

# Türkiye ve AB'de Elektrik Üretiminin Malzeme Ayak İzi Analizi: Derin Öğrenme Yaklaşımı

Dr. Ömer ALGORABI




İKSAD  
Publishing House

# **Türkiye ve AB’de Elektrik Üretiminin Malzeme Ayak İzi Analizi: Derin Öğrenme Yaklaşımı**

**Dr. Ömer ALGORABI**

DOI: <https://dx.doi.org/10.5281/zenodo.17776139>



Copyright © 2025 by iksad publishing house  
All rights reserved. No part of this publication may be reproduced, distributed  
or transmitted in any form or by  
any means, including photocopying, recording or other electronic or  
mechanical methods, without the prior written permission of the publisher, except in  
the case of

brief quotations embodied in critical reviews and certain other noncommercial  
uses permitted by copyright law. Institution of Economic Development and Social

Researches Publications®

(The Licence Number of Publicator: 2014/31220)

TÜRKİYE TR: +90 342 606 06 75

USA: +1 631 685 0 853

E mail: [iksadyayinevi@gmail.com](mailto:iksadyayinevi@gmail.com)

[www.iksadyayinevi.com](http://www.iksadyayinevi.com)

It is responsibility of the author to abide by the publishing ethics rules.

Iksad Publications – 2025©

**ISBN: 978-625-378-409-6**

Cover Design: İbrahim KAYA

November / 2025

Ankara / Türkiye

Size: 16x24cm

## ÖNSÖZ

Bu kitabın konusunu temsil eden araştırma, İstanbul Üniversitesi-Cerrahpaşa Mühendislik Fakültesi öğretim üyesi Doç. Dr. Ersin NAMLI danışmanlığında Endüstri Mühendisliği Anabilim dalında yüksek lisans tez çalışması olarak hazırlanmıştır.

Bu çalışmada, küresel ölçekte artan enerji talebinin doğal kaynaklar üzerindeki baskısını incelemek ve farklı enerji politikalarının malzeme bağımlılığı üzerindeki etkilerini değerlendirmek amacıyla hazırlanmıştır. Türkiye, Almanya ve İspanya’nın yenilenebilir ve fosil kaynaklara dayalı elektrik üretimleri çok yönlü bir girdi-çıktı modeliyle analiz edilmiş; metalik ve metalik olmayan materyaller açısından malzeme ayak izi değerlendirmeleri yapılmıştır. Bunun yanı sıra, elektrik üretiminin geleceğe yönelik seyrini tahmin etmek üzere LSTM ve ARIMA modelleri geliştirilmiş ve karşılaştırılmıştır.

Çalışma kapsamında olağan durum senaryosuna ek olarak GCA, ST, DG ve EU enerji kalkınma senaryoları incelenmiş; ülkeler ve dönemler için malzeme verimliliği açısından en uygun seçeneklerin belirlenmesine katkı sunulmuştur. Elde edilen bulguların, sürdürülebilir enerji politikalarının geliştirilmesine ve karar vericiler için yol gösterici nitelikte olacağı düşünülmektedir.

Bu araştırmanın tüm aşamalarında desteklerini esirgemeyen danışmanıma, çalışmaya katkı sağlayan tüm akademik ve kurumsal paydaşlara teşekkür ederim.

Dr. Ömer ALGORABI  
İstanbul, 2025



## İÇİNDEKİLER

|                                                 |           |
|-------------------------------------------------|-----------|
| <b>ÖNSÖZ.....</b>                               | <b>i</b>  |
| <b>GİRİŞ.....</b>                               | <b>1</b>  |
| <b>1. GENEL KISIMLAR.....</b>                   | <b>5</b>  |
| 1.1. Elektrik .....                             | 5         |
| 1.1.1. Türkiye’deki Elektrik Sektörü .....      | 7         |
| 1.1.2. Almanya’daki Elektrik Sektörü .....      | 9         |
| 1.1.3. İspanya’daki Elektrik Sektörü .....      | 11        |
| 1.2. Derin Öğrenme .....                        | 11        |
| 1.2.1. Derin Öğrenmede Tarihsel Eğilimler ..... | 12        |
| 1.2.2. Çok Katmanlı Algılayıcılar .....         | 13        |
| 1.2.3. Derin Öğrenmede Düzenleştirme.....       | 14        |
| 1.2.4. Derin Sinir Ağları .....                 | 15        |
| 1.2.5. Evrişimsel Sinir Ağları .....            | 16        |
| 1.2.6. Tekrarlayan Sinir Ağları .....           | 23        |
| 1.3. ARIMA .....                                | 28        |
| 1.3.1. Modelin Belirlenmesi .....               | 29        |
| 1.3.2. Parametre Tahminleri .....               | 30        |
| 1.3.3. Ayırt Edici Kontrol .....                | 30        |
| 1.3.4. Model Seçim Kriterleri.....              | 31        |
| 1.4. Literatür Taraması .....                   | 32        |
| <b>2. MALZEME VE YÖNTEM.....</b>                | <b>45</b> |
| 2.1. Veri Setinin Tanıtılması .....             | 45        |
| 2.2. AKIŞ ŞEMASI .....                          | 46        |
| 2.3. MODELLEME VE YÖNTEM.....                   | 46        |
| 2.3.1. Yazılım Modelleme .....                  | 46        |

|                                                    |           |
|----------------------------------------------------|-----------|
| 2.3.2. Performans Ölçütleri .....                  | 47        |
| 2.3.3. Girdi Çıktı Analizi .....                   | 48        |
| 2.3.4. Malzeme Ayak İzi.....                       | 49        |
| 2.4. Elektrik Gelişim Planları ve Senaryolar ..... | 49        |
| 2.4.1. Küresel İklim Aksiyonu .....                | 50        |
| 2.4.2. Sürdürülebilir Geçiş .....                  | 50        |
| 2.4.3. Dağıtılmış Üretim.....                      | 50        |
| 2.4.4. Avrupa Komisyonu Senaryosu .....            | 51        |
| <b>3. BULGULAR .....</b>                           | <b>52</b> |
| <b>4. TARTIŞMA VE SONUÇ .....</b>                  | <b>87</b> |
| <b>KAYNAKLAR .....</b>                             | <b>89</b> |

## 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 (Topcu vd., 2019).

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 (Gurgul ve Lach, 2012; Altınay ve Karagol, 2005). 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 (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 geliştirmekte olan ülkelere 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 itibarıyla toplam elektrik üretimi miktarının% 36,14’ü ithal doğal gaz ve kömürden gelmektedir. Ayrıca, Türkiye Elektrik İletim Anonim Şirketi’nin 5 yıllık elektrik üretim projeksiyonuna göre, enerji bağımlılığında ani bir değişiklik görülmesi beklenmemektedir.

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 (Mohamed ve Podger, 2005). 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 (Hamzaçebi, 2007; Kavaglioglu, 2007). Özellikle günümüzde çok popüler olan derin öğrenme yöntemleri, elektrik üretim veya tüketim tahmini için kullanılmakta ve üstün başarı elde edilmektedir.

Ünler (2008) çalışmasında, popülasyon, ithalat ve ihracat miktarının bir fonksiyonu olarak belirlenen elektrik üretimini tahmin etmek için Parçacık Sürüsü Optimizasyonu ve Karınca Kolonisi optimizasyonu yöntemleri kullanmıştır. Karınca kolonisi optimizasyon yöntemi elektrik üretiminin yanı sıra tüketimi de tahmin etmek için önerilmiştir (Toksarı, 2009). 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 (Hamzacebi ve Es, 2014; Akay ve Atak, 2007), Akay ve Atak (2007) Optimizasyon yöntemlerine ek olarak, yukarıda belirtilen tahmin problemini ortaya çıkarmak için bazı iyi bilinen istatistiksel yaklaşımlar da önerilmiştir. Otoregresif Entegre Hareketli Ortalama (ARIMA) ve mevsimsel ARIMA (SARIMA), Türkiye'nin enerji talebi ve gelecekteki öngörüler için bir temel tahmin modeli oluşturmak için uygulanmıştır (Ediger ve Akar, 2007; Albayrak 2010). Klasik istatistiksel yöntemlerin yanı sıra, makine öğrenimine dayalı yöntemler literatürde yaygın olarak kullanılmıştır. Destek Vektör Regresyonu (SVR), anahtar girdi elektrik tüketimini nüfus, GSYİH, ithalat-ihracat ve ihracat miktarı olmak üzere dört girdinin bir fonksiyonu olarak tahmin etmek için uygulanmıştır (Kavaklioglu, 2011). 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. Sozen vd. (2005) 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 Kucukali ve Baris (2010) 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 (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 (Giljum vd., 2015)

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 (MRIO) yaklaşımları geliştirilmiştir (Giljum vd., 2015).

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.

Çalışmanın 1. bölümünde, elektrik sektörü, derin öğrenme, ARIMA ile ilgili bilgiler verilmiş ve literatür taraması yapılmıştır. 2. bölümde ise kullanılan


veri seti, yöntem ve yazılımlar ile ilgili bilgiler verilmiştir. 3. bölümde, tahmin sonuçlarının karşılaştırılması ve malzeme ayak izlerinin hesaplanması ile elde edilen bulgulara yer verilmiştir. Son olarak, çalışma, bölüm 4’te verilen sonuç ve öneriler kısmıyla tamamlanmıştır.

## 1. GENEL KISIMLAR

### 1.1. Elektrik


Elektrik enerjisi, üretim yerinden çok uzaklara dağıtım şebekeleri ile kolayca taşınabilen, dağıtımı kontrol altında tutulabilen, temiz bir enerji kaynağıdır (Hamzaçebi ve Kutay, 2004). Elektrik, dünyadaki enerji kaynakları arasında yükselen bir güçtür. Elektrik üretimi kaynaklarına olan talep, dünyanın son yıllarda sahip olduğu ekonomik büyüme nedeniyle artmıştır (Topcu vd., 2019).

Uluslararası Enerji Ajansı (IEA) verilerine göre; 1974-2016 yılları arasındaki farklı ülke gruplarının elektrik üretim değerleri Şekil 1’de gösterilmiştir.




Şekil 1: Farklı Ülke Gruplarının Elektrik Üretim Değerleri (IEA Raporu,2018)

Dünya’daki elektrik üretiminin enerji kaynaklarına göre dağılımı ise Şekil 2’de gösterilmektedir.




**Şekil 0:** 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’dır. Kömürden sonra elektrik üretimine en fazla katkı sağlayan kaynak doğalgazdır. 2016 yılına ait değerlere göre, farklı enerji kaynaklarının elektrik üretimindeki payları Şekil 3’te gösterilmiştir.




**Şekil 1:** Farklı Enerji Kaynaklarının Elektrik Üretimindeki Payları (IEA Raporu,2018)

Şekil 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 4:** Yenilenebilir Enerji Kaynaklarının Elektrik Üretimindeki Payları (IEA Raporu,2018)

2016 yılında dünya toplam nihai elektrik tüketimi 20 863 TWh'ye ulaşmıştır (IEA Raporu,2018). Şekil 5'te 1974-2016 yılları arasındaki farklı sektörlere göre nihai elektrik tüketim değerleri gösterilmiştir.



**Şekil 5:** Farklı Sektörlere Göre Nihai Elektrik Tüketimi (IEA Raporu,2018)

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

### 1.1.1. 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 (Aydın, 2018). Türkiye, ekonomik güçlenme üzerinde büyük etkisi olan kişi başına düşen elektrik talebi büyümesi bakımından Ekonomik İşbirliği ve Kalkınma Örgütü ülkeleri arasında şampiyondur (Hamzaçebi ve Kutay, 2004). 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 (IEA Raporu,2018).

Tablo 1’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’ünü 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 (Hamzaçebi ve Kutay, 2004).

**Tablo 1:** Elektrik üretimi


| Kaynak      | Elektrik Üretimi |       |
|-------------|------------------|-------|
|             | 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 |

### 1.1.2 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 (Deloitte, n.d.).

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 6'da 2018 yılına ait farklı enerji kaynaklarına göre elektrik üretim miktarları gösterilmiştir (Fraunhofer ISE, 2018).




Şekil 6: 2018 yılına ait Almanya’da farklı enerji kaynaklarına göre elektrik üretim miktarı

Yıllara göre Almanya’daki yenilenebilir enerji kaynaklarının elektrik üretimindeki değerleri Şekil 7’de gösterilmiştir (Fraunhofer ISE, 2018).



**Şekil 7:** Almanya’da Yenilenebilir Enerji Kaynaklarının Elektrik Üretimindeki Değerleri

Yıllara göre Almanya’daki yenilenebilir olmayan enerji kaynaklarının elektrik üretimindeki değerleri Şekil 8’de gösterilmiştir (Fraunhofer ISE, 2018).




**Şekil 8:** Almanya’da Yenilenebilir Olmayan Enerji Kaynaklarının Elektrik Üretimindeki Değerleri

### 1.1.3 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 (de España, 2014).

2018 yılında, İspanya’daki tüm üretim tesislerindeki kurulu güç kapasitesi, üst üste üçüncü yıl düştü ve yılı, Tarragona Kombine Çevrim Elektrik Santralini 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 (de España, 2014).

İspanya’daki elektrik üretiminin enerji kaynakları ve yıllara göre dağılımı Şekil 9’da gösterilmiştir (IEA Raporu,2018). Son yıllarda, doğal gaz ve kömür ile üretilen elektrik üretiminin azaldığı, rüzgar enerjisi ile ise elektrik üretiminin arttığı gözlemlenmektedir.



Şekil 9: İspanya’da Elektrik Üretiminin Enerji Kaynaklarına Göre Dağılımı

### 1.2. Derin 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 (MLP’de) 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 (Lago, De Ridder ve De Schutter, 2018).

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 (Guo vd., 2016).


### **1.2.1 Derin Öğrenmede Tarihsel Eğilimler**

Derin öğrenmeyi açıklamak için ilk olarak tarihsel eğilimleri dikkate almak gerekir. Derin öğrenmedeki önemli eğilimler (Goodfellow vd., 2016):

- Derin öğrenme uzun ve geniş bir tarihe sahiptir, ancak farklı felsefi bakış açılarını yansıtan birçok isimle geçmiş ve popüleritesi 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 popüleritesinden 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. (Goodfellow vd., 2016).

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 10’da gösterilmiştir (Goodfellow vd., 2016).



Şekil 10: Sibernetik ve Bağlantıcılık

### 1.2.2 Çok Katmanlı Algılayıcılar

Çok Katmanlı Algılayıcılar (MLP), verilen girdi verilerini beklenen çıktı verileriyle eşleyen bir sinir ağı türüdür. MLP, yönlendirilmiş bir grafikte birden çok düğüm katmanından oluşur; her katman bir sonrakine tamamen bağlanır (Zhang vd., 2016).

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 1'deki gibi ifade edilir.

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

$g$  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,

$$y_l(n) = h(\sum_{j=0}^M B_k z_j(n)) \quad (2)$$

$z_j(n)$  gizli katmandaki  $j$ 'inci nöronun çıktısı ve  $j = 1, 2, \dots, M$ , Denklem 3'teki gibi temsil edilir:

$$z_j(n) = g(\sum_{i=0}^d A_{ji}x_i(n)) \quad (3)$$

### 1.2.3 Derin Öğrenmede Düzenleştirme

#### 1.2.3.1 Parametre Normu Cezaları

Çoğu düzenleştirme 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,

$$\hat{J}(\theta; X, y) = J(\theta; X, y) + \alpha\Omega(\theta) \quad (4)$$

burada  $\alpha \in [0, \omega)$  norm ceza terimi  $\Omega$ ’nın standart amaç fonksiyonu  $J$ ’ye göre katkısının ağırlığını belirleyen bir hiperparametredir.

#### 1.2.3.2 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.

#### 1.2.3.3 Gürültü Direnci

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

#### 1.2.3.4 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.

#### 1.2.3.5 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.

### **1.2.3.6 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 döndürmekten önce, kaydedilen parametreler geri döndürülür. Bu strateji, erken durdurma olarak bilinir.

### **1.2.3.7 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.

### **1.2.4 Derin Sinir Ağları**

Derin Sinir Ağları (DNN), girdi ve çıktı arasında birden fazla gizli birim katmanına sahip, ileri beslemeli, yapay bir sinir ağıdır (Hinton *vd.*, 2012). 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 ağı modeli, verilen görüntü ile birlikte köpeğin belirli bir cins olma olasılığını hesaplayacaktır. Kullanıcı sonuçları inceleyebilir ve ağın hangi olasılıkları göstermesi gerektiğini (belirli bir eşliğin 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 (Shinde *vd.*, 2019).

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. Ağı belirli bir modeli doğru şekilde tanımazsa, bir algoritma ağırlıkları ayarlayacaktır.

DNN'ler, daha sıkı sinir ağlarına göre daha karmaşık ve soyut olan üst düzey özellikleri öğrenebilirler. Bu noktayı gösteren bir örnek, görsel verileri işlemek için DNN'leri kullanmaktır (Sze *vd.*, 2017).

### **1.2.5 Evrişimsel Sinir Ağları**


Evrişimsel Sinir Ağları (ESA, CNN) yapısı ilk olarak LeCun tarafından 1989 yılında ortaya atılmıştır (LeCun *vd.*, 1989). 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 (Kelleher, 2019).

Evrişimsel sinir ağlarına ile öne sürülen modeller birçok avantaja sahiptir. Bunlar (TÜRKOĞLU *vd.*, no date);

- 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 kullanılabilir.

#### **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 11'de gösterilmektedir (O'Shea and Nash, 2015).




Şekil 11: CNN mimarisi

### 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 (Yaseen and Saud, 2018):

- 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 12: Evrişim Katmanı

### 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 ögeyi varsayar. En büyük unsurun varsayılması da ortalama ortaklamayı oluşturur. Tüm özellik eşleme öğelerinin toplanması, toplam ortaklamayı üretir. Maksimum tipi ortaklama Şekil 13’te gösterilmiştir (Yaseen and Saud, 2018).



**Şekil 2:** Maksimum ortaklama

### **Tam Bağlantı Katmanı**

Tam bağlantı katmanı, nöronların geleneksel bir sinir ağında düzenlenmesine benzer. Bu nedenle, tam bağlantı katmandaki her düğüm, Şekil 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 (Albawi, Mohammed and Al-Zawi, 2017).




Şekil 3: Tam bağlantı katmanı

#### 1.2.5.2 ESA Modelleri

##### LeNet-5


LeNet-5, gradyan tabanlı bir öğrenme CNN yapısıdır ve ilk olarak elle yazılmış dijital karakter tanımda başarıyla uygulanmıştır. Tipik LeNet-5 yapı şeması Şekil 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 çıktı 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 x 2'ye ayarlanmıştır. Tam bağlantı katmanı, parametre eğitimini azaltmak için nöron sayısını 120'den 84'e düşürür (Wei vd., 2019).



Şekil 4: LeNet-5 Yapısı

## AlexNet

Krizhevsky, Sutskever ve Hinton tarafından geliştirilmiştir. 2012’de Alex Krizhevsky 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,  $11 \times 11$  boyutunda 96 farklı alıcı filtrenin kullanıldığı Yerel Yanıt Normalizasyonu (LRN) ile evrişim ve maksimum ortaklama gerçekleştirir. Maksimum ortaklama işlemleri, adım boyutu 2 olan  $3 \times 3$  filtrelerle gerçekleştirilir. Aynı işlemler  $5 \times 5$  filtreli ikinci katmanda gerçekleştirilir. Üçüncü, dördüncü ve beşinci evrişimsel katmanlarda sırasıyla 384, 384 ve 296 özellik haritalarına sahip  $3 \times 3$  filtreler kullanılır. Seyreltme ve en sonda bir softmax ile iki tam bağlantı katmanları kullanılır. Benzer yapıya ve aynı sayıda özellik haritasına sahip iki ağı, bu model için paralel olarak eğitilir. Yerel ağıda Normal Yanıt (LRN) ve seyreltme olmak üzere iki yeni kavram bu ağda tanıtılmaktadır. LRN iki farklı şekilde uygulanabilir: ilk önce aynı kanal haritasından bir  $N \times N$  yamasının seçildiği v komşuluk değerlerine göre normalleştirildiği tek kanal veya özellik haritalarına uygulanmaktadır. İkincisi, LRN kanallara veya özellik haritalarına uygulanabilmektedir (Alom *vd.*, 2018). Şekil 16’da AlexNet mimarisi gösterilmektedir (KIZRAK and BOLAT, 2018).




Şekil 5: 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 17’de gösterildiği gibi bir üst maksimum biriktirme katmanı izler (Yu vd., 2016).




Şekil 6: VGG-16 mimarisi (DOĞAN and TÜRKOĞLU, 2018).

## 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 5’teki gibi ifade edilir (Tai, Yang and Liu, 2017):

$$\hat{x} = U(x) = \sigma(F(x, W) + h(x)) \quad (5)$$


burada  $\hat{x}$  artık ünitenin çıktısı,  $h(x)$  ise haritalamanın kimliğidir:  $h(x) = x$ ,  $W$  bir ağırlık kümesidir (notasyonları basitleştirmek için sapmalar ihmal edilir),  $\sigma$  fonksiyonu ReLU’yu,  $F(x, W)$  öğrenilecek kalıcı haritalamayı ve  $U$ , kalıcı birim yapısının fonksiyonunu belirtir. Res-Net yapısı Şekil 18’deki gibidir (Tai, Yang and Liu, 2017).



**Şekil 7:** Res-Net mimarisi

### 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 19’da GoogLeNet ağ mimarisi verilmiştir (DOĞAN and TÜRKOĞLU, 2018). GoogLeNet’te, mimariyi oluşturmak için kullanılan 9 Inception modülü vardır. Başlangıç modülü, parametrelerin ölçeğini ve model karmaşıklığını sınırlamak için elverişli, küçük boyutlu ( $1 \times 1$ ,  $3 \times 3$  ve  $5 \times 5$  gibi) birkaç evrilşim 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 (Tang, Wang and Kwong, 2017).



Şekil 8: GoogLeNet mimarisi

### 1.2.6 Tekrarlayan Sinir Ağları

Tekrarlayan sinir ağları (RNN), doğal dil için gerekli olduğu düşünülen hiyerarşik yapıyı açıkça kodlamayan genel dizi işleme mekineleridir. Yapay dilleri kullanarak yapılan erken çalışmalar, yine de bağımsız 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 (Gulordava vd., 2018). 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 ögesi için (cümledeki kelimeler gibi) aynı görevi önceki çıktılara bağlı olarak yerine getirmesidir (Şeker, Diri and Balık, no date).

Bir girdi dizisi  $x = (x_1, \dots, x_T)$  verildiğinde, standart bir tekrarlayan sinir ağı, Denklem 6 ve Denklem 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 (Graves, Mohamed and Hinton, 2013):

$$h_t = H(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \quad (6)$$

$$y_t = W_{hy}h_t + b_y \quad (7)$$

$W$  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 (Graves, Mohamed and Hinton, 2013).

### 1.2.6.1 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 8 ve 9’daki gibi gösterilmiştir (Mesnil vd., 2015):

$$h^{(1)}(t) = f \left( U^{(1)} C_d (l_{t-d}^{t+d}) + U'^{(1)} h^{(1)}(t-1) \right) \quad (8)$$

$$h^{(n+1)}(t) = f \left( U^{(n+1)} h^{(n)}(t) + U'^{(n+1)} h^{(n+1)}(t-1) \right) \quad (9)$$

Burada, doğrusal olmayan sigmoid fonksiyonunu kullanıldığı yerde,  $f(x) = 1/(1 + e^{-x})$  ve  $h^{(i)}(0) \in R^{d_h}$  gizli katmanı için akıllı öğrenin 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 softmax fonksiyonu Denklem 10’da verilmiştir (Mesnil vd., 2015):

$$P(y(t) = i | l_0^{t+d}) = \frac{e^{\sum_{j=1}^{d_h} V_{i,j} h_j^{(H)}(t)}}{\sum_{i=1}^N e^{\sum_{j=1}^{d_h} V_{i,j} h_j^{(H)}(t)}} \quad (10)$$

Burada  $V$ , softmax üst katmanın ağırlığına karşılık gelir (Mesnil vd., 2015).


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 (Zhang vd., 2018).

Jordan RNN, Elman tipi ağa, tekrarlayan bağlantıların girdilerini çıktı sonsal olasılıklarından alması dışında benzerdir ve Denklem 11’deki gibi ifade edilir (Mesnil vd., 2015):

$$h(t) = f \left( U C_d (l_{t-d}^{t+d}) + U' P(y(t-1)) \right) \quad (11)$$

$U' \in M_{d_h \times N}(R)$  ve  $P(y(0)) \in R^N$  ayarlanması gereken ek parametrelerdir (Mesnil vd., 2015).

Bu modellerin mimarileri Şekil 20'de gösterilmektedir (Mesnil vd., 2015).



Şekil 9: 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 12 ile temsil edilebilir (Zhang vd., 2018):

$$\begin{aligned} \text{çıktı}(t+1) = \\ f \left[ \begin{array}{c} \text{çıktı}(t-1), \text{çıktı}(t-2), \dots, \text{çıktı}(t+1-q); \\ \text{girdi}(t-k), \text{girdi}(t-k-1), \dots, \text{girdi}(t-k-p+1) \end{array} \right] \end{aligned} \quad (12)$$

$\text{girdi}(t)$  ve  $\text{çıktı}(t)$  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  $k$  ( $k \geq 0$ ) gecikmeli bir terimdir.  $f[\cdot]$  doğrusal olmayan fonksiyondur.  $\text{çıktı}(t-l)$ 'den  $\text{çıktı}(t+1-q)$ 'ya olan girdiler otoregresif bir model olarak işlev görür.  $\text{girdi}(t-k)$ 'den  $\text{girdi}(t-k-p+1)$ 'ye dış kaynaklı bir değişken rolü oynar (Zhang vd., 2018).

İki tür NARX eğitim yöntemi vardır: Seri Paralel (SP) eğitim yöntemi ve Paralel (P) yöntemidir. SP metodu matematiksel olarak Denklem 13 ile gösterilebilir (Zhang vd., 2018):

$$\begin{aligned} \text{çıktı}(t+1) = \\ f \left[ \begin{array}{c} \text{gerçek}(t-1), \text{gerçek}(t-2), \dots, \text{gerçek}(t+1-q); \\ \text{girdi}(t-k), \text{girdi}(t-k-1), \dots, \text{girdi}(t-k-p+1) \end{array} \right] \end{aligned} \quad (13)$$

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, ağıın girdi katmanına, çıktı regresörü olarak geri beslemeli ise, bu mod P yöntemi olarak yapılabilir ve Denklem 14’teki gibi ifade edilir (Zhang vd., 2018):


$$\text{çıktı}(t + 1) = f \left[ \widehat{\text{gerçek}}(t - 1), \widehat{\text{gerçek}}(t - 2), \dots, \widehat{\text{gerçek}}(t + 1 - q); \widehat{\text{girdi}}(t - k), \widehat{\text{girdi}}(t - k - 1), \dots, \widehat{\text{girdi}}(t - k - p + 1) \right] \quad (14)$$

( $\wedge$ ) sembolü, tahmini değerleri belirtmek için kullanılmıştır (Zhang vd., 2018).

#### 1.2.6.3 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 (Fischer and Krauss, 2018). (Hochreiter and Schmidhuber, 1997) tarafından tanıtıldılar ve sonraki yıllarda, örneğin (Gers, Schmidhuber and Cummins, 1999) ile (Graves and Schmidhuber, 2005) 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 (Fischer and Krauss, 2018).

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 21’de gösterilmektedir (Fischer and Krauss, 2018).



Şekil 10: LSTM bellek hücresinin yapısı

Her zaman noktasında, üç geçitten her biri, önceki zaman adımıdaki  $t - 1$  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 (Fischer and Krauss, 2018):

- 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 (Fischer and Krauss, 2018):

- $x_t$ ,  $t$  adımıdaki girdi vektörüdür
- $W_{f,x}$ ,  $W_{f,h}$ ,  $W_{\tilde{s},x}$ ,  $W_{\tilde{s},h}$ ,  $W_{i,x}$ ,  $W_{i,h}$ ,  $W_{o,x}$  ve  $W_{o,h}$  ağırlık matrisleridir.
- $b_f$ ,  $b_{\tilde{s}}$ ,  $b_i$ , ve  $b_o$  önyargı vektörleridir.
- $f_t$ ,  $i_t$  ve  $o_t$ , ilgili geçitlerin aktivasyon değerlerine yönelik vektörlerdir.
- $s_t$  ve  $\tilde{s}_t$  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 (Fischer and Krauss, 2018):

İlk adımda, LSTM katmanı hangi bilgilerin önceki hücre durumlarından  $s_{t-1}$ 'den çıkarılması gerektiğini belirler. Bu nedenle,  $t$  adımıdaki unutma geçitlerinin aktivasyon değerleri  $f_t$ , mevcut  $x_t$  girdisine, önceki zaman

adımındaki  $(t - 1)$  bellek hücrelerinin  $h_{t-1}$  çıktısına ve unutmaya geçitlerinin  $b_f$  önyargı terimlerine göre hesaplanır. Sigmoid fonksiyonu sonunda tüm aktivasyon değerlerini 0 (tamamen unut) ve 1 (tamamen hatırla) arasındaki aralığa ölçeklendirir (Fischer and Krauss, 2018):

$$f_t = \text{Sigmoid}(W_{f,x}x_t + W_{f,h}h_{t-1} + b_f) \quad (15)$$

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 (Fischer and Krauss, 2018):

$$\hat{s}_t = \tanh(W_{\hat{s},x}x_t + W_{\hat{s},h}h_{t-1} + b_{\hat{s}}) \quad (16)$$

$$i_t = \text{Sigmoid}(W_{i,x}x_t + W_{i,h}h_{t-1} + b_i) \quad (17)$$

$$s_t = f_t \circ s_{t-1} + i_t \circ \hat{s}_t \quad (18)$$

Üçüncü adımda, yeni hücre durumları  $s_t$ , Hadamard (bilge element) ürününü ifade eden  $\circ$  önceki iki adımın sonuçlarına dayanarak hesaplanır (Fischer and Krauss, 2018):

Son adımda, bellek hücrelerinin  $h_t$  çıktısı aşağıdaki iki denklemde belirtildiği gibi türetilir (Fischer and Krauss, 2018):

$$o_t = \text{Sigmoid}(W_{o,x}x_t + W_{o,h}h_{t-1} + b_o) \quad (19)$$

$$h_t = o_t \circ \tanh(s_t) \quad (20)$$

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 (Fischer and Krauss, 2018).

### 1.3. ARIMA

Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli Box ve Jenkins tarafından önerilmiştir (Box and Jenkins, 1970). 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 (Cadenas *vd.*, 2016).

Birçok ARIMA modeli vardır. Mevsimsel olmayan genel model ARIMA (p, d, q) olarak bilinir, burada (Cadenas *vd.*, 2016):

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 (Cadenas *vd.*, 2016):

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

varyansı dengeleme katsayısı  $\varphi_i$ ,  $i$ . otoregressif parametresidir,  $\theta_j$ ,  $j$ . hareketli ortalama parametresidir ve  $\epsilon_t$ ,  $t$  zamanında hata terimidir (Cadenas *vd.*, 2016).

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 modellenenebilir (Cadenas *vd.*, 2016).

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 (ACF) ve kısmi otokorelasyon (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 (BAYRAMOĞLU and ÖZTÜRK, 2017).

### 1.3.1. Modelin Belirlenmesi

Model belirleme aşamalarını aşağıdaki gibi sıralamak mümkündür (Sevüktekin and Çınar, 2014):

Örneklem değerlerinin zaman serisi grafiği çizilir. Aykırı değerler tespit edilir. Eğer varyansın sabitliği için işlem gerekiyorsa, varyansın sabitliği gerçekleşene dek dönüştürme işlemi sürdürülür.

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.

Durağanlığa ulaşıldığında belirli bir kalıp görülüyorsa ACF’ler incelenir. Bu durumda

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.

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.

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.

### **1.3.2 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 (Sevüktekin and Çınar, 2014).

ARIMA modelleri tahminleri etkin bilgisayar programlarından yararlanılır. Bu programlarda, optimum parametre değerleri elde edilmeye çalışılmaktadır (Sevüktekin and Çınar, 2014).

### **1.3.3. Ayırt Edici Kontrol**

Model yeterliliği için başvuru alan 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 (Sevüktekin and Çınar, 2014).

Modelin kalıntıları test süreci için önemli bilgiler sağlar eğer uydurulan model yeterli ise kalıntılar yukarıda da ifade edildiği gibi yaklaşık olarak temizdir. Başka bir ifadeyle ARIMA(p,d,q) modeli veri-üretim sürecini yeteri düzeyde gösteriyorsa, kalıntılar korelasyonsuz ve rassal olacaklardır (Sevüktekin and Çınar, 2014).

### 1.3.4. Model Seçim Kriterleri

#### 1.3.4.1 Standart Belirlenim Katsayısı - $R^2$

Standart Belirleme Katsayısı ( $R^2$ ) bağımsız değişken(ler)’den öngörülebilir bağımlı değişken içindeki varyansın oranıdır. En genel tanımı Denklem 21’deki gibidir.

$$R^2 = 1 - \frac{SS_{gör}}{SS_{top}} \quad (21)$$

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

#### 1.3.4.2 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 22’deki gibi formüle edilir (Kumar and Jain, 2010):

$$AIC: c_n(k) = 2 \times \left(\frac{k}{n}\right) - 2 \times \ln(L)/n \quad (22)$$

L olabilirlik fonksiyonu, k modeldeki parametre sayısı ve n gözlem sayısıdır (Kumar and Jain, 2010).

#### 1.3.4.3 F-İstatistiği

ARIMA model belirlemede model seçim kriteri olarak başvuru 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 (Sevüktekin and Çınar, 2014).

Hesaplanan kısmi otokorelasyonların istatistiksel olarak anlamlı olup olmadığı, tahmin edilen katsayıların sayısı birden fazla ise F-istatistiğine 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 23’taki gibi hesaplanır (Sevüktekin and Çınar, 2014):

$$F^* = \frac{(SSR_r - SSR_u)/(u-m)}{SSR_u/(T-u)} \quad (23)$$

Hipotezler aşağıdaki gibi olsun:

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

$$H_1: \phi_i \text{’lerden en az biri farklıdır} (i=m+1, \dots, p)$$

Burada,  $SSR_r$  = kısıtlı AR(m) modelinin hata kareler toplamını,  $SSR_u$  = bütüncül AR(p) modelinin hata kareler toplamını gösterir. Eğer  $F^* > F_{u-m, T-u}^c$  (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 (Sevüktekin and Çınar, 2014).

#### *1.3.4.4 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 (Clement, 2014).

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 (Clement, 2014).

BIC Denklem 24’teki gibi tanımlanır (Clement, 2014):

$$BIC = n\{\ln(\hat{\sigma}_e^2)\} + k\{\ln(n)\} \quad (24)$$

$n$ : gözlem sayısı,  $k$ : tahmini edilecek serbest parametrelerin sayısı,  $\hat{\sigma}_e^2$ : hata sapmasıdır (Clement, 2014).

### **1.4. Literatür Taraması**

Elektrik sektörü ile ilgili literatürde birçok tahmin çalışması bulunmaktadır. Bu çalışmalardan bazıları Tablo 2’de gösterilmektedir.

**Tablo 0:** Derin Öğrenme Tahmin Çalışmaları

| Yazarlar                        | Metodoloji                       | Çalışmanın Özeti                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                            |
|---------------------------------|----------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Catalão vd. (Catalão vd., 2007) | Sinir Ağları 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. (Lora vd., 2007)       | 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 yapıp; 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 (Ertugrul, 2016)       | 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 ağı 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. (Chen vd., 2017)        | 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. (Li vd., 2013)           | -<br>Genelleştirilmiş Regresyon Sinir Ağı<br>-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. (Niu, Wang and Wu, 2010) | Destek Vektör Makineleri<br>Karıncalı Kolonisi Optimizasyonu           | Çalışmada, Destek Vektör Makinesi ve Karıncalı Kolonisi Optimizasyonu kullanılarak güç yükü tahmini için bir sistem oluşturulmuştur. Karıncalı 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 (Pai and Hong, 2005) | Tekrarlayan Destek Vektör Makineleri<br>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. (Dedinec 2016)     | Derin İnanç Ağları                                          | Çalışmalarında, elektrik yükü tahmini için çok sayıda kısıtlı Boltzmann makinesinden oluşan bir Derin İnanç Ağları (DBN) kullanmışlardır. 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 (Ju and Hong, 2013) | 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 (Taylor, 2010)                         | ARMA<br>Üstel<br>Düzleştirme<br>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 kullanarak, gün öncesi üçlü mevsimsel yöntemlerin çift mevsimsel yöntemlerden ve aynı zamanda tek değişkenli bir sinir ağı yaklaşımından daha iyi performans gösterdiği bulunmuştur. |
| Bianco vd. (Bianco, Manca and Nardini, 2009)  | 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 (Akay and Atak, 2007)            | 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. (Rahman, Srikumar and Smith, 2018) | 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. (Chen, Lo and Do, 2017)              | Gravitasyonel Arama Algoritması<br>Cuckoo Optimizasyon Algoritması<br>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 Toshiwal (Bedi and Toshiwal, 2019) | 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. (Al-Musaylh vd., 2018)      | 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 Otoresif 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 3'te gösterilmektedir.

**Tablo 3:** Derin Öğrenme Tahmin Çalışmaları

| Yazarlar                         | Metodoloji                                             | Çalışmanın Özeti                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                    |
|----------------------------------|--------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Zhao vd. (Zhao vd., 2017)        | 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 ağına, 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 (Qing and Niu, 2018) | 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. (Zhao, Li and Yu, 2017) | Torbalama Yöntemi<br>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. (Zhang vd., 2015)      | 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. (Ke vd., 2017)                       | 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. (Alzahrani vd., 2017)         | Derin Tekrarlayan Sinir Ağları                         | Çalışmada, Derin Tekrarlayan Sinir Ağları kullanılarak güneş ışıınımı 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. (Suryanarayana vd., 2018) | 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. (Law vd., 2019)                     | 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.<br>(Hwangbo vd., 2019)       | 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<br>(Huang and Kuo, 2018)    | Evrişimsel Sinir Ağları<br>Uzun-Kısa Süreli Bellek Ağı | PM <sub>2.5</sub> konsantrasyonunu izlemek ve tahmin etmek için, Evrişimsel Sinir Ağı (CNN) ve Uzun-Kısa Süreli Bellek Ağı (LSTM) hibrit olarak kullanılarak PM <sub>2.5</sub> 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 <sub>2.5</sub> konsantrasyonu gibi tarihsel verilerle geliştirilmiştir. |
| Zheng vd.<br>(Zheng, Fu and Zhang, 2019) | 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. (Jiang vd., 2017)              | Genetik Algoritma<br>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 öznelilik 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.<br>(Wang 2018)                  | K-Ortalamalar<br>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<br>(Kim and Won, 2018) | LSTM<br>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 4’te gösterilmektedir.

**Tablo 4:** ARIMA Yöntemiyle Tahmin Çalışmaları

| Yazarlar                                        | Metodoloji   | Çalışmanın Özeti                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                             |
|-------------------------------------------------|--------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Cadenas ve Rivera<br>(Cadenas and Rivera, 2010) | ARIMA<br>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<br>Madhu<br>(Kumar and<br>Anand,<br>2014)   | 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.<br>(Wang vd.,<br>2015)                      | ARIMA<br>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<br>Sadegh<br>(Barak and<br>Sadegh,<br>2016) | ARIMA<br>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 özneteliğiyle uygulanır. İkinci modelde, ANFIS tahmini için, 4 girdi özneteliğine 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. (Qin,<br>Li and Du,<br>2017)                 | ARIMA<br>Derin İnanc<br>Ağları<br>Parçacık Sürü<br>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.<br>(Jiang vd.,<br>2018)                                 | 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.<br>(Amini,<br>Kargarian<br>and<br>Karabasoglu,<br>2016) | 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.<br>(Yuan, Liu<br>and Fang,<br>2016)                      | ARIMA<br>Gri Model<br>(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.<br>(Leithon,<br>Lim and Sun,<br>2016)                 | ARIMA<br>Markov Zinciri<br>Modeli<br>Lineer<br>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<br>Oliveira (de<br>Oliveira and<br>Oliveira,<br>2018) | ARIMA<br>Torbalama<br>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.                                                                                                                                                                                                                                                                                                                                                                     |

## 2. MALZEME VE YÖNTEM


### 2.1. Veri Setinin Tanıtılması

Bu çalışmada ileriye dönük elektrik üretimi tahmini için, 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 22-24’teki gibidir.



Şekil 22: Türkiye Elektrik Üretimi




Şekil 23: Almanya Elektrik Üretimi



Şekil 24: İspanya Elektrik Üretimi

## 2.2. AKIŞ ŞEMASI

Bu çalışmasının akış şeması Şekil 3.4’deki gibidir.



Şekil 25: Akış Şeması

## 2.3. MODELLEME VE YÖNTEM

### 2.3.1. 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 problemi. 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 algoritmalarından 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 alınmıştır.

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  $2\sigma$  hata limitleri içinde olduğu görülmektedir.

### 2.3.2. Performans Ölçütleri

Tahmin yöntemlerinin performansını karşılaştırmak için, çeşitli tahmin özellikleri için çeşitli ölçütler kullanılır. Yöntemlerin kalitesini belirlemek için, Ortalama Mutlak Yüzde Hata (MAPE), Kök Bağlı Kare Hata (RRSE), Bağlı Mutlak Hata (RAE) ve Kök Ortalama Kare Hata (RMSE) kullanılmıştır. Bu ölçütler Denklem 25-28’de gösterilmiş olup; burada  $a$ , gerçek değeri ve  $p$ , tahmin değerini ifade etmektedir.

$$MAPE = \frac{1}{n} \times \sum_{i=1}^n \frac{|p_i - a_i|}{a_i} \quad (25)$$

$$RMSE = \sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n}} \quad (26)$$

$$RAE = \frac{1}{n} \times \frac{|p_1 - a_1| + \dots + |p_n - a_n|}{|a_1 - \bar{a}| + \dots + |a_n - \bar{a}|} \quad (27)$$

$$RRSE = \sqrt{\frac{1}{n} \times \frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2}} \quad (28)$$

### 2.3.3. 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 (Ebiefung and Kostreva, 1993). Bu model öyle ki, k üretimi üreten k sayıda endüstriler vardır. Başka bir deyişle, herhangi bir endüstrinin toplam tüketimi üretime eşittir (Kucukvar, Onat and Haider, 2018). 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 (de la Rúa and Lechón, 2016).

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 (de la Rúa and Lechón, 2016).

Bu nedenle, her sektörden toplam çıktı Denklem 29'teki gibi tanımlanır (de la Rúa and Lechón, 2016):

$$x_i = z_{i1} + z_{i2} + \dots + z_{in} + y_i \quad (29)$$

burada x, toplam çıktıyı ifade eden bir vektördür, Z, IO matrisidir ve y, son talep vektörüdür (de la Rúa and Lechón, 2016).

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 30'daki gibi ifade edilir (de la Rúa and Lechón, 2016):

$$a_{ij} = \frac{z_{ij}}{x_j} \quad (30)$$

Teknik katsayılar A matrisi olarak ifade edilebilir. Teknik katsayılar için Denklem (3.6) 'da  $z_{ij}$  yerine geçer ve toplam çıktı Denklem 31’deki gibi tanımlanır (de la Rúa and Lechón, 2016):

$$x = Ax + y \quad (31)$$

Denklem 3.7 yeniden düzenlenerek Denklem 32’deki gibi ifade elde edilir (de la Rúa and Lechón, 2016):

$$x = (I - A)^{-1}y \quad (32)$$

burada  $(I-A)^{-1}$ , 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 (de la Rúa and Lechón, 2016).

#### 2.3.4. Malzeme Ayak İzi

EXIOBASE küresel, detaylı Çok Bölgeli Çevresel Genişletilmiş Tedarik Kullanım Tablosu (MR-SUT) ve Giriş-Çıkış 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.2’den tabloları alındıktan sonra, malzemelerin kg 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.

#### 2.4. Elektrik Gelişim Planları 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.

#### **2.4.1. Küresel İklim Aksiyonu**

Küresel İklim Aksiyonu (GCA) planında küresel iklim çabalarını ele almaktadır. CO<sub>2</sub> 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 etkidir. 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 odaklanması nedeniyle şeyl gazına yatırım yapılması beklenmemektedir (ENTSO-E, n.d.).

#### **2.4.2. 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 şekli 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 başarılabılır (ENTSO-E, n.d.).

#### **2.4.3. 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 (ENTSO-E, n.d.).

#### **2.4.4. 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 (ENTSO-E, n.d.).

### 3. 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 5’teki gibidir,

**Tablo 5:** 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 5’teki 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 6’daki gibidir,

**Tablo 6:** 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 6 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 7’deki gibidir,


**Tablo 7:** 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 7 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.


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 26-28’deki gibidir.



Şekil 26: Farklı Enerji Kaynaklarına Göre Türkiye Elektrik Üretimi




Şekil 27: Farklı Enerji Kaynaklarına Göre Almanya Elektrik Üretimi




**Şekil 28:** Farklı Enerji Kaynaklarına Göre İspanya Elektrik Üretimi

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


Ülkeler için 2030 ve 2040 yıllarına ait BAU, ST, DG, EU ve GCA senaryolarına farklı kaynaklara göre elektrik üretim değerleri Şekil 29-34’teki gibidir.




**Şekil 29:** 2030 Türkiye’nin Senaryolara Göre Elektrik Üretim Değerleri




**Şekil 30:** 2030 Almanya’nın Senaryolara Göre Elektrik Üretim Değerleri




Şekil 31: 2030 İspanya’nın Senaryolara Göre Elektrik Üretim Değerleri



Şekil 32: 2040 Türkiye’nin Senaryolara Göre Elektrik Üretim Değerleri



**Şekil 33:** 2040 Almanya’nın Senaryolara Göre Elektrik Üretim Değerleri




**Şekil 34:** 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 önemliken, 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 35-42’deki gibidir.




Şekil 35: 2030 Türkiye Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı




**Şekil 36:** 2030 Türkiye Elektrik Üretiminde Metalik Malzeme Kullanımı




**Şekil 37:** 2030 Türkiye Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı




Şekil 38: 2030 Türkiye Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı




Şekil 39: 2030 Türkiye Elektrik Üretiminde Plastik Kullanımı



**Şekil 00:** 2030 Türkiye Elektrik Üretiminde Sıvı Gaz Kullanımı



**Şekil 41:** 2030 Türkiye Elektrik Üretiminde Ormancılık Ürünleri Kullanımı




**Şekil 02:** 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 43-50’deki gibidir.




**Şekil 03:** 2030 Almanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı




**Şekil 04:** 2030 Almanya Elektrik Üretiminde Metalik Malzeme Kullanımı




Şekil 05: 2030 Almanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı




Şekil 06: 2030 Almanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı




**Şekil 07:** 2030 Almanya Elektrik Üretiminde Plastik Kullanımı



**Şekil 08:** 2030 Almanya Elektrik Üretiminde Sıvı Gaz Kullanımı



**Şekil 09:** 2030 Almanya Elektrik Üretiminde Ormanlık Ürünleri Kullanımı




**Şekil 50:** 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 kullanımının 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 51-58’deki gibidir.




**Şekil 51:** 2030 İspanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı




Şekil 52: 2030 İspanya Elektrik Üretiminde Metalik Malzeme Kullanımı




Şekil 53: 2030 İspanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı




**Şekil 54:** 2030 İspanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı




**Şekil 55:** 2030 İspanya Elektrik Üretiminde Plastik Kullanımı



Şekil 56: 2030 İspanya Elektrik Üretiminde Sıvı Gaz Kullanımı



Şekil 57: 2030 İspanya Elektrik Üretiminde Ormancılık Ürünleri Kullanımı




**Şekil 58:** 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 59-66’daki gibidir.




Şekil 59: 2040 Türkiye Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı




Şekil 60: 2040 Türkiye Elektrik Üretiminde Metalik Malzeme Kullanımı




**Şekil 61:** 2040 Türkiye Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı




**Şekil 62:** 2040 Türkiye Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı




Şekil 63: 2040 Türkiye Elektrik Üretiminde Plastik Kullanımı



Şekil 64: 2040 Türkiye Elektrik Üretiminde Sıvı Gaz Kullanımı



**Şekil 65:** 2040 Türkiye Elektrik Üretiminde Ormancılık Ürünleri Kullanımı




**Şekil 66:** 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 67-74’deki gibidir.




**Şekil 67:** 2040 Almanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı




**Şekil 68:** 2040 Almanya Elektrik Üretiminde Metalik Malzeme Kullanımı




**Şekil 69:** 2040 Almanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı




Şekil 70: 2040 Almanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı




Şekil 71: 2040 Almanya Elektrik Üretiminde Plastik Kullanımı



**Şekil 72:** 2040 Almanya Elektrik Üretiminde Sıvı Gaz Kullanımı




**Şekil 73:** 2040 Almanya Elektrik Üretiminde Ormancılık Ürünleri Kullanımı




**Şekil 74:** 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 75-82’deki gibidir.




**Şekil 75:** 2040 İspanya Elektrik Üretiminde Kömür, Linyit ve Turba Kullanımı




**Şekil 76:** 2040 İspanya Elektrik Üretiminde Metalik Malzeme Kullanımı




Şekil 77: 2040 İspanya Elektrik Üretiminde Metalik Olmayan Malzeme Kullanımı




Şekil 78: 2040 İspanya Elektrik Üretiminde Kağıt ve Kağıt Ürünleri Kullanımı




**Şekil 79:** 2040 İspanya Elektrik Üretiminde Plastik Kullanımı



**Şekil 80:** 2040 İspanya Elektrik Üretiminde Sıvı Gaz Kullanımı



Şekil 81: 2040 İspanya Elektrik Üretiminde Ormançılık Ürünleri Kullanımı



Şekil 82: 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.

#### 4. 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’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 kullanımı tasarrufu sağlandığı tespit edilmiştir. Almanya için ise bu tasarrufun %10 ve %14 olduğu tespit edilmiştir. Her iki ülke için de ST senaryosu ile kömür kullanımının %84 azalacağı hesaplanmıştır.

Literatürde, malzeme ayak izi kavramı oldukça kısıtlı geçmesinden dolayı bu çalışma oldukça 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

- Akay, D. and Atak, M. (2007) ‘Grey prediction with rolling mechanism for electricity demand forecasting of Turkey’, *Energy*. Elsevier, 32(9), pp. 1670–1675.
- Al-Musaylh, M. S. vd. (2018) ‘Short-term electricity demand forecasting with MARS, SVR and ARIMA models using aggregated demand data in Queensland, Australia’, *Advanced Engineering Informatics*. Elsevier, 35, pp. 1–16.
- Albawi, S., Mohammed, T. A. and Al-Zawi, S. (2017) ‘Understanding of a convolutional neural network’, in *2017 International Conference on Engineering and Technology (ICET)*. IEEE, pp. 1–6.
- Albayrak, A. S. (2010) ‘ARIMA forecasting of primary energy production and consumption in Turkey: 1923-2006’, *Enerji, piyasa ve düzenleme*, 1(1), pp. 24–50.
- Alom, M. Z. vd. (2018) ‘The history began from alexnet: A comprehensive survey on deep learning approaches’, *arXiv preprint arXiv:1803.01164*.
- Altınay, G. and Karagol, E. (2005) ‘Electricity consumption and economic growth: evidence from Turkey’, *Energy economics*. Elsevier, 27(6), pp. 849–856.
- Alzahrani, A. vd. (2017) ‘Solar irradiance forecasting using deep neural networks’, *Procedia computer science*. Elsevier, 114, pp. 304–313.
- Amini, M. H., Kargarian, A. and Karabasoglu, O. (2016) ‘ARIMA-based decoupled time series forecasting of electric vehicle charging demand for stochastic power system operation’, *Electric Power Systems Research*. Elsevier, 140, pp. 378–390.
- Aydın, L. (2018) ‘Effects of increasing indigenous coal share in Turkey’s electricity generation mix on key economic and environmental indicators: An extended input–output analysis’, *Energy Exploration & Exploitation*. SAGE Publications Sage UK: London, England, 36(2), pp. 230–245.
- Barak, S. and Sadegh, S. S. (2016) ‘Forecasting energy consumption using ensemble ARIMA–ANFIS hybrid algorithm’, *International Journal of Electrical Power & Energy Systems*. Elsevier, 82, pp. 92–104.

- BAYRAMOĞLU, A. T. A. Y. and ÖZTÜRK, Z. (2017) ‘ARIMA ve Gri Sistem Modelleri ile Enflasyon Tahmini’, *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 6(2), pp. 760–776.
- Bedi, J. and Toshniwal, D. (2019) ‘Deep learning framework to forecast electricity demand’, *Applied Energy*. Elsevier, 238, pp. 1312–1326.
- Bianco, V., Manca, O. and Nardini, S. (2009) ‘Electricity consumption forecasting in Italy using linear regression models’, *Energy*. Elsevier, 34(9), pp. 1413–1421.
- Box, G. E. P. and Jenkins, G. M. (1970) ‘Time Series Analysis Forecasting and Control/’Holden Day, San Francisco, California’.
- Cadenas, E. vd. (2016) ‘Wind speed prediction using a univariate ARIMA model and a multivariate NARX model’, *Energies*. Multidisciplinary Digital Publishing Institute, 9(2), p. 109.
- Cadenas, E. and Rivera, W. (2010) ‘Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA–ANN model’, *Renewable Energy*. Elsevier, 35(12), pp. 2732–2738.
- Catalão, J. P. da S. vd. (2007) ‘Short-term electricity prices forecasting in a competitive market: A neural network approach’, *electric power systems research*. Elsevier, 77(10), pp. 1297–1304.
- Chen, J.-F., Lo, S.-K. and Do, Q. (2017) ‘Forecasting monthly electricity demands: an application of neural networks trained by heuristic algorithms’, *Information*. Multidisciplinary Digital Publishing Institute, 8(1), p. 31.
- Chen, Y. vd. (2017) ‘Short-term electrical load forecasting using the Support Vector Regression (SVR) model to calculate the demand response baseline for office buildings’, *Applied Energy*. Elsevier, 195, pp. 659–670.
- Clement, E. P. (2014) ‘Using normalized bayesian information criterion (BIC) to improve box-jenkins model building’, *American Journal of Mathematics and Statistics*, 4(5), pp. 214–221.
- Dedinec, Aleksandra vd. (2016) ‘Deep belief network based electricity load forecasting: An analysis of Macedonian case’, *Energy*. Elsevier, 115, pp. 1688–1700.
- DOĞAN, F. and TÜRKOĞLU, İ. (2018) ‘Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması’, *Sakarya*

- University Journal of Computer and Information Sciences*, 1(1), pp. 10–21.
- Ebiefung, A. A. and Kostreva, M. M. (1993) ‘The generalized Leontief input-output model and its application to the choice of new technology’, *Annals of Operations Research*. Springer, 44(2), pp. 161–172.
- Ediger, V. Ş. and Akar, S. (2007) ‘ARIMA forecasting of primary energy demand by fuel in Turkey’, *Energy policy*. Elsevier, 35(3), pp. 1701–1708.
- ENTSO-E. (n.d.). TYNDP [Web sayfası]. <https://tyndp.entsoe.eu/>
- Ertugrul, Ö. F. (2016) ‘Forecasting electricity load by a novel recurrent extreme learning machines approach’, *International Journal of Electrical Power & Energy Systems*. Elsevier, 78, pp. 429–435.
- de España, R. E. (2014) ‘The Spanish electricity system preliminary report’, *Red Eléctrica de España: Madrid, Spain*.
- ‘European energy market reform Country profile: Germany - Deloitte.’ (no date).
- Fahlman, S. E., Hinton, G. E. and Sejnowski, T. J. (1983) ‘Massively parallel architectures for AI: NETL, Thistle, and Boltzmann machines’, in *National Conference on Artificial Intelligence, AAAI*.
- Fischer, T. and Krauss, C. (2018) ‘Deep learning with long short-term memory networks for financial market predictions’, *European Journal of Operational Research*. Elsevier, 270(2), pp. 654–669.
- Fraunhofer ISE. (2018). *Germany – annual energy production*. Energy-Charts.
- Gers, F. A., Schmidhuber, J. and Cummins, F. (1999) ‘Learning to forget: Continual prediction with LSTM’. IET.
- Giljum, S., Bruckner, M. and Martinez, A. (2015) ‘Material footprint assessment in a global input-output framework’, *Journal of Industrial Ecology*. Wiley Online Library, 19(5), pp. 792–804.
- Goodfellow, I. vd. (2016) *Deep learning*. MIT press Cambridge.
- Graves, A., Mohamed, A. and Hinton, G. (2013) ‘Speech recognition with deep recurrent neural networks’, in *Acoustics, speech and signal processing (icassp), 2013 ieee international conference on*. IEEE, pp. 6645–6649.
- Graves, A. and Schmidhuber, J. (2005) ‘Framewise phoneme classification with bidirectional LSTM and other neural network architectures’, *Neural networks*. Elsevier, 18(5–6), pp. 602–610.

- Gulordava, K. vd. (2018) ‘Colorless green recurrent networks dream hierarchically’, *arXiv preprint arXiv:1803.11138*.
- Guo, Y. vd. (2016) ‘Deep learning for visual understanding: A review’, *Neurocomputing*. Elsevier, 187, pp. 27–48.
- Gurgul, H. and Lach, Ł. (2012) ‘The electricity consumption versus economic growth of the Polish economy’, *Energy Economics*. Elsevier, 34(2), pp. 500–510.
- Hamzaçebi, C. (2007) ‘Forecasting of Turkey’s net electricity energy consumption on sectoral bases’, *Energy policy*. Elsevier, 35(3), pp. 2009–2016.
- Hamzaçebi, C. and Es, H. A. (2014) ‘Forecasting the annual electricity consumption of Turkey using an optimized grey model’, *Energy*. Elsevier, 70, pp. 165–171.
- Hamzaçebi, C. and Kutay, F. (2004) ‘Yapay sinir ağları ile Türkiye elektrik enerjisi tüketiminin 2010 yılına kadar tahmini’, *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 19(3).
- Hinton, G. vd. (2012) ‘Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups’, *IEEE Signal processing magazine*. IEEE, 29(6), pp. 82–97.
- Hinton, G. E. and Salakhutdinov, R. R. (2006) ‘Reducing the dimensionality of data with neural networks’, *science*. American Association for the Advancement of Science, 313(5786), pp. 504–507.
- Hochreiter, S. and Schmidhuber, J. (1997) ‘Long short-term memory’, *Neural computation*. MIT Press, 9(8), pp. 1735–1780.
- Huang, C.-J. and Kuo, P.-H. (2018) ‘A deep cnn-lstm model for particulate matter (PM<sub>2.5</sub>) forecasting in smart cities’, *Sensors*. Multidisciplinary Digital Publishing Institute, 18(7), p. 2220.
- Hwangbo, S. vd. (2019) ‘Hydrogen-based self-sustaining integrated renewable electricity network (HySIREN) using a supply-demand forecasting model and deep-learning algorithms’, *Energy Conversion and Management*. Elsevier, 185, pp. 353–367.
- IEA Reports. (2018) ‘<https://www.iea.org/statistics/electricity/>’
- ‘<https://www.teias.gov.tr/>.’
- Jiang, S. vd. (2017) ‘Modified genetic algorithm-based feature selection combined with pre-trained deep neural network for demand forecasting


- in outpatient department’, *Expert Systems with Applications*. Elsevier, 82, pp. 216–230.
- Jiang, S. vd. (2018) ‘ARIMA forecasting of China’s coal consumption, price and investment by 2030’, *Energy Sources, Part B: Economics, Planning, and Policy*. Taylor & Francis, 13(3), pp. 190–195.
- Ju, F.-Y. and Hong, W.-C. (2013) ‘Application of seasonal SVR with chaotic gravitational search algorithm in electricity forecasting’, *Applied Mathematical Modelling*. Elsevier, 37(23), pp. 9643–9651.
- Kavaklioglu, K. (2011) ‘Modeling and prediction of Turkey’s electricity consumption using Support Vector Regression’, *Applied Energy*. Elsevier, 88(1), pp. 368–375.
- Ke, J. vd. (2017) ‘Short-term forecasting of passenger demand under on-demand ride services: A spatio-temporal deep learning approach’, *Transportation Research Part C: Emerging Technologies*. Elsevier, 85, pp. 591–608.
- Kelleher, J. D. (2019) *Deep Learning*. MIT Press (MIT Press essential knowledge series). Available at: [https://books.google.com.tr/books?id=p\\_fTxQEACAAJ](https://books.google.com.tr/books?id=p_fTxQEACAAJ).
- Kim, H. Y. and Won, C. H. (2018) ‘Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models’, *Expert Systems with Applications*. Elsevier, 103, pp. 25–37.
- KIZRAK, M. A. and BOLAT, B. (2018) ‘Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma’, *Bilişim Teknolojileri Dergisi*, 11(3), pp. 263–286.
- Kucukali, S. and Baris, K. (2010) ‘Turkey’s short-term gross annual electricity demand forecast by fuzzy logic approach’, *Energy policy*. Elsevier, 38(5), pp. 2438–2445.
- Kucukvar, M., Onat, N. C. and Haider, M. A. (2018) ‘Material dependence of national energy development plans: The case for Turkey and United Kingdom’, *Journal of Cleaner Production*. Elsevier, 200, pp. 490–500.
- Kumar, M. and Anand, M. (2014) ‘An application of time series ARIMA forecasting model for predicting sugarcane production in India’, *Studies in Business and Economics*. Lucian Blaga University of Sibiu, Faculty of Economic Sciences, 9(1), pp. 81–94.

- Kumar, U. and Jain, V. K. (2010) ‘ARIMA forecasting of ambient air pollutants (O<sub>3</sub>, NO, NO<sub>2</sub> and CO)’, *Stochastic Environmental Research and Risk Assessment*. Springer, 24(5), pp. 751–760.
- de la Rúa, C. and Lechón, Y. (2016) ‘An integrated Multi-Regional Input-Output (MRIO) Analysis of miscanthus biomass production in France: Socio-economic and climate change consequences’, *Biomass and Bioenergy*. Elsevier, 94, pp. 21–30.
- Lago, J., De Ridder, F. and De Schutter, B. (2018) ‘Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms’, *Applied Energy*. Elsevier, 221, pp. 386–405.
- Law, R. vd. (2019) ‘Tourism demand forecasting: A deep learning approach’, *Annals of Tourism Research*. Elsevier, 75, pp. 410–423.
- LeCun, Y. vd. (1989) ‘Backpropagation applied to handwritten zip code recognition’, *Neural computation*. MIT Press, 1(4), pp. 541–551.
- Leithon, J., Lim, T. J. and Sun, S. (2016) ‘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*. IEEE, pp. 1–6.
- Li, H.-Z. vd. (2013) ‘A hybrid annual power load forecasting model based on generalized regression neural network with fruit fly optimization algorithm’, *Knowledge-Based Systems*. Elsevier, 37, pp. 378–387.
- Lora, A. T. vd. (2007) ‘Electricity market price forecasting based on weighted nearest neighbors techniques’, *IEEE Transactions on Power Systems*. IEEE, 22(3), pp. 1294–1301.
- Ly, N. vd. (2018) ‘Deep learning and superpixel feature extraction based on contractive autoencoder for change detection in SAR images’, *IEEE transactions on industrial informatics*. IEEE, 14(12), pp. 5530–5538.
- Mesnil, G. vd. (2015) ‘Using recurrent neural networks for slot filling in spoken language understanding’, *IEEE/ACM Transactions on Audio, Speech, and Language Processing*. IEEE, 23(3), pp. 530–539.
- Mohamed, Z. and Bodger, P. (2005) ‘Forecasting electricity consumption in New Zealand using economic and demographic variables’, *Energy*. Elsevier, 30(10), pp. 1833–1843.

- Niu, D., Wang, Y. and Wu, D. D. (2010) ‘Power load forecasting using support vector machine and ant colony optimization’, *Expert Systems with Applications*. Elsevier, 37(3), pp. 2531–2539.
- O’Shea, K. and Nash, R. (2015) ‘An introduction to convolutional neural networks’, *arXiv preprint arXiv:1511.08458*.
- de Oliveira, E. M. and Oliveira, F. L. C. (2018) ‘Forecasting mid-long term electric energy consumption through bagging ARIMA and exponential smoothing methods’, *Energy*. Elsevier, 144, pp. 776–788.
- Pai, P.-F. and Hong, W.-C. (2005) ‘Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms’, *Electric Power Systems Research*. Elsevier, 74(3), pp. 417–425.
- Qin, M., Li, Z. and Du, Z. (2017) ‘Red tide time series forecasting by combining ARIMA and deep belief network’, *Knowledge-Based Systems*. Elsevier, 125, pp. 39–52.
- Qing, X. and Niu, Y. (2018) ‘Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM’, *Energy*. Elsevier, 148, pp. 461–468.
- Rahman, A., Srikumar, V. and Smith, A. D. (2018) ‘Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks’, *Applied energy*. Elsevier, 212, pp. 372–385.
- Şeker, A., Diri, B. and Balık, H. H. (no date) ‘Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme’, *Gazi Mühendislik Bilimleri Dergisi*, 3(3), pp. 47–64.
- Sevüktekin, M. and Çınar, M. (2014) ‘Ekonometrik Zaman Serileri Analizi, Dora Yayıncılık, 4’, *Baskı, Bursa*.
- Shinde, P. vd. (2019) ‘Smart Traffic Control System using YOLO’.
- Sozen, A., Arcaklioglu, E. and Ozkaymak, M. (2005) ‘Modelling of Turkey’s net energy consumption using artificial neural network’, *International Journal of Computer Applications in Technology*. Inderscience Publishers, 22(2–3), pp. 130–136.
- Suryanarayana, G. vd. (2018) ‘Thermal load forecasting in district heating networks using deep learning and advanced feature selection methods’, *Energy*. Elsevier, 157, pp. 141–149.
- Sze, V. vd. (2017) ‘Efficient processing of deep neural networks: A tutorial and survey’, *Proceedings of the IEEE*. Ieee, 105(12), pp. 2295–2329.

- Tai, Y., Yang, J. and Liu, X. (2017) ‘Image super-resolution via deep recursive residual network’, in *Proceedings of the IEEE Conference on Computer vision and Pattern Recognition*, pp. 3147–3155.
- Tang, P., Wang, H. and Kwong, S. (2017) ‘G-MS2F: GoogLeNet based multi-stage feature fusion of deep CNN for scene recognition’, *Neurocomputing*. Elsevier, 225, pp. 188–197.
- Taylor, J. W. (2010) ‘Triple seasonal methods for short-term electricity demand forecasting’, *European Journal of Operational Research*. Elsevier, 204(1), pp. 139–152.
- Toksarı, M. D. (2009) ‘Estimating the net electricity energy generation and demand using the ant colony optimization approach: case of Turkey’, *Energy Policy*. Elsevier, 37(3), pp. 1181–1187.
- Topcu, I. vd. (2019) ‘The evaluation of electricity generation resources: The case of Turkey’, *Energy*. Elsevier, 167, pp. 417–427.
- TÜRKOĞLU, M. vd. (no date) ‘Derin Evrimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması’, *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), pp. 334–345.
- Ünler, A. (2008) ‘Improvement of energy demand forecasts using swarm intelligence: The case of Turkey with projections to 2025’, *Energy policy*. Elsevier, 36(6), pp. 1937–1944.
- Vincent, P. (2011) ‘A connection between score matching and denoising autoencoders’, *Neural computation*. MIT Press, 23(7), pp. 1661–1674.
- Wang, K. vd. (2018) ‘Deep belief network based k-means cluster approach for short-term wind power forecasting’, *Energy*. Elsevier, 165, pp. 840–852.
- Wang, W. vd. (2015) ‘Improving forecasting accuracy of annual runoff time series using ARIMA based on EEMD decomposition’, *Water Resources Management*. Springer, 29(8), pp. 2655–2675.
- Wei, G. vd. (2019) ‘Development of a LeNet-5 Gas Identification CNN Structure for Electronic Noses’, *Sensors*. Multidisciplinary Digital Publishing Institute, 19(1), p. 217.
- Yaseen, A. F. and Saud, L. J. (2018) ‘A Survey on the Layers of Convolutional Neural Networks’.
- Yu, W. vd. (2016) ‘Visualizing and comparing AlexNet and VGG using deconvolutional layers’, in *Proceedings of the 33 rd International Conference on Machine Learning*.

- Yuan, C., Liu, S. and Fang, Z. (2016) ‘Comparison of China’s primary energy consumption forecasting by using ARIMA (the autoregressive integrated moving average) model and GM (1, 1) model’, *Energy*. Elsevier, 100, pp. 384–390.
- Zhang, C.-Y. vd. (2015) ‘Predictive deep Boltzmann machine for multiperiod wind speed forecasting’, *IEEE Transactions on Sustainable Energy*. IEEE, 6(4), pp. 1416–1425.
- Zhang, D. vd. (2018) ‘Manage Sewer In-Line Storage Control Using Hydraulic Model and Recurrent Neural Network’, *Water Resources Management*. Springer, 32(6), pp. 2079–2098.
- Zhang, Y. vd. (2016) ‘A multilayer perceptron based smart pathological brain detection system by fractional Fourier entropy’, *Journal of medical systems*. Springer, 40(7), p. 173.
- Zhao, Y., Li, J. and Yu, L. (2017) ‘A deep learning ensemble approach for crude oil price forecasting’, *Energy Economics*. Elsevier, 66, pp. 9–16.
- Zhao, Z. vd. (2017) ‘LSTM network: a deep learning approach for short-term traffic forecast’, *IET Intelligent Transport Systems*. IET, 11(2), pp. 68–75.
- Zheng, J., Fu, X. and Zhang, G. (2019) ‘Research on exchange rate forecasting based on deep belief network’, *Neural Computing and Applications*. Springer, 31(1), pp. 573–582.



**ISBN: 978-625-378-409-6**