinin hata üretme olasılığı yönünden, zaman serisi analizi modelinden daha iyi performansa sahip olduğunu göstermiştir. Araştırma, uluslararası medikal turizm yöneticileri için önemli karar öngörülerini sağlamıştır.

Xu vd.,[21], doğal afetlerden sonra acilen ihtiyaç duyulacak malzemelerin talep tahmini üzerine yaptıkları çalışmada; doğal afetlerden hemen sonraki ilkyardım sürecinde ihtiyaç duyulan malzemelerin tahmininde lineer regresyon, ARIMA gibi geleneksel istatistiksel ve ekonometrik metotları kullanmışlardır. Bu çalışma, 2008'deki Çin kış fırtınasından sonraki afet döneminde, tarımsal ürün talep tahmininde kullanılarak başarılı sonuçlar elde edilmiştir.

Griffiths vd. [22], regresyon modeli ile yerel buğday verimliliği tahmin çalışmasında, batı Avustralya'daki 5 farklı eyaletten elde ettikleri verileri kullanarak bazı belirsizliklerin tahminini yapmışlardır. Sezon boyunca yağın yağmurlar, buğday ürününün yetişmesinin temel belirleyicisi olduğundan, tahmin çalışması için geçmiş dönemlere ait bu yağış bilgileri toplanmış ve Regresyon modeliyle tahminleme çalışması yapılmıştır. Sun vd.,[23], son yıllarda turizm piyasasında pazar payı hızlı bir şekilde büyüyen gemi turu endüstrisinin, müşteri talep tahmini çalışmasını yapmışlardır. Uygulama sonuçları, bazı belirsizliklere rağmen tahminlerin oldukça tutarlı ve güvenilir olduğunu göstermiştir.

Yukarıdaki örneklere ek olarak; Amerikan donanmasında regresyon analizi ile bakım-onarım parçalarının talep tahmini yapılmıştır. Hong Kong'a Japon turistlerin seyahat taleplerinin tahmini üzerine çalışılmıştır. Amerika'da birleşik perakende satışlarının zaman serileri analizinde çoklu regresyon kullanımı ile tahmin ve yapay sinir ağları ile yapılan tahminlerle karşılaştırılması yapılmıştır. Hareketli ortalamalar, üstel düzeltme ve çoklu regresyon analizi gibi yöntemler yardımıyla Amerikan turistlerin Durban'a seyahat taleplerinin tahmininden elde edilen sonuçlar karşılaştırılmıştır. Zaman serileri analizi kullanılarak Melbourne su tedarik sisteminin şehir bölgesine ilişkin saatlik ve günlük su talebinin tahmini yapılmıştır. Doğrusal ve doğrusal olmayan modellerle Amerika nüfus idaresinden alınan 1985-1999 yıllarına ait aylık perakende satış verileri kullanılarak satışların tahmini yapılmıştır. Tedarik zincirinde bulunan servis parçalarının rassal taleplerin tahmini uygulanmıştır. Logaritmik regresyon modeli kullanılarak Avrupa'daki bir marketler zincirine ait beş ürünün bütünsel talebinin tahmini yapılmıştır [24].

1.1.2 Yapay Sinir Ağları Literatür Özeti

Literatürde yapay sinir ağları ile ilgili, birçok disiplin ve endüstriyel alanında yapılmış yüzlerce tahmin çalışması mevcuttur. Yapay sinir ağları ile yapılan ilk tahmin çalışması hava durumunun tahmin edilmesidir. Daha sonra Hu tarafından 1964 yılında işletmelerde yapılan yapay sinir ağları modeli çalışması, modeli popüler yapmıştır. İşletmelerde yapay sinir ağları ile tahmin çalışmaları, öncelikle finans ve ekonomi alanlarında yapılmış ve önemli sonuçlar elde edilmiştir. Daha sonraları işletmelerde birçok konuda tahmin uygulamaları yaygınlaşmaya başlanmıştır. Çalışma konumuzla ilgili olan bu uygulamalardan bazıları literatür taraması sonucu incelenip, uygulama alanları baz alınarak aşağıda özetlenmiştir.

Wong vd. [25], yapay sinir ağları uygulamaları ile ilgili 1988-1995 yılları arasında yayınlanmış bilimsel makaleleri bir anket vasıtasıyla incelediği çalışmasında; yapay sinir ağları uygulamalarının her geçen gün artan bir şekilde işletme faaliyetlerinde kullanıldığını tespit etmiştir. Çalışma sonuçlarına göre; yapay sinir ağlarının var olan veya gelişen yeni teknolojilere çok çabuk uyum sağladığı, yapay zeka teknolojileri ve bilgisayar temelli sistemlerde yapılan yeniliklerin sinir ağları teknolojisinin işletme araştırmalarında kullanımı için yepyeni fırsatlar oluşturduğu ifade edilmiştir.

Kirby vd. [26], otoyol trafik yoğunluğu tahmini, Gürbüz [27], yolcu ve yük taşımacılığı konusundaki talebi, Tsai vd. [20] demiryolu yolcu talebi, Yaşar [28] otobüs yolcu talebi konularında yaptıkları tahmin çalışmalarında, yapay sinir ağları modellerini kullanmışlardır. Çalışmalarda, bazı geleneksel metotlarla sinir ağı metodu karşılaştırılarak yapay sinir ağı modelinin ulaştırma problemlerinde tahmin performansını geliştirdiği ve tutarlı sonuçlar ürettiği ifade edilmiştir.

Chung [29], şehrin kanalizasyonu kirlilik yoğunluğunun belirlenmesi, Yüksek [30], hava kirliliği tahmini, Shuai ve Gong, [31], çevre kirlenmesi şiddetinin tahminlemesi gibi şehirlerdeki altyapı planlamasına ve ilerde meydana gelebilecek çevre felaketlerine karşı önceden tedbirler alınmasına yardımcı olacak gelecek bilgilerinin üretilmesi amacıyla yapay sinir ağları metodunu kullanarak tahmin çalışmaları yapmışlardır.

Hu [32], iç turizm talep tahmini, Çuhadar vd. [33], dış turizm talep tahmini çalışmalarında; yapay sinir ağları metodunun diğer geleneksel metotlara göre daha iyi tahminlerde bulunduğunu, geliştirilen modellerin veriler arasındaki doğrusal olmayan ilişkileri öğrenerek genelleme yapabildiğini ve böylelikle daha önce hiç karşılaşılmayan sorunları bile kabul edilebilir hata sınırları içinde çözebildiğini ifade etmişlerdir.

Yu [34], tedarik zinciri yönetimi veya e-ticaret yapan işletmeler için agent temelli bir talep tahmin modeli önermiştir. Çalışmada önerilen model, yapay sinir ağları modeli temelinde oluşturulmuş olup, talep miktarları ve temin sürelerinin belirsiz olduğu tedarik zinciri yönetim sürecinde, oldukça güvenilir sonuçlar ürettiği ifade edilmiştir.

Ataseven [35]; Çelik, [36]; İnsel vd.,[37]; Hajirezaie vd. [38], yaptıkları çalışmalarda, yapay sinir ağı modelinin planlama ve kalite kontrol uygulamalarının performans ölçümünde hem güvenilir, hem de hızlı olduğunu, modelin tahmin gücü kullanılarak yöneticilerin karar verme sürecinde daha tutarlı kararlar verebileceğini ifade etmişlerdir.

Yu vd. [34] ve Kaynar vd. [39], yaptıkları çalışmalarda, ham petrol fiyatlarının tahmininde karmaşık ilişkileri başarıyla modelleyebilen yapay sinir ağları metodunu kullanmışlardır. Çalışma sonuçları metodun en iyi performansı gösterdiğini ispatlamıştır.

Sahoo vd. [40], sıcak su akıntı hızının, Aydoğan vd. [41] İstanbul Boğazı'ndaki deniz suyu akıntı hızının, Shamseldin, [42], Sudan'daki mavi Nil nehrinin akış hızının tahminlemesini yapmak üzere, birer yapay sinir ağı modeli tasarlamışlardır.

Çalışmalarda tasarlanan modeller, tatmin edici sonuçlar üretmiş ve daha önce geleneksel metotlarla yapılmış tahminlerden daha tutarlı oldukları gözlenmiştir.

Jones [43], hastanelerin ilk yardım bölümlerine olan talep tahmini modellemesi ve değerlendirilmesi başlıklı doktora çalışmasında, gizli katmanlı, geri beslemeli bir yapay sinir ağı modeli tasarlamıştır. Modelin giriş katmanı tatil dönemlerine ait aylık, haftalık, talep bilgisi değişkenlerinden oluşmaktadır. Geliştirilen modeldeki işlemci elemanların ağırlıkları ve geri yayılma algoritmaları sayesinde tutarlı tahminler yapılabilmektedir.

Kellova [44], yaptığı kısa dönemli elektrik talep tahmini doktora çalışmasında, yapay sinir ağı ile tasarladığı bir model geliştirerek tahminlemeler yapmıştır. Çalışmada, elektrik talep tahmininin yıllardır düşünülen aksine doğrusal değil de doğrusal olmayan bir problem durumu olduğunu ifade edilmiş ve değişken koşullarda doğrusal olmayan modellerin yani, yapay sinir ağlarının kullanımının çok yararlı sonuçlar verdiğini ifade etmiştir.

Aksoy ve Dahamsheh [45]'in yaptıkları Ürdün'deki yağış miktarı tahmininde, yapay sinir ağlarıyla geliştirdikleri bir model kullanmışlardır. Ürdün bölgesinde yağmur yağışlarının yegâne su kaynağı olması sebebiyle, yağışlar bu bölge için hayati önem taşımaktadır.

Asilkan [46], yaptığı çalışmada, yapay sinir ağları kullanarak ikinci el otomobillerin gelecekteki fiyatlarını tahmin etmeye çalışmıştır. Çalışmada, yapay sinir ağları uygulamasından elde edilen sonuçlar, zaman serisi analizleri ile elde edilen sonuçlar ile karşılaştırılmış ve sonuçlar, yapay sinir ağlarının ikinci el otomobillerin gelecekteki fiyatlarını tahminde daha başarılı olduğunu göstermiştir.

Higgins vd. [47], yaptıkları çalışmada, yeşil bezelyenin olgunlaşma süresini yapay sinir ağları yardımıyla tahmin etmişlerdir. Çalışmada, bezelye üreticisi firmaların önemle ihtiyaç duydukları, en uygun hasat zamanının tahmin edilmesi için yapay sinir ağları ile bir model tasarlanmıştır. Geliştirilen modelin, geleneksel metotlardan daha doğru tahminlerde bulunduğu gözlenmiştir. Çalışma sonucunda modelin diğer ürünler için de uygulanabileceği, örneğin kuru fasulye, patates, karnabahar gibi ürünler için de bu türden çalışmalar yapılması gerektiği ifade edilmiştir.

Özkan [48], yaptığı çalışmada, Türk Lirası'nın, ABD Doları ve EURO karşısındaki döviz kurlarını, yapay sinir ağları öngörü performansı ile karşılaştırılarak tahmin

etmiştir. Çalışmanın sonucunda, yapay sinir ağlarının son dönemlerde tahmin problemlerinde kullanılan ve yüksek düzeyde tahmin performansı sağlayan yöntem olduğuna ulaşmıştır.

Kaynar vd. [39], kararsız ve dinamik bir yapıya sahip olan benzin endüstrisinde geleceğe yönelik olarak doğru ve güvenilir tahminler gerekli olduğunu tespit ederek yaptıkları çalışmada, klasik zaman serisi analizi yöntemi ARIMA, MLP (Çok Katmanlı Algılayıcı) ve RBF (Radyal Temelli Fonksiyon) yapay sinir ağları yöntemleri kullanılarak, veri setindeki karmaşık ilişkileri modellemek mümkün olduğu sonucuna ulaşmışlardır.

Sattari vd. [49], çalışmalarında rezervuar işletmesinde depolanan, savaklanan, hazne alanı üzerine düşen yağış ve buradan buharlaşan su miktarları, akımların çok tabakalı ileri beslemeli geriye yayılım yapay sinir ağları simülasyonu yönteminden yararlanarak tahmin etmişlerdir.

Ziariati vd. [50], son yıllarda, geri yayılım tekniğine dayanan yapay sinir ağı modeli ile gerçek bir firmanın malzeme tedarik zincirinde geleceğe dönük malzeme talep miktarı tahmin etmiştir. Yapay sinir ağlarının hızlı olması, büyük miktardaki verinin ele alınabilmesi, malzeme akış diyagramlarında geleceğe yönelik tahminlerde potansiyel bir model olmalarını sağlamaktadır. Bu çalışmada, yapay sinir ağ (YSA) yapısı yerine Genetik Hücresel Yapay Sinir Ağ (GHYSA) modeli konulmuştur. Söz konusu yaklaşım daha az parametre ile kestirim yapabilmekte ve dolayısıyla hızlı değişimli gerçek tedarik zincir problemlerine daha hızlı uyum sağlamaktadır. Önerilen modelin, tedarik zinciri problemlerinde, gerek eğitim sürecinin kısaltılmasında gerekse malzeme istek kestirimde üstün başarımlar göstermesi beklenmiştir.

Demir [51], çalışmasında, Eskişehir orta gelir grubu için geleneksel (logit model) ve esnek hesaplama yöntemleri (YSA, BM-Bulanık Mantık ve Sinir-Bulanık) kullanarak geliştirilmiş ulaştırma türü seçim modelleri incelemiş ve başarımları karşılaştırmıştır. Özellikle Sinir-bulanık modeller, diğer bulanık modellere göre daha iyi tahminler yapmıştır. Ayrıca, logit modelin esnek modellere göre düşük örnekleme düzeylerinde daha başarısız tahminler yaptığı görülmüştür.

Çuhadar ve Güngör [33], çalışmalarında, Antalya iline yönelik Alman turist talebinin tahmininde kullanılmak üzere yapay sinir ağı, çoklu doğrusal regresyon ve çoklu logaritmik regresyon modellerinin tahmin performansları karşılaştırmış ve en iyi

performans gösteren model olan yapay sinir ağı kullanılarak 2005 ve 2006 yılları için aylık tahminler yapmıştır. Uygun modelin oluşturulabilmesi için Ocak 1991 – Temmuz 2004 yıllarına ait aylık verilerden yararlanılmıştır. Elde edilen sonuçlar yapay sinir ağı modelinin, regresyon modellerine göre daha düşük sapma değerlerine ve daha yüksek açıklama oranına sahip olduğunu göstermektedir. Bu konuda daha önce yapılan çalışmalarda da yapay sinir ağları ile elde edilen modellerin diğer yöntemlere göre daha iyi sonuçlar verdiği görülmektedir.

Çuhadar ve Kayacan [52], çalışmalarında, yapay sinir ağı kullanılarak Türkiye'deki bakanlık belgeli konaklama işletmelerindeki, dış turizm talebi ile oluşan doluluk oranları tahmin etmişlerdir. Çalışmanın Türk turizm literatürüne katkısı, konaklama işletmelerinde doluluk oranlarının tahmininde yeni bir yöntemi bir uygulama ile göstermektir. İleriye yönelik yapılacak çalışmalarda, yapay sinir ağları ile farklı değişkenleri kullanarak belirli bir bölge veya il sınırları içerisinde faaliyet gösteren konaklama işletmelerindeki doluluk oranları, yerli ve yabancı konukların konaklama işletmelerindeki harcamaları, turistlerin geceleme sayıları ve ortalama kalış süreleri tahmin edilebilir.

Zou vd. [53], Çin gıda endüstrisinde buğday fiyatları tahmini için, yapay sinir ağları ve zaman serisi modellerinin incelenmesi ve karşılaştırılmasına dayalı bir çalışma yapmışlardır. Bu çalışmada, Çin buğday pazarında fiyat tahmini yapılabilmesi için yapay sinir ağları, doğrusal kombinasyon modelleri ve tahmini ARIMA performansı modelleri karşılaştırmışlardır. Üç model performansının değerlendirilmeleri sonucunda, yapay sinir ağları modelinin, Çin gıda pazarında buğday fiyatlarının belirlenmesi için alternatif ve en iyi model olduğu sonucuna varmışlardır.

Önüt vd. [54], yapay sinir ağları ve nöro-bulanık sistemler ile talep tahmini için bir karar destek sistemi için karşılaştırma analizi yapmışlardır. Bu çalışmada, yapay sinir ağları teknikleri ile çok düzeyli tedarik zinciri (SC) yapısı belirsiz müşteri taleplerine ilişkin karşılaştırmalı bir metodoloji sunmuşlardır. Bildirinin amacı eksik bilgi ile bulanık talep yönetmek için yapay sinir ağları ve adaptif ağ tabanlı bulanık çıkarım sistemi teknikleri hem karşılaştırma dahil olmak üzere yapay zeka yaklaşımları ile modellenen yeni bir tahmin mekanizması önermektir. Talep tahmini sorununa önerilen yaklaşımın etkinliği İstanbul, Türkiye içerisinde dayanıklı tüketim malları sektöründe faaliyet gösteren bir şirketin gerçek dünya verileri kullanılarak gösterilmiştir.

Beccali vd. [55], yapay sinir ağı modelleri ile, günlük kentsel elektrik yükü tahmini yapmışlardır. Bu çalışmalarında, gerçek tahmini bir iki katmanlı ileri beslemeli yapay sinir ağı kullanılarak belirlenmiş ve geri yayılım momentum öğrenme algoritmasıyla eğitmişlerdir. Elektrik tüketiminin iklimlere göre değişimini araştırmak amacıyla Palermo (İtalya)'daki şehir elektrik santralinde, iki yıl süreyle (2001-2003) hava durumu verileri sıcaklık, bağıl nem, güneş ışıması verileri kullanılarak tarihlere göre kullanılan elektrik yükleri yapay sinir ağı ile test edilmiştir. Elde edilen sonuçlardan, kısa dönem yük tahmini problemlerinde şehir içi ve şehirlerarası elektrik dağıtım taleplerinde uygulanabilecek bir yöntem olduğu sonucuna varılmıştır.

Wu vd. [56], çalışmalarında, araç yakıt tüketim tahmini için bir radyal tabanlı fonksiyonlu yapay sinir ağı kullanımı gerçekleştirmişlerdir. Bu çalışmalarında, radyal taban fonksiyonlu yapay sinir ağı kullanılarak araçların yakıt tüketimi için bir tahmin önermişlerdir. Yakıt tüketim tahmini için, önerilen RBF sinirsel sisteminin akıllı şebeke etkisini doğrulamak için, bir geri yayılma (BP) sinir ağı ile yapay sinir ağı ile karşılaştırılır. Tahmini sonuçlarda yapay sinir ağlarının daha etkili olduğu sonucuna ulaşılmıştır.

Yu vd. [57], moda renk trend tahminleri üzerinde akıllı uzman sistemleri ile bir ampirik çalışma yapmışlardır. Bu çalışmalarında, moda sektöründe tasarım, üretim ve satış işlemleri dahil olmak üzere gelecekteki renk trendini tahmin etmek amacıyla bir analiz yapılmıştır. Gelişmiş yöntemler olmadan, moda renk trendlerinde yüksek doğruluk ile tahmin yapmak zor olduğundan dolayı akıllı sistemler kullanılmasına karar verilmiştir. Gelecekteki moda trendi tahmini için Gri Metodu, ARIMA ve yapay sinir ağı ile geleneksel regresyon modelleri kullanılarak çalışmaları yapılmıştır. Gerçek veri analizi ile yapılan çalışmalar sonucunda renk trendi için en iyi performansı yapay sinir ağlarının sağladığı belirlenmiştir.

Shakya vd. [58], dinamik fiyatlandırmada yapay sinir ağı talep modelleri ve evrimsel optimizasyonlara dayanan bir çalışma yapmışlardır. Bu çalışmada, sinir ağı ve evrimsel algoritmaların, fiyatlandırma politikalarını optimize etmek için birlikte kombine edilebilecekleri üzerinde durulmuştur. Bu yaklaşımın iki önemli özelliği vardır: Yapay sinir ağı kullanımı, farklı ürün ve hizmetlerde meydana gelen farklı talep miktarlarını modellemeyi esnek hale getirir. Evrimsel algoritmalar da, karmaşık modelleri çözmeyi çok yönlü şekilde gerçekleştirir. Bu çalışmada bilinen talep

modelleri ve yapay sinir ağıları ile fiyatlandırma politikaları üzerinde çalışılmış ve en tutarlı sonuca yapay sinir ağıları kullanımı ile ulaşılmıştır.

Günümüzde çoğu üretim kuruluşu rekabet nedeniyle, karlarını arttırıp maliyetlerini azaltma konusunda büyük çaba içerisinde. Gelişmiş müşteri hizmeti sağlama, ürün kayıpları ve iadelerini azaltacak verimli bir üretim planlamanın yanında, doğru satış tahmini gerçekleştirebilmek de önemli fayda sağlamaktadır. Özellikle gıda endüstrisi insan sağlığı ile doğrudan ilişkili olduğu için, raf ömrü kısa ürünlerde başarılı satış tahminleri ürün kalitesi açısından yarar sağlar.

Doganis vd. [59], raf ömrü kısa gıda ürünlerinin yapay sinir ağıları ve evrimsel hesaplamalar kullanılarak zaman serisi satış tahminlerine dayanan bir çalışma yapmışlardır. Çalışmalarında, non-lineer zaman serisi satış modelleri kullanılarak tahmin geliştirmek amacıyla bir inceleme sunmaktadırlar. Kullanılan yöntem, iki yapay zeka teknolojisi, radyal tabanlı fonksiyonu sinir ağı mimarisi ve özel tasarlanmış genetik algoritma kombinasyonudur. Metodoloji, süt ürünleri açısından önemli bir üretim şirketi tarafından sağlanan taze süt satış verilerine başarıyla uygulanmıştır.

Jin vd. [60], yapmış oldukları çalışmalarında kamu-özel sektör ortaklığı PPP projelerinde esas işlem maliyet ekonomisinden yararlanarak risk dağılımı üzerinde, yapay sinir ağıları (YSA) modellerinin kurulması, eğitilmesi, doğrulanması ve test edilmesi üzerinde durmuşlardır. PPP (Satınalma gücü paritesi) projelerinde risk değerlemesi yapabilmek, YSA modellerinin eğitimi için veri toplamak amacıyla bir endüstride anket değerlendirmesi yapmışlardır.

Keçebaş vd. [61], yapay sinir ağı modellemesi ile jeotermal bölge ısıtma sisteminin ekserji analizi yapmışlardır. Çalışmalarında, yapay sinir ağı modellemesi ile geniş kapsamlı olarak jeotermal bölge ısıtma sisteminin ekserji verimliliği tahmin etmişlerdir. Bir vaka çalışması olarak, Türkiye’de Afyonkarahisar jeotermal merkezi ısıtma sistemi incelenmiştir. 2009-2010 ısıtma sezonunda, örnek vakadan alınan günlük ortalama gerçek termal veriler toplanmış ve ekserji analizi için bir veri tabanı oluşturmuştur. Bu çalışmadaki YSA modellemesi, geri yayılım öğrenme algoritmasına dayalı olarak geliştirilmiştir. Bu algoritmaya göre sistemin ekserji verim tahminindeki parametreleri; akış hızı, ortam sıcaklığı ve kaynak sıcaklığıdır. Daha sonra farklı tarihlerde AGDHS (Afyonkarahisar Jeotermal Merkezi Isıtma Sistemi)’nden alınıp, kaydedilmiş ve hesaplanmış olan veri, ağıın eğitiminde kullanılmıştır.

Doğan vd. [62], Türkiye’de Melen Nehri’nde, biyolojik açıdan oksijen gereksinimini tahmin edebilmek için yapay sinir ağı kullanarak bir model geliştirmişlerdir.

Boone vd. [63], pazar bölümlemesinde yapay sinir ağı kullanarak bir çalışma yapmışlardır.

Yapılan tez çalışmaları incelendiğinde, yapay sinir ağları ile talep tahmini uygulamalarının yaygınlaştığı görülmektedir. Karahan [1] ve Demirceylan [64], yapay sinir ağları ile yaptıkları talep tahmin çalışmalarında, Alyuda NeuroIntelligence programını kullanmışlardır. Yine incelenen tez çalışmalarında, MATLAB, EXCEL NS, EASY NN, SPSS paket programları kullanılmıştır.

Şekil 1.1, Şekil 1.2 ve Şekil 1.3’te yukarıda belirtilen literatüre ek olarak incelenen makaleler ve özetleri tablo halinde aktarılmaya çalışılmıştır.

Çalışmalar							Ağın Özellikleri				
Sıra No	Çalışma Adı	Uygulanan Teknik	Kullanılan Program	Uygulama Alanı	Ağ Yapısı	Aktivasyon Fonksiyonu	Değişken Sayısı	Öğrenme Kuralı	Öğrenme Yöntemi	Aşama Sayısı	Veri Sayısı (Ay)
1	Wong (1997)	Anket	-	Tüm alanlar*	-	-	10	-	-	-	-
2	Kirby (1997)	YSA	Easy NN	Trafik yoğunluk tahmini	MLP	Sigmoid	8	ART	Gözetimsiz	3	12
3	Gürbüz (2008)	karşılaştırmalı YSA	MATLAB	Yolcu-yük talebi	RBF	lineer doğrusal	10	Kohonen	Gözetimsiz	4	10
4	Tsai (2009)	karşılaştırmalı YSA	MATLAB	Demiryolu yolcu talebi	MLP	Logsig	6	Hopfield	Destekleyici	3	12
5	Yaşar (2009)	karşılaştırmalı YSA	MATLAB	Otobüs yolcu talebi	MLP	Doğrusal	11	ART	Gözetimsiz	3	24
6	Chung (2011)	YSA	MATLAB	Kanalizasyon kirlilik yoğunluğu tahmini	RNN	Eşik	6	Hopfield	Gözetimli	4	10
7	Yüksek (2007)	YSA	MATLAB	Hava kirliliği tahmini	MLP	Sigmoid	5	Hebb	Destekleyici	3	24
8	Shuai ve Gong (2009)	YSA	EXCEL NS	Çevre kirliliği tahmini	MLP	Sigmoid	8	Basit Algılayıcı	Gözetimsiz	4	12
9	Hu (2002)	karşılaştırmalı YSA	SPSS	İç turizm talep tahmini	RBF	Lineer sigmoid	7	Basit Algılayıcı	Gözetimli	3	12
10	Çuhadar (2009)	karşılaştırmalı YSA	SPSS	Dış turizm talep tahmini	MLP	Tanjant hiperbolik	8	ART	Gözetimsiz	4	12
11	Yu (2003)	YSA	MATLAB	Tedarik zincirinde talep tahmini, e-ticaret	MLP	Tansig	12	Kohonen	Gözetimsiz	4	12
12	Ataseven (2007)	YSA	MATLAB	Planlama ve kalite kontrol	RNN	Logsig	4	Delta	Destekleyici	3	12
13	Çelik (2008)	YSA	MATLAB	Planlama ve kalite kontrol	MLP	Logsig	7	ART	Gözetimsiz	3	12
14	İnsel (2010)	YSA	EXCEL NS	Planlama ve kalite kontrol	MLP	Tanjant hiperbolik	5	Kohonen	Gözetimsiz	3	24

Şekil 1.1 Literatür özeti

Çalışmalar						Ağın Özellikleri					
Sıra No	Çalışma Adı	Uygulanan Teknik	Kullanılan Program	Uygulama Alanı	Ağ Yapısı	Aktivasyon Fonksiyonu	Değişken Sayısı	Öğrenme Kuralı	Öğrenme Yöntemi	Aşama Sayısı	Veri Sayısı (Ay)
15	Hajirezaie vd. (2010)	YSA	SPSS	Planlama ve kalite kontrol	MLP	Sigmoid	5	Basit Algılayıcı	Gözetimsiz	4	12
16	Yu vd. (2008)	karşılaştırmalı YSA	DELPHI	Ham petrol fiyat tahmini	RNN	Lineer sigmoid	8	Basit Algılayıcı	Gözetimsiz	3	12
17	Kaynar vd. (2010)	karşılaştırmalı YSA	EXCEL NS	Ham petrol fiyat tahmini	MLP	Tanjant hiperbolik	8	ART	Gözetimsiz	3	12
18	Sahoo vd. (2009)	YSA	MATLAB	Sıcak su akıntı hızı tahmini	MLP	Tansig	4	ART	Gözetimsiz	4	12
19	Aydoğan vd. (2010)	YSA	EXCEL NS	Deniz suyu akıntı hızı (İstanbul Boğazı)	MLP	Sigmoid	4	Kohonen	Gözetimsiz	3	24
20	Shamseldin (2010)	YSA	MATLAB	Nehir akış hızı (Sudan-mavi Nil Nehri)	MLP	Tansig	5	ART	Gözetimsiz	3	24
21	Jones (2008)	YSA	EXCEL NS	Hastanede ilkyardım talep tahmini	MLP	Lineer	3	Kohonen	Gözetimsiz	3	6
22	Kellova (2008)	YSA	SPSS	Kısa dönem elektrik talep tahmini	RBF	Sigmoid	7	Hebb	Gözetimli	3	12
23	Aksoy vd. (2009)	YSA	MATLAB	Yağış miktarı tahmini (Ürdün)	MLP	Logsig	5	ART	Gözetimsiz	4	12
24	Avcı (2009)	YSA	DELPHI	Hisse senedi günlük getirisi tahmini	RBF	Sigmoid	6	Basit Algılayıcı	Destekleyici	4	12
25	Asilkan (2009)	karşılaştırmalı YSA	MATLAB	İkinci el otomobil fiyat tahmini	RNN	Logsig	6	Basit Algılayıcı	Destekleyici	4	24
26	Higgins vd. (2010)	karşılaştırmalı YSA	EXCEL NS	Yeşil bezelye olgunlaşma süresi tahmini	İleri besleme	Sigmoid	7	Delta	Gözetimli	3	36
27	Özkan (2012)	karşılaştırmalı YSA	DELPHI	Döviz kuru tahmini	RNN	Sigmoid	5	Delta	Gözetimli	3	12

Şekil 1.2 Literatür özeti (devamı)

Çalışmalar						Ağın Özellikleri					
Sıra No	Çalışma Adı	Uygulanan Teknik	Kullanılan Program	Uygulama Alanı	Ağ Yapısı	Aktivasyon Fonksiyonu	Değişken Sayısı	Öğrenme Kuralı	Öğrenme Yöntemi	Aşama Sayısı	Veri Sayısı (Ay)
28	Kaynar vd. (2010)	karşılaştırmalı YSA	DELPHI	Benzin fiyat tahmini	İleri besleme	Lineer	8	Delta	Destekleyici	4	12
29	Sattari vd. (2007)	YSA	MATLAB	Yağış miktarı tahmini	MLP	Lineer sigmoid	5	ART	Gözetimsiz	4	12
30	Ziariati vd. (2002)	YSA	MATLAB	Tedarik zincirinde malzeme talep miktarı	MLP	Tansig	7	Kohonen	Gözetimli	3	18
31	Demir (2006)	karşılaştırmalı YSA	EXCEL NS	Ulaştırma türü seçimi	RBF	Sigmoid	6	Basit Algılayıcı	Gözetimli	4	6
32	Çubadar vd. (2005)	karşılaştırmalı YSA	-	Turist talep tahmini (Antalya)	MLP	-	6	-	-	-	162
33	Zou vd. (2007)	karşılaştırmalı YSA	DELPHI	Buğday fiyat tahmini (Çin)	MLP	Lineer doğrusal	7	Kohonen	Gözetimsiz	4	12
34	Kayacan vd. (2005)	YSA	SPSS	Otel doluluk oranı tahmini	MLP	Lineer doğrusal	5	ART	Gözetimsiz	3	36
35	Beccali vd. (2004)	YSA	-	Elektrik yük tahmini (günlük-Palermo)	MLP	-	5	-	-	-	24
36	Wu vd. (2012)	YSA	MATLAB	Araç yakıt tüketimi tahmini	RBF	Tansig	7	Basit Algılayıcı	Gözetimli	3	12
37	Doganis vd. (2006)	karşılaştırmalı YSA	SPSS	Raf ömrü tahmini (süt)	MLP	Sigmoid, lineer sigmoid	8	ART	Gözetimsiz	4	6
38	Jin vd. (2011)	YSA	MATLAB	Risk dağılımı tahmini	RNN	Lineer sigmoid	7	Basit Algılayıcı	Gözetimli	3	12
39	Keçebaş vd. (2012)	YSA	MATLAB	Jeotermal enerji	MLP	Tansig	8	ART	Gözetimsiz	3	12
40	Doğan vd. (2009)	YSA	MATLAB	Biyolojik oksijen ihtiyacı (Melen Nehri)	MLP	Logsig	5	ART	Gözetimsiz	3	12
41	Boone vd. (2002)	YSA	SPSS	Pazar bölümlenmesi	MLP	Sigmoid	10	Kohonen	Gözetimsiz	3	12

Şekil 1.3 Literatür özeti (devamı)

1.2 Tezin Amacı

Bu tez çalışmasında, yapay sinir ağları yöntemi kullanılarak, gıda sektöründe bir talep tahmin uygulaması yapılması amaçlanmıştır. Uygulama kısmı iki bölümden oluşmakta olup, öncelikle talebi tahmin edilecek ürün grubu seçilmiş ve toplanan veriler ışığında yapay sinir ağları yöntemi ile talep tahmini yapılmıştır. İzleyen bölümde ise, diğer talep tahmin yöntemleri ile de tahmin yapılmış ve sonuçlar karşılaştırılmıştır. Yapılan yurtiçi

ve yurtdışı literatür incelemeleri sonucunda, birçok konuda talep tahminiyle ilgili çalışmalara rastlanmıştır. Bu çalışmada literatüre katkıda bulunmak amacıyla, hızlı tüketim ürünleri üreten et sektöründe talep tahmini yapılmıştır. Hızlı tüketim ürünü olan şarküteri grubu et ürünlerinde üretimi etkileyen, hammadde, raf ömrü, müşteri sayısı, ürün satış fiyatı gibi veriler ışığında talep tahmini yapılması sırasında önemli zorluklarla karşılaşıldığı gözlemlenmiştir. Özellikle stokta tutulacak miktarın belirsiz oluşu, ürünlerin son tüketim tarihinden bir süre öncesinde müşteriye satılması ve sevki ve raf ömrü (bozulma riski) gibi kısıtlamalar nedeniyle taze gıda üretimi yapan firmalarda talep tahmini yapmak oldukça büyük bir problemdir.

İncelenen çalışmalara göre bu alanda yapılmış olan bir talep tahmini uygulamasına rastlanmamıştır. Firma, 2010-2013 yılları arasında aylık olarak yapılan talep tahminlerinin haftalık olarak yapılması konusunda bir uygulama yapmak istemektedir. Bu nedenle bu çalışmada, şarküteri grubu ürünlerde öncelikle ABC analizi yapılarak belirli bir ürün grubu seçilmiş, daha sonra belirlenen ürün grubuna ait veriler düzenlenerek bir model oluşturulmuştur. Oluşturulan bu model ile yapay sinir ağları kullanılarak, ürün grubundaki ürünlere ait aylık talep tahminleri yapılmıştır. Burada yapay sinir ağının kullanılmasının sebebi ise, incelenen literatüre göre yapay sinir ağı ile talep tahmini uygulamalarının, diğer talep tahmin yöntemlerine göre daha doğru sonuçlar vermesidir.

Yapay sinir ağı modelinin kurulmasında, incelenen örneklerden yararlanılmıştır. Yapılan incelemelerde, tahmin modellerinde genellikle ileri beslemeli-geri yayımlı ağ yapısının kullanıldığı belirlenmiştir. Literatürde geliştirilen ileri beslemeli yapay sinir ağlarında genellikle tek gizli katman kullanılmaktadır. Bu çalışmada, firmadan elde edilen veriler ve literatür doğrultusunda kurulan yapay sinir ağı modeli; ileri beslemeli, 5 elemanlı bir tek gizli katman kullanılması uygun görülmüştür. Ağı aktif etmek için kullanılan aktivasyon fonksiyonu, kullanılan program doğrultusunda belirlenmiş olup, bu fonksiyon literatürde de sıklıkla kullanılan lineer (doğrusal) fonksiyondur.

Uygulama kısmında, talep tahmin yöntemlerinden birkaçı ile yapay sinir ağı ile talep tahmini yöntemi sonuçları karşılaştırılmış ve yapay sinir ağının daha az hata değeri oluşturduğu sonucuna ulaşılmıştır. Alyuda NeuroIntelligence programı kullanılarak aylık olarak elde edilen talep tahmin verileri, diğer yöntemlere göre daha tutarlı bir sonuç vermiştir. Gıda sektöründe talebin değişkenliği diğer sektörlerle göre daha fazladır.

1.3 Hipotez

Bu tez çalışmasında, gıda sektöründe talep tahminlerinde, aylık satış verileri, satış yapılan müşteri sayısı, pazardaki rakip firma sayısı, özel günler, satış yapılan ay ve satış fiyatı verilerinin etkili olduğu ve yapay sinir ağları yöntemi seçilerek talep tahmini uygulaması yapıldığında, sonuçların diğer yöntemlere göre gerçeğe daha yakın ve tutarlı sonuçlar vereceği savunulmuştur.

Bu çalışmada, istatistiksel talep tahmin tekniklerinden yapay sinir ağı modeli kullanılarak, taze gıda sektöründe kırmızı et işleyerek faaliyet gösteren bir firmanın belirlenen ürün grubuna ait gelecekteki talep miktarlarının tahmini yapılmıştır. Geliştirilen sinir ağı modeli tarafından üretilen tahminler üzerinde yapılan hata testi sonuçları, modelin ürettiği tahminlerin güvenilir ve tutarlı olduğunu göstermiştir. Ayrıca yapay sinir ağları dışında, talep tahmininde kullanılan diğer yöntemlerle de tahmin çalışması yapılmış ve yapay sinir ağlarının daha başarılı olduğu sonucuna ulaşılmıştır.

Çalışma altı bölümden oluşmaktadır. Birinci bölümde konuyla ilgili daha önce yapılmış olan çalışmalar incelenerek literatür taraması oluşturulmuştur.

İkinci bölümde, üretim planlama kavramı ve talep tahmini ile ilişkisi kısaca anlatılmıştır.

Üçüncü bölümde, talep tahmini ile ilgili kavram ve tanımlar özetlenmiş ve çalışmanın gerekçesinin teorik altyapısı oluşturulmaya çalışılmıştır. Talep tahmin yöntemlerinin en yaygın kullanılanları kısaca anlatılmıştır.

Dördüncü bölümde, istatistiksel talep tahmininde kullanılan yöntemlerden çağdaş yöntem olan yapay sinir ağları teorisi, kullanım alanları, hata analizleri ayrıntılı olarak anlatılmıştır.

Beşinci bölümde, ABC analizi ile talep tahmini yapılacak ürün grubu belirlenmiş, ürününün gelecekteki talep miktarı tahminini yapmak üzere bir yapay sinir ağı modeli tasarlanmış, modelin eğitimi ve testi yapılmış, tahmin süreci hakkında detaylı bilgiler verilmiştir. Daha sonra üretilen bu tahminlerin hata analizleri yapılmıştır. Talep tahmininde kullanılan diğer yöntemler ile de hesaplamalar yapılmış, karşılaştırmalı sonuçlar özet halinde verilmiştir.

Çalışmanın sonuç kısmında, uygulamadan elde edilen bulgular doğrultusunda değerlendirmeler ve yorumlamalar yapılarak literatüre katkı sağlanmış ve gelecekte yapılacak çalışmalara yönelik bazı önerilerde bulunulmuştur.

ÜRETİM PLANLAMASI VE TEMEL KAVRAMLAR

2.1 Üretim Planlama ve Kontrol

Üretim planlama ve kontrol, üretilecek ürünü belirlemek, üretim için gerekli olacak malzeme ve miktarlarını saptamak, ürünlerin istenilen kalite ve maliyette, istenilen zamanda oluşumunu sağlayacak çizelgeleme çalışmalarını yapmak gibi faaliyetlerden oluşan bir üretim yönetimi etkinliğidir. İşletmelerin temel amaçları olan, toplam karın maksimize edilmesi, siparişlerin zamanında karşılanması, eldeki kaynakların (malzeme, makine, işgücü, donanım vb.) en verimli şekilde kullanılması gibi amaçlara önemli ölçüde katkıda bulunur [65].

Üretim planlama ve kontrol iki temel faaliyetten oluşmaktadır. Üretim planlama, hangi üründen, ne zaman, ne kadar miktar kullanılacağı ve üretimin nerede, hangi olanaklar ile yapılacağı sorularına cevap ararken; kontrol faaliyetleri, fiili üretimin planlanan üretime uygunluğunu denetlemektedir. Üretim planlama önceden, üretim kontrol ise üretim sırasında veya üretimin hemen öncesinde yapılan faaliyetlerdir. Bu nedenle belirtilen bu iki faaliyetin bir arada değerlendirilmesi gerekmektedir.

Üretim planlama, üretim fonksiyonlarının başlıca üç aşamasından birisidir. Üretim planlaması yapılırken, işletmelerin üretim yönetimi amaçları dikkate alınarak, üretim alt sistemlerinin organizasyonu, üretim politikaları, üretim programları ve üretimle ilgili faaliyetlerle ilgili gerekli planlama çalışmalar gerçekleştirilir. Planlama aşamasında, talep tahminlerine uygun olarak; üretim planlaması, malzeme ihtiyaç planlaması, işgücü planlaması, personel planlaması, üretim metotları, finansal planlama, ödeme planı, çalışma sermayesi ve nakit akışı, bilgisayar destekli üretim gibi işlemler yapılmaktadır [1].

Üretim planlaması yapılırken; üretimi yapılacak ürüne ait talep durumu dikkate alınarak, tüketicinin istediği ürünün özellikleri, miktarı, kalitesi ve fiyatı ile ilgili bilgiler toplanmalı ve bu bilgiler değerlendirilmelidir. Tüketici taleplerinde meydana gelen değişiklikler sürekli takip edilerek, tüketici taleplerine uygun üretim yapılması sağlanmalıdır. Üretim teknolojisinde ve malın temel fiziksel ve kimyasal özelliklerinde değişiklikler meydana geldiği takdirde, gerekli düzeltme işlemi yapılarak talep edilen malın özelliklerine göre üretim yapılmalıdır. İşletmenin gelecekte üreteceği ürünler veya yeni ürün üretim kararı verilecek ürünler için gerekli kaynaklar, üretim süreçlerinin belirlenmesi, üretim kapasitesi, takip edilmesi gereken politikalar ve teknoloji ile geleceğe ilişkin diğer konular tespit edilerek üretim planlamasının yapılması gereklidir [1].

Üretim planlaması ve denetimi, iş hazırlama, iş dağıtımı, programlama, tahmin, üretim emri verme ve denetim-kontrol olmak üzere altı aşama veya fonksiyon halinde ele alınmaktadır. Üretime geçişten önceki hazırlık çalışmalarından birisi olan tahmin, yapılacak belirli bir üretimle ilgili olarak tahmini üretim maliyetlerinin belirlenmesi açısından oldukça önemlidir [1], [66].

Üretim planlama, planlanan dönem için gerçekleştirilecek faaliyetlerin genel durumunu gösterir. Söz konusu faaliyetler için, eldeki kaynakların yeterli olup olmadığını belirlemektedir. Günümüzde işletmelerin amaçlarından birisi de, talepleri karşılarken eldeki kaynakları verimli kullanmaktır. Eldeki kaynakların verimli kullanılabilmesi, üretim kontrolünün etkili olmasına bağlıdır. Üretim planlaması, en genel anlamıyla; gelecek bir planlama dönemi için üretim hedeflerinin tespit edilmesi olarak tanımlanabilir. Üretim planlamasının amacı, belirlenen üretim hedeflerine ulaşabilmek ya da mevcut satış imkânlarından faydalanabilmek için kaynakların en uygun şekilde kullanımını tespit etmektir.

Üretim planlamanın girdilerini; talep tahmin değerleri, sipariş miktarları, stok seviyeleri, üretim ara stok seviyeleri, üretim merkezi kapasiteleri, üretim rotaları, malzeme miktarı, standart üretim süreleri, işgücü seviyesi, malzemenin temin edilebilirliği, maliyet standartları, satış fiyatı ve yönetim politikaları oluşturmaktadır. Bu verilerin periyodik olarak toplanması ve analizi sonucunda üretim planları hazırlanmaktadır.


Sonuç olarak üretim planlama; toplu değerden başlayarak giderek ayrıntıya inen bir yapıda, üretim hedefleri koyan, bu hedefleri gerçekleyecek kapasitenin nasıl kullanılacağına ilişkin politikaları belirleyen, iş emirleri ve satınalma isteklerinin hazırlanmasını sağlayan ve iş merkezlerindeki iş çizelgelerinin oluşturulmasıyla biten hiyerarşik bir süreç oluşturmaktadır [65].

Üretim planlama; gelecekteki ihtiyaçları karşılamak için üretim sürecinin sabit ve değişken girdilerini karşılaştıran ve belirli oranlarda bir araya getiren bir orta dönem planlamadır. Üretim planları tahmin edilen rakamlara dayanır. Planlama, üretimi yapılacak ürün hakkındaki bütün verilerin analiziyle başlamaktadır [24].

Üretim planlama dönemleri, uzun, orta ve kısa olmak üzere üç döneme ayrılmaktadır. Uzun dönemli planlama; şirketlerin stratejik kararlarına ve hedeflerine ışık tutan planlamadır. Yeni ürün üretim kararları, sistem değişikliği, yeni bir tesis kurma gibi kararlar uzun dönemli planlama kararlarıdır. Orta dönemli planlama; talepleri karşılamak için üretim miktarını artırma ya da azaltma, stok hedeflerini belirleme, işgücü düzeyini ayarlama ve satınalma politikalarından oluşan, genelde üç ay ila bir yıllık planlama dönemini kapsamaktadır. Kısa dönemli planlama ise; haftalık, günlük veya vardiyalık olan yapılan planlardır. Üretim çizelgeleme, fazla mesai kararları, satınalma emirlerinin verilmesi, iş tahsisleri kısa dönemli planlara örnek olarak verilebilmektedir.

Planlama, yöneticilerin işlerinin ayrılmaz bir parçasıdır. Belirsizlikler yöneticilerin etkin ve verimli plan yapmalarını zorlaştırmaktadır. İşletmelerde geleceğe yönelik birtakım belirsizlikleri gidermenin yolu geçmiş verilerden hareketle ileriye yönelik tahminler yapmaktır [67].

Bir işletmede üretim planlama ve kontrol fonksiyonu bağlamında gerçekleştirilmesi gereken faaliyetler Şekil 2.1’de gösterilmektedir.



Şekil 2.1 Üretim planlama ve kontrol faaliyetleri [1]

Üretim planları bir kere yapıldıktan sonra, plana uyulmasını sağlamak amacıyla sürekli kontrol edilmesi gerekmektedir. Bunun için gerçek durum ile yapılan üretim planı karşılaştırılarak gerçek durumdan sapmalar varsa bunlar düzeltilir. Üretim kontrolünün amacı, işletmelerin hedefleri çerçevesinde, optimum kar sağlayacak şekilde işletmenin içine ve dışına olan malzeme ve ürün akışını örgütlemek ve kontrol etmek şeklinde tanımlanabilir. Bu nedenle üretim kontrolünün, müşteri talebini, sermaye durumunu üretim kapasitesini, insan gücü vb. sürekli olarak tartan, kontrol altında tutan bir araç olması gerekmektedir.

2.2 Tahmin Teorileri ve Tahminleme Yöntemleri

Belirsizliđi azaltmak için atılacak her adımın, sađlıklı kararlar alınması yönünde deđerli katkıları olacaktır. İşletmecilik alanında belirsizliđi azaltmak için birtakım tahmin yöntemleri kullanılmaktadır. Bu tahmin yöntemlerinin dođruluđu işletmeler açısından oldukça önemli olduğundan, sađlıklı tahminlerin yapılabilmesi için tahminlerin bilimsel temellere dayandırılması gerekmektedir [68].

Tahmin, gelecek dönemlerde meydana gelebilecek olayların sonuçlarının önceden hesaplanmasıdır. Diđer bir ifadeyle; tahmin, geçmiş dönemlerde meydana gelmiş olay/olayların sonuçlarını deđerlendirerek gelecek dönem/dönemlerde meydana gelebilecek olayların sonuçlarını önceden görebilmektir. Tahmin deđerleri ile gerçekleşen deđerler arasında farklara “tahmin hataları” denilmektedir [69].

İşletme faaliyetlerinin düzgün bir şekilde sürmesi açısından tahminler önemlidir. Tahminler, gelecekteki faaliyetleri işletme amaçları dođrultusunda yönlendirmede yöneticilere yardımcı olacak bilgileri sađlar. Tahminler, belirsiz olayların ortaya çıkışına, zamanlamasına ve büyüklüğüne ilişkin öngörülerdir. Üretim yöneticileri, genellikle pazarlama fonksiyonu tarafından (veya birlikte)hazırlanan talep tahminleriyle ilgilenirler. Ancak, yöneticiler, hammadde fiyatlarını öngörmek, insan gücü planlaması yapmak, bulundurulacak stok düzeyine ilişkin karar vermek ve diđer birçok faaliyeti yönetmek için başka deđerşkenlere ilişkin tahminlerden de yararlanırlar. Böylece kapasiteyi daha iyi kullanma, müşteriye daha iyi hizmet verme ve karlılıđı artırma imkanına kavuşurlar [70].

Tahmin kelimesinin sözlük anlamı; akla, sezgiye veya bazı verilere dayanarak gelecekte olması muhtemel olayların tahmin edilmesidir. Geleceđi tahmin etmek veya tahmin etmeye çalışmak sosyoekonomik gelişmenin bir unsurudur. Karar verme zorunluluğunda olan bütün özel veya kamu kuruluşlarının gelecek zamanda mevcut durumlarını muhafaza etmeleri ve geliştirebilmeleri için gelecekteki olayları tahmin edebilmeleri ve iyi bir plan çerçevesinde uygun çözümler bulmaları gerekmektedir.

Kuruluşlar veya şirketler geleceđe yönelik kararlar verirken, dođru ve güvenilir tahminlere ihtiyaç duyarlar. Çünkü, dođru olmayan tahminler kuruluşun veya şirketlerin gelecekteki hedeflerini olumsuz etkiler. Bu olumsuzluklar sonucunda stok maliyetlerinin artması ve talebe cevap verilememesi gibi nedenler şirketin pazar kaybına neden olabilir [24]. Kuruluşlar tahmin yaparken, satış hedeflerindeki artış oran

ile talep artış oranlarını göz önünde bulundurmalıdırlar. Diğer taraftan, tahminin üretim kapasitesi tarafından sınırlandırılmaması için, muhtemel talebe cevap verebilecek şekilde önceden kapasite planlaması da yapılmalıdır.

Bir işletme, hangi ürününü ne kadar miktarda, ne zaman, ne kadar maliyete ve hangi yollarla elde edeceğini bilmeye ihtiyaç duymaktadır. Süreç satışların tahmin edilmesiyle başlamaktadır. Satış tahminleri esas alınarak mevcut imkan ve işgücü çerçevesinde personel, malzeme ve kapasitenin yer aldığı bir üretim programı hazırlanacağından, bu tahminleri gerçeğe en yakın şekilde işletme amaçlarına ve durumuna uygun yapmakta fayda vardır. Kısacası satış tahminleriyle ile üretim tahmini ve planına bağlı olarak, üretim için ihtiyaç duyulan girdi özellikleri, miktarı ve zamanı ile ilgili bilgiler belirlenmektedir [71].

Tahminleme, geçmiş bilgileri veya veri setlerini kullanarak, gelecekle ilgili projeksiyon yapma, tahmin modeli geliştirme sürecidir. Tahmin modeli gerçek olayın basit bir kopyası, bir dizi ilişki setidir. Model bu ilişkilerle ilgili geçmiş bilgilerden yararlanarak gelecekle ilgili projeksiyonlar yapabilir. Tahminleme, yönetim sürecinde hayati öneme sahip olduğundan, işletme yöneticileri tarafından daima göz önünde tutulması gerekir. Bir yönetici başarısızlık riskini minimize etmek için tahminlerden de yararlanırlar. Böylece kapasiteyi daha iyi kullanma, müşterilere daha iyi hizmet verme ve karlılığı artırma imkanına kavuşurlar [70].

Tahmin kelimesinin sözlük anlamı; akla, sezgiye veya bazı verilere dayanarak gelecekte olması muhtemel olayların tahmin edilmesidir. Geleceği tahmin etmek veya tahmin etmeye çalışmak sosyoekonomik gelişmenin bir unsurudur. Karar verme zorunluluğunda olan bütün özel veya kamu kuruluşlarının gelecek zamanda mevcut durumlarını muhafaza etmeleri ve geliştirebilmeleri için gelecekteki olayları tahmin edebilmeleri ve iyi bir plan çerçevesinde uygun çözümler bulmaları gerekmektedir.

Kuruluşlar veya şirketler geleceğe yönelik kararlar verirken, doğru ve güvenilir tahminlere ihtiyaç duyarlar. Çünkü, doğru olmayan tahminler kuruluşun veya şirketlerin gelecekteki hedeflerini olumsuz etkiler. Bu olumsuzluklar sonucunda stok maliyetlerinin artması ve talebe cevap verilememesi gibi nedenler şirketin pazar kaybına neden olabilir [24]. Kuruluşlar tahmin yaparken, satış hedeflerindeki artış oran ile talep artış oranlarını göz önünde bulundurmalıdırlar.

Diğer taraftan, tahminin üretim kapasitesi tarafından sınırlandırılmaması için, muhtemel talebe cevap verebilecek şekilde önceden kapasite planlaması da yapılmalıdır. Bir işletme, hangi ürününü ne kadar miktarda, ne zaman, ne kadar maliyete ve hangi yollarla elde edeceğini bilmeye ihtiyaç duymaktadır. Süreç satışların tahmin edilmesiyle başlamaktadır. Satış tahminleri esas alınarak mevcut imkan ve işgücü çerçevesinde personel, malzeme ve kapasitenin yer aldığı bir üretim programı hazırlanacağından, bu tahminleri gerçeğe en yakın şekilde işletme amaçlarına ve durumuna uygun yapmakta fayda vardır. Kısacası satış tahminleriyle üretim tahmini ve planına bağlı olarak, üretim için ihtiyaç duyulan girdi özellikleri, miktarı ve zamanı ile ilgili bilgiler belirlenmektedir [71].

Tahminleme, geçmiş bilgileri veya veri setlerini kullanarak, gelecekle ilgili projeksiyon yapma, tahmin modeli geliştirme sürecidir. Tahmin modeli gerçek olayın basit bir kopyası, bir dizi ilişki setidir. Model bu ilişkilerle ilgili geçmiş bilgilerden yararlanarak gelecekle ilgili projeksiyonlar yapabilir. Tahminleme, yönetim sürecinde hayati öneme sahip olduğundan, işletme yöneticileri tarafından daima göz önünde tutulması gerekir. Bir yönetici başarısızlık riskini minimize etmek için geleceğini iyi planlamalıdır. İyi bir plan yapmak için ise, iyi tahminleme yapmak gerekir [13].

Temel olarak tahminleme, girişimciler tarafından sağlanmış olan ürün veya hizmetlere gelecekteki muhtemel taleplerdir. Üretim miktarını belirleme yeteneği, açık bir şekilde üretim kontrolünde karar verme sürecinin kalitesini artıracaktır. Üretim kontrolüne temel giriş, ürün veya hizmet sağlamaya başlamak için gerekli olan pazarlama grupları tarafından yapılan tahminlerdir. Tahminin ürettiği sonuçlar, değişik faktörler göz önünde tutularak değerlendirilmelidir. Bu faktörler, geçmişe ait talep verileri, trend veya mevsimsel etkilerdir. Tahmin sürecinin desteklenmesi mümkün olan her yerde yapısal bir yaklaşım kullanılmalıdır. Bunun ötesinde, tahminleri izlemek için var olan teknikler güncellenmeli ve sezgisel eğilimler ile karşılaştırılarak tahminin gelişmesi sağlanmalıdır [72].

2.2.1 Tahmin İlkeleri

Tahminlerin daha etkin kullanımı için tahmin ilkelerinin ya da tahminlerin özelliklerinin bilinmesi gerekir. Bu ilkeleri aşağıdaki gibi sıralamak mümkündür [68].

- Tahminlerde mükemmelliğe ulaşmak genellikle imkansız olup gerçekleşen sonuçlar genellikle tahmin değerlerinden farklılık göstermektedir. Bunun

nedenlerinden birisi, tahmin edilecek değişkeni etkileyen faktörlerin tümünün göz önüne alınmaması, ikincisi ise öngörülemeyen tesadüfi olayların ortaya çıkmasıdır.

- Tahminlerin hata ihtimali olduğuna göre, yapılan tahminin ne ölçüde hata içerdiğinin bilinmesi önemlidir. Bu durum, tek bir tahmin değerinin yanı sıra, bir aralığın, yani alt ve üst sınırların belirlenmesini gerektirir.
- Bir grup ürün için yapılan tahminler, tek tek ürünler için yapılan tahminlere kıyasla daha doğru sonuç verir.
- Kısa dönemli tahminlerin daha az belirsizlik içermesi nedeniyle, tahmin dönemi uzadıkça tahminin doğruluğu azalır.

Bir tahmin sürecinde çeşitli aşamaların izlenmesi gerekir. Bunlar:

- Tahminin amacının belirlenmesi,
- Tahmin döneminin belirlenmesi,
- Bir tahmin yönteminin seçilmesi,
- Gerekli verilerin toplanması ve tahminin oluşturulması,
- Tahmin modelinin geçerliliğinin test edilmesi,
- Modelin çözümü ve tahmin sonuçlarının elde edilmesi,
- Sonuçların uygulanması ve izlenmesidir.

Tahminde istenen ayrıntı derecesi, tahmine ayrılacak kaynak miktarı ve istenen doğruluk düzeyinin belirlenebilmesi için, öncelikle tahminin amacı kararlaştırılmalıdır. Uygun yöntemin seçilmesinden sonra veriler toplanarak tahmin yapılır. Bunu izleyen aşamada, modelin geçerlilik testi yapılarak modelinin kullanılabilirliğine karar verilir. Modelin geçerli bulunmaması halinde, yöntem, yapılan varsayımlar, verilerin geçerliliği tekrar gözden geçirilerek, gerektiğinde kullanılan yöntem değiştirilebilir. Sadece geçerliliği kabul edilmiş tahmin yöntemiyle oluşturulan tahmin değerleri, planlama amacıyla kullanıldığında doğru sonuçlar verecektir.

2.2.2 Tahmin Yönteminin Seçimi

Bütün yönetim kararları mutlaka gelecekle ilgilidir. Geleceği öngörme, kestirme veya tahmin, yönetimin karar verme sürecinde önemli bir dayanağı olduğundan işletmeler için oldukça önemli bir konudur. Gelecekte olması muhtemel tüm olaylar, kabul edilebilir düzeyde doğru olarak tahmin edilemeyebilir, fakat karar sürecinde

yöneticilere rehberlik edecek önünü görmesine yarayacak bazı bilgiler sağlanması bile karar vericilere önemli avantajlar sağlayacaktır. Doğru ve güvenilir tahminler ve tahmin modelleri, çok faktörün bir fonksiyon olarak düşünülebilir. Bu faktörlerden birisi de tahmin dönemidir. Uzun dönemli tahminler, doğası gereği kısa dönemli tahminlerden daha fazla hata eğilimlidir. Tahminin doğruluğunu ve güvenilirliğini etkileyen diğer faktör ise, bir model geliştirirken kullanılan geçmiş verilerin gözlem sayısının oluşturduğu, örnek hacmidir [73].

Bir üretim yöneticisinin kendi ihtiyaçlarını en iyi karşılayan modeli seçmesi gerekir. Tahmin yönteminin seçimini etkileyebilecek faktörleri su şekilde sıralamak mümkündür [68]:

- Tahminin uzun ya da kısa oluşu,
- Verilerin mevcudiyeti,
- Arzulanan doğruluk derecesi,
- Tahmin yönteminin maliyeti ve tahmin çalışmaları için ayrılan bütçe,
- Ürün ve hizmetlere ilişkin özellikler,
- Tahmin sürecinde çalışacak nitelikli personelin mevcudiyeti.

Tahmin yönteminin seçiminde en önemli kriterler, maliyet ve doğruluk olmalıdır. Doğruluğun ölçümünde ortalama mutlak hata değeri kullanılmalı, model seçiminde tahmin hatalarının oluşturduğu maliyetlerle veri toplama ve uygulama maliyetleri göz önüne alınmalıdır.

Tahmin metodunun seçiminde, işletmenin sahip olduğu esneklik derecesi de önemli bir faktördür. Ayrıca, tahmin metodunun seçiminde tahmine dayalı olarak verilecek kararın önem derecesi de göz önüne alınmalıdır. Elde edilen tahmin değeri büyük bir sermaye yatırım kararının verilmesinde kullanılacaksa, metodun seçiminde doğruluğun ön planda tutulması gerekecektir. Tahmin modellerinin bir araç olduğu unutulmamalı, elde edilen sonuçlara kesin gözüyle bakılmamalıdır. Yöneticilerin deneyimleri; sezgileri; toplumun sosyal ve kültürel değerleri, tahmin modellerinin dikkate alınmadığı, ancak talep üzerinde etkili olabilen faktörlerdir. Bu nedenle, yöneticilerin, tahmin sürecinde göz önüne alınamayan veriler çerçevesinde birtakım düzeltmeler yapmaları gerekebilir.

2.2.3 Tahminleme Teknikleri

İşletmelerde tahminler, satılması beklenen ürün miktarı olabileceği gibi, beklenen kar, gelecekteki ekonomik göstergeler, çalışanların ihtiyaçları gibi konularda da olabilir. Yapılacak bu gibi tahminler işletmede bulundurulması gereken stok miktarı, yapılacak yeni yatırımların büyüklükleri, çeşitli faaliyetler için ayrılması gereken bütçe miktarları gibi konuların belirlenmesinde büyük yardım sağlayacaktır. O halde tahminlerin yeterince güvenilir olması istenir. Bu nedenle bilimsel olarak geliştirilmiş tahmin tekniklerinden yararlanılması doğru olacaktır.

Günümüze kadar geliştirilen tahmin teknikleri farklı kaynaklarda çeşitli sınıflamalara tabi tutulmuştur.

Lancaster ve Massingham [74], tahminleme tekniklerini temel olarak; nitel ve sayısal tahmin teknikleri olarak ikiye ayırmışlardır. Nitel teknikler, sübjektif veya yargısal teknikler olarak da isimlendirilmektedir. Sayısal teknikler terimin ile anlatılmak istenen ise, matematiksel bir yöntem olmasıdır. Sayısal teknikler bilgisayar programlarının hızla gelişmesiyle uygulamalara başarılı katkılar sağlamakta ve bu yüzden de gittikçe popüler olmaya başlamıştır.

Düzakın [67], tahmin tekniklerini üç ana başlık altında toplamıştır. Bunlar, zaman serileri yöntemleri, nedensel yöntemler ve yargısal yöntemlerdir. Tahmin yöntemlerinin işletmelerde kullanılabileceği bazı alanlar şunlardır:

- Satış tahmini
- Yedek parça ihtiyacı tahmini
- Üretim gelirinin tahmini
- Ekonomik eğilim tahmini
- Personel ihtiyaçları tahmini

Tahmin çalışmaları, elde edilen uygun verilerin analizi ile gelecekteki bazı olayların veya durumların projeksiyonu olarak tanımlanabilir. Bir olayın modellenenebilmesi için olay hakkındaki bilgilerin (veri) matematiksel bir model aracılığıyla analiz edilmesi gerekir. Ayrıca, yapılan analizlerin doğruluğu için değişkenlerin iyi tanımlanması gerekir. Tahmin işlemleri, zaman serileri, ekonometrik modeller, uzman görüşleri ve anket gibi yöntemlerle yapılmaktadır. Tahmin yönteminin seçimi, duruma uygunluk, popülerlik, yapısal uyumluluk, istatistiksel kriterlere uyumluluk ve geçmişte yapılan çalışmalara uyumluluk gibi kriterlere göre yapılmaktadır. Tahmin modellerinde, uygun


değişkenlerin seçimi, özellikle ekonometrik modellerde daima zor bir istir. Geniş ve karmaşık model yapıları, tahminleme sürecinde istenmeyen bir durumdur [75].

Tahmin araştırması, geleceğe ait planlama ve karar sürecine destek sağlamak için yapılır. İşletmeler çeşitli kademelerde gelecekle ilgili planlamaya ihtiyaç duyarlar. Bazı işletmeler bir kaç yılın toplam parasal gelirlerinin tahmini ile ilgilenirken, diğeri de üretmiş olduğu ürüne ne kadar talep olacağı ile ilgilenebilmektedir.

Tahminleri dört temel başlık altında sınıflandırmak mümkündür. Bunlar; kalitatif (niteleyici), zaman serileri analizleri, nedensel ilişkiler ve simülasyondur. Kalitatif teknikler; sübjektif (öznel) veya yargısal ve öngörülere ve fikirlere dayalıdır. Zaman serileri analizleri; geçmiş talep verileri ile ilişkili olarak gelecekteki talebi tahmin fikrine dayalıdır. Geçmiş veriler; trend, mevsimsel veya devirli etkiler gibi değişik özelliklerde olabilir. Nedensel tahminleme; bazı temel faktör veya çevresel faktörlerle ilgili tahminlerdir. Simülasyon (benzetim) modelleri; gelecekte olması muhtemel olaylar hakkında tahminciye benzetim yoluyla belirli bir doğruluk oranında fikirler sunan modellerdir [76].

2.2.4 Tahmin Maliyetleri

Tahmine önem vermeyen işletmeler, geçmişte ne olduysa gelecekte de aynen devam edeceğini varsaymaktadırlar. Oysaki, tutarsız ve yetersiz tahminler, işletmelerin işgücü, malzeme veya sermaye maliyetlerini artırmakta ve gelirlerinin büyük bir kısmının kaybedilmesine neden olmaktadır. Diğer taraftan, bir işletmede tahmin faaliyeti yoğunlaştıkça veri toplama ve inceleme maliyetleri de buna bağlı olarak artacaktır. Bu yüzden, işletmeler uygun düzeyde bir denge sağlamak, tahmin çalışmalarına gerekli önemi vermek durumundadırlar [77]. Şekil 2.2’de tahmin maliyetlerinin dengelenmesinde ölçüt olabilecek tahmin maliyetleri grafiği gösterilmiştir.



Şekil 2.2 Tahmin maliyetleri grafiği [65]

Yukarıdaki Şekil 2.2'deki grafikte görüldüğü gibi, işletmelerin toplam maliyetlerini minimum düzeyde tutabilmeleri için tahmin çalışmalarını belirli bir denge düzeyinde tutmaları gerekmektedir.

2.2.5 Talep Tahmini

Talep, alıcıların her fiyat seviyesinde bir maldan, zaman birim başına satın almak istedikleri mal miktarıdır. Kısaca talep, insanların üretilmiş ya da üretilmesi düşünülen bir ürünü satın alma isteklerinin ölçüsüdür. İktisadi anlamda talep, tüketicilerin bir mal veya hizmeti belirli bir fiyat seviyesinde almaya hazır oldukları miktara denir. İşletmelerin temel amacı, piyasa talebini karşılamak üzere mal ve hizmet üretmek ve pazarlamaktır. Kısaca, işletmeler tüketici talebini karşılamak amacıyla faaliyette bulunmaktadır ve bunun için de pazarlama araştırmasıyla piyasa talebini ölçerek bu talebi karşılayacak bir üretim sistemi kurmaya çalışırlar.

Talep tahmini, işletmenin ürettiği mal ve hizmetlere olan talebi gelecek dönemler için tahmin edilmesi işlemine denilmektedir. Tahmin yapılırken, bir değişkene ait geçmiş zaman dilimlerinde elde edilen verilerden yararlanılarak, gelecekte neler olacağına dair ipuçları aranır. Günümüzde çağdaş işletme yöneticileri, sağlıklı kararlar alabilmek için, geleceğe ilişkin belirsizlikleri hatasız olarak tahmin etmek durumuyla karşı karşıyadır [1].

Talep tahminleri makroekonomik açıdan iki noktada önem kazanmaktadır. İlk olarak, ülke genelinde üretilmekte olan mallar, mevcut talebi karşılayamaz. Bu durumda yetersiz üretim nedeniyle fiyatlar yükselir, ithalat zorunluluğu ortaya çıkabilir. Buna bağlı olarak işletmeler piyasadaki talebi karşılamak üzere kapasitelerinin üzerinde çalıştıklarından dolayı, maliyetlerin artması durumuyla karşılaşır. İkinci olarak, işletmelerin ürettikleri mallardan bazıları satılamaz. Büyük miktarda mal stokları birikebilir. Bunun sonucunda büyük işletmeler kapasitelerinin altında çalışırlar. Bu durumda, üretim maliyetleri artarak kaynak israfı durumu ortaya çıkabilir. Yeterli ve doğru tahminler ile yukarıda açıklanan olumsuz durumlar ortadan kaldırılarak, daha etkin bir kaynak kullanımı ve üretim verimliliği elde edilebilir [78].

Tahmin işletmenin üretim seviyesinin saptanmasında temel oluşturur. Hangi ürünün üretilceği, tüketicilerin bu üründen ne miktar talep edecekleri ve bu talebin yoğunlukla hangi tarihlerde gerçekleşme olasılığının bulunduğu, talep tahminleri ile yorumlanır [24].

Gelecekteki üretim faaliyetlerinin planlanmasında ilk hareket noktası üretilmesi gereken veya istenen miktarlardır. Üretilmesi düşünülen ürüne ne kadar talep olacağı bilinmeden herhangi bir planlamaya kalkışılmaz. Hammadde, yedek parça, yarı mamul, makine, insan gücü ve yatırım ihtiyaçlarının saptanmasında temel veri talep tahminleridir [79].

İşletmelerin ürünlerine olan talebi tahmin etmeleri, pazarlama stratejilerinin belirlenmesinde önemli bir girdi niteliği taşımaktadır [80]. Üretim işletmeleri için talep, kısa dönemli bir tahmin modelinin ekonometrik özüdür. Üretim işletmelerinde yapılacak çalışmaların neredeyse tamamının talebe bağlı olması talep tahmininin ne kadar önemli olduğunu ortaya koymaktadır.

Tahminler, şirket faaliyetlerini (üretim, finans, Ar-Ge, satınalma vb.) birçok açıdan uygun hale getirilmesini teşvik etmekte ve kolaylaştırmaktadır. Satış tahmini, belirli bir pazarlama planında ve genelde şirket planlamasında hayati rol oynamaktadır. Önceden belirlenen kar hedeflerinin istendiği gibi gerçekleşmesini veya kısa, orta ve uzun dönemli amaçları elde etmek için tüm pazarlama planlarını kapsamaktadır.

İşletmeler amaçları doğrultusunda hedeflerine ulaşabilmek için, şirket kaynaklarının düzenleyicisi olan, etkili bir satış tahmini yaparak en uygun kar seviyesine ulaşabilirler [81].

Talep tahminleri, kullanılan tahmin yöntemlerinin etkinliğine bağlı olarak başarılı veya başarısız olabilir. Talep tahminleri belirli dönemler için yapılmaktadır. İşletmeler gelecek dönemlere ilişkin faaliyetleri planlamak amacıyla mal ve hizmetlere olan talebi belirli metotlar ve ölçülere göre tahmin ederler [65]. Tahmin işlemi, geçmiş faaliyetlerin seyrine göre projeksiyon metodu kullanılarak yapılabileceği gibi, gelecekte talebi etkileyen temel değişkenler için geliştirilen denklemler aracılığıyla da yapılabilir.

Talep tahminleri işletmenin kuruluş aşamasından başlayarak, fabrika yeri, kapasite kullanımı, stok kontrolü, ürün tasarımı, fiyatların belirlenmesi, kalite kontrolü, üretim planlama ve kontrolü, makine araç gereç seçimi ve işyeri düzenlenmesi gibi pek çok faaliyeti doğrudan ilgilendirmektedir [24], [65].

2.2.5.1 Talep Tahminlerinin Sınıflandırılması (Tahmin Dönemleri)

Talep tahminleri, zaman aralığı, kullanma amacı, ürün cinsi, hesaplama tekniği gibi çeşitli kriterlere göre sınıflandırılabilir. En fazla yapılan sınıflandırma, tahminlerin kapsadığı zaman aralığına göre yapılanıdır. Talep tahminlerinin kapsadığı zaman aralığı

büyüdükçe sonucu etkileyen faktörlerin sayısı artar ve bunlar arasındaki ilişkiler gittikçe karmaşık bir hal almaktadır. Buna karşılık süre kısaldıkça tahminlerin gerçeğe uygunluk derecesi artar.

Bir işletmenin talep tahminlerine duyduğu ihtiyaç, üretim tipi, imalat araçları ve yöntemleri, mamul çeşidi, tüketici eğilimi, rakiplerin durumu, stoklama olanakları, dağıtım kanalları gibi pek çok faktörün etkisi altında belirir. Bu faktörlerin bir kısmını içeren genel bir kural olarak denilebilir ki; tüketiciden gelen talep geldiği andan başlayarak mamulün istenen teslim zamanına kadar geçen sürenin uzunluğu talep tahmini ihtiyacını ortaya çıkarır. Tüketicinin isteklerini zamanında karşılamak amacıyla stoklamaya gidilmesi talep tahminlerinin önemini bir kat daha artırır [79].

Üretim yönetimi açısından, farklı planlama dönemlerine ilişkin tahminlere ihtiyaç duyulur. Bu farklı planlama dönemleri ve bunlara ait tahminlerin kullanıldığı karar alanları, Çizelge 2.1’de gösterilmiştir.

Çizelge 2.1 Planlama dönemleri ve kullanım amaçları [1]

Planlama Dönemi	Kullanım Amaçları (Karar Alanları)
Uzun Dönemli (2-10 yıl)	Üretilecek ürün ve hizmetlerin belirlenmesi
	Kullanılacak süreç ve teknolojilerin belirlenmesi
	Kapasite seçimi
	Kuruluş yeri seçimi
Orta Dönemli (1-24 ay)	İşgücü büyüklüğünün belirlenmesi
	Bulundurulacak stok düzeyinin belirlenmesi
	Yapılması gereken fazla mesai saatlerinin belirlenmesi
	Optimal üretim ve satınalma parti büyüklüklerinin belirlenmesi
Kısa Dönemli (1-8 hafta)	Siparişlerin makinelere tahsisi
	İnsan gücünün makinelere veya siparişlere tahsisi
	Siparişlerin işlem görme sıralarının belirlenmesi

Çizelge 2.1’de görüldüğü gibi, tahminler kullanım amaçlarına göre karar vericiler tarafından kısa, orta ve uzun dönem olarak yapılırlar. Tahminler bir plan dahilinde (genellikle üç aylık veya bir yıllık) her bir dönem (genellikle bir hafta veya ay) için yapılır. Tek tek, dönemlere göre yapılan tahminler daha sonra toplam talebi elde etmek üzere birleştirilir. Bundan yararlanılarak uzun dönem üretim planları yapılabilir.

Ürünün özellikleri ile talep modeli, yapılacak tahminin tipini ve kapsayacağı zaman süresini etkiler. Eğer mamule olan talep daima sabit ise, tahminin zaman süresi biraz daha kısa olabilir. Geleceği planlama, talebin daima aynı düzeyde kalacağı kabulüne

dayanır ve bu tarz durumlarda var olan kapasite genellikle talep hacminin çoğunu karşılayabilir. Ürüne olan talep dalgalanmalar gösteriyorsa, tahmin yalnız bir dönemi kapsamalıdır. Eğer talepte dönemsel değişiklikler varsa talebi karşılamak için fazla mesai veya stok gerekli olabilir. Talepte uzun bir zaman sürecinde, gittikçe artan bir eğilim bekleniyorsa, zorunlu olarak genişleme veya yeni donanımlar sağlanmasına olanak veren bir zaman süresi için tahmin yapılmalıdır. Bu zaman aralığı birkaç aydan, birkaç yıla kadar değişebilir. Bazı ürünlerin talep değerleri mevsimlere göre azalır veya çoğalır. Böyle durumlarda öncelikle talepteki mevsimsel değişimlerin nedenini iyi belirlemek gerekmektedir. Eğer talebin bazı mevsimlerde fazla, bazılarında az olmasını gerektiren geçerli nedenler varsa o zaman mevsimsel tahmin yöntemleri kullanılabilir [79].

Firmaların büyük bir kısmında birden fazla tahmine gerek vardır. Bunlar zaman sürelerine göre aşağıdaki şekilde sınıflandırılabilir [24]:

- Uzun vade tahminleri: İşletme tesislerinin genişletilmesi, yeni makine ve donanım için gerekli sermaye yatırımı planlamak için yapılır. Beş yıllık veya daha fazla olabilir.
- Orta vade tahminleri: Tedarik süresi belirsiz veya uzun olan malzeme alımlarının, üretim süreci karmaşık ürünlere ait üretim faaliyetlerinin, talebi mevsimsel dalgalanma gösteren mamul stoklarının planlanması amacıyla hizmet ederler. Altı aydan başlayarak beş yıla kadar uzanan bir süreyi kapsayabilirler.
- Kısa vade tahminleri: İşgücü seviyesini hesaba katarak, satınalma veya üretim için uygun sipariş miktar ve zamanlarını tespit etmek ve uygun üretim kapasitesini planlamak için yapılır. Üç aydan, altı aya kadar bir süreyi kapsar.
- Çok kısa vadeli tahminler: Haftalık, hatta günlük olarak parça, malzeme ve mamul stoklarının kontrolü veya montaj hattı is programlarının hazırlanması amacı ile yapılır. Daha çok işletme içi verilerden yararlanılır.

Talep tahmininin kapsadığı zaman aralığı büyüdükçe sonucu etkileyen faktörlerin sayısı artar ve bunlar arasındaki ilişkiler gittikçe karmaşık bir hal alır. Doğru bir tahmin için her detayı önemsemek gerekir. Buna karşılık vade kısaldıkça tahminlerin gerçeğe uygunluk derecesi de artar.

2.2.5.2 Talep Tahmini İlke ve Yöntemleri

Piyasa araştırması daha ziyade tüketicinin veya kullanıcının eğilimlerini ortaya koyar. Bu bilgiler elde edildikten sonra olayı teknik ve ekonomik açıdan ele alıp talebin ne miktarda olacağını hesaplamaya geçmek gerekir. Bu ancak bir tahminden ibarettir, ancak seçilecek yöntem ve kullanılacak verilerin gerçeklere yakın oluşu tahmindeki doğruluk şansını artırır. İlk planda ele alınan malın özellikleri ve kullanım alanları bilinmelidir. Yerli üretici olan firmaların kapasiteleri ve üretim miktarları bir istatistik veri olarak son on yılı kapsayacak şekilde ele alınmalı ve ithalat yapılıyorsa aynı şekilde incelenmelidir. Bu konudaki hükümetin ekonomik ve politik yaklaşımları tespit edilmeli ve sonra en pratik yol olarak istatistiksel yöntemlerle sonuca gidilmeli, talep tahmini yapılmalıdır. Burada esas olan talebin geçmiş yıllara ait değişim verilerinin bulunmasıdır [82].

Başlıca talep tahmin ilkeleri şunlardır [1]:

- Talep tahminlerinin kapsadığı zaman aralığı kısaldıkça tahminin duyarlılığı artar. İşletmenin üç yıllık satışının model alınması, sekiz yıllık model analizinden daha duyarlı olmaktadır.
- Talep tahmin araştırmalarında sapmaları belirleyecek hata hesaplamaları yapılmalıdır. Tahmin işlemi için kullanılan her model belirli bir standart sapmayagöre analiz edilerek değerlendirilmelidir. Meydana gelen sapmaları en az olan model kullanılmalıdır.
- Miktar ve çeşit bakımından büyük olan ürün grupları için yapılan tahminler daha duyarlı olmaktadır. Bu tür tahminlerde ürün grupları büyük olduğu için birçok değişiklikler olabilir. Bu değişiklikler elde edilecek sonucun belirli güven aralıklarına göre farklı olmasına sebep olabilir. Gruplar büyüdüğü taktirde, tahminler farklılık gösterecektir. Bu gibi durumlarda tahmin aralığını mümkün olduğu kadar düşük tutmak gerekir.
- Talep tahmin araştırması sonuçlarına göre uygulamaya geçilmeden önce bu bilgilerin doğruluğunun test edilmesi gerekir. Test aşamasında ortaya çıkan birtakım hatalar ve sapmaları, düzeltmek üzere gerekli tedbirler alınır.

2.2.5.3 Talep Araştırmasında Yapılacak İşlemler

Talep araştırması taleple doğrudan ilgili faktörleri belirlemek amacıyla yapılan bir araştırmadır. Talep araştırması, talep eğrisi, talep fonksiyonu, talep-fiyat ilişkisi, talebin fiyat esnekliği, talebin gelir esnekliği, üretim faktörleri, pazar dengesi gibi bilgilerin ışığında yapılan bir çalışmadır. Talep araştırması, prensipleri göz önüne alınmak koşuluyla başlıca 4 aşamada gerçekleştirilen bir faaliyettir [24], [78], [79].

1. Talep tahminiyle ilgili bilgi toplama: Araştırmanın değerini veya geçerliliğini etkileyen son derece önemli bir aşamadır. Gerçekten ise yarayacak bilgilerin toplanması işletmenin kayıt sisteminin iyiliğine bağlıdır. Geçmişe ait satış, tedarik, işlem zamanı ve maliyet kayıtları olmadan geleceği tahmin etmek güç hatta imkânsızdır. Diğer taraftan araştırmacının da amaçlarını göz önüne alarak toplayacağı bilgilerin cinsi, kapsamı ve ayrıntısı konusunda isabetli karar vermesi gerekir. Geniş kapsamlı bir pazar araştırmasıyla, talep tahmininde kullanılacak bilgilere ulaşılır. Bu bilgilerin talebi etkileyen bütün faktörleri ve konuyla ilgili tüm değişkenleri göz önünde bulundurulacak şekilde geniş ve detaylı bir araştırma sonucuna dayalı olması gerekir. Araştırmanın hedefine bağlı olarak bilgiler objektif ölçülere göre doğru ve tam olarak elde edilmelidir. Böylece araştırmadan elde edilmesi beklenen sonuçlara daha kolay ulaşılacaktır.
2. Talep tahmin döneminin tespiti: Talep araştırma 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 kaybolabilir.
3. Talep tahmin metodunun seçimi ve hata hesabı: Tahmin için toplanan bilgilerin belirsizlik, duyarlık, değişim gibi özellikleri ile uygulama amaçları kullanılacak yöntemin seçiminde göz önünde tutulması gereken unsurlardır. Duyarlı olmayan bilgilere çok ayrıntılı sonuçlar veren yöntemlerin uygulanması gibi çelişkili davranıştan kaçınılmalıdır. Ayrıntılı talep araştırması gerektiren durumlar için fazla ayrıntılı inceleme yapmayan metotların kullanılması, istenilen sonuçların elde edilmesini engelleyebilir. Aynı ölçünün ve durumun hata hesabında da dikkate alınması gerekmektedir. Bir tahminin doğruluğu, tahmin edilen değerler ile gerçekleşen değerler arasındaki farktır. Bu farka hata denir. Doğru bir

tahminin özellikleri, önyargılı olmaması (sapmasız) ve tutarlı olmasıdır. Önyargısız bir tahmin, ortalama sıfır sapmaya sahiptir. Etkili bir tahmin yapıldığı zaman elde edilen tüm bilgileri yansıtır [75].

4. Tahmin sonuçlarının geçerliliğinin araştırılması: Çeşitli bilgilere dayanılarak yapılan tahminlerde gerçek değerler arasındaki farkların sistematik biçimde tespiti ve nedenlerinin araştırılmasıdır. Tahmin geçerliliği büyük ölçüde toplanan bilgilerin doğruluk derecesine bağlıdır. Elde edilen sonuçlarla gerçekleşen sonuçlar arasındaki farklar bulunarak, bu farkların nedenleri araştırılmalıdır. Bu faaliyetin satış veya pazarlama yerine üretim planlaması ve kontrol bölümünün sorumluluğuna verilmesi yerinde olur. Çünkü sapmaların giderilmesi yolunda alınacak tedbirlerin büyük çoğunluğu üretim planlaması ve kontrol bölümünü ilgilendirir.

Çalışmanın bu bölümünde, çalışmanın kavramsal temelini oluşturan üretim planlamanın ve dolayısıyla talep tahmininin temel kavramlarından üretim planlaması ve kontrolü, tahmin teorileri ve tahminleme yöntemleri ve talep tahmini kavramlarıyla ilgili kısa tanımlamalar yapılmıştır. İlerleyen bölümlerde ise, uygulamada kullanılan istatistiki talep tahmin yöntemleri, yapay sinir ağları metoduyla talep tahmini, yapay sinir ağlarının eğitimi, testi ve tahminlerin hata testleri konularında, uygulama ile ilgili önemli bulunan bilgiler sunularak yapılan yapay sinir ağlarıyla ürün talep tahmini uygulamasının çalışma mantığı ve anlaşılabilirliği artırılmaya çalışılmıştır.

BÖLÜM 3

TALEP TAHMİNİ

3.1 İstatistiksel Yöntemlerle Talep Tahmini

İşletmelerin ürettikleri mal ve hizmetlerin birbirinden farklı olması, kullanılan talep tahmin yöntemlerin de farklı olmasını gerektirmektedir. Tüketici davranışlarının birbirinden farklı olması, bir tek talep tahmin yönteminin kullanılmasını zorlaştırmaktadır. Piyasadaki değişikliklere göre farklı şekillerde uygulanan değişik tahmin yöntemleri bulunmaktadır. Uygulamalarda yaygın olarak kullanılan başlıca talep tahmin yöntemleri olarak; görüş toplama metodu, ekonomik göstergelere dayanan tahmin metodu, istatistiksel metotlarla yapılan talep tahmini sayılabilmektedir.

İstatistiksel yöntemler, geçmişteki talep durumlarını, talebi etkileyen faktörleri ve ekonomik gösterge ilişkilerine göre analiz ederek, talep tahmini yapılmasını sağlamaktadır. İstatistiksel yöntemlerle geçmiş olaylar incelenerek gelecekle ilgili planlar yapılabilmektedir. Talep tahmininde en yaygın kullanılan istatistiksel yöntemlerden bazıları; regresyon metodu, korelasyon katsayısı metodu, eğri uyurma metodu, zaman serileri analizi metodu, hareketli ortalamalar metodu olarak sayılabilir [1], [78].

İstatistiksel yöntemlerle talep tahmini, günümüz koşullarında içinde başvurulması zorunlu hale gelen bir yoldur. Talebi etkileyen faktörlerin çokluğu ve bunlar arasındaki ilişkilerin karmaşıklığı, tecrübe ve sezgiye dayanan yöntemleri geçersiz değilse de yetersiz kılmaktadır. Talep tahminlerinde kullanılan teknikler, uygulamalı istatistiğin konuları arasında yer almaktadır [79].

İstatistik metodolojisinin uğraştığı temel alanlardan birisi, ana kitle ile ilgili özelliklerin tahminidir. Özellikle ana kitlenin çok büyük olduğu ve parametrelerin doğrudan

hesaplanmasının mümkün olmadığı durumlarda, istatistiksel tahmin yoluna başvurulması gerekmektedir [1].

İstatistiksel tahmin yöntemlerinin seçilmesi sürecinde, veri özelliklerinin ve tahminin yapılacağı zaman periyodunun (kısa-orta-uzun vadeli olması) göz önünde tutması gerekmektedir. Örneğin, üssel düzeltme metodu, dairesel bileşenlerin baskın olduğu veriler üzerinde yapılan uygulamalarda daha iyi sonuçlar verirken, hareketli ortalamalar metodu, gürültülü özelliklerin baskın olduğu uygulamalarda daha üstün sonuçlar üretebilmektedir [8].

Sayısal tahminleme, gelecekte ortaya çıkması muhtemel gelişmelerin, planlamaların, niceliksel değerlerinin (bir ürün tohumunun büyüüp gelişme süresinin tahmini gibi) önceden tahmin edilmesi olarak tanımlanmaktadır. Tahminin tutarlılığı ve performansı üretim planlaması için oldukça önemlidir [75]. Sayısal tahminleme teknikleri, geçmiş verilerden ve değişkenlerden yararlanarak, matematiksel bir model oluşturularak yapılan tahminlerdir. Çeşitli açılardan sınıflandırılabilir de esas olarak, sebep-sonuç ilişkisine dayanan teknikler ve zaman serisi analizlerine dayanan teknikler olarak iki gruba ayrılabilir [24].

Tahmin işleminde kullanılabilecek çok sayıda model bulunmaktadır. Bunları, sayısal olmayan tahmin modelleri ve sayısal tahmin modelleri şeklinde iki ana grupta toplamak mümkündür. Geçmişe ilişkin yeterli veri bulunmaması durumunda, kişisel yargı, gözlem, deneyim ve uzmanlığa dayalı olarak tahmin yapılabilmektedir. Sayısal modeller ile tahmin yaparken ise, geçmişe ait verilerden yararlanılmaktadır. Tüm sayısal teknikler, geçmişe ilişkin doğru ve yeterli bilgi toplanmasını gerekmektedir. Ne kadar kapsamlı bir tahmin modeli kullanılırsa kullanılsın, yetersiz ve doğruluk derecesi düşük veriler ile iyi sonuçlar alınması mümkün olmamaktadır. Yeterli ve doğru verilerin bulunmaması, tahmin yönteminin seçimi sürecine kısıtlama getirmektedir. Sayısal tahmin yöntemlerini bir kısmı son derece basit olmasına rağmen, bir kısmı da oldukça karmaşık yöntemlerdir. Bazı yöntemlerin diğerlerinden daha iyi sonuç verdiği görülmekteyse de, bir genelleme yapmak mümkün olmamaktadır. Farklı yapıdaki tahmin durumlarının, farklı yöntemlerle ele alınmaları gerekir [68].


Sayısal tahmin yöntemleri; nedensel yöntemler ve zaman serileri yöntemleri olmak üzere iki kategoride sınıflandırılabilir. Nedensel yöntemler, bağımlı ve bağımsız değişkenler arasındaki ilişkileri analiz etmek için tasarlanmış yöntemlerdir. Regresyon

analizleri ve yapısal yöntemleri içermektedir. Gelir dağılımı, fiyat ilişkileri, yaşam maliyetleri, gayri safi milli hasıla, yaşam maliyetleri, döviz değişim oranları, ülke nüfusu, ulaşım maliyetleri gibi değişkenler arasındaki ilişkileri ve ilişki derecelerini ölçmek amacıyla kullanılmaktadırlar [13]. Geçmiş hakkında bilgiler bulunduğunda, elde edilen bu veriler sayısal forma dönüştürülebildiğinde ve bazı belirli görüşlerin gelecekte de aynen devam edeceği varsayıldığı durumlarında sayısal tahmin yöntemleri uygulanabilir.

Sayısal tahmin yapılabilmesi için gereken çalışmaların beş temel aşamadan oluştuğu görüşü bulunmaktadır:

- Problemin tanımlanması,
- Bilgilerin toplanması,
- Ön hazırlık analizlerinin yapılması,
- Model seçimi ve uyumlulaştırılması,
- Tahmin modelinin uygulanması ve değerlendirilmesi aşamalarıdır [83].

Gerçekleşen ürün veya hizmet talebi; dönemsel ortalama talep, trend, sezonsal (mevsimsel) etkiler, periyodik(döngüsel) unsurlar, rastgele değişim ve otokorelasyon olarak genellikle altı biçimde sınıflandırılabilir [76]. Şekil 3.1’de dört yıllık dönemi kapsayan bir talep durumu örneklenmiş ve bu grafikte ortalama, trend, mevsimsel bileşenler ve yumuşatılmış talep eğrisi etrafında rastgele dağılmış talep bir tek grafik üzerinde gösterilmiştir.



Şekil 3.1 Büyüme eğilimi ve mevsimsel talep eğrilerinin gösterimi [24]

Yapay sinir ağları, özellikle son yıllarda yaygın olarak kullanılmaya başlanan önemli bir talep tahmin yöntemidir. Yapay sinir ağları metodunun temelinde geleneksel talep

tahmin yöntemlerinden olan; Regresyon Analizi, Korelasyon Analizi, Hareketli Ortalamalar, Üssel Düzeltme Yöntemi, Box-Jenkins Yöntemi, Otoregresif Hareketli Ortalamalar Yöntemi, Otoregresif Bütünleşik Hareketli Ortalamalar, Simülasyon Yöntemi yer almaktadır. Bu yöntemlerle ilgili olarak kısaca bilgi verilecektir.

3.1.1 Regresyon Analizi Yöntemi

Regresyon analizi, herhangi bir değişkenin (bağımlı değişken) bir veya birden fazla değişken ile (bağımsız veya açıklayıcı değişken) arasındaki ilişkinin matematiksel bir fonksiyon şeklinde yazılmasıdır. Bu fonksiyona regresyon denklemi adı verilmektedir. Regresyon denklemi yardımıyla bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi kuran parametrelerin değerleri tahmin edilmektedir. Bağımlı değişkeni etkileyen bağımsız değişkenlerin tahmin edilmesi, bu değişken üzerinde geliştirilecek plan ve politikalarda hangi değişkenlerin önem kazandığının belirlenmesine yardımcı olmaktadır [24].

Regresyon analizi yöntemi sayesinde hangi faktörlerde nasıl bir değişiklik yapılırsa, ilgilenilen değişkende artış veya azalış meydana geleceği ortaya çıkarılabilmektedir. Yeterli düzeyde açıklayıcı gücü olan güvenilir bir regresyon katsayısı ile güvenilir tahminler yapılabilir. Regresyon analizinde, eşitlik (formül) dönemsel olarak değişen geçmiş veriler kullanılarak geliştirilebilir. Eğer tahminde bağımsız değişkenlerin değerleri büyük ölçüde sıra dışı değerler ise, tahmin hatası da fazla olacaktır. Geçmiş veriler düzenli ve sürekli ise tahminin tutarlılığı da o ölçüde yüksek olur [73].

İki veya daha fazla değişken arasındaki ilişki doğrusal ya da eğrisel olmaktadır. Temel olarak basit doğrusal regresyon, çoklu doğrusal regresyon, üssel regresyon ve eğrisel regresyon denklemleri bulunmaktadır. Bu denklemler matematiksel olarak aşağıdaki şekilde ifade edilmektedirler.

$$\text{Basit Doğrusal Regresyon} : Y = a + bX \quad (3.1)$$


$$\text{Çoklu Doğrusal Regresyon} : Y = a + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (3.2)$$

$$\text{Üssel Regresyon} : Y = a + b_1^x \quad (3.3)$$

$$\text{Eğrisel Regresyon} : Y = a + b_1X + b_2X^2 + \dots + b_nX^n \quad (3.4)$$

Basit doğrusal regresyon, iki değişken arasındaki ilişkinin doğrusal olduğu kabul edilirse, denklem “ $Y = a + bX_i + e$ ” şeklinde ifade edilir ve bağımsız değişkenin değeri yerine konarak tahmin değeri elde edilir. Bu denklemdaki a, b değerlerinin

bulunabilmesi için En Küçük Kareler yöntemi (EKK) kullanılmaktadır [1]. En küçük kareler metodunda kullanılan matematiksel ifadeleri grafiksel olarak Şekil 3.2'deki gibi göstermek mümkündür.




Şekil 3.2 Regresyon doğrusu [84]

Şekil 3.2'de regresyon doğrusuna ait grafikte görüldüğü gibi, doğru üzerindeki bağımlı değişken değerleri ile gerçek değerler arasındaki farkın karelerinin toplamını minimum yapacak en uygun doğru belirlenmeye çalışılmaktadır.

3.1.2 Korelasyon Yöntemi

Regresyon denklemi, bağımsız değişkenlerdeki değişiklikler karşısında, bağımlı değişkenin alacağı değerleri göstermektedir. Korelasyon ise, iki değişken arasındaki ilişkinin derecesini ifade eden bir kavram olup, doğrunun uygunluğunu ölçmektedir. Başka bir deyişle, denklemin ilişkiyi ne ölçüde tanımladığını gösterir. İlişki ne kadar güçlü ise oluşturulan tahminlerin doğruluğunun da o derece artması beklenir [68].

Basit korelasyon, iki değişken arasındaki ilişkinin yakınlığını korelasyon katsayısı cinsinden ifade etmektedir. İki değişken arasındaki ilişkinin derecesini gösteren korelasyon katsayısı (r) ile gösterilmektedir. Şekil 3.3'te gerçekleşen değerler ile, tahmin edilen değerler arasındaki korelasyonu gösteren eğrinin grafiği görülmektedir. Korelasyon katsayısı, gözlem noktalarının regresyon doğrusu karşısında gösterdiği değişkenliğin dolaylı bir ölçüsüdür [1].



Şekil 3.3 Korelasyon katsayısı eğrisi [1]

Şekil 3.3'te bağımlı değişkenin gerçek değerlerinin oluşturduğu Korelasyon eğrisi görülmektedir. Korelasyonu incelenen iki değişken arasındaki ilişki değeri sürekli 1'den küçük olmaktadır. Çizelge 3.1'de korelasyon katsayısının aldığı değerlerin yorumlanmasında kullanılan ölçütler verilmiştir [78].


Çizelge 3.1 Korelasyon katsayısı değerleri ve yorumlamaları [78]

Korelasyon Katsayısı Değerleri	Yorumlamaları
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

Çizelge 3.1'de görüldüğü üzere korelasyon katsayısı değerlerinin 1'e yaklaşması, yüksek korelasyon oluştuğuna; 0'a yaklaşması düşük korelasyon ilişkisine işaret etmektedir. Korelasyon katsayısı (r), (-1,1) arasında herhangi bir değer almaktadır. Buradaki korelasyon değeri, yine x değerleri beraber artıyorsa pozitif; x arttığında y azalıyorsa negatif bir değer alır. İki değişken arasında bir ilişki olmaması durumunda $r=0$ değerini alır. Korelasyon katsayısı, aldığı değere göre aşağıdaki biçimde yorumlanmaktadır:

- Korelasyon katsayısı (r), 0'a yakınsa ilişkinin zayıf,
- Korelasyon katsayısı (r), +1'e yakında ilişkinin kuvvetli pozitif,
- Korelasyon katsayısı (r), -1'e yakında ilişkinin kuvvetli negatif olduğu görülmektedir.

Korelasyon katsayısının işareti, her zaman b katsayısınınkiyle aynıdır olmaktadır. Bu durum, regresyon doğrusunun eğiminin negatif olması halinde, korelasyon katsayısının değerinin de negatif olacağını göstermektedir [68]. Şekil 3.4'te korelasyon katsayısı değerlerine göre oluşan doğrular ve yorumlamaları gösterilmektedir.



Şekil 3.4 Korelasyon katsayısının yorumlanması [1], [68]

Şekil 3.4'te görüldüğü gibi korelasyon değeri 1'eyaklaştıkça ilgililişim yükselmekte ve grafiklerdeki dağılım bir doğru etrafında yoğunlaşmaktadır. Tam tersine 0'a yaklaştıkça da dağılım yayılmaktadır.


3.1.3 Zaman Serileri Analizine Dayanan Talep Tahmin Yöntemleri

Zaman serileri analizi, bir işletmenin geçmiş satışlarının incelenmesi ve bu satışlara ilişkin belirli bir eğilim olup olmadığının tespit edilerek, gelecekle ilgili talep tahminlerinin yapılmasıdır [1]. Zaman serileri analizleri, geçmiş verilerin zaman içinde gösterdiği düzeni esas almaktadır. Amaç, geçmiş verilere bakılarak geleceğin tahmin edilmesidir [68]. Geçmişe ait verilerin, belirli aralıklarla toplanmasıyla ortaya çıkan istatistik verilerdir [24]. Zaman serileri, bir değişken üzerinde düzenli aralıklarla yapılan bir dizi gözlemdir [70].

Zaman serisi analizi yapılırken, belirli dönemlerde gözlemlenen talep bilgileri bir ölçeğe göre sıralanmakta ve oluşturulan talep doğrusunun belirli bir düzen gösterip göstermediğine bakılmaktadır. Bu gözlem sonucunda, talebin sabit olduğu, bir eğilim

gösterdiği veya mevsimsel/dönemsel değişimler geçirdiği veya bunların hepsinin karışık bir şekilde dağılım gösterdiği gözlenebilmektedir.

Zaman serisi analizi yapan kişiler, belirli zamanlarda gözlemlenen talep verilerini yerleştirerek bir zaman ölçeği oluştururlar. Verilerin yerleştirdikleri bu noktalar incelenerek, bu noktaların zaman içerisinde kararlı bir seyir izleyip izlemediklerini tespit etmeye çalışırlar [85]. Zaman serilerinde, ortalama talep düzeyinde uzun dönemli bir artış veya düşüş görülmesi halinde, bir eğilimden bahsedilebilir. Eğilim; artan, azalan, doğrusal veya doğrusal olmayan bir şekilde olabilir. Talep düzeninde uzun vadeli bir eğilim tespit edildiği zaman, yöneticilerin bu sonuca göre bir talep beklentileri olabilecektir [68]. Şekil 3.5'te zamana göre değişebilen çeşitli talep düzenleri gösterilmiştir.



Şekil 3.5 Zamana göre çeşitli talep düzenleri [68]

Şekil 3.5'te, zaman serileri analizine dayanan talep tahminlerindeki eğilimlerden, doğrusal eğilim, mevsimsel değişimler eğrisi ve değişmeyen sabit talep düzenleri bir grafik üzerinde gösterilmiştir.

Zaman Serisi Analizleri Yöntemleri uygulanırken izlenmesi gereken adımlar aşağıda belirtilmiştir [85]:

1. Tahmin yönteminin değerlendirilmesi, yürütülebilmesi için ilgili zaman serisi iki eşit parçaya bölünür.
2. Tahmin yöntemi mümkün olan metotlar içerisinde seçilir.
3. Başlangıç veri seti tahmin yöntemini başlatmak için kullanılır.
4. Modelin parçalarını hesaplamada kullanılmayan veriler de, tahminde etkisinin nasıl olduğunu görmek için test setine uygulanır. Her bir tahminden sonra

tahmin hataları hesaplanır. Bu aşama modeldeki parametre değerlerinin uygun hale getirilmesi için başlangıç işlemlerinin düzenlenmesini gerektirir.

5. Değişik veri örnekleri için tahmin yönteminin uygunluğu değerlendirilir.

Zaman serisi analizine dayanan tahmin yöntemlerinden en çok kullanılanlarından bazıları; Basit Ortalamalar Yöntemi, Son Dönem Talebi Yöntemi, Hareketli Ortalamalar Yöntemi, Üssel Düzeltme Yöntemi ve Box-Jenkins yöntemleri şeklinde sıralanabilir.

3.1.3.1 Basit Ortalamalar Yöntemi

Basit ortalama, bir serideki veriler toplamının, fiili gözlem sayısına bölünmesi yoluyla bulunmaktadır. Geçmiş ilişkin veriler, genellikle bir artış veya azalış eğilimi göstermiyorsa veya gelecek için büyük çaplı bir değişiklik beklenmiyorsa tahmin çalışmalarında bu yöntem kullanılabilir. Ancak izleyen dönemlerde artış veya azalış eğilimi başladığı durumlarda gerçekleşen talep, öngörülen talepten aynı yönde giderek artan sapmalar gösterecektir [79].

3.1.3.2 Son Dönem Talebi Yöntemi

Son dönem talebi yönteminde, bir önceki dönemde gerçekleşen talep, gelecek dönemde de gerçekleşecek talebin tahmini olarak kullanılmaktadır. Bu yöntem uzun hesaplamalar gerektirmemektedir. Geçmişe ait veriler, bir ortalama değer etrafında sürekli ve az değişim eğilimi gösteriyorsa tercih edilmektedir [65].

3.1.3.3 Hareketli Ortalamalar Yöntemi

Talepteki mevsimsel dalgalanmaların incelenmesi yoluyla bu dalgalanmaların talep üzerindeki etkisinin belirlenmesinde kullanılan bir yöntem olarak bilinmektedir. Geçmiş dönemlerdeki satışların incelenmesiyle ve satışların zamana göre gösterdiği eğilim doğrusundan yararlanılarak, gelecek dönemlerdeki talep tahminleri yapılabilir.

Hareketli ortalamalar yönteminin en belirgin özelliği, mevsimsel etkilerin talep üzerindeki etkilerini belirgin olarak ortaya çıkarması ve çok eskiye ait geçmiş dönem verilerini dikkate almamasıdır. Hareketli ortalamalara dayanarak yapılan tahminler, aylık satışların, önceki veya yakın dönemli ayların etkisinde olması durumunda iyi sonuç vermektedir [65].

Hareketli ortalamalar yöntemine göre 3, 4, 6 ve 12 aylık satış ortalamalarına göre değerlendirmeler yapılabilmektedir [78]. Hareketli ortalama yönteminde, her seferinde en eski değeri çıkarmak ve yeni değeri eklemek yoluyla belli sayıda döneme ilişkin değerlerin tekrarlı olarak ortalamasının alınmasıyla elde edilir. Hareketli ortalamalar, genel veri düzenini korumakla birlikte, verilerdeki dalgalanmaları düzeltebilmektedir. Ancak, bir tahmin denklemi oluşturmazlar ve veri serilerinin son dönemlerine ilişkin tahmini değerlerin elde edilmesini sağlamazlar [70].

Yeni bilgiler geldikçe düzeltilen ortalamalara hareketli ortalamalar denir. Her seferinde en eski değeri çıkarmak ve yeni değeri eklemek suretiyle, belli sayıda geçmiş döneme ilişkin gerçekleşen talep değerlerinin ortalaması alınarak elde edilmektedir. Elde edilen sonuç, bir sonraki dönem için tahmin değeri olarak kullanılmaktadır. Tepki hızı, hareketli ortalamaya alınan dönem sayısı ve her döneme verilen ağırlık ile kontrol edilmektedir. Örneğin üç aylık hareketli ortalama ile Temmuz ayının satış tahmini, Nisan, Mayıs ve Haziran aylarının satışlarının ortalaması alınarak bulunmaktadır [68].

Hareketli ortalamalar yöntemi, uzak geçmişten çok, yakın geçmişe ağırlık verir ve buna dayanarak, yalnızca bir dönem için satış tahminini yapar. Örneğin geçmiş tarihi dönem verilerinin üçü, dördü veya beşi alınarak, en son gerçekleşen dönem bunlara ilave edilir. Daha sonra, bu verilerin ortalaması, bir sonraki dönem satış miktarı olarak kabul edilir [1].

Hareketli ortalamalar yöntemi, talebin yükselen bir eğilim gösterdiği durumlarda düşük bir tahmin değerini; talebin azalan bir eğilim gösterdiği durumlarda ise yüksek bir tahmin değerini ortaya çıkarmaktadır.

3.1.3.4 Ağırlıklı Ortalama Yöntemi

Belirli dönem verilerinin (en yakın geçmiş dönem verileri), gelecek dönemler için kesin bir fikir verdiği durumlarda bu yöntem kullanılabilmektedir. Ağırlıklı ortalama yönteminin dayandığı ana düşünce, geçmişteki bilgilerin ortalama olan etkisinin aynı olmadığıdır. Bu nedenle, eğilim durumu ve diğer etmenlerin etkisi ortalama olarak sönümlenmelidir. Bu yöntemde ilk dönemden itibaren tüm dönemler dikkate alınmaktadır [65].

3.1.3.5 Ağırlıklı Hareketli Ortalama Yöntemi

Ağırlıklı hareketli ortalama yönteminde, ağırlıklı ortalama yönteminde olduğu gibi dönemler ağırlıklandırılmaktadır. Ancak, geçmişe ait tüm değerler dikkate alınmamaktadır. Bu yöntemde, tahmin yapılırken belli sayıdaki en yakın dönem değerleri dikkate alınmaktadır. Hesaplama sırasında, yakın zamanlı olan dönemlere daha fazla ağırlık verilmektedir. Dikkate alınacak dönem sayısı ve ağırlıklar değiştikçe tahmin değerleri de değişmektedir [65].

3.1.3.6 Üssel Düzeltme Yöntemi

Üssel düzeltme yöntemi, ağırlıklı ortalama sistematığını dikkate alan bir tahmin yöntemidir. Geçmiş dönem verilerine eşit ağırlık veren basit hareketli ortalamalar yöntemine benzemekte olup; geçmiş dönem verilerine eşit olmayan, farklı ağırlıkların verildiği yöntemler topluluğudur. Üssel terimi, verilen ağırlıkların veriler eskidikçe üstel bir şekilde azalması anlamını taşımaktadır. Diğer bir ifadeyle, tahminde kullanılan geçmiş dönem verilerinden yakın geçmişte gerçekleşenlere yüksek üssel değerler vermesi, eski verilere düşük üssel değerler verilmesi anlamını taşımaktadır [24].

Üssel düzeltme, hareketli ortalamalarda en yakın geçmişteki verilerin daha fazla ağırlık taşımalarını sağlayacak şekilde, geçmiş verileri üstel olarak ağırlıklandıran tahmin yöntemidir. Verilen ağırlıklar üstel fonksiyonla ifade edilebilen bir seri oluşturduğu için istatistiksel verinin saklanması zahmetinden kurtulunur. Üstel düzeltmenin avantajı, eski verilere gereksinim duyulmadan hesaplama kolaylığı sağlamasıdır [65].

Yöntemde kullanılan düzeltme katsayısı (α), 0 ile 1 arasında değerler alabilmektedir. Buradaki α katsayısının kullanılması, gerekli verilerin miktarını önemli ölçüde azaltmaktadır. Artık hareketli ortalamalar yönteminde olduğu gibi ortalama dâhil edilen dönem sayısı kadar veriye ihtiyaç kalmamakta, içinde bulunan dönemin tahmin değerini elde etmek için, sadece bir önceki dönemin gerçekleşen ve tahmini talep rakamları yeterli olmaktadır [68].

Düzeltilme katsayısı (α), $\alpha=1$ seçildiği durumda yöntem, son dönem talebi yöntemine dönüşmektedir. $\alpha=0$ seçildiği durumda ise ilk dönem talebi ileriki dönemlere aynen aktarılmış olur ki bu durum anlamsızdır. Bu nedenler α katsayısının 0,2 ile 0,8 arasında seçilmesi önerilmektedir. Yüksek α değerleri, dalgalanan talep miktarları için tahmin yaparken kullanılmaktadır ve genellikle son döneme ait gerçekleşen talep değerlerine

ağırlık verilmesini gerektirmektedir. Bu durumda son dönem verisinin ve dolayısıyla rastgele etkenlerin tahmin üzerindeki etkisi büyük olacaktır. Düşük α değerleri ise, daha kararlı yapıya sahip olan veri setleri için tahminde bulunurken kullanılmakta olup, geçmişin ortalamasından yararlanılmasını sağlamaktadır. Bu durumda geçmiş verilerin tahmine olan etkisi daha büyük olacak ve rastgele değişkenlerin etkisi azalacaktır [65].

3.1.3.7 Box-Jenkins Yöntemi

Box-Jenkins metodu tek değişkenli bir model olup, kısa dönemli tahminlerde oldukça başarılıdır. Box-Jenkins yönteminin uygulandığı serinin, eşit zaman aralıklarıyla elde edilen gözlem değerlerinden oluşan kesikli ve durağan bir seri olması, bu metodun önemli bir varsayımdır. Tekniğin amacı, en az sayıda parametre içeren uygun modeller elde etmektir. Box-Jenkins'ten önce kullanılmakta olan Hareketli Ortalama ve Üssel Düzeltme Teknikleri'nde tahmin değerleri, otomatik olarak bilgisayar programına müdahale edilmeden elde edilirken, Box-Jenkins tekniğinde bu işlem tamamıyla otomatik değildir. Ayrıca diğer tekniklere göre oldukça karmaşık ve anlaşılması zordur. Box-Jenkins yönteminin, incelenen serilerin durağan olup olmamasına, mevsimsel etki içerip içermemesine göre, farklı şekillerde tahmin modelleri geliştirme yeteneği vardır. Öte yandan Box-Jenkins yöntemine, zaman serileri için doğrusal filtreleme tekniği de denilmektedir [24].

3.1.3.8 Otoregresif Hareketli Ortalamalar (AR-MA) Yöntemi

Zaman serilerinin modellenmesinde esneklik sağlamak ve en az sayıda parametre ilkesini gerçekleştirmek amacıyla bazı durumlarda, modele hem otoregresif ve hem de hareketli ortalama parametrelerinin alınması daha çok yarar sağlamaktadır. Bu düşünce Otoregresif Hareketli Ortalamalar yöntemini ortaya çıkarmıştır. Otoregresif Hareketli Ortalamalar yönteminde herhangi bir zaman serisinin, herhangi bir dönemine ait elde edilen gözlem değerleri, söz konusu dönemden önceki, belirli sayıdaki gözlem değeri ve hata teriminin doğrusal bir bileşimi olarak ifade edilmektedir.

Otoregresif (AR) süreç, zaman içinde verilerin değişmeyeceği varsayımına dayanmaktadır. Örneğin ayda 100 birim satış varsa bu farkı kapatmak için aylık 100 birim yerine koyulur. Daha fazla veya daha az satış olma durumu olmazsa süreç etkilenmez. Bu durum otoregresif bir süreçtir. Hareketli ortalama (MA) süreci ise,

serinin gecikmeli hata teriminin, şimdiki hata terimini etkileme durumu olarak tanımlanmaktadır [84].

3.1.3.9 Otoregresif Bütünleşik Hareketli Ortalamalar (ARIMA) Yöntemi

Otoregresif Bütünleşik Hareketli Ortalamalar modeli, zaman serileri temelli sayısal bir model olup; tek veya çok değişkenli olabilmektedir. Talep tahmini çalışmalarında çoğunlukla tek değişkenli Otoregresif Bütünleşik Hareketli Ortalamalar yöntemi kullanılmaktadır [32]. Modelin temel işlevi otoregresif süreçler içermesidir. Yani, geçmiş verilerden yararlanarak gelecekle ilgili istatistiksel tahminler yapabilmesi, süreçleri birleştirmesi ve hareketli ortalama süreçlerinin hepsini birlikte içermesi olarak bilinmektedir [29].

Box ve Jenkins iki modeli birleştirerek Otoregresif Bütünleşik Hareketli Ortalamalar modelini geliştirmiştir. Bu yaklaşım, zaman serilerinin durağan olduğu varsayımına dayanmaktadır. Zaman serilerinin durağan olmaması, belirli bir eğilim içermesi anlamına gelmektedir. Zaman serilerinin durağan olmaması durumunda, zaman serilerinin bir veya daha fazla kere farkının alınması ile durağanlaştırılarak Otoregresif Bütünleşik Hareketli Ortalamalar yapısı oluşturulabilmektedir [84].

3.1.4 Simülasyon (Benzetim) Yöntemiyle Talep Tahmini

Simülasyon terimi, en genel biçimde “gerçek sistemin işleyen bir modeli” olarak tanımlanmaktadır. Simülasyon, gerçek sistemi arayan bir analiz yöntemi olarak da düşünülebilir. Gerçekten de, kurulan bir simülasyon modeli, işlemeye başladığı andan başlayarak gerçek sisteme biraz daha yaklaşmış olur [1].

Simülasyon en geniş anlamda gerçeğin temsil edilmesi demektir. Bu anlamıyla simülasyon bir benzetim işlemi olmaktadır. Simülasyon gerçek olayların sözel, şekilsel veya sembolik olarak temsil edilmesidir.

Benzetim yönteminde, dışsal değişkenlerin verilerine göre, içsel değişkenlerde gelecek dönemlerde meydana gelmesi muhtemel değişiklikler hesaplanmaktadır. Kısaca, simülasyon ile geleceğin tahmini yapılmaktadır.

Rekabetin her geçen gün arttığı, piyasa koşullarının zorlaştığı günümüzde karmaşık süreç ve sistemlerin tasarlanmasında benzetim en güçlü analiz araçlarından birisi olarak kabul edilmektedir. Çünkü benzetim; sistemde oluşabilecek risklere karşı sisteme yeterli

esnekliđi kazandırabilmek için sistemin işletiminden sorumlu kişilere çalışmalar yapma imkanı sunmaktadır [1], [86].

Benzetim iki farklı açıdan incelenebilmektedir. Bunlardan birincisi “benzeştirme”, diğeri ise “matematiksel benzetim”dir. Benzeştirme, fiziksel bir sistemin aynısının laboratuvar ortamında oluşturulması ve bu ortam üzerinde denemelerin yapılması anlamına gelmektedir. Örneğın, bir lastik üreticisinin lastiklerin yol dayanıklılık testini gerçek bir yol yerine gerçeğine çok benzer oluşturulan bir cihaz veya ortamda yapmasıdır. Matematiksel benzetim, sistemin matematiksel modelinin oluşturularak bilgisayar ile analizinin yapılması anlamındadır. Bu anlamıyla benzetim, işletme problemlerinin çözülmesinde, sıkça kullanılan bir teknik haline gelmiştir [67].

Benzetim, matematik modellerin kullanılmadığı her yerde uygulanabilen çok esnek ve etkili bir yöntemdir. Bir problemin simülasyon yöntemi ile çözülebilmesi için tek şart sistemin davranışlarına ait bilgi toplayabilmektir. Ayrıca simülasyon ile elde edilen çözümlerin optimal olmadığı, ancak yeterli sayıda tekrardan sonra optimum değere yaklaşılabileceğı unutulmamalıdır [79].

İşletme problemlerinin analizi için tanımlanan bir sistemin modeli bazen çok karmaşık olabileceğı gibi kurulan modelin analitik ve nümerik olarak çözümü de güç olabilir. Bu hallerde simülasyon önemli bir model kurma ve çözme tekniğı olarak kullanılmaktadır [87].

Benzetim, bir faaliyetin veya sistemin esasını modellemenin bir yoludur. Modellemenin amacı, zaman içinde sistemin davranışını veya tepkisini değerlendirmek için deneyler yapabilmesini sağlamaktır. Doğrusal programlama gibi optimizasyon sağlayan bir yöntem değildir, ancak basit matematikle çözülemeyecek kadar karmaşık veya basit matematikle çözülmeye elverişli olmayan problemlere yaklaşma olanağı sağlayabilmektedir [70].

Benzetim, durağan olmayan karmaşık sorunların çözümünde kullanılan sistemli bir deneme yanılma yöntemidir. Geniş anlamda benzetim, gerçeğın örneğini oluşturmaktır. Benzetimi gerçek hayatta var olan bir sistemin veya önerilerin kabulü ile var olabilecek bir sistemin uygulanma olasılığının incelenmesi için herhangi bir modelden yararlanmak olarak da tanımlamak mümkündür. Modeller gerçekleri yansıtır; benzetim ise bunu taklit eder ve gerçeğın canlı resmini yansıtabilmek için manipölasyonla ilgilenir [1], [88].

Simülasyon, özellikle analitik ve nümerik çözüm metotlarının uygulanmadığı veya uygulanmasının pratik olmadığı durumlarda kullanılmaktadır. Varsayımlar yapılabiliriyorsa ve sistem müsaitse ilk olarak analitik modellerin denenmesi gerekmektedir. Simülasyon modelleriyle analitik modeller arasında karma modeller bulunmaktadır. Analitik modeller cevap vermezse karma modeller, onlardan da sonuç alınamazsa benzetim modeline başvurulur. Karmaşık sistemlerin birçoğu için analitik yöntemler ve konusu geçen karma yöntemler, sisteme uygun olmayan, çok pahalı ve zaman alıcı yöntemlerdir. Benzetim yöntemleri ile sistemin zaman içerisindeki davranışları ele alınarak; değişik koşullar altında sistem elemanlarının davranışları incelenmekte ve elemanlar arasındaki ilişki anlaşılmaktadır [1], [77], [89].

Günümüzde kullanıldığı şekliyle simülasyon, işletme yönetiminde karşılaşılan problemleri çözümlmek amacıyla bilgisayar kullanılarak matematiksel model aracılığıyla gerçek bir sistemin temsil edilmesini sağlayan bir tekniktir. Simülasyon tekniği bilgisayar alanındaki teknolojik gelişmelere ve değişmelere bağlı olarak hızlı bir gelişme göstermiştir. Bu duruma bağlı olarak başta işletmecilik olmak üzere birçok alanda uygulama olanağı bulmuştur. Simülasyonun diğer kullanım alanları olarak; ekonomi, pazarlama araştırması, talep tahminleri, eğitim, politika, sosyal bilimler, davranış bilimleri, şehircilik ve savunma vb. alanlar sayılabilmektedir. Simülasyon tekniği talep tahminlerinde de yaygın olarak kullanılmaktadır.

3.2 Yapay Sinir Ağları Yöntemiyle Talep Tahmini

Yapay sinir ağları yöntemiyle talep tahminleri dördüncü bölümde ayrıntılı olarak ele alınacaktır.

YAPAY SİNİR AĞLARI

Yapay sinir ağlarının yapısı ve insanlardaki sezgi yeteneğini anlayabilme ve taklit edebilme özelliği ile ilgili ayrıntılı açıklamalardan da anlaşılacağı üzere; günümüzde işletmeler karar süreçlerinin neredeyse tamamında hayati önem arz eden talep tahmini çalışmalarında yapay sinir ağları metodunu kullanmaktadırlar.

4.1 Yapay Sinir Ağı Tanımları

Yapay sinir ağları (Artificial Neural Networks - ANN), insan beyninin çalışma ilkesinden esinlenerek geliştirilmiş, birbiriyle paralel çalışan, birbirine bilgi gönderen ve bilgi alan bir organizasyonlardan oluşmaktadır. Problem çözümü amacıyla kullanılan iş elemanları (yapay sinir hücreleri), bir ağ şeklinde birbirine bağlanmıştır. Hücreler arasındaki bilgi akışı bağlantı değerleri ve ilişkilerle gösterilmektedir. Sistemin öğrenme yeteneği ve zeki davranışı, bağlantı değerlerinin kullanılmasıyla sağlanmaktadır [78].

Yapay sinir ağları, insan beyninin özelliklerinden olan, öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla geliştirilen bilgisayar sistemleridir. Yapay sinir ağlarının, programlanması çok zor ve mümkün olmayan olaylar için geliştirilmiş adaptif bilgi işleme ile ilgilenen bir bilgisayar bilim dalı olduğu söylenebilmektedir [90].

Yapay sinir ağları insan beyninin fonksiyonel özelliklerini taklit eden, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda yararlanılan bir modeldir. Örneklerden elde ettikleri bilgiler ile kendi deneyimlerini oluşturur; daha sonra benzer konularda benzer kararları verirler. Bilim

adamları, insan beyninin sahip olduğu özelliklerden esinlenerek beynin nöro-fiziksel yapısını incelemiş ve matematiksel modelini çıkartmaya uğraşmışlardır. Böylece, beynin bütün davranışlarını tam olarak modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesinden hareketle, birçok yapay hücre ve ağ modelleri geliştirmişlerdir. Sonuçta, Yapay Sinir Ağları olarak adlandırılan, normal bilgisayarlardan farklı işlem gerçekleştirme yöntemine sahip, farklı bir bilim alanı ortaya çıkmıştır.

Yapay sinir ağlarıyla ilk hesaplama modelleri, 1940'ların başında Culloch ve Pitts'in, 1943 yılında yayınlanan makaleleriyle başlamıştır. Bu alanda yapılan ilk çalışmalar beyin hücrelerinin işlevlerinin ve birbirleri ile haberleşme şekillerinin ortaya çıkarılmasını amaçlamaktaydı. Daha sonra, 1954 yılında Farley ve Clark tarafından bir ağ içerisinde uyarılara tepki veren, uyarılara adapte olabilen bir model oluşturulmuştur. İlk sinirsel bilgisayarın çıkışı ise 1960 yılıdır. 1963 yılında basit modellerin ilk eksiklikleri fark edilmiş, başarılı sonuçların elde edilmesi 1970 ve 1980'leri bulmuş olup, termodinamikteki teorik yapıların doğrusal olmayan ağların geliştirilmesinde kullanılmasına kadar gecikmiştir. 1985 yılı ise yapay sinir ağlarının yaygın olarak tanınmaya başladığı ve yoğun araştırmaların başladığı yıl olarak bilinmektedir [1], [27], [46].

Yapay sinir ağları, insan beyninin bilişsel öğrenme sürecine benzer bir biçimde, biyolojik nöron hücresinin yapısı ve öğrenme karakteristiklerinden esinlenerek geliştirilmiş, birlikte işleyen çok sayıda işlem elemanından oluşan bir bilgisayar işleme ve hesaplama sistemi olarak tanımlanabilir [71].

Yapay sinir ağları, biyolojik sinir sistemini taklit etmeye çalışan, insanlardaki sinir hücrelerinin basit bir model benzetimini yapan; öğrenme, öğrendiklerini hafızasında saklama ve genelleme yapabilme gibi insani özellikleri taklit edebilen bir sistemdir. Paralel çalışma özellikleri sayesinde çok kısa zamanda sonuçlar üretebilmekte, dolayısıyla gerçek zamanlı problemlerin çözümünde oldukça faydalı sonuçlar ortaya koymaktadırlar [36], [91], [92], [93]. Literatürde bazen nöro bilgisayarlar (neurocomputers), iletişimsel ağlar (connectionist networks), paralel dağıtık işlemciler gibi isimlerle de anılmaktadırlar [94].

Yapay sinir ağları, yöneylem araştırmasının inceleme sahalarına giren tahmin, modelleme, araç rotalama, gezgin satıcı problemi, kümeleme, sınıflandırma gibi birçok

alandaki problemlerin çözümünde tercih edilen bir metottur. Yapay zeka ve beynin modellenmesi alanlarında geliştirilmiş, regresyon ve benzer yöntemlerde olduğu gibi bağımlı ve bağımsız değişkenler arasındaki ilişkiyi inceleyen bir fonksiyon tahmin aracıdır. Yapay sinir ağları ile istatistiksel yöntemler arasındaki temel farklılık, sinir ağlarının istatistiksel dağılımla veya verilerin özellikleri ile ilgili herhangi bir varsayım yapmamasıdır. Doğrusal olmayan bir tahmin yöntemi olduğundan karmaşık verilerin modellenmesinden daha uygun sonuçlar üretmesi de diğer bir önemli özelliği olarak literatürde yer almaktadır [95].

Yapay sinir ağları, ayarlanabilir ağırlıklarla birbirine bağlı birçok basit işlem biriminden oluşmaktadır. Geleneksel model esaslı yöntemlerin aksine, değişkenler arasındaki ilişkiler bilinmese veya anlaşılmalrı zor olsa bile bu ilişkileri veriler arasından yakalayabilmekte ve örneklerden öğrenebilmektedirler. Yapay sinir ağları genelleme yapma, bir veri kümesindeki yapıyı kavrama, sınıflama ve değişen şartlara uyum sağlama yeteneklerine sahip, alternatif hesaplama araçlarıdır [96]. Yapay sinir ağları, tipik zeki öğrenme paradigmasının bir türüdür. Özellikle uygulamalı çalışmalarda geniş bir kullanım alanı vardır [34].

Yapay sinir ağı modelinin gücü, yapay nöronların birlikte çalışmasından kaynaklanmaktadır. Bu sistemlerin en önemli avantajları, öğrenme yetenekleri ve ortam değişikliklerine uyum sağlayabilme yetenekleridir. Yapay sinir ağları, geçmiş zamandaki veri örneklerinden yararlanarak, problemi tanımlar ve matematik bir model oluşturarak gelecekle ilgili tahminlerde bulunabilir [32].

4.2 Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağlarının özellikleri kullanılan ağ modeline ve algoritmalarına göre değişmekle birlikte, genel olarak aşağıdaki gibi sıralanabilir [90], [94]:

- Yapay sinir ağları makine öğrenmesi gerçekleştirmektedirler. Temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar.
- Programları çalışma stili bilinen programlama yöntemlerine benzememektedir.
- Yapay sinir ağları örnekleri kullanarak öğrenirler.
- Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir.

- Yapay sinir ağlarında bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır.
- Görülmemiş örnekler hakkında bilgi üretebilirler. Ağ, kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgi üretebilir.
- Algılamaya yönelik olaylarda kullanılabilirler.
- Şekil ilişkilendirme ve sınıflandırma yapabilirler.
- Örüntü tamamlama gerçekleştirebilirler.
- Kendi kendini organize etme ve öğrenebilme yetenekleri vardır.
- Eksik bilgi ile çalışabilmektedirler. Yapay sinir ağları, eğitildikten sonra, gelen yeni örneklerde eksik bilgi olsa bile sonuç üretebilirken, geleneksel sistemler eksik bilgiyle çalışamazlar.
- Hataya toleransına sahiptirler. Eksik bilgilerle çalışabilme yetenekleri hatalara karşı toleranslı olmalarını sağlamaktadır. Ağın bazı hücrelerinin bozulması ve çalışmaz duruma düşmesi halinde ağ çalışmaya devam eder. Geleneksel bilgisayarlar ise genellikle eksiksiz verilere ihtiyaç duyar.
- Dereceli bozulma gösterirler.
- Dağıtık belleğe sahiptirler. Yapay sinir ağlarında bilgi, ağa yayılmış durumdadır. Yani, ağın tamamı öğrendiği olayın bütünü karakterize etmektedir.
- Sadece nümerik bilgiler ile çalışabilmektedir; sembolik ifadeler ile gösterilen bilgilerin sayısal değerlere çevrilmesi gerekmektedir.
- Belirsiz, tam olmayan bilgileri işleyebilmektedirler.

Yapay sinir ağlarının günümüzde kullanılan diğer bilgi işlem yöntemlerinden farkları ise aşağıdaki şekilde sıralanabilir [30], [84]:

- *Paralellik:* Yapay sinir ağlarında işlemler doğrusal değildir ve bu bütün ağa yayılmış durumdadır. Bu sayede doğrusal olmayan karmaşık problemlerin de çözümlenmesi mümkündür.
- *Öğrenebilirlik:* Yapay sinir ağlarının temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer karar vermeye çalışırlar. Yapay sinir ağlarının arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. Yapay sinir ağlarının karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden

ayarlı olarak verilemez veya tasarlanamaz. Bu nedenle yapay sinir ağıları, istenen davranışı gösterecek şekilde ilgilendiği problemten aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.

- *Hata Toleransı:* Yapay sinir ağılarındaki paralel yapı, ağına sahip olduğu bilginin tüm bağlantılara yayılmasını sağladığı için bazı bağlantıların veya hücrelerin etkisiz hale gelmesi ağın doğru bilgiyi üretmesini önemli derecede etkilemez. Oysa çok sayıda hücrenin çeşitli şekillerde bağlanması ile oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağıdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir yapay sinir ağılarının bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağın doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hata ayıklama yetenekleri son derece yüksektir.
- *Genelleme:* Yapay sinir ağıları kendisine gösterilen örneklerden yola çıkarak görmediği örnekler hakkında da bilgiler üretebilirler. Yapay sinir ağılarının eğitilmesi istenen olayları öğrenebilmesi için o olay ile ilgili örneklerin belirlenmesi gerekmektedir. Örnekler kullanılarak ilgili olay hakkında genelleme yapabilecek yetenek kazandırılır ve ağın eğitilmesi sağlanır. Olayla ilgili gerçekleşmiş örnek veriler olmadan yapay sinir ağıının eğitilmesi mümkün değildir. Ağ eğitilirken kullanılan örneklerin olayı temsil edebilmesi önemlidir. Olayın tüm yönlerini içerecek şekilde örnekler ağına gösterilirse ağ sorunsuz bir şekilde çalışır.
- *Dereceli Bozulma:* Ağlar bir eksik ve problem ile karşılaştıklarında hemen bozulmazlar. Hata toleransına sahip oldukları için dereceli bir şekilde bozulurlar.
- *Uyarlanabilirlik:* Yapay sinir ağılarında ağırlıkların yeniden yapılandırılabilir olması belirli bir problemi çözmek için eğitilen yapay sinir ağıının, problemdeki değişikliklere göre yeniden eğitilebilmesi ve farklı koşullara uyarlanabilmesini sağlamaktadır. Yapay sinir ağıları, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen yapay sinir ağıları, problemdeki değişimlere göre tekrar eğitilebilir ve değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile yapay sinir ağıları, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

- *Donanım ve Hız:* Yapay sinir ağıları, paralel yapısı nedeniyle büyük ölçekli bütünleşmiş devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, yapay sinir ağlarının hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda tercih edilmesini sağlar.
- *Analiz ve Tasarım Kolaylığı:* Yapay sinir ağlarının temel işlem elemanı olan hücrenin yapısı ve modeli, bütün yapay sinir ağları yapılarında yaklaşık aynıdır. Dolayısıyla, yapay sinir ağlarının farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan yapay sinir ağları benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler.

Bir sinir ağı tabakalar halinde düzenlenmiş sinirlerin oluşturduğu bir ağ olarak düşünülebilir. Ağın en alt tabakası giriş tabakası, en üstteki tabakası ise çıkış tabakası vardır. Her tabaka yüksek seviyelerdeki diğer tabakalarla birbirine ilişkilendirilmiştir. Bir sinir ağı oluşturmak için ihtiyaç duyulan bileşenler; ağ (network) mimarisi, aktivasyon fonksiyonları, maliyet fonksiyonu (tahminin doğruluk derecesi), eğitim algoritması bileşenleridir [83], [97].

4.3 Yapay Sinir Ağlarının Tarihçesi

Yapay sinir ağlarının tarihçesi insanların nörobiyoloji konusuna ilgi duymaları ve sonuçları bilgisayar bilimine uygulamaları ile başlamaktadır. Bu çalışmalar aşağıdaki şekilde özetlenebilir [84], [90]:

- 1890: İnsan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması
- 1911: İnsan beyninin bileşenlerinin belirli bir düzenek ile sinir hücrelerinden oluştuğu fikrinin benimsenmesi
- 1943: Yapay sinir hücrelerine dayalı hesaplama teorisinin ortaya atılması: Warren McCulloch/Walter tarafından Pitts “Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap” teorisi ortaya atılmıştır.
- 1949: Biyolojik olarak mümkün olabilen öğrenme prosedürlerinin bilgisayarlar tarafından gerçekleştirilecek biçimde geliştirilmesi: Hebb Kuralı.
- 1956-1962: Adaline ve Windrow öğrenme algoritmasının geliştirilmesi.
- 1957-1962: Tek Katmanlı Algılayıcının (Perceptron) geliştirilmesi.
- 1965: İlk makine öğrenme kitabının yazılması.

- 1967-1969: Bazı gelişmiş öğrenme algoritmalarının geliştirilmesi: Grosberg öğrenme algoritması.
- 1969: Tek katmanlı algılayıcıların problemleri çözme yeteneklerinin olmadığı gösterilmesi.
- 1969-1972: Çağrışimli Bellek (Associative memory) konusunda çalışmalar: Kohonen ve Anderson çalışmaları.
- 1969-1972: Doğrusal ilişkilendiricilerin geliştirilmesi.
- 1972: Korelasyon ve matriks belleğinin geliştirilmesi.
- 1974: Geri Yayılım modelinin (Çok katmanlı algılayıcıların ilk çalışmaları) geliştirilmesi.
- Öğretimsiz Öğrenmenin geliştirilmesi:
 - 1978: ART Modelinin geliştirilmesi.
 - 1982: Kohonen Öğrenmesi ve SOM modelinin geliştirilmesi.
- 1982: Hopfield Ağlarının geliştirilmesi.
- 1982: Çok Katmanlı algılayıcılarının geliştirilmesi.
- 1984 Boltzman makinesinin geliştirilmesi.
- 1985: Çok katmanlı algılayıcıların Genelleştirilmiş Delta Öğrenme Kuralı ile geliştirilmesi.
- 1988: RBF modelinin geliştirilmesi.
- 1988: PNN modelinin geliştirilmesi.
- 1991: GRNN modelinin geliştirilmesi
- 1991'den günümüze sayısız çalışma ve uygulamalar geliştirilmiştir.

4.4 Yapay Sinir Ağları Yönteminin Diğer Yöntemlerle Karşılaştırılması

Yapay sinir ağları ile yapılan tahmin yöntemi, kullanılan diğer yöntemlerden oldukça farklı bir terminolojiye sahiptir. Örneğin sinir ağları terminolojisinde “model” terimi yerine “network-ağ” terimi kullanılmaktadır. Parametreler terimi yerine network’un sahip olduğu “ağırlıklar” terimi, “tahmini parametreler” terimi hakkında konuşmak yerine, sinir ağlarıyla tahmin yapanlar “ağın çalışması” hakkında konuşmak, ifadeleri kullanılmaktadır [1].


Yapay sinir ağlarının bazı özellikleri, her ne kadar ilgili problemin yapısına ve kullanılan sinir ağı modeline bağlı olsa da, geleneksel bilgi işleme yöntemlerinden ayrılan bazı özellikleri, Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1 Yapay sinir ağları ve geleneksel talep tahmin metotlarının karşılaştırılması
[92]

	Geleneksel Yöntemler	Yapay Sinir Ağları
Öğrenme süresi	-	Uzun
Cevap verme süresi	Uzun	Kısa
Öncelikli bilgi	Gerekli	Sadece örnekler gerekli
Bilgi temsili	Zor	Kolay
Rastgele seçilmiş problem	Zor	Kolay
Performans	Uygun	İyi
Bilgi işleme	Açık	Kapalı
Kaynak	Uzman kişi	Örnekler

Çizelge 4.1’de yapay sinir ağlarıyla, geleneksel yöntemlerin talep tahmin yöntemleriyle karşılaştırılması yapılmıştır. Buna göre, geleneksel yöntemlerle tahmin sürecinde, uzman görüşüne ihtiyaç varken, sinir ağları dışarıdan hiçbir müdahale olmaksızın geçmişe ait örneklerden yararlanarak kendisi işlem yapabilmektedir. Ayrıca geleneksel yöntemlerde sistemin cevap verme süresi çok uzunken, sinir ağı yönteminde bu süre çok kısadır.

Günümüzde, yapay zekanın yerini, yapay sinir ağlarının alacağı düşünülmektedir. Oysa yapılan uygulamalardaki eğilim, yapay sinir ağları ve uzman sistemlerin, her biri kendi uzmanlık alanına giren işi yapmak üzere, birleşip aynı sistem üzerinde bulunmalarının daha iyi sonuçlar vereceğidir. Oluşturulan bu yeni sistemlere karma (hibrid) sistemler adı verilmektedir. Yapay zeka tekniklerinin aynı sistemde birlikte hareket etmesi, tek başlarına olmalarından daha güçlü bir sistem oluşturmaktadır. Şekil 4.1’de, yapay sinir ağı yöntemiyle, geleneksel tahmin yöntemlerinin, tahmin işlem süreci bakımından karşılaştırılması akış diyagramı olarak gösterilmektedir.



Şekil 4.1 Yapay sinir ağları ile geleneksel yöntemlerin işlem süreci olarak karşılaştırılması [32]

İki yöntem arasındaki ana farklılık, sinir ağlarının veri işleme yöntemidir. Geleneksel istatistiksel yöntemde veri işleme, grup (yığın) ve sıralı olarak, fakat bir defada yapılırken; yapay sinir ağı yönteminde örnek alınan veri tekrar tekrar (defalarca iterasyon yapılmakta) ağı sunulmaktadır. Bu işlem ağın öğrenmesi tamamlanana kadar devam etmektedir. Diğer bir fark ise, yapay sinir ağlarında veri işleminin, paralel olarak yapılması ve yapay nöronlar aracılığıyla etkileşimli olarak ağı dağıtılmasıdır [32].

Çizelge 4.2’de uzman sistemler ve yapay sinir ağları arasındaki benzerlikler karşılaştırılmıştır. Karşılaştırılması verilen uzman sistemler ve yapay sinir ağı yöntemleri birbirini tamamlayıcı özelliğe sahiptirler.

Çizelge 4.2 Uzman sistemler ve yapay sinir ağlarına karşılık gelen elemanlar [92]

Uzman Sistemler	Yapay Sinir Ağları
Şartlar ve sonuçlar	İşlem elemanları (düğümler)
Kurallar	Bağlantılar
Belirsizlik değerleri	Ağırlık değerleri
Gerçekleri toplama	Toplama fonksiyonu
Kuralları çalıştırma	Çıkış fonksiyonu

Çizelge 4.2’de görüldüğü üzere, bir uzman sistem (US) ile yapay sinir ağları arasındaki temel farklardan birisi, öğrenme biçimi ile ilgilidir. Uzman sistemlerde öğrenme ya yapılamamakta, ya da zor yapılmaktadır. Yapay sinir ağlarında ise model öğrenme olayı üzerine kurgulandığından öğrenme işlemi oldukça kolaydır. Bu yöntemler çoğu zaman birbirini tamamlayıcı özelliklere sahiptirler. Bu yüzden son yıllarda her iki yöntemin birleştirildiği ve birbirinin zayıf taraflarının giderildiği birleşik sistemlerin tasarımı gittikçe yaygınlaşmıştır [1].

Çizelge 4.3’te ise uzman sistemler ile yapay sinir ağları arasındaki farklılıklar gösterilmiştir.

Çizelge 4.3 Uzman sistemler ve yapay sinir ağları arasındaki farklılıklar [92]

Parametreler	Uzman Sistemler	Yapay Sinir Ağları
Kullanıcı arabirimi	Mevcuttur	Mevcut değildir
Açıklama yeteneği	Mevcuttur	Mevcut değildir
Uzman kişi	İhtiyacı var	İhtiyacı yok
Örnekler	İhtiyacı yok	İhtiyacı var
Problemin boyutu çoğaldığında bakım	Zorlaşır	Değişmemektedir
Oluşturulması	Kurallar, hiyerarşik yapılar	Eğitilmekle
Bilgi işleme	Seri ve karmaşık	Paralel
Bilgi temsili	Kesin ve açık/Sözlü ifade	Saklı/Sözlü ve sayısal ifade
Tam değerlerin belli olması	Şarttır	Şart değildir

Çizelge 4.3'te görüldüğü gibi uzman sistemlerle yapay sinir ağları yöntemleri arasındaki temel farklar; uzman bilgi ve müdahalesine ihtiyaç duyulması, örneklem gereksinimi, kesin bilgi gereksinimi gibi konularda oluşmaktadır.

Yapay sinir ağları bilinen hesaplama yöntemlerinden farklı bir hesaplama yöntemi önermektedir. Bulundukları ortama uyum sağlayan, adaptif, eksik bilgi ile çalışabilen, belirsizlikler altında karar verebilen, hatalara karşı toleranslı olan bu hesaplama yönteminin hayatın neredeyse tüm alanında başarılı uygulamalarını görmek mümkündür. Oluşturulacak olan ağın yapısının belirlenmesinde, ağ parametrelerinin seçiminde, belirli bir standardın olmaması, problemlerin sadece nümerik bilgiler ile gösterilebilmesi, eğitimin nasıl bitirileceğinin bilinmemesi ve ağın davranışlarının açıklanamamasına rağmen bu ağlara olan ilgi her geçen gün artmaktadır. Biyolojik sinirlerden esinlenerek tasarlanan yapay sinir ağları, doğrusal olmayan ve paralel bilgi işleme özellikleri olan, bulunduğu ortamın değişmesiyle ürettiği sonucu değiştirebilen, giriş parametrelerindeki küçük değişimleri tolere edebilen, değişik verilerle karşılaştığında daha önceki verilerde var olan benzer özellikleri keşfeden, deneyimi olmadığı hallerde bile yeni veri değerlerine cevap verebilme gibi üstün özelliklere sahiptir [46].

4.5 Yapay Sinir Ağlarının Avantajları

Yapay sinir ağları kullanılarak yapılan analizlerde, elde edilebilecek avantajlardan bazıları aşağıdaki gibi sıralanmaktadır:

- Yapay sinir ağları diğer sistemlerle karşılaştırıldığında birtakım üstün özellikleri bulunmaktadır. Bunlar; doğrusal olmama, örneklerden öğrenme yeteneği, genelleme yapabilme, uyarlanabilme, veri dağıtılmış birleşik hafıza yapısı, paralel işlem yapma özelliği, hata ayıklama yeteneği, donanımlarının kolay elde edilebilmesi, hızlı hesaplama yapabilmesi, analiz ve tasarım kolaylığı ile hazır paket programlarının bulunması şeklinde sıralanabilir [27], [95].
- Yapay sinir ağları kullanılarak, matematiksel olarak modellenmesi mümkün olmayan veya zor olan karmaşık problemler rahatlıkla çözülebilmektedir. Yapay sinir ağlarının, geleneksel bilgisayar yazılım teknolojisi ile çözilemeyen birçok problemi çözülebileme özelliği, normal olmayan eksik ve belirsiz bilgilerle işlem yapabilmek, paralel dağılmış yapısından, öğrenebilme ve genelleme yapma

yeteneđi, öğrendiđi bilgiyi sinaptik ağırlıklar yardımıyla dağıtık hafızasında saklama yeteneđi gibi birçok avantajını saymak mümkündür.

- Yapay sinir ağırları, giriş bilgilerine göre kendi ilişkilerini oluştururlar. Başka bir ifadeye göre, teorik modeller olduklarından denklem içermezler. Bununla birlikte modelin içinde ne olduđu tam olarak analiz edilemez. Yapay sinir ağırları, bu karışık özellikleri nedeniyle, bazıları tarafından akıllı bir “kara kutu” olarak tanımlanmaktadır.
- Model, sınırsız sayıda deđişkenden sadece gerektiđi anda, gerektiđi kadarını kullanarak çalışabildiğinden, mükemmel bir öngörü doğruluđu ile genel çözümler üretebilmektedir. Bazı nedenlerle insan beynindeki sinir hücrelerinin ölmesi sonucunda bu hücrelere depolanan bilgilerin yok olma riskinin olmasına karşın, yapay sinir ağırlarındaki matematiksel nöronların ölme ihtimali olmadığından hafızasındaki bilgiler asla kaybolmamaktadır.
- Yapay sinir ağırları yöntemi, giriş verisi miktarındaki artmayla doğru orantılı olarak daha tutarlı sonuçlar üretebilmektedir. Yapay sinir ağırları diđer metotlarla birçok çalışmada karşılaştırmalı olarak incelenmiş ve sonuç olarak özellikle sabit olmayan ve kesikli veri serilerinin bulunduđu durumlarda, oldukça tutarlı ve güvenilir sonuçlar ürettiđi görölmüşdür [44].
- Yapay sinir ağı uygulamaları hem pratik hem de maliyet bakımından ucuzdurlar.
- Zaman bakımından verimli çalışmaktadırlar.
- Yapay sinir ağırları yeni bilgilerin ortaya çıkması ve ortamda bazı deđişikliklerin olması durumunda yeniden eğitilebilirler.
- Yapay sinir ağı modeli, her biri büyük bir problemin farklı parçası ile ilgilenen çok sayıda işlemciden oluşması ve bağlantı ağırlıklarının ayarlanabilir olması gibi özelliklerinden dolayı, esnek bir yapıya sahiptir. Bu esnek yapı sayesinde, ağıın bir kısmı zarar görse bile model yine de çalışmaya devam eder. Bu durum sadece performans düşüklüğüne sebep olur, fakat modelin işlevini tamamen yitirmesi söz konusu olmamaktadır.

4.6 Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağlarının yukarıda belirtilen avantajlarının yanı sıra bazı dezavantajları da bulunmaktadır. Bunlardan bazılarını aşağıdaki gibi özetlemek mümkündür [90]:

- Yapay sinir ağlarının donanım bağımlı çalışmaları önemli bir sorun olarak görülebilir. Ağların temel varoluş nedenlerinden birisi de paralel işlemciler üzerinde çalışabilmeleridir. Ağların özellikle, gerçek zamanlı bilgi işleyebilmeleri paralel çalışabilen işlemcilerin varlığına bağlıdır. Günümüzdeki bilgisayarların çoğu seri olarak çalıştığından aynı anda sadece tek bir bilgiyi işleyebilmektedir. Paralel işlemleri seri makinelerde yapmak ise zaman kaybına yol açmaktadır. Bazı problemleri çözebilmek için gerekli olan paralel işlemcilerin tamamını bir arada çalıştırmak mümkün olmayabilir.
- Yapay sinir ağları her tür problemin çözümünde kullanılabilecek bir model değildir. Bazı problemlerin çözümü hiçbir zaman bulunamayabilir ve oluşturulan çözüm kümesinin gerçek değerle hiçbir ilgisi olmayabilir.
- Probleme uygun ağ yapısının belirlenmesi genellikle deneme yanılma yöntemi ile yapılmaktadır. Bu durum ise önemli bir problemdir. Çünkü eğer problem için uygun bir ağ oluşturulmaz ise çözümü olan bir problemin çözülememesi veya performansı düşük sonuçlar elde edilmesi mümkündür.
- Yapay sinir ağları, kabul edilebilir çözümler üretir fakat en iyi çözümü garanti etmez.
- Bazı ağlarda, ağın parametre değerlerinin belirlenmesinde bir kural olmaması, belirlemenin sübjektif olarak yapılması da bir problemdir. Bu durum, iyi çözümler bulmayı zorlaştıran bir etken olarak görülebilir. Bu parametrelerin belirlenmesi de kullanıcının tecrübesine bağlıdır. Her problem için ayrı faktörlerin dikkate alınması gerekebilir. Bu parametre değerleri için belirli standartların oluşturulması çok zor olduğundan her problem için ayrı ayrı değerlendirmeler yapılması gerekmektedir. Bu da modelin önemli bir dezavantajı olarak görülebilir.
- Ağın öğreneceği problemin ağa gösterimi de çok önemli bir problemdir.
- Yapay sinir ağları sadece nümerik bilgiler ile çalışmaktadırlar. Modele veriler sunulmadan önce nümerik biçime dönüştürülmesi gerekmektedir. Bu ise kullanıcının becerisine bağlıdır. Bu konuda, kullanıcının tecrübesi de yeterli olmayabilir. Bu durum, günümüzde birçok olayın yapay sinir ağları ile çözülememesinin en önemli sebeplerinden birisi olarak sayılabilir.

- Ađın eđitiminin ne zaman bitirileceđine karar vermek iin de geliřtirilmiř bir yntem yoktur. Ađın rnekler zerindeki hatasının belirli bir deđerin altına indirilmesi eđitimin tamamlanması iin yeterli grlmektedir.
- Bir diđer dezavantaj da ađın davranıřlarının aıklanamaması durumudur. Bir probleme zm retildiđi zaman bunun nasıl ve neden retildiđi konusunda bir bilgi bulmak mmkn olamamaktadır. Bu durum ađın rettiđi zme gveni azaltmaktadır.
- Problemlere optimum sonuları garanti etmez.
- Yapay sinir ađlarının đrenme sresinin uzun olmasıdır. Bir yapay sinir ađını eđitebilmek iin ok fazla denemeye ihtiya vardır. Eđitme zamanının kısaltılması ise kritik bir durumdur, nk yapay sinir ađları ile tahminleme bir deneme yanılma srecidir; bundan dolayı bir arařtırmacı sınırlı bir zaman diliminde ne kadar fazla deneme yaparsa sonutan o kadar emin olacaktır.

4.7 Yapay Sinir Ađlarının Uygulama Alanları

İlgili yazın tarandıđında, yapay sinir ađlarıyla deđiřik alanlarda binlerce uygulamanın yapıldıđı ve bařarılı sonuların elde edildiđi sylenebilmektedir. İlk yapay sinir ađı alıřması yaklaşık elli yıl nce bařlamıř olmasına rađmen, yntemin etkin olarak kullanımı ve geliřimi son 20 yıl ierisinde olmuřtur. Oysaki diđer iyileřtirme (optimizasyon) ve matematik yntemlerin geliřimi ok uzun yıllar srmřtr. Yapay sinir ađı yntemi; yksek eđitim, arařtırma, endstri ve teknolojik geliřmeler iin, Bulanık Mantık (BM) ve Genetik Algoritmalar (GA) yntemleri ile beraber ok bařarılı bir temel teřkil etmektedir. Her bir yntemin deđiřik alanlarda stn olduđu uygulamaları bulunmaktadır.

alıřmalar, eskiden laboratuvarlarda yrtlmekte ve veriler benzetim yolu ile elde edilmekte iken, yapay sinir ađları sayesinde alıřmalar gnlk hayatın iinde ve gerek verilerle yapılır hale gelmiřtir. Evimizdeki aletlerden, elimizdeki cep telefonlarına kadar birok alanda, yapay sinir ađları uygulamalarına rastlamak mmkndr. Yapay sinir ađları uygulamaları; endstriyel uygulamalar, finansal uygulamalar, askeri ve savunma uygulamaları, sađlık uygulamaları ve diđer alanlardaki uygulamalar řeklinde sınıflandırılabilir [90].

Yapay sinir ağıları, özellikle günümüze kadar çözümü güç ve karmaşık olan ya da ekonomik olmayan çok farklı alanlardaki problemlerin çözümünde kullanılmış ve genellikle başarılı sonuçlar alınmıştır, bunlardan bazıları aşağıda verilmiştir [30].

- *Arıza Analizi ve Tespiti:* Bir sistemin, cihazın ya da elemanın düzenli çalışma şeklini öğrenen bir sinir ağı yardımıyla, bu sistemde meydana gelebilecek arızaların önceden belirlenmesi mümkündür. Bu amaçla yapay sinir ağıları; elektrik makinelerinin, uçakların, tümleşik devrelerin vb. arıza analizinde kullanılmaktadır.
- *Tıp Alanında:* Yapay sinir ağıları, tıbbi sinyallerin analizi, kanserli hücrelerin belirlenmesi, protez tasarımı, transplantasyon zamanlarının optimizasyonu ve hastane giderlerinin optimizasyonu gibi konularda uygulanmaktadır.
- *Savunma Sanayi:* Silahların otomasyonu ve hedef izleme, nesneleri/görüntüleri ayırma ve tanıma, yeni algılayıcı tasarımı ve gürültü önleme gibi alanlarda uygulanmaktadır.
- *Haberleşme:* Görüntü ve veri sıkıştırma, otomatik bilgi sunma servisleri, konuşmaların gerçek zamanlı çevirisinin yapılması gibi konularda uygulanmaktadır.
- *Üretim:* Üretim sistemlerinin optimizasyonu, ürün analizi ve tasarımı, ürünlerin kalite analizi ve kontrolü, planlama ve yönetim analizleri gibi konularda kullanılmaktadır.
- *Otomasyon ve Kontrol:* Yapay sinir ağıları, uçaklarda otomatik pilot sistemi otomasyonu, ulaşım araçlarında otomatik yol bulma/gösterme, robot sistemlerinin kontrolü, doğrusal olmayan sistem modelleme ve kontrolü, elektrikli sürücü sistemlerin kontrolü gibi alanlarda yaygın olarak kullanılmaktadır.
- *İstatistik:* Klasik istatistik yöntemler yerine, yapay sinir ağıları modellerinin alternatif olarak kullanıldığı birçok çalışma vardır. Özellikle, regresyon ve kümeleme analizi ile ilgili birçok uygulama bulunmaktadır.
- *Finans:* Borsa endeks tahmini, enflasyon tahmini ve ülkelerin finansal değerlere göre kümelenmesi gibi birçok finansal uygulamaları mevcuttur.

Yapay sinir ağıları gerçek hayatta karşılaşılan problemlerde oldukça geniş bir uygulama alanı kazanmıştır. Bugün, birçok endüstri dalında başarılı şekilde kullanılmaktadır. Uygulama alanları için bir sınır olmamakla birlikte, sınıflandırma, öngörü ve

modelleme konularında daha fazla kullanılmaktadırlar. Model, verilerin eğilimlerini veya yapılarını en iyi tanımlayan bir yöntem olduğundan, tahmin işlemi için çok uygundur.

Yapay sinir ağlarının gerçek hayatta yaygın olarak uygulandığı alanlara; Kalite Kontrol, Finansal Öngörü [17], Ekonomik Öngörü, Kredi Derecelendirme, Laboratuvar Araştırmaları, İflas Tahmini, Petrol ve Gaz Arama [26], Sistem Modelleme, Parmak İzi Tanıma, Meteorolojik Yorumlama, Otomatik Araç Denetimleri, Sağlık ihtiyaçları [97], Kalp fonksiyonları gibi işaretleri izleme ve değerlendirme gibi örnekler verilebilir [36].

Yapay sinir ağlarının potansiyel uygulama alanları, insan zekasının kolaylıkla üstesinden geldiği fakat bazı teknik sorunlar yüzünden klasik bilgisayarların çok yavaş veya yetersiz kaldığı durumlar olarak tarif edilebilir.

Yapılan uygulamalar incelendiğinde, yapay sinir ağlarının genel olarak aşağıdaki fonksiyonları gerçekleştirmek üzere kullanıldıkları görülmektedir[90]:

- *Tahmin:* Ağa sunulan giriş bilgilerinden yararlanılarak, çıktı değerinin tahmin edilmesidir. Hava tahmini, borsadaki hisse değerlerinin, gelecekte yapılacak satışların tahmini, üretim ihtiyaçlarının belirlenmesi, pazar performansının tespiti, enerji ihtiyaçlarının belirlenmesi, at yarışlarının tahminlemesi, kanser risk oranlarının belirlenmesi, döviz kurlarının tahminlemesi gibi örnekler vermek mümkündür.
- *Sınıflandırma:* Yapay sinir ağları kendine sunulan bilgileri kategorize edebilirler. Bir makine üzerinde görülen hatalar, müşteri/pazar profilleri, imza tetkikleri, mal değerinin belirlenmesi, hücre tiplerinin sınıflandırılması, borçlanma/risk değerlendirmeleri buna örnek olarak verilebilir.
- *Veri ilişkilendirme:* Bu amaçla eğitilen ağlar, ağa sunulan verilerin hatalı ve eksik olup olmadığını belirlerler. Öğrendikleri bilgiler ile eksik olan bilgileri tamamlarlar ve ilave olarak hatalı olan verileri de tanımlarlar. Örnek olarak taranan bir dokümandaki karakterleri algılamamanın yanında tarayıcının düzgün olarak çalışmadığını da algılayabilirler.
- *Veri filtreleme:* Filtreleme amacıyla eğitilen ağlar, birçok veri arasından uygun verileri belirleme görevini yerine getirirler. Telefon konuşmalarındaki gürültülerin asıl konuşmalardan ayrılması, bir resim üzerindeki istenilmeyen parazitlerin temizlenmesi gibi konularda örnek uygulamaları vardır.

- *Tanıma ve eşleştirme:* Değişik şekil ve örüntülerin tanınması, eksik, karmaşık, belirsiz bilgilerin işlenerek eşleştirme ve tanıma fonksiyonları gerçekleştirebilirler. Daha önce örneği verilen, kalite kontrol şemaları üzerindeki şekilleri tanıyabilen sinir ağı, bu konuya örnek olarak verilebilir.
- *Teşhis:* Bu amaçla geliştirilen ağlar, sistemlerin olumsuzluklarının ortaya çıkarılması ve sorunun belirlenmesi işlemini yapar. Makinelerin, arazi durumlarının, hastalıkların tanınması ve hataların tespiti buna örnek olarak verilebilir.
- *Yorumlama:* Bir olay hakkında toplanan örneklerden elde edilen bilgiler ve eğitim sonucu öğrenilenler kullanarak, meydana gelecek yeni olayların yorumlanması bu kapsamda düşünülmektedir. Bir olay hakkında toplanan verilerin yorumlanarak istatistiksel dağılımlarının oluşturulması bu konuya örnek olarak verilebilir.

4.8 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

4.8.1 Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları, belli bir hiyerarşik yapıda birbirine bağlanmış birden çok basit işlemci elemanın girişi yapılan verilerden, çıktılar üretebildiği bir *Kara Kutu* olarak tanımlanabilmektedir. Bu kara kutunun işlevi, basitçe bir matematiksel fonksiyonu temsil etmektir. Yapay sinir ağlarının bu fonksiyonunun tam olarak bir matematiksel karşılığı yoktur. Diğer bir deyişle modelin matematiksel denklemlere değil de örneklerle ihtiyacı vardır. Modelin öğrenmeyi gerçekleştirmesi için yalnızca geçmiş ile ilgili örneklerle ihtiyacı vardır. Şekil 4.2’de geçmişe ait veri girişlerinden sonuçlar üretebilen Kara Kutu benzetimi verilmiştir.




Şekil 4.2 Yapay sinir ağlarının kara kutu benzetimi [90]

Kara Kutuya benzetilen sinir ağlarının, tüm hücrelerden bilgi toplama ve bu bilgileri işleyerek diğer elemanlara gönderme özelliği vardır. Bu konuda çeşitli algoritmalar ve yaklaşımlar söz konusudur.

Yapay sinir ağıları, geçmişe ait gerçekleşmiş örnek olaylardan deneyim kazanarak öğrenmeyi gerçekleştirdiklerinden, uzman sistemlerde olduğu gibi bilgi toplama sorunu yoktur. Burada kullanılan örneklerin, bilgisayarın öğrenmesi istenen ilişkileri doğru şekilde temsil ediyor olması gerekmektedir. Problemin ağa sunum şekli, ağın sahip olduğu topolojik yapı, ağın kullandığı öğrenme stratejisi ve öğrenme kuralları, ağın performansı üzerinde etkili olacaktır. Sinir ağını oluşturan işlemci elemanlar birbirleri ile sürekli iletişim içerisinde oldukları için [92].

Şekil 4.3'te yapay sinir ağlarının işleyişi bir blok sema üzerinde gösterilmiştir.



Şekil 4.3 Yapay sinir ağları yapısı blok gösterimi [90]


Şekil 4.3'te gösterildiği gibi, yapay sinir ağları girdi katmanı, ara katman ve çıktı katmanlarından oluşmaktadır. Bu katmanları aşağıdaki gibi açıklamak mümkündür [1].

Girdi Katmanı: Girdi katmanı en az bir girdi elemanının bulunduğu bölümdür. Bu katmanda veriler herhangi bir işleme tabi tutulmadan giriş ile aynı değerde çıktılar üretmektedirler.

Ara Katmanlar: Girdilerin belirli işlemlere tabi tutulduğu bölümdür. Seçilen ağ yapısına göre işlem katmanının, yapısı ve fonksiyonu da değişebilir. Ara katman, tek bir katmandan oluşabileceği gibi birden fazla katmandan da oluşabilir [98].

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

Yapay sinir ağları işlem süreci Şekil 4.4'te gösterilmiştir. Görüldüğü gibi sisteme, geçmiş zamana ait verilerin girişi yapıldıktan sonra işlemci elemanlar(nöronlar) ve bağlantı elemanları (aksonlar) işlem sürecini çıkışa doğru sürdürmektedir.



Şekil 4.4 Yapay sinir ağı işlem süreci [90]

Temel bir yapay sinir ağı hücresi, biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. Yapay sinir ağı hücresinde temel olarak dış ortamdan yada diğer nöronlardan alınan veriler yani girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır. Dış ortamdan alınan veri ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Toplama fonksiyonu ise net girişi hesaplar. Net giriş, girişlerle bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur. Aktivasyon fonksiyonu işlem süresince net çıkışını hesaplar ve bu işlem aynı zamanda nöron çıkışını verir. Genelde aktivasyon fonksiyonu doğrusal olmayan bir fonksiyondur [30].

4.8.2 Yapay Sinir Ağlarının Temel Elemanları

4.8.2.1 Biyolojik Sinir Hücreleri


Yapay sinir ağlarının daha iyi anlaşılabilmesi için örnek oluşturan doğal sinir ağı olan biyolojik sinir ağlarının yapısının ve çalışma ilkelerinin iyi bilinmesi gerekmektedir. Günümüzde hala, insan beyninin bilgiyi işleyerek kendi kendisinin asıl eğittiği tam olarak bilinmemekle birlikte bu konuda bilim adamları tarafından ortaya birçok teori atılmıştır.

Bu teorilerin çoğunluğuna göre; insan beyni bir biri ile karmaşık ilişkiler içinde bulunan milyarlarca sinir hücresi (nöron) ile vücut aktivitelerini kontrol eden bir mekanizmadır. Bir insan beyninde 10 milyardan fazla sinir hücresi bulunmakta, her bir hücre ortalama 10.000 hücre ile bağlantı içerisinde çalışmaktadır. Nöron adı verilen bu sinir

hücrelerinde sinyaller, çok karmaşık elektro-kimyasal olaylar zinciriyle oluşan ve sayısı saniyede 1000 taneye kadar çıkabilen titreşimler halinde iletilmektedir [30].

Bu mekanizma içerisindeki tipik bir sinir hücresi, dendrit olarak adlandırılan ince kılcak yollar aracılığıyla komşu hücrelerden gelen sinyalleri, toplayarak sinir hücresinin binlerce dala ayrılan ince ve uzun ayakları olan aksonlar vasıtasıyla beyine iletirler. Her akson dalının sonunda, sinaps olarak adlandırılan bir düğüm noktası vardır. Bu düğüm noktaları aksonlardan aldıkları sinyalleri beyine iletirler. Beyne iletilen bu sinyaller (veri) sayesinde, öğrenme olayı gerçekleşir [99].

Biyolojik sinir sistemi, bilgiyi alan, yorumlayan ve uygun kararlar üreten bir kontrol merkezidir. Bu kontrol birimi, alıcı ve tepki sinirlerinden oluşmaktadır [100]. İnsan beyninin çalışmasını sağlayan temel taşlardan birisi olan sinir sistemi, insanların bütün davranışları ve çevresini anlamasını sağlamaktadır. Şekil 4.5'te, sinaps, akson, soma ve dendritlerden oluşan biyolojik bir sinir hücresi gösterilmektedir.



Şekil 4.5 Biyolojik sinir hücresi [36]

İnsan beyninde bulunan sinir hücrelerine tıp literatüründe “nöron” adı verilmektedir. Nöron; biyolojik sistemden gelen uyarıları alan ve bunları yorumlayarak uygun çıktılara dönüştüren temel işlemcidir. Nöronlar çevresinden aldığı hücresel bilgileri, işleme ve iletme yetenekleriyle donatılmış çok özel hücrelerdir. Nöronlar yeterince uyarıldığında, aksondan gelen bir elektriksel uyarıya anında tepki gösterirler. Nöronların başlıca işlevi, “işaret alıp işaret göndermek”, yani bilgi alışverişidir. Şekil 4.6’da, biyolojik sinir sisteminin işleyişi blok diyagram olarak verilmiştir.



Şekil 4.6 Sinir sisteminin blok gösterimi [94]

Şekil 4.6’da insanlara ait biyolojik sinir sistemine algılayıcı sinir uçlarıyla bilgi girişinden başlayıp, merkezi sinir sisteminde bu bilginin işlenmesi sonucu tepkiye dönüşümü, temsili olarak resmedilmiştir.

Sinir ağı sistemi, insan beyinin temel kısımlarından birisi olup, ancak mikroskopla görülebilecek kadar küçüktür. Nöronlar, şaşılacak kadar karmaşık bir biyokimyasal ve elektriksel sinyal işleme fabrikası olarak düşünülebilmektedir [101].


4.8.2.2 Yapay Sinir Hücreleri

Yapay nöronlar, sinir ağlarını oluşturan en temel birimlerdir. Yapay nöronların aralarında bir bağlantı oluşturmak kaydıyla katmanlar halinde kümelenmesiyle yapay sinir ağları oluşmaktadır.

Yapay sinir hücresi, biyolojik sinir hücresinin temel davranışlarından esinlenen matematiksel modeli ortaya koyan bir algoritma veya fiziksel araç olarak tanımlanabilmektedir. Biyolojik sinir hücresinin tanımından hareket ederek, yapay bir sinir hücresinin diğer sinir hücrelerinden aldığı sinyalleri bünyesinde topladığını ve toplam sinyal birikiminin belli bir eşiği aştığı anda, bu yapay sinir hücresinin kendi sinyalini bir başka sinir hücresine ilettiği söylenebilmektedir [102].

Yapay sinir ağları metodolojisinde, biyolojik sinir sisteminin temel işlem birimi olan nöronlar, matematiksel olarak modellenebilirler ve biyolojik sinir sistemlerinde olduğu gibi birbirleriyle ilişkilendirilebilirler. Bir yapay sinir ağına dışarıdan veri girişi yapıldığında, insanda sinir sisteminde olduğu gibi yapay modelde, bu girdileri matematiksel yapay nöronlarda işler ve çıktılar üretebilir. Başlangıçta üretilen çıktı değerleri istenenden oldukça uzak olabilmekte, fakat öğrenme işlemi devam ettikçe yapay nöronlar arasındaki sinaptik ağırlıklar ayarlanarak belirli bir yakınsama sağlanmakta ve öğrenme tamamlanmaktadır. Buna göre, yapay sinir ağları biyolojik sinir ağlarının taklit edildiği bir modellemedir.

Şekil 4.7’de, yapay sinir hücrelerinin katmanlar halinde matematiksel fonksiyonları gösterilmektedir. Şekilde görüldüğü gibi, her bir girdideki değişim, nöron çıkışında belirli bir değişime neden olmakta ve bu değişim büyüklüğü, girdinin ağırlık derecesine bağlıdır.



Şekil 4.7 Yapay sinir hücrelerinin matematiksel yapısı [1], [30]

Şekil 4.7'deki X_i sembolü giriş verilerini, W_i sembolü kazanç ağırlıklarını, Σ sembolü toplama fonksiyonunu, Q sembolü eşik değerini, $f(x)$ sembolü ise aktivasyon fonksiyonunu ifade etmektedir.

Yapay sinir hücreleri mühendislik biliminde, en temel haliyle beş bileşenden oluşmaktadır. Her proses elemanının beş temel elemanı bulunmaktadır ve bunlar aşağıda belirtilmiştir:

1. **Girdiler:** Yapay sinir hücresine dış dünyadan gelen bilgilerdir. Bilgiler dış dünyadan geldiği gibi başka hücrelerden veya kendisinden de gelebilir. Girişlerin verileri bir sonraki aşamaya iletmekten başka hiçbir işlevi bulunmamaktadır. Başka bir ifadeyle girişler veri üzerinde hiçbir matematiksel işlem yapmadan sadece bir iletici görevi yapmaktadırlar. Girişler, yapay sinir ağlarının dış dünya ile ilişki halinde olan iki elemanından biridir. Bir nöronun çevreyi algılamasına bağlı olarak sınırsız sayıda girişi olabilir fakat her bir nöronun sadece tek bir çıkışı olmak zorundadır. Girdiler, yapay sinir ağlarının algılayıcıları nitelendirilebilir.
2. **Ağırlıklar:** Yapay sinir sistemine girilen veriler, bağlantılar üzerindeki ağırlıklar aracılığıyla hücreye girerek bulunduğu giriş hücresini etkilerler. Ağırlıkların bir başka özelliği de nörona girdi olarak kullanılan değerlerin, matematiksel katsayısı olmalarıdır. Girdiler ile nöronlar arasında iletişimi sağlayan bütün bağlantıların değişik ağırlık değerlerinin olması, ağırlıkların tüm işlem elemanları üzerinde etkili olmasını sağlamaktadır. Ağırlıklar hücreye gelen bilgilerin hücre üzerindeki etki ve önemini gösterir. Yapay sinir ağları, öğrenme işlevini ağırlıkların değiştirilmesi sayesinde başarabilmektedir. Ağırlıklar,

biyolojik sinir hücresindeki aksonlar olarak düşünülebilirler. Ağırlıkların başlangıç değerleri genellikle (-1 ile +1) aralığında rastgele seçilmektedir[1].

3. Toplama Fonksiyonu: Biyolojik nöronda yer alan dendritlerin yaptığı görevi yapan toplama fonksiyonu aslında birleştirme fonksiyonunun en yaygın kullanılan türüdür. Bir hücreye gelen net girdileri hesaplayan bir fonksiyondur ve genellikle girişlerin ilgili ağırlıkla çarpımının toplamı şeklinde ifade edilir. Bu fonksiyon hücreye gelen net girdiyi hesaplar. Toplama fonksiyonunun farklı fonksiyonları olmakla beraber, en yaygın kullanılanı ağırlıklı toplama fonksiyonudur [49]. En yaygın olarak ağırlıklı toplam fonksiyonu kullanılır. Bu fonksiyon aşağıdaki şekilde formülize edilir.

$$\text{Net} = \sum G_i \cdot A_i \quad (n=1, \dots, n) \quad (4.1)$$

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

Her proses elemanı bağımsız olarak farklı bir toplama fonksiyonuna sahip olabilecekleri gibi aynı toplama fonksiyonuna da sahip olabilirler. Toplama fonksiyonuna aşağıdaki fonksiyonlar örnek olarak verilebilir:

- Çarpım: $\text{NET} = \sum G_i \cdot A_i \quad (4.2)$

- Maksimum: $\text{NET} = \text{Max} (G_i \cdot A_i) \quad (4.3)$

- Minimum: $\text{NET} = \text{Min} (G_i \cdot A_i) \quad (4.4)$

- Çoğunluk : $\text{NET} = \sum \text{sgn} (G_i \cdot A_i) \quad (4.5)$

- Kümülatif Toplam : $\text{NET} = \text{NET}_{(\text{eski})} + \sum (G_i \cdot A_i) \quad (4.6)$

4. Aktivasyon Fonksiyonu: Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da çıktıyı hesaplamak için değişik formüller kullanılmaktadır. Bazı modellerde bu fonksiyonun türevinin alınabilir bir fonksiyon olması şart koşulmaktadır. Aktivasyon fonksiyonunda, ağırlık işlemci elemanlarının hepsinin aynı fonksiyonu kullanması gerekmez. Bazı elemanlar aynı fonksiyonu diğerleri farklı fonksiyonları kullanabilirler. Problem durumuna en uygun fonksiyonu tasarımcı yaptığı denemeler sonucunda kendisi belirleyebilir. Genellikle doğrusal olması tercih edilmeyen bir fonksiyondur. Aktivasyon fonksiyonu olarak hangi fonksiyonun seçileceği sinir ağırlıklarının verilerine ve ne öğrenmek istediğine bağlı olarak değişmektedir. En çok kullanılan türleri doğrusal, sigmoid ve tanjant hiperbolik fonksiyonudur.

Aktivasyon fonksiyonları, çıktı değerlerinin belirli sınırlar içerisinde kalmasını sağlarlar. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da işlemci elemanlar farklı fonksiyonlar kullanabilirler. Çok Katmanlı Algılayıcı modellerde, en çok sigmoid fonksiyonu kullanılmaktadır [84], [90].

$$\text{Sigmoid Fonksiyonu: } F(\text{NET}) = 1 / (1 + e^{-\text{NET}}) \quad (4.7)$$

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

- Lineer Fonksiyon: $F(\text{NET}) = \text{NET}$ (4.8)

- Step Fonksiyonu: $F(\text{NET}) = 1 \text{ Net} > \text{eşik değeri}$
 $F(\text{NET}) = 0 \text{ NET} \leq \text{eşik değeri}$ (4.9)

- Sinüs Fonksiyonu: $F(\text{NET}) = \sin(\text{NET})$ (4.10)

- Çoğunluk: $F(\text{NET}) = 0 \quad \text{NET} \leq 0$
 $F(\text{NET}) = \text{NET} \quad 0 < \text{NET} < 1$
 $F(\text{NET}) = 1 \quad \text{NET} > 1$ (4.11)

- Hiperbolik Tanjant Fonksiyonu:

$$F(\text{NET}) = (e^{\text{NET}} + e^{-\text{NET}}) / (e^{\text{NET}} - e^{-\text{NET}}) \quad (4.12)$$

5. Hücre Çıktısı: Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı, dış dünyaya veya başka bir hücreye gönderilir. Hücre kendi çıktısını kendisine girdi olarak da gönderebilir. Aktivasyon fonksiyonundan geçildikten sonra elde edilen sonuca çıktı değeri denilir. Çıkış işlevi; aktivasyon fonksiyonundan alınan, $Y = f(v_i)$ çıktısını, ağın nihai çıktısı olarak dış dünyaya, ya da çıktıyı oluşturan nöronun bağlı olduğu diğer nöronlara girdi olarak gönderilmesinden sorumludur. Yapay sinir ağları, tek bir nörondan oluştuğu için; bu ağ, Y çıktısını dış dünyaya nihai çıktı olarak göndermektedir [27], [36], [84], [90].

4.8.2.3 Biyolojik Sinirler ile Yapay Sinirlerin Karşılaştırılması

Beyin ve sinir sisteminin tüm özellikleri, içyapısı ve nasıl çalıştığının günümüzde tam olarak bilinmemesi, sağlıklı bir karşılaştırma yapmayı zorlaştırmaktadır. Ancak, bilgisayarlar ve bilgisayar ağlarında yaşanan gelişmeler insan beyninin ve sinir sisteminin en ince detaylarına kadar değilse de belli bir aşama kaydetmesine yardımcı olmuş ve yapay sinir ağları metodunun geliştirilmesi sayesinde de belirli bir düzeyde

sinir sisteminin taklit eden modeller tasarlanmaya başlanmıştır. Beyin ve sinir sistemi hakkında detaylı bilgi artışı sağlandığında çok daha sağlıklı bir karşılaştırma yapmak mümkün olabilecektir.

Aşağıda verilen Çizelge 4.4'te, biyolojik sinir hücresinin elemanlarına karşılık gelen yapay sinir hücresi elemanları gösterilmektedir.

Çizelge 4.4 Biyolojik sinirler ile yapay sinirlerin karşılaştırılması [36]

İşlem Birimi		
Biyolojik Sinir Ağı	Yapay Sinir Ağı	Görevleri
Dendrit	Alıcı ve Toplayıcı	Çevreden gelen veriyi alır
Akson	Verici	Gövdenin oluşturduğu veriyi iletir
Hücre Gövdesi	Aktivasyon Fonksiyonu	Gelen veriyi toplayarak yorumlar ve veriyi oluşturur
Sinaptik Ağırlıklar	Bağlantı Ağırlıkları	Öğrenilenleri hafızada saklar

Çizelge 4.4'te, görüldüğü gibi yapay sinir ağlarının insan sinir sisteminde bulunan mekanizmaları taklit eden, aynı görevi yapan yapay elemanları bulunmaktadır.

Yapay sinir ile biyolojik sinirlerin işlemci elemanlarının, işlevleri konusundaki benzerlikleri karşılaştırmıştır. Çizelge 4.5'te biyolojik sinir hücreleri ile yapay sinir hücrelerinin işlevsellikleri açısından karşılaştırmaları göstermiştir [35].


Çizelge 4.5 Biyolojik sinir hücresi ile yapay sinir hücresinin karşılaştırılması [35]

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

Çizelge 4.5'te, biyolojik sinir sistemi ile onun bir anlamda taklidi olan, yapay sinir ağları arasındaki benzer noktalar gösterilmiştir. Görüldüğü gibi insanlardaki sinir sisteminde bulunan her elemanın yapay sinir sisteminde bir karşılığı tasarlanmıştır.

4.8.3 Yapay Sinir Ağlarının Sınıflandırılması (YSA Mimarileri)

Yapay sinir ağları, sinir hücrelerinin birbirlerine çeşitli şekillerde bağlanmalarından oluşmaktadır. Hücre çıkışları, ağırlıklar üzerinden diğer hücrelere veya kendisine giriş olarak bağlanabilir ve bağlantılarda gecikme birimi de kullanılabilir. Hücrelerin bağlantı şekillerine, öğrenme kurallarına ve aktivasyon fonksiyonlarına göre çeşitli modeller geliştirilmiştir. İçerisinde birçok nöron bulunduran yapay sinir ağları, belli topolojilerle (mimariler) tanımlanabilir. Bu mimarilerden en yaygın kullanılanlar, aşağıda Şekil 4.8’de gösterilmiştir.



Şekil 4.8 Yapay sinir ağları mimarileri [101]


Şekil 4.8’de görüldüğü üzere, ağlar tek katmanlı ve çok katmanlı olmak üzere birbirinden ayrılabilir. Tipik olarak bir modelin istenen çıkışı elde etmek üzere inşa edilen bir giriş tabakası, çıkışların elde edildiği bir çıkış tabakası ve giriş ve çıkış tabakaları arasında bulunan en az bir gizli katmanı bulunmaktadır. Gizli katman sayısı en az bir veya daha fazla olmalıdır, çünkü bir çıktı gizli katman olmadan direkt olarak elde edilemez [101].

Yapay sinir ağları, yapılarına göre, ileri beslemeli (feed-forward) ve geri beslemeli (feedback) olmak üzere iki farklı yapıda incelenebilir.

4.8.3.1 İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli (feedforward) ağlarda, işlemci elemanlar genellikle katmanlara ayrılmışlardır. İşaretler, girdi katmanından çıktı katmanına tek yönlü bağlantılarla iletilir. İşlemci elemanlar, bir katmandan diğerine bağlantı kurarken, aynı katman içerisinde bağlantıları bulunmaz. İleri beslemeli ağlara örnek olarak, çok katmanlı algılayıcılar (MLP) ve sayısallaştırılmış öğrenme vektörü (LVQ) ağları verilebilir [100].

Şekil 4.9’da ileri beslemeli yapay sinir ağı işleyişi blok diyagram olarak ifade edilmiştir.




Şekil 4.9 İleri beslemeli yapay sinir ağları [100]

Blok olarak ifade edilen ve oldukça yaygın kullanım alanı bulunan çok katmanlı algılayıcı sinir ağı (MLP); bir giriş, bir veya birden çok gizli katman ve bir çıkış katmanından oluşmaktadır. Her katmanında, bir veya daha fazla işlemci eleman bulunabilmektedir. Çok katmanlı algılayıcı sinir ağından çıkan herhangi bir nöron çıkışı, aşağıdaki denklemde gösterildiği gibi formüle edilmiştir.

$$y_k = f(\sum_k w_k x) \quad (4.13)$$

İleri beslemeli sinir ağı giriş katmanında veriler üzerinde herhangi bir işlem yapılmadan bir sonraki katmana gönderilir. Gizli katmandaki işlemci elemanı sayısı tamamen uygulanan problemlerin giriş sayısına bağlı olarak sistem tarafından veya tasarımcı tarafından belirlenebilir. Gizli katmandaki, ara katman sayısı ve ara katmanlardaki işlemci elemanı sayısı deneme yanılma yoluyla da bulunabilir [30].

Şekil 4.10’da birden fazla girişi olan, bir gizli katmanı ve iki ara katmanı bulunan, iki adet çıkışa sahip ileri beslemeli çok katmanlı bir yapay sinir ağı modeli gösterilmiştir.




Şekil 4.10 İleri beslemeli çok katmanlı yapay sinir ağları [30]

Şekil 4.10’da, ileri beslemeli, çok katmanlı yapay sinir ağının, veri girişlerinin yapıldığı giriş katmanı, bilgi işlemin yapıldığı gizli katman ve işlenmiş verilerin çıkışının alındığı çıkış katmanları, bölümler halinde gösterilmiştir.

4.8.3.2 Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağlarında, en az bir işlemci elemanın çıktısı, kendisine ya da diğer işlemci elemanlara girdi olarak verilmekte ve genellikle geri besleme, bir geciktirme elemanı (ara katman veya çıktı katmanındaki aktivasyon değerlerini, bir sonraki iterasyona girdi olarak taşımakla görevli eleman) üzerinden yapılmaktadır. Geri besleme, bir katmandaki işlemci elemanlar arasında olduğu gibi katmanlar arasındaki işlemci elemanlar arasında da olabilmektedir. Bu yapısı sayesinde geri beslemeli yapay sinir ağları, doğrusal olmayan dinamik bir davranış gösterirler. Bu sayede, geri beslemenin yapılış şekline göre farklı yapı ve davranışta geri beslemeli yapay sinir ağları elde edilebilir. Geri beslemeli yapay sinir ağları, karmaşık bir çalışma düzeneğine sahip olmasına rağmen, dinamik hafızaları nedeniyle ön tahmin uygulamalarında başarılı sonuçlar vermektedirler [100].

Şekil 4.11’de geri beslemeli yapay sinir ağının genel işleyişi ve geri besleme olayı sembolik olarak gösterilmiştir.



Şekil 4.11 Geri beslemeli yapay sinir ağları [100]

Şekil 4.11’de görüldüğü üzere, geri beslemeli yapay sinir ağlarında en az bir hücrenin çıkışı kendisine veya diğer hücrelere giriş olarak verilmektedir. Geri besleme genellikle bir geciktirme elemanı üzerinden yapılır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilmektedir. Bu yapısı ile geri beslemeli yapay sinir ağları, doğrusal olmayan dinamik bir davranış göstermektedirler.


İleri beslemeli yapay sinir ağları notasyonları kullanılarak ağın gecikme anındaki çıkışları aşağıdaki denklemde görüldüğü gibi formüle edilmiştir. Ağın tanındaki çıkışı $o(t)$ ise, $t + d$ anındaki çıkışı ise $o(t + d)$ olacaktır. Buradaki d sabiti sembolik olarak gecikme süresini göstermektedir.

$$o(t + \delta) = f [w.o(t)] \quad (4.14)$$

4.8.3.3 Geri Beslemeli Geri Yayılmalı Sinir Ağları

Geri beslemeli geri yayılmalı ağlar (Feed Forward, Back Propagation Networks), sinir ağlarının çok popüler bir modelidir. Çok katmanlı geri beslemeli ağlarda, işlemci elemanlar katmanlar halinde (tabaka) inşa edilmiştir ve yalnızca bitişik katmanlardaki elemanlar birbirleriyle iletişim halindedir. Bu tip ağlarda bilgi yayılımı geriye doğru olmaktadır ve bir geri besleme düğüm noktası yoktur. Hatalar, ağın öğrenme sürecinde geriye doğru yayılarak öğrenilmekte ve çözüme kavuşturulmaktadır [103].

Şekil 4.12’de geri beslemeli, geri yayılmalı sinir ağı modelinin hataları geriye doğru yayarak öğrenmesi, yani hatalardan deneyim kazanarak uzmanlaşması süreci gösterilmiştir.



Şekil 4.12 Geri beslemeli geri yayılmalı sinir ağı modeli mimarisi [104]

Şekil 4.12’de görüldüğü gibi, model geri besleme sayesinde karşılaştığı her hatadan bir şeyler öğrenerek, bir ileriki adımda bu hataları tanıyarak kolayca çözümler üretebilmektedir.

4.8.4 Yapay Sinir Ağlarının Temel Öğrenme Kuralları

Yapay sinir ağlarının en önemli özelliklerinden birisi öğrenme yeteneğine sahip olması olarak kabul edilmektedir. Sinir ağlarında çok önemli bir konu olan öğrenme, günümüzde yapay ağlar konusuyla ilgilenen bilim adamlarının yoğun ilgisini çekmeye devam etmektedir. Araştırmacıların cevaplamaya çalıştıkları temel sorular; “nasıl öğrenebiliyoruz”, “öğrenme için en etkili süreç hangisidir”, “ne kadar ve nasıl daha hızlı öğrenebiliriz”, “öğrenmenin önündeki engeller nelerdir” sorularıdır.

Yapay sinir ağlarında öğrenme işlemi, istenilen çıktıları elde edebilmek amacıyla bağlantı ağırlıklarının belirlenmesidir. Öğrenme, mevcut örnekler arasındaki yapının iyi bir davranış göstermesini sağlayabilecek olan bağlantı ağırlıklarının hesaplanmasıdır. Yapay sinir ağlarının öğrenme esnasında elde ettikleri bilgiler, sinir hücreleri arasındaki bağlantı ağırlıkları şeklinde saklanır. Bu ağırlık değerleri, sinir ağlarının verileri işleyebilmesi için gerekli olan bilgileridir [103].

Öğrenme, örneklerden-öğrenme şeklinde gerçekleşmektedir. Örneklerden öğrenmenin temel felsefesi, bir olay hakkında gerçekleşmiş geçmiş örnekler kullanılarak, olayın girdi ve çıktıları arasındaki ilişkilerden yararlanılarak, gelecekte oluşacak yeni çıktılar belirlemektir.

Şimdiye kadar tasarlanan yapay sinir ağı modelleri, farklı yollarla birbirleriyle iletişim kurabilmektedirler, fakat her birinin öğrenme süreci birbiriyle aynı değildir. Sinir ağları, bir modelin öğrenme sürecini tanımlayan ve öğrenme denklemleri olarak adlandırılan matematiksel ifadelerle tanımlanmış, öğrenme kurallarına göre işlem yaparlar. Öğrenme biçimleri, insanlarda olduğu gibi sinir ağlarında da birbirinden farklı olabilmektedir [101].

Öğrenmenin gerçekleşebilmesi için, yapay nöronlar arasındaki sinaptik ağırlıkların en uygun bir biçimde ayarlanması gerekmektedir. Yapay sinir ağları, klasik programlamalar gibi belirli bir algoritma çerçevesinde programlanmazlar.

Sinir ağları insanlar gibi örnekler ile eğitilirler. Yapay sinir ağlarının öğrenmesi birçoğunun öğrenmesine benzetilebilir. Sıcak bir nesneye dokunmaması gerektiğini

deneyerek öğrenen çocuklar, zamanla daha az sıcak olan bir cisme dokunabilme cesaretini gösterirler ve sıcak süt dolu bardağı elleriyle tutarlar. Yani çocuk sıcaklık bilgisini bir deneyim sonucu öğrenmiştir. Yapay nöronlar da benzer şekilde; mevcut örnek kümesi üzerinde girdi ile çıktı arasındaki sinaptik ağırlıkları değiştirilerek eğitilirler [36]. Bu şekilde, sinir ağları geçmiş deneyimlerine dayanarak problem çözme yeteneklerini geliştirebilirler.

Sinir ağlarında öğrenme işlemi, çok parametrelili, karmaşık ve matematiksel olarak ifade edilmesi zor bir işlemdir. Bugün kullanılan öğrenme kuralları, bu işlemin basitleştirilmiş veya farklı formatta ifade edilmiş biçimleridir. Bu algoritmalar dört tanesi temel olup diğerleri bunlardan türetilmiştir. Bunlar; Hebb, Hopfield, Delta ve Kohonen öğrenme kurallarıdır.

4.8.4.1 Hebb Öğrenme Kuralı

Hebb Kuralı 1949 yılında Donald Hebb [105], tarafından geliştirildiği bilinen öğrenme kuralıdır. Kuralın tanımı Hebb'in bahsedilen yılda yazmış olduğu , "The Organization of Behaviour" adlı kitabında yer almaktadır. Kural özetle şu şekildedir; "Eğer sinyal alan ile gönderen nöronlar arasındaki sinaptik ağırlıkların ikisi de matematiksel olarak aynı işarete sahip ise, bu iki nöron arasındaki bağ kuvvetlendirilmelidir. Aksi halde bağın kuvveti azaltılmalıdır." [36].

Bilinen en eski öğrenme kuralıdır ve diğer öğrenme kurallarının temelini oluşturmaktadır. Hebb öğrenme kuralına göre öğrenme sinyali hücre çıkışına eşittir. Yani bir hücre aktif ise bağlı olduğu hücreyi aktif, pasif ise hücreyi pasif yapma eğilimindedir [84].

Öğrenme sinyali = $f(w_i^t x)$ (4.15)
ile belirtilir.

Ağırlık vektöründeki artış ise;

$$\Delta w_i = c f(w_i^t x) x \quad (4.16)$$

ile veya

$$w_{ij} = c o_i x_j \quad (4.17)$$

ile belirtilir.

Bu öğrenme kuralında başlangıç olarak sıfıra yakın değerler ile başlanılmalıdır. Hebb öğrenme kuralına göre giriş ve çıkış değerlerinin çarpımı pozitif ise w_{ij} ağırlığında bir artış, negatif ise bir azalış gerçekleşmektedir.

4.8.4.2 Hopfield Öğrenme Kuralı

Hebb kuralına benzeyen bu kuralda, ek olarak bağ kuvvetlerindeki değişimlerin ne kadar olacağı da belirtmektedir. Bu kurala göre; bağ kuvveti öğrenme hızı kadar artırılır ya da azaltılır. Öğrenme hızı pozitif ya da negatif bir sayısal değerdir. Uygulamada öğrenme hızı 0 ile 1 arasında seçilmektedir [71], [97].

Yapay sinir ağları ile işlemci eleman bağlantılarının ne kadar kuvvetlendirilmesi veya zayıflatılması gerektiği belirlenirken, beklenen çıkış ve girişlerin her ikisi de aktif veya pasif ise ağırlık değerleri, öğrenme katsayısı kadar kuvvetlendirilir veya zayıflatılır. Yani ağırlıkların kuvvetlendirilmesi veya zayıflatılması öğrenme katsayısı yardımıyla gerçekleştirilmektedir. Öğrenme katsayısı genellikle 0 ile 1 arasında sabit ve pozitif bir değerdir [24], [105], [113].

4.8.4.3 Delta Öğrenme Kuralı

Widrow ve Hoff tarafından geliştirilen bu kural Hebb kuralının gelişmiş şeklidir. Günümüzde en yaygın kullanılan öğrenme kullarından birisi olan Delta kuralı, yapay sinir hücresinin gerçek çıktısı ile beklenen çıktısı arasındaki farkı azaltmak için yapay sinir ağlarının işlemci elemanları arasındaki bağlantı ağırlık değerlerinin sürekli değiştirilmesi ilkesine dayanır. Bu kuralla, gerçek çıktı ile beklenen çıktı arasındaki fark (delta) en aza indirilmeye çalışılmaktadır [100]. Kısacası, Delta kuralında amaç sinir ağının hata kareleri toplamının en aza indirilmesidir. Delta öğrenme kuralına göre, beklenen çıkış ile gerçekleşen çıkış arasındaki farkı azaltmak için, sinir ağı işlemci elemanlarının ağırlık değerleri, hata kareleri ortalaması en aza indirilene kadar sürekli olarak değiştirilir.

4.8.4.4 Kohonen Öğrenme Kuralı

Kohonen [106] tarafından ortaya atılan bu öğrenme kuralı, biyolojik sistemlerdeki öğrenmeden esinlenerek geliştirilmiştir. Bu yöntemde, hücreler ağırlıklarını değiştirmek (öğrenmek), elverişli durum veya ölçülerini güncellemek için birbirleri ile yarışır. Ağırlık vektörleri girdi vektörüne en yakın olan işlemci eleman yarışmayı kazanan ilan edilir ve komşularına bağlantı ağırlıklarını güncellemek için izin verilir [36], [91].

4.8.4.5 Basit Algılayıcı (Perseptron) Öğrenme Kuralı

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

- Ağa girilen değerler : X
 - Çıktı değeri : $\hat{C}$
 - Beklenen değerler : B
 - Girdilerin ağırlıkları : W
 - Eşik değeri : ϕ (Çıktının sıfırdan farklı olmasını sağlayan değer)
 - Öğrenme katsayısı : λ
- olmak üzere;

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

Perseptron ünitesine gelen net girdi aşağıdaki gibidir:

$$NET = \sum w_i x_i \quad (4.18)$$

olur.

Perseptron ünitesinin çıktısı ise:

$$\hat{C} = \begin{cases} 1 & \text{Eğer } NET > 0 \\ 0 & \text{Eğer } NET < 0 \end{cases} \quad (4.19)$$

olur.

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

$$W_n = W_0 - \lambda \times \begin{cases} B - \hat{C} & \text{Eğer } B=0 \text{ ve } \hat{C}=1 \\ \hat{C} - B & \text{Eğer } B=1 \text{ ve } \hat{C}=0 \end{cases} \quad (4.20)$$

olur.

Bu adımlar bütün girdi setindeki örnekler için sınıflandırma yapılmaya kadar devam eder [90].

4.8.4.6 Delta Öğrenme Kuralı (Windrow-Hoff) Kuralı

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

- *İleri Doğru Hesaplama Safhası:*

Ağın çıktısının hesaplanması safhasıdır. Bilgi işleme, eğitim setindeki bir örneğin *girdi katmanından*($G1, G2, \dots$)ağa gösterilmesi ile başlar. Gelen girdiler olduğu gibi ara katmana gönderilir. Girdi katmanının k . proses elemanının çıktısı ζ_k^i ,

$$\zeta_k^i = G_k \quad (4.21)$$

k . girdi elemanının j . ara katmanına bağlayan bağlantının ağırlık değeri A_{kj} ,
Ara katmandaki proses elemanlarına net girdi NET_j^a ,

$$NET_j^a = \sum A_{kj} \zeta_k^i \quad (k=1, \dots, n) \quad (4.22)$$

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

B_j ara katmanda bulunan j . elemana bağlanan eşik değer elemanın ağırlığı,
Sigmoid fonksiyonun kullanılması halinde çıktı:

$$\zeta_j^a = 1 / [1 + e^{-(NET_j^a + \beta_j^a)}] \quad (4.23)$$

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

Ara katmanın bütün proses elemanları ve çıktı katmanının proses elemanlarının çıktıları aynı şekilde kendilerine gelen NET girdinin hesaplanması ve sigmoid fonksiyonundan geçirilmesi sonucu belirlenir. Çıktı katmanının çıktıları ($\zeta_1, \zeta_2, \dots$) bulununca ağın ileri hesaplama işlemi tamamlanmış olur.

- *Geriye Doğru Hesaplama Safhası*

Ağırlıkları değiştirme safhasıdır. Ağın çıktıları ($\zeta_1, \zeta_2, \dots$), beklenen çıktılarla ($B_1, B_2, \dots$) ile karşılaştırılır. Aradaki fark hata kabul edilir. Amaç bu hatayı düşürmektir. Geriye hesaplamada bu hata, ağın ağırlık değerlerine dağıtılarak bir sonraki iterasyonda hatanın azaltılması sağlanır. Çıktı katmanındaki m . proses elemanı için oluşan hata (E_m),

$$E_m = B_m - \zeta_m \text{ olur.} \quad (4.24)$$

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

$$TH = \frac{1}{2} \sum E_m^2 \quad (4.25)$$

Toplam hatayı en aza indirmek için hatanın kendisine neden olan proses elemanlarına dağıtılarak ağırlıklar değiştirilir. Bunun için:

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

Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi:

Ara katmandaki j . proses elemanını çıktı katmanındaki m . proses elemanına bağlayan bağlantının ağırlığındaki değişim miktarı ΔA^a 'nın, t . iterasyondaki ağırlığın değişim miktarı $\Delta A^a_{jm}(t)$;

m . çıktı ünitesinin hatası δ_m ,

Öğrenme katsayısı (ağırlıkların değişim miktarı) λ ,

Momentum katsayısı α olmak üzere;

$$\Delta A^a_{jm}(t) = \lambda \delta_m \zeta_j^a + \alpha \Delta A^a_{jm}(t-1) \quad \text{olur.} \quad (4.26)$$

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

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

$$\delta_m = f'(NET) \cdot E_m \quad (4.27)$$

$$\delta_m = \zeta_m (1 - \zeta_m) \cdot E_m \quad (4.28)$$

olur.

t . iterasyondaki ağırlıkların yeni değerleri:

$$A^a_{jm}(t) = A^a_{jm}(t-1) + \Delta A^a_{jm}(t) \quad (4.29)$$

olur.

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

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

$$\Delta \beta^c_m(t) = \lambda \delta_m + \alpha \Delta \beta^c_m(t-1) \quad (4.30)$$

t . iterasyondaki ağırlıkların yeni değerleri:

$$\beta^c_m(t) = \beta^c_m(t-1) + \Delta \beta^c_m(t-1) \quad (4.31)$$

olur.

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

Ağırlıklardaki değişim ΔA^i ;

Hata terimi δ^a olmak üzere;

$$\Delta A^i_{kj}(t) = \lambda \delta^a_j \zeta^i_k + \alpha \Delta A^i_{kj}(t-1) \quad (4.32)$$

$$\Delta^a_j = f'(NET) \sum \delta_m A^a_{jm} \quad (4.33)$$

olur.

Aktivasyon fonksiyonu $f(NET)$, sigmoid fonksiyon düşünülürse:

$$\delta^a_j = \zeta^a_j (1 - \zeta^a_j) \sum \delta_m A^a_{jm} \quad (4.34)$$

Ağırlıkların yeni değerleri ise:

$$A^i_{kj}(t) = A^i_{kj}(t-1) + \Delta A^i_{kj}(t-1) \quad (4.35)$$

olur.

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

$$\Delta \beta^a_j(t) = \lambda \delta_m + \alpha \Delta \beta^a_j(t-1) \quad (4.36)$$

olur.

t. iterasyondaki ağırlıkların yeni değeri ise:


$$\beta^a_j(t) = \beta^a_j(t-1) + \Delta \beta^a_j(t-1) \quad (4.37)$$

olur.

Böylece bir iterasyonun ileri ve geri hesaplamaları tamamlanmış olur. İkinci bir örnek verilerek sonraki iterasyona başlanır ve aynı işlemler öğrenme tamamlanıncaya kadar yinelenir [24].

4.8.4.7 Gözetimli (Öğretmenli) Öğrenme Yöntemi


Öğrenen sistemin öğrenebilmesi için bir öğretmen yardımcı olmaktadır. Öğretmen, öğrenilmesi istenen olay ile ilgili örneklerin hem girdi değerlerini, hem girdiler karşılığında olması gereken çıktı değerlerini verir. Sistemin görevi girdileri öğretmenin belirlediği çıktıları haritalamak ve bu sayede girdiler ile çıktılar arasındaki ilişkileri öğrenmektir. En çok kullanılan model olan *Çok Katmanlı Algılayıcılar Yapay Sinir Ağı Modelinde* bu yöntem kullanılmaktadır [84], [107]. Şekil 4.13'te gözetimli öğrenme yöntemi ifade edilmiştir.



Şekil 4.13 Gözetimli öğrenme yöntemi [84]

4.8.4.8 Gözetimsiz (Öğretmensiz) Öğrenme Yöntemi


Bu yöntemde sistemin öğrenmesi için herhangi bir öğretmen yoktur. Yani sisteme sadece girdi değerleri gösterilir. Örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendisine öğrenmesi beklenir. Sistemin öğrenmesi bittikten sonra çıktıların ne anlama geldiği kullanıcı tarafından belirlenmelidir. Bu yöntemler daha çok sınıflandırma için kullanılan yöntemlerdir. En yaygın olarak *Kohonen Ağları Yapay Sinir Ağı* ve *ART Ağları Yapay Sinir Ağı* modellerinde kullanılır [107]. Şekil 4.14'te gözetimsiz öğrenme yöntemi ifade edilmiştir.



Şekil 4.14 Gözetimsiz öğrenme yöntemi [84]

4.8.4.9 Destekleyici Öğrenme

Gözetimli öğrenme kuralına yakın bir metottur. Bu yöntemde de sisteme bir öğretmen yardımcı olmaktadır. Ağ çıkışından alınan değerler karşılaştırma için kullanılmamaktadır. Ancak üretilen çıktının doğru ya da yanlış olduğunu gönderen bir sinyal, ağı geri verilir. Sistemin, öğretmenden gelen bu sinyali dikkate alması ile öğrenme gerçekleştirilir. *LVQ Ağı Yapay Sinir Ağı* modelinde kullanılır[84], [107]. Şekil 4.15'te destekleyici öğrenme yapısı ifade edilmiştir.



Şekil 4.15 Destekleyici öğrenme yapısı [113]

Yukarıda anlatılan üç temel yöntemin birlikte kullanıldığı karma yöntemler de uygulanmaktadır. Kısmen öğretmenli, kısmen öğretmensiz olarak öğrenme yapan ağlarda kullanılır. *Radyal Tabanlı Yapay Sinir Ağlar (RBN)* ve *Olasılık Tabanlı Yapay Sinir Ağları (PBN)* karma öğrenme yöntemine örnek verilebilmektedir.

4.9 Yapay Sinir Ağlarının Geliştirilmesi ve Eğitilmesi

Yapay sinir ağlarındaki işlemci elemanların bağlantı ağırlık değerlerinin belirlenmesi işlemine, ağı eğitilmesi denir. Başlangıçta bu değerler rastgele atanırken, daha sonra ağı sunulan örneklerle ağırlık değerleri değiştirilir. Burada amaç ağı sunulan örneklerin doğru çıkışları üretecek ağırlık değerlerini bulmaktır.

Ağın doğru ağırlık değerlerine ulaşması, örneklerin temsil ettiği olay hakkında genellemeler yapabilme yeteneğine kavuşması demektir. Yapay sinir ağlarının eğitilmesinin iki aşaması vardır. İlk aşamada, ağı sunulan örnek için ağın üreteceği çıkış belirlenir. Çıkış değerinin doğruluk derecesine göre ikinci aşamada, ağın bağlantılarının sahip olduğu ağırlıklar değiştirilir [90].

Yapay sinir ağlarının eğitimi ve testi için toplanan veriler, sistemin düzgün çalışma uzayını kapsamalıdır. Örnek kayıtlarının çalışma uzayının sınırlarını belirlediği ve yapay sinir ağlarının yalnızca eğitildiği çalışma aralığı için güvenilir sonuç verebildiği unutulmamalıdır. Genel özelliklerin net olarak belirlenmesi için örnek kümesinin geniş olması tercih edilir. Bu kümenin bir kısmı eğitim aşamasında kullanılırken, bir kısmı test aşamasında ağın genelleştirme yeteneğinin onayı amacıyla kullanılır. Testin başarısızlığı durumunda, test amacıyla kullanılan kayıtların bir kısmı eğitim verilerine aktararak, eğitim ve test işlemleri kabul edilebilir bir performans düzeyine ulaşmaya kadar bu işlem tekrarlanır [71].

Yapay sinir ağları uygulamasının başarısı, uygulanacak olan yaklaşımlar ve deneyimlerle yakından ilgilidir. Uygulamanın başarısında uygun yöntemi belirlemek büyük önem taşır. Yapay sinir ağının geliştirilmesi sürecinde ağın yapısına ve işleyişine ilişkin aşağıdaki kararların verilmesi gerekir:

- Yapay Sinir Ağları Ağ Yapısının Seçimi,
- Öğrenme Algoritmasının Seçimi,
- Ara Katman Sayısının Belirlenmesi,
- Nöron Sayısının Belirlenmesi,
- Normalizasyon,
- Performans Fonksiyonunun Seçimi

Bir yapay sinir ağlarının uygun parametrelerle tasarlanması durumunda yapay sinir ağları sürekli olarak kararlı ve istikrarlı sonuçlar üretecektir. Ayrıca sistemin tepki süresinin yeterince kısa olabilmesi için de ağ büyüklüğünün yeterince küçük olması gerekir. İhtiyaç duyulan toplam hesaplama da bu sayede sağlanmış olacaktır.

Yapay Sinir Ağları Ağ Yapısının Seçimi

Yapay sinir ağlarının tasarımı sürecinde ağ yapısının seçilmesi, uygulama problemine bağlı olarak seçilmelidir. Hangi problem için hangi ağın daha uygun olduğunun bilinmesi önemlidir. Kullanım amacı ve o alanda başarılı olan ağ türleri Çizelge 4.6'da verilmiştir.

Çizelge 4.6 Ağ türleri ve başarılı oldukları alanlar [90]

Kullanım Amacı	Ağ Türü	Ağın Kullanımı
Tahmin	ÇKA	Ağın girdilerinden bir çıktı değerinin tahmin edilmesi.
Sınıflandırma	LVQ ART Counterpropagation Olasılıklı Sinir Ağları	Girdilerin hangi sınıfa ait olduklarının belirlenmesi.
Veri İlişkilendirme	Hopfield Boltzman Makinesi Bidirectional Associative Memory	Girdilerin içindeki hatalı bilgilerin bulunması ve eksik bilgilerin tamamlanması.

Uygun yapay sinir ağları yapısının seçimi, büyük ölçüde ağda kullanılması düşünülen öğrenme algoritmasına da bağlıdır. Ağda kullanılacak öğrenme algoritması seçildiğinde, bu algoritmanın gerektirdiği mimaride zorunlu olarak seçilmiş olacaktır. Örneğin geri yayılım algoritması ileri beslemeli ağ mimarisi gerektirir.

Bir yapay sinir ağlarının karmaşıklığının azaltılmasında en etkin araç, yapay sinir ağları ağ yapısını değiştirmektir. Gereğinden fazla sayıda işlemci eleman içeren ağ yapılarında, daha düşük genelleme kabiliyeti ile karşılaşılır.

Öğrenme Algoritmasının Seçimi

Yapay sinir ağları yapısının seçiminden sonra uygulama başarısını belirleyen en önemli faktör öğrenme algoritmasıdır. Genellikle ağ yapısı öğrenme algoritmasının seçiminde belirleyicidir. Bu nedenle seçilen ağ yapısı üzerinde kullanılabilecek öğrenme algoritmasının seçimi ağ yapısına bağlıdır.

Yapay sinir ağının geliştirilmesinde kullanılacak çok sayıda öğrenme algoritması bulunmaktadır. Bunlar içinde bazı algoritmaların bazı tip uygulamalar için daha uygun olduğu bilinmektedir.

Bu algoritmalar eğer uygun oldukları uygulama alanlarına göre sınıflandırılacak olursa, gruplar ve içinde yer alacak öğrenme algoritmaları Çizelge 4.7'deki gibi özetlenebilir.

Çizelge 4.7 Uygulama tipleri ve kullanılabilir yapay sinir ağları [90]

Uygulama Tipi	Yapay Sinir Ağı
Öngörü Tanıma	Geri yayılım Delta Bar Delta Geliştirilmiş Delta Bar Delta Yönlendirilmiş Rassal Tarama Geri Yayılım İçinde Self Organizing Map Higher Order Neural Networks
Sınıflandırma	Learning Vektor Quantization Counter-Propagation Olasılıklı Yapay Sinir Ağları
Veri İlişkilendirme	Hopfield Boltmann Makinesi Bidirectional Associative Memory Spation-Temproal Pattern Recognition
Veri Kavramlaştırma	Adaptive Resonance Network Self Organizing

Yapay sinir ağları belki de en çok öngörü amacıyla kullanılmaktadır. Öngörü için kullanılan yapay sinir ağları içinde de en yaygın olarak kullanılanı geri yayılım algoritmasıdır. Geri yayılım algoritması ileri beslemeli ve çok katmanlı bir ağ mimarisini gerektirmektedir.

Ara Katman Sayısını Belirleme

Yapay sinir ağlarının tasarımı sürecinde tasarımcının yapması gereken diğer işlemlerde, ağdaki katman sayısına karar vermektir. Çoğu problem için 2 veya 3 katmanlı bir ağ tatmin edici sonuçlar üretebilmektedir. Nöronların aynı doğrultu üzerinde bir araya gelmeleriyle katmanlar oluşmaktadır. Katmanların değişik şekilde bir birleriyle bağlanmaları değişik ağ yapılarını oluşturur. Girdi ve çıktı katmanlarının sayısı, problemin yapısına göre değişir. Katman sayısını belirlemenin en iyi yolu, birkaç deneme yaparak en uygun yapının ve yapının ne olduğuna karar vermektir.

Yapay sinir ağları, özellikle bir girdinin A veya B gibi herhangi bir sınıfa ait olup olmadığı araştırıldığında bu istatistiksel özelliklerini sergileyebilmektedirler. Yapay sinir ağı eşik değerine sahip ve tek katmanlı bir yapı oluşturduğunda, doğrusal olarak ayrılabilen iki sınıflı örnekleme sınıflandırmak için kullanılabilir. İki katmandan oluşan bir ağ ise her bir katman girdi uzayını bir düzlemle böldüğünden, birçok düzlemin oluşturduğu dışbükey acık veya dışbükey kapalı bir girdi uzayını bölümleyebilir. Üç katmanlı bir ağ girdi uzayını dışbükey olmayan ve parçalı bir biçimde bölümleyebilme yeteneği taşır [84].

Nöron Sayısının Belirlenmesi

Ağın yapısal özelliklerinden birisi her bir katmandaki nöron sayısıdır. Katmandaki nöron sayısının tespitinde de genellikle deneme-yanılma yöntemi kullanılır. Bunun için izlenecek yol, başlangıçtaki nöron sayısını istenilen performansa ulaşıncaya kadar arttırmak veya tersi şekilde istenen performansın altına inmeden azaltmaktır. Bir katmanda kullanılacak nöron sayısı olabildiğince az olmalıdır. Nöron sayısının az olması yapay sinir ağının genelleme yeteneğini arttırırken, gereğinden fazla olması ağın verileri ezberlemesine neden olur. Ancak gereğinden az nöron kullanılmasının verilerdeki örüntünün ağ tarafından öğrenilememesi gibi bir sorun yaratabilir [90].

Nörondaki fonksiyonların da karakteristik özellikleri de yapay sinir ağlarının tasarımında önemli kararlardan biridir. Nöronun geçiş fonksiyonunun seçimi büyük ölçüde yapay sinir ağının verilerine ve ağın neyi öğrenmesinin istendiğine bağlıdır. Geçiş fonksiyonları içinde en çok kullanılanı sigmoid ve hiperbolik tanjant fonksiyonlarıdır. Daha önce belirtildiği gibi sigmoid fonksiyonun çıktı aralığı 0 ve 1 arasında olurken, hiperbolik tanjant fonksiyonunun çıktısı -1 ve 1 aralığında oluşmaktadır. Eğer ağın bir modelin ortalama davranışını öğrenmesi isteniyorsa sigmoid fonksiyon, eğer ortalamadan sapmanın öğrenilmesi isteniyorsa hiperbolik tanjant fonksiyon kullanılması önerilmektedir [103].

Normalizasyon

Yapay sinir ağlarının en belirgin özelliklerinden olan doğrusal olmama özelliğini anlamlı kılan yaklaşım, verilerin bir normalizasyona tabi tutulmasıdır. Verilen normalizasyonu için seçilen yöntem yapay sinir ağları performansını doğrudan etkileyecektir. Çünkü normalizasyon, giriş verilerinin transfer edilirken fonksiyonun aktif olan bölgesinden aktarılmasını sağlar. Veri normalizasyonu, işlemci elemanlarını verileri kümülatif toplamların oluşturacağı olumsuzlukların engellenmesini sağlar. Veri normalizasyonu, işlemci elemanlarını verileri kümülatif toplamlarla koruma eğilimleri nedeniyle zorunludur ve aşırı değerlendirilmiş kümülatif toplamların oluşturacağı olumsuzlukların engellenmesini sağlar. Genellikle verilerin $[0,1]$ veya $[-1,+1]$ aralıklarından birine ölçeklendirilmesi önerilmektedir. Ölçekleme verilerin geçerli eksen sisteminde sıkıştırılması anlamı taşıdığından veri kalitesi aşırı salınımlar içeren problemlerin yapay sinir ağları modellerini olumsuz yönde etkileyebilir. Bu olumsuzluk, kullanılacak öğrenme fonksiyonunu da başarısız kılabilir.

Veri kümesinin $[0,1]$ arasında bir ölçeklendirmeye tabi tutulabilmesi için o kümenin $X_{\min}$ - $X_{\max}$ aralığı bulunur ve aşağıdaki formüle göre ölçeklendirme yapılabilir.

$$x_{yeni} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4.38)$$

Performans Fonksiyonunun Seçimi

Öğrenme performansını etkileyen önemli hususlardan bir de performans fonksiyonudur. İleri beslemeli ağlarda kullanılan tipik performans fonksiyonu hata kareleri ortalamasıdır (Mean Square Error).

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_{tahmin}(i) - x_{gercek}(i))^2 \quad (4.39)$$


Yapay sinir ağlarının eğitiminde, genel olarak aşağıdaki adımlar izlenmektedir [91], [104]:

- Sistemin ihtiyaç duyduğu girdi parametreleri tanımlanır. Bu parametreler operasyonel parametreleri içermelidir.
- Güvenilirlik, kullanılabilirlik, dayanıklılık gibi faktörler açısından sistem performansını ölçebilecek çıktı parametreleri tanımlanmalıdır.
- Bu parametreler, sistem çıktısının basit bir ölçümü içinde birleştirilmelidir.
- Girdi ve çıktı çiftlerinden çok sayıda eğitim ve sağlama veri grubu hazırlanmalıdır.
- Gizli katman sayısı ve gizli hücrelerin sayısının doğru olarak belirlenmesi deneme yanılma yoluyla gerçekleştirildiği için öncelikle bir gizli katman ve birkaç gizli hücre ile başlanmalı ve daha sonra bu sayı optimum sonuca ulaşmaya kadar artırılmalıdır.
- Eğitilen ve sağlama yapılan yapay sinir ağları modelinin farklı koşullarda davranışlarını belirlemek için sinir ağı modelinin simülasyonu yapılmalıdır.
- Optimal bir sonuç elde edebilmek için yukarıdaki adımlar yerine getirildikten sonra eğer elde edilen sonuçlar beklendiği gibi değilse, yukarıdaki adımlar tekrar edilerek en iyi sonuç elde edilinceye kadar tekrarlanmalıdır.

Sinir ağlarının eğitilmesi sürecinde, bazen ağın takıldığı hata düzeyinin istenen sınırların üstünde kaldığı durumlarda, ağın olayı öğrenme sürecinde bazı değişiklikler yapılarak ağın yeniden eğitilmesi gerekebilir. Bu gibi durumlarda süreçte yapılabilecek başlıca değişiklikler şunlardır [1]:

- Başka eğitim başlangıç değerleri kullanılabilir.
- Ara katman sayısını değiştirmek, işlemci eleman sayısını değiştirmek gibi, sinir ağı topolojisiinde değişiklikler yapılabilir.
- Öğrenme ve momentum katsayılarının değiştirilmesi gibi, parametre değişiklikleri yapılabilir.
- Problemin sunum şekli ve örnekler değiştirilerek yeni örnek seti oluşturulabilir,
- Öğrenme setindeki örneklerin sayısı artırılabilir veya azaltılabilir.

Şekil 4.16'da ileri beslemeli bir sinir ağının eğitim ve test aşamalarına ait akış diyagramı gösterilmiştir.




Şekil 4.16 İleri beslemeli bir sinir ağının eğitim ve test aşamaları [104]

Yukarıda Şekil 4.16'da yapay sinir ağlarının eğitim sürecinde yapılan işlemler ve eğitimin tamamlanan sinir ağının hata düzeyinin kabul edilebilir sınırlar içerisinde olup olmadığının test edilmesi işlemleri gösterilmiştir.

Sinir ağlarının eğitilmesi esnasında karşılaşılan önemli sorunlardan birisi de, öğrenme süresinin çok uzun olmasıdır. Ağırlık değerlerinin başlangıçta büyük olması, ağın lokal sonuçlara düşmesi ve bir lokal sonuçtan diğerine sıçraması naneden olmaktadır. Eğer işlemci elemanların ağırlıkları küçük aralıklarda seçilirse o zaman da ağırlıkların doğru değerleri bulması uzun zamanlar almaktadır. Bazı problemlerin çözümü sadece 200 iterasyon sürerken bazıları 5-10 milyon iterasyon gerektirmektedir. Başlama koşullarının tamamen deneme yanılma yolu ile belirlenmesi ve en uygun başlama koşullarının böylelikle bulunması gerekmektedir [90].


Aşağıda Şekil 4.17’de sinir ağının eğitiminin tamamlanması ve hata düzeyinin istenen düzeye indirilmesi için işlemci elemanın ağırlık değerinde yapılacak değişim sayısı (iterasyon) ilişkisini gösteren grafik gösterilmiştir.



Şekil 4.17 Yapay sinir ağlarının öğrenme eğrisi [90]


Şekil 4.17’de görüldüğü gibi, iterasyon sayısı arttıkça ağın öğrenmesi de artmakta ve bu öğrenme zamanıyla birlikte hata oranı da düşmektedir. Ancak, grafikte görüldüğü gibi, iterasyon sayısı belli bir düzeye ulaştıktan sonra hata oranında artık daha fazla azalma olmadığı görülmektedir. Bu durum, ağın eğitiminin tamamlandığını, öğrenmenin artık durduğunu ve bundan daha iyi sonuca ulaşamayacağını göstermektedir.

Şekil 4.18’de öğrenmenin hata uzayındaki gösterimi ifade edilmiştir. Ağa gösterilen girdinin beklenen çıktıyı üretmesi için ağa başlangıç ağırlık değerleri rastgele verilmekte ve ağ, zaman içinde öğrenerek ağırlıkları belirlemektedir. İstenen ağırlıklar bilinmemekle beraber hatanın en az olması istenmektedir. Ağın öğrenmesi, istenen olayın bir hata uzayının olduğu varsayılırsa, W^* en az hatanın olduğu ağırlık vektörünü göstermektedir.



Şekil 4.18 Öğrenmenin hata uzayındaki gösterimi [90]

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



Şekil 4.19 Çok boyutlu hata uzayı [90]

Şekil 4.19'da daha karmaşık bir problem uzayı gösterilmektedir. W^* en iyi çözüm olmasına rağmen bu değeri yakalamak mümkün olmayabilmektedir. Ağ, eğitim sırasında kendisi bu çözümü yakalamaya çalışmaktadır.

Bazen ise farklı bir çözüme takılabilmekte ve performansı daha iyileştirmek mümkün olamamaktadır. Bu nedenle kullanıcılar belirli bir tolerans değerine kadar hatayı kabul etmektedirler. Tolerans değerindeki noktalardaki çözümler için ağ öğrenmiş kabul edilmektedir. Şekil 4.19'da görülen noktalardan W_0 ve W_2 tolerans değerinin üzerindedir, dolayısıyla bu çözümler kabul edilememektedir. Bunlara *yerel çözümler*

denilmektedir. W_1 ve W_3 çözümleri ise en iyi çözüm olmamalarına rağmen tolerans değerinin altında bir hataya sahiptirler ve kabul edilebilir yerel çözümlerdir.

Yapay sinir ağlarında birden fazla çözüm olabilir ve en iyi çözümün hangisi olduğunu bilmek çoğu zaman mümkün olmamaktadır. Bu nedenle yapay sinir ağlarının en iyi çözümü bulduğu iddia edilemez. En iyi çözüm bulamamanın sebepleri aşağıdakilerden birisi gibi olabilir:

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


Bazı durumlarda da ağın takıldığı yerel çözüm tolerans değerinin üstünde kalmaktadır. Bu durumda ağın olayı öğrenmesi için bazı değişiklikler yapılarak yeniden eğitilmesi gerekmektedir. Başlıca yapılabilecek değişiklikler aşağıdaki şekilde sıralanmaktadır:

- Başka başlangıç değerlerinin kullanılması
- Topolojide değişiklikler yapılması (ara katman sayısını artırmak, proses elemanı sayısını artırmak veya azaltmak gibi)
- Parametrelerde değişiklik yapılması (fonksiyonların başka seçilmesi, öğrenme ve momentimi katsayılarının değiştirilmesi gibi)
- Problemin gösterimi ve örneklerin formülasyonu değiştirilerek yeni örnek seti oluşturulması
- Öğrenme setindeki örneklerin sayısının artırılması veya azaltılması
- Öğrenme sürecinde örneklerin ağa gösterilmesidir [90].

Eğitim süreci sonucunda yapay sinir ağında hesaplanan hatanın kabul edilebilir bir hata oranına inmesi beklenir. Ancak hata kareleri ortalamasının düşmesi her zaman için yapay sinir ağının genellemeye ulaştığını göstermez. Yapay sinir ağının gerçek amacı girdi-çıkı örnekleri için genellemeye ulaşmaktır.

Genelleme, yapay sinir ağının eğitimde kullanılmamış ancak aynı evrenden gelen girdi-çıkı örneklerini ağın doğru bir şekilde sınıflandırabilme yeteneğidir. İstatistiksel açıdan genelleme bir uygun eğrinin bulunması veya doğrusal olmayan ara değer atama işi olarak görülebilir. Ancak ağ gereğinden fazla girdi-çıkı ilişkisini öğrendiğinde, ağ verileri ezberlemektedir. Bu durum genellikle gereğinden fazla gizli katman kullanıldığında verilerin sinaptik bağlantılar üzerinde saklanmasıyla veya gereğinden

fazla veri kullanılarak eğitilmesinden kaynaklanmaktadır. Ezberleme, genellemenin iyi gerçekleşmediğini ve girdi-çıkı eğrisinin düzgün olmadığını gösterir. Verilerin ezberlenmiş olması yapay sinir ağı için istenmeyen bir durum olup, verileri ezberleyen ağı ait eğitim hatası oldukça düşme, test verilerinde ise hata artma eğilimi gösterir. Bundan dolayı birçok yapay sinir ağı yazılımı ağı eğitim ve test verilerine ait hataları grafik olarak göstermektedir. Verileri ezberleyen ağ gerçek hayattaki örüntüyü iyi temsil edemeyeceği için kullanılamaz. Şekil 4.20’de a şeklinde ağ verileri ezberlediği için eğitim hatası azalma, test hatası ise artma eğilimi göstermektedir. Şekil 4.20’de b şeklinde ise ağ kabul edilebilir bir genellemeye ulaşmıştır.



Şekil 4.20 Verileri ezberleyen ve iyi genellemeye ulaşan ağlardaki hata eğrileri [1]

4.10 Tahminin Hata Testi

Tahmin modellerinin başarısının izlenmesi ve denetlenmesinde hata testleri oldukça önemli bir yere sahiptir. Tahmin yöntemlerinin etkinliğini ölçmemizi sağlayan hata testleri, tahmin edilen talep ile gerçekleşen talep arasındaki farkı ölçmektedirler.

Hata nedenlerini, tesadüfi ve tesadüfi olmayan nedenler olmak üzere iki grupta incelemek mümkündür. Doğru değişkenlerin seçilmemesi, değişkenler arasında yanlış ilişkiler kurulması, hatalı eğilimler belirlenmesi, mevsimsel etkilerin göz ardı edilmesi gibi nedenler tesadüfi olmadığından, hataya süreklilik kazandırır. Diğer taraftan, kullanılan tahmin modeli tarafından açıklanmayan hatalar ise tesadüfi hatalar olarak kabul edilirler [68].

Tahmin yöntemlerinin en sık kullanılan hata ölçülerinden birisi, ortalama mutlak sapmadır. Ortalama mutlak sapma aşağıdaki şekilde formüle edilmiştir.

$$\text{Ortalama mutlak sapma} = \frac{\sum_{i=1}^n |\text{Tahmin hatası}|}{n} \quad (4.40)$$

$$\text{Ortalama mutlak sapma} = \frac{\sum_{i=1}^n |\text{Gerçekleşen talep} - \text{Tahmini talep}|}{n} \quad (4.41)$$

Ortalama mutlak hata denklemi kullanılarak o güne kadarki tahmin hatası hesaplanır. Ancak tahminde tam başarı sağlayabilmek ve tahmin hatasını sifıra yaklaştırmak için mutlak değer yerine, hata kareleri ortalaması hesaplanarak daha hassas ölçümler yapmak mümkündür. Bunun için aşağıdaki denklemden yararlanılmaktadır.

$$\text{Hata Kareleri Ortalaması} = \frac{\sum_{i=1}^n (\text{Gerçekleşen talep} - \text{Tahmini talep})^2}{N} \quad (4.42)$$

Gerçekleşen talep azalıyor veya artıyor olabilir. Dolayısıyla bu ölçülerden başka, tahmin ortalamasının, talepte meydana gelen değişikliklere ayak uydurup uydurmadığını belirlemek üzere izleme sinyali kullanılmaktadır. İzleme sinyali, aşağıdaki gibi birikimli sapmanın, ortalama mutlak sapmaya bölünmesiyle elde edilmektedir.


$$\text{İzleme sinyali} = \frac{\sum_{i=1}^n (\text{Gerçekleşen talep} - \text{Tahmini talep})^2}{\text{Ortalama mutlak sapma}} \quad (4.43)$$

İzleme sinyalleri, bir tahminin gerçek değerlere ne kadar yaklaştığını izlemenin bir yoludur. Bu sinyaller, birikimli sapmayı (tahmin hatasının süregelen toplamı) ortalama sapma sayısı cinsinden gösterirler. İzleme sinyallerine ilişkin sınırlar genellikle üç ile sekiz arasında değişir. İzleme sinyalinin bu sınırların ötesine geçmesi durumunda düzeltici hareket gerekebilir [70].

Tahmin hatalarını izlemenin diğer bir yolu kontrol şemalarıdır. Tahmini veya ortalama değer karşısında, gerçekleşen değerlerin gösterdiği değişkenlikler, tahminin standart sapması SF olarak sayısallaştırılır.

$$S_F = \sqrt{\frac{\sum (\text{Gerçekleşen} - \text{Tahmin})^2}{n-1}} \quad (4.44)$$

Aşağıda Şekil 4.21’de, tahmin çalışmalarının hata testlerinde kullanılan alt ve üst kontrol noktalarını gösteren grafik gösterilmektedir.



Şekil 4.21 Tahminler için kontrol sınırları [70]

Şekil 4.21’de görüldüğü gibi, yapılan bir tahmin çalışmasının geçerli ve güvenilir olması için belirlenen sınırlar içerisinde olması gerekmektedir. Bu sınırların altında veya üstünde çıkan tahmin değerleri geçerli olmayacağından, veriler tekrar gözden geçirilerek, tahminin yenilenmesi gerekir.

Yapay sinir ağlarının yapısı ve insanlardaki sezgi yeteneğini anlayabilme ve taklit edebilme özelliği ile ilgili ayrıntılı açıklamalardan da anlaşılacağı üzere; günümüzde işletmeler karar süreçlerinin neredeyse tamamında hayati önem arz eden talep tahmini çalışmalarında yapay sinir ağları metodunu kullanmaktadırlar.

Yapay sinir ağlarının, incelemesi yapılan çalışmalarının neredeyse tümünde, hata ve tahmin tutarlılığı yönünden oldukça yüksek performans sergilediği görülmüştür. Buna ilaveten, yapılan bu çalışmada olduğu gibi, literatür örneklerinin birçoğunda yapay sinir ağları metodu, geleneksel metotlarla talep tahmin performansı yönünden de karşılaştırılmıştır. Yapay sinir ağları bu sonuçlara göre, talep tahmini performansı yönünden de, diğer metotlardan çoğunlukla daha yüksek performans sergilemiştir. Yapılan bu çalışmada da yapay sinir ağları lehine sonuçlar elde edilmiştir.

Bu bağlamda, çalışmanın Beşinci Bölümü’nde gıda sektöründe faaliyet gösteren bir firmada yapılan talep tahmini uygulamasında, yapay sinir ağları metodunun kullanılmasına karar verilmiştir.

YAPAY SİNİR AĞLARI KULLANILARAK ÜRÜN TALEP TAHMİNİ UYGULAMASI

5.1 Uygulamada Ele Alınan Şarküteri Ürünleri

Taze gıda sektörlerinin başında gelen et sektöründe faaliyet gösteren firmada yapılan uygulamada marka değeri diğer ürün gruplarına göre daha belirgin ve yüksek olan şarküteri ürün grupları ele alınmıştır.

Şarküteri (charcuterie) kelimesi Fransızca kökenli bir kelime olup, peynir, zeytin gibi kahvaltılık ürünlerin ve et grubu (sucuk, salam, sosis, jambon, pastırma, kavurma vb.) ürünlerin satıldığı dükkan ya da bölüm anlamına gelmektedir.

Şarküteri sanayisi son yıllarda ülkemizde büyük yer tutmaya başlayan bir besin sanayisidir. Kırmızı et veya beyaz et kullanılarak hazırlanan ürün sayısı çok sınırlıdır. Şarküteri ürünleri ya büyüklüğü değişken sanayi işletmelerinde ya da çoğu küçük imalathanelerde hazırlanır. Bu imalathaneler, kendi ürünlerinin ve başka besin maddelerinin perakende satışını kendileri yaparlar. Esas şarküteri etkinliği, bu imalathanelerde genellikle bir soğuk ve hazır yemek satıcısının etkinliğiyle tamamlanır. Şarküteri ürünlerindeki yağ miktarı genellikle oldukça yüksektir (%20-30 ya da daha fazla). Bu ürünler, içerdikleri hammaddeler ile ve katkı maddelerinin içeriği bakımından çok sıkı kurallara bağlanmıştır.

Gelişen ve değişen dünyada insanoğlunun önemli ve değişmez sorunlarının başında yetersiz ve dengesiz beslenme problemleri gelmektedir. Dünya Sağlık Örgütü verilerine göre sağlıklı bir insanın vücut ağırlığının her kilogramı için günde 1 gr protein tüketmesi ve bunun da %42'sinin hayvansal kökenli olması gerekmektedir. Ancak,

lkemizde tketilen gnlk protein miktarının %73 bitkisel kkenli gıda maddelerinden karılanmaktadır. Dnyada kii baına ortalama gnlk protein tketimi 79 gr olup, bunun 31 grlık kısmı hayvansal kaynaklı proteinlerden karılanmaktadır. Proteinlerin hayvansal rnlerden karılanma oranları gelimekte olan lkelerde %20lerde iken gelimi lkelerde %65lere kadar ıkmaktadır. Trkiye kırmızı et ve kanatlı eti retimi 2013 yılında 2012 yılına gre %3,7 artarak yaklaık 2,8 milyon tona ulamıtır. Kii baı yıllık et tketimleri ise 13,01 kg kırmızı et ve 21 kg beyaz et olmak zere 34,01 kga ykselmitir [108].


Son yıllarda arkteri grubu rnler belirtilen tketim rakamları ierisindeki payını arttırmıtır. arkteri grubu rnleri, sucuk, salam, sosis, jambon, pastırma ve kavurma rn grupları oluturmaktadır. Belirtilen bu rn grupları ierisinde markalı ve markasız tm mamulleri gz nnde bulundurarak, Trkiyede tketilen toplam arkteri rn miktarının yıllık yaklaık 100 bin ton olduėunu syleyebiliriz. Bu miktarın yzde 50sini sucuk, kalanını ise sırasıyla salam, sosis ve pastırma gibi mamuller oluturmaktadır [108].

arkteri rnlerine artan talep doėrultusunda yapılacak talep tahmini iin ncelikle bu rn grubu ierinden talebi tahmin edilecek olan grubun belirlenmesine karar verilmitir.

5.2 ABC Analizi ile rn Grubu Seimi

Wilfredo Paretonun aratırmaları sonucu ortaya ıkan Pareto (ABC) Analizi toplumsal gelirin bireyler arasında eit daėılmadıėını gstermitir. Paretoya gre milli sermayelerin %80i, %20lik kesimin elinde, geri kalan %20si ise toplumun %80lik kesiminin elindedir.

Paretonun bu basit ıkarımı endstri mhendisliėi iin devrim niteliėinde uygulamalara yol amıtır. Pareto analizi ile iletme kaynakları, elde tutulan stoklar ya da satıı arttırılacak rnler nem derecelerine gre sınıflandırılabilmi ve analiz dnemleri ierisinde daha doėru karar almak kolaylamıtır. Pareto (ABC) analizi, olduka kolay ve anlaılır bir karar verme tekniėidir. ekil 5.1de ABC analizi yapıldıėı zaman ortaya ıkacak grafik gsterilmektedir.




Şekil 5.1 ABC analizi grafik örneği

Yapılan ABC analizi ile, ele alınan şarküteri grubu ürünlerin yıllık satış miktarları ve satış fiyatları çarpılarak toplam kazanç elde edilmiş ve buna göre ürün grupları arasındaki önem sırası oluşturulmuştur. Ancak firmanın gizlilik politikası gereği ürün başına tek tek satış miktarları ve satış fiyatları paylaşılamamaktadır. Bu nedenle yapılan ABC analizine ait özet tablo aşağıda Çizelge 5.1’de gösterilmektedir.

Çizelge 5.1 ABC analizi özet tablosu [109]

Ürün Grubu	Ürün Adı	Toplam Miktar*Satış Fiyatı	Yüzde	Kümülatif Yüzde	Sınıfı
1	SUCUK GRUBU GENEL TOPLAMI	76.673.964,43	39%	39%	A
3	SOSİS GRUBU GENEL TOPLAMI	63.646.868,03	33%	72%	A
2	SALAM GRUBU GENEL TOPLAMI	30.116.990,95	15%	87%	B
4	PASTIRMA GRUBU GENEL TOPLAMI	14.687.903,30	8%	95%	B
5	JAMBON GRUBU GENEL TOPLAMI	5.859.551,90	3%	98%	C
6	KAVURMA GRUBU GENEL TOPLAMI	4.070.431,80	2%	100%	C

Yapılan ABC analizi sonucunda Şekil 5.2’deki grafik elde edilmiştir.



Şekil 5.2 ABC analizi grafiği

Sucuk, salam, sosis, jambon, pastırma ve kavurma olmak üzere firmanın üretim yaptığı 6 ürün grubu bulunmaktadır. Firmaya en çok kazanç getiren ürün grubunu bulmak için ABC analizi yapılmıştır. Son iki yılda bütün ürün gruplarında üretim ve dolayısıyla satış yapıldığı için, ABC analizinde son iki yılın satış ve ortalama fiyat verileri kullanılmıştır. Satış fiyatları her bir ürün için ayrı ayrı hesaplanmıştır; ancak firma gizlilik gereği satış fiyatlarını ayrı ayrı paylaşmamaktadır.

Yapılan ABC analizi sonucunda en çok satış yapılan ürün grubu sucuk grubu olduğu belirlenmiştir. Ortalama fiyat bazında en yüksek miktar olmasa da, satış miktarı fazlalığı sebebiyle en çok kar getiren grup olan sucuk grubu olmuştur. Sucuk grubunu kendi içinde incelendiğinde en çok kar getiren ürün ve aynı üretim prosesine sahip 5 ürün talep tahmininde kullanılmak üzere seçilmiştir.

5.3 Yapay Sinir Ağları ile Yöntemiyle Sucuk Grubu Ürün Talep Tahmini Uygulaması


5.3.1 Tahmin Sürecinin Tasarımı

Zaman serileri ile tahmin yapabilmek için bilinen ve en yaygın kullanılan istatistiksel tahmin yöntemleri Box-Jenkins tahmin yöntemleridir. Box-Jenkins metodolojisi; kesikli, doğrusal stokastik süreçlere dayanmaktadır. Ancak gerçek hayata ilişkin seriler genellikle doğrusal olmamaktadır. Bu nedenle doğrusal olmayan zaman serilerini modellemede farklı tekniklere ihtiyaç duyulmaktadır. 1980’li yılların sonlarından

itibaren zaman serileri tahminlerinde kullanılmakta olan en önemli yöntemlerden birisi de yapay sinir ağıdır. Yapay sinir ağı, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye ve varsayıma ihtiyaç duymadan gerekli modellemeyi sağlayabilmektedir [46].

Bu sebeple çalışmada tahmin aracı olarak diğerlerine göre daha avantajlı ve başarılı sonuçlar üretebilen yapay sinir ağı yöntemi tercih edilmiştir.

Yapay sinir ağıyla yapılan talep tahmini uygulama sürecinde, yapılacak işlemleri aşamalar halinde, Şekil 5.3'te görüldüğü gibi bir akış şeması ile özetlenmiştir.



Şekil 5.3 Yapay sinir ağları talep tahmini süreci akış şeması

Yukarıda Şekil 5.3'teyapay sinir ağlarıyla talep tahmini uygulamasının, veri toplanmasından başlanarak tasarım, öğrenme, test ve genelleştirme aşamaları akış şeması şeklinde gösterilmiştir.

Bu kısımda, uygulamada kullanılan sucuk grubu ürün talebi üzerinde etkisi olduğu şirketin planlama ve satış yöneticilerinin görüşü alınarak tespit edilen bağımsız (açıklayıcı) değişkenler belirlenmiş ve bu değişkenlerle ilgili veriler toplanmıştır. Sonra, çalışmada kullanılan yapay sinir ağları modeli tanıtılmış ve gelecek bir dönem için sucuk grubu seçilen ürünler için aylık talep miktarlarını tahmin etmek üzere bir yapay sinir ağı modeli tasarlanmıştır.

Daha sonra, yapay sinir ağları modelinin tahmin gücünü (performansını) tespit etmek amacıyla hata analizleri yapılmış ve modelden elde edilen sonuçların yorumlamaları yapılmıştır.

Taze gıda üretim sektöründe karşılaşılan en büyük sorun talebin düzenli bir seyir göstermeyişidir. Bu nedenle firma, üretim planını haftalık olarak yapma kararı almış olup, belirlenen ürün grubundan haftalık ne kadar ürün üretmesi gerektiğini tespit etmek istemektedir. Bu nedenle öncelikle üretilmesi gereken talep miktarlarının tahmini istenmektedir.

5.3.2 Veri Setinin Hazırlaması

Planlama ve satış yöneticilerinin görüşleri doğrultusunda belirlenen ürün grubuna olan talebi etkileyecek çok sayıda faktör olduğu belirlenmiştir. Ancak bu verilerin tamamı için aylık veri elde edilemeyeceği için, aylık veri elde edilebilecek dört sayısal faktör belirlenmiştir. Bu dört faktörün gerçekten de talebi etkileyip etkilemediği konusunda yapay sinir ağları modeli ile ön bir çalışma yapılmış ve bu ön çalışma sonrasında, dört faktörün talebi etkilediği sonucuna varılmış ve talep tahmini hesaplamalarında kullanılmasına karar verilmiştir.

Uygulamada kullanılmasına karar verilen, sucuk ürün grubu talebi üzerine etkisi olduğu belirlenen bağımsız değişkenler şunlardır:

- Satış fiyatı (aylık satış fiyat ortalaması)
- Rakip firma sayısı (pazarda bulunan rakip firma sayısı)
- Müşteri sayısı (aylık satış yapılan müşteri sayısı)
- Aylar (mevsimsel etkiler)
- Özel günler (yarı yıl başlangıcı, tatil sezonu, ramazan, yılbaşı, okul sezonu başlangıcı, özel olmayan tarihler)

Uygulamanın bağımlı değişkeni, yani hedeflenen değer ise aylık sucuk grubu talep miktarları olarak belirlenmiştir.

Uygulamada kullanılan bu verilerin tamamı, firmada kullanılan NETSIS ERP programından elde edilmiştir; ancak firmanın gizlilik politikası gereği net değerler paylaşılamamaktadır. Elde edilen veriler gerçeğe yakın değerler olarak aktarılmış olup, buna göre hesaplamalar yapılmıştır. Düzenlenen bu veriler daha sonra MS Excel programına aktarılarak gerekli grafik ve tablolar hazırlanmıştır.

- Aylık Satış Miktarı Verileri

Aylık satış miktarı verileri, 5 ürün içinde Çizelge 5.2’de gösterilmiştir.

Çizelge 5.2 Aylık satış miktarı verileri

SATIŞ VERİLERİ (KG)		ÜRÜN GRUBU				
YILLAR	AYLAR	1	2	3	4	5
2010	OCAK	30158	-	-	-	-
	ŞUBAT	29630	-	-	-	-
	MART	36457	-	-	-	-
	NİSAN	51260	-	-	-	-
	MAYIS	34862	-	-	-	-
	HAZİRAN	40251	-	-	-	-
	TEMMUZ	44320	-	-	-	-
	AĞUSTOS	49965	-	-	-	-
	EYLÜL	60120	-	-	-	-
	EKİM	85779	-	-	-	-
	KASIM	73542	-	-	-	-
	ARALIK	79265	-	-	-	-
2011	OCAK	39711	12147	11211	1211	120
	ŞUBAT	36673	10309	4231	2231	1125
	MART	60925	17210	10872	5087	1520
	NİSAN	66880	17126	8772	3444	2068
	MAYIS	56140	13933	7658	5836	2426
	HAZİRAN	48498	11165	9200	7199	4488
	TEMMUZ	72306	18591	8510	10349	4802
	AĞUSTOS	72140	19770	7456	9444	4930
	EYLÜL	65567	16056	7380	11677	2298
	EKİM	74011	18045	8118	10081	5317
	KASIM	52252	14642	7651	10512	3376
	ARALIK	70686	17545	7720	17391	9875

Çizelge 5.2 Aylık satış miktarı verileri (devamı)

2012	OCAK	92917	23492	8270	7020	459
	ŞUBAT	114226	26520	7880	12416	3191
	MART	92378	22848	6210	13535	4860
	NİSAN	50662	12942	5623	9507	3255
	MAYIS	67803	17119	7104	6215	2801
	HAZİRAN	53193	11925	8889	6899	3453
	TEMMUZ	82247	18938	10062	10673	3202
	AĞUSTOS	70983	17432	16009	13352	7135
	EYLÜL	72805	15176	11963	6531	2073
	EKİM	89375	18317	10239	9352	4199
	KASIM	56799	15557	14520	11312	2556
	ARALIK	69390	14819	16241	28592	10787
2013	OCAK	68276	15422	16478	5267	2295
	ŞUBAT	74346	17991	14088	9132	4327
	MART	81106	19721	14571	2324	820
	NİSAN	69750	20959	9643	10770	5296
	MAYIS	68713	17616	15481	10889	5844
	HAZİRAN	69352	19322	9721	4604	2713
	TEMMUZ	68108	18008	10008	32170	10388
	AĞUSTOS	48237	13243	12774	1364	1485
	EYLÜL	43913	18199	16312	10891	8521
	EKİM	39698	16799	15321	14010	7884
	KASIM	39937	13544	14114	13170	9037
	ARALIK	44849	16146	16624	15451	11163

Çizelge 5.2 ve devamında, incelenen ürün grubuna ait 2010-2013 yılları arası aylık satış verileri kilogram biriminde gösterilmektedir. Birinci ürün grubu haricindeki diğer grup ürünler 2011 yılından itibaren üretilmeye ve dolayısıyla satılmaya başlanmıştır.

- Aylık Ortalama Satış Fiyatı Verileri

Ürünler için aylık ortalama satış fiyatı verileri TL biriminden Çizelge 5.3'te gösterilmektedir. Belirtilen fiyatlar, firmadaki gizlilik politikası nedeniyle belirli bir ortalama değer olarak verilmiştir.

Çizelge 5.3 Aylık ortalama satış fiyatı verileri

SATIŞ FİYATI (TL)		ÜRÜN GRUBU				
YILLAR	AYLAR	1.	2.	3.	4.	5.
2010	OCAK	21,5	-	-	-	-
	ŞUBAT	21,5	-	-	-	-
	MART	23	-	-	-	-
	NİSAN	23	-	-	-	-
	MAYIS	23	-	-	-	-
	HAZİRAN	23	-	-	-	-
	TEMMUZ	23	-	-	-	-
	AĞUSTOS	23	-	-	-	-
	EYLÜL	23	-	-	-	-
	EKİM	23	-	-	-	-
	KASIM	23	-	-	-	-
	ARALIK	23	-	-	-	-
2011	OCAK	23	21,5	20	18,4	23,5
	ŞUBAT	23	21,5	20	18,4	23,5
	MART	24,5	23	21,5	18,4	24,9
	NİSAN	24,5	23	21,5	18,4	24,9
	MAYIS	24,5	23	21,5	18,4	24,9
	HAZİRAN	24,5	23	22	19,6	24,9
	TEMMUZ	24,5	23	22	19,6	24,9
	AĞUSTOS	24,5	23	22,5	19,6	24,9
	EYLÜL	24,5	23	22,5	19,6	24,9
	EKİM	24,5	23	22,5	19,6	24,9
	KASIM	24,5	23	23	19,6	24,9
	ARALIK	24,5	23	23	19,6	24,9
2012	OCAK	24,5	23	23	24	24,9
	ŞUBAT	24,5	23	23	24	24,9
	MART	26	24,5	23,5	24	26,1
	NİSAN	26	24,5	23,5	24	26,1
	MAYIS	26	24,5	23,5	24	26,1
	HAZİRAN	26	24,5	24	24	26,1
	TEMMUZ	26	24,5	24	26	26,1
	AĞUSTOS	26	24,5	24	26	26,1
	EYLÜL	26	24,5	24,5	26	26,1
	EKİM	26	24,5	24,5	26	26,1
	KASIM	26	24,5	24,5	26	26,1
	ARALIK	26	24,5	25	26	26,1

Çizelge 5.3 Aylık ortalama satış fiyatı verileri (devamı)

2013	OCAK	26	24,5	25	26,5	26,1
	ŞUBAT	26	24,5	25	26,5	26,1
	MART	27,5	26,5	25	26,5	27,5
	NİSAN	27,5	26,5	25	26,5	27,5
	MAYIS	27,5	26,5	25	26,5	27,5
	HAZİRAN	27,5	26,5	26,5	26,5	27,5
	TEMMUZ	27,5	26,5	26,5	26,5	27,5
	AĞUSTOS	27,5	26,5	26,5	26,5	27,5
	EYLÜL	27,5	26,5	27	26,5	27,5
	EKİM	27,5	26,5	27	26,5	27,5
	KASIM	27,5	26,5	27	26,5	27,5
	ARALIK	27,5	26,5	27	26,5	27,5

- Rakip Firma Sayısı Verileri

Aylık olarak pazarda yer alan rakip firma sayısı verileri Çizelge 5.4’te gösterilmiştir. Rakip firma sayısı verileri, firmada kullanılan ERP programı NETSİS’ten elde edilmiştir.

Çizelge 5.4 Rakip firma sayısı

RAKİP FİRMA SAYISI		ÜRÜN GRUBU				
YILLAR	AYLAR	1	2	3	4	5
2010	OCAK	8	-	-	-	-
	ŞUBAT	8	-	-	-	-
	MART	8	-	-	-	-
	NİSAN	8	-	-	-	-
	MAYIS	8	-	-	-	-
	HAZİRAN	8	-	-	-	-
	TEMMUZ	8	-	-	-	-
	AĞUSTOS	8	-	-	-	-
	EYLÜL	8	-	-	-	-
	EKİM	8	-	-	-	-
	KASIM	8	-	-	-	-
	ARALIK	8	-	-	-	-

Çizelge 5.4 Rakip firma sayısı (devamı)

2011	OCAK	8	8	5	2	2
	ŞUBAT	8	8	5	2	2
	MART	8	8	5	2	2
	NİSAN	9	8	4	2	2
	MAYIS	9	8	4	2	2
	HAZİRAN	9	8	4	2	2
	TEMMUZ	9	8	5	2	2
	AĞUSTOS	9	8	5	2	2
	EYLÜL	9	8	5	2	2
	EKİM	9	8	5	2	2
	KASIM	9	9	5	2	2
	ARALIK	9	9	5	2	2
2012	OCAK	9	9	4	1	1
	ŞUBAT	9	9	4	1	1
	MART	10	9	5	1	1
	NİSAN	10	9	5	1	1
	MAYIS	10	10	5	1	1
	HAZİRAN	10	10	5	1	1
	TEMMUZ	10	10	4	1	1
	AĞUSTOS	10	10	4	1	1
	EYLÜL	11	10	4	1	1
	EKİM	11	11	4	1	1
	KASIM	11	11	4	1	1
	ARALIK	11	11	4	1	1
2013	OCAK	11	11	4	0	0
	ŞUBAT	12	11	4	0	0
	MART	12	11	4	0	0
	NİSAN	12	12	4	0	0
	MAYIS	12	12	4	0	0
	HAZİRAN	12	12	5	0	0
	TEMMUZ	12	12	5	0	0
	AĞUSTOS	11	12	4	0	0
	EYLÜL	11	11	4	0	0
	EKİM	11	11	4	0	0
	KASIM	12	11	4	0	0
	ARALIK	12	11	4	0	0

- Aylık Satış Yapılan Müşteri Sayısı Verileri

Aylık satış yapılan müşteri sayılarına ait veriler Çizelge 5.5’te gösterilmektedir. Rakip firma sayısı verileri, firmada kullanılan ERP programı NETSİS’ten elde edilmiştir.

Çizelge 5.5 Aylık satış yapılan müşteri sayısı

MÜŞTERİ SAYISI		ÜRÜN GRUBU				
YILLAR	AYLAR	1	2	3	4	5
2010	OCAK	20	-	-	-	-
	ŞUBAT	26	-	-	-	-
	MART	24	-	-	-	-
	NİSAN	24	-	-	-	-
	MAYIS	25	-	-	-	-
	HAZİRAN	27	-	-	-	-
	TEMMUZ	26	-	-	-	-
	AĞUSTOS	28	-	-	-	-
	EYLÜL	32	-	-	-	-
	EKİM	32	-	-	-	-
	KASIM	34	-	-	-	-
	ARALIK	37	-	-	-	-
2011	OCAK	40	16	1	2	2
	ŞUBAT	41	15	1	2	2
	MART	42	25	1	2	2
	NİSAN	41	26	1	2	2
	MAYIS	44	22	2	2	2
	HAZİRAN	45	21	2	2	2
	TEMMUZ	45	29	2	2	2
	AĞUSTOS	46	29	2	2	2
	EYLÜL	49	24	2	2	2
	EKİM	52	26	3	2	2
	KASIM	50	25	3	2	2
	ARALIK	41	26	3	2	2
2012	OCAK	43	30	3	2	2
	ŞUBAT	58	32	3	2	2
	MART	51	30	4	2	2
	NİSAN	44	26	4	2	2
	MAYIS	46	27	4	2	2
	HAZİRAN	48	21	4	2	2
	TEMMUZ	45	27	4	2	2
	AĞUSTOS	43	26	4	2	2
	EYLÜL	47	29	4	2	2
	EKİM	49	24	4	2	2
	KASIM	44	25	4	2	2
	ARALIK	47	25	4	2	2

Çizelge 5.5 Aylık satış yapılan müşteri sayısı (devamı)

2013	OCAK	43	26	4	2	2
	ŞUBAT	50	27	4	2	2
	MART	52	28	4	2	2
	NİSAN	54	34	4	2	2
	MAYIS	49	29	4	2	2
	HAZİRAN	47	33	4	2	2
	TEMMUZ	48	32	5	2	2
	AĞUSTOS	45	29	5	2	2
	EYLÜL	49	33	5	2	2
	EKİM	49	32	5	2	2
	KASIM	49	32	5	2	2
	ARALIK	49	34	5	2	2

- Özel Tarih Verileri

Yıl içerisindeki aylara ait özel tarih verileri Çizelge 5.6’da gösterilmiştir.

Çizelge 5.6 Özel tarih verileri

Aylar	Özel Tarihler
Ocak	yarı yıl başlangıcı
Şubat	Yok
Mart	Yok
Nisan	Yok
Mayıs	tatil sezonu
Haziran	Ramazan
Temmuz	Yok
Ağustos	Yok
Eylül	okul sezonu başlangıcı
Ekim	Yok
Kasım	Yok
Aralık	Yılbaşı

Veri setleri incelendiğinde, genellikle satış fiyat verileri sürekli artan bir eğilim göstermektedir. Müşteri sayısı verileri her ürün grubunda aylara göre farklılık göstermekle birlikte, 4. ve 5. ürün gruplarında aynı değerde seyretmektedir. Satış miktar verileri, özel tarihlerle ilişkilendirildiğinde, tatil sezonu, ramazan, okul dönemleri ve yılbaşı periyotlarında artış göstermektedir. Genellikle, belirtilen bu tarih dönemleri müşterilerin kampanya/aksiyon dönemlerine denk gelmektedir.

5.4 Yapay Sinir Ağı Modelinin Kurulması ve Uygulama

5.4.1 Modelin Tasarımı

Belirlenen 5 ürün grubundan her biri için yapay sinir ağları ile talep tahmini ayrı ayrı yapılmıştır. Uygulamalarda kullanılan yapay sinir ağı modeli, yapay sinir ağlarının anlatıldığı dördüncü bölümde yer alan ve ilgili yazınlarda en çok kullanılan ileri beslemeli geri yayımlı bir ağıdır. İleri beslemeli geri yayımlı ağın kullanılmasının sebebi ise, hem tahmin çalışmalarında en çok kullanılan model olması ve doğrusal veya doğrusal olmayan modellerdeki tahmin başarısıdır. Bunun yanında kullanım kolaylığı ve yakınsama hızı da bu ağ modelinin seçilmesinde etkili olmuştur. Yapay sinir ağları ile talep tahmini için oluşturulan model, Alyuda Research Inc. tarafından geliştirilen Alyuda NeuroIntelligence paket programı kullanılarak kurulmuştur. Yukarıda belirlenen ve tablolarda gösterilen gerçek veri setleri, sinir ağlarının -1 ile +1 aralığındaki sayılardan başka değerleri tanımadığı için, ağa sunulmadan önce normalizasyon işlemine tabi tutulmuştur. Bu işlem model kurulumundan önce program tarafından yapılarak giriş verilerinin tümü $[-1, 1]$ aralığına indirgenmiştir.

Tasarlanan modelde, bağımlı değişken olarak, sucuk ürün grubundaki 5 ayrı ürüne ait ayrı ayrı satış miktar verileri alınmıştır. Bağımsız değişken olarak, geçmişteki satış miktar verileri, aylık ortalama satış fiyat verileri, aylık satış yapılan müşteri sayısı verileri, pazardaki rakip firma sayısı verileri, aylar (mevsimsel etkiler) ve özel tarih verileri alınmıştır.

Çalışmada tasarlanan bütün yapay sinir ağı modellerinde, altı adet girdi ve bir adet çıktı değişkeni bulunmaktadır. Girdi katmanında, ağa sunulan beş bağımsız değişkene ait beş adet girdi işlemci elemanı, çıktı katmanında ise bağımsız değişkene ait bir adet çıktı işlemci elemanı bulunmaktadır. Ara katmandaki gizli işlemci eleman sayısı ise, modelin kurulumu sırasında, sistemin oluşturduğu ağlardan uygunluk değeri en iyi olan ağdaki katman sayısı kadardır. Bu sayının belirlenmesi için çeşitli işlemci eleman sayıları ile yapılan denemeler sonucunda açıklayıcılığı yüksek olan bu sayıda karar kılınmıştır.

Geliştirilen yapay sinir ağında iteratif tahmin yöntemi benimsendiğinden çıktı nöron sayısı birdir. Aynı şekilde, literatürde geliştirilen ileri beslemeli yapay sinir ağlarında genellikle tek gizli katman kullanılmaktadır. Bu nedenle çalışmada geliştirilen yapay sinir ağları modelinde 5 elemanlı bir tek gizli katman kullanılması uygun görülmüştür.

Yapay sinir ağı modelinin, gizli katmanındaki nöron sayısının belirlenmesinde deneme-yanılma yöntemi benimsenmiştir. Buradan hareketle her bir seri için, en iyi yapay sinir ağı modeli doğrulama kümesinde, en iyi sonucu veren (en düşük hata kareler toplamını veren) ağ seçilmiştir. Modelde işlemci elemanların birleştirme fonksiyonu toplama fonksiyonu olarak belirlenmiş, gizli katmandaki ve çıktı katmanındaki transfer fonksiyonları da kullanılan programın sınırları dahilinde lineer fonksiyon olarak seçilmiştir. Performans fonksiyonu olarak Ortalama Hata Kareleri (MSE) ve Ortalama Mutlak Yüzde Hata (MAPE) kullanılmıştır.

Açıklamalar doğrultusunda ürün grubu içerisindeki 5 farklı ürün içinde yukarıdaki işlemler tek tek yapılmış olup, bunlardan birinci ürün grubunun yapay sinir ağı ile talep örnek olacak şekilde açıklamalı olarak anlatılmıştır. Kalan 4 ürün grubu için yapılan yapay sinir ağı ile talep tahmini sonuçları özet ve sonuç olarak verilmiştir.

5.4.2 Yapay Sinir Ağı ile Talep Tahmini Uygulaması

Birinci ürün grubu için toplanan veriler, ilk olarak Microsoft Excel 2010 Programında düzenlenmiş ve Alyuda NeuroIntelligence programına aktarılmıştır. Programa aktarılan veri seti Şekil 5.4'te gösterilmiştir.

Raw Data						
TRN	VLD	TST	IGN	Target:	SATIŞ MİKTARI	Show row numbers
	(C12) AYLAR	(C6) ÖZEL GÜNLER	(N) SATIŞ MİKTARI	(N) SATIŞ FİYATI	(N) RAKİP FİRMA SAYISI	(N) MÜŞTERİ SAYISI
VLD	ocak	yok	30188	21,5	8	20
TRN	şubat	yarı yıl başlangıcı	29630	21,5	8	26
TRN	mart	yok	36457	23	8	24
TRN	nisan	yok	51260	23	8	24
TRN	mayıs	yok	34862	23	8	25
TST	haziran	tatil sezonu	40251	23	8	27
TRN	temmuz	yok	44320	23	8	26
TRN	ağustos	ramazan	49965	23	8	28
TRN	eylül	okul sezonu başlangıcı	60120	23	8	32
TRN	ekim	yok	85779	23	8	32
TST	kasım	yok	73542	23	8	34
TRN	aralık	yılbaşı	79265	23	8	37
TRN	ocak	yok	39711	23	8	40
VLD	şubat	yarı yıl başlangıcı	36673	23	8	41
TRN	mart	yok	60925	24,5	8	42
TRN	nisan	yok	66880	24,5	9	41
TRN	mayıs	yok	56140	24,5	9	44
TRN	haziran	tatil sezonu	48498	24,5	9	45
TRN	temmuz	yok	72306	24,5	9	45
TST	ağustos	ramazan	72140	24,5	9	46
VLD	eylül	okul sezonu başlangıcı	65567	24,5	9	49
TRN	ekim	yok	74011	24,5	9	52
TRN	kasım	yok	52252	24,5	9	50
TRN	aralık	yılbaşı	70686	24,5	9	41
TRN	ocak	yok	92917	24,5	9	43
TST	şubat	yarı yıl başlangıcı	114226	24,5	9	58
VLD	mart	yok	92378	26	10	51
TRN	nisan	yok	50662	26	10	44
TRN	mayıs	yok	67803	26	10	46
VLD	haziran	tatil sezonu	53193	26	10	48

Şekil 5.4 Birinci ürün grubu veri analizi [111]

Programa aktarılan veriler kategorik ve nümerik olarak ayrılmıştır. Ay ve özel durum verileri kategorik (C); pazardaki rakip firma sayısı, müşteri sayısı, satış fiyatı ve satış yapılan gün sayısı verileri de nümerik (N) olarak belirlenmiştir.

Programa tanıtılan veri setinin %68'i ağı eğitilmesi için eğitim seti olarak, %16'sı uygun yapay sinir ağı mimarisini belirlemek amacıyla doğrulama seti olarak ve %16'sı da ağı performansını ölçmek amacıyla test seti için program tarafından rastgele seçilmiştir ve Şekil 5.5'te gösterilmiştir.

Partition sets using:	Records	Percentage
Total:	34	100
Training set:	24	70
Validation set:	5	15
Test set:	5	15
Ignored set:	0	0

Şekil 5.5 Veri seti dağılımı

- Vektörlerin Normalizasyonu

Veriler programa aktarıldıktan sonraki aşama bu verilere normalizasyon işlemi uygulanmasıdır. Verilerin normalize edilmesi ile işlemci elemanlarında verilen kümülatif toplamaların oluşturduğu olumsuzluklar engellenmektedir [64], [110].

Verilerin normalizasyonu genellikle [0 1] veya [-1 1] aralıklarında yapılmaktadır. Çalışmada sayısal olarak programa aktarılan veriler bu yöntemler kullanılarak normalize edilmiştir.

Pazardaki rakip firma sayısı, müşteri sayısı ve satış fiyatı verileri için [-1 1] aralığında normalizasyon yapılmıştır. Bu işlem için sütunlardaki en küçük ve en büyük değerler alınmış ve aşağıdaki formüller kullanılarak hesaplanmıştır.

$$SF = \frac{SR_{max} - SR_{min}}{X_{max} - X_{min}} \quad (5.1)$$

$$X_p = SR_{min} + (X - X_{min}) * SF \quad (5.2)$$

SF : Ölçekleme faktörü

SR_{min} : En küçük ölçekleme değeri

SR_{max} : En büyük ölçekleme değeri

X : Özellik vektör değeri

X_{min} : İlgili sütunun en küçük değeri

$X_{\max}$: İlgili sütunun en büyük değeri

X_p : Ölçekleme sonunda elde edilen değer

Örneğin, ilk satış fiyatı değerine göre normalizasyon aşağıdaki şekilde yapılmıştır:

X : 21,5 TL

$X_{\min}$: 21,5 TL

$X_{\max}$: 27,5 TL

$SR_{\min}$: -1

$SR_{\max}$: 1

$$SF = \frac{1 - (-1)}{27,5 - 21,5} = 0,33$$

$$Xp = -1 + (21,5 - 21,5) * 0,33 = -1$$

Bu yöntem kullanılarak Alyuda NeuroIntelligence Programı tarafından satış fiyatı, pazardaki rakip firma sayısı ve müşteri sayısı verileri normalizasyonları yapılmıştır. Gerçek veriler ve bu verilere karşılık gelen normalizasyon değerleri Çizelge5.7’de gösterilmiştir.

Çizelge 5.7 Normalizasyon değerleri

Rakip Firma Sayısı Normalizasyon	Rakip Firma Sayısı	Satış Fiyatı Normalizasyon (TL)	Satış Fiyatı	Müşteri Sayısı Normalizasyon	Müşteri Sayısı
-1	21,5	-1	8	-1	20
-1	21,5	-1	8	-0,6842	26
-0,5	23	-1	8	-0,7895	24
-0,5	23	-1	8	-0,7895	24
-0,5	23	-1	8	-0,7368	25
-0,5	23	-1	8	-0,6316	27
-0,5	23	-1	8	-0,6842	26
-0,5	23	-1	8	-0,579	28
-0,5	23	-1	8	-0,3684	32
-0,5	23	-1	8	-0,3684	32

Çizelge 5.7 Normalizasyon değerleri (devamı)

-0,5	23	-1	8	-0,2632	34
-0,5	23	-1	8	-0,1053	37
-0,5	23	-1	8	0,05263	40
-0,5	23	-1	8	0,10526	41
0	24,5	-1	8	0,1579	42
0	24,5	-0,5	9	0,10526	41
0	24,5	-0,5	9	0,26316	44
0	24,5	-0,5	9	0,31579	45
0	24,5	-0,5	9	0,31579	45
0	24,5	-0,5	9	0,36842	46
0	24,5	-0,5	9	0,52632	49
0	24,5	-0,5	9	0,68421	52
0	24,5	-0,5	9	0,57895	50
0	24,5	-0,5	9	0,10526	41
0	24,5	-0,5	9	0,21053	43
0	24,5	-0,5	9	1	58
0,5	26	0	10	0,63158	51
0,5	26	0	10	0,26316	44
0,5	26	0	10	0,36842	46
0,5	26	0	10	0,47368	48
0,5	26	0	10	0,31579	45
0,5	26	0	10	0,21053	43
0,5	26	0,5	11	0,42105	47
0,5	26	0,5	11	0,52632	49
0,5	26	0,5	11	0,26316	44
0,5	26	0,5	11	0,42105	47
0,5	26	0,5	11	0,21053	43
0,5	26	1	12	0,57895	50
1	27,5	1	12	0,68421	52
1	27,5	1	12	0,78947	54
1	27,5	1	12	0,52632	49
1	27,5	1	12	0,42105	47
1	27,5	1	12	0,47368	48
1	27,5	0,5	11	0,31579	45
1	27,5	0,5	11	0,52632	49
1	27,5	0,5	11	0,52632	49
1	27,5	1	12	0,52632	49
1	27,5	1	12	0,52632	49

Aylık satış verileri için [0 1] aralığında normalizasyon yapılmıştır. Bu işlem için verilerin en küçük ve en büyük değerleri kullanılmış ve formül (5.3) ile normalize değerler hesaplanmıştır.

$$X_{yeni} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (5.3)$$

X : Özellik vektör değeri

X_{min} : İlgili sütunun en küçük değeri

X_{max} : İlgili sütunun en büyük değeri

Örneğin ilk aylık satış miktarı verisine göre normalizasyon aşağıdaki şekilde yapılmaktadır.

$$X = 30158 \text{ kg}$$

$$X_{min} = 29630 \text{ kg}$$

$$X_{max} = 114226 \text{ kg}$$

$$X_{yeni} = \frac{30158 - 29630}{114226 - 29630} = 0,006241$$

Bu yöntem kullanılarak Alyuda NeuroIntelligence Programı tarafından tüm aylık satış miktarı verileri için normalizasyon yapılmıştır. Gerçek aylık satış miktarları ve bu verilere karşılık gelen normalizasyon değerleri Çizelge 5.8’de gösterilmiştir.

Çizelge 5.8 Aylık satış miktarı normalizasyon verileri

Satış Miktarı Normalizasyon	Satış Miktarı (kg)
0,00624	30158
0	29630
0,0807	36457
0,25569	51260
0,06185	34862
0,12555	40251
0,17365	44320
0,24038	49965
0,36042	60120
0,66373	85779

Çizelge 5.8 Aylık satış miktarı normalizasyon verileri (devamı)

0,51908	73542
0,58673	79265
0,11917	39711
0,08326	36673
0,36994	60925
0,44033	66880
0,31337	56140
0,22304	48498
0,50447	72306
0,50251	72140
0,42481	65567
0,52462	74011
0,26741	52252
0,48532	70686
0,74811	92917
1	114226
0,74174	92378
0,24862	50662
0,45124	67803
0,27854	53193
0,62198	82247
0,48883	70983
0,51037	72805
0,70624	89375
0,32116	56799
0,47	69390
0,45683	68276
0,52858	74346
0,60849	81106
0,47425	69750
0,462	68713
0,46955	69352
0,45484	68108
0,21995	48237
0,16884	43913
0,11901	39698
0,12184	39937
0,1799	44849

Ay ve özel durum verileri için One-of-N yöntemi ile normalizasyon yapılmıştır. Ay için yapılan normalizasyonda One-of-12 yöntemi kullanılmıştır. Burada 12 rakamı ayları (Ocak, Şubat, Mart, Nisan, Mayıs, Haziran, Temmuz, Ağustos, Eylül, Ekim, Kasım, Aralık) temsil etmektedir. Örneğin ilk ay girdisi ocak ayıdır. Yapılan normalizasyon matrisinde ocak ayına '1' matrisin geri kalanına '-1' konulmuştur. Özel günler için yapılan normalizasyonda One-of-6 yöntemi kullanılmıştır. Burada 6 rakamı 6 özel durumu (okul sezonu başlangıcı, yarıyıl başlangıcı, ramazan dönemi, tatil dönemi, yok) belirtmektedir. Çizelge 5.9 aylar için yapılan normalizasyon değerlerini, Çizelge 5.10 özel günler için yapılan normalizasyon değerlerini göstermektedir.

Çizelge 5.9 Aylar için normalizasyon

Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1
-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1
-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1
-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1
-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1
-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1
-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1
1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1
-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1
-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1
-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1
-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1
-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1
-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1
1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1	-1
-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1	-1
-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1	-1
-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1	-1

Çizelge 5.9 Aylar için normalizasyon (devamı)

-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1	-1
-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	-1
-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1
-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1	-1
-1	-1	-1	-1	-1	-1	-1	-1	-1	1	-1	-1

Çizelge 5.10 Özel günler için normalizasyon


ramazan	okul sezonu başlangıcı	yarı yıl başlangıcı	tatil sezonu	Yılbaşı	yok
1	-1	-1	-1	-1	-1
-1	1	-1	-1	-1	-1
1	-1	-1	-1	-1	-1
1	-1	-1	-1	-1	-1
1	-1	-1	-1	-1	-1
-1	-1	1	-1	-1	-1
1	-1	-1	-1	-1	-1
-1	-1	-1	1	-1	-1
-1	-1	-1	-1	1	-1
1	-1	-1	-1	-1	-1
1	-1	-1	-1	-1	-1
-1	-1	-1	-1	-1	1
1	-1	-1	-1	-1	-1
-1	1	-1	-1	-1	-1
1	-1	-1	-1	-1	-1
1	-1	-1	-1	-1	-1
1	-1	-1	-1	-1	-1
-1	-1	1	-1	-1	-1
1	-1	-1	-1	-1	-1
-1	-1	-1	1	-1	-1
-1	-1	-1	-1	1	-1
1	-1	-1	-1	-1	-1
1	-1	-1	-1	-1	-1
-1	-1	-1	-1	-1	1
1	-1	-1	-1	-1	-1
-1	1	-1	-1	-1	-1
1	-1	-1	-1	-1	-1
1	-1	-1	-1	-1	-1
-1	-1	1	-1	-1	-1
-1	-1	-1	1	-1	-1
1	-1	-1	-1	-1	-1

Çizelge 5.10 Özel günler için normalizasyon (devamı)

-1	-1	-1	-1	1	-1
1	-1	-1	-1	-1	-1

- Ağ Mimarisinin Belirlenmesi


Yapılan çalışmada en uygun sinir ağı mimarisini bulmak için deneme yanılma yolu kullanılmıştır. Deneme yanılma yöntemiyle ve geçmiş çalışmalar ışığında kullanılacak ağın 1 girdi katmanı, 1 ara katman ve 1 çıktı katmanı olması gerektiğine karar verilmiştir. Yapay sinir ağı mimarisinin belirlenmesindeki bir diğer önemli konu da mimaride kaç nöronun kullanılacağını belirlemesidir. Nöron sayısını belirleyebilmek için Alyuda Neurointelligence Programı'ndaki tecrübeye dayalı 'Exhaustive Search Method' kullanılmıştır. Şekil 5.6'da ağ mimarisi arama ayarları gösterilmiştir. Şekil 5.6'da görüldüğü üzere ara katmandaki nöron sayısı için 1'den 50'ye kadar her sayı için uygun model aranmıştır. Uygunluk kriteri olarak test hatası değerini gösteren 'Inverse Test Error' seçilmiş olup iterasyon sayısı 500 ve yeniden öğrenme sayısı 1 olarak belirlenmiştir. Uygunluk kriterine göre en iyi performansa sahip ağ yapısı seçilmektedir.



Şekil 5.6 Ağ mimarisi arama ayarları

En iyi ağ yapısı Şekil 5.7'de gösterilmiştir. Şekil 5.7'den görüldüğü üzere "Inverse Test error" kriter alınarak en küçük hataya sahip olan en iyi 5 ağ yapısı gösterilmiştir. Bu ağlar arasından 21:49:1 ağ yapısı en uygun ağ olarak belirlenmiştir. Bu ağ yapısında 21

sayısı girdileri, 49 sayısı ara katmandaki nöron sayısını ve 1 sayısı da çıktı yani aylık satış tahmin miktarını göstermektedir. Belirlenen ağ yapısının test hatası 10737,832031 kg'dır.



Şekil 5.7 En iyi ağ yapısı

Nöron sayısı 1'den 50'ye kadar değiştirilerek elde edilen yapay sinir ağlarının uygunluk değerleri Çizelge 5.11'de gösterilmiştir. Yapay sinir ağlarının uygunluk değerlerine bakıldığında en uygun yapay sinir ağı uygunluk değeri 0,00093 olan 21:49:1 ağ yapısı en uygun ağ olarak belirlenmiştir.

Çizelge 5.11Yapay sinir ağları uygunluk değerleri

Ağ Mimarisi	Uygunluk
[21-1-1]fitness:	0,000058
[21-2-1]fitness:	0,000054
[21-3-1]fitness:	0,000057
[21-4-1]fitness:	0,000051
[21-5-1]fitness:	0,000053
[21-6-1]fitness:	0,000054
[21-7-1]fitness:	0,00005
[21-8-1]fitness:	0,00005
[21-9-1]fitness:	0,000052
[21-10-1]fitness:	0,000053
[21-11-1]fitness:	0,00006

Çizelge 5.11 Yapay sinir ağıları uygunluk değerleri (devamı)

[21-12-1]fitness:	0,000051
[21-13-1]fitness:	0,000052
[21-14-1]fitness:	0,00005
[21-15-1]fitness:	0,000057
[21-16-1]fitness:	0,000044
[21-17-1]fitness:	0,000057
[21-18-1]fitness:	0,000051
[21-19-1]fitness:	0,000053
[21-20-1]fitness:	0,000055
[21-21-1]fitness:	0,000049
[21-22-1]fitness:	0,000051
[21-23-1]fitness:	0,00006
[21-24-1]fitness:	0,000049
[21-25-1]fitness:	0,000048
[21-26-1]fitness:	0,000057
[21-27-1]fitness:	0,000065
[21-28-1]fitness:	0,000052
[21-29-1]fitness:	0,000044
[21-30-1]fitness:	0,000054
[21-31-1]fitness:	0,000054
[21-32-1]fitness:	0,000049
[21-33-1]fitness:	0,000047
[21-34-1]fitness:	0,000051
[21-35-1]fitness:	0,000058
[21-36-1]fitness:	0,000055
[21-37-1]fitness:	0,000055
[21-38-1]fitness:	0,000042
[21-39-1]fitness:	0,000054
[21-40-1]fitness:	0,000053
[21-41-1]fitness:	0,000049
[21-42-1]fitness:	0,000042
[21-43-1]fitness:	0,000056
[21-44-1]fitness:	0,000061
[21-45-1]fitness:	0,000047
[21-46-1]fitness:	0,000044
[21-47-1]fitness:	0,000053
[21-48-1]fitness:	0,000049
[21-49-1]fitness:	0,000093
[21-50-1]fitness:	0,000056

Sucuk grubu ürünlerden birinci grup için yapılan aylık talep tahminini etkileyebilecek girdi faktörlerinin önem yüzdeleri program tarafından belirlenmiştir. Buna göre en önemli girdi müşteri sayısı girdisidir ve Çizelge 5.12’de gösterilmiştir.

Çizelge 5.12 Önem yüzdeleri


Özel tarihler	10,122477
Aylar	18,939764
Satış fiyatı	10,349296
Rakip firma sayısı	20,588462
Müşteri sayısı	40,000001

- Ağın Öğrenme Algoritmasının Seçimi

En uygun ağın seçilmesinden sonra yapay sinir ağının eğitilmesi aşamasına geçilmiştir. Eğitim algoritması için tahmin modellerinin en çok kullanılan öğretmenli öğrenme algoritmalarından biri olan geriye yayılım algoritması kullanılmıştır. Geriye yayılım algoritmaları hatayı geriye doğru azaltmaya çalışır.

Şekil 5.8’de görüldüğü gibi 7 tane öğrenme algoritması bulunmaktadır. Bu algoritmalar içerisinde en çok kullanılan geriye yayılım algoritmalarından olan quick propagation (hızlı yayılım), conjugate gradient descent (eşleştirmeli eğitim), leverberg marquardt, online back propagation (geriye yayılım), batch back propagation (yığın geriye yayılım) eğitim algoritmaları için ağı kullanılarak ağ eğitilmiştir.

Öğrenme katsayısı için en uygun aralık olan 0,2-0,4 aralığı, momentum katsayısı içinse 0,6-0,8 aralığında değiştirilerek ağ algoritmalarına göre eğitilmiştir. Eğitim durdurma kriteri olarak iterasyon sayısını 500 olarak belirlenmiştir.



Şekil 5.8 Öğrenme algoritmaları

21:49:1 yapılı yapay sinir ağı, tüm eğitim algoritmaları ile eğitilmiş ve sonuçları Çizelge 5.13'te gösterilmiştir.

Çizelge5.13 Eğitim algoritma sonuçları

Eğitim Algoritması	Ort. Eğitim Hatası (kg)	Ort. Doğrulama Hatası (kg)	Ort. Test Hatası (kg)	Korelasyon	R ²
Batch Back Propagation	2820,13	2092,79	2415,97	0,249	0,02645
Quick Propagation	704,459	1078,73	2525,49	0,97442	0,93715
Quick Propagation	1482,2	976,125	1481,61	0,879	0,76044
Conjugate Gradient Descent	1171,29	1809,67	3552,3	0,91876	0,84151
Quasi-Newton	1520,49	939,62	1793,39	0,87544	0,76533
Limited Memory Quasi-Newton	2436,22	1721,84	3152,25	0,61765	0,25624
Levenberg-Marquardt	1699,75	1524,88	1816,7	0,87071	0,66737
Online Back Propagation	1432,82	972,664	1704,22	0,90787	0,80834
Online Back Propagation	2031,31	1046,9	1686,67	0,82442	0,51733
Online Back Propagation	1813,16	806,219	1633,96	0,87021	0,64049
Online Back Propagation	1882,44	764,95	1632	0,84245	0,59981
Online Back Propagation	70,6408	458,251	1126,13	0,99989	0,9998

Çizelge 5.13 Eğitim algoritma sonuçları (devamı)

Quick Propagation	1238,55	1017,63	1581,69	0,92038	0,84351
Quick Propagation	1262,62	903,108	1934,61	0,91697	0,83761
Quick Propagation	74,9248	1102,11	1909,77	0,99946	0,99854
Quick Propagation	79,5545	3150,02	1639,71	0,99977	0,99896
Quick Propagation	0,0252	0,39391	0,16003	0,99698	0,99222
Quick Propagation	0,01923	0,35922	0,21694	0,99925	0,99711

- Geriye Yayılım Algoritması Uygulanan Ağın Eğitim Aşaması

Seçilen yapay sinir ağının eğitimi sonucunda ortaya çıkan eğitim sonuçları Çizelge 5.14'teki gibidir.

Çizelge 5.14 Eğitim sonuçları

	Satır No	Beklenen Çıktı (kg)	Ağ Çıktısı (kg)	Mutlak Hata	Mutlak Bağlı Hata
TRN	1	29630	30599,7	969,734	3,27281
TRN	2	36457	36479,9	22,8825	0,06277
TRN	3	51260	51263,6	3,55615	0,00694
TRN	4	34862	34729,9	132,076	0,37885
TRN	6	44320	44317,3	2,73903	0,00618
TRN	7	49965	49963,7	1,31152	0,00263
TRN	8	60120	60139,4	19,3452	0,03218
TRN	9	85779	85770,5	8,49254	0,0099
TRN	11	79265	79252,3	12,7265	0,01606
TRN	12	39711	39687,5	23,5031	0,05919
TRN	14	60925	60937,4	12,4435	0,02042
TRN	15	66880	66884,6	4,54975	0,0068
TRN	16	56140	56139,4	0,56032	0,001
TRN	17	48498	48425,8	72,2189	0,14891
TRN	18	72306	72313,5	7,53595	0,01042
TRN	21	74011	74030,8	19,7545	0,02669
TRN	22	52252	52276,2	24,2033	0,04632
TRN	23	70686	70702,7	16,6945	0,02362
TRN	24	92917	92964,3	47,2532	0,05086
TRN	27	50662	50663	1,02391	0,00202
TRN	28	67803	67800,4	2,6469	0,0039
TRN	31	70983	70981,2	1,76874	0,00249

Çizelge 5.14 Eğitim sonuçları (devamı)

TRN	32	72805	72810,5	5,48839	0,00754
TRN	33	89375	89330,4	44,6513	0,04996
TRN	34	56799	56796,3	2,75488	0,00485
TRN	35	69390	69412,5	22,4978	0,03242
TRN	36	68276	68255,4	20,6166	0,0302
TRN	37	74346	74347,3	1,30172	0,00175
TRN	40	68713	68736	22,9646	0,03342
TRN	41	69352	69358,6	6,57065	0,00947
TRN	42	68108	68110,6	2,59154	0,00381
TRN	43	48237	48246,6	9,5862	0,01987
TRN	45	39698	39736,8	38,7543	0,09762
TRN	47	44849	44867,1	18,0766	0,04031


Eğitim değerlerinin ortalaması (mean), standart sapması (std dev.), mutlak hata (AE) ve mutlak bağıl hata (ARE) değerleri Şekil 5.9’da belirtilmiştir.

Summary				
	Target	Output	AE	ARE
Mean:	60746,470588	60774,433575	47,143348	0,00133
Std Dev:	15753,868295	15704,901073	162,551136	0,005506
Min:	29630	30599,733525	0,560323	0,00001
Max:	92917	92964,253174	969,733525	0,032728
Correlation: 0,999949				
R-squared: 0,999884				

Şekil 5.9 Eğitim sonuç özeti

Geriye yayılım algoritması eğitim aşaması sonuçlarından da anlaşılacağı üzere korelasyon (ilişki) değeri 0,999949, R^2 değeri 0,999884 çıkmış olup, %100’e yakın sonuçlar elde edilmiştir.

Şekil 5.10 Eğitim sonuç grafiğine bakıldığında kırmızı çizgiler beklenen değerleri, mavi çizgiler ise program çıktıları göstermektedir. Grafikten, korelasyon ve R^2 değerlerinden de anlaşılacağı üzere eğitim aşaması başarıyla sonuçlanmıştır.



Şekil 5.10 Eğitim sonuç grafiği

- Geriye Yayılım Algoritması Uygulanan Ağın Doğrulama Aşaması

Seçilen yapay sinir ağının doğrulama sonucunda beklenen çıktı ile program çıktı değerleri ile program çıktı değerleri Çizelge 5.15’te verilmiştir.

Çizelge 5.15 Doğrulama sonuçları


	Satır No	Beklenen Çıktı (kg)	Ağ Çıktısı (kg)	Mutlak Hata	Mutlak Bağlı Hata
VLD	0	30158	31732,7	1574,75	5,22166
VLD	13	36673	37835,5	1162,5	3,16991
VLD	20	65567	74250,5	8683,53	13,2437
VLD	26	92378	77948,1	14429,9	15,6205
VLD	29	53193	53813,5	620,524	1,16655
VLD	38	81106	64807,5	16298,5	20,0953
VLD	44	43913	42507,4	1405,61	3,20089

Doğrulama değerlerinin ortalaması (mean), standart sapması (std dev.), mutlak hata (AE) ve mutlak bağlı hata (ARE) değerleri Şekil 5.11’de belirtilmiştir.

Summary				
	Target	Output	AE	ARE
Mean:	57569,714286	54699,328875	6310,756856	0,088169
Std Dev:	21458,485832	16844,709312	6286,934498	0,068449
Min:	30158	31732,746687	620,524134	0,011666
Max:	92378	77948,068227	16298,459937	0,200953
Correlation: 0,931078				
R-squared: 0,720343				

Şekil 5.11 Doğrulama sonuç özeti

Geriye yayılım algoritması doğrulama aşaması sonuçlarından da anlaşılacağı üzere korelasyon (ilişki) değeri 0,931078, R^2 değeri 0,720343 çıkmış olup, %100'e yakın sonuçlar elde edilmiştir. Şekil 5.12'de doğrulama grafiği gösterilmiştir.



Şekil 5.12 Doğrulama grafiği

Şekil 5.12 Doğrulama grafiğine bakıldığında kırmızı çizgiler beklenen değerleri, mavi çizgiler ise program çıktılarını göstermektedir. Grafikten, korelasyon ve R^2 değerlerinden de anlaşılacağı üzere eğitim aşaması başarıyla sonuçlanmıştır.

- Geriye Yayılım Algoritması Uygulanan Ağın Test Değerleri

Seçilen yapay sinir ağının test sonucunda beklenen çıktı değerleri ile program çıktı değerleri Çizelge 5.16'da gösterilmiştir.

Çizelge 5.16 Test sonuçları

	Satır No	Beklenen Çıktı (kg)	Ağ Çıktısı (kg)	Mutlak Hata	Mutlak Bağlı Hata
TST	5	40251	36212,7	4038,31	10,0328
TST	10	73542	35278,1	38263,9	52,0299
TST	19	72140	76471,8	4331,77	6,00467
TST	25	114226	70948,5	43277,5	37,8876
TST	30	82247	77935,4	4311,55	5,2422
TST	39	69750	37162	32588	46,7211
TST	46	39937	37197,3	2739,7	6,86005


Test değerlerinin ortalaması (mean), standart sapması (std dev.), mutlak hata (AE) ve mutlak bağlı hata (ARE) değerleri Şekil 5.13'te belirtilmiştir.

Summary				
	Target	Output	AE	ARE
Mean:	70299	53029,408033	18507,240903	0,235398
Std Dev:	23637,975234	19240,163919	17165,516167	0,194857
Min:	39937	35278,142482	2739,699455	0,052422
Max:	114226	77935,448501	43277,519827	0,520299
Correlation: 0,648643				
R-squared: -0,721233				

Şekil 5.13 Test sonuçları özeti

Geriye yayılım algoritması test aşaması sonuçlarından da anlaşılacağı üzere korelasyon (ilişki) değeri 0,648643, R^2 değeri -0,721233 çıkmıştır.

Şekil 5.14 Doğrulama grafiğine bakıldığında kırmızı çizgiler beklenen değerleri, mavi çizgiler ise program çıktıları göstermektedir. Grafikten, korelasyon ve R^2 değerlerinden de anlaşılacağı üzere eğitim aşaması başarıyla sonuçlanmıştır.



Şekil 5.14 Test grafiği

- Geriye Yayılım Algoritması Uygulanan Yapay Sinir Ağı Sonuçları

Seçilen yapay sinir ağının beklenen değerleri ile programın çıktı değerleri Çizelge 5.17’de gösterilmiştir.

Çizelge 5.17 Uygulama değerleri

	Satır No	Beklenen Çıktı (kg)	Ağ Çıktısı (kg)	Mutlak Hata	Mutlak Bağlı Hata
VLD	0	30158	31732,7	1574,75	5,22166
TRN	1	29630	30599,7	969,734	3,27281
TRN	2	36457	36479,9	22,8825	0,06277
TRN	3	51260	51263,6	3,55615	0,00694
TRN	4	34862	34729,9	132,076	0,37885
TST	5	40251	36212,7	4038,31	10,0328
TRN	6	44320	44317,3	2,73903	0,00618
TRN	7	49965	49963,7	1,31152	0,00263
TRN	8	60120	60139,3	19,3452	0,03218
TRN	9	85779	85770,5	8,49254	0,0099
TST	10	73542	35278,1	38263,9	52,0299
TRN	11	79265	79252,3	12,7265	0,01606
TRN	12	39711	39687,5	23,5031	0,05919
VLD	13	36673	37835,5	1162,5	3,16991
TRN	14	60925	60937,4	12,4435	0,02042
TRN	15	66880	66884,5	4,54975	0,0068
TRN	16	56140	56139,4	0,56032	0,001

Çizelge 5.17 Uygulama değerleri (devamı)

TRN	17	48498	48425,8	72,2189	0,14891
TRN	18	72306	72313,5	7,53595	0,01042
TST	19	72140	76471,8	4331,77	6,00467
VLD	20	65567	74250,5	8683,53	13,2437
TRN	21	74011	74030,8	19,7545	0,02669
TRN	22	52252	52276,2	24,2033	0,04632
TRN	23	70686	70702,7	16,6945	0,02362
TRN	24	92917	92964,3	47,2532	0,05086
TST	25	114226	70948,5	43277,5	37,8876
VLD	26	92378	77948,1	14429,9	15,6205
TRN	27	50662	50663	1,02391	0,00202
TRN	28	67803	67800,4	2,6469	0,0039
VLD	29	53193	53813,5	620,524	1,16655
TST	30	82247	77935,4	4311,55	5,2422
TRN	31	70983	70981,2	1,76874	0,00249
TRN	32	72805	72810,5	5,48839	0,00754
TRN	33	89375	89330,3	44,6513	0,04996
TRN	34	56799	56796,2	2,75488	0,00485
TRN	35	69390	69412,5	22,4978	0,03242
TRN	36	68276	68255,4	20,6166	0,0302
TRN	37	74346	74347,3	1,30172	0,00175
VLD	38	81106	64807,5	16298,5	20,0953
TST	39	69750	37162	32588	46,7211
TRN	40	68713	68736	22,9645	0,03342
TRN	41	69352	69358,6	6,57065	0,00947
TRN	42	68108	68110,6	2,59154	0,00381
TRN	43	48237	48246,6	9,5862	0,01987
VLD	44	43913	42507,4	1405,61	3,20089
TRN	45	39698	39736,8	38,7543	0,09762
TST	46	39937	37197,3	2739,7	6,86005
TRN	47	44849	44867,1	18,0766	0,04031


Yapay sinir ağının eğitim, doğrulama ve test değerlerinin ortalaması (mean), standart sapması (std dev.), mutlak hata (AE) ve mutlak bağıl hata (ARE) değerleri Şekil 5.15'te belirtilmiştir.

Summary				
	Target	Output	AE	ARE
Mean:	61676,270833	58758,997915	3652,684545	0,048129
Std Dev:	18394,243148	16737,346788	9548,36558	0,114636
Min:	29630	30599,733525	0,560323	0,00001
Max:	114226	92964,253174	43277,519827	0,520299
Correlation: 0,848544				
R-squared: 0,626923				

Şekil 5.15 Eğitim, doğrulama ve test sonuçları özeti

Geriye yayılım algoritması eğitim doğrulama ve test aşamaları sonuçlarından da anlaşılacağı üzere korelasyon (ilişki) değeri 0,848544, R^2 değeri 0,626923 çıkmıştır.

Şekil 5.16 Eğitim, doğrulama ve test grafiğine bakıldığında kırmızı çizgiler beklenen değerleri, mavi çizgiler ise program çıktılarını göstermektedir. Grafikten, korelasyon ve R^2 değerlerinden de anlaşılacağı üzere eğitim aşaması başarıyla sonuçlanmıştır.



Şekil 5.16 Eğitim, doğrulama ve test grafiği

5.4.3 Yapay Sinir Ağı Tahmin Sonuçları

Kullanılan Alyuda NeuroIntelligence Programı'nda tahmin sonuçlarını elde etmek için Şekil 5.17'de gösterilen 'Manual Query' kısmı kullanılmıştır.

Manual Query				
aylar	özel günler	rakip firma sayısı	satış fiyatı	müşteri sayısı
max: n/a	max: n/a	max: 12	max: 28	max: 34
min: n/a	min: n/a	min: 8	min: 19	min: 15

Şekil 5.17 Manuel Sorgu

Ay, özel günler, rakip firma sayısı, satış fiyatı ve müşteri sayısı değerleri girildikten sonra Ocak, 2014-Aralık, 2014 ayları için yapılan tahmin sonuçları Çizelge 5.18’de gösterilmiştir.

Tahminleme yapılırken, geleceğe yönelik fiyat, müşteri sayısı ve rakip firma sayıları belirli bir kabul içerisinde programa aktarılmıştır. Firmanın satış fiyatı politikası gereğince, fiyat artışları her yılın Şubat ayında yapılmakta ve yeni fiyat takip eden aylar boyunca uygulanmaktadır. Rakip firma sayısının değişmeyeceği, müşteri sayısının ise markaya özel üretim yapıldığı için yeni yıl ile birlikte sabit kalacağı varsayılmıştır.

Çizelge 5.18 Birinci ürün grubu için yapılan talep tahmin sonuçları

Aylar	Özel Günler	Rakip Firma Sayısı	Satış Fiyatı	Müşteri Sayısı	Satış Tahmini (kg)
Ocak	yarı yıl başlangıcı	27,5	12	49	33690,65
Şubat	Yok	27,5	12	49	53766,58
Mart	Yok	29	13	50	38809,43
Nisan	Yok	29	13	49	31261,21
Mayıs	tatil sezonu	29	13	49	50732
Haziran	Ramazan	29	13	50	44111,47
Temmuz	Yok	29	13	50	43315,35
Ağustos	Yok	29	13	50	37680,15
Eylül	okul sezonu başlangıcı	29	13	50	34201,04
Ekim	Yok	29	13	50	33159,13
Kasım	Yok	29	13	50	31360,26
Aralık	Yılbaşı	29	13	50	32382,02

Yapay sinir ağı ile tahmin çalışmasının bu kısmında görüldüğü gibi istediğimiz değerleri girdiğimizde tahmin değerlerine kolaylıkla ulaşabiliriz. Ağı eğittikten sonra istediğimiz her değer için tahmin yapabiliriz.

Birinci ürün grubu için yapay sinir ağlarıyla talep tahmini detaylı olarak yukarıda açıklanmıştır. Diğer dört ürün grubu için de, aynı yöntemler sırasıyla izlenerek talep tahmini yapılmıştır. Yapılan talep tahminleri için eğitim, doğrulama ve test aşamalarının

korelasyon ve R^2 değerleri Şekil 5.18’de özet halinde verilmiştir. Diğer dört ürün grubunun tahmininde de, kurulan model yapıları aynı olup, aktivasyon fonksiyonu lineer fonksiyon, eğitim algoritması geriye yayılım algoritmasıdır.

Aşamalar	Eğitim Aşaması		Doğrulama Aşaması		Test Aşaması		Özet	
Ürün Grubu	Korelasyon Değeri	R^2 Değeri	Korelasyon Değeri	R^2 Değeri	Korelasyon Değeri	R^2 Değeri	Korelasyon Değeri	R^2 Değeri
1	0,999949	0,999884	0,931078	0,720343	0,648643	-0,721233	0,848544	0,626923
2	0,994586	0,998452	0,901257	0,801751	0,82106	0,49562	0,888959	0,804115
3	0,998692	0,997231	0,953918	0,846498	0,669347	0,400134	0,921355	0,834767
4	0,999272	0,998176	0,992241	0,966269	0,957682	-1,592845	0,865419	0,798404
5	0,940451	0,862684	0,921456	0,861572	0,655034	0,455034	0,90823	0,76852

Şekil 5.18 Ürün gruplarına göre aşama değerleri

Kurulan modellerin açıklama değeri olan R^2 ve korelasyon değerleri çoğunlukla 1’e yakındır. Bu durum kurulan modellerin açıklama değerinin kuvvetli olduğunu göstermektedir.

Kurulan modeller doğrultusunda, yapay sinir ağı ile yapılan talep tahmin sonuçları Çizelge 5.19, Çizelge 5.20, Çizelge 5.21 ve Çizelge 5.22’de gösterilmiştir.

Çizelge 5.19 İkinci ürün grubu için yapılan talep tahmin sonuçları

Aylar	Özel Günler	Rakip Firma Sayısı	Satış Fiyatı	Müşteri Sayısı	Satış Tahmini
Ocak	yarı yıl başlangıcı	11	28	32	13746,18520
Şubat	Yok	11	28	32	17321,39512
Mart	Yok	11	29,5	32	14627,95121
Nisan	Yok	11	29,5	32	15085,04574
Mayıs	tatil sezonu	11	29,5	32	18295,34806
Haziran	Ramazan	11	29,5	32	18282,04298
Temmuz	Yok	11	29,5	32	17805,47096
Ağustos	Yok	11	29,5	32	12781,89114
Eylül	okul sezonu başlangıcı	11	29,5	32	17244,13655
Ekim	Yok	11	29,5	32	16496,07058
Kasım	Yok	11	29,5	32	13153,09871
Aralık	Yılbaşı	11	29,5	32	18340,34867

Çizelge 5.20 Üçüncü ürün grubu için yapılan talep tahmin sonuçları

Aylar	Özel Günler	Rakip Firma Sayısı	Satış Fiyatı	Müşteri Sayısı	Satış Tahmini
Ocak	yarı yıl başlangıcı	4	25	5	12630,4
Şubat	Yok	4	25	5	15351,5
Mart	Yok	4	26,5	5	13614
Nisan	Yok	4	26,5	5	12327,5
Mayıs	tatil sezonu	4	26,5	5	15822,1
Haziran	Ramazan	4	26,5	5	15258
Temmuz	Yok	4	26,5	5	15229,8
Ağustos	Yok	4	26,5	5	15683,6
Eylül	okul sezonu başlangıcı	4	26,5	5	15887,9
Ekim	Yok	4	26,5	5	15856,8
Kasım	Yok	4	26,5	5	14943,3
Aralık	Yılbaşı	4	26,5	5	15764,7

Çizelge 5.21 Dördüncü ürün grubu için yapılan talep tahmin sonuçları

Aylar	Özel Günler	Rakip Firma Sayısı	Satış Fiyatı	Müşteri Sayısı	Satış Tahmini
Ocak	yarı yıl başlangıcı	0	27	2	13113,125268
Şubat	Yok	0	27	2	14015,831069
Mart	Yok	0	28,5	2	12438,744331
Nisan	Yok	0	28,5	2	17053,822795
Mayıs	tatil sezonu	0	28,5	2	17968,359137
Haziran	Ramazan	0	28,5	2	13652,950949
Temmuz	Yok	0	28,5	2	19693,760052
Ağustos	Yok	0	28,5	2	14224,299229
Eylül	okul sezonu başlangıcı	0	28,5	2	17411,244213
Ekim	Yok	0	28,5	2	18970,406569
Kasım	Yok	0	28,5	2	18758,372273
Aralık	Yılbaşı	0	28,5	2	12545,00188

Çizelge 5.22 Beşinci ürün grubu için yapılan talep tahmin sonuçları

Aylar	Özel Günler	Rakip Firma Sayısı	Satış Fiyatı	Müşteri Sayısı	Satış Tahmini
Ocak	yarı yıl başlangıcı	0	27	2	5612,958421
Şubat	Yok	0	27	2	4015,831069
Mart	Yok	0	28,5	2	2438,744331
Nisan	Yok	0	28,5	2	7053,822795

Çizelge 5.22 Beşinci ürün grubu için yapılan talep tahmin sonuçları (devamı)

Mayıs	tatil sezonu	0	28,5	2	7968,36
Haziran	Ramazan	0	28,5	2	3652,95
Temmuz	Yok	0	28,5	2	9693,76
Ağustos	Yok	0	28,5	2	4224,3
Eylül	okul sezonu başlangıcı	0	28,5	2	7411,24
Ekim	Yok	0	28,5	2	8970,41
Kasım	Yok	0	28,5	2	8758,37
Aralık	Yılbaşı	0	28,5	2	10747,3

5.4.4 Gerçekleşen Talep ile Tahminlenen Talebin Karşılaştırılması

Kurulan sinir ağı modeli doğrultusunda 2010-2013 yılları arasında, 48 aylık veri girişi yapılarak, eğitim, doğrulama ve test aşamalarından olumlu sonuçlar alındıktan sonra eğitimi tamamlanan modelde gelecek ile ilgili tahminler yapılmıştır. Veri girişi yapılan her ay için tahminler üretilmiştir. Ancak, ilgili literatürde yapıldığı gibi, grafiklerde karışıklığa neden olmaması ve daha net yorumlar yapılabilmesi için, aşağıda Çizelge 5.23'te görüldüğü gibi, burada yalnızca 24 aylık talep miktarları ele alınmıştır. Örnek olarak seçilen birinci ürün grubu için gerçekleşen talep ve tahminlenen talep verileri Çizelge 5.23'te gösterilmiştir.


Çizelge 5.23 Gerçekleşen talep ve tahminlenen talep verileri

Aylar	Gerçekleşen Talep	Tahminlenen Talep	Fark
Ocak	30158	31732,7	1574,7
Şubat	29630	30599,7	969,7
Mart	36457	36479,9	22,9
Nisan	51260	51263,6	3,6
Mayıs	34862	34729,9	132,1
Haziran	40251	36212,7	4038,3
Temmuz	44320	44317,3	2,7
Ağustos	49965	49963,7	1,3
Eylül	60120	60139,3	19,3
Ekim	85779	85770,5	8,5
Kasım	73542	35278,1	38263,9
Aralık	79265	79252,3	12,7
Ocak	39711	39687,5	23,5
Şubat	36673	37835,5	1162,5

Çizelge 5.23 Gerçekleşen talep ve tahminlenen talep verileri (devamı)

Mart	60925	60937,4	12,4
Nisan	66880	66884,5	4,5
Mayıs	56140	56139,4	0,6
Haziran	48498	48425,8	72,2
Temmuz	72306	72313,5	7,5
Ağustos	72140	76471,8	4331,8
Eylül	65567	74250,5	8683,5
Ekim	74011	74030,8	19,8
Kasım	52252	52276,2	24,2
Aralık	70686	70702,7	16,7

Talepler arasında oluşan en büyük fark değeri, 2010 yılının Kasım ayına denk gelmektedir. Bu durum, firmadan alınan bilgiye göre ürüne olan özel bir kampanya tarihine denk gelmesiyle açıklanmaktadır. Şekil 5.19’da yapılan karşılaştırmanın grafiği gösterilmektedir.



Şekil 5.19 Gerçekleşen talep ve tahminlenen talebin karşılaştırılması

Şekil 5.19’da yapay sinir ağı tarafından tahminlenen ve gerçekleşen talep miktarlarının birbirine çok yakın değerler olduğu açık bir şekilde görülmektedir. Talebi etkileyen mevsimsel dalgalanmalar gibi birçok faktör ve doğrusal olmayan bir talep dönemi göz önünde tutulduğunda, modelin performansının oldukça yüksek olduğu görülmektedir.

5.4.5 Modelde Üretilen Talep Tahminlerinin Hata Testleri

Yapılan talep tahminlerinin doğruluğunu ölçmek üzere, öncelikle tahmini değerler $x(t)$ ile gerçekleşen değerler $f(t)$ arasındaki sapma, yani basit hata $e(t)$; formül (5.4)’te gösterildiği gibi, tahminlenen değer ile gerçekleşen değer farkı alınarak hesaplanmıştır.

$$e(t) = x(t) - f(t) \quad (5.4)$$

Tahminin hata yüzdesi $p(t)$; formül (5.5) ile basit hatanın tahmin değerlerine oranı alınarak hesaplanmaktadır.

$$p(t) = e(t) / f(t) \quad (5.5)$$

Daha sonra, yapay sinir ağı tahmin sonuçlarının tutarlılığını ölçmede yaygın olarak kullanılan ölçütlerinden Ortalama Hata Kareleri (Mean Squared Error-MSE) ve Ortalama Mutlak Yüzde Hata (Mean Absolute Percent Error-MAPE) hesaplamaları yapılmıştır. R^2 değerinin hesaplaması MS Excel 2010 programındaki otomatik formül yardımıyla yapılmıştır.

$$MSE = \frac{1}{n} \sum [e(t)]^2 \quad (5.6)$$

$$MAPE = \frac{1}{n} \sum |p(t)| \quad (5.7)$$

Korelasyon değeri aşağıdaki formüle göre hesaplanmaktadır.

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{n(\sum x^2) - (\sum x)^2} \sqrt{n(\sum y^2) - (\sum y)^2}} \quad (5.8)$$

MS Excel ortamında yapılan bu hata hesaplamaları, örnek seçilen birinci ürün grubu için Çizelge 5.24'te gösterilmiştir.

Çizelge 5.24 Talep tahminin hata testleri Excel çözümü

Aylar	Gerçekleşen Talep (f)	Tahminlenen Talep (x)	Sapma (e)	Yüzde Hata (p)	Mutlak Yüzde Hata p
Ocak	30158	31732,7	1574,7	0,052215	0,052215
Şubat	29630	30599,7	969,7	0,032727	0,032727
Mart	36457	36479,9	22,9	0,000628	0,000628
Nisan	51260	51263,6	3,6	0,000070	0,000070
Mayıs	34862	34729,9	-132,1	-0,003789	0,003789
Haziran	40251	36212,7	-4038,3	-0,100328	0,100328
Temmuz	44320	44317,3	-2,7	-0,000061	0,000061
Ağustos	49965	49963,7	-1,3	-0,000026	0,000026
Eylül	60120	60139,3	19,3	0,000321	0,000321
Ekim	85779	85770,5	-8,5	-0,000099	0,000099

Çizelge 5.24 Talep tahminin hata testleri Excel çözümü (devamı)

Kasım	73542	35278,1	-38263,9	-0,5203	0,5203
Aralık	79265	79252,3	-12,7	-0,00016	0,00016
Ocak	39711	39687,5	-23,5	-0,000592	0,000592
Şubat	36673	37835,5	1162,5	0,031699	0,031699
Mart	60925	60937,4	12,4	0,000204	0,000204
Nisan	66880	66884,5	4,5	0,000067	0,000067
Mayıs	56140	56139,4	-0,6	-0,000011	0,000011
Haziran	48498	48425,8	-72,2	-0,001489	0,001489
Temmuz	72306	72313,5	7,5	0,000104	0,000104
Ağustos	72140	76471,8	4331,8	0,060047	0,060047
Eylül	65567	74250,5	8683,5	0,132437	0,132437
Ekim	74011	74030,8	19,8	0,000268	0,000268
Kasım	52252	52276,2	24,2	0,000463	0,000463
Aralık	70686	70702,7	16,7	0,000236	0,000236
Ocak	92917	92964,3	47,3	0,000509	0,000509
Şubat	114226	70948,5	-43277,5	-0,378876	0,378876
Mart	92378	77948,1	-14429,9	-0,156205	0,156205
Nisan	50662	50663	1	0,00002	0,00002
Mayıs	67803	67800,4	-2,6	-0,000038	0,000038
Haziran	53193	53813,5	620,5	0,011665	0,011665
Temmuz	82247	77935,4	-4311,6	-0,052423	0,052423
Ağustos	70983	70981,2	-1,8	-0,000025	0,000025
Eylül	72805	72810,5	5,5	0,000076	0,000076
Ekim	89375	89330,3	-44,7	-0,0005	0,0005
Kasım	56799	56796,2	-2,8	-0,000049	0,000049
Aralık	69390	69412,5	22,5	0,000324	0,000324
Ocak	68276	68255,4	-20,6	-0,000302	0,000302
Şubat	74346	74347,3	1,3	0,000017	0,000017
Mart	81106	64807,5	-16298,5	-0,200953	0,200953
Nisan	69750	37162	-32588	-0,467211	0,467211
Mayıs	68713	68736	23	0,000335	0,000335
Haziran	69352	69358,6	6,6	0,000095	0,000095
Temmuz	68108	68110,6	2,6	0,000038	0,000038
Ağustos	48237	48246,6	9,6	0,000199	0,000199
Eylül	43913	42507,4	-1405,6	-0,032009	0,032009
Ekim	39698	39736,8	38,8	0,000977	0,000977
Kasım	39937	37197,3	-2739,7	-0,068601	0,068601
Aralık	44849	44867,1	18,1	0,000404	0,000404

Çizelge 5.24'te görüldüğü gibi model tarafından yapılan talep tahmininin mutlak yüzde hata değeri en çok 2010 yılının Kasım ayında tarihinde 0,5203 olarak gerçekleşmiş, en az mutlak hata değeri de 2012 yılının Ekim ayı ve 2013 yılının Ocak ayında 0,000006 olarak gerçekleşmiştir. Bu sonuçlara göre, model tasarımında kullanılan özel tarih değişkeni önem kazanmaktadır. Araştırmalar sonucunda, belirlenen bu ürüne 2010 yılı Kasım ayında özel bir kampanya olduğu ve satışının arttığı öğrenilmiştir. 2012 yılının Ekim ayı verileri için, bu tarihin bayram periyoduna; 2013 yılı Ocak ayı verileri ise yılbaşı tarihlerine dikkat çekmektedir.

Çizelge 5.25'te görülen modelin açıklayıcılığı ve daha ileri düzeydeki hata testi hesaplamaları yapılmıştır.

Çizelge 5.25 Model tarafından yapılan talep tahmininin hata ve güvenilirlik sonuçları

	Korelasyon	R ²	MSE	MAPE
YSA	0,848544188	0,6269239	104513458,4	0,048129

Çizelge 5.25'te görüldüğü üzere, modelin açıklayıcılığı %85 olarak hesaplanmıştır. Bu hesaplamalara göre %85 korelasyon yüksek bir ilişkiyi göstermektedir. Buna göre sucuk grubu birinci ürün talep tahminiyle gerçekleşen talep miktarları arasında yüksek bir ilişki bulunmuştur. Bu durum modelin tutarlılığını ve isabetliliğini göstermektedir. Yine aynı tabloda tahmin sonuçlarının tutarlılığını ölçmede yaygın olarak kullanılan hata ölçütlerinden, Ortalama Hata Kareleri (MSE) değeri 104513458,4 olarak hesaplanmıştır. Hesaplanan bu hata değeri sinir ağının öğrenmeyi tamamladığı noktada, yapılan en az toplam hata değeridir. Daha sonra, yine tahmin tutarlılığını ölçmede kullanılan hata ölçütlerinden Ortalama Mutlak Yüzde Hata (MAPE) değeri 0,048129 olarak hesaplanmış ve ilgili tabloda gösterilmiştir.

Hesaplanan bu hata değeri de sinir ağının yaptığı talep tahmininde sıfıra yakın bir oranda hata yaptığını, dolayısıyla tahmin tutarlılığının ve isabetliliğinin çok yüksek olduğunu göstermektedir. Elde edilen tüm bu sonuçlara göre, tasarlanan yapay sinir ağı modelinin yapmış olduğu tahminlerin hata oranları uygun sınırlar içerisinde olup, modelin açıklayıcılığı da oldukça yüksektir.

5.4.6 Gerçekleşen Talepler ile Yapay Sinir Ağı Modeli ve Diğer Tahminlerin Karşılaştırılması

Çalışmanın bu kısmında, gerçekleşen talepler ile yapay sinir ağı yöntemiyle yapılan talep tahminleri ve zaman serileri ile talep tahmini yöntemlerinden Son Dönem Talebi

Yöntemi, Basit Ortalama Yöntemi, Hareketli Ortalama Yöntemi ve Üssel Düzeltme Yöntemleri karşılaştırılarak performansları değerlendirilmiştir. Zaman serileri ile talep tahmini yöntemleri daha önceki bölümlerde ayrıntılı olarak anlatılmıştır.

Belirtilen yöntemlerin karşılaştırmalı tahminleri EK-A'da detaylı olarak verilmiştir. Çizelge 5.26'da karşılaştırma yapılan talep tahmin yöntemlerine ait hata analizleri gösterilmektedir. Kullanılan yöntemlere ait bilgiler BÖLÜM 3'te ayrıntılı olarak anlatılmıştır.

Çizelge 5.26 Talep tahmin yöntemlerinin karşılaştırmalı hata analizi

Tahmin Yöntemleri	Korelasyon	R²	MSE	MAPE
Son Dönem Talebi	0,638629033	0,139673297	273846732,85	0,228869
Basit Ortalama	0,438656294	0,139673297	370157020,5	0,2531003
Hareketli Ortalama	0,514461373	0,122614937	405113942,2	0,3014093
Üssel Düzeltme	0,632213483	0,278352388	304824988,4	0,261454
Yapay Sinir Ağı	0,848544188	0,6269239	104513458,4	0,048129

Sonuç olarak, Çizelge 5.26'daki değerler karşılaştırmalı olarak incelendiğinde, sucuk ürünü grubu talep tahminini yapmak üzere tasarlanan yapay sinir ağı modelinin tahmin performansının, diğer talep tahmin modellerine göre daha yüksek olduğuna ve yapay sinir ağı modeli tarafından yapılan tahminlerin geçerli ve güvenilir olduğuna karar verilmiştir.

5.4.7 Uygulama Sonuçlarının Değerlendirilmesi

Uygulama olarak, kırmızı et işleme sektöründe lider bir kuruluştaki talep tahmin çalışması yapılmıştır. Öncelikle, planlama ve satış yöneticileri ile görüşülüp geçmiş döneme ait ulaşılabilen kayıtlı satış verilerine ve talebi etkilediği kabul edilen faktörlere ve bu faktörlere ait verilere ulaşılmaya çalışılmıştır. Talebi etkileyen faktörler, pazarda bulunan rakip firma sayısı, satış fiyatı, müşteri sayısı, mevsimsellik ve özel tarihler olarak belirlenmiştir. Bu verilerin bir kısmı sayısal olmadığı için, tecrübeye dayalı bir veri toplama gerçekleştirilmiştir. Sayısal veriler ise, firma gizlilik politikası gereği net olarak paylaşılmamakta olup, yakın değerler kabul edilerek talep tahmin çalışması yapılmıştır.

Tahmin çalışması yapılan şarküteri grubu oldukça geniş bir ürün yelpazesine sahiptir. Bu nedenle öncelikle şarküteri ürünleri kendi içerisinde, sucuk, salam, sosis, jambon, pastırma ve kavurma olmak üzere 6 ürün grubuna ayrılmıştır. Sonrasında yapılan ABC

analizi ile karlılık oranı en yüksek ürün grubunun sucuk ürün grubu olduğu belirlenmiştir. Seçilen ürün grubunda, üretim süreci birbirine çok yakınlık gösteren 5 farklı ürün için veriler oluşturulmuştur. Oluşturulan veri setleri çeşitli talep tahmin yöntemlerinde girdi olarak kullanılmıştır. İncelenip test edilen ve uygulamada kullanılmasına karar verilen, istatistiksel tahmin yöntemlerinden yapay sinir ağıları metodu kullanılarak sucuk grubunda belirlenen ürünlere olan talebin tahminlemesi aşamasına geçilmiştir. Tasarlanan modele veri girişi yapılmadan önce veri setlerinin tümü sinir ağı tarafından normalizasyon işleminden geçirilip sinir ağına veri girişleri yapılmıştır.

Çalışmada tasarlanan yapay sinir ağı modelinin, beş adet girdi ve bir adet çıktı değişkeni vardır. Model, 1 girdi katmanı-1 çıktı katmanı ve 1 gizli katmanına sahip, ileri beslemeli, geri yayılmalı bir sinir ağıdır. Girdi katmanında, ağı sunulan beş bağımsız değişkene ait beş adet girdi işlemci elemanı, çıktı katmanında ise bağımsız değişkene ait bir adet çıktı işlemci elemanı bulunmaktadır. Ağın eğitimi için ise, çevrimiçi geriye yayılım algoritması kullanılmış, başlangıç öğrenim oranı ve momentum değerleri 0,1 olarak alınmıştır. Bu değerlerin seçimi için farklı başlangıç değerleri ile denemeler yapılmış ve sonunda bu değerlerde karar kılınmıştır. Program her iterasyonda öğrenim oranı ve momentum değerlerini değiştirmek üzere ayarlanmıştır. Ağın başlangıç ağırlık değerleri yine program tarafından rassal olarak atanmıştır. Yapay sinir ağıları modeli 500 iterasyon yaptırılarak eğitilmiştir.

Eğitimi tamamlanan modelin test aşamasına geçilerek elde edilen hata değerleri program tarafından üretilmiştir. Bu işlemler belirlenen ürün grubu içindeki 5 ürün için de ayrı ayrı yapılmış olup, örnek olarak seçilen birinci ürün grubu üzerinden işlemler ayrıntılı olarak anlatılmıştır.

Yapılan analizler sonucunda kurulan yapay sinir ağı modelinin hem öğrenme hem de test setinde başarılı olduğu görülmektedir. En iyi iterasyon sayısına ulaşıp ağın eğitiminin tamamlanmasından sonra, sinir ağının yaptığı tahmin değerleri ile gerçek tahmin değerlerinin karşılaştırması aşamasına geçilmiştir.

Karşılaştırma sonucunda tahmin değerleriyle gerçekleşen değerler arasındaki fark istenen sınırlar içerisinde bulunduğundan modelin ürettiği tahminlerin tutarlı olduğuna karar verilmiştir.

Tasarlanan yapay sinir ağı modelinin eğitim ve test aşamasından sonra, modelde ele alınan değişkenlerin 2010 ile 2013 yılları arası dönemine ait veriler temel alınarak, gelecekte gerçekleşmesi beklenen, Ocak 2014 ile Aralık 2014 arası dönem, 12 aylık talep miktarlarının talep tahmini yapılmıştır.

Yapılan tahminlerin hata ve güvenilirlik testleri sonuçlarına göre, toplam talep tahmini modelinin açıklayıcılığı %85 olarak hesaplanmıştır. Buna göre sucuk ürün grubundan seçilen ürünlere yönelik talep tahmini ile gerçekleşen talep miktarları arasında yüksek bir ilişki olduğu söylenebilmektedir. Elde edilen tüm bu sonuçlara göre, tasarlanan yapay sinir ağı modelinin yapmış olduğu tahminlerin hata oranları uygun sınırlar içerisinde olup, modelin açıklayıcılığı da oldukça yüksektir. Zaman serisi analizi içerisinde yer alan birkaç talep tahmin yöntemiyle, aynı veriler tahmin edilmiş olup, en tutarlı tahmini yapay sinir ağı ile oluşturulan modeli yaptığı kanıtlanmıştır. Yapay sinir ağı ile kurulan bu modelde, talebi etkileyen faktörlerin tamamının doğrusal olmasa da modele dahil edilebilmesinin, tahmin yöntemi açısından büyük avantaj sağlaması olarak düşünülmektedir.

BÖLÜM 6

SONUÇ VE ÖNERİLER

Üretim, doğada var olan maddelerin insanların gereksinimlerini ve gereksinimlerden doğacak talepleri karşılayacak ürünler ve hizmetler haline dönüştürülmesi işlemi olarak tanımlanabilmektedir. Diğer bir ifadeyle üretim, beşeri ve maddi faktörlerin ürün ve hizmetlere dönüştürülmesidir. Üretim yönetimi ise, en az maliyetle, belirli nitelikte ve belirli miktarda üretimi, en iyi biçimde gerçekleştirecek kararları almaktır. Üretim yönetimi, üretilecek malın istenilen miktar, kalite, zaman ve maliyet faktörleri ile ilgili olup; temel amacı bu faktörler için en uygun değerlerin bulunmasıdır. Diğer bir ifadeyle üretim yönetimi, hangi malların ne miktarda, hangi özelliklerde, nerede ve kim tarafından yapılacağı sorularına en düşük maliyeti ve en fazla kârı sağlayan cevabı bulmaya çalışır. Üretim yönetimi, sistem içinde bir sistemdir, örgütün diğer kısımlarından farklı bir karakteristiğe sahiptir ve birçok alt sistemden oluşur. Üretim yönetimi fonksiyonlarından belki de en önemlilerinden birisi planlama fonksiyonudur kabul edilmektedir. Çünkü karar sürecinde hızlı olabilmek için örgütün sistemlere ve planlamaya ihtiyacı vardır.

Üretim planlaması yapılırken; üretimi yapılacak malın talep durumu dikkate alınarak, tüketicinin istediği ürünün özellikleri, fiyatı, kalitesi ve miktarıyla ilgili bilgiler toplanmalı ve bu bilgiler değerlendirilmelidir. Tüketici taleplerinde meydana gelen değişiklikler sürekli takip edilerek, bu taleplere uygun üretim yapılmalıdır. İşletmenin gelecekte üreteceği ürünler için gerekli kaynaklar, takip edilmesi gereken politikalar, üretim süreçleri, üretim kapasitesi ve geleceğe ilişkin diğer konular önceden tespit edilerek üretim planlamasının yapılması gereklidir. Üretime geçişten önceki hazırlık çalışmalarından birisi olan talep tahmini; yapılacak belirli bir üretimle ilgili olarak tahmini üretim maliyetlerinin, ürün miktarlarının belirlenmesi, stok maliyetlerinin

minimum yapılması açısından oldukça önemlidir. Üretilmesi düşünülen mala ne kadar talep olacağı bilinmeden herhangi bir planlamaya girilemez. Çünkü bu planlamaya göre hammadde, yedek parça, yarı mamul, makine, insan gücü ve yatırım ihtiyaçları belirlenecektir. Bunun için de öncelikle üretimi yapılacak ürüne ait talep tahminlerinin yapılması gereklidir.

Tahmin, gelecek dönemlerde meydana gelebilecek olayların sonuçlarının belli bir dönem için hesaplanmasıdır. Diğer bir ifadeyle; tahmin, geçmiş dönemlerde meydana gelmiş olayların sonuçlarını değerlendirerek gelecek dönemlerde meydana gelebilecek olayların sonuçlarını önceden görebilmektir.

Tahminin sonuçları değişik faktörler göz önünde tutularak değerlendirilir. Bu faktörlerden bazıları, geçmişe ait veriler, trend veya mevsimsel etkilerdir. Bunun ötesinde, tahminleri izlemek için var olan teknikler güncellenmeli ve sezgisel eğilimler ile karşılaştırılarak tahminin geliştirilmesi gereklidir.

Talep, alıcıların her fiyat seviyesinde bir maldan almak istedikleri mal miktarıdır. Kısaca talep, insanların üretilmiş ya da üretilmesi düşünülen bir ürünü satınalma isteklerinin bir ölçüsü olarak tanımlanabilmektedir. İktisadi anlamda talep, tüketicilerin bir mal veya hizmeti belirli bir fiyat seviyesinde almaya hazır oldukları miktardır. İşletmelerin temel amacı, piyasa talebini karşılamak üzere mal ve hizmet üretmek, pazarlamak, tüketici taleplerini karşılamak amacıyla faaliyetlerde bulunmak olduğundan, piyasa talepleri ölçülerek, talebin karşılanması için gerekli üretim sistemleri kurulmaya çalışılır.

Talep tahmini, işletmenin ürettiği mal ve hizmetlere olan talebin gelecek dönemler için tahmin edilmesidir. Gelecekteki üretim faaliyetlerinin planlanmasının hareket noktası talep miktarlarıdır.

Günümüzde talebi etkileyen faktörlerin çoğalması, bunlar arasındaki ilişkilerin karmaşıklığı, tecrübe ve sezgiye dayanan yöntemlerin yetersiz kalması, istatistiksel metotlarla talep tahmin metotlarına başvurmayı zorunlu kılmıştır. İstatistiksel metotlar; geçmişteki talep durumlarını, talebi etkileyen faktörleri ve ekonomik gösterge ilişkilerini analiz ederek talep tahmini yapılmasına olanak sağlayan, gelecekte ortaya çıkması muhtemel gelişmelerin, planlamaların önceden yapılmasını mümkün kılan metotlardır. Literatürde yapılan çalışmalar incelendiğinde, model doğruluklarında

istatistiksel yöntemlerin tecrübeye dayanan yöntemlere göre daha başarılı olduğunu göstermektedir.

Bilgisayarlar üzerinde yapılan uzun süreli çalışmalar, zamanla insan beynini modelleme ve yapay zeka modelini yaşamımıza sokmuştur. Bunu izleyen çalışmalar, yapay sinir ağları adı verilen yeni bir alanı ortaya çıkarmıştır. Yapay sinir ağlarının doğrusal olmayan problemlerin çözümünde etkin olarak kullanılması ve oldukça güvenilir sonuçlar sunması, bu tekniğin kullanımını gittikçe yaygınlaştırmıştır. Yapay sinir ağları, insan beyninin özelliklerinden olan, öğrenme yolu ile yeni bilgiler oluşturabilme, türetebilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan gelişmiş bilgisayarlar vasıtasıyla otomatik olarak gerçekleştirebilen istatistiki bir metottur. Yapay sinir ağları, hayvan ve insanlardaki sinir hücrelerinin işlevlerini, taklit eden bir bilgisayar yazılımıdır. Bu benzetimin temel amacı, sinir hücrelerinin zekilik ve sezgi yeteneklerini elde edebilmektir. Yapay sinir ağları, genellikle tahminlemelerde, kümelenmelerde, sınıflandırmalarda ve sıra dışı durumların bildirimlerinde kullanılan bir metottur. İnsan beyninin bilişsel öğrenme sürecine benzer bir biçimde, biyolojik nöron hücresinin yapısı ve öğrenme karakteristiklerinden esinlenerek geliştirilmiş, birlikte işleyen çok sayıdaki işlemci elemandan oluşmaktadır.

İnsanlar yaşamını sürdürebilmesi için temel ihtiyaçlarını karşılayabilmek zorundadırlar. Bu ihtiyaçların başında gıda, ilaç ve tekstil sektörleri yer almaktadır. Taze gıda sektörü, talebin sürekli değişkenlik gösterdiği, mevsimsel etkilerden ve kampanyalardan en çok etkilenen sektör olarak bilinmektedir. Gıda sektöründe talep dalgalanmaları, hammadde fiyatlarındaki değişiklik, mevsimsel etkiler, belirli tarih dönemlerinde sürekli olarak yapılan kampanyalar gibi birçok etkenden oluşmaktadır.

Türkiye’de ve dünyada, tüketim eğilimlerinin son yıllarda değişmesi ile birlikte hazır gıdalara olan talep de hızlı ve istikrarlı bir şekilde artmaktadır. Bu durum et işleme yapan gıda sanayisini de güçlendirmektedir. Ülkemizde et işleme yapan onlarca firma bulunmaktadır. Bunların bir kısmı küçük işletmeler; bir kısmı da fabrika şeklindeki büyük firmalardır. Araştırmalar sonucunda, Türkiye’de kırmızı et tüketim oranının diğer et gruplarına göre daha fazla olduğu ve kırmızı etin temel beslenme ihtiyacı olduğu gözlemlenmiştir. Kırmızı etin gıda sektöründeki payı büyüktür. Bu nedenle üretimi yapılacak miktarların taleplerinin doğru bir şekilde yapılabilmesi önem taşımaktadır.

Günümüzde gıda firmaları talep dalgalanmalarını yönetebilmek için üretim planlarını haftalık olarak oluşturma yoluna gitmeye başlamışlardır. Kırmızı et işleyen hazır gıda firmalarında, ürünlerin mevcut durumlarının bilinmesi, üretimden pazarlamaya kadar geçen süreçte yaşanan sorunların, talebi etkileyen faktörlerin belirlenmesi firmalara ve dolayısıyla ülkeye büyük katkılar sağlayacaktır. Özellikle literatür incelendiğinde, yapılmış olan talep tahmin çalışmalarında gıda sektörünü ele alan çalışmalara seyrek rastlanmıştır. Bunun, gıda sektöründeki belirsizliklerin ve dolayısıyla talep dalgalanmalarının yüksek olduğundan kaynakladığı görüşü bulunmaktadır.

Bu bağlamda, kırmızı et işleme sektöründe lider bir kuruluşta talep tahmin çalışması yapılmıştır. Öncelikle, planlama ve satış yöneticileri ile görüşülüp geçmiş döneme ait ulaşılabilen kayıtlı satış verilerine ve talebi etkilediği kabul edilen faktörlere ve bu faktörlere ait verilere ulaşılmaya çalışılmıştır. Talebi etkileyen faktörler, pazarda bulunan rakip firma sayısı, satış fiyatı, müşteri sayısı, mevsimsellik ve özel tarihler olarak belirlenmiştir. Bu verilerin bir kısmı sayısal olmadığı için, tecrübeye dayalı bir veri toplama gerçekleştirilmiştir. Sayısal veriler ise, firma gizlilik politikası gereği net olarak paylaşılmamakta olup, yakın değerler kabul edilerek talep tahmin çalışması yapılmıştır.

Tahmin çalışması yapılan şarküteri grubu oldukça geniş bir ürün yelpazesine sahiptir. Bu nedenle öncelikle şarküteri ürünleri kendi içerisinde, sucuk, salam, sosis, jambon, pastırma ve kavurma olmak üzere 6 ürün grubuna ayrılmıştır. Sonrasında yapılan ABC analizi ile karlılık oranı en yüksek ürün grubunun sucuk ürün grubu olduğu belirlenmiştir. Seçilen ürün grubunda, üretim süreci birbirine çok yakınlık gösteren 5 farklı ürün için veriler oluşturulmuştur. Oluşturulan veri setleri çeşitli talep tahmin yöntemlerinde girdi olarak kullanılmıştır. İncelenip test edilen ve uygulamada kullanılmasına karar verilen, istatistiksel tahmin yöntemlerinden yapay sinir ağları metodu kullanılarak sucuk grubunda belirlenen ürünlere olan talebin tahminlemesi aşamasına geçilmiştir. Tasarlanan modele veri girişi yapılmadan önce veri setlerinin tümü sinir ağı tarafından normalizasyon işleminden geçirilip sinir ağına veri girişleri yapılmıştır.

Çalışmada tasarlanan yapay sinir ağı modelinin, beş adet girdi ve bir adet çıktı değişkeni vardır. Model, ileri beslemeli, geri yayılmalı bir sinir ağıdır. Girdi katmanında, ağı sunulan beş bağımsız değişkene ait beş adet girdi işlemci elemanı, çıktı katmanında ise bağımsız değişkene ait bir adet çıktı işlemci elemanı bulunmaktadır.

Ağın eğitimi için ise, çevrimiçi geriye yayılım algoritması kullanılmış, başlangıç öğrenim oranı ve momentum değerleri 0,1 olarak alınmıştır. Bu değerlerin seçimi için farklı başlangıç değerleri ile denemeler yapılmış ve sonunda bu değerlerde karar kılınmıştır. Program her iterasyonda öğrenim oranı ve momentum değerlerini değiştirmek üzere ayarlanmıştır. Ağın başlangıç ağırlık değerleri yine program tarafından rassal olarak atanmıştır. Yapay sinir ağları modeli 500 iterasyon yaptırılarak eğitilmiştir.

Eğitimi tamamlanan modelin test aşamasına geçilerek elde edilen hata değerleri program tarafından üretilmiştir. Bu işlemler belirlenen ürün grubu içindeki 5 ürün için de ayrı ayrı yapılmış olup, örnek olarak seçilen birinci ürün grubu üzerinden işlemler ayrıntılı olarak anlatılmıştır.

Yapılan analizler sonucunda kurulan yapay sinir ağı modelinin hem öğrenme hem de test setinde başarılı olduğu görülmektedir. En iyi iterasyon sayısına ulaşıp ağın eğitiminin tamamlanmasından sonra, sinir ağının yaptığı tahmin değerleri ile gerçek tahmin değerlerinin karşılaştırması aşamasına geçilmiştir.

Karşılaştırma sonucunda tahmin değerleriyle gerçekleşen değerler arasındaki fark istenen sınırlar içerisinde bulunduğundan modelin ürettiği tahminlerin tutarlı olduğuna karar verilmiştir.

Tasarlanan yapay sinir ağları modelinin eğitim ve test aşamasından sonra, modelde ele alınan değişkenlerin 2010 ile 2013 yılları arası dönemine ait veriler temel alınarak, gelecekte gerçekleşmesi beklenen, Ocak 2014 ile Aralık 2014 arası dönem, 12 aylık talep miktarlarının talep tahmini yapılmıştır.

Yapılan tahminlerin hata ve güvenilirlik testleri sonuçlarına göre, toplam talep tahmini modelinin açıklayıcılığı %85 olarak hesaplanmıştır. Buna göre sucuk ürün grubundan seçilen ürünlere yönelik talep tahmini ile gerçekleşen talep miktarları arasında yüksek bir ilişki olduğu söylenebilmektedir. Elde edilen tüm bu sonuçlara göre, tasarlanan yapay sinir ağı modelinin yapmış olduğu tahminlerin hata oranları uygun sınırlar içerisinde olup, modelin açıklayıcılığı da oldukça yüksektir. Zaman serisi analizi içerisinde yer alan birkaç talep tahmin yöntemiyle, aynı veriler tahmin edilmiş olup, en tutarlı tahmini yapay sinir ağı ile oluşturulan modeli yaptığı kanıtlanmıştır. Yapay sinir ağı ile kurulan bu modelde, talebi etkileyen faktörlerin tamamının doğrusal olmasa da

modele dahil edilebilmesinin, tahmin yöntemi açısından büyük avantaj sağlaması olarak düşünülmektedir.

Çalışmada geliştirilen modelden elde edilen faydanın yaygınlaştırılması, şarküteri grubu ürünler ile ilgili üretim yapan firmaların ve işletmelerin üretim planlamalarında önemli katkılar sağlayacaktır. Bu anlamda çalışmanın sonuçları ışığında geliştirilebilecek öneriler şunlardır:

- Yapay sinir ağları modeli tarafından yapılan tahminleme sonucunda elde edilecek bilgiler sayesinde; öncelikle bilimsel anlamda konuyla ilgilenen üreticiler, sucuk ürün üretimi ve tüketimi ile ilgili veriler ışığında üretim/tüketim dengelemesini daha kolay yapabileceklerdir.
- Yapay sinir ağları modelinin ürettiği tahminler, şarküteri üretimindeki yatırım planlamalarını daha tutarlı ve güvenilir olarak yapmalarına olanak sağlayabilecektir.
- Yapay sinir ağları modelinin sağladığı veriler, şarküteri grubu ürünlerin satış fiyatı tahminleri açısından bir öngörü sağlayabilecek ve fiyat-maliyet karşılaştırması sürecini daha sağlıklı bir hale getirebilecektir.
- Yapay sinir ağları ile yapılan talep tahmini sayesinde üreticiler/yatırımcılar, sektörün gelecek dönemlerdeki hammadde ihtiyaçlarını elde edilen bu sonuçlara göre önceden belirleyebileceklerdir. Bu durum, besicilikle geçimini sağlayan kişilere olumlu katkılar sağlayacaktır.
- Yapay sinir ağları modeli ürünün üretildiği diğer firmalara örnek teşkil ederek, ülkemizdeki üreticilerin rekabet gücünü artıracaktır.
- Mevcut durumda ülkemiz bilim adamlarının yeterince yoğunlaşmadığı yapay sinir ağları uygulamaları üzerinde araştırmacıların bu konu üzerine daha fazla eğilerek yapay sinir ağları metodu ile sınıflandırma, tahmin, veri ve kontrol problemlerinin çözümü gibi birçok konuda da çözümler geliştirmeleri, ülkemiz bilimini daha ileri düzeylere taşıyabilecektir.
- Yeni mimarilerin geliştirilmesi, bulanık mantık ve genetik algoritmalar yardımıyla yapay sinir ağları metodunun daha da iyileştirilmesi konusunda da çalışmaların yapılması ülkemizin dünya yazınında yeterli çalışma ile temsil edilmesini ve ülkemizin yeni bin yılın yeni teknolojileri ile donanmasını sağlayabilecektir.

Çalışmanın yapıldığı işletmede üretimi gerçekleştirilen ürünler için herhangi bir talep tahmin yöntemi kullanılmamaktadır. Çalışmada belirlenen talep tahmin yöntemlerinin, seçilen grup ürünler için uygulanması sonucunda işletmeye sağlayacağı faydalar aşağıdaki gibi özetlenebilmektedir [112]:

- Tüm ürün grupları için üretim planlaması yapılmasına örnek bir model olacaktır.
- İşletmede oluşturulacak tüm üretim planlarının temeli olan talep tahminlerinin doğru yapılması sonucunda diğer planlamaların da doğruluğu artmış olacaktır.
- Üretim için gerekli olan kaynaklar daha etkin olarak kullanılabilir.
- Daha düşük envanter seviyelerine sahip olunacaktır.
- Stoksuz kalma veya fazla stok bulundurma durumu daha az yaşanacaktır.
- Üretim hattının kapasitesi daha verimli kullanılabilir.

Taze gıda üretim sektöründe çalışan firmanın şarküteri grubu ürün üretim verileri kullanılması ile yapılan bu tez çalışmasında anlatılan ve uygulanan tahmin yöntemleri, aynı sektörde faaliyet gösteren firmalarda da rahatlıkla uygulanabilir. Üretim planlamanın temel taşı sayılan talep tahmininin doğruluğu sonucunda, işletmeler açısından talep değişkeninin üzerine kurulacak diğer tüm faaliyet planlamalarının doğruluğu ve güvenilirliği artacaktır.

KAYNAKÇA

- [1] Karahan, M., (2011), İstatistiksel Tahin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması, Doktora Tezi, Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, Konya.
- [2] Fildes, R., (2006). “The Forecasting Journals and Their Contribution to Forecasting Research: Citation Analysis and Expert Opinion”, *International Journal of Forecasting*, 22(3): 415–432.
- [3] Kusters, U., McCullough, B. D. ve Bell, M., (2006). “Forecasting Software: Past, Present and Future”, *International Journal of Forecasting*, 22(3): 599–615.
- [4] Fildes, R. ve Beard, C., (1992). “Forecasting Systems For Production And Inventory Control”, *International Journal of Operations and Production Management*, 12(5): 4–27.
- [5] Gardner, E. S. Jr., (1990). “Evaluating Forecasting Performance in An Inventory Control System”, *Management Science*, 36(4): 490–499.
- [6] Wacker, J.G. ve Lummus, R.R., (2002). “Sales Forecasting For Strategic Resource Planning”, *International Journal of Operations and Production Management*, 22(9): 1014–1031.
- [7] Serttaş, Z.S., (2011). Türkiye’de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay SinirAğlarıyla Talep Tahmini Uygulaması, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [8] Kirby, Robert M. (1966). “A Comparison of Short And Medium Range Statistical Forecasting Methods, *Management Science*”, 13(4): B202-B210.
- [9] Bhattacharya, S., (1997). A Comparative Study of Different Methods of Predicting Time Series, Yüksek Lisans Tezi. Concordia University, Canada.
- [10] Carlson, R. L., ve Umble, M., (1980). “Statistical demand functions for automobiles and their use for forecasting in an energy crisis”, *The Journal of Business*, 53:2-10.
- [11] Akbay, A.Ö., Aktaş, E. ve Koç, A., (1999). “Konsantre Meyve Suyu Talebinin “Tobit” Modeli ile Analizi”, *Turkish Journal of Agriculture and Forestry*, 23: 493-499.

- [12] Gavcar, E., Şen, S. ve Aytekin, A., (1999). “Türkiye’de Kullanılan Kağıt-Karton Türlerinin Talep Tahminlerinin Belirlenmesi”, Tr. Journal of Agriculture and Forestry, TÜBİTAK, 23: 203-211, Kocaeli.
- [13] Chen, J., (2000). Forecasting Method Applications to Recreation and Tourism Demand, Doktora Tezi, North Carolina State University, USA.
- [14] Armstrong, J.S., Morwitz, V.G. ve Kumar, V., (2000). “Sales Forecasts For Existing Consumer products And Services: Do Purchase Intentions Contribute To Accuracy?”, International Journal Of Forecasting, 16: 383–397.
- [15] ZhoumcMahon, S. L., Walton, T. A., Lewis, A., (2002). “Forecasting perational Demand for an Urban Water Supply Zone”, Journal of Hydrology, 259: 1.
- [16] Cahow, E. E., (2004). Forecast of Demand for Chronic Care Nursing Home Services: 2005-2025, Doktora Tezi, Brandeis University, Waltham Massachusetts, USA.
- [17] Satır, B., ve Köksal, M., (2006). Entegre Tavuk Organizasyonları İçin Genel Üretim ve Finansal Planlama Modeli, <http://academic.cankaya.edu.tr/~benhur/cv/yaem2004.doc> , 11 Kasım 2013.
- [18] Matuyama, K., Sumita, T. ve Wakayama, D., (2009). “Periodic Forecast And Feedback to Maintain Target Inventory Level”, International Journal of Production Economics, 118(1):298-304.
- [19] Avcı, E., (2009). “Yapay Sinir Ağları Modelleri ile Hisse Senedi Getiri Tahminleri”, Marmara Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 26(1): 443-461.
- [20] Tsai, L.C., In-Fun, L. ve Huang, Y. (2009). “Forecasting Thailand's Medical Tourism Demand and Revenue From Foreign Patients”, The Journal of Grey System 4: 369-376.
- [21] Xu, X., Qi, Y. ve Hua, Z. (2010). “Forecasting Demand of Commodities After Natural Disasters. Expert Systems With Applications”, 37: 4313-4317.
- [22] Griffiths, W.E., Newton, L.S. ve O'Donnell, C.J. (2010). “Predictive Densities For Models with Stochastic Regressors and Inequality Constraints: Forecasting Local-Area Wheat Yield”, International Journal Of Forecasting, 26: 397–412.
- [23] Sun, X., Gauri, D. Ve Webster, S., (2010). “Forecasting For Cruise Line Revenue Management”, Journal of Revenue and Pricing Management.
- [24] Çağlar, T., (2007). Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması, Yüksek Lisans Tezi, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Kırıkkale.
- [25] Wong, B.K., Bodnovich, T.A., Selvi, Y. (1997). “Neural Network Applications in Business: A Review and Analysis of The Literature (1988-95)”, Decision Support Systems 19: 301-320.
- [26] Kirby, H.R., Watson, S.M. ve Dougherty, M.S. (1997). “Should We Use Neural Networks or Statistical Models For Short-Term Motorway Traffic Forecasting?”, International Journal Of Forecasting, 13: 43-50.
- [27] Gürbüz, T., (2008). Yapay Sinir Ağları Yaklaşımıyla Türkiye’deki Ulaştırma Talebinin Tahmini, Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale.

- [28] Yaşar, A.B., (2009). Kent İçi Otobüs Taşımacılığında Talep Tahmini, Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimler Enstitüsü, Denizli.
- [29] Chung, S., (2001). Demand Modeling And Analysis For The Management of Underground Infrastructure Systems, Doktora Tezi, Purdue University, USA.
- [30] Yüksek, A. G., (2007). Hava Kirliliği Tahmininde Yapay Sinir Ağları ve Çoklu Regresyon, Doktora Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas.
- [31] Shuai, H., Gong, Q., (2009). “A new multi-method combination forecasting model for ESDD predicting”, Energy and Power Engineering, 94-99.
- [32] Hu, Clark (2002). Advanced Tourism Demand Forecasting: ANN and Box-Jenkins Modelling, Doktora Tezi, Purdue University, MI, USA.
- [33] Çuhadar, M., Güngör, İ., ve Göksu, A. (2009). “Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya iline Yönelik Bir Uygulama”, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14(1): 99-114, Isparta.
- [34] Yu, L., Wang, S. ve Lai, K.K., (2008). “Forecasting Crude Oil Price with An EMD-Based Neural Network Ensemble Learning Paradigm”, Energy Economics, 30: 2623-2635.
- [35] Ataseven, B., (2007). Satış Öngörü Modellemesi Olarak Yapay Sinir Ağlarının Kullanımı: PETKİM’de Uygulanması, Yüksek Lisans Tezi, Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü, Manisa.
- [36] Çelik, B., (2008). Yapay Sinir Ağları Metodolojisi ile Zaman Serisi Analizi: Teori ve Uygulama, Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- [37] İnel, A., Sualp, M. N. ve Karakaş, M., (2010). “A Comparative Analysis of The Arma and Neural Network Models: A Case Turkish Economy”, İktisat İşletme ve Finans, 25(290): 35-64.
- [38] Hajirezaie, M., Hussein, S., Barfouroush, A. ve Karimi, B., (2010). “Modeling And Evaluating The Strategic Effects Of Improvement Programs On The Manufacturing Performance Using Neural Networks”, African Journal of Business Management, 4(4): 414-424.
- [39] Kaynar, O., Taştan, S. ve Demirkoparan, F. (2010). “Ham Petrol Fiyatlarının Yapay Sinir Ağları ile Tahmini”, Ege Akademik Bakış, 10(2): 561-575.
- [40] Sahoo, G.B., Schladow, S.G. and Reuter, J.E. (2009). “Forecasting Stream Water Temperature Using Regression Analysis, Artificial Neural Network and Chaotic Non-Linear Dynamic Models”, Journal Of Hydrology, 378: 325–342.
- [41] Aydoğan, B., Ayat, B., Öztürk, M. N., Çevik, Ö. E. ve Yüksel, Y., (2010). “Current Velocity Forecasting in Straits with Artificial Neural Networks, A Case Study: Strait of Istanbul”, Ocean Engineering, 37: 443–453.
- [42] Shamseldin, A. Y., (2010). “Artificial Neural Network Model For River Flow Forecasting in A Developing Country”, Journal of Hydro Informatics, 12(1): 22.
- [43] Jones, S. S., (2008). Measuring, Modeling, and Forecasting Demand in The Emergency Department, Doktora Tezi, The University of Utah, USA.

- [44] Kellova, A., (2008). Statistical Approach to Short-Term Electricity Forecasting, Dissertation, Doktora Tezi, Charles University, Prague.
- [45] Aksoy, H. ve Dahamsheh, A., (2009). “Artificial Neural Network Models For Forecasting Monthly Precipitation in Jordan”, Stock Environ Res Risk Assess , 23: 917–931.
- [46] Asilkan, Ö. ve Irmak, S. (2009). “İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi”, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14(2): 375-391.
- [47] Higgins, A., Prestwidge, D., Stirling, D.,ve Yost, J. (2010). “Forecasting Maturity of Green Peas: An Application of Neural Networks”, Computers and Electronics in Agriculture, 70: 151–156.
- [48] Özkan, F., (2012).“Döviz Kuru Tahmininde Parasal Model ve Yapay Sinir Ağları Karşılaştırması”, Business and Economics Research Journal, ISSN 1309-2448, 3(1): 27.
- [49] Sattari, M.T., Fard, A.F., Öztürk, F., Docherkhesaz, M., (2007).“Yapay Sinir Ağları Yöntemi ile Savalan Sulama Rezervuarının Simülasyonu”,Ankara Üniversitesi Ziraat Fakültesi Tarım Bilimleri Dergisi, ISSN 1300-7580, 13(4): 327 – 345.
- [50] Ziarati, M., Stockton, D., Uçan, O.N., Bilgili, E. (2002).“Design and Development of Material and Information Flow Supply Chains Using Genetic Cellular Networks”, Doğu Üniversitesi Dergisi, ISSN 1302-6739, 5(1): 193 – 209, İstanbul.
- [51] Demir, Y.K., (2006).“Ulaştırma Türü Seçiminde Esnek Hesaplama Yöntemleri, İstanbul Teknik Üniversitesi Dergisi Seri D: Mühendislik, ISSN 1303-703X, 5(6): 61 – 73, İstanbul.
- [52] Çuhadar, M., Kayacan, C., (2005).“Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye’deki Konaklama İşletmeleri Üzerine Bir Deneme”, Anatolia/ Turizm Araştırmaları Dergisi, ISSN 1300-4220, 16(1): 24 – 30.
- [53] Zou, H.F., Xia, G.P., Yang, F.T., Wang, H.Y., (2007).“Çin Gıda Endüstrisinde Buğday Fiyatları Tahmini İçin Yapay Sinir Ağları ve Zaman Serisi Modellerinin İncelenmesi ve Karşılaştırılması”, Neurocomputing,70(16): 2913-2923.
- [54] Efendigil, T., Önüt, S., ve Kahraman, C., (2009). “A Decision Support System For Demand Forecasting with Artificial Neural Networks And Neuro-Fuzzy Models: A Comparative Analysis”,Expert Systems with Applications, 36: 6697-6707.
- [55] Beccali, M., Cellura, M., Brano, V.L., Marvuglia, (2010). “Yapay Sinir Ağları ile Günlük Kentsel Elektrik Yükü Profilleri Tahmini”, Energy Conversion and Management, 45(19): 2879-2900.
- [56] Wu, J.D., Liu, J.C., (2012). “ Yakıt Tüketim Tahmini İçin Bir Radyal Tabanlı Fonksiyonlu Yapay Sinir Ağı Kullanımı”, Expert Systems with Applications, 39(2): 1883-1888.
- [57] Yu, Y., Hui, C.L., Choi, T.M., (2012). “Moda Renk Trend Tahminleri Üzerinde Akıllı Uzman Sistemleri ile Bir Ampirik Çalışma”, Expert Systems with Applications, 39(4): 4383-4389

- [58] Shakya, S., Kern, M., Owusu, G., Chin, C.M., (2012). “Dinamik Fiyatlandırmada Yapay Sinir Ağı Talep Modelleri ve Evrimsel Optimizasyonlar”, Knowledge-Based Systems, 29: 44-53.
- [59] Doganis, P., Alexandridis, A., Patrinos, P., Sarimveis, H., (2006). “Raf Ömrü Kısa Gıda Ürünlerinin Yapay Sinir Ağları ve Evrimsel Hesaplamalar Kullanılarak Zaman Serisi Satış Tahminleri”, Journal of Food Engineering, 75(2): 196-204.
- [60] Jin, X.H., Zhang, G., (2011). “Modelling Optimal Risk Allocation in PPP Projects Using Artificial Neural Networks”, International Journal of Project Management, 29: 591–603.
- [61] Keçebaş, A., Yabanova, İ., Yumurtacı, M., (2012). “Artificial Neural Network Modeling Of Geothermal District Heating System Thought Exergy Analysis”, Energy Conversion and Management, 64: 206-212.
- [62] Doğan, E., Şengörür, B., Köklü, R., (2009). “Modeling Biological Oxygen Demand of The Melen River in Turkey Using An Artificial Neural Network Technique”, Journal of Environmental Management, 90: 1229–1235.
- [63] Boone, S.D., Roehm, M., (2002). “Retail Segmentation Using Artificial Neural Networks”, Intern. J. of Research in Marketing, 19: 287–301.
- [64] Demirceylan, S., (2012). Erzurum’da Doğalgaz Tüketim Miktarının Yapay Sinir Ağı Algoritması Kullanılarak Tahmin Edilmesi, Yüksek Lisans Tezi, Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Erzurum.
- [65] Tanyaş, M. ve Baskak, M., (2008), Üretim Planlama ve Kontrol, 3. Baskı, İrfan Yayıncılık, İstanbul.
- [66] Mucuk, İ., (2001), Temel İşletme Bilgileri, 1. Basım, Türkmen Kitabevi, İstanbul.
- [67] Düzakın, E., (2005). İşletme Yöneticileri İçin Excel ile Sayısal Karar Verme Teknikleri, Kare Yayınları, İstanbul.
- [68] Üreten, S. (2005). Üretim/İşlemler Yönetimi, Stratejik Kararlar ve Karar Modelleri, 5. Baskı, Gazi Kitabevi, Ankara.
- [69] Bağırkan, Ş. (1982). İstatistiksel Analiz, İstanbul: Önsöz Basım ve Yayıncılık.
- [70] Monks, J.G. (1996), İşlemler Yönetimi Teori ve Problemler, (Çeviren: Sevinç Üreten) Nobel Yayın Dağıtım, Ankara.
- [71] Efendigil, T., (2008). Müşteri Odaklı Sistemler için Yapay Sinir Ağları ve Bulanık Çıkarım Tabanlı Karar Destek Sistemi Yaklaşımı, Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [72] Muhlemann, A., Oakland, J. ve Lockyer, K., (1994), Production and Operations Management, Sixth Edition, Pitman Publishing, London.
- [73] Ballot, M., (1986). Decision Making Model in Production & Operations Management. Robert E. Krieger Publishing Company, Florida.
- [74] Lancaster, G. ve Massingham (1988), Essentials of Marketing: Text and Cases. McGraw-Hill Book Company, London.
- [75] Tenkorang, F. A., (2006). Projecting World Fertilizer Demand in 2015 and 2030, Doktora Tezi, Purdue University, West Lafayette, Indiana, USA.
- [76] Chase, R. B. ve Aquilano, N.J. (1981). Production and Operations Management, A Life Cycle Approach, 3, Richard D. Irwin Inc. Illinois.
- [77] Ergün, M. E., (2008). Sermaye Bütçelemesi ve Türk Sanayi İşletmelerinde Uygulaması, Yüksek Lisans Tezi, Çukurova Üniversitesi Sosyal Bilimler Enstitüsü, Adana.
- [78] Tekin, M., (2009). Üretim Yönetimi Cilt 1, 6. Baskı, Günay Ofset, Konya.

- [79] Kobu, B. (1994). Üretim Yönetimi, Avcıol Basım-Yayım, 8. Baskı, İstanbul.
- [80] Özdemir, A. ve Özdemir, A., (2006). “Talep Tahminlemede Kullanılan Yöntemlerin Karşılaştırılması: Seramik Ürün Grubu Firma Uygulaması”, Ege Academic Review, 105-114.
- [81] Bolt, G. J., (1981). Market and Sales Forecasting, A Total Approach, 2, Kogan Page Limited, London.
- [82] Saygılı, İ., (1991), Üretim Yönetiminin Fonksiyonları, İşletme Fakültesi Yayınları, Küre Ajans No: 244, İstanbul.
- [83] Makridakis, S., Wheelwright, S.C. ve Hyndman, R.J. (1998), Forecasting Methods and Applications, 3, John Wiley & Sons Inc., New York.
- [84] Adıyaman, F., (2007). Talep Tahmininde Yapay Sinir Ağlarının Kullanılması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [85] Meydan, Y.A., (2007), Talep Tahmin Yöntemleri ve Orta Ölçekli Bir İşletmede Uygulanması, Yüksek Lisans Tezi, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [86] Kurşun, S., (2007), Tekstil Endüstrisinde Benzetim Tekniği ile Üretim Hattı Modellemesi ve Uygun İş Akış Stratejisinin Belirlenmesi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [87] Halaç, O., (1995). Kantitatif Karar Verme Teknikleri, Alfa Basım Yayım Dağıtım 4. Baskı, İstanbul.
- [88] Hiller, F. S. ve Liebermann, G. J., (1970). Introduction to Operation Research, 6, Golden Day Inc., San Francisco.
- [89] İpek, M., (1995). Tam Zamanında Üretim Sistemi ve Bir Simülasyon Uygulaması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [90] Öztemel, E. (2012). Yapay Sinir Ağları, 2. Baskı, Papatya Yayıncılık, İstanbul.
- [91] Güngör, E., (2007). Yapay Sinir Ağları Yardımı ile Makine Arızalarının Önceden Tahmin Edilmesi, Yüksek Lisans Tezi, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü, Kocaeli.
- [92] Toktaş, İ. ve Aktürk, N., (2004). Makine Tasarım İşleminde Kullanılan Yapay Zeka Teknikleri ve Uygulama Alanları, Makine Teknolojileri Elektronik Dergisi, 2: 7-20.
- [93] Whitby, B., (2005). Yapay Zeka Yeni Başlayanlar İçin Kılavuz (Çeviren: Çiğdem Karabağlı), İletişim Yayınları, İstanbul.
- [94] Haykin, S., (1999). Neural Networks: A Comprehensive Foundation, Prentice-Hall, Second Edition, New Jersey.
- [95] Ermiş, M. (2005). Lojistik Sistemlerinin Yapay Sinir Ağları ile Modellenmesi, Gerçeklenmesi ve Kontrolü, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- [96] Ayan, T. Y., (2009). Dinamik Parti Büyüklüğü Problemi İçin Yapay Sinir Ağı Modelleri, Marmara Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 26(1): 501-515.

- [97] Kohonen, T., Barna, G., (1987). Statistical Pattern Recognition with Neural Networks: Benchmarking Studies, Proc. of The İnt. Joint Conf. on Neural Networks, 1: 1-66
- [98] Chaudhury, A., Stahl, D. O., Whinston, A. B., (1994). The Economic Foundation for Neural Computing Systems im, Advances in AI in Economics Finance and Management. Eds. Johnson J.D.. Whinston A.B.. JAI Pres Inc.
- [99] Stergiou, C. ve Siganos, D. (2010), Neural Networks, http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html, 11 Kasım 2013.
- [100] Saygılı, Y. S., (2008). İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülenmesi, Yüksek Lisans Tezi, Kara Harp Okulu Savunma Bilimleri Enstitüsü, Ankara.
- [101] Kartalopoulos, S.V., (1996). “Understanding Neural Networks and Fuzzy Logic”, Basic Concepts and Applications, IEEE Press New York.
- [102] Fahey, C., (2003). Neural network with learning by backward error propagation, http://www.colinfahey.com/2003apr20_neuron/2003apr20_neuron.html , 01 Ekim 2013.
- [103] Rao, A.M. ve Srinivas, J., (2003), Neural Networks Algorithms and Applications, Alpha Science International Ltd., Pangbourne England.
- [104] Rajpal, P.S., Shishodia, K.S. Ve Sekhon, G.S. (2006). “An Artificial Neural Network For Modeling Reliability, Availability and Maintainability of A Repairable System”, Reliability Engineering and System Safety, 809-819.
- [105] Hebb, D. O., (1949). The Organization of Behaviour, Wiley, Newyork.
- [106] Kohonen, T.,(1982). Self-Organized Formation Of Topologically Correct FeatureMaps, Biological Cybernetics, 43: 59-69.
- [107] Masters, T.,(1993). Practical Neural Network Recipes in C++, Academic Pres, USA.
- [108] http://www.pinar.com.tr/yatirimci_iliskileri/et-detay/Sektorel-Bakis/1476/1337/0 ,11 Mart 2014.
- [109] <http://www.namet.com.tr/>, 10 Ekim 2013.
- [110] Saraoğlu H.M.,(1998), Beyin Sinyallerinin Geri Yaymalı Yapay Sinir Ağı ile Eğitilmesi, Haritalanması. Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- [111] Alyuda (2010). Yapay Sinir Ağları Yazılım Şirketi Web Sayfası.<http://www.alyuda.com/neural-networks-software.html>20 Aralık 2013
- [112] Maltepe, I. (2012). Doğrusal Programlama Yardımıyla Üretim Planlamasının Sanal Bir Petrol Rafineri Şirketine Uygulanması, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Sosyal Bilimler Enstitüsü, Trabzon.
- [113] Hopfield, J.J.,(1982).“Neural Networks and Physical Systems with Emergent Collective Computational Abilities”, Proceedings of National Academy ofScience, 79: 2554-2558.

EK-A

AYLAR	YÖNTEMLER	Son Dönem Talebi Yöntemi		Basit Ortalama Yöntemi		Hareketli Ortalama Yöntemi		Üssel Düzeltme Yöntemi		Yapay Sinir Ağları Yöntemi	
	Lürün grubu satış verileri	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)
Ocak	30158	*	*	*	*	*	*	*	*	31732,7	1574,75
Şubat	29630	30158	528	30158	528	*	*	*	*	30599,7	969,734
Mart	36457	29630	6827	29894	6563	*	*	*	*	36479,9	22,8825
Nisan	51260	36457	14803	32082	19178	*	*	32082	19178	51263,6	3,55615
Mayıs	34862	51260	16398	36876	2014	36876	2014	45507	10645	34729,9	132,076
Haziran	40251	34862	5389	36473	3778	38052	2199	38055	2196	36212,7	4038,31
Temmuz	44320	40251	4069	37103	7217	40708	3613	39592	4728	44317,3	2,73903
Ağustos	49965	44320	5645	45272	4693	42673	7292	42902	7063	49963,7	1,31152
Eylül	60120	49965	10155	47128	12992	42350	17771	47846	12274	60139,3	19,3452
Ekim	85779	60120	25659	41891	43888	48664	37115	56438	29341	85770,5	8,49254
Kasım	73542	85779	12237	46280	27262	60046	13496	76977	3435	35278,1	38263,9
Aralık	79265	73542	5723	48759	30506	67352	11914	74572	4693	79252,3	12,7265

AYLAR	YÖNTEMLER	Son Dönem Talebi Yöntemi		Basit Ortalama Yöntemi		Hareketli Ortalama Yöntemi		Üssel Düzeltme Yöntemi		Yapay Sinir Ağları Yöntemi	
	Lürün grubu satış verileri	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)
Ocak	39711	79265	39554	51301	11590	74677	34966	77857	38146	39687,5	23,5031
Şubat	36673	39711	3038	50409	13736	69574	32901	51155	14482	37835,5	1162,5
Mart	60925	36673	24252	49428	11497	57298	3627	41018	19907	60937,4	12,4435
Nisan	66880	60925	5955	50195	16685	54144	12737	54953	11927	66884,5	4,54975
Mayıs	56140	66880	10740	51237	4903	51047	5093	63302	7162	56139,4	0,56032
Haziran	48498	56140	7642	51526	3028	55155	6657	58289	9791	48425,8	72,2189
Temmuz	72306	48498	23808	51358	20948	58111	14195	51435	20871	72313,5	7,53595
Ağustos	72140	72306	166	52460	19680	60956	11184	66045	6095	76471,8	4331,77
Eylül	65567	72140	6573	53444	12123	62271	3296	70311	4744	74250,5	8683,53
Ekim	74011	65567	8444	54021	19990	64628	9383	66990	7021	74030,8	19,7545
Kasım	52252	74011	21759	54930	2678	71006	18754	71905	19653	52276,2	24,2033
Aralık	70686	52252	18434	54814	15872	65993	4694	58148	12538	70702,7	16,6945

AYLAR	YÖNTEMLER	Son Dönem Talebi Yöntemi		Basit Ortalama Yöntemi		Hareketli Ortalama Yöntemi		Üssel Düzeltme Yöntemi		Yapay Sinir Ağları Yöntemi	
	İ.ürün grubu satış verileri	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)
Ocak	92917	70686	22231	55475	37442	65629	27288	66925	25992	92964,3	47,2532
Şubat	114226	92917	21309	56973	57253	72467	41760	85119	29107	70948,5	43277,5
Mart	92378	114226	21848	59175	33203	82520	9858	105494	13116	77948,1	14429,9
Nisan	50662	92378	41716	60404	9742	92552	41890	96313	45651	50663	1,02391
Mayıs	67803	50662	17141	60056	7747	87546	19743	64357	3446	67800,4	2,6469
Haziran	53193	67803	14610	60324	7131	81267	28074	66769	13576	53813,5	620,524
Temmuz	82247	53193	29054	60086	22161	66009	16238	57266	24981	77935,4	4311,55
Ağustos	70983	82247	11264	62827	8156	63476	7507	74753	3770	70981,2	1,76874
Eylül	72805	70983	1822	65194	7611	68557	4249	72114	691	72810,5	5,48839
Ekim	89375	72805	16570	65439	23936	69807	19568	72598	16777	89375	44,6513
Kasım	56799	89375	32576	66187	9388	78853	22054	84342	27543	56799	2,75488
Aralık	69390	56799	12591	65903	3487	72491	3101	65062	4328	69390	22,4978

AYLAR	YÖNTEMLER	Son Dönem Talebi Yöntemi		Basit Ortalama Yöntemi		Hareketli Ortalama Yöntemi		Üssel Düzeltme Yöntemi		Yapay Sinir Ağları Yöntemi	
	İ.ürün grubu satış verileri	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)	Tahmin	Sapma (Mutlak Hata)
Ocak	68276	69390	1114	86314	18038	72092	3816	68092	184	68276	20,6166
Şubat	74346	68276	6070	68013	6333	70960	3386	68221	6125	74346	1,30172
Mart	81106	74346	6760	85243	4137	67203	13903	72508	8598	81106	16298,5
Nisan	69750	81106	11356	70512	762	73280	3530	78527	8777	69750	32588
Mayıs	68713	69750	1037	84588	15875	73370	4657	72383	3670	68713	22,9645
Haziran	69352	68713	639	72399	3047	73479	4127	69814	462	69352	6,57065
Temmuz	68108	69352	1244	72317	4209	72230	4122	69491	1383	68108	2,59154
Ağustos	48237	68108	19871	72206	23969	68981	20744	68523	20286	48237	9,5862
Eylül	43913	48237	4324	71591	27678	63603	19690	54323	10410	43913	1405,61
Ekim	39698	43913	4215	70899	31201	57403	17705	47036	7338	39698	38,7543
Kasım	39937	39698	239	70138	30201	49989	10052	41899	1962	39937	2739,7
Aralık	44849	39937	4912	69419	24570	42946	1903	40526	4323	44849	18,0766
Hata Toplamı			545830		567877		518860		498551		168518

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Müzeyyen Tuğba BALLI
Doğum Tarihi ve Yeri : 05.01.1988
Yabancı Dili : İngilizce, Almanca
E-posta : tubaballi@hotmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Endüstri Mühendisliği	Okan Üniversitesi	2011
Lisans	Uluslararası Lojistik	Okan Üniversitesi	2011
Lise	Fen	Kocaeli Anadolu Lisesi	2006

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2013-..	NAMET Gıda San. ve Tic. A.Ş.	Üretim Planlama Mühendisi