



SIVAS CUMHURİYET ÜNİVERSİTESİ

Sosyal Bilimler Enstitüsü

İşletme Ana Bilim Dalı

**TÜRKİYE ENERJİ SEKTÖRÜNÜN STRATEJİK KONUMU
VE YAPAY SİNİR AĞI MODELLERİYLE ENERJİ
TÜKETİMİNİN TAHMİNİ**

Doktora Tezi

Hatice GENÇ KAVAS

Sivas

Ekim 2019

SİVAS CUMHURİYET ÜNİVERSİTESİ

Sosyal Bilimler Enstitüsü

İşletme Ana Bilim Dalı

**TÜRKİYE ENERJİ SEKTÖRÜNÜN STRATEJİK KONUMU
VE YAPAY SİNİR AĞI MODELLERİYLE ENERJİ
TÜKETİMİNİN TAHMİNİ**

Doktora Tezi

Hatice GENÇ KAVAS

Tez Danışmanı


Prof. Dr. Hüdaverdi BİRCAN

Sivas

Ekim 2019

KABUL VE ONAY

Üniversite: : Sivas Cumhuriyet Üniversitesi
Enstitü : Sosyal Bilimler Enstitüsü
Ana Bilim Dalı : İşletme Ana Bilim Dalı
Tezin Başlığı : Türkiye Enerji Sektörünün Stratejik Konumu ve Yapay Sinir Ağı Modelleriyle Enerji Tüketiminin Tahmini
Savunma Tarihi : 20.09.2019
Danışmanı : Prof. Dr. Hüdaverdi BİRCAN

	Unvanı - Adı Soyadı	İmza
Jüri Başkanı	: Prof. Dr. Ahmet ŞENGÖNÜL	
Üye	: Prof. Dr. Hüdaverdi BİRCAN	
Üye	: Prof. Dr. Yalçın KARAGÖZ	
Üye	: Doç. Dr. Selahattin YAVUZ	
Üye	: Dr. Öğr. Üyesi Hasan SÖYLER	

Oy Birliği

Oy Çokluğu

Hatice GENÇ KAVAS tarafından hazırlanan "Türkiye Enerji Sektörünün Stratejik Konumu ve Yapay Sinir Ağı Modelleriyle Enerji Tüketiminin Tahmini" başlıklı tez, kabul edilmiştir.

.../.../.....

Prof. Dr. Ahmet ŞENGÖNÜL
Enstitü Müdürü

ETİK İLKELERE UYGUNLUK BEYANI

Sivas Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü bünyesinde hazırladığım bu Doktora tezinin bizzat tarafımdan ve kendi sözcüklerimle yazılmış orijinal bir çalışma olduğunu ve bu tezde;

1- Çeşitli yazarların çalışmalarından faydalandığımda bu çalışmaların ilgili bölümlerini doğru ve net biçimde göstererek yazarlara açık biçimde atıfta bulunduğumu;

2- Yazdığım metinlerin tamamı ya da sadece bir kısmı, daha önce herhangi bir yerde yayımlanmışsa bunu da açıkça ifade ederek gösterdiğimi;

3- Başkalarına ait alıntılanan tüm verileri (tablo, grafik, şekil vb. de dahil olmak üzere) atıflarla belirttiğimi;

4- Başka yazarların kendi kelimeleriyle alıntıladığım metinlerini, tırnak içerisinde veya farklı dizerek verdiğim yine başka yazarlara ait olup fakat kendi sözcüklerimle ifade ettiğim hususları da istisnasız olarak kaynak göstererek belirttiğimi, beyan ve bu etik ilkeleri ihlal etmiş olmam halinde bütün sonuçlarına katlanacağımı kabul ederim.

29/10/2019

Hatice GENÇ KAVAS

TEŞEKKÜR

Tez çalışmam esnasında bana yardımlarını ve desteklerini esirgemeyen, tezimi inceleyerek yol gösteren tez danışmanım Sayın Prof. Dr. Hüdaverdi BİRCAN, hocalarım Sayın Prof. Dr. Ahmet ŞENGÖNÜL ve Prof. Dr. Yalçın KARAGÖZ'e,

Çok yoğun bir döneminde hiç tanımadığı bir öğrenciye büyük bir özveriyle bilgisini aktarmaya çalışan ve keşke akademide heryerde hep varolsalar dediğim Sayın Doç. Dr. Fatma LATİFOĞLU'na ve Sayın Doç. Dr. Bekir YILDIRIM'a,

Metodoloji üzerinde çalışırken çok bunaldığım bir anda büyük desteğiyle ve tüm teknik bilgisiyle yanımda olan Sayın Abolfazl NEJATIAN'a,

Çalışmamda emeğini esirgemeyen Sayın Dr. Ahmet KOÇ'a ve yardımlarından dolayı Sayın Doç. Dr. Gürkan YÜKSEK'e çok teşekkür ederim.

Ayrıca, her ne kadar bilimsel bir çalışma yapıyor ve özellikle ülkemizin bir problemine çözüm aramaya çalışıyor olsak da, veri elde etme konusunda ne yazık ki bürokratik engelleri aşmada çok büyük sıkıntı yaşadım. Ancak bu süreçte özellikle iki kurum hiçbir zorluk çıkarmadan ivedilikle verileri tarafıma sağlamıştır. Bu nedenle Sayın Fırat KAYHAN nezdinde Türkiye Taşkömürü Kurumu'na ve Sayın Alp ALBOSTAN nezdinde Türkiye Elektrik İletim A.Ş.'ye teşekkür etmek istiyorum.

Ve son olarak geçirdiğim bu meşakkatli süreçte yaşadığım her sıkıntıya ortak olan, hiçbir desteğini benden esirgemeyen, sığındığım limanım biricik eşim Sayın Ferhat KAVAS'a, moral kaynaklarım olan oğullarım Muhammed Umut ve Semih Gökay'a çok ama çok teşekkür ediyorum. İyi ki varsınız.

Eşim ve
Oğullarıma...



İÇİNDEKİLER

İÇİNDEKİLER	i
KISALTMALAR	v
TABLO LİSTESİ	ix
ŞEKİL LİSTESİ	xiii
GİRİŞ	1
Literatür Taraması	3
BİRİNCİ BÖLÜM	17
1.ENERJİ KAYNAKLARI	17
1.1.Enerji Kaynakları Kavram Ve Kapsamı	17
1.1.1 Kömür	23
1.1.2 Petrol	26
1.1.3 Doğalgaz	30
1.1.4 Yenilenebilir Enerji Kaynakları	34
1.1.4.1 Hidrolik Enerji / Hidro-Elektrik Enerjisi	36
1.1.4.2 Rüzgâr Enerjisi	37
1.1.4.3 Güneş Enerjisi	40
1.1.4.4 Jeotermal Enerji	42
1.1.4.5 Biyokütle Enerjisi	44
1.1.5 Nükleer Enerji	47
1.2 Enerji İletim Hatları / Enerji Ticaret Akışı	54
1.2.1 Petrol Taşımacılığı ve Petrol Boru Hatları	54
1.2.2 Türkiye Petrol Boru Hatları	56
1.2.2.1 Irak - Türkiye Ham Petrol Boru Hattı / Kerkük – Yumurtalık Ham Petrol Boru Hattı	58
1.2.2.2 Bakü - Tiflis – Ceyhan (BTC) Ana İhraç Ham Petrol Boru Hattı	59
1.2.3 Doğalgaz Taşımacılığı ve Doğalgaz Boru Hatları	60
1.2.3.1 Rusya - Türkiye Doğalgaz Boru Hattı (Batı Hattı)	63
1.2.3.2 Mavi Akım Doğalgaz Boru Hattı	64
1.2.3.2.1 İran-Türkiye / Doğu Anadolu Doğal Gaz Ana İletim Hattı	65

1.2.3.3 Bakü -Tiflis-Erzurum Doğalgaz Boru Hattı (BTE).....	66
1.2.3.4 Türkiye-Yunanistan Doğal Gaz Enterkoneksiyonu (ITG).....	67
1.2.3.5 Trans – Anadolu Doğalgaz Boru Hattı Projesi (TANAP).....	68
1.2.3.6 TürkAkım Gaz Boru Hattı Projesi	69
İKİNCİ BÖLÜM	73
2.KÜRESEL ENERJİ SEKTÖRÜ AKTÖRLERİ VE TÜRKİYE.....	73
2.1 Küresel Enerji Üretimi Trendleri	73
2.1.1 Petrol Üreticileri, Tedarikçileri ve Alıcıları	75
2.1.1.1 Türkiye'nin Petrol Görünümü	80
2.1.2 Doğalgaz Üreticileri, Tedarikçileri ve Alıcıları	83
2.1.2.1 Türkiye'nin Doğalgaz Görünümü	89
2.1.3 Kömür Üreticileri, Tedarikçileri ve Alıcıları	93
2.1.3.1 Türkiye'nin Kömür Görünümü	101
2.1.4 Elektrik Üreticileri, Tedarikçileri ve Alıcıları.....	105
2.1.4.1 Türkiye'nin Elektrik Görünümü.....	110
ÜÇÜNCÜ BÖLÜM	119
3.YAPAY SINIR AĞLARI VE MODELLERİ	119
3.1 Yapay Sinir Ağları	119
3.1.1 Yapay Sinir Ağlarının Özellikleri	120
3.1.1.1 Doğrusal Olmayan Yapı.....	121
3.1.1.2 Örnekten Öğrenme	122
3.1.1.3 Paralellik.....	122
3.1.1.4 Yerel İşlem ve Esneklik	122
3.1.1.5 Gerçek Zamanlı İşlem	122
3.1.1.6 Genelleme Yeteneği	123
3.1.1.7 Uyarlanabilirlik	123
3.1.1.8 Sınırsız Sayıda Değişken ve Parametre.....	123
3.1.2 Yapay Sinir Ağlarının Kullanım Alanları	125
3.1.3 Yapay Sinir Ağının Yapısı	125
3.1.4 Yapay Sinir Ağı Modelleri.....	130
3.1.4.1 Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı.....	130
3.1.4.2 Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı	131

3.1.4.3 Tekrarlayan Yapay Sinir Ağı (Recurrent Neural Network).....	133
3.1.4.4 LSTM (Long- Short Term Memory/Uzun- Kısa Süreli Bellek) ve Bi-LSTM (Bidirectional Long Short Term Memory/Çift Yönlü Uzun-Kısa Süreli Bellek).....	135
3.1.5 Yapay Sinir Ağı Modellerinde Kullanılan Süreçler ve Algoritmalar	137
3.1.5.1 Verileri Normalleştirme Yöntemleri.....	137
3.1.5.1.1 Normalizasyon	138
3.1.5.1.2 Z-Skore Standardizasyonu	138
3.1.5.2 Feed Forward Öğrenme/Eğitim/Optimizasyon Algoritmaları	138
3.1.5.2.1 Lavenberg-Marquart (LM).....	139
3.1.5.2.2 Bayesian Regularization (BR).....	139
3.1.5.2.3 Scaled Conjugate Gradient (SCG)	140
3.1.5.2.4 Gradient Backpropagation with Fletcher-Reeves Restarts (CGF)	141
3.1.5.3 LSTM Optimizasyon Yöntemleri	141
3.1.5.3.1 Root mean square error probability (RMSprop).....	142
3.1.5.3.2 Adaptive Momentum Estimation (ADAM)	142
3.1.5.3.3 Stochastic Gradient Descent with Momentum (SGDM)	143
DÖRDÜNCÜ BÖLÜM	145
4.UYGULAMA VE BULGULAR	145
4.1 Yapay Sinir Ağları ile Enerji Kaynakları Talep Tahminleri.....	145
4.2 Talep Tahmini Modellerinin Oluşturulması	145
4.3 Araştırmanın Evreni ve Örneklemi	145
4.4 Çalışmanın Amacı.....	146
4.5 Çalışmanın Önemi.....	146
4.6 Çalışmanın Sınırlılıkları	147
4.7 Doğalgaz Tüketim Tahmini	147
4.7.1 Doğalgaz Tüketimi Bi-LSTM Yöntemi ADAM Optimizasyonu	149
4.7.2 Doğalgaz Tüketimi Bi-Lstm RMSprop Optimizasyonu	151
4.7.3 Doğalgaz Tüketimi Bi-Lstm SGDM Optimizasyonu	153
4.7.4 Doğalgaz Tüketimi FeedForward Br Optimizasyonu	154
4.7.5 Doğalgaz Tüketimi FeedForward LM Optimizasyonu	156

4.7.6 Doğalgaz Tüketimi FeedForward SCG Optimizasyonu	158
4.7.7 Doğalgaz Tüketimi FeedForward CGF Optimizasyonu	159
4.7.8 Doğalgaz Tüketim Tahmininde En İyi Performans Gösteren Optimizasyonların Kıyaslanması	161
4.8 Elektrik Tüketim Tahmini	165
4.8.1 Elektrik Tüketimi Bi-Lstm ADAM Optimizasyonu	168
4.8.2 Elektrik Tüketimi Bi-Lstm RMSprop Optimizasyonu	170
4.8.3 Elektrik Tüketimi Bi-Lstm SGDM Optimizasyonu	171
4.8.4 Elektrik Tüketimi FeedForward BR Optimizasyonu	173
4.8.5 Elektrik Tüketimi FeedForward LM Optimizasyonu	174
4.8.6 Elektrik Tüketimi FeedForward SCG Optimizasyonu	176
4.8.7 Elektrik Tüketimi FeedForward CGF Optimizasyonu	177
4.8.8 Elektrik Tüketim Tahmininde En İyi Performans Gösteren Optimizasyonların Kıyaslanması	179
SONUÇ	185
KAYNAKÇA	191
EKLER	207
ÖZGEÇMİŞ	229

KISALTMALAR

AB	: Avrupa Birliđi
ABD	: Amerika Birleşik Devletleri
ADAM	: Adaptive Momentum Estimation (Uyarlanabilir Momentum Tahmini)
AIOC	: Azerbaijan International Operating Company (Azerbaycan Uluslararası İşletmecilik Şirketi)
ANFIS	: Adaptive Neural-Fuzzy Inference Systems (Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi)
ARIMA	: Autoregressive integrated moving average
bcm	: Billion cubic meter (milyar metre küp)
Bi-LSTM	: Bidirectional Long Short-Term Memory (Çift Yönlü Uzun-Kısa Dönemli Bellek)
BOTAŞ	: Boru Hatları ile Petrol Taşıma Anonim Şirketi
BP	: British Petroleum
BR	: Bayesian regularization
BTC	: Bakü-Tiflis-Ceyhan
BTE	: Bakü-Tiflis-Erzurum
CGF	: Conjugate Gradient Backpropagation with Fletcher-Reeves Restarts
Corr	: Korelasyon
DEPA	: Public Gas Company SA
EDAM	: Ekonomi ve Dış Politika Araştırma Derneđi
EIA	: Energy Information Administration
ENTSO-e	: European Network of Transmission System Operators (Avrupa İletim Sistemi Operatörleri Ađı)
EPDK	: Enerji Piyasaları Denetleme Kurumu
ETKB	: Enerji ve Tabii Kaynaklar Bakanlığı
FSRU	: Depolama ve yeniden gazlaştırma terminali
GSMH	: Gayri safi milli hasıla
GSYİH	: Gayri safi yurtiçi hasıla
GW	: Giga Watt

GWh	: Giga Watt saat
HES	: Hidroelektrik Santrali
IEA	: International Energy Agency (Uluslararası Enerji Ajansı)
INOGATE	: Interstate Oil and Gas Transport to Europe (Avrupa'ya Devletlerarası Petrol ve Gaz Taşımacılığı Programı)
KWh	: Kilowatt saat
LM	: Lavenberg-Marquardt
LNG	: Liquefied Natural Gas (Sıvılaştırılmış Doğal Gaz)
LPG	: Liquefied Petroleum Gas (Sıvılaştırılmış Petrol Gazı)
LSTM	: Long Short Term Memory (Uzun Kısa Dönemli Bellek)
MLP	: Multi layer perceptron (Çok Katmanlı Algılayıcı)
MSE	: Mean squared error (Ortalama Karesel Hata)
Mt	: Milyon ton
Mtoe	: Million tons of oil equivalent (Milyon Tona Eşdeğer Petrol)
Mtpe	: Milyon ton petrol eşdeğeri
MW	: Mega watt
MWh	: Megawatt saat
OECD	: Organisation for Economic Co-operation and Development (Ekonomik İşbirliği ve Kalkınma Örgütü)
OPEC	: Organization of Petroleum Exporting Countries (Petrol İhraç Eden Ülkeler Örgütü)
REN21	: Renewable Energy Policy Network for the 21st Century
RMSprop	: Root mean square error propability (Karesel Ortalama Hata Olasılığı)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağı)
SARIMA	: Seasonal autoregressive integrated moving average (Mevsimsel Otoregresif Entegre Hareketli Ortalama)
SCG	: Scaled conjugate gradient (Ölçeklenmiş Konjüge Gradyan)
SGDM	: Stochastic gradient descent with momentum (Momentum ile Stokastik Dereceli Alçalma)
SOCAR	: State Oil Company of Azerbaijan Republic (Azerbaycan Cumhuriyeti Devlet Petrol Şirketi)

SRN	: Simple recurrent network (Basit Tekrarlayan Ağ)
SSCB	: Sovyet Sosyalist Cumhuriyeti Birliđi
TANAP	: Trans Anadolu Dođal Gaz Boru Hattı Projesi
TAP	: Trans Adriyatik Dođalgaz Boru Hattı Projesi
TFC	: Toplam enerji tüketim oranı
TKİ	: Türkiye Kömür İşletmeleri
TP	: Türkiye Petrolleri
TPAO	: Türkiye Petrolleri Anonim Ortaklığı
Tpes	: Total primary energy supply (Toplam Birincil Enerji Arzı)
Tpet	: Toplam birincil enerji talebi
TTK	: Türkiye Taşkömürü Kurumu
TÜFE	: Tüketici fiyatları endeksi
TÜSİAD	: Türk Sanayicileri ve İşadamları Derneđi
TWh	: Terawatt saat
UEA	: Uluslararası Enerji Ajansı
WEC	: World Energy Council (Dünya Enerji Konseyi)
WWEA	: World Wind Energy Association (Dünya Rüzgar Enerjisi Birliđi)
YSA	: Yapay Sinir Ađı



TABLO LİSTESİ

Tablo 1. Dünya Birincil Enerji Talebi (Milyon Ton Petrol Eşdeğeri - mtpe)	19
Tablo 2. Dünya Fosil Yakıt Kaynaklarının Tükenme Ömrü (Yıl)	20
Tablo 3. Kömür Rezerv Miktarı Bakımından Dünya Sıralaması (2016)	24
Tablo 4. 2016 Kanıtlanmış En Yüksek Petrol Rezervi Olan Ülkeler.....	28
Tablo 5. Kanıtlanmış En Yüksek Doğalgaz Rezervi Olan Ülkeler (2017)	33
Tablo 6. Nükleer Kaynaklı Elektrik Üretiminde Ülkeler ve Değerleri (2015).....	51
Tablo 7. Nükleer Kaynaklı Elektrik Üretiminde Ülkelere Ait Kurulu Kapasite (2015)	51
Tablo 8. Ülkelerin Toplam İç Elektrik Üretiminde Nükleer Yüzdesi (%).....	52
Tablo 9. 2016 Dünya Petrol Üreticileri (2016)	76
Tablo 10. 2015 Yılı Ülkelerin Günlük Petrol Üretim, Tüketim ve Tüketim Fazlası (Bin Varil)	77
Tablo 11. Petrol İhraç Eden Ülkeler (2015).....	79
Tablo 12. Petrol İthal Eden Ülkeler (2015).....	80
Tablo 13. Ülkeler Bazında Kuru Doğal Gaz* Üretim, Tüketim ve Tüketim Fazlası Miktarları (2015)	84
Tablo 14. Doğalgaz Üreten İlk 10 Ülke Sıralaması (2016).....	88
Tablo 15. Doğalgaz Net İhracatçısı İlk 10 Ülke (2016)	88
Tablo 16. Doğalgaz Net İthalatçısı İlk 10 Ülke (2016).....	89
Tablo 17. 2008-2017 Yılları Türkiye Doğal Gaz İthalat Miktarları (Milyon Sm ³)..	91
Tablo 18. 2008-2017 Yunanistan'a İhraç Edilen Doğalgaz Miktarı (Milyon cm ³)...	92
Tablo 19. Ülkeler Bazında Kömür Üretim, Tüketim ve Tüketim Fazlası Miktarları (2015)	94
Tablo 20. Kömür Üretiminde Dünya Sıralaması (2016).....	98
Tablo 21. Kömür İhraç Eden Ülke Sıralamaları (2016).....	100
Tablo 22. Kömür İthal Eden Ülke Sıralamaları (2016).....	100
Tablo 23. 2011-2015 Yılları Arasında Türkiye Kömür Madeni Üretim Verileri....	102
Tablo 24. Türkiye Taşkömürü Üretim, İthalat ve Tüketim Değerleri (Bin Ton)....	103
Tablo 25. Ülkeler Bazında Elektrik Üretim, Tüketim ve Tüketim Fazlası Miktarları (2015)	105
Tablo 28. Elektrik İhraç Eden Ülkeler (2015).....	109

Tablo 29. Elektrik İthal Eden Ülkeler (2015).....	110
Tablo 30. 2014-2017 Türkiye Elektrik Piyasası Genel Görünümü	111
Tablo 31. 2018 Yılı Ülkeler Bazında Elektrik Enerjisi İthalat ve İhracatı (MWh) .	117
Tablo 32. Geçmiş dönemler doğalgaz tüketim verileri (Milyon Sm ³)	148
Tablo 33. Doğalgaz Adam Optimizasyonu Modellerinin Parametre Sonuçları	150
Tablo 34. ADAM Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01.2019-04.2019/Milyon sm ³).....	150
Tablo 35. Doğalgaz RMSprop Optimizasyonu Modellerinin Parametre Sonuçları	151
Tablo 36. RMSprop Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01.2019-04.2019/Milyon sm ³).....	152
Tablo 37. Doğalgaz SGDM Optimizasyonu Modellerinin Parametre Sonuçları	153
Tablo 38. SGDM Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01.2019-04.2019/Milyon sm ³).....	153
Tablo 39. Doğalgaz BR Optimizasyonu Modellerinin Parametre Sonuçları	155
Tablo 40. BR Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01,2019-04,2019/Milyon sm ³).....	155
Tablo 41. Doğalgaz LM Optimizasyonu Modellerinin Parametre Sonuçları.....	156
Tablo 42. LM Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01.2019-04.2019/Milyon sm ³).....	157
Tablo 43. Doğalgaz SCG Optimizasyonu Modellerinin Parametre Sonuçları	158
Tablo 44. SCG Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01,2019-04,2019/Milyon sm ³).....	158
Tablo 45. Doğalgaz CGF Optimizasyonu Modellerinin Parametre Sonuçları	159
Tablo 46. CGF Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01,2019-04,2019/Milyon sm ³).....	160
Tablo 47. Doğalgaz Tüketim Tahmini En Yüksek Performans Gösteren Modellerinin Parametreleri.....	161
Tablo 48. Doğalgaz Tüketim Tahmini için En Yüksek Performans Gösteren Bi-LSTM Modelleri ve Gerçek Değer (01.2019-04.2019/Milyon cm ³).....	161
Tablo 49. Doğalgaz Tüketim Tahmini için En Yüksek Performans Gösteren Feed Forward Modelleri	162

Tablo 50. Doğalgaz Tüketim Tahmini RMSprop Optimizasyonu gelecek 60 aylık tahmin değerleri (Milyon sm ³)	164
Tablo 51. 2005-2008 Türkiye Elektrik Tüketim Verileri (Kwh)	165
Tablo 52. 2009-2013 Türkiye Elektrik Tüketim Verileri (Kwh)	166
Tablo 53. 2014-2018 Türkiye Elektrik Tüketim Verileri (Kwh)	166
Tablo 54. Elektrik ADAM Optimizasyonu Modellerinin Parametre Sonuçları.....	168
Tablo 55. ADAM Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh).....	169
Tablo 56. Elektrik RMSprop Optimizasyonu Modellerinin Parametre Sonuçları ..	170
Tablo 57. RMSprop Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh).....	170
Tablo 58. Elektrik SGDM Optimizasyonu Modellerinin Parametre Sonuçları	171
Tablo 59. SGDM Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh).....	172
Tablo 60. Elektrik BR Optimizasyonu Modellerinin Parametre Sonuçları.....	173
Tablo 61. BR Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh)	173
Tablo 62. Elektrik LM Optimizasyonu Modellerinin Parametre Sonuçları	174
Tablo 63. LM Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh)	175
Tablo 64. Elektrik SCG Optimizasyonu Modellerinin Parametre Sonuçları	176
Tablo 65. SCG Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh).....	176
Tablo 66. Elektrik CGF Optimizasyonu Modellerinin Parametre Sonuçları	177
Tablo 67. CGF Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh).....	178
Tablo 68. Elektrik Tüketim Tahmini En Yüksek Performans Gösteren Modellerinin Parametreleri.....	179
Tablo 69. Elektrik Tüketim Tahmini için En Yüksek Performans Gösteren Bi-LSTM Modelleri ve Gerçek Değer (12.2018-04.2019/Kwh)	180
Tablo 70. Elektrik Tüketim Tahmini için En Yüksek Performans Gösteren Feed Forward Modelleri ve Gerçek Değer (12.2018-04.2019/Kwh).....	180

Tablo 71. Elektrik Tüketim Tahmini RMSprop Optimizasyonu gelecek 60 aylık tahmin değerleri (Kwh)..... 182



ŞEKİL LİSTESİ

Şekil 1. Enerji Kaynakları.....	18
Şekil 2. 1973 Kaynaklarına Göre Dünya Enerji Arz Oranları	20
Şekil 3. 2015 Kaynaklarına Göre Dünya Enerji Arz Oranları	21
Şekil 4. 1973 Kaynaklarına Göre Dünya Toplam Enerji Tüketim Oranları	22
Şekil 5. 2015 Kaynaklarına Göre Dünya Toplam Enerji Tüketim Oranları	22
Şekil 6. Bölgelere Göre 1971'den 2016'ya Kadar Dünya Kömür** Üretimi (Mt)	25
Şekil 7. 1973 yılı Dünya Bölgesel Kömür** Üretimi Oranları	25
Şekil 8. 2016 yılı Dünya Bölgesel Kömür** Üretimi Oranları	26
Şekil 9. 2015 Yılı Bölgelere Göre Dünya İspatlanmış Petrol Rezervi Dağılımı (Birim: Milyar Varil)	27
Şekil 10. İspatlanmış Petrol Rezervlerinin 1996, 2006, 2016 Bölgesel Dağılımı	29
Şekil 11. 1973 Bölgelere Göre Dünya Doğalgaz Üretimi	32
Şekil 12. 2016 Bölgelere Göre Dünya Doğalgaz Üretimi	32
Şekil 13. 1996, 2006, 2016 İspatlanmış Doğalgaz Rezerv Dağılımı	34
Şekil 14. 2015 Yılı Dünya Toplam Birincil Enerji Arzının Kaynaklarına Göre Dağılımı	35
Şekil 15. 2015 Dünya Yenilenebilir Enerji Arzının Kaynaklara Göre Dağılımı.....	36
Şekil 16. 2015 Dünya Hidroelektrik Enerji Arzının Bölgesel Paylaşımları	37
Şekil 17. Dünya Toplam Kurulu Güç Miktarı (2012-2016/MW).....	39
Şekil 18. 2016 Dünya Bölgelere Göre Güneş Enerjisi Kurulu Gücü (227 GW).....	41
Şekil 19. Yıllar Bazında Dünya Toplam Güneş Pilleri Kapasite ve Yıllık Artışlar, 2006-2016	42
Şekil 20. 2016 Yılı Jeotermal Kurulu Kapasitede İlk 10 Ülke	44
Şekil 21. Yıllar Bazında Bölgelere Göre Küresel Biyo-Enerji Üretimi.....	46
Şekil 22. Bölgelere Göre Dünya Nükleer Elektrik Üretimi 1971-2015.....	49
Şekil 23. 1973 Yılı Dünya Nükleer Elektrik Üretimi	49
Şekil 24. 2015 Yılı Dünya Nükleer Elektrik Üretimi	50
Şekil 25. Yıllar Bazında Dünya Toplam Nükleer Enerji Tüketimi	53
Şekil 26. Dünya Petrol Ana Ticaret Akışı	56
Şekil 27. Türkiye Petrol Boru Hatları Haritası	57
Şekil 28. Türkiye Petrol Boru Hatları Projeleri	58

Şekil 29. 2017 Küresel Doğalgaz Ticareti Haritası (Mm ³)	61
Şekil 30. Türkiye Doğalgaz Boru Hatları Haritası.....	63
Şekil 31. Güney Kafkasya Doğal Gaz Boru Hattı (BTE)	67
Şekil 32. TANAP - TAP Doğalgaz Boru Hatları.....	69
Şekil 33. TürkAkım Doğalgaz Boru Hattı Projesi	71
Şekil 34. Küresel Enerji Üretimine Kaynaklarına Göre Yıllık Ortalama Değişimi .	74
Şekil 35. Dünya Fosil Yakıt Üretiminde Yıllık Ortalama Değişim.....	75
Şekil 36. 2007 2016 Yılları Arası Türkiye Yerli Petrol Üretimi ve Petrol İthalatı (Bin Varil/Gün)	81
Şekil 37. Türkiye'nin 2006 2017 Yılları Arasındaki Petrol Tüketimi (Bin Varil/ Gün)	82
Şekil 38. Türkiye'nin 2008 2017 Dönemlerine Ait Doğalgaz Verileri Kıyaslaması (Milyon Sm ³).....	90
Şekil 39. 1965-2015 Yılları Arası TTK ve Özel Sektör Kömür Üretimi (Ton).....	103
Şekil 40. 1970-2013 Türkiye Linyit Üretimi (Ton)	104
Şekil 41. Yıllar Bazında Türkiye Elektrik Talebinde Gerçekleşen Değişim	112
Şekil 42. 2017 Yılı Türkiye Elektrik Üretimine Kaynaklara Göre Dağılımı (%) ..	113
Şekil 43. Yıllara Göre Elektrik Üretimine Kaynak Bazında Değişimi.....	114
Şekil 44. 2017 Yılı Aylar Bazında Türkiye Elektrik İthalatı	115
Şekil 45. 2017 Yılı Aylar Bazında Türkiye Elektrik İhracatı (MWh)	115
Şekil 46. 2005-2018 Yıllık Türkiye Elektrik İthalat ve İhracatı (kwh)	116
Şekil 47. 2005-2018 Aylık Türkiye Elektrik İthalat ve İhracatı (KWh).....	116
Şekil 48. Sinir Hücresi	119
Şekil 49. Basit Bir Yapay Sinir	126
Şekil 50. Basit Bir Yapay Sinir Ağı.....	127
Şekil 51. Yapay Sinir Ağının Genel Yapısı	128
Şekil 52. Sıklıkla Kullanılan Transfer Fonksiyonları	130
Şekil 53. İleri Beslemeli Tek Katmanlı Sinir Ağı.....	131
Şekil 54. Bir Gizli Katmanlı ve Bir Çıktı Katmanı Bulunan Tam Bağlantılı İleri Beslemeli Ağ.....	132
Şekil 55. Kendi Kendine Geri Bildirim Döngülerinin Olmadığı Ve Gizli Bir Nöronun Bulunmadığı Tekrarlayan Sinir Ağı.....	134

Şekil 56. Gizli Katmanlı Tekrarlayan Sinir Ağı	134
Şekil 57. Basit bir Tekrarlayan Ağ (SRN) birimi (solda) ve tekrarlayan bir sinir ağının gizli katmanlarında kullanılan bir Lstm mimarisinin (sağ) ayrıntılı şeması.....	136
Şekil 58. Üçlü çift yönlü LSTM (Bi-LSTM) mimarisi.....	137
Şekil 59. Doğalgaz ADAM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	151
Şekil 60. Doğalgaz RMSprop optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	152
Şekil 61. Doğalgaz SGDM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	154
Şekil 62. Doğalgaz BR optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	156
Şekil 63. Doğalgaz LM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	157
Şekil 64. Doğalgaz SCG optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	159
Şekil 65. Doğalgaz CGF optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	160
Şekil 66. Doğalgaz Tüketim Tahmini En Yüksek Performans Gösteren Modellerin gelecek tahmin değerleri ve gerçek değerler	162
Şekil 67. Doğalgaz Tüketim Tahmini RMSprop sonuçları I.....	163
Şekil 68. Doğalgaz Tüketim Tahmini RMSprop sonuçları II.....	163
Şekil 69. RMSprop ile elde edilen doğalgaz tüketim çizelgesi (2012-2023)	165
Şekil 70. Elektrik ADAM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	169
Şekil 71. Elektrik RMSprop optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	171
Şekil 72. Elektrik SGDM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	172
Şekil 73. Elektrik BR optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	174

Şekil 74. Elektrik LM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	175
Şekil 75. Elektrik SCG optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	177
Şekil 76. Elektrik CGF optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler.....	178
Şekil 77. Elektrik Tüketim Tahmini En Yüksek Performans Gösteren Modellerin gelecek tahmin değerleri ve gerçek değerler	180
Şekil 78. Elektrik Tüketim Tahmini RMSprop sonuçları I.....	181
Şekil 79. Elektrik Tüketim Tahmini RMSprop sonuçları II	181
Şekil 80. RMSprop ile elde edilen elektrik tüketim çizelgesi (2005-2023).....	183
Şekil 81. BR ile elde edilen elektrik tüketim çizelgesi (2005-2023)	183

ÖZET

Küresel ölçekte enerji kaynağının arz ve talebi ülkeler için güncel bir sorun teşkil etmektedir. Bu sorunun nedeni gelişmiş ve gelişmekte olan ülkeler için ekonomik sürdürülebilirliğin enerji arz güvenliği ile paralel bir seyir izlemesindedir. Enerji talebi ise enerji arz güvenliğinin başlangıcı olarak karşımıza çıkmaktadır. Bu nedenle enerji tüketiminin tahmini ve dolayısıyla yönetimi mikro ve makro düzeyde büyük bir öneme sahiptir.

Gelişmişlik seviyesini tamamlamamış bir ülke olan Türkiye'nin geçmiş verileri de dikkate alındığında enerji tüketimi gittikçe artmaktadır. Fakat enerji üretiminde kaynaklarının sınırlı olması nedeniyle tükettiğini karşılayamayan ve çok büyük bir oranda dışa bağımlı olan bir ülkedir. Bu dezavantajının yanı sıra, Türkiye'nin enerji tedarikçileri ile enerji tüketicileri arasında bulunması ülkeye jeostratejik bir konum kazandırmaktadır. Ayrıca son zamanlarda yapılan çalışmalarla ortaya çıkan Akdeniz Havzası'nın enerji zenginliği de dikkate alındığında Türkiye'nin tahmin edilen rezerv miktarı ile enerji problemi çözümlenebilecek ve Türkiye enerji pazarında söz sahibi olabilecektir.

Bu bağlamda bu tezin amacı, küresel olarak enerji sektörünün seyrini ele almak, enerji tedarikçileri ile enerji alıcılarının bulunduğu pazarı gözlemleyebilmek, Türkiye'nin cari açığının en önemli kalemlerinden olan doğalgaz ve elektrik enerjisinin tüketim talebini tahmin etmek, tahmin değerleri üzerinden Türkiye'nin enerji görünümünü ele almak ve tahminlemede kullanılan yapay sinir ağları olan feed forward ve bi-lstm mimarileri ve optimizasyon yöntemlerini karşılaştırarak en doğru sonuca ulaşmaya çalışmaktır. Ayrıca literatürde sıklıkla kullanılan tek yönlü ileri beslemeli feed forward mimarisi ile bidirectional-long short term memory (bi-lstm) mimarisine ait öğrenme algoritmalarının hangisinin en iyi performans göstereceği belirlenmeye ve veri seti uzunluğunun model tercih etmede etkin olup olmadığı gözlemlenmeye çalışılmıştır.

Çalışmada karşılaşılan en büyük problem veri toplama sürecinde yaşanmıştır. Kurumların veri işleme departmanları ile direk iletişime geçilmiş ve eş zamanlı olarak benzer kurumların yayınladığı raporlardan faydalanılarak veriler elde edilmeye çalışılmıştır. Bu kurumlara ek olarak TÜİK verileri kontrol edilmiş ve

kurumlararası veri uyumsuzlukları tespit edilmiştir. Bu nedenle doğalgaz kaleminde veriler, Enerji Piyasası Denetleme Kurumu (EPDK) Doğalgaz departmanından; elektrik kaleminde ise veriler, Türkiye Elektrik İletim A.Ş'den (TEİAŞ) elde edilmiştir. Doğalgaz mimarisinde eğitim için kullanılan veri aralığı 2012 Ocak / 2018 Aralık olmak üzere 84 aydır. Elektrik tüketimi verileri ise 2005 Ocak / 2018 Kasım olmak üzere 167 aydır. Oluşturulan tahmin modelleri ile karşılaştırılmak üzere mimarilere eklenmeyen gerçek veriler ise doğalgaz da 2019 Ocak/Nisan olmak üzere 4 aylık, elektrikte ise 2018 Aralık- 2019 Ocak/Nisan olmak üzere 5 aylık verilerdir.

Doğalgaz tüketimine ait veriler kurumlardan elde edilmeye çalışırken geçmiş dönem verilerin tam tutulmadığı saptanmış, 2009'dan itibaren EPDK'nın verileri toplaması nedeniyle kurumlar arası veri transferinin gerçekleşmediği bilgisi alınmış ve en çok geri giden veri setinin ithalat verileri olması nedeniyle tüketim değerleri olarak ithalat değerleri çalışmaya dahil edilmiştir. Özellikle doğalgazda dışa çok yüksek oranda bağımlı olan Türkiye'nin doğalgaz üretiminin çok düşük kalmasından ve oranda çok etkili olmamasından dolayı ithalat verileri iç tüketim verisi olarak ele alınmıştır.

Yapay sinir ağları (YSA) mimarisinde kullanılan birçok algoritma olmasına rağmen çalışmada ele alınan algoritmalar feed forward için levenberg-marquardt (LM), bayesian regularization (BR), scaled conjugate gradient (SCG) ve conjugate gradient backpropagation with Fletcher-Reeves restarts (CGF) iken LSTM mimarisi için adaptive momentum estimation (ADAM), root mean square error probability (RMSprop) ve stochastic gradient descent with momentumdur (SGDM). Mimarileri elde etmek için MATLAB 2019a programı kullanılmıştır. Aynı zamanda feed forward ve bi-lstm mimarilerinin birlikte yer aldığı yeni bir kod yazılarak YSA eğitimleri gerçekleştirilmiştir.

Eğitimlerde en yüksek performansı elde edebilmek amacıyla her bir algoritma için farklı katman, farklı ünite, farklı nöron sayıları denenmiştir. Ayrıca %75 ve %80 eğitim oran, normalizasyon ve standardizasyon yöntemleri her bir süreç için kullanılmıştır. Doğalgaz tüketim tahmininde gerçekleştirilen toplam eğitim sayısı 1856, elektrik tüketim tahmininde gerçekleştirilen toplam eğitim sayısı ise 1773'tür. Gerçekleştirilen bu eğitimler sonucunda; doğalgaz tüketim veri seti uzunluğunun

elektrik tüketim veri seti uzunluğunun yarısı kadar olmasına rağmen her iki modelde de en yüksek performans bi-LSTM mimarisinde RMSProp optimizasyonu ile elde edilmiştir.

Doğalgaz tüketim tahmininde 84 veri ile oluşturulan mimaride gelecek dönemler için elde edilen tahminlerde 12-20 ay aralığının daha tutarlı olduğu ve modelin uzak gelecek için performansının zayıfladığı gözlemlenmiştir. Elektrik tüketim tahmininde ise 167 veri ile oluşturulan mimaride gelecek dönemler için elde edilen tahminlerde özellikle 24-30 aylık bir tutarlılık söz konusudur. Veri setinin artması ise tutarlılık zaman aralığını da artırmaktadır.

Anahtar Kelimeler: Küresel Enerji Sektörü, Yapay Sinir Ağları, Optimizasyon, Feed Forward, Bİ- LSTM



ABSTRACT

Supply and demand of the energy source on a global scale is an issue that is constantly encountered as a current problem. Economic sustainability for developed and developing countries is in parallel with security of energy supply. Energy demand is the beginning of security of the energy supply. Therefore, the estimation and the management of energy consumption is of great importance at the micro and macro levels.

Turkey is a developing country views, therefore, as it is supported by historical data, the energy consumption is increasing. However, due to being a poor country in energy production, it cannot afford to consume and is highly dependent on the outside. With this disadvantage, being physically located between energy suppliers and energy consumers gives the country a geo-strategic position. In addition, the energy wealth of the Mediterranean Basin has been widely discussed recently and Turkey can resolve the energy problems with reserves estimated amount and will have a say in the energy market.

The aim of this thesis globally to trace the path of the energy sector and to observe the market that energy suppliers and energy demandants come together, to estimate the demand of Turkey's natural gas and electricity consumption which is the most important item of the current account deficit, to review predicted values by addressing the energy outlook in Turkey and to compare the feed forward and bidirectional-long short term memory (bi-lstm) architectures and optimization methods which are artificial neural networks used in estimation and try to reach the most accurate results.

The biggest problem encountered in the study was the data collection process. I talked with the data processing departments of the institutions and tried to obtain data from the reports issued by the same and similar institutions. In addition to these institutions, TURKSTAT data was checked and inter-institutional data conflicts were observed. Therefore, natural gas data is obtained from Natural Gas department of Energy Market Regulatory Authority (EMRA); The electrical data is obtained from Turkey Electricity Transmission Company (TETC). The data range used for training in natural gas architecture is 84 months, from January 2012 to December 2018 and

electricity consumption data is 167 months, from January 2005 to November 2018. The actual data that are not added to the architectures to be compared with the forecast models are 4 months data for natural gas in January/April 2019 and 5 months data for electricity in 2018 December-2019 January / April.

While trying to obtain natural gas consumption data from institutions, it was informed that past data were not kept fully, and since 2009, due to EMRA has collected data no inter-institutional data transfer has taken place. So the most backward data set is import data, import values were included as consumption values in the study. Especially as Turkey very highly dependent on foreign gas and natural gas production thought to be effective as the ratio is very low, therefore the import data are handled as domestic consumption. Turkey natural gas is dependent on the outside particularly in a high rate of gas production and is thought to be effective because of the ratio is very low so imports data are addressed as domestic consumption.

Although there are many algorithms used in artificial neural network (ANN) architecture, the algorithms discussed in the study are levenberg-marquardt (LM), bayesian regularization (BR), scaled conjugate gradient (SCG) and conjugate gradient backpropagation with Fletcher-Reeves restarts (CGF) for feed forward. And also discussed adaptive momentum estimation (ADAM), root mean square error probability (RMSprop) and stochastic gradient descent with momentum (SGDM) for bidirectional-long short term memory. MATLAB 2019a program was used to obtain the architectures. At the same time, a new code including feed forward and bi-lstm architectures was written and ANN trainings were conducted.

In order to achieve the highest performance in the trainings, different layers, different units and different neuron numbers were tested for each algorithms. Furthermore, 75% and 80% training ratio, normalization and standardization methods were used for each process. The total number of trainings in natural gas consumption estimation is 1856 and the total number of trainings in electricity consumption estimation is 1773. As a result of these trainings; though the length of the natural gas consumption data set is half the length of the electricity consumption

data set, the highest performance in both models was achieved by RMSProp optimization in the bi-lstm architecture.

It was observed that the performance of the model for the distant future is weakened so it was decided that 12-20 months interval was more consistent in the forecasts obtained for the future periods in the architecture, which was formed with 84 data in the natural gas consumption forecast. In the electricity consumption estimation, there is a consistency of 24-30 months especially in the estimations obtained for the future periods in the architecture which is formed with 167 data. So that it also can be said increasing the data set increases the consistency interval.

Keywords: Global Energy Sector, Artificial neural networks, Optimization, Feed Forward, BI-LSTM



GİRİŞ

Belli bir durumu yönetmek için planlama ve kontrol hayati önem taşıyan aşamalardır. Bu aşamalarda ise fırsatları kaçırmamak, oluşabilecek fırsatları değerlendirmek ya da yüksek maliyetlere neden olabilecek hataları önleyebilmek için tahmin/öngörüler ön plana çıkmaktadırlar.

İşletmeler geçmiş durumlarından ya da pazarlama araştırmalarıyla piyasa talebinin özelliklerini ve miktarını ölçerek bu talebi karşılayacak bir üretim sistemi kurarlar. Veri elde etmenin zorluğu ve doğru bilgilerin/verilerin getireceği avantajlar ve performansın yüksekliği bu hayati durumu iyi yönetmede anahtar rol oynamaktadır. Tahmin etmede kullanılacak birçok yöntem mevcuttur. Tahmin işlemi; geçmiş faaliyetlerin seyrine göre projeksiyon metodu kullanılarak yapılabileceği gibi, gelecek dönemleri etkileyen temel değişkenler için geliştirilen denklemler aracılığıyla da yapılabilir (Tekin 2012: 261). Bu yöntemler arasında hem hataları minimize edebilecek hem de yüksek performansı sağlayabilecek kapasiteye sahip olan yöntemlerden birisi makine öğrenmesidir (machine learning).

Mevcut öğrenme sistemleri tarafından elde edilen performansı etkileyebilecek çeşitli yönler olmasına rağmen, makine öğrenmesi deneyimlerini çalışarak performansı otomatik olarak artıran bilgisayar sistemleri geliştirmeyi amaçlamaktadır. Özel öğrenme program biçimleri bugün mevcut olsa da, nihai amaç daha güçlü öğrenme yeteneklerine sahip daha geniş çapta uygulanabilir sistemler geliştirmektir (Batista 2004: 20; Mitchell 1990: 417).

Bu bağlamda yapay sinir ağları tahminleme modellerinde sıklıkla tercih edilen ve çalışmalarla da desteklendiği gibi yüksek performans gösteren bir metod olarak karşımıza çıkmaktadır. Yapay sinir ağlarının kullanıldığı farklı modeller de mevcuttur. Bu modellerle elde edilecek tahmin değerler sonucunda yönetsel kararlar alınabilmektedir. Gelecekte oluşabilecek durum üzerine stratejiler geliştirilerek ilgili pazarda konum elde edilebilmekte ve maliyet kontrolü sağlanabilmektedir.

Yapay sinir ağ modelleri ile tahmin metodu enerji alanında da kullanılmaktadır. Enerji sektörü hareketli bir yapıya sahip olduğundan ve enerji

kaynağının hem mikro hem de makro düzeyde en önemli girdi elemanlarından biri olması nedeniyle yönetsel açıdan üst düzey dikkatle kontrol edilmelidir. Dikkat edilmesi gereken hususlar geçmişte enerjinin ne kadar kullanıldığı olduğu gibi gelecekte de muhtemel hangi düzeyde kullanılacağıdır. Geleceğe dair elde edilen olasılığı en yüksek tüketim miktarları planlama ve kontrol aşamalarında gerekli olan hayati bilgilerdir. Bu işletmeler açısından olduğu kadar ülkeler açısından da aynı derecede öneme sahip bir konu olarak karşımıza çıkabilmektedir.

Küresel olarak enerji tüketimi her yıl daha da artmaktadır ve Türkiye'nin enerji kullanım hacminin artan bir artan bir seyir izlemesi dışa bağımlılığı da beraberinde getirmektedir. Ülkenin ekonomisinin cari açığının çok önemli bir kısmının ana kaynağı enerjidir. Özellikle doğalgaz ve petrol bu payda en önemli kalemlerdendir. Gelişmekte olan bir ülke konumundaki Türkiye'de enerji bağımlılığı bu zamana kadar artan bir trendle devam etmiştir. Enerji arz edenlerle enerji talep edenler arasındaki köprü olması nedeniyle enerji konusunda stratejik bir öneme sahip olmakla beraber kendi kendine yeterliliği söz konusu değildir. Bu aşamada enerji için gelecek projeksiyonlarını, planlamasının önemini bir kez daha göstermektedir.

Böyle bir önem söz konusu iken ortaya çıkan soru ise projeksiyonların güvenilirliği ve doğruluğudur. Bu noktada tahmin metodları olarak geliştirilen bir çok analiz mevcuttur ancak en doğruya yaklaşma sorunu mevcuttur. Yapılan çalışmalarda birçok analiz kullanılmıştır ve YSA bu analizlerden birisidir. Karşılaştırmalı çalışmalarda çok büyük oranda YSA daha iyi bir performans göstermektedir. Ancak hangi YSA modelinin kullanılması daha yüksek doğruluk payı sağlayabilir konusu gündeme gelmektedir. Mikro ve makro önemi bu kadar büyük olan enerji alanında bu soruya cevap aranmasının fayda sağlayacağı düşünülmektedir. Böyle bir çalışma sonucu elde edilen verilerin etkin enerji yönetimi konusuna ışık tutabileceği öngörülmektedir.

Tezin birinci bölümünde enerji kaynaklarının kapsamı ile küresel enerji ve Türkiye enerji görünümü ele alınmıştır. Enerji yenilenemeyen ve yenilenebilir enerji kaynaklarından elde edilmektedir. Küresel ölçekte enerji tüketimi yıllar bazında artış göstermektedir bu nedenle enerji arzı da artan bir seyre sahiptir. Yoğunlukla Rusya Federasyonu ve Orta Doğu bölgesi enerji akışını tüm dünyaya sağlamaktadır.

Bununla beraber Avrupa alıcı konumunda görünmektedir. Amerika ve Çin enerji üretimi bakımından ilk sıralarda yer alsalar da tüketim oranı da çok yüksek olduğundan tedarikçi görünümü sergilememektedir. Türkiye ise yenilenebilir enerji üretimi konusunda son yıllarda ilerleme kaydetmiş olsa da enerji tüketimi her geçen yıl artış gösterdiğinden enerji konusunda kendi kendine yetemeyen bir görünüme sahiptir. Bu nedenle dışa bağımlılığı devam etmektedir.

Çalışmanın ikinci bölümde küresel enerji sektörünün aktörleri ile Türkiye'nin konumu ele alınmıştır. Enerji kaynakları bakımından üretici ve tüketici ülkeler bölüm içerisinde anlatılmaktadır. Türkiye'nin enerji arz edenlerle enerji talep edenler arasındaki konumu verilerle desteklenmektedir.

Üçüncü bölümde yapay sinir ağlarının yapısı ve modelleri anlatılmıştır. Yapay sinir ağlarının genel yapısı, yapay sinir ağı modelleri ve uygulamada kullanılacak olan yöntemler ile bu yöntemlere ait algoritmalar ele alınmıştır. Feed forward yöntemi ile bi-LSTM yöntemi ve bu yöntemlere ait optimizasyonlar olan BR, LM, SCG, CGF, ADAM, RMSprop ve SGDM algoritmalarına açıklık getirilmiştir.

Dördüncü bölümde ise uygulama ve bulgular yer almaktadır. Doğalgaz ve elektrik enerjisi tüketimlerinin gelecek 60 ay (2019-2023) için tahmin edilmeye çalışılmıştır. Tahminleme kullanılabilecek olan yöntemler ve algoritmalar arasında kıyaslama yapılarak her iki enerji kaynağı için en yüksek performansa sahip olan modeller belirlenmeye çalışılmıştır.

Literatür Taraması

Yapılan literatür taramasında enerji kaynaklarının arz, talep ve üretim tahmin çalışmalarının yapıldığı birçok bilimsel çalışma mevcuttur. Konu itibariyle hem dünya enerji sektöründe hem de Türkiye enerji sektöründe yapılan çalışmalar için tahminleme metodları kullanılmıştır.

Bayramoğlu ve Pabuççu'nun (2017) Türkiye'nin birincil enerji talep tahmini için yapmış oldukları çalışmanın yöntemi ANFIS'tir. Bulanık mantıkla kurmuş oldukları mimari de GSYİH, nüfus ve enerji fiyatlarını multi input olarak modele

dahil etmişler, 1990 ve 2013 yılları arasındaki yıllık verileri kullanarak birincil enerji tüketimine ulaşmaya çalışmışlardır. 2016 ve 2030 yılları arasında gerçekleşebilecek birincil enerji tüketimini tahmin etmişlerdir. Çalışmada diğer OECD ülkeleri ile Türkiye'nin gelecek projeksiyonunu kıyaslamışlardır. Çalışmaya göre Türkiye'nin diğer OECD ülkelerinde olduğu gibi enerji talebinde artış olabileceği ancak petrol ve doğalgaz talebinde çok ciddi bir değişme olmayacağı sonucuna varmışlardır. Enerji fiyatlarını bağımsız değişken olarak modele eklemeleri çalışmayı literatürdeki diğer çalışmalardan ayırdığını ifade etmektedirler.

Kalaycı'nın (2015) hazırlamış olduğu yüksek lisans tezinde Türkiye'nin doğalgaz talebi tahminlenmeye çalışılmıştır ve tezde ANFIS modeli kullanılmıştır. GSYİH, sıcaklık ve doğalgaza ulaşan nüfus bağımsız değişkenler olarak modele dahil edilmiştir. 2002 ve 2014 yılları arasındaki aylık veriler kullanılarak 2015 yılı için sıcaklığın düşük, orta ve yüksek olması açısından 3 aşamalı gerçekleştirilen çalışmada başarılı bir tahmin sonucuna ulaşıldığı ifade edilmektedir.

Demirel vd. (2010) GSYİH, üretilen enerji, tüketilen enerji, nüfus ve kurulu güç değişkenlerini kullanarak ANFIS ve ARMA yöntemlerinin tahmin sonuçlarını karşılaştırmışlardır. Aralık 1970 ve 2007 arasındaki yıllık verilerdir. 2006-2010 yıllarında gerçekleşebilecek elektrik tüketimi tahmin edilmiş ve modeller arası kıyaslama yapılmıştır. Yapılan yöntem kıyaslamasında ANFIS modelinin daha doğru sonuçlara ulaştığı ifade edilmektedir.

Yine Demirel vd. (2012) OLS, ARMAX ve YSA modellerini kullanarak 2009'daki Türkiye doğalgaz tüketimini tahmin etmeye çalışmışlardır. Sıcaklık, doğalgaz kullanıcı sayısı ve doğalgaz fiyatına ait 2004-2009 arası günlük verileri kullanmışlardır. Doğal gaz tüketimini tahinlemede kullanılabilir en iyi yöntem araştırılmış; OLS, ARMAX ve YSA modelleri birbirleriyle kıyaslanmıştır. Sıcaklık ve doğalgaz fiyatı tüketimi en çok etkileyen faktörler olarak gözlemlenmiştir. YSA geri beslemeli tahmin yöntemi diğer yöntemlerden çok daha iyi performans göstermiştir.

Erdoğan (2010) ARIMA yöntemini kullanarak 2008-2030 yılları arasında gerçekleşebilecek doğalgaz talebini tahmin etmiş, kısa ve uzun vadeli fiyat ve gelir esnekliğini ele alınmıştır. 1987-2007 arası aylık olarak doğalgaz Fiyatı, kişi başı gelir

ve doğalgaz tüketimi verilerini kullanmıştır. Sonuca göre doğalgaz tüketicileri doğalgaz fiyatlarına karşı düşük bir tepki göstermektedirler yani talep fiyata göre çok değişkenlik göstermemektedir.

Yine Erdoğan (2007) ARIMA yöntemini kullanarak 2005-2014 yılları arasında gerçekleşebilecek elektrik enerjisi talebini tahmin etmeye çalışmıştır. Elektrik Fiyatı, kişi başı gelir, nüfus değişkenlerine ait 1923-2004 aralığına ait yıllık verileri kullanarak elektrik tüketimini tahminlemiştir. Çıkan sonuç resmi projeksiyonlarla karşılaştırılmış ve resmi rakamların fazla abartıldığı yorumu yapılmıştır. Tüketicilerin elektrik fiyatlarına duyarlı oldukları sonucuna varılmıştır.

Ediger ve Akar (2007) ARIMA ve SARIMA modellerini kullanarak birincil enerji kaynaklarının (taşkömürü, linyit, asfaltit, doğalgaz, petrol, hidrolik vs) 2005-2020 arasındaki talebini tahmin etmeye çalışmışlardır. 1950 ve 2005 yılları arasındaki birincil enerji kaynaklarının tüketim verilerini kullanarak zaman serisi oluşturmuşlar ve bunun diğer bağımsız değişkenlere göre daha etkin sonuç verdiğini ifade etmişlerdir. Farklı kaynaklar için ARIMA ve SARIMA metotların iyi performans gösterdiğini ifade etmekle beraber toplam birincil enerji talep tahmininin kaynakların ayrı ayrı tahminlemesinden daha güvenilir olduğunu ileri sürmüşlerdir.

Küçükali ve Barış (2010) ANFIS yöntemi ile 1970-2014 arasındaki yıllık GSYİH verilerini kullanarak 2010-2014 yılları arasında gerçekleşebilecek brüt elektrik tüketimi tahmin etmeye çalışmışlardır. Oluşturulan model 2009 için %4,5'lik bir düşüş gösterirken 2010-2014 yılları arasında elektrik talebinde ortalama olarak %4'lük bir artış göstermektedir.

Ediger vd. (2006), 2004-2038 yılları arasında fosil yakıtların üretimini tahmin etmişlerdir. Kullandıkları yöntemler Regresyon analizi, ARIMA ve SARIMA'dır. 1950 ve 2003 arasındaki yıllık bazlı üretim eğrisi ve rezerv miktarlarını kullanarak farklı kaynaklar için üretim tahmin değerlerine ulaşmışlardır. Her bir yakıt türü için farklı modelleme kullanılmıştır. Daha iyi tanımlandığı için en iyi sonuç petrolde elde edilmiştir. Tüketim ve üretim arasındaki farkın sürekli artacağı sonucuna varılmış 2000 yılına göre 2030 senesinde farkın 2 kat olacağını ifade etmişlerdir. Bu sonuçlarla beraber 2019'da kömür, 2024'te doğalgaz, 2029'da petrol ve 2031'de asfaltit rezervlerinin Türkiye'de biteceği sonucuna ulaşmışlardır.

Görücü ve Gümrah (2004), 2002 ve 2005 yılları arasında Ankara’da oluşabilecek doğalgaz tüketimini tahmin etmeye çalışmışlardır. Sıcaklık, doğalgaz kullanıcı sayısı, fiyat ve döviz kuru değişkenlerine ait 1991 ve 2001 arasındaki günlük veriler ile çoklu regresyon analizi kullanarak sonuç elde etmişlerdir. İyimser ve kötümser iki senaryo üzerinde tahminleme yapmışlar ve sonuçların tatmin edici olduğunu ifade etmişlerdir.

Sarak ve Satman (2003), degree-day metodu kullanarak sıcaklık, nüfus ve doğalgaz kullanıcı sayısı girdilerine ait 1998 ve 2000 arasındaki günlük verilerle 2000-2023 yılları arasında konutlarda ısınma amaçlı talep edilecek doğalgaz tüketim tahminini yapmaya çalışmışlardır. Çalışmaya göre eğer bütün konutlarda ısınma amaçlı doğalgaz kullanılırsa 2023 yılında tüketimin 14.92 Gm³’e yükseleceğini ifade etmektedirler.

Say ve Yücel (2006), 1970-2002 arasındaki yıllık GSYİH ve nüfus verileri ile hükümetlerarası iklim değişikliği panelini kullanarak 2010 ve 2015 yılları arasında Türkiye’de oluşabilecek toplam enerji tüketimi ve CO₂ emisyonunu tahmin etmeye çalışmışlardır. Hem enerji tüketiminin hem de buna bağlı olarak CO₂ emisyonunun artacağını ifade etmektedirler.

Tunç vd. (2006), regresyon analizi kullanarak birincil enerji kaynakları’na ait 1980 ve 2001 arasındaki yıllık verileri kullanarak 2004-2020 yılları arasında Türkiye’de oluşabilecek elektrik üretim ve tüketim tahminlemesi yapmışlardır. Elektrik enerjisi üretim ve tüketimi Almanya, Fransa ve İsviçre ile kıyaslanmıştır.

Aydın (2014), 1971 ve 2010 arasındaki yıllık GSYİH ve nüfus verileri ile regresyon analizi kullanarak 2010-2025 yılları arasında Türkiye’de gerçekleşebilecek birincil enerji tüketimini tahmin etmeye çalışmış, 3 senaryo oluşturularak gözlemlenmiştir. Çalışmaya göre 3 senaryo için 2025 yılında 174.65 ve 203.13 Mtoe arasında birincil enerji tüketimi farklılık göstermektedir.

Özçelik ve Hepbaşlı (2006), 1990-2000 arasında yıllık GSYİH ve araç sahiplik oranlarına ait verilerle tavlama metodu ve genetik algoritma optimizasyonunu kullanarak 2000-2020 yılları arasında gerçekleşebilecek petrol ekserjisi için üretim ve tüketim değerlerini tahmin etmeye çalışmışlardır. Genetik algoritma yöntemi ile elde edilen veriler ile yapılan kıyaslamaya göre tavlama

yönteminin genetik algoritma yönteminden daha iyi performans sergilediği gözlemlenmiştir.

Dilaver ve Hunt (2011), yapısal zaman serileri ile elektrik tüketimi, endüstriyel değer ve elektrik fiyatlarına ait 1960-2008 arasındaki yıllık verileri kullanarak 2020 yılına kadar gerçekleşebilecek endüstriyel elektrik enerjisi tüketimini tahmin etmeye ve fiyat elastikiyetini gözlemlenmeye çalışmışlardır. Sonuca göre 2020 yılında Türkiye'nin endüstriyel elektrik enerjisi tüketimi 97 TWh ile 148 TWh arasında beklenmektedir.

Söylar (2014), 2003-2013 arasındaki yıllık enerji kaynaklarının arz ve talep değerleri ile dinamik simülasyon kullanarak 2014-2023 yılları için enerji sektörüne ait parametrelerin (enerji kaynakları, elektrik dengesi, enerji santralleri vs.) tahmini değerlerini elde etmeye çalışmıştır.

Ediger ve Tatlıdil (2002), 1950-2000 arasında gerçekleşen yıllık nüfus, GSMH ve GSYİH verileri ile döngü analizi ve Winter's metodunu kullanarak 2000-2010 yılları arasında Türkiye'de gerçekleşebilecek enerji talebini tahmin etmişlerdir. Elde edilen sonuçlar için metodlar arası kıyaslama yapmışlardır. Döngü analizine göre tüketimin 130 mtoe civarında gerçekleşeceği ifade edilmektedir.

Ceylan ve Öztürk (2004), GSYİH, nüfus, ithalat ve ihracat'a ait 1970-2001 arasındaki yıllık verilerle genetik algoritma optimizasyonunu kullanarak 2000-2025 yılları arası Türkiye'nin enerji talebini tahmin etmişlerdir. Farklı senaryoların uygulandığı model sonuçları Enerji ve Tabii Kaynaklar Bakanlığı'nın projeksiyonuyla kıyaslanmış ve modelin bakanlığın projeksiyonuna göre daha düşük hatayla sonuç elde ettiğini ifade etmişlerdir.

Ceylan vd. (2005), 1990-2000 arasındaki yıllık GSYİH, nüfus, ithalatın ihracata oranı'na ait verilerle 2000-2020 yılları arası 3 değişik genetik algoritma yaklaşımıyla enerji ve enerji üretim ve tüketimi tahmin etmeye çalışmışlardır. Bu çalışma 2 bölüm halinde indexte yer almaktadır. Veri aralığının kısa olmasına rağmen genetik algoritma ile gelecek dönem tahmininin enerji ve enerji talebinin ölçülmesinde alternatif bir çözüm olduğunu iddia etmekle beraber daha fazla veriyle çalışılabileceğini ifade etmişlerdir.

Canyurt vd. (2004), 1980-2001 arasındaki yıllık GSYİH, nüfus, ithalat ve ihracat verileriyle genetik algoritma optimizasyonunu kullanarak 2002-2025 yılları arasında gerçekleşebilecek Türkiye enerji tüketimini tahmin etmişlerdir. Üstel ve quadratic olarak iki farklı model uygulanmış quadratic modelin daha yüksek performans gösterdiği sonucuna varmışlardır.

Öztürk vd. (2004), 1990-2000 arasındaki yıllık GSYİH, araç sayısı verilerini genetik algoritma optimizasyonu ile kullanarak 2001-2020 yılları arasında gerçekleşebilecek Türkiye petrol üretim ve tüketimini tahmin etmişlerdir. Lineer, üstel ve quadratic form olarak 3 aşamada incelemişlerdir. Gelecek tahmini ise quadratic form ile elde edilmiştir.

Yine Öztürk vd. (2005) çalışmasında, 1980-2001 arasındaki yıllık GSYİH, nüfus, ithalat ve ihracat verileriyle genetik algoritma optimizasyonu uyguladıkları modelde 2002-2025 yılları arasında Türkiye’de gerçekleşebilecek toplam ve endüstriyel elektrik tüketimini tahmin etmişlerdir. Tahmin değerleri Enerji ve Tabii Kaynaklar Bakanlığı’nın proeksiyonuyla kıyaslanmıştır. Yine quadratic ve üstel formlarla uyguladıkları modellerde quadratic formun gözlemlenen veriler için daha yüksek performans sergilediği gözlemlenmiştir.

Haldenbilen ve Ceylan (2005), 1970-2000 arasındaki yıllık GSYİH, nüfus, araç-km verileri ile genetik algoritma optimizasyonunu kullanarak 2001-2020 yılları arasında Türkiye ulaşım sektöründe talep edilecek enerjiyi tahmin etmişlerdir. Lineer, üstel ve quadratic formda oluşturdukları modelde quadratic formun daha yüksek performans gösterdiğini gözlemlenmişlerdir.

Ceylan ve Öztürk (2008), 1975-2006 arasındaki yıllık GSYİH, nüfus, ithalat ve ihracat verileri ile genetik algoritma optimizasyonunu kullanarak 2006-2020 yılları arasında gerçekleşebilecek fosil enerji kaynaklarına ait tüketim tahminini yapmaya çalışmışlardır. Dünya Enerji Konseyi Türk Milli Komitesi tarafından hazırlanan projeksiyonlarla karşılaştırma yapılmış konseyin tahminlemesinin çok yüksek olduğu gözlemlenmiştir.

Yiğit (2011), 1979-2009 arası yıllık GSYİH, nüfus, ithalat ve ihracat verileri ile genetik algoritma optimizasyonunu kullanarak 2010-2020 yılları arasında gerçekleşebilecek Türkiye elektrik enerjisi tüketimini tahmin etmeye çalışmıştır.

2020 yılında lineer formda çıkan sonuca göre 452.47 TWh tüketim gözlemlenirken, üstel formda 354.29 TWh tüketim olabileceği ifade edilmektedir.

Akay ve Atak (2007), 1970-2004 arası yıllık elektrik tüketim verileri kullanılarak gri tahminleme metodu ile gerçekleşen toplam ve endüstriyel elektrik enerjisi tüketimini tahmin etmeye çalışmışlardır. Enerji ve Tabii Kaynaklar Bakanlığı'nın tahmin verileriyle kıyaslamışlar ve gri modelin performansının daha iyi olduğunu ifade etmişlerdir.

Toksarı (2007), 1979-2005 arası yıllık GSYİH, nüfus, ithalat ve ihracat verileri kullanılarak karınca kolonisi optimizasyonu ile 2006-2025 yılları arasında Türkiye'de gerçekleşebilecek enerji talebini 3 senaryo altında tahmin etmiş ve sonuçları Enerji ve Tabii Kaynaklar Bakanlığı'nın enerji projeksiyonu ile karşılaştırmıştır. Denklemler lineer ve quadretic olarak kurulmuştur ve quadratik denklemin daha iyi bir çözüm sağladığı görülmüştür.

Yine Toksarı (2009) çalışmasına göre, 1979-2006 arası yıllık GSYİH, nüfus, ithalat ve ihracat ile yüklü kapasite verileri kullanılarak karınca kolonisi optimizasyonu modeli oluşturulmuştur. 2007-2025 yılları arasında gerçekleşebilecek net elektrik enerjisi tüketim talebi ve üretimi 3 senaryo ile lineer ve quadratic denklemler kurularak tahmin edilmeye çalışılmıştır. Quadratic denklemin daha iyi bir çözüm sağladığı söylenmektedir. 1. ve 2. senaryoda elektrik tüketimi, elektrik üretiminden fazla çıkmış 3. senaryoda ise tüketim üretimden düşük çıkmıştır.

Yumurtacı ve Asmaz (2004), 1970-2000 arası yıllık nüfus ve enerji tüketim oranı verilerini kullanarak lineer regresyon analizi ile 1980-2050 yılları arasındaki Türkiye elektrik üretimini tahmin etmeye çalışmışlar, çalışmanın sonuca göre 2050 yılında elektrik tüketiminin 1173 milyon KWh olacağı ifade edilmektedir.

Ceylan vd. (2008), 1970-2005 arası yıllık nüfus, GSYİH, araç-km değeri verileri ile Meta-Heuristik harmonik araştırma algoritması kullanarak 2006-2025 yılları arasında ulaşım sektörü için talep edilen toplam enerjiyi tahmin etmiş ve Enerji ve Tabii Kaynaklar Bakanlığı'nın projeksiyonuyla kıyaslama yapmışlardır. Lineer, üstel ve quadratik oluşturulan denklemlerde enerji tüketim tahminlemesinde Meta-Heuristik harmonik araştırma algoritmasının kullanılabilmesi ancak duyarlılık analizinin kullanılması gerekliliği ifade edilmiştir.

Filik (2011), 2002-2005 arası saatlik, haftalık ve 1982-2007 arası yıllık elektrik tüketimi verileri ile novel model kullanılarak 2002-2005 yılları için kısa, orta ve uzun vadeli Türkiye elektrik talebini tahmin etmeye çalışmıştır. Yöntemin diğer saatlik tahminleme yöntemlerine kıyasla birkaç yıllık tahmin yapabilmesinden dolayı yük tahminleme konusunda benzersiz olduğu iddia edilmektedir.

Hamzaçebi ve Es (2014), 1945-2010 arası yıllık elektrik üretim değerleri ile optimize edilmiş gri model kullanarak 2013-2025 yılları içinde oluşabilecek toplam elektrik talebini ve enerji üretimindeki birincil enerji kaynaklarının katkı değerlerini tahmin etmeye çalışmışlardır.

Ünler (2008), 1979-2005 arası yıllık GSYİH, nüfus, ithalat ve ihracat verilerini kullanarak parçacık sürü optimizasyonu ile 2006-2025 yılları arasında Türkiye’de gerçekleşebilecek toplam enerji talebini tahmin etmiştir. Enerji ve Tabii Kaynaklar Bakanlığı tarafından yapılan tahminlemeler ele alınıp gerçekleşen değerlerden sapma durumları gösterilmektedir. Model karınca kolonisi optimizasyonu ile karşılaştırılıp uygunluğu test edilmiştir.

Kıran (2012), 1979-2005 arası yıllık GSYİH, nüfus, ithalat ve ihracat verilerini kullanarak parçacık sürü optimizasyonu ve karınca kolonisi optimizasyonu ile 2006-2025 yılları arasında Türkiye’de gerçekleşebilecek toplam enerji talebini tahmin etmeye çalışmıştır. Lineer ve kuadratik modeller kıyaslanmış, quadratic modelin sosyo-ekonomik dalgalanmalara karşı daha iyi bir çözüm sunduğu gözlemlenmiştir.

Boğar ve Boğar (2017), 1970-2015 arası yıllık GSYİH, nüfus, ithalat ve ihracat verilerini kullanarak parçacık sürü optimizasyonu ve regresyon analizi ile 1970 ve 2015 yılları arasında Türkiye’de gerçekleşmiş toplam net elektrik enerjisi tüketimini tahmin etmişlerdir. Modellemede bir çok fonksiyon kullanılmış ancak Chebyshev polinomsal regresyon modelinin en iyi sonucu verdiği gözlemlenmiştir.

Bilgili (2009), 1990-2007 arası yıllık yüklü kapasite, brüt elektrik üretimi, nüfus ve kullanıcı sayısı verileri kullanılarak lineer regresyon analizi, nonlinear regresyon analizi ve yapay sinir ağları (feed forward) ile 2008-2012 yılları arasında Türkiye’de gerçekleşebilecek net elektrik tüketimini tahmin etmiştir. 3 yöntem

karşılaştırılmış, yapay sinir ağları modelinin diğer modellerden daha iyi performans sergilediği gözlemlenmiştir.

Taşpınar vd. (2013), 2007-2011 arası günlük sıcaklık, bulutluluk, bağıl nem, basınç ve rüzgar hızı verilerini kullanarak SARIMA ve yapay sinir ağları (feed forward) ile 2007-2011 yılları arasındaki gerçeğeşen doğalgaz tüketimini tahmin etmeye çalışmışlardır. Modeller arası kıyaslama yapılmıştır. Kısa dönemli doğalgaz tüketimi tahmininde SARIMAX modeli daha iyi performans sergilemiştir.

Görücü vd. (2004), 1991-2001 arası günlük sıcaklık, kullanıcı sayısı, fiyat ve döviz kuru verilerini kullanarak yapay sinir ağları (feed forward) ile Ankara'da 2002-2005 yılları arasında günlük gerçekleşebilecek doğalgaz tüketimini tahmin etmişlerdir. İyimser ve kötümser iki senaryo olarak çalışılmıştır. YSA'nın iyi bir performans sergilediği gözlemlense de 3 yıllık tahminin model için çok uzun bir dönem olduğu ileri sürülmüştür. Kısa dönem tahminlemede yüksek performans sergilediği ifade edilmektedir.

Hamzaçebi ve Kutay (2004), 1970-2003 arası yıllık nüfus verilerini kullanarak regresyon analizi, Box-Jenkins ve yapay sinir ağları (feed forward) ile 2003-2010 yılları arasında Türkiye'de oluşabilecek elektrik tüketim talebini tahmin etmişlerdir. Kullandıkları diğer modeller regresyon ve Box-Jenkins'dir. YSA bu iki modele göre daha iyi performans sergilemiştir.

Sözen vd. (2005), 1975-2003 arası yıllık nüfus, brüt üretim ve yüklü kapasite verilerini kullanarak yapay sinir ağları (feed forward) ile gerçekleşmiş Türkiye net enerji talebini tahmin etmişler ve oluşturulan modelin performansının iyi performans sergilediğini ifade etmişlerdir.

Murat ve Ceylan (2006), 1970-2001 arası yıllık GSYİH, nüfus, araç-km verilerini kullanarak yapay sinir ağları (feed forward) ile 2000-2020 yılları arası ulaşım enerji tüketimini tahmin etmeye çalışmışlardır. Oluşturulan modelin ulaşım sektörü enerji tüketim talebini tahmin etmede uygun olduğunu ifade etmişlerdir.

Sözen ve Arcaklıoğlu (2007), 1968-2005 arası yıllık GSYİH, GSMH, nüfus, yüklü kapasite, enerji üretimi, enerji ithalatı ve ihracatı verilerini kullanarak yapay sinir ağları (feed forward) ile tahminleme yapmışlardır. YSA'yı eğitmek için 3 model kullanılmıştır. Model 1'de yüklü kapasite, üretim, nüfus, enerji ithalatı ve ihracatı,

Model 2'de GSMH ve nüfus ve Model 3'te GSYİH ve nüfus girdi verileri olarak kullanılmıştır. Çalışmada 3 farklı modellemenin amacı bu ekonomik girdilerin net enerji tüketim tahminine olan etkilerini ölçümlemektir ve tahminlemede bu girdilerin hepsinin yüksek güvenilirliğe sahip olduğu gözlemlenmiştir.

Kavaklıoğlu vd. (2009), 1975-2006 yıllık GSYİH, nüfus, ithalat ve ihracat verilerini kullanarak yapay sinir ağları (feed forward) ile 2027 yılına kadar gerçekleşebilecek elektrik tüketimini tahmin etmişlerdir. YSA'nın elektrik tüketimin tahmin etmede kullanılabilir bir model olduğunu ifade etmişlerdir.

Hotunoğlu ve Karakaya (2011), 1970-2008 arası yıllık GSYİH, nüfus, ithalat, ihracat ve enerji yoğunluğu verilerini kullanarak yapay sinir ağları (feed forward) ile farklı senaryolarda 2009'dan 2030 yılına kadar gerçekleşebilecek toplam enerji talebini tahmin etmişler ve Enerji ve Tabii Kaynaklar Bakanlığı tarafından yapılan tahminlemeler ile kıyaslamışlardır. Bakanlığın projeksiyonlarının elde edilen bulgulardan çok yüksek olduğu gözlemlenmiştir.

Es vd. (2014), 1970-2010 arası yıllık GSYİH, nüfus, ithalat, ihracat, bina yüzölçümü ve taşıt sayısı verilerini kullanarak yapay sinir ağları (feed forward) ve çoklu doğrusal regresyon analizi ile 2011-2025 yılları arası Türkiye'nin net enerji talebini tahmin etmişlerdir. Sonuçlar çoklu doğrusal regresyon analizi ile kıyaslanmış ve bu kıyas sonucu YSA'nın performansının daha yüksek olduğu gözlemlenmiştir.

Sözen vd. (2004), 2000-2002 arası aylık Enlem, boylam, rakım, ay, ortalama güneş ışığı süresi ve ortalama sıcaklık verilerini kullanarak yapay sinir ağları (feed forward) ile 17 istasyona ait güneş enerjisini etkileyecek girdiler kullanılarak Türkiye'nin güneş enerjisi potansiyeli ölçümlenmeye çalışılmıştır. YSA'nın tahminlemede klasik regresyon modellerinden daha iyi performans ortaya koyduğu ileri sürmektedirler.

Sözen vd. (2005), 1975-2003 arası yıllık nüfus, brüt üretim, yüklü kapasite, ithalat, ihracat ve birincil enerji kaynakları verilerini kullanarak yapay sinir ağları (feed forward) modellerini oluşturmuş, ve her iki model için de tek bir output olarak net enerji tüketimi kullanılmıştır. YSA'nın enerji tüketimini tahmin etmede kullanılabilir bir model olduğu ileri sürülmektedir.

Sözen (2009), 1968-2005 arası yıllık kişi başına toplam birincil enerji üretimi, kişi başına toplam brüt elektrik üretimi, kişi başına nihai enerji tüketimi, kişi başına sektörel enerji tüketimi verilerini kullanarak yapay sinir ağları (feed forward) ile 2 model oluşturmuş ve her iki model için de tek bir output olarak modellenen enerji bağımlılığı tahmin edilmeye çalışılmıştır.

Çınar ve Kayakutlu (2007), 2000-2004 arası günlük elektrik tüketimi, yüklü kapasite, nüfus, enerji tüketimi, GSYİH ve GSMH tüketimi verilerini kullanarak yapay sinir ağları (feed forward) modeli oluşturmuşlardır. Cognitive mapping yöntemiyle enerji üretimini etkileyen faktörler tespit edilmeye çalışılmış, elde edilen değişkenler hidroelektrik üretiminde input olarak kullanılmıştır. 2000-2004 yılları arasında gerçekleşmiş hidroelektrik üretimi tahmin edilmeye çalışılmış ve gerçek değerlerle kıyaslanmıştır.

Bayrak ve Esen (2014), 1960-2011 arası yıllık GSYİH, nüfus, ithalat ve ihracat verilerini kullanarak yapay sinir ağları (feed forward) ile 2012-2020 yılları arasında Türkiye’de gerçekleşebilecek enerji üretim ve tüketimi tahmin etmeye çalışmışlar ve bu süreç için enerji açığı gözlemlemişlerdir.

Söyler vd. (2016), 1950-2014 arası yıllık net elektrik tüketimi, GSYİH, nüfus, ithalat ve ihracat verilerini kullanarak yapay sinir ağları (feed forward) ve ANFIS ile 1950 ve 2014 yılları arasında gerçekleşmiş net elektrik tüketimini 3 farklı modelleme ile test etmeye çalışmışlardır. Tahminleme de en iyi performans geri beslemeli Elman Ağı (YSA) göstermiştir.

Kaynar vd. (2011), 2005-2006 arası günlük ve haftalık doğalgaz tüketim verilerini kullanarak yapay sinir ağları (feed forward) ve ARIMA ile Ankara ilinin doğalgaz tüketimini tahmin etmişlerdir. Yapay sinir ağı modellerinde ARIMA modellerinden daha iyi performans elde edilmiştir.

Bilgili vd. (2012), 1990-2007 arası yıllık yüklü kapasite, brüt elektrik üretimi, nüfus ve kullanıcı sayısı verilerini kullanarak yapay sinir ağları (feed forward) ve regresyon analizi kullanarak 2008-2015 yılları arasında gerçekleşebilecek konut ve sanayi için elektrik enerjisi tüketim tahminini yapmış, üç model ve Enerji ve Tabii Kaynaklar Bakanlığın projeksiyonlarını karşılaştırmışlardır. En iyi performans yapay sinir ağları modelinde elde edilmiştir.

Kankal vd. (2010), 1980-2007 arası yıllık GSYİH, nüfus, ithalat, ihracat ve istihdam verilerini kullanarak yapay sinir ağları (feed forward) ve regresyon analizi kullanarak 2008-2014 yılları arasında gerçekleşebilecek net enerji tüketimi tahmin etmeye çalışmışlar, 4 farklı senaryo oluşturularak karşılaştırma yapılmıştır. Elde edilen senaryolar Enerji ve Tabii Kaynaklar Bakanlığı'nın tahmininden daha düşük çıkmıştır.

Çınar vd. (2010), 1970-2006 arası yıllık elektrik tüketimi, yüklü kapasite, nüfus, birincil enerji tüketimi ve GSMH verilerini kullanarak yapay sinir ağları (feed forward) ve genetik algoritma optimizasyonu kullanılarak 2007-2012 yıllarında gerçekleşebilecek hidroelektrik üretimi tahmin etmeye çalışmışlardır. Oluşturulan hibrit modelin klasik yapay sinir ağı modellemesinden daha iyi performans gösterdiği ifade edilmektedir.

Günay (2016), 1975-2013 arası yıllık nüfus, kişi başı GSYİH, enflasyon yüzdesi, ortalama yaz sıcaklığı, elektrik tüketimi verilerini kullanarak yapay sinir ağları (feed forward) ve çoklu regresyon analizi kullanarak 2014-2028 yılları arasındaki brüt elektrik tüketimini tahmin etmeye çalışmıştır. 15 yıl içerisinde tüketimin iki katına çıkacağı gözlemlenmiştir. Sonuçlar iki model ve Enerji ve Tabii Kaynaklar Bakanlığı'nın projeksiyonuyla kıyaslanmış YSA modelinin daha iyi performans sergilediği gözlemlenmiştir.

Abual-Foul (2012), 1976-2008 arası yıllık GSYİH, nüfus, ithalat ve ihracat verilerini kullanarak yapay sinir ağları (feed forward) ile 2010-2025 yılları arasında Ürdün'de gerçekleşebilecek enerji tüketimini tahmin etmeye çalışmıştır.

Geem (2011), 1990-2007 arası yıllık GSYİH, nüfus, petrol fiyatı, araç sayısı, yurtiçi yolcu miktarı verilerini kullanarak yapay sinir ağları (feed forward) ile 2008-2025 yılları için 4 farklı model oluşturularak Güney Kore ulaşım sektörü için talep edilen enerji miktarını tahmin etmeye çalışmıştır. YSA'nın ulaşım enerji talebini tahminlemede kullanılabilecek iyi bir yöntem olduğu gözlemlenmiştir.

Szoplik (2015), 2009-2011 arası saatlik Sıcaklık, günün saati, haftanın günü, ay ve ayın günü verilerini kullanarak yapay sinir ağları (feed forward) ile Szczecin'de konutlarda tüketilen doğalgaz miktarını tahmin etmiştir. YSA'nın tahminleme için uygun bir model olduğunu ifade etmiştir.

Pao (2006), 1990-2002 arası aylık milli gelir, nüfus, GSYİH, TÜFE, sıcaklık verilerini kullanarak yapay sinir ağları (feed forward) ve ARMA ile Tayvan'da ihtiyaç duyulan elektrik enerjisi tüketimini tahmin etmeye çalışmış ve oluşturulan modeller karşılaştırılmıştır. YSA modellerinin daha iyi performans sergilediği gözlemlenmiştir.

Limanond vd. (2011), 1989-2008 arası yıllık GSYİH, nüfus ve araç sayısı verilerini kullanarak yapay sinir ağları (feed forward) ve regresyon analizi ile Tayland'da 2010-2030 yılları için ulaşım sektöründe ihtiyaç duyulan enerjiyi tahmin etmeye çalışmışlardır. Regresyon projeksiyonu YSA projeksiyonundan daha yüksek çıkmıştır.

Ekonomou (2010), 1992-2004 arası yıllık sıcaklık, yüklü kapasite, elektrik tüketimi, GSYİH verilerini kullanarak yapay sinir ağları (feed forward), regresyon analizi ve destek vektör makinesi ile 2005-2015 yılları arasında Yunanistan'da gerçekleşecek enerji tüketimini tahmin etmeye çalışmıştır. Modeller arası ve gerçek verilerle karşılaştırma yapılmıştır. YSA modelinin diğer modellerden daha iyi sonuç verdiğini ifade etmiştir.

Tokgöz ve Ünal (2018), Türkiye elektrik tüketimini tekrarlayan sinir ağları (RNN), kapalı tekrarlayan birimler (GRU) ve uzun-kısa süreli bellek (LSTM) metotlarını kullanarak ölçümlemeye çalışmışlardır. 01.01.2013 ve 31.12.2014 dönemleri arasındaki saatlik veriler kullanılarak mimari oluşturulmuştur. Geçmiş dönemlerde aynı tahminlemeyi sunan ARIMA ve YSA modelleri kıyaslamasını yaparak en düşük MAPE (mutlak yüzdellik hata- mean absolute percentage error) değerini elde ettiklerini ifade etmişlerdir.



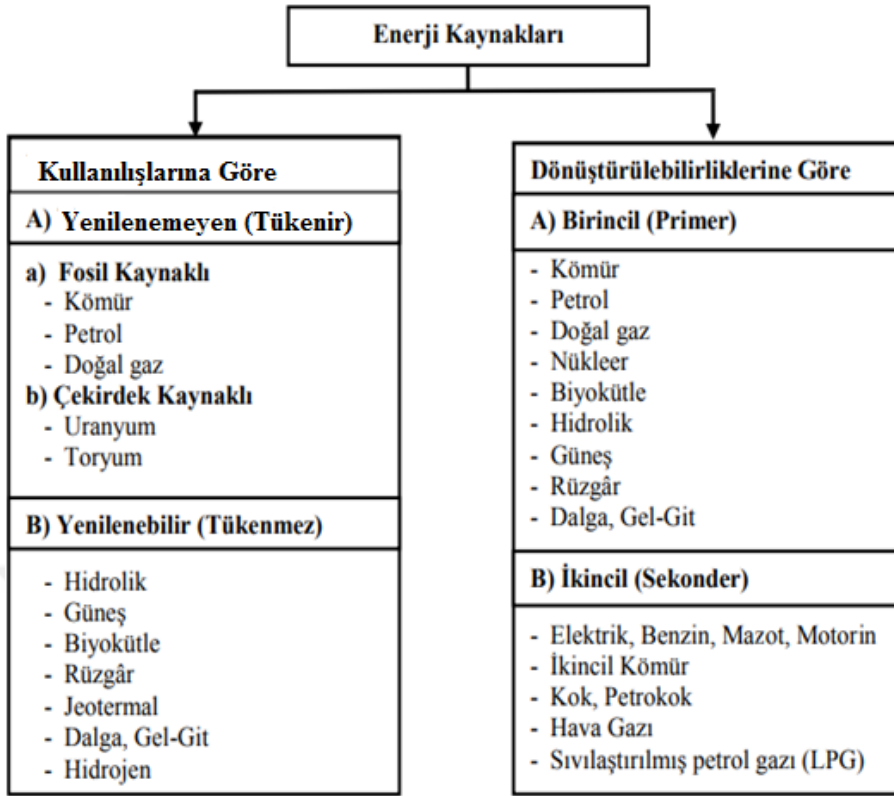
BİRİNCİ BÖLÜM

1.ENERJİ KAYNAKLARI

1.1 Enerji Kaynakları Kavram Ve Kapsamı

Dünya üzerinde kullanılan enerji; potansiyel veya kinetik olarak yani mekanik, kimyasal, nükleer, termal, hidrolik, jeotermal, rüzgâr, güneş, elektrik enerjisi gibi hallerde bulunabilmektedir. Bu enerji türleri uygun yöntemlerle birbirlerine dönüştürülebilirler. Enerjinin elde edildiği kaynaklara ise enerji kaynakları denilmektedir. Farklı şekillerde sınıflandırılabilen enerji kaynakları kullanışlarına göre yenilenebilir ve yenilenemeyen enerji kaynakları olarak ikiye ayrılırlar. Diğer bir sınıflandırma tipi ise dönüştürülebilirliklerine göredir. Bu sınıflandırma türünde ise enerji kaynakları birincil ve ikincil enerji kaynakları olarak ikiye ayrılırlar. Yakın gelecekte tükenebileceği öngörülen enerji kaynaklarına yenilemez enerji kaynakları denir ve yenilemez enerji kaynakları ise fosil kaynaklılar ve çekirdek kaynaklılar olarak sınıflandırılırlar. Uzun vadede tükenmeden kalabilen ve kendisini sürekli olarak yenileyebilen enerji kaynaklarına ise yenilenebilir enerji kaynakları denilmektedir (Koç, Şenel 2013: 33).

Bir değişim ya da dönüşüme uğramayan enerji türüne birincil (primer) enerji denilmektedir. Birincil enerji kaynakları arasında kömür, doğalgaz, petrol, güneş, rüzgar, biyokütle, dalga, hidrolik ve nükleer enerji yer almaktadır. Birincil enerji kaynaklarının dönüştürülerek elde edilen enerji türüne ise ikincil (sekonder) enerji denilmektedir. İkincil enerji sınıfında ise motorin, fueloil, elektrik, benzin, kok kömürü, ikincil kömür, petrokok, LPG (sıvılaştırılmış petrol gazı) ve hava gazı gibi kaynaklar yer almaktadır (Koç, Şenel 2013: 33). Enerji kaynaklarının sınıflandırıldığı şema aşağıda Şekil 1’de olduğu gibidir.



Şekil 1. Enerji Kaynakları

Kaynak: Koç, E., Şenel, M. C. 2013. “Dünyada ve Türkiye’de Enerji Durumu - Genel Değerlendirme,” Mühendis ve Makina, cilt 54, sayı 639, s. 32-44.

Sanayi devrimiyle beraber hızlı şekilde yükselen bir grafik seyreden enerji kullanımı etkisini hem Türkiye’de hem de dünyada devam ettirmektedir. Enerjinin güvenli ve sürdürülebilir olarak temin edilmesi gelişmiş ve gelişmekte olan ülkeler için stratejik bir önem taşımaktadır. Ülkelerin devamlılığı enerjinin sürdürülebilirliğiyle paralel bir yapı göstermektedir.

Yukarıda bahsedilen enerji kaynaklarında en avantajlı görüneni yenilenebilir enerji kaynakları olmasına rağmen hem Türkiye’de hem de dünyada enerji arzının büyük kısmı yenilenemez yani tükenbilir (fossil) enerji kaynaklarından sağlanmaktadır (Külebi 2007: 33).

BOTAŞ’ın hazırlamış olduğu 2016 sektör raporunda Uluslararası Enerji Ajansı (UEA)’nın dünya gelecek projeksiyonlarına yer verilmektedir. Hazırlanan rapora göre 2040 yılında dünya nüfusunun yıllık ortalama %0,9 büyüyerek 9,2

milyar olacağı öngörülmektedir. Bu artışa paralel olarak 2014 yılı için belirlenmiş olan 13,684 mtpe dünya toplam birincil enerji talebinin yine 2040 yılında ortalama değerinde çıkan senaryoya göre 17,866 mtpe olacağı tahmin edilmektedir. Oluşturulan 3 farklı senaryoya göre yakıt türleri bakımından Dünya toplam birincil enerji talebi projeksiyonları Tablo 1’de görülmektedir. Tabloya göre şurada olduğu gibi ileriki dönemlerde kullanılacak baskın enerji türlerinin yine fosil kaynaklı yakıtların olacağı öngörülmektedir. (BOTAŞ 2016: 5).

Tablo 1. Dünya Birincil Enerji Talebi (Milyon Ton Petrol Eşdeğeri - mtpe)

	2014	Yeni Politikalar Senaryosu		Mevcut Politikalar Senaryosu		450 Senaryo	
		2025	2040	2025	2040	2025	2040
Kömür	3.926	3.955	4.140	4.361	5.327	3.175	2.000
Petrol	4.266	4.577	4.775	4.751	5.402	4.169	3.326
Doğal Gaz	2.893	3.390	4.313	3.508	4.718	3.292	3.301
Nükleer	662	888	1.181	865	1.032	960	1.590
Hidro	335	420	536	414	515	429	593
Biyoenjeri *	1.421	1.633	1.883	1.619	1.834	1.733	2.310
Diğer Yenilenebilir	181	478	1.037	420	809	596	1.759
Toplam	13.684	15.340	17.866	15.937	19.636	14.355	14.878
TBET içindeki fosil yakıt payı (%)	81	78	74	79	79	74	58
CO₂ Emisyonları (Gt)	32,2	33,6	36,3	36,0	43,7	28,9	18,4

* Geleneksel ve modern biyokütle kullanımlarını içerir.

TBET: Toplam birincil enerji talebi

Kaynak: BOTAŞ Sektör Raporu 2016


Bölgeler bazında fosil yakıtların tükenme ömürleri Tablo 2’de görülebilmektedir.

Tablo 2. Dünya Fosil Yakıt Kaynaklarının Tükenme Ömrü (Yıl)

Bölge	Petrol	Doğal Gaz	Kömür
Kuzey Amerika	33,1	13,0	276,0
Orta ve Güney Amerika	117,0	42,5	150,0
Avrupa & Asya	24,4	57,4	273,0
Ortadoğu	73,1	129,5	123,0
Afrika	42,2	66,4	
Asya & Pasifik	14,0	28,1	51,0
TOPLAM DÜNYA	50,7	52,8	114,0
Avrupa Birliği	10,1	10,8	112,0
OECD	29,7	15,1	206,0
Eski Sovyet Ülkeleri	27,8	71,3	435,0

Kaynak: TTK, 2017, 2016 Yılı Türkiye Taşkömürü Sektör Raporu, Ankara: 6


Uluslararası Enerji Ajansının hazırlamış olduğu dünya enerji istatistiklerine göre 1973 (Toplam 6101 Mtoe) ve 2015 (Toplam 13647 Mtoe) yıllarına ait “Toplam Birincil Enerji Arzı (TPES)”nin kaynaklarına göre oranları Şekil 2 ve Şekil 3’teki gibidir.



Şekil 2. 1973 Kaynaklarına Göre Dünya Enerji Arz Oranları

* Jeotermal, güneş, rüzgâr, gelgit / dalga / okyanus, ısı ve diğerlerini içerir.

Kaynak: Uluslararası Enerji Ajansı “Key World Enerji Statistics 2017” , 2017, s. 6



13 647 Mtoe


Şekil 3. 2015 Kaynaklarına Göre Dünya Enerji Arz Oranları

* Jeotermal, güneş, rüzgâr, gelgit / dalga / okyanus, ısı ve diğerlerini içerir.

Kaynak: Uluslararası Enerji Ajansı "Key World Enerji Statistics 2017" , 2017, s. 6

Şekil 2 ve Şekil 3'teki verilere göre petrol haricindeki tüm kaynakların arz oranları artış göstermektedir. Enerji arzı dünyada 1973 yılında 6101 Mtoe'den 2015 yılında 13 647 Mtoe'ye yükselmiştir. Doğalgaz ve özellikle nükleer enerjideki artış dikkat çekmektedir. Bu verilere göre nükleer enerji arzı diğer kaynaklara nazaran dünya çapında önemli bir oranda artmaktadır.

Yine Uluslararası Enerji Ajansı'nın hazırlamış olduğu enerji istatistiklerine göre kaynaklarına göre dünya toplam enerji tüketim oranları (TFC) Şekil 4 ve Şekil 5'te gösterilmektedir.




Şekil 4. 1973 Kaynaklarına Göre Dünya Toplam Enerji Tüketim Oranları

* Biyoyakıt ve atık nihai tüketim verileri birkaç ülke bazında tahmin edilmiştir.

** Isı, güneş enerjisi ve jeotermal enerjii içermektedir.

Kaynak: Uluslararası Enerji Ajansı "Key World Enerji Statistics 2017" , 2017, s. 34



Şekil 5. 2015 Kaynaklarına Göre Dünya Toplam Enerji Tüketim Oranları

* Biyoyakıt ve atık nihai tüketim verileri birkaç ülke bazında tahmin edilmiştir.

** Isı, güneş enerjisi ve jeotermal enerjii içermektedir.

Kaynak: Uluslararası Enerji Ajansı "Key World Enerji Statistics 2017" , 2017, s. 34

1973 yılında dünya toplam enerji tüketimi 4661 Mtoe iken 2015 senesinde bu tutar 9384 Mtoe'ye yükselmiştir. Kaynaklara göre enerji tüketiminde özellikle ısı, güneş enerjisi ve jeotermal enerji türlerinin ve elektrik enerjisinin kullanım oranlarında artış görülmektedir. Petrolün kullanımı ise yıllar arasında %7'lik bir azalış seyretmiştir.

Verilerden de anlaşıldığı gibi enerji kullanımı yıllar bazında sürekli artmaktadır. Fosil kaynaklara olan talebin ise sürekli devam ettiği açıkça görülebilmektedir.

1.1.1 Kömür

Yıllar boyunca enerji kaynağı olarak kullanılan kömür, geri dönüşümü olmayan, yenilenemeyen fosil kaynaklı bir yakıttır. Yanabilme özelliği olan kömür sedimanter organik bir kayadır. Milyonlarca yıl boyunca basınç, ısı ve biyolojik etkiler sonucu oluşan kömür; hidrojen, oksijen ve karbon gibi elementlerin biraraya gelmesiyle oluşmaktadır (ETKB 2017b: 1). Kömür bataklık kökenlidir ve bataklık şartlarının değişmesine bağlı olarak birikmiş organik maddelerin “kömürleşme” olarak tamamlanan olay sonucunda değişime uğramış halidir (Demirbilek 1987: 34).

Bir kömür çeşidi olan ve ısıl değeri düşük olan linyit kömürü; içerdiği kül ve nem miktarının fazlalığından dolayı genellikle termik santrallerde yakıt olarak kullanılmaktadır. Yerkabuğunda bol miktarda bulunduğu için de büyük bir oranda kullanılan enerji hammaddesidir. Yine bir kömür çeşidi olan “taşkömürü” ise yüksek kalorili bir kömür çeşitidir (<http://www.enerji.gov.tr/tr-TR/Sayfalar/Komur> Erişim Tarihi: 05.08.2018).

Kömürün küresel olarak bulunduğu rezerv miktarları Tablo 3'te görülebilmektedir.


Tablo 3. Kömür Rezerv Miktarı Bakımından Dünya Sıralaması (2016)

Sıralama	Ülke	Milyon Ton	Pay (%)
1	Amerika	251582	22,1
2	Çin	244010	21,4
3	Rusya	160364	14,1
4	Avustralya	144818	12,7
5	Hindistan	94769	8,3
6	Almanya	36212	3,2
7	Ukrayna	34375	3
8	Kazakistan	25605	2,2
9	Endonezya	25573	2,2
10	Polonya	24161	2,1
11	Türkiye	11353	1
12	Güney Afrika	9893	0,9
13	Yeni Zelanda	7575	0,7
14	Sırbistan	7514	0,7
15	Brezilya	6596	0,6
16	Diğer Ülkeler	54931	4,8
17	Dünya Toplam	1139331	100

*Antrasit, bitümlü, alt bitümlü ve linyit kömür toplamı alınmıştır.

Kaynak: BP, 2017, Statistical Review of World Energy 2017, ss: 36

Kömür üretiminin Dünya bölgelerindeki dağılımı ise Şekil 6'da gösterilmektedir. 45 yıllık süreçte OECD ülkelerinin üretimi sabit devam ederken özellikle 2000 yılından sonra Çin Halk Cumhuriyeti'nin üretim hacminde dikkate değer bir artış gözlemlenmektedir.




Şekil 6. Bölgelere Göre 1971'den 2016'ya Kadar Dünya Kömür** Üretimi (Mt)

* Çin hariç OECD dışı Asya Ülkeleri

** Buhar Kömürü, kok kömürü, linyit ve kazanılmış kömürü içermektedir.

Kaynak: Uluslararası Enerji Ajansı "Key World Enerji Statistics 2017" , 2017, s. 16

1973 ve 2016 kömür üretiminin dünyada bölgesel olarak paylar Şekil 7 ve Şekil 8'de gösterilmektedir.




Şekil 7. 1973 yılı Dünya Bölgesel Kömür** Üretimi Oranları

* Çin hariç OECD dışı Asya Ülkeleri

** Buhar Kömürü, kok kömürü, linyit ve kazanılmış kömürü içermektedir.

Kaynak: Uluslararası Enerji Ajansı "Key World Enerji Statistics 2017" , 2017, s. 16



Şekil 8. 2016 yılı Dünya Bölgesel Kömür** Üretimi Oranları

* Çin hariç OECD dışı Asya Ülkeleri

** Buhar Kömürü, kok kömürü, linyit ve kazanılmış kömürü içermektedir.

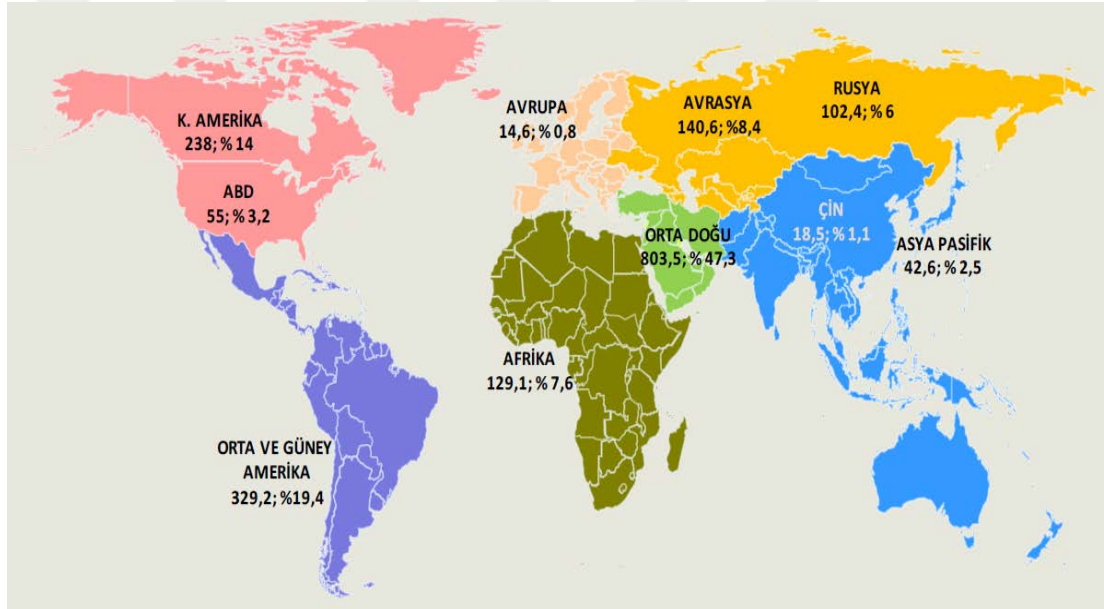
Kaynak: Uluslararası Enerji Ajansı “Key World Enerji Statistics 2017” , 2017, s. 16

1973 senesinde OECD Ülkeleri kömür üretiminde öncü iken 2016 senesinde yaklaşık yarı yarıya bir düşüş gerçekleştirmişlerdir. Buna karşılık Çin üretim hacmini 3 kattan daha fazla olacak şekilde artırmıştır. OECD Dışı Asya ülkeleri ise toplamda yaklaşık 6 kat üretimlerini artırmışlardır. OECD Dışı Avrupa ve Asya Ülkeleri de yine büyüme gerçekleştirerek üretim hacimlerini toplamda yine yaklaşık olarak 3 kat artırmışlardır. OECD ülkelerinin pastadan kaybettikleri pay Çin, OECD Dışı Asya ve Avrupa ülkeleri arasında paylaşılmaya başlanmıştır.

1.1.2 Petrol

Enerji elde edilmede kullanılan bir diğer fosil bazlı kaynak ise petroldür. Özellikle hidrojen, oksijen, karbon ve kükürt elementlerinin birleşmesiyle meydana gelen ve az miktarda da olsa nitrojen barındıran bir bileşimdir. Doğada sıvı, katı ve gaz hallerinde bulunabilmektedir. Üretilmiş gazdan ayırt edilmesi adına gaz halindeki petrole doğalgaz denilmektedir. Ana bileşenlerinin hidrojen ve karbon olması nedeniyle ham petrol ve doğalgaza "hidrokarbon" kaynaklar denilmektedir (<http://www.enerji.gov.tr/tr-TR/Sayfalar/Petrol> Erişim Tarihi: 08.06.2018).

BP'nin 2017 de hazırlayıp sunduğu rapora göre küresel enerjinin üçte birini oluşturan petrol dünyanın önde gelen yakıtları arasında yerini korumaktadır. 1999'dan 2014'e kadar 15 yıllık düşüşün ardından petrol, ikinci çeyrekte küresel pazar payı kazanmıştır. Küresel petrol tüketimi günde ortalama günde 1,6 milyon varile çıkararak artış göstermiştir. En büyük artış ise Hindistan (330000 b/d) ve Çin'de (400000b/d) görülmektedir. Üretim alanında Orta Doğuda; İran (700000b/d), Irak (400000b/d) ve Suudi Arabistan'da (400000b/d) artış görülmekle birlikte en büyük düşüş Amerika'da (-400000b/d) gerçekleşmiştir. Amerika'nın ardından Çin (-310000b/d) ve Nijerya (-280000b/d) gelmektedir (BP Statistical Review of World Energy, 2017: 2).



Şekil 9. 2015 Yılı Bölgelere Göre Dünya İspatlanmış Petrol Rezervi Dağılımı
(Birim: Milyar Varil)

Kaynak: TP, Ham Petrol ve Doğal Gaz Sektör Raporu, Mayıs 2017, s. 6

2015 yılı için Dünya ispatlanmış petrol rezervi Orta Doğu Bölgesi'nde (%47.3) görülmektedir. Bölgeyi takiben en çok rezerv Venezuela'nın içinde bulunduğu Orta ve Güney Amerika Bölgesin'de (%19.4) bulunmaktadır.

Worldatlas'ın derlemiř olduđu 2016 senesinin sonu itibariyle ÷lkeler bazında en yüksek petrol rezervi bulunan ÷lkeler ise Tablo 4'te gör÷lmektedir.


Tablo 4. 2016 Kanıtlanmış En Yüksek Petrol Rezervi Olan ÷lkeler

Sıralama	÷lke	Birim (Miyar Varil)
1	Venezuela	298,4
2	Suudi Arabistan	268,3
3	Kanada	171
4	İran	157,8
5	Irak	144,2
6	Kuveyt	104
7	Rusya Federasyonu	103,2
8	Birleşik Arap Emirlikleri	97,8
9	Libya	48,36
10	Nijerya	37,07
11	ABD	36,52
12	Kazakistan	30
13	Katar	25,24
14	Çin	24,65
15	Brezilya	15,31
16	Cezayir	12,2
17	Meksika	9,812
18	Angola	9,011
19	Ekvator	8,832
20	Azerbaycan	7

Kaynak: Worldatlas (2017), "The World's Largest Oil Reserves By Country"

298 milyar varilin üzerinde ispatlanmış petrol rezerviyle Venezuela, dünyanın en çok petrol rezervine sahiptir. 2012 yılına kadar açık ara farkla Suudi Arabistan 268 milyar varilden fazla petrol rezerviyle birinci sırada yer almaktaydı. Kanada'daki petrol kum yataklarında olduđu gibi; Venezuela'da kendi petrol kum yataklarında büyük miktardaki rezervini keşfederek sıralamada zirveye oturmuştur.

Bununla beraber, Venezuela hala pek çok geleneksel petrol yatağına sahiptir. Venezuela'nın Orinocotar kumları Kanada'dakilere göre çok daha az viskoz olduğundan, orada bulunan petrol kumları konvansiyonel yağ emme yöntemleri kullanılarak çıkarılabilir, bu da sermaye gereksinimleri ve çıkarma maliyetleri açısından Kuzey Amerika rakibine oranla belirgin bir üstünlük sağlamaktadır (Worldatlas 2017).



Şekil 10. İspatlanmış Petrol Rezervlerinin 1996, 2006, 2016 Bölgesel Dağılımı

Kaynak: BP, Statistical Review of World Energy 2017, s. 13

Petrol, enerji tüketiminde en çok kullanılan kaynaklardan biri olsa da yıllar içerisinde rezerv artışı Şekil 10'da görülmektedir. Bu artışta özellikle Güney Amerika'daki Venezuela'da bulunan rezervlerin etkisi görülebilmektedir.

OPEC'in 2017 Kasım ayında hazırlamış olduğu "OPEC Aylık Petrol Piyasası Raporuna göre (2017 Kasım), küresel petrol arz/talep dengesine dayanılarak 2018'de OPEC petrol talebinin karşılanması için üretilmesi gerek miktara ilişkin tahmini, günlük 460 bin varil yukarı çekerek 33.46 milyon varil olarak açıklamıştır. 2017'deki OPEC ham petrolü ise günlük 33 milyon varil olarak tahmin edilmekte, bu ise grubun 2016 petrol talebinden günlük 710 bin varil daha fazla olduğunu göstermektedir.

Dünya toplam petrol talebi ise 2017 senesi için 2016 yılından %1,6 oranında artış göstermiştir. Tahmin ise %1,52 oranında öngörülmüştür. 2018 yılı tahminleri ise 2017 yılından %1,56 oranında olması beklenmektedir (OPEC 2017: 30-31).

1.1.3 Doğalgaz

Doğal gaz esas olarak metan gazı içeren önemli bir enerji kaynağıdır. Genellikle ham petrol yataklarıyla ve ayrıca gazın taşındığı bağımsız petrol yataklarında, birleştirilmiş petrolün bir başka yerde bırakıldığı durumda bulunur. Metan bazı kömür madenlerinde ve arazi dolumlarında çürümüş bitki örtüsü (bataklık gazı) ile üretilir, ancak bu kaynaklar genellikle ticari kullanım için uygun değildir. (Macmillan Encyclopedia of Energy 2001: 828).

Doğal gaz yerden çıktığında, tipik olarak yüzde 75-95 oranında metan, az miktarda etan, propan ve bütandan oluşur. Su buharı, karbondioksit, azot, oksijen ve hidrojen sülfür gibi sülfürlü gazları da içerebilir. Çeşitli yakıtlara ve petrokimyasal ürünlere ayrılması ve rafine edilmesi gereken petrolün aksine, doğal ve genel saflık doğalgazın işlenmesini çok daha az karmaşık hale getirmektedir (Macmillan Encyclopedia of Energy 2001: 828). Doğal gaz, doğal olarak oluşan metan (CH₄) ile diğer hidrokarbonlar ve atıl gazların bir karışımıdır. 1800'lü yıllardan önce Londra sokaklarında gaz aydınlanma için kullanılırdı; ardından evler, işyerleri ve kamu binaları için aydınlatma, pişirme, su ve yerden ısıtma kaynağı olarak kullanılmaya başlandı. On dokuzuncu yüzyılın sonuna dek, gaz ışığı, Kuzey Amerika ve Batı Avrupa'daki kent merkez ilçelerinde ve daha büyük şehirlerde, hatta Buenos Aires, Kahire, St. Petersburg, Şangay ve Sidney gibi yerlerde yaygın olarak kullanılmaktaydı (Macmillan Encyclopedia of Energy 2001: 820-821).

Enerji ticaretine en çok konu olan kaynaklar petrol ve doğalgazdır. Yenilenemez kaynaklar içerisinde çevre kirliliği açısından doğalgaz en büyük avantajı sağlamaktadır. Öyle ki Türkiye'de yaygınlaşmaya başlamasının en büyük nedeni yine ısınmada kömürden kaynaklı hava kirliliğinin artık tahammül sınırlarını aşmasıdır.


Özellikle 1970'lerde Ankara'da hava kirliliğinin çok ciddi boyutlara ulaşmasının nedeni ısınmada kullanılan düşük kaliteli linyit olarak görülmüştür. İthal kömür kullanımı bu problemin çözümü olarak düşünülmüş ancak bu çözüm kısa

vadeli olarak kalmış büyük bir fayda sağlayamamıştır. Doğalgazın kullanımı bu süreçle beraber 1989 yılında Ankara’da ısınma amaçlı kullanımıyla başlanmış ve hava kirliliğinin önüne geçildiği gözlemlenmiştir. Yine hava kirliliğinin yoğun yaşandığı diğer bir il olan İstanbul’da doğalgaz kullanımı 1994’te ısınma olarak hayata geçirilmiştir (Engin 2010: 235).

Kimyasal özelliklerinden kaynaklı olarak atmosfer basıncının altında ya da oda sıcaklığında tamamen gaz halinde yer alan doğalgaz, pek çok üstün özelliği ile hidrokarbon enerji kaynakları arasında birinci sırada yer almaktadır. Örneğin diğer kaynaklara göre zehirsiz bir gazdır, solunduğu takdirde aşırı bir şekilde olumsuz bir etki yapmaz. Havadan daha hafiftir dolayısıyla herhangi bir gaz kaçağının olması halinde havalandırma deliklerinden dışarı atılabilmektedir. Yine en üstün özelliklerinden birisi de tamamen yanmasına bağlı olarak maksimum enerji elde edilmesidir. Kullanımı kolay ve ekonomiktir (Armaroli, Balzani 2011: 69-71).


Doğalgaz, maliyetleri düşünüldüğünde petrolden, LPG ve benzeri petrol gazlarından daha ucuz, temiz yakıt olması, toz sorunu oluşturmaması, uzak mesafelere de kolaylıkla taşınabilir hale gelmesi, kömüre göre daha düşük CO₂ emisyonu meydana getirmesi, özellikle elektrik üretiminde kullanılan doğalgazın, santrallerinin kuruluş süresinin kısa oluşu da tercih edilme sebepleri arasındadır (Hodalğulları 2015: 49-50). Ancak stok yapılma güçlüğü ise doğalgazın dezavantajları arasındadır.

Dünya doğalgaz üretiminin yıllar içerisindeki seyri Şekil 11 ve Şekil 12’de gösterilmektedir.



Şekil 11. 1973 Bölgelere Göre Dünya Doğalgaz Üretimi

Kaynak: IEA, Key World Energy Statistics, 2017: 14



Şekil 12. 2016 Bölgelere Göre Dünya Doğalgaz Üretimi

Kaynak: IEA, Key World Energy Statistics, 2017: 14

1973 yılında dünyada doğalgaz üretiminin öncü bölgesinin OECD olduğu görülmektedir ancak 2016 senesine geldiğinde bu oran yaklaşık olarak yarı yarıya düşmektedir. OECD üretimde yine lider olmakla beraber büyük oranda pastayı özellikle Orta Doğu ardından Afrika, OECD olmayan Amerika Ülkeleri, OECD

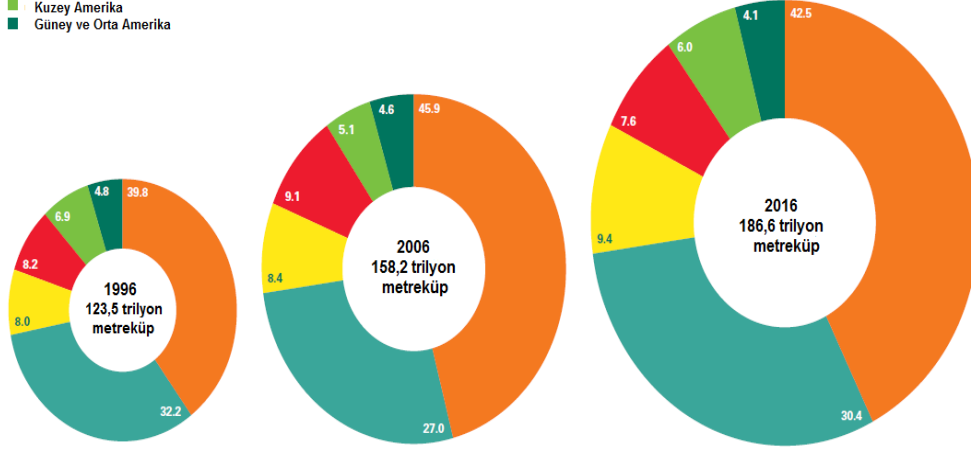

olmayan Asya Ülkeleri ve Çin ile artan oranda paylaşmak durumunda kalmıştır. Üretimin 1973 yılında 1.224 bcm iken 2016 yılında 3.613 bcm'ye yükselerek 3 katı değerine çıktığı görülmektedir.

Tablo 5'te ispatlanmış doğalgaz rezervinde ilk 20 sırada yer alan ülkeler yer almaktadır. Dünyada bölgesel olarak ispatlanmış doğalgaz rezervleri ise yıllar içerisinde Şekil 13'teki gibi dağılım göstermektedir. Bölgesel olarak bakıldığında an itibariyle en çok rezervin %42,5 oranında Orta Doğuda bulunduğu görülmektedir. Yıllar içerisinde oran dağılımında büyük ölçekli değişiklikler gerçekleşmemiştir.

Tablo 5. Kanıtlanmış En Yüksek Doğalgaz Rezervi Olan Ülkeler (2017)

Sıralama	Ülke	Birim (Trilyon m ³)
1	Rusya Federasyonu	1688
2	İran	1187
3	Katar	890
4	ABD	308
5	Suudi Arabistan	288
6	Türkmenistan	265
7	Birleşik Arap Emirlikleri	215
8	Venezuela	195
9	Nijerya	182
10	Cezayir	159
11	Çin	141
12	Irak	112
13	Endonezya	108
14	Kazakistan	85
15	Malezya	83
16	Mısır	77
17	Norveç	73
18	Kanada	68
19	Özbekistan	65
20	Kuveyt	64

Kaynak: EIA, "Natural gas" <https://www.eia.gov/naturalgas/data.php> Erişim Tarihi: 15.08.2019




Şekil 13. 1996, 2006, 2016 İspatlanmış Doğalgaz Rezerv Dağılımı

Kaynak: BP, Statistical Review of World Energy 2017, s. 27

1.1.4 Yenilenebilir Enerji Kaynakları

Doğada mevcut olan, kullanılması halinde tükenmeden kendisini yenileyebilen ve bunu sürekli kılan enerji kaynaklarına yenilenebilir enerji kaynağı denilmektedir. Uzun ya da kısa vadede tükenmesi beklenen ve bununla beraber çevre kirliliğine neden olan birincil enerji kaynaklarının yerine kullanılacak olan bu enerji kaynağı türleri arasında rüzgar, güneş, jeotermal enerji, hidrojen, hidrolik, biyokütle, dalga-gelgit gibi enerji kaynakları yer almaktadır (Akt: Önal, Yarbay 2010: 79).

Yenilenebilir enerji kaynakları, fosil yakıtlarda olduğu gibi, ısınma, sıcak su elde etme, güç üretme, ulaşımda araç yakıtlarında ve tarımsal faaliyetler gibi alanlarda kullanılabilirler. Bu bağlamda gelişen ülkelerde yemek ve aydınlanma için biyogazın, yemek yapmada kullanılan diğer yakıtların yerini aldığı görülebilmektedir. Sıcak su ve mekân ısıtılması için ise güneş, biyokütle ve jeotermal enerjiden faydalanılmaktadır. Sanayide ya da kırsalda toprak işleme biyogazdan faydalanılabilmektedir (Önal, Yarbay 2010: 80).




Şekil 14. 2015 Yılı Dünya Toplam Birincil Enerji Arzının Kaynaklarına Göre Dağılımı

Kaynak: IEA, Renewables Information: Overview, 2017: 3

* Diğer yenilenemez atıkları ve yakıt hücreleri gibi başka yerlerde bulunmayan diğer kaynakları içerir.

Şekil 14'te 2015 Yılı Dünya toplam birincil enerji arzının kaynak paylaşımı görülmektedir. Yenilenebilir enerji kaynakları bu pastanın ancak %13,4'lük kısmını kapsamaktadır ve görüldüğü üzere dünya enerji kaynağı olarak yine çok büyük bir oranda fosil kaynaklardan faydalanmaktadır.

2015 Yılı içerisinde dünya yenilenebilir enerji arzının kaynak paylaşımı Şekil 15'te gösterilmektedir. Arzın çok büyük bir kısmı olan %70,7'lik dilimi biyoyakıtlardan ve atıklardan elde edilmektedir.



Şekil 15. 2015 Dünya Yenilenebilir Enerji Arzının Kaynaklara Göre Dağılımı

Kaynak: IEA, Renewables Information: Overview, 2017: 3

1.1.4.1 Hidrolik Enerji / Hidro-Elektrik Enerjisi


Suyun potansiyel enerjisinin kinetik enerjiye dönüştürülmesinden oluşan enerjiye hidroelektrik enerjisi denir. Akan suyun kurulu türbinleri döndürmesiyle elektrik enerjisi elde edilir. Açığa çıkan enerjiden yeni bir enerjinin elde edilmesinden dolayı fosil kaynaklarda olduğu gibi birincil enerji kaynağı olarak adlandırılmazlar. İkincil enerji kaynağı olarak hidroelektrik elektrik santralleri (HES) dünyada sıklıkla kullanılmaktadır.

Akan suyun gücünü elektriğe dönüştüren kurulu güçlere hidroelektrik santraller (HES) denilmektedir. Büyük bir nehirde suyun akışı büyük miktarda enerjiyi içinde barındırmaktadır bununla beraber yine çok yüksek bir noktadan aşağı düşen su yüksek miktarda enerji elde etmede fayda sağlar. Mekanik enerjinin elektrik enerjisine dönüştürülebildiği bir sistem olarak karşımıza çıkmaktadır (Yenilenebilir Enerji Genel Müdürlüğü, <http://www.yegm.gov.tr/> Erişim Tarihi: 01.11.2017).

Dünyada 2016 yılı için yenilenebilir enerji arzında %18,3'lük bir payla hidroelektrik enerjisi, %63,7'lik bir payla katı biyoyakıt ve mangal kömüründen elde

edilen enerjinin hemen ardından ikinci sırada gelmektedir. Bu da hidroelektrik potansiyelinin diğer kaynaklara nazaran daha yüksek olduğunu göstermektedir.

Yine 2015 yılı için hidroelektrik enerji arzının bölgesel paylaşımı Şekil 16'da görülmektedir. Grafiğe göre Çin'in tek bir ülke bazında hidroelektrik enerji üretiminin öncüsü olduğu söylenebilir. Bununla beraber liderlik ise OECD ülkelerinin toplamındadır. Ortadoğu ülkelerinin ise fosil yakıtların aksine bu alanda çok pasif olduğu görülebilmektedir.



Şekil 16. 2015 Dünya Hidroelektrik Enerji Arzının Bölgesel Paylaşımı

Kaynak: IEA, Renewables Information: Overview, 2017: 4

* Pompa depolama üretimini kapsamamaktadır.

Dünya 1990-2015 yılları arasında hidroelektriğe dayalı enerji arzının ortalama büyüme oranı %2,4 olarak gerçekleşmiştir. Diğer yenilenebilir enerji kaynaklarına göre bu oran artışı geride kalmıştır (IEA 2017: 3)

1.1.4.2 Rüzgâr Enerjisi


Yenilenebilir, temiz, doğal, bir güç olan rüzgâr enerjisinin kaynağı güneştir. Güneş enerjisinin dünyada oluşturduğu enerjinin çok küçük bir miktarı –yaklaşık %1-2 oranında- dönüşerek rüzgar enerjisi oluşturur. Güneşin, atmosferi ve yeryüzünü homojen ısıtmamasından dolayı oluşan sıcaklık ve basınç farkı hava akımına neden

olur (http://www.yegm.gov.tr/yenilenebilir/ruzgar-ruzgar_enerjisi.aspx Erişim Tarihi: 14.11.2017). Bu hava akımından kaynaklı basıncın ortaya çıkardığı kinetik enerji sonucuna rüzgâr enerjisi denmektedir. Bu bağlamda güneş'in var olduğu kadar rüzgâr enerjisinin varlığından bahsetmek doğru olacaktır.

Rüzgârların yüksek basınç alanlarından alçak basınç alanlarına akımı sırasında; yüzey sürtünmeleri, yerel ısı yayılımı, dünyanın kendi eksenini etrafında dönmesi, rüzgâr önündeki farklı atmosferik olaylar ve arazinin topografik yapısı gibi nedenlerden dolayı rüzgârlar şekillenmeye başlarlar. Rüzgârlar, yerel coğrafi farklılıklar ve yeryüzünün homojen olmayan ısınmasından dolayı zamana ve yöreye göre değişiklik gösterir (Yerci 2015: 1).

Avrupa rüzgâr enerjisi endüstrisi, 2009'dan bu yana çok hızlı bir oranda büyüme ile yıllık ortalama 11,3 GW yıllık pazara ulaşmıştır (Wind Europe, Erişim Tarihi: 22.11.2017). Dünya pazarında küçük, rüzgar pazarında ise 2015 yılında 2014'e kıyasla (830 MW) %14'lük büyüme ile 945 MW'lık bir pazar oluşmuştur. Ve neredeyse 1 milyon adet kurulu güç tesis edilmiştir. Dünya çapında İtalyan pazarı en çekici hale gelen pazar olmuştur. Çin, küresel kapasitenin %43'ünü, ABD % 25'ini, İngiltere %15'ini, İtalya ise %6,3'ünü oluşturmaktadır (WWEA, <https://wwindea.org/blog/2017/06/02/wwea-released-latest-global-small-wind-statistics/> Erişim Tarihi: 22.11.2017). Yine Dünya Rüzgâr Enerjisi Kuruluşunun 2016 yılı, yarı döneme ait yayınladığı istatistiklere göre; 2015 yılı ile aynı oranda gerçekleşerek 21 GW'lık yeni kurulu güç tesis edilmiştir. Dünya rüzgâr gücü 456 GW'a ulaşmış ve yılsonuna kadar 500 GW'a ulaşması beklenmiştir. Almanya, Hindistan ve Brezilya 2016 yılının ilk yarısında büyümede lider olarak başı çekmişlerdir. 2016 yılının ilk yarısında ilk 15 rüzgâr ülkesi farklı bir tablo çizmekte ve 2015 yılına kıyasla daha güçlü bir pazar oluşturmaktalar. Bu ülkeler ise Almanya, Hindistan, Fransa, Brezilya, İtalya, İsveç ve Polonya olarak raporda geçmektedir. Türkiye ise listede 15 ülke arasında 2016 ilk yarısındaki kapasitesine 428 MW'lık bir ekleme gerçekleştirerek 2016 Haziran ayında 5146 MW'lık kapasite oluşturarak 13. sırada yer almıştır (WWEA 2016: 2). Büyüme oranında Türkiye Rüzgâr enerjisi pazarında ise %50'lik bir artış gerçekleştirerek sıralamada Amerika Birleşik Devletleri ve Fransa'dan sonra gelerek 8. sırada yer almıştır (WWEA 2016: 3). Şekil

17'de 2012-2016 yılları arası Dünya genelindeki toplam rüzgar enerjisi kurulu gücü değişimi görülebilmektedir.



Şekil 17. Dünya Toplam Kurulu Güç Miktarı (2012-2016/MW)

*Şebekeye bağlı ve bağlı olmayan tüm kurulu rüzgâr kapasitesini içerir.

Kaynak: The World Wind Energy Association, Half Year Report 2016: 2

Dünya genelinde rüzgâr enerjisi kapasitesi 2016 Haziran Ayı sonuna kadar 456.486 MW'a ulaşmış ve 2016 yılının ilk altı ayına 21.714 MW'lık bir kapasite eklenmiştir. Bu artış 2015 yılının ilk yarısında olduğu gibi 21,6 GW olarak gerçekleşmiştir. 2016 yılının ortalarında dünya çapında kurulmuş olan tüm rüzgâr türbinleri, dünyanın elektrik ihtiyacının yaklaşık %4,7'sini üretebilmektedir. Küresel rüzgâr kapasitesi altı ay içinde % 5 artmış (2015 yılının aynı döneminde %5,8 ve 2014'te % 5,6 olarak gerçekleşmesinden sonra) ve yıllık bazda %16,1 oranında (2016 ortasında, 2015 yılının ortalarıyla karşılaştırıldığında) artış göstermiştir (WWEA 2016: 2).


Avrupa'da ise 2016 yılında 2015 yılına kıyasla %3'lük bir düşüş gerçekleşerek, 12.5 GW'lık yeni rüzgar enerjisi kapasitesi kurulmuş ve şebekeye bağlanmıştır. Kurulum yeri olarak kapasite kıyıda 10.923 MW, denizde ise 1.567 MW olmuştur. Rüzgâr enerjisi santralleri 2016'da Avrupa'daki diğer herhangi bir güç üretim biçiminden daha fazla artış göstermiştir. Rüzgâr enerjisi, toplam kurulu

kapasitenin %51'ini oluşturmuştur. 2016'da üretilen yaklaşık 300 TWh ile rüzgâr enerjisi AB'nin elektrik talebinin %10,4'ünü karşılamıştır. Rüzgâr enerjisi geliştirme yatırımlarını finanse etmek için 2016 yılında 27,5 milyar avro yatırım yapılmıştır. Bu tutar ise 2015'teki toplam yatırımdan %5 oranında daha fazladır (Windeurope 2016: 10-13).

1.1.4.3 Güneş Enerjisi

Dünyanın en önemli enerji kaynağı güneştir. Rüzgar enerjisi kaynağının kökeninin güneş olması gibi yer ve atmosferdeki fiziksel oluşumların çoğunun kaynağı da yine güneştir. Yani denizde oluşan dalga, okyanus ve denizlerdeki sıcaklık farklılıkları, biyokütle enerjileri gibi oluşumlar güneş enerjisinin değişim geçirmesiyle meydana gelmektedir. Yine madde ve enerji akışları güneş enerjisi sayesinde gerçekleşmektedir. Akarsu gücünü yaratan yine güneş enerjisidir bunula beraber hidrokarbon kaynakların ve biyokütle kabul edilen maddelerin yıllarca biriken güneş enerjisi olduğu kabul görmektedir. Pek çok enerji türünün kökeni olarak karşımıza çıkan güneş enerjisi ısıtma ve elektrik elde etme gibi amaçlar için doğrudan kullanılabilir (Varınca, Gönüllü 2006: 270). Güneş enerjisi oluşabilecek karbon emisyonlarının azaltılmasında ve enerji arzının sürdürülebilir olmasında büyük rol oynamaktadır. Bu enerji türü ısıtma, soğutma, aydınlatma, elektrik gücü, nakliye ve çevre temizliği için kullanılabilir (WEC, <https://www.worldenergy.org/data/resources/resource/solar/> Erişim Tarihi: 24.11.2017).


Termal toplayıcılar ile fotovoltaik toplayıcılar iki temel güneş enerjisi teknolojisi türüdür. Bir ısı motoru kullanmadan güneş ışınımını elektriğe direk olarak dönüştüren teknoloji türü fotovoltaik toplayıcılardır. Evlerde ısınma ve sıcak su elde etmede kullanılan tür ise termal toplayıcılardır. Bunlarla beraber büyük ölçekli olarak yani endüstriyel ısı elde etmede ya da fosil yakıtlarda olduğu gibi aynı mekanizmalar kullanılarak elde eilecek elektrik enerjisi üretiminde de rol oynamaktadırlar. (WEC, <https://www.worldenergy.org/data/resources/resource/solar/> Erişim Tarihi: 24.11.2017).



Şekil 18. 2016 Dünya Bölgelere Göre Güneş Enerjisi Kurulu Gücü (227 GW)

Kaynak: WEC, 2017, Energy Resources: Solar

Şekil 18’de de görüldüğü gibi güneş enerjisi toplam 227 GW’lık Kurulu gücü alanında öncülüğü %43,7’lik payıyla Avrupa üstlenmektedir. Hemen ardından ise %35,2’lik dilime sahip olan Doğu Asya ülkeleri gelmektedir. Kuzey Amerika ise bu teknolojiye %13,2 ile 3. sırada gelmektedir.



Şekil 19. Yıllar Bazında Dünya Toplam Güneş Pilleri Kapasite ve Yıllık Artışlar, 2006-2016

Kaynak: REN21, 2017, Renewables 2017 Global Status Report: 66

Dünya genelinde güneş pillerindeki artış Şekil 19'da görülmektedir. 2016 yılında dünya çapında en az 75 GW güneş enerjisi kapasitesi eklenmiştir ve bu; saat başına 31.000'den fazla güneş panelinin kurulumuna eşdeğer olarak karşımıza çıkmaktadır (REN21, 2017: 66). 2016 yılı için güneş enerjisi bazında öncülük eden ülkeler sırasıyla; Çin, Japonya, Almanya, Birleşik Devletler, İtalya, Birleşik Krallık, Hindistan, Fransa, Avustralya ve İspanya olmuştur. İlk sırada yer alan Çin, dünya toplam güneş enerjisi kapasitesinin %46'sına, Japonya %11,5'ine, Amerika Birleşik Devletleri ise %20'sine sahiptir. İlk 10 ülkenin haricindeki diğer dünya ülkeleri toplamda bu kapasitenin yalnızca %8'ine sahiptir (REN21 2017: 67).

1.1.4.4 Jeotermal Enerji

Yer altında bulunan kayalar içinde biriken ısının taşınıp depolanması sonucu buhar, kuru buhar ve sıcak sudan suni olarak elde edilen ısı enerjisine jeotermal

enerji denmektedir (ETKB, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Jeotermal>, Erişim Tarihi: 30.11.2017).


Yerkürenin iç ısısı olarak karşımıza çıkan jeotermal enerjiden elektrik enerjisi, mekan ısıtılması, kış aylarında yüzeyde biriken karların eritilmesi, tarım gibi bir çok alanda kullanılabilir. Yani jeotermal kaynaklar elektrik ve termal enerji hizmetleri (ısıtma ve soğutma) sağlamaktadır (Koç, Şenel 2013: 38; REN21 2017: 52).

Jeotermal enerji olarak kurulu güç; elektrik ve ısı üretim gücü olmak üzere ikiye ayrılmaktadır. 2016'da, jeotermal kaynaklardan gelen tahmini elektrik ve termal çıktı, her biri yaklaşık eşit paylar sağlayan 567 PJi (157 TWh) olarak gerçekleşmiştir. Hidroelektrik enerjisine benzer şekilde, 1990 ve 2016 yılları arasında jeotermal elektrik üretiminde de önemli bir büyüme yaşanmamıştır. Yıllık ortalama % 28,6 TWh ile 51,8 TWh arasındaki bir oranda artış göstermiştir. 2016 yılında yaklaşık 0,4 GW yeni jeotermal enerji üretme kapasitesi çevrimiçi hale gelmiş ve böylece toplamda yaklaşık 13,5 GW'luk bir artış sağlanmıştır. Yeni kurulumlarda Endonezya ve Türkiye liderlik etmişlerdir. Kenya, Meksika ve Japonya da yıl boyunca projelerini bu alanda tamamlamışlardır. 2016 yılı sonunda en büyük jeotermal enerji üretim kapasitesine sahip ülkeler Amerika Birleşik Devletleri (3.6 GW), Filipinler (1.9 GW), Endonezya (1.6 GW), Yeni Zelanda (1.0 GW), Meksika (0.9 GW) , İtalya (0.8 GW), Türkiye (0.8 GW), İzlanda (0.7 GW), Kenya (0.6 GW) ve Japonya (0.5 GW) olarak karşımıza çıkmaktadır (Koç, Şenel 2013:38; REN21 2017: 52; IEA 2017: 11).

Endonezya, 2016'da yaklaşık 200 MW yeni kapasite eklemiş ve yılsonunda kapasitesini 1.64 GW'a yükseltmiştir. 2017 yılının başlarına gelindiğinde ülke, dünyanın en büyük jeotermal santrallerinden biri olan 110 MW Sarulla fabrikasında da ticari işletmeye başlamıştır. Tesis, geleneksel flaş türbinlerinin, flaş sonrası türbin buharından ek enerji çıkarmak için ikili bir sistemle desteklendiği, enerji çıkarma ve verimliliğini en üst düzeye çıkararak 2017'de faaliyete başlamış bir Türk tesisine benzeyen, birleşik çevrim işlemi olarak dikkat çekmektedir (REN21 2017: 52).

2015 yılında 10 adet tesisin açılmasının ardından Türkiye, 2016 yılında en az 10 yeni jeotermal enerji santrali daha eklemiş ve toplamda 821 MW'lık kapasiteyle

yaklaşık kurulu gücünü 200 MW artırmıştır. Çevrimiçi olarak çok fazla ek kapasite ile Türkiye, jeotermal enerjiden üretilen elektrik enerjisinin hızlı bir şekilde artırmaya devam etmiş; böylelikle üretim sadece 2016'daki % 25 artışıyla 4.21 TWh'ye yükselmiştir. Türkiye ayrıca, ülkenin geri kalan yüksek sıcaklık kaynaklarına uygun geleneksel flash türbin teknolojisi ile projeler geliştirmektedir (REN21 2017: 52). Bu bağlamda Endonezya ve Türkiye'nin jeotermal enerji bazında öncülük yapıyor olması, bu ülkelerin jeotermal ısı için etkin bir pazar olarak karşımıza çıkmasını sağlamaktadır. 2016 Yılı için jeotermal kurulu kapasitede yer alan ilk 10 ülke ve kapasite tutarları Şekil 20'de görülebilmektedir. Türkiye bu sıralamada 7. Sırada yer almakla beraber 2016 yılında Endonezyadan sonra en çok kapasite artıran ülke olmuştur.



Şekil 20. 2016 Yılı Jeotermal Kurulu Kapasitede İlk 10 Ülke

Kaynak: REN21, 2017, Renewables 2017 · Global Status Report: 53


1.1.4.5 Biyokütle Enerjisi

Biyomas ya da biyokütle enerji; güneş enerjisinin bitkiler tarafından dönüştürülmüş şekli olarak tanımlanmakla beraber biyokütle enerji kaynakları için içerisinde karbonhidrat bileşikleri olan bitkisel ve hayvansal kökenli tüm maddelerdir denilmektedir. Bitkilerin bünyesinde dönüştürülmüş halde depolanan enerjinin ihtiyaç duyulduğunda kullanılması da biyokütle enerji'nin kullanımı olarak karşımıza

çıkmaktadır. Biyokütle enerji kaynakları kullanılarak, biyoetanol, biyodizel ve biyogaz olmak üzere üç temel yakıt elde edilebilmektedir. (TÜSİAD 1998: 81; Koç, Şenel 2013: 38) Yağlı tohumlu bitkiler, şeker ve nişasta bitkileri, elyaf bitkileri, protein bitkileri, bitkisel ve tarımsal atıklar, odun ve orman atıkları; hayvansal ürünleri elde etme esnasında oluşan atıklar ve mezbahane atıkları, büyükbaş ve küçük baş hayvanların ve tavuk gibi kümes hayvanlarının dışkıları, dip ve kanalizasyon çamurları, sanayi, endüstriyel ve evsel atıklar ve atık sular, kağıt ve gıda atıkları, biyokütle kaynakları olarak karşımıza çıkmaktadır (ETKB <http://www.enerji.gov.tr/tr-TR/Sayfalar/Biyokutle> Erişim Tarihi: 30.11.2017).

Biyokütle hammaddelerinin yenilenebilir enerjiye dönüştürülebildiği birçok faydalı yol vardır. Enerji amaçlı yetiştirilen bitkiler ve artıklar doğrudan ısıtma ve soğutma veya elektrik üretimi için yakıt olarak kullanılabilir veya nakliye için gazlı veya sıvı yakıtlara dönüştürülebilir veya petrokimyasalların yerini alabilirler (REN21 2017: 45).

Dünya yenilenebilir enerji kaynaklı elektrik üretiminin 2015 yılı verilerine göre büyük bir kısmı hidrolik enerjiden elde edilmekle beraber katı biyoyakıtlar da dâhil olmak üzere, biyoyakıtlar ve atıklar, elektrik üretiminde ufak bir rol oynamaktadır ve dünya elektriğinin % 1,9'unu temin etmektedir (IEA 2017: 5). 2006-2016 yılları arasında Dünya bölgeler bazında biyo-enerji üretim hacmindeki değişim Şekil 21'de görülebilmektedir.



Şekil 21. Yıllar Bazında Bölgelere Göre Küresel Biyo-Enerji Üretimi

Kaynak: REN21, Renewables 2017 · Global Status Report: 47

Bölgesel olarak bakıldığında Avrupa Birliğine üye olan ülkelerin biyo-enerji üretim hacminin diğer bölgelere oranla daha fazla olduğu görülmektedir. Bununla beraber küresel biyo-güç kapasitesi, 2016 yılında yaklaşık %6 artarak 112 GW'a yükselmiştir. Üretim %6 artışla 504 terawatt saat'e (TWh) ulaşmıştır. 2016 yılında biyokütle kaynaklı elektrik üretimi için önde gelen ülke sırasıyla Çin (54 TWh), Almanya (52 TWh), Brezilya (51 TWh), Japonya (38 TWh), Hindistan (30TWh) ve Birleşik Krallık (30 TWh) olarak karşımıza çıkmaktadır (REN21 2017: 46).

Birleşik Devletler, biyokütle kaynaklı en büyük elektrik üreticisi olmaya devam etse de, var olan kapasite, bir dizi devlete ait yenilenebilir portföy standartlarına dayalı alternatif yenilenebilir üretim kaynaklarının artan fiyat rekabeti ile yüz yüze geldiğinden, üretim 2016 yılında % 2 oranında düşerek 2015 yılındaki seviyesinin (69 TWh) altına 68 TWh'ye gerilemiştir. Bununla birlikte, Birleşik Devletlerin bio-güç kapasitesi, 51 küçük ölçekli üretim tesisi kurulmasıyla 197 MW (% 0,5) artışla 16,8 GW'a yükselmiştir (REN21 2017: 46) .

1.1.5 Nükleer Enerji

Nükleer kelimesi; çekirdekle ilgili olan, çekirdeksel anlamına gelmektedir. Buradan çıkışla nükleer enerji, atomik enerji ya da çekirdek enerjisi olarak ifade edilebilmektedir. Nükleer enerji, atom çekirdeklerinin parçalanması veya birleşmesi sonucunda açığa çıkan enerji türüdür (Kocaeren 2016: 288). Çekirdeksel kuvvetler, atomun bünyesinde yürürlükte olan elektrik kuvvetlere oranla, çok daha şiddetlidir. Bundan dolayı nükleer enerji, atomsal boyutta oluşan fosil enerjilere oranla, altı aşama (10^6) kadar daha yüksek değere ulaşmaktadır. Kıyas yapılması sonucu %1 kadar U^{235} içeren 100 ton doğal uranyum, Keban Barajı boyutlarındaki bir nükleer santrale 1 yıl süreyle yeterken, aynı boy bir termik santrale 1 milyon ton petrol gerekliliği ortaya çıkmaktadır (Yarman 2009: 61).

Nükleer enerjinin iki temel kaynağı fisyon (parçalanma/bölünme) ve füzyondur (birleşme). Nükleer enerjiye karşı birçok eleştiri gelse de, dünya enerjisinin büyük bir bölümünün nükleer füzyon enerjisinden meydana gelen güneş enerjisinden geldiğinin de farkında olunmalıdır (Ferguson 2015: 23). Günümüzde kullanılan enerji kaynaklarının çoğu kömür, petrol ve doğalgaz gibi fosil yakıtlardır ve bu fosil yakıtlar da zaman içerisinde hayvan ve bitkilerin çürümesi sonucu oluşan bir yaşamın sonucudur. Güneşin nükleer enerjiden ışık ürettiği düşünüldüğünde hayvan ve bitkilerin çok eskiden kalma güneş ışığını depoladıkları göz önünde bulundurulduğunda, bu yaşam formlarından elde ettiğimiz enerjinin içerisinde nükleer enerjinin varlığı söz konusu olmaktadır¹.

Nükleer enerjiyi elde etmek için nükleer reaktörler kullanılmaktadır. Nükleer enerji kullanımı sonucu karbondioksit üretilmez. Bundan dolayı nükleer enerji türü kömür yakan termik enerjiye göre daha çevreci olarak görülmektedir (Doğanay 1998: 457). Bu çevresel özelliğine rağmen nükleer enerjinin kötü imajının da bulunduğu inkâr edilmemelidir. Bu bağlamda 1979'daki ABD Pensilvanya'daki


¹ Bkz: Charles D. Ferguson'un yazmış olduğu Nükleer Enerji: Herkesin Bilmesi Gerekenler eserinin 23-25. sayfalarında bu konu detaylı işlenmiştir. Yanlızca fosil kaynaklardan bahsetmemiş aynı zamanda enerji üretiminde kullanılan güneş ve rüzgar enerjilerinin kaynağında nükleer enerji olduğunu dile getirmektedir. Nükleer enerjiden elde edilmeyen herhangi bir enerji kaynağı düşünüldüğünde buna örnek olarak hidrolik gücün suyun akışından elde edildiğini vurgulayarak cevap vermektedir. Bu enerjinin arkasındaki kaynak yer çekimi kuvvetidir. Buna benzer olarak elektrik üretiminde kullanılan gelgit kuvveti de yerçekimi kuvvetinin bir sonucudur.

Three Mile Island'da, 1986'da Sovyetler Birliği'nde Ukrayna Çernobil'de, 2011'de Japonya'da Tokyo Fukuşima Santrali'nde meydana gelmiş büyük ölçekli kazalar bu kötü imajın kaynaklarından başlıcalarıdır (Yarman 2009: 62).

Nükleer santraller günümüzde kendilerine has özelliklerden dolayı ülkelerin tercih ettiği bir elektrik enerjisi kaynağıdır. Ancak şimdiye kadar gerçekleşen kazaların yanı sıra nükleer atıkların nihai kalıcı ve aynı zamanda güvenli olarak sorununun olması diğer yandan Amerika ve Avrupa'da toplumsal farkındalığın gelişmesi ile nükleer silahlar ve nükleer teknolojiye karşı siyasal ve toplumsal bir muhalefet de oluşmuştur (EDAM 2011: V). Bahsedilen dezavantajlı durumlar ise tarihsel süreç içerisinde elde edilen deneyimlerle ortadan kaldırılmış ya da kaldırılmaya çalışılmaktadır. Elektrik üretiminde diğer fosil yakıtlar gibi karbon salınımı gerçekleştirmemesi nedeniyle daha çevreci, ucuz, güvenilir, erişilebilir ve sürdürülebilir olan nükleer santraller diğer alternatif enerji kaynaklarına göre daha ön plana çıkmaktadır. Nükleer santrallerin bazı özellikleri aşağıdaki gibidir (ETKB, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Nukleer-Enerji> Erişim Tarihi: 11.12.2017) :

- Nükleer santraller iklim ve doğa koşullarından etkilenmeden sürekli elektrik üretimi gerçekleştirir. Kapasite faktörü %90'lar seviyesindedir.
- Nükleer santraller işletme sırasında sera gazı salımı yapmazlar. Bu nedenle küresel ısınmayı önlemede önemli bir alternatiftirler.
- Elektrik birim maliyet fiyatlandırmasında yakıt maliyeti diğer kaynaklara nazaran çok düşüktür. Dolayısı ile yakıt fiyatlarında yaşanacak dalgalanmalar, elektrik üretim maliyetlerini etkilemez.
- Nükleer yakıt hammaddesi Uranyum dünyada farklı coğrafyalara yayılmıştır. Nükleer yakıtlar her zaman ve şartta erişilebilirdir.
- Ayrıca nükleer santrallerin birim elektrik üretimi başına kurulum alanı diğer tüm santrallere göre oldukça küçüktür. Bu nedenle tarım, yerleşim ve doğal hayata minimum etki ederler.

Bölgelere göre 1971-2015 yılları arası nükleer elektrik üretimi hacmi Şekil 22'de görülebilmektedir.




Şekil 22. Bölgelere Göre Dünya Nükleer Elektrik Üretimi 1971-2015

* Non-OECD Asya Ülkelerine Çin dahil edilmemiştir.

** Diğer Bölgelere; Afrika, Non-OECD Amerika Ülkeleri ve Orta Doğu girmektedir.


Kaynak: IEA,2017, Key World Energy Statistics 2017, ss:18



Şekil 23. 1973 Yılı Dünya Nükleer Elektrik Üretimi

* Non-OECD Asya Ülkelerine Çin dahil edilmemiştir.

Kaynak: IEA,2017, Key World Energy Statistics 2017, ss:18



Şekil 24. 2015 Yılı Dünya Nükleer Elektrik Üretimi

* Non-OECD Asya Ülkelerine Çin dâhil edilmemiştir.

** Diğer Bölgelere; Afrika, Non-OECD Amerika Ülkeleri ve Orta Doğu girmektedir.

Kaynak: IEA,2017, Key World Energy Statistics 2017, ss:18

Dünya nükleer kaynaklı elektrik üretimi Şekil 22, Şekil 23 ve Şekil 24'te görülmektedir. 1973'te 203 TWh olan üretim 42 senede 2571 TWh'e yükselmiştir. Bu alanda özellikle Amerika Birleşik Devletlerinin başını çektiği OECD ülkeleri lider konumdadır. Çin'in bu yıllar aralığında sisteme dahil olduğu ve tek başına önemli bir dilime sahip olduğu görülebilmektedir. 2015 yılı için Nükleer üretimde dünyada önemli yere sahip ülkeler, kurulu güçleri ve elektrik üretiminde nükleer enerji kullanım oranları Tablo 6, Tablo 7 ve Tablo 8'de görülmektedir.

Tablo 6. Nükleer Kaynaklı Elektrik Üretiminde Ülkeler ve Değerleri (2015)

Ülkeler	Miktar (TWh)	%
ABD	830	32,3
Fransa	437	17
Rusya	195	7,6
Çin	171	6,7
Kore	165	6,4
Kanada	101	3,9
Almanya	92	3,6
Ukrayna	88	3,4
Birleşik Krallık	70	2,7
İspanya	57	2,2
Dünya Kalan	365	14,2
Dünya Toplam	2571	100

Kaynak: IEA,2017, Key World Energy Statistics 2017, ss:19

Tablo 7. Nükleer Kaynaklı Elektrik Üretiminde Ükelere Ait Kurulu Kapasite (2015)

Ülkeler	Kurulu Kapasite (GW)
ABD	99
Fransa	63
Japonya	40
Çin	27
Rusya	25
Kore	22
Kanada	14
Ukrayna	13
Almanya	11
İsveç	10
Dünya Kalan	59
Dünya Toplam	383


Kaynak: IEA,2017, Key World Energy Statistics 2017, ss:19

Tablo 8. Ülkelerin Toplam İç Elektrik Üretiminde Nükleer Yüzdesi (%)

Ülkeler (İlk 10 Üretici)	Toplam İç Elektrik Üretiminde Nükleer Yüzdesi (%)
Fransa	77,6
Ukrayna	54,1
Kore	30
Birleşik Krallık	20,9
İspanya	20,6
ABD	19,3
Rusya	18,3
Kanada	15,1
Almanya	14,3
Çin	2,9
Dünya Kalan	7,2
Dünya Toplam	10,6

Kaynak: IEA,2017, Key World Energy Statistics 2017, ss:19

Dünya nükleer enerji tüketimi ise Şekil 25'te görülmektedir. 2011 yılına kadar 600 TWh'in üzerinde bir düzeye sahip iken bu değer 2012 yılında 559.2 TWh'e düşmüştür. Fukuşima kazasından kaynaklı ülkelerin nükleer programlarını revize etmeleri ve askıya almaları bu düşüşte rol oynamaktadır. Ancak sonraki yıllarda trend yine artan yönlü olarak karşımıza çıkmaktadır.



Şekil 25. Yıllar Bazında Dünya Toplam Nükleer Enerji Tüketimi

Kaynak: BP, 2017, Statistical Review of World Energy 2017, s.41

2019 Yılı Ağustos Ayı itibariyle, 31 ülkede 450 nükleer reaktör işlem halindedir ve 52 adet nükleer reaktör ise 19 ülke bünyesinde inşa edilmektedir. Nükleer Güç Santrallerinden elde edilen elektrik Dünya elektrik arzının %10'una denk gelmektedir. Ülkeler bazında Fransa elektrik talebinin yaklaşık %72'sini, Ukrayna %53'ünü, İsveç %40'ını, Belçika %39'unu, Avrupa Birliği %28'ini, Güney Kore %24'ünü ve ABD %19'unu nükleer enerjiden karşılamaktadır. İnşa halindeki nükleer reaktörlerin 9'u Çin'de, 7'si Hindistan'da, 6'sı ise Rusya'dadır. Bunun yanında ABD'de 2, Birleşik Arap Emirlikleri'nde 4, Güney Kore'de 4, Fransa ve Türkiye'de 1'er nükleer reaktör inşa halindedir.

(ETKB, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Nukleer-Enerji> Erişim Tarihi: 09.18.2019).

Türkiye bu alanda uzun yıllara yayılan bir çaba sarf etmiştir. Bu çabalar sonucunda 12 Mayıs 2010 tarihinde Türkiye Hükümeti ile Rusya Federasyonu arasında Akkuyu Sahasında Bir Nükleer Güç Santralini Tesisine ve İşletimine Dair İşbirliğine İlişkin Anlaşma imzalanmıştır. 2023 yılında Akkuyu Nükleer Santralini ilk ünitesinin işletim aşamasına geçmesi hedeflenmektedir. Bir diğer çalışma ise Japonya Hükümeti ile 3 Mayıs 2013 tarihinde imzalanan Sinop Nükleer Santrali anlaşmasıdır (ETKB, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Nukleer-Enerji> Erişim

Tarihi: 12.12.2017). Enerji bağımlılığı konusunda büyük problem yaşayan ülkenin bu iki çalışmanın faaliyete geçmesi halinde bağımlılığını çok büyük oranda düşüreceği düşünülmektedir. Bu iki santralin faaliyete geçmesinden sonra üçüncü bir santral yapımıyla ilgili çalışmaların da yapıldı Enerji ve Tabii Kaynaklar Bakanlığı'nca dile getirilmektedir.

1.2 Enerji İletim Hatları / Enerji Ticaret Akışı

Dünyada fosil kaynaklı enerji rezervinin çok yüksek bir oranını barındıran Güney Akdeniz Bölgesi, Ortadoğu ülkeleri ve Hazar Havzasına komşu olan Türkiye, jeostratejik konumundan kaynaklı önemli avantajını, hem kendi enerji ihtiyacının bir kısmını karşılayarak hem de komşusu olduğu zengin bölgelerin enerji kaynaklarını dünya pazarlarına iletecek boru hattı projeleri geliştirerek en yüksek düzeyde faydalanmaya çalışmaktadır. Bununla beraber Türkiye'de Boru Hatlarıyla Petrol Taşıma Şirketi (BOTAŞ) enerji politikasına maksimum katkıyı sunmak için çeşitli ham petrol ve doğal gaz boru hattı projeleri güzerinde çalışmakta, geliştirmekte ve geliştirilen projelere de katılım sağlanmaktadır (BOTAŞ 2017: 31). Tedarikçi ülkelere ait konsorsiyumlarla yapmış olduğu anlaşmalar çerçevesinde projeler hayata geçirilmekte ve Türkiye'nin sıkıntı yaşamış olduğu enerji alanında gelişmelere imza atmaktadır.

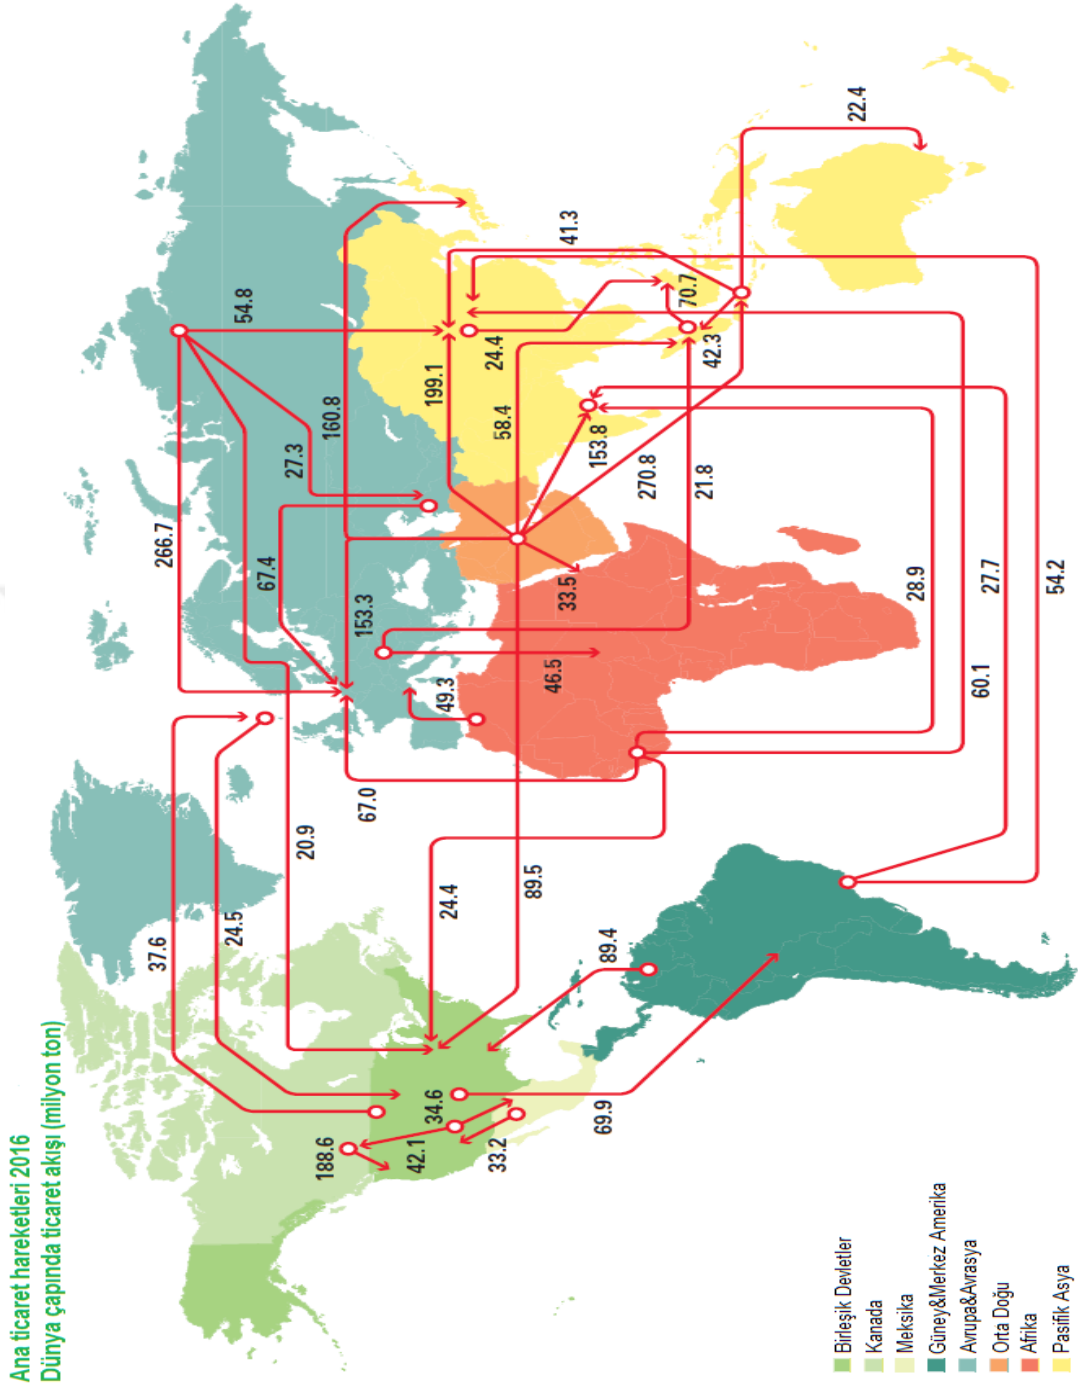
1.2.1 Petrol Taşımacılığı ve Petrol Boru Hatları

Küresel ölçekte 2015 yılında toplam 2035,9 milyon ton ham petrol ihraç edilmişken, 2016 yılı için bu değer 2117,8 milyon ton olarak gerçekleşmiştir. İşlenmiş petrolün 2015 yılındaki küresel ihraç değeri ise 1056,7 milyon ton iken, 2016 yılı için 1105,2 milyon ton değerinde gerçekleşmiştir. Petrol piyasasının net ihracatçıların Orta Doğu ve Rusya Federasyonu olduğu ticari akışlardan görülebilmektedir (BP 2017: 25) Petrolün üreticilerden tüketicilere ucuz ve güvenilir bir şekilde nakledilmesi önemli bir sorundur ve enerji arzının güvenliği için ele alınması gereken başlıca konulardan biridir (McMillan 2003: 15). Fosil kaynaklı yakıtlara olan bağımlılığın artarak devam etmesi ve rezerv lideri Ortadoğu'da mevcut olan istikrarsızlığın petrole dayalı enerji konusunun artan önemini gözler önüne sermektedir. Artan önemi dikkate alındığında petrol rezervinin bulunduğu ve

üretildiği bölgeler kadar alıcılara ulaştırılan güzergahlar ve ulaşım şekilleri de önem kazanmaktadır. Uluslararası olarak petrol iletimi boru hatları ile deniz yolunda tankerler ile ve kısa mesafelerde kara tankerleri ile gerçekleştirilebilmektedir (Akpınar 2005: 235).

Petrol arz eden bölgelerden, petrol talep eden bölgelere gerçekleşen dağıtım kanalı bizlere petrol kaynaklı ticaret akışını göstermektedir. 2016 yılı için dünya çapındaki ana ticaret akışı Şekil 26'da gösterilmektedir. Haritaya göre petrol akışının yoğun olarak Orta Doğu, Rusya Federasyonu ve Batı Afrika bölgelerinden dünya geneline doğru gerçekleştiği görülebilmektedir.





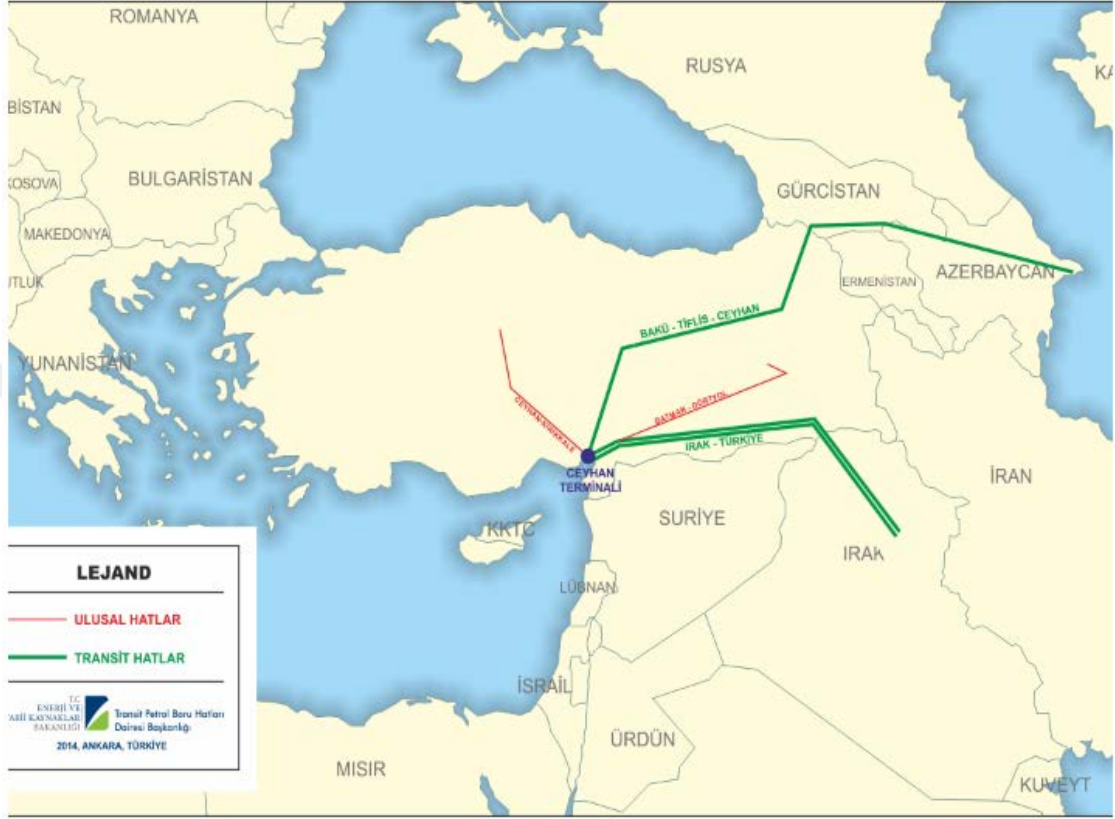
Şekil 26. Dünya Petrol Ana Ticaret Akışı

Kaynak: BP, 2017, Statistical Review of World Energy, 2017, s. 25

1.2.2 Türkiye Petrol Boru Hatları

Enerji bağımlılığı olan Türkiye, özellikle fosil kaynaklarda net ithalatçı konumdadır. Petrolün kara yoluyla taşımacılığı sağlanırken aynı zamanda Türkiye'nin içinde bulunduğu boru hatlarıyla da bu akış sağlanabilmektedir. 2016

yılı itibariyle Türkiye'nin sahip olduđu 2 adet transit petrol boru hattı mevcuttur ve Şekil 27'de görölmektedir. Türkiye petrol boru hatlarına ait özellikler ise Şekil 28'de görölebilmektedir.



Şekil 27. Türkiye Petrol Boru Hatları Haritası

Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı

	Kapasite		Uzunluk(km) / Çap(inç)			Pompa İst.	Tank Sayısı	
	milyon ton/yıl	milyon varil/yıl	Uzunluk		Çap			
Irak - Türkiye HPBH	70,9	553	Türkiye		40	6	12	
			Toplam					
			I. Hat	641				986
			II. Hat	656				890
Toplam			1.297	1.876				
Ceyhan - Kırıkkale HPBH	7,2	51	448		24	2	3	
Batman - Dört Yol HPBH	4,5	31,5	511		18	3	22	
BTC HPBH*	50	365	Türkiye	Toplam	34 - 42 - 46	4	7	
			1.076	1.776				

Şekil 28. Türkiye Petrol Boru Hatları Projeleri

Kaynak: BOTAŞ, 2017, Sektör Raporu 2016, s.21

Yıllık 70,9 milyon ton/yıl taşıma kapasitesine sahip olan Irak-Türkiye Ham Petrol Boru Hattı, Irak petrolünün İskenderun körfezine ulaştırılması amacıyla inşa edilmiştir. Kırıkkale Rafinerisinin ham petrol ihtiyacını karşılamak üzere inşa edilen ve uzunluğu 448 km, yıllık taşıma kapasitesi 7,2 milyon ton/yıl olan hat Ceyhan-Kırıkkale Ham Petrol Boru Hattı'dır. Türkiye'nin ilk boru hattı olan 511 km. uzunluğundaki 4,5 milyon ton/yıl taşıma kapasiteli Batman Dört Yol Ham Petrol Boru Hattı ise Batman ve çevresinde üretilen ham petrolün taşınması amacıyla inşa edilmiştir.

1.2.2.1 Irak - Türkiye Ham Petrol Boru Hattı / Kerkük – Yumurtalık Ham Petrol Boru Hattı

Petrol konusunda zengin olan Irak'ın, Kuzey Irak petrol yatakları diye adlandırılan bölge Musul ve Kerkük petrol yataklarını kapsamaktadır ve toplam rezervin yaklaşık olarak %80'inin Kerkük bölgesindeki yataklarda olduğu belirtilmektedir (Doğanay 1998: 310).

Kerkük-Yumurtalık Petrol Boru Hattı, Irak'ın özellikle Kerkük ve bununla beraber diğer üretim sahalarında üretilen ham petrolün Ceyhan Deniz Terminaline ulaştırılması amacıyla oluşturulmuştur. 25 Mayıs 1977 tarihinde ilk tanker yüklemesi

gerçekleşmiş olan hattın uzunluğu 986 km'dir. Bu boru hattına paralel olan ikinci hattın yapım aşaması 1985 yılında başlamış ve 1987 yılında tamamlanmıştır. Böylece yıllık taşıma kapasitesi 70,9 milyon tona yükseltilmiştir. (ETKB, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Petrol-Boru-Hatlari> Erişim Tarihi: 14.12.2017; BOTAŞ 2016: 21). Irak bu boru hatlarıyla Akdeniz'e ulaşarak dış dünyaya ihracatını gerçekleştirebilmektedir.

1.2.2.2 Bakü - Tiflis – Ceyhan (BTC) Ana İhraç Ham Petrol Boru Hattı

(BTC) Ham Petrol Boru Hattı ile başta Azerbaycanda üretilen petrol olmak üzere, Hazar Bölgesi petrolünün ekonomik ve çevresel açıdan uygun bir boru hattı sistemi aracılığıyla ve de emniyetli olarak Azerbaycan ardından Gürcistan üzerinden Ceyhan'a taşınması ve sonrasında buradan tankerlerle dünya pazarlarına ulaştırılması amaçlanmaktadır (ETKB, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Petrol-Boru-Hatlari> Erişim Tarihi: 26.12.2017). Petrol açısından çok zengin olan Ortadoğu'nun can damarlarından biri olan Hazar petrolünün uluslararası piyasalara ulaşması için güvenilir bir taşıma sistemi olmasının yanında, ucuz ve de sürdürülebilir bir enerji devri olarak bakılabilmektedir.

Azeri petrolünün uluslararası pazarlara taşınması 4 Haziran 2006 tarihinde Ceyhan İhraç Terminali'nden çıkan petrol tankeri ile gerçekleşmiştir. Bu proje kapsamında elde edilecek dolaylı kazançlar haricinde, geçiş vergisi ve işletmecilik hizmetleri dahilinde taşınacak kapasite göz önüne alınarak 16 yıllık bir süreçte 200 milyon dolar, sonrasındaki 23 yıllık dönemde ise 300 milyon dolar kadar gelir elde edileceği düşünülmektedir (<http://www.btc.com.tr/proje.html> Erişim Tarihi: 26.12.2017).

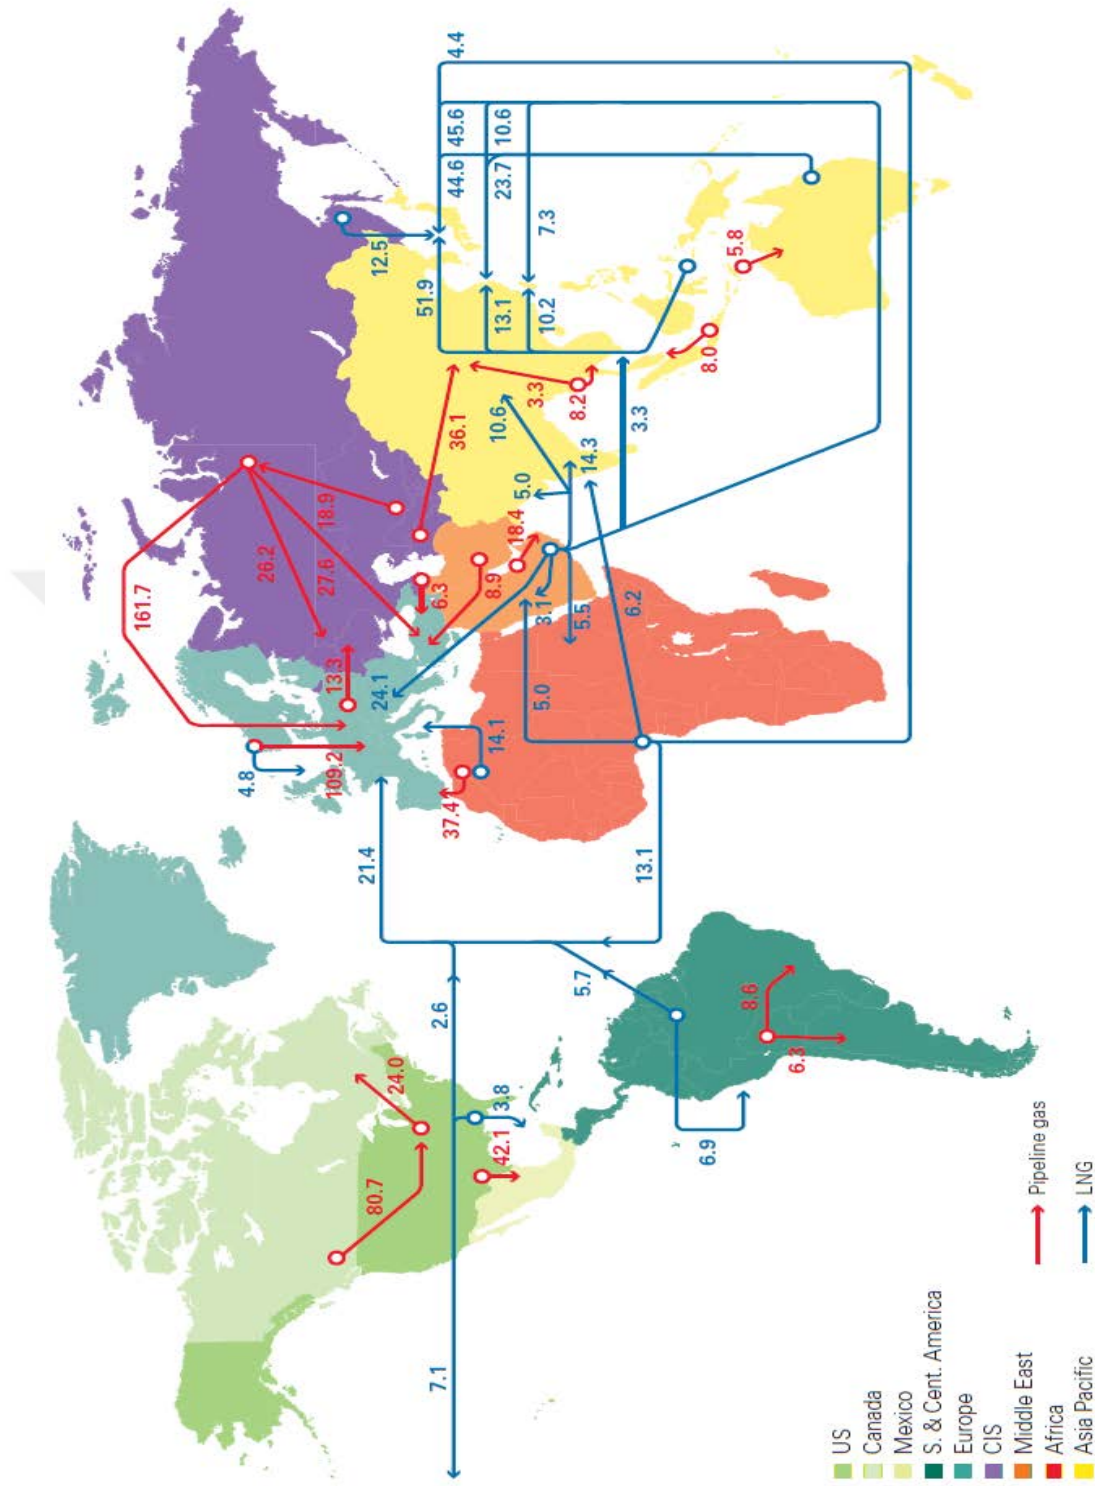
Türkiye BTC projesi ile Güney Kafkasya ve Orta Asya'yı, Türkiye ve Akdeniz'e bağlaması planlanan ve "Doğu-Batı Enerji Koridoru" olarak adlandırılan sağlam bir güvenlik koridoru oluşturarak Batı'nın çok önem verdiği "enerji arz güvenliği" açısından sağlam bir temel atılmasını garantilemiş olmaktadır. Ayrıca Türk boğazlarındaki aşırı trafik yükünden kaynaklanan geçiş risklerinin en aza indirilmesi açısından da BTC Türkiye için açık ve önemli bir avantaj sağlayacaktır (<http://www.btc.com.tr/proje.html> Erişim Tarihi: 26.12.2017).

Hattın Doğu-Batı güzergâhında stratejik bir öneme sahip olduğu görülebilmektedir. Bu hat ile Azerbaycan petrollerinin yanı sıra, Kazak ve Türkmen petrolleri de uluslararası pazara sürülebilmektedir.

1.2.3 Doğalgaz Taşımacılığı ve Doğalgaz Boru Hatları

Ülkelerin doğalgaz rezervine sahip olmalarının yanı sıra üretilecek doğalgazın pazarlanması ve pazarlara ulaştırılması da önemlidir. Örnek olarak, oldukça büyük doğalgaz rezervine sahip olan Türkmenistan, Hazar Denizi'nin statüsü henüz belli olmadığı için, Hazar Denizi'ni boru hattı ile geçememekte, diğer ülkelere doğrudan satış şansını bulamadığı için gazını boru hattı altyapısına sahip Rusya'ya düşük fiyatla satmak zorunda kalmaktadır (Kocaeren 2016: 208).

Piyasaya sunulan doğalgaz genellikle gaz fazında boru hatları ile taşınır. En yaygın doğalgaz taşıma yöntemi olan boru taşımacılığı 2000 km'den az mesafelerde sıvılaştırılmış doğalgaz taşımacılığından daha ekonomik bulunmaktadır (Kocaeren 2016: 208). Deniz yolu ile transferine bakıldığında doğalgazın transferinin ilk olarak sıvılaştırılmış doğalgaz (LNG) halinde 1964 yılında Cezayir'den İngiltere'ye taşındığı görülmektedir. Doğalgazda deniz taşımacılığının maliyeti oldukça yüksektir. Petrol ile kıyaslandığında taşıma maliyetinin 7 kata kadar fazla olduğu bilinmektedir (Demir 2007: 39). Dünya doğalgaz ticaret haritası Şekil 29'da görülebilmektedir.



Şekil 29. 2017 Küresel Doğalgaz Ticareti Haritası (Mm3)

Kaynak: BP, 2018, Statistical Review of World Energy, ss.35

Şekil 29’da da görüldüğü gibi küresel gaz akışı petroldekine benzer olarak yoğunlukla Rusya Fedderasyonu, Orta Doğu ve Batı Afrika bölgesinden gerçekleşmektedir.

Teknik açıdan petrol ile karşılaştırıldığında doğalgaz taşımacılığı daha zordur. Depolama maliyetleri ise petrole göre çok daha yüksektir. Zorluk ve maliyetlerin yüksekliği dikkate alındığında doğalgaz taşımacılığının en ucuz yolunun boru hatları ile taşımacılık olduğu kabul edilmektedir. Bu yöntem daha ucuz olarak tanımlansa da altyapının kurulma maliyeti oldukça yüksektir. Maliyetten kaçınmak için tedarikçiler ile alıcılar arasında uzun dönemli sözleşmeler imzalanmaktadır. Çok yüksek miktarda yatırıma neden olan boru hattı projelerinin bu yapısından dolayı yatırımı üstlenen, projeleri gerçekleştirebilen ve bu teknolojiye sahip olan; bunlarla beraber yapılan yatırımın maliyetini karşılayabilecek doğalgaz satışını sağlayabilen aktörler doğalgaz piyasasında çok güçlü konuma gelmekte ve hatta monopol durumuna yükselbilmektedir (Ericson 2009: 29).

Doğalgaz alım-satım anlaşmalarında, her iki taraf için doğalgaz sürekliliğinin sağlanması çok önemlidir. Doğalgazın yoğun olarak taşındığı boru hatları belli bir akış kapasitesi için tasarlanmakta, ancak bazen de yetersiz kalabilmektedir. Doğalgaza olan değişken talebi karşılayabilmenin en ekonomik yolu, talebin az olduğu yaz aylarında boru hatları ile ithal edilen gazın yer altı katmanlarında (akiferler, terk edilmiş doğalgaz ve petrol rezarvuarları, tuz mağaraları gibi) depolanmasıdır. Doğalgaz arz-talep trendi incelendiğinde mevsimsel olarak değişimin olduğu görülmektedir ancak buna rağmen doğalgaz alımı belli bir oranda devam eder. Bu durumda, doğalgaz talebinin az olduğu zamanlarda fazla gelip kullanılmayan gazın depolanarak talebin artışıyla beraber şebekeye verilmesi mümkün olabilmektedir (Kocaeren 2016: 208-209).



Şekil 30. Türkiye Doğalgaz Boru Hatları Haritası

Kaynak: T.C. Enerji ve Tabii Kaynaklar Bakanlığı

BOTAŞ'ın, Türkiye'nin doğal gaz ihtiyacını karşılayarak doğal gaz arz güvenliğini ve çeşitliliğini sağlayabilmek adına uzun dönemli doğal gaz alım satım anlaşmaları yapmıştır. Bu anlaşmalar (BOTAŞ 2017: 23);

- Rusya Federasyonu (Batı Hattı ve Mavi Akım) : 20 milyar m³/yıl,
- İran : 9,6 milyar m³/yıl,
- Azerbaycan (3 anlaşma toplamı) : 12,75 milyar m³/yıl,
- Türkmenistan : 15,6 milyar m³/yıl
- Cezayir : 4,4 milyar m³/yıl,
- Nijerya (LNG) : 1,3 milyar m³/yıl

şeklinde dir.

1.2.3.1 Rusya - Türkiye Doğalgaz Boru Hattı (Batı Hattı)

Türkiye'nin Rusya'dan doğalgaz satın almaya başladığı ilk hat, Rusya – Türkiye Doğalgaz Boru hattı'dır. Bu hat, Batı hattı olarak da bilinir. Doğalgaz Rusya'dan çıkarak sırasıyla Ukrayna, Moldova, Romanya ve Bulgaristan'ı geçmekte ve ardından Tekirdağ'dan giriş yaparak Türkiye'ye ulaşmaktadır. 1984 yılında

imzalanan 25 yıllık sözleşmeyle ve 1986 yılında inşasına başlanan hattın BOTAŞ aracılığıyla doğalgaz alınmaya başlanmıştır. 1993 yılında maksimum miktar olan 6 milyar m³/yıl'a ulaşılmıştır. BOTAŞ, 1998 yılında imzalanan 23 yıllık bir başka sözleşme imzalayarak doğalgaz alımını sürdürmüştür. 2008-2009 yılından itibaren Gazprom'un onay verdiği özel şirketler aracılığıyla ithalat gerçekleştirilmektedir. 845 km uzunluğunda olan Rusya-Türkiye Doğal Gaz Boru Hattı Türkiye'ye Bulgaristan sınırında Malkoçlar'dan girerek, Hamitabat, Ambarlı, İstanbul, İzmit, Bursa, Eskişehir üzerinden Ankara'ya ulaşmaktadır (Karakaya 2011: 2; Oğan 2003: 1; ETKB, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Dogal-Gaz-Boru-Hatlari-ve-Projeleri> Erişim Tarihi: 26.12.2017).

2017 Eylül döneminde Rusya Federasyonu'ndan diğer boru hatlarından nakiller de dâhil olmak üzere toplamda 2121,94 Milyon Sm³ boru gazı ithal edilmiştir. 2016 yılının aynı dönemi için bu miktar 1507,35 Milyon Sm³ olarak gerçekleşmiştir. Dönemler kıyaslandığında ülkeye toplam ithal edilen doğal gaz miktarında %40,77'lik bir pay artışı söz konusudur. Genel toplamda 2017 Eylül dönemi için pay %57,65 olarak sektör raporunda yer almaktadır (EPDK 2017d: 7-8). Bu da Rusya Federasyonu'nun doğalgaz tedarikçisi olarak Türkiye için ne kadar önemli olduğunu bize göstermektedir. Bu nedenle doğalgaz iletim hatları bu bağlamda daha da önemini artırabilmektedir.

1.2.3.2 Mavi Akım Doğalgaz Boru Hattı

Bölgedeki enerji yollarını yeniden şekillendiren önemli doğalgaz nakil projelerinden biri olan Mavi Akım, Rusya Federasyonu'ndan Türkiye'ye doğalgaz tedarik etmek için yapılan Karadeniz geçişli bir boru hattıdır (Aras 2001: 124). Mavi Akım Projesi, Rusya Federasyonu ile yapılan üçüncü doğal gaz alım anlaşmasıdır (Oğan 2003: 2).

Rusya Federasyonu ve Türkiye arasında 1988'de faaliyete geçen ve Ukrayna-Moldova-Romanya ve Bulgaristan hattını izleyen bir doğalgaz boru hattı olmasına rağmen bu hattın verimli çalışmaması, gönderilen doğalgaz miktarının istikrarsız oluşu ve ara ülkelerin haber vermeksizin Türkiye'ye gelen doğalgaz miktarını azaltmaları gibi nedenlerden dolayı Türkiye ve Rusya Federasyonu arasında doğrudan bir doğalgaz boru hattı döşenmesi fikri ortaya çıkmıştır (Aras 2001:123).

15 Aralık 1997 tarihinde BOTAŞ ve Gazexport arasında imzalanan 25 yıllık Doğal Gaz Alım-Satım Anlaşması kapsamında, yıllık 16 milyar m³ kontrat miktarı olan ve Rusya'dan Türkiye'ye doğal gaz akışını gerçekleştiren Mavi Akım Hattı Rusya Federasyonu içerisinde 370 km. uzunluğunda, Karadeniz geçişinde 390 km. uzunluğunda paralel 2 hat ve Türkiye topraklarında 501 km. uzunluğunda bir hat olmak üzere 3 ana bölümden oluşmaktadır. Hat Türkiye'de Samsun'dan başlayarak Amasya, Çorum, Kırıkkale güzergahı üzerinden Ankara'ya ulaşmaktadır ve devamında Malkoçlar-Ankara iletim hattı ile birleşmektedir. Söz konusu Mavi Akım Doğalgaz Boru Hattı'nın Rusya Federasyonu topraklarında kalan bölümü ile Karadeniz geçişinin finansmanı ve inşaatı GAZPROM Şirketi'nin, Türkiye bölümünün finansmanı ve inşaatı ise BOTAŞ'ın yükümlülüğünde gerçekleştirilmiştir (BOTAŞ 2017: 25; ETKB, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Dogal-Gaz-Boru-Hatlari-ve-Projeleri> Erişim Tarihi: 26.12.2017).

Mavi Akım doğalgaz boru hattı, Türkiye'ye istikrarlı doğal gaz tedarikinin sağlanması için önemli bir konumda yer almaktadır. Gazprom yetkilileri ile Türk yetkililerin görüşmeleri sonrası yapılan açıklamada; ticari gaz sevkiyatının başlamasından 2014 yılına kadar Mavi Akım üzerinden 110 milyar metreküp gazın iletildiği belirtilmiştir. Toplantı katılımcıları, bu rota üzerinden Rus gaz ihracatının giderek arttığını ve bu artış trendinin devam edebileceğini vurgulamışlar, bu bağlamda, Mavi Akım'ın kapasitesini 3 milyar metreküp genişletme konusunda karşılıklı karar almışlardır (Gazprom, <http://www.gazprom.com/press/news/2014/november/article207801/> Erişim Tarihi: 03.01.2018).

1.2.3.2.1 İran-Türkiye / Doğu Anadolu Doğal Gaz Ana İletim Hattı

8 Ağustos 1996 tarihinde Türkiye'nin ihtiyacı olan doğalgazı karşılamak amacıyla yıllık bazda 10 milyar m³ İran doğalgazının Türkiye'ye boru hattı ile taşınması için iki ülke arasında doğalgaz alım satım anlaşması imzalanmıştır. Anlaşmaya konu olan Doğu Anadolu Doğal Gaz Ana İletim Hattı yaklaşık olarak 1491 km uzunluğundadır. Çapı ise 48" ile 16" arasında değişmektedir. İletim hattı Doğubeyazıt'tan başlayarak Erzurum, Kayseri, Sivas ve Ankara'ya ulaşmakta, bu hatta bağlı olan başka bir kol da Kayseri'den ayrılarak Konya ve Seydişehir'e

uzanmaktadır (ETKB, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Dogal-Gaz-Boru-Hatlari-ve-Projeleri> Erişim Tarihi: 05.01.2018).

EPDK'nın yayınlamış olduğu 2017 Eylül Ayı sektör raporunda İran'dan ithal edilen boru gazı miktarının 530,54 Milyon Sm³, 2016 yılı aynı dönem için ise 518,60 Milyon Sm³ olduğu görülmektedir. İthal edilen toplam doğalgazda pay olarak %17,24'ten %14,41'e düşüş görülmektedir (EPDK 2017d: 7-8). İran'dan ithal edilen doğalgaz miktarı artmış olsa da Azerbaycan, Cezayir ve özellikle Rusya Federasyonu'ndan ithal edilen doğalgaz miktarları dâhil edilence pay olarak azalan ivme göstermesi normal olarak gözükmemektedir.

1.2.3.3 Bakü -Tiflis-Erzurum Doğalgaz Boru Hattı (BTE)

Azerbaycan doğalgaz arz kaynağı olarak karşımıza çıkan ve diğer adı *Uluslararası Güney Kafkasya Doğalgaz Boru Hattı* olan Bakü-Tiflis-Erzurum (BTE) Doğalgaz Boru hattı ile yıllık olarak toplam 6,75 milyar m³ doğalgazın Gürcistan güzergahı kullanılarak Türkiye'ye iletilmesi amacıyla inşa edilmiştir. İlk sevkiyat Azerbaycan Şah Deniz Faz I sahasından 2007 yılında gerçekleştirilmiştir. İletim hattının Türkiye'deki toplam uzunluğu 226 km'dir (BOTAŞ 2017: 25; Ener, Ahmedov 2008: 126).

Azerbaycan-Gürcistan-Türkiye güzergâhında bulunan bu doğalgaz boru hattı ile Avrasya bölgesinin hidrokarbon kaynaklarının dünya piyasasına ulaştırılmasında, önemli bir hat olarak karşımıza çıkmaktadır. Bu boru hattının esas amacı Şah Deniz sahasında üretilen doğalgazın Türkiye ve dünya piyasasına taşınarak kullanıma sunulmasıdır. BTC hattına paralel olarak yapılan bu boru hattının toplam uzunluğu 970 kilometredir. Yıllık kapasitesi 30 milyar m³'tür. 13 Mart 2007'de ilk Şah Deniz gazı bu hatta verilmiş, öncelikle Erzurum'a ulaşan gaz, sonrasında Türkiye'nin batısına, ardından ise Orta ve Güney Avrupa ülkelerine taşınmıştır (Ener, Ahmedov 2008: 126).

Bakü-Tiflis-Erzurum Doğalgaz Boru Hattı Şekil 31'de görülmektedir. Bakü-Tiflis-Ceyhan Petrol Boru Hattı'na paralel olan doğalgaz hattının toplam uzunluğu 980 km uzunluğunda olup, 42'' çapındadır. Boru hattı, yılda 20 milyar m³ doğalgaz pompalama kapasitesine sahiptir

(<http://socar.az/socar/en/activities/transportation/baku-tbilisi-erzurum-gas-pipeline>

Erişim Tarihi: 05.01.2018).



Şekil 31. Güney Kafkasya Doğal Gaz Boru Hattı (BTE)

Kaynak: <http://socar.az/socar/en/activities/transportation/baku-tbilisi-erzurum-gas-pipeline> , Erişim

Tarihi: 05.01.2018

1.2.3.4 Türkiye-Yunanistan Doğal Gaz Enterkoneksiyonu (ITG)

Türkiye'den Yunanistan'a iletimini gerçekleştirmek amacıyla Avrupa Birliği INOGATE² (Interstate Oil and Gas Transport to Europe) Programı kapsamında geliştirilen Güney Avrupa Gaz Ringi'nin ilk aşaması olan ve doğal gaz şebekelerinin enterkoneksiyonu olarak karşımıza çıkan doğalgaz boru hattıdır. Türkiye'nin iletimini gerçekleştireceği doğalgaza ait bu iletim hattı için Türkiye (BOTAŞ) ve Yunanistan (DEPA) arasında 23 Şubat 2003 tarihinde 15 yıllık süreci kasayan

² Bkz. Kılıçbeyli, 2002, s.109-110 : AB tarafından finanse edilen INOGATE Programı'nın genel amacı, petrol ve doğalgaz boru hattı sistemlerinin bölgesel entegrasyonunu teşvik ederek ve hem bölgede hem de Avrupa ihracat pazarlarına doğru ulaşımını kolaylaştırarak Avrupa'nın enerji arz güvenliğini artırmak ve özel sektörü çekmek için bir katalizör olarak hareket etmektir. Yatırımcılara ve uluslararası finans kurumlarına bu boru hattı projelerini sunmaktır. Teknik yardım programı olan INOGATE, diğer teknik yardım programlarıyla aynı şekilde çalışır. Ancak, bölgesel işbirliği perspektifinden konuları ele alışından dolayı farklılık göstermektedir. Aynı zamanda INOGATE, AB'nin teknik yardım programı kapsamında, SSCB'nin dağılmasından sonra bağımsızlık ilan eden cumhuriyetler arasındaki enerji temelinde bölgesel ilişkileri iyileştirmek için uygulanan bir program olarak karşımıza çıkmaktadır.

hükümetlerarası bir anlaşma imzalanmıştır. Doğalgazın ilk akışı ise 18 Kasım 2007 tarihinde gerçekleşmiştir (ETKB, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Dogal-Gaz-Boru-Hatlari-ve-Projeleri>, Erişim Tarihi: 05.01.2018).

1.2.3.5 Trans – Anadolu Doğalgaz Boru Hattı Projesi (TANAP)

Hidrokarbon rezervi olarak zengin olan Azerbaycan'ın doğalgaz kaynağının Türkiye'ye ve sonrasında Türkiye üzerinden enerji talep eden Avrupa ülkelerine nakledilmesi amaçlanarak; Türkiye (BOTAŞ) ve Azerbaycan (SOCAR) arasında Şah Deniz Konsorsiyumu Faz 2 Projesi kapsamında Azerbaycan'ın üreteceği doğalgazın yıllık olarak 6 milyar m³'ünü Türkiye'ye, 10 milyar m³'ünü ise Avrupaya iletilebilmesi için 24 Aralık 2011 tarihinde hükümetlerarası anlaşma imzalanmıştır (BOTAŞ 2017: 31).

Trans - Anadolu Doğal Gaz Boru Hattı Projesi (TANAP) Türkiye ve Avrupa Birliği ülkelerinin arz çeşitliliğini ve enerji arz güvenliğini sağlamak için önemli bir proje olarak karşımıza çıkmaktadır. TANAP projesi kapsamında 2018 yılında Türkiye'ye gaz akışı başlatılması planlanmaktadır. Başlangıç kapasitesi yılda 16 milyar m³'e, kademeli olarak 24 milyar m³'e, daha sonra 31 milyar m³'e ulaşacaktır. 1850 kilometrelik uzun TANAP hattı Trans Adriyatik Doğal Gaz Boru Hattı'na (TAP) bağlanarak ve 2020'nin başında Güney Kafkasya Boru Hattı'ndan (SCP) Yunanistan, Arnavutluk ve İtalya'ya doğalgaz tedarik edileceği düşünülmektedir. TANAP, Ardahan'ın Posof ilçesi, Türk-Gürcü sınırındaki Türkgözü köyünden Ardahan, Kars, Erzurum, Erzincan, Bayburt, Gümüşhane, Giresun, Sivas, Yozgat, Kırşehir ve Kırgızistan'dan 20 il, 67 ilçe ve 600 köyden geçerek, Kırıkkale, Ankara, Eskişehir, Bilecik, Kütahya, Bursa, Balıkesir, Çanakkale, Tekirdağ ve Edirne'de, Türk-Yunan sınırında Edirne İpsala ilçesine kadar devam edecek ve bu noktadan itibaren Trans-Adriyatik Boru Hattı (TAP) ile birleşecektir (<http://socar.az/socar/en/news-and-media/news-archives/news-archives/id/8232> Erişim Tarihi: 09.01.2018). Şekil 32'de Şah Deniz-II, TANAP ve TAP'ın güzergahı görülebilmektedir.



Şekil 32. TANAP - TAP Doğalgaz Boru Hatları

Kaynak: <https://report.az/en/energy/55-work-of-tanap-project-completed/> Erişim Tarihi: 09.01.2018

1.2.3.6 TürkAkım Gaz Boru Hattı Projesi

TürkAkım Gaz Boru Hattı Projesi tedarikçisi Rusya Federasyonu olan Karadeniz üzerinden kıyısındaki alım terminallerine ve ülke topraklarına ulaşan iki hattan meydana gelen bir doğalgaz boru hattıdır. Her bir hattın kapasitesi yıllık 15,75 milyar m³ olmasıyla beraber toplam doğalgaz akış kapasitesi 31,5 milyar m³'tür (<http://www.enerji.gov.tr/tr-TR/Sayfalar/Dogal-Gaz-Boru-Hatlari-ve-Projeleri> Erişim Tarihi: 09.01.2018).

TürkAkım Gaz Boru Hattı Projesi'ne ait hükümetlerarası anlaşma; ekonomik, teknik ve hukuki anlamda çerçeveyi belirlemek ve politik desteği elde etmek amacıyla Türkiye Cumhuriyeti Hükümeti ile Rusya Federasyonu Hükümeti arasında 10 Ekim 2016 tarihinde İstanbul'da Türkiye Cumhurbaşkanı Recep Tayyip ERDOĞAN ve Rusya Devlet Başkanı PUTİN'in huzurlarında imzalanmıştır. (<http://www.enerji.gov.tr/tr-TR/Sayfalar/Dogal-Gaz-Boru-Hatlari-ve-Projeleri> Erişim Tarihi: 09.01.2018).

Bu proje sadece Türkiye'nin ihtiyacı olan doğalgazı tedarik etmenin yanı sıra, Rus kaynağının Türkiye üzerinden Avrupa'ya naklini de sağlayacaktır.

Enerji bakanlığının projeye dair yapmış olduğu açıklamaya göre, “Rusya Federasyonu ve Ukrayna arasında yaşanan doğal gaz anlaşmazlıkları Batı Hattı'ndan Türkiye'ye arz edilen gazın zaman zaman kesilmesine neden olmakta ve bu durum özellikle kış aylarında ülkenin enerji arz güvenliğini tehlikeye sokmaktadır.

Türk Akım kapsamında sadece Türkiye'ye gaz arz etmesi amacıyla inşa edilecek boru hattının devreye alınması ile birlikte Batı Hattı'ndan alınan yıllık toplam 14 milyar m³ gazın, mevcut sözleşmelerin şart ve koşulları değişmeksizin Türk Akımı üzerinden Türkiye'ye teslim edilmesi planlanmaktadır. Böylece başka bir ülkenin iletim sistemi kullanılmadan doğrudan Rusya Federasyonu'ndan Türkiye'ye taşınacak gazın, üçüncü taraflardan kaynaklı muhtemel kesintilere maruz kalmaması sağlanmış olacaktır” (<http://www.enerji.gov.tr/tr-TR/Sayfalar/Dogal-Gaz-Boru-Hatlari-ve-Projeleri> Erişim Tarihi: 09.01.2018). Bu da projenin Türkiye açısından önemini göstermektedir.

TürkAkım projesi Türkiye ve Rusya Federasyonu temelli görünse de doğrudan ya da dolaylı olarak bu proje bir çok ülkeyi ilgilendirmektedir. Türkiye'nin devamında Avrupa'ya iletilecek doğalgaza ait projede Türkiye ve Rusya'nın yanı sıra Yunanistan, Makedonya, Sırbistan gibi ülkelerin de yer alması beklenmektedir (Karagöl, Kızılkaya 2015: 4). Türk Akımı Türkiye'nin yanı sıra Güney ve Güneydoğu Avrupa'ya olan gaz arzının güvenilirliğini de önemli ölçüde artıracaktır (<http://www.gazprom.com/about/production/projects/pipelines/built/turk-stream/>. Erişim Tarihi: 09.01.2018).

AB ülkeleri içinde projeden en çok etkilenecek ülkenin Yunanistan olacağı düşünülürken, (Karagöl ve Kızılkaya, 2015: 4), hattın güzergâh konusunda önemli bir değişiklik gündeme gelmiştir. Buna göre hat, Türkiye'den çıktıktan sonra Yunanistan yerine Bulgaristan'a giriş yapacak ve sonrasında da Bulgaristan, Romanya, Macaristan üzerinden Avusturya'ya ulaşacaktır. (<http://enerjienstitusu.com/2017/12/15/turk-akiminin-guzergahi-degisti/> Erişim Tarihi: 09.01.2018). Diğer yandan bu proje ile ilgili çalışmalar devam etmektedir (BOTAŞ 2017: 31).

19 Kasım 2018 tarihinde deniz kısmı tamamlanan TürkAkım projesinin açılışı Türkiye ve Rusya Federasyonu devlet başkanlarının katılımıyla Türkiye'de gerçekleşmiştir. İki ülke arasında gerçekleşen siyasi çatışmalar, uçak krizi, büyükelçi Karlov cinayeti ve Suriye'deki savaşta karşı karşıya gelme, ABD'nin Rusya Federasyonu'na karşı Avrupa'yı yanına çekmeye çalışması gibi problemler çıksa da proje adının “TürkAkım” olmasının ve tüm olumsuzluklara rağmen projenin

tamamlanıp açılış gerçekleştirilmesinin Türkiye'ye duyulan güven için bir işaret olduğu düşünülebilir. Şekil 33'te TürkAkım Doğalgaz Boru Hattı'nın güzergahı görülebilmektedir.



Şekil 33. TürkAkım Doğalgaz Boru Hattı Projesi

Kaynak: <http://www.gazprom.com/about/production/projects/pipelines/built/turk-stream/> Erişim Tarihi: 09.01.2018



İKİNCİ BÖLÜM

2.KÜRESEL ENERJİ SEKTÖRÜ AKTÖRLERİ VE TÜRKİYE

2.1 Küresel Enerji Üretimi Trendleri

Dünya enerji üretimi, 2015 yılında 2014'e göre % 0,6 artarak 13.790 Mtoe olarak gerçekleşmiştir. Enerji artışı payında yer alan petrol kaynağının üretimi % 2,3 artmış, bunu yenilenebilir kaynaklar % 1.9 oranında, doğalgaz ve nükleer kaynaklar ise her biri % 1.4 oranında artarak takip etmiştir. Fosil kaynaklı yakıtlarda 2014 yılında keskin bir düşüş yaşayan kömürün üretim telafisi petrol ve doğal gazdaki büyüme ile karşılanmıştır (IEA 2017c: 3).

Fosil olmayan kaynaklar arasında biyoyakıtlar ve atıklar 2015 yılında dünya enerji üretimindeki payını % 9,6 oranla gerçekleştirerek ve 2014'teki %9,5'lik oranına kıyasla korumuştur ancak 2012, 2013 ve 2014 teki artış trendlerine nazaran yavaş bir gelişme göstermiştir. Hidrolik enerji, 2015 yılında % 0,5 oranında hafif bir düşüşle 1989'dan beri küresel üretimdeki ilk düşüşünü göstermiştir. Bununla birlikte, hidrojen, sadece 2014'teki % 2,4'lük bir küresel üretim sağlamıştır (IEA 2017c: 3) .


Bununla beraber rüzgâr (%16,8), güneş solar (%6,8), güneş fotovoltaik (%29,7) ve jeotermal (%4,1) gibi diğer yenilenebilir kaynaklar hızlı bir şekilde büyümeyi sürdürmüştür (IEA 2017c: 3).

Son olarak, 2015'te 2014'e göre %1,4 artış göstererek nükleer kaynak enerji üretiminde payını % 4,9 çıkarmıştır (IEA 2017c: 3).

2016 yılı için küresel olarak ülkeler düzeyinde üretim verileri fosil yakıtlarla sınırlı olarak elde edilmiştir. Bu verilere dayanarak, fosil yakıtların 2016 yılı için üretim artışı önemli ölçüde azalmış ve bu değer 2015'e göre % -1.3 olarak gerçekleşmiştir. Düşüşün nedeni; 2016 yılında tamamen kömür üretimindeki düşüşün % -4,5 olmasından kaynaklanmaktadır (2015 yılında ise bu değer % -2,6'dır). Kömür üretiminin aksine ham petrol ve doğal gaz üretimi 2015 ve 2016 yılında artış göstermiştir (IEA 2017c: 3).

Kömür üretiminin en belirgin olarak düşüş gösterdiği bölgeler OECD ülkeleri (%10'dan fazla düşüşle, -95 Mtoe) ve Çin (neredeyse % -6 olarak, -110 Mtoe) olmuştur. Doğal gaz üretimi 2016 yılında, üretimi 1080 Mtoe olarak gerçekleşen OECD bölgesi haricinde tüm bölgelerde artış göstermiştir. Ham petrol ise 2016 yılındaki OECD (% -2,7) ve Afrika'da (% - 6,9) gerçekleşen üretim düşüşünü Ortadoğu (% 6,3) ve OECD dışı Avrupa ve Avrasya ülkelerinde (% 1,2) üretim artışıyla telafi etmiştir (IEA, 2017c: 3-4).

Bu açıklamalara ek olarak dünyada gerçekleşen enerji üretiminin yıllara göre ortalama değişimi Şekil 34'te görülmektedir.




Şekil 34. Küresel Enerji Üretiminin Kaynaklarına Göre Yıllık Ortalama Değişimi

*Turba ve bitümlü şist, kömüre dâhil edilmiştir.

** Jeotermal, güneş enerjisi, güneş fotovoltaği ve rüzgâr enerjilerini içerir.

Kaynak: International Energy Agency, 2017, World Energy Balances: Overview (2017 Edition), s. 3

Şekil 35'de fosil yakıt üretiminin dünyadaki yıllık ortalama değişimi görülebilmektedir. Şekle göre petrol ve doğalgazda 2014 ve 2015'e göre 2016 yılında üretim artışı gözlemlenirken kömür de üretim düşüklüğü gözlemlenmektedir.



Şekil 35. Dünya Fosil Yakıt Üretiminde Yıllık Ortalama Değişim

*Turba ve bitümlü şist, kömüre dâhil edilmiştir.

Kaynak: International Energy Agency, 2017, World Energy Balances: Overview (2017 Edition), s. 4

2.1.1 Petrol Üreticileri, Tedarikçileri ve Alıcıları

Fosil yakıtlardan olan petrol, enerji elde ediminde hala etkinliğini koruyan bir kaynak olarak karşımıza çıkmaktadır. Küresel enerji üretimi trendlerinde de görüldüğü gibi petrol üretimi artan bir eğilimle devam etmektedir (Bkz: Şekil 34 ve Şekil 35). Küresel petrol piyasasının aktörleri ise genellikle stabil kalmaktadırlar. İstisna olarak rezervler açısından zaman içerisinde liderlik konusunda farklılıklarla karşılaşılabilir. Örnek olarak 2010 yılında rezerv bakımından 10. Sırada yer alan Venezuela, 2011 yılında 211 milyar varil rezerv ile 2. sıraya yükselmiş, 2013 yılında ek rezervlerin bulunarak miktarın 298 milyar varile yükselmesi ile 1. sıraya yükselerek bir önceki yıl 264 milyar varil rezerve sahip olan Suudi Arabistan'ı geride bırakmıştır. 2016 itibariyle Venezuela'nın sahip olduğu rezerv miktarı 300 milyar varildir³.

BP'nin 2018 Şubat ayında açıkladığı dünya petrol talebi projeksiyonunda; 2016 yılında dünyadaki benzinle çalışan araçların toplam günlük tüketimi 18,7

³ Bkz: İstatistikler için Energy Information Administration'ın internet sayfasında bütün sıralamalar görülmektedir. Dünya rezerv miktarları için https://www.eia.gov/beta/international/rankings/#?product=57-6&iso=VEN&pid=57&aid=6&tl_id=6-A&tl_type=a&cy=2016 bakınız. Türkiye bu sıralamada 3 milyon varille 53. sırada yer almaktadır.

milyon varil iken 2040 senesinde bu miktarın elektrikle çalışan araçların artmasına rağmen aynı seviyede kalacağını açıklamıştır (BP 2018: 3).

Küresel ölçekte 2016 yılında ilk 10 sırada yer alan petrol üreticileri, net ihracatçıları ve net ithalatçıları ile ülkelere ait üretim ve tüketim verileri Tablo 9’da görülmektedir.

Tablo 9. 2016 Dünya Petrol Üreticileri (2016)

Üreticiler	Miktar (Mt)	Pay (%)
Suudi Arabistan	583	13,5
Rusya Federasyonu	546	12,6
Amerika Birleşik Devletleri	537	12,4
Kanada	220	5,1
İran	200	4,6
Çin Halk Cumhuriyeti	200	4,6
Irak	191	4,4
Birleşik Arap Emirlikleri	182	4,2
Kuveyt	159	3,7
Brezilya	135	3,1
Dünya Kalan	1368	31,8
Dünya Toplam	4321	100

Kaynak: International Energy Agency, 2017, Key World Energy Statistics, ss. 13

Tablo 9’da da görüldüğü gibi petrol üretiminde Dünya liderliği Suudi Arabistan’dadır. Yakın bir oranla takipçisi ise Rusya Federasyonu’dur. Üretimde ilk 10 sırada yer alan ülkelerin üretim toplamı diğer ülkelerdeki üretim toplamının 2 katından daha fazladır.

Dünya genelinde 2015 yılı için petrol üreten ülkeler, petrol tüketim miktarları ve tüketim fazlalıkları Tablo 10’da görülebilmektedir.

Tablo 10. 2015 Yılı Ülkelerin Günlük Petrol Üretim, Tüketim ve Tüketim Fazlası
(Bin Varil)

Ülkeler	Üretim Miktarı (Bin Varil/Gün)	Tüketim Miktarı (Bin Varil/Gün)	Tüketim Fazlası (Bin Varil/Gün)
Suudi Arabistan	11986	3868	8118
Rusya Federasyonu	10981	3137	7844
Amerika Birleşik Devletleri	12757	19531	-6774
Irak	4031	788	3243
Kanada	4389	2299	2090
İran	3897	1850	2047
Çin Halk Cumhuriyeti	4309	11986	-7677
Birleşik Arap Emirlikleri	3928	926	3002
Kuveyt	3068	506	2562
Brezilya	2525	3170	-645
Venezuela	2644	648	1996
Nijerya	2329	325	2004
Norveç	1948	238	1710
Angola	1826	142	1684
Katar	1890	316	1574
Kazakistan	1695	289	1406
Cezayir	1558	425	1133
Umman	981	181	800
Kolombiya	1006	333	673
Birleşik Krallık	963	1565	-602
Endonezya	841	1592	-751
Azerbaycan	840	99	741
Hindistan	876	4164	-3288
Mısır	726	830	-104
Malezya	699	814	-115
Ekvator	543	254	289

Arjantin	641	692	-51
Libya	432	259	173
Tayland	468	1355	-887
Vietnam	362	407	-45
Ekvator Ginesi	289	5,2	283,8
Türkmenistan	261	147	114
Kongo Cumhuriyeti	257	30	227
Gabon	230	21	209
Güney Sudan	148	11	137
Sudan	109	113	-4
Çad	73	2,2	70,8
Romanya	83	191	-108
Tunus	65	100	-35
Özbekistan	57	57	0
Suriye	27	139	-112
Yemen	44	100	-56

Kaynak: BP, 2017, Statistical Review of World Energy, ss. 14-15 ve EIA, International Energy Statistics, Petroleum Consumption 2015, <https://www.eia.gov/beta/international/rankings/#?product=5-2&cy=2015> (Erişim Tarihi: 20.02.2018)

Üretici ve tüketim fazlası olan ülkeler arasında coğrafi olarak Türkiye'ye yakın olan ülkelerin sayıca fazla olması alıcı olarak Türkiye'yi güçlü bir pozisyonda koruyan bir durumdur. Petrol'de Orta Doğu'nun lider konumda olması ve Türkiye'nin lider pozisyonundaki Orta Doğu ile Avrupa gibi alıcılar arasındaki terminal olması bu etkin pozisyondaki nedenlerden biridir. Suudi Arabistan, Irak, İran, Birleşik Arap Emirlikleri, Kuveyt, Katar, Umman gibi ülkeler bu tedarikçilere örnek olarak yine Tablo 10'da görülebilmektedir.

Rusya Federasyonu, Azerbaycan, Kazakistan, Türkmenistan, Özbekistan gibi Avrasya Ülkeleri ise diğer bir potansiyel tedarikçi grubu olarak karşımıza çıkabilmektedir.

Bununla beraber üretici konumunda ve tüketim fazlası olan bir diğer bölge ise Afrika Bölgesi'dir. Bunlar Cezayir, Mısır, Libya, Nijerya, Angola, Sudan, Güney Sudan ve Çad gibi ülkelerin yer aldığı gruptur.

Tablo 11'de küresel olarak en güçlü petrol tedarikçileri yer almaktadır. Venezuela ve Kanada haricindeki diğer ülkelerin Türkiye'ye coğrafi olarak çok yakın olması Türkiye açısından büyük bir avantajdır.

Tablo 11. Petrol İhraç Eden Ülkeler (2015)

Net İhracatçılar	Miktar (Mt)
Suudi Arabistan	369
Rusya Federasyonu	243
Irak	148
Birleşik Arap Emirlikleri	125
Kanada	116
Nijerya	104
Kuveyt	100
Venezuela	98
Angola	86
İran	64
Diğerleri	539
Dünya Toplam	1992

Kaynak: International Energy Agency, 2017, Key World Energy Statistics, ss. 13

Tablo 12'de net tüketici ülkeler görülmektedir. Alıcı olarak net tüketici konumunda olmak enerji arzının sürdürülebilirliği konusunda dezavantaj olarak karşımıza çıkmaktadır.

Tablo 12. Petrol İthal Eden Ülkeler (2015)

Net İthalatçılar	Miktar (Mt)
Amerika Birleşik Devletleri	348
Çin Halk Cumhuriyeti	333
Hindistan	203
Japonya	165
Kore	139
Almanya	91
İtalya	67
İspanya	65
Hollanda	59
Fransa	57
Diğerleri	514
Dünya Toplam	2041


Kaynak: International Energy Agency, 2017, Key World Energy Statistics, ss. 13

2.1.1.1 Türkiye'nin Petrol Görünümü

Rusya, Ortadoğu, Hazar Ülkeleri gibi petrol rezervleri ispatlanmış ihracatçı ülkeler ile ithalat bağımlılığı olan AB ülkeleri gibi tüketiciler arasındaki geçiş köprüsü olması nedeniyle Türkiye çok önemli bir konuma sahiptir. Arz ve talebi buluşturma kabiliyeti olması stratejik önemini çok artırmaktadır. Bununla beraber kendisinin de yoğun enerji talebinde bulunuyor olması elindeki bu avantajı gölgede bırakabilmektedir.

Türkiye Petrolleri Anonim Ortaklığı tarafından yayınlanan ham petrol ve doğal gaz sektör raporuna (2017) göre 2015 yılı için günlük olarak Türkiye'de yaklaşık 51 bin varil üretimi gerçekleştirilmiştir. Tüketim ise günlük olarak 835 bin varil olmuştur. İthalat rakamları ham petrol için günlük 503 bin varil, işlenmiş petrol ürünü 242 bin varildir. 2015 yılı için bir önceki seneye göre işlenmiş petrol ürünü ithalatı azalmış ancak ham petrol ithalatı ve ham petrol tüketimi artmıştır. Aynı yıl için yerli ham petrol üretiminin toplam tüketime oranı ise %6,4'tür. Petrol kaleminde dışa bağımlılığın düzeyi bu oranla açık bir şekilde görülebilmektedir.

Rapora göre Türkiye'nin 2007-2016 yılları arası petrol üretim ve ithalat değerleri Şekil 36'da gösterilmektedir.




Şekil 36. 2007 2016 Yılları Arası Türkiye Yerli Petrol Üretimi ve Petrol İthalatı (Bin Varil/Gün)

Kaynak: TPAO, 2017 Ham Petrol ve Doğal Gaz Sektör Raporu, s. 37

Şekil 36'da görüldüğü gibi 10 yıllık aralıkta yerli olarak petrol üretimi ham petrol ve diğer ürün ithalatının yanında çok düşük bir seviyede gerçekleşmiştir. Petrol kaynağı konusunda Türkiye'nin dışarıya çok yüksek bir oranda bağımlı olduğu verilerden görülmektedir.

Enerji ve Tabii Kaynaklar Bakanlığının verilerine göre 2017 yılı için ilk 6 ayda toplam olarak Türkiye'de 1,3 milyon ton ham petrol üretilmiştir. Üretim sonucunda yerli üretilen bilinen petrol rezerv miktarı ise 48 milyon ton'dur. Bu rakamlar kapsamında yeni petrol kaynakları bulunmaması halinde aynı üretim seviyesi korunduğu takdirde 18 yıllık bir rezerv ömrü bulunmaktadır. Aynı yıl için toplam petrol tüketiminin %7,7'lik kısmı yerli üretimle karşılanırken kalan %92,3'lük kısım ise ithal ürünle karşılanmıştır (ETKB 2017c).

2006-2015 yılları arasında Türkiye petrol tüketimi ise Şekil 37'deki gibidir. Yıllar itibariyle genel olarak petrol tüketiminin artış gösterdiği görülebilmektedir.



Şekil 37. Türkiye'nin 2006 2017 Yılları Arasındaki Petrol Tüketimi (Bin Varil/Gün)

Kaynak: TPAO, 2017 Ham Petrol ve Doğal Gaz Sektör Raporu, s. 36

2016 yılında 2015 yılına göre toplam rafineri petrol üretimi %3,11 artarak 28.71.203 tona yükselmiştir. Motorin türlerinde de %12,60'lık bir değer artışıyla üretim 9.587.347 tona ulaşmıştır. Benzin türlerinin üretimi diğerlerinin aksine %0,22 oranında azalmış ve 5.101.861 tona gerilemiştir. Havacılık yakıtları üretiminde ise azalış değeri daha yüksektir. Bu oran %10,70 olarak gerçekleşerek üretim 4.486.633'e gerilemiştir (EPDK 2017e: V).

Toplam petrol ürünleri ithalatı 2016 yılında bir önceki seneye göre %1,09 artmış ve 40.064.001 tona yükselmiştir. Ham petrol ithalatı ise %0,43'lük bir azalışla 24.957.985 tona gerilemiştir. Motorin türleri ithalatı %4,03 artarak 12.370.935 tona, havacılık yakıtları ithalatı ise %105,23 lük gibi büyük bir oran artışıyla 341.235 tona yükselmiştir (EPDK 2017e: V).

İhracatta 2016 yılında 2015 yılına göre genel itibariyle bir düşüş görülmektedir. Toplam petrol ürünleri ihracatı %10,34 azalarak 9.688.515 tona, benzin türleri ihracatı %7,30 azalarak 2.888.063 tona, Havacılık yakıtları ihracatı %6,09 azalarak 3.528.546 tona gerilemiştir. Petrol, benzin ve havacılık yakıtlarının

aksine; motorin türleri ihracatı %159,41 artarak 71.405 tona yükselmiştir (EPDK 2017e: V).

Yurt içi satış değerlerine bakıldığında Türkiye net olarak tüketici konumunda olmayı sürdürmektedir. 2016 yılında 2015 yılına göre; toplam petrol ürünleri satışları %7,62 artarak 26.716.335 tona yükselmiştir. Benzin türleri ise %6,52'lik bir artışla gerçekleşerek 2.234.045 ton olarak satış gerçekleşmiştir. Motorin türleri satışları %8,55 artarak 22.322.574 tona yükselmiş, havacılık yakıtları satışları %1,38 artarak 1.337.418 ton olarak gerçekleşmiştir (EPDK 2017e: V).

2.1.2 Doğalgaz Üreticileri, Tedarikçileri ve Alıcıları

Küresel çapta kanıtlanmış gaz rezervleri 2016 yılında, 1,2 trilyon metreküp (tm^3) gibi % 0,6'lık bir oranda çok az bir yükselişle 186,6 tm^3 kadar yükselmiştir. Petrolde olduğu gibi, bu rezerv miktarı 50 yıldan daha fazla süreliğine (52.5 yıl) mevcut üretimi karşılamak için yeterlidir. 2016'daki büyümenin ana katkısını ise Myanmar (+0,7 tm^3) ve Çin (+0,06 tm^3) gerçekleştirmiştir (BP <https://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy/natural-gas/natural-gas-reserves.html>, Erişim Tarihi: 01.03.2018).

Bölgelere göre, en büyük kanıtlanmış rezervler toplam 79,4 tm^3 Orta Doğu'da bulunmaktadır ve bu miktar küresel toplamın %42,5'ine denk gelmektedir. Rezerv miktarında lider ülke İran'dır. İran'da mevcut doğalgaz rezervi küresel toplamın %18'ini temsil etmekte ve bu miktar 33,5 tm^3 olarak kayıtlarda yer almaktadır (BP, 2017: 26). Bu verilerle beraber tüketici sınıfı doğalgaz olarak tanımlanan katı doğal gaz üreten ve tüketen ülkeler Tablo 13'te gösterilmektedir. Üretici ülkelerin aynı zamanda tükettiği doğalgaz miktarları da tablolara eklenmiştir. Bu tablolar aracılığıyla doğalgaz piyasasında tedarikçi ve alıcı olan bütün ülkeler görülebilmektedir.

Tablo 13. Ülkeler Bazında Kuru Doğal Gaz* Üretim, Tüketim ve Tüketim Fazlası Miktarları (2015)

Ülkeler	Üretim Miktarı (Milyar m ³)	Tüketim Miktarı (Milyar m ³)	Tüketim Fazlası (Milyar m ³)
Amerika Birleşik Devletleri	27059	27306	-247
Rusya Federasyonu	21141	14794	6347
İran	6526	6568	-42
Katar	5794	1451	4343
Kanada	5295	4053	1242
Çin Halk Cumhuriyeti	4487	6575	-2088
Norveç	4139	185	3954
Suudi Arabistan	3614	2459	1155
Türkmenistan	2965	1533	1432
Cezayir	2933	1399	1534
Endonezya	2571	1501	1070
Avustralya	2373	1407	966
Malezya	2240	1120	1120
Birleşik Arap Emirlikleri	2125	2459	-334
Özbekistan	1967	1700	267
Hollanda	1935	1409	526
Nijerya	1594	665	929
Mısır	1565	1693	-128
Birleşik Krallık	1460	2544	-1084
Trinidad ve Tobago	1444	813	631
Meksika	1426	2752	-1326
Tayland	1406	1877	-471
Pakistan	1388	1436	-48
Arjantin	1285	1659	-374
Hindistan	1103	1753	-650
Umman	1057	774	283

Tablo 13 devamı

Bangladeş	949	949	0
Venezuela	918	936	-18
Kazakistan	749	481	268
Brezilya	721	1391	-670
Bolivya	717	79	638
Ukrayna	671	1172	-501
Azerbaycan	636	384	252
Burma	618	127	491
Kuveyt	597	738	-141
Bahreyn	547	547	0
Peru	446	271	175
Brunei	424	123	301
Kolombiya	421	406	15
Libya	410	159	251
Romanya	394	369	25
Papua Yeni Gine	346	3,5	342,5
Vietnam	321	321	0
Almanya	308	2873	-2565
İsrail	300	306	-6
Doğu Timor	272	0	272
İtalya	239	2385	-2146
Ekvator Ginesi	219	42	177
Polonya	217	643	-426
Mozambik	201	67	134
Yeni Zelanda	175	179	-4
Danimarka	163	113	50
Japonya	157	4364	-4207
Suriye	152	152	0
Yemen	101	34	67
Filipinler	92	92	0

Tablo 13 devamı

Fil Dişı Sahilleri	73	73	0
Macaristan	63	333	-270
Kongo (Brazzaville)	53	53	0
Hırvatistan	47	88	-41
Avusturya	45	296	-251
Küba	44	44	0
Güney Afrika	39	173	-134
Tanzanya	39	39	0
Şili	36	155	-119
Irak	35	35	0
Angola	27	27	0
Kamerun	24	24	0
Sırbistan	21	77	-56
Ekvator	18	18	0
Gana	16	38	-22
Türkiye	13	1697	-1684
Gabon	13	13	0
Tayvan	12	697	-685
Çek Cumhuriyeti	8,7	278	-269,3
Afganistan	6,7	6,7	0
Güney Kore	6,6	1565	-1558,4
Ürdün	5,3	102	-96,7
İrlanda	4,7	154	-149,3
Fas	3,3	39	-35,7
Slovakya	3,3	164	-160,7
Bulgaristan	2,8	103	-100,2
Senegal	2,2	2,1	0,1
İspanya	2,2	946	-943,8
Arnavutluk	1,2	1,2	0
Beyaz Rusya	1,1	612	-610,9

Tablo 13 devamı

Kırgızistan	1,1	6,4	-5,3
Fransa	1	1343	-1342
İsviçre	0,9	124	-123,1
Tacikistan	0,7	0,7	0
Gürcistan	0,4	45	-44,6
Moldova	0,4	96	-95,6
Finlandiya	0,3	96	-95,7
Lüksemburg	0,2	31	-30,8
Yunanistan	0,1	111	-110,9
Slovenya	0,1	29	-28,9

** Kuru doğal gaz, tüketici sınıfı doğal gaz olarak da bilinir ve Ölçüm parametreleri, 60 Fahrenheitta kübik feet ve mutlak inç kare başına 14.73 liradır.

Kaynak: EIA, International Energy Statistics, Dry Natural Gas Production 2015, https://www.eia.gov/beta/international/rankings/#?product=261&cy=2015&pid=3&tl_type=a (Erişim Tarihi: 01.03.2018); EIA, International Energy Statistics, Dry Natural Consumption 2015 https://www.eia.gov/beta/international/rankings/#?product=261&cy=2015&pid=26&tl_type=a&aid=2&tl_id=2-A (Erişim Tarihi: 01.03.2018)

Tablo 13'e göre tüketim fazlası sağlayan ülkeler potansiyel tedarikçi olarak görülebilir. Net ihracatçı konumundaki Rusya Federasyonu ile Türkiye arasında mevcut anlaşmalar eşliğinde stratejik işbirlikleri mevcuttur. Rusya Federasyonu ile beraber İran'ın rezerv'de lider olması ve rezervlerini elinde tutması Türkiye için net tedarikçi konumuna geçebileceğini gösterebilmektedir. Katar, Suudi Arabistan, Türkmenistan, Cezayir, Endonezya, Malezya, Nijerya, Özbekistan, Kazakistan ve Azerbaycan da Türkiye için muhtemel tedarikçi ağına yer alabilirler.

Türkiye'nin bu durumda net ithalatçı olduğu görülebilmektedir. Tablo 14, Tablo 15 ve Tablo 16'da ise net olarak doğalgaz üreticileri, ihracatçıları ve ithalatçıları gösterilmektedir. Orta Doğu'nun ihracatçı, Avrupa'nın ise ithalatçı görünümünde olduğu görülebilmektedir.

Tablo 14. Doğalgaz Üreten İlk 10 Ülke Sıralaması (2016)

Üreticiler	Miktar (Milyar m3)	Pay (%)
Amerika Birleşik Devletleri	749	20,7
Rusya Federasyonu	644	17,8
İran	190	5,3
Kanada	174	4,8
Katar	165	4,6
Çin Halk Cumhuriyeti	137	3,8
Norveç	121	3,3
Cezayir	92	2,5
Suudi Arabistan	90	2,5
Avustralya	88	2,4
Dünya Kalan	1163	32,3
Dünya Toplam	3613	100

Kaynak: International Energy Agency, 2017, Key World Energy Statistics, ss. 15

Tablo 15. Doğalgaz Net İhracatçısı İlk 10 Ülke (2016)

Net İhracatçılar	Miktar (Milyar m3)
Rusya Federasyonu	205
Katar	117
Norveç	115
Kanada	61
Cezayir	54
Türkmenistan	53
Avustralya	41
Endonezya	34
Malezya	24
Nijerya	23
Diğerleri	142
Dünya Toplam	869

Kaynak: International Energy Agency, 2017, Key World Energy Statistics, ss. 15

Tablo 16. Doğalgaz Net İthalatçısı İlk 10 Ülke (2016)


Net İthalatçılar	Miktar (Milyar m3)
Japonya	116
Almanya	79
Çin Halk Cumhuriyeti	69
İtalya	65
Türkiye	46
Kore	44
Meksika	43
Fransa	43
Birleşik Krallık	38
İspanya	28
Diğerleri	286
Dünya Toplam	857

Kaynak: International Energy Agency, 2017, Key World Energy Statistics, ss. 15

2.1.2.1 Türkiye'nin Doğalgaz Görünümü

Doğalgaz alanında zengin olmayan hatta bu konuda fazlasıyla fakir olan Türkiye, tamamen dışa bağımlı bir varlık göstermektedir.

Şekil 38'de Enerji Piyasası Denetleme Kurulu'nun 2018 yılında yayınlamış olduğu doğalgaz sektör raporuna göre; 2008-2017 dönemlerine ait ithalat, üretim, ihracat ve tüketim verileri görülmektedir.



Şekil 38. Türkiye'nin 2008 2017 Dönemlerine Ait Doğalgaz Verileri Kıyaslaması
(Milyon Sm³)

Kaynak: EPDK, 2017 Doğalgaz Sektör Raporu, 2018

Şekil 38'de görülen verilere göre yıllar bazında üretim ve ihracat değerleri çok düşük seyrederken ithalat ve tüketim değerleri yüksek gerçekleşmiştir ve genel itibariyle artan bir seyir göstermiştir. Diğer yıllar arasındaki veriler de kıyaslandığında küçük oranlı değişikliklerle artış ve azalışların mevcut olduğu sektör

raporlarında belirtilmektedir⁴. Ancak burada dikkate alınması gereken değerler ithalat oranının hayati önemde fazla olmasıdır.

İthalatçı konumunda olan Türkiye'nin doğalgazı ithal ettiği ülkeler ise Tablo 19'da gösterilmektedir. İthal edilen doğalgazın %50'den fazlası Rusya Federasyonundan temin edilmektedir.

Tablo 17. 2008-2017 Yılları Türkiye Doğal Gaz İthalat Miktarları (Milyon Sm³)

Ülke	Rusya		İran		Azerbaycan		Cezayir		Nijerya		Diğer*		Toplam	Bir Önceki Yıla Göre Yüzde Değişim
	Miktar	Pay (%)	Miktar	Pay (%)	Miktar	Pay (%)	Miktar	Pay (%)	Miktar	Pay (%)	Miktar	Pay (%)		
2008	23.15	62,01	4.113	11,01	4.580	12,26	4.148	11,11	1.017	2,72	333	0,89	7.350	4,21
2009	19.47	54,31	5.252	14,65	4.90	13,83	4.487	12,51	903	2,52	781	2,18	5.856	-4
2010	17.57	46,21	7.765	20,41	4.521	11,89	3.906	10,27	1.189	3,13	3.079	8,09	8.036	6,08
2011	25.40	57,91	8.190	18,67	3.806	8,67	4.156	9,47	1.248	2,84	1.069	2,44	3.874	15,35
2012	26.49	57,69	8.215	17,89	3.354	7,3	4.076	8,88	1.322	2,88	2.464	5,37	5.922	4,67
2013	26.21	57,9	8.730	19,28	4.245	9,38	3.917	8,65	1.274	2,81	892	1,97	5.269	-1,42
2014	26.97	54,76	8.932	18,13	6.074	12,33	4.179	8,48	1.414	2,87	1.689	3,43	9.262	8,82
2015	26.78	55,31	7.826	16,16	6.169	12,74	3.916	8,09	1.240	2,56	2.493	5,15	8.427	-1,7
2016	24.54	52,94	7.705	16,62	6.480	13,98	4.284	9,24	1.220	2,63	2.124	4,58	6.352	-4,28
2017	28.69	51,93	9.251	16,74	6.544	11,85	4.617	8,36	1.344	2,43	4.804	8,7	5.250	19,2

* Spot LNG ithalatının yapıldığı ülkeleri temsil etmektedir.

Kaynak: EPDK, 2018, Doğalgaz Sektör Raporu 2017: 9

⁴ Bkz. EPDK'nın doğalgaz sektör raporlarının yıllar bazında yayınlamış olduğu veriler dikkate alındığında bu değişiklikler görülmektedir. Raporlara EPDK'nın resmi internet sitesinden ulaşmanız mümkündür. <http://www.epdk.org.tr/TR/Dokumanlar/Dogalgaz/YayinlarRaporlar/Aylik>

Türkiye'nin doğalgazı ihraç ettiği ise sadece Yunanistan bulunmaktadır. Yunanistan'a ihraç edilen doğalgaz miktarlarının Tablo 18'de gösterilmektedir.

Tablo 18. 2008-2017 Yunanistan'a İhraç Edilen Doğalgaz Miktarı (Milyon cm³)

Yıllar	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
Miktar	435,8	708,5	648,6	714	611	682	632,63	623,94	674,68	630,67

Kaynak: EPDK, 2018, Doğalgaz Piyasası Sektör Raporu 2017:18

Tablo 18'e göre yıllar bazında Yunanistan'a ihraç edilen doğalgaz miktarı hemen hemen aynı düzeyde seyretmiştir.

Türkiye toplam tüketim değerleri incelendiğinde 2016 yılı içinde 367,28 milyon cm³ doğalgaz satışa sunulmuş ve tüketiciye ulaştırılmıştır. Üretimi yapılarak satışa sunulan doğalgaz miktarı bir önceki yıla göre %3,69 azalma göstermiştir. Aynı yıl içerisinde BOTAS aracılığıyla sadece Yunanistan'a 674,68 milyon cm³ doğalgaz ihraç edilmiştir. 2016 yılı için toplam tüketim miktarı ise 46,395 milyar cm³ olarak gerçekleşmiştir (EPDK 2017f: V).

Doğalgazda belirgin olarak en hareketli kalem ithalatta yer almaktadır ve Türkiye; Rusya Federasyonu, İran ve Azerbaycan olmak üzere 3 farklı ülkeden uzun vadeli olarak boru hatlarıyla doğalgaz ithal etmektedir. (EPDK 2017f: 6). Teknik ya da ekonomik açıdan boru hatları ile doğalgaz iletiminin mümkün olmadığı durumlarda ise -1620C'ye kadar soğutulmuş elde edilen sıvılaştırılmış doğalgaz (LNG) böylelikle hacminin 600 katı kadar küçültülmüş olur ve özel tankerler aracılığıyla taşınabilir. Bu kapsamda arzın güvenliğini garanti altına almak ve tedarik zincirinde esnek olabilmek için arz kaynaklarını çeşitlendirmek amacıyla Türkiye LNG alımı yapmaktadır. BOTAS'ın yapmış olduğu ikili anlaşmalar çerçevesinde LNG ithalatının yapıldığı ülkeler Cezayir (1994'ten itibaren), ve Nijerya'dır (1999'dan itibaren) (EPDK 2017f: 6).

Uzun dönemli imzalanan sözleşmeler kapsamında Cezayir ve Nijerya'dan ithal edilen LNG ile spot piyasadan alınan LNG'nin depolanması, gazlaştırılması ve

iletim hattına gönderilmesi için hayata geçirilen üç tane LNG terminali bulunmaktadır. Bunlar 1994 yılında faaliyete başlayan Marmara Ereğlisi LNG Terminali, 2006 yılında faaliyete başlayan EGE Gaz A.Ş LNG Terminali ve 2016 yılında faaliyete geçen Etki Liman İşletmeleri Doğal Gaz İthalat ve Ticaret A.Ş yüzen LNG Terminali (FSRU)'dir (EPDK 2017f: 6).

2.1.3 Kömür Üreticileri, Tedarikçileri ve Alıcıları

Dünya kömür rezervlerinin %32,3'ü Asya-Pasifik'te, 27,5'i Kuzey Amerika'da, %3,7'si Ortadoğu ve Afrika'da, %17,6'sı Rusya'da bulunmaktadır (TTK 2017: 5).

Dünyada bilinen kömür rezervlerinin mevcut üretim seviyeleri ile ortalama olarak 114 yıllık bir sürede tüketileceği tahmin edilmektedir. Buna karşılık bilinen doğalgaz ve petrol rezervlerinin tükenme ömrünün mevcut üretim seviyeleri ile sırasıyla 54 ve 53 yıl süreceği tahmin edilmektedir (TTK 2017: 5). Bu durumda kömürün petrol ve doğalgaza oranla fazla ömre sahip olması ülkeleri kömür kaynaklı enerji üretiminde yeni programlara yönlendirebilmektedir.

Küresel mevcut rezerv miktarı göz önüne alındığında, kömür üretiminde dünyada önemli bir payı bulunan Endonezya'nın mevcut üretim hızıyla devam etmesi halinde 71 yıllık bir ömre sahip olduğu görülebilmektedir (TTK 2017: 5), bununla beraber Tablo 19 ve Tablo 'te de görüldüğü üzere Avustralya'nın tüketim fazlalığının yüksekliği onu ihracatçılar arasında ilk sıraya yükseltmektedir.

Ülkeler bazında kömür üreticileri, tüketim miktarları ve tüketim fazlalıkları Tablo 19'da görülebilmektedir.

Tablo 19. Ülkeler Bazında Kömür Üretim, Tüketim ve Tüketim Fazlası Miktarları
(2015)

Ülkeler	Üretim Miktarı (tst)	Tüketim Miktarı (tst)	Tüketim Fazlası (tst)
Çin Halk Cumhuriyeti	4376984	4376326	658
Amerika Birleşik Devletleri	896941	798155	98786
Hindistan	643720	879608	-235888
Avustralya	560714	130585	430129
Endonezya	432106	95901	336205
Rusya Federasyonu	409701	228176	181525
Güney Afrika	256876	169607	87269
Almanya	203613	262922	-59309
Polonya	149147	148717	430
Kazakistan	118168	86882	31286
Kolombiya	94248	6416	87832
Kanada	68267	46297	21970
Çek Cumhuriyeti	51168	49909	1259
Yunanistan	50977	49106	1871
Türkiye	48824	98619	-49795
Sırbistan	41696	42594	-898
Vietnam	41000	41650	-650
Bulgaristan	39528	40628	-1100
Kuzey Kore	38810	17927	20883
Ukrayna	33522	45503	-11981
Romanya	28101	29771	-1670
Mongolya	26681	9824	16857
Tayland	18888	37443	-18555
Meksika	16831	24251	-7420
Macaristan	10208	11801	-1593

Tablo 19 devamı

Birleşik Krallık	9478	41195	-31717
Kosova	9084	9189	-105
Brezilya	8850	34172	-25322
Filipinler	7816	24258	-16442
Mozambik	7274	0	7274
Bosna Hersek	6666	8922	-2256
Makedonya	6543	6672	-129
Özbekistan	4849	4843	6
Zimbabve	4732	3221	1511
Pakistan	4590	5686	-1096
Yeni Zelanda	3736	3102	634
Slovenya	3492	3967	-475
İspanya	3377	27694	-24317
Şili	3373	11301	-7928
Malezya	2822	24472	-21650
Botswana	2277	1492	785
Slovakya	2137	7014	-4877
Kırgızistan	2060	3159	-1099
Montenegro	1954	1896	58
Güney Kore	1944	146301	144357
Afganistan	1504	1504	0
Norveç	1219	869	350
İran	1213	947	266
Venezuela	1189	320	869
Tacikistan	1184	1056	128
Bangladeş	1026	2207	-1181
Burma	699	663	36
Laos	478	382	96
Gürcistan	389	505	-116
Tanzanya	282	356	-74

Tablo 19 devamı

Peru	273	1277	-1004
Nijer	249	249	0
Zambiya	220	187	33
Svazilan	156	138	18
Nijerya	134	142	-8
Bhutan	94	88	6
Arjantin	88	1301	-1213
Malawi	83	85	-2
İtalya	80	21450	-21370
Mısır	49	1885	-1836
Nepal	17	793	-776
Kongo (Kinsasa)	4	7,5	-3,5
Arnavutluk	0,1	113	-112,9
Cezayir	0	28	-28
Japonya	0	210734	-210734
Birleşik Arap Emirlikleri	0	2170	-2170
Fransa	0	15045	-15045
Hollanda	0	19883	-19883
Ermenistan	0	1,2	-1,2
Hırvatistan	0	1098	-1098
Avusturya	0	4147	-4147
Azerbaycan	0	0,2	-0,2
Suudi Arabistan	0	61	-61
Fas	0	6695	-6695
Danimarka	0	3458	-3458
Beyaz Rusya	0	698	-698
Belçika	0	4573	-4573
Kıbrıs	0	6,6	-6,6
Finlandiya	0	4438	-4438
İsveç	0	3083	-3083

Tablo 19 devamı

Taiwan	0	68071	-68071
İsrail	0	11568	-11568
İrlanda	0	2551	-2551
Honkong	0	12329	-12329
Portekiz	0	6973	-6973
Kuveyt	0	409	-409
Kenya	0	677	-677
Senegal	0	642	-642
Lübnan	0	371	-371

*tst: Thousand Short Tons, 1 tst= 907 184,74 kg

Kaynak: EIA, International Energy Statistics, Coal Production 2015, <https://www.eia.gov/beta/international/rankings/#?product=7-1&cy=2015> Erişim Tarihi: 02.03.2018;
EIA, International Energy Statistics, Coal Consumption 2015, <https://www.eia.gov/beta/international/rankings/#?product=7-2&cy=2015> Erişim Tarihi: 02.03.2018

Tablo 19'da görüldüğü üzere kömür üretiminde liderliği Çin Halk Cumhuriyeti üstelenmektedir. 2015 yılı için bu miktar Çin Halk Cumhuriyeti için 3,52 milyar ton olarak gerçekleşmiş ve böylelikle ülke dünya taş kömürü üretiminin %51'ini tek başına gerçekleştirmiştir (TTK 2017: 7). 2016 ülkeler bazında üretim sıralaması ise Tablo 20'de görülebilmektedir. Kömür üretiminde Çin Halk Cumhuriyeti küresel üretimin %44.6'lık payına açık ara hakim olarak birinci sırada, ikinci sırada ise %9.7'lik üretim payıyla Hindistan yer almaktadır. Küresel üretimde ilk 10 sırada yer alan ülkelerin üretimlerinin toplamı geri kalan dünya ülkelerinin kömür üretiminin toplamlarının yaklaşık 10 katı kadardır.

Tablo 20. Kömür Üretiminde Dünya Sıralaması (2016)

Üreticiler	Milyon Ton	Pay (%)
Çin Halk Cumhuriyeti	3242	44,6
Hindistan	708	9,7
Amerika Birleşik Devletleri	672	9,2
Avustralya	503	6,9
Endonezya	460	6,3
Rusya Federasyonu	365	5
Güney Afrika	257	3,5
Almanya	176	2,4
Polonya	131	1,8
Kazakistan	98	1,3
Dünya Kalan	657	9,3
Dünya Toplam	7269	100

* Buhar kömürü, taş kömürü, linyit ve geri kazanılmış kömür içerir.

Kaynak: International Energy Agency, 2017, Key World Energy Statistics, ss. 17

Demir-Çelik sanayisinde kullanılan, koklaşabilir özellikteki taşkömürü üretimi 2015 yılı için 1089,9 milyon ton olarak gerçekleşmiştir. %56'lık bir oranla 611,1 milyon tonu Çin tek başına gerçekleştirmiştir. Sıralamadaki 5 ülkeden diğer 4'ü ise Avustralya (%17,5), Rusya (%7), ABD (%5), Hindistan (%5) olarak raporlarda yer almaktadır. Lider olan bu 5 ülke koklaşabilir kömür üretiminin %90,5'ine sahiptir (TTK 2017: 7).

Termik santrallerde, elektrik üretiminde, sanayi sektöründe ısıl amaçlı ve konutlarda ısınma amaçlı olarak kullanılan termal taşkömürü üretiminde de yine Çin Halk Cumhuriyeti 1. sırada yer almaktadır. Bu miktar 2 916,1 milyon ton ve toplam üretimin %50,17'sini kapsamaktadır. 2015 yılı için ABD (%11,18), Hindistan (%10,21), Endonezya (%8,02), Avustralya (%4,34), Güney Afrika Cumhuriyeti (%4,28) ve Rusya Federasyonu (%3,40) Çin Halk Cumhuriyeti'ni takip etmektedirler. Bu 7 ülkenin toplam üretim oranı ise %91,6'dır (TTK 2017: 8).

Elektrik üretiminde ve ısınma amaçlı kullanılan linyitte dünya genelinde üretim 2015 yılında %11'lik bir düşüş yaşamış ve miktar 807,4 milyon ton'a gerilemiştir. Almanya 178,1 milyon tonluk üretim gerçekleştirerek linyit üretiminde lider konumda yer almıştır. Türkiye de önemli linyit üretici ülkelerden biridir ve 2015 yılında 50,4 milyon ton üretim gerçekleştirmiştir (TTK 2017: 9).

Tablo 19'da görüldüğü gibi Çin Halk Cumhuriyeti kömür bazında üretim lideridir. Ancak bununla beraber net ithalatçı olduğu da Tablo 22'de (2016 Yılı verisi) görülebilmektedir. Bu da ülkeyi alıcı konumuna getirmektedir. Bu alanda güçlü olan tedarikçiler ise Tablo 21'de görülen ve Tablo 19'da görüldüğü üzere tüketim fazlası sağlayan ülkeler olarak ortaya çıkan Avustralya, Endonezya, Rusya, Kolombiya, Güney Afrika Cumhuriyeti ve Amerika Birleşik Devletleri'dir. Tüketim fazlası sağlamayı başaran küçük miktarlı ülkeler olan Mozambik, Çek Cumhuriyeti, Yunanistan ve Zimbabve ise yine tedarikçi konumunda yer alabilmektedir. Türkiye'nin ise net ithalatçı olduğu görülebilmektedir. 2015 yılı verilerine göre Türkiye üretici ülkeler arasında yer alsa da üretim tüketimi karşılayamamaktadır. Tablo 19'da görüldüğü üzere -49.795 tst'dir. Bu miktar da Türkiye'nin alıcı gücünü düşürmektedir. Küresel boyutta tedarikçi ülkeler Tablo 21'de, alıcılar ise Tablo 22'de görülebilmektedir.

Tablo 21. Kömür İhraç Eden Ülke Sıralamaları (2016)

Net İhracatçılar	Milyon Ton
Avustralya	389
Endonezya	367
Rusya Federasyonu	147
Kolombiya	83
Güney Afrika	76
Amerika Birleşik Devletleri	46
Mongolya	26
Kazakistan	26
Kanada	24
Kuzey Kore	21
Diğerleri	8
Dünya Toplam	1213

Kaynak: International Energy Agency, 2017, Key World Energy Statistics, ss. 17

Tablo 22. Kömür İthal Eden Ülke Sıralamaları (2016)

Net İthalatçılar	Milyon Ton
Çin Halk Cumhuriyeti	247
Hindistan	199
Japonya	189
Güney Kore	134
Tayvan	66
Almanya	53
Türkiye	36
Malezya	29
Tayland	23
Brezilya	20
Diğerleri	215
Dünya Toplam	1211

Kaynak: International Energy Agency, 2017, Key World Energy Statistics, ss. 17

2.1.3.1 Türkiye'nin Kömür Görünümü

Rezerv bakımından tükenme ömrü diğer fosil yakıtlara nazaran daha uzun olması ve küresel boyutta geniş bir coğrafyaya yayılması nedeni ile kömür diğer kaynaklara göre daha avantajlı konuma gelebilmektedir. Petrol ve doğalgazın daha çok istikrarsız bölgelerde yer aldığı bilinmektedir. Bu nedenle yüzölçümü bakımından geniş ülkelerde bulunması ve bu ülkelerin genel itibariyle istikrarlı bölgelerde yer alması nedeniyle kömür kaynak olarak daha önemli hale gelebilmektedir.

Enerji ve Tabii Kaynaklar Bakanlığı resmi sitesinde Türkiye kömür durumunun ele alındığı raporda Türkiye'nin rezerv ve üretim miktarı bakımından linyit alanında dünya sıralamasında orta sıralarda, taşkömürü alanında ise alt sıralarda yer aldığı belirtilmektedir. Dünya toplam linyit rezervinin yaklaşık olarak %3,2'lik kısmı Türkiyede yer almaktadır. Ancak Türkiye'de üretilen linyit kömürünün ısı değeri düşük olması nedeniyle kullanım alanı genellikle termik santralleri olmaktadır. Türkiye linyit rezervinin yaklaşık olarak %46'lık bölümü Afşin-Elbistan havzasında ve taşkömürünün çok büyük kısmı ise Zonguldak ve civarında yer almaktadır. Taşkömürünün yer aldığı Zonguldak'ta görünür rezerv 506 milyon ton olmasına rağmen, havzadaki toplam taşkömürü miktarı 1,3 milyar tondur (<http://www.enerji.gov.tr/tr-TR/Sayfalar/Komur> Erişim Tarihi: 05.03.2018). Enerji ve Tabii Kaynaklar Bakanlığının yerli üretime daha fazla ağırlık vermesiyle beraber kömür kaynağına ilgi artmıştır. Yine aynı raporda, 2005 yılı itibariyle dışa bağımlılığın azaltılarak yerli kaynaklara önem verilmesinin planlandığı ve böylece sanayileşme ve nüfus artışından kaynaklı olarak artan enerji talebinin karşılanması amaçlandığı bildirilmektedir. Bu kapsamda mevcut kömür sahalarının geliştirilmesi ve yeni kömür sahalarının bulunması çalışmaları hızlandırılmıştır. Çalışmalarla beraber mevcut olan 8,3 milyar ton kömür rezervine ilaveten 2014 yılı sonunda 7,38 milyar ton linyit rezervi bulunmuştur. 2015 sonunda toplam linyit rezervi 15 milyar ton olarak gerçekleşmiştir. 2016'da da kömür kaynaklı santrallerden toplam olarak 92,3 TWh elektrik üretimi gerçekleşmiştir ve toplam elektrik üretiminin %33,9'u da kömürden elde edilmiştir (<http://www.enerji.gov.tr/tr-TR/Sayfalar/Komur> Erişim Tarihi: 05.03.2018). Bu veriler ışığında kısmi olarak diğer fosil kaynaklara nazaran

kömür açısından daha zengin olan Türkiye'nin, enerji elde etmede politikasını bu yöne kaydırmaya başladığı görülebilir.


Tablo 23'te 2011-2015 yılları arasında Türkiye'de üretilen kömür miktarı görülmektedir. Genel olarak yıllar itibariyle kömür üretiminde azalış meydana gelmiştir.

Tablo 23. 2011-2015 Yılları Arasında Türkiye Kömür Madeni Üretim Verileri

2011-2015 YILLARI ENERJİ HAMMADDELERİ ÜRETİMİ (ton)						
Maden	Üretici	2011	2012	2013	2014	2015
Asfaltit	572.089	649.830	648.953	336.852	837.112
Bitümlü	TKİ	394.277	394.277	149.828	259.508	288.185
Kömür	EÜAŞ	31.455.812	24.297.709	16.011.459	18.987.907	10.855.125
.....	TKİ	41.530.095	36.815.592	23.257.009	22.854.114	12.432.171
.....	Diğer Kamu			11.245.055	1.063.927	399.816
...	Özel Sektör	9.389.340	16.900.893	12.810.342	23.301.062	35.043.058
....	Toplam	82.375.247	78.014.194	63.323.865	66.207.011	58.730.170
Taş kömürü	TTK ve Rödövanşçılar	2.619.247	3.235.299	2.789.338	1.916.833	2.074.049
KÖMÜR GENEL		85.960.860	82.293.600	66.911.984	68.720.204	61.929.516

Kaynak: Enerji ve Tabii Kaynaklar Bakanlığı, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Komur> (Erişim Tarihi: 10.10.2017)

Yıllar bazında Türkiye taşkömürü üretim değerleri Şekil 39'da görülebilmektedir. 1991 yılında başlayan ve özel sektör tarafından üretilen taşkömürü miktarı kamu üretiminin aksine artan yönlü olarak gerçekleşmiştir. 2011 yılından itibaren her iki kesim içinde üretim miktarı düşmektedir.



Şekil 39. 1965-2015 Yılları Arası TTK ve Özel Sektör Kömür Üretimi (Ton)

Kaynak: TTK, 2017, 2016 Yılı Türkiye Taşkömürü Sektör Raporu, Ankara: 26


1980’li yılların başında hareket kazanan kömür ithalatı ile birlikte Türkiye toplam taşkömürü tüketiminin %80’ini yerli kaynaklardan sağlarken 1980’li yılların sonlarında bu oran %45’e gerilemiştir. 2016 yılına bakıldığında ise 36,195 milyon ton olan taşkömürü tüketiminin yalnızca %3,63’ü yerli kaynaklardan (TTK ve havza üretiminden) karşılanmıştır (TTK 2017: 27). Türkiye’nin 2000-2016 yılları arasında üretim, ithalat ve tüketim miktarları Tablo 24’te görülebilmektedir.

Tablo 24. Türkiye Taşkömürü Üretim, İthalat ve Tüketim Değerleri (Bin Ton)

YILLAR	ÜRETİM	İTHALAT	TOPLAM TÜKETİM
2000	2.373	12.990	15.363
2001	2.587	8.028	10.615
2002	2.732	11.693	14.425
2003	2.064	16.166	18.230
2004	2.029	16.427	18.456
2005	2.177	17.360	19.537
2006	2.318	20.286	22.604
2007	2.492	22.946	25.438
2008	2.630	19.489	22.119
2009	2.879	20.364	23.243
2010	2.591	21.333	23.924
2011	2.619	23.679	26.298
2012	2.292	29.195	31.487
2013	1.915	28.200	30.115
2014	1.788	29.000	30.788
2015	1.434	31.494	32.928
2016	1.315	34.880	36.195

Kaynak: TTK, 2017, ss: 28

Şekil 40'taki Türkiye linyit üretimine ait grafikte görüldüğü gibi, petrol krizlerinin yaşandığı 1970 yıllarında elektrik üretimi için linyit kaynağının kullanımına dair işletme yatırımları hız kazanmıştır. 1970'lerde 5.8 milyon tonluk linyit üretimi 1998 senesinde 65 milyon tona kadar çıkmıştır. Bu dönemden sonra ise doğalgazın Türkiye'de yayılması ile beraber üretim sürekli azalmış, en düşük üretim ise 2004 senesinde 43,7 milyon ton seviyesini göstermiştir. 2004'den sonra yine artan bir ivme kazanarak linyit üretimi 2008 yılında 76 milyon tona ulaşmıştır. Yine 2013 yılına kadar azalış göstermiş (57,5 milyon ton) ardından 2014'te 62,6 milyon tona yükselmiştir (TKİ 2016: 27). Türkiye Linyit üretim grafiği Şekil 40'da görülebilmektedir.



Şekil 40 1970-2013 Türkiye Linyit Üretimi (Ton)

Kaynak: TKİ, 2016, ss. 27

Toplam linyit arzı 2014 yılında 64,7 milyon ton olarak gerçekleşmiş ve bu arzın %88,8'lik kısmının tüketimi elektrik elde etmek amacıyla termik santrallerde gerçekleşmiştir. Linyit kömürünün kullanım payı sanayi sektöründe %6,3 iken, konut ve işyerlerinde kullanım payı %4,7 seviyesindedir. Elektrik üretimi için kullanılan linyitin ısı değeri ısınma amaçlı kullanılan linyitten çok daha düşüktür. Bu bağlamda Toplam ısı değeri üzerinden bakıldığında; 2014 yılında kullanılan linyitin %79,9'unun elektrik üretiminde, %11,3'ünün sanayi sektörlerinde ve %8,5'inin ise konut ve işyerlerinde tüketildiği görülmektedir. Yine 2014 yılı için 771 bin ton olan asfaltit kullanımının %59,4'ü elektrik üretiminde, %20,4'ü sanayide ve %20,2'si ısınmada tüketilmiştir (TKİ 2016: 35).

Kömür kaynaklı enerji üretiminin maliyetleri zaman içerisinde düşmüştür. Bu avantajı ile beraber çevre için yaratmış olduğu problemler kömürü dezavantajlı hale getirmektedir. Kömürün özellikle sera gazı salınımına neden olması bu kaynak üzerinde çevre baskısını artırabilmektedir. Kömürden kaynaklı hava ve iklim problemleri nedeni ile alınması gereken bazı tedbirler bu kaynak için dikkatli olunması gerektiğini göstermektedir.

Çevre kirliliğinin çok büyük bir kaynağı olan kömür kullanımı için Türkiye 2014 yılında Lima’da gerçekleştirilen COP20 iklim değişikliği zirvesinde teknolojik, kapasite geliştirme ve finans desteğinden faydalanabilmek için 2020 ve 2030 yılları arasında sera gazı emisyonunu %21’e kadar düşüreceğini bildirmiştir (TTK 2017: 21).

2.1.4 Elektrik Üreticileri, Tedarikçileri ve Alıcıları

Küresel bazda ülkelerin elektrik üretim, tüketim ve tüketim fazlası verileri Tablo 29, Tablo 30 ve Tablo 31’de görülebilmektedir. Elektrik enerjisinin depolanamaması en büyük dezavantajdır. Bu nedenle üretim ve tüketim eş zamanlı gerçekleşmektedir. Elektriğin depolanabilmesi ile ilgili çalışmalar devam etmektedir. Depolama teknolojisi gerçekleştiğinde ülkeler için büyük bir maliyetten arınma söz konusu olabilecektir.

Tablo 25. Ülkeler Bazında Elektrik Üretim, Tüketim ve Tüketim Fazlası Miktarları (2015)

Ülkeler	Üretim Miktarı (Milyar Kwh)	Tüketim Miktarı (Milyar Kwh)	Tüketim Fazlası (Milyar Kwh)
Çin Halk Cumhuriyeti	5582	5271	311
Amerika Birleşik Devletleri	4097	3920	177
Hindistan	1295	1054	241
Rusya Federasyonu	1008	890	118
Japonya	976	934	42
Kanada	647	520	127
Almanya	610	536	74

Tablo 25'in devamı

Brezilya	569	510	59
Fransa	540	440	100
Güney Kore	517	498	19
Birleşik Krallık	318	310	8
Suudi Arabistan	318	293	25
Meksika	295	247	48
İtalya	269	296	-27
İran	265	221	44
İspanya	264	238	26
Türkiye	249	216	33
Tayvan	240	232	8
Avustralya	239	225	14
Güney Afrika	231	209	22
Endonezya	221	199	22
Mısır	172	150	22
Tayland	168	168	0
İsveç	159	130	29
Polonya	155	144	11
Ukrayna	152	133	19
Vietnam	147	134	13
Norveç	142	119	23
Malezya	142	133	9
Arjantin	134	122	12
BAE	120	111	9
Venezuela	114	74	40
Pakistan	105	86	19
Hollanda	104	108	-4
Kazakistan	101	95	6
Filipinler	79	71	8
Çek Cumhuriyeti	78	61	17

Tablo 25'in devamı

Şili	72	69	3
Kolombiya	67	58	9
Finlandiya	66	80	-14
Belçika	66	83	-17
Irak	65	40	25
Cezayir	65	53	12
İsviçre	64	58	6
Kuveyt	64	54	10
Romanya	63	49	14
İsrail	60	53	7
Avusturya	57	64	-7
Bangladeş	56	49	7
Paraguay	55	10	45
Özbekistan	54	48	6
Yunanistan	49	54	-5
Portekiz	49	47	2
Singapur	47	47	0
Peru	47	41	6
Bulgaristan	46	32	14
Yeni Zelanda	43	40	3
Katar	39	37	2
Hong Kong	36	42	-6
Sırbistan	35	29	6
Libya	35	8,1	26,9
Beyaz Rusya	32	32	0
Umman	31	28	3
Nijerya	30	25	5
Macaristan	29	39	-10
Danimarka	28	32	-4
Fas	28	27	1
Bahreyn	27	26	1

Tablo 25'in devamı

İrlanda	27	25	2
Ekvator	25	22	3
Slovakya	25	26	-1
Azerbaycan	23	20	3
Türkmenistan	21	15	6
Porto Riko	20	19	1
Mozambik	20	14	6
Küba	19	16	3
İzlanda	19	18	1
Tunus	18	15	3
Ürdün	18	16	2
Lübnan	17	16	1
Tacikistan	17	13	4
Suriye	17	14	3
Dominik Cumhuriyeti	16	13	3
Burma	15	13	2
Bosna Hersek	15	11	4
Slovenya	14	13	1
Uruguay	14	11	3
Kuzey Kore	13	11	2
Zambiya	13	12	1
Kırgızistan	13	11	2

Kaynak: EIA, International Energy Statistics, Total Electricity Net Generation 2015, <https://www.eia.gov/beta/international/rankings/#?product=2-12&cy=2015> Erişim Tarihi: 02.03.2018;
EIA, International Energy Statistics, Total Electricity Net Consumption 2015, <https://www.eia.gov/beta/international/rankings/#?product=2-2&cy=2015> Erişim Tarihi: 02.03.2018

Tablo 25'te görüldüğü gibi üretim konusunda lider olan ülke Çin Halk Cumhuriyeti'dir. Endüstriyel gelişimin yüksek olması nedeniyle tüketim fazlasını ihraç edebilmekte ancak sıralamada geri düşmektedir. Ürettiği elektriğin çok büyük bir kısmını tüketmektedir. Aynı zamanda tüketim konusunda da lider olarak yerini almıştır.

2015 yılı itibariyle kurulu güçte en yüksek paya Çin Halk Cumhuriyeti sahiptir. 1519 Milyon KWh kurulu güce sahiptir. Türkiye bu sıralamada 73 Milyon KWh ile 14. Sırada yer almaktadır (EIA, <https://www.eia.gov/beta/international/rankings/#?product=2-7&cy=2015> Erişim Tarihi: 07.03.2018).

Elektrik ihraç eden ülkeler Tablo 28’de görülmektedir. Fosil kaynaklarda net ithalatçı olan Avrupa ülkelerinin elektrik bazında ihracatçı olduğu görülebilmektedir. Bu alanda liderlik ise ihraç ettiği 85 Milyar KWh ile Almanya’ya aittir. Fransa 74 Milyar KWh ile Almanya’yı takip etmektedir. Her iki ülkenin de yenilenebilir enerji kaynaklarının ve özellikle nükleer santrallerinin olması bu sıralamada lider koltuğuna oturmalarına neden olmaktadır.

Tablo 26. Elektrik İhraç Eden Ülkeler (2015)

İhracatçılar	Milyar Kwh
Almanya	85
Fransa	74
Kanada	68
Paraguay	41
İsviçre	35
İsveç	32
Çek Cumhuriyeti	29
Norveç	22
Hollanda	22
Avusturya	19
Çin Halk Cumhuriyeti	19
Türkiye	3,2

Kaynak: EIA, International Energy Statistics, Total Electricity Exports 2015, <https://www.eia.gov/beta/international/rankings/#?product=2-4&cy=2015> Erişim Tarihi: 02.03.2018

Elektrik ithalatçısı ülkeler ise Tablo 29’da yer almaktadır. Amerika Birleşik Devletleri elektrik üretim konusunda Çin Halk Cumhuriyetinden sonra 2. sırada yer alsa da⁵ ithalatçı olarak lider konumundadır.

Tablo 27. Elektrik İthal Eden Ülkeler (2015)

İthalatçılar	Milyar Kwh
Amerika Birleşik Devletleri	76
İtalya	51
Almanya	37
Brezilya	35
İsviçre	34
Avusturya	29
Belçika	24
Birleşik Krallık	23
Finlandiya	21
Macaristan	20
Çek Cumhuriyeti	16
Türkiye	7,1

Kaynak: EIA, International Energy Statistics, Total Electricity Imports 2015, <https://www.eia.gov/beta/international/rankings/#?product=2-3&cy=2015> Erişim Tarihi: 02.03.2018

2.1.4.1 Türkiye’nin Elektrik Görünümü

Türkiye’de elektirik kurulu gücü 2016 yılında bir önceki yıla göre %6,27 artış göstererek 77.737 MW’a yükselmiştir. Bu kurulu gücün kaynakları ise, %32,77 pay ile doğalgaz santralleri, %25,16 ile barajlı hidroelektrik santralleri, %9,16 ile akarsu hidroelektrik santralleri, %11,92 ile linyit santralleri, %7,39 ile rüzgar santrallerinden oluşmaktadır. Yenilenebilir enerjinin toplam kurulu güçteki payı hidrolik kaynaklar

⁵ Bkz. Tablo 29. ABD 4097 Milyar KWh ile 2. Sırada yer almaktadır. 2015 yılı için tüketim miktarı 3920 Milyar KWh olarak raporlanmıştır. 177 Milyar KWh tabloda tüketim fazlası olarak görülebilmektedir. Elektriğin depolanamaması, yıllık olarak bu atıl kapasitenin göz ardı edilmesini gerektirmiş olabilir. Kesintisiz elektrik ihtiyacını karşılamak için ABD’nin burada net ithalatçı olduğu söylenebilir.

da dahil olmak üzere %43,41'e yükselmiştir, termik santrallerin ise payı %56,59 olarak gerçekleşmiştir (EPDK 2017c: V) .

Elektrik üretim miktarı aynı yıl için, 2015 yılına göre %4,12 artmış ve 272,56 TWh olmuştur. Tüketim miktarı 2015 yılına göre %4,44 artmış ve 277,52 TWh'a ulaşmıştır. Üretim miktarının kaynaklara göre oranı %32,16 doğal gaz, %24,7 hidroelektrik, %15,35 taş kömürü ve linyit, %17,52 ithal kömür, %5,69 rüzgâr ve geri kalan kısım diğer kaynaklardan oluşmaktadır (EPDK 2017c: V).

Elektrik üretimi için lisanssız olarak kurulan santraller de önemli artışlar gözlemlenmiştir. 2015 yılına oranla 2016 yılında lisanssız kurulu güç %191,95 artarak 1.048 MW'a yükselmiştir. Bu artışta %89,81'i fotovoltaik güneş enerjisinden elde edilmiştir. Üretim miktarı ise aynı yıllar için %410,89 artarak 1,14 TWh'a yükselmiştir. Yine bu üretimin %90,64'ü fotovoltaik güneş enerjisinden elde edilmiştir (EPDK 2017c: V).

2016 yılı için elektrik ithalatı 2015 yılına göre %13,64 azalarak 6,40 TWh olarak gerçekleşmiştir. Elektrik ihracatı ise yine 2015 yılına göre %51,36 azalarak 1,44 TWh olarak gerçekleşmiştir (EPDK 2017c: V).


Tablo 28. 2014-2017 Türkiye Elektrik Piyasası Genel Görünümü

	Birim	2014	2015	2016	Değişim (%) 2015→2016	2017	Değişim (%) 2016→2017
Lisanslı	MW	69.520	73.146,90	77.563,44	6,04	81.563,32	5,16
Lisanssız	MW	29,99	359,04	1.048,21	191,95	3.173,32	202,74
Puant Talep	MW	41.003	43.289,00	44.733,98	3,34	47.659,65	6,54
Lisanslı Üretim	GWh	251.962	261.783,30	272.563,63	4,12	292.574,58	7,34
Lisanssız Üretim	GWh	3,92	222,72	1.137,87	410,89	3.031,56	166,42
Tüketim	GWh	257.220	265.724,40	277.522,01	4,44	292.003,54	5,22
İthalat	GWh	7.953	7.411,10	6.400,13	-13,64	2.729,06	-57,36
İhracat	GWh	2.696	2.964,60	1.442,08	-51,36	3.300,10	128,84

Kaynak: EPDK, 2018, Elektrik Piyasası 2017 Yılı Sektör Raporu, Ankara, ss. 16

Tablo 30’da görüldüğü üzere, 2016 yılı ile 2017 yılındaki ithalat ve ihracat değerlerindeki değişim çok yüksektir. 6400 GWh’lik ithalat 2017’de %57 azalmış ve 2729 GWh’e gerilemiştir. Yarısından daha fazla azalan ithalat ile birlikte ihracat ise yarı değerinden daha fazla artarak 2964 GWh’ten 3300 GWh’e yükselmiştir. Böyle ciddi bir değişim Türkiye’nin enerji görünümünün pozitif yönlü olduğunu gösterebilmektedir.

Türkiye elektrik piyasasındaki talebin sürekli arttığı Şekil 41’de görülebilmektedir. 2009’daki talep yüzde artışındaki keskin düşüş’den sonra sürekli bir artan trend yakalamıştır. Özellikle 2017 senesinde en yüksek talep miktarı görülebilmektedir. Artış oranı 2017 yılında %5,07 ile kendinden önceki 4 yılın en yüksek seyirini göstermiştir.




Şekil 41. Yıllar Bazında Türkiye Elektrik Talebinde Gerçekleşen Değişim

Kaynak: EPDK, 2018, Elektrik Piyasası 2017 Sektör Rapor, Ankara, ss. 17

ENTSO-E’nin 2016 yılında hazırlamış olduğu “Orta Vadeli Yeterlilik Tahmin Raporu”nda, ENTSO-E’nin talebi yıllık ortalama olarak % 1,03 oranında artarken ülkeler genellikle bu oran çevresinde hareket etmektedir. Ancak iki ülkenin yıllık talep artışının ENTSO-E ortalama büyüme düzeyinin iki katından fazla çıkacağı tahmin edilmiştir. Bu ülkelerden ilki %5,7 ile Türkiye iken ikinci sırada %4,7 ile Kıbrıs Rum Kesimi yer almaktadır (ENTSO-E 2016: 45).


2015 yılında gerçekleşen elektrik üretiminin %37,81'i doğal gaz'dan elde edilirken 2016 yılında bu oran %32,16'ya gerilemiştir. Yine 2015 için üretimde payı %25,76 olan hidroelektrik santrallerinin 2016 yılındaki payı %24,69'a gerilemiştir. Bununla beraber yerli kömür santrallerinin payı 2015 yılında %13,23'ten 2016 yılında %16,40'a, ithal kömür santrallerinin payı 2015 yılında %15,22'ten 2016 yılında %17,52'ye, rüzgar santrallerinin payı 2015 yılında %4,45'ten 2016 yılında %5,69'a, jeotermal santrallerinin payı 2015 yılında %1,30'dan 2016 yılında %1,77'ye çıkmıştır. 2017 yılı için Türkiye elektrik üretiminin kaynaklara göre dağılımı Şekil 42'de görülebilmektedir (EPDK 2017c: V).



Şekil 42. 2017 Yılı Türkiye Elektrik Üretimine Kaynaklara Göre Dağılımı (%)

Kaynak: EPDK, 2018, Elektrik Piyasası 2017 Sektör Raporu, Ankara, ss. 27


Elektrik üretiminde termik santrallerin önemli etkisi Şekil 43'de görülebilmektedir. Bununla beraber özellikle son 10 yılda yenilenebilir enerji kaynağındaki değişim de dikkate alınmalıdır. Yenilenebilir kaynakların, elektrik üretimindeki payı her geçen yıl artış göstermektedir.



Şekil 43. Yıllara Göre Elektrik Üretimini Kaynak Bazında Değişimi

Kaynak: EPDK, 2017c, Elektrik Piyasası 2017 Sektör Raporu, Ankara, ss. 27


Türkiye'nin giderek artan elektrik talebinin kesintisiz karşılanması için elektrik ithal edilebilmektedir. 2017 yılında elektriğin en çok oranlı ithal edildiği ülke Bulgaristan (%76,02) olmuştur. Toplam 2.729.060,87 MWh olarak gerçekleşen elektrik ithalatının % 18,08'i ise Gürcistan'dan karşılanmış, %5,88'i İran'dan ve %0,02'si ise Yunanistan'dan gerçekleştirilmiştir. İthalatın en yüksek olarak gerçekleştiği ay Ocak ayı iken, ithalatın en düşük seyrettiği ay ise Ekim ayı olmuştur. 2017 yılı için elektrik ithalat verileri Şekil 44'te gösterilmiştir.



Şekil 44. 2017 Yılı Aylar Bazında Türkiye Elektrik İthalatı

Kaynak: EPDK, 2018, Elektrik Piyasası 2017 Sektör Raporu, Ankara, ss. 47


2017 yılında gerçekleşen elektrik ihracatına ait grafik ise Şekil 45'te görülebilmektedir. Toplam gerçekleşen 3.300.096,20 MWh'lik elektrik ihracatının çok büyük bir kısmı (%96,97) Yunanistan'a, toplam %3,03'lük kısmı ise Bulgaristan ve Gürcistan'a yapılmıştır. İhracatın en yüksek gerçekleştiği ay Kasım ayı iken En düşük gerçekleştiği ay Şubat ayı olmuştur.




Şekil 45. 2017 Yılı Aylar Bazında Türkiye Elektrik İhracatı (MWh)

Kaynak: EPDK, 2017c, Elektrik Piyasası 2017 Sektör Rapor, Ankara, ss. 47

Türkiye'nin 2005 ile 2018 yılları arasında elektrik enerjisinde gerçekleştirmiş olduğu yıllık bazda ithalat ve ihracat göstergeleri Şekil 46'da, aylık bazda ise Şekil 47'de gösterilmektedir.



Şekil 46. 2005-2018 Yıllık Türkiye Elektrik İthalat ve İhracatı (kwh)



Şekil 47. 2005-2018 Aylık Türkiye Elektrik İthalat ve İhracatı (KWh)

Şekil 46'da görüldüğü gibi elektrik ithalatı 2014 yılı içerisinde en üst seviyeyi görmüş ondan sonra ise ithalat seviyesi azalarak devam etmiştir. Türkiye'deki

yenilenebilir enerjiden üretilen elektrik seviyesi buna neden olmuştur denilebilir. 2017 yılında ise elektrik ihracatı, elektrik ithalatının üzerinde seyretmiştir.

Tablo 29. 2018 Yılı Ülkeler Bazında Elektrik Enerjisi İthalat ve İhracatı (MWh)

		Yunanistan	Bulgaristan	Gürcistan	Toplam
Ocak	İthalat	6	165117	0	165123
	İhracat	245465	8829	0	254294
Şubat	İthalat	7	175547	13264	188818
	İhracat	205936	679	22	206637
Mart	İthalat	2386	127256	0	129642
	İhracat	163918	15317	36838	216073
Nisan	İthalat	4966	227769	0	232735
	İhracat	68982	2006	0	70988
Mayıs	İthalat	3346	117606	167674	288626
	İhracat	118665	11229	4201	134095
Haziran	İthalat	1	76393	151906	228300
	İhracat	279778	1	10455	290234
Temmuz	İthalat	0	204224	68453	272677
	İhracat	302792	1086	6	303884
Ağustos	İthalat	0	229858	0	229858
	İhracat	276355	2077	0	278432
Eylül	İthalat	18	204551	0	204569
	İhracat	221654	6156	0	227810
Ekim	İthalat	2	147358	1	147361
	İhracat	327465	6542	28045	362052

Kaynak: EPDK, 2018 Yılı Elektrik Piyasası Aylık Sektör Raporları

Tablo 31’de Türkiye’nin elektrik enerjisi dış ticaret konumu görünmektedir. Buna göre 2018 yılı için elektrik ticareti Yunanistan, Bulgaristan ve Gürcistan ile gerçekleştirilmiştir. Ticaret hacmine bakıldığında Yunanistan’ın elektrik tedarikçisinin Türkiye olduğu bununla beraber Bulgaristan ve Gürcistan’ın da Türkiye’nin tedarikçisi olduğu görülmektedir. 2016 ve 2017 yıllarında Türkiye elektrik ticaretine dâhil olan ülkelerden birisi de İran’dır. 2016 yılının ilk 5 ayı ve Aralık ayı ile 2017 Ocak ayında İran ile sadece ithalat gerçekleştirilmiştir. Şekil 47 ve Tablo 31’de görüldüğü üzere kış aylarında artan elektrik talebi İran’ın bu

denkleme dâhil olmasına neden olmuştur. Bununla beraber 2016 yılının Eylül ayında 29 MWh Suriye'ye elektrik ihraç edilmiştir. Bulgaristan, Gürcistan ve Yunanistan yine 2016 yılında Türkiye'nin elektrik ticaretinin aktörleri olmuşlardır⁶.



⁶ Bkz. Elektrik Piyasası Aylık Sektör Raporları. Elektrik enerjisi ithalat ve ihracat rakamlarına EPDK'nın yayınlamış olduğu 2016, 2017 ve 2018 yıllarına ait aylık elektrik piyasası sektör raporlarından ulaşılabilir.

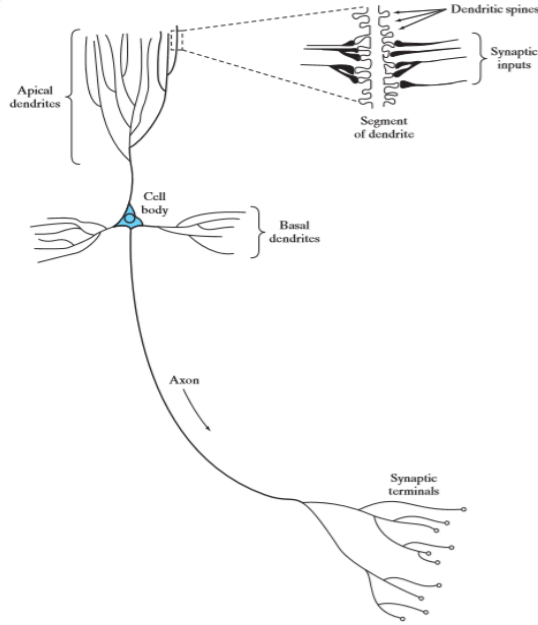
ÜÇÜNCÜ BÖLÜM

3.YAPAY SİNİR AĞLARI VE MODELLERİ

3.1 Yapay Sinir Ağları

Yapay sinir ağlarının konuşulmaya başlanması yaklaşık 50 yıl öncesine dayanmaktadır. Yapay sinir ağları ile insan beynini anlamak ve gücünü taklit etmek amaçlanmıştır (Fauset 1994:1).

Sinir hücresi ya da nöron merkezi sinir sisteminin temel işlem elemanıdır. Sinir hücrelerinin insan beyninde 10 milyar'a yakın olduğu söylenmektedir. Dentritle ise bir ağaç dalları gibi ince yollarla başka hücrelerden aldığı bilgileri hücre gövdesine (soma) iletir. Akson adı verilen yapılar dentritlere göre bilgiyi hücreden dışarıya taşıyan daha uzun bir yoldur. Aksonların ince yollara ayrılarak bitebilir ve bu yollar da böylece diğer hücreler için dentritleri oluşturur (Yüksek 2007: 11). Şekil 48'de basit bir sinir hücresi görülebilmektedir.



Şekil 48. Sinir Hücresi

Kaynak: Simon Haykin, 2009, Neural Networks and Learning Machine, Third Ed. New Jersey: Printice Hall, ss. 8

“Sinapsise gelen ve dentritler tarafından alınan bilgiler genellikle elektriksel darbelerdir ancak, sinapsisteki kimyasal ileticilerden etkilenir. Belirli bir sürede bir hücreye gelen girişlerin değeri, belirli bir eşik değerine ulaştığında hücre bir tepki üretir. Hücrenin tepkisini artırıcı yöndeki girişler uyarıcı, azaltıcı yöndeki girişler ise önleyici girişler olarak söylenir ve bu etkiyi sinapsis belirler. İnsan beyninin 10 milyar sinir hücresinden ve 60 trilyon sinapsis bağlantısından oluştuğu düşünülürse son derece karmaşık ve etkin bir yapı olduğu anlaşılır. Diğer taraftan bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş, duyuşsal bilgileri ise son derecede hızlı değerlendirebilmektedir. Beynin nöronları organize etme yeteneđi, böylece kesin hesaplamaları gerçekleştirme (örüntü tanıma, algılama gibi) bugünün en hızlı sayısal bilgisayarlarından daha hızlıdır” (Akt. Yüksek 2007: 12).

Hücrede gerçekleşen bir işlemin hızı yukarıda da belirtildiđi gibi çok yüksek değildir. Bununla beraber her bir nöron, işlevini oldukça yavaş ve kusurlu bir şekilde uygulamasına rağmen, bir ağ, şaşırtıcı derecede çok sayıda görevi oldukça verimli bir şekilde gerçekleştirebilir. Beynin bilgiyi işleme prosesi taklit edilerek geliştirilen yapay sinir ağları da bu özellik sayesinde güçlü bir hesaplama cihazı haline gelir ve örneklerden öğrenebilir ve daha önce hiç görülmemiş örneklere genelleme yapabilir (Zhang vd. 1998: 37). Bir sinir ađı, basit işlem birimlerinden oluşur ve tecrübe ettiđi bilgileri biriktirmeye, ezberlemeye yönelik eğilimi mevcuttur. Öğrendiđi verilerin ise kullanılmasını sağlamak için yoğun bir şekilde paralel dağılan bir işlemci gibi hareket eder. Yapay sinir ağları iki yönüyle beyine benzemektedir. Bunlardan birincisi; bilgiyi öğrenme yoluyla elde eder, diđeri ise nöronlar (sinir hücreleri) bilgiyi saklamak için kullanılır (Haykin 1999: 1-2).

3.1.1 Yapay Sinir Ağlarının Özellikleri

Yapay sinir ağlarının sahip olduđu öğrenme kabiliyeti, farklı problemlere kolay bir şekilde uyarlanabilmesi, öğrenme sürecinden sonra daha az bilgiye ihtiyaç

duyması, genelleme yapabilmesi, paralel yapılarından dolayı hızlı işlem yapabilmeleri ve zor matematiksel modelleri çok hızlı bir şekilde çözebilmeleri gibi sahip oldukları özellikler nedeniyle farklı birçok alanda başarılı bir şekilde uygulanabilmektedir. Yapay sinir ağları uygulanan ağ modeli ve algoritmaya göre değişik özellik göstermektedir. Genel olarak yapay sinir ağlarının özellikleri ise aşağıdaki gibi özetlenebilir (Kargı 2015: 25):

3.1.1.1 Doğrusal Olmayan Yapı

Yapay sinir ağlarının temel işlemi olan hücre elemanı doğrusal olmadığından hücrelerin birleşmesinden de doğrusal olmayan yapay sinir ağları oluşmaktadır. Bu özellik bütün ağa yayılmaktadır ve aynı katmanlar arasında zaman bağımlılığı bulunmamaktadır. Böyle bir yapı eş zamanlı olarak çalışabilmekte ve çalışmanın hızını artırmaktadır. Böyle bir yapı doğrusal olmayan karmaşık problemlerin çözümünde kolaylık sağlamaktadır (Kargı 2015: 25).

Doğrusal olmayan karmaşık problemleri çözümleyebilmesi açısından bu çalışmada da kullanılması ayrıca önem arz etmektedir. Ekonomik verilerin doğrusal olmaması yapıları gereği normal görülebilir ancak ortaya çıkan tahminlerde zorlanması nedeniyle analizler büyük ölçüde lineer yöntemler tercih edilerek yapılmaktadır. Ama böyle bir durum, problemlerin doğrusal olmayan yapı içermesi nedeniyle yanlış sonuçlara yol açabilmekte ya da analizi yapılan sistemde açıklanamayan bileşenler ortaya çıkabilmektedir. Analiz için kullanılacak veri setinin doğrusal veya doğrusal olmayan yapı içermesi analiz sonuçlarını etkileyecek önemli bir unsurdur (Bahadır, Özdemir 2016: 45-46). Bu nedenle YSA'lar kompleks yapıları çözümleyebilmesi adına önemli bir model olarak karşımıza çıkmaktadır.

YSA'ların bu özelliğini anlamlı kılan yaklaşım ise verilerin normalizasyon işlemidir. Veriler ağa gönderilmeden önce normalizasyon işlemine tabi tutulurlar, bu işlem verideki aşırı salınımları engellemek ve sistem performansını artırmak için kullanılır. Çünkü normalizasyon işlemi giriş verileri transfer edilirken fonksiyonun aktif olan bölgesinden aktarılmasını sağlar. Genellikle verilerin $[0, 1]$ veya $[-1, 1]$ aralıklarından birine ölçeklendirilmesi önerilmektedir. Veri kümesinin $[0, 1]$ arasında bir ölçeklendirmeye tabi tutulabilmesi için o kümenin minimum ve maksimum aralığının bulunması gerekmektedir (Kargı 2015: 78).

3.1.1.2 Örnekten Öğrenme

Sistem eğitime veya başlangıç tecrübesi sayesinde veriyi kullanarak öğrenme kabiliyetine sahiptir (Bahadır, Özdemir 2016:46). Öğrenme eğitime yoluyla örnekler kullanarak olur. Başka bir ifadeyle, eğitime algoritmasının verileri kullanarak bağlantı ağırlıklarını bir yakınsama sağlanana kadar tekrar tekrar ayarlamasıyla olur. Böylelikle yapay sinir ağları örnekleri kullanarak ilgili olay hakkında genelleme yapabilecek yeteneğe kavuşmuş olur (Kargı 2015: 26).

3.1.1.3 Paralellik

Ağlar, çok sayıda hücrenin farklı şekillerde bağlanmasıyla oluştuğundan paralel dağıtılmış bir yapıdadır ve ağdaki bilgi bütün bağlantılara dağılmış durumdadır. Alışılmış bilgi işlem yöntemlerinin ise çoğu seri işlemlerden oluşur. Bunun sonucunda hızda ve güvenilirlikte problemler doğurur. Seri işlemlerde herhangi bir birimdeki yavaşlama bütün sistemi yavaşlatır ancak paralel yapılarda yavaş bir birimin etkisi çok azdır (Simpson 1989: 6).

3.1.1.4 Yerel İşlem ve Esneklik

Geleneksel işlemcilerde, tek bir merkezi işlem elemanı her hareketi sırasıyla gerçekleştirir. Yapay sinir ağları ise geleneksellerden farklı işlem yapmaktadır. Yapay sinir ağları modelleri, her biri büyük bir problemin bir parçası ile ilgilenen çok sayıda basit işlem elemanlarından oluşma ve bağlantı ağırlıklarının ayarlanabilmesi gibi özelliklerinden dolayı önemli derecede esnek bir yapı sergilemektedir. Bu esnekliği sayesinde ağın bir kısmının zarar görmesi modelde sadece performans düşüklüğüne neden olur. Modelin işlevini tamamen yitirmesi söz konusu değildir. Bununla beraber, toplam işlem yükünü paylaşan işlem elemanlarının birbirleri arasındaki yoğun bağlantı yapısı sinirsel hesaplamanın temel güç kaynağıdır. Bu yerel işlem yapısı sayesinde, model en karmaşık problemlere bile uygulanıp yüksek performans sergileyebilmektedir (Bahadır, Özdemir 2016: 46).

3.1.1.5 Gerçek Zamanlı İşlem

Hesaplamalar paralel olarak yürütülebildiğinden gerçek zamanlı işlem yapılabilir (Bahadır, Özdemir 2016: 46).

3.1.1.6 Genelleme Yeteneđi

Yapay sinir ađları, ilgilendiđi problemi öğrenmesinden sonra eğitim aşamasında karşılaşmadıđı test örnekleri için de beklenen tepkiyi üretebilir. Örnek olarak; karakter tanıma amacıyla eğitilmiş bir yapay sinir ađının bozuk karakter girişı olduğunda da dođru karakterlerin elde edilmesine olanak sađlar yani hatalı veya kayıp veriler için çözüm üretebilmektedir. (Kargı 2015: 27; Bahadır, Özdemir 2016: 47).

3.1.1.7 Uyarlanabilirlik

Problemde herhangi bir deđişiklikte yeniden eğitilebilir ve farklı koşullara uyarlanabilir. Bu özelliđiyle örnek tanıma, sinyal işleme, sistem tanıma ve kontrol gibi alanlarda etkin olarak kullanılır (Simpson 1989: 6)

3.1.1.8 Sınırsız Sayıda Deđişken ve Parametre

Karmaşık ya da sorunlu verilerden bile anlam çıkarabilme özelliđinden dolayı YSA'lar, insanlar ya da bilgisayarlar tarafından anlaşılması güç hareketleri çözümlmek için kullanılabilirler. Yapay sinir ađları tam eğitildiđi zaman analiz edilen bilgi kümesi için uzmanlaşmaktadır. Bu uzmanlık ise farklı durumlar ve farklı sorular için (...olsa ne olur?) simüle edilerek projeksiyon elde edilmesinde kullanılabilir.

Bahsedilen avantajlarının yanısıra YSA'ların bazı dezavantajları da bulunmaktadır. Bunlardan ilki büyük hacimli veri setine duyulan ihtiyaçtır. Yapay sinir ađlarının eğitimi ve test edilebilmesi için veri setinin sayıca yüksek olması beklenir. Bir diđer dezavantaj ise uygulamanın karmaşık ve zor olabileceđi kısmıdır. Bazı problemlerde yakın sonuç elde etme imkansız olabilmektedir ancak bu durum model uygulamasına bađlıdır ve problem çok fazla karmaşık ise görülebilir (Bahadır, Özdemir 2016: 47-48).

Buradan hareketle yapay sinir ađlarının avantajları ve dezavantajları řu şekilde sıralanabilir (Elmas 2016: 33-34):

- Modellerin eğitimlerinde verilen bilgiler sayesinde genelleme yapabilme özelliđi mevcuttur ve bu sayede bilgi üretebilir.
- Matematiksel bir modele ihtiyaç duyulmamaktadır.

- Eğitim süresinde ihtiyaç duyulan bir varsayım yoktur.
- Modele dâhil edilen veriler aracılığıyla bilinmeyen ilişkileri de ortaya çıkarabilir.

- Esnekliği yani hataya karşı toleransı sayesinde nöronlarda gerçekleşebilecek bir zarar bütün bir sistemi büyük oranda etkilemez ancak geleneksel sistemlerde oluşabilecek böyle bir hata bütün bir sisteme mal olarak sonucun üretilmemesine neden olmaktadır.

- Ağırlık katsayısı gibi herhangi bir parametre değişikliğinde çözüm için ağ kendini uyarlayabilmektedir.

- Doğrusal olan modellere göre üstünlüğü mevcuttur çünkü ağlar dorusal olmadığından karmaşık problemlere çözüm sunabilmektedir.

Dezavantajları ise şu şekilde sıralanabilir (Elmas 2016: 33-34).

- Probleme uygun bir ağ yapısının belirlenme zorluğu vardır. Uygun ağ yapısının belirlenme süreci genellikle deneme yanılma ile tespit edilir bu nedenle uzun zaman alabilmektedir. Eğer probleme uygun bir ağ yapısı oluşturulamazsa çözümü olan bir problemin çözülememesine ya da düşük performans elde edilmesine neden olabilmektedir. Bununla beraber bulunan çözümün en iyi çözüm olduğunun garantisi de verilememektedir.

- Ağ için gerekli olan parametre değerleri (öğrenme katsayısı, hücre sayısı gibi) belirlemede bir kural yoktur, bu nedenle çözümlere ulaşmada sıkıntı oluşabilmektedir. Bu değerler ağı kullananın tecrübesine bağlıdır.

- Problemin ağ gösterimi çok önemlidir. YSA'lar sadece sayısal verilerle çalıştığı için oluşturulan problemin sayısal değerlere çevrilmesi gerekmektedir.

- Oluşturulan ağın eğitiminin ne zaman bitirileceğine dair net bir kural bulunmamaktadır. Eğitim sırasında hata toleransının belirli bir değerin altına inmesi eğitimin tamamlanması için yeterli görülmektedir.

3.1.2 Yapay Sinir Ağlarının Kullanım Alanları

Yapay sinir ağlarının kullanım alanı oldukça çeşitlilik göstermektedir. Literatürde çeşitli alanlarda YSA'nın kullanıldığı çalışmalar mevcuttur. YSA'nın uygulama alanları şu şekilde belirtilebilir (Bahadır, Özdemir 2016: 48-50);

- Arıza analizi ve tespiti
- Tıp
- Savunma sanayi
- Haberleşme
- Üretim
- Otomasyon ve kontrol
- Eğitim
- Kalite kontrol
- Finansal öngörü
- Ekonomik öngörü
- Kredi derecelendirme
- Konuşma ve yapı tanımlama
- İşlem modelleme ve yönetimi
- Laboratuvar araştırmaları
- İflas tahmini
- Petrol ve gaz arama


3.1.3 Yapay Sinir Ağının Yapısı

Bir sinir ağı, nöronlar, birimler, hücreler veya düğümler olarak adlandırılan çok sayıda basit işleme elemanından oluşur. Her nöron, her biri ilişkili bir ağırlığa sahip olan yönlendirilmiş iletişim bağlantıları vasıtasıyla diğer nöronlara bağlanır. Ağırlıklar, bir problemi çözmek için ağ tarafından kullanılan bilgiyi temsil eder. Sinir ağları, veri veya örüntüleri saklamak ve geri çağırmak, kalıpları sınıflandırmak, giriş örüntülerinden çıkış örüntülerine genel eşleştirmeler yapmak, benzer modelleri gruptandırmak veya kısıtlı optimizasyon problemlerine çözüm bulmak gibi çok çeşitli problemlere uygulanabilir (Fauset 1994: 3).

Her nöron, aldığı girişlerin bir fonksiyonu olan aktivasyon veya aktivite seviyesi olarak adlandırılan dahili bir duruma sahiptir. Yapısal olarak bir nöron aktivasyonunu diğer birçok nörona bir sinyal olarak gönderir. Sinyalin diğer nöronlara yayın yapması durumunda, bir nöronun her seferinde sadece bir sinyal gönderebileceğini unutmamak önemlidir (Fauset 1994: 3).

Şekil 49’da görüldüğü gibi; X_1 , X_2 ve X_3 nöronlarından giriş alan bir Y nöronu düşünülebilir. Bu nöronların aktivasyonları (çıkış sinyalleri) sırasıyla x_1 , x_2 ve x_3 ’tür. X_1 , X_2 ve X_3 ’ten Y nöronuna olan bağlantılar üzerindeki ağırlıklar sırasıyla w_1 , w_2 ve w_3 ’tür. Net girdi olan y_{in} , Y nöronuna X_1 , X_2 ve X_3 ’ten gelen ağırlıklı sinyallerin toplamıdır (Fauset 1994: 3).

$$y_{in} = w_1 x_1 + w_2 x_2 + w_3 x_3$$




Şekil 49. Basit Bir Yapay Sinir

Kaynak: L. Fauset, 1994, Fundamentals of Neural Network, Prentice Hall International, London, s. 4

Y nöronunun y aktivasyonu, net girdinin $y = f(y_{in})$ gibi bir fonksiyonla, S-şekilli bir eğri olan lojistik sigmoid fonksiyonu ile veya başka bir dizi aktivasyon fonksiyonundan herhangi biri ile verilir (Fauset 1994: 4).

$$F(x) = \frac{1}{1 + \exp(-x)}$$


Y nöronunun sırasıyla v_1 ve v_2 ağırlıkları olan Z_1 ve Z_2 nöronlarına bağlı olduğu varsayılırsa; Y nöronu sinyalinin bu birimlerin her birine gönderir (Şekil 50). Bununla birlikte, genel olarak, Z_1 ve Z_2 nöronları tarafından alınan değerler farklı olacaktır, çünkü her sinyal uygun v_1 veya v_2 ağırlıkları ile ölçeklendirilir. Tipik bir ağda, Z_1 ve Z_2 nöronlarının z_1 ve z_2 etkileşimleri, sadece bir değil, birçok nörondan gelen girdilere bağlı olacaktır (Fauset 1994: 4).



Şekil 50. Basit Bir Yapay Sinir Ağı

Kaynak: L. Fauset, 1994, Fundamentals of Neural Network, Prentice Hall International, London, s. 4

Yapay sinir ağı çok basit olmasına rağmen, bir gizli ünitenin, lineer olmayan bir aktivasyon fonksiyonu ile birlikte, sadece bir giriş ve çıkış birimleri ile bir ağ tarafından çözülebilecek olandan çok daha fazla problemi çözme yeteneğini verir. Öte yandan, gizli birimlerle bir ağı eğitimi, ağırlıklar için en uygun değerlerin bulunması gibi problemler olduğundan zorlaşabilmektedir (Fauset 1994: 4).



Şekil 51. Yapay Sinir Ağının Genel Yapısı

Kaynak: Simon Haykin, 2009, Neural Networks and Learning Machines, 3. Baskı, New Jersey: Prentice Hall, ss.11

Şekil 51’de yapay sinir ağının matematiksel olarak basit bir şekilde ifade edilişi görülmektedir. Model incelendiğinde “*biyolojik nörona benzer bir şekilde işlem elemanı toplama fonksiyonu sonucunun belirli bir eşik değerinin altında veya üstünde olmasına göre çıktısını iki ihtimal arasından seçerek oluşturmaktadır. Bu matematiksel modelin fonksiyonel gösterimi*” (Bahadır, Özdemir 2016: 28);

$$y(i) = \Psi(g(x)) = \Psi(\sum_{j=1}^n w_{ij}x_j - Q_i ; x_i = (x_0, x_1, \dots, x_n) \in$$

“*Bu gösterimde $y(i)$ çıktı değeri, $\Psi(\cdot)$ transfer fonksiyonunu, $g(\cdot)$ toplama fonksiyonunu, w_{ij} bağlantı ağırlıklarını ve Q_i ise i nolu nöron için eşik değerini göstermektedir. $\Psi(\cdot)$ Transfer fonksiyonu birim adım fonksiyonudur*” (Bahadır, Özdemir 2016: 28).

$$\Psi(\cdot) = \frac{1; g(\cdot) \geq 0}{0; g(\cdot) < 0}$$

$g(.)$ toplama fonksiyonu ise x_i girdilerinin doğrusal bir bileşimi olarak düşünülmektedir;


$$g(.) = \sum_{j=0}^n w_{ij} x_i - Q_i$$

Yukarıda belirtilen fonksiyonlarla beraber YSA alanındaki gelişmeler farklı fonksiyonların kullanılabilmesini sağlamıştır. YSA modellerinde kullanılacak fonksiyonlar değişebilmektedir. Örneğin toplama fonksiyonu yerine maksimumum, minimum, ortalama gibi fonksiyonlar kullanılabilir. Transfer fonksiyonunda ise farklı olarak hiperbolik tanjant, lineer, sigmoid gibi fonksiyonlar kullanılabilir. Böyle durumlarda hangi fonksiyon kullanılırsa kullanılsın, bir sinir ağı modelinin matematiksel ve fonksiyonel gösterimi değişmeyecektir (Bahadır, Özdemir 2016: 29-30).

“Bu yapıda kullanılan fonksiyonlar temelde uygulama konusuna bağlıdır. Bazı uygulamalar ikili veri seti gerektirmektedir. Bu uygulamalara örnek olarak konuşma tanımlama ve metin tanıma uygulamaları verilebilir. Bu tür uygulamalar, doğal olarak, sadece toplama fonksiyonu içeren nöronlardan oluşan ağları kullanamazlar. Bu ağlar mantıksal fonksiyonları kullanabilir ve bu fonksiyonlar toplama ve transfer fonksiyonlarına dâhil edilebilir ya da bazı uygulamalar basit bir şekilde toplama ve belirli bir eşik değeri ile karşılaştırma şeklinde bir işleme gereksinim duyabilirler. Bu şekilde evet/hayır, doğru/yanlış veya 0/1 gibi iki olası sonuç arasından seçim yapılabilir. Bazı fonksiyonlar ise girdi verileri zamanla ilişkilendirebilir ve bu şekilde zamana bağlı ağlar oluşturabilir” (Bahadır, Özdemir 2016: 29).

Toplama fonksiyonu ile hesaplanan net girdi değerine göre sistem üreteceği çıktıyı belirlemek için transfer fonksiyonunu kullanmaktadır. Transfer fonksiyonu transfer fonksiyonu genellikle doğrusal olmayan bir fonksiyondur çünkü doğrusal fonksiyonlarda çıktı girdi ile orantılıdır. Genellikle kullanılan transfer fonksiyonları Şekil 52’de gösterilmektedir (Bahadır, Özdemir 2016: 31-32; Öztemel 2006: 50). Örneğin bir ağı bir modelin ortalama davranışını öğrenmesi isteniyorsa sigmoid,

ortalamadan sapmasını öğrenmesi isteniyorsa hiperbolik tanjant fonksiyonlarının kullanılması önerilmektedir (Kargı 2015: 74).



Şekil 52. Sıklıkla Kullanılan Transfer Fonksiyonları

Sisteme tekdüze olarak dağılmış bir rassal hata, transfer fonksiyonu işlemi öncesinde eklenebilir. Eklenen rassal hatanın büyüklüğü ve ağırlık öğrenme işlemi esnasında belirlenir. Böyle bir hata teriminin sisteme eklenmesinin sebebi, insan beyninin fonksiyonel olarak içinde bulunduğu ortam şartlarından (örneğin sıcaklık/soğukluk) etkileniyor olmasıdır. Bu nedenle, literatürde rassal hata ekleme işlemine sıcaklık (temperature) adı verilmektedir (Bahadır, Özdemir 2016:31).


3.1.4 Yapay Sinir Ağı Modelleri

Hücrelerin çeşitli şekillerde birbirleri ile bağlanmalarından oluşan yapay sinir ağlarında hücre çıkışları, ağırlıklar üzerinden diğer hücelere ya da kendisine giriş olarak bağlanabilirler. Hücrelerin bağlantı şekillerine, öğrenme biçimlerine ve kullanılan aktivasyon fonksiyonlarına göre çeşitli yapay sinir ağı modelleri geliştirilmiştir.

3.1.4.1 Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı

Tek katmanlı bir sinir ağında, nöronlar tabakalar halinde düzenlenmektedir. En basit biçimde katmanlı bir ağda, sinyallerin giriş katmanından doğrudan çıkış katmanına akışının olduğu bir yapı bulunmaktadır. Bu akış tam tersi yönde olamaz.

Başka bir deyişle, bu ağ kesinlikle ileriye dönük bir türdür. Şekil 54’te ileri beslemeli tek katmanlı ağ yapısı görülmektedir. Girdi ve çıktı katmanları göz önüne alındığında bu ağın tek katmanlı ağ olarak adlandırılmasının nedeni; girdi katmanında hiçbir hesaplama yapılmamasından kaynaklanmaktadır (Haykin 1998: 21).



Şekil 53. İleri Beslemeli Tek Katmanlı Sinir Ağı


Kaynak: Simon Haykin, 1998, Neural Networks: A Comprehensive Foundation, Second Ed., Prentice hall, New Jersey, s. 21

3.1.4.2 Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı

İleri beslemeli sinir ağlarının bir diğer formu ağın girdisinde ya da çıktısında doğrudan görülmeyen bir ya da birden fazla gizli katmanın ya da gizli nöronların olduğu çok katmanlı modeldir. Gizli nöronların fonksiyonu girdi ve çıktı arasında ağda faydalı müdahalelerde bulunmaktır. Bir veya daha fazla gizli katman eklendiğinde, ağın girişinden daha yüksek sıralı istatistikler çıkarılması sağlanır. Böylelikle ağ, sinaptik bağlantıların ekstra seti ve sinirsel etkileşimlerin ekstra boyutu nedeniyle yerel bağlantısına rağmen küresel bir bakış açısı kazanır (Haykin 1998: 22).

Ağın giriş katmanı, ikinci tabakadaki (yani ilk gizli katman) nöronlara uygulanan giriş sinyallerini oluşturan aktivasyon modelinin ilgili verilerini tedarik

eder. İkinci katmanın çıkış sinyalleri, üçüncü katmana girdi olarak kullanılırken ağın geri kalanı için de kullanılır. Tipik olarak, ağın her katmanındaki nöronlar, sadece önceki katmanın çıkış sinyallerini alırlar. Ağın çıkış (nihai) katmanındaki nöronların çıkış sinyal dizisi, ağın girdi (birinci) katmandaki kaynak düğümler tarafından sağlanan aktivasyon modeline olan genel cevabı oluşturur. Şekil 54, tek bir gizli katmanı bulunan çok katmanlı ileri besleme ağının düzenini göstermektedir. Özetle bu ağ, 10 kaynak düğümü, 4 gizli nöron ve 2 çıkış nöronuna sahip olduğu için 10-4-2 ağ olarak adlandırılır. Başka bir örnek olarak, m kaynağı düğümleri olan bir ileri besleme ağının, birinci gizli katmanında h1 nöronları, ikinci gizli katmanında h2 nöronları ve çıkış katmanında q nöronları bulunuyorsa bu da bir m – h1 – h2 – q ağı olarak adlandırılır (Haykin 1998: 22).



Şekil 54. Bir Gizli Katmanlı ve Bir Çıktı Katmanı Bulunan Tam Bağlantılı İleri Beslemeli Ağ

Kaynak: Simon Haykin, 1998, Neural Networks: A Comprehensive Foundation, Second Ed., Prentice hall, New Jersey, s. 22

Şekil 55'in "tam bağlantılı ağ" olarak adlandırılmasının nedeni katmanlardaki tüm düğümlerin kendilerinden sonraki bütün düğümlere bağlanmış olmasıdır. Eğer

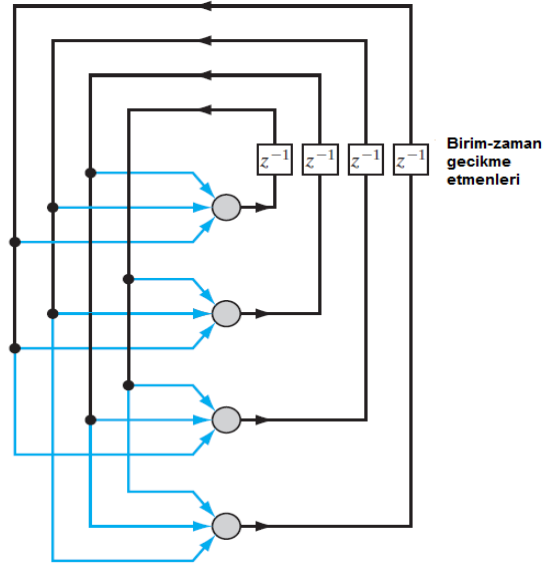
sinaptik bağlantılardan herhangi biri yada birileri eksik olsaydı “kısmen bağlı ağ” olarak adlandırılacaktı (Haykin 1998: 22).

Görüldüğü üzere bir ileri beslemeli yapay sinir ağında işlemler girdi katmanından çıkış katmanına doğru iletilmektedir. Dışarıdan alınan bilgiler değişikliğe uğramadan gizli katmana gönderilirler. Bu katmanda işlenen veriler ise çıktı katmanına iletilirler. Gizli ve ara katmanlardaki çıktıların değerleri sonraki katmanlardaki girdilerin değeri olarak karşımıza çıkmaktadır.

3.1.4.3 Tekrarlayan Yapay Sinir Ağı (Recurrent Neural Network)


Tekrarlayan bir sinir ağı, en az bir geri besleme döngüsüne sahip olmasıyla, ileriye dönük bir sinir ağından kendisini ayırt etmektedir. Örneğin, tekrarlayan bir ağ, Şekil 55'teki mimari grafikte gösterildiği gibi her nöronun çıkış sinyalini diğer tüm nöronların girişlerine geri besleyen tek bir nöron katmanından oluşabilir. Ağda kendi kendine geri bildirim döngüsü yoktur; kendinden geribildirim ise bir nöronun çıkışının kendi girdisine geri beslendiği durumdur. Şekil 55'te gösterilen tekrarlayan ağda ayrıca hiçbir gizli nöron yoktur (Haykin 1998: 23).

Şekil 56'da gizli nöronlara sahip tekrarlayan bir yapay ağ gözlemlenmektedir. Bu ağ yapısında gösterilen geri besleme bağlantıları, gizli nöronlardan olduğu kadar, çıktı nöronlarından da kaynaklanmaktadır. Şekil 55'deki tekrarlanan yapıda veya Şekil 56'da gösterilen döngüdeki geri beslemenin varlığı, ağın öğrenme kapasitesini ve performansını büyük bir oranda etkilemektedir. Ayrıca, geri bildirim döngüleri, sinirsel ağın lineer olmayan birimler içerdiğini varsayarak, doğrusal olmayan bir dinamik davranışla ortaya çıkan birim-zaman gecikme elemanlarından (z^{-1} ile belirtilen) oluşan özel düzeylerin kullanımını içermektedir (Haykin 1998: 23). Tekrarlayan ağlarda oluşturmuş ara katman elemanlarının sadece ileriye değil ağa tekrar gönderilerek işlenmesi (Öztemel 2012: 184) nedeniyle bu yöntem daha güçlü bir yöntem olarak görülmektedir.



Şekil 55. Kendi Kendine Geri Bildirim Döngülerinin Olmadığı Ve Gizli Bir Nöronun Bulunmadığı Tekrarlayan Sinir Ağı

Kaynak: Simon Haykin, 1998, Neural Networks: A Comprehensive Foundation, Second Ed., Prentice hall, New Jersey, s. 23



Şekil 56. Gizli Katmanlı Tekrarlayan Sinir Ağı


Kaynak: Simon Haykin, 1998, Neural Networks: A Comprehensive Foundation, Second Ed., Prentice hall, New Jersey, s. 23

3.1.4.4 LSTM (Long- Short Term Memory/Uzun- Kısa Süreli Bellek) ve Bi-LSTM (Bidirectional Long Short Term Memory/Çift Yönlü Uzun-Kısa Süreli Bellek)

Uzun kısa süreli belleğe sahip tekrarlayan sinir ağları (LSTM), dizi verilerini işleyen ve derin öğrenme alanında kullanılan özel bir yapay tekrarlayan sinir ağı mimarisidir (RNN).

LSTM'ler, sıralı verilerle ilgili çeşitli öğrenme problemleri için etkili ve ölçeklenebilir bir model olarak ortaya çıkmıştır. Öte yandan LSTM'ler uzun vadeli geçici bağımlılıkları yakalamada etkilidirler. Basit tekrarlayan ağlarda (SRN'ler) varolan optimizasyon engellerine takılmazlar ve birçok zor problemlerde son teknolojiyi geliştirmek için kullanılmışlardır. El yazısı tanımlama, konuşma sentezi, ses analizi ve yapı tahminleri kullanıldığı alanlara örnektir (Gref vd. 2017: 2222).


LSTM mimarisinin arkasındaki ana fikir, zaman içinde durumunu koruyabilen bir bellek hücresi olması ve hücreye giren ve çıkan bilgi akışını düzenleyen doğrusal olmayan kapama birimlerini barındırmasıdır. LSTM'ler şu anda, bu gelişmelerin başlangıçta test edildiği problemlerden, ölçek ve nitelik bakımından önemli ölçüde farklılık gösteren birçok öğrenme problemine uygulanmaktadır. LSTM'leri içeren çeşitli hesaplama bileşenlerinin kullanımına dair sistematik bir çalışma Şekil 57'de görülebilmektedir. (Gref vd. 2017: 2222).



Şekil 57. Basit bir Tekrarlayan Ağ (SRN) birimi (solda) ve tekrarlayan bir sinir ağının gizli katmanlarında kullanılan bir Lstm mimarisinin (sağ) ayrıntılı şeması.

Kaynak: Gref, K., Srivastava, R. K., Koutnik, J., Steunebrink, B. R. ve Schminhuber, J. (2017), “LSTM-A Search Space Odyssey”, Transactions on Neural Networks And Learning Systems, 1-12

Bi-LSTM’ler ise dizi problemlerinde model performansını artırabilen bir LSTM uzantısıdır. Giriş sırasının tüm zaman adımlarının mevcut olduğu problemlerde bi-LSTM’ler, giriş sırasındaki bir tane lstm algoritması yerine iki tane çalıştırmaktadır. Birincisi, giriş sırasındaki gibi, ikincisi ise girdi sırasının tersi şeklinde kopyalanmış şekildedir. Her adımda bi-lstm geçmiş ve gelecekteki değerlere bakar. Bu da ağa ek içerik sağlayabilir ve sorunla ilgili daha hızlı ve hatta daha dolu bir öğrenmeyi beraberinde getirir. Şekil 58’de bir bi-LSTM mimarisi görülebilmektedir.



Şekil 58. Üçlü çift yönlü LSTM (Bi-LSTM) mimarisi

Kaynak: Cui, Z., Ke, R. ve Wang, Y. (2017) “Deep Stacked Bidirectional and Unidirectional LSTM Recurrent Neural Network for Network-wide Traffic Speed Prediction”, <https://arxiv.org/ftp/arxiv/papers/1801/1801.02143.pdf> Erişim Tarihi: 27.05.2019

3.1.5 Yapay Sinir Ağı Modellerinde Kullanılan Süreçler ve Algoritmalar

İstatistiksel yöntemlerde verilerden en iyi performansla doğru sonuçları elde etmek için çeşitli algoritmalar kullanılmaktadır. Yapay sinir ağı modelleri olan Bi-LSTM ve feed forward methodlarında da performansı artırmak için kullanılan optimizasyon ve öğrenme algoritmaları mevcuttur. Bunlarla beraber büyük ölçekli verilerin oluşturduğu modellerde bilgilerin doğru işlenebilmesi ve okunabilmesi için de normalleştirme yöntemlerini kullanılması gerekmektedir.

3.1.5.1 Verileri Normalleştirme Yöntemleri

Yapay sinir ağlarının eğitiminde belirli ön işleme (preprocess) adımları uygulayarak sinir ağı eğitimi daha verimli hale getirilebilir. Yapay sinir ağı işleme fonksiyonları, ağ kullanımı için girdileri daha iyi bir forma dönüştürmektedir. Ham girdiler için normalleştirme sürecinin, verilerin eğitime uygun olması için hazırlanmasında çok büyük etkisi vardır. Bu normalleşme olmadan, sinir ağlarını

eğitmek çok yavaş olabilmektedir. Birçok veri normalleştirme türü vardır. Sinir ağlarındaki olumsuz etkileri en aza indirmek amacıyla normalleştirme her bir giriş verisini aynı değer aralığında ölçeklendirmek için kullanılabilir. Girdilerin genellikle farklı ölçeklerde olduğu modellerde özellikle yararlıdır. Normalleştirme sürecinde farklı teknikler kullanılabilir (Jayalakshmi, Santhakumaran 2011: 91). Doğru verilerin işlenememesi ve yorumlanabilmesi için tercih edilen methodlardan ikisi “normalizasyon” ve “z-score standardizasyon”dur.

3.1.5.1.1 Normalizasyon

Normalizasyonun amacı, Öklid norm matrisiyle elde edilebilecek olan değerler için 0 dan 1 e kadar karakter kazandırmaktır (Trebuna vd. 2014: 383).

Normalizasyonda en çok tercih edilen tekniklerden birisi “min-max normalizasyonu”dur. Bu tekniğin formülü;

$$X_{norm} = \frac{X - \min(X)}{\max(X) - \min(X)}$$

şeklindedir.

3.1.5.1.2 Z-Skore Standardizasyonu

İstatistikî analizlerde en çok kullanılan normalleştirme metotlarından birisi de Z-Score standardizasyonudur. Bu yöntemde standardize edilmiş değer alınan değer ile ortalama değer arasındaki fark standart sapmaya bölünerek elde edilmektedir (Larose 2005: 37).

$$X_{stand} = \frac{X - ortalama(X)}{standart sapma(X)}$$

3.1.5.2 Feed Forward Öğrenme/Eğitim/Optimizasyon Algoritmaları

Eğitim, YSA'nın en uygun ağırlıklarını ve biasını belirleme sürecidir. Bu süreç ağırlık çıkışı ile istenen hedef arasındaki toplam hata işlevini tanımlanarak ve ardından ağırlıklar en aza indirilerek yapılır. İleri beslemeli yapay sinir ağlarının öğrenilmesinde kullanılan ve çalışmada ele alınan öğrenme algoritmaları aşağıdaki gibidir (Zhou, Jang 2010: 946; Baghirli 2015: 9-12):

- Lavenberg-Marquardt (LM)

- *Bayesian regularization (BR)*
- *Scaled conjugate gradient (SCG)*
- *Conjugate Gradient Backpropagation with Fletcher-Reeves Restarts (CGF)*

3.1.5.2.1 Lavenberg-Marquart (LM)

LM algoritması, $f(x)$ fonksiyonunun ikinci derece kısmı türevini içeren ve simetrik yapıda olan Hessian matrisini hesaplamak zorunda kalmadan ikinci dereceden eğitim hızına yaklaşmak için tasarlanmıştır. Performans işlevi bir toplam kareler şeklinde olduğunda, Hessian matrisi yaklaşık olarak hesaplanabilir ve eğim ölçümlenebilir (akt. Baghirli 2015: 9).

LM algoritmasının eşitliği aşağıdaki gibidir;

$$w_{ij}(k+1) = w_{ij}(k) - (J_k^T J_k + \mu I)^{-1} J_k e_k$$

w_{ij} , i_{th} nöronunun j_{th} girdisi ağırlığı; e_k , k_{th} iterasyonundaki hata sayısı; J_k $w_{ij}(k)$ ağırlığına ilişkin e_k jakobisi; her zaman pozitif olan μ kombinasyon katsayısı ve I ise birim matrisidir (Keshavarz-Hedayati vd. 2015: 2).

3.1.5.2.2 Bayesian Regularization (BR)

Yapay sinir ağlarında düzenleme, eğitim algoritmasına kısıtlama getirme sürecidir. Bu sınırlama, kötü bilgilendirilmiş problemi, belli bir bilgi ve varsayım ekleyerek iyi bir soruna dönüştürür. Bayesian düzenlemesinde, performans işlevi bir hata teriminin toplamı ve ağırlıkların ağırlığına bağlı bir terim olarak oluşturulur (Keshavarz-Hedayati vd. 2015: 2);

$$E_D = \sum_{i=1}^N (t_i - o_i)^2$$

N , giriş veri noktası sayısı; t_i , i_{th} veri noktası için hedef değer, o_i ise ağırlık veri noktasına verdiği cevaptır. Performans işlevi ise aşağıda gösterildiği gibidir;

$$F = \beta E_D + \alpha \sum_j \sum_i w_{ij}^2$$

α ve β amaç fonksiyonu parametreleridir. w_{ij} , j_{th} nöronuna olan girdinin ağırlığıdır. Bu metodoloji kullanıldığında, eğitim süreci genellikle küçük ağırlıkları

olan ağırları seçerek aşırı esnek veya karmaşık ağırlardaki problemleri çözümlenebilir (Keshavarz-Hedayati vd. 2015: 2).

α ve β 'nin optimal değerlerini bulmak oldukça zor bir iştir. Bayesian düzenleme algoritmasında, α ve β bir başlangıç değeri kabul eder ve LM kullanılarak, bir eğitim iterasyonu gerçekleştirilir. Daha sonra bir olasılık dağılımı (normal dağılım) kullanılarak, α ve β 'nin optimal değerleri hesaplanır. Sonra bu işlem yakınsama sağlanana kadar tekrarlanarak devam eder (Foresee, Hagan 1997: 1930-1931). Anlaşıldığı üzere Bayesian regularization algoritması, levenberg-marquart optimizasyonuna göre ağırlıkları ve bias değerlerini güncelleyen bir eğitim algoritmasıdır. Hata karelerini ve ağırlıkların kombinasyonunu en aza indirir ve daha sonra genel olarak iyi bir ağ oluşturmak için doğru kombinasyonu belirler (akt. Baghirli 2015: 12).

3.1.5.2.3 Scaled Conjugate Gradient (SCG)

SCG algoritması, eşlenik gradyan yönteminin, ölçeklendirilmiş adım büyüklüğüne sahip bir varyasyonudur. Ağırlıklar eşlenik doğrultular boyunca ayarlanmaktadır. Bununla birlikte, her bir yinelemede zaman alan hat aramalarını önlemek için, SCG algoritması, adım boyutunu ölçeklendirmek adına model-güven bölgesi yaklaşımını birleşik gradyan yaklaşımı ile birleştirir. Bu algoritma, diğer eşlenik gradyan algoritmalarından daha fazla yakınsama yapmak için daha fazla yineleme gerektirebilir, ancak genellikle daha az hesaplama karmaşıklığı içerir ve her yineleme için daha az bilgisayar belleği gerektirmektedir (Zhou, Yang 2010: 947).

SCG'yi kullanarak bir sinir ağını eğitmek için; ağırlıklar, girdiler ve transfer fonksiyonları türev fonksiyonlara sahip olmalıdır. SCG, Newton metodu ile gradyan azalma arasında olan bir yöntemdir. Newton'un yönteminde, Hessian matrisinin ters çevrilmesi, saklanması ve değerlendirilmesi gibi bazı bilgiler gereklidir ve SCG bu bilgilerden kaçınır. SCG, gradyan azalma yöntemiyle bağlantılı olarak yavaş yakınsamayı hızlandırmak için uygulanmaktadır. w_0 'ın başlangıç parametresi vektörü ve " $v_0 = -g_0$ "ın başlangıç eğitim vektörü olduğu düşünüldüğünde, eğitim fonksiyonu eşitliği şu şekilde oluşturulabilir (Bataineh, Kaur 2018: 176);

$$v_{i+1} = g_{i+1} + v_i X_i, \quad i = 0, 1, 2, 3, \dots$$

Burada v eğitim vektörü, X ise eşlenik (konjuge) parametredir. SCG'de eğitim daima gradyanın negatifine doğru sıfırlanır (Bataineh, Kaur 2018: 176-177).

3.1.5.2.4 Gradient Backpropagation with Fletcher-Reeves Restarts (CGF)

Bu algoritma Fletcher ve Reeves tarafından 1964'te önerilmiştir. Modelde algoritma mevcut gradyanın norm karesinin önceki gradyanın norm karesine oranı alınarak hesaplanmaktadır (Zhou, Yang 2010: 946).

Eşlenik gradyan algoritmalarının çoğunda, her bir yinelemede adım boyutu ayarlanır ve steepest descent algoritması yönünde (gradyanın negatifi) bir arama yapılmakta ve küçültme, geçerli arama yönünde gerçekleştirilmektedir. Yeni arama yönü, steepest descent algoritması yönü ile önceki arama yönü olan β_k ile birleştirilerek, Fletcher-Reeves güncellemesinde parametre olarak belirlenir (Payal vd. 2014: 2).

$$\beta_k = \frac{\mathbf{g}_k^T \mathbf{g}_k}{\mathbf{g}_{k-1}^T \mathbf{g}_{k-1}}$$

Burada \mathbf{g}_k geçerli adımdaki gradyanın tahmini, \mathbf{g}_{k-1} ise önceki adımdaki gradyanın tahminidir. Fonksiyon mevcut gradyanın norm karesinin, önceki gradyanın norm karesine oranıdır (Payal vd. 2014: 3).

3.1.5.3 LSTM Optimizasyon Yöntemleri

En iyileme anlamına gelen optimizasyon, belirli sınırlamaları sağlayarak sonucu bilinmeyen problemlerin parametre değerlerinin bulunmasını içermektedir. Başka bir deyişle herhangi bir problemde, mevcut koşullar altında tüm çözümler içinden en iyi çözüme ulaşmaktır (Altunbey, Alataş 2015: 34). Çalışmanın Metodu olan Bi-Lstm için kullanılan optimizasyon yöntemleri;

- *Adaptive momentum estimation (ADAM)*
- *Root mean square error probability (RMSprop)*
- *Stochastic gradient descent with momentum (SGDM)*

şeklinde sıralanabilir.

3.1.5.3.1 Root mean square error probability (RMSprop)

Rmsprop, Geoff Hinton tarafından önerilen bir uyarlanabilir öğrenme metodudur. RMSprop öğrenme hızını üssel olarak azalan kare gradyanlarının ortalamasına böler. İşlem fonksiyonu aşağıdaki gibidir (Ruder 2017: 7 <https://arxiv.org/pdf/1609.04747.pdf> Erişim Tarihi: 27.07.2019);

$$E[g^2]_t = 0.9E[g^2]_{t-1} + 0.1g_t^2$$
$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}}g_t$$

Hinton γ 'nin 0.9 olarak alınmasını önerirken, η öğrenme oranı için ise 0.001 değerinin alınmasını önermektedir (Ruder 2017: 7 <https://arxiv.org/pdf/1609.04747.pdf> Erişim Tarihi: 27.07.2019).

3.1.5.3.2 Adaptive Momentum Estimation (ADAM)

ADAM optimizasyonu farklı parametreler için bireysel uyarlamalı öğrenme oranlarını birincil ve ikincil gradyanların tahminleriyle hesaplamaktadır. Gradyanın yeniden ölçeklendirilmesinde parametrelerin büyüklüğünün değişmezliği, adım büyüklüklerinin sınırlandırılması, durağan bir amaç gerektirmemesi, aralıklı gradyanlarla çalışabilmesi ADAM'ın avantajları arasında yer almaktadır (Kingma, Ba 2015: 1). Performans işlevi aşağıdaki gibidir (Yazan, Talu 2017: 3);

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

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

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

$$\theta_{t+1} = \theta_t - \frac{\alpha}{\sqrt{\hat{v}_t + \epsilon}} \cdot \hat{m}_t$$

Optimizasyon RMSprop avantajını kullanmaktadır ancak RMSprop ölçeklenmiş gradyan üzerinde bir momentumu parametre güncellemesi olarak gerçekleştirirken ADAM'da parametre güncellemeleri gradyanın ilk ve ikinci moment ortalamasının kullanılmasıyla gerçekleşir (Kingma, Ba 2015: 5).

3.1.5.3.3 Stochastic Gradient Descent with Momentum (SGDM)

Stochastic gradient descent metodunda her bir eğitim setinde güncelleme işlemi gerçekleştirildiğinden dolayı gradient descent metoduna göre daha hızlı çalışıp minimum değere daha kısa sürede ulaştırmaktadır. SGD'nin momentum türevi (SGD+m) ise, SDG metodunu daha da hızlandıran ve metottaki dezavantajları ortadan kaldıran bir yöntem olarak ileri sunulmaktadır. Eklenen momentum yöntemi ile geçmiş parametreler güncellenirken yalnızca o iterasyondaki gradyan değil geçmiş gradyanlar da hesaba katılır (Yazan, Talu 2017: 1-2). Performansı işlevi aşağıdaki gibidir;

$$v_t = \rho \cdot v_{t-1} + \alpha \cdot \nabla_{\theta} J(\theta; x^i, y^i)$$

$$\theta_t = \theta_{t-1} - v_t$$

Eşitlikteki ρ 0 ve 1 arasında bir değerdir ve önceki gradyanların hesaba katılacak kısmını belirlemektedir. Bu parametre genellikle 0,9 dolaylarında bir değer olarak alınmaktadır (Yazan, Talu 2017: 2).



DÖRDÜNCÜ BÖLÜM

4.UYGULAMA VE BULGULAR

4.1 Yapay Sinir Ağları ile Enerji Kaynakları Talep Tahminleri

Enerji kaynaklarına ait arz ve talep tahmini uygulamaları literatürde bulunan çalışmalardandır. Tek tip kaynak ve yıllık bazlı olarak karşılaşılabilmektedir. Elde edilen verilere dair yorumlar yapılmakta ve gelecek dönemler için öneriler sunulabilmektedir. Gerçekleştirilen çalışmaların genelinde yıllık olarak tahminlemeler yapılmıştır. Kullanılan yöntemlerin çoğu MLP (multi layer perceptron/feedforward) olarak ele alınmıştır.

4.2 Talep Tahmini Modellerinin Oluşturulması

Bu çalışma ile enerji elde etmede kullanılan kaynaklar olan gelecek dönemlere ait doğalgaz ve elektrik tüketim tahminleri yapılmıştır.

Yapay sinir ağları modeli ile input olarak sadece zaman serileri alınmıştır. Zaman serileri analizleri (time series analysis) bazı problemlerle karşılaşmasına rağmen yapay sinir ağları yöntemi karşılaşılan problemlerin elemine edilmesini gerçekleştirdiği için tercih edilebilmektedir. Artificial neural network time series prediction analysis bu çalışmada enerji talep tahmini için kullanılan yol olmuştur. Metod için MATLAB 2019a versiyonu kullanılmıştır.

4.3 Araştırmanın Evreni ve Örneklemi

Çalışmada ulaşılmaya çalışılan doğalgaz ve elektrik tüketimi için kullanılan veriler aşağıdaki gibidir;

- Doğalgaz Tüketimi: 2012 Ocak Ayı ile 2018 Aralık Ayı arasındaki aylara ait değerler kullanılmıştır.
- Elektrik Tüketimi: 2005 Ocak Ayı ile 2018 Kasım Ayı arasındaki aylara ait değerler kullanılmıştır.

4.4 Çalışmanın Amacı

İşletmelerin geçmiş satışları ya da durumları incelenerek, taleplerde ya da arzulanan durumlarda belirli bir trendin (değişim şeklinin) olup olmadığının belirlenmesi ve gelecekle ilgili tahminlemelerin yapılması için zaman serileri analizi (time series prediction analysis) yapılmaktadır (Tekin 2012: 279). Esnek modelleme yapabilme yeteneği nedeniyle zaman serisi tahminleme problemlerinde, YSA'lar tercih edilmektedir. Doğrusal ya da eğrisel olan belirli bir model kalıbı, normal dağılım ve durağanlık gibi ön koşullara ihtiyaç duymadığından YSA'lar istenilen herhangi bir zaman serisine uygulanabilmektedir (Erilli vd. 2010: 42).

Bu çalışmada Türkiye'nin enerji sektörüne konu olan ana kalemlerden doğalgaz ve elektrik enerjisi kaynaklarının gelecek dönemler için talep tahmin değerleri yapay sinir ağları modellerinden olan bi-LSTM ve feedforward yöntemleriyle ölçümlenmeye ve en doğru tahmin değerlere ulaşılmaya çalışılmaktadır. Feed forward ile bi-LSTM modellerine ait öğrenme algoritmalarının (LM, BR, SCG, CGF, ADAM, RMSprop, SGDM) hangisinin en iyi performans göstereceği belirlenmeye ve veri seti uzunluğunun model tercih etmede etkin olup olmadığı gözlemlenmeye çalışılmıştır.

4.5 Çalışmanın Önemi

Literatürde Türkiye ve başka ülkelere ait enerji tüketim taleplerinin tahmin edildiği birçok çalışma mevcuttur. Farklı istatistikî yöntemlerin kullanıldığı bu çalışmalarda yapay sinir ağları da tercih edilmektedir. Bu bağlamda Türkiye doğalgaz ve elektrik enerjisi talep tahminleri feed forward ile bi-LSTM mimarileri ve mimarilere ait optimizasyon algoritmaları kullanılarak ölçümlenmeye çalışılmış ve kıyaslama yapılmıştır.

Çalışmada ise Türkiye'ye ait elektrik ve doğalgaz enerji kaynaklarının bi-LSTM ve feedforward (MLP) yöntemleri ve optimizasyon algoritmaları kullanılarak yüksek performanslar elde edilmeye çalışılmış, metod karşılaştırmaları yapılmış ve gelecek dönem tahminleri sunularak yorumlar eklenmiştir. Gelecek dönem için 60 aylık bir dönem için tahminler gerçekleştirilmiştir.

4.6 Çalışmanın Sınırlılıkları

Doğalgaz tüketimine ait veriler kurumlardan elde edilmeye çalışırken geçmiş dönem verilerin tam tutulmadığı, 2009'dan itibaren EPDK'nın verileri toplaması nedeniyle kurumlar arası veri transferinin gerçekleşmediği bilgisi alınmış ve elde edilebilen en uzun veri setinin ithalat verileri olması nedeniyle tüketim değerleri olarak ithalat değerleri çalışmaya dahil edilmiştir. Doğalgazda aylık olarak 2012 yılı Ocak Ayı'na kadar gidilmişken; elektrik için bu tarih 2005 Ocak Ayı'dır. Özellikle doğalgazda dışa çok yüksek oranda bağımlı olan Türkiye'nin doğalgaz üretimi çok düşük kalmasından ve oranda çok etkili olmamasından dolayı ithalat verileri iç tüketim verisi olarak ele alınmıştır.

Yapay sinir ağları mimarisinde kullanılan birçok algoritma olmasına rağmen çalışmada ele alınan algoritmalar feed forward için BR, LM, SCG ve CGF iken LSTM mimarisi için ADAM, RMSprop ve SGDM'dir.

4.7 Doğalgaz Tüketim Tahmini

Geçmiş döneme ait Türkiye doğalgaz tüketim verileri Tablo 36'da gösterilmiştir. Doğalgazda Türkiye net ithalatçı bir durum sergilediği için ithalat verileri modele eklenmiştir. Üretim veriler çok düşük olduğundan ve oranların tüketim tipini etkileyeceği düşünülmediğinden ithalat verilerinin kullanılmasına karar verilmiştir. Bu modelin Türkiye'nin dış bağımlılığını ölçümlemede de daha doğru sonuçlar sunacağı tahmin edilmektedir. Veriler EPDK'dan temin edilmiştir.

Tablo 30. Geçmiş dönemler doğalgaz tüketim verileri (Milyon Sm³)

Aylar/Yıllar	2012	2013	2014	2015	2016	2017	2018
Ocak	4783.6	4536.21	4791.87	4997.8	5392.94	5914.34	6216.51
Şubat	4202.65	4095.23	4219.7	4634.5	3964.11	5252.73	5403.56
Mart	4645.52	3889.33	4535.44	4277.5	3812.55	5028.78	4725.37
Nisan	3889.33	3447.54	4114.91	3572.83	3553.46	4250.26	3670.11
Mayıs	3198.17	3512.94	3881.93	3332.88	3215.71	3727.77	3008.82
Haziran	3202.72	3143.21	3301.27	3201.4	3173.14	3609.89	2922.57
Temmuz	3698.37	3404.38	3689.75	3325.49	3220.08	4135.45	3635.41
Ağustos	3365.72	3268.74	3828.66	3741.33	3627.2	4015.73	3034.61
Eylül	3746.61	3526.97	3894.04	3684.66	3007.63	3680.77	3281.47
Ekim	3213.49	3545.24	3442.02	3745.98	3456.31	4137.1	3707.83
Kasım	4025	3936.82	4558.66	4571.5	4354.71	5448.85	4695.69
Aralık	4592.42	4962.36	5004.02	5341.2	5574.35	5995.79	6052.56

Tablo 32'den anlaşılacağı üzere doğalgaz tüketimi kış aylarına yaklaştıkça ve kış aylarında artış göstermektedir. Ve Türkiye için bu artış gösteren bir grafik olarak karşımıza çıkmaktadır.

Doğalgaza ait geçmiş dönem verileri 84 aydır. Bi-LSTM ve feedforward için katman sayısı, ünite sayısı, nöron sayısı, eğitim oranı, iterasyon sayısı ve gecikme sayısı farklı değerler girilerek denenmiş ve toplamda 1856 eğitim gerçekleştirilmiştir.

Bu denemeler sırasında bi-LSTM mimarisi ADAM, RMSProp, SGDM optimizasyonları için 1 katmanlı mimaride 75, 100, 125, 150, 175, 200, 225, 250, 275, 300, 325, 350, 375, 400 üniteleri; 2 katmanlı mimaride 75/75, 100/100, 125/125, 150/150, 175/175, 200/200, 225/225, 250/250, 275/275, 300/300, 325/325, 350/350, 375/375, 400/400 üniteleri kullanılmıştır. Her bir optimizasyon için ayrı ayrı %75 ve %80 eğitim oranları ile yine ayrı ayrı normalizasyon ve standardizasyon preproses yöntemleri modellere eklenmiştir.

Feed forward mimarisinde kullanılan BR, LM, SCG ve CGF optimizasyonları için 1 katmanlı mimaride 5, 10, 15, 20, 25, 30 nöron; 2 katmanlı mimaride 5/5, 5/10,

5/15, 5/20, 5/25, 5/30, 10/5, 10/10, 10/15, 10/20, 10/25, 10/30, 15/5, 15/10, 15/15, 15/20, 15/25, 15/30, 20/5, 20/10, 20/15, 20/20, 20/25, 20/30, 25/5, 25/10, 25/15, 25/20, 25/25, 25/30, 30/5, 30/10, 30/15, 30/20, 30/25, 30/30, 3 katmanlı mimari için 5/5/5, 5/10/5, 5/10/10, 5/10/15, 5/10/20, 5/15/20, 5/15/25, 5/15/30, 5/20/30, 5/25/30, 10/5/10, 10/10/10, 10/15/10, 10/20/10, 10/15/20, 10/20/30, 15/5/10, 15/10/10, 15/15/15, 15/20/25, 15/15/30, 15/25/30, 15/20/30, 20/5/10, 20/10/10, 20/10/15, 20/15/15, 20/10/25, 20/20/20, 20/25/30, 25/5/10, 25/10/10, 20/10/15, 20/15/20, 20/15/30, 20/25/25, 25/5/10, 25/10/10, 25/10/15, 25/15/15, 25/15/20, 25/25/25, 25/25/30, 30/5/10, 30/10/10, 30/10/15, 30/15/15, 30/20/25, 30/25/20, 30/25/25, 30/25/30, 30/30/30 nöronları modelleri eklenerek çalıştırılmıştır ve hepsi için ayrı ayrı optimizasyonlar ile ayrı ayrı %75 ve %80 eğitim oranları ve ayrı ayrı normalizasyon ve standardizasyon yöntemleri kullanılmıştır. Tek tek çalıştırılan bu mimariler içinde en yüksek performansı gösteren modeller tekrar tekrar onlarca kez eğitilerek daha yüksek performans elde edilmeye çalışılmıştır.

Her bir algoritmaya ait en iyi performans gösteren modeller ayrı ayrı ele alınmış, algoritmalar arası en iyi modeller de kıyaslanarak doğalgaz tüketim veri seti için en uygun olan preproses yöntemi ve algortimalar değerlendirilmiştir. Bi-LSTM ve feed forward mimarilerine ait yeni bir kod MATLAB 2019a ile yazılmıştır ve kodun tamamı ise ekte sunulmuştur.

4.7.1 Doğalgaz Tüketimi Bi-LSTM Yöntemi ADAM Optimizasyonu

Doğalgaz tüketimine ait bidirectional Lstm modeli oluşturulurken kullanılan ADAM optimizasyonuna ait preprocess yöntemleri ve eğitim oranları ile parametre değerleri Tablo 33'te görülmektedir. Bu verilere ait gelecekte oluşması muhtemel doğalgaz tüketim değerleri gerçekleşen ve EPDK'dan elde edilen 2019 yılı Ocak, Şubat, Mart ve Nisan için 4 aylık değerlerle beraber verilmektedir.

Tablo 34'te oluşturulan doğalgaz tüketim modellerin gelecek tahmin değerleri, Şekil 59'da ise ADAM optimizasyonu ile elde edilen modellerin tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.

Tablo 31 Doğalgaz Adam Optimizasyonu Modellerinin Parametre Sonuçları

Parametre	ADAM I	ADAM II	ADAM III	ADAM IV
Korelasyon	0.93243	0.93791	0.96992	0.97968
NMSE	0.066346	0.060595	0.04588	0.039027
R ²	0.90336	0.91104	0.95384	0.9662
Katman	1	1	2	2
Ünite	150	75	75 75	75 75
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 33'te görüldüğü üzere doğalgaz tüketim talebine ait oluşturulan ADAM projeksiyonlarında en düşük NMSE değeri, standardize edilmiş ve % 80 eğitim oranı kullanılmış modelde oluşmaktadır. Her bir proses için kullanılan preproses modellerinin en iyileri kıyaslamaya dahil edilmiştir. 2 katmandan oluşan, her bir katmanda 75 ünite bulunan ve en iyi performans gösteren ADAM modeli (ADAM IV) 0,039027 NMSE, 0,9662 R² ve 0,97968 korelasyon değerlerine sahiptir ve aynı zamanda standardize edilerek %80 eğitim oranına tabi tutulmuştur.


Şekil 34'te her bir katman ve bu katmanlara ait her bir ünite için %80 ve %75'lik eğitim oranları ve normalizasyon ile standardizasyon yöntemleri ayrı ayrı denenerek elde edilen ve kendi içinde en iyi performans gösteren ADAM algoritmalarına ait modellerin tahmin ettiği ilk 4 aylık veriler ile tahminlemeye dahil edilmeyen gerçekleşmiş aynı 4 aya ait veriler görülebilmektedir.

Tablo 32. ADAM Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01.2019-04.2019/Milyon sm³)

Aylar	Gerçek	Adam 75 Norm	Adam 80 Norm	Adam 75 Stand	Adam 80 Stand
Ocak 19	5810.25	6407.948242	6357.595215	6338.472168	6327.532715
Şubat 19	4275.92	5052.414551	5056.193848	4930.92627	5010.544922
Mart 19	4296.13	3580.98877	3616.029053	3723.819092	3835.593018
Nisan 19	3550.34	2801.679688	2862.578857	2866.67334	2921.467773

Şekil 59'da, kullanılan preproseslerde en iyi performansı gösteren ADAM modellerinin hareketleri aynı anda görülebilmektedir. 4 modelde hemen hemen aynı ağıme sahiptirler ancak ADAM IV modelinin (Adam 80 Stand- Standardize edilmiş

ve %80 eğitim oranına sahip) her adımda gerçek değere diğer modellere göre daha yaklaştığı söylenebilir.



Şekil 59. Doğalgaz ADAM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.7.2 Doğalgaz Tüketimi Bi-Lstm RMSprop Optimizasyonu

Doğalgaz tüketimine ait bidirectional LSTM modeli oluşturulurken kullanılan RMSprop optimizasyonuna ait preprocess yöntemleri ve eğitim oranları ile parametre değerleri Tablo 35’de görülmektedir.

Tablo 36’da oluşturulan doğalgaz tüketim modellerinin gelecek tahmin değerleri Şekil 60’da ise RMSProp optimizasyonu ile elde edilen modellerin tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.


Tablo 33 Doğalgaz RMSprop Optimizasyonu Modellerinin Parametre Sonuçları

Parametre	RMSProp I	RMSProp II	RMSProp III	RMSProp IV
Korelasyon	0.93799	0.93549	0.97033	0.98653
NMSE	0.062334	0.060459	0.050207	0.034939
R^2	0.91429	0.91346	0.94337	0.97411
Katman	1	1	2	2
Ünite	75	75	250 250	75 75
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 34. RMSprop Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01.2019-04.2019/Milyon sm³)

Aylar	Gerçek	RMSprop 75 Norm	RMSprop 80 Norm	RMSprop 75 Stand	RMSprop 80 Stand
Ocak 19	5810.25	6412.40625	6395.48291	6214.212891	6367.070313
Şubat 19	4275.92	5073.519531	5060.788086	4772.275879	5138.412598
Mart 19	4296.13	3584.762939	3594.403076	3621.305176	4064.699463
Nisan 19	3550.34	2786.81958	2809.059326	2771.415039	3024.03833

Doğalgaz tüketim talebine ait oluşturulan RMSprop projeksiyonlarında en düşük NMSE değeri, en yüksek R^2 ve en yüksek korelasyon değerleri standardize edilmiş ve % 80 eğitim oranı kullanılmış modelde oluşmaktadır. Her bir proses için kullanılan preproses modellerinin en iyileri kıyaslamaya dahil edilmiştir. Kıyaslamaya göre 0,034939 NMSE, 0,97411 R^2 ve 0,98653 korelasyon ile standardize edilmiş 2 katmanlı ve her katmanda 75 ünitenin olduğu RMSprop modelinde (RMSprop IV) en iyi performansı göstermektedir.



Şekil 60. Doğalgaz RMSprop optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

Şekil 60'a göre RMSprop IV modeli diğer modellere göre özellikle 3 ve 4. ayda gerçekleşen değerlere daha yaklaşmıştır.

4.7.3 Doğalgaz Tüketimi Bi-Lstm SGDM Optimizasyonu

Doğalgaz tüketimine ait bidirectional Lstm modeli oluşturulurken kullanılan SGDM optimizasyonuna ait preprocess yöntemleri ve eğitim oranları ile parametre değerleri Tablo 37’de görülmektedir. Bu verilere ait gelecekte oluşması muhtemel doğalgaz tüketim değerleri gerçekleşen 4 aylık değerlerle beraber verilmektedir.

Tablo 38’de oluşturulan doğalgaz tüketim modellerinin gelecek tahmin değerleri Şekil 61’de ise SGDM optimizasyonu ile elde edilen modellerin tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.


Tablo 35 Doğalgaz SGDM Optimizasyonu Modellerinin Parametre Sonuçları

Parametre	SGDM I	SGDM II	SGDM III	SGDM IV
Korelasyon	0.80906	0.80866	0.89615	0.89977
NMSE	0.16505	0.15662	0.076978	0.072824
R2	-5.4043	-3.3341	0.82258	0.85419
Katman	1	1	1	1
Ünite	250	75	125	250
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 36. SGDM Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01.2019-04.2019/Milyon sm³)

Aylar	Gerçek	SGDM 75 Norm	SGDM 80 Norm	SGDM 75 Stand	SGDM 80 Stand
Ocak 19	5810.25	4781.58252	5124.560547	5809.46582	6086.197266
Şubat 19	4275.92	4418.675293	4656.132813	4620.78125	4779.717773
Mart 19	4296.13	4142.525879	4226.069824	3585.622559	3631.424316
Nisan 19	3550.34	3916.220703	3913.904785	3060.67334	3034.312256

Doğalgaz tüketim talebine ait oluşturulan SGDM projeksiyonlarında en düşük NMSE, en yüksek R² ve en yüksek korelasyon değerleri standardize edilmiş ve % 80 eğitim oranı kullanılmış modelde oluşmaktadır. Her bir proses için kullanılan preprocess modellerinin en iyileri kıyaslamaya dahil edilmiştir. Kıyaslamaya göre 0,072824 NMSE, 0.85419 R² ve 0.89977 korelasyon ile standardize edilmiş ve %80 eğitim oranına tabi tutulmuş SGDM en iyi performansı göstermektedir.



Şekil 61. Doğalgaz SGDM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

Şekil 61’de görüldüğü üzere SGDM IV modeli ADAM ve RMSprop modellerindeki gibi gerçek değerlere trend olarak yaklaşamamıştır ancak en yüksek performans gerçemiş tahmin değerler göz önüne alındığında SGDM IV modelinde elde edilmiştir. Bununla beraber SGDM III modeli yani standardize edilmiş ve %75 eğitim oranı uygulanmış model ilk ayda çok yakın bir değerlerle gerçek değerle kesişmiştir. Buna rağmen gelecek için en yakın tahminlemenin SGDM IV modeli ile bulunacağı elde edilen değerlerle söylenebilir.

4.7.4 Doğalgaz Tüketimi FeedForward Br Optimizasyonu

Doğalgaz tüketimine ait feed forward modeli oluşturulurken kullanılan BR optimizasyonuna ait preproses yöntemleri ve eğitim oranları ile parametre değerleri Tablo 39’da görülmektedir.

Tablo 40’ta oluşturulan doğalgaz tüketim modellerinin gelecek tahmin değerleri Şekil 62’de ise BR optimizasyonu ile elde edilen modellerin tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülebilmektedir.


Tablo 37 Doğalgaz BR Optimizasyonu Modellerinin Parametre Sonuçları

Parametre	BR I	BR II	BR III	BR IV
Korelasyon	0.94388	0.91066	0.90373	0.9309
NMSE	0.05835	0.066402	0.07522	0.062452
R2	0.91819	0.88615	0.89104	0.9031
Katman	2	1	2	2
Nöron	5 30	5	5 20	5 25
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 38. BR Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01,2019-04,2019/Milyon sm³)

Aylar	Gerçek	BR 75 Norm	BR 80 Norm	BR 75 Stand	BR 80 Stand
Ocak 19	5810.25	6023.108028	6105.827405	6096.877545	6337.877946
Şubat 19	4275.92	4798.206217	4669.240463	4657.813117	5320.476864
Mart 19	4296.13	3729.056045	3295.406156	3828.15597	4128.646363
Nisan 19	3550.34	2825.039003	2727.808617	2390.657178	2952.371167

Doğalgaz tüketim talebine ait oluşturulan BR projeksiyonlarında en düşük NMSE değer ile en yüksek R² ve en yüksek korelasyon değerleri normalize edilmiş ve %75 eğitim oranı kullanılmış BR I modelinde oluşmaktadır. Kendi içinde her bir proses için kullanılan preproses modellerinin en iyileri arasında kıyaslama yapılmıştır. Kıyaslamaya göre 0,05835 NMSE, 0,91819 R² ve 0,94388 korelasyon ile normalize edilmiş ve %75 eğitim oranı kullanılan BR I en iyi performansı göstermektedir.



Şekil 62. Doğalgaz BR optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.7.5 Doğalgaz Tüketimi FeedForward LM Optimizasyonu

Doğalgaz tüketimine ait feed forward modeli oluşturulurken kullanılan LM optimizasyonuna ait preproses yöntemleri ve eğitim oranları ile parametre değerleri Tablo 41’de görülmektedir.

Tablo 42’de oluşturulan doğalgaz tüketim modellerinin gelecek tahmin değerleri Şekil 63’te ise LM optimizasyonu ile elde edilen modellerin tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.

Tablo 39 Doğalgaz LM Optimizasyonu Modellerinin Parametre Sonuçları

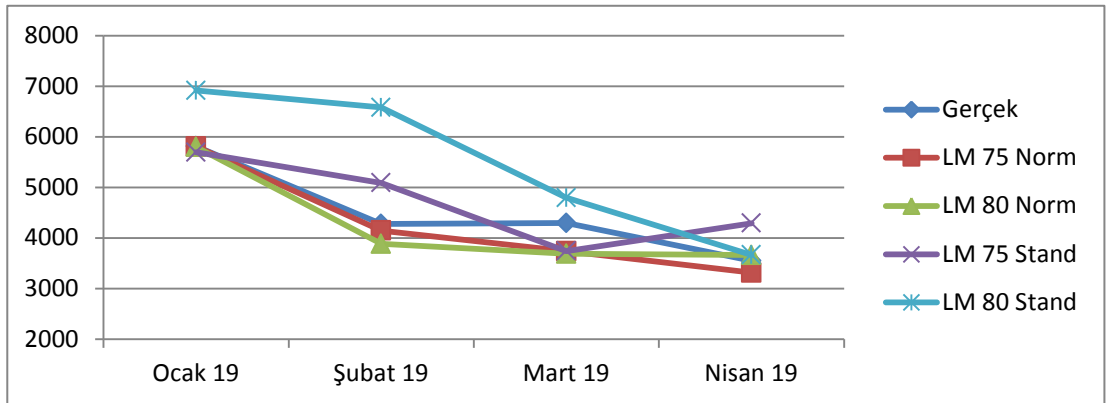
Parametre	LM I	LM II	LM III	LM IV
Korelasyon	0.9288	0.92017	0.88776	0.94573
NMSE	0.083171	0.087501	0.084349	0.071618
R2	0.84138	0.83731	0.8254	0.89143
Katman	2	1	2	2
Nöron	30 5	5	25 10	25 10
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 40. LM Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01.2019-04.2019/Milyon sm³)

Aylar	Gerçek	LM 75 Norm	LM 80 Norm	LM 75 Stand	LM 80 Stand
Ocak 19	5810.25	5805.975713	5798.264009	5694.059539	6913.743537
Şubat 19	4275.92	4147.055141	3884.200648	5090.639113	6578.204033
Mart 19	4296.13	3739.42349	3687.928409	3741.764949	4794.514986
Nisan 19	3550.34	3316.474678	3663.328572	4293.926175	3664.804308

Doğalgaz tüketim talebine ait oluşturulan LM projeksiyonlarında en düşük NMSE değer ve en yüksek R² ile en yüksek korelasyon değerleri standardize edilmiş ve % 80 eğitim oranı kullanılmış modelde oluşmaktadır. Kendi içinde en iyi performans gösteren modellerin kıyaslamasına göre 0,071618 NMSE, 0,89143 R² ve 0,94573 korelasyon ile standardize edilmiş ve %80 eğitim oranı kullanılmış LM IV modeli en iyi performansı göstermektedir. Modelde en iyi performansın elde edildiği katman sayısı 2'dir ve ilk katmanda 25 nöron varken 2. katmanda 10 nöron bulunmaktadır.

Şekil 63'te görüldüğü gibi başlangıçta gerçek değerden uzak olan BR VI modeli 3 ve 4. ayda gerçekleşen değerlere yaklaşmaktadır.



Şekil 63. Doğalgaz LM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.7.6 Doğalgaz Tüketimi FeedForward SCG Optimizasyonu

Doğalgaz tüketimine ait feed forward modeli oluşturulurken kullanılan SCG optimizasyonuna ait preproses yöntemleri ve eğitim oranları ile parametre değerleri Tablo 43'te görülmektedir.

Tablo 44'te oluşturulan doğalgaz tüketim modellerinin gelecek tahmin değerleri, Şekil 64'te ise SCG optimizasyonu ile elde edilen modellerin tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.

Tablo 41 Doğalgaz SCG Optimizasyonu Modellerinin Parametre Sonuçları


Parametre	SCG I	SCG II	SCG III	SCG IV
Korelasyon	0.8951	0.83986	0.84777	0.90026
NMSE	0.87797	0.088101	0.98854	0.083886
R2	0.79169	0.82049	0.81014	0.83683
Katman	1	2	1	1
Nöron	20	5 25	10	10
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 42. SCG Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01,2019-04,2019/Milyon sm³)

Aylar	Gerçek	SCG 75 Norm	SCG 80 Norm	SCG 75 Stand	SCG 80 Stand
Ocak 19	5810.25	6288.416049	6796.650132	5825.819866	5728.529773
Şubat 19	4275.92	6564.571135	4597.965268	4135.491109	4152.941151
Mart 19	4296.13	4028.729514	4210.700208	3448.987012	3174.385889
Nisan 19	3550.34	2655.331782	3524.928992	3898.722568	2845.034745

Doğalgaz tüketim talebine ait oluşturulan SCG projeksiyonlarında en düşük NMSE değer ile en yüksek R² ve en yüksek korelasyon değerlerine standardize edilmiş ve % 80 eğitim oranı kullanılmış modelde ulaşılmaktadır. En iyiler arasındaki kıyaslamaya göre 0,083886 NMSE, 0.83683 R² ve 0.90026 korelasyon ile standardize edilmiş SCG IV modeli en iyi performansı göstermektedir.

Şekil 64'te modellerin ilk 4 aydaki tahmin değerleri ile eğitime dahil edilmeyen ancak gerçekleşmiş tüketim değerlerinin grafiği görülebilmektedir. SCG IV modelinin özellikle ilk 2 ayda gerçek değerlere çok yakın olduğu söylenebilir.



Şekil 64. Doğalgaz SCG optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.7.7 Doğalgaz Tüketimi FeedForward CGF Optimizasyonu

Doğalgaz tüketimine ait feed forward modeli oluşturulurken kullanılan CGF optimizasyonuna ait preprocess yöntemleri ve eğitim oranları ile parametre değerleri Tablo 45'te görülmektedir.

Tablo 46'da oluşturulan doğalgaz tüketim modellerinin gelecek tahmin değerleri Şekil 65'te ise CGF optimizasyonu ile elde edilen modellerin tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.


Tablo 43 Doğalgaz CGF Optimizasyonu Modellerinin Parametre Sonuçları

Parametre	CGF I	CGF II	CGF III	CGF IV
Korelasyon	0.90453	0.87147	0.92622	0.90179
NMSE	0.069184	0.08746	0.070155	0.088493
R2	0.88419	0.83659	0.89181	0.80891
Katman	1	2	1	1
Nöron	15	10 5	5	5
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 44. CGF Optimizasyonu Sonucu Doğalgaz Tüketim Tahmin Değerleri ile Gerçek Değerler (01,2019-04,2019/Milyon sm³)

Aylar	Gerçek	CGF 75 Norm	CGF 80 Norm	CGF 75 Stand	CGF 80 Stand
Ocak 19	5810.25	6157.188173	6087.934035	5618.655317	5983.190667
Şubat 19	4275.92	5020.943399	5603.079454	4996.67189	5983.190667
Mart 19	4296.13	5294.844463	5223.02051	4786.00691	5983.190667
Nisan 19	3550.34	5823.322402	3672.568163	3542.794123	5983.190667

Doğalgaz tüketim talebine ait oluşturulan CGF projeksiyonlarında en iyi performans standardize edilmiş ve % 75 eğitim oranı kullanılmış CGF III modelinde oluşmaktadır. NMSE değerinin en düşük olduğu model CGF I olmasına rağmen korelasyon ve R² değeri CGF I'e göre CGF III'te daha yüksektir. Bu nedenle en iyi performans CGF III gözlemlenmektedir. Modelde her bir proses için kullanılan preproses modellerinin en iyileri kıyaslamaya dahil edilmiştir. Yine Şekil 65'te gerçekleşen değerlere en yakın tahmin değerlerin SCG III modelinde olduğu gözlemlenebilmektedir. Özellikle 4. ayda yaklaşıma oranı çok yüksektir.



Şekil 65. Doğalgaz CGF optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.7.8 Doğalgaz Tüketim Tahmininde En İyi Performans Gösteren Optimizasyonların Kıyaslanması

Doğalgaz tüketim talebi için oluşturulan modellerde kendi aralarında en iyi performans gösteren optimizasyonların parametre değerleri Tablo 47’de ve gelecekte gerçekleşebilecek tüketim değerleri ile 4 aylık gerçek değerler Tablo 48 ve Tablo 49’da bir arada görülebilmektedir.

Tablo 45 Doğalgaz Tüketim Tahmini En Yüksek Performans Gösteren Modellerinin Parametreleri

Parametre	ADAM	RMSprop	SGDM	BR	LM	SCG	CGF
Korelasyon	0.97968	0.98653	0.89977	0.94388	0.94573	0.90026	0.92622
NMSE	0.039027	0.034939	0.072824	0.05835	0.071618	0.083886	0.070155
R2	0.9662	0.97411	0.85419	0.91819	0.89143	0.83683	0.89181
Katman	2	2	1	2	2	1	1
Ünite/Nöron	75 75	75 75	250	5 30	25 10	10	5
Preproses	Stand	Stand	Stand	Norm	Stand	Stand	Stand
Validation	80	80	80	75	80	80	75

Kendi aralarında değerlendirilen ve en yüksek performans gösteren optimizasyon modelleri arasında en düşük NMSE değer olan 0.034939, en yüksek değerler olan 0.97411 R² ve 0.98653 korelasyon ile RMSprop optimizasyonu en yüksek performans gösteren optimizasyon modeli olmuştur.


Tablo 46. Doğalgaz Tüketim Tahmini için En Yüksek Performans Gösteren Bi-LSTM Modelleri ve Gerçek Değer (01.2019-04.2019/Milyon cm³)

Aylar	Gerçek	ADAM	RMSprop	SGDM
Ocak 19	5810.25	6327.532715	6367.070313	6086.197266
Şubat 19	4275.92	5010.544922	5138.412598	4779.717773
Mart 19	4296.13	3835.593018	4064.699463	3631.424316
Nisan 19	3550.34	2921.467773	3024.03833	3034.312256

Tablo 47. Doğalgaz Tüketim Tahmini için En Yüksek Performans Gösteren Feed Forward Modelleri

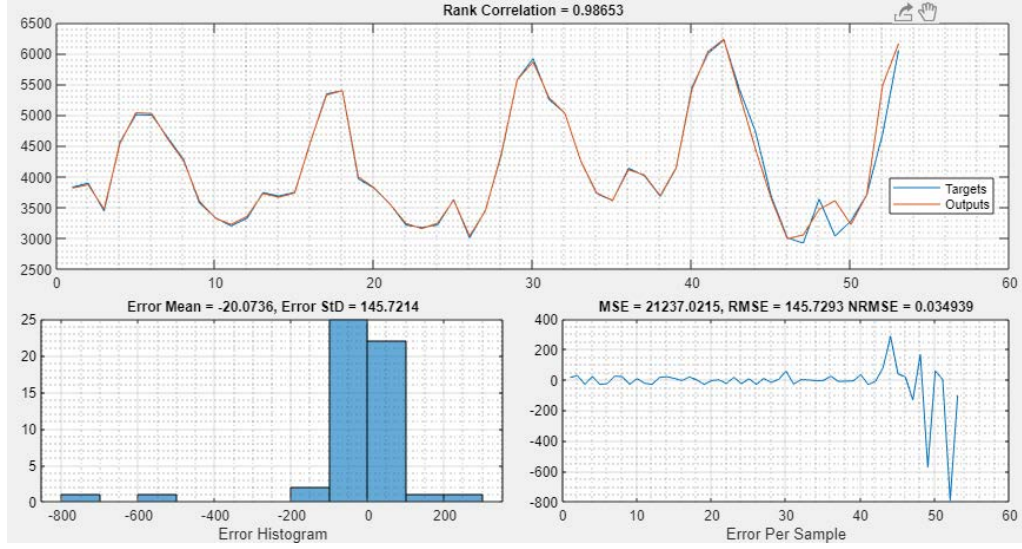
Aylar	Gerçek	BR	LM	SCG	CGF
Ocak 19	5810.25	6023.108028	6913.743537	5728.529773	5618.655317
Şubat 19	4275.92	4798.206217	6578.204033	4152.941151	4996.67189
Mart 19	4296.13	3729.056045	4794.514986	3174.385889	4786.00691
Nisan 19	3550.34	2825.039003	3664.804308	2845.034745	3542.794123

Optimizasyonların gelecek tahmin değerleriyle beraber oluşturdukları gerçekleşen gelecek 4 aylık doğalgaz tüketim değerlerinin grafiği Şekil 66'da görülmektedir. Özellikle 3. ayda RMSprop modeline ait tahmin değer diğer modellere kıyasla en yakın değer olarak ortaya çıkmaktadır.




Şekil 66. Doğalgaz Tüketim Tahmini En Yüksek Performans Gösteren Modellerin gelecek tahmin değerleri ve gerçek değerler

Doğalgaz tüketim tahmin modellerinde en yüksek performans gösteren RMSprop optimizasyon modelinin eğitim sonuçları Şekil 67 ve Şekil 68'de görülebilmektedir.



Şekil 67. Doğalgaz Tüketim Tahmini RMSprop sonuçları I

RMSprop optimizasyonu için veri setinin %80'i eğitime tabii tutulmuş ve %20'lik kısmı ile test edilmiştir. 0.99937'lik çok iyi bir oranla eğitim aşaması tamamlanmış 0.91295'lik çok iyi bir oranla da test aşaması sonuçlanmıştır.



Şekil 68. Doğalgaz Tüketim Tahmini RMSprop sonuçları II

Şekil 68’de tahmin değerlerin eğitim eğrisi üzerinde yoğun bir şekilde toplandığı gözlemlenebilmektedir. Yapay sinir ağlarında tahmin modelinin eğriden sapmaması beklenmektedir ve bu modelde istenilen sonuçtan sapma gerçekleşmemiştir.


Standardize edilmiş RMSprop optimizasyonu modeli sonucu gelecek 60 ay için gerçekleşmesi tahmin edilen doğalgaz tüketim değerleri ve 2018 yılı gerçekleşen doğalgaz tüketim değerleri Tablo 50’de görülebilmektedir.

Tablo 48. Doğalgaz Tüketim Tahmini RMSprop Optimizasyonu gelecek 60 aylık tahmin değerleri (Milyon sm³)

Aylar/Yıllar	2018	2019	2020	2021	2022	2023
Ocak	6216.51	6367.07	5780.263	4555.418	3561.202	2824.112
Şubat	5403.56	5138.413	4608.16	3158.4	2723.118	2716.534
Mart	4725.37	4064.699	3254.703	2570.495	2822.537	2814.872
Nisan	3670.11	3024.038	2932.837	2693.228	2863.974	3134.85
Mayıs	3008.82	3109.264	3081.87	2740.779	2836.776	2831.116
Haziran	2922.57	3166.958	2996.723	2556.475	2283.377	2648.065
Temmuz	3635.41	2805.436	2489.842	2201.748	2589.07	4443.498
Ağustos	3034.61	2478.164	2683.437	2972.719	5082.582	6056.808
Eylül	3281.47	2833.606	4109.409	5837.719	6260.818	6161.864
Ekim	3707.83	5305.856	6036.202	6430.156	6238.735	4609.955
Kasım	4695.69	6559.634	6383.357	6004.133	4893.503	3572.079
Aralık	6052.56	6540.969	5825.439	4736.56	3894.554	2727.001

Doğalgaz tüketiminin kış aylarında en yüksek tüketim değerine ulaştığı 2012-2018 gerçekleşen değerlerden bilinmektedir. Model 20 aylık tüketim dönemlerini iyi tahminleyebilmesine rağmen 2. yılın sonlarına doğru tüketim dönemlerinde yüksek değerlerin sonbahar aylarına kayması gözlemlenmesinden dolayı uzak geleceği tahminleme de modelin zayıfladığı görülebilmektedir. Lineer olmayan bir trend göstermesinden dolayı bu farklılık daha baskın bir şekilde hissedilmektedir.

Oluşturulan RMSprop optimizasyon modelinin 2012 ve 2023 doğalgaz tüketim değerlerine ait grafik ise Şekil 69’da görülebilmektedir.



Şekil 69. RMSprop ile elde edilen doğalgaz tüketim çizelgesi (2012-2023)

4.8 Elektrik Tüketim Tahmini

Türkiye elektrik enerjisi tüketimine ait veriler TEİAŞ'tan elde edilmiştir. Veriler 2005 Ocak Ayı ile 2018 Kasım ayı arasındaki dönemleri kapsamaktadır. Geçmiş dönemlere ait Türkiye elektrik tüketim verileri Tablo 51, Tablo 52 ve Tablo 53'de görülmektedir;

Tablo 49. 2005-2008 Türkiye Elektrik Tüketim Verileri (Kwh)

Aylar/Yıllar	2005	2006	2007	2008
Ocak	13212301334	14172081801	15685715555	17948279110
Şubat	12523926657	13540278203	14547957578	16503972978
Mart	13465769154	14471412846	15622619393	16244633117
Nisan	12533842619	13277548893	14785781929	15652217930
Mayıs	12759765757	13875711909	15112512246	16284002741
Haziran	12602905486	14336053517	15560403159	16527139162
Temmuz	14254279601	15452769957	17491582426	18308510826
Ağustos	14694039513	16267168043	17579492716	18391795973
Eylül	13283399370	14395157749	15636431483	16045189368
Ekim	13407113966	13735247402	15071117215	14916919003
Kasım	13322227662	15067957333	16103446067	15446091276
Aralık	14734393079	16045962696	16803192487	15816435004

Tablo 50. 2009-2013 Türkiye Elektrik Tüketim Verileri (Kwh)

Aylar/ Yıllar	2009	2010	2011	2012	2013
Ocak	16851415517	17421708440	19724373026	21406128244	21790017403
Şubat	15010029912	15745016068	17790305539	19994766574	19207027267
Mart	15983709185	17078834396	19278117471	20757882512	20781841292
Nisan	14849111780	16313736237	17923318607	18254835373	19464719260
Mayıs	15297713906	16711662290	17686346903	18953659775	19981946356
Haziran	15899617232	17143073542	18002761819	20100590984	20250986699
Temmuz	17743507927	19427951413	21070042357	22879950721	22691837695
Ağustos	17704553933	20453133423	20673509578	21539313315	21767142606
Eylül	15379301311	17094002910	18986104205	19863007705	20419871100
Ekim	15989904567	17318096101	18934786493	18217447112	19120624935
Kasım	15779290584	16494856977	19146615942	19243717660	20258221162
Aralık	17590908057	19231895422	21090029585	21158567371	22589522055

Tablo 51. 2014-2018 Türkiye Elektrik Tüketim Verileri (Kwh)

Aylar/ Yıllar	2014	2015	2016	2017	2018
Ocak	22039075751	22781619133	23960537853	25585991887	26211733068
Şubat	19749304552	20496228056	21406006285	22883817656	23230872352
Mart	21042536264	21699968796	22422936042	24056374354	24729132828
Nisan	20318009558	20564870507	21616639007	22431856521	23586542395
Mayıs	20640843096	21375132739	22259972870	23341197119	23964680909
Haziran	20721684955	21093225287	23411761994	22860236702	23855663704
Temmuz	23377403347	23756064226	24749519874	28384330442	29215672778
Ağustos	24308232196	25142970986	26689093254	28100723903	27571280932
Eylül	21646200698	21794526852	21641882805	24472648272	25051959467
Ekim	19581416859	21258632822	22364736615	23886375834	23375800129
Kasım	21288821835	21569210646	23182516797	24565080420	23848697410
Aralık	22506591691	24191903867	25580782115	26133485560	

Türkiye elektrik enerjisi tüketiminin yaz aylarında maksimum değerlere ulaştığı ve artan bir oranda devam ettiği Tablo 51, Tablo 52 ve Tablo 53'te görülmektedir. Yaz aylarında günlerin uzun olmasının elektrik tüketimini artırdığı söylenebilir.

Elektrik tüketimine ait geçmiş dönem verileri 167 aydır. Bi-LSTM ve feedforward için katman sayısı, ünite sayısı, nöron sayısı, eğitim oranı, iterasyon sayısı ve gecikme sayısı farklı değerler girilerek denenmiş ve toplamda 1773 eğitim gerçekleştirilmiştir.

Bu denemeler sırasında Bi-LSTM mimarisi ADAM, RMSProp, SGDM optimizasyonları için 1 katmanlı mimaride 75, 100, 125, 150, 175, 200, 225, 250, 275, 300, 325, 350, 375, 400 üniteleri; 2 katmanlı mimaride 75/75, 100/100, 125/125, 150/150, 175/175, 200/200, 225/225, 250/250, 275/275, 300/300, 325/325, 350/350, 375/375, 400/400 üniteleri kullanılmıştır. Her bir optimizasyon için ayrı ayrı %75 ve %80 eğitim oranları ile yine ayrı ayrı normalizasyon ve standardizasyon preproses yöntemleri modellere eklenmiştir.

Feed forward mimarisi BR, LM, SCG ve CGF optimizasyonları için 1 katmanlı mimaride 5, 10, 15, 20, 25, 30 nöron; 2 katmanlı mimaride 5/5, 5/10, 5/15, 5/20, 5/25, 5/30, 10/5, 10/10, 10/15, 10/20, 10/25, 10/30, 15/5, 15/10, 15/15, 15/20, 15/25, 15/30, 20/5, 20/10, 20/15, 20/20, 20/25, 20/30, 25/5, 25/10, 25/15, 25/20, 25/25, 25/30, 30/5, 30/10, 30/15, 30/20, 30/25, 30/30, 3 katmanlı mimari için 5/5/5, 5/10/5, 5/10/10, 5/10/15, 5/10/20, 5/15/20, 5/15/25, 5/15/30, 5/20/30, 5/25/30, 10/5/10, 10/10/10, 10/15/10, 10/20/10, 10/15/20, 10/20/30, 15/5/10, 15/10/10, 15/15/15, 15/20/25, 15/15/30, 15/25/30, 15/20/30, 20/5/10, 20/10/10, 20/10/15, 20/15/15, 20/10/25, 20/20/20, 20/25/30, 25/5/10, 25/10/10, 20/10/15, 20/15/20, 20/15/30, 20/25/25, 25/5/10, 25/10/10, 25/10/15, 25/15/15, 25/15/20, 25/25/25, 25/25/30, 30/5/10, 30/10/10, 30/10/15, 30/15/15, 30/20/25, 30/25/20, 30/25/25, 30/25/30, 30/30/30 nöronları modelleri eklenerek çalıştırılmıştır ve hepsi için ayrı ayrı optimizasyonlar ile ayrı ayrı %75 ve %80 eğitim oranları ve ayrı ayrı normalizasyon ve standardizasyon yöntemleri kullanılmıştır.

Her bir algoritmaya ait en iyi performans gösteren modeller ayrı ayrı ele alınmış, algoritmalar arası en iyi modeller de kıyaslanarak elektrik tüketim veri seti için en uygun olan preproses yöntemi ve algortimalar değerlendirilmiştir.

Bi-LSTM ve feed forward mimarilerine ait yeni bir kod MATLAB 2019a'da yazılmış ve bu kodun tamamı ekte sunulmuştur.

4.8.1 Elektrik Tüketimi Bi-Lstm ADAM Optimizasyonu

Elektrik tüketimine ait bidirectional Lstm modeli oluşturulurken kullanılan ADAM optimizasyonuna ait preproses yöntemleri ve eğitim oranları ile parametre değerleri Tablo 54'te görülmektedir. Bu verilere ait gelecekte oluşması muhtemel elektrik tüketim değerleri gerçekleşen ve TEİAŞ'tan elde edilen 2018 Yılı Aralık ayı ile 2019 yılı Ocak, Şubat, Mart ve Nisan ayları için 5 aylık değerlerle beraber verilmektedir.

Tablo 55'te oluşturulan elektrik tüketim modellerinin gelecek tahmin değerleri, Şekil 70'te ise ADAM optimizasyonu ile elde edilen modellerin elektrik tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.


Tablo 52. Elektrik ADAM Optimizasyonu Modellerinin Parametre Sonuçları

Parametre	Adam I	Adam II	Adam III	Adam IV
Korelasyon	0.97715	0.97874	0.98443	0.98434
NMSE	0.037372	0.03658	0.030426	0.031543
R2	0.94273	0.9436	0.96324	0.95897
Katman	2	2	1	1
Ünite	150 150	150 150	75	375
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 53. ADAM Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh)

Aylar	Gerçek	Adam 75 Norm	Adam 80 Norm	Adam 75 Stand	Adam 80 Stand
Aralık 18	25478934000	27549065216	27322486784	27442108416	26848212992
Ocak 19	25735841000	25589940224	25149134848	23423889408	23099281408
Şubat 19	23196503000	25665122304	25511086080	25044881408	25289562112
Mart 19	24632078000	24697339904	24241969152	24827027456	24704536576
Nisan 19	23418583000	24252450816	24172681216	24611895296	23826755584

Elektrik tüketim talebine ait oluşturulan ADAM projeksiyonlarında en düşük NMSE değer ile en yüksek R^2 ve en yüksek korelasyon değerleri standardize edilmiş ve % 75 eğitim oranı kullanılmış ADAM III modelinde oluşmaktadır. Her bir proses için kullanılan preproses modellerinin en iyileri kıyaslamaya dahil edilmiştir. Kıyaslamaya göre 0.030426 NMSE, 0.96324 R^2 ve 0.98443 korelasyon ile standardize edilmiş ve %75 eğitim oranı kullanılmış ADAM III en iyi performansı göstermektedir.



Şekil 70. Elektrik ADAM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.8.2 Elektrik Tüketimi Bi-Lstm RMSprop Optimizasyonu

Elektrik tüketimine ait bidirectional Lstm modeli oluşturulurken kullanılan RMSprop optimizasyonuna ait preproses yöntemleri ve eğitim oranları ile parametre değerleri Tablo 56'da görülebilmektedir.

Tablo 57'de oluşturulan elektrik tüketim modellerinin gelecek tahmin değerleri, Şekil 71'de ise RMSprop optimizasyonu ile elde edilen modellerin elektrik tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.

Tablo 54 Elektrik RMSprop Optimizasyonu Modellerinin Parametre Sonuçları


Parametre	RMSPROP I	RMSPROP II	RMSPROP III	RMSPROP IV
Korelasyon	0.97577	0.97543	0.98667	0.98633
NMSE	0.038112	0.037806	0.031118	0.029407
R2	0.93889	0.93869	0.95962	0.9666
Katman	1	1	2	1
Ünite	275	275	125 125	100
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 55. RMSprop Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh)

Aylar	Gerçek	RMSPROP 75 Norm	RMSPROP 80 Norm	RMSPROP 75 Stand	RMSPROP 80 Stand
Aralık 18	25478934000	27488004096	27261030400	26624178176	27491414016
Ocak 19	25735841000	25339848704	25427726336	23601313792	23457576960
Şubat 19	23196503000	25546997760	25284253696	25191729152	24807421952
Mart 19	24632078000	24635275264	24339603456	24380768256	24109404160
Nisan 19	23418583000	24249849856	23999985664	23856883712	24425443328

Elektrik tüketim talebine ait oluşturulan RMSprop projeksiyonlarında en düşük NMSE değer ile en yüksek R^2 ve yüksek korelasyon değerleri standardize edilmiş ve % 80 eğitim oranı kullanılmış modelde oluşmaktadır. Kendi içinde en iyi performans gösteren RMSprop modellerinin kıyaslamasına göre 0.029407 NMSE, 0.9666 R^2 ve 0.98633 korelasyon ile standardize edilmiş ve %80 eğitim oranı

uygulanmış RMSprop IV modeli en iyi performansı göstermektedir. Model tek katman ve bu katman içinde 100 üniteden oluşmaktadır.



Şekil 71. Elektrik RMSprop optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.8.3 Elektrik Tüketimi Bi-Lstm SGDM Optimizasyonu

Elektrik tüketimine ait bidirectional Lstm modeli oluşturulurken kullanılan SGDM optimizasyonuna ait preprocess yöntemleri ve eğitim oranları Tablo 62’de görülmektedir.

Tablo 58’de oluşturulan elektrik tüketim modellerinin gelecek tahmin değerleri, Şekil 72’de ise SGDM optimizasyonu ile elde edilen modellerin elektrik tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.


Tablo 56. Elektrik SGDM Optimizasyonu Modellerinin Parametre Sonuçları

Parametre	SGDM I	SGDM II	SGDM III	SGDM IV
Korelasyon	0.92825	0.92355	0.97215	0.97234
NMSE	0.070835	0.070241	0.045789	0.043488
R2	0.68198	0.70877	0.89968	0.91315
Katman	1	1	1	1
Ünite	150	225	75	75
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 57. SGDM Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh)

Aylar	Gerçek	SGDM 75 Norm	SGDM 80 Norm	SGDM 75 Stand	SGDM 80 Stand
Aralık 18	25478934000	24852068352	25262424064	25764222976	26011283456
Ocak 19	25735841000	24998721536	25206122496	24329943040	24350369792
Şubat 19	23196503000	24743327744	25113608192	24277760000	24161196032
Mart 19	24632078000	24418338816	25061922816	23556132864	23712989184
Nisan 19	23418583000	24542285824	25293156352	23103662080	23497000960

Elektrik tüketim talebine ait oluşturulan SGDM projeksiyonlarında en düşük NMSE değer ile en yüksek R^2 ve en yüksek korelasyon değerleri standardize edilmiş ve % 80 eğitim oranı kullanılmış SGDM IV modelinde oluşmaktadır. Her bir proses için kullanılan preproses modellerinin en iyileri kıyaslamaya dahil edilmiştir. Kıyaslamaya göre 0.043488 MSE, 0.91315 R^2 ve 0.97214 korelasyon ile standardize edilmiş ve %80 eğitim oranı kullanılmış SGDM IV en iyi performansı göstermektedir.



Şekil 72. Elektrik SGDM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.8.4 Elektrik Tüketimi FeedForward BR Optimizasyonu

Elektrik tüketimine ait feed forward modeli oluşturulurken kullanılan BR optimizasyonuna ait preprocess yöntemleri ve eğitim oranları ile parametre değerleri Tablo 60'ta görülmektedir.

Tablo 61'de oluşturulan elektrik tüketim modellerinin gelecek tahmin değerleri, Şekil 73'te ise BR optimizasyonu ile elde edilen modellerin elektrik tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.


Tablo 58 Elektrik BR Optimizasyonu Modellerinin Parametre Sonuçları

Parametre	BR I	BR II	BR III	BR IV
Korelasyon	0.98623	0.98488	0.9849	0.98698
NMSE	0.029891	0.031688	0.028887	0.029451
R2	0.96444	0.95925	0.96575	0.96442
Katman	1	1	1	2
Nöron	15	30	15	30 25
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 59. BR Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh)

Aylar	Gerçek	BR 75 Norm	BR 80 Norm	BR 75 Stand	BR 80 Stand
Aralık 18	25478934000	26066425751	27154288672	26786380294	26678071168
Ocak 19	25735841000	23275850048	24323890236	24175764683	23906251942
Şubat 19	23196503000	23651737446	24584621426	24136754300	23983616719
Mart 19	24632078000	23785477057	23654126030	24206804141	24341138778
Nisan 19	23418583000	23680950156	23524158256	23534686840	24434548412

Elektrik tüketim talebine ait oluşturulan BR projeksiyonlarında en düşük NMSE değer ve en yüksek R² değeri standardize edilmiş ve % 75 eğitim oranı kullanılmış BR III modelinde oluşmaktadır. Diğer modellerde de yüksek korelasyon elde edilmiş olmasına rağmen belirleyici parametreler R² ve NMS değerler olmuştur. Model kıyaslamalarına göre 0.028887 NMSE, 0.96575 R² ve 0.9849 korelasyon ile standardize edilmiş ve %75 eğitim oranı uygulanmış BR III en iyi performansı göstermektedir.



Şekil 73. Elektrik BR optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.8.5 Elektrik Tüketimi FeedForward LM Optimizasyonu

Elektrik tüketimine ait feed forward modeli oluşturulurken kullanılan LM optimizasyonuna ait preproses yöntemleri ve eğitim oranları ile parametre değerleri Tablo 62’de görülmektedir.

Tablo 63’te oluşturulan elektrik tüketim modellerinin gelecek tahmin değerleri, Şekil 74’te ise LM optimizasyonu ile elde edilen modellerin elektrik tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.


Tablo 60 Elektrik LM Optimizasyonu Modellerinin Parametre Sonuçları

Parametre	LM I	LM II	LM III	LM IV
Korelasyon	0.98433	0.98289	0.97752	0.98429
NMSE	0.037217	0.038223	0.037802	0.03299
R2	0.93882	0.93706	0.93827	0.95464
Katman	2	2	2	2
Nöron	15 20	20 10	20 5	10 15
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 61. LM Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh)

Aylar	Gerçek	LM 75 Norm	LM 80 Norm	LM 75 Stand	LM 80 Stand
Aralık 18	25478934000	25796693739	29518919333	25918566296	25151383588
Ocak 19	25735841000	21386811561	23210583031	25916120293	24375074094
Şubat 19	23196503000	23708403990	26817727525	22240585563	26572974629
Mart 19	24632078000	22282057127	24861260574	24344243906	23277481031
Nisan 19	23418583000	21986070109	27103252509	23738738498	22990942146

Elektrik tüketim talebine ait oluşturulan LM projeksiyonlarında en düşük NMSE değer ile en yüksek R^2 ve yüksek korelasyon değerleri standardize edilmiş ve % 80 eğitim oranı kullanılmış LM IV modelinde oluşmaktadır. Kıyaslamaya dahil edilen modellere göre 0.03299 NMSE, 0.95464 R^2 ve 0.98429 korelasyon ile standardize edilmiş ve %80 eğitim oranı kullanılmış LM IV modeli en iyi performansı göstermektedir.



Şekil 74. Elektrik LM optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.8.6 Elektrik Tüketimi FeedForward SCG Optimizasyonu

Elektrik tüketimine ait feed forward modeli oluşturulurken kullanılan SCG optimizasyonuna ait preprocess yöntemleri ve eğitim oranları ile parametre değerleri Tablo 64'te görülmektedir.

Tablo 65'te oluşturulan elektrik tüketim modellerinin gelecek tahmin değerleri, Şekil 75'te ise SCG optimizasyonu ile elde edilen modellerin elektrik tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.


Tablo 62 Elektrik SCG Optimizasyonu Modellerinin Parametre Sonuçları

Parametre	SCG 75 Norm	SCG 80 Norm	SCG 75 Stand	SCG 80 Stand
Korelasyon	0.96703	0.96655	0.96852	0.98127
NMSE	0.047971	0.044416	0.044126	0.035047
R2	0.9054	0.91516	0.91882	0.95497
Katman	2	2	2	2
Nöron	10 20	10 20	20 10	10 5
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 63. SCG Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh)

Aylar	Gerçek	SCG 75 Norm	SCG 80 Norm	SCG 75 Stand	SCG 80 Stand
Aralık 18	25478934000	25195170268	26144128574	26764506309	26447693917
Ocak 19	25735841000	19201965759	25093168787	23393358627	25863294390
Şubat 19	23196503000	21139832053	24453991136	23192448753	26902258155
Mart 19	24632078000	21655911363	25080894740	23675061428	25516885123
Nisan 19	23418583000	15465624149	25987614357	22775408224	25155000857

Elektrik tüketim talebine ait oluşturulan SCG projeksiyonlarında en düşük NMSE değer ile en yüksek R^2 ile en yüksek korelasyon değerleri standardize edilmiş ve % 80 eğitim oranı kullanılmış SCG IV modelinde oluşmaktadır. Model kıyaslamasına bakıldığında 0.035047 NMSE, 0.95497 R^2 ve 0.98127 korelasyon ile standardize edilmiş SCG IV en iyi performansı göstermektedir.



Şekil 75. Elektrik SCG optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.8.7 Elektrik Tüketimi FeedForward CGF Optimizasyonu

Elektrik tüketimine ait feed forward modeli oluşturulurken kullanılan CGF optimizasyonuna ait preproses yöntemleri ve eğitim oranları ile parametre değerleri Tablo 66'da görülebilmektedir.

Tablo 67'de oluşturulan elektrik tüketim modellerinin gelecek tahmin değerleri, Şekil 76'da ise CGF optimizasyonu ile elde edilen modellerin elektrik tüketim tahmin değerleri ile gerçek değerlerin olduğu grafik görülmektedir.


Tablo 64 Elektrik CGF Optimizasyonu Modellerinin Parametre Sonuçları

Parametre	CGF 75 Norm	CGF 80 Norm	CGF 75 Stand	CGF 80 Stand
Korelasyon	0.97445	0.97707	0.97365	0.98155
NMSE	0.038019	0.036024	0.045029	0.033404
R2	0.94001	0.94629	0.9276	0.95255
Katman	2	2	2	1
Nöron	10 10	15 15	10 20	5
Eğitim Oranı	75%	80%	75%	80%
Preproses	Normalizasyon	Normalizasyon	Standardizasyon	Standardizasyon

Tablo 65. CGF Optimizasyonu Sonucu Elektrik Tüketim Tahmin Değerleri ile Gerçek Değerler (12.2018-04.2019/Kwh)

Aylar	Gerçek	CGF 75 Norm	CGF 80 Norm	CGF 75 Stand	CGF 80 Stand
Aralık 18	25478934000	25551818673	25017244930	25191208532	27144628902
Ocak 19	25735841000	23241196239	23430445256	28580966562	25277807877
Şubat 19	23196503000	22559169246	22896307176	27304896778	25043222250
Mart 19	24632078000	22974178494	22207184418	25434156288	24578614170
Nisan 19	23418583000	20987834573	21951114183	23033160831	25170964687

Elektrik tüketim talebine ait oluşturulan CGF projeksiyonlarında en düşük NMSE değer ile en yüksek R^2 ve en yüksek korelasyon değerleri standardize edilmiş ve % 80 eğitim oranı kullanılmış modelde oluşmaktadır. Her bir proses için kullanılan preproses modellerinin en iyileri kıyaslamaya dahil edilmiştir. Kıyaslamaya göre 0.033404 NMSE, 0.95255 R^2 ve 0.98155 korelasyon ile standardize edilmiş ve %80 eğitim oranı uygulanmış CGF IV en iyi performansı göstermektedir.



Şekil 76. Elektrik CGF optimizasyonu ile elde edilen gelecek tahmin değerler ve gerçek değerler

4.8.8 Elektrik Tüketim Tahmininde En İyi Performans Gösteren Optimizasyonların Kıyaslanması

Elektrik tüketim talebi için oluşturulan modellerde kendi aralarında en iyi performans gösteren optimizasyonların parametre değerleri Tablo 68’de görülmektedir.

Tablo 66 Elektrik Tüketim Tahmini En Yüksek Performans Gösteren Modellerinin Parametreleri

Parametre	ADAM	RMSprop	SGDM	BR	LM	SCG	CGF
Korelasyon	0.98443	0.98633	0.97234	0.9849	0.98429	0.98127	0.98155
NMSE	0.030426	0.029407	0.043488	0.028887	0.03299	0.035047	0.033404
R2	0.96324	0.9666	0.91315	0.96575	0.95464	0.95497	0.95255
Katman	1	1	1	1	2	2	1
Ünite/Nöron	75	100	75	15	10 15	10 5	5
PreProses	Stand	Stand	Stand	Stand	Stand	Stand	Stand
Validation	75	80	80	75	80	80	80

Kendi aralarında değerlendirilen ve en yüksek performans gösteren optimizasyon modelleri arasında en düşük değer olan 0.028887 NMSE değeri BR optimizasyonuna aittir. Bununla beraber BR optimizasyonuna en yakın olan değer 0.029407 NMSE ile RMSprop optimizasyonuna aittir. Tablo 68’de görüldüğü üzere en yüksek değerler olan 0.9666 R² ve 0.98633 korelasyon değerlerine sahip RMSprop optimizasyonu görülebilmektedir. Bu nedenle RMSprop optimizasyonunun performansı BR optimizasyonunun performansından daha iyi sonuç vermektedir. Gelecek dönem tahminleri için performans farklılıkları Şekil 80 ve Şekil 81’de daha etkin bir şekilde gözlemlenebilmektedir.

Elektrik tüketim talebi için oluşturulan modellerde kendi aralarında en iyi performans gösteren optimizasyonlarının oluşturduğu gelecekte gerçekleşebilecek tüketim değerleri ile 5 aylık gerçek değerler Tablo 69 ve Tablo 70’de bir arada görülebilmektedir.


Tablo 67. Elektrik Tüketim Tahmini için En Yüksek Performans Gösteren Bi-LSTM Modelleri ve Gerçek Değer (12.2018-04.2019/Kwh)

Aylar	Gerçek	Adam	RMSprop	SGDM
Aralık 18	25478934000	27442108416	27491414016	26011283456
Ocak 19	25735841000	23423889408	23457576960	24350369792
Şubat 19	23196503000	25044881408	24807421952	24161196032
Mart 19	24632078000	24827027456	24109404160	23712989184
Nisan 19	23418583000	24611895296	24425443328	23497000960

Tablo 68. Elektrik Tüketim Tahmini için En Yüksek Performans Gösteren Feed Forward Modelleri ve Gerçek Değer (12.2018-04.2019/Kwh)

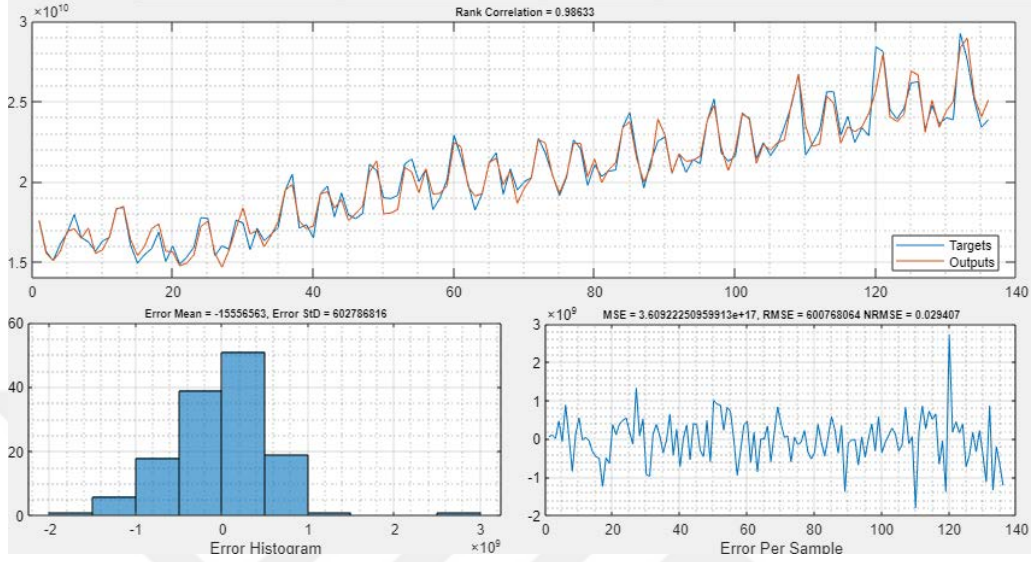
Aylar	Gerçek	BR	LM	SCG	CGF
Aralık 18	25478934000	26786380294	25151383588	26447693917	27144628902
Ocak 19	25735841000	24175764683	24375074094	25863294390	25277807877
Şubat 19	23196503000	24136754300	26572974629	26902258155	25043222250
Mart 19	24632078000	24206804141	23277481031	25516885123	24578614170
Nisan 19	23418583000	23534686840	22990942146	25155000857	25170964687

Optimizasyonların gerçek değerle beraber oluşturdukları gerçekleşen gelecek 5 aylık elektrik tüketim değer grafiği ise Şekil 77’de görülebilmektedir.




Şekil 77. Elektrik Tüketim Tahmini En Yüksek Performans Gösteren Modellerin gelecek tahmin değerleri ve gerçek değerler

Elektrik tüketim tahmin modellerinde en yüksek performans gösteren RMSprop optimizasyon modelinin eğitim sonuçları Şekil 78 ve Şekil 79’da görülebilmektedir.



Şekil 78. Elektrik Tüketim Tahmini RMSprop sonuçları I

RMSprop optimizasyonu için veri setinin %80’i eğitime tabii tutulmuş ve %20’lik kısmı ile test edilmiştir. 0.9666’lık çok iyi bir oranla eğitim aşaması tamamlanmış 0.73402’lik iyi bir oranla da test aşaması sonuçlanmıştır.



Şekil 79. Elektrik Tüketim Tahmini RMSprop sonuçları II


Standardize edilmiş RMSprop optimizasyonu modeli sonucu gelecek 60 ay için gerçekleşmesi tahmin edilen doğalgaz tüketim değerleri ve 2018 yılı gerçekleşen elektrik tüketim değerleri Tablo 71’te görülebilmektedir.

Tablo 69. Elektrik Tüketim Tahmini RMSprop Optimizasyonu gelecek 60 aylık tahmin değerleri (Kwh)

Aylar	2018	2019	2020	2021	2022	2023
Ocak	26211733504	23457576960	25993959424	26466361344	26075408384	26707234816
Şubat	23230873600	24807421952	25526040576	25534482432	26264088576	28368646144
Mart	24729133056	24109404160	24903561216	26009845760	28794564608	30057457664
Nisan	23586543616	24425443328	25922545664	29076025344	30558103552	31395620864
Mayıs	23964680192	25276004352	28997683200	30991056896	31188959232	31726587904
Haziran	23855663104	29510416384	30713524224	30473099264	30813081600	30632185856
Temmuz	29215672320	30136856576	28798552064	29508640768	29586694144	28643837952
Ağustos	27571281920	26661978112	27859890176	28351754240	27810717696	27477786624
Eylül	25051959296	25768042496	27118284800	26944423936	27120134144	27366258688
Ekim	23375800320	25588623360	26651906048	26900506624	27422281728	26825791488
Kasım	23848697856	27643537408	26405779456	27313381376	26897131520	26487521280
Aralık	27491414016	25565028352	26526713856	26958540800	26357544960	


Elektrik tüketiminin yaz aylarında en yüksek tüketim değerine ulaştığı 2005-2018 gerçekleşen değerlerden bilinmektedir. Model 3 yıllık bu tüketim dönemlerini iyi tahminleyebilmesine rağmen 3. yılda tüketim dönemlerinde yüksek değerlerin ilkbahar aylarına kayması gözlemlenmesinden dolayı uzak geleceği tahminleme de modelin zayıfladığı görülebilmektedir. Lineer olmayan bir trend göstermesinden dolayı bu farklılık daha baskın bir şekilde hissedilmektedir.

Oluşturulan RMSprop optimizasyon modelinin 2005 ve 2023 elektrik tüketim değerlerine ait grafik ise Şekil 80’de görülebilmektedir.



Şekil 80. RMSprop ile elde edilen elektrik tüketim çizelgesi (2005-2023)

En düşük NMSE değeri gösteren BR optimizasyonunun 2005-2023 yılı elektrik tüketim çizelgesi Şekil 81’de görülebilmektedir. Artan bir trend gösteren ve göstermesi beklenen elektrik tüketiminin sabit ve ardından azalarak devam etmesi BR optimizasyonu ile elde edilen tahmin modelinin, RMSprop optimizasyonu ile elde edilen modele kıyasla zayıf olduğu söylenebilir. R^2 bu zayıflıkta etkin bir rol oynamıştır denilebilir.



Şekil 81. BR ile elde edilen elektrik tüketim çizelgesi (2005-2023)



SONUÇ

Türkiye enerji üretme konusunda fakir bir ülke olarak karşımıza çıkmaktadır. Yıllar içerisinde enerji tüketiminin ise gelişmekte olan bir ülke olması nedeniyle artan bir trend gösterdiği görülmektedir. Gelecek dönemlerde de bu görünümün değişiklik göstermeyeceği çalışmada görülebilmektedir. Böyle bir durum Türkiye'nin enerji arz güvenliği konusunun, iç ve dış politikada önemli bir role sahip olacağını gözler önüne sermektedir. Dış ticaret hacminde cari açığa neden olan konunun %60'tan büyük bir kısmı enerji ürünlerinin ithalinden kaynaklanmaktadır. Gelişmekte olan bir ülke için artan döviz kuruyla beraber böyle bir bağımlılık hayati bir önem arz etmektedir. Ülkelerin devamlılığının enerjinin sürdürülebilirliğiyle paralel bir yapı göstermesi nedeniyle de bu hayati durumun devam edeceği söylenebilir.

Türkiye'nin jeo-stratejik konumu dikkate alındığında doğu-batı; kuzey-güney enerji koridorunda köprü olduğu görülebilmektedir. Türkiye özellikle TANAP ve TürkAkım boru hatları ile enerji transfer merkezine dönüşmüştür. Boru hatlarının yanı sıra enerji taşımacılığında coğrafi konumu nedeniyle ulaşım maliyetlerinin en düşük olduğu güzergah yine Türkiye üzerinden geçmektedir. Bu durum da stratejik konumunu güçlendirmektedir. Tedarikçiler ile alıcılar arasında bulunmak Türkiye'yi enerji pazarındaki bir aktöre çevirmektedir.

Her ne kadar bu stratejik konum avantaj olarak görülse de politik açıdan enerjinin çok kritik bir konu olduğu göz ardı edilmemelidir. Tarih boyunca enerji konusunun birçok çatışmaya neden olduğu bilinmektedir ve özellikle son dönemlerde enerji yoğunluğunun Orta Doğu'da olmasından kaynaklanan Türkiye çevresindeki istikrarsız görünüm, ülkenin bu konuda doğru stratejik adımları atmasını zorunlu kılmaktadır. Enerji güvenliğinin, ekonomik ve toplumsal gelişmişliği etkilediği gibi siyasi ve askeri alanı da derinden etkilediğinden ve çatışma konusunun enerji olmasından dolayı böyle bir jeo-stratejik konum Türkiye'yi siyasi ve askeri olarak da zor duruma sokabilmektedir. Bu nedenle Doğu Akdeniz Havzası'nda mevcut olan enerji kapasitesi bu sorunun ana kaynaklarından biri olarak karşımıza çıkmaktadır.

Türkiye için özellikle fosil yakıtların ithalatının çok yüksek olduğu düşünüldüğünde bu kaynakların arz ve talebinin yönetimi problemi ortaya çıkmaktadır. Bu kaynaklara ait gelecek dönemlerde gerçekleşmesi muhtemel değerlerin tahmin edilmesi de doğru bir yönetim stratejisinin belirlenmesi için çok önemli bir konu olmaktadır. Enerji iç talebinin karşılanması ülkenin sürdürülebilir bir arz politikasını belirleyici bir unsurdur. Bu nedenle bu çalışmada Türkiye enerji sektörüne konu olan doğalgaz ve elektrik kaynaklarının tüketim miktarları tahmin edilmeye ve gelecek dönem projeksiyonlarının okunmasının gerçekleştirilmesine çalışılmıştır.

Çalışmada doğalgaz ve elektrik tüketim miktarları tahmin edilmeye çalışılırken 2 farklı YSA modeli olan bidirectional LSTM ve feedforward modelleri ve LSTM modeline ait ADAM, RMSprop, SGDM optimizasyonları ile feed forward modeline ait BR, LM, SCG ve CGF optimizasyonları verilerin eğitiminde kullanılmıştır. Preproses olarak max-min normalizasyon yöntemi ile z-score standardizasyon teknikleri uygulanmış, eğitim oranları ise %75 ve %80 olarak ele alınmıştır.

2012-2018 arası gerçekleşen doğalgaz tüketimi veri seti aylık olarak 84, 2005-2018 arası gerçekleşen elektrik tüketimi veri seti ise aylık olarak 167'dir. Her iki kaynak için de hem bi- lstm ve feed forward YSA yöntemleri ve her iki metoda ait optimizasyon yöntemleri ayrı ayrı çalıştırılmıştır. Doğalgaz tüketim tahmini için çalıştırılan eğitim sayısı 1886, elektrik tüketimi tahmini için çalıştırılan eğitim sayısı 1773'tür. Eğitimlerin sonuçları her bir optimizasyon için farklı nöron sayısı, farklı katman sayısı, farklı ünite sayısı, farklı preproses yöntemi ve %75 ile %80'lik eğitim oranları kullanılarak elde edilmiştir.

Doğalgaz ve elektrik kaynaklarının tüketim değerlerine ait veri seti uzunlukları birbirine eşit olmamakla beraber elektriğin veri seti doğalgazın 2 katı kadardır. Yapay sinir ağları yüksek performans elde edebilmek için uzun veri setine ihtiyaç duymaktadır. Bu nedenle veri setlerinin uzunluğu ele alındığında yöntemler arası farklılık oluşup oluşmayacağı da bu çalışmanın konuları arasındadır.

Doğalgaz için elde edilen modeller arasında en yüksek performansı standardize edilmiş ve %80'lik eğitim oranı ile çalıştırılan RMSprop optimizasyonu

modeli göstermiştir. Kış aylarında maksimum değerlere ulaşan doğalgaz tüketimi RMSprop projeksiyonunda ilk sene için kış aylarında maksimum değer alırken sonrası için kayma yaparak sonbahar aylarında maksimum değeri göstermiştir. Tahmin modeli gerçek zamandan uzaklaştıkça zayıflık göstermektedir. 60 aylık tahminin bu nedenle fazla olduğu söylenebilir ve 12-20 aylık tahmin değerlerin yönetsel stratejilerin geliştirilmesi açısından doğru olacağı ifade edilebilir.

Doğalgaz tüketiminin gelecek dönemlerde tahmini en yüksek olarak 6559.634 milyon cm^3 'e ulaşacağı gözlemlenmiştir. En düşük tahmini olarak ise 2201.748 milyon cm^3 olarak karşımıza çıkmaktadır. En yüksek ve en düşük değerler arasındaki fark çok yüksektir. Dönemsel olarak doğalgaz tüketim ve ithalatı üzerine en iyi stratejilerin tercih edilmesi gerekmektedir. Dönemsel tutarlılığın en yüksek olduğu 2019 yılı için toplam doğalgaz tüketiminin bir önceki yıl olan 2018'e göre artış gösterdiği gözlemlenebilmektedir. Bundan sonraki süreçte modele göre toplam doğalgaz tüketiminin azalacağı gözlemlenmektedir ancak tutarlılığın giderek daha da azalması en düşük noktanın çok daha düşük görünmesine neden olmuş olabilir. Geçmiş dönemlerde de kullanılan doğalgaz miktarında bazı dalgalanmalar gerçekleşmiştir. Yıllık toplamlarda artış ve azalışların olduğu doğalgaz kullanımında maksimum değerlerin bir önceki döneme göre daha da yüksek olduğu ise görülebilmektedir. Bu nedenle 12 aylık süreç için yönetsel kararlarda doğalgaz kaynağının Türkiye için hayati olduğu söylenebilir ve Rusya, İran, Azerbaycan gibi tedarikçilerle olan ilişkiler dikkate alınmalıdır. Özellikle Rusya ve İran ile olan diplomatik seviye üst düzey öneme sahiptir. Bununla beraber Doğu Akdeniz Levant havzasında doğalgaz ve petrol arama işlemlerine başlayan Türkiye bu konumunu kaybetmemelidir. Yine Türkiye halkının doğalgaz tüketimi konusunda bilinçlendirilmesi muhtemel olan tüketim ve ithalat için büyük bir önem arz etmektedir.

Elektrik için elde edilen modeller arasında ise yine en yüksek performansı standardizasyon preprosesine tabi tutulan ve %80'lik eğitim oranı ile çalıştırılan RMSprop optimizasyonu modeli göstermiştir. Veri setinin doğalgaza göre uzun olması ya da doğalgaz tüketim veri setinin elektrik tüketimine kıyasla kısa olması bir farklılık göstermemiştir.

Yaz aylarında maksimum değerlere ulaşan elektrik tüketimi RMSprop projeksiyonunda ilk 2 sene için yine yaz aylarında maksimum değer alırken sonrası için kayma yaparak ilkbahar aylarında maksimum değeri göstermiştir. Tahmin modeli gerçek zamandan uzaklaştıkça yine zayıflık göstermektedir. Ancak elektrik tüketim tahmininde kayma doğalgaz tüketim tahminine göre daha geç gerçekleşmiştir. Bunun da veri setinin uzunluğundan kaynaklanıyor olduğu söylenebilir. Yine de 60 aylık tahminin bu veri seti için de fazla olduğu söylenebilir ve 24-30 aylık tahmin değerlerin yönetsel stratejilerin geliştirilmesi açısından doğru olacağı ifade edilebilir.

Elektrik tüketiminin gelecek dönemlerde tahmini en yüksek olarak 31726587904 Kwh'e ulaşacağı gözlemlenmiştir. En düşük tahmini olarak ise 23457576960 Kwh olarak karşımıza çıkmaktadır. En yüksek ve en düşük değerler arasındaki fark yüksektir. Elektrik tüketimin yıllar bazında artacağı gözlemlenebilmektedir.

Gelişmekte olan bir ülke olarak karşımıza çıkan Türkiye için sürekli artan elektrik tüketimi beklenen bir durumdur. Ancak enerji konusunda fakir olan Türkiye bu durumu en iyi şekilde yönetmelidir. Zira ikincil enerji kaynağı olan elektrik doğrudan birincil enerji kaynaklarını etkilemekte ve onlardan etkilenmektedir.

Türkiye özellikle son dönemlerde yenilenebilir enerji kaynakları konusunda atılım gerçekleştirmiştir. Enerji konusunda kendi kaynağına dönmek ülkeler açısından geliştirilecek en önemli stratejiler arasındadır. Bu nedenle yenilenebilir enerji kaynaklarından üretilen elektrik, elektrik tüketimi konusunda Türkiye'yi rahatlatacak bir yöntemdir. Bununla beraber nükleer enerji kaynağının gündeme gelmiş olması bu açıdan önemli bir gelişmedir. En önemli elektrik ihracatçılarının da tercih ettiği nükleer enerji bu anlamda Türkiye için kullanılması gereken bir yöntem olarak karşımıza çıkmaktadır. Yenilenebilir enerjinin dönemselsel olarak garanti bir kaynak olmaması nükleer enerjinin tercih edilmesi gereken bir yöntem olduğunu da gösterebilmektedir. Ayrıca küresel ısınma probleminin artık çok hissedilir olması yenilenebilir kaynakları bu noktada garanti dışı bırakabilmektedir. Elektrik enerjisinin elde edildiği kaynakların en büyük oranı doğalgaza aittir. Bu nedenle Doğu Akdeniz Levant havzası bu konuda da önemini korumaktadır. Bunlara ek

olarak Türkiye halkının elektrik tüketimi konusunda da doğalgazda olduğu gibi bilinçlendirilmesi ve takip edilmesi doğru stratejilerden biri olacaktır.

Literatürde enerji tahmin çalışmaları için kullanılan yapay sinir ağıları metodu MLP olarak tercih edilmektedir. Yapılan çoğu çalışmada feed forward metodunun kullanıldığı ve diğer istatistikî metotlarla karşılaştırıldığı görülmektedir. Genel olarak YSA'nın diğer istatistikî analizlere göre daha iyi performans gösterdiği söylenmektedir. Bu çalışmada ise hem 84 adet verinin yer aldığı doğalgaz talep tahmini çalışmasında hem de 167 adet verinin yer aldığı elektrik talep tahmini çalışmasında bi-LSTM mimarisinin feed forward mimarisinden daha iyi performans gösterdiği gözlemlenmiştir. Bi-LSTM mimarisinde RMSprop optimizasyonu her iki tahminleme için en yüksek performansı gösteren öğrenme algoritması olmuştur. Bununla beraber literatürde mevcut olan feed forward çalışmalarında genellikle LM optimizasyonunun kullanıldığı görülmüştür ancak çalışmamızda her iki tahmin eğitiminde de BR optimizasyonunun feed forward mimarisi için iyi sonuçlar gösterdiği gözlemlenmiştir. Bu nedenle YSA zaman serisi tabanlı bir tahminlemede feed forward mimarisi tercih edilecekse BR optimizasyonunun da ele alınması tavsiye edilebilir. Bununla beraber özellikle feed forward ve bi-LSTM mimarisinin seçimi söz konusu ise bi-LSTM mimarisinin tercih edilmesi daha doğru bir yol olacaktır. Optimizasyonların yanısıra normalleştirme yöntemi olan “z-skore” standardizasyonu ile “min-max” normalizasyon yöntemine göre daha yüksek performans elde edilmiştir. Preproses olarak standardizasyon yönteminin tercih edilebilirliği normalizasyon yöntemine göre daha yüksektir.

Gelecek dönem tahmin performans tutarlılığının güçlendirilmesi için ise; veri seti uzunluğunun önemi çalışmada ortaya çıkmaktadır. Bu nedenle oluşturulacak mimarilerde mümkün olduğu kadar uzun veri setinin girdi olarak kullanılmasına dikkat edilmelidir.



KAYNAKÇA

- Abual-Foul, Bassam (2012). "Forecasting Energy Demand in Jordan Using Artificial Neural Networks", *Topics in Middle Eastern and African Economies*. 14: 473-478
- Akay Diyar ve Atak Mehmet (2007). "Grey Prediction with Rolling Mechanism for Electricity Demand Forecasting of Turkey". *Energy*. 32: 1670–1675
- Akpınar, Erdal (2005). "Bakü-Tiflis-Ceyhan (BTC) Ham Petrol Boru Hattı ve Türkiye Jeopolitiğine Etkileri". *GÜ Gazi Eğitim Fakültesi Dergisi*. 25/2: 229-248
- Altunbey Feyza ve Alataş Bilal (2015). "Sosyal Ağ Analizi için Sosyal Tabanlı Yapay Zeka Optimizasyon Algoritmalarının İncelenmesi". *Int. J. Pure Appl Sci*. 1: 33-52.
- Aras, Osman Nuri (2001). *Azerbaycan'ın Hazar Ekonomisi ve Stratejisi*. İstanbul: Derin Yayınları.
- Armaroli Nicola ve Balzani Vincenzo (2011). *Energy for a Sustainable World, From the Oil Age to a Sun- Powered Future*. Weinheim: WILEY-VCH Verlag GmbH & Co. KGaA.
- Aydın, Gökhan (2014). "Modeling of Energy Consumption Based on Economic and Demographic Factors: The Case of Turkey With Projections". *Renewable and Sustainable Energy Reviews*. 35: 382–389.
- Baghirli, Orkhan (2015). "Comparison of Lavenberg-Marquardt, Scaled Conjugate Gradient and Bayesian Regularization Backpropagation Algorithms for Multistep Ahead Wind Speed Forecasting Using Multilayer Perceptron Feedforward Neural Network". *Yüksek Lisans Tezi*. Uppsala Üniversitesi.
- Bataineh Ali A. ve Kaur Devinder (2018). "A Comparative Study of Different Curve Fitting Algorithms in Artificial Neural Network using Housing Dataset". *National Aerospace and Electronics Conference*. USA: 174-178.
- Batista Gustavo E. A. P. A, Prati Ronaldo C. ve Monard Maria C. (2004). "A Study of the Behavior of Several Methods for Balancing Machine Learning Training Data". *ACM SIGKDD Explorations Newsletter – Special Issue on Learning From Imbalanced Datasets*. 6/1: 20-29.

- Bayrak Metin ve Esen Ömer (2014). “Forecasting Turkey’s Energy Demand Using Artificial Neural Networks: Future Projection Based on an Energy Deficit”. *Journal of Applied Economic Sciences*. 9/2: 191-204.
- Bayramoğlu Turgut, Pabuçcu Hakan ve Boz, Füsün Ç. (2017). “Türkiye İçin Anfis Modeli İle Birincil Enerji Talep Tahmini”. *Ege Akademik Bakış*. 17/3: 431-446.
- Bilgili, Mehmet (2009). “Estimation of Net Electricity Consumption of Turkey”. *İst Bilimi ve Tekniği Dergisi*. 29/2: 89-98.
- Bilgili Mehmet, Şahin Beşir, Yaşar Abdulkadir ve Şimşek Erdoğan (2012). “Electric Energy Demands of Turkey in Residential and Industrial Sectors”. *Renewable and Sustainable Energy Reviews*. 16: 404-414.
- Boğar Eşref ve Boğar Zeynep Ö. (2017). “Türkiye Net Elektrik Enerjisi Tüketiminin Parçacık Sürü Optimizasyonu Tabanlı Modellenmesi”. *Akademia Mühendislik ve Fen Bilimleri Dergisi*. 1/3: 40-47.
- BOTAŞ (2013). *2012 Yılı Sektör Raporu*. Ankara.
- BOTAŞ (2016). *2015 Yılı Faaliyet Raporu*. Ankara.
- BOTAŞ (2017). *2016 Yılı Sektör Raporu*. Ankara
- BP (2018). *Energy Outlook 2018*.
- BP (2018a). *Natural Gas: Statistical Review of World Energy*.
- BP (2018b). *Oil: Statistical Review of World Energy*.
- BP (2018). *Natural Gas Reserves*, <https://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy/natural-gas/natural-gas-reserves.html> Erişim Tarihi: 01.03.2018.
- BP (2017). *Statistical Review of World Energy*. <https://www.bp.com/content/dam/bp/en/corporate/pdf/energy-economics/statistical-review-2017/bp-statistical-review-of-world-energy-2017-full-report.pdf> Erişim Tarihi: 01.03.2018.
- Canyurt Olcay E. ve Öztürk Harun K. (2008). “Application of Genetic Algorithm (GA) Technique on Demand Estimation of Fossil Fuels in Turkey”. *Energy Policy*. 36: 2562-2569.

- Canyurt Olcay E., Ceylan Halim, Öztürk Harun K., Hepbaşlı Arif (2004). “Energy Demand Estimation Based on Two-Different Genetic Algorithm Approaches”. *Energy Sources*. 26: 1313-1320.
- Ceylan Hüseyin, Ceylan Halim, Haldenbilen Soner ve Başkan Özgür (2008). “Transport Energy Modeling With Meta- Heuristic Harmony Search Algorithm, An Application to Turkey”. *Energy Policy*. 36: 2527-2535.
- Ceylan Halim ve Öztürk Harun K. (2004). “Estimating Energy Demand of Turkey Based on Economic Indicators Using Genetic Algorithm Approach”. *Energy Conversion and Management*. 45: 2525-2537.
- Ceylan Halim, Öztürk Harun K., Hepbaşlı Arif ve Utlü Zafer (2005). “Estimating Energy and Exergy Production and Consumption Values Using Three Different Genetic Algorithm Approaches. Part 1: Application and Scenarios”, *Energy Source*. 27: 621–627.
- Ceylan Halim, Öztürk Harun K., Hepbaşlı Arif ve Utlü Zafer (2005). “Estimating Energy and Exergy Production and Consumption Values Using Three Different Genetic Algorithm Approaches. Part 2: Application and Scenarios”. *Energy Sources*. 27: 629–639.
- Cui Zhiyong, Ke Ruimin ve Wang Yinhai (2017). “Deep Stacked Bidirectional and Unidirectional LSTM Recurrent Neural Network for Network-wide Traffic Speed Prediction”. <https://arxiv.org/ftp/arxiv/papers/1801/1801.02143.pdf> Erişim Tarihi: 27.05.2019.
- Çınar Didem ve Kayakutlu Gülgün (2007). “Forecasting Production of Renewable Energy Using Cognitive Mapping and Artificial Neural Networks”. *19th International Conference on Production Research*. <https://pdfs.semanticscholar.org/a95a/4a55199eb49cb324d2a9cb100ca3a91badec.pdf> Erişim Tarihi: 22.11.2018
- Çınar Didem, Kayakutlu Gülgün ve Daim Tuğrul (2010). “Development of Future Energy Scenarios with Intelligent Algorithms: Case of Hydro in Turkey”. *Energy*. 35: 1724-1729.
- Demir, Faruk (2007). *Enerji Güvenliği, Ekonomisi, Diplomasisi*. Ankara: Altın küre Yayınları.

- Demirbilek, Sami (1987). “Kömür Kullanımı ve İlgili Çevre Kirlenmesi”. *Madencilik*. 16/3: 33-43.
- Demirel Ömer F., Zaim Selim, Çalışkan Ahmet ve Özuyar Pınar (2012). “Forecasting Natural Gas Consumption in İstanbul Using Neural Networks and Multivariate Time Series Methods”. *Turk J Elec Eng & Comp Sci*. 20/5: 695-711.
- Demirel Özkan, Kakilli Adnan ve Tektaş Mehmet (2010). “ANFIS ve ARMA Modelleri ile Elektrik Enerjisi Yük Tahmini”. *Gazi Üniv. Müh. Mim. Fak. Dergisi*. 25/3: 601-210.
- Dilaver Zafer ve Hunt Lester C. (2011). “Industrial Electricity Demand for Turkey: A Structural Time Series Analysis”. *Energy Economics*. 33: 426–436.
- Doğanay, Hayati (1998). *Ekonomik Coğrafya 2 (Enerji Kaynakları)*, Genişletilmiş 2. Baskı. Erzurum: Şafak Yayınevi.
- EDAM (2011). *Nükleer Enerjiye Geçişte Türkiye Modeli*, İstanbul: Tor Ofset.
- Ediger Volkan Ş. ve Akar Sertaç (2007). “ARIMA Forecasting of Primary Energy Demand by Fuel in Turkey”. *Energy Policy*. 35: 1701-1708.
- Ediger Volkan Ş., Akar Sertaç ve Uğurlu Berkin (2006). “Forecasting Production of Fossil Fuel Sources in Turkey Using a Comparative Regression and ARIMA Model”. *Energy Policy*. 34: 3836-3846.
- Ediger Volkan Ş. ve Tatlıdil Hüseyin (2002). “Forecasting the Primary Energy Demand in Turkey and Analysis of Cyclic Patterns”. *Energy Conversion and Management*. 43: 473-487.
- EIA (2018). “Russia is World's Largest Producer of Crude Oil and Lease Condensate”. <https://www.eia.gov/todayinenergy/detail.php?id=22392> Erişim Tarihi: 10.12.2018
- EIA (2018). “Glossary: Natural Gas; Dry Natural Gas” <https://www.eia.gov/tools/glossary/?id=natural%20gas>. Erişim Tarihi: 01.03.2018
- EIA (2018). “Total Electricity Installed Capacity 2015”, <https://www.eia.gov/beta/international/rankings/#?product=2-7&cy=2015> Erişim Tarihi: 07.03.2018
- EIA (2017). <https://www.eia.gov/> Erişim Tarihi: 11.12.2017

- Ekonomou, Lambros (2010). “Greek Long-Term Energy Consumption Prediction Using Artificial Neural Networks”. *Energy*. 35: 512–517.
- Elmas, Çetin (2016). *Yapay Zeka Uygulamaları*. İstanbul: Seçkin Yayıncılık.
- Enerji Enstitüsü, <http://enerjiensitüsü.com/2016/03/08/fukisima-faciasindan-5-yil-sonra-bugun-durum-yeni-nukleer-santrallar-icin-alinacak-dersler/> Erişim Tarihi: 11.12.2017
- Enerji ve Dış Politika Araştırma Merkezi (2011). *Nükleer Enerjiye Geçişte Türkiye Modeli*. (Ed. Sinan Ülgen). İstanbul: Tor Ofset Sanayi ve Ticaret Ltd.Şti.
- Engin, Naci (2010). “Enerji Kaynağı Olarak Doğalgaz ve Türkiye”. *Marmara Coğrafya Dergisi*. 22: 233-244.
- ENTSO-E (2016). *Mid-term Adequacy Forecast*
- EPDK. (2016b). *Elektrik Piyasası 2015 Yılı Piyasa Gelişim Raporu 2016*.
- EPDK (2017a). *Doğalgaz Sektör Raporu Temmuz 2017 Raporu*
- EPDK (2017b). *Elektrik Piyasası Sektör Raporu Ağustos*.
- EPDK (2017c). *Elektrik Piyasası 2016 Yılı Piyasa Gelişim Raporu 2017*.
- EPDK (2017d). *Doğalgaz Piyasası Sektör Raporu Eylül*.
- EPDK (2017e). *Petrol Piyasası Sektör Raporu 2016*.
- EPDK (2017f). *Doğalgaz Sektör Raporu Temmuz 2016 Raporu*.
- Erdoğan, Erkan (2007). “Electricity Demand Analysis Using Cointegration and ARIMA Modelling: a Case Study of Turkey”. *Energy Policy*. 35: 1129–1146.
- Erdoğan, Erkan. (2010). “Natural Gas Demand in Turkey”. *Applied Energy*. 87: 211-219.
- Ericson, Richard E. (2009). “Eurasian Natural Gas Pipelines: The Political Economy of Network Interdependence”. *Euroasian Geograph and Economics*. 50: 28-57.
- Erilli Necati A., Eğrioğlu Erol, Yolcu Ufuk, Aladağ Hakan Ç. ve Uslu Rezan V. (2010). “Türkiye’de Enflasyonun İleri ve Geri Beslemeli Yapay Sinir Ağlarının Melez Yaklaşımı ile Öngörüsü”. *Doğuş Üniversitesi Dergisi*. 11/1: 42-55.
- Es Hüseyin A., Kalender Yeşim F. ve Hamzaçebi Coşkun (2014). “Yapay Sinir Ağları ile Türkiye Net Enerji Talep Tahmini”. *Gazi Üniv. Müh. Mim. Fak. Dergisi*. 29/3: 495-504.

- ETKB (2017). “Doğalgaz Boru Hatları ve Projeleri”. <http://www.enerji.gov.tr/tr-TR/Sayfalar/Dogal-Gaz-Boru-Hatlari-ve-Projeleri>, Erişim Tarihi: 26.12.2017.
- ETKB (2017b). “Kömür Nedir?” <http://www.enerji.gov.tr/File/?path=ROOT%2F1%2FDocuments%2FSayfalar%2FK%C3%B6m%C3%BCr+Nedir-.pdf> Erişim Tarihi: 15.12.2018.
- ETKB (2017c). “Petrol”, <http://www.enerji.gov.tr/tr-TR/Sayfalar/Petrol> Erişim Tarihi: 15.12.2018.
- ETKB (2017). “Jeotermal”. <http://www.enerji.gov.tr/tr-TR/Sayfalar/Jeotermal> Erişim Tarihi: 30.11.2017.
- ETKB (2017). “Nükleer Enerji”. <http://www.enerji.gov.tr/tr-TR/Sayfalar/Nukleer-Enerji> Erişim Tarihi: 11.12.2017.
- ETKB (2017). “Rüzgar”. <http://www.enerji.gov.tr/tr-TR/Sayfalar/Ruzgar> Erişim Tarihi: 22.11.2017.
- European Commission (2018). “Enerji Security Strategies”. <https://ec.europa.eu/energy/en/topics/energy-strategy-and-energy-union/energy-security-strategy> Erişim Tarihi: 11.12.2018.
- Fauset, Laurene (1994). *Fundamentals of Neural Network*. London:Prentice Hall International,.
- Ferguson, Charles D. (2015). *Nükleer Enerji: Herkesin Bilmesi Gerekenler*. (Çev: Fatih Güdük). Anlara: Buzdağı Yayınevi.
- Filik Ümmühan B., Gerek Ömer N. ve Kurban Mehmet (201). “A Novel Modeling Approach for Hourly Forecasting of Long-Term Electric Energy Demand”. *Energy Conversion and Management*. 52: 199-211.
- Foresee Dan F. ve Hagan Martin (1997). "Gauss-Newton Approximation to Bayesian Learning in Neural Networks". *Proceedings of International Conference on Neural Networks*. USA: 1930-1935.
- Gazprom (2018). “Gazprom and Turkey – Strategic Partners”. <http://www.gazprom.com/press/news/2014/november/article207801/> Erişim Tarihi: 03.01.2018.
- Gazprom (2019). “TurkStream”. <http://www.gazprom.com/about/production/projects/pipelines/built/turk-stream/> Erişim Tarihi: 09.01.2019.

- Geem, Zong W. (2011) “Transport Energy Demand Modeling of South Korea Using Artificial Neural Network”. *Energy Policy*. 39: 4644–4650.
- Geostat (2019). “External Trade”, http://www.geostat.ge/index.php?action=page&p_id=134&lang=eng Erişim Tarihi: 24.01.2019.
- Görücü F. B., Geriş P. U. ve Gümrah Fevzi (2004). “Artificial Neural Network Modeling for Forecasting Gas Consumption”, **Energy Sources**, 26: 299-307.
- Görücü F. B. ve Gümrah Fevzi (2004). “Evaluation and Forecasting of Gas Consumption by Statistical Analysis”. *Energy Sources*. 26: 267-276.
- Gref Klaus, Srivastava Kumar R., Koutnik Jan, Steunebrink Bas R. ve Schminhuber Jürgen (2017). “LSTM-A Search Space Odyssey”. *Transactions on Neural Networks And Learning Systems*. 28/10: 2222-2232.
- Günay Erdem M. (2016). “Forecasting Annual Gross Electricity Demand by Artificial Neural Networks Using Predicted Values of Socio-Economic Indicators and Climatic Conditions: Case Of Turkey”. *Energy Policy*. 90: 92–101.
- Haldenbilen Soner ve Ceylan Halim (2005). “Genetic Algorithm Approach to Estimate Transport Energy Demand in Turkey”. *Energy Policy*. 33: 89-98.
- Hamzaçebi Coşkun ve Es Hüseyin A. (2014). “Forecasting The Annual Electricity Consumption of Turkey Using an Optimized Grey Model”. *Energy*, 70: 165-171.
- Hamzaçebi Coşkun ve Kutay Fevzi (2004). “Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini”. *Gazi Üniv. Müh. Mim. Fak. Dergisi*. 19/3: 227-233.
- Haykin, Simon (1998). *Neural Networks: A Comprehensive Foundation*. Second Ed. New Jersey: Prentice hall.
- Haykin, Simon (2009). *Neural Networks and Learning Machines*. Third Ed. New Jersey: Prentice Hall.
- Hotunoğlu Hakan ve Karakaya Etem (2011). “Forecasting Turkey’s Energy Demand Using Artificial Neural Networks: Three Scenario Applications”. *Ege Akademik Bakış*. 11: 87-94.

- <https://medium.com/deep-learning-turkiye/derin-ogrenme-uygulamalarinda-en-sik-kullanilan-hiper-parametreler-ece8e9125c4> Erişim tarihi: 20.05.2019.
- <https://www.muhendisbeyinler.net/cpu-vs-gpu/> Erişim tarihi: 20.05.2019.
- IEA (2019). “Bulgaria”. <https://www.iea.org/countries/Bulgaria/> Erişim Tarihi: 11.01.2019.
- IEA (2018). “France”. <https://www.iea.org/countries/France/> Erişim Tarihi: 13.12.2018 .
- IEA (2019). “Germany”. <https://www.iea.org/countries/Germany/> Erişim Tarihi: 13.12.2018 .
- IEA (2019). “Greece”. <https://www.iea.org/countries/Greece/> Erişim Tarihi: 10.01.2019 .
- IEA (2018). “IEA Atlas of Energy : Electricity”, <http://energyatlas.iea.org/#!/tellmap/-1118783123/2> Erişim Tarihi: 12.12.2018.
- IEA (2018). “Italy”. <https://www.iea.org/countries/Italy/> Erişim Tarihi: 13.12.2018.
- IEA (2018). “Norway”. <https://www.iea.org/countries/Norway/> Erişim Tarihi: 12.12.2018.
- IEA (2018). “Turkey”. <https://www.iea.org/countries/Turkey/> Erişim Tarihi: 12.12.2018.
- IEA (2017a). “Key World Enerji Statistics 2017”. <https://www.iea.org/publications/freepublications/publication/KeyWorld2017.pdf> Erişim Tarihi: 09.01.2019.
- IEA (2017b). *Renewables Information: Overview*
- IEA (2017c). *World Energy Balances: Overview*
- IEA (2017d). “Energy Policies of IEA Countries: Greece” 2017 Review.
- Jayalakshmi T. ve Santhakumaran A. (2011). “Statistical Normalization and Backpropagation for Classification”. *International Journal of Computer Theory and Engineering*. 3/1: 1793-8201.
- Kalaycı, Eylem (2015). “ANFIS ile Türkiye’nin Doğalgaz Talep Tahmini”. **İnönü Üniversitesi Yüksek Lisans Bitirme Tezi**. Malatya.

- Kankal Murat, Akpınar Adem, Kömürcü Murat İ. ve Özşahin Talat Ş. (2011). “Modeling and Forecasting of Turkey’s Energy Consumption Using Socio-Economic and Demographic Variables”. *Applied Energy*. 88/5: 1927-1939.
- Karagöl Erdal T. ve Kızılkaya Mehmet (2015). *Rusya-AB-Türkiye Üçgeninde Türk Akımı*. İstanbul: Seta Perspektif.
- Karakaya, Leyla (2011). “Batı Hattı Gözden Çıkarılabilir Mi?”. Değerlendirme Notu, *Türkiye Ekonomi Politikaları Araştırma Vakfı*, No: 201159.
- Kargı, Vesile S. A. (2015). *Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama*. Bursa: Ekin Basım Yayın Dağıtım.
- Kavaklıoğlu Kadir, Ceylan Halim, Öztürk Harun K. ve Canyurt Olcay E. (2009), “Modeling and Prediction of Turkey’s Electricity Consumption Using Artificial Neural Networks”. *Energy Conversion and Management*. 50: 2719-2727.
- Kaynar Oğuz, Taştan Serkan ve Demirkoparan Ferhan (2011). “Yapay Sinir Ağları ile Doğalgaz Tüketim Tahmini”. *Atatürk Ü. İİBF Dergisi*. 10. Ekonometri ve İstatistik Sempozyumu Özel Sayısı, 463-474.
- Keshavarz-Hedayati B., Guangyuan P., Jooya A. ve Dimopoulos N. J. (2015). “In-Training and Post-Training Generalization Methods: the case of ppar – α and ppar - γ agonists”. *International Joint Conference on Neural Networks*. Ireland.
- Kılıçbeyli, Elif H. (2002). “Europe and Asia: new Partnership After the Cold War Era”. *Alternatives; Turkish Journal of International Relations*. 1/3: 89-115.
- Kıran Mustafa S., Özceylan Eren, Gündüz Mesut ve Paksoy Turan (2012). “A Novel Hybrid Approach Based on Particle Swarm Optimization and Ant Colony Algorithm to Forecast Energy Demand of Turkey”. *Energy Conversion and Management*. 53: 75-83.
- Kingma Diederick P. ve Ba Jimmy (2015). “Adam: A Method for Stochastic Optimization”, *ICLR*. 1-15.
- Koç Erdem ve Şenel Mahmut C. (2013). “Dünyada ve Türkiye’de Enerji Durumu - Genel Değerlendirme”. *Mühendis ve Makine*. 54/ 639: 32-44.
- Kocaeren, Aysel A. (2016). *Çevre ve Enerji*. İstanbul: Nobel Yayınları.

- Küçükali Serhat ve Barış Kemal (2010). “Turkey’s Short-Term Gross Annual Electricity Demand Forecast by Fuzzy Logic Approach”. *Energy Policy*. 38: 2438–2445.
- Külebi, Ali (2007). *Türkiye’nin Enerji Sorunları ve Nükleer Gerekliklik*. Ankara: Bilgi Yayınevi.
- Larose, Daniel T. (2005). *Discovering Knowledge In Data: An Introduction to Data Mining*. New Jersey: John Wiley and Sons Inc.
- Limanond Thirayoot, Jomnonkwao Sajjakaj ve Srikaew Artit (2011). “Projection of Future Transport Energy Demand of Thailand”. *Energy Policy*. 39: 2754–2763.
- Macmillan Encyclopedia of Energy (2001). (Ed. Zümerchik, J) Macmillan Reference. USA, Newyork.
- McMillan, J., (2003). *U.S. Interests and Objectives, The United States and persian Gulf: Reshaping Security Strategy for the post-Containment Era*. (Ed. Richard D. Sokolsky). Washington.
- Mitchell Tom, Buchanan Bruce, Dejong Gerald, Dietterich Thomas, Rosenbloom Paul ve Waibel Alex (1990). “Machine Learning”. *Annual Review of Computer Science*. 4: 417-433.
- Murat Yetiş S. ve Ceylan Halim (2006). “Use of Artificial Neural Networks for Transport Energy Demand Modeling”. *Energy Policy*. 34: 3165-3172.
- Oğan, Sinan (2003). “Mavi Akım Projesi: Bir Enerji Stratejisi ve Stratejisizliği Örneği”. *Stradigma*. 7: 1-20
- Önal Eylem ve Yarbay Zerrin R. (2010). “Türkiye’de Yenilenebilir Enerji Kaynakları Potansiyeli ve Geleceği”. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 8: 77-96.
- OPEC (2017). *Aylık Petrol Piyasası Raporu: Küresel Petrol Stoklarında Son Gelişmeler*. Kasım.
- Özçelik Yavuz ve Hepbaşı Arif (2006). “Estimating Petroleum Exergy Production and Consumption Using a Simulated Annealing Approach”, *Energy Sources*. Part B. 1: 255–265.
- Öztemel, Ercan (2006). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık Eğitim Bilgisayar Sis. San. ve Tic. A.Ş.

- Öztürk Harun K., Ceylan Halim, Canyurt Olcay E. ve Hepbaşı Arif, (2005). “Electricity estimation using genetic algorithm approach: a case study of Turkey”. *Energy*, 30: 1003–1012.
- Öztürk Harun K., Ceylan Halim, Hepbaşı Arif ve Utlu Zafer (2004). “Estimating petroleum exergy production and consumption using vehicle ownership and GDP based on genetic algorithm approach”. *Renewable and Sustainable Energy Reviews*. 8: 289–302.
- Pao, Hsiao-Tien (2006). “Comparing Linear and Nonlinear Forecasts for Taiwans Electricity Consumption”. *Energy*. 31: 2129–2141.
- Payal Ashish, Rai, C. S. ve Reddy, B. V. R. (2014). “Artificial Neural Networks for Developing Localization Framework in Wireless Sensor Networks”. India.
- PETDER (2017). *2016 Sektör Raporu*
- RENA (2016). *Renewable Energy Statistics 2016*.
- Ruder, Sebastian (2017). “An Overview of Gradient Descent Optimization Algorithms”. <https://arxiv.org/pdf/1609.04747.pdf> Erişim Tarihi: 27.07.2019.
- Sarak Hülya ve Satman Abdurrahman (2003). “The Degree-Day Method to Estimate the Residential Heating Natural Gas Consumption in Turkey: A Case Study”. *Energy*. 28: 929–939.
- Say Nuriye P. ve Yücel Muzaffer (2006). “Energy Consumption and CO2 Emissions in Turkey: Empirical Analysis and Future Projection Based on an Economic Growth”. *Energy Policy*. 34: 3870–3876.
- Simpson, Patrick K. (1989). *Artificial Neural Network*. New York: Pergamon Press.
- SOCAR (2019). “TANAP Shareholder Agreement signed in Ankara”. <http://socar.az/socar/en/news-and-media/news-archives/news-archives/id/8232> Erişim Tarihi: 09.01.2019.
- SOCAR (2019). Baku-Tbilisi-Erzurum Gas Pipeline. <http://socar.az/socar/en/activities/transportation/baku-tbilisi-erzurum-gas-pipeline> , Erişim Tarihi: 05.01.2019.
- Söyler, Hasan (2014). *Türkiye'nin Enerji Simülasyonu ve Senaryo Analizleri*. Malatya: Medipress Matbaacılık.
- Söyler Hasan, Kızılkaya Oktay, Fendoğlu Eda ve Gökçe Mustafa (2016). “Türkiye’deki Elektrik Tüketimi Tahmini için İleri ve Geri Beslemeli Yapay

- Sinir Ağları ve ANFIS Model Karşılaştırılması”. Conference Paper. https://www.researchgate.net/publication/320719655_Turkiye'deki_Elektrik_Tuketimi_Tahmini_icin_Ileri_ve_Geri_Beslemeli_Yapay_Sinir_Aglari_ve_ANFIS_Model_Karsilastirilmesi Erişim Tarihi: 20.11.2018.
- Sözen Adnan ve Arcaklıoğlu Erol (2007). “Prediction of Net Energy Consumption Based on Economic Indicators (GNP And GDP) in Turkey”. *Energy Policy*. 35: 4981-4992.
- Sözen, Adnan (2009). “Future projection of the energy dependency of Turkey using artificial neural network”. *Energy Policy*. 37: 4827–4833.
- Sözen Adnan, Akçayol Ali M. ve Arcaklıoğlu Erol (2006). “Forecasting Net Energy Consumption Using Artificial Neural Network”. *Energy Sources*. Part B. 2: 147-155.
- Sözen Adnan, Arcaklıoğlu Erol ve Özalp Mehmet (2004). “Estimation of Solar Potential in Turkey by Artificial Neural Networks Using Meteorological and Geographical Data”. *Energy Conversion and Management*. 45: 3033–3052.
- Sözen Adnan, Arcaklıoğlu Erol ve Özkaymak Mehmet (2005). “Turkey’s Net Energy Consumption”. *Applied Energy*. 81: 209–221.
- Szoplik, Jolanta (2015). “Forecasting of Natural Gas Consumption with Artificial Neural Networks”. *Energy*. 85: 208-220.
- TANAP (2018). “Dünya’nın Konuştuğu Proje: TANAP”. http://www.tanap.com/content/file/TANAP_WEB_201812.pdf Erişim Tarihi: 11.12.2018.
- TANAP (2019). “TANAP nedir?” <http://www.tanap.com/tanap-projesi/tanap-nedir/> Erişim Tarihi: 10.01.2019.
- Taşpınar Fatih, Çelebi Numan ve Tutkun Nedim (2013). “Forecasting Of Daily Natural Gas Consumption On Regional Basis İn Turkey Using Various Computational Methods”. *Energy and Buildings*. 56: 23–31.
- Tekin, Mahmut (2012). *Üretim Yönetimi*. 8. Ed. Vol. 1. Konya: Günay Ofset.
- TKİ (2016). *2015 Kömür (Linyit) Sektör Raporu*. Ankara.
- Tokgöz Alper ve Ünal Gözde (2018). “Türkiye Elektrik Tüketimi Tahmini için RNN Tabanlı Zaman Serisi Yaklaşımı”. *26th Signal Processing and Communications Applications Conference (SIU)*.

<https://ieeexplore.ieee.org/abstract/document/8404313> Erişim Tarihi: 17.08.2019.

Toksarı, Duran M. (2007). “Ant Colony Optimization Approach to Estimate Energy Demand Of Turkey”. *Energy Policy*. 35: 3984–3990.

Toksarı, Duran M. (2009). “Estimating the net electricity energy generation and demand using the ant colony optimization approach: Case of Turkey”, *Energy Policy*. 37: 1181–1187.

TPAO (2016). *Ham Petrol ve Doğal Gaz Sektör Raporu*.

TPAO (2017). “2015 Yıllık Raporu”. <http://www.tpao.gov.tr/tp5/docs/rapor/TP-2015-YILLIK-RAPORU.pdf> Erişim Tarihi: 10.01.2019.

Trebuna Peter, Halcinova Jana, Fil’o Milan ve Markovic Jaromir (2014). “The Importance of Normalization and Standardization in the Process of Clustering”, *IEEE 12th International Symposium on Applied Machine Intelligence and Informatics*, Slovakya: 381-386.

Tunç Murat, Çamdalı Ünal ve Parmaksızoğlu Cem (2006). “Comparison of Turkey’s Electrical Energy Consumption and Production with Some European Countries and Optimization of Future Electrical Power Supply Investments in Turkey”. *Energy Policy*. 34: 50–59.

TTK (2017). *2016 Yılı Taşkömürü Sektör Raporu*. Ankara.

TÜSİAD (1998). *21. Yüzyıla Girerken Türkiye’nin Enerji Stratejisinin Değerlendirilmesi*. İstanbul.

UEA (2017). *Key World Enerji Statistics 2017*.

Ünler, Alper (2008). “Improvement of Energy Demand Forecasts Using Swarm Intelligence: The Case of Turkey with Projections to 2025”. *Energy Policy*. 36: 1937-1944.

Varınca Kamil B. ve Günüllü Talha M. (2006). “Türkiye’de Güneş Enerjisi Potansiyeli ve Bu Potansiyelin Kullanım Derecesi, Yöntemi ve Yaygınlığı Üzerine Bir Araştırma”. *UGHEK’2006: I. Ulusal Güneş ve Hidrojen Enerjisi Kongresi*. Eskişehir Osmangazi Üniversitesi, Eskişehir: 270-275.

Wind Energy in Europe (2017). *Outlook to 2020*. <https://windeurope.org/about-wind/reports/wind-energy-in-europe-outlook-to-2020/> Erişim Tarihi: 22.11.2017.

- Windeurope (2016). *Wind in Power 2016 European Statistics*.
- World Energy Council (2017). “Energy Resources: Solar”.
<https://www.worldenergy.org/data/resources/resource/solar/> Erişim Tarihi:
24. 11.2017.
- World Wind Energy Association (2016). *WWEA Half-year Report 2016*.
- World Wind Energy Association (2017). “Wwea Released Latest Global Small Wind Statistics”. <http://www.wwindea.org/wwea-released-latest-global-small-wind-statistics/> Erişim Tarihi: 22.11.2017.
- Worldatlas (2017). “The World’s Largest Oil Reserves By Country”.
<http://www.worldatlas.com/articles/the-world-s-largest-oil-reserves-by-country.html> Erişim Tarihi: 25.12.2018.
- www.world-nuclear.org (2018). “German’s Energiwende”. <https://www.world-nuclear.org/information-library/energy-and-the-environment/energiwende.aspx> Erişim Tarihi: 13.12.2018.
- Yarman, Tolga (2009). *Enerji Kaynakları*, İstanbul: T.C. Okan Üniversitesi Yayınları.
- Yazan Ersan ve Talu Fatih M. (2017). “Stokastik Dereceli Alçalma Yöntemi Temelli Optimizasyon Tekniklerinin Karşılaştırılması”. *2017 International Artificial Intelligence and Data Processing Symposium*. Turkey.
- Yenilenebilir Enerji Genel Müdürlüğü (2017). “Hidroelektrik Enerjisi Nedir?”.
http://www.eie.gov.tr/yenilenebilir/h_hidrolik_nedir.aspx Erişim Tarihi:
01.11.2017
- Yerci, Volkan (2015). “Türkiye Denizlerindeki Rüzgâr Enerjisi Potansiyeli ve Deniz Üstü Rüzgâr Santralleri Kurulabilecek Bölgelerin Belirlenmesi”. *Mevlana Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı, Yayınlanmamış Yüksek Lisans Tezi*. Konya.
- Yiğit, Vecihi (2011). “Genetik Algoritma ile Türkiye Net Elektrik Enerjisi Tüketiminin 2020 Yılına Kadar Tahmini”. *International Journal of Engineering Research and Development*. 3/2: 37-41.
- Yüksek, Ahmet G. (2007) “Hava Kirliliği Tahmininde Çoklu Regresyon Analizi ve Yapay Sinir Ağları Yönteminin Karşılaştırılması”. *Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü Doktora tezi*, Sivas.

Yumurtacı Zehra ve Asmaz Ercan (2004). “Electric Energy Demand of Turkey for the Year 2050”. *Energy Sources*. 26: 1157–1164.

Zhang Guokiang, Patuwo Eddy B. ve Hu Michael Y. (1998). “Forecasting with Artificial Neural Networks: The State of The Art”. *International Journal of Forecasting*. 14: 35–62.

Zhou Libin ve Jang Xiaojun (2010). “Training Algorithm Performance for Image Classification by Neural Networks”. *Photogrammetric Engineering & Remote Sensing*. 76/8: 945-951.





EKLER

Kullanılan Bi-LSTM ve FeedForward Kodları

Veri Yükleme

```
function data = loadData(opt)
[chosenfile,chosendirectory] = uigetfile({'*.xlsx'; '*.csv'},...
    'Select Excel time series Data sets','data.xlsx');
filePath = [chosendirectory chosenfile];
if filePath ~= 0
    data.DataFileName = chosenfile;
    data.CompleteData = readtable(filePath);
    if size(data.CompleteData,2)>1
        warning('Input data should be an excel file with only one column!');
        disp('Operation Failed... '); pause(.9);
        disp('Reloading data. '); pause(.9);
        data.x = [];
        data.isDataRead = false;
        return;
    end
    data.seriesdataHeader =
data.CompleteData.Properties.VariableNames(1,:);
    data.seriesdata = table2array(data.CompleteData(:,:));
    disp('Input data successfully read. ');
    data.isDataRead = true;
    data.seriesdata = PreInput(data.seriesdata);

    figure('Name','InputData','NumberTitle','off');
    plot(data.seriesdata);
    title(['Mean = ' num2str(mean(data.seriesdata)) ', STD = '
num2str(std(data.seriesdata)) ']);
    if strcmpi(opt.dataPreprocessMode,'None')
        data.x = data.seriesdata;
    elseif strcmpi(opt.dataPreprocessMode,'Data Normalization')
        data.x = DataNormalization(data.seriesdata);
```

```

elseif strcmpi(opt.dataPreprocessMode,'Data Standardization')
    data.x = DataStandardization(data.seriesdata);
end
figure('Name','NormalizedInputData','NumberTitle','off');
plot(data.x);
title(['Mean = ' num2str(mean(data.x)) ', STD = ' num2str(std(data.x))
]);
else
    warning(['In order to train network, please load data.' ...
'Input data should be an excel file with only one column!']);
disp('Operation Cancel. ');
data.isDataRead = false;
end
end

function data = PreInput(data)
if iscell(data)
for i=1:size(data,1)
for j=1:size(data,2)
if strcmpi(data{i,j},'#NULL!')
tempVars(i,j) = NaN; %#ok
else
tempVars(i,j) = str2num(data{i,j}); %#ok
end
end
end
data = tempVars;
end

end

```

Veri Eğitimi

```

function [opt,data] = TrainData(opt,data)
% Bi-LSTM parameters
if opt.NumOfHiddenLayers ==1
    opt.numHiddenUnits1 = opt.NumOfUnitsInFirstlayer;
elseif opt.NumOfHiddenLayers ==2
    opt.numHiddenUnits1 = opt.NumOfUnitsInFirstlayer;
    opt.numHiddenUnits2 = opt.NumOfUnitsInSecondlayer;
elseif opt.NumOfHiddenLayers ==3
    opt.numHiddenUnits1 = opt.NumOfUnitsInFirstlayer;
    opt.numHiddenUnits2 = opt.NumOfUnitsInSecondlayer;
    opt.numHiddenUnits3 = opt.NumOfUnitsInThirdlayer;
elseif opt.NumOfHiddenLayers ==4
    opt.numHiddenUnits1 = opt.NumOfUnitsInFirstlayer;
    opt.numHiddenUnits2 = opt.NumOfUnitsInSecondlayer;
    opt.numHiddenUnits3 = opt.NumOfUnitsInThirdlayer;
    opt.numHiddenUnits4 = opt.NumOfUnitsInFourthlayer;
end
% feedforward parameters
if opt.NumOfFeedForwardLeyars ==1
    opt.ShallowhiddenLayerSize =
[opt.NumOfNeuronsInFirstlayer];
% number of Hidden layers in feedforward network.
elseif opt.NumOfFeedForwardLeyars ==2
    opt.ShallowhiddenLayerSize = [opt.NumOfNeuronsInFirstlayer
opt.NumOfNeuronsInSecondlayer]; % number of Hidden layers
in feedforward network.
elseif opt.NumOfFeedForwardLeyars ==3
    opt.ShallowhiddenLayerSize = [opt.NumOfNeuronsInFirstlayer
opt.NumOfNeuronsInSecondlayer opt.NumOfNeuronsInThirdlayer];% number
of Hidden layers in feedforward network.
end

%%
tic;
% prepare delays for time serie network
data = CreateTimeSeriesData(opt,data);

% divide data into test and train data
data = dataPartitioning(opt,data);

```

```

if strcmpi(opt.learningMethod, 'LSTM')
    % LSTM data form
    data = LSTMInput(data);
    % Define LSTM architect
    opt = LSTMArchitect(opt,data);
elseif strcmpi(opt.learningMethod, 'FeedForward')
    % Prepare input data for FeedForward network.
    FeedForwardInput();
    % Define feedforward architect
    opt = FeedForwardArchitect(opt);
end

% Train LSTM, FeedForward or ANFIS Network
data = TrainNet(opt,data);

end

%% -----> Local Functions <-----
--

% ---- data preparation ----
% make some delays on input filed
function data = CreateTimeSeriesData(opt,data)
    Delays = opt.Delays;

    x = data.x';
    T = size(x,2);

    MaxDelay = max(Delays);

    Range = MaxDelay+1:T;

    X= [];
    for d = Delays
        X=[X; x(:,Range-d)];
    end

    Y = x(:,Range);

```



```

        data.X = X;
        data.Y = Y;
    end
    % partitioning input data
    function data = dataPartitioning(opt,data)
    data.XTr = [];
    data.YTr = [];
    data.XTs = [];
    data.YTs = [];

    numTrSample = round(opt.trPercentage*size(data.X,2));

    data.XTr = data.X(:,1:numTrSample);
    data.YTr = data.Y(:,1:numTrSample);

    data.XTs = data.X(:,numTrSample+1:end);
    data.YTs = data.Y(:,numTrSample+1:end);

    disp(['Time Series data divided to '
    num2str(opt.trPercentage*100) '% Train data and ' num2str((1-
    opt.trPercentage)*100) '% Test data']);
    end
    % Prepare input data for FeedForward network.
    function FeedForwardInput()
        disp('Time Series data prepared as suitable feedforward
    Input data.');
```

```
end
```

```
% Prepare input data for LSTM network.
```

```
function data =LSTMInput(data)
```

```
for i=1:size(data.XTr,2)
```

```
    XTr{i,1} = data.XTr(:,i);
```

```
    YTr(i,1) = data.YTr(:,i);
```

```
end
```

```
for i=1:size(data.XTs,2)
```

```
    XTs{i,1} = data.XTs(:,i);
```

```
    YTs(i,1) = data.YTs(:,i);
```

```
end
```

```

data.XTr    = XTr;
data.YTr    = YTr;
data.XTs    = XTs;
data.YTs    = YTs;

disp('Time Series data prepared as suitable LSTM Input
data.');
```

end

```

% ---- network structure ----
% bi-LSTM Deeplearning Architect
function opt = LSTMArchitect(opt,data)

miniBatchSize    = opt.miniBatchSize;
maxEpochs       = opt.maxEpochs;
trainingProgress = opt.trainingProgress;
executionEnvironment = opt.executionEnvironment;

inputSize = size(data.X,1);
outputMode = 'last';
numResponses = 1;

if opt.isUseDropoutLayer % if dropout layer is true
    if opt.NumOfHiddenLayers ==1
        if opt.isUseBiLSTMLayer == 1
            opt.layers = [ ...
                sequenceInputLayer(inputSize)
                bilstmLayer(opt.numHiddenUnits1,'OutputMode',outputMode)
                dropoutLayer(0.2)
                fullyConnectedLayer(numResponses)
                regressionLayer];
        else
            opt.layers = [ ...
                sequenceInputLayer(inputSize)
                lstmLayer(opt.numHiddenUnits1,'OutputMode',outputMode)
                dropoutLayer(0.2)
                fullyConnectedLayer(numResponses)

```

```

        regressionLayer];
    end
elseif opt.NumOfHiddenLayers ==2
    if opt.isUseBiLSTMLayer
        opt.layers = [ ...
            sequenceInputLayer(inputSize)

bilstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')
            dropoutLayer(0.2)

bilstmLayer(opt.numHiddenUnits2, 'OutputMode', outputMode)
            dropoutLayer(0.2)
            fullyConnectedLayer(numResponses)
            regressionLayer];
    else
        opt.layers = [ ...
            sequenceInputLayer(inputSize)

lstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')
            dropoutLayer(0.2)

lstmLayer(opt.numHiddenUnits2, 'OutputMode', outputMode)
            dropoutLayer(0.2)
            fullyConnectedLayer(numResponses)
            regressionLayer];
    end
elseif opt.NumOfHiddenLayers ==3
    if opt.isUseBiLSTMLayer
        opt.layers = [ ...
            sequenceInputLayer(inputSize)

bilstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')
            dropoutLayer(0.2)

bilstmLayer(opt.numHiddenUnits2, 'OutputMode', 'sequence')
            dropoutLayer(0.2)

bilstmLayer(opt.numHiddenUnits3, 'OutputMode', outputMode)
            dropoutLayer(0.2)
            fullyConnectedLayer(numResponses)
            regressionLayer];
    end

```

```

        else
            opt.layers = [ ...
                sequenceInputLayer(inputSize)

                bilstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')
                    dropoutLayer(0.2)

                bilstmLayer(opt.numHiddenUnits2, 'OutputMode', 'sequence')
                    dropoutLayer(0.2)

                bilstmLayer(opt.numHiddenUnits3, 'OutputMode', outputMode)
                    dropoutLayer(0.2)
                    fullyConnectedLayer(numResponses)
                    regressionLayer];
        end
    elseif opt.NumOfHiddenLayers ==4
        if opt.isUseBiLSTMLayer
            opt.layers = [ ...
                sequenceInputLayer(inputSize)

                bilstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')
                    dropoutLayer(0.2)

                bilstmLayer(opt.numHiddenUnits2, 'OutputMode', 'sequence')
                    dropoutLayer(0.2)

                bilstmLayer(opt.numHiddenUnits3, 'OutputMode', 'sequence')
                    dropoutLayer(0.2)

                bilstmLayer(opt.numHiddenUnits4, 'OutputMode', outputMode)
                    dropoutLayer(0.2)
                    fullyConnectedLayer(numResponses)
                    regressionLayer];
        else
            opt.layers = [ ...
                sequenceInputLayer(inputSize)

                bilstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')
                    dropoutLayer(0.2)

                bilstmLayer(opt.numHiddenUnits2, 'OutputMode', 'sequence')
                    dropoutLayer(0.2)

```

```

bilstmLayer(opt.numHiddenUnits3, 'OutputMode', 'sequence')
    dropoutLayer(0.2)

bilstmLayer(opt.numHiddenUnits4, 'OutputMode', outputMode)
    dropoutLayer(0.2)
    fullyConnectedLayer(numResponses)
    regressionLayer];
    end
end
else % if dropout layer is false
    if opt.NumOfHiddenLayers ==1
        if opt.isUseBiLSTMLayer
            opt.layers = [ ...
                sequenceInputLayer(inputSize)
bilstmLayer(opt.numHiddenUnits1, 'OutputMode', outputMode)
                fullyConnectedLayer(numResponses)
                regressionLayer];
        else
            opt.layers = [ ...
                sequenceInputLayer(inputSize)

lstmLayer(opt.numHiddenUnits1, 'OutputMode', outputMode)
                fullyConnectedLayer(numResponses)
                regressionLayer];
        end
    elseif opt.NumOfHiddenLayers ==2
        if opt.isUseBiLSTMLayer
            opt.layers = [ ...
                sequenceInputLayer(inputSize)

bilstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')

bilstmLayer(opt.numHiddenUnits2, 'OutputMode', outputMode)
                fullyConnectedLayer(numResponses)
                regressionLayer];
        else
            opt.layers = [ ...
                sequenceInputLayer(inputSize)

```

```

lstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')

lstmLayer(opt.numHiddenUnits2, 'OutputMode', outputMode)
    fullyConnectedLayer(numResponses)
    regressionLayer];
end
elseif opt.NumOfHiddenLayers ==3
    if opt.isUseBiLSTMLayer
        opt.layers = [ ...
            sequenceInputLayer(inputSize)

bilstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')

bilstmLayer(opt.numHiddenUnits2, 'OutputMode', 'sequence')

bilstmLayer(opt.numHiddenUnits3, 'OutputMode', outputMode)
    fullyConnectedLayer(numResponses)
    regressionLayer];
else
    opt.layers = [ ...
        sequenceInputLayer(inputSize)

bilstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')

bilstmLayer(opt.numHiddenUnits2, 'OutputMode', 'sequence')

bilstmLayer(opt.numHiddenUnits3, 'OutputMode', outputMode)
    fullyConnectedLayer(numResponses)
    regressionLayer];
end
elseif opt.NumOfHiddenLayers ==4
    if opt.isUseBiLSTMLayer
        opt.layers = [ ...
            sequenceInputLayer(inputSize)

bilstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')

bilstmLayer(opt.numHiddenUnits2, 'OutputMode', 'sequence')

bilstmLayer(opt.numHiddenUnits3, 'OutputMode', 'sequence')

bilstmLayer(opt.numHiddenUnits4, 'OutputMode', outputMode)

```

```

        fullyConnectedLayer(numResponses)
        regressionLayer];
    else
        opt.layers = [ ...
            sequenceInputLayer(inputSize)

            bilstmLayer(opt.numHiddenUnits1, 'OutputMode', 'sequence')

            bilstmLayer(opt.numHiddenUnits2, 'OutputMode', 'sequence')

            bilstmLayer(opt.numHiddenUnits3, 'OutputMode', 'sequence')

            bilstmLayer(opt.numHiddenUnits4, 'OutputMode', outputMode)

            fullyConnectedLayer(numResponses)
            regressionLayer];
    end
end
end
% Training Network Options
% 'sgdm'
% 'rmsprop'
% 'adam'

opt.opts = trainingOptions(opt.LR, ...
    'MaxEpochs', maxEpochs, ...
    'GradientThreshold', 1, ...
    'InitialLearnRate', 0.005, ...
    'LearnRateSchedule', 'piecewise', ...
    'LearnRateDropPeriod', 125, ...
    'LearnRateDropFactor', 0.2, ...
    'Verbose', 1, ...
    'MiniBatchSize', miniBatchSize, ...
    'ExecutionEnvironment', executionEnvironment, ...
    'Plots', trainingProgress);
disp('LSTM architect successfully created.');
```

```

end
% FeedForward Shallowlearning Architect
function opt = FeedForwardArchitect(opt)
    opt.Net =
        feedforwardnet(opt.ShallowhiddenLayerSize, opt.trainFcn);

```

```

opt.Net.divideParam.trainRatio = 80/100;
opt.Net.divideParam.valRatio   = 10/100;
opt.Net.divideParam.testRatio  = 10/100;

opt.Net.trainParam.epochs      = opt.maxIterations;
opt.Net.trainParam.showWindow  = opt.showWindow;
opt.Net.trainParam.showCommandLine = opt.showCommandLine;
disp('FeedForward architect successfully created.');
```

end

```

% Train Network
function data = TrainNet(opt,data)

if strcmpi(opt.learningMethod,'LSTM')
    try
        data.BiLSTM.Net =
trainNetwork(data.XTr,data.YTr,opt.layers,opt.opts);
        disp('LSTM Network successfully trained.');
```

data.IsNetTrainSuccess =true;

```

    catch me
        disp('Error on Training LSTM Network');
```

data.IsNetTrainSuccess = false;

```

    return;
end
elseif strcmpi(opt.learningMethod,'FeedForward')
    try
        [data.FF.Net,~] = train(opt.Net,data.XTr,data.YTr);
        disp('Feed Forward Network successfully trained.');
```

data.IsNetTrainSuccess = true;

```

    catch me
        disp('Error on Training FF Network');
```

data.IsNetTrainSuccess =false;

```

    return;
end
end
end
```


Eğitilen Verinin Ölçümü

```
function [opt,data] = EvaluationData(opt,data)
if strcmpi(opt.learningMethod,'LSTM')

    data.BiLSTM.TrainOutputs =
deNorm(data.seriesdata,predict(data.BiLSTM.Net,data.XTr,'MiniBatchSi
ze',opt.miniBatchSize),opt.dataPreprocessMode);

    data.BiLSTM.TrainTargets =
deNorm(data.seriesdata,data.YTr,opt.dataPreprocessMode);

    data.BiLSTM.TestOutputs =
deNorm(data.seriesdata,predict(data.BiLSTM.Net,data.XTs,'MiniBatchSi
ze',opt.miniBatchSize),opt.dataPreprocessMode);

    data.BiLSTM.TestTargets =
deNorm(data.seriesdata,data.YTs,opt.dataPreprocessMode);

    data.BiLSTM.AllDataTargets = [data.BiLSTM.TrainTargets
data.BiLSTM.TestTargets];

    data.BiLSTM.AllDataOutputs = [data.BiLSTM.TrainOutputs
data.BiLSTM.TestOutputs];

    data = PlotResults(data,'Tr',...
        data.BiLSTM.TrainOutputs, ...
        data.BiLSTM.TrainTargets);

    data =
plotReg(data,'Tr',data.BiLSTM.TrainTargets,data.BiLSTM.TrainOutputs)
;

    data = PlotResults(data,'Ts',...
        data.BiLSTM.TestOutputs, ...
        data.BiLSTM.TestTargets);

    data =
plotReg(data,'Ts',data.BiLSTM.TestTargets,data.BiLSTM.TestOutputs);

    data = PlotResults(data,'All',...
        data.BiLSTM.AllDataOutputs, ...
        data.BiLSTM.AllDataTargets);

    data =
plotReg(data,'All',data.BiLSTM.AllDataTargets,data.BiLSTM.AllDataOut
puts);

    disp('Bi-LSTM network performance evaluated.');
```

```
elseif strcmpi(opt.learningMethod,'FeedForward')
```

```

        data.FF.TrainOutputs =
deNorm(data.seriesdata,data.FF.Net(data.XTr)',opt.dataPreprocessMode
);

        data.FF.TrainTargets =
deNorm(data.seriesdata,(data.YTr)',opt.dataPreprocessMode);

        data.FF.TestOutputs =
deNorm(data.seriesdata,data.FF.Net(data.XTs)',opt.dataPreprocessMode
);

        data.FF.TestTargets =
deNorm(data.seriesdata,(data.YTs)',opt.dataPreprocessMode);

        data.FF.AllDataTargets = [data.FF.TrainTargets
data.FF.TestTargets];

        data.FF.AllDataOutputs = [data.FF.TrainOutputs
data.FF.TestOutputs];

    DispVal = 1;
    for i= DispVal
        data = PlotResults(data,'Tr',...
            data.FF.TrainOutputs(i,:), ...
            data.FF.TrainTargets(i,:));
        data =
plotReg(data,'Tr',data.FF.TrainTargets(i,:),data.FF.TrainOutputs(i,:
));

        data = PlotResults(data,'Ts',...
            data.FF.TestOutputs(i,:), ...
            data.FF.TestTargets(i,:));
        data =
plotReg(data,'Ts',data.FF.TestTargets(i,:),data.FF.TestOutputs(i,:))
;

        data = PlotResults(data,'All',...
            data.FF.AllDataOutputs(i,:), ...
            data.FF.AllDataTargets(i,:));
        data =
plotReg(data,'All',data.FF.AllDataTargets(i,:),data.FF.AllDataOutput
s(i,:));

        disp('Feedforward network performance evaluated.');
```

end

end

end

```

function vars = deNorm(data,stdData,deNormMode)
if iscell(stdData(1,1))
    for i=1:size(stdData,1)
        tmp(i,:) = stdData{i,1}';
    end
    stdData = tmp;
end
if strcmpi(deNormMode,'Data Normalization')

    for i=1:size(data,2)
        vars(:,i) = (stdData(:,i).*(max(data(:,i))-
min(data(:,i)))) + min(data(:,i)));
    end
    vars = vars';
elseif strcmpi(deNormMode,'Data Standardization')

    for i=1:size(data,2)
        x.mu(1,i) = mean(data(:,i),'omitnan');
        x.sig(1,i) = std (data(:,i),'omitnan');
        vars(:,i) = ((stdData(:,i).* x.sig(1,i))+ x.mu(1,i));
    end
    vars = vars';
else
    vars = stdData';
    return;
end
end
% display results
function data = PlotResults(data,firstTitle,Outputs,Targets)
Errors = Targets - Outputs;
MSE = mean(Errors.^2);
RMSE = sqrt(MSE);
NRMSE = RMSE/mean(Targets);
ErrorMean = mean(Errors);
ErrorStd = std(Errors);
rankCorre = RankCorre(Targets,Outputs);

if strcmpi(firstTitle,'tr')
    DisplName = 'OutputGraphEvaluation_TrainData';

```

```

        Disp2Name = 'ErrorEvaluation_TrainData';
        Disp3Name = 'ErrorHistogram_TrainData';
elseif strcmpi(firstTitle,'ts')
    Disp1Name = 'OutputGraphEvaluation_TestData';
    Disp2Name = 'ErrorEvaluation_TestData';
    Disp3Name = 'ErrorHistogram_TestData';
elseif strcmpi(firstTitle,'all')
    Disp1Name = 'OutputGraphEvaluation_ALLData';
    Disp2Name = 'ErrorEvaluation_ALLData';
    Disp3Name = 'ErrorHistogram_AllData';
end

figure('Name',Disp1Name,'NumberTitle','off');
plot(1:length(Targets),Targets,...
    1:length(Outputs),Outputs);grid minor
legend('Targets','Outputs','Location','best');
title(['Rank Correlation = ' num2str(rankCorre)]);

figure('Name',Disp2Name,'NumberTitle','off');
plot(Errors);grid minor
title(['MSE = ' num2str(MSE) ', RMSE = ' num2str(RMSE)...
    ' NRMSE = ' num2str(NRMSE)]);
xlabel(['Error Per Sample']);

figure('Name',Disp3Name,'NumberTitle','off');
histogram(Errors);grid minor

title(['Error Mean = ' num2str(ErrorMean) ', Error Std = '
num2str(ErrorStd)]);
xlabel(['Error Histogram']);

if strcmpi(firstTitle,'tr')
    data.Err.MSETr = MSE;
    data.Err.STDTr = ErrorStd;
    data.Err.NRMSETr = NRMSE;
    data.Err.rankCorreTr = rankCorre;
elseif strcmpi(firstTitle,'ts')
    data.Err.MSETs = MSE;

```

```

        data.Err.STDTs = ErrorStd;
        data.Err.NRMSETs = NRMSE;
        data.Err.rankCorreTs = rankCorre;
    elseif strcmpi(firstTitle,'all')
        data.Err.MSEAll = MSE;
        data.Err.STDAll = ErrorStd;
        data.Err.NRMSEAll = NRMSE;
        data.Err.rankCorreAll = rankCorre;
    end
end
function [r]=RankCorre(x,y)
x=x';
y=y';
% Find the data length
N = length(x);
% Get the ranks of x
R = crank(x)';
for i=1:size(y,2)
    % Get the ranks of y
    S = crank(y(:,i))';
    % Calculate the correlation coefficient
    r(i) = 1-6*sum((R-S).^2)/N/(N^2-1); %#ok
end
end
function r=crank(x)
u = unique(x);
[~,z1] = sort(x);
[~,z2] = sort(z1);
r = (1:length(x))';
r=r(z2);
for i=1:length(u)
    s=find(u(i)==x);
    r(s,1) = mean(r(s));
end
end
function data = plotReg(data,Title,Targets,Outputs)

    if strcmpi(Title,'tr')

```

```

        DispName = 'RegressionGraphEvaluation_TrainData';
elseif strcmpi(Title,'ts')
        DispName = 'RegressionGraphEvaluation_TestData';
elseif strcmpi(Title,'all')
        DispName = 'RegressionGraphEvaluation_ALLData';
end

figure('Name',DispName,'NumberTitle','off');
x = Targets';
y = Outputs';
format long
b1 = x\y;
yCalc1 = b1*x;
scatter(x,y,'MarkerEdgeColor',[0 0.4470
0.7410],'LineWidth',.7);
hold('on');
plot(x,yCalc1,'Color',[0.8500 0.3250 0.0980]);
xlabel('Prediction');
ylabel('Target');
grid minor
% xgrid = 'on';
% disp.YGrid = 'on';
X = [ones(length(x),1) x];
b = X\y;
yCalc2 = X*b;
plot(x,yCalc2,'-
.', 'MarkerSize',4, "LineWidth",.1, 'Color',[0.9290 0.6940 0.1250])
legend('Data','Fit','Y=T','Location','best');
%
Rsquared = 1 - sum((y - yCalc1).^2)/sum((y - mean(y)).^2);

if strcmpi(Title,'tr')
        data.Err.RSqur_Tr = Rsquared;
        title(['Train Data, R^2 = ' num2str(Rsquared)]);
elseif strcmpi(Title,'ts')
        data.Err.RSqur_Ts = Rsquared;
        title(['Test Data, R^2 = ' num2str(Rsquared)]);
elseif strcmpi(Title,'all')
        data.Err.RSqur_All = Rsquared;

```

```

        title(['All Data, R^2 = ' num2str(Rsq2)]);
end

```

```

end

```

Tahminleme

```

function [opt,data] = PredictionData(opt,data)
AllData = data.x';
delays = opt.Delays;
PD = [];
if strcmpi(opt.learningMethod, 'LSTM')
    for i=1:opt.PredictionHorizone
        %       uiprogresdgl(app.mainWindow, 'Value',
(i/app.PredictHorizon.Value), 'ShowPercentage', 'on', 'Message', 'Data
Prediction in progress. Please wait...');
        Data = TSDataPreparation(opt,[AllData PD]);
        predictedSample =
predict(data.BiLSTM.Net,Data.x, 'MiniBatchSize',opt.miniBatchSize);
        PD = predictedSample(end-min(delays)+1:end)';
        AllData = [AllData PD];
    end
elseif strcmpi(opt.learningMethod, 'FeedForward')
    for i=1:opt.PredictionHorizone
        %       uiprogresdgl(app.mainWindow, 'Value',
(i/app.PredictHorizon.Value), 'ShowPercentage', 'on', 'Message', 'Data
Prediction in progress. Please wait...');
        Data = TSDataPreparation(opt,[AllData PD]);
        predictedSample = data.FF.Net(Data.x);
        PD = predictedSample(end-min(delays)+1:end);
        AllData = [AllData PD];
    end
end
AllData =
deNorm(data.seriesdata,AllData,opt.dataPreprocessMode);
PlotTS(opt,data,AllData,delays);
data.Predicted = AllData;
end
function PlotTS(opt,data,AllData,delays)
% make some delays on input filed

```

```

figure('Name', ['PredictionOutput on horizon: '
num2str(opt.PredictionHorizone)], 'NumberTitle', 'off');
plot(1:length(data.x'), ...
      AllData(1:length(data.x')), 'blue', ...
      length(AllData)-
(opt.PredictionHorizone)*min(delays):length(AllData)-
(opt.PredictionHorizone)*min(delays)+1, ...
      AllData(length(AllData)-
(opt.PredictionHorizone)*min(delays):length(AllData)-
(opt.PredictionHorizone)*min(delays)+1), '-r', ...
      length(AllData)-
(opt.PredictionHorizone)*min(delays)+1:length(AllData), ...
      AllData(length(AllData)-
(opt.PredictionHorizone)*min(delays)+1:length(AllData)), '-
or', 'MarkerSize', 3, "LineWidth", 1.1);

grid minor;
grid on;
hold on;
title('predicted data');
legend('Real Data', 'Predicted
Data', 'Location', 'best', 'FontSize', 8, 'TextColor', 'black');
end

function Data = TSDataPreparation(opt,data)
LRmethod      = opt.learningMethod;
% make some delays on input filed
delay         = opt.Delays;
x = data;
T = size(x,2);
MaxDelay = max(delay);
MinDelay = min(delay);
Range = MaxDelay+1:T;
X= [];
for d = delay
    X=[X; x(:,Range-d+MinDelay)];
end
Range = MaxDelay+1:T;
Y = x(:,Range);

if strcmpi(LRmethod, 'LSTM')
    for i=1:size(X,2)

```



```
        Data.x{i,1} = X(:,i);  
        Data.y{i,1} = Y(:,i);  
    end  
elseif strcmpi(LRmethod,'FeedForward')  
    Data.x = X ;  
    Data.y = Y ;  
end
```





ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Hatice GENÇ KAVAS
Uyruğu : T.C.
Doğum Tarihi ve Yeri : 13.07.1985 / Tokat
e-posta : hkavas@cumhuriyet.edu.tr
ORCID ID : <https://orcid.org/0000-0002-6813-529X>

EĞİTİM

Derece	Kurum	Mezuniyet Yılı
Lisans	Sivas Cumhuriyet Üniversitesi / İ.İ.B.F / İşletme	2009
Yüksek Lisans	Sivas Cumhuriyet Üniversitesi / Sosyal Bilimler Enstitüsü / İşletme	2011

İŞ TECRÜBESİ

Tarih	Kurum
2010-2011	Sivas Bilim A.Ş.
2013-2016	Mardin Artuklu Üniversitesi
2016-	Sivas Cumhuriyet Üniversitesi

YABANCI DİL BİLGİSİ

Yabancı Dilin Adı : ÜDS (83,75)