

T.C. İSTANBUL KÜLTÜR ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

TALEP TAHMİN YÖNTEMLERİNİN KARŞILAŞTIRMALI  
ANALİZİ: GIDA SEKTÖRÜNDE BİR UYGULAMA

YÜKSEK LİSANS TEZİ

Aydın YILDIRIM

1600007117

Anabilim Dalı: İşletme

Programı: İşletme Uzaktan Eğitim

Tez Danışmanı: Dr. Öğr. Üyesi Murat Taha BİLİŞİK

Mayıs 2019

T.C. İSTANBUL KÜLTÜR ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

TALEP TAHMİN YÖNTEMLERİNİN KARŞILAŞTIRMALI  
ANALİZİ: GIDA SEKTÖRÜNDE BİR UYGULAMA

YÜKSEK LİSANS TEZİ

Aydın YILDIRIM

1600007117

Anabilim Dalı: İşletme

Programı: İşletme Uzaktan Eğitim

Tez Danışmanı: Dr. Öğr. Üyesi Murat Taha BİLİŞİK

Jüri Üyeleri: Dr. Öğr. Üyesi Özge Nalan BİLİŞİK

Öğr. Gör. Dr. Meral ARIK TOPRAK

Mayıs 2019

## ÖNSÖZ

Tez çalışmamda emeğini, ilgi ve alakasını, her türlü desteğini benden esirgemeyen Danışman Hocam Dr. Öğr. Üyesi Murat Taha BİLİŞİK'e; çalışmanın her aşamasında katkılarını esirgemeyerek yardımcı olan ve her ihtiyacım olduğunda desteğini, yardımını esirgemeyen değerli dostlarım Yasin Gürses başta olmak üzere, Şehmus Aslan, Alp Eren Güney ve Cumali Kılıç'a; hayatım boyunca her alanda olduğu gibi bu süreçte de her yönüyle sürekli yanımda olup desteğini hissettiren değerli aileme teşekkürlerimi ve saygılarımı sunarım.



## İÇİNDEKİLER

ÖNSÖZ .....	ii
İÇİNDEKİLER.....	iii
KISALTMALAR.....	vi
TABLO LİSTESİ.....	vii
ŞEKİL LİSTESİ .....	viii
ÖZET .....	ix
ABSTRACT .....	x
GİRİŞ.....	1
1. TALEP TAHMİNİ.....	3
1.1. Tahmin İlkeleri.....	4
1.2. Tahmin Yönteminin Seçimi .....	6
1.3. Talep Tahminlerinin Sınıflandırılması (Tahmin Dönemleri).....	7
1.4. Tahmin Maliyetleri.....	8
1.5. Talep Araştırmasında Yapılacak İşlemler.....	9
1.6. Tahminleme Teknikleri.....	10
1.6.1. Nitel Yöntemler .....	10
1.6.1.1. Delphi Tekniği.....	11
1.6.1.2. Yönetici Görüşleri .....	12
1.6.1.3. Uzman Grup Görüşü.....	13
1.6.1.4. Satış Gücü Karması Tekniği .....	13
1.6.1.5. Uzman Panel.....	13
1.6.1.6. Senaryo Analizi .....	14
1.6.1.7. Uzman Sistemler.....	14
1.6.2. Nicel Yöntemler .....	14
1.6.2.1. Son Dönem Talebi Yöntemi.....	15
1.6.2.2. Ortalamalar Yöntemi .....	15
1.6.2.3. Üstel Düzeltme Yöntemi.....	16
1.6.2.4. Box-Jenkins Yöntemi .....	17
1.6.2.5. AR Yöntemi .....	17
1.6.2.6. Hareketli Ortalamalar Yöntemi .....	18
1.6.2.7. ARMA Yöntemi .....	18

1.6.2.8. ARİMA Yöntemi.....	19
1.6.2.9. Regresyon Analizi Yöntemi.....	20
1.6.2.10. Yapay Sinir Ağları Yöntemiyle Talep Tahmini.....	20
1.5. Tahmin Yöntemlerinin Karşılaştırılması.....	21
1.5. Tahmin Hatasının Ölçümü.....	22
1.5.1. Ortalama Mutlak Sapma (MAD).....	23
1.5.2. Ortalama Hata.....	23
1.5.3. Ortalama Mutlak Hata (MAE).....	23
1.5.4. Ortalama Mutlak Yüzde Hata (MAPE).....	23
1.5.5. Ortalama Hata Kare (MSE).....	24
1.5.6. Ortalama Hata Karesinin Kökü (RMSE).....	24
1.5.7. Simetrik ortalama mutlak yüzde hata (sMAPE).....	24
1.5.8. Ortalama mutlak ölçekli hata (MASE).....	25
2. YAPAY SİNİR AĞLARI.....	26
2.1. Yapay Sinir Ağı Kavramı.....	26
2.2. Yapay Sinir Ağları Yönteminin Uygulama Alanları.....	29
2.3. Yapay Sinir Ağları Yönteminin Avantajları ve Dezavantajları.....	31
2.4. Diğer Talep Tahmin Yöntemleri İle Yapay Sinir Ağları Yönteminin Karşılaştırılması.....	32
2.5. Biyolojik Sinir Hücreleri ile Yapay Sinir Hücrelerinin Karşılaştırılması.....	33
2.5.1. Yapay Sinir Hücreleri.....	33
2.5.2. Biyolojik Sinir Hücreleri.....	34
2.5.3. Biyolojik Sinir Hücreleri ile Yapay Sinir Hücrelerinin Karşılaştırılması.....	35
2.6. Yapay Sinir Ağları Yönteminin Temel Yapısı.....	35
2.7. Yapay Sinir Ağlarının Sınıflandırılması.....	37
2.7.1. İleri Beslemeli Yapay Sinir Ağları.....	38
2.7.2. Geri Beslemeli Yapay Sinir Ağları.....	41
2.7.3. İleri Beslemeli Geri Yayılmalı Sinir Ağları.....	43
2.8. Yapay Sinir Ağlarında Öğrenme.....	44
2.8.1. Danışmanlı Öğrenme.....	45
2.8.2. Danışmansız Öğrenme.....	46
2.8.3. Destekleyici Öğrenme.....	46
2.8.4. Öğrenme Kuralları.....	46

2.9. Yapay Sinir Ağlarının Tasarımı ve Eğitimi .....	48
2.10. Veri Normalleştirme .....	49
2.11. Ağ Yapısının Seçimi.....	50
2.12. Öğrenme Algoritmasının Seçimi .....	50
2.13. Gizli Katman Sayısının Belirlenmesi .....	51
2.14. Nöron Sayısının Belirlenmesi .....	51
2.15. Yapay Sinir Ağlarının Eğitimi ve Testi .....	51
2.16. Durdurma Kriterinin Belirlenmesi .....	52
3. GIDA SEKTÖRÜNDE TALEP TAHMİN YÖNTEMLERİ UYGULAMASI .....	53
3.1. Regresyon Yöntemi .....	53
3.2. Hareketli Ortalamalar Yöntemi .....	56
3.3. Üstel Düzeltme Yöntemleri .....	60
3.4. Yapay Sinir Ağları İle Talep Tahmin Yöntemi.....	64
3.4.1. Değişkenlerin Tanımlanması .....	64
3.4.2. Modelin Tasarlanması .....	70
3.4.3. Talep Tahmin Uygulaması .....	72
3.4.4. Yapay Sinir Ağları Tahmin Sonuçları.....	75
3.5. Tahminlerin Hata Testleri ve Karşılaştırması .....	77
SONUÇ VE ÖNERİLER .....	80
KAYNAKÇA .....	85

## **KISALTMALAR**

AR: Auto-Regressive (Oto regresif)

ARMA: Auto regressive moving average (Oto regresif hareketli ortalama)

ARİMA: Regressive integrated moving average (Birleřtirilmiř oto regresif hareketli ortalama)

ART: Adaptif rezonans teorisi

ÇKA: Çok katmanlı algılayıcılar

ERP: Enterprise resource planning (Kurumsal kaynak planlama)

GYA: Geri yayılım algoritması

LMS: Least mean square (En küçük ortalama kare)

LVQ: Learning vektör quantization (vektör kuantalama)

MA: Moving average (Hareketli ortalama)

MAD: Ortalama mutlak sapma

MAE: Ortalama mutlak hata

MAPE: Ortalama mutlak yüzde hata

MASE: Ortalama mutlak ölçekli hata

MSE: Ortalama hata kare

sMAPE: Simetrik ortalama mutlak yüzde hata

Sig.: Anlamlılık (significance)

RMSE: Ortalama Hata Karesinin Kökü

RTF: Radyal tabanlı fonksiyon

YSA: Yapay sinir ağıları

## TABLO LİSTESİ

Çizelge 2.1: Yapay sinir ağı, uzman sistemler ve geleneksel hesaplama yöntemleri karşılaştırması.....	32
Çizelge 2.2: Biyolojik-Yapay Sinir Hücresi Elemanlarının Karşılıkları .....	35
Çizelge 3.1: Regresyon Analizi Betimleyici İstatistikler Tablosu .....	53
Çizelge 3.2: Regresyon Analizi Özet Tablosu .....	54
Çizelge 3.3: Regresyon Analizi Anova Tablosu .....	54
Çizelge 3.4: Regresyon Modeli Katsayı Tablosu .....	55
Çizelge 3.5: Aylık Ortalama İthal Ceviz Talebi .....	65
Çizelge 3.6: Pazarda Faaliyet Gösteren Rakip Sayısı.....	66
Çizelge 3.7: Aylık Satış Yapılan Müşteri Sayısı .....	66
Çizelge 3.8: Aylık Ortalama Ceviz Fiyatı.....	67
Çizelge 3.9: 12 Aylık Ortalama Enflasyon (TÜFE) .....	68
Çizelge 3.10: Aylık Ortalama Dolar Kuru .....	69
Çizelge 3.11: Eğitim Çıktıları.....	74
Çizelge 3.12: Ağın Tutarlılığı İçin Kullanılacak Veri Seti .....	75
Çizelge 3.13: Tahminlenen Talep İle Gerçek Talep Arasındaki Fark .....	76
Çizelge 3.14: Oluşturulan Modellerin Hata Terimleri Tablosu.....	78



## ŞEKİL LİSTESİ

Şekil 1.1: Tahmin Maliyeti Dengesi .....	9
Şekil 2.1. Amaca Göre YSA Modelleri .....	30
Şekil 2.2. Yapay Sinir Hücresi Yapısı .....	33
Şekil 2.3: Yapay bir nöronun genel işleyişi. ....	34
Şekil 2.4. Biyolojik Sinir Hücresi Yapısı.....	34
Şekil 2.5. YSA Yapısı.....	36
Şekil 2.6: Yapay Sinir Ağları Sınıflandırması.....	38
Şekil 2.7: İleri Beslemeli Yapay Sinir Ağı.....	39
Şekil 2.8: Elman ve Jordan Ağı Gösterimi.....	41
Şekil 2.9: Geri Beslemeli Yapay Sinir Ağı .....	42
Şekil 2.10: İleri Beslemeli Geri Yayılmalı Yapay Sinir Ağı Yapısı.....	44
Şekil 3.1: Regresyon Modeliyle Tahmin Edilen Değerler İle Gerçek Değerlerin Grafığı .....	56
Şekil 3.2: 3'lü Hareketli Ortalama Grafığı.....	57
Şekil 3.3: 3'lü Hareketli Ortalama Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Değerlerinin Grafığı.....	57
Şekil 3.4: 4'lü Hareketli Ortalama Grafığı.....	58
Şekil 3.5: 4'lü Hareketli Ortalama Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Değerlerinin Grafığı.....	58
Şekil 3.6: 6'lı Hareketli Ortalama Grafığı.....	59
Şekil 3.7: 6'lı Hareketli Ortalama Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Değerlerinin Grafığı.....	60
Şekil 3.8: Tekli Üstel Düzeltme Yöntemi Grafığı .....	61
Şekil 3.9: Tekli Üstel Düzeltme Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Talep Değerlerinin Grafığı.....	61
Şekil 3.10: 2'li Üstel Düzeltme Yöntemi Grafığı.....	62
Şekil 3.11: 2'li Üstel Düzeltme Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Talep Değerlerinin Grafığı .....	63
Şekil 3.12: Winters' Üstel Düzeltme Yöntemi Grafığı.....	63
Şekil 3.13: Winters' Üstel Düzeltme Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Talep Değerlerinin Grafığı.....	64
Şekil 3.14: Veri Setinin Matlab Programına Aktarımı .....	70
Şekil 3.15: Matlab Yapay Sinir Ağı Oluşturulması.....	71
Şekil 3.16: Yapay Sinir Ağı Modeli .....	71
Şekil 3.17: Eğitim Algoritması Parametreleri .....	72
Şekil 3.18: Yapay Sinir Ağı Eğitimi Performans Grafığı .....	72
Şekil 3.19: Ağ Eğitiminde Regresyon Değerleri .....	73
Şekil 3.20: YSA Çıktısı İle Gerçek Değerlerin Gösterimi .....	74
Şekil 3.21: Tahminlenen Talep İle Gerçek Talep.....	77

**Enstitü** : **Lisansüstü Eğitim Enstitüsü**  
**Anabilim Dalı** : **İşletme**  
**Programı** : **İşletme Uzaktan Eğitim**  
**Danışman** : **Dr. Öğr. Üyesi Murat Taha BİLİŞİK**  
**Tez Türü ve Tarihi** : **Yüksek Lisans Tezi – Mayıs 2019**

## **TALEP TAHMİN YÖNTEMLERİNİN KARŞILAŞTIRMALI ANALİZİ: GIDA SEKTÖRÜNDE BİR UYGULAMA**

Aydın YILDIRIM

### **ÖZET**

Çalışmada, gıda sektöründe faaliyet gösteren bir firma ele alınmıştır. Ceviz ithalatı alanında faaliyet gösteren firmanın 2013-2018 yılları arasındaki satış verileri alınarak araştırmaya dahil edilmiştir. Şirketin satın alma ve pazarlama yöneticileri ile görüşülüp geçmiş yıllara ait satış rakamlarına ulaşılmış ve talebi etkileyen faktörler belirlenmiştir. Veriler firmanın talebi doğrultusunda gerçek değerlere yakın değerler kullanılarak talep tahmin çalışması yapılmış, günümüzde literatürde yer alan bazı talep tahmin yöntemlerinin yapay sinir ağları yöntemi ile karşılaştırılması hedeflenmiştir. Çalışma üç bölümden meydana gelmektedir. İlk bölümde; talep tahmin kavramı, bu kavramın temel özellikleri ve zaman içerisindeki değişimi hakkında literatür taraması yapılmıştır. İkinci bölümde; yapay sinir ağları kavramı, bu kavramın temel özellikleri, zaman içerisindeki gelişimi ve kullanım alanları hakkında literatür taraması yapılarak gerekli bilgilendirmeler yapılmıştır. Çalışmanın son bölümünü ve uygulama kısmını oluşturan üçüncü bölümde ise; çalışmanın amacı, veri toplama yöntemi, analiz teknikleri gibi çalışma probleminin incelenmesi adına ihtiyaç duyulan gerekli bilgilendirmeler yapılmış; çalışmanın bulguları, sonucu ve önerileri ele alınarak çalışma nihayete erdirilmiştir. Sonuç olarak; oluşturulan veri seti ile çoklu regresyon, 3'lü, 4'lü ve 6'lı hareketli ortalamalar, tekli, ikili ve winters' metodu üstel düzeltme yöntemleri ve yapay sinir ağları yöntemi ile talep tahmin modelleri kurulmuştur. Kurulan bu modeller ile yapılan tahminlerin hata terimleri incelenerek en uygun model belirlenmeye çalışılmıştır. Yapay sinir ağları ile kurulan modelin; regresyon, 3'lü, 4'lü ve 6'lı hareketli ortalamalar ve tekli üstel düzeltme, ikili üstel düzeltme ve winters' metodu üstel düzeltme yöntemlerinden bu çalışma özelinde daha tutarlı tahminlerde bulunduğu saptanmıştır.

**Anahtar Kelimeler:** Talep, tahmin, talep tahmini, yapay sinir ağları.

**Enstitü** : **Lisansüstü Eğitim Enstitüsü**  
**Anabilim Dalı** : **İşletme**  
**Programı** : **İşletme Uzaktan Eğitim**  
**Danışman** : **Dr. Öğr. Üyesi Murat Taha BİLİŞİK**  
**Tez Türü ve Tarihi** : **Yüksek Lisans Tezi – Mayıs 2019**

**COMPARATIVE ANALYSIS OF DEMAND PREDICTION METHODS: AN  
APPLICATION IN FOOD SECTOR**

Aydın YILDIRIM

**ABSTRACT**

In this study, a company operating in the food sector was discussed. Sales data of the company operating in the field of walnut importation between 2013-2018 years were included in the study. As a result of the interviews with the purchasing and marketing managers of the company, sales figures of the company have been reached and the factors affecting the demand have been determined. According to the request of the firm, demand estimation study was performed by using values close to real values and it is aimed to compare some demand estimation methods in the literature with artificial neural network method. The study consists of three parts. In the first part; the concept of demand estimation, the basic features of this concept and the change of concept in time have been reviewed. In the second part; the concept of artificial neural networks, the basic features of this concept, the development of concept in time and the areas of use have been reviewed by making a literature review. In the third part, that constitutes the last part of the study and the application part; necessary information such as the purpose of the study, data collection method and analysis techniques which are needed to examine the working problem are explained; findings, results and suggestions of the study have been discussed and the study has been finalized. Consequently, with the data set created, demand estimation models which are multiple regression technique; 3, 4, and 6 moving averages techniques; singular, binary and winters' exponential correction methods and artificial neural network method are compared. The most appropriate model was tried to be determined by examining the error terms of the estimations made with these models. It was found that, artificial neural networks model gave more consistent results and estimations than, regression; 3, 4 and 6 moving averages; single, binary and winters' exponential correction techniques.

**Keywords:** Demand, estimation, demand estimation, artificial neural networks

## GİRİŞ

Günümüz modern toplumlarında, bireylerin ve örgütlerin içerisinde bulunduğu sürekli değişen ve gelişen küresel yapı bireyleri ve örgütleri olumlu ya da olumsuz birçok açıdan etkilemektedir. İnsanoğlu var olduğundan beri üretmekte, endüstriyel devrimlere ve gelişmelere maruz kaldığından beri ise ihtiyacından fazla ürettiklerini değerlendirme problemi ile karşı karşıya kalmaktadır. Piyasa koşulları içerisinde şekillenen talep koşulları ve değişimleri ise bu değerlendirme çabasının en temelinde yer almakta ve örgütler adına hayati önem taşımaktadır. Talep kavramının sahip olduğu bu önem, bu kavramın uzun yıllarca ve halen günümüzde de etraflı bir şekilde incelenip araştırılmasına neden olmuştur.

Örgütler, gelecek dönemlerde ortaya çıkabilecek örgütsel problemleri tahmin edebilmek zorundadır ve kıt kaynaklarla yapılan üretim sınırlı olduğu için, üretim miktarının önceden belirlenmesine ya da tahmin edilebilmesine ihtiyaç duymaktadırlar. Belirli bir süre içerisinde tüketicilerin gelirleri, beğenileri ve satın alabilecekleri diğer ürünlerin fiyatlarının sabit kalacağı kabul edilirse; bir mal ya da hizmetin talep edilen miktarının sadece o ürüne yönelik duyulan ihtiyaca ve ürün fiyatına bağlı olarak değişiklik göstereceğini açıklayan fonksiyonel ilişki talep olarak adlandırılmaktadır. Tüketicilerin, belirli bir fiyat üzerinden satın almaya niyetlendikleri miktar şeklinde tanımlanan talep, olası satış hacmini ifade etmektedir.

Bir mal ya da hizmete olan talebin miktarı ve bu durumun ölçülmesinin gerekliliği yıllar içerisinde talep tahmini kavramının derinlemesine araştırılmasına neden olmuştur. Bu tahmin süreci açısından farklı talep tahminleri kullanılmış, ortaya atılmış, literatüre dahil edilmiş ya da edilmemiştir fakat özellikle son yıllarda giderek daha fazla uygulama alanı bulan ve detaylı araştırılmaya başlanılan "yapay sinir ağları" yöntemi öne çıkmaya başlamıştır. Yapay sinir ağları, nörobiyolojik sistemlerden ilham alan ve nöron olarak adlandırılan işlem birimlerinden oluşan bir yapıdadır. Temel olarak, insan beyninin öğrenme sürecinin sanal ortamda taklit edilmesi çabalarıyla ortaya çıkarılmış bir yöntem olan yapay sinir ağları yöntemi genellikle karmaşık problemlerin çözümünde tercih edilmektedir. Bu çalışmada da,

talep kavramı ve daha açık anlaşılabilmesi adına gerekli açıklamalar yapılarak bir uygulama ile talep tahmin yöntemleri karşılaştırılmaya çalışılmıştır.

Araştırmanın uygulaması esnasında, gıda sektöründe faaliyet gösteren bir firma ele alınmıştır. Ceviz ithalatı alanında faaliyet gösteren firmanın 2013-2018 yılları arasındaki satış verileri alınarak araştırmaya dahil edilmiştir. Şirketin ERP sisteminden alınan verilere uygulanan analizler neticesinde bağımlı ve bağımsız değişkenlerin ortalamaları ve standart sapmaları hesaplanmış, şirketin satın alma ve pazarlama yöneticileri ile görüşülüp geçmiş yıllara ait satış rakamları alınmış ve talebi etkileyen faktörler belirlenmiştir. Veriler firmanın talebi doğrultusunda gerçek değerlere yakın değerler kullanılarak talep tahmin çalışması yapılmıştır.

Çalışmanın tek bir firma özelinde kalması bu araştırma adına bir sınırlılık oluşturmaktadır. Ayrıca, araştırma konusunu oluşturan ürünün de tek bir ürün olarak ele alınması bir başka sınırlılık olarak karşımıza çıkmaktadır. Fizyolojik yeterlilik ve ulaşılabilirlik açısından bu çalışma belirli bir ürün ve firmaya odaklanmış olsa da ilerleyen dönemlerde, daha geniş imkanlar dahilinde daha büyük veriler ile belki de daha elverişli sonuçlara ulaşmak mümkün olabilecektir.

## 1. TALEP TAHMİNİ

Tahmin etmek zordur, hem de gelecek için bir tahmin yapıyorsanız. Fakat bununla birlikte, insanođlu alışkan bir yaratıktır. Bir düşünür, insanođlunu "yarın ne yapacağını görmek için ya onu bugün gözlemler ya da ona dün ne yaptığını sor" diye tarif etmiştir. O nedenle; yıllar boyu süren arařtırmalar, deneyler ve gözlemler tarihin çođu kez tekerrürden ibaret olduğunu, gelecek için tahminde bulunurken geçmişini muhakkak incelemek gerektiğini göstermiştir (Serttař, 2011: 1).

Tahmin kavramı, belirli bir deđişkenin belli varsayımlar kapsamında gelecek dönemde alabileceđi muhtemel deđerlerin yaklaşık olarak saptanmaya çalışılması şeklinde tanımlanabilir. Zaman serisi çözümlemesinden de yardım alarak, öngörü, belirlenen deđişkenin řu anki ve geçmiş dönemlerdeki gözlem deđerlerini de ele alarak varsayımlar vasıtasıyla öngörü deđerlerinin sınırlarını belirleyebilme adına gösterilen çabalardır. Başarılı bir öngörünün başarılı kararları getireceđi, bunun yanında yararlanılan faydanın maksimum seviyeye çıkartılabileceđi gerçeđi, öngörü modellemelerine olan ilgiyi yükseltmektedir (Ataseven, 2013: 1).

Tahmin, normal günlük hayatta öngörme, fikir yürütme, kehanet gibi terimlerin aralarındaki farklar dikkate alınmadan çođu zaman birbirlerinin yerine kullanılması şeklinde karşımıza çıkmaktadır. Benzer durum İngilizce'de de görölmektedir: forecast, predict, estimate ve cast gibi terimler birbirlerinin yerine kullanılabilir (Tokpunar, 2014: 12). Fakat bu kavramlar, her ne kadar günlük yaşantıda birbirlerinin yerine kullanılsa da temelde farklı anlamlar taşımaktadır. Bu çalışma açısından tahmin kavramı talep kavramı ile yakından ilişkili olacağı için her iki kavramın da kısaca açıklanmasına ihtiyaç duyulmaktadır.

Talep kavramı ise, " belirli bir dönemde ve belirli bir pazarda tüketicilerin deđişik fiyat düzeylerinde satın almaya istekli oldukları ve satın alabilecekleri ürün miktarı" şeklinde açıklanabilir. Ayrıca, belirli bir süre içerisinde tüketicilerin gelirleri,

beğenileri ve satın alabilecekleri diğer ürünlerin fiyatlarının sabit kalacağı kabul edilirse; bir mal ya da hizmetin talep edilen miktarının sadece o ürüne yönelik duyulan ihtiyaca ve ürün fiyatına bağlı olarak değişiklik göstereceğini açıklayan fonksiyonel ilişki talep olarak adlandırılmaktadır. Tüketicilerin, belirli bir fiyat üzerinden satın almaya niyetlendikleri miktar şeklinde tanımlanan talep, olası satış hacmini ifade etmektedir. Bir mal ya da hizmete olan talebin miktarı ve bu durumun ölçülmesi işletmeler adına büyük öneme sahiptir (Aydın, 2017: 2).

Talep tahmini, envanter yönetiminden nakliye, dağıtım, yenileme, üretim, bakım-onarım, tedarikçi koordinasyonuna bir çok iş operasyonunda geniş bir yelpazede kullanılmaktadır (Fildes vd., 2006: 352). Silver, Pyke ve Peterson, tahmini geçmişte gözlemlenen ve gelecekteki olaylara yönelik yargılar doğrultusunda yapılan geleceğe dönük çıkarımların bir kombinasyonu olarak tanımlamaktadır (Silver vd., 2000: 74).

Yöneticiler, gelecek dönemlerde ortaya çıkabilecek örgütsel problemleri tahmin edebilmek zorundadır. Kıt kaynaklar ile yapılan üretim sınırlı olduğu için, üretim miktarının önceden belirlenmesi önemlidir. Yöneticilerin ürünlerine yönelik talebi tahmin edebilmeleri için gelecek dönemlerin genel ekonomik durumunda tahmin edilmesi gerekir. (Öztürk, 2006: 4).

Hem yatırım projelerinin hazırlanmasında hem de ekonomik değişimlerin ve güncel gelişmelerin etkili bir biçimde anlaşılmasında en önemli adımlardan biri de üretilmesi planlanan mal ya da hizmetin günümüzdeki ve gelecekteki talebinin incelenmesidir. Optimum kapasitenin belirlenmesi, karşılaştırma yapılabilmesi, faydaların ortaya çıkarılabilmesi, yatırım projesinin finansal karlılığının sağlıklı bir biçimde değerlendirilebilmesi adına; proje ömrü süresince geçerliliğini koruyacak, gerçeğe en yakın talep tahminini yapmak en önemli koşuldur (Çetinel, 2005: 95).

### **1.1. Tahmin İlkeleri**

Tahmin yöntemlerinin seçilmesinde; tahmin yönteminin kolaylığı, tahmin yönteminin maliyeti, tahminlerin hazırlanma süresi, verilerin derlenmesi, verilerin özellikleri, tahmin döneminin zaman aralığı, tahmin sonuçlarına bakarak alınacak kararların uzun veya kısa vadeli oluşu, karar vericinin tolere edebileceği hata payı, yöntemi uygulamaya koyacak ve tahminler ışığında karar verecek birimlerin özellikleri gibi çok sayıda faktörün değerlendirilmesine ihtiyaç duyulmaktadır.

Tahmin modellerinde, özellikle ekonometrik modellerde uygun deęişkenlerin seçimi de büyük dikkat gerektirmektedir. Geniş ve karmaşık modeller, tahmin süreçlerinde istenilmeyen yapılardır (Akgül, 2013: 93).

Tahmin yaparken gelecek ile ilgili ve hakkında bilgi sahibi olunan veriler hesaba katılmalıdır. Reklam programlarının beklenen etkileri ya da bir kampanya, talep üzerinde hızlı bir artış sonrası hızlı bir düşüşe ve daha sonrasında normal seviyeye ulaşılmasıyla sonuçlanabilmektedir. Bir işletmenin gelecekte yapmayı düşündüğü promosyon dağıtımlarının, sonrasında talebin artacağı bilinmelidir. Promosyon kampanyasının bitmesinden sonra ürün talebindeki azalmalar dikkate alınmalıdır. Rekabet (piyasaya sunulan yeni ürünler ya da rakip firmaların benzer ürünlerinin fiyatında yaşanan düşmeler gibi), politika ve endüstrinin genel ekonomik yapısı gibi faktörler göz önünde bulundurulmalıdır. Bu bilgilere talep tahmininde dikkat edilmelidir (Aydın, 2017: 4).

Tahmin sonuçlarının etkin bir şekilde kullanılması adına tahmin ilkeleri ile ilgili bilgi sahibi olunması gerekmektedir. Bu ilke ve özellikler aşağıda gösterilmiştir (Bulut, 2006: 11-13; Meydan, 2007: 16-17; Demirbaş, 2011: 7-8):

- Tahmin çalışmalarında mükemmelliğe ulaşmak genel anlamda mümkün değildir. Çoğu zaman gerçek sonuçlar tahminde bulunan değerlerden farklıdır. Bu farklılığın nedenlerinden ilki, tahmini yapılacak deęişkene etki eden tüm faktörlerin dikkate alınamaması gerçeęi ve ikincisi ise beklenilmeyen, ön görülemeyen tesadüfi olayların etkisidir.
- Tahminlerin belirli oranda hata barındırdığı mutlaklıdır. Bu yüzden tahmin uygulamalarında bir tahmin deęerinin yanında belirlenen tahmin deęeri için alt ve üst sınırların yani bir aralığın belirlenmesi gerekmektedir.
- Tahminler, miktar ya da çeşit açısından büyük gruplar için yapıldığında daha duyarlı olmaktadır.
- Tahminlerin kapsadığı zaman aralığının kısalığı ile duyarlılık ters orantılıdır. Yani, zaman aralığı ne kadar kısaysa duyarlılık o düzeyde artacaktır.
- Tahmin esnasında, gelecek ile ilgili ve bilgi sahibi olunan gelişmeler ve deęişimler hesaba katılmalıdır. Örneğin, bir firmanın promosyon kapsamında yapmayı planladığı hediye dağıtımlarının, normal koşullara göre talebi daha fazla göstereceğinin saptanması gibi serinin eski dönemlerdeki hareketlerine



bakılarak ulaşılamayacak bilgilere ulaşılabilir. Bu bilgiler tahminin içerisine entegre edilmelidir.

İyi bir tahminin özellikleri ise aşağıdaki şekilde sıralanabilir;

- Tahmin zamanını göz önünde bulundurmak gerekmektedir. Gerekli değişikliklerin yapılabilmesi adına yeterli zamana sahip olunmalıdır.
- Mümkün oldukça isabetli olmalı ve bu isabetin derecesi de belirtilmelidir.
- Güvenilir olmalıdır.
- Yazılı olmalıdır.
- Tahmin değerleri anlamlı birimler olarak açıklanmalı, ifade edilmelidir.
- Kolaylıkla anlaşılabilmesi ve uygulanabilmesidir.

## **1.2. Tahmin Yönteminin Seçimi**

Tüm yönetim kararları gelecek ile ilgilenecektir. Geleceği ön görebilme ya da tahmin edebilme çabaları; yönetim birimlerinin ve yönetim uygulamalarının karar verme sürecinde önemli bir dayanak olması sebebiyle işletmeler açısından büyük öneme sahiptir. Gerçekleşme olasılığı bulunan bütün olaylar kabul edilebilir seviyede doğru tahmin edilemeyebilir ancak karar verme süreci içerisinde yöneticilere yol göstererek onlara yardımcı olacak bilgiler sunulması bile önemli avantajlar sağlayabilecektir. Güvenilir ve doğru tahmin modellerini birden fazla faktörden oluşan bir fonksiyon şeklinde düşünebiliriz. Bu faktörlerden biri de tahmindir. Uzun dönemli tahminler, yapısı itibarıyla kısa dönemli tahminlere nazaran hataya daha fazla eğilimlidir. Tahminin güvenilirliğini ve doğruluğunu etkileyen bir diğer faktör de model geliştirme esnasında kullanılan geçmiş bilgilerin gözlem sayısının oluşturduğu örnek hacmidir (Karahana, 2011: 29).

Talep tahmin yöntemlerinin gelişmesi, gerek öncül gerek formel tahminleri de içerisinde barındıran çok aşamalı bir süreçtir. Ürün talebine etki eden iç ve dış faktörler belirlendikten ve değerlendirildikten sonra ürün ile ilgili öncül tahminler geliştirilmektedir. Bu tahminler vasıtasıyla elde edilen bilgiler işletmenin pazarlama stratejisini oluşturmada kullanılmaktadır. Sonrasında ise formel talep tahminleri hazırlanıp raporlanmaktadır. Bu sürecin sonuncu aşaması ise tahminlerin

izlenmesidir. Bu süreç boyunca, tahminlerin gerçekleşen durumları ne kadar yansıttığı izlenmeli ve saptanmalıdır (Aydın, 2017: 2).

Talep tahmininde kullanılması planlanan yöntemin; maliyet, duyarlılık ve zaman tasarrufu açısından önem taşıması beklenmektedir. Bunun yanında:

- Karar verici açısından anlaşılabilir olması
- Zaman
- Kararın niteliği (kısa, orta ya da uzun dönem)
- Kullanılacak tekniğin veriye uygunluğu
- Değişkenlik
- Karar vericinin departmanı

Tahmin yönteminin seçiminde etkili olan etkenler olarak değerlendirilmelidir (Kobu, 2010: 131-132).

### **1.3. Talep Tahminlerinin Sınıflandırılması (Tahmin Dönemleri)**

Talep tahminleri, öngörülme istenen zamana göre kısa, orta ve uzun vadeli olarak yapılabilmektedir. Kısa vadeli tahminler bir saatten bir haftaya kadar, orta vadeli tahminler bir haftadan bir yıla kadar ve uzun vadeli tahminlerden bir yıldan uzun süreler için yapılmaktadır (Tutu, 2017: 53).

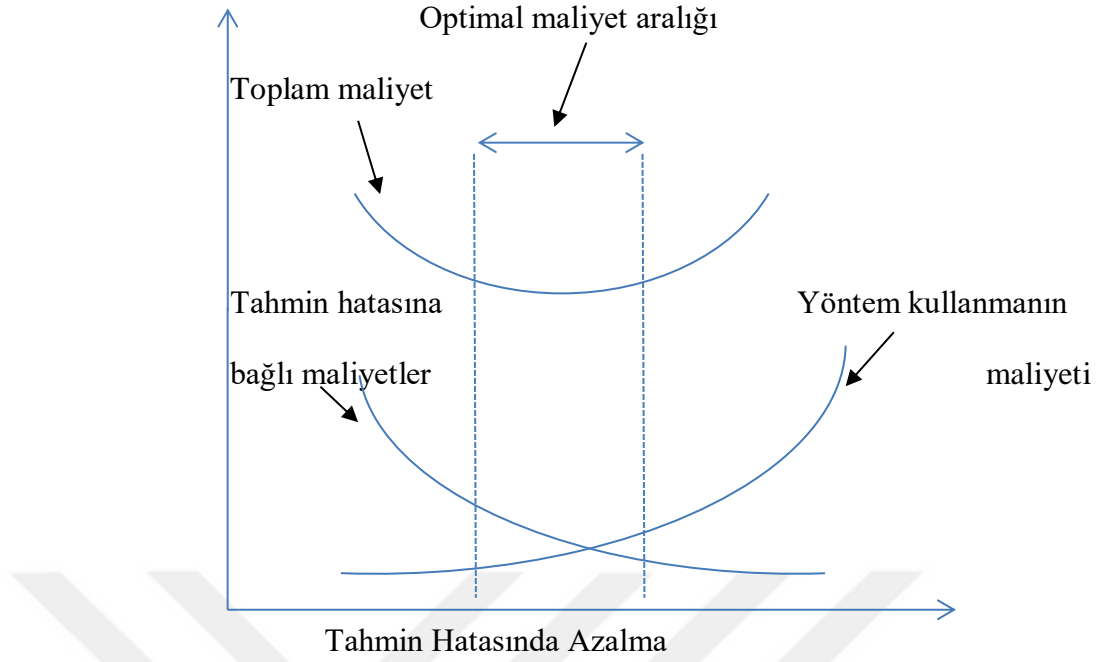
- Kısa Vadeli Tahminler: Üretim açısından en uygun parti hacmi, tedarik zamanı ve sipariş hacmi tahminine yöneliktir. Ayrıca makinelerdeki iş yüküyle birlikte insan gücü ihtiyaçlarının tespiti adına veri hazırlamaya da yöneliktir (Kobu, 2010: 112). Kısa ve mikro tahminler ise orta ve ilk düzey yöneticilerin kullandığı – ihtiyaç duyduğu tahmin sınıflandırmalarıdır (İlhan, 2015: 34).
- Orta Vadeli Tahminler: Uzun veya belirsiz tedarik sürecine sahip malzeme alımı, karmaşık üretim işlemlerine sahip mallara yönelik üretim ve mevsimsellik içeren malların stok planlamaları amacıyla kullanılmaktadır (Kobu, 2010: 112). Üç ay ile üç yıl arasında değişebilen bir zaman dilimi için, iş gücü büyüklüğünün planlanması, satış tahmini, bütçe ve nakit akışı gibi konularını ilgilendiren tahminlerdir (Demirbaş, 2011: 8).

- Uzun Vadeli Tahminler: İşletmenin yatırım planları için veri sağlamayı amaçlayan tahminlerdir (Kobu, 2010: 112). Uzun dönem tahminler ve makro tahminler üst düzey yönetimin kullandığı tüm organizasyonu etkileyen rakamsal büyüklüklerin olduğu tahminleme sınıflandırmalarıdır( İlhan, 2015: 34).

#### **1.4. Tahmin Maliyetleri**

İşletmedeki tahmin maliyetini belirleyen faktörler arasına işletmenin büyüklüğü, kullanılan tahmin yönteminin türü, tahminin belirlenen doğruluk oranı, tahmin örgütlenmenin niteliği ve tahminde kullanılan araçlar bulunur. Tahminin işletme içinde merkezleşmiş yada merkezleşmemiş bir biçimde ele alınması doğrudan işletme büyüklüğü ile ilişkilidir ve işletme büyüdükçe merkezleşmiş tahminde azalır (Öztürk, 2006: 13).

Tahmin uygulamalarına gerekli önemi vermeyen işletmeler, durumun geçmişte nasılsa gelecekte de aynı şekilde devam edeceğini varsaymaktadır. Fakat, yetersiz ve tutarsız tahminler işletmelerin; işgücü, malzeme ya da sermaye maliyetlerini yükseltmekte, gelirlerinin büyük kısmının kaybolmasına yol açmaktadır. Ayrıca, işletmelerde tahmin faaliyetleri arttıkça bilgi toplama ve inceleme maliyetleri de artabilecektir. Bundan dolayı firmalar tahmin çalışmalarına verecekleri önem ve bütçe dengesini gözetmek durumundadır. Şekil 1.1’de tahmin faaliyetlerinin maliyetinin dengelenmesinde ölçüt olabilecek bir grafik gösterilmiştir. Şekil ...’deki grafikte de görülebileceği gibi, işletmelerin toplam maliyetlerini en aza indirgeyebilmeleri adına tahmin faaliyetlerini belirli bir düzeyde tutmaları, dengeyi gözetmeleri gerekmektedir (Ballı, 2014: 29).



Şekil 1.1: Tahmin Maliyeti Dengesi

Kaynak: Tokpunar, 2014: 36.

### 1.5. Talep Araştırmasında Yapılacak İşlemler

Talep tahmin süreci tahminlerin etkin ve efektif olarak nasıl geliştirildiği ve bunların nasıl kullanıldığına yönelik faaliyetleri içermektedir. Sürecin çıktıları kadar sürecin etkileri, şeffaflığı ve anlaşılabilirliği de önemlidir. Talep tahmin süreci; satışların daha iyi yönetilmesine, finansal büyüme projeksiyonlarının hazırlanmasına, satış senaryolarının oluşturulmasına ve bu senaryoların üst yönetim ve ortaklara daha somut ve daha anlaşılır olarak sunulabilmesine yardımcı olmalıdır (Tokpunar, 2014: 39).

Talep tahminlerinin gerçekleştirilmesi sürecinde izlenilmesi gereken beş aşama bulunmaktadır (Ballı, 2014: 35; Yücesoy, 2011: 7):

- **Talep Tahminin Amacının Belirlenmesi:** Yapılması planlanan tahminlerin ne amaçla kullanılacağına, bu tahminlere ne zaman gerek duyulacağına tespit edilmesi ve bunun yanında talep tahmininin ne kadar ayrıntılı olması gerektiğinin belirlenmesi işlemidir. Tahmin amacı göz önünde bulundurularak, gereken iş gücü, süre, donanım ve diğer ihtiyaçlar tespit edilmeli; talep tahmininin hassaslık derecesi belirlenmelidir.

- **Talep Tahmin Döneminin Belirlenmesi:** Talep araştırması sonuçlarının kullanım amacıyla zaman periyodunun süresi arasında yakın bir ilişki bulunmaktadır. Örneğin, gündelik iş emirlerinin hazırlanması esnasında faydalanılacak tahminlerin aylık dönemler şeklinde yapılması yanıltıcı sonuçlar verebilecektir. Bunun sebebi, günlük değerlerde meydana gelebilecek değişimlerin aylık dönemlerde tamamen kaybolmasıdır.
- **Verilerin Toplanması:** Talep tahminlerinin yapılabilmesi adına bütün süreç içerisinde baz alınması planlanan verilerin toplanmasına ve derlenmesine ihtiyaç duyulmaktadır. Elde edilen veriler, kullanılması planlanan tahmin yöntemi konusunda da yol gösterici olmaktadır. Yapılacak tahminlerin geçerliliği ve doğruluğu, elde edilen verilerin güvenilirliğine ve doğruluğuna dayanmaktadır. Yetersiz veriye sahip olunması ya da ihtiyaç duyulandan daha ayrıntılı veriler araştırma maliyetini artırmakta ve tahmin sonuçlarına ulaşma süresini uzatmaktadır. Bu durum ise sonuçların duyarlılığını olumsuz anlamda etkilemektedir.
- **Tahmin Yönteminin Seçimi ve Talebin Tahmini:** En uygun talep tahmin yönteminin seçilmesi için, yapılacak olan tahminin amacı ve eldeki verilerin niteliği büyük önem taşımaktadır. Bunun yanında, eldeki verilerin belirsizlik, duyarlılık, değişim biçimi gibi özellikleri ve uygulama amacı kullanılacak yöntemin seçilmesinde göz önünde bulundurulması gereken diğer faktörlerdendir.
- **Sonuçların Başarısının İzlenmesi:** Son aşamada elde edilen tahmin sonuçlarının gerçek değerler ile karşılaştırılması gerekmektedir. Karşılaştırma sonucunda belirgin bir sapma söz konusuysa, tercih edilen yöntemin özellikleri, varsayımları ve verilerin doğruluğu tekrar ele alınmalıdır.

## **1.6. Tahminleme Teknikleri**

### **1.6.1. Nitel Yöntemler**

Nitel yöntemler; sübjektif yöntemler olarak bilinir. Geçmişe yönelik yeterli bilgi bulunmadığı koşullarda, bilimsel yöntemler yerine kişilerin görüş ve deneyimine dayalı olarak tahminlerde bulunularak karar mekanizmasının işletilmesidir. Bilimsel verilere dayandırılmadığından tahmin performansı düşüktür. Öte yandan işletme

tarafından kullanılan teknolojinin artık kullanılmaz hale geleceđi bir dönemin tahmini söz konusu olduđunda geçmiş verilerin bir yararı olamayacaktır. Böyle durumlarda teknolojik deđişim ve gelişim konularında bilgi ve deneyime sahip kişilerin görüşüne başvurulur. Ek olarak, makro çevrenin hızlı bir şekilde deđiştiiği veya çevresel etkiler anlamında karışıklıkların beklendiđi koşullarda kullanılabilir olması önemli avantajlarından biridir. Bunun yanında genellikle düşük maliyete sahip olmaları ve üstün istatistiksel bilgi ve yeteneđe ihtiyaç duyulmadan yapılabilmesi de avantajları arasında yer alır. Ancak, görüşüne başvuru alan kişilerin deneyimlerinin yetersizliđi ve gelecek ile ilgili beklentiler nedeniyle tahminin etkilenebilme olasılıđı dezavantajları arasında yer alır (Demirbaş, 2011: 10).

#### 1.6.1.1. Delphi Tekniđi

Delphi yöntemi opinion-polling (fikir-oylama) teknikleri kullanılarak seçilen konularda bir uzlaşma sağlamak amacıyla ve özellikle çok seçenekli fikirlere dayalı uzun dönemli tahminler için tasarlanmıştır. Delphi yöntemleri üçe ayrılmaktadır. Birincisi, “*Decision Delphi*” tekniđi tam katılımcılık (bottom-up) yaklaşımıdır. Bu yöntem kararlar almak/hazırlamak ve bu kararlar yoluyla sosyal gelişmeleri etkilemek amacıyla kullanılan bir araçtır. İkincisi, “*Klasik Delphi*” tekniđinde kurallar açıkça belirlenir, bu ön koşul sosyal sistemler için pek uygun deđildir. Üçüncü teknik ise “*Policy Delphi*” tekniđidir. Burada fikirler ön plana geçer, istatistikler ve gerçekler önemini kaybeder ve panelistler kendi görüşlerini Delphi tekniklerini kullanarak açıklarlar (Akgül, 2013: 99).

Yöntemin işleyiş biçimini şu şekilde özetlemek mümkündür (Bulut, 2006: 17).

- Koordinatör, grupta yer alan uzmanların her birine yazılı biçimde gelecekteki talep hakkında beklentilerini sorar,
- Gruptaki her bir uzman, gelecekteki talep tahmini ile ilgili beklentisini, savını destekler bilgilerle birlikte yazılı bir şekilde ayrıntılı olarak bildirir,
- Koordinatör, uzmanlardan gelen yazılı talep tahmini beklentilerini bir araya getirir. Ortaya çıkan talep tahmini beklentileriyle ilgili görüş ve bilgileri düzenler, özetler, ortalamalara, aralıklara, standart sapmalara ait hesaplanan değerlerini tahminlere ekler,
- Koordinatör, uzmanların yaptıkları ve kendisine sunmuş oldukları talep tahmini beklentileriyle ilgili görüşlerle birlikte, kendisinin düzenlediđi

görüşleri tekrar uzmanlara yazılı bir şekilde dağıtır. Uzmanlardan alınan geri dönüşleri ve yeni bilgileri de değerlendirerek ilk aşamada yaptıkları tahminlerini tekrar değerlendirmelerini ve uygulamanın en başındakine benzer bir talep tahmininde bulunmalarını talep eder. Böylelikle ikinci turu başlatır,

- İkinci turda ise, uzmanların tekrar değerlendirme sonucu yapmış oldukları tahminlerle ilgili yazılı bilgiler koordinatör tarafınca toplanır, düzenlenir ve özetlenir. Bu işlemler, uzmanlardan gelen cevaplarda ortak bir görüş elde edilene kadar sürdürülür.

Yönteminin avantajları ve dezavantajları (Demirbaş, 2011: 12):

- Bireylerin karşı karşıya gelmelerinden kaynaklanabilecek problemler en aza indirgenmektedir. Bu şekilde bireyler, diğerlerinin baskısına maruz kalmadan düşüncelerini özgürce ifade edebilmektedirler.
- Katılımcılar, ardışık anketler vasıtasıyla edinilen geri bildirimler neticesinde, farklı düşüncelerle ilgili bilgi sahibi olmaktadır. Böylece, kendi düşüncelerini gözden geçirme ve değerlendirebilme imkanına sahip olmaktadır.
- Başarının, uzmanların seçimlerine bağlı olması,
- Sonuçların geri bildiriminin zaman alması,
- Sürecin uzaması ile birlikte katılımın azalmasıdır.

#### 1.6.1.2. Yönetici Görüşleri

Bu metot, bir veya daha çok yöneticinin veya müşterinin görüşlerinin, tecrübelerinin ve bilgilerinin bir tahmine ulaşmak için özetlendiği bir metottur. Daha sonra tartışılacağı üzere, yeni satış promosyonları veya beklenmeyen uluslararası olaylar gibi olağan dışı durumları göz önünde bulundurarak yönetici görüşü, mevcut satış tahminini düzeltmek için kullanılabilir. Yönetici görüşü ayrıca teknolojik tahmin yapmak için kullanılabilir. Teknolojik değişimin hızlı adımları, son gelişmeleri yakından takip etmeyi zorunlu kılar (Bal, 2015: 23).

Bu yöntemin avantajı hızlı ve kolay tahmin yapılmasının yanı sıra istatistiksel gereksinim olmamasıdır. Ancak belirlenen tahmin değerleri tek bir kişiye değil bir gruba ait olacağı için sorumluluk da grup üyelerine yayılacaktır. Bu durum ise daha

iyi tahmin deęerleri belirlenmesinde bireysel sorumluluęu azaltmaktadır ki bu yöntemin en ön önemli dezavantajıdır (Aydın, 2017: 9).

#### 1.6.1.3. Uzman Grup Görüşü

Alanında uzman kişilerin birikmiş tecrübeleri ve benzeşen olay yönetimindeki içgüdüsel avantajlarını deęerlendirmeye alarak, uzman şahıslardan oluşan jüri grubunun görüşleriyle deęerlendirilebilir. İşletmede karar yetkisine sahip yöneticilerin, uzmanların, tecrübeli kişilerin düşünceleri ve kişisel deęerlendirmeleri birleştirilerek işletme satış tahmini elde edilir (Aıkeshan, 2014: 10).

Yöntemin en önemli zayıflıklarından biri toplam tahmini yansıtmamasıdır (Çaęlar, 2007: 20).

Yöntemin Üstünlükleri;

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

#### 1.6.1.4. Satış Gücü Karması Teknięi

Satış çalışanlarının tüketicilerle en yakın ilişki kuran bireyler olduęunun varsayılması sebebiyle, tüketicilerin gelecekteki davranışları ile ilgili bilgi edinilememesi durumunda en sağlıklı verinin satış personelinden alınabileceęi düşüncesine dayandırılmaktadır (Çaęlar, 2007: 21).

Tüketiciler ile yüz yüze görüşmenin olanaklı olmadığı, satış personelinin işbirlięi yapmaya yatkın oldukları, satış biriminin önyargılarının bulunmadığı, tahmin uygulamasının satıcı ve satış personelinden yana yararlar sağladığı durumlarda uygulanabilmektedir (Bulut, 2006: 15).

#### 1.6.1.5. Uzman Panel

Bu tahmin yöntemi, oluşturulan bir panel yardımıyla üyelerin çoğunluęunun onayladığı bir sonuç elde etmeyi amaçlamaktadır. Bu yöntemin Delphi yönteminden farkı, panel üyelerinin toplanarak konu ile ilgili fikir ve görüşlerini açıklama, fikir ve görüş alış verişinde bulunma olanağını bulmalarıdır. Bu yüzden bu yöntemin en



önemli özelliđi, grup üyelerinin etkileşimine dayanmasıdır. Çalışmalar seminer ve komite toplantıları aracılığıyla uygulamaya konulur ve mümkün olduđu kadar çok fikir ve görüş alış verişine yer verilmektedir. Çalışma süreci, panel üyelerinin ortak bir noktada buluşmaları ve karar vermeleri ile sonlanır (Çağlar, 2007: 23-24).

#### 1.6.1.6 Senaryo Analizi

Bu yöntemde işletme gelecekte istenilen sonuçlara ulaşabilme aşamasında karşılaşılabilecek muhtemel durumları, çeşitli nicel ve nitel tahmin teknikleri ile kurgulamakta ve bunlara uyumlu davranışlar dizisi oluşturmaya çalışmaktadır. Senaryo geliştirmek, yaratıcılık isteyen bir faaliyet olup, asıl amaç sonuca ulaşma yolunda "birden fazla" sayıda muhtemel durum geliştirmek ve bunlara uyumlu davranışları belirleyebilmektir (Ülgen ve Mirze, 2013: 112).

#### 1.6.1.7. Uzman Sistemler

Uzman sistemler, belirli bir alana ait bilgilere sahip ve karşılaşılabilecek problemleri sahip olduđu bilgi birikimi ile çözüm sunabilecek kişiler gibi çözümler getiren bilgisayar programlarıdır. Söz konusu sistemler birçok bilgi içerdiğinden dolayı bu yöntemde uzman sistemler adı verilmiştir. Oldukça güncel bir yaklaşım olan uzman sistemlerde başarılı analizlerin yapılması büyük ölçüde güvenilir bilgi ve kuralların açıkça belirlenmesine bağlıdır. Uzman sistemler hastalık teşhisi, endüstriyel robotların tasarımında, süreç planlamalarında, ekonomik analizlerde, askeri ve uzay çalışmalarında sıklıkla kullanılmaktadır (Tutu, 2017: 55).

#### 1.6.2. Nicel Yöntemler

Nicel yöntemler; geçmiş verileri kullanarak gelecekteki verilerin tahmininin matematiksel olarak yapılmasıdır. Geçmişe yönelik yeterli bilgi bulunuyor ve elde edilen bilgiler matematiksel olarak ölçülebiliyor ise kullanılır. Nicel tahmin yöntemlerinin bir kısmı basit olmasına karşın diğer bölümü karmaşık işlemler içermektedir. Uygulamada bazı yöntemlerin diğer yöntemlere bakıldığında daha uygun sonuçlara olanak sağladığı görülürse de, tahmin yöntemleri hakkında bir genelleme yapılarak en iyi yöntem şudur demek doğru değildir. Farklı tahmin yöntemlerinin farklı tahmin yapıları ile birlikte uygulanması ve incelenmesi gerekir (Demirbaş, 2011: 13).

### 1.6.2.1. Son Dönem Talebi Yöntemi

Mekanik modeller, en basit tahmin yöntemleri olarak değerlendirilmektedir. Bir tahminde bulunmanın yanı sıra yapılmış olan tahminin bir üstünlüğe sahip olup olmadığı belirlenmesinde kullanılmaktadır. Bir zaman serisi değişkeninin son dönemde aldığı değer bir sonraki dönem tahmini olarak kullanılmaktadır. Eğer tahmini yapılması planlanan serinin kesin trendi gözleniyorsa, tahmin trendin yönüne göre yapılmaktadır (Çağlar, 2007: 39).

Trendin gözlenmediği durum:  $F_{t+1} = Y_t$

Trendin gözlendiği durum:  $F = Y_t + (Y_t - Y_{t-1})$

t = dönem

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

$Y_t$  = t dönemindeki gerçekleşen talep değeri

### 1.6.2.2. Ortalamalar Yöntemi

*Basit ortalama yöntemi* geleceğin, geçmişte olanların ortalamasına doğru eğilim göstereceğini varsaymak, talep tahmini açısından en basit yöntemlerden biridir. Bu yöntemde son n dönemde gerçekleşmiş değerler toplanarak ortalaması alınır ve bulunan sonuç tahmini değer kabul edilir. Bu yöntem, gerçekleşen talep değerlerinin trend, konjonktürel ve mevsimsel değişimlerin ve dalgalanmaların etkisinde olmadığı koşullarda; ulaşılabilen az miktarda veriler için başarılı sonuçlar vermektedir. Veri miktarı arttıkça belirli bir trendi yakalayamamaktadır (Demirbaş, 2011: 15-16).

$$F_{t+1} = \frac{1}{t} \sum_{t=1}^t Y_t \quad (1.1)$$

t = dönem

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

$Y_t$  = t dönemindeki gerçekleşen talep değeri

*Ağırlıklı ortalama yöntemi* üstünlüğü yakın dönemin talebine daha fazla önem verilmesine imkan sağlamasıdır. (Aynı mevsimde önceki yıllarda daha yüksek ağırlıklar verilerek mevsimsel etkiler de ele alınabilir.) Tahmin asıl talep serisinin

ortalamasındaki deęişikliklere, basit ortalama yöntemi tahminine göre daha duyarlı olacaktır (Bal, 2015: 31).

$$F_{t+1} = \alpha Y_t + (1-\alpha)Y_{t-1} \quad (1.2)$$

t = dönem

$F_{t+1}$  = t+1 dönemi için tahmin deęeri

$Y_t$  = t dönemindeki gerçekleşen talep deęeri

$\alpha$  = *Ağırlık deęeri (0 ile 1 arasında olmalı)*

### 1.6.2.3. Üstel Düzeltme Yöntemi

Üstel düzeltme yöntemi, ağırlıklı ortalama sistematiğini dikkate alan bir tahmin yöntemidir. Geçmiş dönem verilerine eşit ağırlıklar verilen basit hareketli ortalamalar tekniğine benzemekle birlikte; geçmiş dönem verilerine eşit olmayan, farklı ağırlıkların verildiği yöntemler topluluğudur. Üstel terimi, verilen ağırlıkların veriler eskidikçe üstel bir şekilde azalması anlamına gelmektedir. Bir dięer ifadeyle, tahmin esnasında kullanılan geçmiş dönem verilerinden yakın geçmişte olanlara yüksek üstel deęerler, daha eski dönemdekilere ise düşük üstel deęerler verilmesi şeklinde uygulanmaktadır (Ballı, 2014: 47).

Serilerdeki rassal dalgalanmaları ve/veya mevsimsellięi ortadan kaldırmak veya azaltmak amacıyla geliştirilen düzeltme yöntemlerinden birisi de üstel düzeltmedir. Geçmiş deęerlere göre düzeltilmiş deęerler belirlenmekte, bu deęerlere göre tahmin hesaplanmaktadır. Bu yöntemde en son gözlem deęerinin ağırlığı öncekilere göre daha fazladır. En son gözlemlerden hareketle tahminler sürekli olarak revize edilmektedir (Erkan, 2008: 31).

Üstel düzeltme tekniğinde düzeltme katsayılarının belirlenmesi büyük öneme sahiptir. Katsayıların belirlenmesinde asıl amaç; uygulanan modelin hata kareleri ortalamalarını en küçük yapan düzeltme katsayısı deęerlerini saptamaktır. Üstel düzeltme teknięi, verilerin özelliklerine uygun olarak farklı yöntemlerden oluşabilmektedir. Bu yöntemler arasında;

- 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 sayılabilir.

Trend ve mevsimsel dalgalanmalar gösteren verilerin tahmininde ise Winters Mevsimsel Üstel Düzleştirme Yöntemi kullanılmaktadır (Çuhadar vd., 2009: 104).

#### 1.6.2.4. Box-Jenkins Yöntemi

Bu model tek değişkenli bir model olup George Box ve Gwilym Jenkins tarafından 1970'li yıllarda geliştirilmiştir. Tek değişkenli zaman serilerinde tahmin adına elverişli modelin seçilmesinde sıklıkla kullanıldığı görülmektedir. Yöntem kısa dönem tahminlerde başarılıdır ve uygulanan serinin eşit zaman dilimlerinde edinilen gözlem değerlerinden oluşan kesikli ve durağan bir seri olması, bu yöntemin önemli bir varsayımını oluşturmaktadır (İlhan, 2015: 65).

Box-Jenkins modellerinde ana yaklaşım, incelenen değişkenlerin günümüzdeki değerinin, geçmiş dönemlerdeki verilere göre ağırlıklı toplamı ve tesadüfi şokların bileşimine dayanmasıdır. Model seçimi esnasında, serinin durağanlığı ve mevsimsel etkiler belirleyici olmaktadır. Bu yüzden ilk önce zaman serisinin özellikleri belirlenmekte ve uygun bir model aranmaktadır. Box-Jenkins yöntemi, tüm model kombinasyonları arasından uygun bir modeli belirleyebilmek adına 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: 105-106).

#### 1.6.2.5. AR Yöntemi

Otoregresif modellerde bağımsız değişken olarak geçmiş dönem değerleri kullanılır. p. dereceden otoregresif model eşitlik 1.3'de verilmiştir (Karaca, 2015: 41).

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t \quad (1.3)$$

$Y_t = t$  periyodu için talep (bağımlı değişken)

$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$  = Geçmiş dönemler için talep (bağımsız değişken)

$\varphi_0, \varphi_1, \varphi_2, \dots, \varphi_p$  = Kestirilecek katsayılar

$\varepsilon_t = t$  periyodu için hata terimi

### 1.6.2.6. Hareketli Ortalamalar Yöntemi

Bir değişkenin t dönemindeki değeri aynı dönem içerisindeki hata terimi (et) ve bu hata teriminin geçmiş dönemlerdeki gecikmeli değerleri aracılığıyla belirleniyorsa bu sürece hareketli ortalama süreci adı verilmektedir. Buradaki hareketli ortalama teriminin kullanılma nedeni, zaman ilerledikçe sadece değişkenin kendisi değil hataların da zamana bağlı olarak değişmesini ifade etmesidir. Hareketli ortalama modelleri, içerisinde yer alan geçmiş dönem hata terimi sayısına göre birinci, ikinci ve genel olarak q'inci dereceden MA modelleri olarak isimlendirilirler (Akgül, 2013: 112).

Hareketli ortalamalar yönteminde; 3, 4, 6 ve 12 aylık satış ortalamaları ele alınarak değerlendirme yapılmaktadır. Bu yöntem, her denemede en eski değeri çıkarıp yeni değeri ekleme şeklinde belirli sayıda döneme ait değerlerin tekrarlı bir şekilde ortalamasının bulunması şeklinde uygulanmaktadır. Hareketli ortalamalar genel veri düzenini korumakta ve verilerdeki dalgalanmaları düzeltmeye yardımcı olabilmektedir. Fakat, veri serilerinin son dönemlerine ait tahmini değerle ulaşılmasını sağlamaz ve bir tahmin denklemi oluşturamazlar (Ballı, 2014: 46).

$$T_t = HO_n = \frac{\sum_{i=1}^n G_{t-i}}{n} \quad (1.4)$$

$T_t = t$ . Döneme ait talep tahmini

HO = Hareketli ortalama

$G_{t-i} = t-i$ . Dönemin gerçekleşen talebi

n = Hareketli ortalama için kullanılacak dönem sayısı (Top ve Yılmaz, 2009: 248).

### 1.6.2.7. ARMA Yöntemi

Çoğu zaman serisi sadece hareketli ortalamayla ya da oto regresyonla modellenemeyebilir. Bu seriler her iki modelin özelliklerini de içerir ve bundan dolayı standart modelle açıklanamaz. Bununla birlikte, karma model (autoregressive movingaverage) olarak adlandırılan ve ARMA'ya (p, q) kısaltılmış olan bu özellikleri veren bir model vardır; Burada (p) regresyon sırası (q) hareketli ortalama sırasını gösterirken (p, q) sıralamayı temsil eder (Omarbl, 2017: 23).

Otoregresif ve hareketli ortalamanın beraber ele alındığı modeller ARMA modelleri olarak adlandırılır. ARMA (p,q) şu şekilde ifade edilir: (Karaca, 2015: 42).

$$Y_t = \varphi_0 + \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + \varepsilon_t - \omega_1 \varepsilon_{t-1} - \omega_2 \varepsilon_{t-2} - \dots - \omega_q \varepsilon_{t-q} \quad (1.5)$$

$Y_t$  = t. periyot için talep (bağımlı değişken)

$\varphi_0, \varphi_1, \varphi_2, \dots, \varphi_p$  = Kestirilecek katsayılar

$\omega_1, \omega_2, \dots, \omega_q$  = Kestirilecek katsayılar

$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$  = Geçmiş dönemler için talep (bağımsız değişken)

$\varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-q}$  = Geçmiş dönemlere ilişkin hata terimleri (bağımsız değişken)

#### 1.6.2.8. ARİMA Yöntemi

Literatürde Box-Jenkins metodolojisi olarak yer alan metod, temelinde durağan olan ya da durağanlığı sağlanmış olan bir zaman serisine ilişkin birçok olası model arasında uygun ARIMA modelinin belirlenmesi, parametrelerin bulunması ve modelin uygunluğunun değerlendirilmesi olmak üzere üç aşamadan oluşur. Bulunan model uygunluk testlerini geçemezse, süreç baştan başlatılarak uygunluk kriterlerinden en iyi dereceyi alan model nihai model olarak seçilir ve tahminde bu model kullanılır (Olgun, 2009: 24).

Zaman serileri kesikli, doğrusal ve stokastik bir sürece sahipse Box-Jenkins ya da ARIMA modeli olarak isimlendirilir. Bu modeller, doğrusal filtreleme modelleri şeklinde de adlandırılmaktadır. Otoregresif (AR-Auto-Regressive), hareketli ortalama (MA-Moving Average), AR ve MA modellerinin karışımı olan Otoregresif Hareketli Ortalama (ARMA-Auto Regressive Moving Average) modelleri en genel doğrusal durağan Box-Jenkins modelleridir. Durağan olmadığı halde fark alma işlemi ile durağanlaştırılan serilere uygulanan modellere Birleştirilmiş Otoregresif Hareketli Ortalama (ARIMA-Auto Regressive Integrated Moving Average) modeli denilmektedir. ARIMA modeli Box-Jenkins tekniği olarak da bilinmektedir. Box-Jenkins modellerinde temel amaç; zaman serisine en uygun olan, en az parametreye sahip doğrusal modelin tespit edilmesidir (Ataseven, 2013: 6).

Otoregresif entegre hareketli ortalama (ARIMA) modeli, bir otoregresif hareketli ortalama (ARMA) modelinin genelleştirilmesidir. Bu modellerin her ikisi de ya veriyi daha iyi anlamak için ya da dizideki gelecekteki noktaları öngörmek için (tahmin) veri dizisi verisine uyarlanmıştır. ARIMA modelleri, durağan olmayan durumun kanıtlarını gösteren bazı durumlarda uygulanır; burada ilk farklılaşma aşaması (entegre) durağanlaşmayı ortadan kaldırmak için bir veya daha fazla kez uygulanabilir (Omarbl, 2017: 23).

#### 1.6.2.9. Regresyon Analizi Yöntemi

Regresyon analizi yöntemi, bağımlı bir değişkenin bir ya da daha fazla bağımsız ya da açıklayıcı değişken ile arasındaki ilişkinin matematiksel bir fonksiyon biçiminde ifadesidir. Bu fonksiyona regresyon denklemi denilmektedir. Regresyon denklemi yardımı ile, bağımlı değişken ve bağımsız değişkenler arasındaki ilişkiyi oluşturan parametrelerin değerleri tahmin edilmektedir. Bağımlı değişken üzerinde etkisi bulunan bağımsız değişkenlerin tahmin edilebilmesi, bu değişken üzerinde geliştirilebilecek plan ve politikalarda hangi etmenlerin önemli olduğunun tespitinde kullanılmaktadır (Çağlar, 2007: 25).

Yeterli seviyede açıklayıcı güce sahip olan güvenilir bir regresyon katsayısıyla güvenilir tahminler yapılabilmektedir. Regresyon analizinde, eşitlik (formül) dönemselsel olarak değişiklik gösteren geçmiş veriler yardımıyla geliştirilebilir. Tahminde bağımsız değişkenlerin değerleri büyük oranda sıra dışı değerler ise, tahmin hatasının da fazla olması beklenmektedir. Geçmiş verilerin düzenli ve sürekli şekilde oluştuğu durumlarda ise tahminin tutarlılığı da o düzeyde yüksek olacaktır (Karahana, 2011: 44).

Basit doğrusal regresyonda iki değişkenin birbiriyle olan ilişkisinin doğrusal olduğu varsayımına göre tahmin denklemi  $Y=a+bx$  olarak oluşturulur.

#### 1.6.2.10. Yapay Sinir Ağları Yöntemiyle Talep Tahmini

Yapay sinir ağları kavramı, insan beyninin çalışma prensiplerinin bilgisayar ortamında taklit edilme fikriyle ortaya çıkmış ve ilk çalışmalar beynimizi oluşturan hücrelerin, literatürdeki adıyla nöronların matematiksel şekilde modellenmesi üzerine yoğunlaşmıştır (Efe ve Kaynak, 2000: 1). Bu çalışmalar, araştırmanın 2. bölümünde detaylı olarak incelenecektir.

## 1.5. Tahmin Yöntemlerinin Karşılaştırılması

Unutulmaması gereken diğer bir nokta da yöntem belirlemenin dinamik bir süreç olduğudur. Dinamik bir pazarda rekabet yapısı ve tüketici davranışları hızla değişebilmektedir. Dolayısıyla çeşitli dönemlerde seçilen yöntemle birlikte alternatif yöntemler de değerlendirilmelidir. Tahmin yöntemleri karşılaştırılırken yöntemi kullanmanın toplam maliyeti de dikkate alınmalıdır. Toplam maliyet, tahmindeki sapmanın oluşturduğu maliyetle ilgili yöntemi kullanmanın maliyetinden oluşur

Tahmin yöntemlerinin karşılaştırılmasında en temel seviye kalitatif yöntemlerle kantitatif yöntemlerin karşılaştırılmasıdır. Kantitatif yöntemler geçmiş satış verilerini baz alan zaman serisi yöntemleriyle tahmin üzerinde etkisi olabilecek diğer değişkenleri de analize dahil eden nedensel modellerden oluşmaktadır. Bu iki yöntem karşılaştırılırken kullanılan metod tahmin doğruluklarının karşılaştırılmasıdır. Bu alandaki ilk çalışma 1975 yılına Mabert tarafından yapılmıştır. Bu çalışmada Mabert satış ekibiyle üst yönetimin görüşlerinden oluşan firma tahminiyle üssel düzeltme, basit ortalama ve Box-Jenkins yöntemlerini karşılaştırmış; kantitatif yöntemlerin kalitatif yöntemlere göre daha doğru bir sonuç verdiğini bulmuştur. Ayrıca zaman ve maliyet açısından kantitatif yöntemlerin çok daha etkin olduğunu ifade etmiştir (Makridakis ve Wheelright, 1977: 32).

Kalitatif yöntemleri kantitatif yöntemlerle karşılaştırdığımızda avantaj/dezavantaj ve kullanıldığı yerler şöyle özetlenebilir (Erkan, 2008: 74-75; Akgül, 2010: 60-61):

- Kalitatif yöntemlerde tahmini yapan kişilerin matematiksel bir özgeçmişe sahip olması gerekli değildir.
- Bu yöntemler kullanıcılar tarafından oldukça kabul görmektedir. Örneğin Dalrymple'in 1987 yılında yaptığı çalışmada; %82 oranında satış gücü ve üst yönetim görüşlerinin kullanıldığı, %12 oranında çoklu regresyon veya ekonometrik modellerin kullanıldığı belirlenmiştir.
- Mevcut trendlerdeki değişime bağlı olarak tahmin yapılır. Dolayısıyla dinamik talep yapısında bir yöntem başvurulur.
- Konusunda uzman kişilerin görüşlerinin tam olarak dikkate alınır.
- Çok az veya hiç geçmiş veri olmadan tahmin yapılabilir.



- Zaman içerisinde doğruluk oranı deęişkenlik gösterebilmektedir. Çünkü tahmin doğruluęunu nasıl arttırabiliriz sorusuna cevap vermek zordur. Oldukça zaman alıcı ve kantitatif yöntemlere göre pahalıya mal olmaktadır.
- Uzun dönemli tahminlerde, firma düzeyinde tahminlerde ve yeni ürünlerde yaygın olarak kullanılmaktadır.
- Kantitatif yöntemlerle birlikte kullanıldığında daha doğru sonuçlar elde edilmektedir. Fakat iki yöntemi birlikte kullanmak tecrübe gerektirmektedir. Bu durumda öncelikle kantitatif yöntemin temel fikrinin ve varsayımlarının bilinmesi gerekir.

### **1.5. Tahmin Hatasının Ölçümü**

Tahminin doğruluęu, belirlenen talep tahmini deęeri için çok büyük önem teşkil etmektedir. Gerçek hayatta çok fazla deęişkenin yer alması, tam bir tahmin deęerinin hesaplanmasını mümkün kılmamaktadır. Bu nedenle tahmin hatasını minimum seviyede tutmak asıl amaçlardan birisi haline gelmiştir. Talep tahmini için hangi yöntemin kullanılacağı ya da hangi teknik tercih edilmeli noktasında dikkat edilmesi gereken faktörlerden birisi maliyet dięeri ise kullanılması planlanan tekniğin hata oranı olmalıdır (Top ve Yılmaz, 2009: 248).

Geçmiş verilere dayanarak yapılan tahminlerde verileri rassallıktan arındırmak tahminin doğruluęu için gerekli görülmektedir (Çelikçapa, 2015: 14).

Tahminler her zaman hatalar içerir. Tahmin hataları, yanlışlı hataları ve rastgele hatalar olarak sınıflandırılabilir. Yanlışlı hataları tutarlı hataların sonucudur, tahmin her zaman çok yüksek ya da çok düşüktür. Dięer hata türü olan rastgele hata, tahminin gerçekleşen satıştan sapmasına neden olan ve öngörülemeyen faktörlerin sonucudur. Tahmin analistleri, uygun tahmin modellerinin seçimi ile yanlışlı ve rastgele hatalarının etkilerini minimize etmeye çalışırlar; fakat her türlü hatayı ortadan kaldırmak imkansızdır (Bal, 2015: 42).

### 1.5.1. Ortalama Mutlak Sapma (MAD)

$$OMS = \frac{\sum |G_t - T_t|}{n} \quad (1.6)$$

$G_t$  = t. Dönemin gerçekleşen talep miktarı

$T_t$  = t. Döneme ait talep tahmini miktarı

$n$  = Kullanılacak dönemlerin sayısı (Top ve Yılmaz, 2009: 248).

### 1.5.2. Ortalama Hata

Hata toplamlarının gözlem değerlerine bölünmesiyle elde edilmektedir (Kale, 2018: 268).

$$ME = \frac{1}{n} \sum_{t=1}^n e_t \quad (1.7)$$

### 1.5.3. Ortalama Mutlak Hata (MAE)

Tahmin yöntemlerinin en çok tercih edilen hata ölçülerinden birisi, ortalama mutlak hatadır ve bu denklem kullanılarak o zamana kadar geçen süredeki tahmin hatası hesaplanmaktadır. Fakat, başarılı bir tahminde bulunmak ve tahmin hatasını sıfıra yaklaştırabilmek adına mutlak değer yerine, hata kareleri ortalaması hesaplanarak daha hassas ölçümler yapabilmek mümkün hale gelmektedir (Karahan, 2011: 93).

$$MAE = \frac{1}{n} \sum_{t=1}^n |Gerçekleşen Talep - Tahminlenen Talep| \quad (1.8)$$

### 1.5.4. Ortalama Mutlak Yüzde Hata (MAPE)

$$MAPE = \frac{\sum \frac{|G_t - T_t|}{G_t} * 100}{n} \quad (1.9)$$

$G_t$  = t. Dönemin gerçekleşen talep miktarı

$T_t$  = t. Döneme ait talep tahmini miktarı

$n$  = Kullanılacak dönemlerin sayısı (Top ve Yılmaz, 2009: 248).

### 1.5.5. Ortalama Hata Kare (MSE)

Tahmin hatalarının karelerinin ortalamasını hesaplayan bu yöntem, en iyi tahmin yöntemini belirlemede yaygın olarak kullanılmaktadır. Hataların büyük olduğu tahminlerde değerlerin karelerinin alınması hatayı da arttıracığından olumlu sonuç vermeyebilir. Bu nedenle düşük hataların gözlemlendiği durumlarda kullanılabilir (Erkan, 2008: 88).

$$MSE = \frac{\sum(G_t - T_t)^2}{n} \quad (1.10)$$

$G_t$  = t. Dönemin gerçekleşen talep miktarı

$T_t$  = t. Döneme ait talep tahmini miktarı

$n$  = Kullanılacak dönemlerin sayısı (Top ve Yılmaz, 2009: 248).

### 1.5.6. Ortalama Hata Karesinin Kökü (RMSE)

Tahmin edilen değerler ile gerçek değerler arasındaki hata karelerinin kökü alınarak hesaplanan bu yöntemle elde edilen sonuç sifıra ne kadar yakın ise yapılan tahminlerde o ölçüde duyarlıdır (Saatçioğlu ve Özçakar, 2016: 22).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (1.11)$$

### 1.5.7. Simetrik ortalama mutlak yüzde hata (sMAPE)

Ortalama Mutlak Yüzde Hata (MAPE) ve benzeri zaman serileri, ilgili doğruluk ölçütleri çoğunlukla talep değeri sıfır olan aralıklı talep tahminlerinde kullanılamamaktadır. Bu durumda Simetrik Ortalama Mutlak Yüzde Hata (sMAPE) hesaplanır (Syntetos ve Boylan, 2005: 307).

sMAPE ölçütü kullanımının 2 nedeni vardır. İlki talep değerinin sifıra yaklaşması ve tahmin ile talep karşılaştırıldığında talebin büyük olmasına rağmen yüzdesel hatanın büyümeyecek olmasıdır. Diğeri ise hatanın simetrisidir. Talep değeri ile tahmin değeri arasında fark olması değildir, hata yine aynı kalacaktır (Wallström ve Segerstedt, 2010: 628).

$$sMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|G_t - F_t|}{\frac{(G_t + F_t)}{2}} * 100 \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (1.12)$$

$G_t$ : t. Dönemdeki gerçekleşen talep miktarı.

$F_t$ : t. dönem için tahmin edilen talep miktarı.

#### 1.5.8. Ortalama mutlak ölçekli hata (MASE)

Hyndman ve Koehler (2006), aralıklı talebe sahip olan ürünlerin talep tahmini esnasında tahmin doğruluğunun ölçülebilmesi adına Ortalama Mutlak Ölçekli Hata (MASE) olarak adlandırılan yeni bir ölçüt önerisinde bulunmuşlardır. Farklı ölçeklere sahip olan, sifıra yakın veya negatif verilerin yer aldığı durumlarda MASE'nin tahmin doğruluğunun ölçülmesinde en iyi sonuçlara olanak veren ölçüt olduğunu düşünmektedirler. Bu hata ölçütü, zaman serileri ile ilişkili diğer ölçütlerde hesaplama kaynaklı ortaya çıkan sıfır ve sonsuz hata olasılığını en aza indirmektedir (Saatçioğlu ve Özçakar, 2016: 23).

$$MASE = Ortalama(|q_t|) \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (1.13)$$

$$q_t = \frac{e_t}{\frac{1}{n-1} \sum_{i=2}^n |G_i - G_{i-1}|} \quad (1.14)$$

## 2. YAPAY SİNİR AĞLARI

### 2.1. Yapay Sinir Ağı Kavramı

Yapay sinir ağları, parametrik olmayan ve esnek modelleme araçlarıdır (Tang & Chi, 2005:248). Temel olarak, insan beyninin bilişsel öğrenme sürecinin sanal ortamda taklit edilmesi çabalarıyla ortaya çıkarılmış bir yöntem olarak bilinmektedir ve karmaşık problemlerin çözümünde etkili sonuçlar verdiği görülmüştür. Tahminleme, sınıflandırma, kümeleme gibi çok sayıda probleme çözüm üretmektedir. Sinir ağlarının en fazla ön plana çıkan özelliği karmaşık sistemlerin geçmiş verilerinden fikir edinilerek örnek üzerinde öğrenme tekniği yardımıyla probleme çözüm üretmesidir (Efendigil vd., 2009: 6699; Kuan ve White, 1994: 3).

Yapay sinir ağları, insan beyninin temel seviyelerinin nöronlara benzer hale getirilmesidir ve birbiriyle ilişkilidir. Bir bilgisayarın nasıl bir seçenek oluşturması gerektiğidir. Programda adım adım bir ya da daha fazla yapan iç kurallarını kendisi üretir ve bu kuralları, sonuçları örneklerle karşılaştırarak düzenler (Civalek ve Ülker, 2004:2).

Yapay Sinir Ağları, teknik detaya girilmeksizin en basit ve kısa biçimde, bir örnekler kümesi yardımı ile parametrelerin uyarlanabilmesini sağlayabilecek matematiksel bir formül için yazılan bilgisayar programı şeklinde tanımlanabilir (Anderson ve McNeill, 1992: 4).

Bir sinir ağı, biyolojik beynin paralel hesaplama yeteneğini taklit etmeye çalışan işlem öğelerinin yüksek oranda bağlı bir yapısı olarak düşünülebilir. Biyolojik beyin geleneksel doğrusal bir bilgisayar kadar hızlı hesaplama yapamayabilir. Bununla birlikte, bazı durumlarda biyolojik beynin paralel işlem kabiliyeti verileri anında oluşturabilir, işleyebilir ve genelleştirebilir, buna karşın geleneksel bir bilgisayar çok fazla zaman alacaktır ve çoğu durumda sorunu anlayamayacaktır. Beyni taklit

etmeye çalışarak, yapay sinir ağıları geleneksel bilgisayarların dezavantajlarının üstesinden gelmeye çalışır (Detienne vd., 2003: 2).

Yapay sinir ağıları, paralel şekilde bağlantılı basit elemanlardan oluşmaktadır. Bu elemanlar biyolojik sinir sistemine benzer bir yapıya sahiptir. Ağın temel fonksiyonunu bahsedilen elemanlar arasında oluşan büyük çaplı bağlantılar oluşturmaktadır. Elemanların birbirleri ile bağlandıkları ağırlık değerlerinin ayarlanarak belirli bir fonksiyonun gerçekleştirilebilmesi adına ağın eğitimi sağlanmaktadır. Bu şekilde belirli bir girdiye karşılık ağ bir çıktı üretmektedir (Karaatlı vd., 2012: 91).

Sinir ağıları potansiyel olarak çok sayıda temel işlem biriminden oluşur; Her birim diğer birimlerle birbirine bağlıdır ve her biri nispeten basit hesaplamalar gerçekleştirebilmektedir. Ağın işlem sonucu, tek bir birimin özel davranışından ziyade kolektif davranışlarından kaynaklanır (Altman, 1993: 9).

Yapay sinir ağıları nörobiyolojik sistemlerden ilham alır. En eski nöro-bilgisayarlardan birinin mucidi olan Robert Hecht-Nielsen, nöral bir ağı, dış girdilere dinamik durum tepkileriyle bilgileri işleyen bir dizi basit, birbiriyle bağlantılı işleme elemanından oluşan bir hesaplama sistemi olarak tanımlar ( Coats ve Fant, 1993: 3).

Yapay sinir ağıları nöron olarak adlandırılan işlem birimlerinden oluşmaktadırlar. Nöronlar ise genel itibariyle katman adı verilen mantıksal gruplar içerisinde yer alır. Ağ, 3 ya da daha fazla katmana sahip hiyerarşik bir yapıdadır. Bu ağ içerisinde; 1 girdi, 1 ya da daha çok gizli ve 1 çıktı katmanları bulunmaktadır. Girdi katmanında, ağa girdi desenlerini sağlayan girdi kümesi bulunmaktadır. Girdi katmanı ile sinyalin sağlandığı çıktı katmanı arasında en az 1 gizli ara katman yer almaktadır (Kutlu ve Badur, 2009: 4-5).

Yapay sinir ağlarının temel yapısı ve sinir hücrelerinin miktarı değişkenlik gösterse de, yapay sinir ağlarının oluşumu açısından kabul gören bir genel kural bulunmamaktadır. Gereken gizli katman miktarından daha az sayıda gizli katman içeren yapay sinir ağıları karmaşık fonksiyonların çözülmesinde yetersiz kalmakta iken, fazla sayıda gizli katman içeren yapay sinir ağıları ise istenilmeyen kararsızlıklar ile karşı karşıya kalınmasına neden olabilmektedir. Gizli katman miktarının belirlenmesinin ardından karşılaşılan bir diğer temel problemse her tabakada ne kadar nöronun bulunacağına karar verilmesi problemidir. Girdi katmanı

açısından herhangi bir sorun yoktur çünkü belirlenen girdi sayısı miktarı sistem içerisinde yer alan girdilerin sayısı ile aynıdır. Benzer şekilde, çıktı katmanında da istenen çıktı miktarıyla belirlenmektedir. Asıl problem, gizli katmanlar içerisinde yer alan nöron sayısını belirleyebilmektir. Geleneksel matris algoritmasında, matris boyutlarının girdi veya çıktı sayısına denk olması gerektiği söylenmektedir. Fakat, gizli katman içerisinde en verimli haliyle ne kadar nöronun yer alacağı noktasında uygulanabilir bir matematiksel test bulunmamaktadır. Nöron sayısına, deneme yanılma yöntemiyle karar verilebilir (Ataseven, 2013: 3).

Yapay sinir ağlarının özellikleri (Aktaş vd., 2003: 10-11; Akgül, 2013: 128-129):

- Paralellik: Klasik problem çözüm algoritmalarının tersine yapay sinir ağları, paralel çalışmaya elverişli bir yapıdadır. Bu özellikleri ile de problemleri çok hızlı bir şekilde çözebilmektedirler.
- Doğrusal Olmama: Yapay sinir ağlarının temelinde yer alan nöronların doğrusal olmamasından kaynaklanan bu özelliğin ağına kendisine de yansıdığı söylenilebilir. Doğrusal olmamaları açısından yapay sinir ağları çoğunlukla karışık problemleri çözmede kullanılmaktadır. Yapay sinir ağları, özellikle doğrusal olmayan sistemlerde tahminde bulunabilme yönleriyle istatistiksel hesaplamalara bakıldığında daha doğru sonuçlar vermesi nedeniyle sık tercih edilen bir yöntem haline gelmiştir ve tahmin gerektiren birçok alanda, özellikle işletmecilik ve finans gibi, kullanılmaktadır.
- Öğrenme: Yapay sinir ağları, insan beyni ile benzer biçimde bir çalışma prensibi izleyerek öğrenmeyi gerçekleştirirler. Yapay sinir ağları geçmiş olaylardan edinimler çıkararak benzer durumlar karşısında benzer çıkarımlar vermeye çalışırlar ve böylelikle genelleme yapabilme yeteneğine kavuşurlar. Bu özelliği nedeniyle yapay sinir ağı, geleneksel yöntemler için karmaşık olan olaylara çözüm üretilebilmektedir.
- Bilginin Saklanması: Geleneksel hesaplama yöntemlerinde bilgi, herhangi bir veri tabanı içerisinde ya da bir program içerisinde gömülü olarak saklanmaktadır. Yapay sinir ağlarında bilgi, nöronlar arasındaki ağırlıklı bağlantılarda yani ağ üzerinde saklanmaktadır. Bilgi ağ içerisinde dağınık bir durumdadır ve ağ, öğrendiği olayın tamamını yansıtmaktadır. Bu yüzden yapay sinir ağlarının dağıtılmış bellekte bilgi depolama kapasitesine sahip oldukları söylenebilmektedir.

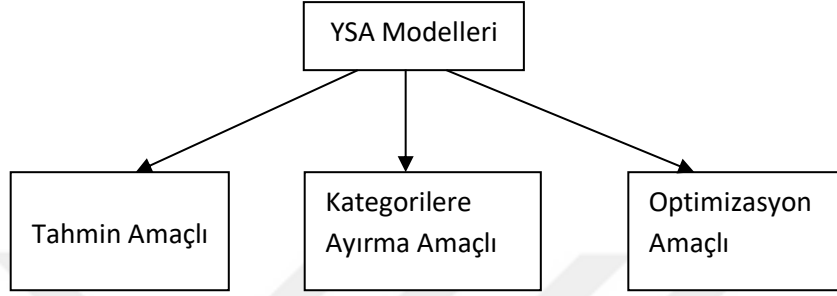
- **Hata Toleransı:** Çok sayıda basit işlemci elemandan oluşan yapay sinir ağı modelleri, bağlantı ağırlıklarını ayarlayabilmelerinden dolayı oldukça esnek bir yapıdadır. Bu yüzden, ağın bir kısmının zarar görmesi modelde performans düşüklüğü oluşturmakta ve problemin çözümünü etkileyecek büyük sorunlara neden olmamaktadır. Bunun aksine geleneksel yöntemler tek merkezi işlemciye sahip olduklarından, bir birimin hatalı çalışması veya tamamen bozulması bütün sistemin bozulmasına ya da hatalı çalışmasına neden olabilmektedir.
- **Genelleme:** Yapay sinir ağları kendi kendine öğrenme yetenekleri ile bilinen örneklerden yararlanarak önceden karşılaşmadıkları durumlar için genelleme yapabilmektedirler. Yani, hatalı veya kayıp veriler için çözüm üretebilmektedirler. Yapay sinir ağları, ilk kez karşılaştıkları ya da eksik veriler hakkında genelleme yaparak karar verebilme yeteneğine sahip olduklarından dolayı iyi birer Desen (Örüntü) Tanımlayıcısı (Pattern Recognition Engine) ve Sağlam Sınıflandırıcılardır.
- **Uyarlanabilirlik:** Yapay sinir ağları, çalıştığı problemdeki değişimlere bakarak ağırlıklarını düzenleyebilmekte ve ayarlayabilmektedir. Bir problemi çözebilmek adına eğitilen bir yapay sinir ağı, karşılaşılan değişikliklere göre düzenlenebilmekte, eğitilebilmekte ve bir başka problemi çözmek adına kolaylıkla kullanılabilir. Bu kullanım için gerekli tek şey değişen koşulların, yani yeni problemin girdi ve çıktıları ile ağın tekrar eğitilmesidir.
- **Eksik Verilerle Çalışma:** Geleneksel sistemlerin aksine, yapay sinir ağları, eğitilmelerinin ardından yetersiz bilgiyle de çalışmalarını devam ettirebilmekte ve yeni örnekler eksik bilgi sağlasa dahi sonuç verebilmektedirler. Yapay sinir ağlarının eksik bilgilerle çalışması performansını düşürmemektedir. Performansın düşmesi eksik olan bilginin önemine bağlı olmaktadır. Yapay sinir ağları hangi bilginin önemli olduğunu eğitim sırasında öğrenmektedir.

## 2.2. Yapay Sinir Ağları Yönteminin Uygulama Alanları

1960'lardan bu yana yapılan çalışmalar sonucunda farklı amaçlar için çeşitli YSA modelleri geliştirilmiştir. YSA modelleri, öğrenme algoritmalarına, mimari yapılarına göre değişmekte ve farklı/benzer amaçlar için kullanılabilir. 29



YSA'lar, tahmin, fonksiyon yaklaşımı, sınıflandırma, kümeleme, optimizasyon gibi birçok amacı gerçekleştirmek üzere başvurulan bir araçtır. Kullanım amaçlarına göre YSA modelleri Şekil 2.1 deki gibi sınıflandırılabilir (Akdağ, 2014: 62). Sinyal işleme, örüntü tanıma, paralel hesaplama, sabit nokta hesaplama, optimizasyon, ilişkisel hafıza vb. Birçok pratik araştırma alanına uygulanabilir (Ji et al., 2011: 6169).



Şekil 2.1. Amaca Göre YSA Modelleri

Kaynak: Akdağ, 2011: 62.

Başarılı uygulamalar incelendiğinde yapay sinir ağlarının kullanım alanları için; doğrusal olmayan, çok boyutlu, karmaşık, kesinlik içermeyen, eksik, kusurlu, gürültülü, hata olasılığı yüksek verilere sahip; problemin çözümü adına gerek duyulan matematiksel bir modelin ve algoritmanın bulunmadığı durumlarda ihtiyaç duyulmakta denilebilir. Bu gibi koşullarda ihtiyaç duyulan ağlar genelde aşağıdaki fonksiyonları yerine getirmektedirler (Yücesoy, 2011: 39).

- Muhtemel fonksiyon kestirimleri
- Sınıflandırma
- İlişkilendirme ya da örüntü eşleştirme
- Zaman serileri analizi
- Sinyal filtreleme
- Veri sıkıştırma
- Örüntü tanıma
- Doğrusal olmayan sistem modelleme
- Optimizasyon

### 2.3. Yapay Sinir Ağları Yönteminin Avantajları ve Dezavantajları

Sinirsel ağların doğrusal modellenen problemlere önceki uygulamalarında muazzam gelişmeler meydana geldi. Huang ve Lippmann, geleneksel istatistik sınıflandırma şemalarıyla geri yayılım karşılaştırmasını gerçekleştirdi. Geri yayılmanın, Gauss olmayan veri dağılımları için karar bölgeleri oluşturmada ve çok sayıda aykırı olan dağılımlarda mükemmel olduğunu bulmuşlardır. Ek olarak, sinir sistemi daha az depolama gerektirir ve geleneksel istatistiksel yaklaşımlardan çok daha hızlıdır. Karar bölgeleri doğrusal olarak ayrılabilir olsa bile. Bir sinir ağı yaklaşımının, lineer ayrımcılığa göre çok daha yüksek bir sinyal / gürültü oranına sahip bir ayırma oluşturduğunu keşfetti. Belki de sinir ağları ve giderek verimli bir araştırma alanı için en eşsiz, sistemin genelleme yeteneğidir. Bir sinir sistemi, nesne özellikleri ve ilgili değerlendirmelerin örneklerinden oluşan bir veri kümesi üzerinde eğitilmişse, genelleme yeteneği, eğitim setinin dışında yer alan nesnelere üzerindeki performansıyla ölçülür. Açıkçası, genelleme yeteneği eğitim setinin yeterliliğine bağlıdır. İstatistiksel modelde çok fazla serbestlik derecesi gibi çok sayıda gizli birimin, genelleştirmeyi engelleyeceği ve bir eğitim setinin “ezbere ezilmeye” yol açacağı da bilinmektedir. Gizli birimlerin, parametrelerin ve eğitim stratejisinin sayısının seçilmesi ve değiştirilmesi için bir dizi kılavuz, bir nöral ağdaki başarımın öncelikle şans içerdiğini algılamış ve geliştirmiştir (Burke ve Ignizio, 1992: 6-7).

Yapay sinir ağları Paralellik, Doğrusal Olmama, Öğrenme, Bilginin Saklanması, Hata Toleransı, Genelleme, Uyarlanabilirlik ve Eksik Verilerle Çalışma gibi özellikleri avantajları olarak söylenebilmektedir (Akgül, 2013: 128).

Yapay sinir ağlarının dezavantajları şu şekilde sıralanabilir (Aktaş vd., 2003: 10-11):

- Uygun çözüme ulaşamama: Yapay sinir ağlarının her alanda uygulanabileceği ve her koşula uyum sağlayarak çözüme ulaşabilecek bir yapıda olduğunu düşünmek yanlıştır. Bu teknoloji, bazı problemlerde eğitim verisine de bağlı olarak, yanlış ve alakasız sonuçlar da üretebilmektedir. Bunun yanında bazı alanlarda ağın eğitimi hiç mümkün olamamaktadır.
- Açıklama eksikliği: İstatistiksel yöntemler, soruna ilişkin anlaşılabilir ve yorumlamaya elverişli parametreler ortaya koymasına karşın, yapay sinir ağlarının ağırlıklarını yorumlayabilme olanağı henüz bulunmamaktadır.

Bundan dolayı, yapay sinir ağı ile elde edilen sonuçlarda model, kapalı bir kutu özelliği taşımaktadır denilebilir.

#### 2.4. Diğer Talep Tahmin Yöntemleri İle Yapay Sinir Ağları Yönteminin Karşılaştırılması

YSA, geleneksel hesaplama yöntemlerinden farklı bir veri analizi ve veri içerisindeki ilişkileri tanıma yolu sunar. Bununla birlikte her türlü hesaplama problemlerine çözüm değildirler. YSA, problem çözmeye çok farklı bir yaklaşım getirir ve bazen hesaplamamın altıncı kuşağı olarak adlandırılır. Sinir ağları problemleri bir uzmanın yardımı olmaksızın ve programlamaya ihtiyaç duyulmadan çözüme kabiliyeti sağlamak için yapılandırılırlar. Bununla birlikte, her ne kadar bu çok özel alanlarda sinir ağları hem uzman sistemler hem de daha geleneksel hesaplama göre avantajlı ise de tam çözüm sağlamazlar. Tamamen hatadan arındırılmış değildirler. Hata yaparlar ve böylece öğrenmeye devam ederler. Daha da ötesi bir ağ geliştirildiği zaman bile ağın en iyi ağ olduğunu garanti edecek herhangi bir yöntem yoktur. Geleneksel hesaplama metotları iyi tanımlanabilen problemler için uygundur. Geleneksel bilgisayarlar, pek çok uygulama için idealdir; veri işleyebilir, stokları takip edebilirler, sonuçları birbirine bağlayabilirler. Bu uygulamalar, sinir ağlarının özel karakteristiklerini gerektirmez. Aşağıda bulunan Tablo 2.1'de geleneksel hesaplama, uzman sistemler ile YSA arasındaki temel farkları göstermektedir (Hamzaçebi, 2011: 18-19).

Çizelge 2.1: Yapay sinir ağları, uzman sistemler ve geleneksel hesaplama yöntemleri karşılaştırması

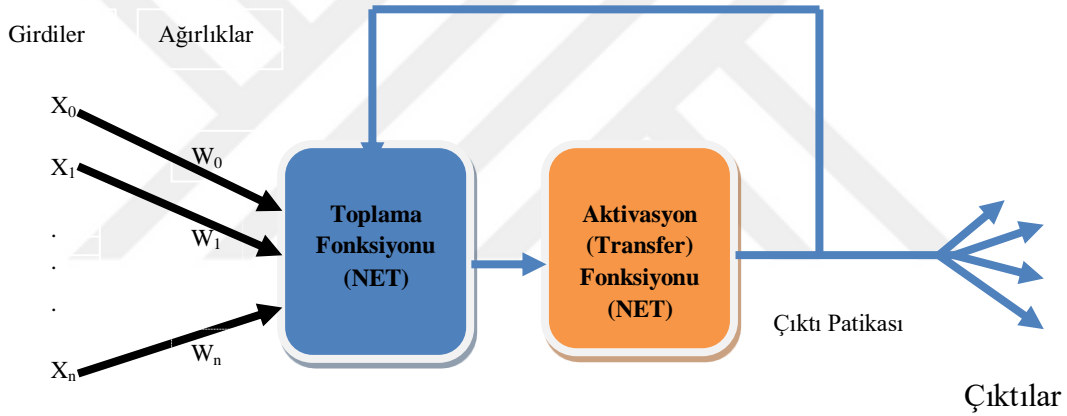
Kaynak: Hamzaçebi, 2011: 19.

Karakteristikler	Programlama Teknikleri	Uzman Sistemler	YSA
Veri İşleme	Seri	Seri	Paralel
Girdi Verisi	Sayısal	Bilgi	Örüntü
Algoritma	Programlama	Sezgisel	İstatistiksel
Hesaplama	Mantıksal/Aritmetiksel	Mantıksal/Sembolik	Sayısal
Çıktılar	Hesaplama	Tümdengelimli	Tümevarımsal

## 2.5. Biyolojik Sinir Hücreleri ile Yapay Sinir Hücrelerinin Karşılaştırılması

### 2.5.1. Yapay Sinir Hücreleri


Bir yapay sinir ağı; nöron, birim, hücre, düğüm, işlem elemanı ya da proses elemanı olarak isimlendirilen çok sayıda basit işlem biriminden oluşmaktadır. Biyolojik sinir ağlarının hücrelerine benzer şekilde yapay sinir ağlarının da yapay sinir hücreleri bulunmaktadır. Yapay sinir ağları, basit biyolojik sinir sisteminin çalışma prensibini simüle etmek adına geliştirilen bir programdır. Yapay sinir ağları, simüle edilen sinir hücrelerini içermektedir ve bu hücreler farklı şekillerde birbirlerine bağlanarak ağı oluşturmaktadır. Şekil 2.2'de genel bir yapay sinir hücresinin yapısı sunulmaktadır (Yurtoğlu, 2005: 14).



Şekil 2.2. Yapay Sinir Hücresi Yapısı

Kaynak: Yurtoğlu, 2005: 14.

Yapay bir nöron olan  $j$ 'nin görevi basittir. Komşu nöronlardan gelen giriş sinyallerini ( $x_i$ ) alır. Bu ağırlıklı sinyallerin toplamı, nöronun toplam veya net girişini ( $net_j$ ) sağlar. Daha sonra, pozitif veya negatif bir  $y_j$  değeri ile temsil edilen nöron  $j$ 'nin aktivasyon eşiği, net girişe eklenir ve bir matematiksel fonksiyon  $f()$  (genellikle doğrusal olmayan ve bir aktivasyon fonksiyonu) net girişine, çıkış değeri  $y_j$ 'ye uygulanır. Hesaplanır ve diğer nöronlara gönderilir (Palmer et al., 2006: 782-783).

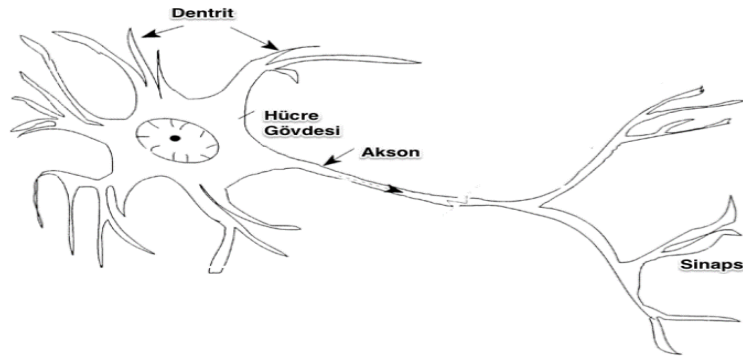


Şekil 2.3: Yapay bir nöronun genel işleyişi.

Kaynak: Palmer et al., 2006: 783.

### 2.5.2. Biyolojik Sinir Hücreleri

Beynimizin çalışma sistemi, günümüzde bile tam olarak çözülemeyen bir yapıdadır. 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 1010 sinir hücresi ve bu hücrelerin de 6x1010'dan fazla bağlantıya sahip olduğu bilinmektedir. İnsan beyнинin gücü ise; hayli çok olan bu sinir hücreleri ve aralarında bulunan bağlantıların genetik yapıları yardımıyla öğrenme yeteneğidir (Yücesoy, 2011: 40).



Şekil 2.4. Biyolojik Sinir Hücresi Yapısı

Kaynak: Basheer ve Hajmeer, 2000: 3.

### 2.5.3. Biyolojik Sinir Hücreleri ile Yapay Sinir Hücrelerinin Karşılaştırılması

Beyin ve sinir sisteminin özellikleri, içsel yapısı ve çalışma sisteminin bilinmemesi bu konuda sağlıklı bir karşılaştırma yapılmasını zorlaştırmaktadır. Fakat, teknoloji ve bilgisayar ağlarında meydana gelen ilerlemeler insan beyni ve sinir sisteminin araştırılmasında ilerlemelere olanak sağlamıştır. Yapay sinir ağları tekniğinin geliştirilmesiyle belli düzeyde sinir sistemini taklit eden modeller tasarlanmaya başlamıştır. Sinir sistemi ve beyin hakkında sağlanan bilgi artışı ise daha sağlıklı karşılaştırmalar yapılması mümkün olabilecektir. Aşağıda yer alan Çizelge 2.2’de, biyolojik sinir hücresinin elemanlarına karşılık gelen yapay sinir hücresi elemanları gösterilmektedir (Ballı, 2014: 76).

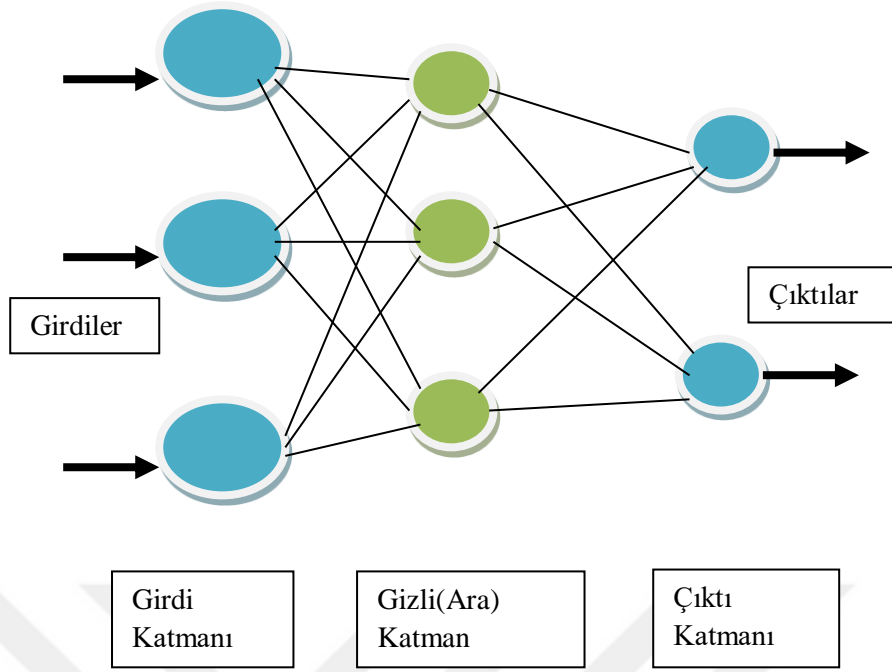
Çizelge 2.2: Biyolojik-Yapay Sinir Hücresi Elemanlarının Karşılıkları

Kaynak: Ballı, 2014: 76.

İşlem Birimi		
Biyolojik Sinir Ağı	Yapay Sinir Ağı	Görevleri
Dendrit	Alıcı ve Toplayıcı	Çevreden gelen veriyi alır
Akson	Verici	Gövdenin oluşturduğu veriyi iletir
Hücre gövdesi	Aktivasyon Fonksiyonu	Gelen veriyi toplayarak yorumlar ve veriyi oluşturur
Sinaptik Ağlar	Bağlantı Aralıkları	Öğrenilenleri hücrede saklar

### 2.6. Yapay Sinir Ağları Yönteminin Temel Yapısı

Bir yapıyı dizayn edebilmenin en basit yolu elemanları katmanlandırmaktan geçmektedir. Bu sürecin üç bölümü bulunmaktadır. Bu bölümler; nöronları katmanlar şeklinde gruplandırmak, katmanlar arasındaki bağlantıları gruplandırmak, toplama ve transfer fonksiyonlarını gruplandırmak şeklindedir. Bir başka ifadeyle, sinir hücrelerinin bir araya gelmesi rastgele olamaz. (Öztemel, 2006: 52; Gorr et al., 1994: 19-20);



Şekil 2.5. YSA Yapısı

Kaynak: Öztemel, 2006: 53.

*Girdiler:* Bu katman içerisindeki nöronlar, dış çevreden bilgi edinerek gizli katmanlara transfer ederler. Bazı ağlarda girdi katmanında herhangi bir bilgi işleme olmamaktadır. Sadece girdi değerlerini sonraki katmana iletirler. Bundan dolayı bazı araştırmacılar, bu katmanı ağların katmanları içerisinde ilave etmezler (Collins ve Clark, 1993: 506-507).

*Ağırlıklar:* Gelen bilgilerin hücre üzerindeki etkisini belirleyen değerlerdir. Her giriş için bir ağırlık bulunmaktadır. Ağırlığın büyük olması girişin önemli olduğu veya ağırlığın küçük olması girişin önemsiz olduğu anlamına gelmez, bazen bir girişin ağırlığının sıfır olması o ağ için en önemli olay olabilir. Aynı şekilde negatif değerler de yine girişin önemi ile ilgili bilgi vermemektedir, ağırlığın artı ve eksi olması girişin etkisinin pozitif veya negatif olduğunu göstermektedir. Ayrıca ağırlıklar değişken veya sabit de olabilmektedirler (Atasoy, 2012: 50).

*Gizli (Ara) Katman:* Girdi katmanından elde edilen bilgiler işlenerek çıktı katmanına gönderilmektedir. Bu bilgilerin işlenmesi gizli katmanlarda gerçekleştirilmektedir. Standart bir ağ içerisinde girdi ve çıktı katmanları tek katmandan oluşmaktayken, gizli katman miktarı birden fazla olabilmektedir. Gizli tabakalar çok sayıda nöron içermektedir ve bu nöronlar diğer nöronlarla bağlantılıdır. Ağın büyüklüğünün

tanımlanması ve performansın bilinmesi açısından gizli katmanda bulunan nöronların sayısının seçimi oldukça önemlidir. Ayrıca gizli katmandaki nöronların ve katmanların sayısının artırılması veya azaltılması ağın basit veya karışık yapıda olmasını etkilemektedir (Curry ve Moutinho, 1993: 9-10).

*Toplama Fonksiyonu:* Bir hücreye gelen net girdiyi hesaplamaktadır. Bu hesaplama esnasında farklı fonksiyonlar kullanılabilir. Bu fonksiyonlardan en çok tercih edileni ağırlıklı toplamı bulmaktır. Burada, gelen her bir girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece, ağa gelen net girdi hesaplanabilmektedir. Bir işlem elemanın gerçekleştirdiği ilk faaliyet, tüm girdilerin ağırlıklandırılmış toplamlarını hesaplamaktır. Matematiksel olarak; girdiler ( $X$ ) ve ağırlıklar ( $W$ ) vektörlerdir. Toplam girdi sinyali, bu iki vektörün oluşturduğu noktadır (Atasoy, 2012: 51).

*Aktivasyon fonksiyonu:* Toplama fonksiyonundan gelen girdiyi işlemekte ve yapay sinir hücresinin çıkışını belirlemektedir. Transfer fonksiyonu adıyla da bilinen aktivasyon fonksiyonu, farklı tiplerde ve genelde doğrusal olmayan bir fonksiyondur. Doğrusal fonksiyonların tercih edilmemesinin sebebi, doğrusal fonksiyonlarda girdiyle çıktının doğru orantılı olmasından kaynaklanmaktadır. Bu durum, ilk yapay sinir ağları denemelerinin başarısızlıkla sonuçlanmasının temel sebebidir (Atasoy, 2012: 51).

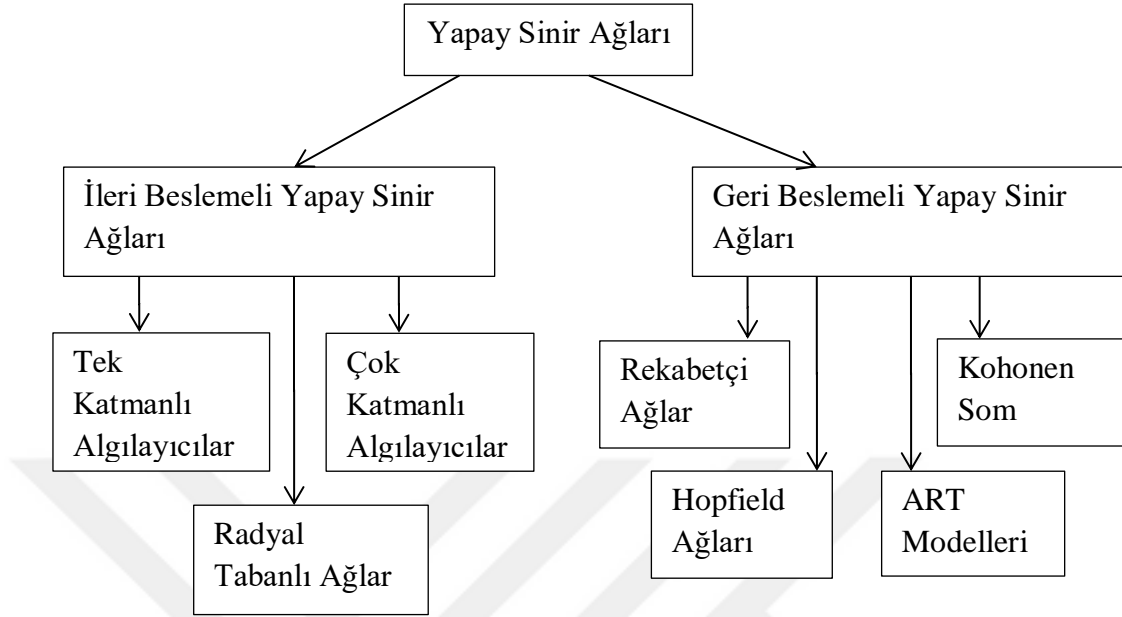
*Çıktı Katmanı:* Bu katmanda yer alan nöronlar, gizli katmandan alınan bilgileri işleyerek ağın girdi katmanından sunulan girdi seti (örnek) için üretmesi gereken çıktıyı üretmektedirler. Üretilen çıktı dış dünyaya gönderilmektedir (Fletcher ve Goss, 1993: 162).

## **2.7. Yapay Sinir Ağlarının Sınıflandırılması**

Yapay sinir ağlarını, yapısı ve öğrenme algoritmasına bağlı olarak sınıflandırmak mümkündür. İleri beslemeli ağlarda işlemci birimler genelde katmanlara ayrılmış bir yapıdadır. İşaretler, girdi katmanından çıktı katmanına tek yönlü bağlantılar yardımıyla iletilmektedir. İleri beslemeli bir yapay sinir ağında hücreler katmanlar şeklinde düzenlenmektedir ve bir katman içerisindeki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden girdi olarak verilmektedir. Giriş katmanı, dış ortamdan edindiği bilgileri değişikliğe uğratmadan orta kısımda yer alan gizli katmandaki



hücrelere iletir. Bilgi, gizli ve çıkış katmanında işlenerek ağ çıkışı belirlenmektedir (Ataseven, 2013: 3).



Şekil 2.6: Yapay Sinir Ağları Sınıflandırması


Kaynak: Jain, et al., 1996: 35.

Yapay sinir ağları, sinir hücrelerinin farklı şekillerde birbirlerine bağlanmaları ile meydana gelmektedir. Hücre çıkışları, ağırlıklar üzerinden diğer hücrelere veya hücrenin kendisine giriş olarak bağlanabilmekte ve bağlantılarda gecikme birimi de kullanılabilir. Hücrelerin bağlantı türlerine, öğrenim kurallarına ve aktivasyon fonksiyonlarına göre farklı teknikler geliştirilmiştir. İçinde çok sayıda nöron barındıran yapay sinir ağları, belli topolojilerle (mimariler) tanımlanabilirler. Bu topolojiler tek katmanlı ve çok katmanlı şeklinde birbirlerinden ayırt edilebilir. Tipik olarak bir modelin istenilen çıkışı elde etmek için oluşturulan bir giriş tabakası, çıktılar elde edildiği bir çıkış tabakası, giriş ve çıkış tabakalarının arasında yer alan en az bir gizli tabakası bulunmaktadır. Bir çıktı gizli katman olmadan direkt olarak elde edilememektedir, bu yüzden gizli katman sayısı en az bir olmalıdır (Ballı, 2014: 77).

### 2.7.1. İleri Beslemeli Yapay Sinir Ağları

Bağlantıların girdiden çıktıya tek yönlü olarak gelişim gösterdiği ağlara ileri beslemeli ağlar denilmektedir. Çok katmanlı algı (MLP-Multi Layered Perceptron)

ağları ise, statik geri dağılım yardımıyla eğitilen katmanlı ileri beslemeli ağlardır. Bu ağlar özellikle desen sınıflandırmasına ihtiyaç duyulan uygulamalarda kullanılmaktadır (Tam ve Kiang, 1992: 929).



Şekil 2.7: İleri Beslemeli Yapay Sinir Ağı

Kaynak: Krenker et al., 2011: 6.

*Tek Katmanlı Algılayıcılar:* Tek katmanlı yapay sinir ağları, doğrusal problemlerin çözümünde tercih edilmekte ve yalnızca girdi ve çıktı katmanlarından meydana gelmektedir. Katmanların bir ya da daha fazla nöronu bulunabilmektedir. Eşik girdisi, bu tip ağlarda nöron elemanlarının değerlerinin ve ağın çıktısının sıfır olmasını engellemektedir. Değeri daima 1'dir. Ağın çıktısı Denklem (2.1)'de gösterildiği şekilde ağırlıklandırılmış girdi değerlerinin eşik değeriyle toplanması sonucunda elde edilmektedir (Arı ve Berberler, 2017: 57).

$$\zeta = f \left( \sum_{i=1}^n W_i X_i + \phi \right) \quad (2.1)$$

Denklem (2.1)'de  $x_i, i=1,2,\dots,n$  ile ağın girdileri,  $w_i, i=1,2,\dots,n$  ile bu girdilere karşılık gelen ağırlık değerleri,  $\phi$  ile eşik değeri gösterilmiştir (Arı ve Berberler, 2017: 57).

*Çok Katmanlı Algılayıcılar:* Çok katmanlı algılayıcı adı verilen en yaygın ileri besleme ağları ailesinde, nöronlar aralarında tek yönlü bağlantıları olan katmanlar halinde düzenlenir. Farklı bağlantılar farklı ağ davranışları sağlar. Genel olarak konuşursak, ileri beslemeli ağlar statiktir, yani belirli bir girişten bir değer dizisi yerine yalnızca bir çıktı değeri kümesi üretirler. İleri beslemeli ağlar, bir giriş

verdikleri yanıtın önceki ağ durumundan bağımsız olması bakımından hafızasızdır (Jain, et al., 1996: 34).

*Radyal Tabanlı Fonsiyonlar:* Radyal Bazlı Yapay Sinir Ağları (RTYSA), 1988 yılında biyolojik sinir hücrelerinin mevcut görünümünü etkileme davranışından esinlenen ve filtreleme problemine uygulanan ANN tarihine girmiştir. RTYSA modellerinin eğitimini çok boyutlu uzayda eğriye uygun bir yaklaşım olarak görmek mümkündür. RTYSA modelleri genel ANN mimarisine benzer şekilde giriş katmanı, gizli katman ve çıktı katmanı olarak 3 kat olarak tanımlanır. Bununla birlikte, geleneksel ANN yapılarının aksine, girdilerden gizli katmanlara geçişte RTYSA'lar, radyal tabanlı aktivite planlama ve doğrusal olmayan kümeleme analizi yapılmıştır. Gizli katmanla çıkış katmanı etkileşimi, diğer YSA türlerinde olduğu gibi devam eder ve asıl eğitim burada gerçekleştirilir. RTYSA tarafından üretilen çıktı (y) olduğu varsayılırsa (2.2) denklemi yardımıyla hesaplanabilir.

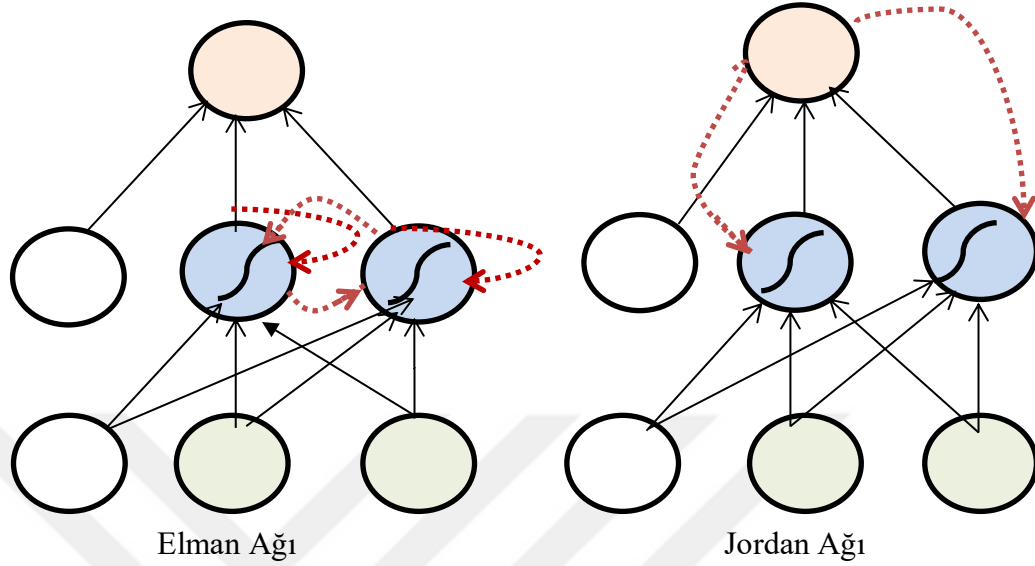
$$y_i = \sum_{k=1}^N w_{ik} \phi_k(x, c_k) = \sum_{k=1}^N w_{ik} \phi_k(\|x - c_k\|_2), \quad i = 1, 2, \dots, m \quad (2.2)$$

(2.2) formülde x ağın girdi vektörünü,  $\phi_k$  radyal bazlı aktivasyon fonksiyonunu,  $c_k$  vektör uzayı (girdi) alt setine ait radyal tabanlı merkezleri,  $w_{ik}$  çıktı katmanındaki ağırlıkları,  $\| \cdot \|$  öklid normu, N gizli katmanda bulunan toplam hücre sayısını ifade etmektedir (Okkan ve Dalkılıç, 2012: 5959).

*Elman-Jordan Ağları:* Klasik ileri beslemeli sinir ağlarının aksine, Elman sinir ağı, tekrarlanan bağlantıları aracılığıyla önceki gizli katman durumlarını takip eder. Dolayısıyla, zamandaki gizli katman, mevcut girdiyle birlikte geçmiş girdileri özetleyen bir durum olarak görülebilir. Matematiksel olarak Elman, gizli katmanların her birinde gizli düğümlerle dinamiği gösterir (Mesnil, et al. 2015: 532).

Jordan ağı girdi, çıktı ve ara katmanlara ilaveten durum elemanları olarak adlandırılan. özel işlemci elemanlarının bulunduğu, çok katmanlı geri beslemeli bir ağ yapısına sahiptir. Bu sinir ağında yer alan durum elemanları, çıktı tabakasından aktivasyon değerlerini alarak bir sonraki iterasyonda bunu girdi olarak taşımakla görevli olan elemanlardır. Elman ağı, Jordan ağı ile büyük benzerliklere sahip olmakla birlikte aralarında iki önemli farklılık bulunmaktadır. Birincisi, geri besleme

yaptıkları aktivasyon değerlerini çıktı katmanından almak yerine ara katmandan almaları iken diğer farklılık ise içerik elemanlarının kendilerine bağlantı durumlarının olmayışıdır ( Atasoy, 2012: 66).



Şekil 2.8: Elman ve Jordan Ağı Gösterimi

Kaynak: Mesnil, et al. 2015: 532.

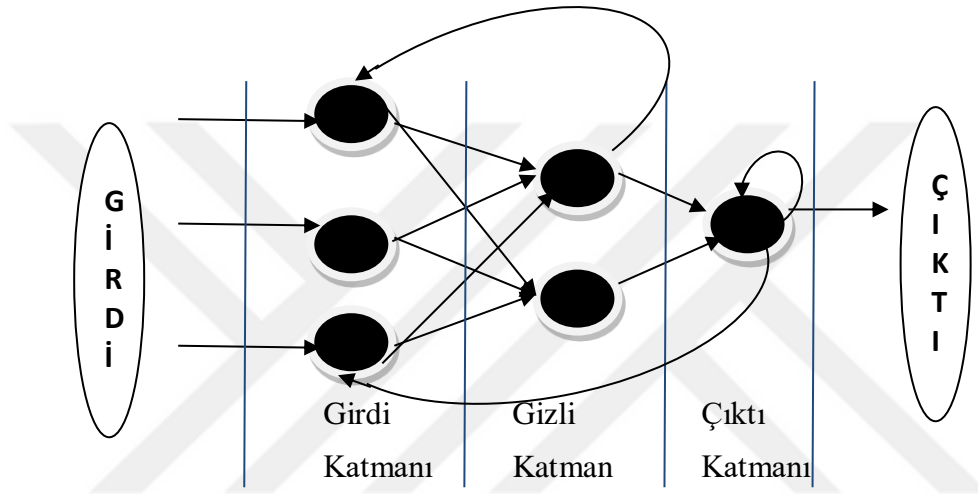
### 2.7.2. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağlarında, asgari bir hücrenin çıkışı kendisine veya diğer hücrelere giriş olarak verilmekte ve genel olarak geri besleme bir geciktirme elemanı vasıtasıyla yapılmaktadır. Geri besleme, bir katman içerisinde yer alan hücreler arasında olabileceği gibi katmanlar arasında yer alan hücrelerde de olabilmektedir. Bu yapısı itibariyle geri beslemeli ağlar, doğrusal olmayan dinamik davranış göstermektedir. Bu nedenle, geri beslemenin yapılış şekline göre değişken yapılarda ve davranışta geri beslemeli ağlar elde edilebilmektedir. Yayılma ve uyum gösterme şeklinde iki aşamalı bir işlem sürecine sahip olan Standart Geri Besleme Algoritması, katmanlar arası tam bağlantının olduğu çok katmanlı, ileri beslemeli ve öğreticili olarak eğitilen bir yapay sinir ağı modelidir (Olgun, 2009: 52). Bu özelliği ile geri beslemeli ağlar dinamik sistemlerdir (Jain, et al., 1996: 34).

Geri dağılım kullanımı esnasında ağ, her bir girdi deseniyle hedef çıktıyı karşılaştırarak öğrenmekte, hatayı hesaplayarak hata fonksiyonunu ağ üzerinde çıktıdan girdiye doğru (geriye doğru) çalıştırmaktadır. Bu tür ağların en önemli getirisi kolay kullanımları ve girdi/çıkı haritası için yakınsamadır. En önemli

dezavantajı, öğrenme yeteneğinin yavaş olması ve bu öğrenme süreci esnasında çok fazla veriye ihtiyaç duymasıdır (Kutlu ve Badur, 2009: 6).

Standart Geri Besleme Algoritması, hataları geriye doğru azaltmaya çalışmasından nedeniyle bu şekilde adlandırılmıştır. Geri yayımlı öğrenme kuralı, ağ çıkışındaki hata düzeyine göre her katmanda yer alan ağırlıkların tekrar hesaplanması adına kullanılmaktadır. Bir geri beslemeli ağ modelinde giriş, gizli ve çıkış olmak üzere 3 katman bulunmaktadır ve problemin özelliklerine göre gizli katman sayısını artırabilme olanağı bulunmaktadır (Çetin ve diğ., 2009).



Şekil 2.9: Geri Beslemeli Yapay Sinir Ağı

Kaynak: Krenker et al., 2011: 6.

*Khonen SOM*: Kohonen tarafından sunulan SOM, herhangi bir sınıf bilgisi olmadan bir örüntü dizisinin dağılımını öğrenen denetimsiz bir öğrenme sürecidir. Bir model, bir giriş alanından haritadaki bir konuma yansıtılır; bilgi, aktif bir düğümün yeri olarak kodlanır. SOM, sınıfların topolojik bir sıralamasını sağlaması bakımından çoğu sınıflandırma veya kümeleme tekniğinden farklıdır. Giriş modellerinde benzerlik işleminin çıktısında korunur. SOM sürecinin topolojik olarak korunması, özellikle çok sayıda sınıf içeren verilerin sınıflandırılmasında yararlıdır (Lawrence et al., 1997: 102).

En önemli YSA'dan biri, Kohonen tarafından önerilen Öz Organizasyon Haritasıdır (SOM). Bu ağda Bir giriş katmanı ve genellikle n boyutlu girişi iki boyutlu olarak eşleyen nöronların iki boyutlu düzenlemesi olarak tasarlanmış Kohonen katmanı vardır. Temel olarak, girdi alanından kümelere kadar topoloji koruyan bir haritalama

sağlayan öz-örgütlenme özelliği olan rekabetçi bir ağıdır. Kazanan düğüm için Kohonen güncelleme kuralı (2.3), kazanamayan düğümler için (2.4). (Mingoti and Lima, 2006: 1747).

$$w_q^{s+1} = w_q^s(1 - \alpha^s) + X_i \alpha^s \quad (2.3)$$

$$w_i^{s+1} = w_i^s \quad (2.4)$$

*Hopfield Ağları:* Hopfield ağları paralel hesaplama yapma yeteneğine sahip bir ilişki bellemek için ağıdır. Optimizasyon sorunları içeren sinyal ve görüntü işleme uygulamalarında kullanılabilmektedir (Chen et al., 2002: 1028).

Optimizasyon problemleri için hopfield ağlarının sıklıkla kullandığı nöron aktivasyon işlevi aşağıdaki denklemde (2.6) gösterilmiştir.

$$V = f(U) = \frac{1}{2} \left( 1 + \tanh \frac{U}{U_0} \right) \quad (2.5)$$

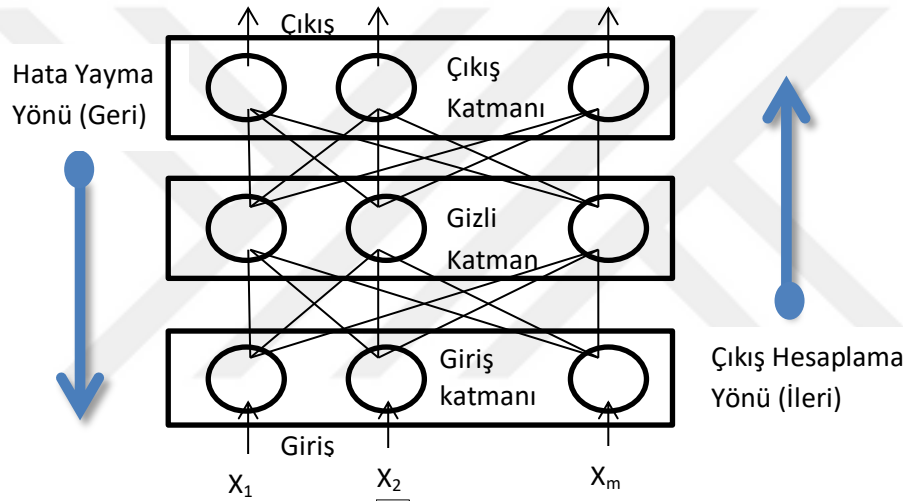
Denkleminde (2.6) yer alan U giriş sinyali, V çıkış sinyali, U<sub>0</sub> ise sabit sayıdır. Hopfield sinir ağlarının faydalarına rağmen bazı dezavantajları var; en önemli dezavantajlardan biri, zaman zaman küresel minimum tablolara yerine yerel olarak minimum tablolara bulmalarıdır (Jolai and Ghanbari, 2010: 5331-5332).

*ART Ağları:* Adaptif rezonans teorisi (ART) sinir ağları gerçek zamanlı hipotez testleri, arama, öğrenme, tanıma ve tahmin modellemesi yapar. 1980'lerden bu yana, insan bilişsel bilgi işlemenin bu modelleri, çeşitli nöromorfik teknolojiler için hesaplamalı motorlar olarak hizmet vermiştir (Carpenter and Grossberg, 2016: 1).

### 2.7.3. İleri Beslemeli Geri Yayılmalı Sinir Ağları

İleri beslemeli geri yayılım mimarisi 1970'lerin başında bağımsız birkaç araştırmacı tarafından geliştirilmiştir. Bu gelişme, çeşitli konferans, görüşmeler ve makalelerin çoğalmasının bir sonucuydu. Sinerjik olarak geliştirilmiş olan bu mimari çok katmanlı ağlar için en popüler, etkili ve öğrenmesi kolay olması diğerlerinden daha fazla kullanılmasını sağlamıştır. Bu ağ mimarisi bir çok farklı topolojiye ve eğitim yöntemine sahip olması birçok farklı uygulamada kullanılmasının önünü açmıştır. Bu mimarinin en büyük gücü ise yanlış tanımlanan sorunlara sunduğu doğrusal olmayan çözümlerdir (Anderson ve McNeill, 1992: 32).

Günümüzde oldukça yaygın bir kullanım sahasına sahip olan ileri beslemeli geri yayılım sinir ağı, mimari olarak çok katmanlı perceptron mimarisine sahip ve öğrenme yöntemi olarak da geri yayılım algoritmasını kullanan bir yapıya sahip olan bir ağıdır. Bu ağlarda, katman sayıları ve işlemci elemanların sayısının belirlenmesi ağın başarılı sonuçlar üretmesi açısından büyük önem taşımakta olup, bu sayıların belirlenmesi açısından kesin bir kriter mevcut olarak bulunmamaktadır. Bu ağ yapısı özellikle öngörü ve sınıflandırma problemlerinde üstün başarı göstermekte olup, geri yayılım algoritması ile de eğitilir. Geri yayılım algoritması ile eğitim üç aşamalı olarak gerçekleştirilir. Girdi değerinin ileri beslenmesi, ilişkili hatanın geri yayılımı, bağlantı ağırlıklarının ayarlanması ( Atasoy, 2012: 66).



Şekil 2.10: İleri Beslemeli Geri Yayılmalı Yapay Sinir Ağı Yapısı

Kaynak: Atasoy, 2012: 65.

## 2.8. Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağları, belli bir algoritma çerçevesinde programlanmazlar ve insanlar gibi örneklerle eğitilirler. Öğrenme süreçleri, bir çocuğun öğrenme sürecine benzemektedir. Sıcak bir nesneye dokunulmayacağını deneyerek tecrübe eden ve öğrenen bir çocuk, zamanla daha az sıcak olan bir nesneye dokunma cesaretini göstererek sıcak bir süt bardağını tutabilmektedir. Çocuk, sıcaklık kavramını tecrübe ederek ve deneyerek öğrenmiş, ölçebilecek konuma gelmiştir. Yapay sinir ağları da aynı şekilde girdi ile çıktı arasındaki bağlantı ağırlıklarının değiştirilmesi ile eğitilirler. Sunulan girdi kümesi için; transfer fonksiyonu aracılığıyla elde edilen

değerlere cevap olarak bağlantı ağırlıklarının tamamının ya da bir kısmının istenilen çıktı ile elde edilen ağ çıktısı arasındaki farkın hedeflenen değere düşürülünceye dek değiştirilmesi işlemidir. Günümüze kadar çeşitli öğrenme algoritmaları geliştirilmiştir. Bunlar; denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme olarak üç ana gruba ayrılmaktadır (Civalek ve Ülker, 2004:4).

Öğrenme, yapay sinir ağının, başlangıç esnasında 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: 53; Kattan et al., 1993: 42).

#### 2.8.1. Danışmanlı Öğrenme

Denetimli bir öğrenme algoritması, belirli bir giriş karşılık gelen istenen ve gerçek ağ çıkışları arasındaki farka göre, nöronlar arası bağlantıların kuvvetini veya ağırlığını ayarlar. Bu nedenle, denetlenen öğrenme, istenen veya hedef çıktı sinyallerini sağlamak için bir öğretmen veya danışman gerektirir. Denetimli öğrenme algoritmalarına örnek olarak delta kuralı, genelleştirilmiş delta kuralı veya geri yayılma algoritması ve LVQ algoritması dahildir (Pham et al., 2007: 68). Çok Katmanlı Algılayıcı (ÇKA) ile Radyal Taban Fonksiyonlu (RTF) ağlar bu stratejiyi kullanan ağlara örnek olarak verilebilir (Efendigil, 2008: 41).

Yapay sinir ağlarında en fazla kullanılan öğrenim tekniği olan danışmanlı öğrenmede, ağa örnek olarak bir çıktı (beklenen çıktı) girilir ve sonrasında verilen çıktı ile ağda üretilen çıktı karşılaştırılır. Çıktılar arasındaki fark hata olarak adlandırılır. Başlangıç esnasında genellikle tesadüfi olarak girilen ağırlıklar yapay sinir ağı tarafından hata minimum düzeye getirilene kadar döngüler halinde değiştirilir. Danışmanlı öğrenmede, ağ kullanım öncesinde eğitilmelidir. Eğitim, yapay sinir ağına giriş ve çıkış bilgileri oluşturma işlemini içermektedir. Bu bilgiler genellikle eğitime kümesi olarak adlandırılır. Yani, ağ içerisindeki her bir giriş kümesi için çıkış kümesi sağlanmalıdır (Ataseven, 2013: 4).



### 2.8.2. Danışmansız Öğrenme

Sistemin öğrenmesine yardım eden bir eğitici yoktur. Sisteme yalnızca giriş değerleri gösterilmektedir. Örneklerdeki parametreler arasında yer alan ilişkileri sistemin kendiliğinden öğrenmesi beklenilir. Sistemin öğrenme süreci sona erdikten sonra çıkışların ne manaya geldiğini gösteren etiketlendirmenin kullanıcı tarafından yapılması gerekmektedir (Efendigil, 2008: 41). Denetimsiz öğrenme algoritmalarına örnek olarak Kohonen ve Carpenter-Grossberg Uyarlanabilir Rezonans Teorisi (ART) ve rekabetçi öğrenme algoritmaları dahildir (Pham et al., 2007: 68).

Denetimsiz öğrenme verilen veri ve minimize edilecek bir maliyet fonksiyonuna dayalı bir yapay sinir ağının parametreleri ayarlayan bir makine öğrenme tekniğidir. Maliyet fonksiyonu herhangi bir fonksiyon olabilir ve görev formülasyonu tarafından belirlenir. Denetimsiz öğrenme, çoğunlukla istatistiksel modelleme, sıkıştırma, filtreleme, kör kaynak ayırma ve kümeleme gibi tahmin problemleri alanına giren uygulamalarda kullanılır. Yapay sinir ağına sadece etiketlenmemiş örnekler verilmiş olması, denetimli öğrenme ve güçlendirme öğrenmesinden farklıdır. Denetimsiz öğrenmenin yaygın bir biçimi, farklı kümelerdeki verileri benzerlikleriyle kategorize etmeye çalıştığımız kümelendirme. Yukarıda tarif edilen yapay sinir ağı modelleri arasında, Kendini organize eden haritalar en çok denetlenmemiş öğrenme algoritmaları kullananlardır (Krenker et al., 2011: 14).

### 2.8.3. Destekleyici Öğrenme

Destekleyici öğrenme, denetimli öğrenmenin özel bir durumudur. Hedef çıktılar için danışman kullanmak yerine destekleyici bir algoritma kullanmaktadır. Bu algoritma her bir girdiye karşılık gelen çıktının uygunluğunu değerlendirmektedir. Algoritma (Pham vd., 2007: 68). Sistem eğiticiden gelen bu sinyali dikkate alarak öğrenme sürecini devam ettirir. Genetik algoritma ve Vektör Kuantalama Modelleri (LVQ) bu yapıyı kullanan sistemlere örnek olarak verilebilir (Efendigil, 2008: 41).

### 2.8.4. Öğrenme Kuralları

*Hebb öğrenme kuralı:* İlk ve kuşkusuz en iyi bilinen öğrenme kuralı Donald Hebb tarafından tanıtıldı. Tanım, 1949 yılında Davranış Örgütü kitabında ortaya çıktı. Temel kuralı: Bir nöron başka bir nörondan bir girdi alırsa ve her ikisi de yüksek

derecede aktifse (matematiksel olarak aynı işarete sahipse), nöronlar arasındaki ağırlık güçlendirilmelidir (Keleş ve Çepni, 2006: 68).

*Hopfield Öğrenme Kuralı:* Hebb'nin kuralı, güçlendirme veya zayıflamanın büyüklüğünü belirlemesi istisnası ile benzerdir. “İstenilen çıkış ve giriş hem aktif hem de aktif değil ise, öğrenme hızına göre bağlantı ağırlığını artırır, aksi takdirde öğrenme oranıyla ağırlığı azaltır (Sezgin vd., 2012: 259).

*Delta Öğrenme Kuralı:* Bu kural Hebb Kuralı'nın başka bir varyasyonudur. En çok kullanılanlardan biridir. Bu kural, istenen çıktı değeri ile işlem elemanının akım çıkışı arasındaki farkı (delta) azaltmak için giriş bağlantılarının kuvvetlerini sürekli olarak değiştirmenin basit fikrine dayanır. Bu kural, sinaptik ağırlıkların, ağırlık ortalaması hatasını en aza indirecek şekilde değiştirir. Bu kural aynı zamanda Widrow-Hoff Öğrenme Kuralı ve En Küçük Ortalama Kare (LMS) Öğrenme Kuralı olarak adlandırılır (Taşova, 2011: 31; Piramuthu et al., 1994: 516-517).

Delta Kuralı'nın çalışma şekli, çıktı katmanındaki delta hatasının transfer fonksiyonunun türevi tarafından dönüştürülmesi ve giriş bağlantı ağırlıklarının ayarlanması için önceki nöral katmanda kullanılmasıdır. Başka bir deyişle, bu hata önceki katmanlara bir seferde bir katman halinde geri yayılır. Ağ hatalarını geri yayma işlemi, ilk katmana ulaşılan kadar devam eder. Feedforward olarak adlandırılan ağ tipi, Geri yayılma, bu terimi hata teriminin hesaplanması yönteminden alır (Piramuthu et al., 1994: 516-517).

Delta kuralını kullanırken, girdi veri kümesinin iyi bir şekilde randomize olduğundan emin olmak önemlidir. Eğitim setinin iyi hazırlanmış veya yapılandırılmış sunumu, istenen doğruluğa yaklaşamayan bir ağa yol açabilir. Bu olursa, ağ sorunu öğrenmekten acizdir (Taşova, 2011: 31).

*Gradyan Kuralı:* Bu kural Delta Kuralına benzerdir, çünkü transfer fonksiyonunun türevi hala bağlantı ağırlıklarına uygulanmadan önce delta hatasını değiştirmek için kullanılır. Bununla birlikte, burada, öğrenme oranına bağlı ilave bir orantılı sabit, ağırlığa etki eden son modifiye edici faktöre eklenir. Bu kural, bir istikrar noktasına çok yavaş bir şekilde yaklaşırsa da, yaygın olarak kullanılır (Ataseven, 2013: 105).

Bir ağırlık farklı katmanları için farklı öğrenme oranlarının, öğrenme sürecinin daha hızlı birleşmesine yardımcı olduğu gösterilmiştir. Bu testlerde, çıktıya yakın olan katmanların öğrenme oranları, girdinin yakınındaki katmanlardan daha düşük olarak

ayarlanmıştır. Bu, giriş verilerinin güçlü bir temel modelden türetilmediği uygulamalar için özellikle önemlidir (Sharda, 1994: 117-118).

*Kohonen Öğrenme Kuralı:* Teuvo Kohonen tarafından geliştirilen bu prosedür, biyolojik sistemlerde öğrenimden ilham almıştır. Bu prosedürde, işleme elemanları, öğrenme, ya da ağırlıklarını güncelleme fırsatı için yeterlidir. En büyük çıktısı olan işleme elemanı kazanan olarak ilan edilir ve rakiplerini ve komşularını da heyecanlandırabilme kabiliyetine sahiptir. Sadece kazananın bir çıkışa izin verilir ve sadece kazananın artı komşularının bağlantı ağırlıklarını ayarlamalarına izin verilir (Civalek ve Calayır, 2007: 4163).

Kohonen'in öğrenme yasası, her eğitim vakasına en yakın düğümü bulan ve 'kazanma' düğümünü eğitim vakasına yaklaştıran çevrimiçi bir algoritmadır. Düğüm, kendisiyle eğitim durumu arasındaki mesafenin bir kısmına taşınır. Oran, öğrenme oranı ile belirlenir. Egzersiz verilerindeki her nesne için, ağırlık vektörü ile giriş sinyali arasındaki mesafe hesaplanır. Sonra yarışma başlar ve en küçük olan düğüm kazanır. Kazanan düğümün ağırlıkları daha sonra bazı öğrenme kuralları kullanılarak güncellenir. Kazanan olmayan düğümlerin ağırlıkları değişmez (Mingoti and Lima, 2006: 1747).

Ayrıca, mahalle büyüklüğü eğitim süresince değişebilir. Genel paradigma, mahallenin daha geniş bir tanımıyla başlamak ve eğitim süreci ilerledikçe daralmaktır. Kazanan eleman, giriş modeline en yakın olanı olarak tanımlandığından, Kohonen ağırları girdilerin dağılımını modellemektedir. Bu, verilerin istatistiksel veya topolojik modellemesi için iyidir ve bazen kendi kendini organize eden haritalar veya kendi kendini organize eden topolojiler olarak adlandırılır (Öğücü, 2006: 5; Taşova, 2011: 32).

## **2.9. Yapay Sinir Ağlarının Tasarımı ve Eğitimi**

Eğitim sürecinin amacı, girdiler ve çıktı arasındaki model ve ilişkiyi öğrenmektir. Bu eşsiz yapı öğrenme için, bilgiyi gizli düğümler ve bağlantı ağırlıklarına göre kategorize eder. 1950'lerde Kolmogorov'un kanıtladığı matematik teoremine göre çalışma sürecindeki doğru eşleşmeler yakınsama olarak adlandırılır. Bu 1980'lerin sonlarında Hecht-Nielsen tarafından geri yayımlı sinir ağları ve 1990'ların başlarında Lacher tarafından Cascor sinir ağları için yeniden düzenlenmiştir. Ağ,

yapay sinir ağlarının eğitildiği veri için kusursuz eşleştirmeleri nasıl yapacağını eninde sonunda anlayacaktır ( Coats and Fant, 1993: 5-6).

Ağ, geçmiş dönem ile ilgili çeşitli girdi-çıkıtı değerlerine sahip olan veriyi kullanıp eğitilerek girdilerle çıkıtı arasındaki ilişkiyi öğrenmektedir. Eğitim sürecinde, bir eğitim algoritması kullanılarak öngörüm hatalarının minimuma indirilmesine olanak veren ağırlıklar ayarlanmaktadır. Yani, eğitim için gereken girdi ve çıkıtının yanında ayrıca hata tanımı ve eğitim kuralına da ihtiyaç duyulmaktadır. Eğitim kuralı, ağırlıkların sistematik biçimde hatayı minimuma indirgeyecek biçimde değiştirilmesi sürecidir. En yaygın olan ve MLP'ler tarafından en çok tercih edilen eğitim kuralı geri yayma (back propagation) algoritmasıdır. Geri yayma esnasında ağa yeni veri girildikçe eğitim yapılmaktadır. Çıkıtlar ileriye doğru giderken, ağırlık ayarlamaları sonucunda elde edilen hata ise geriye yollanır. Ağ, bir veri kalıbıyla ilk kez karşılaşması esnasında ağı anlamaya ve tanımaya çalışırken ağırlıkları rastgele atamaktadır. Elde ettiği çıkıtıyı gerçek değerle karşılaştırır ve ağırlıklarda bu duruma göre gerekli ayarlamaları yapar (Tektaş ve Karataş, 2004: 5).

## 2.10. Veri Normalleştirme

Elde edilmiş olan verileri düzgün bir aralıkta (0,1) ölçeklendirmek esastır. Özellikle gerçek verilerin büyük değerler alması durumunda geçerlidir. Normalleştirme için standart bir prosedür yoktur. Transfer fonksiyonunun aralığına karşılık gelen  $[\lambda_1, \lambda_2]$  aralığında giriş ve çıkış değişkenlerini ( $z_i$ ) ölçeklendirmenin (normalleştirmenin) bir yolu denklemde (2.7) gösterilmektedir.

$$x_i = \lambda_1 + (\lambda_2 - \lambda_1) \left( \frac{z_i - z_i^{min}}{z_i^{max} - z_i^{min}} \right) \quad (2.6)$$

Buradaki  $x_i$ ,  $z_i$ 'nin normalize edilmiş değeridir ve  $z_i^{min}$  ve  $z_i^{max}$  değerleri veritabanındaki  $z_i$ 'lerin maksimum ve minimum değeridir. Verilerin, sigmoid fonksiyonunun doyunluğunu önlemek için 0 ile 1 arasında değil, 0.1 ve 0.9 gibi hafif ofset değerler arasında normalleştirilmesi önerilir. Son derece geniş bir aralıktaki parametreler için, normalleşmeden önce logaritmayı almak yararlı olabilir. Eğer veri sıfır içeriyorsa,  $\log(z_i+1)$  kullanılabilir (Basheer ve Hajmeer, 2000: 19).

## 2.11. Ağ Yapısının Seçimi

Yapay sinir ağları içerisinde farklı ağ yapıları ve modelleri bulunmaktadır. Yapay sinir ağı, bir dizi sinir hücresinin ileri sürümlü ve geri beslemeli bağlantı şekilleriyle birbirlerine bağlanmasından oluşmaktadır. Ağ yapısı belirleme süreci, ağın kaç katmandan oluşacağını, her katmanda kaç işlem elemanı bulunacağını, bu işlem elemanlarının hangi transfer fonksiyonuna sahip olacağını tespiti işlemlerini kapsamaktadır. Yapılan çalışmalar detaylı incelendiğinde genelde tek gizli katmanı bulunan ağ yapılarının tercih edildiği, gizli katman içerisinde farklı nöron sayılarının yer aldığı, çıkış katmanında doğrusal aktivasyon fonksiyonun, gizli katmanda ise sigmoid aktivasyon fonksiyonunun kullanıldığı görülmüştür (Kaynar ve Taştan, 2009: 166).

Bir ağ içerisindeki bütün katmanların aktivasyon fonksiyonları birbirlerinden farklı olabilmektedir. Aktivasyon fonksiyonlarında doğrusal fonksiyonlar genellikle tercih edilmemektedir. Zaman serileri için “Sigmoid”, ikili (binary) değişkenler için “Adım” fonksiyonları önerilmektedir. En sık kullanılan aktivasyon fonksiyonları ise şunlardır: Doğrusal, adım, esik değer, hiperbolik tanjant ve sigmoid (Asilkan ve Irmak, 2009: 381).

## 2.12. Öğrenme Algoritmasının Seçimi

Bir ağın, veri yapısı içerisindeki ilişkiyi öğrenebilmesi, problemle ilgili örnekler vasıtasıyla ağ ağırlıklarının en uygun değerlerinin belirlenmesi işlemine dayanmaktadır. Herhangi bir ağırlığın alacağı yeni değer, eski değer ve ağırlık değerlerinin değişim miktarının ( $\Delta W$ ) toplamı olarak belirlenmektedir ( $W_{\text{yeni}} = W_{\text{eski}} + \Delta W$ ). Belirli bir kuralla hesaplanan değişim miktarını ( $\Delta W$ ) belirleyebilmek adına yapılan tanımlamalara “öğrenme algoritmaları” denmektedir (Asilkan ve Irmak, 2009: 381).

Yapay sinir ağlarının parametrelerinin güncellenmesi adına kullanılan hatayı geriye yayma yöntemi, literatürde en sık kullanılan yöntemdir. Ses tanıma problemlerinden lineer olmayan sistem tanılama ve denetimi problemlerine kadar yapay sinir ağlarıyla çözüm üretilen çoğu alanda başarıyla kullanılmakta olan bu yöntem, quadratik bir maliyet fonksiyonunun zaman içinde, ağ parametrelerinin

uyarlanmasıyla en düşük düzeye indirgenmesine dayanmaktadır (Fırat ve Güngör, 2004: 3274).

### **2.13. Gizli Katman Sayısının Belirlenmesi**

YSA tasarımımda 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: 70).

### **2.14. Nöron Sayısının Belirlenmesi**

YSA yapısal özelliklerinden bir diğeri ise her katmanda bulunan nöronların sayısıdır. Doğru nöron sayısının bulunması için kullanılan diğer bir yöntem ise ara katman sayısının belirlerken kullanılan deneme yanılma yöntemidir. Nöron sayısının az olması yapay sinir ağında genelleme yeteneğini artırır fakat buna rağmen fazla sayıda nöron sayısına oranla daha fazla tercih edilir. Çünkü çok sayıda nöron sayısı ağın verileri ezberlemesine sebep olur (Atasoy, 2012: 70).

Kaç dönemlik bir tahminde bulunulacağına bağlı olarak çıkış nöron miktarı belirlenmektedir. Girişte ihtiyaç duyulan nöron sayısının belirlenmesi işlemi çıkış nöron sayısının belirlenmesi gibi kolay olmamaktadır. Çünkü serinin t zamandaki değerinin geçmişte kaç gözlem değerinden etkilendiğinin tespiti önem arz etmektedir ve bu duruma bağlı olarak girdi işlem elemanı sayısı da saptanabilmektedir (Kaynar ve Taştan, 2009: 165-166).

### **2.15. Yapay Sinir Ağlarının Eğitimi ve Testi**

Bu adımın amacı, yapay sinir ağlarının herhangi bir girdi vektörü için çıktı vektörünü genelleştirebilmesini sağlamaktır. Eğitim sırasında gösterilmeyen bazı gözlemleri test etmek bunu yapar. Ağın ezberlemediğini, girdi-çıkış ilişkisini genelleştirdiğini kanıtlıyor (Al-Saba and El-Amin, 1999: 190).

Yapay sinir ağının eğitimi için çok sayıda farklı optimizasyon yöntemi bulunmaktadır ve optimum sonucu garanti edebilen genel bir algoritma yoktur.

Ağın eğitiminde hatayı asgari düzeye indirebilmek adına genellikle, hata fonksiyonunun yönünü saptayabilmeye ve çıktı değerini azaltabilmeye çalışan dereceli azaltma (gradient descent) tabanlı algoritmalar kullanılmaktadır. Dereceli azaltma algoritmaları arasında en çok bilinen ve tercih edilen algoritma “Geri Yayılım Algoritması (GYA)”dır (Asilkan ve Irmak, 2009: 381).

Ağın eğitiminin tamamlanmasının ardından öğrenip öğrenmediğini belirlemek adına başvurulan denemelere ağın test edilmesi denilmektedir. Test işleminin gerçekleşebilmesi adına ağın öğrenme esnasında görmediği örneklerden yararlanılmaktadır. Ağ, eğitim esnasında belirlenen bağlantı ağırlıklarını kullanarak görmediği bu örnekler için çıktılar üretmektedir. Ulaşılan çıktılar doğruluk değerleri ağın öğrenmesi ile ilgili bilgi vermektedir. Elde edilen sonuçlara bağlı olarak eğitim performansının kalitesi de saptanabilmektedir, elde edilen sonuçlar ne kadar iyiyse eğitim performansının da o kadar iyi olduğu söylenebilmektedir (Akkaya vd., 2009: 194).

### **2.16. Durdurma Kriterinin Belirlenmesi**

Durdurma kriteri, hatanın belirli bir değerin altına düşmesi veya araştırmacıya göre belirlenen kabul edilebilir bir hatanın altına düşmesi durumunda ve ağın belirlenen iterasyon sayısını tamamlaması durumunda ağın eğitiminin durdurulması biçiminde olmak üzere iki şekilde belirlenebilir (Storm, 1997: 344).

### 3. GIDA SEKTÖRÜNDE TALEP TAHMİN YÖNTEMLERİ UYGULAMASI

Gıda sektöründe faaliyet gösteren firmada yapılan uygulamada Chandler türü ithal iç ceviz ele alınmıştır. Ceviz sofralarımızda oldukça önemli bir yere sahiptir. Tatlı sektörünün vazgeçilmezi olmasının yanı sıra ham haliyle de tüketimi oldukça fazladır. Diyet programlarının adeta vazgeçilmezi olan ceviz her kesimden tüketiciler için takviye gıda olarak tüketilmektedir.

İsminin gizli tutulmasını isteyen şirket başta Marmara bölgesi olmak üzere tüm Türkiye'ye satış yapmaktadır. Ele aldığımız şirket bu ürünün ithalatçısı konumundadır. Ceviz saklanması oldukça zahmetli bir ürün olmasının yanı sıra beklemesi halinde ise kalite kaybı azımsanamayacak derecededir. Oldukça maliyetli olan bu ürün için talebe ilişkin tahminlerin önemini arttırmaktadır.

Şirket yöneticileri ve pazarlama çalışanları ile yapılan görüşmeler sonucunda talep bağımsız değişkenini etkileyen bağımsız değişkenler dolar kuru, müşteri sayısı, enflasyon, rakip sayısı ve fiyat olarak belirlendi.

#### 3.1. Regresyon Yöntemi

Regresyon yöntemi, bağımsız değişken ya da değişkenlerin aldığı değerler karşısında bağımlı değişken değerinin kurulan regresyon modeline göre hesaplanarak tahmin edilmesi işlemidir (Sarı, 2014: 1).

Şirketin ERP sisteminden alınan veriler SPSS 20.0 programı kullanılarak çoklu regresyon analizi yapılmıştır. Yapılan analiz sonucunda bağımlı ve bağımsız değişkenlerin ortalamaları ve standart sapmaları hesaplanmıştır.

Çizelge 3.1: Regresyon Analizi Betimleyici İstatistikler Tablosu

	Talep	Fiyat	Kur	Müşteri	Enflasyon	Rakip
Ortalama	2275,5	38,74	2,69	111,4	8,27	16,08
Standart Sapma	1580,35	6,51	,64	11,76	,83	3,84



Bağımlı değişken olan talebin standart sapması 2275,5, ortalaması 1580,35 olarak hesaplanmıştır. Kur değişkeni standart sapması 0,64, ortalaması 2,69, enflasyon değişkeni standart sapması 0,83, ortalaması 8,27, rakip değişkeni standart sapması 3,84 ortalaması 16,08, müşteri değişkeni standart sapması 11,76, ortalaması 111,4, fiyat değişkeni standart sapması 6,51, ortalaması 38,74 olarak hesaplanmıştır.

Çizelge 3.2: Regresyon Analizi Özet Tablosu

Model	R	R Kare	Düzeltilmiş R Kare
1	,662	,438	,386
2	,661	,437	,396
3	,657	,432	,401

Oluşturulan çoklu regresyon modelinde anlamlı çıkmayan bağımsız değişkenler backward yöntemiyle modelden çıkarılmıştır. Modelden 2 bağımsız değişken çıkarılmış olup bu değişkenler rakip ve enflasyon bağımsız değişkenleridir. Modelde yer alan bağımsız değişkenlerin kur, müşteri ve fiyat bağımsız değişkenlerinin bağımlı değişkeni açıklama oranı %40,1 olarak hesaplanmıştır.

Çizelge 3.3: Regresyon Analizi Anova Tablosu

Model		Ortalama Kare	F	Sig.
Model 1	Regresyon	12903686,53	8,412	,000
	Artıklar	1533982,45		
Model 2	Regresyon	16106781,59	10,683	,000
	Artıklar	1507751,98		
Model 3	Regresyon	21202261,47	14,178	,000
	Artıklar	1495476,8		

Oluşturulan istatistiksel olarak anlamlı modelin F değeri 14,178 olarak hesaplanmış olup anlamlılık değeri ise 0,000 olarak hesaplanmıştır. Bu değerler bize modelin

istatistiksel olarak anlamlı olduğunu ve kullanılabilirliğini göstermektedir. Modelin artık kareler toplamı 83746700,604 olarak hesaplanmış buna bağlı olarak MSE değeri 1495476,797 olarak hesaplanmıştır.

Çizelge 3.4: Regresyon Modeli Katsayı Tablosu


Model		Sabit	Fiyat	Kur	Müşteri	Enflasyon	Rakip
1	Katsayı	-12659,999	230,266	-1613,017	108,496	-229,607	10,74
	Sig	,003	,013	,023	,000	,453	,808
2	Katsayı	-12385,418	224,525	-1579,477	108,091	-220,507	-
	Sig.	,002	,012	,022	,000	,464	-
3	Katsayı	-13078,253	183,776	-1362,275	106,861	-	-
	Sig.	,001	,007	,026	,000	-	-

Oluşturulan çoklu regresyon modelindeki istatistiksel olarak anlamlı olmayan bağımsız değişkenler modelden backward yöntemiyle çıkarılmıştır. Model 3 adımda oluşturulmuş olup ilk aşamada bütün bağımsız değişkenler yer almaktadır. 2. aşamada rakip bağımsız değişkeni çıkarılarak tekrar kurulmuştur. Rakip ve enflasyon bağımsız değişkenleri istatistiksel olarak anlamlı bulunamamış olmasına rağmen rakip değişkeninin significance değeri daha yüksek olması modelden ilk onun atılmasına neden olmuştur.

Elde edilen çoklu regresyon modeli sabit ve bağımsız değişkenlerden kur, müşteri ve fiyat olarak oluşmuştur. Sabit terimin katsayısı -13078,25, kur değişkeninin katsayısı -1362,28, müşteri değişkeninin katsayısı 106,86, fiyat değişkeninin katsayısı 183,78 olarak hesaplanmıştır.

$$Talep = -13078,25 - 1362,28 Kur + 106,86 Müşteri Sayısı + 183,78 Fiyat \quad (3.1)$$

3.1'deki denklem ile hesaplanan talep değerlerinin hataları MSE 3831146, MAPE 143,02 olarak hesaplanmıştır.




Şekil 3.1: Regresyon Modeliyle Tahmin Edilen Değerler İle Gerçek Değerlerin Grafiği

Regresyon modeli ile tahmin edilen değerler ve gerçek değerlerin yer aldığı grafik şekil 3.1'de gösterilmiştir. Modelin açıklayıcılık açısından düşük değerlere sahip olması modelin ortaya çıkardığı tahmin sonuçlarını açıklar niteliktedir.


### 3.2. Hareketli Ortalamalar Yöntemi

Hareketli ortalamalar sık kullanılan talep tahmin yöntemlerinden bir tanesidir. Bu bölümde elimizde bulunan aylık ortalama ceviz talebine ilişkin veriler için hareketli ortalamalar yöntemiyle tahmin yapılacaktır. Yapılacak olan tahminler için şirketin ERP sisteminden alınan veriler Minitab 15.0 programında işlenerek tahminler yapılacaktır.



Şekil 3.2: 3'lü Hareketli Ortalama Grafiği

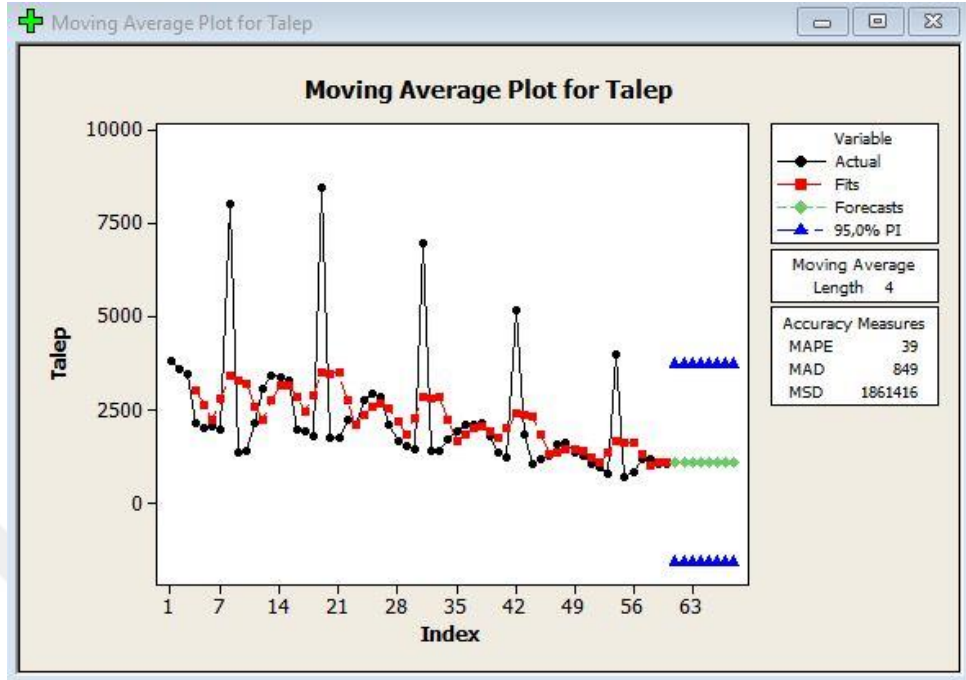
3'lü Hareketli ortalama ile yapılan analizde MAPE değeri 38, MSE 1712108 olarak hesaplanmıştır. Bu yöntemle 8 dönemlik tahmin yapılmış olup bu tahminlere ait MAPE değeri 29, MSE değeri ise 1521263 olarak hesaplanmıştır.



Şekil 3.3: 3'lü Hareketli Ortalama Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Değerlerinin Grafiği


Şekil 3.3'de 3'lü hareketli ortalamalar yöntemiyle hesaplanan tahmin değerleri ile gerçek değerler aynı grafikte gösterilmektedir. Bir sonraki dönem için sağladığı

tahmin tutarlılığını sonraki dönemler için göstermediği görülmektedir. Birden fazla dönem için bu model ile tahmin bu çalışma için yetersiz kalacaktır.




Şekil 3.4: 4'lü Hareketli Ortalama Grafiği

4'lü Hareketli ortalama ile yapılan analizde MAPE değeri 39, MSE 1861416 olarak hesaplanmıştır. Bu yöntemle 8 dönemlik tahmin yapılmış olup bu tahminlere ait MAPE değeri 29,06, MSE değeri ise 1519542 olarak hesaplanmıştır.




Şekil 3.5: 4'lü Hareketli Ortalama Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Değerlerinin Grafiği

Şekil 3.5’de gösterilen grafikte 4’lü hareketli ortalamalar yöntemiyle hesaplanan tahmin değerleri ile gerçek değerler aynı grafikte gösterilmektedir. Bir sonraki dönem için sağladığı tahmin tutarlılığını sonraki dönemler için göstermediği görülmektedir. Bu noktada birden fazla dönem için bu model ile tahmin bu çalışma için yetersiz kalacaktır.



Şekil 3.6: 6’lı Hareketli Ortalama Grafiği

6’lı Hareketli ortalama ile yapılan analizde 60 adet veri kullanılmış olup bu 60 verinin MAPE değeri 41, MSE 1999546 olarak hesaplanmıştır. Bu yöntemle 8 dönemlik tahmin yapılmış olup bu tahminlere ait MAPE değeri 35,08, MSE değeri ise 1412513 olarak hesaplanmıştır.

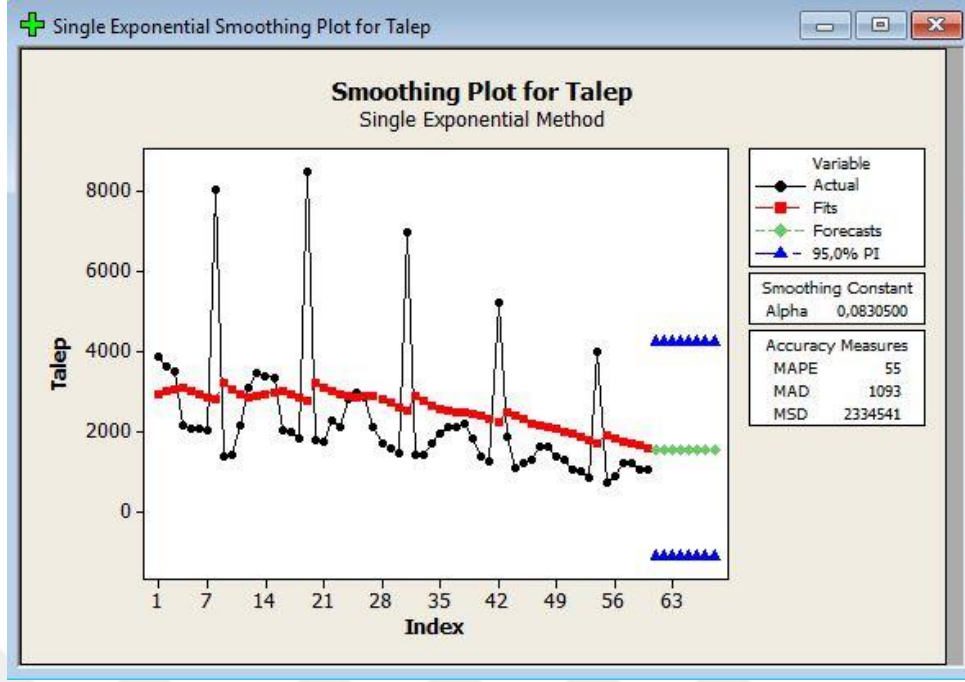


Şekil 3.7: 6'lı Hareketli Ortalama Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Değerlerinin Grafiği

Şekil 3.7'de gösterilen grafikte 6'lı hareketli ortalamalar yöntemiyle hesaplanan tahmin değerleri ile gerçek değerler aynı grafikte gösterilmektedir. Bir sonraki dönem için sağladığı tahmin tutarlılığını sonraki dönemler için göstermediği görülmektedir. Bu noktada birden fazla dönem için bu model ile tahmin bu çalışma için yetersiz kalacaktır.


### 3.3. Üstel Düzeltme Yöntemleri

Bu bölümde elimizde bulunan aylık ortalama ceviz talebine ilişkin veriler için üstel düzeltme yöntemleriyle tahmin yapılacaktır. Şirketin ERP sisteminden alınan veriler Minitab 15.0 programına aktarılarak tahmin modelleri oluşturulacak ve tahminler yapılacaktır.



Şekil 3.8: Tekli Üstel Düzeltme Yöntemi Grafiği

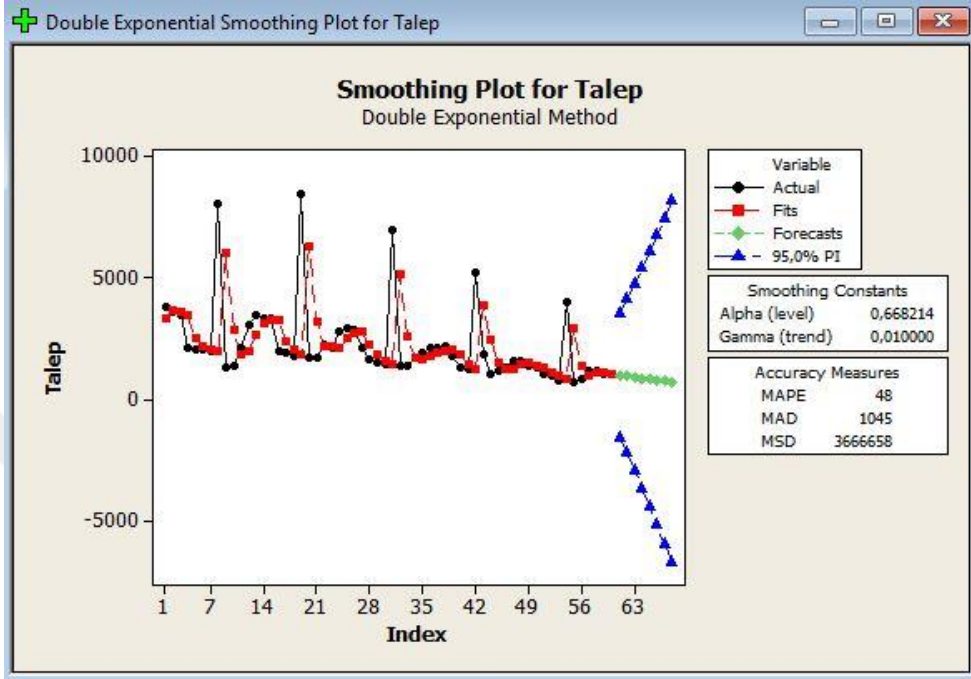
*Tekli üstel düzeltme yöntemi* tekli üstel düzeltme yöntemi modeli kurulmuş ve tahmin yapılmıştır. Modelin kurulması esnasında ortaya çıkan hata değerlerinden olan MAPE değeri 55, MSE değeri ise 140072528,9 olarak hesaplanmıştır. Toplamda 68 veriden oluşan veri setinin 60 adet verisi ile model kurulmuş ve hata terimleri hesaplanmıştır. Kalan 8 adet veri ise modelin tahmin ettiği değerler ile karşılaştırılmış ve hata değerleri hesaplanmıştır. Bu hesaplamalar sonucu MAPE değeri 54,78, MSE değeri 1350848 olarak bulunmuştur.



Şekil 3.9: Tekli Üstel Düzeltme Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Talep Değerlerinin Grafiği




Tekli üstel düzeltme yöntemi ile hesaplanan değerler ile gerçek talep değerleri şekil 3.9'daki grafikte gösterilmiştir. Bu modelin ilk dönem tahmini sonraki dönemlerle de aynı düzeyde seyretmiştir. Bu açıdan birden fazla dönem için bu model ile tahmin bu çalışma için yetersiz kalacaktır.



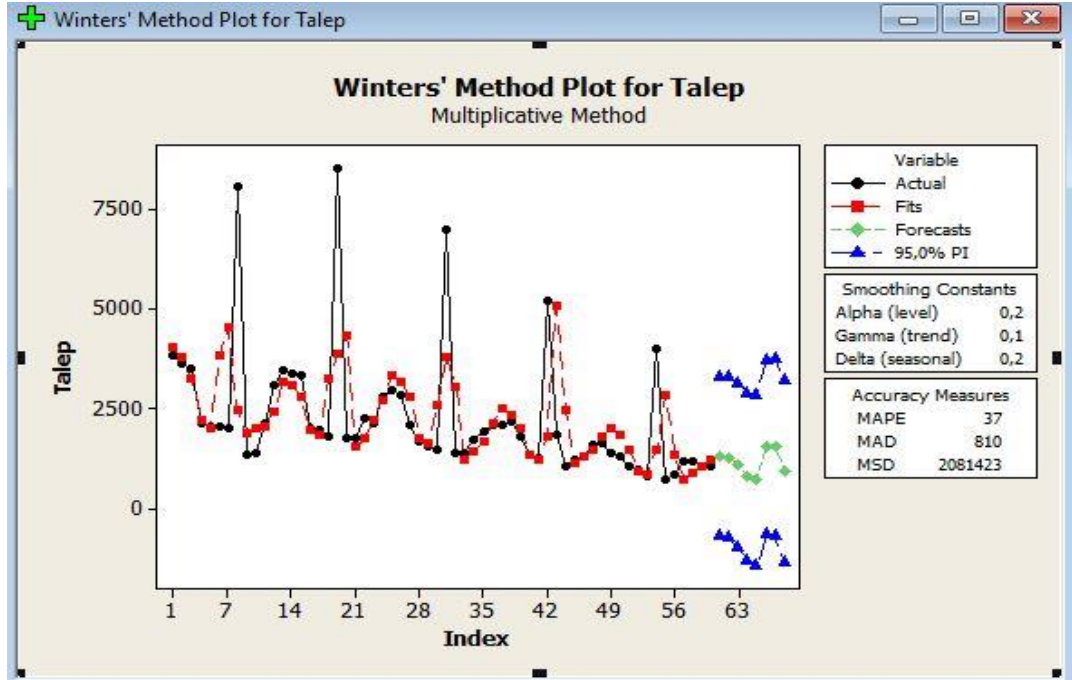
Şekil 3.10: 2'li Üstel Düzeltme Yöntemi Grafiği

2'li üstel düzeltme yöntemi 2'li üstel düzeltme yöntemi modeli kurulmuş ve tahmin yapılmıştır. Modelin kurulması esnasında ortaya çıkan hata değerlerinden olan MAPE değeri 48, MSE değeri ise 219999474,3 olarak hesaplanmıştır. Toplamda 68 veriden oluşan veri setinin 60 adet verisi ile model kurulmuş ve hata terimleri hesaplanmıştır. Kalan 8 adet veri ise modelin tahmin ettiği değerler ile karşılaştırılmış ve hata değerleri hesaplanmıştır. Bu hesaplamalar sonucu MAPE değeri 25,62, MSE değeri 1819814 olarak bulunmuştur.




Şekil 3.11: 2'li Üstel Düzeltme Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Talep Değerlerinin Grafiği

2'li üstel düzeltme yöntemi ile hesaplanan değerler ile gerçek talep değerleri şekil 3.11'deki grafikte gösterilmiştir. Trende dayalı tahmin yapan bu model, ilk tahmininden sonra azalan bir eğilim göstermiş bir noktada tutarlı tahminde bulunsa da bu durumun sebebinin serinin azalan eğilimi nedeniyle bu şekilde sonuçlar verdiği düşünülmektedir ve bu durumun modelin duyarlılığından ziyade serinin azalan trendine bağlı olarak şekillendiği söylenebilir.



Şekil 3.12: Winters' Üstel Düzeltme Yöntemi Grafiği

*Winters' üstel düzeltme yöntemi* Winters' üstel düzeltme yöntemi modeli kurulmuş ve tahmin yapılmıştır. Modelin kurulması esnasında ortaya çıkan hata değerlerinden olan MAPE değeri 37, MSE değeri ise 124885474,6 olarak hesaplanmıştır. Toplamda 68 veriden oluşan veri setinin 60 adet verisi ile model kurulmuş ve hata terimleri hesaplanmıştır. Kalan 8 adet veri ise modelin tahmin ettiği değerler ile karşılaştırılmış ve hata değerleri hesaplanmıştır. Bu hesaplamalar sonucu MAPE değeri 28,83, MSE değeri 1222917 olarak bulunmuştur.



Şekil 3.13: Winters' Üstel Düzeltme Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Talep Değerlerinin Grafiği

Winters' üstel düzeltme yöntemiyle kurulan model yardımıyla hesaplanan değerler ile gerçek talep değerleri şekil 3.13'deki grafikte gösterilmiştir. Model, bir noktada gerekli tepkiyi vererek yükseliş trendinin olduğu noktada bir yükselme eğilimi gösterse de gözlenen aykırı değeri hesaplama yetersiz kalmıştır.

### 3.4. Yapay Sinir Ağları İle Talep Tahmin Yöntemi

#### 3.4.1. Değişkenlerin Tanımlanması

Satış ve pazarlama ekibi ile yapılan görüşmeler ile ceviz talebini etkileyen çok sayıda bağımsız değişken olduğu belirlenmiş olup bu değişkenler hakkında sayısal veri veya aylık sayısal veri elde etmek pek mümkün değildir.

Uygulamanın bağımlı değişkeni aylık ceviz talebi miktarıdır. Satış ve pazarlama ekibi ile yapılan görüşmeler ile ithal ceviz talebini etkileyen bağımsız değişkenler ise şunlardır:

- Satış fiyatı ortalaması
- Rakip firma sayısı
- Müşteri sayısı
- Dolar kuru ortalaması (Aylık)
- Enflasyon

Uygulamada kullanılan verilerden kur ve enflasyon verileri hariç diğer veriler firma tarafından verilmiştir. Gizlilik politikası gereği gerçek değerler paylaşılmamış olup gerçeğe yakın değerlerin verildiği ifade edilmiştir. Hesaplamalar söz konusu verilere göre yapılmıştır.

*Aylık Ortalama Ceviz Talebi Miktarı* çizelge 3.5’de verilmiştir. Ceviz talebine ilişkin değerler 2013-2018 yılları arasında aylık olarak verilmiş olup kilogram cinsindedir.

Çizelge 3.5: Aylık Ortalama İthal Ceviz Talebi

Aylar	2013	2014	2015	2016	2017	2018
Ocak	3850	3450	2950	2100	1380	1250
Şubat	3620	3370	2850	2180	1300	1170
Mart	3500	3320	2110	1820	1050	1040
Nisan	2150	2000	1680	1350	980	840
Mayıs	2050	1960	1550	1250	810	790
Haziran	2070	1800	1450	5210	4000	4500
Temmuz	2000	8500	7000	1840	720	820
Ağustos	8050	1760	1400	1060	850	1600
Eylül	1350	1750	1400	1200	1190	
Ekim	1400	2250	1700	1300	1180	
Kasım	2150	2120	1920	1600	1040	
Aralık	3100	2780	2100	1620	1040	

*Pazarda Faaliyet Gösteren Rakip Firma Sayısı* çizelge 3.6’de verilmiştir. Firmanın faaliyet gösterdiği pazarda faaliyette bulunan rakip sayısı aylık olarak verilmiştir. Firma pazardaki rakip sayısında değişmeyi pazara olan ilgi ile açıklamaktadır.

Çizelge 3.6: Pazarda Faaliyet Gösteren Rakip Sayısı

Aylar	2013	2014	2015	2016	2017	2018
Ocak	13	14	15	15	13	14
Şubat	14	16	15	15	13	13
Mart	14	14	15	15	13	10
Nisan	14	14	15	15	13	10
Mayıs	14	14	15	15	13	13
Haziran	14	16	19	21	13	14
Temmuz	16	16	14	18	11	10
Ağustos	20	22	15	14	11	10
Eylül	22	22	26	16	17	
Ekim	20	27	33	17	17	
Kasım	14	16	15	15	16	
Aralık	14	15	16	15	16	

*Aylık Satış Yapılan Müşteri Sayısı* çizelge 3.7’de verilen müşteri sayıları gizlilik gereği gerçeğe yakın değerlerdir. Müşteri sayısındaki değişimleri ve müşteri talepleri çeşitlilik göstermekte olduğu belirtilmiştir.

Çizelge 3.7: Aylık Satış Yapılan Müşteri Sayısı

Aylar	2013	2014	2015	2016	2017	2018
Ocak	125	125	120	113	100	102
Şubat	125	120	118	113	100	100
Mart	125	115	115	110	100	99
Nisan	125	106	110	105	95	83

Mayıs	117	106	108	105	90	76
Haziran	120	106	127	117	112	97
Temmuz	120	130	127	115	80	70
Ağustos	120	123	102	102	99	102
Eylül	100	125	112	108	90	
Ekim	100	115	112	107	90	
Kasım	125	115	120	113	89	
Aralık	125	125	120	113	89	

*Aylık Ortalama Ceviz Fiyatı* çizelge 3.8’de verildiği gibidir. Söz konusu satış fiyatı, firmanın toptan satış fiyatları olup gerçeğe yakın değerlerdir.

Çizelge 3.8: Aylık Ortalama Ceviz Fiyatı

Aylar	2013	2014	2015	2016	2017	2018
Ocak	32	34	35,50	38	48	62
Şubat	32	34	35,50	38	48	62
Mart	32	34	35,50	38	48	62
Nisan	32	34	35,50	38	48	66
Mayıs	32	34	35,50	38	50	68
Haziran	32	36	37	40	50	68
Temmuz	34	36	37	40	52	70
Ağustos	34	36	37	40	52	75
Eylül	34	35	37	40	52	
Ekim	33	35	36	40	52	
Kasım	34	35	36	40	54	
Aralık	33	34	36	42	54	

*Ortalama Enflasyon* çizelge 3.9’da 12 aylık ortalama tüketici fiyat endeksi yer almaktadır. Veriler, Bütçe ve Mali Kontrol Genel Müdürlüğü Sitesinden alınmış gerçek değerlerdir.

Çizelge 3.9: 12 Aylık Ortalama Enflasyon (TÜFE)

Kaynak: Bütçe ve Mali Kontrol Genel Müdürlüğü

Aylar	2013	2014	2015	2016	2017	2018
Ocak	8,62	7,53	8,8	7,87	7,78	11,14
Şubat	8,33	7,6	8,77	7,97	7,76	11,23
Mart	8,08	7,7	8,7	7,96	7,88	11,23
Nisan	7,66	7,97	8,57	7,84	8,21	11,14
Mayıs	7,51	8,23	8,45	7,71	8,66	11,06
Haziran	7,47	8,31	8,28	7,74	9,09	11,1
Temmuz	7,47	8,35	8,07	7,91	9,36	11,49
Ağustos	7,42	8,46	7,88	7,98	9,44	12
Eylül	7,32	8,54	7,8	7,92	9,66	12,61
Ekim	7,32	8,65	7,69	7,89	9,98	
Kasım	7,39	8,8	7,61	7,79	10,37	
Aralık	7,49	8,85	7,67	7,78	10,87	

*Ortalama Dolar Kuru* çizelge 3.10’da aylık ortalama dolar kuru verileri yer almaktadır. Söz konusu cevizin ithal olması dolar kurunun etkisini anlamlı kılmaktadır. Veriler, Bütçe ve Mali Kontrol Genel Müdürlüğü Sitesinden alınmış gerçek değerlerdir.

Çizelge 3.10: Aylık Ortalama Dolar Kuru

Kaynak: Bütçe ve Mali Kontrol Genel Müdürlüğü

Aylar	2013	2014	2015	2016	2017	2018
Ocak	1,764	2,217	2,328	3,007	3,735	3,772
Şubat	1,77	2,213	2,455	2,941	3,672	3,778
Mart	1,807	2,218	2,584	2,892	3,666	3,881
Nisan	1,796	2,127	2,648	2,835	3,654	4,054
Mayıs	1,823	2,091	2,646	2,927	3,564	4,414
Haziran	1,895	2,116	2,701	2,917	3,519	4,628
Temmuz	1,93	2,119	2,695	2,958	3,56	4,748
Ağustos	1,955	2,158	2,846	2,963	3,512	5,73
Eylül	2,017	2,204	3,003	2,96	3,468	
Ekim	1,99	2,258	2,93	3,068	3,662	
Kasım	2,022	2,234	2,871	3,267	3,879	
Aralık	2,058	2,288	2,917	3,489	3,848	

Toplanan veriler excel ortamında gözden geçirildikten sonra Matlab R2019a programına aktarılmıştır. Şekil 3.14’te excel dosyasının Matlab programına aktarımı gösterilmektedir.



veriseti						
Kur	Enflasyon	Rakip	Mteri	Fiyat	Talep	
Number	Number	Number	Number	Number	Number	
1	Kur	Enflasyon	Rakip	Müşteri	Fiyat	Talep
2	1.7640	8.6200	13	125	32	3850
3	1.7700	8.3300	14	125	32	3620
4	1.8070	8.0800	14	125	32	3500
5	1.7960	7.6600	14	125	32	2150
6	1.8230	7.5100	14	117	32	2050
7	1.8950	7.4700	14	120	32	2070
8	1.9300	7.4700	16	120	34	2000
9	1.9550	7.4200	20	120	34	8050
10	2.0170	7.3200	22	100	34	1350
11	1.9900	7.3200	20	100	33	1400
12	2.0220	7.3900	14	125	34	2150
13	2.0580	7.4900	14	125	33	3100
14	2.2170	7.5300	14	125	34	3450
15	2.2130	7.6000	16	120	34	3370
16	2.2180	7.7000	14	115	34	3320
17	2.1270	7.9700	14	106	34	2000
18	2.0910	8.2300	14	106	34	1800
19	2.1160	8.3100	16	106	36	1800
20	2.1190	8.3500	16	130	36	8500
21	2.1580	8.4600	22	123	36	1760
22	2.2040	8.5400	22	125	35	1750

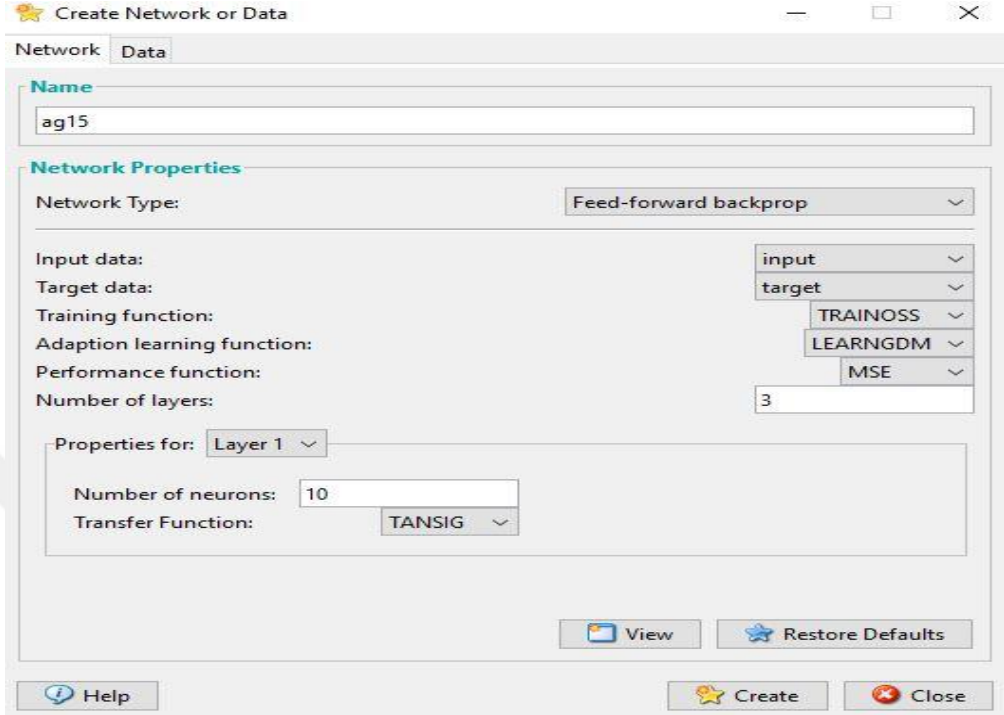
Şekil 3.14: Veri Setinin Matlab Programına Aktarımı

İçeride aktarılan veri setinin kullanıma uygun hale getirmek amacıyla çeşitli parçalara ayrılmıştır. 60 adet veri yapay sinir ağı eğitiminde kullanılmak amacıyla ayrılmıştır. Bağımsız değişkenleri olarak input tablosu, bağımlı değişken olan talep değerlerinden ise target tablosu oluşturulmuştur. Kalan 8 adet verinin bağımsız değişkenleri oluşturulan ağı simüle etmek için kullanılmak üzere test isimli bir tabloda toplanmıştır. Yapay sinir ağı oluşturmak için gerekli hazırlıklar yapılmıştır.

### 3.4.2. Modelin Tasarlanması

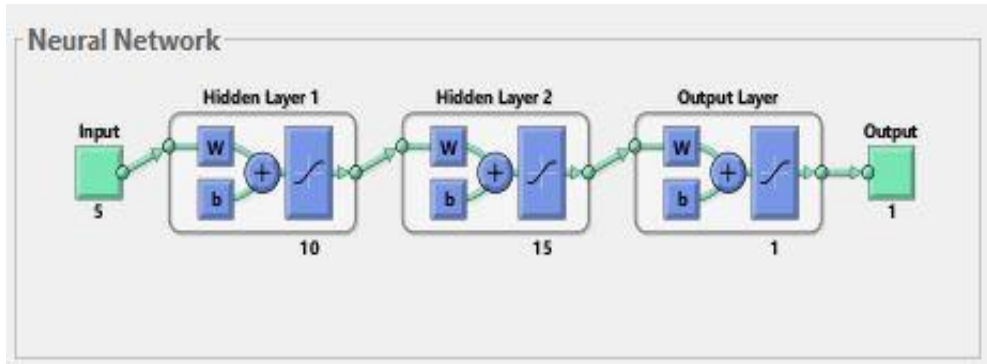
Uygulamada kullanılan ağı literatürde sıkça bahsedilen ileri beslemeli geri yayımlı yapay sinir ağı tercih edilmiştir. İleri beslemeli geri yayımlı yapay sinir ağının kullanım amacı tahmin çalışmalarında sıklıkla kullanılması ve tahminlerdeki başarısıdır. Yapay sinir ağı modeli Matlab R2019a programı kullanılarak oluşturulmuştur.

Şekil 3.15’de görüldüğü üzere modelin transfer fonksiyonu tanjant sigmoid, eğitim fonksiyonu trainoss kullanılmıştır. Performans fonksiyonu hata kareleri ortalaması (MSE), ortalama mutlak yüzde hata (MAPE) kullanılmıştır.



Şekil 3.15: Matlab Yapay Sinir Ağı Oluşturulması

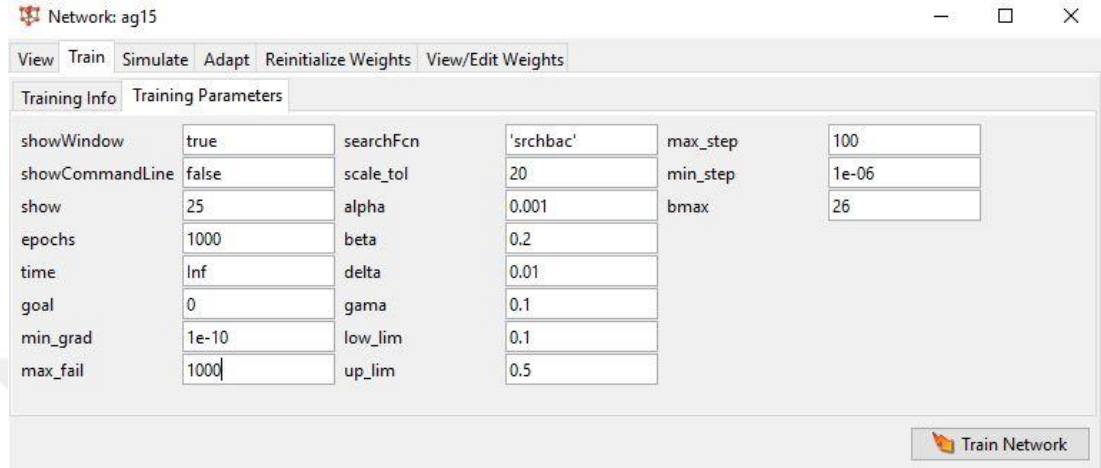
Çalışmada tasarlanan yapay sinir ağı modelinde, 5 girdi ve 1 çıktı değişkeni bulunmaktadır. Oluşturulan modelde şekil 3.16’da gösterildiği gibi, girdi katmanı, 2 gizli katman ve 1 çıktı katmanı bulunmaktadır. Gizli katman sayısı ve her katmanda yer alan nöron sayısı denemeler sonucunda belirlenmiştir.



Şekil 3.16: Yapay Sinir Ağı Modeli

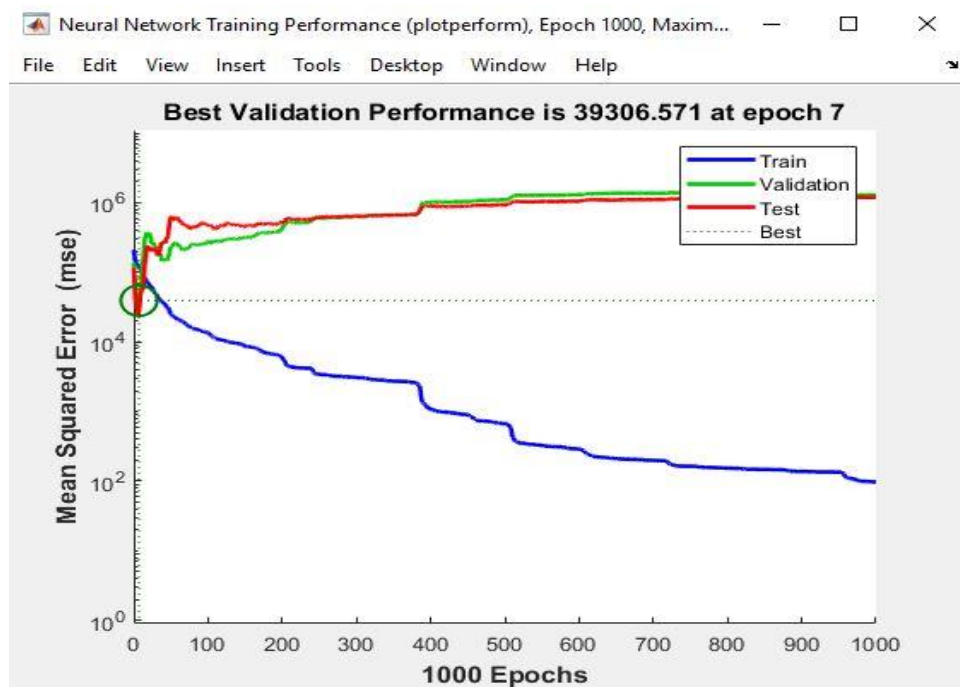
### 3.4.3. Talep Tahmin Uygulaması

Oluşturulan ağı eğitimi için çeşitli algoritma ve fonksiyonlar vardır. Bunlardan en uygun olanı deneme yanılma yöntemi ile bulunmuştur. Uygunluğu  $R^2$  değerinin en büyük olanı, MSE değerlerinin ise en küçük olması belirlemektedir.



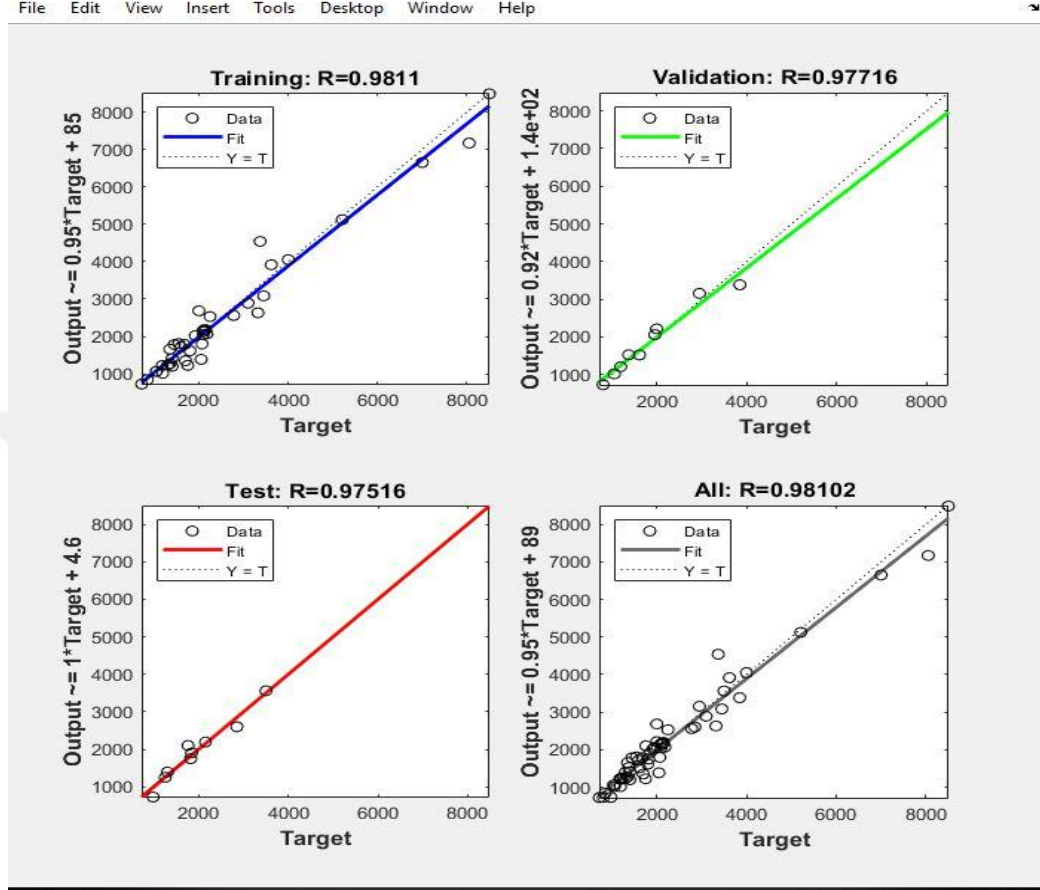
Şekil 3.17: Eğitim Algoritması Parametreleri

Trainoss eğitim algoritması ağırlık ve yanlılık değerlerini, kesişen her adımda güncelleyen algoritmadır. İterasyon sayısı 1000, maksimum doğrulama hatası 1000, alfa katsayısı 0,001, beta katsayısı 0,2, delta katsayısı 0,01, gamma katsayısı 0,1 ve diğer değerleri varsayılan olarak ağı eğitilmiştir.



Şekil 3.18: Yapay Sinir Ağı Eğitimi Performans Grafiği

Eđitimi tamamlanan ađ sonucunda ortaya performans grafiđi Őekil 3.18’de g3r3ld3đ3 zere 7 iterasyonda en iyi deđere ulaŐmıŐtır. Hen3z ezberleme yapmamıŐ olması genelleme yapması ađısından olumlu olacaktır.



Őekil 3.19: Ađ Eđitiminde Regresyon Deđerleri


Eđitilen ađın regresyon deđerleri Őekil 3.19’da g3r3lmektedir. Eđitim regresyon deđerinin 0,9811 gibi y3ksek bir deđere sahip olması eđitim aŐamasındaki baŐarıyı g3stermektedir. Regresyon deđerine 1’e ne kadar yakınsa s3z konusu aŐama o kadar baŐarılıdır. Dođrulama ve test aŐamalarındaki regresyon deđerleri de oldukça iyi olması ađın eđitim s3recinin baŐarılı geđtiđini g3stermektedir.

$R^2$  deđerine 1’e ne kadar yakınsa modelin ađıklama oranı o kadar iyidir. 0,9624 olan modelin ađıklama oranı oldukça iyi olup eđitim s3recinin baŐarısını teyit etmektedir.

Yapay sinir ađı modelinde eđitim esnasında 3retilen talep deđerleri Őizelge 3.11’de verilmektedir.

Çizelge 3.11: Eğitim Çıktıları

Aylar	2013	2014	2015	2016	2017
Ocak	3383,837	3082,883	3155,339	2048,331	1524,863
Şubat	3916,266	4539,802	2600,757	2068,727	1394,286
Mart	3560,687	2630,171	2127,93	1749,816	1067,04
Nisan	2179,821	2212,883	1783,272	1272,987	727,75
Mayıs	1385,167	2058,311	1807,359	1252,173	729,168
Haziran	1796,629	1614,472	1783,611	5121,837	4052,071
Temmuz	2683,862	8485,27	6649,021	1902,041	725,3835
Ağustos	7169,036	2102,9	1409,02	1017,911	844,9968
Eylül	1657,981	1225,384	1403,429	1206,338	1014,568
Ekim	1200,732	2529,722	1349,425	1234,529	1223,935
Kasım	2193,927	2177,439	2020,609	1718,388	1062,427
Aralık	2888,817	2559,085	2164,51	1520,141	1061,902



Şekil 3.20: YSA Çıktısı İle Gerçek Değerlerin Gösterimi

Ağ çıktıları ile gerçek değerleri aynı grafikte gösterimi şekil 3.20’de görülmektedir. Gerçek değerler ile ağ çıktısının arasındaki fark ağ çıktılarındaki başarıyı ortaya koymaktadır.

#### 3.4.4. Yapay Sinir Ağları Tahmin Sonuçları

Başlangıçta bulunan 68 adet veriden 60 adedi oluşturulan yapay sinir ağı modeli için kullanılmıştır. Kalan 8 adet veri ağı hiç gösterilmemiştir. Çizelge 3.12’deki bu veriler ile oluşturulan yapay sinir ağının tutarlılığının ölçülmesi hedeflenmektedir.

Çizelge 3.12: Ağın Tutarlılığı İçin Kullanılacak Veri Seti


Aylar	Kur	Enflasyon	Rakip	Müşteri	Fiyat	Talep
Ocak	3,772	11,23	14	102	62	1250
Şubat	3,778	11,23	13	100	62	1170
Mart	3,881	11,14	10	99	62	1040
Nisan	4,054	11,06	10	83	66	840
Mayıs	4,414	11,1	13	76	68	790
Haziran	4,628	11,49	14	97	68	4500
Temmuz	4,748	12	10	70	70	820
Ağustos	5,73	12,61	10	102	75	1600
Eylül	-	-	-	-	-	-
Ekim	-	-	-	-	-	-
Kasım	-	-	-	-	-	-
Aralık	-	-	-	-	-	-

Çizelge 3.12’deki kur, enflasyon, rakip, müşteri ve fiyat değişkenleri yapay sinir ağının girdi değerlerini oluşturacaktır. Eğitilmiş olan yapay sinir ağı modeline daha önceden ağın görmediği girdi değerleri girilerek gelecek 8 aya ilişkin talep tahmin edilmiştir. Çizelge 3.13’de gerçek değerler ile modelin tahmin ettiği talep değerleri ve arasındaki fark görülmektedir.

Çizelge 3.13: Tahminlenen Talep İle Gerçek Talep Arasındaki Fark

Aylar	Gerçek Talep	YSA Talebi	Fark
Ocak	1250	1264,144	-14,1436
Şubat	1170	1007,888	162,1123
Mart	1040	983,414	56,58597
Nisan	840	891,6171	-51,6171
Mayıs	790	868,6808	-78,6808
Haziran	4500	3831,623	668,3768
Temmuz	820	798,1723	21,8277
Ağustos	1600	1306,323	293,6771
Eylül	-	-	-
Ekim	-	-	-
Kasım	-	-	-
Aralık	-	-	-

Gerçekleşen talep ile modelin tahmin ettiği talebin grafiksel gösterimi şekil 3.21’de gösterildiği gibidir. Tahminlenen talep ile gerçek talep değerleri arasındaki farkın çok az olduğu açıkça görülmektedir. Talebi etkileyen çok fazla değişkenin bulunması ve ayrıca talep döneminin doğrusal olmayışı yapay sinir ağı modeli performansı hakkında oldukça olumlu görünmektedir.



Şekil 3.21: Tahminlenen Talep İle Gerçek Talep

### 3.5. Tahminlerin Hata Testleri ve Karşılaştırması

Uygulama sonuçlarını incelediğimizde, oluşturulan modeller yardımıyla yapılan tahminlerin hataları hesaplanmıştır. Hesaplanan hata terimleri MSE ve MAPE hata terimleridir. Hangi modelin daha iyi tahmin yaptığını hesaplanan hata terimlerine göre karar verebiliriz. Hangi modelin hata terimi daha küçük ise o model daha iyi tahmin yaptığı söylenebilir. Bu çalışmada kullanılan hata terimleri olan MSE ve MAPE değerleri formül (3.2) ve (3.3) yardımıyla hesaplanmaktadır.

$$MSE = \frac{\sum(G_t - T_t)^2}{n} \quad (3.2)$$

$$MAPE = \frac{\sum \frac{|G_t - T_t|}{G_t} * 100}{n} \quad (3.3)$$

$G_t$  = t. Dönemin gerçekleşen talep miktarı

$T_t$  = t. Döneme ait talep tahmini miktarı

$n$  = Kullanılacak dönemlerin sayısı (Top ve Yılmaz, 2009: 248).



Çizelge 3.14: Oluşturulan Modellerin Hata Terimleri Tablosu

<b>Yöntem</b>	<b>MSE</b>	<b>MAPE</b>
Regresyon	3831146,032	143,02
3'lü Hareketli Ortalama	1521262,514	29,006
4'lü Hareketli Ortalama	1519542,188	29,062
6'lı Hareketli Ortalama	1412512,5	35,075
Tekli Üstel Düzeltme	1350848	54,78
İkili Üstel Düzeltme	1819814	25,62
Winters' Metodu	1222917	28,83
Yapay Sinir Ağları	71498,462	9,05

Çizelge 3.14'de uygulamada oluşturulan modellerin hata terimlerini görebiliriz. Oluşturulan regresyon modeline ait MSE değeri 3831146,032 iken MAPE değeri 143 çıkmıştır.

Hareketli ortalamalardan 3, 4 ve 6'lı hareketli ortalamalar sonucunda tahmin modeli oluşturulmuştur. 3'lü hareketli ortalamalar yöntemi ile yapılan tahminin hataları MSE 1521262,514, MAPE 29,006 değerleri olarak hesaplanmıştır. 4'lü hareketli ortalamalar yöntemi ile yapılan tahminin hataları MSE 1519542,188 MAPE 29,062 değerleri olarak hesaplanmıştır. 6'lı hareketli ortalamalar yöntemi ile yapılan tahminin hataları MSE 1511412512,5 MAPE 35,075 değerleri olarak hesaplanmıştır.

Uygulamada kullanılan bir diğer yöntem olan üstel düzeltme yöntemlerinden tekli, ikili ve winters' üstel düzeltme yöntemleri kullanılmıştır. Kullanılan bu yöntemlerin hesaplanan hata terimleri çizelge 3.13'de verilmiş olup tekli üstel düzeltme yönteminin hesaplanan hata terimleri MSE 1350848 ve MAPE 54,78 olarak bulunmuştur. İkili üstel düzeltme yöntemi ise MSE 1819814 ve MAPE 25,62 sahip tahminler üretmiştir. Winters' metoduna ait tahminlerin hata terimi değerleri ise MSE 1222917 ve MAPE 28,83 olarak hesaplanmıştır.

Bir diğer yöntem olan yapay sinir ağlarına ait hata terimi değerleri de çizelge 3.14'de yer almaktadır. Yapay sinir ağının tahminine ilişkin hata terimi değerleri ise MSE

71498,462 ve MAPE 9,05 bulunmuştur. Yapay sinir ağı yöntemi diğer yöntemlerden açık ara daha iyi olduğunu hata terimlerinden görebilmekteyiz.



## SONUÇ VE ÖNERİLER

Günden güne değişen dünyamızda insan ihtiyaçları da değişmekte ve çeşitlenmektedir. Toplumlar önceleri fazla beklentisi olmayan, sahip olduklarıyla yetinen fazla seçeneği olmayan bir anlayışa sahiplerdi. Gelişen dünyada tüketici anlayışları hızla değişmekte ve dolayısıyla daha bilinçli ve bilinçlenmeye devam eden tüketicilerden oluşan bir toplumsal yapı oluşmaya başlamaktadır. Tüketici ihtiyaçları ise demografik, psikolojik, sosyokültürel, coğrafi ve tüketiciye sağladığı faydalara göre çeşitlilik göstermektedir. İhtiyaçları tespit edebilmek bu ihtiyaçlara göre ürün geliştirmek ya da mevcut ürünü talebe göre üretmek örgütler açısından büyük önem taşımaktadır.

Talep tüketicilerin belirli bir dönemde belirli bir fiyat üzerinden satın almayı istedikleri ürünlerin miktarı olarak tanımlanabilir. Bir başka deyişle tüketicilerin mevcut bir ürünü ya da üretilmesi planlanan bir ürüne ilişkin satın alma istekliliği olarak açıklanabilir. Günümüzde çeşitlenen insan ihtiyaçları, talebe yönelik değişkenlerde de çeşitliliğe neden olmaktadır. Talebe etki eden faktörlerin çoğalmas ve bu değişkenler arasındaki ilişkinin karmaşıklığı istatistiksel yöntemlere olan eğilimi arttırmıştır. İstatistiksel metotların başarısının, sezgisel metotların başarısına göre daha iyi sonuçlar verdiği literatürdeki araştırmalardan da görülebilmektedir.

Talep kavramı literatürde genellikle arz kavramı ile birlikte anılmaktadır çünkü tüketici ihtiyaçları talebi doğurmakta, talep edilen ürün ya da hizmetlerin sektörler aracılığıyla karşılanması süreci de arz kavramını karşımıza çıkarmaktadır. Arz kavramının arka planına bakıldığında ve temeline inildiğinde ise üretim kavramı ile karşılaşmak kaçınılmazdır. Üretim, doğada bulunan maddeleri insan ihtiyaçları doğrultusunda işleyerek mal veya hizmete dönüştüren faaliyetler bütünü olarak tanımlanabilir (Ballı, 2014: 1). Bir işletmenin; üretmesi gereken ürünleri belirlemesi, belirlenen ürünün üretim miktarı, üretimin nerede yapılacağı, maliyeti ve karı gibi soruların cevabı ancak üretim yönetimi uygulamaları ile bulunabilmektedir. Üretilecek olan ürünlerin planlanması yapılırken ürüne olan talep ve ürünün diğer

özellikleri de göz önünde bulundurulmalı, bir ürüne yönelik talep hakkında bilgi sahibi olunmadan üretim planlaması yapılmamalıdır.

Gelecekle ilgili değerlendirmeler yapabilme ve olası talep miktarları hakkında bilgi edinmeye çalışma faaliyetleri talep tahmin çalışmalarına kaynaklık etmektedir. Tahmin veya öngörü kavramı, geçmişten bugüne süregelen olaylardan yola çıkarak belirli dönem ya da dönemler için hesaplanmasıdır. Hesaplanan bu tahminlerin sürekli olarak değişen koşullara uyarlanarak güncellenmesi gerekmektedir. Bunun yanında, trend gibi mevsimsel etki durumları da göz önünde bulundurularak bu konuda uzman kişilerin görüşleriyle de tahminler harmanlanmalıdır. Görüldüğü üzere talep tahmin uygulamaları farklı yönleri ve özellikleri ile örgütler adına iyi analiz edilmesi gereken ve önemli faydalar sağlayabilecek fırsatlar sunabilmektedir.

Son yıllarda bilgisayar teknolojilerindeki gelişmeler yapay zeka kavramını hayatımıza sokmuş ve hayatımızın her alanında farklı yenilikler getirmiştir. Özellikle, insan beyninin çalışma prensibini model alan yapay sinir ağları yönteminin geliştirilmesi ise talep tahmin uygulamaları farklı bir boyuta taşınmıştır. Yapay sinir ağları insan beyni gibi öğrenme ve keşfetme özelliklerine sahip olması sayesinde öğrendiği bilgilerden yeni bilgiler türetebilen bir metottur ve yapay sinir ağlarında ele alınan problemin doğrusal olamayışı bir dezavantaj yaratmamakta aksine güvenilir sonuçlar vermesi bu tekniğin kullanımının giderek artmasına neden olmaktadır. Günümüzde en fazla kullanıldığı alanlar arasında; tahminleme, kümeleme ve sınıflandırma problemleri yer almaktadır.

Gıda sektöründe yapılan bu çalışmada ürün olarak yoğunlukla Amerika kıtasından ithal edilen Chandler cinsi iç ceviz ele alınmaktadır. Bahsi geçen firma bu ürünün ülkemizde ithalatçısı ve dağıtıcısı konumundadır. Şirketin satın alma ve pazarlama yöneticileri ile görüşülüp geçmiş 5 yıla ait satış rakamları alınmış ve talebi etkileyen faktörler belirlenmiştir. Veriler firmanın talebi doğrultusunda gerçek değerlere yakın değerler kullanılarak talep tahmin çalışması yapılmıştır.

Elde edilen veriler 5 bağımsız 1 bağımlı değişkenden içermektedir. Oluşturulan veri seti ile çoklu regresyon, 3'lü, 4'lü ve 6'lı hareketli ortalamalar, tekli, ikili ve winters' metodu üstel düzeltme yöntemleri ve yapay sinir ağları yöntemi ile talep tahmin modelleri kurulmuştur. Kurulan bu modeller ile yapılan tahminlerin hata terimleri incelenerek en uygun model belirlenmeye çalışılmıştır.

Çoklu regresyon modeli oluşturulurken iki bağımsız değişkenin katsayıları anlamsız çıkmış ve backward yöntemi ile regresyon modelinden çıkarılmıştır. Çıkarılan bağımsız değişkenler sonrasında bağımsız değişkenlerin bağımlı değişkeni açıklama oranı %40 olarak hesaplanmış ve oldukça düşük olduğu gözlenmiştir. MSE ve MAPE değerleri de bu modelin tahminlerinde diğer yöntemlere göre başarısız olduğunu göstermektedir. Verilerin dağılımı, mevsimsellik ve oto korelasyon hesaba katılmadığı için bu şekilde gerçekleşmiştir. İlerleyen süreçte yapılacak olan çalışmalarda parametrik olmayan regresyon tekniğinin ele alınması araştırmacılara farklı bir bakış açısı sağlayabilecektir.

Hareketli ortalama modelleri ile yapılan tahminler ise regresyon modeline göre daha düşük hata terimlerine sahip olsa da birden fazla dönemlik tahminler için bu modellerin yeterli olmadığı kabul edilmektedir.

Üstel düzeltme yöntemleri ile kurulan modellerde tekli üstel düzeltme yönteminin, hareketli ortalamalarla benzer sonuçlara sahip olması açısından ele almış olduğumuz şirket verileri için sağlıklı tahminler üretmediği görülmektedir. İkili üstel düzeltme yöntemi MAPE hata terimine bakıldığında diğer tekli üstel düzeltme ve winters' metoduna göre daha iyi bir performans sergilemektedir. Ancak MSE değerinin winters' metodundan düşük olması ve şekil 3.11'de görüldüğü üzere doğrusal azalan tahminler yapması serinin trendine göre tahmin yaptığını göstermektedir. Winters' metodu, MAPE değeri olarak ikili üstel düzelmeden daha düşük olmasına rağmen MSE değeri olarak tekli ve ikili üstel düzeltme yönteminden daha iyi bir değere sahiptir. Şekil 3.13'de görüldüğü üzere daha iyi bir sonuç verdiği görülebilmektedir.

Çalışmada kullanılan yapay sinir ağı 5 girdi ve 1 çıktı değişkeninden oluşmaktadır. Oluşturulan ağa 68 verinin 60 tanesi eğitim için kullanılmıştır. Ağın eğitimi başarı ile tamamlanmış ağın açıklama oranı %96,24 olarak hesaplanmıştır. 68 veriden kalan 8 veri ile yapay sinir ağına tahmin yaptırılmıştır. Elde edilen sonuçlar ile gerçek değerlerin farkından hesaplanan MAPE ve MSE değerlerine oranla çok düşük çıkmıştır. Tasarlanan bu modelin diğer yöntemlerden daha iyi sonuçlar verdiğini söyleyebiliriz. Şekil 3.21' görüldüğü üzere gerçek değerler ile tahmin değerleri arasındaki fark çok azdır.

Tüm bu sonuçlar ışığında yapay sinir ağları ile kurulan modelin; regresyon, 3'lü, 4'lü ve 6'lü hareketli ortalamalar ve tekli üstel düzeltme, ikili üstel düzeltme ve winters'

metodu üstel düzeltme yöntemlerinden bu çalışmada açık ara daha tutarlı tahminler yaptığı görülmektedir. Ayrıca çalışmada elde edilen model, şirketin bölgesel müşterileri taleplerinde kullanılarak stokların düzenlenmesi açısından da fayda sağlayabilir. Bu sayede işletmenin zaman kaybı ve ekstra taşıma maliyetinden kurtulması sağlanabilecektir.

Konu ile ilgili literatür incelendiğinde gıda sektöründe talep tahmine ilişkin fazla çalışma olmadığı görülmektedir. Bunun sebebi gıda sektörünün belirsizliği ve karmaşıklığı olarak görülebilir. Literatüre genel bir bakış atıldığında ise yapay sinir ağları yönteminin başarısının tesadüf olmadığı görülmektedir.

Law ve Au (1999) yaptıkları çalışmada Japonların Hong Kong'a seyahat talebini talep tahmin yöntemleri ile incelemişlerdir ve yaptıkları bu çalışmada hareketli ortalamalar, üstel düzeltme yöntemleri, çoklu regresyon, naive ve yapay sinir ağları yöntemlerini kullanmışlardır. Yapılan çalışmanın sonucunda MAPE hata terimine göre en iyi sonucu yapay sinir ağları yöntemi vermiştir ve bu çalışmanın sonuçlarıyla örtüşmektedir.

Jain (2001) ve arkadaşları, kısa vadede su talebine ilişkin talep tahmin modelleri geliştirmişlerdir. Bu modelleri regresyon, zaman serileri analizi ve yapay sinir ağları yöntemleri ile kurmuşlardır. Elde ettikleri sonuçlar bu çalışma ile paralellik göstermekle birlikte, yapay sinir ağı yönteminin, regresyon ve zaman serisi analizi yöntemlerine göre daha iyi performans sergilediğini belirtmişlerdir.

Olgun (2009) çalışmasında, "Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemleri Ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması" konusunu ele almış ve yapay sinir ağları ile regresyon yöntemini ortalama mutlak hataya göre karşılaştırmıştır. Yapay sinir ağları yönteminin ortalama mutlak hatasını regresyon yönteminin hatasına göre daha düşük olduğunu bulmuştur ve bu çalışmanın sonuçları ile paralellik göstermektedir.

Yücesoy (2011) çalışmasında temizlik kağıdı talebine ilişkin talep tahmin modelleri kurmuş ve sonucunda yapay sinir ağları yöntemi, regresyon yöntemine göre daha başarılı olmuştur.

Ballı (2014) gıda sektöründe yaptığı çalışmasında bu çalışmadaki sonuçlara benzer sonuçlar bulmuştur. Çalışmasında son dönem talebi, basit ortalama, hareketli

ortalama, üstel düzeltme yöntemi ve yapay sinir ağı gibi yöntemleri ele almış ve en iyi tahmin modelini yapay sinir ağları ile kurmuştur.

Sonuç olarak bu çalışma literatürdeki diğer çalışmalarla benzerlik göstermektedir. Doğrusal olmayan serilerde yapay sinir ağları yöntemleri başarılı sonuçlar vermektedir. Araştırma konusunun daha da geliştirilebilmesi adına ilerleyen çalışmalarda parametrik olmayan regresyon analizi gibi yöntemlerle karşılaştırılabilir. Kısa vadeli tahminlerde oldukça iyi performans gösteren bu yöntem uzun vadeli tahminler açısından genetik algoritma yöntemiyle karşılaştırılması gelecekteki çalışmalar için farklı bir bakış açısı oluşturabilir.



## KAYNAKÇA

- Aıkeshan, A., (2014), “Bulanık Doğrusal Regresyon Yöntemi İle Talep Tahmini: Medikal Asistans Firmasında Bir Uygulama”, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Akdağ, R., (2014), “Yapay Sinir Ağları Yöntemiyle Diyarbakır İli Kent Merkezi İçme Suyu Talep Tahmini Uygulaması”, Dicle Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Diyarbakır.
- Akgül, B., (2010), “Türkiye'deki Otomotiv Sektörü ve Örnek Bir Talep Tahmin Çalışması”, Yıldız Teknik Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Akgül, S., (2013), “Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Talep Tahmini ve Diğer Yöntemlerle Karşılaştırmalı Analizi”, Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Erzurum.
- Akkaya G.C., Demireli, E. ve Yakut, Ü.H., (2009), “İşletmelerde Finansal Başarısızlık Tahminlemesi: Yapay Sinir Ağları Modeli İle İmkb Üzerinde Bir Uygulama”, Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi, 10 (2), ss. 187-216.
- Aktaş, R., Doğanay, M. ve Yıldız, B., (2003), “Mali Başarısızlığın Öngörülmesi: İstatistiksel Yöntemler ve Yapay Sinir Ağı Karşılaştırması”, Ankara Üniversitesi Siyasal Bilgiler Fakültesi Dergisi, Cilt: 58, Sayı: 4, ss. 1-24.
- Al-Saba, T. and El-Amin İ., (1999), “Artificial Neural Networks As Applied To Long-Term Demand Forecasting”, Artificial Intelligence in Engineering, 13, pp. 189–197.



- Altman, E.I., Marco, G. and Varetto, F., (1994), "Corporate Distress Diagnosis: Comparisons Using Linear Discriminant Analysis And Neural Networks (The Italian Experience)", Journal of Banking and Finance, Vol: 18, No: 3, pp. 505-529.
- Anderson, D. and McNeill, G., (1992), "Artificial Neural Networks Technology", A DACS State Of The Art Report, New York.
- Arı, A. ve Berberler, M.E., (2017), "Yapay Sinir Ağları İle Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı", Acta Infologica, 1 (2), ss. 55-73.
- Asilkan, Ö. ve Irmak, S., (2009), "İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları İle Tahmin Edilmesi", Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Cilt: 14, Sayı: 2, ss. 375-391.
- Ataseven, B., (2013), "Yapay Sinir Ağları İle Öngörü Modellemesi", Öneri Dergisi, Cilt: 10, Sayı: 39, ss. 101-115.
- 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.
- Aydın, M.Ç., (2017), "Giyim Endüstrisinde Talep Tahmin Yöntemlerinin Uygulanması: Örnek Bir Uygulama", Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Konya.
- Bal, B., (2015), "Talep Tahminleme ve Planlama; Perakende Sektörü, E-Ticaret", Maltepe Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Ballı, M.T., (2014), "Yapay Sinir Ağları İle Talep Tahmini ve Gıda Sektöründe Uygulanması", Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Basheer, I. and Hajmeer, M., (2000) "Artificial Neural Networks: Fundamentals, Computing, Design and Application", Journal of Microbiological Methods, 43 (1), pp. 3-31.
- Bulut, Ş., (2006), "Orta Ölçekli Bir İşletmede Talep Tahmin Yöntemlerinin Uygulanması", Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kırıkkale.
- Burke, L.L. and Ignizio, J.P. (1992), "Neural Networks and Operations Research: An Overview", Computers and Operations Research, Vol: 19, No: 3/4, pp. 179-189.

- Carpenter, G.A. and Grossberg, S., (2016), "Adaptive Resonance Theory". C. Sammut, G.I. Webb (Eds), inside "Encyclopedia of Machine Learning and Data Mining" (pp. 1-17), Springer Science and Business Media, New York.
- Chen, A., Cao, J. and Huang, J., (2002), "An Estimation of Upperbound of Delays For Global Asymptotic Stability of Delayed Hopfield Neural Networks", Fundamental Theory and Applications, Vol: 49, No: 7, pp. 1028-1032.
- Civalek, Ö. ve Calayır, Y., (2007), "İnce Dikdörtgen Plakların Titreşim Frekanslarının Yapay Sinir Ağları Yaklaşımı ile Tahmini", İMO Teknik Dergi, Yazı 275, ss. 4161 - 4176.
- Civalek, Ö. ve Ülker, M., (2004), "Dikdörtgen Plakların Doğrusal Olmayan Analizinde Yapay Sinir Ağı Yaklaşımı", İMO Teknik Dergi, Cilt: 15, Sayı: 72, ss. 3171-3190.
- Coats, P.K. and Fant, L.F., (1993), "Recognizing Financial Distress Patterns Using a Neural Network Tool", Financial Management, Vol: 22, No: 3, pp. 142-155.
- Collins, J.M. and Clark, M.R., (1993), "An Application of The Theory of Neural Computation To The Prediction of Workplace Behavior: An İllustration and Assessment of Network Analysis", Personnel Psychology, Vol: 46, No: 3, pp. 503-524.
- Curry, B. and Moutinho, L., (1993), "Neural Networks İn Marketing: Modelling Consumer Responses To Advertising Stimuli", European Journal of Marketing, Vol: 27, No: 7, pp. 5-20.
- Çağlar, T., (2007), "Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması", Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kırıkkale.
- Çelikçapa, F.O., (2015), "Üretim Planlaması", Ekin Basım Yayın Dağıtım, 1. Baskı, Bursa.
- Çetinel, S., (2005), Pazarlama Planı, Girişimciler İçin Yatırım Danışma ve Girişimcilik Geliştirme Merkezi Projesi, Ankara.
- 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.

- Demirbaş, F.P., (2011), “Kombi Üretiminde Talep Tahmin Yöntemlerinin Uygulanması”, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kocaeli.
- Detienne, K.B., Detienne, D.H. and Joshi, S.A., (2003), “Neural Networks as Statistical Tools for Business Researchers”, *Organizational Research Methods*, Vol: 6, No: 2, pp. 236-265.
- Efe, Ö. ve Kaynak, O., (2000), “Yapay Sinir Ağları ve Uygulamaları”, İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Efendigil, T., Önüt, S., ve Kahraman, C., (2009), “A Decision Support System For Demand Forecasting With Artificial Neural Networks and Neuro-Fuzzy Models: A Comparative Analysis”, *Expert Systems With Applications*, 36, pp. 6697–6707.
- Erkan, H., (2008), “Talep Tahmin Doğruluğunu Arttırmak İçin Talebi Etkileyen Faktörlerin Analizi ve İlaç Sektöründe Ekonometrik Bir Model Önerisi”, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, İstanbul.
- Fırat, M. ve Güngör, M., (2004), “Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi”, *İMO Teknik Dergi*, Yazı 219, ss. 3267-3282.
- Fildes, R., Goodwin, P. and Lawrence, M., (2006), “The Design Features of Forecasting Support Systems And Their Effectiveness”, *Decision Support Systems*, 42 (1), pp. 351–361.
- Fletcher, D. and Goss, E., (1993), "Forecasting With Neural Networks: An Application Using Bankruptcy Data," *Information and Management*, Vol: 24, No: 3, pp. 159-167.
- Gorr, W.L., Nagin, D. and Szczypula, J., (1994), "Comparative Study of Artificial Neural Network and Statistical Models For Predicting Student Grade Point Averages", *International Journal of Forecasting*, Vol: 10, No: 1, pp. 17-34.
- Hardgrave, B.C., Wilson, R.L. and Walstrom, K.A., (1994), "Predicting Graduate Student Success: A Comparison of Neural Networks and Traditional Techniques", *Computers and Operations Research* , Vol: 21, No: 3, pp. 249-263.
- Hyndman, R.J. and Anne B.K., (2006) “Another Look at Measures of Forecast Accuracy”, *International Journal of Forecasting*, 22 (4), pp. 679-688. Aktaran: Saatçioğlu, D. ve Özçakar, N., (2016), “Yapay Sinir Ağları Yöntemi İle Aralıklı Talep Tahmini”, *Beykoz Akademi Dergisi*, 4 (1), ss. 1-25.

- İlhan, İ., (2015), “Tedarik Zinciri Yönetiminde Kantitatif Talep Tahmin Yöntemi Seçimi İle Stok Optimizasyonuna Dair Bir Uygulama”, Maltepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Jain A.K., Mao, J. and Mohiuddin, K.M., (1996), “Artificial Neural Networks: A Tutorial”, Journal Computer - Special Issue: Neural Computing: Companion Issue to Spring 1996 IEEE Computational Science and Engineering, Vol: 29, Issue: 3, pp. 31-44.
- Jain, A., et al., (2001), “Short-Termwater Demand Forecast Modelling At IIT Kanpur Using Artificial Neural Networks”, Water Resources Management, 15, pp. 299–321.
- Ji, D.H. et al., (2011), “Passivity-Based Control For Hopfield Neural Networks Using Convex Representation”, Applied Mathematics and Computation, 217, pp. 6168–6175.
- Jolai, F. and Ghanbari, A., (2010), “Integrating Data Transformation Techniques With Hopfield Neural Networks For Solving Travelling Salesman Problem”, Expert Systems With Applications, 37, pp. 5331–5335.
- Kale, M.M., (2018), “Yeşilirmak Havzası Mekansal Yağış Dağılımına Ait Değişiminin Deterministik ve Stokastik Yöntemlerle Belirlenmesi”, Hacettepe Üniversitesi Yerbilimleri Uygulama ve Araştırma Merkezi Bülteni, 39 (3), ss. 263-276.
- Karaatlı, M. vd., (2012), “Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini”, Uluslararası Yönetim İktisat ve İşletme Dergisi, Cilt: 8, Sayı: 17, ss. 87-100.
- Karaca, K., (2015), “Araç Talep Tahmininde Kullanılan Yöntemlerin Karşılaştırılması”, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Karahan, M., (2011), “İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu İle Ürün Talep Tahmini Uygulaması”, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Konya.
- Kattan, M.W., Adams, D.A. and Parks, M.S., (1993), "A Comparison of Machine Learning With Human Judgement", Journal of Management Information Systems, Vol.: 9, No: 4, pp. 37-57.
- Kaynar, O. ve Taştan, S., (2009), “Zaman Serisi Analizinde Mlp Yapay Sinir Ağları ve Arima Modelinin Karşılaştırılması”, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Sayı: 33, ss.161-172.

- Keleş, E. ve Çepni, S., (2006), “Beyin ve Öğrenme”, Türk Fen Eğitimi Dergisi, Yıl: 3, Sayı: 2, ss. 66-82.
- Kobu, B., (2010), “Üretim Yönetimi”, Beta Basım, 15. Baskı, İstanbul.
- Krenker, A., Janez, B., and Andrej K., (2011), “Introduction to Artificial Neural Networks”. K. Suzuki (Ed.), Inside “Artificial Neural Networks-Methodological Advances and Biomedical Applications”, (pp. 3-19), InTech, Rijeka.
- Kuan, C.M. and White, H., (1994), "Artificial Neural Networks: An Econometric Perspective", *Econometric Reviews*, Vol: 13, No: 1, pp. 1-91.
- Kutlu, B. ve Badur, B., (2009), “Yapay Sinir Ağları İle Borsa Endeksi Tahmini”, İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadı Enstitüsü Dergisi - Yönetim, Cilt: 20, Sayı: 63, ss. 25-40.
- Law R. and Au, N., (1999), “A Neural Network Model To Forecast Japanese Demand For Travel To Hong Kong”, *Tourism Management*, 20, pp. 89-97.
- Lawrence, S. et al., (1997), “Face Recognition: A Convolutional Neural-Network Approach”, *Ieee Transactions On Neural Networks*, Vol: 8, No: 1, pp. 98-113.
- Makridakis, S. and Wheelright, S.C., (1977), “Forecasting: Issues & Challenges for Marketing Management”, *Journal of Marketing*, Vol: 41, Issue: 4, pp. 24-38.
- Mesnil, G. et al., (2015), “Using Recurrent Neural Networks for Slot Filling in Spoken Language Understanding”, *Acm Transactions on Audio, Speech, And Language Processing*, Vol. 23, No: 3, pp. 530-539.
- Meydan, Y.A., (2007), “Talep Tahmin Yöntemleri ve Orta Ölçekli Bir İşletmede Uygulanması”, İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Mingoti, S.A. and Lima, J.O., (2006), “Comparing SOM Neural Network With Fuzzy C-Means, K-Means and Traditional Hierarchical Clustering Algorithms”, *European Journal of Operational Research*, 174, pp. 1742–1759.
- Okkan, U. ve Dalkılıç, H.Y., (2012), “Radyal Tabanlı Yapay Sinir Ağları İle Kemer Barajı Aylık Akımlarının Modellenmesi“, *İMO Teknik Dergi*, Yazı 379, ss. 5957-5966.

- Olgun, S., (2009), “Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemleri ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması”, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Omarbl, H.A., (2017), “The 2018 Forecasting of Opec Oil Price by Using Time Series Model”, Van Yüzüncü Yıl University Institute of Natural and Applied Sciences, Master’s Thesis, Van.
- Öğücü, M.O., (2006), “Yapay Sinir Ağları İle Sistem Tanıma”, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Öztemel, E., (2006), “Yapay Sinir Ağları”, Papatya Yayıncılık, 2. Basım, İstanbul.
- Öztürk, H., (2006), “Türkiye Yongalevha ve Liflevha Endüstrisinde Talep Tahmini Uygulamaları”, Zonguldak Karaelmas Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Bartın.
- Palmer, A., Montano, J.J. and Sese, A., (2006), “Designing An Artificial Neural Network For Forecasting Tourism Time Series”, *Tourism Management*, 27, pp. 781–790.
- Pham, D. T., Packianather, M. S. and Afify, A. A. (2007), “Artificial Neural Networks”. D. Andina and D.T. Pham (Eds.), inside “Computational Intelligence” (pp. 67-92), Springer, Cardiff.
- Piramuthu, S., Shaw, M.J. and Gentry, J.A., (1994), "A Classification Approach Using Multi-Layered Neural Networks", *Decision Support Systems*, Vol: 11, No: 5, pp. 509- 525.
- Saatçioğlu, D. ve Özçakar, N., (2016), “Yapay Sinir Ağları Yöntemi İle Aralıklı Talep Tahmini”, *Beykoz Akademi Dergisi*, 4 (1), ss. 1-25.
- Salchenberger, L. M., Cinar, E. M. and Lash, N. A., (1992), "Neural Networks: A New Tool For Predicting Thrift Failures", *Decision Sciences*, Vol: 23, No: 4, July/Aug., pp. 899-916.
- Sarı, B., (2014), “Hisse Senetleri Getirilerinin Lojistik Regresyon ve Doğrusal Regresyon Modelleri İle Bir Analizi”, Kadir Has Üniversitesi, Sosyal Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.

- Serttař, Z.S., (2011), “Türkiye’de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması”, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Sezgin, N., Tekin, R. ve Çalışkan, A., (2012), “Örüntü Tanımada Hopfield Ağının Kullanılması”, Batman Üniversitesi Yaşam Bilimleri Dergisi, Cilt: 1, Sayı: 2, ss. 257-266.
- Sharda, R., (1994), "Neural Networks For The MS/OR Analyst: An Application Bibliography", Interfaces, Vol: 24, No: 2, pp. 116-130.
- Silver E.A., Pyke, D.F. and Peterson, R., (2000), “Inventory Management and Production planning and Scheduling”, John Wiley Sons, 3th Edition, USA.
- Storn R., (1997), “Differential Evolution: A Simple and Efficient Heuristic Strategy for Global Optimization over Continuous Spaces”, Journal of Global Optimization, vol. 11, pp. 341-359.
- Syntetos, A.A. and Boylan, J.E., (2005) “The Accuracy of Intermittent Demand Estimates”, International Journal of Forecasting, 21 (2), pp. 303-314.
- Tam, K.Y. and Kiang, M.Y. (1992), "Managerial Applications of Neural Networks: The Case of Bank Failure Predictions", Management Science, Vol: 38, No: 7, pp. 926-947.
- Tang, T.C., and Chi, L.C., (2005), “Neural Networks Analysis in Business Failure Prediction of Chinese Importers: A Between-Countries Approach”, Expert Systems With Applications, 29, pp. 244–255.
- Tařova, O., (2011),” Yapay Sinir Ağları İle Yüz Tanıma”, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İzmir.
- Tektař, A. ve Karatař, A., (2004), “Yapay Sinir Ağları ve Finans Alanına Uygulanması: Hisse Senedi Fiyat Tahminlemesi”, İktisadi ve İdari Bilimler Dergisi, Cilt: 18, Sayı: 3-4, ss. 337-349.
- Tokpunar, İ., (2014), “Tedarik Zinciri Yönetiminde Talep Tahmin Doğruluğunu Arttırmak İçin Radar Diyagramının Kullanımı”, Bahçeşehir Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Top, Y. ve Yılmaz, E., (2009), “Üretim Yönetimi”, Yaprak Yayın Dağıtım, Genişletilmiş 2. Baskı, İstanbul.

- Tutu, B.E., (2017), “Türkiye İçin Kısa Vadeli Elektrik Enerjisi Talep Tahmini”, Tobb Ekonomi ve Teknoloji Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Ankara.
- Wallström, P. and Segerstedt, A., (2010), “Evaluation of Forecasting Error Measurements and Techniques for Intermittent Demand”, International Journal of Production Economics, 128 (2), pp. 625-636.
- Yurtoğlu H., (2005), “Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği”, DPT Uzmanlık Tezi, Ankara.
- Yücesoy, M., (2011), “Temizlik Kağıtları Sektöründe Yapay Sinir Ağları İle Talep Tahmini”, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Aylık Ortalama Dolar Kuru, <https://www.bumko.gov.tr/TR,150/doviz-kurlari.html>, Erişim tarihi: 25.09.2018, 17:54.
- 12 Aylık ortalama Enflasyon, <https://www.bumko.gov.tr/TR,149/enflasyon.html>, Erişim tarihi: 26.09.2018, 21:20.