



T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

SERA GAZI EMİSYONU
HESAPLAMALARINDA YAPAY ZEKA
UYGULAMALARI

Serkan ERTUĞRUL

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Temmuz-2023
BATMAN
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Serkan ERTUĞRUL tarafından hazırlanan “Sera Gazı Emisyonu Hesaplamalarında Yapay Zeka Uygulamaları” adlı tez çalışması 21/07/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Fevzi HANSU

.....

Danışman

Prof. Dr. Necmettin SEZGİN

.....

Üye

Dr. Öğr. Üyesi Abdulkerim ÖZTEKİN

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr.Osman Pakman
Lisansüstü Eğitim Enstitüsü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Serkan ERTUĞRUL

Tarih: 21/07/2023

ÖZET

YÜKSEK LİSANS TEZİ

SERA GAZI EMİSYONU HESAPLAMALARINDA YAPAY ZEKA UYGULAMALARI

Serkan ERTUĞRUL

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Necmettin SEZGİN

2023, 72 Sayfa

Jüri

Prof. Dr. Fevzi HANSU

Prof. Dr. Necmettin SEZGİN

Dr. Öğr. Üyesi Abdulkarim ÖZTEKİN

Küresel ısınmayı tetikleyen sera gazları, doğal etmenlerin yanı sıra insan kaynaklı faaliyetlerden de kaynaklanmaktadır. Fosil yakıtların kullanımıyla ortaya çıkan sera gazları emisyonu, küresel ısınmada önemli bir etkidir. Özellikle karbondioksit, küresel ısınma üzerinde en güçlü etkiye sahiptir; çünkü sıcaklığı emen bir gaz olarak, etkisi son derece büyük ölçüdedir. Küresel anlaşmalar, özellikle Paris Anlaşması gibi, insan faaliyetlerinin azaltılması ve net sıfır emisyon hedeflerinin benimsenmesi yönünde önemli adımlar atmıştır. Bu bağlamda, tüm ülkelerin sürdürülebilir ve gerçekçi programlar uygulayarak sera gazı emisyonlarını azaltma hedeflerine ulaşmaları beklenmektedir.

Finansal, ekonomik ve insani gelişmişlik göstergeleri, nüfus, ormansızlaştırma ve enerji tüketimi gibi verileri kullanarak, bazı ülkelerde gelecekteki sera gazı emisyon seviyelerini hesaplamak için makine öğrenimi yöntemleri kullanılmıştır. Bu çalışmada, sera gazı emisyonlarının azaltılması hedefine ulaşmak için MATLAB programı aracılığıyla uzun kısa dönem bellek (LSTM) ve hibrit CNN-RNN modeli gibi derin öğrenme yöntemleri kullanılarak karşılaştırmalar yapılmıştır. Ayrıca, zaman serisi verileri için NARX modellemesi ile elde edilen tahminlerle LSTM modellemesi sonuçları karşılaştırılarak gelecekteki sera gazı emisyonları tahmin edilmiştir. Bu çalışma ayrıca, ülkelerin sera gazı emisyon azaltma hedeflerine ulaşmaları için farklı verileri göz önünde bulundurarak sürdürülebilir programlar geliştirmelerine kolaylık sağlaması beklenmektedir.

Anahtar Kelimeler: Derin Öğrenme; LSTM; NARX; Regresyon; Sera Gazı; YSA

ABSTRACT

MS THESIS

ARTIFICIAL INTELLIGENCE APPLICATIONS IN GREENHOUSE GAS EMISSION CALCULATIONS

Serkan ERTUGRUL

**THE INSTITUTE OF GRADUATE STUDIES OF BATMAN UNIVERSITY
IN ELECTRICAL AND ELECTRONICS ENGINEERING**

Advisor: Prof. Dr. Necmettin SEZGİN

2023, 72 Pages

Jury

Prof. Dr. Fevzi HANSU

Prof. Dr. Necmettin SEZGİN

Assist. Prof. Dr. Abdulkерim ÖZTEKİN

Greenhouse gases that trigger global warming stem from both natural factors and human activities. The emission of greenhouse gases resulting from the use of fossil fuels constitutes a paramount factor in global warming. Particularly, carbon dioxide exerts the most potent impact on global warming, as it acts as a heat-absorbing gas, with its effect being considerably significant. Global agreements, notably the Paris Agreement, have taken significant steps towards reducing human activities and embracing net zero emission targets. Consequently, it is anticipated that all countries will strive to achieve their greenhouse gas emission reduction goals by implementing sustainable and pragmatic programs.

Machine learning methods have been employed in this study, utilizing financial, economic, and human development indicators, population data, deforestation rate and energy consumption data to calculate future greenhouse gas emission levels in certain countries. In this study, comparisons have been made using deep learning techniques, such as Long Short-Term Memory (LSTM) and hybrid CNN-RNN models, through the MATLAB program to achieve the objective of reducing greenhouse gas emissions. Additionally, future greenhouse gas emission predictions were made by comparing LSTM modeling results with those obtained through NARX modeling for time-series data. This study is also expected to facilitate the development of sustainable programs by considering different data for countries to achieve their greenhouse gas emission reduction targets.

Keywords: ANN; Deep Learning; Greenhouse Gas; LSTM; NARX; Regression

ÖNSÖZ

Yüksek Lisans Tez çalışmam süresince, beni destekleyen, yakından ilgilenen, yol gösteren ve desteğini esirgemeyen kıymetli danışman Hocam Sayın Prof. Dr. Necmettin SEZGİN ve desteklerinden dolayı Batman Üniversitesi Elektrik-Elektronik Mühendisliği bölümündeki değerli hocalarıma sonsuz teşekkürlerimi sunuyorum.

Serkan ERTUĞRUL
BATMAN - 2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER.....	vii
ŞEKİLLER LİSTESİ	ix
ÇİZELGELER LİSTESİ	xii
SİMGELER VE KISALTMALAR.....	xiv
1. GİRİŞ.....	1
1.1. Atmosfer	1
1.2. Sera Gazları ve Sera Etkisi	2
1.3. Küresel Isınma ile Mücadelede Uluslararası Çabalar	4
1.4. Ülkelerin Sera Gazı Emisyon Durumları	6
1.5. Türkiye’de Sera Gazı Emisyonları	7
1.6. Sürdürülebilir Kalkınma Hedefleri	8
2. KAYNAK ARAŞTIRMASI	10
3. YAPAY ZEKA BİLEŞENLERİ.....	15
3.1. Veri Toplama	15
3.1.1. Sera Gazı Emisyon Verileri	15
3.1.2. Nüfus Verileri	16
3.1.3. İnsani Gelişme Endeksi Verileri	16
3.1.4. Finansal Veriler.....	17
3.1.5. Ekonomik Veriler	17
3.1.6. Birincil ve Yenilenebilir Enerji Arz Verileri	18
3.1.7. Ağaçlandırma Verileri	19
3.2. Yöntem.....	20
3.2.1. Ülke Seçimi ve Uygulanan Metotlar	20
3.2.2. Verilerin Düzenlenmesi	22
3.2.3. LSTM ile Derin Öğrenme (Deep Learning)	27
3.2.4. CNN-RNN ile Derin Öğrenme (Deep Learning).....	30
3.2.5. Yapay Sinir Ağları	31
4. BULGULAR VE TARTIŞMA.....	35
4.1. LSTM ile Gelecek Tahminlemeleri	35
4.2. CNN-RNN ve LSTM Sera Gazı Emisyonu Gelecek Tahminlemelerinin Karşılaştırılması	42
4.3. YSA Sonuçları	46

4.4. YSA ve LSTM Sera Gazı Emisyonu Tahminlemelerinin Karşılaştırılması	56
5. SONUÇLAR VE ÖNERİLER	65
5.1 Sonuçlar	65
5.2 Öneriler	66
KAYNAKLAR	68
ÖZGEÇMİŞ	72

ŞEKİLLER LİSTESİ

Şekil 1.1: Mauna Loa Gözlemevi'nde ölçülen atmosferdeki aylık ortalama CO ₂ konsantrasyonu (1958-2022 yılları arasında kuru havadaki CO ₂ fraksiyonu (µmol/mol)	Error! Bookmark not defined.
Şekil 1.2: Ülkelerin Sera Gazı Emisyon Durumları	6
Şekil 1.3: 1750-2010 arası ülkelerin CO ₂ fosil yakıtları ve çimento üretimi ile ilgili emisyon miktarları.....	7
Şekil 2.1: Türkiye'nin sera gazı emisyon senaryosu	11
Şekil 3.1: LSTM ile derin öğrenme aşamaları.....	29
Şekil 3.2: NARX (Nonlinear AutoRegressive with eXternal (eXogenous) Input) model yapısı (x(t) giriş dizileri, d y(t)'nin geçmiş değerleri, y(t) tahmin dizileri).....	32
Şekil 3.3: Matlab uygulamasından alınan örnek bir sinir ağı modeli	34
Şekil 4.1: Almanya için aylık olarak Mton CO ₂ e cinsinden "Sera Gazı Emisyon" grafiği.....	36
Şekil 4.2: Almanya için "Derin Öğrenme" LSTM algortiması ile elde edilen eğitim sonucu	36
Şekil 4.3: Almanya için yıllık "Sera Gazı Emisyon"un "Derin Öğrenme"de eğitim sonrası için yapılan tahmini değerlerin grafiksel gösterimi	37
Şekil 4.4: Almanya yıllık "Sera Gazı Emisyon"un "Derin Öğrenme"de eğitim sonrası gelecek için yapılan tahmini değerler için hata değerleri	37
Şekil 4.5: ABD için CNN-RNN modellerinin Hibrit bir şekilde kullanılması ile ortaya çıkan Regresyon değeri.....	43
Şekil 4.6: ABD için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları.....	44
Şekil 4.7: Almanya için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları.....	44
Şekil 4.8: İngiltere için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları.....	45
Şekil 4.9: Avusturya için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları.....	45
Şekil 4.10: Fransa için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları.....	46
Şekil 4.11: Türkiye için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları.....	46

Şekil 4.12: ABD için, NARX ağ modelinin genel görünümü (Gizli katmandaki nöron sayısı ve geçikme katsayısı ile beraber)	47
Şekil 4.13: Almanya ve İngiltere için, NARX ağ modelinin genel görünümü (Gizli katmandaki nöron sayısı ve geçikme katsayısı ile beraber).....	48
Şekil 4.14: ABD için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler	50
Şekil 4.15: Almanya için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler	50
Şekil 4.16: İngiltere için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler	51
Şekil 4.17: Avustralya için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler	51
Şekil 4.18: Fransa için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler	52
Şekil 4.19: Türkiye için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler	52
Şekil 4.20: ABD için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri	53
Şekil 4.21: Almanya için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri	53
Şekil 4.22: İngiltere için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri	54
Şekil 4.23: Avustralya için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri	54
Şekil 4.24: Fransa için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri	55
Şekil 4.25: Türkiye için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri	55
Şekil 4.26: ABD için 2010 yılına ait aylarlar göre hem gerçek hem de YSA - NARX model sonrası elde edilen tahmini sera gazı emisyon verileri karşılaştırılması	57
Şekil 4.27: Almanya için 2010 yılına ait aylarlar göre hem gerçek hem de YSA - NARX model sonrası elde edilen “Mton CO ₂ e” cinsinden tahmini sera gazı emisyon verileri karşılaştırılması	58
Şekil 4.28: İngiltere için 2010 yılına ait aylarlar göre hem gerçek hem de YSA - NARX model elde edilen “Mton CO ₂ e” cinsinden tahmini sera gazı emisyon verileri karşılaştırılması	58
Şekil 4.29: Avustralya için 2010 yılına ait aylarlar göre hem gerçek hem de YSA - NARX model sonrası elde edilen “Mton CO ₂ e” cinsinden tahmini sera gazı emisyon verileri karşılaştırılması	59
Şekil 4.30: Fransa için 2010 yılına ait aylarlar göre hem gerçek hem de YSA - NARX model sonrası elde edilen “Mton CO ₂ e” cinsinden tahmini sera gazı emisyon verileri karşılaştırılması	59
Şekil 4.31: Türkiye için 2010 yılına ait aylarlar göre hem gerçek hem de YSA - NARX model sonrası elde edilen “Mton CO ₂ e” cinsinden tahmini sera gazı emisyon verileri karşılaştırılması	60
Şekil 4.32: ABD’nin 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen tahmini verileri (mavi çizgiler) ile YSA için “ntstool” ile kullanılarak elde edilen ait tahmini verilerin (kırmızı çizgi) karşılaştırılması	60
Şekil 4.33: Almanya’nın 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen “Mton CO ₂ e” cinsinden tahmini verileri (mavi çizgiler) ile YSA için “ntstool” ile kullanılarak elde edilen ait tahmini verilerin (kırmızı çizgi) karşılaştırılması	61

Şekil 4.34: İngiltere'nin 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen "Mton CO ₂ e" cinsinden tahmini verileri (mavi çizgiler) ile YSA için "ntstool" ile kullanılarak elde edilen ait tahmini verilerin (kırmızı çizgi) karşılaştırılması	61
Şekil 4.35: Avustralya'nın 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen "Mton CO ₂ e" cinsinden tahmini verileri (mavi çizgiler) ile YSA için "ntstool" ile kullanılarak elde edilen ait tahmini verilerin (kırmızı çizgi) karşılaştırılması	62
Şekil 4.36: Fransa'nın 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen "Mton CO ₂ e" cinsinden tahmini verileri (mavi çizgiler) ile YSA için "ntstool" ile kullanılarak elde edilen ait tahmini verilerin (kırmızı çizgi) karşılaştırılması	62
Şekil 4.37: Türkiye'nin 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen "Mton CO ₂ e" cinsinden tahmini verileri (mavi çizgiler) ile YSA için "ntstool" ile kullanılarak elde edilen ait tahmini verilerin (kırmızı çizgi) karşılaştırılması	63
Şekil 4.38: ABD, Almanya, İngiltere, Avustralya, Fransa ve Türkiye için hesaplanan "Mton CO ₂ e" cinsinden Sera Gazı Emisyon gerçek değerler ile tahminleme değerleri	64

ÇİZELGELER LİSTESİ

Çizelge 3.1: Bazı ülkelerin 1970 ile 1974 yılları için Mton CO ₂ eşd. cinsinden sera gazı emisyon miktarları.....	15
Çizelge 3.2: Trilyon BTU cinsinden Yenilenebilir Enerji Tüketimi cinsinden miktarları “U.S. Energy Information Administration” (EIA).....	16
Çizelge 3.3: Avustralya için kişi başı dolar cinsinden yıllık Gayri Safi Milli Hasıla toplam değeri	18
Çizelge 3.4: Avustralya'nın (AUT) yıllık olarak milyon ton petrol eşdeğeri (MLN_TOE) cinsinden kullanılan birincil enerji kaynaklarının toplam yıllık miktarları	19
Çizelge 3.5: Trilyon BTU cinsinden Birincil Enerji Tüketimi miktarları	19
Çizelge 3.6: Amerika Birleşik Devletleri için sera gazı emisyon tahminlemede kullanılan veriler	23
Çizelge 3.7: Almanya için sera gazı emisyon tahminlemede kullanılan veriler	23
Çizelge 3.8: Birleşik Krallık için sera gazı emisyon tahminlemede kullanılan veriler	24
Çizelge 3.9: Avustralya için sera gazı emisyon tahminlemede kullanılan veriler	25
Çizelge 3.10: Fransa için sera gazı emisyon tahminlemede kullanılan veriler	26
Çizelge 3.11: Türkiye için sera gazı emisyon tahminlemede kullanılan veriler	26
Çizelge 3.12: Amerika Birleşik Devletleri (USA), Almanya (DEU), Birleşik Krallık (GBR), Avustralya (AUS), Fransa (FRA) ve Türkiye (TUR) için sera gazı emisyon tahminlemede “+” ile işaretlenen veriler kullanıldı	31
Çizelge 4.1: ABD için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte.....	38
Çizelge 4.2: Almanya için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte.	38
Çizelge 4.3: İngiltere için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte	39
Çizelge 4.4: Avustralya için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte	40
Çizelge 4.5: Fransa için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte.....	40
Çizelge 4.6: Türkiye için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte	41
Çizelge 4.7: “Mton CO ₂ e” cinsinden 2019 yılı ilk 8 ay gerçek ve 2026 yılı ilk 8 ay tahmini Sera Gazı Emisyon değerleri	42
Çizelge 4.7: ABD, Almanya, İngiltere, Avusturya, Fransa ve Türkiye için Sera Gazı Emisyon verileri ile Derin Öğrenme’de CNN-RNN hibrit algoritması ile yapılan modelleme sonucunda elde edilen R değerleri.....	43
Çizelge 4.8: ABD için YSA “ntstool” aracı ile kullanılan NARX Bayesian modeli ile yapılan eğitim ve test için elde edilen R değerleri.....	48
Çizelge 4.9: Almanya için YSA “ntstool” aracı ile kullanılan NARX Bayesian modeli ile yapılan eğitim ve test için elde edilen R değerleri.....	49
Çizelge 4.10: İngiltere için YSA “ntstool” aracı ile kullanılan NARX Bayesian modeli ile yapılan eğitim ve test için elde edilen R değerleri.....	49

Çizelge 4.11: ABD, Almanya, İngiltere, Avustralya, Fransa ve Türkiye için tüm verilerle hesaplanan Sera Gazı Emisyon veri tahminlemesi sonucu hem eğitim hem de test için elde edilen R değerleri.....	56
Çizelge 4.12: Almanya için kullanılan verilerin Derin Öğrenme’de LSTM algoritması ile yapılan modelleme sonucunda elde edilen gelecek tahminlerinin bir kısmı.....	56
Çizelge 4.13: ABD, Almanya, İngiltere, Avustralya, Fransa ve Türkiye için hesaplanan “Mton CO ₂ e” cinsinden Sera Gazı Emisyon tahminlemeleri	63

SİMGELER VE KISALTMALAR

Simgeler

CH ₄	: Metan
CO ₂	: Karbondioksit
CO ₂ eşd.	: Karbondioksit Eşdeğeri
CO ₂ eşd./kişi	: Kişi Başına Düşen Karbondioksit Miktarı
CO ₂ e	: Karbondioksit Equivalent (Karbondioksit Eşdeğeri)
EDGAR	: EDGAR - Emissions Database for Global Atmospheric Research (Küresel Atmosfer Araştırmaları için Emisyon Veritabanı)
EIA	: The U.S. Energy Information Administration (Amerika Birleşik Devleti (ABD) Enerji Bilgi İdaresi)
HFC	: Hidroflorokarbonlar
kha	: küresel hektar
km ²	: kilometrekare
KTOE	: thousand tonnes of oil equivalent
MLN_TOE	: milyon ton yağ eşleniği
Mt	: Milyon Ton
Mton CO ₂ eq.	: Milyon ton Karbondioksit eşdeğeri (Mton CO ₂ eşd.)
NF ₃	: Nitrojen Triflorür
N ₂ O	: Nitrus Oksit
PFC	: Perflorokarbonlar
SF ₆	: Kükürt Hekzaflorür
Tep	: ton petrol eşdeğeri
%	: Yüzde

Kısaltmalar

A	: Annual (Yıllık)
AARD	: Mutlak Ortalama Bağlı Sapma (Absolute Average Relative Deviation)
AB	: Avrupa Birliği
ABC	: Artificial Bee Colony (Yapay Arı Kolonisi)

ABD	: Amerika Birleşik Devletleri
Adam	: Adaptive Moment Estimation
ANN	: Artificial Neural Networks (Yapay Sinir Ağları)
Ar-Ge	: Araştırma - Geliştirme
AUT	: Avustralya
BAU	: Business As Usual (Referans Senaryo)
BMİDÇS	: Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi
CNN	: Convolutional Neural Network (Evrişimli Sinir Ağları)
COP	: Conference of the Parties (Taraflar Konferansı)
EDGAR	: Emissions Database for Global Atmospheric Research (Küresel Atmosfer Araştırmaları için Emisyon Veritabanı)
EIA	: The U.S. Energy Information Administration (ABD Enerji Bilgi İdaresi)
ENN	: Elman Neural Network (Elman Sinir Ağı)
GDP	: Gross Demostic Product (Gayri Safi Yurtiçi Hasıla)
GHG	: Greenhouse Gas (Sera Gazı)
GISSTEMP	: Goddard Institute for Space Studies Surface Temperature Analysis
GMDH	: Group Method of Data Handling (Grup Veri İşleme Yöntemi)
GNI	: Gross National Income (Gayri Safi Milli Gelir)
GSYİH	: Gayri safi yurt içi hasıla
GWO	: Grey Wold Optimisation (Gri Kurt Optimizasyonu)
GWP	: Global Warming Potential (Küresel ısınma potansiyeli)
HDI	: Human Development Index (İnsani Gelişme Endeksi (İGE))
HFC	: Hidroflorokarbon sınıfı gazları
IJ	: Joint Implementation
IMF	: International Monetary Fund (Uluslararası Para Fonu)
IPCC	: Hükümetler Arası İklim Değişikliği Paneli (Intergovernmental Panel on Climate Change)
İGE	: İnsani Gelişme Endeksi
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)
MEI	: Main Economic Indicators (Temel Ekonomik Göstergeler)
MLO	: Mauna Loa Gözlemevi
MLP	: Mulit-Layer Perceptron (Çok Katmanlı Perceptron)

MSE	: Mean Squared Error (Hata Kareleri Toplamı)
NARX	: Nonlinear AutoRegressive with eXternal input (Doğrusal Olmayan Otoregresif Dışsal Girdiler)
NDC	: Ulusal Katkı Beyanları (Nationally Determined Contribution)
NNI	: Net National Income (Net Milli Gelir)
OECD	: Organisation for Economic Co-operation and Development (Ekonomik İşbirliği ve Kalkınma Örgütü)
ResNet	: Residual Neural Netwok (Artık Sinir Ağı)
RMSE	: Hata karelerinin karekötün toplamı (root mean squared error)
RMSProp	: Root Mean Square Prop
RNN	: Reccurent Neural Network (Tekrarlayan Sinir Ağı)
R2	: Korelasyon Katsayısı
SKH	: Sürdürülebilir Kalkınma Hedefleri
SVR	: Destek Vektör Makinası (Support Vector Machine)
TLBO	: Teachin-Learning Based Optimisation (Öğretme-Öğrenme Tabanlı Optimizasyon)
UNDP	: United Nations Expanded Programme (Birleşmiş Milletler Geliştirme Programı)
UNEP	: United Nations Environment Programme (Birleşmiş Milletler Çevre Programı)
UNFCCC	: Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi (United Nations Framework Convention on Climate Change)
USD_CAP	: United States Dollars / Capita
VİGY	: Veri İşleme Grup Yöntemi (Group Method of Data Handling (GMDH))
WMO	: Dünya Meteorolojik Organizasyonu (World Meteorological Organization)
YSA	: Yapay Sinir Ağları

1. GİRİŞ

1.1. Atmosfer

Dünya ile uzay boşluğu arasında atmosfer bulunmaktadır ve Türkiye Uzay Ajansı web sitesinden yazıldığı gibi altı katmandan oluşmaktadır (Ajansı, T.U., 2022). Yer yüzeyinden 14 kilometreye kadar çıkan alana troposfer denir. Troposferde değişken hava koşulları vardır. Troposferin üstünde bulunan katmana stratosfer denir. Kendi içinde farklı katmanlar bulunur ve bu katmanlarda hava değişimi yoktur. Stratosfer 35 kilometre kalınlığında olup bu katmanda ozon tabakası bulunmaktadır. Ozon tabakası güneşten gelen ultraviyole ışınların çoğunu emerek dünya yüzeyini aşırı ultraviyole ışınından korur. Aksi durumda yer yüzeyinde yaşam mümkün olmazdı. Atmosferin tersine stratosferin troposferden itibaren mezosfere doğru bulunan alt katmanlarda hava sıcaklığı artarak ilerler. Mezosfer katmanı 35 kilometre kalınlığındadır ve atmosfere göre oldukça ince bir hava olmasına rağmen, daha fazla gaz miktarına sahiptir. Mezosfer katmanından sonra termosfer katmanı gelir. Termosfer katmanı 513 kilometre kalınlığındadır ve içerisinde fazla gaz bulunmamaktadır. Ortam sıcaklığı 2000 dereceye kadar ulaşır. Ancak, içerisinde gaz olmadığından ısı transferi mümkün değildir. Termosfer katmanından sonra gelen iyonosfer katmanında, Güneş'ten gelen ısı nedeniyle elektrik yüklü iyonlar oluşur. Bu iyonlar manyetik alanlar tarafından etkilenecek büyür veya küçülür. Atmosferin en dış katmanı olan ekzosfer, 10.000 kilometre kalınlığındadır ve içerisinde hidrojen ve helyum gazları bulunur. Ancak, gazlar arasındaki boşluk oldukça fazladır.

Dünya atmosferinde çeşitli gazlar bulunmaktadır. Atmosferdeki gazların % 78.08'ini Nitrojen, % 20.95'ini Oksijen ve % 0,93'unuda Argon gazı oluşturmaktadır (Türkeş ve ark., 2000). Bu üç gaz doğada en fazla bulunan gazlardır. Bunlar haricinde, seyrek gazlar ile % 0.037 oranında karbondioksit bulunmaktadır. Bu seyrek gazlar içerisinde su buharı, metan ve ozon gibi gazlar bulunmaktadır. Karbondioksit ve seyrek gazlar, atmosferde sera gazları olarak adlandırılırlar. Sera gazların en önemli özelliği kızılötesi radyasyonun emme ve yayma kabiliyetine sahip olmalarıdır. Bu gazlar, atmosferin toplam hacminin neredeyse % 0,1'ini oluştursalar da, önemli bir sera etkisi yaratmaktadırlar.

1.2. Sera Gazları ve Sera Etkisi

Güler (2018) dünya gezegenindeki denge için güneşten gelen ışınlar bir kısmı yer yüzeyine ulaşırken, bir kısmı atmosferden uzaya geri yansıtılır. Atmosfer bir sera gibi davranmaktadır yani hem ısıtmayı hem de yalıtımı sağlar, bu ısıyı tutan gazlar sera gazları olarak adlandırılırlar. Sera gazları arasında su buharı, karbondioksit, ozon, metan ve nitrik asit doğal gazlardır, ancak insan faaliyetleri sonrası ortaya çıkanlar arasında kloroflorokarbon, hidro kloroflorokarbon, halokarbonlar ve kükürt hekzaflorür gazları da bulunmaktadır.

Artan dünya nüfusu, sanayileşme, ilaçlama, sağlıksız kentleşme ve kimyasal maddeler çevreyi kirleterek canlılar için yaşanan ortamları zararlı hale getirmiştir. Bununla beraber fosil yakıtlarının kullanımı bu olumsuz etkilerin artmasına sebep olmuştur (Korkmaz, 2007). Fosil yakıtlarının yanması ile atmosfere yayılan karbondioksit miktarı ve diğer sera gazlarının artışları iklim değişikliklerini oluşturmaktadır (Bolin ve Doos, 1989).

Sera gazları arasında ısıyı en fazla tutan gaz, karbondioksittir. Kokusu ve rengi olmayan karbondioksit, karbon içeren fosil yakıtlarının oksijenle yanması sonucu oluşmaktadır. Doğadaki karbondioksit miktarı, endüstride fosil yakıtlarının kullanılması ile beraber artmaktadır (Avcı, 2014).

Karbondioksit (CO_2) kömür, doğal gaz ve petrol gibi fosil yakıtlarının yanması sonucu ortaya çıkmakta olup, ağaç gibi biyolojik maddelerin yanmasıyla da ortaya çıkabilir. Ayrıca çimento üretimi gibi kimyasal reaksiyon gerçekleştiren tesislerde de atmosfere karbondioksit salınımı gerçekleşebilir. Doğaya salınan metan (CH_4) ise fosil yakıtlarının üretimi esnasında ortaya çıkmaktadır. Ayrıca metan gazı katı atık depolama alanları, arazi kullanımı, tarım ve hayvancılık faaliyetleriyle de ortaya çıkabilmektedir. Azot oksit (N_2O) ise arazi kullanımı, tarım, atık su arıtımı, fosil yakıtların yanması, katı yakıtların yanması ve endüstriyel faaliyetler sonucunda ortaya çıkabilmektedir. Florlu gazlar olan hidroflorokarbonlar, perflorokarbonlar, kükürt hekzaflorür ve nitrojen triflorür gazları endüstriyel tesislerle ortaya çıkan gazlardır. Florlu gazlar, CO_2 'den daha fazla ısı tuttukları için güçlü sera gazları olarak adlandırılabilirler, ancak doğaya salınım miktarları oldukça düşüktür (United States Environment Protection Agency, 2023).


Isıyı tutan gazların atmosferde oluşturduğu etkiye sera etkisi denir. Sera gazların, atmosferdeki miktarının artması doğal olarak sera etkisinin miktarını artırmış olacaktır. Bu nedenle insanlar tarafından oluşturulan sera gazlarının takip edilmesi ve mümkünse kullanım miktarlarının azaltılması veya tekrar tekrar kullanılması

sağlanmalıdır. Fosil yakıtları bu gazı ortaya çıkaran birincil sebeplerdir. Elektrik tüketiminin artırılması veya farklı bir aktivite ile insanlar bu tip ikincil kaynakları kullansalar da, birçok ülkede elektrik üretimi hala fosil yakıtlardan sağlanmaktadır. Bu nedenle, insanlar elektrik tüketimlerine dikkat etmedikçe, doğaya karbondioksit salınımına katkıda bulunmaktadır.

İnsan kaynaklı çevresel etkiler, antropojenik etkiler olarak adlandırılmaktadır. Artan nüfus ve gelişen teknoloji, bu etkilerin iklim üzerinde oluşturduğu değişimler ve yeryüzündeki biyolojik yaşam için oluşan tehditleri artırmaktadır (Diken, 2020).

Keeling Eğrisi, küresel iklim değişikliği ile ilişkili olan atmosferdeki karbondioksit artışını tanımlamak için kullanılan bir veridir (Levinson, 2020).

Şekil 1.1’de Mauna Loa Gözlemevi’nde 1958-2022 yılları arasında ölçülen atmosferdeki aylık ortalama CO₂ konsantrasyonu $\mu\text{mol/mol}$ cinsinden kuru havadaki CO₂ fraksiyonu görülebilir.



Şekil 1.1. Mauna Loa Gözlemevi’nde ölçülen atmosferdeki aylık ortalama CO₂ konsantrasyonu 1958-2022 yılları arasında kuru havadaki CO₂ fraksiyonu ($\mu\text{mol/mol}$) (Wikimedia Foundation, Inc., 2023)

Mauna Loa Gözlemevi’nde (MLO) Charles David Keeling tarafından 1958 ile 2005 yılları arasında deniz seviyesinden 3 km yüksekten alınan karbondioksit numuneleri ile yapılan ölçümler, dünyada ilk defa atmosferdeki artan ısınmaya vurgu

yapmak için kullanıldı ve bu ölçümler sonucunda elde edilen eğriye 'Keeling Eğrisi' adı verildi (Ayyıldız, 2013).

1.3. Küresel Isınma ile Mücadelede Uluslararası Çabalar

1980'li yıllarda bilim adamlarının ısrarlı yaklaşımı ve bilimsel bazı kanıtların etkisiyle, insan kaynaklı iklim değişikliklerinin kontrol altına alınması ve çözüm odaklı yaklaşımların dünya genelindeki insanların katkısıyla gerçekleştirileceği anlayışı, tüm ülke temsilcileri tarafından benimsenmeye başlandı. Bu bağlamda, ülkeler iklim değişikliği ile ilgili adım atmak için çeşitli anlaşmalar yapıp ve kararlar almaya başladılar. Bunun ilki Viyana Sözleşmesi olup diğerleri ise “Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi” (United Nations Framework Convention on Climate Change, UNFCCC), Montreal Protokolü, Kyoto Protokolü ve Paris Anlaşması’dır. Birleşmiş Milletler İklim Değişikliği Konferansları her yıl düzenlenmekte olup 1995 yılında ilk kez Almanya’nın başkenti Berlin’de gerçekleştirildi ve “COP 1” (Conferences of the Parties) olarak adlandırıldı. Bu konferanslar yılda bir kez olmak üzere düzenlenmeye devam etmektedir.

Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'nın (2022) web sitesinden alınan bilgiye göre, 2015 yılında Paris’te yapılan COP 21 ile Paris Anlaşması sera gazlarının % 55’ini oluşturan ülkelerin anlaşma içeriğindeki koşulları sağlaması ile yürürlüğe gireceğinden ve bu koşula uyması gereken 55 ülkenin onaylaması ile 4 Kasım 2016’da anlaşma sağlandı. Anlaşmanın hedefi ilk etapta sanayileşme öncesi döneme göre 2 derecenin altına inmek ve daha sonra 1,5 derecenin altında tutmayı çabalamaktır. Bu amaç doğrultusunda, gıda üretimi zarar görmeden düşük emisyon hedeflerine ulaşmak ve finans akışının planlanmasını içermektedir. Her ülkenin, anlaşmanın yer aldığı temel hedefleri yerine getirmek için yapılan faaliyetleri içeren "Ulusal Katkı Beyanlarını" 5 yılda bir sunması gerekmektedir.

Türkiye Cumhuriyeti Dışişleri Bakanlığı, 2022 resmi web sitesinde verilen bilgiye göre, Paris Anlaşması ile Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi (BMİDÇS) arasındaki en önemli fark, Paris Anlaşması’nda tüm ülkelere göreceli kabiliyetlerine göre belirgin sorumluluklar yüklenmesi ve tüm ülkelerin ortak fakat farklılaştırılmış sorumluluklar vermesidir. Paris Anlaşması ile gelişmiş ve gelişmemiş gibi ülke ayrımı yapılmamıştır.

Hükümetlerarası İklim Değişikliği Paneli (Intergovernmental Panel on Climate Change - IPCC, iklim değişikliğinin bilimsel temeli, etkileri, gelecekteki riskleriyle uyum ve etkileri azaltma seçenekleri hakkında düzenli değerlendirmeler sağlar (Intergovernmental Panel on Climate Change, 2022). “Intergovernmental Panel on Climate Change” (2022) resmi web sitesine göre, 1988 yılında Dünya Meteorolojik Organizasyonu (World Meteorological Organization (WMO)) ve Birleşmiş Milletler Çevre Programı (United Nations Environment Programme (UNEP)) üye ülkelerin oluşturduğu iklim değişikliğini bilimsel olgulara, etki ve risk değerlendirmeleri yapmaya, emisyon azaltım seçeneklerini değerlendirmeye ve hükümetlere iklim değişikliğine katkı sağlayacak gelişmeler için bilimsel bilgiler sağlamışlardır. Bu panellerden çıkan politikalar BM İklim Konferansı - Birleşmiş Milletler Çerçevesi için bilimsel temel olmuştur.

Paris Anlaşması, tüm ülkelerden sera gazı emisyonlarını azaltma ve iklim değişikliğinin etkilerine uyum sağlamak için birlikte çalışma taahhütle bulunmalarını içermekte ve ülkeleri zamanla taahhütlerini güçlendirmeye teşvik etmektedir. Anlaşma, gelişmiş ülkelerin ulusal iklim hedeflerinin şeffaf bir şekilde izlenmesi ve raporlanması için bir çerçeve oluştururken, aynı zamanda gelişmekte olan ülkelere iklim değişikliği ile mücadele ve uyum çabalarında destek olacak bir yol sunmaktadır.


Paris Anlaşması, gelecek on yıl boyunca küresel çabalara rehberlik eden sağlam bir çerçeve sunarak, net sıfır emisyonlu bir dünyaya geçişin temellerini atmaktadır. Aynı zamanda, anlaşmanın uygulanması “Sürdürülebilir Kalkınma Hedeflerine” ulaşmak için de gereklidir.

Paris Anlaşması'nın önemli konuları aşağıdaki gibidir:

1. Paris Anlaşması'nın ilk hedefi, küresel ısınmayı sanayi devriminin hemen öncesindeki sıcaklıklar baz alınarak 2 °C derecenin üstüne çıkarmamak ve uzun vadede ise 1.5 °C ile sınırlamaktır.
2. Her 5 yılda bir, taraf ülkeler "küresel durum değerlendirmesi" ile emisyon azaltımı ve uyum konularındaki ilerlemeleri değerlendirecektir.
3. İklim finansmanı ile uyum ve iklim değişikliğinin olumsuz etkilerine bağlı olarak, gelişmiş ülkeler gelişmekte olan ülkelerin iklim planlarına finansman desteği sağlayacaktır.

1.4. Ülkelerin Sera Gazı Emisyon Durumları

Şekil 1.2’de görüleceği üzere emisyon üreten ülkelere göre sıralandığında 3 ülke (Şekil 1.2’de bulunan sarı kısım) en az üreten 100 ülkenin (Şekil 1.2’de yeşil alan) 16 katı kadar üretiyor. En çok sera gazı üreten 10 ülke Şekil 1.2’de bulunan kırmızı alanlar küresel sera gazı üretilen miktar % 68’dir. Bunların içinde İran ise Paris Anlaşmasını imzalamayan ülkeler arasındadır. 100 ülke Şekil 1.2’de bulunan yeşil alan global olarak % 3 kadar sera gazı salınımı yapıyor.




Şekil 1.2. Ülkelerin Sera Gazı Emisyon Durumları (United Nations Resmi Web Sitesi, 2022)

Paris Anlaşması'na göre, Avrupa Birliği ülkeleri tarafından onaylanan ülkelerin ürettiği emisyonun %95'i insan kaynaklıdır (Wikimedia Foundation, Inc., 2022). Bu anlaşmayı onaylamayanlar arasında en yüksek emisyon salınımını gerçekleştiren ülke İran'dır. Ayrıca, diğer anlaşma yapmayan ülkeler arasında Eritre, Libya ve Yemen bulunmaktadır. Anlaşmanın 28. Maddesine göre, bir ülke anlaşmaya taraf olduktan

sonra en az 3 yıl boyunca geri çekilme bildirimi sunamaz ve geri çekilme bildirimi sunduktan sonra ise en erken 1 yıl sonra geri çekilebilir.

Union of Concerned Scientists (2022) güncel raporuna göre, gelişmiş ve zengin ülkeler, karbon emisyonundan en fazla sorumlu olan ülkeler olarak görülmektedir. Toplam karbondioksit emisyonu, iklim değişikliğinin ana nedenlerinden biridir. Bu durum, 1850 yılında Endüstriyel Devrim'in başlamasıyla, yani zengin ülkelerin ekonomik sistemlerinin ağır sanayiye dönüştürmeye başlamasıyla, iklim etkilerinin görülmeye başlandığı döneme denk gelmektedir. Hem tarihsel olarak hem de son yıllarda, düşük ve orta gelirli ülkelerin sera gazı emisyonları üretimde düşük kaldığı ve büyük çoğunluğunun gelişmiş veya gelişmekte olan ülkelerin faaliyetlerinden kaynaklandığı görülmektedir. Şekil 1.3'te, kümülatif olarak 1750-2020 yıllarında hesaplanan fosil yakıtlar ile çimento sanayisinde ortaya çıkan sera gazı emisyon miktarları gösterilmektedir.



Şekil 1.3. 1750-2010 arası ülkelerin CO₂ fosil yakıtları ve çimento üretimi ile ilgili emisyon miktarları (Union of Concerned Scientists, 2022)

1.5. Türkiye’de Sera Gazı Emisyonları

Türkiye İstatistik Kurumu (2022) tarafından yapılan değerlendirmeye göre, 2020 yılında Türkiye'deki sera gazı emisyonu 523,9 Mt CO₂ eşdeğer olarak kayıtlara geçti. Bu emisyonların % 3,1'lik artışı bir önceki yıla göre hesaplandı. Tarım sektörü

emisyonları ise 2020 yılında 73,2 Mt CO₂ eşdeğerine ulaştı. 2020 yılı içinde toplam sera gazı emisyonlarının içinde CO₂ eşdeğerine göre enerji sektörünün payı % 70,2 olarak kayıtlara geçti. Tarım sektörü % 14, endüstriyel işlemler % 12,7 ve atık sektörü ise % 3,1'lik payla Türkiye'deki sera gazı emisyonlarına katkıda bulundu.

Türkiye'de 1990 yılında ilk tutulan sera gazı envanterine göre, kişi başına düşen toplam sera gazı emisyon değeri 4 ton CO₂ eşdeğer iken, 2020 yılında bu değer 6,3 ton CO₂ eşdeğerine yükseldi.

2013 tarihli 28788 sayılı Resmi Gazete'de yayınlanan Genelge ile Türkiye'de sera gazı emisyonları ve hava emisyonlarının envanterini iyileştirmek, emisyon oluşturan sektörlerden detaylı bilgi toplamak, iklim değişikliğinin zararlı etkilerini önlemek için tedbirleri almak, iç ve dış politikaları belirlemek ve emisyonları azaltmak amacıyla "İklim Değişikliği Koordinasyon Kurulu" oluşturulmuştur.

1.6. Sürdürülebilir Kalkınma Hedefleri

"Net Sıfır" hedefi, atmosferdeki sera gazı emisyonlarını sıfıra yakın bir seviyeye indirme amacını belirtmektedir. Atmosferdeki sıcaklık 19. yüzyılın sonuna göre yaklaşık 1.1 derece artmış durumdadır ve sera gazı emisyonları artış eğilimindedir. Paris Anlaşması, küresel sıcaklık artışını 2030 yılına kadar 1.5 derece sınırında tutma ve 2050 yılına kadar net sıfır hedefine ulaşma planını içermektedir. 2030 yılındaki hedefe ulaşmak için mevcut sera gazı emisyonlarını % 45 oranında azaltmak gerekmektedir. Enerji sektörü, sera gazı üretiminin yaklaşık dörtte üçünü oluşturmakta ve iklim değişikliği açısından en önemli etkenlerden biridir. Kömür, gaz ve petrol yerine rüzgar ve güneş gibi yenilenebilir enerji kaynaklarına geçiş, karbon emisyonlarını önemli ölçüde azaltabilir. Ülkelerin sunduğu ulusal iklim planlarına göre 2030 yılına kadar emisyonlar, 2010'a kıyasla % 14 artışa sebep olacaktır. Glasgow'da yapılan 26. Taraflar Toplantısı (COP 26) sırasında ülkeler, Ulusal İklim Planlarını (NDC) 2022 sonuna kadar tekrar gözden geçirme çağrısı yapılmıştır (United Nations Resmi Web Sitesi, 2022).

Paris Anlaşması'nın 4. Maddesi, küresel olarak en kısa sürede emisyon miktarının tepe noktasına ulaşarak azaltılmasını ve 2050 itibarıyla insan kaynaklı sera gazı emisyonları ile yutaklar arasında denge sağlanmasını öngörmektedir. Hükümetler Arası İklim Değişikliği Paneli (IPCC) tarafından yayınlanan 1,5 Derece Özel Raporu, küresel sıcaklığı 2030'a kadar 1,5 derecede sınırlamanın ve 2050'de net sıfır emisyon

hedefine ulaşmanın doğal yaşamın devamı için önemli olduğunu vurgulamaktadır. BM İklim Değişikliği Çerçeve Sözleşmesi'nin (UNFCCC) 26. Taraflar Konferansı (COP 26) ile kabul edilen "Glasgow İklim Paktı" da bu hedefi tekrar vurgulamıştır (Şahin ve ark., 2021).


United Nations Resmi Web Sitesi'nde (2022) yayınlanan bilgiye göre Sürdürülebilir Kalkınma Hedefleri (The Sustainable Development Goals) doğal yaşama zarar veren küresel ısınmanın önüne geçecek adımları atarken refah seviyesini de düzeltecek hedefler doğrultusunda çalışmalar yapılmasına yönelik bir çağrıdır. İklim değişikliği ile yapılan mücadele devam ederken eğitim, sağlık, sosyal koruma, ekonomik büyüme, sürdürülebilir yerleşim alanları, tüketim ve üretim modelleri, çevre ve iş olanaklarını da ele alacak bir ekonomik büyüme stratejisi ile hareket etmenin önemini vurgular.

2. KAYNAK ARAŞTIRMASI

Paris İklim Anlaşması ile hem ekonomik hem de çevresel etkilerinin analiz edildiği çalışmalarda, ülkelerin anlaşma taahhütlerini yerine getirmesi durumunda atmosfere yayılan karbondioksit miktarında hedeflenen azalmaların gözlemlenebildiği görülmüştür. Aynı şekilde, ülkelerin kademeli olarak karbon piyasasını da hesaba katarak yapılan modellemelerde, farklı bölgelerde ekonomik sebeplerden dolayı ortaya çıkan maliyetlerin bölgesel olarak değiştiği tespit edilmiştir. Bu ek modellemeler ayrıca, bazı ülkelerin anlaşmadan çekildiği varsayıldığında, söz konusu ülkelerdeki GSYİH'nin arttığı gözlenmiştir. Ancak bu ortak harekette çekilen ülke modellemede negatif sonuçlarla karşılaştığı ortaya çıktığı ve ülkelerin anlaşma çerçevesi içinde olmanın her ülkeye pozitif katkı olacağı çıkarımına ulaşılmıştır. (Liu ve ark., 2020)

Türkiye, 2015 yılında Paris İklim Anlaşması'yla sera gazı salınım miktarını azaltma hedefini benimserken, gelişmekte olan bir ülke olması nedeniyle enerji tüketimine ihtiyaç duymaktadır. Enerji tüketimi gibi ulaşım, GSYH ve nüfus gibi parametreler de sera gazı salınım miktarını etkilemektedir. Paris İklim Anlaşmasına üye ülkeler, beş yıllık kalkınma planlarını sunmaktadır. Bu planlar doğrultusunda yapılan çalışmalarda, “Yapay Sınır Ağı” (YSA) modeli kullanılarak Türkiye'nin 2020, 2025 ve 2030 yıllarında atmosfere saldığı sera gazı miktarının, taahhüt ettiği değerin üstünde arttığı modellenmiştir. Bu nedenle Türkiye'nin taahhüdünü yerine getirmek için enerji verimliliğini artıracak ve yenilenebilir enerjiye yönelik çalışmalar yapması gerektiği belirtilmektedir (Pabuçcu ve Bayramoğlu, 2016).

Tahmin konusunda başarılı sonuçlar veren Yapay Sınır Ağları Modeli kullanılarak Türkiye'nin 2020, 2025 ve 2030 yıllarında CO₂ eşdeğeri salım miktarları Şekil 2.1'de görüleceği “Referans Senaryo“ sırasıyla 740,33 Milyon Ton (Mt), 1039,32 Mt ve 1244,13 Mt bulunmuştur (Pabuçcu ve Bayramoğlu, 2016).



Şekil 2.1. Türkiye'nin sera gazı emisyon senaryosu (Pabuçcu ve Bayramoğlu, 2016)

Özhan (2020) tarafından yapılan çalışmada, Holt'un lineer trend yöntemi kullanılarak oluşturulan yapay sinir ağı modellemesi sonucunda Türkiye'deki sera gazı emisyon miktarı zamanla değişen bir şekilde analiz edilmiştir. Türkiye'de sera gazı salınım miktarının dalgalı bir seyir izlemesine rağmen artış eğiliminde olduğu tespit edilmiştir.

Aydın (2022) ve Aydoğdu (2022) tarafından yapılan çalışmada, insan faaliyetleri sonucu ortaya çıkan sera gazı emisyonunun Avrupa Birliği ülkeleri ile Türkiye için makine öğrenmesi kullanılarak “Karar Ağacı Modellemesi”, “Yapay Sinir Ağı” ve “Destek Vektör Makineler”i yöntemleriyle yapılan modellemeler sonucunda, gelişmiş Avrupa ülkelerinde CO₂ emisyonunun azalma eğiliminde olacağı tahmin edilirken, Türkiye'de ise artış eğiliminde olduğu ortaya çıkmıştır.

Sel (2020) tarafından yapılan araştırmaya göre, sanayi devrimi ile fosil yakıtlarının kullanım miktarı sürekli olarak artmakta ve bu durum atmosferdeki sera gazı miktarının artmasına yol açmaktadır. Araştırmada, Dünya Bankası'na üye 36 ülke ile yapılan Kendini Organize Eden Harita (SOM) modeli kullanılarak, ülkeler karbon emisyon miktarlarına göre 4 ayrı kümeye sıralanmıştır. Bu kümelerde yüksek emisyon yayan ülke sayısı 1, ikinci yüksek emisyon yayan kümede 9 ülke, üçüncü kümede 10 ülke ve en az karbon emisyonu yayan 16 ülke bulunmaktadır. Araştırmada, Dünya Bankası'na ait 1990 ile 2014 yılları arasındaki veriler kullanılmıştır.

Brezilya, Rusya, Hindistan, Çin ve Güney Afrika'dan oluşan BRICS üyeleri ile Türkiye'nin kömür kaynaklı oluşan sera gazı emisyon tahminlemesi için yapılan çalışmada, bu altı ülkenin demografik yapısı ve ekonomik durumları da değerlendirilerek çoklu regresyon modeli kullanılmıştır. Çalışmada, 1971 ile 2010

yılları arasındaki veriler istatistiksel modeli geliştirmek için kullanılmış, 2011 ile 2016 yılları arasındaki ikinci grup veriler ise elde edilen modelin performans ölçümünde kullanılmıştır. Regresyon tekniği ile yapılan çalışmada, bir veya daha fazla değişken arasındaki ilişkiyi dahil ederek tahminleme yapılmış ve başarı elde edilmiştir. Çalışma sonucunda, kömür kaynaklı oluşan CO₂ emisyonunun en önemli kaynağının nüfus olduğu tespit edilmiştir. Büyük nüfusa sahip ülkeler olan Çin ve Hindistan gibi ülkelerde toplam nüfusun etkisinin yüksek olduğu görülürken, diğer ülkelerde ise kentsel nüfusun etkisinin yüksek olduğu belirlenmiştir (Karakurt ve Aydın, 2020).

Küresel olarak birincil enerji ihtiyacının %85'i fosil yakıtlardan karşılandığı bilinmektedir. Sera gazlarının salınımına en büyük etki ise %25 oranında elektrik ve ısı üretimi nedeniyle ortaya çıkmaktadır. Bu sebeple, “Derin Öğrenme”, “Destek Vektör Makinası” (SVR) ve “Yapay Sinir Ağı” modelleri kullanılarak yapılan tahminleme ile atmosfere yayılan sera gazı miktarının hesaplanması amaçlanmıştır (Bakay ve Ağbulut, 2021).

Uzlu, E. (2021) tarafından yapılan çalışmaya göre Gri Kurt Optimizasyonu (GWO - Grey Wolf Optimisation) yöntemi, Gayri Safi Yurtiçi Hasıla, enerji tüketimi, yenilenebilir enerji üretimi, nüfus ve şehirleşme oranlarına ait verileri kullanarak başarılı sonuçlar elde edilmiştir. Yapay sinir ağı modelleri arasında Gri Kurt Optimizasyonu, Geri Yayılım algoritması, Yapay Arı Kolonisi (Artificial Bee Colony - ABC) ve Öğretme-Öğrenme Tabanlı Optimizasyon (Teaching-Learning Based Optimisation - TLBO) yöntemleri karşılaştırılmış ve ortalama bağıl hata değerleri incelenmiştir. Bu karşılaştırmada Gri Kurt Optimizasyonu yöntemi yüksek başarı göstermiş ve 2030 yılına kadar yapılan modelleme ile Türkiye'de daha az sera gazı üretileceği tahmin edilmiştir. Bu çalışma ile 2030 yılına kadar beklenen sera gazı emisyon değerleri ile yapılan tahminlemeler karşılaştırılmış ve azaltılması hedeflenen sera gazı emisyonlarının elde edilmesi yolunda olumlu bir sonuca ulaşılmıştır.

Sera gazının küresel ısınmaya neden olduğu açıktır. Sera gazlarının en önemli kaynağı olan enerji kaynaklarına bağlı faaliyetlerden meydana geldiğinden dolayı enerji kaynakları modelleme için kullanılabileceği gibi ekonomik faaliyetlerde benzer etkiyi oluşturabilir ve bunun için GSYİH kullanılmıştır. İran, Kuveyt, Katar, Suudi Arabistan ve Birleşik Arap Emirliği ile yapılan çalışmada yapay sinir ağı modellerinden Veri İşleme Grup Yöntemi (VİGY, GMDH (Group Method of Data Handling)) kullanılmıştır (Ahmadi ve ark., 2019).

Dünyada hızlı ekonomik gelişme ile beraber atmosfere salınan karbondioksit emisyonu sonucu atmosferde oluşan sera etkisi ile doğada olumsuz etkilerle karşılaşmaktadır. Artık Sinir Ağı (ResNet – Residual Neural Network) ile derin sinir ağlarında artan derinlik ile gradyan kaybolması azaltmak için ResNet modeli ile ekonomi ve karbondioksit emisyonlarını tahminleme yapılmıştır. 24 ülke veya bölge için ResNet ile yapılan modellemede 2009 yılı ile 2020 yılları arasındaki konvansiyonel yakıtlar, hidroelektrik ve yenilenebilir enerji ihtiyaçları enerji kaynağı olarak, kişi başına Gayri Safi Milli Hasıla (GSYİH) ve karbondioksit emisyon değerleri kullanılmıştır (Han ve ark., 2023).

Sera gazı emisyonuna etki eden dokuz farklı parametre kullanılarak yapay sinir ağı modeli ile Avustralya, Brezilya, Çin, Hindistan ve ABD'deki sera gazı emisyonunun yoğunluğunu araştırmaya yönelik bir modelleme yapılmıştır. Girdi olarak ekonomik büyüme, enerji tüketimi, finansal gelişim, Ar-Ge (Araştırma-Geliştirme), doğrudan yabancı yatırım, ticari açıklık, sanayileşme ve kentleşme olarak kullanılan dokuz farklı değişken ile 1980'den başlayarak 2015 yılı sonuna kadar 3 aylık verilerle farklı ülkeler için farklı modeller uygulanmıştır. Çok katmanlı (Multi-Layer Perceptron) bir algılayıcı ile kullanılan Geri Yayılım Algoritması (Back-propagation Algorithm) ile doğrulanmış modeller sonucuna yaklaşık sıfır hata ile tahminleme yapılmıştır (Acheampong ve Boateng, 2019).

Enerji talebi nedeniyle artan sera gazı emisyonlarını azaltmak için güneş, rüzgar ve hidroelektrik gibi yenilenebilir enerji modern bir dünya için bir avantaj olduğu açıktır. Derin sinir ağı tabanlı yaklaşımlardan Doğrusal Olmayan Otoregresif Dışsal Girdiler (NARX - Nonlinear AutoRegressive with eXternal input) ile rüzgar hızı tahminlemesi yaparak tahmin modeli oluşturulmuş olup “ortalama kare hatası (MSE)” ve “korelasyon katsayısı (R^2)” ile en iyi performans elde edilmiştir. Ayrıca Tekrarlayan Sinir Ağı (RNN - Recurrent Neural Network) ve “Eğri Uydurma” (Curve Fitting) R^2 ile daha iyi performans ile rüzgar hız tahmin modellemesi elde edilmiştir (Rahman ve ark., 2022).

Rusya'daki Arktik Adasında ana sera gazlarındaki değişimi izlemek için yüzeyde ölçülen CO₂ konsantrasyonlarında elde edilen veriler kullanılarak yapay sinir ağlarından bazı modeller ile tahminleme yapılmıştır. Kullanılan yapay sinir ağı modelleri arasında Doğrusal Olmayan Otoregresif Dışsal Girdiler (NARX - Nonlinear AutoRegressive with eXternal input), Elman Sinir Ağı (Elman Neural Network - ENN) ve Çok Katmanlı Perceptron (Multi-Layer Perceptron - MLP) yer almaktadır. Çalışmada, 2015 yılının

Temmuz ve Ağustos ayları içindeki günlük ölçülen CO₂ konsantrasyon değerlerinin 168 saatlik dilimi kullanılarak yapılan tahminleme çalışmasında, yapay sinir ağı modellerinden olan NARX modeli, tahminleme yöntemi için en iyi performansı sağlayan model olarak tespit edilmiştir (Sergeev ve ark., 2022).

Sera gazı emisyonunun büyük çoğunluğu CO₂ kaynaklı olup, bu gaz büyük ölçüde fosil yakıtlarını kullanan enerji sistemlerinden kaynaklanmaktadır. Bu nedenle Türkiye, Bulgaristan ve Yunanistan'ın enerji tüketimine göre yapılan çalışmada 2000 ile 2009 yılları arasındaki farklı enerji kaynaklarının tüketim verileri ile Gayri Safi Milli Hasıla (GSYİH) kullanılarak CO₂ emisyonu modellemek için yapay sinir ağı modellerinden olan Grup Veri İşleme Yöntemi (GMDH - Group Method of Data Handling) uygulanmıştır. Çalışmada, eğitim, test ve genel veri için R² (R-kare) değerleri sıfıra yakın sonuçlar verirken, AARD (Mutlak Ortalama Bağıl Sapma - Absolute Average Relative Deviation) değeri ise sıfıra yakın sonuçlarla modelin başarılı tahminleme yapabildiği gözlenmiştir (Ali ve ark., 2022).

Karbondioksit, insan faaliyetleri sonucu ortaya çıkan ve büyük miktarı enerji kaynaklı olduğu bilinen bir sera gazıdır. Güneydoğu Asya'daki farklı ülkeler olan Malezya, Endonezya, Singapur ve Vietnam gibi ülkelerle yapılan bu çalışmada, farklı enerji kaynakları kullanılarak ortaya çıkan karbondioksit (CO₂) miktarının modellenmesi sağlanmıştır. Çalışmada, ekonomide enerji tüketiminin en önemli süreçlerden biri olduğundan ülkelerin ekonomi göstergelerinden olan Gayri Safi Yurtiçi Hasıla (GSYİH) verileri dikkate alınmıştır. Modelleme için normalleştirilmiş radyal tabanlı ve tansig olarak adlandırılan iki transfer fonksiyonlu yapay sinir ağı (YSA) kullanılarak karbondioksit (CO₂) üretimi başarılı bir şekilde modellenmiştir (Komeili ve ark., 2022).

3. YAPAY ZEKA BİLEŞENLERİ

3.1. Veri Toplama

3.1.1. Sera Gazı Emisyon Verileri

European Union (2023) resmi web sitesi olarak kullanılan Küresel Atmosfer Araştırmaları için Emisyon Veritabanı (EDGAR - Emissions Database for Global Atmospheric Research) ile florlu gazların emisyonları ülke raporlarından eğer mümkün değilse UNEP (Birleşmiş Milletler Çevre Programı (UNEP - United Nations Environment Programme)) veriler, bilimsel literatürler ve uzman görüşlerden elde edilerek raporlara dahil edilmiştir. ABD (Amerika Birleşik Devletleri) hariç diğer ülkeler için EDGAR sisteminde bulunan sera gazı emisyon veriler baz alınarak çalışma yapıldı. EDGAR sisteminde elde edilen Çizelge 3.1, bazı ülkelerin belirli yıllar için Mton CO₂eşd. cinsinden sera gazı emisyon miktarlarını örnek olarak göstermektedir.

Çizelge 3.1. Bazı ülkelerin 1970 ile 1974 yılları için Mton CO₂eşd. cinsinden sera gazı emisyon miktarları (European Union, 2023)

Ülke Kodu	Ülke Adı	1970	1971	1972	1973
ARG	Arjantin	223,683963	227,1941099	234,418048	242,4446487
ARM	Ermenistan	13,58249164	13,7459407	14,64714725	15,78724254
ABW	Aruba	0,102236263	0,102845917	0,116487421	0,120939701
AUS	Avustralya	313,8993778	319,9069074	331,7658466	339,1957456
AUT	Avusturya	73,52036608	76,16351691	78,46490582	82,23043465

Elde edilen veriler, European Union (2023) resmi web sitesinde sera gazı emisyonlarının Mton CO₂eşd. (Mton CO₂eq.) birimiyle ifade edildiğini göstermektedir. Sera gazı (GHG) emisyonları, karbondioksit (CO₂), metan (CH₄), azot oksit (N₂O) ve F-gazları gibi bileşenleri içermektedir. F-gazları, hidroflorokarbonlar (HFC'ler), perflorokarbonlar (PFC'ler), kükürt hekzaflorür (SF₆) ve nitrojen triflorür (NF₃) gazlarından oluşmaktadır.

U.S. Energy Information Administration (EIA) (2023) resmi web sitesine göre, Amerika Birleşik Devletleri (ABD) toplam enerji CO₂ emisyon verileri milyon metrik ton karbon cinsinden Ocak 1970 yılından itibaren aylık verilere ulaşılabilir. Aynı şekilde ABD'deki Birincil Enerji Tüketimi ile Yenilenebilir Enerji Tüketimi verilerinde

1970 Ocak ayından itibaren yıllık olarak Triyon BTU cinsinden ulaşılabilir. Buradaki çalışmada, Amerika Birleşik Devletleri sera gazı emisyonu ile ilgili veriler ABD Enerji Bilgi İdaresi veri tabanından alınarak kullanıldı ve Çizelge 3.2’de ABD’ye ait toplam enerji kaynaklı CO₂ emisyon verilerinin bir kısmı görülebilir.

Çizelge 3.2. Trilyon BTU cinsinden Yenilenebilir Enerji Tüketimi cinsinden miktarları “U.S. Energy Information Administration” (EIA) (2023)

Aylar	Toplam Enerji Kaynaklı CO ₂ Emisyonları (Milyon Metrik Ton Karbondioksit)
1973 Ocak	454,077
1973 Şubat	415,098
1973 Mart	407,423
1973 Nisan	368,205
1973 Mayıs	376,028

3.1.2. Nüfus Verileri

Birleşmiş Milletler İstatistik Bölümü, küresel istatistik sisteminin ilerlemesine yardımcı olup, küresel istatistiksel bilgileri derleyerek yayınlar ve ülkelerin ulusal istatistik sistemlerini güçlendirmesine yardımcı olur. Uluslararası istatistiksel faaliyetlerin koordinasyonun için Birleşmiş Milletler İstatistik Komisyonu'nun işleyişine yardımcı olur (Birleşmiş Milletler, 2023).

Birleşmiş Milletler İstatistik Bölümü'nün faaliyetleri kapsamında, kayıt altında tutulan tüm verilerden ülke nüfus kayıtlarından faydalanılmıştır.

3.1.3. İnsani Gelişme Endeksi Verileri

Birleşmiş Milletler Geliştirme Programı (UNDP - United Nations Expanded Programme, 2022) resmi web sitesinden alınan bilgilere göre İnsani Gelişme Endeksi (İGE (HDI - Human Development Index)) uzun ve sağlıklı bir yaşam (sağlık boyutu), bilgili olmak (eğitim boyutu) ve iyi bir yaşam standardına sahip olmak (yaşam boyutu) gibi temel boyutları normalleştirip geometrik ortalama ile ölçümlendiren bir çalışmadır. Yaşam boyutu kişi başı gayri safi milli gelir kullanılır. İnsani gelişme verileri Sürdürülebilir Kalkınma Hedefleri (SKH) ile doğrudan bağlantılıdır ve bu nedenle bir ülkenin kalkınmasını değerlendirmek için ülkelerin ekonomik büyümesi ile beraber o

ülkede ki insanların sađlık, eđitim ve gelir boyutları da önemli kısımlardır. İGE, bir ülkenin kalkınma ölçeklendirmelerinde kullanılabilir. İGE verileri İnsani Gelişme Endeksi UNDP resmi web sitesinden elde edildi.

3.1.4. Finansal Veriler

Uluslararası Para Fonu (IMF - International Monetary Fund), İkinci Dünya Savaşı sonrasında, üye ülkelerin ödemeler dengesi ile ilgili ihtiyaçlarına fon sağlamak için kurulmuştur (Tunalı, 2011).

Ülkelerin finans durumlarının güçlölüğü sera gazı emisyonla mücadele konusunda daha güçlü hareket etmelerini sağlamaktadır. Uluslararası Para Fonu tarafından ülkelerdeki finans durumları ile ilgili envanterleri Uluslararası Finansal İstatistikleri'ne ait veritabanında tutulmaktadır. Buradaki verilerden tüm mallara ait üretici fiyatları endeksi, mevsimsellikten arındırılmış sanayi üretimi, tüketici fiyatları endeksi, sanayi üretimi ekonomik faaliyet endeksi ve finansal piyasa fiyatları dönem sonu endeksi kullanılmıştır.

3.1.5. Ekonomik Veriler

Bir ülkenin ekonomik performanslarını ölçme ve diğer ülkeler ile karşılaştırma yapmak için ekonomik veriler kullanılır. Temel Ekonomik Göstergeler, Gayri Safi Milli Gelir, Gayri Safi Yurtiçi Hasıla ve Net Milli Gelir bunlardan bazılarıdır. Buradaki çalışmada, Gayri Safi Yurtiçi Hasıla için Birleşmiş Milletler İstatistik Bölümü'nün kaydettiğı veriler kullanılırken, diğer veriler için Ekonomik İşbirliği ve Kalkınma Örgütü tarafından elde edilen veriler kullanıldı.

Ekonomik İşbirliği ve Kalkınma Örgütü (OECD) (Organisation for Economic Co-operation and Development, 2023) web sitesine göre bir ülkenin ulaşım, ekonomik projeksiyon, finans, üretim, eğitim, tarım ve balıkçılık gibi birçok veriyi tek bir endeks ile göstermek için kullanılan “Temel Ekonomik Göstergeler (Main Economic Indicators (MEI))”, üretim sübvansiyonları hariç gayri safi yurtiçi hasıla ile yurtdışından gelen net gelirler ve net vergileri gösteren GSMG (Gayri Safi Milli Gelir), brüt milli gelirden sabit sermaye varlıklarının amortismanlarının çıkarılması ile elde edilen Net Milli Gelir (Net National Income (NNI)) ve belirli bir dönemde bir ülkede üretilen mal ve hizmetlerin değerinin ölçülmesi için Gayri Safi Yurtiçi Hasıla (Gross Domestic Product

(GDP - GSYİH) kullanıldı. Avustralya için OECD verilerinden elde edilen, bazı yıllara ait kişi başı dolar cinsinden yıllık Gayri Safi Milli Hasıla toplam değerleri Çizelge 3.3'te görülebilir.

Çizelge 3.3. Avustralya için kişi başı dolar cinsinden yıllık Gayri Safi Milli Hasıla toplam değeri (Organisation for Economic Co-operation and Development, 2023)

Ülke Kodu	Gösterge	Başlık	Ölçüm	Frekans (A= Yıllık)	Yıl	Değer
AUS	GNI	TOT	USD_CAP	A	1970	4.601
AUS	GNI	TOT	USD_CAP	A	1971	4.843
AUS	GNI	TOT	USD_CAP	A	1972	5.214
AUS	GNI	TOT	USD_CAP	A	1973	5.776
AUS	GNI	TOT	USD_CAP	A	1974	6.259

3.1.6. Birincil ve Yenilenebilir Enerji Arz Verileri

Ekonomik İşbirliği ve Kalkınma Örgütü (OECD - Organisation for Economic Co-operation and Development, 2023) web sitesine göre birincil enerji arzı, ihtiyaç duyulan enerji üretimini ifade ederken, kullanılan veride enerji ürünlerinin kalori içeriği ile hesaplanarak ton petrol eşdeğeri (tep). Ton petrol eşdeğeri 107 kilokaloriye denk gelir veya 41.868 gigajoule'a eşittir. Ayrıca, yenilenebilir enerji kaynakları birincil enerji eşdeğerine göre birincil enerji arzına katkıda bulunmaktadır. Yenilenebilir kaynaklar, pompa depolama metodu hariç hidrolik, jeotermal, güneş, rüzgar, gel-git, dalga gibi kaynakları içerirken, aynı zamanda biyoyakıtlar, biyogazolin, biyodizeller, biyogazlar ve kentsel atıkların yenilenebilir atıklar ile elde edilen enerji gibi kaynakları da içermektedir. Ayrıca, doğrudan veya dolaylı olarak biyokütleden (canlı veya yakın zamanda yaşayan organizmalardan elde edilen malzemeden) türetilen yakıtlar, odun, enerji üretimi için kullanılan bitkisel atıklar, etanol, hayvansal malzemeler veya atıklar ve sülfat kül suyu da yenilenebilir kaynaklar arasında yer almaktadır. Bunun yanı sıra, ısı ve/veya elektrik üretimi için merkezi bir yerde kullanılan atıklar da yenilenebilir kaynaklara dahil edilmektedir. Yenilenebilir enerji kaynaklarının toplam birincil enerji arzına oranı yüzde olarak veri setinde ulaşılabileceği gibi, aynı zamanda bin tep (ton petrol eşdeğeri) cinsinden de veriye ulaşmak mümkündür. Avustralya için, OECD veri tabanından elde edilen bazı yıllara ait "Miyon TOE" cinsinden birincil enerji tüketimi miktarları Çizelge 3.4'te sunulmaktadır.

Çizelge 3.4. Avustralya'nın (AUT) yıllık olarak milyon ton petrol eşdeğeri (MLN_TOE) cinsinden kullanılan birincil enerji kaynaklarının toplam yıllık miktarları (Organisation for Economic Co-operation and Development, 2023)

Ülke Kodu	Birim	Frekans (A= Yıllık)	Yıl	Değer
AUT	MLN TOE	A	2018	32.861
AUT	MLN TOE	A	2019	33.447
AUT	MLN TOE	A	2020	31.516
AUT	MLN TOE	A	2021	33.212

United States (U.S.) Energy Information Administration (EIA) (2023) resmi web sitesine göre, Amerika Birleşik Devletleri'nde (ABD) toplam enerji CO₂ emisyon verilerine Ocak 1970 yılından itibaren aylık olarak milyon metrik ton karbon cinsinden ulaşılabilmektedir. Aynı şekilde, ABD'deki birincil enerji tüketimi ile yenilenebilir enerji tüketimi verileri, 1970 Ocak ayından itibaren yıllık olarak trilyon BTU (British Thermal Unit) cinsinden “ABD Enerji Bilgi İdaresi” veri tabanından alınarak kullanılmıştır. ABD için, “ABD Enerji Bilgi İdaresi” veri tabanından elde edilen bazı aylara ait "Trilyon BTU" cinsinden birincil enerji tüketimi miktarları Çizelge 3.5'te sunulmaktadır.

Çizelge 3.5. Trilyon BTU cinsinden Birincil Enerji Tüketimi miktarları (U.S. Energy Information Administration, 2023)

Aylar	Birincil Enerji Tüketimi Toplamı (Trilyon Btu)
2022 Nisan	7752,803
2022 Mayıs	7941,386
2022 Haziran	8165,758
2022 Temmuz	8598,485

3.1.7. Ağaçlandırma Verileri

The World Bank Group (2023) resmi web sitesine göre Dünya Bankası çeşitli ülkeler ve bölgeler ile farklı ortaklarla işbirliği yapmaktadır. Ormanların sürdürülebilir yönetimini ve uzun vadeli programlarla bu hedefe yönelik ülkeleri teşvik etmek, Dünya Bankası'nın önceliklerinden biridir. Ormanlar, kırsal ekonomileri destekleyerek birçok insanı aşırı yoksulluktan korumada önemli bir rol oynamaktadır. Aynı zamanda, ormanlar ülkelerin ekonomilerine istihdam, gıda ve enerji gibi alanlarda katkı sağlamakta ve iklim değişikliği konusunda da önemli bir rol üstlenmektedir. Ayrıca

odun bazlı yakıtlar, Afrika için önemli bir enerji kaynağı olarak görülmekte ve fosil yakıtlara alternatif olma potansiyeline sahiptir. Bu nedenle, ormanların sürdürülebilir şekilde yönetilmesi büyük önem taşımaktadır. Ayrıca, ormanlar toprak verimliliğine, su havzalarına ve canlılar için yaşam alanlarına sahip olmaktadır. Tabii ki, ormanların en önemli özelliği atmosferdeki CO₂'i emmeleridir. Bu nedenle, ormanlar iklim değişikliğini yavaşlatma konusunda etkili bir rol oynamaktadırlar. Yapılan araştırmalara göre, ormansızlaşma sera gazı emisyonlarının yaklaşık % 12'sine neden olmaktadır. Yaklaşık olarak yılda 13 milyon hektar (brüt) orman ortadan kalkarken, yeniden ağaçlandırma faaliyetleriyle bu değer 5.6 milyon hektara düşebilmektedir. Ayrıca, 2 milyar hektar ormanın geri kazanılması mümkün olabilmektedir.

3.2. Yöntem

3.2.1. Ülke Seçimi ve Uygulanan Metotlar

Bu çalışmada, odak noktası olarak belirlenen konularla ilgili önemli ve kapsamlı verilere sahip olan Almanya, Amerika Birleşik Devletleri, Avustralya, Birleşik Krallık, Fransa ve Türkiye gibi çeşitli lokasyonlardaki çoğunluğu gelişmiş ülkeler örnek olarak seçildi. Ayrıca, bu ülkelerin verilerine uluslararası platformlara ait veritabanlarından erişilebildiği için araştırmacılar daha güvenilir ve kapsamlı veri kaynaklarına ulaşma imkanına sahipler. Bu sayede çalışmanın sonuçları daha sağlam temellere dayanarak ve ilgili alanlarda faaliyet gösteren araştırmacılar için önemli bir referans kaynağı olabilecektir.

Çalışma sürecinde, her bir ülkenin uygun ve yeterli verilerini elde etmek için çeşitli kaynaklardan yapılan çalışmalarla veri toplandı ve analiz edildi. Bu veriler arasında sera gazı emisyonları, insani gelişme endeksi, finansal ve ekonomik göstergeler, birincil ve yenilenebilir enerji arzı ile ağaçlandırma alanları yer almaktadır. Bu sayede, çalışma kapsamında yer alan ülkelerin sera gazı emisyonları ve diğer önemli verileriyle ilgili sağlam bir temel oluşturuldu.

“Derin Öğrenme”, makina öğrenme'nin bir alt dalı olup veya özelleşmiş bir öğrenme biçimidir. Biyolojik sinir ağını model alır. Giriş katmanı olarak adlandırılan sinir hücreleri, bilgileri alır ve düğümler vasıtasıyla diğer katmanlara veya gizli katmanlara iletirler. Her düğümde, ağırlıklar hesaplanır ve bu şekilde devam ederek en son çıkış katmanına ulaşarak çıkışlar elde edilir. Derin öğrenmede giriş katmanı, çıkış

katmanı ve birden fazla gizli katman bulunur. Her nöron, doğrusal olmayan ve belirli bir aralıkta sonuçlanabilen aktivasyon fonksiyonları içerir. Bu yapı, insanlarda olan sinir ağı modeli yapısına benzer şekilde algoritma oluştuktan sonra yeni verilere göre çıkışlar veya tahminlemeler yapar. Derin öğrenmede verinin büyük kısmı eğitim için kullanılır ve bir kısım test verisi olarak performans değerlendirmesi için kullanılır.

“Yapay Sinir Ağ” (YSA) (ANN - Artificial Neural Network) metotları farklı tabakalardan oluşan ve “iterasyon” gerektiren işlemlerle çalışan yöntemlerdir. Bu nedenle, verilerle işlem yapmak için daha uzun süreler gerektirebilirler; ancak istenen sonuçlara yüksek doğrulukla ulaşmada yardımcı olurlar.

Regresyon (Regression) tekniği ile değişkenler arasındaki ilişkileri tahmin ederek çözümler. Regresyondan değişkenler sürekli değişken bir yapıya sahiptirler. Regresyon, değişkenler arasında neden sonuç ilişkilerini tahminleme yaparak modelleme oluşturur ve tahminleme yapmak istendiğinde kullanmak için iyi bir algoritmadır. Regresyon teknikleri ile finansal durumlar gibi herhangi bir veride tahminleme yapılmak istendiğinde bu teknik ile tahminleme yapılabilir (The MathWorks, Inc., 2023).

Bu çalışmada, başlangıçta derin öğrenme yöntemi ile LSTM Regresyon algoritması kullanıldı. derin öğrenme yaklaşımıyla, sera gazı emisyonu, ekonomik veriler, nüfus ve ağaçlandırma gibi farklı veriler ayrı ayrı değerlendirilerek zaman serilerini içerecek şekilde tahminleme sonuçları elde edildi. Bu tahminler, farklı veri girişleri için ayrı ayrı yapıldı.

İkinci aşamada, derin öğrenme yöntemi ile CNN-RNN algoritmaları bir arada kullanılarak Hibrit bir yöntem uygulandı. Bu hibrit yöntem sadece ilgili ülkelerin sera gazı emisyon verileri için kullanıldı ve LSTM Regresyon algoritması ile karşılaştırılarak yapılan çalışmanın sonuçları doğrulandı.

Son olarak, tüm veriler için ayrı ayrı derin öğrenme yöntemlerinden LSTM Regresyon algoritması ile elde edilen tahminleme sonuçları bir araya getirildi. Ardından, sera gazı emisyon verileri çıktı olarak kullanılarak diğer veriler giriş verisi olarak alınarak yapay sinir ağı NARX modeli ile sera gazı emisyon tahminlemesi yapıldı. Yapay sinir ağı ile gerçekleştirilen eğitimlerde % 15'lik rastgele veri test için ayrıldı ve başarı oranları Regresyon modeli kullanılarak R değeri ile değerlendirildi. Elde edilen sera gazı emisyon tahmin verileri gerçek verilerle karşılaştırıldı. Ayrıca gelecek için tahmin edilen sera gazı emisyon verileri ile LSTM sonucu ortaya çıkan sera gazı emisyon tahmin verileri karşılaştırıldı.

3.2.2. Verilerin Düzenlenmesi

Bu çalışmada, 1970 yılı Ocak ayı başlangıç olarak kabul edildi ve 2022 Aralık ayı son veri olarak kullanıldı. Bu tarihler aralığında eksik verilere rastlandı. Eksik olan veriler ya ilk kayıtlı veri tarihinden öncesine ait oldu ya da son kayıtlı veri tarihi olan 2022 Aralık ayından önceki dönemlere ait olabilirler. Bu durumlarda, ilk verilerden eksik olan veriler için 1970 Ocak ayından başlayarak ilk kayıtlı veri tarihine kadar olan veriler, ilk kayıtlı veri ile dolduruldu. Benzer şekilde, son kayıtlı veri tarihi 2022 Aralık ayından öncesine aitse, 2022 Aralık ayına kadar olan dönemdeki eksik veriler, son kayıtlı veri ile tamamlandı. Çok fazla eksik veriye sahip olan giriş verileri ise çalışmada kullanılmadı. Bu şekilde eksik veri durumlarından kaynaklı boşluklar verilerde giderilerek analizlere uygun hale getirildi.

Amerika Birleşik Devleti için sera gazı emisyon miktarı, Birincil ve Yenilenebilir Enerji Kaynaklarına ait veriler, ABD Enerji Bilgi İdaresi veritabanından aylık olarak temin edildi. Ancak, Almanya, Birleşik Krallık, Avustralya, Fransa ve Türkiye için sera gazı emisyon verilerine aylık olarak ulaşılamadı. Bu ülkeler için "Küresel Atmosfer Araştırmaları için Emisyon Veritabanı (EDGAR - Emissions Database for Global Atmospheric Research)" adlı Avrupa Birliği'ne ait veritabanında yıllık veriler elde edildi. Diğer veriler ise Birleşmiş Milletler, IMF, OECD ve Avrupa Birliği resmi web sitelerinde bulunan verisetlerinden temin edildi. Bazı ekonomik veya finansal veriler, baz yıl olarak 2010 yılı verisi alınarak yüzdesel değerlere çevrildi ya da veri setine sahip kuruluş tarafından çevrilmiş haliyle kullanıldı.

Elde edilen verilerin güvenilirliği ve doğruluğu önemsenmiş ve eksik veri durumlarına uygun şekilde işlem yapılarak analizler için kullanılmıştır. Bu veriler, çalışmanın temelini oluşturan veri kaynakları olarak değerlendirilmiş ve çalışmanın sonuçlarına etkileri göz önünde bulundurulmuştur. Elde edilen Sera Gazı Emisyon verileri, ABD hariç olmak üzere yıllık veriler olarak elde edildi. Bu yıllık veriler, "Keeling Curve" dikkate alınarak her yıl için artan bir sinüzoidal grafik oluşturacak şekilde aylık verilere dönüştürüldü. ABD için ise bu veriler aylık olarak elde edildi ve analizde kullanıldı. Ülke nüfusu ve orman alanlarına ait yıllık veriler, o yıl içinde bulunan aylara aynı değerler olarak aktarıldı. Bunun haricinde, diğer giriş veriler, eğer yıllık olarak elde edilebildi ise her aya eşit olarak dağıtıldı. Çizelge 3.6 ABD, Çizelge 3.7 Almanya, Çizelge 3.8 İngiltere, Çizelge 3.9 Avustralya, Çizelge 3.10 Fransa ve

Çizelge 3.11 Türkiye için bu çalışmada kullanılacak tüm verilerin tanımları, birimleri hangi veri aralıklarına sahip olduğu ve verilerin kayıt periyotları görülmektedir.

Çizelge 3.6. Amerika Birleşik Devletleri için sera gazı emisyon tahminlemede kullanılan veriler

Tanım – ABD için Kullanılan Veriler	Birim	İlk Kayıtlı Veri Tarihi	Alınana Son Veri Tarihi	Veri Kayıt Periyodu
Toplam Enerji - CO ₂ Salınımı	Milyon Metrik Ton Karbondioksit	1973 Ocak	2022 Eylül	aylık
İnsani Gelişmişlik Endeksi	Endeks	1990	2021	yıllık
Ormanlaşma	Orman arazisi km ²	1990	2020	yıllık
Nüfus	insan	1970	2020	yıllık
Gayri Safi Milli Gelir - GSMH	Yüzdelik Oran - Baz Yıl 2010=100 (kişi başı ABD Doları)	1970	2021	yıllık
Net Milli Gelir	Yüzdelik Oran - Baz Yıl 2010=100 (kişi başı ABD Doları)	1970	2021	yıllık
Gayri Safi Yurt İçi Hasıla - GSYİH	Yüzdelik Oran - Baz Yıl 2010=100 (ABD Doları)	1970	2020	yıllık
Tüm Mallara ait Üretici Fiyatları Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Ağustos	aylık
Tüketici Fiyatları Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Aralık	aylık
Mevsimsel Düzeltmeli Sanayi Üretimi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Ağustos	aylık
Sanayi Üretimi Ekonomik Faaliyet Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Ağustos	aylık
Uzun Dönem Yatırım Oranları, Yıllık yüzde oranları	Yüzdelik Oran - Baz Yıl 2010=100	1973 Ocak	2022 Aralık	aylık
Toplam Birincil Enerji Tüketimi	Trilyon BTU	1973 Ocak	2022 Eylül	aylık
Toplam Yenilenebilir Enerji Tüketimi	Trilyon BTU	1973 Ocak	2022 Eylül	aylık

Çizelge 3.7. Almanya için sera gazı emisyon tahminlemede kullanılan veriler

Tanım	Birim	İlk Kayıtlı Veri Tarihi	Alınana Son Veri Tarihi	Veri Kayıt Periyodu
Sera Gazı Emisyon	Mton CO ₂ e	1970	2021	yıllık
İnsani Gelişmişlik Endeksi	Endeks	1990	2021	yıllık
Ormanlaşma	Orman arazisi km ²	1990	2020	yıllık
Nüfus	insan	1970	2020	yıllık

Gayri Safi Milli Gelir - GSMH	Yüzdelik Oran - Baz Yıl 2010=100 (kişi başı ABD Doları)	1970	2021	yıllık
Net Milli Gelir	Yüzdelik Oran - Baz Yıl 2010=100 (kişi başı ABD Doları)	1970	2021	yıllık
Gayri Safi Yurt İçi Hasıla - GSYİH	Yüzdelik Oran - Baz Yıl 2010=100 (ABD Doları)	1970	2020	yıllık
Tüm Mallara ait Üretici Fiyatları Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Kasım	aylık
Tüketici Fiyatları Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Aralık	aylık
Mevsimsel Düzeltmeli Sanayi Üretimi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Aralık	aylık
Finansal Piyasa Fiyatları Dönem Sonu Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2012 Aralık	aylık
Sanayi Üretimi Ekonomik Faaliyet Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Ekim	aylık
Uzun Dönem Yatırım Oranları, Yıllık yüzde oranları	Yüzdelik Oran - Baz Yıl 2010=100	1973 Ocak	2022 Aralık	aylık
Birincil Enerji	MLN_TOE	1970	2021	yıllık
Yenilenebilir Enerji	KTOE	1970	2019	yıllık

Çizelge 3.8. Birleşik Krallık için sera gazı emisyon tahminlemede kullanılan veriler

Tanım	Birim	İlk Kayıtlı Veri Tarihi	Alınana Son Veri Tarihi	Veri Kayıt Periyodu
Sera Gazı Emisyon	Mton CO ₂ e	1970	2021	yıllık
İnsani Gelişmişlik Endeksi	Endeks	1990	2021	yıllık
Ormanlaşma	Orman arazisi km ²	1990	2020	yıllık
Nüfus	insan	1970	2020	yıllık
Gayri Safi Milli Gelir - GSMH	Yüzdelik Oran - Baz Yıl 2010=100 (kişi başı ABD Doları)	1970	2021	yıllık
Net Milli Gelir	Yüzdelik Oran - Baz Yıl 2010=100 (kişi başı ABD Doları)	1970	2021	yıllık
Gayri Safi Yurt İçi Hasıla - GSYİH	Yüzdelik Oran - Baz Yıl 2010=100 (ABD Doları)	1970	2020	yıllık
Tüm Mallara ait Üretici Fiyatları Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Ekim	aylık
Tüketici Fiyatları Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Aralık	aylık

Mevsimsel Düzeltmeli Sanayi Üretimi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Ekim	aylık
Sanayi Üretimi Ekonomik Faaliyet Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Ekim	aylık
Uzun Dönem Yatırım Oranları, Yıllık yüzde oranları	Yüzdelik Oran - Baz Yıl 2010=100	1973 Ocak	2022 Aralık	aylık
Birincil Enerji	MLN TOE	1970	2021	yıllık
Yenilenebilir Enerji	KTOE	1970	2019	yıllık

Çizelge 3.9. Avustralya için sera gazı emisyon tahminlemede kullanılan veriler

Tanım	Birim	İlk Kayıtlı Veri Tarihi	Alınana Son Veri Tarihi	Veri Kayıt Periyodu
Sera Gazı Emisyon	Mton CO ₂ e	1970	2021	yıllık
İnsani Gelişmişlik Endeksi	Endeks	1990	2021	yıllık
Ormanlaşma	Orman arazisi km ²	1990	2020	yıllık
Nüfus	insan	1970	2020	yıllık
Gayri Safi Milli Gelir - GSMH	Yüzdelik Oran - Baz Yıl 2010=100 (kişi başı ABD Doları)	1970	2021	yıllık
Net Milli Gelir	Yüzdelik Oran - Baz Yıl 2010=100 (kişi başı ABD Doları)	1970	2021	yıllık
Gayri Safi Yurt İçi Hasıla - GSYİH	Yüzdelik Oran - Baz Yıl 2010=100 (ABD Doları)	1970	2020	yıllık
Tüm Mallara ait Üretici Fiyatları Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1987 Ocak	2022 Kasım	aylık
Mevsimsel Düzeltmeli Sanayi Üretimi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2021 Ocak	aylık
Finansal Piyasa Fiyatları Dönem Sonu Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2019 Ağustos	aylık
Sanayi Üretimi Ekonomik Faaliyet Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Ekim	aylık
Uzun Dönem Yatırım Oranları, Yıllık yüzde oranları	Yüzdelik Oran - Baz Yıl 2010=100	1973 Ocak	2022 Aralık	aylık
Birincil Enerji	MLN TOE	1970	2021	yıllık
Yenilenebilir Enerji	KTOE	1970	2019	yıllık

Çizelge 3.10. Fransa için sera gazı emisyon tahminlemesinde kullanılan veriler

Tanım	Birim	İlk Kayıtlı Veri Tarihi	Alınana Son Veri Tarihi	Veri Kayıt Periyodu
Sera Gazı Emisyon	Mton CO ₂ e	1970	2021	yıllık
İnsani Gelişmişlik Endeksi	Endeks	1990	2021	yıllık
Ormanlaşma	Orman arazisi km ²	1990	2020	yıllık
Nüfus	insan	1970	2020	yıllık
Gayri Safi Milli Gelir - GSMH	Yüzdelik Oran - Baz Yıl 2010=100 (kişi başı ABD Doları)	1970	2021	yıllık
Net Milli Gelir	Yüzdelik Oran - Baz Yıl 2010=100 (kişi başı ABD Doları)	1970	2021	yıllık
Gayri Safi Yurt İçi Hasıla - GSYİH	Yüzdelik Oran - Baz Yıl 2010=100 (ABD Doları)	1970	2020	yıllık
Tüm Mallara ait Üretici Fiyatları Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1995 Ocak	2022 Kasım	aylık
Tüketici Fiyatları Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Aralık	aylık
Mevsimsel Düzeltmeli Sanayi Üretimi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Ekim	aylık
Sanayi Üretimi Ekonomik Faaliyet Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Ekim	aylık
Uzun Dönem Yatırım Oranları, Yıllık yüzde oranları	Yüzdelik Oran - Baz Yıl 2010=100	1973 Ocak	2022 Aralık	aylık
Birincil Enerji	MLN TOE	1970	2021	yıllık
Yenilenebilir Enerji	KTOE	1970	2019	yıllık

Çizelge 3.11. Türkiye için sera gazı emisyon tahminlemesinde kullanılan veriler

Tanım	Birim	İlk Kayıtlı Veri Tarihi	Alınana Son Veri Tarihi	Veri Kayıt Periyodu
Sera Gazı Emisyon	Mton CO ₂ e	1970	2021	yıllık
İnsani Gelişmişlik Endeksi	Endeks	1990	2021	yıllık
Ormanlaşma	Orman arazisi km ²	1990	2020	yıllık
Nüfus	insan	1970	2020	yıllık

Gayri Safi Milli Gelir - GSMH	Yüzdelik Oran - Baz Yıl 2010=100 (kişi başı ABD Doları)	1970	2021	yıllık
Gayri Safi Yurt İçi Hasıla - GSYİH	Yüzdelik Oran - Baz Yıl 2010=100 (ABD Doları)	1970	2020	yıllık
Tüm Mallara ait Üretici Fiyatları Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1986 Ocak	2020 Nisan	aylık
Tüketici Fiyatları Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1970 Ocak	2022 Aralık	aylık
Mevsimsel Düzeltmeli Sanayi Üretimi	Yüzdelik Oran - Baz Yıl 2010=100	1986 Ocak	2022 Eylül	aylık
Sanayi Üretimi Ekonomik Faaliyet Endeksi	Yüzdelik Oran - Baz Yıl 2010=100	1985 Ocak	2022 Eylül	aylık
Birincil Enerji	MLN TOE	1970	2021	yıllık
Yenilenebilir Enerji	KTOE	1970	2019	yıllık

3.2.3. LSTM ile Derin Öğrenme (Deep Learning)

Uzun Kısa Süreli Bellek (LSTM - Long Short-Term Memory) ileri beslemeli yapay sinir ağlarından farklı olarak geri beslemeli bir yapıya sahiptir. LSTM yaklaşımı tahminleme metotlarında kullanılabilmektedir. LSTM ile grafik, ses tanıma, el yazısı tanıma gibi alanlarda kullanılabilmektedir.

Bu çalışmada, örnek olarak seçilen Amerika Birleşik Devletleri, Almanya, Birleşik Krallık, Avustralya, Fransa ve Türkiye için verilerle ilgili önçalışma bittikten sonra her bir veri girişi için ayrı yarı Matlab programında bulunan Deep Network Designer'dan faydalanıldı. Derin öğrenme tasarımı kütüphane katmanlarından faydalanılarak bir çalışma dizisi oluşturuldu. 5 farklı katman ile tahminleme için diziden diziye (Sequence-to-Sequence) LSTM regresyon modeli tercih edildi. Giriş katmanı olarak zaman serili bir dizi veri kullanıldı ve çıkış verisi olarak Regresyon modeli tercih edildi.

“Long Short-Term Memory (LSTM)” kullanılarak zaman serili veya sıralı verilerden tahmin etmek için kullanılacaktır. LSTM katmanında eğitilerek veri çıkışı sadece tek bir zaman serili veri girişi ile elde edildikten sonra ortaya çıkan veri olacaktır. LSTM katmanında 128 adet gizli katman tercih edildi. LSTM katmanı yinelemeli bir sinir ağı (RNN - Recurrent Neural Network) katmanıdır. Zaman serili verilerde bir

sonraki adımı zaman serisine bağlı olarak uzun dönemli olarak birbirleri ile olan bağımlılıkları öğrenen bir algortima kullanıldı.

Derin öğrenme metotlarında ortaya çıkacak modelin daha iyi performans vermesi amacı ile öğrenme aşamasında algoritmada yapılan değişiklikler ile modelin doğruluğunu geliştirmek için Düzenleme Teknikleri (Regularisation Technique) kullanılır. Burda aşırı öğrenme (overfitting) ve eksik öğrenme (underfitting) gibi sonuca etki edecek ve yeni gelecek veri için modelin daha doğru bir yaklaşımla en iyi sonuca ulaşması için kullanılan tekniklerdir. Bu tekniklerden en önemlileri L1, L2 ve Dropout tekniklerdir. “L2 Regülasyonu” ile ağırlık azaltma şeklinde bir teknik iken, “L1 Regülasyonu” ise ağırlıkların sıfıra doğru çevrerek ağ içindeki etkileri azaltılmaya çalışılmaktadır. “Dropout Regülasyon”da bazı nöronlar deaktif edilerek yapay sinir ağındaki gürültüleri ortadan kaldırmayı amaçlar. Bunun için belirli bir olasılık değeri olarak 0 ile 1 arasında bir aralık seçilir. Eğer ağırlıklar bu oranın altında ise burdaki gizli katmanlarda bulunan bazı “node”lar (düğüm) ağdan çıkartılır ve bu şekilde ağ hem daha kompakt hale gelir hem daha hızlı işlem yapar ve hemde gürültüler ortadan kalkmış olur. Olasılık değerini 1’e yakınlaşması daha fazla nöronun atılmasına sebep olur. Ancak sinir ağında “node”lardaki ağırlıkların büyük olması iyi eğitilmiş “node” kısımları olarak kabul edilir. Burdaki çalışmada “Dropout Layer” kullanılırken olasılık değeri ise 0,5 olarak seçildi.

Tamamen Bağlı Katman (Fully Connected Layer – FC Layer) bir önceki katmandaki nöron katmanına bağlanarak ağırlık matrisi ile yapılan işlemlere bir de sapmayı ekleyip çıkışları iyileştirmek için yapılan bir işlemdir. Burdaki çalışmada “Fully Connected Layer” kullanılarak çıkış verisi 1 olarak seçildi.

Son katman olarakta “Regresyon Katmanı” seçildi. Regresyon katmanı ile regresyon görevleri için Ortalama Kare Hatası (MSE – Mean Squared Error) hesaplanır ve modül sonucundan çıkan gerçek değer ile hedef değer arasında kare farklarının ortalamasını vererek uzaklığı hesaplayan mutlak bir değer verir.

“Deep Network Designer”da ağ sırasıyla tek satırlı veri girişi kullanılarak bir giriş katmanı, LSTM katmanı, “drop” katmanı, tek çıkış olacak FC (fully connected) ve regresyon katmanında oluşturuldu. 5 katmanlı “Sequence-to-Sequence LSTM Regression model”i ile yapılan analizde herhangi bir hata veya uyarı alınmadı. Şekil 3.1’de Matlab programı ile yapılan çalışmada “Deep Network Designer”da katmanlar tespit edilip, uygun ayarlar yapıldıktan sonra tasarının uygunluk kontrolü sonrası yapılan analiz sonucu görülebilir.

ANALYSIS RESULT					
	Name	Type	Activations	Learnables	
1	input Sequence input with 1 dimensions	Sequence Input	1	-	
2	lstm LSTM with 128 hidden units	LSTM	128	InputWeights RecurrentWe... Bias	512×1 512×... 512×1
3	drop 50% dropout	Dropout	128	-	
4	fc 1 fully connected layer	Fully Connected	1	Weights Bias	1×128 1×1
5	regressionoutput mean-squared-error	Regression Output	1	-	

Şekil 3.1. LSTM ile derin öğrenme aşamaları

Derin öğrenmede, iyi bir performans elde etmek için verinin büyüklüğü yeterince sağlanmalıdır. Ayrıca, derin öğrenmede “Eğitim Seçenekleri” (Training Options) bölümünde derin öğrenme ile ağı eğitmek için seçenekler görülüyor. “Solver” kısmında eğitim için SGDM (Stochastic Gradient Descent with Momentum), RMSProp (Root-mean square propagation) ve Adam (Adaptive Moment Estimation) iyileştirici seçenekleri seçilebilir. “Adam” ile farklı katmanlar için farklı öğrenme hızı belirlenebilir ve eğitim hızı açısından yüksek performans gösterir. Burdaki çalışmada 0.005 olarak öğrenme hızı seçildi. “MaxEpochs” 500, “Batch Size” 128, “Gradient Threshold” 1 ve “Gradient Threshold Method” ise “L2 norm” seçildi.

Derin öğrenmede iyi bir performans elde etmek için verinin büyüklüğü yeterince sağlanmalıdır. Ayrıca, derin öğrenmede ağı eğitimi esnasında eğriye göre ağı nasıl eğitildiği gözlemlenebilir. Yinelemeler ile ağı eğitime devam eder. Eğitim süreci içerisinde düzeltilmiş eğitim doğruluk çizgisi, düzeltilmemiş eğitim çizgisi ile doğrulama çizgisi görülebilir. Ayrıca kayıp eğitim doğruluk çizgisi, düzeltilmemiş eğitim çizgisi ile doğrulama çizgisi görülebilir.

Derin öğrenme sonrası eğitim verileri kullanılarak gelecekte birçok zaman adımlarında tahmin yapılarak model test edilir. Ardından tahminlemedeki değerlerle oluşan hataya göre ağı güncellenir ve eğitim ağına göre gelecek için tahmin verisi oluşturur.

3.2.4. CNN-RNN ile Derin Öğrenme (Deep Learning)

CNN modellemesine ön-eğitimli ağlar modelin öğrenme hızını artırdığından işlemlerin hızlı olması ile beraber doğruluk ile ilgili başarıyı artırdığı görülmüş olup, ağlar önceden oluşan benzer problemi örnek alarak buna bağlı ağırlıkları belirler ve yeni bir problem için en iyi daha iyi sonuçlar elde etmede faydalı olduğu ve aynı işlemleri tekrarlamak ihtiyacını azaltarak işlemi hızlandırır. Ön-eğitimli ağlar için ResNet50, DenseNet201, InceptionV3 ve Xception ağları kullanılabilir. ResNet (Residual Network), modelde artık değerler ve blokların (residual value/block) eklenmesi ile işlem yaparken. DenseNet'te ise eklenen bu değerler sonraki tüm katmanlara dahil edilerek eğitimi hızlandırır. Inception ön-eğitimli ağda ise CNN'de kullanılan öz-filtreleme katmanı ile havuzlama (pooling) katmanlarında yapılan işlemlerin aynı anda modüler şeklinde işlem yapar. Xception ağında ise bu Inception ağının üzerine eklenerek geliştirilen bir ağ olup akıllı derinlik evrişimi (depthwise convolution) ile akıllı nokta evrişimi (pointwise convolution) şeklinde uygulanır (Dandil, E. ve Serin, Z., 2020).

Tekrarlayan sinir ağı (RNN - Recurrent Neural Network), ileri beslemeli sinir ağları (feedforwarding neural network)'ndan ortaya çıkan bir modeldir. Zaman sıralı verileri işlediğinden konuşma tanıma gibi özellikli uygulamalarda kullanılır. Düğümler arasındaki bağlantıların bir döngü oluşturabildiği ve bazı düğümlerden gelen çıktıların aynı düğümlerle yapılan sonraki girdileri etkilemesine izin veren bir yapay sinir ağları sınıfıdır. Bu, zamansal dinamik davranış sergilemesine izin verir. İleri beslemeli sinir ağlarından türetilen RNN'ler, değişken uzunluklu girdi dizilerini işlemek için dahili durumlarını (bellek) kullanabilir. Bu, onları bölümlere ayrılmamış, bağlantılı el yazısı tanıma veya konuşma tanıma gibi görevlere uygulanabilir kılar.

Sanches (2023) tarafından “mathworks.com” web sitesinden yayınlanan örneğe göre önceki aylara bağlı olarak gelecek aylara ait tahminleme yapmak için CNN ile RNN birleştirilerek oluşturulmuş olan Hibrit bir örnek kullanılarak yapılan bu çalışmada CNN zaman adımlarında verilen diziye ait özellikler ile ilgili çıkarımları için kullanılırken, RNN ise zaman bağlı bir sonraki dizilerdeki değerleri tahminlemek için kullanıldı. Matlab araçlarından olan “Deep Learning Toolbox” ile kullanıldı. Bununla beraber yapılan örnekte Xception ağı mimarisi seçimi ile, 600 “MaxEpochs”lu, 0.00611 öğrenme hızı, ileri beslemeli öğrenme ve “adam” problem çözümü kullanıldı. % 90 kadar veri eğitim amaçlı kullanılırken, kalan % 10'luk veri ise test amaçlı kullanılmış oldu. CNN ile bir dizi geri inceleme ile özellikler ağı aktarılıp bir sonraki adım için

tahminleme yapılır ve eğer ihtiyaç olursa Bayesian Optimizasyon kullanılabilir. Bu aşamalardan sonra “Deep Learning Toolbox“ ile eğitim aşaması yapılır ve ardından bilinen değerlere göre test yapılır ve sMAPE (Symmetric Mean Asolute Percentage Error - Simetrik Ortalama Mutlak Yüzde Hatası) ile yüzde hataya dayalı doğrulama ölçüsü ile test edilen değer ile tahmin edilen değer arasında bir korelasyon yöntemi ile sonuçlar standartlaştırılarak yorumlanır ve test dizisi ile tahmin değerleri arası korelasyon ile R-kare ve RMSE değerlerine bakılır. Bu aşamalardan sonra eğitilmiş ağ ile gelecek veriler yani son diziden sonraki adımlar için tahminleme yapar.

CNN-RNN algoritmaları beraber kullanılarak hibrit olarak yapılan bu çalışma sonucunda, Amerika Birleşik Devletleri, Almanya, Birleşik Krallık, Avustralya, Fransa ve Türkiye’nin Sera Gazı Emisyon miktarlarının gelecek 63 ay için belirlenmesi için önceden kullanılan LSTM algoritması sonuçları ile karşılaştırılmaları yapıldı. Böylece sadece hedef veriler için doğrulukları karşılaştırılarak bir sonraki yapılacak yapay sinir ağları çalışmasında da önceden bir karşılaştırma yapılmış oldu.

3.2.5. Yapay Sinir Ağları

Amerika Birleşik Devleti, Almanya, Birleşik Krallık, Avustralya, Fransa ve Türkiye için Çizelge 3.12’de bulunan verilere göre farklı ülkeler için farklı veriler kullanılarak derin öğrenmede gelecek ile ilgili tahminler yapıldı. Bu aşamadan sonra farklı ülkeler için ilgili veriler kullanılarak yapay sinir ağında kullanılan zaman serili sinir ağı aracı ile tahminleme yapıldı ve bu tahminleme test edilerek çıkan sonucun doğruluğuna bakıldı. Kullanılan zaman sıralı sinir ağı aracı (Neural Network Time Series) olarak aşağıdaki tabloda belirtilen “+” işareti olan verilerle işlem yapıldı.


Çizelge 3.12. Amerika Birleşik Devletleri (USA), Almanya (DEU), Birleşik Krallık (GBR), Avustralya (AUS), Fransa (FRA) ve Türkiye (TUR) için sera gazı emisyon tahminlemesinde “+” ile işaretlenen veriler kullanıldı

Tanım	USA	DEU	GBR	AUS	FRA	TUR
Toplam Enerjinin CO ₂ Salınımı	+	-	-	-	-	-
Sera Gazı Emisyon	-	+	+	+	+	+
İnsani Gelişmişlik Endeksi	+	+	+	+	+	+
Ormanlaşma	+	+	+	+	+	+
Nüfus	+	+	+	+	+	+

Gayri Safi Milli Gelir - GSMH	+	+	+	+	+	+
Net Milli Gelir	+	+	+	+	+	-
Gayri Safi Yurt İçi Hasıla - GSYİH	+	+	+	+	+	+
Tüm Mallara ait Üretici Fiyatları Endeksi	+	+	+	+	+	+
Tüketici Fiyatları Endeksi	-	+	+	-	+	+
Mevsimsellikten Arındırılmış Sanayi Üretimi	+	+	+	+	-	+
Finansal Piyasa Fiyatları Dönem Sonu Endeksi	+	+	-	+	+	-
Sanayi Üretimi Ekonomik Faaliyet Endeksi	+	+	+	+	+	+
Uzun Dönem Yatırım Oranları	+	+	+	+	+	-
Birincil Enerji	-	+	+	+	+	+
Yenilenebilir Enerji	-	+	+	+	+	+
Toplam Birincil Enerji Tüketimi	+	-	-	-	-	-
Toplam Yenilenebilir Enerji Tüketimi	+	-	-	-	-	-

Her veri için ayrı ayrı Deep Network Designer kullanarak 1970 yılı Ocak ayından 2022 Aralık ayına kadar olan bilinen veriler ile mevcut bilginin yüzde 10'u kadar data elde edildi. Yani 2023 Ocak ayı ile 2028 Mart ayına kadar gelecek için tahminler oluşturuldu. Bu durumda her veri için 636 aylık veri ile yapılan tahminlemede 63 aylık gelecekte tahmin edilen veriler elde edildi. Toplamda 699 aylık veriye sahip olunmuş oldu.

Şekil 3.2'de görüleceği şekilde Matlab'de "ntstool" ile "NARX Neural Network" kullanarak bir ağ yapısı oluşturuldu.



Şekil 3.2. NARX (Nonlinear AutoRegressive with eXternal (eXogenous) Input) model yapısı ($x(t)$ giriş dizileri, d $y(t)$ 'nin geçmiş değerleri, $y(t)$ tahmin dizileri)

Doğrusal Olmayan Oto regresif Dışsal Girdiler (NARX - Nonlinear AutoRegressive with eXternal (eXogenous) Input) ile oluşturulan modelleme ile rastgele yapılan seçimlerle Bayesian Regülasyon" eğitimi sonrası "ortalama kare hatası


(MSE – Mean Squared Error)” ve “korelasyon katsayısı (R)” ile performans ölçümü kullanıldı.

NARX modelleme ile zaman serili verilerde tahmin amaçlı kullanılabilir. Geri beslemeli olarak kullanılan ağda genellikle lineer olmıyan veri girişlerinde kullanılan dinamik bir yapay sinir ağı modelidir (Alizadeh, M., 2011).

Matlab “ntstool”da NARX modeli seçildikten sonra yapılan işlemde Amerika Birleşik Devletleri için “Toplam Enerjinin CO₂ Salınımı” çıkış verisi olarak seçildi, diğerleri giriş verisi olarak seçildi. Diğer ülkeler için ise “Sera Gazı Emisyon” verisi hedef veri olarak seçilip diğer veriler giriş verileri olarak kullanıldı.

Rastgele olarak yapılan seçimlerde verilerin % 70’i eğitim amaçlı kullanıldı ve hata oranlarına göre eğtiliyor. Doğrulama kısmı için % 15’lik bir veri kullanıldı ve eğitim aşamasında doğrulama verilerine göre eğitildiğini gösterir ve doğrulama değerlerine ulaşıldığında eğitim bitmiş olur. Test kısmı için ise % 15’lik kalan kısım kullanıldı ve eğitim kısmını etkilemeyecek verilerden oluşmaktadır.

NARX sinir ağı modelinde kullanılmak istenen gizli katman sayıları ile gecikme seçildi. Ağ “open loop” olarak seçildi, bu şekilde yapılan eğitimde eğer ihtiyaç duyulursa uygulama “closed loop” veya başka bir formada dönüşebilir. Şekil 3.3’te örnek olarak Matlab “ntstool” ile “NARX Neural Network” uygulaması seçildikten sonra kullanılan giriş veri sayısı, sonuç veri sayısı, gizli ve çıkış katman bilgileri ile çıkış veri sayıları görülebilir. Ayrıca gizli katmanda giriş ve çıkış veriler arasındaki zamana aralığının da gösterir yuvarlak şekil içinde gösterir. "ntstool" aracında "number of delays (d)" ifadesi, giriş ve çıkış verileri arasındaki zaman aralığını ifade eder. Bu parametre, geçmiş verilerin gelecek tahminlerinde kullanılacağı zaman aralığını belirler. Yüksek bir d değeri, daha uzun zaman aralığını dikkate alarak tahmin yapmaya olanak tanırken, daha düşük bir d değeri, daha kısa zaman aralığını dikkate alarak tahmin yapmaya neden olur. Bu parametre, doğru tahminler yapmak için önemlidir.



Şekil 3.3. Matlab uygulamasından alınan örnek bir sinir ağı modeli

Eğitim algoritması olarak 3 seçenek mevcuttur. Bunlar “Levenberg-Marquardt”, “Bayesian Regularisation”, “Scaled Conjugate Gradient”tır. Gürültülü ve çok fazla verinin olmadığı veri setleri için Bayesian algoritması biraz zaman alsada iyi sonuçlar vermektedir.

“Bayesian Regularization” ile yapılan eğitim sonucunda MSE (ortalama kare hata) hedef değer ile çıkış arasındaki ortalama karelerin farkını gösteren bir değer iken R değeri (korelasyon değeri) ise hedef ile çıkış değerleri arasındaki korelasyon değerini gösteren regresyon değeridir. R değeri 1’e yaklaştıkça yakın sonuçlar verir. Yapılan eğitimin amacıda bu sonuca mümkün oldukça yaklaşılmaktır.

4. BULGULAR VE TARTIŞMA


Yapılan çalışmada, Amerika Birleşik Devletleri, Almanya, Birleşik Krallık, Avustralya, Fransa ve Türkiye için 1970 Ocak ayından 2022 Aralık ayına kadar olan veriler kullanılarak, 2023 Ocak ayından 2028 Mart ayına kadar olan muhtemel veriler Matlab programı kullanılarak aylık olarak tahmin edilmiştir. Hem LSTM hem de CNN-RNN ile hibrit bir şekilde yapılan iki ayrı çalışmada sadece Sera Gazı Emisyon verilerinin gelecek için yapılan tahmini değerleri bulunmuş. Daha sonra bu tahminler karşılaştırılmıştır. Karşılaştırılan değerlerin birbirlerine yakın değerlere sahip oldukları ortaya çıkmıştır. Sera Gazı Emisyon değerli hedef veri seçilip diğer verilerde giriş verisi olarak kullanılarak NARX Sinir Ağı modeli ile yapılan YSA çalışmasında ise bir ülkedeki Sera Gazı Emisyon miktarları hedef veri seçilerek birincil ve yenilenebilir enerji tüketimleri, ekonomik ve finansal veriler, popülasyon, ormanlaşma ile insani gelişim endeks verileri arasında ilişkiler ortaya konulmuş oldu.

4.1. LSTM ile Gelecek Tahminlemeleri


Derin öğrenme LSTM Algoritması ile yapılan tahminlemede Amerika Birleşik Devletleri için 14, Almanya için 15, İngiltere için 14, Avustralya için 14, Fransa için 14 ve Türkiye için 12 adet veri girişleri kullanılmıştır. Bu verilerden birer adedi sera gazı emisyonu ile ilgili verilerdir.

Her veri girişi için derin öğrenmede LSTM Regresyon algoritması kullanılarak eğitim yapılmıştır. Şekil 4.1'de Almanya için sera gazı emisyonuna ait "Deep Learning Designer" kullanılarak elde edilen Sera Gazı Emisyon verilerine ait grafiği görülebilir.

Yapılan tüm eğitimlerde, RMSE (Root Mean Square Error) değeri 0.3 ile 0.1 arasında değişen değerlere ulaşmıştır. Bu da modellerin iyi eğitildiğini ve tahminlemede gerçek değerlere daha yakın hale gelmiş olduğunu gösterir. Ayrıca derin öğrenmedeki amaçlardan biri de hata değerlerini minimize etmektir. Derin öğrenme grafiğinde bu durum "Loss" eğrisi ile takip edilir ve yapılan çalışmada tüm veriler için "Loss" eğri değerleri 0'a yakın olarak sonuçlanmıştır. Şekil 4.2 'de örnek olarak Almanya için sera gazı emisyonuna ait "Deep Learning Designer" kullanılarak elde edilen Sera Gazı Emisyon verilerine ait eğitim sonucu elde edilen RMSE ve Loss grafikleri "iterasyon" sayısına göre sonuçları elde edilmiştir.




Şekil 4.1. Almanya için aylık olarak Mton CO₂e cinsinden “Sera Gazı Emisyon” grafiği




Şekil 4.2. Almanya için “Derin Öğrenme” LSTM algoritması ile elde edilen eğitim sonucu

Şekil 4.3’de Almanya için “Sera Gazı Emisyon”un derin öğrenmede yapılan eğitim sonrası 2023 Ocak ayı sonrası 63 aylık gelecek için tahmin verileri ile ilgili oluşan grafik görülmektedir. Ayrıca Şekil 4.4’de gelecek 63 aya ait tahmini değerleri görülebildiği gibi RMSE değeri 1,7977 olarak oluştuğu gözlemlenmektedir.



Şekil 4.3. Almanya için yıllık “Sera Gazı Emisyon”un “Derin Öğrenme”de eğitim sonrası için yapılan tahmini değerlerin grafiksel gösterimi



Şekil 4.4. Almanya yıllık “Sera Gazı Emisyon”un “Derin Öğrenme”de eğitim sonrası gelecek için yapılan tahmini değerler için hata değerleri

Derin öğrenme kullanılarak yapılan eğitim sonucunda tahmin edilen gelecek verileriyle beraber RMSE sonuçları verilerdeki tüm değerler arasındaki en yüksek değere göre yüzdesel oranları ile kıyasla çok düşük kalmaktadır.

ABD için Çizelge 4.1’de RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları yüzde 5’in altında görülmektedir.

Çizelge 4.1. ABD için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte

Tanım	En Yüksek Değer	RMSE	RMSE'nin En yüksek değere göre yüzdesel oranları
Toplam Enerjinin CO ₂ Salımı	560.77	27.56	4.914546071
İnsani Gelişmişlik Endeksi	0.93	0.00	0.280473505
Ormanlaşma	3100950.00	1717.50	0.055386253
Nüfus	328061423340	3026763.44	0.922620956
Gayri Safi Milli Gelir - GSMH	157.60	3.82	2.426800261
Net Milli Gelir	154.80	4.64	2.995560233
Gayri Safi Yurt İçi Hasıla - GSYİH	133.37	2.969	2.226214247
Tüm Mallara ait Üretici Fiyatları Endeksi	137.34	1.72	1.255222449
Finansal Piyasa Fiyatları Dönem Sonu Endeksi	141.08	4.17	2.957979744
Mevsimsellikten Arındırılmış Sanayi Üretimi	114.26	3.0039	2.629033725
Sanayi Üretimi Ekonomik Faaliyet Endeksi	115.82	3.35	2.894096362
Uzun Dönem Yatırım Oranları, Yıllık yüzde oranları	15.32	0.21	1.338772846
Toplam Birincil Enerji Tüketimi	9664.30	358.94	3.714064517
Toplam Yenilenebilir Enerji Tüketimi	1200.25	51.3992	4.282378073

Almanya için Çizelge 4.2’de RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları yüzde 7,6’nin altında görülmektedir.

Çizelge 4.2. Almanya için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte

Tanım	En Yüksek Değer	RMSE	RMSE'nin En yüksek değerine göre yüzdesel oranı
Sera Gazı Emisyon	215,32	1,7977	0,83490556
İnsani Gelişmişlik Endeksi	0,94	0,0079	0,841213413
Ormanlaşma	114190,00	29,50	0,025832472

Nüfus	83892362	91365,00	0,108907411
Gayri Safi Milli Gelir - GSMH	150,40	2,6945	1,791593792
Net Milli Gelir	148,13	1,6013	1,080982985
Gayri Safi Yurt İçi Hasıla - GSYİH	148,13	2,0027	1,351954427
Tüm Mallara ait Üretici Fiyatları Endeksi	156,28	3,3383	2,136154485
Tüketici Fiyatları Endeksi	131,02	2,3308	1,778975312
Mevsimsellikten Arındırılmış Sanayi Üretimi	117,64	5,2001	4,420175809
Finansal Piyasa Fiyatları Dönem Sonu Endeksi	154,60	0,458	0,296249443
Sanayi Üretimi Ekonomik Faaliyet Endeksi	126,27	9,5943	7,598249244
Uzun Dönem Yatırım Oranları, Yıllık yüzde oranları	10,80	0,2354	2,17962963
Birincil Enerji	30504,83	269,95	0,884928946
Yenilenebilir Enerji	37098001,44	451140,00	1,216076291

İngiltere için Çizelge 4.3’de RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları “Yenilenebilir Enerji” hariç yüzde 7’nin altında görülmektedir.

Çizelge 4.3. İngiltere için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte

Tanım	En Yüksek Değer	RMSE	RMSE'nin En yüksek değerine göre yüzdesel oranı
Sera Gazı Emisyon	778.89	2.15	0.275557422
İnsani Gelişmişlik Endeksi	0.93	0.00	0.246445933
Ormanlaşma	31950.35	47.58	0.148903829
Nüfus	67354120	529000.00	0.785401094
Gayri Safi Milli Gelir - GSMH	135.77	3.7728	2.778918945
Net Milli Gelir	136.15	3.4168	2.509654826
Gayri Safi Yurt İçi Hasıla - GSYİH	128.77	2.8632	2.223579367
Tüm Mallara ait Üretici Fiyatları Endeksi	151.07	3.42	2.261706126
Tüketici Fiyatları Endeksi	139.45	1.87	1.343306222
Mevsimsellikten Arındırılmış Sanayi Üretimi	121.72	3.94	3.237508747
Sanayi Üretimi Ekonomik Faaliyet Endeksi	134.48	8.60	6.395527327
Uzun Dönem Yatırım Oranları, Yıllık yüzde oranları	16.34	0.30	1.823133415
Birincil Enerji	18808.83	263.4198	1.400511107
Yenilenebilir Enerji	17840042.92	662590.00	3.714060572

Avustralya için Çizelge 4.4’de RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları yüzde 2,5’nin altında görülmektedir.

Çizelge 4.4. Avustralya için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte

Tanım	En Yüksek Değer	RMSE	RMSE'nin En yüksek değerine göre yüzdesel oranı
Sera Gazı Emisyon	89,65	1,76	1,961097224
İnsani Gelişmişlik Endeksi	0.95	0.0018	0.189274448
Ormanlaşma	1340372,00	354,20	0,026425753
Nüfus	25619683	141860,00	0,553714882
Gayri Safi Milli Gelir - GSMH	145,33	1,9639	1,351344874
Net Milli Gelir	144,22	1,8942	1,313380491
Gayri Safi Yurt İçi Hasıla - GSYİH	118,41	1,3647	1,152539126
Tüm Mallara ait Üretici Fiyatları Endeksi	120,74	1,8626	1,542623029
Mevsimsellikten Arındırılmış Sanayi Üretimi	121,73	2,74	2,249455871
Finansal Piyasa Fiyatları Dönem Sonu Endeksi	145,75	3,17	2,172253733
Sanayi Üretimi Ekonomik Faaliyet Endeksi	128,49	2,24	1,742976874
Uzun Dönem Yatırım Oranları, Yıllık yüzde oranları	16,50	0,19	1,145454545
Birincil Enerji	10916,83	133,3167	1,221203035
Yenilenebilir Enerji	7837515,00	39672,00	0,506180849

Fransa için Çizelge 4.5’de RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları yüzde 5’nin altında görülmektedir.

Çizelge 4.5. Fransa için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte

Tanım	En Yüksek Değer	RMSE	RMSE'nin En yüksek değerine göre yüzdesel oranı
Sera Gazı Emisyon	105,52	1,9022	1,802652065
İnsani Gelişmişlik Endeksi	0,91	0,0062	0,680366042
Ormanlaşma	172530,00	295,42	0,171227323
Nüfus	67515709	368080,00	0,545176827
Gayri Safi Milli Gelir - GSMH	144,59	2,5431	1,75888391
Net Milli Gelir	140,54	2,3624	1,68093698
Gayri Safi Yurt İçi Hasıla - GSYİH	111,66	1,1783	1,055302227
Tüm Mallara ait Üretici Fiyatları Endeksi	147,70	2,93	1,983293768
Tüketici Fiyatları Endeksi	129,30	1,67	1,290372268
Mevsimsellikten Arındırılmış Sanayi Üretimi	115,89	4,75	4,096631263
Sanayi Üretimi Ekonomik Faaliyet Endeksi	123,89	0,24	0,190727405

Uzun Dönem Yatırım Oranları, Yıllık yüzde oranları	17,32	0,2289	1,321593533
Birincil Enerji	22721,50	304,99	1,342307506
Yenilenebilir Enerji	21489417,83	301970,00	1,40520326

Türkiye için Çizelge 4.6’da RMSE değerleri yüzde 11.5 civarlarına ulaşan değerler görülebilmektedir. Ancak genel olarak yapılacak çalışmayı etkilemeyecek seviidedirler.

Çizelge 4.6. Türkiye için RMSE değerleri ve RMSE değerlerinin en yüksek değere göre oranları görülmekte

Tanım	En Yüksek Değer	RMSE	RMSE'nin En yüksek değerine göre yüzdesel oranı
Sera Gazı Emisyon	94,07	7,2559	7,713234463
İnsani Gelişmişlik Endeksi	0,85	0,0044	0,520502626
Ormanlaşma	221257,50	902,44	0,407869972
Nüfus	84951197	578260,00	0,680696704
Gayri Safi Milli Gelir - GSMH	117,25	1,4668	1,251027961
Gayri Safi Yurt İçi Hasıla - GSYİH	117,43	1,9891	1,693839015
Tüm Mallara ait Üretici Fiyatları Endeksi	271,00	17,49	6,453204511
Tüketici Fiyatları Endeksi	625,15	72,15	11,54145272
Mevsimsellikten Arındırılmış Sanayi Üretimi	211,34	17,56	8,306708832
Sanayi Üretimi Ekonomik Faaliyet Endeksi	238,67	24,4698	10,25239306
Birincil Enerji	13187,42	355,1154	2,692835215
Yenilenebilir Enerji	19485138,67	1420200,00	7,288631733

Ayrıca, her ülke için pandemi dönem öncesi olan 2019 yılının ilk 8 ay gerçek değerleri ile 2026 yılının ilk 8 ayı için tahmini olarak hesaplanmış değerlerin karşılaştırmaları Çizelge 4.7’de görülmektedir. Yapılan tahminlerde, 2026 yılı içerisinde Sera Gazı Emisyon değerlerinin 2019 yılına göre düşüşe geçeceği tahmin edilmiştir.


Çizelge 4.7. “Mton CO₂e” cinsinden 2019 yılı ilk 8 ay gerçek ve 2026 yılı ilk 8 ay tahmini Sera Gazı Emiyon değerleri

Ülkeler	Yıllar	1	2	3	4	5	6	7	8
ABD	2019	499.59	432.65	448.42	383.10	398.97	401.85	442.43	443.76
	2026	401.84	402.41	412.93	414.87	388.59	403.85	377.58	363.22
Almanya	2019	81.77	106.31	89.95	57.24	32.71	73.60	98.13	122.66
	2026	61.88	61.87	61.86	61.85	63.88	64.66	64.73	64.66
İngiltere	2019	45.60	59.29	50.17	31.92	18.24	41.04	54.73	68.41
	2026	34.60	34.67	34.81	34.91	35.87	36.36	36.31	36.05
Avustralya	2019	58.49	76.04	64.34	40.95	23.40	52.64	70.19	87.74
	2026	47.76	47.76	47.79	47.86	47.51	47.46	47.63	47.78
Fransa	2019	44.85	58.31	49.34	31.40	17.94	40.37	53.82	67.28
	2026	17.25	9.66	19.94	38.86	51.03	44.16	28.49	16.52
Türkiye	2019	58.53	76.09	64.38	40.97	23.41	52.68	70.24	87.79
	2026	47.23	47.23	47.23	47.23	50.29	50.36	50.34	50.33

4.2. CNN-RNN ve LSTM Sera Gazı Emisyonu Gelecek Tahminlemelerinin Karşılaştırılması

Derin öğrenme CNN-RNN hibrit modeli ile sera gazı emisyon verileri kullanılarak gelecek aylara ait tahminelemeler elde edildi.

Derin öğrenmede LSTM Regresyon algoritması kullanılarak eğitim haricinde Matlab programı ile gelecek tahminlemesi için CNN-RNN modellerinin beraberce kullanıldığında Şekil 4.5 gibi ABD için elde edilmiş R değerini gösteren bir Regresyon grafiği elde edilmiştir.



Şekil 4.5. ABD için CNN-RNN modellerinin Hibrit bir şekilde kullanılması ile ortaya çıkan Regresyon değeri


Derin öğrenme CNN-RNN hibrit modeli ile sera gazı emisyon verileri ile yapılan eğitimin sonucunda ortaya çıkan R değerlerinin karşılaştırılması Çizelge 4.7’de görülebilir. Burda da görüldüğü üzere değerler 1’e yakın olduklarından eğitimlerin başarılı olduğu ve tahminleme çalışmalarına uygun olduğu görülmüştür.

Çizelge 4.7. ABD, Almanya, İngiltere, Avusturya, Fransa ve Türkiye için Sera Gazı Emisyon verileri ile Derin Öğrenme’de CNN-RNN hibrit algoritması ile yapılan modelleme sonucunda elde edilen R değerleri


	ABD	Almanya	İngiltere	Avustralya	Fransa	Türkiye
R değeri	0,86814	0,99012	0,99231	0,99829	0,99339	0,96966

Şekil 4.6 ABD, Şekil 4.7 Almanya, Şekil 4.8 İngiltere, Şekil 4.9 Avustralya, Şekil 4.10 Fransa ve Şekil 4.11 Türkiye için CNN-RNN ile Hibrit şekilde uygulanan derin öğrenme yöntemi sonucu elde edilen gelecek sera gazı emisyon tahminleri ile


LSTM ile derin öğrenme yöntemi sonucu ortaya çıkan gelecek sera gazı emisyon karşılaştırması, 2027 yılı içinde aylık olarak elde edilmiş tahmini değerleri içermektedir. Gözlemlendiği üzere, sonuçlar birbirine yakın bir şekilde oluşmaktadır.




Şekil 4.6. ABD için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları




Şekil 4.7. Almanya için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları




Şekil 4.8. İngiltere için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları



Şekil 4.9. Avusturya için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları



Şekil 4.10. Fransa için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları



Şekil 4.11. Türkiye için, mavi çizgi CNN-RNN ile Hibrit şekilde uygulanan Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyon tahminlemesi, kırmızı çizgi LSTM ile Derin Öğrenme yöntemi sonucu elde edilmiş gelecek sera gazı emisyonu ve karşılaştırmaları


4.3. YSA Sonuçları

Bu aşamada Matlab programında mevcut "ntstool" uygulaması ile ilgili ülke için LSTM algoritması kullanılarak derin öğrenme yöntemi ile gelecek tahminlemesi verileri hesaplandı. Ardından, LSTM algoritması ile hesaplanan gelecek tahmin verileri ile tüm

giriş verileri ve aynı zamanda hedef veri olan sera gazı emisyon verileri kullanılarak gelecek tahminler dahil mevcut tahminler gerçekleştirildi.


Bu çalışmanın ana amacı, ilgili ülke için sera gazı emisyon hesaplamasına etki eden faktörleri bir araya getirerek bu faktörler arasındaki ilişkiyi yapay sinir ağı kullanarak başarılı bir şekilde kurmaktır. Yapay sinir ağı yöntemi kullanılarak (Bayes) Bayesian Regülasyon eğitim algoritması ile zaman serili NARX sinir ağı modeli incelendi.

Şekil 4.12’de ABD için, Matlab “ntstool” ile “NARX Neural Network” uygulaması seçildikten sonra kullanılan 13 adet zaman serili giriş veri sayısı, 1 adet zaman serili sonuç veri sayısı, 12 adet gizli katmanlar ve 1 adet çıkış katmanı ile çıkış veri sayıları görülebilir. Giriş ve çıkış verileri arasındaki zaman aralığı veya gecikme sayısı 5 olarak seçilerek, tahmin sonuçları elde edildi.



Şekil 4.12. ABD için, NARX ağ modelinin genel görünümü (Gizli katmandaki nöron sayısı ve gecikme katsayısı ile beraber)

Matlab “ntstool” ile “NARX Neural Network” uygulaması seçildikten sonra kullanılan zaman serili giriş veri sayısı bu çalışmada değerlendirilen diğer ülkeler için farklı olmasına rağmen, 1 adet zaman serili sonuç veri sayısı, 10 adet gizli katmanlar ve 1 adet çıkış katmanı ile çıkış veri sayıları görülebilir. Giriş ve çıkış verileri arasındaki zaman aralığı 2 olarak seçilerek, tahmin sonuçları elde edildi. Şekil 4.13’te kullanılan zaman serili veri giriş adedi Almanya ve İngiltere için 14’er adet iken, Avusturya ve Fransa için 13 ve Türkiye için 11 adettir.



Şekil 4.13. Almanya ve İngiltere için, NARX ağı modelinin genel görünümü (Gizli katmandaki nöron sayısı ve gecikme katsayısı ile beraber)

ABD için yapılan çalışmada gizli katman sayısı 10 ve gecikme sayısı 2 olarak seçildiğinde R değeri 0.96974 elde edilirken, test için R değeri 0.67255 ile istenen değere ulaşılmadı. Ancak farklı gizli katmanlar ve gecikme sayıları ile denemeler yapılabilir. Bu şekilde hem eğitim hem de testte ait R değerlerine bakılarak araştırma için gizli katman ve gecikme değerleri seçilebilir. Farklı gizli katman ve gecikme değerleri için yapılan işlemlerden örnek olarak ABD için Çizelge 4.8, Almanya için Çizelge 4.9 ve İngiltere için Çizelge 4.10 görülebilir. Tabii ki benzer verilerle tekrar tekrar denendiğinde farklı R değerleri elde etmek mümkündür, bu nedenle en uygun olan değerler görüldüğünde çalışma sonlandırılabilir. Bu çalışmada, ABD gizli katman 15 ve gecikme değeri 5 seçildi, diğer ülkeler için gizli katman sayıları 10 ve gecikme sayıları 2 olarak tercih edildi.

Çizelge 4.8. ABD için YSA “ntstool” aracı ile kullanılan NARX Bayesian modeli ile yapılan eğitim ve test için elde edilen R değerleri

ABD		R değeri		Süreç Tamamlanma Nedeni
Gizli Katman Sayısı	Gecikme Sayısı (d)	Eğitim	Test	
9	2	0.98945	0.90050	Mu Katsayısı
9	5	0.97756	0.85609	Mu Katsayısı
10	2	0.98882	0.91281	Mu Katsayısı
10	5	0.96774	0.92773	Mu Katsayısı
14	2	0.99650	0.92802	Mu Katsayısı
14	5	0.97995	0.87176	Mu Katsayısı
15	5	0.99616	0.93254	Mu Katsayısı
15	2	0.96987	0.67255	Mu Katsayısı
16	2	1.00000	0.86903	Mu Katsayısı
16	5	0.98008	0.81632	Mu Katsayısı
20	2	0.99972	0.96141	Mu Katsayısı
20	5	1.00000	0.99525	Mu Katsayısı


Çizelge 4.9. Almanya için YSA “ntstool” aracı ile kullanılan NARX Bayesian modeli ile yapılan eğitim ve test için elde edilen R değerleri

Almanya		R değeri		
Gizli Katman Sayısı	Gecikme Sayısı (d)	Eğitim	Test	Süreç Tamamlanma Nedeni
8	2	0.95825	0.91331	Mu Katsayısı
8	5	0.98385	0.94453	Mu Katsayısı
9	2	0.95990	0.71675	Mu Katsayısı
9	5	0.99093	0.93738	Mu Katsayısı
10	2	0.99896	0.97168	Mu Katsayısı
10	5	0.99172	0.95171	Mu Katsayısı
11	2	0.95885	0.91246	Mu Katsayısı
11	5	0.99194	0.91243	Mu Katsayısı
12	2	0.96468	0.70220	Mu Katsayısı
12	5	0.99379	0.92410	Epoch Sayısı
20	2	0.98517	0.82370	Mu Katsayısı
20	5	0.99982	0.86287	Mu Katsayısı


Çizelge 4.10. İngiltere için YSA “ntstool” aracı ile kullanılan NARX Bayesian modeli ile yapılan eğitim ve test için elde edilen R değerleri

İngiltere		R değeri		
Gizli Katman Sayısı	Gecikme Sayısı (d)	Eğitim	Test	Süreç Tamamlanma Nedeni
8	2	0.99943	0.99407	Mu Katsayısı
8	5	0.99992	0.99653	Mu Katsayısı
9	2	0.99964	0.99814	Mu Katsayısı
9	5	0.99995	0.99780	Mu Katsayısı
10	2	0.99843	0.97529	Mu Katsayısı
10	5	0.99999	0.99906	Mu Katsayısı
11	2	0.99805	0.98896	Mu Katsayısı
11	5	0.99998	0.99899	Mu Katsayısı
12	2	0.99866	0.99489	Mu Katsayısı
12	5	0.99999	0.99881	Mu Katsayısı
20	2	0.99967	0.99108	Mu Katsayısı
20	5	1.00000	0.99778	Epoch Sayısı


ABD için Şekil 4.14’de, Almanya için Şekil 4.15’de, İngiltere için Şekil 4.16’da, Avusturalya için Şekil 4.17’de, Fransa için Şekil 4.18’de ve Türkiye için Şekil 4.19’da eğitimle ilgili algoritmalar ve süreçle ilgili bilgileri göstermektedir. Yapılan sinir ağı eğitimlerinde “Mu” katsayısı ile nöronlarda ağırlıkların en iyi performansa ulaştığı ve daha fazla iyileştirme olmadığı için eğitimler sona erdi.




Şekil 4.14. ABD için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler




Şekil 4.15. Almanya için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler




Şekil 4.16. İngiltere için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler



Şekil 4.17. Avustralya için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler



Şekil 4.18. Fransa için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler




Şekil 4.19. Türkiye için eğitimle ilgili algoritmalar ve süreçle ilgili bilgiler

Yapay sinir ağları ile yüzde 75'lik veri ile eğitim için kullanılmış, yüzde 15'lik veri ile doğrulama yapmak ve yüzde 15'lik kalan veri ile de test yapmak için kullanılmıştır.


Regresyon "R" değeri, çıkış verileri ile hedef veri arasındaki korelasyonu ölçerek iki veri arasındaki ilişkiyi değerlendirir. Eğer "R" değeri 1'e yakın bir değerse, çıkış verileri ile hedef veri arasında güçlü bir ilişki olduğu düşünülür. Bu durumda,

verilerin benzer bir eğilimle değiştiği ve tahminin doğru olduğu söylenebilir. Öte yandan, "R" değeri 0'a yakınsa, çıkış verileri ile hedef veri arasında zayıf bir ilişki veya rastgele bir ilişki olduğu düşünülür. Bu durumda, tahminin doğruluğu düşük olabilir ve daha fazla analiz yapılması gerekebilir.


Hem eğitim hem de test için kullanılan çıkış verileri ile hedef veriler arasındaki korelasyon sonucu ortaya çıkan Regresyon değerleri ABD için Şekil 4.20'de, Almanya için Şekil 4.21'de, İngiltere için Şekil 4.22'de, Avustralya için Şekil 4.23'de, Fransa için Şekil 4.24'de ve Türkiye için Şekil 4.25'de görülmektedir.




Şekil 4.20. ABD için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri




Şekil 4.21. Almanya için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri




Şekil 4.22. İngiltere için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri



Şekil 4.23. Avustralya için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri



Şekil 4.24. Fransa için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri



Şekil 4.25. Türkiye için NARX Sinir Ağı modeli sonucu eğitim ve test sonrası Regresyon değerleri

ABD, Almanya, İngiltere, Avustralya, Fransa ve Türkiye için tüm veriler kullanılarak YSA ntstool ile gerçekleştirilen çalışma sonucunda elde edilen Sera Gazı Emisyon tahminleri ile hesaplanan R değerleri, hem eğitim hem de test süreçleri için Çizelge 4.11'de karşılaştırmalı olarak sunulmuştur.

Çizelge 4.11. ABD, Almanya, İngiltere, Avustralya, Fransa ve Türkiye için tüm verilerle hesaplanan Sera Gazı Emisyon veri tahminlemesi sonucu hem eğitim hem de test için elde edilen R değerleri

Ülkeler	Tanım	R değerleri
ABD	R (Eğitim)	0.99616
	R (Test)	0.93254
Almanya	R (Eğitim)	0.99896
	R (Test)	0.97168
İngiltere	R (Eğitim)	0.9997
	R (Test)	0.97529
Avustralya	R (Eğitim)	0.99843
	R (Test)	0.97813
Fransa	R (Eğitim)	0.99809
	R (Test)	0.98775
Türkiye	R (Eğitim)	0.9968
	R (Test)	0.99225

4.4. YSA ve LSTM Sera Gazı Emisyonu Tahminlemelerinin Karşılaştırılması


LSTM algoritması ile derin öğrenme sonucu ortaya çıkan gelecek 2023 Ocak ayından itibaren gelecek 63 aya ait veri ile beraber tüm veriler bir araya getirildi. YSA için “ntstool” ile kullanılarak sera gazı emisyon verileri çıkış verisi diğer tüm veriler giriş verileri şeklinde kullanılarak tahminlemeler yapıldı. Çizelge 4.12’de Almanya için kullanılan verilerle uygulanan derin öğrenme’de LSTM algoritması sonucu elde edilen gelecek tahminlerinin 2027 yılının ilk dört ayına ait tahmini verileri görülebilir.

Çizelge 4.12. Almanya için kullanılan verilerin Derin Öğrenme’de LSTM algoritması ile yapılan modelleme sonucunda elde edilen gelecek tahminlerinin bir kısmı


Tanım	Birim	2027/01	2027/02	2027/03	2027/04
Sera Gazı Emisyon	Mton CO ₂ e	65	65	65	65
İnsani Gelişmişlik Endeksi	Endeks	1	1	1	1
Ormanlaşma	Orman arazisi km ²	114161	114161	114161	114161
Nüfus	İnsan	83825028	83814080	83806149	83825028
Gayri Safi Milli Gelir - GSMH	Baz Yıl 2010=100 (kişi başı ABD Doları)	148	148	148	148
Net Milli Gelir	Baz Yıl 2010=100 (kişi başı ABD Doları)	148	148	148	148
Gayri Safi Yurt İçi Hasıla - GSYİH	Baz Yıl 2010=100 (ABD Doları)	147	147	147	147

Tüm Mallara ait Üretici Fiyatları Endeksi	Baz Yıl 2010=100	117	119	121	117
Tüketici Fiyatları Endeksi	Baz Yıl 2010=100	117	117	117	117
Mevsimsellikten Arındırılmış Sanayi Üretimi	Baz Yıl 2010=100	101	103	106	101
Finansal Piyasa Fiyatları Dönem Sonu Endeksi	Baz Yıl 2010=100	117	117	117	117
Sanayi Üretimi Ekonomik Faaliyet Endeksi	Baz Yıl 2010=100	112	109	98	112
Uzun Dönem Yatırım Oranları, Yıllık yüzde oranları	Baz Yıl 2010=100	0	0	0	0
Birincil Enerji	MLN_TOE	24109	24108	24108	24109
Yenilenebilir Enerji	KTOE	37097987	37097990	37097992	37097987


YSA NARX modeli ile yapılan tahminlemelerde gerçek veriler ile tahmini veriler kıyaslandığında sera gazı emisyon verileri ile ilgili yakın değerler elde edildiği ABD için Şekil 4.26'da, Almanya için Şekil 4.27'de, İngiltere için Şekil 4.28'de, Avustralya için Şekil 4.29'da, Fransa için Şekil 4.30'da ve Türkiye için Şekil 4.31'de 2010 yılına ait veri kıyaslamaları görülebilir.




Şekil 4.26. ABD için 2010 yılına ait aylara göre hem gerçek hem de YSA - NARX model sonrası elde edilen tahmini sera gazı emisyon verileri karşılaştırılması




Şekil 4.27. Almanya için 2010 yılına ait aylara göre hem gerçek hem de YSA - NARX model sonrası elde edilen “Mton CO₂e” cinsinden tahmini sera gazı emisyon verileri karşılaştırılması




Şekil 4.28. İngiltere için 2010 yılına ait aylara göre hem gerçek hem de YSA - NARX model elde edilen “Mton CO₂e” cinsinden tahmini sera gazı emisyon verileri karşılaştırılması



Şekil 4.29. Avustralya için 2010 yılına ait aylara göre hem gerçek hem de YSA - NARX model sonrası elde edilen “Mton CO₂e” cinsinden tahmini sera gazı emisyon verileri karşılaştırılması




Şekil 4.30. Fransa için 2010 yılına ait aylara göre hem gerçek hem de YSA - NARX model sonrası elde edilen “Mton CO₂e” cinsinden tahmini sera gazı emisyon verileri karşılaştırılması




Şekil 4.31. Türkiye için 2010 yılına ait aylara göre hem gerçek hem de YSA - NARX model sonrası elde edilen “Mton CO₂e” cinsinden tahmini sera gazı emisyon verileri karşılaştırılması


YSA NARX modeli ile birçok farklı kaynağa ait tahmini verilerin eklenmesi ile yapılan modelleme sonucunda, sera gazı emisyon tahmini değerleri ile Derin öğrenme LSTM algoritması sonucu elde edilen gelecek sera gazı emisyon verileri örnek olarak 2025 aylarına ait veriler kıyaslandığında yakın değerler elde edildiği görülmektedir. Örnek olarak ABD için Şekil 4.32’de, Almanya için Şekil 4.33’de, İngiltere için Şekil 4.34’de, Avustralya için Şekil 4.35’de, Fransa için Şekil 4.36’da ve Türkiye için Şekil 4.37’de 2025 yılına ait tahmini verilerin kıyaslamaları görülebilir.




Şekil 4.32. ABD’nin 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen tahmini verileri (mavi çizgiler) ile YSA için “ntstool” ile kullanılarak elde edilen tahmini verilerin (kırmızı çizgi) karşılaştırılması




Şekil 4.33. Almanya'nın 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen "Mton CO₂e" cinsinden tahmini verileri (mavi çizgiler) ile YSA için "ntstool" ile kullanılarak elde edilen ait tahmini verilerin (kırmızı çizgi) karşılaştırılması




Şekil 4.34. İngiltere'nin 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen "Mton CO₂e" cinsinden tahmini verileri (mavi çizgiler) ile YSA için "ntstool" ile kullanılarak elde edilen ait tahmini verilerin (kırmızı çizgi) karşılaştırılması



Şekil 4.35. Avustralya'nın 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen "Mton CO₂e" cinsinden tahmini verileri (mavi çizgiler) ile YSA için "ntstool" ile kullanılarak elde edilen ait tahmini verilerin (kırmızı çizgi) karşılaştırılması



Şekil 4.36. Fransa'nın 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen "Mton CO₂e" cinsinden tahmini verileri (mavi çizgiler) ile YSA için "ntstool" ile kullanılarak elde edilen ait tahmini verilerin (kırmızı çizgi) karşılaştırılması




Şekil 4.37. Türkiye'nin 2025 yılına ait ayları için, LSTM algoritması ile Derin Öğrenme sonucu elde edilen "Mton CO₂e" cinsinden tahmini verileri (mavi çizgiler) ile YSA için "ntstool" ile kullanılarak elde edilen ait tahmini verilerin (kırmızı çizgi) karşılaştırılması

ABD, Almanya, İngiltere, Avustralya, Fransa ve Türkiye için YSA "ntstool" aracı kullanılarak NARX modeli sonucu elde edilen Sera Gazı Emisyon tahminleri Çizelge 4.13'da karşılaştırmalı olarak görülebilir. Aynı zamanda Şekil 4.38'de 1970 ile 2025 arası gerçek değerler ile tahmini değerler 5 yıl aralıklı olarak grafik şeklinde görülebilir.

Çizelge 4.13. ABD, Almanya, İngiltere, Avustralya, Fransa ve Türkiye için hesaplanan "Mton CO₂e" cinsinden Sera Gazı Emisyon tahminlemeleri

	2026/01	2026/02	2026/03	2026/04	2026/05	2026/06	2026/07	2026/08	2026/09
ABD	409.82	406.45	407.91	416.00	394.70	401.25	376.33	362.80	368.39
Almanya	44.50	33.20	40.81	70.49	102.90	88.80	52.66	29.15	74.27
İngiltere	16.20	9.22	24.27	41.50	54.10	45.11	28.46	18.38	37.08
Avustralya	21.56	18.87	27.94	55.16	68.36	64.72	37.36	21.97	51.23
Fransa	16.69	12.50	19.85	38.83	53.10	43.53	27.68	15.24	34.41
Türkiye	18.03	5.88	26.20	52.43	78.81	52.18	29.75	21.74	43.00



Şekil 4.38. ABD, Almanya, İngiltere, Avustralya, Fransa ve Türkiye için hesaplanan “Mton CO₂e” cinsinden Sera Gazı Emisyon gerçek değerler ile tahminleme değerleri

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Günümüzde “Makina Öğrenimi”, insanoğluna zamanı, ürünü ve hizmeti en iyi ve en verimli şekilde kullanımı için yeni fırsatlar sunmuştur. Yapay zeka yöntemleri kullanılarak elde edilen veriler ile çalışma kapsamındaki ülkelerin ayrı ayrı mevcut durumları göz önünde tutularak küresel ısınmanın önüne geçecek katkıları veya hedeflerinin gelecekteki etkileri ortaya çıkarılmıştır. Ayrıca, birden fazla faktöre bakılarak ihtiyaç duyulan önlemlerin ve tedbirlerin en uygun yöntemi seçilerek ülkelerin verimli ve sürdürülebilir bir şekilde istenen hedefe ulaşılabilmesi için karar vericilere yol göstereceği gibi, aynı zamanda mevcut durumun değişime olan ihtiyacının ortaya çıkartılması ve farkındalık yaratılması da beklenmektedir.

Farklı lokasyonlardaki çeşitli ülkeler arasından Almanya, Amerika Birleşik Devletleri, Avustralya, Birleşik Krallık, Fransa ve Türkiye gibi sürdürülebilir bir kalkınma ile sera gazı emisyonlarını azaltmaya ve diğer ilgili verilerin analizini yapmaya yönelik çalışma yapılmıştır. Çalışma, dünyanın farklı bölgelerinden ve çoğunlukla gelişmiş ülkelere örnekler içermektedir. Bu örnekler, iklim değişikliği ve sürdürülebilirlik konularında önemli bir rol oynayan ve küresel ölçekte etkisi olan ülkeleri temsil etmektedir. Çalışma sürecinde, her bir ülkenin sera gazı emisyonu, ekonomik ve finansal durumu, birincil ve yenilenebilir enerji arzları, nüfusu ve ağaçlandırma gibi verileri ayrı ayrı değerlendirilerek zaman serileri oluşturulmuştur. Ardından, bu veriler LSTM Regresyon algoritması kullanılarak tahmin edilmiş ve gelecek için yapılan tahminler yapay sinir ağı NARX modeli ile desteklenmiştir. Sonuçlar, ülkelerin sera gazı emisyon tahminleri ve gelecekteki olası eğilimleri hakkında önemli bilgiler sağlamış ve gelecekteki politika ve strateji oluşturulmasına, enerji yönetimine ve sürdürülebilir kalkınma hedeflerine ulaşılması açısından önemli katkılar sunması beklenmektedir.

Çalışma sonunda elde edilen veriler metot açısından incelendiğinde aşağıdaki sonuçlar elde edilmiştir.

- Yapay zeka yöntemlerinden derin öğrenme'nin LSTM ve ayrıca CNN-RNN hibrit olarak kullanımı, başarılı tahmin sonuçları vermiştir.
- Aynı şekilde, Matlab "ntstool" aracıyla kullanılan NARX model ile korelasyon değerlerinin 1'e yakın olması, çalışmanın etkinliğini

göstermektedir. Çalışma sonucunda sera gazı emisyon değerleri gerçek verilerle kıyaslandığında başarılı tahminler yapıldığı görülmüştür.

Sonuçlar ülke bazlı olarak incelendiğinde aşağıdaki sonuçlar elde edilmiştir.

- Çalışma içerisinde ele alınan ülkeler arasında Almanya, Fransa ve İngiltere'nin belirli bir eğimle sera gazı emisyonu azaltma yönünde tahminlere ulaşılmıştır. Avrupa ülkelerinin küresel ısınma ile mücadelede yenilenebilir enerjiye verdiği önem, fosil yakıtlardan uzaklaşma ve sürdürülebilir kalkınma için alınan ekonomik ve politik kararların başarılı sonuçlar elde etmeye yönelik olduğu görülmektedir.
- Avustralya ve Türkiye'nin 2019 yılında başlayan pandemi dönemiyle birlikte sera gazı emisyonlarında azalmalar yaşadığı yorumlanabilir, bu da dünyadaki ekonomik sorunlara bir gösterge niteliği taşıyabilir.
- ABD için yapılan analizde ise gelecek tahmini verilere bakıldığında, 2000 yıllara oranla sera gazı üretiminde azalma görülse de 1990 yılların altına düşmediği gözlenmiştir.
- Çalışma kapsamında, Almanya, Amerika Birleşik Devletleri, Avustralya, Birleşik Krallık, Fransa ve Türkiye gibi gelişmiş veya gelişmekte olan ülkelerle yapılan analiz sonuçlarına göre ABD, Türkiye ve Avustralya'nın 1990 yıllara ait sera gazı üretim seviyelerine düşmediği görülmüştür. Bu durum, iklim değişikliği konusunda birçok ülkenin daha fazla çaba sarf etmesi gerektiğini gösterebilir. Ayrıca, ülkelerin küresel ısınma konusunda farkındalık oluştuğu sonucuna varılmıştır.

5.2 Öneriler

Çalışma kapsamında, iklim değişikliği ve sera gazı emisyonları konusunda derinlemesine bir analiz ve tahmin modeli ile elde edilen sonuçlar, gelecekteki sera gazı emisyonlarını belirlemek ve bu emisyonları azaltmak için etkili politikaların oluşturulmasına katkı sağlamaktadır. Bu alanda daha da ilerlemek ve daha kapsamlı sonuçlar elde edebilmek için bazı öneriler aşağıda sunulmaktadır:

- Gelecekteki sera gazı emisyonlarını daha doğru bir şekilde tahmin edebilmek için daha zengin veri kaynaklarının kullanılabilir. Örneğin, iklim verileri, ekonomik ve finansal göstergeler, nüfus istatistikleri,

enerji tüketim verileri, şehirleşme oranları, göç hareketleri, orman alanları, çevre politikaları ve yenilenebilir enerji teknolojilerine yönelik yatırımlar gibi çeşitli parametreler ile veri kategorileri kullanılarak daha kapsamlı bir model oluşturulabilir.

- “Derin Öğrenme” ve benzeri YSA algoritmalarıyla elde edilen başarılı sonuçlar göz önünde bulundurulduğunda, ileri düzeyde yapay zeka teknikleri ile daha başarılı sonuçlar elde edilebilir.
- Sera gazı emisyonları üzerinde etkili politikalar oluşturmak için gelecekteki farklı senaryolarla analizler yapılabilir ve bu analizlerin sonuçlarına dayanarak politika önerileri sunulabilir. Politika geliştiriciler, makina öğrenmesi ile daha etkin stratejiler belirleyebilirler.

Yukarıdaki öneriler, iklim değişikliğiyle mücadelede daha güçlü ve etkili bir yaklaşımın benimsenmesine yardımcı olabilir. Bu şekilde, araştırmacılar, enerji planlayıcıları, politika yapıcıları ve ilgili tüm paydaşlar için daha kapsamlı sonuçlar elde edilerek etkili politikalar oluşturulabilir.

KAYNAKLAR

- Acheampong, A. O. and Boateng, E. B., 2019, Modelling carbon emission intensity: Application of artificial neural network, *Journal of Cleaner Production*, 225, 833-856.
- Ajansı, T.U., 2022, Türkiye Uzay Ajansı Dünya'nın Atmosferi ve Katmanları [online], <https://tua.gov.tr/tr/blog/dunya/dunya-nin-atmosferi-ve-katmanlari> , [Ziyaret Tarihi: 20 Mayıs 2022].
- Ahmadi, M. H., Jashnani, H., Chau, K. W., Kumar, R. and Rosen, M. A., 2019, Carbon dioxide emissions prediction of five Middle Eastern countries using artificial neural networks. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 1-13.
- Ali, N., Assad, M. E. H., Fard, H. F., Jourdehi, B. A., Mahariq, I. and Al-Shabi, M. A., 2022, CO₂ Emission Modeling of Countries in Southeast of Europe by Using Artificial Neural Network, *In Sensing for Agriculture and Food Quality and Safety XIV*, Vol. 12120, 100-104.
- Alizadeh, M., 2011, Yapay Sinir Ağları İle Fiyat Tahmin Analizi, Yüksek Lisans Tezi, *İstanbul Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 90s.
- Avcı, A.S., 2014, Batman Üniversitesi Dersliklerinde İç Hava Kalitesinin Araştırılması, Master's Thesis, *Batman Üniversitesi*, Batman.
- Aydın, S. G. ve Aydoğdu, G., 2022, Makine Öğrenmesi Algoritmaları Kullanılarak Türkiye ve AB Ülkelerinin CO₂ Emisyonlarının Tahmini, *Avrupa Bilim ve Teknoloji Dergisi*, (37), 42-46.
- Ayyıldız, B., 2013, Ekolojik ekonomi yaklaşımı ile Türkiye'de çevresel etkinlik analizi, Master's Thesis, *Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü*, Tokat.
- Bakay, M. S. ve Ağbulut, Ü., 2021, Electricity Production Based Forecasting of Greenhouse Gas Emissions in Turkey with Deep Learning, Support Vector Machine and Artificial Neural Network Algorithms, *Journal of Cleaner Production*, 285, 125324.
- Birleşmiş Milletler, 2023, *Basic Data Selection* [online], <https://unstats.un.org/unsd/snaama/Basic>, [Ziyaret Tarihi: 19 Şubat 2023].
- Bolin, B. ve Doos, B. R., 1989, Greenhouse Effect.
- Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2022, *Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi* [online], <https://iklim.csb.gov.tr/birlesmis-milletler-iklim-degisikligi-cerceve-sozlesmesi-i-4362> , [Ziyaret Tarihi: 28 Mayıs 2022].
- Dandil, E. ve Serin, Z., 2020, Derin Sinir Ağları Kullanarak Histopatolojik Görüntülerde Meme Kanseri Tespiti, *Avrupa Bilim ve Teknoloji Dergisi*, 451-463.

- Diken, G., 2020, Antropojenik İklim Değişikliğinin Balıkçılık ve Su Ürünleri Üzerine Etki ve Yönetim Stratejilerine Genel Bir Bakış, *Journal of Anatolian Environmental and Animal Sciences*, 5(3), 295-303.
- European Union, Official Website, 2023, *Global Greenhouse Gas Emissions* [online], https://edgar.jrc.ec.europa.eu/dataset_ghg70#p3, [Ziyaret Tarihi: 24 Şubat 2023]
- Güler, Y., 2018, Sera Gazları, *İklim Değişikliğinde Sera Gazı Emisyonlarının Rolü ve Emisyon Ticareti*, ISHAD, 517-527.
- Han, Y., Cao, L., Geng, Z., Ping, W., Zuo, X., Fan, J., ... and Lu, G. (2023). Novel Economy and Carbon Emissions Prediction Model of Different Countries or Regions in the World for Energy Optimization Using Improved Residual Neural Network, *Science of The Total Environment*, 860, 160410.
- Hükûmetlerarası İklim Değişikliği Paneli (Intergovernmental Panel on Climate Change) IPCC Resmi Web Sitesi, 2022, *IPCC Factsheet What is the IPCC?* [online], https://www.ipcc.ch/site/assets/uploads/2021/07/AR6_FS_What_is_IPCC.pdf , [Ziyaret Tarihi: 10 Haziran 2022]
- Rahman, M. M., Shakeri, M., Khatun, F., Tiong, S. K., Alkahtani, A. A., Samsudin, N. A., ... & Hasan, M. K., 2022, A Comprehensive Study and Performance Analysis of Deep Neural Network-Based Approaches in Wind Time-Series Forecasting, *Journal of Reliable Intelligent Environments*, 1-18.
- Sanchez, H., 2023, Time Series Forecasting Using Hybrid CNN – RNN, *MATLAB Central File Exchange*, Retrieved April 24, 2023.
- Karakurt, İ. ve Aydın, G., 2015, Kömür Kaynaklı CO₂ Emisyonlarının Tahminine Yönelik Model Geliştirilmesi: BRICS-T Ülkeleri Örneği, *Karadeniz Fen Bilimleri Dergisi*, 10(1), 214-229.
- Komeili Birjandi, A., Fahim Alavi, M., Salem, M., Assad, M. E. H. and Prabakaran, N., 2022, Modeling Carbon Dioxide Emission of Countries in Southeast of Asia by Applying Artificial Neural Network, *International Journal of Low-Carbon Technologies*, 17, 321-326.
- Korkmaz, K., 2007, Küresel Isınma ve Tarımsal Uygulamalara Etkisi, *Alatırım Dergisi*, 2007, 6.2: 43-49.
- Levinson, D., 2020, Logistic Curve Models of CO₂ Accumulation. Findings.
- Liu, W., McKibbin, W. J., Morris, A. C. and Wilcoxon, P. J., 2020, Global Economic and Environmental Outcomes of the Paris Agreement, *Energy Economics*, 90, 104838.
- Organisation for Economic Co-operation and Development, 2023, *Primary Energy Supply* [online], <https://data.oecd.org/energy/primary-energy->

supply.htm#:~:text=Primary%20energy%20supply%20is%20defined,plus%20or%20minus%20stock%20changes, [Ziyaret Tarihi: 21 Şubat 2023].

Organisation for Economic Co-operation and Development, 2023, *Renewable Energy* [online], <https://data.oecd.org/energy/renewable-energy.htm#indicator-chart>, [Ziyaret Tarihi: 21 Şubat 2023].

Organisation for Economic Co-operation and Development, 2023, *Monthly Monetary and Financial Statistics (MEI)* [online], <https://stats.oecd.org/index.aspx?queryid=6779>, [Ziyaret Tarihi: 20 Şubat 2023].

Özhan, E., 2020, Yapay Sinir Ağları ve Üstel Düzleştirme Yöntemi ile Türkiye'deki CO₂ Emisyonunun Zaman Serisi ile Tahmini, *Avrupa Bilim ve Teknoloji Dergisi*, (19), 282-289.

Pabuççu, H. ve Bayramoğlu, T., 2016, Yapay Sinir Ağları İle CO₂ Emisyonu Tahmini: Türkiye Örneği. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Ankara, 18(3), 762-778.

Sel, A., 2020, Veri Madenciliği Kümeleme Yöntemleri Kullanarak Karbon Emisyonu Göstergeleri Açısından OECD Ülkelerinin Sınıflandırılması, *Karadeniz Uluslararası Bilimsel Dergi*, 1(46), 169-187.

Sergeev, A., Buevich, A., Shichkin, A., Baglaeva, E., Subbotina, I., Medvedev, A. and Sergeeva, M., 2020, Prediction the Dynamic of Changes in the Concentrations of Main Greenhouse Gases by an Artificial Neural Network Type NARX, *In AIP conference proceedings*, Vol. 2293, No. 1, AIP Publishing.

Şahin, Ü., Tör, O. B., Kat, B., Teimourzadeh, S., Demirkol, K., Künar, A., ... ve Yeldan, E., 2021, Türkiye'nin Karbonsuzlaşma Yol Haritası: 2050'de Net Sıfır, *Istanbul Policy Center*, 20211103-19115588.

The MathWorks, Inc., 2023, *How Machine Learning Works* [online], <https://www.mathworks.com/discovery/machine-learning.html#:~:text=Machine%20learning%20uses%20two%20types,intrinsic%20structures%20in%20input%20data.>, [Ziyaret Tarihi: 05 Mart 2023]

The World Bank, 2023, *Forests and Landscapes* [online], <https://www.worldbank.org/en/topic/forests/forests-area#4>, [Ziyaret Tarihi: 19 Şubat 2023]

Tunalı, Ç. B., 2011, Uluslararası Para Fonu'nun Kredilendirme Mekanizması: Düşük Gelirli Ülkelere Yönelik Bir İnceleme, *Maliye Araştırma Merkezi Konferansları*, (56), 69-93.

Türkeş, M., Sümer, U. M. ve Çetiner, G., 2000, Kyoto Protokolü Esneklik Mekanizmaları (Flexibility Mechanisms Under the Kyoto Protocol), *Tesisat Dergisi*, 52: 84-100.

- Türkiye Cumhuriyeti Dışişleri Bakanlığı, 2022 , *Paris Anlaşması* [online], <https://www.mfa.gov.tr/paris-anlasmasi.tr.mfa> , [Ziyaret Tarihi: 10 Haziran 2022]
- Türkiye İstatistik Kurumu, 2023, *Sera Gazı Emisyon İstatistikleri, 1990-2020* [online], <https://data.tuik.gov.tr/Bulten/Index?p=Sera-Gazi-Emisyon-Istatistikleri-1990-2020-45862>, [Ziyaret Tarihi: 18 Şubat 2022]
- United Nations, 2022, *The Paris Agreement* [online], <https://www.un.org/en/climatechange/paris-agreement> , [Ziyaret Tarihi: 07 Haziran 2022]
- United Nations, 2022, *17 Goals to Transform Our World* [online], <https://www.un.org/en/climatechange/17-goals-to-transform-our-world> , [Ziyaret Tarihi: 07 Haziran 2022]
- Union of Concerned Scientists, 2022, *Each Country's Share of CO₂ Emissions* [online], <https://www.ucsusa.org/resources/each-countrys-share-co2-emissions> , [Ziyaret Tarihi: 08 Haziran 2022]
- UNDP (United Nations Expanded Programme), 2023, *What is Human Development?* [online], <https://hdr.undp.org/about/human-development>, [Ziyaret Tarihi: 15 Şubat 2023]
- U.S. Energy Information Administration (EIA), 2023, *Total Energy* [online], <https://www.eia.gov/totalenergy/data/monthly/index.php>, [Ziyaret Tarihi: 20 Şubat 2023]
- Wikimedia Foundation, Inc., 2022, *Paris Anlaşması* [online], https://tr.wikipedia.org/wiki/Paris_Anla%C5%9Fmas%C4%B1#:~:text=Amerika%20Birle%C5%9Fik%20Devletleri%202020%27de,ancak%202021%27de%20yeniden%20kat%C4%B1ld%C4%B1.&text=Paris%20Anla%C5%9Fmas%C4%B1%27n%C4%B1n%20uzun%20vadeli,5%20%C2%B0C%20%C3%A7aba%20harcamas%C4%B1d%C4%B1r [Ziyaret Tarihi: 07 Haziran 2022]
- Wikimedia Foundation, Inc., 2022, *Charles David Keeling* [online], https://en.wikipedia.org/wiki/Charles_David_Keeling, [Ziyaret Tarihi: 15 Şubat 2023]
- United States Environment Protection Agency (EPA), 2023, *Overview of Greenhouse Gases* [online], <https://www.epa.gov/ghgemissions/overview-greenhouse-gases> , [Ziyaret Tarihi: 19 Nisan 2023]
- Uzlu, E., 2021, Estimates of Greenhouse Gas Emission in Turkey with Grey Wolf Optimizer Algorithm-Optimized Artificial Neural Networks, *Neural Computing and Applications*, 33(20), 13567-13585.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Serkan ERTUĞRUL
Uyruğu : T.C.

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Üniversite	: İstanbul Üni., Elektronik Müh.	2002
Üniversite	: Anadolu Üni., İşletme	2021
Yüksek Lisans	: Batman Üni., Elektrik-Elektronik Müh.	DevamEdiyor
Doktora	: -	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2002-2003	Aset Telekom	Proje Müh.
2004-...	ENKA	Endüstriyel ve Kontrol Müh.

UZMANLIK ALANI Endüstriyel ve Kontrol Müh.

YABANCI DİLLER İngilizce

YAYINLAR -