T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

TÜRKİYE VE AB ÜLKELERİNDE ELEKTRİK ÜRETİMİNDEKİ MALZEME AYAK İZLERİNİN TAHMİNİ İÇİN BİR DERİN ÖĞRENME MODELİ

Ömer ALGORABİ

DANIŞMAN
Doç. Dr. Ersin NAMLI

II. DANIŞMAN
Dr. Öğr. Üyesi Ramazan ÜNLÜ

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

İSTANBUL-2021

Bu çalışma, [15.01.2021] tarihinde aşağıdaki jüri tarafından [Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Programı]nda [Yüksek Lisans tezi] olarak kabul edilmiştir.

Tez Jürisi

[Doç. Dr.] [Ersin NAMLI](Danışman)
[İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi]

[Prof. Dr.] [Mehmet Mutlu YENİSEY]
[İstanbul Üniversitesi-Cerrahpaşa]
[Mühendislik Fakültesi]

[Dr. Öğr. Üyesi] [Zeynep DOĞRUÖZ GERGİN]
[İstanbul Kültür Üniversitesi]
[Mühendislik Fakültesi]

20.04.2016 tarihli Resmi Gazete'de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa'nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

Bu tez, İstanbul Üniversitesi-Cerrahpaşa Bilimsel Araştırma Projeleri Yürütücü Sekreterliğinin FYL-2019-33358. numaralı projesi ile desteklenmiştir.

ÖNSÖZ

Tez çalışmam boyunca gerek tez konumun belirlenmesinde gerekse çalışmanın tüm detaylarında bana her türlü desteği sağlayıp, çeşitli yöntemleri öğrenmem konusunda bana yol göstererek çalışmamı yönlendirdiğinden dolayı danışmanım Doç. Dr. Ersin NAMLI'ya,

Tez çalışmam sürecinde benimle paylaştığı bilgi, tecrübe ve yardımlarından dolayı ikinci danışmanım Dr. Öğr. Üyesi Ramazan ÜNLÜ'ye,

Eğitim hayatım boyunca bütün başarılarımın temelinde var olan sevgili aileme her zaman yanımda oldukları ve beni desteklediklerini için,

Tez çalışmam boyunca bana her türlü desteği bulunan sevgili eşim Firdevs Nur ALGORABİ'ye

çok teşekkür ederim.

Ocak 2021 Ömer ALGORABİ

İÇİNDEKİLER

Sayfa No

ÖNSÖZ ..... **iv**
İÇİNDEKİLER ..... **v**
ŞEKİL LİSTESİ ..... **viii**
TABLO LİSTESİ ..... **xii**
SİMGE VE KISALTMA LİSTESİ ..... **xiii**
ÖZET ..... **xvi**
SUMMARY ..... **xvii**
1. GİRİŞ **1**
2. GENEL KISIMLAR **5**
2.1 ELEKTRİK 5
2.1.1 Türkiye'deki Elektrik Sektörü 8
2.1.2 Almanya'daki Elektrik Sektörü 9
2.1.3 İspanya'daki Elektrik Sektörü 11
2.2 DERİN ÖĞRENME 12
2.2.1 Derin Öğrenmede Tarihsel Eğilimler 13
2.2.2 Çok Katmanlı Algılayıcılar 14
2.2.3 Derin Öğrenmede Düzenlileştirme 15
2.2.3.1 Parametre Normu Cezaları 15
2.2.3.2 Veri Kümesi Çeşitleme 15
2.2.3.3 Gürültü Direnci 15
2.2.3.4 Yarı-denetimli Öğrenme 15
2.2.3.5 Çoklu- görev Öğrenme 15
2.2.3.6 Erken Durdurma 16
2.2.3.7 İstifleme 16
2.2.4 Derin Sinir Ağları 16
2.2.5 Evrişimsel Sinir Ağları 17
2.2.5.1 ESA Yapı Taşları 17
2.2.5.2 ESA Modelleri 20
2.2.6 Tekrarlayan Sinir Ağları 24
2.2.6.1 Jordan Elman Ağları 24

2.2.6.2 Doğrusal Olmayan Otoregresif Ekzojen Model *26*
2.2.6.3 Uzun Kısa Süreli Bellek *27*
2.2.7 Özyinelemeli Sinir Ağları 29
2.2.8 Boltzmann Makineleri 30
2.2.9 Sınırlı Boltzmann Makineleri 31
2.2.10 Derin İnanç Ağları 32
2.2.11 Oto Kodlayıcılar 34
2.2.11.1 Gürültü Giderici Oto Kodlayıcılar *36*
2.2.11.2 Seyrek Oto Kodlayıcılar *36*
2.2.11.3 k-Seyrek Oto Kodlayıcı *37*
2.2.11.4 Varyasyonel Oto Kodlayıcı *37*
2.2.11.5 Daralan Oto Kodlayıcı *38*
2.3 ARIMA 38
2.3.1 Modelin Belirlenmesi 40
2.3.2 Parametre Tahminleri 41
2.3.3 Ayırt Edici Kontrol 41
2.3.4 Model Seçim Kriterleri 42
2.3.4.1 Standart Belirlenim Katsayısı - R^2 ..... *42*
2.3.4.2 Akaike Bilgi Kriteri *42*
2.3.4.3 F-İstatistiği *42*
2.3.4.4 Bayes Bilgi Kriteri *43*
2.4 LİTERATÜR TARAMASI 43
3. MALZEME VE YÖNTEM 54
3.1 VERİ SETİNİN TANITILMASI 54
3.2 AKIŞ ŞEMASI 56
3.3 MODELLEME VE YÖNTEM 56
3.3.1 Yazılım Modelleme 56
3.3.2 Performans Ölçütleri 59
3.3.3 Girdi Çıktı Analizi 59
3.3.4 Malzeme Ayak İzi 60
3.4 ELEKTRİK GELİŞİM PLANLARI VE SENARYOLAR 62
3.4.1 Küresel İklim Aksiyonu 64
3.4.2 Sürdürülebilir Geçiş 64
3.4.3 Dağıtılmış Üretim 65

3.4.4 Avrupa Komisyonu Senaryosu 65
4. BULGULAR 66
5. TARTIŞMA VE SONUÇ 104
KAYNAKLAR 106
ÖZGEÇMİŞ 115

ŞEKİL LİSTESİ

Şekil 2.1 Farklı Ülke Gruplarının Elektrik Üretim Değerleri [18] 5

Şekil 2.2 Farklı Enerji Kaynaklarına Göre Elektrik Üretimi [18] 6

Şekil 2.3 Farklı Enerji Kaynaklarının Elektrik Üretimindeki Payları [18]. 6

Şekil 2.4 Yenilenebilir Enerji Kaynaklarının Elektrik Üretimindeki Payları [18]. 7

Şekil 2.5 Farklı Sektörlere Göre Nihai Elektrik Tüketimi [18]. 7

Şekil 2.6 2018 yılına ait Almanya'da farklı enerji kaynaklarına göre elektrik üretim miktarı 10

Şekil 2.7 Almanya'da Yenilenebilir Enerji Kaynaklarının Elektrik Üretimindeki Değerleri 10

Şekil 2.8 Almanya'da Yenilenebilir Olmayan Enerji Kaynaklarının Elektrik Üretimindeki Değerleri 11

Şekil 2.9 İspanya'da Elektrik Üretiminin Enerji Kaynaklarına Göre Dağılımı 12

Şekil 2.10 Sibernetik ve Bağlantıcılık 14

Şekil 2.11 CNN mimarisi 18

Şekil 2.12 Evrişim Katmanı 18

Şekil 2.13 Maksimum ortaklama 19

Şekil 2.14 Tam bağlantı katmanı 19

Şekil 2.15 LeNet-5 Yapısı 20

Şekil 2.16 AlexNet Mimarisi 21

Şekil 2.17 VGG-16 mimarisi [40]. 22

Şekil 2.18 Res-Net mimarisi 23

Şekil 2.19 GoogLeNet mimarisi 23

Şekil 2.20 İki tip sinir ağı. (a) Elman-RNN; (b) Jordan-RNN. 26

Şekil 2.21 LSTM bellek hücresinin yapısı 27

Şekil 2.22 Özyinelemeli Ağlar 30

Şekil 2.23 Sınırlı Boltzmann Makineleri 31
Şekil 2.24 Bir DBN'nin şematik diyagramı 33
Şekil 2.25 Oto Kodlayıcı Şematik Diyagramı 34
Şekil 2.26 Yığın Oto Kodlayıcılar 35
Şekil 2.27 VAE mimarisi 38
Şekil 2.28 Box-Jenkins Yaklaşımı 40
Şekil 3.1 Türkiye Elektrik Üretimi 54
Şekil 3.2 Almanya Elektrik Üretimi 55
Şekil 3.3 İspanya Elektrik Üretimi 55
Şekil 3.4 Akış Şeması 56
Şekil 3.5 Python yazılımı ile modelleme 58
Şekil 3.6 MATLAB-Leontief ters işlemi 61
Şekil 3.7 MATLAB-Malzeme Ayak İzi 62
Şekil 4.1 İleriye Dönük Türkiye Elektrik Üretimi Tahmini 68
Şekil 4.2 İleriye Dönük Almanya Elektrik Üretimi Tahmini 68
Şekil 4.3 İleriye Dönük İspanya Elektrik Üretimi Tahmini 69
Şekil 4.4 Farklı Enerji Kaynaklarına Göre Türkiye Elektrik Üretimi 70
Şekil 4.5 Farklı Enerji Kaynaklarına Göre Almanya Elektrik Üretimi 70
Şekil 4.6 Farklı Enerji Kaynaklarına Göre İspanya Elektrik Üretimi 71
Şekil 4.7 2030 Türkiye'nin Senaryolara Göre Elektrik Üretim Değerleri 72
Şekil 4.8 2030 Almanya'nın Senaryolara Göre Elektrik Üretim Değerleri 72
Şekil 4.9 2030 İspanya'nın Senaryolara Göre Elektrik Üretim Değerleri 73
Şekil 4.10 2040 Türkiye'nin Senaryolara Göre Elektrik Üretim Değerleri 73
Şekil 4.11 2040 Almanya'nın Senaryolara Göre Elektrik Üretim Değerleri 74
Şekil 4.12 2040 İspanya'nın Senaryolara Göre Elektrik Üretim Değerleri 74
Şekil 4.13 2030 Türkiye Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı 75
Şekil 4.14 2030 Türkiye Elektrik Üretiminde Metalik Malzeme Kullanımı 76

Şekil 4.15 2030 Türkiye Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı 76

Şekil 4.16 2030 Türkiye Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı 77

Şekil 4.17 2030 Türkiye Elektrik Üretiminde Plastik Kullanımı 77

Şekil 4.18 2030 Türkiye Elektrik Üretiminde Sıvı Gaz Kullanımı 78

Şekil 4.19 2030 Türkiye Elektrik Üretiminde Ormancılık Ürünleri Kullanımı 78

Şekil 4.20 2030 Türkiye Elektrik Üretiminde Demir-Çelik Kullanımı 79

Şekil 4.21 2030 Almanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı 80

Şekil 4.22 2030 Almanya Elektrik Üretiminde Metalik Malzeme Kullanımı 81

Şekil 4.23 2030 Almanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı 81

Şekil 4.24 2030 Almanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı 82

Şekil 4.25 2030 Almanya Elektrik Üretiminde Plastik Kullanımı 82

Şekil 4.26 2030 Almanya Elektrik Üretiminde Sıvı Gaz Kullanımı 83

Şekil 4.27 2030 Almanya Elektrik Üretiminde Ormancılık Ürünleri Kullanımı 83

Şekil 4.28 2030 Almanya Elektrik Üretiminde Demir-Çelik Kullanımı 84

Şekil 4.29 2030 İspanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı 85

Şekil 4.30 2030 İspanya Elektrik Üretiminde Metalik Malzeme Kullanımı 86

Şekil 4.31 2030 İspanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı. 86

Şekil 4.32 2030 İspanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı 87

Şekil 4.33 2030 İspanya Elektrik Üretiminde Plastik Kullanımı 87

Şekil 4.34 2030 İspanya Elektrik Üretiminde Sıvı Gaz Kullanımı 88

Şekil 4.35 2030 İspanya Elektrik Üretiminde Ormancılık Ürünleri Kullanımı 88

Şekil 4.36 2030 İspanya Elektrik Üretiminde Demir-Çelik Kullanımı 89

Şekil 4.37 2040 Türkiye Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı 90

Şekil 4.38 2040 Türkiye Elektrik Üretiminde Metalik Malzeme Kullanımı 91

Şekil 4.39 2040 Türkiye Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı 91

Şekil 4.40 2040 Türkiye Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı 92

Şekil 4.41 2040 Türkiye Elektrik Üretiminde Plastik Kullanımı 92

Şekil 4.42 2040 Türkiye Elektrik Üretiminde Sıvı Gaz Kullanımı 93

Şekil 4.43 2040 Türkiye Elektrik Üretiminde Ormancılık Ürünleri Kullanımı 93

Şekil 4.44 2040 Türkiye Elektrik Üretiminde Demir-Çelik Kullanımı 94

Şekil 4.45 2040 Almanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı 95

Şekil 4.46 2040 Almanya Elektrik Üretiminde Metalik Malzeme Kullanımı 95

Şekil 4.47 2040 Almanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı 96

Şekil 4.48 2040 Almanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı 96

Şekil 4.49 2040 Almanya Elektrik Üretiminde Plastik Kullanımı 97

Şekil 4.50 2040 Almanya Elektrik Üretiminde Sıvı Gaz Kullanımı 97

Şekil 4.51 2040 Almanya Elektrik Üretiminde Ormancılık Ürünleri Kullanımı 98

Şekil 4.52 2040 Almanya Elektrik Üretiminde Demir-Çelik Kullanımı 98

Şekil 4.53 2040 İspanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı 99

Şekil 4.54 2040 İspanya Elektrik Üretiminde Metalik Malzeme Kullanımı 100

Şekil 4.55 2040 İspanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı 100

Şekil 4.56 2040 İspanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı 101

Şekil 4.57 2040 İspanya Elektrik Üretiminde Plastik Kullanımı 101

Şekil 4.58 2040 İspanya Elektrik Üretiminde Sıvı Gaz Kullanımı 102

Şekil 4.59 2040 İspanya Elektrik Üretiminde Ormancılık Ürünleri Kullanımı 102

Şekil 4.60 2040 İspanya Elektrik Üretiminde Demir-Çelik Kullanımı 103

TABLO LİSTESİ

Tablo 2.1 Türkiye'nin elektrik üretim endüstrisinin gelişimi (1990–2016)..... 8

Tablo 2.2 Elektrik üretimi 9

Tablo 2.3 Elektrik-Literatür Taraması 44

Tablo 2.4 Derin Öğrenme Tahmin Çalışmaları 48

Tablo 2.5 ARIMA Yöntemiyle Tahmin Çalışmaları 51

3.1 Senaryolara Göre Türkiye'nin Elektrik Üretim Değerleri 63

3.2 Senaryolara Göre Almanya'nın Elektrik Üretim Değerleri..... 63

3.3 Senaryolara Göre İspanya'nın Elektrik Üretim Değerleri..... 64

Tablo 4.1 Türkiye'nin elektrik üretim tahmini test veri seti performansı..... 66

Tablo 4.2 Almanya'nın elektrik üretim tahmini test veri seti performansı..... 66

Tablo 4.3 İspanya'nın elektrik üretim tahmini test veri seti performansı..... 67

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
p	: ARIMA Modelinin Otoregresyon Sırası
d	: ARIMA Modelinin Farklılık Derecesi
p	: ARIMA Modelinin Hareketli Ortalama Boyutu
R^2	: Standart Belirleme Katsayısı

Kısaltmalar	Açıklama
LSTM	: Long Short Term Memory (Uzun Kısa Süreli Bellek)
ARIMA	: Autoregressive Integrated Moving Average (Bütünleşik Otoregresif Hareketli Ortalama)
GCA	: Global Climate Action (Küresel İklim Aksiyonu)
ST	: Sustainable Transition (Sürdürülebilir Geçiş)
DG	: Distributed Generation (Dağıtılmış Üretim)
EU	: European Commission (Avrupa Komisyonu)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
RRSE	: Root Relative Squared Error (Kök Göreceli Kare Hata)
RAE	: Relative Absolute Error (Bağıl Mutlak Hata)
RMSE	: Root Mean Square Error (Kök Ortalama Kare Hata)
IEA	: International Energy Agency (Uluslararası Enerji Ajansı)
OECD	: Organisation for Economic Co-operation and Development (İktisadi İşbirliği ve Gelişme Teşkilatı)
TWh	: Terawatt hour (Terawatt saat)
GSYİH	: Gayri Safi Yurt İçi Hasıla
SARIMA	: Seasonal Autoregressive Integrated Moving Average (Mevsimsel Otoregresif Hareketli Ortalama)
SVR	: Support Vector Regression (Destek Vektör Regresyonu)
YSA, ANN	: Yapay Sinir Ağları, Artificial Neural Networks
DBN	: Deep Belief Network (Derin İnanç Ağları)
MRIO	: Multi-Regional Input Output (Çok Bölgeli Girdi Çıktı)
entso-e	: European Network of Transmission System Operators for Electricity (Avrupa Elektrik İletim Sistemi İşleticileri Birliği)
GWh	: Gigawatt hour (Gigawatt saat)

DÖ, DL : Derin Öğrenme, Deep Learning

MLP : Multilayer Perceptron (Çok Katmanlı Algılayıcılar)

GPU : Graphics Processing Unit (Grafik İşlemci Birimi)

DNN : Deep Neural Network (Derin Sinir Ağları)

ESA, CNN : Evrişimsel Sinir Ağları, Convolutional Neural Network

ILSVRC : ImageNet Large Scale Visual Recognition Challenge (Büyük Ölçekli Görsel Tanıma Zorluğu)

LRN : Local Response Normalization (Yerel Yanıt Normalizasyonu)

RNN : Recurrent Neural Networks (Tekrarlayan Sinir Ağları)

NARX : Nonlinear Autoregressive with External Input (Doğrusal Olmayan Otoregresif Ekzojen Model)

RBM : Restricted Boltzmann Machine (Sınırlı Boltzmann Makineleri)

BP : Back-propagation (Geri Yayılım)

AE : Autoencoder (Otomatik Kodlayıcı)

DAE : Denoising Autoencoder (Gürültü Giderici Otomatik Kodlayıcı)

VAE : Variational AutoEncoder (Varyasyonel Otomatik Kodlayıcı)

CAE : Contractive Autoencoder (Daralan Otomatik Kodlayıcı)

ACF : Autocorrelation (Otokorelasyon)

PACF : Partial Autocorrelation (Kısmi Otokorelasyon)

AIC : Akaike Information Criterion (Akaike Bilgi Kriteri)

BIC : Bayes Information Criterion (Bayes Bilgi Kriteri)

RELM : Recurrent Extreme Learning Machine (Tekrarlayan Aşırı Öğrenme Makinesi)

ELM : Extreme Learning Machine (Aşırı Öğrenme Makinesi)

GRNN : Generalized Regression Neural Network (Genelleştirilmiş Regresyon Sinir Ağı)

RSVM : Recurrent Support Vector Machine (Tekrarlayan Destek Vektör Makinesi)

SVM : Support Vector Machine (Destek Vektör Makinesi)

CGSA : Chaotic Gravitational Search Algorithm (Kaotik Yerçekimi Arama Algoritması)

GSA : Gravitational Search Algorithm (Gravitasyonel Arama Algoritması)

COA : Cuckoo Optimization Algorithm (Guguk Kuşu Optimizasyon Algoritması)

MARS : Multivariate Adaptive Regression Splines (Çok Değişkenli Uyarlanabilir Regresyon Eğrileri)

MAE : Mean Absolute Error (Ortalama Mutlak Hata)

EEMD : Ensemble Empirical Mode Decomposition (Topluluk Ampirik Mod Ayırma)

ANFIS : Adaptive Neural Fuzzy Inference Systems (Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi)

PSO : Parçacık Sürü Optimizasyonu

GM : Gri Model

TEİAŞ : Türkiye Elektrik İletim Anonim Şirketi

EXIOBASE : Multi-regional Environmentally Extended Supply and Use / Input Output database (Çok Bölgeli Çevresel Olarak Genişletilmiş Tedarik ve Kullanım / Girdi Çıktı veritabanı)

ÖZET

[YÜKSEK LİSANS TEZİ]

[TÜRKİYE VE AB ÜLKELERİNDE ELEKTRİK ÜRETİMİNDEKİ MALZEME AYAK İZLERİNİN TAHMİNİ İÇİN BİR DERİN ÖĞRENME MODELİ]

[Ömer ALGORABİ]

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

[Endüstri Mühendisliği Anabilim Dalı]

[Danışman : Doç. Dr. Ersin NAMLI

II. Danışman : Dr. Öğr. Üyesi Ramazan ÜNLÜ]

[Dünya çapında artan üretim ve tüketim nedeniyle, enerji talebi hızla artmakta, bu da dünyanın kıt doğal kaynaklarına ek yük getirmektedir. Bu nedenle, artan enerji talebini karşılamak için yeryüzündeki kıt malzemelerin verimli kullanılmasına ihtiyaç duyulmaktadır. Bu tez çalışmasında, Türkiye, Almanya ve İspanyanın çeşitli yenilenebilir ve fosil enerji kaynaklarından elektrik üretimi ile bunların materyal tüketimleri arasındaki ilişkileri araştırmak ve malzeme ayak izi analizi yapmak için çok yönlü bir girdi-çıktı modeli uygulanmıştır. Derin öğrenmeye dayalı yöntemlerden olan Uzun-Kısa Süreli Bellek (Long Short Term Memeory, LSTM) ile Otoregresif Hareketli Ortalamalar (Autoregressive Integrated Moving Average, ARIMA) modelleri, elektrik üretiminin tahmin edilmesi için geliştirilmiştir. Farklı enerji kalkınma politikalarının malzemeye bağımlılığını karşılaştırmak için, olağan durum ile Küresel İklim Aksiyonu (Global Climate Action, GCA), Sürdürülebilir Geçiş (Sustainable Transition, ST), Dağıtılmış Üretim (Distributed Generation, DG) ve Avrupa Komisyonu (European Commission, EU) senaryoları incelenmiştir. Farklı kaynaklardan gelen metalik ve metalik olmayan materyallere dayalı elektrik yatırımı için en iyi senaryonun elde edilmesi amaçlanmıştır. Elde edilen sonuçlara göre LSTM tahmin modeli, performans ölçütlerine göre ARIMA'dan daha üstün bulunmuştur. 2040 Türkiye, Almanya ve İspanya'nın elektrik üretimi için ST senaryosunun uygulanması daha önemli olduğu belirlenmiştir.]

Ocak 2021, [113] sayfa.

Anahtar kelimeler: [Elektrik, Tahmin, ARIMA, LSTM, Malzeme Ayak İzi]

SUMMARY

M.Sc. THESIS

A DEEP LEARNING MODEL FOR MATERIAL FOOTPRINTS OF ELECTRICITY GENERATION PREDICTION IN TURKEY AND EU COUNTRIES

Ömer ALGORABI

Istanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Industrial Engineering

Supervisor : Assoc. Prof. Dr. Ersin NAMLI

Co-Supervisor : Assist. Prof. Dr. Ramazan ÜNLÜ

Due to the increasing production and consumption worldwide, energy demand is increasing rapidly, adding additional burden to the world's scarce natural resources. Therefore, efficient use of scarce materials on earth is needed to meet the increasing energy demand.. In this study, a versatile input-output model is applied to investigate the relationship between Turkye, Germany and Spain's electricity production from various renewable and fossil energy sources with their material consumption and to make a material footprint analysis. Long-Short Term Memory (LSTM) which is based on deep learning methods and Autoregressive Moving Averages (ARMA) models have been developed to estimate electricity production. In order to compare the dependence of different energy development policies on the material, current state with Global Climate Action (GCA), Sustainable Transition (ST), Distributed Production (DG) and European Commission (EU) scenarios were examined. It is aimed to obtain the best scenario for electrical investment based on metallic and non-metallic materials from different sources. According to the results obtained, LSTM estimation model was found to be superior to ARIMA according to performance criteria. For 2040 Turkey, Germany and Spain's electricity production, the implementation of the ST scenario was determined to be more important.

January 2021, 113 pages.

Keywords: Electricity, Forecasting, ARIMA, LSTM, Material Footprint

1. GİRİŞ

Son yıllarda, artan enerji talebi, tüm dünyada kritik bir konu haline gelmiştir. Sanayileşme, kentleşme ve aşırı nüfus, enerji tüketimi üzerinde doğrudan etkide bulunmuştur. Diğer yandan; enerji talebi ve arz açığı dünya çapındaki ülkelerde endişe kaynağı haline gelmiştir. Ekonomik büyüme, artan enerji talebini karşılamak için enerji yatırımlarını önemli ölçüde etkiler. Dünyada enerji yatırımlarını yönetmek için pek çok yöntem vardır. Finansal endişeler, farklı enerji alternatifleri için belirsiz ve esnek olmayan talepler, kapasite gereksinimleri ve devlet politikaları, uygun enerji alternatiflerinin belirlenmesini etkileyen faktörlerden bazılarıdır [1].

Elektrik, insanların yaşamını doğrudan veya dolaylı olarak etkileyen ana enerji kaynaklarından biridir. Sadece insanların yaşamını etkilemekle kalmaz, aynı zamanda ülkelerin kalkınmasında da etkili bir rol oynar. Günümüz dünyasında, elektrik tüketimi ile ekonomik kalkınma arasında yakın bir ilişki vardır [2], [3]. Böylece elektrik tüketiminin ülkelerin kalkınma düzeyini değerlendirdiği ve gelişmiş, gelişmekte olan ile gelişmemiş ülkeler için çok önemli bir enerji kaynağı olduğu söylenebilir.

Uluslararası Enerji Ajansı (International Energy Agency, IEA) 2016 verilerine göre; OECD ülke gruplarındaki toplam elektrik üretimi 10943 TWh'dir. Diğer ülke gruplarının elektrik üretim değerleri: OECD olmayan Avrupa ve Avrasya'nın 1763,5 TWh, Orta Doğu'nun 1080,2 TWh, Çin'in 6225,4 TWh, OECD olmayan Asya'nın (Çin hariç) 2931,9 TWh, OECD olmayan Amerika'nın 1228 TWh ve Afrika'nın 801,1 TWh'dir.

Türkiye gelişmekte olan ülkelerden biri olarak stratejik ve jeopolitik bir öneme sahiptir. Türkiye, coğrafi konumu nedeniyle enerji ticaret merkezi haline gelmek için büyük adımlar atmaktadır. Bununla birlikte, yerel kaynakların kullanılmamasından dolayı mutlak enerji bağımlılığı devam etmektedir. 2017 yılı itibariyle toplam elektrik üretimi miktarının% 36,14'ü ithal doğal gaz ve kömürden gelmektedir. Ayrıca, Türkiye Elektrik İletim Anonim Şirketinin 5 yıllık elektrik üretim projeksiyonuna göre, enerji bağımlılığında ani bir değişiklik görülmesi beklenmemektedir [4].

Optimum miktarda elektrik üretmek amacıyla, gelecekteki elektrik üretim tahminleri son on yılda çok daha önemli hale gelmiştir ve araştırmacılar en iyi tahmin modellerini geliştirmeye

daha fazla önem vermektedir. Literatürde elektrik üretim tahmin problemi ile başa çıkmak için iki temel yaklaşım görülmektedir 1) problemi girdi ve çıktı analizi olarak düşünmek 2) problemi zaman serisi analizi olarak değerlendirmek. Sorunu girdi ve çıktı analizi olarak gören araştırmacılar genellikle elektrik üretim veya tüketim miktarını nüfus, ithalat ve ihracat miktarı, ortalama gayri safi yurtiçi hasıla (GSYİH) gibi bazı girdilerin bir fonksiyonu olarak tahmin etmektedir [5]. Aksine, sorunu zaman serisi analizi olarak görenler, elektrik üretim verilerini zaman içinde alır ve ARIMA, SARIMA veya makine öğrenimi tabanlı yöntemler gibi bazı zaman serisi analiz yöntemlerini uygular [6], [7]. Özellikle günümüzde çok popüler olan derin öğrenme yöntemleri, elektrik üretim veya tüketim tahmini için kullanılmakta ve üstün başarı elde edilmektedir.

Unler çalışmasında, popülasyon, ithalat ve ihracat miktarının bir fonksiyonu olarak belirlenen elektrik üretimini tahmin etmek için Parçacık Sürüsü Optimizasyonu ve Karınca Kolonisi optimizasyonu yöntemleri kullanmıştır [8]. Karınca kolonisi optimizasyon yöntemi elektrik üretiminin yanı sıra tüketimi de tahmin etmek için önerilmiştir [9]. Belirsiz sistemlerden kullanılabilir bilgileri ortaya çıkarabilen gri teorisi ve optimize gri teorisi adı verilen diğer optimizasyon teknikleri, Türkiye'nin yıllık elektrik talebini tahmin etmek için kullanılmıştır [10], [11]. Optimizasyon yöntemlerine ek olarak, yukarıda belirtilen tahmin problemini ortaya çıkarmak için bazı iyi bilinen istatistiksel yaklaşımlar da önerilmişitr. Otoregresif Entegre Hareketli Ortalama (ARIMA) ve mevsimsel ARIMA (SARIMA), Türkiye'nin enerji talebi ve gelecekteki öngörüler için bir temel tahmin modeli oluşturmak için uygulanmıştır[12], [13]. Klasik istatistiksel yöntemlerin yanı sıra, makine öğrenimine dayalı yöntemler literatürde yaygın olarak kullanılmıştır. Destek Vektör Regresyonu (Support Vector Regression, SVR), anahtar girdi elektrik tüketimini nüfus, GSYİH, ithalat-ihracat ve ihracat miktarı olmak üzere dört girdinin bir fonksiyonu olarak tahmin etmek için uygulanmıştır [7]. Yapay Sinir Ağları (YSA), tahmin problemleri için kullanılan bir başka makine öğrenmesi tabanlı yöntemdir. YSA'lar, Türkiye'nin enerji talebini ve tüketimini tahmin etmek için yaygın olarak kullanılmıştır. [14] çalışmasında olduğu gibi YSA, Türkiye'nin elektrik talebini ve üretimini nüfus, kurulu kapasite, brüt üretim, ithalat ve ihracat miktarının bir fonksiyonu olarak tahmin etmek için uygulanmıştır. Ayrıca elektrik üretiminde kullanılan doğal gaz, kömür, linyit gibi ana kaynak miktarını YSA modelinin girdisi olarak kullanmışlardır. Makine öğrenmeye dayalı bir başka yaklaşım da [15] tarafından kullanılan bulanık mantıktır. GDP'yi Türkiye'nin elektrik talebini tahmin etmek için bulanık mantık modelinin girdisi olarak kullanılmıştır. Günümüzde

derin öğrenme yöntemlerinin elektrik üretimi ve tüketiminde sıkça kullanıldığı görülmektedir. Bedi ve Toshniwal (2019) çalışmalarında, uzun vadeli tarihsel bağımlılıkları göz önüne alarak elektrik talebini tahmin etmek için uzun kısa süreli bellek ağı temelli bir çerçeve önermişlerdir. Dedinec vd. (2016) çalışmalarında, elektrik yükü tahmini için çok sayıda kısıtlı Boltzmann makinesinden oluşan bir Derin İnanç Ağları (Deep Belief Network, DBN) kullanmışlardır. Rahman vd. (2018) çalışmalarında, ticari ve konut binalarında bir saatlik dilimdeki elektrik tüketiminin orta ila uzun vadeli elektrik tahminlerini yapmak için tekrarlayan bir sinir ağı modeli sunmuşlardır.

Son yıllarda, kaynak verimliliği ve ayrıştırmayla ilgili konular sürekli olarak dünya çapında politika gündemini artırmaktadır. Bu gelişme, ekonomik büyümenin kaynak kullanımından ayrılması ve bununla ilişkili çevresel etkilerden beklenen olumlu etkiler yoluyla stratejik kaynaklar üzerinde artan rekabet ve çevresel etkenler gibi ekonomik zorluklardan kaynaklanmaktadır [16].

Özellikle günümüzde, İkili ticaretle bağlantılı daha fazla sayıda ülke içindeki ve arasındaki akışları açıkça kapsayan malzeme akışlarının değerlendirilmesi de dahil olmak üzere çevresel uygulamalar için çok bölgeli girdi-çıktı (Multi-Regional Input Output, MRIO) yaklaşımları geliştirilmiştir [16].

Bu çalışmada, Türkiye, Almanya ve İspanya'nın elektrik üretimlerinin tahmini için LSTM ve ARIMA yöntemleri kullanılmıştır. Performans ölçütlerine göre bu iki yöntem karşılaştırılmıştır. Bulunan en iyi yöntem ile ileriye dönük elektrik üretim tahmini yapılmıştır. Avrupa Elektrik İletim Sistemi İşleticileri Birliği (entso-e)'den, 2030 ve 2040 yıllarına ait bazı elektrik üretim senaryoları alınmıştır. Bu senaryolar ile tahmin yöntemiyle elde edilen farklı enerji kaynaklarına göre elektrik üretim değerleri için malzeme ayak izleri hesaplanmıştır. Hesaplanan malzeme ayak izleri metalik ve metalik olmayan malzemeler olarak ayrılmıştır.

Almanya'nın çok gelişmiş bir ülke olması, İspanya'nın Türkiye ile yakın elektrik tüketim değerlerine sahip olması nedeniyle çalışmada bu iki ülke Türkiye ile birlikte ele alınmıştır.

Tez çalışmasının 2. bölümünde, elektrik sektörü, derin öğrenme, ARIMA ile ilgili bilgiler verilmiş ve literatür taraması yapılmıştır. 3. bölümde ise kullanılan veri seti, yöntem ve yazılımlar ile ilgili bilgiler verilmiştir. 4. bölümde, tahmin sonuçlarının karşılaştırılması ve

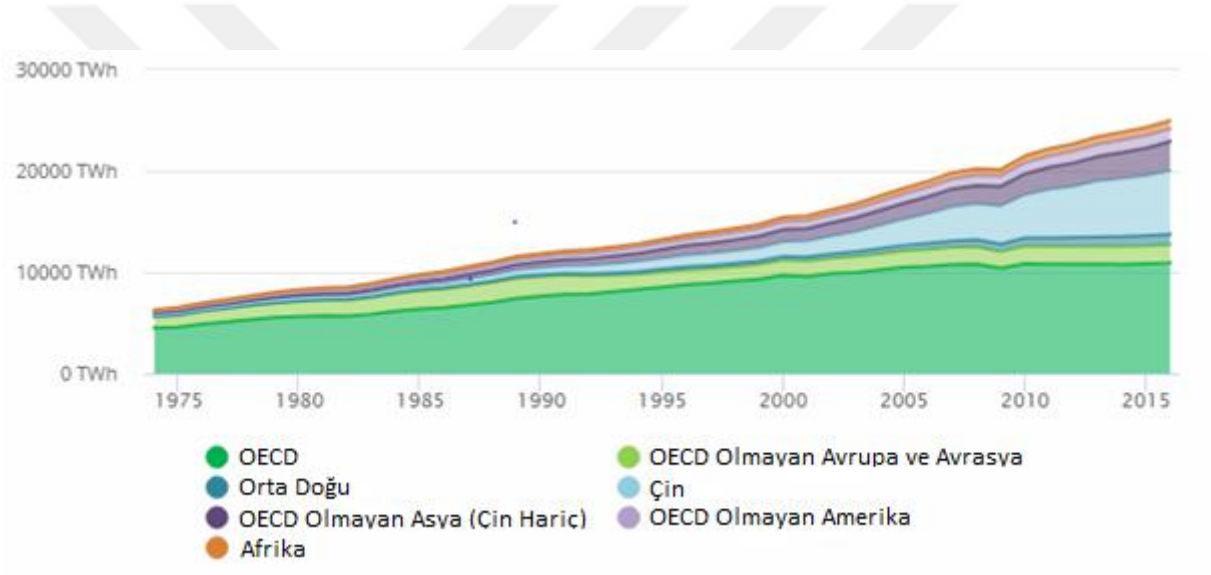
malzeme ayak izlerinin hesaplanması ile elde edilen bulgulara yer verilmiştir. Son olarak, çalışma, bölüm 5'te verilen sonuç ve öneriler kısmıyla tamamlanmıştır.

2. GENEL KISIMLAR

2.1 ELEKTRİK

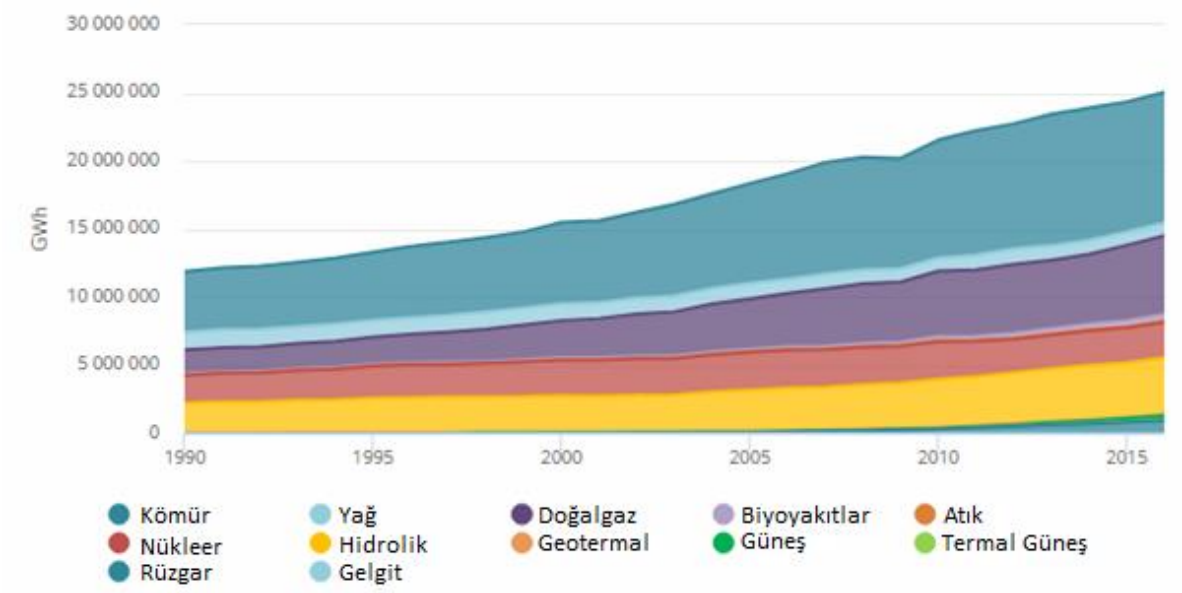
Elektrik enerjisi, üretim yerinden çok uzaklara dağıtım şebekeleri ile kolayca taşınabilen, dağıtımı kontrol altında tutulabilen, temiz bir enerji kaynağıdır [17]. Elektrik, dünyadaki enerji kaynakları arasında yükselen bir güçtür. Elektrik üretimi kaynaklarına olan talep, dünyanın son yıllarda sahip olduğu ekonomik büyüme nedeniyle artmıştır [1].

Uluslararası Enerji Ajansı (IEA) verilerine göre; 1974-2016 yılları arasındaki farklı ülke gruplarının elektrik üretim değerleri Şekil 2.1'de gösterilmiştir.



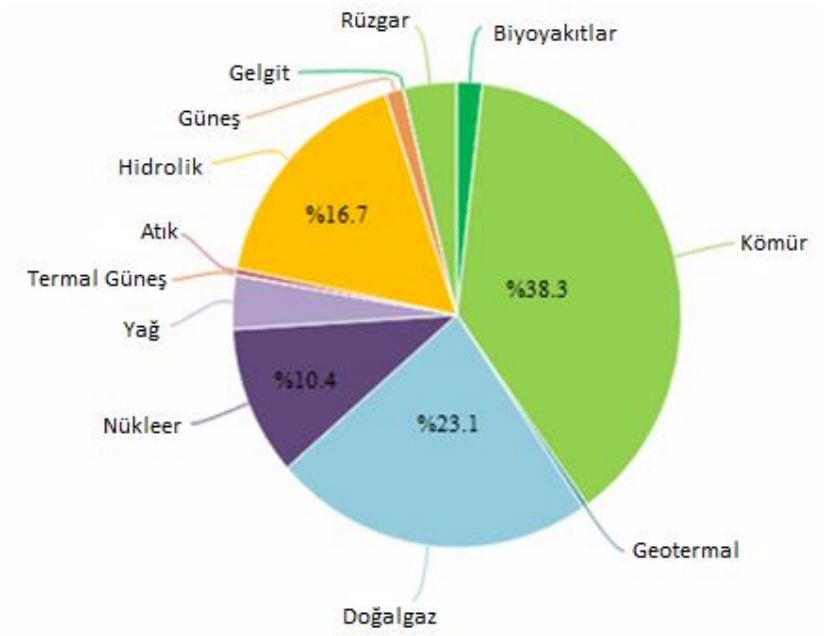
Şekil 2.1 Farklı Ülke Gruplarının Elektrik Üretim Değerleri [18]

Dünya'daki elektrik üretiminin enerji kaynaklarına göre dağılımı ise Şekil 2.2'de gösterilmektedir.



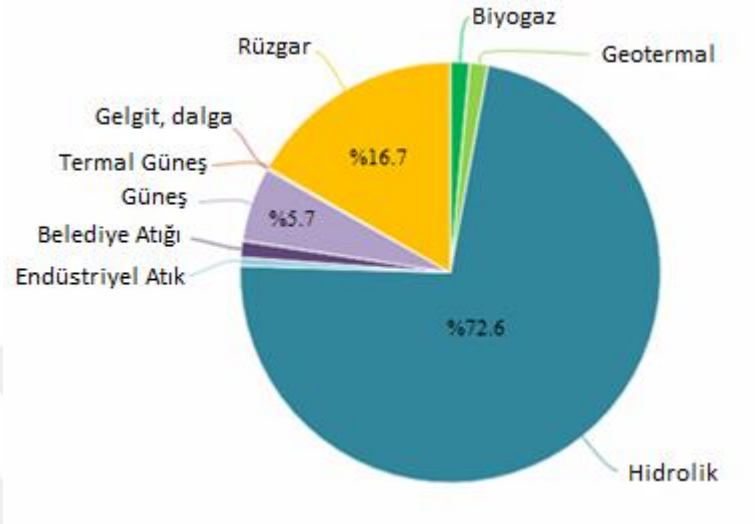
Şekil 2.2 Farklı Enerji Kaynaklarına Göre Elektrik Üretimi [18]

2016 yılına ait değerlere göre, Dünya'daki elektrik üretiminin büyük bir kısmını kömür kaynağı üstlenmektedir. Kömür yoluyla üretilen elektrik miktarı 9.594.341 GWh'dir. Kömürden sonra elektrik üretimine en fazla katkı sağlayan kaynak doğalgazdır. 2016 yılına ait değerlere göre, farklı enerji kaynaklarının elektrik üretimindeki payları Şekil 2.3'te gösterilmiştir.



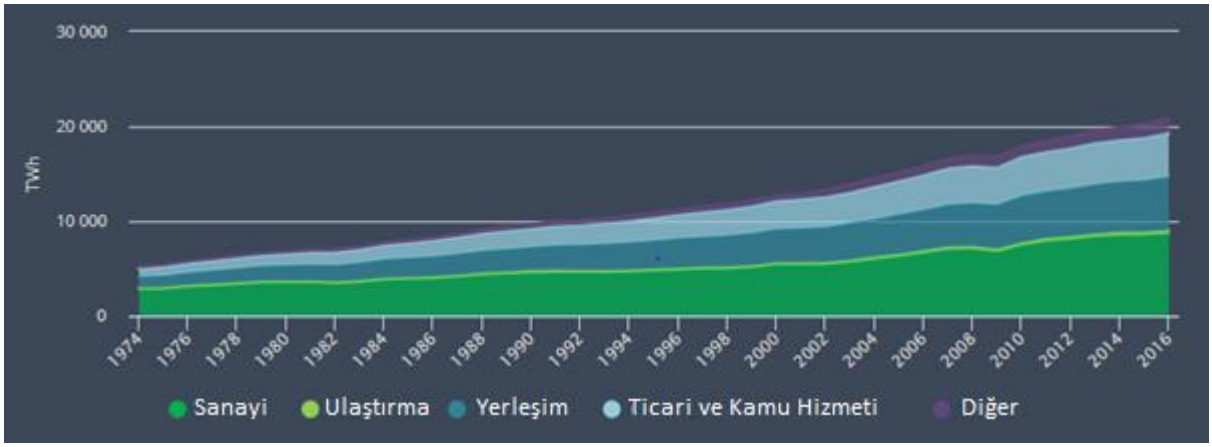
Şekil 2.3 Farklı Enerji Kaynaklarının Elektrik Üretimindeki Payları [18].

Şekil 2.4'te ise 2016 yılına ait farklı yenilenebilir enerji kaynaklarının Dünya'daki elektrik üretimindeki payları gösterilmiştir. Elektrik üretiminde hidrolik ve rüzgar en çok kullanılan yenilenebilir enerji kaynaklarıdır.



Şekil 2.4 Yenilenebilir Enerji Kaynaklarının Elektrik Üretimindeki Payları [18].

2016 yılında dünya toplam nihai elektrik tüketimi 20 863 TWh'ye ulaşmıştır [18]. Şekil 2.5'te 1974-2016 yılları arasındaki farklı sektörlere göre nihai elektrik tüketim değerleri gösterilmiştir.



Şekil 2.5 Farklı Sektörlere Göre Nihai Elektrik Tüketimi [18].

2016 yılındaki verilere göre; sanayide 8684 TWh, ulaştırmada 357 TWh, yerleşim yerlerinde 5681 TWh ve ticari ile kamu hizmetinde 4600 TWh elektrik tüketilmiştir.

2.1.1 Türkiye'deki Elektrik Sektörü

Türkiye elektrik üretimi sektörü, güçlü ekonomik büyüme, hızlı nüfus artışı ve kentleşme ile kişi başına düşen elektrik talebinin artmasından dolayı ve elektrifikasyonun tüm ülkeye yayılması nedeniyle hızla büyüyen bir sektördür [19]. Türkiye, ekonomik güçlenme üzerinde büyük etkisi olan kişi başına düşen elektrik talebi büyümesi bakımından Ekonomik İşbirliği ve Kalkınma Örgütü ülkeleri arasında şampiyondur [17]. Ülkenin toplam elektrik üretimi 1980'de 23.275 TWh'den 2017'de 290.546 TWh'e ve tüm yurt içi ürün aynı dönemde 67.4646 milyar dolardan 719.965 milyar dolara yükselmiştir. Geçtiğimiz çeyrek yüzyıl boyunca, elektrik üretiminin ve talebin yıllık ortalama büyüme oranları %6,5 civarındayken, üretim kapasitesi %6,1 oranında artmıştır. Aynı dönemde kişi başına düşen elektrik talebi yıllık %6,1 oranında artmıştır (Tablo 2.1) [18].

Tablo 2.1 Türkiye'nin elektrik üretim endüstrisinin gelişimi (1990–2016)

	1990	2000	2010	2016	Ortalama yıllık büyüme oranı
Nüfus (bin)	56473	67845	73723	79814	1,5
GSYİH (mevcut USD, milyon)	150676	272980	771902	863772	4,2
Kurulu güç kapasitesi (MW)	16318	27264	49524	78497	6,1
Brüt elektrik üretimi (GWh)	57543	124922	211207	274407	6,5
Brüt elektrik talebi (GWh)	56812	128276	210434	279286	6,5
Kişi başına düşen elektrik talebi (KWh)	1006	1891	2854	3499	6,1

Tablo 2.2'de gösterildiği gibi, Türkiye'nin elektriği, temel olarak doğal gaz, kömür ve petrol de dahil olmak üzere fosil yakıtlardan üretilmekte olup, bu miktar 2018 yılında toplam üretimin yaklaşık %70'unu oluşturmaktadır. Elektrik üretimindeki ana yakıt kömürdür (% 37). Doğalgaz %30 ile ikinci kaynak olarak takip etmektedir. Nükleer enerji eksikliğinden dolayı, elektrik üretiminde yenilenebilir kaynaklar üçüncü sıradadır ve bu tür kaynakların enerji üretimindeki payları şöyledir: hidrolik %20, rüzgar %6,75, jeotermal 2,36, atık ile biyo yakıtlar %1 ve güneş %0,02'dir. Kurulu güç kaynakları, %31,9 ile hidroelektrik santralleri, %25,3 doğal gazla çalışan santraller, %21,4 ile kömürle çalışan santraller ve %7,8 rüzgardan oluşur [4].

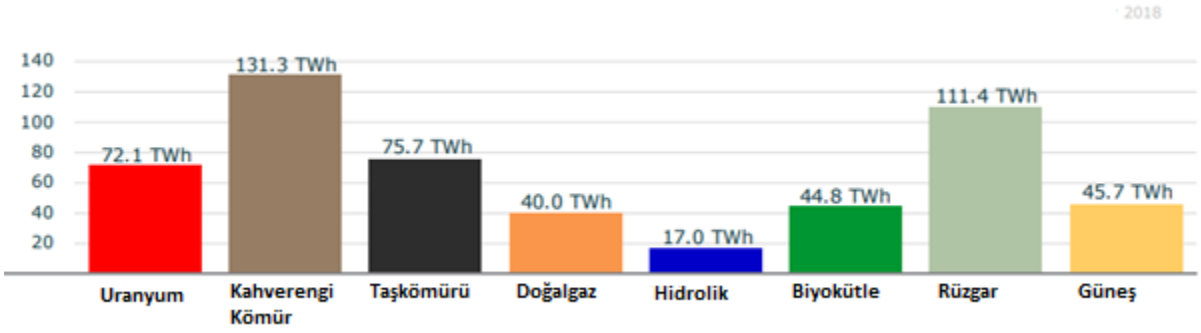
Tablo 2.2 Elektrik üretimi

	Elektrik Üretimi	
Kaynak	GWh	%
Doğalgaz	90087	30,77
LNG	0,95	0,00
Linyit	44838	15,31
Taşkömür	2504	0,86
Asfaltit	2327	0,80
İthal Kömür	62149	21,23
Fuel Oil	1429	0,49
Atık Isı	693	0,24
Biyokütle	2308	0,79
Jeotermal	6905	2,36
Akarsu	18831	6,43
Barajlı	40887	13,97
Güneş	57	0,02
Rüzgar	19757	6,75
Toplam Üretim	292779	100,0

2.1.2 Almanya’daki Elektrik Sektörü

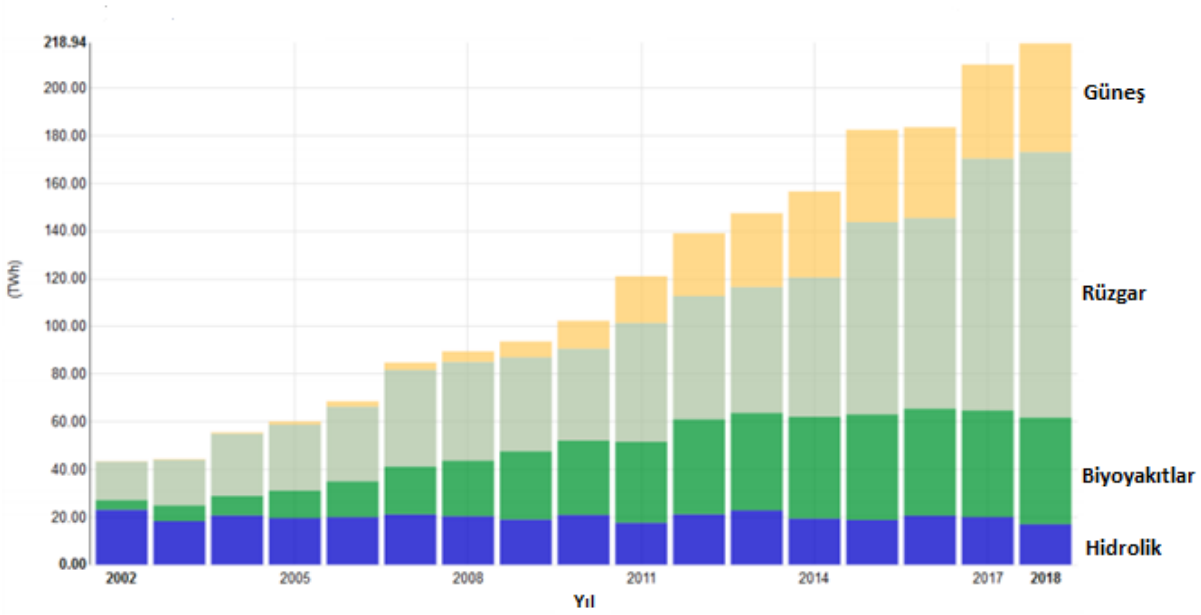
Almanya'nın yurt içi elektrik piyasası 1998'de serbestleşti. Şu anda 800'den fazla bireysel sağlayıcı olmasına rağmen, ülke elektriğinin çoğunluğu hala dört büyük enerji şirketi tarafından üretilmektedir: E.ON, RWE, Vattenfall ve EnBW [20].

Almanya'nın elektrik şebekesi, Kıta Avrupası’nın Senkron şebekesinin bir parçasıdır. 2018'de Almanya, %40'ı yenilenebilir enerji kaynaklarından, % 38'ini kömürden, % 8'inin doğal gazdan olduğu 540 TWh elektrik üretti. Şekil 2.6’da 2018 yılına ait farklı enerji kaynaklarına göre elektrik üretim miktarları gösterilmiştir [21].



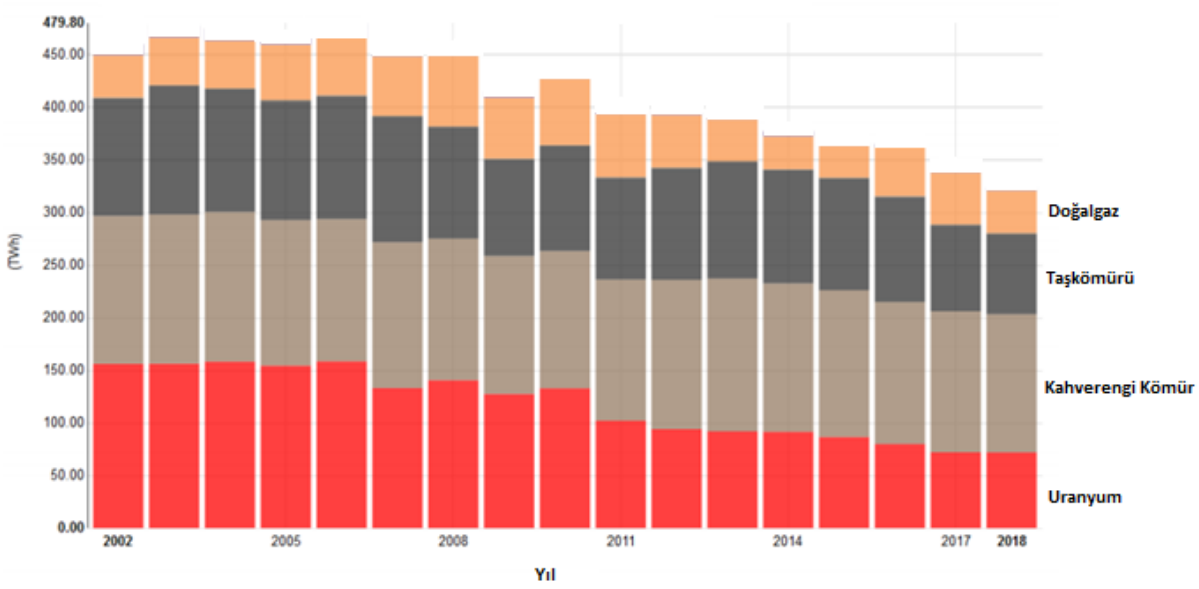
Şekil 2.6 2018 yılına ait Almanya'da farklı enerji kaynaklarına göre elektrik üretim miktarı

Yıllara göre Almanya'daki yenilenebilir enerji kaynaklarının elektrik üretimindeki değerleri Şekil 2.7'de gösterilmiştir [21].



Şekil 2.7 Almanya'da Yenilenebilir Enerji Kaynaklarının Elektrik Üretimindeki Değerleri

Yıllara göre Almanya'daki yenilenebilir olmayan enerji kaynaklarının elektrik üretimindeki değerleri Şekil 2.8'de gösterilmiştir [21].



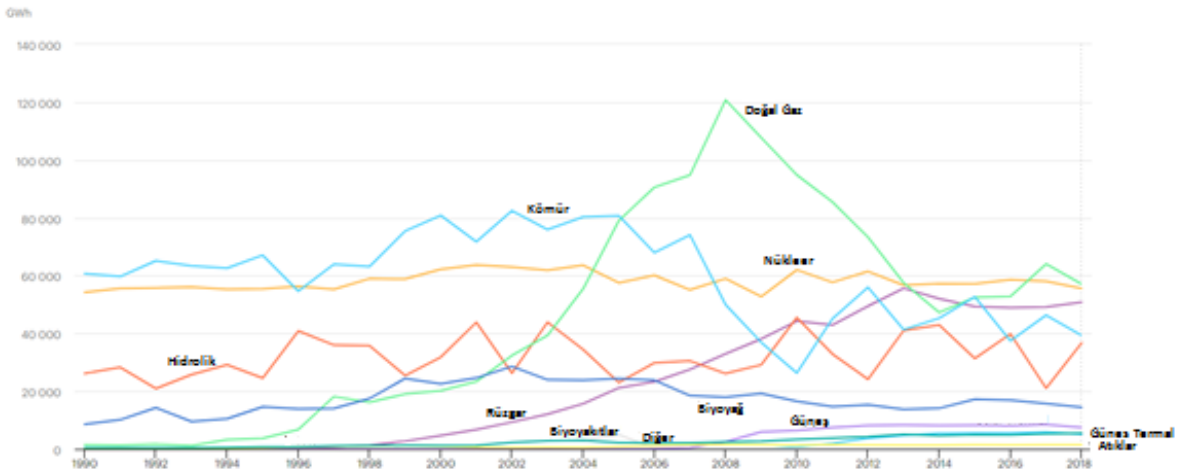
Şekil 2.8 Almanya'da Yenilenebilir Olmayan Enerji Kaynaklarının Elektrik Üretimindeki Değerleri

2.1.3 İspanya'daki Elektrik Sektörü

İspanya'da elektrik talebi, ekonomik kriz nedeniyle önceki yıllarda kaydedilen düşüşün ardından 2015 yılında artan bir eğilim göstermiştir. Özellikle, 2018 yılında talep bir önceki yıla göre %0,4 artışla 268.808 GWh'ye ulaşmıştır. Öte yandan, üretim 2017 yılına göre %0,5'lik bir düşüş kaydetti, bu da üretimi sırasıyla %17,2 ve %18,9 azalan kömür kırmızısı ve birleşik çevrim üretim istasyonlarını etkiledi. Uluslararası borsalar itibarıyla ithalat, ihracatı 11.102 GWh aşmıştır [22].

2018 yılında, İspanya'daki tüm üretim tesislerindeki kurulu güç kapasitesi, üst üste üçüncü yıl düştü ve yılı, Tarragona Kombine Çevrim Elektrik Santralinin kesin kapanması nedeniyle, bir önceki yıla göre %0,1 daha düşük olan 104,053 MW ile kapatmıştır. Rüzgar enerjisi ile üretim %1,5 artmıştır. Elektrik üretim teknolojilerinin geri kalanı minimal veya önemsiz farklılıklar göstermiştir [22].

İspanya'daki elektrik üretiminin enerji kaynakları ve yıllara göre dağılımı Şekil 2.9'da gösterilmiştir [18]. Son yıllarda, doğal gaz ve kömür ile üretilen elektrik üretiminin azaldığı, rüzgar enerjisi ile ise elektrik üretiminin arttığı gözlemlenmektedir.



Şekil 2.9 İspanya'da Elektrik Üretiminin Enerji Kaynaklarına Göre Dağılımı

2.2 DERİN ÖĞRENME

Son on yılda, sinir ağları alanında derin öğrenme (DÖ) olarak bilinen makine öğrenimine yol açan bazı yenilikler yaşanmıştır. Özellikle, sinir ağlarının geleneksel sorunlarından biri, her zaman büyük modelleri eğitmenin büyük hesaplama maliyeti olmuştur. İlgili gelişmelerin takip ettiği gibi, araştırmacılar derinliği sadece gizli bir katmanla sınırlı kalmayan karmaşık sinir ağlarını (geleneksel Çok Katmanlı Algılayıcılar'da (Multilayer Perceptron, MLP) olduğu gibi) verimli bir şekilde eğitmeye başlamışlardır. Bu yeni yapılar sistematik olarak daha iyi sonuçlar ve genelleme kabiliyetleri gösterdiğinden, elde edilen iyileştirmelerdeki derinliğin önemini vurgulamak için yapı, derin öğrenme olarak yeniden adlandırıldı [23].

Derin öğrenme, hiyerarşik mimarileri kullanarak verideki üst düzey soyutlamaları öğrenmeye çalışan makine öğreniminin bir alt alanıdır. Ortaya çıkan bir yaklaşımdır ve semantik ayrıştırma, doğal dil işleme, bilgisayar görüşü ve daha birçokları gibi geleneksel yapay zeka alanlarında yaygın olarak uygulanmaktadır. Günümüzde derin öğrenmenin artması için temel olarak üç önemli nedeni vardır: çarpıcı şekilde artan çip işleme yetenekleri (örneğin GPU birimleri), bilgisayar donanımının maliyetini önemli ölçüde düşürmesi ve makine öğrenmesi algoritmalarındaki kayda değer ilerlemeler [24].

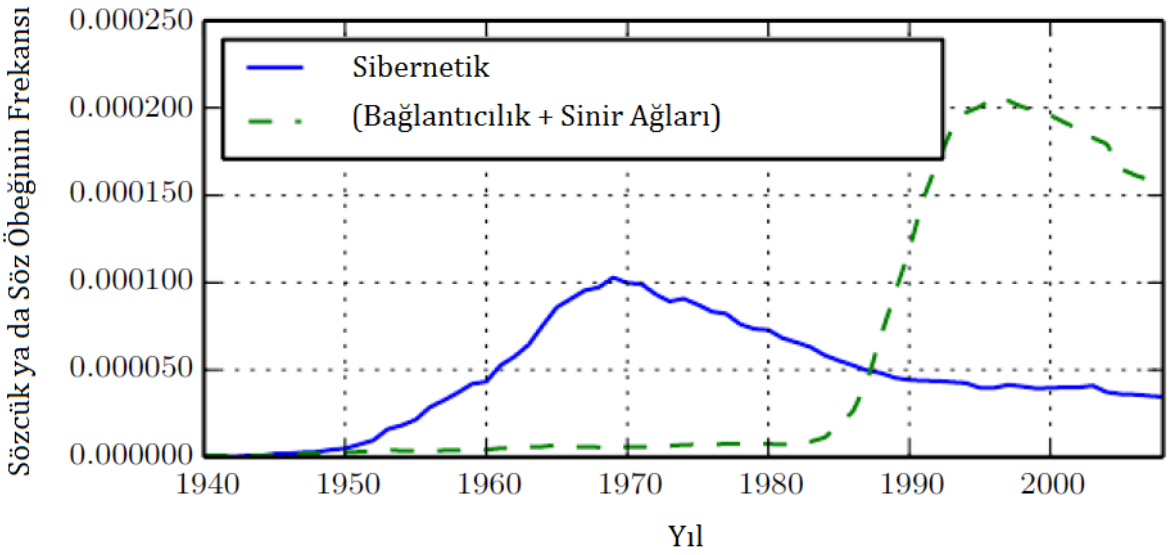
2.2.1 Derin Öğrenmede Tarihsel Eğilimler

Derin öğrenmeyi açıklamak için ilk olarak tarihsel eğilimleri dikkate almak gerekir. Derin öğrenmedeki önemli eğilimler [25]:

- Derin öğrenme uzun ve geniş bir tarihe sahiptir, ancak farklı felsefi bakış açılarını yansıtan birçok isimle geçmiş ve popülaritesi artmış azalmıştır.
- Mevcut eğitim verilerinin miktarı arttıkça derin öğrenme daha faydalı hale gelmiştir.
- Derin öğrenme modelleri, derin öğrenme için bilgisayar altyapısı (donanım ve yazılım) geliştikçe zamanla büyümüştür.
- Derin öğrenme, zaman içinde daha karmaşık uygulamaları daha yüksek doğrulukla çözebilmeye başlamıştır.

Derin öğrenme 1940'lı yıllara dayanır. Derin öğrenme sadece yeni gibi görünmektedir, çünkü mevcut popülaritesinden önce birkaç yıl boyunca nispeten popüler olmayışı ve birçok farklı isimden geçip, son zamanlarda "derin öğrenme" olarak adlandırıldığı içindir. Alan, farklı araştırmacıların ve farklı bakış açılarının etkisini yansıtan birçok kez yeniden adlandırılmıştır. [25].

Açık bir şekilde değerlendirildiğinde, derin öğrenmenin üç fazdan oluşan bir ilerleme dönemi vardır. Bunlar sibernetik olarak bilinen ve 1940-1960 arasındaki yılları kapsayan, bağlantıcılık adıyla bilinen ve 1980-1990 arasındaki yılları kapsayan ve son olarak da 2006'da beliren ve derin öğrenme olarak adlandırılan dönemlerdir. Bu dönemler Şekil 2.10'da gösterilmiştir [25].



Şekil 2.10 Sibernetik ve Bağlantıcılık

2.2.2 Çok Katmanlı Algılayıcılar

Çok Katmanlı Algılayıcılar (MLP), verilen girdi verilerini beklenen çıktı verilerle eşleyen bir sinir ağı türüdür. MLP, yönlendirilmiş bir grafikte birden çok düğüm katmanından oluşur; her katman bir sonrakine tamamen bağlanır [26].

Genel olarak, [$x(n),t(n)$] n'inci eğitim örneği olduğu varsayalım, $x(n)= [x_1(n), x_2(n),\dots x_d(n)]^T$ $(n = 1,2\dots N)$ d-boyutundaki girdi örneği iken, $t(n)= [t_1(n), t_2(n),\dots t_c(n)]^T$ c-boyutundaki çıktıdır. MLP'nin eğitimi, hedef $t_k(n)$ ve gerçek çıktı $y_k(n)$ arasındaki ortalama hata değeri (MSE) olan E toplamını en aza indirgeyen optimizasyon problemidir. Denklem 2.1'deki gibi ifade edilir.

$$E = \sum_{n=1}^{N} \sum_{k=1}^{C} (y_k(n) - t_k(n))^2 \tag{2.1}$$

g gizli katmandaki aktivasyon fonksiyonu, k hedefin boyutu, h çıktı katmanındaki aktivasyon fonksiyonu, A girdiyi gizli katmanlara bağlayan ağırlıklar ve B çıktıyı gizli katmanlara bağlayan ağırlıklar olsun,

$$y_l(n) = h(\sum_{j=0}^{M} B_k z_j(n)) \tag{2.2}$$

$z_j(n)$ gizli katmandaki j'inci nöronun çıktısı ve $j = 1, 2, \ldots, M$, Denklem 2.3'teki gibi temsil edilir:

$$z_j(n) = g(\sum_{i=0}^{d} A_{ji} x_i(n)) \tag{2.3}$$

2.2.3 Derin Öğrenmede Düzenlileştirme

2.2.3.1 Parametre Normu Cezaları

Çoğu düzenlileştirme yaklaşımı, sinir ağları, doğrusal bağlanım ve lojistik bağlanım gibi modellerin kapasitesini sınırlandırmaya dayanır. Bunu yapmak için J amaç fonksiyonuna parametre norm cezası, $\Omega(\theta)$ eklenir,

$$\hat{J}(\theta; X, y) = J(\theta; X, y) + \alpha\Omega(\theta) \tag{2.4}$$

burada $\alpha \epsilon [0, \infty)$ norm ceza terimi Ω'nın standart amaç fonksiyonu J'ye göre katkısının ağırlığını belirleyen bir hiperparametredir.

2.2.3.2 Veri Kümesi Çeşitleme

Bir makine öğrenmesi modelinin daha iyi genelleştirme yapabilmesini sağlamanın en iyi yolu, daha fazla veri kullanarak eğitmektir. Elbette pratikte sahip olduğumuz veri miktarı sınırlıdır. Bu sorunu aşmanın bir yolu, sahte veriler oluşturmak ve bu verileri eğitim kümesine eklemektir.

2.2.3.3 Gürültü Direnci

Modelleri düzenlileştirmek maksadıyla uygulanabilecek bir diğer teknik ağırlıklara gürültü eklemektir. Özellikle yinelemeli sinir ağlarında bu teknik uygulanmaktadır.

2.2.3.4 Yarı-denetimli Öğrenme

Yarı-denetimli öğrenme yaklaşımında, etiketsiz örnekler $P(x)$ dağılımından, etiketli örnekler ise $P(x,y)$ dağılımından kullanılır veya $P(y|x)$ kestirimi ya da x'ten y öngörüsü yapılır.

2.2.3.5 Çoklu- görev Öğrenme

Çoklu-görev öğrenme, birçok görevde karşımıza çıkan örnekleri biriktirerek genelleştirme konusunda iyileştirmeler yapmanın bir yoludur. Ek eğitim örneklerinin, modelin parametreleri

üzerinde daha iyi genelleştiren değerlere doğru baskı oluşturması gibi modelin bir kısmı görevler arasında paylaşıldığında, modelin bu kısmı daha iyi değerlere kısıtlanmaktadır, ki bu da genellikle daha iyi genelleme sağlar.

2.2.3.6 Erken Durdurma

Sağlama kümesindeki hatanın en düşük olduğu andaki parametrelere dönülmesi, sağlama hatası çok daha iyi olan modeller elde edilebilir. Sağlama kümesi hatasındaki her iyileşmede model parametrelerinin bir kopyası alınır. Eğitim algoritması bittiğinde, en son parametreleri geri döndürmektense, kaydedilen parametreler geri döndürülür. Bu strateji, erken durdurma olarak bilinir.

2.2.3.7 İstifleme

İstifleme, çeşitli modelleri birleştirerek genelleştirme hatasını düşürme tekniğidir. Buradaki fikir, birçok modeli ayrı ayrı eğitip, bu modellerin test örnekleri için bir oy vermesini sağlamaktır. İstifleme, makine öğrenmesinde model ortalama olarak adlandırılan genel bir stratejinin örneğidir. Bu stratejiyi kullanan yöntemler topluluk yöntemleri olarak adlandırılır.

2.2.4 Derin Sinir Ağları

Derin Sinir Ağları (Deep Neural Network, DNN), girdi ve çıktı arasında birden fazla gizli birim katmanına sahip, ileri beslemeli, yapay bir sinir ağıdır [27]. DNN, ister doğrusal bir ilişki ister doğrusal olmayan bir ilişki olsun, girdiyi çıktıya dönüştürmek için doğru matematiksel manipülasyonu bulur. Şebeke, her çıktının olasılığını hesaplayarak katmanlar arasında kaynaşır. Örneğin, köpek ırklarını tanımak için görüntüleri kullanarak eğitilen sinir ağ modeli, verilen görüntü ile birlikte köpeğin belirli bir cins olma olasılığını hesaplayacaktır. Kullanıcı sonuçları inceleyebilir ve ağın hangi olasılıkları göstermesi gerektiğini (belirli bir eşiğin üzerinde vb.) seçebilir ve önerilen etiketi döndürebilir. Her matematiksel manipülasyon bir katman olarak kabul edilir ve karmaşık DNN'nin birçok katmanı vardır, bu nedenle "derin" ağlar olarak adlandırılır [28].

DNN bir sanal nöron haritası oluşturur ve aralarındaki bağlantılara rasgele sayısal değerler veya "ağırlıklar" atar. Ağırlıklar ve girdiler çarpılır ve 0 ile 1 arasında bir çıktı döndürür. Ağ belirli bir modeli doğru şekilde tanımazsa, bir algoritma ağırlıkları ayarlayacaktır.

DNN'ler, daha sığ sinir ağlarına göre daha karmaşık ve soyut olan üst düzey özellikleri öğrenebilirler. Bu noktayı gösteren bir örnek, görsel verileri işlemek için DNN'leri kullanmaktır [29].

2.2.5 Evrişimsel Sinir Ağları

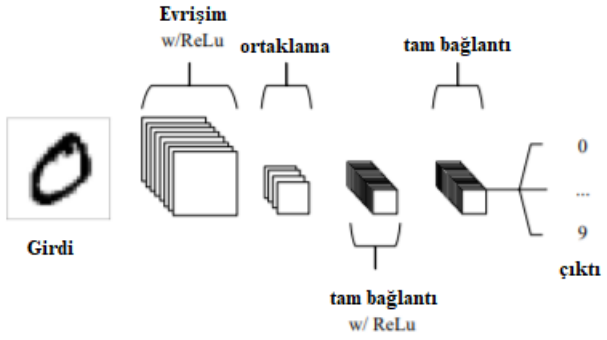
Evrişimsel Sinir Ağları (Convolutional Neural Network, CNN) yapısı ilk olarak LeCun tarafından 1989 yılında ortaya atılmıştır [30]. ESA'lar görüntü tanıma görevleri için tasarlanmış ve başlangıçta el yazısı rakam tanımaya meydan okumak için uygulanmıştır. ESA'ların temel tasarım hedefi, yerel görsel özellikleri bir ağ özü oluşturmak ve sonraki katmanlardaki nöronlar bu özellikleri daha yüksek düzen özellikleri oluşturmak için birleştirmektir. Yerel bir görsel özellik, kapsamı görüntüdeki küçük bir parçayla, bir dizi komşu pikselle sınırlı olan bir özelliktir. Örneğin, yüz tanıma görevine uygulandığında, ESA'nın ilk katmanlarındaki nöronlar basit yerel özelliklere yanıt olarak aktive olmayı öğrenir, ağdaki daha derin nöronlar bu düşük seviyeli özellikleri vücut kısımlarını temsil eden özelliklerle birleştirir ve ağın son katmanlarındaki nöronlar, görüntüdeki tüm yüzleri tanımlayabilmek için vücut parçası aktivasyonlarını birleştirir [31].

Evrişimsel sinir ağlarına ile öne sürülen modeller birçok avantaja sahiptir. Bunlar [32];

- Bölümleme ve nesneyi arka plandan ayırma gibi ön-işlem aşaması uygulanmaksızın ileri düzey görevler gerçekleştirilebilmektedir.
- Geleneksel görüntü tanımlayıcılara göre daha üstün performans göstermektedir.
- Geliştirilen modeller sadece bir nesnenin özelliklerine bağlı olmadan tüm nesnelerin sınıflandırılması için kullanılabilmektedir.

2.2.5.1 ESA Yapı Taşları

CNN'ler üç tip katmandan oluşur. Bunlar evrişimli katmanlar, ortaklama katmanları ve tam bağlantı katmanlardır. Bu katmanlar istiflendiğinde bir CNN mimarisi oluşturur. Basitleştirilmiş bir CNN mimarisi Şekil 2.11'de gösterilmektedir [33].

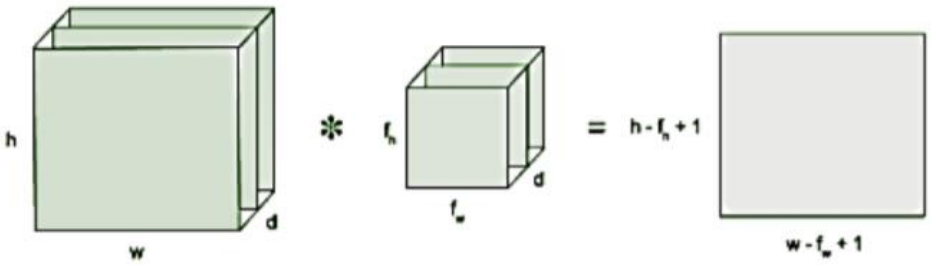


Şekil 2.11 CNN mimarisi

2.2.5.1.1 Evrişim Katmanı

Girilen bir görüntüden özellikleri soyutlamak için kullanılan ilk katman, evrişim katmanıdır. Pikseller arasındaki ilişki, girilen verinin küçük karelerine bağlı olarak görüntünün özelliklerini öğrenerek evrişimle korunur. Matematiksel bir işlem olarak evrişim, biri çekirdek veya filtre, diğeri ise bir görüntü matrisi olan iki girdi ile ilgilidir. Bu, Şekil 2.12'de gösterilmiştir. Burada [34]:

- Boyutların bir görüntü matrisi: yükseklik (h), genişlik (w) ve derinlik (d).
- Boyutlar filtresi: filtre yüksekliği (f_h) filtre genişliği (f_w) ve derinlik (d).
- Hacim boyutlarına sahip bir çıktı: $(h - f_h + 1) * (w - f_w + 1) * 1$.

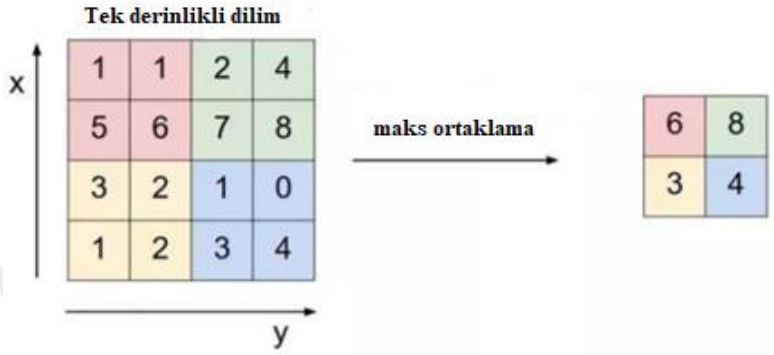


Şekil 2.12 Evrişim Katmanı

2.2.5.1.2 Ortaklama Katmanı

Bu bölüm, görüntülerin çok büyük olması durumunda parametrelerin sayılarının azaltılmasına katkıda bulunur. Alt örnekleme veya aşağı örnekleme olarak da bilinen bölgesel tip ortaklama, her haritanın boyutsal olarak azaltılmasına yol açar ve aynı zamanda önemli bilgileri tutar. Bölgesel tip ortaklama türlerinden bazıları şunlardır: toplam ortaklama, maksimum ortaklama

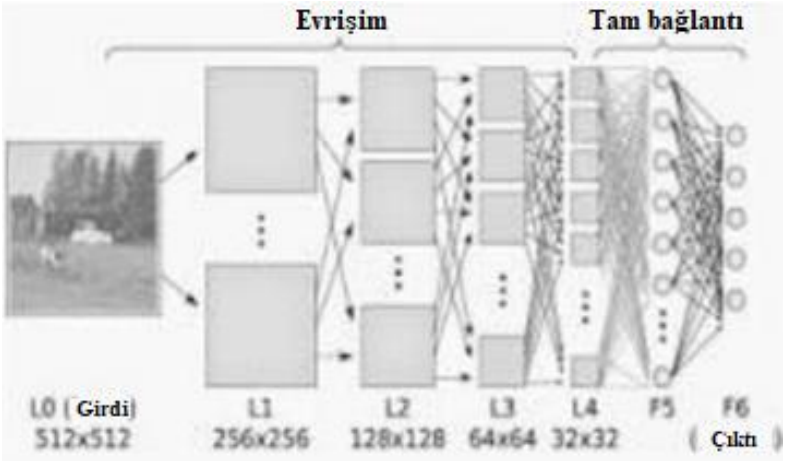
ve ortalama ortaklamadır. Maksimum ortaklama oluşturma, değiştirilen özellik haritasındaki en büyük öğeyi varsayar. En büyük unsurun varsayılması da ortalama ortaklamayı oluşturur. Tüm özellik eşleme öğelerinin toplanması, toplam ortaklamayı üretir. Maksimum tipi ortaklama Şekil 2.13'te gösterilmiştir [34].



Şekil 2.13 Maksimum ortaklama

2.2.5.1.4 Tam Bağlantı Katmanı

Tam bağlantı katmanı, nöronların geleneksel bir sinir ağında düzenlenmesine benzer. Bu nedenle, tam bağlantı katmandaki her düğüm, Şekil 2.14'te gösterildiği gibi hem önceki hem de sonraki katmandaki her düğüme doğrudan bağlanır. Bu şekilden, havuzdaki son karelerdeki düğümlerin her birinin katman, tam bağlantı katmandan birinci katmana bir vektör olarak bağlanır. Bunlar, bu katmanlardaki CNN ile en çok kullanılan parametrelerdir ve eğitimi uzun zaman alır [35].

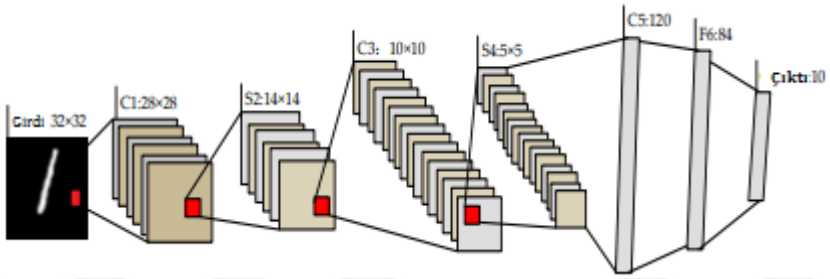


Şekil 2.14 Tam bağlantı katmanı

2.2.5.2 ESA Modelleri

2.2.5.2.1 LeNet-5

LeNet-5, gradyan tabanlı bir öğrenme CNN yapısıdır ve ilk olarak elle yazılmış dijital karakter tanımada başarıyla uygulanmıştır. Tipik LeNet-5 yapı şeması Şekil 2.15'te gösterilmektedir. Girdi katmanı, 32 x 32 boyutunda 0 ~ 9 el yazısıyla yazılmış bir dijital resimdir ve çıktı katmanı, 0 ~ 9'lara karşılık gelen 10 düğüme sahiptir. Girdi ve çıkıtı katmanlarına ek olarak, genel olarak LeNet-5, üç evrişimli katman, iki biriktirme katmanı ve bir tam bağlantı katmanından oluşan altı katman içerir. Evrişim çekirdeğinin büyüklüğü evrişim tabakasında 5 x 5'e, biriktirme tabakasındaki çekirdek ise 2 × 2'ye ayarlanmıştır. Tam bağlantı katmanı, parametre eğitimini azaltmak için nöron sayısını 120'den 84'e düşürür [36].

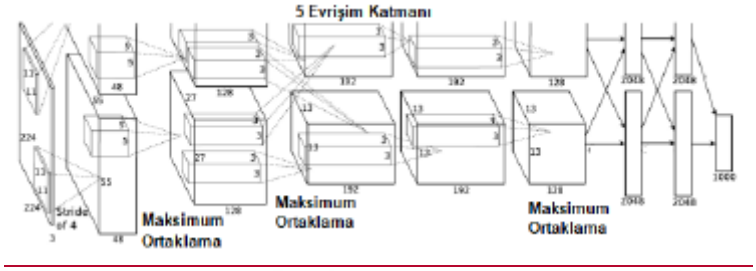


Şekil 2.15 LeNet-5 Yapısı

2.2.5.2.2 AlexNet

Krizhevsky, Sutskever ve Hinton tarafından geliştirilmiştir. 2012'de Alex Krizhevesky ve diğerleri, LeNet ile karşılaştırıldığında daha derin ve daha geniş bir CNN modeli önermiş ve 2012'de ImageNet Büyük Ölçekli Görsel Tanıma Zorluğu (ILSVRC) adı verilen görsel nesne tanıma için en zor ImageNet yarışmasını kazanmışlardır. Birbirini takip eden evrişim ve ortaklama katmanları bulunmasından dolayı, temel olarak LeNet modeline benzemektedir. AlexNet'in mimarisinde ilk evrişimsel katman, 11 × 11 boyutunda 96 farklı alıcı filtrenin kullanıldığı Yerel Yanıt Normalizasyonu (LRN) ile evrişim ve maksimum ortaklama gerçekleştirir. Maksimum ortaklama işlemleri, adım boyutu 2 olan 3 × 3 filtrelerle gerçekleştirilir. Aynı işlemler 5 × 5 filtreli ikinci katmanda gerçekleştirilir. Üçüncü, dördüncü ve beşinci evrişimsel katmanlarda sırasıyla 384, 384 ve 296 özellik haritalarına sahip 3 × 3 filtreler kullanılır. Seyreltme ve en sonda bir softmax ile iki tam bağlantı katmanları kullanılır. Benzer yapıya ve aynı sayıda özellik haritasına sahip iki ağ, bu model için paralel olarak eğitilir. Yerel ağda Normal Yanıt (LRN) ve seyreltme olmak üzere iki yeni kavram bu ağda

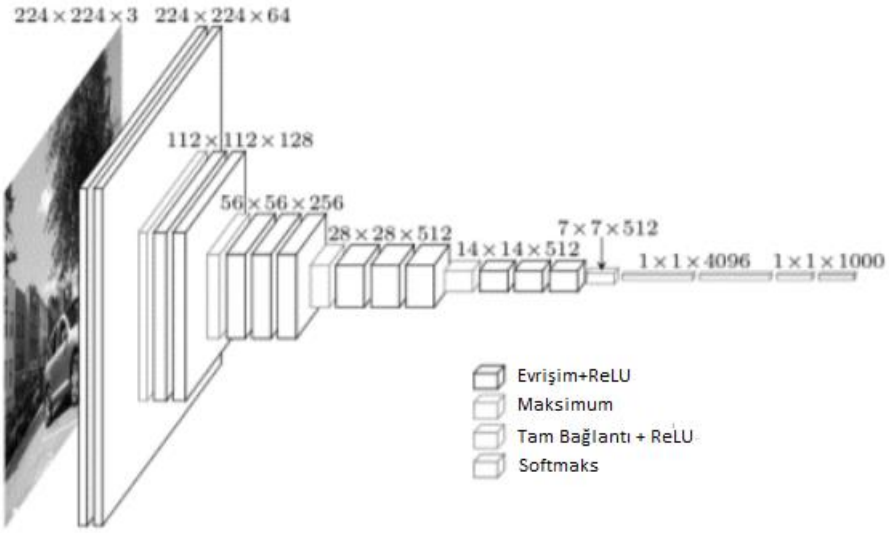
tanıtılmaktadır. LRN iki farklı şekilde uygulanabilir: ilk önce aynı kanal haritasından bir N × N yamasının seçildiği ve komşuluk değerlerine göre normalleştirildiği tek kanal veya özellik haritalarına uygulanmaktadır. İkincisi, LRN kanallara veya özellik haritalarına uygulanabilmektedir [37]. Şekil 2.16'da AlexNet mimarisi gösterilmektedir [38].



Şekil 2.16 AlexNet Mimarisi

2.2.5.2.3 VGG-16

VGG-16, 3 x 3 filtre büyüklüğüne sahip on üç evrişim katmanı ve 3 tam bağlantılı katmanı içeren 16 ağırlık katmanından oluşan daha derin bir modeldir. VGG-16'da tam bağlantı katmanların konfigürasyonları AlexNet ile aynıdır. Tüm evrişimli katmanların uzun adım ve dolgusu 1 piksele sabitlenir. Tüm evrişimli katmanlar 5 gruba ayrılır ve her grubu, Şekil 2.17'de gösterildiği gibi bir üst maksimum biriktirme katmanı izler [39].



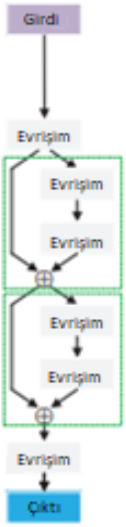
Şekil 2.17 VGG-16 mimarisi [40].

2.2.5.2.4 Res-Net

ResNet'in ana fikri, çok derin ağların eğitimini kolaylaştırmak için kalıcı bir öğrenme çerçevesi kullanmaktır. Her birkaç biriktirme katmanının optimizasyon için daha kolay olduğu varsayılan bir kalıcı haritalamaya uymaktadır. Girdiyi, x ve altındaki haritalamayı, H (x) olarak göstererek, kalıcı haritalama *F (x) = H (x) - x* olarak tanımlanır ve kalıcı birim yapısı Denklem 2.5'teki gibi ifade edilir [41]:

$$\hat{x} = U(x) = \sigma\big(F(x, W) + h(x)\big) \tag{2.5}$$

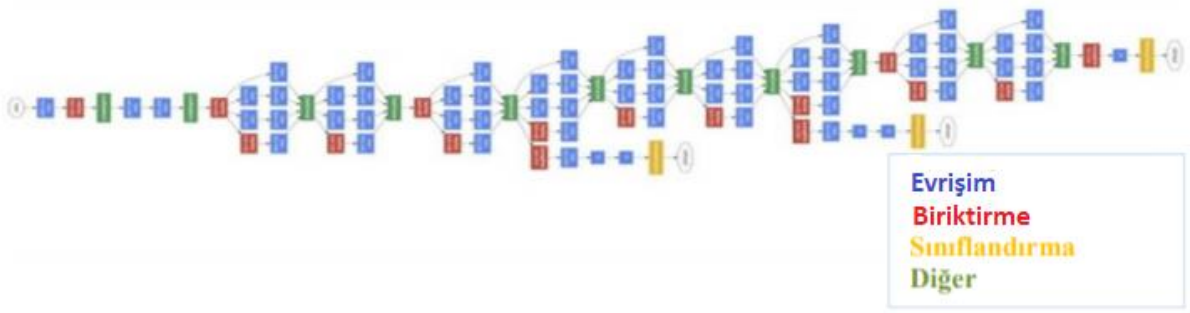
burada $\hat{x}$ artık ünitenin çıktısı, *h(x)* ise haritalamanın kimliğidir: *h (x) = x*, *W* bir ağırlık kümesidir (notasyonları basitleştirmek için sapmalar ihmal edilir), σ fonksiyonu ReLU'yu, *F(x, W)* öğrenilecek kalıcı haritalamayı ve *U*, kalıcı birim yapısının fonksiyonunu belirtir. Res-Net yapısı Şekil 2.18'deki gibidir [41].



Şekil 2.18 Res-Net mimarisi

2.2.5.2.2 GoogLeNet

GoogLeNet yapısındaki Inception modüllerinden dolayı karmaşık bir mimaridir. Temel Inception Modülü, ağ içindeki yapısıyla birlikte Google çalışanları, 2012 yılında gösterime giren 'Inception' filminden esinlenerek isimlendirdikleri Inception modüllerinin birleşiminden oluşan GoogLeNet'i yayımlamışlardır. Şekil 2.19'da GoogLeNet ağ mimarisi verilmiştir [40]. GoogLeNet'te, mimariyi oluşturmak için kullanılan 9 Inception modülü vardır. Başlangıç modülü, parametrelerin ölçeğini ve model karmaşıklığını sınırlamak için elverişli, küçük boyutlu (1 × 1, 3 × 3 ve 5 × 5 gibi) birkaç evrişim çekirdeğinden oluşur. Kaybolan gradyan ve aşırı uyma sorunlarının üstesinden gelmek için, bu 9 Inception modülü 3 gruba ayrılır ve her 3 Inception modülüne üç objektif fonksiyon eklenir [42].



Şekil 2.19 GoogLeNet mimarisi

2.2.6 Tekrarlayan Sinir Ağları

Tekrarlayan sinir ağları (Recurrent Neural Networks, RNN), doğal dil için gerekli olduğu düşünülen hiyerarşik yapıyı açıkça kodlamayan genel dizi işleme mekineleridir. Yapay dilleri kullanarak yapılan erken çalışmalar, yine de bağlamsız dilleri tahmin edebileceklerini göstermiştir. Daha yakın zamanda, RNN'ler ile yapılan çalışmalar sonucunda, konuşma tanıma ve makine çevirisi için dil modelleme gibi büyük ölçekli görevlerde etkileyici sonuçlar elde edilmiştir. Bu, RNN'lerin daha gürültülü doğal veriler üzerine eğitilmiş olsalar bile gramer yapısını izlemeyi öğrenebileceklerini göstermektedir [43]. Tekrarlayan Sinir Ağları, önceki zaman adımlarındaki değerleri 'hatırlamak' için geri bildirim bağlantıları kullanılarak zaman serisi verilerinde bulunan geçici bağımlılıkları modelleyen sinir ağlarıdır. RNN mimarisinin yinelenen (recurrent) olarak adlandırılmasının sebebi, bir dizinin her öğesi için (cümledeki kelimeler gibi) aynı görevi önceki çıktılara bağlı olarak yerine getirmesidir [44].

Bir girdi dizisi $x = (x_1, \dots, x_T)$ verildiğinde, standart bir tekrarlayan sinir ağı, Denklem 2.6 ve Denklem 2.7'i $t = 1$'den T'ye yineleyerek (RNN) gizli vektör dizisini $h = (h_1, \dots, h_T)$ ve çıktı vektör dizisini $y = (y_1, \dots, y_T)$ hesaplar [45]:

$$h_t = \mathrm{H}(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \tag{2.6}$$

$$y_t = W_{hy}h_t + b_y \tag{2.7}$$

W terimleri, ağırlık matrislerini (örneğin, W_{xh}, girdi-gizli ağırlık matrisidir) belirtir; b terimleri, sapma vektörüdür (örneğin, b_h, gizli sapma vektörüdür) ve H, gizli katman fonksiyonudur [45].

2.2.6.1 Jordan Elman Ağları

Elman sinir ağı, tekrarlanan bağlantıları aracılığıyla önceki gizli katman durumlarını takip eder. Bu nedenle, zamandaki gizli katman, mevcut girdiyle birlikte geçmiş girdileri özetleyen bir durum olarak görülebilir. Matematiksel olarak, H gizli katmanlarının her birinde d_h gizli düğümlü Elman dinamikleri Denklem 2.8-9 'daki gibi gösterilmiştir [46]:

$$h^{(1)}(t) = f\left(U^{(1)}C_d\left(l_{t-d}^{t+d}\right) + U'^{(1)}h^{(1)}(t-1)\right) \tag{2.8}$$

$$h^{(n+1)}(t) = f\left(U^{(n+1)}h^{(n)}(t) + U'^{(n+1)}h^{(n+1)}(t-1)\right) \tag{2.9}$$

Burada, doğrusal olmayan sigmoid fonksiyonunu kullanıldığı yerde, $f(x) = 1/(1 + e^{-1})$ ve $h^{(i)}(0) \in R^{d_h}$ gizli katmanı için akıllı öğenin öğrenilmesi gereken parametre vektörleridir. Üst simge, gizli katmanların derinliğini belirtir ve $U^{'}$, tekrarlayan ağırlıklar bağlantısını temsil eder. Sınıflandırıcının her bir sınıf için sonsal olasılıkları daha sonra gizli duruma uygulanan softmaks fonksiyonu Denklem 2.10'da verilmiştir [46]:

$$P\left(y(t) = i \backslash l_0^{t+d}\right) = \frac{e^{\sum_{j=1}^{d_h} V_{i,j} h_j^{(H)}(t)}}{\sum_{i=1}^{N} e^{\sum_{j=1}^{d_h} V_{i,j} h_j^{(H)}(t)}} \tag{2.10}$$

Burada *V*, softmaks üst katmanın ağırlığına karşılık gelir [46].

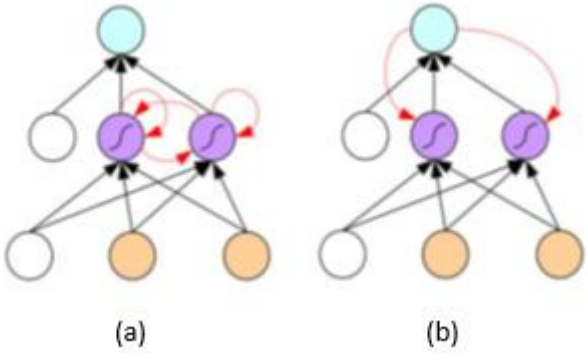
Elman sinir ağının eğitimi, uzun vadeli bağımlılıkları öğrenme zorluğundan dolayı, bu durumlarda kullanışlı olmayabilir. Girdi nöronlarından gizli nöronlara, gizli nöronlardan çıktı nöronlarına ve ağırlıklar adı verilen gizli nöronlar arasındaki parametrelerdir. Elman sinir ağını eğitirken, nihai amaç ağırlıklara karşılık gelen hatanın gradyanlarını hesaplamaktır. Gradyanlar, bir eğitim örneği için her bir adımda toplanır. Bu gradyanları hesaplamak için farklılaşma zincirini kullanılır. Yok olan ve bozulan gradyanların sorunları, birçok zaman aşaması boyunca hataları geri yayarken ortaya çıkar. Modern dinamik RNN mimarileri son yıllarda yok olan ve bozulan gradyanlarla mücadele etmektedir [47].

Jordan RNN, Elman tipi ağa, tekrarlayan bağlantıların girdilerini çıktı sonrasal olasılıklarından alması dışında benzerdir ve Denklem 2.11'deki gibi ifade edilir [46]:

$$h(t) = f\left(UC_d\left(l_{t-d}^{t+d}\right) + U'P\left(y(t-1)\right)\right) \tag{2.11}$$

$U' \in M_{d_h \times N}(R)$ ve $P(y(0)) \in R^N$ ayarlanması gereken ek parametrelerdir [46].

Bu modellerin mimarileri Şekil 2.20'de gösterilmektedir [46].



Şekil 2.20 İki tip sinir ağı. (a) Elman-RNN; (b) Jordan-RNN.

2.2.6.2 Doğrusal Olmayan Otoregresif Ekzojen Model

Doğrusal Olmayan Otoregresif Ekzojen Model (NARX) ağı bir tür tipik dinamik tekrarlayan sinir ağıdır. N aşamalı NARX, Denklem 2.12 ile temsil edilebilir [47]:

$$çıktı(t+1) = f\begin{bmatrix} çıktı(t-1), çıktı(t-2), \dots, çıktı(t+1-q); \\ girdi(t-k), girdi(t-k-1), \dots, girdi(t-k-p+1) \end{bmatrix} \quad (2.12)$$

girdi(t) ve *çıktı(t)* sırasıyla *t* adımındaki girdi ve çıktı değeri, p ve q ise gecikme parametreleridir. $p \geq 1$ ve $q \geq 1$, $p \leq q$. Proses atıl zaman parametresi *k* ($k \geqslant 0$) gecikmeli bir terimdir. *f[]* doğrusal olmayan fonksiyondur. *çıktı(t-1)*'den *çıktı(t+1-q)*'ya olan girdiler otoregresif bir model olarak işlev görür. *girdi(t-k)*'den *girdi(t-k-p+1)*'ye dış kaynaklı bir değişken rolü oynar [47].

İki tür NARX eğitim yöntemi vardır: Seri Paralel (SP) eğitim yöntemi ve Paralel (P) yöntemidir. SP metodu matematiksel olarak Denklem 2.13 ile gösterilebilir [47]:

$$çıktı(t+1) = f\begin{bmatrix} gerçek(t-1), gerçek(t-2), \dots, gerçek(t+1-q); \\ girdi(t-k), girdi(t-k-1), \dots, girdi(t-k-p+1) \end{bmatrix} \quad (2.13)$$

SP yönteminde, girdi katmanındaki çıktının regresörü sadece gerçek değeri kullanır. Performans çok adımlı ileri tahminlerde, *gerçek (t)*, *gerçek (t-1)*, *..., gerçek (t + 1- q)* değerler, geçerli zaman adımında elde edilemeyen gelecekteki değerlerdir. Hesaplanan çıktılar, ağın girdi katmanına, çıktı regresörü olarak geri beslemeli ise, bu mod P yöntemi olarak yapılabilir ve Denklem 2.14'teki gibi ifade edilir [47]:

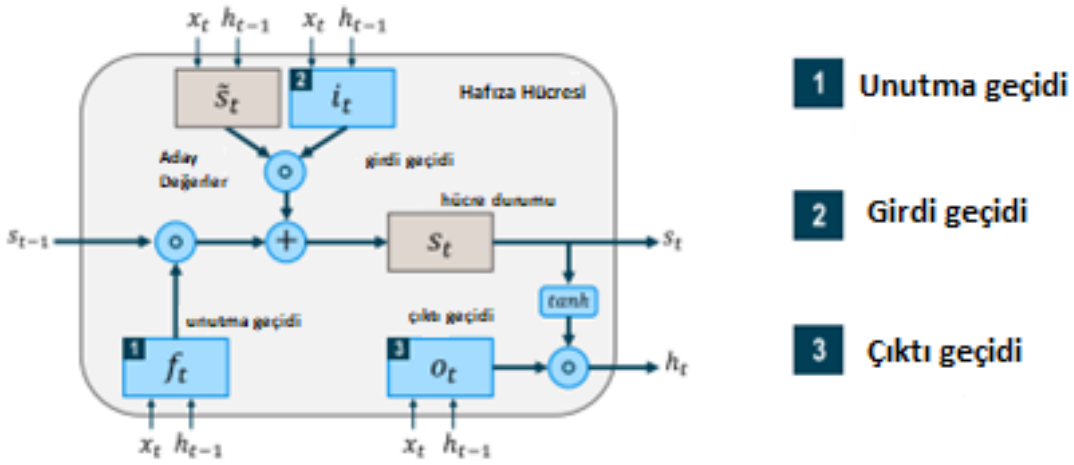
$$çıktı(t+1) = f\begin{bmatrix} \widehat{gerçek}(t-1), \widehat{gerçek}(t-2), \dots, \widehat{gerçek}(t+1-q); \\ girdi(t-k), girdi(t-k-1), \dots, girdi(t-k-p+1) \end{bmatrix} \quad (2.14)$$

($\wedge$) sembolü, tahmini değerleri belirtmek için kullanılmıştır [47].

2.2.6.3 Uzun Kısa Süreli Bellek

Uzun Kısa Süreli Bellek (LSTM) ağları, tekrarlayan sinir ağları (RNN'ler) sınıfına, yani "nöronal bağlantıların altında yatan topolojide en az bir döngü içeren" sinir ağlarına aittir [48]. [49] tarafından tanıtıldılar ve sonraki yıllarda, örneğin [50] ile [51] tarafından birkaç isim verilmiştir. LSTM ağları, uzun vadeli bağımlılıkları öğrenmek için özel olarak tasarlanmıştır ve daha önce RNN'lerin özünde olan problemlerini, yani gradyanları yok etme problemlerini çözme yeteneğine sahiptir [48].

LSTM ağları bir girdi katmanından, bir veya daha fazla gizli katmandan ve bir çıktı katmanından oluşur. Girdi katmanındaki nöronların sayısı açıklayıcı değişkenlerin sayısına eşittir (özellik alanı). Çıktı katmanındaki nöronların sayısı çıktı alanını yansıtır. LSTM ağlarının temel özelliği, bellek hücrelerinden oluşan gizli katmanlar bulunur. Bellek hücrelerinin her biri, hücre durumunu s_t koruyan ve ayarlayan üç geçide sahiptir: unutma geçidi (f_t), girdi geçidi (i_t) ve çıktı geçidi (o_t). Bir hafıza hücresinin yapısı, Şekil 2.21'de gösterilmektedir [48].



Şekil 2.21 LSTM bellek hücresinin yapısı

Her zaman noktasında, üç geçitten her biri, önceki zaman adımındaki *t - 1* bellek hücrelerinin çıktı h_{t-1}'in yanı sıra girdi x_t'si (girdi dizisinin bir elemanı) ile birlikte sunulur. Her biri farklı bir amacı yerine getiren filtreler [48]:

- Unutma geçidi, hangi bilgilerin hücre durumundan çıkarıldığını tanımlar.
- Girdi geçidi, hangi bilgilerin hücre durumuna ekleneceğini belirtir.
- Çıktı geçidi, hücre durumundan hangi bilgilerin çıktı olarak kullanılacağını belirtir.

Aşağıdaki denklemler vektörleştirilir ve her zaman diliminde LSTM katmanındaki bellek hücrelerinin güncellenmesini tarif eder. Semboller aşağıdaki gibidir [48]:

- x_t, t adımındaki girdi vektörüdür
- $W_{f,x}, W_{f,h}, W_{\hat{s},x}, W_{\hat{s},h}, W_{i,x}, W_{i,h}, W_{o,x}$ ve $W_{o,h}$ ağırlık matrisleridir.
- b_f, $b_{\hat{s}}$, b_i, ve b_o önyargı vektörleridir.
- f_t, i_t ve o_t, ilgili geçitlerin aktivasyon değerlerine yönelik vektörlerdir.
- s_t ve $\hat{s}_t$ hücre durumları ve aday değerlerine yönelik vektörlerdir.
- h_t, LSTM katmanının çıktısı için bir vektördür.

Bir ileri geçiş sırasında, t zamanı basamağında LSTM katmanının s_t hücre durumu ve h_t çıktıları aşağıdaki şekilde hesaplanır [48]:

İlk adımda, LSTM katmanı hangi bilgilerin önceki hücre durumlarından s_{t-1}'den çıkarılması gerektiğini belirler. Bu nedenle, t adımındaki unutma geçitlerinin aktivasyon değerleri f_t, mevcut x_t girdisine, önceki zaman adımındaki $(t-1)$ bellek hücrelerinin h_{t-1} çıktısına ve unutma geçitlerinin b_f önyargı terimlerine göre hesaplanır. Sigmoid fonksiyonu sonunda tüm aktivasyon değerlerini 0 (tamamen unut) ve 1 (tamamen hatırla) arasındaki aralığa ölçeklendirir [48]:

$$f_t = Sigmoid(W_{f,x}x_t + W_{f,h}h_{t-1} + b_f) \tag{2.15}$$

İkinci adımda, LSTM katmanı hangi bilgilerin hücre durumlarının ağına (s_t) eklenmesi gerektiğini belirler. Bu yöntem iki işlemden oluşur: ilk önce, hücre durumlarına potansiyel olarak eklenebilecek aday değerler $\hat{s}_t$ hesaplanır. İkinci olarak, girdi geçitlerinin i_t aktivasyon değerleri hesaplanır [48]:

$$\hat{s}_t = tanh(W_{\hat{s},x}x_t + W_{\hat{s},h}h_{t-1} + b_{\hat{s}}) \tag{2.16}$$

$$i_t = Sigmoid(W_{i,x}x_t + W_{i,h}h_{t-1} + b_i) \tag{2.17}$$

Üçüncü adımda, yeni hücre durumları s_t, Hadamard (bilge element) ürününü ifade eden ○ önceki iki adımın sonuçlarına dayanarak hesaplanır [48]:

$$s_t = f_t \circ s_{t-1} + i_t \circ \hat{s}_t \tag{2.18}$$

Son adımda, bellek hücrelerinin h_t çıktısı aşağıdaki iki denklemde belirtildiği gibi türetilir [48]:

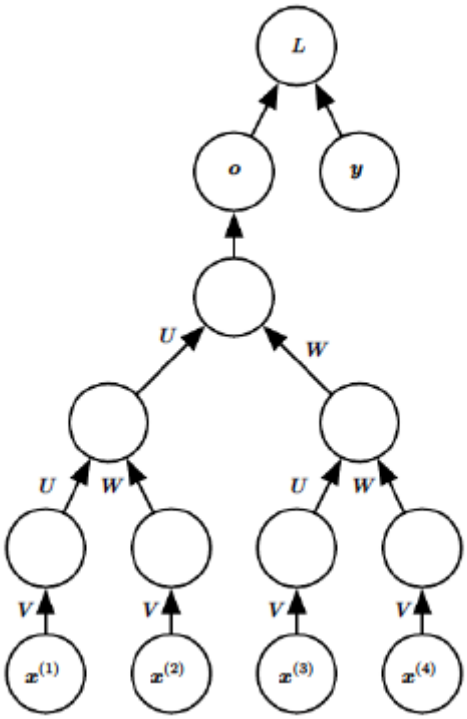
$$o_t = Sigmoid(W_{o,x}x_t + W_{o,h}h_{t-1} + b_o) \tag{2.19}$$

$$h_t = o_t \circ tanh(s_t) \tag{2.20}$$

Bir girdi sırasını işlerken, özellikleri, LSTM ağına adım adım sunulur. Böylelikle, her bir *t* zaman dilimindeki girdi, ağ tarafından yukarıdaki denklemlerde belirtildiği gibi işlenir. Dizinin son elemanı işlendikten sonra, dizinin tamamı için nihai çıktı geri döndürülür [48].

2.2.7 Özyinelemeli Sinir Ağları

Özyinelemeli yapay sinir ağları (Recursive Neural Network), tekrarlayan sinir ağlarının başka bir genellemesini gösterir. Burada, zincir benzeri RNN yapısından ziyade, derin bir ağaç olarak yapılandırılmış farklı bir hesaplamalı çizge kullanılır. Özyinelemeli ağlar için tipik bir hesaplamalı çizge Şekil 2.22'de gösterilmektedir. Özyinelemeli sinir ağları, [52] tarafından tanıtılmış ve öğrenim amacıyla kullanım potansiyeli [53] tarafından tanımlanmıştır. Özyinelemeli ağlar sinir ağlarına girdi olarak verilen veri yapılarını işleme, doğal dil işleme ve bilgisayarlı görü alanlarında başarıyla uygulanmıştır [25].



Şekil 2.22 Özyinelemeli Ağlar

Özyinelemeli ağların yinelemeli ağlara göre açık olan bir avantajı, aynı τ uzunluğa sahip bir dizi için derinliği τ'dan $O(\log \tau)$'ya büyük ölçüde düşürebilir olmasıdır. Bu da uzun vadeli bağımlılıkların ele alınmasını kolaylaştırabilir. Derinlik eğrisel işlemlerin bileşimlerinin sayısı olarak ölçülür. Bu noktada iyi bir ağaç yapısının oluşturulması önemlidir. Bazı uygulama alanlarında harici yöntemler ağaç yapısını önerebilmektedir. Örneğin; doğal dil cümlelerini işlerken kullanılan özyinelemeli ağın ağaç yapısı, bir doğal dil ayrıştırıcısı tarafından sağlanan cümle ayrıştırma ağacının yapısına sabitlenebilmektedir [25].

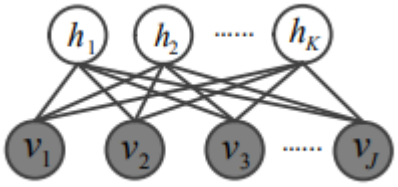
2.2.8 Boltzmann Makineleri

Hinton ve diğ. tarafından 1983'te önerilen Boltzmann makinesi [54], iç temsiller öğrenebilen ve kombinatoryal optimizasyon problemlerini çözebilen stokastik bir sinir ağının iyi bilinen bir örneğidir. Boltzmann makinesi, iki durumlu birimler içeren tam bağlantılı bir ağdır ve olası ağ durumları arasında geçiş için benzetimli tavlama kullanır. Birimler, ağ enerjisini en aza indirmeye eşdeğer bir küresel konsensüs işlevini en üst düzeye çıkarmak için durumlarını, komşularının mevcut durumuna ve karşılık gelen kenar ağırlıklarına göre çevirir [55].

Birçok kombinatoryal optimizasyon probleminin yanı sıra makine öğrenme görevleri, uygun kenar ağırlıkları ve ağ içindeki ünitelerin başlangıç durumu seçilerek doğrudan bir Boltzmann makinesine eşlenebilir. Bu eşlemenin bir sonucu olarak, (1) ağın her olası durumu optimizasyon problemine aday bir çözümü temsil eder ve (2) ağ enerjisini en aza indirmek optimizasyon problemini çözmeye eşdeğer hale gelir. Enerji minimizasyonu işlemi tipik olarak kenar ağırlıklarının ayarlanması (öğrenme) veya birim durumlarının yeniden hesaplanması (arama ve sınıflandırma) ile gerçekleştirilir. Bu işlem yakınsama sağlanana kadar tekrarlanır. Bir optimizasyon probleminin çözümü, ağın son durumunu okuyarak ve uygun şekilde yorumlayarak bulunabilir [55].

2.2.9 Sınırlı Boltzmann Makineleri

Sınırlı Boltzmann Makinesi (Restricted Boltzmann Machine, RBM), $h = \{h_k\}_{k=1}^{K}$ gizli birimler kümesi ve $v = \{v_j\}_{j=1}^{J}$ görünür birimler grubundan oluşan yönlendirilmemiş bir grafik modeldir. Hem h_k hem de v_j'nin ikili sayılar olduğu varsayılmaktadır. Her gizli ünite, yönlendirilmiş kenarları olan tüm görünür ünitelere bağlanır ve iki gizli ünite veya iki görünür ünite arasında bağlantı yoktur. Şekil 2.23'te, temel RBM gösterilmektedir [56].



Şekil 2.23 Sınırlı Boltzmann Makineleri

Bir RBM'de, görünür ve gizli birimlerin ortak olasılık dağılımı, enerji fonksiyonu ile tanımlanır. Belirli bir durum için (v, h) Bernoulli - Bernoulli RBM'in enerji fonksiyonu Denklem 2.21'deki gibidir [57]:

$$E(h, v\backslash\theta) = -\sum_{j=1}^{J} b_j v_j - \sum_{k=1}^{K} a_k h_k - \sum_{j=1}^{J}\sum_{k=1}^{K} w_{jk} v_j h_k \qquad (2.21)$$

$\theta = (w,b,a)$, bilinmeyen model parametresini belirtir, w_{jk}, v_j *ve* h_k arasındaki bağlantı ağırlığıdır ve b_j *ve* a_k, sırasıyla sapmalardır. J ve K, görünür ve gizli birimlerin sayısını temsil eder. Bu

nedenle, enerji fonksiyonuna dayanarak, ortak olasılık dağılımı Denklem 2.22'deki gibi verilmiştir [57]:

$$p(v,h\backslash\theta) = \frac{e^{-E(v,h\backslash\theta)}}{Z(\theta)} \tag{2.22}$$

Z = $\sum v, h^{e^{-E(v,h\backslash\theta)}}$ normalizasyon faktörünü veya bölümleme fonksiyonunu temsil eder. Daha sonra, modelin görünür bir *v* vektörüne atadığı marjinal olasılık Denklem 2.23'te verilmiştir [57]:

$$p(v\backslash\theta) = \frac{\sum h^{e^{-E(v,h\backslash\theta)}}}{Z(\theta)} \tag{2.23}$$

Herhangi iki görünür birimde ve iki gizli birimde bağlantı olmadığı için, koşullu olasılıklar *p(h|v,θ)* ve *p(v|h,θ)* faktöriyeldir ve Denklem 2.24-25'teki gibi hesaplanabilir [57]:

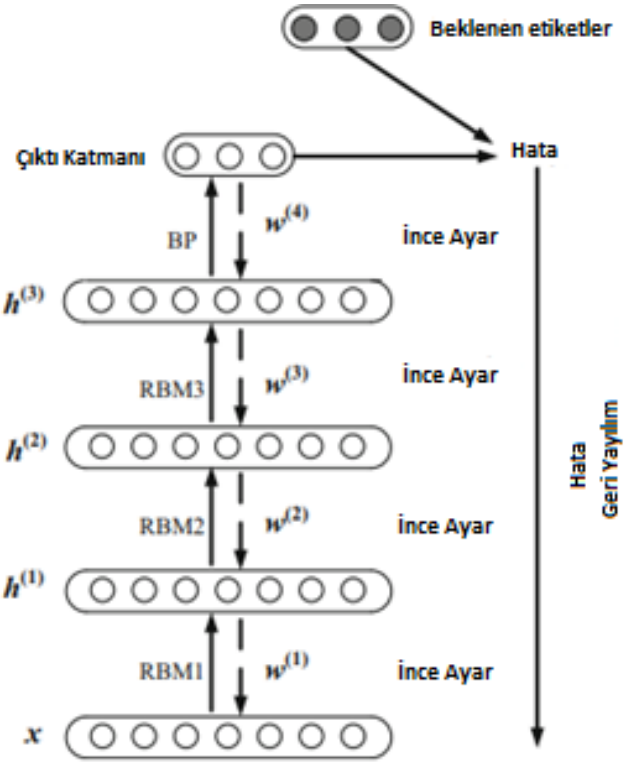
$$p(h_k = 1|v,\theta) = \sigma(\sum_{k=1}^{K} w_{jk}v_j + a_k) \tag{2.24}$$

$$p(v_j = 1|v,\theta) = \sigma(\sum_{k=1}^{K} w_{jk}h_k + b_j) \tag{2.25}$$

2.2.10 Derin İnanç Ağları

Derin inanç ağı (DBN) 2006 yılında Hinton [58] tarafından önerilmiş ve o zamandan beri, DBN çeşitli derin öğrenme görevlerinin hem teorisi hem de uygulamalarında geniş çapta araştırılmıştır ve yaygın olarak kullanılmaktadır. Şekil 2.24'4e gösterildiği gibi, DBN çok katmanlı RBM ve tek katmanlı geri yayılımdan (BP) yapılmış bir sinir ağıdır. DBN aslında açgözlü ve çok katmanlı bir öğrenme modeli olup, bir RBM yığını ile birleştirilmiştir. DBN'nin ayırt edici bir özelliği, gizli katman birimlerinin durumlarını bir ileri geçişle elde edebilmesidir. Bir DBN eğitimi sırasında, ilk adım, çok sayıda RBM katmanını aşağıdan yukarıya doğru katman halinde istifleyen ön eğitimdir. Alt katman RBM'nin parametreleri öğrenilerek belirlendiğinde, gizli özellik aktivasyonlarının vektörleri, yüksek katman RBM için görünür

birimlerin girişi olarak kullanılabilir. Daha sonra, ince ayar aşamasında, tüm ağın ağırlıklarını ayarlamak için geri yayılım yaklaşımı kullanılır [57].



Şekil 2.24 Bir DBN'nin şematik diyagramı

Çıktı katmanının düğümü için, asıl çıktının o_i ve beklenen çıktının d_i olduğunu varsayalım. Duyarlılık δ_i Denklem 2.26'daki gibi hesaplanabilir [57]:

$$\delta_i = o_i(1 - o_i)(d_i - o_i) \tag{2.26}$$

l. gizli katmanı için, y_i, i. düğümün çıktısı olsun, duyarlılık δ_i Denklem 2.27'deki gibi tanımlanır [57]:

$$\delta_i^l = y_i^l(1 - y_i^l)\sum_j w_{ij}^l \delta_j^{l+1} \tag{2.27}$$

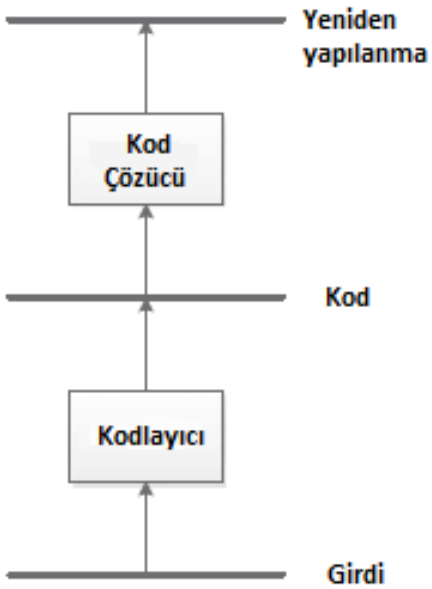
Son olarak, DBN'nin ağırlıkları Denklem 2.28-29'daki gibi güncellenir [57]:

$$w_{ij}^l = w_{ij}^l + \varepsilon_{ceza-ayar} y_i^l \delta_j^{l+1} \tag{2.28}$$

$$b_i^l = b_i^l + \varepsilon_{ceza-ayar} \delta_j^{l+1} \tag{2.29}$$

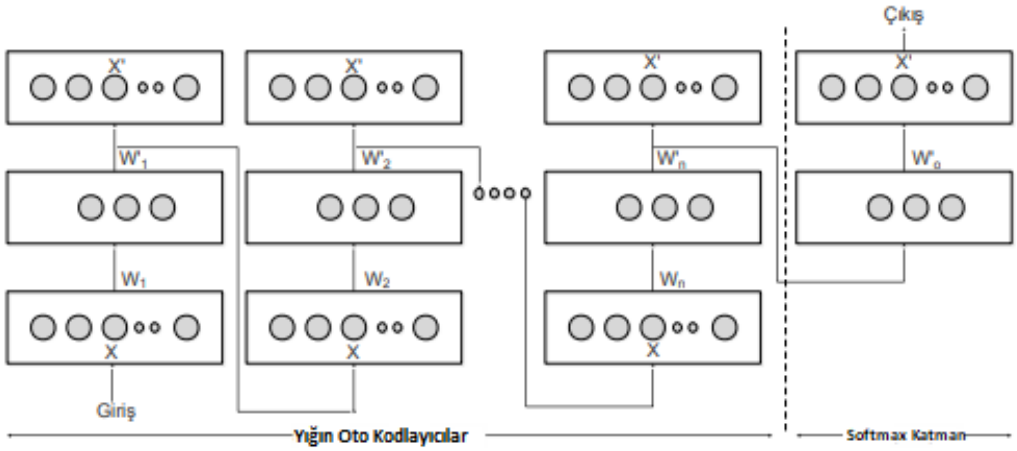
2.2.11 Oto Kodlayıcılar

Oto kodlayıcı (AE) yapay sinir ağı modelinden türetilmiş denetimsiz bir makine öğrenmesi yöntemidir[59]. Bir oto kodlayıcının amacı, genellikle boyutsallığın azaltılması amacıyla bir veri kümesi için bir temsili öğrenmektir. Derin oto kodlayıcı, modelin çoklu gizli katmanları aracılığıyla hiyerarşik doğrusal olmayan eşlemeler yoluyla etkili özellik öğrenme için kullanılır .Oto kodlayıcıların eğitimi genellikle iki aşamada gerçekleştirilir: ön eğitim ve sonlandırma. Ön eğitim genellikle katman katman yapılır ve iyi bir çözüme yeterince yakın katman ağırlıklarını başlatmak için birden fazla basit otomatik kodlayıcı kullanılır. İnce ayar, nihai hedef fonksiyonuna göre tüm ağın çoklu katmanlarını optimize etmek için yapılır [60]. Modelin şematik diyagramı, Şekil 2.25'te gösterilmiştir [61].



Şekil 2.25 Oto Kodlayıcı Şematik Diyagramı

Şekil 2.26'da gösterildiği gibi oto kodlayıcıların yığın (stacked) şeklinde arka arkaya bağlanmasıyla derin öğrenme mimarisi elde edilir. [59].



Şekil 2.26 Yığın Oto Kodlayıcılar

Geleneksel bir oto-kodlayıcı iki temel parçadan oluşur: tek bir gizli katmanı olan kodlayıcı ve kod çözücüdür [60].

Kodlayıcı: d boyutlu girdi vektörü $x' \in R^d$'yi, r boyutlu gizli vektörü $h' \in R^r$ dönüştüren deterministik eşleme $f(x')$, kodlayıcı olarak adlandırılır. Tipik formu Denklem 2.30'daki gibi ifade edilebilen bir afin haritalama ve ardından doğrusal olmayan bir dönüşümdür [60].

$$h' = f(x') = \varphi(Wx' + b') \tag{2.30}$$

burada W, kodlayıcının eşleme ağırlık matrisini belirtir, b, önyargı vektörü ve Φ, aktivasyon fonksiyonudur [60].

Gizli temsili h'yi (yukarıda tarif edilen adımda gözlemlenir) giriş alanında yeniden yapılandırılmış bir $z' \in R^d$ vektörüne dönüştüren g(h'), kod çözücü olarak adlandırılır. Bir kod çözücünün tipik formu Denklem 2.31'deki gibidir. Ayrıca bu kod çözücü, isteğe bağlı olarak bir sıkışmış doğrusal olmama özelliğinin ardından bir afin eşlemedir [60].

$$z' = g(h') = \varphi(W'h' + b'') \tag{2.31}$$

burada W' kod çözücünün ağırlık matrisidir, b'', önyargı vektörü ve Φ, aktivasyon fonksiyonudur [60].

2.2.11.1 Gürültü Giderici Oto Kodlayıcılar

Gürültü Giderici Oto Kodlayıcılar (DAE'ler), klasik otomatik kodlayıcı sinir ağlarının basit bir modifikasyonudur. Girdileri yeniden kurmak için değil, girdilerinin yapay olarak gürültülü bir versiyonunun gürültüsünü gidermek için eğitilmektedirler. Aşırı tamamlanmış normal bir otomatik kodlayıcı, işe yaramaz bir kimlik haritasını kolaylıkla öğrenebilse de, bir DAE'nin daha zorlu gürültü giderme problemini çözmek için daha kullanışlı özellikler çıkarması gerekir [62].

DAE'de optimizasyonun amaç fonksiyonu Denklem 2.32'de gösterilmiştir [61]:

$$J_{DAE} = \sum_{t} IE_{q(\tilde{x}\backslash x^{(t)})}[L(x^{(t)}, g_\theta(f_\theta(\tilde{x})))] \tag{2.32}$$

Burada J_{DAE}, bozulma işlemi $q(\tilde{x}\backslash x^{(t)})$'dan alınan bozuk $\tilde{x}$ verisi üzerindeki ortalama değeri temsil eder. Uygulamada, amaç fonksiyonunu optimize etmek için stokastik gradyan inişi kullanılır [61].

2.2.11.2 Seyrek Oto Kodlayıcılar

Seyrek Oto Kodlayıcı, temel olarak bir veri kümesinin özelliklerini denetimsiz bir şekilde öğrenmek için kullanılan simetrik bir sinir ağıdır. Tipik olarak, seyrek AE, sırasıyla kodlama ve kod çözme parçalarından oluşur. Kodlama bölümünde, x_i girdisi Denklem 2.33'teki gibi doğrusal olmayan aktivasyon fonksiyonu g aracılığıyla S boyutunun gizli gösterimi h_i ile eşleştirilir [63]:

$$h_i = g\left(W^{(e)}x_i + b^{(e)}\right) \tag{2.33}$$

$W^{(e)} \in^{S\times D}$ kodlayıcı ağırlık matrisi ve $b^{(e)} \in R^S$ kodlama sapma vektörüdür. Aktivasyon fonksiyonunun tipik bir seçimi sigmoid fonksiyondur. Kod çözme aşamasında, gizli temsilci ayrıca girdi vektörünü (x_i) Denklem 2.34'teki gibi yeniden yapılandırmak için doğrusal olmayan bir aktivasyon fonksiyonu ile eşleştirilir [63]:

$$\hat{x}_i = g\left(W^{(d)}h_i + b^{(d)}\right) \tag{2.34}$$

burada $\hat{x}_i$, yeniden yapılandırılmış CNN özellik vektörüne atıfta bulunur; $W^{(d)} \in^{D\times S}$, kod çözme ağırlığı matrisidir ve $b^{(d)} \in^{D}$, kod çözme eğilimidir [63].

AE yapısının tamamını temsil eden $\theta_{AE} = \{W^{(e)}, W^{(d)}, b^{(e)}, b^{(d)}\}$ parametresi vektörünü belirlemek için, Denklem 2.35'teki maliyet fonksiyonu minimize edilebilir [63]:

$$\mathcal{L}_1(\theta_{AE}) = \frac{1}{2n}\sum_{i=1}^{n} x_i - \hat{x}_i^2 + \lambda \sum_{j=1}^{L} KL(\rho\hat{\rho}_j) \tag{2.35}$$

λ, bir düzenleme parametresidir ve ilk terim, tüm n eğitim örnekleri üzerindeki yeniden yapılanma hatasını temsil eder. Seyreklik kısıtlaması, ρ *ve* $\hat{\rho}_j$ araçlarıyla iki dağıtım arasında hesaplanan Kullback-Leibler ıraksama KL aracılığıyla uygulanır. Burada ρ, gizli ünitelerin hedef aktivasyon fonksiyonunu belirtir ve $\hat{\rho}_j$, j. gizli düğümünün tüm örneklerde ortalama aktivasyon fonksiyonudur [63].

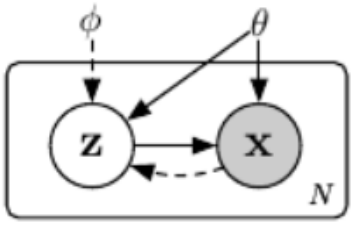
2.2.11.3 k-Seyrek Oto Kodlayıcı

K-seyrek otomatik kodlayıcı, doğrusal etkinleştirme işlevlerine ve bağlı ağırlıklara sahip bir otomatik kodlayıcıya dayanır. İleri besleme aşamasında, $z = W^Tx+b$ gizli kodları hesapladıktan sonra, tüm gizli ünitelerden gelen girişi yeniden yapılandırmak yerine, en büyük k gizli üniteleri belirlenir ve diğerleri sıfıra ayarlanır. Bu, aktiviteleri sınıflandırarak veya geniş kapsamlı aktiviteler tanımlanıncaya kadar uyarlanabilir şekilde ayarlanmış eşikleri olan ReLU gizli katmanları kullanarak yapılabilmektedir. Bu, $supp_k(W^Tx + b)$ destek dizisiyle bir aktivite vektöründe sonuçlanır. En büyük k aktivitesi seçildikten sonra, ağ tarafından hesaplanan fonksiyon doğrusaldır. Dolayısıyla, doğrusal olmayan tek şey, en büyük k aktivitelerinin seçiminden gelir. Bu seçim adımı, girişi yeniden yapılandırırken aşırı sayıda gizli ünitenin kullanılmasını önleyen bir düzenleyici görevi görür [64].

2.2.11.4 Varyasyonel Oto Kodlayıcı

Varyasyonel Oto Kodlayıcılar (VAE) derin bir Bayes ağıdır. Gizli değişken z ve görünür değişken x olmak üzere iki rasgele değişken arasındaki ilişkiyi modeller. Genellikle çok değişkenli birim Gauss $N(0, I)$ olan z için bir ön seçim belirlenir. Bundan sonra x, parametre θ

ile bir sinir ağından türetilen $p_\theta(x \mid z)$ 'den örneklenir. $p_\theta(x \mid z)$ 'nin kesin şekli, görev durumuna göre seçilir. Gerçek sonsal $p_\theta(z \mid x)$ analitik yöntemlerle inatçıdır, ancak eğitim için gereklidir ve genellikle tahminlerde faydalıdır, bu nedenle varyasyon çıkarım teknikleri, sonsal $q_\phi(z \mid x)$ olarak başka bir sinir ağına uyması için kullanılır. Bu sonsalın genellikle $N(\mu_\phi(x), \sigma_\phi^2(x))$ olduğu varsayılır, burada $\mu_\phi(x)$ ve $\sigma_\phi(x)$ sinir ağları tarafından türetilir. VAE'nin mimarisi Şekil 2.27'de gösterilmiştir [65].



Şekil 2.27 VAE mimarisi

2.2.11.5 Daralan Oto Kodlayıcı

Daralan Oto Kodlayıcı (CAE), eğitim setindeki gürültülü bozulmalara karşı sağlamlığı artıran geleneksel AE'nin bir çeşididir. Düzenleme terimi olarak Jacobian'ın Frobenius normu benimsenmiştir. Değişim tespitinde sınıflandırma için sadece kodlanmış özellik temsili kullanıldığından, benek seslerinin etkisini azaltmayı tercih eden yerel olarak değişmez ve sağlam kodlama temsilini geliştirmek için CAE'nin Jacobian terimi ile yapılan daralan ceza kabul edilir [66]. Jacob teriminin düzenlenmesi Denklem 2.36'daki gibidir [67]:

$$J_{cae}(\theta) = \sum_{x \in D_n} (L\left(x, g\left(f(x)\right)\right) + \lambda \,||\, J_f(x)||_F^2) \tag{2.36}$$

burada, $x \in R^{dx}$ girdi, D_n eğitim seti, L yeniden yapılanma hatası, parametreler $\theta = \{ W, W', b_h, b_y, W$ ile W' ağırlık matrisleri, b_h ile b_y önyargı vektörleri ve $g(f(x))$, x'in yeni yapılanmasıdır [67].

2.3 ARIMA

Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli Box ve Jenkins tarafından önerilmiştir [68]. ARIMA modelleri çok sayıda zaman serisi tahmin probleminde kullanılmıştır, çünkü güçlü oldukları, anlaşılması ve uygulaması kolay olduğu için. Ancak,

gelecekteki değerlerin tahminini etkileyen aykırı değerlerde problemler oluşturmaktadır. Stokastik modellerin diğer bir dezavantajı, yüksek dizileridir [69].

Birçok ARIMA modeli vardır. Mevsimsel olmayan genel model ARIMA (p, d, q) olarak bilinir, burada [69]:

AR: p = modelin otoregresyon sırası;

I: d = modeli sabit yapmak için farklılık derecesi;

MA: q = modelin hareketli ortalama boyutunun sırası.

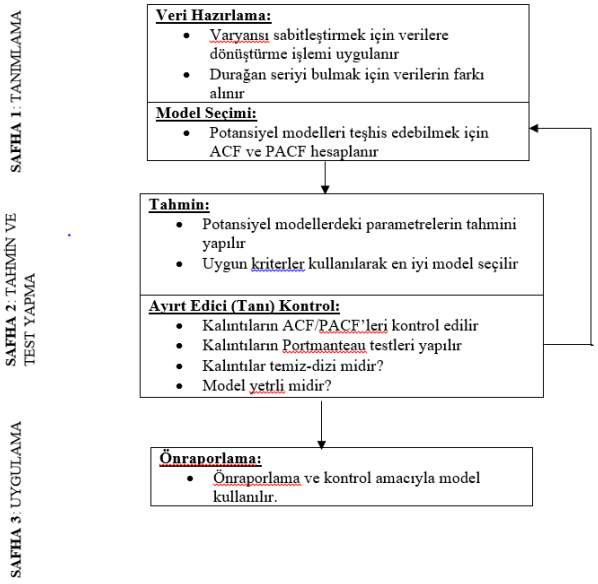
Yukarıdaki gösterimi tanımlayan doğrusal ifade Denklem 2.37'deki gibidir [69]:

$$y_t = \sum_{i=1}^{p} \varphi_i y_{t-i} + \sum_{j=1}^{p} \theta_j e_{t-j} + \epsilon_t \tag{2.37}$$

varyansı dengeleme katsayısı φ_i, i. otoregressif parametresidir, θ_j, j. hareketli ortalama parametresidir ve ϵ_t, t zamanında hata terimidir [69].

ARIMA modelleri mühendislikten ekonomiye kadar çok çeşitli uygulamalarda kullanılır. Güç talebinin tahmini, rüzgar hızı ve borsa değeri davranışı, yani yeterli ölçümle zaman serisi olarak temsil edilebilecek şeyler gibi durumlarda, bu teknikle modellenebilir [69].

ARIMA metoduyla tahmin yapılırken izlenen metodoloji dört adımdan oluşmaktadır. İlk adımda uygun fark derecesi (d) değeri için değişkenlerin durağanlık analizi yapılır, AR (p) ve MA (q) değeri için ise otokorelasyon(Autocorrelation, ACF) ve kısmi otokorelasyon(Partial Autocorrelation, PACF) işlevleri incelenir. İkinci aşamada belirlenen p, d ve q'ya göre ARIMA modeli ortaya konur. Üçüncü aşamada kullanılacak modelin olası olan diğer ARIMA modelleri arasında en iyi model olup olmadığı, modelin hata değerlerinin beyaz gürültü özelliği gösterip göstermediği tespit edilir ve en son ileriye dönük tahmin yapılır [70]. Zaman serisi modeli kurmada Box-Jenkins yaklaşımı Şekil 2.28'de şematik olarak özetlenmiştir [71].



Şekil 2.28 Box-Jenkins Yaklaşımı

2.3.1 Modelin Belirlenmesi

Model belirleme aşamalarını aşağıdaki gibi sıralamak mümkündür [71]:

1. Örneklem değerlerinin zaman serisi grafiği çizilir. Aykırı değerler tespit edilir. Eğer varyansın sabitliği için işlem gerekiyorsa, varyansın sabitliği gerçekleşene dek dönüştürme işlemi sürdürülür.
2. ACF'ler ve PACF'ler hesaplanır. Eğer ACF'ler ortadan kalkmıyorsa seri durağan-dışıdır. Bu durumda durağanlık sağlanana kadar fark alınır. Farkı alınan seriler için ARIMA modeli ortaya konur.
3. Durağanlığa ulaşıldığında belirli bir kalıp görülüyorsa ACF'ler incelenir. Bu durumda
    a) Bir MA(q) sürecine ilişkin ACFler $k>q$ için $\rho_k = 0$'dır veya gecikme q'dan sonra anlamlı ACF'ler yoktur. PACF'ler bir süre daha anlamlı olmaya devam ederler. ACF fonksiyonunun kesilme noktasını belirleme için örneklem ACF'ler $\pm \frac{2}{\sqrt{T}}$ ile karşılaştırılır.
    b) Bir AR(p) sürecine ilişkin PACF'ler $k>p$ için $\phi_{kk} = 0$'dır veya gecikme p'den sonra anlamlı PACF yoktur. ACF'ler bir süre daha anlamlı olmaya devam

ederler. PACF fonksiyonunun kesilme noktasını belirlemek için $\pm\frac{2}{\sqrt{T}}$ ile karşılaştırılır.

c) Ne ACF'ler ne de PACF'ler belirli bir noktada durmuyorsa bu durumda ARMA modeli uygun olacaktır. AR ve MA bileşenlerinin derecesi ACF ve PACF durumlarına göre belirlenir.

2.3.2 Parametre Tahminleri

Uygun bir zaman serisi modeli muvakkat olarak ortaya konduktan sonra, sürecin parametreleri tahmin edilir. Eğer pür bir AR süreci ortaya konmuşsa parametreler en küçük kareler yöntemi vasıtasıyla tahmin edilirler. Herhangi bir MA süreci ortaya konmuşsa maksimum benzerlik veya yine en küçük kareler metodu uygulanır. Her ikisi aynı anda modelde yer alıyorsa doğrusal olmayan optimizasyon metodu uygulanır [71].

ARIMA modelleri tahminleri etkin bilgisayar programlarından yararlanılır. Bu programlarda, optimum parametre değerleri elde edilmeye çalışılmaktadır [71].

2.3.3 Ayırt Edici Kontrol

Model yeterliliği için başvurulan ayırt edici (teşhis) kontrol testleri genelde kalıntı analizleri ve modelin aşırı uyumunu içerir. Burada aşırı uyum ile eğer bir ARIMA(p,d,q) modeli belirlenmiş ve tahmin edilmiş ise, bir ARIMA(p+1,d,q) ve bir ARIMA(p,d,q+1) modeli tahmin edilir ve ilaveten parametrelerin anlamlılıkları kontrol edilir. Eğer doğru model ARIMA(p,d,q) ise, büyük modeller tarafından sunulan ilave parametreler sıfırdan anlamlı bir şekilde farklı olmayacaklardır. Dolayısıyla tanımlamada bir ya da daha fazla değişkenin ilave edilmesinin etkisi test edilerek ortaya konulmalıdır [71].

Modelin kalıntıları test süreci için önemli bilgiler sağlar eğer uydurulan model yeterli ise kalıntılar yukarıda da ifade edildiği gibi yaklaşık olarak temiz-dizidir. Başka bir ifadeyle ARIMA(p,d,q) modeli veri-üretme sürecini yeteri düzeyde gösteriyorsa, kalıntılar korelasyonsuz ve rassal olacaklardır [71].

2.3.4 Model Seçim Kriterleri

2.3.4.1 Standart Belirlenim Katsayısı - R^2

Standart Belirleme Katsayısı (R^2) bağımsız değişken(ler)'den öngörülebilen bağımlı değişken içindeki varyansın oranıdır. En genel tanımı Denklem 2.38'deki gibidir.

$$R^2 = 1 - \frac{SS_{gör}}{SS_{top}} \tag{2.38}$$

Burada; $SS_{gör}$, göreceli kareler toplamı, SS_{top}, kareler toplamını ifade etmektedir.

2.3.4.2 Akaike Bilgi Kriteri

Akaike bilgi kriteri (AIC) entropi kavramına dayanan titiz bir bilgi analizi çerçevesi kullanır. AIC'nin arkasındaki itici güç, modelin karmaşıklığını, örnek verilere uygunluğuyla birlikte incelemek ve ikisi arasındaki dengeyi sağlayan bir ölçüt üretmektir. Denklem 2.39'daki gibi formüle edilir [72]:

$$AIC: c_n(k) = 2 \times \left(\frac{k}{n}\right) - 2 \times \ln(L)/n \tag{2.39}$$

L olabilirlik fonksiyonu, k modeldeki parametre sayısı ve n gözlem sayısıdır [72].

2.3.4.3 F-İstatistiği

ARIMA model belirlemede model seçim kriteri olarak başvurulan ve daha ziyade bir regresyon tekniği olarak bilinen başka bir kriter F-istatistiği yaklaşımıdır. Dolayısıyla otoregresif (AR) zaman serisi modellerinin seçiminde uygulama kolaylığı ve basitliğinden ötürü çok sık kullanılır [71].

Hesaplanan kısmi otokorelasyonların istatistiksel olarak anlamlı olup olmadığı, tahmin edilen katsayıların sayısı birden fazla isei F-istatistiğne başvurulur. Uygulanacak test istatistiği için genel bir sonuç çıkarılabilir. Şöyle ki, bütüncül model olarak AR(p), kısıtlı model olarak da AR(m) düşünüldüğünde, Wald F-istatistiği şu Denklem 2.40'taki gibi hesaplanır [71]:

$$F^* = \frac{(SSR_r - SSR_u)/(u-m)}{SSR_u/(T-u)} \tag{2.40}$$

Hipotezler aşağıdaki gibi olsun:

H_0: $\phi_{m+1}= \phi_{m+2}=\ldots= \phi_p=0$

H_1: ϕ_i'lerden en az biri farklıdır(i=m+1,…,p)

Burada, SSR_r = kısıtlı AR(m) modelinin hata kareler toplamını, SSR_u = bütüncül AR(p) modelinin hata kareler toplamını gösterir. Eğer $F^{*}>F^{c}_{u-m,T-u}$ (seçilen anlamlılık düzeyinde) ise sıfır hipotezi red edilir. F^c, u-m ve T-u serbestlik derecesiyle F dağılımına sahiptir. Diğer durumda serinin AR(m) olduğuna karar verilir [71].

2.3.4.4 Bayes Bilgi Kriteri

Bayes bilgi kriteri (BIC) veya Schwarz kriteri (ayrıca SBC, SBIC) sonlu modeller arasında model seçimi için kullanılan bir kriterdir. Kısmen, olasılık fonksiyonuna dayanır ve Akaike bilgi kriteri (AIC) ile yakından ilgilidir [73].

Modelleri uydururken, olasılığı, parametreler ekleyerek artırmak mümkündür, ancak bunu yapmak aşırı uydurma ile sonuçlanabilir. BIC, bu sorunu, modeldeki parametre sayısı için bir ceza terimi getirerek çözer. BIC'de ceza terimi AIC'den daha büyüktür [73].

BIC Denklem 2.41'deki gibi tanımlanır [73]:

$$BIC = n\{\ln(\hat{\sigma}_e^2)\} + k\{\ln(n)\} \tag{2.41}$$

n: gözlem sayısı, k: tahmini edilecek serbest parametrelerin sayısı, $\hat{\sigma}_e^2$: hata sapmasıdır [73].

2.4 LİTERATÜR TARAMASI

Elektrik sektörü ile ilgili literatürde birçok tahmin çalışması bulunmaktadır. Bu çalışmalardan bazıları Tablo 2.3'te gösterilmektedir.

Tablo 2.3 Elektrik-Literatür Taraması

Yazarlar	Metodoloji	Çalışmanın Özeti
Catalâo vd. [74]	Sinir Ağı Yaklaşımı	Çalışmada kısa vadeli elektrik fiyatlarının tahmini için bir sinir ağı yaklaşımı önerilmektedir. Bir sonraki haftanın elektrik fiyatlarının tahmininde, üç katmanlı bir ileri beslemeli sinir ağı kullanılmıştır. İspanya ve Kaliforniya'nın elektrik piyasalarından elde edilen sonuçlar rapor edilerek, önerilen sinir ağı yaklaşımı modelinin fiyat tahmininin doğruluğu değerlendirilmiştir. Bahar ayları için önerilen tahmin modeli, İspanyanın elektrik fiyatları için %5,36, Kaliforniya'nın elektrik fiyatları için %3,09 MAPE değeri elde edilmiştir. Yaklaşım ARIMA ve Naive Bayes yöntemleriyle de karşılaştırılmış; önerilen model ile daha iyi MAPE değeri elde edilmiştir.
Lora vd. [75]	Ağırlıklı En Yakın Komşu Yöntemi	Çalışmada, en yakın komşu metodolojisine dayanarak ertesi günün elektrik piyasası fiyatlarını tahmin etmek için bir teknik sunulmuştur. İspanyanın saatlik elektrik fiyat verileri kullanılmıştır. Parametre optimizasyonu yapılıp; Nöro-Bulanık Sistem, Yapay Sinir Ağları ve Dalgacık ARIMA hibrit modelleriyle karşılaştırılmıştır. MRE değerlerine göre önerilen ağırlıklı en yakın komşu modeli daha iyi bir sonuç vermiştir.
Ertugrul [76]	Tekarlayan Aşırı Öğrenme	Çalışmada, tekrarlayan aşırı öğrenme makinesi (RELM), elektrik yükünü tahmin etmek için yeni bir yaklaşım olarak önerilmiştir. RELM'de, tek gizli katman ileri beslemeli sinir ağ için bir eğitim yöntemi olan aşırı öğrenme makinesi (ELM), tek bir gizli katman Jordan tekrarlayan sinir ağını eğitmek için uyarlanmıştır. Önerilen yaklaşımı değerlendirmek ve doğrulamak için Elektrik Yükü Şemaları 2011-2014 arası günlük veriler zaman serisi olarak kullanılmıştır. Elde edilen sonuçlar geleneksel ELM, lineer regresyon, genelleştirilmiş regresyon sinir ağı ve diğer bazı popüler makine öğrenme yöntemleri ile karşılaştırılmıştır. RELM'in elde ettiği RMSE değeri, diğer kullanılan makine öğrenme yöntemleri ile elde edilen sonuçlardan iki kat daha iyi sonuç verdiği tespit edilmiştir.
Chen vd. [77]	Destek Vektör Regresyon	Talep Yanıtı olayından iki saat önceki ortam sıcaklığına sahip girdi değişkenleri olan bir Destek Vektör Regresyon (SVR) tahmin modeli önerilmiştir. Yöntemi test etmek için örnek veriler olarak dört tipik ofis binası için elektrik yükleri kullanılmıştır. Çalışma takvimi ve hava faktörüne ait bazı değişkenler, modelin girdisi olarak kullanılmıştır. Model tahmin sonuçlarını analiz ettikten sonra, SVR modelinin yedi farklı geleneksel tahmin modeline

		kıyasla, kısa vadeli yük tahmininde daha yüksek derecede bir tahmin doğruluğu ve istikrarı sunduğu tespit edilmiştir.
Liv vd. [78]	- Genelleştirilmiş Regresyon Sinir Ağı -Meyve Sineği Algoritması	Çalışmada, Genelleştirilmiş Regresyon Sinir Ağı (GRNN) yıllık elektrik yükü tahmini için kullanılmıştır. GRNN'nin güç yükü tahmini için kullanılmasında uygun yayılma parametresini belirlemek için Meyve Sineği algoritması kullanılmıştır. Önerilen bu hibrid model, varsayılan parametrelere sahip GRNN, hibrid GRNN-Parçacık Sürü Optimizasyonu ve en küçük kareler doğrusal regresyon modellerinden daha iyi sonuç verdiği tespit edilmiştir.
Niu vd. [79]	Destek Vektör Makineleri Karınca Kolonisi Optimizasyonu	Çalışmada, Destek Vektör Makinesi ve Karınca Kolonisi Optimizasyonu kullanılarak güç yükü tahmini için bir sistem oluşturulmuştur. Karınca Kolonisi Optimizasyon yöntemi, büyük miktarda veriyi işlemek ve gereksiz bilgileri elemek için kullanılmıştır. Daha sonra, bulanık kaba veri azaltma işleminde optimal özellikli alt kümeleri bulmak için uygulanmıştır. Hava durumu ve günlerle ilgili öznitelikler kullanılmıştır. Önerilen yöntem, Basit Destek Vektör Makinesi ve Basit Yapay Sinir Ağları yöntemlerine göre daha iyi sonuç verdiği tespit edilmiştir.
Pai ve Hong [80]	Tekrarlayan Destek Vektör Makineleri Genetik Algoritma	Çalışmalarında, elektrik yükünü tahmin etmek için Genetik Algoritma ile birlikte Tekrarlayan Destek Vektörü Makinelerini (RSVMG) önermişlerdir. Genetik algoritmalar, Destek Vektör Makinelerinin serbest parametrelerini belirlemek için kullanılmıştır. Daha sonra, önerilen RSVMG modelinin performansını göstermek için Tayvan'dan elektrik yükü veri örneklerini kullanmışlardır. Ampirik sonuçlar, önerilen modelin, SVM, yapay sinir ağı (YSA) ve regresyon modellerini geride bıraktığı bulunmuştur.
Dedinec vd. [81]	Derin İnanç Ağları	Çalışmalarında, elektrik yükü tahmini için çok sayıda kısıtlı Boltzmann makinesinden oluşan bir Derin İnanç Ağları (DBN) kullanımışlardır. Çalışmada katmanlar halinde denetimsiz eğitim yöntemini, denetimli bir geri yayılma eğitim yöntemi kullanarak parametrelerin ince ayarlanması yapılmıştır. DBN modeli, 2008-2014 döneminde Makedonya'nın saatlik elektrik tüketimi verilerine dayanarak kısa vadeli elektrik yükü tahminine uygulanmıştır. Elde edilen sonuçlar, en son gerçek verilerle karşılaştırmanın yanında; tipik bir ileri beslemeli çok katmanlı algılayıcı sinir ağından ve Makedon sistem operatörü (MEPSO) tarafından sağlanan tahmin verileriyle karşılaştırılmıştır. DBN kullanılırken, Ortalama mutlak yüzde hata (MAPE)

		değeri, MEPSO sonuçlarına kıyasla %8,6'ya ve günlük tepe noktası tahmini için MAPE değeri %21'e kadar azaltılmıştır.
Ju ve Hong [82]	Destek Vektör Regresyonu Kaotik Yerçekimi Arama Algoritması	Çalışmalarında, Kaotik Yerçekimi Arama Algoritması (CGSA) ile SVR tabanlı bir elektrik tahmin modeli önermişlerdir. Önerilen CGSA, mevcut en iyi çözümü aramak ve iyileştirmek için orijinal GSA'nın yinelemesinde lojistik kaotik haritalama işleviyle Kaotik Yerel Arama kullanılmıştır. Ek olarak, mevsimsel elektrik eğilimini ele almak için mevsimsel mekanizmalar da uygulanmıştır. Önerilen SSVRCGSA modelinin tahmin performansını göstermek için sayısal bir örnek kullanılmıştır. Tahmin sonuçları, önerilen modelin ARIMA ve SVR-Benzetimli Tavlama modellerinden daha doğru tahmin sonuçları verdiği bulunmuştur.
Taylor [83]	ARMA Üstel Düzleştirme Holt-Winters	Çalışmada, çevrimiçi kısa vadeli yük tahmini için çift mevsimsel ARMA, çift mevsimsellik için üstel düzleştirme uyarlamalı Holt-Winters ve bir üstel düzleştirme yöntemlerini kullanmıştır. Çok yıllık yük verilerinde, gün içi ve hafta içi döngülere ek olarak, yıl içi mevsimsel döngünün de belirgin olduğu belirtilerek üçlü mevsimsel yöntem kullanılmıştır. Altı yıllık İngiliz ve Fransız verilerini kullanılarak, gün öncesi üçlü mevsimsel yöntemlerin çift mevsimsel yöntemlerden ve aynı zamanda tek değişkenli bir sinir ağı yaklaşımından daha iyi performans gösterdiği bulunmuştur.
Bianco vd. [84]	Çoklu Lineer Regresyon	Çalışmalarında, 2030'a kadar İtalya'da elektrik tüketimini tahmin etmek için girdi değişkenleri olarak GSYİH ve popülasyon kullanarak Çoklu Lineer Regresyonlar sunmuşlardır. Model sonuçları resmi İtalyan makam tahminleri ve enerji alanında aktif olan kamu / özel araştırma kurumlarının tahminleri ile karşılaştırılmıştır. Farklı tahminler arasında iyi bir uyum olduğu tespit edilmiştir.
Akay ve Atak [11]	Gri Tahmin Modeli	Çalışmalarında, Türkiye'nin toplam ve endüstriyel elektrik tüketimini tahmin etmek için yuvarlanma mekanizması (GPRM) yaklaşımıyla Gri tahmin yöntemini önermişlerdir. Sonuçlar, önerilen yaklaşımın Türkiye Enerji ve Tabii Kaynaklar Bakanlığının Enerji Talebi Analiz Modelinden daha doğru tahmin ettiği bulunmuştur.
Rahman vd. [85]	Tekrarlayan Sinir Ağı	Çalışmalarında, ticari ve konut binalarında bir saatlik dilimdeki elektrik tüketiminin orta ila uzun vadeli elektrik tahminlerini yapmak için tekrarlayan bir sinir ağı modeli sunulmuştur. Binaların toplam elektrik tüketimini tahmin

		etmek için önerilen model, Çok Katmanlı Algılayıcılar metoduna göre doğruluk oranı daha yüksek bulunmuştur.
Chen vd. [86]	Gravitasyonel Arama Algoritması Cuckoo Optimizasyon Algoritması Yapay Sinir Ağları	Çalışmalarında, aylık elektrik taleplerini tahmin etmek için Gravitasyonel Arama Algoritması (GSA) ve Cuckoo Optimizasyon Algoritması (COA) dahil olmak üzere farklı sezgisel algoritmalar tarafından eğitilmiş Yapay Sinir Ağları (YSA) kullanmışlardır. Çalışmalarında kullanılan ampirik veriler, yağmurlu zaman, sıcaklık, nem, rüzgar hızı vb. dahil olmak üzere elektrik talebini etkileyen çevresel ve tarihsel verilerdir. Önerilen modeller Vietnam, Hanoi'ye uygulanmıştır. Çalışmalarında, ANN-COA modelinin diğerlerinden daha iyi performans gösterdiği ve geleneksel yöntemlerden daha doğru tahminler sunduğu ileri sürülmüştür.
Bedi ve Toshniwal [87]	Uzun-Kısa Süreli Bellek Ağı	Çalışmalarında, uzun vadeli tarihsel bağımlılıkları göz önüne alarak elektrik talebini tahmin etmek için derin öğrenme temelli bir çerçeve önermişlerdir. Uzun Kısa Süreli Bellek Ağı çoklu girdi çoklu çıktı modelleri, mevsim, gün ve aralık verilerine göre elektrik talebini tahmin etmek için eğitilmiştir. Bu çalışmada, tahmin sonuçlarını geliştirmek için hareketli pencere tabanlı aktif öğrenme kavramı da dahil edilmiştir. Önerilen yaklaşımın uygulanabilirliğini ve etkililiğini göstermek için, Hindistan Birlik Bölgesi Chandigarh'ın tüketim verilerine uygulanmıştır. Önerilen yaklaşımın tahmin sonuçlarının performansı, Yapay Sinir Ağı, Tekrarlayan Sinir Ağı ve Destek Vektörü Regresyon modelleri ile karşılaştırılarak değerlendirilmiştir.
Al Musaylh vd. [88]	MARS ARIMA SVR	Çalışmalarında, son kullanıcılara olan elektrik talebinin artmaya devam ettiği Avustralya'nın ikinci büyük devleti olan Queensland'e odaklanmışlardır. Tahmin çalışması, Çok Değişkenli Uyarlanabilir Regresyon Eğrileri (MARS), Destek Vektör Regresyon (SVR) ve Otoregresif Entegre Hareketli Ortalama (ARIMA) modellerine dayanmaktadır. MARS ve SVR, model girdilerini belirlemek için kısmi otomatik korelasyon işlevi, önemli (gecikmeli) girdileri ayırt etmeye yarayan eğitim döneminde tarihsel (toplanmış alan) G verilerine uygulanmıştır. Öte yandan, tek değişkenli G verileri tek değişkenli ARIMA modelini geliştirmek için kullanılmıştır. Öngörüler, istatistiksel olarak anlamlı olan gecikmeli girdilere ve öngörme modellerini oluşturmak için eğitim (% 80) ve test etme (% 20) alt gruplarına ayrılmıştır. G tahminlerinin ölçülen G verilerine göre doğruluğu, Pearson Momentler Çarpımı Korelasyon katsayısı (r), Ortalama Ortalama Karekökü (RMSE) ve Ortalama Mutlak Hata (MAE) gibi istatistiksel ölçütler kullanılarak değerlendirilmiştir. MARS ve SVR

		modelleri, ARIMA modeline kıyasla Avustralya'daki Queensland'deki kısa vadeli elektrik tahmini için daha uygun olduğu bulunmuştur.

Derin öğrenme yöntemleri ile yapılan tahmin Tablo 2.4'te gösterilmektedir.

Tablo 2.4 Derin Öğrenme Tahmin Çalışmaları

Yazarlar	Metodoloji	Çalışmanın Özeti
Zhao vd. [89]	Uzun - Kısa Süreli Bellek Ağı	Uzun- Kısa Süreli Bellek (LSTM) ağına dayalı bir trafik tahmin modeli önerilmiştir. Dakikalık zaman serisi ile tahmin modeli oluşturulmuştur. Veriler Pekin Trafik Yönetimi Bürosundan alınmıştır. Önerilen LSTM ağında, birçok bellek biriminden oluşan iki boyutlu bir ağ üzerinden trafik sistemindeki zamansal-uzamsal korelasyonu göz önünde bulundurulmuştur. Önerilen modelin, ARIMA, SVM, RBF, SAE ve RNN yöntemlerine göre daha iyi sonuçlar verdiği tespit edilmiştir.
Qing ve Niu [90]	Uzun - Kısa Süreli Bellek Ağı	Çalışmada, hava tahmini verilerini kullanarak saat başı ileriki günün güneş ışını kestirimi için bir güneş tahmin şeması önerilmiştir. Önerilen tahmin modeli, aynı günün ardışık saatleri arasındaki bağımlılığı hesaba katarak uzun kısa süreli bellek (LSTM) ağları kullanılarak eğitilmiştir. Önerilen model, lineer regresyon ve geri yayılma algoritmasının kullanıldığı çok katmanlı geri beslemeli sinir ağlarıyla (BPNN) karşılaştırılmıştır. Önerilen model, RMSE ölçütüne göre, BPNN'den %18.34 daha doğru sonuç verdiği bulunmuştur.
Zhao vd. [91]	Torbalama Yöntemi Gürültü Giderici Oto Kodlayıcılar	Çalışmada petrol fiyatlarını tahmin etmek için derinlemesine bir öğrenme topluluğu yaklaşımı önerilmiştir. Gürültü giderici oto kodlayıcılar sinir ağı modeli ile torbalama topluluk yöntemi kullanılmıştır. Ampirik çalışmada, West Texas Intermediate ham petrol fiyat serileri incelenmiş ve eksojen değişkenler olarak 198 ekonomik seri kullanılmıştır. Önerilen model, DA, MAPE ve RMSE ölçütlerine göre, Rastgele Yürüyüş, Markov Rejim Değişim modeli, Destek Vektör Makinesi ve İleri Beslemeli Sinir Ağlar yöntemlerine göre daha iyi sonuçlar vermiştir.
Zhang vd. [92]	Derin Boltzmann Makineleri	Çalışmada, kısa ve uzun vadeli rüzgar hızı tahmini için, derin öğrenme tekniği olan derin Boltzmann makinesi (PDBM) kullanılmıştır. Önerilen derin öğrenme modeli ile rüzgar hızı verilerinin düşük seviye özelliklerinden soyutlanan yüksek seviye özellikleri analiz edilmiştir. Önerilen PDBM modelinin değerlendirilmesi, gerçek rüzgar hızı veri setlerine dayanan hem bir saat sonrası hem de gün öncesi tahmin

		deneyleriyle tasvir edilmiştir. Önerilen modelin, AR, ANFIS ve SVR yöntemlerine göre %10 oranında daha iyi sonuçlar verdiği bulunmuştur.
Ke vd. [93]	Hibrit Evrişimli Uzun-Kısa Süreli Bellek Ağı (Fcl-Net)	Çalışmalarında, kısa vadeli yolcu talep tahminleri için, Hibrit Evrişimli Uzun-Kısa Süreli Bellek Ağı (FCL-Net) adlı bir derin öğrenme yaklaşımı önermişlerdir. Önerilen bu model ile uzaysal bağımlılıklar, geçici bağımlılıklar ve dışsal bağımlılıklar aynı anda dikkate alınmıştır. Önerilen derin öğrenme yaklaşımı Çin'in Hangzhou kentinde bir sürüş servis platformu altında yolcu talebinin kısa vadeli tahminine uygulanmıştır. FCL-Net modelinin, klasik zaman serisi tahmin modelleri ile Yapay sinir ağları, XGBoost, LSTM ve CNN gibi modern yaklaşımlardan daha iyi tahmin performansı gösterdiği bulunmuştur.
Alzahrani vd. [94]	Derin Tekrarlayan Sinir Ağları	Çalışmada, Derin Tekrarlayan Sinir Ağları kullanılarak güneş ışınımı tahmini yapılmıştır. Tahmin çalışması için Kanada'daki doğal kaynaklardan elde edilen veriler kullanılmıştır. Güneş açıları ile ilgili bazı özellikler girdi olarak kullanılmıştır. Önerilen model, ileri beslemeli sinir ağlar ve destek vektör regresyon modellerinden daha iyi sonuçlar verdiği bulunmuştur.
Suryanarayana vd. [95]	Derin Sinir Ağları	Çalışmada, ısı yük tahmini için lineer, ridge ve lasso regresyon tahmin modelleri ile derin sinir ağları yöntemi karşılaştırılmıştır. Linner, ridge ve lasso regresyon modelleri ile yapılan tahmin çalışmasında öznitelik seçimi uygulanmıştır. Elde edilen sonuçlara göre derin sinir ağları modeli daha iyi sonuçlar verdiği bulunmuştur. Yöntemler farklı iki bölgede uygulanmış ve karşılaştırılmıştır.
Law vd. [96]	Uzun- Kısa Süreli Bellek Ağı	LSTM kullanılarak, aylık Macau turist varış hacimlerini tahmin etme çalışması yapılmıştır. Derin öğrenme modeli, SVR, ARIMA, ANN ve bunlar arasındaki hibrit modellerden daha iyi sonuçlar verdiği bulunmuştur. Önerilen derin ağ modeli ile uygulayıcılara, çeşitli turist talep tahmin faktörleri ve turist varış hacimleri arasındaki ilişkileri inceleme olanağı sunduğu belirtilmiştir.
Hwangbo vd. [97]	Derin Sinir Ağları	Çalışmada, arz-talep tahmin modeli ve derin-öğrenme (DL) algoritmaları kullanarak, hidrojen bazlı, kendi kendine yeten bir entegre yenilenebilir elektrik şebekesinin (HySIREN) matematiksel bir modelini geliştirmişlerdir. Önerilen modeli, Kore Cumhuriyeti Jeju Adası vaka

		çalışmasında uygulamışlardır. Önerilen model ile toplam çevresel maliyetlerin yaklaşık %64,5'i elimine edilmiştir.
Huang ve Kuo [98]	Evrişimsel Sinir Ağları Uzun-Kısa Süreli Bellek Ağı	$PM_{2.5}$ konsantrasyonunu izlemek ve tahmin etmek için, Evrişimsel Sinir Ağı (CNN) ve Uzun-Kısa Süreli Bellek Ağı (LSTM) hibrit olarak kullanılarak $PM_{2.5}$ tahmin sistemine uygulamışlardır. Her algoritmanın genel performansını karşılaştırmak için MAE, RMSE, Pearson korelasyon katsayısı ve Uzlaşma Endeksini kullanmışlardır. Önerilen CNN-LSTM modelinin tahmin doğruluğu diğer yöntemlere göre daha yüksek olduğu bulunmuştur. Model, kümülatif yağmur saatleri, kümülatif rüzgar hızı ve $PM_{2.5}$ konsantrasyonu gibi tarihsel verilerle geliştirilmiştir.
Zheng vd. [99]	Derin İnanç Ağları	Çalışmada, döviz kuru (INR/USD ve CNY/USD) tahmini için derin inanç ağları kullanılmıştır. DBN parametreleri optimize edilmiştir. Önerilen modeli, ileri beslemeli sinir ağları ile karşılaştırmışlardır. MAPE performans ölçütüne göre DBN modelinin daha iyi sonuç verdiğini bulmuşlardır.
Jiang vd. [100]	Genetik Algoritma Derin Sinir Ağları	Çalışmada, hastaların ayakta tedavi bölümünde farklı ana kaynaklar olan taleplerini tahmin etmek için genetik algoritma ve derin sinir ağlarını birleştiren hibrit bir metodoloji kullanmışlardır. Genetik algoritma öznitelik seçimi için kullanılmıştır. Girdi olarak takvime dayalı faktörler ile meteorolojik faktörler kullanmışlardır. Önerilen hibrit model, MLR, ARIMAX ve YSA ile karşılaştırılmıştır. Önerilen modelin performansı, diğer modellerin performansına göre çok daha üstün bulunmuştur.
Wang vd. [101]	K-Ortalamalar Derin İnanç Ağları	Çalışmada, derin inanç ağı modeli geliştirerek rüzgar enerjisi tahmini yapmışlardır. Girdi olarak, sayısal hava tahmin verilerini kullanmışlardır. Hava tahmin verilerinin çok büyük olmasından dolayı; tahmin doğruluğunu en çok etkileyenler k-ortalamalar analizi ile seçilmiştir. DBN modeli, Geri yayılım sinir ağı (BP) ve Morlet dalgacık sinir ağı (MWNN) ile karşılaştırılmıştır. Sonuçlarda DBN modelinin, diğer tahmin modellerinden %44 daha doğru tahmin ettiğini bulmuşlardır.
Kim ve Won [102]	LSTM GARCH	Çalışmada, LSTM modelini çeşitli genelleştirilmiş otoregresif koşullu değişkenli (GARCH) tipi modellerle birleştiren hisse senedi fiyatı oynaklığını tahmin etmek için yeni bir hibrit uzun kısa süreli bellek (LSTM) modeli önerilmiştir. LSTM'yi bir ila üç GARCH tipi modelle birleştirip önerilen hibrid modelleri denemek için KOSPI 200 endeks verilerini kullanmışlardır. GARCH, üstel GARCH, üstel ağırlıklı

		hareketli ortalama, derin bir ileri beslemeli sinir ağı (DFN) ve LSTM gibi tek modeller ve hibrid DFN-GARCH modellerini analiz ederek performanslarını önerilen yöntemle karşılaştırmışlardır. LSTM modelini üç GARCH tipi hibrid modeli olan GEW-LSTM'nin, ortalama mutlak hata (MAE), ortalama kare hatası (MSE), hetero-esneklik ayarlı MAE (HMAE) açısından en düşük tahmin hatalarına sahip olduğu bulunmuştur.

ARIMA yöntemiyle ilgili yapılan çalışmalar Tablo 2.5'te gösterilmektedir.

Tablo 2.5 ARIMA Yöntemiyle Tahmin Çalışmaları

Yazarlar	Metodoloji	Çalışmanın Özeti
Cadenas ve Rivera [103]	ARIMA YSA	Çalışmada, Baja California'daki Isla de Cedros'ta, rüzgar hızı tahmini yapılmıştır. Kullanılan zaman serisi, yaklaşık bir ay boyunca farklı sahalarda gerçekleştirilen ölçümlerden doğrudan elde edilen ortalama saatlik rüzgar hızı verileridir. Rüzgar hızı tahmini yapmak için, ARIMA ve YSA hibrit modeller geliştirmişlerdir. ARIMA modelleri ilk olarak zaman serilerinin rüzgar hızı tahminini yapmak için kullanılmış ve daha sonra elde edilen hatalarla YSA'nın, ARIMA tekniğinin tanımlayamadığı doğrusal olmayan eğilimlerdeki bu hataları azalttığı belirtilmiştir. Hibrit modeller geliştirildikten sonra, rüzgar hızı tahminini yapmak için sahaların her biri için örneklemden 48 veri kullanılmış ve sonuçlar ARIMA ve ayrı çalışan YSA modelleriyle karşılaştırılmıştır. Elde edilen sonuçlarda, Hibrit modellerin incelenen üç bölgedeki rüzgar hızlarını ARIMA ve YSA modellerinden daha yüksek doğrulukla tahmin ettiği belirtilmiştir.
Manoh ve Madhu [104]	ARIMA	Çalışmada, Hindistan'daki şeker kamışı üretimini tahmin etmek için ARIMA modeli kullanılmıştır. En iyi ARIMA modeli ARIMA (2,1,0) olarak bulunmuştur. ARIMA (2,1,0) modeli ile 5 yıllık şeker kamışı üretimi tahmin edilmiştir. Tahmin sonuçlarının, yıllık şeker kamışı üretiminin yıllık ortalama %3'lük bir ortalama büyüme hızıyla sürekli büyüyeceğini gösterdiği belirtilmiştir.
Wang vd. [105]	ARIMA EEMD	Yıllık hidrolojik deney zaman serisi tahmini için, Topluluk Ampirik Mod Ayırma (EEMD) ile birlikte ARIMA modelini kullanmışlardır. İlk olarak, orijinal yıllık akış zaman serileri, sonlu ile genellikle az sayıda iç mod fonksiyonlarına (IMF'lere) ayrıştırılır ve veri özelliklerine derinlemesine bir bakış için EEMD tekniği kullanılır. Daha sonra her bir IMF bileşeni ve kalanlar, sırasıyla bir ARIMA modeli ile tahmin edilmiştir.

Barak ve Sadegh [106]	ARIMA ANFIS	İran'daki yıllık enerji tüketimi 3 ARIMA-ANFIS modeli kullanılarak tahmin edilmiştir. Birinci modelde, ARIMA, doğrusal olmayan kalanların, ızgara bölümleme, alt kümeleme ve bulanık küme araçlarını içeren 6 farklı ANFIS yapısı tarafından tahmin edildiği 4 girdi özniteliğiyle uygulanır. İkinci modelde, ANFIS tahmini için, 4 girdi özniteliğine ek olarak, ARIMA tahminleri girdi olarak kullanılmıştır. Üçüncü modelde veri yetersizliği ile ilgili olarak ikinci model AdaBoost veri çeşitlendirme modeliyle uygulanmış ve yeni bir topluluk metodolojisi sunulmuştur. Sonuçlarda, önerilen hibrid desenlerin, tek bir ARIMA ve ANFIS modelinin enerji tüketimini tahmin etmedeki doğruluğunu artırdığı, üçüncü model ise kullanılan çeşitlendirme modelinin diğerlerinden daha iyi davrandığı bulunmuştur. Önerilen model başka çalışmalardaki hibrid modelleriyle karşılaştırılmıştır.
Qin vd. [107]	ARIMA Derin İnanç Ağları Parçacık Sürü Optimizasyonu	Kırmızı gelgit tahmini için ARIMA ve DBN'yi birleştiren bir karma model önerilmiştir. ARIMA modeli, farklı kıyı bölgelerindeki her çevresel faktör için zamansal korelasyonu ve mekansal heterojenliği tanımlamak için inşa edilmiştir. DBN, çevresel faktörler ve kırmızı gelgit biyokütlesi arasındaki karmaşık doğrusal olmayan ilişkiyi yakalamak ve kırmızı gelgit uyarısını önceden gerçekleştirmek amacıyla kullanılmıştır. Model eğitimi hızını arttırmak için parçacık sürüsü optimizasyonunu (PSO) kullanmışlardır. 2008-2014 döneminde Zhoushan kıyı bölgesinde ve Wenzhou kıyı bölgesinde toplanan gemi izleme verileri, deneysel veri seti olarak kullanılmıştır. Önerilen ARIMA-DBN modeli ile MAPE değerini %17,21 bulmuşlardır.
Jiang vd. [108]	ARIMA	2016'dan 2030'a kadar Çin'in kömür fiyatı, tüketimi ve yatırımını tahmin etmek için ARIMA tahmin modelini kullanmışlardır. Kömür fiyatı, tüketimi ve yatırımı için en uygun modeller her tahmin adımında seçilmiştir. Ampirik sonuçlar, yıllık ortalama kömür tüketimi ve yatırım oranının, tahmin döneminde dalgalı davranış sergileyen kömür fiyatı hariç, 2016 ve 2030 yılları arasında azalacağı bulunmuştur.
Amini vd. [109]	ARIMA	Çalışmada, geleneksel elektrik yükünün (CEL) ve EV (CDE) otoparklarının şarj taleplerinin tahmininde ARIMA yöntemini kullanmışlardır. Günlük sürüş düzenleri ve mesafeleri, modelin girdileri olarak alınmışlardır. EV şarj talebinin önerilen yük tahmincisinin doğruluğu üzerindeki etkisi iki yaklaşımda incelemişlerdir: (1) CEL + CDE için entegre tahminci ve (2) bağımsız olarak CEL ve CDE'yi hedef

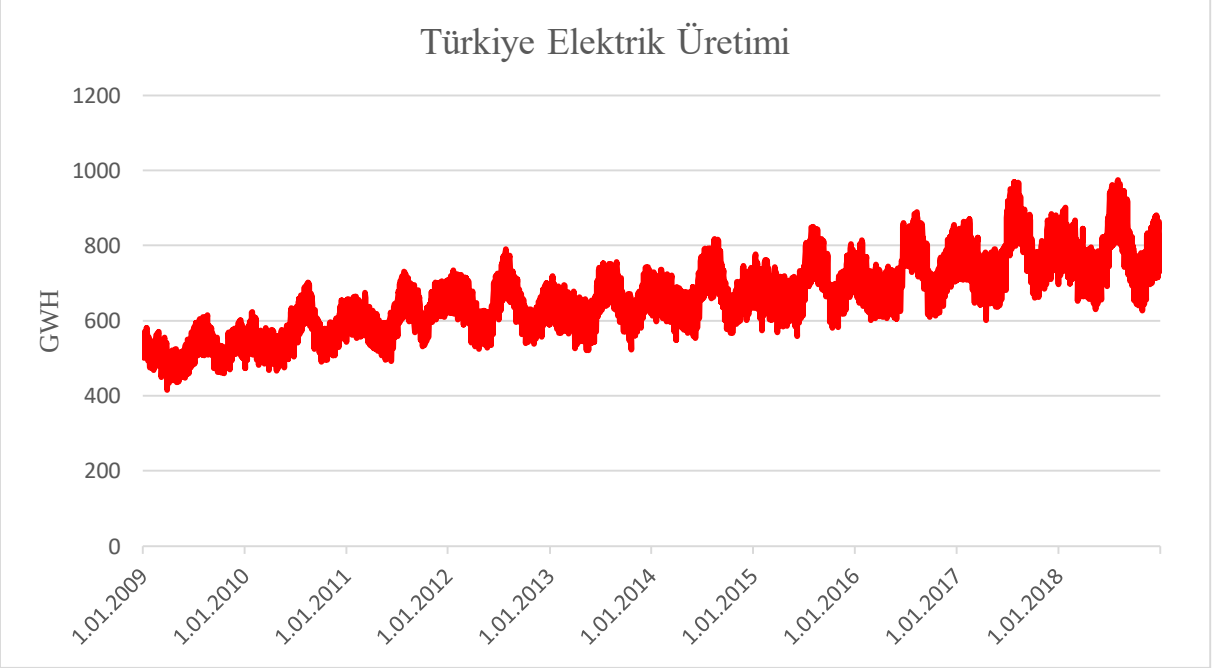
		alan ayrıştırılmış tahminci. Entegre tahminciyle karşılaştırıldığında ayrıştırılmış tahmincinin daha doğru sonuçlar verdiği bulunmuştur.
Yuan vd. [110]	ARIMA Gri Model (GM)	Çalışmada, Çin'in birincil enerji tüketimini tahmin etmek için iki tek değişkenli model, ARIMA modeli ve GM (1,1) modeli kullanılmıştır. Karşılaştırma yoluyla, ARIMA modelinin takılan değerlerinin dalgalanmalara daha az yanıt verdiği, çünkü uzun vadeli eğiliminin sınırlandığı, GM (1,1) modelinin ise en son dört verinin kullanımı nedeniyle daha fazla etkilendiğini bulmuşlardır. Wilcoxon işaretli derece testine göre, iki modelin kalanları istatistiksel olarak zıt olduğu bulunmuştur. Bu nedenle, iki model ile bir hibrit model oluşturmuşlardır. Hibrit yöntemin tahmin sonucunda elde edilen MAPE değeri, ARIMA ve GM (1,1) modelinden daha küçük olduğu bulunmuştur.
Leithon vd. [111]	ARIMA Markov Zinciri Modeli Lineer Programlama	Çalışmada, hem yenilenebilir hem de geleneksel enerjiyle çalışan hücresel baz istasyonları tarafından gerçekleştirilen işletme giderlerini en aza indirmek için çevrimiçi bir enerji yönetimi stratejisi önerilmiştir. Günler arası tahmin için Otomatik Regresif Entegre Hareketli Ortalama (ARIMA) zaman serisi modeli, gün içi tahminler için bir Markov zincir modeli ve karar değişkenlerini gerçek zamanlı olarak optimize etmek için doğrusal programlama teknikleri kullanılmıştır. Simülasyonlar sayesinde, önerilen algoritmayı üreme stratejisine karşı kıyaslamışlardır ve algoritmanın sağlamlığını belirlemek için rastgele enerji oranlarını dikkate almışlardır.
Oliveira ve Oliveira [112]	ARIMA Torbalama Yöntemi	Çalışmada, farklı ülkelerden gelen aylık elektrik enerjisi tüketim zaman serileri kullanılarak karşılaştırmalı bir örneklem dışı analiz yapmışlardır. Tahmin için Torbalama yöntemi ile ARIMA, ANN, SVR, Holt Winter, Remainder Sieve Bootstrap ve Moving Blocks Bootstrap tahmin yöntemleri kullanılmıştır.

3. MALZEME VE YÖNTEM

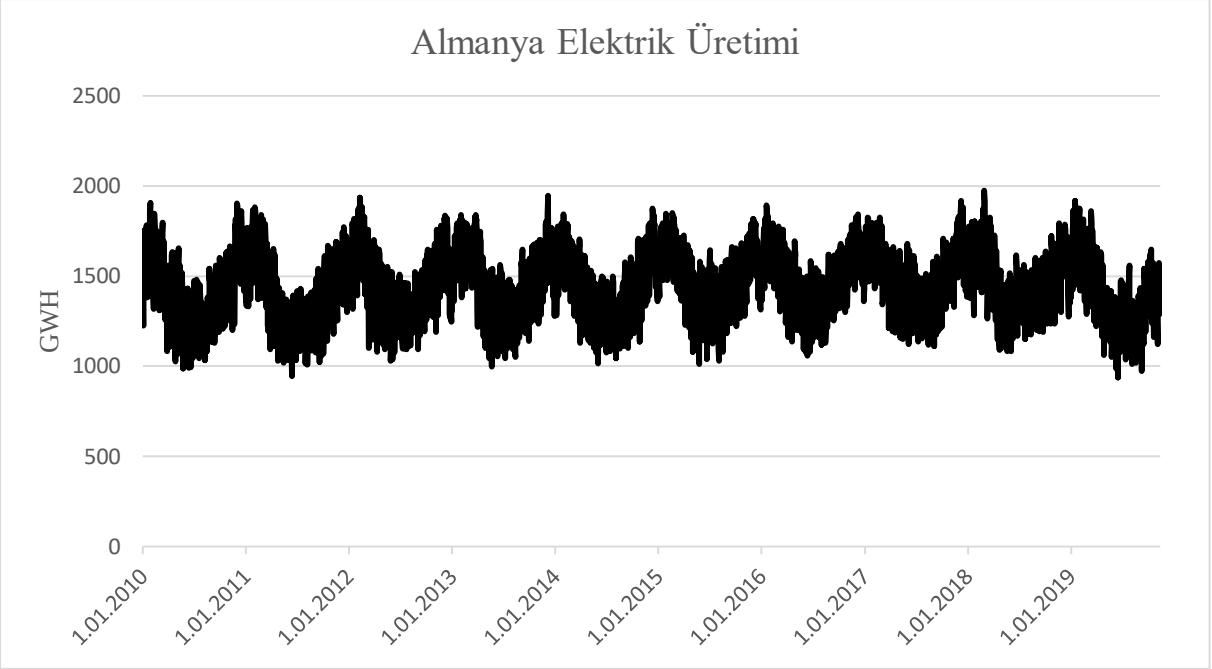
3.1 VERİ SETİNİN TANITILMASI

Bu çalışmada ileriye dönük elektrik üretimi tahmini için, Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ), Fraunhofer ISE ve Red Electrica'dan alınan Türkiye, Almanya ve İspanya elektrik üretim değerleri kullanılmıştır.

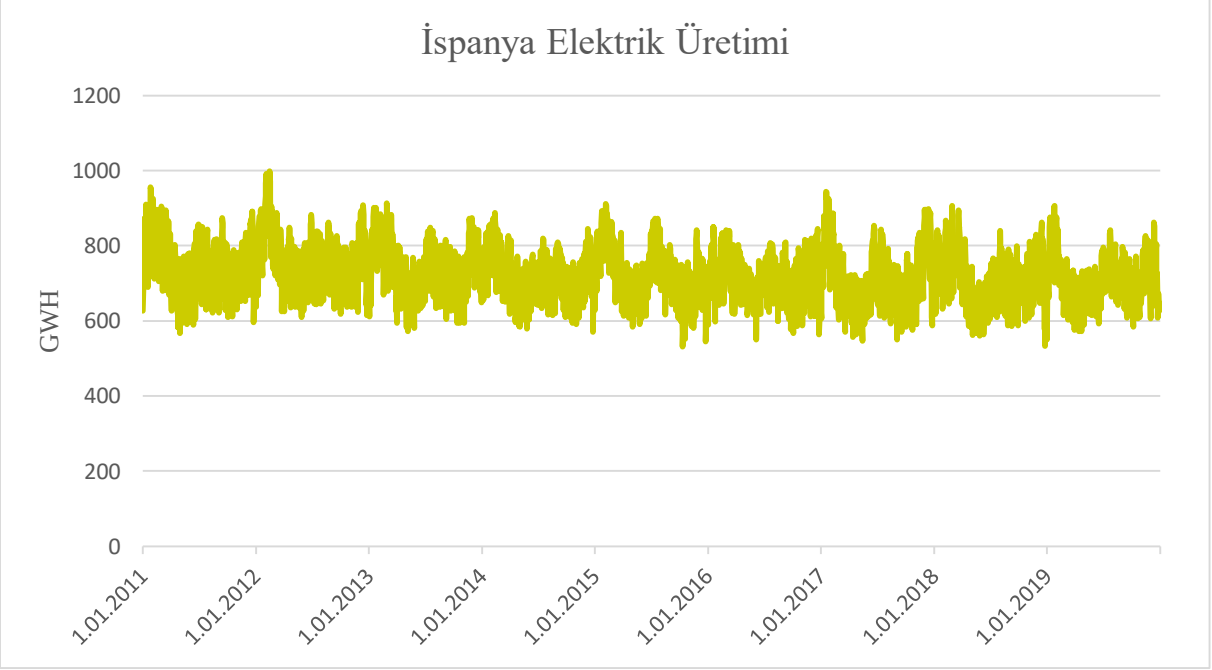
Türkiye verilerinde bayramlarda meydana gelen ani elektrik üretim değerlerindeki azalmaları önlemek için bir önceki haftanın ortalaması alınarak düzeltilmiştir. Türkiye, Almanya ve İspanya'ya ait elektrik üretim değerleri Şekil 3.1-3'teki gibidir.



Şekil 3.1 Türkiye Elektrik Üretimi



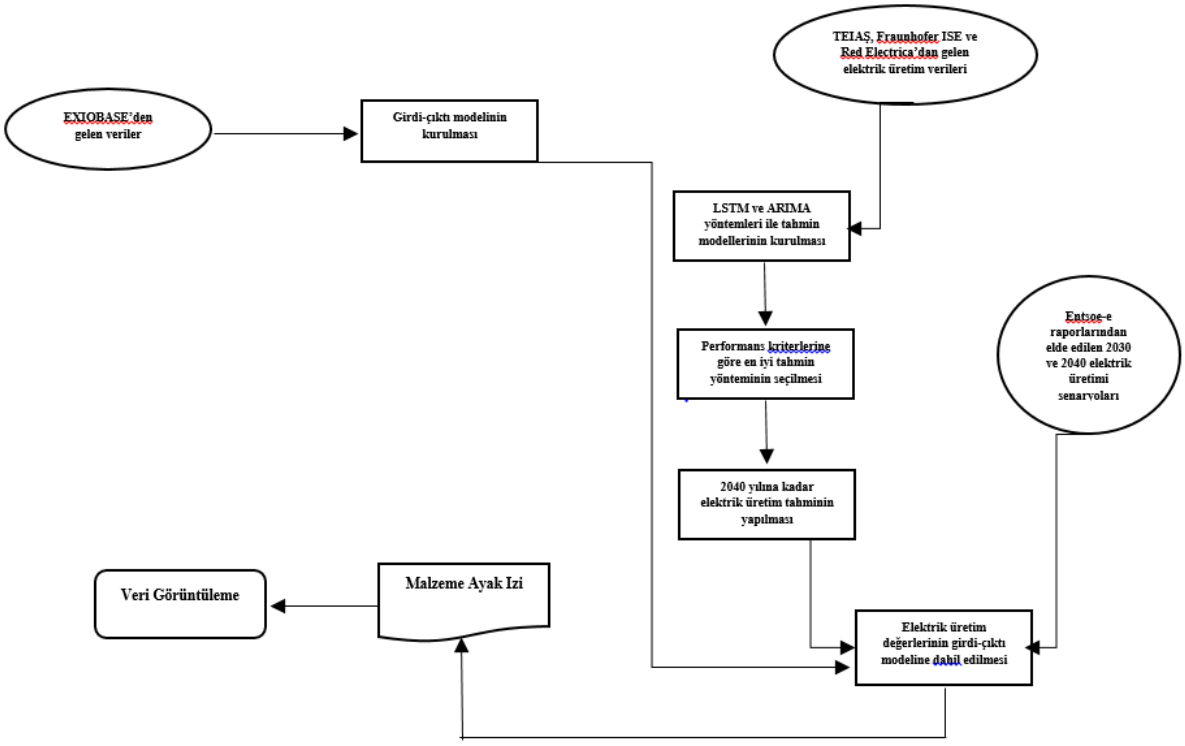
Şekil 3.2 Almanya Elektrik Üretimi



Şekil 3.3 İspanya Elektrik Üretimi

3.2 AKIŞ ŞEMASI

Bu çalışmasının akış şeması Şekil 3.4'deki gibidir.



Şekil 3.4 Akış Şeması

3.3 MODELLEME VE YÖNTEM

3.3.1 Yazılım Modelleme

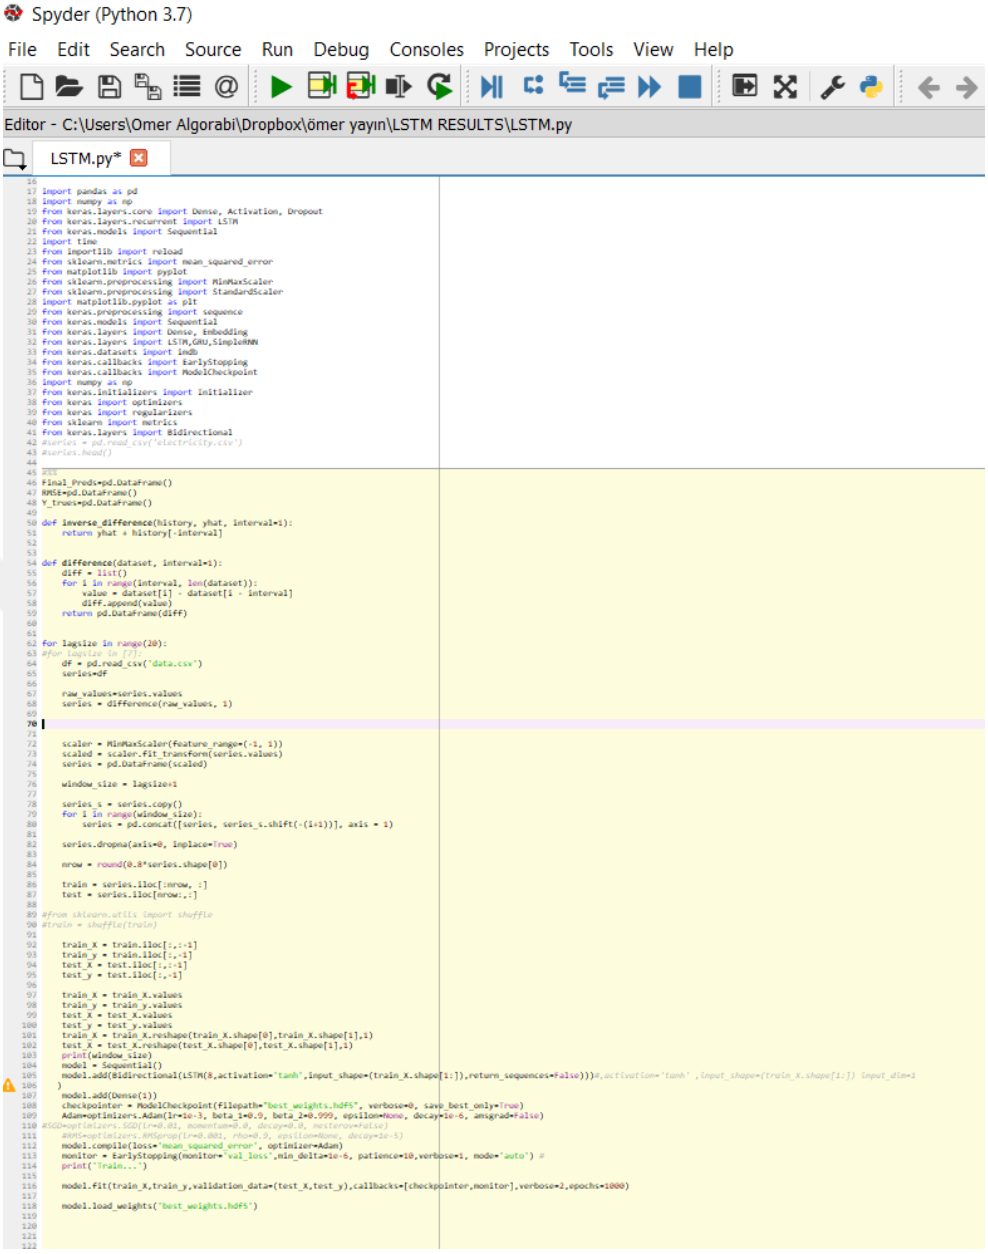
Bu çalışmada elektrik üretimi tahmini için LSTM ve ARIMA yöntemleri kullanılmıştır. LSTM yöntemi Python yazılım diliyle, ARIMA ise SPSS programı kullanılarak modellenmiştir. Eğitim veri seti %80 test veri seti %20 olarak alınmıştır.

Derin öğrenme konusunda oldukça önemli paketlerden biri olan Keras, LSTM yöntemini modellemek için kullanılmıştır. Keras, modelleri tanımlamayı ve eğitmeyi çok kolay hale getiren bir kütüphanedir.

Derin öğrenme uygulamalarında öğrenme işleminin temelde bir optimizasyon problemidir. Doğrusal olmayan problemlerin çözümünde optimum değeri bulmak için optimizasyon yöntemleri kullanılmaktadır. Bu çalışmada da ‘Adam’ optimizasyon yöntemi kullanılmıştır. Adam optimizasyon algoritması, çok çeşitli derin öğrenme mimarilerinde iyi çalışan algoritmalardan biridir. Birçok tanınmış sinir ağı algoritması uzmanı tarafından tavsiye edilir. Adam optimizasyon algoritması, momentumlu gradient descent ile RMSprop algoritmalarının birleşimidir. Adam optimizasyon yönteminin avantajı; nispeten düşük bellek gereksinimleri ve genellikle küçük bir hiperparametre ayarı ile bile iyi çalışır (alfa hariç).

Çalışmada kullanılan diğer kütüphaneler; pandas, numpy, sklearn, matplotlib ve importlib. Çalışmada gecikme sayısı ise 20 olarak alınmştır.

Elektrik üretimi tahmini için modelin kodlanması Şekil 3.6’daki gibidir.



Şekil 3.5 Python yazılımı ile modelleme

ARIMA yöntemi SPSS programı kullanılarak modellenmiştir. Modelin otoregresyon sırası, 365, modeli sabit yapmak için farklılık derecesi, 1, modelin hareketli ortalama boyutunun sırası, 7 alınarak; ARIMA(365,1,7) modeli kullanılmıştır. Bu model ile Türkiye, Almanya ve İspanya elektrik üretim verileri, beyaz gürültü serisi özelliklerine ulaşılmıştır. Seride düzey ve varyans durağanlığı elde edilmiştir. ACF ve PACF değerleri incelendiğinde ise değerler 2σ hata limitleri içinde olduğu görülmektedir.

3.3.2 Performans Ölçütleri

Tahmin yöntemlerinin performansını karşılaştırmak için, çeşitli tahmin özellikleri için çeşitli ölçütler kullanılır. Yöntemlerin kalitesini belirlemek için, Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error, MAPE), Kök Bağıl Kare Hata (Root Relative Squared Error, RRSE), Bağıl Mutlak Hata (Relative Absolute Error, RAE) ve Kök Ortalama Kare Hata (Root Mean Square Error, RMSE) kullanılmıştır. Bu ölçütler Denklem 3.1-3.4'te gösterilmiş olup; burada *a*, gerçek değeri ve p, tahmin değerini ifade etmektedir.

$$MAPE = \frac{1}{n} \times \sum_{i=1}^{n} \frac{|p_i - a_i|}{a_i} \tag{3.1}$$

$$RMSE = \sqrt{\frac{(p_1 - a_1)^2 + \cdots + (p_n - a_n)^2}{n}} \tag{3.2}$$

$$RAE = \frac{1}{n} \times \frac{|p_1 - a_1| + \cdots + |p_n - a_n|}{|a_1 - \bar{a}| + \cdots |a_n - \bar{a}|} \tag{3.3}$$

$$RRSE = \sqrt{\frac{1}{n} \times \frac{(p_1 - a_1)^2 + \cdots + (p_n - a_n)^2}{(a_1 - \bar{a})^2 + \cdots + (a_n - \bar{a})^2}} \tag{3.4}$$

3.3.3 Girdi Çıktı Analizi

Girdi-çıktı analizi (Input-output analysis, IO analysis), ekonominin tüm sektörlerinin karşılıklı bağımlılığını ve bir endüstri veya sektördeki üretimin ulusal ekonomiyi nasıl etkilediğini analiz etmek için Wassily Leontief tarafından geliştirilmiştir [113]. Bu model öyle ki, k üretimi üreten k sayıda endüstriler vardır. Başka bir deyişle, herhangi bir endüstrinin toplam tüketimi üretime eşittir [114]. IO tabloları, belirli bir ekonomi için bölgesel veya ulusal düzeyde olabilecek ve farklı faaliyet sektörleri ve talepleri arasında veya üreticiler ve tüketiciler arasında parasal olarak mal ve hizmet akışlarını tanımlayan istatistiksel verilere dayanılarak oluşturulmuştur. IO tabloları, sektör i'den sektör j'ye akışı ve nihai talebi tanımlayan sektörler arası akışlar veya işlem matrisi olmak üzere iki ana bileşene ayrılabilir. Ara mallar ve hizmetler diğer sektörler tarafından da işlenmektedir [115].

Bir IO tablosu, her sektörde belirli bir üretim elde etmek için diğer sektörlerden tüketilen kaynakları hesaba katarak sütunlardaki üretim maliyeti bileşenlerini temsil ederken, satırlarda bir sektörün üretiminin diğer sektörler arasındaki dağılımı açıklanmaktadır [115].

Bu nedenle, her sektörden toplam çıktı Denklem 3.5'teki gibi tanımlanır [115]:

$$x_i = z_{i1} + z_{i2} + .. z_{in} + y_i \tag{3.5}$$

burada x, toplam çıktıyı ifade eden bir vektördür, Z, IO matrisidir ve y, son talep vektörüdür [115].

IO matrisi, girdinin çıktıya oranını temsil eden teknik katsayılarla, yani diğer sektörlerden bir sektörün parasal bir çıktı üretmek için ihtiyaç duyduğu miktar ile ifade edilebilir. Teknik katsayılar Denklem 3.6'daki gibi ifade edilir [115]:

$$a_{ij} = \frac{z_{ij}}{x_j} \tag{3.6}$$

Teknik katsayılar A matrisi olarak ifade edilebilir. Teknik katsayılar için Denklem (3.6) 'da zij yerine geçer ve toplam çıktı Denklem 3.7'deki gibi tanımlanır [115]:

$$x = Ax + y \tag{3.7}$$

Denklem 3.7 yeniden düzenlenerek Denklem 3.8'deki gibi ifade elde edilir [115]:

$$x = (I - A)^{-1} y \tag{3.8}$$

burada $(I\text{-}A)^{-1}$, nihai talebi karşılamak için gereken her bir sektörün toplam üretimini ifade eden Leontief ters matrisi veya çarpan matrisidir. Bu birim, nihai talep başına doğrudan ve dolaylı gereksinimlerdir [115].

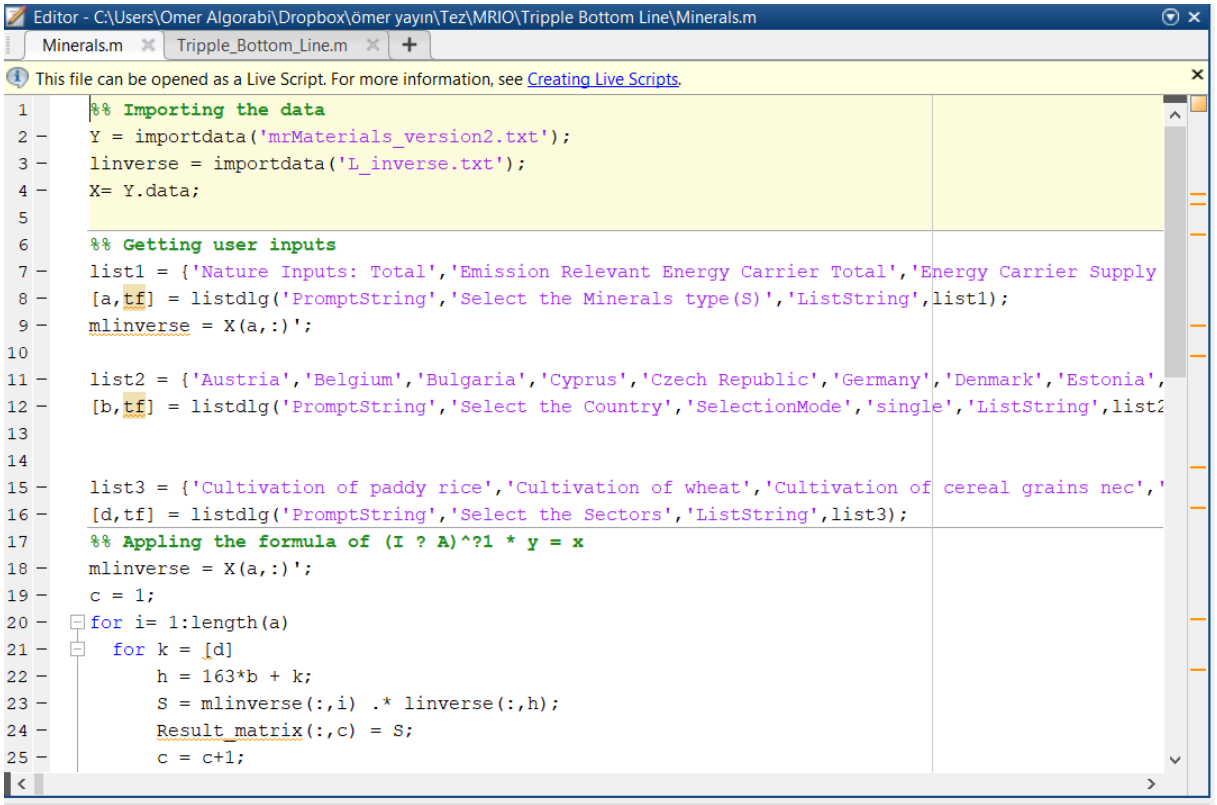
3.3.4 Malzeme Ayak İzi

EXIOBASE, küresel, detaylı Çok Bölgeli Çevresel Genişletilmiş Tedarik Kullanım (MR-SUT) ve Girdi-Çıktı Tablosudur (MR-IOT). Çok sayıda ülke için arz-kullanım tablolarının uyumlu hale getirilmesi ve detaylandırılması, endüstrinin emisyon ve kaynak çıkarımı tahmin edilerek geliştirilmiştir. Daha sonra ülke arz-kullanım tabloları, bir MR-SUT yaratarak ve bundan bir MR-IOT üreterek ticaret ile ilişkilendirildi. MR-IOT, ürün gruplarının nihai tüketimi ile ilişkili çevresel etkilerin analizi için kullanılmaktadır.

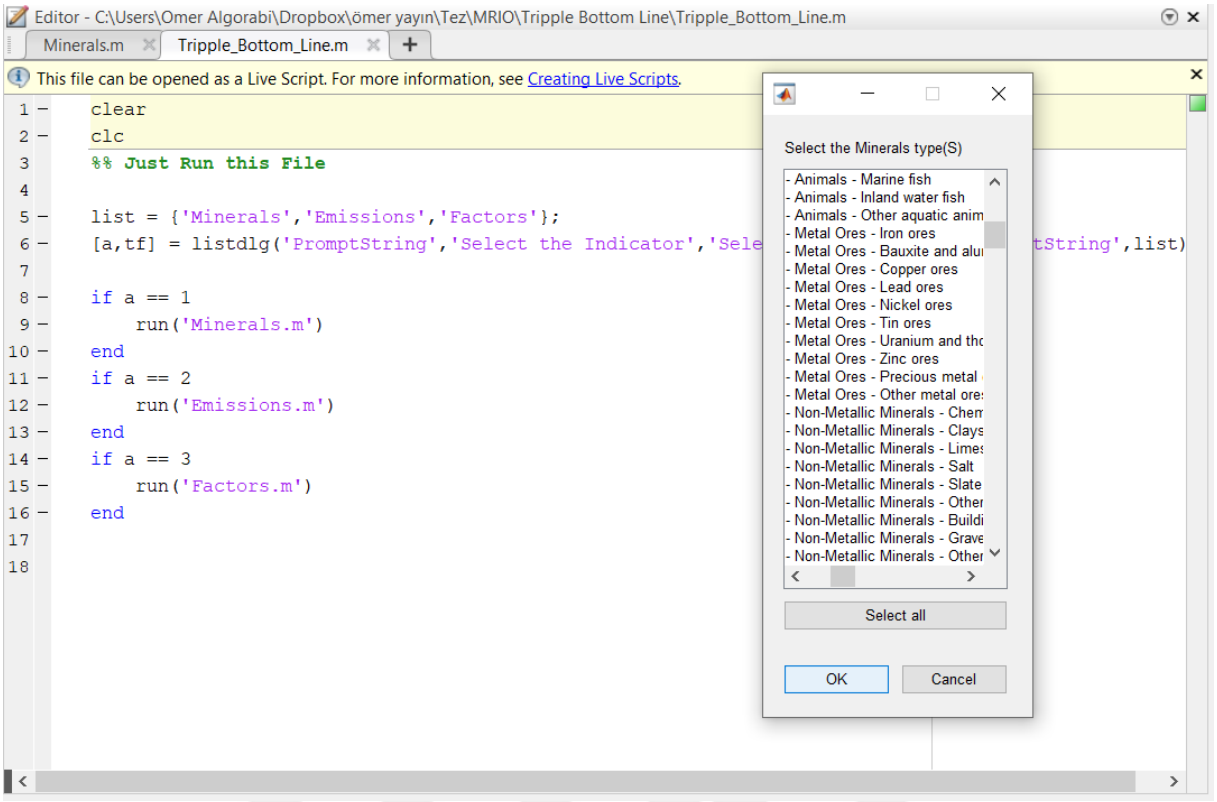
Bu araştırmada, EXIOBASE v.3'den tabloları alındıktan sonra, malzemelerin ton cinsinden tüketimini elde etmek için veri setine Leontief ters işlemi uygulanmıştır. Leontief ters işlemi,

tüm ekonomik faaliyetlerin birbiriyle bağlantılı olması nedeniyle, belirli bir ekonomik faaliyetin, diğerinin tüketim örneğini ne kadar etkileyeceğini gösterecektir. Geliştirilen model, tedarik zincirlerinin doğrudan ve dolaylı etkilerini de net bir şekilde izlememize izin vermektedir.

Leontitef ters işlemini uygulamak için MATLAB programı kullanılmış ve uygulama Şekil 3.6'daki gibi gösterilmiştir



Şekil 3.6 MATLAB-Leontief ters işlemi



Şekil 3.7 MATLAB-Malzeme Ayak İzi

3.4 ELEKTRİK GELİŞİM PLANLARI VE SENARYOLAR

Bu çalışmada, Avrupa Elektrik İletim Sistemi İşleticileri Birliği (entso-e)'den 2030 ve 2040 yıllarına ait elektrik üretim senaryoları alınmıştır. Bu senaryolar uygulandığında, elektrik üretimi sonucunda ortaya çıkacak malzeme ayak izleri hesaplanmıştır. Küresel İklim Aksiyonu (GCA), Sürdürülebilir Geçiş (ST), Dağıtılmış Üretim (DG) ve Avrupa Komisyonu (EU) senaryoları incelenmiştir.

Senaryolara göre 2030 ve 2040 yıllarına ait elektrik üretim değerleri Tablo 3.1-3.3'teki gibidir.

3.1 Senaryolara Göre Türkiye'nin Elektrik Üretim Değerleri

Kaynak\Senaryo	2030ST	2030DG	2030EU	2040ST	2040GCA	2040DG
Nükleer	57366	52403	57367	51945	29825	41381
Kömür + Linyit	69995	104339	74495	31053	0	28011
Doğalgaz	99276	6192	99517	17519	12771	14303
Hidrolik	97847	97849	97844	97862	97897	97941
Rüzgar	56794	56794	56794	147279	169780	149224
Güneş	13680	99866	13680	43506	116440	158901
Biyokütle vd.	6111	6111	6111	6111	6111	6111

3.2 Senaryolara Göre Almanya'nın Elektrik Üretim Değerleri

Kaynak\Senaryo	2030ST	2030DG	2030EU	2040ST	2040GCA	2040DG
Nükleer	0	0	0	0	0	0
Kömür + Linyit	71565	139217	117213	34615	10575	68360
Doğalgaz	125888	70076	69557	110832	78994	76164
Hidrolik	24959	28303	23974	31340	36772	32867
Rüzgar	195879	195736	177406	256925	327636	259928
Güneş	66682	95118	81970	75434	141811	141220
Biyokütle vd.	37152	37150	34075	37151	37151	37151

3.3 Senaryolara Göre İspanya'nın Elektrik Üretim Değerleri

Kaynak\Senaryo	2030ST	2030DG	2030EU	2040ST	2040GCA	2040DG
Nükleer	49172	49172	51117	21179	21179	21179
Kömür + Linyit	7132	6101	4634	0	0	0
Doğalgaz	33994	31648	51548	37833	21994	43862
Hidrolik	41645	44224	36586	45462	54159	46247
Rüzgar	65835	65835	73507	84017	110065	76183
Güneş	80477	93964	62284	104305	152559	131180
Biyokütle vd.	13373	13373	6272	13373	13373	13373

3.4.1 Küresel İklim Aksiyonu

Küresel İklim Aksiyonu (GCA) planında küresel iklim çabalarını ele almaktadır. CO_2 azaltımına ilişkin küresel yöntemler mevcuttur ve AB 2030 ve 2050 dekarbonizasyon hedeflerine doğru ilerlemektedir. Verimli bir ETS ticaret şeması, elektrik sektörünün küresel / AB dekarbonizasyon politikası hedeflerine katkıda bulunmadaki başarısında kilit bir etkendir. Genel olarak, yenilenebilir enerji kaynakları en iyi rüzgar ve güneş kaynaklarının bulunduğu Avrupa'da bulunmaktadır. Aralıklı olmayan yenilenebilir enerji kaynakları olarak biyo-metan da geliştirilmiştir. Çevre konularına odaklanılması nedeniyle şeyl gazına yatırım yapılması beklenmemektedir [116].

3.4.2 Sürdürülebilir Geçiş

Sürdürülebilir Geçiş (ST) planında, ulusal düzenlemelerin, emisyon alım satım programlarının ve sübvansiyonların bir karışımı ile iklim eylemi gerçekleştirilir. Ulusal düzenleme bağlayıcı emisyon hedefleri uygulayan mevzuat şeklini alır. Genel olarak, AB 2030 hedeflerine doğru ilerlerken, 2040'ta 2050 dekarbonizasyon hedeflerine giden yolda biraz geride kalmıştır. Bununla birlikte, 2040'lı yıllarda enerji sektörünün dekarbonize edilmesinde hızlı ilerleme kaydedilmesi durumunda hedefler hala başarılabilir [116].

3.4.3 Dağıtılmış Üretim

Dağıtılmış Üretim (DG) planında, küçük ölçekli üretim ve konut / ticari depolama teknolojilerinin yenilikçiliğinde önemli sıçramalar iklim eyleminde kilit bir faktördür. Küçük ölçekli üretimdeki artış, AB'yi 2030 ve 2050 hedeflerine doğru ilerletiyor. Zengin bir toplum, enerji piyasalarına girmiştir, böylece toplum yaşamak için dekarbonize edilmiş bir yer elde etmek için devreye girer ve güçlendirilir. Kesintisiz yenilenebilir enerji kaynakları olarak biyo-metan da geliştirilmiştir. Kesintisiz yenilenebilir enerji kaynakları olduğu için biyo-metan da dağıtım düzeyinde daha büyük bir oranda gelişmiştir. Sonuç olarak, şeyl gazına yatırım yapılması beklenmemektedir [116].

3.4.4 Avrupa Komisyonu Senaryosu

Avrupa Komisyonu'nun (EC) 2016 yılında etki değerlendirme çalışmasının bir parçası olarak, EU 30, başlangıç noktası olarak PRIMES modeli ve AB Referans Senaryosu 2016 kullanılarak oluşturulan temel bir politika senaryosudur. Senaryo, Avrupa Konseyi tarafından 2014 yılında kabul edilen 2030 iklim ve enerji hedeflerine ulaşılmasını modelliyor, ancak% 30'luk bir enerji verimliliği hedefi içeriyor. Atina Ulusal Teknik Üniversitesi'nde (NTUA) bulunan ve Uluslararası Uygulamalı Sistem Analizi Enstitüsü (IIASA) dahil olmak üzere E3Mlab liderliğindeki bir konsorsiyum tarafından hazırlanmıştır [116].

4. BULGULAR

Bu çalışmada ilk olarak Türkiye, Almanya ve İspanya'nın günlük elektrik üretim tahmini yapılmıştır. Elektrik üretimi tahmini için ARIMA ve LSTM yöntemleri kullanıldı. Türkiye Elektrik İletim A.Ş., Fraunhofer ISE ve Red Electrica De Espana kurumlarından sırasıyla, 2009-2018, 2010-2019 ve 2011-2019 arasındaki günlük elektrik üretim verileri alınmıştır. Bu verilerin %80 eğitim ve %20'si test veri seti olarak alınıp; ARIMA ve LSTM yöntemleri performans ölçütlerine göre karşılaştırılmıştır.

Türkiye'nin elektrik üretim değerlerinin tahmininde kullanılan ARIMA ve LSTM yöntemlerinin test veri seti üzerindeki performansı Tablo 4.1'deki gibidir,

Tablo 4.1 Türkiye'nin elektrik üretim tahmini test veri seti performansı

	RAE	RRSE	MAPE	RMSE
LSTM	0,19	0,219	1,37%	15,81
ARIMA	0,54	0,534	3,73%	38,63

Tablo 3'deki sonuçlar incelendiğinde her iki yöntemin performansı iyi olduğu söylenebilmektedir. Her iki yöntemde de MAPE değeri %5'in altında bulunmuştur. İki yöntem karşılaştırıldığında ise performans ölçütleri açısından, LSTM yöntemi ARIMA yöntemine göre çok daha üstün bulunmuştur. LSTM'in test veri seti üzerindeki performansı incelendiğinde; ortalama bir hatayı (artık) önemsiz veya saf bir model tarafından üretilen hatalarla karşılaştıran RAE değeri 0,19, RRSE değeri 0,219, hataların genel bir ortalamasını temsi eden MAPE değeri 1,37 ve büyük hataların tespitini daha kolaylaştıran RMSE değeri 15,81 bulunmuştur.

Almanya'nın elektrik üretim değerlerinin tahmininde kullanılan ARIMA ve LSTM yöntemlerinin test veri seti üzerindeki performansı Tablo 4.2'deki gibidir,

Tablo 4.2 Almanya'nın elektrik üretim tahmini test veri seti performansı

	RAE	RRSE	MAPE	RMSE
LSTM	0,408	0,424	4,39%	81,755
ARIMA	0,636	0,633	7,08%	122,041

Tablo 4 incelendiğinde performans ölçütleri açısından, LSTM yöntemi ARIMA yöntemine göre çok daha üstün bulunmuştur. LSTM'in Almaya elektrik üretimi test veri seti üzerindeki performansı incelendiğinde; RAE değeri, 0,408, RRSE değeri 0,424, MAPE değeri, %4,39 ve RMSE değeri 81,755 bulunmuştur. Her iki yöntemin de Türkiye elektrik üretimi test veri setini, Almanya elektrik üretimi test veri setine göre daha iyi tahminlediği bulunmuştur.

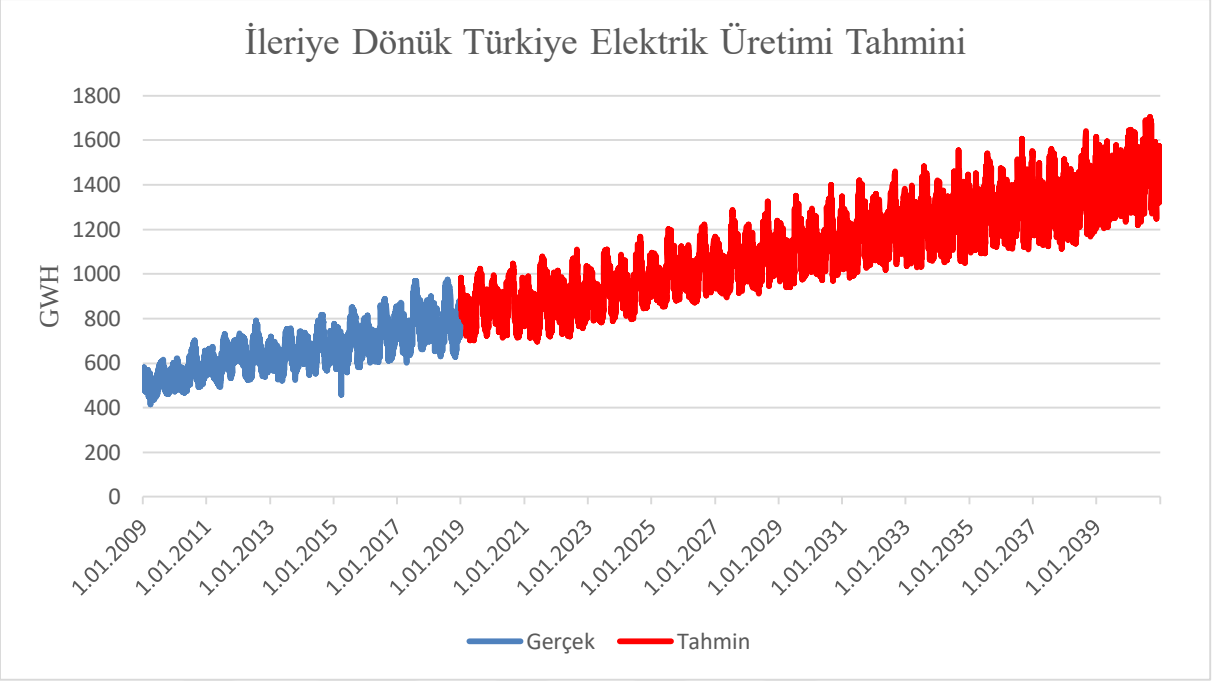
İspanya'nın elektrik üretim değerlerinin tahmininde kullanılan ARIMA ve LSTM yöntemlerinin test veri seti üzerindeki performansı Tablo 4.3'teki gibidir,

Tablo 4.3 İspanya'nın elektrik üretim tahmini test veri seti performansı

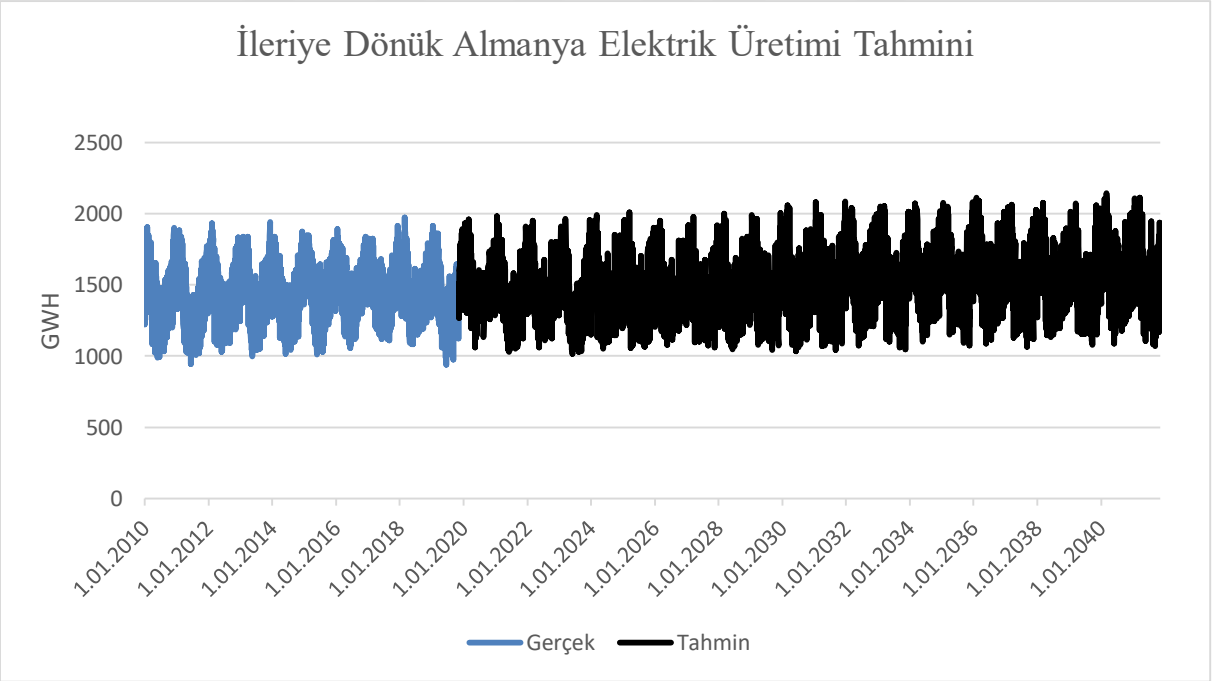
	RAE	RRSE	MAPE	RMSE
LSTM	0,433	0,474	3,40%	31,98
ARIMA	0,798	0,823	6,31%	55,51

Tablo 5 incelendiğinde performans ölçütleri açısından, LSTM yöntemi ARIMA yöntemine göre çok daha üstün bulunmuştur. LSTM'in Almaya elektrik üretimi test veri seti üzerindeki performansı incelendiğinde; RAE değeri, 0,433, RRSE değeri 0,474, MAPE değeri, %3,40 ve RMSE değeri 31,98 bulunmuştur. Her iki yöntemin de İspanya elektrik üretimi test veri setini, Türkiye elektrik üretimi test veri setine göre daha kötü tahminlediği bulunmuştur.

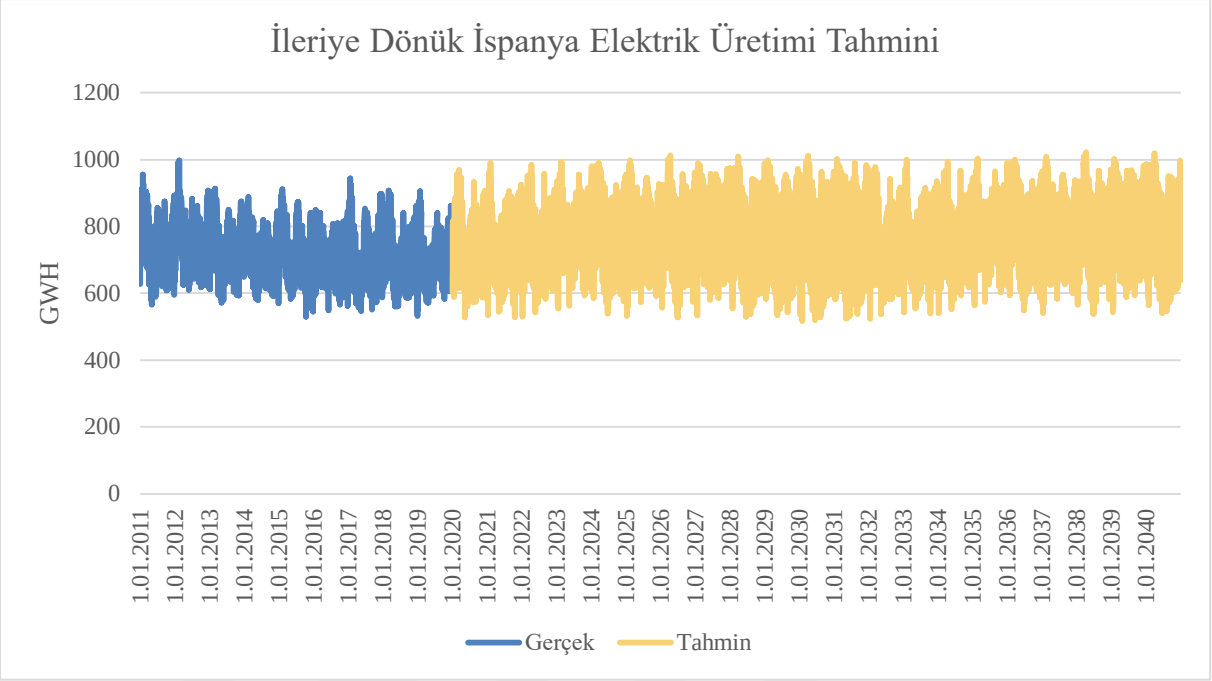
LSTM, en iyi tahmin yöntemi olduğu tespit edildikten sonra, Türkiye, Almanya ve İspanya için ileriye dönük elektrik üretimi tahmini yapılmıştır. Bu ülkelerin 2040 yılına kadar olan günlük elektrik tahmin sonuçları Şekil 4.1-4.3'deki gibidir.



Şekil 4.1 İleriye Dönük Türkiye Elektrik Üretimi Tahmini

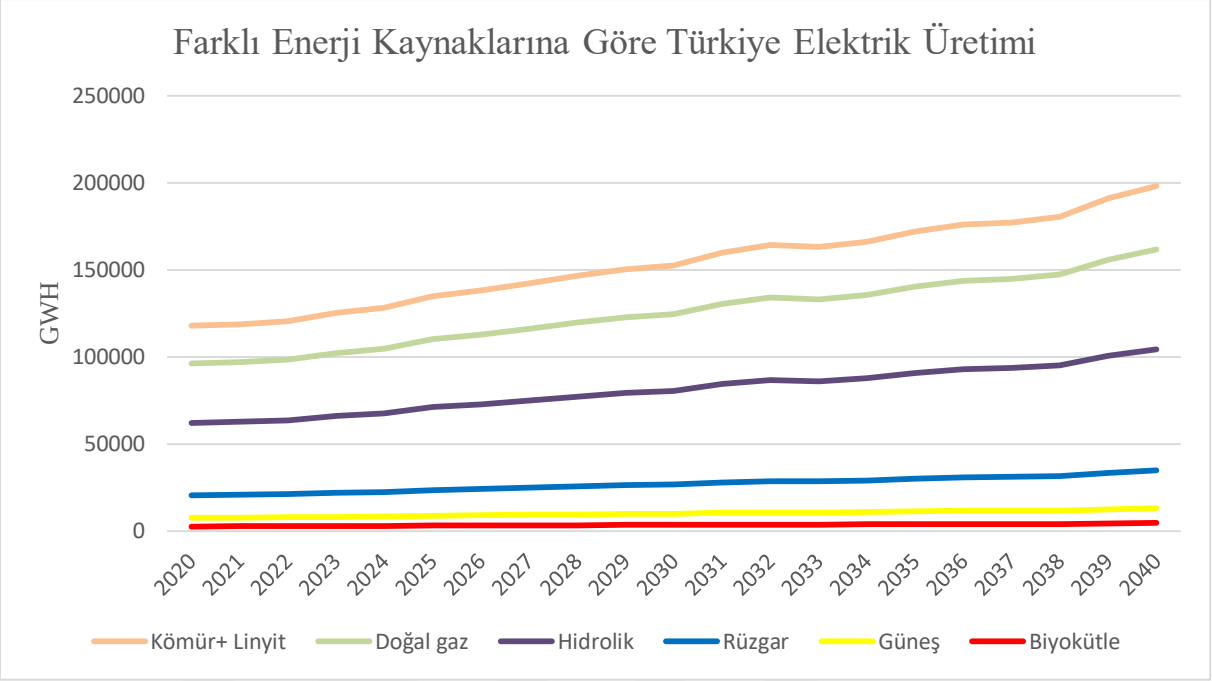


Şekil 4.2 İleriye Dönük Almanya Elektrik Üretimi Tahmini

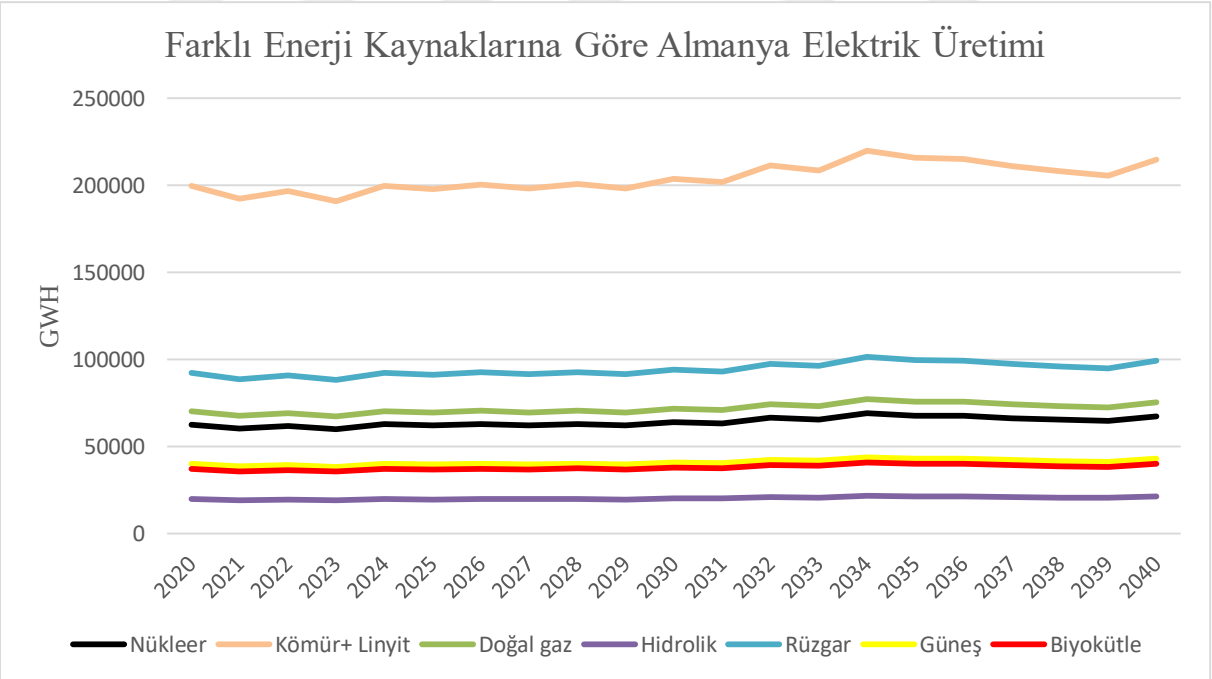


Şekil 4.3 İleriye Dönük İspanya Elektrik Üretimi Tahmini

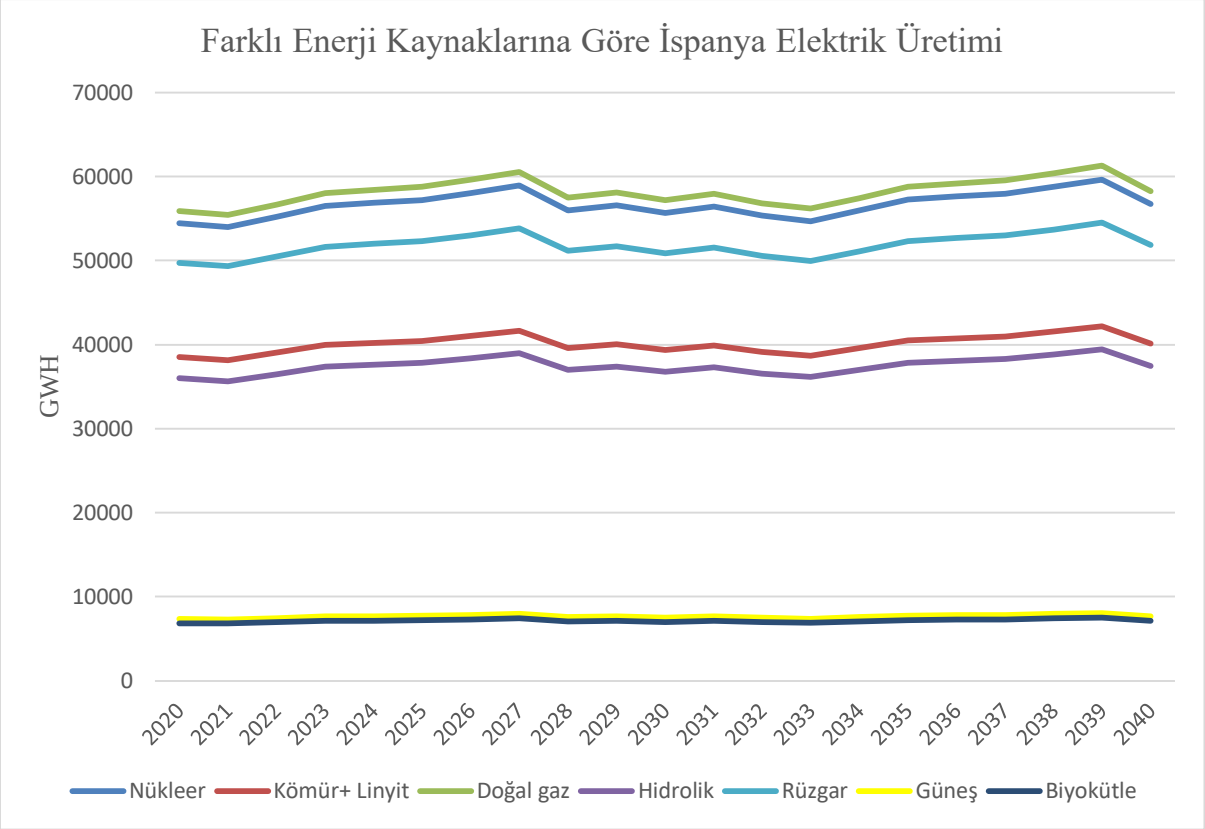
Farklı enerji kaynaklarının toplam elektrik üretimindeki payları, ileriye dönük değişmeyeceği varsayılarak; 2040 yılına kadar olan farklı enerji kaynaklarının elektrik üretim değerleri hesaplanmıştır. Elde edilen sonuçlar Şekil 4.4-4.6'daki gibidir.



Şekil 4.4 Farklı Enerji Kaynaklarına Göre Türkiye Elektrik Üretimi



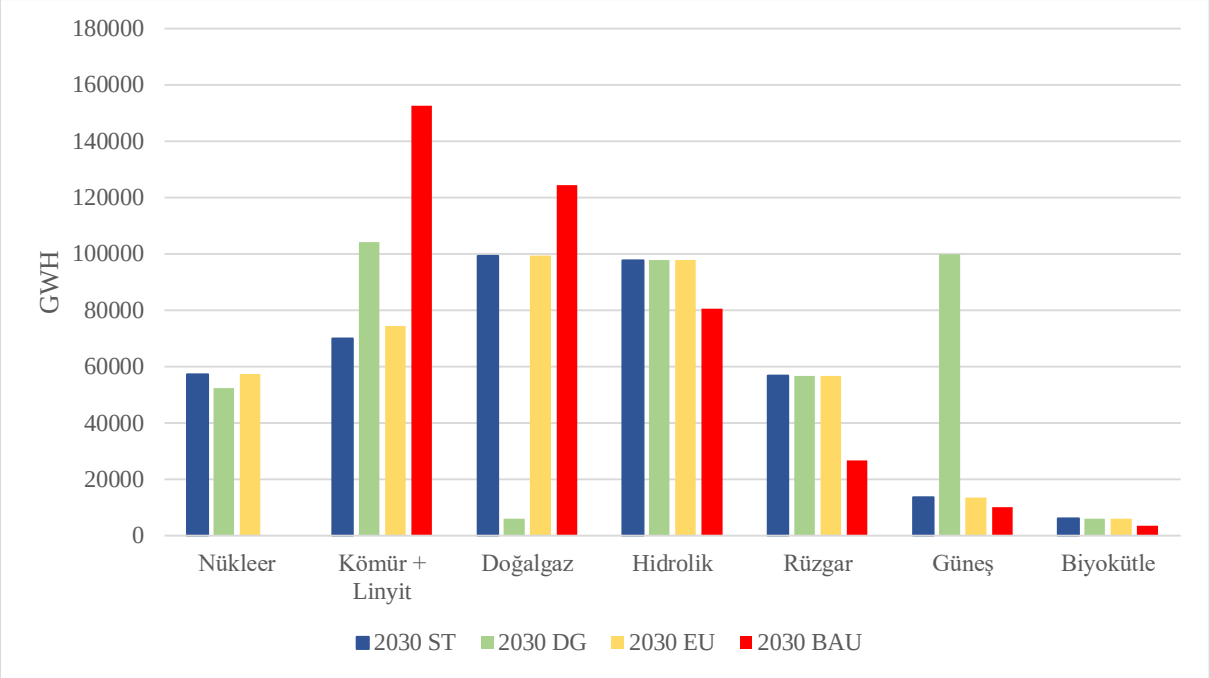
Şekil 4.5 Farklı Enerji Kaynaklarına Göre Almanya Elektrik Üretimi



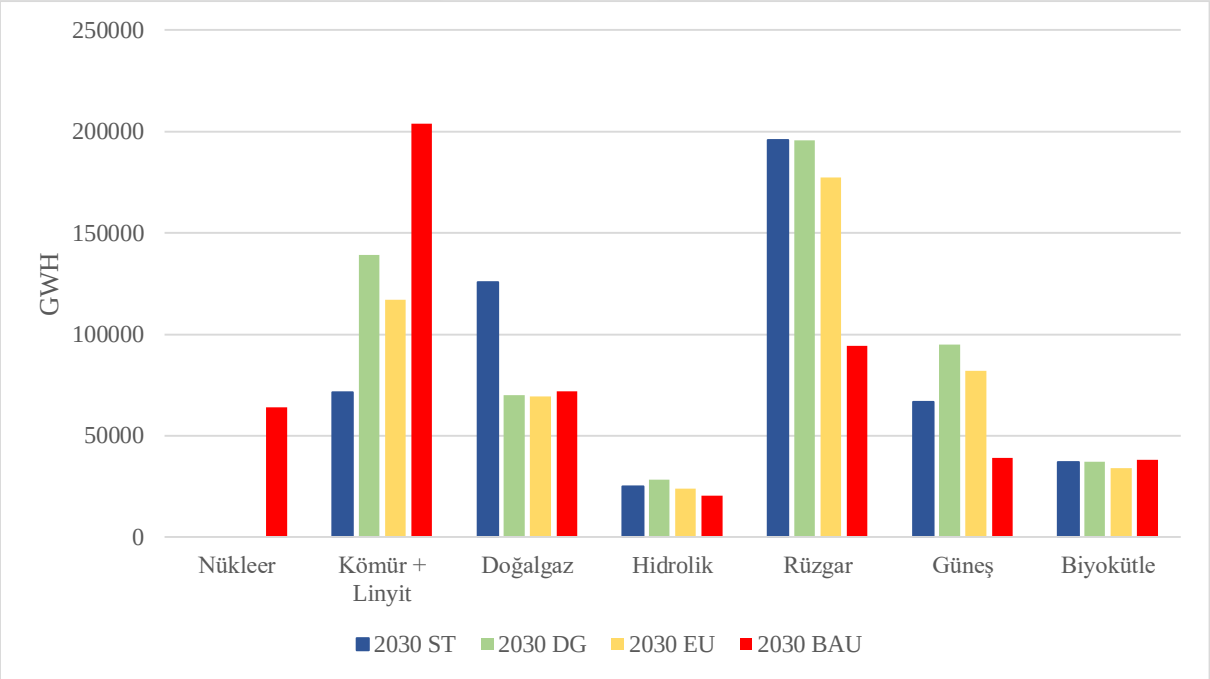
Şekil 4.6 Farklı Enerji Kaynaklarına Göre İspanya Elektrik Üretimi

İleriye dönük tahminler yapıldıktan sonra; bu tahminler sonucunda beklenen elektrik üretimi için malzeme ayak izi hesaplanmıştır. Olağan durumdaki (BAU) malzeme ayak izi, farklı elektrik üretimi senaryoları ile oluşacak malzeme ayak izleriyle karşılaştırılmıştır.

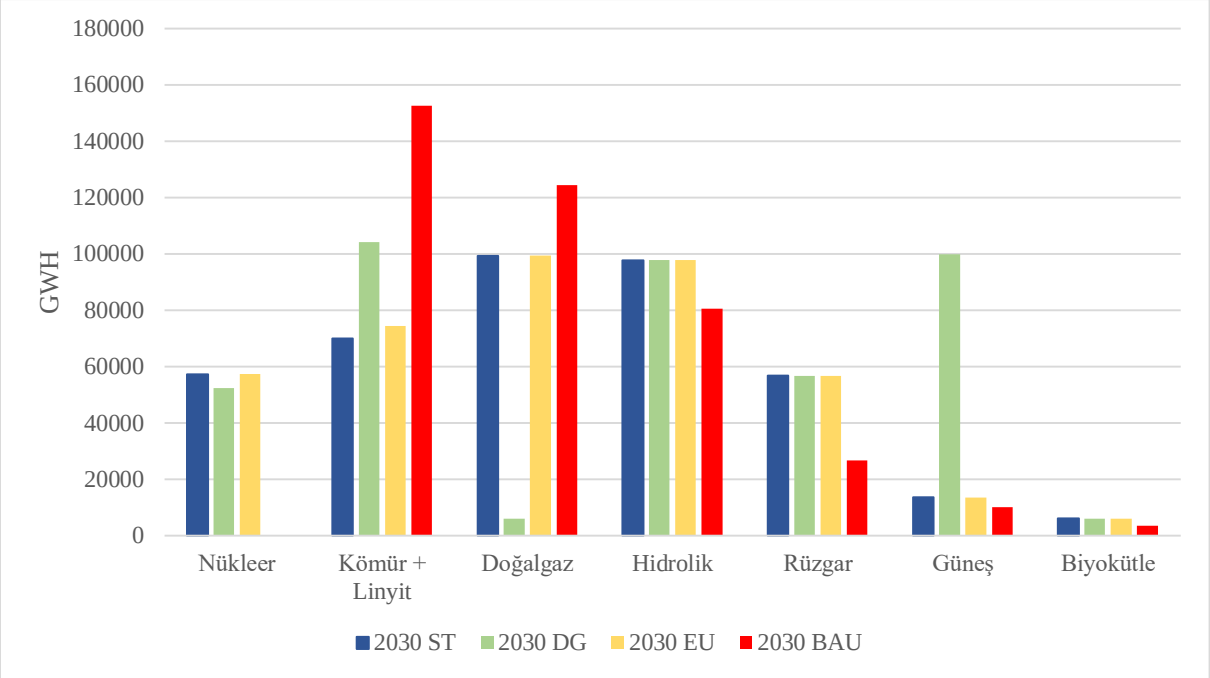
Ülkeler için 2030 ve 2040 yıllarına ait olağan durum (BAU), ST, DG, EU ve GCA senaryoları farklı kaynaklara göre elektrik üretim değerlerinin karşılaştırılması Şekil 4.7-4.12'deki gibidir.



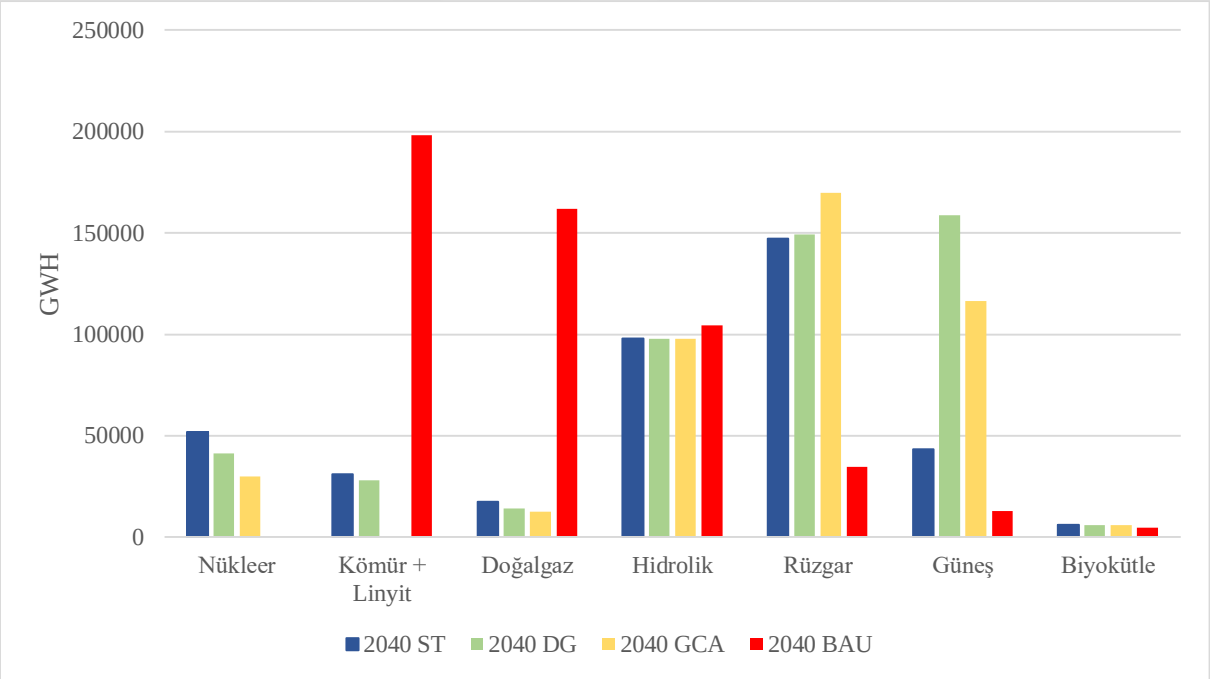
Şekil 4.7 2030 Türkiye'nin Senaryolara Göre Elektrik Üretim Değerleri



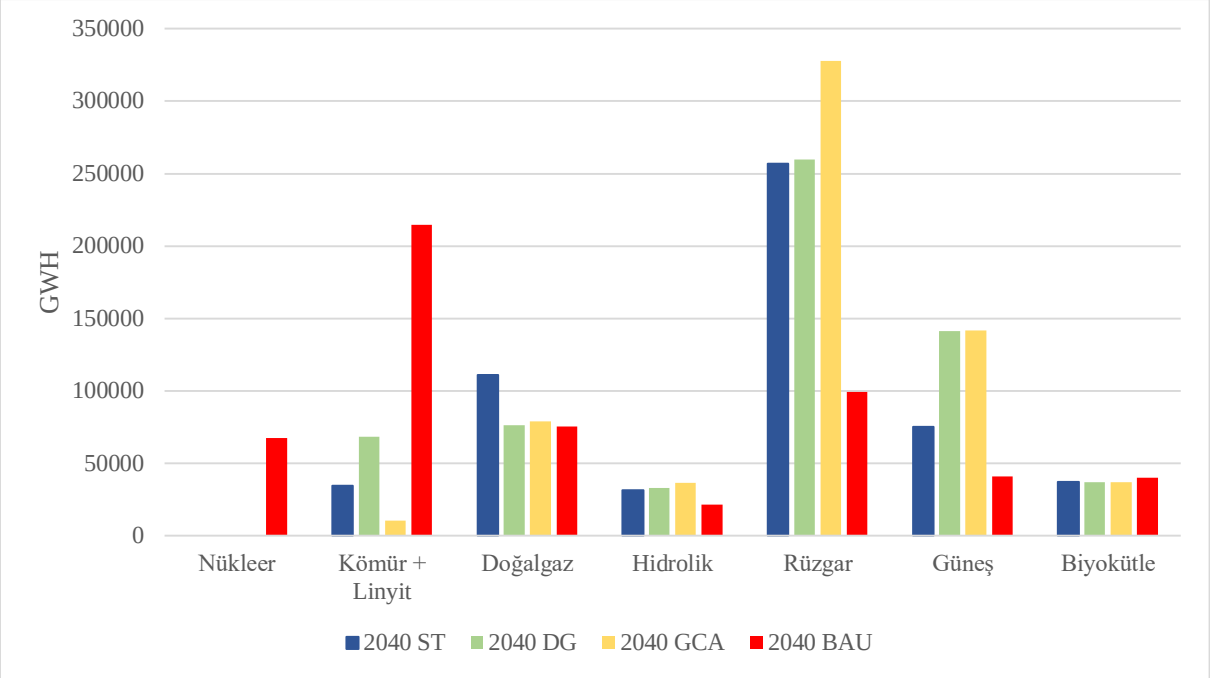
Şekil 4.8 2030 Almanya'nın Senaryolara Göre Elektrik Üretim Değerleri



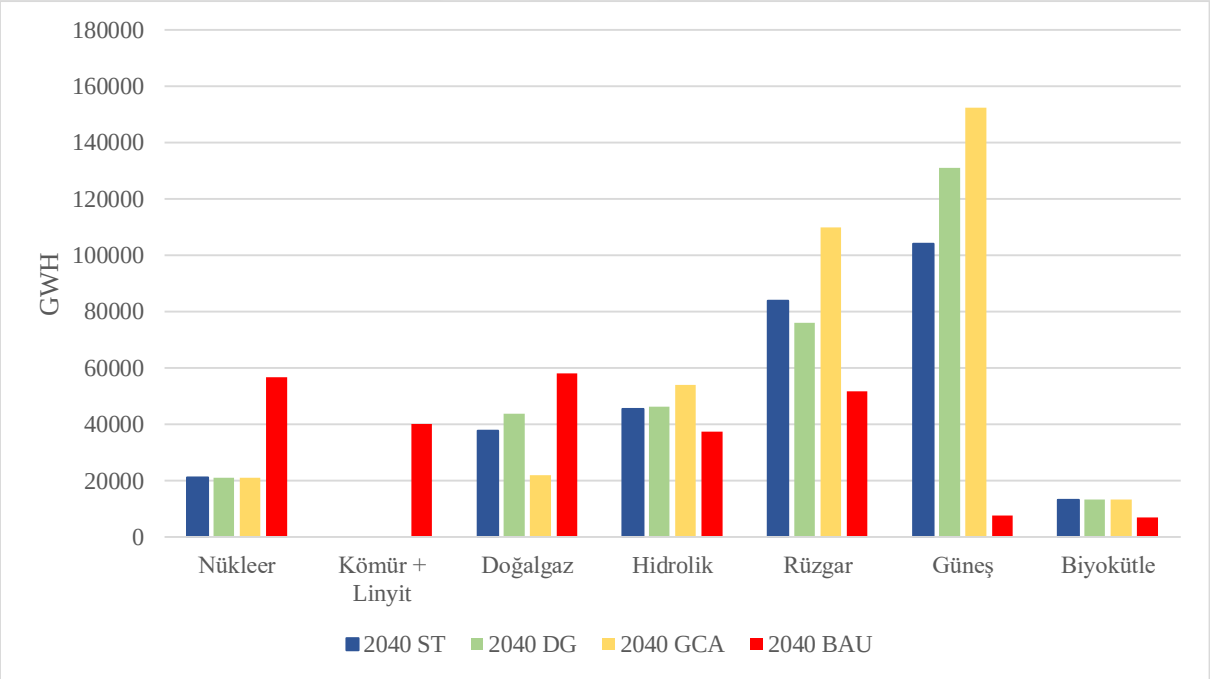
Şekil 4.9 2030 İspanya'nın Senaryolara Göre Elektrik Üretim Değerleri



Şekil 4.10 2040 Türkiye'nin Senaryolara Göre Elektrik Üretim Değerleri



Şekil 4.11 2040 Almanya'nın Senaryolara Göre Elektrik Üretim Değerleri



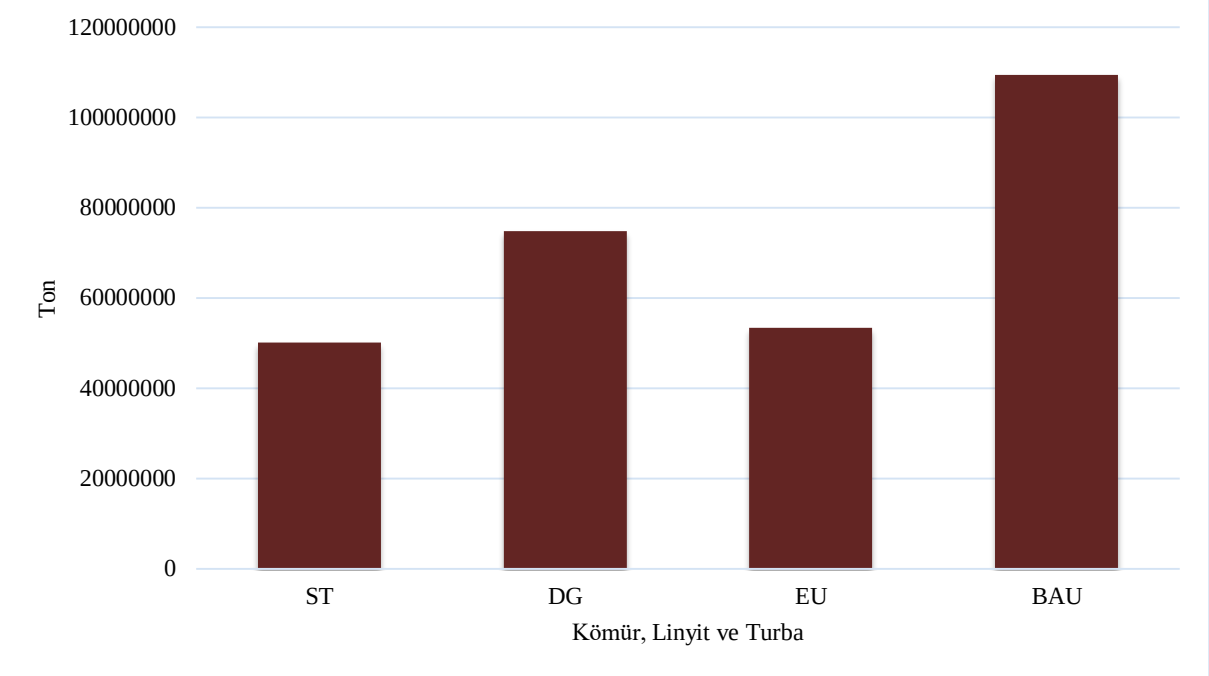
Şekil 4.12 2040 İspanya'nın Senaryolara Göre Elektrik Üretim Değerleri

2030 yılına ait senaryolar incelendiğinde; BAU senaryosuna göre, Türkiye ve İspanya'nın elektrik üretiminde kömür ve doğalgaz kaynakları daha önemliyken, DG senaryosuna göre

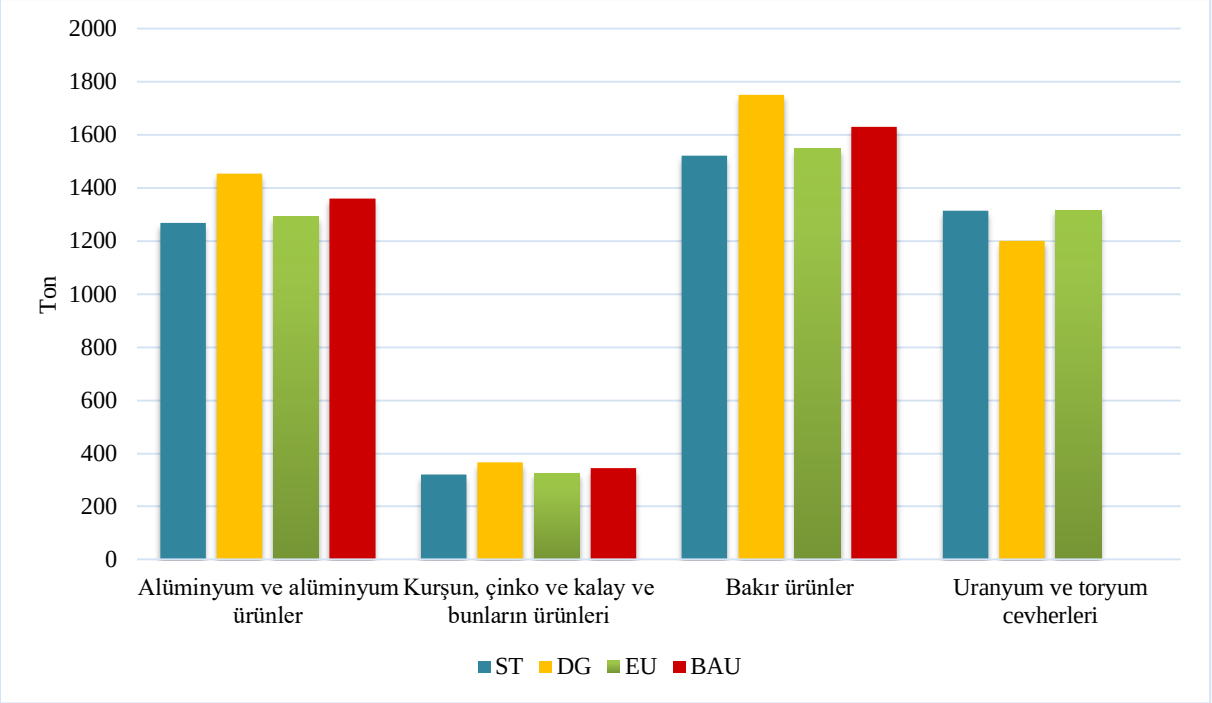
elektrik üretiminde kömür, güneş ve hidrolik kaynakları daha önemlidir. Türkiye ve İspanya için ST ve EU senaryolarında ise doğalgaz ve hidrolik kaynakları ön plana çıkmaktadır. 2030 yılı Almanya elektrik üretiminde, BAU senaryosunda kömür kaynağı ön plana çıkarken, diğer senaryolarda rüzgar enerjisi ile elektrik üretimi daha yüksek değerlere sahiptir.

2040 yılına ait ST, DG ve GCA senaryolarında ise, Türkiye ve Almanya için rüzgar enerjisi ile elektrik üretimi daha çok ön plana çıkarken, İspanya için güneş enerjisi ile elektrik üretimi daha önemlidir.

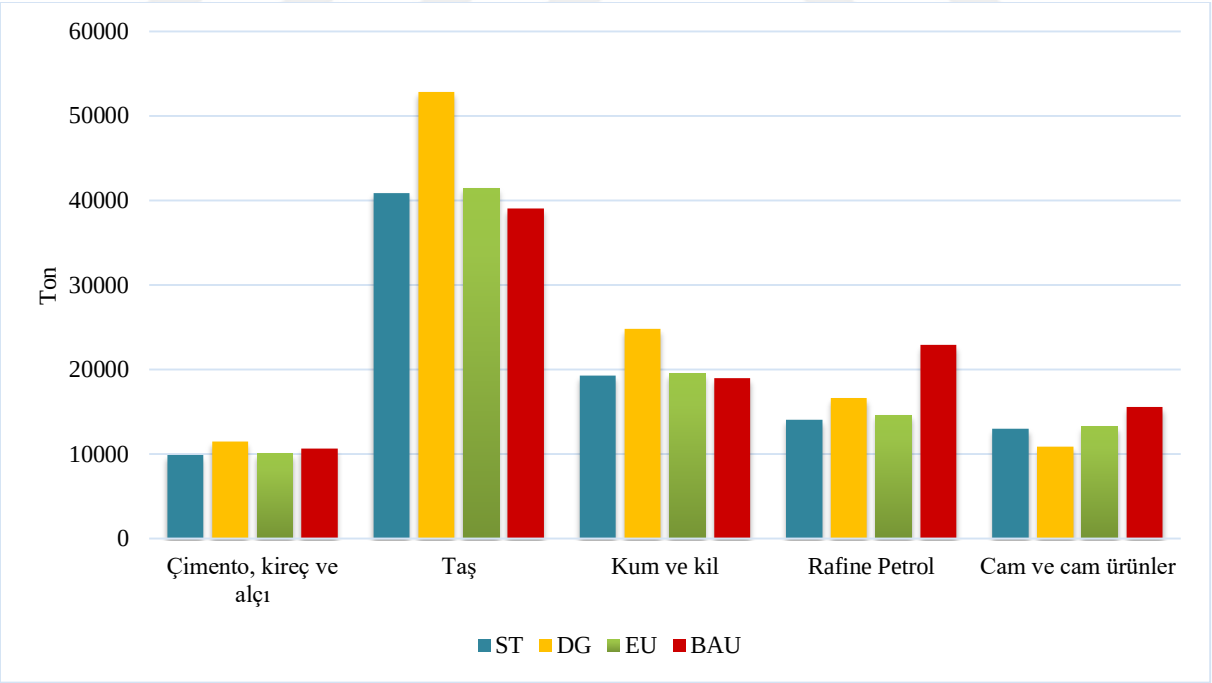
Olağan Durum (BAU), Sürdürülebilir Geçiş (ST), Dağıtılmış Üretim (DG) ve Avrupa Komisyonu (EU) senaryolarına göre, 2030 yılında Türkiye'nin farklı enerji kaynaklarına göre elektrik üretimi sonucunda ortaya çıkacak malzemelerin ayak izleri Şekil 4.13-4.20'deki gibidir.



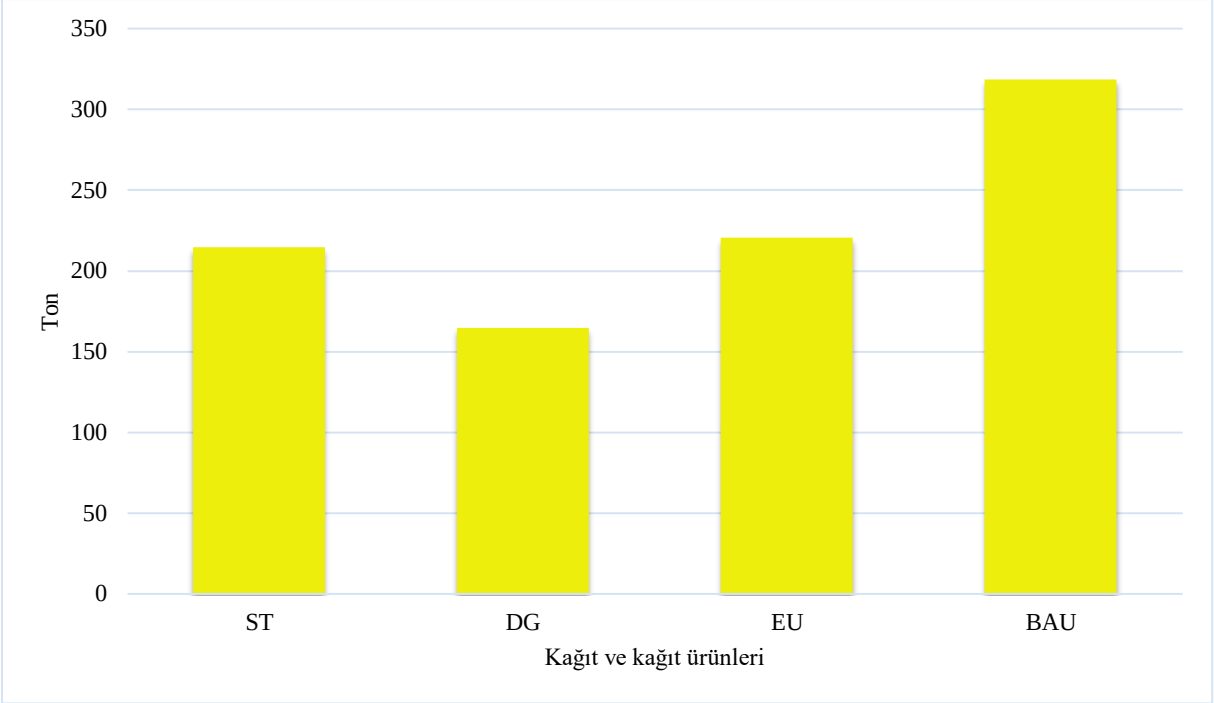
Şekil 4.13 2030 Türkiye Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı



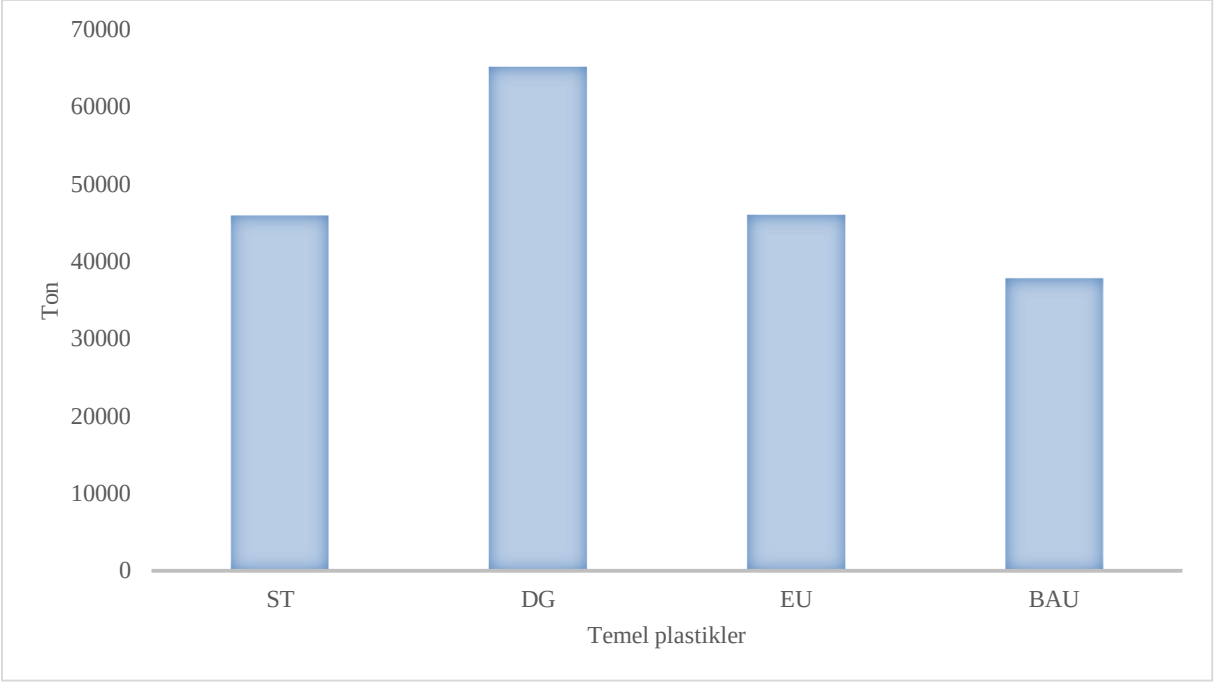
Şekil 4.14 2030 Türkiye Elektrik Üretiminde Metalik Malzeme Kullanımı



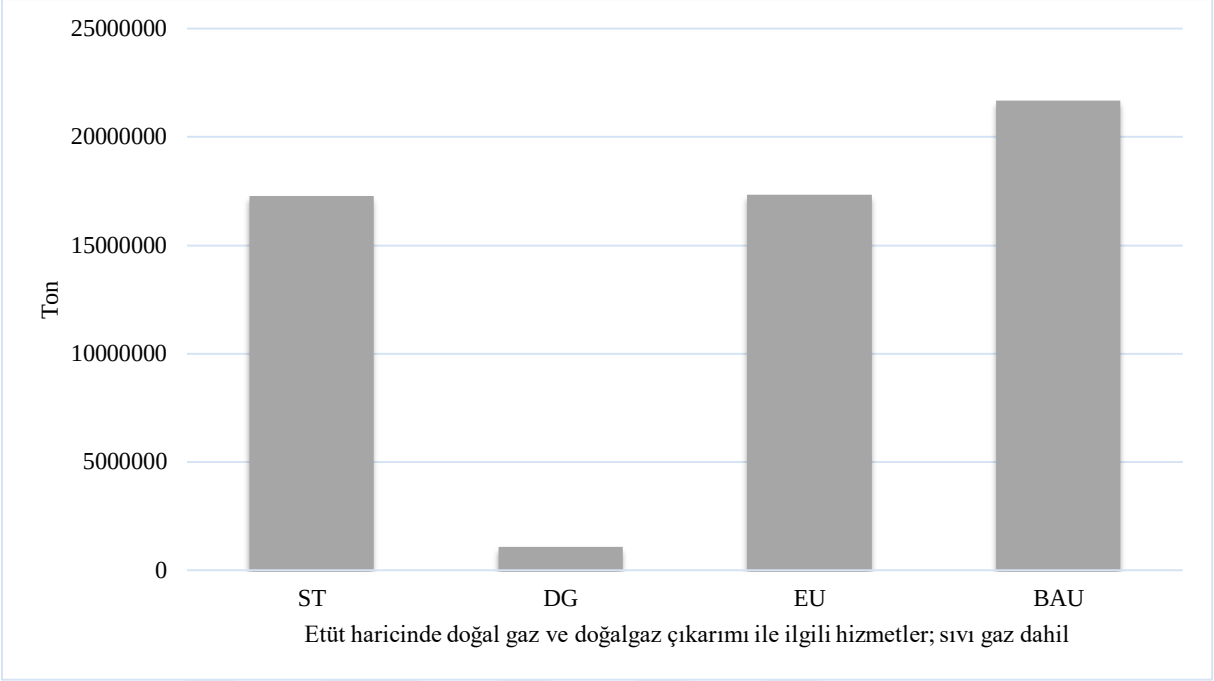
Şekil 4.15 2030 Türkiye Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı



Şekil 4.16 2030 Türkiye Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı



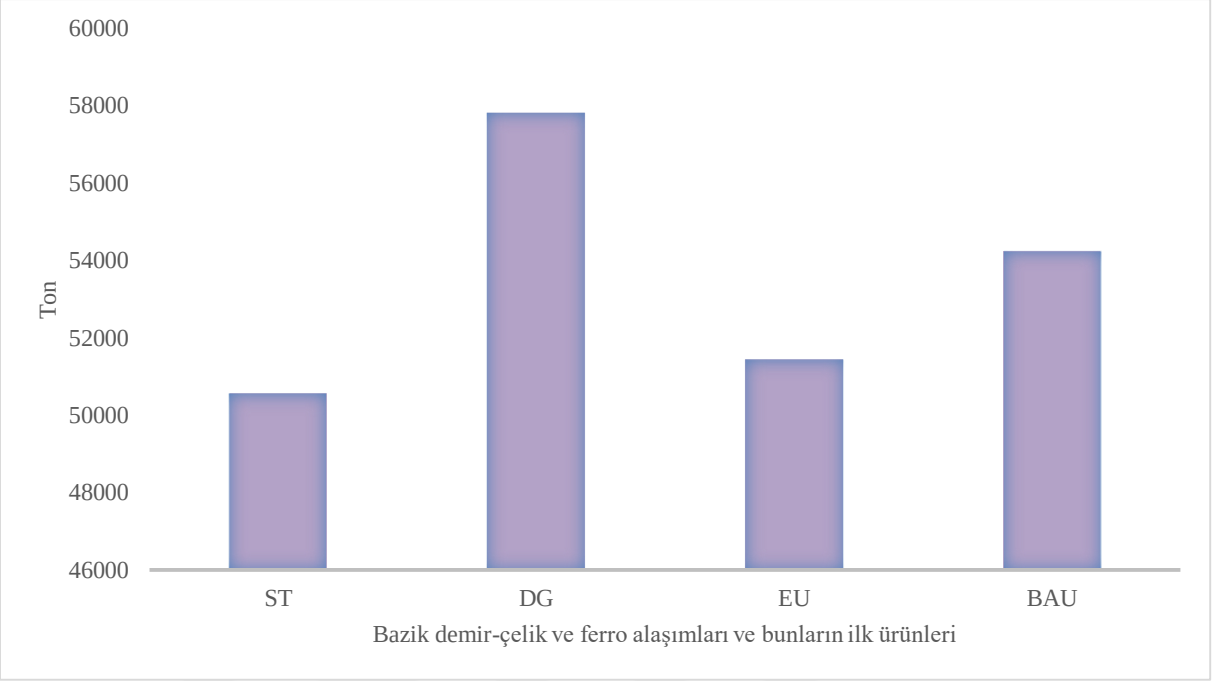
Şekil 4.17 2030 Türkiye Elektrik Üretiminde Plastik Kullanımı



Şekil 4.18 2030 Türkiye Elektrik Üretiminde Sıvı Gaz Kullanımı



Şekil 4.19 2030 Türkiye Elektrik Üretiminde Ormancılık Ürünleri Kullanımı

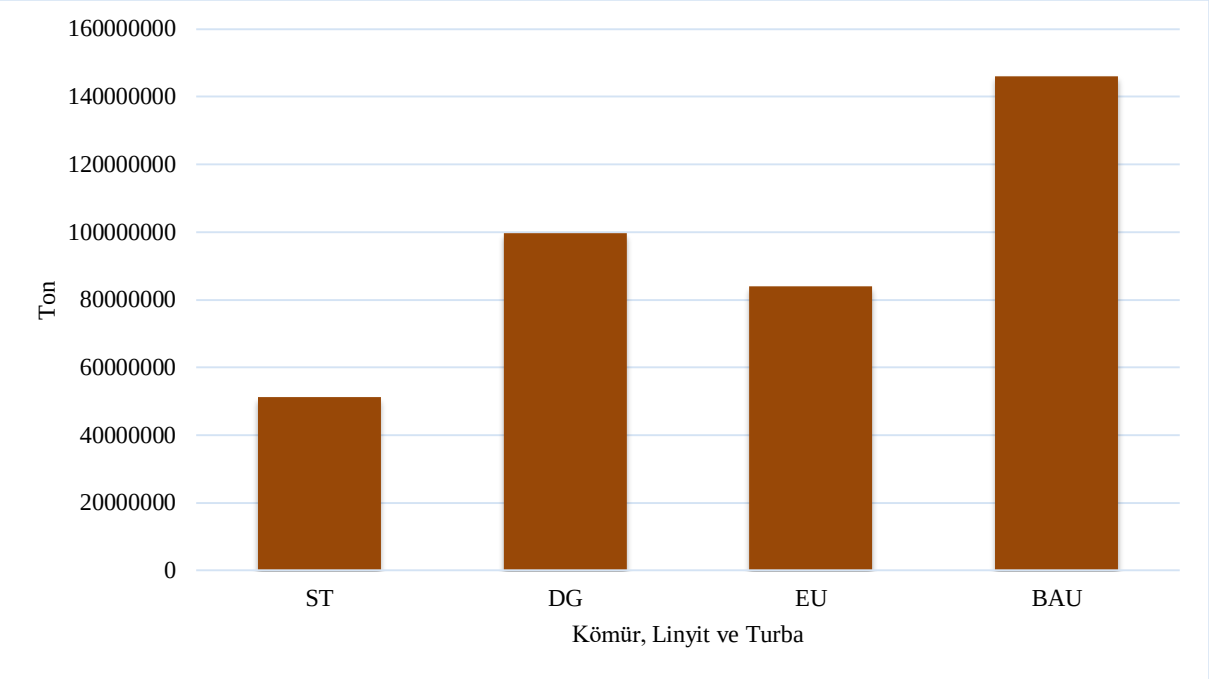


Şekil 4.20 2030 Türkiye Elektrik Üretiminde Demir-Çelik Kullanımı

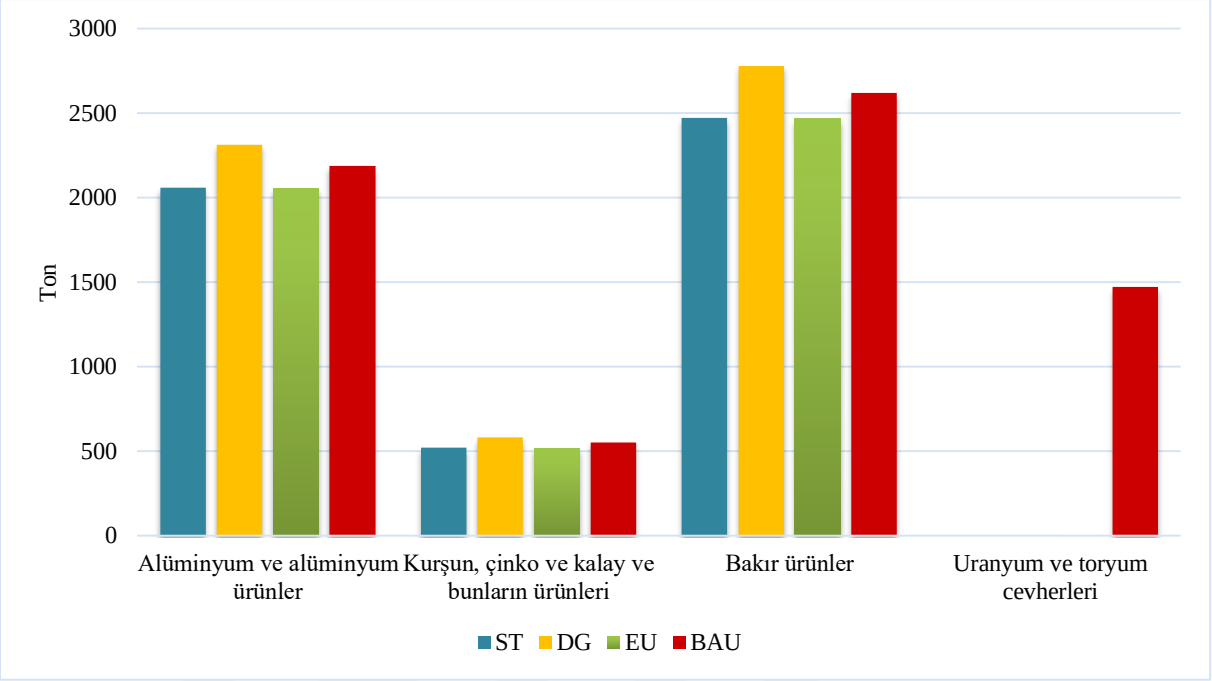
2030 yılı Türkiye elektrik üretimi için BAU senaryosunda kömür ile linyit, sıvı gaz ve kağıt ile kağıt ürünleri kullanımı diğer senaryolardaki kullanıma göre daha fazladır. BAU senaryosunun uygulanması sonucunda 109391517 ton kömür ve linyit kullanımı beklenmektedir. ST senaryosuna göre ise 50160412 tonluk kömür ve linyit kullanımı beklenmektedir. Temel plastikler ve demir-çelik kullanımı ise en çok DG senaryosunun uygulanması sonucunda ortaya çıkacağı tespit edilmiştir. DG senaryosunun uygulanması sonucunda 57819 ton demir çelik kullanımı gerçekleşeceği bulunmuştur. Alüminyum, kurşun, çinko, kalay ve bakır ürünlerinin kullanımı yine en çok DG senaryosunda gerçekleşeceği hesaplanırken, ST ve EU senaryolarında nükleer enerji ile elektrik üretimden kaynaklı toryum ve uranyum malzemelerinin kullanımı daha yüksek olacağı bulunmuştur. Metalik olmayan malzemelerden çimento, taş, kum ve kil kullanımı, DG senaryosunda daha yüksek olması beklenirken, senaryosuz olağan durumda rafine petrol ve cam ürünleri kullanımının daha yüksek olacağı tespit edilmiştir. Ormancılık ürünlerinin kullanımında ise senaryolu durumun olağan duruma göre daha yüksek malzeme ayak izine yol açacağı bulunmuştur. ST, DG veya EU senaryoları uygulandığında 1067135 tonluk ormancılık ürünü kullanımı olacağı hesaplanmıştır.

Her dört senaryo için toplam elektrik üretim değerleri birbirlerine yakın olduğundan, senaryoların ton/gwh açısından karşılaştırma yapıldığında sonuçların farklı olmayacağı tespit edilmiştir.

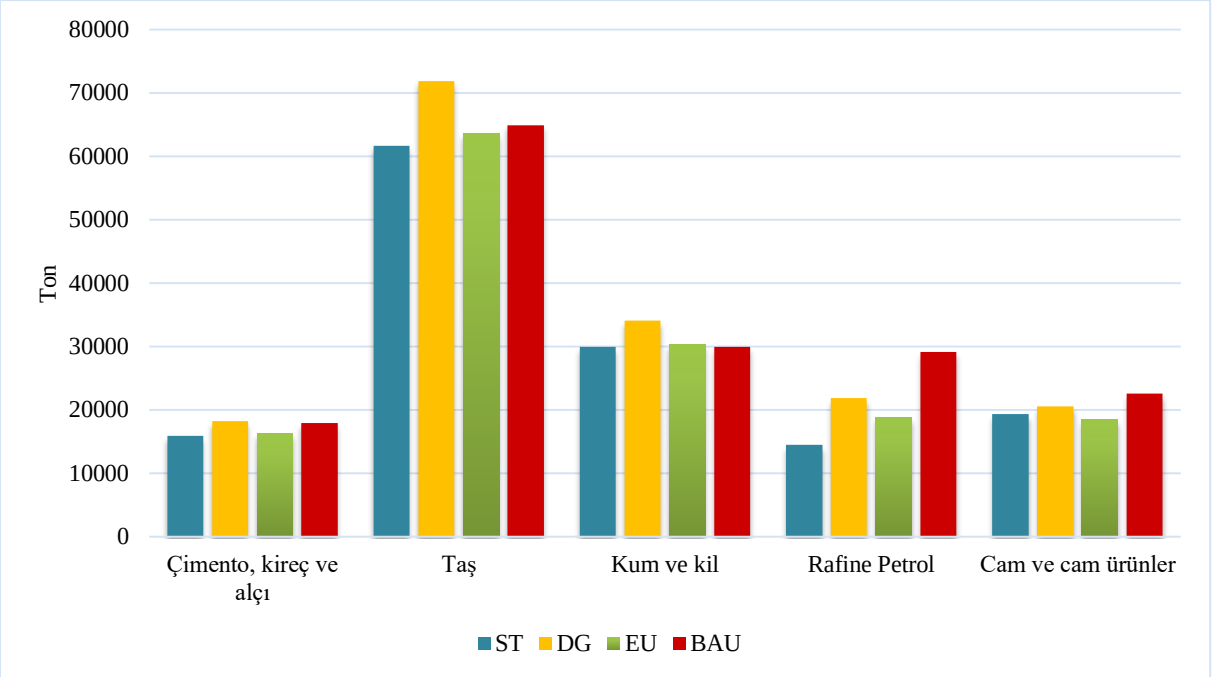
BAU, ST, DG ve EU senaryolarına göre, 2030 yılında Almanya'nın farklı enerji kaynaklarına göre elektrik üretimi sonucunda ortaya çıkacak malzemelerin ayak izleri Şekil 4.21-4.28'deki gibidir.



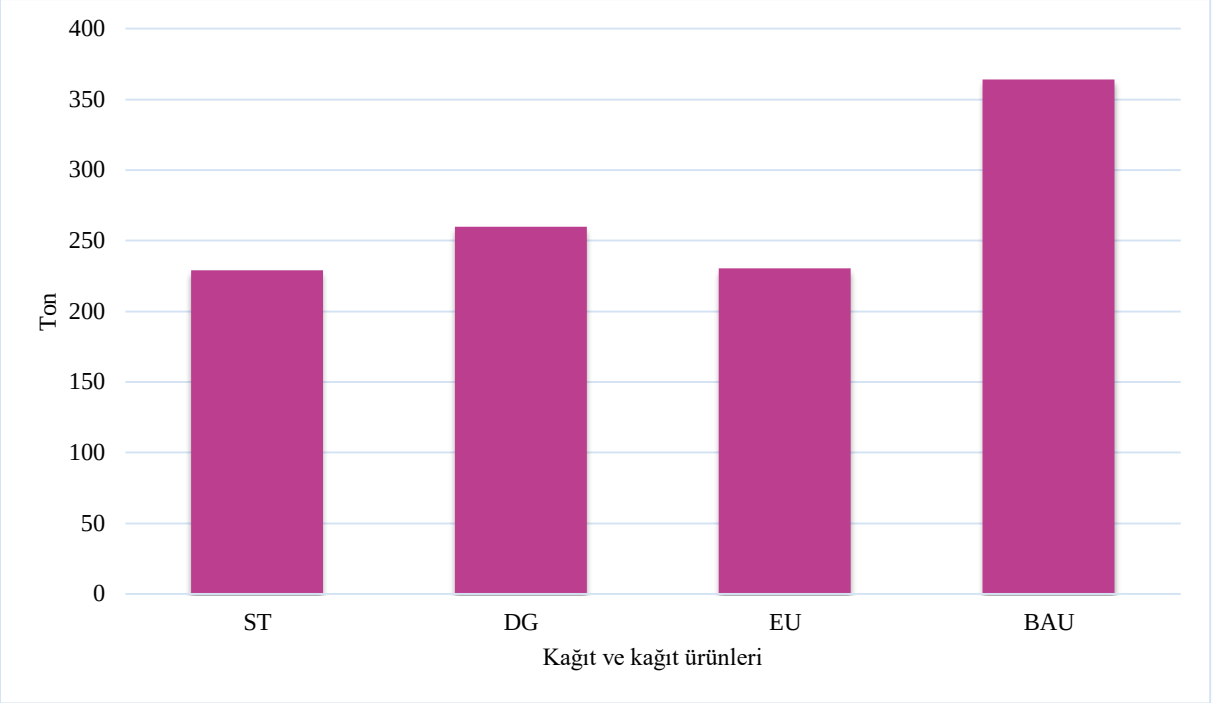
Şekil 4.21 2030 Almanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı



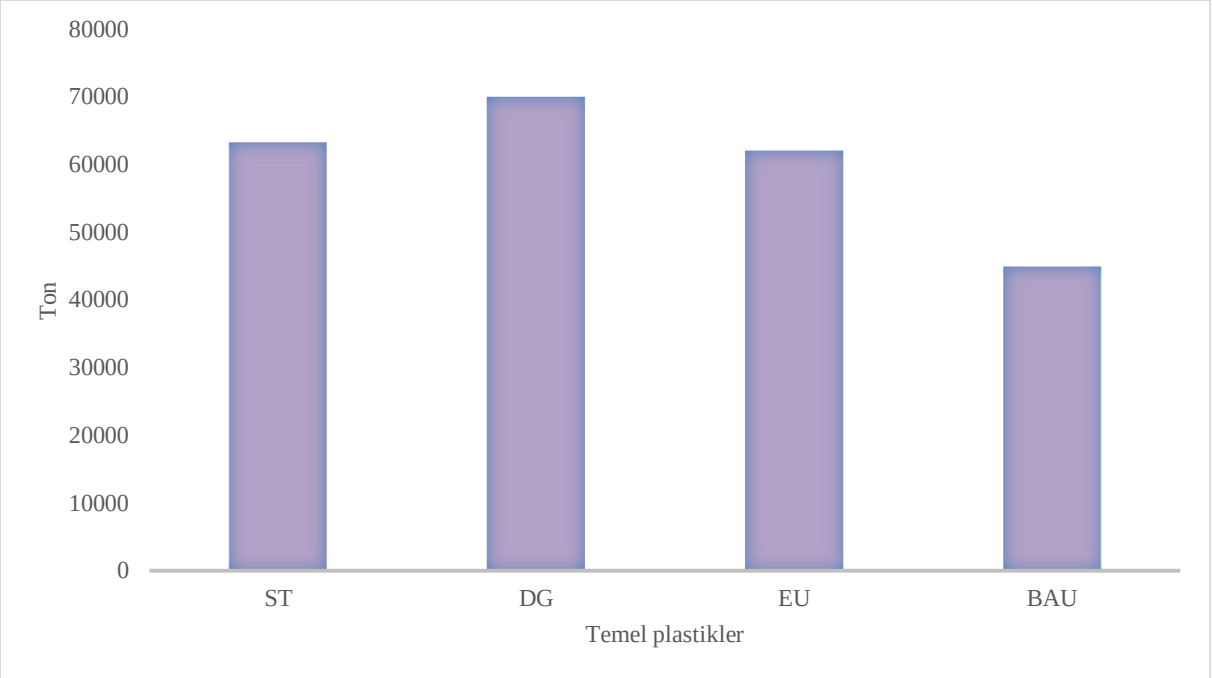
Şekil 4.22 2030 Almanya Elektrik Üretiminde Metalik Malzeme Kullanımı



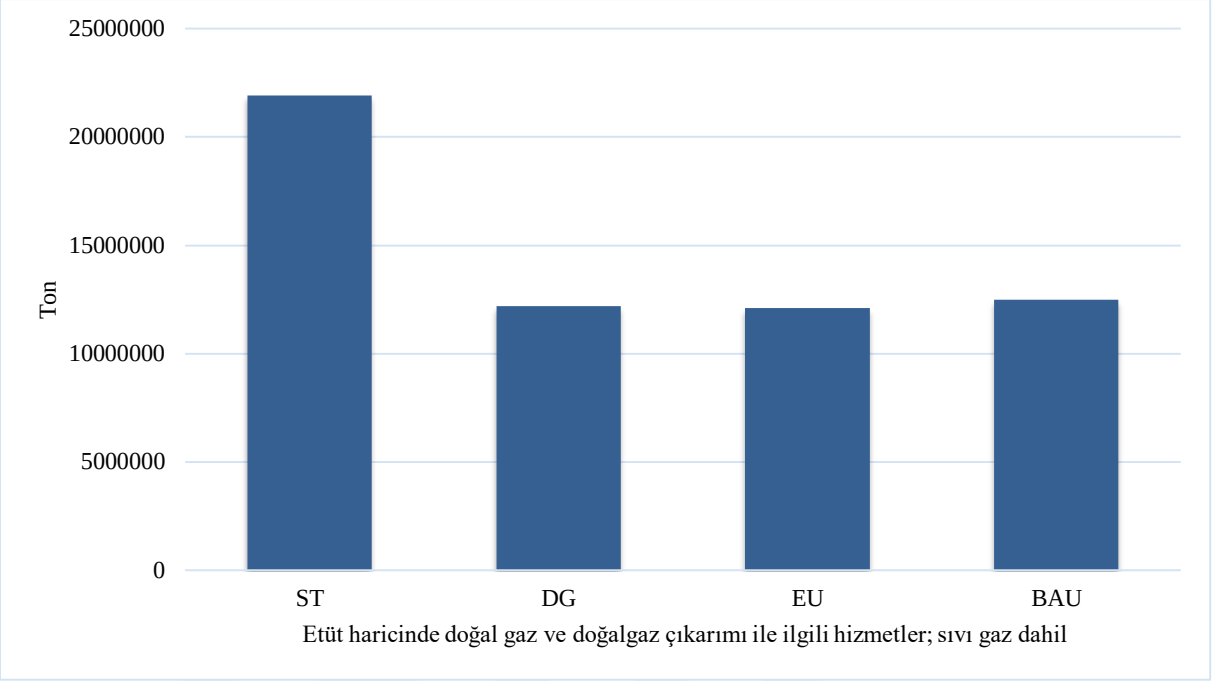
Şekil 4.23 2030 Almanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı



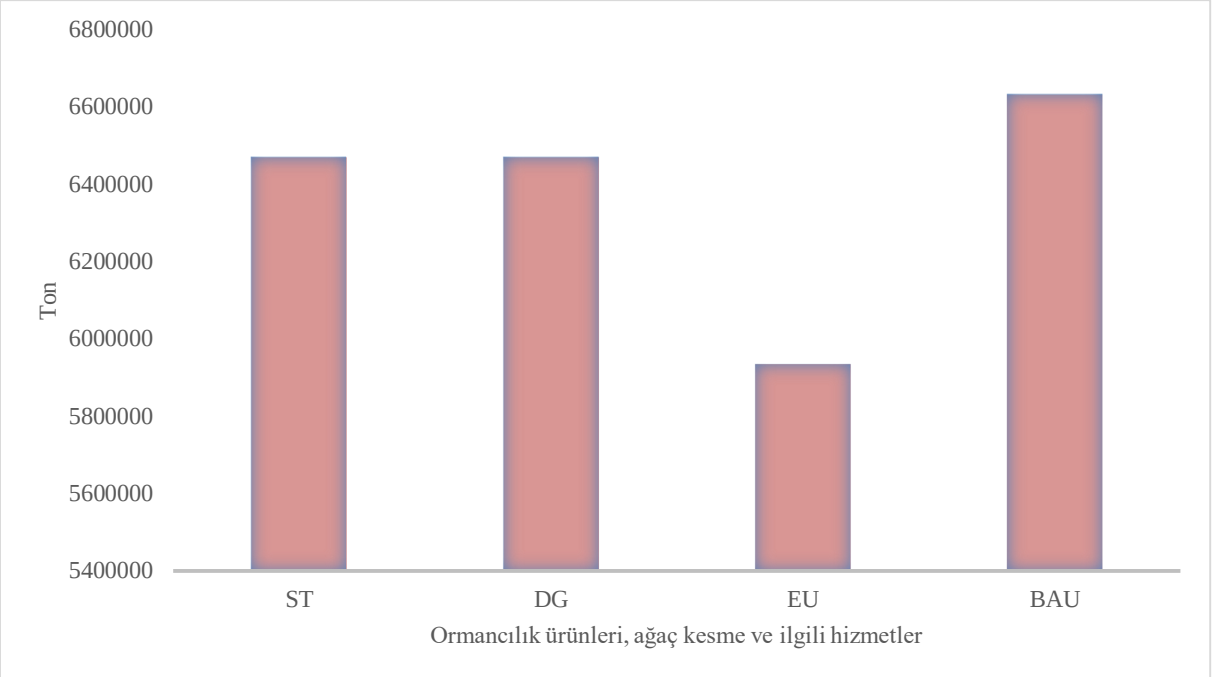
Şekil 4.24 2030 Almanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı



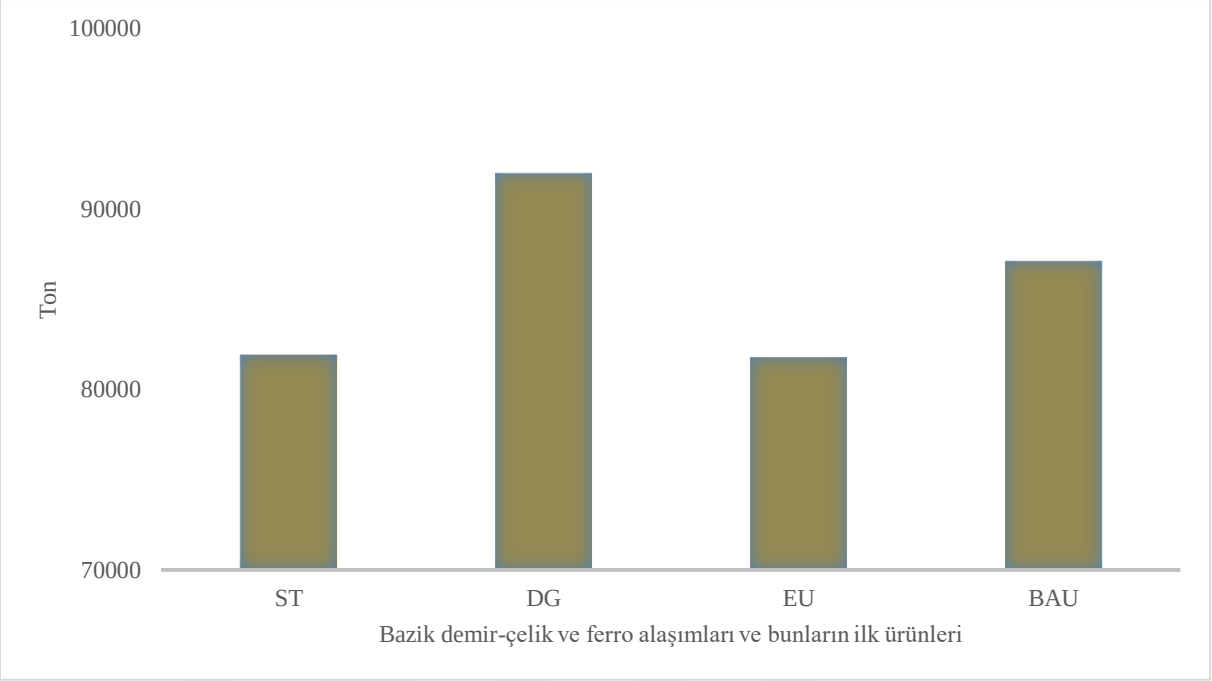
Şekil 4.25 2030 Almanya Elektrik Üretiminde Plastik Kullanımı



Şekil 4.26 2030 Almanya Elektrik Üretiminde Sıvı Gaz Kullanımı



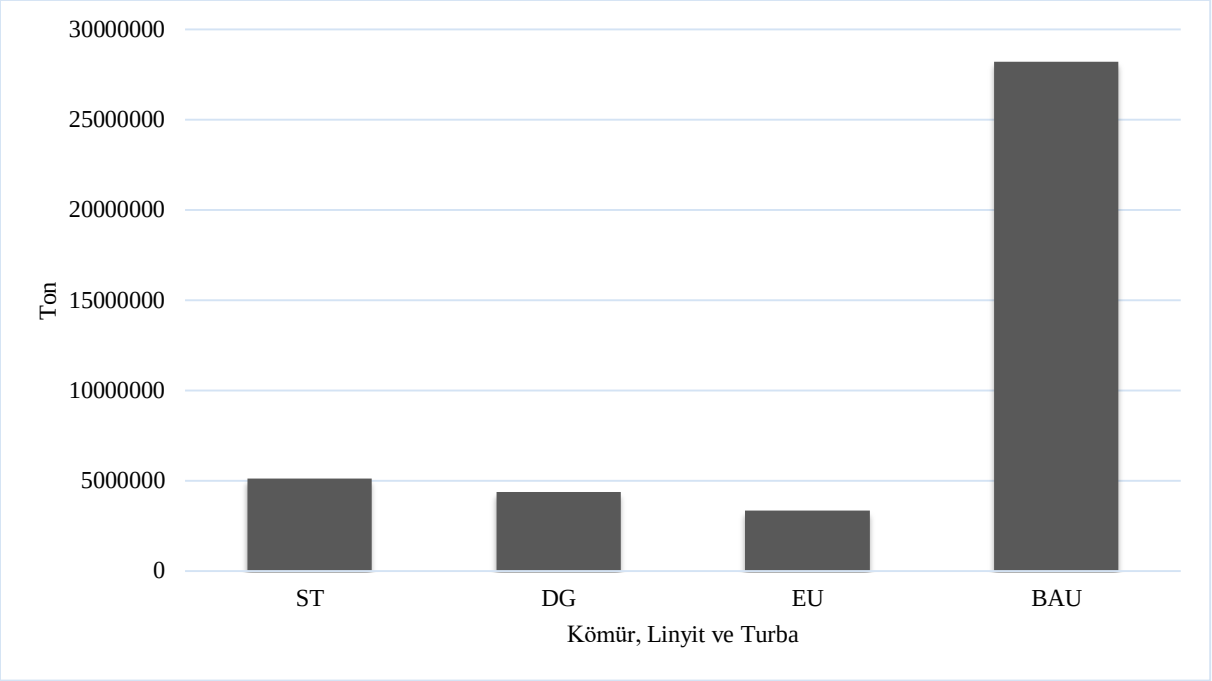
Şekil 4.27 2030 Almanya Elektrik Üretiminde Ormancılık Ürünleri Kullanımı



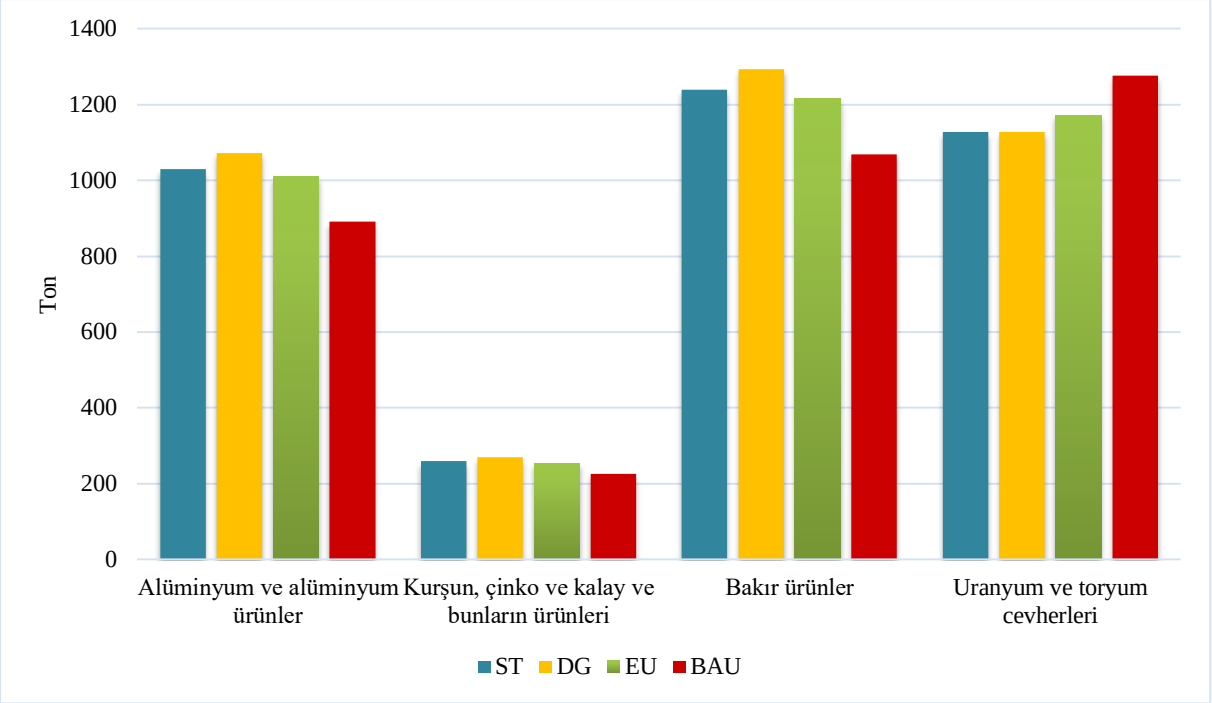
Şekil 4.28 2030 Almanya Elektrik Üretiminde Demir-Çelik Kullanımı

2030 yılı Almanya elektrik üretimi için BAU senaryosundaki kömür ve linyit kullanımının diğer senaryolardaki kullanıma göre çok daha yüksek olacağı bulunmuştur. BAU senaryosu ile 146111138 ton kömür ve linyit kullanımı gerçekleşeceği belirlenmiştir. DG senaryosu sonucunda ortaya çıkacak 91956 ton demir-çelik ile en yüksek değere sahipken, EU senaryosunun uygulanması sonucunda 81794 ton demir-çelik kullanımı ile en düşük değere sahiptir. Sıvı gaz malzeme ayak izi açısından değerlendirildiğinde; ST senaryosundaki malzeme ayak izi en yüksek iken, diğer senaryoların uygulanmasında ortaya çıkacak malzeme ayak izi yaklaşık olarak birbirlerine eşit ve ST senaryosunda ortaya çıkacak malzeme kullanımın yaklaşık yarısıdır. Metalik malzeme kullanımı değerlendirildiğinde; ST ve EU senaryolarındaki malzeme kullanımı diğer senaryolara göre daha azdır. Olağan durumdaki uranyum ve toryum kullanımı 1471 ton olacağı tespit edilmiştir. Metalik olmayan malzemelerden çimento, taş, kum ve kil kullanımı, DG senaryosunda daha yüksek olması beklenirken, senaryosuz olağan durumda rafine petrol ve cam ürünleri kullanımının daha yüksek olacağı tespit edilmiştir. EU senaryosundaki ormancılık ürünleri kullanımı diğer senaryolardaki kullanıma göre daha az ve avantajlıdır.

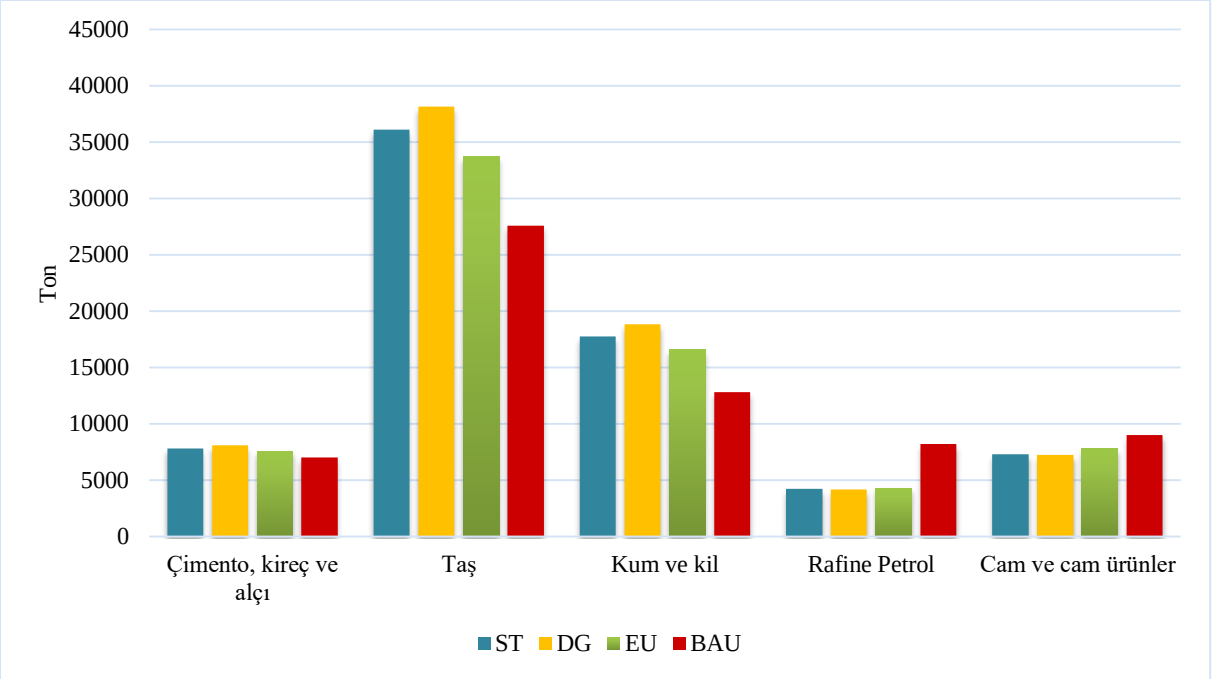
BAU, ST, DG ve EU senaryolarına göre, 2030 yılında İspanya'nın farklı enerji kaynaklarına göre elektrik üretimi sonucunda ortaya çıkacak malzemelerin ayak izleri Şekil 4.29-4.36'daki gibidir.



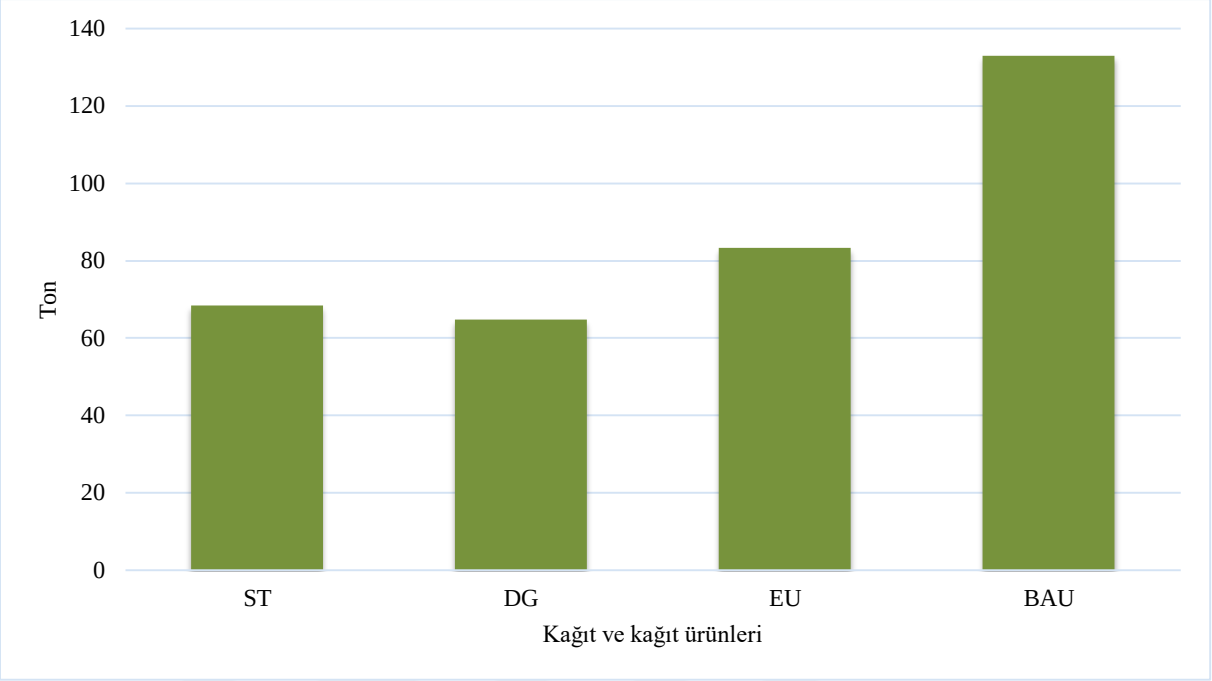
Şekil 4.29 2030 İspanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı



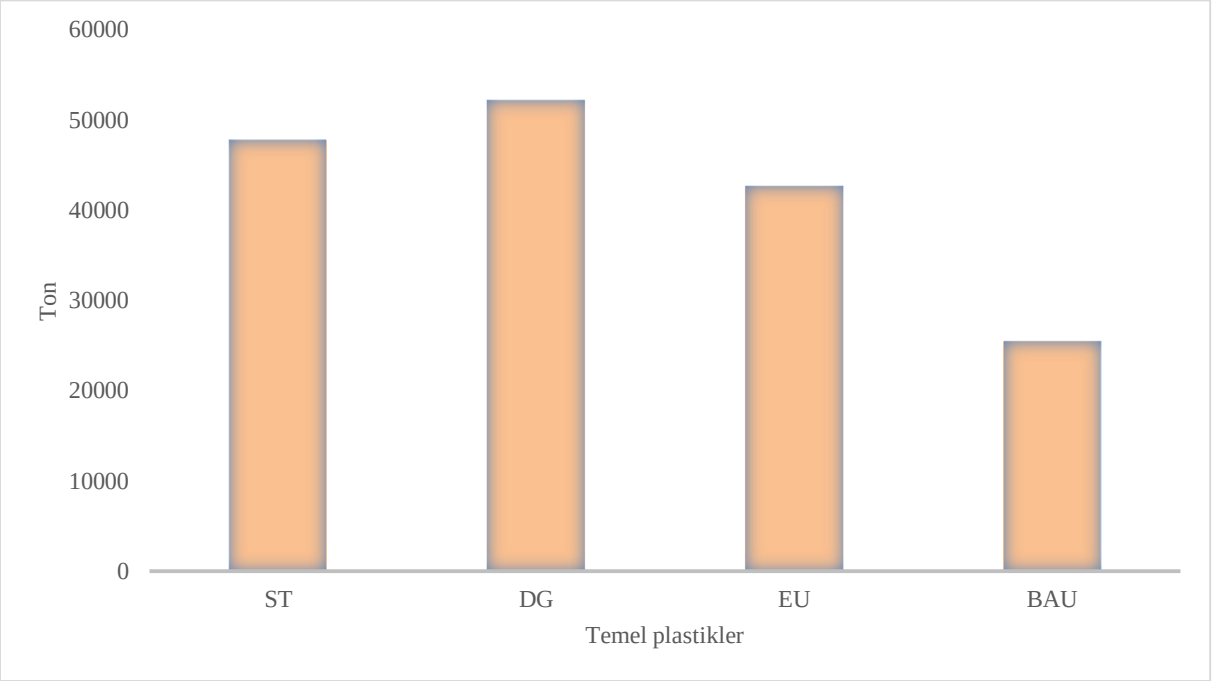
Şekil 4.30 2030 İspanya Elektrik Üretiminde Metalik Malzeme Kullanımı



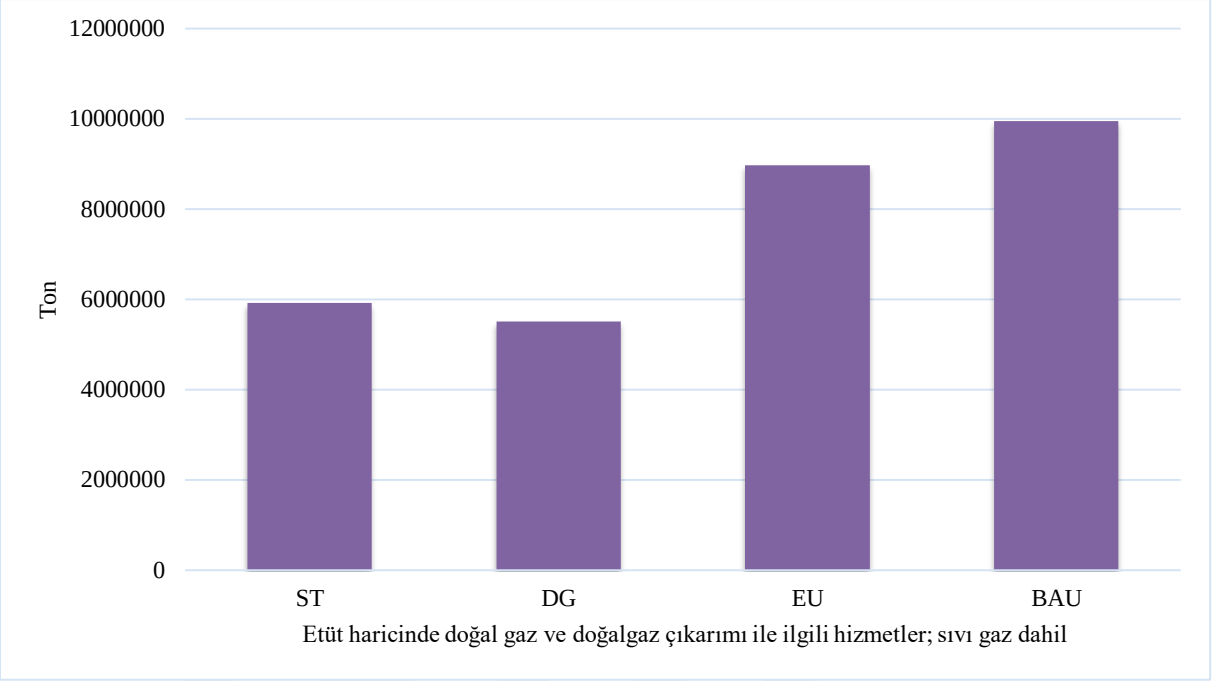
Şekil 4.31 2030 İspanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı



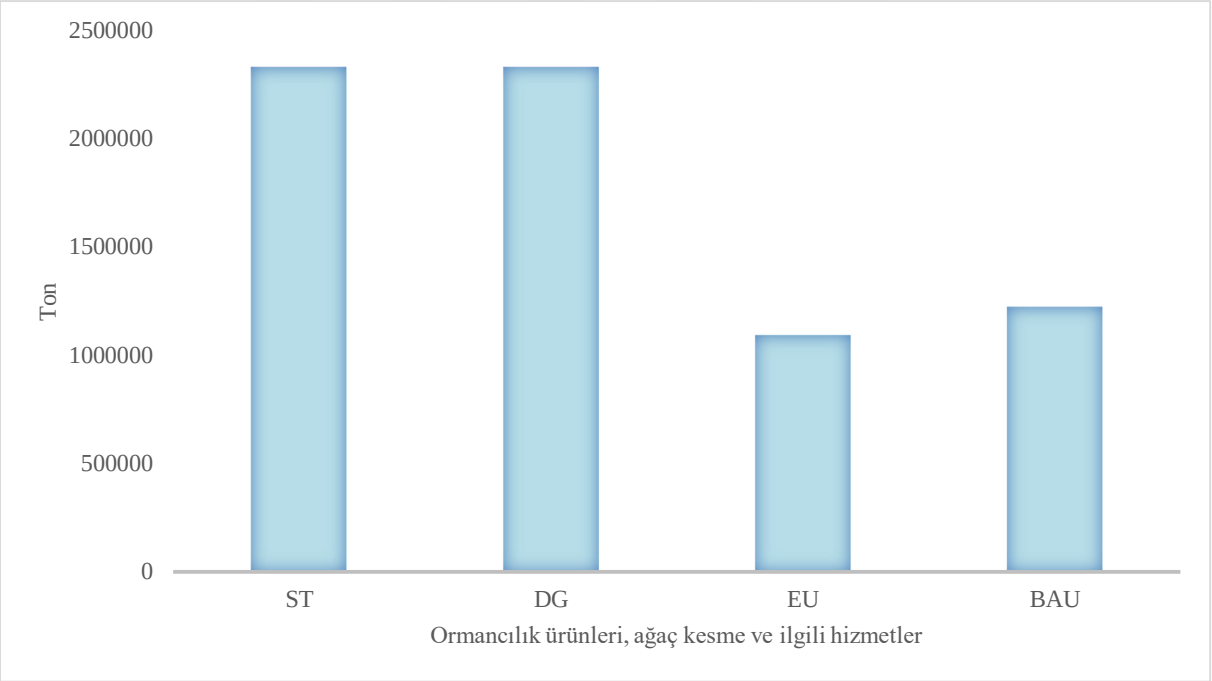
Şekil 4.32 2030 İspanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı



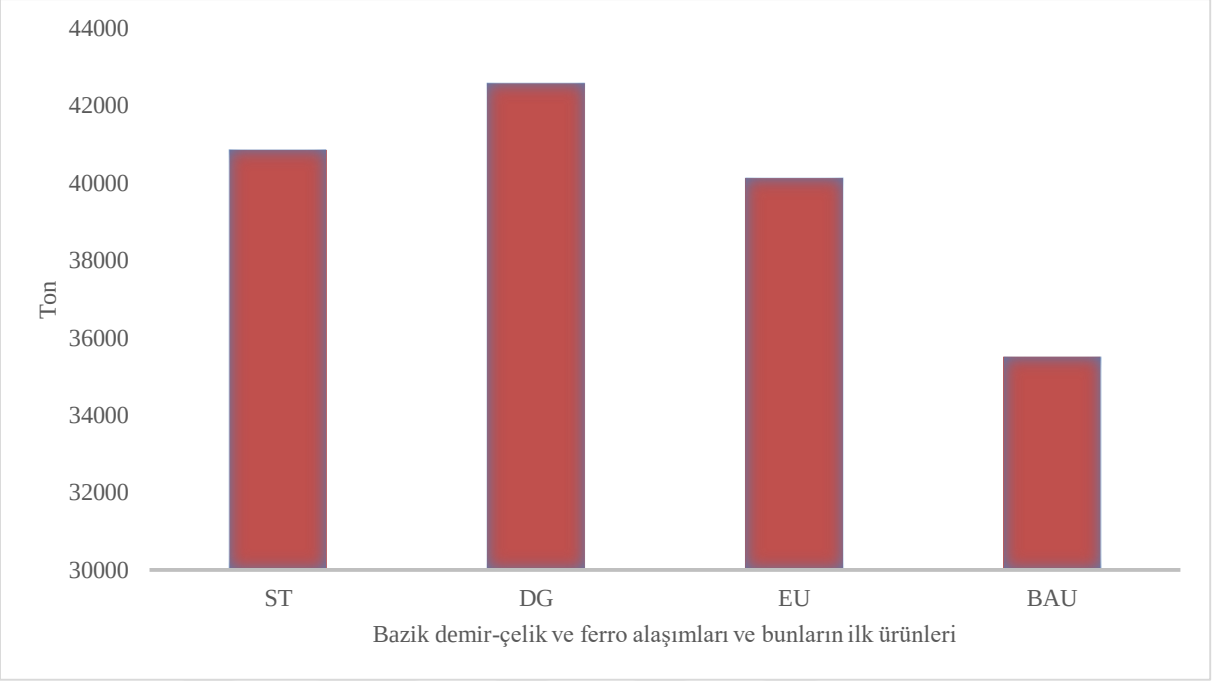
Şekil 4.33 2030 İspanya Elektrik Üretiminde Plastik Kullanımı



Şekil 4.34 2030 İspanya Elektrik Üretiminde Sıvı Gaz Kullanımı



Şekil 4.35 2030 İspanya Elektrik Üretiminde Ormancılık Ürünleri Kullanımı

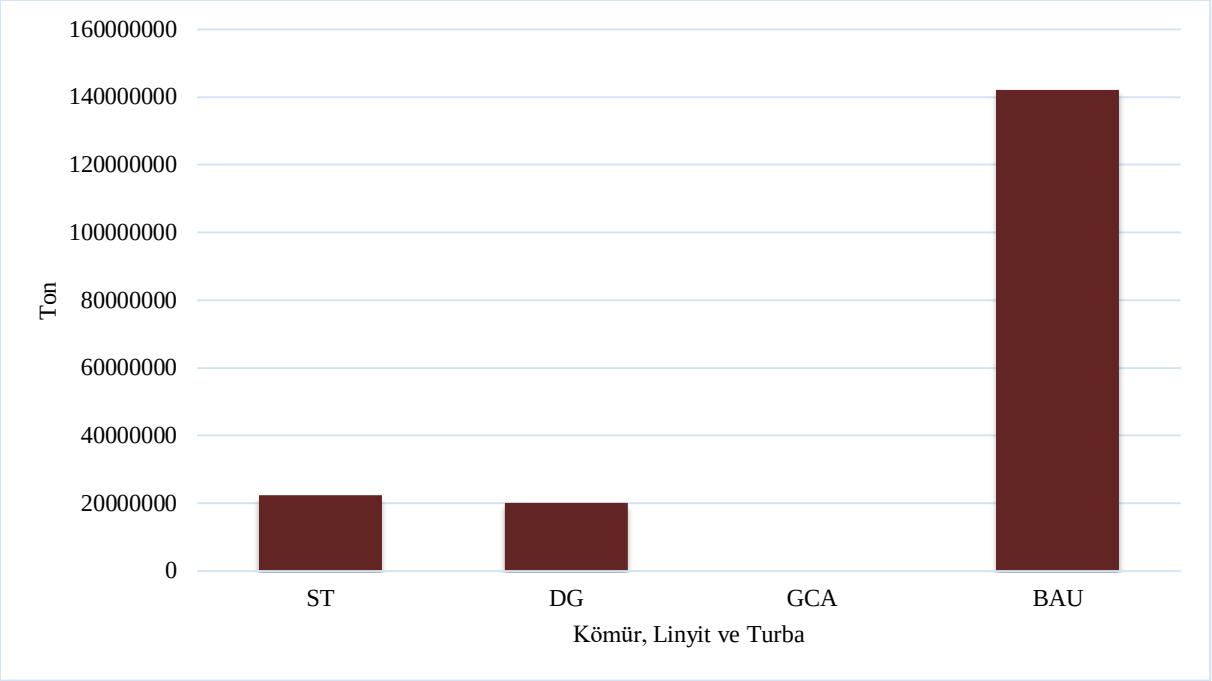


Şekil 4.36 2030 İspanya Elektrik Üretiminde Demir-Çelik Kullanımı

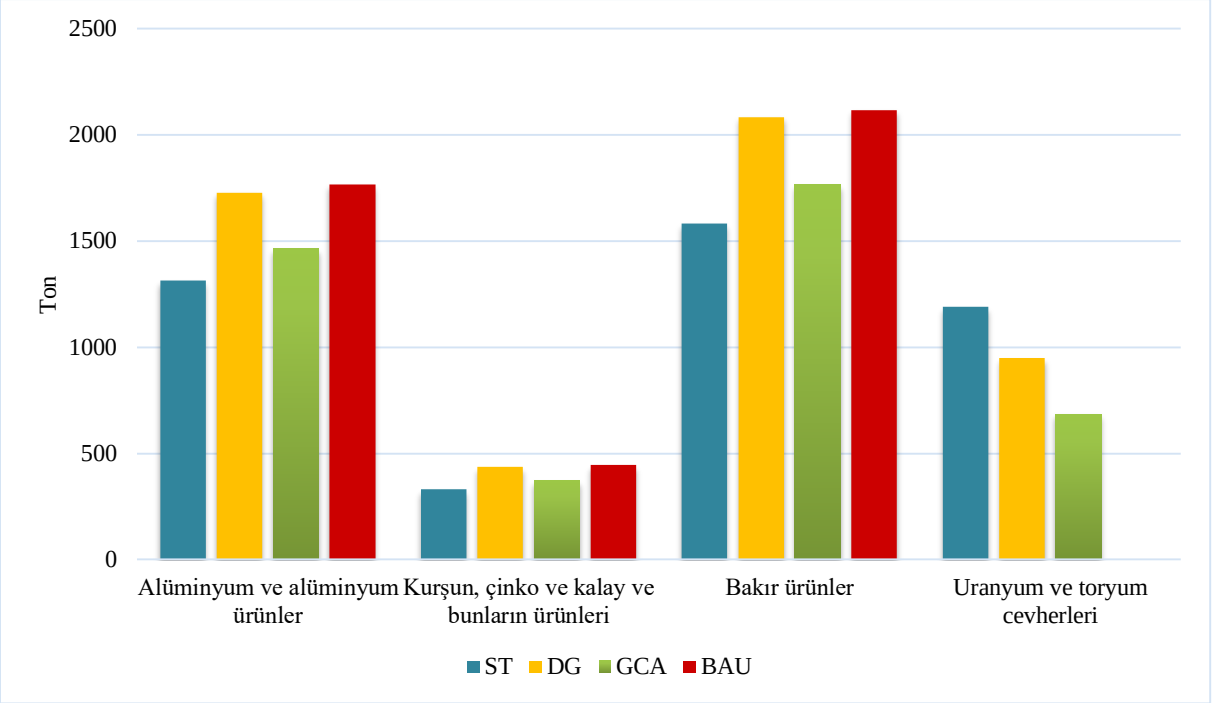
2030 yılı İspanya elektrik üretimi için BAU senaryosundaki kömür ve linyit kullanımının diğer senaryolardaki kullanıma göre çok daha yüksek olacağı bulunmuştur. BAU senaryosu ile 28208363 ton kömür ve linyit kullanımı gerçekleşeceği belirlenirken, EU senaryosundaki kullanımın yaklaşık 9 kat daha az olacağı tespit edilmiştir. BAU senaryosundaki demir-çelik kullanımı ise 35517 ton ile diğer senaryolardaki kullanıma göre daha avantajlıdır. Metalik malzemeler değerlendirildiğinde; alüminyum, kurşun, çinko, kalay ve bakır ürünlerinin en çok DG senaryosunda kullanılacakları hesaplanırken, BAU senaryosunda uranyum ve toryum kullanımının daha yüksek olacağı tespit edilmiştir. Metalik olmayan malzemelerden çimento, taş, kum ve kil kullanımının, DG senaryosunda daha yüksek olması beklenirken, senaryosuz olağan durumda rafine petrol ve cam ürünleri kullanımının daha yüksek olacağı tespit edilmiştir.

İspanya için malzeme kullanımındaki farkların, kullanılan enerji kaynağı ile ilgili olduğu gibi senaryodaki toplam elektrik üretimi ile de alakalıdır. 2030 DG senaryosundaki toplam elektrik üretimi 304317 GWH iken, BAU senaryosundaki toplam elektrik üretimi 254390 GWH'tir.

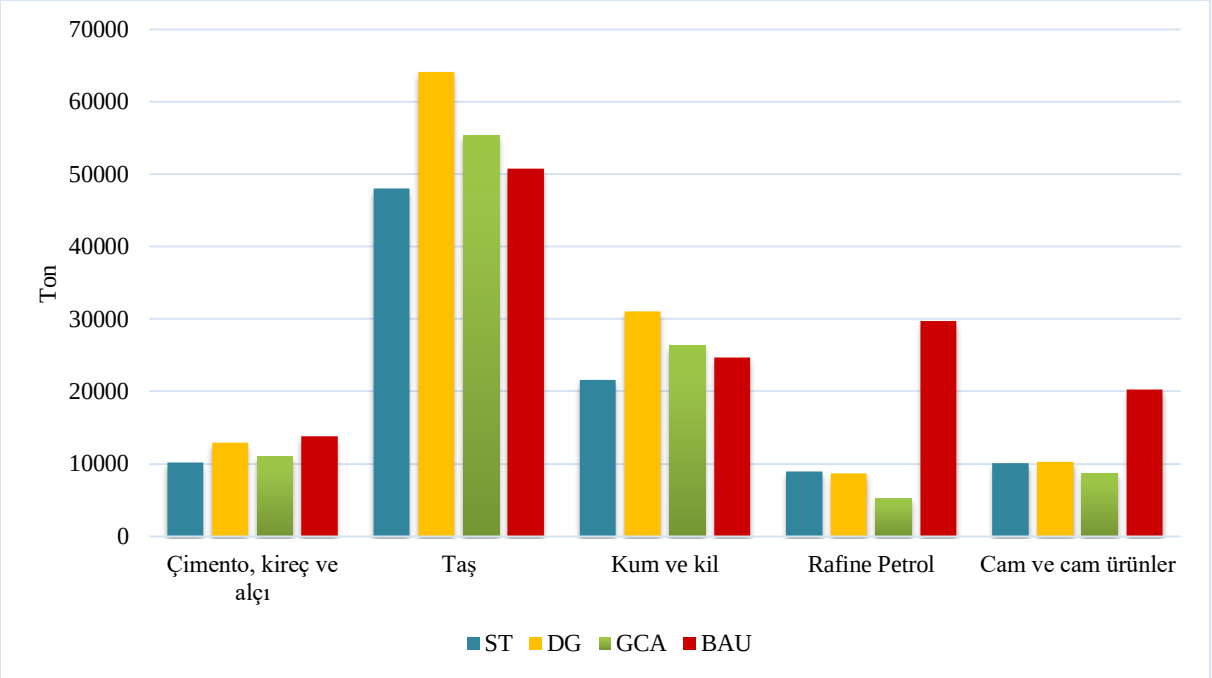
BAU, ST, DG ve EU senaryolarına göre, 2040 yılında Türkiye'nin farklı enerji kaynaklarına göre elektrik üretimi sonucunda ortaya çıkacak malzemelerin ayak izleri Şekil 4.37-4.44'teki gibidir.



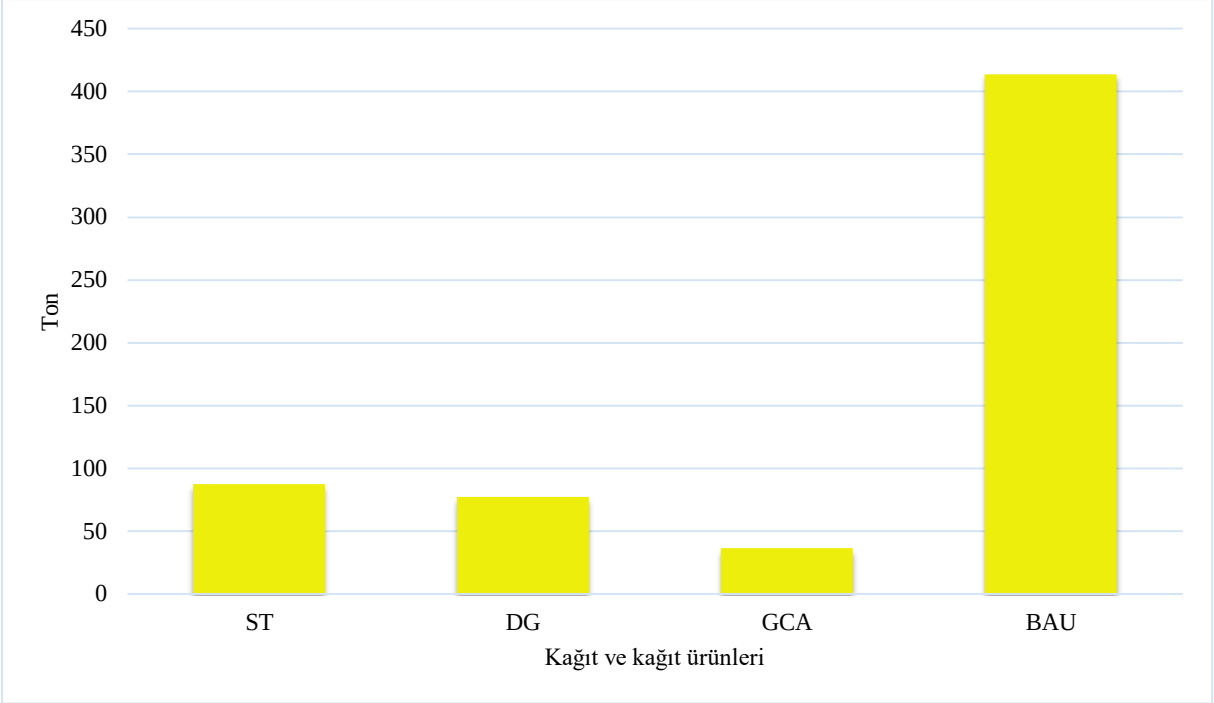
Şekil 4.37 2040 Türkiye Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı



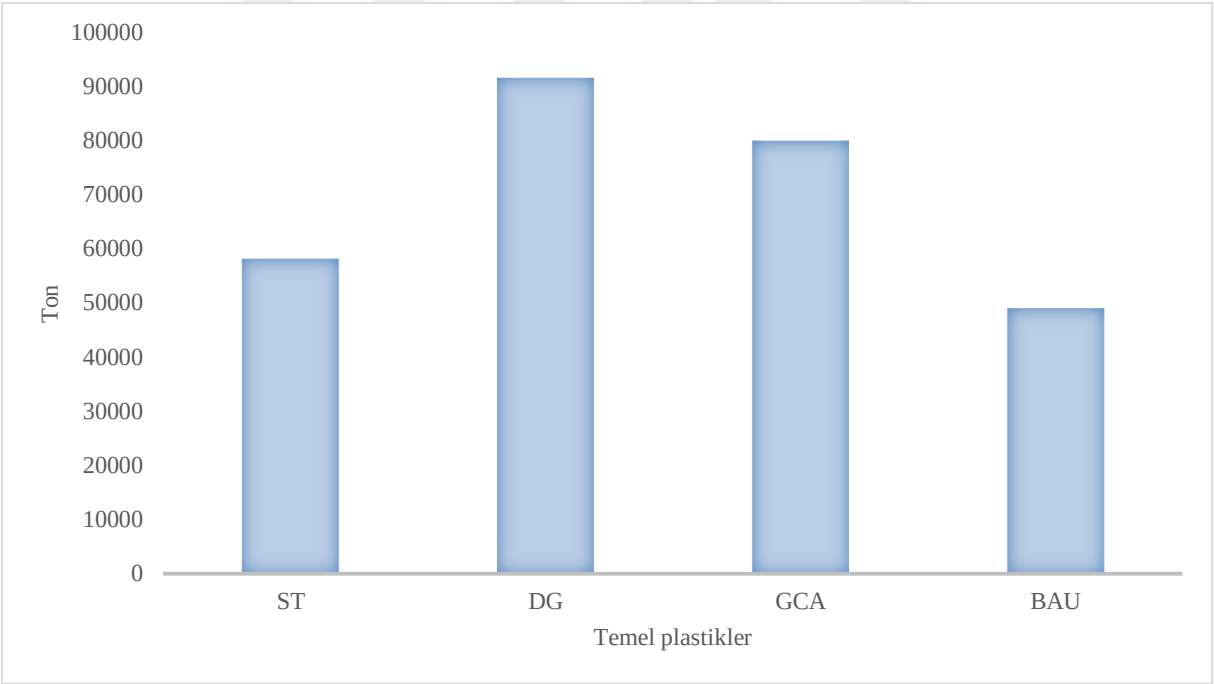
Şekil 4.38 2040 Türkiye Elektrik Üretiminde Metalik Malzeme Kullanımı



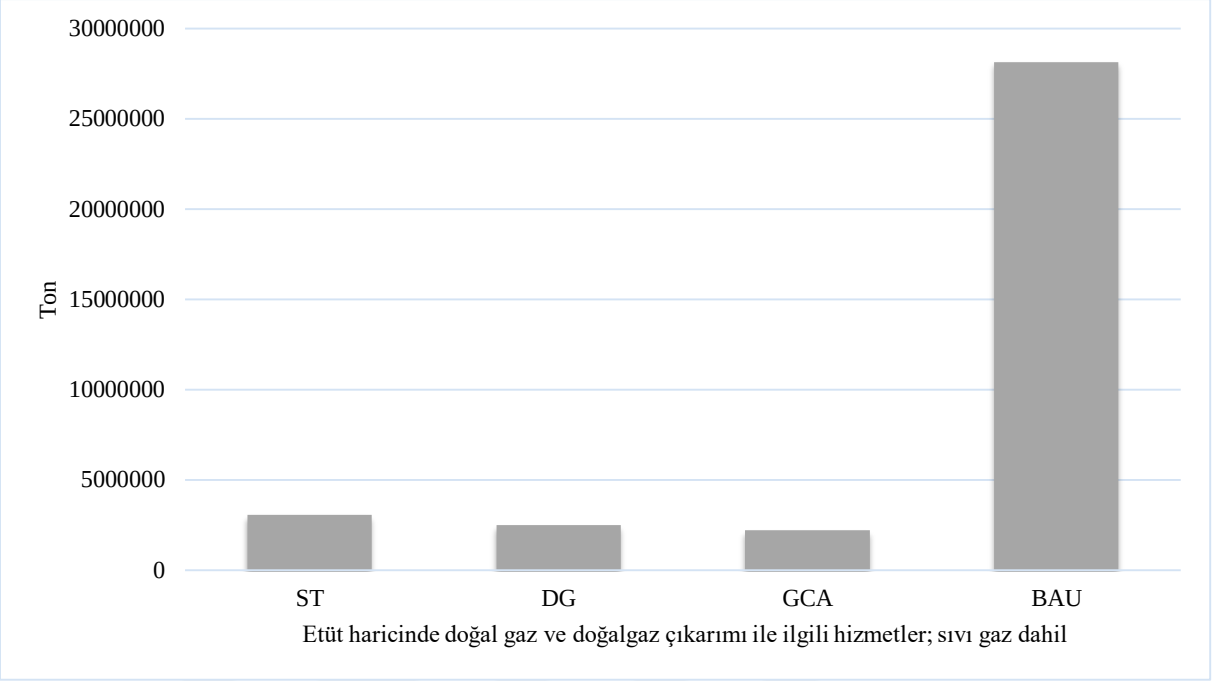
Şekil 4.39 2040 Türkiye Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı



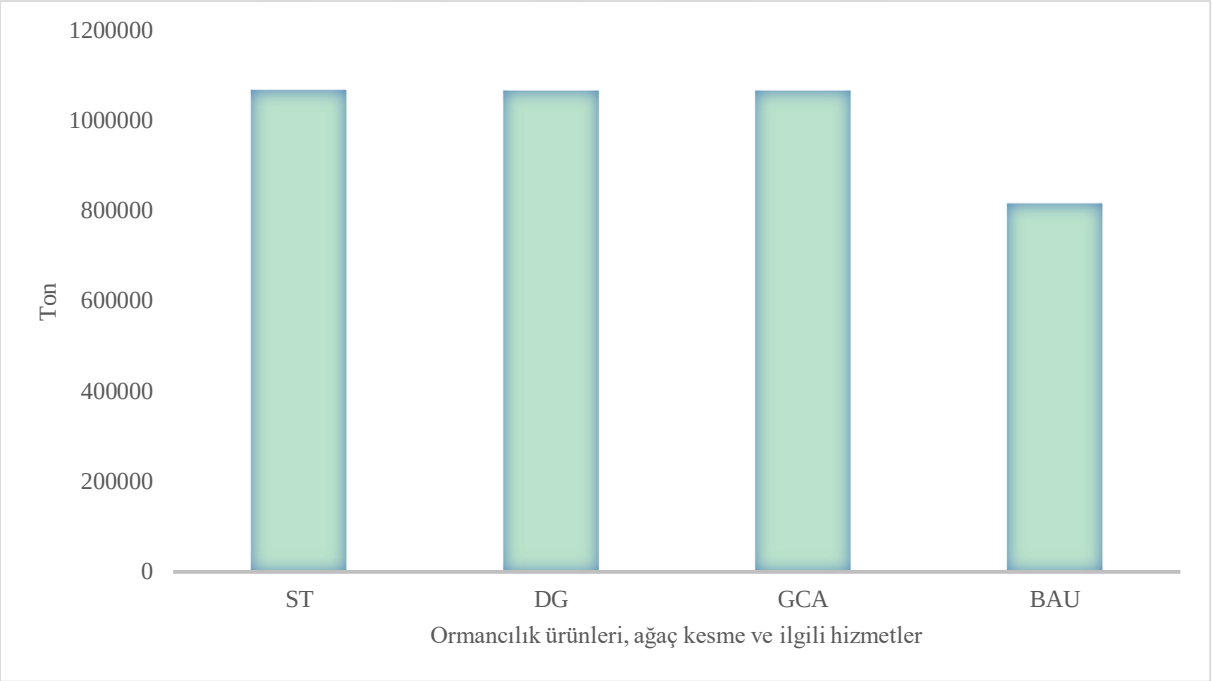
Şekil 4.40 2040 Türkiye Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı



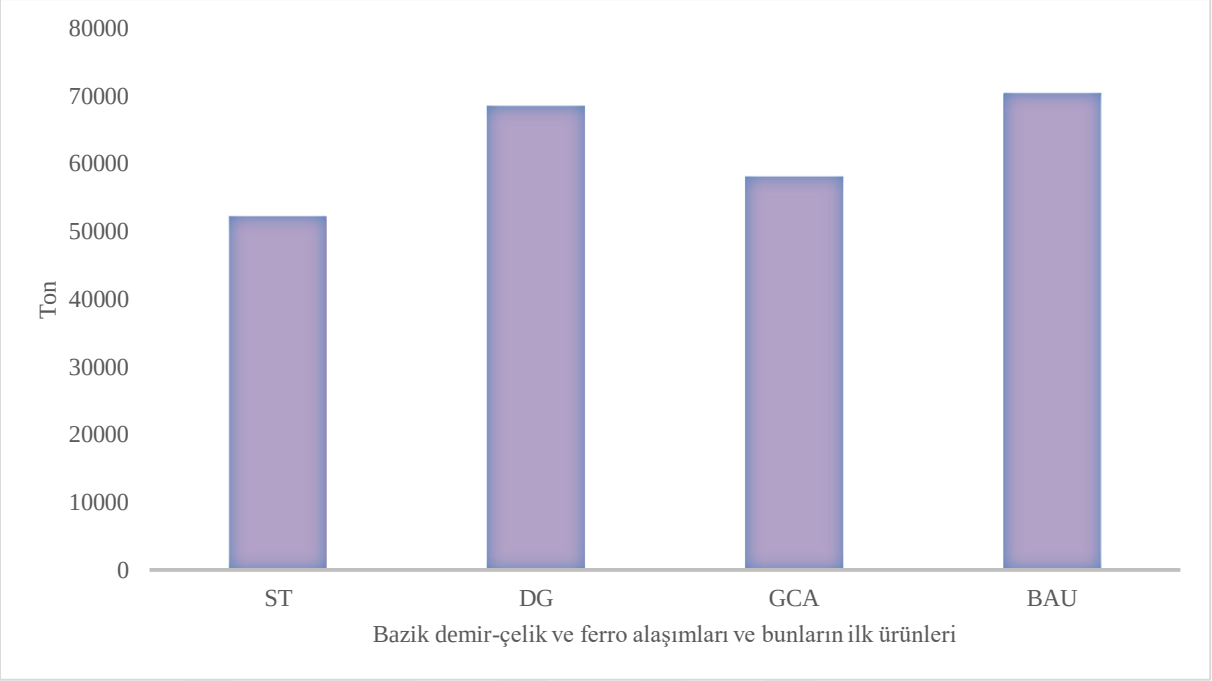
Şekil 4.41 2040 Türkiye Elektrik Üretiminde Plastik Kullanımı



Şekil 4.42 2040 Türkiye Elektrik Üretiminde Sıvı Gaz Kullanımı



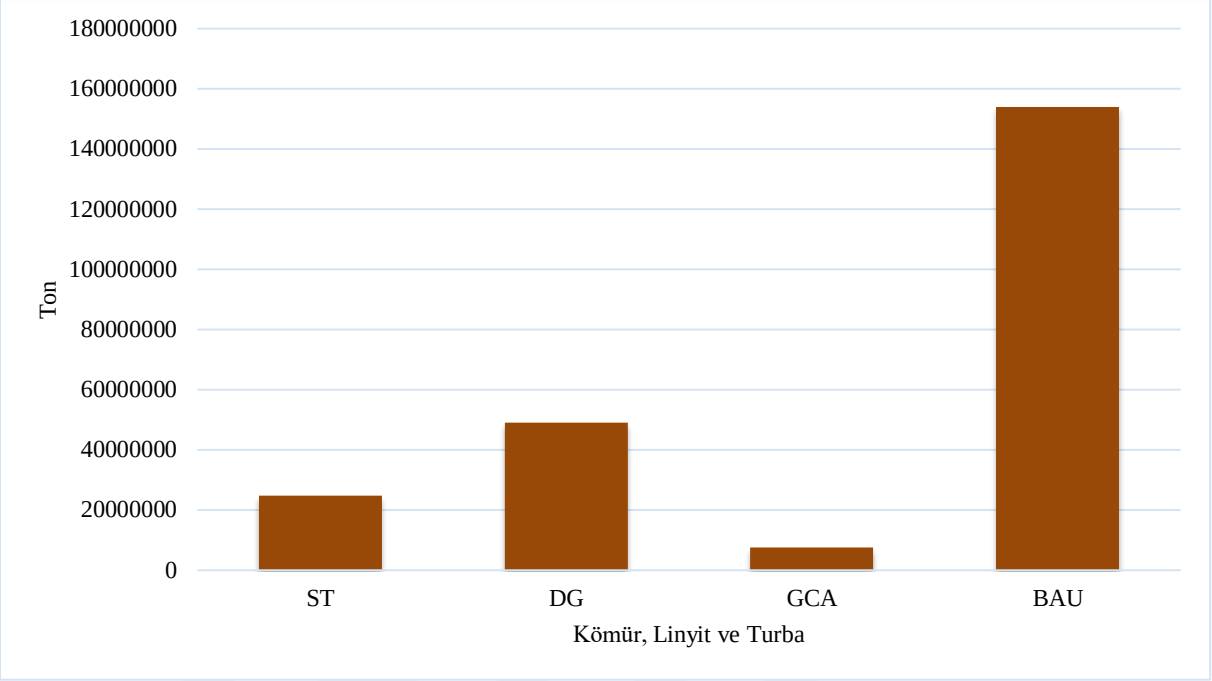
Şekil 4.43 2040 Türkiye Elektrik Üretiminde Ormancılık Ürünleri Kullanımı



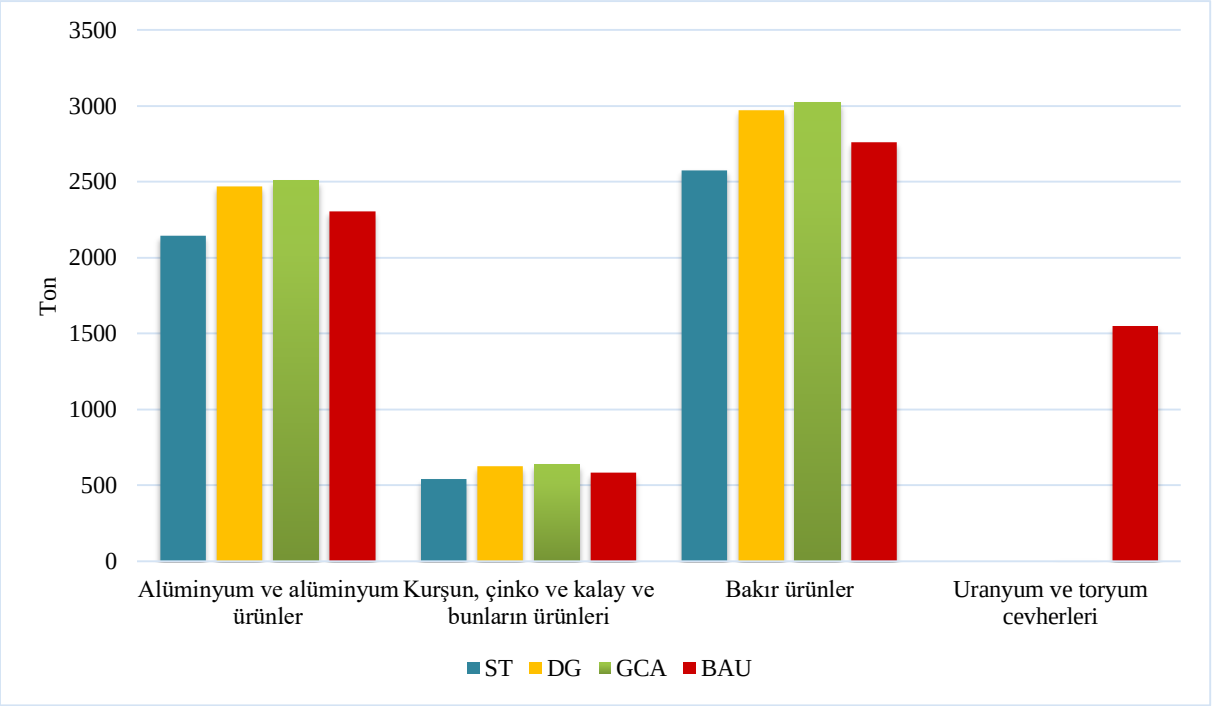
Şekil 4.44 2040 Türkiye Elektrik Üretiminde Demir-Çelik Kullanımı

2040 yılına ait Türkiye elektrik üretimi senaryoları incelendiğinde; BAU senaryosuna göre kömür ve linyit kullanımı 142040315 ton olması beklenirken, GCA senaryosu ile kömür enerjisi ile üretim olmadığından kömür kullanımı beklenmemektedir. 2040 yılı olağan durumda sıvı gaz kullanımının 28160007 tona ulaşması beklenirken, GCA senaryosu ile bu kullanımın 2223082 ton olması beklenmektedir. Metalik malzemeler değerlendirildiğinde; alüminyum, kurşun, çinko, kalay ve bakır ürünlerinin en çok DG ve BAU senaryoları uygulandığında kullanılacakları hesaplanırken; ST senaryosuna göre uranyum ve toryum kullanımının 1191 ton olması beklenmektedir. Metalik olmayan malzemelerden çimento, taş, kum ve kil kullanımının, DG senaryosunda daha yüksek olması beklenirken, senaryosuz olağan durumda rafine petrol ve cam ürünlerinin kullanımının daha yüksek olacağı tespit edilmiştir. Kağıt ve kağıt ürünleri kullanımında GCA senaryosunun, demir-çelik kullanımında ise ST senaryosunun daha avantajlı olduğu görülmektedir.

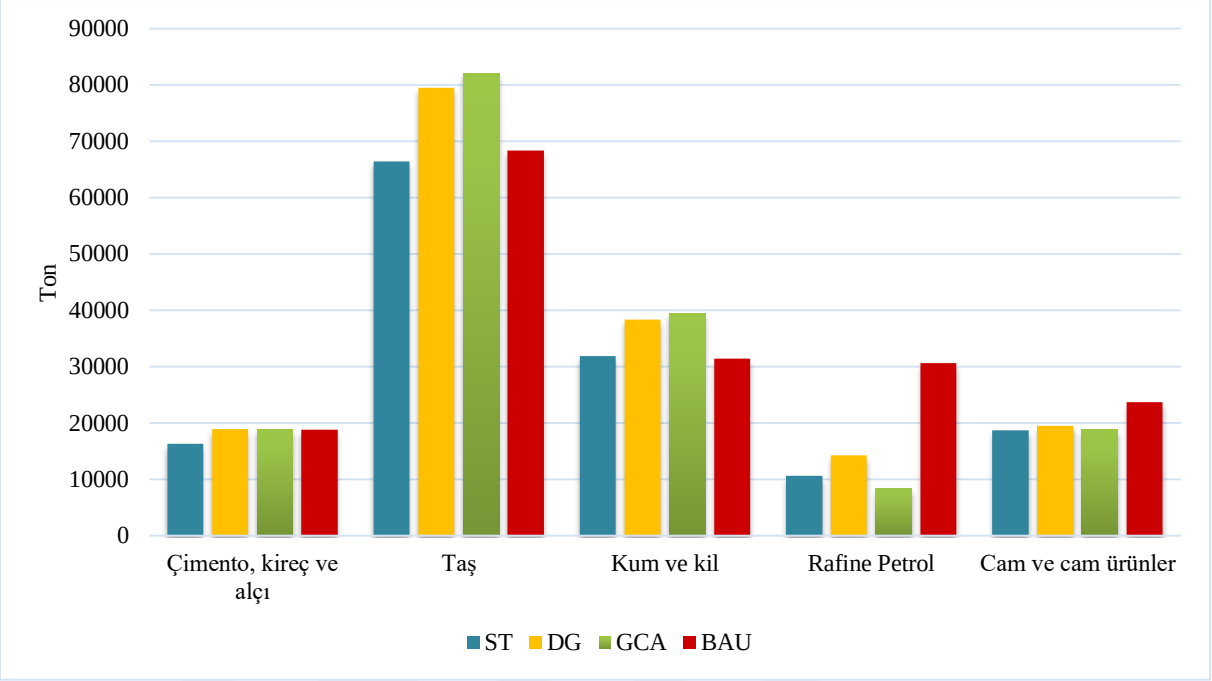
BAU, ST, DG ve EU senaryolarına göre, 2040 yılında Almanya'nın farklı enerji kaynaklarına göre elektrik üretimi sonucunda ortaya çıkacak malzemelerin ayak izleri Şekil 4.45-4.52'deki gibidir.



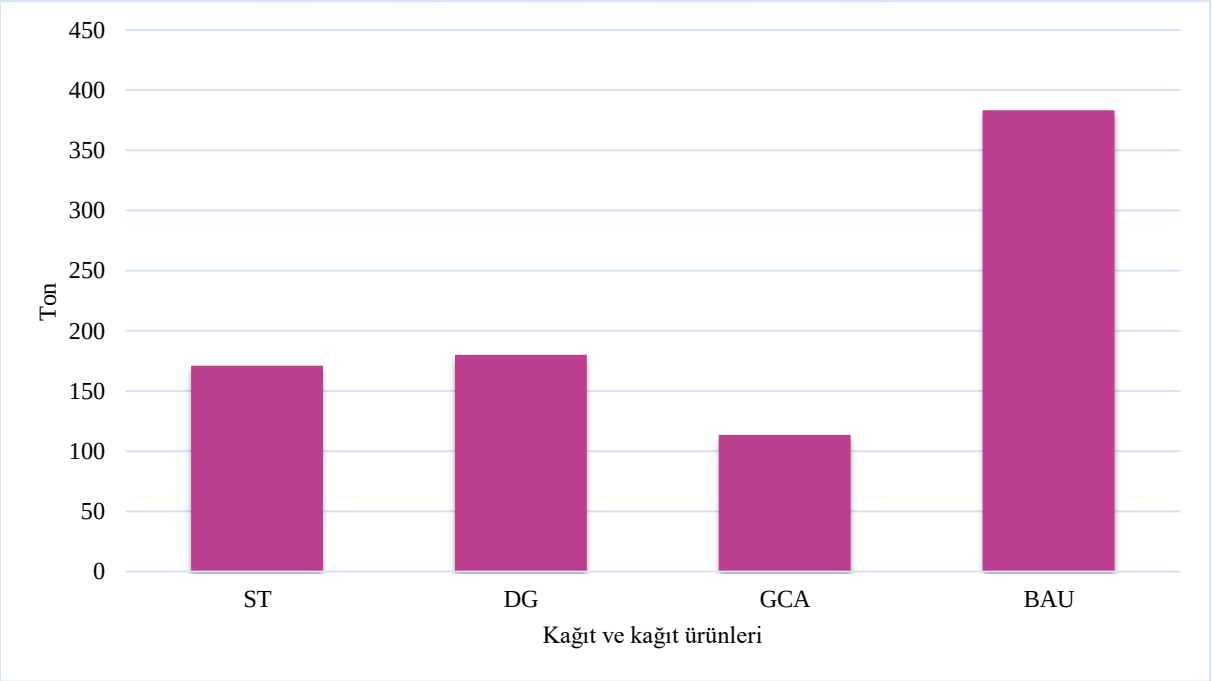
Şekil 4.45 2040 Almanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı



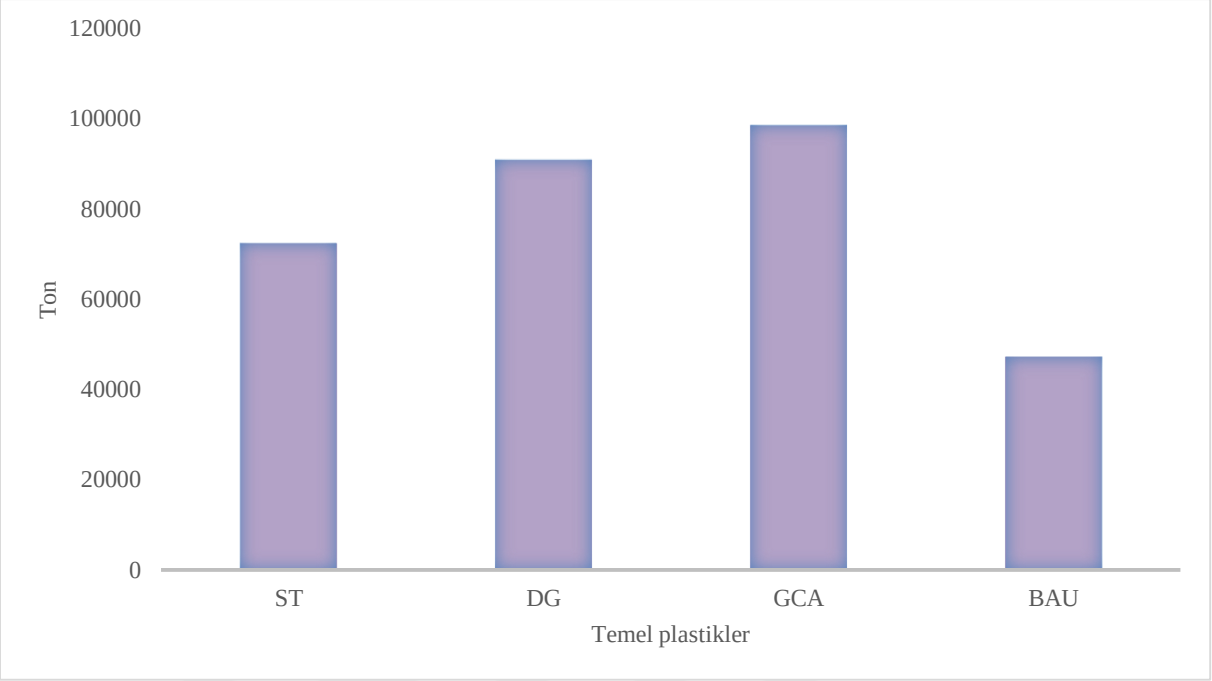
Şekil 4.46 2040 Almanya Elektrik Üretiminde Metalik Malzeme Kullanımı



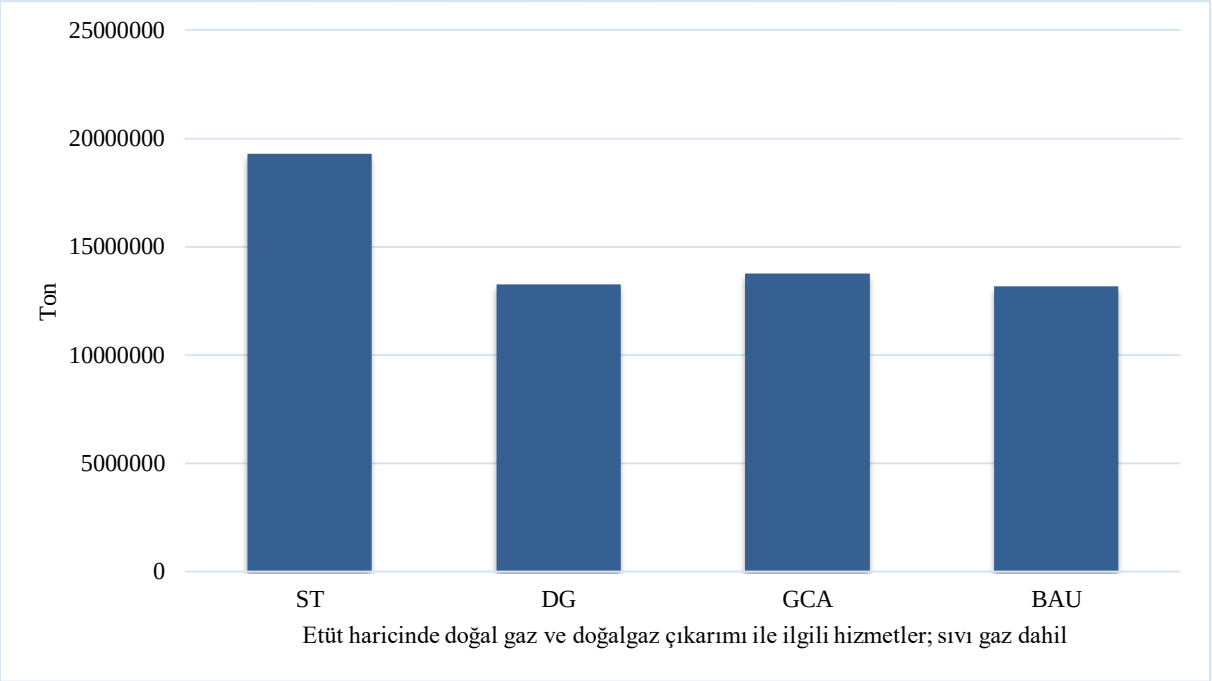
Şekil 4.47 2040 Almanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı



Şekil 4.48 2040 Almanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı



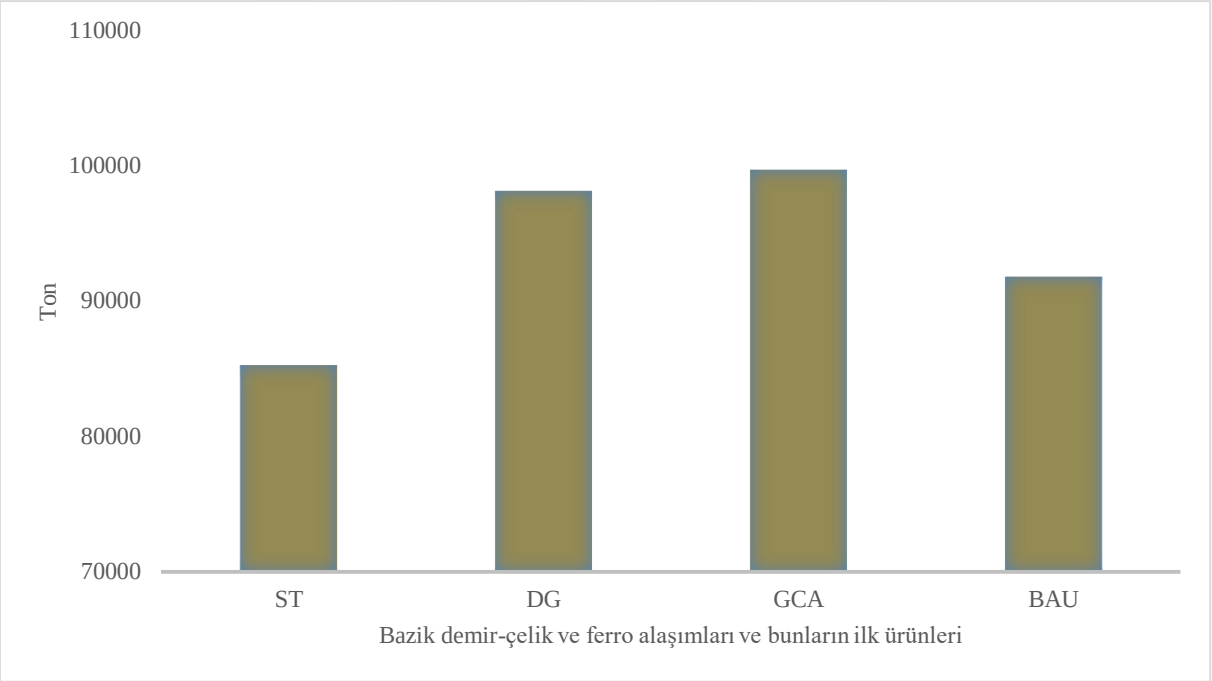
Şekil 4.49 2040 Almanya Elektrik Üretiminde Plastik Kullanımı



Şekil 4.50 2040 Almanya Elektrik Üretiminde Sıvı Gaz Kullanımı



Şekil 4.51 2040 Almanya Elektrik Üretiminde Ormancılık Ürünleri Kullanımı

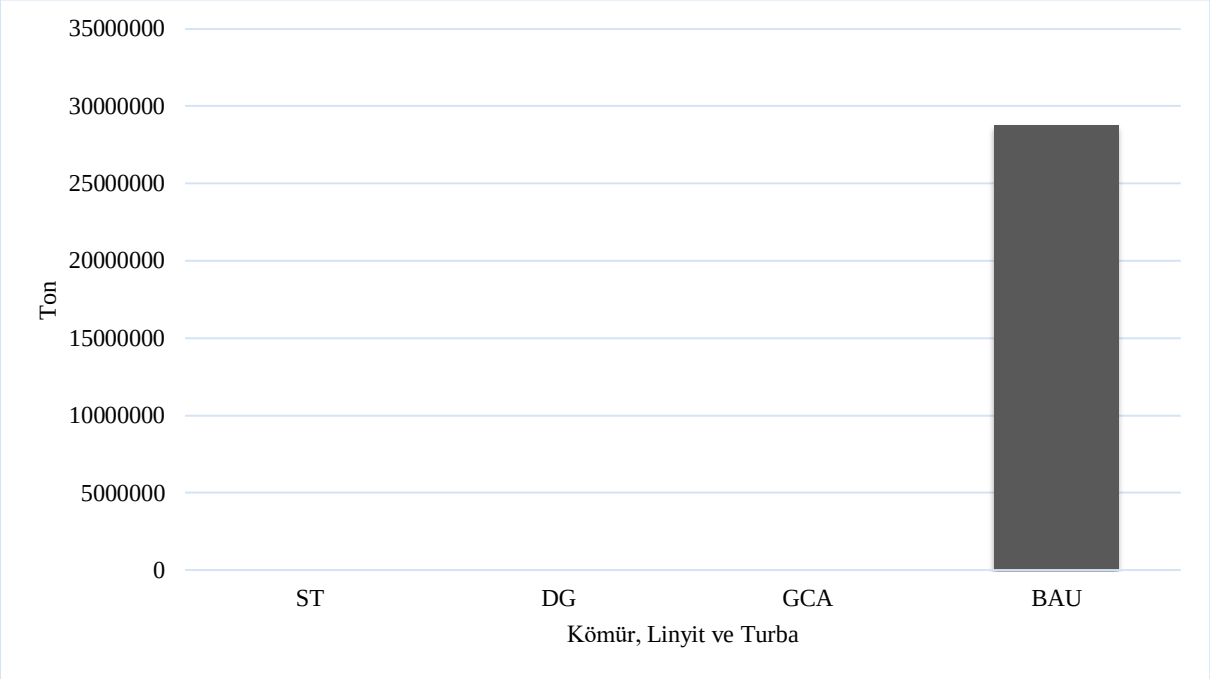


Şekil 4.52 2040 Almanya Elektrik Üretiminde Demir-Çelik Kullanımı

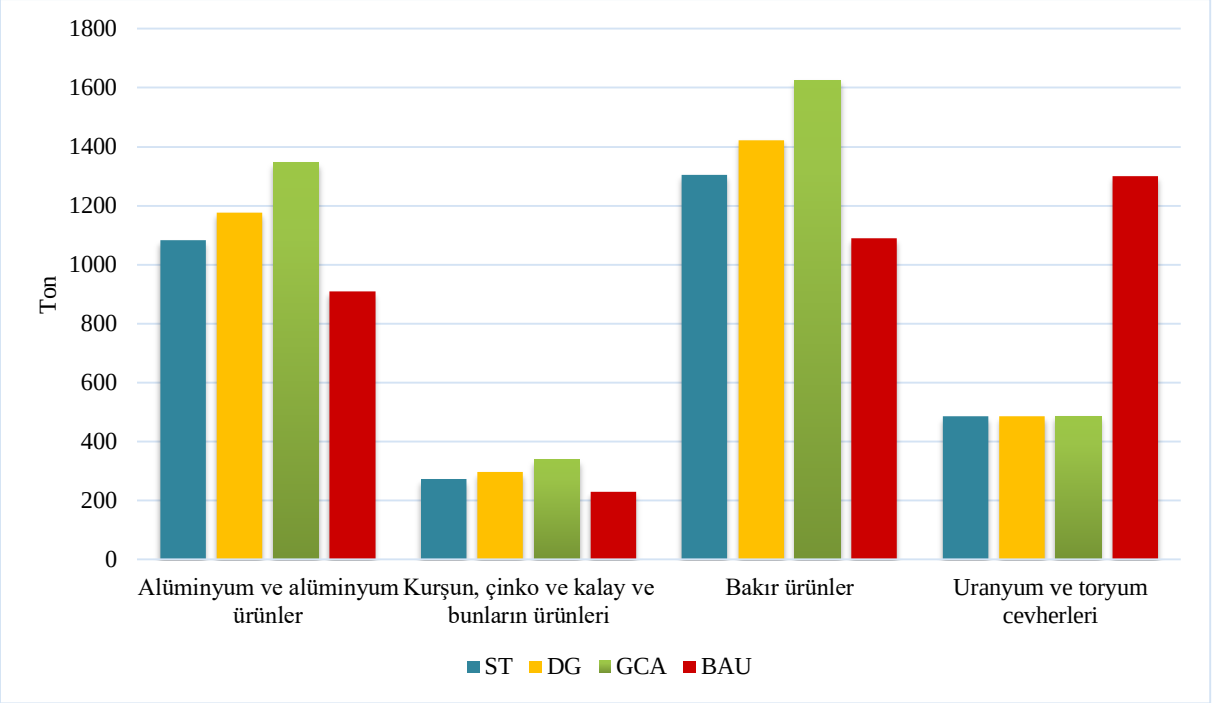
2040 yılına ait Almanya elektrik üretimi senaryoları incelendiğinde; BAU senaryosuna göre kömür ve linyit kullanımı 153944265 ton olması beklenirken, GCA senaryosu bu tüketimin

7578661 ton olması beklenmektedir. 2040 yılı ST senaryosuna göre sıvı gaz kullanımının 19292345 tona ulaşması beklenmektedir. Bu sıvı gaz kullanımı diğer senaryolara göre daha yüksek olduğu hesaplanmıştır. Metalik malzemeler değerlendirildiğinde; alüminyum, kurşun, çinko, kalay ve bakır ürünlerinin malzeme ayak izleri en çok GCA senaryosu uygulandığında ortaya çıkacakken; BAU senaryosuna göre uranyum ve toryum kullanımının 1550 ton olması beklenmektedir. Diğer senaryolarda nükleer enerji ile elektrik üretimi olmadığından, uranyum ve toryum kullanımı olmayacaktır. Metalik olmayan malzemelerden çimento, taş, kum ve kil malzeme ayak izlerinin, GCA senaryosunda daha yüksek olması beklenirken, senaryosuz olağan durumda rafine petrol ve cam ürünlerinin kullanımının daha yüksek olacağı tespit edilmiştir. Kağıt ve kağıt ürünleri kullanımında GCA senaryosunun, demir-çelik kullanımında ise ST senaryosunun daha avantajlı olduğu görülmektedir.

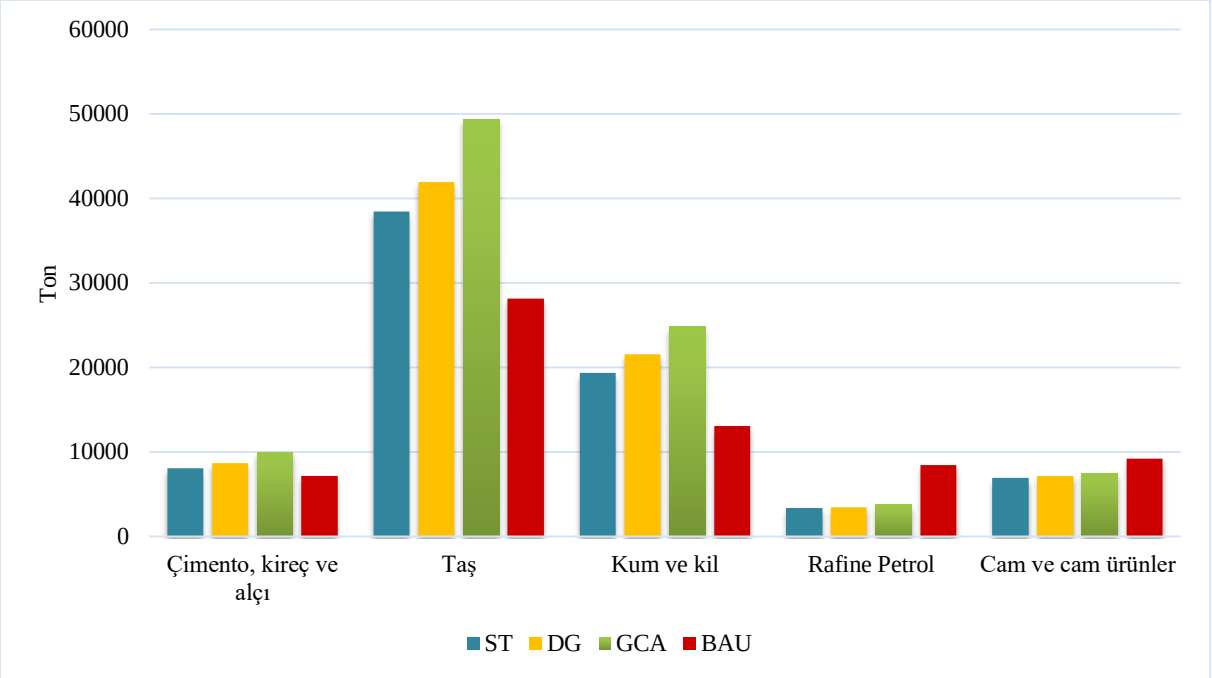
BAU, ST, DG ve EU senaryolarına göre, 2040 yılında İspanya'nın farklı enerji kaynaklarına göre elektrik üretimi sonucunda ortaya çıkacak malzemelerin ayak izleri Şekil 4.53-4.60'daki gibidir.



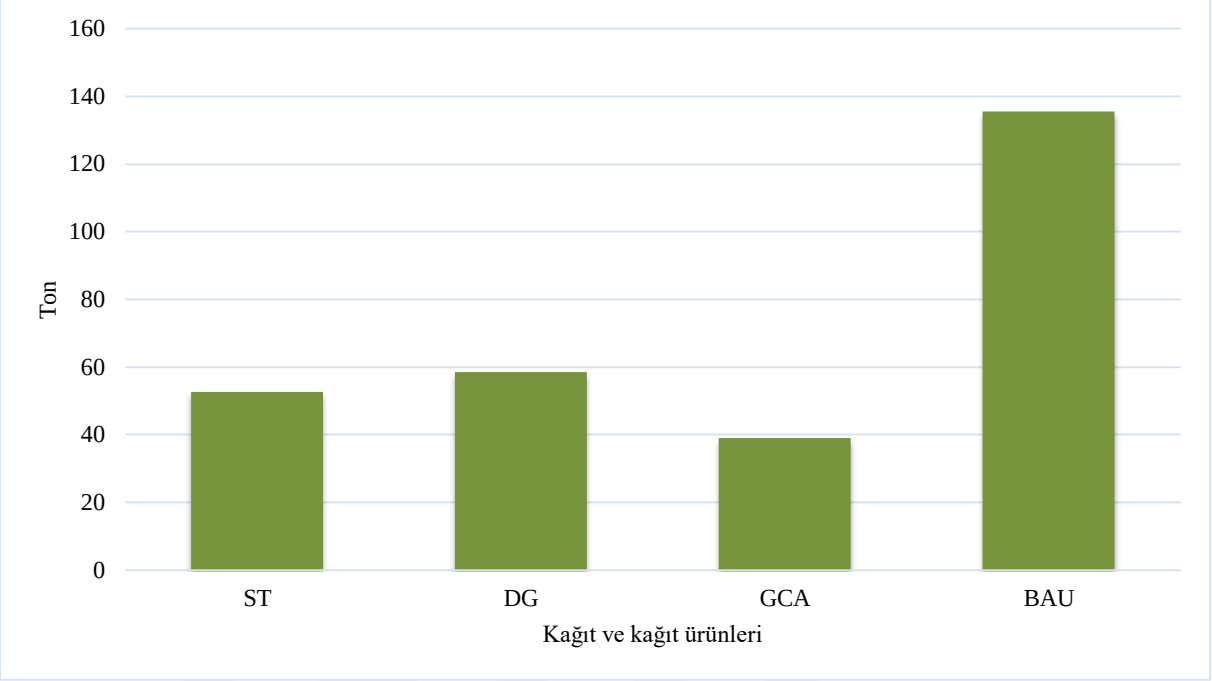
Şekil 4.53 2040 İspanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı



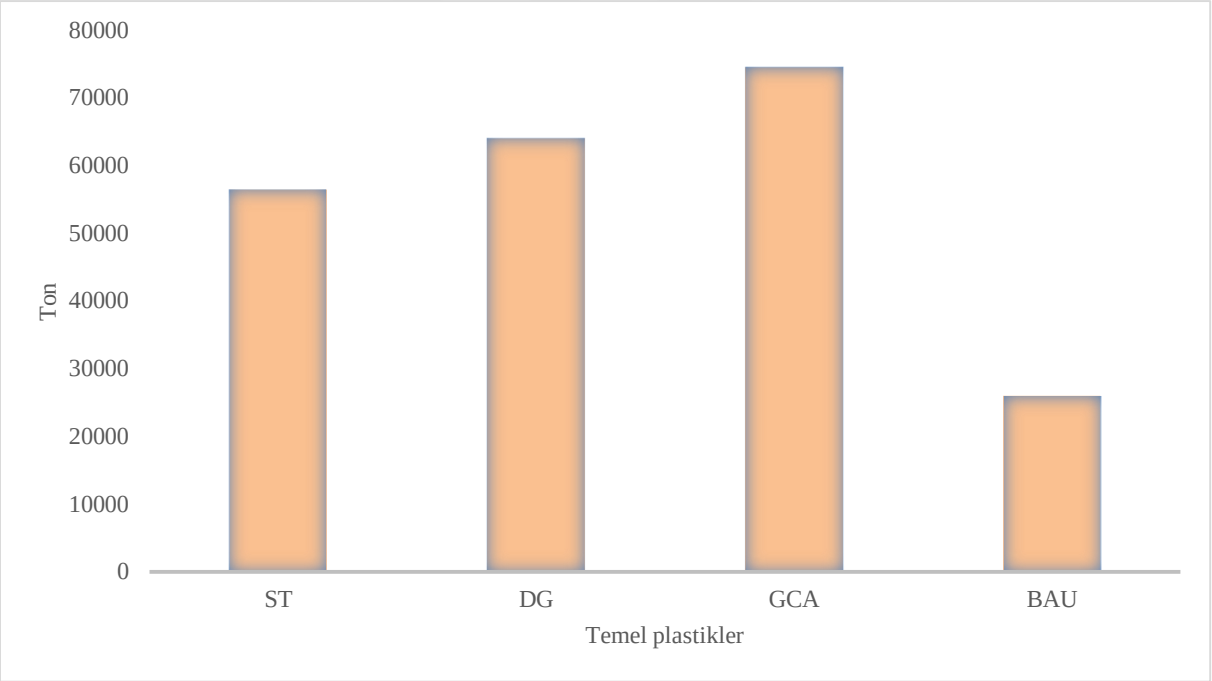
Şekil 4.54 2040 İspanya Elektrik Üretiminde Metalik Malzeme Kullanımı



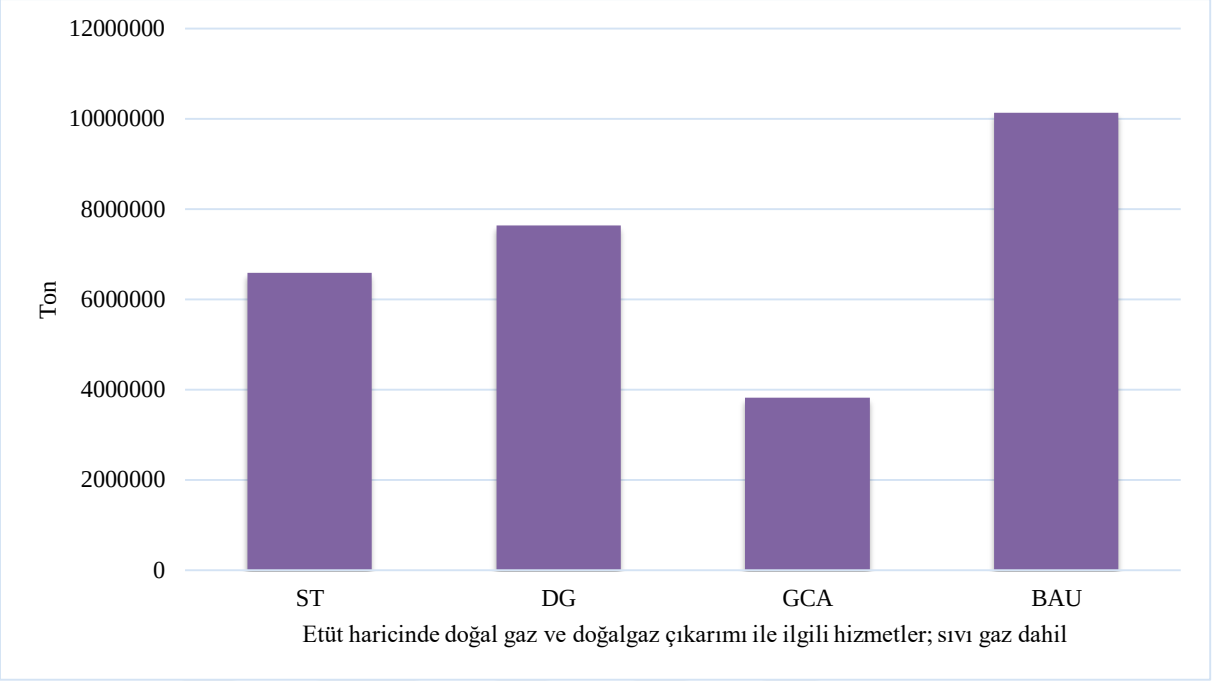
Şekil 4.55 2040 İspanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı



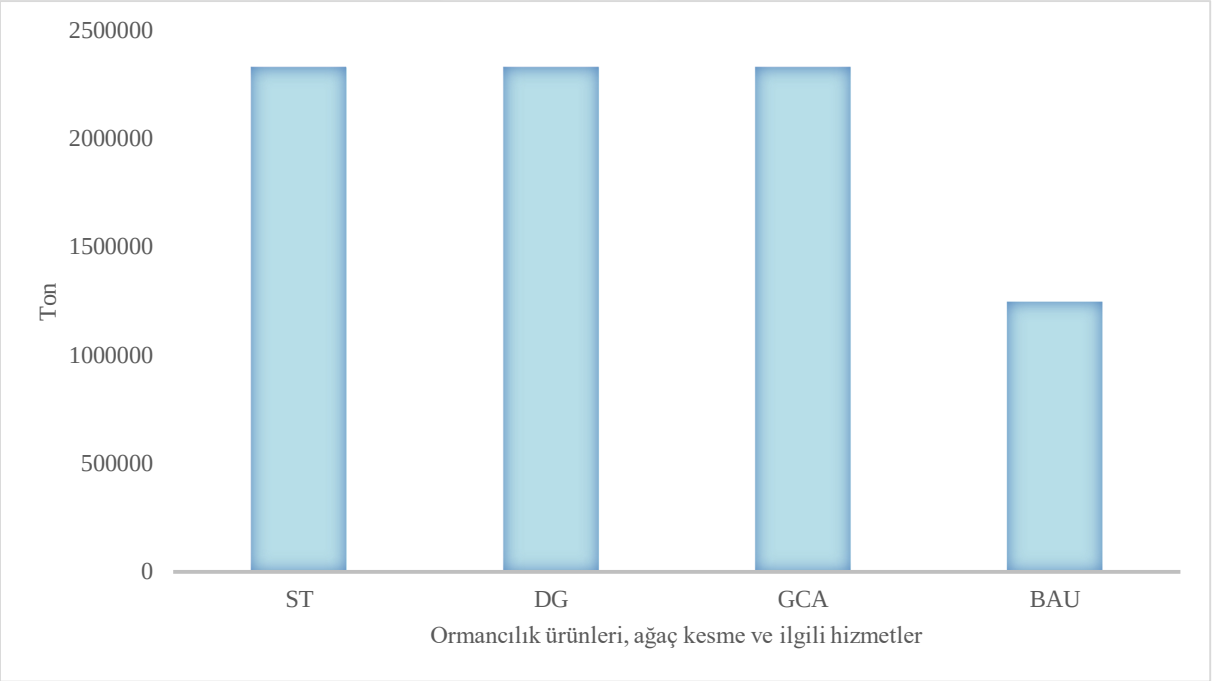
Şekil 4.56 2040 İspanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı



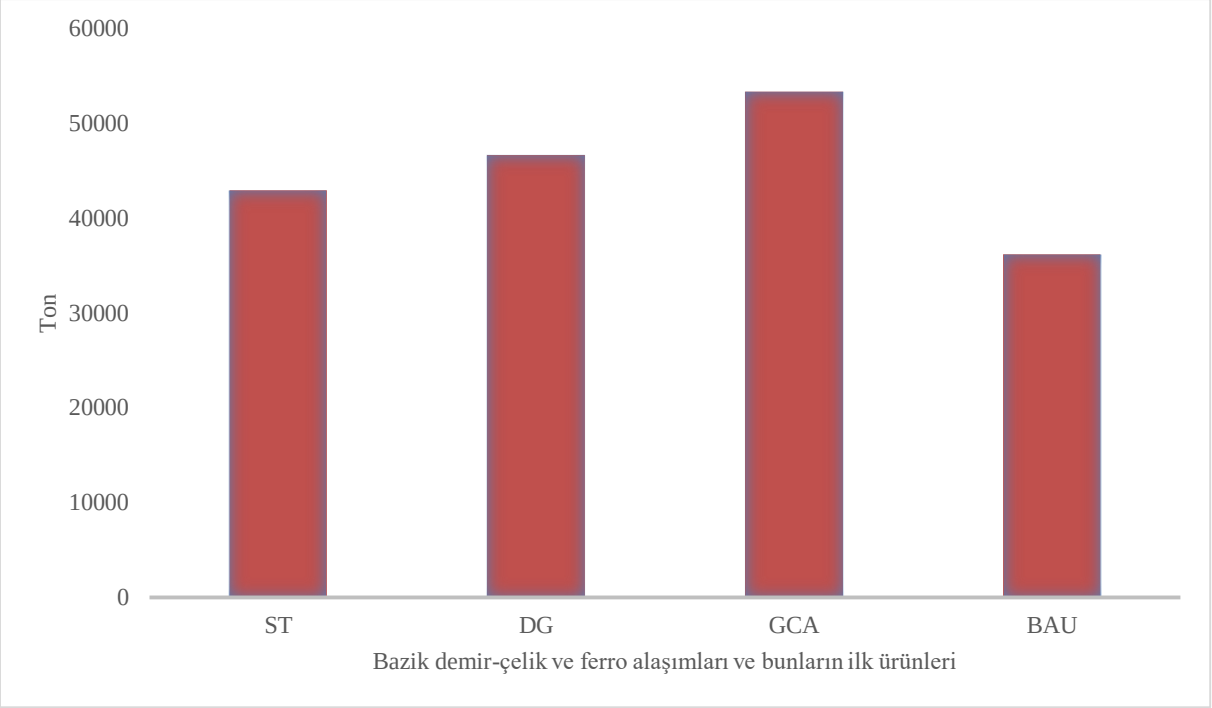
Şekil 4.57 2040 İspanya Elektrik Üretiminde Plastik Kullanımı



Şekil 4.58 2040 İspanya Elektrik Üretiminde Sıvı Gaz Kullanımı



Şekil 4.59 2040 İspanya Elektrik Üretiminde Ormancılık Ürünleri Kullanımı



Şekil 4.60 2040 İspanya Elektrik Üretiminde Demir-Çelik Kullanımı

2040 yılına ait İspanya elektrik üretimi senaryoları incelendiğinde; BAU senaryosuna göre kömür ve linyit kullanımı 28745306 ton olması beklenirken, ST, DG ve GCA senaryoları ile kömür enerjisi ile üretim olmadığından kömür kullanımı beklenmemektedir. 2040 yılı olağan durumda sıvı gaz kullanımının 10139711 tona ulaşması beklenirken, GCA senaryosu ile bu kullanımın 3828449 ton olması beklenmektedir. Metalik malzemeler değerlendirildiğinde; alüminyum, kurşun, çinko, kalay ve bakır ürünlerinin malzeme ayak izleri en çok GCA senaryosu uygulandığında ortaya çıkacakken, BAU senaryosuna göre uranyum ve toryum kullanımının 1300 ton olması beklenmektedir. Metalik olmayan malzemelerden çimento, taş, kum ve kil kullanımının GCA senaryosu ile daha yüksek olması beklenirken, senaryosuz olağan durumda rafine petrol ve cam ürünlerinin kullanımının daha yüksek olacağı tespit edilmiştir. Kağıt ve kağıt ürünleri kullanımında GCA senaryosunun, demir-çelik ve plastik ürünleri kullanımında ise BAU senaryosunun daha avantajlı olduğu görülmektedir.

5. TARTIŞMA VE SONUÇ

Bu çalışmada, Türkiye, Almanya ve İspanya'nın elektrik üretimlerini tahmini için LSTM ve ARIMA yöntemleri kullanılmıştır. Performans ölçütlerine göre bu iki yöntem karşılaştırılmıştır. Bulunan en iyi yöntem ile ileriye dönük elektrik üretim tahminleri yapılmıştır. Avrupa Elektrik İletim Sistemi İşleticileri Birliği (entso-e)'den 2030 ve 2040 yıllarına ait bazı elektrik üretim senaryoları alınmıştır. Bu senaryolar ile tahmin yöntemiyle elde edilen farklı enerji kaynaklarına göre elektrik üretim değerleri için malzeme ayak izleri hesaplanmıştır. Hesaplanan malzeme ayak izleri metalik ve metalik olmayan malzemeler olarak ayrılmıştır.

Türkiye, Almanya ve İspanya'nın elektrik üretim test değerleri tahmini sonucunda; RAE, RRSE, MAPE ve RMSE performans ölçütlerine göre LSTM yöntemi ARIMA yöntemine göre daha üstün bulunmuştur. LSTM yöntemi ile her üç ülkenin elektrik üretim test değerlerini tahmini sonucunda MAPE değeri %5'in altında bulunmuştur. Bu nedenle ileriye dönük elektrik üretim tahminlerinde derin öğrenme yöntemlerinden LSTM'in kullanılması önemlidir.

Olağan durum ve senaryolar malzeme ayak izi değerlerine göre değerlendirildiğinde; 2030 yılı Türkiye, ve Almanya elektrik üretim stratejileri açısından ST senaryosu, İspanya için ise EU senaryosu diğerlerine göre daha avantajlıdır. Bu senaryolar ile metalik ve metalik olmayan malzemelerde ciddi tasarruflar sağlanacaktır. 2040 yılı için bu durum değerlendirildiğinde; Türkiye, Almanya ve İspanya için Sürdürülebilir Geçiş stratejisi daha önemlidir. 2040 İspanyada toplam elektrik üretim değeri LSTM sonucuna yakın çıkması durumunda ise BAU senaryosu daha avantajlı olduğu bulunmuştur. Bu senaryolar uygulandığında; Türkiye'nin 2040 yılı elektrik üretiminde metalik ve metalik olmayan malzeme ayak izi açısından sırasıyla, ortalama %24 ve %30 malzeme tasarrufu sağlanacağı tespit edilmiştir. Almanya için ise bu tasarrufun %10 ve %14 olacağı tespit edilmiştir. Her iki ülke için de ST senaryosu ile kömür kullanımının %84 azalacağı hesaplanmıştır.

Literatürde, malzeme ayak izi kavramının oldukça kısıtlı geçmesinden dolayı bu çalışma önemlidir. Gelecekte elektrik üretimi sonucunda ortaya çıkacak malzeme ihtiyacının belirlenmesi, tedarikçilerin planlanması ve yatırımların yapılması açısından da önemlidir.

Bunun yanı sıra elektrik üretimi sadece malzeme ayak izi açısından değil, su ayak izi, karbon ayak izi vb. çevresel etkiler dikkate alınarak incelenmeli ve planlamalar yapılmalıdır.

Ülkemizdeki elektrik üretiminin çeşitli faaliyetler ile ilişkilerini inceleyebilmek için buna yönelik veri tabanlarının oluşturulması önerilmektedir.

KAYNAKLAR

[1] I. Topcu, F. Ülengin, Ö. Kabak, M. Isik, B. Unver, and S. O. Ekici, "The evaluation of electricity generation resources: The case of Turkey," *Energy*, vol. 167, pp. 417–427, 2019.

[2] H. Gurgul and Ł. Lach, "The electricity consumption versus economic growth of the Polish economy," *Energy Econ.*, vol. 34, no. 2, pp. 500–510, 2012.

[3] G. Altinay and E. Karagol, "Electricity consumption and economic growth: evidence from Turkey," *Energy Econ.*, vol. 27, no. 6, pp. 849–856, 2005.

[4] "https://www.teias.gov.tr/."

[5] Z. Mohamed and P. Bodger, "Forecasting electricity consumption in New Zealand using economic and demographic variables," *Energy*, vol. 30, no. 10, pp. 1833–1843, 2005.

[6] C. Hamzaçebi, "Forecasting of Turkey's net electricity energy consumption on sectoral bases," *Energy Policy*, vol. 35, no. 3, pp. 2009–2016, 2007.

[7] K. Kavaklioglu, "Modeling and prediction of Turkey's electricity consumption using Support Vector Regression," *Appl. Energy*, vol. 88, no. 1, pp. 368–375, 2011.

[8] A. Ünler, "Improvement of energy demand forecasts using swarm intelligence: The case of Turkey with projections to 2025," *Energy Policy*, vol. 36, no. 6, pp. 1937–1944, 2008.

[9] M. D. Toksarı, "Estimating the net electricity energy generation and demand using the ant colony optimization approach: case of Turkey," *Energy Policy*, vol. 37, no. 3, pp. 1181–1187, 2009.

[10] C. Hamzacebi and H. A. Es, "Forecasting the annual electricity consumption of Turkey using an optimized grey model," *Energy*, vol. 70, pp. 165–171, 2014.

[11] D. Akay and M. Atak, "Grey prediction with rolling mechanism for electricity demand forecasting of Turkey," *Energy*, vol. 32, no. 9, pp. 1670–1675, 2007.

[12] V. Ş. Ediger and S. Akar, "ARIMA forecasting of primary energy demand by fuel in Turkey," *Energy Policy*, vol. 35, no. 3, pp. 1701–1708, 2007.

[13] A. S. Albayrak, "ARIMA forecasting of primary energy production and consumption in Turkey: 1923-2006," *Enerj. Piyas. ve düzenleme*, vol. 1, no. 1, pp. 24–50, 2010.

[14] A. Sozen, E. Arcaklioglu, and M. Ozkaymak, "Modelling of Turkey's net energy consumption using artificial neural network," *Int. J. Comput. Appl. Technol.*, vol. 22, no. 2–3, pp. 130–136, 2005.

[15] S. Kucukali and K. Baris, "Turkey's short-term gross annual electricity demand forecast by fuzzy logic approach," *Energy Policy*, vol. 38, no. 5, pp. 2438–2445, 2010.

[16] S. Giljum, M. Bruckner, and A. Martinez, “Material footprint assessment in a global input-output framework,” *J. Ind. Ecol.*, vol. 19, no. 5, pp. 792–804, 2015.

[17] C. Hamzaçebi and F. Kutay, “Yapay sinir ağlari ile Türkiye elektrik enerjisi tüketiminin 2010 yilina kadar tahmini,” *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Derg.*, vol. 19, no. 3, 2004.

[18] “https://www.iea.org/statistics/electricity/.”

[19] L. Aydın, “Effects of increasing indigenous coal share in Turkey’s electricity generation mix on key economic and environmental indicators: An extended input–output analysis,” *Energy Explor. Exploit.*, vol. 36, no. 2, pp. 230–245, 2018.

[20] “European energy market reform Country profile: Germany - Deloitte.”

[21] “https://www.energy-charts.de/energy.htm?source=all-sources&period=annual&year=2018.”

[22] R. E. de España, “The Spanish electricity system preliminary report,” *Red Eléctrica España Madrid, Spain*, 2014.

[23] J. Lago, F. De Ridder, and B. De Schutter, “Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms,” *Appl. Energy*, vol. 221, pp. 386–405, 2018.

[24] Y. Guo, Y. Liu, A. Oerlemans, S. Lao, S. Wu, and M. S. Lew, “Deep learning for visual understanding: A review,” *Neurocomputing*, vol. 187, pp. 27–48, 2016.

[25] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio, *Deep learning*, vol. 1. MIT press Cambridge, 2016.

[26] Y. Zhang, Y. Sun, P. Phillips, G. Liu, X. Zhou, and S. Wang, “A multilayer perceptron based smart pathological brain detection system by fractional Fourier entropy,” *J. Med. Syst.*, vol. 40, no. 7, p. 173, 2016.

[27] G. Hinton *et al.*, “Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups,” *IEEE Signal Process. Mag.*, vol. 29, no. 6, pp. 82–97, 2012.

[28] P. Shinde, S. Yadav, S. Rudrake, and P. Kumbhar, “Smart Traffic Control System using YOLO,” 2019.

[29] V. Sze, Y.-H. Chen, T.-J. Yang, and J. S. Emer, “Efficient processing of deep neural networks: A tutorial and survey,” *Proc. IEEE*, vol. 105, no. 12, pp. 2295–2329, 2017.

[30] Y. LeCun *et al.*, “Backpropagation applied to handwritten zip code recognition,” *Neural Comput.*, vol. 1, no. 4, pp. 541–551, 1989.

[31] J. D. Kelleher, *Deep Learning*. MIT Press, 2019.

[32] M. TÜRKOĞLU, K. HANBAY, I. S. SİVRİKAYA, and D. HANBAY, “Derin

Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması," *Bitlis Eren Üniversitesi Fen Bilim. Derg.*, vol. 9, no. 1, pp. 334–345.

[33] K. O'Shea and R. Nash, "An introduction to convolutional neural networks," *arXiv Prepr. arXiv1511.08458*, 2015.

[34] A. F. Yaseen and L. J. Saud, "A Survey on the Layers of Convolutional Neural Networks," 2018.

[35] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network," in *2017 International Conference on Engineering and Technology (ICET)*, 2017, pp. 1–6.

[36] G. Wei, G. Li, J. Zhao, and A. He, "Development of a LeNet-5 Gas Identification CNN Structure for Electronic Noses," *Sensors*, vol. 19, no. 1, p. 217, 2019.

[37] M. Z. Alom *et al.*, "The history began from alexnet: A comprehensive survey on deep learning approaches," *arXiv Prepr. arXiv1803.01164*, 2018.

[38] M. A. KIZRAK and B. BOLAT, "Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma," *Bilişim Teknol. Derg.*, vol. 11, no. 3, pp. 263–286, 2018.

[39] W. Yu, K. Yang, Y. Bai, T. Xiao, H. Yao, and Y. Rui, "Visualizing and comparing AlexNet and VGG using deconvolutional layers," in *Proceedings of the 33 rd International Conference on Machine Learning*, 2016.

[40] F. DOĞAN and İ. TÜRKOĞLU, "Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması," *Sak. Univ. J. Comput. Inf. Sci.*, vol. 1, no. 1, pp. 10–21, 2018.

[41] Y. Tai, J. Yang, and X. Liu, "Image super-resolution via deep recursive residual network," in *Proceedings of the IEEE Conference on Computer vision and Pattern Recognition*, 2017, pp. 3147–3155.

[42] P. Tang, H. Wang, and S. Kwong, "G-MS2F: GoogLeNet based multi-stage feature fusion of deep CNN for scene recognition," *Neurocomputing*, vol. 225, pp. 188–197, 2017.

[43] K. Gulordava, P. Bojanowski, E. Grave, T. Linzen, and M. Baroni, "Colorless green recurrent networks dream hierarchically," *arXiv Prepr. arXiv1803.11138*, 2018.

[44] A. Şeker, B. Diri, and H. H. Balık, "Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme," *Gazi Mühendislik Bilim. Derg.*, vol. 3, no. 3, pp. 47–64.

[45] A. Graves, A. Mohamed, and G. Hinton, "Speech recognition with deep recurrent neural networks," in *Acoustics, speech and signal processing (icassp), 2013 ieee international conference on*, 2013, pp. 6645–6649.

[46] G. Mesnil *et al.*, "Using recurrent neural networks for slot filling in spoken language understanding," *IEEE/ACM Trans. Audio, Speech, Lang. Process.*, vol. 23, no. 3, pp.

530–539, 2015.

[47] D. Zhang, N. Martinez, G. Lindholm, and H. Ratnaweera, “Manage Sewer In-Line Storage Control Using Hydraulic Model and Recurrent Neural Network,” *Water Resour. Manag.*, vol. 32, no. 6, pp. 2079–2098, 2018.

[48] T. Fischer and C. Krauss, “Deep learning with long short-term memory networks for financial market predictions,” *Eur. J. Oper. Res.*, vol. 270, no. 2, pp. 654–669, 2018.

[49] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.

[50] F. A. Gers, J. Schmidhuber, and F. Cummins, “Learning to forget: Continual prediction with LSTM,” 1999.

[51] A. Graves and J. Schmidhuber, “Framewise phoneme classification with bidirectional LSTM and other neural network architectures,” *Neural networks*, vol. 18, no. 5–6, pp. 602–610, 2005.

[52] J. B. Pollack, “Recursive distributed representations,” *Artif. Intell.*, vol. 46, no. 1–2, pp. 77–105, 1990.

[53] L. Bottou, “From machine learning to machine reasoning,” *Mach. Learn.*, vol. 94, no. 2, pp. 133–149, 2014.

[54] S. E. Fahlman, G. E. Hinton, and T. J. Sejnowski, “Massively parallel architectures for Al: NETL, Thistle, and Boltzmann machines,” in *National Conference on Artificial Intelligence, AAAI*, 1983.

[55] M. N. Bojnordi and E. Ipek, “Memristive boltzmann machine: A hardware accelerator for combinatorial optimization and deep learning,” in *2016 IEEE International Symposium on High Performance Computer Architecture (HPCA)*, 2016, pp. 1–13.

[56] P. Xie, Y. Deng, and E. Xing, “Diversifying restricted boltzmann machine for document modeling,” in *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2015, pp. 1315–1324.

[57] N. Zeng, Z. Wang, H. Zhang, W. Liu, and F. E. Alsaadi, “Deep belief networks for quantitative analysis of a gold immunochromatographic strip,” *Cognit. Comput.*, vol. 8, no. 4, pp. 684–692, 2016.

[58] G. E. Hinton and R. R. Salakhutdinov, “Reducing the dimensionality of data with neural networks,” *Science (80-.).*, vol. 313, no. 5786, pp. 504–507, 2006.

[59] O. KAYNAR, Y. GÖRMEZ, and Y. E. IŞIK, “OTO KODLAYICI TABANLI DERİN ÖĞRENME MAKİNALARI İLE SPAM TESPİTİ.”

[60] C. S. N. Pathirage, J. Li, L. Li, H. Hao, W. Liu, and P. Ni, “Structural damage identification based on autoencoder neural networks and deep learning,” *Eng. Struct.*, vol. 172, pp. 13–28, 2018.

[61] W. Liu, Z. Wang, X. Liu, N. Zeng, Y. Liu, and F. E. Alsaadi, "A survey of deep neural network architectures and their applications," *Neurocomputing*, vol. 234, pp. 11–26, 2017.

[62] P. Vincent, "A connection between score matching and denoising autoencoders," *Neural Comput.*, vol. 23, no. 7, pp. 1661–1674, 2011.

[63] E. Othman, Y. Bazi, N. Alajlan, H. Alhichri, and F. Melgani, "Using convolutional features and a sparse autoencoder for land-use scene classification," *Int. J. Remote Sens.*, vol. 37, no. 10, pp. 2149–2167, 2016.

[64] A. Makhzani and B. Frey, "K-sparse autoencoders," *arXiv Prepr. arXiv1312.5663*, 2013.

[65] H. Xu *et al.*, "Unsupervised anomaly detection via variational auto-encoder for seasonal kpis in web applications," in *Proceedings of the 2018 World Wide Web Conference*, 2018, pp. 187–196.

[66] N. Lv, C. Chen, T. Qiu, and A. K. Sangaiah, "Deep learning and superpixel feature extraction based on contractive autoencoder for change detection in SAR images," *IEEE Trans. Ind. informatics*, vol. 14, no. 12, pp. 5530–5538, 2018.

[67] S. Zhang, L. Yao, and X. Xu, "AutoSVD++ An Efficient Hybrid Collaborative Filtering Model via Contractive Auto-encoders," in *Proceedings of the 40th International ACM SIGIR conference on Research and Development in Information Retrieval*, 2017, pp. 957–960.

[68] G. E. P. Box and G. M. Jenkins, "Time Series Analysis Forecasting and Control/'Holden Day, San Francisco, California." 1970.

[69] E. Cadenas, W. Rivera, R. Campos-Amezcua, and C. Heard, "Wind speed prediction using a univariate ARIMA model and a multivariate NARX model," *Energies*, vol. 9, no. 2, p. 109, 2016.

[70] A. T. A. Y. BAYRAMOĞLU and Z. ÖZTÜRK, "ARIMA ve Gri Sistem Modelleri ile Enflasyon Tahmini," *İnsan ve Toplum Bilim. Araştırmaları Derg.*, vol. 6, no. 2, pp. 760–776, 2017.

[71] M. Sevüktekin and M. Çınar, "Ekonometrik Zaman Serileri Analizi, Dora Yayıncılık, 4," *Baskı, Bursa*, 2014.

[72] U. Kumar and V. K. Jain, "ARIMA forecasting of ambient air pollutants (O 3, NO, NO 2 and CO)," *Stoch. Environ. Res. Risk Assess.*, vol. 24, no. 5, pp. 751–760, 2010.

[73] E. P. Clement, "Using normalized bayesian information criterion (BIC) to improve box-jenkins model building," *Am. J. Math. Stat.*, vol. 4, no. 5, pp. 214–221, 2014.

[74] J. P. da S. Catalão, S. J. P. S. Mariano, V. M. F. Mendes, and L. Ferreira, "Short-term electricity prices forecasting in a competitive market: A neural network approach," *Electr. power Syst. Res.*, vol. 77, no. 10, pp. 1297–1304, 2007.

[75] A. T. Lora, J. M. R. Santos, A. G. Expósito, J. L. M. Ramos, and J. C. R. Santos, "Electricity market price forecasting based on weighted nearest neighbors techniques," *IEEE Trans. Power Syst.*, vol. 22, no. 3, pp. 1294–1301, 2007.

[76] Ö. F. Ertugrul, "Forecasting electricity load by a novel recurrent extreme learning machines approach," *Int. J. Electr. Power Energy Syst.*, vol. 78, pp. 429–435, 2016.

[77] Y. Chen *et al.*, "Short-term electrical load forecasting using the Support Vector Regression (SVR) model to calculate the demand response baseline for office buildings," *Appl. Energy*, vol. 195, pp. 659–670, 2017.

[78] H.-Z. Li, S. Guo, C.-J. Li, and J.-Q. Sun, "A hybrid annual power load forecasting model based on generalized regression neural network with fruit fly optimization algorithm," *Knowledge-Based Syst.*, vol. 37, pp. 378–387, 2013.

[79] D. Niu, Y. Wang, and D. D. Wu, "Power load forecasting using support vector machine and ant colony optimization," *Expert Syst. Appl.*, vol. 37, no. 3, pp. 2531–2539, 2010.

[80] P.-F. Pai and W.-C. Hong, "Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms," *Electr. Power Syst. Res.*, vol. 74, no. 3, pp. 417–425, 2005.

[81] A. Dedinec, S. Filiposka, A. Dedinec, and L. Kocarev, "Deep belief network based electricity load forecasting: An analysis of Macedonian case," *Energy*, vol. 115, pp. 1688–1700, 2016.

[82] F.-Y. Ju and W.-C. Hong, "Application of seasonal SVR with chaotic gravitational search algorithm in electricity forecasting," *Appl. Math. Model.*, vol. 37, no. 23, pp. 9643–9651, 2013.

[83] J. W. Taylor, "Triple seasonal methods for short-term electricity demand forecasting," *Eur. J. Oper. Res.*, vol. 204, no. 1, pp. 139–152, 2010.

[84] V. Bianco, O. Manca, and S. Nardini, "Electricity consumption forecasting in Italy using linear regression models," *Energy*, vol. 34, no. 9, pp. 1413–1421, 2009.

[85] A. Rahman, V. Srikumar, and A. D. Smith, "Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks," *Appl. Energy*, vol. 212, pp. 372–385, 2018.

[86] J.-F. Chen, S.-K. Lo, and Q. Do, "Forecasting monthly electricity demands: an application of neural networks trained by heuristic algorithms," *Information*, vol. 8, no. 1, p. 31, 2017.

[87] J. Bedi and D. Toshniwal, "Deep learning framework to forecast electricity demand," *Appl. Energy*, vol. 238, pp. 1312–1326, 2019.

[88] M. S. Al-Musaylh, R. C. Deo, J. F. Adamowski, and Y. Li, "Short-term electricity demand forecasting with MARS, SVR and ARIMA models using aggregated demand data in Queensland, Australia," *Adv. Eng. Informatics*, vol. 35, pp. 1–16, 2018.

[89] Z. Zhao, W. Chen, X. Wu, P. C. Y. Chen, and J. Liu, "LSTM network: a deep learning approach for short-term traffic forecast," *IET Intell. Transp. Syst.*, vol. 11, no. 2, pp. 68–75, 2017.

[90] X. Qing and Y. Niu, "Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM," *Energy*, vol. 148, pp. 461–468, 2018.

[91] Y. Zhao, J. Li, and L. Yu, "A deep learning ensemble approach for crude oil price forecasting," *Energy Econ.*, vol. 66, pp. 9–16, 2017.

[92] C.-Y. Zhang, C. L. P. Chen, M. Gan, and L. Chen, "Predictive deep Boltzmann machine for multiperiod wind speed forecasting," *IEEE Trans. Sustain. Energy*, vol. 6, no. 4, pp. 1416–1425, 2015.

[93] J. Ke, H. Zheng, H. Yang, and X. M. Chen, "Short-term forecasting of passenger demand under on-demand ride services: A spatio-temporal deep learning approach," *Transp. Res. Part C Emerg. Technol.*, vol. 85, pp. 591–608, 2017.

[94] A. Alzahrani, P. Shamsi, C. Dagli, and M. Ferdowsi, "Solar irradiance forecasting using deep neural networks," *Procedia Comput. Sci.*, vol. 114, pp. 304–313, 2017.

[95] G. Suryanarayana, J. Lago, D. Geysen, P. Aleksiejuk, and C. Johansson, "Thermal load forecasting in district heating networks using deep learning and advanced feature selection methods," *Energy*, vol. 157, pp. 141–149, 2018.

[96] R. Law, G. Li, D. K. C. Fong, and X. Han, "Tourism demand forecasting: A deep learning approach," *Ann. Tour. Res.*, vol. 75, pp. 410–423, 2019.

[97] S. Hwangbo, K. Nam, S. Heo, and C. Yoo, "Hydrogen-based self-sustaining integrated renewable electricity network (HySIREN) using a supply-demand forecasting model and deep-learning algorithms," *Energy Convers. Manag.*, vol. 185, pp. 353–367, 2019.

[98] C.-J. Huang and P.-H. Kuo, "A deep cnn-lstm model for particulate matter (PM2. 5) forecasting in smart cities," *Sensors*, vol. 18, no. 7, p. 2220, 2018.

[99] J. Zheng, X. Fu, and G. Zhang, "Research on exchange rate forecasting based on deep belief network," *Neural Comput. Appl.*, vol. 31, no. 1, pp. 573–582, 2019.

[100] S. Jiang, K.-S. Chin, L. Wang, G. Qu, and K. L. Tsui, "Modified genetic algorithm-based feature selection combined with pre-trained deep neural network for demand forecasting in outpatient department," *Expert Syst. Appl.*, vol. 82, pp. 216–230, 2017.

[101] K. Wang, X. Qi, H. Liu, and J. Song, "Deep belief network based k-means cluster approach for short-term wind power forecasting," *Energy*, vol. 165, pp. 840–852, 2018.

[102] H. Y. Kim and C. H. Won, "Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models," *Expert Syst. Appl.*, vol. 103, pp. 25–37, 2018.

[103] E. Cadenas and W. Rivera, "Wind speed forecasting in three different regions of Mexico,

using a hybrid ARIMA–ANN model," *Renew. Energy*, vol. 35, no. 12, pp. 2732–2738, 2010.

[104] M. Kumar and M. Anand, "An application of time series ARIMA forecasting model for predicting sugarcane production in India," *Stud. Bus. Econ.*, vol. 9, no. 1, pp. 81–94, 2014.

[105] W. Wang, K. Chau, D. Xu, and X.-Y. Chen, "Improving forecasting accuracy of annual runoff time series using ARIMA based on EEMD decomposition," *Water Resour. Manag.*, vol. 29, no. 8, pp. 2655–2675, 2015.

[106] S. Barak and S. S. Sadegh, "Forecasting energy consumption using ensemble ARIMA–ANFIS hybrid algorithm," *Int. J. Electr. Power Energy Syst.*, vol. 82, pp. 92–104, 2016.

[107] M. Qin, Z. Li, and Z. Du, "Red tide time series forecasting by combining ARIMA and deep belief network," *Knowledge-Based Syst.*, vol. 125, pp. 39–52, 2017.

[108] S. Jiang, C. Yang, J. Guo, and Z. Ding, "ARIMA forecasting of China's coal consumption, price and investment by 2030," *Energy Sources, Part B Econ. Planning, Policy*, vol. 13, no. 3, pp. 190–195, 2018.

[109] M. H. Amini, A. Kargarian, and O. Karabasoglu, "ARIMA-based decoupled time series forecasting of electric vehicle charging demand for stochastic power system operation," *Electr. Power Syst. Res.*, vol. 140, pp. 378–390, 2016.

[110] C. Yuan, S. Liu, and Z. Fang, "Comparison of China's primary energy consumption forecasting by using ARIMA (the autoregressive integrated moving average) model and GM (1, 1) model," *Energy*, vol. 100, pp. 384–390, 2016.

[111] J. Leithon, T. J. Lim, and S. Sun, "Renewable energy management in cellular networks: An online strategy based on ARIMA forecasting and a Markov chain model," in *2016 IEEE Wireless Communications and Networking Conference*, 2016, pp. 1–6.

[112] E. M. de Oliveira and F. L. C. Oliveira, "Forecasting mid-long term electric energy consumption through bagging ARIMA and exponential smoothing methods," *Energy*, vol. 144, pp. 776–788, 2018.

[113] A. A. Ebiefung and M. M. Kostreva, "The generalized Leontief input-output model and its application to the choice of new technology," *Ann. Oper. Res.*, vol. 44, no. 2, pp. 161–172, 1993.

[114] M. Kucukvar, N. C. Onat, and M. A. Haider, "Material dependence of national energy development plans: The case for Turkey and United Kingdom," *J. Clean. Prod.*, vol. 200, pp. 490–500, 2018.

[115] C. de la Rúa and Y. Lechón, "An integrated Multi-Regional Input-Output (MRIO) Analysis of miscanthus biomass production in France: Socio-economic and climate change consequences," *Biomass and Bioenergy*, vol. 94, pp. 21–30, 2016.

[116] entso e, "https://tyndp.entsoe.eu/"

EKLER

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Ömer Algorabi
Doğum Yeri	Kadıköy
Doğum Tarihi	15.03.1993
Uyruğu	☑ T.C. ❒ Diğer:
Telefon	05342173693
E-Posta Adresi	omer.algorabi@istanbul.edu.tr
Web Adresi	



Eğitim Bilgileri	
Lisans	
Üniversite	İstanbul Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Endüstri Mühendisliği
Mezuniyet Yılı	2016

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi-Cerrahpaşa
Enstitü Adı	Lisansüstü Eğitim Enstitüsü
Anabilim Dalı	Endüstri Mühendisliği Anabilim Dalı
Programı	Endüstri Mühendisliği, Yüksek Lisans Programı(Örgün Öğretim)

Makale ve Bildiriler
ÜNLÜ R., NAMLI E., ALGORABİ Ö., "A Machine learning based forecasting model for real time electricity markets in Turkey", 5TH INTERNATIONAL ENGINEERING SCIENCES CONFERENCE, Ankara, Türkiye, 19 Eylül 2019, ss.42 ALGORABİ Ö., NAMLI E., ÜNLÜ R., "A comprehensive energy supply forecasting model: comparison between Turkey and EU Countries", 10th International Symposium on Intelligent Manufacturing and Service Systems, Sakarya, Türkiye, 9 - 11 Eylül 2019, ss.373-380