

T.C.
İSTANBUL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
ÜRETİM ANABİLİM DALI

YÜKSEK LİSANS TEZİ

TÜRKİYE İÇİN DOĞAL GAZ TALEP TAHMİNİ

Salih BAKKAL

2501210901

TEZ DANIŞMANI

Prof. Dr. Necdet ÖZÇAKAR

İSTANBUL – 2023

ÖZ

TÜRKİYE İÇİN DOĞAL GAZ TALEP TAHMİNİ

Salih BAKKAL

Teknolojik gelişmeler, artan nüfus, değişen yaşam tarzları, iktisadi gelişmişlik düzeyinin yakalanması için artan sanayileşme gibi birçok nedenden dolayı enerji tüketiminde önemli bir artış yaşanmaktadır. Bu çalışmada, son yıllarda tüketimi giderek artan ve fosil yakıtlar içerisinde sürdürülebilirlik açısından güçlü bir seçenek olan doğal gaz enerjisi üzerinde çalışılmıştır. Bu amaçla ilk olarak doğal gaz tedarik zincirinin yapısal özellikleri ve operasyonel süreçleri incelenmiştir. Daha sonrasında stok yönetimi, arz talep dengesinin sağlanması, enerji güvenliği ve kesintisiz hizmet verilmesi için önemli olan enerji talep tahmini üzerinde durulmuştur. 2010-2022 yılları arası aylık veriler kullanılarak Türkiye'nin doğal gaz tüketimini tahmin etmek için üç popüler makine öğrenmesi algoritması kullanılmıştır. Bunlar; çoklu doğrusal regresyon, destek vektör regresyonu ve rastgele orman regresyonu. HDD, 12 ay gecikme değerleri ve nem bağımsız değişkenleri kullanılarak oluşturulan modellerin performansları birbirine yakın olmakla birlikte en yüksek R^2 değerine sahip olan yöntemin çoklu doğrusal regresyon olduğu tespit edilmiştir. Geleneksel yöntemlerin yalın ve görece az değişkenle hazırlanmış olan modellerde makine öğrenmesi modellerine göre iyi performans gösterebildiği tespit edilmiştir. Makine öğrenmesindeki gelişmiş algoritmaların karmaşık, doğrusal olmayan ilişkilerin tespit edilmesi açısından daha başarılı performans göstermesi olasıdır. Yürütülen çalışma, doğal gaz tedarik zincirinin incelenmesi, doğal gaz tüketimini aylık olarak Türkiye geneli için değerlendirmesi ve farklı makine öğrenmesi yöntemlerinin karşılaştırılması yönüyle literatüre katkı sağlamaktadır. Elde edilen bulgular, enerji kaynaklarının etkin kullanımı, tedarik zinciri planlaması ve enerji güvenliği konularında karar vericilere bilgi sunmaktadır.

Anahtar Kelimeler: Enerji, Doğal Gaz Tedarik Zinciri, Doğal Gaz Piyasası, Talep Tahmini, Makine Öğrenmesi, Regresyon Modelleri

ABSTRACT

NATURAL GAS DEMAND FORECASTING FOR TURKEY

Salih BAKKAL

Due to advancements in technology, population growth, changing lifestyles, and the pursuit of industrialization for economic development, there has been a considerable increase in energy consumption. This research focuses on natural gas as a sustainable option within fossil fuels, which has experienced a rising demand in recent years. The study initially examines the structural characteristics and operational processes of the natural gas supply chain. It then shifts attention to energy demand forecasting, a crucial aspect for managing stocks, achieving supply-demand balance, ensuring energy security, and providing uninterrupted services. Three popular machine learning algorithms, namely multiple linear regression, support vector regression, and random forest regression, are utilized to predict Turkey's natural gas consumption using monthly data from 2010 to 2022. The models constructed using heating degree days (HDD), 12-month lag values, and humidity as independent variables exhibit comparable performance, with multiple linear regression yielding the highest R^2 value. Traditional approaches perform well in simpler models with fewer variables compared to machine learning models. However, advanced machine learning algorithms may excel in capturing complex and non-linear relationships. This study contributes to the existing literature by examining the natural gas supply chain, evaluating monthly natural gas consumption for Turkey as a whole, and comparing different machine learning methods. The findings offer valuable insights for decision-makers regarding the efficient utilization of energy resources, supply chain planning, and energy security.

Keywords: Energy, Natural Gas Supply Chain, Natural Gas Market, Demand Estimation, Machine Learning, Regression Models

TEŞEKKÜR

Türkiye İçin Doğal Gaz Talep Tahmini konulu tez çalışmamda bana olan güveni ve desteği için çok değerli danışman hocam Prof. Dr. Necdet ÖZÇAKAR'a, tecrübeleri ve fikirleri ile bana yol gösteren kıymetli hocalarım Doç. Dr. Nihan KABADAYI ve Dr. Öğretim Üyesi Pınar GÜROL'a teşekkürlerimi sunarım.

Tez çalışmam sırasında manevi desteklerini her zaman hissettiğim ve bu süreçte karşılaştığım her zorlukta bana yardımcı olmaya çalışan kardeşim Sümeyye BAKKAL ve değerli dostum Yunus Emre OKUYUCU'ya gönülden teşekkür ederim.

ÖNSÖZ

Tedarik zincirleri, uluslararası alana yayılan, çok sayıda paydaşa sahip olan ve kesintisiz hizmet sağlamak için önemli süreçleri içeren yapılar olarak öne çıkmaktadır. Her bir tedarik zinciri, kendine özgü yapısal özelliklere ve operasyonel süreçlere sahiptir. Bu özgün yapıları anlamak, stratejik avantaj sağlayacak konularda doğru kararlar almak ve kesintisiz bir hizmet sunmak için oldukça önemlidir. Gelişen teknoloji, değişen müşteri alışkanlıkları, artan nüfus, son dönemde yaşanan pandemi ve doğal afetler gibi beklenmedik olaylar, tedarik zincirlerini daha karmaşık ve belirsiz hale getirmektedir. Bu belirsizliklerle başa çıkmak, kesintisiz hizmet sunmak ve rekabette güvenilir bir konuma gelmek için stok yönetimi, talep tahmini, kalite yönetimi gibi geniş kapsamlı konularda pek çok çalışma yürütülmektedir.

Bu çalışma, iki temel amaç etrafında şekillendirilmiştir. İlk olarak, doğal gaz tedarik zincirinin yapısını ve üretim, taşıma, depolama, dağıtım gibi operasyonel süreçlerini incelemeyi hedeflemektedir. İkinci olarak, doğal gaz tüketimini etkileyen değişkenleri belirlemek ve talep tahmini probleminde en düşük hatayı veren modeli önermeyi amaçlamaktadır. Bir enerji tedarik zincirini anlamak ve gelecekte bu enerjinin tüketimiyle ilgili doğru tahminlerde bulunmak, güvenli enerji akışını sürdürmek, kesintisiz hizmet sağlamak ve enerji piyasasında önemli bir konuma gelmek için uluslararası düzeyde ülkelere, ulusal düzeyde ise özel enerji dağıtım şirketlerine rekabet avantajı sağlamaktadır.

Salih BAKKAL

İSTANBUL, 2023

İÇİNDEKİLER

ÖZ	ii
ABSTRACT	iii
ÖNSÖZ	v
TABLOLAR LİSTESİ	x
ŞEKİLLER LİSTESİ	xi
KISALTMALAR LİSTESİ	xiii
GİRİŞ	1

BİRİNCİ BÖLÜM

DOĞAL GAZ ENERJİSİ

1.1. DOĞAL GAZIN TARİHÇESİ	3
1.2. DOĞAL GAZIN TANIMI VE ÖZELLİKLERİ	6
1.3. DOĞAL GAZ TEDARİK ZİNCİRİ	8
1.3.1. DOĞAL GAZIN KEŞFİ	11
1.3.2. DOĞAL GAZIN ÇIKARILMASI	12
1.3.3. DOĞAL GAZIN İŞLENMESİ	12
1.3.4. DOĞAL GAZIN TAŞINMASI	14
1.3.4.1. BORU HATTI İLE TAŞIMA	14
1.3.4.2. SIVILAŞTIRILMIŞ ŞEKİLDE TAŞIMA (LNG)	16
1.3.4.3. SIKIŞTIRILMIŞ ŞEKİLDE TAŞIMA (CNG)	17
1.3.4.4. DOĞAL GAZ HİDRAT OLARAK TAŞIMA (NGH)	18
1.3.5. DOĞAL GAZIN DEPOLANMASI	19
1.3.5.1. YERALTINDA DEPOLAMA	19
1.3.5.2. YERÜSTÜNDE DEPOLAMA	24
1.3.6. DOĞAL GAZIN DAĞITILMASI	26
1.4. DOĞAL GAZIN KULLANIM ALANLARI	26
1.4.1. ENERJİ SEKTÖRÜ	27
1.4.2. KONUTLAR	27
1.4.3. SANAYİ SEKTÖRÜ	28
1.4.4. HİZMET SEKTÖRÜ	28

1.4.5. ULAŞIM SEKTÖRÜ	29
1.5. DÜNYA DOĞAL GAZ PİYASASI	30
1.6. TÜRKİYE DOĞAL GAZ PİYASASI	38
1.6.1. ÜRETİM VE TÜKETİM	39
1.6.2. İTHALAT VE İHRACAT	42
1.6.3. DEPOLAMA	46
1.6.4. DOĞAL GAZ TEDARİK KAYNAKLARI	48
1.6.4.1. RUSYA – TÜRKİYE DOĞALGAZ BORU HATTI (BATI HATTI) ..	49
1.6.4.2. MAVİ AKIM DOĞALGAZ BORU HATTI	50
1.6.4.3. DOĞU ANADOLU DOĞALGAZ ANA İLETİM HATTI (İRAN – TÜRKİYE)	50
1.6.4.4. BAKÜ-TİFLİS-ERZURUM DOĞALGAZ BORU HATTI (BTE)	50
1.6.4.5. TÜRKİYE-YUNANİSTAN DOĞALGAZ ENTERKONNEKSİYONU	51
1.6.4.6. TRANS-ANADOLU DOĞALGAZ BORU HATTI (TANAP)	51
1.6.4.7. TÜRKAKIM DOĞALGAZ BORU HATTI	52

İKİNCİ BÖLÜM

TALEP TAHMİNİ

2.1. TALEP TAHMİNİNE GENEL BİR BAKIŞ	53
2.2. TAHMİNİN ÖZELLİKLERİ	54
2.3. TAHMİN SÜRECİ ADIMLARI	55
2.4. İYİ BİR TAHMİNİN BİLEŞENLERİ	56
2.5. TALEP TAHMİN YÖNTEMLERİ	57
2.5.1. KALİTATİF (NİTEL) YÖNTEMLER	57
2.5.1.1. YÖNETİCİ GÖRÜŞÜ	58
2.5.1.2. SATIŞ EKİBİ TAHMİNLERİ	58
2.5.1.3. DELPHİ METODU	58
2.5.1.4. PAZAR ARAŞTIRMASI	60
2.5.1.5. SENARYO ANALİZİ	60
2.5.1.6. YAŞAM ÇEVİRİMİ BENZEŞİMİ	60
2.5.2. KANTİTATİF (NİCEL) YÖNTEMLER	61

2.5.2.1. ZAMAN SERİSİ MODELLERİ	61
2.5.2.2. NEDENSEL (İLİŞKİSEL) YÖNTEMLER.....	65
2.5.2.3. YAPAY ZEKÂ MODELLERİ.....	68
2.6. DOĞAL GAZ TALEP TAHMİNİ İLE İLGİLİ YAPILAN ÇALIŞMALAR	68
2.7. TAHMİN HATASININ ÖLÇÜMÜ.....	80
2.7.1. ORTALAMA MUTLAK HATA (MAE).....	81
2.7.2. ORTALAMA KARELER HATASI (MSE)	81
2.7.3. HATA KARELER ORTALAMASININ KAREKÖKÜ (RMSE)	82
2.7.4. ORTALAMA MUTLAK YÜZDE HATASI (MAPE)	82
2.7.5. BELİRLİLİK KATSAYISI (R^2)	83

ÜÇÜNCÜ BÖLÜM

MAKİNE ÖĞRENMESİ

3.1. MAKİNE ÖĞRENMESİNE GENEL BAKIŞ	85
3.2. MAKİNE ÖĞRENMESİNİN ÖNEMİ	88
3.3. MAKİNE ÖĞRENMESİ TÜRLERİ.....	89
3.3.1. DENETİMLİ ÖĞRENME.....	89
3.3.2. DENETİMSİZ ÖĞRENME	91
3.3.3. YARI DENETİMLİ ÖĞRENME.....	93
3.3.4. PEKİŞTİRMELİ ÖĞRENME	94
3.4 MAKİNE ÖĞRENMESİ PROJESİ	96
3.4.1. VERİ TOPLAMA VE HAZIRLAMA	96
3.4.2. ÖZELLİK SEÇİMİ.....	97
3.4.3. ALGORİTMA SEÇİMİ	100
3.4.4. PARAMETRE VE MODEL SEÇİMİ.....	100
3.4.5. EĞİTİM VE TEST	101
3.4.6. DEĞERLENDİRME	101

DÖRDÜNCÜ BÖLÜM

METODOLOJİ

4.1. ÇOKLU DOĞRUSAL REGRESYON	102
4.2. DESTEK VEKTÖR REGRESYONU	104

4.3. RASTGELE ORMAN REGRESYONU	109
--------------------------------------	-----

BEŞİNCİ BÖLÜM

UYGULAMA

5.1. UYGULAMANIN AMACI VE ÖNEMİ.....	112
5.2. DEĞİŞKEN BELİRLEME VE VERİ TOPLAMA	114
5.3. VERİ ANALİZİ	117
5.4. MODEL OLUŞTURMA.....	122
5.4.1 ÇOKLU DOĞRUSAL REGRESYON	122
5.4.2 DESTEK VEKTÖR REGRESYON.....	124
5.4.3 RASTGELE ORMAN REGRESYON.....	126
SONUÇ.....	129
BİBLİYOGRAFYA / KAYNAKÇA.....	132

TABLÖLAR LİSTESİ

Tablo 1: Doğal Gaz Bileşenleri ve Oranları.....	6
Tablo 2: Yeraltı Depolama Tesisleri Karşılaştırması.....	24
Tablo 3: Farklı Doğal Gaz Müşteri Tipleri ve Özellikleri	29
Tablo 4: Ülkelere Göre Kanıtlanmış Doğal Gaz Rezervleri	32
Tablo 5: Sektörlere Göre Doğal Gaz Tüketimi	41
Tablo 6: Doğal Gaz İthalatı (Milyon Sm ³).....	43
Tablo 7: Doğal Gaz Türüne Göre İthalat Miktarları (Milyon Sm ³)	43
Tablo 8: Doğal Gaz Anlaşmaları.....	44
Tablo 9: Doğal Gaz Depolama Tesisleri	47
Tablo 10: 2007-2022 Yılları Arası Doğal Gaz Talep Tahmini Çalışmaları Özeti....	74
Tablo 11: Doğal Gaz Talep Tahmini Çalışmalarında Nadiren Kullanılan Hata Metrikleri	83
Tablo 12: İki Değişken Arasındaki Korelasyon Karar Aralıkları	98
Tablo 13: Meteorolojik Değişkenler	115
Tablo 14: Doğal Gaz Tüketim Verileri İçin Otokorelasyon Değerleri	116
Tablo 15: OLS Regresyon Sonuçları	118
Tablo 16: KPSS Test Sonuçları.....	121
Tablo 17: Çoklu Doğrusal Regresyon İçin Gerçekleşen ve Tahmin Edilen Değerler Tablosu.....	123
Tablo 18: Destek Vektör Regresyonu İçin Gerçekleşen ve Tahmin Edilen Değerler Tablosu.....	125
Tablo 19: Rastgele Orman Regresyonu İçin Gerçekleşen ve Tahmin Edilen Değerler Tablosu.....	127

ŞEKİLLER LİSTESİ

Şekil 1: Doğal Gaz Tedarik Zinciri Süreçleri	9
Şekil 2: Doğal Gaz Tedarik Zinciri Paydaşları İçin Kılavuz	10
Şekil 3: Basit Doğal Gaz İşleme Akış Şeması	13
Şekil 4: LNG Tedarik Zinciri	16
Şekil 5: Doğalgazın Hidrat Olarak Taşınması	19
Şekil 6: Küresel Enerji Tüketimi (1990-2021)	30
Şekil 7: Bölgelere Göre Kanıtlanmış Doğal Gaz Rezervleri (2020)	31
Şekil 8: Küresel Doğal Gaz Üretimi (1990-2021)	33
Şekil 9: 2021 Küresel Boru Hattı Doğal Gaz Ticareti	34
Şekil 10: 2021 Küresel LNG Ticareti	35
Şekil 11: 2021 Yılı Küresel Gaz Ticareti Hareketi	36
Şekil 12: Küresel Doğal Gaz Tüketimi (2021)	37
Şekil 13: Küresel Doğal Gaz Talebindeki Eğilim (2021-2050)	38
Şekil 14: Türkiye Doğal Gaz Üretimi (2011-2022)	40
Şekil 15: Doğal Gaz Üretim Sahaları ve Üretim Miktarları (2022 yılı)	40
Şekil 16: Türkiye Doğal Gaz Tüketimi	41
Şekil 17: Doğal Gaz İhracatı	45
Şekil 18: 2022 Yılında Doğal Gaz İhracat Yapılan Ülkelere ve Doğal Gazın Türüne Göre İhracat Miktarları	45
Şekil 19: Yıllara Göre Ay Sonu Doğal Gaz Stok Miktarları	48
Şekil 20: 2022 Yılında Aylara Göre İthalat-Tüketim-Stok Miktarları Karşılaştırması	48
Şekil 21: Türkiye'de Doğal Gaz Altyapısı ve Giriş Noktaları	49
Şekil 22: Boru Hatlarının Türkiye'ye Giriş Noktaları ve Kapasiteleri	52
Şekil 23: Talep Tahmin Hatasının Karşılaştırmalı Analizi	54
Şekil 24: Talep Yapıları	62
Şekil 25: Basit Doğrusal Regresyon Çizgisi	66
Şekil 26: Denetimli Öğrenme ile Sınıflandırma Örneği	91
Şekil 27: Üç Merkezli k-Ortalamalar ile Oluşturulmuş Kümeleme	92
Şekil 28: Pekiştirmeli Öğrenme	96
Şekil 29: İki Bağımsız Değişken İçeren Çoklu Regresyon Hiper Düzlemi	103
Şekil 30: İki Sınıfı Ayıran Hiper Düzlem	104
Şekil 31: Destek Vektör Regresyonu İçin Hiper Düzlem	107
Şekil 32: Rastgele Orman Çalışma Prensibi	110
Şekil 33: Çalışmanın Akış Diyagramı	113
Şekil 34: 2010-2022 Yılları Arası Türkiye'nin Doğal Gaz Tüketim Verileri	114
Şekil 35: Doğal Gaz Tüketim Verilerinin Otokorelasyon Grafiği	116
Şekil 36: Değişkenler Arasındaki Korelasyonlar Değerleri	117
Şekil 37: HDD ve Doğal Gaz Tüketimi Verilerinin Serpilme Diyagramı	119

Şekil 38: 12 Ay Gecikme ve Doğal Gaz Tüketimi Verilerinin Serpilme Diyagramı	120
Şekil 39: Nem Oranı ve Doğal Gaz Tüketimi Arasındaki İlişki.....	121
Şekil 40: Çoklu Doğrusal Regresyon İçin Gerçekleşen ve Tahmin Edilen Değerler Grafiği	123
Şekil 41: Destek Vektör Regresyonu İçin Gerçekleşen ve Tahmin Edilen Değerler Grafiği	125
Şekil 42: Rastgele Orman Regresyonu İçin Gerçekleşen ve Tahmin Edilen Değerler Grafiği	127

KISALTMALAR LİSTESİ

M.Ö	: Milattan Önce
M.S	: Milattan Sonra
ABD	: Amerika Birleşik Devletleri
TPAO	: Türkiye Petrolleri Anonim Ortaklığı
OAPEC	: Organization of Arab Petroleum Exporting Countries
CGS	: City Gate Station
NGL	: Natural Gas Liquids
LNG	: Liquefied Natural Gas
CNG	: Compressed Natural Gas
NGH	: Natural Gas Hidrat
LDC	: Local Distribution Company
MMsfc	: Million Standard Cubic Feet Per Day
DWT	: Dead Weight Tonnage
PSI	: Pounds Per Square Inch
CIS	: Commonwealth of Independent States
IEA	: International Energy Agency
GEFC	: Gas Exporting Countries Forum
EPDK	: Enerji Piyasaları Denetleme Kurulu
BOTAŞ	: Boru Hatları ile Petrol Taşıma Anonim Şirketi
A. Ş	: Anonim Şirket
FSRU	: Floating Storage and Regasification Unit
TANAP	: Trans Anadolu Doğalgaz Boru Hattı
INOGATE	: Interstate Oil and Gas Transportation to Europe
ARIMA	: Autoregressive Integrated Moving Average
ARIMAX	: ARIMA with Explanatory Variables
MAPE	: Mean Absolute Percentage Error
ANFIS	: Adaptive Neuro-Fuzzy Inference System
GDP	: Gross Domestic Product
RMSE	: Root-Mean-Square Error
GP	: Genetik Programlama

ETKB	: Enerji ve Tabii Kaynaklar Bakanlığı
SARIMA	: Seasonal Autoregressive Integrated Moving Average
SARIMAX	: SARIMA with Explanatory Variables
MARS	: Multivariate Adaptive Regression Splines
CMARS	: Conic Multivariate Adaptive Regression Splines
MAE	: Mean Absolute Error
MAD	: Median Absolute Deviation
APE	: Absolute Percentage Error
NMAE	: Normalized Mean Absolute Error
NRMSE	: Normalized Root Mean Squared Error
ARE	: Absolute Relative Error
MARNE	: Mean Absolute Range Normalized Errors
MNAPE	: Mean Normalized Absolute Percentage Error
WMAPE	: Weighted MAPE
NMSE	: Normalized Mean Square Error
CC	: Correlation Coefficient
SD	: Standard Deviation
IBM	: International Business Machines
DNA	: Deoksiribo Nükleik Asit
DBSCAN	: Density-Based Spatial Clustering Of Applications With Noise
RSS	: Residual Sum of Squares
DVR	: Destek Vektör Regresyonu
DVM	: Destek Vektör Makinesi
HDD	: Heating Degree Days
OLS	: Ordinary Least Squares
KPSS	: Kwiatkowski-Phillips-Schmidt-Shin

GİRİŞ

Enerji, sanayi devriminden bu yana artan gelişmişlik düzeyinin belirleyici bir unsuru olmuştur. Bir sistemin işleyebilmesi için vazgeçilmez bir güç ve kapasite sağlar ve üretim süreçlerinin temel bir kaynağı olarak önem taşır. Makinelerin çalışması, ısıtma veya soğutma gereksinimleri, aydınlatma, lojistik ve taşıma gibi birçok adımda enerji tüketimi gerekmektedir. Hammaddelerin işlenmesi, montajı, ambalajlanması ve depolanması gibi üretim faaliyetleri genellikle enerji bağımlıdır.

Farklı enerji kaynakları vardır. Bu kaynaklar içerisinde doğal gaz, enerji sektöründe önemli bir role sahip olan temiz ve verimli bir fosil yakıttır. Türkiye doğal gazı enerji üretiminde, sanayi sektöründe, ısınma amaçlı olarak konutlarda ve diğer pek çok sektörde önemli ölçüde tüketen bir ülke olarak, enerji güvenliğini sağlamak için doğal gaz tedarik zincirinin etkin bir şekilde yönetilmesine önem vermektedir. Bununla birlikte, gelecekteki doğal gaz tüketim miktarlarının doğru bir şekilde tahmin edilmesi, tedarik zincirinin optimize edilmesi, kaynakların etkin bir şekilde kullanılması ve arz-talep dengesinin sağlanması için kritik bir faktördür. Hatalı sonuçlar sunan talep tahmin projeleri kaynakların verimsiz bir şekilde kullanılmasına ve tedarik zinciri içerisinde yürütülen süreçlerin katma değer sağlamayan bir şekilde yürütülmesine neden olmaktadır. Güçlü tahmin modelleri kurumlar için hedef değişkenleri ele alan konularda stratejik üstünlük elde edilmesine fırsat vermektedir. Bu fırsatın elde edilmesi için farklı talep tahmin yöntemleri ve modelleri geliştirilmiştir.

Makine öğrenmesi, tahmin problemlerinde bir çözüm aracı olarak son yıllarda sıklıkla kullanılmaya başlanmıştır. Karmaşık veri setlerindeki ilişkileri keşfetmek, tahmin yapmak, operasyonel ve stratejik kararlar vermek için kullanılan güçlü bir istatistiksel araçtır. Geniş kapsamlı bir uygulama alanı bulunan makine öğrenmesi son yıllarda enerji tüketimini modellemek için de sıklıkla kullanılmaya başlanmıştır. Bu çalışma, doğal gaz tedarik zincirinin yapısal ve operasyonel özelliklerini incelemeyi, Türkiye'nin doğal gaz ticareti içerisindeki yerini analiz etmeyi ve doğal gaz tüketimini tahmin etmek için makine öğrenmesi modellerini kullanarak en düşük hata oranına sahip modeli belirlemeyi hedeflemektedir. Bu amaçla, doğal gaz tedarik zincirinin farklı aşamalarını analiz etmek, talep tahminini gerçekleştirmek ve mevcut verilerin

en iyi şekilde kullanılması için uygun bir makine öğrenmesi modelini seçmek üzere bir çalışma yürütülmüştür.

Bu çalışma, beş bölümden oluşmaktadır. İlk bölümde, doğal gaz hakkında genel bir bilgi verilmiş ve doğal gaz tedarik zincirinin süreçleri incelenmiştir. Dünya ve Türkiye doğal gaz piyasasının analizi de ilk bölümün önemli alt başlıklarındandır. İkinci bölümde ise talep tahmini ile ilgili genel bir inceleme yapılmış ve doğal gaz talep tahmini ile ilgili literatürde bulunan çalışmalar gözden geçirilmiştir. Üçüncü bölümde makine öğrenmesi konusunda temel bilgiler verilmiştir ve bir makine öğrenmesi projesinin hazırlanması konusunda yol haritası tanımlanmıştır. Dördüncü ve beşinci bölümlerde ise sırasıyla çalışmada kullanılacak yöntemler açıklanmıştır ve farklı makine öğrenmesi modelleri uygulanarak bu modellerin performansları hakkında bilgi verilmiştir.

BİRİNCİ BÖLÜM

DOĞAL GAZ ENERJİSİ

1.1. DOĞAL GAZIN TARİHÇESİ

21. yüzyılın önemli enerji kaynaklarından biri olan doğal gaz, imalat sektöründen hizmet sektörüne kadar birçok alanda kullanılmaktadır. Bundan yüzyıllar önce farklı coğrafyalarda keşfedilen, farklı şekillerde tanımlanan ve günümüz modern yöntemlerin gerisinde olan ilkel yöntemler ile çıkarılan doğal gazın uzun dönemleri kapsayan bir tarihsel gelişim süreci vardır. İran'da M.Ö. 6000-2000 yılları arasında keşfedilen doğal gaz, günümüzde yaygın olarak enerji kaynağı olarak kullanılmasına rağmen başlangıçta dini amaçlar için kullanılmıştır. İran, Yunanistan ve Hindistan gibi ülkelerde gaz sızıntılarının yıldırım tarafından tutuşması ile meydana gelen alevlerin etrafında tapınaklar inşa edilmiştir (Mokhatab, Poe, Speight, 2018: 2) Bu alevlerin en ünlülerinden birisi Antik Yunanistan'da M.Ö 1000 yıllarında Parnassos Dağı'nda ortaya çıkmıştır. Bir keçi çobanı bölgede bir kayadaki yarıktan yükselen aleve rastlamıştır. Bu ateşin tanrısal olduğuna inanan Yunanlılar, onun üzerine bir tapınak inşa etmiştir (Speight, 2018: 8).

M.Ö 900 yıllarında Çin'de doğal gazın enerji kaynağı olarak değeri fark edilmiş ve tuz çökertme işlemi için kullanılmıştır (Speight, 2018: 7). Roma'da M.Ö 50 yıllarında Uesta Tapınağında yer alan aşk tanrıçası heykelinin sürekli olarak doğal gazdan elde edilen alev ile aydınlatıldığı bilinmektedir. M.S 221-263 yıllarında Çin'de bulunan Shu Hanedanlığı tarafından çıkarılan doğal gaz, bambu kamışları ile taşınmıştır (Bayraç, 2018: 16).

Asya, Orta Doğu ve Antik Yunan'da yapılan keşiflerin ardından doğal gazın Avrupa'daki ilk keşfi 1659'da gerçekleştirilmiştir (Speight, 2018: 8). Ticari olarak kullanımı ise İskoç mühendis William McMaster Murdoch'un kömürden doğal gaz elde etmesi ile 18. yüzyılda başlamıştır (Öztürk, 2007: 6). Büyük Britanya'da 1785 yılında kömürü damıtarak üretilen doğal gaz, sokak lambaları ve evlerin aydınlatılması için kullanılmıştır. Bu şekilde üretilen doğal gaz ABD'de ise ilk kez 1816'da Baltimore, Maryland sokaklarını aydınlatmak için kullanılmıştır (Speight, 2018: 8).

Alessandro Volta 1776 yılında doğal gazı “Bataklıkların Alevli Havası” olarak tanımlamış ve bazı deneyler yaparak bu enerji kaynağının özelliklerini incelemiştir. İtalyan bilim insanı Lazzaro Spallanzani, Flemenk bilim insanı Jan Baptista Van Helmont’un 1609’da ortaya attığı gaz teriminden ilham alarak 1795 yılında doğal gazı bugünkü ismi ile adlandırmıştır (Öztürk, 2007: 6).

Frederick Winsor 1803 yılında Londra’da gaz aydınlatma sisteminin patentini almıştır ve 1812 yılında Londra’nın ilk doğal gaz şirketi kurulmuştur. İngiliz mühendis olan Samuel Clegg 1815 yılında gaz işleri süreçlerini geliştirmek amacıyla evler için bir ölçüm cihazı icat etmiştir. 1816 yılında Amerika’nın ilk doğal gaz şirketi kurulmuştur (Speight, 2018: 8). Kasıtlı olarak doğal gaz çıkarmak için ilk kuyu 1821’de açılmıştır. William Hurt, New York’un Fredonia köyünde bir derenin yüzeyinde yükselen gaz kabarcıklarını fark ettikten sonra yüzeye doğru daha büyük bir gaz akışı sağlamak için 8,22 metrelik bir kuyu kazmıştır (Çevrimiçi 1). 1840 yılında 50 ve daha fazla ABD şehrinde doğal gaz kullanılmaya başlanmıştır. Doğal gazın ilk defa endüstriyel kullanımı ise 1841 yılında ABD’nin Batı Virginia Charleston bölgesindeki bir tuz madeninde gerçekleşmiştir (Speight, 2018: 8; Öztürk, 2007: 6).

Doğal gaz keşfinden itibaren 19. yüzyılın büyük bir çoğunluğunu kapsayan zaman diliminde sokaklar, binalar, evler ve deniz feneri gibi alanların ışıklandırılması için kullanılmıştır. 1855 yılında Alman kimyager Robert Bunsen’in Bunsen Brülörü’nü icat etmesiyle doğal gaz artık evlerde de kullanılmaya başlanmıştır (Öztürk, 2007: 6). Bu cihaz doğal gazı hava ile doğru oranlarda karıştırarak ısıtma ve pişirme işlemlerinde güvenle kullanılabilecek bir alev ortaya çıkarmaktadır (Çevrimiçi 1).

1859 yılında eski bir demiryolu kondüktörü olan Albay Edwin Drake petrol kuyusu keşfi yapmıştır. Drake, yeryüzünün 21,03 metre altında ham petrol ve doğal gaz bulmuştur (Speight, 2018: 8-9). Bu kuyudan Pennsylvania’nın Titusville köyüne 8 km uzunluğunda bir boru hattı inşa edilmiştir. İlk büyük boru hatlarından biri ise 1891 yılında inşa edilen 193 km uzunluğundaki, İndiana’nın merkez kuyularından Chicago’ya doğal gaz taşıyan hattır. (Çevrimiçi 1).

Türkiye’de ise doğal gaz ilk kez 1970 yılında TPAO tarafından Hamitabat ve Kumrulara keşfedilmiştir. Keşfedilen bu gaz 1976 yılında Pınarhisar Çimento

Fabrikası'nda kullanılmaya başlanmıştır. 1980'li yıllardan itibaren ise doğal gaza olan talep katlanarak artmaya devam etmiştir (Beyca vd., 2019: 938).

Yüzyılları kapsayan gelişim süreci içinde, doğal gazın sondaj işlemi sırasında havaya karışması onu bir süre istenmeyen yan ürün haline getirmiştir. Bundan dolayı sondaj çalışanları gazın havaya karışmasını önlemek için bu çalışmaları durdurmak zorunda kalmıştır (Speight, 2018: 9). Bununla birlikte hem doğal gazın alternatif kullanımlarının değerlendirilmesi için bu enerji kaynağı ile ilgili yeterli bilgiye sahip olunmaması hem de büyük miktarlarda ve uzun mesafelerde taşınması için gerekli olan altyapıyı oluşturacak teknolojik yeterliliğin eksikliği bu enerji kaynağının kullanımının yaygınlaşmasını engellemiştir. Doğal gazın ışık kaynağı olarak kullanımından üretim süreçlerinde hammadde olarak kullanılması ve bambu kamışları ile taşınmasından, büyük çaplı ve uzun mesafelere yayılan boru hatları ile taşınması 1900'lü yılların ortalarına kadar etkin bir şekilde gerçekleşmemiştir. II. Dünya Savaşı'ndan sonra artan üretim hacimleri ve gelişen teknoloji ile doğal gazın üretim süreçlerine dahil edilmesinde ve ülkeler arası gaz akışında önemli bir artış meydana gelmiştir. 1973 yılında OAPEC'in koyduğu ambargo ile meydana gelen Petrol Krizi'nden sonra ülkeler alternatif bir enerji kaynağı olarak doğal gaza olan taleplerini hızla arttırmışlardır. Kuyulardan çıkarılması, taşınması ve depolanması süreçleri için iyileştirilen şartlar ile doğal gaz talebi artmaya devam etmektedir.

Ülkeler için enerji kaynakları, sosyo-ekonomik hayat kalitesinin, ulusal kalkınmanın ve güvenliğin sağlanması açısından önem arz etmeye başlamıştır. Bu enerji kaynakları içerisinde doğal gazda yukarıda da bahsedildiği gibi Körfez Savaşı sonrasında meydana gelen petrol krizinden sonra önemli bir talep artışı yaşanmıştır. Fakat doğal gaz rezervleri tüm ülkelere eşit bir şekilde dağılmamıştır. Rusya, İran, Cezayir, Türkmenistan gibi ülkelerde bolca bulunan rezervler birçok Avrupa ülkesinde yoktur. Bu nedenle doğal gazın ülkeler arasında akışı siyasi, sosyal ve çevresel boyutta önem arz etmektedir. Talebi tüm ülkelerde giderek arttığı için doğal gaz stratejik bir öneme sahiptir.

1.2. DOĞAL GAZIN TANIMI VE ÖZELLİKLERİ

Enerji kaynakları genellikle iki gruba ayrılmaktadır; yenilenebilir ve yenilenemeyen enerji kaynakları. Yenilenebilir enerji kaynakları doğada sürekli olarak var olan ve doğal süreç içerisinde devamlı yenilenen kaynaklardır. Bunlar; rüzgâr, güneş, su gibi doğal kaynaklardan elde edilir. Yenilenemeyen enerji kaynakları ise canlı kalıntılarından elde edilen fosil yakıtlardır. Çeşitli birincil enerji kaynakları vardır. Bunların içerisinde ilk akla gelenler petrol, kömür ve doğal gazdır (Kılıç, 2006: 1929).

Diğer fosil yakıtlar gibi doğal gaz da milyonlarca yıl önce yaşamış olan bitki ve hayvan gibi organik madde kalıntılarının ayrışması sonucu meydana gelmiştir. Bu kalıntılar çamur, silt ve kumla karışarak deniz tabanında yavaş yavaş gömülür. Oksijensiz bir ortamda yüksek miktarlarda basınca ve ısıya maruz kalan kalıntılar ayrışarak gaz haline gelir (Speight, 2018: 26). Genellikle yeraltında geçirimsiz tabakalar içinde gözenekli kayalar arasına sıkışmış, serbest halde veya petrol yataklarındaki kayaların içerisinde bulunan kokusuz, renksiz ve hafif bir gazdır (Öztürk, 2007: 4; Bayraç, 2018: 14).

Doğal gaz esas olarak en basit hidrokarbon olan metanı içerir fakat bunun yanında etan, propan ve temel olarak tüm bütan ve pentan izomerleri ile eser miktarda karbondioksit, nitrojen ve hidrojen sülfür gibi hidrokarbon olmayan molekülleri de içermektedir. (Balzani, Armaroli, 2010: 69). Bu enerji kaynağını oluşturan bileşenler ve oranları Tablo 1’de görüldüğü gibidir.

Tablo 1: Doğal Gaz Bileşenleri ve Oranları

Bileşen	İçerik Yüzdesi (%)
Metan	>85
Etan	3-8
Propan	1-5
Bütan	1-2
İzobütan	<0.3
Pentan	1-5
İzopentan	<0.4
Hekzan, Heptan ve Oktan	<2
Karbondioksit	1-2
Hidrojen Sülfür	1-2
Oksijen	<0.1
Nitrojen	1-5

Helyum	<0.5
--------	------

Kaynak: Speight (2018), s.5

Doğal gazın bileşimi menşei, bulunduğu gaz yatağının yeri ve jeolojik yapısına göre çeşitlilik göstermektedir. Fakat tabloda da görüldüğü üzere esas olarak metan gibi doymuş alifatik hidrokarbonlar içerir (Liang, Ryvak, Sayeed, Zhao, 2012: 1).

Geleneksel katı ve sıvı yakıtlar yanma esnasında atmosfere hem doğa hem de insan için zararlı etkileri bulunan gazlar yaymaktadırlar. Fakat doğal gaz, hava kirliliğinin temel sebeplerinden olan kükürt ve kükürtdioksit içermemesi nedeniyle kömür gibi diğer katı fosil yakıtlara göre daha temiz bir enerji kaynağı olarak değerlendirilmektedir (Gültekin, Örgün, 1993: 37-38). Bundan dolayı yakıt olarak kullanıldığında çok az veya neredeyse hiç partikül madde ortaya çıkarmaz.

Doğal gazı diğer fosil yakıtlardan ayıran ve talebinde artış meydana getiren en önemli nedenlerden birisi temiz yakıt olmasıdır. Bileşim özellikleri neticesinde yandığında diğer birincil kaynaklara göre daha temiz bir enerji açığa çıkarır. Çok az miktarda reaktif hidrokarbonlar yayar ve neredeyse hiç partikül madde açığa çıkarmaz. Kömür ve petrol ise yandığında nitrojen oksit, sülfür dioksit gibi yüksek seviyede zararlı emisyonlar yayar (Liang, Ryvak, Sayeed, Zhao, 2012: 1).

Doğal gazın kullanıldığında daha az zararlı emisyon yaymasının dışında bazı avantajları vardır. Bunları aşağıdaki gibi sıralayabiliriz (Aydın, 1999: 47; Balzani, Armaroli, 2010: 70);

- Kükürt içermediğinden dolayı yandığında alev veya duman ile temas eden yüzeylerde korozyon problemi oluşmamaktadır.
- Yapı olarak homojen olduğundan, içinde yanmayan madde bulunmadığından ve hava fazlalık katsayısı diğer yakıtlara göre daha düşük olduğundan dolayı yanma verimi %95-99 arasındadır.
- Daha temiz bir yakıt olduğundan dolayı diğer fosil yakıtlara göre yüksek talebe sahip olarak çevresel sürdürülebilirlik açısından fayda sağlamaktadır. Bu da ekolojik dengenin oluşmasına katkıda bulunmaktadır.

- Nispeten zehirsiz olmakla beraber havadan daha hafif olduğundan dolayı herhangi bir gaz kaçağı durumunda havalandırma bacaları gibi alanlardan kolaylıkla dışarı atılabilir, atmosfere yükselir ve dağılır.
- Yüksek ısı değeri ve temiz bir yakıt olması nedeniyle birçok sektörde (konutlar, sanayi, ulaşım vb.) kullanım alanı bulmaktadır.

Doğal gazın bahsedilen avantajlara sebep olan özellikleri aynı zamanda bazı dezavantajları da beraberinde getirmektedir. Bu dezavantajları şu şekilde sıralayabiliriz (Aydın, 1999: 47; Yükseltan, Yücekaya, Bilge, Aktunç, 2021: 1);

- Kapalı ortamlarda hava içerisindeki gaz oranı %5-15 arasında olduğunda patlayıcı özellik kazanmaktadır.
- Zehirsiz olmasına rağmen ortamdaki oksijen azalıp gaz miktarı arttığında boğulmalara sebep olabilir.
- Renksiz ve kokusuz olduğundan dolayı hissedilmesi zordur. Bu nedenle kokulandırılması gerekmektedir.
- Yapısı ve özellikleri gereği özel bir depolama gerektirdiğinden dolayı stoklanması maliyetli ve zordur. Uygun depolama alanları bulmak veya oluşturmak gerekmektedir.
- Ülkeler arasında tedariğinin sağlanması için gerekli altyapıyı kurmak yüksek yatırım gerektiren pahalı ve kritik bir süreçtir.


1.3. DOĞAL GAZ TEDARİK ZİNCİRİ

Küreselleşen ve artan nüfus miktarı ile tüketim yoğun bir toplum tarafından şekillenen dünyada tedarik zincirlerini tanımlamak, planlamak, tasarlamak ve kesintisiz operasyon sunacak şekilde oluşturmak oldukça önemlidir. Otomotiv sektöründeki bir parçanın, tekstil sektöründeki bir ham maddenin veya bir hızlı tüketim ürününün tedarik zinciri ile ilgili pek çok şey söylenebilir. Bu tedarik zinciri en basit haliyle ürünlerin üretilmesi için ham madde tedariğinden nihai ürünün müşteriye ulaştırılmasına kadar devam eden operasyonel bir süreçtir.

Gelenekselleşmiş bir tedarik zinciri yapısı içeren pek çok ürünün aksine doğal gaz tedarik zinciri karmaşık ve maliyetli bir yapıya sahiptir. Uzun süren ve uygun altyapı gerektiren farklı aşamalar içermektedir. İlk olarak uzmanlar tarafından doğal gaz ve

petrol yataklarında keşif işlemi yapılır ve uygun miktarda gazın varlığı tespit edildikten sonra bulunduğu yerden çıkarılır. Nakliyesine ve kullanıma uygun hale getirmek için çeşitli bileşenler ayrıştırılarak doğal gaz işleme işlemi yapılır. Sonraki aşamada üretim bölgelerinden tüketim noktalarına taşınması için güvenilir bir taşıma sistemine ihtiyaç duyulur. Bu taşıma sistemi genellikle boru hatlarından oluşmasının yanında farklı seçenekler de bulunmaktadır. Tüketim noktasına gelen doğal gaz hemen tüketilmeyeceğinden dolayı diğer birçok ürün gibi belirli süreler için depolanmaktadır. Bu depolama tesisleri yerel gaz şirketleri gibi tüketim merkezlerinin yakınında bulunabilir (Hamed, Farahani, Hussein, Esmailian, 2009: 800-802).

Şekil 1: Doğal Gaz Tedarik Zinciri Süreçleri



Kaynak: Hamed, Farahani, Hussein, Esmailian (2009), s.803

Şekil 2: Doğal Gaz Tedarik Zinciri Paydaşları İçin Kılavuz

Doğal Gaz Ağındaki Fiziksel Varlıklar	Şekil	Doğal Gaz Tedarik Zincirindeki Fiziksel Varlıklar	Doğal Gaz Ağındaki Fiziksel Varlıklar	Şekil	Doğal Gaz Tedarik Zincirindeki Fiziksel Varlıklar
Gaz ve Petrol Kuyuları		Tedarikçi	Gaz Enjeksiyon kuyusu		Tüketici
İthalat			Konutlar & Ticari Aboneler		
Rafineri		Üretici	Elektrik Santrali Tüketicileri		
Kompresör İstasyonu		Dağıtıcı	İhracat		
Şehir Kapı İstasyonu (CGS)			Depolama Tankı		Depo
Yerel Gaz Şirketi		Toptancı	Boru Hattı		Taşıma Modu

Kaynak: Hamed, Farahani, Hussein, Esmaeilian (2009), s.803

Hamed ve diğerleri (2009) altı seviyeli bir doğal gaz tedarik zinciri tanımlamışlardır. Şekil 1'e göre birinci seviyede iki tür tedarikçi vardır: (a) birinci tür tedarikçi ham madde sağlayan gaz ve petrol kuyuları ve (b) ikinci tür tedarikçi ise ithalat terminalleridir. Üreticiler olarak rafineriler zincirin ikinci seviyesindedir. Üçüncü seviyede ise birinci tip distribütörler olan kompresör istasyonları bulunmaktadır. Yerel gaz şirketleri ise toptancılar olarak tedarik zincirinin dördüncü seviyesini oluşturmaktadır. Beşinci seviyede ise şehir kapısı istasyonları vardır. Dağıtım yapan gaz kuruluşlarının gazı aldığı nokta ya da ölçüm istasyonu olan şehir kapısı istasyonları, tip iki distribütörlerdir. Altıncı seviyede ise dört tip tüketici grubu yer almaktadır. Bunlar; enjeksiyon petrol kuyuları, konutlar ve ticari aboneler, elektrik santralleri ve ihracat terminalleri (Hamed, Farahani, Hussein, Esmaeilian, 2009: 803).

Yukarıda tanımlanan doğal gaz tedarik zinciri yapısından hareket ile altı temel tedarik zinciri operasyonunun gerçekleştiği görülmektedir. Bunlar; doğal gazın keşfi, kaynağından çıkarılması, bazı bileşenlerin ayrıştırılarak işlenmesi/üretilmesi, dağıtım merkezlerine veya ihracat terminallerine taşınması, nihai tüketicilere dağıtılması ve son olarak depolanmasıdır.

1.3.1. DOĞAL GAZIN KEŞFİ

Doğal gaz ilk kez petrol arama faaliyetleri sırasında keşfedilmiştir. Bu nedenle doğal gazı keşfetmek için kullanılan yöntemler petrol keşfi için kullanılan yöntemler ile benzerlik göstermiştir. Doğal gaz endüstrisinin ilk zamanlarında gaz yataklarının yerini belirlemek için doğal gaz veya ham petrol sızıntıları gibi yeraltı oluşumlarının yüzey kalıntıları araştırılmıştır. Daha sonra doğal gaz yatağının varlığından emin olmak için keşif kuyuları açılmaya başlanmıştır. Fakat bu keşif kuyularının açılması pahalı ve zaman alıcı olduğundan dolayı gaz yatağı bulunan kuyuların yerini doğru tahmin etmek için yeni teknolojiler ve araştırma yöntemleri geliştirilmiş ve kullanılmıştır. Bunlar; jeolojik araştırma, sismik araştırma, manyetometre ve kuyu logudur (Speight, 2018: 29-33).

- a. **Jeolojik Araştırma:** Doğal gaz yatakları arama çalışmaları genellikle dünyanın yüzey yapısının jeolojik olarak incelenmesi ve gaz yatağının bulunma olasılığının yüksek olduğu alanların belirlenmesi ile başlar. Jeologlardan oluşan bir araştırma ekibi belirli alanların yüzey ve yeraltı özelliklerini araştırıp haritalandırarak bu alanların doğal gaz rezervi içermesi olasılığını tahmin edebilir. Rezerv içeren potansiyel bir yeraltı oluşumu tespit edildikten sonra daha ayrıntılı bilgiler elde etmek ve bu oluşumların doğru bir şekilde haritalandırılması için ileri teknikler kullanılabilir.
- b. **Sismik Araştırma:** Doğal gaz arama çalışmalarının hızlanması ve geliştirilmesindeki en büyük atılım sismolojinin kullanılmasıdır. Bu yöntem yer kabuğundaki enerjinin sismik dalgalar biçimindeki hareketini inceler ve yer kabuğunun bileşimi ile ilgili veri toplanmasına yardımcı olur.
- c. **Manyetometre:** Dünya'nın manyetik alanındaki küçük farklılıkları ölçerek jeolojik ve jeofiziksel veriler üretilmesini sağlayan bir cihazdır. Operasyonların daha hassas ve detaylı bir şekilde yürütülmesine yardımcı olarak oluşumlar arasındaki her türlü küçük farkı doğru bir şekilde ölçerek jeofizikçilerin yeraltı oluşumlarının yapısını anlamalarına ve bu oluşumların doğal gaz içermesi potansiyelini doğru tahmin etmelerine yardımcı olur.

- d. Kuyu Logu:** Bir kablo hattının ucuna yeraltı oluşumunun kaya ve sıvı özelliklerini ölçmek için kayıt aracı yerleştirilmesi ve bu kablo hattının doğal gaz veya petrol kuyusuna indirilmesi işlemidir. Bu ölçümlerden elde edilen veriler, potansiyel olarak doğal gaz veya petrol içeren sahaların yerini ve rezerv miktarını belirlemek için kullanılır.

1.3.2. DOĞAL GAZIN ÇIKARILMASI

Teknolojik gelişmeler sonucu elde edilen araştırma ve operasyon süreçlerini kolaylaştıran teknikler ve araçlar ile yeryüzündeki ve yeraltındaki yapıları inceleyen jeologlar gaz ve petrol olma ihtimali olan yerleri belirler. Belirlenen yerlerde bir kuyu açılıp açılmayacağı ile ilgili karar, gaz rezervuarının ekonomik özellikleri dahil birçok faktöre bağlıdır. Bu kararı vermek için uygun şartlar sağlandıktan sonra çalışma yapılacak en uygun sondaj sahasının belirlenmesi sondaj yapılacak oluşumun doğası, yeraltı jeolojisinin özellikleri ve potansiyel yatağın derinliği ve boyutu gibi birçok faktöre bağlıdır (Speight, 2018: 151).

Belirlenen uygun noktada makine ve matkaplar yardımı ile kuyu açılır ve matkap gaz yatağına ulaştırılır. Gaza ulaşım sağlandıktan sonra matkap çekilir ve gazın kontrollü olarak borudan akması sağlanır. Etkili bir altyapının ve operasyonun kurulmasını gerektiren doğal gazın çıkarılması işlemi karadan sondaj kulesi ve denizden sondaj platformu ile yapılmaktadır (Öztürk, 2007: 7-8). İşlenmemiş, saf bir halde çıkarılan bu gaz düşük basınçlı boru hatları aracılığıyla rafinerilere gönderilir.


1.3.3. DOĞAL GAZIN İŞLENMESİ

Kara veya denizde yapılan sondaj çalışmaları sonucu çıkarılan gaz, nihai tüketicinin kullanmakta olduğu gaz ile aynı değildir. Ham haliyle hem boru hatlarında taşınması hem de tüketici tarafından kullanılması uygun olmamaktadır. Hidrokarbon bileşimi türüne bakılmaksızın kuyudan çıkarılmış olan doğal gazdan su buharları ve katı kirleticileri uzaklaştırmak yani ham doğal gazı saflaştırılmak ve kurutmak için ön işlemler uygulanmaktadır.

Kaynağından çıkarılan gaz tüketicilere ulaştırılmak için uzun mesafeler ve geniş alanları kapsayan boru hatlarına aktarılmadan önce işlenmelidir. Bu işlemin temel

amacı gazı, kondensatı (yoğunlaşan sıvı), yoğunlaşmayan asit gazları ve suyu doğal gaz üreten bir kuyudan ayırmak ve bu sıvıları satış veya imha için uygun hale getirmektir (Mokhatab, Poe, Speight, 2018: 189).

Şekil 3: Basit Doğal Gaz İşleme Akış Şeması



Kaynak: Mokhatab, Poe, Speight (2018), s.190

İşleme prosesleri için doğal gaz üretim bölgesine kurulmuş olan merkezi proses fabrikalarına ham bir şekilde gelen doğal gaz, ilk olarak kendisini oluşturan bileşenlere ayrılma işleminden geçer. Şekil 3’te görüldüğü üzere bu işlem sıvı hidrokarbonlar, su ve katıları içeren farklı fazların birbirinden ayrılmasıdır. Bir sonraki aşama ise asit gazı işlemedir. Ağır hidrokarbonlara ve su buharına ek olarak doğal gaz genellikle çıkarılması gereken kirleticileri de içerir. Karbondioksit, hidrojen sülfür ve merkaptanlar gibi kükürt içeren türler tamamen veya kısmen uzaklaştırılması gereken bileşiklerdir. Bu bileşikler toplu olarak “asit gazları” olarak bilinir. Doğal gaz işlemedeki bir sonraki adım ise doğal gaz çiğ noktasının kontrolüdür. Spesifikasyonları karşılamak ve hidrat oluşumunu önlemek için bu işlem oldukça önemlidir. Hidratlar, boru hatlarında bulunan basınç ve sıcaklık koşullarında hidrokarbonlar ile su arasındaki reaksiyon sonucu oluşan katı bileşiklerdir. Bu bileşiklerin oluşumu boru hatlarının tıkanmasına ve beraberinde birçok soruna neden olduğundan dolayı doğal gaz endüstrisi için endişe kaynağıdır. Dehidrasyon işlemi ile

su uzaklaştırılmakta ve bu hidratların oluşumu önlenebilmektedir (Mokhatab, Poe, Speight, 2018: 190-192).

İşleme sürecinin beşinci aşamasında, doğal gaz sıvıları ayrıştırılır. Doğal gazın saflaştırılma sürecinde elde edilen doğal gaz sıvıları, önemli yan ürünlerdir. Bu yan ürünler etan, propan, bütan, izobütan ve pentanlardan oluşan hidrokarbonlardır. Bu bileşiklerin bazıları sıvılaştırılmış petrol gazı, bazıları ise doğal benzin bileşenleridir. Ayrıştırılan doğal gaz sıvıları, farklı kullanım alanları bulunan ve ayrı olarak satılan ürünlerdir. Bunlar, petrol kuyularının verimini artırmak, rafineriler ve petrokimya fabrikalarında hammadde olarak kullanmak, enerji kaynağı olarak kullanmak gibi birçok farklı alanda kullanılmaktadır (Çevrimiçi 2).

İlgili prosesler neticesinde kuru hale getirilen gaz, tipik bir satış boru hattı basıncından daha düşük basınçlarda üretilir ise satış gazı basıncına sıkıştırılır. Bu sıkıştırmanın satış gazı basıncına ulaşması için birkaç aşama gerekir. Taşınmak için uygun hale gelen gaz boru hatlarına aktarılır. Kullanılabilir bir boru hattının olmadığı durumlarda ayrılmış ilgili gaz yakılabilir veya nihai geri kazanım ve satış için üretim oluşumlarına sıkıştırma ve yeniden enjeksiyon yoluyla korunabilir. Ayrıca gaz yoğunlaşma rezervuarlarında, rezervuardan değerli sıvı hidrokarbonların daha yüksek net geri kazanımını sağlamak amacıyla gaz genellikle yeniden enjekte edilir veya döngüye sokulur (Mokhatab, Poe, Speight, 2018: 193).

1.3.4. DOĞAL GAZIN TAŞINMASI

Kaynağı her ülkede bulunmayan ve çoğunlukla ithal edilen, genellikle tüketim noktalarına uzak yerlerde keşfedilen ve çıkarılan doğal gazın, etkili ve verimli bir şekilde üretim noktasından tüketim noktasına aktarılması için geniş çaplı ve ayrıntılı bir taşıma sistemi kurulması ihtiyacı doğmuştur. Bu sistemin kurulması doğal gazın enerji kaynağı olarak kullanım oranını da arttırmıştır. Çoğunlukla boru hatları ile taşınan doğal gaz LNG, CNG, NGH gibi farklı şekillerde de taşınmaktadır.

1.3.4.1. BORU HATTI İLE TAŞIMA

Boru hattı taşımacılığı doğal gazın taşınması için kullanılan en eski ve en yaygın yöntemdir. Ekonomik olarak uygulanabilir olması için büyük ve yüksek değerli

pazarlara ve kanıtlanmış rezervlere ihtiyaç duyar. Bu rezervler tespit edildikten ve uygun pazar oluşturulduktan sonra gazı rafinerilere iletmek, tüketicilere dağıtmak ve ülkeler arası dolaşıma sokmak için yeraltı, yeryüzü ve deniz altından geniş çaplı borular ile kapsamlı bir taşıma sistemi kurulmaktadır (Najibi vd., 2009: 2009-2010).

Yeryüzünde inşa edilecek boru hattının geçeceği güzergâh ağaçlar, çalılar, kayalar gibi inşaatı engelleyebilecek her türlü malzemeden arındırılır. Yol temizlendikten sonra hat boyunca genellikle 12-24 metre uzunluğunda olan boru bölümleri döşenir. Döşenen borunun yanında hendekler kazınır ve borular bu hendeklere uygun ekipmanlar kullanılarak indirilir ve hendeklerin üzeri boru hattının zarar görmemesi için kapatılır. Akarsular veya nehirler boyunca boru hattı döşemek için de iki yol vardır. İlk olarak boruyu yerleştirmek için nehrin tabanına hendekler açılabilir. Bu durumda, borunun kendisine beton bir kılıf takılır. Bu hem borunun nehrin dibinde kalmasını sağlar hem de suya gaz sızıntısını önlemek için bir korucuyu görevi görür. İkinci bir yol ise nehrin altında, içinden borunun geçebileceği bir tünelin açıldığı tek yönlü sondajdır. Boru hatları döşendikten ve üzeri kapatıldıktan sonra hattın geçtiği yolu orijinal durumuna geri getirmek ve inşaat süresince meydana gelebilecek çevresel veya diğer etkileri önlemek için yoğun bir çaba gerekir (Çevrimiçi 3).


Taşıma güzergahı boyunca üç ana boru hattı vardır; toplama sistemi, eyaletler arası boru hattı ve dağıtım sistemi. Toplama sistemi, ham gazı çıkarıldığı kuyudan işleme tesisine taşıyan düşük basınçlı ve küçük çaplı boru hatlarından oluşur. Eyaletler arası boru hatları ise gazın bazı endüstriyel kullanıcılar, ticari hizmet veren işletmeler ve enerji üretim müşterileri tarafından doğrudan alındığı yüksek kapasiteli hatlardır. Dağıtım sistemi gazın son kullanıcılara ulaştırılmasındaki en son adımdır. Bu operasyon genellikle belirli bir coğrafyada tüketicilere doğal gaz dağıtımını yapan LDC tarafından gerçekleştirilir (Hamed, Farahani, Hussein, Esmailian, 2009: 802).

Boru hatları doğal gazın tüm dünyada yaygın bir şekilde kullanılmaya başlanan enerji kaynağı olması ile uluslararası bir altyapıya ihtiyaç duymuştur. Ülkeler arası siyasi krizler, coğrafi yapı nedeniyle karşılaşılan zorluklar, yüksek altyapı maliyetleri gibi sorunlar boru hattı taşımacılığı dışında taşıma sistemlerinin geliştirilmesine yol açmıştır.

1.3.4.2. SIVILAŞTIRILMIŞ ŞEKİLDE TAŞIMA (LNG)

Doğal gazın sıvı hali olan LNG teknolojisi 1970'lerin ortalarından beri etkin bir şekilde kullanılmaktadır. 2011 yılındaki Fukushima nükleer kazasından beri temiz enerji ile ilgili farkındalığın artması ile doğal gazın deniz aşırı taşımacılığı için popüler bir ulaşım çözüm olarak LNG'ye olan talep hızla artmıştır (Lee, Seo, Lee, Chang, 2016:405). Boru hattının yapılamaması, doğal gaz kaynaklarının uzaklığı, teknolojik, ekonomik, siyasi ve stratejik sebepler de LNG taşımacılığının giderek yaygınlaşmasında etkili olmuştur (Mokhatab vd., 2018: 19; Öztürk, 2007: 25).

Şekil 4: LNG Tedarik Zinciri



Kaynak: Grønhaug ve Christiansen (2009), s.198

LNG tedarik zinciri beş ana süreçten oluşur. Bunlar; doğal gaz üretimi, sıvılaştırma süreci, nakliye, yeniden gazlaştırma ve dağıtım (Economides, Sun, Subero, Houston, 2006: 318-319). Şekil 4'te görüldüğü üzere LNG tedarik zinciri, gaz kaynağından çıkarıldıktan sonra gazı sıvılaştırma prosesi ile başlar. Doğal gaz yaklaşık -160 derecede sıvılaşır. Gazın bu şekilde LNG'ye dönüştürülmesi, gazı hacminin altı yüzde birine (1/600) indirerek, uzun mesafelerde özel LNG tanker gemileri ile taşınılabilir hale getirir (Subero vd., 2004:2). Bu gemiler hem güvenlik hem de izolasyon amaçlı kullanılan çift cidarlı gemilerdir. LNG, gemi alıcı limana vardığında iyi yalıtılmış depolama tanklarına boşaltılır. Tüketicinin kullanımına uygun hale getirmek için gaz haline dönüştürme prosesi gerçekleştirilir. Yeniden gazlaştırma olarak adlandırılan bu süreç LNG'yi nihai olarak son kullanıcıya teslim edilen gaz formuna dönüştürmek için yapılır (Speight, 2018: 171). Gaz formuna dönen LNG, boru hatları ile nihai tüketicilere ulaştırılır.

LNG yüksek hacimli ve uzun mesafeli taşımalara olanak sağlamanın yanı sıra pek çok avantaja sahiptir. Bunlar; araçlarda yakıt olarak kullanıldığında benzin ve dizel yakıtlarla karşılaştırılabilir bir enerji yoğunluğu sunması, menzili uzatması ve yakıt ikmal sıklığını azaltmasıdır (Taheri vd., 2014: 846; Speight, 2018: 169). Bunların yanı sıra bazı dezavantajları da vardır. LNG ticaretinin yapılması için, ihracatçı ülkenin sıvılaştırma ve ihraç terminallerine, ithalatçı ülkenin de depolama, yeniden gazlaştırma ve LNG ithalatı operasyonlarının gerçekleştirileceği terminallere ihtiyacı vardır. Temel altyapı gereksinimlerinin ve LNG işleme ve üretim tesislerinde kullanılan, özel olarak imal edilmesi gereken taşıma araçlarının maliyeti bu dezavantajlardan bazılarıdır (Economides, Sun, Subero, Houston, 2005: 319; Brzeziński, 2007: 109).

Bahsi geçen dezavantajlarına rağmen termodinamik verimliliklerinin büyük ölçüde gelişmesi nedeniyle LNG tesisi inşa etmenin maliyeti 1980'lerden beri oldukça azalmıştır. Böylece doğal gazın sıvılaştırılması dünyada önemli bir gaz ihracat yöntemi haline gelmiştir (Mokhatab vd., 2018: 20).

1.3.4.3. SIKIŞTIRILMIŞ ŞEKİLDE TAŞIMA (CNG)

1960'larda CNG teknolojisini uygulamak için yapılan girişimler, teknik zorluklar ve yüksek maliyetli yatırımlar ile karşılaşmıştır. Bu nedenle CNG'nin başlangıçta nispeten yakın yerlere küçük hacimlerle taşınması hedeflenmiştir. Fakat teknolojideki son gelişmeler CNG'nin büyük hacimlerle daha uzun mesafelere maliyet etkin bir şekilde taşınmasına olanak sağlamıştır (Dunlop, White, 2003: 1). 1990'ların sonlarına doğru David Stenning ve Jim Cran tarafından "Coselle" adı verilen yeni bir tür basınçlı muhafaza kabının keşfi ve geliştirilmesi ile doğal gaz taşıma teknolojisi alternatifi olarak CNG tekrar gündeme gelmiştir. Bu yüksek basınçlı gaz depolama ve taşıma sistemi, çelik kirişli bir karusele oturan görece küçük çaplı büyük bir boru bobinidir. Tipik bir CNG gemisi, 330 MMscf gaz kapasitesine sahip 60000-DWT'lik bir dökme yük gemisidir (Economides, Sun, Subero, Houston, 2005: 319). CNG projelerinde sermaye yatırımının çoğu gemilerin inşasına harcanmaktadır. LNG'nin gerektirdiği karmaşık ve sermaye yoğun bir altyapıya ihtiyaç olmadığından yükleme ve boşaltma terminalleri için gerekli altyapı yatırımı daha az maliyetlidir (Subero vd., 2004: 2).

Deniz yolu ile taşınmasının yanı sıra özel kamyon, çekici ve tırlar vasıtası ile taşınarak da kullanıcılara ulaştırılmaktadır (Öztürk, 2007: 27).

Yüksek basınçlarda sıkıştırılmış olan CNG bazı ülkelerde geleneksel yakıtlara alternatif olarak kullanılmaktadır. Normal atmosferik basınçta kaplayacağı hacmin %1'i ile 3000 psi üzerinde sıkıştırılan doğal gaz, uygun şekilde modifiye edilmiş içten yanmalı bir motorda yakılabilir. CNG kullanan araçlar daha az karbonmonoksit, nitrojen oksit ve partikül madde salar. Bununla birlikte enerji yoğunluğunun sıvı yakıtlara göre düşük olması bir dezavantaj yaratmaktadır. Bir galon CNG bir galon benzindeki enerjinin yaklaşık dörtte birine sahiptir ve bu sebeple CNG ile çalışan araçlar daha büyük yakıt depolarına ihtiyaç duymaktadır. Bu da CNG'yi kamyon ve otobüs gibi büyük araçlar için daha uygun hale getirmektedir (Speight, 2018: 176-177).

1.3.4.4. DOĞAL GAZ HİDRAT OLARAK TAŞIMA (NGH)

Hidrokarbon gazları ve su arasındaki reaksiyon sonucu oluşan doğal gaz hidratlar boru hattında tıkanmalara neden olduğu için istenmeyen bir oluşum iken, LNG ve boru hatlarına alternatif bir taşıma sistemi olarak değerlendirilmeye başlanmıştır. Gazın katı bir şekilde taşınmasına olanak sağlayan bu yöntem doğal olarak oluşmasının yanı sıra kasıtlı bir şekilde doğal gaz ve suyun 80-100 bar ve 2-10 C° karıştırılması ile oluşturulabilir. Diğer taşıma teknolojileri ile karşılaştırıldığında daha düşük sermaye ve işletme maliyetlerine sahiptir (Thomas, Dawe, 2003: 1468-1469). Doğal gazın hidrat olarak taşınması süreçleri Şekil 5'te gösterilmektedir.

Şekil 5: Doğalgazın Hidrat Olarak Taşınması



Kaynak: Merey, Longinos (2018), s.944

1.3.5. DOĞAL GAZIN DEPOLANMASI

Doğal gazın uygun alanlarda depolanmasını önemli hale getiren iki temel konu vardır. İlk olarak, farklı kullanım alanlarında doğal gaza olan talebin artması ile özellikle doğal gaz piyasası giderek büyüyen ülkelerin ithalata daha fazla güvenmek zorunda olmasıdır. İkincisi ise doğal gaz taşıma altyapılarında meydana gelen herhangi bir hasarın müşteriler için yüksek maliyetli sonuçları ile daha yüksek gaz fiyatlarına veya arzda kesintilere sebep olmasıdır. Bu iki sorunun üstesinden gelmek için doğal gazın depolanması etkili bir çözüm sunmaktadır (Teatini vd., 2011: 1). Yeraltında ve yerüstünde olmak üzere iki temel depolama yöntemi bulunmaktadır.

1.3.5.1. YERALTINDA DEPOLAMA

Doğal gazın yeraltında depolanması ile ilgili ilk başarılı girişim 1915 yılında Kanada'nın Ontario eyaletinde bulunan Welland'de gerçekleşmiştir. Kanada Ulusal Akaryakıt Şirketi kısmen tükenmiş olan bir gaz alanındaki bazı kuyuları yenilemiş ve

bölgedeki basıncı oluşturmak için gaz enjekte etmiştir. Bu ilk girişimin etkisi ile farklı doğal gaz depolama çalışmaları gerçekleştirmeye başlamıştır. Iroquois Gaz şirketi 1916 yılında New York'un Buffalo şehrindeki Zoar bölgesinde, dünyanın en uzun süre işletilen yeraltı depolama tesisi olarak tarihe geçmiş olan Zoar depolama tesisini açmıştır. 1919 yılında Kentucky'de ve 1920 yılında Pennsylvania'da da benzer denemeler yapılmıştır (Knepper ve Cuthbert, 1979: 2). Türkiye'de ise ilk olarak 1988 yılında Rusya'dan gelen gazı depolamak için BOTAS bünyesinde kurulan Yeraltı Depolama Koordinatörlüğü birimi doğal gazın yeraltında uygun bir şekilde depolanmasını ve Türkiye'nin bu konudaki potansiyelini araştırmaya başlamıştır (Öztürk, 2007: 34).

Keşif ve taşıma sistemlerindeki teknolojik gelişmeler sonucunda hızla büyümeye başlayan doğal gaz endüstrisi nedeniyle gazın depolanması, farklı kullanım alanlarına kesintisiz bir şekilde hizmet sağlanması açısından gaz teslim sisteminin oldukça önemli bir parçası haline gelmiştir. Özellikle konutlar tarafından tüketilen gazın mevsimsel talep değişkenliğine sahip yapısı depolama ihtiyacını öne çıkaran faktörlerdendir. Bu sezonsal talep değişiklikleri ve arz talep dengesi yeraltı depolama ile kontrol altına alınmaktadır. Taşıma ve dağıtım sistemi içerisinde büyük yeri olan boru hatlarında meydana gelecek herhangi bir bozulmanın yaratabileceği kesintiyi güvence altına almak için de yeraltı depolama önemli bir seçenek ve stratejik bir rezervdir. Ayrıca korumalı, oksijensiz bir yeraltı sahasında depolama yapılması yangın veya patlama risklerini büyük ölçüde azaltmaktadır (Türeyen, Karaalioğlu, Satman, 2000: 1).

Yukarıda bahsedilen doğal gazı yeraltında depolama motivasyonunu oluşturan faktörler ve bazı avantajları dışında doğal gazı yeraltı tesislerinde depolamanın farklı avantaj ve dezavantajları vardır. Bunlar şu şekilde sıralanabilir (Öztürk, 2007: 47);

Avantajları:

- İnşa etmek ve işletmek yerüstü depolamaya göre daha ekonomiktir.
- Depolama için ihtiyaç duyulan alan daha küçüktür.

- Yeraltı depolama sahasının bulunduğu jeolojik yapı hem dışardan gelebilecek tehlikelere karşı hem de işletme hatlarından doğan sorunlara karşı koruma sağlar.
- Depolama işlemi yeraltında gerçekleştiğinden dolayı tesislerin yapıldığı çevrede yaratacağı zarar azalır.

Dezavantajları:

- Doğal gazın su ve istenmeyen bazı bileşikler ile karışma ihtimali vardır ve bu durumda geri üretimde sorun çıkmaktadır.
- Depolama yapılması için gerekli özelliklere sahip alanlar her yerde bulunmamaktadır.
- Geri üretim daha yavaş olmaktadır.

Dört tip yeraltı doğal gaz depolama alanı vardır. Bunlar; tükenmiş petrol ve gaz rezervuarları, akiferler, tuz yatakları/mağaraları ve terk edilmiş maden ocaklarıdır. Doğalgaz depolama tesislerini birbirinden ayıran dört temel özellik vardır. Bunlar; temel gaz ve çalışma gazı kapasiteleri, teslim edilebilirlik, enjeksiyon kapasitesi ve çevrim. Temel gaz, rezervuarda yeterli basınç miktarını korumak için gereken gazdır ve genelde hiçbir zaman çıkarılmaz. Çalışma gazı ise üretilip satılabilen gaz miktarıdır. Teslim edilebilirlik rezervuarın rezervlerinden gaz salma oranını ifade eder. Bir tesisin teslim edilebilirliği, rezervuar en yüksek kapasiteye yakın olduğunda yüksek ve rezervuar en düşük kapasiteye yakın olduğunda ise düşüktür. Enjeksiyon kapasitesi doğalgazın daha sonra kullanılmak üzere depoya pompalanabileceği hızı ifade eder. Teslim edilebilirliğin tam tersi olarak enjeksiyon hızı, rezervuar en yüksek kapasiteye sahipken en düşük ve rezervuar boşken en yüksektir. Çevrim ise çalışma gazı hacimlerinin bir yıl içinde kaç kez enjekte edildiğini ve çekildiğini göstermektedir (Thompson, Davison ve Rasmussen, 2009: 226-227).

1.3.5.1.1. TÜKENMİŞ PETROL VE GAZ REZERVUARLARINDA DEPOLAMA

Bu tesislerden daha önce doğal gaz veya petrol çıkarılmış olduğu için depolanan doğal gazın oluşumundaki yapıya benzerler. Tükenmiş petrol ve gaz rezervuarlarında zaten

önceden doğal gaz çekildiğinden dolayı gazı tutabilen gözeneklilik ve geçirgenliğe sahip bir depolama sahası da oluşmuş olur. Eski bir rezervuarın verimli olduğu dönemden kalan çıkarma ve dağıtım ekipmanına sahip olunması bu rezervuarı bir depolama tesisine dönüştürmenin maliyetini en aza indirmektedir. Bu durum yeni bir depolama alanı araştırmanın da olası maliyetlerini azaltmaktadır (Speight, 2018: 159-160).

Kullanılacak eski rezervuarın belirli jeolojik ve coğrafi özelliklere sahip olması gerekmektedir. Bunlar (Öztürk, 2007: 35-36; Speight, 2018: 160);

- Depolanması gereken miktara uygun kapasitede olmalıdır.
- Tüketim bölgelerine ve boru hatları, dağıtım sistemlerini içeren taşıma altyapısına yakın olmalıdır.
- Uygun geçirgenlik ve gözeneklilik değerlerine sahip olmalıdır.
- Gazın yatay hareketinin engellenmesine yardımcı olacak jeolojik bir engel olmalıdır.
- Gazın yukarıya doğru hareketini, sızıntıları ve basınç kayıplarını önlemek için geçirimsiz bir örtü tabakaya ihtiyaç vardır.
- Su girişi veya sızıntısı olmamalıdır.

Bu depolama tesisleri genellikle mevsimsellik etkisi ile değişen talepleri karşılayabilmek için yeterli miktarda doğal gazın depolanmasına imkân verir ve yüksek bir çalışma hacmi sağlar. Bununla birlikte düşük teslim edilebilirlik ve enjeksiyon oranlarına ve yılda bir veya en fazla iki kez çevrim yapma yeteneğine sahiptir (Erdoğan, 2011: 26; De Jong, 2015: 366).

1.3.5.1.2. AKİFERLERDE DEPOLAMA

Doğal su rezervuarları gibi işlev görebilen akiferler, gözenekli ve geçirgen bir yapıya sahip yeraltı kaya oluşumlarıdır. Su taşıyan bir tortul kaya geçirimsiz bir örtü kaya ile kaplandığında doğal bir akifer oluşur ve gaz depolama için uygun bir alan meydana gelir. Genellikle tükenmiş petrol ve gaz rezervuarlarından daha pahalı bir oluşum sürecine sahip olduğundan dolayı tükenmiş rezervlerin olmadığı durumlarda bir seçenek olarak değerlendirilmektedir (Speight, 2018: 160-161).

Akiferlerin içerisi doğal olarak su ile dolu olduğundan dolayı yerleşik olarak bulunan suyu aşağı itmek ve doğal gazı enjekte etmek gerekir. Akifer içerisinde daha önce hiç gaz bulunmadığından dolayı enjekte edilen gazın çoğu fiziksel olarak geri kazanılamaz. Böylece akiferler %80'e varan bir oran ile son derece yüksek bir temel gaz gereksinimine ihtiyaç duyar. Teslim edilebilirlik, çalışma çevrim hızı ve enjeksiyon kapasitesi tükenmiş rezervuarlar ve tuz mağaralarının arasındadır (Speight, 2018:161; Thompson, Davison ve Rasmussen, 2008: 227).

1.3.5.1.3. TUZ YATAKLARINDA DEPOLAMA

Tuz mağaralarında doğal gaz depolaması ilk olarak I. Dünya Savaşı sırasında Almanya'da gerçekleşmiş ve daha sonra dünyaya yayılmıştır (Erdoğan, 2011: 19). Bu mağaralar mevcut tuz birikintilerinden meydana gelir. Yeraltı tuz birikintileri iki biçimde var olabilir: tuz kubbeleri ve tuz yatakları (Speight, 2018: 161). Tuz kubbesi veya tuz yatağının gaz depolama için değerlendirmeye alınmasında üç önemli kriter vardır (Öztürk, 2007: 37-38);

- Depolama için uygun derinliklerde tuz kalınlığı olmalıdır.
- Kolay çözünebilen ve nispeten daha zor çözünebilen yapıların bir arada bulunması deponun geometrik yapısında düzensizliklere sebep olacağından dolayı tuz domundaki mineral dağılımı homojen olmalıdır.
- Depolama için gerekli boşluğu oluştururken tuz eritme işlemi için yeterli tatlı su ve bu işlemin sonunda oluşan tuzlu suyun atılacağı uygun bir yer olmalıdır.

Tuz kubbesi veya tuz yatağı yukarıda bahsedilen nitelikleri karşıladığında ve depolama için uygun görüldüğünde oluşum içerisinde bir tuz mağarası geliştirmek gerekmektedir. Tortu içerisinde bir kuyu açılarak bu kuyudan içeriye verilen su birikintideki tuzun bir kısmını çözer. Tuzu çözen su daha sonra yüzeye geri pompalanır. Mağara istenilen büyüklüğe gelene kadar tatlı su ile tuz yatağı içerisinde uygun alan açma işlemi devam eder (Speight, 2018: 162). Oluşan tuz mağarasının duvarları çelik kadar sağlam bir yapıya sahip olduğundan dolayı depolama tesisinin kullanıldığı süre boyunca rezervuar bozulmasına karşı direnç sağlar (Çevimiçi 4).

Tuz mağarası depolama tesisleri çok düşük temel gaz gereksinimine, yüksek dağıtım kapasitesine, yüksek enjeksiyon oranına ve yılda dört veya beş defaya varan yüksek döngü özelliklerine sahiptirler (Thompson, Davison ve Rasmussen, 2008: 227). Ayrıca tuz mağaraları acil durumlarda veya beklenmedik kısa vadeli talep dalgalanmaları sırasında kısa bir süre içerisinde gaz akışını başlatabilir (Speight, 2018: 162).

Doğal gazın yeraltında depolama tesislerinin karşılaştırılmalı bir şekilde analizi Tablo 2’de gösterilmektedir.

Tablo 2: Yeraltı Depolama Tesisleri Karşılaştırması

Faktör	Boş Petrol ve Gaz Yatakları	Akiferler	Tuz Mağaraları
Temel Kullanım	Sınırlı çok döngülü Mevsimsel Stratejik	Mevsimsel Stratejik	Çok döngülü
Avantajları	Düşük maliyet Yüksek kapasite	Yüksek kapasite	Yüksek enjeksiyon ve çekme oranları Düşük temel gaz
Dezavantajları	Fazla temel gaz gereksinimi Düşük enjeksiyon ve çekilme oranları	Yüksek maliyet Potansiyel çevresel itirazlar	Düşük hacimler Tuz kontaminasyon riski Yüksek işletme maliyeti

Kaynak: Gürol (2019), s.34

1.3.5.2. YERÜSTÜNDE DEPOLAMA

Doğal gaz genellikle yeraltında depolanmasının dışında yerüstünde boru hatlarında, sıvılaştırılmış (LNG) şekilde özel tanklarda ve yüksek basınçlı tanklarda depolanmaktadır.

1.3.5.2.1. BORU HATTINDA DEPOLANMASI

Mevcut boru hattı şebekelerinden, talebin düşük olduğu dönemlerde az miktarda ve kısa bir süre için doğal gazı depolamak, talebin arttığı dönemlerde ise arz miktarını sağlayabilmek amacıyla depolama tesisi olarak yararlanılır. Birkaç saat gibi kısa sürede değişen talepleri karşılamak için faydalı bir sistem sunan boru hatları depolaması hat basıncını ayarlayarak yapılır. Doğal gaz, boru hattının bir ucundan basınç ile verilir ve bu miktar ayarlanabilir. Verilen gaz nispeten daha az basınç içeren diğer uca doğru hareket eder ve kullanım noktası olan bu uçta gaz miktarı ayarlanamaz ve anlık olarak değişebilir. Talebin az olduğu dönemlerde boru hattının şişmemesi ve sağlam kalması için boru hatlarında belli bir miktar gaz birikecek şekilde çap ve basınca dayanıklı et kalınlığı seçilmelidir. Bölgesel basınçlandırma merkezi boru hattı şebekesini depolama alanı olarak kullanmak için sistem içerisindeki basıncı yükselterek hattın içerisindeki gaz miktarını artırır. Talep arttığı zaman depolanan gaz basınç azaltılıp gaz akışı sağlanarak kullanıma sunulur (Öztürk, 2007: 31; Erdoğan, 2011: 17).

1.3.5.2.2. LNG OLARAK DEPOLANMASI

Doğal gazın sıvılaştırılması gazın hacmini 1/600 oranında azalttığından dolayı depolama için önemli bir avantaj oluşturmaktadır. Özel depolama tankları ile deniz aşırı bir şekilde taşınabilir olması, ihtiyaç duyulması halinde hızlı bir şekilde depodan çekilebilmesi ve yeraltı tesisine göre daha kısa zamanda depolama için uygun tesisin oluşturulması LNG depolamanın avantajlarından. Özel depolama tanklarının yapım ve alım maliyetlerinin fazla olması, çok büyük miktarlarda depolama yapılamaması ve nakliye için ihtiyaç duyulan zaman nedeniyle depoya ancak belirli dönemlerde gaz doldurulması ise dezavantaj oluşturan faktörlerdir (Öztürk, 2007: 41-42).

1.3.5.2.3. CNG OLARAK YÜKSEK BASINÇLI TANKLARDA DEPOLAMA

Doğal gazın taşınması için bir yöntem olarak geliştirilen gazın sıkıştırılması depolama için de bir seçenek oluşturmaktadır. Gazın yüksek basınca dayanıklı tanklar içinde sıkıştırılması ile depolama işlemi gerçekleştirilir. Fakat boru hatları gibi bu yöntem de

mevsimsel talep dalgalanmalarını karşılayabilecek düzeyde değildir. Kurulum ve işletim maliyetleri de yeraltı depolama tesisleri ile karşılaştırıldığında oldukça yüksektir. Bu da CNG yöntemini depolama için zayıf bir seçenek haline getirmektedir (Erdoğan, 2011: 18).

1.3.6. DOĞAL GAZIN DAĞITILMASI

Doğal gaz nihai tüketicinin kullanması için uygun hale getirildikten sonra iletim sisteminden tüketim noktalarına dağıtılmaya başlanır. Tedarikçilerden alınan doğal gaz büyük çaplı ve yüksek basınçlı boru hattı iletim sistemi aracılığı ile dağıtım merkezlerine getirilir. Daha sonra doğal gazı iletim sisteminden alan ve küçük çaplı boru hatları aracılığı ile müşterilere teslim eden daha düşük basınçlı bir boru hattı sistemi oluşturulur (Üster, Dilaveroğlu, 2014: 57). Sanayi kuruluşları, ticari hizmet veren işletmeler ve enerji üretim tesisleri gibi gaz tüketim hacmi yüksek olan işletmeler gazı direkt olarak boru hatlarından alırken küçük tüketiciler yerel yönetimlerin veya özel yatırımcıların mülkiyetinde bulunan yerel dağıtım şirketlerinden alırlar. İletim sisteminden gelen gaz “şehir kapısı” teslim noktasından yerel dağıtım şirketlerine aktarılır. LDC’ler daha sonra şehir kapısından alınan gazın mülkiyetine sahip olurlar ve gazı tüketiciye dağıtma hakkını elde ederler. Bu noktada kapsamlı bir küçük çaplı ve düşük basınçlı dağıtım boru hattı inşasına ihtiyaç duyulur. Bu boru hatları, büyük çaplı boru hatlarının inşasına benzer bir şekilde inşa edilmektedir. Kilometrelerce inşa edilen boru hatları, LDC’lerden doğal gaz alan küçük tüketiciler için doğal gaz maliyetlerinin büyük bir kısmını oluşturmaktadır. Önceleri sert çelikten yapılan borular kullanılırken teknolojinin gelişmesi ile esnek, plastik ve oluklu paslanmaz çelik boru kullanılmaya başlanmıştır. Kullanılan yeni boru türleri yerel dağıtım işletmeleri için esnek bir kurulum sağlamış ve maliyetlerin azalmasına neden olmuştur. Dağıtım sisteminin kurulumunun daha düşük maliyet ile inşa edilmesi, nihai tüketicilerin de doğal gazı alırken katlandıkları maliyeti azaltmıştır (Liang, Ryvak, Sayeed, Zhao, 2012: 20).

1.4. DOĞAL GAZIN KULLANIM ALANLARI

Doğal gaz, uygun bir tedarik zinciri altyapısı tasarlandıktan sonra ve bir enerji kaynağı olarak değerlendirilebileceği alanlar keşfedildikçe kendisine farklı sektörlerde, farklı

şekillerde ve farklı talep yapıları içerisinde kullanım alanı bulmuştur. Diğer fosil yakıtlara göre daha çevreci olması ve keşfedilmesi, işlenmesi, taşınması, depolanması, dağıtılması süreçlerinde yaşanan gelişmeler neticesinde bu süreçlerin hızla ve kolayca yapılması doğal gaz kullanım alanlarını genişletmiş ve talep miktarını artırmıştır. Bugün konutlarda, elektrik santrallerinde, sanayi içerisinde imalat işletmelerinde, ticari hizmet veren işletmelerde, toplu taşıma veya bireysel araçlarda doğal gaz enerji veya hammadde olarak kullanılmaktadır.

1.4.1. ENERJİ SEKTÖRÜ

Tüm dünyadaki en önemli enerji formu elektriktir. Birçok sistemin işleyebilmesi ve operasyonun devam edebilmesi için elektrik enerjisinin kesintisiz bir şekilde akışı sağlanmalıdır. Bu enerjinin üretilmesi ise bazı fosil veya yenilenebilir kaynaklar aracılığı ile yapılmaktadır. Kömür, doğalgaz, petrol, nükleer gibi fosil yakıtlar ve su, güneş, rüzgâr, jeotermal gibi yenilenebilir kaynaklar elektrik enerjisinin üretiminde kullanılmaktadır (Bilim, 2016: 146).

Sanayi devrimleri ile artan üretim hacimleri beraberinde büyük bir enerji ihtiyacı ortaya çıkarmıştır. Üretim için gerekli makine, teçhizatın çalışması ve operasyonların işleyişinin devamı için önemli olan elektrik enerjisi o zamanlarda genellikle kömür ile karşılanmaktaydı. Birim maliyetinin daha az olması bu kullanımı desteklemekteydi. Fakat son zamanlarda sürdürülebilirlik bilincinin oluşmaya başlaması ve beraberinde gelen değişim ile çevreye daha az zararlı fosil yakıt olan doğal gaz elektrik enerjisi üretiminde kullanılmaya başlanmıştır. Doğal gaz kullanan enerji santralleri genellikle doğrudan yanma süreci sonucunda çıkan sıcak egzoz gazlarını kullanarak gaz türbinlerinde elektrik üretir. Bu santraller hızlıca açılıp kapatılabildikleri için kömür santrallerinden daha fazla işletme esnekliğine sahiptirler (Speight, 2018: 18).

1.4.2. KONUTLAR

Doğal gaz konut tüketicileri için genellikle hem ısınma hem de yemek pişirme amacı ile kullanılmaktadır. Her iki kullanım için de bazı fırsatlar sunmaktadır. Pişirme için kullanıldığında kolay sıcaklık kontrolü, kendi kendine tutuşma ve kendi kendini temizleme gibi avantajlar sağlar. Diğer fosil yakıtlara oranla daha temiz olması da

doğal gazı ısınma için önemli bir seçenek haline getirmektedir. Bunların dışında bazı klima sistemlerinde de doğal gaz kullanılmaktadır. Bu sistemler elektrikli olanlar ile karşılaştırıldığında daha maliyetlidirler fakat beklenen çalışma ömürleri daha uzundur ve daha az bakım gerektirirler (Liang, Ryvak, Sayeed, Zhao, 2012: 2-3). Doğalgazın konutlarda ısınma amaçlı kullanılması, doğal gaz talep tahmini için önemli bir değişkendir. Mevsimsellik bulunan bu talep yapıları en doğru şekilde analiz edilmelidir. Özellikle küresel ısınma nedeniyle çok fazla değişkenlik göstermeye başlayan hava durumları konutlardaki kullanıcıların doğalgaz talebini etkilemektedir.

1.4.3. SANAYİ SEKTÖRÜ

Doğal gaz, imalat sektöründe önemli bir girdidir. Plastik, gübre, çelik, cam, kâğıt veya tuğla gibi temel malzemelerin üretim süreçlerinde hammadde, atık işleme ve yakma, metal ön ısıtma, cam eritme, endüstriyel kurutma için ısı üretimi ve nem alma, gıda işleme ve endüstriyel kazanların yakıt ikmali için kullanılmaktadır. Örneğin gübre endüstrisi amonyak üretimine dayalı olarak mineral gübrelerin üretimi için doğal gaz kullanır (Liang, Ryvak, Sayeed, Zhao, 2012: 3; Sánchez-Úbeda, Berzosa, 2007: 711). Görüldüğü üzere doğal gazın farklı sektörlerde farklı ihtiyaçlar için kullanım alanları bulunmaktadır. Bu nedenle olası bir doğal gaz kesintisi yaşandığında üretim aksar ve üretim seviyeleri azalır. Bu tür kıtlıklar hemen çözülmez ve yaygınlaşırsa toplam üretim düzeylerini etkileyebilir. Ani ve beklenmeyen gaz kesintileri firmaların soruna tepki verme yeteneğini de zayıflatır ve olumsuz etkileri şiddetlendirir. Gaz kıtlığı, farklı imalat sektörlerini farklı şekillerde kesintiye uğratmanın yanı sıra fabrikasyon metaller ve makineler gibi doğal gaz kullanımının daha yaygın olduğu sektörlerde daha fazla kesinti yaşanmasına neden olur (Alcaraz, Villalvazo, 2017: 147).

1.4.4. HİZMET SEKTÖRÜ

Ticari hizmet veren işletmelerde doğal gaz kullanımı genellikle ısıtma (alan, su vb.), soğutma ve aydınlatma için kullanılmaktadır. Büyük ticari binalar için verimli ve ekonomik bir yakıttır. Özellikle gıda hizmet sektöründeki büyük hacimli ticari yemek hazırlama tesislerinde doğal gaz ile çalışan cihazların talebinde artış yaşanmıştır. Bu cihazlar kompakt olmasının yanı sıra sürecin kolay ve verimli bir şekilde yürütülmesine de yardımcı olur. Doğal gazın hizmet sektöründe kullanımının bir diğer

örneği ise ticari ortamlarda enerji verimliliğini artırmaktır. Doğal gaz ile çalışan yakıt hücreleri, pistonlu motorlar ve türbinler elektrik üretebilir ve bu üniteler işletmeleri elektrik kesintisine karşı korur. Bunun yanı sıra tutarlı yüksek kaliteli elektrik ve işletmelerin kendi enerji kaynakları üzerinde kontrolü elde tutmalarını sağlar (Liang, Ryvak, Sayeed, Zhao, 2012: 3).

1.4.5. ULAŞIM SEKTÖRÜ

Motorlu taşıtlar yaymış oldukları sera gazları nedeniyle çevresel sürdürülebilirliği önemli derecede etkilemektedir. Bunun önüne geçmek için elektrik, sıkıştırılmış doğal gaz gibi farklı yakıt kaynakları seçenек olarak kullanılmaya başlanmıştır.

Sıkıştırılmış doğal gaz içerdiği bileşenlerden dolayı daha temiz bir yakıttır. Doğal gazı yakıt olarak kullanan araçlar diğer araçlara göre %70 daha az karbonmonoksit, %80 daha az nitrojen oksit ve %87 daha az metan olmayan organik gaz üretir. Ayrıca doğal gaz havadan daha hafif olduğundan dolayı herhangi bir trafik kazası olduğunda havaya dağılır ve diğer yakıtlar gibi tehlikeli bir yanıcı havuz oluşturmaz. Fakat bahsedilen avantajlarının dışında bazı dezavantajları da vardır. Bunlar; kısa menzil, yüksek başlangıç maliyeti, yakıt ikmal altyapısının gelişmemesi (Liang, Ryvak, Sayeed, Zhao, 2012: 4).

Yukarıda bahsedildiği gibi doğal gaz farklı sektörlerde, farklı amaçlar ve talep yapıları içerisinde kullanılmaktadır. Tablo 3 doğal gaz kullanan sektörlerin özelliklerini ve kullanım alanlarını özetlemektedir.

Tablo 3: Farklı Doğal Gaz Müşteri Tipleri ve Özellikleri

Müşteri Tipi	Özellikleri	Doğal gaz kullanım alanı
Elektrik Santralleri	-	Elektrik jeneratörünü çalıştıran türbinleri çalıştırmak için
Konutlar	Hava koşullarına bağlı Hafta sonları artan tüketim	Evi ısıtmak, cihazları çalıştırmak, su ısıtıcılarını kullanmak
Sanayi	Düşük oranda hava koşullarına bağlı	Bazı ürünler için hammadde olarak kullanım


	Ekonomik faktörler tarafından etkilenir Hafta sonları azalan tüketim	
Ticari	Hava koşulları dahil birçok koşula bağlı Hafta sonları azalan tüketim	Binaları ısıtmak, soğutmak, aydınlatmak
Ulaşım	-	Yakıt olarak kullanım

Kaynak: Behrooz, Boozarjomehry (2017), s.973

1.5. DÜNYA DOĞAL GAZ PİYASASI

Enerji tüketimi, sanayileşme ve küreselleşme ile giderek artmaktadır. Fakat Covid-19 pandemisi nedeniyle 2020 yılında küresel enerji tüketiminde %4,5’lik bir düşüş meydana gelmiştir. Şekil 6’da da görüldüğü üzere bu düşüşten sonra 2021 yılında %5’lik bir büyüme ile enerji tüketimi tekrar artmaya devam etmiştir.

Şekil 6: Küresel Enerji Tüketimi (1990-2021)




Kaynak: Enerdata, 2021 (Çevrimiçi 5)

2021 yılında dünyada tüketilmiş olan enerji kaynaklarının ilk üçü %30,95 ile petrol, %26,9 ile kömür ve %24,42 ile doğal gazdan oluşmaktadır (BP, 2022: 9). Küresel enerji tüketimi içerisinde doğal gaz talebi Covid-19 salgınının ilk yılında diğer fosil

yakıtlara göre daha iyi durumda kalmış ve 2021 yılında %5.3 artarak son on yıldaki (2011-2021) büyüme oranının iki katına çıkmıştır (IEA, 2022: 368).

Sürdürülebilir fırsatlar oluşturan ve petrol ve kömür gibi diğer fosil yakıtlara alternatif olarak Sanayi Devrimi'nden beri kullanımı artan doğal gaz her bölgeye eşit bir şekilde dağılan rezervlere sahip değildir. Doğal gaz rezervleri bazı bölgelerde ve ülkelerde yoğunlaşmış durumdadır. Bu durum ülkelerin enerji güvenliği konusunda stratejik kararlar alması için güçlü bir motivasyon yaratmaktadır. Tablo 5'te görüldüğü üzere tüm dünyada en fazla doğal gaz rezervine sahip bölge Orta Doğu'dur. 2020 yılı verilerine göre 188,1 trilyon m³ kanıtlanmış doğal gaz rezervinin %40,3'ü Orta Doğu'da bulunmaktadır. Avrupa ise 3,2 trilyon m³ doğal gaz rezervi ve toplam kanıtlanmış rezervin %1,7'sini oluşturması ile en az rezerve sahip bölgedir.

Şekil 7: Bölgelere Göre Kanıtlanmış Doğal Gaz Rezervleri (2020)



Kaynak: BP (2022)

Gaz rezervlerinin bazı bölgelerde daha fazla yoğunlaşmış olması tek bir noktadan yapılan enerji kesintilerinin tüm dünyayı etkilemesine neden olmaktadır. Bunun yanı sıra nihai tüketicilere gaz akışını sağlayacak projelerin planlanması ve hayata geçirilmesi de önem arz etmektedir. Bu yeni projelerin kısıtlılığı, hava durumuna bağlı ani talep artışları, LNG kesintileri ve Rusya'nın gaz ihracatı politikası 2021 yılında küresel gaz piyasasını sıkıştırmıştır (IEA, 2022: 368).

Tablo 4'teki tabloda da görüldüğü üzere 2020 yılı için kanıtlanmış doğal gaz rezervi en fazla olan ülke kanıtlanmış rezervin %19'una sahip olması ile Rusya'dır. Doğal gazın bu şekilde dengesiz dağılımının etkileri 2021 ve 2022 yılları içerisinde önemli enerji krizlerine neden olmuştur. 2021 yılında Rusya'nın gaz ihracatını azaltması politikası ve 2022 yılında başlayan Rusya-Ukrayna savaşı zaten kırılgan olan gaz dengesi üzerinde yıkıcı bir etkiye sahip olmuştur. Bu durumdan olumsuz etkilenen Avrupa ülkelerinin kış aylarından önce gaz depolarını doldurma çabaları, Rusya'nın gaz arzını stratejik olarak azaltması ve durdurması ve yüksek düzeyde piyasa oynaklığı ile olağanüstü yüksek fiyatlar getiren olası arz kıtlığı ihtimaliyle karşılaşmıştır. Gaz arzında yaşanan bu baskılar gelişmekte olan Pakistan ve Bangladeş gibi ithal gaza bağımlı ülkelerde de enerji kıtlığına yol açmıştır (IEA, 2022: 368).


Tablo 4: Ülkelere Göre Kanıtlanmış Doğal Gaz Rezervleri

Ülkeler	Kanıtlanmış Doğal Gaz Rezervi (tcm) (2020)
Amerika	12,6
Rusya	37,4
İran	32,1
Katar	24,7
Suudi Arabistan	6,0
Birleşik Arap Emirlikleri	5,9
Türkmenistan	13,6
Çin	8,4

Kaynak: BP (2022)

Doğal gaz rezervlerinin dengesiz dağılısının yanı sıra mevcut rezervlerden gaz üretimi yapabilmek de önemlidir. Covid-19'un ilk yıllarında düşüşe geçen gaz üretimi, 2021 yılında bir önceki yıla göre %4,8 artış ile 4036,9 milyar m³ olmuştur. Bu üretimin ilk üç sırasında %28,5 ile Kuzey Amerika, %22,19 ile Bağımsız Devletler Topluluğu ve %17,70 ile Orta Doğu vardır. En düşük doğal gaz üretim oranına sahip bölge ise %3,8 ile Latin Amerika'dır. Ülke bazında incelendiğinde ise %23,1'lik oran ile Amerika, %17,4 ile Rusya ve %6,4 ile İran en fazla doğal gaz üreten ilk üç ülke konumundadır (BP, 2022: 29).

Şekil 8: Küresel Doğal Gaz Üretimi (1990-2021)



Kaynak: Enerdata, 2021 (Çevrimiçi 5)

Doğal gaz rezervlerinden gaz üretimi yapan ülkeler ile ithal gaza bağımlı ülkeler arasında doğal gaz akışı boru hatları ile veya LNG olarak gerçekleşmektedir. 2021 yılında 1021.9 milyar m³ doğal gaz ihracatı gerçekleşmiştir. Bunun %49,5’u boru hattı ile %50,5’i ise LNG olarak taşınmıştır. Rusya (241 milyar m³) %23,6’lık bir oran ile uluslararası gaz ticaretinde en yüksek paya sahiptir. Bunun %19,7’si boru hattı ile gerçekleşirken %3,9’u LNG olarak taşınmıştır. Rusya boru hattı ile yaptığı ihracatın %82,8 gibi büyük bir çoğunluğunu Avrupa Birliğine yapmaktadır. LNG olarak gerçekleşen taşımaların ise %22,2’sini Japonya’ya yapmaktadır. Uluslararası gaz ticaretinde Rusya’yı taşımış olduğu %20,9 oranında LNG ile Avustralya ve %20,7 LNG ile Katar takip etmektedir (BP, 2022: 37-37).

2021 yılında en yüksek doğal gaz ithalatı ise %33,4 oran ile Avrupa’ya aittir. Avrupa aynı zamanda %22,8 oranında boru hattı ticareti ile en fazla ithalat yapan bölgedir. LNG ile en fazla doğal gaz ithalatı yapan bölge ise %72 ile Asya’dır. Çin ise %21,2 ile en fazla LNG ithalatı yapan ülkedir (BP, 2022: 37-37). 2021 yılı için boru hattı ve LNG olarak küresel doğal gaz ticareti ile ilgili veriler Şekil 9 ve Şekil 10’da yer almaktadır.

Şekil 9: 2021 Küresel Boru Hattı Doğal Gaz Ticareti

[illegible]

Kaynak: BP (2022), s.37


Şekil 10: 2021 Küresel LNG Ticareti

İhracat Eden Ülke																								
Milyar m³	Amerika	Peru	Trinidad ve Tobago	Diğer Amerika Ülkeleri	Norveç	Diğer Avrupa Ülkeleri	Rusya	Ukrayna	Katar	Birleşik Arap Emirlikleri	Yemen	Cezayir	Angola	Mısır	Nijerya	Diğer Afrika Ülkeleri	Avustralya	Brunei	Endonezya	Malezya	Papua Yeni Gine	Diğer Asya Pasifik Ülkeleri	Toplam İthalat	
İthal Eden Ülke																								
Kanada	↑	0,1	0,6	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,7	
Meksika	0,4	-	0,1	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,4	-	-	-	0,9	
Amerika	-	-	0,6	↑	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,6	
Kuzey Amerika	0,4	0,1	1,3	↑	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,4	-	-	-	2,2	
Arjantin	2,2	-	0,1	-	-	-	-	-	1,4	-	-	-	-	-	-	-	-	-	-	-	-	-	3,7	
Brezilya	8,7	-	0,3	-	-	0,1	-	-	0,9	-	-	-	0,1	-	0,1	-	-	-	-	-	-	-	10,1	
Şili	3,4	-	0,7	-	-	-	-	-	-	-	-	-	-	-	-	0,4	↑	-	-	-	-	-	4,5	
Diğerleri	2,5	-	2,6	0,6	-	0,3	-	-	↑	-	-	-	-	↑	↑	-	-	-	-	-	-	↑	6,1	
Latin Amerika	16,8	-	3,6	0,6	-	0,4	-	-	2,3	-	-	-	0,1	↑	0,1	0,4	↑	-	-	-	-	↑	24,4	
Belçika	0,2	-	-	-	-	-	1,9	-	3,2	-	-	-	0,1	-	0,1	-	-	-	-	-	-	-	5,5	
Fransa	4,3	0,1	-	0,1	-	-	4,7	-	0,7	-	-	-	4,5	-	0,2	3,5	-	-	-	-	-	-	18,1	
İtalya	1	-	0,2	-	-	0,1	-	-	6,5	-	-	-	1,3	-	0,3	0,3	-	-	-	-	-	-	9,5	
İspanya	5,8	0,1	1,1	-	-	0,1	3,3	-	2,4	-	-	-	2,1	0,4	0,4	4,3	0,8	0,1	-	-	-	↑	20,8	
Türkiye	4,5	-	0,2	-	-	↑	-	-	0,3	-	-	-	6,1	-	1,3	1,5	-	-	-	-	-	-	13,9	
İngiltere	4	0,8	0,2	-	-	0,1	3	-	6	-	-	-	0,7	-	-	0,1	-	-	-	-	-	-	14,9	
Diğer AB Ülkeleri	11,1	0,3	0,8	↑	0,2	0,4	4,4	-	3,5	-	-	-	0,6	0,4	0,3	3,4	0,2	-	-	-	-	-	25,5	
AB'nin geri kalanı	-	-	-	-	-	0,1	↑	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,1	
Avrupa	30,8	1,3	2,4	0,1	0,2	0,8	17,4	-	23	-	-	-	15,4	0,8	2,5	13	1	0,1	-	-	-	↑	108,2	
Mısır	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	
Kuveyt	0,9	-	0,2	-	-	0,3	-	0,4	3,6	0,3	-	-	0,1	0,1	0,4	1,3	0,1	-	-	-	-	0,1	7,7	
Birleşik Arap Emirlikleri	-	-	-	-	-	-	-	-	1,4	-	-	-	-	0,1	-	0,2	-	-	-	-	-	-	1,7	
Diğer Orta Doğu ve Afrika Ülkeleri	0,2	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,2	
Orta Doğu & Afrika	1,2	-	0,2	-	-	0,3	-	0,4	5	0,3	-	-	0,1	0,2	0,4	1,5	0,1	-	-	-	-	0,1	9,6	
Çin	12,4	0,2	0,6	↑	-	0,5	6,2	2,2	12	1	-	-	0,3	0,6	1,7	2,1	1,4	43,6	0,9	6,6	12	4,5	0,6	109,5
Hindistan	5,6	-	0,4	-	-	0,6	0,6	1,7	14	4,9	-	-	0,1	1,4	1,5	2	0,8	0,4	-	-	0,1	-	-	33,6
Japonya	9,6	0,7	-	-	-	0,2	8,8	2,6	12	1,8	-	-	-	-	0,3	1,2	0,4	36	5,8	2,6	14	4,8	0,2	101,3
Malezya	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0,1	-	2,1	0,3	-	-	-	-	2,5
Pakistan	1,2	-	-	-	-	0,2	-	↑	8,1	0,3	-	-	-	0,8	1,1	0,2	0,1	-	-	-	-	-	-	12,1
Singapur	0,7	-	-	-	-	-	0,1	-	0,2	-	-	-	-	0,3	0,3	0,1	0,2	3	-	0,1	0,1	-	-	5,1
Güney Kore	12,1	1,2	0,1	-	-	0,2	3,9	6,3	16	0,4	-	-	-	0,2	0,3	0,9	0,4	13	0,3	3,3	5,3	0,3	0,1	64,1
Tayvan	2,4	-	0,2	-	-	-	2,6	0,6	6,5	0,1	-	-	-	-	0,3	0,8	0,3	8,6	0,1	1,6	0,7	2	-	26,8
Tayland	0,5	-	0,3	-	-	0,1	-	0,3	3,6	-	-	-	-	0,2	-	1,2	0,3	1	0,3	-	1,5	-	-	9,2
Diğer Asya Pasifik	1,2	-	-	-	-	0,4	0,1	-	4,1	-	-	-	0,2	0,2	0,6	0,2	0,2	0,1	-	0,1	0,2	-	0,1	7,6
Asya Pasifik	45,8	2,1	1,6	↑	-	2,2	22,2	14	77	8,5	-	-	0,6	3,5	6,1	8,7	3,9	108	7,6	14	34	11,5	0,9	371,8
Toplam İhracat	95	3,5	9,1	0,7	0,2	3,6	39,6	14	107	8,8	-	-	16,1	4,7	9	23	5,4	108	7,6	15	34	11,5	1	516,2

Kaynak: BP (2022), s.37

Boru hattı taşımacılığı doğal gazın endüstriyel ve yerel tüketicilere ulaştırılmasında yıllarca temel taşıma modu olmuşken, gazın kullanımının küresel olarak artması ile deniz aşırı dağıtım sistemine ihtiyaç duyulmuştur. Doğal gazın gerekli koşullarda sıvılaştırılarak özel tasarlanmış gemilerde taşınması deniz aşırı gaz ticaretinin gelişmesine sebep olmuştur. Şekil 11'de dünya haritası üzerinde LNG ve boru hattı ticaretinin 2021 yılı için dağılımı gösterilmektedir.

Şekil 11: 2021 Yılı Küresel Gaz Ticareti Hareketi




Kaynak: BP (2022), s.37

Şekil 11’de görüldüğü üzere, boru hatları kısıtlı bir alana yayılmış iken LNG taşımacılığı birçok noktada gaz ticaretinin yapılmasını mümkün kılmaktadır. Boru hatlarının inşası hem siyasi hem de coğrafi açıdan birçok çıkmaz ile karşılaşmaktadır. Proje taşımacılığında önemli bir yeri olan boru hatlarının hem parçalarının taşınması hem de uygun arazi yapısı üzerine inşa edilmesi önemli stratejik kararlar içermektedir. Doğal gaz talebinin küresel çapta artması ile birlikte de bu boru hatlarının başlangıç ve bitiş noktaları uzaklığı giderek artmaktadır. Bunun yanı sıra LNG taşımacılığı deniz aşırı bir şekilde özel gemiler içerisinde daha esnek bir gaz ticareti sağlamaktadır. Uygun sıvılaştırma ve nihai tüketiciye ulaştırmadan önce tekrar gazlaştırma tesislerinin altyapısı sağlandığı takdirde LNG taşımacılığının payı giderek artacaktır. Doğal gaz ticaret akışının gelişmiş ülkelerde gelişmekte olan ülkelere göre daha fazla olduğu görülmektedir. Daha sürdürülebilir ve diğer yakıtlara göre nispeten daha ucuz olması doğal gazın tercih edilmesindeki önemli nedenlerdir. Hem boru hatlarının hem de LNG tesislerinin yüksek altyapı maliyetleri gaz tüketiminin gelişmiş ülkelere gelişmemiş ülkelere göre daha yaygın olmasının önemli bir diğer nedenidir.

Doğal gazın farklı taşıma teknolojilerinin geliştirilmesi ile daha fazla tüketiciye ulaşımı sağlanmıştır. Sanayi, konutlar, elektrik santralleri gibi farklı tüketici grupları farklı talep yapılarına sahip olan doğal gaz tüketicileri konumundadır. 2021 yılında doğal gaz talebi en fazla olan ilk üç sektör %38,76 ile elektrik üretim tesisleri, %21,03 ile konutlar ve %20,93 ile sanayidir (IEA, 2022: 369).

Küresel doğal gaz tüketimi, küresel enerji tüketimi gibi Covid-19 döneminde düşüş yaşamasına rağmen 2021 yılında bir önceki yıla göre %4.8 gibi bir artış göstermiştir. Şekil 12’de görüldüğü üzere kriz dönemlerinde doğal gaz enerji taleplerinde bir düşüş yaşanmaktadır. 2008 yılında yaşanan ekonomik kriz ve 2019 yılının sonlarında başlayan Covid-19 pandemisi dönemlerinde doğal gaz talebinde düşüş yaşandığı gözlemlenmektedir. Bu düşüş ise kriz dönemlerinin bitmesi, talebin normale dönmesi ve talepte gözlemlenebilir bir artış yaşanması ile son bulmaktadır.

Şekil 12: Küresel Doğal Gaz Tüketimi (2021)




Kaynak: Enerdata (2022)

1990 yılında 2046 milyar m³ olan küresel doğal gaz tüketimi %103 oranında bir artış ile 2021 yılında 4167 milyar m³'e çıkmıştır. Son 31 yılda bölgesel olarak en büyük üç artış ise Asya, Orta Doğu ve Kuzey Amerika'da yaşanmıştır. Dünya'nın en büyük doğal gaz tüketicisi Amerika'da doğal gaza olan talep düzenli bir yapıya sahip iken özellikle Asya'da doğal gaz tüketimi yıllar geçtikçe artmaktadır. Bu artış özellikle Çin, Güney Kore ve Tayvan gibi ülkelerde yaşanmaktadır.

Gaz İhraç Eden Ülkeler Formunun tahminlerine göre küresel doğal gaz talebi 2050 yılına kadar %36 oranında bir artış gösterecektir. Bu oran 2021 yılındaki doğal gaz talebinden 1435 milyar m³ artışı ifade etmektedir. Artan nüfus, kentleşme, elektrik üretiminde kömür ve petrolden gaza geçiş ve genişleyen ekonomik faaliyetler ile özellikle Asya Pasifik, Orta Doğu ve Afrika ülkelerinde sürekli bir talep artışı yaşanacaktır. Küresel doğal gaz talebinin artışının 2035 yılından sonra ise yavaşlayacağı tahmin edilmektedir. ABD'nin bu yüzyılın ortasına kadar karbon nötr olma hedefi ve Avrupa'nın petrol ve doğal gaza bağımlılığını azaltmak için hazırlamış olduğu REPowerEU planı bu talep artış hızındaki yavaşlama beklentisinin temel sebeplerindendir (GECF, 2022: 54).

Şekil 13: Küresel Doğal Gaz Talebindeki Eğilim (2021-2050)



Kaynak: GECF (2023), s.55

1.6. TÜRKİYE DOĞAL GAZ PİYASASI

Türkiye’de doğal gazın ortaya çıkması 1970’lere dayanmaktadır. İlk kez 1970 yılında TPAO tarafından Hamitabat ve Kumrular doğal gaz sahalarında keşfedilen gaz 1976 yılında Pınarhisar Çimento Fabrikası’nda kullanılmaya başlanmıştır. 1975 yılında Çamurlu’da keşfedilen doğal gazın Mardin Çimento Fabrikasına satılması ile doğal gazın kullanım alanları oluşmaya başlamıştır (Beyca vd., 2019: 938; Gürol, 2019: 43). O dönemde sadece birkaç sanayi işletmesinde kullanılan doğal gazın piyasası esas olarak 1980’lerin sonuna doğru oluşmuştur.


Türkiye, 1984 yılında eski Sovyetler Birliği ile ilk doğal gaz ithalat anlaşmasını imzalamıştır. 1987 yılında bu anlaşma gereği Rusya'dan boru hatları aracılığı ile Türkiye'ye gaz nakli başlamıştır. Doğal gaz 1987 yılında sadece elektrik üretimi için kullanılırken 1988 yılında gübre endüstrisinde ve konutlarda, 1989'da ise sanayide kullanılmaya başlanmıştır (Öztürk, Hepbaşlı, 2003: 300). Elektrik santrallerinde yakıt, gübre üretiminde hem hammadde hem de enerji, konutlarda ısınma ve yemek pişirme için ve sanayide hem hammadde hem de enerji kaynağı olarak kullanım alanları gittikçe genişlemiştir. 1987 yılına kadar ülkemizdeki şehirlerde konutların ısınmasında çoğunlukla kömür ve akaryakıt kullanılmıştır. Şehir şebekesinden verilen kömür gazı ve sıvılaştırılmış petrol gazı (LPG) ise yemek pişirme amacı ile kullanılmıştır. Sanayileşme ve şehirleşmenin fazla olduğu büyükşehirlerde bu durum hava kirliliğine neden olmuştur. (Melikoğlu, 2013: 394). Bu nedenle doğal gaz ilk olarak sanayisi yoğun ve gelişmekte olan şehirlere getirilmiştir. Ekim 1988'de Ankara'da konutlar ve ticari işletmelerde kullanılmaya başlanan doğal gaz Ocak 1992'de İstanbul'da, Aralık 1992'de Bursa'da, Eylül 1996'da İzmit'te ve Ekim 1996'da Eskişehir'de kullanılmaya başlanmıştır (Öztürk, Hepbaşlı, 2003: 296).

1.6.1. ÜRETİM VE TÜKETİM

Hızla büyüyen genç nüfus, kişi başına düşen enerji talebindeki artış, şehirleşme ve ekonomik gelişmişlik düzeyini yakalama faaliyetleri ve sürdürülebilir bir enerji arayışı Türkiye'de doğal gaz tüketiminin hızla artmasına neden olmuştur. 1987 yılında 0,5 milyar m³ olarak başlayan doğal gaz tüketiminde yıllar geçtikçe büyük bir artış görülmüştür. (Erdoğan, 2010: 211). Fakat doğal gaz rezervi ve üretim miktarı tüketim miktarının oldukça aşağısında olan Türkiye kullandığı gazın büyük bir kısmını ithal etmektedir.

Şekil 14'te görüldüğü üzere son 10 yılda 5,62 milyar m³ doğal gaz üretimi yapılmıştır. Bu üretim genellikle Hamitabat, Umurca, Karacaoğlan, Değirmenköy, Kuzey Marmara, Silivri, Çamurlu Hayrabolu, Tekirdağ Kumrular ve Ardıc bölgelerinde gerçekleşmiştir (Öztürk, Hepbaşlı, 2003: 297).


Şekil 14: Türkiye Doğal Gaz Üretimi (2011-2022)



Kaynak: EPDK (2022), s.2

2022 yılında ise 379,82 milyon m³ doğal gaz üretimi gerçekleştirilmiştir ve bu üretim 2022 yılı doğal gaz tüketiminin sadece %0,71'ini oluşturmuştur. Geri kalan %99,29 ise ithal edilmiştir. Doğal gaz üretiminin büyük çoğunluğu ise Kırklareli ve Tekirdağ'da yapılmıştır. Şekil 15'te 2022 yılı doğal gaz üretim bölgeleri ve üretilen doğal gaz miktarı gösterilmektedir. En düşük doğal gaz üretim miktarına sahip üretim sahaları ise Hatay, Adıyaman, Çanakkale ve Edirne'dir.

Şekil 15: Doğal Gaz Üretim Sahaları ve Üretim Yüzdeleri (2022 yılı)




Kaynak: EPDK (2022), s.3

Şekil 16 incelendiğinde son otuz altı yıllık süreçte doğal gaz tüketim miktarında önemli bir artış meydana geldiği görülmektedir. 1986 yılındaki verilere göre doğal gaz tüketimi 0,4 milyar m³ iken bugün 53,33 milyar m³'lük bir tüketim miktarına ulaşılmıştır. Özellikle kriz dönemlerinde doğal gaz tüketiminde azalış yaşanmaktadır. 2008 yılının son aylarında ortaya çıkan küresel ekonomik krizin de etkisi ile doğal gaz

tüketimi 2009’da %4,7 oranında azalmıştır. Covid-19 döneminde ise 2019 doğal gaz tüketimi %8,05 oranında azalmıştır.

2022 yılı doğal gaz tüketimi bir önceki yıla göre %6,9 oranında azalmıştır. 2012-2022 yılları arası değişim incelendiğinde ise %23’lük bir artış gerçekleşmiştir.

Şekil 16: Türkiye Doğal Gaz Tüketimi



BP, EPDK (2021,2022).

Doğal gaz tüketimi kullanım alanlarına göre incelendiğinde altı sektör öne çıkmaktadır. Bunlar; dönüşüm/çevrim, enerji, ulaşım, sanayi, hizmet ve konutlardır. Tablo 5’te görüldüğü üzere 2022 yılında en fazla doğal gazı konutlar tüketmiştir. Tüm doğal gaz tüketiminin %33,64’ünü oluşturan konutları, %27,108 ile dönüşüm/çevrim sektörü, %25 ile sanayi sektörü takip etmektedir. Bu üç sektör tüm doğal gaz tüketiminin %86’sını oluşturmaktadır.

Tablo 5: Sektörlere Göre Doğal Gaz Tüketimi

Sektör	2022	
	2022 Miktar (milyon sm³)	2022 Pay (%)
1. Dönüşüm/Çevrim Sektörü	14.508,40	27,108
Elektrik Santralleri	12.337,92	23,052
...	...	...
2. Enerji Sektörü	1.324,21	2,474
Petrol Rafinerileri	1.156,32	2,161

...	...	...
3. Ulaşım Sektörü	312,89	0,585
Araç yakıtı	85,87	0,160
Boru hattı taşımacılığı	226,95	0,424
...	...	...
4. Sanayi Sektörü	13.383,45	25,006
OSB'ler	4.153,64	7,761
Kimya (petrokimya dahil)	1.900,94	3,552
Ametal mineraller (cam, seramik, çimento, vs.)	1.404,08	2,623
Demir- Çelik	1.330,40	2,486
Tekstil, deri ve giyim sanayi	847,29	1,583
Gübre	685,18	1,280
...	...	...
5. Hizmet Sektörü	5.869,49	10,967
Ticarethane	2.987,38	5,582
Resmi daire	2.353,48	4,397
Diğer Hizmet Sektörü Tüketicileri	528,63	0,988
6.1. Konut	18.007,26	33,645
...	...	...
Genel Toplam	53.521,06	100

Kaynak: EPDK (2022), s.69-70

1.6.2. İTHALAT VE İHRACAT

Yukarıdaki ilgili grafiklere (Şekil 14 ve Şekil 16) bakıldığında görüldüğü üzere ülkemizde doğal gaz üretimi, tüketilen miktarın oldukça altındadır. Bu nedenle Türkiye doğal gazın büyük çoğunluğunu ithal eden bir ülkedir. İlk ithalat anlaşması 18.09.1984'te Rusya ile yapıp 1987'de bu anlaşma gereği yıllık 5,66 milyar m³ doğal gaz tedariği başlamıştır. Şubat 1997'de ise 1998 yılından itibaren gaz arzını 7,92 milyar m³'e çıkarma kararı alınmıştır (Yazıcı, Demirbaş,2001: 806).

Tablo 6 incelendiğinde Türkiye'nin doğal gaz ithalatının büyük bir kısmı son on yılda Rusya'dan yapıldığı görülmektedir. En fazla doğal gaz ithalatı bir önceki yıla göre %21,98 artış ile 2021 yılında yapılmıştır. 2022 yılında yapılan doğal gaz ithalatlarının %72,25'i boru hattı ile yapılırken %27,75'i LNG olarak gerçekleştirilmiştir. Tablo 7'de doğal gaz türüne göre ithalat miktarları gösterilmektedir.

Tablo 6: Doğal Gaz İthalatı (Milyon Sm³)

Ülke	Rusya		İran		Azerbaycan		Cezayir		Nijerya		Diğer**		Toplam	Bir Önceki Yıla Göre Yüzde Değişim
Yıllar	Miktar	Pay (%)	Miktar	Pay (%)	Miktar	Pay (%)	Miktar	Pay (%)	Miktar	Pay (%)	Miktar	Pay (%)	Miktar	
2011	25.406	57,91	8.190	18,67	3.806	8,67	4.156	9,47	1.248	2,84	1.069	2,44	43.874	15,35
2012	26.491	57,69	8.215	17,89	3.354	7,3	4.076	8,88	1.322	2,88	2.464	5,37	45.922	4,67
2013	26.212	57,9	8.730	19,28	4.245	9,38	3.917	8,65	1.274	2,81	892	1,97	45.269	-1,42
2014	26.975	54,76	8.932	18,13	6.074	12,33	4.179	8,48	1.414	2,87	1.689	3,43	49.262	8,82
2015	26.783	55,31	7.826	16,16	6.169	12,74	3.916	8,09	1.240	2,56	2.493	5,15	48.427	-1,7
2016	24.540	52,94	7.705	16,62	6.480	13,98	4.284	9,24	1.220	2,63	2.124	4,58	46.352	-4,28
2017	28.690	51,93	9.251	16,74	6.544	11,85	4.617	8,36	1.344	2,43	4.804	8,7	55.250	19,2
2018	23.642	47,02	7.863	15,64	7.527	14,97	4.521	8,99	1.668	3,32	5.061	10,21	50.282	-8,99
2019	15.196	33,61	7.736	17,11	9.585	21,2	5.678	12,56	1.756	3,88	5.260	11,63	45.211	-10,08
2020	16.166	33,59	5.321	11,06	11.548	24,00	5.573	11,58	1.358	2,82	8.159	16,95	48.126	6,45
2021	26.343	44,87	9.434	16,07	7.986	13,60	5.987	10,20	1.249	2,13	7.706	13,13	58.704	21,98
2022	21.574	39,46	9.404	17,20	8.704	16,00	5.260	9,62	818,39	1,49	8.897	16,27	54.661	-6,88

Kaynak: EPDK (2022), s.12

Tablo 7: Doğal Gaz Türüne Göre İthalat Miktarları (Milyon Sm³)

Yıllar	Gazın Türü				
	BORU GAZI		LNG		TOPLAM
	Miktar	Pay (%)	Miktar	Pay (%)	Miktar
2013	39.419,44	87,08	5.849,54	12,92	45.268,98
2014	41.981,41	85,22	7.280,87	14,78	49.262,28
2015	40.778,11	84,21	7.648,96	15,79	48.427,08
2016	38.724,48	83,54	7.627,68	16,46	46.352,17
2017	44.484,67	80,52	10.765,28	19,48	55.249,95
2018	39.032,13	77,63	11.249,92	22,37	50.282,05
2019	32.517,40	71,92	12.694,07	28,08	45.211,47
2020	33.047,16	68,67	15.078,35	31,33	48.125,51
2021	44.596,57	75,97	14.107,36	24,03	58.703,93

2022	39.490,99	72,25	15.170,68	27,75	54.661,67
------	-----------	-------	-----------	-------	-----------

Kaynak: EPDK (2022), s.14

Gazın yaygın bir şekilde kullanılmaya başlandığı 1980'lerin sonlarında Rusya'nın gazına bağımlılığı azaltmak için çeşitli ülkeler ile ithalat anlaşmaları yapılmıştır. Bu anlaşmaları yapma yetkisi BOTAŞ'a aittir (Hacıalihoğlu, 2008: 1869). Doğal gaz boru hatlarının inşasından ve işletilmesinden, gazın ithal edilmesinden ve müşterilere iletilmesinden sorumlu olan BOTAŞ 1974 yılında Irak petrolünü Türkiye üzerinden taşımak üzere kuruldu. 1994 yılına kadar TPAO'ya bağlı olarak faaliyet gösterdikten sonra 1995 yılında Devlet İktisadi Teşebbüsü olarak yeniden yapılandırıldı (Öztürk, Hepbaşlı, 2004: 279).

Rusya gazına olan bağımlılığı azaltmak için gazın boru hatları ile ve LNG olarak ithali için yapılan anlaşmalar Tablo 8'de gösterilmektedir. Gaz ithalini dengelemek için yapılan ilk anlaşma Cezayir'den LNG olarak gaz ithali anlaşmasıdır. Sonrasında Nijerya ile yine bir LNG ithalat anlaşması, Rusya ile Mavi Akım anlaşması, İran, Türkmenistan, Azerbaycan ve çeşitli ülkelerle anlaşmalar yapılmıştır.


Tablo 8: Doğal Gaz Anlaşmaları

Anlaşma	İmza Tarihi	İşletim Tarihi	Süre (Yıl)	Miktar (Plato – milyar m ³ / yıl)	Bitiş Tarihi
Nijerya (LNG)	1995	1999	22	1,2	2021
İran	1996	2001	25	10	2026
Cezayir (LNG)	1988	1994	27	4	2021
Rusya (Mavi Akım)	1997	2003	25	16	2028
Rusya (Balkan Rotası)	1998	1998	23	8	2021
Rusya (Balkan Rotası)	1998	1998	23	4	2021
Rusya (Balkan Rotası)	2013	2013	23	1	2036
Rusya (Balkan Rotası)	2013	2013	30	5	2043
Türkmenistan	1999	-----	30	16	---
Azerbaycan	2001	2007	15	6,6	2021

Kaynak: Çevrimiçi 6


Doğal gaz ticaretinin büyük bir kısmı ithalattan oluşan Türkiye ağırlıklı olarak Yunanistan olmak üzere Bulgaristan, Sırbistan, Makedonya ve Romanya gibi ülkelere gaz ihraç etmektedir. 2011-2022 yılları arasında (Şekil 17) toplamda 7546,72 milyon sm³ doğal gaz ihracatı gerçekleşmiştir. 2022 yılında toplamda 581,43 milyon sm³ doğal gaz ihracatı yapılmıştır. Bulgaristan %43,83 ile en fazla doğal gaz ihracatı yapılan ülke olurken onu %39,26 ile Yunanistan ve %16,89 ile İsviçre takip etmektedir. Şekil 18’de 2022 yılında doğal gaz ihracatı yapılan ülkelere ve doğal gazın türüne göre ihracat miktarları gösterilmektedir.

Şekil 17: Doğal Gaz İhracatı



Kaynak: EPDK (2022), s.25

Şekil 18: 2022 Yılında Doğal Gaz İhracat Yapılan Ünelere ve Doğal Gazın Türüne Göre İhracat Miktarları



Kaynak: EPDK (2022), s.26

1.6.3. DEPOLAMA

Doğal gaz tüketim sektörlerine göre farklı talep yapılarına sahiptir. Sanayi sektöründe kullanılan doğal gaz talebi aylara göre sabit ve durağan bir yapıya sahipken, ticari işletmelerde ve konutlarda kullanılan doğal gaz talebi mevsimsellik içermektedir. Bu mevsimsel değişiklikleri karşılamak, olası kesintilerine karşı oluşabilecek gaz açığını gidermek ve sistemin kesintisiz bir şekilde işleyebilmesini sağlamak için doğal gazın yerüstünde veya yeraltında depolanması gerekmektedir (EPDK, 2011: 38).

Türkiye'nin yeraltındaki ilk doğal gaz depolama tesisi tükenmiş petrol ve doğal gaz depolama tesisi örneğidir. Trakya'daki Kuzey Marmara ve Değirmenköy doğal gaz üretim sahalarındaki doğal gazın tüketilmesi sonucu bu sahaların depolama alanı olarak kullanılmasına ilişkin BOTAŞ ve TPAO arasında 21.07.1999'da Doğal Gaz Yer Altı Depolama ve Yeniden Üretim Hizmetleri Anlaşması imzalanmıştır. 20 Temmuz 2007'de ise Silivri'deki bu sahalar depolama tesisi olarak işletmeye açılmıştır (EPDK, 2010: 28). İlk açıldığında 1,6 milyar sm^3 kapasiteye sahip olan Silivri doğal gaz depolama tesisinde, kapasite artışı için yürütülen çalışmalar sonucunda 4,6 milyar sm^3 depolama kapasitesine ulaşılmıştır ve denizlerde Avrupa'daki en büyük depolama tesisi olmuştur (Çevrimiçi 7).

Yeraltında depolama tesisi için bir diğer çalışma ise Tuz Gölü depolama tesisidir. Tuz Gölü Havzası'nda oluşturulacak tuz domlarının doğal gazı yeraltında depolama amacıyla kullanılacağı projenin mühendislik çalışmaları 2010 yılında tamamlanmış olup yapım çalışmaları 2011 yılında Aksaray'ın Sultanhanı ilçesinde başlamıştır. 2021 yılında tamamlanan proje (I. Etap) ve sonrasında genişletme (II. Etap) çalışmaları ile 5,4 m^3 depolama ve 80 milyon m^3 üretim kapasitesine ulaşılması hedeflenmektedir. I. Etap çalışmalarının 2021 yılı sonunda tamamlanması ile 1.2 milyar sm^3 çalışma gazı kapasitesine ve 40 milyon sm^3 günlük geri üretim kapasitesine ulaşılmıştır (EPDK, 2010:28; Çevrimiçi 8).

Ülkemizdeki ilk yerüstü depolama tesisi ise 1994 yılında devreye alınmış ve BOTAŞ mülkiyet ve işletmesinde olan Marmara Ereğlisi LNG terminalidir. Ardından 2001'de İzmir Aliğa'da kurulan ve 2006'da kullanılmaya başlanan Ege Gaz LNG terminalleri kullanıma açılmıştır. 2016 yılında Yüzen LNG Terminallerinde gerçekleştirilecek

faaliyetler depolama faaliyeti olarak değerlendirilmiş ve Etki Liman İşletmeleri Doğal Gaz İthalat ve Ticaret AŞ'ye ait Yüzen LNG Terminali (FSRU) Aralık 2016'da işletmeye açılmıştır (EPDK, 2016: 21). 2017 yılında ise Hatay Dörtyol LNG tesisi lisans alarak faaliyete geçmiştir (EPDK, 2018: 6). BOTAŞ tarafından ilerleyen zamanlarda hayata geçirilmesi beklenen Saros FSRU Projesi Türkiye'nin LNG depolama tesis kapasitesini daha da arttıracaktır (IEA, 2021: 149). Tablo 9'da 2007-2022 yılları arasında tamamlanan ve inşa halinde olan depolama tesislerinin çizelgesi gösterilmektedir.


Tablo 9: Doğal Gaz Depolama Tesisleri

Proje	Tesis Türü	Günlük Kapasite (Milyon m ³)	Operatör	Durum
Silivri	Yeraltı	75	BOTAŞ	Aktif
Marmara Ereğlisi	LNG	37	BOTAŞ	Aktif
İzmir Aliğa	LNG	40	EgeGaz	Aktif
Etki	LNG	28	Etki	Aktif
Dörtyol LNG	LNG	20	BOTAŞ	Aktif
Saros FSRU	LNG	20	BOTAŞ	İnşa halinde
Tuz Gölü (Faz I)	Yeraltı	20	BOTAŞ	Tamamlandı
Tuz Gölü (Faz II)	Yeraltı	40	BOTAŞ	Tamamlandı
Tuz Gölü (Faz II)	Yeraltı	80	BOTAŞ	Devam ediyor

Kaynak: IEA (2021), s.148-149

Farklı depolama tesislerinin faaliyete geçmesi ile yıllara göre doğal gaz depo kapasite ve stok miktarlarında (Şekil 19) önemli artışlar gözlenmiştir.


Şekil 19: Yıllara Göre Ay Sonu Doğal Gaz Stok Miktarları



Kaynak: EPDK (2022), s.28

2022 yılı için ithalat-tüketim-depolama verileri (Şekil 20) birlikte incelendiğinde stok miktarlarının Şubat-Nisan arası artış ve azalış gösterdiği ve mayıs ayından itibaren ise devamlı bir artış yaşandığı görülmektedir. Doğal gaza olan talebin arttığı kış aylarında tüketim artış gösterdiğinden dolayı stok oranı düşmekte, yaz aylarında ise gaz için talep azaldığından dolayı stok miktarı artmaktadır. Stoklanan doğal gaz miktarının %92'si yeraltında %8'i ise LNG olarak depolanmaktadır.

Şekil 20: 2022 Yılında Aylara Göre İthalat-Tüketim-Stok Miktarları Karşılaştırması



Kaynak: EPDK (2022), s.29

1.6.4. DOĞAL GAZ TEDARİK KAYNAKLARI

Türkiye'nin en büyük doğal gaz tedarikçisi, birden fazla boru hattı ile gaz akışı sağlayan Rusya'dır. İlk doğal gaz tedariği uzun vadeli bir sözleşme kapsamında

Rusya-Türkiye Doğal Gaz Boru Hattı (Batı Hattı) ile 1986 yılında başlamıştır. İlerleyen yıllarda çeşitli ülkeler ile yapılan anlaşmalar neticesinde farklı boru hatları ile gaz tedariği sağlanmıştır. Şekil 21, Türkiye'nin doğal gaz altyapısını ve giriş noktalarını göstermektedir.

Şekil 21: Türkiye'de Doğal Gaz Altyapısı ve Giriş Noktaları



Kaynak: IEA (2021), s.150

1.6.4.1. RUSYA – TÜRKİYE DOĞALGAZ BORU HATTI (BATI HATTI)

18 Eylül 1984 yılında Türkiye ve Sovyetler Birliği hükümetleri arasında doğal gaz sevkiyatı hakkında Hükümetlerarası Anlaşma imzalanmıştır. Daha sonra BOTAŞ, doğal gaz sevkiyatı için çalışmalara başlamıştır ve 1985 yılında Türkiye'nin doğal gaz tüketim potansiyelini ve uygun güzergahı belirlemek amacıyla Türkiye Doğal Gaz Kullanım Etüdü yapılmıştır. 14 Şubat 1986'da BOTAŞ ve SoyuzGazExport arasında 25 yıl süreli bir Doğalgaz Alım-Satım Anlaşması imzalanmıştır. Rusya'dan başlayarak Ukrayna, Moldova, Romanya ve oradan Bulgaristan sınırında Malkoçlardan girerek ülkemize ulaşan hattın yapımına 26 Ekim 1986'da başlanmıştır. 23 Haziran 1987 tarihinde ise ülkemizdeki ilk durağı olan Hamitabat'a ulaşmıştır ve bu tarihten itibaren ithal doğal gaz, Trakya Kombine Çevrim Santrali'nde elektrik enerjisi üretmek için

kullanılmaya başlanmıştır (Çevrimiçi 9). 845 km olan hattın mevcut kapasitesi 18,8 milyar m³'tür (IEA, 2021: 150).

1.6.4.2. MAVİ AKIM DOĞALGAZ BORU HATTI

Ekim 2002'de tamamlanan, Şubat 2003'te işletmeye alınan ve resmi açılışı 17 Kasım 2005 tarihinde yapılan Mavi Akım boru hattı, 15 Aralık 1997'de BOTAŞ ve Gazexport arasında imzalanan ve yirmi beş yıllık bir geçerlilik süresi bulunan Doğalgaz Alım-Satım Anlaşması kapsamında Rusya'dan başlayarak Karadeniz üzerinden Türkiye'ye yılda 16 milyar m³ gaz akışı sağlar (IEA, 2021: 151; Çevrimiçi 9). Rusya'nın güneyindeki Krasnodar yakınlarında bulunan İzobilnoye'den başlayan hat Karadeniz kıyısında karadan Džubga'ya kadar 370 km uzanır. Hattın denizaltı kısmı Džubga kentinden Samsun limanına kadar uzanan 390 km uzunluğundaki paralel 2 boru hattından oluşmaktadır. Samsun'dan Ankara'ya ulaşarak Ana Hat ile bağlanmaktadır (Kılıç, 2006: 1933).

1.6.4.3. DOĞU ANADOLU DOĞALGAZ ANA İLETİM HATTI (İRAN – TÜRKİYE)

Tahran'da 8 Ağustos 1996 tarihinde imzalanan Doğal Gaz Alım-Satım Anlaşması ile yılda 10,4 milyar m³ İran gazının Türkiye'ye arzı sağlanmıştır. Doğubayazıt'tan başlayan ve 1491 km uzunluğunda olan bu hattın bir kolu Erzurum'dan başlayarak Ankara'ya, diğeri ise Kayseri'den başlayarak Seydişehir'e uzanmaktadır (Çevrimiçi 9).

1.6.4.4. BAKÜ-TİFLİS-ERZURUM DOĞALGAZ BORU HATTI (BTE)

Bu hat, Bakü-Tiflis-Ceyhan petrol hattına paralel olarak yapılan 970 km uzunluğundadır. Hattın inşa edilme amacı, Şahdeniz sahasında üretilen doğal gazın Türkiye'ye ulaşımını sağlamaktır. Türkiye ve Azerbaycan arasında 12 Mart 2001'de imzalanan bir Hükümetlerarası Anlaşması çerçevesinde hattın inşasına karar verilmiştir ve 16 Ekim 2004 tarihinde çalışmalara başlanmıştır. 2006 yılının sonunda yapımı tamamlanan hat, 4 Temmuz 2007 tarihinde gaz akışına başlamıştır (Ener, Ahmedov, 2007: 126; Çevrimiçi 9).

1.6.4.5. TÜRKİYE-YUNANİSTAN DOĞALGAZ ENTERKONNEKSİYONU

Avrupa Birliği'nin INOGATE programı kapsamında geliştirilen Güney Avrupa Gaz Ringinin ilk aşaması olan Türkiye ve Yunanistan doğalgaz şebekelerinin enterkoneksiyonu kapsamında Türkiye-Yunanistan gaz akışını sağlayan hattır. Bu hat, 23 Şubat 2003 tarihinde Türkiye'den Yunanistan'a doğal gaz arzına ilişkin Hükümetlerarası Anlaşma ile resmiyet kazanmıştır. Türkiye'den BOTAŞ ve Yunanistan'dan DEPA tarafından imzalanan 15 yıl süreli Doğal Gaz Alım Satım Anlaşması ise 23 Aralık 2003 tarihinde gerçekleştirilmiştir. Hat üzerinden gaz akışı 18 Kasım 2007 tarihinde başlamıştır (Çevrimiçi 9).

1.6.4.6. TRANS-ANADOLU DOĞALGAZ BORU HATTI (TANAP)

Ülkemizdeki gaz talebinin karşılanması için Azerbaycan Hükümeti ve Şahdeniz Konsorsiyumu ile yürütülen görüşmeler sonucunda, 25 Ekim 2011 tarihinde başlangıcı 2018 olarak belirlenen ve yıllık 6 milyar m³ gaz akışı sağlayan bir anlaşma imzalanmıştır. Ayrıca, yıllık 10 milyar m³ Azerbaycan gazının Türkiye üzerinden Avrupa'ya taşınması için 26 Haziran 2012 tarihinde Azerbaycan ve Türkiye arasında TANAP Projesine ilişkin Hükümetlerarası Anlaşma imzalanmıştır (Çevrimiçi 10).

TANAP, Güney Gaz Koridorunun önemli bir bileşenidir ve Azerbaycan'ın Şahdeniz sahasında üretilen doğal gazın öncelikle Türkiye'ye, buradan da Avrupa'ya taşınmasını amaçlamaktadır. Türkiye Gürcistan sınırında Ardahan'ın Posof ilçesi Türkgözü köyünden başlayan hat Tekirdağ'dan geçerek Türkiye'deki son nokta olan Edirne'nin İpsala ilçesinde son bulmaktadır. Bu noktadan Trans Adriyatik Boru Hattı'na bağlanarak Avrupa ülkelerine gaz aktarılmaktadır (Çevrimiçi 10). Hat üzerinden ilk gaz akışı Türkiye'ye Haziran 2018'de, Avrupa'ya ise Aralık 2020'de başlamıştır (Çevrimiçi 11).

Azerbaycan'ı Avrupa Birliği için yeni bir gaz tedarikçisi haline getiren ve Türkiye'yi gaz ticareti içerisinde önemli bir konuma taşıyan TANAP projesi, dünyadaki enerji jeopolitiğini yeniden şekillendirerek özellikle Rusya'nın gazına bağımlı Avrupa için kaynak çeşitliliği ve enerji arz güvenliği sağlamaktadır.

1.6.4.7. TÜRKAKIM DOĞALGAZ BORU HATTI

TürkAkım Boru Hattı, Rusya'dan gelen gazın ülkemiz üzerinden Avrupa'ya taşınmasını sağlamak amacıyla 10 Ekim 2016 imzalanan Hükümetlerarası Anlaşma ile kurulmuştur. Rusya'dan başlayarak Karadeniz üzerinden Türkiye'nin Karadeniz kıyısındaki alım terminaline ve oradan da Türkiye'ye komşu devletlere uzanan iki hattan oluşmaktadır. Her bir hat 15,75 milyar m³ kapasiteye sahiptir. Hattın, inşası ve işletimi Rusya tarafından yapılan iki deniz bölümü, sadece ülkemize doğal gaz arz eden ve BOTAŞ tarafından inşa edilen bir kara bölümü ve Avrupa'ya gaz ileten ve inşası ile işletimi Türkiye ve Rusya'nın ilgili şirketlerince kurulan TürkAkım Gaz Taşıma Anonim Şirketi tarafından yapılan ikinci bir kara bölümü vardır (Çevrimiçi 10). Açık deniz boru hatlarının her biri 12 metre uzunluğundaki binlerce borudan oluşan bu hat iki kilometreyi aşan derinlikte inşa edilen 81 cm çapındaki ilk boru hattı sistemi olarak önemli bir doğal gaz altyapı sistemine sahiptir (Çevrimiçi 12).

Yukarıda bahsedilen boru hatlarının Türkiye'ye giriş noktaları ve günlük kapasiteleri Şekil 22'de gösterilmektedir.

Şekil 22: Boru Hatlarının Türkiye'ye Giriş Noktaları ve Kapasiteleri

Giriş Noktası	Günlük Kapasite (milyon m ³)
Durusu (Mavi Akım)	47
Malkoçlar (Batı Hattı)	45
Gürbulak (İran-Türkiye)	29
Türkçözü (BTE)	19
Seyitgazi (TANAP)	11,4
Kırıkköy (TürkAkım)	41,16

Kaynak: IEA (2021), s.151

İKİNCİ BÖLÜM

TALEP TAHMİNİ


2.1. TALEP TAHMİNİNE GENEL BİR BAKIŞ

Tahmin, geleceği öngörme sanatıdır. Önceleri batıl inanç, dinsel ya da olağanüstü olan ile ilişkilendirilen tahmin alanı fen bilimlerinde uygulanmaya başlanarak daha bilimsel bir hal almıştır. 19.yy'ın sonunda ekonomik döngüleri ve borsayı bilimsel olarak tahmin etme girişimleri ile sosyal bilimlerde de yaygın bir şekilde kullanılmaya başlanmıştır. Sonrasında işletme, finans, demografi, psikoloji ve diğer pek çok sosyal bilim alanında kullanılmıştır. Gelişmekte olan bu alan, İkinci Dünya Savaşı'ndan sonra donanma depolarında depolanan ürünlere olan talebi tahmin etmek için Robert Brown tarafından yapılan çalışma ile önemli bir başarı elde etmiştir (Makrikadis, Hyndman, Petropoulos, 2020: 15).

Farklı alanlarda yürütülen tahmin çalışmalarının artması ile elde edilen bilimsel yaklaşım, farklı sektörlerde faaliyet gösteren tedarik zincirleri için de talebi tahmin etme noktasında önem arz etmeye başlamıştır. Ürün, hizmet ya da enerjinin nihai tüketiciye ulaştırılmasında aktif rol oynayan tedarik zincirleri işletmeler için stratejik bir güç haline gelmiştir. Farklı müşteri tiplerine tedarik edilen ve bununla birlikte farklı talep yapılarına sahip ürünlerin zincir içerisinde kesintisiz bir şekilde akışını sağlayan faktör, işletmelerin talebi anlama yeteneğidir. Talep tahmini bu yönüyle tedarik zinciri planlamasının temelini oluşturmaktadır. Ürün portföyünün genişletilmesi, üretim miktarlarının arttırılması, işgücü veya tesislerde kapasite planlamasının yenilenmesi gibi önemli kararların alınmasına rehberlik etmektedir. Gerçekte olduğundan daha fazla tahmin edilen talep yüksek miktarda stoğu ve stok tutma maliyetini, ürünün değerinin eskimesini beraberinde getirmektedir. Olduğundan daha az tahmin edilen talep ise işletmelerin müşteriye hızlı cevap verme yeteneğine sekte vuran, üretimin aksamasına neden olan, talebi karşılama isteği nedeniyle agresif satın almalar veya dış kaynak kullanımı sonucunda satın alma stratejilerinde yaşanan başarısızlıkları ve ürün kalitesi ile ilgili belirsizlikleri ortaya çıkaran bir durum oluşturmaktadır. Başarısız talep tahmininin ortaya çıkardığı tüm bu olumsuz durumlar verimsiz operasyonlara ve yüksek maliyetlere neden olmaktadır. Rekabetçi çalışma ortamında arz ve talebi en

doğru şekilde eşlemenin hem daha cevap verebilir hem de daha az maliyetli tedarik zincirleri oluşturma gücünün farkında olan işletmeler talep tahmini faaliyetlerine giderek daha fazla önem vermeye başlamıştır. Şekil 23'te talep tahmin hatasının az ve fazla olduğu durumlarda ortaya çıkan avantaj ve dezavantajlar gösterilmiştir.

Şekil 23: Talep Tahmin Hatasının Karşılaştırmalı Analizi



Kaynak: Wisner, Tan, Leong (2014), s.136

Şekilde de görüldüğü üzere tahmin hatası ile ilgili iki seçenek vardır; tahmin ile gerçek talep arasındaki fark ya düşüktür ya da fazladır. İşletmeler bilinmeyen bir geleceği daha net bir şekilde görebilmeye çalıştığından dolayı gerçek ve tahmini talep arasında her zaman bir fark olması beklenir. Gerçeğe en yakın, düşük hata değerine sahip talep tahmini yapmak işletmedeki pek çok departman için önemlidir. Düşük mutlak hata, satın alma departmanının doğru miktarda ürün siparişi vermesine, üretim departmanının doğru miktarda ürün üretmesine ve lojistik departmanının da doğru miktarda ürün taşımaya yardımcı olur (Wisner, Tan, Leong, 2014: 136).

2.2. TAHMİNİN ÖZELLİKLERİ

İşletmelerin uzun vadeli kapasite ihtiyaçlarını, yıllık iş planlarını, daha kısa vadeli operasyonları ve tedarik zinciri faaliyetlerini planlamasında talep tahmini alanı için iki önemli mutlak gerçek vardır. İlk olarak hiç kimse gelecek ile ilgili belirsizliği net bir

şekilde çözüp kesin bir doğruya ulaşamaz. Yani hata payı her zaman mevcuttur. İkinci olarak ise tahminler arasında değişen en önemli şey bu belirsizliğin boyutudur (Bozarth, Handfield, 2013: 254; Makrikadis, Hyndman, Petropoulos, 2020: 15). Bunlarla birlikte talep tahminleri belirli özelliklere sahiptir. Bu özellikleri aşağıdaki gibi sıralayabiliriz (Stevenson, 1996: 469; Chopra, Meindl, 2001: 188-189; Bozarth, Handfield, 2013: 255).

- Tahminler genellikle yanlış olduklarından dolayı hem tahminin değerini hem de tahmin hatasının ölçüsünü yani talepteki belirsizliği içermelidirler.
- Tahminler kısa, orta ve uzun vadeli olarak üç ayrı zaman dilimine göre sınıflandırılabilirler. Güncel bilgilerin dikkate alınmasına olanak sağlayan kısa vadeli ve yakın dönem için yapılan tahminler uzun vadeli olanlara göre daha az standart hata sapmasına sahip olup, daha doğru sonuçlar vermektedir. Çünkü yakın dönem için yapılan tahmin değişkenlerini etkileyen faktörler çok fazla değişkenlik göstermez.
- Bütünleştirilmiş tahminler ortalamaya göre düşük standart hata sapmasına sahip olduklarından dolayı ayrıştırılmış tahminlerden daha az tahmin hatasına sahiptir. Özel bir ürün ya da hizmetin talep tahmini birçok faktörden etkilendiği için bir ürüne ya da hizmet grubuna ilişkin tahminlerden daha zordur.
- Tedarik zinciri içerisinde nihai müşteriden uzak konumda bulunan işletmelerin tahmin hatası diğerlerine göre daha büyüktür. Son müşteriye yakın işletmeler ile iş birliğine dayalı tahmin, üretime yakın işletmelerin tahmin hatasını azaltmasına yardımcı olur.
- Tahmin teknikleri talep yapılarının altında yatan ve geçmişte var olan nedenselliğin gelecekte de devam edeceğini varsayar.
- Tahminler ilgilenilen değişkeni belirlemek için daha doğru sonuçlar verebilecek yaklaşımlar olmadığında kullanılır.

2.3. TAHMİN SÜRECİ ADIMLARI

Talep tahmini sürecini başarı ile yürütebilmek sistematik bir çalışma gerektirir. Oluşturulan bu talep tahmin sistemi, aşamalı bir şekilde belirli kararların verilerek uygun sonucun elde edilmesini kapsamaktadır. İşletme içerisinde üretim, pazarlama,

satın alma gibi pek çok departman için önemli olan talep tahmin sistemi yedi temel adımdan oluşmaktadır (Heizer, Render, Munson, 2017: 148-149).

- Tahmini kullanma amacının belirlenmesi
- Tahmin yapılacak ürün ya da ürün gruplarının belirlenmesi
- Tahmin yapılacak zaman dilimine karar verilmesi
- Eldeki kaynaklara göre en uygun tahmin modelinin seçilmesi
- Tahmin için ihtiyaç duyulan verinin toplanması
- Tahminin yapılması
- Sonuçların hata metrikleri kullanılarak değerlendirilmesi ve uygulanması

2.4. İYİ BİR TAHMİNİN BİLEŞENLERİ

Yukarıda bahsedilen tahmin süreci adımlarının başarılı bir şekilde yürütüldüğü kararı bazı unsurlara bağlıdır. Tedarik zincirlerinin karşılaştığı potansiyel risklerin azalmasına ve gelecekteki fırsatlar için avantaj elde edilmesine imkân tanıyan başarılı tahmin süreci için gerekli olan bileşenler aşağıdaki gibi sıralanabilir (Stevenson, 1996: 503-504).

- Tahmin zamanında yapılmalıdır. Tahmin sonucu elde edilen bilgilerin gerektirdiği değişiklikleri uygulayabilmek için gerekli zaman aralığı bırakılmalıdır.
- Yapılan tahmin seçilmiş olan hata metrikleri ile ölçülmeli ve doğruluk derecesi belirtilmelidir. Bu hem olası hatalar için plan yapılması hem de farklı tahmin yöntemlerinin karşılaştırılması için önemlidir.
- Tahmin istikrarlı ve güvenilir bir şekilde çalışmalıdır.
- Tahmin sonuçları, anlaşılabilir olması için anlamlı birimler ile ifade edilmelidir. Finans, üretim ve işgücü planlama departmanları yapılan tahmin sonucunda farklı birimler ile ifade edilen farklı ihtiyaçları belirlerler.
- Tahmin sonuçları, kolay değerlendirme yapılabilmesi için yazılı olmalıdır.
- Tahmin, karmaşık tekniklerin kullanıcılar tarafından anlaşılması daha zor olacağından dolayı anlaşılır ve kullanımı kolay bir teknik ile yapılmalıdır.

2.5. TALEP TAHMİN YÖNTEMLERİ

Tahmin sisteminin kritik adımlarından birisi olan talep tahmin yöntemi seçiminde birden fazla seçenek vardır. İş ortaklarından alınan veya kurum içinde üretilen verinin kullanılabilirliğine, bilgi ve beceri düzeyine, talep tahmini yapılacak ürünün özelliğine göre seçimi yapılan bu yöntemler kalitatif (nitel) ve kantitatif (nicel) olarak iki temel yaklaşıma ayrılmışlardır.

2.5.1. KALİTATİF (NİTEL) YÖNTEMLER

Nitel yöntemler tahmin yapmak için yeterli ve faydalı veri bulunmadığında, yeni bir ürünün piyasaya sürüldüğü veya teknolojinin değişeceği beklentisinin olduğu durumlarda ve geçmiş olay ile gelecek olay arasındaki ilişkinin matematiksel olarak modellenmesinin zor olduğu koşullarda kullanılır (Krajewski, Ritzman, Malhotra, 2010: 284; Bozart, Handfield, 2013: 256). İnsan yargısına dayanan, sezgisel ve öznel olan bu yöntemler bazı durumlarda nicel teknikler yardımı ile üretilen tahmin sonuçlarını değiştirmek için de kullanılabilir. Tahmin yapan kimsenin neden-sonuç ilişkileri, tahmin edilen değişken üzerinde etkisi olabilecek organizasyonel bilgi ve çevresel ipuçları gibi bağlamsal bilgilere sahip olduğu durumlarda nicel yöntemlerin sonuçları üzerinde düzeltmeler yapılabilir (Chopra, Meindl, 2001: 190 Krajewski, Ritzman, Malhotra, 2010: 284).

Çoğunlukla muhakemenin ve birikmiş bilginin ürünü olan ve belirli bir sayısal tahmin sunmak yerine ipuçları sağlamak, planlamacıya yardımcı olmak ve nicel tahminleri desteklemek için kullanılan nitel yöntemlerin tahmin performansını ölçmek zordur. Doğaları ve maliyetleri gereği kullanımına şüpheli yaklaşılsa da ürün geliştirme, sermaye harcamaları, hedef ve strateji oluşturma gibi konularda orta ve küçük ölçekli kuruluşlar tarafından nicel yöntemler ile başarıyla kullanılmaktadırlar (Makridakis, Wheelwright, Hyndman, 1997: 12). Kullanılan bu yöntemler yönetici görüşleri, müşteri anketleri, satış personeli görüşleri, Delphi metodu, senaryo analizi ve yaşam çevrimi benzeşimi olarak altı başlıkta incelenebilir.

2.5.1.1. YÖNETİCİ GÖRÜŞÜ

Yönetici görüşleri, hedef veya mevcut pazar ve rekabet ortamı hakkında bilgi ve deneyim sahibi uzman ve yöneticilerin, açıkça ve özgürce konuşup beyin fırtınası yaparak tahmin geliştirmesi için kullanılmaktadır. Farklı deneyim ve bakış açısına sahip birkaç kişinin birlikte çalışmasının avantajını sunan yöntem genellikle uzun vadeli planlama ve piyasaya yeni ürün sunma çalışmalarında yaygın bir şekilde kullanılmaktadır. Tartışma içerisinde bir üyenin baskın bir şekilde düşüncelerini dayatması ihtimali ise bu yöntemin önemli bir dezavantajıdır (Wisner, Tan, Leong, 2014: 137).

2.5.1.2. SATIŞ EKİBİ TAHMİNLERİ

Talep tahmininin temel motivasyonu müşteri ihtiyaç ve beklentilerinin kesintisiz bir şekilde karşılanmasını sağlamaktır. Bu durumda müşteri davranışlarının doğru bir şekilde anlaşılması oldukça önemlidir. Talebi oluşturan müşteri ile yakın temasta bulunan satış ekipleri işletme için iyi bir pazar bilgisi kaynağıdır. Satış ekipleri gelecek yıl satacakları ürünlerin satış tahminlerini söyleyerek tahmin sürecini başlatır. Ekip üyeleri tarafından bireysel olarak verilen tahminler satış yöneticisi tarafından her bir coğrafi bölge ya da ürün grubu için kapsamlı tahminler oluşturmak amacıyla bütünleştirilir. Satış ekibinin belirli bir kotayı karşılaması sonucunda maaş veya promosyon alması, yapılan tahminlerin gerçek değerinin altında söylenmesine sebep olmaktadır. Bu durum, yöntemi kullanmak için değerlendirmeye alırken dikkat edilmesi gereken bir dezavantaj oluşturmaktadır (Nahmias, Olsen, 2015: 57).

2.5.1.3. DELPHİ METODU

İsmi Antik Yunan'ın Delfi Kâhininden alan yöntem farklı uzman görüşlerini alarak bir fikir birliği oluşturmayı amaçlamaktadır. Yöntemde, probleme uygun şekilde hazırlanan anket ile bilgi ve deneyime sahip uzmanların bireysel olarak görüşleri alınır. Yönetici görüşü tekniğinde oluşabilecek, tek bir uzmanın baskın tavırları sonucu meydana gelen verimsiz tartışma ortamını önlemek için anonim olarak sürece dahil edilen uzmanlar fiziksel olarak da bir araya gelmezler. Çevrimiçi bir şekilde gönderilen ankete verilen yanıtlar derlenir ve sonuçların bir özeti hazırlanır. Daha sonra bu sonuçlar tüm uzmanlara geri gönderilir ve yanıtlarının bu sonuçlar ışığında

tekrar gözden geçirilmesi istenir. Her yeni anket bir öncekinden elde edilen bilgiler kullanılarak geliştirilir. Bu süreç fikir birliği oluşana kadar devam eder. (Nahmias, Olsen, 2015: 58).

Bu yöntemin temel avantaj ve dezavantajları aşağıdaki gibi sıralanabilir (Stevenson, 1996: 472-473).

Avantajları;

- İhtiyaç duyulan sezgisel bilgi yeterli deneyim ve bilgiye sahip uzmanlar tarafından sunulur.
- Yüz yüze yapılan görüşmelerde bir araya gelmesi zor olan uzmanlara kolayca erişim sağlanabilir.
- Grup üyeleri fiziksel olarak bir araya gelmediğinden dolayı tartışmaya bir veya birkaç uzmanın hâkim olabileceği senaryodan kaçınılır. Böylece daha özgür bir beyin fırtınası projesi gerçekleştirilir.
- Pahalı projeler veya yeni ürün tanıtımları gibi riskli kararlar için uygun sonuçlar sunar.

Dezavantajları;

- Uzmanlara gönderilen anketteki sorular belirsiz ve muğlak ifadeler içerebilir. Bu durumda uzmanlar yanlış fikir birliğine ulaşabilirler.
- Süreç uzun olabileceğinden dolayı bazı uzmanların ilerleyen zamanlarda ayrılması veya değişmesi söz konusu olabilir. Bu durum ortak bir fikir birliğine ulaşılmasını geciktirir.
- Fikir birliğine ulaşmanın uzun sürdüğü durumlarda çok fazla zaman ve maliyet sorunu ile karşılaşılacaktır
- Bazı durumlarda uzmanların tartışılan konu hakkında tam bir yetkinliğe sahip olmadığı görülebilir
- Anonim olma durumu problemin çözümü ile ilgili sorumluluğu ve yükümlülüğü kaldırabilir.

2.5.1.4. PAZAR ARAŞTIRMASI

Piyasaya yeni bir ürün sürmek veya mevcut ürün ile ilgili bir yenilik yapmak istendiği durumlarda tüketici ilgi ve beklentisinin belirlenmesi ya da talebi tahmin etmek için sistematik bir yaklaşım sunan pazar araştırması yöntemi, anket tasarlanması, uygulama yönteminin belirlenmesi, örneklem seçimi, yanıtların toplanması ve istatistiksel yöntemler kullanılarak elde edilen bilgilerin analiz edilmesi süreçlerinden oluşur (Krajewski, Ritzman, Malhotra, 2010: 284). Temsili örneklem seçimi, kabul edilebilir yanıt oranı, iyi tasarlanmış ve anlaşılır sorular pazar araştırması için önemli başarı kriterleridir. İyi yapılandırılmış ve tasarlanmış, genellemeye izin verecek örnekleme uygulanmış anketler oldukça etkili ve yol gösterici sonuçlar sunmaktadır.

2.5.1.5. SENARYO ANALİZİ

Konu ile ilgili uzmanlardan oluşan bir panel tartışması kullanılarak uzun vadeli tahmin çalışmaları için uygulanır. Panele katılan yönetici ve uzmanların her birinden gelecek ile ilgili bir dizi senaryo tasarlaması istenir. Daha sonra hazırlanan senaryoların her biri tartışılır ve gelecek ile ilgili riskler değerlendirilir. Senaryo analizinde Delphi yöntemindeki gibi bir fikir birliğine ulaşma amacı yoktur. Yöntem, olası seçeneklere bakmayı ve bunlar içerisinde karşılaşılmaması en az istenenlerden kaçınmak için plan yapmayı ve en çok isteneni takip etmek için harekete geçmeyi amaçlamaktadır (Slack, Chambers, Johnston 2007: 179).

2.5.1.6. YAŞAM ÇEVİRİMİ BENZEŞİMİ

Pek çok ürün ve hizmet pazara giriş, büyüme, olgunluk ve düşüş aşamalarından oluşan bir yaşam çevriminde yer almaktadır. Piyasaya yeni sürülecek ürün veya hizmete benzer ürün veya hizmetin yaşam çevriminin incelenmesi talep tahmini problemlerinde uygulayıcıya yardımcı olmaktadır. Benzer ürünün yaşam çevrim evrelerindeki talep yapıları, işletmelerin kendi ürünleri hakkında da talep ile ilgili öngörülerde bulunmasına imkân vermektedir. Özellikle, yeni ürün veya hizmet pazarda bulunan diğerinin yerini alıyorsa ve aynı kitleyi hedefliyorsa bu yöntemin kullanılması faydalı olacaktır (Bozart, Handfield, 2013: 257).

2.5.2. KANTİTATİF (NİCEL) YÖNTEMLER

Nicel tahmin yöntemleri, gelecek ile ilgili bir tahmin yapmak için geçmişe ait verileri ve nedensel değişkenleri matematiksel teknikler kullanarak modellemektedirler. Bu tahmin modelleri aracılığı ile talep tahmini değerlerini hesaplarken belirli kuralları takip etmek gerektiği için nitel yöntemlerin doğasında bulunan subjektif bakış açısı yerini objektif bir bakış açısına bırakmaktadır (Bozart, Handfield, 2013: 257; Wisner, Tan, Leong, 2014: 138). Zaman serisi teknikleri, nedensel modeller, ekonometrik modeller, simülasyon çalışmaları ve yapay zekâ teknikleri nicel tahminler üretmek için kullanılan başlıca yöntemlerdir.

2.5.2.1. ZAMAN SERİSİ MODELLERİ

Zaman serileri saatlik, günlük, haftalık, aylık, yıllık vb. bir zaman periyodunda düzenli aralıklar ile alınan gözlemlerin dizisidir. Bu gözlemler satışların, tüketimin, arızaların veya kazançların ölçümü olabileceği gibi başka pek çok veriyi de içerebilir. Zaman serilerine dayanan tahmin teknikleri, serilerin gelecekteki değerlerini sadece geçmiş değerlere bakarak tahmin etmektedir. Bu serilerde farklı veri yapıları görülmektedir ve bu yapılar farklı zaman serisi tekniklerinin geliştirilmesi için de itici bir güç oluşturmaktadır (Stevenson, 1996: 473). Trend, mevsimsellik, döngüsel ve rassal değişimler olmak üzere dört farklı zaman serisi bileşeni vardır.


- Trend: Zaman serilerinin sistematik bir şekilde artış veya azalış göstermesidir. Nüfus artış veya azalışları, değişen gelir veya kültürel değişiklikler trend içeren yapıların oluşmasına sebep olan gelişmelerdendir (Nahmias, Olsen, 2015: 59).
- Mevsimsellik: Belirli bir günde, haftada, ayda veya çeyrek zaman diliminde kendini tekrarlayan yapılardır. Tekstil ürünleri, doğal gaz tüketimi, elektrik tüketimi veya dondurma gibi bazı tüketim ürünleri güçlü bir şekilde mevsimsel yapı içerirler (Nahmias, Olsen, 2015: 59).
- Döngüsel Değişimler: Mevsimsel yapıya benzeyen fakat birkaç yılda bir oluşan yapılardır. Genellikle iki etkiden meydana gelirler. Bunlardan birincisi durgun olan ekonomik yapının birkaç yıl içerisinde büyümesine neden olan faktörleri içeren iş döngüsüdür. Ulusal veya uluslararası politik olaylardan ve kargaşalardan etkilendiği için iş döngüsünün öngörülmesi zordur. Diğer etki

ise gelişmeden düşüşe kadar talebin seyrini yansıtan hizmet veya ürün yaşam döngüsüdür (Krajewski, Ritzman, Malhotra, 2010: 277).

- **Rassal Değişimler:** Savaşlar, doğal afetler, grevler gibi tesadüfen ve beklenmedik olaylardan dolayı oluşan verideki sinyallerdir. Rastgele oluşan veri belirli bir yapıya sahip değildir ve bu nedenle önceden tahmin edilmesi oldukça zordur (Heizer, Render, Munson, 2017: 151). Sabit bir ortalama etrafında toplanan rassal veriler yatay bir model oluştururlar (Nahmias, Olsen, 2015: 60).

Elde bulunan verinin yukarıda ifade edilen bileşenlerden hangisini içerdiğini anlamak için bazı testlerin uygulanması gerekmektedir. Bununla birlikte verinin grafik üzerinde görselleştirilmesi de mevcut yapının anlaşılması için bir seçenek sunmaktadır. Şekil 24'te zamana ve nicel bir değere göre talep yapılarının grafik üzerindeki gösterimleri yer almaktadır.

Şekil 24: Talep Yapıları



Kaynak: Krajewski, Ritzman, Malhotra, (2010) s.278

Talep tahmin problemlerinde farklı yöntemler kullanılmaktadır. Bu yöntemler sırasıyla açıklanmıştır.

Naif Metot: Zaman serisi yöntemleri içerisinde en kolay uygulanan teknik olan naif metot gelecek dönemin talebinin son dönemin talebine eşit olduğunu varsaymaktadır. Yöntem yatay, trend veya mevsimsel kalıplar sabit olduğunda ve rassal varyasyon küçük olduğunda en iyi sonucu vermektedir (Krajewski, Ritzman, Malhotra, 2010: 287).

Hareketli Ortalama: Basit hareketli ortalama ile tahmin uygulaması yaparken geçmiş belirli sayıdaki dönem (n) verisi kullanılır. Bu n dönemdeki verilerin ortalaması bir sonraki dönem tahmini için kullanılır. Sonraki dönem için talep belli olduktan sonra bir önceki ortalamaadaki en eski talep işleminden çıkarılır ve hesaplanan en son talep ile gelecek dönem tahmini için ortalama tekrar hesaplanır. Bu şekilde ortalamalar dönemden döneme hareket eder.

Bu yöntemde karar verilmesi gereken önemli nokta periyot sayısı olan n değerinin belirlenmesidir. İstikrarlı talep yapılarına sahip ürünler için büyük n değerleri seçilebilirken, talebi değişkenlik gösteren ürünler için ise düşük n değerleri seçilmelidir.

Hareketli ortalamanın her döneme aynı ağırlığı vermesinden kaynaklanan hatalı tahminlerin önlenmesi için ağırlıklı hareketli ortalama yöntemi geliştirilmiştir. Bu yöntemde tahmin yapılacak döneme yakın döneme en fazla ağırlık verilirken en uzak döneme ise en düşük ağırlık değeri verilmektedir. Burada amaç en yeni değerini önemini korumak ve en son yaşanan değişikliklere daha duyarlı bir tahmin modeli oluşturmaktır. Ağırlık değerlerinin belirlenmesi ile ilgili belirli bir kural olmadığından dolayı daha önce edinilen tecrübelerden faydalanılır.

Üstel Düzeltme: Üstel düzeltme, İkinci Dünya Savaşı'nın yaşandığı 1944 yılında ABD Donanmasında çalışan Robert G. Brown tarafından ileri sürülen ateş kontrol teçhizatı izleme modeli ile ortaya çıkmıştır. Brown'ın izleme modeli sürekli verilerin basit bir şekilde üstel düzeltmesini içermiştir. Yöntem 1950'lerin başlarında Brown tarafından ayrık veriler için genişletilmiş, trend ve mevsimsellik içeren veri yapılarının analizi için geliştirilmiştir. Geliştirilen yöntemler donanma stoklarında bulunan yedek parça talep tahmini çalışmasında kullanılmıştır. 1950'lerde Charles C. Holt, Brown'dan bağımsız bir şekilde çalışarak trend içeren verileri üstel düzeltmek için

benzer bir yöntem ve mevsimsel verileri düzeltmek için ise tamamen farklı bir yöntem geliştirmiştir. 1960 yılında fikirleri geniş bir şekilde yayılmaya başlayan Holt'un yöntemleri, Winters tarafından deneysel veriler ile test edilmiştir ve bunlar Holt-Winters metodu olarak kullanılmaya başlanmıştır (Gardner Jr, 2006: 638).

Basit, kullanışlı, düşük maliyetli ve tahmin hesaplaması için az veriye ihtiyaç duyması ile sıkça kullanılan üstel düzeltme teknikleri için üç veri ögesi gerekmektedir; önceki dönemin tahmini, önceki dönemin gerçek talebi ve üstel sabit. Modelde kullanılacak düzeltme sabitinin 0'a eşit veya daha büyük ve 1'e eşit veya daha küçük olması gerekmektedir. 1'e yakın değere sahip olan düzeltme sabiti son talep seviyelerini vurgular ve temel ortalamadaki değişikliklere daha duyarlı tahminler üretir. 0'a daha yakın düzeltme sabiti ise geçmiş son talep seviyelerine daha az önem vererek daha durağan tahminler üretir (Krajewski, Ritzman, Malhotra, 2010: 288). Düzeltme sabitinin belirlenmesi ile ilgili kesin bir kural yoktur. Genellikle deneme-yanılma yolu ile ve önceki deneyimlerden edinilen tecrübelerle göre belirlenmektedir.

Üstel düzeltme tekniklerinin uygulanmasında farklı talep yapılarına sahip zaman serileri için yaygın bir şekilde kullanılan üç temel üstel düzeltme modeli vardır. Zaman serisi trend ve mevsimsellik içermediğinde genellikle basit üstel düzeltme tekniği kullanılmaktadır. Bu teknikte ortalama için düzeltme sabiti olan α değeri tahmin hatasının azaltılması için önemlidir. Diğer bir metod olan ikili üstel düzeltme yöntemi (Holt's Metod) yavaşça değişen ve doğrusal bir trend gösteren zaman serisini modellemek için kullanılmaktadır. Uygun α ve trend için düzeltme sabiti olan β değerlerinin belirlenmesi gerçeğe yakın tahminlerin yapılmasına yardımcı olmaktadır. Üçüncü model ise mevsimsellik içeren verilerin tahmin uygulamasında kullanılan Winters yöntemidir. α , β ve mevsimsellik için düzeltme sabiti olarak kullanılan γ değerleri başarılı tahmin sonuçları için dikkatle seçilmelidir (Lai, Yu, Wang, Huang, 2006: 494-495).

Box-Jenkins Yöntemi: ARIMA modelleri olarak da bilinen Box-Jenkins modellerinin temelleri 1920'lerin ikinci yarısında atılmaya başlanmıştır. AR modelleri 1926 yılında Yule tarafından tanıtılmıştır. 1937 yılında ise Slutsky tarafından MA modelleri oluşturulmuştur. AR ve MA modelleri 1938 yılında Word tarafından

birleştirilerek ARMA modeli oluşturulmuştur fakat gerçek hayat serileri üzerinde uygulamaları, modelin karmaşık hesaplamalarını yapmaya yardımcı olan bilgisayarlar bulunmadığı için 1960'lara kadar mümkün olmamıştır. 1970-1976 yıllarında George Box ve Gwilym Jenkins tarafından ARIMA modeli geliştirilmiştir. Model 1970'lerden itibaren zaman serisi analizleri için yürütülen deneysel çalışmalarda sıkça kullanılmaya başlanmıştır (Makridakis, Hibon, 1997: 147-148).

Bir zaman serisinin gelecekteki değerlerini geçmiş verilerin doğrusal bir kombinasyonunu ve bir dizi hatayı kullanarak tahmin eden ARIMA modellerini oluşturmak için beş temel adım vardır. ARIMA modelleri durağan zaman serileri üzerinde uygulandığından dolayı ilk önce durağanlık testleri yapılır. Serilerde mevsimsellik veya trend tespit edilirse fark alma işlemi yapılarak veriler durağan hale getirilir. Daha sonra hangi ARIMA modelinin daha uygun olduğuna karar verilmesi gerekir. Uygun modelin seçilmesinin ardından model parametrelerinin en uygun değerleri belirlenmelidir. Bu karar genellikle en küçük kareler yöntemleri veya maksimum olasılık yöntemi aracılığı ile yapılır. Model tanımlandıktan ve en uygun parametre değerlerine karar verildikten sonra tahmin işlemi gerçekleştirilir. Oluşturulan model zaman serilerinin gelecekteki olası değerlerini verir. En son adımda ise elde edilen tahmin sonuçlarına göre modelin performansı ilgili hata metrikleri ile değerlendirilir (Nahmias, Olsen, 2015: 100-101).

2.5.2.2. NEDENSEL (İLİŞKİSEL) YÖNTEMLER

Zaman serileri yöntemleri gelecek ile ilgili tahmini serinin geçmiş zamandaki değerleri ile ilişkilendirmektedir. Oysa bir serideki değerlerin farklılaşmasının tek nedeni zamandaki değişim olmayabilir. Çoğu zaman daha çevik ve doğru bir tahmin modeli oluşturmak için tahmin edilmek istenilen ilgili değişkeni etkileyen bazı açıklayıcı değişkenler dikkate alınmaktadır. Bu değişkenlerin bir veya birden fazla olmasına göre modelin yapısı değişmektedir. Basit doğrusal regresyon, çoklu doğrusal regresyon, lojistik regresyon, sıralı regresyon ve bazı makine öğrenmesi algoritmalarının regresyon modelleri, ekonometrik modeller ve simülasyon modelleri matematiksel olarak geliştirilmiş ve tahmin aracı olarak kullanılmıştır.

Basit Doğrusal Regresyon: Bağımlı değişkenin bir bağımsız değişken ile doğrusal bir denklem ile ilişkili olduğu modeldir. Bağımsız veya açıklayıcı değişkenin geçmişte gözlemlenen sonuçlara neden olduğu varsayılır. Basit doğrusal regresyonun matematiksel açıklaması aşağıdaki gibidir (Zou, Tuncali, Silverman, 2003: 619).

$$Y = a + bX + \varepsilon \quad (1)$$

Y = Bağımlı değişken

a = X sıfır olduğunda regresyon çizgisinin y eksenini kestiği değer


b = Bilinmeyen regresyon katsayısı ve regresyon çizgisinin eğimidir

X = Bağımsız değişken

ε = Hata terimi

Denklemin grafik üzerinde gösterimi Şekil 25'te gösterilmiştir.

Şekil 25: Basit Doğrusal Regresyon Çizgisi



Kaynak: Krajewski, Ritzman, Malhotra, (2010) s.285

İfade edilen doğrusal regresyon modelinde amaç denklem içerisindeki katsayıların (a ve b) tahmini değerlerini bulmaktır. Modelin doğruluğu üzerinde etkisi büyük olan model parametrelerini bulmak için hataları veya artık değerleri en aza indirmeyi amaçlayan en küçük kareler yöntemi kullanılmaktadır. Veri noktalarına en iyi uyan doğruyu tespit etmek için önem arz eden bu katsayıların en küçük kareler yöntemine göre hesaplanması için kullanılan matematiksel formüller aşağıdaki gibidir (James, Witten, Hastie, Tibshirani, 2013: 62).

$$b = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (2)$$

$$a = \bar{y} - b\bar{x} \quad (3)$$

Bu denklemdeki $\bar{x}$ ve $\bar{y}$ ifadeleri x ve y değişkenlerinin örneklem ortalamalarına karşılık gelmektedir.

Ekonometrik Modeller: Nedensel ilişkileri keşfederek tahmin çalışması yapmak için çeşitli regresyon modelleri dışında bazı diğer yöntemler de kullanılmaktadır. Örneğin sosyo-ekonomik verileri, ekonomik modelleri ve matematiksel istatistikleri incelemek için ekonometrik modeller kullanılmaktadır. Bağımlı ve bağımsız değişkenler arasındaki neden sonuç ilişkileri bu ekonometrik modellerle de tanımlanmaktadır. Bu modeli oluştururken altı temel adımdan söz edilmektedir. Bunlar; ekonomik hipotez geliştirme, hipotezin matematiksel modeli, hipotezin ekonometrik modeli, ekonometrik modelin bir tahmini, hipotezin testi ve tahmin (Ghalekhondabi, Ardjmand, Weckman, Young, 2017: 436).

Simülasyon Modeli: Bilgisayar simülasyonu, tahmin üretmek için çalışılan problem matematiksel olarak modellenemeyecek kadar karmaşık olduğunda en iyi alternatiflerden birisidir. Simülasyon, bir bilgisayar programına indirgenmiş problemin tanımıdır ve program gerçek durum dinamiklerinin temel yönlerini yeniden yaratmak için tasarlanmıştır. Program farklı koşullar ve senaryolar altında yeniden çalıştırılarak deneme yanılma yolu ile sistemi yönetebilecek en iyi stratejinin keşfedilmesine yardımcı olmaktadır (Nahmias, Olsen, 2015: 108-109).

2.5.2.3. YAPAY ZEKÂ MODELLERİ

Birçok işletme depolama, lojistik, tedarik zinciri ile ilgili önemli kararları verirken ve öngörülerde bulunurken yapay zekadan yararlanmaktadır. En basit tanımı ile yapay zekâ yöntemleri insan zekasını taklit etmek için hesaplama yeteneklerini kullanan yöntemlerdir. Bu yöntemler, tedarik zincirinde ortaya çıkacak risklerin veya yıkıcı olayların hızla değerlendirilmesi ve bu olayların olumsuz etkilerinin en aza indirilmesine olanak sağlayan tahmine dayalı yaklaşımların uygulanmasını mümkün kılmıştır (Riahi, Saikouk, Gunasekaran, Badraoui, 2021: 1-2). Tedarik zinciri talep tahmini problemlerinde yapay zekâ yöntemlerinden faydalanan çalışmalarda genetik algoritmalar, parçacık sürü optimizasyonu, karınca kolonisi algoritması, yapay sinir ağları, destek vektör makineleri gibi yöntemler sıklıkla kullanılmaktadır.

2.6. DOĞAL GAZ TALEP TAHMİNİ İLE İLGİLİ YAPILAN ÇALIŞMALAR

Son yıllarda doğal gaz tüketimini tahmin etmek üzerine birçok çalışma yapılmıştır. Bu çalışmalarda çeşitli ülkeler, bölgeler için farklı doğal gaz kullanıcıları, açıklayıcı değişkenler ve zaman aralıkları ele alınarak zaman serileri analizi, yapay zekâ kapsamında makine öğrenmesi yöntemleri ve hibrit yöntemler kullanılarak çeşitli tahmin modelleri geliştirilmiştir. Sanchez-Ubeda ve Berzosa (2007) İspanya’da sanayi sektörünün günlük doğal gaz tüketimini tahmin etmek için hazırladığı çalışmasında ayrıştırma yöntemini kullanmıştır. Oluşturduğu modelde haftanın günleri, hafta sonları ve tatil günleri gibi takvim ile ilgili çeşitli açıklayıcı değişkenleri kullanmıştır. Brabec, Konár, Pelikán ve Malý (2008) 62 bireysel müşteriden almış olduğu veriler ile günlük doğal gaz tüketimini tahmin etmek için ortalama sıcaklık ve zaman değişkenlerini kullanarak ARIMAX modeli kurmuştur. Tonkovic, Susac ve Somolanji (2009) Hırvatistan’ın saatlik doğal gaz talebini tahmin etmek için yapay sinir ağlarını kullanmıştır. Bağımsız değişken olarak meteorolojik verilerin kullanıldığı çalışmada ileri beslemeli bir yapay sinir ağı sınıfı olan çok katmanlı algılayıcı en düşük hata oranına sahip model olarak bulunmuştur. Elragal (2009) Bahreyn’in günlük doğal gaz tüketimini tahmin etmek için hibrit bir model geliştirmiştir. Parçacık sürü optimizasyonu ve yapay sinir ağından oluşan bu model hibrit olmayan yapay sinir ağı modeline göre daha az MAPE değeri ile daha başarılı tahmin sonuçları sunmuştur. Xie

ve Li (2009) Çin'in doğal gaz tüketimini tahmin etmek için genetik algoritma ile optimize edilmiş gri tahmin modelini oluşturmuştur. Hibrit model geleneksel gri modele göre daha az mutlak hataya sahip olup, daha başarılı tahmin sonuçlarının elde edilmesini sağlamıştır. Forouzanfar vd. (2010) İran'ın konut ve ticaret sektörlerinin yıllık doğal gaz tüketimini tahmin etmek için lojistik temelli bir yaklaşım sunmuştur. Azadeh vd. (2010) İran'ın kısa vadeli doğal gaz talebini tahmin etmek için hazırladığı çalışmada ANFIS ve yapay sinir ağlarını kullanmıştır. Tahmin modeline haftanın günü, bir önceki yılın aynı gününe ait talep, bir gün öncesine ait talep ve 2 gün öncesine ait talep verileri açıklayıcı değişken olarak dahil edilmiştir. ANFIS modeli düşük MAPE değeri ile yapay sinir ağlarına göre daha başarılı sonuçlar sunmuştur. Xu ve Wang (2010) Çin'in 2009-2015 yılları arasındaki gelecek doğal gaz talebini tahmin etmek için polinom eğrisi ve hareketli ortalama hibrit modelini kullanmıştır. PCMACP %3,63 MAPE oranı ile başarılı sonuçlar vermiştir. Sabo vd. (2011) farklı matematiksel modeller oluşturarak Hırvatistan'ın doğal gaz tüketimini tahmin etmek için yürüttüğü çalışmada sıcaklık verilerini açıklayıcı değişken olarak kullanmıştır. Çalışmada, oluşturulan matematiksel modellerin (Gompertz eğrisi doğrusal model Fermat – Torricelli – Weber (FTW)) doğal gaz tahmini için kabul edilebilir sonuçlar sağladığı ve doğal gaz tüketiminin hava sıcaklığı ile ilişkili olduğu tespit edilmiştir. Wadud vd. (2011) Bangladeş'in doğal gaz talep tahmini için ve 2025 yılına kadar ulusal ve sektörel (elektrik, sanayi) doğal gaz talep tahmini yapmak için dinamik ekonometrik model oluşturmuştur. Yapılan çalışmada GDP'nin doğal gaz talebini etkilediği sonucuna ulaşılmıştır. Yu vd. (2014) Şanghay'ın kısa dönem doğal gaz yükünü tahmin etmek için genetik algoritma ve geri yayımlı sinir ağı algoritmalarını içeren hibrit bir model sunmuştur. Karimi ve Dastranj (2014) İran'ın Yasouj şehrinin günlük doğal gaz talebini tahmin etmek genetik algoritma ve geri yayımlı sinir ağı algoritmalarını içeren hibrit bir model geliştirmiştir. Hava sıcaklığı, bağıl nem, yağış ve rüzgâr hızı bağımsız değişkenlerini içeren model, düşük MAPE oranıyla günlük doğal gaz talebini doğru bir şekilde tahmin edebilen güçlü bir araç olarak değerlendirilmiştir. Bianco vd. (2014) İtalya'da konut dışı yıllık doğal gaz tüketiminin uzun vadeli tahmini için bir regresyon modeli geliştirmiştir. Oluşturulan modelde ortalama yıllık minimum sıcaklık, GDP ve gaz fiyatı açıklayıcı değişkenler olarak kullanılmıştır. Khan (2015) Pakistan'ın yıllık doğal gaz talebini sektörel olarak tahmin etmek için ekonometrik bir

model ileri sürmüştür. Modelde GDP, doğal gaz fiyatı, tüketici fiyat endeksi ve nüfus olmak üzere dört açıklayıcı değişken kullanılmıştır. Azadeh vd. (2015) İran'ın doğal gaz tüketimini tahmin etmek için uyarlamalı ağ tabanlı bulanık çıkarım sistemi ve bilgisayar simülasyonu yöntemlerinden oluşan hibrit bir model geliştirmiştir. Szoplik (2015) yapay sinir ağları ile Polonya'nın Szczecin şehrinin konut ve ticari sektörü için saatlik doğal gaz talebini tahmin etmiştir. Hava sıcaklığı ve zaman ile ilgili değişkenlerin (ay, ayın günü, haftanın günü, günün saati) kullanıldığı modelde veri boyutu ve gizli nöron sayısının tahmin performansını etkilediği bulunmuştur. Izadyar vd. (2015) İran'da konutların aylık doğal gaz talebini tahmin etmek için aşırı öğrenme makineleri, yapay sinir ağları ve genetik programlama olmak üzere üç model kullanmıştır. RMSE ve R^2 sonuçlarına göre aşırı öğrenme makinelerinin diğer modellerden daha iyi sonuçlar sunduğu tespit edilmiştir. Fagiani vd. (2015) ev suyu ve doğal gaz talebini tahmin etmek ve karşılıklı korelasyon etkilerini araştırmak için genetik programlama ve genişletilmiş kalman filtresini kullanmıştır. Yapılan çalışmada GP modeli en iyi tahmin sonuçlarını sunarken su tüketimi ve doğal gaz kullanımı arasında güçlü bir korelasyon bulunmuştur. Shaikh ve Ji (2016) orta ve uzun vadede Çin'in doğal gaz talebini tahmin etmek için lojistik model oluşturmuştur. Parametreleri Levenberg-Marquardt algoritması ile elde edilen ve nüfus ve GDP bağımsız değişkenlerinin kullanıldığı lojistik model düşük MAPE değerleri ile güçlü sonuçlar sunmuştur. Shakouri ve Kazemi (2016) İran'da konut ve ticaret sektörleri yıllık enerji talep tahmini için ARMAX modeli oluşturmuştur. Modele açıklayıcı değişken olarak GDP, nüfus, doğal gaz fiyatı ve gelir dahil edilmiştir. Cardoso vd. (2016) Brezilya'nın doğal gaz tüketimini tahmin etmek için yapay sinir ağları, ARIMA ve sinir ağları ve ARIMA hibrit modeli kullanmıştır. Yapay sinir ağı ve hibrit modeller ARIMA modelinden daha az hata oranına sahip değerler tahmin etmiştir. Panapakidis ve Dagoumas (2017) Yunanistan'ın günlük doğal gaz talebini tahmin etmek için wavalet dönüşüm, ANFIS, genetik algoritma ve ileri beslemeli sinir ağından oluşan hibrit bir model sunmuştur. Scarpa ve Bianco (2017) İtalya konut sektörü için doğal gaz tüketimi tahmini ve bu tahminin dışsal değerler bağlamında kalitesini ölçmek için yürüttüğü çalışmada regresyon modeli ve kalman filtresini kullanmıştır. Oluşturulan tahmin modelinde ısıtılan gün sayısı, GDP ve doğal gaz fiyatı açıklayıcı değişkenler olarak kullanılmıştır. Chen vd. (2018) Almanya'nın gün öncesi doğal gaz

talebini tahmin etmek için dıřsal (aıklayıcı) deęiřkenli fonksiyonel otoregresif modeller sunmuřtur. Fonksiyonel otoregresif modeller karřılařtırılan dięer modellerden daha gl performans gstermiřtir. Ding (2018) in'in yıllık doęal gaz talebini tahmin etmek iin kendini uyarlayan akıllı bir gri model geliřtirmiřtir. Oluřturulan model, karřılařtırma yapmak iin kullanılan dięer modellerden daha iyi sonular sunmuřtur. Liu vd. (2018) in'in hane halkının doęal gaz tketimi ve doęal gaz tketimini etkileyen faktrler zerine bir arařtırma yapmıřtır. Genelleřtirilmiř en kk kareler yntemi ile oluřturulan modelde doęal gaz fiyatı ve gelir aıklayıcı deęiřken olarak kullanılmıřtır ve bu iki deęiřkenin ortalama doęal gaz tketimini etkiledięi sonucuna ulařılmıřtır. Wang vd. (2018) in'in doęal gaz talebini tahmin etmek iin hibrit bir model oluřturmuřtur. Paracık sr optimizasyonu ve wavelet sinir aęını birleřtiren hibrit model %2,31 MAPE oranıyla dięer modellere gre daha gl sonular ortaya ıkarmıřtır. Potonik vd. (2019) Slovenya'nın Ljubljana řehrindeki konutların doęal gaz talebini tahmin etmek iin doęrusal regresyon, kernel metot ve yapay sinir aęlarını kullanmıřtır. Hava durumu ile ilgili verilerin (hava sıcaklıęı, gneř radyasyonu, nem ve rzgr hızı) aıklayıcı deęiřken olarak kullanıldıęı alıřmada yinelemeli sinir aęı ve doęrusal regresyon en az hata oranına sahip sonular retmiřtir. Lu, Azimi, Iseley (2019) in'in Kunming kentindeki gazın kısa vadeli yk tahmini iin meyve sineęi optimizasyon algoritması ve destek vektr makinesini ieren hibrit bir model sunmuřtur. Costa vd. (2020) Brezilya'nın yıllık doęal gaz talebini tahmin etmek sıradan ve saęlam en kk kareler ynteminin kullanıldıęı doęrusal regresyon modeli oluřturmuřtur. GDP, doęal gaz fiyatı, depolanan enerji ve nfusun aıklayıcı deęiřken olarak dahil edildięi saęlam en kk kareler yntemi ile oluřturulan doęrusal regresyon model sıradan en kk kareler yntemine gre daha bařarılı sonular vermiřtir. Hussain vd. (2022) 2016–2030 yılları arasında Pakistan'daki doęal gaz talebini tahmin etmek iin en uygun modeli semek amacıyla bir alıřma yrtmřtir. Gemiř verileri kullanarak oluřturulan ARIMA ve Holt-Winter modellerini hata metrięi olan MAPE'yi kullanarak karřılařtırmıřtır. alıřmanın sonuları ARIMA'nın Pakistan'daki gaz tketimini tahmin etmek iin uygun model olduęunu ortaya koymuřtur.

Türkiye'nin doğal gaz talebini tahmin etmek için yürütülen çalışmalar da son yıllarda artmaya başlamıştır. Aras (2008) konut sektöründe aylık doğal gaz tüketimini tahmin etmek için genetik algoritma modeli kurmuştur. Oluşturulan modelde ortalama sıcaklık ve tüketici fiyat endeksi açıklayıcı değişken olarak kullanılmıştır. Kızılaslan ve Karlık (2008) kapsamlı bir faktör analizi yapılarak belirlenen değişkenleri kullanarak İstanbul'un doğal gaz talebini günlük ve haftalık olarak tahmin etmek için yapay sinir ağlarını kullanmıştır. Günlük talep tahmini için hızlı yayılım algoritması, haftalık talep tahmini için ise eşlenik gradyan iniş algoritmasının daha uygun olduğu belirlenmiştir. Erdoğan (2010) Türkiye'deki sektörel doğal gaz talebinin özelliklerine ve tahmini kısa ve uzun vadeli fiyat ve gelir esnekliklerine odaklanmıştır. Gelecekte talepte görülecek büyümeyi ARIMA modelini kullanarak tahmin etmiştir. Modelin tahmin sonuçlarını resmi makamların (ETKB vs.) yapmış olduğu tahminler ile karşılaştırmıştır ve yapılan tahminler arasında ciddi bir fark olmadığı belirlenmiştir. Görücü vd. (2010) Ankara için doğal gaz tüketimini değerlendirmek ve tahmin etmek için Yapay Sinir Ağlarını kullanmıştır. Derece gün (DD), doğal gaz fiyatı, tüketici sayısı ve enflasyon oranı açıklayıcı değişkenler olarak kullanılmıştır. Akkurt, Demirel, Zaim (2010) Türkiye'nin aylık ve yıllık doğal gaz tüketimini tahmin etmek için zaman serisi tahmin modellerini kullanmıştır. Yıllık veri setinde çift üstel düzeltme modelinin, aylık veri setinde ise SARIMA modelinin diğerlerinden daha iyi sonuçlar verdiği sonucuna ulaşılmıştır. Toksari (2010) Türkiye'nin doğal gaz talebini tahmin etmek için ekonomik göstergelere dayalı olasılıksal yaklaşımlı bir algoritma kullanmıştır. Kaynar vd. (2011) Türkiye'nin haftalık doğal gaz tüketimini tahmin etmek için ARIMA, yapay sinir ağları ve ANFIS modellerini kullanmıştır. Demirel vd. (2012) enerji sektöründe faaliyet gösteren bir Türk işletmesinin doğal gaz tüketimini tahmin etmek için yapay sinir ağları ve çok değişkenli zaman serisi yöntemlerini kullanmıştır. Çalışmada, geri yayımlı yapay sinir ağı modelinin diğer modellere göre daha az hata değerine sahip olduğu sonucuna ulaşılmıştır. Taşpınar vd. (2013) Sakarya ilinin günlük doğal gaz tüketimini meteorolojik verileri kullanarak oluşturulan SARIMAX ve ileri beslemeli yapay sinir ağı olan çok katmanlı algılayıcı ile tahmin etmiştir. Hata metrikleri sonuçlarına göre SARIMAX modelinin daha doğru tahmin yaptığı görülmüştür. Melikoğlu (2013) Türkiye'nin 2013-2030 yılları arası Türkiye doğal gazını tahmin etmek lojistik model ve doğrusal model kullanmıştır. Kullanılan

modeller resmi makamlar tarafından yapılan tahminlere göre daha başarılı sonuçlar vermiştir. Boran (2015) Türkiye'nin doğal gaz talebini 1987-2012 yılları tüketim verilerini kullanarak gri tahmin modeli ile modelledikten sonra, 2014-2018 yılları tüketim miktarını tahmin etmiştir. Çalışmanın sonucunda sadece yıllık veriler içeren az miktardaki veri setleri için Gri Tahmin modellerinin güçlü tahmin sonuçları verdiği anlaşılmıştır. Akpınar ve Yumuşak (2016) zaman serisi yöntemlerini kullanarak Sakarya ilinin doğal gaz tüketimini konut ve düşük tüketim oranına sahip ticari işletmelerin tüketim verilerini kullanarak tahmin etmiştir. Ervural vd. (2016) İstanbul'un aylık doğal gaz talebini tahmin etmek için ARMA ve genetik algoritmayı birleştiren hibrit bir model sunmuştur. Özdemir vd. (2016) Türkiye'nin yıllık doğal gaz tüketimini tahmin etmek için doğrusal regresyon, genetik algoritma, benzetilmiş tavlama ve genetik algoritma hibrit modeli kullanmıştır. Önerilen hibrit model kullanılan diğer yöntemlere göre daha az hata oranına sahip sonuçlar sunmuştur. Karadede vd. (2017) Türkiye'nin yıllık doğal gaz talebi tahminini modellemek için breeder hibrit algoritma kullanmıştır. Özmen vd. (2018) Ankara'da bulunan konut kullanıcılarının günlük doğal gaz talebini tahmin etmek için MARS (Multivariate Adaptive Regression Splines), CMARS (Conic Multivariate Adaptive Regression Splines), yapay sinir ağları ve doğrusal regresyon yöntemlerini kullanmıştır. MARS ve CMARS modelleri düşük ve birbirine çok yakın MAPE oranlarıyla diğer modellerden daha iyi tahmin değerleri üretmiştir. Beyca vd. (2019) İstanbul ilinin aylık doğal gaz tüketimini çoklu doğrusal regresyon, Yapay sinir ağları ve destek vektör regresyonu modellerini kullanarak tahmin etmiştir. Çalışmanın bulgularına göre destek vektör regresyonu ile oluşturulan modelin diğer modellere göre daha az tahmin hatasına sahip olduğu sonucuna ulaşılmıştır. Şen, Günay, Tunç (2019) Türkiye'nin doğal gaz tüketimini sosyo-ekonomik değişkenler (GDP ve enflasyon) kullanarak tahmin etmiştir. Yapılan çalışmada doğrusal regresyon, doğrusal olmayan regresyon ve logaritmik regresyon yöntemleri kullanılmıştır. Düşük hata oranına sahip doğrusal olmayan regresyon modeli kullanılarak 2015-2025 yılları arası doğal gaz tahmini yapılmıştır. Es (2021) Türkiye'nin aylık doğal gaz tüketimini tahmin ettiği çalışmasında sezonsal gri tahmin modeli, ayarlamalı sezonsal gri tahmin modeli ve SARIMA modeli oluşturmuştur. Yükseltan vd. (2021) Fourier serilerini kullanarak

Türkiye'deki büyük yerleşim bölgeleri (İstanbul, Ankara, Bursa ve Eskişehir) için doğal gaz tüketimini yıllık, aylık, haftalık ve günlük olarak incelenmiştir.

Tablo 10: 2007-2022 Yılları Arası Doğal Gaz Talep Tahmini Çalışmaları Özeti

Uygulanan Alan	Şehir	Yazarlar	Metot	Hata Metriği	Zaman Aralığı	Değişkenler
Almanya	-	Chen vd. (2018)	Dışsal değişkenli Fonksiyonel Otoregresif Modeller	MAPE RMSE	Saatlik	Hava sıcaklığı
Bahreyn	-	Elragal (2009)	Parçacık Sürü Optimizasyonu ve Yapay Sinir Ağından oluşan hibrit bir model	MAPE	Günlük	-
Bangladeş	-	Wadud vd. (2011)	Dinamik Ekonometrik Model	R ²	Yıllık	GDP Nüfus Fiyat
Brezilya	-	Cardoso vd. (2016)	Yapay Sinir Ağları ARIMA Modeli Sinir Ağları ve ARIMA hibrit modeli	MAE RMSE MAPE	-	-
		Costa vd. (2020)	Doğrusal Regresyon	MAD	Yıllık	Ortalama doğal gaz fiyatı GDP Nüfus Rezervlerde depolanan enerji
Çek Cumhuriyeti	-	Brabec vd. (2008)	ARIMAX	MAE	Günlük	Günlük ortalama sıcaklık
	-	Xie, Li (2009)	Geleneksel Gri Model Genetik Algoritma ile optimize edilmiş Gri Model	Mutlak Hata	Yıllık	-
	-	Xu, Wang (2010)	Polinom Eğrisi Hareketli Ortalama	MAPE	Yıllık	-
	-	Shaikh, Ji (2016)	Lojistik Model	MAPE	Yıllık	Nüfus GDP
	-	Ding (2018)	Yeni geliştirilen kendini	APE MAPE RMSE	Yıllık	-

Çin			uyarlayan akıllı bir gri model			
	-	Liu vd. (2018)	Genelleştirilmiş En Küçük Kareler Yöntemi	-	Yıllık	Kişi baş doğal gaz tüketimi Gaz fiyatı
	-	Wang vd. (2018)	Parçacık Sürü Optimizasyonu ve Wavelet Sinir Ağı hibrit model	MAPE	Yıllık	GDP Doğal gaz üretim miktarı Hane halkı tüketim seviyesi Gaza erişimi olan nüfus Şehirleşme oranı
	-	Fan vd. (2018)	Genetik Algoritma, Gri Model ve Kendini Uyarlayan Akıllı Gri Modeli içeren bir hibrit model	MAPE RMSE MAE	Yıllık	-
	Kunming	Lu vd. (2019)	Meyve Sineği Optimizasyon Algoritması ve Destek Vektör Makinesi Hibrit Model	MAPE MSE RMSE	Günlük Haftalık Aylık	Ortalama sıcaklık Hava durumu verileri Tatil günleri Tarih (gün)
Hırvatistan	-	Tonkovic vd. (2009)	Yapay Sinir Ağları	MAPE	Saatlik	Meteorolojik değişkenler (sıcaklık, rüzgâr hızı, rüzgâr yönü) Önceki günün saatlik tüketimi Takvimsel değişkenler (gün türü-tatil, çalışma günü-, haftanın günleri ve sezon)
	-	Sabo vd. (2011)	Gompertz eğrisi Doğrusal model Fermat – Torricelli – Weber (FTW)	Mutlak Hata	Saatlik	Sıcaklık
	-	Potocnik vd. (2014)	Kıyaslama Modelleri (RW)	NMAE R ²	Günlük	Hava sıcaklığı Güneş radyasyonu

			Model, TC Model) Doğrusal Modeller (Kademeli Regresyon,) Doğrusal Olmayan Modeller (Yapay Sinir Ağları, Destek Vektör Regresyonu)			
İran	-	Forouzanfar vd. (2010)	Lojistik Temelli Yaklaşım *Lojistik parametreleri tahmin etmek için Doğrusal Olmayan Programlama ve Genetik Algoritma kullanıldı	-	Yıllık	-
	-	Azadeh vd. (2010)	ANFIS Yapay Sinir Ağları	MAPE	Günlük	Haftanın günü, bir önceki yılın aynı gününe ait talep, bir gün öncesine ait talep ve 2 gün öncesine ait talep
	Yasouj	Karimi, Dastranj (2014)	Genetik Algoritma ve Geri Yayılımlı Sinir Ağı algoritmalarını içeren hibrit bir model	MAPE	Günlük	Hava sıcaklığı Bağlı nem Yağış ve rüzgâr hızı
	-	Azadeh vd. (2015)	Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi ve Bilgisayar Simülasyonu yöntemlerinde n oluşan hibrit bir model	MAPE	Yıllık	Nüfus GDP Fiyat Enflasyon İşsizlik Oranı IT/IS indeksi İnsani Gelişim İndeksi Karbonmonoksit Emisyonu
	-	Izadyar vd. (2015)	Aşırı Öğrenme Makineleri Yapay Sinir Ağları Genetik Programlama	RMSE R ²	Aylık	Hava sıcaklığı

	-	Shakouri, Kazemi (2016)	ARMAX Modeli	MAPE R ²	Yıllık	GDP Nüfus Fiyat Gelir
İspanya	-	Sanchez-Ubeda, Berzosa (2007)	Ayrıştırma Yöntemi	MAPE	Günlük	Takvim Bilgisi (haftanın günleri, hafta sonu ve tatiller, Paskalya ve Noel)
İtalya	-	Bianco vd. (2014)	Regresyon	MAPE MAD MSE	Yıllık	Ortalama yıllık minimum sıcaklık GDP Gaz fiyatı
	-	Fagiani vd. (2015)	Genetik Programlama Genişletilmiş Kalman Filtresi	NMSE R ²	Saatlik	Zaman
	-	Scarpa, Bianco (2017)	Regresyon Modeli Kalman Filtresi	-	Yıllık	HDD GDP Doğal gaz fiyatı
Pakistan	-	Khan (2015)	Ekonometrik Model	MAPE	Yıllık	GDP Doğal gaz fiyatı Tüketici Fiyat Endeksi Nüfus
	-	Hussain vd. (2022)	ARIMA Holt-Winter Yöntemi	MAPE	Yıllık	-
Polonya	-	Szoplik (2015)	Yapay Sinir Ağları	MAPE RMSE nRMSE	Saatlik	Hava sıcaklığı Zaman ile ilgili değişkenler (ay, ayın günü, haftanın günü, günün saati)
Slovenya	Ljubljana	Potočnik vd. (2019)	Doğrusal Regresyon Kernel Method Yapay Sinir Ağları	MAE MAPE	Saatlik	Hava durumu değişkenleri (Hava sıcaklığı, güneş radyasyonu, nem ve rüzgâr hızı)
Şanghay	-	Yu vd. (2014)	Genetik Algoritma ve Geri Yayılımlı Sinir Ağı algoritmalarını içeren hibrit bir model	MAE MAPE RMSE	-	-
	-	Aras (2008)	Genetik Algoritma	-	Aylık	Ortalama sıcaklık

Türkiye						Tüketici Fiyat Endeksi
	İstanbul	Kızılaslan, Karlık (2008)	Yapay Sinir Ağları	ARE	Günlük Haftalık	Toplam tüketici sayısı Zaman (gün, ay ve yıl) Önceki gün tüketimi Önceki gün maksimum ve minimum hava sıcaklığı Maksimum ve minimum hava sıcaklığı
	-	Kızılaslan, Karlık (2009)	Yapay Sinir Ağları	ARE	Aylık	Maksimum ve minimum tüketici sayısı Aylık ortalama sıcaklık değerleri Ay faktörü Yıl faktörü
	-	Erdoğan (2010)	ARIMA modeli	MAPE	Çeyreklik (3 aylık)	Sanayi, konut ve elektrik üretim sektörü doğal gaz tüketimi GDP Fiyat
	Ankara	Görücü vd. (2004)	Yapay Sinir Ağları	-	Günlük	Degree-Day(DD), Fiyat Tüketici sayısı Enflasyon oranı
	-	Akkurt vd. (2010)	ARIMA Box-Jenkins Üstel Düzeltilme Winters Modeli	MAD	Aylık Yıllık	-
	-	Toksari (2010)	Benzetilmiş Tavlama	Mutlak Hata	Yıllık	GDP Nüfus İhracat İthalat
	-	Kaynar vd. (2011)	ARIMA Yapay Sinir Ağları Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS)	MAPE	Haftalık	-
	-	Demirel vd. (2012)	Yapay Sinir Ağları	RMSE MAD	Günlük	Hava sıcaklığı Fiyat

			Çok Değişkenli Zaman Serisi Yöntemleri (ARMAX, OLS)	MAPE		Tüketim gecikmeleri
	Sakarya	Taşpınar vd. (2013)	SARIMAX Yapay Sinir Ağları-MLP Yapay Sinir Ağları-RBF Regresyon	RMSE MAPE R ²	Günlük	Meteorolojik Veriler (nem, atmosferik basınç, rüzgâr hızı ve sıcaklık)
	-	Melikoğlu (2013)	Lojistik Model Doğrusal Model	RMSE MAPE R ²	Yıllık	Nüfus değişimi GDP
		Boran (2015)	Yuvarlanma Mekanizmalı Gri Tahmin Modeli	MAPE	Yıllık	-
	Sakarya	Akpınar, Yumuşak (2016)	Holt-Winters Üstel Düzeltme ARIMA SARIMA	MAPE R ²	Aylık	-
	İstanbul	Ervural vd. (2016)	ARMA ve Genetik Algoritmayı birleştiren hibrit bir model	MAPE	Aylık	-
	-	Özdemir vd. (2016)	Doğrusal Regresyon Genetik Algoritma Benzetilmiş Tavalama ve Genetik Algoritma hibrit modeli	MAPE	Yıllık	GDP Nüfus Büyüme hızı
	-	Karadede vd. (2017)	Breeder Hibrit Algoritma	MAPE	Yıllık	GDP Nüfus Büyüme hızı
	Ankara	Özmen vd. (2018)	MARS CMARS Yapay Sinir Ağları Doğrusal Regresyon	R ² AAE RMSE MAPE	Günlük	Isıtma Gün Dereceleri (HDD)
	İstanbul	Beyca vd. (2019)	Çoklu Doğrusal Regresyon, Yapay Sinir Ağları ve	MAPE MSE	Aylık	Mevsim indeks, hava sıcaklık değerleri, doğal gaz fiyatı, nüfus, 12

			Destek Vektör Regresyonu			gecikmeli tüketim
	-	Şen vd. (2019)	Çoklu Doğrusal Regresyon Çoklu Doğrusal Olmayan Regresyon Logaritmik Çoklu Regresyon	MAD RMSE R ²	Yıllık	Nüfus GDP Enflasyon Oranı Doğal Gaz Fiyatı Ortalama Hava Sıcaklığı
	-	Es (2021)	Sezonsal Gri Tahmin Modeli Ayarlamalı Sezonsal Gri Tahmin Modeli SARIMA	MAE RMSE MAPE	Aylık	-
	İstanbul, Ankara, Bursa ve Eskişehir	Yükseltan vd. (2021)	Fourier Serisi	RMSE MAPE	Yıllık, Aylık Haftalık	Sıcaklık
Yunanistan	-	Panapakidis , Dagoumas (2017)	Wavalet Dönüşüm, ANFIS, Genetik Algotirma ve İleri Beslemeli Sinir Ağı'ndan oluşan hibrit bir model	MAE MAPE RMSE MARN E	Günlük	Zaman Hava sıcaklığı

2.7. TAHMİN HATASININ ÖLÇÜMÜ

Geleceğin ve tahmine eklenen değişkenlerin belirsizliğinden dolayı yapılan tahminler her zaman hata içerirler. Bu tahmin hatasının ölçümü tahmin modelinin performansını değerlendirmek veya farklı tahmin modellerinin performansını karşılaştırmak için önemli bir yol göstericidir. Tahminlerin gerçekleşenden ne kadar farklı olduğunun bir göstergesi olan tahmin hatalarının birden fazla nedeni olabilir. Bunları aşağıdaki gibi sıralayabiliriz (Stevenson, 1996: 498).

- Modele dahil edilmesi gereken önemli bir değişkenin ihmalı
- Modele eklenen değişkenlerde ani trend veya döngü gibi başa çıkılamayan değişiklikler

- Domino etkisi yaratabilecek ciddi hava ve diğer doğal olaylar, ani kıtlık, arızalar ve afet benzeri olaylar sonucu meydana gelebilecek düzensiz sapmalar
- Tahmin tekniğinin yanlış kullanımı ve sonuçların yanlış yorumlanması
- Veride bulunan rastgele sapmalar. Bu rastgelelik tüm sapma/değişim nedenleri açıklandıktan sonra verilerde kalan doğal sapmalar/değişimlerdir.

Yukarıda belirtilen sebeplerden dolayı meydana gelen ve belirli bir zaman diliminde gerçekleşen talep ile tahmin edilen talep arasındaki farkı belirten tahmin hatalarını değerlendirmek için farklı ölçütler kullanılmaktadır. Bu ölçütler hataları vurgulama biçimleri açısından farklılık göstermektedir (Krajewski, Ritzman, Malhotra, 2010: 282).

2.7.1. ORTALAMA MUTLAK HATA (MAE)

Ortalama mutlak hata, n dönemdeki t zamanda gerçekleşen değer A_t ve tahmin edilen değer F_t arasındaki mutlak farkın ortalamasını vermektedir. Diğer bir deyişle gerçekleşen ve tahmin edilen değer arasındaki doğrudan sapmayı temsil etmektedir. Aynı veri kümesiyle yapılan farklı tahminleri karşılaştırmak için kullanışlıdır fakat farklı veri kümelerindeki sonuçları karşılaştırmak için uygun değildir (Karabiber, Xydis, 2020: 6).

Hataları fazla veya az olduğuna bakmaksızın düz bir şekilde ölçen Ortalama Mutlak Hata (MAE) aşağıdaki denklem ile hesaplanmaktadır (Ciulla, D'Amico, 2019: 8).

$$MAE = \frac{1}{n} \sum_{t=1}^n |A_t - F_t| \quad (4)$$

2.7.2. ORTALAMA KARELER HATASI (MSE)

Hata metrikleri içerisinde en yaygın kullanılanlardan birisi olan Ortalama Kareler Hatası gerçekleşen ve tahmin edilen değer arasındaki varyansı hesaplar. Hata ölçümü yaparken hataların karesi alındığından dolayı negatif ve pozitif hata aynı etkiye sahiptir. Bununla birlikte daha büyük hatalara ve aykırı değerlere karşı hassastır. (Karabiber, Xydis, 2020: 6).

MSE hata değeri aşağıda gösterilen denklem ile hesaplanmaktadır (Ciulla, D'Amico, 2019: 8);

$$MSE = \frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2 \quad (5)$$

2.7.3. HATA KARELER ORTALAMASININ KAREKÖKÜ (RMSE)

RMSE metriği hata kareler ortalamasının karekökünü temsil etmektedir. RMSE, hataların tarafsız olduğu ve normal bir dağılım izlediği varsayımında hata dağılımının geniş bir resmini sağlamaktadır (Chai, Draxler, 2014: 1248).

RMSE aşağıdaki formül ile hesaplanmaktadır (Ciulla, D'Amico, 2019: 8).

$$RMSE = \sqrt{\sum_{t=1}^n \frac{(A_t - F_t)^2}{n}} \quad (6)$$

2.7.4. ORTALAMA MUTLAK YÜZDE HATASI (MAPE)

Ortalama Mutlak Yüzde Sapması olarak da bilinen metrik, gerçekleşen ve tahmin edilen değerler arasındaki mutlak hatayı göstermektedir. Model tahmini için kullanılan verilerin farklı ölçeklere sahip olduğu durumlarda bağıl hataları tahmin etmek için tercih edilen bir yöntemdir (Azadeh, Asadzadeh, Ghanbari, 2010: 1530). Finans, enerji, üretim ve birçok alanda yürütülen tahmin çalışmaları için hata ölçüm kriteri olarak sıklıkla kullanılmaktadır. Yüzde olarak ifade edildiğinden dolayı tahmin edilecek miktarın sıfırın çok üzerinde olduğu durumlarda önemli bir seçenektir (De Myttenaere, Golden, Le Grand, Rossi, 2016: 38). Gerçek verinin sıfır olduğu durumlarda hata sonsuz olacağından sıfır değerinin olabileceği verilerle kullanmak mümkün değildir ((Karabiber, Xydis, 2020: 6).

Ortalama Mutlak Yüzde Hatası aşağıdaki denklem ile ifade edilmektedir (Ciulla, D'Amico, 2019: 8). Formülde bulunan mutlak değer negatif ve pozitif yüzde hatalarının birbirini ortadan kaldırmasını engellemek için kritik bir öneme sahiptir (Akpınar, Yumuşak, 2016: 6).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100 \quad (7)$$

2.7.5. BELİRLİLİK KATSAYISI (R²)

Belirlilik Katsayısı (R²) oluşturulan modelin gerçek veri noktalarına ne kadar iyi uyduğunu değerlendirir. Bu ölçü modelin tahmin edebilirlik derecesinin önemli bir göstergesidir. R² değeri ne kadar yüksek olursa geliştirilen modelin o kadar verimli olduğu varsayılır (Ciulla, D’Amico, 2019: 8).

Belirlilik Katsayısı (R²) aşağıdaki formül ile hesaplanmaktadır (Ciulla, D’Amico, 2019: 8).

$$R^2 = 1 - \frac{\sum_{t=1}^n (A_t - F_t)^2}{\sum_{t=1}^n (A_t - \bar{A})^2} \quad (8)$$

Tablo 2.1’de görüldüğü üzere doğal gaz talep tahmin modellerinin performansını değerlendirmek için genellikle MAE, MSE, RMSE, MAPE ve R² metrikleri kullanılmıştır. Bu metrikler yukarıda detaylı bir şekilde açıklanmıştır. Fakat bunların yanı sıra MNAPE, MARNE, WMAPE, NMSE, ARE, CC ve SD metriklerinin de bazı çalışmalarda kullanıldığı görülmüştür. Bu hata ölçüm araçlarının matematiksel açıklamaları Tablo 11’de gösterilmiştir.

Tablo 11: Doğal Gaz Talep Tahmini Çalışmalarında Nadiren Kullanılan Hata Metrikleri

MNAPE	$\frac{1}{n} \sum_{t=1}^n \frac{ A_t - F_t }{\bar{A}} \times 100$
MARNE	$\frac{1}{n} \sum_{t=1}^n \frac{ A_t - F_t }{\max(A_t)} \times 100$
WMAPE	$\frac{\sum_{t=1}^n A_t - F_t }{\sum_{t=1}^n A_t} \times 100$
NMSE	$\frac{\sum_{t=1}^n (A_t - F_t)^2}{\sum_{t=1}^n (A_t - \bar{A})^2}$
ARE	$\frac{ F - A }{F}$
CC	$\frac{cov(A_t, F_t)}{\sqrt{D(A_t)D(F_t)}}$

SD	$\sqrt{\frac{\sum_{t=1}^n (F_t - \bar{A})^2}{n}}$
------	---

Kaynak: Liu, Wang, Wei, Chen, Xie, Wang (2021), s.10

ÜÇÜNCÜ BÖLÜM

MAKİNE ÖĞRENMESİ

3.1. MAKİNE ÖĞRENMESİNE GENEL BAKIŞ

İnsanın yaşam serüveni içerisinde çok yönlü bir olgu olan öğrenme, yeni bildirimsel bilginin elde edilmesi, eğitim veya uygulama gibi çeşitli yöntemlerle motor ve bilişsel becerilerin geliştirilmesi, gözlem ve deneyim yolu ile yeni gerçeklerin ve teorilerin keşfedilmesi süreçlerini kapsamaktadır (Carbonell, Michalski, Mitchell, 1983: 69). Söz konusu makineler olduğunda ise öğrenme sürecinden bahsedilmesi için bir makinenin performansını arttıracak şekilde girdilere ve dışarıdan gelen bilgilere yanıt olarak yapısal programını veya verilerini değiştirmesi beklenmektedir. Örneğin, konuşma tanıma görevini yerine getirmesi beklenen makinenin bir kişinin konuşmasının birkaç örneğini dinledikten sonra performansının artması makinenin öğrenme süreci içerisinde olduğuna işaret etmektedir (Nillson, 1997: 1).

İnsanın evrim ve öğrenme sürecinin makinelere kazandırılması düşüncesi ile önemli bir araştırma alanı haline gelen makine öğrenmesi için son yetmiş yılda sektörün öncüleri tarafından birçok çalışma yapılmıştır. Şüphesiz bu çalışmalardan ilk akla gelen Alan Turing'in "Imatation Game" oyununu anlatmış olduğu ve 1950 yılında yayınlanmış olan, temelinde "Makineler düşünebilir mi?" sorusuna yanıt arayan "Computing Machinery and Intelligence" isimli makalesidir. Yargıç, insan ve bilgisayardan oluşan üç katılımcı ile oluşturulan oyunda amaç yargıç rolündeki insanın diğer insan ve bilgisayar ile terminal programı üzerinden yapmış olduğu konuşmaların insana mı yoksa bilgisayara mı ait olduğunu ayırt etmesidir. Yargıcın bu yanıtlar arasındaki farkı tutarlı bir şekilde söyleyemediği durumda oyunu bilgisayarın kazandığı bir kurgu oluşturulmuştur (Bell, 2020: 2).

Makine öğrenmesi alanının bir diğer önemli ismi ise Arthur Samuel'dir. Samuel 1959 yılında makine öğrenmesini, bilgisayarlara açıkça programlanmadan öğrenme yeteneği kazandıran bir çalışma alanı olarak tanımlamıştır. IBM'de yaptığı çalışmalar ile kendi kendine öğrenen ilk bilgisayar programlarından birini yaratması ile tanınmaktadır. Bilgisayarların bir şeyler öğrenmesini sağlamaya odaklanan Samuel,

basit ama birçok strateji gerektiren yapay zekaya sahip dama oyununu geliştirmiştir (Bell, 2020: 2).

Tom M. Mitchell 1997 yılında makine öğrenmesini genel ve teknik bir yaklaşımla, “Bir bilgisayar programının T’deki görevlerde P ile ölçülen performansı E deneyimi ile iyileşiyorsa, bazı T görev sınıfları ve P performans ölçütü açısından E deneyiminden öğrendiği söylenir” olarak tanımlamıştır. Örneğin, dama oynamayı öğrenen bir bilgisayar programı kendisine karşı oyun oynayarak elde ettiği deneyim sayesinde dama oyunu oynamayı içeren görevler sınıfında kazanma becerisi ile ölçülen performansını geliştirebilir. Genel olarak, iyi tanımlanmış bir öğrenme problemine sahip olmak için şu üç özelliği tanımlamak gerekir: görev sınıfı, geliştirilecek performans ölçütü ve deneyim kaynağı. Dama oyunu için öğrenme probleminde T, E ve P aşağıdaki gibidir (Mitchell, 1997: 2-3):

T: Dama oynamak

P: Rakiplere karşı kazanılan oyunları yüzdesi

E: Kendine karşı alıştırmaya oyunları oynamak

Çeşitli tanımlar ve hakkında pek çok çalışmalar yapılan makine öğrenmesi araştırmalarındaki gelişmelere birçok farklı disiplin katkı sağlamıştır. Yapay zekâ, evrimsel öğrenme, sinir bilim, biyoloji, istatistik, matematik ve fizikten pek çok kanun ve fikirler bunlardan birkaçıdır (Marsland, 2015: 4; Nillson, 1997: 3).

Bu alanların makine öğrenmesi ile ilişkisi incelendiğinde ilk olarak makine öğrenmesini de içine alan ve kapsayıcı bir alan olan yapay zekadan bahsetmek gerekir. Yapay zekâ beyinden ilham alır ve makine öğrenmesi de yapay zekanın bir parçasıdır. Zeki olan bir sistemin değişen çevrede herhangi bir müdahaleye gerek kalmadan öğrenme yeteneğine sahip olması beklenir. Sistem bu değişikliklere uyum sağlar ve öğrenirse, sistemi tasarlayan kişinin tüm olası değişiklikleri tahmin etmesine ve modellemesine gerek kalmaz. Bu durumda sistem tasarımcısının yapay zekâ kapsamında öğrenen bir makineye sahip olduğu söylenebilir. Bir diğer önemli alan ise istatistiktir. Makine öğrenmesi örneklemden çıkarım yapmaya çalıştığından dolayı matematiksel modeller inşa ederken istatistik teorisini kullanmaktadır (Alpaydın,

2020: 3-4). Evrimsel öğrenme açısından bakıldığında ise bilgisayar programlarının performansını artırmak için biyolojik evrimin belirli yönlerini modelleyen tekniklerin öğrenme yöntemi olarak geliştirildiği görülmektedir. Bu hesaplama tekniklerinin arasında en sık kullanılanlar genetik algoritmalar ve genetik programlamadır (Nillson, 1997: 5). İnsan beyninin bilgi işleme tekniğinden esinlenerek oluşturulan sinir ağı modelleri de makine öğrenmesi alanının önemli kilometre taşlarından birisidir. Fakat ilk sinir ağı yaklaşımlarının doğasında bulunan sınırlamalar makine öğrenmesi konusunun araştırma hacminde düşüşe neden olmuştur. Sonrasında geliştirilen yeni yöntem ve bilgi yoğun teknikler ise makine öğrenmesi araştırmalarında bir canlılığa sebep olmuştur (Carbonell, Michalski, Mitchell, 1983: 69).

Farklı disiplinlerden kanun ve yöntemlerin makine öğrenmesi araştırma alanını geliştirmesinin yanı sıra üç önemli teknolojik trend de bu alanın yaygınlaşmasına sebep olmuştur. Bunlar; büyük verinin ortaya çıkışı, veri depolama ve işleme alanlarında bilgisayar teknolojisindeki ilerleme ve makine öğrenmesi teorik ve pratik araştırmalarındaki ilerlemelerdir (Lee, Shin, 2020: 158). Mikroişlemcinin icadı ve elektronik devrelerde küçükleştirilmesiyle maliyetler düşmüş ve bu sayede 1980'lerin başından itibaren kişisel bilgisayarlar daha erişebilir hale gelmiştir. Önceleri çoğunlukla kurumsal işletmeler ve üniversitelerde bulunan bilgisayarlar zamanla küçülmüş ve 1990'ların ortalarında pil teknolojisindeki gelişmeler ile taşınabilir bilgisayarlar yaygınlaşmıştır. Böylece yeni bir bilgi işlem çağı başlamıştır (Alpaydın, 2021: 19-21). Yaşanan bu gelişmeler ile veriyi elde etmek ve depolamak daha kolay hale gelmiştir ve büyük veri kavramı ortaya çıkmaya başlamıştır. Büyük veri kavramının ortaya çıkışına sebep olan veri toplama, taşıma ve depolama becerisindeki hız ve kapasite ile bilim insanları ve mühendislerin bu tür veri setlerinin altında yatan faydalı bilgileri çıkarmak, iç görüler elde etmek ve doğru kararlar vermek için verimli algoritmalar geliştirmeleri ihtiyacı doğmuştur. Verilerden faydalı bilgi çıkarılmasını içeren veri madenciliği ile makine öğrenmesi arasındaki ilişki de gittikçe güçlenmiştir (Marsland, 2015: 5, Jordan, Mitchell, 2015: 257).

Geniş bir perspektif ile baktığımızda makine öğrenmesinin üç ana araştırma odağı bulunmaktadır (Carbonell, Michalski, Mitchell, 1983: 69):

Hedef Odaklı Çalışmalar: Önceden belirlenmiş bir dizi görevin performansını artırmak için öğrenme sistemlerinin geliştirilmesini ve analizini kapsar. Bu yaklaşım mühendislik yaklaşımı olarak da bilinmektedir.

Bilişsel Simülasyon: İnsanın öğrenme süreçlerinin araştırılması ve bu süreçlerin bilgisayar ortamında simülasyonunun yapılmasını kapsar. Bu yaklaşım bilişsel modelleme yaklaşımı olarak da bilinmektedir.

Teorik Analiz: Olası öğrenme yöntemleri ve algoritmalarının uygulama alanlarından bağımsız bir şekilde teorik olarak araştırılmasını kapsar.

3.2. MAKİNE ÖĞRENMESİNİN ÖNEMİ

Makine öğrenmesi yıkıcı yeniliklerin geliştirilmesi konusundaki performansı ve etkili kullanıldığında ortaya çıkardığı rekabet avantajı ile sağlık, banka, imalat, taşımacılık, enerji gibi birçok sektörde kullanılmaya başlanmıştır. İnsan süreçlerini akıllı ve otomatik süreçlere dönüştürerek kaynakların faydalı bir şekilde kullanımına olanak vermesi ile son yıllarda katma değer sağlayan ve üzerinde pek çok araştırma yapılmaya başlanılan çalışma alanlarından birisi haline gelmiştir.

Makine öğrenmesi araştırma alanının öneminden bahsederken aslında makinelerin neden öğrenmek zorunda olduğu sorusuna cevap aranmaktadır. Elbette makinelere öğrenme yeteneğinin kazandırılmasının hayvanların ve insanların nasıl öğrendiğini anlamamıza yardımcı olduğu bir gerçektir fakat bazı önemli mühendislik nedenleri de vardır. Bunlardan bazılarını aşağıdaki gibi sıralayabiliriz (Nillson, 1997: 2-3);

- Bazı görevler örnek dışında iyi bir şekilde tanımlanamaz, yani girdi-çıkı çiftleri belirlenebilir ancak girdiler ve istenen çıktılar arasında açıklayıcı bir ilişki kurulamayabilir. Makinelerin iç yapılarını çok sayıda örnek girdisi için doğru çıktılar üretecek şekilde ayarlayabilmeleri ve böylece örneklerde ortaya çıkarılmayı bekleyen ilişkiyi yakalamak için girdi/çıkı fonksiyonlarını uygun şekilde kısıtlayabilmeleri için makine öğrenmesi kullanılabilir.
- Büyük veri yığınları arasında önemli ilişkiler ve korelasyonlar gizlenmiş olabilir. Bu ilişkileri ortaya çıkarmak (veri madenciliği) için genellikle makine öğrenmesi yöntemleri kullanılabilir.

- İnsanlar genellikle kullandıkları ortamlarda istenildiği kadar iyi çalışmayan makineler üretirler. Aslında çalışma ortamının belirli özellikleri tasarım sırasında tam olarak bilinmeyebilir. Makine öğrenmesi yöntemleri, mevcut makine tasarımlarının iş başında iyileştirilmesi için kullanılabilir.
- Belirli görevlerle ilgili mevcut bilgi miktarı, insanlar tarafından kodlanamayacak kadar büyük olabilir. Bu bilgiyi aşamalı olarak öğrenen makineler, insanların kod yazarak öğrenebileceği bilgiden daha fazlasını öğrenebilirler.
- Ortamlar zaman içinde değişir. Değişen ortama uyum sağlayabilen makineler ise sürekli yeniden tasarım ihtiyacını azaltmaktadır.
- İnsanlar sürekli olarak görevler hakkında yeni bilgiler keşfetmektedir. Yapay zekâ sistemlerinin yeni bilgilere uyacak şekilde sürekli olarak yeniden tasarlanması pratik değildir ancak makine öğrenmesi yöntemleri bu bilgilerin çoğunu takip edebilir.

3.3. MAKİNE ÖĞRENMESİ TÜRLERİ

Makine öğrenmesi türleri öğrenme sürecinde kullanılan veri türüne ve problem çözme yaklaşımlarına göre farklı gruplara ayrılmaktadır. Bunlar; denetimli, denetimsiz, yarı denetimli ve pekiştirmeli öğrenmedir. Hangi öğrenme türünün kullanılacağına, karşılaşılan problemin türüne ve eldeki verinin uygunluğuna göre karar verilmektedir. Her bir öğrenme türü farklı problemlere çözüm bulma arayışındadır ve bunların her biri için farklı makine öğrenmesi algoritmaları geliştirilmiştir.

3.3.1. DENETİMLİ ÖĞRENME

Bu öğrenme türünde girdiler ve hedefler olarak isimlendirilen çıktıların bulunduğu bir eğitim seti vardır ve algoritma bu eğitim setinden öğrenerek geliştirdiği fonksiyon ile olası tüm girdilere doğru yanıt verecek şekilde genelleme yapar. Bu öğrenme türüne örneklerden öğrenme de denir (Marsland, 2015: 6).

Denetimli öğrenmede amaç, (x_i, y_i) çiftlerinden oluşan bir eğitim kümesi verildiğinde x 'ten y 'ye bir eşleme öğrenmektir. Burada $y_i \in Y$, x_i örneklerinin etiketleri veya hedefleri olarak adlandırılır. Diğer bir deyişle x_i girdi, y_i ise çıktı örneklerini ifade


etmektedir. Girdiler klasik vektörler olabileceği gibi belgeler, görüntüler, DNA dizileri veya grafikler gibi daha karmaşık nesneler de olabilirler. Benzer şekilde farklı türde çıktılar üzerinde de çalışılabilir. Burada y_i değerlerinin sayı veya kategorik bir değer olmasına bağlı olarak denetimli öğrenme uygulama problemi değişiklik göstermektedir. $Y = R$ veya $Y = R^d$ olduğunda yani hedef değerler sürekli olduğunda denetimli öğrenme kullanarak yerine getirilen görev regresyondur. Y 'nin sonlu bir kümede (ayrık etiketler) değerler aldığı durumda yerine getirilen görev ise sınıflandırma olarak adlandırılır (Chapelle, Scholkopf, Zien, 2009: 2; Jordan, Mitchell, 2015: 257).

Regresyonun amacı bağımlı ve bağımsız değişken veya değişkenlerden oluşan bir veri seti üzerinden farklı bir bağımsız değişken kümesi ile karşılaşıldığında bağımlı değişken değerini tahmin edecek fonksiyonu bulmaktır. Bölüm 2.5.2.2'de daha önce anlatıldığı gibi eğitim süreci sonunda elde edilen fonksiyon ile oluşturulan eğrinin, gerçek veri noktalarından mümkün olduğunca yakın geçmesi istenir (Marsland, 2015: 7).

Sınıflandırma probleminde ise girdiler ve bu girdilerin sınıflarından oluşan veri oluşturulur veya bu veri seti bazı durumlarda hazırır. Buradaki amaç eğitim süreci ile algoritmanın daha önce hiç görmediği örneğin N sınıftan hangisine ait olduğuna karar vermektir. Sınıflandırma problemlerinde en önemli nokta ayrık olmasıdır ve bu durum sınıflandırma için kullanılan algoritmaların doğru sonuçlar üretmesi için oldukça önemlidir. Ayrıklık, her bir örneğin bir sınıfa ait olduğunu ve hedefler yani sınıflar kümesinin tüm olası çıktı uzayını kapsadığını ifade etmektedir. Bazı durumlarda bu iki kısıtlama her zaman doğru olmayabilir. Bazen girdi kümesindeki örnekler iki farklı sınıfa aitmiş gibi görünebilir. Bu sorunu çözmek için bulanık sınıflandırıcılar üzerinde çalışmalar yapılmıştır (Marsland, 2015: 7).

Sınıflandırma ile ilgili en yaygın örneklerden birisi e-postaları spam veya spam değil olarak ayıran spam filtresi örneğidir. Spam ve spam olmayan birçok e-posta örneklerinden oluşan eğitim verisi ile öğrenen algoritma, bir sonraki e-postaları nasıl sınıflandıracığı konusunda bir beceri kazanır.

Şekil 26: Denetimli Öğrenme ile Sınıflandırma Örneği



Kaynak: Géron (2019), s.8

Denetimli öğrenme kapsamında regresyon ve sınıflandırma problemlerini çözmek için kullanılan popüler algoritmalarından bazıları; k-en yakın komşu, naif bayes sınıflandırıcı, karar ağaçları, doğrusal regresyon, ridge regresyon, lasso regresyon, lojistik regresyon, destek vektör makineleri, rastgele ormanlar ve yapay sinir ağları (Lee, Shin, 2020: 159; Jiang, Gradus, Rosellini, 2020: 678-679).

3.3.2. DENETİMSİZ ÖĞRENME

Bu öğrenme türünde sadece girdi verisi vardır. Dolayısıyla eğitim verisinin etiketlenmediği bir öğrenme sisteminden bahsedilmektedir. Denetimsiz öğrenme algoritmaları, girdi verileri ile ilişkili olabilecek çıktı sınıfları olmadığından dolayı girdi veri setindeki öğeler arasındaki benzerlikleri belirlemeye ve anlamlı iç görüler elde etmek için bu öğeleri kümelemeye çalışmaktadır. Girdi uzayında belirli kalıpların daha sık ortaya çıktığı bir yapı vardır ve bu yapıda ne olup bittiği anlaşılmaya çalışılmaktadır. İstatistikte buna yoğunluk tahmini denilmektedir. (Alpaydın, 2020: 11; Lee, Shin, 2020: 159).


En önemli denetimsiz öğrenme algoritmaları; kümeleme (k-ortalamalar, DBSCAN, Hiyerarşik Küme Analizi), anomali ve yenilik tespiti (Tek Sınıf Destek Vektör Makinesi, İzolasyon Ormanı), görselleştirme ve boyut indirgeme (Temel Bileşen Analizi, Çekirdek Temel Bileşen Analizi, Yerel Olarak Doğrusal Gömme, t-dağılımlı Stokastik Komşu Yerleştirme), birliktelik kuralı öğrenme (Apriori ve Eclat) (Géron, 2019: 10).

Bahsedilen algoritmalar içerisinde yaygın olarak kullanılanlardan biri olan kümeleme, girdi veri setindeki nesneleri benzerliklerine göre gruplandırmak amacıyla kullanılmaktadır. Aynı küme içerisinde bulunan nesnelerin, farklı kümede bulunan nesnelere kıyasla birbirlerine daha çok benzemeleri beklenmektedir. İki nesne arasındaki benzerlik bir benzerlik mesafesi fonksiyonu ile ölçülmektedir (Lee, Shin, 2020: 160). Etiketsiz verinin altında yatan gizli yapıyı açıklaması ve iş operasyonları için en iyi kararların belirlenmesi konusundaki katkısı nedeniyle birçok farklı sektör tarafından kullanılmaktadır. Örneğin kişiselleştirilmiş ürün ve hizmet vermek için müşterileri kümeleyerek her bir kümedeki müşteriyi daha iyi tanımaya ve bunlar için farklı stratejiler geliştirmeye yardımcı olmaktadır.

Şekil 27 k-ortalamlar algoritması ile oluşturulmuş kümeleme işlemini göstermektedir. Bu algoritma her bir veri gözlemini k farklı kümeye sınıflandırır. Algoritmanın çalışma aşamaları aşağıdaki gibidir (Vandeput, 2021: 209-210);

- Her bir K merkezi rastgele bir koordinata atanır.
- Her bir veri kendisine en yakın merkez ile ilişkilendirilir.
- Her merkez, kendisi ile ilişkili tüm veri noktalarının ortasına taşınır.
- Küme merkezleri değişmeyene kadar ikinci ve üçüncü adımlar tekrarlanır.

Şekil 27: Üç Merkezli k-Ortalamlar ile Oluşturulmuş Kümeleme



Kaynak: Vandeput, (2021), s.210

Boyut indirgeme, öğrenme problemindeki karmaşıklığı azaltmak için çok fazla bilgi kaybetmeden verileri basitleştirmeyi amaçlamaktadır. Bunu yapmanın bir yolu, birbiri ile ilişkili özellikleri tek bir özellik altında birleştirmektir. Örneğin bir arabanın yaşı ile kilometresi birbiri ile güçlü bir ilişki içerisinde olabilir. Bu durumda boyut indirgeme algoritması bunları arabanın aşınması ve yıpranmasını temsil eden tek bir özellikte birleştirebilmektedir (Géron, 2019: 12).

Anomali tespiti verilerin büyük bir çoğunluğundan önemli derecede farklılaşan verilerin tespiti için kullanılmaktadır. Kişinin kendisi tarafından yapıldığı konusunda şüphe uyandıran olağan dışı kredi kartı harcamalarının tespiti, üretim hatalarının yakalanması, veri analizinde sonuçların doğruluğunu önemli ölçüde etkileyebilen aykırı değerlerin tespiti gibi alanlarda sıklıkla kullanılmaktadır. Benzer şekilde yenilik tespiti de eğitim seti içerisindeki örneklerden farklı görünen örnekleri tespit etmek için kullanılmaktadır (Géron, 2019: 12).

Birliktelik kuralı öğrenme ise büyük veri kümeleri içerisindeki değişkenler arasındaki ilginç ilişkileri çözmek için kullanılmaktadır. Örneğin bir süper market, satış kayıtları içerisinde bazı ürünlerin birlikte alındığına dair bir eğilim keşfedilebilir. Bu durumda süpermarket işletmesi bu ürünleri tesis içerisinde birbirlerine yakın olarak konumlandırabilir (Géron, 2019: 13).

3.3.3. YARI DENETİMLİ ÖĞRENME

Yarı denetimli öğrenme denetimli ve denetimsiz öğrenme türlerinin kesişim kümesi gibidir. Öğrenici hem etiketli hem de etiketsiz verilerden oluşan bir eğitim örneği alır ve daha önce görmediği tüm noktalar için tahminler yapmaktadır. Etiketsiz verilerin etiketli verilerden daha fazla olduğu yani etiketsiz verilere ulaşmanın kolay olduğu ve bu etiketsiz verileri tek tek etiketlemenin hem zaman alıcı hem de maliyetli olduğu durumlarda kullanılmaktadır (Mohri, Rostamizadeh, Talwalkar, 2018: 7). Burada veri seti $X = (x_i)_{i \in [n]}$, $Y_l := (y_1, y_2, \dots, y_l)$ etiketli $X_l := (x_1, x_2, \dots, x_l)$ noktaları ve etiketi bilinmeyen $X_u := (x_{l+1}, x_{l+2}, \dots, x_{u+1})$ noktaları olmak üzere ikiye ayrılmaktadır (Chapelle, Scholkopf, Zien, 2009: 2). Buradaki etiketli veriler denetimli öğrenme için sınıflandırma kuralları elde etmek amacı ile kullanılabilir. Bu kurallar daha sonra denetimsiz makine öğrenimi ile kalan verilerin etiketlenmesine yardımcı

olur ve son olarak tüm etiketli veriler denetimli makine öğrenimi ile eğitim için kullanılabilir (Lee, Shin, 2020: 159).

3.3.4. PEKİŞTİRMELİ ÖĞRENME

Bazı algoritmaların öğrenme sürecinin sonucunda elde edilen çıktı bir dizi eylemdir. Böyle bir durumda önemli olan hedefe ulaşmak için tek bir eylemi değil doğru eylemler dizisini bulmaktır. Yani herhangi bir durumda en iyi eylem diye bir şey yoktur, bir eylem iyi bir eylem planının parçası ise iyidir. Bu durumda makine öğrenmesi programı eylem planının başarısını değerlendirebilmeli ve geçmişteki başarılı eylem dizilerinden öğrenerek strateji üretebilmelidir. Bu öğrenme yöntemlerine pekiştirmeli (takviyeli) öğrenme algoritmaları denilmektedir (Alpaydın, 2020: 13).

Pekiştirmeli öğrenmede algoritmaya cevabın veya eylemin yanlış olduğu söylenir ama bu yanlışın nasıl düzeltileceği ve geliştirileceği hakkında bilgi verilmez. Ajan olarak adlandırılan öğrencinin doğru yanıtı veya eylemi bulana kadar farklı olasılıkları keşfetmesi ve denemesi gerekir. Bu arama süreci takviye öğrencisinin temel bir parçasıdır (Marsland, 2015: 231).

Günlük yaşamda sık karşılaşılan bir durum ile pekiştirmeli öğrenme yönteminin mantığını somutlaştırmaya çalışalım. Ayağa kalkmayı ve yürümeyi öğrenen bir çocuğun öğrenme sürecini ele alalım. Çocuk dik durmak için birçok eylemi dener ve sonunda yüz üstü düşüp düşmediğine bakarak hangi eylemin işe yaradığına dair geri bildirim alır. İşe yaradığı görülen eylemler en iyisi olana kadar ve daha iyi çözümler bulunana kadar tekrar tekrar denenir ve işe yaramayan eylemlerden vazgeçilir. Bunun sonucunda tespit edilen en iyi eylemler ile çocuk ayağa kalkmayı ve yürümeyi öğrenir (Marsland, 2015: 232).

Başarılı bir sonuç elde etmek için tek bir hamlenin değil doğru hamleler dizisinin önemli olduğu satranç, dama, tavla gibi oyunlar da pekiştirmeli öğrenmeye iyi birer örnektir. Oyun oynarken yapılan bir hamle, iyi bir oyun oynama eyleminin parçasıysa iyidir. Örneğin satranç oyununun az sayıda kuralı vardır fakat her durumda çok sayıda olası hamlenin olması oyunu karmaşık hale getirmektedir. Oyunları iyi oynayan


algoritmalar oluşturmak için en iyi eylem dizisine pekiştirmeli öğrenme ile sahip olmak gerekmektedir (Alpaydın, 2020: 13).

Pekiştirmeli öğrenme birbirini takip etmeyi, parlak ışıklara gitmeyi ve yön bulmayı öğrenen robotlar dahil olmak üzere pek çok robotik uygulamada kullanılmaktadır (Marsland, 2015: 246).

Şekil 28’de bir robotun labirent içerisinde çıkışa doğru ilerlemesi için yerine getirilecek pekiştirmeli öğrenme süreci ve temel kavramlar gösterilmektedir. Burada öğrenme ajanı olan robot belirli bir görevi (labirentten dışarı çıkmak) yerine getirmek için tasarlanmış bir program veya sistemdir. Çevre, öğrenme ajanının etkileşimde bulunduğu ve eylemlerin ve ödüllerin gerçekleştiği sistemi temsil eder. Burada çevre labirenttir. Yorumlayıcı ise ajanın çevreyi algılamak ve durumları anlamak için kullandığı bir bileşendir. Ortamdan gelen bilgileri işler ve ajanın mevcut durumu belirlemesine yardımcı olur. Durum, öğrenme ajanının içinde bulunduğu mevcut durumu veya çevrenin anlık durumunu temsil etmektedir. Eylem ise ajanın çevreye uygulayabileceği bir hareket, karar veya seçenektir. Ajan, mevcut duruma bağlı olarak uygun bir eylem seçer ve bu eylemi çevreye uygular. Robotun sağa veya sola doğru ilerleme kararı eylemi ifade etmektedir. Ödül, öğrenme ajanının geri bildirim mekanizmasıdır ve doğru davranışları teşvik etmek ve hedefe yönelik ilerlemeyi sağlamak için kullanılmaktadır. Çevre, ajanın gerçekleştirdiği eylemlere bağlı olarak ödül verir. Ajanın buradaki amacı ödülü maksimize etmek için öğrenme sürecinde doğru eylemleri keşfetmektir.

Özetlemek gerekirse, öğrenme ajanı yorumlayıcı aracılığı ile ortamı gözlemler, durumları değerlendirir, uygun eylemleri seçip çevreye uygular, aldığı ödüller ile maksimum ödüle ulaşmak için ilerler ve doğru eylemleri keşfederek görevini optimize etmeyi öğrenir.

Şekil 28: Pekiştirmeli Öğrenme



Kaynak: Mahesh, (2020), s.385

3.4 MAKİNE ÖĞRENMESİ PROJESİ

Günümüzde makine öğrenmesi doğal dil işlemeden kanserli hücre tespitine, metin ve belge sınıflandırmadan piyasaya yeni sürülecek ürünün talep tahminine kadar birçok problemin çözümü için kullanılmaktadır. Teknolojik gelişmeler ile farklı verilerin elde edilmesi ve beraberinde büyük veri kavramının ortaya çıkışı makine öğrenmesi projelerinde önemli bir artışa neden olmuştur. Her bir makine öğrenmesi projesinin kendine özgü özellikleri ve problemleri olmasının yanı sıra temelde altı aşamalı bir süreçten söz etmek mümkündür. Bunlar; veri toplama ve hazırlama, özellik seçimi, algoritma seçimi, parametre ve model seçimi, eğitim ve test ve değerlendirme süreçlerinden oluşmaktadır.

3.4.1. VERİ TOPLAMA VE HAZIRLAMA

Bu aşamada makine öğrenmesi projesi için ihtiyaç duyulan veriler toplanır. Bu veriler işletmenin kendi kayıtlarından elde edilebileceği gibi ikincil veri dediğimiz daha önce başka amaç için toplanmış olan ve mevcut veri kaynaklarından alınan veriler de kullanılabilir. İkincil veri ile hazırlanan projelerde verinin kaynağının güvenilir olması önem arz etmektedir. Yanlış bilgi içeren veriler doğru olmayan sonuçların elde edilmesine ve yanlış kararların verilmesine neden olacaktır.

Veri toplama aşamasında toplanan verinin miktarı önemlidir. Çoğu makine öğrenmesi algoritmasının daha iyi eğitilmesi için büyük miktarda verinin kullanılması faydalı olmaktadır. Fakat büyük verinin toplanması ve işlenmesi ile ilgili bazı zorluklar vardır. Büyük verinin elde edilmesi için çok sayıda ölçüm yapılması gerekebilir ya da çeşitli yerlerde veya formatlarda bulunan verilerin toplanması ve birleştirilmesi zor olabilir. Bu noktada önemli bir zaman yatırımına ihtiyaç duyulmaktadır. İkinci olarak artan veri kümesi boyutu ile hesaplama maliyetleri de artmaktadır (Marsland, 2015: 10). Bu durumda makine öğrenmesi projesinin karmaşıklığı ve veri miktarı arasında bir denge kurulması ihtiyacı ortaya çıkmaktadır.

Veri toplama sürecinden sonra doğru ve güvenilir sonuçlar elde etmek için veri ön işleme yapılması gerekmektedir. Teknik sorunlardan dolayı bazı verilerin eksik olması ve yanlış ölçüm, veri girişinin hatalı yapılması gibi nedenlerden dolayı aykırı verilerin oluşması sistematik hatalara neden olmaktadır. Eksik ve aykırı değerlere sahip veri kümesi, makine öğrenmesi algoritmasının eğitim ve test sürecinde doğru modelin kurulması ve düşük hataya sahip sonuçların elde edilmesinde önemli bir engeldir. Eğitim sürecinde hata meydana gelir ve yüksek oranda tahmin hatasına sahip sonuçlar ortaya çıkar (Yu ve Xu, 2014: 103). Modelin performansını iyileştirmek için eksik verilerin uygun yöntemler ile doldurulması ve aykırı değerlerin silinmesi veya geçerli bir veri ile doldurulması gibi kararların verilmesi gerekmektedir.

3.4.2. ÖZELLİK SEÇİMİ

Özellik seçimi aşamasında hedef değişkeni en iyi şekilde açıklayan değişkenler tespit edilmeye çalışılmaktadır. Modele açıklayıcı değişken olarak eklenecek olan özelliklerin tespit edilmesinde ilgili konu ile ilgili literatür taraması, uzman görüşlerinin alınması ve bu görüşlerin çok kriterli karar verme yöntemleri gibi yöntemler ile değerlendirilmesi faydalı olmaktadır.

Belirlenen özelliklerin hedef değerler ile olan ilişkisinin yönünü ve gücüne gösteren korelasyon analizi özellik seçimi için kullanılan yöntemlerden birisidir. Korelasyon analizi iki değişken arasındaki ilişkiyi ölçmekte ve bir korelasyon katsayısı vermektedir. Bu katsayı +1 ve -1 arasında bir değer almaktadır ve bağımsız değişkendeki değişimin bağımlı değişkende herhangi bir değişime eden olup

olmadığını göstermektedir. Korelasyon katsayısının pozitif olduğu durumda bağımlı ve bağımsız değişken arasında aynı yönde ilişki olduğu yani bir değişkende artış veya azalış gözlenirken diğesinde de artış veya azalış olduğu gözlenmektedir. Korelasyon katsayısının negatif olduğu durumda ise bağımlı ve bağımsız değişken arasında ters yönlü bir ilişki olduğu yani bir değişkendeki artışın diğesinde azalışa neden olduğu gözlenmektedir. Düşük korelasyon katsayısı iki değişken arasındaki ilişkinin zayıf olduğunu veya hiç olmadığını göstermektedir. Yüksek korelasyon katsayısı ise değişkenler arasındaki ilişkinin güçlü olduğunu yani bağımsız değişken de meydana gelecek herhangi bir değişikliğin bağımlı değişkeni de değiştireceğini göstermektedir. Çeşitli korelasyon katsayıları vardır ve bunların içerisinde en yaygın olarak kullanılanı Pearson korelasyon katsayısıdır (Wang, Liu, Wu, Fu, Shi, Guo, 2018: 9). Tablo 12’de iki değişken arasındaki korelasyon karar aralıkları gösterilmektedir. Buradaki r korelasyon katsayısını ifade etmektedir.

Tablo 12: İki Değişken Arasındaki Korelasyon Karar Aralıkları

Korelasyonun Mutlak Değeri	Korelasyon Düzeyi	Korelasyonun Mutlak Değeri	Korelasyon Düzeyi
$ r = 1$	Doğrusal İlişki	$ r > 0.95$	Önemli İlişki
$ r \geq 0.8$	Güçlü İlişki	$0.5 \leq r \leq 0.8$	Orta Dereceli İlişki
$ r < 0.5$	Zayıf İlişki	$ r = 0$	İlişki yok

Kaynak: Wang, Liu, Wu, Fu, Shi, Guo, (2018), s.9

İki değişken arasındaki ilişkinin anlamlı olup olmadığını belirlemek için hipotez testleri de yapılabilir. En yaygın hipotez testi sıfır hipotezi ve alternatif hipotezden oluşan testtir. Burada H_0 hipotezi bağımlı ve bağımsız değişken arasında ilişki olmadığını, H_1 hipotezi ise bağımlı ve bağımsız değişken arasında ilişki olduğunu belirtmektedir. Hipotez testinin yorumlanmasında p-değerinin incelenmesi gerekmektedir. P-değeri, H_0 hipotezinin kabul edilmesi veya reddedilmesi kararının verilmesi için önemlidir. Küçük p-değeri bağımsız değişken ile bağımlı değişken arasında gerçek bir ilişki olmaması durumunda böyle güçlü bir ilişkinin şansa bağlı olarak gözlemlenme olasılığının düşük olduğunu göstermektedir. Dolayısı ile küçük

p-değeri bağımlı ve bağımsız değişken arasında bir ilişki olduğunu sonucunu vermektedir. Sıfır hipotezini reddetmek için dikkate alınan p-değeri genellikle %5 veya %1'dir (James, Witten, Hastie, Tibshirani, 2013: 67-68).

Regresyon analizi de bağımlı değişken ve bağımsız değişken arasındaki ilişkiyi ve hangi açıklayıcı değişkenlerin modelin doğru sonuçlar üretmesinde önemli olduğunu belirlemek için kullanılabilecek yöntemlerdendir. Birden fazla değişkenin dahil edildiği modelde bağımlı değişken ve bağımsız değişkenler arasında ilişki olup olmadığını ve modelin anlamlılığını yorumlamak için F-statistic değerine ve R^2 değerine bakılmaktadır. R^2 değeri 2.7.5'te açıklanmaktadır. F-statistic değerinin 1'e yakın olduğu durumlarda bağımsız değişkenlerin bağımlı değişkeni açıklamada yetersiz olduğu, 0'a yakın olduğu durumlarda ise bağımsız değişkenler ile bağımlı değişken arasında ilişki olduğu sonucu çıkarılmaktadır (James, Witten, Hastie, Tibshirani, 2013: 75-76).

Regresyon analizinde değişkenler arasındaki ilişkiyi inceledikten sonra, model performansını en iyileştirecek değişkenlerin seçimi için üç klasik yaklaşım vardır. Bunlar aşağıda açıklanmıştır (James, Witten, Hastie, Tibshirani, 2013: 78-79).

- **İleri Seçim:** İlk olarak hiçbir açıklayıcı değişkenin olmadığı bir model kurulmaktadır. Daha sonra açıklayıcı değişkenler önceden belirlenen kriterlere göre tek tek modele dahil edilmektedir ve her bir değişkenin anlamlılık düzeyi değerlendirilmektedir. Bu değerlendirmeye göre modele en yüksek katkıyı sağlayan değişkenler çözüme dahil edilmektedir.
- **Geriye Doğru Seçim:** Sıfır model ile başlayan ileri seçim tekniğinin aksine geriye doğru eleme yönteminde ilk olarak tüm değişkenlerin dahil edildiği bir model kurulmaktadır. Daha sonra istatistiksel olarak anlamlılık değeri en düşük olan yani p-değeri en büyük olan değişken modelden çıkarılmaktadır. Bu süreç kalan tüm açıklayıcı değişkenler p-değeri için belirlenen eşik değerin altında kalana kadar devam etmektedir.
- **Karışık Seçim:** Bu teknikte ileriye doğru ve geriye doğru seçim teknikleri birleştirilmekte ve aşamalı bir regresyon oluşturulmaktadır. İlk olarak bağımsız değişkenin olmadığı bir model kurulmakta ve daha sonra en yüksek anlamlılık

değerine sahip değişken modele eklenip, diğer değişkenler de teker teker modele dahil edilmektedir. Modele yeni değişkenler eklendikçe değişkenler için p-değeri büyüyebilmektedir. Bu nedenle ileri seçim yaklaşımının belirli bir evresinde modeldeki açıklayıcı değişkenlerden biri için p-değeri belirlenen eşik değerin üzerine çıkarsa bu değişken modelden çıkarılmalıdır. İleri ve geri adımlar, tüm değişkenler düşük p-değerine (<0.05) sahip olana kadar devam etmektedir.

3.4.3. ALGORİTMA SEÇİMİ

Sınıflandırma, tahmin, kümeleme, sıralama gibi birçok görev için farklı algoritmalar bulunmaktadır. Uygun algoritmanın seçimi projenin hedefine, veri setinin özelliklerine ve problem tipine göre belirlenmelidir. Örneğin bir ürünün satış verileri ve müşteriler hakkında bilgilerin bulunduğu bir veri kümesi kullanılarak ulaşılması hedeflenen sonuç, ürünün talep tahmini için müşterilerin özelliklerinin açıklayıcı değişken olarak kullanıldığı bir model oluşturmak olacaktır. Bu durumda doğrusal regresyon, destek vektör regresyonu gibi regresyon algoritmaları tercih edilmektedir. Problemin türüne göre bir seçim yapmanın yanı sıra algoritmaların özellikleri de algoritma seçimi için önemlidir. Bazı algoritmalar karmaşık ve anlaşılması zor olabilir fakat doğru sonuçlar üretme konusunda oldukça başarılıdırlar. Bazıları ise kolay anlaşılır ve yorumlanabilir, az sayıda ayarlanması gereken hiper parametreye sahiptirler fakat hata oranları diğerlerinden daha fazla olabilir. Sonuç olarak en uygun algoritmanın seçimi için bahsedilen doğruluk ve yorumlanabilirlik faktörleri arasında bir denge sağlanmalıdır (Lee, Shin, 2020: 158).

3.4.4. PARAMETRE VE MODEL SEÇİMİ

Bir makine öğrenmesi modelinde eğitim sürecinde veriye uyum sağlamak için algoritma tarafından otomatik olarak hesaplanan değerler vardır. Bunlara parametre denilmektedir. Örneğin doğrusal regresyondaki eğim ve kesme terimleri bu şekilde belirlenmektedir. Bir de modelin karmaşıklığını tanımlayan üst parametreler yani hiper parametreler vardır (Alpaydın, 2021: 46). Makine öğrenmesi projesini yürüten kişi tarafından belirlenmesi gereken hiper parametreler deneme yanılma yolu ile veya hiper parametre optimizasyon teknikleri ile bulunmaktadır. Doğru modelin

oluşturulmasında önemli bir yeri olan hiper parametrelere yapay sinir ağlarındaki öğrenme hızı, epoch sayısı gibi değerler, destek vektör regresyonunda hataya tolerans gösterme derecesini kontrol eden C parametresi, kabul edilebilir hata marjını belirleyen epsilon vb. parametreler örnek olarak gösterilebilir. En uygun hiper parametreler ile düşük hataya sahip yanıtları üreten model, problem çözümü için en uygun model olarak seçilmektedir.

3.4.5. EĞİTİM VE TEST

Hazırlanan veya zaten hazır bir şekilde elde edilen veri seti incelendikten ve veri ön işleme süreçleri gerçekleştirilip, doğru algoritma ve parametreler belirlendikten sonra model performansını doğrulamak için veri seti eğitim (train), doğrulama (validation) ve test seti olarak üçe ayrılır. Eğitim veri seti öğrenme algoritmasını eğitmek için, doğrulama veri seti öğrenme algoritmasının hiper parametrelerinin en uygun değerlerini bulmak için ve test seti ise algoritmanın daha önce hiç görmemiş olduğu veriler üzerindeki performansını ölçmek için kullanılmaktadır.

3.4.6. DEĞERLENDİRME

Eğitim veri seti ile oluşturulan modelin performansı test veri seti ile değerlendirilmektedir. Modelin performansının üstünlüğü gerçek değerler ile tahmin edilen değerler arasındaki farkın az olmasından gelmektedir. Modelin performansını ölçmek için çeşitli kriterler kullanılmaktadır. Bu kriterler hem modelin doğruluğu hakkında yorum yapılmasına hem de farklı algoritmalar arasında seçim yapılmasına yardımcı olmaktadır. Tahmin hatasının ölçümü ve model performansının değerlendirilmesi için yaygın olarak kullanılan ölçütler 2.7’de açıklanmıştır.

DÖRDÜNCÜ BÖLÜM

METODOLOJİ

4.1. ÇOKLU DOĞRUSAL REGRESYON

Regresyon analizleri bağımlı ve bağımsız değişkenler arasındaki nedenselliği açıklamak için kullanılan yöntemlerdir. Makine öğrenmesinde denetimli öğrenme problemlerini çözmek için kullanılan regresyon analizinin farklı problemler için geliştirilmiş ve farklı algoritmalar için genişletilmiş çeşitleri vardır. Bunlardan en çok kullanılan ve regresyon analizinin mantığının temelini oluşturan basit doğrusal regresyon bağımlı değişken ve bağımsız değişken arasındaki ilişkiyi modellemektir. Fakat çoğu durumda tek bir bağımsız değişkenin bağımlı değişkeni açıklayabilmesi mümkün değildir. Bu sorunu çözmek için çoklu doğrusal regresyon modeli geliştirilmiştir. Çoklu doğrusal regresyonda bağımlı değişkeni açıklayan birden fazla bağımsız değişken vardır ve değişkenler arasındaki bu ilişki doğrusal bir model olarak açıklanmaktadır. Modelin denklemi aşağıdaki gibidir;

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_pX_p + \varepsilon \quad (9)$$

Burada:

Y= Bağımlı değişken

$X_1, X_2, \dots, X_p$ = Bağımsız değişkenler

b_0 = Regresyon eğrisinin y eksenini kesim noktası

$b_1, b_2, \dots, b_p$ = Bağımsız değişkenlerin bilinmeyen katsayıları


ε = Hata terimi

Denklem 9'daki b_0 ve $b_1, b_2, \dots, b_p$ regresyon katsayıları basit doğrusal regresyonda olduğu gibi bilinmemektedir ve en küçük kareler yaklaşımı kullanılarak tahmin edilmektedir. En küçük kareler yöntemi parametrelerin tahmin edilen değerlerinin hata terimleri karelerinin toplamını en az indirmeyi sağlamaktadır. Matematiksel gösterimi aşağıdaki gibidir (James, Witten, Hastie, Tibshirani, 2013: 215);

$$\text{Artık Kareler Toplamı (RSS): } \sum_{i=1}^n \left(y_i - b_0 - \sum_{j=1}^p b_j x_{ij} \right)^2 \quad (10)$$

Denklem 10’da hatayı minimize eden $b_0, b_1, b_2, \dots, b_j$ değerleri, en küçük kareler yöntemi ile hesaplanan katsayı tahminleridir. Bu denklemde $y_i - b_0 - \sum_{j=1}^p b_j x_{ij}$ ifadesi hatayı temsil etmektedir.

Şekil 29: İki Bağımsız Değişken İçeren Çoklu Regresyon Hiper Düzlemi




Kaynak: James, Witten, Hastie, Tibshirani (2013), s.73

Basit doğrusal regresyonda en küçük kareler yöntemi ile oluşturulan regresyon çizgisi bir doğru ile gösterilirken, birden fazla bağımsız değişkenden oluşan regresyon probleminde bu çizgi bir düzlem haline gelmektedir. Burada amaç, kırmızı ile gösterilen her bir gözlem ile düzlem arasındaki karesel dikey mesafelerin yani gerçekleşen ve tahmin edilen değerlerin arasındaki farkların toplamını en aza indirmektir.

4.2. DESTEK VEKTÖR REGRESYONU

DVR, destek vektör makinesi yönteminin regresyona uyarlanmış halidir. Destek vektör makinesi yapay sinir ağlarının ağ yapısı oluşturma, aşırı uyum, bağlantı ağırlığı tahminleri ve sistem eğitimi için çok sayıda veri ihtiyacı sorunlarına çözüm için ilk kez Vladimir Naumovich Vapnik ve çalışma arkadaşları tarafından 1992 yılında düzenlenen COLT (Computational Learning Theory) konferansında önerilmiştir. 1995 yılında ise Corinna Cortes ve Vladimir Vapnik tarafından günümüzde kullanılan haline getirilmiştir (Bilişik, 2011: 788; Kavousi-Fard, Samet, Marzbani, 2014: 6047). Birden fazla değişkenin olduğu çok boyutlu bir uzayda belirlenmesi gereken iki sınıfın olduğu sınıflandırma problemleri için geliştirilen DVM, sınıflar arasında ayırım yapmak için sonuç kategorilerini maksimum düzeyde ayıran bir hiper düzlem belirlemektedir (Jiang, Gradus, Rosellini, 2020: 680). Verinin hangi sınıfa ait olacağına karar vermek için iki sınıfı ayıran bir doğru çizilmektedir ve bu doğrunun +1 ve -1'i arasında kalan bölgeye marjin denilmektedir. Marjin ne kadar geniş olursa sınıflar arasında ayırım o kadar iyi yapılmaktadır. Şekil 30'da verileri iki sınıfa ayıran doğrusal bir destek vektör makinesi sınıflandırıcı örneği gösterilmektedir.

Şekil 30: İki Sınıfı Ayıran Hiper Düzlem



Kaynak: Marsland (2015), s.171

Az sayıda gözlem içeren veri kümelerini içeren sınıflandırma problemlerinde başarılı performans gösteren destek vektör makineleri 1997 yılında Vapnik ve arkadaşları tarafından regresyon uygulamalarında da kullanılmak üzere genişletilmiştir (Bilişik, 2011: 788). Regresyon problemleri için geliştirildiği tarihten beri de finansal parametrelerin tahmini, elektrik yük tahmini, rüzgâr hızı tahmini, yağış tahmini gibi pek çok farklı alanda uygulanmıştır (Kavousi-Fard, Samet, Marzbani, 2014: 6048).

Sınıflandırma problemlerinde hedef değer olan y çıktısı yalnızca iki değer ($y \in \pm 1$) alırken regresyon problemlerinde çıktı gerçek bir değeri ($y \in \mathbb{R}$) temsil etmektedir. Destek vektör regresyonunda esas amaç gerçek değerlere belirli bir mesafede olan hataları göz ardı eden bir kayıp fonksiyonu tanımlamaktır (Camastra, Vinciarelli, 2015: 229).

Tek bir çıktıyı (y) n sayıda girdi değişkeninin (x) fonksiyonu olarak modellemeye çalıştığımızı ve N uzunluğunda bir eğitim kümesine sahip olduğumuzu varsayalım: $T: \{(x_1 y_1), (x_2 y_2), \dots (x_N y_N)\}$. Burada $x_k \in R^n$, $y_k \in R^n$ ve $k=1, 2, \dots, N$ 'dir. x_k , k zamanda her bir girdinin değerlerini taşıyan n boyutlu vektörleri ve y_k k zamanda çıktı değişkeninin değerlerini taşıyan skalerlerdir. Eğitim verisi elde edildikten sonra yapılmak istenen şey eğitim setini en iyi açıklayan modeli bulmaktır. Destek vektör regresyonunda bunun için Denklem 13'te gösterilen doğrusal bir model önerilmektedir. Modelde w ağırlık vektörünü, b ise eşik seviyesini ifade etmektedir (Kavaklıoğlu, 2011: 369).

$$f(x) = w^T(x) + b \quad (13)$$

Aslında w vektörü problemin özellik uzayının bir elemanıdır fakat gerçek dünyada karşılaşılan çoğu problem doğrusal formlar kullanılarak modellenemez. Destek vektör regresyonu doğrusal olmayan modellemeyi sağlamak ve eğitim verilerini yüksek boyutlu bir özellik uzayına yerleştirmek için doğrusal olmayan bir eşleme fonksiyonu ($\phi(x)$) oluşturmaktadır. Bu fonksiyon denklem 14'te gösterilmektedir (Kavaklıoğlu, 2011: 369; Kavousi-Fard, Samet, Marzbani, 2014: 6048).

$$f(x) = w^T \phi(x) + b \quad (14)$$

Denklem 14'te ki $\varphi(x)$, girdiler için çekirdek fonksiyonu ifade etmektedir. Buradaki w ve b katsayıları Denklem 15'teki düzenlenmiş risk fonksiyonu ile belirlenmektedir (Beyca vd. 2015: 941)

$$R(f) = C \frac{1}{n} \sum_{i=1}^n L_{\varepsilon}(y_i, f(x_i)) + \frac{1}{2} \|w\|^2 \quad (15)$$

Denklemdaki ε (epsilon) hiper parametresi tahmin edilen değerlerin gerçek değerlerden ne kadar sapma göstereceği konusunda izin verilen tolerans aralığını ifade eder. C hiper parametresi ise w vektörünün düzlüğü ile ε 'den büyük hataların cezalandırılması arasındaki dengeyi belirlemektedir (Kavaklıoğlu, 2011: 370).

$$L_{\varepsilon}(y, f(x)) = \begin{cases} 0, & |y - f(x)| < \varepsilon \\ |y - f(x)| - \varepsilon, & |y - f(x)| \geq \varepsilon \end{cases} \quad (16)$$

Yukarıda gösterilen Denklem 16'da $L_{\varepsilon}(y, f(x))$ ε duyarsız kayıp fonksiyonu olarak tanımlanmıştır. Tahmin edilen değer ε aralığı içindeyse kayıp sıfıra eşit olmaktadır. Yumuşak marj hiper düzlemine benzer şekilde, ε bölgesinden sırasıyla pozitif ve negatif sapmaları temsil eden ξ_i ve ξ_i^* olmak üzere iki serbest değişkenin tanımlanması gerekmektedir. ξ_i ifadesi ε (hata toleransı) altında kalan eğitim hatalarını, ξ_i^* ifadesi ise ε üzerindeki eğitim hatalarını göstermektedir. Bu değişkenler bazı hatalara izin verilmesini sağlamaktadır. Bu durumda Denklem 14, aşağıda gösterilen Denklem 18, Denklem 19 ve Denklem 20'daki kısıtlar çerçevesinde Denklem 17 olarak yeniden yazılır (Beyca vd. 2015: 941; Fan, Peng, Hong, Sun, 2016: 961; Smola, Schölkopf, 2004: 200). Şekil 31'de destek vektör regresyonu için $f(x)$ fonksiyonu, ε ve ξ_i^* , ξ_i ifadelerinin görsel gösterimi bulunmaktadır.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (17)$$


Kısıtlar:

$$[w^T \varphi(x_i) + b] - y_i \leq \varepsilon + \xi_i^* \quad i = 1, \dots, n \quad (18)$$

$$y_i - [w^T \varphi(x_i) + b] \leq \varepsilon + \xi_i \quad i = 1, \dots, n \quad (19)$$

$$\xi_i, \xi_i^* \geq 0 \quad i = 1, \dots, n \quad (20)$$

Şekil 31: Destek Vektör Regresyonu İçin Hiper Düzlem



Bu kısıtlı optimizasyon problemi Denklem 21’de gösterilen Lagrange formu kullanılarak çözülmektedir (Hong, 2009: 411).

$$L(w, b, \xi_i, \xi_i^*, \alpha_i, \alpha_i^*, \beta_i, \beta_i^*) = \min \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^n (\xi_i + \xi_i^*) \right) - \sum_{i=1}^n \beta_i [w^T \varphi(x_i) + b - y_i + \varepsilon + \xi_i] - \sum_{i=1}^n \beta_i^* [y_i - w^T \varphi(x_i) - b + \varepsilon + \xi_i^*] - \sum_{i=1}^n \alpha_i \xi_i + \alpha_i^* \xi_i^* \quad (21)$$

Denklem 21, w, b, ξ_i, ξ_i^* değişkenlerine göre minimize edilirken, $\alpha_i, \alpha_i^*, \beta_i, \beta_i^*$ negatif olmayan Lagrange çarpanlarına göre maksimize edilir. Böylece Denklem 22-25 elde edilir (Hong, 2009: 411).

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^n (\beta_i - \beta_i^*) \varphi(x_i) = 0 \quad (22)$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^n (\beta_i^* - \beta_i) = 0 \quad (23)$$

$$\frac{\partial L}{\partial \xi_i} = C - \beta_i - \alpha_i = 0 \quad (24)$$

$$\frac{\partial L}{\partial \xi_i^*} = C - \beta_i^* - \alpha_i^* = 0 \quad (25)$$

Son olarak da Karush-Kuhn-Tucker koşulları regresyona uygulanır ve Denklem 17, Denklem 22-25'in Denklem 21'de yerine yazılması ile dual forma dönüşür. Dual Lagrange formu Denklem 26'da gösterilmektedir (Hong, 2009: 412; Beyca vd. 2015: 941).

$$\max \sum_{i=1}^n y_i (\beta_i - \beta_i^*) - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i ((\beta_i - \beta_i^*) x (\beta_j - \beta_j^*) K(x_i x_j)) \quad (26)$$

Kısıtlar:

$$\sum_{i=1}^n (\beta_i - \beta_i^*) = 0 \quad (27)$$

$$0 \leq \beta_i \leq C \quad (28)$$

$$0 \leq \beta_i^* \leq C \quad (29)$$

$$i = 1, 2, 3, \dots, n \quad (30)$$

Denklem 26'daki Lagrange çarpanları $\beta_i * \beta_i^* = 0$ eşitliğini sağlar. β_i ve β_i^* Lagrange çarpanları hesaplanır ve regresyon hiper düzleminin istenilen optimal ağırlık vektörü Denklem 31 ile bulunur. Sonuç olarak regresyon fonksiyonu Denklem 32 ile ifade edilir (Hong, 2009: 412).

$$w^* = \sum_{i=1}^n (\beta_i - \beta_i^*) \varphi(x_i) \quad (31)$$

$$f(x) = (\beta_i - \beta_i^*) K(x_i x_j) + b \quad (32)$$

Denklem 32'de ki $K(x_i x_j)$, değeri $\varphi(x_i)$ ve $\varphi(x_j)$ özellik uzayındaki iki vektörün (x_i, x_j) iç çarpımına eşit olan çekirdek (Kernel) fonksiyondur. Destek vektör

regresyonunda en popüler çekirdek fonksiyonları radyal tabanlı çekirdek, polinom çekirdek, sigmoid çekirdek ve doğrusal (lineer) çekirdektir (Beyca vd. 2015: 941).


Başarılı bir destek vektör regresyonu modeli oluştururken C ve ε hiper parametrelerinin ve çekirdek fonksiyon parametrelerinin iyi bir şekilde belirlenmesi gerekmektedir. Eğitim hatası ile modelin sağlamlığı arasındaki dengeyi sağlayan C hiper parametresi büyük bir değer alırsa amaç fonksiyonunun ampirik riski ($L_\varepsilon(y, f(x))$) en aza indirilecektir. Diğer önemli hiper parametre ise destek vektör sayısını kontrol eden ε parametresidir. Büyük ε değerleri daha az sayıda destek vektörü kullanılmasına sebep olacaktır. Bu da daha basit regresyon fonksiyonları ile sonuçlanmaktadır. Bu parametreleri belirlenmesi için bilgi ve deneyime dayalı olarak karar vermek veya çapraz doğrulama yöntemi yaygın bir şekilde kullanılmaktadır (Hong, 2009: 412; Kavousi-Fard, Samet, Marzbani, 2014: 6049).

4.3. RASTGELE ORMAN REGRESYONU

Leo Breiman tarafından ileri sürülen rastgele ormanlar, sınıflandırma ve regresyon problemlerinin çözümü için kullanılan denetimli makine öğrenmesi algoritmasıdır. Tek bir ağaç iyi performans gösteriyorsa aralarında yeterli çeşitlilik olması koşulu ile birden fazla ağacın bir araya gelmesi ile oluşan rastgele ormanların daha iyi performans göstereceği temel fikrine dayanmaktadır (Marsland, 2015: 275). Bu algoritmanın temelini oluşturan istatistiksel prosedür torbalama (bagging) yöntemidir. Bagging yönteminde veri seti içerisinde bootstrap tekniği ile örneklem seçilerek birbirinden bağımsız karar ağaçları oluşturulmaktadır (Akman, 2010: 33). Bir dizi bootstrap örneği alındıktan sonra bagging yöntemi her veri kümesi için bir model oluşturmayı ve ardından bir tahmin çıktısı üretmeyi içerir. Sınıflandırma için kullanıldığında rastgele bir orman her ağaçtan bir sınıf oyu alır ve ardından çoğunluk oyu kullanarak sınıflandırma işlemini gerçekleştirir. Regresyon problemlerinde kullanıldığında ise orman içerisindeki her bir ağacın ürettiği tahminlerin ortalaması alınarak nihai bir tahmin sonucu üretilir (Hastie, Tibshirani, Friedman, 2008: 605). Bu çalışma prensibi, her bir alt küme farklı bir örnekleme ile alındığından dolayı aşırı uyum (overfitting) riskini azaltmakta ve modelin genelleme yeteneğini artırmaktadır (Jiang, Gradus, Rosellini, 2020: 678). Rastgele orman algoritmasının tercih

edilmesinin en önemli nedenlerinden birisi aşırı uyumu azaltıyor olmasıdır. Bir diğer özelliği ise karar verilmesi gereken çok fazla hiper parametreye sahip olmamasıdır. Üç önemli hiper parametresi vardır. Bunlar; rastgele oluşturulan alt kümedeki değişken sayısı, ormandaki ağaç sayısı ve her bir ağacın boyutudur (derinliği) (Liaw, Wiener, 2002: 18; Díaz, Hansen, Cabrera, 2020: 3).

Şekil 32: Rastgele Orman Algoritması Çalışma Prensibi



Şekil 32’de rastgele orman algoritmasının çalışma prensibi gösterilmektedir. Buna göre temel rastgele orman eğitim algoritmasının oluşturulması için gerçekleştirilen işlemler aşağıdaki gibi sıralanabilir (Liaw, Wiener, 2002: 18; Akman, 2010: 35-36);

1. Orijinal veri setinden n tane (n_{tree}) bootstrap örneklem oluşturun. Oluşturulan her bir örneklemin $2/3$ ’ünü ağacı oluşturmak için eğitim verisi olarak kullanın.
2. Her bir bootstrap örnekleme için budanmamış sınıflama veya regresyon ağacını aşağıdaki adımları takip ederek oluşturun;
 - i. Eğitim veri setinden her düğümde tüm bağımsız değişkenler içerisinde en iyi değişkeni seçmek yerine rastgele m tane (m_{try}) değişkeni seçin ve bunların arasından en çok bilgi kazancı sağlayacak olanı belirleyin. Varsayılan m değeri

regresyon problemlerinde $p/3$, sınıflandırma problemlerinde ise $p^{\frac{1}{2}}$ yani $\sqrt{p}$ olarak önerilmiştir. Buradaki p ifadesi bağımsız değişkenlerin toplam sayısını ifade etmektedir.

- ii. Gini indeksini kullanarak belirlenen tahmin değişkeni için en iyi dallanma kriterini hesaplayın ve hesaplanan değere göre veri setini her düğümde iki alt dala ayırın.
- iii. İlk iki adımı (i ve ii) aşağıya doğru yaprak düğüm elde edilinceye kadar her düğümde tekrar edin.

3. n tane ağacın yapmış olduğu tahminleri bir araya getirerek yeni bir tahminde bulunun. Daha önce de bahsedildiği gibi sınıflandırma için oy çoğunluğu, regresyon için ortalama alma işlemi uygulanmaktadır.

Rastgele orman algoritmasının kullanılmasına karar verirken bazı olumlu ve olumsuz tarafları karar vericiler için bir yol gösterici olmaktadır. Algoritmanın olumlu ve olumsuz yanları aşağıdaki gibi sıralanmıştır.

Üstün yönleri (Aung, Min, 2017: 129);

- Aşırı uyuma dayanıklıdır.
- Düşük tahmin hatası ile yüksek doğruluğa sahip sonuçlar üretir.
- Yüksek boyutlu veri kümelerinde kullanılabilir.
- Binlerce değişkenin önem derecelerini gösterdiğinden dolayı önemsiz olanları modelden çıkarmak için fırsat sunar (boyut azaltma).
- Eksik veri setlerine karşı tutarlı sonuçlar üretebilir.
- İstenildiği kadar ağaç ile çalışılmasına olanak sağlar.

Zayıf yönleri (Jiang, Gradus, Rosellini, 2020: 680);

- Yüzlerce veya binlerce ağaçtan oluşan bir orman görsel olarak tek bir ağaç kadar kolay yorumlanamaz.
- Birden fazla karar ağacını eğitmek ve birleştirmek yüksek işlem gücü ve bellek kullanımı gerektirmektedir.
- Gürültülü veri setlerinden etkilenmektedir.

BEŞİNCİ BÖLÜM

UYGULAMA

5.1. UYGULAMANIN AMACI VE ÖNEMİ

Doğal gaz, stratejik önemi olan bir enerji kaynağıdır ve ülkeler tarafından giderek artan bir şekilde tüketilmektedir. Doğal gaz, enerji kaynakları arasında önemli bir yer tutmakla birlikte, sadece gaz rezervine sahip olmak değil, bu gazı çıkararak ticari bir ürüne dönüştürmek ve mevcut kullanıcılar tarafından tüketilecek miktarı belirlemek de son derece önemlidir. Özellikle doğal gaz kaynağı açısından yüksek oranda dışa bağımlı olan ülkeler için doğal gaz talebinin tahmin edilmesi, enerji kaynak planlaması, take-or-pay anlaşmalarının olumsuz etkilerinden kaçınma ve mevcut depolama kapasitesi ile talep fazlası ürün arasında bir denge sağlama gibi nedenlerle kritik bir öneme sahiptir. Doğal gaz talebini en az hata ile tahmin etmek, bu ülkelerin doğal gaz taleplerini yönetmeleri açısından oldukça önemlidir.


Bu çalışmada doğal gaz tedarik zinciri yapısı incelendikten sonra Türkiye'nin doğal gaz tüketimini açıklayan bazı değişkenlerin belirlenmesi ve doğal gaz tüketimi için uygun tahmin modelinin tespit edilmesi amaçlanmıştır. Yapılan çalışmanın önemi üç ana başlık altında açıklanabilir.

1. Enerji Kaynak Planlaması: Doğal gaz tüketimini düşük hata değerleri ile tahmin etmek arz-talep dengesinin sağlanması açısından önemlidir. Sanayi, ticari hizmet veren işletmeler, konutlar gibi birçok sektörde etkin bir şekilde kullanılan doğal gazın, artan taleplere yanıt veren miktarlarda bulundurulması gerekmektedir.
2. Yatırım Kararları: Doğal gazın tüketim miktarını doğru izleyerek alınması gereken kararlar vardır. Doğal gaz talep tahminleri doğal gaz altyapısı, depolama tesisleri ve iletim hatlarının geliştirilmesi ve yatırımlarının planlanması için kullanılır. Türkiye'nin mevcut doğal gaz yatırımları artarak devam etmektedir. Mevcut doğal gaz depolama tesisleri yeterli olmamakla birlikte yapımı devam eden veya kapasitesi genişletilmesi planlanan depolama tesisleri bulunmaktadır. Talep tahminleri gelecek dönemlerde doğal gaz depolarının yatırımları ve hacmi hakkında bir öngörü sunmaktadır.

3. Ticari Anlaşmalar ve Dışa Bağımlılık: Türkiye yapmış olduğu ticari anlaşmalar ile birçok ülkeden doğal gaz ithal etmektedir. Bu anlaşmalar take-or-pay anlaşmalarıdır. Bu tür anlaşmalarda alıcı belirli bir miktarda ürün veya hizmeti satın almayı garanti eder ve bu miktarı satın almazsa yine de ödeme yapmayı kabul eder. Yetersiz tahmin modelleri ile tahmin edilen doğal gaz tüketim miktarı ihtiyaç duyulandan fazla miktarı içeren anlaşmaların imzalanmasına ve take-or-pay cezalarına katlanılmasına neden olmaktadır. Bu durumda yeterli depolama altyapısı satın alma işleminin yine de gerçekleşmesine fırsat verebilirken, depolama maliyetlerini de göz önünde bulundurmak gerekmektedir.

Bahsedilen amaç ve önemler dikkate alınarak hazırlanan çalışmada tahmin modelini oluşturmak için son yıllarda pek çok sektör için kullanılan ve başarılı sonuçlar veren makine öğrenmesi yöntemleri kullanılmıştır. Bunlar; çoklu doğrusal regresyon, destek vektör regresyonu ve rastgele orman regresyonudur. Çalışmanın akış diyagramı Şekil 33'te gösterilmektedir.

Şekil 33: Çalışmanın Akış Diyagramı




Çalışmada oluşturulacak olan tahmin modelleri Python programlama dili kullanılarak oluşturulmuştur. Python, hem anlaşılır ve kolay bir dil olması hem de veri analizi, yapay zekâ, otomasyon gibi birçok alanda geniş bir şekilde kullanımına sebep olan kütüphaneleri ile günümüzün popüler bir programlama dili olmuştur. Python kodları Visual Studio Code düzenleyicisi üzerinde çalıştırılmıştır.

5.2. DEĞİŞKEN BELİRLEME VE VERİ TOPLAMA

Çalışmada doğal gaz tüketimini modellemek için 2010-2022 yılları arası toplam Türkiye doğal gaz tüketim verileri hedef değişken olarak kullanılmıştır. İlgili veriler jodidata.org sitesinden alınmıştır. İlgili tüketim verileri Şekil 34’te gösterilmektedir.

Şekil 34: 2010-2022 Yılları Arası Türkiye’nin Doğal Gaz Tüketim Verileri



Doğal gaz tüketimini modelleme amacıyla açıklayıcı değişkenleri belirlemek için kapsamlı bir literatür taraması gerçekleştirildi. İkinci bölümde yer alan Tablo 10, bağımsız değişkenlerin belirlenmesinde göz önünde bulundurulmuştur. Tabloda doğal gaz talebini modellerken dikkate alınan değişkenlerin büyük bir çoğunluğunun meteorolojik veriler olduğu gözlemlenmiştir. Yıllık veya çeyreklik gibi uzun dönemli tüketim verilerini modellerken sosyo-ekonomik değişkenler dikkate alınırken daha kısa süreli olan saatlik, günlük, haftalık ve aylık tüketim verilerini modellerken meteorolojik değişkenlerin dikkate alındığı gözlemlenmiştir. Bu nedenle modele eklenecek bağımsız değişkenlerin meteorolojik değişkenler olmasına karar verilmiştir.

Sıklıkla kullanılan hava sıcaklığı (Chen vd., 2018; Brabec vd. 2008; Lu vd., 2019; Tonkovic vd., 2009; Sabo vd., 2011; Potocnik vd., 2014; Karimi ve Dastranj, 2014; İzadyar vd., 2015; Szoplik, 2015, Potocnik vd. 2019; Aras, 2008; Kızılaslan ve Karlık, 2009; Demirel vd., 2012; Taşpınar vd., 2013; Beyca vd., 2019; Şen vd., 2019; Yükseltan vd., 2021; Panapakidis ve Dagoumas, 2017), yağış (Karimi ve Dastranj, 2014), nem (Karimi ve Dastranj, 2014; Potocnik vd. 2019; Taşpınar vd., 2013), HDD (Scarpa ve Bianco, 2017; Özmen vd., 2018), rüzgâr hızı (Tonkovic vd., 2009; Karimi ve Dastranj, 2014; Potocnik vd. 2019; Taşpınar vd., 2013) ve güneş radyasyonu (Potocnik vd., 2014; Potocnik vd. 2019) verileri Meteoroloji Genel Müdürlüğü ile yapılan resmi yazışmalar sonucunda elde edilmiştir. Türkiye'nin her şehri için ilgili verilerin toplandığı veri toplama merkezlerinden gelen verilerin, veri analizi için yaygın bir şekilde kullanılan Pandas kütüphanesinde bulunan “groupby” fonksiyonu ile her yılın her ayı için Türkiye geneli ortalamaları alınmıştır. Oluşturulan verilerin bir kısmının örneği Tablo 13'te gösterilmiştir.

Tablo 13: Meteorolojik Değişkenler

Tarih	Nem_(%)	Rüzgar_Hızı_(m:sn)	Yağış_(mm)	Güneş_Radyasyonu_(kws)	HDD	Ortalama_Sıcaklık_(°C)
Jan2010	78.044390	2.407143	105.238626	46.061682	390.6	5.050000
Feb2010	74.654768	2.546875	88.866208	61.583654	297.0	7.115892
Mar2010	66.734474	2.466827	48.509954	105.207407	256.3	9.240931
Apr2010	65.750123	2.285372	48.589634	139.619266	163.3	12.421182
May2010	59.398030	2.188249	36.901994	171.019820	60.4	17.685749
Jun2010	60.289163	2.279856	54.008576	165.361818	13.0	21.853317
Jul2010	55.204878	2.421241	18.858462	189.077273	10.0	25.522439
Aug2010	48.313350	2.298575	7.554717	176.465487	8.0	27.009685
Sep2010	54.458596	2.479858	21.159591	137.138739	21.2	22.141646
Oct2010	70.822222	2.069504	114.700000	86.846429	120.9	14.659662


Literatür taraması sonucunda doğal gaz tüketiminde bağımsız değişken olarak gecikme değerlerini de dikkate alan çalışmalar ile karşılaşılmıştır (Tonkovic vd. 2009; Azadeh vd., 2010; Demirel vd., 2012, Beyca vd., 2019). Bu nedenle geçmiş tüketim verilerinin de bağımsız değişken olarak dahil edilmesine karar verilmiştir. Burada önemli olan kaç dönemlik gecikme verilerinin dikkate alınacağını belirlenmesidir. Bunun için 1 ve 15 ay arasında gecikme değerlerinin otokorelasyon değerleri kontrol edilmiştir. Python'da bulunan “statsmodel” modülünün içerisinde zaman serileri

üzerinde istatistiksel analizler yapmak için kullanılan “tsa” alt modülü kullanılarak otokorelasyon testi yapılmıştır. Otokorelasyon değerleri Tablo 14’te ve Şekil 35’te gösterilmektedir. 1 aylık gecikme ve 12 aylık gecikme değerlerinin otokorelasyon katsayıları birbirine çok yakın çıkmıştır. Mevsimsel etkilerin ve zaman içindeki trendlerin doğru bir şekilde modellenmesini sağlamak için ve bağımlı değişken ile 1 aylık gecikme değerlerine göre daha yüksek korelasyona sahip olduğu tespit edildiğinden dolayı model oluştururken 12 aylık gecikme değerleri dikkate alınmıştır. İleride oluşturulan tahmin modellerinde 1 aylık ve 12 aylık gecikme değerleri ayrı ayrı incelendiğinde de 12 aylık gecikme değerlerinin bağımsız değişken olarak dahil edildiği modellerin daha düşük RMSE ve daha yüksek R^2 değerine sahip olduğu tespit edilmiştir.

Tablo 14: Doğal Gaz Tüketim Verileri İçin Otokorelasyon Değerleri

Gecikmeler	Otokorelasyon Katsayısı	Gecikmeler	Otokorelasyon Katsayısı	Gecikmeler	Otokorelasyon Katsayısı
1	0.7412	6	-0.50	11	0.59
2	0.42	7	-0.46	12	0.7404
3	0.05	8	-0.31	13	0.58
4	-0.23	9	-0.02	14	0.29
5	-0.43	10	0.27	15	-0.05


Şekil 35: Doğal Gaz Tüketim Verilerinin Otokorelasyon Grafiği



5.3. VERİ ANALİZİ

Düşük hataya sahip modeller oluşturmak için hedef değişkeni en iyi şekilde açıklayan değişkenlerin tespit edilmesi oldukça önemlidir. Bu sebeple ilk olarak literatür taraması sonucu dikkate alınmasına karar verilen bağımsız değişkenler ve tüketim verisi arasındaki ilişkiyi tespit etmek için korelasyon analizi yapılmıştır. Python’da veri görselleştirmek için kullanılan Seaborn ve Matplotlib kütüphaneleri kullanılarak ısı haritası (heatmap) oluşturulmuştur. Oluşturulan harita Şekil 36’da gösterilmektedir.

Şekil 36: Değişkenler Arasındaki Korelasyon Değerleri



Isı haritası incelendiğinde 12 ay gecikme değerleri, HDD ve ortalama sıcaklık verilerinin doğal gaz tüketimi ile güçlü bir şekilde ($|r| \geq 0.8$), nem, yağış ve güneş radyasyonu verilerinin orta derecede ($0.5 \leq |r| \leq 0.8$) ilişkili olduğu tespit edilmiştir. Rüzgâr hızı ise -0.079 korelasyon katsayısı ile doğal gaz tüketimini açıklamak için yetersiz bulunmuştur. Bu nedenle rüzgâr hızı değişkeninin doğal gaz tüketimi için oluşturulacak tahmin modelinden çıkarılmasına karar verilmiştir. Modele dahil edilmeyen bir diğer değişken ise ortalama sıcaklık değişkenidir. Isı haritasında da

görüldüğü üzere ortalama sıcaklık verileri ile HDD verileri arasında -0.96 korelasyon katsayısı ile güçlü bir ilişki olduğu tespit edilmiştir. Bağımsız değişkenler arasında bu şekilde güçlü ilişki olması modelde çoklu doğrusallık probleminin oluşmasına sebep olacağından ortalama sıcaklık verilerinin modelden çıkarılmasına karar verilmiştir.

Korelasyon analizi sonuçlarına göre modele eklenmesi planlanan değişkenlerin anlamlılığını ve uygunluğunu gözlemleyebilmek için Python'ın "statsmodel" modülünde yer alan sıradan en küçük kareler regresyonu (OLS) kullanılmıştır. İlk olarak tüm değişkenler modele eklenmiş ve OLS modeli sonucuna göre değişkenlerin uygunluğu tespit edilip, anlamlı çıkmayan verilerin modelden çıkarılması hedeflenmiştir. İlk yapılan OLS regresyon sonuçlarına göre yağış ve güneş radyasyonu değişkenlerinin $P > |t|$ değerlerinin 0.05 sınırından büyük olması nedeni ile modelden çıkarılmış ve OLS regresyonu tekrar yapılmıştır.

Tablo 15'te anlamlı çıkmayan değişkenlerin geri eleme yöntemi ile çıkarılması sonucu elde edilen OLS regresyon sonuçları gösterilmektedir. Bu tablodaki R-squared değeri doğrusal modelin anlamlılığını göstermektedir. En yüksek değeri 1 olan R-squared değeri oluşturulan doğrusal modelde 0.982 olarak hesaplanmıştır. Bu da modelin anlamlılığını göstermektedir. Bağımsız değişkenlerin $P > |t|$ değerlerinin 0 olması ise bu değişkenleri modele eklemenin sonuçları kötü etkilemeyeceği sonucunu vermektedir.

Tablo 15: OLS Regresyon Sonuçları


OLS Regression Results						
Dep. Variable:	dgtüketim	R-squared (uncentered):	0.982			
Model:	OLS	Adj. R-squared (uncentered):	0.981			
Method:	Least Squares	F-statistic:	2521.			
Date:	Wed, 14 Jun 2023	Prob (F-statistic):	3.07e-122			
Time:	23:36:45	Log-Likelihood:	-1119.1			
No. Observations:	144	AIC:	2244.			
Df Residuals:	141	BIC:	2253.			
Df Model:	3					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025	0.975]
12aygecikme	0.4784	0.071	6.761	0.000	0.338	0.618
Nem_(%)	25.2820	3.861	6.547	0.000	17.648	32.916
HDD	2.7218	0.414	6.578	0.000	1.904	3.540

Analizler sonucu modeli oluşturmak için HDD, tüketim verilerinin 12 ay gecikme değerleri ve nem verileri dikkate alınmıştır. Bu değişkenler aşağıda kısaca açıklanmıştır.

HDD (Heat Degree Days)

Isı haritası incelendiğinde 0.86 Pearson korelasyon katsayısına göre doğal gaz tüketimi ile en yüksek ilişkisi tespit edilen değişken HDD'dir. Isıtma gün dereceleri olarak ifade edilen HDD gün, ay, yıl gibi belirli bir zamanda dış ortam ve oda sıcaklığını hesaba katarak soğğun şiddetini açıklamaktadır. Hesaplama günlük yapılır, aylık ve yıllık gün derece toplamaları daha sonra bulunur. Sıcaklık ve soğuk hava koşullarını temsil ettiği için doğal gaz tüketimi ile ilişkilendirilebilir. Şekil 37 doğal gaz tüketim verileri ve HDD verileri arasındaki ilişkiyi göstermektedir.

Şekil 37: HDD ve Doğal Gaz Tüketimi Verilerinin Serpilme Diyagramı




Gecikme Değerleri

Korelasyon katsayısı yüksek çıkan bir diğer değişken ise 12 ay gecikme değerleridir. Bu durum bize örneğin 2021 yılının ocak ayı tüketiminin 2020 yılının ocak ayı tüketimi ile güçlü bir ilişkisi olduğunu söylemektedir. Doğal gaz tüketim verileri ve

gecikme verileri arasındaki ilişkiyi göstermektedir. İyi seçilmiş gecikme değişkenleri trendlerin yakalanmasına, tahmin gücünün artırılmasına yardımcı olmaktadır. Doğal gaz tüketim verileri ve 12 aylık gecikme değerleri arasındaki ilişkiyi gösteren serpilme diyagramı Şekil 38’de yer almaktadır.


Şekil 38: 12 Ay Gecikme ve Doğal Gaz Tüketimi Verilerinin Serpilme Diyagramı



Nem

0.72 korelasyon katsayısına sahip nem ise ile doğal gaz tüketimi ile arasında iyi ilişki bulunan bir diğer değişkendir. Bölgelere göre farklılık gösteren nem oranı havanın içerisinde taşıdığı su buharı miktarıdır. Hava sıcaklığının yüksek olduğu zamanlarda nem oranının da yüksek olması beklenmektedir.

Şekil 39: Nem Oranı ve Doğal Gaz Tüketimi Arasındaki İlişki



Modele eklenmesine karar verilen değişkenlerin ve hedef değişkenin durağan olup olmadığını kontrol etmek gerekmektedir. Durağan olmayan seriler birim kök içermektedir. Birim kök içeren serinin gelecekteki davranışını tahmin etmek zordur. Değişkenlerin durağanlığını kontrol etmek için KPSS (Kwiatkowski-Phillips-Schmidt-Shin) testi kullanılmıştır. Serinin durağan olduğunu yani birim kök içermediğini ileri süren H_0 hipotezi ile serinin durağan olmadığını yani birim kök içerdiğini ileri süren H_1 hipotezini test etmektedir. KPSS testinde test istatistik değerinin kritik değerden küçük olması durumunda serinin birim kök içermediği sonucuna ulaşıp H_0 hipotezi kabul edilmektedir.

Tablo 16’da gösterilen KPSS test sonuçlarına göre tüm serilerin durağan olduğu tespit edilmiştir.

Tablo 16: KPSS Test Sonuçları

	LM-ist.	%5 Kritik Değer
Doğal Gaz Tüketim	0.167670	0.463000
12 Ay Gecikme	0.346724	0.463000
HDD	0.042439	0.463000
Nem	0.182427	0.463000

5.4. MODEL OLUŞTURMA


Çalışmada kullanılan yöntemlerin performansları seçilen hata metriklerine göre karşılaştırılacaktır. Hata metriklerinin temelinde tahmin hatasının hesaplanması vardır. Bunu yapmak için ilk önce oluşturulacak model bazı verilerle eğitilmiş, sonrasında ise oluşan model daha önce hiç görmediği veriler ile test edilmiştir. Çalışmada 12 aylık gecikme değerleri kullanıldığından dolayı ve 2009 yılına ait veriler elimizde bulunmadığından dolayı 2010 yılı tüketim verileri 2011 yılının tüketim verilerinin hesaplanmasında bağımsız değişken olarak kullanılmıştır. Bu nedenle dikkate alınan dönem 2011-2022 yılları arası olmuştur. Veriler %80'i eğitim %20'si test verisi olarak ikiye ayrılmıştır. Bu işlemin gerçekleştirilmesi için Python'da bulunan Sklearn kütüphanesinden “train_test_split” fonksiyonu kullanılmıştır. Veriler eğitim ve test verisi olarak ayrıldıktan sonra algoritmaları kullanarak modeller kurulmuş ve tahmin hataları kullanılan metriklerine (RMSE, R^2) göre tespit edilmiştir.

5.4.1 ÇOKLU DOĞRUSAL REGRESYON

Çoklu doğrusal regresyon modeli geleneksel yöntem olarak ele alınmış olup ileri seviye makine öğrenmesi algoritmalarının yöntemlerinin tahmin performansını karşılaştırmak için kullanılmıştır. Bu yöntemde ayarlanması gereken bir hiper parametre bulunmamaktadır. İlk olarak Sklearn kütüphanesinden LinearRegression modülü çağırılmıştır. Daha sonra bağımlı değişkenler ve bağımsız değişkenler eğitim ve test verisi olarak ayrılmıştır. Bağımlı değişken y_{train} , y_{test} , bağımsız değişkenler X_{train} , X_{test} olarak gösterilmiştir. Eğitim verileri ile oluşturulan modele daha sonra test verileri verilmiştir. Bu işlem sonrasında da tahmin hataları elde edilmiştir.

Oluşturulan çoklu doğrusal regresyon modelinde RMSE değeri 536.29 ve R^2 değeri ise %80.57 bulunmuştur. RMSE yüksek olması tahmin performansının düşük olduğu anlamına gelirken, R^2 değerinin yüksek olması tahmin performansının iyi olduğu anlamına gelmektedir. Tablo 17'de model sonucunda elde edilen tahmin değerleri ve gerçekleşen değerlerin tablosu, Şekil 40'ta model sonucunda elde edilen tahmin değerleri ve gerçekleşen değerlerin karşılaştırıldığı grafik gösterilmektedir.

Şekil 40: Çoklu Doğrusal Regresyon İçin Gerçekleşen ve Tahmin Edilen Değerler Grafiği



Tablo 17: Çoklu Doğrusal Regresyon İçin Gerçekleşen ve Tahmin Edilen Değerler Tablosu

Tarih	Gerçekleşen Değerler	Tahmin Değerleri
Ekim 2020	3572	3133.43
Ağustos 2012	3152	3104.25
Kasım 2017	5908	4686.2
Şubat 2019	4854	5276.99
Eylül 2015	3185	3521.62
Ocak 2012	5244	5730.47
Ocak 2022	7137	6466.14
Haziran 2016	2830	2975.44
Temmuz 2016	2875	2983.34
Temmuz 2012	3455	3086.16
Nisan 2015	3797	4057.66
Temmuz 2017	3938	2975.85
Kasım 2018	4208	4964.26
Şubat 2022	6138	5468.45
Mayıs 2019	2543	3203.14
Mayıs 2016	2880	3123.86
Nisan 2013	3341	3421.99
Ekim 2016	3379	3562.84


Haziran 2021	3811	2748.52
Şubat 2017	5512	5216.3
Aralık 2011	5072	5266.54
Aralık 2020	6341	5371.28
Mart 2020	4210	4721.17
Haziran 2020	2498	2587.07
Ağustos 2015	3411	3215.94
Ekim 2014	3389	3510.86
Ekim 2011	3684	3754.91
Mayıs 2011	2664	3031.62
Mart 2013	4139	4777.74

5.4.2 DESTEK VEKTÖR REGRESYON

Destek vektör regresyonu modelini oluşturmak için Sklearn kütüphanesinden SVR modülü çağırılmıştır. Bu yöntemde ayarlanması gereken iki önemli hiper parametre vardır. Bunlar C ve epsilon değerleridir. Model performansı üzerinde etkili olduğu bilinen bu iki hiper parametrenin belirlenmesi için çapraz doğrulama (cross-validation) işlemi yapılmıştır. Bu yöntem veri setini farklı parçalara böler ve modelin eğitim ve değerlendirme sürecini bu parçalar üzerinde tekrar tekrar gerçekleştirir. En az hataya sahip modelde kullanılan hiper parametreleri vererek, nihai modelde bu hiper parametre değerlerinin kullanılmasını önermektedir. Bu işlemi gerçekleştirmek için Sklearn kütüphanesinden GridSearchCV çağırılmıştır. Lineer kernel en anlamlı sonuçları verdiği için çekirdek fonksiyon olarak seçilmiştir. C parametresi 0.1, epsilon parametresi ise 0.9 olarak tespit edilmiştir. Sonuçlara göre RMSE değeri 543.97 bulunurken R^2 değeri %80.01 çıkmıştır.

Tablo 18’de model sonucunda elde edilen tahmin değerleri ve gerçekleşen değerlerin tablosu, Şekil 41’de model sonucunda elde edilen tahmin değerleri ve gerçekleşen değerlerin karşılaştırıldığı grafik gösterilmektedir.

Şekil 41: Destek Vektör Regresyonu İçin Gerçekleşen ve Tahmin Edilen Değerler Grafiği



Tablo 18: Destek Vektör Regresyonu İçin Gerçekleşen ve Tahmin Edilen Değerler Tablosu

Tarih	Gerçekleşen Değerler	Tahmin Değerleri
Ekim 2020	3572	3099.31
Ağustos 2012	3152	3032.48
Kasım 2017	5908	4718.91
Şubat 2019	4854	5267.87
Eylül 2015	3185	3268.77
Ocak 2012	5244	5564.63
Ocak 2022	7137	6387.18
Haziran 2016	2830	2987.09
Temmuz 2016	2875	2957.58
Temmuz 2012	3455	3030.58
Nisan 2015	3797	3986.33
Temmuz 2017	3938	2926.99
Kasım 2018	4208	5092.83
Şubat 2022	6138	5461.76
Mayıs 2019	2543	3226.14
Mayıs 2016	2880	3181.17
Nisan 2013	3341	3374.89


Ekim 2016	3379	3537.68
Haziran 2021	3811	2767.92
Şubat 2017	5512	5047.67
Aralık 2011	5072	5095.12
Aralık 2020	6341	5389.5
Mart 2020	4210	4717.57
Haziran 2020	2498	2590.67
Ağustos 2015	3411	3244.35
Ekim 2014	3389	3572.52
Ekim 2011	3684	3692.3
Mayıs 2011	2664	3052.22
Mart 2013	4139	4691.08

5.4.3 RASTGELE ORMAN REGRESYON

Rastgele orman regresyonu modelini oluşturmak için Sklearn kütüphanesinden RandomForestRegressor modülü çağırılmıştır. Bu yöntemde ayarlanması gereken üç önemli hiper parametre vardır. Bunlar maksimum derinlik, maksimum özellik ve oluşturulacak karar ağacı sayısıdır. Çapraz doğrulama ile bu hiper parametrelerin en uygun değerleri bulunmuştur. “max_depth” hiper parametresi 2, “max_features” hiper parametresi 3 ve “n_estimators” hiper parametresi ise 100 bulunmuştur. Modelin RMSE değeri 546.65 ve R^2 değeri %79 bulunmuştur.

Tablo 29’da model sonucunda elde edilen tahmin değerleri ve gerçekleşen değerlerin tablosu, Şekil 42’de model sonucunda elde edilen tahmin değerleri ve gerçekleşen değerlerin karşılaştırıldığı grafik gösterilmektedir.

Şekil 42: Rastgele Orman Regresyonu İçin Gerçekleşen ve Tahmin Edilen Değerler Grafiği



Tablo 19: Rastgele Orman Regresyonu İçin Gerçekleşen ve Tahmin Edilen Değerler Tablosu

Tarih	Gerçekleşen Değerler	Tahmin Değerleri
Ekim 2020	3572	2966.86
Ağustos 2012	3152	3388.96
Kasım 2017	5908	4811.81
Şubat 2019	4854	5464.43
Eylül 2015	3185	3002.85
Ocak 2012	5244	5125.24
Ocak 2022	7137	6410.33
Haziran 2016	2830	2930.47
Temmuz 2016	2875	3090.21
Temmuz 2012	3455	3677.08
Nisan 2015	3797	4053.04
Temmuz 2017	3938	3390.54
Kasım 2018	4208	5317.28
Şubat 2022	6138	5903.78
Mayıs 2019	2543	3244.93
Mayıs 2016	2880	3171.22
Nisan 2013	3341	4064.91
Ekim 2016	3379	3391.99

Haziran 2021	3811	2426.36
Şubat 2017	5512	5032.93
Aralık 2011	5072	5080.87
Aralık 2020	6341	5875.54
Mart 2020	4210	4986.22
Haziran 2020	2498	2487.12
Ağustos 2015	3411	3091.14
Ekim 2014	3389	3415.71
Ekim 2011	3684	3746.91
Mayıs 2011	2664	2700.75
Mart 2013	4139	4541.07

SONUÇ

Bu çalışmada iki temel amaç üzerinde durulmuştur. Bunlardan bir tanesi doğal gaz tedarik zincirinin yapısal ve operasyonel özelliklerini ve Türkiye'nin doğal gaz tedarik zinciri içerisindeki yerini incelemektir. Diğer bir amaç ise Türkiye'nin doğal gaz tüketimini modellemek için kullanılabilecek anlamlı değişkenleri belirlemek ve farklı modellerin performanslarını karşılaştırarak bir model önerisinde bulunmaktır.

Doğal gaz tüketiminin üretim miktarını aşmasından dolayı çoğunlukla doğal gazı ithal eden Türkiye dünya doğal gaz piyasasında önemi giderek artan bir aktördür. Ülkeler arası enerji akışının sağlanmasında transit bir ülke konumunda olması nedeniyle birçok boru hattı Türkiye üzerinden geçmektedir. Bu durum Türkiye'nin dünya doğal gaz tedarik zinciri içerisindeki konumunu güçlendirmektedir. Özellikle artan nüfus ve gelişmiş sanayi faaliyetleri enerji kullanımının artmasına neden olmuştur. Öyle ki doğal gaz tüketiminde her bir tüketim sektörü açısından düzenli sayılabilecek bir artış yaşanmaktadır. Enerji dönüşüm, konutlar ve sanayi sektörleri bu tüketici gruplarının başında gelmektedir. Enerji akışındaki herhangi bir kesinti başta bu üç sektör olmak üzere diğerlerini de önemli ölçüde etkileyecektir.

Çalışmada doğal gaz tüketimini tahmin etmek için az sayıda veri ile iyi sonuçlar verdiği bilinen çoklu doğrusal regresyon, destek vektör regresyonu ve rastgele orman regresyonu yöntemleri kullanılmıştır. Bu yöntemler ile oluşturulan modellerde literatür taraması sonucu elde edilen ve doğal gaz tüketimini açıklamada anlamlı olan HDD, 12 aylık gecikme ve nem değerleri bağımsız değişken olarak kullanılmıştır. 2010-2022 yılları arası Türkiye'nin aylık doğal gaz tüketim miktarı da bağımlı değişken olarak kullanılmıştır. Modellerin performansı RMSE ve R^2 değerleri dikkate alınarak yorumlanmıştır. Çoklu doğrusal regresyon modelinin RMSE değeri 536.29, R^2 değeri %80.57 olarak hesaplanmıştır. Rastgele orman regresyonu yöntemi ile oluşturulan modelin RMSE değeri 546.65, R^2 değeri ise %79 olarak hesaplanmıştır. Destek vektör regresyonu ile oluşturulan modelin RMSE değeri 543.97 ve R^2 değeri %80.01 bulunmuştur. Seçilen üç modelin performanslarının birbirlerine yakın olmasının yanı sıra en düşük hata oranı çoklu doğrusal regresyon modeli ile elde edilmiştir. Model performansının birbirine yakın çıkmasının nedeni, kullanılan

bağımsız değişkenlerin ve veri setinin özellikleriyle ilişkilendirilebilir. Nem, HDD ve gecikme değerleri gibi faktörlerin doğal gaz talebi üzerinde önemli etkileri olduğu bilinmektedir. Bu nedenle, anlamlılık düzeyi yüksek olan bu bağımsız değişkenlerin modelde kullanılmasıyla tüm yöntemler benzer bir tahmin doğruluğu sunmuş olabilir.

Ayrıca, çoklu doğrusal regresyon, destek vektör regresyonu ve rastgele orman regresyonu yöntemleri farklı özelliklere ve varsayımlara sahiptir. Çoklu doğrusal regresyon, doğrusal ilişkileri yakalamak için kullanılırken, destek vektör regresyonu esnek bir çizgiyi takip edebilir ve rastgele orman regresyonu daha karmaşık ilişkileri modelleyebilir. Bununla birlikte destek vektör regresyonu doğrusal olmayan ilişkileri yakalamakta daha başarılı sonuçlar vermektedir. Modelde en düşük hatayı çekirdek fonksiyonlar içerisinde lineer çekirdek fonksiyonu ile oluşturulan model vermiştir. Lineer kernel, doğrusal bir hiper düzlemle verileri ayırarak regresyon işlemini gerçekleştirir. Bu durumda, doğrusal regresyon ve lineer kernel kullanılan SVR modeli benzer tahmin performansı göstermesi normaldir. Çalışmanın sonuçları gelişmiş makine öğrenmesi tekniklerinin yüksek performansının her veri kümesi için geçerli olmadığını göstermektedir. Geleneksel yöntemler bazı veri setleri için makine öğrenmesi yöntemlerine göre daha doğru sonuçlar üretme potansiyeline sahiptir.

Sonuç olarak, bu çalışma doğal gaz talep tahmini için farklı regresyon yöntemlerinin performansını değerlendirmekte ve bu yöntemlerin benzer tahmin doğruluğu sağladığını göstermektedir. Bu bulgular, enerji sektöründeki paydaşlara, doğal gaz taleplerini tahmin etmek için farklı yöntemleri kullanma esnekliği sağlamaktadır. Ancak, kullanılan bağımsız değişkenlerin ve model özelliklerinin daha detaylı bir analizini yaparak, yöntemlerin performansını daha iyi anlamak ve gelecekteki tahminlerin doğruluğunu artırmak mümkün olabilir.

Çalışmanın en önemli kısıtı model oluşturmak için erişilen verinin az sayıda olmasıdır. Şehir bazında doğal gaz tüketimi için bir tahmin modeli oluşturulmak istenildiğinde doğal gaz dağıtım işletmelerinden daha kısa zaman aralığını (saat, gün, hafta gibi) içeren tüketim verileri elde edilebilir. Fakat tüm ülke için doğal gaz tüketimini modellerken kullanılmak üzere erişilebilecek veri belirli bir döneme kadar aylık ve yıllık zaman aralıklarında sunulmaktadır. Bu durumda ilgili kurumlar ile iletişime

geçilip daha önceki (2010 ve öncesi) dönemler için aylık verilere ulaşılmalıdır. Daha fazla veri modelin eğitilmesi açısından önemli olmaktadır.

İleride yapılacak çalışmalarda doğal gaz tüketimini sektörlere göre tahmin eden modeller kurulabilir. Doğal gaz kullanan her bir sektörün (sanayi, konut vb.) kendine özgü özellikleri ve tüketim alışkanlıklarını yönlendiren faktörler vardır. Bu özellikleri keşfetmek için her bir sektör yapısı ayrı ayrı incelenip doğal gaz tüketimini etkileyecek faktörler belirlenebilir. Sektörler için ayrı ayrı yapılan ve farklı değişkenleri içeren modellerin sonuçları daha sonrasında birleştirilerek bir tahmin sonucu elde edilebilir. Doğal gaz tüketimini etkilediği düşünülen örneğin Gayri Safi Yurtiçi Hasıla, nüfus gibi sosyo-ekonomik veriler aylık doğal gaz tüketimini modellediğimiz çalışmada kullanılamamıştır. Bu veriler genellikle çeyreklik ve yıllık bazda yayınlanmaktadır. İlgili göstergelerin aylık verilerine erişmek daha genellenebilir model oluşturmak için bir fırsat sunabilir.

BİBLİYOGRAFYA / KAYNAKÇA

- Akman, Muhammet: “Veri Madenciliğine Genel Bakış ve Random Forests Yönteminin İncelenmesi: Sağlık Alanında Bir Uygulama,” **Ankara Üniversitesi Sağlık Bilimleri Enstitüsü**, 2010.
- Akkurt, M., Demirel, O. F., Zaim, S.: “Forecasting Turkey’s Natural Gas Consumption by Using Time Series Methods,” **European Journal of Economic and Political Studies**, C:3 No:2, 2010, pp.1-21.
- Akpınar, M., Yumusak, N.: “Year Ahead Demand Forecast of City Natural Gas Using Seasonal Time Series Methods,” **Energies**, C:9, No:9, 2016, pp.1-17.
- Alcaraz, C., Villalvazo, S.: “The Effect of Natural Gas Shortages on The Mexican Economy,” **Energy Economics**, C:66, 2017, pp.147-153.
- Alpaydın, Ethem: **Introduction To Machine Learning**, MIT Press., 2020.
- Alpaydın, Ethem: **Yapay Öğrenme: Yeni Yapay Zekâ**, Çev. Aylin Ağar, İstanbul, Tellekt Yayınları, 2021.
- Aras, Nil: “Forecasting Residential Consumption of Natural Gas Using Genetic Algorithms,” **Energy Exploration & Exploitation**, C:26, No:4, 2008, pp. 241-266.
- Aung, Y. Y., Min, M. M.: “An Analysis of Random Forest Algorithm Based Network Intrusion Detection System,” **18th IEEE/ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD)**, 2017, pp. 127-132.
- Aydın, Cihat: “İstanbul’da Doğal Gaz Kullanımının Çevreye Etkisi” **Sakarya Üniversitesi, Fen Bilimleri Enstitüsü**, Yüksek Lisans Tezi, Sakarya, 1999.
- Azadeh, A., Asadzadeh, S. M., Ghanbari, A.: “An Adaptive Network-Based Fuzzy Inference System for Short-Term Natural Gas Demand Estimation: Uncertain and Complex Environments,” **Energy Policy**, C:38, No:3, 2010, pp.1529-1536.
- Azadeh, A., Zarrin, M., Beik, H. R., Bioki, T. A.: “A Neuro-Fuzzy Algorithm for Improved Gas Consumption Forecasting with Economic, Environmental And IT/IS Indicators,” **Journal of Petroleum Science and Engineering**, C:133, 2015, pp.716-739.

- Balzani, V., Armaroli, N.: **Energy for a Sustainable World: From the Oil Age to A Sun-Powered Future**, John Wiley & Sons, 2010.
- Bayraç, H. N.: “Uluslararası Doğalgaz Piyasasının Ekonomik Yapısı ve Uygulanan Politikalar,” **Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi**, C:13, No:3, 2018, s.13-36.
- Behrooz, H. A., Boozarjomehry, R. B.: “Dynamic Optimization of Natural Gas Networks Under Customer Demand Uncertainties,” **Energy**, C:134, 2017, pp.968-983.
- Bell, J.: **Machine Learning: Hands-On for Developers and Technical Professionals**, John Wiley & Sons, 2020.
- Beyca, O. F., Ervural, B. C., Tatoglu, E., Ozuyar, P. G., Zaim, S.: “Using Machine Learning Tools for Forecasting Natural Gas Consumption in The Province of Istanbul,” **Energy Economics**, C:80, 2019, pp.937-949.
- Bianco, V., Scarpa, F., Tagliafico, L. A.: “Scenario Analysis of Nonresidential Natural Gas Consumption in Italy,” **Applied Energy**, C:113, 2014, pp.392-403.
- Bilim, Niyazi: “Türkiye’nin Elektrik Enerjisi Üretimindeki Dışa Bağımlılığın Azaltılması İçin Uygulanması Gereken Politikalar,” **Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi**, C:4, No:2, 2016, s.145-154.
- Bilişik, M.T.: “Destek Vektör Makinesi Çoklu Regresyon ve Doğrusal Olmayan Programlama ile Perakendecilik Sektöründe Gelir Yönetimi İçin Dinamik Fiyatlandırma,” **XI. Üretim Araştırmaları Sempozyumu**, 2011, s.785-799.
- Boran, F. E.: “Forecasting Natural Gas Consumption in Turkey Using Grey Prediction,” **Energy Sources, Part B: Economics, Planning, and Policy**, C:10, No:2, 2015, pp.208-213.
- Bozarth, C. C., Handfield, R. B., Weiss, H. J.: **Introduction to Operations and Supply Chain Management**, Upper Saddle River, NJ: Pearson Prentice Hall, 2013.
- BP: **Statistical Review of World Energy 71st Edition**, London, 2022, pp.1-60.

- Brabec, M., Konár, O., Pelikán, E., Malý, M.: "A Nonlinear Mixed Effects Model for The Prediction of Natural Gas Consumption by Individual Customers," **International Journal of Forecasting**, C:24, No:4, 2008, pp.659-678.
- Brzeziński, S.: "Natural Gas Transportation," **Advanced Logistic Systems**, C:1, No:1, 2007, pp.108-112.
- Camstra, F., Vinciarelli, A.: **Machine Learning for Audio, Image And Video Analysis: Theory and Applications**, London, Springer, 2015.
- Carbonell, J.G., Michalski, R.S., Mitchell, T.M.: "Machine Learning: A Historical and Methodological Analysis," **AI Magazine**, C:4, No:3, 1983, pp.69-69.
- Cardoso, C. A. V., Cruz, G. L.: "Forecasting Natural Gas Consumption Using ARIMA Models and Artificial Neural Networks," **IEEE Latin America Transactions**, C:14, No:5, 2016, pp.2233-2238.
- Chai, T., Draxler, R.: "Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)? –Arguments Against Avoiding RMSE in The Literature," **Geoscientific Model Development**, C:7, No:3, 2014, pp.1247-1250.
- Chapelle, O., Scholkopf, B., Zien, A.: **Semi-Supervised Learning**, MIT Press., 2009.
- Chen, Y., Chua, W. S., Koch, T.: "Forecasting Day-Ahead High-Resolution Natural-Gas Demand and Supply in Germany," **Applied Energy**, C:228, 2018, pp.1091-1110.
- Chopra, S., Meindl, P.: **Supply Chain Management Strategy, Planning, and Operation**, Pearson Prentice Hall, 2001.
- Ciulla, G., D'Amico, A.: "Building Energy Performance Forecasting: A Multiple Linear Regression Approach," **Applied Energy**, C:253, 2019, pp.1-16.
- Costa, O. L., de Oliveira Ribeiro, C., Ho, L. L., Rego, E. E., Parente, V., Toro, J.: "A Robust Least Square Approach for Forecasting Models: An Application to Brazil's Natural Gas Demand," **Energy Systems**, C:11, 2020, pp.1111-1135.

- De Jong, Cyriel: “Gas Storage Valuation and Optimization,” **Journal of Natural Gas Science and Engineering**, C:24, 2015, pp.365-378.
- De Myttenaere, A., Golden, B., Le Grand, B., Rossi, F.: “Mean Absolute Percentage Error for Regression Models,” **Neurocomputing**, C:192, 2016, pp.38-48.
- Demirel, Ö. F., Zaim, S., Çalışkan, A., Özuyar, P.: “Forecasting Natural Gas Consumption in Istanbul Using Neural Networks and Multivariate Time Series Methods,” **Turkish Journal of Electrical Engineering and Computer Sciences**, C:20, No:5, 2012, pp.695-711.
- Díaz, J. D., Hansen, E., Cabrera, G.: “A Random Walk Through the Trees: Forecasting Copper Prices Using Decision Learning Methods,” **Resources Policy**, C:69, 2020, pp.1-9.
- Ding, Song: “A Novel Self-Adapting Intelligent Grey Model for Forecasting China's Natural-Gas Demand,” **Energy**, C:162, 2018, pp.393-407.
- Dunlop, J. P., White, C. N.: “CNG Transport Technology is Delivering on Promises,” **SPE Annual Technical Conference and Exhibition**, 2003, pp.1-7.
- Economides, M. J., Sun, K., Subero, G.: “Compressed Natural Gas (CNG): An Alternative to Liquefied Natural Gas (LNG),” **SPE Production & Operations**, C:21, No:2, 2006, pp.318-324.
- Elragal, H. M.: “Improving Neural Networks Prediction Accuracy Using Particle Swarm Optimization Combiner,” **International Journal of Neural Systems**, C:19, No:5, 2009, pp.387-393.
- Ener, M., Ahmedov, O.: “Türkiye-Azerbaycan Petrol-Doğalgaz Boru Hattı Projelerinin Ülke Ekonomileri ve Avrupa Birliği Açısından Önemi,” **Girişimcilik ve Kalkınma Dergisi**, 2007, s.117-136.
- EPDK: “2010 Yılı Doğal Gaz Piyasası Sektör Raporu,” **Enerji Piyasası Düzenleme Kurumu**, 2010, s.1-100.
- EPDK: “2011 Yılı Doğal Gaz Piyasası Sektör Raporu,” **Enerji Piyasası Düzenleme Kurumu**, 2011, s.1-85.
- EPDK: “2016 Yılı Doğal Gaz Piyasası Sektör Raporu,” **Enerji Piyasası Düzenleme Kurumu**, 2016, s.1-173.

- EPDK: “2018 Yılı Doğal Gaz Piyasası Sektör Raporu,” **Enerji Piyasası Düzenleme Kurumu**, 2018, s.1-154.
- EPDK: “2022 Yılı Doğal Gaz Piyasası Sektör Raporu.” **Enerji Piyasası Düzenleme Kurumu**, 2022, s.1-170.
- Erdogdu, Erkan: “Natural Gas Demand in Turkey,” **Applied Energy**, C:87, No:1, 2010, pp.211-219.
- Erdoğan, S. M.: “Doğal Gazın Yeraltında Depolanmasının Modellenmesi ve Etkileyen Parametrelerin İncelenmesi (Doktora Tezi).” **İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü**, 2011.
- Ervural, B. C., Beyca, O. F., Zaim, S.: “Model Estimation of ARMA Using Genetic Algorithms: A Case Study of Forecasting Natural Gas Consumption,” **Procedia-Social and Behavioral Sciences**, C:235, 2016, pp.537-545.
- Es, H. A.: “Monthly Natural Gas Demand Forecasting by Adjusted Seasonal Grey Forecasting Model,” **Energy Sources, Part A: Recovery, Utilization, and Environmental Effects**, C:43, No:1, 2021, pp.54-69.
- Fagiani, M., Squartini, S., Gabrielli, L., Spinsante, S., Piazza, F.: “Domestic Water and Natural Gas Demand Forecasting by Using Heterogeneous Data: A Preliminary Study,” **Advances in Neural Networks: Computational and Theoretical Issues**, 2015, pp.185-194.
- Fan, G. F., Peng, L. L., Hong, W. C., Sun, F.: “Electric Load Forecasting by The SVR Model with Differential Empirical Mode Decomposition and Auto Regression,” **Neurocomputing**, C:173, 2016, pp.958-970.
- Fan, G. F., Wang, A., Hong, W. C.: “Combining Grey Model and Self-Adapting Intelligent Grey Model with Genetic Algorithm and Annual Share Changes in Natural Gas Demand Forecasting,” **Energies**, C:11, No:7, 2018, pp.1-21.
- Forouzanfar, M., Doustmohammadi, A., Menhaj, M. B., Hasanzadeh, S.: “Modeling And Estimation of The Natural Gas Consumption for Residential and Commercial Sectors in Iran,” **Applied Energy**, C:87, No:1, 2010, pp.268-274.
- Gardner Jr, E. S.: “Exponential Smoothing: The State of The Art—Part II,” **International Journal of Forecasting**, C:2 No:4, 2006, pp.637-666.

- Gareth, J., Daniela, W., Trevor, H., Robert, T.: **An Introduction to Statistical Learning: With Applications in R**, Springer, 2013.
- GEFC: “Global Gas Outlook 2022 Edition,” **Gas Exporting Countries Forum**, 2023, pp.1-91.
- Géron, Aurélien: **Hands-On Machine Learning with Scikit-Learn, Keras, And Tensorflow**, O'Reilly Media, Inc., 2019.
- Ghalekhondabi, I., Ardjmand, E., Weckman, G. R., Young, W. A.: “An Overview of Energy Demand Forecasting Methods Published in 2005–2015,” **Energy Systems**, C:8, 2017, pp.411-447.
- Gorucu, F. B.: “Artificial Neural Network Modeling for Forecasting Gas Consumption” **Energy Sources**, C:26, No:3, 2004, pp.299-307.
- Grønhaug, R., Christiansen, M.: “Supply Chain Optimization for The Liquefied Natural Gas Business,” **Innovations in Distribution Logistics**, Berlin: Springer, 2009, pp.195-218.
- Gültekin, A. H., Örgün, Y.: “Doğalgaz ve Çevre,” **Çevre Dergisi**, C:9, 1993, s.37-41.
- Gürol, Pınar: “Sürdürülebilir Tedarik Zinciri Yönetimi İçin Kavramsal Model Önerisi: Türkiye Doğal Gaz Sektörü Uygulaması (Doktora Tezi),” **Gazi Üniversitesi Fen Bilimleri Enstitüsü**, 2019.
- Hacisalihoglu, Bilge: “Turkey's Natural Gas Policy,” **Energy Policy**, C:36, No:6, 2008, pp.1867-1872.
- Hamed, M., Farahani, R. Z., Husseini, M. M., Esmailian, G. R.: “A Distribution Planning Model for Natural Gas Supply Chain: A Case Study,” **Energy Policy**, C:3 No:3, 2009, pp.799-812.
- Hastie, T., Tibshirani, R., Friedman, J.H.: **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**, Vol.2, New York, Springer, 2009.
- Heizer, J., Reder, B., Muson, C.: **Operations Management: Sustainability and Supply Chain Management**, Pearson Education, 2017.
- Hong, W. C.: “Hybrid Evolutionary Algorithms in An SVR-Based Electric Load Forecasting Model,” **International Journal**

Of Electrical Power & Energy Systems, C:31, No:7-8, 2009, pp.409-417.

Hussain, A., Memon, J. A., Murshed, M., Alam, M. S., Mehmood, U., Alam, M. N., Rahman M., Hayat, U.: "A Time Series Forecasting Analysis of Overall and Sector-Based Natural Gas Demand: A Developing South Asian Economy Case," **Environmental Science and Pollution Research**, C:29, No:47, 2022, pp.71676-71687.

IEA: "Turkey 2021 Energy Policy Review," **International Energy Agency**, 2021, pp.1-191.

IEA: "World Energy Outlook," **International Energy Agency**, 2022, pp.1-524.

Izadyar, N., Ong, H. C., Shamshirband, S., Ghadamian, H., Tong, C. W.: "Intelligent Forecasting of Residential Heating Demand for The District Heating System Based on The Monthly Overall Natural Gas Consumption," **Energy and Buildings**, C:104, 2015, pp.208-214.

James, G., Witten, D., Hastie, T., Tibshirani, R.: **An Introduction to Statistical Learning**, New York, Springer, 2013.

Jiang, T., Gradus, J. L., Rosellini, A. J.: "Supervised Machine Learning: A Brief Primer," **Behavior Therapy**, C:51, No:5, 2020, pp.675-687.

Jordan, M. I., Mitchell, T. M.: "Machine Learning: Trends, Perspectives, and Prospects," **Science**, C:349, No:6245, 2015, pp.255-260.

Karabiber, O. A., Xydis, G.: "Forecasting Day-Ahead Natural Gas Demand in Denmark," **Journal of Natural Gas Science and Engineering**, C:76, 2020, pp.1-25.

Karadede, Y., Ozdemir, G., Aydemir, E.: "Breeder Hybrid Algorithm Approach for Natural Gas Demand Forecasting Model," **Energy**, C:141, 2017, pp.1269-1284.

Karimi, H., Dastranj, J.: "Artificial Neural Network-Based Genetic Algorithm to Predict Natural Gas Consumption," **Energy Systems**, C:5, No:3, 2014, pp.571-581.

Kavaklioglu, Kadir: "Modeling and Prediction of Turkey's Electricity Consumption Using Support Vector Regression," **Applied Energy**, C:88, No:1, 2011, pp.368-375.

- Kavousi-Fard, A., Samet, H., Marzbani, F.: "A New Hybrid Modified Firefly Algorithm and Support Vector Regression Model for Accurate Short Term Load Forecasting," **Expert Systems with Applications**, C:41, No:13, 2014, pp.6047-6056.
- Kaynar, O., Yilmaz, I., Demirkoparan, F.: "Forecasting Of Natural Gas Consumption with Neural Network and Neuro Fuzzy System," **Energy Education Science and Technology Part A: Energy Science and Research**, C:26, No:2, 2011, pp.221-238.
- Khan, M. A.: "Modelling And Forecasting the Demand for Natural Gas in Pakistan," **Renewable and Sustainable Energy Reviews**, C:49, 2015, pp.1145-1159.
- Kızılaslan, R., Karlık, B.: "Combination of Neural Networks Forecasters for Monthly Natural Gas Consumption Prediction," **Neural Networks**, C:6, No:13, 2009, pp.1-6.
- Kiliç, A. M.: "Turkey's Natural Gas Necessity, Consumption and Future Perspectives," **Energy Policy**, C:34, No:14, 2006, pp.1928-1934.
- Kizilaslan, R., Karlik, B.: "Comparison Neural Networks Models for Short Term Forecasting of Natural Gas Consumption in Istanbul," **First International Conference on The Applications of Digital Information and Web Technologies (ICADIWT)**, 2008, pp. 448-453.
- Knepper, G. A., Cuthbert, J. F.: "Gas Storage Problems and Detection Methods." SPE Annual Technical Conference and Exhibition, 1979, pp.1-13.
- Krajewski, L. J., Ritzman, L. P., Malhotra, M. K.: **Operations Management: Processes and Supply Chains**, New Jersey, Pearson, 2010.
- Lai, K. K., Yu, L., Wang, S., Huang, W.: "Hybridizing Exponential Smoothing and Neural Network for Financial Time Series Predication," **In Computational Science-ICCS 2006: 6th International Conference**, 2006, pp. 493-500.
- Lee, I., Shin, Y. J.: "Machine Learning for Enterprises: Applications, Algorithm Selection, and Challenges," **Business Horizons**, C:63, No:2, 2020, pp.157-170.

- Lee, S., Seo, Y., Lee, J., Chang, D.: "Economic Evaluation of Pressurized LNG Supply Chain," **Journal of Natural Gas Science and Engineering**, C:33, 2016, pp.405-418.
- Liang, F. Y., Ryvak, M., Sayeed, S., Zhao, N.: "The Role of Natural Gas as A Primary Fuel in The Near Future, Including Comparisons of Acquisition, Transmission and Waste Handling Costs of as with Competitive Alternatives," **Chemistry Central Journal**, C:6, No:1, 2012, pp.1-24.
- Liaw, A., Wiener, M.: "Classification and Regression by Randomforest," **R News**, C:2, No:3, 2002, pp.18-22.
- Liu, G., Dong, X., Jiang, Q., Dong, C., Li, J.: "Natural Gas Consumption of Urban Households in China and Corresponding Influencing Factors," **Energy Policy**, C:122, 2018, pp.17-26.
- Liu, J., Wang, S., Wei, N., Chen, X., Xie, H., Wang, J.: "Natural Gas Consumption Forecasting: A Discussion on Forecasting History and Future Challenges," **Journal of Natural Gas Science and Engineering**, C:90, 2021, pp.1-20.
- Lu, H., Azimi, M., Iseley, T.: "Short-Term Load Forecasting of Urban Gas Using a Hybrid Model Based on Improved Fruit Fly Optimization Algorithm and Support Vector Machine," **Energy Reports**, C:5, 2019, pp.666-677.
- Mahesh, Batta: "Machine Learning Algorithms-A Review," **International Journal of Science and Research (IJSR)**, C:9, 2020, pp.381-386.
- Makridakis, S., Hibon, M.: "ARMA Models and The Box-Jenkins Methodology," **Journal of Forecasting**, C:16, No:3, 1997, pp.147-163.
- Makridakis, S., Hyndman, R. J., Petropoulos, F.: "Forecasting in Social Settings: The State of The Art," **International Journal of Forecasting**, C:36, No:1, 2020, pp.15-28.
- Marsland, Stephen: **Machine Learning: An Algorithmic Perspective**, CRC Press., 2015.
- Melikoglu, Mehmet: "Vision 2023: Forecasting Turkey's Natural Gas Demand Between 2013 and 2030," **Renewable and Sustainable Energy Reviews**, C:22, 2013, pp.393-400.

- Merey, Şükrü: "The Role of Natural Gas Hydrate During Natural Gas Transportation," **Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi**, C:7, No:2, 2018, pp.937-953.
- Mitchell, T. M.: **Machine Learning**, New York, Mcgraw-Hill., 1997.
- Mohri, M., Rostamizadeh, A., Talwalkar, A.: **Foundations of Machine Learning**, MIT Press, 2018.
- Mokhatab, S., Poe, W. A., Mak, J. Y.: **Handbook of Natural Gas Transmission and Processing: Principles and Practices**, Gulf Professional Publishing, 2018.
- Nahmias, S., Olsen, T. L.: **Production and Operations Analysis**, Waveland Press, 2015.
- Najibi, H., Rezaei, R., Javanmardi, J., Nasrifar, K., Moshfeghian, M.: "Economic Evaluation of Natural Gas Transportation from Iran's South-Pars Gas Field to Market," **Applied Thermal Engineering**, C:29, No:10, 2009, pp.2009-2015.
- Nilsson, N. J.: **Introduction to Machine Learning**, 1997.
- Ozdemir, G., Aydemir, E., Olgun, M. O., Mulbay, Z.: "Forecasting of Turkey Natural Gas Demand Using a Hybrid Algorithm," **Energy Sources, Part B: Economics, Planning, and Policy**, C:11, No:4, 2016, pp.295-302.
- Ozturk, H.K., Hepbasli, A.: "The Place of Natural Gas in Turkey's Energy Sources and Future Perspectives," **Energy Sources**, C:25, 2003, pp.293-307.
- Ozturk, H. K., Hepbasli, A.: "Natural Gas Implementation in Turkey. Part 1: Turkey's Natural Gas Demand and Supplies," **Energy Sources**, C:26, No:3, 2004, pp.277-286.
- Özmen, A., Yılmaz, Y., Weber, G. W.: "Natural Gas Consumption Forecast with MARS and CMARS Models for Residential Users," **Energy Economics**, C:70, 2018, pp.357-381.
- Öztürk, Selman: "Doğal Gazın Depolanması ve Türkiye İçin Önemi (Yüksek Lisans Tezi)," **Kocaeli Üniversitesi Fen Bilimleri Enstitüsü**, 2007.
- Panapakidis, I. P., Dagoumas, A. S.: "Day-Ahead Natural Gas Demand Forecasting Based on The Combination of Wavelet Transform and

- ANFIS/Genetic Algorithm/Neural Network Model,” **Energy**, C:118, 2017, pp.231-245.
- Potočnik, P., Šilc, J., Papa, G.: “A Comparison of Models for Forecasting the Residential Natural Gas Demand of an Urban Area,” **Energy**, C:167, 2019, pp.511-522.
- Potočnik, P., Soldo, B., Šimunović, G., Šarić, T., Jeromen, A., Govekar, E.: “Comparison of Static and Adaptive Models for Short-Term Residential Natural Gas Forecasting in Croatia,” **Applied Energy**, C:129, 2014, pp.94-103.
- Riahi, Y., Saikouk, T., Gunasekaran, A., Badraoui, I.: “Artificial Intelligence Applications In Supply Chain: A Descriptive Bibliometric Analysis and Future Research Directions,” **Expert Systems with Applications**, 173, 2021, pp.1-19.
- Sabo, K., Scitovski, R., Vazler, I., Zekić-Sušac, M.: “Mathematical Models of Natural Gas Consumption,” **Energy Conversion and Management**, C:52, No:3, 2011, pp.1721-1727.
- Sánchez-Úbeda, E. F., Berzosa, A.: “Modeling And Forecasting Industrial End-Use Natural Gas Consumption,” **Energy Economics**, C:29, No:4, 2007, pp.710-742.
- Scarpa, F., Bianco, V.: “Assessing The Quality of Natural Gas Consumption Forecasting: An Application to The Italian Residential Sector,” **Energies**, C:10, No:11, 2017, pp.1-13.
- Sen, D., Günay, M. E., Tunç, K. M.: “Forecasting Annual Natural Gas Consumption Using Socio-Economic Indicators for Making Future Policies,” **Energy**, C:173, 2019, pp.1106-1118.
- Shaikh, F., Ji, Q.: “Forecasting Natural Gas Demand in China: Logistic Modelling Analysis,” **International Journal of Electrical Power & Energy Systems**, C:77, 2016, pp.25-32.
- Shakouri G, H., Kazemi, A.: “Selection of the Best ARMAX Model for Forecasting Energy Demand: Case Study of The Residential and Commercial Sectors in Iran,” **Energy Efficiency**, C:9, 2016, pp.339-352
- Slack, N., Chambers, S., Johnston, R.: **Operations Management**, Pearson Education, 2007.
- Smola, A. J., Schölkopf, B.: “A Tutorial on Support Vector Regression,” **Statistics and Computing**, C:14, 2004, pp.199-222.

- Speight, J. G.: **Natural Gas: A Basic Handbook**, Gulf Professional Publishing, 2018.
- Stevenson, W. J.: **Operations Management**, Fifth Edition, USA, Times Mirror Higher Education Group, 1996.
- Subero, G., Sun, K., Deshpande, A., McLaughlin, J., Economides, M. J.: "A Comparative Study of Sea-Going Natural Gas Transport," **SPE Annual Technical Conference and Exhibition**, 2004, pp.1-7.
- Szoplik, J.: "Forecasting Of Natural Gas Consumption with Artificial Neural Networks," **Energy**, C:85, 2015, pp.208-220.
- Taheri, Z., Shabani, M. R., Nazari, K., Mehdizaheh, A.: "Natural Gas Transportation and Storage by Hydrate Technology: Iran Case Study," **Journal of Natural Gas Science and Engineering**, C:21, 2014, pp.846-849.
- Taşpınar, F., Celebi, N., Tutkun, N.: "Forecasting of Daily Natural Gas Consumption on Regional Basis in Turkey Using Various Computational Methods," **Energy and Buildings**, C:56, 2013, pp.23-31.
- Teatini, P., Castelletto, N., Ferronato, M., Gambolati, G., Janna, C., Cairo, E., Marzorati, D., Colombo B., Ferretti, A., Bagliani, A., Bottazzi, F.: "Geomechanical Response to Seasonal Gas Storage in Depleted Reservoirs: A Case Study in The Po River Basin, Italy," **Journal of Geophysical Research: Earth Surface**, C:116, 2011, pp.1-21.
- Thomas, S., Dawe, R. A.: "Review Of Ways to Transport Natural Gas Energy from Countries Which Do Not Need the Gas for Domestic Use," **Energy**, C:28, No:14, 2003, pp.1461-1477.
- Thompson, M., Davison, M., Rasmussen, H.: "Natural Gas Storage Valuation and Optimization: A Real Options Application," **Naval Research Logistics (NRL)**, C:56, No:3, 2009, pp.226-238.
- Toksari, Murat: "Predicting The Natural Gas Demand Based on Economic Indicators: Case of Turkey," **Energy Sources, Part A: Recovery, Utilization, and Environmental Effects**, C:32, No:6, 2010, pp.559-566.

- Tonković, Z., Zekić-Sušac, M., Somolanji, M.: “Predicting Natural Gas Consumption by Neural Networks,” **Tehnički Vjesnik**, C:16, No:3, 2009, pp.51-61.
- Tureyen, O. I., Karaalioglu, H., Satman, A.: “Effect of the Wellbore Conditions on the Performance of Underground Gas-Storage Reservoirs,” **SPE/CERI Gas Technology Symposium**, 2000, pp.1-12.
- Üster, H., Dilaveroğlu, Ş.: “Optimization For Design and Operation of Natural Gas Transmission Networks,” **Applied Energy**, C:133, 2014, pp.56-69.
- Vandeput, Nicolas: **Data Science for Supply Chain Forecasting**, De Gruyter, 2021.
- Wadud, Z., Dey, H. S., Kabir, M. A., Khan, S. I.: “Modeling and Forecasting Natural Gas Demand in Bangladesh,” **Energy Policy**, C:39, No:11, 2011, pp.7372-7380.
- Wang, D., Liu, Y., Wu, Z., Fu, H., Shi, Y., Guo, H.: “Scenario Analysis of Natural Gas Consumption in China Based on Wavelet Neural Network Optimized by Particle Swarm Optimization Algorithm,” **Energies**, C:11, No:4, 2018, pp.1-16.
- Wheelwright, S., Makridakis, S., Hyndman, R. J.: **Forecasting: Methods and Applications**, John Wiley & Sons, 1998.
- Wisner, J. D., Tan, K. C., Leong, G. K.: **Principles of Supply Chain Management: A Balanced Approach**, Cengage Learning, 2014.
- Xie, Y., Li, M.: “Research On Prediction Model of Natural Gas Consumption Based on Grey Modeling Optimized by Genetic Algorithm,” **IITA International Conference on Control, Automation and Systems Engineering**, 2009, pp. 335-337.
- Xu, G., Wang, W.: “Forecasting China's Natural Gas Consumption Based on A Combination Model,” **Journal of Natural Gas Chemistry**, C:19, No:5, 2010, pp.493-496.
- Yazici, N., Demirbas, A.: “Turkey’s Natural Gas Necessity and Turkey’s Natural Gas Consumption,” **Energy Sources**, C:23, 2001, pp.801–808.
- Yu, F., Xu, X.: “A Short-Term Load Forecasting Model of Natural Gas Based on Optimized Genetic Algorithm and Improved BP

Neural Network,” **Applied Energy**, C:134, 2014, pp.102-113.

Yukseltan, E., Yucekaya, A., Bilge, A. H., Aktunc, E. A.: “Forecasting Models for Daily Natural Gas Consumption Considering Periodic Variations and Demand Segregation,” **Socio-Economic Planning Sciences**, C:74, 2021, pp.1-12.

Zou, K. H., Tuncali, K., Silverman, S. G.: “Correlation and Simple Linear Regression,” **Radiology**, C:227, No:3, 2003, pp.617-628.

Çevrimiçi 1 <http://naturalgas.org/overview/history/>

(10.12.2022)

Çevrimiçi 2 http://bilsenbesergil.blogspot.com/p/3_5.html

(28.12.2022)

Çevrimiçi 3 <http://naturalgas.org/naturalgas/transport/>

(10.12.2022)

Çevrimiçi 4 <http://naturalgas.org/naturalgas/storage/>

(10.12.2022)

Çevrimiçi 5 <https://yearbook.enerdata.net/total-energy/world-consumption-statistics.html>

(03.02.2023)

Çevrimiçi 6 <https://www.petform.org.tr/dogal-gaz-piyasasi/turkiye-dogal-gaz-piyasasi/>

(16.01.2023)

Çevrimiçi 7 <https://www.botas.gov.tr/Sayfa/silivri-dogal-gaz-depolama/21>

(19.02.2023)

Çevrimiçi 8 <https://www.botas.gov.tr/Sayfa/tuz-golu-dogal-gaz-depolama/23>

(19.02.2023)

Çevrimiçi 9 <https://enerji.gov.tr/bilgi-merkezi-dogal-gaz-boru-hatlari>

(05.03.2023)

Çevrimiçi 10 <https://enerji.gov.tr/bilgi-merkezi-transit-boru-hatlari>

(05.03.2023)

Çevrimiçi 11 <https://www.tanap.com/tanap-projesi>

(05.03.2023)

Çevrimiçi 12 <https://turkstream.info/tr/project/>

(05.03.2023)