



AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ



Buse Ceren AKBAŞ

TEDARİK ZİNCİRİ YÖNETİMİNDE YAPAY ZEKA TABANLI TALEP
TAHMİNİ: BİR TEKSTİL FİRMASINDA UYGULAMA

Uluslararası Ticaret ve Lojistik Ana Bilim Dalı
Yüksek Lisans Tezi

Antalya, 2022



AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ



Buse Ceren AKBAŞ

TEDARİK ZİNCİRİ YÖNETİMİNDE YAPAY ZEKA TABANLI TALEP TAHMİNİ: BİR
TEKSTİL FİRMASINDA UYGULAMA

Danışman

Doç. Dr. Fahriye MERDİVENCİ

Uluslararası Ticaret ve Lojistik Ana Bilim Dalı

Yüksek Lisans Tezi

Antalya, 2022

Akdeniz Üniversitesi
Sosyal Bilimler Enstitüsü Müdürlüğüne,

Buse Ceren AKBAŞ'ın bu çalışması, jürimiz tarafından Uluslararası Ticaret ve Lojistik Ana Bilim Dalı Yüksek Lisans Programı tezi olarak kabul edilmiştir.

Başkan : Prof. Dr. Şerife Gözde YİRMİBEŞOĞLU (İmza)

Üye (Danışmanı) : Doç. Dr. Fahriye MERDİVENÇİ (İmza)

Üye : Dr. Öğr. Üyesi Hacer YUMURTACI AYDOĞMUŞ (İmza)

Tez Başlığı: TEDARİK ZİNCİRİ YÖNETİMİNDE YAPAY ZEKA TABANLI TALEP TAHMİNİ: BİR TEKSTİL FİRMASINDA UYGULAMA
--

Onay: Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

Tez Savunma Tarihi :20/06/2022

Mezuniyet Tarihi : 28/07/2022

(İmza)
Prof. Dr. Ebru İÇİGEN
Müdür

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Tedarik Zinciri Yönetiminde Yapay Zekâ Tabanlı Talep Tahmini: Bir Tekstil Firmasında Uygulama” adlı bu çalışmanın, akademik kural ve etik değerlere uygun bir biçimde tarafımda yazıldığını, yararlandığım bütün eserlerin kaynakçada gösterildiğini ve çalışma içerisinde bu eserlere atıf yapıldığını belirtir; bunu şerefimle doğrularım.

İmza

Buse Ceren AKBAŞ



T.C.
AKDENİZ ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
TEZ ÇALIŞMASI ORJİNALLİK RAPORU
BEYAN BELGESİ



SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜ'NE

ÖĞRENCİ BİLGİLERİ	
Adı-Soyadı	Buse Ceren AKBAŞ
Öğrenci Numarası	20185265001
Enstitü Ana Bilim Dalı	Uluslararası Ticaret ve Lojistik Ana Bilim Dalı
Programı	Tezli Yüksek Lisans
Programın Türü	(X) Tezli Yüksek Lisans () Doktora () Tezsiz Yüksek Lisans
Danışmanın Unvanı, Adı-Soyadı	Doç.Dr. Fahriye MERDİVENCİ
Tez Başlığı	TEDARİK ZİNCİRİ YÖNETİMİNDE YAPAY ZEKA TABANLI TALEP TAHMİNİ: BİR TEKSTİL FİRMASINDA UYGULAMA
Turnitin Ödev Numarası	1867649210

Yukarıda başlığı belirtilen tez çalışmasının a) Kapak sayfası, b) Giriş, c) Ana Bölümler ve d) Sonuç kısımlarından oluşan toplam 81 sayfalık kısmına ilişkin olarak, 07/07/2022 tarihinde tarafımdan Turnitin adlı intihal tespit programından Sosyal Bilimler Enstitüsü Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Uygulama Esasları'nda belirlenen filtrelemeler uygulanarak alınmış olan ve ekte sunulan rapora göre, tezin/dönem projesinin benzerlik oranı;

alıntılar hariç % 8

alıntılar dahil % 14'tür.

Danışman tarafından uygun olan seçenek işaretlenmelidir:

(X) Benzerlik oranları belirlenen limitleri aşmıyor ise;

Yukarıda yer alan beyanın ve ekte sunulan Tez Çalışması Orijinallik Raporu'nun doğruluğunu onaylarım.

() Benzerlik oranları belirlenen limitleri aşıyor, ancak tez/dönem projesi danışmanı intihal yapılmadığı kanısında ise;

Yukarıda yer alan beyanın ve ekte sunulan Tez Çalışması Orijinallik Raporu'nun doğruluğunu onaylar ve Uygulama Esasları'nda öngörülen yüzdeler sınırlarının aşılmasına karşın, aşağıda belirtilen gerekçe ile intihal yapılmadığı kanısında olduğumu beyan ederim.

Gerekçe:

Benzerlik taraması yukarıda verilen ölçütlerin ışığı altında tarafımda yapılmıştır. İlgili tezin orijinallik raporunun uygun olduğunu beyan ederim.

07/07/2022

(imzası)

Doç. Dr. Fahriye MERDİVENCİ

İÇİNDEKİLER

ŞEKİLLER LİSTESİ	iv
TABLOLAR LİSTESİ	v
KISALTMALAR LİSTESİ.....	vi
ÖZET	vii
SUMMARY	viii
TEŞEKKÜR.....	ix
ÖNSÖZ	x
GİRİŞ.....	1

BİRİNCİ BÖLÜM

TEDARİK ZİNCİRİ VE STOK YÖNETİMİ

1.1.	Tedarik Zinciri Kavramı	3
1.2.	Tedarik Zinciri Yönetiminin Önemi.....	4
1.3.	Tedarik Zincirinde Stok Kavramı	5
1.3.1.	Stok Çeşitleri	5
1.3.2.	Stok Bulundurma Nedenleri	6
1.3.3.	Stok Maliyetleri	6
1.4.	Tedarik Zincirinde Stok Yönetimi.....	7
1.4.1.	Stok Kontrol Yöntemleri	8
1.4.1.1.	Gözle Kontrol Yöntemi	8
1.4.1.2.	Çift Kutu Yöntemi	9
1.4.1.3.	Sabit Sipariş Miktarı Yöntemi.....	9
1.4.1.4.	Sabit Sipariş Periyodu Yöntemi	9
1.4.1.5.	ABC Analizi	10
1.4.1.6.	Maksimum-Minimum Yöntemi.....	11
1.4.1.7.	Ekonomik Sipariş Miktarı Modeli.....	11

İKİNCİ BÖLÜM

TALEP TAHMİNİ

2.1.	Talep Tahmini Kavramı ve Önemi.....	14
2.2.	Talep Tahmininin Adımları	15
2.3.	Talep Tahmin Yöntemleri	15

2.3.1.	Nitel Tahmin Yöntemleri.....	16
2.3.1.1.	Uzman Görüşlerinin Esas Alınması	16
2.3.1.2.	Kilit Personelin Kararı.....	16
2.3.1.3.	Anket Yöntemi	17
2.3.1.4.	Delphi Tekniği.....	17
2.3.1.5.	Senaryo Analizi	17
2.3.2.	Nicel Tahmin Yöntemleri.....	18
2.3.2.1.	Nedensel Yöntemler	18
2.3.2.2.	Zaman Serisi Yöntemleri.....	20
2.3.3.	Yapay Zeka Tabanlı Yöntemler	24
2.3.3.1.	Yapay Sinir Ağları.....	25
2.3.3.2.	Bulanık Mantık	26
2.3.3.3.	Genetik Algoritma	27
2.4.	Talep Tahmininin Doğruluğu ve Yöntem Seçimi	28
2.5.	Tedarik Zincirinde Talep Tahmini	29

ÜÇÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ

3.1.	Yapay Sinir Ağlarının Tanımı	31
3.2.	Yapay Sinir Ağlarının Tarihçesi.....	32
3.3.	Yapay Sinir Ağlarının Genel Özellikleri	32
3.4.	Yapay Sinir Ağlarının Avantaj ve Dezavantajları.....	33
3.5.	Yapay Sinir Ağlarının Yapısı ve Elemanları.....	35
3.5.1.	Biyolojik Sinir Hücresi.....	35
3.5.2.	Yapay Sinir Hücresi	36
3.5.3.	Yapay Sinir Ağlarının Yapısı	39
3.6.	Yapay Sinir Ağlarının Sınıflandırılması.....	40
3.6.1.	Tiplerine Göre Yapay Sinir Ağları	40
3.6.1.1.	İleri Beslemeli Yapay Sinir Ağları	40
3.6.1.2.	Geri Beslemeli Yapay Sinir Ağları.....	41
3.6.2.	Öğrenme Yöntemlerine Göre Yapay Sinir Ağları.....	41
3.6.2.1.	Öğretmenli (Danışmanlı) Öğrenme	42
3.6.2.2.	Öğretmensiz (Danışmansız) Öğrenme	42

3.6.2.3.	Destekleyici (Takviyeli) Öğrenme	43
3.6.2.4.	Yapay Sinir Ağlarında Öğrenme Kuralları.....	43
3.6.3.	Katman Sayılarına Göre Yapay Sinir Ağları.....	44
3.6.3.1.	Tek Katmanlı Yapay Sinir Ağları.....	44
3.6.3.2.	Çok Katmanlı Yapay Sinir Ağları	45
3.6.4.	Yapısına Göre Yapay Sinir Ağları	46
3.7.	Yapay Sinir Ağlarının Tasarımı ve Eğitimi.....	47
3.7.1.	Yapay Sinir Ağları Ağ Yapısının Seçimi	48
3.7.2.	Öğrenme Algoritmasının Seçimi	48
3.7.3.	Ara Katman Sayısının Belirlenmesi	49
3.7.4.	Nöron Sayısının Belirlenmesi.....	49
3.7.5.	Normalizasyon.....	50
3.7.6.	Performans Fonksiyonu Seçimi.....	50
3.8.	Yapay Sinir Ağlarının Uygulama Alanları	50
3.9.	Literatür Araştırması.....	51

DÖRDÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ ÜZERİNE BİR UYGULAMA

4.4.1.	Tahmin Süreci Tasarımı	63
4.4.2.	Veri Setinin Hazırlanması	63
4.4.2.1.	Bağımlı Değişkenler	64
4.4.2.2.	Bağımsız Değişkenler.....	64
4.4.3.	Yapay Sinir Ağı Modelinin Seçimi	68
4.4.3.1.	Modelin Tasarımı ve Matlab Uygulaması	69
4.4.4.	YSA ile Elde Edilen Tahmin Sonuçları.....	76

SONUÇ	78
KAYNAKÇA.....	80
EKLER	88
ÖZGEÇMİŞ	94

ŞEKİLLER LİSTESİ

Şekil 1.1 ABC Stok Kontrolünde Sınıflandırma.....	10
Şekil 1.2 Ekonomik Sipariş Miktarı Modeli	12
Şekil 1.3 Ekonomik Sipariş Modeli	13
Şekil 2.1 Yapay Sinir Ağları Yöntemi ve Geleneksel Yöntemlerle Talep Tahmini Adımları.....	26
Şekil 2.2 Genel Bulanık Mantık Yapısı	27
Şekil 2.3 Genetik Algoritma Akış Diyagramı	28
Şekil 3.1 Biyolojik Sinir Hücresi Yapısı	36
Şekil 3.2 Yapay Sinir Hücresi Yapısı.....	37
Şekil 3.3 Yapay Sinir Ağı Yapısı	39
Şekil 3.4 Yapay Sinir Ağlarının Sınıflandırılması	40
Şekil 3.5 İleri Beslemeli Yapay Sinir Ağları.....	40
Şekil 3.6 Geri Beslemeli Yapay Sinir Ağları	41
Şekil 3.7 Tek Katmanlı Yapay Sinir Ağları	45
Şekil 3.8 Çok Katmanlı Yapay Sinir Ağları.....	46
Şekil 4.1 Terbiye İşlemleri Akış Şeması.....	58
Şekil 4.2 Tekstil Sektörü Proses Aşamaları	59
Şekil 4.3 ABC Analizi Eğrisi	62
Şekil 4.4 Uygulamada Kullanılan Yapay Sinir Ağı Modeli.....	69
Şekil 4.5 Transpoze Formülleri	71
Şekil 4.6 NNToolBox Arayüzü	71
Şekil 4.7 Parametre Arayüzü.....	72
Şekil 4.8 MATLAB Yapay Sinir Ağı Modeli	72
Şekil 4.9 MATLAB Yapay Sinir Ağı Eğitim Ekranı	73
Şekil 4.10 MATLAB Yapay Sinir Ağı Performans Grafiği.....	73
Şekil 4.11 MATLAB Yapay Sinir Ağı Regresyon Değerleri	74
Şekil 4.12 MATLAB Eğitim Çıktıları Karşılaştırma	75
Şekil 4.13 MATLAB Yapay Sinir Ağı Test Ekranı	76
Şekil 4.14 YSA Tahmin Değerleri ile Gerçek Değerlerin Karşılaştırılması	77

TABLolar LİSTESİ

Tablo 3.1 Biyolık Sinir Ağları ile Yapay Sinir Ağları Karşılaştırması	38
Tablo 3.2 Ağ Türleri ve Kullanım Amacı.....	48
Tablo 3.3 Uygulama Tiplerine Göre Kullanılabilir Yapay Sinir Ağları.....	49
Tablo 4.1 ABC Analizi Veri Tablosu	61
Tablo 4.2 ABC Analizi Sınıf Tablosu	61
Tablo 4.3 Bağımlı – Bağımsız Değişkenler	63
Tablo 4.4 Aylık PB İşlem Grubu Satış Verileri.....	64
Tablo 4.5 Aylık Döviz Kuru Verileri.....	65
Tablo 4.6 Aylık TÜFE Verileri.....	65
Tablo 4.7 Aylık ÜFE Verileri	66
Tablo 4.8 Aylık Amerikan Pamuk Fiyat Verileri	66
Tablo 4.9 Aylık Tekstil ve Hammaddeleri İhracat Verileri	67
Tablo 4.10 Aylık Tekstil Ürünleri İthalat Verileri.....	67
Tablo 4.11 Yöntem Parametreleri.....	70
Tablo 4.12 MATLAB Eğitim Çıktıları	74
Tablo 4.13 MATLAB YSA Tahmin Performansı	76
Tablo 4.14 YSA Tahmin Değerleri ile Gerçek Değerlerin Karşılaştırılması.....	76

KISALTMALAR LİSTESİ

AB	Akar Boya
ABC	Always Better Control
AHP	Analitik Hiyerarşi Proses
CBM	Durum Bazlı Bakım
D	Diğer İşlemler
DB	Düz Boya
DISPERS	Dispers Baskı
DİGİTAL	Digital Baskı
DVM	Destek Vektör Makinesi
ERP	Kurumsal Kaynak Planlama
İMKB	İstanbul Menkul Kıymetler Borsası
İND	Indantren Boya
K	Beyaz
KES	Kawabata Değerlendirme Sistemi
KY	Kenar Yazı
LVQ	Linear Vektör Quantization
MLP	Çok Katmanlı Algılayıcı
MLR	Çoklu Doğrusal Regresyon
MRP	Malzeme İhtiyaç Planlama
MSE	Hata Karelerin Ortalaması
PB	Pigment Baskı
RB	Reaktif Baskı
RBFN	Radyal Tabanlı Fonksiyon Ağ
SCM	Supply Chain Management
TCMB	Türkiye Cumhuriyeti Merkez Bankası
TİM	Türkiye İhracatçılar Meclisi
TÜFE	Tüketici Fiyat Endeksi
TÜİK	Türkiye İstatistik Kurumu
TZ	Tedarik Zinciri
TZY	Tedarik Zinciri Yönetimi
ÜFE	Üretici Fiyat Endeksi
YSA	Yapay Sinir Ağı

ÖZET

İşletmeler, günümüz küreselleşen dünyada artan maliyetler ve dijitalleşme sonucu değişen rekabet koşullarına karşı ayakta kalabilmek için karşılaştıkları çeşitli sorunlara etkin çözümler üretilip karar vermek zorundadırlar. Bu bağlamda Tedarik Zincirini doğru yönetmek çok önemlidir. Sürprizlerle karşılaşmamak, maliyetleri önceden belirleyip öngörmek ve bu öngörülerini tutarlı kılmak tahmin ile mümkün olur. Talep tahminlerinin yüksek doğrulukla elde edilmesi, tüm tedarik zinciri yönetimi süreçlerinin başarısı için kilit bir faktördür.

Yaşanan küresel pandemi sebebiyle ülkeler arası seyahat ve ticari faaliyetlere getirilen kısıtlamalar en büyük değişikliklerin tedarik zincirinde yaşanmasını sağlamıştır ve tedarik zinciri yönetimini olumsuz etkilemiştir. Bu etkiler otomotiv yedek parça sektöründen gıda sektörüne, tekstilden turizme kadar birçok sektörü uzun süre etkilemeye devam etmiştir. Bu yüzden en çok etkilenen sektörlerden biri olan tekstil sektöründe değişen talebin doğru ve hızlı bir şekilde tahmini işgücü ve kaynak planlamalarının etkin bir şekilde yapılması açısından önem arz etmektedir.

Tahminin amacı işletmelerin gelecekte karşılaşabilecekleri durumları önceden öngörmek, çeşitli veri ve teknikleri kullanarak önceden önlemler alınmasını sağlamaktır. Bu sebeple yapılan çalışmada, istatistiksel talep tahmin yöntemlerinden yapay sinir ağları kullanılarak işletmeye bir tahmin modeli önerilmiştir.

Çalışmada, tekstil sektöründe faaliyet gösteren bir işletme ele alınmıştır. Tekstil sektöründe faaliyet gösteren firmanın 2018-2021 yılları arasındaki satış verileri alınarak araştırmaya dahil edilmiştir. MATLAB programı ile satış verileri kullanılarak tahmin modeli oluşturulmuştur. Eğitim verileri ile çıktı verileri karşılaştırılmıştır. Uygulama sonrası yapılan hata testi sonuçları, modelin yaptığı tahminlerin güvenilir ve tutarlı olduğunu göstermiştir.

Anahtar Kelimeler: Tedarik Zinciri Yönetimi, ABC Analizi, Talep Tahmini, Yapay Sinir Ağları, MATLAB

SUMMARY

AI-BASED DEMAND FORECAST IN SUPPLY CHAIN MANAGEMENT: IMPLEMENTATION IN A TEXTILE COMPANY

In today's globalizing world, businesses have to produce effective solutions and decide on various problems they encounter in order to survive against the changing competitive conditions as a result of increasing costs and digitalization. In this context, it is very important to manage the Supply Chain correctly. It is possible to avoid surprises, to predict and predict costs, and to make these predictions consistent with forecasting. Obtaining demand forecasts with high accuracy is a key factor for the success of all supply chain management processes.

Restrictions on international travel and commercial activities due to the global pandemic have caused the biggest changes in the supply chain and adversely affected the supply chain management. These effects continued to affect many sectors for a long time, from the automotive spare parts sector to the food sector, from textiles to tourism. For this reason, accurate and fast estimation of the changing demand in the textile sector, which is one of the most affected sectors, is important in terms of effective workforce and resource planning.

The purpose of forecasting is to predict the situations that businesses may encounter in the future and to take precautions in advance by using various data and techniques. For this reason, in this study, a forecasting model was proposed to the enterprise by using artificial neural networks, one of the statistical demand forecasting methods.

In the study, a business operating in the textile sector is discussed. The sales data of the company operating in the textile sector between the years 2018-2021 were taken and included in the research. A forecasting model was created using the sales data with the MATLAB program. Training data and output data were compared. Error test results after the application showed that the predictions made by the model were reliable and consistent.

Keywords: Supply Chain Management, ABC Analysis, Demand Forecasting, Artificial Neural Networks, MATLAB

TEŐEKKÜR

Yüksek lisans tez çalışmam süresinde desteęini esirgemeyen ve önerileri ile beni yönlendiren, her zaman ulaşabildiğim danışmanım Sayın Doç. Dr. Fahriye MERDİVENCI'ye ve tezimin tamamlanmasında emeęi geçen Öğr. Gör. Hayrullah ALTINOK'a teşekkür ederim.

Varlıkları ve destekleri ile her zaman yanımda olduklarını hissettiren başta canım annem ve aileme, bana benden daha çok inanan Hasan GÜNDÜZ'e teşekkür ederim.

Buse Ceren AKBAŐ

ÖNSÖZ

Günümüz küreselleşen dünyada tedarik zinciri yönetimi, işletmeler arasında önemli bir rekabet unsurudur. Artan maliyetler ve dijitalleşme sonucu değişen rekabet koşullarına karşı işletmeler ayakta kalabilmek için karşılaştıkları çeşitli sorunlara etkin çözümler üretilip karar vermek zorundadırlar. Artık rekabet işletmeler arasında değil daha çok tedarik zincirleri arasında olmaya başlamıştır. Bu yüzden tedarik zincirinin doğru yönetmek gerekmektedir. Tedarik zinciri yönetiminde amaç son kullanıcıya doğru ürünün, doğru yerde, doğru biçimde, doğru zamanda, doğru miktarda, doğru kalitede ve düşük maliyetli olarak sağlanabilmesidir. Bu amaca ulaşmak için tedarik zincirinde süreçlerinin doğru ve etkin yönetilmesi gerekmektedir.

Yaşanan küresel pandemi sebebiyle ülkeler arası seyahat ve ticari faaliyetlere getirilen kısıtlamalar en büyük değişikliklerin tedarik zincirinde yaşanmasını sağlamıştır ve tedarik zinciri yönetimini olumsuz etkilemiştir. Bu etkiler otomotiv yedek parça sektöründen gıda sektörüne, tekstilden turizme kadar birçok sektörü uzun süre etkilemeye devam etmiştir. Bu yüzden en çok etkilenen sektörlerden biri olan tekstil sektöründe değişen talebin doğru ve hızlı bir şekilde tahmini işgücü ve kaynak planlamalarının etkin bir şekilde yapılması açısından önem arz etmektedir.

Bu yüksek lisans çalışmasında ilk olarak tedarik zinciri ve tedarik zinciri yönetiminde talep tahminin öneminden bahsedilmiştir. Daha sonra literatürde kullanılan talep tahmin yöntemleri ayrıntılı olarak incelenmiştir. Yapılan talep tahminin öneminden bahsedildikten sonra, literatürde yer alan nitel, nicel ve yapay zeka tabanlı yöntemler sunulmuştur. Uygulamada da kullanılacak olan yapay zeka tabanlı talep tahmin yöntemlerinden biri olan yapay sinir ağları yöntemi detaylı bir şekilde incelenerek, bir uygulama problemi üzerinde yöntemin başarısı test edilmiştir.

Uygulamada tekstil sektöründe faaliyet gösteren bir işletmenin satış verileri ele alınmıştır. Tekstil sektöründe faaliyet gösteren firmanın 2018-2021 yılları arasındaki satış verileri araştırmaya dahil edilmiştir. MATLAB programı ile satış verileri kullanılarak tahmin modeli oluşturulmuştur. Eğitim verileri ile çıktı verileri karşılaştırılmıştır. Uygulama sonrası yapılan hata testi sonuçları, modelin yaptığı tahminlerin güvenilir ve tutarlı olduğunu göstermiştir.

GİRİŞ

Günümüzde işletmeler globalleşen dünyada ve dijitalleşme ile birlikte artan rekabetle beraber şirketler müşterilerine en iyi hizmeti sunma yarışı içerisinde olduklarıdır. Bunu yaparken ürünlerini istenen zamanda ve miktarda minimum maliyetle müşterilerine ulaştırmaya çalışırlar. Tedarik zinciri bu döngüde en önemli rollerden birini üstlenmektedir.

Tedarik zincirinin doğru yönetimi, işletmeler arasında önemli bir rekabet unsurudur. Tedarik zincirinin doğru yönetilmesinde önemli bir adım olan planlamanın temeli tahmine dayanmaktadır. Tedarik zincirinde oluşacak taleplerin tahmin edilebilmesi, tedarik zincirini doğru yönetmek için son derece önemlidir.

Yaşanan küresel pandemi sebebiyle ülkeler, şehirler arası seyahat etme yasakları ve mevcut ticari faaliyetlere uygulanan kısıtlamalar en büyük değişikliklerin tedarik zincirinde yaşanmasını sağlamıştır ve tedarik zinciri yönetimini olumsuz etkilemiştir. Bu olumsuz etkiler otomotiv ve gıda sektörü başta olmak üzere, tekstil sektöründen turizme sektörüne kadar birçok sektörü uzun süre etkilemiştir. Tekstil sektörü bu etkilerden doğrudan etkilenmiştir. Tekstil sektöründe değişken olan talebin en doğru ve en hızlı şekilde tahmin edilmesi tedarik zinciri yönetimi açısından oldukça önemlidir.

Ülkemizin ekonomi dağılımında payı ve önemi oldukça fazla olan tekstil sektöründe faaliyet gösteren işletmeler giderek çoğalan rekabet koşullarıyla karşı karşıya kalmaktadır. Tekstil işletmeleri bu rekabet koşullarının yanında maliyetlerini etkileyen pamuk fiyatlarında olan artışlar ve döviz kurlarında yaşanan ani değişimlere de hazırlıklı olmak zorundadır. Bu yüzden tedarik zinciri süreçlerini doğru yönetebilmek için daha net tahminlere gereksinim duymaktadır.

Bu yüksek lisans tez çalışmasındaki temel amaç, işletme için geliştirilecek yapay sinir ağı tahmin modeli ile satış tahmini yapabilecek duruma gelmesi ve üretim için tedarik zincirindeki farklı senaryolara cevap verebilme kabiliyeti kazanabilmesidir. Bu sayede gereksiz stok maliyetlerinden veya stok yetersizliklerinden kaçınılabileceği düşünülmektedir.

Birinci bölümde ilk olarak tedarik zinciri kavramı açıklanacaktır. Sonra Tedarik zinciri yönetimi kavramı açıklanacak ve tedarik zincirinde stok kavramı üzerinde durulacaktır. Stok çeşitleri, stok kontrol yöntemlerinden bahsedildikten sonra tahmin konusuna geçilecektir.

İkinci bölümde tahmin yöntemleri anlatılacaktır. Tahmin yöntemlerinin temelde üçe ayrıldığı ve bunların nitel, nicel ve yapay zeka tabanlı yöntemler olduğu açıklanacaktır. İkinci

bölümde son olarak talep tahmininin doğruluğundan ve seçiminden bahsedilecektir ve üçüncü bölüme geçilecektir.

Üçüncü bölümde yapay sinir ağları detaylı olarak yer alacaktır. Daha sonra yapay sinir ağlarının türleri hakkında ayrıntılı bilgi verilecek ve uygulama bölümüne geçilecektir.

Uygulama bölümünde ilk olarak çalışmanın gerçekleştirildiği şirket hakkında bilgi verilmiştir. Çalışma, tekstil sektöründe faal olan bir işletme ile gerçekleştirilmiştir. Tekstil sektöründeki bu firmanın 2018-2021 yılları arasındaki satış verileri kullanılarak araştırmaya dahil edilmiştir. Daha sonra geçmiş yıllara ait satış verilerine ABC Analizi uygulanmıştır. Analiz sonucu çıkan A grubu satış verilerinden en çok tercih edilen seçilmiştir. Daha sonra satışları etkileyen değişkenler şirket çalışanları ile birlikte belirlenmiştir. ABC analizi sonucu seçilen ürün grubuna belirlenen satış etkileyen değişkenler ile birlikte yapay sinir ağları modeline ait ileri beslemeli geri yayımlı modeli kullanılarak tahmin işlemi gerçekleştirilmiştir. MATLAB programı kullanılarak satış verileri ile tahmin modeli oluşturulmuştur. Eğitim verileri ile çıktı verileri karşılaştırılmıştır.

Uygulamadan sonra yapılan hata testinin sonuçlarına göre, modelin yaptığı tahminlerin güvenilir ve tutarlı olduğunu göstermiştir.

BİRİNCİ BÖLÜM

TEDARİK ZİNCİRİ VE STOK YÖNETİMİ

1.1. Tedarik Zinciri Kavramı

Literatürde birçok Tedarik Zinciri tanımı mevcuttur. Tedarik Zinciri Konseyi'nin tanımına göre, kavram olarak Tedarik Zinciri nihai ürünün üretilmesi ve tedarikçinin tedarikçisinden müşterinin müşterisine kadar olan dağıtım ile ilgili bütün çalışmaları kapsar (The Supply Chain Council, 2001).

Tedarik zinciri, hammaddelerin nihai ürünlere dönüştürülmesi ile başlayan ve son müşteriye teslim edilmesi ile son bulan bir üretim sürecidir. Tedarik zinciri, hammaddelerin tedarik süreci ile başlayan ve son ürünlerin son tüketiciye ulaştırılmasıyla büyüyen birbiriyle bağlantılı bir kaynak ve süreçler kümesidir. Bu yüzden tedarik zincirinin, hammaddelerin ürün haline dönüştürülmesi ve son kullanıcıya taşınması için organizasyonların dahil olduğu süreç entegrasyonunun genel bir tanımı olduğu söylenebilmektedir (JanvierJames, 2012).

Modern tedarik zinciri tanımında ise tedarik zinciri, yalnızca tedarikçiler, üreticiler, toptancılar, perakendeciler ve müşteriler değil; aynı zamanda tedarikçinin tedarikçileri, müşterinin müşterileri de dahil olmak üzere geniş ve karmaşık birbirine bağlı birimler ağından oluşan çok daha karmaşık yapılar hale gelmiştir (Mari vd., 2015).

Özetle tedarik zincirini tanımlamak gerekirse, ürünlerin başlangıç noktası olan hammadde halinden son halinin tüketim noktasında kadar gerçekleşen tüm süreçleri kapsayan dinamik bir yapıdır.

Tedarik Zincirinin etkin ve verimli bir şekilde kullanılmasını sağlamak ise Tedarik Zinciri Yönetimidir (TZY). TZY'nin temel amacı doğru ürünün, doğru yerde, doğru zamanda, doğru miktarda, doğru şekilde ve doğru kalitede tedarik edilmesidir.

Tedarik zinciri yönetiminde, her bir zincir üyesinin amacı, güncel bilgileri zincirdeki diğer işletmelere iletmek ve bu sayede daha doğru arz ve talep dengesi sağlamaktır. Tedarik zincirinin kısa vadede amacı, gereksiz stokları ortadan kaldırmak ve üretimi doğru planlayarak müşteriye daha hızlı cevap vermeyi sağlamaktır. Uzun vadede amacı ise, müşterilerin beklentilerini doğru yerde teslim edilmiş doğru ürünle karşılamaktır. Bu şekilde pazar payını ve kârları artmaktadır. Tedarik zinciri yönetiminde, ürünü kaynağından tüketim noktasına en kısa zamanda ve en düşük maliyette götürmek esastır (Çiçek ve Murat, 2007).

Tedarik zinciri yönetimini yapısal olarak değerlendirmek istersek, tedarik zincirinin ve tedarik zinciri yönetiminin işletmeler için ne kadar önemli olduğunu ve işletmeler için başarının anahtarının bu zincirin halkalarına bağlı olduğunu anlayabiliriz. Tedarik zinciri yönetimiyle ilgili tanımlar çok fazladır ve hepsi temelde aynı anlamı taşır. Tedarik zincirinin yönetimi, hammaddenin tedarik zincirine girdiği ilk noktadan son kullanıcıya teslim edildiği son noktaya kadar gerçekleşen tedarik zincirindeki hareketlerdir. Bu hareketler hem yukarı hem de aşağı yönlü gerçekleşir. Bu hareketler doğrultusunda tüm malzeme ve bilgi akışlarının kontrol ve koordinasyonunu kapsayan bir faaliyettir (Eymen, 2007).

1.2. Tedarik Zinciri Yönetiminin Önemi

TZY'nin işletmelere sağladığı faydalar arasında işletmelerin kaynaklarını gereksiz kullanımından kaçınması ve zamandan tasarruf etmek başta gelir. Bunların yanında diğer faydalardan da bahsedebiliriz (The Supply Chain Council, 2001).

Bu faydalardan bazılarını Tedarik Zinciri Konseyi şu şekilde ifade edilmiştir (The Supply Chain Council, 2001),

- 1) Teslimat performansının iyileştirmek.
- 2) Stokları azaltmak.
- 3) Çevrim süresini kısaltmak.
- 4) Tahmin doğruluğunu artırmak.
- 5) Zincir boyunca verimliliği artırmak.
- 6) Zincir boyunca maliyetleri düşürmek.
- 7) Kapasite gerçekleştirme oranını artırmak.

Bunlar ve daha fazla faydalar aynı zincirde yer alan işletmelerin (tedarikçi, üretici, toptancı, perakendeci, müşteri vb.) arasında tam bir iletişimin kurulması, zincir boyunca gerçekleşen faaliyetlerin koordinasyonu ve kontrolü sayesinde ortak amaç olarak belirlenen zincirin bütününde maliyetlerin azaltılması, verimliliğin artırılması, karlılık ve müşteri tatmini gibi amaçlara ulaşmak üzere elde edilebilir (Özdemir, 2004).

TZY'den beklenen faydaların gerçekleşmesinde önemli başarı faktörlerinden biri de tedarik zinciri üyeleri arasındaki koordinasyon ve entegrasyonu sağlayan bilgi akışıdır (Swaminathan vd., 1998).

Tedarik zinciri üyeleri arasındaki koordinasyon ve bilgi akışı sayesinde talepte oluşan belirsizlikler azalır, bu sayede zincirdeki işletmelerin stok maliyetleri azalır. Stok maliyetlerini azaltmak planlamanın daha kolay yapılmasını ve maliyetlerde azalmayı sağlayacaktır.

Ayrıca işletmeler arasında oluşacak güven ve işbirliği sonucunda risklerin paylaşılması, işletmeler arasındaki mesafenin azaltılması ve esnekliğin artırılmasıyla yeni ürün geliştirme ve pazara sunma süreleri kısalmıştır. Bu sayede rakiplere karşı büyük avantajlar sağlanabilir. Bu sayede müşterin ihtiyaçları karşılanacağı için müşterilerin tatmin düzeylerinde artışlar sağlanabilir. Bütün bunların maddi karşılığı olarak da tedarik zinciri boyunca nakit düzenli akar ve firmaların maliyetleri düşeceği için karlılıkları artar (Özdemir, 2004).

1.3. Tedarik Zincirinde Stok Kavramı

Stoklar, genelde talepteki beklenmeyen değişimlere hızlı cevap verebilmek ve tedarikteki belirsizliklere karşı korunmak için tutulur. Büyük miktarlarda tutulan stoklar, müşteri memnuniyetini garantiler ancak tedarik zinciri boyunca etkisi olan en büyük maliyet kalemleridir (Tanrıverdi, 2010).

Tedarik zinciri üyeleri arasında iş birliği olmadığı zaman tedarikçiden müşteriye olan akışta bilgi kaybı olacaktır. Bu bilgi kaybı sipariş üretiminde ve transferinde de gecikmeye yol açacağı gibi, yanlış zamanlarda ve düzensiz teslimatlara da sebep olacaktır. Bu durum literatürde Kamçı Etkisi olarak bilinir. Zincirde tüketicinin talebinde oluşacak küçük dalgalanmalar, üreticiye doğru ilerledikçe büyük talep dalgalanmalarına sebep olmaktadır (Tanrıverdi, 2010).

Tedarik zincirinde oluşan kamçı etkisi sebebiyle stokların artması beklenir. Stokların artması hem stok maliyetlerin oluşmasına hem de gereğinden fazla paranın stoklara bağlanmasına sebep olmaktadır.

3.6.1. Stok Çeşitleri

İşletmeler tedarik zinciri boyunca dört çeşit stok çeşidi ile karşılaşabilir. Bunlar hammadde stokları, yarı mamul stokları, mamul stokları ve tamamlayıcı stoklarıdır (Kobu, 2006). Zincirde stok bulundurulması, istenmeyen stok maliyetlerine neden olacağı için tedarik zinciri işlemlerinde etkili yönetilmelidir. (Doğar, 2006).

1. Hammadde Stokları: İşletmelerde ürünü oluşturacak ilk maddelerdir. Üretime giren ve üzerinde proses uygulanarak değer kazandırılan tüm varlıklar hammaddedir (Doğar, 2006).

2. Yarı Mamul Stokları: Üzerlerinde yapılması gereken prosesler henüz bitmemiş devam eden ve iş istasyonları arasındaki ara depolarda biriktirilen varlıklardır. Bunların yarı mamul durumu, son işlemlerin tamamlanması ile birlikte son bulur ve mamule dönüşür (Karahan, M. ve Aslan, Ş., 2016).

3. Mamul Stoklar: İşlemlerin bitmiş, ürünün son halini almış şeklinin stoklarıdır. Tüm proseslerin tamamlanıp, müşteriye teslim edilmek üzere depoya konulan varlıklardır. Mamul stoklar, planlanan bütün prosesleri tamamlayıp belirlenen noktada hareketsiz durdukları için, sayma, değerlendirme ve kontrol açısından kolaylık sağlarlar. Hammadde ve yarı mamul stoklarda belirsizlik biraz daha fazla olduğu için kontrolleri daha güçtür (Doğar, 2006).

4. Tamamlayıcı Stoklar: Son ürünün meydana gelmesinde kullanılan ancak hammadde ve yarı mamulden farklı olan malzeme stoklarıdır (Kobu, 2006).

3.6.2. Stok Bulundurma Nedenleri

İşletmeler birçok sebepten dolayı stok bulundurmaya zorunda kalırlar. Gelen talep ve talebi karşılamak için oluşan tedarik fonksiyonlarının senkronize edilmesinin zorluğu işletmeleri stok tutmaya zorlamaktadır.

Bir tedarik zincirinde hangi aşamada ne kadar stok tutulacağı ile ilgili üç çeşit karar verilebilir. İlk karar, ürün için talep edilen satın alma ile gerçekleşen satın alma arasındaki talebi dengelemek için tutulan stok çevrimidir. Diğerleri ise belirsizliğe karşı tutulan emniyet stoku ve mevsimsel talep artışlarına karşı tutulan sezonluk stoktur. Bu üç karar tedarik zincirindeki belirsizliklere karşı tampon görevi görmektedir (Tanrıverdi, 2010).

3.6.3. Stok Maliyetleri

Stok için uygulanacak politikalarının belirlenmesinde, stok sisteminin işlemesi sırasında ortaya çıkan maliyetler önemlidir. Bu maliyetler, stok politikasını değiştirerek değişmektedir. Stok maliyetleri temelde üç grup altında toplanabilir (Gençyılmaz, 1988).

1. Elde bulundurma maliyeti.
2. Elde bulundurmama maliyeti.

3. Sipariş maliyeti.

Günümüzde bazı işletmeler tam zamanında üretim sistemi gibi yalın üretim yöntemlerini tercih ederek sıfır stok bulundurmaya hedeflemektedir. Bu sayede, stok maliyetlerinden kurtulmayı amaçlamaktadır. İşletmeler bu yöntemler sayesinde büyük avantajlar kazanmaktadır. Buna rağmen bu yöntemlerin tedarik zinciri yönetiminde kullanılması çok mümkün değildir. Çünkü üretim için tedarik süresi sıfır olsa bile, bir ürünün tedarik zincir elemanlarından birinden diğerine geçmesi için yolda geçen zamanı beklemesi gerekmektedir. Bu zaman bazen üretim için gerekli olan zamandan bile fazla olabilmektedir. Bu nedenle tedarik zinciri üyeleri ellerinde mutlaka bir miktar stok bulundurmak durumundadır (Disney, Naim, Towill, 1997).

Bu yüzden tedarik zinciri elemanlarının ellerinde bulundurması gereken optimum stok miktarını araştırmak için çeşitli çalışmalar yapılmaktadır.

1.4. Tedarik Zincirinde Stok Yönetimi

Stok yönetimi, işletmelerde hangi üründen sipariş verilecek, sipariş miktarı ne kadar olacak, ürüne ne zaman ihtiyaç olacak ve ne zaman satın alınacak, nerede ve nasıl depolanacak gibi soruların cevabını bulmak için yapılan çalışmalar bütünüdür (Tanrıverdi, 2010).

Stok yönetiminin temel amacı, stok maliyetlerini azaltmak ve müşteri hizmet düzeyini arttırmaktır. Amaca ulaşmadaki en önemli yol ise, tedarik zinciri üyeleri arasında iş birliğinin sağlanmasıdır.

Stoklar tüm tedarik zinciri boyunca farklı şekillerde görülebilir. Stoklarla ilgili alınacak kararlar ve sahip olunan stok politikaları sürecin etkinliği için önemlidir. Üretim aşamasından, müşteriye ürünün teslimine kadar olan stok ve ilgili bilgilerin hareketi tüm tedarik zincirinin etkinliğini ilgilendirmektedir. Stoklar ile ilgili bilgilerin doğruluğu ve bu bilgilere hızlı ulaşmak çok önemlidir. Tedarik zinciri boyunca depolanan, taşınan ve satılan stoklarla ilgili bilgiler doğrultusunda gerekli satın alma, üretim, tahmin ve dağıtım işlemleri gerçekleşmektedir. Oluşan bilgilerin yanlış olması veya doğru zamanda doğru birimlere ulaşmaması sonucunda bu faaliyetler aksayabilmekte veya yanlış gerçekleşebilmektedir (Doğar, 2006).

Tüm tedarik zinciri bu durumdan etkilenir ve iki farklı sorun yaşanabilir. İlk sorun stok seviyesinin mevcut seviyesinin altında sanılmasıdır. Stok ihtiyaçlarını karşılamak için firma talepte bulunur. Fakat firmanın gerçekte stoka ihtiyacı yoktur ve gereksiz yere stok

istenmiş olunur bu yüzden stok bulundurma maliyetleri artar. Ve tedarik zinciri içerisindeki stok seviyesinin artışına da sebep olur. Diğer sorun ise stok seviyesinin mevcut seviyesinin üstünde sanılmasıdır. Firma elinde yeterli miktarda stok bulunduğunu düşündüğü için gerekli önlemleri almaz. Hata olduğu anlaşıldığında ise stok ihtiyacını karşılamak için hızlı bir şekilde eksik stokların tarafına ulaşmasını sağlamaya çalışır. Bu da taşımacılık maliyetlerini arttırır (Doğar, 2006).

1.4.1. Stok Kontrol Yöntemleri

Her işletme mali imkanları, işletme yapısı, yönetim politikaları, büyüklüğü, üretim türleri gibi faktörleri göz önünde bulundurarak kendine uygun stok kontrol sistemini uygular. Bu stok kontrol sistemlerinde uygulanan yöntemler gözle kontrol yöntemi, basit sayma ve bilgisayar destekli karmaşık olasılıklı modeller gibi değişkenlik gösterebilir. İşletmeler uygulayacağı stok kontrol yöntemini seçerken bu faktörlerin yanı sıra bilgi işlem sistemleri, personel olanakları ve iletişim yöntemlerini de göz önünde bulundurmalıdır (Kobu, 2006).

Stok tamamlama, stokların tedarik zinciri içindeki hareketinde, ihtiyaç duyulduğu zaman, depolandığı yerden ya da elde bulunmuyorsa tekrar tedariki sağlanarak, ihtiyaç duyulduğu yere ulaştırılması sürecidir. İşletmenin elindeki bilgiler ve stoka olan talep doğrultusunda farklı sistemler gelişmiştir. Stok kararlarını verecek olan yetkili, elinde bulunan bilgiler ve değişkenler üzerine karar vermek durumundadır. Bir ürüne olan talebin sabit olduğu bir durum ile sabit olmadığı durumlarda aynı sistemi kullanmak sağlıklı sonuçlar vermeyecektir dolayısıyla bu iki durum için ayrı sistemler kullanılması doğru bir yaklaşım olacaktır. Buna göre stok sistemlerini bağımsız talep sistemleri (geleneksel stok kontrol yöntemleri) ve bağımlı talep sistemleri olarak sınıflandırabilir (Doğar, 2006).

1.4.1.1. Gözle Kontrol Yöntemi

Stoklar düzenli olarak tecrübeli bir çalışan tarafından gözden geçirilir. Belirli bir seviyenin altına düşen stok kalemleri için hemen sipariş verilir. Küçük işletmelerde, işini bilen bir çalışan sorumluluğuna bırakılan bu yöntem kolay ve ucuz bir stok kontrol yöntemidir (Kobu, 2006).

Küçük üretim işletmelerinde, perakende satış mağazalarında, daha çok gıda süper marketlerinde büyük ölçüde uygulanan gözle kontrol yönteminin başlıca üç sorunu vardır (Tanrıverdi, 2010).

1. Gözden geçirme sıklığı, sipariş düzeyi ve sipariş miktarı kişisel düşünceye bağlı olduğundan hata olasılığı yüksektir.

2. Stoklar depoda sistematik bir düzenle yerleştirilmemişse kontrolü yapan çalışan sık sık yanlışlık yapması mümkündür.

3. Tüketim hızı, tedarik süresi veya başka bir faktörün değişmesi halinde bunun hemen farkına varılması zordur. Bu yüzden gerekli tedbirlerin geç alınabilir.

1.4.1.2. Çift Kutu Yöntemi

Çift kutu yönteminde, depodaki her malzeme iki farklı boyutta kutuda tutulur. Büyük kutu bitinceye kadar içindeki malzeme kullanılır. Büyük kutunun en altında, tekrar malzeme siparişi için bir talep formu vardır. Kutu tamamen boşalınca yeni sipariş talebi gönderilir ve bu sırada küçük kutudaki malzemeler kullanılır. Küçük kutuda, yeni sipariş teslim edilene kadar yetecek ve siparişin teslimi geciktiğinde veya beklenenden fazla malzeme kullanıldığı durumda yeterli olacak miktarda emniyet stoku bulunmaktadır. Stok yenilendiğinde, talep formu tekrar büyük kutunun en altına konur, her iki kutu doldurulur ve döngü tekrar başlar (Doğruer, 2005).

1.4.1.3. Sabit Sipariş Miktarı Yöntemi

Stok belirlenen düzeye indiğinde, toplam stok maliyetini minimum yapacak şekilde önceden belirlenmiş sabit bir miktar sipariş edilir. Bu modelde her stok kalemi için, toplam stok kontrol maliyetini minimum yapan bir sipariş miktarı, sipariş düzeyi ve emniyet stokunun hesaplanması gerekir. Sipariş miktarı sabit olduğu halde, sipariş periyotlarının değişken olması tedarikte bazı sorunlar yaratabilir. Tüketim hızının sabit halde olması bu sorun ortadan kalkacaktır (Kobu, 2006).

1.4.1.4. Sabit Sipariş Periyodu Yöntemi

Her stok kalemi önceden belirlenmiş bir sürenin sonunda sayılır ve bu maldan belirli bir maksimum stok seviyesine ulaşacak miktarda sipariş verilir. Her sayım periyodunda tüketim hızı farklı olabileceğinden sipariş edilen parti büyüklüğü de farklı olacaktır. Çok sayıda stok kalemi bulunan işletmelerde her kalem için farklı sipariş periyotları belirlenmesi ve bu sürelerde kontrollerin yapılması bilgisayar kullanılsa bile zor ve zaman alıcı bir iştir. Ayrıca her sipariş miktarı farklı olacağından satın alma güçlükleri ile karşılaşma ve miktara bağlı iskontolarından faydalanamama gibi sakıncaları vardır (Negüs, 2010).


1.4.1.5. ABC Analizi

ABC (Always Better Control) yöntemini İtalyan ekonomist Vifredo Pareto geliştirmiştir. Pareto Analizi adı ile de bilinmektedir (Ghewari ve Manvar, 2016). Bu yöntemde bütün elemanların küçük bir bölümü, her zaman en büyük etkiye sahiptir. Bu yöntem 80/20 olarak da bilinir, bunun anlamı elemanların yüzde 20'sinin etkisi yüzde 80 olmasıdır.

Stok kontrolünde ABC analizi, stok kalemlerinin toplam içindeki kümülatif yüzdelere göre sınıflandırılması anlamına gelmektedir. ABC analizi stok kontrolünün yanı sıra satış, dağıtım, kalite kontrol, ürün çeşidi, malzeme tedariki ve üretim planlama sorunlarına çözüm için de uygulanır (Doğar, 2006).

ABC analizinde kümülatif sınıflandırma sonucu stoklar çoğunlukla 3 gruba ayrılır. Bunlar:

1. A Grubu: Toplam miktarın % 15-20'sini oluştururken, toplam değer % 75-80'ini oluşturan stok kalemleridir.
2. B Grubu: Toplam miktarın % 30-40'ını oluştururken, toplam değer % 10-15'ini oluşturan stok kalemleridir.
3. C Grubu: Toplam miktarın % 40-50'sini oluştururken, toplam değer % 5-10'unu oluşturan stok kalemleridir.



Şekil 1.1 ABC Stok Kontrolünde Sınıflandırma

Kaynak: (Kobu, 2006)

ABC analizinin uygulanmasında öncelikle iki kural göz önüne alınmalıdır. İlk kural düşük değerli kalemlerden bol miktarda bulundurulmasıdır. Diğer kural ise yüksek değerli kalemlerin miktarını düşük tutup kontrolünü sıkılaştırmaktır (Kobu, 2006).

1.4.1.6. Maksimum-Minimum Yöntemi

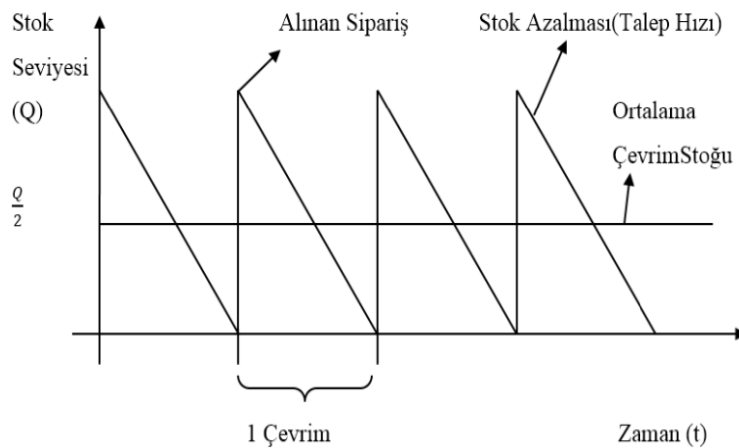
Bu yöntemde, stokları kontrol etmek görevli personel vardır. Bu personel gerekli durumlarda yeniden sipariş vermekle görevlidir. Bu personeller, siparişlerin teslim edilme süresini, stokların bitme süresini ve ayrıca stokların hangi seviyeye indiğinde siparişin yeniden verilmesi gerektiği önceden belirlemek zorundadır. Stoklar yeniden sipariş seviyesine indiğinde, personel daha önceden belirlediği miktarda sipariş verir (Küçük, 2011).

1.4.1.7. Ekonomik Sipariş Miktarı Modeli

Stokları kontrol etmek için geliştirilen ilk model Ekonomik Sipariş Miktarı modelidir. Klasik Ekonomik Sipariş modeli ilk defa Ford W.Harris tarafından 1915 yılında uygulanmıştır. Modelin temelini, sipariş maliyetleri ile depolama maliyetleri arasındaki dengeyi sağlama amacı oluşturmaktadır (Simchi-Levi vd, 2000). Modelin kurulması için yapılan varsayımlar yapılmıştır. Bu varsayımlar şu şekildedir (Öztürk, 2005):

- Talep “D” belli ve sabittir.
- Mallar için sipariş eşit aralıklarda ve “Q” miktarda verilir.
- Malların fiyatı sabittir ve birim maliyet “C” ile gösterilir.
- Her sipariş verildiğinde “S” değerinde sabit bir maliyeti oluşur.
- Elde bulundurma maliyeti “H”, malların elde bulunduğu her gün için geçerlidir.
- Sipariş edilen malların hemen işletmeye teslim edildiği varsayılır ve elde bulundurmamaya izin verilmez.
- Tedarik süresi kesin olarak bilinmekte sabit veya sıfırdır.

Bu varsayımlara göre, stok seviyesinin zamana göre değişimi aşağıdaki şekli alır ve şekil 1.2’deki gibi gösterilir. (İzzet, 2015).



Şekil 1.2 Ekonomik Sipariş Miktarı Modeli

Kaynak: (İzzet, 2015)

Şekilden görüldüğü üzere bir işletme için stok kalemlerine ait maliyetler aşağıdaki şekilde hesaplanabilir (Öztürk, 2005):

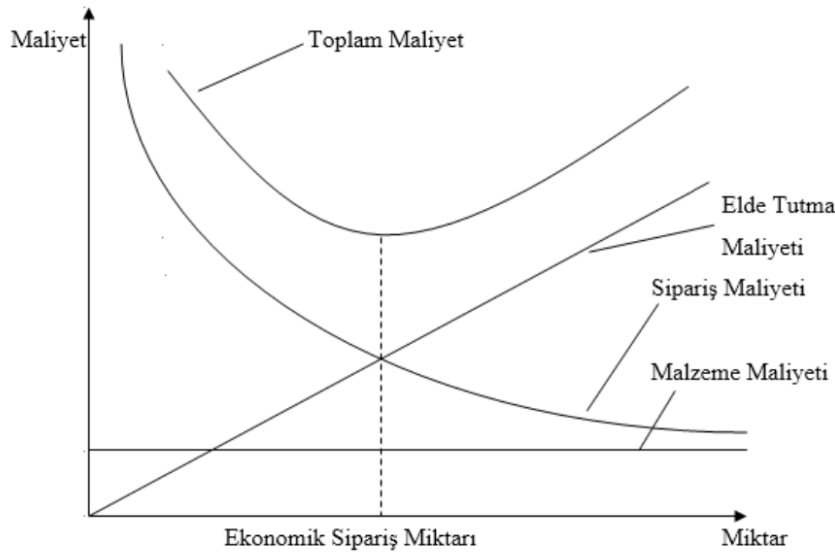
- Çevrim Stoğu (Ortalama Stok) = " $Q/2$ "
- Yıllık Malzeme Maliyeti = " $C \cdot D$ "
- Yıllık Sipariş Sayısı = Yıllık Talep/Sipariş Miktarı = " D/Q "
- Yıllık elde bulundurma maliyeti = " $(Q/2) \cdot H$ "
- Yıllık sipariş maliyeti = " $(D/Q) \cdot S$ "
- Toplam yıllık stok maliyeti = " $(Q/2) \cdot H + (D/Q) \cdot S$ "

Böylece toplam maliyetleri minimum yapan optimum sipariş miktarını yukarıdaki formülün Q 'ya göre türevinin alınması ve çözülmesi ile aşağıdaki gibi ifade edilebilir.

- Ekonomik Sipariş Miktarı = $Q^* = \sqrt{(2DS)/H}$

Ekonomik sipariş modelinde optimum sipariş miktarını bulmak için stok seviyesi zamanın bir fonksiyonu olarak ele alınmıştır. Buna göre bir işletme için stok kalemlerine ait maliyetler aşağıdaki şekilde hesaplanabilir. Modelin toplam maliyeti, üç maliyet bileşiminin toplamıdır (Öztürk, 2005).

- Yıllık Toplam Maliyet = "Yıllık Sipariş Maliyeti + Yıllık Elde Bulundurma Maliyeti + Satın Alınan Malların Yıllık Maliyeti"



Şekil 1.3 Ekonomik Sipariş Modeli

Kaynak: (İzzet, 2015)

Başarılı bir stok yönetimi için stoku oluşturan ürünlerin özelliklerinin bilinmesi gereklidir. Stok kontrolüne yardımcı analizler ve analizlerin sonucu ortaya çıkan sonuçlara yapılacak sınıflandırmalar yardımıyla özellikle çok fazla ürün çeşitliliğine sahip stokların yönetilmesinde zaman ve emek tasarrufu sağlamaktadır. Aynı sınıflandırmaya ya da birden çok analiz sonucu kesişen sınıflandırmalardaki ürünler için benzer stok yönetim kararları alınabilir. Bu kararlar verimliliği arttırarak stok yönetiminin başarısını arttıracak ve maliyetleri azaltacaktır (İzzet, 2015).

Stok kontrol yöntemlerine ek olarak yardımcı sistemler bulunmaktadır. Bunlara malzeme ihtiyaç planlaması (MRP), tam zamanında üretim (JIT), kurumsal kaynak planlaması (ERP), barkod, kare kod sistemi, RFID gibi güncel stok kontrol sistemleri verilebilir. (Tengilimoğlu ve Yiğit, 2013)

İKİNCİ BÖLÜM

TALEP TAHMİNİ

2.1. Talep Tahmini Kavramı ve Önemi

Talep temel olarak, tüketicilerin bir ürün veya bir hizmeti belirli bir fiyattan almaya hazır oldukları miktara denir (Tekin, 1996). Talep tahminini tanımlamak gerekirse, ürün veya hizmet için gelecekte oluşacak talebin hatasız ve doğru bir şekilde hesaplanmasıdır. Gelecek ile ilgili talebi belirleyebilmek için, geçmişteki verilerden, uzman görüşlerinden, deneyimlerden ve çıkarımlardan yararlanılarak bilimsel ve ölçülebilir tekniklerden yararlanılmaktadır (Yıldız, 2021).

İşletmeler, müşterin ihtiyaç ve isteklerini karşılayabilmek için mal ve hizmet üretmektedirler. Ürettikleri mal ve hizmeti pazara sunmaktadırlar. Müşterilerin belirli bir fiyat karşılığında pazara sunulan bu mal ve hizmeti alma isteğine ise talep denir (Şenbaş, 2020).

Talep tahmini, işletmelerin yönetimde önemli ve stratejik kararların alınmasında, belirlenen kısa ve uzun dönemli hedeflere ulaşmada kullanılacak en temel araçların başında gelmektedir (Bolt, 1994).

Talep tahmini belirli kural ve yöntemlere göre yapılır. Tahminde hangi yöntem kullanılırsa kullanılsın, yapılan tüm talep tahminlerinin belli bir doğruluk derecesi söz konusudur. Hiçbir tahmin %100'lük bir doğruluk derecesine sahip olamaz (Adıyaman, 2007).

Talep tahminleri tedarik zinciri içinde önemlidir. Tahminler tedarik zincirinde bir önceki zincirin girdisi olarak kullanılır. Satış tahminlerinden yararlanarak ne kadar hammadde sipariş verileceğini, nereye ne kadar ürün taşınacağını, hangi üründen nerede ve ne kadar stok bulundurulacağı belirlenir.

Başarılı bir tahmin işletmenin stok düzeyini belirlemede önemli rol oynamaktadır. Müşterilerin taleplerine zamanında tepki alınması gerekmektedir. Tahminlerdeki başarı oranı işletmenin beklediği oranda değil ise stok düzeyi bu riski indirgeyecek güvenlik stokları meydana getirilecektir. Doğruluk oranı yüksek bir tahminle stok seviyesi azaltılıp, stok taşıma maliyeti indirgenebilir (Moon, Mentzer, Smith, & Garver, 1998).

2.2. Talep Tahmininin Adımları

Talep tahmini temelde beş adımda gerçekleştirilir. Aşağıdaki şekilde talep tahmini adımları yer almaktadır.

1. Talebi Etkileyen Faktörlerin Belirlenmesi: Talep tahmini yapılmadan önce işletme analiz edilmelidir. İşletmenin çevresi, ürettiği ürünler, mevcut durumu ve gelecekte olmak istediği durumu, rakiplerin durumu, fiyat ve talep ilişkisi, ekonomik değişimler, endüstriyel değişimler, teknolojik gelişimler, sosyal değişimler, ulusal ve uluslararası eğilimler gibi talebi etkileyen etkenler ve ağırlıkları belirlenmelidir. (Bolt, 1994)

2. Verilerin Toplanması: Talebi etkileyen faktörler göz önüne alınarak planlamaya girdi olacak veriler toplanır. Veri olarak genellikle gerçekleşen geçmiş veriler, istatistiksel olasılıklar ve hedef verilerden oluşur. Verilerin düzenlenmesinde iç kaynaklar, işletme tarafından yapılan anket ve tahmin araştırmaları, yayınlanmış istatistik verileri, yayınlanmış anketler ve iktisadi veriler kullanılabilir (Bolt, 1994).

3. Talep Tahmin Dönemlerinin Belirlenmesi: Talep tahmin sonuçlarının kullanılma amacı ile dönem uzunlukları arasında yakın bir ilişki vardır. Örneğin, aylık yapılan talep tahminlerinin yıllık talep tahmininde kullanılması büyük ölçüde yanıltıcı sonuçlar meydana getirebilir (Tekin, 1996).

4. Tahmin Yönteminin Seçimi: Talep tahmin yöntemleri olarak Nitel ve Nicel yöntemler kullanılabilir. Nicel yöntemlerin temeli istatistiksel ve matematiksel verilere dayanır. Nitel yöntemler ise matematiksel ve istatistiksel veriler yerine daha çok tecrübeler, gözlemlere kişisel yargılara ve hislere dayanan yöntemlerdir. İdeal olan talep tahmini yöntemi ise Nitel ve Nicel yöntemlerin birlikte kullanılmasıdır (Bolt, 1994).

5. Tahmin Sonuçlarının Doğruluğunun Ölçülmesi: Tahmin yapıldıktan sonra elde edilen sonuçların gerçekleşen sonuçlarla arasındaki ilişkinin incelenmesi gerekmektedir. Hesaplanan ilişki oranında sapma yüksek ise, uygulanan yöntemin uygunluğu ve verilerin doğruluğu kontrol edilmelidir (Tekin, 1996).

2.3. Talep Tahmin Yöntemleri

Mal ve hizmet çeşitliliği çok fazladır. Bununla birlikte bu mal ve hizmeti talep eden müşterilerin tutumları da farklıdır. Bu yüzden tek bir talep tahmin yönteminden bahsetmek doğru olmayacaktır. Talep tahmininde kullanılan yöntemler temel olarak Nitel yöntemler ve Nicel yöntemler olmak üzere ikiye ayrılır (Bolt, 1994).

Nitel yöntemler genellikle uzman kişilerin görüşlerine dayanırken, nicel yöntemler matematiksel ve istatistiksel hesaplamalara dayanmaktadır. Bu iki yöntemin yetersiz kaldığı durumlarda, yapay zeka tabanlı yöntemler kullanılmaktadır (Sarı, 2016).

2.3.1. Nitel Tahmin Yöntemleri

Verilere dayanarak matematiksel ve istatistiksel yöntemler yerine daha çok hissi ve kişisel yargıları temel alarak yapılan tahminlerdir. Nitel tahmin yöntemi bilimsel verilere dayanmaması nedeniyle tahmin performansı diğer yöntemlere göre daha düşüktür (Olgun, 2009).

Nitel tahmin yöntemlerinden literatürde en çok tercih edilenlerden bazılarını aşağıda sıralanmıştır. Bunlar uzman görüşlerinin esas alınması, kilit personel kararı, anket yöntemi, delphi tekniği ve senaryo analizidir.

2.3.1.1. Uzman Görüşlerinin Esas Alınması

Tahmin yapılmak istenen konu üzerinde muhasebe, satın alma, üretim ve planlama, yönetim kurulu gibi departmanlardaki idari görevlilerin ve yöneticilerin tecrübelerine, bilgilerine ve sezgilerine dayanarak yapılan tahmin yöntemleridir. Zamanın kısıtlı olduğu çabuk karar verilmesi istenen zamanlarda bu yöntem kullanılabilir. Bu sayede verilerle analiz yapmak için harcanan zamandan tasarruf edilebilir. Uzman görüşlerinin esas alınması yöntemi diğer yöntemlere göre basit, uygulanması kolay ve düşük maliyetli olduğu için daha avantajlı olduğu düşünülebilir ancak sadece kişisel görüşlere dayalı olduğundan yanlış sonuçlara varma olasılığı diğer yöntemlere göre daha yüksektir (Koçkaya, 2016).

2.3.1.2. Kilit Personelin Kararı

İşletme içerisindeki satış ve pazarlama departmanında çalışan personelin tecrübelerine dayanarak yapılan bu tahminler, işletme yöneticileri tarafından değerlendirilmekte ve gerekli olduğunda belli değişiklikler yapılarak son karar verilmektedir. Kilit personel kararı tekniğinin avantajı maliyetin düşük olması ve hızlı sonuç alınmasıdır (Heizer vd., 2006).

Talep tahmininde karar merkezi olan kilit personel yani o konu hakkında uzman kişinin görüşü gelecek için karar vermede kullanılabilir. Tahminin deneyim ve sezgilere dayanıyor olması, karamsar tahminler ile iyimser tahminlerin eş değer tutulması gibi sakıncaları bulunmaktadır. Bu yöntemin avantajları ise; maliyetinin düşük olması ve hızlı sonuç alınabilmesidir.

2.3.1.3. Anket Yöntemi

Hedeflenen müşterilere uygulanan anket yöntemi genellikle yeni bir ürün veya hizmet pazara sunulurken ya da mevcut ürün veya hizmet için değişiklik, yenileme gibi çalışmalar yapıldığında yeni ürün veya hizmete oluşacak talebin tahmin edilmesi için kullanılan yöntemdir.

Anket yoluyla geniş kitlelere ulaşarak, araştırmayı büyük gruplara uygulamak daha basittir. Anket yöntemi harcanacak para, zaman ve enerji bakımından araştırmacıya avantaj sağlar. Ancak bu teknik çok güvenilir değildir. Anketler yoluyla ayrıntılı bilgi edinme kolay olmamaktadır. Anket uygulanan kişilerin soruları aynı şekilde anlayamamaları veya verdikleri cevaplarda doğru olmamaları ve rastgele cevaplar vermeleri yöntemin dezavantajları arasındadır. Araştırmacıların bu durumları kontrol etme imkânı da çoğunlukla bulunmamaktadır (Sarı, 2016).

2.3.1.4. Delphi Tekniği

Delphi tekniği, bir ürüne ya da hizmete ait ileriki dönemlerde gerçekleşmesi beklenen talebi tahmin etmek için yüz yüze görüşmeler gerçekleştirilmeden uzman kişiler tarafından belirlenmesine olanak veren bir yöntemdir. Bu yöntem uygulanacak anket formlarının uzman kişilere gönderilip feedback ile grupta yer alan kişilerin ortak bir fikirde birleşmelerini sağlamaktadır (Seaton ve Bennet, 1996).

Delphi tekniği 3 temel özelliğe sahiptir. Bunlardan ilki katılımcıların gizli tutulmasıdır. Gizliliğin amacı birbirinden etkilenen fikirlerin istenmemesidir. İkinci özellik ise grup katılımcılarının tepkilerinin istatistiksel analizidir. Anketler yapıldıktan sonra analizi yapılır. Üçüncü özellikse kontrollü geri beslemedir. Anketlerin analiz sonuçlarının katılımcılar ile paylaşarak grup üyelerinin tümünün ortak bir görüş birliğine varmalarını sağlamaktır.

2.3.1.5. Senaryo Analizi

Senaryo analizi geleneksel tahmin yöntemlerinden farklı olarak alternatif senaryolar ortaya koymakta ve matematiksel yöntemlerin dışında kaldığı konuları ve nitel araştırmaları da içine almaktadır. Senaryolar, gelecekte olabilecek gelişmeleri dikkate alarak daha net bir görüş açısı sağlayabildiği gibi nelerin olabileceğini veya olanların ne olduğunu anlamaya yardımcı olmaktadır (Erkut ve Akgüç, 1997).

Senaryo analizi tahmin yöntemi için sezgisel mantık yaklaşımı, eğilim etki analizi ve çapraz etki analizi olmak üzere üç farklı yöntem kullanılmaktadır.

Bu üç yöntem arasından senaryo analizi için kullanılan en yaygın yöntem sezgisel mantık yaklaşımıdır. Matematiksel modeller içermediğinden esnek ve tutarlı senaryolar üretilebilir. Kullanılan ikinci yöntem ise eğilim etki analizidir. Bu yöntem nitel faktörler ile geleneksel tahmin yöntemleri arasında bağ oluşturmaktadır. Kullanılan diğer bir yöntem çapraz etki analizidir. Senaryo oluşturulmasında hesaba katılan durumların birbiri ile olan ilişkilerini analiz içerisinde dikkate alır (Şenbaş, 2020).

2.3.2. Nicel Tahmin Yöntemleri

Nicel tahmin yöntemleri geçmiş dönemlerde gerçekleşen talep miktarlarını temel alan istatistiksel yöntemlerdir. Talebin gerçekleşmesinde etkili olan faktörlerle talep edilen miktar arasındaki ilişkinin gelecek dönemler için de aynı şekilde eğilim göstereceği hipotezine dayanmaktadır. İstatistiksel metotlarda geçmiş dönemlere ait veriler incelenir ve bunlar esas alınarak gelecek dönemlere ait talep miktarları bulunur. Bu yöntemler zaman serileri analizi ve nedensel yöntemler olmak üzere ikiye ayrılır. Kullanılan yöntemler; incelenen değişkende gözlenen gelişmelerin analiz edilmesi, veri serisinin dinamik özelliklerinin belirlenmesi ve bu özelliklerin matematiksel bir fonksiyon ile ifade edilerek geleceğe ilişkin öngörülerin yapılmasını içermektedir (Yazıcıoğlu, 2010).

2.3.2.1. Nedensel Yöntemler

Nedensel yöntemlerde talebi etkileyen faktörler ile talep arasında neden-sonuç ilişkisi bulunmaktadır. Nedensel yöntemlerde genellikle, bir değişkenin gelecekteki değeri tahmin edilmesinin dışında, bu değişkeni etkileyen faktörler arasındaki ilişkinin açıklanmasına çalışılmaktadır. Bağımlı değişken ile ilişkisi olan değişkenlerin belirlenmesi ve bu ilişkinin bir matematiksel modelinin bulunması amaçlanmaktadır (Sarı, 2016).

En çok tercih edilen nedensel yöntemler arasında regresyon analizi ve ekonometrik modeller bulunur.

Regresyon Analizi

Regresyon analizi genellikle bağımlı değişkenler ile bağımsız değişkenler arasındaki ilişkiyi matematiksel modellerle açıklayarak bu değişkenler arasında bağlantı ya da bağlantılar bulmak olarak tanımlanabilir (Alpar, 2017).

Regresyon analizi, bağımlı değişkenin bir veya birden fazla bağımsız değişken ile 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 edilir. Bağımlı değişkeni etkileyen bağımsız değişkenlerin tahmin edilmesi, bu değişken üzerinde geliştirilecek plan ve politikalarda hangi değişkenlerin önem kazandığının belirlenmesine yardımcı olmaktadır. Bu teknik sayesinde, hangi faktörlerde nasıl bir değişiklik yapılarak ilgilenilen değişkende artış veya azalış meydana geleceği ortaya çıkarılabilmektedir (Nezcan, 2011).

Bağımlı değişken genellikle Y ile gösterilirken bağımsız değişkenler genellikle X ile gösterilir.

Basit Doğrusal Regresyon Analizi: Temeli Y bağımlı değişkeni ile tek bir bağımsız değişken X arasındaki ilişkinin doğrusal bir fonksiyonla ifade edilmesine dayanmaktadır (Orhunbilge, 2002).

Basit doğrusal regresyon denklemi aşağıdaki formül ile gösterilmiştir.

$$“Y = a + bX + e”$$

a: Doğrusal fonksiyonun sabiti.

b: Doğrusal fonksiyonun eğimi.

X: Regresyon doğrusunun dikey eksenini kestiği nokta.

e: Hata terimi

Regresyon katsayısı, bağımsız değişkendeki bir birimlik artış ya da azalış gösterdiği durumda bağımlı değişken üzerinde, bağımlı değişken türünden ne kadarlık bir değişme oluşturacağını göstermektedir. Regresyon katsayısının işareti pozitif ise bağımsız değişken bir birim artırıldığında bağımlı değişken “b” kadar artmaktadır. Regresyon katsayısının işareti negatif ise bağımsız değişken bir birim artırıldığında bağımlı değişken “b” kadar azalmaktadır (Orhunbilge, 2002).

Çoklu Doğrusal Regresyon Analizi: Bağımlı bir değişkeni tek bir bağımsız değişkenle açıklamak her zaman mümkün değildir. İşletmecilik ve ekonomi alanlarında bu durumla çokça karşılaşmaktadır. Çünkü ekonomik değişkenler karmaşık değişkenlerdir. Birden fazla ekonomik değişken bir araya gelerek bir değişkeni etkileyebildikleri gibi birbirlerini de etkileyebilmektedirler. Böyle durumlarda basit doğrusal regresyon analizi kullanılamaz.

Birden fazla bağımsız değişkenli analize ise çoklu regresyon analizi denilmektedir (Orhunbilge, 2002).

Çoklu doğrusal regresyon denklemi formül aşağıda verilmiştir.

$$Y = a + b_1X^1 + b_2X^2 \dots + b_nX^n + e$$

y: Bağımlı değişken

x_1, x_2, \dots, x_k : Bağımsız değişkenler

e: Tahmin hatası

Ekonometrik Modeller

Talep tahmininde yeterli istatistiksel veri sağlandığı zaman ekonometrik modeller, tahmin yapmak için en güvenilir yöntemdir.

Talep tahmini için kullanılan ekonometrik modeller başta basit modeller olmak üzere çok değişkenli karışık modellere kadar geniş bir alanda kullanılmaktadır. Talep tahmini için kullanılan çok denklemlili ve çok bilinmeyenli girdi-çıkıtı analizi veya doğrusal programlama gibi ekonometrik modeller mevcuttur. Bu modeller çoğu zaman bilgisayar desteği ile kullanılabilir. Talep tahmini yaparken ekonomik modelleri kullanmak uzmanlık gerektirmektedir (Özsoy, 2006).

2.3.2.2. Zaman Serisi Yöntemleri

Zaman serisi yöntemleri belirli işlemler ile geleceğe yönelik tahmin yapılmasıdır. İlk olarak geçmiş dönemlere ait veriler incelenir daha sonra belli bir eğilim olup olmadığı belirlenir. Geçmiş dönem verileri zaman sırasına dizilir. Zaman serisi analizinde, bu geçmiş dönem verilerinin değişim biçimi araştırılır ve bu süreci temsil eden bir model kurulur. Bu model ile geleceğe yönelik talepler tahminleri yapılır (Sarı, 2016).

Zaman serileri analizinin uygulama alanı çok geniştir. İstatistik ve ekonomi alanları bu alanların başında gelir. Zaman serisini, zaman içinde gözlenen ölçümler dizisi olarak tanımlayabiliriz. Geçmiş verilere ait verilere sahipsek zaman serileri yöntemleriyle geçmiş verileri kullanarak gelecek yıllara ait tahminlerde bulunabiliriz.

Zaman serileri Trend, Mevsimsel Dalgalanmalar, Ekonomik Dalgalanmalar ve Düzensiz Dalgalanmalar olarak dört ana bileşenden etkilenir. Eğilim, bir zaman serisindeki uzun vadeli bir harekettir. Zaman serileri artabilir, azalabilir veya durabilir. Mevsimsel farklılıklar, mevsim boyunca bir yıl içinde hava ve iklim koşulları gibi dalgalanmalardır. Düzensiz veya rastgele değişkenler, zaman içinde tekrar etmeyen ve düzenli olmayan

beklenmedik etkilerden kaynaklanır. Beklenmeyen etkiler savaş, grev, deprem veya sel olabilir (Şenbaş, 2020).

Mekanik Yöntemi

Uygulaması basit talep tahmin yöntemlerindedir. Tahmin yapmakla beraber yapılan tahminin üstünlüğünün tespitinde de kullanılmaktadır. Mekanik yönteminde oluşturulan modeller, eldeki en son gözlem değerinin bir sonraki dönem için en iyi girdi değeri olarak alınabileceği varsayan modellerdir (Çuhadar vd., 2009).

Formülü;

y_{t+1} : “t+1 dönemindeki tahmini değeri”,

y_t : “t dönemindeki değer”,

$y_t - y_{t-1}$: “bir önceki dönemle t dönemi ile değerleri arasındaki fark”

Trend Analizi

Trend analizi, geçmiş dönem işletme satışlarını kullanarak geleceğe dair satış miktarları üzerine tahmin yapılmasına dayanır. Geçmişte var olan tüm koşulların gelecekte de aynı olması durumunda, yöntem oldukça sağlıklı sonuçlar verir (Meydan, 2007).

Trend analizi gerçekleştirilmede dört farklı yöntem kullanılır. Bunlar:

- 1) Elle çizme yöntemi.
- 2) Yarım ortalama yöntemi.
- 3) Hareketli ortalama yöntemi.
- 4) En küçük kareler yöntemi.

Elle Çizme Yöntemi: Saptanmış iki nokta arasında bir eğri veya doğru çizilmesi ile uygulanır. Eğri ya da doğru çizilirken, noktaların çizilen eğrinin iki yanında aynı oranda dağılım gösterecek şekilde olmasına dikkat edilir ve çizilen eğriye ilişkin eşitlik hesaplanır. Yöntemi uygulayan kişiler birbirlerinden farklı çizimler yapabileceği için yöntemde farklılıklar meydana gelebilir. Elle çizme yöntemi basit ve hızlıdır (Meydan, 2007).

Yarım Ortalama Yöntemi: İncelenen zaman serisi iki eşit parçaya ayrılır. Bu iki parçaya ayrılan zaman serilerinde her iki parça için aritmetik ortalaması hesaplanır. Sonrasında hesaplanan aritmetik ortalamaların doğrusu çizilir. Bunların yanında, serinin elemanlarının toplamı tek sayı ise ortadaki veri dikkate alınmaz, çift sayı ise sistem tam olarak ikiye ayrılarak işlem yapılır. Bu yöntemde trendin doğrusal olduğunu varsayılmaktadır ve

serinin her iki kısmına da mevsimsel dalgalanmaların aynı şekilde olduğunu varsaymaktadır. Ama bu varsayım her zaman geçerli değildir (Meydan, 2007).

Hareketli Ortalamalar Yöntemi: Ekonomik dalgalanmalardan etkilenmek istenilmediği durumlarda zaman serisi için uygun yöntem hareketli ortalamalar yöntemidir. Hareketli ortalamalar yönteminde dalganın uzunluğu ile uzunlukların değişkenliği önemlidir. Uzunluklar sabit olmadığı durumlarda diğer yöntemler tercih edilebilir (Meydan, 2007).

En Küçük Kareler Yöntemi: En küçük kareler yöntemi hata kareleri minimum yapmak üzerine kuruludur. Yani en küçük kareler yöntemi hata payı olan “e”yi minimum yapan yöntemdir. Aşağıdaki formülden bulunabilir.

$$S = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Bu fonksiyonun minimum yapılması için “ α ” ve “ β ” parametrelerine göre kısmi türevlerinin alınması ve bunların 0’a eşitlenmesi gerekir. Kısmi türevler alındıktan sonra aşağıdaki denklemler elde edilir (Kılıç, 2015).

$$\sum y_i = \alpha N + \beta \sum x_i$$

$$\sum x_i y_i = \alpha \sum x_i + \beta \sum x_i^2$$

Bu denklemlere ‘normal denklemler’ denir. Normal denklemler yardımıyla α ve β değerleri bulunduktan sonra “ $y = \alpha + \beta x$ ” denkleminde yerine yazılarak, istenen regresyon denklemi elde edilmiş olur (Kılıç, 2015).

Hareketli Ortalamalar Yöntemi

Talepte meydana gelen mevsimsel dalgalanmaları inceleyerek mevsimsel dalgalanmaların talep üzerindeki etkisi öğrenilmek istendiği zaman hareketli ortalama yöntemi kullanılabilir. Geçmiş dönem satış verileri incelenir ve satışların zamanla oluşturduğu satış eğilimi bulunur. Eğilim doğrusundan faydalanarak gelecek dönem talep tahmini yapılır. Hareketli ortalamalar yöntemine göre 3, 4, 6 ve 12 aylık ortalamalar kullanılarak hesaplamalar yapılabilir. En çok kullanılan ortalama 3 aylık olanlardır (Tekin, 1996).

Yönteme hareketli ortalama denmesinin nedeni ise zaman serisine eklenen her yeni değer ile yeni bir ortalamanın hesaplanabilmesi ve bunun tahmin olarak kullanılabilir olmasıdır. Hareketli ortalamalar yöntemi üç grupta incelenebilmektedir. Bunlar basit, ağırlıklı ve çift hareketli ortalamalardır (Olgun, 2009).

Basit Hareketli Ortalama: Basit hareketli ortalama yönteminde, son gözlem verilerinin bir miktarı hareketli ortalamaya dahil edilir ve bu gözlem verilerinin ortalaması alınarak bir sonraki dönem tahmin edilmeye çalışılır (Olgun, 2009).

Ağırlıklı Hareketli Ortalama: Basit hareketli ortalama yönteminde belirli gözlem verilerinin ortalamaları alınırken veriler eşit ağırlık verilmekteydi fakat ağırlıklı hareketli ortalama yönteminde her döneme farklı ağırlıklar verilir. Gözlenen verilerin toplamı, belirlenen ağırlıklarla çarpılır ve ortalama alınırken gözlem sayısına değil, ağırlıklar toplamına bölünür (Olgun, 2009).

Çift Hareketli Ortalama: Seçilen verilerin birinci veya ikinci dereceden polinom şekli oluşturduğu trendlerde basit veya ağırlıklı ortalama yöntemleri işe yaramayabilir. Gözlenen veriler bir trend oluşturduğu zaman tahmin edilen değerler, gerçekleşen değerleri gecikmeli olarak takip etmektedir. Elde bulunan zaman serisi, böyle bir trende sahipse çift hareketli ortalama tahmin yöntemi olarak kullanılabilir. Bu yöntem, adından da anlaşıldığı gibi bir seri için hareketli ortalamasının hesaplanmasının ardından birinci serinin hareketli ortalaması olarak ikinci bir serinin hesaplanması temeline dayanmaktadır (Olgun, 2009).

Üstel Düzeltme Yöntemi

Uzun bir süredir kullanılan üstel düzeltme yöntemi günümüzde pratik olduğu için hala kullanılan tahmin yöntemlerinden biridir. Çok fazla tercih edilen yöntemlerden biri olmasının nedenleri arasında yöntemin açık ve anlaşılır olması, şeffaf olması ve birçok farklı duruma uyum sağlama yeteneğidir. Üstel düzeltme yönteminin temel bileşenleri hata, eğilim ve mevsimsellik değişkenleridir.

Yöntemin çalışma prensibi, yeni gözlemlerin eski gözlemlere göre daha önemli olmasıdır. Üstel düzeltme yöntemi, üstel olarak azalan, ağırlıklı olarak hareketli ortalama verilerini kullanır. Bu temel fikirden yola çıkarak üstel düzeltme farklı bileşenlerin modellemesini geliştirmektedir. Bu farklı bileşenler; mevsimsel değişimler, eğilimler ya da serilerin uzun vadeli değişimi, tespit edilen periyotlarda serilerdeki tekrarlayan bileşenler ya da tahmin edilemeyen diğer bileşenler gibi geri kalan değişkenlerdir. Yönteme ait bileşenler, mevcut koşulun süresi ve büyümesinin kombinasyonudur. Zamana bağlı olarak farklılık gösteren değişkenlere sahip olan ve regresyon eğrisi ya da doğrusuna dönme potansiyeli bulunmadığı için birden çok regresyon eğrisi ile açıklanabilen serilere stokastik eğilime sahip seriler denilir. Üstel düzeltme yöntemi hem deterministik hem de stokastik trende sahip olan tüm serilere uygulanabilmektedir (Yağımlı ve Ergin, 2017).

Üstel düzeltme yöntemi, temelde dört farklı yöntemden oluşmaktadır. Bu yöntemler;

- Basit (Tekli) Üstel Düzeltme.
- Brown'un Tek Parametrelili Doğrusal Üstel Düzeltmesi Yöntemi.

- Holt'un İki Parametrelili Doğrusal Üstel Düzeltmesi Yöntemi.
- Winters Mevsimsel Üstel Düzeltme Yöntemi.

Holt Üstel Düzeltme Metodu; mevsimsel dalgalanmaların olmadığı verilerin tahminleri için kullanılan bir yöntemdir. Winters Üstel Düzeltme Yöntemi ise trend ve mevsimsel dalgalanmaya sahip zaman serileri değerlendirmeye alır. Basit üstel düzeltme yönteminde ise herhangi bir trend ya da mevsimsel dalgalanma yaşanmamış, sadece bir ortalama seviye düzeyinde değişim gösteren serilere uygulanır. Basit üstel düzeltme metodu ise zaman serisi verilerindeki değişimleri azaltmak için kullanılan pürüzsüzleştirme teknikleri arasında çok popüler, pratik ve genel kabul gören bir yöntemdir. Bu yöntemde, bir zaman serisine bağlı olarak elde edilen verilerin, eşit zaman aralıkları ele alınarak ortaya çıkan fiziksel veya finansal olarak, zaman içerisindeki sıralamaları basitçe tanımlanabilir (Yağimli ve Ergin, 2017). Brown'un Tek Parametrelili Doğrusal Üstel Düzeltme yöntemi ise zaman serisi trend gösterip mevsimsel dalgalanma göstermediğinde kullanılmaktadır.

Box-Jenkins Yöntemi

Bu yöntem tek değişkenli zaman serilerinde doğru tahmin modelinin seçilmesinde sıklıkla kullanılmaktadır. Box-Jenkins yöntemi kısa dönem için yapılan tahminlerde başarılıdır. Yöntemin uygulandığı zaman serisinin eşit zamanlarda gözlenen değerlerden oluşan kesikli ve durağan bir seri olması, bu yöntemin önemli bir varsayımını oluşturmaktadır (İlhan, 2015).

Box-Jenkins yöntemi, tüm modeller arasından uygun bir modeli belirleyebilmek için dört basamaktan oluşan tekrarlamalı bir yaklaşımı tercih etmektedir. Bu basamaklar; belirleme, parametre tahminleri, uygunluk testleri ve geleceğe yönelik tahmin şeklindedir. Belirlenen modelin yeterli olmaması durumunda süreç, orijinal modeli geliştirmek adına oluşturulan bir model kullanılarak tekrar eder. Tatmin edici bir model elde edilene değin bu süreç tekrar ettirilmektedir (Çuhadar vd., 2009).

2.3.3. Yapay Zekâ Tabanlı Yöntemler

Yapay zekâ, insanın düşünme sistemini anlamak ve insan beyni gibi düşünebilen bilgisayar işlemlerini geliştirme olarak tanımlanabilmektedir. Diğer bir tanıma göre, insana özgü olan algılama, görme, düşünme, karar verme, öğrenme gibi özelliklere sahip olan bilgisayarlardır (Sarı, 2016).

Yapay zekâ, bilgisayar ve benzeri insan yapımı araçları kullanarak insanlar ve hayvanlar gibi doğal sistemleri taklit etmek için geliştirilen yöntemlerdir. Bu yöntem, kesin

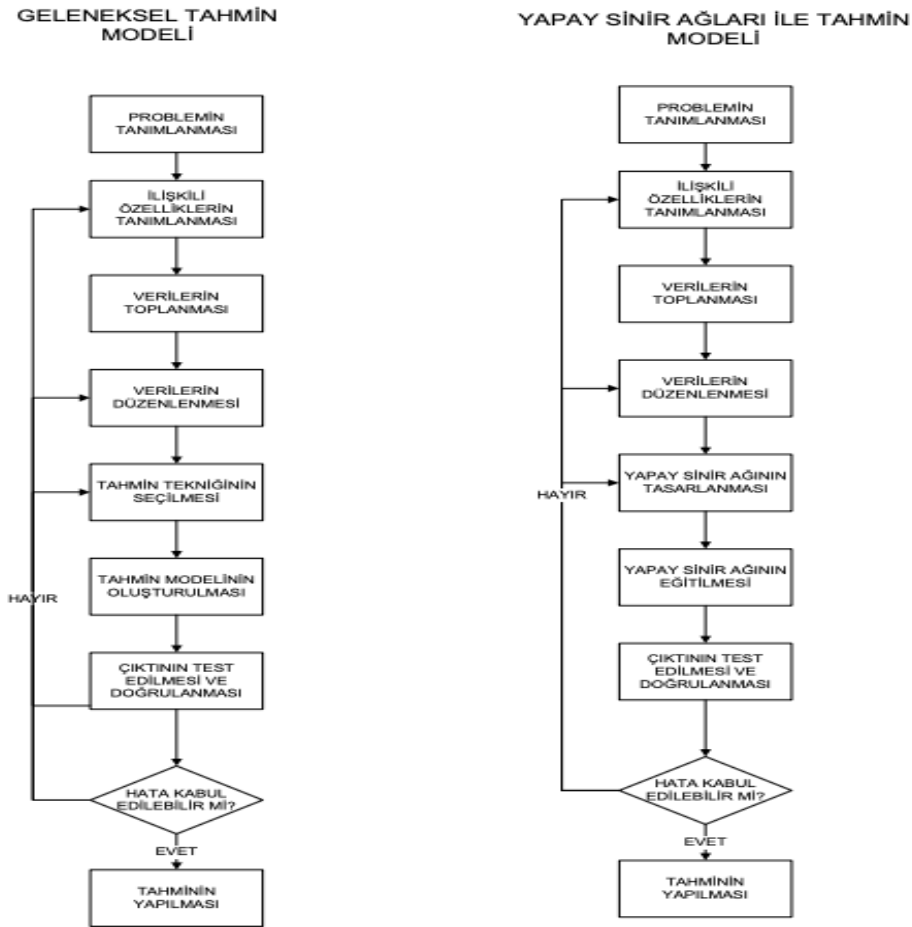
olmayan belirsiz bilgiler başta olmak üzere diğer bilgilerinde bilgisayar hafızasında depolanması ve bu bilgilerden otomatik olarak çıkarımlar yapılması amacıyla bilginin nasıl temsil edilebileceğini anlamayı içermektedir. Ayrıca depolanan bilgileri kullanarak kararların nasıl alınabileceğini ve eylem planlarının nasıl oluşturulabileceğini içermektedir. Bunların yanında verilen örnek veriden öğrenerek ya da insan uzmanları sorgulayarak karşılığında bilgisayarda işlenebilir bilginin nasıl oluşabileceğini anlamayı da içermektedir. (Borgelt ve Kruse, 2002).

Yapay zekâ tabanlı yöntemler özellikle diğer yöntemlerin yeterli olmadığı karmaşık problemlerin çözümünde kullanılan güçlü yöntemler olarak ortaya çıkmaktadır. Literatürde çeşitli yapay zekâ algoritmaları, talep tahmini amacıyla kullanılmıştır. Bunlar arasında en çok kullanılan yöntemler yapay sinir ağları, bulanık mantık ve genetik algoritmalarıdır. Bu yöntemler yapısal olarak nicel yöntemler olabileceği gibi uzman görüşlerinin de değerlendirilmeye katılmasını sağlayan yöntemler de mevcuttur (Olgun,2009).

2.3.3.1. Yapay Sinir Ağları

Yapay sinir ağları, yapay zekâ tabanlı yöntemler arasında en çok kullanılan yöntemlerin başında gelmektedir. Yapay sinir ağları verilen örneklerden öğrenebilme ve bu sayede genelleme yapabildiği için YSA esnek ve güçlü araçlardır. 3. bölümde yapay sinir ağları konusu ayrıntılı olarak işlenecektir.

Talep tahmininde yapay sinir ağları yöntemlerinin adımları ile diğer geleneksel tahmin yöntemlerinin adımlarının kıyaslanması aşağıda Şekil 2.1’de gösterilmiştir.



Şekil 2.1 Yapay Sinir Ağları Yöntemi ve Geleneksel Yöntemlerle Talep Tahmini Adımları

Kaynak: (Denton, 1995)

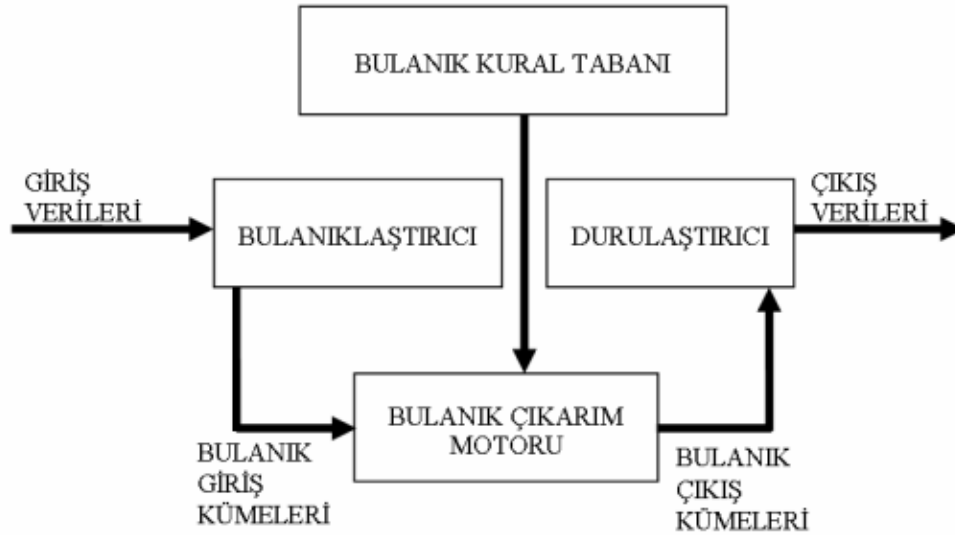
2.3.3.2. Bulanık Mantık

Bulanık mantık kavramını ilk kez 1965 yılında Zadeh tarafından yapılan çalışmalar sonucu ortaya çıkmıştır. Zadeh yaptığı çalışmalarda, girdi verilerinin farklı kümelerdeki farklı üyelik derecelerinden bahsetmiş ve girdinin çıktıya dönüşümünün bu kümeler aracılığıyla yapılabileceğinden söz etmiştir. Bulanık mantık yöntemi daha çok deneyimlere dayanan verileri veya sayısal olarak ifadesi zor olan verilerin yorumlanmasında sıkça kullanılmaktadır (Yazıcıoğlu, 2010).

Bir kavramı açıklayan, bir amacı aktaran veya bir sistemi tanıtan ifadelerdeki belirsizliği veya kesin olmama durumuna bulanıklık denir. İnsanların zihinsel boyuttaki algılama düzeylerinin farklılıkları, öznel davranışları, ifade ve amaçlarındaki belirsizlikler bulanıklık kavramı ile açıklanabilmektedir (Aikeshan, 2014).

Bulanık mantık klasik mantıktan oldukça farklıdır. Klasik mantık, sadece 0 ve 1 değerlerini alır. Örneğin evet/hayır, iyi/kötü gibi değerleri almaz. Bulanık mantık ise bulanık

kümelerdeki üyelik dereceleri 0 ve 1 dahil olmak üzere sonsuz değerler almaktadır. Örneğin, az/çok, orta/uzun, 0-1 değerleri yerine ara değerleri 0.3-0.6 kullanarak işlem yapar.



Şekil 2.2 Genel Bulanık Mantık Yapısı

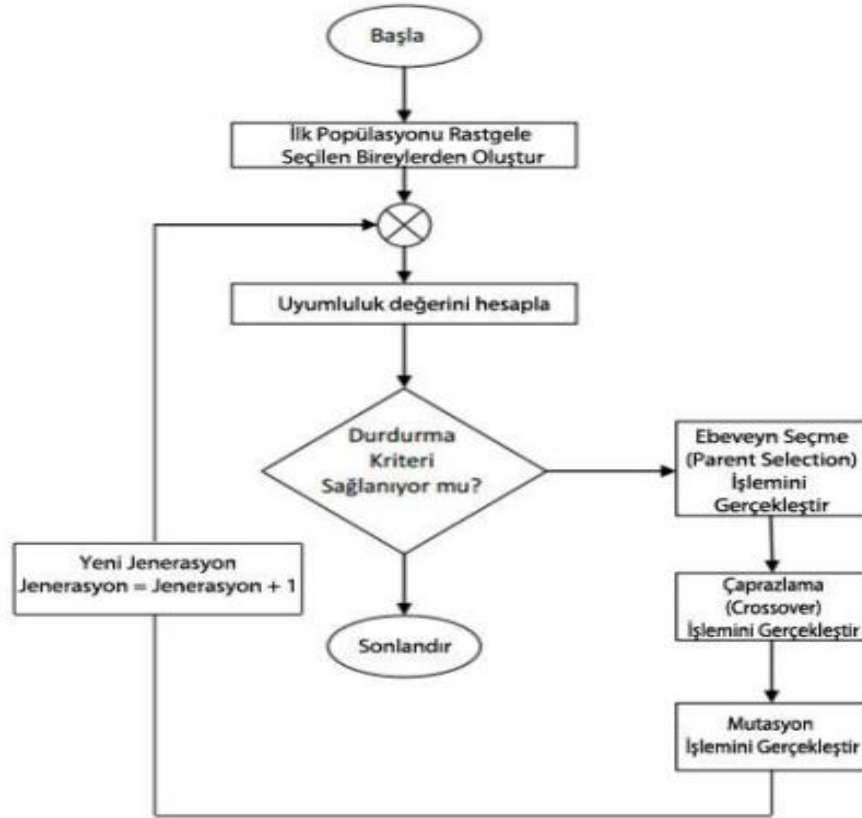
Kaynak: (Güneş ve İncekırık, 2016)

2.3.3.3. Genetik Algoritma

Genetik Algoritma ilk olarak 1970'lerin başlarında ortaya çıkmıştır. 1975'te John Holland'ın makine öğrenmesi üzerine yaptığı çalışmalarda canlılardaki evrimden ve değişimden etkilenerek, bu genetik evrim sürecini bilgisayar ortamına aktarması ve böylece bir tek mekanik yapının öğrenme yeteneğini geliştirmek yerine, çok sayıdaki böyle yapıların tamamını “çiftleşme, çoğalma, değişim...” gibi genetik süreçler sonunda üstün yeni bireylerin elde edilebileceğini gösteren çalışmasından çıkan sonuçların yayınlanmasından sonra geliştirdiği yöntemin adı “Genetik Algoritmalar” olarak tanınmıştır (Karasoy ve Ballı, 2016).

Genetik algoritmaların amacı, geleneksel olan yöntemlerle çözümü çok zor veya imkânsız olan problemleri sanal ortamda evrimden geçirerek en iyi çözümü elde etmektir.

Genetik algoritmalar, bir çözüm uzayındaki her noktayı kromozom adı verilen ikili bit dizisi ile kodlamaktadır. Her noktanın bir uygunluk değeri bulunmaktadır. Tek bir nokta yerine genetik algoritmalar bir popülasyon olarak noktalar kümesini muhafaza etmektedir. Her kuşakta genetik algoritma, çaprazlama ve mutasyon gibi genetik faktörleri kullanarak yeni bir popülasyon oluşturur (Emel ve Taşkın, 2002).



Şekil 2.3 Genetik Algoritma Akış Diyagramı

Kaynak: (Koç vd., 2017)

2.4. Talep Tahmininin Doğruluğu ve Yöntem Seçimi

Tahmin yöntemlerinden hiçbiri %100 doğru değeri veremez. Zaten gelecekte olacak talep %100 biliyorsa bu da tahmin olmaz. Bu sebeple yapılan bütün tahminlerde belirli bir hata payı vardır. Çeşitli tahmin modelleri arasında birini seçme sürecinde en yaygın kabul gören kriterlerden biri de modelin verilere uyum göstermesi, modelin öngörü başarısının yüksek olmasıdır. Modellerin öngörü başarılarının karşılaştırılması amacıyla çeşitli kriterler mevcuttur. Bu kriterlerden en önemlisi, tahmin doğruluğudur. Tahmin yönteminin doğruluğu, tahmin edilen hataların analiz edilmesiyle ölçülür. Tahmin hatası, gözlenen gerçek değerler ile tahmin edilen değerler arasındaki farktır (Sarı, 2016).

Tahmin hatası aşağıdaki şekilde hesaplanabilir:

Hata = Gerçekleşen Talep-Tahmini Talep

$$h_t = G_t - T_t$$

G_t , gözlenen gerçek değer

T_t , modelin ürettiği değer

h_t değeri ise tahmin hatasını göstermektedir.

Tahmin hatasının hesaplanmasının temel amacı tahmin hatası sonuçlarına göre kullanılan talep tahmin yöntemleri arasında kıyaslama yapabilmektir.

En çok kullanılan tahmin doğruluğu ölçme yöntemleri aşağıdaki gösterilmektedir.

Mutlak Hata: $|h_t| = |G_t - T_t|$

Ortalama Mutlak Hata: $\frac{1}{n} \sum_{t=1}^n |h_t|$

Hata Kareleri Toplamı: $\sum_{t=1}^n h_t^2$

Hata Kareleri Ortalaması: $\frac{1}{n} \sum_{t=1}^n h_t^2$

Tahmin yapılma aşamasında elde edilen verilerin doğru tahmin yöntemi ile kullanılması tahmin sürecinin en önemli aşamalarında birisidir. Bu nedenle var olan veriler ne kadar anlamlı olursa olsun eğer yöntem yanlış seçilirse hatalı sonuçlar verecektir (Korkut, 2019).

2.5. Tedarik Zincirinde Talep Tahmini

Tedarik zincirinde talep yönetiminde, talep tahmini oldukça önemli bir konuyu oluşturmaktadır. İşletmeler doğru bir şekilde talep tahminini gerçekleştirerek, ürünlerin ne kadarlık kısmının stokta tutulacağına ne kadarlık kısmının siparişleri karşılamak için ayrılacağını belirlemektedir (Chopra ve Meindil, 2007).

Tedarik zinciri yönetiminde talebin doğru tahmin edilmesi öncelikle stok açısından çok önemlidir. Talep tahminin yanlış yapılması, çok fazla stok oluşmasına ya da eksik stokların ortaya çıkmasına sebep olacaktır. Fazla stok oluşması durumunda, ek olarak emniyet stokları da düşünüldüğünde stok maliyetlerinde artışlara sebep olacaktır. Eksik stok durumunda ise ürün planlanan zamanda işlenemeyecektir. Talep tahminin doğru bir şekilde yapılması durumunda ise emniyet stoklarına gerek kalmayacaktır (Olgun, 2009).

Tedarik zincirinde talep tahmini yapılırken, tüm tedarik zinciri yönetim ağı üyelerinin ortak bir talep tahmini planlaması uygulaması gerekmektedir. Örneğin bir tedarik zinciri ağında perakendeci bir işletme yaptığı promosyonları esas alarak bir tahmin yaptığında, üretici yapılan tahminden haberdar olmazsa bu durum üreticinin doğru üretim planı

gerçekleştirememesine neden olmaktadır. Böyle bir durumda arz ve talep arasında uyumsuzluk olmakta ve kötü müşteri hizmeti ortaya çıkmaktadır (Chopra ve Meindil, 2007).

ÜÇÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ

3.1. Yapay Sinir Ağlarının Tanımı

Yapay sinir ağları (YSA) temelde, insan beyni içerisindeki sinirlerin çalışmasını taklit ederek insan beyninin özelliklerinden öğrenme, keşfetme, genelleme yapma, hatırlama gibi yetenekleri yardım almadan gerçekleştirmeyi amaçlayan bir bilgi işleme algoritmalarıdır (Öztürk ve Şahin, 2018).

Literatürde ise YSA'nın daha geniş ve farklı tanımları mevcuttur.

YSA, tecrübeye dayanan bilgiyi depolamaya ve bu bilgiyi kullanıma sunmaya yönelik doğal bir eğilim içinde olan dağıtılmış bir işlemcidir. YSA, insan beynine iki yönden benzemektedir. Bilgi, ağ tarafından bir öğrenme süreci ile elde edilmektedir. Sinir hücreleri arasında snaptik ağırlıklar olarak adlandırılan bağlar bilgiyi depolamakta kullanılmaktadır (Haykin, 1999).

YSA, insan beyninin temel unsuru olan nöronlara benzetilen yapay işlem elemanlarının farklı yapılarda ve ağ modelleriyle birbirine bağlanmasıyla oluşan karmaşık sistemlerdir. Bir YSA, birbiriyle etkileşim içinde olan çok sayıda yapay nöronun birbirine paralel olarak bağlı hiyerarşik organizasyonudur (Çelik, 2003).

YSA'lar, insan beyninin çalışma prensibinden esinlenerek geliştirilmiştir. Birbiriyle paralel çalışan, birbirine bilgi gönderen ve bilgi alan organizasyondan oluşmaktadır. Problem çözmek için kullanılan yapay sinir hücreleri birbirine ağ şeklinde bağlanmıştır. Hücreler arasındaki bilgi akışı bağlantı değerleri ve ilişkilerle gösterilmektedir. Sistemin öğrenme yeteneği ve zeki davranışı, bağlantı değerlerinin kullanılmasıyla sağlanır (Karahan, 2011).

Yapay sinir ağları, insanların keşfetme, yeni bilgiler öğrenme ve bilgileri çoğaltma gibi özelliklerinin bilgisayar sistemine uyarlanmasıdır. İnsan beynine özgü olan bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek çok zordur. Bu yüzden YSA, programlaması çok zor olan olaylar için geliştirilmiş uyarlayıcı bilgi işleme ile ilgilenen bir analiz ve modelleme tekniğidir (Öztemel, 2006).

3.2. Yapay Sinir Ağlarının Tarihçesi

Yapay Sinir Ağları tarihte ilk kez 1943 yılında sinir hastalıkları doktoru Warren McCulloch ile matematikçi Walter Pitts tarafından yayınlanan “Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap” adlı makale ile ortaya çıkmıştır. YSA’lar insan sinir sistemi yapısının bilgisayar üzerinde taklit edilmesidir. Başka bir ifadeyle bilgisayarda oluşturulan yapay bir sinir ağı ile verilerin eğitilmesi ve öğrenme sürecidir (McCulloch ve Pitts, 1943).

Gerçek anlamda ilk çalışmalar 1900 yılların başında sinir hücrelerinin varlığının kanıtlanması ile başlamıştır. 1950 yıllarına gelindiğinde teknolojinin gelişmesiyle birlikte bilgisayar sistemlerinin gelişmesi ile birlikte sinir hücrelerinin matematiksel yöntemler ile hesaplanabileceği ortaya atılmıştır. Bunu en iyi açıklayan teori ise Walter ve McCulloch beraber oluşturdukları sinir hücrelerine ait mantıksal hesap teorisidir. İlerleyen süreçte bu teoriye ek olarak öğrenme algoritmaları geliştirilmiştir. İlk zamanlarda tek katmanlı problemlerin çözümü için kullanılırken bir süre sonra bunun çözümlenememesinde yetersiz kaldığının farkına varılmıştır. Bu nedenle daha karmaşık problemlerin çözümü için çok katmanlı problemlerin çözümü için çalışmalar yapılmaya başlanmıştır. 1980’li yıllara gelindiğinde ise çok katmanlı algılayıcılar geliştirilerek ilerlemiştir (Öztemel, 2006).

Öztemel (2006), yapay sinir ağlarıyla ilgili çalışmaları 1970 öncesi ve sonrası olarak ikiye ayırmıştır. 1970 yılında YSA’nda önemli bir dönüm noktası başlamış ve o zamana kadar olmaz diye düşünülen birçok sorun çözülerek yeni bir süreç başladığını belirtmiştir.

1990’lı yıllardan itibaren birçok çalışma ve uygulama geliştirilmiştir. Özellikle yapay sinir ağlarını eğitmek için gerekli süreleri kısaltmak, yeni ve daha verimli öğrenme algoritmaları geliştirmek, zamana bağlı olarak değişen modellere karşılık verebilen ağlar ve silikon sinir ağları geliştirmek, yapılan araştırmaların en önemli amaçlarını oluşturmuştur (Yücesoy, 2011).

Günümüzde ise yapay sinir ağları, diğer yapay zekâ tahmin yöntemlerinden olan bulanık mantık ve genetik algoritma ile birlikte daha etkili çözümler sunmaktadır. Sınıflandırma, tahmin ve örüntü tanıma gibi konularda sıklıkla YSA kullanılmaktadır.

3.3. Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağları da diğer modeller gibi kendine özgü özellikler bulundurmaktadır. Bu özellikler arasında hata toleransına sahip olma, genelleme yapabilme ve öğrenebilir oluşu,

doğrusal olmayan yapıları modelleyebilme, birbirinden farklı problemler için uyarlanabilme, hızlı analiz ve tasarım kolaylığı, paralel yapısı yer almaktadır. Yapay sinir ağlarının bu özellikleri günümüzde kullanılan diğer yöntemler yerine kullanılmasını sağlamıştır.

Yapay sinir ağlarının diğer modellere göre bazı farklı özellikleri olsa da temel özellikleri aşağıdaki gibi sıralanabilir (Öztemel, 2006).

- YSA'nın kullanıma alınması için eğitilmesi ve test edilmesi gerekmektedir. Mevcut örnekler eğitim ve test kümesi olarak iki ayrı sete ayrılır. Ayrılan setlerden eğitim kümesi ile ağ eğitilir ve ağ bütün örneklere doğru cevaplar vermeye başladıysa eğitim işi tamamlanmış olarak kabul edilir. Ağ daha önce hiç görmediği test kümesindeki verilere kabul edilebilir bir ölçüde doğru cevaplar veriyorsa ağın performansı iyi kabul edilir ve kullanıma alınır .

- Görülmemiş örnekler hakkında bilgi üretebilir.
- Algılamaya yönelik olaylarda kullanılabilirler.
- Şekil (örüntü) ilişkilendirme ve sınıflandırma yapabilirler. Bir şeklin eksik kalan kısmını tamamlayabilirler.
- Eksik bilgi ile çalışabilirler.
- Hata toleransına sahiptir.
- Dereceli bozulma gösterirler. Bir hata ortaya çıkınca ağ büyük bir hata ile birden bozulmaz.
- Dağıtık belleğe sahiptir. Bilgi tüm ağa yayılmış durumdadır.
- Sadece nümerik bilgi ile çalışırlar. Sembolik ifadelerin sayısal karşılıklarının olması gerekmektedir.

3.4. Yapay Sinir Ağlarının Avantaj ve Dezavantajları

YSA'lar yapısı gereği sahip olduğu özellikler sayesinde birçok avantaja sahiptir. YSA'nın en önemli avantajları aşağıda sıralanmıştır.

1. Yapay sinir ağları sahip olduğu genel özelliklerden hızlı analiz sayesinde problemi çözmeye diğer yöntemlerine göre zamanı çok daha verimli kullanır çözüme daha hızlı ulaşır.

2. Yapay sinir ağlarının en büyük avantajı öğrenme kabiliyetinin olmasıdır. Verilen örnekler yardımıyla öğrenir ve sürekli kendisini geliştirir. Yeteri miktarda örnek içeren ve YSA'nın yapısına göre düzenlenmiş olan giriş ve çıkış verilerinin sağlanması gerekir.

3. Gerçek hayatta problemlerin çoğu doğrusal olmayan problemlerden oluşmaktadır. YSA doğrusal olmayan problemlerin çözümünde diğer yöntemlere göre çok daha başarılı olduğundan birçok alanda kullanılmaktadır.

4. Yapay sinir ağları farklı değişken ortamlara uyum sağlayan esnekliğe sahiptir.

5. Şekil tanıma, genelleme, sınıflandırma ve ilişkilendirme konularında güçlü bir yöntemdir. YSA, eğitim sürecinin ardından, eğitim kümesi dışındaki veriler için de çıkış verileri üretir. Test verileri ile bu çıkışlar test edilir. Eğer bu çıkış değerleri kabul edilebilir hata değeri içerisinde ise, YSA genelleme yapabilmektedir (Sarı, 2016).

6. YSA yapısı insan beynine benzediği için deneyimleyerek öğrenir. Deneyimleyip öğrendikleri sayesinde genelleme yaparak sonuç çıkartabilir.

7. YSA, sisteme yeni bilgilerin eklenmesi ve sistemde değişikliklerin olması durumunda tekrar eğitilebilir.

8. Yapay sinir ağları eksik bilgi ile çalışabilmektedir. Ayrıca belirsiz ve ulaşılamayan bilgiler içinde sonuç çıkartabilir.

9. Yapay sinir ağları hata toleransına sahip olduğu için ağın herhangi bir hücresinin bozulması ağın tümünü etkilememektedir. Ancak ağın bozuk olan hücresinin etkisine göre, ağın performansında azalma oluşabilmektedir (Sarı, 2016).

10. Yapay sinir ağları paralel çalışabildikleri için daha hızlı ve güvenilir olması doğru sonuçlar doğurmaktadır.

YSA'ların belirtilen avantajlarının yanında bazı dezavantajları da vardır.

1. Yapay sinir ağının yapısının oluşturulmasında ve modelin seçilmesinde belli bir kural yoktur. Genellikle deneme yanılma yöntemi kullanılarak kullanıcının tecrübesine ve sezgilerine bağlı olarak yapılmaktadır. Bu şekilde yapılması problem teşkil etmektedir. Çünkü problem için uygun bir ağ yapısı oluşturulamaz ise problemin çözümünden istenen sonuç alınamayabilir ve ağa duyulacak güven azalır (Sarı, 2016). Uygun yapay sinir ağı yapısının bulunması için çok fazla test yapılması gerekmektedir.

2. YSA'lar uygun çözüme her zaman ulaşmayabilir. Bu da modelin sonuçlarına olan güveni azaltmaktadır.

3. YSA üzerlerinde çalışacağı donanıma bağımlı olarak çalışırlar. Paralel işlem yaptıkları için çok hızlı çalışan paralel işlemcilerle ihtiyaç duyarlar.

4. Yapay sinir ağı'nın eğitiminin ne zaman durdurulacağı ile ilgili net bir yöntem yoktur. Mevcut yöntemin sürekli en iyi performansı sağlayacağı garanti değildir.
5. Bazı ağlarda, kullanılacak parametrelerin belirlenmesi ile ilgili bir kural yoktur.
6. YSA modeli içerisinde birden çok öğrenme kuralı bulunmaktadır. Kullanılacak öğrenme algoritmasının YSA yapısına uygun olmayabilir ve istenilen sonuç alınamaz.
7. Sistem içerisinde ağı'nın davranışları açıklanamaz. Bu durum ağa olan güveni azaltmaktadır.

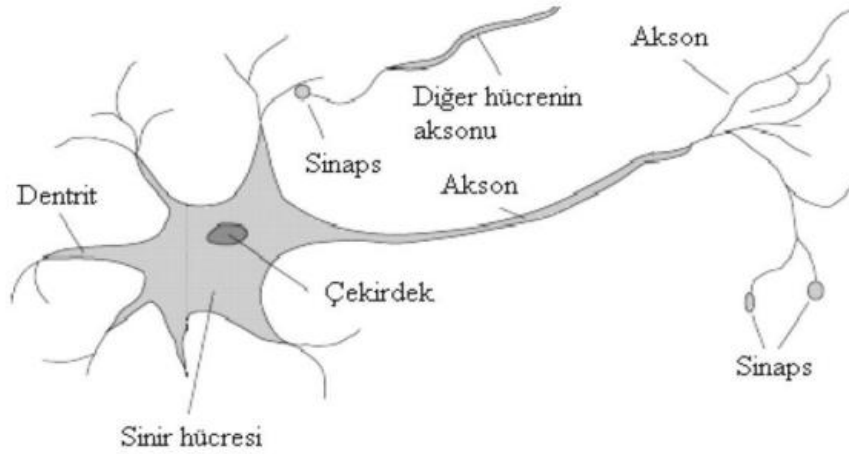
3.5. Yapay Sinir Ağlarının Yapısı ve Elemanları

Yapay sinir ağları, insan beyninin çalışmasını temel alarak bilgisayar sistemlerine aktarım işlem yapmaya dayanır. YSA'nın işleyişi insan beyninin işleyişi ile benzemektedir. Bu nedenle önce insan beyninin yapısı ve hücrelerini tanıtıp daha sonra yapay sinir ağlarının oluşumu yapısına değinilecektir.

3.5.1. Biyolojik Sinir Hücresi

İnsan beyninin çalışma sistemi, günümüzde bile tam olarak çözülememiş bir yapıdır. Özellikle, insan vücudunun diğer organlarında yer alan hücrelerin aksine farklı şekilde yenilenme özelliği bulunmayan beyin insana; hatırlama, düşünebilme ve eski tecrübelerle başvurabilme yeteneğini sunan sinir hücrelerinin işleme prensibi hala büyük oranda bilinmemektedir. Bir insan beyninde ortalama 10^{10} sinir hücresi ve bu hücrelerin de 6×10^{10} dan fazla bağlantıya sahip olduğu bilinmektedir. İnsan beyninin gücü ise; hayli çok olan bu sinir hücreleri ve aralarında bulunan bağlantıların genetik yapıları yardımıyla öğrenme yeteneğidir (Yücesoy, 2011).

Biyolojik sinir ağları, insan beyninin çalışması için en önemli yapılardan birisidir. İnsanın bütün davranışlarını ve çevresini anlamasını sağlar. Biyolojik sinir ağları beş duyu organından gelen bilgiler doğrultusunda geliştirdiği algılama ve anlama mekanizmalarını çalıştırarak olaylar arasındaki ilişkileri öğrenmektedir (Gürsoy, 2012).



Şekil 3.1 Biyolojik Sinir Hücresi Yapısı

Kaynak: (Doğan, 2012)

Biyolojik sinir hücresi, beyin merkez olmak üzere üç katmandan oluşmaktadır. Bu katmanlar; çevreden gelen sinyalleri elektriksel sinyallere çeviren alıcı sinirler, beyin ürettiği sinyalleri uygun tepkilere dönüştüren tepki sinirleri ve tepki sinirleri arasında sürekli ileri geri besleme yaparak uygun sinyaller üreten merkezi sinir sisteminden oluşmaktadır. Sinir sisteminin temel elemanları nöronlardır. Nöronlar; dendritler, hücre gövdesi, aksonlar ve sinaplardan oluşur (Doğan, 2012).

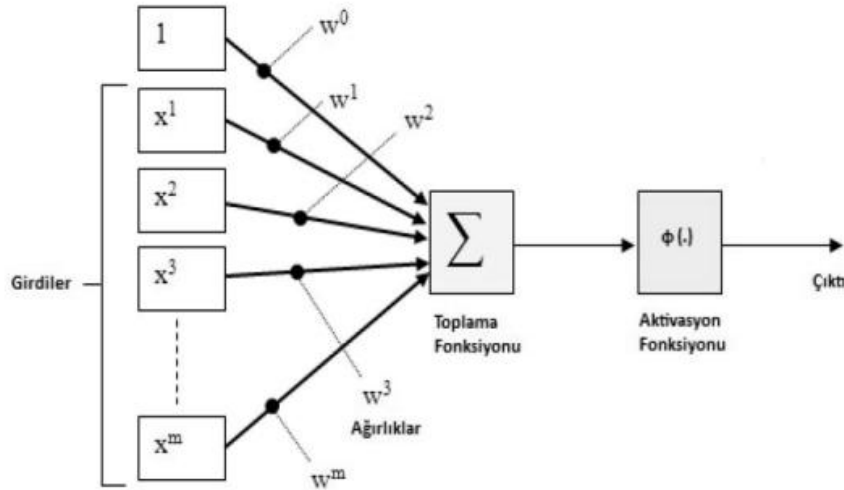
Sinir hücresi, dendrit adı verilen uzantılarla diğer sinir hücresinden aldığı işaretleri hücre gövdesine taşır. Hücre gövdesinde toplanan bu işaretler değerlendirilerek bir çıkış işareti üretilir. Bu işaretler aksonlar aracılığıyla diğer sinir hücresine gönderilir. Bir sinir hücresinde birden çok giriş olmasına rağmen sadece tek bir çıkış vardır. İki sinir hücresinde, birinin çıkış elemanı olan akson ile diğer sinir hücresinin giriş elemanı dendriti arasında olan bağlantıya sinaps adı verilmektedir ve sinapstik bağ oluşturmaktadır. Vücut içerisinde yer alan milyarlarca sinir hücresi sinapstik bağlarla birbirlerine bağlanarak sinir ağını oluşturmaktadır (Sarı, 2016).

3.5.2. Yapay Sinir Hücresi

Biyolojik sinir ağları sinir hücrelerinden oluşurken, yapay sinir ağları da yapay sinir hücrelerinden oluşur. Bu sebeple yapay sinir hücrelerinin biyolojik sinir hücreleri ile aynı yapıda olduğunu söylenebilir. Yapay sinir hücrelerinin farklı adlandırılmaları mevcuttur. Bunlar düğüm (node), birim (unit) veya işlemci eleman (processing unit)'dir. Yapay sinir

ağları çok sayıda yapay sinir hücrelerinin birbiriyle bağ kurmasıyla meydana gelmektedir (Akpınar, 1994).

Yapay sinir ağları, temelde beş bölümden oluşmaktadır. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu (birleştirme fonksiyonu), aktivasyon fonksiyonu (transfer fonksiyonu) ve çıktı olmak üzere beş bileşen olarak sıralanabilir (Öztemel, 2006).



Şekil 3.2 Yapay Sinir Hücresi Yapısı

Kaynak: (Çuhadar, 2009)

Girdiler (X_i): Yapay sinir hücresine dışarıdan gelen bilgilerdir. Bilgiler dışarıdan geldiği gibi başka hücrelerden veya hücrenin kendisinden de gelebilir (Öztemel, 2006). Girişler sadece verileri bir sonraki aşamaya iletmede görev yapmaktadır.

Ağırlıklar (W_i): Yapay sinir hücresi tarafından alınan girişlerin sinir üzerinde ne kadar etkisi olduğunu belirleyen katsayılardır. Her bir girişin kendine ait bir ağırlığı vardır (Çuhadar, 2009). Ağırlık değerinin küçük ya da büyük olması önemli değildir.

Toplama Fonksiyonu (Birleştirme Fonksiyonu): 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 (Öztemel, 2006).

Aktivasyon Fonksiyonu (Transfer Fonksiyonu): Aktivasyon fonksiyonu, 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, ağıın 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. Fonksiyonun doğrusal olması genelde tercih edilemez. Transfer fonksiyonu olarak hangi fonksiyonun seçileceği sinir ağıının verilerine ve ne öğrenmek istediğine bağlı olarak değişmektedir. En çok kullanılan türler ise doğrusal, sigmoid ve tanjant hiperbolik fonksiyonudur. Transfer fonksiyonları, çıktı değerlerinin belli 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 (Öztemel, 2006).

Çıktı: Aktivasyon fonksiyonu tarafından belirlenen çıktı değerine denir. Üretilen çıktı, dışarıya veya farklı 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, ağıın nihai çıktısı olarak dışarıya ya da çıktıyı oluşturan nöronun bağlı olduğu diğer nöronlara girdi olarak gönderilmesinden sorumludur. YSA tek bir nörondan oluştuğu için bu ağ, Y çıktısını dışarıya nihai çıktı olarak göndermektedir (Öztemel, 2006).

Biyolojik sinir hücresi ile yapay sinir hücresi arasındaki karşılaştırma Tablo 3.1.’de verilmiştir.

Tablo 3.1 Biyolojik Sinir Ağları ile Yapay Sinir Ağları Karşılaştırması

Biyolojik Sinir Ağı	Yapay Sinir Ağı	Görevleri
Sinir Hücresi (Nöron)	Yapay Sinir Hücresi	Sistem
Sinaps	Ağırlıklar	Verileri hafızada saklar.
Dendrit	Toplama Fonksiyonu	Çevreden gelen veriyi alır.
Hücre Gövdesi	Aktivasyon Fonksiyonu	Gelen veriyi toplayarak yorumlar ve çıktıyı oluşturur.
Akson	Çıktı	Oluşan veriyi iletir.

Kaynak: (Ballı, 2014)

Yapay sinir hücresi, biyolojik sinir hücresindeki karşılığı nörondur. Veriler biyolojik sinir hücresinde sinapslar ile iletilirken, yapay sinir hücresinde veriler ağırlıklar ile çarpılarak iletilmektedir. Dendrit görevini yapay sinir hücresinde toplama fonksiyonu, hücre gövdesi

görevini ise aktivasyon fonksiyonu üstlenmektedir. Biyolojik sinir hücresinde aksonlar yoluyla iletilen bilgiler, yapay sinir hücresinde çıktı olarak nitelendirilmiştir.

3.5.3. Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları, yapay sinir hücrelerinin bağlanarak bir araya gelmeleri ile oluşur. Yapay sinir ağlarını üç katmanda inceleyebiliriz. Birinci katman giriş katmanıdır, ikinci katman ara (gizli) katmadır ve üçüncü katman çıkış katmanıdır.


Bu katmanları aşağıdaki gibi açıklamak mümkündür.

Giriş Katmanı: En az bir girdi elemanının bulunduğu bölüme giriş katmanı denir. Giriş katmanında veriler herhangi bir işleme tabi tutulmadan giriş ile aynı değerde çıktılar üretirler (Adıyaman, 2007).

Ara Katmanlar: Girdilere belirli işlemlerin uygulandığı bölümdür. Seçilen ağ yapısına göre işlem katmanının, yapısı ve fonksiyonu da değişebilir. Ara katman, tek bir katmandan oluşabileceği gibi birden fazla katmandan da oluşabilir (Adıyaman, 2007).

Çıktı Katmanı: Çıktı katmanı en az bir çıktıdan oluşur ve çıktı ağ yapısında bulunan fonksiyona bağlıdır. Bu katmanda işlemler gerçekleştirilir ve burada üretilen çıktılar dışarıya gönderilir (Adıyaman, 2007).

Yapay sinir ağı sistemine geçmişe ait verilerin girildikten sonra işlemci elemanlar (nöronlar) ve bağlantı elemanları (aksonlar) işlemi sürecini çıkışa doğru sürdürmektedir.

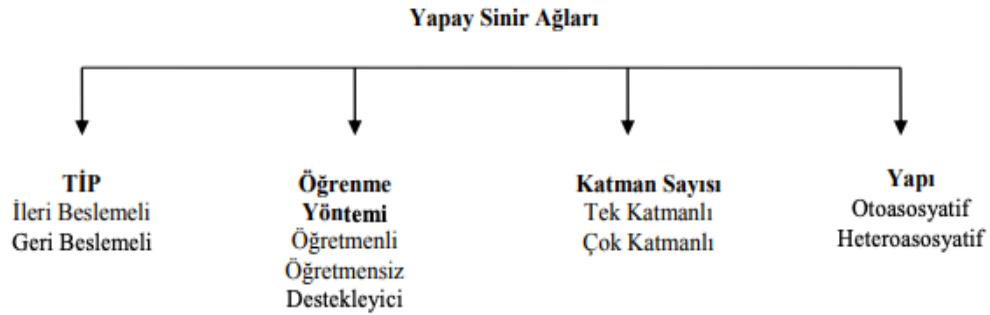


Şekil 3.3 Yapay Sinir Ağı Yapısı

Kaynak: (Öztemel, 2006)

3.6. Yapay Sinir Ağlarının Sınıflandırılması

YSA'nın birçok türü vardır. Yapay sinir ağlarını tiplerine, öğrenme yöntemlerine, katman sayılarına ve yapılarına göre sınıflandırabiliriz.



Şekil 3.4 Yapay Sinir Ağlarının Sınıflandırılması


Kaynak: (Hamzaçebi, 2011)

3.6.4. Tiplerine Göre Yapay Sinir Ağları

Yapay sinir ağlarını nöronları aralarında bağlantı yapma tipine göre ikiye ayırabiliriz. Bunlar ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağlarıdır.

3.6.4.1. İleri Beslemeli Yapay Sinir Ağları

Çok katmanlı sinir ağları olarak da tanımlanan ileri beslemeli yapay sinir ağları modelinde hücreler katmanlar halinde bulunur. Bir katmanın giriş verileri işlendikten sonra diğer katmana çıkış verileri olarak aktarılırlar. Dış katmandaki veriler bir işlem yapılmadan gizli katmana, orada işlendikten sonra da çıktı katmanına aktarılır. Bu modelin en önemli özelliği verilerin ileri doğru akması, geriye doğru bir veri aktarımı olmamasıdır (Çoban, 2019).

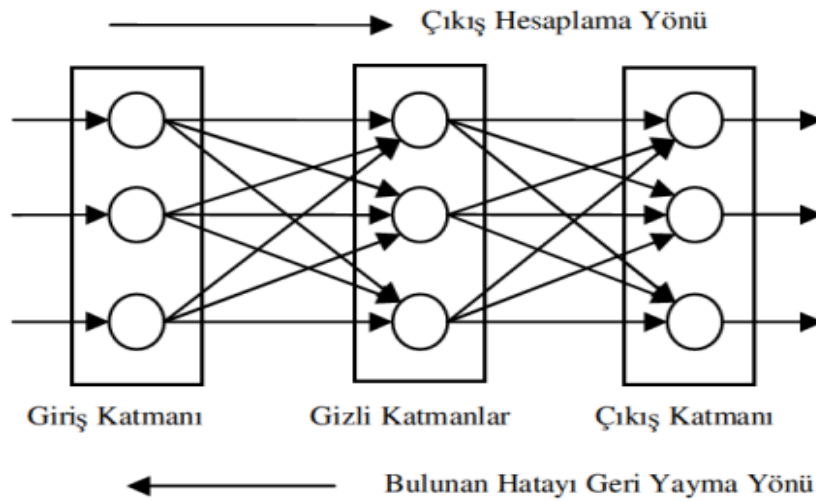


Şekil 3.5 İleri Beslemeli Yapay Sinir Ağları

Kaynak: (Hamzaçebi, 2011)

3.6.4.2. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağları (feedback/recurrent) modelinde sadece ileriye doğru veri akışı olmaz, geriye doğru da bir veri akışı söz konusudur. Veriler çıkıştan girişe veya gizli katmandan girişe doğru iletilirler. Doğrusal olmayan dinamik bir yapıdır. Geriye doğru besleme yapmasından dolayı hataları azaltmaya yönelik çalışır. Bu nedenle zaman serileri ve tahmin problemlerinde makul sonuçlar vermektedir (Çoban, 2019). İleri beslemeli yapay sinir ağlarına göre dinamik yapıdadır.



Şekil 3.6 Geri Beslemeli Yapay Sinir Ağları

Kaynak: (Öztürk ve Şahin, 2018)

3.6.5. Öğrenme Yöntemlerine Göre Yapay Sinir Ağları

Yapay sinir ağlarında ağa verilen örneklerle ağ öğrenir yani insanlar gibi örneklerle eğitilirler.

Öğrenme, YSA'nın başlangıç anında rastgele atanan ağırlık değerlerinin belirlenmesi işlemidir. Ağ, gördüğü her örnek için ağırlık değerlerini değiştirmektedir. Bu süreç ağın doğru ağırlık değerlerine ulaşabilmesi, örneklerin temsil ettiği olaya ait genellemeler yapabilecek düzeye gelebilmesi ile sonuçlanmaktadır. Ağırlık değerlerinin değiştirilmesi, kullanılan öğrenme stratejisine bağlı olarak değişkenlik gösteren ve öğrenme kuralı olarak adlandırılan kurallar bütünü ile yürütülmektedir (Olgun, 2009).

Yapay sinir ağları öğrenme yapılarına göre öğretmenli (danışmanlı) öğrenme, öğretmensiz (danışmansız) öğrenme ve destekleyici (takviyeli) öğrenme olarak üç ana gruba ayrılmaktadır.

3.6.5.1. Öğretmenli (Danışmanlı) Öğrenme

Yapay zeka yöntemi kullanılarak yapılan tahminlemenin büyük bir çoğunluğunda öğretmenli veya diğer bir adıyla danışmanlı öğrenme kullanılmaktadır. Burada kullanılan ağ yapısı gereği gerçekleşen ve istenilen çıkış değerleri karşılaştırılarak ilerlenir. Burada hata değerinin minimum olması istendiğinden dolayı ağ üzerindeki ağırlıklar sürekli değiştirilerek ağın doğru sonuçlar vermesi sağlanır (Olgun, 2009).

Danışmanlı öğrenmede ağın eğitimi için bir öğretmen yardımcı olmaktadır. Öğretmen ağa, öğrenilmesi istenen olayla ilgili örnek girdi değerlerinden ve hedef (gerçek) çıktı değerlerinden oluşan bir veri seti verir. Ağ verilen girdileri işleyerek kendi çıktısını üretir. Üretilen çıktı gerçek çıktı ile karşılaştırılarak hata (sapma) oranı tespit edilir. Buradaki hata gerçekleşen çıktı ile ağın öğrenmesi sonucunda oluşan çıktı arasındaki farktır. Bu hatayı en aza indirmek için bağlantıların ağırlıkları yeniden düzenlenir. Bu işlem hata seviyesi en uygun seviyeye inene kadar sürer. Hata değeri istenilen düzeye geldiğinde eğitim işlemi bitmiş olur ve tüm ağırlıklar sabitlenir (Yanık, 2019).

Danışmanlı öğrenme algoritmalarında, genellikle hataların hesaplanması için Ortalama Mutlak Hata ve Hata Kareleri Ortalamasının Karekökü performans ölçütleri kullanılır. Bu performans ölçütleri yardımıyla ağın, kendi ürettiği çıktılar ile hedef çıktılar arasında oluşan hata sinyallerini dikkate alarak kıyaslama yapması sağlanır. Ağın ürettiği çıktılar ile hedef çıktılar arasındaki hata sinyallerini minimize etmek amacıyla, işlem elemanları arasındaki bağlantı ağırlıkları düzenlenir. Başka bir ifadeyle, danışmanlı öğrenme ile yapay sinir ağı, örnek girdiyi işleyerek kendi çıktısını üretir ve gerçek çıktı ile karşılaştırır. Öğrenme metodu sayesinde, hatayı en aza indirmek için bağlantı ağırlıkları yeniden düzenlenerek yapay sinir ağının danışmana benzemesi amaçlanır (Haykin, 1999).

Bu sayede hedef çıktı değerlerine en yakın çıktı değerleri yapay sinir ağları tarafından üretilebilir. Öğretmenli öğrenmeye Delta Kuralı örnek olarak verilebilir.

3.6.5.2. Öğretmensiz (Danışmansız) Öğrenme

Bu öğrenme yöntemine kendi kendine öğrenme yöntemi de denilmektedir. Danışmansız öğrenme yönteminde ağ yapısında sadece giriş değerleri tanıtılarak parametreler arasındaki bağlantıyı kendisi kurması istenmektedir. Burada danışmanlı öğrenme yönteminde olduğu gibi herhangi bir öğrenmeye yardımcı veriler bulunmamaktadır. Danışmansız öğrenmede girdi verileri aynı zamanda çıktı verileri olarak görülmektedir (Yanık, 2019).

Öğretmensiz öğrenme yöntemi genellikle sınıflandırma problemlerinin çözümünde kullanılır. Öğretmensiz öğrenmeye Hebb, Hopfield ve Kohonen öğrenme kuralları örnek olarak verilebilir.

3.6.5.3. Destekleyici (Takviyeli) Öğrenme

Destekleyici öğrenme sisteme yardımcı olan bir danışman olduğu için danışmanlı öğrenmeye benzemektedir. Ancak danışman girdi ve çıktı setini sisteme öğretmek yerine, üretilen çıktının doğru ya da yanlış olduğunu gösteren bir sinyal üretir. Sistem danışmandan aldığı bu sinyalleri dikkate alarak öğrenmeye devam eder. Doğrusal vektör parçalama modeli diye isimlendirilen LVQ (Linear Vektör Quantization) destekleyici öğrenmeyi kullanan modellere örnek olarak gösterilebilir (Öztemel, 2006).

3.6.5.4. Yapay Sinir Ağlarında Öğrenme Kuralları

Yapay sinir ağlarında öğrenme kurallarında birçok yöntem bulunmaktadır. Ancak en sık kullanılan öğrenme kurallarını; Hebb Kuralı, Hopfield Kuralı, Kohonen Kuralı ve Delta Kuralı olarak sıralayabiliriz.

Hebb Öğrenme Kuralı

Hebb Kuralı 1949 yılında Donalt Hebb tarafından geliştirilmiştir. Daha sonra bu kuralı Hebbin bahsedilen yılda yazmış olduğu “The Organization of Behavior “adlı kitabında yer almaktadır. Kural özetle şu şekildedir. Eğer Nöronlar arasındaki ağırlıklar aynı işarette ise iki bağ arasında güçlü bir bağ bulunmalıdır. Durum tam tersi ise arasındaki bağ değeri zayıf bir bağ olmalıdır (Keskenler, 2007).

Hebb kuralı ilk kural olduğu için sonraki tüm kuralların temelini oluşturur. Diğer öğrenme kuralları Hebb kuralına bağlı olarak gelişmiştir.

Hopfield Öğrenme Kuralı

Hopfield öğrenme kuralının çıkış noktası Hebb kuralıdır. Bu yüzden temelde benzer yönleri bulunmaktadır ancak bazı farklılıklar vardır.

Bu kurala göre, ağırlıkların güçlendirilmesi işleminde güçlendirme veya zayıflatma için bir büyüklük tanımlamak gerekmektedir. İstenen çıktı ve girdinin her ikisi de aktif veya pasifse, bağlantı ağırlığı öğrenme oranı kadar artırılır. Ters durumda ise bağlantı ağırlığı öğrenme oranı kadar azaltılır. Hebb kuralından farklı olarak, elemanlarının bağlantılarının ne kadar güçlendirilmesi veya zayıflatılması gerektiğini belirler. Ağırlıkların güçlendirilmesi

veya zayıflatılması öğrenme katsayısı ile yapılmaktadır ve öğrenme katsayısı kullanıcı tarafından belirlenen 0-1 arasında sabit pozitif bir değerdir (Olgun, 2009).

Kohonen Öğrenme Kuralı

Kohonen 1982 yılında bu kuralı geliştirilmiştir. Kohonen öğrenme kuralında sinir hücreleri ağırlıkları değiştirmek için birbirleri ile yarışır. En büyük çıktıyı üreten hücre kazanan hücre olur ve bağlantı ağırlıklarını değiştirir. Kazanan hücre, yakınındaki hücelere göre daha kuvvetli hale gelmektedir (Öztemel, 2006).

Kohonen Öğrenme kuralına göre ağ kendi kendini danışmana ihtiyaç duymadan eğitebilmektedir. Bunun olmasını sağlayan aynı anda paralel bir şekilde en optimal sonucu üretebilmek için düğümlerin yarışmasıdır. Sistem girdi verisini gruplandırmak için hangi özellikleri kullanacağına kendi kendisine karar verir. Ağın bağlantı ağırlıkları için başlangıç değerlerinin verilmesi ve girdi değerlerinin normalleştirilmesi gereklidir (Sarı, 2016).

Delta Öğrenme Kuralı

Hebb kuralının geliştirilmiş hali olarak bilinen Delta kuralı Widrow ve Hoff tarafından ortaya atılmıştır. En çok kullanılan öğrenme kurallarından biridir.

Beklenen çıktı ile gerçekleşen çıktı arasındaki farkı azaltmak için ağırlıkların sürekli değiştirilmesi gerektiğini belirtir. Ağın hatasının minimizasyonu için, ağırlıklar sürekli güncellenmektedir. Bu kural en küçük kareler kuralını kullanır (Sarı, 2016).

3.6.6. Katman Sayılarına Göre Yapay Sinir Ağları

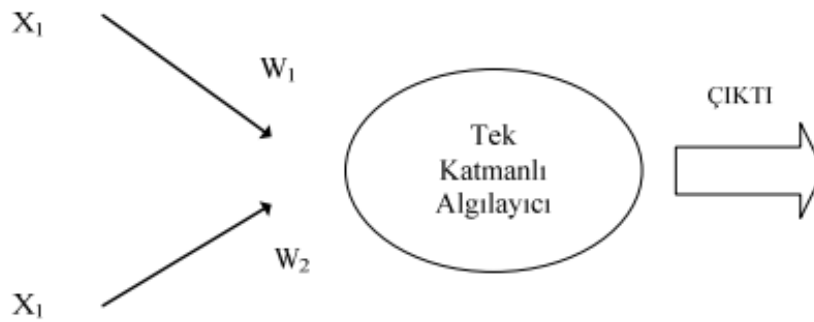
YSA, yapay sinir hücrelerinden oluşmaktadır ve yapay sinir hücrelerinin oluşturduğu kümeye de katman denmektedir. Burada girdi sinir hücreleri girdi katmanını oluştururken çıktı sinir hücreleri çıktı katmanını oluşturmaktadır. Yapay sinir ağları tek katmandan oluşuyor ise tek katmanlı, birden fazla katmandan oluşuyor ise çok katmanlı yapay sinir ağı olarak adlandırılır (Hamzaçebi, 2011).

3.6.6.1. Tek Katmanlı Yapay Sinir Ağları

Literatürde ilk yapay sinir ağı çalışmaları ve geliştirilen ilk modeller tek katmanlı yapay sinir ağları ile yapılmıştır. Tek katmanlı yapay sinir ağların sadece iki katmandan oluşur. Bunlar girdi ve çıktı katmanlarıdır (Öztemel, 2006). Bu yöntem daha çok doğrusal problemlerin çözümünde kullanılmıştır ancak doğrusal olmayan problemlerin çözümünde başarısız kalmıştır.

Tek katmanlı yapay sinir ağı modellerinin en önemlileri Basit Algılayıcı Modeli, Adaptif Doğrusal Eleman ve Çoklu Adaptif Doğrusal Eleman'dır.

Tek katmanlı yapay sinir ağı sadece girdi ve çıktı katmanından oluşmaktadır. Her ağı bir ya da daha fazla girdisi ve çıktısı vardır. Çıktı üniteleri “Ç” bütün girdi ünitelerine “X” bağlanmaktadır ve her bağlantının bir ağırlığı “W” vardır. Bu ağılarda proses elemanlarının değerinin sıfırdan farklı olmasını önleyen eşik değeri vardır ve bu daima “1”dir (Öztemel, 2006).



Şekil 3.7 Tek Katmanlı Yapay Sinir Ağları

Kaynak: (Öztemel, 2006)


3.6.6.2. Çok Katmanlı Yapay Sinir Ağları

Tek katmanlı yapay sinir ağı doğrusal problemlerin çözümünde kullanıldığı için girdi ve çıktı arasında doğrusal olmayan bağlantı olduğu zaman yetersiz kalmaktadır. Böyle durumlarda daha gelişmiş olan çok katmanlı yapay sinir ağı kullanılmaktadır.

Çok katmanlı ağı eğitmek tek katmanlı ağı eğitmeye göre daha zordur. Yine de birçok problemin çözümünde çok katmanlı ağların eğitimi, tek katmanlı ağların eğitimi göre daha başarılı olabilmektedir. Bunun sebebi, tek katmanlı ağların problemin çözümü için yetersiz kalmalarındandır (Yücesoy, 2011).

Çok katmanlı ağılarda yapay sinir hücreleri yapay sinir ağını oluştururken rasgele bir araya gelmezler. Yapay sinir hücreleri üç katman halinde ve her katman kendi içinde paralel olarak yerleşerek çok katmanlı ağı oluştururlar.

Çok katmanlı yapay sinir ağlarının yapısı aşağıda verilen Şekil 3.8'de gösterilmektedir. Şekilden de görüldüğü gibi çok katmanlı sinir ağı ileriye doğru bağlantılı ve üç katmandan oluşan bir ağıdır.



Şekil 3.8 Çok Katmanlı Yapay Sinir Ağları

Kaynak: (Öztemel, 2006)

Girdi Katmanı: Dışarıdan gelen girdi verilerini “ G_1, G_2, \dots, G_N ” alınarak ara (gizli) katmana gönderilir. Gelen veri üzerinde herhangi bir işlem yapılmadan bir sonraki katmana iletilir. Katmana birden çok girdi gelebilmektedir. Her süreçte bir girdi ve bir çıktı vardır. Bu çıktı sıradaki katmandaki bütün sürece gönderilir. Girdi katmanındaki tüm süreçler daha sonraki süreçlerin hepsi ile ilişkilidir (Yılmaz, 2018).

Ara (Gizli) Katman: Ara katman girdi katmanından gelen bilgileri işleyerek bir sonraki katmana gönderir. Çok katmanlı yapay sinir ağlarında birden fazla ara katman ve bu ara katmanlarda da birden fazla işlem bulunabilir. Ara katmanın işlemi ve bir sonraki katmanın işlemleri birbirine bağlıdır (Yılmaz, 2018).

Çıktı Katmanı: Girdi katmanındaki girdilerin ara katmana iletilmesinde sonra girdi katmanından gelen girdilere karşılık üretilen çıktıların “ $\Ç_1, \Ç_2, \dots, \Ç_N$ ” belirlenmesi ile dışarıya gönderdiği katmandır. Çıktı katmanından bir veya birden fazla çıktı bulunabilir. Her işlem elemanının bir çıktısı olmakla birlikte her bir işlem elemanı öncesinde bulunan bütünü işlem elemanlarına bağlıdır (Yılmaz, 2018).

3.6.7. Yapısına Göre Yapay Sinir Ağları

Yapay sinir ağları yapısına göre “otoasosyatif” ve “heteroasosyatif” olmak üzere iki sınıfta incelenebilir. Girdi nöronlarının çıktı olarak görev yaptığı ağlar otoasosyatif ağlardır ve Hopfield ağlar bu türe aittir. Girdilerin ve çıktıların farklı olduğu ağlar heteroasosyatif ağlardır. Khonen, algılayıcı ve çok katmanlı algılayıcı ağlar bu türe aittir (Hamzaçebi, 2011).

3.7. Yapay Sinir Ağlarının Tasarımı ve Eğitimi

Yapay sinir ağlarında hücre elemanlarının bağlantılarının ağırlık değerlerini belirleme işlemine “ağın eğitilmesi” denir. İlk başta bu ağırlık değerleri rastgele alınır. Yapay sinir ağları kendine örnekler gösterildikçe bu ağırlık değerlerini yenileyerek amaca ulaşmaya çalışırlar. Ağırlıkların sürekli yenilenip istenilen sonuca ulaşana kadar geçen zamana “öğrenme” denir. Ağırlık değerlerinin değişmesi belirli kurallara göre yürütülmektedir. Bu kurallara “öğrenme kuralları” denir (Yanık, 2019).

Ağın doğru ağırlık değerlerine ulaşması, örneklerin temsil ettiği olay hakkında genellemeler yapabilme yeteneğine kavuşması demektir. YSA'nın eğitilmesinde iki aşama vardır. İlk ağı sunulan örnek için ağın üreteceği çıkış belirlenir. Çıkış değerinin doğruluk derecesine göre ikinci aşamada, ağın bağlantılarının sahip olduğu ağırlıklar değiştirilir (Öztemel, 2006).

YSA' da eğitim süreci veri setinin rastgele seçimle 3 alt veri setinin oluşturulmasıyla başlar. Bu veri setleri eğitim, doğrulama ve test verilerini içermelidir. Genellikle veri örneklerinin %50–70 arası eğitim setinde, %50–30 arası doğrulama ve test setinde yer alır. Doğrulama ve test setine de verilerin rastgele ve eşit oranlarda dağıtılmasına dikkat edilir. Ağ ağırlıklarının güncellenmesi ve nihai değerlerinin kestirimi eğitim aşamasında gerçekleşir. Eğitim sürecinin ne zaman sonlandıracağına karar vermek ezberleme probleminin önüne geçmek ve en etkili modeli oluşturmak için önemlidir. Ağırlıkların sürekli yenilenmesi ağın öğrenmeye çalıştığı olayla ilgili genelleme yapabilecek düzeye ulaşmasıyla yani en doğru ağırlık değerlerine ulaşmasıyla son bulur (Yanık, 2019).

Yapay sinir ağlarının başarısı, uygulanacak yaklaşımlar ve deneyimlerle doğrudan ilgilidir. Uygulamanın başarısında uygun yöntemi belirlemek büyük önem taşır. Yapay sinir ağının geliştirilmesi sürecinde ağın yapısına ve işleyişine ilişkin aşağıdaki kararların verilmesi gerekir (Ballı, 2014):

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

YSA'nın uygun parametrelerle tasarlanması durumunda yapay sinir ağları devamlı 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 (Ballı, 2014).

3.7.1. Yapay Sinir Ağları Ağ Yapısının Seçimi

Yapay sinir ağlarının tasarımı sürecinde ağ yapısının seçilmesinde önemli olan faktör uygulama problemdir. Bu probleme uygun olarak seçilmelidir. Bu yüzden hangi problem için hangi ağın daha uygun olduğunun bilinmesi önemlidir. Aşağıdaki tablo 3.2'de ağların kullanım amacı ve o alanda başarılı olan ağ türleri gösterilmiştir.

Tablo 3.2 Ağ Türleri ve Kullanım Amacı

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.

Kaynak: (Öztemel, 2006)

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 (Ballı, 2014).

Yapay sinir ağlarında karmaşıklık azaltılmak istediğinde en etkin araç, doğru ağ yapısını seçerek ağ yapısını değiştirmektir.

3.7.2. Öğrenme Algoritmasının Seçimi

Yapay sinir ağlarının ağ yapısını seçtikten sonra uygulamanın başarısını belirleyen en önemli faktör öğrenme algoritmasını doğru seçmektir. Seçilen ağ yapısı öğrenme

algoritmasının seçiminde belirleyicidir. Bu yüzden kullanılacak öğrenme algoritmasının seçimi ağ yapısına bağlıdır.

Öğrenme algoritmalarının uygun oldukları uygulama alanlarına göre sınıflandırılması aşağıdaki tabloda özetlenmiştir.

Tablo 3.3 Uygulama Tiplerine Göre Kullanılabilir Yapay Sinir Ağları

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 Spantion-Temproal Pattern Recognition
Veri Kavramlaştırma	Adaptive Resonance Network Self Organizing

Kaynak: (Öztemel, 2006)

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 (Ballı, 2014).

3.7.3. Ara Katman Sayısının Belirlenmesi

Yapay sinir ağlarının tasarımında diğer bir konu ara katman sayısının belirlenmesidir. Katmanlar aynı doğrultu üzerinde bir araya gelmesiyle oluşur. Genellikle problemlerde 2 veya 3 katman yeterli olmaktadır. Çözümlemek istenilen problemde yer alan girdi ve çıktı katmanları farklılaşabilmekte ve katman sayısının belirlenmesi esnasında araştırmacı deneme-yanılma tekniğiyle en uygun katman sayısını ve en uygun ağ yapısını belirleyebilmektedir (Atasoy, 2012).

3.7.4. 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 ulaşınca 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 artırırken, gereğinden fazla olması ağın verileri ezberlemesine neden olur. Ancak gereğinden az nöron kullanılmasının verilerdeki örüntünün ağ tarafından öğrenilememesi gibi bir sorun yaratabilir (Öztemel, 2006).

3.7.5. Normalizasyon

Yapay sinir ağlarının en belirgin özelliklerinden olan doğrusal olmama özelliğini anlamlı kılan yaklaşım, verilerin bir normalizasyona tabi tutulmasıdır. Verilerin 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 (Ballı, 2014).

Eldeki veri kümesinin [0,1] arasında bir ölçeklendirilebilmesi için o kümenin X_{min} - X_{max} aralığı bulunur. Aşağıdaki formüle göre ölçeklendirme yapılabilir.

$$X_{yeni} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

3.7.6. Performans Fonksiyonu Seçimi

Öğrenme algoritmasını etkileyen en önemli maddelerden biri de performans fonksiyonudur. İleri beslemeli ağlarda genellikle kullanılan performans fonksiyonu hata kareleri ortalamasıdır.

3.8. Yapay Sinir Ağlarının Uygulama Alanları

Yapay sinir ağları genel olarak, doğrusal olmayan, karmaşık ve hata olasılığı yüksek verilere sahip olunan durumlarda ve problemin çözümü için herhangi bir matematik modelin olmadığı durumlarda kullanılmaktadır. Yapay sinir ağlarının başlıca uygulama alanları

sınıflandırma, tahmin ve modelleme olarak ele alınabilir. Günlük hayatta, finansal konulardan mühendisliğe ve tıp bilimine kadar birçok uygulamadan bahsetmek mümkündür. Bunlardan bazıları şöyle sıralanabilir (Öztemel, 2006):

- Veri madenciliği.
- Optik karakter tanıma ve çek okuma.
- Bankalardan kredi isteyen müracaatları değerlendirme.
- Ürünün pazardaki performansının tahmin etme.
- Kredi kartı hilelerini saptama.
- Zeki araçlar ve robotlar için optimum rota belirleme.
- Güvenlik sistemlerinde konuşma ve parmak izi tanıma.
- Robot hareket mekanizmalarının kontrol edilmesi.
- Mekanik parçaların ömürlerinin ve kırılmalarının tahmin edilmesi.
- Kalite kontrolü.
- İş çizelgeleme ve iş sıralaması.
- İletişim kanallarındaki geçersiz ekoların filtrelenmesi.
- İletişim kanallarındaki trafik yoğunluğunu kontrol etme ve anahtarlama.
- Radar ve sonar sinyalleri sınıflandırma.
- Üretim planlama ve çizelgeleme.
- Kan hücreleri reaksiyonları ve kan analizlerini sınıflandırma.
- Kanserin saptanması ve kalp krizlerinin tedavisi.
- Beyin modellenmesi çalışmaları.

3.9. Literatür Araştırması

Literatür incelendiğinde bulunan yapay sinir ağları ile gerçekleşen bazı talep tahmini çalışmaları aşağıda özetlenmiştir:

- Ringwood vd. (2001), yaptıkları çalışma incelendiğinde, yapay sinir ağlarının bir elektrik tedarikçisinin yaşadığı elektrik talebinin tahmini modellenmesinin uygulanması görülmektedir.

- Alon vd. (2001), yaptıkları çalışma incelendiğinde, ABD perakende sektörü için gerçekleştirdikleri uygulamada, fazla eğilim ve mevsimsellik içeren satış verilerini kullanarak yapay sinir ağlarını ve Winters üstel yumuşatma, Box-Jenkins ARIMA modeli ve çok değişkenli regresyon dahil geleneksel yöntemleri karşılaştırılmıştır. Sonuçlar, ortalama olarak YSA'ların daha geleneksel istatistiksel yöntemlere ve ardından Box-Jenkins modeline göre daha olumlu sonuç verdiğini göstermektedir.
- Frank, Garg vd. (2003), yaptıkları çalışma incelendiğinde, kadın giyim sektöründeki satışlarını tahmin etmek, istatistiksel zaman serisi modellemesi ve YSA kullanarak modelleme yapmak için iki yaklaşım araştırılmıştır. Modelde geriye dönük veri olarak dört yıllık satış verileri (1997-2000) kullanılmış ve 2000 yılının 2 ayı için bir tahmin yapılmıştır. Modellerin performansı karşılaştırılmıştır. Tek mevsimsel üstel düzeltme ve Winters'ın üç parametrelili modeli için sırasıyla 0.75 ve 0.90'lık bir R2 bulunmuştur. YSA'ya dayalı model, 0.92 ortalamayla daha yüksek bir R2 vermiştir.
- Adıyaman (2007), yaptığı yüksek lisans tez çalışması incelendiğinde, yapay sinir ağları kullanılarak altın ürün satışları ile ilgili bir tahmin modelinin kurulduğu görülmüştür. Yapay sinir ağları yönteminin yanında regresyon analizi ve eğri uyurma yöntemlerini de kullanmıştır. Bu yöntemler ile altın ürünlerine olan talep tahmini yapmış ve sonuçları kıyaslamıştır. Uygulama sonucunda yapay sinir ağı yönteminin etkin bir talep tahmini yöntemi olduğu gösterilmiştir.
- Çuhadar vd. (2009), yaptıkları çalışma incelendiğinde, zaman serisi yöntemlerinden Üstel Düzleştirme ve Box-Jenkins yöntemlerini kullanarak farklı yapay sinir ağı modellerinin tahmin doğruluklarını karşılaştırmışlardır. Antalya ilinin aylık dış turizm talep tahmini için Ocak 1992- Aralık 2005 döneminde Antalya iline gelen aylık yabancı turist sayısı verilerinden yararlanılmıştır. Yapılan denemeler sonucu yapay sinir ağı modelinin en yüksek doğruluğu sağladığı görülmüş ve elde edilen model yardımıyla 2009 yılı için Antalya iline yönelik aylık dış turizm talebi tahminleri yapılmıştır.
- Yazıcıoğlu (2010), yaptığı çalışma incelendiğinde, yapay sinir ağlarını Mart 2001- Haziran 2009 arasındaki aylık otomobil satışları kullanılarak bir

tahmin modeli kurulmuş ve uygulanmıştır. Yapay sinir ağları yönteminin yanında regresyon analizi kullanılmış ve sonuçlar kıyaslanmıştır. Sonuç olarak yapay sinir ağları analizlerinin, klasik yöntemlere güçlü bir alternatif olabileceği görülmüştür.

- Karahan (2011), yaptığı doktora tez çalışması incelendiğinde, istatistiksel talep tahmin yöntemlerinden yapay sinir ağı modelini kullanılarak, Malatya ilinden ihraç edilen kuru Kayısı ürününün gelecekteki talep miktarları tahmin edilmiştir. İlk olarak talebe etki eden faktörler belirlenmiştir. Geliştirilen yapay sinir ağı modeli tarafından üretilen tahminler üzerinde yapılan hata testi sonuçları, modelin ürettiği tahminlerin güvenilir ve tutarlı olduğunu göstermiştir.
- Yücesoy (2011), yaptığı çalışma incelendiğinde, yapay sinir ağları kullanılarak tahmin modeli gerçekleştirilmiştir. Uygulama bölümünde Türkiye'de yıllık temizlik kağıdı satış tahmin modeli oluşturulmuştur. YSA modelinin yanında basit ve çoklu regresyon modelleri de oluşturulmuştur. Sonuçlar karşılaştırılarak yapay sinir ağlarının tahmin için etkili bir araç olduğu gözlenmiştir. 1981-2010 yılları arasındaki 29 adet verinin, 24 adedini ağı eğitmek için 5 adedini ise test için kullanmıştır. 7 bağımsız değişken, 1 ara katman ve 3 gizli hücre sayısı ile modellediği ağ mimarisi, basit ve çoklu regresyon yöntemine göre daha etkin bir tahmin başarısı sağlamıştır.
- Serttaş (2011), yaptığı çalışma incelendiğinde, bir süpermarkette bulunan bir ürün için günlük ve mevsimsel satışları dikkate alarak bir talep tahmini gerçekleştirmiştir. Talepler yapay sinir ağları ile tahmin edilmiştir. Seçilen en uygun ağ modeliyle parametreleri kaldırarak yeni bir tahmin yapmıştır. Bu iki tahmin sonunda iki tahmin sonucunu karşılaştırmıştır.
- Kaynar vd. (2011), yaptıkları çalışma incelendiğinde, Ankara ili için doğal gaz tüketim tahmini çalışması yapılmıştır. Bu amaçla klasik zaman serileri (ARIMA) analizi ile ileri beslemeli yapay sinir ağları kullanılarak tahmin modelleri oluşturulmuştur. Günlük ve haftalık veriler kullanılarak kısa dönemli tahmin sonuçları elde edilmiştir. Her iki yöntem için tahmin değerleri ile gerçek değerler karşılaştırılmıştır.

- Sevgi (2012), yaptığı çalışma incelendiğinde, hazır giyim perakendeciliğinde faaliyet gösteren bir işletme için 6 yıllık haftalık satış verilerini kullanarak talep tahmin gerçekleştirmiştir. 2011 yılı satış tahmini için bir sinir ağı türü olan NARX (nonlinear autoregresif exogenous) modeli belirlenmiştir. Ayrıca zaman serisi yöntemi ARIMA modeli kullanarak tahmin sonuçları karşılaştırmıştır. Sonuçları kıyasladığında NARX modelinin daha az hata oranı ile daha iyi sonuçlar verdiğini gözlemlemiştir.
- Boltürk (2013), yaptığı çalışma incelendiğinde, tahmin modelleri için veri yapısına göre en uygun yöntemi bulmak ya da karma modeller oluşturmanın en doğru yöntem olduğunu savunmuştur. Verileri ayırdığı üç ayrı döneme uyguladığı analizler sonucu en iyi yöntemin bulanık mantık olduğunu söylemiştir. “Kısa dönemli elektrik tüketim talebini bulmada Bulanık Mantık yaklaşımları, Holt Modeli, Hareketli Ortalama ve YSA’lar; orta dönemli elektrik tüketim talebini tahmin etmede Singh’in Bulanık Mantık Yaklaşımı, Holt Modeli, YSA’lar, Üstel Düzeltme Yöntemleri ve Çoklu Regresyon Modelleri, uzun dönemli elektrik talebini tahmin etmede ÜstelDüzeltme, Singh’in Bulanık Mantık Yaklaşımı, Hareketli Ortalama ve Holt Modeli’nin” uygun olduğu söylemiştir.
- Ballı (2014), yaptığı çalışma incelendiğinde, gıda endüstrisinde hızlı tüketim malı olan şarküteri ürünleri üzerinden talep tahmini uygulaması yapılmıştır. Hata testi sonuçlarına göre modelin tahminlerinin güvenilir ve tutarlı olduğunu gözlemlemiştir. Diğer yöntemlerle de talep tahminleri gerçekleştirmiş ve sonuçları karşılaştırmıştır. Yapay sinir ağlarının diğer yöntemlerden daha iyi olduğunu göstermiştir.
- Es vd. (2014), yaptıkları çalışma incelendiğinde, Türkiye’nin net enerji talebinin tahmini için yapay sinir ağlarını kullanmışlardır. 1970-2010 yılları arasındaki GSYH, nüfus, ithalat, ihracat, bina yüz ölçümü ve taşıt sayısı gibi bağımsız değişkenler YSA modeline girdi olarak kullanılmıştır. Aynı zamanda çoklu doğrusal regresyonu ile de tahmin yapılmıştır. İki tahmin performansı karşılaştırılmıştır. Karşılaştırma sonucu YSA’nın üstünlüğünü görülmüştür.
- Özudođru ve Görener (2015), yaptıkları çalışma incelendiğinde, İstanbul’da faaliyet gösteren bir hastaneden aldıkları 2010-2014 yıllarındaki veriler ile,

temel medikal malzemelerin talep tahmini uygulamasını yapmışlardır. Minitab17 istatistik programı kullanılarak mevcut verilere zaman serisi yöntemleri uygulanmıştır. En uygun tahmin yönteminin tespiti ile 2015 yılına ait talep aylık olarak tahmin edilmiştir.

- Sarı (2016), yaptığı çalışma incelendiğinde, yapay sinir ağları kullanılarak motor yataklarının satış talep tahminini yapmaya çalışmıştır. Satışı etkileyen faktörler olarak dolar kuru, GSYH, araç parkı sayısı, üretilen araç sayısı, ihracat sayısı, faiz oranı, Tüfe ve Üfe'yi almıştır. Elde ettiği sonuçları regresyon analizi ve zaman serileri ile yapılan tahmin sonuçlarıyla karşılaştırılmış.YSA tekniğinin daha başarılı olduğunu gözlemlemiştir.
- Silva vd. (2017), yaptıkları çalışma incelendiğinde, simüle edilmiş bir tedarik zincirinin gelen siparişleri yerine getirme kapasitesini tahmin etmek ve bir sonraki dönem için hangi tedarik zinciri düğümlerinin bir sipariş alacağını tahmin etmek için yapay sinir ağlarının kullanmışlardır.
- Ulucan ve Kızılırmak (2018), yaptıkları çalışma incelendiğinde, İstanbul faaliyet gösteren beş yıldızlı bir otelin 2013-2016 yılları arasında satılan oda verilerini kullanmışlardır. Bu verilere yapay sinir ağı ile bir model oluşturmuşlardır. Model sonucu elde edilen verilerin gerçek değerlere çok yakın sonuçlar verdiği görülmüştür. Bunun üzerine 2017-2018 yılları için satılan oda sayılarına tahmin edilmiştir.
- Yanık (2019), yaptığı çalışma incelendiğinde, iş makineleri yedek parçaları üreten bir üretim tesisinde stok yönetiminde etkin bir olmak için YSA kullanılarak talep tahmini uygulaması yapmıştır. Bağımlı değişken 9 yıla ait satış verileri, bağımsız değişkenler ise dünyada satılan iş makinası sayısı, dolar kurudur. Aynı zamanda çoklu regresyon analiziyle de tahmin yapıp sonuçlar karşılaştırılmıştır. Yapay sinir ağlarının daha iyi sonuçlar verdiği gözlenmiştir.
- Söylemez (2020), yaptığı çalışma incelendiğinde, yapay sinir ağları ile altın fiyatlarının bir gün önceki çeşitli girdi değişkenleriyle tahmin edilebilmesini amaçlamıştır. Uygulama 03.11.2014-31.10.2019 tarihleri arasında oluşan altın fiyatları, Brent petrol fiyatları, VIX endeksi, Dow Jones Endeksi ve ABD Dolar endeksi değişkenleri kullanılarak çok katmanlı yapay sinir

ağları ile tahmin edilmektedir. Sonuç kısmında altın fiyatlarını en iyi tahmin eden modelin %98,44 doğruluk oranıyla yapay sinir ağları olduğu belirtilmiştir.

- Yıldız (2021), yaptığı çalışma incelendiğinde, yapı sektöründe faaliyet gösteren işletmenin geçmişteki kayıtlı verileri kullanılarak talep tahmini yapılmıştır. Uygulamada trend analizi, basit üstel düzeltme, çift üstel düzeltme, winters yöntemleri ve bulanık zaman serisi yöntemi kullanılmıştır. Tahmin sonucu hata değerleri hesaplanmıştır. Bulunan sonuçlar kıyaslandığında en iyi talep tahmin yönteminin, en düşük ortalama mutlak yüzde hata değerine (%3,6) sahip olan Toplamsal Holt-Winters yöntemi olduğu belirlenmiştir.

DÖRDÜNCÜ BÖLÜM

YAPAY SINIR AĞLARI İLE TALEP TAHMİNİ ÜZERİNE BİR UYGULAMA

Firmalar buldukları pazarlarda öne çıkmak, oluşabilecek belirsizlikleri minimuma indirmek, müşterilerin talebini eksiksiz karşılamak ve ürünün üretiminden teslimine kadar planlamasını verimli bir şekilde gerçekleştirmek için talep tahmini yöntemini kullanırlar. İşletmelerin talep tahmin uygulamaları geleceğini öngörebilmek için önemlidir.

Tekstil sektöründe üretilecek ürün ve bu ürüne ait miktar oldukça önemlidir. Ürünler birbirlerinden çokça farklılık gösterebilir. Her ne kadar üretilecek ürün adına oluşacak talebin ya da satışın bilinmemesi sorunu olsa da bu talebin tahmin edilmeden üretim aşamasına geçilmesi gelecekte farklı sorunları da beraberinde getirebilir. Her sektörde olduğu gibi tekstil sektöründe de bir ürün adına yapılan tahminin doğruluğu şirketin karlılığı bakımından yüksek önem taşımaktadır. Talep tahmini çalışmaları firmanın kapasitesinin ne kadarını değerlendirebildiği, sezonluk trendlerde nelerle karşılaşılacağı, pazarlama stratejilerinin belirlenmesi ve üretim planlarının verimli şekilde yapılması adına önemlidir (Odabaş, 2019).

Tekstil sektöründe müşterilerin taleplerini etkileyen birçok değişken olabilir. Müşteri taleplerini etkileyen değişkenlerin belirlenmesi işletmenin tasarım, pazarlama ve üretim başta olmak üzere bütün departmanlarına katkı sağlayacaktır. Talep üzerinde etkisi olan değişkenler göz önüne alınarak yapılan üretim ve planlama müşterinin isteklerinin karşılanmasında aktif rol alacaktır. Bu önemli etken de işletmeyi pazardaki rakiplerinden daha iyi bir noktaya getirecektir.

Bu çalışmada bir tekstil entegre terbiye işletmesi olan ismini vermek istemeyen firma adına talep tahmini uygulaması yapılmıştır. İlk olarak firmanın geçmiş yıllara ait Ocak 2018 - Aralık 2021 ayları arasındaki satış verileri alınmıştır. Bu veriler çok fazla işlem içerdiği için ve her işlem sonucu farklı bir ürün grubu olduğu için ilk olarak ABC Analizi uygulanmıştır. Uygulanan ABC Analizi sayesinde en çok talep edilen ürün grubu seçilmiştir. Geçmiş yılların verileri kullanılarak gelecek yılların satış tahmini yapılmaya çalışırken satışı etkileyen diğer faktörlerin belirlenebilmesi için uzun süredir sektörde olan şirket çalışanının görüşlerine başvurulmuştur. Satış tahmini yapılırken satışları etkileyen dış faktörler dikkate alınarak yapay sinir ağları modeli ile MATLAB programında çözülmüştür.

4.1. Firma ve Sektör Bilgileri

Uygulama yapılan tekstil firması 1980 yılında Uşak ilinde kurulmuş olup, gerek iç piyasanın ihracatçı firmalarına fason üretim yapan, gerekse ev tekstili konusunda AB ülkelerine kendi ürünlerini ihraç eden Türkiye'nin önde gelen tekstil fabrikalarından biridir.

Tekstil ürünlerine değer kazandırma (terbiye) işlemleri çok eskiye dayanır. Tekstil sektöründe terbiye işlemlerini açıklamak gerekirse, materyallerinin (elyaf, iplik, kumaş, giysi vb) niteliklerini kullanım alanına veya tüketici isteğine göre değiştirmek için uygulanan işlemlerin tümüne tekstil terbiye işlemleri denir.

Uygulama yapılan tekstil firması entegre bir terbiye işletmesidir. Bu tekstil terbiye işletmesinde her türlü pamuklu dokuma ve örgü ürünleri ile pamuk/sentetik elyaf karışımları en son teknoloji ile üretilmektedir.



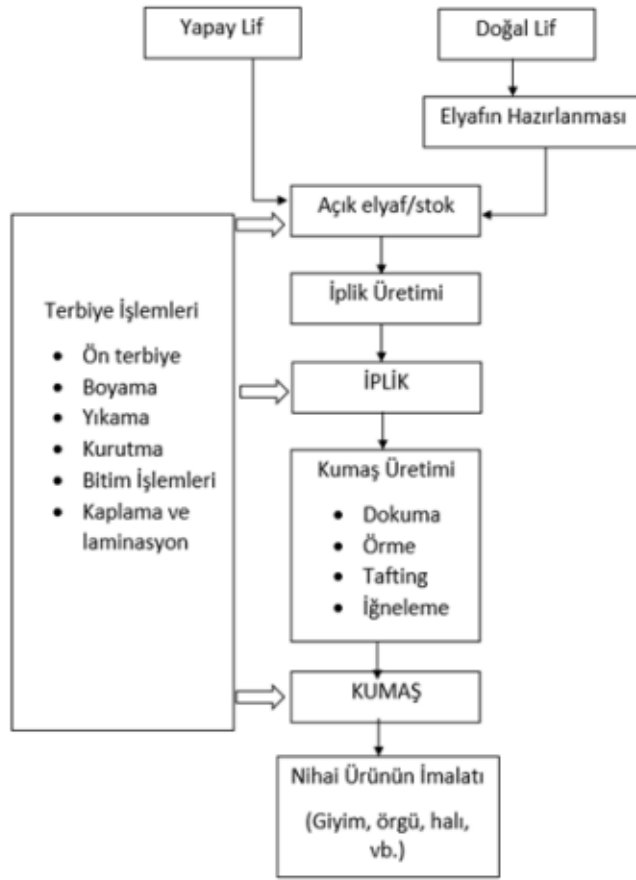
Şekil 4.1 Terbiye İşlemleri Akış Şeması

Kaynak: (Çevre ve Şehircilik Bakanlığı Tekstil Kılavuzu, 2017)

Tekstil sektöründe üretim süreci birkaç temel proses aşamasını bünyesinde barındıran karmaşık süreçleri içermektedir. Üretim süreci genelde dört temel süreçten oluşur: iplik üretimi, kumaş üretimi, boyama/terbiye/bitirme işlemi ve nihai ürün üretimi.

Terbiye işlemleri olarak adlandırılan işlemler, üretim sürecinin farklı basamaklarında kumaş, iplik veya açık elyaf halindeki tekstil materyallerine uygulanabilmektedirler. Bu yüzden tekstil terbiyesi standart sıralı işlemler olarak tanımlamak doğru değildir. Daha çok

nihai kullanıcının gereksinimlerine bağlı olarak, tekstil ürünlerinin üretilmesi sırasında uygulanabilen temel işlemlerin kombinasyonlarıdır.



Şekil 4.2 Tekstil Sektörü Proses Aşamaları

Kaynak: (Çevre ve Şehircilik Bakanlığı Tekstil Kılavuzu, 2017)

4.2. Uygulamada Ele Alınan Tekstil Ürünleri

Uygulama çalışması söz konusu tekstil işletmesinin Ocak 2018 ile Aralık 2021 yılları arasındaki dört yıllık sürecin aylık bazda satış verilerini kullanmıştır.

Gelen siparişler kumaş üzerine yapılan çeşitli işlemler sonucu farklılık göstermektedir. Firmanın kumaş tipi önemsenmeden yapılan işlem türleri üzerinden tahmin yapılmaktadır. Çünkü kumaş üzerine yapılan her farklı işlem sonucu farklı bir ürün elde edilmektedir.

Uygulanan işlem türleri; AB, AB+PB, D, DB, DB+KY, DB+PB, DB+RB, DB+DİGİTAL, DİGİTAL, DISPERS, DİS+DB, DİS+İND, İND, K, K+KY, PB, RB, PB+KY ve RB+KY' dir.

- AB = Akar Boya

- $AB+PB$ = Akar boya + Pigment Baskı
- D = Diğer İşlemler
- DB = Düz Boya
- $DB+KY$ = Düz Boya + Kenar Yazı
- $DB+PB$ = Düz Boya + Pigment Baskı
- $DB+RB$ = Düz Boya + Reaktif Baskı
- $DB+DİGİTAL$ = Düz Boya + Dijital Baskı
- $DİGİTAL$ = Dijital Baskı
- $DISPERS$ = Dispers Baskı
- $DİS+DB$ = Dispers Baskı + Düz Boya
- $DİS+İND$ = Dispers Baskı + İndantren Boya
- $İND$ = İndantren Boya
- K = Beyaz
- $K+KY$ = Beyaz + Kenar Yazı
- PB = Pigment Baskı
- RB = Reaktif Baskı
- $PB+KY$ = Pigment Baskı + Kenar Yazı
- $RB+KY$ = Reaktif Baskı + Kenar Yazı

4.3. ABC Analizi ile Ürün Grubu Seçimi

ABC analizi işletme kaynaklarını, elde tutulan stokları ya da satışı arttırılacak ürünleri önem derecelerine göre sınıflandırılabilmiş ve analiz dönemleri içerisinde daha doğru karar almayı kolaylaştırmıştır. ABC analizi, oldukça kolay ve anlaşılır bir karar verme tekniğidir.

Müşteri taleplerinin miktar ve karakteristiğine göre gruplandırılmasını amaçlayan bu yöntem ürünleri talep miktarına göre büyükten küçüğe ve A, B, C tipi olarak sıralar.

Yapılan ABC analizinde ele alınan işlem türlerinin 4 yıllık toplam satış miktarlarına göre sıralanmış buna göre ürün grupları arasındaki önem sırası oluşturulmuştur.

Tablo 4.1 ABC Analizi Veri Tablosu

İŞLEM	YILLAR				TOPLAM
	2018	2019	2020	2021	
PB	9722240	12537475	10224851	12824419	45308985
RB	5945815	6487848	6875703	7100137	26409503
DB	3281433	4511057	4678108	6522032	18992630
K	2847194	2608722	2782616	2903928	11142460
D	1759839	1378809	928398	1005526	5072572
DİGİTAL	430024	606221	755237	1083526	2875008
DB+KY	238284	139258	290802	345604	1013948
AB	221562	178229	55920	44209	499920
İND	96801	103031	30657	30353	260842
AB+PB	138554	22214	8142	9036	177946
DB+RB	17399	38715	27980	23553	107647
DB+PB	31339	38137	16830	4269	90575
K+KY	35107	14687	15490	2493	67777
DİS+İND	28170	3147	3025	0	34342
PB+KY	0	30138	0	0	30138
DİS+DB	26400	382	0	0	26782
RB+KY	0	0	25291	0	25291
DB+DİGİTAL	0	1954	0	0	1954
DISPERS	1954	0	0	0	1954
TOPLAM	24822115	28700024	26719050	31899085	112140274

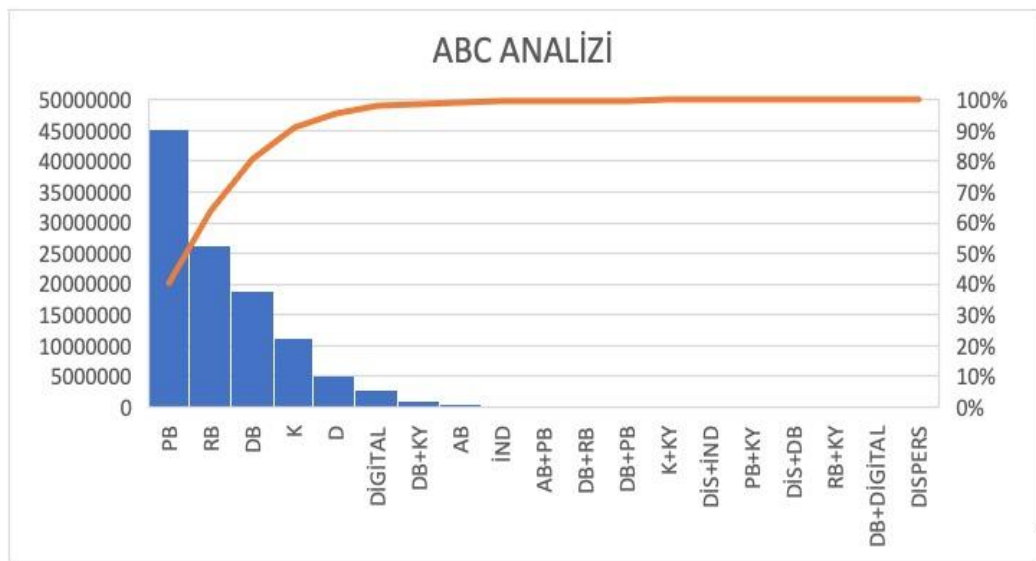
Firmada toplamda 19 adet işlem türü bulunmaktadır. Bu işlem türlerinin yıllık satış miktarları metre cinsinden yukarıdaki tabloda verilmiştir. 4 yılın toplam satış miktarı üzerinden her bir işlemin toplam satış miktarı içerisindeki yüzde belirlenmiştir. Daha sonra ABC analizini net gözlemleyebilmek için kümülatif yüzdeleri hesaplanmıştır.

Tablo 4.2 ABC Analizi Sınıf Tablosu

YÜZDE	KÜMÜLATİF YÜZDE	SINIF
40,404%	40,404%	A
23,550%	63,954%	A
16,936%	80,891%	A
9,936%	90,827%	B
4,523%	95,350%	B
2,564%	97,914%	C
0,904%	98,818%	C
0,446%	99,264%	C
0,233%	99,497%	C
0,159%	99,655%	C

0,096%	99,751%	C
0,081%	99,832%	C
0,060%	99,893%	C
0,031%	99,923%	C
0,027%	99,950%	C
0,024%	99,974%	C
0,023%	99,997%	C
0,002%	99,998%	C
0,002%	100,000%	C

Tablo ve grafikte 19 adet ürünün 4 yıllık bazda satış rakamlarındaki yüzdesel ve kümülatif dağılımlarını içeren ABC Analizi görülmektedir.



Şekil 4.3 ABC Analizi Eğrisi

Bu analize göre ilk 3 işlem (A grubu), toplam kalem sayısının yaklaşık %15'ini oluştururken toplam talebinin %80'nini oluşturmaktadır.

Onu takip eden 2 işlem (B Grubu), toplam kalem sayısının yaklaşık %10'nunu oluştururken toplam talebin %15'ini oluşturmaktadır.

Geriye kalan 14 işlem (C Grubu), toplam kalem sayısının yaklaşık %75'ini oluştururken toplam talebin sadece %5'ini oluşturmaktadır.

Yapılan ABC analizi sonucunda en çok satış yapılan işlem grubu A grubu olduğu belirlenmiştir. A grubunu kendi içinde incelendiğinde en çok kar getiren işlem olan PB işlemi talep tahmininde kullanılmak üzere seçilmiştir.

4.4. YSA ile Seçilen Ürün Grubu Talep Tahmini Uygulaması

Uygulamada kullanılan PB işleminin talebi üzerinde etkisi olduğu düşünülen bağımsız (açıklayıcı) değişkenler şirket çalışanı ile görüşülerek belirlenmiş ve bu değişkenlerle ilgili veriler toplanmıştır. Sonra, çalışmada kullanılan yapay sinir ağları modeli tanıtılmış ve gelecek bir dönem için PB işlemlerinin aylık talep miktarlarını tahmin etmek üzere bir yapay sinir ağı modeli tasarlanmıştır.

Daha sonra, yapay sinir ağları modelinin tahmin performansını tespit etmek amacıyla MSE hata analizi yapılmış ve modelden elde edilen sonuçların yorumlamaları yapılmıştır.

4.4.1. Tahmin Süreci Tasarımı

Yapılan uygulamada tahmin aracı olarak diğerlerine göre daha avantajlı ve başarılı sonuçlar üreten yapay sinir ağları yöntemi tercih edilmiştir.

4.4.2. Veri Setinin Hazırlanması

Şirket çalışanı görüşleri dikkate alınarak belirlenen işlem türüne olan talebi etkileyecek çok sayıda faktör olduğu belirlenmiştir. Ancak bu verilerin tamamı için aylık veri elde edilemeyeceği için, aylık veri elde edilebilecek sayısal faktörler seçilmiştir.

Bağımlı değişken tekstil firmasına ait Ocak 2018 – Aralık 2021 dönemi PB işlem türüne ait satış rakamları olurken, bağımsız değişkenler ise yapay sinir ağları ile kurulacak olan modelin doğru tahmin yapabilmesi için şirket çalışanı tarafından görüş alınıp literatürde araştırılmış ve satış rakamlarına etki edebilecek bağımsız değişkenler seçilmiştir.

Bu bağımsız değişkenler; döviz kuru, tüketici fiyat endeksi, üretici fiyat endeksi, Amerikan pamuk fiyat endeksi, tekstil ve hammaddeleri ihracat miktarları ve tekstil ürünleri ithalat miktarları olarak belirlenmiştir.

Talep tahmini için kullanılacak değişkenler aşağıdaki tabloda belirtilmiştir.

Tablo 4.3 Bağımlı – Bağımsız Değişkenler

		DEĞİŞKENLER	KAYNAK
BAĞIMLI	1	SATIŞ VERİLERİ (AYLIK)	TEKSTİL FİRMASI
BAĞIMSIZ	1	DÖVİZ KURU (DOLAR/TL) (AYLIK)	TCMB
	2	TÜKETİCİ FİYAT ENDEKSİ (AYLIK)	TÜİK
	3	ÜRETİCİ FİYAT ENDEKSİ (AYLIK)	TÜİK
	4	AMERİKAN PAMUK FİYAT ENDEKSİ (AYLIK)	INVESTING
	5	TEKSTİL VE HAMMADDELERİ İHRACAT VERİLERİ (AYLIK)	TİM
	6	TEKSTİL ÜRÜNLERİ İTHALAT VERİLERİ (AYLIK)	TÜİK

4.4.2.1. Bağımlı Değişkenler

Uygulamanın bağımlı değişkeni PB işlem gurubunun aylık satış miktarlarıdır. Uygulamada kullanılan veriler firmanın tuttuğu GENEL SATIŞ EXCEL veri tabanından elde edilmiştir. Belirlenen işlem gurubuyla ilgili satış verileri aylık olarak sorgulanmış ve özet tablolar oluşturulmuştur. Tahmin çalışması için 2018-2021 yılları arasındaki 48 aylık veriler toplanmıştır. Değişkenlerin seçim nedenleri ve özet veri setleri aşağıdaki gibidir.

1. Aylık Satış Miktarı Verileri:

Firmaya ait 2018-2021 yılları arasında gerçekleşen PB işlem türünün satış miktarları aşağıdaki tabloda gösterilmiştir.

Tablo 4.4 Aylık PB İşlem Grubu Satış Verileri

AYLIK SATIŞ VERİLERİ (METRE)												
AYLAR		PB		PB		PB		PB				
Ocak		845522		1067429		809975		1032394				
Şubat		945992		1148787		791803		1006224				
Mart		815632		1147506		728577		1304748				
Nisan		946219		880069		344973		1441109				
Mayıs		935693		918589		421549		691481				
Haziran	2018	643331	2019	917698	2020	976102	2021	1292452				
Temmuz		599392		1202608		976638		1058760				
Ağustos		456212		917588		810216		936889				
Eylül		687260		1322306		732373		994050				
Ekim		919977		1014741		1109746		848797				
Kasım		1099177		1041278		868713		1025335				
Aralık		827833		958876		1654186		1192180				
Genel Toplam				9722240				12537475		10224851		12824419

4.4.2.2. Bağımsız Değişkenler

Uygulamada kullanılacak bağımsız değişkenler belirlenirken ilk olarak literatüre başvurulmuştur. Literatür taraması ile elde edilen bağımsız değişkenler tekstil firmasında çalışan uzman personel ile birlikte incelenmiştir. İncelenen bağımsız değişkenler arasından tekstil sektöründe talebi etkileyecek değişkenler seçilmiştir. Tekstil firması çalışanı yapılan görüşmeler ve incelenen literatür sonucunda PB işlem gurubunun talebini etkileyen bağımsız değişkenler aşağıdaki gibi belirlenmiştir.

1. T.C. Merkez Bankası Aylık Döviz Kuru (Dolar/TL):

Veriler, TCMB veritabanından alınmıştır. Dolar kurunda yaşanabilecek artışların tekstilin sektöründe girdi maliyetlerini yükselteceği ve satışların azalacağı

düşünülmektedir.

Tablo 4.5 Aylık Döviz Kuru Verileri

DÖVİZ KURU (DOLAR/TL)								
AYLAR		DOLAR/TL		DOLAR/TL		DOLAR/TL		DOLAR/TL
Ocak	2018	3,78	2019	5,38	2020	5,93	2021	7,41
Şubat		3,78		5,27		6,06		7,09
Mart		3,89		5,45		6,33		7,64
Nisan		4,06		5,75		6,83		8,17
Mayıs		4,42		6,06		6,96		8,36
Haziran		4,64		5,82		6,82		8,61
Temmuz		4,76		5,68		6,86		8,63
Ağustos		5,74		5,63		7,27		8,49
Eylül		6,38		5,72		7,52		8,53
Ekim		5,87		5,79		7,89		9,16
Kasım		5,38		5,74		8,02		10,54
Aralık		5,32		5,85		7,73		13,55
TCBM- (USD) ABD Doları (Döviz Satış)								

Kaynak: (TCMB, 2022)

2. Tüketici Fiyat Endeksi (TÜFE):

Tüketici tarafından satın alınan mal ve hizmetlerin fiyatlarındaki değişimleri ölçen endekse tüketici fiyat endeksi denir. Yıllık enflasyon değerindeki değişimi ölçmek için kullanılır. TÜFE müşterilerin satın alma gücüyle doğrudan ilişkili olduğu için satışlar üzerinde etkili olacağı düşünülmüştür.

Tablo 4.6 Aylık TÜFE Verileri

Tüketici fiyat endeksi ve değişim oranları, 2018-2021												
[2003=100]												
Yıl	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
	Endeks											
2018	330,75	333,17	336,48	342,78	348,34	357,44	359,41	367,66	390,84	401,27	395,48	393,88
2019	398,07	398,71	402,81	409,63	413,52	413,63	419,24	422,84	427,04	435,59	437,25	440,50
2020	446,45	448,02	450,58	454,43	460,62	465,84	468,56	472,61	477,21	487,38	498,58	504,81
2021	513,30	517,96	523,53	532,32	537,05	547,48	557,36	563,60	570,66	584,32	604,84	686,95

Kaynak: (TÜİK, 2022)

3. Üretici Fiyat Endeksi (ÜFE):

Üretici fiyat endeksi, belli dönemlerde ülke ekonomisinde üretimi yapılan ve yurt içine satışa konu olan ürünlerin, üretici fiyatlarını zaman içinde karşılaştırarak fiyat değişikliklerini

ölçen fiyat endeksidir. Enflasyonun belirlenmesinde kullanılır. ÜFE'nin artması ile girdi maliyetlerinin artacağı bu sebeple satış fiyatlarının artıp satışların azalacağı düşünülmüştür.

Tablo 4.7 Aylık ÜFE Verileri

Yurt içi üretici fiyat endeksi ve değişim oranı, 2018-2021												
[2003=100]												
Yıl	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
	Endeks											
2018	319,60	328,17	333,21	341,88	354,85	365,60	372,06	396,62	439,78	443,78	432,55	422,94
2019	424,86	425,26	431,98	444,85	456,74	457,16	452,63	449,96	450,55	451,31	450,97	454,08
2020	462,42	464,64	468,69	474,69	482,02	485,37	490,33	501,85	515,13	533,44	555,18	568,27
2021	583,38	590,52	614,93	641,63	666,79	693,54	710,61	730,28	741,58	780,45	858,43	1022,25

Kaynak: (TÜİK, 2022)

4. Amerikan Pamuk Fiyat Endeksi :

Amerikan Ulusal Pamuk Konseyi (NCC) tarafından belirlenen pamuk satış fiyatları baz alınmıştır. Uluslararası piyasalarda pamuk talebinin değişkenliği yüzünden pamuk fiyatlarında iniş çıkışlar meydana gelmektedir. Bu iniş çıkışlar hammadde fiyatlarına yansımaktadır. Bu değişimin üreticinin maliyetlerini artıracığı düşünülmektedir.

Tablo 4.8 Aylık Amerikan Pamuk Fiyat Verileri

ABD PAMUK FİYATLARI ENDEKSİ								
AYLAR		PAMUK		PAMUK		PAMUK		PAMUK
Ocak	2018	77,19	2019	74,24	2020	67,42	2021	80,61
Şubat		82,88		72,77		61,8		89,02
Mart		81,58		77,58		51,14		80,77
Nisan		83,88		76,77		57,42		88,34
Mayıs		93,09		68,17		57,24		82,09
Haziran		85,38		65,73		60,98		85,05
Temmuz		89,55		63,88		62,74		89,59
Ağustos		82,29		58,88		65,26		92,52
Eylül		76,38		60,74		65,81		105,59
Ekim		76,86		64,38		68,98		115,03
Kasım		78,83		65,3		72,24		106,41
Aralık		72,27		68,98		78,24		113,63

Kaynak: (Investing, 2022)

5. Tekstil ve Hammaddeleri İhracat Verileri:

İhracat, bir malın diğer ülkelere döviz karşılığı satılan satış işlemleridir. Tekstil ve hammaddelerinin ihracat miktarı tekstil üretimini etkileyeceği için, PB işlem grubunun satışını da etkileyeceği düşünülmektedir.

	2	202	234	304	370	359	370	315	310	281	258	402	380
	6	595	054	275	940	463	224	256	522	325	365	718	326
	6	394	433	512	529	594	628	511	520	530	506	618	669
	5	220	843	737	113	117	770	733	066	440	346	133	007
TOPLAM		596	667	817	900	953	998	826	830	811	764	1 020	1 049
		815	897	011	053	579	994	989	589	765	711	851	333
26 = Dokuma elyafı ve bunların artıkları- Textile fibres (other than wool tops) and their wastes													
65 = Tekstil ürünleri (iplik, kumaş, yer kaplamaları, hazır eşya)- Textile yarn, fabrics, made up articles, etc.													

Kaynak: (TÜİK, 2022)

4.4.3. Yapay Sinir Ağı Modelinin Seçimi

Önceki bölümde de anlatıldığı üzere yapay sinir ağları ile yapılan talep tahmininde en çok kullanılan yöntemlerden biri çok katmanlı ileri beslemeli geri yayımlı algoritmasıdır. Bu nedenle yapılan çalışmada çok katmanlı ileri beslemeli geri yayılım algoritması kullanılmaya karar verilmiştir.

Ocak 2018 – Aralık 2021 yılları arasındaki 48 adet veri kullanılmaktadır. Verilerin yaklaşık %70’i olan Ocak 2018 – Haziran 2020 yılları arasındaki 30 adet veri ağı eğitim verisi olarak kullanılırken geri kalan yaklaşık %30’luk kısmı Temmuz 2020 – Aralık 2021 yılları arasındaki 18 adet veri ağı performansını test etmek amacıyla kullanılmıştır.

Normalizasyon tekniği olarak en çok tercih edilen Min-Max yöntemi kullanılarak, tüm veriler [0,1] arasında normalize edilmiş ve programa aktarılmıştır.

Belirlenen 6 adet bağımsız değişken yapay sinir ağı modelinin giriş katmanını oluşturmaktadır. Çıktı katmanını ise tahmini yapılacak bağımlı değişken olan PB işleminin satış değerleri oluşturur. Girdi ve çıktı katmanları kullanılarak ileri beslemeli geri yayılım algoritması seçilmiştir. Tek gizli katmandan oluşan çok katmanlı algılayıcılar problemleri çözmeye daha iyi sonuçlar verdiği için gizli katman sayısının bir olarak belirlenmesine karar verilmiştir.

Yapay sinir ağlarında kaç adet gizli katman kullanılacağına dair net bir bilgi bulunmamaktadır. Yapay sinir ağları modelinde genelde gizli hücre sayısını belirlemede “geometrik piramit kuralı” olarak bilinen bir yöntem kullanılabilir. Bu kuralın iki ana maddesi vardır. Bunlar;

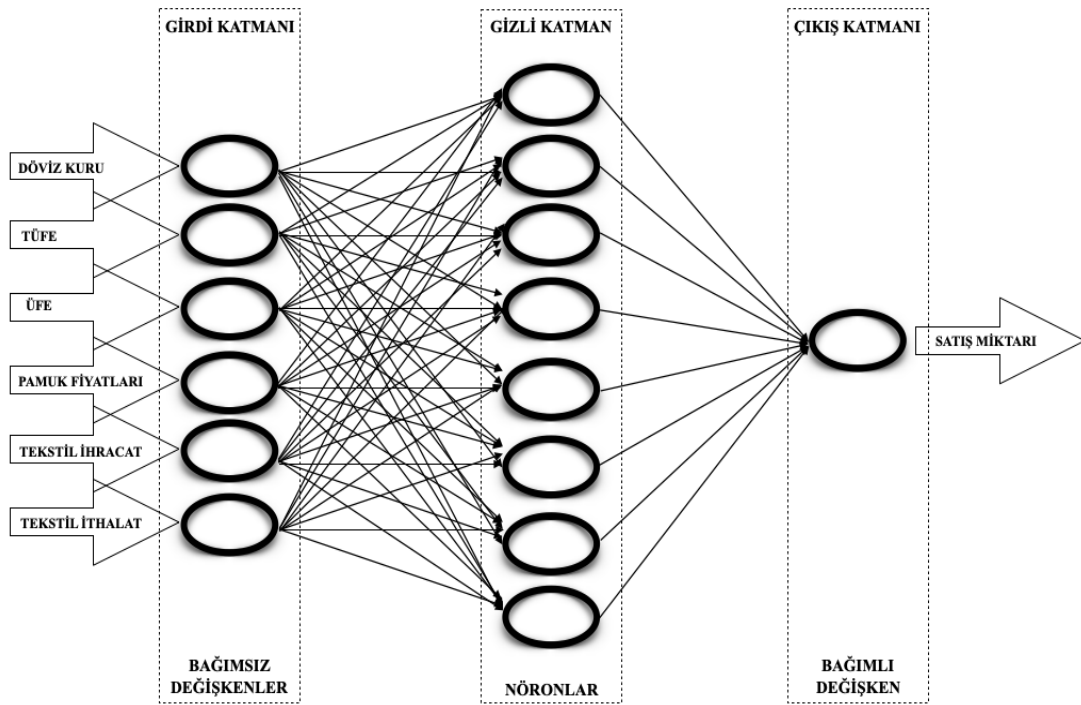
1. Gizli hücre sayısı girdi hücre sayısının iki katını geçmemelidir.

Bu kurala göre uygulamada girdi sayısı 6’dır. Gizli katman sayısı “ $6 \times 2 = 12$ ” adeti geçmemelidir.

2. Gizli hücre sayısı girdi hücre sayısı ile çıktı hücre sayısının çarpımının karekökünden az olmamalıdır.

Girdi hücre sayısı 6, çıktı hücre sayısı 1'dir. " $6 \times 1 = 6$ ve $\sqrt{6} = 2.44$ tür. Bu durumda gizli katman sayısı aynı zamanda 3 adetten de az olmamalıdır.

Yukarıdaki işlemler sonucu gizli katman sayısının " $3 < \text{gizli katman} < 12$ " olduğu belirlenmiştir. Aynı zamanda literatürde tahmin işlemlerinde en etkili olan ve 1-10 arasında yapılan denemeler neticesinde en iyi sonucu veren gizli katman hücre sayısı 8 olduğu bilindiği için gizli katman sayısı 8 olarak tercih edilmiştir.



Şekil 4.4 Uygulamada Kullanılan Yapay Sinir Ağı Modeli

4.4.3.1. Modelin Tasarımı ve Matlab Uygulaması

Uygulamada kullanılan yapay sinir ağı literatürde de sıkça bahsedilen ileri beslemeli geri yayımlı yapay sinir ağıdır. İleri beslemeli geri yayımlı yapay sinir ağının kullanılmasının sebebi tahmin uygulamalarında çokça kullanılması ve tahminlerdeki başarısıdır. Yapay sinir ağı modeli MATLAB R2022b programı kullanılarak oluşturulmuştur. NN Toolbox yapay sinir ağı alt programı kullanılmıştır.

Verilerin normalizasyon işleminin Excel'de tamamlanmasının ardından kullanılan MATLAB programında tahmin edilmeye çalışılmıştır. 2018 – 2021 yılları arasında toplam 30 veri ağın eğitimi için 18 adet veride test aşamasında kullanılmıştır. İlk olarak talep tahmini

yapmak için toplanan ve Microsoft Excel programına kayıtlı olan veriler Matlab'a yüklenmiştir.

Yapay sinir ağının öğrenebilmesi için aşağıdaki işlemler gerçekleştirilecektir:

1. Bağımsız değişken verileri eğitim ve test verileri olarak ayrılır.
2. Bağımlı değişken verileri eğitim ve test verileri olarak ayrılır.
3. Eğitim girdileri ve çıktıları kullanılarak ağ eğitilir.
4. Test girdileri ve çıktıları ağa verilerek eğitilmiş ağdan çıkan çıktılarıyla gerçek çıktılar karşılaştırılır.

Modelde 6 adet girdi 1 adet çıktı kullanılmakla beraber tek ara katman kullanılmıştır. Normalize edilen veriler eğitilmeden önce modelde kullanılması gereken parametrelerin belirlenmesi gerekmektedir.

Bu parametreler öğrenme katsayısı, momentum katsayısı ve iterasyon sayısıdır. Tahmini yapılan her model için tüm parametreler belirlenen aralık değerleri arasında deneme yanılma yöntemi ile ağın eğitimi yapılmaktadır. Modeli en iyi açıklayan parametreler ile test verisinin tahmini yapılmaktadır.

Tablo 4.11 Yöntem Parametreleri

PARAMETRELER	
AĞ TİPİ	Feed- Forward backprop
EĞİTİM FONKSİYONU	TRAINLM
ÖĞRENME FONKSİYONU	LEARNGDM
PERFORMANS FONKSİYONU	MSE
KATMAN SAYISI	2
NÖRON SAYISI	8
TRANSFER FONKSİYONU	TANSIG
İTERASYON SAYISI	1000

Veriler ağa sunulmuş ve 1000 iterasyonlu bir öğrenme modeli uygulanmıştır. Burada öğrenmenin yeterli bir şekilde gerçekleştiğini anlamak için hata kareleri ortalaması (MSE) seçilmiştir.

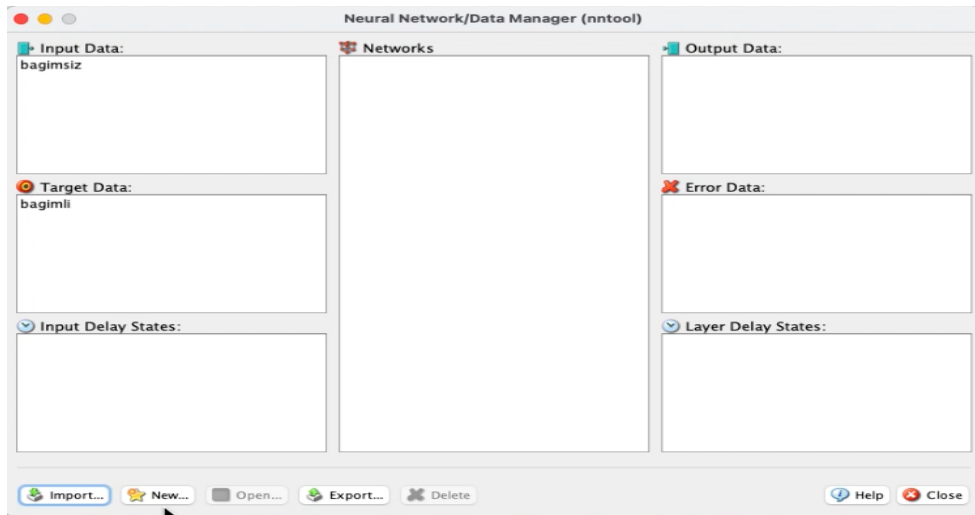
Öncelikle tahmin yapacağımız tüm verileri Excel'de düzenlememiz gerekmektedir. Toplam 48 adet verinin test edeceğimiz 18 farklı Excel'de farklı bir sayfada kalan 30 eğitim verisi farklı bir sayfada olmak üzere ayrı ayrı incelenmelidir. Eğitim verisi "Import Data" kısmından MATLAB programına normalize edilen değerler yüklenir. Daha sonra "New Variable" kısmından verilen tablolara aktarılır. MATLAB programına tanımlanan değerlerin

Transpoze edilmesinin ardından program çalıştırılır. Verilerin transpoze edilmesi aşağıda gösterilmiştir.

```
Command Window
>> bagimli=bagimli';
>> bagimsiz=bagimsiz';
```

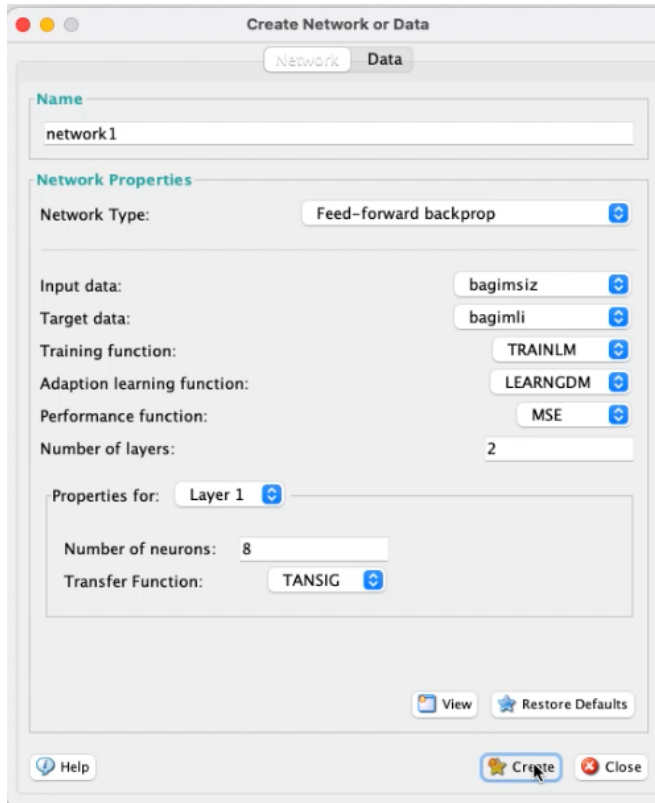
Şekil 4.5 Transpoze Formülleri

Transpoze edilmesinin sebebi Excel'den aldığımız verilerin satır ve sütun değişimini yapmaktır. Bu sayede uygulama verileri tanımlayabilmektedir. Verilerin transpoze edilmesinden sonra command window'a "nntool" yazılarak NNToolBox çalıştırılır.




Şekil 4.6 NNToolBox Arayüzü

Çıkan bu ara yüzde Import sekmesinden tanımladığımız bağımsız veriler Input Data'ya bağımlı veriler Target Data'ya atanır. Daha sonra New sekmesine tıklanarak yapay sinir ağı oluşturulmaya başlanır.



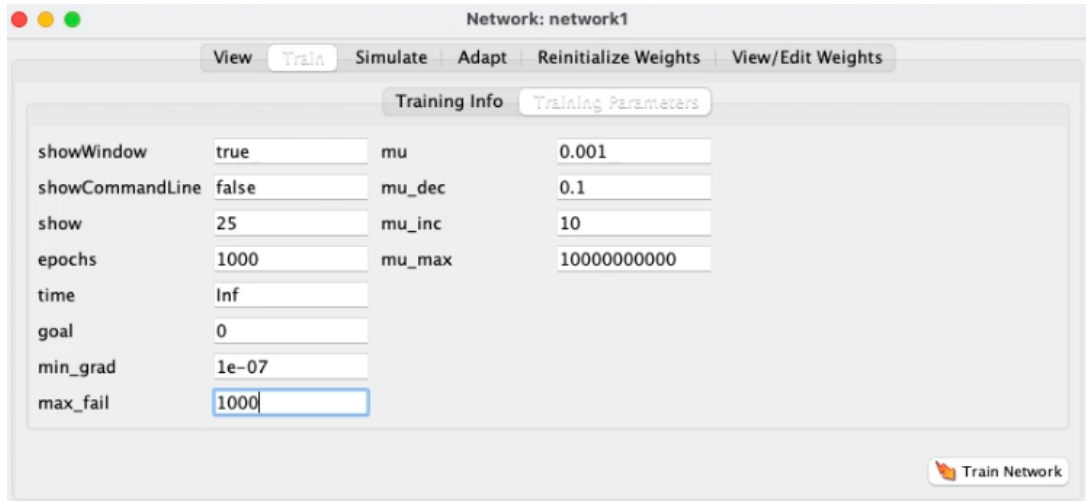
Şekil 4.7 Parametre Arayüzü

Programda literatürde en çok tercih edilen tahmin etme ağı olarak FeedForward Backprob kullanılmıştır. Eğitim girdisi “bagimsiz”, eğitim çıktısı “bagimli” verileri, eğitim ve öğrenme algoritmaları, performans fonksiyonu, katman sayısı, gizli hücre sayısı, nöron sayısı ve aktivasyon fonksiyonu girişleri yapıldı sonrasında “Create” butonuna basılarak ağ yaratma işlemi gerçekleştirilir.



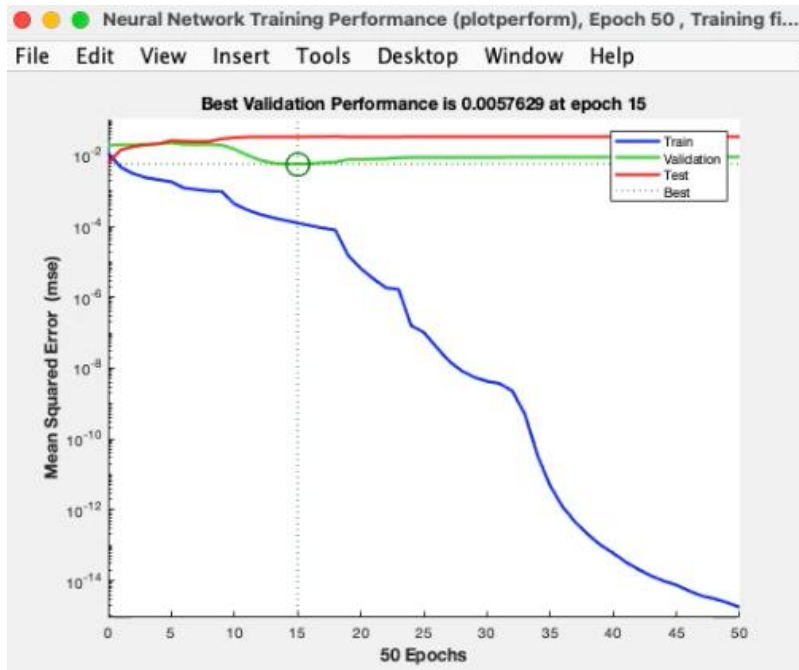
Şekil 4.8 MATLAB Yapay Sinir Ağı Modeli

Çalışılan ağda altı girdi verisi sekiz sinir hücresi ve iki katman bulunmaktadır. Oluşturulan ağın eğitimi için “Train” sekmesinden ağın eğitim işlemi gerçekleştirilmiştir. Aşağıdaki Train sekmesine ait ekran görüntüsü verilmiştir. Burada ağın eğitimi için gerekli parametreler seçildikten sonra “Train Network” ile modelin eğitimi yapılmaktadır.



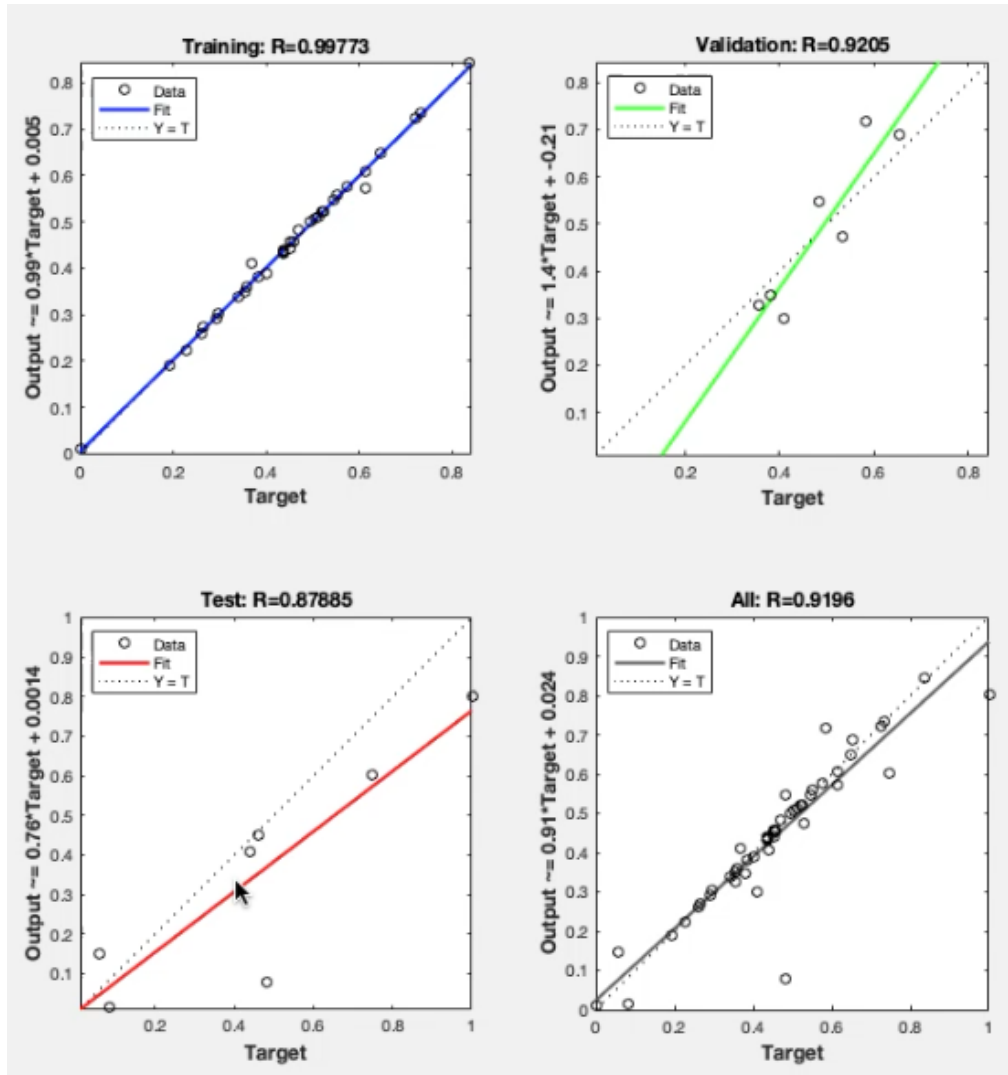
Şekil 4.9 MATLAB Yapay Sinir Ağı Eğitim Ekranı

MATLAB programında öğrenme işlemi gerçekleştirildikten sonra elde edilmiş performans grafiği aşağıdaki gibidir. Performans grafiği ağıın eğitimi sonucunda her iterasyondaki eğitim doğrulama ve test kümelerinin ne şekilde değiştiğini gösterir. Grafikten görüldüğü üzere 15 iterasyonda optimum sonuca ulaşılmıştır. Henüz ezberleme yapmamış olması genelleme yapması açısından olumlu olacaktır.



Şekil 4.10 MATLAB Yapay Sinir Ağı Performans Grafiği

Öğrenme işleminin ardından Regression sekmesinden eğitilen modelin başarısı aşağıdaki gibidir.



Şekil 4.11 MATLAB Yapay Sinir Ağı Regresyon Değerleri

Eğitilen ağın regresyon değerleri şekildeki gibidir. Eğitim regresyon değerinin $R^2 = 0,99773$ gibi yüksek bir değere sahip olması eğitim aşamasındaki başarıyı göstermektedir. Regresyon katsayıları test için 0,87885, doğrulama için 0,9205 ve toplam regresyon için ise 0,9196 olarak tespit edilmiştir.

Regresyon değeri 1'e ne kadar yakınsa söz konusu aşama o kadar başarılıdır. Doğrulama ve test aşamalarındaki regresyon değerleri de oldukça iyi olması ağın eğitim sürecinin başarılı geçtiğini göstermektedir.

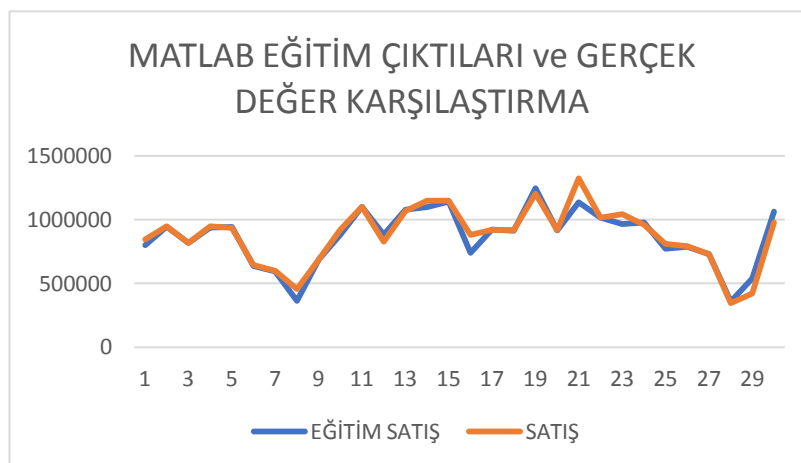
Yapay sinir ağı modelinde eğitim esnasında üretilen talep değerleri aşağıdaki tabloda verilmektedir.

Tablo 4.12 MATLAB Eğitim Çıktıları

AYLAR	SATIŞ	NORMALİZE SATIŞ	NORMALİZE EĞİTİM ÇIKTI	EĞİTİM SATIŞ
2018-1	845522	0,382328162	0,3478800000	800422,018
2018-2	945992	0,459068922	0,4581600000	944802,028

2018-3	815632	0,359497652	0,3603100000	816695,536
2018-4	946219	0,459242308	0,4523200000	937156,224
2018-5	935693	0,451202364	0,4563000000	942366,892
2018-6	643331	0,227891107	0,2225600000	636351,445
2018-7	599392	0,194329723	0,1900600000	593802,023
2018-8	456212	0,084966312	0,0143180000	363718,312
2018-9	687260	0,261444853	0,2601300000	685538,578
2018-10	919977	0,439198205	0,4081600000	879341,378
2018-11	1099177	0,576074329	0,5762600000	1099420,08
2018-12	827833	0,368816992	0,4093800000	880938,618
2019-1	1067429	0,551824646	0,5588600000	1076639,78
2019-2	1148787	0,613967322	0,5739100000	1096343,43
2019-3	1147506	0,612988872	0,6083000000	1141367,27
2019-4	880069	0,40871577	0,3009000000	738915,192
2019-5	918589	0,438138026	0,4410600000	922414,486
2019-6	917698	0,437457465	0,4323500000	911011,241
2019-7	1202608	0,655076752	0,6878500000	1245515,16
2019-8	917588	0,437373445	0,4341000000	913302,363
2019-9	1322306	0,746504198	0,6036100000	1135227,06
2019-10	1014741	0,511580621	0,5112300000	1014281,96
2019-11	1041278	0,53185005	0,4725900000	963693,972
2019-12	958876	0,468909948	0,4829000000	977191,958
2020-1	809975	0,355176736	0,3259100000	771658,609
2020-2	791803	0,341296642	0,3369400000	786099,228
2020-3	728577	0,293003507	0,2929500000	728506,948
2020-4	344973	0	0,0104580000	358664,75
2020-5	421549	0,058490101	0,1483500000	539194,749
2020-6	976102	0,482067471	0,5476200000	1061924,22

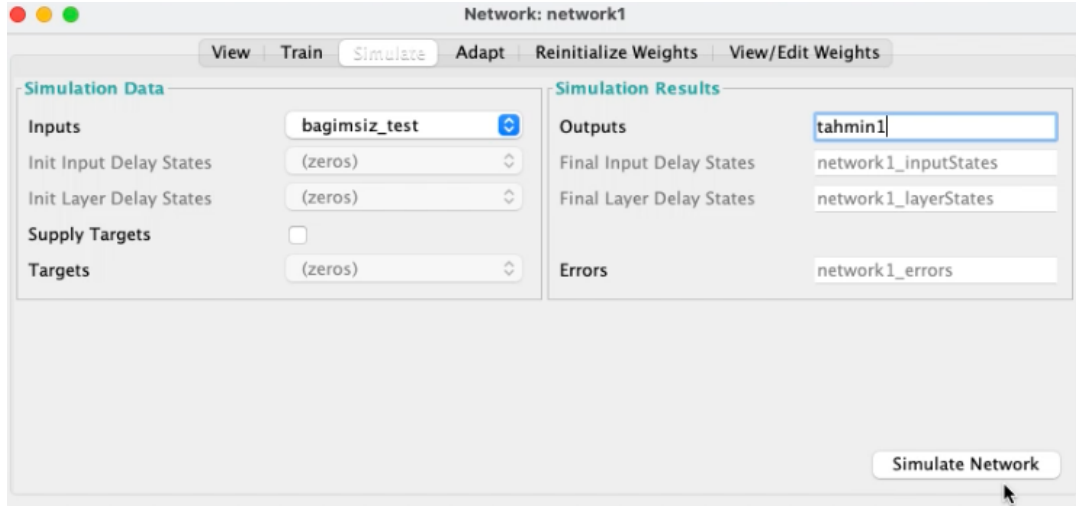
Ağ çıktıları ile gerçek değerleri aynı grafikte gösterimi aşağıda görülmektedir. Gerçek değerler ile ağ çıktısının arasındaki fark ağ çıktılarındaki başarıyı ortaya koymaktadır.



Şekil 4.12 MATLAB Eğitim Çıktıları Karşılaştırma

4.4.4. YSA ile Elde Edilen Tahmin Sonuçları

Model eğitildikten sonra test için oluşturulan test verileri seçilerek tahmin sonuçlarının üretilmesi istenmektedir. Eğitim ekranı üzerinde “Simulate” tıklanıp gelip bu sefer “Inputs” yerine test için ayrılan verinin seçilmesinin ardından “Simulate Network” e tıkladığında test verileri için sonuçlar çıkarılmış olacaktır.



Şekil 4.13 MATLAB Yapay Sinir Ağı Test Ekranı

Test işleminden sonra ağın tahmin olarak verdiği test çıktı verileri ile gerçek değerlerin karşılaştırılması gerekmektedir. Buna göre MSE (Ortalama Kare Hata) değeri 0,01227813 olarak bulunmuştur. MSE değerinin sıfıra yakın olması iyi bir performans gösterdiğini söylenebilir.

Tablo 4.13 MATLAB YSA Tahmin Performansı

Tahmin Değer (Toplam)	Gerçek Değer (Toplam)	Toplam Sapma %
18976291,00	18358291,83	3,26

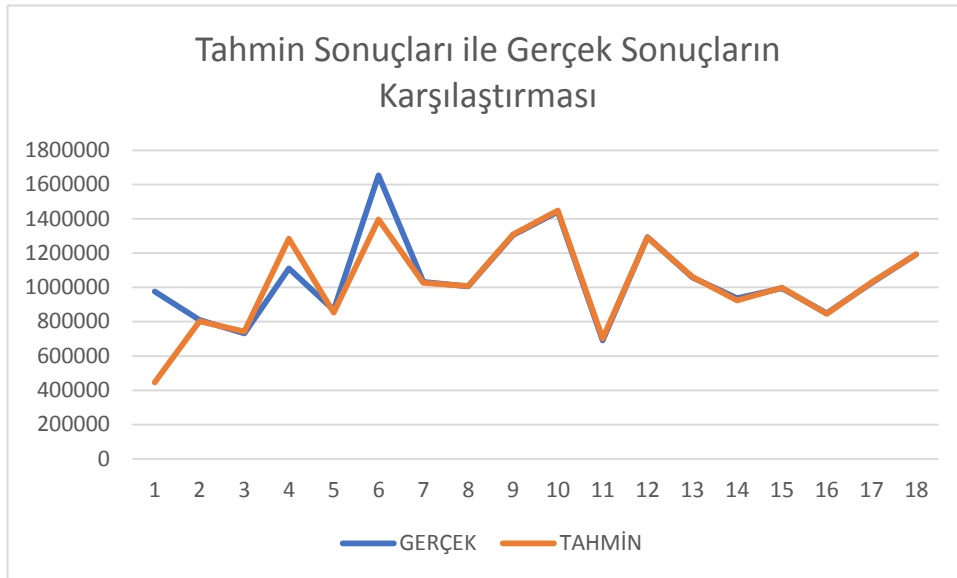
Tahmin işlemi yapıldıktan sonra gerçek veriler ile tahmini yapılan test verileri birbirleri ile karşılaştırılmıştır. Aşağıdaki tahmini ve gerçek değerlerin toplam miktarları yer almaktadır. Test verilerinin toplamı ile tahmin verilerinin toplamı arasında %3.26’lık bir sapma vardır.

Tablo 4.14 YSA Tahmin Değerleri ile Gerçek Değerlerin Karşılaştırılması

TEST KÜMESİ				
AYLAR	TEST	TEST (normalize)	TAHMİN	TAHMİN (normalize)
2020-7	976638	0,482476877	446628,681	0,076464036
2020-8	810216	0,355360816	803161,6101	0,349972548
2020-9	732373	0,295902958	742563,0027	0,303686262

2020-10	1109746	0,584147117	1284316,986	0,717487518
2020-11	868713	0,400041857	852359,1626	0,387550507
2020-12	1654186	1	1396148,513	0,802906412
2021-1	1032394	0,525064294	1026487,67	0,520552935
2021-2	1006224	0,505075186	1008541,677	0,506845469
2021-3	1304748	0,733093087	1307387,157	0,735108922
2021-4	1441109	0,837248026	1448439,028	0,842846831
2021-5	691481	0,264668927	701015,0434	0,271951198
2021-6	1292452	0,723701185	1291588,322	0,723041493
2021-7	1058760	0,545203111	1062534,492	0,548086134
2021-8	936889	0,452115889	923479,8559	0,441873748
2021-9	994050	0,49577647	998393,6238	0,499094207
2021-10	848797	0,384829665	845407,1691	0,382240452
2021-11	1025335	0,519672506	1027965,18	0,521681483
2021-12	1192180	0,647111662	1191874,657	0,646878436

Tabloda tahmini yapılan 18 verinin gerçekleşen değerleri ve tahmin değerlerin bir arada verilmiştir. Tahmin değerleri incelendiğinde gerçek değerlere yakın bir tahmin yapıldığı görülmektedir.



Şekil 4.14 YSA Tahmin Değerleri ile Gerçek Değerlerin Karşılaştırılması

Tahmin sonuçları ile gerçek değerleri aynı grafikte gösterimi yukarıda görülmektedir. Gerçek sonuçlar ile YSA tahmin sonuçlarının benzerliği ağ çıktılarındaki başarıyı ortaya koymaktadır.

SONUÇ

İşletmeler, günümüz küreselleşen dünyada artan maliyetler ve dijitalleşme sonucu değişen rekabet koşullarına karşı ayakta kalabilmek için karşılaştıkları çeşitli sorunlara etkin çözümler üretilip karar vermek zorundadırlar. Bu bağlamda Tedarik Zincirini doğru yönetmek çok önemlidir. Sürprizlerle karşılaşmamak, maliyetleri önceden belirleyip öngörmek ve bu öngörülerini tutarlı kılmak tahmin ile mümkün olur. Talep tahminlerinin yüksek doğrulukla elde edilmesi, tüm tedarik zinciri yönetimi süreçlerinin başarısı için önemli bir faktördür.

Her geçen gün artan rekabet koşulları sektörleri farklı arayışlara itmiştir. İşletmeler arasındaki ilişkiler karmaşıklaştıkça ve tedarik zincirleri büyüdükçe tedarik zinciri yönetimi daha da önem kazanmıştır. Günümüzde ise rekabet, işletmeler arasında olmaktan çıkıp tedarik zincirleri arasında olmaya doğru yönelmiştir.

Yaşanan küresel pandemi sebebiyle ülkeler arası seyahat ve ticari faaliyetlere getirilen kısıtlamalar en büyük değişikliklerin tedarik zincirinde yaşanmasını sağlamıştır ve tedarik zinciri yönetimini olumsuz etkilemiştir. Bu etkiler otomotiv yedek parça sektöründen gıda sektörüne, tekstilden turizme kadar birçok sektörü uzun süre etkilemeye devam etmiştir. Bu yüzden en çok etkilenen sektörlerden biri olan tekstil sektöründe değişen talebin doğru ve hızlı bir şekilde tahmini işgücü ve kaynak planlamalarının etkin bir şekilde yapılması açısından önem arz etmektedir.

İşletmeler gelecekte neyin nasıl olacağını öngörmek isterler ve bu yüzden birçok konuda çeşitli talep tahmin yöntemlerine başvururlar. Bu talep tahmin yöntemlerinde biri olan ve son yıllarda sıkça kullanılan yeni yöntemlerden birisi de yapay sinir ağlarıdır. Yapay sinir ağları çok farklı alanlarda hem tahmin yapabildiğinden hem de gerçeğe daha yakın sonuç vermesinden birçok araştırmada kullanılmaktadır.

Bu çalışma yapay zeka teknolojilerinden olan yapay sinir ağlarının tahmin yapmadaki başarısını göstermek amacıyla hazırlanmıştır. Verilerin doğrusal olmadığı ve talebi etkileyen birden fazla değişkenin olduğu tahmin problemlerinde YSA'nın nasıl etkin sonuçlar verdiği gösterilmiştir.

Tekstil sektöründe hizmet veren bir firmaya ait 2018 - 2021 arasındaki aylık satış verileri kullanılarak bir yapay sinir ağı tahmin modeli oluşturulmuştur. Ülkemiz ekonomisinde önemli rolü olan tekstil sektöründe faaliyet gösteren firmalar her geçen gün giderek artan rekabet koşullarına maruz kalmaktadır. Bu sektörün bir parçası olan tekstil işletmeleri de

pamuk fiyatlarında, döviz kurlarında ve yaşanan ani değişimlere daha hazırlıklı olmak ve tedarik zinciri süreçleri doğru yönetebilmek için daha net tahminlere gereksinim duymaktadır.

İşletmeye ileri beslemeli geri yayımlı yapay sinir ağları kullanılarak tahmin eden bir model önerilmiştir. Önerilen model, gerçek verilerle test edilmiş ve sonuçları verilmiştir. Geliştirilen YSA tahmin modeli çalışmanın yapıldığı işletmenin satış verilerini yüksek doğruluk ile tahmin edebileceği belirlenmiştir, dolayısıyla modelin performans bakımından oldukça iyi olduğunu ortaya çıkmıştır. İşletme, geliştirilen YSA tahmin modeli ile satış tahmini yapabilecek ve üretim için tedarik senaryolarını belirleme kabiliyeti kazanacaktır.

Elde edilen sonuçlar doğrultusunda, yapay sinir ağlarının gerçek sonuçlara yakın değerler verdiği ortaya çıkmıştır. Yapay sinir ağları, veriler arasındaki doğrusal olmayan ilişkileri öğrenip genelleme yapabilmekte ve bu sayede daha önce hiç karşılaşmadığı örneklere kabul edilebilir bir hatayla cevap bulabilmektedir. Bu özellikleri nedeniyle yapay sinir ağları, tahmin etmede etkili bir yöntem olarak kullanılmaktadır.

Uygulamada 2018-2021 yılları arasında gerçekleşen satış verilerine ABC Analizi uygulanarak en çok talep edilen işlem türünden seçilmiştir. Satışları etkileyen faktörler, çalışma öncesinde görüşülen uzman kişilerin görüşleri alınarak belirlenmiştir.

Bu faktörlere ait bilgiler, TCMB, TÜİK vb. kurum kaynaklarından elde edilmiştir. Eğitim verileri olarak satışını etkileyen 6 ana faktör olduğunu düşünülmüştür. Bunlar; döviz (dolar) kuru, TÜFE, ÜFE, Amerikan pamuk endeksi fiyatları, tekstil ve hammaddeleri ihracat verileri ve tekstil ürünleri ithalat verileridir.

Bu veriler (0,1) aralığında normalize edilerek eğitim ve test amacıyla ağa sunulmuştur. Yapılan çalışmalar sonucunda YSA modelinin başarılı olduğu görülmüş ve test verilerine ait değerler için tahmini değerler bulunmuştur. Bu değerler gerçek verilerle karşılaştırılmış ve gerçek değerlere ne derece yaklaştığı hesaplanmıştır. MSE Değeri: 0,01227813, Tahmin ve Gerçekleşen Satış tutarları arasındaki Sapma: 3,26 olarak bulunmuştur. Bu değerler en düşük hata değerini veren yapay sinir ağları ile bulunan değerdir.

YSA ile oluşturulan tahmin modellerinin etkili sonuçlar vermesine rağmen, geleneksel metotlar ile bulunan deney sonuçları YSA'yı desteklemede yardımcı olarak kullanılabilir. Nitel ve nicel yöntemlerin bir arada kullanıldığı melez yöntemlerle yapılan talep tahminleri çok daha fazla doğruluk gösterebilir. Çalışmanın bir sonraki aşamasında, farklı tasarıma sahip YSA modelleri kullanılarak tahminler önerilebilir.

KAYNAKÇA

- Adıyaman, F. (2007). *Talep Tahmininde Yapay Sinir Ağlarının Kullanılması*. Yayınlanmamış Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Aikeshan, A. (2014). Bulanık Doğrusal Regresyon Yöntemi ile Talep Tahmini: Medikal Asistans Firmasında Bir Uygulama. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İşletme Mühendisliği Ana Bilim Dalı.
- Akpınar, H. (1994). “Yapay Sinir Ağları Gelişimi ve Yapılarının incelenmesi”. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 23(1).
- Alon, I., Qi M., Sadowski R.J. “Forecasting aggregate retail sales: a comparison of artificial neural networks and traditional methods”, *Journal of Retailing and Consumer Services*, 8: 147-156, 2001.
- Alpar, R. (2017). *Çok değişkenli istatistiksel yöntemler*. Ankara: Detay Yayıncılık.
- Atasoy, S., (2012). *Yapay Sinir Ağları ve Sinirsel Bulanık Ağlar İle İnsan Kaynaklarında Performans Yönetimi Modellenmesi*. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Bal, S. (2012). *Tedarik Zinciri Yönetiminde Envanter Modellerinin Önemi Üzerine Bir Uygulama*. Doktora Tezi. Uludağ Üniversitesi, Bursa.
- Ballı, M. T. (2014). *Yapay sinir ağları ile talep tahmini ve gıda sektöründe uygulanması*. Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi, İstanbul.
- Bolt, G., 1994. *Market and sales forecasting: a total approach*. Kogan Page, Londra.
- Boltürk, E., “Elektrik Talebi Tahmininde Kullanılan Yöntemlerin Karşılaştırılması”. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, İstanbul, 2013.
- Borgelt, C., and R. Kruse. (2002). *Graphical Models: Methods for Data Analysis and Mining*. Chichester, UK: J. Wiley and Sons.
- Carbonneau, R. A., Vahidov, R., Laframboise, K. (2007). “Machine Learning-Based Demand Forecasting in Supply Chains”. *International Journal of Intelligent Information Technologies*, 40-55.

- Carmichael D. (1998). *Supply Chain Planning Systems in Manufacturing*. Unpublished Master Thesis in Manufacturing: Management and Technology.
- Chopra, S. ve P. Meindl. (2007). *Supply Chain Management, Strategy, Planning and Operation*. Third Edition. New Jersey: Pearson Prentice Hall.
- Çelik, B. (2003). “Yapay Zeka”. *Türkiye Mühendislik Haberleri*, 40-50.
- Çevre ve Şehircilik Bakanlığı, (2017). Çevre ve Şehircilik Bakanlığının ÇED Alanında Kapasitesinin Güçlendirilmesi için Teknik Yardım Projesi Sözleşmesi. <http://www.hlcevre.com/images/PDF/sektorel-kilavuzlar/g23-tekstil-kilavuzu.pdf> (Erişim Tarihi: 28.03.2022)
- Çiçek, E., & Murat, B. A. Y. (2007). “Stratejik küresel tedarik zinciri yönetimi ve lojistik”. *Sosyal Ekonomik Araştırmalar Dergisi*, 7(13), 91-117.
- Çoban, F. (2019). *Belirsiz koşullar altında talep tahmini ve gıda işletmesinde bir uygulama*. Yüksek Lisans Tezi. Pamukkale Üniversitesi Fen Bilimleri Enstitüsü, Denizli.
- Çörekcioglu, M., Ercan, E., & Elibüyük, S. A. (2021). “Yapay Sinir Ağı Yöntemlerinin Tekstil Sektöründe Kullanım Uygulamaları”. *Teknik Bilimler Dergisi*, 11(2), 14-20.
- Çuhadar, M., Güngör, İ. ve Göksu, A., (2009), “Turizm Talebinin Yapay Sinir Ağları İle Tahmini ve Zaman Serisi Yöntemleri İle Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama”, *Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi*, Cilt: 14, Sayı: 1, ss. 99-114.
- Denton, J. W., (1995). “How good are neural networks for casual forecasting?”, *The Journal of Business Forecasting Methods & Systems*, 14, p.17
- Disney, S. M. Naim, M. M. Towill, D. R. (1997). “Dynamic Simulation Modelling for Lean Logistics”, *International Journal of Physical Distribution & Logistics Management, Bradford*. Vol.27, Iss. 3/4 ; pg 174.
- Doğan, M. (2012). *Ekonomik Bir Büyüme Modelinin Yapay Sinir Ağları ile Tahmini ve Türkiye’ de Uygulanması*. Yüksek Lisans Tezi Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Doğar, A. (2006). *Tedarik Zincirinde Stok Yönetimi*. Doktora Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

- Doğruer, İ.M. (2005). *Üretim Organizasyonu ve Yönetimi*, Alfa Yayınları, 1.Basım, İstanbul.
- Özsoy, E. (2006). *Talep Tahminine Dayalı Müşteri Odaklı Üretim Planının Oluşturulması ve Bir Uygulama*. Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, İzmir.
- Emel, G. ve Taşkın, Ç. (2002). “Genetik Algoritmalar ve Uygulama Alanları”, Uludağ Üniversitesi, *İdari ve İktisadi Bilimler Fakültesi Dergisi*, 11(1):129- 152.
- Erkut H. ve Akgüç Ö., (1997). *Stratejik Yönetim ve Senaryo Tekniği*. İrfan Yayınevi, İstanbul
- Es, H.A., Kalender F.Y., Hamzaçebi C. “Yapay Sinir Ağları İle Türkiye Net Enerji Talep Tahmini”, *Journal of the Faculty of Engineering and Architecture of Gazi University*, s. 495-504, 2014.
- Eymen, U. Erman, (2007). *Tedarik Zinciri Yönetimi*. Kaliteofisi Yayınları No: 14 s.8
- Gençyılmaz, G. (1988). *Stok Sistemlerinin Yönetimi I*, İstanbul Matbaası. No:204
- Güneş, M. & İncekırık, A. (2016). “Ege bölgesinde faaliyet gösteren KOSGEB kapsamındaki farklı ölçeklerdeki şirketlerin (KOBİ) bulanık kümeleme analizi ile gruplandırılması”. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 22 (4) , 314-323 .
- Güngör, E., (2007). *Yapay Sinir Ağları Yardımı ile Makine Arızalarının Önceden Tahmin Edilmesi*. Yüksek Lisans Tezi. Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü, Kocaeli.
- Gürsoy, A. (2012). *Yapay Sinir Ağları Yaklaşımıyla Lastik Kalıbı Maliyetinin Tahmin Edilmesi*. Yüksek Lisans Tezi. Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü.
- Ghewari A. and Manwar T. (2016) “Analysis Of Inventory Control Techniques- ABC & VED; A Comparative Study”. *GE-International Journal of Management Research* 4(4):127-132.
- Hamzaçebi, C. (2011). *Yapay Sinir Ağları*. Ekin Kitabevi, İstanbul
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Prentice Hall, New Jersey.
- Heizer, J. H., & Render, B. (2006). *Operations Management*.

- Investing Amerikan Pamuk Fiyatları, <https://tr.investing.com/commodities/us-cotton-no.2-historical-data>, (Erişim Tarihi: 28.03.2022)
- İlhan, İ. (2015). *Tedarik Zinciri Yönetiminde Kantitatif Talep Tahmin Yöntemi Seçimi İle Stok Optimizasyonuna Dair Bir Uygulama*. Yüksek Lisans Tezi. Maltepe Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Hanke J. E. Reitsch A. G. (1992). *Business Forecasting*, Allyn and Bacon, Boston.
- Janvier James, A. (2012). “A new introduction to supply chains and supply chain management: Definitions and theories perspective”. *International Business Research*, 5(1), 194-207.
- Karahan, M. (2011). *İstatistiksel tahmin yöntemleri: yapay sinir ağları metodu ile ürün talep tahmini uygulaması*. Yayınlanmamış Doktora Tezi. Konya Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Konya.
- Karahan, M., & Aslan, Ş. (2016). “Bir Çimento Fabrikasında Hammadde Stok Kontrolü Uygulaması”. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(3).
- Karasoy, O., & Ballı, S. (2016). Google Maps ve Genetik Algoritmalarla GSP Çözümü İçin Öneri. *XVIII. Akademik Bilişim Konferansı*.
- Kargı, V.S. (2013). *Yapay Sinir Ağ Modelleri Ve Bir Tekstil Firmasında Uygulama*. Doktora Tezi. Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü Ekonometri Anabilim Dalı Yöneylem Bilim Dalı, Bursa.
- Kaynar, O., Taştan S., Demirkoparan F. “Yapay Sinir Ağları İle Doğalgaz Tüketim Tahmini”, *Atatürk Ü. İİBF Dergisi*, 10. Ekonometri ve İstatistik Sempozyumu Özel Sayısı, 2011.
- Keskenler, M. F. & Keskenler, E. F. (2017). “Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi”. *Takvim-i Vekayi*, 5 (2), 8-18
- Kılıç, G. (2015). *Yapay Sinir Ağları ile Yemekhane Günlük Talep Tahmini*. Yüksek Lisans Tezi. Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.
- Kobu B, (2006). *Üretim Yönetimi (13. Baskı)*, Beta Basım Yayım Dağıtım A.Ş., İstanbul.
- Koç, E., Çalışkan, S., Demirci, U., & Kuş, Z. (2017). *Evrimsel Algoritmalar ve Uygulamaları*. Yüksek Lisans Tezi. Fatih Sultan Mehmet Vakıf Üniversitesi, Mühendislik ve Fen Bilimleri Enstitüsü, İstanbul.

- Koçkaya, A. (2016). *Otomotiv sanayisi için üretim yapan bir işletmede talep tahmin yöntemlerinin uygulanması*. Yüksek Lisans Tezi. Maltepe Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Korkut, D. (2019). *Yapay sinir ağları yöntemi ile talep tahmini ve ayakkabı sektörüne uygulaması*. Yüksek Lisans Tezi. Ankara Hacı Bayram Üniversitesi, Lisansüstü Eğitim Enstitüsü, Ankara.
- Kurt, R. , Karayılmazlar, S. , İmren, E. & Çabuk, Y. (2017). “Yapay Sinir Ağları İle Öngörü Modellemesi: Türkiye Kağıt-Karton Sanayi Örneği”. *Bartın Orman Fakültesi Dergisi*, 19 (2) , 99-106
- Küçük, Orhan (2011). *Stok Yönetimi*. Seçkin Yayıncılık, Ankara.
- Laudon, K. C., Laudon, J. P. (2012). *Management Information Systems: Managing The Digital Firm*. New Jersey: Pearson Education.
- Mari, S., Lee, Y., & Memon, M. (2015). “Complex network theorybased approach for designing resilient supply chain networks”. *International Journal of Logistics Systems and Management*, 21(3), 365-384.
- McCulloch, W. S., ve Pitts, W. (1943). "A logical calculus of the ideas immanent in nervous activity", *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Meydan, Y. (2007). *Talep Tahmin Yöntemleri ve Orta Ölçekli Bir İşletmede Uygulanması*. Yüksek Lisans Tezi. İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Moon, M. A., Mentzer, J. T., Smith, C. D., & Garver, M. S. (1998). Seven keys to better forecasting. *Business Horizons*, 41(5), 44-52.
- Negüs, A. F. (2008). *Çok Kademeli Stok Yönetimi Ve Dağıtım Optimizasyonu*. Doktora Tezi. İstanbul Üniversitesi, Sosyal Bilimleri Enstitüsü, İstanbul.
- Tezcan, N. (2011). “Parametrik Olmayan Regresyon Analizi”. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 25.
- Odabaş, S. (2019). *Tekstil Sektöründe İhracat Yapan Bir Firmada Talep Tahmini Uygulanması*. Doktora Tezi. Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Karabük.
- Olgun, S. (2009). *Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemler ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması*. Yüksek Lisans Tezi. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

- Orhunbilge, N. (2002). *Uygulamalı Regresyon ve Korelasyon Analizi*. Nobel Yayınevi, İstanbul.
- Özdemir, D. A. İ. (2004). “Tedarik Zinciri Yönetiminin Gelişimi, Süreçleri ve Yararları”. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* , 0 (23).
- Öztemel, E. (2006). *Yapay Sinir Ağları*. Papatya Bilim Yayınevi, İstanbul.
- Öztürk, A. (2005). *Yöneylem Araştırması*, Ekin Kitabevi, Genişletilmiş 10.Baskı, Bursa
- Öztürk, K. & Şahin, M. E. (2018). “Yapay Sinir Ağları ve Yapay Zekâ ’ya Genel Bir Bakış”. *Takvim-i Vekayi* , 6 (2) , 25-36 .
- Özüdoğru A.G., Görener A. “ Sağlık Sektöründe Talep Tahmini Üzerine Bir Uygulama” , İstanbul Ticaret Üniversitesi Sosyal Bilimleri Dergisi, 27: s. 37- 53, 2015.
- Ringwood, J.V., Bofelli D., Murray F.T. “Forecasting Electricity Demand on Short, Medium and Long Time Scales Using Neural Networks”. *Kluwer Academic Publishers*, 31: 129–147, 2001.
- Sarı, M. (2016). “Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması”. Yüksek Lisans Tezi. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Seaton , A., & Bennet , M. (1996). *Marketing Tourism Products: Concepts, issues, cases*. Londra: Cengage Learning.
- Serttaş, Z.S., “ Türkiye’de Perakende Sektöründe Talebi Etkileyen Etmenler Ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması” . Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi, İstanbul, 2011.
- Sevgi, P., “Hazır Giyim Perakendeciliği Yapan Bir Firmada Yapay Sinir Ağları İle Satış Tahmini”. Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi, İstanbul, 2012.
- Simchi-Levi, D., Kaminsky, P., Simchi-Levi, E., & Shankar, R. (2008). *Designing and managing the supply chain: concepts, strategies and case studies*. Tata McGraw-Hill Education.
- De Souza, R., Zice, S., & Chaoyang, L. (2000). “Supply chain dynamics and optimization”. *Integrated Manufacturing Systems*. Vol. 11 No. 5, pp. 348-364.

- Supply Chain Council, <https://www.ascm.org/corporate-transformation/>, (Erişim Tarihi: 14.03.2022).
- Swaminathan, J. M., Smith, S. F., & Sadeh, N. M. (1998). "Modeling supply chain dynamics: A multiagent approach". *Decision sciences*, 29(3), 607-632.
- Şenbaş, T. (2020). *Lojistik Sektöründe Talep Tahmini Uygulaması*. Yüksek Lisans Tezi. İstanbul Arel Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Tanrıverdi, Y. (2010). *Tedarik zinciri ve stok yönetimi üzerine bir uygulama*. Yüksek Lisans Tezi. Pamukkale Üniversitesi, Sosyal Bilimler Enstitüsü, Denizli.
- TCMB, <https://www.tcmb.gov.tr/>, (Erişim Tarihi: 22.03.2022)
- Tekin, M. (1996). *Üretim Yönetimi*. Arı Ofset Matbaacılık, Konya.
- Tengilimoğlu D. ve Yiğit V. (2013). *Sağlık işletmelerinde Tedarik Zinciri ve Malzeme Yönetimi*. Nobel Yayın, Ankara.
- TİM, <https://tim.org.tr/tr/ihracat-rakamlari>, (Erişim Tarihi: 22.03.2022)
- Turhan, E., Ağlargoş, O., Çınar, E., Yılmaz, H., Yapıcıoğlu, H., & Baraz, B. (2012). *E-iş Süreçleri*. Anadolu Üniversitesi, Eskişehir.
- TÜİK, <https://www.tuik.gov.tr/>, (Erişim Tarihi: 22.03.2022)
- Ulucan, E. & Kızılırmak, İ. (2018). Konaklama İşletmelerinde Talep Tahmin Yöntemleri: Yapay Sinir Ağları İle İlgili Bir Araştırma . *Seyahat ve Otel İşletmeciliği Dergisi* , 15 (1) , 89-101.
- Yağımlı, M., ve Ergin, H. (2017). "Türkiye'de İş Kazalarının Üssel Düzeltme Metodu ile Tahmin Edilmesi". *Marmara Fen Bilimleri Dergisi*, 29(4), 118-123.
- Yanık, E. (2019). *İş makineleri sektöründe yapay sinir ağları ile talep tahmini uygulaması*. Yüksek Lisans Tezi. Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale.
- Yazıcıoğlu, N. (2010). *Yapay Zeka İle Talep Tahmini*. Yüksek Lisans Tezi. Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Bursa.
- Yıldırım, S. (2016). "İşletmelerde Tedarik Zinciri Yönetimi Ve Toplam Kalite Yönetimi İlişkisi". *Süleyman Demirel Üniversitesi Vizyoner Dergisi* , 1 (1) , 175-191.

- Yücesoy, M. (2011). *Temizlik kağıtları sektöründe yapay sinir ağları ile talep tahmini*. Doktora Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Yıldız, R. (2021). “Klasik Talep Tahmin Yöntemleri İle Bulanık Zaman Serileri Yöntemlerinin Büyük Ölçekli Yapı Sektöründe Uygulaması”. *Journal Of Orjinal Studies*, 2(1), 1-10.
- Yılmaz, H. (2018). *Antalya ili aylık konut satışının çoklu doğrusal regresyon analizi ve yapay sinir ağları ile tahmini*. Yüksek Lisans Tezi. Akdeniz Üniversitesi, Sosyal Bilimler Enstitüsü, Antalya.

EKLER

EK 1- YILLARA GÖRE İŞLEM TÜRLERİNİN SİPARİŞ MİKTARLARI (metre)

İŞLEM TÜRÜ	YILLARA GÖRE SİPARİŞ MİKTARLARI (metre)			
	2018	2019	2020	2021
AB	221562	178229	55920	44209
AB+PB	138554	22214	8142	9036
D	1759839	1378809	928398	1005526
DB	3281433	4511057	4678108	6522032
DB+KY	238284	139258	290802	345604
DB+PB	31339	38137	16830	4269
DB+RB	17399	38715	27980	23553
DB+DİGİTAL	0	1954	0	0
DİGİTAL	430024	606221	755237	1083526
DISPERS	1954	0	0	0
DİS+DB	26400	382	0	0
DİS+İND	28170	3147	3025	0
İND	96801	103031	30657	30353
K	2847194	2608722	2782616	2903928
K+KY	35107	14687	15490	2493
PB	9722240	12537475	10224851	12824419
RB	5945815	6487848	6875703	7100137
PB+KY	0	30138	0	0
RB+KY	0	0	25291	0
TOPLAM	24822115	28700024	26719050	31899085

EK 2- 2018- 2021 YILLARI ARASI BAĞIMSIZ VERİLERİN DEĞERLERİ

AYLAR	DOLAR	TÜFE	ÜFE	PAMUK	İHRACAT	İTHALAT
2018-1	3,78	330,75	319,60	77,19	695250,15	695327,34
2018-2	3,78	333,17	328,17	82,88	698403,16	698486,04
2018-3	3,89	336,48	333,21	81,58	791182,52	791264,10
2018-4	4,06	342,78	341,88	83,88	706286,53	706370,41
2018-5	4,42	348,34	354,85	93,09	747262,96	747356,05

2018-6	4,64	357,44	365,60	85,38	659459,94	659545,32
2018-7	4,76	359,41	372,06	89,55	699662,71	699752,26
2018-8	5,74	367,66	396,62	82,29	616081,45	616163,74
2018-9	6,38	390,84	439,78	76,38	717101,18	717177,56
2018-10	5,87	401,27	443,78	76,86	760085,95	760162,81
2018-11	5,38	395,48	432,55	78,83	747408,99	747487,82
2018-12	5,32	393,88	422,94	72,27	623297,84	623370,11
2019-1	5,38	398,07	424,86	74,24	675589,90	675664,14
2019-2	5,27	398,71	425,26	72,77	639693,47	639766,24
2019-3	5,45	402,81	431,98	77,58	727808,60	727886,18
2019-4	5,75	409,63	444,85	76,77	690699,96	690776,73
2019-5	6,06	413,52	456,74	68,17	786328,83	786397,00
2019-6	5,82	413,63	457,16	65,73	509869,39	509935,12
2019-7	5,68	419,24	452,63	63,88	662373,68	662437,56
2019-8	5,63	422,84	449,96	58,88	572662,83	572721,71
2019-9	5,72	427,04	450,55	60,74	677695,64	677756,38
2019-10	5,79	435,59	451,31	64,38	704751,84	704816,22
2019-11	5,74	437,25	450,97	65,30	673997,06	674062,36
2019-12	5,85	440,50	454,08	68,98	598256,98	598325,96
2020-1	5,93	446,45	462,42	67,42	673012,54	673079,96
2020-2	6,06	448,02	464,64	61,80	645868,96	645930,76
2020-3	6,33	450,58	468,69	51,14	584618,18	584669,32
2020-4	6,83	454,43	474,69	57,42	306249,94	306307,36
2020-5	6,96	460,62	482,02	57,24	368574,71	368631,95
2020-6	6,82	465,84	485,37	60,98	553321,32	553382,30
2020-7	6,86	468,56	490,33	62,74	655113,32	655176,06
2020-8	7,27	472,61	501,85	65,26	568069,16	568134,42
2020-9	7,52	477,21	515,13	65,81	687453,07	687518,88
2020-10	7,89	487,38	533,44	68,98	769646,11	769715,09
2020-11	8,02	498,58	555,18	72,24	705036,89	705109,13
2020-12	7,73	504,81	568,27	78,24	769596,95	769675,19
2021-1	7,41	513,30	583,38	80,61	730139,00	730219,61
2021-2	7,09	517,96	590,52	89,02	744960,00	745049,02
2021-3	7,64	523,53	614,93	80,77	868486,00	868566,77
2021-4	8,17	532,32	641,63	88,34	877323,00	877411,34
2021-5	8,36	537,05	666,79	82,09	743336,00	743418,09
2021-6	8,61	547,48	693,54	85,05	898791,00	898876,05
2021-7	8,63	557,36	710,61	89,59	723634,00	723723,59
2021-8	8,49	563,60	730,28	92,52	828181,00	828273,52
2021-9	8,53	570,66	741,58	105,59	943613,00	943718,59
2021-10	9,16	584,32	780,45	115,03	917487,00	917602,03
2021-11	10,54	604,84	858,43	106,41	936663,00	936769,41
2021-12	13,55	686,95	1022,25	113,63	933219,00	933332,63

EK 3- BAĞIMSIZ VERİLERİN NORMALİZE HALİ

AYLAR	DOLAR	TÜFE	ÜFE	PAMUK	İHRACAT	İTHALAT
2018-1	0	0	0	0,40773204	0,61032751	0,6103124
2018-2	0	0,00679394	0,01219668	0,49679136	0,61527447	0,61526791
2018-3	0,01125896	0,01608647	0,01936953	0,47644389	0,76084198	0,76082239
2018-4	0,02865916	0,03377316	0,03170853	0,51244326	0,62764319	0,62763727
2018-5	0,06550665	0,04938237	0,05016722	0,65659728	0,69193376	0,69193743
2018-6	0,08802456	0,07492981	0,06546645	0,53592111	0,55417394	0,55417593
2018-7	0,10030706	0,08046042	0,07466021	0,60118954	0,61725066	0,61725442
2018-8	0,20061412	0,10362156	0,10961361	0,48755674	0,48611463	0,48611691
2018-9	0,26612078	0,16869736	0,17103821	0,395054	0,644611	0,64459203
2018-10	0,21392016	0,19797866	0,17673095	0,40256691	0,71205257	0,71202926
2018-11	0,16376663	0,18172375	0,16074859	0,43340116	0,69216288	0,69214416
2018-12	0,15762538	0,17723189	0,1470718	0,33072468	0,49743689	0,4974226
2019-1	0,16376663	0,18899495	0,14980431	0,36155893	0,57948127	0,57946387
2019-2	0,15250768	0,19079169	0,15037359	0,33855063	0,52316105	0,52314559
2019-3	0,17093142	0,20230208	0,15993738	0,41383628	0,66141056	0,66139221
2019-4	0,20163767	0,22144862	0,17825375	0,40115824	0,60318843	0,6031732
2019-5	0,23336745	0,23236946	0,19517541	0,26655189	0,75322672	0,75318666
2019-6	0,20880246	0,23267827	0,19577314	0,22836125	0,31947169	0,31946058
2019-7	0,19447288	0,24842785	0,18932612	0,19940523	0,55874549	0,5587134
2019-8	0,18935517	0,25853453	0,18552622	0,12114572	0,41799236	0,41796306
2019-9	0,19856704	0,27032566	0,1863659	0,15025826	0,58278511	0,58274627
2019-10	0,20573183	0,29432903	0,18744752	0,20723118	0,62523532	0,62519899
2019-11	0,20061412	0,29898933	0,18696364	0,22163093	0,57698216	0,57695092
2019-12	0,21187308	0,30811342	0,19138974	0,27922993	0,45814867	0,45813218
2020-1	0,22006141	0,32481752	0,20325909	0,25481296	0,57543749	0,5754097
2020-2	0,23336745	0,32922515	0,20641856	0,16684927	0,53285018	0,53281678
2020-3	0,26100307	0,33641213	0,21218245	0	0,43674988	0,43670702
2020-4	0,31218014	0,34722066	0,22072155	0,09829394	0	0
2020-5	0,32548618	0,36459854	0,23115349	0,0954766	0,09778534	0,09777767
2020-6	0,3111566	0,37925323	0,23592116	0,15401471	0,38764622	0,38762251
2020-7	0,31525077	0,38688939	0,24298015	0,18156206	0,54735425	0,54732123
2020-8	0,35721597	0,3982594	0,25937522	0,22100485	0,41078505	0,41076631
2020-9	0,3828045	0,4111735	0,2782751	0,2296134	0,59809417	0,59806213
2020-10	0,42067554	0,43972487	0,30433359	0,27922993	0,72705214	0,72701533
2020-11	0,43398158	0,47116788	0,33527361	0,33025513	0,62568255	0,62565852
2020-12	0,40429887	0,48865806	0,35390308	0,42416654	0,726975	0,72695272
2021-1	0,37154555	0,51249298	0,37540739	0,46126154	0,66506688	0,665053
2021-2	0,33879222	0,52557552	0,38556892	0,59289404	0,6883205	0,68831806
2021-3	0,395087	0,5412128	0,42030883	0,46376585	0,88212841	0,88209837
2021-4	0,4493347	0,56588995	0,45830783	0,58225074	0,89599334	0,89597414
2021-5	0,46878199	0,57916901	0,49411514	0,48442636	0,6857725	0,68575938
2021-6	0,49437052	0,60845031	0,5321853	0,53075599	0,92967587	0,92964896
2021-7	0,4964176	0,63618754	0,55647904	0,60181562	0,65486076	0,65486174
2021-8	0,48208802	0,65370578	0,58447307	0,64767569	0,81889129	0,81888447
2021-9	0,48618219	0,67352611	0,60055504	0,85224605	1	1

2021-10	0,5506653	0,71187535	0,65587419	1	0,95900923	0,95902714
2021-11	0,69191402	0,76948344	0,76685405	0,86508061	0,9890957	0,98909781
2021-12	1	1	1	0,97808734	0,98369218	0,98370603

EK 4- 2018-2021 YILLARI ARASI BAĞIMLI VERİLER VE NORMALİZE DEĞERLERİ

AYLAR	SATIŞ	NORMALİZE SATIŞ
2018-1	845522	0,382328162
2018-2	945992	0,459068922
2018-3	815632	0,359497652
2018-4	946219	0,459242308
2018-5	935693	0,451202364
2018-6	643331	0,227891107
2018-7	599392	0,194329723
2018-8	456212	0,084966312
2018-9	687260	0,261444853
2018-10	919977	0,439198205
2018-11	1099177	0,576074329
2018-12	827833	0,368816992
2019-1	1067429	0,551824646
2019-2	1148787	0,613967322
2019-3	1147506	0,612988872
2019-4	880069	0,40871577
2019-5	918589	0,438138026
2019-6	917698	0,437457465
2019-7	1202608	0,655076752
2019-8	917588	0,437373445
2019-9	1322306	0,746504198
2019-10	1014741	0,511580621
2019-11	1041278	0,53185005
2019-12	958876	0,468909948
2020-1	809975	0,355176736
2020-2	791803	0,341296642
2020-3	728577	0,293003507
2020-4	344973	0
2020-5	421549	0,058490101
2020-6	976102	0,482067471
2020-7	976638	0,482476877
2020-8	810216	0,355360816
2020-9	732373	0,295902958
2020-10	1109746	0,584147117
2020-11	868713	0,400041857
2020-12	1654186	1
2021-1	1032394	0,525064294
2021-2	1006224	0,505075186
2021-3	1304748	0,733093087
2021-4	1441109	0,837248026
2021-5	691481	0,264668927

2021-6	1292452	0,723701185
2021-7	1058760	0,545203111
2021-8	936889	0,452115889
2021-9	994050	0,49577647
2021-10	848797	0,384829665
2021-11	1025335	0,519672506
2021-12	1192180	0,647111662

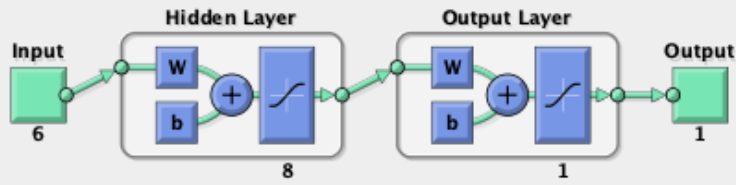
EK 5- MSE HESAPLAMA TABLOSU

AYLAR	normalize TEST	normalizeTAHMİN	MSE
2020-7	0,482476877	0,076464036	0,164846427
2020-8	0,355360816	0,349972548	2,90334E-05
2020-9	0,295902958	0,303686262	6,05798E-05
2020-10	0,584147117	0,717487518	0,017779663
2020-11	0,400041857	0,387550507	0,000156034
2020-12	1	0,802906412	0,038845882
2021-1	0,525064294	0,520552935	2,03524E-05
2021-2	0,505075186	0,506845469	3,1339E-06
2021-3	0,733093087	0,735108922	4,06359E-06
2021-4	0,837248026	0,842846831	3,13466E-05
2021-5	0,264668927	0,271951198	5,30315E-05
2021-6	0,723701185	0,723041493	4,35194E-07
2021-7	0,545203111	0,548086134	8,31183E-06
2021-8	0,452115889	0,441873748	0,000104901
2021-9	0,49577647	0,499094207	1,10074E-05
2021-10	0,384829665	0,382240452	6,70402E-06
2021-11	0,519672506	0,521681483	4,03599E-06
2021-12	0,647111662	0,646878436	5,43944E-08
			TOPLAM
			0,221964997
			MSE
			0,012331389

EK 6- MATLAB YAPAY SİNİR AĞI PERFORMANS VERİLERİ

Neural Network Training (nntraintool)

Neural Network



Algorithms

Data Division: Random (dividerand)
 Training: Levenberg-Marquardt (trainlm)
 Performance: Mean Squared Error (mse)
 Calculations: MEX

Progress

Epoch:	0	50 iterations	1000
Time:		0:00:00	
Performance:	0.0120	1.77e-15	0.00
Gradient:	0.146	9.89e-08	1.00e-07
Mu:	0.00100	1.00e-15	1.00e+10
Validation Checks:	0	35	1000

Plots

(plotperform)
 (plottrainstate)
 (plotregression)

Plot Interval: epochs

✔ Opening Training State Plot

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER	
Adı ve SOYADI	Buse Ceren AKBAŞ
Yabancı Dil	İNGİLİZCE
EĞİTİM DURUMU	
Mezun Olduğu Lise	Antalya Aldemir-Atilla Konuk Anadolu Lisesi – 2014
Lisans Diploması	Akdeniz Üniversitesi, Alanya Mühendislik Fakültesi, Endüstri Mühendisliği, Antalya, 2018
Yüksek Lisans	Akdeniz Üniversitesi, Uygulamalı Bilimler Fakültesi, Uluslararası Ticaret ve Lojistik, Devam
İŞ DENEYİMİ	
Çalıştığı Kurumlar	One Life Medikal Kozmetik İth. İhr. San. ve Tic. Ltd. Şti., Endüstri Mühendisi, 2020.
	Antalya Akev Üniversitesi, Uluslararası Ticaret ve İşletmecilik Bölümü Araştırma Görevlisi, 2022- Devam