

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENERJİ YÖNETİMİ VE TEKNOLOJİLERİ ANABİLİM DALI**

**YAPAY SİNİR AĞLARI İLE DENİZLİ İLİ DOĞAL GAZ
TÜKETİM ANALİZİ VE TAHMİNİ**

YÜKSEK LİSANS TEZİ

CAHİT YILMAZ

DENİZLİ, AĞUSTOS - 2022

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENERJİ YÖNETİMİ VE TEKNOLOJİLERİ ANABİLİM DALI**



**YAPAY SİNİR AĞLARI İLE DENİZLİ İLİ DOĞAL GAZ
TÜKETİM ANALİZİ VE TAHMİNİ**

YÜKSEK LİSANS TEZİ

CAHİT YILMAZ

DENİZLİ, AĞUSTOS - 2022

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu alıřmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan alıřmalara atfedildiđine beyan ederim.

Cahit YILMAZ

ÖZET

**YAPAY SINIR AĞLARI İLE DENİZLİ İLİ DOĞAL GAZ TÜKETİM
ANALİZİ VE TAHMİNİ
YÜKSEK LİSANS TEZİ
CAHİT YILMAZ
PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ENERJİ YÖNETİMİ VE TEKNOLOJİLERİ ANABİLİM DALI
(TEZ DANIŞMANI:DR. ÖGR. ÜYESİ ŞENGÜL GÜVEN)**

DENİZLİ, AĞUSTOS - 2022

İnsanlık tarihi boyunca her zaman enerjiye ihtiyaç duyulmuştur. Sanayi devrimi ve sonrasında hem endüstrinin gelişimi hem de nüfusun artışı enerji talebini önemli oranda arttırmıştır. Her geçen yıl artan enerji talebi, günümüzde ağırlıklı olarak fosil kaynaklardan ve yenilenebilir enerji kaynaklarından karşılanmaktadır. Petrol ve kömür ile birlikte fosil kaynaklar arasında olan doğal gazın talep, ülkeler tarafından gerçekleştirilen şebeke yatırımları sonucu ulaşılan tüketici sayısındaki yükselme ile önemli bir artış göstermiştir. Bu sebeple doğal gaz, yurtdışından doğal gaz ithal eden ülkeler için ekonomik, siyasi ve sosyolojik açıdan kritik bir önem taşımaktadır.

Türkiye’de son zamanlarda gerçekleştirilen doğal gaz arama faaliyetleri sonucunda önemli oranda doğal gaz rezervleri tespit edilmekle birlikte halihazırda doğal gazın yaklaşık %99’u yurtdışından ithal edilmektedir. Bu nedenle doğal gaz sektörünün dengeli bir yapıda ilerleyebilmesi, ekonomik istikrar ve enerji arzı güvenliği hususlarında doğal gaz tüketim tahmini önemli bir rol oynamaktadır.

Bu çalışmada, çok katmanlı algılayıcı (MLP), uzun-kısa süreli bellek (LSTM) ve iki yönlü uzun-kısa süreli bellek (BİLSTM) yapay sinir ağı yöntemleri kullanılarak Denizli iline ait günlük doğal gaz tüketim tahmini gerçekleştirilmiş, sonuçlar çoklu regresyon ve rassal orman yöntemleri ile elde edilen tahmin sonuçlarıyla karşılaştırılmıştır. Çalışmada doğal gaz tüketimi üzerinde etkisi olduğu öngörülen bağımsız birim sayısı, doğal gaz satış fiyatı, günlük ortalama sıcaklık, günlük maksimum, minimum sıcaklık farkı, günlük ortalama nispi nem, günlük ortalama rüzgâr hızı, günlük toplam yağış, günlük güneşlenme süresi ve günlük bulutluluk verileri kullanılmıştır. Tüketim verileri Enerjya Denizli Gaz Dağıtım A.Ş.’den temin edilmiştir. Veriler 2009 ile 2020 yılları arasındaki Denizli ili günlük Sm^3 cinsinden serbest olmayan abone ve Kademe 1 tipindeki serbest tüketicilere ait tüketimleri içermektedir.

İlgili veri setinin 10 yıllık kısmı eğitim son bir yıllık kısmı test verisi olarak kullanılmıştır. Veriler analizi R Studio uygulamasında, tahmin işlemleri Jupyter Lab uygulamasında gerçekleştirilmiştir. Elde edilen sonuçlarda en iyi sonucu veren modelin tahmin değerleri test verisi ile karşılaştırılmıştır. Ek olarak çoklu regresyon ve rassal orman yöntemleri ile gerçekleştirilen tahmin işlemlerinden elde edilen sonuçlar yapay sinir ağı modellerinden elde edilen tahmin sonuçlarıyla karşılaştırılmıştır.

ANAHTAR KELİMELER: Yapay Sinir Ağları, Doğal Gaz, Tahmin, Tüketim.

ABSTRACT

ANALYSIS AND FORECASTING OF NATURAL GAS CONSUMPTION IN DENİZLİ PROVINCE WITH ARTIFICIAL NEURAL NETWORKS

MSC THESIS

CAHİT YILMAZ

PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE
ENERGY MANAGEMENT AND TECHNOLOGIES
(SUPERVISOR: ASSIST. PROF. DR. ŞENGÜL GÜVEN)

DENİZLİ, AUGUST 2022

Energy has always been needed throughout human history. During and after the industrial revolution, both the development of the industry and the increase in the population increased the energy demand significantly. Increasing energy demand with each passing year is mostly met by fossil sources and renewable energy sources. The demand for natural gas, which is among fossil resources along with oil and coal, has increased significantly with the increase in the number of consumers reached as a result of network investments made by countries. For this reason, natural gas has a critical economic, political and sociological importance for countries importing natural gas from abroad.

Although a significant amount of natural gas reserves have been identified as a result of the natural gas exploration activities carried out recently in Turkey, approximately 99% of the natural gas is currently imported from abroad. For this reason, natural gas consumption estimation plays an important role in the balanced development of the natural gas sector, economic stability and energy supply security.

In this study, the daily natural gas consumption estimation of Denizli province was realized by using multilayer perceptron (MLP), long-short-term memory (LSTM) and bidirectional long-short-term memory (BiLSTM) artificial neural network methods. The results were compared with the estimation results obtained by multiple regression and random forest methods. In the study, the number of independent units, natural gas sales price, daily average temperature, daily maximum, minimum temperature difference, daily average relative humidity, daily average wind speed, daily total precipitation, daily sunshine duration and daily cloudiness were used. These parameters are predicted to affect natural gas consumption. Consumption data was obtained from Enerya Denizli Gaz Dağıtım A.Ş. The data includes daily consumption in Sm³ of non-free consumers and Level 1 eligible consumers in Denizli province between 2009 and 2020.

The 10-year part of the relevant data set was used as the training data and the last one-year part was used as the test data. Data analysis was performed in R Studio and estimation was performed in Jupyter Lab. The prediction values of the model that gave the best result in the obtained results were compared with the test data. In addition, the results obtained from the estimation processes performed with multiple regression and random forest methods were compared with the estimation results obtained from artificial neural network models.

KEYWORDS: Artificial Neural Network, Natural Gas, Forecasting, Consumption.

İÇİNDEKİLER

Sayfa

ÖZET.....	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ	v
TABLO LİSTESİ	viii
SEMBOLE ve KISALTMA LİSTESİ	ix
ÖNSÖZ.....	x
1. GİRİŞ.....	1
1.1 Literatür Özeti	2
2. DOĞAL GAZ.....	5
2.1 Enerji Kaynağı Olarak Doğal Gaz Kavramına Genel Bakış	6
2.2 Dünya Doğal Gaz Sektörünün Görünümü	9
2.2.1 Dünya Doğal Gaz Rezervleri Ve Üretimi.....	11
2.2.2 Dünya Doğal Gaz Tüketimi.....	15
2.3 Türkiye Doğal Gaz Sektörünün Görünümü	17
2.3.1 Türkiye Doğal Gaz Piyasasının Yapısı.....	18
2.3.2 Rezervler	19
2.3.3 Üretim	20
2.3.4 İthalat	23
2.3.5 İhracat	27
2.3.6 Depolama	28
2.3.7 Toptan Satış	29
2.3.8 Sıkıştırılmış Doğal Gaz (CNG).....	30
2.3.9 İletim	31
2.3.10 Dağıtım	32
2.3.11 Tüketim.....	33
2.3.12 Tarife Ve Fiyatlandırma.....	35
3. TALEP TAHMİN.....	36
3.1 Talep Tahmin Yöntemleri	38
3.2 Nitel (Kalitatif) Talep Tahmin Yöntemleri	38
3.3 Nicel (Kantitatif) Talep Tahmin Yöntemleri.....	39
3.3.1 Regresyon Analizi.....	40
3.3.2 Korelasyon Yöntemi	43
3.3.3 Basit Hareketli Ortalamalar Yöntemi	45
3.3.4 Basit Üssel Düzeltme Yöntemi.....	45
3.3.5 Birleştirilmiş Otoregresif Hareketli Ortalamalar (Box-Jenkins) Yöntemi	46
3.3.6 Yapay Sinir Ağları Metodu İle Talep Tahmin.....	47
4. YAPAY SİNİR AĞLARI.....	48
4.1 Yapay Sinir Ağlarının Genel Tanımı	48
4.2 Yapay Sinir Ağlarının Dezavantajları	49
4.3 Yapay Sinir Ağlarının Kullanım Alanları	50
4.4 Yapay Sinir Hücresinin Yapısı Ve Temel Elemanları	51
4.5 Yapay Sinir Hücresinin Çalışma Prensipleri.....	54
4.6 Yapay Sinir Ağları Yapısı	55

4.7	Yapay Sinir Ağlarının Temel Öğrenme Kuralları	57
4.8	Yapay Sinir Ağlarının Sınıflandırılması.....	58
4.8.1	Öğrenme Yapısına Göre Yapay Sinir Ağlarının Sınıflandırılması59	
4.8.1.1	Eğitmeli (supervised) Öğrenme	59
4.8.1.2	Takviyeli (reinforcement) Öğrenme	60
4.8.1.3	Eğitmesiz (unsupervised) Öğrenme	60
4.8.2	Ağ Yapısına Göre Yapay Sinir Ağlarının Sınıflandırılması.....	61
4.8.2.1	İleri Beslemeli Yapay Sinir Ağları.....	61
4.8.2.2	Geri Beslemeli Yapay Sinir Ağları	62
5.	YAPAY SINİR AĞLARI METODU KULLANILARAK DENİZLİ İLİ	
	DOĞAL GAZ TÜKETİM TAHMİN UYGULAMASI	64
5.1	Denizli İli Tüketim Analizi	64
5.2	Doğal Gaz Tüketimine Etki Eden Parametreler	66
5.2.1	Doğal Gaz Kullanan Bağımsız Birim Sayısı	66
5.2.2	Sıcaklık	68
5.2.3	Nem.....	70
5.2.4	Rüzgâr Hızı	72
5.2.5	Yağış	74
5.2.6	Güneşlenme Süresi	76
5.2.7	Bulutluluk	78
5.2.8	Doğal Gaz Satış Fiyatı	80
5.3	Tüketim, Doğal Gaz Kullanan Bağımsız Birim Sayısı, Meteorolojik Parametreler ve Doğal Gaz Satış Fiyatı Karşılaştırılması	82
5.4	Çok Katmanlı Algılayıcı (MLP) Yapay Sinir Ağı, Uzun Kısa Süreli Bellek (LSTM) Yapay Sinir Ağı, İki Yönlü Uzun Kısa Süreli Bellek (BILSTM) Yapay Sinir Ağı, Rassal Orman ve Çok Değişkenli Doğrusal Regresyon Yöntemlerinin Tahmin İçin Uygulanması.....	83
5.4.1	Çok Katmanlı Algılayıcı (MLP) Yapay Sinir Ağı Uygulaması ..	86
5.4.2	Uzun Kısa Süreli Bellek (LSTM) Yapay Sinir Ağı Uygulaması.	90
5.4.3	İki Yönlü Uzun Kısa Süreli Bellek (BILSTM) Yapay Sinir Ağı Uygulaması	94
5.4.4	Rassal Orman (Random Forest) Uygulaması	97
5.4.5	Çok Değişkenli Doğrusal Regresyon Uygulaması	99
5.5	Tahmin Sonuçlarının Karşılaştırılması.....	100
6.	SONUÇ VE ÖNERİLER	102
7.	KAYNAKLAR.....	105
8.	ÖZGEÇMİŞ.....	111

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Doğal gaz oluşumu	5
Şekil 2.2: İşlenmemiş doğal gazın temel elemanları.....	6
Şekil 2.3: Doğal gaz rezervlerinin şematik gösterimi.	7
Şekil 2.4: Geleneksel olmayan kaynakların sınıflandırılması.....	8
Şekil 2.5: 1990-2040 yılları enerji kaynağı bazında küresel enerji talebi.....	10
Şekil 2.6: 1990-2040 yılları bölge bazında küresel enerji talebi.....	10
Şekil 2.7: 2019 yılı dünya ispatlanmış doğal gaz rezervleri dağılımı	11
Şekil 2.8: 2019 yılı sonu itibariyle en fazla doğal gaz rezervine sahip 10 ülke.12	
Şekil 2.9: 2010-2019 yılları arasında bölgelere göre doğal gaz üretimi	12
Şekil 2.10: 2018-2024 yılları arasında bölgelere göre doğal gaz üretim tahmini	13
Şekil 2.11: 2018-2024 yılları dünya doğal gaz üretimi artış/azalış tahmini	14
Şekil 2.12: 2019 yılı dünya konvansiyonel ve konvansiyonel olmayan gaz üretimi	14
Şekil 2.13: 2010-2019 yılları dünya doğal gaz tüketimi	15
Şekil 2.14: 2018-2024 yılları dünya doğal gaz tüketim tahmini.....	16
Şekil 2.15: 2018-2024 yılları dünya doğal gaz tüketimi artış/azalış tahmini....	16
Şekil 2.16: 2019 yılı ulusal enerji denge durumu	17
Şekil 2.17: 2019 yılı Türkiye birincil enerji kaynakları arzı dağılımı.....	18
Şekil 2.18: Yıllara göre doğal gaz arz haritası	19
Şekil 2.19: 2020 yılı doğal gaz üretimi yapan toptan satış lisansı sahibi şirketlerin üretim oranları	21
Şekil 2.20: 2010-2020 yılları arasında Türkiye doğal gaz üretimi.....	22
Şekil 2.21: 2020 yılı üretim sahalarının bulunduğu illere göre doğal gaz üretim oranları	23
Şekil 2.22: 2010-2020 yılları doğal gaz ithalat oranları.....	24
Şekil 2.23: Türkiye doğal gaz tedarik haritası	24
Şekil 2.24: 2020 yılı uzun dönemli ithalat lisansı kapsamında ithalat gerçekleştirilen ülkelerin miktara göre oransal dağılımı.....	25
Şekil 2.25: 2020 yılı spot LNG ithalatının, ithalat yapılan ülkelere göre dağılımı	26
Şekil 2.26: Yıllara göre Türkiye doğal gaz ihracat miktarı.....	28
Şekil 2.27: 2020 yılı aylara göre ithalat, tüketim ve depolama miktarları	29
Şekil 2.28: 2020 yılı toptan satış faaliyeti gerçekleştiren şirketlerin doğal gaz arzı oranları	30
Şekil 2.29: 2020 yılı nihai tüketicilere yapılan satışların türelere göre dağılımı	31
Şekil 2.30: 2020 yılı il bazlı doğal gaz abone sayısı	33
Şekil 2.31: 2020 yılı Türkiye doğal gaz tüketimi sektör dağılımı.....	33
Şekil 2.32: Sektörlere göre yıllık doğal gaz tüketimlerinin karşılaştırılması....	34
Şekil 2.33: 2020 yılı konut ve sanayi tüketicilerine dağıtım şirketleri ve tedarikçi şirketler tarafından satılan doğal gazın fiyat oluşumları	35
Şekil 3.1: Regresyon doğrusu	42
Şekil 3.2: İki değişken arasında bulunan korelasyonun serpilme diyagramı ile gösterilmesi	44

Şekil 4.1: Biyolojik sinir hücresi.....	51
Şekil 4.2: Yapay sinir hücresi	52
Şekil 4.3: Basit yapay sinir hücresi modeli.....	55
Şekil 4.4: Yapay sinir ağını oluşturan katmanlar	56
Şekil 4.5: Yapay sinir ağı örneği.....	57
Şekil 4.6: Eğitmeli (supervised) öğrenme yapısı	59
Şekil 4.7: Takviyeli (reinforcement) öğrenme yapısı	60
Şekil 4.8: Eğitmesiz (unsupervised) öğrenme yapısı	61
Şekil 4.9: Çok katmanlı ileri beslemeli yapay sinir ağı	62
Şekil 4.10: Çok katmanlı geri beslemeli yapay sinir ağı.....	63
Şekil 5.1: 2009-2020 yılları arasında serbest olmayan abone ve kademe 1 tipindeki serbest tüketicilerin toplam tüketim grafiği.	65
Şekil 5.2: 2009-2020 yılları arasında gazı açılan tüketim noktalarının kümülatif BBS sayısı grafiği.....	67
Şekil 5.3: Doğal gaz tüketimi ve BBS arasındaki korelasyon analizi.....	68
Şekil 5.4: Günlük doğal gaz tüketimi ve BBS arasındaki korelasyon grafiği... 68	
Şekil 5.5: Günlük doğal gaz tüketimi ve günlük ortalama sıcaklığın zaman ile değişim grafiği.....	69
Şekil 5.6: Günlük doğal gaz tüketimi ve günlük ortalama sıcaklık arasındaki korelasyon analizi.....	70
Şekil 5.7: Günlük doğal gaz tüketimi ve günlük ortalama sıcaklık arasındaki korelasyon grafiği.....	70
Şekil 5.8: Günlük doğal gaz tüketimi, günlük ortalama bağıl nem ve günlük ortalama sıcaklığın zaman içerisindeki değişim grafiği.....	71
Şekil 5.9: Günlük doğal gaz tüketimi ve günlük ortalama bağıl nem arasındaki korelasyon analizi.....	72
Şekil 5.10: Günlük doğal gaz tüketimi ve günlük ortalama bağıl nem arasındaki korelasyon grafiği.....	72
Şekil 5.11: Günlük doğal gaz tüketimi ve günlük ortalama rüzgâr hızının zaman içerisindeki değişim grafiği.....	73
Şekil 5.12: Günlük doğal gaz tüketimi ve günlük ortalama rüzgâr hızı arasındaki korelasyon analizi.....	73
Şekil 5.13: Günlük doğal gaz tüketimi ve günlük ortalama rüzgâr hızı arasındaki korelasyon grafiği.....	74
Şekil 5.14: Günlük doğal gaz tüketimi ve günlük toplam yağış miktarının zaman içerisindeki değişim grafiği.....	75
Şekil 5.15: Günlük doğal gaz tüketimi ve günlük toplam yağış miktarı arasındaki korelasyon analizi.....	75
Şekil 5.16: Günlük doğal gaz tüketimi ve günlük toplam yağış miktarı arasındaki korelasyon grafiği.....	76
Şekil 5.17: Günlük doğal gaz tüketimi ve günlük ortalama güneşlenme süresinin zaman içerisindeki değişim grafiği.	77
Şekil 5.18: Günlük doğal gaz tüketimi ve günlük ortalama güneşlenme süresi arasındaki korelasyon analizi.	77
Şekil 5.19: Günlük doğal gaz tüketimi ve günlük ortalama güneşlenme süresi arasındaki korelasyon grafiği.	78
Şekil 5.20: Günlük doğal gaz tüketimi ve günlük ortalama bulutluluğun zaman içerisindeki değişim grafiği.....	79
Şekil 5.21: Günlük doğal gaz tüketimi ve günlük ortalama bulutluluk arasındaki korelasyon analizi.....	79

Şekil 5.22: Günlük doğal gaz tüketimi ve günlük ortalama bulutluluk arasındaki korelasyon grafiği.....	80
Şekil 5.23: Günlük doğal gaz tüketimi ve doğal gaz satış fiyatlarının zaman içerisindeki değişim grafiği.....	81
Şekil 5.24: Günlük doğal gaz tüketimi ve doğal gaz satış fiyatı arasındaki korelasyon analizi.....	81
Şekil 5.25: Günlük doğal gaz tüketimi ve doğal gaz satış fiyatı arasındaki korelasyon grafiği.....	82
Şekil 5.26: Günlük doğal gaz tüketimi, gazı açılan bağımsız birim sayısı, ortalama sıcaklık, nem, rüzgar hızı, yağış miktarı, güneşlenme süresi, bulutluluk ve doğal gaz satış fiyatının zaman ile değişim grafiği..	83
Şekil 5.27: Çok katmanlı algılayıcı birinci aşama en iyi model gösterimi.	86
Şekil 5.28: Çok katmanlı algılayıcı birinci aşama tahmin performansı grafiği..	87
Şekil 5.29: ReLU aktivasyon fonksiyonunun grafik gösterimi.....	88
Şekil 5.30: Çok katmanlı algılayıcı ikinci aşama en iyi model gösterimi.....	89
Şekil 5.31: Çok katmanlı algılayıcı ikinci aşama tahmin performansı grafiği..	89
Şekil 5.32: Uzun kısa süreli bellek birinci aşama en iyi model gösterimi.	90
Şekil 5.33: Uzun kısa süreli bellek birinci aşama tahmin performansı grafiği. .	91
Şekil 5.34: Tanh aktivasyon fonksiyonunun grafik gösterimi.	92
Şekil 5.35: Uzun kısa süreli bellek ikinci aşama en iyi model gösterimi.	93
Şekil 5.36: Uzun kısa süreli bellek ikinci aşama tahmin performansı grafiği. .	93
Şekil 5.37: İki yönlü uzun kısa süreli bellek birinci aşama en iyi model gösterimi.	94
Şekil 5.38: İki yönlü uzun kısa süreli bellek birinci aşama tahmin performansı grafiği.	95
Şekil 5.39: İki yönlü uzun kısa süreli bellek ikinci aşama en iyi model gösterimi.	96
Şekil 5.40: İki yönlü uzun kısa süreli bellek ikinci aşama tahmin performansı grafiği.	96
Şekil 5.41: Rassal orman yöntemi örnek modeli.	98
Şekil 5.42: Çalışmada kullanılan parametreler.	98
Şekil 5.43: Rassal orman tahmin performansı grafiği.....	99
Şekil 5.44: Çok değişkenli doğrusal regresyon tahmin performansı grafiği... .	100
Şekil 5.45: Tahmin yöntemleri performans grafiği.....	101

TABLO LİSTESİ

Sayfa

Tablo 2.1: Birincil enerji kaynakları kullanım istatistikleri	9
Tablo 2.2: 2013-2020 yılları arasında, doğal gaz ithalatı gerçekleştiren şirketlerin ithalat türüne göre miktar ve payları	26
Tablo 2.3: 2008-2020 yılları arasında spot LNG ithalatı gerçekleştiren şirketlerin payları.....	27
Tablo 2.4: Yıllara göre toplam doğal gaz tüketim miktarları.....	34
Tablo 4.1: Toplama fonksiyonu örnekleri.....	53
Tablo 4.2: Aktivasyon fonksiyonu örnekleri	54
Tablo 5.1: Tahmin ve gerçek tüketim verisinin hesaplanan MAPE değerleri.	101

SEMBOL ve KISALTMA LİSTESİ

°C	:	Derece Santigrat
ADAM	:	A Method for Stochastic Optimization
AR	:	Autoregressive
ARIMA	:	Autoregressive Integrated Moving Average
ART	:	Adaptive Resonance Theory
BBS	:	Bağımsız Birim Sayısı
BILSTM	:	Bidirectional Long-Short Term Memory
BOTAŞ	:	Boru Hatları İle Petrol Taşıma Anonim Şirketi
BP	:	British Petroleum
C ₂ H ₆	:	Etan
C ₃ H ₈	:	Pentan
C ₃ H ₈	:	Propan
C ₄ H ₁₀	:	Bütan
CH ₄	:	Metan
CO ₂	:	Karbon dioksit
EPDK	:	Enerji Piyasası Düzenleme Kurumu
FSRU	:	Floating Storage Regasification Unit
H ₂ S	:	Hidrojen sülfür
He	:	Helyum
Kcal	:	Kilokalori
KDV	:	Katma Değer Vergisi
KM	:	Kilometre
kg/m ²	:	Kilogram/Metrekare
kg/m ³	:	Kilogram/Metreküp
LNG	:	Liquefied Natural Gas
LR	:	Linear Regression
LSTM	:	Long-Short Term Memory
LVQ	:	Learning Vector Quantization
m ³	:	Metreküp
MA	:	Moving Average
MAPE	:	Mean Absolute Percentage Error
MAPEG	:	Maden ve Petrol İşleri Genel Müdürlüğü
MLP	:	Multi Layer Perceptron
MSE	:	Mean Squared Error
m/s	:	Metre/Saniye
N ₂	:	Azot
ÖTV	:	Özel Tüketim Vergisi
r	:	Korelasyon Katsayısı
ReLU	:	Rectified Linear Unit
RF	:	Random Forest
Rmsprop	:	Root Mean Square Error Probability
SOM	:	Self Organizing Map
TEP	:	Ton Eşdeğer Petrol
TPAO	:	Türkiye Petrolleri Anonim Ortaklığı
vpe / g	:	Varil Petrol Eşdeğeri / Gün

ÖNSÖZ

Bu tez çalışması ile Denizli ili doğal gaz tüketim, fiyat ve bazı meteoroloji verileri kullanılarak doğal gaz dağıtım ve ticaret faaliyeti gerçekleştiren işletmeler başta olmak üzere birçok işletme tarafından operasyonel süreçlerde kullanılacak doğal gaz tüketim tahmini gerçekleştirilmiştir.

Tez çalışmam süresince yönlendirmeleri ve desteği için tez danışmanım Sayın Dr. Öğr. Üyesi Şengül GÜVEN'e teşekkür ederim.

Her zaman sevgilerini, desteklerini ve güvenlerini esirgemeyen değerli aileme teşekkür ederim.

Tez çalışmama ve bana olan katkılarından dolayı, birlikte çalışma imkanı bulduğum değerli Enerya Enerji A.Ş. yöneticileri ve personelleri ile Asilhan Mehmet NACAR ve Haydar Safa KILIÇ'a teşekkür ederim.

1. GİRİŞ

Bu çalışmada ülkeler için ekonomik ve politik açıdan kritik öneme sahip ve enerji alanının bir konusu olan doğal gaz tüketiminin yapay sinir ağları ile tahmin işlemi gerçekleştirilmiştir. Türkiye doğal gaz üretimi olarak toplam doğal gaz arzının %0,7'sini yerli olarak üretebilmektedir. %99,3 oranında ise doğal gaz ithal etmektedir (TPAO 2021).

2021 yılı sonu itibariyle Türkiye'de doğal gazın birincil enerji kaynakları içerisindeki oranı ise %27 olarak gerçekleşmiştir (TPAO 2021). Bu oran doğal gaz dağıtımının yaygınlaşması ile orantılı olarak artış göstermektedir. Türkiye'de doğal gaz dağıtım lisansına sahip 72 adet şirket tarafından 81 ilde 594 ilçe ve 49 beldeye doğal gaz arzı sağlanmış durumdadır (EPDK 2021). Özellikle doğal gaz tüketiminde ithalata bağımlı ülkeler için olduğu gibi birincil enerji kaynakları kullanımındaki payı ve yaygınlığı dikkate alındığında Türkiye için de doğal gaz tüketimi için uygulanacak doğru tahmin modelleri ticari ve ekonomik olarak önemli bir avantaj sağlayacaktır.

Tahmin konusunda gelinen noktada yapay zeka temelinde geliştirilen tahmin modelleri, klasik yöntemlere göre daha başarılı sonuçlar verebilmektedir. Yapay zekâ temelli tahmin konularından olan yapay sinir ağları biyolojik sinir hücresinden esinlenerek geliştirilmiştir. Biyolojik sinir hücreleri çevreden algılayıcılar aracılığı ile alınan sinyalleri yorumlayan, işleyen ve sonuç üreten yapılardır. Yapay sinir ağları metodolojisine göre yapay sinir hücreleri de biyolojik sinir hücreleri gibi modellenebilmekte ve birbiri ile ilişki kurabilmektedir. Yapay sinir hücreleri de biyolojik sinir hücreleri gibi girdileri yorumlayıp çıktı üretmektedirler (Akın 2017).

Bu kapsamda, çalışmada Denizli iline ait 01.01.2009 ile 31.12.2020 tarihleri arasındaki günlük konut doğal gaz tüketimi ve meteoroloji verileri ile yapay sinir ağları kullanılarak tahmin işlemi gerçekleştirilmiştir. Çalışmada çok katmanlı yapay sinir ağı (MLP- Multi Layer Perceptron), uzun-kısa süreli bellek yapay sinir ağı (LSTM-Long-Short Term Memory), iki yönlü uzun-kısa süreli bellek yapay sinir ağı (BiLSTM-Bidirectional Long-Short Term Memory) modelleri ile lineer regresyon (LR-Linear Regression) ve random forest (RF) modelleri kullanılmıştır. Yapay sinir ağı modelleri

hiperparametre optimizasyonu yöntemi ile birinci aşamada 500, ikinci aşamada 300 tekrar ve her tekrarda 100 eğitim adımı, katman sayısı 1-5 arasında, öğrenme katsayısı 0,001, 0,0001, 0,00001, 0,000001 değerleri arasında, nöron sayısı da 16-64 arasında seçim rastgele olacak şekilde çalıştırılmıştır. Elde edilen sonuçlar beşinci ve altıncı bölümde detaylı bir şekilde açıklanmıştır.

1.1 Literatür Özeti

Talep tahmini, üretim planlaması, yönetim bilimi, enerji gibi birçok alanda işletmeler için stratejik öneme sahip bir konudur. Bakım-onarım, lojistik, üretim gibi çok sayıda iş sürecinde kullanılmaktadır. Tahmin konusunda yapay sinir ağları ile birçok disiplin ve endüstriyel alanda gerçekleştirilmiş çok sayıda tahmin çalışması mevcuttur. Konuyla ilgili çalışmalardan bazıları aşağıda özetlenmiştir.

Wong ve diğ. (1997), yapmış oldukları çalışmada 1988-1995 yıllarında yayınlanmış makaleleri incelemiş ve yapay sinir ağı uygulamalarının işletme faaliyetlerinde kullanımının arttığını gözlemlemiştir. Çalışmada, yapay sinir ağlarının yeni teknolojilere kolay uyum sağladığı, teknolojik ve yapay zekâ alanındaki gelişmelerin yapay sinir ağlarının işletme faaliyetlerinde kullanımı hususunda yeni fırsatlar oluşturduğu ifade edilmiştir.

Kellova (2008), yapmış olduğu çalışmada kısa dönemli elektrik talep tahmini üzerinde çalışmış, elektrik talep tahmininin doğrusal olmayan bir problem olduğu ve bu tarz problemlerde yapay sinir ağlarının olumlu sonuçlar verdiği ifade edilmiştir.

Çuhadar ve Kayacan (2005), yapmış oldukları çalışmada yapay sinir ağı kullanarak Türkiye'deki konaklama işletmelerinin doluluk oranlarını tahmin etmişlerdir. Çalışmada yapay sinir ağları kullanılarak Türkiye'deki konaklama işletmelerinde doluluk oranlarının tahmin edilebileceğini ve bu yöntemin karar vericilerin kullanabileceği geleneksel yöntemlere alternatif oluşturduğunu ifade edilmiştir.

Efendigil ve diğ. (2009), yapmış oldukları çalışmada yapay sinir ağları ve nöro-bulanık sistemlerin tahmin hususunda karşılaştırmalı analizini yapmışlardır.

Çalışmada Türkiye İstanbul ilinde dayanıklı tüketim ürünleri alanında faaliyet gösteren bir işletmenin gerçek verileri kullanılmıştır. Çalışma ile belirsiz müşteri taleplerine ilişkin çok düzeyli tedarik zinciri yapısında yapay sinir ağları teknikleri ile karşılaştırmalı bir metodoloji sunmuşlardır.

Shakya ve diğ. (2010), yapmış oldukları çalışmada sinir ağı tabanlı talep modeli oluşturmuş ve bu model temelinde fiyat politikası optimizasyonunun evrimsel algoritmalarla kullanımını hakkında bilgi vermişlerdir. Bu yaklaşımla karmaşık modellerin ve talep çeşitliğinin esnek ve çok yönlü bir şekilde çözümlenebileceğini ifade etmişlerdir.

Keçebaş ve diğ. (2012), yapmış oldukları çalışmada jeotermal ısıtma sisteminin ekserji verimliliğini tahmin etmek amacıyla yapay sinir ağı modellemesi kullanmışlardır. Sistemin ekserji verimliliğini ortam sıcaklığı, akış hızı ve kuyu başı sıcaklığına göre tahmin etmek için geri yayılım öğrenme algoritmasına dayalı bir YSA modellemesi geliştirmişlerdir. Sonuç olarak yapay sinir ağlarının jeotermal bölgesel ısıtma sistemlerinin ekserji verimliliğini tahmin etmede yüksek doğruluk ve güvenilirlik sağlayabileceğini ifade etmişlerdir.

Hill ve diğ. (1994), yapmış oldukları çalışmada zaman serisi tahmini, regresyona dayalı tahmin ve istatistiksel modelleri gözden geçirmiş, yapay sinir ağlarının tahmin işlemlerinde kullanım potansiyelini değerlendirmişlerdir.

Cam ve diğ. (2018), yapmış oldukları çalışmada Türkiye'nin 1960-2013 yılları için enerji verimliliğini TOPSIS (Technique for Order Preference by Similarity to the Ideal Solution) temelinde ARDL (Autoregressive Distributed Lag) otoregresif dağıtılmış gecikme ve yapay sinir ağları kullanarak değerlendirmişlerdir. Çalışma sonucuna göre Türkiye'nin enerji verimliliğinin yıllar içerisinde artma eğiliminde olduğunu ve yapay sinir ağları ile elde edilen sonuçlarda enerji verimliliğini etkileyen en önemli değişkenin kişi başına sermaye stoku olduğunu ifade etmişlerdir.

Moon ve diğ. (2019), yapmış oldukları çalışmada etkin enerji yönetimi için gerekli olan doğru yük tahmini konusunda yapay sinir ağlarında kullanılacak hiperparametrelerin belirlenmesinin kritik öneme sahip olduğunu belirtmişlerdir. İki

hiperparametrenin farklı kombinasyonları ile elektrik enerjisi tüketim tahmin modelleri oluşturmuşlar ve performanslarını karşılaştırmışlardır.

Del Real ve diğ. (2020), yapmış oldukları çalışmada enerji talebi tahmini gerçekleştirmek için derin öğrenme tekniklerini kullanmışlardır. Action de Recherche Petite Echelle Grande Echelle meteoroloji verileri ile yapay sinir ağı ve evrimsel yapay sinir ağı teknikleri birlikte kullanılarak Fransa enerji talebi tahmini üzerinde çalışmışlardır. Sonuç olarak önerilen çözümün otoregresif entegre hareketli ortalamalar ve geleneksel yapay sinir ağı metotlarına göre yüksek doğrulukta tahmin gerçekleştirdiğini ifade etmişlerdir.

Puri ve Kumar (2021), yapmış oldukları çalışmada Himalaya bölgesinde Pir Panjal olarak adlandırılan sıradağlarında deniz seviyesinden 1200 m yükseklikte rüzgâr akışına engel olmayacak şekilde seçilen alanlardan oluşan bir bölgede hava yoğunluğu, rüzgâr hızı ve sıcaklık verilerini toplamış, 30 günlük veri üzerinden yapay sinir ağları yöntemi ile tahmin işlemi gerçekleştirmişlerdir.


Mejias ve diğ. (2017), yapmış oldukları çalışmada Şili'deki ofis binalarının ısıtma ve soğutma enerji taleplerini, enerji ve karbondioksit tüketimlerini tahmin etmek için lineer regresyon ve yapay sinir ağı modellerini karşılaştırmışlardır. Sonuç olarak yapay sinir ağı modellerinin tahmin işleminde lineer regresyon modeline göre tatmin edici bir performans gösterdiğini ifade etmişlerdir.

Ascione ve diğ. (2017) yapmış oldukları çalışmada, 1920-1970 yılları arasında güney İtalya'da inşa edilen ofis binalarında enerji performansı tahmin işlemi gerçekleştirmişlerdir. Sonuç olarak bina enerji performansını yapay sinir ağları ile tahmin için daha önce gerçekleştirilen çalışmalarla uyumlu sonuçlar elde etmişlerdir.

Bu çalışmada konuyla ilgili yapılan diğer çalışmalardan farklı olarak Denizli iline ait doğal gaz tüketim, abone BBS ve doğal gaz satış fiyatı verileri ve bazı meteorolojik veriler kullanılarak Python'da geliştirilen iki yönlü uzun kısa süreli bellek, uzun kısa süreli bellek, çok katmanlı algılayıcı yapay sinir ağı modelleri ve rassal orman, klasik regresyon yöntemleri ile zaman serisi yapısındaki doğal gaz tüketiminin tahmini gerçekleştirilmiş, ilgili yöntemlerin tahmin sonuçlarına göre değerlendirilmesi ve karşılaştırılması yapılmıştır.

2. DOĞAL GAZ

Doğal gaz hidrokarbon kökenli bir enerji kaynağıdır. Diğer fosil yakıtlarda olduğu gibi milyonlarca yıl önce yaşamış olan bitki ve hayvan artıklarının yer altında yüksek sıcaklık ve basınç altında uğradıkları kimyasal değişimin bir sonucu olarak meydana geldiği görüşü kabul görmektedir (Bayraç 2018). Doğal gaz oluşumu Şekil 2.1’de gösterilmiştir.



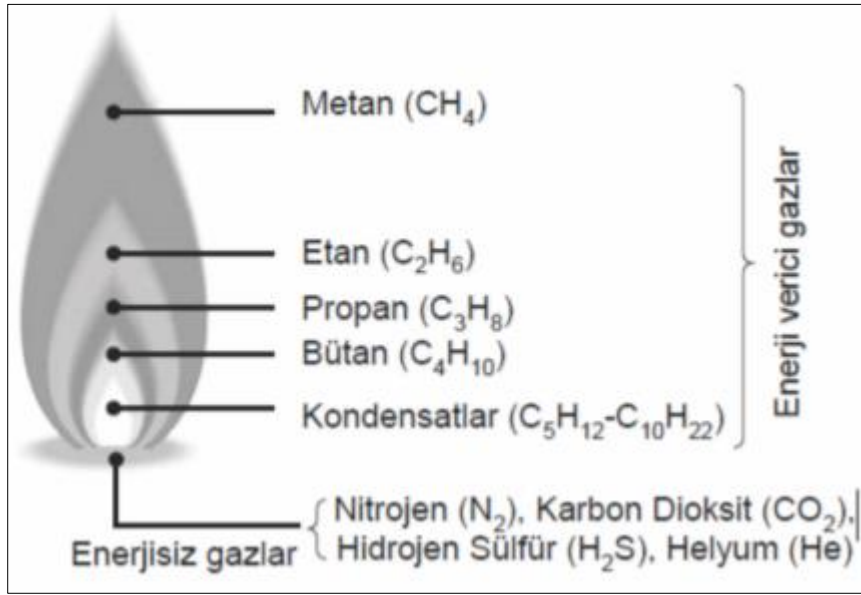
Şekil 2.1: Doğal gaz oluşumu (Esim 2021).

Doğal gazın keşfi antik zamanlara rastlamaktadır. Binlerce yıl önce kayaların arasından sızan gazların yanması ile fark edilmiştir. İran, Yunanistan ve Hindistan’da insanlar bu alevlerin etrafına dini uygulamaları için tapınaklar inşa etmişlerdir. Ancak doğal gazın enerji değeri yaklaşık milattan önce 900 yılına kadar bilinmemiştir. Bilinen ilk doğal gaz kuyusunun Çin’de milattan önce 211 yılında açıldığı düşünülmektedir. Kuyuların bambu direkleri ve ilkel vurma aletleri ile açıldığı, çıkarılan gazın kireçtaşlarının arasında bulunan kaya tuzunun kurutulması amacıyla kullanılmıştır. Avrupa’da doğal gaz, 1659’da Büyük Britanya’daki keşfedilmiş ancak 1790 yılına kadar ticarileşmemiştir. 1790 yılından itibaren Avrupa’nın büyük bir kısmında cadde ve sokakları aydınlatmak için kullanılmıştır. Amerika’da doğal gaz 1821 yılında Fredonia’da yaşayan insanlar tarafından bir dereden yüzeye çıkan gaz kabarcıklarının gözlemlenmesi ile keşfedilmiştir. Keşfedilen gaz küçük çaplı kurşun borularda aydınlatma ve pişirme amaçlı tüketicilere dağıtılmıştır. (Mokhatab ve diğ.

2006). 19. yüzyılda gerçekleşen yeni rezerv keşifleri, üretim, işletme ve dağıtım süreçlerinde kullanılan teknolojilerin gelişmesi ile birlikte doğal gazın kullanımı yaygınlaşmıştır. Günümüzde doğal gaz, endüstride ve konutlarda bireysel ve ticari amaçlarla yaygın olarak kullanılmaktadır.

2.1 Enerji Kaynağı Olarak Doğal Gaz Kavramına Genel Bakış


Doğal gaz, fosil kaynaklı, renksiz, kokusuz ve havadan hafiftir. Metan (CH_4), etan (C_2H_6), propan (C_3H_8), bütan (C_4H_{10}), azot (N_2), karbondioksit (CO_2), hidrojen sülfür (H_2S), helyum (He) gibi gazlardan oluşmaktadır. İzobütan, pentan ve benzeri ağır gazlarda içerebilmektedir. Karışımda en yüksek orana sahip olan gaz metan (CH_4) gazıdır.



Şekil 2.2: İşlenmemiş doğal gazın temel elemanları (Bulundu ve Say 2016).

Doğal gaz konvansiyonel bir kaynaktır. Üzerinde çok sayıda inceleme, araştırma ve ekonomik etütler yapılmış, teknolojiler üretilmiş pratik ve kolay kaynaklardır (Bulundu ve Say 2016). Şekil 2.3’de gösterildiği gibi bulunduğu yataкта ham petrolle birlikte bulunabilir. Bu durumda olan doğal gaza bağlı doğal gaz denilmektedir. Yeterli miktarda ham petrolün bulunmadığı yataklarda bulunan doğal gaza bağımsız doğal gaz denilmektedir. Doğal gaz, geçmişte petrol üretimi sırasında çıkan değersiz bir gaz olarak düşünülmüş ve yakarak uzaklaştırılmıştır. Ancak

günümüzde konutlarda ve endüstride kullanılan değerli ve stratejik bir enerji kaynağı olma konumuna gelmiştir (Bulundu ve Say 2016).



Şekil 2.3: Doğal gaz rezervlerinin şematik gösterimi (Bulundu ve Say 2016).

Doğal gaz sondaj ve kuyu tamamlama faaliyetleri sonrasında CO₂'nin ayrıştırılması, suyun giderilmesi, ağır hidrokarbonların ayrıştırılması, azotun giderilmesi, gazın temizlenmesi ve kurutma işlemlerinden sonra kullanıma sunulmaktadır (Bulundu ve Say 2016). Tanklar ve boru hatları ile son kullanıcılara ulaştırılan doğal gaz diğer fosil yakıtlara oranla daha düşük karbon emisyon değerine sahip bir enerji kaynağıdır (Lin ve Agyeman 2021). Doğal gazın kimyasal özellikleri aşağıdaki gibidir (Bulundu ve Say 2016).

- Renksiz, kokusuz, rutubetsiz, kuru ve zehirli olmayan bir gazdır.
- -162 °C de sıvılaşır.
- Yaklaşık %95'i metan olmak üzere yanıcı gazlardan oluşur.
- 1 m³ doğal gazın yanması ile 8250 kcal ısı açığa çıkar.
- Yanmanın tam sağlanamaması sonucu karbon monoksit açığa çıkar.
- Tutuşma sıcaklığı 650 °C, alev hızı 0,36 m/s'dir.
- Yoğunluğu 0 °C ve 1 atmosfer basınçta 0,67-0,8 kg/m³ arasında değişir.

- Kapalı bir hacimde hava ile %5-%15 oranında karışması durumunda patlayıcı bir özellik alır. Ateş ve kıvılcım ile teması durumunda patlama olayı gerçekleşir.

Bununla birlikte konvansiyel olmayan düşük geçirgenli sıkı kum taşı gazı, basen ortası gazı, kömür yatağı metanı, şeyl gazı ve metan hidratlar gibi formları da bulunmaktadır. Günümüzde dünyanın bazı bölgelerinde gelişen teknoloji ile birlikte geçirgenli sıkı kum taşı gazı ve kömür yatağı gazı konvansiyonel olarak değerlendirilmektedir. Konvansiyonel olmayan kaynaklar özel üretim teknikleri gerektiren, hidrodinamik etkilerden uzak ve büyük alanlara yayılmış kaynaklardır. Şekil 2.4’de gösterildiği gibi kaynakların çok az bir kısmı iyi kalitede özellikler sergilemektedir.



Şekil 2.4: Geleneksel olmayan kaynakların sınıflandırılması (Aydın ve diğ. 2020).

Diğer kısımlar daha düşük kalitede olup, ileri teknoloji ve yüksek yatırım gerektirmektedir. Bu kaynaklardan şeyl gazının yatay kuyu ve çok kademeli hidrolik çatlatma teknolojilerinin gelişmesi ile karlı bir şekilde üretimin sağlanması devrimsel bir gelişme olarak değerlendirilmektedir. Hidrokarbon piyasalarına etki eden şeyl devrimi ile şeyl gazı petrol endüstrisi için oyun değiştirici olarak görülmektedir (Aydın ve diğ. 2020).


2.2 Dünya Doğal Gaz Sektörünün Görünümü

Doğal gazın sanayi, ulaşım, konut ve ticarethaneler gibi temel alanlarda enerji kaynağı olarak kullanılması ile dünyadaki birincil enerji kaynakları arasındaki tüketim payı zamanla artmıştır. Toplumsal, ticari, çevresel ve ekonomik olarak önemli etkileri olan doğal gazın birincil enerji kaynakları arasındaki payı 2019 yılı sonu itibariyle 2018 yılına göre %0,2 artarak %24,2 olmuştur (BP 2020). Tablo 2.1’de birincil enerji kaynaklarının kullanım istatistikleri verilmiştir. Veriler göstermektedir ki, 2019 yılı sonu itibariyle dünya enerji tüketimi yaklaşık 7,8 exajoules artmıştır. Bu artışta en yüksek tüketim miktarı yenilenebilir enerji olmakla birlikte ikinci en büyük pay 2,8 exajoules ile doğal gazın olmuştur.

Tablo 2.1: Birincil enerji kaynakları kullanım istatistikleri (BP 2020).


Enerji Kaynağı	Tüketim (exajoules)	Yıllık Değişim (exajoules)	Birincil Enerji Kaynaklarındaki Oranı (%)	2018 Yılına Göre Değişim Yüzdesi (%)
Petrol	193	1,6	33,1%	-0,2%
Gaz	141,5	2,8	24,2%	0,2%
Kömür	157,9	-0,9	27,0%	-0,5%
Yenilenebilir	29	3,2	5,0%	0,5%
Su	37,6	0,3	6,4%	0,0%
Nükleer	24,9	0,8	4,3%	0,1%
Toplam	583,9	7,8		

Çeşitli ulusal ve uluslararası kurum ve kuruluşların gerçekleştirdiği projeksiyonlara göre petrol ve doğal gazın birincil enerji kaynakları tüketim miktarlarındaki yüksek paylarını uzun dönemde de koruyacakları öngörülmektedir. Şekil 2.5’de 1990-2040 yılları arasında enerji kaynağı bazında küresel enerji talep artış talebi öngörülleri verilmiştir. İstatistiklere göre enerji kaynaklarından doğal gaz ve yenilenebilir enerjide önemli ölçüde artış beklenirken, petroldeki payın 2040 yılına gelindiğinde %3-4 oranında düşmesi beklenmektedir.



Şekil 2.5: 1990-2040 yılları enerji kaynağı bazında küresel enerji talebi (TPAO 2020).

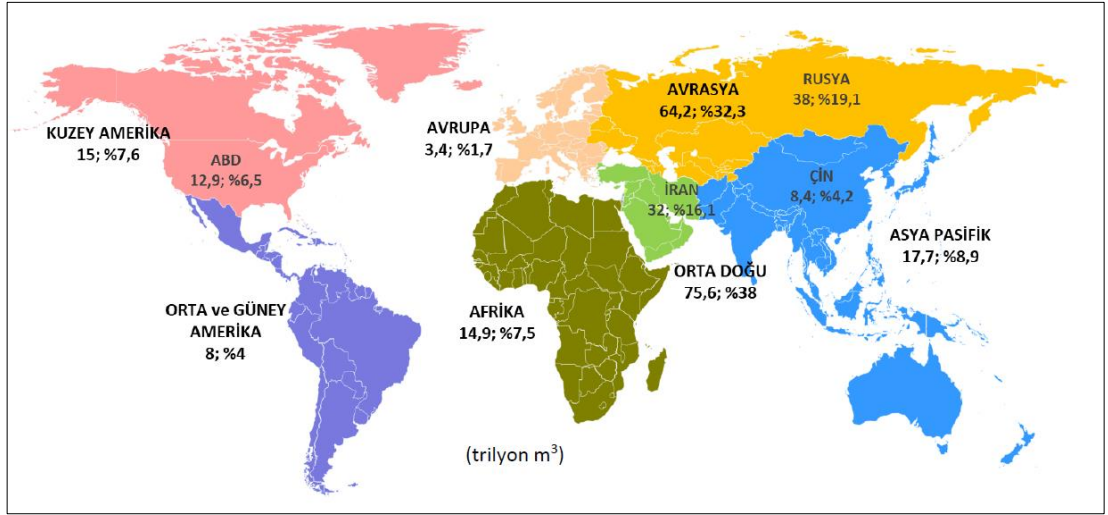
Özellikle OECD dışında kalan ülkelerin tüketimlerinde artış değerlendirildiğinde küresel enerji talebinin 1,5 katına çıkması ve bu artışın üçte ikisinin Asya Pasifik bölgesinden gelmesi beklenmektedir (TPAO 2020). Enerji talebindeki artışın karşılanmasındaki gerçekleşme miktarları, birincil enerji kaynaklarından doğal gazın gelecek enerji kaynaklarının kullanımı ile ilgili tahminlerindeki oranını destekleyen önemli verilerdendir. Şekil 2.6'de 1990-2040 yılları arasında bölge bazında küresel enerji talep artış talebi öngörülmesi verilmiştir.



Şekil 2.6: 1990-2040 yılları bölge bazında küresel enerji talebi (TPAO 2020).


2.2.1 Dünya Doğal Gaz Rezervleri Ve Üretimi

2018 yılı sonunda 197,1 trilyon m³ olarak kaydedilen doğal gaz rezervleri 2019 yılı sonunda %0,86 oranında artmış ve 198,8 trilyon m³ olarak kaydedilmiştir. 2019 yılı sonu ispatlanmış dünya doğal gaz rezerv verileri doğrultusunda dünya doğal gaz rezervlerinin %6'sı Amerika, %7,6'sı Kuzey Amerika, %4 Orta ve Güney Amerika, 1,7'si Avrupa, %32,3'ü Avrasya'da, %38'i Orta Doğu'da, %7,5'i Afrika'da %8,9'u Asya Pasifik ülkelerinde bulunmaktadır. Rezervlerin %89,9'u Ekonomik Kalkınma ve İş Birliği Örgütüne üye olmayan ülkelerde, %10,1'i Ekonomik Kalkınma ve İş Birliği Örgütüne üye ülkelerde, %0,3'ü Avrupa Birliği ülkelerindedir. 2019 yılı dünya ispatlanmış doğal gaz rezervlerine ait dağılım Şekil 2.7'de verilmiştir.




Şekil 2.7: 2019 yılı dünya ispatlanmış doğal gaz rezervleri dağılımı (TPAO 2020).

Ülke olarak Rusya 38, İran 32, Katar 24,7, Türkmenistan 19,5, ABD 12,9 trilyon metreküp rezerv ile ilk 5 sırada bulunmaktadır (BP, 2020). 2019 yılı sonu itibariyle en fazla doğal gaz rezervine sahip 10 ülke Şekil 2.8'de verilmiştir.




Şekil 2.8: 2019 yılı sonu itibariyle en fazla doğal gaz rezervine sahip 10 ülke (TPAO 2020).

2018 yılı sonu itibariyle 3,86 trilyon m³ olan dünya doğal gaz üretimi, %3,4 oranında artarak 2019 yılı sonu itibariyle 3,99 trilyon m³ olmuştur.




Şekil 2.9: 2010-2019 yılları arasında bölgelere göre doğal gaz üretimi (TPAO 2020).

Dünya genelindeki üretim değişimine bakıldığında Kuzey Amerika bölgesindeki üretim artışı %7,4 oranında gerçekleşmişken, Avrupa bölgesinde üretimde meydana gelen %6,1'lik düşüş dikkat çekmektedir. En fazla ikinci üretim artışı ise %6,3 ile Asya Pasifik bölgesinde gerçekleşmiştir (BP 2020). 2010-2019 yılları arasında bölgelere göre doğal gaz üretimi değerleri Şekil 2.9'da verilmiştir. 2024 yılında ise 2019'un pandemi öncesi dönemdeki üretime göre %6'dan fazla olması, dünya genelinde üretimde en fazla üretimin Kuzey Amerika bölgesinde gerçekleşmesi beklenmektedir. 2019 yılı sonu itibariyle Kuzey Amerika'da 1166 milyar m³ olan üretim miktarının 2024 yılında 1229 milyar m³ olacağı öngörülmektedir (UEA 2021). 2018-2024 yılları arasında bölgelere göre doğal gaz üretim tahmini Şekil 2.10'da verilmiştir.




Şekil 2.10: 2018-2024 yılları arasında bölgelere göre doğal gaz üretim tahmini (UEA 2021).

2018-2024 yılları arasındaki bölge bazında üretim artışının 167 milyar m³ ile en fazla Kuzey Amerika'da gerçekleşmesi beklenmektedir. Kuzey Amerika'nın konvansiyonel olmayan kaynaklara yönelmesi ile üretimini arttırması sonucu 2020 yılında da dünyanın en büyük gaz üreticisi konumuna sahip olmuştur. 2018-2024 yılları dünya doğal gaz üretim artış/azalış tahminleri Şekil 2.11'de verilmiştir (UEA 2021).



Şekil 2.11: 2018-2024 yılları dünya doğal gaz üretimi artış/azalış tahmini (UEA 2021).


Konvansiyonel olmayan kaynakların üretiminde Kuzey Amerika'dan sonra yüksek potansiyele sahip olduğu ön görülen Asya gelmekle birlikte, teknik ve jeolojik nedenlerinde arasında bulunduğu bazı problemler nedeniyle hedeflenen üretime ulaşamamıştır (TPAO 2020). 2019 yılı dünya konvansiyonel ve konvansiyonel olmayan gaz üretimleri Şekil 2.12'de verilmiştir.



Şekil 2.12: 2019 yılı dünya konvansiyonel ve konvansiyonel olmayan gaz üretimi (TPAO 2020).


2.2.2 Dünya Doğal Gaz Tüketimi

2019 yılında dünya doğal gaz tüketimi %2 oranında artarak 3929,2 milyar m³ olarak gerçekleşmiştir. 2019 yılı tüketim artışı %4,7 Asya Pasifik bölgesinde, %3,1 Kuzey Amerika bölgesinde, %2,3 Orta Doğu bölgesinde, %1,1 Avrupa bölgesinde, %0,9 Afrika bölgesinde gerçekleşirken, Avrasya bölgesinde %1,5 ve Orta ve Güney Amerika bölgesinde %2,7 oranında azalma meydana gelmiştir (BP 2020). 2010-2019 yılları dünya doğal gaz tüketimi Şekil 2.13’de verilmiştir.




Şekil 2.13: 2010-2019 yılları dünya doğal gaz tüketimi (TPAO 2020).

2018-2024 yılları arasındaki tüketim talebi tahminleri doğrultusunda tüketim talebindeki artışın %59,7 oranında Asya Pasifik bölgesinde, %19,7 oranında Orta Doğu bölgesinde, %14,9 Kuzey Amerika bölgesinde, %6,8 oranında Afrika bölgesinde gerçekleşmesi beklenmektedir. Bununla birlikte Avrupa, Orta ve Güney Amerika bölgesinde %2,3 oranında talep azalması öngörülmektedir (UEA 2021). 2018-2024 yılları dünya doğal gaz tüketim tahmini Şekil 2.14’de verilmiştir.



Şekil 2.14: 2018-2024 yılları dünya doğal gaz tüketim tahmini (UEA 2021).


2018-2024 yılları arasındaki artış dikkate alındığında Asya Pasifik bölgesinde 200 milyar m³, Orta Doğu'da 66 milyar m³, Kuzey Amerika'da 50 milyar m³, Afrika'da 23 milyar m³'lük bir artış beklenmektedir. Avrupa, Orta ve Güney Amerika bölgesinde ise 8 milyar m³'lük bir azalma beklenmektedir (UEA 2021). 2018-2024 dünya doğal gaz tüketim artış/azalış tahminleri Şekil 2.15'de verilmiştir.



Şekil 2.15: 2018-2024 yılları dünya doğal gaz tüketimi artış/azalış tahmini (UEA 2021).


2.3 Türkiye Doğal Gaz Sektörünün Görünümü

Türkiye, ispatlanmış rezervleri bakımından zengin olan Orta Asya, Orta Doğu, Rusya ve Hazar bölgesi ile enerji talebi açısından AB ülkeleri gibi dışa bağımlı ülkeler arasında coğrafi konumu nedeniyle stratejik bir öneme sahiptir. Türk Akım ve TANAP projeleri ile Rusya ve Azerbaycan gazının Avrupa'ya taşınması bu önemi daha da arttırmıştır. Bununla birlikte petrol ve doğal gaz gibi enerji ithalatının ülkeler üzerindeki ekonomik etkileri enerjide büyük ölçüde dışa bağımlı olması açısından Türkiye ekonomisini de önemli ölçüde etkilemektedir. Bu nedenle Enerji ve Tabii Kaynaklar Bakanlığı, TPAO ve enerji şirketleri tarafından yerli kaynakların değerlendirilmesi doğrultusunda çalışmalar yapılmaktadır. Bu çalışmalar doğrultusunda 2020 yılında TPAO tarafından Sakarya doğal gaz sahasında stratejik ve ekonomik açıdan önemli bir keşif gerçekleştirilmiştir (TPAO 2020). Ancak henüz üretim olarak toplam doğal gaz arzının %0,9'u yerli üretim olarak sağlanmaktadır. %99,1'i ise ithal edilmektedir. 2019 yılı ulusal enerji denge durumu Şekil 2.16'da verilmiştir.



Şekil 2.16: 2019 yılı ulusal enerji denge durumu (ETKB 2019).

Türkiye'nin 2019 yılında birincil enerji kaynakları arzı verilerine göre 110,6 milyon tep nihai enerji tüketimi gerçekleşmiştir. Doğal gazın ilgili birincil enerji arzı içerisindeki oranı %25,7 olarak gerçekleşmiştir (TPAO 2020). 2019 yılı Türkiye birincil enerji kaynakları arzı içerisinde kaynakların dağılımı Şekil 2.17'de verilmiştir.

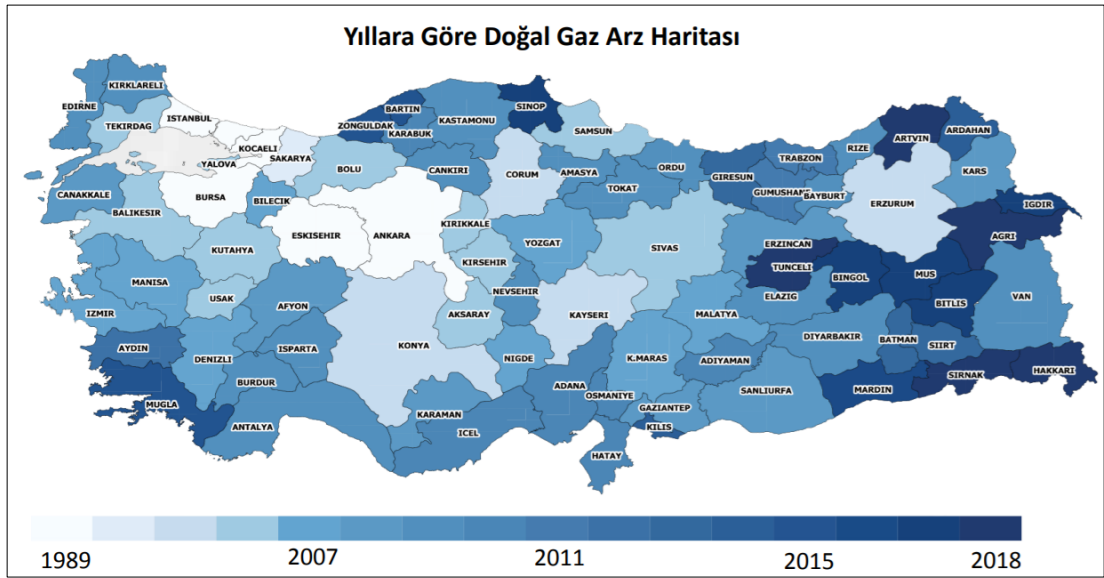


Şekil 2.17: 2019 yılı Türkiye birincil enerji kaynakları arzı dağılımı (TPAO 2020).

2.3.1 Türkiye Doğal Gaz Piyasasının Yapısı

27 Ağustos 1973 tarihinde Türkiye Cumhuriyeti ile Irak Cumhuriyeti hükümetleri arasında imzalanan Ham Petrol Boru Hattı Anlaşması çerçevesinde 15 Ağustos 1974 tarihinde TPAO tarafından kurulan BOTAŞ 1986 yılından itibaren doğal gaz ticareti ve taşımacılığı ile ilgili faaliyetleri de yürütmeye başlamıştır. Hali hazırda petrol ve doğal gaz boru hattı işletmeciliği, LNG/FSRU terminali işletmeciliği, liman hizmetleri, petrol ve doğal gaz boru hatları, kompresör istasyonları ile ilgili projelendirme, mühendislik, arazi etüt, kamulaştırma ve yapım işleri, doğal gaz ve LNG ticareti, doğal gaz ve LNG depolama faaliyetleri, uluslararası doğal gaz ve petrol taşıma projeleri faaliyetlerini yürütmektedir (BOTAŞ 2021). 1980’li yıllardan itibaren enerji piyasalarının küresel ölçekte liberal ve serbest bir yapıya dönüşme eğilimi doğrultusunda piyasaların rekabete açık bir yapıya dönüştürülmesi amacıyla kanun düzenlemesi yapılmıştır. Bu kapsamda Türkiye doğal gaz piyasası, “4646 sayılı Doğal Gaz Piyasası Kanunu” ile düzenlenmiştir. İlgili kanun ile doğal gaz ithalat, iletim, depolama, toptan satış, ihracat, dağıtım, sıkıştırılmış doğal gaz ve iletimi, yürütülmesi lisans alınması zorunlu piyasa faaliyeti olarak tanımlanmıştır. Kanunla birlikte kaynakların yeterli, kaliteli, sürekli, düşük maliyetli ve çevreyle uyumlu bir şekilde tüketicilerin kullanımına sunulması, rekabet ortamında özel hukuk hükümlerine tabi faaliyet gösterilebilmesi, güçlü bir mali yapısı olan, istikrarlı ve şeffaf bir enerji

piyasasının oluşturulması amacıyla Enerji Piyasası Düzenleme Kurumu kurulmuştur (EPDK 2020). Sektörün rekabete açık bir yapıya kavuşması ve doğal gaz tedariki hususundaki gelişmelerle birlikte 2003 yılı itibariyle özel şirketlere EPDK tarafından dağıtım faaliyetleri için lisans vermeye başlanmıştır. 2020 yılı itibariyle EPDK yönetmeliklerine tabi 72 adet doğal gaz dağıtım faaliyetleri için lisans sahibi şirket bulunmaktadır. Türkiye’de 1988 yılında Ankara ile başlayan ve 1992 yılında İstanbul ve Bursa ile devam eden doğal gaz dağıtım faaliyetleri 2021 yılı sonu itibariyle, 81 ilde 594 ilçe ve 49 beldede gerçekleştirilmektedir (EPDK 2021). Yıllara göre doğal gaz arz haritası Şekil 2.18’de verilmiştir.



Şekil 2.18: Yıllara göre doğal gaz arz haritası (GAZBİR 2021).


2.3.2 Rezervler

2020 yılı sonu itibariyle Türkiye doğal gaz rezervi 3 milyar m³ olarak kaydedilmiştir. Mevcut üretimin tüketime oranı değerlendirildiğinde yeni keşifler yapılmaması durumunda mevcut rezervin yaklaşık 9 yılda tükeneceği öngörülmektedir. 2020 yılında TPAO tarafından gerçekleştirilen küresel olarak 2020 yılının en büyük ikinci ve Karadeniz’de gerçekleştirilen en büyük hidrokarbon keşfi olan TUNA-1 sahasındaki 405 milyar m³’lük doğal gaz keşfi ile Türkiye tespit edilen doğal gaz rezerv miktarı artmıştır. Akdeniz ve Karadeniz’de gerçekleştirilen arama faaliyetleri ile birlikte, Trakya ve Güneydoğu Anadolu bölgesinde konvansiyonel

olmayan doğal gaz arama ve üretim çalışmaları da devam etmektedir. Türkiye’de 2019 yılında 80 adet arama, tespit ve 73 adet üretim kuyusu açılmıştır. 2020 yılında ise 58 adet arama, tespit ve 48 adet üretim kuyusu açılmıştır. 2020 yılında açılan arama, tespit kuyularının 40 adeti, üretim kuyularının 38 adeti TPAO tarafından, 18 adet arama, tespit kuyusu ve 10 adet üretim kuyusu ise diğer şirketler tarafından açılmıştır. 2020 yılında eş zamanlı sondaj yapan aktif kule sayısı 20 adet olarak tespit edilmiştir. (TPAO 2020).


2.3.3 Üretim

Doğal gaz arama ve üretim faaliyetleri, 6491 sayılı Türk Petrol Kanunu’na göre Maden ve Petrol İşleri Genel Müdürlüğü tarafından verilen arama ve işletme ruhsatları kapsamında gerçekleştirilmektedir. Üretim şirketleri piyasa faaliyeti sayılmayan üretim faaliyeti sonucu ürettikleri doğal gazı EPDK’dan toptan satış lisansı alarak toptan satış şirketlerine, serbest tüketicilere, kuyu başından olmak kaydı ile CNG satış, iletim ve dağıtım şirketlerine, dağıtım şirketlerine, ithalatçı ve ihracatçı şirketlere pazarlayabilmektedir. Bununla birlikte ihracat lisansı alarak ihraç faaliyeti de gerçekleştirilebilmektedir (EPDK 2020). 2020 yılı itibariyle Maden ve Petrol İşleri Genel Müdürlüğü tarafından 9 adet şirkete toptan satış lisansı verilmiştir. İlgili şirketlerden TPAO, 2020 yılı verileri doğrultusunda %81,54 oranıyla en fazla en fazla doğal gaz üretimi yapan şirkettir. 2020 yılı doğal gaz üretimi yapan toptan satış lisansına sahip olan şirketlerin üretim oranları Şekil 2.19’da verilmiştir.




Şekil 2.19: 2020 yılı doğal gaz üretimi yapan toptan satış lisansı sahibi şirketlerin üretim oranları (EPDK 2020).

2010-2020 yılı EPDK verileri incelendiğinde Türkiye’de doğal gaz üretiminin dalgalı bir seyir izlemekle birlikte ortalama olarak azalma eğilimi gösterdiği gözlemlenmektedir. Ancak yeni rezerv keşifleri ve ilgili rezervlerden üretim gerçekleştirilmesi ile tüketim oranla %0,9 olan üretim miktarının çok daha yüksek seviyelere çıkması beklenmektedir. Özellikle TUNA-1 sahasında gerçekleştirilen 405 Milyar m³’lük doğal gaz keşfinin üretim ve dağıtıma dâhil olmasıyla birlikte doğal gazda ithalat oranının önemli ölçüde azalması beklenmektedir. Bununla birlikte ilgili doğal gaz rezervlerinin ömrü düşünüldüğünde doğal gaz arzında uzun süreli bir yerel tedarik için yeni rezervlerin keşfi önem arz etmektedir. 2010-2020 yılları arasında Türkiye doğal gaz üretim verileri Şekil 2.20’de verilmiştir.



Şekil 2.20: 2010-2020 yılları arasında Türkiye doğal gaz üretimi (**EPDK 2020**).

2020 yılı üretim sahalarının bulunduğu illerde doğal üretim oranları incelendiğinde en fazla üretim yapılan illerin sırasıyla Tekirdağ, İstanbul ve Kırklareli olduğu görülmektedir. Toplam üretimin %37,14'ü Tekirdağ'da, %37,12'si İstanbul'da, %21,40'ı Kırklareli'nde, %2,23'ü Çanakkale'de, 1,68'i Düzce'de, %0,37'si Edirne'de, %0,06'sı Adıyaman'da gerçekleşmiştir. 2020 yılı üretim sahalarının bulunduğu illere göre doğal gaz üretim oranları Şekil 2.21'de verilmiştir.




Şekil 2.21: 2020 yılı üretim sahalarının bulunduğu illere göre doğal gaz üretim oranları (EPDK 2020).

2.3.4 İthalat

Türkiye, 1970 yılından itibaren enerji talebindeki artışa paralel olarak avantajları nedeniyle artan doğal gaz talebine milli rezervlerden üretimin çok düşük kalması nedeniyle zorunlu olarak ithalata yönelmiştir. Bu kapsamda ilk kez 1986 yılında Rusya ile 6 milyar m³ miktarında doğal gaz ithalatı anlaşması gerçekleştirilmiştir. Takiben artan talebi karşılamak amacıyla Rusya ve İran'dan doğal gaz alımı için yeni anlaşmalar imzalanmıştır. 2001 yılında imzalanan anlaşma neticesinde doğal gaz alımı yapılan ülkelerin arasına 2007 yılından itibaren geçerli olmak üzere Azerbaycan'da katılmıştır (EPDK 2020).

Boru hatları ile gerçekleştirilen doğal gaz alımlarına ek olarak boru hatları ile tedarikin ekonomik, jeolojik ve benzeri gerekçelerle mümkün olmadığı durumlara çözüm sağlanması, arz kaynaklarının çeşitlendirilmesi, arz güvenliğinin artırılması ve tedarikte esnekliğin artırılması amacıyla BOTAS tarafından 1988 yılında imzalanan anlaşma kapsamında 1994 yılından itibaren Cezayir'den, 1995 yılında imzalanan anlaşma kapsamında 1999 yılından itibaren Nijerya'dan LNG alımına başlanmıştır. 2010-2020 yılları arasında gerçekleştirilen doğal gaz ithalat oranları Şekil 2.22'de verilmiştir.




Şekil 2.22: 2010-2020 yılları doğal gaz ithalat oranları (EPDK 2020).

2006 yılında Rusya ve Ukrayna arasından yaşanan kriz sonrası Türkiye'nin doğal gaz tedarikinde yaşadığı problem sonrası 2008 yılında gerçekleştirilen kanun düzenlemesi ile LNG ithalatı BOTAS ve diğer piyasa katılımcıları için serbest bırakılmış ve spot LNG ithalat faaliyeti düzenleme altına alınmıştır. Ek olarak tek bir spot LNG ithalat lisansı ile birden fazla ülkeden alım yapılabilmesinin önü açılmıştır (EPDK 2020). Türkiye doğal gaz tedarik haritası Şekil 2.23'de verilmiştir.



Şekil 2.23: Türkiye doğal gaz tedarik haritası (BOTAS 2021).

2010-2020 yılları arasında gerçekleştirilen doğal gaz ithalat oranlarına göre Türkiye doğal gaz tedarikini büyük ölçüde Rusya'dan gerçekleştirmiştir. Ancak zaman içerisindeki tedarik oranlarındaki değişim incelendiğinde Rusya ve İran'dan doğal gaz ithalatı azalan bir seyir izlemiştir. Bununla birlikte Azerbaycan'dan ve LNG ile diğer ülkelerden tedarik edilen doğal gaz miktarında da zaman içerisinde önemli bir artış gerçekleşmiştir. 2020 yılı toplam ithalatta boru gazı oranı %68,67, LNG %31,33 oranında gerçekleşmiştir. 2020 yılında gerçekleştirilen toplam ithalatın %83,05'i uzun dönemli ithalat lisansı kapsamında gerçekleştirilmiştir. Bununla birlikte uzun dönemli ithalatta boru gazı ithalatının payı %82,6, LNG'nin payı %17,3 olarak gerçekleşmiştir. Uzun dönemli ithalat lisansı kapsamında gerçekleştirilen LNG ithalatı %80,41 oranında Cezayir, %19,59 oranında Nijerya'dan gerçekleştirilmiştir (EPDK 2020). 2020 yılında uzun dönemli ithalat lisansı kapsamında gerçekleştirilen doğal gaz ithalatının ülkeler bazında oransal dağılımı Şekil 2.24'de verilmiştir.




Şekil 2.24: 2020 yılı uzun dönemli ithalat lisansı kapsamında ithalat gerçekleştirilen ülkelerin miktara göre oransal dağılımı (EPDK 2020).

Zaman içerisinde boru gazı ithalatı ile LNG ithalatı arasındaki oran değişmiş, ithal edilen LNG oranı artarken boru gazı oranı azalmıştır. 2013-2020 yılları arasında doğal gaz ithalatı gerçekleştiren şirketlerin ithalat türüne göre miktar ve payları Tablo 2.2'de verilmiştir.

Tablo 2.2: 2013-2020 yılları arasında, doğal gaz ithalatı gerçekleştiren şirketlerin ithalat türüne göre miktar ve payları (EPDK 2020).

Yıllar	Boru Gazı Miktar (Milyon Sm3)	Boru Gazı Pay (%)	LNG Miktar (Milyon Sm3)	LNG Pay (%)
2013	39419,44	87,08	5849,54	12,92
2014	41981,41	85,22	7280,87	14,78
2015	40778,11	84,21	7648,96	15,79
2016	38724,48	83,54	7627,68	16,46
2017	44484,67	80,52	10765,28	19,48
2018	39032,13	77,63	11249,92	22,37
2019	32517,4	71,92	12694,07	28,08
2020	33047,16	68,67	15078,35	31,33

2020 yılında doğal gaz ithalatının %90,84'ü BOTAŞ, %4,76'sı BOSPHORUS, %2,93'ü AKFEL GAZ kalanı da diğer gaz şirketleri tarafından gerçekleştirilmiştir. İthalatta zaman içerisinde artış gösteren spot LNG ithalatı 2020 yılında toplam ithalatın %16,95'ini oluşturmuştur. 11 farklı ülkeden gerçekleştirilen spot LNG ithalatının %40'ı Katar, %37'si Amerika Birleşik Devletleri, %8'i ise Trinidad ve Tobago'dan yapılmıştır. 2020 yılında spot LNG ithal edilen ülkelere göre ithal edilen LNG oranları Şekil 2.25'de verilmiştir.



Şekil 2.25: 2020 yılı spot LNG ithalatının, ithalat yapılan ülkelere göre dağılımı (EPDK 2020).

2020 yılı sonu itibarıyla spot ithalat lisansı bulunan 52 şirketten Bosphorus Gas Corporation Anonim Şirketi ve Engie Enerji Ticaret ve Pazarlama Anonim Şirketi spot boru gazı, BOTAŞ ve EGEGAZ spot LNG ithalatı gerçekleştirmiştir. 2020 yılı spot


ithalat içerisinde spot boru gazı ithalat oranı %0,15, spot LNG ithalat oranı %99,85 olarak gerçekleşmiştir (EPDK 2020). 2008-2020 yılları arasında spot LNG ithalatı gerçekleştiren şirketlerin payları Tablo 2.3’de verilmiştir.

Tablo 2.3: 2008-2020 yılları arasında spot LNG ithalatı gerçekleştiren şirketlerin payları (EPDK 2020).

	EGE GAZ (%)	BOTAŞ (%)
2008	-	100
2009	8,46	91,53
2010	37,66	62,33
2011	13,83	86,17
2012	2,8	97,2
2013	24,62	75,38
2014	5,36	94,64
2015	10,79	89,21
2016	11,40	88,60
2017	10,40	89,60
2018	5,18	94,82
2019	5,59	94,41
2020	3,26	96,74

2.3.5 İhracat

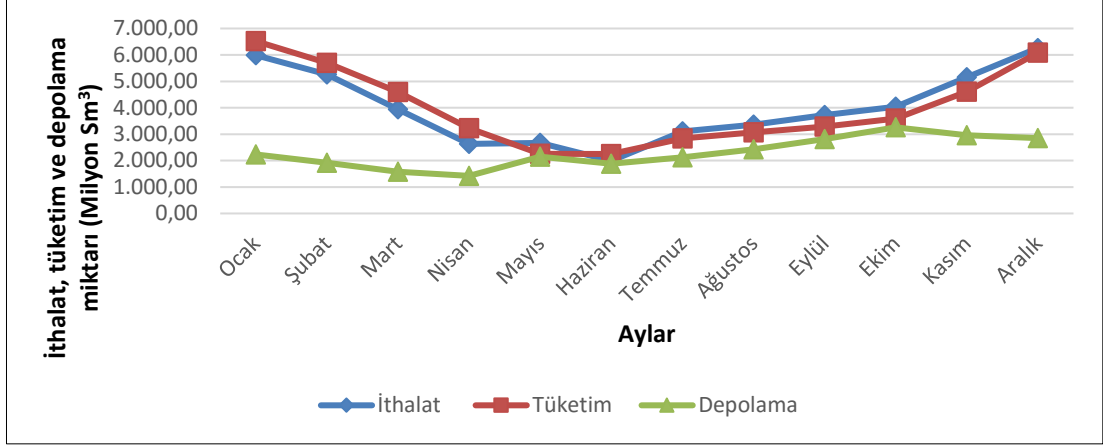
Türkiye’de üretilmiş ya da ithal edilmiş doğal gazın ihracatı ihracat lisansına sahip tüzel kişiler tarafından lisans kapsamında belirtilen ülkelerde gerçekleştirilebilmektedir. Bu kapsamda 2020 yılı sonu itibariyle doğal gaz ihracat lisansına sahip, 18.11.2007 tarihinde Türkiye-Yunanistan doğal gaz boru hattının tamamlanmasıyla doğal gaz ihracatına başlayan BOTAŞ ve 2019 itibariyle Bulgaristan’a LNG ihracatına başlayan Aygaz Doğal Gaz Toptan Satış Anonim Şirketi bulunmaktadır (EPDK 2020). Yıllara göre doğal gaz ihracat miktarlarını gösteren grafik Şekil 2.26’da verilmiştir.



Şekil 2.26: Yıllara göre Türkiye doğal gaz ihracat miktarı (EPDK 2020).

2.3.6 Depolama

Doğal gaz tedarikinde arz güvenliğini arttırmak amacıyla gerçekleştirilen yatırımlar doğrultusunda Türkiye'nin doğal gaz depolama kapasitesi önemli ölçüde artmıştır. 2020 yılı sonu itibariyle yer altı depolarının kapasitesi 3.691 milyon m³, LNG depolama kapasitesi ise 0,964 milyon m³ seviyelerine ulaşmıştır (EPDK 2020). 2016 yılı sonu itibariyle devreye alınan Etki Limanı LNG Tesisi, 2017 yılında devreye giren BOTAŞ Dörtyol Yüzen Sıvılaştırılmış Doğal Gaz Terminali ve LNG piyasasındaki ilerlemeler sonucu LNG stok miktarlarında önemli bir artış gerçekleşmiştir. 2020 yılı aylara göre ithalat, tüketim ve depolama miktarlarına ait grafik Şekil 2.27'de verilmiştir.



Şekil 2.27: 2020 yılı aylara göre ithalat, tüketim ve depolama miktarları (EPDK 2020).


2.3.7 Toptan Satış

Türkiye’de toptan satış faaliyeti EPDK’dan toptan satış lisansı ya da ithalat lisansı almış tüzel kişiler tarafından gerçekleştirilmektedir. 2020 yılı sonu itibariyle toptan satış faaliyeti gerçekleştirmek için lisans sahibi 52 adet şirket bulunmaktadır. Bu şirketlerden 9 adeti üretim faaliyeti gerçekleştirmektedir. Diğer şirketler ise uzun dönemli ve spot ithalat lisansına sahiptir. Faaliyet kapsamında 2020 yılında toplam 48.566,77 Milyon Sm³ doğal gaz arzı gerçekleşmiştir. Bu arzın %90,02’si BOTAŞ, %9,08’i diğer ithalat lisansı şirketler, %0,9’u ise üretim gerçekleştiren toptan satış lisansı şirketler tarafından gerçekleştirilmiştir (EPDK 2020).

Organize doğal gaz toptan satış faaliyetleri 31.03.2012 tarihinde yayımlanan yönetmelikle düzenlenerek doğal gaz iletim sistemi kullanıcılarının sürekli ticaret yapabilmelerine ve dengesizliklerin giderilmesine imkân veren Organize Toptan Doğal Gaz Satış Piyasası 01.09.2018 tarihinde faaliyete başlamıştır. 2020 yılı boyunca 32 lisans sahibi tarafından piyasada işlem yapılmıştır. İlgili lisans sahiplerinin 1’i iletim, 22’si ithalat, 12’si toptan satış lisansına sahiptir (EPDK 2020).

2020 yılında boru hatları ile 43, LNG ile 8 şirket tarafından toptan satış faaliyeti gerçekleştirilmiştir. İlgili toptan satış faaliyetlerinde en fazla satış 32.284,10 Milyon Sm³ olarak uzun dönemli ithalat lisansına sahip şirketler tarafından boru gazı toptan satışı ile gerçekleştirilmiştir. Toptan satış gerçekleştiren şirketler arasındaki en fazla pay ise %90,02’lik doğal gaz arzı ile BOTAŞ tarafından gerçekleştirilmiştir (EPDK


2020). 202 yılı toptan satış gerçekleştiren lisans sahibi şirketlerin oranlarını gösteren grafik Şekil 2.28’de verilmiştir.



Şekil 2.28: 2020 yılı toptan satış faaliyeti gerçekleştiren şirketlerin doğal gaz arzı oranları (EPDK 2020).

2.3.8 Sıkıştırılmış Doğal Gaz (CNG)

Sıvılaştırılmış doğal gaz dağıtım ve satış faaliyeti CNG lisansı sahibi şirketler tarafından gerçekleştirilmektedir. Şirketler lisans kapsamında doğal gazın üretim kuyu başlarından, iletim veya dağıtım şebekesinden ya da tedarikçilerden alınması, sıkıştırılması, uygun özel vasıtalarla taşınması ve satışı faaliyetlerini yürütebilmektedir. CNG lisansına sahip şirketler tarafından 2020 yılında 274,86 milyon Sm³ doğal gaz satın alınmıştır. Satışların %54,95’i ithalat lisansı, %31,70’i dağıtım lisansı, %12,09’u CNG lisansı, %1,26’sı ise toptan satış lisansı şirketler tarafından yapılmıştır. Satın alınan doğal gazın 211,07 Milyon Sm³’ünün CNG lisansı sahibi şirketler tarafından nihai tüketiciye satışı gerçekleştirilmiştir (EPDK 2020). 2020 yılı nihai tüketicilere yapılan satışların lisans türlerine göre dağılımını içeren grafik Şekil 2.29’da verilmiştir.



Şekil 2.29: 2020 yılı nihai tüketicilere yapılan satışların türelere göre dağılımı (EPDK 2020).

2.3.9 İletim

Türkiye’de doğal gaz piyasası faaliyetlerinden serbestleşmeye ya da özelleştirmeye açılmayan tek faaliyettir. Bu sınırlamaya sistem güvenliği ve takibi gerekçe gösterilerek doğal gaz iletim faaliyetinin yalnızca kamu tüzel kişiliği olan BOTAŞ tarafından gerçekleştirilmesine karar verilmiştir. 4646 sayılı doğal gaz kanunu gereğince ticaret ve iletim faaliyetlerinin ayrıştırılması doğrultusunda yapılan yapılandırma sonucu ortaya çıkacak şirketlerden iletim faaliyeti gerçekleştirecek şirketin kamu niteliğinin devam edeceği öngörülmektedir (EPDK 2020). İletim şebekesine üçüncü tarafların erişimi ise özel bir düzenlemeye tabi tutularak, 4646 sayılı Doğal Gaz Piyasası Kanunu kapsamında Doğal Gaz Piyasası İletim Şebekesi İşleyiş Yönetmeliği yayımlanmıştır. İlgili yönetmelik kapsamında doğal gaz sistemine giriş, taşıma miktarının bildirilmesi ve hizmetle ilgili programın oluşturulması, taşıma miktarının tespit edilmesi, kesinti işlemi, sevkiyat kontrolü, sistem dengelemesi, iletişim sistemi, kapasite tahsisi, doğal gaz teslimiyle ölçüm işlemi gibi şebeke işleyişine ait usul ve esaslar düzenlenmiştir.

İletim faaliyeti iki şekilde gerçekleştirilmektedir. Bu doğrultuda 2020 yılında doğal gaz piyasasında faaliyet gösteren ithalat ve toptan satış lisansına sahip şirketler tarafından iletim şebekesine 15 adet giriş noktasından yaklaşık 50,25 Milyar Sm³ fiziki

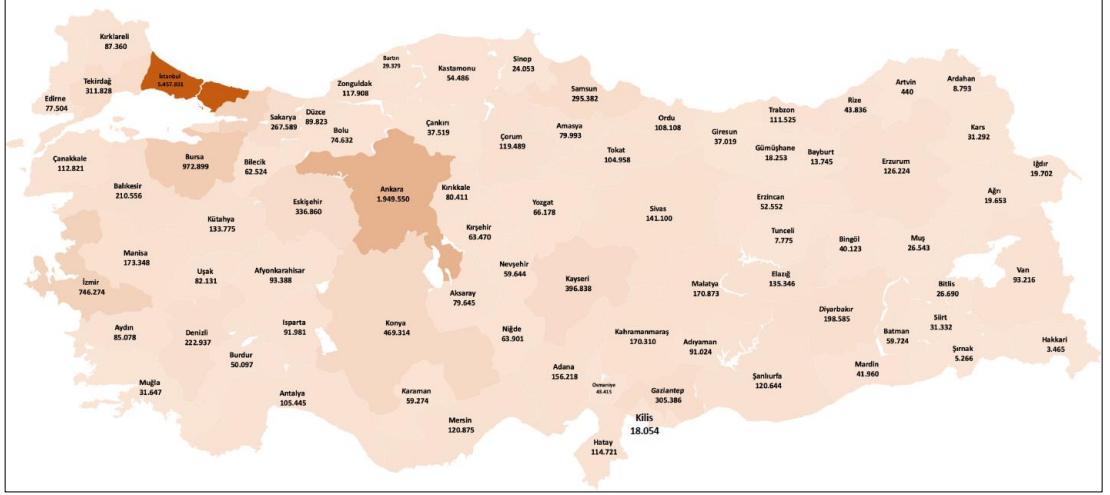
doğal gaz girişi, 50,29 Milyar Sm³ fiziki doğal gaz çıkışı yapılmıştır. Yapılan giriş miktarının %78,58'i BOTAS, %21,42'si ise toptan satış ve ithalat lisansına sahip özel şirketler tarafından gerçekleştirilmiştir. Bununla birlikte 2020 yılında LNG iletim lisansı sahibi 9 adet şirket tarafından 583,87 milyon Sm³ LNG taşınması gerçekleştirilmiştir (EPDK 2020).

2.3.10 Dağıtım

Türkiye'de doğal gaz dağıtım faaliyeti EPDK tarafından verilen dağıtım lisansına sahip şirketler tarafından gerçekleştirilmektedir. 2020 yılı itibariyle doğal gaz dağıtım lisansına sahip şirket sayısı 72 adettir. 2020 yılı sonu itibariyle Türkiye'de 81 ilde 51 merkez ilçe dâhil olmak üzere 554 ilçe ve 35 beldeye doğal gaz arzı sağlanmış durumdadır (GAZBİR 2021).

2020 yılı sonu itibariyle dağıtım lisansına sahip şirketler tarafından 14.924 km botu hattı, 101496 km polietilen hat, 40.748 km servis hattı inşası gerçekleştirilmiştir. Gerçekleştirilen yatırımlarla 16.846.604 aboneye doğal gaz hizmeti götürülmüştür. Doğal gaz hizmeti götürülen konut abone sayısı 16.841.755, serbest tüketici sayısı ise 655.464 seviyesine ulaşmıştır (EPDK 2020).

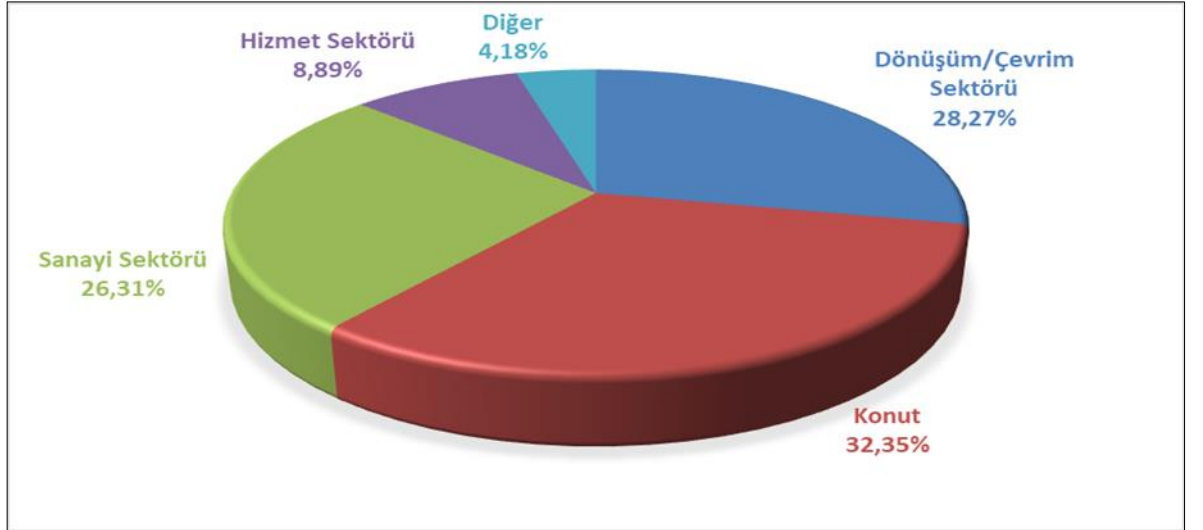
Dağıtım faaliyetleri kapsamında Türkiye nüfusunun %81'ine doğal gaz hizmeti ulaştırılmış, doğal gaz kullanım oranı ise %66 seviyesine gelinmiştir. 2020 yılı sonu itibariyle Türkiye'de en çok abone sayısına sahip birinci il 5.457.831 abone ile İstanbul, ikinci il 1.949.550 abone ile Ankara, üçüncü il ise 972.899 abone ile Bursa olmuştur (GAZBİR 2021). Hali hazırda gelinen noktada faaliyetler şehir için şebekelerde parça hat imalatı, dağıtım firmalarının lisans bölgesinde bulunan ilçelere hat imalatı ve EPDK tarafından dağıtım firmalarının lisanslarına dâhil edilen genişleme bölgelerinde bulunan ilçelerde hat imalatı olarak devam etmektedir. 2020 yılı sonu itibariyle il bazında doğal gaz abone sayılarını içeren veriler Şekil 2.30'da verilmiştir.



Şekil 2.30: 2020 yılı il bazlı doğal gaz abone sayısı (GAZBİR 2021).

2.3.11 Tüketim


2020 yılı doğal gaz tüketimi dağılımına göre en fazla tüketim %32,35 oranı ile konutlarda olmak üzere, %28,27 oranı ile elektrik, %26 oranı ile sanayi alanlarında gerçekleşmiştir (GAZBİR 2021). 2020 yılı Türkiye doğal gaz tüketimi sektör dağılımı Şekil 2.31’de verilmiştir.



Şekil 2.31: 2020 yılı Türkiye doğal gaz tüketimi sektör dağılımı (EPDK 2020).

2020 yılında ulusal doğal tüketimi, 2019 yılı tüketimine göre yaklaşık %7 oranında artmıştır. Tüketimdeki payları dikkate alındığında artış oranına en fazla katkı %21,21 oranında çevrim/dönüşüm sektörü ve %8,45 konut tüketimlerinde gelmekle

birlikte, sanayi sektöründe %2,2 oranında sınırlı bir artış gerçekleşmiştir. Enerji, ulaşım ve hizmet sektörlerinde ise 2019 yılına göre tüketimlerde önemli oranda bir azalma meydana gelmiştir (EPDK 2020). Sektörlere göre yıl bazında tüketim karşılaştırması Şekil 2.32’de verilmiştir.



Şekil 2.32: Sektörlere göre yıllık doğal gaz tüketimlerinin karşılaştırılması (EPDK 2020).


2010 yılı ile 2020 yılı arasındaki tüketim verileri incelendiğinde doğal tüketiminin çoğunlukla bir önceki yıla göre artış gösterdiği gözlemlenmektedir. Tüketim oranlarındaki değişim nüfus sayısının değişimi, doğal gaz hizmeti ulaşan abone sayısı, doğal kullanılan sanayi alanları, doğal gaz çevrim santrallerinin kullanım oranları, meteorolojik, politik ve ekonomik faktörler gibi birçok parametreden etkilenmektedir. Yıllara göre toplam doğal gaz tüketim miktarları Tablo 2.4’de verilmiştir.

Tablo 2.4: Yıllara göre toplam doğal gaz tüketim miktarları (EPDK 2020).

Yıl	Tüketim (Milyon Sm ³)	Bir önceki yıla göre değişim (%)
2010	37.411	6,22
2011	43.697	16,8
2012	45.242	3,53
2013	45.918	1,5
2014	48.717	6,1
2015	47.999	-1,47
2016	46.480	-3,16
2017	53.857	15,87
2018	49.204	-8,64
2019	45.286	-7,96
2020	48.261	6,57

2.3.12 Tarife Ve Fiyatlandırma

Türkiye doğal gaz piyasasında tüketiciye yansıtılan ücretler gaz bedeli, sistem kullanım bedeli, ÖTV ve KDV girdilerinden oluşmaktadır. Güncel mevzuat doğrultusunda müşterilere tüketim faturasında bu bedeller dışında herhangi bir bedel yansıtılmamaktadır. İlgili bedellerden gaz bedeli müşteri tipine göre ilgili lisanslara sahip dağıtım şirketine ya da tedarikçiye ödenmektedir. Müşteriler serbest ve serbest olmayan olmak üzere iki gruba ayrılmaktadır. Serbest tüketiciler doğal gaz dağıtım şirketi dışında EPDK tarafından verilen gerekli lisanslara sahip tedarikçilerden gaz satın alabilmektedir. Serbest olmayan tüketiciler ise ilgili bölgede EPDK tarafından verilen doğal gaz dağıtım lisansına sahip şirket tarafından gaz alması zorunlu olan müşterilerdir. Sistem kullanım bedeli ise ilgili dağıtım şirketinin EPDK tarafından belli dönemlerde revize edilen ve ilgili dağıtım şirketine ödenen ücrettir. İlgili dağıtım şirketi müşteriye EPDK tarafından belirlenen sistem kullanım bedelinin üzerinde herhangi bir sistem kullanım bedeli yansıtılmamaktadır. Serbest tüketici ve serbest olmayan tüketicilerin doğal gaz kullanım kademelerine göre sistem kullanım bedeli fiyatları EPDK tarafından belirlenmektedir. 2020 yılında konut ve sanayi tüketicilerine dağıtım şirketleri ve tedarikçi şirketler tarafından satılan doğal gazın fiyat oluşumları Şekil 2.33’de verilmiştir (EPDK 2020).



Şekil 2.33: 2020 yılı konut ve sanayi tüketicilerine dağıtım şirketleri ve tedarikçi şirketler tarafından satılan doğal gazın fiyat oluşumları (EPDK 2020).

3. TALEP TAHMİN

Talep, piyasalarda belirli bir mal ya da hizmetin satın alma gücüne sahip tüketiciler tarafından istenmesi durumudur. Tahmin ise geçmişte elde edilen verilerin analiz edilerek ve ilişkilendirilerek gelecekteki muhtemel gerçekleştirmelerin öngörülmesi durumudur. Tanımları itibariyle talep ve tahmin, piyasalardaki işleyişin dengeli yürütülmesi açısından üretimden tüketime giden süreçteki tüm saflarda kritik öneme sahiptir. İktisat biliminde insanların ihtiyaçları ve ihtiyaçları karşılayan kaynakların yönetimi noktasında büyük oranda ihtiyaçlarla doğru orantılı olarak şekillenen talep, insan kaynağı, malzeme tedariki gibi ürün ya da hizmet üretiminin etkilediği ekonomi, yer altı kaynakları, teknoloji gibi önemli faktörleri yönetimini de şekillendirmektedir. Bu nedenle verimli ve dengeli bir yönetim için karar noktasında kuvvetli bir destek rolü mevcuttur.

Bir başka deyişle talep tahmin, tüketicilerin gelecekte ne miktar mal ve hizmet talep edeceklerinin kestirilmesi işlemidir. Bu durum da şirketler için talep ve arz dengesinin sağlanması açısından sürdürülebilirlik hususunda büyük bir öneme sahiptir. Bu doğrultuda sürdürülebilirliğin sağlanması, etkili bir planlama ve kontrol işleyişi için tahminlere ihtiyaç olduğu söylenebilir (Ergün ve Şahin 2017).

Talep tahmini, şirket yönetiminin taktiksel ve stratejik kararların alınması, kısa, orta ve uzun dönemli hedeflere ulaşmada kullanılacak en temel araçların başında gelmektedir. İyi bir yönetim için iyi bir planlama, iyi bir planlama için ise iyi bir tahmin gerekmektedir. Bir yöneticinin başarısızlık riskini azaltmak için iyi bir plan ve dolayısıyla iyi bir tahmin yapması gerekmektedir (Adıyaman 2007).

Ancak bu noktada talebe etken tüketici davranışları gibi parametrelerin çeşitlilik göstermesi yöneticilerin tahmin yapmasını zorlaştırmaktadır. Bu durum talep tahminini parametreler ve bu parametrelerle ilgili verilerin elde edilmesi noktasında çeşitlendirdiği için farklı talep tahmin yöntemlerinin uygulanmasına neden olmaktadır. Bu doğrultuda talep tahmini de kendi içlerinde çeşitli yöntemler barındıran nicel ve nitel tahmin yöntemleri ile gerçekleştirilmektedir. Ancak tüm bu yöntemlerle elde edilen sonuçların bir tahmin olduğunun unutulmaması ve uygulamalarda bu durumun göz önüne alınması gerekmektedir. Tahmin işleminde etken parametrelerin azami düzeyde tespiti, doğru tahmin yönteminin ve modelin uygulanması, nicel ve nitel veri

kalitesi gibi konular tahmin başarısını önemli ölçüde etkilemektedir. Bu doğrultuda tahmin sonuçlarının değerlendirilmesinde modelde bulunmayan ancak talep üzerinde etkili olabilen deneyim, sezgi, sosyal ve kültürel değerler gibi faktörlerde dikkate alınmalıdır (Bulut 2006).

Tahmin işleminin verimliliğinin artırılması için bazı ilkelere dikkat edilmesi gerekmektedir. (Karahan 2011). Bu ilkeler aşağıdaki gibidir.

- Tahminlerin kapsadığı zaman aralığı arttıkça duyarlılık azalır.
- Tahminler yapısal olarak bir hata miktarı içerirler. Bu nedenle her tahmin çalışmasında kabul edilebilecek bir hata oranı olmalıdır. Tahmin çalışmasında standart sapması en az olan model kullanılmalıdır.
- Çeşitlilik ve miktar arttıkça tahmin başarısı artmaktadır.
- Tahmin sonuçları uygulanmadan önce doğruluğu test edilmelidir.

Tahminler yaygın olarak kapsadığı zamana göre sınıflandırılmaktadır. Bunlar kısa, orta ve uzun vadeli olmak üzere üçe ayrılmaktadır. Kısa vadeli tahminlerde zaman aralığı 1 yıla kadar çıkabilse de genellikle 3 aydan kısa süreli tahminlerdir. İşletmenin işgücü ve üretim seviyelerinin belirlenmesi, iş çizelgeleme gibi işlemlerde kullanılmaktadır. Orta vadeli tahminler, genellikle 3 aydan 3 yıla kadar bir zaman aralığını kapsayan tahminlerdir. Satış ve üretim planlama, bütçeleme gibi işlemlerde kullanılmaktadır. Uzun vadeli tahminler ise 3 yıldan daha fazla bir zaman aralığını kapsamaktadır. Yatırım planlaması, yeni ürün planlaması, araştırma ve geliştirme gibi işlemlerde kullanılmaktadır (Heizer ve Render 2017).

Talep tahmininde bir diğer önemli konu ise tahmin yönetim metodolojisinin uygulanmasıdır. Bu kapsamda talebi etkileyen parametrelerin tespit edilmesi, verilerin toplanması, talep tahmin periyodunun tespiti, tahmin yönteminin ve modelin seçimi ve tahmin sonuçlarının geçerliliğinin araştırılması beş temel aşama olarak kabul edilebilir (Ballı 2014).

3.1 Talep Tahmin Yöntemleri

Tüm karar modellemelerini çözmek te kullanılan kalitatif ve kanitatif yöntemler talep tahminleri için de kullanılmaktadır. Kanitatif yöntemler, talep tahmini için ilgili değişkenler ve matematiksel verilere dayanan çeşitli matematiksel modeller kullanmaktadır. Kalitatif yöntemler ise karar vericinin sezgi, bilgi, tecrübe ve değerlerine dayanmaktadır. Pratikte iki yöntemin birlikte uygulanması daha etkili sonuç vermektedir (Heizer ve Render 2017).

3.2 Nitel (Kalitatif) Talep Tahmin Yöntemleri

Nitel talep tahmin yöntemleri hissel, kişisel yargılara dayanan yöntemlerdir. Bu nedenle tahmin performansı kanitatif yöntemlere göre daha düşüktür. Kalitatif yöntemler genel olarak dört başlıkta değerlendirilmektedir. Bunlar;

1. Yönetim/Uzman görüşleri yöntemi: Tahmine etken konularda uzman veya yöneticilerin bir araya getirilerek taleple ilgili tahmin yapılmasına dayanan bir yöntemdir (Heizer ve Render 2017). Grup üyeleri arasında etkileşim mevcuttur.
2. Delfi yöntemi: Yönetici/uzman görüşleri yönteminde bir araya gelen grup üyelerinin birbirleriyle etkileşiminden kaynaklanan olumsuz sonuçları ortadan kaldırmaktadır. Uzman görüşlerinin sistematik olarak elde edilmesini sağlayan bir yöntemdir. Delfi tekniğinde tahmin gerçekleştirecek uzmanların ya da grupların yüz yüze gelmeden fikir birliğinin oluşturulması amaçlanmaktadır. Yazılı olarak yürütülen süreç geri beslemeli olarak fikir birliği sağlanan kadar devam ettirilir (Şahin 2001).
3. Satış gücü bileşimi: Satış gücü bileşimi yönteminde her satıcı kendi bölgesindeki satışlarla ilgili tahminde bulunur. Bu tahminler daha sonra daha üst çerçevede değerlendirilerek toplam tahmine ulaşılmaya çalışılır (Heizer ve Render 2017).
4. Pazar anketi yöntemi: Pazar anketi yönteminde mevcut müşteri ya da potansiyel müşterilerden gelecekteki satın alma planları ile ilgili bilgi toplanır. Bu yöntemle sadece talep tahmini değil, ürün tasarımı, yeni

ürünlerin geliştirilmesi gibi konularda da bilgi temin edilebilir. Seçilen tüketici grubunun temsil gücü tahmin sonucunu doğrudan etkilemektedir. Bu nedenle doğru tüketicilere doğru sorulması duyarlılığı arttıracaktır (Akın 2017).

3.3 Nicel (Kanitatif) Talep Tahmin Yöntemleri

Nicel talep tahmin yöntemleri geçmişteki verilerin ve ilgili değişkenlerin uygun matematiksel modellerle işlenmesi temelini esas alan yöntemlerdir. İstatistik temelli bu metotlar geçmişteki talebe ilişkin verileri, etken faktörleri ile birlikte analiz ederek gelecekle ilgili talep tahmini yapılmasını sağlamaktadır. Günümüzde talebe ilişkin parametrelerin fazla sayıda ve karmaşık yapıda olması nitel tahmin yöntemlerinin yetersiz kalmasına, bu nedenle de talep tahmin başarısının artırılması amacıyla istatistiksel metotların kullanım oranının artmasına neden olmuştur. Nicel tahmin yöntemleri Zaman serileri modelleri ve ilişkişel modeller olarak iki grupta incelenebilir.

İlişkişel modeller, doğrusal regresyon gibi tahmini etkileyecek faktörleri ve değişkenleri dikkate alarak tahmin işlemini gerçekleştirir. Zaman serileri modelleri ise geleceğin, geçmişin bir fonksiyonu olduğu varsayımı ile seri geçmiş zaman verisini kullanarak tahmin gerçekleştirmektedir (Heizer ve Render 2017).

Kronolojik sırayla edinilebilen verilere sahip değişkenlere zaman serisi denilmektedir. Zaman serileri sürekli ve kesikli olmak üzere ikiye ayrılmaktadır Zaman içerisinde edinilebilen verilerin sürekliliği mevcut ise sürekli zaman serileri, belli aralıklarla edinilebilen verilere ise kesikli zaman serileri denilmektedir (Kadılar ve Öncel Çekim 2020).

Zaman serileri belirli aralıklarla toplanan istatistiksel verilerdir. Zaman serileri ile gerçekleştirilen tahminlerde kullanılan istatistiksel veriler geçmişte ve belli koşullarda elde edildiğinden, yöntem değişken olmayan koşullarda daha etkin olmaktadır (Çağlar 2007).

Aşağıda nicel metotlardan genel olarak kullanılan Regresyon Analizi, Korelasyon analizi, Hareketli Ortalamalar Yöntemi, Üssel Düzeltme Yöntemi ve Box-Jenkins yöntemi anlatılmıştır.

3.3.1 Regresyon Analizi

Regresyon, en basit anlatımla iki ya da daha fazla değişken arasında bir ilişkinin olup olmadığının bulunmasıdır. Regresyon analizi ise değişkenler arasındaki ilişkinin matematiksel olarak fonksiyonlarla ifade edilmesidir.

Başka bir deyişle birden fazla değişkenin aralarındaki sebep sonuç ilişkisinin modellendiği istatistiksel bir yöntemdir. Fizik, kimya, biyoloji, tıp gibi birçok alanda kullanılmaktadır (Taşkıner 2018).

En basit regresyon modeli;

$$Y = a + bX + e \quad (3.1)$$

olarak ifade edilebilir.

Denklemden;

Y: Bağımlı Değişken

a: Sabit Değer

b: Regresyon Katsayısı

X: Bağımsız Değişken

e: Hata Katsayısı

olarak ifade edilmektedir.

İkiden fazla değişken arasındaki ilişkinin modellendiği çoklu regresyon modeli ise;

$$Y = a_0 + a_1 * X_1 + a_2 * X_2 + \dots + e \quad (3.2)$$

olarak ifade edilebilir (Adıyaman 2007).

Basit ve çoklu regresyon modellerinde tek bir Y bağımlı değişkeni mevcut olmakla birlikte, basit regresyon modelinde tek bir X bağımsız değişkeni, çoklu regresyon modelinde ise birden fazla X bağımsız değişkeni mevcuttur. Özetle bir bağımlı değişken tek bir bağımsız değişken tarafından açıklanıyorsa basit regresyon, birden fazla değişken tarafından açıklanıyorsa çoklu regresyon modeli söz konusudur (Çil 2021).


Değişkenler arasındaki ilişkinin en iyi şekilde analiz edilebilmesi için en uygun doğrunun çizilmesi ve bu doğru üzerindeki a ve b değerlerinin bulunması gerekmektedir. Bu doğrunun tespitinde en küçük kareler yöntemindeki iki ölçütten faydalanılabilir. Bu ölçütlerden ilki sapmaların toplamının sıfır olmasıdır. Bu doğrultuda denklem;

$$\sum_{i=0}^n [Y_i - (a + bX_i)] = 0 \quad (3.3)$$

olacaktır. İkinci ölçüt ise sapmaların karelerinin toplamının en küçük değerde olmasıdır. Bu kriter doğrultusunda denklem;

$$\sum_{i=0}^n [Y_i - (a + bX_i)]^2 \rightarrow \min \quad (3.4)$$

olacaktır. Hesaplama sonucu elde edilen a ve b değerleri ile oluşturulacak doğruya (X_i , Y_i) kümesinin regresyon doğrusu denir (Taşkın 2018).



Şekil 3.1: Regresyon doğrusu (AKIN 2017).

Gerçek değer y_i ile tahmin edilen değer Y_i arasındaki fark hata değeridir. Hata değerleri sıfır, pozitif ya da negatif değerler alabilmekle birlikte, matematiksel toplamları sıfıra eşittir (AKIN 2017). Bu doğrultuda denklem;

$$\sum_{i=1}^n e_i = \sum_{i=1}^n (y_i - Y_i) = 0 \quad (3.5)$$

olacaktır.

Bununla birlikte değişkenler arasındaki ilişkinin doğrusal regresyon modeliyle yeterli olarak ifade edilmesinin mümkün olmadığı durumlarda eğri denklemleri kullanılmaktadır. Bağımlı değişken ve bağımsız değişken/değişkenler arasındaki ilişkinin açıklanmasında doğrusal regresyon modelinin yetersiz kaldığı durumlarda kullanılan denklemler aşağıdaki gibidir (Dinç 2021).

Parabolik Bağntı:

$$Y = \alpha + \beta_1 X + \beta_2 X^2 \quad (3.6)$$

Kübik Bağntı:

$$Y = \alpha + \beta_1 X + \beta_2 X^2 + \beta_3 X^3 \quad (3.7)$$

Hiperbolik Bağıntı:

$$Y = \frac{1}{(\alpha + \beta_1 X_1)} \quad (3.8)$$

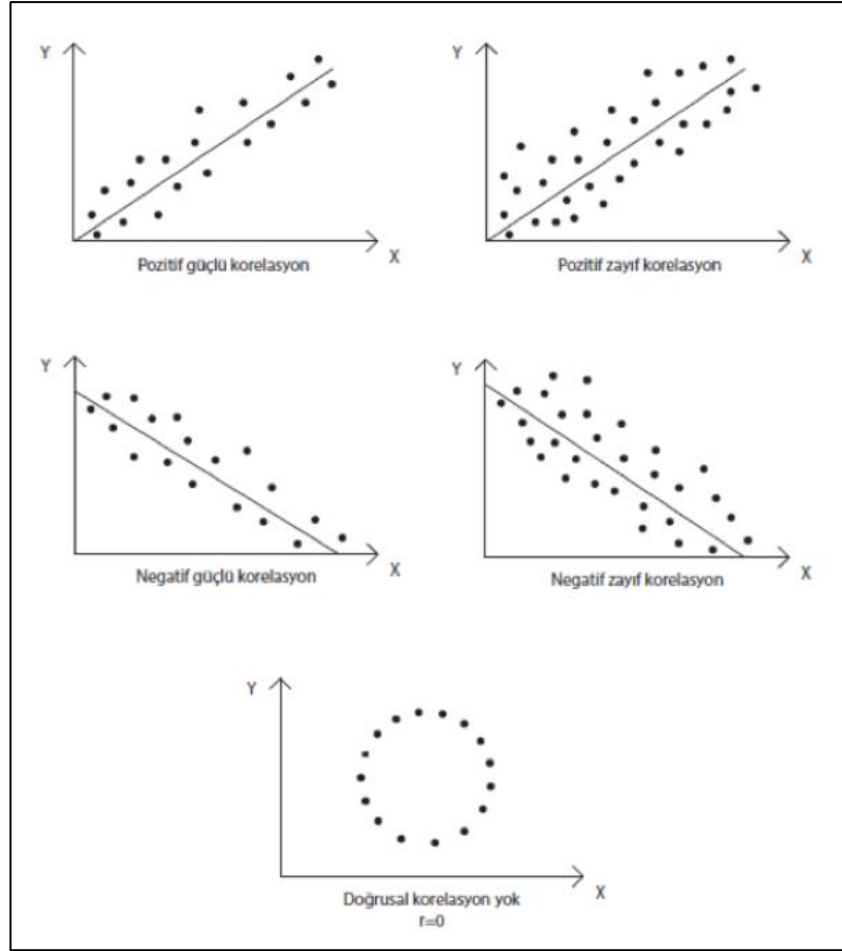
Geometrik Bağıntı:

$$Y = \alpha X^\beta \quad (3.9)$$

3.3.2 Korelasyon Yöntemi

Korelasyon, değişkenler arasındaki ilişki durumunun analizinde kullanılan istatistiksel bir yöntemdir. Korelasyon analizinde bir değişkendeki değişim diğer değişkende artış, azalış ya da değişim olmaması ile sonuçlanmaktadır. Bu durum değişkenler arasındaki ilişki durumunu açıklamaktadır. Matematiksel olarak r ile ifade edilen korelasyon katsayısı değişkenler arasındaki ilişki ile birlikte ilişkinin yönünü de tanımlamaktadır (Dinç 2021).

Korelasyon katsayısının pozitif değer alması değişkenler arasında pozitif ilişkiyi negatif değer alması negatif ilişkiyi temsil etmektedir. Değerin büyüklüğü ise ilişkinin kuvvetini göstermektedir. Korelasyon katsayısının güçlü ya da zayıf, pozitif ya da negatif yönlü olma durumlarını gösteren serpilme diyagramları Şekil 3.2’de verilmiştir.



Şekil 3.2: İki değişken arasında bulunan korelasyonun serpilme diyagramı ile gösterilmesi (İstanbul Üniversitesi 2021).

Korelasyon katsayısı 0 ile 1 arasında değerler almaktadır. Korelasyon katsayısı eğim değeri ile aynı işarete sahiptir. r korelasyon katsayısı değeri 0,8’den büyükse iki değişken arasında kuvvetli bir ilişki, 0,5’den küçükse iki değişken arasında zayıf bir ilişkiden bahsedilebilir. $r = +1$ ise iki değişken arasında artan, $r = -1$ ise azalan doğrusal bir ilişki söz konusudur ve doğrusal eğri tüm noktalardan geçmektedir (Ankara Üniversitesi 2021).

İki değişken arasındaki doğrusal ilişkinin kuvvetini tanımlayan korelasyon katsayısı formülü aşağıda verilen (3.10) eşitliği ile hesaplanmaktadır.

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{n(\sum x^2) - (\sum x)^2} \sqrt{n(\sum y^2) - (\sum y)^2}} \quad (3.10)$$

3.3.3 Basit Hareketli Ortalamalar Yöntemi

Basit hareketli ortalamalar yöntemi, zamanla doğru orantılı bir şekilde dinamik olarak belirli ve tekrar eden bir aralıkta gözlemlenen verilerin ortalama değerlerinin gelecekte benzer eğilim gösterilmesi varsayımı doğrultusunda tahmininde kullanılması düşüncesini temel almaktadır. Basit bir hareketli ortalama yöntemi örneği olarak son üç aylık satış verilerinin ortalamalarının bir sonraki ay için satış tahmini değeri olarak değerlendirilmesi ve zamanla aylık gerçekleştirmelerin son üç aylık dönem içerisinde ortalamaya dahil olarak tahmin değerlerinin dinamik olarak elde edilmesi verilebilir.

Basit hareketli ortalama yöntemi, durağan serilerde iyi sonuçlar üretebilmektedir. Durağan serilerin beklenen değeri zaman içerisinde değişmemesi ve bu nedenle ortalamanın çevresindeki hareketler tanım gereği önceden tespit edilemeyeceğinden en iyi tahmin ortalama değer olacaktır. Hesaplama yapılırken öncelikle toplamlar hesaplanmakta, takiben bu toplamlar dönem sayısına bölünerek hareketli ortalama değeri elde edilmektedir. Hesaplama sürecindeki en önemli adımlardan biri dönem sayısının belirlenmesidir. Dönem sayısının 1 ve n olduğu durumlar uç pozisyonlardır ve bu nedenle ileriye yönelik tahminler gerçekleştirme olanaksız hale gelmektedir. Buna göre dönem sayısının kısa seçilmesi durumunda yöntem rassal hareketleri bastırmayacak, uzun seçilmesi durumunda da yeni bilgilerin etkilerine gereken önem verilmeyecektir (Sarıaslan ve diğ. 2017).

Hareketli ortalamalar yöntemi en basit şekli ile aşağıda verilen (3.11) eşitliği ile ifade edilmektedir.

$$\hat{y}_{t+1} = \frac{y_t + y_{t-1} + \dots + y_{t-k}}{k} \quad (3.11)$$

3.3.4 Basit Üssel Düzeltme Yöntemi

Basit üssel düzeltme yöntemi de hareketli ortalamalar yöntemi gibi zaman serisinin geçmiş verilerinden hesapla tahmin gerçekleştirmektedir. Ancak veride trend ya da mevsimsellik yoksa doğru olarak kullanılabilir. Üssel düzeltme yönteminde herhangi bir zamandaki tahmin değeri eldeki bütün geçmiş verilerin

ağırlıklı ortalaması olarak hesaplanmaktadır. En yeni gözlem α ağırlığı ile çarpılırken, ikinci en yeni gözlem $(1 - \alpha) \alpha$ ile, üçüncü en yeni gözlem $(1 - \alpha)^2 \alpha$ ile, sonraki gözlemlerde benzer şekilde çarpılarak hesaba dahil edilmektedir. Seçilen α katsayısına düzeltme(yumuşatma) katsayısı denilmektedir (Sarıaslan ve diğ. 2017).

Basit üssel düzeltme yöntemi en basit şekli ile aşağıda verilen (3.12) eşitliği ile ifade edilmektedir.

$$F_{t+1} = \alpha X_t + (1 - \alpha)F_t \quad (3.12)$$

Burada;

F_{t+1} : t+1 dönemi için tahmin değeri,

α : Düzeltme katsayısı ($0 < \alpha < 1$),

X_t : Şu andaki gerçek değer,

F_t : t dönemi için düzeltilmiş değeri (bu aynı zamanda t-1 dönemi için düzeltilmiş değeridir).

Düzeltme katsayısı 0 ile 1 arasında olmalıdır. 0 ya da 1 değeri alamaz. Eğer değer 1'e yakın seçilirse geçmiş veriler çok fazla dikkate alınmayacak, 0'a yakın seçilirse eski değerlerin ağırlıkları artacaktır.

3.3.5 Birleştirilmiş Otoregresif Hareketli Ortalamalar (Box-Jenkins) Yöntemi

Box-Jenkins (ARIMA) modelleri yapısal bir regresyon analizinde yer alabilecek birçok bilgiyi göz ardı eden, en yeni gözlemi başlangıç noktası kabul etmektedir. Yöntem genel model sınıfları içerisinde en uygununun tespiti için kendini tekrar eden bir süreç kullanmaktadır. Seçilen model daha sonra test edilmektedir. Eğer tahmin sonuçlarında modelin hataları büyükse, rassal olarak dağılmamışsa ve bağımsız değilse süreç tekrar edilmektedir (Sarıaslan ve diğ. 2017).

Bu yaklaşım tek deęişkenli, kısa dönem tahminlerinde başarılı bir modeldir. Yöntemde, uygulama yapılan serinin eşit zaman aralıklı, kesikli ve durağan bir seri olması varsayılmaktadır (Ballı 2014).

Tam bir ARIMA modelinde p AR modelinin derecesinin, d kaçınıcı dereceden fark alınması gerektiğinin, q MA modelinin derecesinin bilinmesi gerekmektedir. Bu parametreler ile birlikte Box-Jenkins yöntemi (3.13) eşitliğı ile ifade edilmektedir.

$$Y_t = A_1Y_{t-1} + A_1Y_{t-1} + \dots + A_pY_{t-p} + e_t + W_1e_{t-1} + W_2e_{t-2} + \dots + W_qe_{t-q} \quad (3.13)$$

3.3.6 Yapay Sinir Ağları Metodu İle Talep Tahmin

Günümüzde geleneksel yöntemlerle çözümlenemeyen ve doğrusal olmayan problemlerin çözümü için kullanılan en önemli yöntemlerden biri yapay sinir ağlarıdır. Normal dağılıma sahip olmayan verilerin analizini gerçekleştirebilme, eksik verilerle çalışabilme gibi esnek bir yapıya sahip bu yöntem tahmin konusunda başarılı sonuçlar vermektedir (Dinç 2021). Konuyla ilgili detaylar ilerleyen bölümlerde verilecektir.

4. YAPAY SINİR AĞLARI

Yapay sinir ağıları ile ilgili çalışmalar 1940'lı yıllarda başlamış, ilk yapay sinir hücresi modeli 1943 yılında Mc Colloch-Pitts tarafından oluşturulmuştur. 1940 yılında Hebb tarafından birçok öğrenme kuralına temel oluşturan “Hebbian öğrenme kuralı” ortaya atılmıştır. Takip eden yıllarda Rosenbaltt ve Caianiello tarafından algılayıcı modeller, Woidrow ve Hoff tarafından ADALINE doğrusal nöron modeli geliştirilmiştir. 1960'lı yılların sonlarında Minsky ve Papert'ın “Perceptrons” isimli kitaplarında yapay sinir ağlarının doğrusal olmayan problemlerin (XOR problemi) çözümünü gerçekleştiremediği iddiası yapay sinir ağları ile ilgili güven sorunu oluşmasına neden olsa da konu ile ilgili çalışmalar devam etmiştir. 1980'li yıllarda David E. Rummelhart ve James MacCelland'ın “Paralel Dağıtımli İşleme” konusunda yaptıkları çalışma da yapay sinir ağları ile XOR probleminin çözümünü sağlamaları sonrası yapay sinir ağları ile ilgili çalışmalar hız kazanmıştır. Günümüzde ise birçok alanda ve konuda kullanılabilir bir uygulama alanı haline gelmiştir (Öztemel 2006).

4.1 Yapay Sinir Ağlarının Genel Tanımı

Yapay sinir ağları, insan beyninin işleyişinden esinlenerek geliştirilmiş, birbirine bağlı ve her bir bağlantının bir ağırlığa sahip olduğu, her biri kendi belleğine sahip işlem birimlerinden oluşan bilgi işleme yapılarıdır. Başka bir deyişle biyolojik sinir hücrelerini taklit eden bilgisayar programlarıdır (Elmas 2021).

Yapay sinir ağları yeni nesil bilgi işleme birimleri olarak tanımlanmaktadır. Genel olarak programlanması çok zor ya da mümkün olmayan konularda başarılıdır. İnsan beynine benzer bir şekilde öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon konularında başarıyla uygulanmaktadır. Yapay sinir ağlarının karakteristik özellikleri modele göre değişmekle birlikte genel özellikleri aşağıdaki gibi sıralanabilir (Öztemel 2006).

- Temel görevleri bilgisayarların öğrenmesini sağlamaktır.
- Bilgi işleme yöntemi olarak geleneksel programlama ve yapay zeka yöntemlerinden farklıdır.

- Yapay sinir ağlarında bilgi ağın bağlantı noktalarındaki ağırlık değerleri ile ölçülmekte ve ilgili bağlantılarda saklanmaktadır.
- Yapay sinir ağları adaptif öğrenme temelinde geçmiş örnekleri kullanarak öğrenirler.
- Yapay sinir ağlarının verimli ve güvenli kullanılabilmesi için eğitilmesi ve elde edilen çıktılarının test edilmesi gereklidir.
- Eğitim içerisinde görmedikleri örneklerle ilgili bilgi üretebilirler.
- Algılamaya yönelik bilgileri işlemek amacıyla kullanılabilirler.
- Örüntü örnekleri arasında ilişki kurabilir, örnekler arasında kümeleme ve sınıflandırma işlemi gerçekleştirebilirler.
- Örüntülerde eksik bilgileri tespit edebilir ve tamamlayabilirler.
- Eğitildikten sonra gelen eksik bilgilerle çalışabilir ve sonuç üretebilirler.
- Hatalar karşı toleranslıdırlar.
- Tam olmayan ya da belirsiz bilgileri işleme yetenekleri vardır.
- Zaman içerisinde bozulmaya uğrarlar. Problem ortaya çıktığı an hemen bozulmazlar.
- Ağa yayılmış şekilde dağıtık bir belleğe sahiptirler.
- Sadece nümerik yapıdaki bilgilerle çalışabilirler.

4.2 Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağlarının birçok avantajlı yönü olmakla birlikte dezavantajlı yönleri de mevcuttur. Bunlar aşağıdaki gibi sıralanabilir (Öztemel 2006).

- Ağın temel yapısının paralel bilgi işlemeye yönelik olması ve bu doğrultuda gerçek zamanlı bilgiyi işleme hususunda paralel çalışan işlemcilerle ihtiyaç duyulması nedeniyle bazı problemlerin çözümü mümkün olamayabilir.
- Bir problemin çözümü için uygun ağ yapısının tespiti deneme yanılma yolu ile yapıldığı için çözümü olan bir problem çözülemeyebilir ya da çözüm başarısı düşük olabilir.

- Ađın öğrenme katsayısı, nöron sayısı gibi parametrelerinin belirlenmesi ile ilgili bir kural olamaması nedeniyle her problem için ayrı değerlendirilmesi gereklidir. Parametrelerin belirlenmesi kullanıcının tecrübesine bađlıdır.
- Ađın nümerik verilerle çalışması nedeniyle sembolik bilgilerin dönüşümü gereklidir ve bu dönüşüm kullanıcının yetkinliğine bađlıdır.
- Ađ eğitiminin ne zaman bitirilmesi gerektiđi ile ilgili bir kural mevcut değildir. Bu nedenle optimum öğrenmenin 0hangi aşamada gerçekleştiđi tespit edilememektedir.
- Bir probleme çözüm üretilmesi durumunda bu çözümün nasıl ve neden üretildiđi ile ilgili bilgi bulmak mümkün olmamaktadır. Bu durumda ađın ürettiđi sonuca olan güveni azaltmaktadır.

4.3 Yapay Sinir Ağlarının Kullanım Alanları


Günümüzde, yapay sinir ağları eksik bilgileri tamamlayabilme ve normal olmayan verileri işleyebilme özellikleri nedeniyle örüntü tanıma ve sınıflandırma işlemlerinde çok başarılı sonuçlar üretmektedir. Özellikle radar verileri gibi çok sayıda verinin işlenmesi gibi işlemlerde oldukça başarılıdırlar. Genellikle aşağıdaki fonksiyonları yerine getirmektedirler (Öztemel 2006).

- Probabilistik fonksiyon kestirimleri
- Örüntü tanıma
- Sınıflandırma
- Doğrusal olmayan sinyal işleme
- İlişkilendirme veya örüntü eşleştirme
- Doğrusal olmayan sistem modelleme
- Zaman serileri analizi
- Optimizasyon
- Sinyal filtreleme
- Zeki ve doğrusal olmayan kontrol
- Veri sıkıştırma

Günlük hayatta ise birçok alanda uygulamaları mevcuttur. Bunlardan bazıları optik karakter okuma, veri madenciliği, kredi müracaatı değerlendirme, bazı hastalıkların teşhisi, üretim planlama ve çizelgeleme, bakım planlama, kredi kartı hilelerinin tespitidir. Yapay sinir ağları bu konula dışında gerçek hayatta doğrusal olmayan birçok problemin çözümünde de kullanılmaktadır (Öztemel 2006).

4.4 Yapay Sinir Hücresinin Yapısı Ve Temel Elemanları

Yapay sinir ağı biyolojik sinir hücresinden esinlenilerek geliştirilmiştir. Biyolojik sinir hücreleri soma, akson ve dendritlerden oluşmaktadır. Biyolojik sinir hücresine ait görsel Şekil 4.1’de verilmiştir. Soma olarak isimlendirilen hücre gövdesi hücreyi denetlemek ve hücre etkinliklerinin yönetiminden sorumludur Hücre gövdesinden iki uzantı çıkmaktadır. Bu uzantılar akson ve dendritlerdir. Aksonlar, gövdedeki bilgiyi diğer sinir hücrelerinin dendritlerine taşımakla sorumludur. Dendritler ise hücre merkezinden dışarı uzanan ağaç dalları gibidirler. Dendritler bilgiyi iletim hatları olarak kullanılan uzun fiberlerden oluşmuş aksonlar boyunca diğer nöronlardan alır ve hücre merkezine ulaştırırlar (Nabiyev 2021).




Şekil 4.1: Biyolojik sinir hücresi (Öztemel 2006).

Biyolojik sinir hücrelerinin birbirleri ile doğrudan temasları yoktur. Biyolojik sinir hücrelerinin bağlantı noktalarında küçük sinaptik terminaller adı verilen boşluklar bulunmaktadır. Aksonların son bölümünde bulunan uçları yuvarlak küçük sinaptik terminallere gelen bir sinir itkisi nörotransmitter denilen bir kimyasal salgılanması

neden olur. Bu kimyasallar diğer hücre dendritine aradaki küçük sinaptik aralıkları geçerek ulaşır ve sonraki nöron uyarılır. Birden çok sinaps yolu ile nörona ulaşan uyarım, belli bir eşik değerini aştığı zaman ateşlenir ya da boşalır. Nöral itkinin gücü sürekli ve belli bir eşik değerine ulaşmadıkça ateşlenmez. Ateşleme durumunda ise uyarı akson boyunca birçok terminale iletilir (Nabiyev 2021).

Son derece basitleştirilmiş olarak biyolojik sinir hücresi modelini temel alan sanal nöron Mc Culloch ve Pitts tarafından Şekil 4.2'deki gibi modellenmiştir.



Şekil 4.2: Yapay sinir hücresi (Nabiyev 2021).

Yapay sinir ağlarının 5 temel elemanı vardır. Bunlar, girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılardır. Girdiler, ağırlık öğrenmesi istenen örneklerdir. Ağırlıklar, bir yapay hücreye gelen bilginin önem derecesini ve etki düzeyini belirleyen değerlerdir. Toplama fonksiyonu, yapay hücreye gelen net girdileri hesaplayan yapılardır. Aktivasyon fonksiyonu, yapay hücreye gelen net girdiyi işleyerek çıktıyı belirleyen yapılardır. Çıktı ise, toplam fonksiyonu ve takiben aktivasyon fonksiyonu tarafından belirlenen sonuç değeridir. Birden fazla toplama fonksiyonu mevcut olmakla birlikte, genellikle ağırlıklı toplama yöntemi kullanılmaktadır. Bu yöntemde her girdi kendi ağırlık ile çarpılıp toplanmaktadır. Aktivasyon fonksiyonu ise kullanılacak yapay sinir ağının çeşidine göre belirlenmektedir (Öztemel 2006). Yapay sinir ağları uygulamalarında kullanılan bazı toplama fonksiyonlarına ait örnekler Tablo 4.1'de, bazı aktivasyon fonksiyonlarına ait örnekler Tablo 4.2'de verilmiştir.

Tablo 4.1: Toplama fonksiyonu örnekleri (Öztemel 2006).

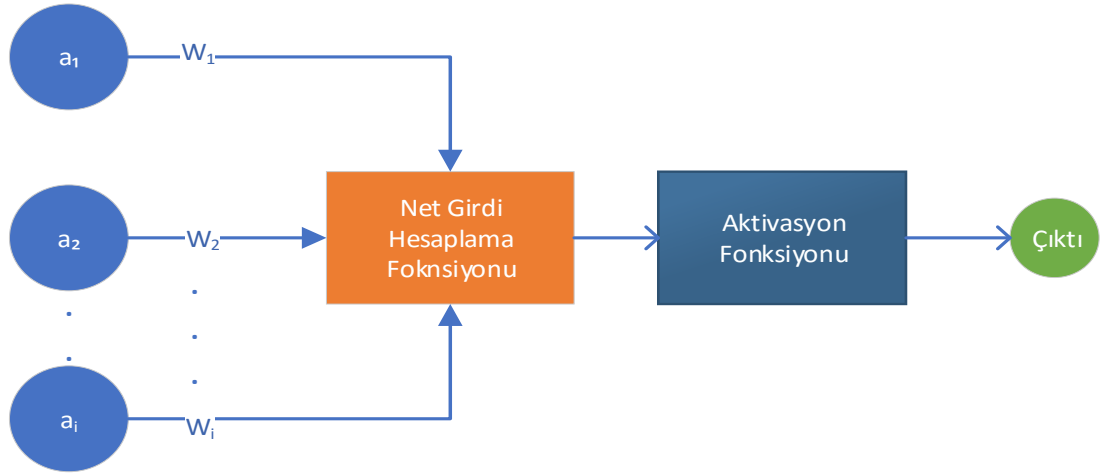
Net Giriş	Açıklama
Ağırlıklı Toplam $NET = \sum_i^n a_i * w_i \quad (4.1)$	Girdiler ağırlıklarla çarpılır. Bulunan değerler toplanarak net girdi hesaplanır.
Çarpım $\text{Net Girdi} = \prod_i G_i A_i \quad (4.2)$	Girdiler ile ağırlık değerleri çarpılır. Bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır.
Maksimum $\text{Net Girdi} = \text{Max}(G_i A_i) \quad i = 1 \dots N \quad (4.3)$	Girdiler ile ağırlık değerleri çarpılır. Çarpımda elde edilen en büyük değer net girdi kabul edilir.
Minimum $\text{Net Girdi} = \text{Min}(G_i A_i) \quad i = 1 \dots N \quad (4.4)$	Girdiler ile ağırlık değerleri çarpılır. Çarpımda elde edilen en küçük değer net girdi kabul edilir.
Çoğunluk $\text{Net Girdi} = \sum_i \text{sgn}(G_i A_i) \quad (4.5)$	Girdiler ile ağırlık değerleri çarpılır. Çarpımda negatif ve pozitif değerlerin sayısı bulunur. Büyük olan değer net girdi olarak kabul edilir.
Kümülatif Toplam $\text{Net Girdi} = \text{Net}(\text{eski}) + \sum (G_i A_i) \quad (4.6)$	Girdiler ağırlıklı olarak toplanır. Önceki bilgilere eklenerek net girdi hesaplanır.

Tablo 4.2: Aktivasyon fonksiyonu örnekleri (Öztemel 2006).

Aktivasyon Fonksiyonu	Açıklama
Lineer Fonksiyon $F(NE T) = NE T \quad (4.7)$	Girdiler hücrenin çıktısı olarak kabul edilir.
Step Fonksiyonu $F(NE T) = \begin{cases} 1 & \text{if } NE T > \text{eşik değ er} \\ 0 & \text{if } NE T \leq \text{eşik değ er} \end{cases} \quad (4.8)$	Girdi değ erinin belli bir eşik değ erinin altında ya da üstünde kalma durumuna göre 1 ya da 0 değ erlerini alır.
Eşik Değ er Fonksiyonu $F(NE T) = \begin{cases} 0 & \text{if } NE T \leq 0 \\ NE T & \text{if } 0 < NE T < 1 \\ 1 & \text{if } NE T \geq 1 \end{cases} \quad (4.9)$	Girdilerin 0'dan küçük olması durumunda 0, 1'den büyük olması durumunda 1, 0 ile 1 arasında olması durumunda kendi değ erini almaktadır.
Hiperbolik Tanjant Fonksiyonu $F(NE T) = \frac{(e^{NE T} + e^{-NE T})}{(e^{NE T} - e^{-NE T})} \quad (4.10)$	Girdiler için -1 ile 1 arasında değ erler üretilmektedir.
Sigmoid Fonksiyonu $F(NE T) = \frac{1}{(1 + e^{-NE T})} \quad (4.11)$	Girdiler için 0 ile 1 arasında değ erler üretilmektedir.

4.5 Yapay Sinir Hücresinin Çalışma Prensibi

Bir yapay sinir hücresi kendisine gelen girdileri seçilen fonksiyona göre net girdiyi hesaplama işlemine tabi tutar. Elde edilen net girdi seçilen aktivasyon fonksiyonuna göre değerlendirilerek sonuca karar verilir. Yapay sinir hücresi modeli Şekil 4.3'de verilmiştir.



Şekil 4.3: Basit yapay sinir hücresi modeli.

Ağırlıklı toplam ve sigmoid aktivasyon fonksiyonu kullanılan bir yapay sinir hücresinin üreteceği çıktı ile ilgili örnek işlem aşağıda verilmiştir.

$$a_1 = 0,3, w_1 = -0,3 \quad (4.12)$$

$$a_2 = 0,7, w_2 = 0,6 \quad (4.13)$$

$$a_3 = 0,6, w_3 = 0,4 \quad (4.14)$$

Ağırlıklı toplam fonksiyonu:

$$NET = \sum_i^n a_i * w_i = (0,3 * (-0,3)) + (0,7 * 0,6) + (0,6 * 0,4) = 0,57 \quad (4.15)$$

Sigmoid aktivasyon fonksiyonu:

$$F(NET) = \frac{1}{1 + e^{-NET}} = \frac{1}{1 + e^{-0,57}} = 0,63 \quad (4.16)$$

4.6 Yapay Sinir Ağları Yapısı

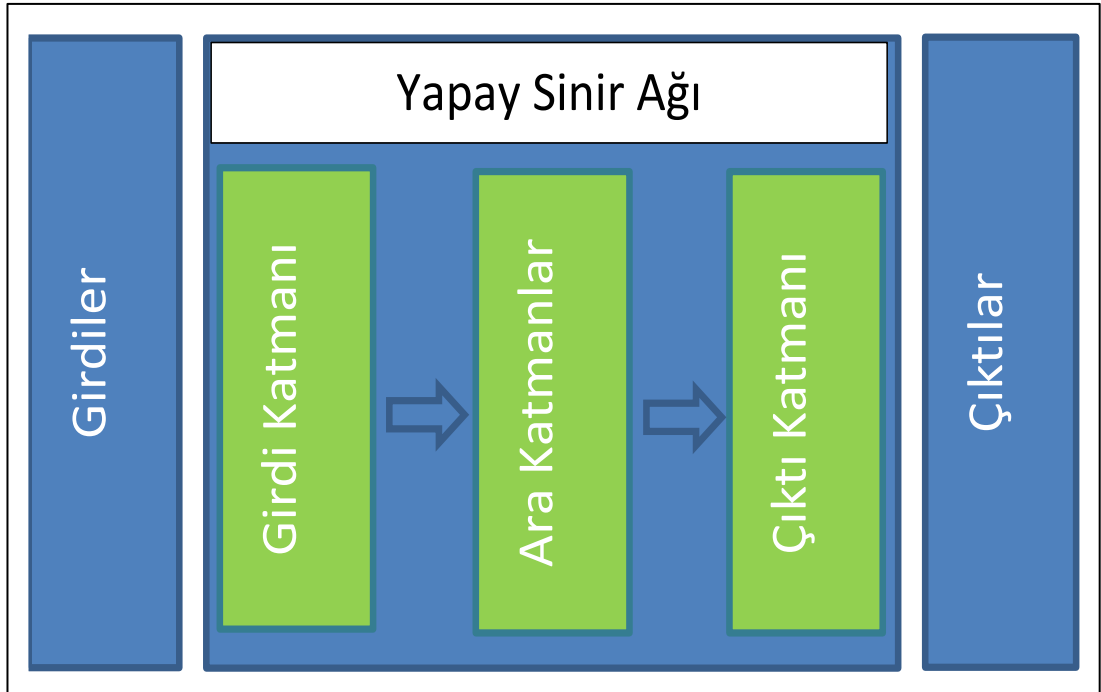
Yapay sinir ağları, yapay sinir hücrelerinin bir araya gelmesi sonucu oluşurlar. Genel olarak bu yapı birbirine paralel katmanlardan oluşturulmaktadır. Bu katmanlardan;

Girdi Katmanı: Girdi katmanı, dış dünyadan bilgileri almak ve ara katmana transfer etmekle sorumludur. Bilgiler herhangi bir işleme tabi tutulmamaktadır.

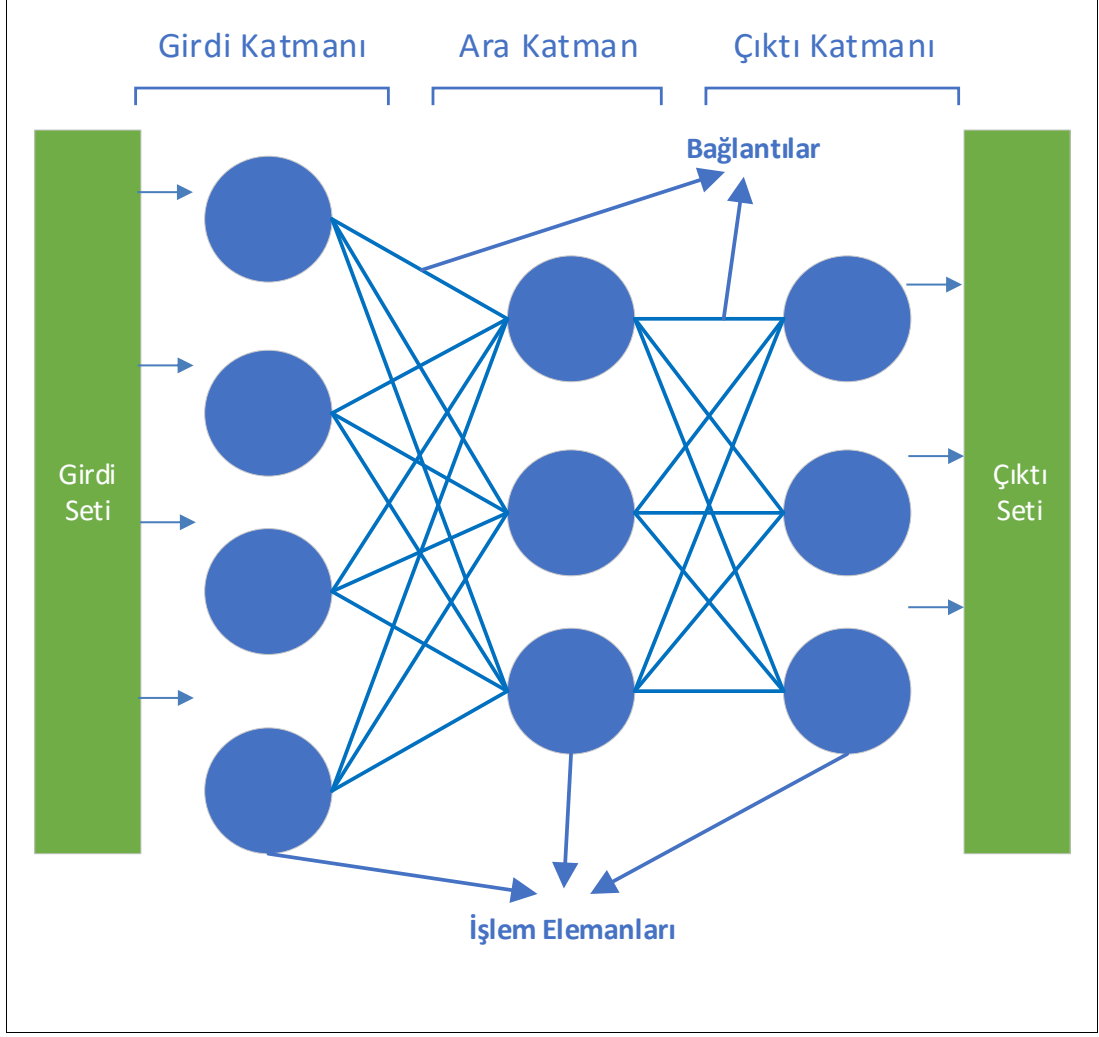
Ara Katman: Girdi katmanından gelen bilgilerin işlenmesi ve çıktı üretilmesinden sorumludur. Bilgiler bu katmanda işleme tabi tutulur. Seçilen ağın yapısına göre yapısı ve fonksiyonu değişiklik gösterebilir. Bir yapay sinir ağında birden fazla ara katman bulunabilir.

Çıktı Katmanı: Ara katmandan gelen bilgilerin girdi katmanında sunulan örnek veri seti uygun çıktının üretilmesi ve dış dünyaya gönderilmesinden sorumludur (Öztemel 2006).

Yapay sinir ağındaki katmanların ilişkilerini gösteren model Şekil 4.4’de, yapay sinir ağı örneği Şekil 4.5’de verilmiştir.



Şekil 4.4: Yapay sinir ağını oluşturan katmanlar (Adıyaman 2007).



Şekil 4.5: Yapay sinir ağı örneği.

4.7 Yapay Sinir Ağlarının Temel Öğrenme Kuralları

Yapay sinir ağlarında işlem elemanlarının bağlantılarının ağırlık değerlerinin belirlenmesine ağı eğitilmesi denilmektedir. İlk değerler rastgele belirlenmektedir. Yapay sinir ağı örnekler üzerinden doğru çıktıyı üretebilmek için ağırlık değerlerini değiştirmektedir. Ağı doğru ağırlık değerlerine ulaşması ve örneklerin temsil ettiği olaylar hakkında genellemeler yapabilme yeteneğine kavuşmasına ağı öğrenmesi denilmektedir (Demirceylan 2012).

Yapay sinir ağlarında, öğrenme sırasında fonksiyonlarını yerine getirebilen kurallara çevrimiçi, eğitim verisi ile öğrenme gerçekleştiren ve sonrasında

fonksiyonlarını yerine getirebilen kurallara çevrimdışı öğrenme kuralları denilmektedir (Adıyaman 2007).

Öğrenme kuralı Donal Hebb tarafından geliştirilen nörofizyolojik bir kuram olan ve adına “Hebbian Öğrenme Kuralı” denilen basit bir ilkeye dayanır. Bu kurala göre iki sinir hücresi birbirleri ile eş zamanlı etkin durumda ise aralarındaki bağın gücü artırılır (Elmas 2021). Öğrenme kurallarından bazıları aşağıda açıklanmıştır.

Hebb Kuralı: İlk ve en temel öğrenme kuralıdır. Donald Hebb tarafından yazılan “The Organization of Behavior” adlı kitabında 1949 yılında tanımlanmıştır. Kuranın temeli, birbirine bağlı iki sinirin her ikisinin etkin olması durumunda sinirler arasındaki ağırlığın artırılması ilkesine dayanmaktadır (Elmas 2021).

Hopfield Kuralı: Hebb kuralı temelinde ağırlıkların seviyelerinin öğrenme katsayısına göre belirlenmesi ilkesine dayanmaktadır. Hopfield kuralında, hücreler arasında eş zamanlı etkinlik veya durgunluk var ise, hücreler arasındaki bağlantı aralıkları öğrenme oranı kadar artırılır ya da azaltılır (Öğücü 2006).

Delta Kuralı: Windrow ve Hoff tarafından geliştirilmiştir. Hebb öğrenme kuralının geliştirilmiş bir çeşididir. Kural hücrenin gerçek çıkış değeri ile istenen çıkış değerinin arasındaki farkın sürekli azaltılması temelini esas alır. Bu işlemi gerçekleştirirken hata karesi minimize edilecek şekilde giriş bağlantı ağırlıkları sürekli olarak değiştirilir (Elmas 2021).

Kohonen Kuralı: Biyolojik sistemlerin öğreniminden esinlenerek geliştirilmiştir. Kohonen tarafında geliştirilen bu kural hücrelerin birbirleri ile yarışması esasına dayanmaktadır. Net girdi hesabı en büyük olan hücre yarışı kazır. Yarışı kazanan hücrenin değeri 1 diğer hücrelerin değeri 0 olarak işlenir (Öztemel 2006).

4.8 Yapay Sinir Ağlarının Sınıflandırılması

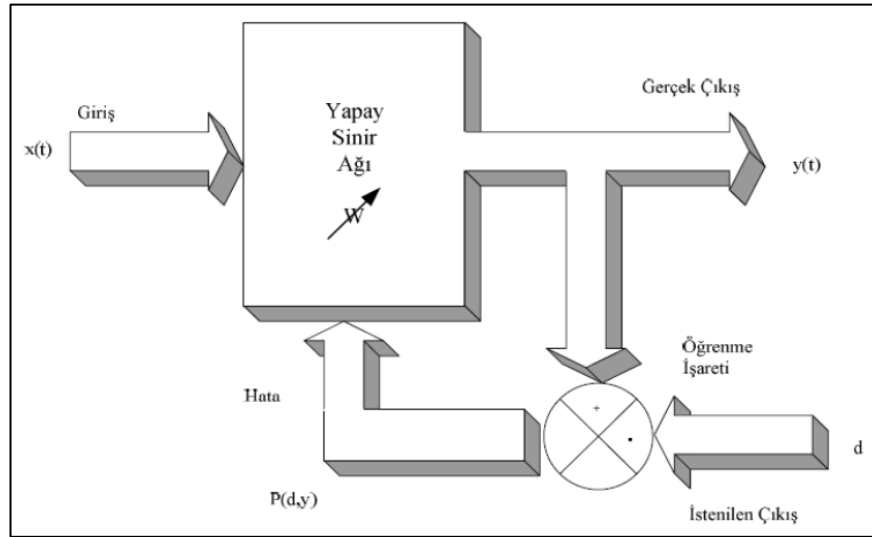
Yapay sinir ağları genel olarak hücreler, bağlantılar ve aktarım işlevlerinden oluşmaktadır. Bu nedenle birbirlerine benzerlik göstermektedirler. Sınıflandırma genellikle öğrenme ve ağ yapısına göre gerçekleştirilmektedir (Demirceylan 2012).

4.8.1 Öğrenme Yapısına Göre Yapay Sinir Ağlarının Sınıflandırılması

Öğrenme yapısına göre yapay sinir ağları, eğitmeli, eğitmesiz ve takviyeli öğrenen yapay sinir ağları olarak üç temel gruba ayrılmaktadır.

4.8.1.1 Eğitmeli (supervised) Öğrenme

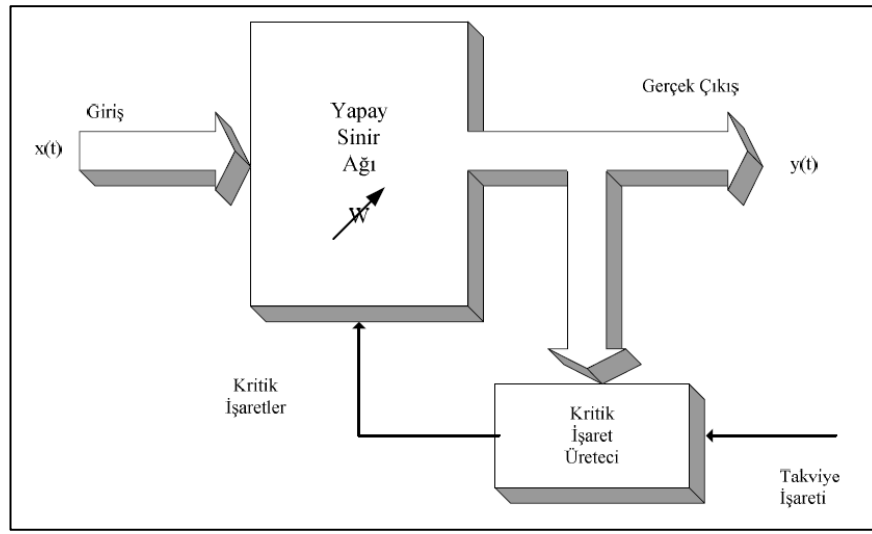
Eğitmeli öğrenme yapısındaki yapay sinir ağlarında danışman tarafından öğrenilmesi istenen olay için girdi verileri ve bu verilere karşılık gelen çıkış verileri ağa verilir. Ağ tarafından, verilen giriş ve ilgili giriş değerlerine karşılık gelen çıkış değerlerinin haritalaması yapılır ve bu doğrultuda ilgili veriler arasındaki ilişkiler öğrenilir. Öğrenmenin gerçekleştirildiği bu veriye eğitim verisi adı verilir. Bununla birlikte verinin bir kısmı da öğrenme sonrası öğrenmenin performansını test etmek için kullanılır. Bu veriye de test verisi adı verilir. Genellikle, veriler danışman tarafından %80 eğitim, %20 test olacak şekilde ayrılır (Aksoy 2020). “Çok Katmanlı Algılayıcılar”, eğitmeli öğrenme yapısındaki yapay sinir ağlarına örnek olarak verilebilir. Eğitmeli öğrenme yapısına ait görsel Şekil 4.6’da verilmiştir.



Şekil 4.6: Eğitmeli (supervised) öğrenme yapısı (Akın 2017).

4.8.1.2 Takviyeli (reinforcement) Öğrenme

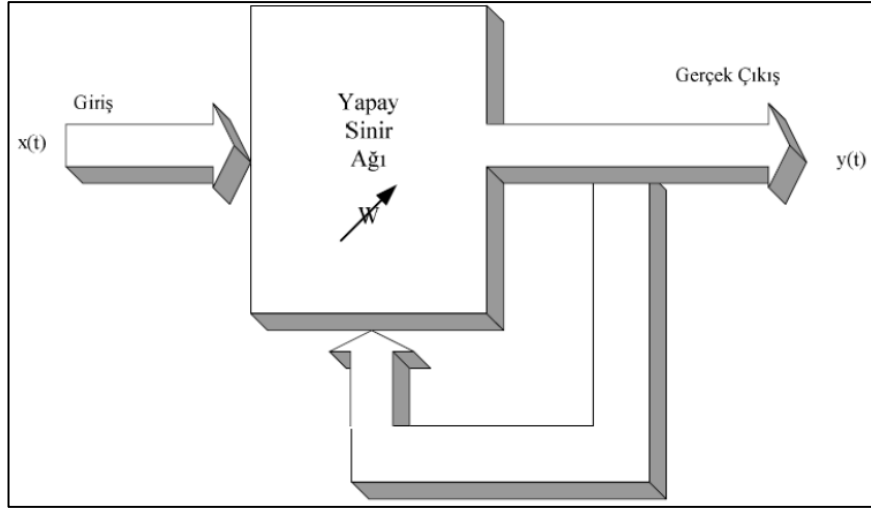
Takviyeli öğrenme yapısındaki yapay sinir ağlarında öğrenilmesi istenen olayla ilgili girdiler sisteme verilir. Üretilen çıktının doğruluğunun danışman tarafından belirlenmesi istenir. Danışman tarafından, üretilen çıktının doğru ya da yanlış olduğu sinyali ağa verilir. Ağ, danışmandan aldığı sinyaller ile öğrenme işlemini gerçekleştirir. LVQ yapay sinir ağı takviyeli öğrenme yapısındaki ağlara örnek olarak verilebilir (Aksoy 2020). Takviyeli öğrenme yapısına ait görsel Şekil 4.7’de verilmiştir.



Şekil 4.7: Takviyeli (reinforcement) öğrenme yapısı (Akın 2017).

4.8.1.3 Eğitmesiz (unsupervised) Öğrenme

Eğitmesiz öğrenme yapısındaki yapay sinir ağlarında öğrenilmesi istenen olayla ilgili sadece girdiler sisteme verilir ve öğrenmenin sistem tarafından gerçekleştirilmesi beklenir. Girdi olarak verilen veriler arasındaki ilişki sistem tarafından öğrenilir. Öğrenme sonuçlarının kullanıcı tarafından yorumlanması gereklidir (Aksoy 2020). Grossberg tarafından geliştirilen ART ve Kohonen tarafından geliştirilen SOM öğrenme kuralı ile çalışan yapay sinir ağları eğitmesiz öğrenme yapısındaki ağlara örnek olarak verilebilir (Demirceylan 2012). Eğitmesiz öğrenme yapısına ait görsel Şekil 4.8’de verilmiştir



Şekil 4.8: Eğitmesiz (unsupervised) öğrenme yapısı (Akın 2017).


4.8.2 Ağ Yapısına Göre Yapay Sinir Ağlarının Sınıflandırılması

Ağ yapılarına göre yapay sinir ağları, ileri ve geri beslemeli yapay sinir ağları olarak iki temel gruba ayrılmaktadır.

4.8.2.1 İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağlarında, işlemler tek bir yönde giriş tabakasından çıkış tabakasına doğru gerçekleşir. Bir tabakadaki işlem elemanları yalnızca sonraki tabakadaki işlem elemanlarına bağlanabilir. Bu doğrultuda bir tabakada elde edilen çıktılar aynı ya da önceki tabakalardaki işlemleri etkilemez (Akın 2017).


Çok katmanlı algılayıcı (MLP) ve öğrenme vektörü nicemlemesi (LVQ) ağları ileri beslemeli yapay sinir ağlarına örnek olarak verilebilir (Karahan 2011). Çok katmanlı ileri beslemeli yapay sinir ağına ait örnek bir model Şekil 4.9’da verilmiştir.



Şekil 4.9: Çok katmanlı ileri beslemeli yapay sinir ağı (Demirceylan 2012).

4.8.2.2 Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağlarında, bir işlem elemanının ürettiği çıktı diğer işlem elemanlarına girdi olarak verilmektedir. Bununla birlikte bir tabakadaki işlem elemanları aynı tabakadaki işlem elemanları ve diğer tabakalardaki işlem elemanları ile bağlantı kurabilmektedir. Bu nedenle geri beslemeli yapay sinir ağlarındaki bir işlem elemanının ürettiği çıktı değeri, ilgili işlem elemanının girdi değerleri, ağırlık değerleri ve bağlı olduğu diğer işlem elemanlarının çıkış değerlerinden de etkilenmektedir (Akın 2017). Çok katmanlı geri beslemeli yapay sinir ağına ait örnek bir model Şekil 4.10'da verilmiştir.



Şekil 4.10: Çok katmanlı geri beslemeli yapay sinir ağı (Demirceylan 2012).

5. YAPAY SİNİR AĞLARI METODU KULLANILARAK DENİZLİ İLİ DOĞAL GAZ TÜKETİM TAHMİN UYGULAMASI

Bu bölümde, yapay sinir ağları yöntemi kullanılarak Denizli ili için günlük doğal gaz tüketim tahmin işlemi gerçekleştirilmiştir. Tüketicinin doğal gaz tüketimine etken olabileceği düşünülen bazı meteorolojik veriler ve doğal gaz satış fiyatı ile birlikte tüketim artışına etken abone BBS verisi incelenmiş ve tüketim üzerindeki etkileri gösterilmiştir.


5.1 Denizli İli Tüketim Analizi

Çalışmada kullanılan ve 2009 ile 2020 yılları arasındaki Denizli ili günlük Sm^3 cinsinden doğal gaz tüketimlerine ait veri seti Enerya Denizli Gaz Dağıtım A.Ş.'den temin edilmiştir. Veri setinde bulunan tüketim verileri serbest olmayan abone ve Kademe 1 tipindeki serbest tüketicilere ait tüketimlerdir. Doğal gazı dağıtım şirketinden tedarik etmeyen müşteriler ve doğal gazı dağıtım şirketinden tedarik eden büyük sanayi müşterileri çalışmaya dahil edilmemiştir. Kademe kavramı ile ilgili olarak;

Doğal gaz piyasasında kullanıcılar yıllık tüketim miktarlarına göre sınıflandırılmıştır. Bu sınıflandırmaya göre tüketiciler serbest ve serbest olmayan olarak iki ana grupta toplanmıştır. EPDK tarafından yayımlanan Doğal Gaz Piyasası Lisans Yönetmeliği (07 Eylül 2002 tarihli ve 24869 sayılı Resmi Gazete) ile tanımlanan serbest tüketici kavramı, “yurt içinde herhangi bir üretim şirketi, ithalat şirketi, dağıtım şirketi veya toptan satış şirketi ile doğal gaz alım-satım sözleşmesi yapma serbestisine sahip gerçek veya tüzel kişiyi” ifade ederken; serbest olmayan tüketici “doğal gazı kendi kullanımı için dağıtım şirketlerinden almak zorunda olan gerçek veya tüzel kişiyi” ifade etmektedir (EPDK 2021). Serbest tüketiciler ise kendi içlerinde iki kademeye ayrılmıştır. Yıllık gaz tüketimi 300.000 Sm^3 olan serbest tüketiciler Kademe 1, 300.000 Sm^3 'den yüksek olan tüketiciler Kademe 2 olarak sınıflandırılmıştır.

Serbest olmayan abone ve okul, hastane, ticarethane vb. gibi kademe 1 tipindeki serbest tüketiciler tarafından doğal gaz öncelikli olarak ısınma olmak üzere sıcak su ve yemek pişirme amaçlı kullanılmaktadır.

2009-2020 yılları arasında serbest olmayan abone ve kademe 1 tipindeki serbest tüketicilerin toplam tüketim grafiği Şekil 5.1’de verilmiştir.



Şekil 5.1: 2009-2020 yılları arasında serbest olmayan abone ve kademe 1 tipindeki serbest tüketicilerin toplam tüketim grafiği.

2009-2020 yılları arasında Denizli ili tüketimleri incelendiğinde hava sıcaklığının genellikle yüksek olduğu yaz aylarında azalan, hava sıcaklığının genellikle düşük olduğu kış aylarında ise artan bir tüketim mevcuttur. En yüksek tüketim genellikle Ocak aylarında, en düşük tüketim ise genellikle Temmuz aylarında gerçekleşmiştir. Tüketim eğilimi yıllar içerisinde artan bir doğrultuda seyir etmiştir. Bu eğilimin nedenleri bir doğal gaz tüketimine etki eden parametreler başlığı altında detaylı olarak değerlendirilecektir.


5.2 Doğal Gaz Tüketimine Etki Eden Parametreler

Meteoroloji, abone sayısındaki artış, demografik yapı, sosyo-kültürel yapı, siyasal ve ekonomik etmenler vb. birçok parametre doğal gaz tüketimini etkilemektedir. Bu çalışma, siyasal etmenler, demografik yapı ve sosyo-kültürel yapı gibi düzensiz ve kısıtlı enformasyon olan konular dışındaki meteorolojik, ekonomik ve abone sayısındaki artış gibi parametrelerin doğal gaz tüketimi üzerindeki etkileri dikkate alınarak gerçekleştirilmiştir.

Çalışmada kullanılan ve 2009 ile 2020 yılları arasındaki Denizli ili günlük adet cinsinden abone BBS sayılarına ait veri seti ve doğal gaz satış fiyatı verileri Enerya Denizli Gaz Dağıtım A.Ş.'den, günlük ortalama sıcaklık (°C), günlük maksimum, minimum sıcaklık farkı (°C), günlük ortalama nispi nem (%), günlük ortalama rüzgâr hızı (m/s), günlük toplam yağış (mm=kg/m²), günlük güneşlenme süresi (saat) ve günlük bulutluluk (8 okta) verileri Meteoroloji Genel Müdürlüğü'nden temin edilmiştir. Temin edilen veriler 17237 numaralı Denizli ölçüm istasyonuna aittir.

5.2.1 Doğal Gaz Kullanan Bağımsız Birim Sayısı

Doğal gaz aboneliğine başvuru yapan kullanıcıların bağlantı bedeli başvuru yapılan tüketim noktasının alanına göre hesap edilmektedir. Bu hesaplamada 200 m² ve daha düşük alana sahip tüketim noktası 1 bağımsız birim sayısı (BBS) olarak dikkate alınmaktadır. 200 m² alanın üzerinde olan bir tüketim noktasında her 100 m² alan ise artı 1 BBS olarak hesaplanmaktadır. Bu çalışmada, ısınma için alan bazlı olan BBS sayısının abone sayısına oranla doğal gaz tüketimini daha fazla etkileyeceği düşünülerek BBS sayısı dikkate alınmıştır. 2009-2020 yılları arasında gazı açılan tüketim noktalarının kümülatif BBS sayısı grafiği Şekil 5.2'de verilmiştir.




Şekil 5.2: 2009-2020 yılları arasında gazı açılan tüketim noktalarının kümülatif BBS sayısı grafiği.

Çalışmada kullanılan ve 2009 ile 2020 yılları arasındaki Denizli ili günlük adet cinsinden abone BBS sayılarına ait veri seti Enerya Denizli Gaz Dağıtım A.Ş.'den temin edilmiştir. İlgili BBS verisi kümülatif olarak günlük periyotta sözleşmesi ve gaz açım işlemi yapılmış aboneleri içermektedir. Sözleşme feshi yapılan ve gaz kesme işlemi yapılan tüketim noktaları ile bordrolu gaz açımı ve gaz açma işlemi yapılan tüketim noktaları hesaplamaya dahil edilmemiştir.

2009-2020 yılları arasındaki Şekil 5.1'deki günlük doğal gaz tüketimi ve Şekil 5.2'deki kümülatif abone BBS sayısındaki artış grafikleri incelendiğinde, doğal gaz tüketimi ile abone BBS sayısı arasında ilişki olduğu düşünülmektedir. Doğal gaz tüketimi ve BBS sayısı arasında gerçekleştirilen pearson korelasyon testinde 0,4026976 oranında orta şiddetli pozitif bir korelasyon gözlemlenmiştir. Korelasyon analizi Şekil 5.3'de, korelasyon grafiği Şekil 5.4'de verilmiştir.


```
Pearson's product-moment correlation
data: df$Tüketim and df$Kümülatif_BBS
t = 29.315, df = 4440, p-value < 2.2e-16
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
 0.3777624 0.4270491
sample estimates:
 cor
0.4026976
```

Şekil 5.3: Doğal gaz tüketimi ve BBS arasındaki korelasyon analizi.

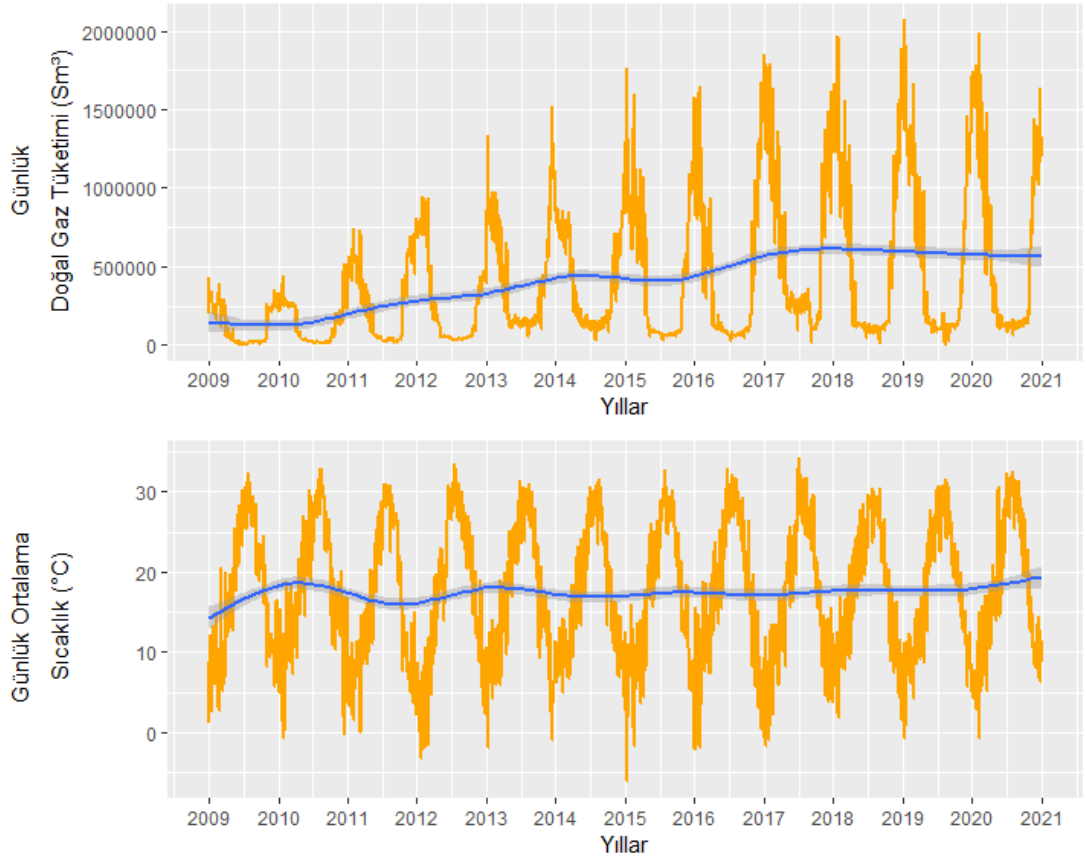


Şekil 5.4: Günlük doğal gaz tüketimi ve BBS arasındaki korelasyon grafiği.

5.2.2 Sıcaklık

Sezgisel olarak değerlendirildiğinde sıcaklığın doğal gaz tüketimi ile arasında ters orantılı bir ilişki olduğu düşünülmektedir. Bu düşünce doğrultusunda hava sıcaklığının düşmesi ısınma amaçlı kullanım sağlayan abonelerin doğal gaz tüketiminde artışa neden olacaktır. Hava sıcaklığının artması ise ısınma amaçlı kullanım sağlayan abonelerin doğal gaz tüketiminde azalmaya neden olacaktır.

Öngörülen bu etki veriler üzerinden analiz edildiğinde; günlük ortalama sıcaklığın zaman içerisindeki seyrinin dalgalı ancak genellikle orantılı bir seyir izlediği gözlemlenmiştir. Bununla birlikte günlük doğal gaz tüketimi ise günlük ortalama sıcaklığa göre ters orantılı bir seyir izlemiştir. Grafikler üzerinden yapılan analizde sıcaklığın dönemsel olarak normal seyrinin dışında aldığı değerlerin doğal gaz tüketimi üzerinde anlamlı ve ters orantılı bir etkisi olduğu gözlemlenmiştir. Çalışmada kullanılan günlük doğal gaz tüketimi ve günlük ortalama sıcaklığın zaman içerisindeki değişimine ait grafik Şekil 5.5’de verilmiştir.




Şekil 5.5: Günlük doğal gaz tüketimi ve günlük ortalama sıcaklığın zaman ile değişim grafiği.

Sezgisel ve grafikler üzerinden gerçekleştirilen sıcaklık ve doğal gaz tüketimi arasındaki ilişki gözlemlerinin istatistiksel olarak analiz edilmesi amacıyla çalışmada kullanılan günlük doğal gaz tüketimi ve günlük ortalama sıcaklık arasında gerçekleştirilen pearson korelasyon testinde, ilgili parametreler arasında $-0,7691568$ oranında yüksek şiddetli negatif bir korelasyon gözlemlenmiştir. Korelasyon analizi Şekil 5.6’da, korelasyon grafiği Şekil 5.7’de verilmiştir.

```
Pearson's product-moment correlation
data: df$Tüketim and df$Ortalama_sıcaklık
t = -80.198, df = 4440, p-value < 2.2e-16
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
 -0.7809017 -0.7568683
sample estimates:
 cor
-0.7691568
```

Şekil 5.6: Günlük doğal gaz tüketimi ve günlük ortalama sıcaklık arasındaki korelasyon analizi.




Şekil 5.7: Günlük doğal gaz tüketimi ve günlük ortalama sıcaklık arasındaki korelasyon grafiği.

5.2.3 Nem

Nem, havada bulunan su buharı olarak tanımlanmaktadır. Yer yüzündeki okyanuslardan, denizlerden, göllerden, akarsulardan buz ve toprak yüzeylerinden buharlaşan ve canlılardan terleme ile atmosfere geçen su tanecikleri havaya karışarak nemi oluşturmaktadır. Bağıl (Nispi) nem ise havadaki nemin, aynı sıcaklıkta havanın taşıyabileceği maksimum neme oranı olarak tanımlanmaktadır (Ankara Üniversitesi

2021). Soğuk havalarda havanın taşıyabileceği nem kapasitesi azalırken, sıcak havalarda bu kapasite artmaktadır. Nemin, hissedilen sıcaklık üzerinde doğrudan etkisi mevcuttur. Hissedilen sıcaklık termometrenin ölçtüğü sıcaklıktan farklı olarak insan vücudunun hissettiği sıcaklıktır. Havadaki nem oranı arttıkça vücuttan buharlaşma yavaşlamakta, terleme ile vücudun soğuma imkânı azalmaktadır. Bununla birlikte soğuk ve nemli havalarda ise havadaki su buharı hem kuru havaya göre daha fazla sıcaklık alması hem de deri üzerinde ıslanmaya neden olması nedeniyle daha fazla sıcaklık kaybına neden olmaktadır (Baloğlu 2001). Bu nedenle nemli havalarda hissedilen sıcaklık kuru havalara göre ölçülen sıcaklıktan fazla ya da az olmaktadır. Çalışmada kullanılan günlük doğal gaz tüketimi, günlük ortalama bağıl nem ve günlük ortalama sıcaklığın zaman içerisindeki değişimine ait grafik Şekil 5.8’de verilmiştir.




Şekil 5.8: Günlük doğal gaz tüketimi, günlük ortalama bağıl nem ve günlük ortalama sıcaklığın zaman içerisindeki değişim grafiği.

Günlük doğal gaz tüketimi ve günlük ortalama bağıl nem değerleri arasında gerçekleştirilen pearson korelasyon testinde, ilgili parametreler arasında 0,4889578 oranında orta şiddetli pozitif bir korelasyon gözlemlenmiştir. Çalışmada kullanılan günlük ortalama sıcaklık ile ters orantılı ilerleyen günlük ortalama bağıl nem, günlük

doğal gaz tüketimi ile doğru orantılı olarak seyretmiştir. Korelasyon analizi Şekil 5.9'da, korelasyon grafiği Şekil 5.10'de verilmiştir.

```
data: df$Tüketim and df$Nem
t = 37.105, df = 4382, p-value < 2.2e-16
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
 0.4661015 0.5111619
sample estimates:
      cor
0.4889578
```

Şekil 5.9: Günlük doğal gaz tüketimi ve günlük ortalama bağıl nem arasındaki korelasyon analizi.




Şekil 5.10: Günlük doğal gaz tüketimi ve günlük ortalama bağıl nem arasındaki korelasyon grafiği.

5.2.4 Rüzgâr Hızı

Çalışmada, doğal gaz tüketimi ve günlük ortalama rüzgâr hızı arasında gerçekleştirilen pearson korelasyon analizlerinde -0,05972853 oranında düşük şiddetli

negatif bir korelasyon gözlemlenmiştir. Günlük doğal gaz tüketimi ve günlük ortalama rüzgâr hızının zaman içerisindeki değişimini gösteren grafik Şekil 5.11’de verilmiştir.

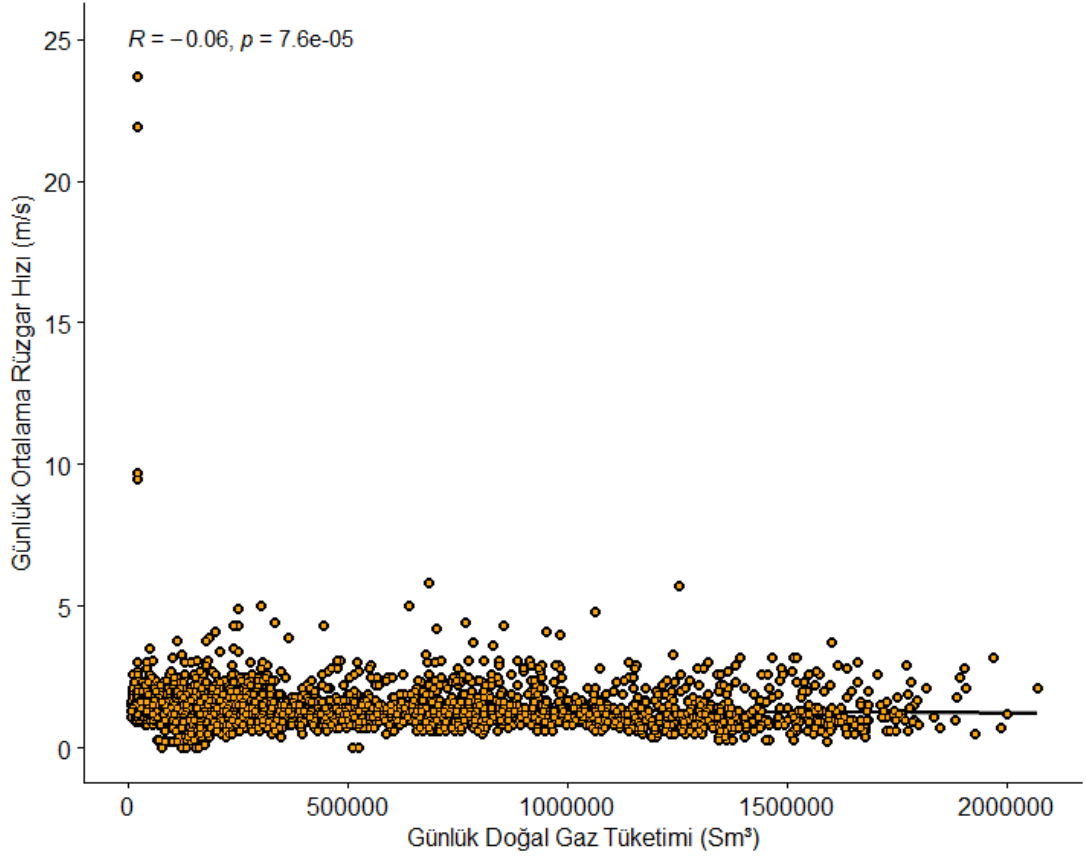


Şekil 5.11: Günlük doğal gaz tüketimi ve günlük ortalama rüzgâr hızının zaman içerisindeki değişim grafiği.

Rüzgâr hızının doğal tüketimi ile arasında anlamlı bir ilişki tespit edilmemiştir. Günlük doğal gaz tüketimi ve günlük ortalama rüzgâr hızı arasındaki korelasyon analizi Şekil 5.12’de, korelasyon grafiği Şekil 5.13’de verilmiştir.

```
Pearson's product-moment correlation  
  
data: df$Tüketim and df$Rüzgar  
t = -3.9609, df = 4382, p-value = 7.585e-05  
alternative hypothesis: true correlation is not equal to 0  
95 percent confidence interval:  
-0.08917378 -0.03017897  
sample estimates:  
cor  
-0.05972853
```


Şekil 5.12: Günlük doğal gaz tüketimi ve günlük ortalama rüzgâr hızı arasındaki korelasyon analizi.



Şekil 5.13: Günlük doğal gaz tüketimi ve günlük ortalama rüzgâr hızı arasındaki korelasyon grafiği.

5.2.5 Yağış

Çalışmada, doğal gaz tüketimi ve günlük toplam yağış miktarı arasında gerçekleştirilen pearson korelasyon analizlerinde 0,1092503 oranında düşük şiddetli pozitif bir korelasyon gözlemlenmiştir. Günlük doğal gaz tüketimi ve günlük toplam yağışın zaman içerisindeki değişimini gösteren grafik Şekil 5.14’de verilmiştir.



Şekil 5.14: Günlük doğal gaz tüketimi ve günlük toplam yağış miktarının zaman içerisindeki değişim grafiği.


Günlük doğal gaz tüketimi ve günlük toplam yağış miktarı arasındaki korelasyon analizi Şekil 5.15’de, korelasyon grafiği Şekil 5.16’de verilmiştir.

```

data: df$Tüketim and df$Yağış
t = 7.2756, df = 4382, p-value = 4.067e-13
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
 0.07990576 0.13840555
sample estimates:
      cor
0.1092503

```


Şekil 5.15: Günlük doğal gaz tüketimi ve günlük toplam yağış miktarı arasındaki korelasyon analizi.



Şekil 5.16: Günlük doğal gaz tüketimi ve günlük toplam yağış miktarı arasındaki korelasyon grafiği.

5.2.6 Güneşlenme Süresi

Çalışmada, doğal gaz tüketimi ve günlük ortalama güneşlenme süresi arasında gerçekleştirilen pearson korelasyon analizlerinde $-0,5177526$ oranında orta şiddetli negatif bir korelasyon gözlemlenmiştir. Günlük doğal gaz tüketimi ve günlük ortalama güneşlenme süresinin zaman içerisindeki değişimini gösteren grafik Şekil 5.17’de verilmiştir.



Şekil 5.17: Günlük doğal gaz tüketimi ve günlük ortalama güneşlenme süresinin zaman içerisindeki değişim grafiği.


Günlük doğal gaz tüketimi ve günlük ortalama güneşlenme süresi arasındaki korelasyon analizi Şekil 5.18’de, korelasyon grafiği Şekil 5.19’da verilmiştir.

```

data: df$Tüketim and df$Güneşlenme_suresi
t = -40.061, df = 4382, p-value < 2.2e-16
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
 -0.5390929 -0.4957480
sample estimates:
 cor
-0.5177526

```


Şekil 5.18: Günlük doğal gaz tüketimi ve günlük ortalama güneşlenme süresi arasındaki korelasyon analizi.



Şekil 5.19: Günlük doğal gaz tüketimi ve günlük ortalama güneşlenme süresi arasındaki korelasyon grafiği.

5.2.7 Bulutluluk

Çalışmada, doğal gaz tüketimi ve günlük ortalama bulutluluk arasında gerçekleştirilen pearson korelasyon analizlerinde 0,3266589 oranında düşük şiddetli pozitif bir korelasyon gözlemlenmiştir. Günlük doğal gaz tüketimi ve günlük ortalama bulutluluğun zaman içerisindeki değişimini gösteren grafik Şekil 5.20’de verilmiştir.



Şekil 5.20: Günlük doğal gaz tüketimi ve günlük ortalama bulutluluğun zaman içerisindeki değişim grafiği.


Günlük doğal gaz tüketimi ve günlük ortalama bulutluluk arasındaki korelasyon analizi Şekil 5.21’de, korelasyon grafiği Şekil 5.22’de verilmiştir.

```

data: df$Tüketim and df$Bulutluluk
t = 22.879, df = 4382, p-value < 2.2e-16
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
 0.2999566 0.3528497
sample estimates:
      cor
0.3266589

```

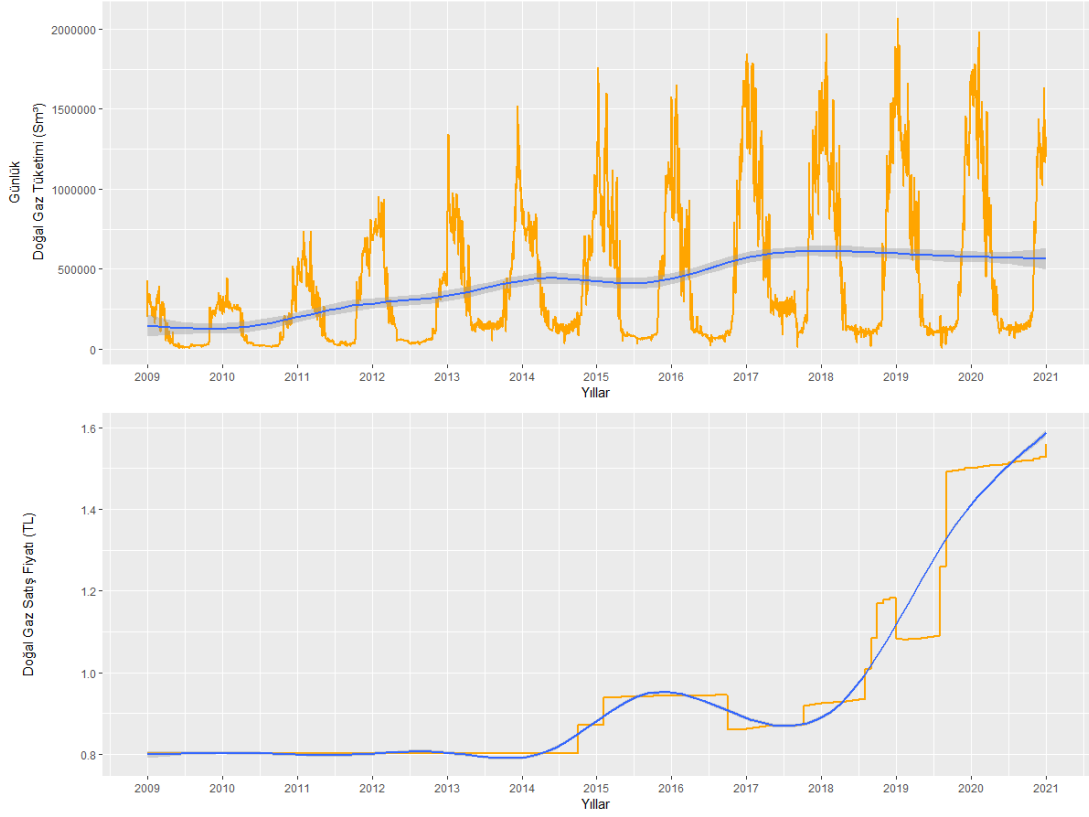
Şekil 5.21: Günlük doğal gaz tüketimi ve günlük ortalama bulutluluk arasındaki korelasyon analizi.



Şekil 5.22: Günlük doğal gaz tüketimi ve günlük ortalama bulutluluk arasındaki korelasyon grafiği.

5.2.8 Doğal Gaz Satış Fiyatı

Çalışmada, doğal gaz tüketimi ve doğal gaz satış fiyatı arasında gerçekleştirilen pearson korelasyon analizlerinde 0,236308 oranında düşük şiddetli pozitif bir korelasyon gözlemlenmiştir. Günlük doğal gaz tüketimi ile Enerya Denizli Gaz Dağıtım A.Ş. resmi internet sitesinde yayınlanan doğal gaz satış fiyatlarının zaman içerisindeki değişimine ait grafik Şekil 5.23’de verilmiştir.



Şekil 5.23: Günlük doğal gaz tüketimi ve doğal gaz satış fiyatlarının zaman içerisindeki değişim grafiği.


Günlük doğal gaz tüketimi ve doğal gaz satış fiyatları arasındaki korelasyon analizi Şekil 5.24’de, korelasyon grafiği Şekil 5.25’de verilmiştir.

```

data: df$Tüketim and df$Fiyat
t = 16.099, df = 4382, p-value < 2.2e-16
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
 0.2081613 0.2640637
sample estimates:
      cor
0.236308

```

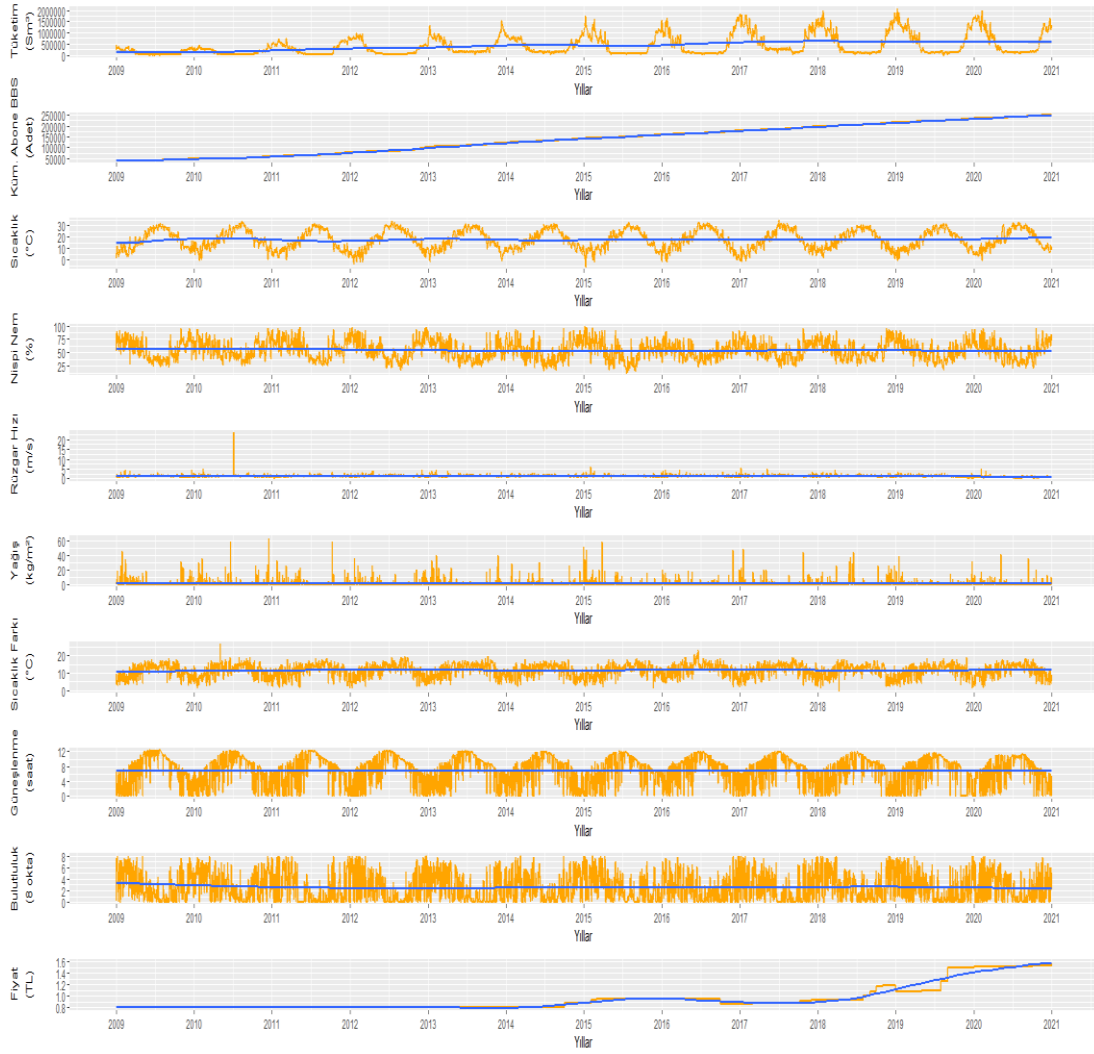
Şekil 5.24: Günlük doğal gaz tüketimi ve doğal gaz satış fiyatı arasındaki korelasyon analizi.



Şekil 5.25: Günlük doğal gaz tüketimi ve doğal gaz satış fiyatı arasındaki korelasyon grafiği.

5.3 Tüketim, Doğal Gaz Kullanan Bağımsız Birim Sayısı, Meteorolojik Parametreler ve Doğal Gaz Satış Fiyatı Karşılaştırılması

Doğal gaz tüketimi, doğal gaz kullanan bağımsız birim sayısı, bu çalışmada kullanılan meteorolojik parametreler ve doğal gaz satış fiyatı karşılaştırıldığında doğal gaz tüketimindeki hacimsel artışın doğal gaz kullanan bağımsız birim sayısındaki artış olduğu ve doğal gaz tüketiminin dönemsel artışına ağırlıklı olarak sıcaklık değişiminin ve nem miktarının neden olduğu gözlemlenmiştir. Diğer meteorolojik parametrelerin ve doğal gaz satış fiyatının ise doğal gaz tüketimi ile aralarında anlamlı bir ilişki gözlemlenmemiştir. Günlük doğal gaz tüketimi, doğal gaz kullanan bağımsız birim sayısı, ortalama sıcaklık, nem, rüzgar hızı, yağış miktarı, güneşlenme süresi, bulutluluk ve doğal gaz satış fiyatının zaman ile değişim grafiği Şekil 5.26'da verilmiştir.



Şekil 5.26: Günlük doğal gaz tüketimi, gazı açılan bağımsız birim sayısı, ortalama sıcaklık, nem, rüzgar hızı, yağış miktarı, güneşlenme süresi, bulutluluk ve doğal gaz satış fiyatının zaman ile değişim grafiği.

5.4 Çok Katmanlı Algılayıcı (MLP) Yapay Sinir Ağı, Uzun Kısa Süreli Bellek (LSTM) Yapay Sinir Ağı, İki Yönlü Uzun Kısa Süreli Bellek (BILSTM) Yapay Sinir Ağı, Rassal Orman ve Çok Değişkenli Doğrusal Regresyon Yöntemlerinin Tahmin İçin Uygulanması

Çalışmada öncelikli olarak veri analizi gerçekleştirilmiş, veri analizleri R Studio uygulaması kullanılmıştır. Kodlar R dilinde yazılmış, çalışmada ggplot2, gpubr, DMwR2, GGally, tidyverse kütüphaneleri kullanılmıştır. Gerçekleştirilen veri analizinde boş değer ve aykırı gözlemler kontrol edilmiştir. Analiz sonuçlarına göre veri setinde herhangi bir boş değer gözlemlenmemiştir. Aykırı gözlemler kontrol

edilmiş ve hata gözlemlenmemiştir. Bu doğrultuda aykırı gözlemlerin yaklaşım metotları uygulanarak değiştirilmesi gibi bir işlem gerçekleştirilmeden tüm veriler olduğu gibi kullanılmıştır. Bununla birlikte çalışmada korelasyon analizi gerçekleştirilmiş, parametreler arasındaki anlamlı ilişkiler istatistiksel olarak incelenmiştir. Ancak herhangi bir parametre tahmin çalışmasından çıkartılmamıştır.

Veri analizi sonrası tahmin işlemi için JupyterLab uygulaması kullanılmıştır. Kodlar python dilinde yazılmış, çalışmada numpy, pandas, matplotlib, random, tensorflow, keras, keras_tuner ve sklearn kütüphaneleri kullanılmıştır. Bu kapsamda verilerin okuma işlemi gerçekleştirildikten sonra tarihe göre küçükten büyüğe olacak şekilde sıralanmıştır. Sıralama işlemi sonrası eğitim ve test verileri tespit edilmiştir. 2009 ile 2019 yılları arasındaki veriler eğitim, 2020 yılındaki veriler ise test verisi olarak belirlenmiştir. Eğitim ve test verisi belirleme işlemi sonrası minimum maksimum ölçeklendirme (MinMaxScaler) yöntemi kullanılarak veriler ölçeklenmiş ve tahmin sonunda ters dönüşüm işlemi için ölçekleme yapısı kayıt altına alınmıştır. Minimum maksimum ölçeklendirme yönteminde veri, ilgili veri setindeki minimum değerden çıkartılarak, yine ilgili veri setindeki maksimum değer ile minimum değer farkına bölünerek ölçeklendirilir. Minimum maksimum ölçeklendirme yönteminin matematiksel ifadesi aşağıda (5.1) eşitliği ile verilmiştir.

$$x' = \frac{x - \min(X)}{\max(X) - \min(X)} \quad (5.1)$$

Verinin ön hazırlık işlemleri sonrası çok katmanlı algılayıcı (MLP), uzun kısa süreli bellek (LSTM), iki yönlü uzun kısa süreli bellek (BILSTM) yapay sinir ağı, rassal orman ve çok değişkenli doğrusal regresyon modelleri oluşturulmuştur. Oluşturulan modellerle ilgili detaylar konunun devamında ilgili model başlığının içerisinde verilecektir. Yapay sinir ağı modellerinde öğrenme katsayısı, katman sayısı ve nöron sayısı değerleri kullanıcı tarafından belirlendiği için hiperparametre optimizasyonu random_search yöntemi kullanılarak dinamik bir yapı oluşturulmuştur. Bu doğrultuda yapay sinir ağı modelleri, birinci aşamada 500, ikinci aşamada 300 kez ve her turda 100 eğitim adımı gerçekleştirecek şekilde yapılandırılmıştır.

Tüm yapay sinir ağı modellerinde öğrenme katsayısı rassal olarak 1×10^{-3} , 1×10^{-4} , 1×10^{-5} ve 1×10^{-6} seçeneklerinden biri olacak şekilde, katman

sayısı ise 1 ile 5 değerleri arasında rassal değerler olacak şekilde yapılandırılmıştır. İşlem gören parça boyutu (batch size) ise 64 olarak kullanılmıştır.

Tüm yapay sinir ağı modellerinde birinci aşamada uygun aktivasyon fonksiyonu ve optimize edici analizi için rassal olacak şekilde Relu, Sigmoid, Softplus, Softsign, Tanh, Selu, Elu aktivasyon fonksiyonları ve SGD, Adam, RMSprop, Adadelta, Adagrad, Adamax, Nadam iyileştirme algoritmaları kullanılmıştır. İkinci aşamada ise tüm yapay sinir ağı modelleri için en iyi sonuç elde edilen aktivasyon fonksiyonları ve iyileştirme algoritmaları için yine rassal olacak şekilde aynı katman aralığı, öğrenme katsayısı, paket boyutu, tekrar sayısı ve eğitim adımı yapısında tekrar çalıştırılmıştır. Tüm yapay sinir ağı modellerinde son katman 1 nöron ve aktivasyon fonksiyonu sigmoid olacak şekilde yapılandırılmıştır.

Birinci ve ikinci aşama sonuçları ile ilgili detaylar devam eden bölümlerdeki ilgili yapay sinir ağı modeline ait konu başlığı altında verilmiştir.

Tüm yapay sinir ağı modellerinde hata hesaplaması olarak ortalama hata kare (MSE) kullanılmıştır. Ortalama hata kare (MSE), gerçek değer ile öngörülen değer arasındaki farkın kareleri toplamı olarak hesaplanır (Yolsal 2022). Ortalama hata karenin matematiksel ifadesi aşağıda (5.2) eşitliği ile verilmiştir.

$$\text{Ortlama Hata Kare (MSE)} = \frac{\sum_{i=1}^k (Y_i - F_i)^2}{k} = \frac{\sum_{i=1}^k e_i^2}{k} \quad (5.2)$$

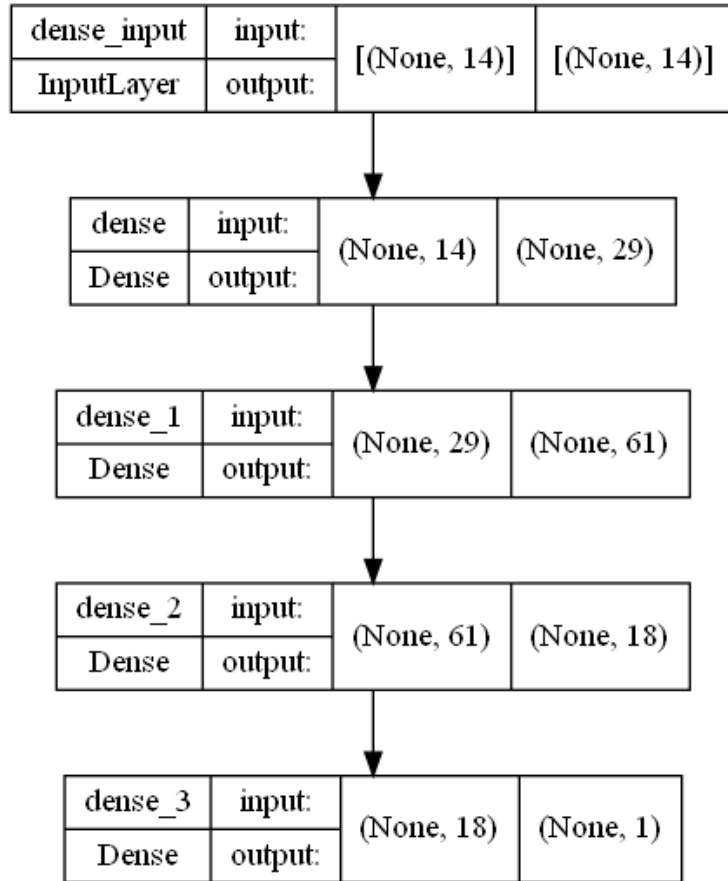
Denklemden, Y_i gerçek değeri, F_i ön görülen değeri, k ise öngörülen dönem sayısını ifade etmektedir. Ortalama hata karenin minimum olması istenir.

Tüm modellerin sonuçlarının karşılaştırılması için ortalama mutlak yüzde hata (MAPE) hesabı kullanılmıştır. Ortalama mutlak yüzde hata (MAPE), yüzde hataların mutlak değerlerinin toplamı olarak hesaplanır (Yolsal 2022). Ortalama mutlak yüzde hatanın matematiksel ifadesi aşağıda (5.3) eşitliği ile verilmiştir.


$$\text{Ortlama Mutlak Yüzde Hata (MAPE)} = \frac{\sum_{i=1}^k \left| \frac{Y_i - F_i}{Y_i} \right| \times 100}{k} \quad (5.3)$$

5.4.1 Çok Katmanlı Algılayıcı (MLP) Yapay Sinir Ağı Uygulaması

Çalışmada, birinci aşamada elde edilen sonuçlar doğrultusunda mevcut parametrelerle gerçekleştirilen rassal denemelerde 0,002684829 mse değeriyle öğrenme katsayısı 1×10^{-3} , iyileştirme algoritması RMSProp, aktivasyon fonksiyonu Relu, katman sayısı 3, birinci katmandaki nöron sayısı 29, ikinci katmandaki nöron sayısı 61, üçüncü katmandaki nöron sayısı 18 olan modelin en iyi model olduğu gözlemlenmiştir. İlgili modelde MAPE değeri 0,308 olarak elde edilmiştir. Birinci aşamada elde edilen en iyi sonuca ait model Şekil 5.27’de, tahmin performansına ait grafik Şekil 5.28’de verilmiştir.



Şekil 5.27: Çok katmanlı algılayıcı birinci aşama en iyi model gösterimi.



Şekil 5.28: Çok katmanlı algılayıcı birinci aşama tahmin performansı grafiği.

İkinci aşamada ise, birinci aşamada en iyi mse değerini veren modelin aktivasyon fonksiyonu olan Relu ve iyileştirme algoritması olan RMSProp kullanılarak 300 deneme ile model tekrar çalıştırılmıştır.

RMSPROP: Rmsprop, uyarlanabilir bir öğrenme yöntemidir. Geoff Hinton tarafından önerilmiştir. Öğrenme hızını üssel olarak azalan kare gradyanlarının ortalamasına bölen bir yapıya sahiptir (Genç Kavas 2019). Rmsprop yönteminin matematiksel ifadesi aşağıda (5.6) eşitliği ile verilmiştir.

$$\vartheta_t = \rho\vartheta_{t-1} + (1 - \rho) * g_t^2 \quad (5.4)$$

$$\Delta\omega_t = -\frac{\eta}{\sqrt{\vartheta_t + \epsilon}} * g_t \quad (5.5)$$

$$\omega_{t+1} = \omega_t + \Delta\omega_t \quad (5.6)$$


η : Öğrenme katsayısı

ϑ_t : Gradyan karelerinin üstel ortalaması

g_t : ω^i boyunca t anındaki gradyan

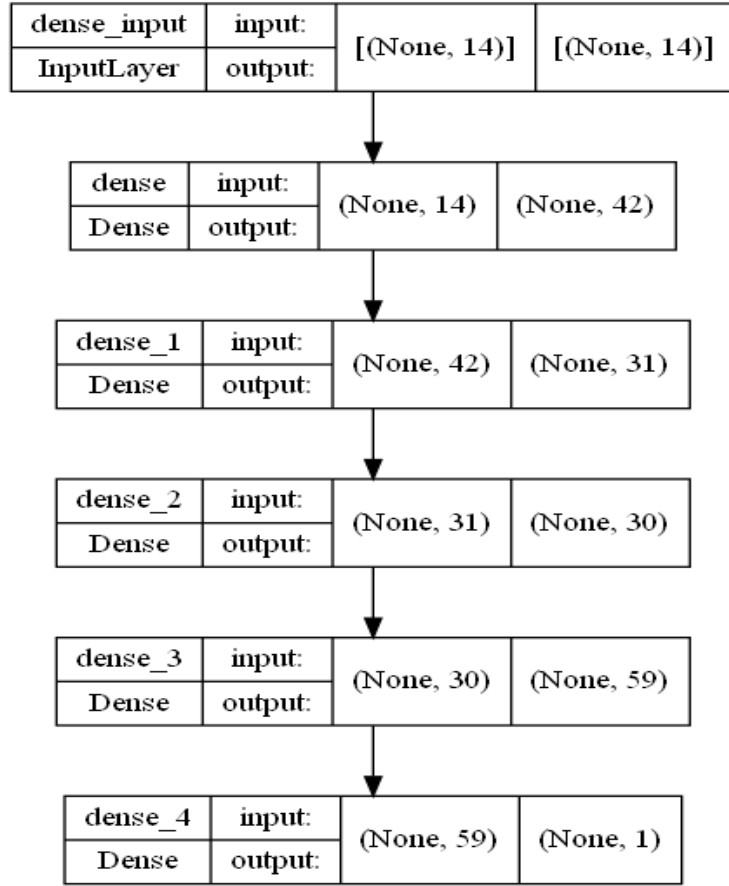
RELU (Rectified Linear Unit): ReLU aktivasyon fonksiyonu girdi değeri sıfırın altında olan durumlarda çıkış değerini sıfır olarak üretmektedir. Ancak girdi değeri sıfır veya daha büyük bir değer ise çıkış değeri üretir (Cengiz 2020). ReLU aktivasyon fonksiyonunun grafik gösterimi Şekil 5.29'da, matematiksel gösterimi aşağıda (5.7) eşitliği ile verilmiştir.

$$F(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (5.7)$$




Şekil 5.29: ReLU aktivasyon fonksiyonunun grafik gösterimi.

Çalışmada, ikinci aşamada elde edilen sonuçlar doğrultusunda mevcut parametrelerle gerçekleştirilen rassal denemelerde 0,002054172 mse değeriyle öğrenme katsayısı 1×10^{-6} , katman sayısı 4, birinci katmandaki nöron sayısı 42, ikinci katmandaki nöron sayısı 31, üçüncü katmandaki nöron sayısı 30, dördüncü katmandaki nöron sayısı 59 olan modelin en iyi model olduğu gözlemlenmiştir. İlgili modelde MAPE değeri 0,216 olarak elde edilmiştir. İkinci aşamada elde edilen en iyi sonuca ait model Şekil 5.30'da, tahmin performansına ait grafik Şekil 5.31'de verilmiştir.



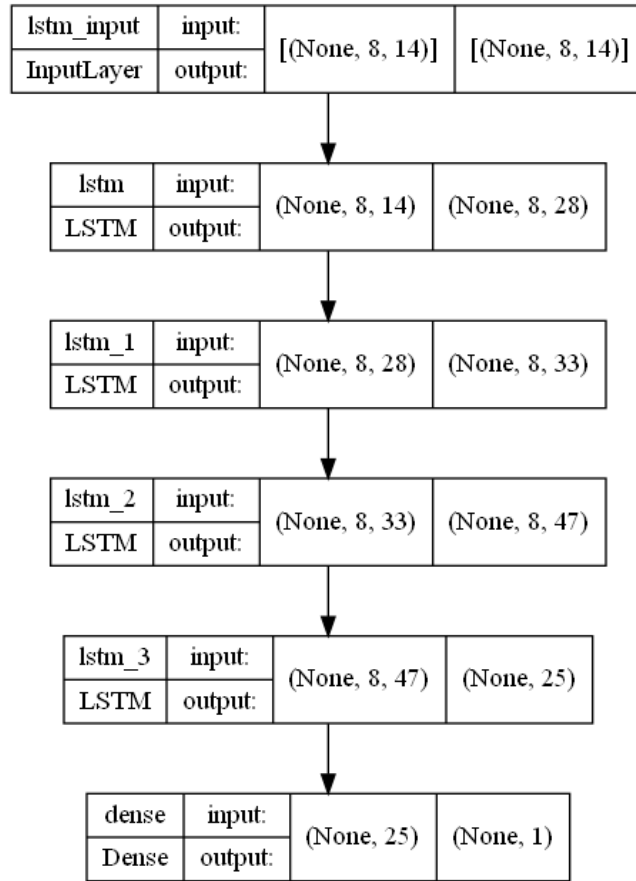
Şekil 5.30: Çok katmanlı algılayıcı ikinci aşama en iyi model gösterimi.




Şekil 5.31: Çok katmanlı algılayıcı ikinci aşama tahmin performansı grafiği.

5.4.2 Uzun Kısa Süreli Bellek (LSTM) Yapay Sinir Ağı Uygulaması

Çalışmada, birinci aşamada elde edilen sonuçlar doğrultusunda mevcut parametrelerle gerçekleştirilen rassal denemelerde 0,001035695 mse değeriyle öğrenme katsayısı 1×10^{-3} , iyileştirme algoritması Adam, aktivasyon fonksiyonu Tanh, katman sayısı 4, birinci katmandaki nöron sayısı 28, ikinci katmandaki nöron sayısı 33, üçüncü katmandaki nöron sayısı 47, dördüncü katmandaki nöron sayısı 25 olan modelin en iyi model olduğu gözlemlenmiştir. İlgili modelde MAPE değeri 0,112 olarak elde edilmiştir. Birinci aşamada elde edilen en iyi sonuca ait model Şekil 5.32’de tahmin performansına ait grafik Şekil 5.33’de verilmiştir.



Şekil 5.32: Uzun kısa süreli bellek birinci aşama en iyi model gösterimi.



Şekil 5.33: Uzun kısa süreli bellek birinci aşama tahmin performansı grafiği.

İkinci aşamada ise, birinci aşamada en iyi mse değerini veren modelin aktivasyon fonksiyonu olan Tanh ve iyileştirme algoritması olan Adam kullanılarak 300 deneme ile model tekrar çalıştırılmıştır.

ADAM (Adaptive Moment Estimation): ADAM iyileştirme yöntemi, düşük dereceli momentlerin uyarlanabilir tahminlerine dayalı, stokastik amaç fonksiyonlarının birinci dereceden gradyan tabanlı bir algoritmadır (Kingma ve Ba 2015). Adadelta ve RMSProp yöntemlerindeki önceki gradientlerin karelerinin hesaplanmasına ek olarak geçmiş gradientleri karesel olmadan hesaplayacak şekilde, RMSProp ve Adagrad yöntemlerin avantajlarını kapsayacak şekilde geliştirilmiştir. ADAM yönteminin matematiksel ifadesi aşağıda (5.12) eşitliği ile verilmiştir (Yazan ve Talu 2017).

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (5.8)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (5.9)$$


$$\hat{m} = \frac{m_t}{1 - \beta_1^t} \quad (5.10)$$

$$\hat{v} = \frac{v_t}{1 - \beta_2^t} \quad (5.11)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \quad (5.12)$$

TANH: Tanh aktivasyon fonksiyonu -1 ile 1 arasında çıkış değeri üretir. x değerlerine göre -1 ya da 1'e yakınsama gerçekleşir. Türevi Sigmoid fonksiyonuna göre daha diktir. Bu durum daha fazla değer alarak, hızlı öğrenme sınıflandırma işlemi yapabilirlik açısından avantaj sağlamaktadır (Cengiz 2020). Tanh aktivasyon fonksiyonunun grafik gösterimi Şekil 5.34'de, matematiksel gösterimi aşağıda (5.13) eşitliği ile verilmiştir.

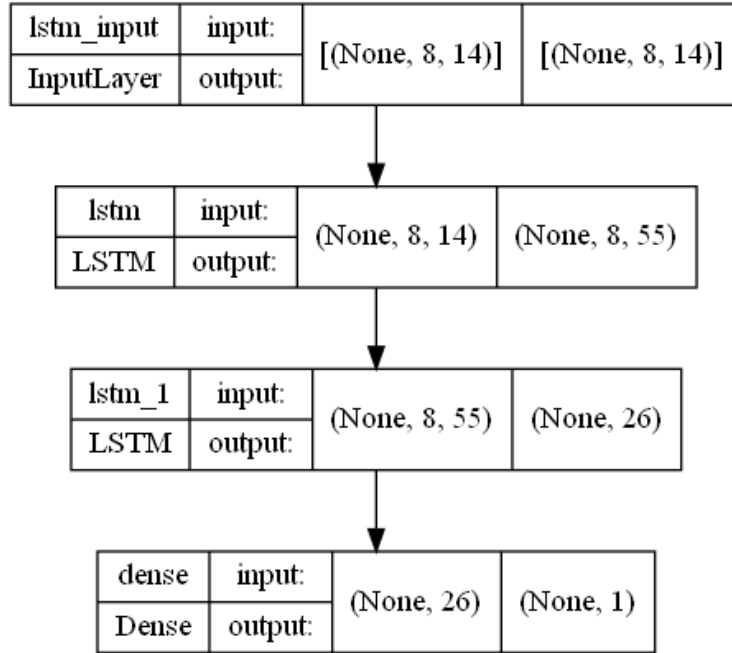
$$F(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5.13)$$




Şekil 5.34: Tanh aktivasyon fonksiyonunun grafik gösterimi.

Çalışmada, ikinci aşamada elde edilen sonuçlar doğrultusunda mevcut parametrelerle gerçekleştirilen rassal denemelerde 0,000920396 mse değeriyle öğrenme katsayısı 1×10^{-5} , katman sayısı 2, birinci katmandaki nöron sayısı 55, ikinci katmandaki nöron sayısı 26 olan modelin en iyi model olduğu gözlemlenmiştir. İlgili modelde MAPE değeri 0,136 olarak elde edilmiştir. İkinci aşamada elde edilen

en iyi sonuca ait model Şekil 5.35’de tahmin performansına ait grafik Şekil 5.36’da verilmiştir.



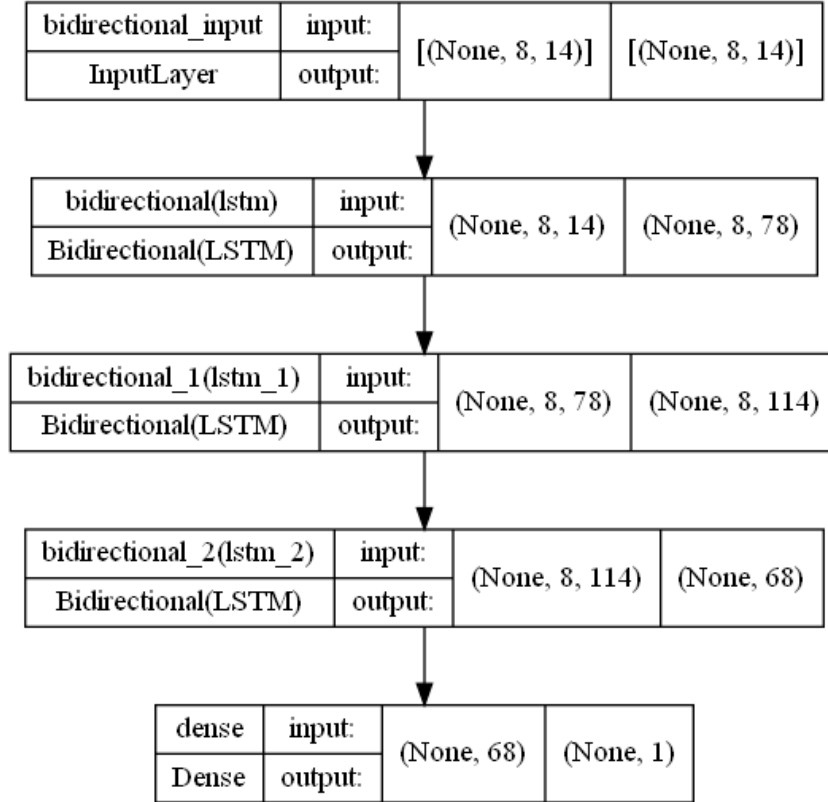
Şekil 5.35: Uzun kısa süreli bellek ikinci aşama en iyi model gösterimi.




Şekil 5.36: Uzun kısa süreli bellek ikinci aşama tahmin performansı grafiği.

5.4.3 İki Yönlü Uzun Kısa Süreli Bellek (BILSTM) Yapay Sinir Ağı Uygulaması

Çalışmada, birinci aşamada elde edilen sonuçlar doğrultusunda mevcut parametrelerle gerçekleştirilen rassal denemelerde 0,0008146 mse değeriyle öğrenme katsayısı 1×10^{-6} , iyileştirme algoritması Adam, aktivasyon fonksiyonu Relu, katman sayısı 3, birinci katmandaki nöron sayısı 39, ikinci katmandaki nöron sayısı 57, üçüncü katmandaki nöron sayısı 34 olan modelin en iyi model olduğu gözlemlenmiştir. İlgili modelde MAPE değeri 0,104 olarak elde edilmiştir. Birinci aşamada elde edilen en iyi sonuca ait model Şekil 5.37’de tahmin performansına ait grafik Şekil 5.38’de verilmiştir.



Şekil 5.37: İki yönlü uzun kısa süreli bellek birinci aşama en iyi model gösterimi.

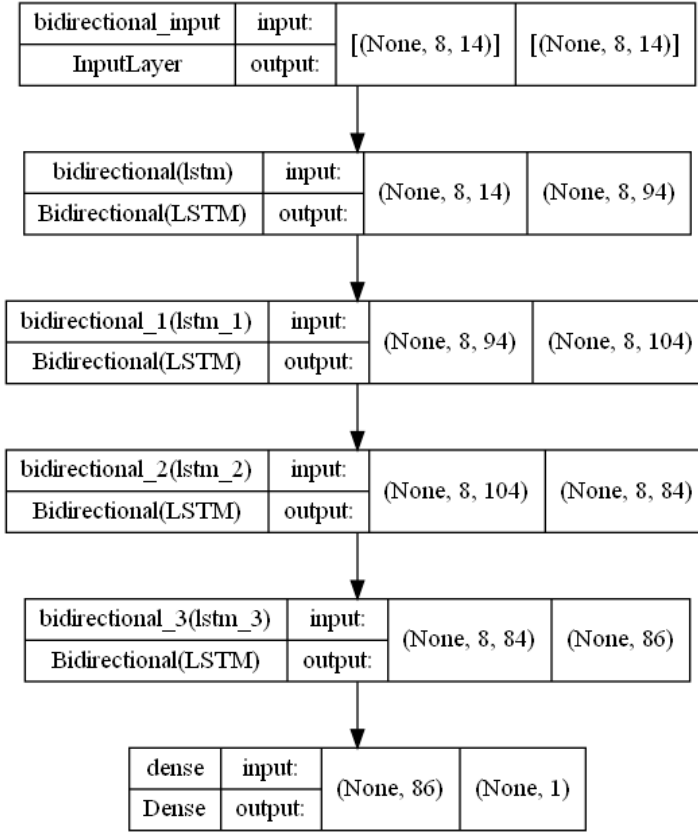


Şekil 5.38: İki yönlü uzun kısa süreli bellek birinci aşama tahmin performansı grafiği.


İkinci aşamada ise, birinci aşamada en iyi mse değerini veren modelin aktivasyon fonksiyonu olan Relu ve iyileştirme algoritması olan Adam kullanılarak 300 deneme ile model tekrar çalıştırılmıştır.

Adam iyileştirme algoritmasına ait detaylar bölüm 5.4.2’de, Relu aktivasyon fonksiyonuna ait detaylar bölüm 5.4.1’de verilmiştir.

Çalışmada, ikinci aşamada elde edilen sonuçlar doğrultusunda mevcut parametrelerle gerçekleştirilen rassal denemelerde 0,000739445 mse değeriyle öğrenme katsayısı 1×10^{-6} , katman sayısı 4, birinci katmandaki nöron sayısı 47, ikinci katmandaki nöron sayısı 52, üçüncü katmandaki nöron sayısı 42, dördüncü katmandaki nöron sayısı 43 olan modelin en iyi model olduğu gözlemlenmiştir. İlgili modelde MAPE değeri 0,107 olarak elde edilmiştir. İkinci aşamada elde edilen en iyi sonuca ait model Şekil 5.39’da tahmin performansına ait grafik Şekil 5.40’da verilmiştir.



Şekil 5.39: İki yönlü uzun kısa süreli bellek ikinci aşama en iyi model gösterimi.



Şekil 5.40: İki yönlü uzun kısa süreli bellek ikinci aşama tahmin performansı grafiği.

5.4.4 Rassal Orman (Random Forest) Uygulaması

Rassal Orman (Random Forest): Rassal orman yönteminde öğrenme eğitici olarak gerçekleştirilmektedir. Aynı türeden olan çoklu karar ağaçlarını bir araya getirilerek bir karar ağacı ormanı oluşturulması ile topluluk öğrenmesi esasına dayanmaktadır (Aktaş 2019).

Karar ağaçları kök, düğüm ve yapraklardan oluşan yapılardır. Entropinin en aza indirgenmesi amaçlanmaktadır. Bununla birlikte karar ağaçları aşırı uyum (over fitting) eğilimine sahiptir (Koçyiğit 2021).

Rassal orman yöntemini karar ağaçları yönteminden ayıran en temel özellik, aşırı uyumu engellemek amacıyla kök ve alt düğümlerde seçimlerin rasgele yapılmasıdır. Karar verilirken ya da tahminde bulunulurken karar ağaçlarından elde edilen en fazla oy temel alınmaktadır. İlgili yöntem hem sınıflandırma hem de regresyon problemleri için kullanılmaktadır. Yöntemin avantaj ve dezavantajları aşağıdaki gibidir (Aktaş 2019).

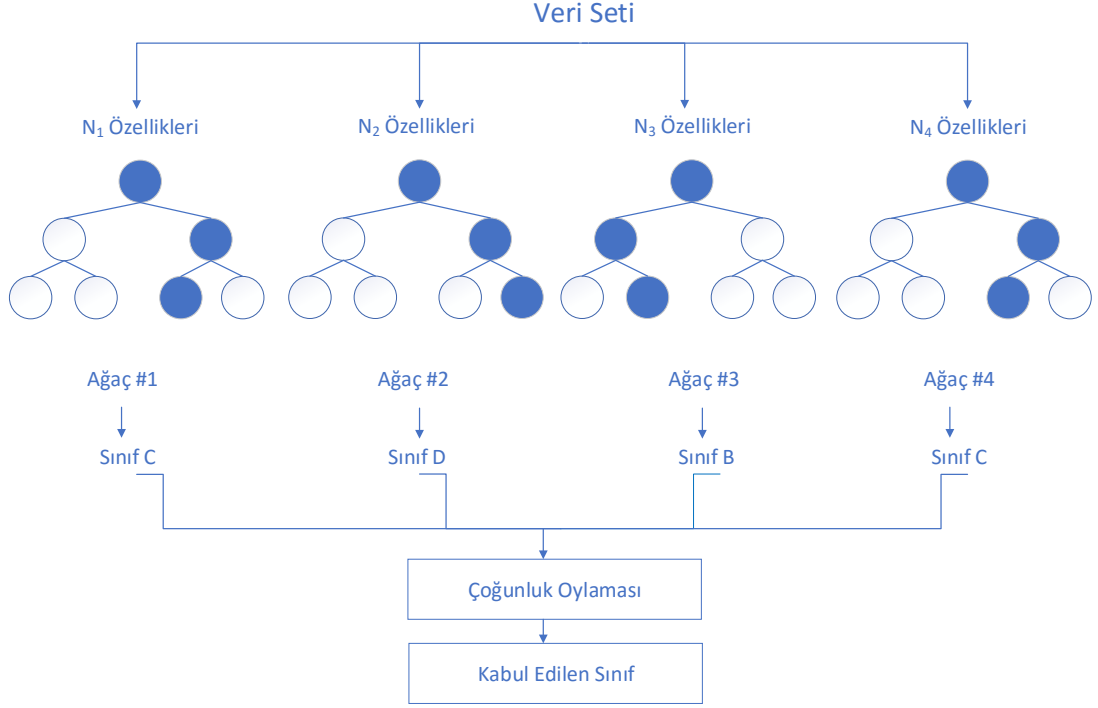
Avantajlar:

- Veri setinde kayıp ya da ölçeklendirilmemiş değerler bulunması durumunda da başarılı sonuçlar üretmektedir.
- Hem kategorik hem de sayısal yapıdaki verilerde iyi çalışmaktadır.

Dezavantajlar:

- Karmaşık bir yapıya sahiptir. Modeli yorumlamak zordur.
- Birden fazla karar ağacı sonucuna göre sonuç üretildiği için, bazı diğer yöntemlere göre yavaştır.

Rassal orman yöntemine ait örnek model Şekil 5.41'de verilmiştir.



Çalışmada kullanılan parametreler Şekil 5.42’de verilmiştir.

```

from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import GridSearchCV

param_grid = {
    'bootstrap': [True],
    'max_depth': [3, 5, 8, 10, 15, 20],
    'min_samples_leaf': [3, 4, 5, 6],
    'min_samples_split': [8, 10, 12, 14],
    'n_estimators': [50, 100, 150, 200]
}

rf = RandomForestRegressor()
grid_search = GridSearchCV(estimator = rf, param_grid = param_grid,
                           cv = 3, n_jobs = -1, verbose = 2)

%%time
grid_search.fit(x_train, y_train)

```

Fitting 3 folds for each of 384 candidates, totalling 1152 fits
Wall time: 4min 11s

```

GridSearchCV(cv=3, estimator=RandomForestRegressor(), n_jobs=-1,
             param_grid={'bootstrap': [True],
                          'max_depth': [3, 5, 8, 10, 15, 20],
                          'min_samples_leaf': [3, 4, 5, 6],
                          'min_samples_split': [8, 10, 12, 14],
                          'n_estimators': [50, 100, 150, 200]},
             verbose=2)

```

Şekil 5.42: Çalışmada kullanılan parametreler.

bootstrap: Ağaç oluştururken örneklerin kullanılıp kullanılmayacağına karar verilir.

max_depth: Ağacın maksimum derinliğini ifade eder.

min_samples_leaf: Bir düğümde olması gereken minimum örnek sayısını ifade eder.

min_samples_split: Bir düğümü bölmek için gerekli minimum örnek sayısını ifade eder.

n_estimators: Ormandaki ağaç sayısını ifade eder.


cv: Çapraz doğrulama için bölme stratejisini belirler.

n_jobs: Paralel olarak çalıştırılacak iş sayısını belirler. -1 değeri tüm işlemcilerin çalıştırılacağını ifade eder.

verbose: Ayrıntıyı kontrol eder. Ne kadar yüksek değer alırsa o kadar fazla mesaj üretilir.

İlgili modelde tahmin sonucuna ait MAPE değeri 0,170 olarak elde edilmiştir.

Tahmin performansına ait grafik 5.43'de verilmiştir.




Şekil 5.43: Rassal orman tahmin performansı grafiği.

5.4.5 Çok Değişkenli Doğrusal Regresyon Uygulaması

Regresyonla ilgili tanımlar Bölüm 3.3.1'de verilmiştir. Çalışmada Python sklearn kütüphanesinde linear_model-LinearRegression kullanılmıştır. İlgili modelde

tahmin sonucuna ait MAPE değeri 0,616 olarak elde edilmiştir. Tahmin performansına ait grafik 5.44’de verilmiştir.




Şekil 5.44: Çok değişkenli doğrusal regresyon tahmin performansı grafiği.

5.5 Tahmin Sonuçlarının Karşılaştırılması

Çalışmada yapay sinir ağı modellerinin ikinci aşamada elde edilen sonuçları ile rassal orman ve çoklu lineer regresyon sonuçları karşılaştırılmış ve mevcut modellere göre en iyi model tahmin sıralamasının iki yönlü uzun kısa süreli bellek (BILSTM), uzun kısa süreli bellek (LSTM), rassal orman (Random Forest), çok katmanlı algılayıcı (MLP) ve çok değişkenli doğrusal regresyon olduğu gözlemlenmiştir. İlgili yöntemlerin MAPE değerleri karşılaştırması Tablo 5.1’de, tahmin performans grafiği Şekil 5.45’de verilmiştir.

Tablo 5.1: Tahmin ve gerek tüketim verisinin hesaplanan MAPE deęerleri.

Tahmin Yöntemi	MAPE Deęeri
İki Yönlü Uzun Kısa Süreli Bellek	0,107
Uzun Kısa Süreli Bellek	0,136
Rassal Orman	0,170
Çok Katmanlı Algılayıcı	0,216
Lineer Regresyon	0,616



Şekil 5.45: Tahmin yöntemleri performans grafięi.

6. SONUÇ VE ÖNERİLER

Enerji, temel olarak canlı yaşamı için kritik bir öneme sahiptir. Bununla birlikte bilim, teknoloji ve endüstrideki gelişmeler ile elde edilen sonuçlar enerjiye olan ihtiyacın ve talebin önemli oranda artmasına neden olmaktadır. Bu durumda ülkeleri öncelikli olarak stratejik ve ekonomik açıdan önemli düzeyde etkilemektedir.

Enerji kaynakları arasında yenilenebilir enerjinin payı gün geçtikçe artmakla birlikte genel olarak enerji talebinin büyük bir kısmı fosil kaynaklar ile karşılanmaktadır. Fosil kaynaklar arasında kömüre olan talep azalma eğilimi gösterirken, gerçekleştirilen şebeke yatırımları ile ulaşılan kullanıcı sayısındaki artış nedeniyle doğal gaza olan talep artmaktadır. Bu durum doğal gazın günümüzde yaklaşık %99'unu yurtdışından ithal eden Türkiye gibi doğal gazda büyük oranda dışa bağımlı ülkelerin ekonomileri için önemli bir yer teşkil etmektedir. Bu nedenle doğal gaz tüketiminin en iyi seviyede tahmin edilmesi ülkeler için önem arz etmektedir.

Bu çalışmada, Denizli ilindeki konutların doğal gaz tüketimlerinin analizi ve tahmini gerçekleştirilmiştir. Analiz ve tahmin işlemlerinde doğal gaz tüketimi üzerinde etkisi olabileceği düşünülen abone bağımsız birim sayısı (BBS), doğal gaz satış fiyatı, ortalama sıcaklık (°C), günlük maksimum, minimum sıcaklık farkı (°C), günlük ortalama nispi nem (%), günlük ortalama rüzgâr hızı (m/s), günlük toplam yağış (mm=kg/m²), günlük güneşlenme süresi (saat) ve günlük bulutluluk (8 okta) verileri kullanılmıştır. Abone bağımsız birim sayısı, doğal gaz satış fiyatı ve tüketim verileri Enerya Denizli Gaz Dağıtım A.Ş.'den, meteorolojik veriler Meteoroloji Genel Müdürlüğü'nden temin edilmiştir.

Çalışmada kullanılan verilerle gerçekleştirilen pearson korelasyon analizlerinde sıcaklık parametresi ile tüketim arasında çalışmada tahmin için kullanılan diğer parametrelere göre daha fazla korelasyon olduğu gözlemlenmiştir. BBS, nem ve güneşlenme süresi ile tüketim arasında orta, rüzgar hızı, bulutluluk, yağış ve doğal gaz satış fiyatı ile tüketim arasında düşük şiddette bir korelasyon olduğu gözlemlenmiştir. Analizler R Studio uygulamasında ggplot2, ggpubr, DMwR2, GGally, tidyverse kütüphaneleri kullanılarak yazılan kodlar ile gerçekleştirilmiştir.

Çalışmada tahmin aşamasında verilerin 2009-2019 yılları arasındaki 10 yıllık kısmı eğitim, 2020-2021 yılları arasındaki 1 yıllık kısmı test verisi olarak kullanılmıştır. Veriler, modellerde min-max scaler yöntemi ile ölçeklenerek kullanılmıştır. Yapay sinir ağı modelleri gizli katman sayısı, nöron sayısı, öğrenme katsayısı, aktivasyon fonksiyonu ve iyileştirme algoritması belli değer aralıklarında rassal olarak belirlenecek şekilde dinamik bir yapıda oluşturulmuştur. Birinci aşamada 500 kez her turda 100 eğitim adımı olacak şekilde MLP, LSTM ve BİLSTM ağları için en iyi sonuç elde edilen modeller tespit edilmiştir. Bu doğrultuda her yapay sinir ağı için tespit edilen iyileştirme algoritması, aktivasyon fonksiyonu ve öğrenme katsayısı ile ikinci aşamada 300 kez her turda 100 eğitim adımı olacak şekilde MLP, LSTM ve BİLSTM ağları için en iyi sonuç elde edilen modeller tespit edilmiştir. Takiben tahmin işlemi gerçekleştirilmiş ve ilgili yapay sinir ağı modellerinin başarısı ölçülmüştür. Ek olarak rassal orman ve çok değişkenli doğrusal regresyon yöntemleri ile de tahmin gerçekleştirilerek tahmin sonuçları ikinci aşamada yapay sinir ağı modellerinden elde edilen tahmin sonuçlarıyla karşılaştırılmıştır. Elde edilen sonuçlar doğrultusunda en iyi modelin 0,107 MAPE, 0,000739445 mse değeriyle aktivasyon fonksiyonu Relu, iyileştirme algoritması Adam, öğrenme katsayısı 1×10^{-6} , katman sayısı 4, birinci katmandaki nöron sayısı 47, ikinci katmandaki nöron sayısı 52, üçüncü katmandaki nöron sayısı 42, dördüncü katmandaki nöron sayısı 43 olan BİLSTM yapay sinir ağı olduğu gözlemlenmiştir. Diğer modellerin sıralaması, LSTM (MAPE 0,136), rassal orman (MAPE 0,170), MLP (MAPE 0,216) ve çoklu lineer regresyon (MAPE 0,616) olarak gerçekleşmiştir.

Çalışmada kullanılan veriler ve modeller ile elde edilen sonuçlar değerlendirildiğinde BİLSTM ve LSTM yapay sinir ağı modellerinin tahmin başarısının rassal orman ve çok değişkenli doğrusal regresyona göre yüksek olduğu gözlemlenmiştir. Bununla birlikte yapay sinir ağı modellerinde tahmin işlemi için geçen sürenin rassal orman ve çoklu lineer regresyona göre fazla olduğu gözlemlenmiştir. Yapay sinir ağı modellerinde birinci aşamada LSTM modelinin eğitim süresi yaklaşık 13 saat, BİLSTM modelinin eğitim süresi yaklaşık 16 saat, MLP modelinin eğitim süresi yaklaşık 2 saat, ikinci aşamada LSTM modelinin eğitim süresi yaklaşık 10 saat, BİLSTM modelinin eğitim süresi yaklaşık 21 saat, MLP modelinin eğitim süresi yaklaşık 1 saat sürmüştür. Bununla birlikte rassal orman yönteminde yaklaşık 4 dakika, çok değişkenli doğrusal regresyonda yaklaşık 1 dakikada işlemler

tamamlanmıştır. Ek olarak tahmin için en uygun yapay sinir ağı modelinin oluşturulması aşamasında katman sayısı, aktivasyon fonksiyonu ve öğrenme katsayısı gibi parametrelerin belirlenmesi ilgili hesaplanmış bir yöntem olmaması nedeniyle modeller rassal olarak elde edilen parametrelerle oluşturulmuştur.

Çalışmada elde edilen sonuçlar doğrultusunda aşırı öğrenme durumu dikkate alınarak ve parametreler değiştirilerek elde edilen en iyi yapay sinir ağı modeli ile gerçekleştirilen tahminlerin doğal gaz ticareti ve faturalama operasyonu gibi süreçlerde önemli avantajlar sağlayabileceği öngörülmektedir. Bununla birlikte tüketim değişimine en fazla etki eden iklim parametrelerinin de doğru tahmin edilmesi tüketim tahmini için önem arz etmektedir. Pandemi sürecinde tam kapanma durumunun, tatil günlerinin ve iklim değişikliğinin tüketim üzerindeki etkileri, alternatif ve nükleer enerji kaynaklarının kullanımının artmasının doğal gaz tüketimi üzerindeki etkileri ayrı tez konusu olabilecek niteliktedir.

7. KAYNAKLAR

- Adıyaman, F., “Talep Tahmininde Yapay Sinir Ağlarının Kullanılması”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, İstanbul, (2007).
- Akın, B., “Yapay Sinir Ağlarıyla Konya Bölgesinde Kullanıcı Doğal Gaz Tüketim Öngörüsü”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Enerji Enstitüsü, Enerji Bilim ve Teknoloji Anabilim Dalı, İstanbul, (2017).
- Aksoy, E., “Enflasyonun Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi”, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, İstanbul, (2020).
- Aktaş, S., “Dow Jones Endüstri Ortalaması Ve Nasdaq 100 Endekslerinin Makine Öğrenmesi Algoritmaları İle Tahmini”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, İstanbul, (2019).
- Ankara Üniversitesi., “Ankara Üniversitesi Açık Öğretim Ders Notları [online]”, (29.09.2021), https://acikders.ankara.edu.tr/pluginfile.php/62029/mod_resource/content/0/4.%20hafta.pdf, (2021).
- Ascione, F., Bianco, N., De Stasio, C., Vanoli, G. and Mauro, G. M., “Artificial neural networks to predict energy performance and retrofit scenarios for any member of a building category: A novel approach”, *Energy*, 118, 999-1017, (2017).
- Aydın, H., Gözel, M. E., Kor, K., Merey, Ş., Özgür, E., Öztürk, T., Tuğan, M. F., Yardımcı, O. ve Yüce, U., *21. Yüzyılda Petrol Ve Doğal Gaz Mühendisliği*, Ankara: Gazi Kitapevi, (2020).
- Ballı, M. T., “Yapay Sinir Ağları İle Talep Tahmini Ve Gıda Sektöründe Uygulanması”, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, İstanbul, (2014).
- Baloğlu, M., “Hissedilen ve Üşüme Sıcaklıklarının Türkiye Üzerindeki Dağılımı”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Meteoroloji Mühendisliği Anabilim Dalı, İstanbul, (2001).
- Bayraç, H. N., “Uluslararası doğalgaz piyasasının ekonomik yapısı ve uygulanan politikalar”, *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 13 (3), 13-36, (2018).

- BOTAŞ., “Doğal Gaz ve Petrol Boru Hatları Haritası [online]”, (16.08.2021),
<https://www.botas.gov.tr/Sayfa/dogal-gaz-ve-petrol-boru-hatlari-haritasi/168#gallery>.
- BOTAŞ., “Şirket Profili [online]”, (06.08.2021),
<https://www.botas.gov.tr/Sayfa/sirket-profil/472>.
- BP., “Statistical Review of World Energy 2020 [online]”, (21.01.2021),
<https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/statistical-review/bp-stats-review-2020-full-report.pdf>, (2020).
- Bulundu, H., Say, S.S., “Genel Doğal Gaz [online]”, (05.03.2021),
<https://ugetam.istanbul/wp-content/uploads/2020/12/Genel-Dogalgaz.pdf>,
(2016).
- Bulut, Ş., “Orta Ölçekli Bir İşletmede Talep Tahmin Yöntemlerinin Uygulanması”, Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Kırıkkale, (2006).
- Cam, S., Sigeze, C. ve Ballı, E., “An analysis of turkey's energy efficiency with artificial neural networks and ardl approach”, *Ege Academic Review*, 18 (4), 661-670, (2018).
- Cengiz, E., “Endoskopi Görüntülerindeki Poliplerin Derin Öğrenme Algoritması Kullanılarak İncelenmesi”, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Eskişehir, (2020).
- Çağlar, T., “Talep Tahmininde Kullanılan Yöntemler Ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması”, Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Kırıkkale, (2007).
- Çil, N., “İstanbul Üniversitesi Açık ve Uzaktan Eğitim Fakültesi Ders Notları [online]”, (13.09.2021),
<http://auzefkitap.istanbul.edu.tr/kitap/kok/ekonometriu159.pdf>, (2021).
- Çuhadar, M. Ve Kayacan, C., “Yapay sinir ağları kullanılarak konaklama işletmelerinde doluluk oranı tahmini: Türkiye'deki konaklama işletmeleri üzerine bir deneme”, *Anatolia: Turizm Araştırmaları Dergisi*, 16 (1), 24-30, (2005).
- Del Real, A., J., Dorado, F. ve Duran, j., “Energy demand forecasting using deep learning: applications for the french grid”, *Energies*, 13 (9), 2242, (2020).
- Demirceylan, S., “Erzurum’da Doğalgaz Tüketim Miktarının Yapay Sinir Ağı Algoritması Kullanılarak Tahmin Edilmesi”, Yüksek Lisans Tezi, Erzurum

Atatürk Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Erzurum, (2012).

Dinç, M., “Yapay Zekâ Tabanlı Talep Tahmin Yöntemlerinin Performans Üstünlükleri Açısından Değerlendirilmesi: Gıda Sektöründe Bir Uygulama”, Yüksek Lisans Tezi, Manisa Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Manisa, (2021).

Efendigil, T., Önüt, S. ve Kahraman, C., “A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis”, *Expert Systems with Applications*, 36 (3), 6697-6707, (2009).

Elmas, Ç., *Yapay Zeka Uygulamaları*, Ankara: Seçkin Yayıncılık, (2021).

EPDK., “EPDK Doğal Gaz Piyasası 2020 Yılı Sektör Raporu [online]”, (05.08.2021),
<https://www.epdk.gov.tr/Detay/DownloadDocument?id=KDn4Bm1KAYA=>, (2020).

EPDK., “EPDK Doğal Gaz Piyasası 2021 Yılı Sektör Raporu [online]”, (13.07.2022),
<https://www.epdk.gov.tr/Detay/DownloadDocument?id=L53LfG19uM4=>, (2021).

EPDK., “Doğal Gaz Piyasası Lisans Yönetmeliği [online]”, (27.11.2021),
<https://www.mevzuat.gov.tr/File/GeneratePdf?mevzuatNo=5717&mevzuatTur=KurumVeKurulusYonnetmeliği&mevzuatTertip=5>.

Ergün, S., ve Şahin, S., “İşletme talep tahmini üzerine literatür araştırması”, *Ulak Bilge*, 5 (10), 469-487, (2017).

Esim, K., N., “Uğruna Savaşlar Çıkan Petrol Nasıl Oluşur? [online]”, (15.03.2021),
<https://www.bilgeyik.com/ugruna-savastlar-cikan-petrol-nasil-olusur-728>, (2021).

ETKB., “2020 Yılı Ulusal Enerji Denge Tabloları [online]”, (03.08.2021),
https://enerji.gov.tr/Media/Dizin/EIGM/tr/Raporlar/Ulusal_Enerji_Denge_Tablolari/2020.xlsx, (2020).

GAZBİR., “2020 Yılı Doğal Gaz Dağıtım Sektör Raporu [online]”, (12.08.2021),
<http://www.gazbir.org.tr/rapor/2020-dogalgaz-sektor-raporu/668dfced1c3035029378fe03b4118223>, (2020).

Genç Kavas, H., “Türkiye Enerji Sektörünün Stratejik Konumu Ve Yapay Sinir Ağı Modelleriyle Enerji Tüketiminin Tahmini”, Doktora Tezi, Sivas Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Sivas, (2019).

- Heizer, J. ve Render, B., *Üretim Yönetimi 11. Baskıdan Çeviri*, Ankara: Palme Yayın, Dağıtım, Pazarlama, İç ve Dış Ticaret LTD. ŞTİ., (2017).
- Hill, T., Marquez, L., O'Connor, M. ve Remus, W., "Artificial neural network models for forecasting and decision making", *International Journal of Forecasting*, 10 (1), 5-15, (1994).
- İstanbul Üniversitesi., "İstanbul Üniversitesi Açık ve Uzaktan Eğitim Fakültesi Ders Notları [online]", (29.09.2021), https://cdn-acikogretim.istanbul.edu.tr/auzefcontent/21_22_Guz/biyoistatistik/12/index.html, (2021).
- Kadılar, C. ve Öncel Çekim, H., *SPSS ve R Uygulamalı Zaman Serileri Analizine Giriş 3.Baskı*, Ankara: Seçkin Yayıncılık, (2020).
- Karahan, M., "Yapay Sinir Ağları Metodu İle Ürün Talep Tahmini Uygulaması", Doktora Tezi, Konya Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Konya, (2011).
- Keçebaş, A., Yabanova, İ. ve Yumurtacı, M., "Artificial neural network modeling of geothermal district heating system thought exergy analysis", *Energy Conversion and Management*, 64, 206-212, (2012).
- Kellova, A., "Statistical approaches to short-term electricity forecasting", Thesis, University of Charles, Prague, (2008).
- Kingma, D. P. ve Ba, J., "Adam: A method for stochastic optimization [online]", (18.01.2022), <https://arxiv.org/pdf/1412.6980v9>, (2015).
- Koçyiğit, E., "Derin Öğrenme İle İçerik Tabanlı Siber Tehdit Tespiti", Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, İstanbul, (2021).
- Lin, B., ve Ageyman, S., "Impact of natural gas consumption on sub-Saharan Africa's CO2emissions: Evidence and policy perspective", *Science of the Total Environment*, 760, 143321, (2021).
- Mejias, P. R., Fargallo, P. A., Bellido, R. C. ve Arcas, P. J., "Comparison of linear regression and artificial neural networks models to predict heating and cooling energy demand, energy consumption and CO2 emissions", *Energy*, 118, 24-36, (2017).
- Mokhatab, S., Poe, W. A. ve Mak, J. Y., *Handbook of Natural Gas Transmission and Processing*, New York: Elsevier Inc., (2015).
- Moon, J., Park, S., Rho, S. ve Hwang, E., "A comparative analysis of artificial neural network architectures for building energy consumption forecasting", *International Journal of Distributed Sensor Networks*, 15(9), 1-19, (2019).

- Nabiyev, V., *Yapay Zeka*, Ankara:Seçkin Yayıncılık, (2021).
- Öğücü, M. O., “Yapay Sinir Ağları İle Sistem Tanıma”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Elektrik Mühendisliği Anabilim Dalı, İstanbul, (2006).
- Öztemel, E., *Yapay Sinir Ağları*, İstanbul:Papatya Yayıncılık, (2006).
- Puri, V. ve Kumar, N., “Wind energy forecasting using artificial neural network in himalayan region”, *Modeling Earth Systems and Environment*, 8, 59-68, (2021).
- Sarıaslan, H., Karacabey, A. A. Ve Gökğöz, F., *Nicel Karar Yöntemleri*, Ankara:Siyasal Kitapevi, (2017).
- Shakaya, S., Kern, M., Owusu, G. ve Chin, C. M., “Dynamic pricing with neural network demand models and evolutionary algorithms”, *Research and Development in Intelligent Systems XXVII*, Cambridge England, 223-236, (2010).
- Şahin, A. E., “Eğitim araştırmalarında delphi tekniği ve kullanımı”, *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 20, 215-216, (2001).
- Taşkıner, B., “Ankara İli Doğal Gaz Tüketiminin Yapay Sinir Ağları İle Öngörüsü”, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Enerji Enstitüsü, Enerji Bilim ve Teknoloji Anabilim Dalı, İstanbul, (2018).
- TPAO., “2020 Petrol ve Doğal Gaz Sektör Raporu [online]”, (13.07.2021), <https://www.tpao.gov.tr/file/2110/tpao-sektor-raporu-2020-sunum-191021-596616ff74617f07.pdf>, (2020).
- TPAO., “2021 Petrol ve Doğal Gaz Sektör Raporu [online]”, (13.07.2022), <https://www.tpao.gov.tr/file/2206/2021-petrol-ve-dogal-gaz-sektor-raporu-88862b56f9494910.pdf>, (2021).
- UEA., “Gaz Piyasası Raporu 3. Çeyrek 2021 [online]”, (03.08.2021), https://iea.blob.core.windows.net/assets/4fee1942-b380-43f8-bd86-671a742db18e/GasMarketReportQ32021_includingGas2021Analysisandforecastto2024.pdf, (2021).
- Wong, B. K., Bodnovich, T. A. Ve Selvi, Y., “Neural network applications in business: A review and analysis of the literature (1988–1995)”, *Decision Support Systems*, 19(4), 301-320, (1997).
- Yazan, E. ve Talu, M. F., “Comparison of the stochastic gradient descent based optimization techniques”, *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, Malatya Türkiye, 1-5, (2017).

Yolsal, H., “İstanbul Üniversitesi Açık ve Uzaktan Eğitim Fakültesi Uygulamalı İstatistik Ders Notları [online]”, (10.03.2022),
http://auzefkitap.istanbul.edu.tr/kitap/iktisat_ue/uygulamaliista.pdf.