

**T.C.
SAKARYA ÜNİVERSİTESİ
İŞLETME ENSTİTÜSÜ**

**İŞLETMELERİN SATIŞ BÜTÇELERİNİN OLUŞTURULMASINDA
ARIMA, LSTM VE HİBRİT MODELLERİN
KARŞILAŞTIRILMASI: ÜRETİM İŞLETMESİ ÖRNEĞİ**

DOKTORA TEZİ

Ayşe SOY TEMÜR

Enstitü Anabilim Dalı : İşletme

Enstitü Bilim Dalı : Muhasebe ve Finansman

Tez Danışmanı : Dr. Öğr. Üyesi Şule YILDIZ

AĞUSTOS – 2019

T.C.
SAKARYA ÜNİVERSİTESİ
İŞLETME ENSTİTÜSÜ

**İŞLETMELERİN SATIŞ BÜTÇELERİNİN OLUŞTURULMASINDA
ARIMA, LSTM VE HİBRİT MODELLERİN
KARŞILAŞTIRILMASI: ÜRETİM İŞLETMESİ ÖRNEĞİ**

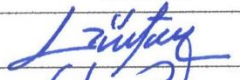
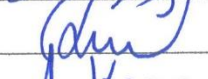

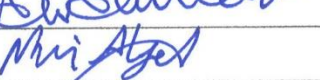

DOKTORA TEZİ

Ayşe SOY TEMÜR

Enstitü Anabilim Dalı : İşletme

Enstitü Bilim Dalı : Muhasebe ve Finansman

“Bu tez 08/08/2019 tarihinde aşağıdaki jüri tarafından Oybirliği / Oyeokluğu ile kabul edilmiştir.”

JÜRİ ÜYESİ	KANAATİ	İMZA
Doç.Dr. Gülfen TUNA	BAŞARILI	
Dr.Öğr.Üyesi Şule YILDIZ	BAŞARILI	
Doç.Dr.Nevran KARACA	BAŞARILI	
Dr.Öğr.Üyesi Ali AKAYTAY	BAŞARILI	
Dr.Öğr.Üyesi Nermin AKYEL	BAŞARILI	



SAKARYA
ÜNİVERSİTESİ

T.C.
SAKARYA ÜNİVERSİTESİ
İŞLETME ENSTİTÜSÜ
TEZ SAVUNULABİLİRLİK VE ORJİNALLİK BEYAN FORMU

Sayfa : 1/1

Öğrencinin

Adı Soyadı	:	Ayşe SOY TEMÜR
Öğrenci Numarası	:	1460D04014
Enstitü Anabilim Dalı	:	İşletme
Enstitü Bilim Dalı	:	Muhasebe ve Finansman
Programı	:	<input type="checkbox"/> YÜKSEK LİSANS <input checked="" type="checkbox"/> DOKTORA
Tezin Başlığı	:	İŞLETMELERİN SATIŞ BÜTÇELERİNİN OLUŞTURULMASINDA ARIMA, LSTM VE HİBRİT MODELLERİN KARŞILAŞTIRILMASI: ÜRETİM İŞLETMESİ ÖRNEĞİ
Benzerlik Oranı	:	% 20

İŞLETME ENSTİTÜSÜ MÜDÜRLÜĞÜNE,

Sakarya Üniversitesi İşletme Enstitüsü Lisansüstü Tez Çalışması Benzerlik Raporu Uygulama Esaslarını inceledim. Enstitünüz tarafından Uygulama Esasları çerçevesinde alınan Benzerlik Raporuna göre yukarıda bilgileri verilen tez çalışmasının benzerlik oranının herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

08.08/2019
İmza

Sakarya Üniversitesi Enstitüsü Lisansüstü Tez Çalışması Benzerlik Raporu Uygulama Esaslarını inceledim. Enstitünüz tarafından Uygulama Esasları çerçevesinde alınan Benzerlik Raporuna göre yukarıda bilgileri verilen öğrenciye ait tez çalışması ile ilgili gerekli düzenleme tarafımda yapılmış olup, yeniden değerlendirilmek üzere@sakarya.edu.tr adresine yüklenmiştir.

Bilgilerinize arz ederim.

...../...../20.....
İmza

Uygundur

Danışman
Unvanı / Adı-Soyadı: Dr. Öğr. Üyesi Şule YILDIZ

Tarih: 08.08.2019

İmza:

KABUL EDİLMİŞTİR

REDDEDİLMİŞTİR

EYK Tarih ve No:

Enstitü Birim Sorumlusu Onayı

ÖNSÖZ

Bu tezin yazılması aşamasında, kıymetli bilgi birikimi ve tecrübeleriyle bana yol göstererek çalışmamı sahiplenip titizlikle takip eden değerli danışmanlarım Prof. Dr. Melek AKGÜN ve Dr. Öğr. Üyesi Şule YILDIZ'a, fikir ve destekleriyle beni yönlendiren ve değerli katkılar sağlayan Doç. Dr. Nevran KARACA, Doç. Dr. Gülfen TUNA ve Dr. Öğr. Üyesi Nermin AKYEL'e değerli katkı ve emekleri için içten teşekkürlerimi ve saygılarımı sunarım.

Tüm bu süreçte motivasyon kaynağım olan, beni tüm zorlukları aşabileceğime inandıran ve hiçbir zaman yardımını ve desteğini esirgemeyen eşim Günay TEMÜR'e sonsuz teşekkür ederim.

Beni bu yaşa getiren ve çalışmalarım boyunca her türlü destekleriyle beni hiçbir zaman yalnız bırakmayan canım aileme şükranlarımı sunarım.

Doktora tezimi kıymetlilerim, en değerli varlıklarım kızlarım Eylül İkra TEMÜR ve Elif Ada TEMÜR'e ithaf ederim.

Ayşe SOY TEMÜR

08.08.2019

İÇİNDEKİLER

KISALTMALAR	v
TABLO LİSTESİ	vi
ŞEKİL LİSTESİ	vii
ÖZET	ix
SUMMARY	x
GİRİŞ	1
BÖLÜM 1: BÜTÇE KAVRAMI VE İŞLETMELERDE BÜTÇELEME	9
1.1. Bütçe Kavramı	9
1.2. Bütçenin Amaçları	10
1.2.1. Planlama	11
1.2.2. Koordinasyon	11
1.2.3. Kontrol.....	12
1.3. İşletme Bütçelerinin İlkeleri.....	13
1.3.1. Örgütsel Uyum İlkesi	13
1.3.2. Yönetimin Desteği İlkesi	14
1.3.3. Katılımcılık İlkesi	14
1.3.4. Gerçekçilik İlkesi.....	15
1.3.5. Sorumluluk Muhasebesi İlkesi	15
1.3.6. Esnek Uygulama İlkesi	16
1.3.7. İzleme İlkesi	16
1.4. İşletme Bütçelerinin Türleri	16
1.4.1. Konuları Bakımından İşletme Bütçeleri	16
1.4.1.1. Gelir Bütçesi	17
1.4.1.2. Gider Bütçesi	17
1.4.2. Sorunları Ele Alış Biçimlerine Göre İşletme Bütçeleri	17
1.4.2.1. Dönemsel Bütçeler	17
1.4.2.2. Proje Bütçeleri	17
1.4.3. Amaçlarına Göre İşletme Bütçeleri	18
1.4.3.1. Program Bütçeleri.....	18
1.4.3.2. Faaliyet Bütçeleri	18
1.4.4. Teknik Yapılarına Göre İşletme Bütçeleri	19

1.4.4.1. Statik (Durağan) Bütçeler.....	19
1.4.4.2. Karşılaştırmalı Statik Bütçeler	19
1.4.4.3. Dinamik (Esnek) Bütçeler	19
1.4.5. Kapsamlarına Göre Bütçeler	20
1.4.5.1. Genel Bütçeler	20
1.4.6. Temel Alınan Başlangıç Rakamlarına Göre Bütçeler	31
1.4.6.1. Geleneksel Bütçeler.....	31
1.4.6.2. Sıfır Tabanlı Bütçeler	31
1.4.7. Rakamların Niteliğine Göre Bütçeler	32
1.4.7.1. Miktar Bütçeleri	32
1.4.7.2. Tutar Bütçeleri.....	32
1.5. İşletmelerde Bütçelemenin Önemi.....	32
BÖLÜM 2: TALEP TAHMİNİ VE TAHMİN TEKNİKLERİ	33
2.1. Talep Tahmini Kavramı	33
2.2. Bütçelemede Tahminin Önemi	33
2.3. Tahmin Teorileri	34
2.3.1. Talep Tahmin İlkeleri	35
2.3.2. Talep Tahmin Aşamaları	36
2.3.3. Talep Tahmin Yönteminin Seçimi	37
2.4. Tahmin Teknikleri	39
2.4.1. Kalitatif Tahmin Teknikleri.....	39
2.4.1.1. Delphi Tekniği.....	39
2.4.1.2. Pazar Araştırmaları Yöntemi.....	41
2.4.1.3. Uzman Görüşleri Yöntemi	41
2.4.1.4. Satış Elemanlarının Görüşleri Yöntemi	41
2.4.1.5. Yaşam Eğrilerinin Benzeşimi Yöntemi.....	41
2.4.1.6. Senaryo Analizi Yöntemi	42
2.4.2. Kantitatif Tahmin Teknikleri.....	43
2.4.2.1. Zaman Serileri Analizine Dayalı Yöntemler.....	43
2.4.2.2. Nedensel (İlişkiye Dayalı) Yöntemler.....	52
2.5. Yapay Sinir Ağları	54
2.5.1. Yapay Sinir Ağlarının Temel Bileşenleri	56

2.5.1.1. Biyolojik Sinir Hücresi.....	56
2.5.1.2. Yapay Sinir Hücresi	57
2.5.2. Yapay Sinir Ağlarının Sınıflandırılması.....	63
2.5.2.1. Mimarilerine Göre Yapay Sinir Ağları	63
2.5.2.2. Öğrenme Zamanına Göre YSA	64
2.5.2.3. Öğrenme Metotlarına Göre YSA	65
2.5.2.4. Kullanım Amaçlarına Göre Yapay Sinir Ağları.....	68
2.5.3. Yapay Sinir Ağları Metoduyla Talep Tahmini.....	69
2.5.4. Yapay Sinir Ağlarının Çalışma Prensipleri	70
BÖLÜM 3: UYGULAMADA KULLANILAN YÖNTEMLER	72
3.1. Otoregresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA) Modelleri	72
3.1.1. Durağan ARIMA Modelleri	73
3.1.1.1. Otoregresif Süreç (AR)	73
3.1.1.2. Hareketli Ortalama (MA) Modelleri	74
3.1.1.3. Otoregresif Hareketli Ortalama (ARMA) Modelleri.....	75
3.1.2. Durağan Olmayan ARIMA Modelleri.....	76
3.1.3. Mevsimsel Modeller (SARIMA).....	78
3.1.4. ARIMA Model Belirleme Süreci	79
3.1.5. Model Belirleme Kriterleri	80
3.1.5.1. Belirlilik Katsayısı (R^2) Kriteri	81
3.1.5.2. En Küçük Kareler Yöntemi (EKK).....	81
3.1.5.3. F İstatistiği Yaklaşımı	82
3.1.5.4. Akaike Bilgi Kriteri (AIC: Akaike Information Criterion).....	82
3.1.5.5. Son Kestirim Hatası (FPE: Final Prediction Error).....	82
3.1.5.6. Bayes Bilgi Kriteri (BIC: Bayes Information Criterion).....	83
3.1.5.7. Schwarz Bilgi Kriteri (SIC: Schwarz Informaiton Criterion)	84
3.1.5.8. Hannan Bilgi Kriteri (HQC: Hannan Quinn Kriteri).....	84
3.1.5.9. Durbin-Watson Testi	85
3.2. Tekrarlayan Sinir Ağları (Recurrent Neural Network-RNN)	85
3.2.1. RNN Hakkında Temel Bilgiler.....	85
3.2.2. Uzun Kısa Süreli Bellek Ağları (Long Short Term Memory - LSTM).....	88

3.2.3. LSTM'nin Aşamaları.....	92
3.2.4. LSTM'lerin Farklı Türevleri	96
3.3. Hibrit Modeller	100
3.3.1. Çeşitli Hibrit Model Yaklaşımları	100
3.3.1.1. Zhang' ın Hibrit Modeli	101
3.3.1.2. Khashei, Bijari' nin Hibrit Modeli	102
3.3.1.3. Khashei, Bijari' nin İkinci Hibrit Modeli.....	102
3.3.1.4. Khashei, Bijari ve Ardali'nin Hibrit Modeli	102
3.3.1.5. Babu ve Reddy' nin Hibrit Modeli.....	103
3.3.2. Çalışmada Kullanılan Hibrit Model Yaklaşımı	104
3.4. Modellerin Başarı Kriterleri.....	105
3.5. ARIMA, LSTM, YSA ve İki Modelin Kullanımı İle Oluşturulan Hibrit Modellere Yönelik Çalışmalar	106
BÖLÜM 4: ÜRETİM İŞLETMESİNDE SATIŞ TAHMİNİ ÜZERİNE UYGULAMA	112
4.1. İşletme Profili.....	112
4.2. Veri ve Araştırma Bulguları.....	113
4.2.1. Veri	113
4.2.2. ARIMA Modeli Uygulama Sonuçları	115
4.2.3. LSTM Modeli Uygulama Sonuçları	119
4.2.4. Hibrit Model Uygulama Sonuçları	121
SONUÇ.....	126
KAYNAKÇA	132
EKLER	153
ÖZGEÇMİŞ.....	161

KISALTMALAR

ABD	: Amerika Birleşik Devletleri
ACF	: Otokorelasyon Fonksiyonu
AIC	: Akaike Bilgi Kriteri
ANN	: Artificial Neural Network
AR	: Otoregresyon
AR-GE	: Araştırma ve Geliştirme
ARIMA	: Otoregresif Entegre Hareketli Ortalama
ARMA	: Otoregresif Hareketli Ortalama
ATDNN	: Uyarlamalı Zaman Gecikmeli Sinir Ağları
BIC	: Bayes Bilgi Kriteri
BJ	: Box-Jenkins
CNN	: Evrişimli Sinir Ağları
EKK	: En Küçük Kareler
FPE	: Son Kestirim Hatası
GLAR	: Genelleştirilmiş Doğrusal Otoregresyon
GSYİH	: Gayri Safi Yurtiçi Hasıla
HQC	: Hannan Bilgi Kriteri
IACF	: Ters Otokorelasyon Fonksiyonu
LSTM	: Uzun Kısa Vadeli Bellek Ağları
MA	: Hareketli Ortalama
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Hata Yüzdesi
MSE	: Ortalama Kare Hatası
PACF	: Kısmi Otokorelasyon Fonksiyonu
RMSE	: Kök Ortalama Kare Hatası
RNN	: Tekrarlayan Sinir Ağları
SARIMA	: Mevsimsel Otoregresif Entegre Hareketli Ortalama
SIC	: Schwarz Bilgi Kriteri
TDNN	: Zaman Gecikmeli Sinir Ağları
YSA	: Yapay Sinir Ağları

TABLO LİSTESİ

Tablo 2.1: Geleneksel Bilgi İşleme ve YSA Yöntemlerinin Karşılaştırılması	56
Tablo 2.2: Kullanım Amaçlarına Göre Yapay Sinir Ağları	68
Tablo 3.1: AR, MA ve ARMA Modellerinde ACF ve PACF'nin Teorik Davranış Biçimleri.....	80
Tablo 3.2: RNN'in Avantaj ve Dezavantajları.....	88
Tablo 3.3: Başarı Kriteri (Korelogram) Formülleri	106
Tablo 4.1: ARIMA Modelleri Korelogram Sonuçları (%67 eğitim seti).....	117
Tablo 4.2: ARIMA Modelleri Korelogram Sonuçları (%73 eğitim seti).....	117
Tablo 4.3: LSTM Modelleri Korelogram Sonuçları (%67 eğitim seti).....	119
Tablo 4.4: LSTM Modelleri Korelogram Sonuçları (%73 eğitim seti).....	120
Tablo 4.5: Hibrit Model Korelogram Sonuçları (%67 eğitim seti).....	122
Tablo 4.6: HYBRID Model Korelogram Sonuçları (%73 eğitim seti)	124
Tablo 4.7: ARIMA, LSTM ve Hibrit Modellerin Karşılaştırılması.....	127
Tablo 4.8: Kullanılan Yöntemlere Göre 2017 Yılı (Aylık) Satış Miktarları Bütçesi...	129

ŞEKİL LİSTESİ

Şekil 2.1 : Elle Çizme Yöntemi Grafiği	48
Şekil 2.2 : Yarı Ortalama Yöntemi Grafiği	49
Şekil 2.3 : En Küçük Kareler Serpme Diyagramı	50
Şekil 2.4 : En Küçük Kareler Grafiği	51
Şekil 2.5 : Regresyon Grafiği	53
Şekil 2.6 : Çok Katmanlı Yapay Sinir Ağı	55
Şekil 2.7 : Biyolojik Sinir Sistemi Blok Diyagramı	56
Şekil 2.8 : İnsan Sinir Hücresi Yapısı.....	57
Şekil 2.9 : Yapay Sinir Hücresinin Basit Yapısı	58
Şekil 2.10: Yapay Sinir Hücresinin Temel Yapısı	59
Şekil 2.11: Simetrik Eşik Transfer Fonksiyonları	61
Şekil 2.12: Lineer Transfer Fonksiyonu	61
Şekil 2.13: Sigmoid Transfer Fonksiyonu	62
Şekil 2.14: Hiperbolik Tanjant Transfer Fonksiyonu	62
Şekil 2.15: İleri Beslemeli Yapay Sinir Ağlarının Basit Yapısı	63
Şekil 2.16: Geri Beslemeli Yapay Sinir Ağlarının Basit Yapısı.....	64
Şekil 2.17: Danışmanlı Öğrenme Yapısı	66
Şekil 2.18: Danışmansız Öğrenme Yapısı	67
Şekil 2.19: Destekleyici Öğrenme Yapısı.....	68
Şekil 2.20: Yapay Sinir Ağlarının Çalışma Prensipleri	70
Şekil 3.1 : ARIMA Modelinin Akış Şeması.....	78
Şekil 3.2 : Basit RNN Mimarisi	86
Şekil 3.3 : Katmanları Açık Hale Getirilmiş RNN Mimarisi	87
Şekil 3.4 : Standart RNN'deki Yinelenen Tek Katman.....	87
Şekil 3.5 : LSTM'in 1997'deki İlk Mimarisi	89
Şekil 3.6 : LSTM'deki Etkileşimli Dört Katman	90
Şekil 3.7 : LSTM Mimarisinde Kullanılan Semboller	90
Şekil 3.8 : LSTM'in Kilit Noktası Hücresinin Durumu.....	91
Şekil 3.9 : Noktasal Çarpma ve Sigmoid Sinir Kapısı	91
Şekil 3.10: LSTM Hücresinin Çizimi.....	92
Şekil 3.11: LSTM İçindeki Unutma Kapısının Gösterimi.....	93
Şekil 3.12: Hücre Durumunu Güncelleme	94
Şekil 3.13: Yeni Hücre Durumunun Hesaplanması.....	94

Şekil 3.14: Hafıza Hücresinin Çıkışı	95
Şekil 3.15: Yığılmış LSTM Mimarisi.....	96
Şekil 3.16: Gözetleme Deliği İle Oluşturulan LSTM Mimarisi	97
Şekil 3.17: Giriş ve Unutma Kapıları Birleştirilmiş LSTM Mimarisi.....	98
Şekil 3.18: Gated Recurrent Unit (GRU) Mimarisi.....	98
Şekil 3.19: Hibrid Model Diyagramı	104
Şekil 4.1 : Aylık ürün satışı veri seti grafiği.....	114
Şekil 4.2 : En Uygun ARIMA Modelinden Elde Edilen Göstergeler	115
Şekil 4.3 : ARIMA(1,0,0) Modeli ve Gerçek Veri Seti Karşılaştırma Grafiği.....	118
Şekil 4.4 : ARIMA(1,0,1) Modeli ve Gerçek Veri Seti Karşılaştırma Grafiği.....	118
Şekil 4.5 : LSTM Modeli (1000 epoch) ve Gerçek Veri Seti Karşılaştırma Grafiği (%67 eğitim)	120
Şekil 4.6 : LSTM Modeli (1000 epoch) ve Gerçek Veri Seti Karşılaştırma Grafiği (%73 eğitim)	121
Şekil 4.7 : Hibrit Model ve Gerçek Veri Seti Karşılaştırma Grafiği (%67 eğitim seti) ...	123
Şekil 4.8 : Hibrit Model ve Gerçek Veri Seti Karşılaştırma Grafiği (%73 eğitim seti)	125
Şekil 4.9 : Satış Miktar Tahminlerinin Yöntemlere Göre Karşılaştırılması	130

Tezin Başlığı: İşletmelerin Satış Bütçelerinin Oluşturulmasında ARIMA, LSTM ve Hibrit Modellerin Karşılaştırılması: Üretim İşletmesi Örneği	
Tezin Yazarı: Ayşe SOY TEMÜR	Danışman: Dr. Öğr. Üyesi Şule YILDIZ
Kabul Tarihi: 8 Ağustos 2019	Sayfa Sayısı: x (ön kısım)+ 152 (tez) + 8 (ek)
Anabilimdalı: İşletme	Bilim Dalı: Muhasebe ve Finansman
<p>İşletmeler, artan rekabet koşullarında varlıklarını sürdürebilmek ve sürekli değişen dünyaya uyum sağlayabilmek amacıyla geleceği tahmin etmek isterler. Bu sebeple talep tahmini, işletmelerin kısa ve uzun vadeli hedeflerine ulaşmak amacıyla kullanacakları en önemli araçlardan biridir. İyi bir tahmin ile geleceğe yönelik belirsizlikler azaltılabilir. Bunun sağlanabilmesi, tahmin sisteminin iyi bir şekilde oluşturulması ve işletilmesine bağlıdır. Yapılan tahminler neticesinde işletmelerin gelecek dönemlere ilişkin faaliyetleri ile ilgili yönetim planlarından oluşan işletme bütçeleri hazırlanmaktadır.</p> <p>Bir işletmenin gelecek faaliyet dönemine yönelik satışlarını miktar ve tutar şeklinde gösteren satış bütçeleri bazı istisnalar dışında işletmelerdeki bütçe sisteminin temelini oluşturmaktadır. Bu sebeple, gelecek döneme ilişkin satış miktarı tahmini iyi bir bütçe sistemi dolayısıyla da iyi bir satış bütçesi için oldukça önemlidir.</p> <p>Bu tezin amacı, bir işletmenin geçmiş dönem satış verilerinden faydalanarak aylık satış miktarı bütçesinin oluşturulmasıdır. Örnekleme açısından ekonominin lokomotifleri olarak ifade edilen inşaat sektöründe faaliyette bulunan bir işletmenin 2010 (1)–2017 (12) aylarına ait gerçekleşen satış adetleri temin edilerek toplamda 96 aylık veri seti kullanılmıştır.</p> <p>Bu tez çalışması kapsamında, ilk olarak bütçeleme kavramı ve işletmelerde bütçeleme konularına ilişkin açıklamalara yer verilmiştir. İkinci bölümde, talep tahmini kavramı ve tahmin teknikleri incelenmiştir. Üçüncü bölümde, çalışmanın uygulama aşamasında kullanılan ARIMA (Autoregressive Integrated Moving Average), LSTM (Long Short-Term Memory) ve Hibrit (ARIMA ve LSTM) yöntemlere ilişkin açıklamalarda bulunulmuştur. Çalışmanın son bölümünde ise satışların zaman serileri tahmini için doğrusal model olarak ARIMA, doğrusal olmayan model olarak LSTM ve tek modele kıyasla tahmin doğruluğunu artırabilmek için oluşturulmuş bir Hibrit model kullanılarak elde edilen uygulama sonuçları gösterilmiştir.</p> <p>Çalışmanın sonucunda, uygulamada kullanılan yöntemlerin her birinden elde edilen MAPE (Mean Absolute Percentage Error) ve MSE (Mean Squared Error) değerleri kıyaslanmış ve kullanılan yöntemlerin tümü ile 2017 yılı için aylık satış miktarı bütçesi oluşturulmuştur. Elde edilen veriler gerçek satış verileri ile karşılaştırılmış ve en iyi performansın en düşük hatayı veren Hibrit model olmasının yanı sıra, çalışmada kullanılan modellerin tümünün geçmiş verilerden yararlanarak gerçeğe oldukça yakın sonuçlar elde etmesi, tahmin edilebilirliğin başarısını göstermektedir. Bu durum, gerçekleştirilen çalışmanın hem satışların güvenilir ve minimum hata seviyesinde tahmin edilmesiyle gelecek dönem üretim ve satış bütçelerinin oluşturulması konusunda işletmeye fayda sağlayacağını hem de bundan sonra yapılacak olan benzer nitelikteki çalışmalar açısından literatüre katkıda bulunabileceğinin bir göstergesidir.</p>	
Anahtar Kelimeler: Satış Bütçesi, Zaman Serileri Tahmini, Hibrit Model, ARIMA, LSTM.	

Title of the Thesis: Comparison of ARIMA, LSTM and Hybrid Models in Establishing Sales Budgets: A Case of Production Facility	
Author: Ayşe SOY TEMÜR	Author: Ayşe SOY TEMÜR
Date: 08 August 2019	Nu. of pages: x (pre text)+152 (main body)+8(App.)
Department: Business Administration	Department: Accountant and Finance
<p>Enterprises want to predict the future in order to survive in an increasingly competitive environment and adapt to the ever-changing world. Therefore, demand forecasting is one of the most important tools that enterprises will use to achieve their short and long term goals. With good forecasting, uncertainties in the future can be reduced. This depends on the establishment and operation of the forecasting system. Operating budgets, which consist of management plans related to the activities of the companies for the future periods, are prepared as a result of the forecasts made.</p> <p>Sales budgets, which show the sales of an enterprise for the next period in the form of quantity and amount, form the basis of the budget system in enterprises with some exceptions. Therefore, the forecast of sales for the next period is very important for a good budget system and therefore a good sales budget.</p> <p>The aim of this thesis is to create monthly sales volume budget by using past sales data of an enterprise. In terms of sampling, the number of sales for 2010 (1)–2017 (12) of a business operating in the construction sector, which is considered the driving force of the economy, was obtained and a total of 96 months data set was used.</p> <p>Within the scope of this thesis, firstly, the concept of budgeting and explanations about budgeting issues in enterprises are given. In the second part, demand forecasting concept and forecasting techniques are examined. In the third part, ARIMA(Autoregressive Integrated Moving Average), LSTM (Long Short-Term Memory) and Hybrid (ARIMA and LSTM) methods are explained. In the last part of the study, application results obtained by using ARIMA as a linear model for the forecasting of the time series of sales, LSTM as a nonlinear model and a Hybrid model which was created in order to increase forecasting accuracy compared to a single model are provided.</p> <p>As a result of the study, MAPE (Mean Absolute Percentage Error) and MSE (Mean Squared Error) values obtained from each of the methods used in the application were compared and monthly sales amount budget was formed with all of the methods used. The data obtained were compared with the actual sales data and it was found that the Hybrid model has the best performance with the lowest error. In addition, the fact that all of the models used in the study obtained very close-to-real results by using historical data shows the success of forecasting. This indicates that this study will be beneficial for the establishment of production and sales budgets for the next period by estimating the sales at reliable and minimum error level and that it will also contribute to the literature to guide similar studies.</p>	
Keywords: Sales Budget, Time Series Forecast, Hybrid Model, ARIMA, LSTM.	

GİRİŞ

İnşaat sektörü, son yıllarda hızla gelişmekle birlikte özellikle 2001 krizinin ardından sağlanan ekonomik gelişmelerden en çok faydalanan sektörlerden biri olmuştur. Kamu ve özel teşebbüs eliyle yürütülen inşaat sektörü ve alt sektörleri ülkedeki ekonomik büyümeyi harekete geçiren diğer sektörler ile olan yoğun ve geniş bağlantısı sebebiyle ülke ekonomisindeki en önemli sektörlerden birisi olarak kabul edilmektedir. Sektör hem diğer mal ve hizmetleri üretebilmek için gerekli altyapıyı sağlar hem de çeşitli bileşimleriyle bu mal ve hizmetlerin üretilmesinde önemli bir girdi olarak kullanılır. Ayrıca yoğun iş gücü kullanımı gerektirmesinden dolayı istihdama, Gayri Safi Yurtiçi Hasıla (GSYİH) içindeki payından dolayı da sosyo-ekonomik refah düzeyi ve ekonomik büyümeye sağladığı katkı inşaat sektörünün ülke ekonomisindeki önemli yerinin bir göstergesidir.

İnşaat sektörü, kendine bağlı birçok alt sektörün üretmiş olduğu mal ve hizmetlere yönelik talebi etkilemesi sebebiyle “ekonominin lokomotifi” niteliğini de taşımaktadır. Sektörün gerçekleştirdiği faaliyetlerin her biri inşaat üretim sürecinde kullanılan girdiler ile olan ilişkisinden ötürü ilişkili diğer sektörleri de etkileyebilir. İnşaat sektörü, istihdama olan katkısı ve diğer sektörlerle olan ilişkisinden dolayı ulaşılmak istenen ekonomik büyüme hızının yakalanması ve sürdürülmesinde önemli bir rol üstlenmektedir (Kılıç & Demirbaş, 2012). İnşaat sektörü ile ekonomik büyüme arasındaki ilişki, sektörün ekonomik dalgalanmalara karşı olan duyarlılığını da artırır. İnşaat sektörü, ekonomik büyümenin hızlı olduğu dönemlerde diğer sektörlerle kıyasla daha hızlı bir gelişme göstermesine rağmen, ekonomideki durgunluk dönemlerinde de olumsuz yönde etkilenen ilk sektörlerden biri olmaktadır.

Diğer taraftan, ekonomik belirsizlikler inşaat sektöründeki talebi etkileyen en önemli faktördür. Bazı dönemlerde sektördeki talebin bastırılması ya da üretimdeki sürekliliğin bozulması da sektördeki sabit sermaye yatırımlarını azaltıcı bir etki oluşturmaktadır. Bu durum ise üreticilerin sabit sermaye yatırımlarından uzaklaşmalarına ve varlıklarını sürekli olarak likit tutmalarına neden olur. İnşaat sektörünün daralmaya girmesi inşaat malzemesi üreten yan sanayilerin de bu zaman sürecinde düşük kapasitede çalışmaya zorlanmasına sebep olabilmektedir. Ortaya çıkan bu olumsuz süreç ise imalat sanayiini, ulusal ekonomiyi ve dolayısıyla istihdamı da etkilemektedir (Düzyol, 1997). Bu

olumsuzluklardan dolayı, işletmeler artan rekabet koşullarında rekabet edebilmek ve sürekli değişen dünyaya uyum sağlayabilmek amacıyla geleceği tahmin etmek isterler. Bu sebeple talep tahmini, işletmelerin kısa ve uzun vadeli hedeflerine ulaşmak amacıyla kullanacakları en önemli araçlardan biridir. İyi bir tahmin ile geleceğe yönelik belirsizliklerin azaltılması sağlanmaktadır. Bunun sağlanabilmesi ise, tahmin sisteminin iyi bir şekilde oluşturulması ve işletilmesine bağlıdır. Yapılan tahminler neticesinde işletmelerin gelecek dönemlere ilişkin faaliyetleri ile ilgili yönetim planlarından oluşan işletme bütçesi hazırlanmaktadır.

İşletme bütçeleri, işletmelerin amaçlarını gerçekleştirilebilmeleri için ihtiyaç duydukları kaynakları, bu kaynakların nasıl elde edileceğini ve nerelerde kullanılacağını gösterir. İstisnalar olmakla birlikte, satış bütçeleri işletmelerdeki bütçe sisteminin temelini oluşturur. Bir işletmenin gelecek faaliyet dönemine yönelik satışlarını tutar ve miktar şeklinde gösteren satış planı satış bütçesidir. Gelecek döneme ilişkin satış miktarı tahmini iyi bir bütçe sistemi dolayısıyla da iyi bir satış bütçesi için oldukça önemlidir.

Satış tahmininde kullanılan metotlar genellikle geleneksel ve gelişmiş metotlar olmak üzere iki gruba ayrılırlar. Daha çok uzman görüşleri ve kişisel tecrübelerle dayanan yöntemler geleneksel metotlar, istatistiksel ve matematiksel verilere dayanan yöntemler ise gelişmiş metotlar şeklinde ifade edilmektedir. Örneğin; regresyon analizi temeline dayanan hedonik modeller geleneksel metotlar içerisinde yer alırlar. Bulanık mantık, insan beyninin düşünme yapısını taklit eden Yapay Sinir Ağları (Artificial Neural Networks-YSA) ile Oto-regresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA) gibi yöntemler gelişmiş yöntemlerin başlıcalarıdır. Bu yöntemler temel olarak zaman serilerini kullanmaktadırlar (Pagourtzi, Assimakolopoulos, Hatzichristos, & French, 2003).

Düzenli zaman aralıklarında ve ardışık zaman alanlarında gözlenen değerler kümesi zaman serileri olarak ifade edilir. Zaman birimi, ay, gün, saat, dakika vb. şeklinde ifade edilebilir. Geçmişte ortaya çıkan verilerin kullanımıyla gelecekte oluşabilecek değerlere ilişkin tahmin ve politikalar oluşturma teknikleri de zaman serisi analizleridir. Zaman serileri analizinin temel amacı, mevcut veriler temelinde matematiksel bir model geliştirmektir. Bir zaman serisinin kesin niteliğinin değerlendirilmesindeki zorluk nedeniyle genellikle uygun tahminler üretmek oldukça zordur (Khandelwal, Adhikari, & Verma, 2015). Zaman serileri analizinde çeşitli yöntemler mevcut olup her yöntem

kendine göre birtakım avantaj ve dezavantajlara sahiptir. Zaman serileri yöntemlerinin en büyük avantajlarından biri, geleneksel teknolojiler için çok karmaşık olan veri setinin doğrusal olmadığı, eksik veya çok boyutlu olduğu problemleri de çözebilme yetenekleridir (Yılmazel, Afşar, & Yılmazel, 2018). Bu avantajlarından dolayı zaman serileri tahminlemede sıklıkla kullanılmaktadır.

Talep tahmin yöntemlerinin güvenilirliği, o yöntemin başarılı olması için en önemli etkidir. Yöntemin başarılı olup olmadığı ise elde edilen tahmin sonuçlarının gerçekleşen değerlerle karşılaştırılması sonucu belirlenir. Yapılan tahminler ile gerçekte ortaya çıkan değerler arasındaki farkın açılmaya başlaması tahmin yapılan ortamın değiştiğine dair kritik bir alarm verdiği anlamına gelmektedir. Hızlı tüketim sektörü düşünüldüğünde, bu sektördeki talep trendinin iyi takip edilmesi ve ürünlerin bu tahminlere göre konumlandırılması; hem müşterilerin aradığı ürünü bulmasına hem de eksik ya da fazla stok yapılmamasına imkan sağlayacaktır. Ayrıca, bütçenin doğru yapılması, nakit akışının doğru yönetilmesi ve fırsatların kaçırılmaması gibi çeşitli faydalar da sağlayacaktır (Ahmetoğlu, 2018).

Tahmin doğruluğunun artırılması için birçok yöntem geliştirilmiştir. Geliştirilen bu metotlar; doğrusal, doğrusal olmayan ve hibrit yöntemler olarak adlandırılabilir. Doğrusal yöntemler, gözlemlenen veri noktaları ile gelecek veri noktaları arasında doğrusal bir ilişki kurarlar. Talep tahmin aşamasında doğrusal yöntemlerden ARIMA doğrusal olmayan yöntemlerden ise yapay zeka tabanlı yöntemler son yıllarda hızla geliştirilmiş ve klasik yöntemlere kıyasla daha doğru tahmin sonuçları vermesi sebebiyle birçok alanda kullanılmaya başlanmıştır.

ARIMA doğrusal istatistiki yöntemler içerisinde yer alır ve literatürde pek çok uygulamada kullanılmıştır. Bu metot, zaman serisinin kendi içindeki etkenleri çıkarmaya yaramaktadır. ARIMA, durağan zaman serilerinde kullanılmaktadır. Durağan olmayan zaman serilerinde ARIMA yönteminin kullanılabilmesi için ise öncelikle fark alma işlemi gerçekleştirilerek serinin durağan hale getirilmesi gerekmektedir. ARIMA yöntemleri üçüncü bölümde kısaca gözden geçirilmiştir.

YSA yöntemi genelleme yapabilme, sınırsız sayıda değişken ile çalışabilme, veriden öğrenebilme gibi önemli birçok özelliğe sahiptir. Bu özelliklerinden dolayı önemli avantajlar sağlayan YSA, etkin bir talep tahmin tekniği olarak öne çıkmaktadır. YSA,

faktörler arasındaki ilişki ve dereceleri öğrenmesi açısından nitel yöntemlere, istatistiksel veri kullanması açısından ise nicel yöntemlere benzemektedir. Fakat insanlar yeni öğrendikleri her sözcük için yeni anlamlar öğrenmezler. Daha önceden var olan benzer sözcüklerden yola çıkarak yeni öğrendikleri sözcüğe anlam yüklerler. Geleneksel YSA'ların en büyük eksikliği, insanlarda bulunan bu anlamlandırma özneliğinin bulunmamasıdır. Tekrarlayan Sinir Ağları (Recurrent Neural Network-RNN) ise, bir döngü oluşturarak geçmiş bilgilerin kullanılmasını sağlar ve böylelikle kareler arasında anlamlandırma yaparak sınıflandırma yapabilir. Bu anlamda, RNN'ler geleneksel YSA'lardaki bu eksikliği gidermektedir.

RNN'ler bir döngü oluşturabilmelerinden dolayı sıralı olarak gelişen olayları birbirleri ile anlamlandırabilmektedirler. Bu avantajından dolayı son yıllarda özellikle dil modelleme, çeviri, resim başlığı oluşturma, konuşma tanıma vb. gibi birçok alanda yaygın olarak kullanılmaktadırlar. Fakat RNN'ler geçmiş ile bağlantı kurulup anlamlandırma özelliklerinden dolayı bazı problemlerde başarılı sonuçlar vermesine rağmen, hangi aktivitelerin hatırlanacağı, ne kadar süre ile hatırlanacağı gibi bazı durumlar bilinmemektedir. Bütün bilgiler model içerisinde tutulmaktadır. Aktiviteler için bazı bilgiler önemli iken bazı bilgiler gereksiz olabilmektedir. Bu sebeple, tüm geçmişin saklanmasına gerek duyulmaz. Sınıflandırma aşamasında, ihtiyaç duyulan bilgi çok önceden oluşmuş ise bu bilgiye ulaşılamayabilir. Bu sebeple RNN'ler çok önceki olayları tahmin edebilmek için farklı bir mimari yapıya ihtiyaç duyarlar. Bu tür problemlerde daha iyi çalışan ve RNN'in özel bir türü ve uzun vadeli bağımlılıkları öğrenebilen Uzun Kısa Vadeli Bellek (Long Short Term Memory-LSTM) ağları kullanılmaktadır (Olah, 2015).

Teoride, RNN'ler iç mimarilerinde kendilerini tekrarlama özelliğine sahip olmalarından dolayı uzun geçmişteki aktiviteleri hatırlama kapasitesine sahiptir. Ancak, bu parametrelerin hatırlanabilmesi için titizlikle seçilmeleri gereklidir. Pratikte böyle bir parametre seçimi mümkün olmadığından RNN'ler uzak geçmişi hatırlayamazlar (öğrenemezler) (Bengio, Simard, & Franscon, 2015). LSTM ağlarında ise bu tür bir sorun bulunmamaktadır. RNN'den farklı olarak eğitim esnasında ortaya çıkabilecek "Vanishing gradient" problemi LSTM ile çözülebilir. Bu sebeple genellikle birçok aktivite sınıflandırmasında LSTM'ler tercih edilmektedir. Son yıllarda RNN'ler ile yapılmış olan başarılı çalışmaların büyük çoğunluğunda LSTM'lerin kullanılması da bu durumun bir göstergesidir.

Doğrusal ve doğrusal olmayan yöntemlerin her ikisi de her koşulda kullanılabilir uygun evrensel modeller değildirler. Bu sebeple literatürde, bu kısıtlamanın üstesinden gelebilmek ve tahmin performansının artırılmasını sağlayabilmek için birden fazla bireysel modelin avantajlarının bir araya getirildiği “hibrit” metotlar kullanılmaktadır. Hibrit metotların temel fikri, kullanılan her bir özgün metodun farklı tahmin modellerini yakalamak için kullanılmasıdır. Örneğin, bir zaman serisinin aynı zaman aralığında hem doğrusal hem de doğrusal olmayan modeller içerdiği durumlarda, ne doğrusal ne de doğrusal olmayan modeller tek başına yeterli değildir. Bu sebeple hibrit modeller homojen, yani farklı konfigürasyonlu sinir ağları ya da heterojen, yani doğrusal ve doğrusal olmayan modellerin bir araya gelmesi ile oluşturulmuş olabilirler. ARIMA’yı YSA ile birleştiren modeller iyi bir melez model örneğidir. Bu tür melez modellerde, YSA doğrusal olmayan modellerle ilgilenirken, ARIMA modeli doğrusal modellerle ilgilenir. Bu tür modeller genellikle, ARIMA modelinin ilk olarak orijinal zaman serisine uygulanması, ardından ise bu modelin kalıntılarının YSA ile modellenmesi şeklinde sıralı bir biçimde inşa edilirler.

Çalışmanın Amacı

Çalışmanın temel amacı, geçmiş dönem verilerini kullanarak gelecek dönemlere ilişkin doğru tahminler üretilebilmesinin sağlanmasıdır. İnşaat sektöründe faaliyette bulunan bir üretim işletmesinin geçmiş dönem satış verilerinin kullanılması ile satış bütçesinin oluşturulması amaçlanmaktadır. Kendine bağlı birçok alt sektörü doğrudan ya da dolaylı bir şekilde etkilemesinden dolayı “ekonominin lokomotifi” vasfını taşıyan inşaat sektörü, özellikle gelişmiş ülkeler ve Türkiye gibi gelişmekte olan ülkelerin ekonomisinde oldukça önemli bir rol oynamaktadır. Bu sektörde faaliyette bulunan her işletmenin satışlarının doğru olarak tahmin edilmesi; işletmenin artan rekabet koşullarında rekabet edebilmesi ve sürekli değişen dünyaya ayak uydurabilmesi için zorunlu bir gerekliliktir.

Bu amaçla, çalışmada verileri kullanılan üretim işletmesinin satışları ARIMA ve özel bir RNN türü olan LSTM yöntemleri kullanılarak tahmin edilmiştir. Ayrıca bu yöntemlere ilaveten ARIMA ve LSTM yöntemlerinin avantajlarını bir araya getiren bir hibrit model oluşturularak satışlara ilişkin tahmin çalışması için bu yöntem de kullanılmıştır. Tüm yöntemlerden elde edilen sonuçlar birbirleriyle ve gerçek değerler ile karşılaştırılmıştır. Farklı yöntemler kullanılarak tahmin yapılmasının amacı ise en doğru sonuçları veren yöntemin daha sonraki satış miktar bütçelerinin oluşturulmasında kullanılabilmesinin

sağlanmasıdır. Bu çalışma ile hem satışların güvenilir ve minimum hata seviyesinde tahmin edilmesiyle gelecek dönem üretim ve satış planlarının oluşturulması konusunda işletmeye fayda sağlanması hem de bundan sonra yapılacak olan benzer nitelikteki çalışmalar açısından literatüre katkıda bulunulması amaçlanmaktadır.

Çalışmanın Önemi

Sinir ağları ile ilgili yapılan çalışmalar incelendiğinde; çalışmaların daha çok mühendislik alanlarında ve YSA konusunda yoğunlaştığı görülmektedir. İşletme alanında hazırlanan tez, makale vb. araştırmalara konu olan YSA ile ilgili çalışmalar içerdikleri konular açısından değerlendirildiğinde; hisse senedi fiyat tahminlemesi, döviz kuru tahminleri, borsa endeksi tahminleri, turizm talep tahminleri, finansal başarısızlık tahminleri, satış tahminleri... vb. gibi farklı sonuçlar ortaya çıkmaktadır. Satış tahminlerine ilişkin çalışmalar incelendiğinde ise, uygulamalarda genellikle YSA ile geleneksel yöntemler arasında karşılaştırma sonuçlarına yer verilmiş olup çoğunlukla YSA yöntemi sonuçlarının daha etkin olduğu görüşüne varılmıştır. Daha önce de belirtildiği gibi geleneksel YSA'nın eksiklerini gidermek için geliştirmiş ve özel bir RNN türü olan LSTM modeli ile hazırlanmış çalışma sayısı yurt dışında oldukça fazla olmasına rağmen ülkemiz açısından oldukça sınırlı sayıdadır.

Diğer taraftan, iki farklı tekniğin kullanımı ile tahminin sınırlı kalmaması ayrıca bu tekniklerin üstünlüklerinin birleştirilmesi yoluyla oluşturulan hibrit modeller de tahmin aşamalarında kullanılmaya başlanmıştır. Sosyal bilimlere ilişkin çalışma sayısı az olmasına rağmen hibrit model oluşturularak daha verimli sonuçların elde edilebildiği görülmüştür. Bu nedenle, sinir ağları yönteminin de kullanımı ile oluşturulan hibrit modellerin işletmelerin satış planlamalarında uygulanmasına yönelik yapılan araştırma sayısının artırılması ihtiyacı vardır. Ayrıca incelenen çalışmalarda, doğru tahmin yönteminden elde edilen verimli sonuçların işletmeler açısından faydalı olacağı belirtilmiş olmasına rağmen işletmelerde dinamik bir planlama modelinin nasıl kurulacağı ve sonuçların nasıl yorumlanacağına dair net bir bilgiye rastlanmamıştır.

Bu anlamda, sürekli değişimin yaşandığı ortamda faaliyetlerini devam ettirmeye ve değişen taleplere uyum sağlamaya çalışan işletmelerin gelecekteki satışlarının etkin bir şekilde planlanmasına imkan sağlayan ARIMA, LSTM ve hibrit yöntemlerinin örnek işletmeye uygulanmasıyla gelecekte sadece bu konuda çalışma yapmak isteyen

arařtırmacılar aısından deęil uygulayıcılar aısından da nemli lde fayda saęlayacaęı düşnlmektedir. Ayrıca Trkiye’de yapılan akademik alıřmalarda ok kısıtlı sayıda LSTM modeli ile ilgili alıřmanın bulunmasından dolayı literatre de katkı saęlayacaktır.

alıřmanın İerięi

Bu alıřma; “bte kavramı ve iřletmelerde bteleme”, “talep tahmini ve tahmin teknikleri”, “uygulamada kullanılan yntemler” ve “retim iřletmesinde satıř tahmini zerine uygulama” olmak zere drt blmden oluřmaktadır.

alıřmanın birinci blmnde, bte kavramından genel olarak bahsedilmiřtir. Btenin amaları ve iřletme btelerinin ilkeleri aıklanmıř ve iřletme btelerinin eřitlerinden satıř btesi, retim btesi, faaliyet giderleri btesi, yatırım btesi ve nakit btesi incelenmiřtir. Son olarak ise iřletmelerde btelemenin neminden bahsedilmiřtir.

İkinci blmde, talep tahmini kavramı ve btelemede tahminin neminden bahsedilmiřtir. Ardından tahmin teorileri ve tahminleme teknikleri aıklanmıřtır. Tahmin teknikleri kalitatif ve kantitatif teknikler olarak bu tekniklere alt bařlıklara ayrılmıř ve incelenen her bir teknik hakkında kısa bilgi verilmiřtir. Ayrıca btelemede tahminin nemine iliřkin aıklamalara ve zaman serileri analizinde sıklıkla kullanılan doęrusal olmayan metotlar ierisinde yer alan YSA yntemine iliřkin genel bilgilere de bu blmde yer verilmiřtir.

nc blmde, alıřmanın uygulama kısmında kullanılan ARIMA, LSTM ve hibrit modellere iliřin aıklamalara deęinilmiřtir. Ayrıca bu yntemlerin kullanımı ile yapılmıř olan alıřmalara iliřkin literatr taramasına da yer verilmiřtir.

Drdnc blmde ise, inřaat sektrnde kullanılan bir rnnn retimini gerekleřtiren X iřlemesinin satıřları adet bazında ARIMA, LSTM ve oluřturulan hibrit model kullanılarak tahmin edilmiř ve elde edilen sonular incelenmiřtir. Ek olarak, elde edilen sonuların tm uygulama yapılan modeller arasında ve gerek satıř deęerleri ile karřılařtırılarak hibrit model ile elde edilen sonuların daha stn olduęu vurgulanmıřtır.

alıřmanın Kısıtları

İřletme satıř btelerinin oluřturulmasında ARIMA, LSTM ve hibrit metotların kullanımına iliřkin rnek iřletme zerinde yapılan uygulamada bazı kısıtlar sz konusudur. alıřmanın hedefi, iřletme satıřlarının tahmininde ifade edilen yntemlerin

kullanılması olduğundan işletmenin sadece geçmiş yıllara ilişkin ulaşılabilir nitelikteki aylık satış verileri kullanılmıştır. LSTM ağları, daha çok derin öğrenme eğilimli olup geniş veri setleri ile daha yüksek başarılar elde etmektedirler. Fakat sınırlı sayıda da olsa az veri seti ile eğitildiği örnekler literatürde mevcuttur. Bu açıdan, uygulama örneğinde konu olan işletmenin ulaşılabilir nitelikteki 9 yıla ilişkin aylık satış verilerinden faydalanılarak tahmin yapılmıştır ve tahmin işlemi için ağların eğitimi yüzlerce kez denenmiş olup, en iyi olduğu düşünülen sonuçlar kullanılmıştır.

Çalışmanın Metodolojisi

Bu çalışmada öncelikle ARIMA, LSTM ve hibrit yöntemlerin kuramsal yapısını ortaya koymak amacıyla bu tekniklerin kullanımı ile yapılmış tahmin çalışmalarına ilişkin literatür taramasına yer verilecektir. Sonrasında işletmenden elde edilen aylık satış verileri kullanılarak ARIMA, LSTM ve bu iki yöntemin avantajlarını birleştirerek oluşturulan bir hibrit metod uygulanacak ve elde edilen satış tahmini sonuçları ortaya konulacaktır. Çalışmada farklı yöntemlerden elde edilen tahmin sonuçları arasında karşılaştırma da yapılacaktır. Tahmin için kullanılan yöntemlerin karşılaştırılmasıyla MAPE hata değeri olarak en düşük değeri veren model en iyi sonucu veren model olarak belirlenecektir. Uygulama aşamasında, belirtilen tüm yöntemler için kullanılabilmesi özelliğinden dolayı Python programı tercih edilmiştir.

Çalışma verilerinin toplanması kısmında, literatür taranarak işletmelerde bütçeleme, tahmin teknikleri, ARIMA, YSA, LSTM ve Hibrit metod ile satış tahmini yaklaşımlarına yönelik teorik alt yapı incelenmiştir. Uygulama aşamasında ise, işletme yöneticileri ile görüşülerek işletmenin geçmiş yıllarına ilişkin aylık satış verileri incelenmiş ve uygulamanın gerçekleştirilebilmesi için gerekli olan veriler toplanmıştır.

Uygulamanın gerçekleştirilmesi için izlenecek adımlar aşağıda sıralandığı gibidir.

- a. Yapay sinir ağının öğrenmesi istenen olay ile ilgili daha önce gerçekleşmiş olan örneklerin toplanması,
- b. Verilerin ön işlenmesi ve normalizasyonu,
- c. Test ve eğitim verilerinin ayrılması,
- d. Eğitim verileri ile ağın eğitilerek tahmin sonuçlarının alınması,
- e. En iyi olduğu düşünülen tahmin sonuçlarının test verileri ile karşılaştırılarak değerlendirme yapılması.

BÖLÜM 1: BÜTÇE KAVRAMI VE İŞLETMELERDE BÜTÇELEME

Bu bölümde; bütçe kavramı ve bütçenin amaçları, işletme bütçelerinin temel prensip ve ilkeleri, işletme bütçelerinin çeşitleri ile işletmelerde bütçelemenin önemi konuları ele alınmıştır.

1.1. Bütçe Kavramı

Günlük yaşamın birçok alanında bilinçli veya bilinçsiz olarak bütçe yapılır. Bu bütçeler; kişisel, aile veya işletme düzeyinde olabilir. Ancak hepsinin ortak yanı gelecekteki gereksinimleri karşılayarak amaca ulaşılması çabasıdır. Bütçe kelimesi, Fransızca'da deri torba ya da pazar çantası olarak çevrilen "bougette" kelimesinden gelmektedir ve İngilizce'ye "budget" olarak yerleşmiştir (Koç, 1989). Bütçe kavramı, Hazine Bakanı tarafından İngiltere'de Parlamenta'ya sunulmak için taşınan ve devletin mali kaynak ve ihtiyaçlarının içinde bulunduğu deri çanta için kullanılmış, daha sonra da taşınan bu belgelerin kendisi için kullanılmıştır (Tepeli, 2010). Türkçe'de ise "bütçe" kelimesi; sözlük anlamı olarak bir devletin, kuruluşun, aile ya da kimsenin geleceğe dönük belli bir zaman için planladığı gelir ve giderlerin tümü anlamına gelir.

Teknolojinin gelişmesi ve pazarların genişlemesi sonucunda yaşanan ekonomik gelişmeler işletmelerin çok daha karmaşık bir yapıya girmelerine sebep olmaktadır (Sevgener & Hacırüstemoğlu, 2000). Bu durum, işletmelerde yönetime düşen sorumlulukları artırmış ve işletmelerin yaşamlarını devam ettirebilmeleri için planlı davranmalarını gerekli hale getirmiştir. Bu sebeple, işletmelerde bütçe ve bütçeleme kavramlarının önemi artmıştır (Püskül, 2010).

Günümüz işletmelerinde planlama, örgütleme, koordinasyon ve kontrol işlevlerini işletmenin amaç ve hedeflerine ulaşabilecek bir biçimde gerçekleştirmek yönetimin en önemli amacı haline gelmiştir. Yöneticilerin bu hususlardan ilk olarak planlamayı ele almaları gereklidir. Planlama zaman açısından kısa ve uzun vadeli olarak iki şekilde yapılabilmektedir. Literatürde, kısa vadeli planlar için daha çok bütçe kavramı kullanılmaktadır.

Geleceğe dair bir planlama ve kontrol aracı olan bütçe; bir yönetimin sürekli olarak aldığı ve gözden geçirdiği kararlar ile işletmenin geleceğini planlayabilir ve kontrol edebilir inancına dayanır. Bu nedenle işletmede yönetimin rastgele genel izlenimlere dayalı

olaylara dayandırılması yerine planlı bir şekilde hesaplanmış ve kontrol edilmiş verilere dayandırılması anlayışı benimsenmelidir. Bu sayede bütçeye güven, karar verme sürecinin temelini diğer bir ifade ile yönetimin ruhunu oluşturur (Welsch, 1971).

İşletme bütçesi kavramı ise, bütçe kavramından doğmuştur ve literatürde farklı şekillerde tanımlanmıştır. Bu kapsamda, işletme bütçesi “belirli bir dönemdeki beklenen gelir ve giderlerin gösterildiği finansal plan ya da saptanan amaçlar doğrultusunda belirlenen faaliyetlerin, uygulama ve sonuçlarının sayısal olarak gösterildiği finansal planlar“ olarak ifade edilmektedir (Büker, 2001). Diğer bir tanıma göre ise, "önceden belirlenen bir hedefe ulaşmak için işletmenin geleceğe yönelik bir dönemde takip edeceği politikayı ve yapacağı şeyleri parasal olarak ve sayısal terimlerle açıklayan bir rapor veya raporlar dizisidir" şeklinde ifade edilmektedir (Sevgener & Hacırüstemoğlu, 2000). İşletme bütçesini kısaca işletmelerin planlanan faaliyetlerinin rakamlarla ifade edilmesi şeklinde tanımlamak da mümkündür.

Bütçeleme kavramı da işletme bütçesi ile birlikte sıklıkla kullanılmaktadır. Bütçeleme, geleceğe yönelik belli bir dönemde yapılacak işleri önceden ve rakamsal olarak gösteren bütçenin yapılabilmesi için ihtiyaç duyulan teknik ve yöntemleri ifade eden genel bir terimdir (Haftacı, 2005). İşletme bütçesi ise bütçeleme işlemi sonucunda oluşmaktadır.

1.2. Bütçenin Amaçları

İşletmeler günlük taleplerini karşılayacak mal ve hizmet üretimlerini gerçekleştirebilmek için kısa vadeli planlara ihtiyaç duymaktadırlar. Kısa vadeli planların oluşturulması ise, yönetimin planlama kapsamındaki görevlerinden birisidir. Bu bağlamda, kısa vadeli planlama, alternatif planlar arasından birinin seçilerek seçilen bu plana ilişkin süreçlerin gerçekleştirilmesini içermektedir (Karacan, 2008). Kısa vadeli bir planlama aracı olan işletme bütçelerinin temel amacı, işletme faaliyetlerinin en verimli düzeyde planlanması ve geleceğe dair kararlarda yöneticilere yardımcı olunmasıdır. En verimli sonuçların elde edileceği hedeflerin ve bu hedeflere ulaşabilmesi için yapılması gerekenlerin belirlenmesi işlemi bütçeleme ile saptanmaktadır. Bütçe çalışmaları yardımıyla belirlenen yöntem ve hedeflerin, alt kademelerdeki çalışanlara iletilmesi ve çalışanların kendilerinden beklenen performansa yönelik bilgilendirilmeleri hedeflenmektedir. Ayrıca, buna ilaveten işletmelerin kısa ve uzun vadeli planları ile departmanları arasında bir uyumun gerçekleştirilmesi de hedeflenmektedir (Püskül, 2010).

Bütçenin amaçlarının genel olarak planlama, koordinasyon ve kontrol olmak üzere üç başlık altında toplanması mümkündür.

1.2.1. Planlama

Bütçe organizasyon yapısı itibariyle bir plan türü olarak değerlendirilmektedir. Bu sebeple bütçenin bir plan olarak amacı, en iyi sonuçların alınabileceği hedeflerin belirlenmesi ve bu belirlenen hedeflere ulaşma yollarının saptanmasıdır. Planlama, işletme için amaçlar ve hedeflerin saptanmasıyla başlar; geçerli seçenekleri analiz eder ve optimum seçeneği belirleyerek karara ulaşır. Kar amaçlı olsun ya da olmasın tüm işletmeler plan yapmaya ihtiyaç duymaktadırlar. Bu planlar zaman açısından kısa ve uzun vadeli olarak düzenlenebilirken, kapsam açısından kısmi ve genel planlar şeklinde düzenlenebilirler (Pekiner, 1988). Hazırlanan planlar sonucunda belirlenen hedeflere ulaşabilmek için gerekli unsurlar tespit edilmelidir. Ancak, bu unsurlar tespit edilirken işletmelerin sahip olduğu kaynakların en etkin düzeyde kullanılmasının sağlanması gerekmektedir. Belirlenen dönemde ve sonrasında işletmenin verimliliği, karlılığı ve likiditesi ile uzun vadede işletmenin gelişmesi ve sürekliliği arasında uygun olan en iyi dengenin sağlanması olarak bilinen bu kaynaklar planlamanın olduğu gibi bütçelemenin de temel amaçlarını oluşturmaktadır (Yılmaz F. , 2001).

1.2.2. Koordinasyon

İşletmeler asıl hedeflerine ulaşabilmek için daha önce de ifade edildiği gibi kısa ve uzun vadeli planlarını uyumlu bir şekilde hazırlar. Fakat, bu durum tek başına yeterli değildir. Dönemsel veya kısa vadeli planlarda işletmenin her bir departmanının işlerinin de iyi bir şekilde koordine edilmesi gereklidir. Örneğin; pazarlama, üretim ve finans departmanları arasında koordinasyonsuzluk veya haberleşme eksikliği söz konusu olduğunda işletmenin başarılı olması güçleşir. Bu nedenle bütçenin diğer bir amacı da koordinasyonun sağlanmasıdır. Böylelikle, bütçeleme işletmenin bütünleşmesini, üretim faktörlerinin optimal bileşimini, sosyal bir birlik oluşturulmasını, işletme politikalarının yürütülmesini ve işletmenin bütünleşmesini sağlar (Sevgener & Hacırüstemoğlu, 2000: 306).

İşletmenin temel amaç ve hedeflerin gerçekleştirilmesini sağlamak için yönetim aracı olarak kullanılan koordinasyon; işletme faaliyetlerinin sağlıklı sürdürülebilmesi için önceden belirlenen amaç ve kurallara uygun olarak işletme çalışanları ve departmanlar arası iletişim ve bilgi akışının dengeli olarak yürütülmesini sağlamayı amaçlar (Aras,

2014: 5). Aynı zamanda koordinasyon, işletmenin farklı bölüm ve işlevleri arasında uyumlaştırma sağlayarak işletmenin verimliliğini de yükseltir.

1.2.3. Kontrol

Kontrol, politikaların, planların, amaçların ve standartların elde edilmesini güvence altına alacak önlemler olarak ifade edilebilir. Yönetim bu önlemler yardımı ile işletme faaliyetlerinin belirlenen hedeflere ulaşip ulaşmadığını denetler. Hedeflerden sapmaların neler olduğunu, bu sapmaların nedenlerini belirler ve düzeltici önlemleri zamanında almaya çalışır.

İşletmeler için; ana bütçe ve kısmi bütçelerin tümü önemli bir kontrol aracıdır. Bütçe rakamlarıyla gerçekleşen rakamların devamlı surette karşılaştırılması rakamlar arasındaki farklılığın belirlenmesine ilaveten ortaya çıkan farklılıkların sebeplerinin araştırılması ve gerekli tedbirlerin alınmasına da olanak sağlamaktadır (Pekiner, 1988: 322).

Ancak şunu da eklemek gereklidir ki bütçeleme, başlı başına bir kontrol olmayıp, sadece kontrole olanak sağlayan bir araçtır. Bütçeleme ile kontrolün esası öncelikle bütçe rakamlarının belirlenmesi, ardından fiili rakamların ortaya çıkması ve bütçe rakamları ile fiili rakamların karşılaştırılarak farklılık varsa bunların nedenlerinin araştırılmasına dayanır.

Bütçe vasıtasıyla kontrol yapılabilmesi için işletmelerde aşağıda belirtilen tedbirlerin alınmış olması gereklidir (Moore & Jaedicke, 1988: 668).

- İşletme içindeki yetki ve sorumluluklar açıkça tespit edilmiş olmalı,
- Faaliyetlerle ilgili politika, hedef, plan ve standartlar belirlenmiş ve bunlar arasındaki bağlantılar sağlanmış olmalı,
- İşletme içerisinde raporlama sistemi kurulmuş olmalı,
- Bütçelenmiş değerler ile fiili değerler arasında oluşan farklılıkların sebeplerinin belirlenmesi ve gerekli düzeltmenin yapılması işinin daimi bir görev haline dönüştürülmüş olması gereklidir.

1.3. İşletme Bütçelerinin İlkeleri

İlke genel anlamda, “bilime temel olan, yön veren, gelecek eylem, gözlem ve denetimler için başlangıca temel olan tartışılmayacak ölçüde sağlam bilgi, düşünce ve kanı” şeklinde tanımlanmaktadır. İşletme bütçelerinin başarılı bir biçimde hazırlanması bir takım ilkelerin esas alınmasıyla mümkündür. Bu ilkelere uygun bir biçimde oluşturulan bütçeler, hazırlanan bütçenin etkinliğini arttıracaktır ve bütçelerin organizasyondaki herkes tarafından sahiplenilmesini sağlayacaktır. İşletme bütçelerinin ilkelerinin sayısına yönelik literatürde tam anlamda bir görüş birliği olmamasına karşın bunların başlıcaları aşağıdaki gibi ifade edilebilir:

- Örgütsel uyum ilkesi,
- Yönetimin desteği ilkesi,
- Katılımcılık ilkesi,
- Gerçekçilik ilkesi,
- Sorumluluk muhasebesi ilkesi,
- Esnek uygulama ilkesi,
- İzleme ilkesi.

1.3.1. Örgütsel Uyum İlkesi

Bu ilkeye göre, bütçe çalışmaları görev yetki ve sorumlulukların açıkça belirlendiği sağlıklı bir örgüt yapısına dayanmalıdır. İşletme bütçelerinde belirlenen amaçlar, planlar ve politikalar işletme çalışanları tarafından uygulamaya konulup gerçekleştirileceğinden işletme bütçeleri, yetki ve sorumluluk merkezleri itibariyle düzenlenerek uygulamaya konulmalıdır (Haftacı, 2005: 5). Bütçenin bir başarı değerlendirme aracı olarak kullanılabilmesi ancak böyle bir düzenleme ile sağlanabilir.

Bütçenin değerlendirmesine kaynak teşkil eden veri tabanı muhasebe kayıtlarıdır. Bütçe ile fiili işlemlerin gerçekleştirilebilmesi için gereken bilgi muhasebe verilerinden alınmaktadır. Bu sebeple karşılaştırılabilir olması için bütçeler hesap planına uyumlu

olmalıdır (Hacırüstemođlu, 2006: 214). Bütçelerin başarısı için muhasebede kullanılan hesap planına uygun alt hesaplar da oluşturulmalıdır.

1.3.2. Yönetimin Desteđi İlkesi

Özellikle işletme yönetimi tarafından bütçe çalışmalarına zaman ayrılması ve çalışmaların desteklenmesi, işletme bütçesinin başarılı olabilmesi için önemlidir. Bütçe sisteminin kar planlama ve kontrol fonksiyonuna sağladığı katkılar belirtilmeli ve sistemin sahip olduğu potansiyel güç net bir şekilde ortaya koyulmalıdır. Böylece grup çalışması ve düzenli faaliyetler için gerekli ortamı yaratan bu sistem genel müdürden başlayarak bütün yönetim üyelerinin tam desteđine sahip olabilir (Koç, 1989: 33). Başarılı bir işletme bütçesinin ilk koşulu olan yönetimin desteđi ilkesine göre, işletmede bütçenin yalnızca bir muhasebe raporu deđil, aynı zamanda bir yönetim aracı olduğu görüşü de çalışanların tümü tarafından benimsenmelidir. Ayrıca yöneticiler tarafından bütçe çalışmaları tam olarak desteklenmelidir (Büyükmirza, 2007: 668).

1.3.3. Katılımcılık İlkesi

Katılımcılık ilkesi, bütçelerde belirlenen amaç ve planların gerçekleştirilebilmesi yönetimdeki tüm kademelerin bütçelerin düzenlenmesi sürecine katılması gerektiğini ifade eder.

İşletme bütçelerinin muhasebe ve finans müdürü, bütçe müdürü, iktisatçılar, istatistikçiler ve bölüm yöneticilerinin işbirliğiyle düzenlenmesi daha sağlıklı sonuçlar elde edilmesini sağlayacaktır. İşletmelerdeki bütçe departmanının sorumluluđu, bütçe faaliyetlerini denetlemek ve bütçelerin düzenlenmesi ve uygulanmasına yönelik konularda danışmanlık ve koordinatörlük hizmeti sağlamaktır (Haftacı, 2005: 5). O halde işletme bütçelerinin düzenlenmesinden birinci derece kademe yöneticileri sorumludur. Bütçelerin hazırlanmasına yönelik bilgilerin sağlanması ise çeşitli bölüm yöneticilerinin yükümlülüđüdür.

Bütçeleme çalışmalarında başarı, katılımın sürekli ve planlı olmasını aynı zamanda işletmede iletişimi ve önemli bir işbirliğini gerektirir. Bu ilke doğrultusunda işletmede her seviyedeki yöneticinin işletme bütçelerinin düzenlenmesi için katılımı önemlidir. (Püskül, 2010).

1.3.4. Gerçekçilik İlkesi

Gerçekçilik ilkesine göre yönetim, amaç ve hedefleri tespit ederken aşırı kötümserlikten kaçınması gerektiği gibi aşırı iyimserlikten de kaçınılmalıdır. Hazırlanan işletme bütçelerinin başarısı verilerin ve beklentilerin gerçekçi olmasıyla yakından ilgilidir.

Standartların ulaşılabilmesi mümkün olmayan yüksek bir verimlilik seviyesinde belirlenmesi nedeniyle gösterilen aşırı çabaya rağmen standartların yakalanamaması hem işletme çalışanlarını olumsuz etkiler hem de bütçenin baskı aracı olduğu fikrinin benimsenmesine sebep olur. Hedeflerin ciddi bir çabaya ihtiyaç duyulmaksızın ulaşılacak seviyede belirlenmesi ise, bütçe standartları haline getirilen faaliyetlerin gerçek bir ölçü olma niteliğini taşımaz ve işletme personelinin verimli faaliyetlerde bulunmasına yöneltme yapmaz (İnanç, 2010: 9).

1.3.5. Sorumluluk Muhasebesi İlkesi

Sorumluluk muhasebesi ilkesine göre, işletmedeki muhasebe sisteminin yönetimin planlama ve kontrol gereksinimine cevap verebilecek nitelikte olması gereklidir. Bu özellikleri taşıyan muhasebe, sorumluluk muhasebesi olarak ifade edilir. Sorumluluk muhasebesi, işletme faaliyetleriyle ilgili bilgilerin sınıflandırılmasında sorumlu yöneticileri ve örgütsel sorumlulukları dikkate alır (Koç, 1989). İşletme yönetiminin başarısında planlama ve kontrol faaliyetlerinin rolünün artmasıyla birlikte sorumluluk muhasebesi de daha fazla önem kazanmıştır.

Sorumluluk muhasebesi uygulamalarına göre, bir sorumluluk merkezinin yöneticisi, birimin girdileri veya çıktıları ile ilgili belli kararları vermekten sorumludur. Bu bağlamda sorumluluk merkezleri aynı zamanda birer karar merkezidir (Nasuhi & Yücel, 2002: 451). Bu muhasebe sisteminde, hesap sınıfları ve muhasebe planı yöneticilerin sorumluluk alanına göre düzenlenmektedir. Böylelikle sorumluluk muhasebesinin varlığı halinde, bütçelerin düzenlenmesi esnasında, muhasebe biriminin kullandığı hesap planlarından yararlanılabilmekte ve aynı gelir-gider sınıflamaları kullanılabilmektedir (Akdoğan, 2009: 615).

Bu ilke doğrultusunda işletme bütçelerinin hazırlanmasında sorumluluk merkezleri esas alınır. Bu sayede, her bir sorumluluk merkezi yöneticisinin planladığı amaçlara ne derecede ulaşıp ulaşmadığı belirlenebilir.

1.3.6. Esnek Uygulama İlkesi

Bu ilke, işletme bütçelerinin ihtiyaç duyulan hallerde ve değişen şartlar neticesinde güncellenebileceğini ve yeniden düzenlenebileceğini ifade etmektedir (Haftacı, 2005: 6).

İşletme bütçelerinin geleceğe dair tahminlere dayanmasından ve bütün olayları kapsayamamasından dolayı kimi zaman bazı unsurların gözden kaçması ya da uygun biçimde değerlendirilmemesi gibi durumlar söz konusu olabilmektedir. Böyle durumlarda gerekli düzeltmelerin yapılabilmesi mümkündür. Ancak bütçenin herhangi bir noktasında bir düzeltme yapıldığında, diğer ilgili bölümlerde de düzeltme yapılması gerekebileceği unutulmamalıdır.

1.3.7. İzleme İlkesi

İşletme bütçeleri yöneticilere şirketin kısa ve uzun vadeli geleceği adına önemli sorumluluklar yüklemektedir. İşletmenin bütçe sistemi, bireysel olarak yöneticilerin başarısını ölçmede etkin bir temel oluşturur. İşletme yönetimi çalışanların bütçe performansını özenle takip etmelidir. Bu ilke olumlu ve olumsuz sapmaların dikkatli bir şekilde araştırılması gerekliliğine ve sapmaların izlenerek analiz edilmesiyle düzeltici önlemlerin alınmasına dayanmaktadır (Akdoğan, 2009: 4). Olumsuz sonuçların ortaya çıkması durumunda gerekli düzeltici önlemler alınarak olumsuzluklar ortadan kaldırılmaktadır. Bu ilke gereğince olağanüstü olumlu performansa yönetim çok önem vermeli ve bunu ödüllendirmelidir. İzleme ilkesi dikkate alındığı sürece hem bütçenin hem de işletme çalışanlarının verimlilikleri artabilir.

1.4. İşletme Bütçelerinin Türleri

İşletme bütçeleri, konularına, sorunları ele alış biçimine, amaçlarına, teknik yapılarına, temel alınan başlangıç rakamlarına, kapsamlarına ve rakamların niteliğine göre olmak üzere farklı şekillerde sınıflandırılabilir (Haftacı, 2005: 8).

1.4.1. Konuları Bakımından İşletme Bütçeleri

Konuları bakımından işletme bütçeleri gelir ve gider bütçeleri olarak ikiye ayrılmaktadırlar.

1.4.1.1. Gelir Bütçesi

Gelir bütçesi, faaliyet sonuçlarının gelir ve hasılat bakımından tahminin ve değerlemesinin yapıldığı sayısal planlardır. Gelir bütçesinde, ilgili birimin üretim, gelir ve hasılat akışları bir bütün olarak gösterilir. Bu bütçeler; satış gelirleri, diğer faaliyetlerden olağan gelir ve karlar, olağan dışı gelir ve karlar gibi gelir verilerine ilişkin tahminleri içerirler.

1.4.1.2. Gider Bütçesi

Gider bütçesi, üretilen hizmet veya mamul ile üretim maliyeti arasındaki ilişkiler bakımından faaliyet sonuçlarının değerlendirildiği bütçelerdir. Maliyet açısından; direkt ilk madde ve malzeme, direkt işçilik, genel üretim giderleri ve satılan malın maliyeti bütçeleri, gider açısından; pazarlama, satış ve dağıtım, genel yönetim ile araştırma geliştirme giderleri gider bütçelerine örnek verilebilir.

1.4.2. Sorunları Ele Alış Biçimlerine Göre İşletme Bütçeleri

Bu açıdan bütçeler, dönemsel bütçeler ve proje bütçeleri olmak üzere iki gruba ayrılırlar.

1.4.2.1. Dönemsel Bütçeler

Belirlenen bir döneme ilişkin tüm faaliyetleri ve sonuçları ele alan bütçe türüdür. Bütçeler esasları itibariyle yıllık olarak hazırlanmakla birlikte, bir yıla ilişkin sonuçların ihtiyaca göre altı ay, üç ay, ay gibi maliyet dönemlerine bölünmesiyle dönemsel bütçeler hazırlanabilir.

1.4.2.2. Proje Bütçeleri

Belirli bir projenin tamamlanmasını hedefleyen bütçeler ve bu projelere ilişkin tahmin ve değerlendirmeleri içeren sayısal planlardır. Uzun süreli yatırım projelerinin ilgili yıla düşen bölümüne ilişkin tutarlar yatırım bütçesi adı altında proje bütçelerini oluşturmaktadır. Projenin gerçekleştirilme süresine bağlı olarak bu bütçelerinin kapsadığı zaman değişiklik göstermektedir (Haftacı, 2005: 13).

Proje yöneticisi, bazı zamanlarda işletmedeki çeşitli fonksiyonel departmanlardan personel ve diğer kaynak ihtiyacını karşılayabilir. Bu gibi bir durumda, proje bütçesi söz konusu departmanın bütçelenmiş miktarlarını içerir. Bundan dolayı bütçe hazırlanması

esnasında, kendine kaynak sağlayan departmanın bütçesi ile proje bütçesinin uyumlu olması oldukça önemlidir (Püskül, 2010: 13).

1.4.3. Amaçlarına Göre İşletme Bütçeleri

İşletme bütçeleri amaçlarına göre program ve faaliyet bütçeleri şeklinde ikiye ayrılmaktadırlar.

1.4.3.1. Program Bütçeleri

Belli programların gerçekleştirilmesi amacıyla işletme yönetimi tarafından yapılmış olan sayısal planlardır. Reklam, yönetim ve diğer fayda/maliyet ile ilişkisi doğrudan belirlenemeyen fakat belli programların yerine getirilmesini ulaşılabilecek sonuç olarak ele alan bütçeler olarak da tanımlanabilir. Program bütçesi uygulamasında, maliyet/fayda karşılaştırması önemlidir ve bütçe olanaklarının verimli kullanımı açısından mevcut seçenekler arasından en uygun olanının seçilmesi gereklidir. Program bütçelerinin uygulanmasında, gerekli verilerin sağlıklı bir şekilde toplanması ve değerlendirilmesinin yanında etkin bir muhasebe sistemine de ihtiyaç duyulmaktadır (İnanç, 2010: 14).

1.4.3.2. Faaliyet Bütçeleri

Faaliyet sonuçlarının gelirler ve giderler ile ilişkilerinin doğrudan doğruya kısa sürede ve ölçülebilir düzeyde belirlenebildiği sayısal planlardır.

Bu türdeki bütçeler düzenleniş biçimlerine göre iki bölümden oluşurlar:

- a) Sorumluluk bütçeleri,
- b) Satış bileşimlerini ve mamul hatlarını programlama bütçeleri.

Sorumluluk bütçesinde; sorumlu bölümlere göre işletmenin öngördüğü faaliyetler gruplandırılır. Bu bütçelerin amacı, dikkate alınan dönem faaliyetlerini başlangıçta belirlenmiş ölçülerle karşılaştırmak ve bu şekilde etkin ve yeterli bir faaliyet yönetiminin gerçekleştirilip gerçekleştirilmediğini kontrol etmektir.

Satış bileşimlerini ve mamul hatlarını programlama bütçelerinin amacı ise, üretim ve satış bütçeleri arasında optimal sonucu verecek araştırmaların yapılmasıdır. Bu türdeki bütçelerde ürünün getireceği hasılat ve maliyeti diğer alternatiflerle karşılaştırılmaktadır (Peker, 1988: 371).

1.4.4. Teknik Yapılarına Göre İşletme Bütçeleri

Teknik yapılarına göre bütçeler; statik (durağan) bütçeler, karşılaştırmalı statik bütçeler ve dinamik (esnek) bütçeler olmak üzere üç gruba ayrılırlar.

1.4.4.1. Statik (Durağan) Bütçeler

Gelecekteki belirli bir faaliyet hacmi dikkate alınarak yalnızca bu faaliyet hacmi için düzenlenen bütçelerdir. Tek bir faaliyet hacmine göre hazırlanmalarından dolayı hacimdeki değişimlere karşı duyarlı değildirler. Bu sebeple bütçe verileri ayrıntılı bir düzeyde ele alınmaz. Statik bütçeler, uygulama kolaylığından dolayı sıklıkla kullanılmaktadırlar.

Faaliyet hacmi; direkt üretim miktarı, direkt işçilik saati, makine saati gibi kıstaslarla ifade edilebilir.

1.4.4.2. Karşılaştırmalı Statik Bütçeler

Alternatif bütçe olarak da adlandırılan karşılaştırmalı statik bütçeler, farklı faaliyet hacimleri için hazırlanmış bir dizi statik sayısal planlardan oluşmaktadır. Bu bütçeler, alternatif hareket biçimlerinden en yüksek gerçekleşme olasılığı olanların diğerlerine göre daha önceden bütçe taslaklarının hazırlanması sistemine dayanmaktadır (Konuk, 2010: 19). Diğer bir deyişle bu tür bütçelerde, gerçekleşme olasılığı en fazla olan birden çok durağan bütçe yan yana getirilir, sonrasında ise belli bir dönemin başlamasıyla yöneticilere hangi bütçeyi esas alacakları açıklanır.

1.4.4.3. Dinamik (Esnek) Bütçeler

Dinamik bütçelerde bütçe rakamları, farklı fiili hacim ve kullanışlarına göre ayarlanabilecek şekilde düzenlenir. Bu türdeki bütçeler, yönetsel kontrol sürecinin bir aşaması olarak gerçekte ortaya çıkan sonuçlar ile bütçelenmiş sonuçların karşılaştırılması imkanını sağlarlar. Bu nedenle, gerçekleşen ve bütçelenen rakamlar arasındaki farkların belirlenerek gerekli tedbirlerin alınması konusunda da faydalıdırlar (Püskül, 2010: 16).

İşletmeler bazen planladıkları faaliyet hacimlerine ulaşamazlar ya da bu hacimleri aşabilirler. Böyle durumlarda bütçe sonuçlarının nasıl etkileneceğinin önceden bilinmesi yönetim açısından gerekli tedbirlerin alınmasına yardımcı olmaktadır. Bu durum esnek bütçe uygulamasının yararlarından biridir.

1.4.5. Kapsamlarına Göre Bütçeler

Kapsamlarına göre bütçeler genel ve bölümsel bütçeler olmak üzere iki gruba ayrılırlar.

1.4.5.1. Genel Bütçeler

İşletmenin tümünü ele alan, diğer bir deyişle işletmenin bölümsel bütçelerinin bir araya getirilmesiyle oluşan sayısal planlardır. Bu tür bütçeler, işletmelerin farklı faaliyet ve işlevlerine göre düzenlenmiş olan bütçelerin ulaşılacak genel amacı gösterecek şekilde birleştirilerek özetlenmesi yoluyla hazırlanmaktadır.

Temel sorunu oluşturduğu gerekçesinden dolayı bütçeleme faaliyetlerine genellikle satış bütçesinden başlanmaktadır. Bu varsayım, tam rekabet ve/veya alıcı pazarın hakim olduğu iktisadi yapılar için doğrudur. Fakat bazı durumlardaki piyasa koşullarında arz düşük, talep yüksek olabilmektedir. Satış hacminin planlanması bu gibi durumlarda önemini yitirirken, üretim unsurları ya da finansman daha önemli bir konuma geçmektedir (Püskül, 2010). Genel bütçe aşağıdaki bütçelerin birleşiminden oluşur.

- Satış Bütçesi
- Üretim Bütçesi
 - Direkt İlk Madde ve Malzeme (Hammadde) Bütçesi
 - Direkt İşçilik Bütçesi
 - Genel Üretim Giderleri (GÜG) Bütçesi
 - Dönemsonu Mamul Stoku Bütçesi
- Faaliyet Giderleri Bütçesi
 - AR-GE Giderleri Bütçesi
 - Pazarlama, Satış ve Dağıtım Giderleri Bütçesi
 - Genel Yönetim Giderleri Bütçesi
- Yatırım Bütçesi
- Nakit Bütçesi
- Proforma Gelir Tablosu
- Proforma Bilanço

Genel bütçenin hazırlanması satış tahmininin gerçekleştirilmesi, beklenen üretim hacminin belirlenmesi, faaliyet giderleri ve üretim maliyetlerinin tahmin edilmesi, işletmenin

gelecek dönem yatırımlarının planlanması, nakit akışı ile diğer finansal unsurların belirlenmesi ile tahmini finansal tabloların düzenlenmesi olmak üzere beş aşamadan oluşmaktadır.

1.4.5.1.1. Satış Bütçesi

Satış bütçesi, bir işletmenin bütçe sisteminin başlangıcını oluşturmaktadır. Bu bütçe ile işletmenin toplam satışları, ürün çeşidi açısından miktar ve tutar şeklinde gösterilir. Pazar payının, satışların ve karın artırılması satış bütçenin genel amaçları arasında sayılabilir. Ayrıca hangi mamulün hangi fiyattan satılacağı tahmin edilmesi ve buna bağlı olarak işletmenin planlanan satış hâsılatının öngörülmesi de satış bütçesinin hazırlanmasının amaçları arasında yer alır.

Bütçe dönemine ilişkin satış tahminlerinin esas alındığı satış bütçelerinin gerçeğe uygun bir biçimde hazırlanması diğer bütçelerinde gerçekçi olması açısından önemlidir. Bu sebeple satış bütçelerinin doğru ve dikkatli bir şekilde hazırlanması gerekmektedir (Karaca, 2008).

Satış bütçeleri genellikle 3 aylık, 6 aylık ya da 1 yıllık dönemleri kapsamaktadır. Bu dönemler, geçmiş dönemler veya birbirleri ile karşılaştırılmak amacıyla ay ve haftalara bölünebilir. Satış bütçesinin hazırlanmasındaki sorumluluk; organizasyonun şekline, işletmenin büyüklüğüne, işletmenin türüne ve tahmin yöntemlerine göre değişmektedir. Satış bütçesinin düzenlenmesindeki sorumluluk, genellikle satış birimi yöneticileri ve yardımcılarına aittir.

1.4.5.1.2. Üretim Bütçesi

İşletme bütçesinin hazırlanmasında en önemli bütçe başlıklarından birisi üretim bütçesidir. Satış için öngörülen miktar ve zamanlar üretim bütçesindeki ana verileri oluşturur.

Üretim bütçesi, bütçelenmiş satışları karşılayabilmek ve stokların işletme yönetimi tarafından istenilen düzeyde tutulabilmesi için her bir mamul türünden belirlenen dönemde ne kadar üretileceğini göstermektedir. Bunun yanı sıra üretim bütçesi ile ilgili dönemler için stok gereksinimleri de beyan edilmektedir. Üretim planlamasında sıklıkla karşılaşılabilen bir sorun olan satışlar, stoklar ve üretim düzeyleri arasındaki dengeyi sağlayabilmek üretim bütçesinin temel amacıdır. Bu bütçenin verimliliğinin yüksek

olması için direkt ilk madde malzeme bütçesi, direkt işçilik bütçesi ve genel üretim giderleri gibi bütçelerinde oluşturulması gereklidir.

İşletmenin mevcut üretim kapasitesinin sınırlı ve satış departmanının isteklerini karşılayamayacak seviyede olması durumunda, üretim bütçesi işletmenin temel bütçesi olarak ele alınır. Bu durum söz konusu olduğunda satış bütçesi üretilecek mamule göre düzenlenecektir.

Üretim bütçeleri hazırlanırken öncelikle işletmenin stok politikaları belirlenir. Ardından satış bütçesi ve satış politikalarına göre üretilecek mamul miktarları tespit edilir. Son olarak ise, üretilecek mamul miktarları ilgili dönemler itibariyle zaman planına bağlanır. Buna göre bütçe dönemindeki üretim miktarının aşağıdaki gibi hesaplandığını ifade etmek mümkündür.

$$\text{İhtiyaç Duyulan Mamul Miktarı} = \text{Bütçelenen Satış Miktarı} + \text{Dönem Sonu İstenilen Stok Miktarı} - \text{Dönem Başı Stok Miktarı}$$

Bütçe Döneminde Üretilmesi Gereken Mamul Miktarı

Üretim bütçesinin hazırlanması ve programlanmasından birinci derecede sorumlu olanlar üretim yöneticileri ve yardımcılarıdır.

I. Direkt İlk Madde ve Malzeme (Hammadde) Bütçesi

Bu bütçe, bütçelenmiş üretim miktarı için gerekli olan direkt İ.M.M. miktarı ve tutarına ilişkin bilgileri içerir. Bu bütçenin temel amaçları;

- Üretim için gerekli olan hammadde ihtiyacının belirlenmesi,
- Hammadde stok düzeyinin tespit edilmesi,
- Hammadde satın alımlarının elverişli şekilde bütçelenmesine imkân sağlanması,
- Finansal ihtiyaçların belirlenmesi için gerekli bilgilerin nakit bütçesine verilmesi,
- Stokların uygun düzeyde olması ve hammadde kontrolünün sağlanmasıdır.

Bu bütçenin düzenlenebilmesi için; üretilecek olan ürün miktarı, her bir ürünün üretimi için gerekli olan standart hammadde miktarı ve maliyetinin bilinmesi gereklidir. Standart

maliyetlerin kullanılmadığı işletmelerde ise bu bilgiler malzeme faturalarına, geçmiş dönemlere ilişkin tüketim belgelerine ve mühendislik çalışmaları sonuçlarına göre tespit edilir (Koç, 1989: 119).

II. Direkt İşçilik Bütçesi

Direkt işçilik bütçesi, üretim bütçesinde planlanan çıktıların üretimi için gerekli direkt işçilik süreleri ve maliyetlerinin tahmininden oluşur. Bu bütçenin düzenlenebilmesi için, üretim bütçesinde belirtilen üretim miktarı, birim üretim için gerekli işçilik saati ve direkt işçilik saat ücreti bilgilerine ihtiyaç vardır.

Direkt işçilik bütçesinin oluşturulması sonucunda üretim için gerekli olan direkt işgücü süresi ve toplam işçilik maliyeti bilgilerine ulaşılır. Direkt işgücü süresini hesaplayabilmek için üretim bütçesindeki üretim miktarı ile birim üretim için gerekli direkt işgücü saati çarpılır. Bulunan bu değer direkt işçilik saat ücreti ile çarpılması sonucunda ise toplam işçilik maliyetine ulaşılır.

Direkt işçilik bütçesinin oluşturulmasından üretim yöneticisi ve yardımcıları sorumlu olmakla birlikte bütçenin hazırlanması aşamasında bütçe kontrol, maliyet muhasebesi, insan kaynakları bölümlerinin de birlikte çalışmaları gereklidir.

Direkt işçilik bütçesinin etkin bir şekilde hazırlanması ile işletme içindeki personelin çalışma verimliliğinde artış sağlanır. İşçiliklerin planlanmış olması, finans birimi açısından da, ilgili dönemde nakit ihtiyaçlarının daha iyi planlanmasına imkan tanır. Ayrıca, işçilikler direkt işçilik bütçesi ile üretim birimlerine göre sınıflandırılarak hem işçilik süresi hem de işçilik maliyeti açısından izlenebilmesinden dolayı direkt işçiliklerin kontrolü açısından oldukça önemlidir.

III. Genel Üretim Giderleri (GÜG) Bütçesi

Genel üretim giderleri, direkt malzeme ve direkt işçilik haricinde kalan üretim ile ilgili tüm maliyetleri kapsar. Bu maliyetler; endirekt malzeme, dolaylı işçilik, amortisman, kira, bakım-onarım, enerji, sigorta, yemekhane vb. olarak sayılabilir. Genel üretim giderlerinin bir mamul ya da maliyet yerine doğrudan yüklenmesi imkânsızdır.

Genel üretim giderleri, direkt ilk madde ve malzeme ile direkt işçilikten farklı olarak aşağıdaki özelliklere sahiptir (Aras, 2014).

- Genel üretim giderleri ile üretilen mamuller arasında doğrudan bir ilişki yoktur.
- Bu giderler yapıları itibariyle birbirlerinden çok farklı niteliklere sahiptirler.
- Bu giderlerin çeşitliliğinin fazla olması ve birçok departman tarafından yapılması nedeniyle sorumluluk merkezi işletme içinde tek bir yerde toplanmamış olup çeşitli yönetim kademelerindeki pek çok yönetici sorumlu durumundadır.

Yukarıda sayılan özellikleri sebebiyle her maliyet alanı için genel bir üretim maliyeti bütçesi düzenlenir. Bir maliyet yerine ilişkin genel üretim maliyeti bütçesi hazırlanırken, o maliyet yerinin sahip olduğu her bir genel üretim maliyeti kalemi ayrı ayrı bütçelenir. Bu bütçelerin birleştirilmesi ile de işletmenin bütününe ait genel üretim maliyeti bütçesi elde edilir. Bu bütçelerin maliyet yerleri ve kalemlerine göre düzenlenmesi özelliğinden ötürü dikkat edilmesi gereken temel koşul, işletmenin uygun yetki ve sorumluluk merkezlerine ayrılması gerekliliğidir. Ayrıca, yetki ve sorumluluk merkezlerinin de yeterli sayıda maliyet yerine ayrılması ve maliyet yerlerindeki genel üretim maliyetleri kalemlerinin de uygun bir şekilde belirlenmesi gerekir (Haftacı, 2005: 38).

Genel üretim giderleri bütçesinin hazırlanmasında üretim yöneticileri, maliyet muhasebesi yöneticileri, fabrika yöneticileri ile bölüm şeflerinin işbirliğine ihtiyaç duyulur. Bu bütçenin hazırlanması, maliyetlerin ortaya çıktığı yerlere ve maliyet kalemlerine göre genel üretim giderlerinin kontrol altına alınmasına olanak sağlar.

IV. Dönemsonu Mamul Stoku Bütçesi

Dönemsonu mamul stoku bütçesi, bütçelenmiş finansal tabloların oluşturulması için gerekli olan bilgileri sağlar. Bu aşamaya kadar hazırlanan satış bütçesi ve üretim ile ilgili diğer bütçelerin tümü üretilen bir birim mamulün maliyetinin hesaplanabilmesi için yeterli bilgiyi içermektedir.

Bütçelenmiş gelir tablosundaki satılan mamul maliyetinin ve bütçelenmiş bilançoda görünecek olan dönemsonu mamul stokunun tutarsal değerinin belirlenebilmesi için üretilen bir birim mamul maliyetinin hesaplanması önemlidir. İşletmeler, bir birim mamulün maliyeti hesapladıktan ve dönem sonu mamul stoku bütçesi oluşturduktan sonra isterseler ayrıca satışların maliyeti bütçesini de düzenleyebilirler.

1.4.5.1.3. Faaliyet Giderleri Bütçesi

Dönem giderleri olarak da tanımlanan faaliyet giderleri, işletmenin esas faaliyetiyle ilgili olarak yapılan, ancak üretim maliyeti haricinde kalan tüm gider kalemlerini kapsar. Bu giderler, araştırma ve geliştirme giderleri, pazarlama, satış ve dağıtım giderleri ile genel yönetim giderleri olmak üzere üç başlık altında toplanır.

I. Araştırma ve Geliştirme (AR-GE) Giderleri Bütçesi

Ekonomik, sosyal, politik, teknolojik ve çevresel etmenlerde meydana gelen hızlı değişimler işletmeler açısından AR-GE faaliyetlerinin önemini arttırmıştır. İşletmelerin yoğun rekabet ortamında yaşayabilmeleri AR-GE faaliyetlerine önem vermeleri ve buna bağlı olarak yeni mamul ve üretim süreçlerini geliştirmeleriyle yakından ilişkilidir (Haftacı, 2005: 44).

Üretilen mamullerin maliyetlerinin düşürülmesi, satışların artırılması, bulunan yeni üretim türlerinin ve işletmede hâlihazırda kullanılan yöntem ve işlemlerin geliştirilmesi veya yeni yöntem ve işlemlerin bulunması, üretimde kullanılmakta olan teçhizatın yenilenmesi ve var olanlarının geliştirilmesine yönelik araştırmaların yapılması ile satış ve pazarlama faaliyetlerinin geliştirilmesine yönelik katlanılan giderler AR-GE bütçesinde düzenlenir (Çam, 2009: 14).

AR-GE giderleri, gerçekleştirilen araştırma ve geliştirme faaliyetlerinin sonuçlarına bağlı olarak kaydedilir. AR-GE çalışmalarından sonuç alınamaması durumunda katlanılan giderler gelir tablosuna AR-GE gideri olarak kaydedilirken, katlanılan giderler neticesinde işletme için orta ya da uzun vadede yararlı bir sonuç ortaya çıkmışsa giderler aktifleştirilerek yararlı olacağı düşünülen zamana bağlı olarak amorti edilmektedirler. AR-GE giderlerinin tamamı bütçe uygulamalarında dönem gideri olarak kabullenilerek gelir tablosuna aktarılır. AR-GE faaliyetleri ile yeni bir pazarlama tekniği, yeni bir üretim tekniği, yeni bir mamul vb. sonuçlar elde edilebilmektedir (Seydi, 2010: 61).

II. Pazarlama, Satış ve Dağıtım Giderleri Bütçesi

Bu bütçede, üretilen mamul ya da hizmetlerin pazarlanabilmesi amacıyla işletmelerin katlandığı giderler bütçelenmektedir. Bu giderler, söz konusu mamul veya hizmete yönelik talebi oluşturmak veya devam ettirmek maksadıyla katlanılan geliştirme, reklam, satış, depolama ve taşıma gibi giderlerdir. Pazarlama, satış ve dağıtım giderleri bütçesinin

oluşturulmasındaki amaç; finansman ile satış-dağıtım faaliyetleri arasındaki dengenin sağlanması, kar marjlarının belirlenmesine yardımcı olunması, satış giderleri için bütçe döneminde gerekli nakit ihtiyaçlarının belirlenmesi ve satış giderlerinin kontrolünün etkin bir şekilde gerçekleştirilmesidir (Koç, 1989: 166). Ayrıca, bu bütçenin alıcı gruplarına, kendi içindeki fonksiyonel gruplara, mamullere, dağıtım kanallarına, satış bölgelerine göre ayrıntılı bir biçimde farklı açılardan düzenlenip planlanmasında fayda vardır. Bütçenin bu biçimde oluşturulmasıyla satış bölgelerinden hangisinin veya alıcılardan hangilerinin daha karlı olduğu belirlenebileceği gibi; faaliyetlerden hangilerinin satışları ne derecede etkilediği de rahatça belirlenebilir (Çam, 2009: 15).

Pazarlama, satış ve dağıtım giderleri uzun dönemli etkisi olan değer kullanımları olup, etkinliklerinin ve gelir getirme güçlerinin ölçümü zordur. Katlandıktan sonra geriye dönüşü olmadığından işletmelerin söz konusu giderler üzerinde özenle durmaları gerekir (Haftacı, 2005: 45).

Pazarlama, satış ve dağıtım giderleri bütçesi pazarlama birimi tarafından hazırlanmasına rağmen, muhasebe ve diğer bütçe bölümleri de bu konuda pazarlama bölümüne yardımcı olurlar. Bütçenin hazırlanma yöntemi ise, satış bütçesine benzediğinden genellikle satış bütçesi ile birlikte çalışılarak oluşturulabilir. Bu bütçe, iki açıdan satış bütçesiyle ilişkilidir. Birincisi; satış bütçesi tarafından yönlendirilmesidir; diğer bir ifade ile artan satış hacmi, pazarlama ve reklam harcamalarında azalışa sebep olabilir. İkincisi; pazarlama, satış ve dağıtım bütçesi satış bütçesini destekler; diğer bir ifade ile tutundurma faaliyetleri satış hacminin ve mamul karışımının artmasını destekler (Lalli, 2003: 16).

Pazarlama, satış ve dağıtım giderlerinin bütçelenmesi, bu faaliyetler ile finansman faaliyetleri arasındaki dengenin sürdürülmesini sağlar. Ayrıca bu bütçe hem kâr marjlarının belirlenmesine yardımcı olur hem de bütçe dönemi için gerekli nakit ihtiyacının hesaplanmasına ve etkili gider kontrolüne imkan sağlar (Koç, 1989: 166).

III. Genel Yönetim Giderleri Bütçesi

Genel yönetim giderleri bütçesi, işletmede pazarlama ve üretim bölümleri dışında kalan, işletmenin belirli bir fonksiyonu ile ilişkilendirilemeyen, tüm işletme fonksiyonlarına ilişkin faaliyetlerin planlanması, yönetimi ve denetimi için yapılan giderlerden oluşur. Yönetici maaşları, kırtasiye giderleri, ofis kiralari, büro mobilya ve donanım aşınma

payları, yolluklar, vergiler, sigorta giderleri, dışarıdan sağlanan çeşitli hizmetler vb. giderler bu giderlere örnek verilebilir.

Genel yönetim giderleri bütçesinin diğer bütçelenmiş faaliyetleri destekleyen faaliyetleri kapsamından dolayı diğer tüm bütçeler arasında oldukça önemli bir bağı vardır. Bu açıdan diğer faaliyetler üzerinde bağımsız bir kontrol olanağı sağlamaktadır.

İşletmelerde genel yönetim hizmetlerini yürüten her bölüm kendi bölümlerine ilişkin genel yönetim giderleri tahmininde bulunur. Ardından, bütçe birimi yapılan tahminleri birleştirerek işletme için bir genel yönetim giderleri bütçesi oluşturur. Genel yönetim giderleri bütçesi oluşturulduktan sonra, genel yönetim giderleri ile satışlar arasında paralelliğin olup olmadığı araştırılır. İlgili giderlerin yapılması için gerekli olan nakit ihtiyacı tespit edilir.

Genel yönetim giderleri tahmin edilirken büyük ölçüde geçmiş dönem verilerinden ve deneyimlerinden faydalanılır. Bütçe dönemi içinde yönetim politikalarında ve genel ekonomik koşullarda ortaya çıkabilecek değişimler de göz önünde bulundurulur (Haftacı, 2005: 47). Genel yönetim giderlerinin önemli bir bölümü sabit olup, bir kısmı ise faaliyet hacmine bağlı olarak değişmektedir. Değişken genel yönetim giderinin belirlenmesinde faaliyet ölçüsü olarak çoğunlukla satış hasılatı, direkt işçilik saati veya vergiden önceki kâr kullanılmaktadır.

1.4.5.1.4. Yatırım Bütçesi

İşletme bilimi açısından belirli bir üretim gücünün elde edilebilmesi için yapılan her türlü harcama yatırım olarak tanımlanır. Bir yıldan kısa vadede mal veya hizmetlere dönüşecek varlıklara yapılan yatırımlar dönen varlık yatırımları, bir yıldan daha uzun vadede faydalanılacak maddi veya maddi olmayan varlıklara yönelik yatırımlar ise duran varlık yatırımları olarak tanımlanmaktadır.

Yatırım harcamaları, büyümek, üretim kapasitesini arttırmak, satışları arttırmak, maliyet azalışı sağlamak, üretim yöntemlerini değiştirmek, ürün kalitesini yükseltmek, verimliliği arttırmak, varlıkları yenilemek vb. nedenlerle yapılabilir. Bu harcamaların zamanlaması, yeterliliği ve niteliği işletme üzerinde uzun vadede bir etki sağlar (Shim, 2005: 201). İşletmelere bir yıldan daha fazla sürede parasal fayda sağlayacak varlıkların elde

edilmesi, bakım-onarımı, yenilenmesi ve satılarak elden çıkartılmasına yönelik yönetim kararları sermaye bütçelemesi olarak ifade edilir (Gürsoy, 2007: 453).

Yatırım bütçesi, işletmelerin bütçe dönemi içinde maddi duran varlıkların hangisine ne miktarda yeni yatırım yapıldığını göstermekle birlikte ticaret unvanı, patent gibi maddi olmayan duran varlıklara yönelik katlanılan harcamaları da kapsamaktadır. Bu türdeki yatırımlar için bütçe döneminde yapılması planlanan harcamalar, yatırım bütçesinde tahmin edilir. Bu gibi yatırımların büyük fon kullanımını gerektirmesi ve etkilerinin bir yıldan uzun sürmesi nedeniyle yapılabilecek bir yanlışlığın etkisini gidermek yıllar alabilir. Yatırım bütçesinin doğruluğu bu açıdan büyük bir öneme sahiptir.

Yatırım bütçesi, muhasebe ve finans yöneticisinin sorumluluğunda ilgili yönetici ve uzmanlarca hazırlanır.

1.4.5.1.5. Nakit Bütçesi

Bu bütçe, işletmelerin bütçe dönemine ait nakit ihtiyaçlarını belirlemek maksadıyla faydalanabileceği en önemli araçlardan birisi olup işletmelerin bütçe dönemindeki nakit giriş ve çıkışlarını gösteren finansal tablodur. Bütçenin kaynaklarını dönem içinde nakit girişi sağlayan kalemler oluştururken, nakit kullanımlarını ise nakit çıkışını gerektiren kalemler göstermektedir. Nakit girişleri kısmında; nakit satışlar, alacaklardan tahsil edilen tutarlar, diğer nakit girişleri (stok dışı varlıkların satışı, finansal borç sağlanması vb. gibi) yer almaktadır. Nakit çıkışları kısmında ise; nakit mal alışları, borç hesaplarına ilişkin yapılan ödemeler, dönen varlık ve sabit varlık alımlarına ilişkin ödemeler, ücret, vergi, faiz ödemeleri, kira ödemeleri, temettü ödemeleri ve diğer ödemeler bulunmaktadır.

Nakit bütçeleri aylık, haftalık hatta günlük olarak düzenlenebilir. Ancak işletmeler çoğunlukla gelecekteki 6-12 aylık dönemi dikkate alarak tahmin ettikleri aylık nakit bütçeleriyle bir sonraki ayın ayrıntılı günlük nakit bütçesini birlikte kullanırlar. Uzun vadeli nakit bütçesi, işletmenin uzun dönemdeki amaçlarını gerçekleştirebilmesi için ihtiyaç duyduğu nakdin sağlanmasının ana hatlarını belirlerken, kısa vadeli nakit bütçesi ise bir işletmenin gelecek döneme ilişkin nakit giriş ve çıkışlarını tespit ederek işletmenin her an ödeme gücünü kontrol ve garanti etmektedir. Nakit bütçesi, nakit girişlerinin çok değişken olduğu işletmelerde kısa süreli, çok değişken olmadığı işletmelerde ise daha

uzun süreli hazırlanabilir. Çünkü nakit bütçesine ilişkin sürenin uzunluğu riski de artırmaktadır.

Nakit bütçesinde tahakkuk esası geçerli olmayıp, bu bütçenin düzenlenmesindeki esas ilke nakit esasıdır. Bu durum, nakit bütçesini diğer bütçelerden ayıran en önemli farktır. Nakit bütçesinde, zamanı ve tutarı kesin olarak belli olmayan nakit girişleri ve nakit çıkışlarına yer verilmez.

Nakit bütçesi genellikle işletmenin mali işler yöneticisi tarafından düzenlenir. Ancak söz konusu bütçe düzenlenirken diğer bütçelerden de faydalandığından diğer bölüm yöneticileri de nakit bütçesinin düzenlenmesine yardımcı olurlar.

1.4.5.1.6. Proforma Gelir Tablosu

Gelir tablosu, işletmelerin belli bir dönemde sağladığı gelirler ile aynı dönemde katlandığı maliyet ve giderlerin tümünün ve bunlar neticesinde elde edilen dönem net kar ya da zararın topluca gösterildiği finansal tablodur (Ercan & Ban, 2014: 24). Proforma gelir tablosu ise, işletmenin planlanan bütçe dönemi içinde elde edeceği gelirleri ile katlanacağı giderlerine, brüt satış kârına, faaliyet kârına ve net kârına yönelik tahminlerini içerir.

Proforma gelir tablosu düzenlenirken aşağıdaki adımlar uygulanır (Çam, 2009: 18-19).

- Brüt satışlar kısmına; satış bütçesindeki satış tutarları yazılır.
- İndirimler kısmına; gider bütçesindeki iade ve iskontolar yazılır.
- Net satışlar; brüt satışlardan indirimlerin düşülmesiyle bulunur.
- Net satışlar bulunduktan sonra, satışların maliyeti bütçesinden yararlanarak satılan mamullerin maliyeti yazılır.
- Gider bütçesinden elde edilen AR-GE, genel yönetim ve pazarlama, satış ve dağıtım giderleri faaliyet giderleri kısmına yazılır.
- Diğer faaliyetlerden olağan gider ve zararlar, diğer faaliyetlerden olağan gelir ve kârlar, olağandışı gider ve zararlar, olağandışı gelir ve kârlar hanelerine, ayrı olarak hesaplanan ve bütçe tabloları içerisinde ayrı olarak bulunan gelir ve giderler yazılmaktadır.
- Finansman giderleri kısmına ise, finansman giderleri bütçesi yazılmaktadır.

Proforma gelir tablosu, proforma bilançonun hazırlanması aşamasında ihtiyaç duyulan ön bilgileri vermekte olup, bu iki tablo birbirini tamamlamaktadır.

Proforma gelir tablosu, bütçe dönemi içinde gerçekleştirilecek faaliyetlerden sağlanacak kazanç ve kayıpları ortaya koymaktadır. Proforma bilançoda ise, bütçe döneminde işletmenin varlık ve borçlarına ilişkin bilgiler bulunur. Proforma gelir tablosu işletmenin gelir-gider durumu ile ilgilenirken, proforma bilanço işletmenin varlık ve borçlarıyla ilgilenmektedir (Sevgener & Hacırüstemođlu, 2000: 341).

1.4.5.1.7. Proforma Bilanço

Bilanço, düzenlendiđi tarih itibariyle işletmelerin sahip oldukları varlıkları ve bunların kaynaklarını (öz kaynak+yabancı kaynak) gruplandırılmış ve özet olarak, tutarları ve türleriyle gösteren mali tablo bilançodur. Proforma bilanço ise, bu mali tablonun tahminlere ya da bütçelenmiş tutarlara göre düzenlenmesi sonucunda elde edilir. Proforma bilançonun düzenlenebilmesi için işletmenin önceki yılın dönem sonu bilanço bilgilerinin bilinmesi gerekmektedir.

İşletmenin genel bütçesini proforma bilanço oluşturmaktadır ve birçok kısım veya fonksiyonel bütçenin konsolide edilmesiyle elde edilir. Düzenlenme aşamasında regresyon yöntemi, yüzde yöntemi ya da rasyo yöntemi gibi çeşitli tekniklerden faydalanılabilir.

Proforma bilançonun hazırlanmasındaki amaç, varlık, yükümlülük ve öz kaynak karışımının planlanması aşamasında yönetime yardım etmektir (Lalli, 2003: 23). Genellikle, proforma bilançoların hazırlanmasında aşağıdaki sıra izlenir (Usta, 2008: 151).

- İşletmeler planladıkları satış hacmine ulaşabilmek için, “aktif” tahmini yaparlar, yani dönen ve duran varlıkları için yapılacak yatırım tutarını belirlerler.
- İşletmelerin satış hacimlerindeki artışlara bađlı olarak ortaya çıkacak finansman kaynakları tahmini yapılır.
- İşletmenin öz sermayesinin tahmini yapılır ya da aynı şekilde kabul edilir.
- Aktif ve pasif tahminlerine ilişkin dengeleme işlemi gerçekleştirilir. Bu şekilde, finansman ihtiyacı ve fazlası tespit edilir.

Proforma tablolar, cari satışların ve giderlerin tahminini yansıtan tahmini mali tablolardır ve işletmenin gelecek dönemdeki mali durumunun tahmin edilmesinde ve faaliyetlerinin planlanmasına yardımcı olurlar.

Proforma bilanço ve gelir tablosunun hazırlanmasından bütçe müdürü sorumludur. Bütçe müdürü, daha önce düzenlenen bütçelerdeki verilerden yararlanarak proforma gelir tablosunu hazırlar. Ayrıca, planlanan faaliyetlerin işletmenin varlıklarında, yükümlülüklerinde ve öz kaynaklarında meydana getirecekleri etkileri saptayarak proforma bilanço düzenler. (Koç, 1989: 202).

1.4.5.2. Bölümsel Bütçeler

Genel bütçenin kısımlarını oluşturan ve işlevsel bir temele dayanan işletmenin belirli bir bölümü ya da faaliyetini konu edinen bütçelerdir. Kimi zaman literatürde kısım bütçeleri şeklinde de tanımlanmaktadır.

Genellikle, genel bütçe içinde özetlenen üretim, finansman, pazarlama gibi işletmenin belirli işlevlerini dikkate alarak oluşturulan bölümlere göre üç gruba ayrılırlar.

1.4.6. Temel Alınan Başlangıç Rakamlarına Göre Bütçeler

Temel alınan başlangıç rakamlarına göre işletme bütçeleri geleneksel bütçeler ve sıfır tabanlı bütçeler olmak üzere ikiye ayrılırlar.

1.4.6.1. Geleneksel Bütçeler

Geleneksel bütçede, gelecek döneme ilişkin tahmin yapmak ve değerlendirmelerde bulunmak için öncelikle geçmiş yılın bütçesi ve gerçekleşen harcama düzeylerine bakılır. Buna ilaveten, gelecek döneme ilişkin tahminler de göz önünde bulundurulur. Bu şekilde geçmiş dönem bütçesi, yeni dönem bütçesini etkilemiş olmaktadır. Bu bütçeler nitelik itibarıyla bir tür eğilim düzeltmesi şeklinde ortaya konan sayısal planlardır.

1.4.6.2. Sıfır Tabanlı Bütçeler

Sıfır tabanlı bütçe, geçmiş yıllardaki ödeneklere bağımlılığı azaltmayı ya da tamamen ortadan kaldırmayı amaçlamaktadır. Bu sebeple, faaliyet ve harcamaların tümünün temel nedenlerini belirli aralıklarla, yani sıfır'dan belirlemeyi öngörmesi açısından diğer bütçeleme sistemlerinden daha farklı bir anlayışı ortaya koymaktadır (Aksoy, 1991: 455). Sıfır tabanlı yaklaşım, öncelikle bir yönetim süreci, daha sonra planlama süreci ve son olarak da bütçeleme sürecidir. Bu bütçelerde gelecek döneme yönelik tahmin ve değerlendirmeler yapılırken, geçmiş döneme ilişkin sonuçlar tümüyle göz ardı edilerek sadece gelecek dönem işlevleri dikkate alınmaktadır. Diğer bir ifadeyle, bu tür bütçelerde

bütçe verisi olarak geçmiş dönemlerdeki bütçe verilerinin hiçbiri gelecek dönem bütçesi içinde kendiliğinden yer almaz. Her veri yeniden değerlendirilir, seçenekler birbirleriyle karşılaştırılarak öncelikler belirlenirler. Bu şekilde sıfır tabandan hareket edilmiş olur.

Sıfır tabanlı bütçeleme; ortaklaşa karar almayı, kapsamlı bir planlamayı, stratejilerin uygulanmasını ve geliştirilmesini destekler ve ifade eder. Ayrıca bu bütçeleme sistemi, işletme içindeki her bir programın ayrı ayrı izlenmesini sağlayarak uygun düzeyde kaynak dağıtımına imkan sağlaması bakımından oldukça faydalıdır (“What is Zero Base Budgeting?”, 2016).

1.4.7. Rakamların Niteliğine Göre Bütçeler

Bu tür bütçeler miktar ve tutar bütçeleri olmak üzere iki gruba ayrılırlar.

1.4.7.1. Miktar Bütçeleri

Gelecek döneme dair faaliyet sonuçları tahmininin ve değerlemesinin miktar bakımından yapıldığı sayısal planlardır. Hammadde ve üretim miktarları bütçeleri bu tür bütçelere örnek olarak verilebilir.

1.4.7.2. Tutar Bütçeleri

Üretim, satış, finans ve genel yönetim fonksiyonlarına yönelik gelecek dönemlere ilişkin faaliyet sonuçları tahmininin ve değerlemesinin parasal olarak yapıldığı sayısal planlardır. Satış bütçesi, üretilen mamul maliyeti bütçesi, nakit bütçesi, faaliyet giderleri bütçesi gibi bütçeler tutar bütçelerine örnek gösterilebilir.

1.5. İşletmelerde Bütçelemenin Önemi

İşletme içindeki yönetim bilgi sistemlerinin en önemli parçası bütçelerdir. Etkin biçimde düzenlenmiş bir bütçe, hazırlama aşamasından uygulama ve sonuç aşamasına kadar bazı fonksiyonların yerine getirilmesini sağlamaktadır (Berikol, 2010: 14). Başarılı işletmelerde, ön plana çıkan “Planlama”, “Organizasyon” ve “Denetim” olmak üzere üç temel unsur bulunmaktadır. Faaliyetlerin doğru bir biçimde planlanması, iyi işleyen bir organizasyon sayesinde değer kazanırken, sağlam bir denetim, başarının sürekliliğine katkıda bulunacaktır (Sürmeli, 2016).

BÖLÜM 2: TALEP TAHMİNİ VE TAHMİN TEKNİKLERİ

Bu bölümde, talep tahmini kavramı, tahminin önemi, tahmin teorileri ve tahminleme teknikleri ve yapay sinir ağları konularına ilişkin bilgilere yer verilmiştir.

2.1. Talep Tahmini Kavramı

Talep, piyasalarda belli bir mal veya hizmete yönelik gerçek bir satın alma gücüyle desteklenmiş olan alma isteğidir. Tek alıcının talebi, belirli bir anda belirli bir maldan muhtemel her fiyattan satın almak istediği mal miktarıdır. Bir malın piyasa talebi ise, tüm alıcıların belirli bir anda söz konusu maldan muhtemel her fiyattan satın almak istedikleri miktarlardır (Eski, 2005: 62).

Tahmin, gelecek dönemlerde ortaya çıkabilecek olayların sonuçlarını geçmişte gerçekleşmiş olay/olayların sonuçlarını değerlendirerek önceden görebilmek şeklinde ifade edilebilir. Sözlük anlamı olarak ise tahmin kelimesi; akla, sezgiye veya bazı verilere dayanarak gelecekte ortaya çıkması muhtemel olan olayların önceden öngörülmesidir. Geleceğin tahmin edilmesi ya da tahmin edilmeye çalışılması sosyo-ekonomik gelişimin bir unsurudur. Karar verme zorunluluğunda olan özel ya da kamu işletmelerinin tümü gelecekte mevcut durumlarını korumak ve geliştirebilmek için geleceğe yönelik olayları doğru ve güvenilir bir şekilde tahmin edebilmeli ve iyi bir plan kapsamında uygun çözümler bulabilmelidir. Tahminlerin doğru yapılamaması kuruluş veya şirketlerin geleceğe dair hedeflerini olumsuz etkilemektedir.

Talep tahmini ise, geleceğe dönük belli bir zaman dilimi içinde talep edilecek mal ve hizmetlerin düzeyinin önceden öngörülmesidir. Geleceğe dair mal ve hizmet talebinin öngörülmesi, işletmedeki tüm tahminlerin başlangıç noktasını oluşturmaktadır ve diğer fonksiyonlara temel girdiyi sağlamaktadır (Doğan, 2007: 104). Talep tahminleri ile işletmede hangi ürünün ne kadar üretileceği, tüketicilerin bu ürünü hangi miktarda talep edeceği ve bu talebin genellikle hangi tarihlerde gerçekleşeceğine yönelik ihtimaller belirlenir.

2.2. Bütçelemeye Tahminin Önemi

Üretim planlamasının yapılmasındaki başlangıç noktası, üretilmesi gerekli veya istenen miktarın doğru olarak hesaplanabilmesidir. Üretim/işlemler yönetiminde talep tahminin

yapılması, müşteri talebini belirleme ve buna bağlı olarak oluşturulacak üretim planı açısından büyük bir öneme sahiptir. Müşteri taleplerinin tahmini, hangi miktarda ürünün ne miktarda hammadde, işgücü ve diğer üretim faktörlerinin kullanılmasıyla üretileceğinin planlanması ve ne miktarda stok bulundurulacağını belirlenmesi açısından işletme yöneticilerine stratejik kararlarında yol gösterici olacaktır (Soysal & Ömürgönülşen, 2010: 130).

Talep tahmininin önemi, başarısız bir talep tahminlemesinin sonuçlarına bakılarak daha iyi anlaşılabilir (Karasu, 2012: 2). Tahmin edilenden daha fazla müşteri talebinin olması halinde talebin tamamı karşılanamayacaktır. Bu durum hem müşteri kayıplarının yaşanmasına hem de satış gelirlerinin düşmesine sebep olacaktır. Tahmin edilenden daha düşük seviyede müşteri talebinin olması halinde ise üretim fazlalığı ortaya çıkacaktır. Ortaya çıkan üretim fazlalığı da hem stokların hem de stok tutma maliyetinin artmasına, karlılığın düşmesine ve nakit akışının azalmasına neden olacaktır.

2.3. Tahmin Teorileri

İşletmeler ya da kuruluşlar geleceğe dair karar verirken, güvenilir ve doğru tahminlere ihtiyaç duyarlar. Çünkü tahminlerin yanlış olması işletme ya da kuruluşların geleceğe yönelik hedeflerini olumsuz etkiler. Bu olumsuzluklar neticesinde stok maliyetlerindeki artış ve taleplerin karşılanamaması gibi durumlar işletmelerin pazar paylarında azalışa sebep olabilir (Çağlar, 2007). İşletmeler, tahmin aşamasında hedefledikleri satış miktarlarındaki artış oranı ile talepteki artış oranlarını dikkate almakla birlikte yapılan tahminin işletmenin üretim kapasitesi açısından kısıtlanmaması için muhtemel talebi karşılayacak düzeyde kapasite planlamasını da önceden yapmalıdırlar.

İşletmelerde hangi ürünün hangi miktarda, hangi zamanda, ne kadar maliyetle ve hangi yollarla elde edeceğinin planlanması süreci satış tahmini ile başlar. Satış tahminleri çerçevesinde var olan imkân ve işgücü kapsamında malzeme, kapasite ve personelin içinde bulunduğu bir üretim programı hazırlanacağından bu tahminlerin gerçeğe maksimum yakınlıkta ve işletmelerin amaçlarına ve durumuna uygun şekilde yapılması önem arz etmektedir.

Yönetim sürecinde yüksek derecede öneme sahip olmasından dolayı tahminleme işletme yöneticileri tarafından sürekli bir şekilde göz önünde tutulmalıdır. Bir yöneticinin

geleceği iyi planlaması başarısızlık riskini minimize eder. İyi bir tahminleme yapmak ise, iyi bir plan yapmanın ön koşuludur (Karahana, 2011: 28).

Talep tahminleri; zaman aralığına, kullanım amacına, mamulün cinsine, hesaplama tekniğine göre farklı esaslara bağlı olarak sınıflandırılabilir. En sık kullanılan sınıflandırma kıstası ise zaman aralığıdır. Zaman aralığı kıstasına göre sınıflandırmada yer alan talep tahmin türleri aşağıda ifade edildiği gibidir (Kobu, 2008: 111).

Çok kısa vadeli tahminler: Günlük ve haftalık olabilir. Parça, malzeme ve yarı mamul stoklarını kontrol etmek ya da montaj hattı iş programlarını oluşturmak amacıyla gerçekleştirilir.

Kısa vadeli tahminler: Genellikle 3 ile 6 aylık bir süreyi kapsarlar. En uygun imalat parti hacimleri, tedarik zamanları ve sipariş miktarlarının belirlenmesinde kullanılırlar. Ayrıca, işgücü ihtiyacının tespit edilmesi ve makinelere iş yüklenmesi amacıyla da hazırlanırlar.

Orta vadeli tahminler: En az 6 ay en fazla 5 yıla kadar olan süreyi kapsayan tahmin türleridir. Tedarik süresi belli olmayan ya da tedarik süresi uzun olan malzeme alımlarının yapılması, karmaşık üretim sürecine sahip imalat faaliyetleri ve mevsime bağlı talep değişikliği yaşanan mamul stoklarının planlanması amacıyla yapılır.

Uzun vadeli tahminler: 5 yıl ve daha uzun süreler için yapılır. İşletme tesislerinin genişletilmesi, yeni makinelerin alınması gibi konularda uzun vadeli tahminler yapılır.

2.3.1. Talep Tahmin İlkeleri

Tahmin sonuçlarının etkili bir biçimde kullanılabilmesi için tahmin ilkelerinin bilinmesi gereklidir. Bu ilkeler aşağıda ifade edildiği gibidir (Üreten, 2005: 123).

- Tahmin çalışmalarının mükemmel olması genellikle imkansızdır. Tahminde bulunan değerler ile gerçekleşen değerler çoğunlukla birbirinden farklıdır. Bu farklılığın nedenlerinden birincisi, tahmini yapılacak değişkeni etkileyebilecek bütün faktörlerin dikkate alınmaması, ikincisi ise tahmin edilemeyen rassal olayların meydana gelmesidir.
- Tahminlerin belli bir düzeyde hata oranına sahip olacağı gözardı edilmemelidir. Bu sebeple tahmin çalışmalarında tek bir tahmin değeriyle birlikte alt ve üst sınırların, yani belli bir aralığın da belirlenmesi gereklidir.

- Çeşit ya da miktar açısından büyük gruplar için gerçekleştirilen tahminler daha duyarlıdır.
- Tahminlerin kapsadığı zaman aralığının kısa olması duyarlılık derecesini arttıracaktır.
- Tahmin aşamasında geleceğe ilişkin ve haberdar olunan bilgiler dikkate alınmalıdır. Bir işletmenin promosyon amacıyla gelecekte gerçekleştirmeyi planladığı hediye ürün dağıtımlarının talebi normalin üzerinde göstereceğinin bilinmesi gerekir.
- Ayrıca serinin geçmiş hareketlerine bakılarak ulaşılamayacak bilgiler söz konusu olabilir. Bu bilgilerin yapılan tahminin içine manuel olarak yerleştirilmesi gerekir.

2.3.2. Talep Tahmin Aşamaları

Talep tahmin süreci temel olarak aşağıdaki aşamalardan oluşmaktadır:

- **Tahminin amacının belirlenmesi:** Tahminde istenilen ayrıntı derecesi, tahmin için ayrılacak kaynak miktarı ve istenilen doğruluk düzeyinin saptanabilmesi için ilk olarak tahminin amacına karar verilmelidir. Bu aşamada amaçların net bir şekilde belirlenmesi bundan sonraki aşamalar açısından büyük bir önem taşır.
- **Tahmin döneminin belirlenmesi:** Talep araştırmasının sonuçlarının kullanılış amacıyla dönemin uzunluğu arasında yakın bir ilişki söz konusudur. Örneğin, uzun dönemlerde kullanılacak tahminlerin haftalık olarak yapılması yanıltıcı sonuçlara neden olabilir (Kobu, 2008: 114).
- **Verilerin toplanması:** Tahminleme çalışmasının geçerliliğini etkileyen oldukça önemli bir süreçtir. İşe yarayacak bilgilerin toplanması işletmedeki kayıt sistemine bağlıdır. Geçmişe ilişkin tedarik, satış, maliyet ve işlem zamanı kayıtları olmaksızın geleceğin tahmin edilmesi son derece zordur. Diğer taraftan, tahminleme amaçları göz önünde bulundurularak toplanacak verilerin kapsamı, cinsi ve ayrıntısı konusunda da doğru karar verilmelidir (Kobu, 2008: 114).
- **Tahmin yönteminin seçilmesi:** Tahminlemede faydalı olması açısından çeşitli yöntemler geliştirilmiştir. Bu yöntemler kalitatif ve kantitatif yöntemler şeklinde

iki gruba ayrılırlar. Kalitatif (nitel) tahmin yöntemleri, sayısal veriler yerine yargıya, zekaya ve tecrübenin uygulanmasına dayanır. Kantitatif (nicel) tahmin yöntemleri ise, istatistiksel ve matematiksel verilere dayanır. İdeal olan talep tahmin yöntemi ise bu iki yöntemin karışımıdır.

- **Tahmininin yapılması ve sonuçlarının geçerliliğinin araştırılması:** Gerçek değerlerin tahmin sonuçlarıyla kıyaslanarak aradaki farkların sistematik bir biçimde incelenmesi gereklidir. Tahmin modeli, varsayımların ve verilerin geçerliliği araştırılmalıdır. Modele ilişkin geçerlilik testi yapılarak modelin kullanılabilir olup olmadığına karar verilir (Karasu, 2012: 5). Modelin geçerli kabul edilmemesi durumunda, verilerin geçerliliği, yapılan varsayımlar ve belirlenen yöntemin tekrar incelenerek gerekli hallerde kullanılan yöntemin değiştirilmesi mümkündür. Yalnızca geçerliliği kabul edilen tahmin yöntemleriyle belirlenen tahmin değerlerinin planlama için kullanılması halinde doğru sonuçlara ulaşılabilecektir (Karahana, 2011: 29).

2.3.3. Talep Tahmin Yönteminin Seçimi

Talep tahmini için faydalı olacak birçok yöntem geliştirilmiş olup, kullanılacak duruma göre tahminleme yönteminin dikkatlice seçilmesi gereklidir. Ayrıca, kullanılacak yöntemlerin tümü için talep tahminlerinde belirli bir doğruluk derecesi söz konusu olmaktadır ve yapılan hiçbir tahmin yüzde yüz oranında doğruluğa sahip değildir. Önemli olan şey, var olan bilgiler ile geleceğe ilişkin kesin öngörülerde bulunmak yerine geliştirilmiş tahminleme tekniklerinden faydalanarak minimum hata seviyesindeki tahminleri gerçekleştirmektir. Bir üretim yöneticisi kendi ihtiyaçlarını en iyi düzeyde karşılayacak modeli seçmelidir.

Kullanılacak yöntemin seçiminde; toplanan bilgilerin değişim biçimi, duyarlılık, belirsizlik gibi nitelikleriyle uygulama amaçları göz önünde bulundurulması gerekli kriterlerdendir. Tahmin yönteminin seçiminde dikkate alınması gereken faktörleri aşağıdaki gibi ifade etmek mümkündür.

- **Bilimsellik Derecesi:** Seçilen metot, sonuçları yorumlayarak karar verecek olan yöneticinin bilgi ve yeteneğiyle bağdaşmalıdır.

- **Zaman Aralığı:** İhtiyaç duyulan bilgilerin toplanması ve işlenerek sonuç çıkarılabilmesi için uzun bir zaman dilimine ihtiyaç duyulabilir.
- **Maliyet:** Tahmin yöntemi seçimindeki en önemli faktörler, doğruluk ve maliyet olmalıdır. Ortalama mutlak hata değeri doğruluğun ölçümünde kullanılmalıdır. Ayrıca tahmin hatalarının oluşturduğu maliyetler ile veri toplama ve uygulama maliyetlerinin model seçiminde göz önünde bulundurulması gereklidir (Karahan, 2011: 30).
- **Kararların Niteliği:** Talep tahmini sonucuna bağlı olarak verilecek kararların kısa ya da uzun vadede olması istenen duyarlılık ve mamul miktarı seçilen yöntemi etkilemektedir.
- **Değişmelerde Kararlılık:** İncelenen olayda değişiklik sayısı az ise küçük n veya α değerli zaman serilerinin kullanımı daha uygundur. Beklenmedik bir şekilde ani değişikliklerin meydana geldiği olaylarda ise uzman kişilerin sezgilerine ve tecrübesine dayalı kalitatif tahmin yöntemleri tercih edilmelidir.
- **Karar Vericinin Niteliği:** Tahmin yöntemleri yöneticilerin sezgi ve deneyimlerini, toplumun sosyal ve kültürel değerlerini dikkate almamaktadır. Ancak, bu faktörler talep üzerinde etkili olabilmektedir. Bu sebeple, tahmin sürecinde dikkate alınmayan veriler çerçevesinde yöneticilerin bazı düzeltmeler yapmaları gerekli olabilir.

Tahmin hatalarının artması, yani gerçekleşen talep değerleri ile tahmin çalışmalarından sağlanan değerler arasındaki farkın büyümesi, tüketicilerin beklenti ve ihtiyaçlarının karşılanamaması, kapasite fazlasının oluşması, ürün stoklarında artış oluşması gibi birçok olumsuz duruma sebep olabilir. Genellikle bu gibi sebeplerden ötürü işletme maliyetlerinde artış oluşmaktadır. Bundan dolayı, üretim sistemlerinin tasarımı, planlanması ve işletilmesine yönelik kararların verilmesinde, doğru tahmin bilgilerinin kullanılması başarı için bir ön koşul olarak kabul edilmelidir (Bulut, 2006).

2.4. Tahmin Teknikleri

Günümüze kadar geliştirilen tahminleme teknikleri literatürde farklı şekillerde sınıflandırılmasına rağmen temel olarak kalitatif ve kantitatif teknikler olmak üzere iki gruba ayrılmaktadır.

2.4.1. Kalitatif Tahmin Teknikleri

Kalitatif tahminleme teknikleri, mevcut duruma ve geleceğe yönelik planlara ilişkin bilgi sahibi olduğu düşünülen kişilerin fikir ve yargılarının toplanmasını gerektirmektedir. Bu teknikler, tahmin yapılacak olguya ait sayısal verilerin elde edilemediği, belirsizlik ve değişkenliğin fazla olduğu durumlarda kullanılmaktadır. Genellikle düşük maliyetli olmaları ve ileri düzeyde istatistiksel yeteneklere ihtiyaç duyulmaması bu yöntemin avantajlarından. Bu yöntemde kullanılacak veriler; müşteriler, satış elemanları, yöneticiler, teknik personeller ya da işletme dışındaki çeşitli uzmanlardan elde edilebilmektedir. Fikir ve yargılarına başvurulacak olan kişilerin tecrübelerinin yetersiz olması, tahminlere kendi fikirlerini yansıtmaya ihtimali, geleceğe yönelik beklentiler sebebiyle tahminlerin etkilenmesi gibi faktörler ise kalitatif yöntemlerin dezavantajları arasında sayılabilmektedir.

Kalitatif teknikler, soyut faktörleri ve sübjektif deneyimleri ele almalarına karşın, karar verme aşamasında kişisel önyargı ve eğilimleri içermesinden ötürü çoğunlukla daha düşük performanslı tahminlerle sonuçlandırılmaktadırlar (Özdemir & Özdemir, 2006: 106).

Delphi tekniği, pazar araştırmaları, uzman görüşleri, satış elemanlarının görüşleri, yaşam eğrilerinin benzeşimi ve senaryo analizi yöntemleri karar verme sürecinde kullanılan başlıca kalitatif tekniklerdir.

2.4.1.1. Delphi Tekniği

Delphi tekniği, 1950'li yıllarda ABD'de RAND firmasında çalışan Olaf Helmer ve Norman Dalkey adlı iki araştırmacı tarafından özellikle askeri konulara yönelik tahminlerde bulunulması amacıyla geliştirilmiştir (Dalkey & Helmer, 1962). Bu teknik, organizasyondaki bir problemin çözülmesi için uzman kişilerin yüz yüze görüşmesine ve birlikte tartışmalar yapmasına gerek kalmaksızın bir konu hakkında karar vermelerine ve uzlaşmalarına imkân tanıyan bir metottur. Bu teknikte, öncelikle konu hakkındaki uzman

kişilere sorunlara bakış açıları ve çözüm önerilerine ilişkin yazılı bir form gönderilmektedir. Bu kişiler formları doldurduktan sonra geri gönderirler. Grup üyelerinin tümünün ya da uzmanların görüş ve önerileri sınıflandırılır ve yazılı bir şekilde tekrar aynı kişilere geri gönderim yapılır. Bu işlem uzlaşma gerçekleşip karar alınıncaya kadar devam eder (Aktan, 1998: 341).

Delphi tekniği, özellikle duygusal veya politik ortamlarda karar verilmesi gerektiğinde ya da güçlü grupların kararları etkileme olasılığının bulunduğu zamanlarda kullanılmalıdır (Şahin, 2001: 216).

Katılımda gizlilik, grup tepkisinin istatistiksel analizi ve kontrollü geri besleme bu tekniğin üç temel özelliği olarak ifade edilmektedir. Bu özellikler arasından en önemlisi katılımda gizliliğidir. Bu özellik sayesinde, araştırma aşamasında öne sürülen düşüncenin kime ait olduğunun gizli tutulmasıyla bireylerden daha fazla fikirlerin öne çıkması sağlanır. Böylelikle grup içinde çok iyi tanınan ve saygı duyulan kimselerin görüşlerinin şartsız kabulü engellenir ve katılan herkesin fikirlerini çekinmeden ifade edebilmesi sağlanır.

Delphi tekniğinin bazı üstünlük ve sınırlılıklarını aşağıdaki gibi ifade etmek mümkündür (Şahin, 2001: 219).

Üstünlükleri:

- Bireylerin yüz yüze gelmeleriyle ortaya çıkabilecek sorunlar minimum seviyeye indirilmektedir. Böylelikle bireyler düşüncelerini diğerlerinin baskısına maruz kalmaksızın serbestçe ifade edebilirler.
- Bu teknik; katılımcıların mekân, zaman, maliyet, uzaklık gibi etkenler sebebiyle sık sık toplanma ihtimalinin bulunmadığı zamanlarda önemli avantajlar sağlar.
- Farklı deneyim, beceri ve bilgiler sayesinde sorunların ilgili kısımlarına farklı bakış açısıyla bireylerin katkı oluşturmalarına fırsat sağlanmaktadır.

Yöntemin eksik yönleri ise; elde edilecek başarının uzmanların seçimine bağlılığı, sonuçlar için geri bildirim zaman alıcı olması, sürecin uzamasına bağlı olarak katılımın azalması şeklinde belirtilebilir.

2.4.1.2. Pazar Arařtırmaları Yöntemi

Pazar kořullarına yönelik verilerin toplanması maksadıyla gerekleřtirilen arařtırma, panel, anket gibi alıřmaları ierir. Pazar arařtırması ve tüketiciler davranıřlarının analizi, pazar talebinin tahmin edilmesinde önemli bilgiler saęlamaktadır. Ayrıca bu yöntem, ürün tasarımı geliřtirilmesi ve yeni ürünlerin planlanması alıřmalarına da yardımcı olmaktadır. Yüksek maliyetli ve zaman alıcı olması ise bu yöntemin sakıncasıdır.

2.4.1.3. Uzman Görüřleri Yöntemi

Talep tahmininde elde edilmesinde iřletmede karar yetkisine sahip üst düzey yöneticilerin, uzmanların, tecrübeli kiřilerin düşünceleri ve kişisel deęerlendirmelerden de faydalanılması mümkündür. Görüřlerin tahmin sürecine aktarılmasında; geleneksel toplantılar yaparak ortak bir görüşe varma, kiřilerle doğrudan tek tek konuşma ya da beyin fırtınasıyla sonuca ulaşma gibi çeřitli metotlar kullanılabilir (Karasu, 2012). Kısa sürede hazırlanabilmesi, her ortamda uygulanabilmesi, geçmişe dayalı verilerin kullanılabilmesi ve bilgisayar desteęine ihtiyaç duyulmaması bu yöntemin avantajları arasında sayılabilir. En zayıf yönü ise, toplam talebi içermemesidir.

2.4.1.4. Satıř Elemanlarının Görüřleri Yöntemi

Pazarlama bölümü ve alıřanlarından özellikle pazarlama stratejilerinin yeniden belirlenmesi, ürün çeřitlendirmesi, kalite ve fiyat tayini, tutundurma ve dağıtım etkinlikleri gibi konularda faydalı bilgiler elde edilebilir. İřletmelerdeki satıř ekipleri, müşteri ile doğrudan temas halinde olduęu ve pazardaki deęiřimleri yakından izledikleri için sübjektif tahminde etkilidirler. Bu yöntemde satıř elemanlarının belirli bir zaman aralıęı için tahmin yapmaları istenir ve daha sonra yapılan tahminler birleřtirilerek deęerlendirilir. Yöntemin uygulanması ve anlaşılmasının basitlięi, kiřilere hedef ve sorumluluk vermenin kolaylıęı, müşteri, ürün, satıřçı ve bölge bazında bölümlendirme yapılabilmesi uzman görüşleri yönteminin avantajları olarak sayılabilir. En büyük dezavantajı ise; tahmin performansının satıř uzmanlarının iyimser veya kötümser olmalarına baęlı olarak sapma göstermesidir.

2.4.1.5. Yařam Eğrilerinin Benzeřimi Yöntemi

Piyasalardaki ürünlerin genel olarak belirli bir yařamının olduęu ve bu yařamın tanınma, büyüme, olgunluk ve gerileme gibi çeřitli ařamalardan getięi kabul edilmektedir.

Gerileme aşaması sonrasında ürünün piyasadaki yaşamı sona ermektedir. Bu yöntem ile genellikle piyasadaki benzer ürünlerin yaşam eğrilerinin çeşitli dönemlerdeki satışlarına bakılarak piyasaya yeni çıkacak bir ürün için talep tahmini yapılır.

2.4.1.6. Senaryo Analizi Yöntemi

1967 yılından sonra Herman Kahn'ın çalışmalarıyla senaryo analizinin tahmin aracı olarak kullanılması popülerlik kazanmıştır. Senaryolar, geleneksel yöntemlerden farklı olarak alternatif gelecekler ortaya koymaktadır ve aynı zamanda ekonometrik yöntemlerin dışarda bıraktığı konuları ve kalitatif perspektifleri de kapsamaktadır. Senaryolar, geleceğe ilişkin olası gelişmelerin göz önünde bulundurulmasıyla daha net bir görüş açısı sağladığı gibi nelerin olabileceği ya da olanların ne olduğunu kavramaya da yardımcı olurlar (Çağlar, 2007). Bu yöntemde en iyiyi, en kötüyü veya beklenen durumu yansıtan senaryolar oluşturulur ve muhtemel sonuç ve olasılıklara yönelik bilgi verilerek tüm bunlar risklerin değerlendirilmesinde göz önünde bulundurulmaktadır.

Senaryo analizi yöntemi, genellikle belirsizliğin fazla olduğu, geçmişte yüksek maliyetli sürprizlerin çok fazla yaşandığı, algılanan ve yaratılan yeni fırsatların yetersiz olduğu, faaliyet gösterilen endüstrinin önemli değişimler içinde bulunduğu veya böyle bir olasılığın var olduğu ya da rakiplerin senaryo analizi kullandığı durumlarda daha sıklıkla kullanılmaktadır. Bu analiz yöntemi, sosyal davranışlar, tüketim ve teknoloji alanındaki son 50 yıla ilişkin değişimleri göz önüne alması açısından güçlü bir sistemdir.

Geçmişe dair bilgilerin kullanılması sırasında gelecek döneme ilişkin birçok tahminde bulunurken, geleneksel yaklaşıma kıyasla daha kullanışlı olabilecek yaklaşımlarda bulunabilmesi ve bilginin tahmin yürütmek için kısıtlı olduğu zamanlarda daha çok hangi açıdan ve neye yönelik tahminler yapılması gerektiğine açıklık getirmesi bu yöntemin güçlü yönlerini oluşturmaktadır. Senaryo analizinin güçlü yönleri olduğu gibi zayıf yönleri de bulunmaktadır. Öncelikle senaryoların oluşturulma süreci halen tam olarak açıklığa kavuşturulmuş değildir ve bazı senaryoların gerçekçi olmayacağı ihtimali de vardır. Senaryo analizleri, uzmanlardan bilgi alınmasını gerektirse de bu bilginin ne şekilde alınacağı ve kısıtlarına yönelik konulara çok değinilmemiştir. Senaryo analizi yöntemlerinin diğer bir temel zayıflığı ise içerdiği statik yapısıdır (Çuhadar, 2006).

2.4.2. Kantitatif Tahmin Teknikleri

Bu yöntem, kalitatif tekniklerdeki gibi kişisel yargı ve görüşlere değil, sayısal verilerin analizine ve çeşitli istatistiksel yöntemlerin sonuçlarına dayanmaktadır. Bu tekniklerin işletmelerin karar verme aşamasında kullanılabilmesi için tahmin yapılacak değişken ya da duruma yönelik sayısal verilerin ulaşılabilir olması gereklidir. Kantitatif tekniklerde faydalanılan sayısal veriler; satış noktası verileri, barkod teknolojisi ve müşterilerden elde edilebilmektedir. Ayrıca doğru bilgilere ulaşılabilmesi için bilişim teknolojilerinden de faydalanılabilmektedir.

Sayısal yöntemlerin tümünde, geçmişe dair doğru ve yeterli bilgi toplanması gerekliliği bulunmaktadır. Yetersiz ve doğruluk derecesi düşük olan veriler ile kullanılan tahmin modeli ne kadar kapsamlı olursa olsun iyi sonuçlar elde edilmesi mümkün değildir. Verilerin yeterli ve doğru bir düzeyde bulunmaması tahmin yöntemi seçim sürecini kısıtlamaktadır. Sayısal tahmin yöntemlerinden bazıları son derece basit bir yapıya sahip olmasına rağmen, bazıları ise oldukça karmaşık yapıdadır. Bazı teknikler diğer tekniklere kıyasla daha iyi sonuç verse de bir genelleme yapılabilmesi mümkün değildir. Tahmin durumlarının yapılarına bağlı olarak kullanılacak yöntem farklı olmalıdır (Üreten, 2005).

Kantitatif tahmin teknikleri, zaman serileri ve nedensel teknikler olmak üzere ikiye ayrılır.

2.4.2.1. Zaman Serileri Analizine Dayalı Yöntemler

Her biri belirli bir t zamanında kaydedilmekte olan gözlemler kümesi zaman serisi olarak ifade edilmektedir. Bir olguya ilişkin değişken veya değişkenlerin zaman içinde yapılan gözlemleri ya da ölçümleri zaman serilerini oluşturur.

Zaman serileri analizinde, tahminleme yapılacak değişkene ait geçmiş veriler belli bir veri seyri elde etmek için analiz edilirler. Bu sebeple tahmin, yalnızca geçmiş verilerin bu maksatla analizine ve daha sonra yapılacak tahminlerde kullanılmasına dayanır. Bu yöntemde, bağımsız değişken daima bir zaman ölçüsü (saat, ay, gün vs.) birimidir ve değerler arasındaki aralıklar eşittir. Bağımlı değişken ise, para, stok düzeyi, verim, mamul sayısı gibi ölçülebilen herhangi bir varlık olabilir. Geçmiş dönemlere ilişkin elde edilen bilgilerin istatistiki değerlendirilmesi yapıp eğilimleri belirlendikten sonra geleceğe yönelik

muhtemel talep tahmini yapılabilir. Sahip olduğu bu özelliklerden dolayı, değişmeyen koşullar altında zaman serileri analizi yöntemi daha etkin sonuçlar ortaya koymaktadır.

Zaman serisi analizinde en çok kullanılan yöntemler; hareketli ortalamalar yöntemi, mekanik (naive) yöntemi, üssel düzeltim yöntemi, trend analizi yöntemi ve Box-Jenkins yöntemleri olarak ifade edilebilir.

2.4.2.1.1. Hareketli Ortalamalar Yöntemi

Bu yöntemde belli bir döneme ait geçmiş verilerin göstermiş olduğu dalgalanmalar ve bunlara ilişkin hareketli ortalamalar hesaplanarak gelecek dönemlerde nasıl bir eğilim göstereceği tahmin edilebilir. Hareketli ortalamaya dahil edilecek gözlem sayısını tahmin yapacak kişi belirlemektedir ve bu sayı sabit kalmaktadır. Hareketli ortalama ifadesinin kullanılmasındaki sebep, seriye her bir yeni değerin eklenmesiyle yeni bir ortalamanın hesaplanması ve bu değerin tahmin olarak kullanılacak oluşudur (Çuhadar, 2006).

Hareketli ortalama, her defasında en eski değerin çıkarılması ve yeni değerin eklenmesiyle belli bir sayıdaki döneme ait değerlerin tekrarlı olarak ortalamasının alınması yoluyla elde edilir. Hareketli ortalamalar, verilerin genel düzenini korumakla beraber verilerdeki dalgalanmaları düzeltebilirler. Fakat tahmine ilişkin bir denklem oluşturamazlar ve veri serilerinin son dönemlerine ait tahmin değerlerine ulaşılmasını sağlamazlar (Monks, 1996). Hareketli ortalamalar yönteminde, uzak geçmişten ziyade yakın geçmişe yoğunluk verilir ve buna dayalı olarak, sadece bir döneme yönelik satış tahmini yapılır. Örneğin, geçmişe ait üç, dört veya beş dönemin verilerine en son gerçekleşen dönem verileri de eklenerek elde edilen verilerin ortalamasının alınmasıyla bulunan değer bir sonraki dönemin satış miktarı olarak kabul edilir.

Hareketli ortalamalar yönteminin basit ve ağırlıklı hareketli ortalamalar olmak üzere iki grupta incelenmesi mümkündür:

Basit Hareketli Ortalama: Talep tahmini açısından geleceğe en basit bakıştır. Geleceğin, geçmişte gerçekleşenlerin ortalamasına doğru eğilim göstereceği varsayımına dayanır. Geleceğin en geçerli tahmini bu varsayıma göre, geçmişteki verilerin tek tek toplanarak ortalamasının alınmasıdır. Bu yöntem oldukça basit olup, sıradan birinin dahi aritmetik ortalamayı matematiksel olarak aşağıda gösterilen formülü kullanarak hesaplayabilmesi mümkündür.

$$F_{t+1} = \frac{(Y_t + Y_{t-1} + \dots + Y_{t-n+1})}{n} \quad (2.1)$$

Formülde yer alan;

F_{t+1} = t+1 dönemindeki tahmin değerini,

Y_t = t dönemindeki gözlem değerini,

n = hareketli ortalamaya dahil edilen gözlem sayısını ifade etmektedir.

Bu yöntemde hatayı minimize etmek için çoğunlukla deneme-yanılma tekniği kullanılır. En eski değer, her yeni değer gerçekleşmesinde hesaplamadan çıkarılarak son n döneme ait ortalama hesaplanır. Bulunan bu ortalama değeri, bir sonraki döneme ait tahmin değeridir (Heize & Render, 2011).

Ağırlıklı Hareketli Ortalama: Basit hareketli ortalama tekniğinde tahmini değer hesaplanması sırasında son n dönemin ortalaması alınırken her döneme eşit bir şekilde ağırlık verilir. Bu yöntemde ise her dönem için verilen ağırlık birbirinden farklıdır. En yakın döneme en büyük ağırlık verilmektedir. Bu sayede, geçmiş hareketlerin daha yakın zamanı etkileme oranı minimum seviyeye indirgenmektedir. Formüldeki w_i değerleri ağırlıkları göstermek üzere ağırlıklı hareketli ortalama yönteminin matematiksel ifadesi aşağıdaki gibidir.

$$F_{t+1}^w = \frac{(w_n Y_t + w_{n-1} Y_{t-1} + \dots + w_1 Y_{t-n+1})}{w_n + w_{n-1} + \dots + w_1} \quad (2.2)$$

Bu yöntemde en yakın döneme en fazla ağırlık verilmesinin nedeni, gelecek dönem satışlarının son dönem satışlarından daha fazla etkileneceğinin kabul edilmesidir.

2.4.2.1.2. Mekanik (Naive) Yöntemi

Naive yöntemi en basit tahmin yöntemi olup, tahmin yapmak için kullanılabilmesi gibi gerçekleştirilmiş bir tahminin üstünlüğünün olup olmadığını belirlemek amacıyla da kullanılabilir. Bu yöntem, gelecek dönem talebinin gözlenen en son değere veya bu değerden belli bir yüzdenin eklenmesi veya çıkartılmasıyla elde edilen değere eşit olacağı varsayımı üzerine kuruludur. Yöntemin matematiksel eşitliği aşağıdaki gibidir;

$$F_{t+1} = Y_t \quad (2.3)$$

t = dönem

F_{t+1} = t+1 dönemi için tahmin değerini

$Y_t = t$ dönemi için gerçekleşen değeri ifade etmektedir.

Herhangi bir dalgalanma göstermeyen zaman serilerinde tahmin amacıyla bu yöntem kullanılabilir. Ayrıca hem maliyetsiz hem de uğraş gerektirmeyen bir yöntemdir. Gelişmiş zaman serisi yöntemleri için bir başlangıç değeri oluşturması yöntemin en büyük avantajıdır (Heize & Render, 2011). Ancak, zaman serilerinde genellikle dalgalanmalar söz konusu olduğu için zaman serileri için pek kullanışlı değildir.

2.4.2.1.3. Üssel Düzeltim Yöntemi

Bu yöntemde, basit hareketli ortalama yönteminde olduğu gibi geçmişe ait tüm veriler dikkate alınır. Ancak, tahmin için kullanılan yakın geçmişte gerçekleşen geçmiş dönem verilerine yüksek ağırlık verilirken, veriler eskidikçe üstel olarak azalan ağırlıklar verilmektedir. Bu durum ise, yöntemin basit hareketli ortalamalara göre en önemli üstünlüğünü ortaya koymaktadır.

Basit üssel düzeltme yöntemi, Holt-Winters yöntemi, Holt'un doğrusal yöntemi ve Pegel'in sınıflandırması yöntemi gibi çeşitli düzeltim yöntemleri geliştirilmiş olup, tez kapsamında bu yöntemlerden sadece basit üssel düzeltim yöntemine değinilecektir. Basit üssel düzeltim modeli matematiksel olarak aşağıdaki gibi gösterilebilir (Anderson, ve diğerleri, 2014):

$$F_{t+1} = \alpha Y_t + (1 - \alpha) F_t \quad (2.4)$$

F_{t+1} = t + 1 dönemi için talep değeri,

Y_t = t dönemi için gerçekleşen talep değeri,

F_t = t dönemi için talep tahmin değeri,

α = düzeltme katsayısıdır.

Düzeltilme katsayısı, $0 \leq \alpha \leq 1$ arası değerler almaktadır. Uygulamada genellikle 0,01-0,3 arasındaki değerlerin daha uygun olduğu tespit edilmiştir. Burada α katsayısının kullanılması ihtiyaç duyulan veri sayısının önemli ölçüde azaltılmasına olanak sağlar. Böylelikle, hareketli ortalamalar yöntemindeki gibi ortalamaya eklenen her dönem sayısı için ayrı bir veriye ihtiyaç kalmaz. İçinde bulunulan döneme ilişkin tahmini değeri

bulmak için yalnızca bir önceki dönemde gerçekleşen ve tahmini talep verilerinin varlığı yeterli kabul edilmektedir (Üreten, 2005).

Üssel düzeltim yöntemlerinin kolay uygulanabilir ve düşük maliyetli olmaları en önemli üstünlükleri olarak gösterilebilir. Ayrıca gerçekleşen her yeni dönem verilerinin modele hemen eklenebilmesi ve yeni dönem tahminlerine anında katkı sağlayabilmeleri de diğer üstünlükleri olarak sayılabilir.

2.4.2.1.4. Trend Analizi Yöntemi

Trend analizi yönteminin temeli; geçmiş dönemlerde gerçekleşen işletme satışlarının dikkate alınarak geleceğe ilişkin satış taleplerinin oluşumuna ait tahmin yapılmasına dayanır. Bu yöntem, geçmişteki tüm koşulların gelecekte de devam etmesinin beklendiği durumlar için oldukça başarılı sonuçlar sağlamaktadır. Ancak, ekonomik ve teknik koşullarda değişimlerin görülmesi halinde, yöntemin kullanımıyla yapılacak tahminde ortaya çıkabilecek değişimler göz önünde bulundurularak ihtiyaç duyulan düzeltmelere yer verilmesi gereklidir. Aksi halde değişikliklere uyum sağlamayan tahminler beklenen gerçeklerden çok uzak düşebilir (Bulut, 2006).

Bu yöntemin varsayımları aşağıdaki gibidir:

- Geçmişe ait veriler düzenli bir gelişme göstermektedir. Ekonomik olayların istatistikleri ele alındığında veriler belirli bir doğru ya da eğri üzerinde sıralanmaktadır.
- Gelecek, geçmişin bir uzantısıdır. Gelecekteki gelişmeyi tahmin ederken doğru eğrinin önceki biçimini sürdüreceği varsayılır. Bu durumda, trend ve trendin ait olduğu değişken zamanın bir fonksiyonu olarak kabul edilmektedir.


Trend hesaplama yöntemleri aşağıda belirtildiği gibi üç ana gruba ayrılarak incelenebilir (Demir & Gümüşoğlu, 2011).

- Elle Çizme Yöntemi
- Yarım Ortalama Yöntemi
- En Küçük Kareler Yöntemi

Elle Çizme Yöntemi: Bu yöntemde, belirlenmiş olan noktalar arasından bir eğri ya da doğru geçirilir. Eğri ya da doğru çizilirken, noktaların eğrinin iki yanında aynı oranda dağılım gösterecek şekilde olmasına dikkat edilir. Daha sonrasında ise, çizilen eğriye ilişkin eşitlik hesaplanır (Demir & Gümüőođlu, 2011).

Bu yöntem uygulama açısından kolaylık göstermesine rağmen objektiflikten uzaktır. Aynı verileri kullanarak farklı kişilerin çizeceđi doğru ya da eğriler birbirinden farklı olabilmektedir. Kabaca tahminin yeterli olduđu durumlarda kullanılması uygun olup, duyarlı analiz yapılmak istenildiđinde ve analiz sonuçlarının iőletmenin yönetimi için alınacak kararlara yol göstermesi beklenildiđinde kullanılması uygun deđildir.


Elle çizme yöntemi grafiđini aőađıdaki gibi ifade etmek mümkündür.



Őekil 2.1: Elle Çizme Yöntemi Grafiđi

Yarım Ortalama Yöntemi: Bu yöntemde, incelenen dönem gözlem sayısı dikkate alınarak iki eőit kısma ayrılır. Her iki kısım için ayrı ayrı aritmetik ortalama hesaplanır ve hesaplanan ortalama deđerler grafik üzerinde iőaretlendikten sonra araları bir doğru ile birleőtirilir.

İncelenen örnekteki (serideki) gözlem sayısının tek veya çift sayıda olmasına bađlı olarak yapılacak iőlem deđişiklik gösterir. Serinin çift sayılı olması halinde, seri tam ortadan iki eőit parçaya ayrılır. Serinin tek sayılı olması halinde ise, tam ortadaki eleman dikkate alınmaksızın seri iki eőit parçaya ayrılır (Köksal, 2003).



Şekil 2.2: Yarı Ortalama Yöntemi Grafiği

Bu yöntemin dezavantajları;

- Trendin doğrusal olduğu varsayımının bulunması, ancak trendin doğrusal olmayabilmesi,
- İkiye bölünen serinin her iki kısmında da mevsimsel dalgalanmaların aynı olduğunun kabul edilmesi, ancak bu durumun çoğu zaman geçerli olmayabilmesidir.

En Küçük Kareler Yöntemi: Trend analiz yöntemleri içinde en güvenilir metod "en küçük kareler yöntemi"dir. Bu sebeple verilerin elverişli olması halinde eğilimin hesaplanmasında en çok uygulanan yol olarak ifade edilmektedir. Eğilimin matematiksel ifadesi aşağıdaki gibidir:

$$Y = a + bX \quad (2.5)$$

En küçük kareler metoduna göre, bir değerler serisini en iyi gösteren doğru ya da eğri, geçmiş dönemlere ilişkin gerçekleşmiş değerler ile formülün uygulanması sonucunda elde edilecek teorik değerler arasındaki farkların karelerinin toplamını minimize eden ve tüm dikey sapmaların toplamını (tahmin hatasını) sıfıra eşitleyen doğru ya da eğridir. Bu durumun matematiksel ifadesi ise;


$$\sum[Y_i - (a + bX_i)]^2 = \min \quad (2.6)$$

$$\sum[Y_i - (a + bX_i)] = 0 \quad (2.7)$$

Aşağıda verilen örnekte en küçük kareler tekniği kullanılarak bir veri grubu üzerinde parametrelerin nasıl tahmin edildiği gösterilmiştir.


Boy(cm) (X)	Çevre(cm) (Y)
6	4
15	6
9	5
24	12
26	17
32	19

Örnekteki X ve Y veri grubuna ilişkin altı gözlem çifti, koordinat düzlemine yerleştirildiğinde bulunan serpmeye diyagramına ait grafik Şekil 2.3'deki gibidir.



Şekil 2.3: En Küçük Kareler Serpmeye Diyagramı

Şekil 2.3'de verilen noktaları temsil eden regresyon doğrusu oluşturulduğunda Şekil 2.4 elde edilir.



Şekil 2.4: En Küçük Kareler Grafiği

Bu yöntem ile elde edilen doğru denklemi, herhangi bir doğruya kıyasla işaretli noktalar arasına en iyi oturan doğru olma özelliğini taşır. En küçük kareler yöntemi, zaman serilerinin yapısal analizleriyle konjonktürel dalgalanmalarının hesaplanmasında bazı fayda ve sakıncalar oluşturur (Bulut, 2006). Eğilim tahminin yalnızca grafikteki dalgalanmalara göre yapılabilmesi ve seriye ait değerlerden hiç kayıp olmaması yöntemin faydaları arasında yer almaktadır. Trend tipi seçimindeki subjektif davranışın araştırmacıyı yanıltabilmesi durumu ise yöntemin sakıncasıdır. Belirlenen trend serideki terimlerin değişmelerine tam olarak uyum sağlamaz, ancak yönünü gösterir.

2.4.2.1.5. Box-Jenkins Yöntemi

Durağan zaman serilerinde modelleme amacıyla yaygın olarak kullanılan yollardan bir diğeri ise, “öz bağımsal tümleşik hareketli ortalama (autoregressive integrated moving average)” ya da kısaca ARIMA yöntemidir. George Box ve Gwilym Jenkins tarafından geliştirdiği için bu yaklaşım Box-Jenkins (BJ) yöntemi olarak da adlandırılmaktadır. Bu yöntemin temel vurgusu, zaman serilerini yalnızca kendi geçmiş değerleri ve olasılıksal hata terimi ile açıklamaktır. Tezin uygulama kısmında kullanıldığı için bu yönteme ilişkin detaylı bilgilere üçüncü bölümde yer verilmiştir.

2.4.2.2. Nedensel (İlişkiye Dayalı) Yöntemler

Nedensel yöntemlerde; tahmini değeri hesaplanacak olan değişkenin farklı faktörlerden etkilendiği düşünülmektedir. Açıklanmak istenen bağımlı değişkeni etkileyen veya bağlı olabileceği düşünülen diğer değişkenler belirlenmeye çalışılmaktadır ve bu etkilerin formüle edilmesi amacı güdülmektedir (Orhunbilge, 1999). Nedensel yöntemler bir değişkenin geleceğe ilişkin değerini tahmin etmekten ziyade değişkenler arasındaki ilişkinin açıklanmasına yöneliktir. Bu modeller problemi daha çok matematiksel bir yolla açıklamaya yararlar.

Nedensel yöntemlerin temelini regresyon ve korelasyon analizi oluşturur. Genellikle; ülke nüfusu, yaşam ve ulaşım maliyetleri, gelir dağılımı, döviz değişim oranları, gayri safi milli hasıla ve fiyat ilişkileri gibi değişkenler arasındaki ilişki derecelerinin ölçümünde kullanılırlar (Karahan, 2011).

2.4.2.2.1. Regresyon Yöntemi

Regresyon analizi, bir ya da daha fazla sayıdaki bağımsız değişken ile bir bağımlı değişken arasındaki ilişkinin matematiksel olarak ifade edilmesini sağlayan istatistiksel bir tahminleme tekniğidir. Bağımlı değişkeni etkileyen bağımsız değişkenlerin tahmin edilmesiyle bu değişken üzerinde geliştirilecek plan ve politikalarda hangi değişkenin önem kazandığının tespit edilmesine yardımcı olunmaktadır. Bu yöntem sayesinde, hangi faktörlerde nasıl bir değişikliğin yapılmasıyla bağımlı değişkende artış ya da azalış oluşturulabileceği belirlenebilir (Montgomery, Jennings, & Kulahci, 2008).

Regresyon modelinde açıklanan veya tahmin edilen değişken bağımlı değişken (Y) olarak ifade edilmektedir. Bu değişkenin bağımsız değişkenle ilişkili olduğu kabul edilir. Bağımsız değişken (X_1, X_2, \dots, X_n) ise, regresyon modelindeki açıklayıcı değişkendir ve bağımlı değişkenin değerini tahmin etmek amacıyla kullanılmaktadır. Y, bağımsız değişkenlerin değerlerine göre farklı değerler alır. İki ya da daha fazla değişken arasındaki ilişki doğrusal veya eğrisel olabilmektedir. Genel olarak basit doğrusal regresyon, eğrisel regresyon, çoklu doğrusal regresyon ve üssel regresyon şeklinde sınıflandırmak mümkündür. Bunların matematiksel gösterimleri ise aşağıdaki gibidir.

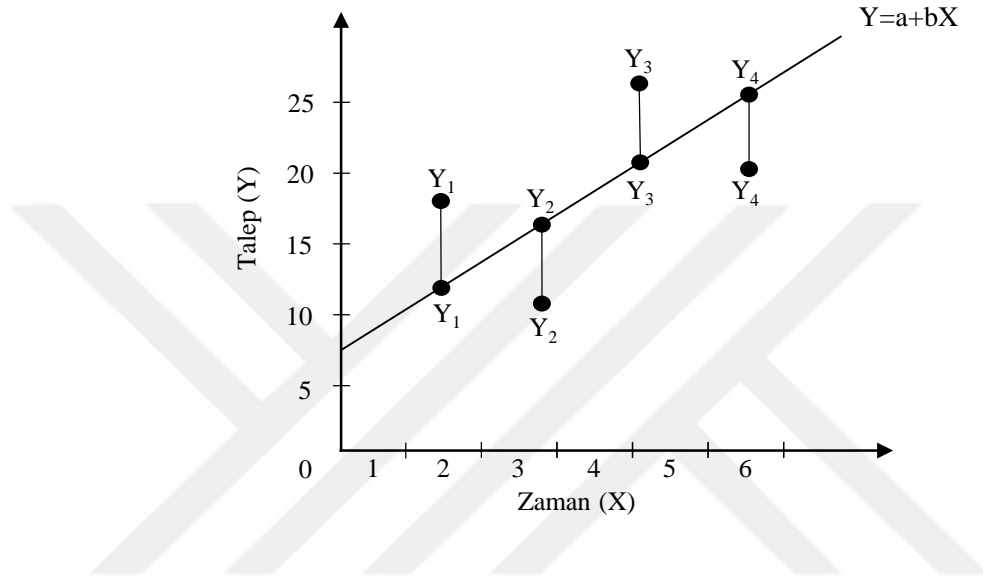
$$\text{Basit Doğrusal Regresyon} \quad : Y = a + bX \quad (2.8)$$

$$\text{Eğrisel Regresyon} \quad : Y = a + b_1X + b_2X^2 + \dots + b_nX^n \quad (2.9)$$

$$\text{Çoklu Doğrusal Regresyon} : Y = a + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (2.10)$$

$$\text{Üssel regresyon} : Y = a \cdot b_1^x \quad (2.11)$$

Basit doğrusal regresyon denklemindeki a ve b değerlerinin bulunabilmesi için en küçük kareler tekniği kullanılır. Bu teknikte kullanılan matematiksel ifadeler grafiksel olarak Şekil 2.5'deki gibi gösterilebilir.



Şekil 2.5: Regresyon Grafiği

Regresyon analizinde, gerçek değerler ile doğru üzerindeki bağımlı değişken değerleri arasındaki farkın karelerinin toplamını minimum hale getirecek en uygun doğru tespit edilmeye çalışılır.

2.4.2.2.2. Korelasyon Yöntemi

Regresyon analizinde değişkenler arasındaki ilişkinin niteliğinin belirlenmesi amaçlanırken, korelasyon analizi değişkenler arasındaki ilişkinin derecesini tanımlamak için kullanılır. Korelasyon analizi; iki değişken arasındaki doğrusal ilişkinin veya bir değişkenin iki ya da daha fazla değişken ile olan ilişkisinin test edilmesi ve var ise bu ilişkinin derecesinin ölçülmesi amacıyla kullanılan istatistiksel bir tekniktir (Karasu, 2012). İki değişken arasındaki ilişki, belirlilik katsayısı ve korelasyon katsayısı olarak ifade edilen iki parametre ile belirlenir (Tütek & Gümüşoğlu, 2000). Basit korelasyonda, iki değişken arasındaki doğrusal ilişkinin yakınlığı ya da derecesi korelasyon katsayısı

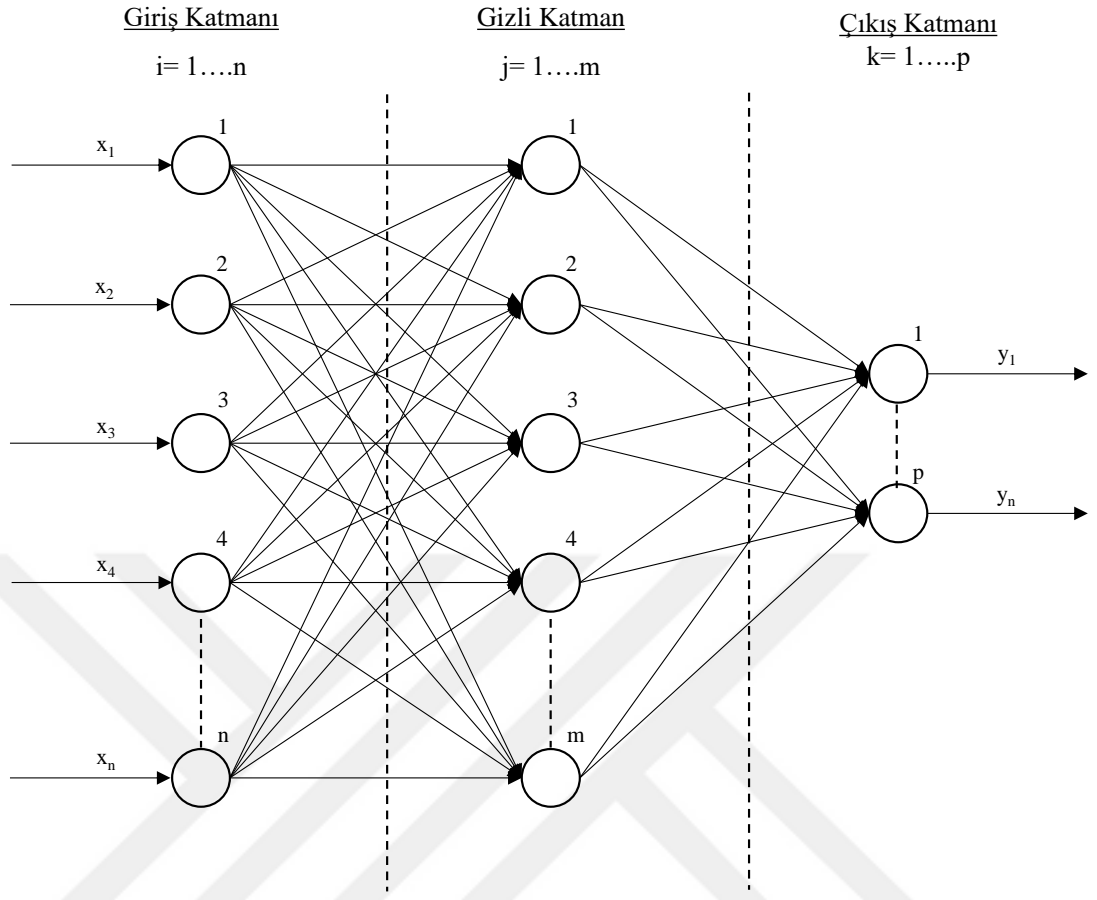
cinsinden ifade edilir ve bu katsayısı regresyon doğrusu karşısında gözlem noktalarının göstermiş olduğu değişkenliğin dolaylı bir ölçüsüdür.

2.5. Yapay Sinir Ağları

Yapay sinir ağları (YSA) insan beyninin çalışma prensibinden esinlenerek tasarlanmış, beynin öğrenme, hatırlama, bilgi alma ve gönderme gibi temel işlevlerini gerçekleştirmek üzere geliştirilen matematiksel modeller olarak ifade edilir. Diğer bir deyişle, insan beyninin kopyası gibidirler. YSA'lar, yeni bilgiler üretebilme, keşfedebilme, gözlemleyebilme yeteneklerini öğrenme yoluyla yardım almaksızın yapabildiği sistemleri geliştirmek için bir yapı taşı olarak kullanılmak üzere tasarlanmışlardır (Temür, 2013).

Problem çözmek amacıyla kullanılan yapay sinir hücreleri birbirine bir ağ şeklinde bağlanmıştır. Hücrelerin aralarındaki bilgi transferi bağlantı değerleri ve ilişkilerle gösterilip, sistemin davranışı ve öğrenme yeteneği bağlantı değerlerinin kullanılması ile sağlanmaktadır (Tekin, 2009). Bu ağlar, öğrenme yeteneği ile birlikte bilgiler arasında ilişkiler oluşturma ve ezberleme yeteneğine de sahiptirler (Elmas, 2007).

YSA'lar tek yönlü olarak iletim yoluna sahip düğümlerden oluşmaktadır. Her düğüm n. dereceden lineer olmayan bir birimdir. Düğümler arasında bağlantılar bulunmakta ve bir düğümün birden fazla düğüme veri aktarabilmesi mümkündür. İşlenen bilgiler bir sonraki katmandaki bir veya birden fazla düğüme iletilirler (Yılmaz N. , 2008). Karmaşık işlemleri hesaplama yeteneğine sahip olmayan ağlar sadece giriş ve çıkış katmanlarında oluşan ağlardır. Bu sebepten dolayı karmaşık hesaplamaların yapılabilmesi için en az bir gizli (ara) katmana ihtiyaç duyulur. Şekil 2.6'da bir gizli katmana sahip katmandan oluşan bir yapay sinir ağı modeli görülmektedir (Elmas, 2003).



Şekil 2.6: Çok Katmanlı Yapay Sinir Ağı

Bir katmanın her bir sinir hücresinin çıkışı bir sonraki katmandaki sinir hücrelerinin tamamı ile bağlantılıdır. Aynı katmandaki sinirlerin birbirleri arasında tek yönlü iletim prensibinden dolayı bağlantılar yoktur. Aynı zamanda geri besleme şeklinde bağlantı mevcut değildir.

YSA, verilerin analiz edilmesinde ve veriler içindeki örneklerin tanınmasında geleneksel hesaplama yöntemlerden farklı bir yöntem sunmaktadır. Fakat YSA, her problemin çözümü için kullanılacak uygun bir yaklaşım olmayabilir. İyi tanımlanmış problemlerin çözümünde, geleneksel yöntemler güçlü bir araç olarak kullanılmaktadırlar. Örneğin, envanter listelerinin kaydedilmesi, muhasebe kayıtlarının tutulması gibi problem çözümlerinde özel bir ağ yapısına ihtiyaç duyulmadığından geleneksel bilgi işleme yöntemleri kolaylıkla kullanılmaktadır (Çakın, 2017). Çeşitli özellikler açısından geleneksel bilgi işleme ve YSA yöntemleri arasındaki farklılıklar Tablo 2.1'deki gibi özetlenebilir (Anderson & McNeill, 1992).

Tablo 2.1
Geleneksel Bilgi İşleme ve YSA Yöntemlerinin Karşılaştırılması


Özellikler	Geleneksel Bilgi İşleme (Uzman Sistemler Dahil)	YSA
Bilgi İşleme Şekli	Ardışık	Paralel
Fonksiyonlar	Kurallar, kavramlar, hesaplamalar ile mantıksal (Sol Beyin)	Şekiller, resimler, kontroller ile biçimsel (Sağ Beyin)
Öğrenme Yöntemi	Kurallar ile (didaktik)	Örnekler ile
Uygulama Alanları	Muhasebe, kelime işleme, matematik, envanter, dijital iletişim	Sensör işleme, konuşma tanıma, örüntü tanıma, metin tanıma

Kaynak: (Anderson & McNeill, 1992: 13)

2.5.1. Yapay Sinir Ağlarının Temel Bileşenleri

2.5.1.1. Biyolojik Sinir Hücresi


Biyolojik sinir sistemi; bilgiyi alan, yorumlayan ve karar üreten merkezi bir yapı tarafından (beyin) yönetilen üç katmanlı bir sistem olarak ifade edilir. Şekil 2.7’de blok diyagramı verilen biyolojik sinir sistemi kapalı çevrim blok diyagramı olarak çalışmaktadır.



Şekil 2.7: Biyolojik Sinir Sistemi Blok Diyagramı

Alıcı sinirler genel olarak dış ortamdan gelen uyarıları merkezi birime iletmek üzere elektriksel sinyallere dönüştürürler. Tepki sinirleri ise, beyin tarafından yorumlanan verinin organizmaya uygun tepkiler olarak aktarılmasını gerçekleştirmektedir. Bu işlemleri gerçekleştiren sistemin temel yapısı sinir hücresidir (nöron). Sinir hücreleri, sinir sisteminin en temel fonksiyonel birimi olup işlevi bilgi transferinin gerçekleştirilmesidir.

Bir insan beyinde milyarlarca sinir hücresi olduğu tahmin edilmektedir. Şekil 2.8’de alıcı lifler (dentrit), sinyal iletici lifler (akson), hücre gövdesi (soma) ve snapslerden meydana gelen bir sinir hücresinin yapısı gösterilmektedir.



Şekil 2.8: İnsan Sinir Hücresi Yapısı

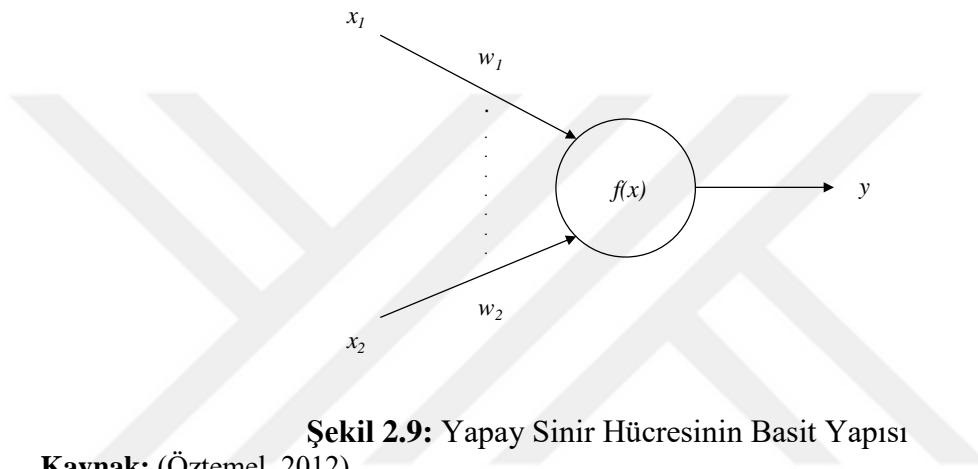
Kaynak: (Güzel, 2019)

Bilgiler dentritler sayesinde hücre gövdesine iletilirler. Hücrelerden gelen çıktılar ise, aksonlar yardımıyla diğer hücrelere aktarılırlar. Bu işlem milyarlarca hücrede aynı şekilde gerçekleşmektedir. Bu hücrelerin hepsine bilginin aktarımı, aksonlar ve dentritler arasındaki bağlantı ile sağlamaktadırlar. Akson-dentrit bağlantısının olduğu bu noktalara sinaps adı verilmektedir. Sinapsa ulaşan bilgiler genellikle elektriksel darbeler olarak tanımlanırlar. Hücrenin gelen bilgilere karşılık tepki oluşturması için belirli bir sürede belirli bir seviyeye erişmiş olması gereklidir. Bu seviye değerine eşik değeri adı verilir. Gelen bu sinyaller somaya gider ve somanın bunları işleme tabi tutması ile sinir hücresi kendi elektrik sinyalini oluşturur. Bu sinyaller akson aracılığıyla dentritlere gönderilir. Dentritler de gelen bu sinyalleri snapslere göndererek diğer hücrelere gönderirler. YSA, sinir hücrelerinin bir araya gelerek sinir sistemini oluşturması özelliğinden faydalanılarak geliştirilmiştir (Öztemel, 2012).

2.5.1.2. Yapay Sinir Hücresi

YSA yapıları, belli sorunları çözmek amacıyla birlikte çalışan ve çok sayıdaki birbirine bağlı bilgi işleme elemanlarından (nöronlar) oluşur. İnsan beyinin öğrenme yoluyla yeni bilgiler üretebilme, keşfedebilme, gözlemlene ve düşünmeye yönelik yeteneklerini örnek


olarak, yardım almaksızın yapabilen sistemler geliştirmek amacıyla tasarlanmışlardır. YSA'lar sorunları çözebilmek için insanlar gibi sorunlara karşı gerçekleştirecekleri davranışları örnekler ile öğrenirler. Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik bağlantıların ayarlanmasını içerir. Bu, YSA'larda da geçerlidir. YSA, Şekil 2.9'da verilen tek bir sinir hücre yapısının çoklu olarak bir araya gelmesi ile oluşturduğu karmaşık bir yapıdır. Bu karmaşık yapıların oluşması rastgele olarak değil, sinir hücrelerinin belirli bir sistematik yapı ile bir araya gelmesiyle gerçekleşirler ve YSA'yı oluştururlar.



Kaynak: (Öztemel, 2012)

Yapay sinir hücresi ise, YSA'nın çalışmasına temel teşkil eden en küçük ve temel bilgi işleme birimidir. Ağ içerisinde bulunan bütün yapay sinir hücreleri bir ya da birden fazla girdi alırlar ve tek bir çıktı üretirler. Üretilen bu çıktı YSA'nın dışına verilebileceği gibi başka bir yapay sinir hücresi için girdi olarak da kullanılabilir (Kızılkaya, 2017).

Genel olarak basit bir YSA modeli bir girdi ve çıktı katmanından oluşmaktadır. Her katman, paralel olarak birden fazla girdi ve çıktı elemanı içerebilir. Girdi ve çıktı katmanından oluşan basit bir YSA modeli Şekil 2.10'da verilmiştir. Yapay sinir hücresi, giriş verilerini toplayan ve eşik fonksiyonuna göre bir değer üreten yapıdır. Toplanan bu değer belli bir eşiği aştığında, hücre bir etki oluşturur. Bu yapı, yapay sinir hücresinin temel mantığıdır. (Yılmaz N. , 2008).



Şekil 2.10: Yapay Sinir Hücresinin Temel Yapısı

Kaynak: (Öztemel, 2012)

İşlemci olarak adlandırılan yapay hücreler, YSA'nın temel birimleridir. Bir yapay hücre biyolojik yapıdaki bir hücre ile kıyaslandığında daha basit bir yapıya sahiptir. Ancak, yapay hücreler genellikle biyolojik hücrelerin bazı temel işlevlerini taklit ederler. Her yapay sinir hücresinin beş temel elemanı bulunmaktadır. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve hücrenin çıktısıdır.

Girdiler

Girdiler ($x_1, x_2, x_3, \dots, x_n$) dış dünyadan ya da başka bir sinir hücresinden gelen bilgilerin gizli katmana gönderilmesi işlemi gerçekleştirirler. Bu gönderim esnasında herhangi bir bilgi işleme durumu gerçekleşmez. Gelen bilgiler bir sonraki katmana aynen iletilirler (Günören, 2010).

Ağırlıklar

Ağırlıklar ($w_1, w_2, w_3, \dots, w_n$), yapay sinir ağı tarafından alınan girdilerin sinir hücresi üzerindeki etkisini belirleyen katsayılarıdır. Bir sinir ağında her bir hücrenin her bir girişi için bir ağırlık vardır. Bir ağırlık değerinin küçük olması, o girdinin sinir hücresine zayıf bağlanması veya önemli olmaması anlamına gelirken, büyük olması girdinin sinir hücresine güçlü bağlanması veya önemli olması anlamına gelmektedir (Elmas, 2007).

Toplama İşlevi

Toplama işlevi, sinir ağında bulunan bir hücrenin her bir girdisi (x) ile o girdiye ait ağırlık (w) değerlerinin çarpımlarının toplanması işlemidir. Matematiksel ifadesi eşitlik 2.12’de olduğu gibidir.

$$Toplam = \sum_i^n x_i * w_i \quad (2.12)$$

Bununla birlikte genellikle birçok uygulamada eşik değeri olan bir θ değeri toplama dahil edilmektedir (Eşitlik 2.13).

$$Toplam = \sum_i^n x_i * w_i + \theta \quad (2.13)$$

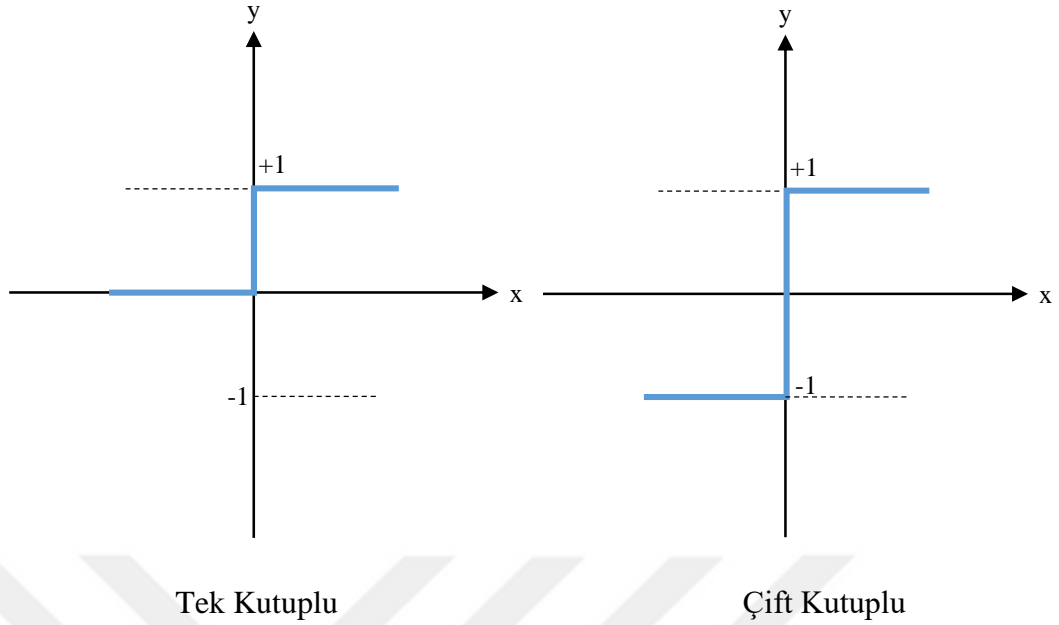
θ eşik değerinin girişlerden tamamen bağımsız bir değer olmasından dolayı bütün girişlerin sıfır olması halinde bile hücre çıkışının sıfır olma ihtimali ortadan kalkmaktadır.

Transfer Fonksiyonları

Transfer fonksiyonları, toplama işlevi ile belirlenen toplam hücre giriş değerini işleyerek hücre çıkışını belirleyen fonksiyonlardır. Hücre modellerinde, hücrenin gerçekleştireceği işleve bağlı olarak farklı şekillerde transfer fonksiyonları kullanılabilir. Bir ağdaki bütün hücrelerin transfer fonksiyonları aynı olabileceği gibi birbirinden farklı da olabilirler (Temür, 2013). Aşağıda yaygın olarak kullanılan transfer fonksiyonlardan bazıları açıklanmıştır.

Simetrik eşik transfer fonksiyonu: McCulloch-Pitts modeli ve perseptron olarak da bilinen eşik transfer fonksiyonlu hücreler, mantıksal çıkış verileri ve sınıflandırıcı ağlarda tercih edilirler. Bu hücrelerin matematiksel ifadesi eşitlik 2.14’teki denklemlerde verildiği gibidir. Tek kutuplu ve çift kutuplu olmak üzere iki farklı türü vardır (Şekil 2.11) (Dere, 2009).


$$y = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad y = \begin{cases} 1 & x \geq 0 \\ -1 & x < 0 \end{cases} \quad (2.14)$$



Şekil 2.11: Simetrik Eşik Transfer Fonksiyonları

Lineer Transfer Fonksiyonu: Bu transfer fonksiyonunda, toplayıcıdan gelen veriler bir α katsayısıyla çarpılmaktadır. $\alpha=1$ olması halinde fonksiyon girişi ve çıkışı birbirine eşittir (eşitlik 2.15, Şekil 2.12). Adaline olarak ta bilinen bu model, regresyon ve klasik işaret işleme regresyon analizlerinde sıklıkla kullanılmaktadır.

$$y = F(x) = \alpha * x, \alpha = 1 \quad (2.15)$$




Şekil 2.12: Lineer Transfer Fonksiyonu

Sigmoid Transfer Fonksiyonu: Şekil 2.13’de grafiksel olarak ve eşitlik 2.16’da formüsel olarak verilen transfer fonksiyonu YSA’larda en fazla kullanılan, doğrusal ve

doğrusal olmayan davranışlar arasında dengelemeyi gerçekleştiren sürekli artan bir fonksiyon olarak ifade edilir.


$$y = \frac{1}{1+e^{-x}} \quad (2.16)$$



Şekil 2.13: Sigmoid Transfer Fonksiyonu

Hiperbolik Tanjant Transfer Fonksiyonu: Eşitlik 2.17’de matematiksel gösterimi verilmiş olan transfer fonksiyonu, türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olmasından ötürü doğrusal olmayan problemlerin çözümünde kullanılan bir transfer fonksiyonudur (Şekil 2.14). Bu transfer fonksiyonunda giriş olarak $-\infty$ ile $+\infty$ arasında herhangi bir değer alır. Çıkış değeri ise, -1 ile $+1$ arasındadır. Literatürde çift kutuplu fonksiyon olarak da tanımlanmaktadır (Dere, 2009).

$$y = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.17)$$



Şekil 2.14: Hiperbolik Tanjant Transfer Fonksiyonu

Çıktı İşlevi

Çıktı $y=f(x)$, transfer fonksiyonunun elde etmesi ya da diğer sinir hücrelerine gönderilmesi istenen işlem çıktısı veya sonuç olarak tanımlanır. Ayrıca bir hücrenin çıktısı, kendine ve kendinden sonra gelen bir ya da daha fazla hücreye girdi olabilir.

2.5.2. Yapay Sinir Ağlarının Sınıflandırılması


YSA, mimari yapılarına, öğrenme zamanına, öğrenme metotlarına ve kullanım amaçlarına göre dört sınıfta incelenmektedir.

2.5.2.1. Mimarilerine Göre Yapay Sinir Ağları

YSA mimari yapılarındaki nöronların arasındaki bağlantı yönlerinin ileri ve geri beslemeli olması bakımından iki çeşittir:

2.5.2.1.1. İleri Beslemeli YSA

Hücrelerin katmanlar şeklinde düzenlendiği ve bir katmandaki hücrelerin çıkışlarının bir sonraki katmana ağırlıklar üzerinden giriş olarak verildiği YSA ileri beslemeli YSA'lar olarak adlandırılmaktadır. En genel halde üç katmanlı bir yapıya sahiptirler. Bu katmanlar ise; giriş katmanı, gizli (orta) katman ve çıkış katmanıdır. Giriş katmanı, dış ortamlardan alınan bilgilerin herhangi bir değişikliğe uğratılmaksızın olduğu gibi orta (gizli) katmandaki hücrelere iletiği katmandır. Orta ve çıkış katmanında bilginin işlenmesiyle ağ çıkışı belirlenir. En uç katmanın çıktı değerleri de ağın çıktısını belirler. Bu türdeki üç katmanlı ileri beslemeli YSA'ların basit yapısı şekil 2.15'de verildiği gibidir (Subaşı, 2010).

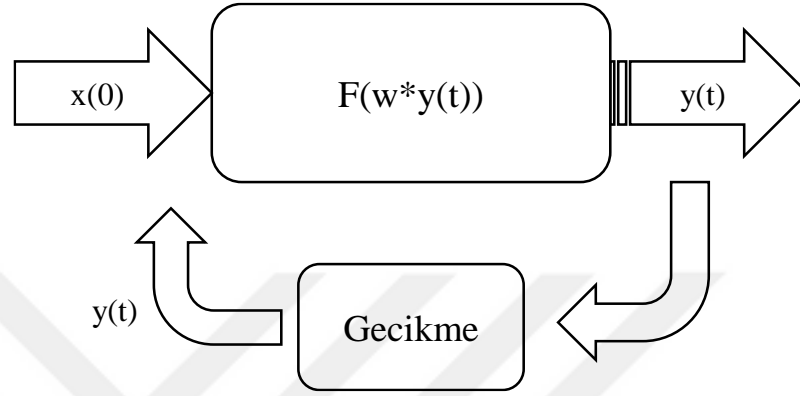


Şekil 2.15: İleri Beslemeli Yapay Sinir Ağlarının Basit Yapısı

2.5.2.1.2. Geri Beslemeli YSA

En az bir hücrenin çıktısının kendisi veya diğer hücrelere girdi olarak verildiği ağlardır. Geri besleme genellikle bir geciktirme elemanı üzerinden yapılır ve bir katmandaki

hücreler arasında olabileceği gibi katmanlar arasındaki hücreler arasında da olabilmesi mümkündür. Geri beslemeli YSA'lar bu yapıyla, doğrusal olmayan dinamik bir davranış gösterirler. Dolayısıyla, geri beslemenin yapılış biçimine bağlı olarak çeşitli davranışta ve yapıda geri beslemeli YSA yapıları elde edilebilir. Geri beslemeli YSA'ların basit yapısı Şekil 2.16'da görüldüğü gibidir (Subaşı, 2010).



Şekil 2.16: Geri Beslemeli Yapay Sinir Ağlarının Basit Yapısı

2.5.2.2. Öğrenme Zamanına Göre YSA

YSA'da öğrenme, çevrimiçi (on-line) ve çevrimdışı (off-line) olmak üzere iki farklı şekilde gerçekleşebilmektedir (Öztemel, 2012).

Çevrimiçi (On-line) Öğrenme: Bu kurala göre öğrenen YSA, gerçek zamanda çalışırken bir taraftan fonksiyonlarını yerine getirirler diğer taraftan ise öğrenmeye devam ederler. Kohonen öğrenme kuralı ve ART ağının öğrenme kuralı bu kategorideki öğrenme kurallarına örnek verilebilir.

Çevrimdışı (Off-line) Öğrenme: Bu kurala dayalı öğrenen sistemlerde, gerçek hayatta kullanıma alındıktan sonra öğrenme söz konusu olmadığından bu YSA kullanıma alınmadan önce örnekler üzerinde eğitilirler. Sistemin öğrenmesi gerekli yeni bilgiler söz konusu olduğunda sistem kullanımdan çıkarılarak çevrimdışı olarak yeniden eğitilir ve eğitim tamamlandıktan sonra tekrar kullanıma alınır. Delta öğrenme kuralı çevrimdışı öğrenmeye örnek gösterilebilir.

2.5.2.3. Öğrenme Metotlarına Göre YSA

YSA'nın verilen girişlere göre çıkış sağlayabilmesi ağın öğrenmesinin sonucudur. Öğrenme metotlarına göre YSA'lar, danışmanlı, danışmansız ve destekleyici öğrenme şeklinde üçe ayrılırlar.

2.5.2.3.1. Danışmanlı Öğrenme

YSA'ların öğrenmesinde kullanılan en yaygın yöntem danışmanlı öğrenme metodudur. Girdi ve çıktı arasındaki ilişkileri belirleyerek parametre değerlerinin ortaya çıkarılması öğrenen YSA'nın görevidir. Bu metot da, YSA'lardan sağlanan gerçek çıktı değeriyle elde edilmesi istenilen çıktı değerleri karşılaştırılmaktadır. İlk etapta rastgele belirlenen ağırlık değerleri ağın eğitimi başlamasının ardından yeniden düzenlenir. Bu şekilde bir sonraki döngüde istenilen çıktı değerleri ile gerçek çıktı değerleri birbirine daha yakın bir şekilde üretilir. Bu öğrenme yöntemi, işlem elementlerinin tümünün var olan hatalarının tamamını minimum yapmaya çalışarak gerçekleşir. Girdilerin ağırlık değerlerinin sürekli değiştirilerek öğrenmenin gerçekleştiği bir ağ performansına ulaşıncaya kadar hataların azaltılması işlemi devam eder.

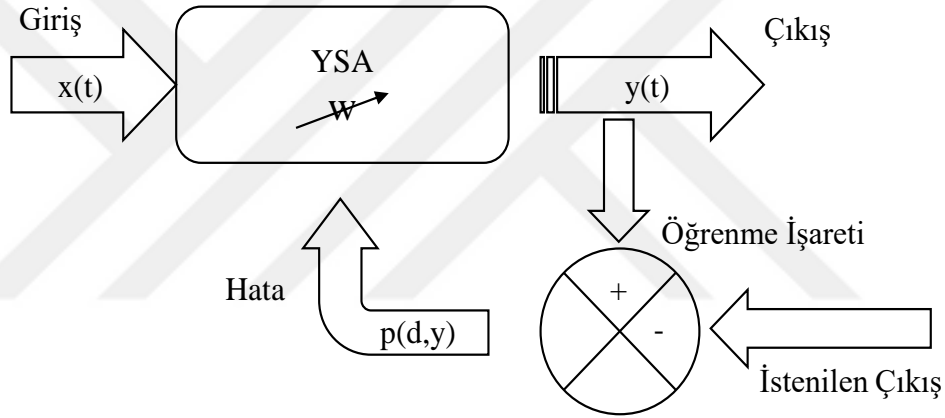
Ağın öğrenmesi girdi ve çıktı değerlerinin ağa sunulması sonucunda gerçekleşir. Bu veriler eğitim seti adıyla ifade edilir ve sisteme verilen her girdi karşılığında istenen çıktı değerleri de ağa sunulmaktadır. Öğrenme zamanı çok uzun sürebilir. Hatta sistemin işlem gücünün yetersiz olması halinde ağın öğrenmesi haftalarca bile devam edebilir. YSA'ların öğrenmesi, ağ kullanıcıları tarafından tanımlanan performans düzeyine ulaştığında sonlandırılır. Bu seviye, ağın verilen girdi değerleri karşılığında istenen istatistiksel kesinlikteki çıktı değerlerinin üretildiği nokta olarak adlandırılır. Daha ileri seviyede bir öğrenmeye ihtiyaç duyulmuyorsa elde edilen ağırlık değerleri uygulamalarda kullanılır. YSA'lardan bazıları çalışma esnasında da düşük hızlarda öğrenmeye devam etmektedir ve bu durum ağın ileri seviyelerdeki değişim koşullarına adapte olmasını sağlar. Ağdan önemli özellikleri ve ilişkileri öğrenmesinin istenmesi durumunda, girdi ve çıktıların ihtiyaç duyulan bütün bilgileri sağlayacak düzeyde büyük olması gereklidir (Anderson & McNeill, 1992).

Bir ağın başarılı bir şekilde öğrenmesi, girdi ve çıktı verilerinin ağa nasıl sunulduğuna bağlıdır. YSA'lar yalnızca sayısal girdi verileriyle çalışabilmektedir. Bu sebeple dış dünyadan alınan sembolik verilerin sayısal verilere çevrilmesi gereklidir. Ayrıca, bu

verilerin ölçeklendirilmesi ya da ağın algılayabileceği şekilde normalize edilmesi de sağlanmalıdır.

Öğrenen bir sinir ağına eğitim verileri üzerinde iyi bir performans göstermesinin ardından daha önce hiç görmediği verilerle ne yapacağını görmesi de çok önemlidir. Eğer bir sistem, test seti için mantıklı çıktılar veremiyorsa bu durum öğrenmenin tam olarak gerçekleşmemiş olduğunu gösterir.

Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart-McClelland tarafından geliştirilen genelleştirilmiş delta kuralı algoritmaları danışmanlı öğrenme algoritmalarına örnek verilebilir. Şekil 2.17’de danışmanlı öğrenme yapısına ait bir akış diyagramı verilmiştir.



Şekil 2.17: Danışmanlı Öğrenme Yapısı

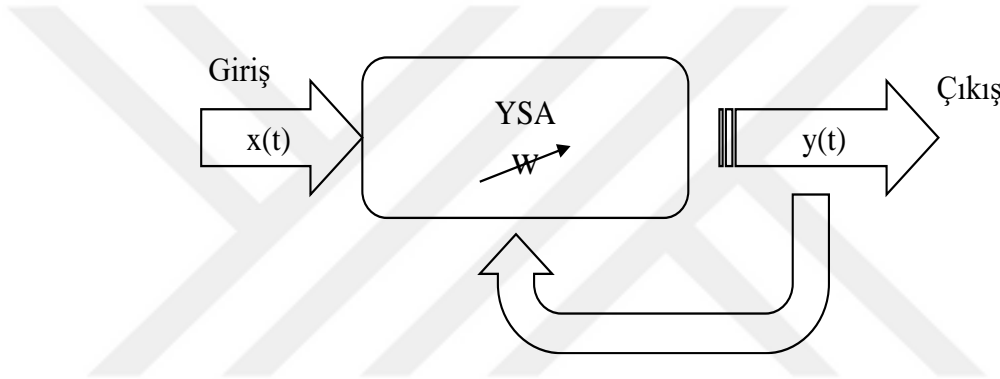
2.5.2.3.2. Danışmansız Öğrenme

Öğrenme sırasında ağı sadece örnek girdilerin verildiği ve beklenen çıktı değerinin verilmediği öğrenme yöntemidir. Danışmansız öğrenme yönteminde, girdiler aynı zamanda çıktı görevi de görmektedirler. Bu metot gözetimsiz öğrenme ya da kendi kendine öğrenme olarak da adlandırılabilir. YSA’da sürekli araştırılan ve geliştirilen bir metot olmasından dolayı gelecekte ümit verici gelişmeler sağlayacak bir yöntemdir. Bu sayede, bir gün bilgisayarlar kendi kendilerine öğrenebileceklerdir.

Danışmansız öğrenme metodu genellikle temel akademik çalışmalar için kullanılmakta olup, çok yaygın bir kullanım alanına sahip değildir. Özellikle, istatistiksel modelleme, kümeleme, filtreleme gibi problemlerde kullanılmaktadırlar. YSA sisteminin istenen

çıkış verileri olmaksızın sadece giriş verilerine göre eğitimini gerçekleştirmesi danışmanlı öğrenmeden farkını oluşturur.

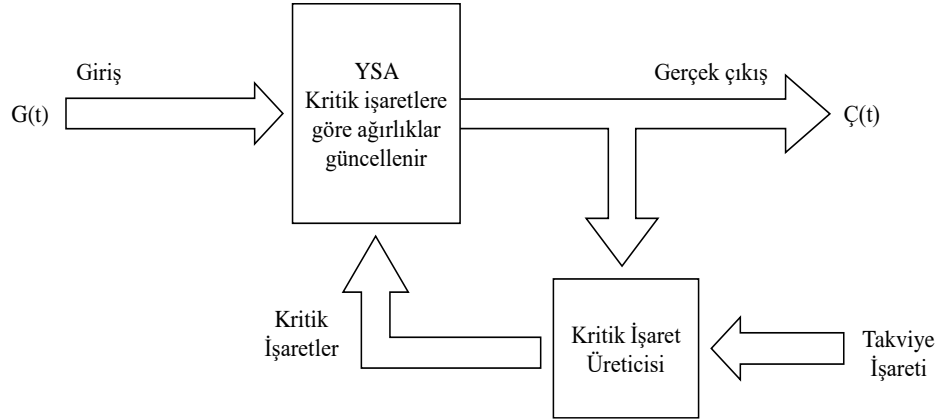
Günümüzde Şekil 2.18’de genel akış diyagramını verilen danışmansız öğrenme ile ilgili yapılan araştırmalar genellikle hükümetlerin ilgi duyduğu alanlardır. Askeri alanlardaki uygulamalar bunların en iyi örneğini oluşturur. Çünkü ağıın öğrenebilmesi için belirli bir veri setine ihtiyaç vardır. Ancak olumsuz durumlar her daim görülmemektedir. Örnek olarak verilen askeri uygulamalarda herhangi bir çatışma çıkıncaya kadar ağıın eğitilmesi için gerekli veri seti bulunmamaktadır. Bu nedenle veri setine ihtiyaç duymayan kendi kendine öğrenebilen ağlar hükümetlerce daha çok tercih edilmektedirler (Anderson & McNeill, 1992).



Şekil 2.18: Danışmansız Öğrenme Yapısı

2.5.2.3.3. (Aksoy, 1991)Destekleyici Öğrenme

Bu yöntemde, girdi-çıkı ilişkisi çevre ile iletişim sonucunda oluşturulmaktadır. Destekleyici öğrenme, YSA'nın genel öğrenme algoritmasının bir parçası olarak sıklıkla kullanılmakta olup, daha çok uzun dönemli başarılar için çevre koşullarında YSA'nın nasıl hareket etmesi gerektiği ile ilgilenir (Çakın, 2017). Danışmanlı öğrenmede, ağırlıkların ayarlanması için ağıın davranışının uygun olup olmadığını belirten bir öz yetenek bilgisine ihtiyaç duyulur. Gerçek zamanda öğrenme yöntemi olup deneme-yanılma esasına göre sinir ağı eğitilir. Bu yöntem genelde danışmanlı öğrenme yöntemine benzemektedir. Fakat ağa hedef çıktılar yerine ağıın çıktılarının ne ölçüde doğru olduğunu belirten bir derece verilir. Performans bilgisi genellikle iki sayıdır ve denetim hareketlerinin başarısını gösterir. Boltzman kuralı, destekleyici öğrenmeye örnek verilebilir. Şekil 2.19’da destekleyici öğrenme yapısı gösterilmektedir.



Şekil 2.19: Destekleyici Öğrenme Yapısı

2.5.2.4. Kullanım Amaçlarına Göre Yapay Sinir Ağları

Nöronlar, bağlantılar ve transfer fonksiyonları bütün yapay sinir ağı metotlarında bulunduğu için tüm metotlar arasında benzerlik bulunmaktadır. Metotlar arasındaki farklılık ise, metotların öğrenme kuralları ve bu kuralların ağın mimarisine nasıl adapte edilebileceğinden kaynaklanmaktadır. Hangi ağların hangi amaçlar için kullanılabileceği aşağıdaki Tablo 2.2’de yer almaktadır.

Tablo 2.2

Kullanım Amaçlarına Göre Yapay Snir Ağları

Kullanım Amacı	Ağ Yapısı
Tahmin	Gerri Yayılım Delta Bar Delta Geniştirilmiş Delta Bar Delta Yönlendirilmiş Rastgele Arama Yüksek Dereceli Sinir Ağları Kendi Kendini Organize Eden Haritalar
Sınıflandırma	Doğrusal Vektör Parçalama (LVQ) Karşı Yayılma Olasılıklı Sinir Ağları
Veri İlişkilendirme	Hopfield Boltzmann Makinesi Hamming Ağları Çift Yönlü İlişkisel Bellek Uzay-Zamansal Desen Tanıma
Veri Kavramsallaştırma	Adaptif Rezonans Ağı Kendi Kendini Organize Eden Haritalar
Veri Filtreleme	Yeniden Dolaşım (Recirculation)

Kaynak: (Anderson & McNeill, 1992: 31)

Yukarıdaki tabloda kullanım amacına göre en çok tercih edilen ağ yapıları örnek olarak verilmiştir. Herhangi bir ağın birden fazla problemin çözümü için uygun olabilmesi mümkündür. Örneğin, ileri beslemeli geri yayılım ağları hemen hemen tüm problemlerin çözümünde kullanılmaktadır (Anderson & McNeill, 1992).

2.5.3. Yapay Sinir Ağları Metoduyla Talep Tahmini

Öngörü veya tahmin gelecek hakkında yorum yapmaktır. Gelecek hakkında yorum yapılabilmesi için tarihi verilerden yararlanılması gerekmektedir. Tahmin modellerindeki temel varsayım, gelecek olayların geçmişteki olayları baz aldığı ve bu doğrultuda geçmişte yaşanan olaylardaki durumların gelecekte de devam edeceğinin kabul edilmesidir. Tahmin modellemesi ise, geçmişte yer alan durumun yakalanarak geleceğe uyarlanması ve bu doğrultuda geleceğin öngörülmesinin modellenmesidir (Yıldız, 2009: 28).

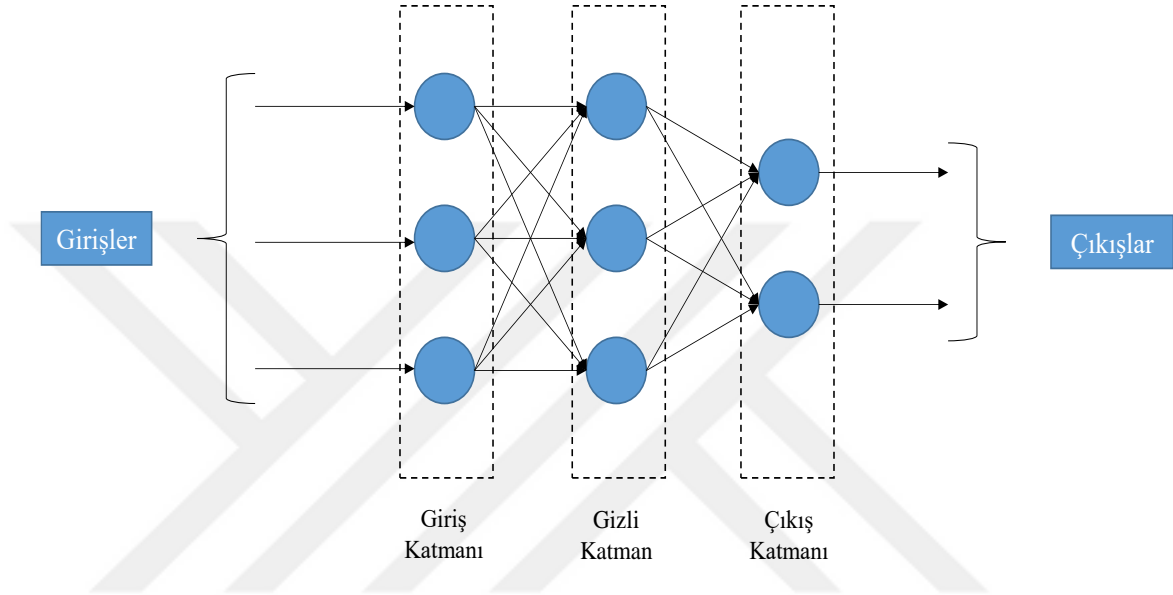
Klasik istatistiksel analizde, modeli oluşturan girdi ve çıktı arasındaki tam ilişki ve kullanılan teorinin kısıtları açıkça ifade edilmelidir. YSA ise, girdi ve çıktı değişkenleri arasında herhangi bir ön bilgiye ihtiyaç duyulmaksızın doğrusal ve doğrusal olmayan modellemeyi sağlayabilen bir yöntemdir. Bu nedenle tahmin aracı olarak YSA, diğer yöntemlere kıyasla daha esnek ve genel bir yapıya sahiptir (Zhang, Patuwo, & Hu, 1998). YSA'lar belirli bir model formunun açıkça belirtilmesine ihtiyaç duymazlar. Aksine, model verilerde sunulan özelliklere bağlı bir formda oluşturulabilir. Veriye dayalı bu yaklaşım, veri üretmek için teorik bir kılavuzun bulunmadığı birçok ampirik veri kümesi için elverişli bir modeldir.

YSA'lar, tahminleme konusunda diğer tahmin yöntemlerine göre bazı avantajlara sahiptir. Bu avantajlardan ilki, YSA'lardaki bilgilerin geleneksel programlamadaki gibi bir veri tabanında değil, ağın tamamında yayılarak saklanmasıdır. Bir ya da bir kaç bilginin kaybolmuş olması ağın çalışmasını engellemez. İkincisi, YSA'ların eğitilmesinden sonra verilerin eksik bilgi içermesi çıktı üretebilmelerini etkilemez. Üçüncüsü, YSA'ların bir ya da birden fazla hücrelerinin bozulması çıktı üretmesine engel teşkil etmez. Bu özellikleri ise, ağları hata toleransına sahip kılar. Dördüncü avantajı ise, YSA'nın olayları öğrenerek benzer olaylar karşısında yorum yaparak karar verebilme yeteneğine sahip olmalarıdır. Beşinci olarak, YSA'nın birden fazla işi aynı anda gerçekleştirebilecek sayısal güce sahip olduklarını söylemek mümkündür. Ayrıca, YSA

hem doğrusal verileri hem de doğrusal olmayan verileri modelleme yeteneğine sahiptir (Aymaz, 2015).

2.5.4. Yapay Sinir Ağlarının Çalışma Prensibi

YSA, deneme ve yanılma yöntemiyle işi nasıl yapması gerektiğini kendi kendine öğretir. Genel olarak bir YSA'nın çalışma prensibi Şekil 2.20'deki gibi gösterilebilir.



Şekil 2.20: Yapay Sinir Ağlarının Çalışma Prensibi

YSA'nın çalışma prensibini aşamalar halinde aşağıdaki gibi açıklayabiliriz.

- YSA'nın eğitilmesi ile ilgili ilk aşama; ağın öğrenmesi istenen olay ile ilgili daha önce gerçekleşmiş olan örneklerin toplanması işlemidir. Bu aşamada, hem ağın eğitimi (eğitim seti) için kullanılacak hem de test edilmesi (test seti) amacıyla kullanılacak örneklerin toplanması gereklidir. Genellikle eldeki verilerin %70 ya da %80'i ağın eğitilmesi için kullanılır, kalan %30 ya da %20'lik kısım ile ise ağın performansının ölçülmesinde kullanılır. Bu şekilde ağın iyi öğrenip öğrenmediği test edilmiş olur.
- Ağın topolojik yapısı belirlenir. Ağ ile ilgili girdi ünitesi sayısı, ara katman sayısı, her arar katman için gerekli olan proses elemanı sayısı ve çıktı elemanı sayısı bu aşamada belirlenir.
- Proses elemanlarının toplama ve aktivasyon fonksiyonları, öğrenme ve momentum katsayıları gibi parametreler belirlenir.

- Proses elemanlarını birbirine bağlayan ağırlık değerlerinin ve eşik değer ünitesinin başlangıç değerleri atanır. Genellikle, başlangıçta rastgele değer ataması yapılır. Daha sonra ise, ağ öğrenme sırasında uygun olan değerleri kendisi belirler.
- Ağın öğrenmeye başlayabilmesi ve öğrenme kurallarına uygun bir şekilde ağırlıkları değiştirebilmesi için öğrenme setinden örnekler seçilerek belirli bir düzene göre ağa örnekler gösterilir.
- Öğrenme sırasındaki ileri düzey hesaplamalar yapılabilmesi için verilen girdi değerleri için ağın çıktı değerleri hesaplanır.
- Ağın ürettiği hata değerlerini görmek için gerçekleşen çıktı ile beklenen çıktı karşılaştırılır.
- Üretilen hatayı azaltmak amacıyla geri hesaplama yöntemi uygulanarak ağırlıkların değiştirilmesi işlemi gerçekleştirilir.
- Gerçekleşen çıktılar ile beklenen çıktılar arasındaki hataların kabul edilebilir seviyeye inmesiyle öğrenme işlemi tamamlanır.

Eğitim ve test verisi miktarının ne kadar olması gerektiği, eğitim ve test setleriyle ilgili olarak karşılaşılan temel sorundur. Bazı durumlarda sınırsız sayıda veri bulunabilir. Bu gibi durumlarda, YSA mümkün olduğunca en fazla veri kullanılarak eğitilmelidir. Kullanılan eğitim verilerinin yeterli olup olmadığını ölçmek için eğitim setindeki veri miktarı artırıldığında ağın performansı üzerinde bir değişiklik oluşturup oluşturulmadığı takip edilebilir. Bu durumun mümkün olmadığı durumlarda ise YSA'nın eğitim ve test verileri üzerindeki performansın birbirine yakın olması verilerin yeterli olduğunun bir göstergesidir. Bununla beraber eğitim seti için gerekli olan veri miktarı farklı yapay sinir ağı metotlarına göre değişkenlik gösterebilmektedir.

Test seti için ise, eğitim setinde kullanılmayan veriler kullanılmaktadır. Test verilerinin ağa verilmesiyle elde edilen çıktılar ile istenilen çıktı değerleri karşılaştırılır. Temel amaç, elde edilen verilerin örneği temsil etme gücünün yeterli olup olmadığını kontrol etmektir. Eğitim ve test süreçlerinde istenen başarı düzeyinin yakalanması halinde ağ modeli kullanılabilir.

BÖLÜM 3: UYGULAMADA KULLANILAN YÖNTEMLER

Bu çalışmada, literatürde oldukça yaygın olarak ve birçok alanda kullanılan ARIMA, LSTM ve bu iki metodun birleşiminden oluşturulan Hibrit metot kullanılarak uygulamalar yürütülmüştür. Bu bölümde ise, çalışmanın uygulama kısmında kullanılan yöntemlere ilişkin açıklamalara değinilmiştir.

3.1. Otoregresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA) Modelleri

Zaman serisi tahminlerinde kullanılan istatistiksel yöntemlerin en popüler ve yaygın olanı Box-Jenkins yöntemidir. Ayrıca en kapsamlı olarak bilinen bu yöntem, 1970’de George Box ve Gwilym Jenkins tarafından geliştirilmiş olup, kısa dönem tahminlerinde gayet başarılı sonuçlar veren tek değişkenli bir model olarak da bilinmektedir. Yöntemin en önemli varsayımlarından biri, uygulanan serinin eşit zaman aralıkları ile elde edilen gözlem değerlerinden oluşan kesikli ve durağan bir seri olmasıdır. Serinin durağan olmaması halinde ise, öncelikle bunun belirlenmesi ve serinin durağan hale getirilmesi gereklidir. Durağanlık, serinin periyodik dalgalanmalardan arınmış olması anlamına gelir. Bu sebeple, yöntemin uygulanabilmesi için trend bileşeni ya da mevsimsellik içeren seriler öncelikle durağanlaştırılmalıdır (Bircan & Karagöz, 2003). Yöntemin amacı, en az sayıda parametre içeren uygun modellerin elde edilmesidir.

Hareketli ortalamalar ve üssel düzeltim yöntemlerinde tahmin değerleri bilgisayar programlarına müdahale edilmeden otomatik olarak tahmin edilirken, Box-Jenkins yöntemi tamamen otomatik değildir ve diğer yöntemlere kıyasla daha karmaşık işlemlerden sonra sonuca ulaşabilen, ara işlemlerde tahmincinin uzmanlığından ve sezgilerinden de yararlanan bir yöntemdir.

Box-Jenkins metodunun içerdiği modeller; zamana bağlı rastgele olaylar ve bu olaylar ile ilgili zaman serilerinin rastlantısal süreç olduğu varsayımına dayalı olarak geliştirilmiştir. Ayrıca iç bağımlılığın en etkili biçimde dikkate alınması da gereklidir. Tüm bu özelliklerinden ötürü Box-Jenkins modelleri doğrusal durağan stokastik (rastlantısal) modeller olarak da ifade edilebilmektedir.

Box-Jenkins yöntemi, incelenecek serilerin durağan olup olmamasına, mevsimsellik etki içerip içermemesine göre farklı türlerde tahmin modelleri geliştirmek için uygun bir

yapıya sahiptir. Bu yöntemde göre tahmin modelinin beş aşamadan geçirilerek kurulması gerekir. İlk olarak genel modele ait sınıf belirlenir. Bu işlemin ardından bu sınıf içinde zaman serisine uyan geçici model belirlenir. Genel model ve geçici model sınıfının belirlenmesinde eldeki zaman serisine ait otokovaryans ve otokorelasyonlardan yararlanılır. Daha sonra belirlenen geçici modele ilişkin parametre tahminleri yapılır. Son olarak bu geçici modelin eldeki verilere uygunluğu test edilir. Belirlenen modelin eldeki verilere uygun olduğuna kararı verilirse bu model tahmin amacıyla kullanılır. Ancak, seçilen model eldeki verilere göre uygun bulunmaz ise için yukarıdaki işlemler tekrarlanır (Montgomery, Jennings, & Kulahci, 2008). Bu yöntemde; otoregresyon (AR), hareketli ortalama (MA) ve bu iki modelin birleşiminden oluşan otoregresif hareketli ortalama (ARMA) modeli olmak üzere 3 tür modelleme vardır. Bu modellerde seri durağan değilse fark alma işlemi ile ARMA süreci birleştirilmiş otoregresif hareketli ortalama (ARIMA) sürecine dönüştürülür. ARIMA, bir değişkenin gelecek değerinin birkaç geçmiş değeri ile rastsal hatalarının doğrusal bir fonksiyonu olduğunu varsaymaktadır (Ateşoğlu, 2015).

3.1.1. Durağan ARIMA Modelleri

Bu tahmin yöntemleri; otoregresif (AR), hareketli ortalama (MA) ve otoregresif hareketli ortalama (ARMA) modelleridir.

3.1.1.1. Otoregresif Süreç (AR)

AR modelleri ile bir zaman serisine ait geçmiş belirli bir sayıdaki gözlem değerlerinin içerdiği bilgiye dayanarak gelecek değerleri hakkında ön raporlama yapılabilmesi mümkündür.

AR modeller içerdiği geçmiş döneme ilişkin gözlem değeri sayısına bağlı olarak adlandırılırlar. Bir adet geçmiş dönem gözlem değeri içerenler “birinci dereceden”, iki adet geçmiş dönem gözlem değeri içerenler “ikinci dereceden” ve genel olarak p adet geçmiş dönem gözlem değeri içerenler “p’inci dereceden” AR modeli olarak ifade edilirler (Thomas, Terry, & D.W., 1972). AR (p) modelinin genel ifadesi aşağıdaki gibidir:

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + a_t \quad (3.1)$$

$x_t, x_{t-1}, x_{t-2}, \dots, x_{t-p}$ gözlem değerleridir.

$\phi_1, \phi_2, \dots, \phi_p$ modele ait parametrelerdir. p modelin derecesini, a_t ise normal dağılmış hata değişkenini ifade etmektedir.

AR(p) modeli, aynı değişkenin belirli bir t dönemine ilişkin gözlem değeri ile ondan önceki dönemlere ait gözlem değerleri arasındaki ilişkiyi açıklamasından dolayı çoklu regresyon modelinden ayrılarak “otoregresif model” adını almaktadır. Yani çoklu regresyon modelindeki gibi bağımlı bir değişken ile bu değişkeni açıklayan bağımsız değişkenler arasındaki ilişkinin ortaya koyulduğu bir model değildir.

Uygulamada sıklıkla birinci ve ikinci dereceden AR modelleri kullanılmaktadır. Sırasıyla kısaca AR(1) ve AR(2) olarak gösterilirler.

AR(1) modelinde bir zaman serisinin t dönemine ait gözlem değeri x_t , $t - 1$ döneminin gözlem değeri x_{t-1} ve a_t hata terimiyle açıklanır.

$$x_t = \phi x_{t-1} + a_t \quad (3.2)$$

Benzer biçimde AR(2) modeli

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + a_t \quad (3.3)$$

denklemleriyle ifade edilir.

3.1.1.2. Hareketli Ortalama (MA) Modelleri

MA modeller, bir zaman serisinin herhangi bir dönemine ilişkin gözlem değerinin aynı dönemine ait hata terimi ve belli sayıdaki geçmiş dönemin hata terimlerinin doğrusal bir bileşimi olarak gösterildiği yöntemlerdir.

MA modelleri içerdikleri geçmiş döneme ilişkin hata terimi sayısına bağlı olarak; birinci dereceden, ikinci dereceden ve genel olarak q 'inci dereceden MA modelleri şeklinde isimlendirilirler.

MA(q) modeli genel olarak;

$$x_t = \theta_0 a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.4)$$

formülü ile gösterilebilir.

x_t , t'inci döneme ait gözlem değerini $\theta_0, \theta_1, \theta_2, \dots, \theta_p$ modelin parametrelerini ve q MA modelinin derecesini göstermektedir.

Uygulamada genellikle birinci ($q=1$ için) ve ikinci derece ($q=2$ için) MA modelleri kullanılmaktadır.

MA(1) modeli;

$$x_t = a_t - \theta_1 a_{t-1} \quad (3.5)$$

şeklinde yazılmaktadır.

Formülde de görüldüğü üzere x_t değişkeninin bugünkü değeri, bugünkü hata değeri (θ değeri) ile ifade edilen bir önceki gecikme değerinin (a_{t-1}) çarpımı ile elde edilen değerler arasındaki farka eşittir.

MA(2) modelinde x_t gözlem değeri $t, t-1, t-2$, dönemlerine ilişkin hata terimlerinin doğrusal bir bileşimi olarak ifade edilir. MA(2) modeli aşağıdaki gibi gösterilmektedir.

$$x_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} \quad (3.6)$$

3.1.1.3. Otoregresif Hareketli Ortalama (ARMA) Modelleri

AR ve MA modellerinin bir kombinasyonu olarak kullanılan ARMA modelleri durağan zaman serilerinin modellenmesi amacıyla kullanılır. Bu modellerde bir zaman serisinin herhangi bir dönemine ilişkin gözlem değeri, ondan önceki belli sayıda gözlem değerinin ve hata teriminin doğrusal bir bileşimi olarak ifade edilir. Eğer ARMA modeli p terimli AR ve q terimli MA modelinin bir bileşimi ise, $p+q$ terim içerir ve ARMA(p,q) şeklinde yazılır.

ARMA (p,q) modelinin fark denklemi genel gösterimi aşağıdaki gibidir: ($\theta_0 = 1$)

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + \theta_0 a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.7)$$

ya da

$$x_t - \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} = a_t - \theta_0 a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.8)$$

ARMA (p,q) modelinde hesaplanması gerekli parametre sayısı $p+q+2$ adettir. Bunlardan p tanesi ϕ (otoregresyon) parametresi, q tanesi θ (hareketli ortalama) parametresi, bir tanesi ortalama değeri μ ve bir tanesi ise δ_α^2 ' dir.

Uygulamada en fazla birinci dereceden ($p=1$) AR ve birinci dereceden ($q=1$) modelinin kombinasyonu olan ARMA model türü ARMA(1,1) modeli kullanılmaktadır. Bu model aşağıdaki denklem ile ifade edilir.

$$x_t - \phi_1 x_{t-1} = a_t - \theta_1 a_{t-1} \quad (3.9)$$

veya

$$x_t = \phi_1 x_{t-1} + a_t - \theta_1 a_{t-1} \quad (3.10)$$

3.1.2. Durağan Olmayan ARIMA Modelleri

ARIMA metodu sırasıyla tanısal denetim, özdeşleşme ve tahmin işlemi olmak üzere üç ana işlemden oluşur. Tanısal denetim olarak ifade edilen ilk aşamada, verilen zaman serisi verileri üzerinde durağanlık kontrolü yapılır. Durağan zaman serileri, ortalama, varyans ve kovaryans gibi istatistiksel özelliklerin zamana göre olduğu bir zaman serisidir. Tahmini kullanışlı ve oldukça pratik hale getiren ARIMA modeli oluşturulurken durağanlık şarttır. Verilen zaman serisinin durağan olmaması halinde ise, durağan hale dönüştürmek için uygun derecede fark (d) alma işlemi uygulanır ve durağanlığı tekrar sınanır. Durağan bir seri elde edene kadar bu işleme devam edilir. (d) pozitif bir tamsayıdır ve fark alma derecesinden sorumludur. Fark alma işlemi (d) kez gerçekleştirilirse, ARIMA modelinin entegrasyon parametresi (d) olarak ayarlanır. Daha sonra, elde edilen durağan veri üzerinde özdeşleşme işlemi gerçekleştirilir. Bu işlem ile otoregresif (AR) ve hareketli ortalama (MA) işlemlerinin parametreleri (sırasıyla (p) ve (q)) belirlenir. Bir ARIMA modeli, ARIMA (p, d, q) olarak tanımlanmıştır (Newbold, 1983).

p : Otoregresif modelin derecesi (AR)

d : Fark alma derecesi

q : Hareketli ortalama modelinin derecesi (MA)

∇ : Fark alma operatörü

w_t : Farkı alınmış seriyi ifade etmektedir.

$$x_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.11)$$

Burada, t zamanı için x_t doğrusallaştırılmış gerçek veriyi, a_t hareketli ortalamadaki hatayı ifade etmektedir. Formülde, tahmin edilecek gerçek veri x_t ile gözlemlenen (p) tane farkı alınmış veri ($w_{t-1}, w_{t-2}, \dots, w_{t-p}$), ve (q) tane hata verisi ($a_t, a_{t-1}, \dots, a_{t-q}$) arasında doğrusal bir ilişki kurulmuştur.

Mevsimsel dalgalanma göstermeyen serilerin geleceğe yönelik tahmininde kullanılmakta olan genel ARIMA (p,d,q) modelinde hesaplanması gerekli parametre sayısı ARMA (p,q)'daki kadardır.

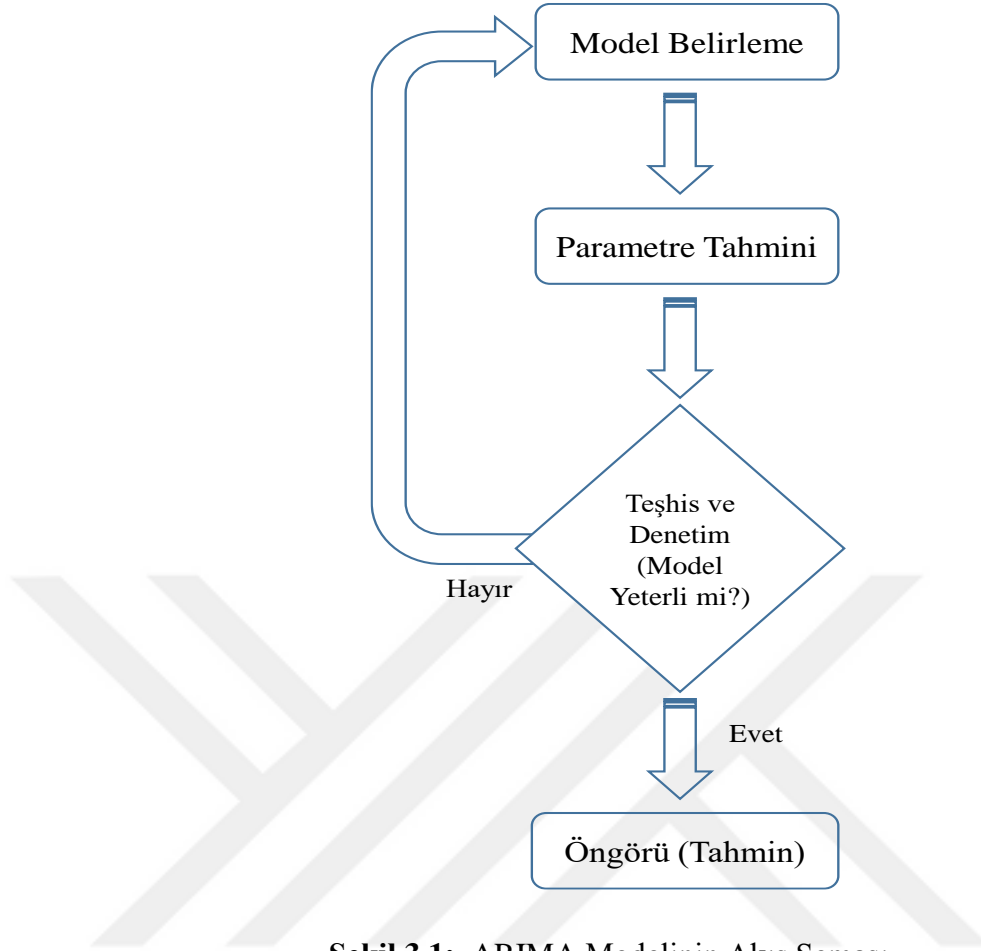
ARIMA (p,d,q) modelinde p veya q sıfır olabilir. Bu durumda model AR (d,p) veya MA (d,q) model türüne indirgenmiş olur.

Zaman serileri tahmininde birçok yöntem bulunmasına rağmen en çok ARIMA yöntemi kullanılmaktadır. Bu yöntemin durağan veya çeşitli istatistiksel tekniklerle durağanlaştırılan zaman serilerine kolaylıkla uygulanabilmesi mümkündür.

ARIMA modellemesi yapılmadan önce bir takım varsayımların gerçekleştirilmesi gereklidir. Bunlar;

- Veriler durağan olmalı,
- Verilerde eksiklik olmamalı,
- Veriler normal dağılım göstermeli,
- Verilerde hiçbir aykırı durum olmamalıdır.

ARIMA modelinin akış şeması aşağıdaki gibi gösterilebilir:



Şekil 3.1: ARIMA Modelinin Akış Şeması

Kaynak: (Lee & Ko, 2011)

3.1.3. Mevsimsel Modeller (SARIMA)

Aylık ya da üç aylık gibi belli zaman aralıklarına ilişkin gözlem değerlerinin oluşturduğu zaman serilerinin birbirini takip eden yılların aynı aylarında veya dönemlerinde maksimuma ve minimuma ulaşma eğilimi mevsim dalgalanmaların göstergesidir. Sosyal ve doğal etkenler sonucunda meydana gelen ve her yıl düzenli bir şekilde tekrarlanan dalgalanmaları içeren seriler “mevsimsel zaman serileri” olarak adlandırılır. Mevsimsel dalgalanmalara ait dalga uzunluğu s ile gösterilir ve aylık gözlem değerlerinin oluşturduğu genellikle $s=12$ 'dir. Fakat 6 aylık ($s=6$) periyoda sahip mevsimsel dalgalanmalar da olabilmektedir. Üç aylık aralıklar ile yapılan gözlem değerlerinin oluşturduğu serilerde ise, $s=4$ 'tür.

Mevsimsellik, zaman serilerinde durağanlığı bozan unsurlardan birisidir ve bu serilerde durağanlığın sağlanması için serinin mevsim etkisinden arındırılması gereklidir (Kendal, 1973: 506-507). Bu maksatla, gözlem değerlerinin s 'inci dereceden farkının alınması

gerekliliğinden dolayı mevsimsel serilerin modellenmesinde s'nin bilinmesi önem arz etmektedir.

Mevsimsel serilerin modellenmesi ARIMA yönteminden faydalanılarak yapılmaktadır. Yapılacak mevsimsel modelin hem mevsimlerin etkisiyle oluşan değişimleri hem de veri düzeyindeki değişimleri yansıtabilmesi gereklidir. Çünkü bir zaman serisi hem mevsimsel dalgalanmalar içerebilir hem de bir trende sahip olabilir. Bu özellikteki bir zaman serisinin gözlem değerleri arasında birbirini izleyen gözlem değerleri arasındaki ilişki ve mevsimsel ilişki (birbirini izleyen yılların aynı aylarına ait gözlem değerleri arasındaki ilişki) olmak üzere iki türlü ilişki vardır.

Genel mevsimsel modelin derecesi, mevsimsel ve mevsimsel olmayan modellerin derecelerinin çarpımıyla bulunur ve $(p,d,q) \times (P,D,Q)^s$ biçiminde gösterilmektedir. Burada (p,d,q) mevsimsel olmayan modelin derecesini, (P,D,Q) mevsimsel modelin derecesini, s ise mevsimsel dönemin uzunluğunu ifade etmektedir.

3.1.4. ARIMA Model Belirleme Süreci

Model belirleme, ARIMA sürecinde en uygun p,d,q yapısının belirlenmesini kapsamaktadır. Bu aşama, serilerin durağan olup olmadığı ve serilerin durağan olması halinde hangi otoregresif süreç (AR(p)) ve hareketli ortalama süreci (MA(q)) modellerinden nasıl bir karışım olacağını tespit edilmesi aşamasıdır (Torun, 2015). Model belirleme sürecinde, öncelikle seriye ait durağanlık ve mevsimsellik analizi uygulanarak serilerin durağan olup olmadığı tespit edilir. Eğer seriler durağan değil ise, d'inci dereceden fark alma işlemi uygulanarak seri durağan hale getirilir. Fark alma derecesini gösteren d; durağan serilerde 0, birinci dereceden fark alma işlemiyle durağan hale gelen serilerde 1, ikinci derece fark alma işlemi ile durağanlık sağlanan serilerde ise 2 değerini alır. Uygulamada genellikle d'nin değeri 1 ya da 2 olarak alınmaktadır. Ancak, serilerin durağan olması halinde seriye herhangi bir fark alma işleminin uygulanmasına gerek yoktur. Bu durumda, en uygun ARIMA modelini tanımlamak için otokorelasyon (ACF), kısmi otokorelasyon (PACF) ve ters otokorelasyon (IACF) fonksiyonlarının dikkate alınmasıyla en uygun p,d,q parametrelerinin anlamlılığı kontrol edilmelidir.

AR modelinin derecesinin belirlenmesi için kısmi otokorelasyon değerlerinin sıfırdan farklı ilk p sayısına bakılır. Örneğin, birinci kısmi otokorelasyon değeri sıfırdan farklı diğer gecikmeler için sıfır değerini alıyorsa AR modelinin p değeri "1", ilk iki kısmi

otokorelasyon değeri sıfırdan farklı diğer gecikmeler sıfır değerini alıyorsa AR modelinin derecesi “2” değerini alacaktır.

MA modelinin derecesi için, otokorelasyon değerinin sıfırdan farklı ilk q sayısına bakılmaktadır. Örneğin, birinci otokorelasyon değeri sıfırdan farklı diğer gecikmeler için sıfır değerini alıyor ise MA modelinin q derecesi “1” değerini, ilk iki otokorelasyon sıfırdan farklı diğer gecikmeler sıfır değerini alıyorsa MA modelinin derecesi “2” değerini alacaktır.

ARMA modelinin derecesinin belirlenmesi ise, AR ve MA kısımları için ayrı ayrı yapılmaktadır. AR kısmının derecesi istatistiksel olarak sıfırdan farklı kısmi otokorelasyon sayısına, MA kısmının ise istatistiksel olarak sıfırdan farklı otokorelasyon sayısına bakılarak belirlenir (Çağıl, 1997).

ARIMA modelinde p,d,q değerleri belirlendikten sonra geçici parametre değerleri tahmin edilir. AR (p), MA (q) ve ARMA (p,q) modellerinde en uygun model tipi aşağıdaki kriterlere göre seçilmektedir.

Tablo 3.1

AR, MA ve ARMA Modellerinde ACF ve PACF'nin Teorik Davranış Biçimleri

Model	Otokorelasyon Fonksiyonu (ACF)	Kısmi Otokorelasyon Fonksiyonu (PACF)
AR (p)	Üssel ve/veya sinüs dalgası şeklinde azalır.	p gecikmesinden sonra istatistiksel olarak anlamlı değildir.
MA (q)	q gecikmesinden sonra istatistiksel olarak anlamlı değildir.	Üssel ve/veya sinüs dalgası şeklinde azalır.
ARMA (p,q)	p-q adet gecikmeden sonra üssel ve/veya sinüs dalgası şeklinde azalır.	p-q adet gecikmeden sonra üssel ve/veya sinüs dalgası şeklinde azalır.

Kaynak: (Gujarati, 2008).

3.1.5. Model Belirleme Kriterleri

ARIMA yönteminde en uygun (p,d,q) yapısının seçilmesi işlemi model belirleme olarak ifade edilmektedir (Andersan, 2003). Bazı durumlarda seriye uygun birden fazla model

olabilmektedir. Bu durumda, bu modellerden seriye en uygun olan modelin seçimi için bir takım kriterler geliştirilmiştir (Kadılar, 2005). Bunlardan bazıları aşağıdaki gibi açıklanabilir.

3.1.5.1. Belirlilik Katsayısı (R^2) Kriteri

R^2 , ARIMA modelleri arasında seçim yaparken yaygın olarak kullanılan kriterlerden birisidir ve 0 ile 1 aralığında değerler almaktadır. 1'e yaklaşması en iyi açıklanabilirliği veren istatistiki değerini elde edildiğinin göstergesidir. Durağan bir ARMA modelinde;

$$R^2 = 1 - \frac{Var(\varepsilon_t)}{Var(Y_t)} \quad (3.12)$$

şeklinde hesaplanmaktadır. $Var(\varepsilon_t)$ modelden elde edilen hata terimlerinin varyansını, $Var(Y_t)$ ise serinin varyansını göstermektedir.

Modele eklenen parametre sayısındaki artış R^2 değerini artırmaktadır. Bu sorunu gidermek amacıyla düzeltilmiş R^2 (\bar{R}^2) değerinin kullanılması önerilmiştir. \bar{R}^2 uygun model için kullanılan parametre sayısını hesaba katmaktadır. Birden fazla model arasında seçim yapılırken \bar{R}^2 değeri yüksek olan model seçilir (Tsay, 2005).

3.1.5.2. En Küçük Kareler Yöntemi (EKK)

Birden çok verinin doğru bir şekilde ifade edilmesi için kullanılmaktadır. Regresyon çözümlemesinde en sık kullanılan yöntem olup, bazı varsayımlara dayalı istatistiki özelliklere sahiptir. Uygunluk kriteri, veri noktaları ile eğrinin bağımlı değişkenlerinin aralarındaki farklarının karelerinin toplamının minimum olmasıdır. Burada karenin alınmasının sebebi, toplam alınırken artı ve eksilerinin birbirini götürmesini engellemektir. EKK yöntemindeki amaç, hata terimlerini (gözlemlenen ve tahmin edilen Y değerleri arasındaki fark) olabildiğince düşük verecek katsayı tahmin değerlerini bulmaktır.

Basit doğrusal regresyon modeli;

$$Y_i = \beta_0 + \beta_1 X_i ; (i=1, \dots, k) \quad (3.13)$$

Denklemden; “ Y_i ” bağımlı değişkenin i.gözlem değerini, “ X_i ” bağımsız değişkenin i.gözlem değerini, “ β_0 ” regresyon doğrusunun Y ekseninin kestiği noktanın orijine olan uzaklığını göstermektedir. “ β_1 ” ise, regresyon katsayısını belirtmekte olup, bağımsız

değişkende meydana gelen bir birimlik değişim karşılığında bağımlı değişkenin kendi birimi cinsinden ortaya çıkan değişim miktarı ortalamasını ifade etmektedir.

EKK yönteminin temel varsayımları, gerçek regresyon modeli ve veri üretme süreci ile ilgili ideal durumu açıklamaktadır. EKK'nin iyi bir tahmin olabilmesi için bu varsayımların sağlanması gereklidir. Ancak çoğu veri seti bu ideal koşulları sağlamaz.

3.1.5.3. F İstatistiği Yaklaşımı

Zaman serisine ilişkin model seçiminde, uygulama kolaylığı ve basitliği sağlamasından dolayı F istatistiği yaklaşımı sıklıkla kullanılmaktadır. Herhangi bir otoregresif sürecin hangi dereceden olduğu tam olarak bilinmiyorsa F-testi kullanılır (Göktaş, 2005).

$$F = \sigma_1^2 / \sigma_2^2 \quad (3.14)$$

Burada σ =Varyans olarak ifade edilir.

3.1.5.4. Akaike Bilgi Kriteri (AIC: Akaike Information Criterion)

AIC, modeller arasından en uygun olanı seçmek için kullanılmaktadır. Ayrıca, ARIMA modelleri arasından en uygun model derecesini tanımlamak amacıyla da kullanılır. AIC, modele eklenen değişkenlerin oluşturduğu artışa sınırlama getirerek düzenlenmiştir.

$$AIC = -2 \log(L) + 2k \quad (3.15)$$

Denklemden; “k” sabit terim dahil parametre sayısını, “n” gözlem sayısını, “L” ise benzerliği (likelihood) vermektedir.

Model karşılaştırmalarında daima en küçük AIC değerinin veren model, en uygun model ya da p ve q değerleri olarak tercih edilir. AIC seçili örnek büyüklüğü içindeki gelecek tahminiyle birlikte seçili örnek büyüklüğü dışındaki gelecek tahmini içinde geçerlidir (Zucchini, 2000).

3.1.5.5. Son Kestirim Hatası (FPE: Final Prediction Error)

FPE kriteri, AR modellerin derecesinin test edilmesi amacıyla önerilmiştir. Bir adım ileri tahmin için tahmin edilmiş en küçük ortalama hata karesine sahip AR modelinin gecikme sayısı seçilmektedir.

AR modellerinde gecikme sayısının belirlenmesi amacıyla ilk tanımlama Akaike tarafından 1969'da yapılmıştır. Bu yöntem, gelecek gözlemleri tahmin etmek amacıyla geçmiş gözlemlerin doğrusal kombinasyonunu kullanmaktadır. t zamanı için Z_t, Z_{t-1}, Z_{t-2} gözlemleri verilmiş ve gelecek Z_{t+1} gözlemi tahmin edilmek isteniyorsa, en iyi bir adım öte tahmin ya da son tahmin $\hat{Z}_t(1)$, geçmiş gözlemlerin lineer kombinasyonları olarak;

$$Z_t(1) = -\phi_1 Z_t - \dots - \phi_p Z_{t-p} \quad (3.16)$$

şeklinde ifade edilmektedir. Bu eşitlik, son tahmin hatası $\varepsilon_t(1)$ 'in kare ortalamasını minimize ettiği için en iyi doğrusal kombinasyondur. Ortalama hata karesi ise matematiksel olarak aşağıdaki gibi gösterilebilir;

$$E[\varepsilon_t(1)]^2 = E[Z_{t-1} - \hat{Z}_t(1)]^2 = \sigma_t^2 \quad (3.17)$$

Bu sebeple, son tahmin ortalama hata karesi artık varyans olarak da değerlendirilebilir. Bir adım ileri tahmin hatası, yalnızca katsayıların kesin olarak bilinmesi halinde kullanılabilir. Katsayılar yerine en küçük kareler tahminlerinin kullanılması halinde, tahmin edilmiş tek adım tahminin ortalama hata karesi σ_ε^2 şeklinde gösterilir (Parkhurst, 1992). Akaike, bu hata karesi tahminini, artıkların en çok olabilirlik tahminini kullanarak aşağıdaki gibi ifade etmiştir (Akaike, 1969);

$$FPE(j) = \frac{n+k}{n-k} \sigma_\varepsilon^2 \quad (3.18)$$

“n”, uydurulan model için gözlem sayısıdır.

$$\hat{\sigma}_\varepsilon^2 = \hat{p}_0 + \hat{\phi}_1 \hat{p}_1 + \dots + \hat{\phi}_p \hat{p}_p \quad (3.19)$$

En uygun model, en küçük FPE değerine sahip olan modeldir. Bu yöntem, uygulamada sıklıkla kullanılan bir yöntem değildir.

3.1.5.6. Bayes Bilgi Kriteri (BIC: Bayes Information Criterion)

Akaike (1978) ve Schwarz (1978) Bayes perspektifinden birbirine yakın tutarlı iki model seçim kriteri tasarlamışlardır. Schwarz Koopman-Dormois türünde modeller için SIC kriterini türetirken, Akaike doğrusal regresyonda seçilmiş model problemleri için BIC model seçim kriterini türetmiştir (McQuarrie & Tsai, 1998).

$$BIC = -2 \log(L) + k \log(n) \quad (3.20)$$

BIC'in AIC'den farklılık gösterdiği nokta; eşitliğin sağ tarafındaki örnek büyüklüğüne bağlı olan ikinci kısım itibariyledir. Literatürdeki çalışmalara bakıldığında; BIC bayes faktöründen daha fazla kullanılmaktadır. Bunun sebeplerinde biri ise, analiz sonrasında büyük hesaplamalara ihtiyaç duyulmasıdır (Zucchini, 2000).

3.1.5.7. Schwarz Bilgi Kriteri (SIC: Schwarz Informaiton Criterion)

SIC kriteri, AIC'ye benzemektedir. Matematiksel ifadesi aşağıdaki gibidir;

$$SIC = n^{k/n} \frac{\sum \hat{u}^2}{n} = n^{k/n} RSS/n \quad (3.21)$$

veya logaritmik form ile;

$$\ln SIC = (k/n) \ln n + \ln(RSS/n) \quad (3.22)$$

Formülde, k tahmin edilen parametre sayısını, n gözlem sayısını, $[(k/n) \ln n]$ sınırlama faktörünü, RSS ise modelden elde edilen artıkların karelerinin toplamını ifade etmektedir.

SIC, AIC'ye göre yeni değişkenlerin modele eklenmesi halinde ortaya çıkacak durumu değerlendirme konusunda geliştirilmiştir. SIC değeri her daim AIC'den daha düşük çıkmaktadır ve sadece seçili örnek büyüklüğü için değil, seçili örnek büyüklüğü haricindeki gelecek tahmini için de geçerlidir (Chen & Szroeter, 2016). Birden çok ARMA modeli arasında seçim yapılması gerektiğinde; en iyi modelin SIC değeri en küçük olan model olduğu belirtilmektedir.

3.1.5.8. Hannan Bilgi Kriteri (HQC: Hannan Quinn Kriteri)

AIC ve BIC kriterlerine alternatif olarak geliştirilmiştir (Chen & Szroeter, 2016). Durağan süreçler için ceza terimi, örnek büyüklüğünün artışına bağlı olarak sonsuza yaklaşma eğilimi göstermektedir. Hannan ve Quinn ceza terimini, tekrarlı bir logaritmaya başvurarak düzeltilmiş ve yeni bir model seçim kriteri geliştirmiştir. Bu kriter, otoregresif model için tutarlı bir tahmin edici sağlamaktadır. HQC model seçim kriteri, ceza faktörünün büyüme hızının azalmasından dolayı tutarlı bir derece seçimi için uygundur (Beran, Bhansali, & Ocker, 1998). Bu kriterin matematiksel gösterimi aşağıdaki gibidir;

$$HQC = -2h + 2k \cdot \log(\log(n)) \quad (3.23)$$

Formülde; “n” örnek çapını, “k” ise modele ait parametre sayısını göstermektedir.

3.1.5.9. Durbin-Watson Testi

Durbin-Watson testi, bir regresyonun modelinin tahmin edilmesinin ardından artık terimlerin korelasyon halinde olup olmadığını belirlemeye yarayan bir sayıdır. Otokorelasyonun belirlenmesinde kullanılan ve en çok bilinen testlerden biri olup, bu sayının 2’ye yakın çıkması “otokorelasyon vardır” boş hipotezinin reddedilemeyeceğinin bir göstergesidir. Bu test, yalnızca birinci derecedeki otokorelasyonun olup olmadığını sınamaktadır (Montgomery, Peck, & Vining, 2013).

$$d = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2} \quad (3.24)$$

d, 0 ile 4 arasında değerler almaktadır ($0 < d < 4$).

3.2. Tekrarlayan Sinir Ağları (Recurrent Neural Network-RNN)


3.2.1. RNN Hakkında Temel Bilgiler

YSA’nın yükselişi 1940’lardan sonra sınıflandırmadaki temel uygulamalar ile birlikte başlamıştır. Sinir ağlarındaki sürekli gelişim, bellekte yönlendirilmiş döngüleri içeren tekrarlayan sinir ağları (RNN) gibi daha ileri yapay sinir ağı yapılarına yol açmıştır. RNN’ler geri bildirim ağları olarak da adlandırılmaktadırlar. RNN’ler çok güçlü bir ağ türü olmakla birlikte karmaşık bir yapıya sahiptirler. RNN’i durumun belirli bir noktaya gelinceye kadar sürekli değiştiği dinamik bir ağ türü olarak ifade etmek de mümkündür (Patro, Sahoo, Panda, & Sahu, 2015). İleri beslemeli sinir ağlarından farkları, RNN’lerin kendi giriş belleklerini girdileri işlemek için kullanabilme özellikleridir.

İleri beslemeli YSA’lar, giriş değişkenlerinin çıktı üzerinde etkili olduğunun bilindiği fonksiyonel görüntüleme problemleri için uygulanırlar. Bu sebeple, görüntü tanıma problemlerinde yaygın olarak kullanılırlar. Diğer taraftan, geri beslemeli sinir ağları ya da RNN’ler ağda döngüler oluşturmak için sinyallerin her iki yönde de akmasına izin vermektedir. Sonuçların ağa gönderilen daha önceki girdilere dayanmasından dolayı hesaplamaları karmaşıktır. Ancak, RNN’lerde tüm girdilerin geçmişi hakkında bir hafıza tutulur ve aktivasyonların bir döngü içerisinde akabileceği şekilde ağ en az bir geri besleme bağlantısı içermektedir. Bu döngü ile dinamik zamansal davranış sergilemesine imkan sağlayan bir ağ iç durumu oluşturulmuştur. RNN’ler, ileri beslemeli sinir ağlarının

tersine kendi giriş belleğini girdilerin rastgele dizilerini işlemek amacıyla kullanılabilirler (Mkolov, Karafiat, Lukas, Cernocky, & Khundapur, 2010).

RNN'lerin zaman serisi tahminlerinde tercih edilmesinin en önemli sebeplerinden biri, diğer ağlardaki kısıtlayıcı ve sabit boyutlu girişleri kabul etme özelliğidir. Bu duruma paralel olarak sabit uzunlukta çıktılar üretirler. Buna ilaveten, bu modeller öğrenme sürecinde sabit hesaplama adımları kullanarak işlem yaparlar. RNN, vektör dizileri üzerinde çalışılmasına da izin verir. Giriş ve çıkışlar diziler halinde olabilir (Karpathy, 2015). Aşağıda, RNN'in basit yapısı görülmektedir.




Şekil 3.2: Basit RNN Mimarisi

Kaynak: (Olah, Colah's Blog, 2019)

Burada “A” sinir ağı yığını, “ x_t ” giriş değerini ve “ h_t ” çıkış değerini vermektedir. Şekil 3.2’de görüldüğü gibi tekrarlayan sinir ağlarında bulunan döngüler sayesinde bir adımdan diğer sinir ağına bilgi gitmesine izin verilmektedir. Bu döngü ile önceki zamana ait bilgilerin kullanılabilmesinden dolayı yeni bilgi, eski bilginin kullanılmasıyla anlamlandırılabilir ve bu sayede sınıflandırma yapılabilir.


Bu döngüler, RNN’lerin gizemli görünmesini sağlamasına rağmen, biraz daha fazla düşünüldüğünde bunların normal bir sinir ağından tamamen farklı olmadıkları görülmektedir. RNN yapısı açıldığında aşağıdaki gibi bir mimari ortaya çıkmaktadır. Zaman dilimi içinde, aynı hücre birden fazla kez kendini tekrar etmektedir. Bu şekilde kareler arasında anlamlandırma da kurulabilmektedir.



Şekil 3.3: Katmanları Açık Hale Getirilmiş RNN Mimarisi

Kaynak: (Olah, Colah's Blog, 2019)

Standart RNN'ler Şekil 3.4'de gösterildiği gibi tekrarlayan kısımda tek bir tanjant katmanının bulunduğu oldukça basit bir yapıdadır.



Şekil 3.4: Standart RNN'deki Yinelenen Tek Katman

Kaynak: (Olah, Colah's Blog, 2019)

RNN'ler bir döngü oluşturabilmelerinden dolayı sıralı olarak gelişen olayları birbirleri ile anlamlandırabilmektedirler. Bu avantajından dolayı son yıllarda özellikle; dil modelleme, çeviri, resim başlığı oluşturma, konuşma tanıma gibi birçok alanda yaygın olarak kullanılmaktadırlar. Tipik bir RNN yapısının avantajları ve dezavantajları aşağıdaki tablodaki gibi özetlenebilir.

Tablo 3.2
RNN'in Avantaj ve Dezavantajları

Avantajları	Dezavantajları
<ul style="list-style-type: none">✓ Herhangi bir girdiyi işleme yeteneği,✓ Girdi büyüklüğüne bağlı olarak artmayan model boyutu,✓ Geçmiş bilgileri dikkate alınarak hesaplama yeteneği,✓ Zaman içinde paylaşılan ağırlıklar	<ul style="list-style-type: none">✓ Hesaplama yavaşlık,✓ Uzun vade önceki bilgilere ulaşma zorluğu,✓ Mevcut durum için gelecekteki herhangi bir girdinin düşünülmemesi,


RNN'ler, geçmiş ile bağlantı kurulup anlamlandırma özelliklerinden dolayı bazı problemlerde başarılı sonuçlar vermesine rağmen, hangi aktivitelerin hatırlanacağı, ne kadar süre ile hatırlanacağı gibi bazı durumlar bilinmemektedir. Bütün bilgiler model içinde tutulmaktadır. Aktiviteler için bazı bilgiler önemli iken, bazı bilgiler gereksiz olabilmektedir. Bu sebeple, tüm geçmişin saklanmasına gerek yoktur. Sınıflandırma aşamasında, ihtiyaç duyulan bilgi çok önceden oluşmuş ise bu bilgiye ulaşamayabilir. Bundan dolayı, RNN'ler çok önceki olayları tahmin edebilmek için farklı bir mimari yapıya ihtiyaç duyarlar. Bu tür problemlerde daha iyi çalışan, RNN'in özel bir türü olan ve uzun vadeli bağımlılıkları öğrenebilen Uzun Kısa Vadeli Bellek (LSTM) ağırları kullanılmaktadır (Olah, 2015).

Buna ek olarak; teoride RNN'ler iç mimarilerinde kendilerini tekrarlama özelliğine sahip olmalarından dolayı uzun geçmişteki aktiviteleri hatırlama kapasitesine sahiptir. Ancak, bu parametrelerin hatırlanabilmesi için titizlikle seçilmeleri gereklidir. Pratikte böyle bir parametre seçimi mümkün olmadığından RNN'ler uzak geçmişi hatırlayamazlar (öğrenemezler) (Bengio, Simard, & Franscon, 2015). LSTM ağırlarında ise, bu tür bir sorun bulunmamaktadır. RNN'den farklı olarak eğitim esnasında oluşabilecek olan "vanishing gradient" problemi LSTM ile çözülebilir. Bu nedenle, birçok aktivite sınıflandırmasında genellikle LSTM'ler tercih edilmektedir. Son yıllarda RNN'ler ile yapılmış olan başarılı çalışmaların büyük çoğunluğunda LSTM'lerin kullanılması da bu durumun bir göstergesidir.

3.2.2. Uzun Kısa Süreli Bellek Ağları (LSTM)

Uzun kısa süreli bellek ağları, RNN'in uzun vadeli bağımlılıkları öğrenebilen özel bir çeşididir. Genellikle LSTM olarak kısaltılmaktadırlar. İlk olarak, 1997'de Hochreiter ve

Schmidhuber tarafından tanıtılmıştır (Hochreiter & Schmidhuber, 1997). Tanıtılan ilk LSTM mimarisi aşağıda gösterilmektedir.




Şekil 3.5: LSTM'in 1997'deki İlk Mimarisi

Kaynak: (Gao, 2016)

LSTM daha sonraki çalışmalarda ise, birçok kişi tarafından rafine edilmiş ve yaygınlaştırılmıştır. Birçok farklı problemde muazzam bir şekilde çalışmaktadır ve günümüzde de yaygın olarak kullanılmaktadırlar.


LSTM'ler, uzun vadeli bağımlılık probleminden kaçınmak için tasarlanmışlardır ve RNN'ler gibi sıralı zaman serisi verilerini işlerken farklı zamanlardaki verilerden de yararlanırlar. LSTM'nin RNN'den farkı, içerdiği LSTM düğümlerinin farklı bir yapıdan oluşmasıdır. LSTM yapısında, RNN hücresine bir de hafıza eşlik etmektedir. Bu hafıza sayesinde, bir önceki zamandan gelen bilgi alınıp bir sonrakine iletilebilir. Model, hangi bilgiyi alıp almayacağına eğitim ile karar verir. Bilgiyi uzun süreler boyunca hatırlamak bu ağların öğrenmeye çalıştıkları bir şey olmayıp pratikte varsayılan davranışlarıdır. LSTM'ler de RNN'ler gibi zincir benzeri bir yapıya sahiptirler. Ayrıca, LSTM'lerde tek bir sinir katmanı yerine birbirleriyle çok özel bir şekilde etkileşime giren dört katman bulunmaktadır. Bu katmanlar Şekil 3.6'da gösterildiği gibidir.



Şekil 3.8: LSTM'in Kilit Noktası Hücrenin Durumu

Kaynak: (Olah, Colah's Blog, 2019)

LSTM'ler, kapılar (gate) adı verilen yapılar tarafından dikkatlice düzenlenen hücre durumuna bilgi ekleme veya çıkarma kabiliyetine sahiptir. Bu kapılar, isteğe bağlı olarak bilgiyi iletmenin bir yoludur. Bunlar, sigmoid sinir ağı katmanı ve noktasal çarpım işleminden oluşmaktadır.



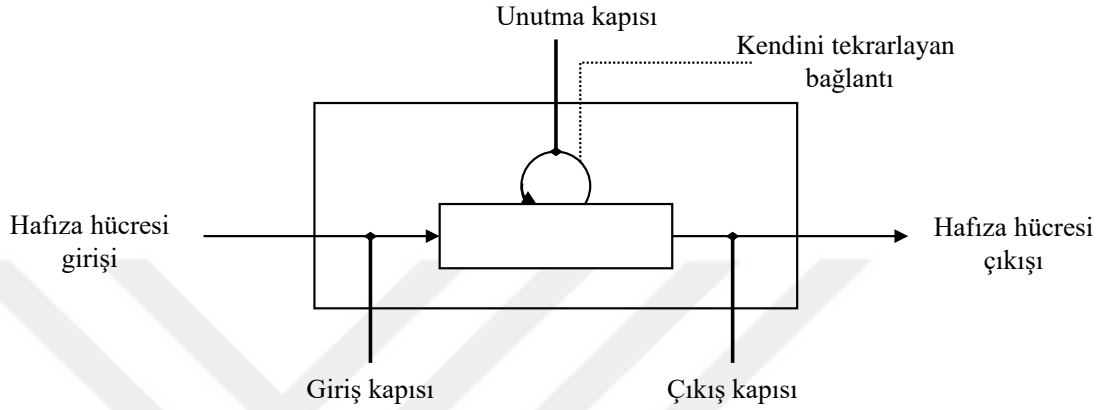
Şekil 3.9: Noktasal Çarpma ve Sigmoid Sinir Kapısı

Kaynak: (Olah, Understanding LSTM Networks, 2015)

Sigmoid katmanı, her bir bileşenden ne kadarının geçmesi gerektiğini tanımlayan "0" ile "1" arasında rakamlar verir. "0" değeri "hiçbir şeyin geçmesine izin vermeyin" anlamına gelirken, "1" değeri "her şeyin geçmesine izin verin" demektir (Olah, Understanding LSTM Networks, 2015). Bir LSTM, hücre durumunu korumak ve kontrol etmek için bu kapılardan üç tanesine sahiptir.

LSTM'deki bir bellek hücresi; giriş kapısı, kendiliğinden tekrarlayan bağlantıya sahip bir nöron, bir unutma kapısı ve bir çıkış kapısından oluşmaktadır. Kendiliğinden tekrarlayan bağlantı "1" değerinde bir ağırlığa sahiptir ve bir bellek hücresinin dış müdahaleler dışında bir zaman aşamasından diğerine sabit kalmasını sağlamaktadır. Giriş kapısı, gelen sinyalin bellek hücresinin durumunu değiştirmesine veya engellemesine izin verebilir.

Diğer taraftan, çıkış kapısı bellek hücresinin durumunun diğer bellek hücreleri üzerinde bir etkiye sahip olmasına izin verebilir veya bunu önleyebilir. Son olarak, unutma kapısı ise bellek hücresinin kendi kendini tekrar eden bağlantısını denetleyerek hücrenin gerektiğinde önceki durumunu hatırlamasını veya unutmasını sağlar (Deep Learning Tutorial, 2015).



Şekil 3.10: LSTM Hücresinin Çizimi

Kaynak: (Deep Learning Tutorial, 2015).

Yukarıdaki şekilde; LSTM ağlarında bulunan kapılar ile hafıza hücresi görülmektedir. Kapılar hücreye erişimi kontrol eder ve standart bir bilgisayarın belleğindeki “okuma”, “yazma” ve “sıfırlama” işlemleri olarak yorumlanabilir. Bu ağ geçitleri kendisini kontrol eder ve mevcut değer her hangi bir zaman aralığında güncellenip güncellenmeyeceğine karar verir. Tüm hücre bileşenleri farklılaştırılabilir işlevlerden türetildiği için tüm sistem ve bu değerleri uçtan uca geri yayılım kullanarak eğitmek mümkündür (Kurach, 2016).

3.2.3. LSTM'nin Aşamaları

Aşağıda bu çalışmada kullanılan kapılara ilişkin semboller ve açıklamalara yer verilmiştir (Cui, Ke, & Wang, 2017);

Giriş kapısı (i_t)


Unutma kapısı (f_t)

Çıkış Kapısı (o_t)

LSTM'deki ilk adım, hangi bilgilerin saklanacağı veya unutulacağına karar verilmesi aşamasıdır. Bu karar “unutma kapısı” adı verilen bir sigmoid katmanı tarafından verilir (Şekil 3.11). Unutma kapısı vektörünün öğeleri, h_{t-1} ve x_t değerlerine bakarak

c_{t-1} hücre durumundaki her bir sayı için 0 ile 1 arasında bir değer çıkarır. Eğer 1 çıkarsa “bunu tamamen koru”, 0 çıkarsa “bundan tamamen kurtul” anlamına gelmektedir. Her LSTM unutmaya kapısı, önceki LSTM biriminin bellek vektörünün durumuna ve çıktısına bağlıdır. h_{t-1} önceki hücre çıktısını, x_t hafıza hücresi giriş değerini göstermektedir.

$$f_t = \sigma(W_{xf} * x_t + W_{hf} * h_{t-1} + b_f) \quad (3.25)$$



Şekil 3.11: LSTM İçindeki Unutmaya Kapısının Gösterimi

Kaynak: (Olah, Colah's Blog, 2019)

İkinci adımda, giriş kapısı ile yapılan hangi yeni bilgilerin hücre durumunda saklanacağına karar verilmektedir. LSTM giriş kapısı, unutmaya kapısındaki gibi önceki LSTM biriminin hafızasının durumuna ve gizli durum vektörlerine bağlıdır. Bu adım iki bölüme ayrılmıştır. İlk olarak; sigmoid sinir katmanında, hangi değerlerin güncelleneceğine karar verilir. Daha sonra, tanjant katmanı duruma eklenebilecek yeni aday değerleri vektörü (\tilde{c}_t) oluşturulur. Son olarak ise, giriş katmanında bu iki değer bir araya getirilerek yeni saklanacak olan değer oluşturulmaktadır (Şekil 3.12).


Hücrenin eski değerini tutmakta olan c_{t-1} vektörü ile giriş kapısından çıkan sonuç olan C_t vektörlerinden hangisinin saklanacağına unutmaya kapısı karar vermektedir. Unutmaya kapısından gelen f_t sonucu ile eski vektör çarpılmaktadır. Unutmaya kapısından 1 değeri gelirse tamamı korunacak, 0 gelirse çarpma işlemi ile beraber saklanan değer saklama denkleminde hiç katılmayacaktır.

Giriş kapısı katmanı ve tanjant kapısı katmanı şekli ile bu kapıların formülleri aşağıda gösterildiği gibidir.

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (3.26)$$

$$\tilde{c}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (3.27)$$

Eski hücre değerinin (C_{t-1}) yeni hücre değeri (C_t) olarak güncellenmesine ilişkin şekil aşağıdaki gibidir.




Şekil 3.12: Hücre Durumunu Güncelleme

Kaynak: (Olah, Understanding LSTM Networks, 2015)

Giriş katmanındaki güncellenecek değerlerin belirlenmesinin ardından tanjant katmanı ile yeni saklanan değer ne olacağına karar verilmektedir. Giriş kapısından gelen vektör değeri, sigmoid sinir katmanından gelen i_t değeri ve tanjant katmanından gelen \tilde{c}_t değerinin çarpımı ile belirlenmektedir. Giriş kapısından çıkan vektör, bir önceki aşamada belirlenmiş olan $f_t c_{t-1}$ değeri ile toplanmaktadır.

$$c_t = f_t c_{t-1} + i_t \tanh(w_{xc}x_t + w_{hc}h_{t-1} + b_c) \quad (3.28)$$



Şekil 3.13: Yeni Hücre Durumunun Hesaplanması


Kaynak: (Olah, Understanding LSTM Networks, 2015)

Nelerin unutulup nelerin unutulmayacağı kararının verilmesinin ardından, yeni bir aktivite geldiğinde önceki aktivitenin ne kadarının hafızada tutulacağına ilişkin karar giriş kapısı katmanı ile birlikte verilmektedir. Hafızada bekleyen veri ile hafızada saklanacak yeni verinin yer değiştirmesine ilişkin işlem ve formüller yukarıda (Şekil 3.13) gösterilmiştir.

Son olarak, neyin çıkartılacağına kararının verilmesi gereklidir. Bu çıkış değeri, hücrenin durumuna dayanacak, ancak filtrelenmiş bir versiyon olacaktır. İlk olarak, hücre durumunun hangi kısımlarının çıkartılacağına karar veren bir sigmoid katmanı çalıştırılacaktır. Daha sonra ise, hücre durumu tanjanta koyulmaktadır. Tanjant katmanında, -1 ile 1 arasında değer çıkmakta ve tanjant katmanı ile saklanan bilginin ne kadarının kullanılacağı hesaplanmaktadır. Sigmoid katmanının çıktısı ise, 0 ile 1 arasında değer almakta ve bu katman yeni gelen bilginin kullanılıp kullanılmayacağına karar veren katmandır. Çıkış katmanı, sigmoid ve tanjant katmanlarından gelen değerlerini çarparak oluşan değeri çıktı olarak belirlemektedir. Aşağıda LSTM hücresinde bulunan çıkış katmanı formülü ve şekli gösterilmiştir.

$$o_t = \sigma(W_{x_o}x_t + W_{h_o}h_{t-1} + b_o) \quad (3.29)$$

$$h_t = o_t \tanh(c_t) \quad (3.30)$$




Şekil 3.14: Hafıza Hücresinin Çıkışı

Kaynak: (Olah, *Understanding LSTM Networks*, 2015)

Bu yeni durum ile birlikte, çıkış kapısının değerleri ve onların çıktıları yeniden hesaplanmıştır (Şekil 3.14).

Yukarıdaki denklemlerde σ , sigmoid fonksiyonunun başvurduğu deneyimli bir element anlamına gelmektedir. Girişler, çıkış ve unutma kapıları sırasıyla i , o ve f ile gösterilmektedir. w terimleri ağırlık matrisleri ve b terimleri ön gerilim vektörleridir. Buna standart LSTM de denmektedir. Yığılmış LSTM (Şekil 3.15) ise, bu modele ait bir uzantı olup, birden fazla LSTM katmanına sahiptir ve her katman birden fazla bellek hücresi içermektedir. Katmanların eklenmesi, zaman içerisinde girdi gözlemlerinin soyutlama seviyelerini artırmaktadır. Bu yaklaşım, potansiyel olarak her seviyedeki gizli durumun farklı zaman ölçeklerinde çalışmasına izin verir (Ravzan, Gülcehre, Cho, & Bengio, 2014). Graves vd. beceriyi modellemek için ağın derinliğinin belirli bir katmandaki hafıza hücrelerinin sayısından daha önemli olduğunu bulmuşlardır (Graves, Mohamed, & Hinton, 2013).




Şekil 3.15: Yığılmış LSTM Mimarisi

Kaynak: (<https://keras.io/>, 2019)

3.2.4. LSTM'lerin Farklı Türevleri

Yukarıda verilen bilgilerin tümü standart LSTM modellerine ilişkindir. Ancak, tüm LSTM'ler yukarıdakiler ile aynı değildirler. Standart LSTM'lere bazı eklemelerin yapılmasıyla yeni mimariler geliştirilmiştir. Gers ve Schmidhuber (2000) tarafından LSTM'e gözetleme deliği bağlantıları eklenerek, hücrede saklanan bilginin giriş ve unutma kapısına da etki etmesi sağlanmıştır (Gers, Schmidhuber, & Cummins, 2000). Bu sayede verinin saklanıp saklanmayacağı, değiştirilip değiştirilmeyeceği ve çıkış bilgisinde yeni gelen bilginin bulunup bulunmayacağına etki edilebilmiştir (Olah, Understanging LSTM Networks, 2015).



Şekil 3.16: Gözetleme Deliği İle Oluşturulan LSTM Mimarisi

Kaynak: (Olah, *Understanding LSTM Networks*, 2015)

$$f_t = \sigma(W_f \cdot [C_{t-1}, h_{t-1}, x_t] + b_f) \quad (3.31)$$


$$i_t = \sigma(W_i \cdot [C_{t-1}, h_{t-1}, x_t] + b_i) \quad (3.32)$$

$$o_t = \sigma(W_o \cdot [C_t, h_{t-1}, x_t] + b_o) \quad (3.33)$$

Gözetleme deliği, hafızadaki değerden giriş ve unutmaya kapısındaki sigmoid fonksiyonlarına bağlanmıştır. Bu durumda oluşan yeni hücre durumundaki veri ise, çıkış kapısındaki sigmoid fonksiyonuna bağlanmıştır. Yukarıdaki tüm kapılara gözetleme deliği eklenmiş olmasına rağmen birçok çalışmada sadece bazılarında gözetleme deliği eklenmektedir.

LSTM'in başka bir varyasyonunda ise, giriş ve unutmaya kapısı birleştirilmiştir. Bu sayede, unutulacak ve yeni eklenecek bilgilerin kararını ayrı ayrı vermek yerine, bu kararlar birlikte alınmaktadır. Giriş ve unutmaya kapıları birleştirilmiş LSTM mimarisi ve matematiksel ifadesi aşağıda gösterildiği gibidir.

$$C_t = f_t * C_{t-1} + (1 - f_t) * \tilde{C}_t \quad (3.34)$$



Şekil 3.17: Giriş ve Unutma Kapıları Birleştirilmiş LSTM Mimarisi

Kaynak: (Olah, *Understanding LSTM Networks*, 2015)

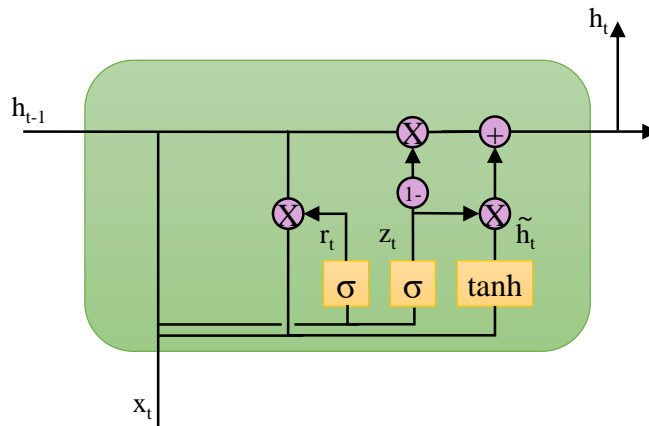
LSTM'in başka bir versiyonu ise 2014 yılında Cho vd. tarafından tanıtılmıştır. Bu model, giriş ve unutma kapılarını tek bir “güncelleme kapısı” içinde birleştiren Gated Recurrent Unit (GRU)'dur. Elde edilen model, geleneksel LSTM modelinden daha basit olduğundan gün geçtikçe daha popüler hale gelmektedir. Şekil 3.18'de GRU ayrıntılı bir biçimde matematiksel denklemleri ile birlikte gösterilmektedir.

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (3.35)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (3.36)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t]) \quad (3.37)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (3.38)$$



Şekil 3.18: Gated Recurrent Unit (GRU) Mimarisi

Kaynak: (Olah, *Understanding LSTM Networks*, 2015)

Bu LSTM türleri, en dikkate değer değişken türlerinden sadece birkaçıdır. Yao vd.nin Depth Gated RNN'ler gibi başka türleri de bulunmaktadır (Yao, Cohn, Vylomova, Duh, & Dyer, 2015). Koutnik ve diğerleri Clockwork RNN'ler gibi uzun vadeli bağımlılıklarla mücadelede tamamen farklı bir yaklaşım geliştirmişlerdir (Koutnik, Greff, Gomez, & Schmidhuber, 2014).

“Bu değişkenlerden hangisi en iyisidir? Farklılıklar önemli midir?” sorularına yanıt aramak için popüler değişkenlerin bir karşılaştırmasını yaparak hepsinin aynı olduğunu tespit etmişlerdir (Jozefowicz, Zaremba, & Sutskever, 2015). Jozefowicz vd. ise, on binden daha fazla RNN mimarisini test ederek, belirli görevlerde bazı modellerin LSTM'lerden daha iyi çalıştığını bulmuşlardır (Jozefowicz, Zaremba, & Sutskever, 2015).

Geleneksel tekrarlanan birimden farklı olarak her j . LSTM birimi t zamanında hafızasını (c_t^j) ile korumaktadır. Burada hafıza hücresi aşağıda verilen denklem yoluyla güncellenmektedir.

$$c_t^j = f_t^j c_{t-1}^j + i_t^j \tilde{c}_t^j \quad (3.39)$$

Yeni hafıza içeriği ise denklem (3.40) ile güncellenmekte ve LSTM birimi için çıktı denklem (3.41) ile hesaplanmaktadır.

$$f_t^j = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c)^j \quad (3.40)$$

$$h_t^j = \sigma_t^j \tanh(c_t^j) \quad (3.41)$$

LSTM ağlarında, diğer YSA'larda da olduğu gibi eğitim yineleme ile gerçekleştirilmektedir. Yineleme (epoch), belirli bir veri kümesinin ağın ağırlık değerlerinin (w) hesaplanmasında eğitim amacıyla kullanılmasının toplam tekrar sayısını belirtir. Bir epoch bütün bir veri kümesinin daha önce ağdan bir kez geçtiğini ve daha sonra ağ üzerinden geri döndüğünü ifade eder.

Derin öğrenme algoritmaları modellerini optimize etmek için, ağırlıkların güncellenmesi ve böylece daha iyi ve daha doğru bir tahmin modeli elde etmek amacıyla tüm veri setini tek bir ağ üzerinden birçok kez iletmek mantıklıdır. Bununla birlikte, optimal ağırlıkları elde etmek ve aynı veri kümesine sahip bir modeli eğitmek için kaç yinelemeye, yani

epoch sayısına ihtiyaç duyulacağı belli değildir. Farklı veri kümeleri farklı davranışlar sergiler ve böylece ağlarını en iyi şekilde eğitmek için farklı bir epoch sayısına ihtiyaç duyulabilir.

3.3. Hibrit Modeller

Birçok zaman serisi modeli doğrusal ilişkinin yanında doğrusal olmayan ilişkileri de içerir. ARIMA modelleri, zaman serilerindeki doğrusal ilişkinin modellenmesinde iyi iken, doğrusal olmayan ilişkilerin modellenmesinde yetersiz kalmaktadırlar. YSA'na ilişkin modeller ise, hem doğrusal hem de doğrusal olmayan ilişkileri modelleyebilme yeteneğine sahip olmalarına rağmen, her veri seti için aynı düzeyde etkin sonuçlar sağlayamazlar. Gerçek hayattaki problemlerde veri yapısının özelliklerinin tamamen bilinmesi kolay değildir. Bu sebeple, en iyi tahminleme sonuçlarına ulaşabilmek için zaman serilerinde doğrusal ve doğrusal olmayan bileşenlerin ayrı ayrı modellenmesine dayanan hibrit modeller kullanılmaktadır. Zaman serisi analizlerine yönelik tahmin işlerinde büyük başarıların sağlandığı bu modeller; kurucu öğrenme algoritmalarından elde edilenden daha iyi tahmin performansı elde etmek için çoklu öğrenme algoritmalarını kullanırlar (Opitz & Maclin, 1999). Eğitilebilir nitelikte ve tahmin amacıyla kullanılabilir olmalarından dolayı bu modeller birer denetimli öğrenme algoritmalarıdır. Bu modellerin amacı, modellerin birleşimiyle ortaya çıkacak çeşitliliği arttırmak ve daha iyi sonuçlar elde edilmesini sağlamaktır (Adeva, Beresi, & Calvo, 2005) (Oliveira & Torgo, 2014).

Hibrit modellerle elde edilen sonuçlar ve modellerin tekil kullanılmaları sonucu elde edilen sonuçlar karşılaştırıldığında birbirinden ilişkisiz bile olsalar, genel varyans veya hatayı düşürebildikleri görülmüştür (Khashei M., 2008). Bu nedenle, hibrit modeller tahmin etme görevinin en başarılı modelleri olarak tanınırlar.

3.3.1. Çeşitli Hibrit Model Yaklaşımları

Daha doğru bir hibrit model elde etmek ve tek bir modele ilişkin eksiklikleri gidermek amacıyla farklı gruplandırma yöntemleri test edilmiştir. Bu çalışmada, mevcut bulunan ARIMA-YSA hibrit modellerinden bazıları özetlenmeye çalışılmıştır.

3.3.1.1. Zhang' ın Hibrit Modeli

2003 yılında Zhang, zaman serilerinin tahmini için bir hibrit ARIMA-YSA modeli önermiştir. Bu model herhangi bir zaman serisinin doğrusal ve doğrusal olmayan iki model bileşeninin matematiksel toplamı olduğu varsayımına dayandırılmış ve aşağıdaki eşitlikteki gibi gösterilmiştir.

$$y_t = L_t + N_t \quad (3.42)$$

Burada doğrusal bileşen L_t ile temsil edilirken, doğrusal olmayan bileşen ise N_t ile gösterilmektedir. Bu bileşenler seriden tahmin edilmektedir. İlk olarak, ARIMA metodu doğrusal bileşenin modellenmesi için çalışılan veri setine uygulanır. Daha sonra, bu doğrusal modelin artıkları sadece doğrusal olmayan ilişkilere sahip olacaktır. Artıklar, gerçek değerlerden ve öngörülen değerlerden denklem 3.43'deki gibi farklılıklar alınarak elde edilebilir.

$$e_t = Y_t - \hat{L}_t \quad (3.43)$$

Bu denklemde e_t , t zamanı için doğrusal modelin (ARIMA) artığını temsil ederken, \hat{L}_t t zamanında ARIMA modeli ile bulunan tahmin değerinin artığını, Y_t t zamanına ait gerçek değeri ifade eder. Artıklar, doğrusal modelin yeterliliğinin belirlenmesinde önem arz ederler. Doğrusal modelin yeterli olabilmesi için artıklarda doğrusal bir korelasyon yapısı bırakılmamalıdır. Doğrusal olmayan ilişkiyi bulmak için ise, artıklar YSA tarafından modellenebilir.

$$\hat{e}_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \epsilon_t \quad (3.44)$$

Bu denklemde; f YSA'daki dönüşüm işlevidir ve ϵ_t rastgele hatadır.

YSA'dan gelen tahmin ve ilk modelden gelen tahmin, \hat{Y}_t serisinin tahminini elde etmek için birleştirilir. Bu şekilde oluşturulan bütünleştirilmiş tahmin modelinin matematiksel gösterimi aşağıdaki gibidir.

$$\hat{Y}_t = \hat{L}_t + \hat{N}_t \quad (3.45)$$

\hat{N}_t doğrusal olmayan bileşen için denklem 3.45'deki eşitlikten tahmin edilmiş t zamanına ilişkin hata değerini ifade etmektedir. Bir basamak ileri ve çok basamak ileri tahminlerde Zhang'ın hibrit modelinin kullanılabilmesi uygundur (Babu & Reddy, 2014).

Bu model, yaklaşımın öne sürüldüğü makalede Wolf'un güneş lekeleri, Kanada vaşağı ve İngiliz sterlini/ABD doları döviz kuru veri setlerinde kullanılmıştır.

3.3.1.2. Khashei, Bijari' nin Hibrit Modeli

2010 yılında, Kashei and Bijari tarafından önerilen model ARIMA yöntemi ve ileri beslemeli YSA'ya dayalı bir hibrit modeldir. Bu model, bir zaman serisine ilişkin verilerin doğrusal ve doğrusal olmayan iki bileşenin toplamı olduğunu varsaymaktadır. Bu yöntemde, öncelikle ARIMA yöntemi çalışılan veri setine uygulanır ve tahmini bir veri değeri elde edilir. Ardından ise, ARIMA modelinin geçmiş artık dizisinin değerleri ile geçmiş orijinal veri değerlerinin tamamı YSA'ya girdi olarak verilir. Elde edilen çıktı, hibrit modele ilişkin tahmin değerini vermektedir. Bu model, yaklaşımın öne sürüldüğü makalede, güneş lekeleri, Kanada' da yakalanan vahşi kedi sayıları ve İngiliz Sterlini- Amerikan Doları döviz kuru veri setlerinde uygulanmıştır (Khashei & Bijari, 2010).

3.3.1.3. Khashei, Bijari' nin İkinci Hibrit Modeli

Kashei and Bijari (2011) başka bir çalışmasında bir önceki modelde uyguladıkları aynı veri seti için farklı bir model önermişlerdir. Önerdikleri model, ARIMA yöntemiyle ileri beslemeli YSA'ya dayalı yeni bir hibrit modelde, herhangi bir zaman serisine ait verilerin doğrusal ve doğrusal olmayan iki bileşenin toplamı olduğu varsayılmaktadır. Bu metotta, ilk olarak ARIMA yöntemi çalışılan veri setine uygulanır ve tahmini bir veri değeri oluşturulur. Sonrasında, geçmiş orijinal veri değerleri, mevcut ARIMA tahmin değerleri ve geçmiş ARIMA hata dizisinin tamamı YSA'ya girdi olarak verilir. Son tahmin değerini, elde edilen YSA çıktısı vermektedir.

3.3.1.4. Khashei, Bijari ve Ardali'nin Hibrit Modeli

Khashei vd. (2012) yine aynı veri seti için önerdikleri hibrit modelde, ARIMA yöntemi ile sınıflandırıcı Olasılıksal Sinir Ağlarını (PNN) bütünleştirmişlerdir. Bu modeldeki amaç, sınıflandırıcı bir model olarak olasılıksal sinir ağlarının avantajlarından yararlanılması ve ARIMA modellerinin artıklarının mevcut eğiliminin belirlenmesidir (Khashei, Bijari, & Ardali, 2012).

Bu modeli aşağıdaki gibi beş aşamada özetlemek mümkündür.

- **Birinci Aşama:** ARIMA modeli üzerinde çalışılan veri kümesinin eğitim setine uygulanır ve bu aşama sonucunda tahmin değerleri ve ARIMA artıkları elde edilir.
- **İkinci Aşama:** İstenen hata düzeyinin hesaplanması ve ilk aşamada hesaplanan ARIMA artıklarının bu hata düzeyine göre sınıflandırılmasıdır.
- **Üçüncü Aşama:** Sınıflandırılmış artıklara $\{-1,0,1\}$ sayılarının atanması ve PNN yapısında bu nümerik değerlerin eğitiminin gerçekleştirilmesi aşamasıdır.
- **Dördüncü Aşama:** Üçüncü aşamada elde edilen hedef değerlerin ve ARIMA modelinden sağlanan tahmin değerlerinin kullanılmasıyla uygun adım genişliğinin hesaplanmasıdır.
- **Beşinci Aşama:** t zamanı hedef değeri ile uygun adım genişliği çarpımsal değerinin t zamanı için elde edilen ARIMA tahmin değerine eklenmesiyle, t zamanı için hibrit model tahmin sonucu hesaplanır.

3.3.1.5. Babu ve Reddy' nin Hibrit Modeli

Babu ve Reddy (2014) ARIMA yöntemi ile YSA yöntemine dayalı bir hibrit model yaklaşımı önermiştir. Bu yöntemde, öncelikle üzerinde çalışılan veriler oynaklık niteliklerine göre karakterize edilir, ardından ARIMA ve YSA'ya uygun bir şekilde uygulanmaktadır (Babu & Reddy, 2014).

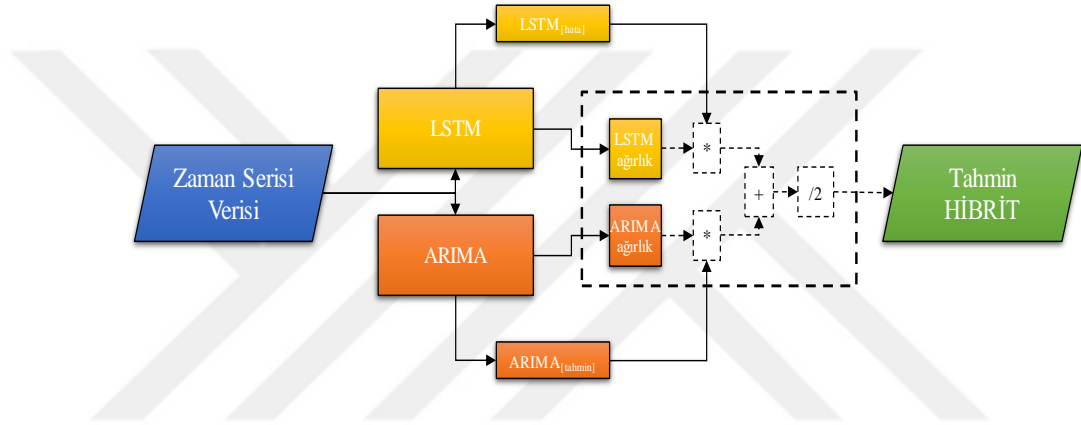
Zhang (Zhang G. , 2003), Khashei and Bijari (Khashei & Bijari, 2010)' nin önerdikleri modellerde, üzerinde çalışılan veri, doğrusal ve doğrusal olmayan bileşenlerin toplamı olarak varsayılmış, ancak doğrusal ve doğrusal olmayan bileşenlere ayrılmamıştır. Bunun yerine doğrusal ARIMA modeliyle ulaşılan artıklar doğrusal olmayan bileşen olarak varsayılmıştır (Babu & Reddy, 2014).

Bu çalışmanın özetinde ise, ilk aşamada üzerinde çalışılan verinin Jarque-Bera Normallik testi ve Basıklık (Kurtosis) katsayısı hesaplanmış, bu katsayının 3'den büyük olması halinde serinin Gauss dağılımına uygun olmadığı ve yüksek oynaklığa sahip olduğu belirtilmiştir. Hesaplanan katsayının 3'e yaklaşması halinde ise, Gauss dağılımı olduğu ve düşük oynaklığa sahip olduğu ifade edilmiştir. Sonuç olarak, zaman serisinin düşük oynaklık ve yüksek oynaklığın toplamı olduğu varsayılmıştır. Gauss dağılımına sahip olan düşük oynaklıktaki bileşen doğrusal ARIMA yöntemiyle, Gauss dağılımına sahip olmayan yüksek oynaklıktaki bileşen ise doğrusal olmayan YSA yöntemiyle tahmin edilir. Önerilen hibrit modelin tahmini de bu iki sonucun toplamı olmaktadır.

Bu model, yaklaşımın oluşturulduğu çalışmada; Güneş lekeleri, Avustralya ulusal elektrik piyasası elektrik fiyatları ve Larsen&Turbo işletmesinin New York Borsası kapanış fiyatlarına ilişkin veri setlerine uygulanmıştır.

3.3.2. Çalışmada Kullanılan Hibrit Model Yaklaşımı

Literatürde doğrusal modeller ile doğrusal olmayan modellerin oluşturduğu birçok hibrit model tahminleme amaçlı kullanılmıştır. Bu çalışmada, bir zaman serisinin geçmiş verilerinden faydalanılarak geleceğe ilişkin tahminler yapmak için oluşturulan ve blog diyagramı Şekil 3.18’de verilen ARIMA-LSTM hibrit modeli kullanılmıştır.



Şekil 3.19: Hibrit Model Diyagramı

Oluşturulan modelin zaman serisi tahmin formülü genel olarak; denklem (3.46)’da gösterildiği gibi doğrusal ve doğrusal olmayan bileşenlerin toplamı şeklinde ifade edilebilir.

$$y_t = L_t + N_t \quad (3.46)$$

L_t zaman serisinin doğrusal bileşenini gösterirken, N_t ise doğrusal olmayan bileşeni göstermektedir. Hibrit modelde ilk olarak, zaman serisinin doğrusal bileşeni L_t ARIMA modeli kullanılarak tahmin edilir, ardından N_t LSTM modeli ile tahmin edilir. Daha sonra her iki modelin de hata değerleri hesaplanır. Bu hesaplama için gerekli formüller denklem 3.47 ve 3.48’de verilmiştir.

$$lstm_{hata} = lstm_{ortalama}[hata] \quad (3.47)$$

$$arima_{hata} = arima_{ortalama}[hata] \quad (3.48)$$

Elde edilen hata deęerleri denklem (3.49) ve (3.50)'de kullanılarak modellerin aęırlıkları hesaplanır.

$$lstm_{aęırlık} = \left(1 - \left(\frac{lstm_{hata}}{lstm_{hata} + arima_{hata}} \right) \right) * 2 \quad (3.49)$$

$$arima_{aęırlık} = 2 - lstm_{aęırlık} \quad (3.50)$$

Modellerin aęırlık deęerleri ile son olarak oluřturulan hibrit modele ait her bir tahmin deęeri, verilen denklem (3.51) sayesinde elde edilmektedir.

$$hibrit_{tahmin}[i] = \frac{(lstm_{aęırlık}[i] * lstm_{hata}[i] + arima_{aęırlık} * arima_{tahmin}[i])}{2} \quad (3.51)$$

3.4. Modellerin Başarı Kriterleri

Tahmin yöntemlerinden hangi yöntem kullanılırsa kullanılsın %100 doęru deęer elde edilemez. Geleceęin %100 bilinmesi halinde zaten bir tahmin durumu söz konusu olamaz. Bu sebeple, her tahmin için belli düzeyde bir hata oranı mevcuttur. Modelin öngörü başarısının yüksek olması ve verilere uyum göstermesi çeřitli tahmin modelleri arasından birinin seęilmesi sürecinde en yaygın kabul gören ölçütlerden birisidir. Modellerin tahmin başarılarının kıyaslanması amacıyla geliştirilen ölçütlerden en önemlisi, tahmin yönteminin doęruluęudur. Tahmin yönteminin doęruluęu, tahmin edilen hataların analiz edilmesi ile ölçülmektedir (Sarı, 2016).

Çalıřmamızda ele alınan 3 yöntemin model öngörü başarısını ölçmek için Ortalama Kare Hatası (Mean Squared Error-MSE), Kök Ortalama Kare Hatası (Root Mean Squared Error-RMSE), Ortalama Mutlak Hata (Mean Absolute Percentage Error-MAPE) ve Ortalama Mutlak Hata Yüzdesi (Mean Absolute Error-MAE) kriterleri kullanılmıřtır. Bu kriterlerin hesaplanabilmesi için kullanılan formüller Tablo 3.3'de verilmiřtir (Sallehuddin, Shamsuddin, Hashim, & Abraham, 2007).

Tablo 3.3
Başarı Kriteri (Korelogram) Formülleri

Kriter Adı	Formüller
Ortalama Kare Hatası (Mean Square Error)	$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2$
Kök Ortalama Kare Hatası (Root Mean Square Error)	$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$
Ortalama Mutlak Hata (Mean Absolute Error)	$MAE = \left(\sum_{t=1}^n \left \frac{y_t - \hat{y}_t}{n} \right \right)$
Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error)	$MAPE = \left(\sum_{t=1}^n \left \frac{y_t - \hat{y}_t}{y_t} \right \right) \frac{100}{n}$

Burada y_t gerçekleşen değeri, \hat{y}_t öngörülen değeri, n öngörülen dönem sayısını ifade eder. Yukarıdaki formüller vasıtasıyla ulaşılan değerlerin küçüklüğü en uygun modele ulaşılmasını sağlayacaktır.

3.5. ARIMA, LSTM, YSA ve İki Modelin Kullanımı İle Oluşturulan Hibrit Modellere Yönelik Çalışmalar

Literatürde ARIMA modelleri, elektrik fiyatları, şeker fiyatları, konut fiyatları, borsa verileri, satış verileri, rüzgâr hızları, su kalitesi, küresel sıcaklık değerleri gibi çeşitli zaman serileri verilerinin gelecekteki değerlerinin tahmini için uygulanmıştır. Bu modellerin popüleritesi istatistiksel özelliklerinin yanı sıra Box-Jenkins metodolojisine bağlı olmasından da kaynaklıdır. Bu modeller, belirli bir uygulamadaki verilerin dinamiklerini anlamaya yardımcı olabilir. Örnek olarak; ARIMA modeli ile Ediger ve Akar, 1950-2004 dönemi verileriyle 2005-2020 dönemi birincil enerji talebini, Albayrak, 1923-2006 dönemi verileri ile 2007-2015 dönemi birincil enerji üretimi ve talebini ve Erdoğan ise, 1923-2004 dönem verileriyle 2005-2014 dönemi elektrik tüketimini tahmin etmiştir (Ediger & Akar, 2007) (Albayrak, 2010) (Erdoğan, 2007).

AR, MA, ARMA ve ARIMA gibi zaman serisi yöntemlerinin kullanılabilmesi için veri setinde bazı şartların sağlanmasının gerekli olmasından dolayı tahmin performansları kısıtlıdır. Bu amaçla geliştirilen; YSA, destek vektör makineleri, derin öğrenme, bulanık

tabanlı ağ çıkarım sistemi ve genetik algoritmalar gibi bilgi işlemsel zeka yöntemleri sosyal bilimlere yönelik çalışmalarda birçok değişkenin tahmininde kullanılmaya başlanmıştır. Bu zeka yöntemleri, geleneksel istatistikî yöntemlerin yetersiz kaldığı gerçek hayattaki karmaşık problemleri çözmeye çalışan ve doğadan esinlenen hesaplama yöntemleridir.

YSA'lar ile ilgili olarak özellikle sosyal bilimler alanındaki çalışmalar incelendiğinde; bu metodun talep, fiyat, maliyet, döviz kuru, hisse senedi, endeks tahmini, başabaş noktası analizi vb. gibi birçok çalışmaya uygulandığını görmek mümkündür. Uygulamalarda genellikle, YSA dışında farklı bir yöntem ile de tahmin çalışması yapılmış ve elde edilen sonuçlar karşılaştırıldığında gerçekleştirilen uygulamaların neredeyse tamamında YSA yönteminin daha elverişli sonuçlar verdiği savunulmuştur.

LSTM ağları, daha çok derin öğrenme eğilimli olup geniş veri setleri ile daha yüksek başarılar elde etmektedirler. Fakat sınırlı sayıda da olsa az veri seti ile eğitildiği örnekler literatürde mevcuttur. Örneğin, Namın ve Namın, 2018 yılında ekonomik ve finansal zaman serileri tahminlemesi üzerine bir LSTM ağ modeli denemışlerdir. Bu deneme sonucunda da %13-%16'lık bir hata ile başarı sağlamışlardır (Namın & Namın, 2018).

Son yıllarda ise, özellikle modellerin avantajlarının birleştirilmesi ile oluşturulan hibrit metodların tek başına kullanılan yöntemlere kıyasla çok daha iyi sonuçlar verdiği ileri sürülmektedir. Literatürde iki veya daha fazla bireysel modelin avantajlarını bir araya getiren hibrit modellere ilişkin çalışmalardan bir kısmını aşağıdaki gibi özetlenebilir.

Wedding ve Cios (1996) radyal tabanlı fonksiyon ağları ve Box-Jenkins ARIMA modelleri ile bütünleştirilmiş bir yöntem bilim sunmuşlardır (Wedding & Cios, 1996). Luxhoj vd. (1996) bir firmaya ait 24 aylık toplam satış tahmini amacıyla hibrit ekonometrik-sinir ağı yaklaşımını kullanmışlardır (Luxhoj, Riis, & Stensballe, 1996). Tsaih vd. (1998) S&P 500 Borsa Endeksi günlük fiyat değişim yönünü tahmin etmek için kural tabanlı sistemler ve hibrit yapay zekâ yöntemlerini birleştirmişlerdir (Tsaih, Hsu, & Lai, 1998).

Tseng vd. (2002) SARIMABP olarak bilinen mevsimsel ARIMA ve sinir ağları geri yayılım algoritmasının (BP) birleşiminden oluşan bir hibrit model önermiştir (Tseng, Yu, & Tzeng, 2002). Zhang (2003) ARIMA ve YSA hibrit modelini kullanarak zaman serileri tahmini konulu bir çalışma gerçekleştirmiştir. Çalışmada, Wolf'un güneş lekeleri verileri,

Kanada vaşığı verileri ve İngiliz sterlini/ABD doları döviz kuru verileri kullanılmıştır. Zhang bu çalışmada geliştirdiği melez model ile; ne ARIMA ne de YSA'nın tüm gerçek zaman serilerine uygun olmadığını, bu serilerde gözlemler arasında doğrusal ve doğrusal olmayan korelasyon yapıları bulunduğunu ve bu nedenle bir zaman serisinin hem doğrusal hem de doğrusal olmayan bileşenlerinin tahmini için bir melez model kullanılması gerektiğini göstermiştir (Zhang G. , 2003).

Armano vd. (2005) borsa tahmininde genetik algoritmayla birleşik YSA'ya dayalı bir hibrit model yaklaşımı önermiştir (Armano, Marchesi, & Murru, 2005). Yu vd. (2005) tahmin performanslarını iyileştirmek ve daha doğru tahmin sonuçları elde edebilmek için YSA ile genelleştirilmiş doğrusal otoregresyonu (GLAR) birleştirerek doğrusal olmayan yeni bir hibrit tahmin modeli sunmuşlardır (Yu, Wang, & Lai, 2005). Kim ve Shin (2007) borsa tahmininde geçici desenlerin belirlenmesi için, uyarlamalı zaman gecikmeli sinir ağları (ATNN) ve zaman gecikmeli sinir ağları (TDNN) gibi YSA'ya dayanan genetik algoritmali bir hibrit modele ilişkin etkinliği araştırmışlardır (Kim & Shin, 2007).

Zhou ve Hu (2008) Grey ve Box-Jenkins ARMA metotlarına dayanan hibrit model tahmin yaklaşımını önermişlerdir (Zhou & Hu, 2008). Khashei vd. (2008) YSA ve bulanık regresyon yöntemlerini kullandıkları çalışmalarında, eksik veri setleri ile daha doğru sonuçlar veren bir hibrit model önermişlerdir. Önerilen modelde, YSA ve bulanık regresyonun avantajları hem YSA'lardaki hem de bulanık regresyondaki sınırlamaların üstesinden gelmek için birleştirilmiştir. Yöntemin uygunluğunu ve etkinliğini göstermek için altın fiyatı (Gram / ABD \$) ve döviz kuru (ABD / İran Riyali) tahmininde kullanılmıştır. Elde edilen sonuçlar ise, önerilen modelin tahmin doğruluğunu iyileştirmenin etkili bir yolu olabileceğini göstermiştir (Khashei, Hejazi, & Bijari, 2008). Aladağ vd. çalışmalarında, Elman'ın tekrarlayan sinir ağları (RNN) ve mevsimsel ARIMA (SARIMA) modelleri ile yeni bir hibrit yaklaşım önermişlerdir. Hibrit modelde 1821-1934 periyodu için Kuzeybatı Kanada'nın Mackenzie Nehri Bölgesi'ndeki yıllık vaşak tuzakları sayısından oluşan Kanada vaşığı verileri kullanılmıştır. Kullanılan veriler, oldukça sınırlı sayıda olmasına rağmen uygulama sonuçları içerisinde hibrit metot en iyi tahmin doğruluğunu vermiştir (Aladağ, Eğrioğlu, & Kadılar, 2009). Koutroumanidis vd. (2009) ormanların Yunanistan'da yakacak odun üretimindeki rolünü incelemeye yönelik olarak yaptıkları çalışmalarında, Yunan devlet orman çiftlikleri tarafından üretilen odun satış fiyatlarının gelecekteki durumunu tahmin etmişlerdir.

Tahmin için ARIMA, YSA ve Hibrit modellerini kullanmışlar ve en iyi tahmin sonuçlarını ARIMA-YSA hibrit modelini kullanarak elde etmişlerdir (Koutroumanidis, Ioannoub, & Arabatzis, 2009).

Koutroumanidis vd. (2011) hibrit yöntem ile hisse senedi pazar fiyatlarının tahminine yönelik olarak gerçekleştirdikleri çalışmalarında, bir zaman serisinin öngörülen değerleri için güven aralıklarının oluşturulmasını amaçlamışlardır. Araştırmanın örneklemini olarak Alpha Bankası'na ait hisse senetlerinin 28/01/2004'den 30/11/2005'e kadar olan günlük kapanış fiyatları kullanılmıştır. Tahmin için ham verilere YSA uygulanmış, ardından Bootstrap yöntemiyle pazar fiyatlarının tahmini gerçekleştirilmiştir. Farklı kriterlerin kullanılması ile tahmin doğruluğu ölçülmüş ve tatmin edici sonuçlar elde edilmiştir (Koutroumanidis, Ioannou, & Zafeiriou, 2011). Ioannou vd. (2011) dikilen kestane ağaçlarında Ring Shake görünümünün olasılığını tahmin etmek için bir yöntem sunmuşlardır. Araştırmalarında, Castanea sativa'da meydana gelen the ring shake olgusunun Avrupa'da kestane odunu üretimini azaltan neden olduğu ve kesin olmamakla birlikte bu kusurun ortaya çıkmasında yaş ve yıllık büyümenin en önemli faktörler olduğu iddia edilmiştir. Çalışmalarında yaşın ve yıllık büyümenin tahmini için YSA yöntemini kullanmışlardır (Ioannou, Birbilis, & Lefakis, 2011). He ve Deng (2012) çalışmalarında, hava kirletici etmenleri tahmin etmek için ARIMA ve YSA'yı kullanarak hibrit bir model geliştirmişlerdir. Öncelikle ARIMA ve YSA ile ayrı ayrı zaman serisi tahmini yapıp, daha sonra geliştirilen hibrit model ile tekrar tahmin uygulaması yapılmıştır. Elde edilen sonuçlar karşılaştırıldığında, hibrit modelin daha iyi performans sergilediği görülmüştür (He & Deng, 2012).

Papagera vd. (2014) MIKE SHE ve YSA modellerini kullanarak su dengesi tahminine yönelik bir araştırma gerçekleştirmişlerdir. Araştırma için Yunanistan'ın kuzey kesiminde bulunan Koronia Gölü'ne ait 2008-2012 yıllarına ilişkin 4 yıllık veri seti kullanılmıştır (Papagera, Ioannou, Zaimis, Iakovoglou, & Simeonidou, 2014). Babu ve Reddy (2014) güneş lekesi, elektrik fiyatı ve borsa verileri gibi simüle edilmiş veri seti ile deneysel veri setlerini kullanarak uçuculuğun doğasını araştırmışlardır. Çalışmalarında, öncelikle hareketli ortalama filtre kullanılmış, daha sonra ise ARIMA ve YSA modelleri uygun bir şekilde uygulanmıştır. Uygulamada kullanılan ARIMA ve YSA modelleri ve bazı mevcut Hibrit ARIMA-YSA modelleriyle birlikte bir hibrit model önerilmiştir. Veri setlerinden elde edilen sonuçlar, hem tek adımlı hem de çok adımlı

tahminler için hibrit modelin daha yüksek tahmin doğruluğuna sahip olduğunu göstermektedir (Babu & Reddy, 2014). Hocaoglu vd. (2015) YSA ve regresyon yöntemlerini kullanarak oluşturdukları hibrit modeli, enerji sektöründe yük tahmini için kullanmışlardır. Elde edilen hata sonuçları kıyaslandığında, hibrit sistemin hatasının en az olduğu sonucuna ulaşılmıştır (Hocaoglu, Kaysal, & Kaysal, 2015).

Ateşoğun (2015) çalışmasında; ARIMA, YSA ve bu iki model ile oluşturmuş olduğu hibrit modeli kullanarak Kanada'daki vahşi kedi sayıları, güneş lekeleri, havayolu yolcu sayıları, Avustralya New South Wales bölgesi saatlik elektrik fiyatları ile Türkiye'deki buğday verimliliği üzerine tahminler yapmıştır. Ulaşılan sonuçlar hem kullanılan yöntemler arasında hem de geçmiş dönemlerde gerçekleştirilen çalışmalarla kıyaslanmıştır (Ateşoğun, 2015).

Pablo vd. (2016) çalışmalarında L-senaryolarının üretimi ile zaman serilerinin yeniden yapılanması için YSA ve Monte Carlo Simülasyonu ile oluşturulan hibrit bir yaklaşım önermişlerdir. Bu modellerle bir süt şirketinin günlük süt satışlarını tahmin etmeye çalışmışlardır. Elde edilen sonuçlar, önerilen yöntemin geçmişi yeniden yapılandırabileceğini ve bilinen zaman serileri segmentinden geleceğin tahmin edilebilir olduğunu göstermektedir (Pablo, ve diğerleri, 2016). Sugiartawan vd. (2017) aylık periyotta Endonezya'ya gelen turistlerin sayısını tahmin etmek için dalgacık dönüşümü ve YSA ile oluşturdukları hibrit bir model kullanmışlardır. Önerilen hibrit modelin tahmin sonuçları, diğer RNN algoritmaları ile yani ELMAN RNN ve Jordan RNN ile birlikte birlikte Elman'ın dalgacığının hibriti ve Jordan'ın dalgacığının hibriti ile karşılaştırılmıştır. Dalgacık dönüşümü ve YSA'den oluşturulan hibrit modelin orijinal YSA ile Elman ve Jordan'ın RNN'lerinden daha iyi bir eğitim süresi verdiği ve gelen turist sayılarını diğer hibrit yöntemlerden daha doğru tahmin edebildiği sonucuna ulaşmışlardır (Sugiartawan, Pulungan, & Sari, 2017). Lin vd. (2017) YSA'nın son zamanlarındaki başarılarından esinlenerek, zaman serilerindeki trendi tahmin etmek için baştan sona yeni bir hibrit sinir ağı olan TreNet'i önermişlerdir. Çalışmalarında, elektrik tüketimi, değişken konsantrasyonlarda dinamik gaz karışımlarına maruz kalan kimyasal sensör kayıtları ve Yahoo Finans ve New York Menkul Kıymetler Borsası'ndaki günlük stok işlem bilgilerini içeren üç farklı veri seti kullanmışlardır. Çalışmanın sonucunda, TreNet'in zaman serilerinde trend evrimini tahmin etmek için kullanılabileceğini belirtmişlerdir (Lin, Guo, & Aberer, 2017).

Yu vd. (2018), Pekin'deki ikinci el konut fiyatlarını tahmin etmek amacıyla; derin öğrenmeye dayalı Evrişimli Sinir Ağları (Convolution Neural Network-CNN) ve LSTM modelleri ile zaman serilerinden Otoresif Hareketli Ortalama (ARMA) modelini kullanmışlardır. CNN, LSTM ve ARMA modelinden elde edilen sonuçlar karşılaştırılmıştır. Kullanılan bu üç model arasında karşılaştırma yapmak için ise mantıksal regresyon modeli uygulanmıştır. Zaman serisini dikkate alan LSTM'in diğer yöntemlere kıyasla tahmin doğruluğunun daha iyi olduğu sonucuna varılmıştır (Yu, Jiao, Xin, Wang, & Wang, 2018).

Temür vd. (2019), Türkiye'deki konut satışlarının tahminine yönelik gerçekleştirdikleri çalışmalarında zaman serisi olarak geçmiş dönemlere ait aylık konut satış verilerini kullanmışlardır. ARIMA, LSTM ve bu iki modelden elde ettikleri Hibrit model ile gerçekleştirdikleri çalışmada en iyi tahmin sonucunu Hibrit modelden elde etmişlerdir (Soy Temür, Akgün, & Temür, 2019).

BÖLÜM 4: ÜRETİM İŞLETMESİNDE SATIŞ TAHMİNİ ÜZERİNE UYGULAMA

Bu bölümde, satış miktar bütçesinin oluşturulması için gerekli olan satış verilerinin tahmin edilmesinde ARIMA, LSTM ve Hibrit metotlardan nasıl faydalanılabileceğinin ortaya konması amaçlanmıştır. Bu amaçla, bir üretim işletmesinden faydalanmak suretiyle öncelikle ARIMA ve LSTM yönteminin kullanımı ile satış miktarı tahmini gerçekleştirilmiştir. Daha sonra ise, bu iki yöntemin avantajlarının bir araya getirilmesi ile geliştirilen hibrit metot verilere uygulanarak tahmin değerleri elde edilmiştir. Son olarak ise, bu yöntemlerin tümünün karşılaştırılması suretiyle gerçekleşen değerlere en yakın sonuçların hangi yöntemin kullanımı sonucunda elde edildiğine dair açıklamalara yer verilmiştir.

4.1. İşletme Profili

Etkin bir envanter yönetimi için aylık satış tahmini önerilen temel adımlardan biridir. İşletmelerin satışlarını doğru tahmin etmeleri gelecek hakkında planlamalar yaparken daha doğru kararların alınmasında yol gösterici nitelikte bilgiler sağlamaktadır. Türkiye gibi ülkelerde inşaat sektörü, pek çok modern ekonomi için ekonominin katalizatörü konumunda olup ekonomik büyüme rakamları içinde izlenmektedir.

Uygulamaya örnek teşkil eden işletme (X), konut üretiminde kullanılan “A” ürününün üretimini gerçekleştirmektedir. İşletme faaliyette bulunduğu piyasa içinde alanında ihtisaslaşmış olup, piyasanın seçkin firmalarına hizmet vermektedir. Yıllık üretim kapasitesinin neredeyse tamamını kullanmakta olan işletmenin aylık üretim miktarları tamamen sabit değildir. Ancak üretim miktarları genellikle birbirine yakın değerlerde gerçekleşmektedir. Üretilen ürünün bozulabilir nitelikte olmamasından dolayı satışların üretimden daha az olduğu dönemlerde stoklama yapılabilmesi mümkündür. Özellikle yaz aylarında daha fazla işgücüne ihtiyaç duyduklarını belirten firma yetkilileri bu işgücünü sağlamakta sıkıntı yaşamalarından dolayı 2017 yılında üretimlerini durdurarak işgücü kullanımını azaltmak için teknolojik yenilenmeye yönelik bir çalışma gerçekleştirmişlerdir ve ardından tekrar üretime başlamışlardır.

4.2. Veri ve Araştırma Bulguları


RNN' ler, gözlemlenen önceki adımlara göre gözlemler sırasındaki bir sonraki adımın tahmin edilmesini sağlayan özel sinir ağlarıdır. Temel olarak RNN'lerin arkasındaki fikir, sıralı gözlemleri kullanmak ve gelecekteki eğilimleri tahmin etmek için önceki aşamalardan öğrenmektir. RNN' lerin yapısında bulunan gizli katmanlar, sıralı verilerin okunmasının önceki aşamalarında yakalanan bilgilerin depolanması için dahili depolama görevi görürler. Gelecekteki görünmeyen sıralı verileri tahmin etmek için daha önce toplanan bilgileri kullanma özelliği ile RNN' lere “tekrarlayan” denir. Tipik bir RNN' deki en büyük zorluk, bu ağların zaman serisindeki sadece birkaç önceki adımı hatırlaması ve dolayısıyla daha uzun geriye dönük verileri hatırlamaya uygun olmamasıdır. Bu sorun, LSTM ağında tanıtilen “bellek hattı” yapısı kullanılarak çözülmüştür. Sonuç olarak LSTM ağ mimarileri için, sonraki aşamaları tahmin ederken önceki aşamalardaki verilerin hatırlanması yeterli olmaktadır (Namin & Namin, 2018). Bu durum tek bir zaman serisinden (veri seti) başka herhangi bağımlı değişken serisine gerek duymadan geleceğe yönelik tahmin yapabilmeyi sağlamaktadır. Literatür taramasında bu duruma örnek çalışmalar sunulmuş olup ek olarak, Taş (2018) çalışmasında, Türkiyede'ki saatlik (kW/h) elektrik fiyatlarını SARIMA, TBATS, YSA modelleri ve bunlar ile oluşturulan Hibrit modeller ile tahmin etmiştir. Bu çalışmada 2012-2018 yılları arasındaki tek değişkenden oluşan günlük ve haftalık elektrik talebinden yararlanmıştır (Taş, 2018). Süzen (2019) çalışmasında, LSTM Derin sinir ağları ile üniversite giriş sınavındaki matematik soru sayılarının konulara göre tahmini adlı çalışmasında veri seti olarak 1981-2018 yılları arasındaki üniversite giriş sınavına ait matematik testi soru sayılarını kullanmıştır (Süzen, 2019).

Çalışmamızın bu kısmında, uygulamalarımızda kullanılan verilere ilişkin bilgilere ve uygulama sonuçlarından elde edilmiş olan bulgulara yer verilmiştir.

4.2.1. Veri

Çalışma kapsamında, inşaat sektöründe kullanılan bir ürünün 2010 (1)–2017 (12) aylarına ait gerçekleşen satış adetleri temin edilmiş olup, toplamda 96 aylık veri seti kullanılmıştır. Firma ve ürün bilgisi rekabet unsurları açısından firmanın isteği üzerine saklı tutulmaktadır. İlgili veri seti, tez içeriğinde belirlenen modellerde kullanılmak üzere bir dizi halinde temsil edilmiştir. Temsil edilen verilerin yıllara ait adet veri grafiği Şekil

4.1’de verilmiştir. Verilerin sayısal olarak büyük olmasından dolayı x(1000) oranında küçültülerek modeller ile işlenmiştir.



Şekil 4.1: Aylık ürün satışı veri seti grafiği

Tahmin uygulamalarında kullanılan bir veri seti, eğitim ve test verileri olmak üzere ikiye ayrılır. Eğitim ve test verisi miktarının ne kadar olması gerektiği tahmin uygulamalarında karşılaşılan en temel sorundur. YSA, mümkün olduğunca en fazla veri kullanılarak eğitilmelidir. Test seti için ise, eğitim setinde kullanılmayan veriler kullanılmaktadır. Test verilerinin ağ yapısına verilmesiyle elde edilen çıktılar ile gerçek çıktı değerleri karşılaştırılır. Temel amaç, elde edilen verilerin örneği temsil etme gücünün yeterli olup olmadığını kontrol etmektir.

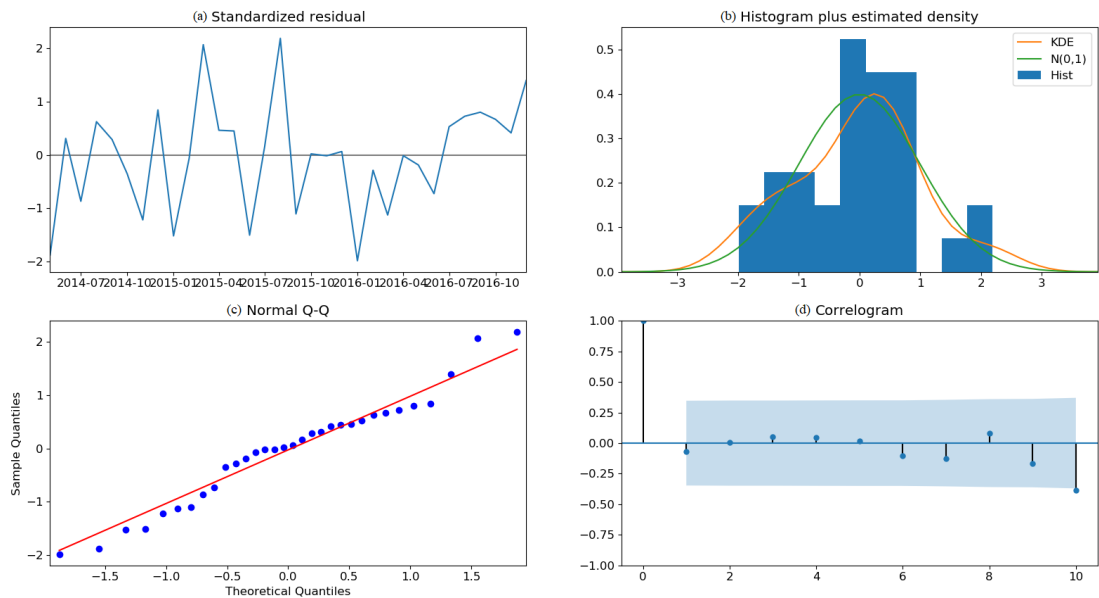
Literatürde eğitim ve test verilerinin belirlenmesinde veri setinin %70 eğitim, %30 test veya %80 eğitim ve %20 test şeklinde bölünmesi genel kabul görmüştür. Bu tez çalışmasında da veri setinin en uygun sonuçlarını tespit etmek amacıyla farklı kombinasyonlarda eğitim oranları denenmiştir. Bu oranların genel kabul gören oranlardan farklı belirlenmesinin sebebi, birçok eğitim oranının denenerek en uygun oran ile uygun olmayan oranların belirlenmesinden kaynaklanmaktadır. Tüm modellerin farklı eğitim seti oranları ile gerçekleştirilen denemelere ait özet çıktılar, ilgili modellerin bölümlerinde sonuçlar halinde gösterilmiş olup tüm denemelere ait çıktılar ise çalışmanın EK’ler bölümünde tablolar halinde sunulmuştur.

Veriler, zaman serisi tahminlerinde yaygın olarak kullanılan doğrusal metotlardan ARIMA ve son dönemlerde özellikle derin öğrenme algoritmaları için kullanılan doğrusal olmayan metotlardan LSTM ağına uygulanmıştır. Ayrıca, literatürde genel kabul görmüş hibrit metotlar incelenmiş ve bu çalışma içinde ARIMA ve LSTM'den oluşan bir hibrit metot da denenmiştir. Tez çalışmasının uygulama aşamasındaki tüm metotlarda Python 3.6 programlama dili kullanılmış olup, açık kaynak kod olarak sunulan hazır kütüphanelerden faydalanılmıştır. Python programlama dilinin seçilmesindeki en önemli neden, akademik ve gelişim için bir araç ve ortam olarak değerlendirildiğinde rakiplerinden daha etkili ve daha hızlı sonuçlara izin veren bir dil olmasıdır. Ayrıca, makine öğrenimi ve veri bilimi alanlarında sıklıkla kullanımı, mevcut kaynakların kullanılabilirliği ve en önemlisi veri işleme kütüphanelerine sahip olma yeteneği de gösterilebilir. Tüm bu özelliklere ek olarak, Python veri görselleştirme açısından sağladığı yetkili araçlarla sunum kalitesini artıran öğeler de içermektedir (Tsay, 2014).

4.2.2. ARIMA Modeli Uygulama Sonuçları

ARIMA tahmin yöntemi ile gerçekleştirilen satış verileri tahmini için $p[0, 1, 2, 3]$, $d[0, 1, 2]$, $q[0, 1, 2]$ değerleri kullanılarak ARIMA(p,d,q) modelleri belirlenmiş ve bu modellerin her birinin ayrı ayrı korelogram incelemeleri gerçekleştirilmiştir.

Belirlenen en uygun ARIMA modelinin kalıntılarına ilişkin elde edilen göstergeler Şekil 4.2'de verilmiştir.



Şekil 4.2: En Uygun ARIMA Modelinden Elde Edilen Göstergeler

Kullanılan modelde, kalıntıların ilişkisiz olması ve normalde sıfır ortalama ile dağıtılması sağlanmalıdır. Böyle bir durumun söz konusu olmaması halinde ise, bu durum ilgili modelin daha da geliştirilebileceğini belirtir ve işlem artıklarıyla tekrar edilmektedir.

Bu durumda, önerilen model artıklarının normal dağılımı aşağıdaki sonuçlara dayanmaktadır:

- Şekil 4.2.b’de bulunan KDE grafiği normal dağılıma neredeyse benzer bir dağılım göstermektedir.
- Şekil 4.2.c’de bulunan Q-Q grafiği, artıkların (mavi noktaların) sıralı dağılımının, $N(0,1)$ standart bir normal dağılımdan alınan numunelerin doğrusal eğilimini takip ettiğini göstermektedir. Yine, bu durum artıkların normal dağılıma sahip olduğunun güçlü bir göstergesidir.
- Zaman içinde kalanlar (Şekil 4.2.a), belirgin bir mevsimsellik göstermez ve gürültü gibi görünmektedir. Bu, Şekil 4.2.d’de bulunan otokorelasyon (yani korelogram) grafiği ile onaylanır. Bu durum, zaman serileri artıklarının gecikmeli versiyonlar ile düşük korelasyona sahip olduğunu göstermektedir.

Bu gözlemler, ARIMA modeliminin zaman serisi verilerini anlamaya ve gelecekteki değerleri tahmin etmeye yardımcı olacak tatmin edici bir uyum sağladığının göstergesi olmakla birlikte iyi çalıştığını da belirtmektedir. Anlatımı yapılan karşılaştırma tablolarında MAPE değerlerinin başarı kriteri olarak kullanılmasındaki temel amaç kriterin yüzdesel olarak ifade edilmesinden dolayı kolay anlaşılabilir olmasıdır. Yapılan tahmin çalışmalarına ait başarı kriterleri ve model hata karşılaştırmalarına ait özet sonuçlar Tablo 4.1 ve Tablo 4.2’de verilmiş olup, bu tablo ve modellerin oluşturduğu çıktı grafikleri üzerinden anlamlılık sınaması yapılmıştır. Tablolardaki model sonuçlarına göre yüzdelik hata oranı daha düşük olan model, tahminlemede daha değerli bir model olmaktadır. Buna göre sınamalar sonucunda eğitim veri seti %67’lik olan çalışmanın en düşük MAPE değerlerine sahip ARIMA(1,0,0) ve ARIMA(1,0,1) modelleri ile eğitim veri seti %73’lük olan çalışmanın en düşük MAPE değerli ARIMA(1,0,0) ve ARIMA(1,0,1) modellerinin en başarılı tahminleri gerçekleştirdikleri görülmüştür. Bu tahminlemeler arasında da eğitim-test veri seti arasından %67’lik çalışmanın düşük MAPE değerleri üretmesi daha değerli tahminleme gerçekleştirdiğini göstermektedir.


Tablo 4.1
ARIMA Modelleri Korelogram Sonuçları (%67 eğitim seti)

ARIMA Modellerinin Karşılaştırılması				
ARIMA	MAE	MSE	RMSE	MAPE
(0,0,1)	775.124	934643.842	966.770	0.255
(0,0,2)	751.472	850727.707	922.349	0.252
(0,1,0)	692.830	766967.805	875.767	0.253
(1,0,0)	672.267	681849.325	825.742	0.234
(1,0,1)	675.996	690921.199	831.217	0.235
(1,0,2)	684.416	707584.581	841.180	0.238
(1,1,0)	688.410	757390.500	870.282	0.251
(2,1,0)	676.638	784725.580	885.847	0.247
(2,2,0)	775.778	935149.511	967.031	0.278


Tablo 4.2
ARIMA Modelleri Korelogram Sonuçları (%73 eğitim seti)

ARIMA Modellerinin Karşılaştırılması				
ARIMA	MAE	MSE	RMSE	MAPE
(0,0,1)	837.842	1048519.893	1023.973	0.281
(0,0,2)	802.764	944684.711	971.949	0.276
(0,1,0)	699.415	828872.420	910.424	0.266
(1,0,0)	710.461	760316.150	871.961	0.254
(1,0,1)	716.008	773831.273	879.677	0.256
(1,0,2)	723.226	792962.528	890.484	0.259
(1,1,0)	706.616	830713.220	911.435	0.268
(2,1,0)	688.728	858269.317	926.428	0.262
(2,2,0)	781.374	967890.861	983.814	0.293

Örnek olarak en düşük MAPE değerlerine sahip en iyi tahminlerden oluşan ARIMA (1,0,0) ve ARIMA (1,0,1) modelleri ile elde edilen 31 aylık tahmin ve 26 aylık tahmin verilerinin gerçek test verileri ile karşılaştırılmasına ilişkin grafikler Şekil 4.3 ve Şekil 4.4'te verilmiştir.



Şekil 4.3: ARIMA(1,0,0) Modeli ve Gerçek Veri Seti Karşılaştırma Grafiği



Şekil 4.4: ARIMA(1,0,1) Modeli ve Gerçek Veri Seti Karşılaştırma Grafiği

Şekil 4.3 ve Şekil 4.4 incelendiğinde, gerçek veriler ile tahminleme çalışmalarının elde edilen aylık satış değerlerinin birbirine örtüşen yapıda olduğu ve aralarındaki sapmaların aşırılık göstermediği görülmektedir. Grafiklerde görülen başarı, verilerin yakınlık değerlerinin yanı sıra özellikle yön kırılmalarının da benzerlik göstermesinden daha net gözlemlenebilmektedir. Burada kullanılan modeller sırasıyla, 0.234 ve 0.235 MAPE hata

değeri ile gerçek veriye oldukça yakın değerler üretebilmektedir. Bu da uygulanan modelin başarısını göstermektedir.

4.2.3. LSTM Modeli Uygulama Sonuçları

Çalışmanın bu kısmında, zaman serisi LSTM mimarisi kullanılmıştır. Python yazılımında kodlanan bu kısım, LSTM model geliştirmede kullanılan bir derin öğrenme kütüphanesi olan KERAS ile gerçekleştirilmiştir. Bilindiği üzere LSTM ağları bir derin öğrenme mimarisi olup, veri seti sayısının yüksek olduğu durumlarda daha iyi sonuçlar vermektedir. Fakat bölüm 3.5’de de belirtildiği gibi çok az sayıda da olsa basit bir LSTM mimarisinin az veri ile eğitilip sonuç alındığı durumlar mevcuttur. LSTM ağı, veriyi sıralı bir biçimde almakta ve satış değerlerinin sıralamalarının da eğitim ve sınıflandırma aşamalarında dikkate alınmasını sağlamaktadır. Uygulamamızda, LSTM ağı 2010-2017 yılları arasında aylık olarak sıralanmış ürün satış miktarları üzerinde çalıştırılmıştır. Bu kısımda da yine verilerin %67’si ve %73’ü olmak üzere 2 çeşit eğitim kombinasyonu ile tahminlemeler gerçekleştirilmiş ve eğitimde kullanılmayan veriler ise test amacıyla kullanılmıştır. Eğitim işlemi sırasında farklı epoch sayıları kullanılmış, sonuçta oluşan hata değerleri gözlemlenmiştir. Gerçekleştirilen eğitim kombinasyonlarına göre epoch sayıları sonucunda oluşan hata değerleri sırasıyla Tablo 4.3 ve Tablo 4.4’te verildiği gibidir.


Tablo 4.3
LSTM Modelleri Korelogram Sonuçları (%67 eğitim seti)

LSTM Modellerinin Karşılaştırılması				
Epoch	MAE	MSE	RMSE	MAPE
1000	876.925	1086744.667	1042.470	0.309
1500	1055.303	1543692.874	1242.454	0.364
2000	1223.365	2021929.469	1421.946	0.406
2500	1332.994	2450055.299	1565.265	0.445

Tablo 4.4
LSTM Modelleri Korelogram Sonuçları (%73 eğitim seti)

LSTM Modellerinin Karşılaştırılması				
Epoch	MAE	MSE	RMSE	MAPE
1000	687.389	661910.062	813.579	0.245
1500	795.090	954889.250	977.184	0.275
2000	900.901	1261486.750	1123.159	0.297
2500	1027.180	1895367.375	1376.723	0.318

Hem %67 eğitim seti hem de %73 eğitim seti ile yapılan uygulamalarda Tablo 4.3 ve 4.4'te de görüldüğü üzere 1000 epoch ile eğitilen modellerin ürettiği sonuçlar en düşük hata oranına sahiptir. Burada üretilen sonuçlara bakıldığında, ulaşılan MAPE değerine göre başarılı bir tahminlemenin gerçekleştiği söylenebilir. Her iki eğitim seti ile eğitilen ağ modellerin oluşturduğu tahmin sonuçlarına ait grafik gösterimler Şekil 4.5 ve Şekil 4.6'da verilmiştir.



Şekil 4.5: LSTM Modeli (1000 epoch) ve Gerçek Veri Seti Karşılaştırma Grafiği (%67 eğitim)



Şekil 4.6: LSTM Modeli (1000 epoch) ve Gerçek Veri Seti Karşılaştırma Grafiği (%73 eğitim)

Şekillerde de görüldüğü gibi LSTM modelleri az veri ile iyi sonuçlar üretmeyi başarmış ve başarı kriter değerlendirmesi olan 0.245 MAPE değeri ile %73'lük eğitim veri seti eşlemesine göre ARIMA modeline göre daha düşük bir hata değeri üretmiştir. Diğer taraftan %67'lik eğitim veri seti kıyaslamasında da ARIMA modeli daha düşük bir hata değeri üretmiştir. Bu karşılaştırma sonucunda, LSTM modeli ile ARIMA modelinin birbirine yakın değerler vermesiyle benzerlik gösterdiği söylenebilir.

4.2.4. Hibrit Model Uygulama Sonuçları


Çalışmanın bu kısmında Şekil 3.19'da tasarımı verilen hibrit model ile diğer modellerde olduğu gibi farklı yüzdelerle eğitim setleri kullanılarak tahmin denemeleri gerçekleştirilmiştir. Hibrit model için LSTM ve ARIMA modellerinin tüm ihtimalleri belirtilen algoritma ile denenmiş ve elde edilen bütün sonuçlar büyük tablolar oluşturduğundan çalışmanın ek kısmında verilmiştir. Tahminlemenin başarısını anlatmak üzere bu kısımda elde edilen sonuçlara ait özet gösterimler Tablo 4.5'te sunulmuştur.

Tablo 4.5
Hibrit Model Korelogram Sonuçları (%67 eğitim seti)

Hibrit Modellerin Karşılaştırılması					
LSTM epoch	ARIMA(p,d,q)	MAE	MSE	RMSE	MAPE
1000	(0, 1, 0)	474.901	539710.087	734.650	0.173
	(0, 1, 1)	473.856	505515.043	710.996	0.176
	(1, 1, 1)	547.064	550803.800	742.162	0.203
	(1, 2, 0)	454.536	574853.193	758.191	0.166
	(2, 1, 0)	471.357	523651.351	723.638	0.175
	(2, 2, 0)	455.894	562571.828	750.048	0.167
1500	(0, 1, 0)	441.230	517109.254	719.103	0.158
	(0, 1, 1)	439.884	483443.968	695.301	0.162
	(1, 1, 1)	519.856	520319.460	721.332	0.192
	(1, 2, 0)	425.395	576725.599	759.425	0.151
	(2, 1, 0)	439.576	500267.806	707.296	0.161
	(2, 2, 0)	440.020	582412.655	763.160	0.156
2000	(0, 1, 0)	435.374	484493.392	696.056	0.151
	(0, 1, 1)	438.542	462836.972	680.321	0.157
	(1, 1, 1)	525.968	501871.120	708.429	0.190
	(1, 2, 0)	406.268	556548.101	746.022	0.143
	(2, 1, 0)	436.966	472535.368	687.412	0.156
	(2, 2, 0)	427.079	572413.420	756.580	0.150
2500	(0, 1, 0)	437.287	497100.030	705.053	0.155
	(0, 1, 1)	439.369	474126.965	688.569	0.161
	(1, 1, 1)	538.044	529362.677	727.573	0.198
	(1, 2, 0)	418.051	596092.088	772.070	0.148
	(2, 1, 0)	436.265	481295.563	693.755	0.159
	(2, 2, 0)	441.840	614257.378	783.746	0.157

Tablodaki %67'lik eğitim seti ile elde edilen değerler incelendiğinde hem LSTM ağı hem de ARIMA modellerinin elde ettiği sonuçlardan çok daha başarılı sonuçlara ulaşıldığı görülmektedir. Bu eğitim setindeki en başarılı tahminlemenin LSTM (2000 epoch) ile ARIMA (1, 2, 0) modelinin ürettiği 0,143 MAPE değerli çalışma olduğu söylenebilir. Bu hata değeri, diğer tekli modellerin ürettiği hata değerleri ile karşılaştırıldığında çok daha düşük bir değere sahip olmasından dolayı oldukça başarılı bir sonucun elde edildiği görülmektedir. Bu durum, literatürdeki örneklerde de bahsedildiği gibi hibrit modellerin tekli modellere göre daha iyi sonuçlar verdiğinin ve başarılı sonuçlara ulaşmak için

kullanılabileceğinin bir göstergesidir. Tablo 4.5'te de görüldüğü üzere bu eğitim seti, 4 adet (1000, 1500, 2000, 2500) farklı epoch değerleri ile eğitilmiştir. Daha fazla epoch sayısının denenmemesinin sebebi, büyüyen epoch değerlerine bağlı olarak tahmin sonuçlarının büyümeye yani kötüleşmeye başlamasıdır. LSTM 2500 epoch değerine bakıldığında 2000 epoch sonuçlarına göre hata değerlerinin arttığı gözlemlendiğinden daha yüksek sayıdaki eğitimlere gerek duyulmamıştır. En iyi tahmin olarak belirlenen LSTM (2000 epoch)-ARIMA(1,2,0) modelinin tahmin sonuçları ve gerçek değerlere ilişkin çıktı grafiği Şekil 4.7'de verilmiştir.




Şekil 4.7: Hibrit Model ve Gerçek Veri Seti Karşılaştırma Grafiği (%67 eğitim seti)

Şekilden anlaşılacağı üzere modelin tahmini gerçek veri grafiği ile oldukça örtüşmektedir. Bu durum, tahminlemenin oldukça başarılı olduğunun bir göstergesidir. Özellikle trend kırılımlarına bakıldığında tahmin grafiğinin çok küçük farklılıklar dışında sanki gerçek grafik ile birebir aynı gibi davrandığı gözlemlenebilmektedir. Diğer taraftan, kullanılan modelin daha da iyileştirilmesi adına eğitim seti %73'e çıkarılıp LSTM ve ARIMA modelleri ile farklı denemelerde bulunulmuştur. %73'lik eğitim seti için yine tüm ARIMA modelleri kullanılmış LSTM epoch değerlerinden de 8 farklı (1000, 1500, 2000, 2500, 3000, 3500, 4000, 4500) değer ile deneme çalışmaları gerçekleştirilmiştir. 3500 epoch değerinden sonraki denemelerde hata değeri büyüme gösterdiğinden epoch değeri artırımı durdurulmuştur. Yapılan tahminlemelerde elde edilen sonuçlara ait özet gösterim Tablo 4.6'da verilmiştir. Modellerin tüm değerlerinin sonuçları ise çalışmanın

ek kısmında sunulmuştur. Tablodaki elde edilen değerlere göre LSTM 3500 epoch ve ARIMA(1,2,0) modellerinin oluşturduğu hibrit modelin ürettiği hata değerinin 0,133 MAPE değeri olduğu görülmektedir. Bu durum, %67'lik eğitim seti ile oluşturulan modele göre çok başarılı bir sonuç edildiğini göstermektedir. Bu modele ait grafiksel gösterim Şekil 4.8'de görüldüğü gibidir.

Tablo 4.6
HYBRID Model Korelogram Sonuçları (%73 eğitim seti)

Hibrit Modellerin Karşılaştırılması					
LSTM epoch	ARIMA(p,d,q)	MAE	MSE	RMSE	MAPE
1000	(0, 1, 0)	459.247	491694.830	701.210	0.185
	(1, 2, 0)	431.770	444982.797	667.070	0.180
	(2, 1, 0)	473.266	515363.694	717.888	0.188
1500	(0, 1, 0)	461.439	481297.330	693.756	0.181
	(1, 2, 0)	421.336	447043.373	668.613	0.171
	(2, 1, 0)	471.049	503728.652	709.738	0.182
2000	(0, 1, 0)	442.282	459427.418	677.811	0.172
	(1, 2, 0)	409.096	463999.091	681.175	0.165
	(2, 1, 0)	446.925	471641.035	686.761	0.170
2500	(0, 1, 0)	413.791	484388.432	695.980	0.157
	(1, 2, 0)	360.368	474134.222	688.574	0.141
	(2, 1, 0)	432.843	509609.739	713.870	0.161
3000	(0, 1, 0)	408.578	533826.667	730.634	0.155
	(1, 2, 0)	344.138	480333.312	693.061	0.135
	(2, 1, 0)	445.409	578365.642	760.504	0.166
3500	(0, 1, 0)	407.097	537043.602	732.833	0.154
	(1, 2, 0)	338.184	470006.272	685.570	0.133
	(2, 1, 0)	446.167	585519.850	765.193	0.166
4000	(0, 1, 0)	416.356	531732.634	729.200	0.156
	(1, 2, 0)	342.317	452430.129	672.629	0.134
	(2, 1, 0)	447.486	581406.834	762.500	0.163
4500	(0, 1, 0)	408.811	538732.181	733.984	0.157
	(1, 2, 0)	339.349	463405.842	680.739	0.136
	(2, 1, 0)	448.035	588540.125	767.164	0.169



Şekil 4.8: Hibrit Model ve Gerçek Veri Seti Karşılaştırma Grafiği (%73 eğitim seti)

Şekilde de görüldüğü gibi gerçek veri grafiği ile Hibrit veri grafiği (%73 eğitim seti) birbirine yakın seviyelerdedir. Hatta bazı dönemlerde kesişme mevcuttur. Ancak, 2. ve 21. aylarda gerçek veri grafiği azalış gösterirken, hibrit grafikte artış; 19. ayda ise tam tersi bir durum ortaya çıkmıştır. Bu durumun ekonomik koşullar, sektörel arz talep değişiklikleri, uygulanan işletme politikaları vb. durumlarla açıklanabilmesi mümkündür. Ancak net bir sebep belirtilebilmesi için işletme yetkilileri ile görüşülmesi daha uygun olacaktır.

SONUÇ

Günümüzde rekabet koşullarına ve hızlı değişen teknolojik gelişmelere bağlı olarak yaşamlarını devam ettirmek ve geliştirmek isteyen işletmeler, kurumlar ve uluslar geleceğe dönük plan yapmak zorundadırlar. İşletmelerde satış tahminlerinin oluşturduğu satış miktar bütçeleri daha önce de belirtildiği gibi diğer bütçelerin hazırlanmasında temel teşkil ettiği için doğru ve güvenilir bir biçimde hazırlanmalıdır.

Bu tez çalışmasında inşaat sektöründe faaliyet gösteren bir işletmenin ürün satış verileri tahmin edilmiştir. Rekabet unsurları ve firma yetkililerinin isteği üzerine firma ve ürün bilgisi saklı tutulmuştur. Ayrıca ürün miktar verileri gizlilik açısından oransal olarak değiştirilmiştir. Veriler, satış müdürü ve muhasebe müdürü ile görüşmeler yaparak sağlanmıştır.

Talep tahmini amacıyla 2010-2017 yıllarına ilişkin aylık satış verileri kullanılmıştır. Satış miktar tahmininde ARIMA, LSTM ve bu iki modelden oluşturulan bir hibrit metottan faydalanılmıştır. Modeller sonucunda 2017 yılı için satış miktar bütçesi oluşturularak karşılaştırma yapılmıştır.

Çalışmada kullanılan “*Ürün Satışları*” serisine ilişkin aylık satış verileri için iki farklı model ve bu modellerin birleşiminden elde edilen bir hibrit model kullanılarak tahminlemeler yapılmıştır. Aynı zamanda bu tahminlemeler farklı eğitim setleri ile eğitilerek de çeşitli denemelerde bulunulmuştur. Modellerin tahminlemeleri ve bu tahminlemelerin karşılaştırılmaları için ilk olarak, veri setinin %67’si modellerin eğitimi için ayrılmış, geriye kalan %37’lik kısım test verisi olarak kullanılmıştır. Diğer taraftan ikinci bir durum olarak ise, %73’lük bir eğitim seti ve %23’lük test verisi ile denemeler gerçekleştirilmiştir.

Veriler düzenlendikten sonra çeşitli kriterler sonucunda en iyi olarak belirlenen ARIMA yöntemi kullanılarak %67 ve %73 eğitim veri seti için ayrı ayrı tahmin çalışması gerçekleştirilmiştir. Elde edilen sonuçlar birbiriyle karşılaştırılmış ve en küçük RMSE ve MAPE değerine sahip olan uygulama en iyi uygulama sonucu olarak belirlenmiştir. Daha sonra aynı eğitim veri setleri kullanılarak son yıllarda giderek kullanımı yaygınlaşan derin öğrenme yöntemlerinden LSTM ile de tahmin çalışması gerçekleştirilmiştir. LSTM ile tahmin aşamasında farklı epoch sayıları ile denemeler gerçekleştirilmiş ve MAPE

değerleri artmaya başladığında denemeler bırakılmıştır. Yine elde edilen sonuçlarda en düşük MAPE değerine sahip olan epoch sayılı deneme en iyi sonucu veren yöntem olarak ifade edilmiştir. Bu metotlara ek olarak iki farklı metodun avantajlarının birleşimiyle daha iyi sonuç alınabileceği düşünülen bir hibrit metot oluşturulmuştur. Oluşturulan bu hibrit metot kullanılarak satış verileri tahmin edilmiştir. Uygulama sonucunda ise tüm modellerden elde edilen satış tahmini değerleri birbirleriyle karşılaştırılmıştır. Buna ilişkin değerler aşağıdaki tabloda gösterildiği gibidir.

Tablo 4.7
ARIMA, LSTM ve Hibrit Modellerin Karşılaştırılması

Modellerin Karşılaştırılması					
Eğitim Seti (%)	MODEL	MAE	MSE	RMSE	MAPE
67	ARIMA(1,0,0)	672.267	681849.325	825.742	0.234
	LSTM (1000 epoch)	876.925	1086744.667	1042.470	0.309
	HYBRİD (LSTM 2000 epoch-ARIMA(1,2,0))	406.268	556548.101	746.022	0.143
73	ARIMA(1,0,0)	710.461	760316.150	871.961	0.254
	LSTM (1000 epoch)	687.389	661910.062	813.579	0.245
	HYBRİD (LSTM 3500 epoch-ARIMA(1,2,0))	338.184	470006.272	685.570	0.133

Tablo 4.7’de görüldüğü gibi ARIMA, LSTM ve hibrit modellerin %67’lik eğitim seti için RMSE değerleri sırasıyla 825.742, 1042.470 ve 746.022 olarak hesaplanırken %73’lük eğitim seti için 871.961, 813.579, 685.570 olarak hesaplanmıştır. RMSE değerleri dikkate alındığında her iki eğitim seti içinde hibrit modelin daha iyi sonuç verdiği görülmektedir. MAPE değerlerinin ise %73’lük eğitim setinde hibrit model için 0.133, ARIMA için 0.254 ve LSTM model için 0.245 olarak hesaplandığı görülmektedir. Benzer şekilde MAPE değerleri açısından yapılan kıyaslamada da hibrit modelin diğer iki modele kıyasla ve her iki eğitim seti içinde daha iyi sonuçlar verdiği gözlemlenmiştir.

RMSE değerleri dikkate alındığında hibrit model en başarılı durumda olup, ARIMA modeli ile yapılan tahminlere göre yaklaşık %16.9’luk, LSTM modeli ile yapılan tahminlere göre ise %15.7’lik bir performans artışı sağlamıştır. Aynı şekilde MAPE başarı kriteri açısından Hibrit model ile ARIMA modeline göre yaklaşık %43.2, LSTM

modeline göre ise %45.7 daha iyi tahmin sonuçları elde edilmiştir. Hem yapılan bu çalışma hem de literatürdeki diğer çalışmaların birçoğu zaman serilerini tek bir yöntemle tahmin etmek yerine veri setindeki farklı fonksiyonel ilişkileri modelleyebilen birden fazla yöntemi birleştirerek tahminler yapmanın daha etkin sonuçlar verdiğini açıkça göstermektedir. Çalışma sonucunda elde edilen bulgular da bunu doğrular niteliktedir. Ayrıca elde edilen sonuçlar işletmenin gerçek satış verileri ile de karşılaştırılmıştır. Gerçek verilere en yakın değerlerin hibrit metottan elde edildiği sonucuna ulaşılmıştır.


Çalışma kapsamında işletmenin 2017 yılına ait oluşturulan satış miktar bütçesi verileri Tablo 4.8’de verilmiştir. Bu verilere ait grafiksel gösterim ise Şekil 4.9’daki gibidir. Daha önce de belirtildiği gibi Tablo 4.8’deki satış miktar bütçesi verileri veri gizliliği sebebi ile belirli bir matematiksel işlemler sonucunda elde edilen değerler olarak sunulmuştur. Tüm verilere aynı formül uygulandığından gerçek verilere ait grafik gösterimi ile değiştirilmiş verilerin grafik gösterimi arasında y eksenindeki değersel genişlik dışında trend yönü farklılığı söz konusu olmayacaktır.

Tablo 4.8
Kullanılan Yöntemlere Göre 2017 Yılı (Aylık) Satış Miktarları Bütçesi*

2017	ARIMA (1,0,0) %67 Eğitim Seti	ARIMA (1,0,1) %67 Eğitim Seti	ARIMA (1,0,0) %73 Eğitim Seti	ARIMA (1,0,1) %73 Eğitim Seti	LSTM 1000 epoch %67 Eğitim Seti	LSTM 1000 epoch %73 Eğitim Seti	Hibrit (LSTM 2000 epoch-ARIMA (1,2,0) %67 Eğitim Seti	Hibrit (LSTM 3500 epoch-ARIMA (1,2,0) %73 Eğitim Seti
Ocak	1.506,59	1.504,03	1.506,59	1504,03	1.432,97	1.545,58	1.931,63	1.895,71
Şubat	1.799,67	1.799,27	1.799,67	1799,27	1.795,62	1.834,77	2.175,44	2.119,73
Mart	1.864,77	1.869,62	1.864,77	1869,62	2.089,70	1.787,01	2.069,41	2.069,41
Nisan	1.845,15	1.854,82	1.845,15	1854,82	1.729,90	1.698,89	2.026,57	2.024,84
Mayıs	1.904,75	1.916,16	1.904,75	1916,16	1.695,62	1.724,11	1.680,17	1.680,17
Haziran	1.553,24	1.572,34	1.553,24	1572,34	1.807,39	1.800,02	1.011,21	1.011,21
Temmuz	1.041,38	1.029,33	1.041,38	1029,33	1.041,69	1.362,86	811,73	783,25
Ağustos	1.432,23	1.420,87	1.432,23	1420,87	1.019,20	1.215,54	1.480,33	1.306,47
Eylül	885,77	920,44	885,77	920,44	1.532,70	1.258,78	818,63	893,67
Ekim	992,23	981,90	992,23	981,90	1.185,93	915,39	1.142,19	1.142,19
Kasım	1.139,57	1.126,58	1.139,57	1126,58	1.085,80	1.226,14	888,74	888,74
Aralık	955,60	964,79	955,60	964,79	609,78	938,09	800,78	572,02

*Aylara ait miktar verileri şirket bilgi gizliliği sebebi ile belirlenen bir matematiksel formül ile değiştirilerek sunulmuştur.

Yukarıdaki tabloda, uygulamanın gerçekleştirildiği işletmenin ürettiği ürüne ilişkin 2017 yılı bütçelenmiş satış miktar verileri yer almaktadır. Karşılaştırmada kolaylık sağlanması açısından ARIMA, LSTM ve Hibrit metotların iki ayrı eğitim veri seti türüne göre elde edilen tahmin sonuçlarının tümü tek bir tablo halinde düzenlenmiştir.



Şekil 4.9: Satış Miktar Tahminlerinin Yöntemlere Göre Karşılaştırılması

Yukarıdaki grafik uygulamada kullanılan yöntemlerden elde edilen satış tahminlerinin karşılaştırmasını vermektedir. Grafikselsel gösterimde gerçekleşen satış verileri de çizime dahil edilmiştir. Şekilden de görüldüğü üzere kullanılan yöntemlerin tümünde aşırı bir sapma meydana gelmemiştir. Gerçek veri grafiğı ile tahmin grafikleri birbirine yakın seviyelerde oluşmuştur. Sadece bazı aylarda gerçek veri grafiğinde artış/azalış (örneğin Temmuz-Ağustus gibi) oluşmuş iken tahmin grafiklerinde azalış/artış gibi zıt bir sonuç elde edilmiştir. Bu durum, ekonomik koşullardaki değışiklik, sektöre olan talepteki farklılık vb. nedenlerle açıklanabilir. Elde edilen sonuçların birbirine yakın seviyelerde olmasından dolayı yöntemlerin tümü daha önce de belirtildiğı gibi işletmenin satış miktar bütçelerinin oluşturulmasında kullanılabilir. Ancak, amaç gerçeğe en yakın bir şekilde tahmin olduğundan en iyi sonuç uygulamada kullanılan hibrit modelden alındığı için en iyi yöntemin bu yöntem olduğunu belirtmek mümkündür.

Gelecek Çalışmalar İçin Öneriler:

- ✓ Çalışmada ARIMA, LSTM ve bu iki modelden oluşturulan hibrit yöntem kullanılarak satış tahminleri gerçekleştirilmiştir. Daha sonraki çalışmalarda satış tahmini için farklı yöntemler denenerek elde edilen sonuçlar karşılaştırılabilir.
- ✓ Uygulama inşaat sektöründe kullanılan bir ürünün üretimini gerçekleştiren bir işletme üzerinde gerçekleştirilmiştir. Gelecek çalışmalarda, farklı sektörlerdeki sonuçları ortaya çıkarmak amacıyla hizmet işletmeleri ya da farklı sanayi dallarına yönelik uygulamalar gerçekleştirilebilir.
- ✓ Çalışmada sadece işletmenin ürettiğı tek bir ürüne yönelik satış miktar tahminleri gerçekleştirilmiştir. Sonraki çalışmalarda hem birden fazla ürüne yönelik tahminler gerçekleştirilebilir.
- ✓ Yapılan satış tahminleri satış bütçelerinin düzenlemesinde kullanılmıştır. Daha sonraki çalışmalarda işletmenin diğers bütçelerinin düzenlenmesi için tahmin çalışmaları yapılabilir.

KAYNAKÇA

Kitaplar

- Akdoğan, N. (2009). *Tekdüzen Muhasebe Sisteminde Maliyet Muhasebesi Uygulamaları* (8 b.), Ankara: Gazi Kitapevi.
- Aksoy, Ş. (1991). *Kamu Maliyesi*, İstanbul: Filiz Kitabevi.
- Andersan: (2003). *Practical Business Forecasting*, Oxford, UK: Blackwell Publishing.
- Anderson, D. R., Sweeney, D. J., Williams, T. A., Camm, J. D., Cochran, J. J., J.Fry, M., & Ohlman, J. W. (2014). *An Introduction to Management Science: Quantative Approaches to Decision Making* (8th Edition b.), United States of America.
- Anderson, P., & McNeill, G. (1992). *Artificial Neural Networks Technology* (Cilt 39), New York: Kaman Sciences Corporation.
- Büker: (2001). *Finansal Yönetim*, Eskişehir: Anadolu Üniversitesi Yayınları.
- Büyükmirza, K. (2007). *Maliyet ve Yönetim Muhasebesi*, Ankara: Gazi Kitabevi.
- Çam: (2009). *İşletmelerde Pratik Bütçe Yönetimi*, İstanbul: Hayat Yayın Grubu.
- Demir, M. H., & Gümüšoğlu, Ş. (2011). *Üretim Yönetimi (İşlemler Yönetimi)* (7 b.), İstanbul: Beta Yayınları.
- Doğan, M. (2007). *İşletme Ekonomisi ve Yönetimi*, İzmir: Nobel Yayınları.
- Elmas, Ç. (2003). *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*, Ankara: Seçkin Yayınevi.
- Elmas, Ç. (2007). *Yapay Zeka Uygulamaları*, Ankara: Seçkin Yayıncılık.
- Ercan, M. K., & Ban, Ü. (2014). *Finansal Yönetim (Değere Dayalı İşletme Finansı)* (8 b.), Ankara: Gazi Kitabevi.
- Göktaş, Ö. (2005). *Teorik ve Uygulamalı Zaman Serileri Analizi*, İstanbul: Beşir Kitabevi.
- Gujarati, D. N. (2008). *Basic Econometrics* (5th b.), United States: United States Military Academy, West Point.
- Gürsoy, C. T. (2007). *Finansal Yönetim İlkeleri*, İstanbul: Doğu Üniversitesi Yayınları.
- Haftacı, V. (2005). *İşletme Bütçeleri* (4 b.), İstanbul: Beta Yayınevi.
- Heize, J., & Render, B. (2011). *Operations Management* (10 b.), United States of America: Pearson International Edition.
- Kadılar, C. (2005). *SPSS Uygulamalı Zaman Serileri Analizine Giriş*, Ankara: Bizim Büro Basımevi.

- Kendal, M. (1973). *The Advanced Theory of Statics*, London: Charles Griffin.
- Kobu, B. (2008). *Üretim Yönetimi* (14 b.), İstanbul: Beta Basım.
- Koç, Y. Y. (1989). *Yönetim Aracı Olarak İşletme Bütçeleri* (3 b.), Ankara: Turhan Kitapevi.
- Köksal, B. A. (2003). *İstatistik Analiz Metodları* (6 b.), İstanbul: Çağlayan Kitabevi.
- Lalli, W. R. (2003). *Handbook of Budgeting* (5 b.), ABD: John Wiley&Sons Inc.
- Monks, J. G. (1996). *İşlemler Yönetimi Teori ve Problemler*, (S. Üreten, Çev.) Ankara: Nobel Yayın Dağıtım.
- Montgomery, C., Peck, A., & Vining, G. (2013). *Doğrusal Regresyon Anaizine Giriş* (5 b.), Ankara: Nobel Akademik Yayıncılık.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2008). *Introduction to Time Series Analysis and Forecasting*, United States of America: John Wile&Sons Inc.
- Moore, C., & Jaedicke, R. K. (1988). *Yönetim Muhasebesi*, (4 b.). (A. Peker, Çev.) İstanbul: Fatih Yayınevi.
- Nasuhi, B., & Yücel, E. (2002). *Maliyet Muhasebesi* (9 b.), İstanbul: Der Yayınları.
- Orhunbilge, N. (1999). *Zaman Serileri Analizi Tahmin ve Fiyat İndeksleri*, İstanbul: Avcıol Basım Yayın.
- Öztemel, E. (2012). *Yapay Sinir Ağları*, İstanbul: Papatya Yayıncılık.
- Parkhurst, A. (1992). *Evaluation of Order Determination Prosedures in ARMA Models*, Nebraska: Presented to The Faculty of The Graduate Collage at The University of Nebraska.
- Peker, A. (1988). *Modern Yönetim Muhasebesi*, İstanbul: İstanbul Üniversitesi İşletme Fakültesi Muhasebe Enstitüsü.
- Pekiner, K. (1988). *İşletme Denetimi*, İstanbul: İstanbul Üniversitesi Yayınları.
- Sevgener, A., & Hacırüstemoğlu, R. (2000). *Yönetim Muhasebesi* (7 b.), İstanbul: Alfa Yayınları.
- Shim, J. K. (2005). *Budgeting Basics & Beyond* (2 b.), ABD: John Wiley & Sons Inc.
- Tekin, M. (2009). *Üretim Yönetimi* (Cilt I), Konya: Günay Ofset.
- Tsay, R. S. (2005). *Analysis of Financial Time Series* (2 b.), United States of America: John Wiley & Sons.
- Tsay, R. S. (2014). *Analysis of Financial Time Series*, Canada: John Wiley & Sons.
- Tütek, H., & Gümüšoğlu, Ş. (2000). *İşletme İstatistiği*, İzmir: Barış Yayınları.

Usta, Ö. (2008). *İşletme Finansı ve Finansal Yönetim* (3 b.), Ankara: Detay Yayıncılık.

Üreten: (2005). *Üretim/İşlemler Yönetimi, Stratejik Kararlar ve Karar Modelleri*, Ankara: Gazi Kitabevi.

Welsch, A. G. (1971). *İşletme Bütçeleri* (3 b.), Ankara, ABD: Bilimsel Yayınlar Derneği.



Sürelî Yayınlar

- Adeva, J. J., Beresi, U. C., & Calvo, R. A. (2005). Accuracy and Diversity in Ensembles of Text Categorisers. *CLEI Electronic Journal*, 8(2), 1-12. doi:DOI: 10.19153/cleiej.12.1.
- Akaike, H. (1969). Fitting Autoregressive Model for Prediction. *Annals of The Institute of Statistical Mathematics*(21), 243-247.
- Aktan, C. C. (1998). “Geleceği Kazanmanın Yolu: Stratejik Yönetim . *Yeni Türkiye*,, 335-342.
- Aladağ, Ç. H., Eğrioğlu, E., & Kadılar, C. (2009). Forecasting Nonlinear Time Series with a Hybrid Methodology. *Applied Mathematics Letters*(22), 1467-1470. doi:https://doi.org/10.1016/j.aml.2009.02.006.
- Albayrak, A. S. (2010). ARIMA Forecasting of Primary Energy Production and Consumption in Turkey: 1923–2006. *Enerji, Piyasa ve Düzenleme*, 24-50.
- Armano, G., Marchesi, M., & Murru, A. (2005). A Hybrid Genetic-Neural Architecture for Stock Indexes Forecasting. *Information Sciences*(170), 3-33.
- Babu, C. N., & Reddy, B. E. (2014). A Moving-Average Filter Based Hybrid ARIMA–ANN Model for Forecasting Time Series Data. *Applied Soft Computing*(23), 27-38. doi:https://doi.org/10.1016/j.asoc.2014.05.028.
- Bengio, Y., Simard, P., & Franscon, P. (2015). Learning Long-Term Dependencies with Gradient Descent is Difficult. *IEEE Trans. Neural Networks*, 5(2), 157-166.
- Beran, J., Bhansali, R., & Ocker, D. (1998). On Unified Model Selection for Stationary and Nonstationary Short and Long Memory Autoregressive Processes. *Biometrika*(85), 921-934.
- Berikol, B. Z. (2010, Aralık). İşletmelerde Bütçeleme Süreci: Adana'da Faaliyet Gösteren Bir İşletmede Uygulama. *Çukurova Üniversitesi İİBF Dergisi*, 14(2), 11-31.
- Bircan, H., & Karagöz, Y. (2003). Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama. *Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 6(2), 49-62. Şubat 10, 2017 tarihinde <http://dergipark.gov.tr/download/article-file/252067> adresinden alındı.
- Chen, L., & Szroeter, J. (2016). Extension of The Schwarz Information Criterion for Models Sharing Parameter Boundaries. *Science Direct Journal*, 42(9), 7-8.
- Dalkey, N., & Helmer, O. (1962). An Experimental Application of the Delphi Method to the Use of Experts. *The RAND Corporation*, 458-467.
- Ediger, V. Ş., & Akar: (2007). ARIMA Forecasting of Primary Energy Demand by Fuel in Turkey. *Energy Policy*, 1701-1708. doi:https://doi.org/10.1016/j.enpol.2006.05.009.

- Erdoğan, E. (2007). Electricity Demand Analysis Using Cointegration and ARIMA Modelling: A Case Study of Turkey. *Energy Policy*, 1129-1146. doi:<https://doi.org/10.1016/j.enpol.2006.02.013>.
- Gers, F., Schmidhuber, J., & Cummins, F. (2000). Learning to Forget: continual Prediction with LSTM. *Neural Computation Journal*, 12(10), 2451-2471.
- Hocaoğlu, F. O., Kaysal, K., & Kaysal, A. (2015). Yük Tahmini İçin Hibrit (YSA ve Regresyon) Model. *Akademik Platform*, 33-39. doi:DOI: 10.5505/apjes.2015.94695.
- Hochreiter, & Schmidhuber, J. (1997). Long ShortTerm Memory. *Neural Computing*, 9(8), 1735-1780.
- Ioannou, K., Birbilis, D., & Lefakis, P. (2011). A Method for Predicting the Possibility of Ring Shake Appearance on Standing Chestnut Trees. *Journal of Environmental Protection and Ecology*, 295-304. <https://docs.google.com/a/jepe-journal.info/viewer?a=v&pid=sites&srcid=amVwZS1qb3VybmFsLmluZm98amVwZS1qb3VybmFsGd4OjJkYzQwODIyZjE4ZmJmMzQ> adresinden alındı.
- Khandelwal, I., Adhikari, R., & Verma, G. (2015). Time Series Forecasting using Hybrid ARIMA and ANN Models based on DWT Decomposition. *Procedia Computer Science*(48), 173-179.
- Khashei M., H. S. (2008). A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting. *Fuzzy Sets and Systems*(159), 769-786. doi:<https://doi.org/10.1016/j.fss.2007.10.011>.
- Khashei, M., & Bijari, M. (2010). An Artificial Neural Network (p, d,q) Model for Time Series Forecasting. *Expert Systems with Applications*(37), 479-489.
- Khashei, M., Bijari, M., & Ardali, G. (2012). Hybridization of Autoregressive Integrated Moving Average (ARIMA) with Probabilistic Neural Networks. *Computers & Industrial Engineering*(63), 37-45.
- Khashei, M., Hejazi: R., & Bijari, M. (2008). A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting. *Fuzzy Sets and Systems*(159), 769-786. doi:<https://doi.org/10.1016/j.fss.2007.10.011>.
- Kılıç, R., & Demirbaş, E. (2012). Türkiye’de Kamu İnşaat Harcamalarının Belirleyicileri ile Ekonomik Büyüme Arasındaki İlişki. *Akademik Yaklaşımlar Dergisi*, 3(2), 84-97.
- Kim, H., & Shin, K. (2007). A Hybrid Approach Based on Neural Networks and Genetic Algorithms for Detecting Temporal Patterns in Stock Markets. *Applied Soft Computing*(7), 569-576.
- Koutroumanidis, T., Ioannou, K., & Zafeiriou, E. (2011). Forecasting Bank Stock Market Prices with A Hybrid Method: The Case of Alpha Bank. *Journal of Business Economics and Management*, 12(1), 144-163. doi:<https://doi.org/10.3846/16111699.2011.555388>.

- Koutroumanidis, T., Ioannoub, K., & Arabatzis, G. (2009). Predicting Fuelwood Prices in Greece With the Use of ARIMA Models, Artificial Neural Networks and a Hybrid ARIMA–ANN Model. *Energy Policy*(37), 3627-3634. doi:<https://doi.org/10.1016/j.enpol.2009.04.024>.
- Kurach, K. (2016). *Deep Neural Architectures for Algorithms and Sequential Data*. Institute of Informatics University of Warsaw.
- Lee, C., & Ko, C. (2011). Short-term Load Forecasting Using Lifting Scheme and ARIMA Models. *Expert Systems with Applications*, 38(5), 5902-5911.
- Lin, T., Guo, T., & Aberer, K. (2017). Hybrid Neural Networks for Learning the Trend in Time Series. *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*, (s. 2273-2279). Melbourne, Australia. doi:<https://doi.org/10.24963/ijcai.2017/316>.
- Luxhoj, J., Riis, J., & Stensballe, B. (1996). A Hybrid Econometric-Neural Network Modeling Approach for Sales Forecasting. *International Journal of Production Economics*(45), 175-192.
- Mkolov, T., Karafiat, M., Lukas, B., Cernocky, J., & Khundapur: (2010). Recurrent Neural Network Based Language Model. *Interspeech 2010 11th Annual Conference of the International Speech Communication Association* (s. 1045-1048). Makuhari, Chiba, Japan: In INTERSPEECH-2010.
- Newbold, P. (1983). ARIMA Model Building and The Time Series Analysis Approach to Forecasting. *Journal of Forecasting*, 2(1), 23-35.
- Oliveira, M., & Torgo, L. (2014). Ensembles for Time Series Forecasting. *In Proceedings of the Sixth Asian Conference on Machine Learning*, (s. 360-370). <http://proceedings.mlr.press/v39/oliveira14.pdf> adresinden alındı.
- Opitz, D., & Maclin, R. (1999). Popular Ensemble Methods: An Empirical Study. *Journal of Artificial Intelligence Research*, 11, 169–198. doi:<https://doi.org/10.1613/jair.614>.
- Özdemir, A., & Özdemir, A. (2006). Talep Tahminlemede Kullanılan Yöntemlerin Karşılaştırılması: Seramik Ürün Grubu Firma Uygulaması. *Ege Akademik Bakış Dergisi*, 6 (2), 105-114.
- Pablo, B. J., Hilda, C., Xavier, A., Diego, J. J., Felipe:, & Henry, B. (2016). Artificial Neural Network and Monte Carlo Forecasting with Generation of L-Scenarios. *2016 Intl IEEE Conferences on Ubiquitous Intelligence & Computing, Advanced and Trusted Computing, Scalable Computing and Communications, Cloud and Big Data Computing, Internet of People and Smart World Congress*, (s. 665-670). doi:10.1109/UIC-ATC-ScalCom-CBDCCom-IoP-SmartWorld.2016.0110.
- Pagourtzi, E., Assimakolopoulos, V., Hatzichristons, T., & French, N. (2003). Real Estate Appraisal: A Review of Valuation Methods. *Journal of Property Investment & Finance*, 21(4), 383-401.

- Papagera, A., Ioannou, K., Zaimes, G., Iakovoglou, V., & Simeonidou, M. (2014). Simulation and Prediction of Water Allocation Using Artificial Neural Networks and a Spatially Distributed Hydrological Model. *Agris on-line Papers in Economics and Informatics*, 6(4), 101-111. <https://ageconsearch.umn.edu/record/196580/> adresinden alındı.
- Sallehuddin, R., Shamsuddin: M., Hashim: Z., & Abraham, A. (2007). Forecasting Time Series Data Using Hybrid Grey Relational Artificial Neural Network and Auto Regressive Integrated Moving Average Model. *ICS AS CR 2007*, (s. 573-605). https://www.researchgate.net/publication/287522177_Forecasting_time_series_data_using_hybrid_grey_relational_artificial_neural_network_and_auto_regressive_integrated_moving_average_model adresinden alındı.
- Soy Temür, A., Akgün, M., & Temür, G. (2019). Predicting Housing Sales In Turkey Using Arima, Lstm And Hybrid Models. *Journal of Business Economics and Management*, 20(5), 920-938. doi:<https://doi.org/10.3846/jbem.2019.10190>.
- Soysal, M., & Ömürgönülşen, M. (2010). Türk Turizm Sektöründe Talep Tahmini Üzerine Bir Uygulama. *Anatolia: Turizm Araştırmaları Dergisi*, 21(1), 128-136.
- Sugiartawan, P., Pulungan, R., & Sari, A. K. (2017). Prediction by a Hybrid of Wavelet Transform and Long-Short-Term-Memory Neural Network. *International Journal of Advanced Computer Science and Applications*, 8(2), 326-332. https://www.researchgate.net/profile/Reza_Pulungan/publication/314166897_Prediction_by_a_Hybrid_of_Wavelet_Transform_and_Long-Short-Term-Memory_Neural_Network/links/5950a68f45851543383a3d3b/Prediction-by-a-Hybrid-of-Wavelet-Transform-and-Long-Short-Term-M adresinden alındı.
- Süzen, A. A. (2019). LSTM Derin Sinir Ağları İle Üniversite Giriş Sınavındaki Matematik Soru Sayılarının Konulara Göre Tahmini. *Engineering Sciences (NWSAENS)*, 14(3), 112-118. doi:10.12739/NWSA.2019.14.3.1A0436.
- Şahin, A. E. (2001). Eğitim Araştırmalarında Delphi Tekniği ve Kullanımı. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 21, 215-220.
- Thomas, H., Terry, G., & D.W., W. (1972). Box Jenkins Methods: An Alternative to Econometric Models. *International Statistical Review*, 40(2), 123-137.
- Tsaih, R., Hsu, Y., & Lai, C. (1998). Forecasting S&P 500 Stock Index Futures with A Hybrid AI System. *Decision Support Systems*(23), 161-174.
- Tseng, F., Yu, H., & Tzeng, G. (2002). Combining Neural Network Model with Seasonal Time Series ARIMA Model. *Tecnological Forecasting&Social Change*(69), 71-87.
- Wedding, D., & Cios, K. (1996). Time Series Forecasting by Combining RBF Networks, Certain Factors and The Box-Jenkins Model. *Neurocomputing*, 10, 149-168.
- Yılmazel, Ö., Afşar, A., & Yılmazel: (2018). Konut Fiyat Tahmininde Yapay Sinir Ağları Yönteminin Kullanılması. *UIİİD-IJEAS*, 285-300.

- Yu, L., Wang:, & Lai, K. (2005). A Novel Nonlinear Ensemble Forecasting Model Incorporating GLAR and ANN for Foreign Exchange Rates. *Computers&Operations Research*(32), 2523-2541.
- Zhang, G. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*(50), 159-175. doi:[https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0).
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with Artificial Neurol Networks: The State of the Art. *International Journal of Forecasting*(14), 6-35.
- Zhou, Z., & Hu, C. (2008). An Effective Hybrid Approach Based on Grey and Arma for Forecasting Gyro Drift. *Chaos, Solitons and Fractals*(35), 525-529.
- Zucchini, W. (2000). An Introduction to Model Selection. *Journal of Mathematical Psychology*, 41-61.

Tezler

- Ahmetođlu, M. E. (2018). *Veri Merkezi Sektöründe Satış Tahminleme Modeli ve Özel Kurum Üzerinde Uygulaması*, Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Aras, F. (2014). *İşletme Bütçe Sistemleri, Üretim İşletmesinde Uygulama Örneđi*, Okan Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Ateşođun, A. A. (2015). *ARIMA ve Yapay Sinir Ağları (YSA) Kullanılarak Hibrit Tahmin Modeli Geliştirilmesi*, Başkent Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara.
- Bulut, Ş. (2006). Orta Ölçekli Bir İşletmede Talep Tahmin Yöntemlerinin Uygulanması. *Orta Ölçekli Bir İşletmede Talep Tahmin Yöntemlerinin Uygulanması*, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kırıkkale.
- Çađıl, G. (1997). *Mevsimsellik Olmayan Box-Jenkins Modellerinde İki Aşamalı Yapay Sinir Ağlarının Kullanılması ve Bir Uygulama*, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, İstanbul.
- Çađlar, T. (2007). Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması. *Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması*, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kırıkkale.
- Çakın, E. (2017). *Ülkelerin İnovasyon Performansının Yapay Sinir Ağları, Bulanık Dematel Tabanlı Analitik Ağ Süreci ve Ağırlık Kısıtlı Veri Zarflama Yaklaşımlarının Bütünleşik Olarak Kullanılması ve Bir Uygulama*, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, İzmir.
- Çuhadar, M. (2006). Turizm Sektöründe Talep Tahmini İçin Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi (Antalya İlinin Dış Turizm Talebinde Uygulama), Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, Isparta.
- Dere, A. (2009). *Yapay Sinir Ağları Yöntemi İle Sivilaşma Analizi ve Adapazarı İçin Örnek Bir Uygulama*, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Sakarya.
- İnanç, Ş. (2010). *İşletme Bütçelerinin Düzenlenmesi: Üretim İşletmesinde Bir Yazılım Geliştirme Uygulaması.*, Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Bursa.
- Karaca, N. (2008). *Faaliyet Tabanlı Bütçeleme Modellemesi ve Bir Üretim İşletmesi Uygulaması*, Sakarya Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, Sakarya.
- Karahan, M. (2011). *İstatiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması*, Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, Konya.

- Karasu, F. (2012). *Petrokimya Sektöründe Talep Tahmininde Yapay Sinir Ağlarının Kullanılması "PETKİM A.Ş. Örneği"*, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İzmir.
- Kızılkaya, O. (2017). *Para Krizlerinin Tahmininde Logit-Probit Modelleri ve Yapay Sinir Ağları: Türkiye Örneği*, İnönü Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, Malatya.
- Konuk, F. (2010). *Simülasyon Tekniği İle Nakit Bütçesinin Oluşturulması ve Bir Uygulama.*, Sakarya Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, Sakarya.
- Püskül, A. S. (2010). *İşletme Bütçe Sistemi ve Bütçe Uygulamalarına Yönelik Bir Araştırma*, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, Doktora Tezi, İstanbul.
- Sarı, M. (2016, Ocak). *Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması*, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Sakarya.
- Seydi, N. (2010). *İşletme Bütçelerinin Bir Kontrol Aracı Olarak Kullanılması Ve Bir Uygulama.*, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Subaşı, H. (2010). *Yapay Sinir Ağları İle Atık Su Arıtma Performansının Modellenmesi*, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Adana.
- Taş, B. (2018). *Electricity Price Forecasting Using Hybrid Time Series Models*. Statistics.: Middle East Technical University Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi,. Ankara.
- Temür, G. (2013). *Yapay Sinir Ağlarının Otomatik Olarak FPGA Çipine Uygulanması İçin Denetleyici Sistem Tasarımı*, Düzce Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Düzce.
- Tepeli: (2010). *İşletmelerde Stratejik Bütçeleme ve Bir Uygulama Örneği*, Yıldız Teknik Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Torun, N. (2015). *Birim Kök Testlerinin Performanslarının Karşılaştırılması*, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Yıldız, D. (2009). *Zaman Serileri Analizi ve Yapay Sinir Ağları İle Tahmin: Yabancı Portföy Yatırımları Üzerine Uygulama*, Ankara Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Ankara.
- Yılmaz, N. (2008). *Alan Programlamalı Kapı Dizileri (FPGA) Üzerinde Bir YSA'nın Tasarlanması ve Donanım Olarak Gerçekleştirilmesi*, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Konya.

Diğer

- “*What is Zero Base Budgeting?*”. (2016, Şubat 11). Caltax Web Sitesi: <http://www.caltax.org/ZeroBase.pdf> adresinden alındı
- (2019, Nisan 12). <https://keras.io/>: <https://keras.io/> adresinden alındı
- Adeva, J. J., Beresi, U. C., & Calvo, R. A. (2005). Accuracy and Diversity in Ensembles of Text Categorisers. *CLEI Electronic Journal*, 8(2), 1-12. doi:DOI: 10.19153/cleiej.12.1.1
- Ahmetoğlu, M. E. (2018). *Veri Merkezi Sektöründe Satış Tahminleme Modeli ve Özel Kurum Üzerinde Uygulaması*. İstanbul: Bahçeşehir Üniversitesi.
- Akaike, H. (1969). Fitting Autoregressive Model for Prediction. *Annals of The Institute of Statistical Mathematics*(21), 243-247.
- Akdoğan, N. (2009). *Tekdüzen Muhasebe Sisteminde Maliyet Muhasebesi Uygulamaları* (8 b.). Ankara: Gazi Kitabevi.
- Aksoy, Ş. (1991). *Kamu Maliyesi*. İstanbul: Filiz Kitabevi.
- Aktan, C. C. (1998). “Geleceği Kazanmanın Yolu: Stratejik Yönetim . *Yeni Türkiye*,, 335-342.
- Aladağ, Ç. H., Eğrioğlu, E., & Kadılar, C. (2009). Forecasting Nonlinear Time Series with a Hybrid Methodology. *Applied Mathematics Letters*(22), 1467-1470. doi:<https://doi.org/10.1016/j.aml.2009.02.006>
- Albayrak, A. S. (2010). ARIMA Forecasting of Primary Energy Production and Consumption in Turkey: 1923–2006. *Enerji, Piyasa ve Düzenleme*, 24-50.
- Andersan, S. (2003). *Practical Business Forecasting*. Oxford, UK: Blackwell Publishing.
- Anderson, D. R., Sweeney, D. J., Williams, T. A., Camm, J. D., Cochran, J. J., J.Fry, M., & Ohlman, J. W. (2014). *An Introduction to Management Science: Quantative Approaches to Decision Making* (8th Edition b.). United States of America.
- Anderson, P., & McNeill, G. (1992). *Artificial Neural Networks Technology* (Cilt 39). New York: Kaman Sciences Corporation.
- Aras, F. (2014). *İşletme Bütçe Sistemleri, Üretim İşletmesinde Uygulama Örneği*. Yüksek Lisans Tezi, Okan Üniversitesi Sosyal Bilimler Enstitüsü.
- Armano, G., Marchesi, M., & Murru, A. (2005). A Hybrid Genetic-Neural Architecture for Stock Indexes Forecasting. *Information Sciences*(170), 3-33.

- Ateşoğlu, A. A. (2015). *ARIMA ve Yapay Sinir Ağları (YSA) Kullanılarak Hibrit Tahmin Modeli Geliştirilmesi*. Ankara: Başkent Üniversitesi Fen Bilimleri Enstitüsü.
- Aymaz, O. (2015, 02 15). *elektrik port*. elektrikport.com: <https://www.elektrikport.com/universite/yapay-sinir-aglari-avantaj-ve-dezavantajlari/15007#ad-image-0> adresinden alındı
- Babu, C. N., & Reddy, B. E. (2014). A Moving-Average Filter Based Hybrid ARIMA–ANN Model for Forecasting Time Series Data. *Applied Soft Computing*(23), 27-38. doi:<https://doi.org/10.1016/j.asoc.2014.05.028>
- Bengio, Y., Simard, P., & Frasconi, P. (2015). Learning Long-Term Dependencies with Gradient Descent is Difficult. *IEEE Trans. Neural Networks*, 5(2), 157-166.
- Beran, J., Bhansali, R., & Ocker, D. (1998). On Unified Model Selection for Stationary and Nonstationary Short and Long Memory Autoregressive Processes. *Biometrika*(85), 921-934.
- Berikol, B. Z. (2010, Aralık). İşletmelerde Bütçeleme Süreci: Adana'da Faaliyet Gösteren Bir İşletmede Uygulama. *Çukurova Üniversitesi İİBF Dergisi*, 14(2), 11-31.
- Bircan, H., & Karagöz, Y. (2003). Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama. *Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 6(2), 49-62. Şubat 10, 2017 tarihinde <http://dergipark.gov.tr/download/article-file/252067> adresinden alındı
- Bulut, Ş. (2006). Orta Ölçekli Bir İşletmede Talep Tahmin Yöntemlerinin Uygulanması. *Orta Ölçekli Bir İşletmede Talep Tahmin Yöntemlerinin Uygulanması*. Kırıkkale: Kırıkkale Üniversitesi, FBE Enstitüsü, YL Tezi.
- Büker, S. (2001). *Finansal Yönetim*. Eskişehir: Anadolu Üniversitesi Yayınları.
- Büyükmirza, K. (2007). *Maliyet ve Yönetim Muhasebesi*. Ankara: Gazi Kitabevi.
- Chen, L., & Szroeter, J. (2016). Extension of The Schwarz Information Criterion for Models Sharing Parameter Boundaries. *Science Direct Journal*, 42(9), 7-8.
- Cui, Z., Ke, R., & Wang, Y. (2017). Deep Stacked Bidirectional and Unidirectional LSTM Recurrent Neural Network for Network-wide Traffic Speed Prediction. *6th International Workshop on Urban Computing*.
- Çağlı, G. (1997). *Mevsimsellik Olmayan Box-Jenkins Modellerinde İki Aşamalı Yapay Sinir Ağlarının Kullanılması ve Bir Uygulama*. İstanbul: İstanbul Üniversitesi.
- Çağlar, T. (2007). Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması. *Talep Tahmininde Kullanılan Yöntemler ve Fens*

Teli Üretimi Yapan Bir İşletmede Uygulanması. Kırıkkale: Kırıkkale Üniversitesi, FBE, YL Tezi.

Çakın, E. (2017). *Ülkelerin İnovasyon Performansının Yapay Sinir Ağları, Bulanık Dematel Tabanlı Analitik Ağ Süreci ve Ağırlık Kısıtlı Veri Zarflama Yaklaşımlarının Bütünleşik Olarak Kullanılması ve Bir Uygulama*. İzmir: Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü.

Çam, S. (2009). *İşletmelerde Pratik Bütçe Yönetimi*. İstanbul: Hayat Yayın Grubu.

Çuhadar, M. (2006). *Turizm Sektöründe Talep Tahmini İçin Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi (Antalya İlinin Dış Turizm Talebinde Uygulama)*. Isparta: Süleyman Demirel Üniversitesi, SBE, Doktora Tezi.

Dalkey, N., & Helmer, O. (1962). An Experimental Application of the Delphi Method to the Use of Experts. *The RAND Corporation*, 458-467.

Deep Learning Tutorial. (2015, September 1). Nisan 11, 2019 tarihinde deeplearnig.net: <http://deeplearning.net/tutorial/deeplearning.pdf> adresinden alındı

Demir, M. H., & Gümüşoğlu, Ş. (2011). *Üretim Yönetimi (İşlemler Yönetimi)* (7 b.). İstanbul: Beta Yayınları.

Dere, A. (2009). *Yapay Sinir Ağları Yöntemi İle Sivilaşma Analizi ve Adapazarı İçin Örnek Bir Uygulama*. Sakarya: Sakarya Üniversitesi.

Doğan, M. (2007). *İşletme Ekonomisi ve Yönetimi*. İzmir: Nobel Yayınları.

Düzyol, M. (1997). *Türkiye'de Bina İnşaatı Sektörü ve 1990-2010 Dönemi Bölgesel İhtiyaç Tahmini*. Ankara: DPT: 2484.

Ediger, V. Ş., & Akar, S. (2007). ARIMA Forecasting of Primary Energy Demand by Fuel in Turkey. *Energy Policy*, 1701-1708. doi:<https://doi.org/10.1016/j.enpol.2006.05.009>

Elmas, Ç. (2003). *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*. Ankara: Seçkin Yayınevi.

Elmas, Ç. (2007). *Yapay Zeka Uygulamaları*. Ankara: Seçkin Yayıncılık.

Ercan, M. K., & Ban, Ü. (2014). *Finansal Yönetim (Değere Dayalı İşletme Finansı)* (8 b.). Ankara: Gazi Kitabevi.

Erdoğan, E. (2007). Electricity Demand Analysis Using Cointegration and ARIMA Modelling: A Case Study of Turkey. *Energy Policy*, 1129-1146. doi:<https://doi.org/10.1016/j.enpol.2006.02.013>

- Eski, H. (2005). *Ekonomiye Giriş* (4 b.). İzmir: DEÜ Mühendislik Yayınları.
- Gao, Q. (2016). *Stock Market Forecasting Using Neural Network*. Columbia: A Thesis Presented to the Faculty of Graduate School at the University of Missouri.
- Gers, F., Schmidhuber, J., & Cummins, F. (2000). Learning to Forget: continual Prediction with LSTM. *Neural Computation Journal*, 12(10), 2451-2471.
- Göktaş, Ö. (2005). *Teorik ve Uygulamalı Zaman Serileri Analizi*. İstanbul: Beşir Kitabevi.
- Graves, A., Mohamed, A.-r., & Hinton, G. (2013). Speech Recognition with Deep Recurrent Neural Networks. *Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on* (s. 6645-6649). IEEE.
- Gujarati, D. N. (2008). *Basic Econometrics* (5th b.). United States: United States Military Academy, West Point.
- Günören, H. (2010). *FPGA Üzerinde Kayan Nokta Sayı Formatı Kullanılarak Yapay Sinir Ağı Tabanlı Sınıflandırma İşlemi*. İstanbul: Yıldız Teknik Üniversitesi.
- Gürsoy, C. T. (2007). *Finansal Yönetim İlkeleri*. İstanbul: Doğu Üniversitesi Yayınları.
- Güzel, Y. (2019, Haziran 15). *Medium Web Sitesi*. Yapay Zeka Ders Notları 03: <https://medium.com/@yasinguzel/yapay-zeka-ders-notlar%C4%B1-03-biyolojik-sinir-sistemi-ve-yapay-sinir-a%C4%9F%C4%B1-h%C3%BCcresi-6555add68d80> adresinden alındı
- Hacırüstemoğlu, R. (2006). İşletme Bütçeleri. *Kontrol, Revizyon seminer notları*. İstanbul.
- Haftacı, V. (2005). *İşletme Bütçeleri* (4 b.). İstanbul: Beta Yayınevi.
- He, G., & Deng, Q. (2012). A Hybrid ARIMA and Neural Network Model to Forecast Particulate. *Matter Concentration in Changsha*. <https://www.isiaq.org/docs/PDF%20Docs%20for%20Proceedings/1F.3.pdf> adresinden alındı
- Heize, J., & Render, B. (2011). *Operations Management* (10 b.). United States of America: Pearson International Edition.
- Hocaoğlu, F. O., Kaysal, K., & Kaysal, A. (2015). Yük Tahmini İçin Hibrit (YSA ve Regresyon) Model. *Akademik Platform*, 33-39. doi:DOI: 10.5505/apjes.2015.94695
- Hochreiter, S., & Schmidhuber, J. (1997). Long ShortTerm Memory. *Neural Computing*, 9(8), 1735-1780.

- İnanç, Ş. (2010). *İşletme Bütçelerinin Düzenlenmesi: Üretim İşletmesinde Bir Yazılım Geliştirme Uygulaması*. Yüksek Lisans Tezi, Uludağ Üniversitesi, Ekonometri ABD Yöneylem Bilimdalı, Bursa.
- Ioannou, K., Birbilis, D., & Lefakis, P. (2011). A Method for Predicting the Possibility of Ring Shake Appearance on Standing Chestnut Trees. *Journal of Environmental Protection and Ecology*, 295-304. <https://docs.google.com/a/jepe-journal.info/viewer?a=v&pid=sites&srcid=amVwZS1qb3VybmFsLmluZm98amVwZS1qb3VybmFsGd40jJkYzQwODIyZjE4ZmJmMzQ> adresinden alındı
- Jozefowicz, R., Zaremba, W., & Sutskever, I. (2015). An Empirical Exploration of Recurrent Network Architectures. *Proceedings of the 32 nd International Conference on Machine Learning*. Lille, France: JMLR: W&CP volume 37.
- Kadılar, C. (2005). *SPSS Uygulamalı Zaman Serileri Analizine Giriş*. Ankara: Bizim Büro Basımevi.
- Karaca, N. (2008). *Faaliyet Tabanlı Bütçeleme Modellemesi ve Bir Üretim İşletmesi Uygulaması*. Sakarya: Sakarya Üniversitesi Sosyal Bilimler Enstitüsü.
- Karacan, S. (2008). Bütçe ve Bütçeleme Konulu Eğitim Semineri Ders Notu.
- Karahan, M. (2011). *İstatiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması*. Doktora Tezi, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü İşletme ABD, Konya.
- Karasu, F. (2012). Petrokimya Sektöründe Talep Tahmininde Yapay Sinir Ağlarının Kullanılması “PETKİM A.Ş. Örneği“. İzmir: Dokuz Eylül Üniversitesi, SBE Enstitüsü, YL Tezi.
- Karpathy, A. (2015, Mayıs 21). *The Unreasonable Effectiveness of Recurrent Neural Networks*. Haziran 26, 2019 tarihinde Andrej Karpathy blog: <http://karpathy.github.io/2015/05/21/rnn-effectiveness/> adresinden alındı
- Kendal, M. (1973). *The Advanced Theory of Statics*. London: Charles Griffin.
- Khandelwal, I., Adhikari, R., & Verma, G. (2015). Time Series Forecasting using Hybrid ARIMA and ANN Models based on DWT Decomposition. *Procedia Computer Science*(48), 173-179.
- Khashei M., H. S. (2008). A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting. *Fuzzy Sets and Systems*(159), 769-786. doi:<https://doi.org/10.1016/j.fss.2007.10.011>
- Khashei, M., & Bijari, M. (2010). An Artificial Neural Network (p, d,q) Model for Time Series Forecasting. *Expert Systems with Applications*(37), 479-489.

- Khashei, M., Bijari, M., & Ardali, G. (2012). Hybridization of Autoregressive Integrated Moving Average (ARIMA) with Probabilistic Neural Networks. *Computers & Industrial Engineering*(63), 37-45.
- Khashei, M., Hejazi, S. R., & Bijari, M. (2008). A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting. *Fuzzy Sets and Systems*(159), 769-786. doi:<https://doi.org/10.1016/j.fss.2007.10.011>
- Kılıç, R., & Demirbaş, E. (2012). Türkiye’de Kamu İnşaat Harcamalarının Belirleyicileri ile Ekonomik Büyüme Arasındaki İlişki. *Akademik Yaklaşımlar Dergisi*, 3(2), 84-97.
- Kim, H., & Shin, K. (2007). A Hybrid Approach Based on Neural Networks and Genetic Algorithms for Detecting Temporal Patterns in Stock Markets. *Applied Soft Computing*(7), 569-576.
- Kızılkaya, O. (2017). *Para Krizlerinin Tahmininde Logit-Probit Modelleri ve Yapay Sinir Ağları: Türkiye Örneği*. Malatya: İnönü Üniversitesi Sosyal Bilimler Enstitüsü.
- Kobu, B. (2008). *Üretim Yönetimi* (14 b.). İstanbul: Beta Basım.
- Koç, Y. Y. (1989). *Yönetim Aracı Olarak İşletme Bütçeleri* (3 b.). Ankara: Turhan Kitapevi.
- Konuk, F. (2010). *Simülasyon Tekniği İle Nakit Bütçesinin Oluşturulması ve Bir Uygulama*. Doktora Tezi, Sakarya Üniversitesi , SBE İşletme ABD Muhasebe ve Finansman Bilimdalı, Sakarya.
- Koutnik, J., Greff, K., Gomez, F., & Schmidhuber, J. (2014, Şubat 14). *A Clockwork RNN*. arxiv.org: <https://arxiv.org/pdf/1402.3511v1.pdf> adresinden alındı
- Koutroumanidis, T., Ioannou, K., & Zafeiriou, E. (2011). Forecasting Bank Stock Market Prices with A Hybrid Method: The Case of Alpha Bank. *Journal of Business Economics and Management*, 12(1), 144-163. doi:<https://doi.org/10.3846/16111699.2011.555388>
- Koutroumanidis, T., Ioannou, K., & Arabatzis, G. (2009). Predicting Fuelwood Prices in Greece With the Use of ARIMA Models, Artificial Neural Networks and a Hybrid ARIMA–ANN Model. *Energy Policy*(37), 3627-3634. doi:<https://doi.org/10.1016/j.enpol.2009.04.024>
- Köksal, B. A. (2003). *İstatistik Analiz Metodları* (6 b.). İstanbul: Çağlayan Kitabevi.
- Kurach, K. (2016). *Deep Neural Architectures for Algorithms and Sequential Data*. Institute of Informatics University of Warsaw.
- Lalli, W. R. (2003). *Handbook of Budgeting* (5 b.). ABD: John Wiley&Sons Inc.

- Lee, C., & Ko, C. (2011). Short-term Load Forecasting Using Lifting Scheme and ARIMA Models. *Expert Systems with Applications*, 38(5), 5902-5911.
- Lin, T., Guo, T., & Aberer, K. (2017). Hybrid Neural Networks for Learning the Trend in Time Series. *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*, (s. 2273-2279). Melbourne, Australia. doi:<https://doi.org/10.24963/ijcai.2017/316>
- Luxhoj, J., Riis, J., & Stensballe, B. (1996). A Hybrid Econometric-Neural Network Modeling Approach for Sales Forecasting. *International Journal of Production Economics*(45), 175-192.
- McQuarrie, A., & Tsai, C. (1998). *Regression and Time Series Model Selection*. World Scientefic.
- Mkolov, T., Karafiat, M., Lukas, B., Cernocky, J., & Khundapur, S. (2010). Recurrent Neural Network Based Language Model. *Interspeech 2010 11th Annual Conference of the International Speech Communication Association* (s. 1045-1048). Makuhari, Chiba, Japan: In INTERSPEECH-2010.
- Monks, J. G. (1996). *İşlemler Yönetimi Teori ve Problemler*. (S. Üreten, Çev.) Ankara: Nobel Yayın Dağıtım.
- Montgomery, C., Peck, A., & Vining, G. (2013). *Doğrusal Regresyon Anaizine Giriş* (5 b.). Ankara: Nobel Akademik Yayıncılık.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2008). *Introduction to Time Series Analysis and Forecasting*. United States of America: John Wile&Sons Inc.
- Moore, C., & Jaedicke, R. K. (1988). *Yönetim Muhasebesi*. (4 b.). (A. Peker, Çev.) İstanbul: Fatih Yayınevi.
- Namın, S. S., & Namın, A. S. (2018). *Forecasting Economic and Financial Time Series: ARIMA vs. LSTM*. Lubbock, TX, USA: Texas Tech University. doi:<https://arxiv.org/ftp/arxiv/papers/1803/1803.06386.pdf>
- Nasuhi, B., & Yücel, E. (2002). *Maliyet Muhasebesi* (9 b.). İstanbul: Der Yayınları.
- Newbold, P. (1983). ARIMA Model Building and The Time Series Analysis Approach to Forecasting. *Journal of Forecasting*, 2(1), 23-35.
- Olah, C. (2015, August 27). *Understanging LSTM Networks*. Nisan 10, 2019 tarihinde [colah.github.io: colah.github.io/posts/2015-08-Understanding-LSTMs/](https://colah.github.io/posts/2015-08-Understanding-LSTMs/) adresinden alındı
- Olah, C. (2019, Mart). *Colah's Blog*. Colah's Blog Web Sitesi: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/> adresinden alındı

- Oliveira, M., & Torgo, L. (2014). Ensembles for Time Series Forecasting. *In Proceedings of the Sixth Asian Conference on Machine Learning*, (s. 360-370). <http://proceedings.mlr.press/v39/oliveira14.pdf> adresinden alındı
- Opitz, D., & Maclin, R. (1999). Popular Ensemble Methods: An Empirical Study. *Journal of Artificial Intelligence Research*, 11, 169–198. doi:<https://doi.org/10.1613/jair.614>
- Orhunbilge, N. (1999). *Zaman Serileri Analizi Tahmin ve Fiyat İndeksleri*. İstanbul: Avcıol Basım Yayın.
- Özdemir, A., & Özdemir, A. (2006). Talep Tahminlemede Kullanılan Yöntemlerin Karşılaştırılması: Seramik Ürün Grubu Firma Uygulaması. *Ege Akademik Bakış Dergisi*, 6 (2), 105-114.
- Öztemel, E. (2012). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık.
- Pablo, B. J., Hilda, C., Xavier, A., Diego, J. J., Felipe, S., & Henry, B. (2016). Artificial Neural Network and Monte Carlo Forecasting with Generation of L-Scenarios. *2016 Intl IEEE Conferences on Ubiquitous Intelligence & Computing, Advanced and Trusted Computing, Scalable Computing and Communications, Cloud and Big Data Computing, Internet of People and Smart World Congress*, (s. 665-670). doi:10.1109/UIC-ATC-ScalCom-CBDCCom-IoP-SmartWorld.2016.0110
- Pagourtzi, E., Assimakolopoulos, V., Hatzichristos, T., & French, N. (2003). Real Estate Appraisal: A Review of Valuation Methods. *Journal of Property Investment & Finance*, 21(4), 383-401.
- Papagera, A., Ioannou, K., Zaimis, G., Iakovoglou, V., & Simeonidou, M. (2014). Simulation and Prediction of Water Allocation Using Artificial Neural Networks and a Spatially Distributed Hydrological Model. *Agris on-line Papers in Economics and Informatics*, 6(4), 101-111. <https://ageconsearch.umn.edu/record/196580/> adresinden alındı
- Parkhurst, A. (1992). *Evaluation of Order Determination Procedures in ARMA Models*. Nebraska: Presented to The Faculty of The Graduate Collage at The University of Nebraska.
- Patro, S. K., Sahoo, P. P., Panda, I., & Sahu, K. K. (2015). Technical Analysis on Financial Forecasting. *IJCSE*. arXiv preprint arXiv:1503.03011 adresinden alındı
- Peker, A. (1988). *Modern Yönetim Muhasebesi*. İstanbul: İstanbul Üniversitesi İşletme Fakültesi Muhasebe Enstitüsü.
- Pekiner, K. (1988). *İşletme Denetimi*. İstanbul Üniversitesi Yayınları.

- Püskül, A. S. (2010). *İşletme Bütçe Sistemi ve Bütçe Uygulamalarına Yönelik Bir Araştırma*. Doktora Tezi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Ravzan, P., Gülcehre, Ç., Cho, K., & Bengio, Y. (2014, Nisan 24). *How to Construct Deep Recurrent Neural Networks*. arXiv: 1312.6026v5: arxiv.org/abs/1312.6026v5 adresinden alındı
- Sallehuddin, R., Shamsuddin, S. M., Hashim, S. Z., & Abraham, A. (2007). Forecasting Time Series Data Using Hybrid Grey Relational Artificial Neural Network and Auto Regressive Integrated Moving Average Model. *ICS AS CR 2007*, (s. 573-605).
https://www.researchgate.net/publication/287522177_Forecasting_time_series_data_using_hybrid_grey_relational_artificial_neural_network_and_auto_regressive_integrated_moving_average_model adresinden alındı
- Sarı, M. (2016, Ocak). Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması. *Yüksek Lisans Tezi*. Sakarya, Türkiye: Sakarya Üniversitesi.
- Sevgener, A., & Hacırüstemoğlu, R. (2000). *Yönetim Muhasebesi (7 b.)*. İstanbul: Alfa Yayınları.
- Seydi, N. (2010). *İşletme Bütçelerinin Bir Kontrol Aracı Olarak Kullanılması Ve Bir Uygulama*. Yüksek Lisans Tezi, Marmara Üniversitesi , Sosyal Bilimler Enstitüsü.
- Shim, J. K. (2005). *Budgeting Basics & Beyond (2 b.)*. ABD: John Wiley & Sons Inc.
- Soy Temür, A., Akgün, M., & Temür, G. (2019). PREDICTING HOUSING SALES IN TURKEY USING ARIMA, LSTM AND HYBRID MODELS. *Journal of Business Economics and Management*, 20(5), 920-938. doi:<https://doi.org/10.3846/jbem.2019.10190>
- Soysal, M., & Ömürgönülşen, M. (2010). Türk Turizm Sektöründe Talep Tahmini Üzerine Bir Uygulama. *Anatolia: Turizm Araştırmaları Dergisi*, 21(1), 128-136.
- Subaşı, H. (2010). *Yapay Sinir Ağları İle Atık Su Arıtma Performansının Modellenmesi*. Adana: Çukurova Üniversitesi.
- Sugiartawan, P., Pulungan, R., & Sari, A. K. (2017). Prediction by a Hybrid of Wavelet Transform and Long-Short-Term-Memory Neural Network. *International Journal of Advanced Computer Science and Applications*, 8(2), 326-332. https://www.researchgate.net/profile/Reza_Pulungan/publication/314166897_Prediction_by_a_Hybrid_of_Wavelet_Transform_and_Long-Short-Term-Memory_Neural_Network/links/5950a68f45851543383a3d3b/Prediction-by-a-Hybrid-of-Wavelet-Transform-and-Long-Short-Term-M adresinden alındı

- Sürmeli, A. (2016, Nisan 17). <http://surmelimusavirlik.com.tr/bulten/isletmelerde-butce-ve-onemi/04/08/2016>. adresinden alındı
- Süzen, A. A. (2019). LSTM Derin Sinir Ağları İle Üniversite Giriş Sınavındaki Matematik Soru Sayılarının Konulara Göre Tahmini. *Engineering Sciences (NWSAENS)*, 14(3), 112-118. doi:10.12739/NWSA.2019.14.3.1A0436.
- Şahin, A. E. (2001). Eğitim Araştırmalarında Delphi Tekniği ve Kullanımı. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 21, 215-220.
- Taş, B. (2018). *Electricity Price Forecasting Using Hybrid Time Series Models*. Statistics. Ankara: Middle East Technical Univesity.
- Tekin, M. (2009). *Üretim Yönetimi* (Cilt I). Konya: Günay Ofset.
- Temür, G. (2013). *Yapay Sinir Ağlarının Otomatik Olarak FPGA Çipine Uygulanması İçin Denetleyici Sistem Tasarımı*. Düzce: Düzce Üniversitesi Fen Bilimleri Enstitüsü.
- Tepeli, S. (2010). *İşletmelerde Stratejik Bütçeleme ve Bir Uygulama Örneği*. . Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi , Sosyal Bilimler Enstitüsü, İstanbul.
- Thomas, H., Terry, G., & D.W., W. (1972). Box Jenkins Methods: An Alternative to Econometric Models. *International Statistical Rewiew*, 40(2), 123-137.
- Torun, N. (2015). *Birim Kök Testlerinin Performanslarının Karşılaştırılması*. İstanbul: İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü.
- Tsaih, R., Hsu, Y., & Lai, C. (1998). Forecasting S&P 500 Stock Index Futures with A Hybrid AI System. *Decision Support Systems*(23), 161-174.
- Tsay, R. S. (2005). *Analysis of Financial Time Series* (2 b.). United States of America: John Wiley & Sons.
- Tsay, R. S. (2014). *Analysis of Financial Time Series*. Canada: John Wiley & Sons.
- Tseng, F., Yu, H., & Tzeng, G. (2002). Combining Neural Network Model with Seasonal Time Series ARIMA Model. *Tecnological Forecasting&Social Change*(69), 71-87.
- Tütek, H., & Gümüšoğlu, Ş. (2000). *İşletme İstatistiği*. İzmir: Barış Yayınları.
- Usta, Ö. (2008). *İşletme Finansı ve Finansal Yönetim* (3 b.). Ankara: Detay Yayıncılık.
- Üreten, S. (2005). *Üretim/İşlemler Yönetimi, Stratejik Kararlar ve Karar Modelleri* . Ankara: Gazi Kitabevi.
- Wedding, D., & Cios, K. (1996). Time Series Forecasting by Combining RBF Networks, Certain Factors and The Box-Jenkins Model. *Neurocomputing*, 10, 149-168.

- Welsch, A. G. (1971). *İşletme Bütçeleri* (3 b.). Ankara, ABD: Bilimsel Yayınlar Derneği.
- Yao, K., Cohn, T., Vylomova, K., Duh, K., & Dyer, C. (2015, Ağustos 19). *Depth-Gated Recurrent Neural Networks*. arxiv.org: <https://arxiv.org/pdf/1508.03790v2.pdf> adresinden alındı
- Yıldız, D. (2009). *Zaman Serileri Analizi ve Yapay Sinir Ağları İle Tahmin: Yabancı Portföy Yatırımları Üzerine Uygulama*. Ankara: Ankara Üniversitesi Sosyal Bilimler Enstitüsü.
- Yılmaz, F. (2001, Nisan-Mayıs-Haziran). İşletmelerde Bütçeleme. *Mali Çözüm Dergisi, İsmmmo Yayınları*,(55). Kasım 17, 2016 tarihinde alındı
- Yılmaz, N. (2008). *Alan Programlamalı Kapı Dizileri (FPGA) Üzerinde Bir YSA'nın Tasarlanması ve Donanım Olarak Gerçekleştirilmesi*. Konya: Selçuk Üniversitesi.
- Yılmazel, Ö., Afşar, A., & Yılmazel, S. (2018). Konut Fiyat Tahmininde Yapay Sinir Ağları Yönteminin Kullanılması. *UIİİD-IJEAS*, 285-300.
- Yu, L., Jiao, C., Xin, H., Wang, Y., & Wang, K. (2018). Prediction on Housing Price Based on Deep Learning. *World Academy of Science, Engineering and Technology*, 12(2). doi:doi.org/10.5281/zenodo.1315879
- Yu, L., Wang, S., & Lai, K. (2005). A Novel Nonlinear Ensemble Forecasting Model Incorporating GLAR and ANN for Foreign Exchange Rates. *Computers&Operations Research*(32), 2523-2541.
- Zhang, G. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*(50), 159-175. doi:https://doi.org/10.1016/S0925-2312(01)00702-0
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with Artificial Neural Networks: The State of the Art. *International Journal of Forecasting*(14), 6-35.
- Zhou, Z., & Hu, C. (2008). An Effective Hybrid Approach Based on Grey and Arma for Forecasting Gyro Drift. *Chaos, Solitons and Fractals*(35), 525-529.
- Zucchini, W. (2000). An Introduction to Model Selection. *Journal of Mathematical Psychology*, 41-61.

EKLER

Ek 1: ARIMA Modelleri korelogram sonuç karşılaştırmaları

Eğitim Seti (%)	ARIMA	MAE	MSE	RMSE	MAPE
67	(0,0,1)	775.124	934643.842	966.770	0.255
	(0,0,2)	751.472	850727.707	922.349	0.252
	(0,1,0)	692.830	766967.805	875.767	0.253
	(0,1,1)	682.341	774691.214	880.165	0.249
	(0,1,2)	680.501	842165.040	917.696	0.248
	(0,2,0)	969.175	1781394.254	1334.689	0.348
	(0,2,1)	711.706	780424.410	883.416	0.257
	(1,0,0)	672.267	681849.325	825.742	0.234
	(1,0,1)	675.996	690921.199	831.217	0.235
	(1,0,2)	684.416	707584.581	841.180	0.238
	(1,1,0)	688.410	757390.500	870.282	0.251
	(1,1,1)	685.596	775116.584	880.407	0.259
	(1,2,0)	850.146	1154097.582	1074.289	0.302
	(2,0,0)	675.486	691174.864	831.369	0.235
	(2,0,2)	686.341	713903.030	844.928	0.239
	(2,1,0)	676.638	784725.580	885.847	0.247
	(2,2,0)	775.778	935149.511	967.031	0.278
	(2,2,1)	698.914	795957.630	892.165	0.251
	(3,0,0)	683.278	706244.244	840.383	0.238
	(3,1,0)	695.930	810263.963	900.147	0.253
(3,2,0)	837.732	994229.156	997.110	0.292	
(3,2,1)	718.608	818122.045	904.501	0.257	
73	(0,0,1)	837.842	1048519.893	1023.973	0.281
	(0,0,2)	802.764	944684.711	971.949	0.276
	(0,1,0)	699.415	828872.420	910.424	0.266
	(0,1,1)	705.674	856644.359	925.551	0.267
	(0,1,2)	714.521	952107.633	975.760	0.268
	(0,2,0)	952.209	1871803.613	1368.139	0.360
	(0,2,1)	720.730	843571.659	918.462	0.271
	(1,0,0)	710.461	760316.150	871.961	0.254
	(1,0,1)	716.008	773831.273	879.677	0.256
	(1,0,2)	723.226	792962.528	890.484	0.259
	(1,1,0)	706.616	830713.220	911.435	0.268
	(1,1,1)	721.629	871697.809	933.648	0.282
	(1,2,0)	876.194	1251961.781	1118.911	0.323
	(2,0,0)	715.443	773943.779	879.741	0.256
	(2,0,2)	727.935	803260.807	896.248	0.260
	(2,1,0)	688.728	858269.317	926.428	0.262
	(2,2,0)	781.374	967890.861	983.814	0.293
	(2,2,1)	713.743	871890.617	933.751	0.266
	(3,0,0)	722.298	790916.417	889.335	0.258
	(3,1,0)	713.400	889748.819	943.265	0.269
(3,2,0)	809.328	970680.478	985.231	0.296	
(3,2,1)	738.584	899890.072	948.625	0.273	

Ek 2: LSTM Modelleri korelogram sonuç karşılaştırmaları

Eğitim Seti (%)	epoch	MAE	MSE	RMSE	MAPE
67	1000	876.925	1086744.667	1042.470	0.309
	1500	1055.303	1543692.874	1242.454	0.364
	2000	1223.365	2021929.469	1421.946	0.406
	2500	1332.994	2450055.299	1565.265	0.445
73	1000	687.389	661910.062	813.579	0.245
	1500	795.090	954889.250	977.184	0.275
	2000	900.901	1261486.750	1123.159	0.297
	2500	1027.180	1895367.375	1376.723	0.318
	3000	1134.353	2377058.250	1541.771	0.352
	3500	1162.526	2533109.000	1591.574	0.356
	4000	1161.869	2452879.500	1566.167	0.351
	4500	1173.684	2619992.750	1618.639	0.358
	5000	1164.475	2550615.500	1597.065	0.355

Ek 3: HYBRID Model korelogram sonuç karşılaştırmaları

Eğitim Seti (%)	LSTM epoch	ARIMA(p,d,q)	MAE	MSE	RMSE	MAPE
67	1000	(0,0,1)	595.146	657305.743	810.744	0.207
		(0,0,2)	570.870	645331.547	803.325	0.198
		(0,1,0)	474.901	539710.087	734.650	0.173
		(0,1,1)	473.856	505515.043	710.996	0.176
		(0,1,2)	494.568	531189.227	728.827	0.183
		(0,2,0)	515.653	736611.661	858.261	0.184
		(0,2,1)	474.478	541416.648	735.810	0.171
		(1,0,0)	527.383	551479.907	742.617	0.184
		(1,0,1)	526.458	549214.087	741.090	0.184
		(1,0,2)	534.001	555757.340	745.491	0.187
		(1,1,0)	476.180	510008.043	714.148	0.176
		(1,1,1)	547.064	550803.800	742.162	0.203
		(1,2,0)	454.536	574853.193	758.191	0.166
		(2,0,0)	526.473	549262.515	741.122	0.184
		(2,0,2)	529.460	559525.031	748.014	0.185
		(2,1,0)	471.357	523651.351	723.638	0.175
		(2,2,0)	455.894	562571.828	750.048	0.167
		(2,2,1)	469.820	525155.998	724.676	0.171
		(3,0,0)	531.789	556023.183	745.670	0.186
		(3,1,0)	481.949	524484.538	724.213	0.178
	(3,2,0)	463.109	596970.772	772.639	0.167	
	(3,2,1)	480.553	525261.278	724.749	0.175	
	1500	(0,0,1)	625.939	718908.189	847.885	0.211
		(0,0,2)	572.524	687840.614	829.362	0.193
		(0,1,0)	441.230	517109.254	719.103	0.158
		(0,1,1)	439.884	483443.968	695.301	0.162
		(0,1,2)	461.850	501510.034	708.174	0.170
		(0,2,0)	511.242	773523.704	879.502	0.177
		(0,2,1)	442.375	525380.452	724.831	0.157
		(1,0,0)	503.702	553014.370	743.649	0.173
		(1,0,1)	502.582	550856.396	742.197	0.173
		(1,0,2)	510.754	559611.939	748.072	0.175
		(1,1,0)	439.455	483697.872	695.484	0.161
		(1,1,1)	519.856	520319.460	721.332	0.192
		(1,2,0)	425.395	576725.599	759.425	0.151
		(2,0,0)	502.393	550718.698	742.104	0.173
(2,0,2)		505.503	564011.673	751.007	0.174	
(2,1,0)		439.576	500267.806	707.296	0.161	
(2,2,0)		440.020	582412.655	763.160	0.156	
(2,2,1)		437.421	508904.737	713.376	0.157	
(3,0,0)		508.536	560152.012	748.433	0.174	
(3,1,0)		447.192	498306.588	705.908	0.164	
(3,2,0)	449.446	627351.831	792.055	0.157		
(3,2,1)	446.517	507526.855	712.409	0.161		

Ek 4: HYBRID Model korelogram sonuç karşılaştırmaları (Devamı)

Eğitim Seti (%)	LSTM epoch	ARIMA(p,d,q)	MAE	MSE	RMSE	MAPE
	2000	(0,0,1)	657.699	772040.197	878.658	0.214
		(0,0,2)	590.763	719550.433	848.263	0.193
		(0,1,0)	435.374	484493.392	696.056	0.151
		(0,1,1)	438.542	462836.972	680.321	0.157
		(0,1,2)	462.177	473899.414	688.404	0.165
		(0,2,0)	484.325	717110.860	846.824	0.164
		(0,2,1)	435.307	494930.146	703.513	0.150
		(1,0,0)	510.529	551716.026	742.776	0.170
		(1,0,1)	509.668	550756.915	742.130	0.170
		(1,0,2)	518.399	561176.334	749.117	0.173
		(1,1,0)	436.291	459243.806	677.675	0.155
		(1,1,1)	525.968	501871.120	708.429	0.190
		(1,2,0)	406.268	556548.101	746.022	0.143
		(2,0,0)	509.500	550679.754	742.078	0.170
		(2,0,2)	512.789	565544.308	752.027	0.171
		(2,1,0)	436.966	472535.368	687.412	0.156
		(2,2,0)	427.079	572413.420	756.580	0.150
		(2,2,1)	434.365	484343.448	695.948	0.151
		(3,0,0)	515.899	561156.664	749.104	0.172
		(3,1,0)	444.871	471398.327	686.585	0.159
	(3,2,0)	432.399	611121.182	781.742	0.150	
	(3,2,1)	444.305	484351.729	695.954	0.155	
	(0,0,1)	2500	657.415	790612.242	889.164	0.218
	(0,0,2)		594.145	742288.078	861.561	0.198
	(0,1,0)		437.287	497100.030	705.053	0.155
	(0,1,1)		439.369	474126.965	688.569	0.161
	(0,1,2)		465.363	481854.458	694.157	0.169
	(0,2,0)		501.076	751090.682	866.655	0.169
	(0,2,1)		435.795	505097.326	710.702	0.152
	(1,0,0)		510.504	563396.705	750.598	0.173
	(1,0,1)		510.006	563553.585	750.702	0.174
	(1,0,2)		518.453	574499.611	757.958	0.176
	(1,1,0)		437.635	471565.316	686.706	0.159
	(1,1,1)		538.044	529362.677	727.573	0.198
	(1,2,0)		418.051	596092.088	772.070	0.148
	(2,0,0)		509.929	563620.196	750.746	0.174
	(2,0,2)		514.247	581397.981	762.495	0.175
	(2,1,0)		436.265	481295.563	693.755	0.159
	(2,2,0)		441.840	614257.378	783.746	0.157
	(2,2,1)		431.464	489764.381	699.832	0.153
	(3,0,0)		515.940	574447.701	757.923	0.175
	(3,1,0)		444.752	479416.878	692.399	0.162
(3,2,0)	436.608	642934.413	801.832	0.153		
(3,2,1)	441.710	488501.066	698.929	0.157		

Ek 5: HYBRID Model korelogram sonuç karşılaştırmaları (Devamı)

Eğitim Seti (%)	LSTM epoch	ARIMA(p,d,q)	MAE	MSE	RMSE	MAPE		
73	1000	(0,0,1)	641.989	662677.592	814.050	0.228		
		(0,0,2)	604.005	631650.514	794.764	0.214		
		(0,1,0)	459.247	491694.830	701.210	0.185		
		(0,1,1)	483.421	517173.679	719.148	0.190		
		(0,1,2)	519.601	554936.226	744.940	0.200		
		(0,2,0)	427.285	457382.300	676.300	0.174		
		(0,2,1)	458.760	482559.502	694.665	0.184		
		(1,0,0)	559.970	561754.045	749.503	0.202		
		(1,0,1)	559.902	564792.588	751.527	0.202		
		(1,0,2)	558.713	570153.866	755.085	0.202		
		(1,1,0)	474.605	504144.154	710.031	0.188		
		(1,1,1)	582.304	599575.481	774.323	0.223		
		(1,2,0)	431.770	444982.797	667.070	0.180		
		(2,0,0)	559.530	564978.796	751.651	0.202		
		(2,0,2)	562.312	571844.242	756.204	0.204		
		(2,1,0)	473.266	515363.694	717.888	0.188		
		(2,2,0)	412.203	435292.022	659.767	0.177		
		(2,2,1)	467.792	503140.779	709.324	0.184		
		(3,0,0)	558.242	568223.658	753.806	0.202		
		(3,1,0)	496.658	532716.091	729.874	0.194		
		(3,2,0)	404.806	429662.845	655.487	0.170		
		(3,2,1)	490.989	519012.630	720.425	0.190		
			1500	(0,0,1)	689.439	756831.165	869.960	0.238
				(0,0,2)	617.648	687765.618	829.316	0.211
		(0,1,0)		461.439	481297.330	693.756	0.181	
		(0,1,1)		480.583	509933.388	714.096	0.184	
		(0,1,2)		514.822	540576.879	735.239	0.193	
		(0,2,0)		434.715	482440.875	694.580	0.170	
		(0,2,1)		463.353	477330.388	690.891	0.181	
		(1,0,0)		571.934	582973.549	763.527	0.201	
		(1,0,1)		569.321	586902.913	766.096	0.200	
		(1,0,2)		568.461	595970.816	771.991	0.200	
		(1,1,0)		468.350	491412.460	701.008	0.181	
		(1,1,1)		573.444	588304.013	767.010	0.215	
		(1,2,0)	421.336	447043.373	668.613	0.171		
		(2,0,0)	567.969	586720.202	765.977	0.199		
	(2,0,2)	578.685	601928.742	775.841	0.203			
	(2,1,0)	471.049	503728.652	709.738	0.182			
	(2,2,0)	429.494	466566.988	683.057	0.179			
	(2,2,1)	472.637	498384.041	705.963	0.180			
	(3,0,0)	567.721	593346.438	770.290	0.199			
	(3,1,0)	492.169	519258.526	720.596	0.187			
	(3,2,0)	421.199	456597.588	675.720	0.172			
	(3,2,1)	495.082	514844.834	717.527	0.186			

Ek 6: HYBRID Model korelogram sonuç karşılaştırmaları (Devamı)

Eğitim Seti (%)	LSTM epoch	ARIMA(p,d,q)	MAE	MSE	RMSE	MAPE
	2000	(0,0,1)	757.136	878111.140	937.076	0.247
		(0,0,2)	660.461	776098.338	880.964	0.214
		(0,1,0)	442.282	459427.418	677.811	0.172
		(0,1,1)	456.611	482088.479	694.326	0.172
		(0,1,2)	489.658	507932.194	712.694	0.181
		(0,2,0)	438.928	531400.486	728.972	0.172
		(0,2,1)	447.424	462007.952	679.712	0.173
		(1,0,0)	572.865	598168.000	773.413	0.195
		(1,0,1)	568.514	601359.669	775.474	0.193
		(1,0,2)	568.057	611608.923	782.054	0.193
		(1,1,0)	444.580	462168.300	679.830	0.170
		(1,1,1)	551.411	560489.645	748.659	0.202
		(1,2,0)	409.096	463999.091	681.175	0.165
		(2,0,0)	567.017	601017.748	775.253	0.193
		(2,0,2)	579.545	623010.604	789.310	0.198
		(2,1,0)	446.925	471641.035	686.761	0.170
		(2,2,0)	422.659	481898.837	694.189	0.176
		(2,2,1)	451.896	474046.545	688.510	0.170
		(3,0,0)	567.578	609977.493	781.011	0.193
		(3,1,0)	468.669	488572.291	698.979	0.175
	(3,2,0)	415.905	476815.353	690.518	0.170	
	(3,2,1)	475.201	492191.727	701.564	0.176	
	2500	(0,0,1)	784.975	1055902.237	1027.571	0.242
		(0,0,2)	670.714	900776.365	949.092	0.207
		(0,1,0)	413.791	484388.432	695.980	0.157
		(0,1,1)	443.190	519922.068	721.056	0.163
		(0,1,2)	479.021	552975.780	743.623	0.172
		(0,2,0)	399.406	545288.316	738.436	0.155
		(0,2,1)	414.831	489065.471	699.332	0.156
		(1,0,0)	564.183	652102.956	807.529	0.184
		(1,0,1)	561.450	656071.194	809.982	0.183
		(1,0,2)	561.818	667612.910	817.076	0.183
		(1,1,0)	425.924	492404.832	701.716	0.159
		(1,1,1)	539.900	596345.438	772.234	0.192
		(1,2,0)	360.368	474134.222	688.574	0.141
		(2,0,0)	559.687	655006.639	809.325	0.183
(2,0,2)		572.467	681873.039	825.756	0.188	
(2,1,0)		432.843	509609.739	713.870	0.161	
(2,2,0)	372.634	483494.695	695.338	0.151		
(2,2,1)	438.690	516211.096	718.478	0.161		
(3,0,0)	561.329	666256.755	816.246	0.183		
(3,1,0)	453.914	525911.196	725.197	0.165		
(3,2,0)	377.657	495534.272	703.942	0.151		
(3,2,1)	460.946	533847.864	730.649	0.166		

Ek 7: HYBRID Model korelogram sonuç karşılaştırmaları (Devamı)

Eğitim Seti (%)	LSTM epoch	ARIMA(p,d,q)	MAE	MSE	RMSE	MAPE
73	3000	(0,0,1)	793.617	1136213.219	1065.933	0.243
		(0,0,2)	684.660	965670.745	982.685	0.211
		(0,1,0)	408.578	533826.667	730.634	0.155
		(0,1,1)	456.083	584902.523	764.789	0.168
		(0,1,2)	494.664	628209.192	792.596	0.179
		(0,2,0)	390.116	565304.002	751.867	0.154
		(0,2,1)	408.858	536962.124	732.777	0.153
		(1,0,0)	569.874	702211.196	837.980	0.186
		(1,0,1)	570.723	707610.996	841.196	0.187
		(1,0,2)	572.515	720192.378	848.641	0.187
		(1,1,0)	435.197	551349.624	742.529	0.162
		(1,1,1)	553.503	662879.441	814.174	0.197
		(1,2,0)	344.138	480333.312	693.061	0.135
		(2,0,0)	569.334	706146.825	840.325	0.186
		(2,0,2)	576.521	730184.304	854.508	0.189
		(2,1,0)	445.409	578365.642	760.504	0.166
		(2,2,0)	353.442	493819.860	702.723	0.142
		(2,2,1)	447.289	582349.217	763.118	0.164
		(3,0,0)	571.778	717771.512	847.214	0.187
		(3,1,0)	467.109	595834.520	771.903	0.171
	(3,2,0)	363.971	516591.632	718.743	0.145	
	(3,2,1)	469.446	601136.503	775.330	0.170	
	3500	(0,0,1)	797.974	1163356.276	1078.590	0.243
		(0,0,2)	685.490	981205.371	990.558	0.211
		(0,1,0)	407.097	537043.602	732.833	0.154
		(0,1,1)	455.377	589494.260	767.785	0.168
		(0,1,2)	494.230	636547.153	797.839	0.178
		(0,2,0)	386.425	565809.350	752.203	0.154
		(0,2,1)	408.055	541416.560	735.810	0.153
		(1,0,0)	568.903	706456.879	840.510	0.186
		(1,0,1)	569.953	711522.334	843.518	0.186
		(1,0,2)	572.336	724650.558	851.264	0.187
		(1,1,0)	433.879	554264.109	744.489	0.162
		(1,1,1)	548.992	661595.138	813.385	0.195
		(1,2,0)	338.184	470006.272	685.570	0.133
(2,0,0)		568.552	709935.860	842.577	0.186	
(2,0,2)		574.942	733075.442	856.198	0.188	
(2,1,0)		446.167	585519.850	765.193	0.166	
(2,2,0)		350.266	481423.785	693.847	0.141	
(2,2,1)		450.308	592318.861	769.623	0.165	
(3,0,0)		571.485	721826.739	849.604	0.186	
(3,1,0)		466.782	604141.572	777.265	0.170	
(3,2,0)	363.881	510201.069	714.284	0.145		
(3,2,1)	470.574	612287.382	782.488	0.170		

Ek 8: HYBRID Model korelogram sonuç karşılaştırmaları (Devamı)

Eğitim Seti (%)	LSTM epoch	ARIMA(p,d,q)	MAE	MSE	RMSE	MAPE
73	4000	(0,0,1)	805.758	1166563.654	1080.076	0.242
		(0,0,2)	684.964	978613.201	989.249	0.206
		(0,1,0)	416.356	531732.634	729.200	0.156
		(0,1,1)	453.834	584566.158	764.569	0.164
		(0,1,2)	492.531	634316.927	796.440	0.174
		(0,2,0)	392.232	548440.836	740.568	0.155
		(0,2,1)	418.910	538311.286	733.697	0.155
		(1,0,0)	572.024	705219.075	839.773	0.183
		(1,0,1)	570.850	709498.972	842.318	0.183
		(1,0,2)	572.784	722860.587	850.212	0.183
		(1,1,0)	434.023	547877.113	740.187	0.159
		(1,1,1)	538.054	645697.173	803.553	0.187
		(1,2,0)	342.317	452430.129	672.629	0.134
		(2,0,0)	569.051	707826.299	841.324	0.182
		(2,0,2)	577.683	730864.561	854.906	0.186
		(2,1,0)	447.486	581406.834	762.500	0.163
		(2,2,0)	356.650	462898.194	680.366	0.143
		(2,2,1)	457.305	593096.679	770.128	0.165
		(3,0,0)	571.911	719734.638	848.372	0.183
		(3,1,0)	467.203	601733.526	775.715	0.167
	(3,2,0)	372.565	495426.661	703.866	0.147	
	(3,2,1)	476.478	615034.100	784.241	0.169	
	4500	(0,0,1)	805.219	1180691.016	1086.596	0.247
		(0,0,2)	689.289	989958.925	994.967	0.214
		(0,1,0)	408.811	538732.181	733.984	0.157
		(0,1,1)	456.537	590676.564	768.555	0.171
		(0,1,2)	496.131	641654.036	801.033	0.181
		(0,2,0)	388.567	567565.277	753.369	0.157
		(0,2,1)	409.597	542429.371	736.498	0.156
		(1,0,0)	571.194	708818.297	841.913	0.189
		(1,0,1)	571.864	713203.314	844.514	0.189
		(1,0,2)	574.141	726036.127	852.078	0.189
		(1,1,0)	434.998	555250.676	745.151	0.165
		(1,1,1)	551.532	666372.520	816.316	0.198
(1,2,0)		339.349	463405.842	680.739	0.136	
(2,0,0)		570.394	711595.114	843.561	0.188	
(2,0,2)		576.607	733635.543	856.525	0.191	
(2,1,0)		448.035	588540.125	767.164	0.169	
(2,2,0)		351.923	474259.495	688.665	0.144	
(2,2,1)		452.489	594426.050	770.990	0.168	
(3,0,0)		573.307	723211.695	850.419	0.189	
(3,1,0)		468.387	607640.166	779.513	0.173	
(3,2,0)		366.332	505342.208	710.874	0.148	
(3,2,1)		472.162	614674.534	784.012	0.173	

ÖZGEÇMİŞ

Ayşe SOY TEMÜR, 1986 yılında Sakarya'da doğmuştur. Eğitim hayatının tamamını Sakarya'da tamamlamış olup, 2003 yılında Sakarya Üniversitesi Sakarya Meslek Yüksekokulu Muhasebe ve Vergi Uygulamaları bölümünde ön lisans eğitimini, 2008 yılında Sakarya Üniversitesi İktisadi ve İdari Bilimler Fakültesi İşletme bölümünde lisans eğitimini tamamlamıştır. 2010 yılında Sakarya Üniversitesi Sosyal Bilimler Enstitüsü Muhasebe ve Finansman Bilim Dalı'nda "Faaliyet Tabanlı Maliyetleme Sistemi: Gıda Sektöründe Bir Uygulama" başlıklı çalışması ile yüksek lisans eğitimini tamamlamıştır. Sakarya Üniversitesi İşletme Enstitüsü Muhasebe ve Finansman Bilim Dalı'nda 2014 yılı itibariyle başladığı doktora eğitimini "İşletmelerin Satış Miktar Bütçelerinin Oluşturulmasında ARIMA, LSTM ve Hibrit Modellerin Kullanılabilirliği: Üretim İşletmesi Örneği" konulu doktora tez çalışması ile devam ettirmektedir. 2010 yılından beri Düzce Üniversitesi Kaynaşlı Meslek Yüksekokulu'nda öğretim görevlisi olarak çalışmaktadır. Evli ve iki çocuk annesidir.