

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**RÜZGAR TÜRBİN GÜÇLERİNİN MAKİNE ÖĞRENMESİ MODELLERİYLE
TAHMİN EDİLMESİ VE SANTRALDAKİ KONUMLARININ ETKİSİ**

YÜKSEK LİSANS TEZİ

Buğra KAPLAN

Makina Mühendisliği Anabilim Dalı

Isı Akışkan Lisansüstü Programı

OCAK 2023

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**RÜZGAR TÜRBİN GÜÇLERİNİN MAKİNE ÖĞRENMESİ MODELLERİYLE
TAHMİN EDİLMESİ VE SANTRALDAKİ KONUMLARININ ETKİSİ**

YÜKSEK LİSANS TEZİ

**Buğra KAPLAN
(503191134)**

Makina Mühendisliği Anabilim Dalı

Isı Akışkan Lisansüstü Programı

Tez Danışmanı: Prof. Dr. Nurdil Eskin

OCAK 2023

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 503191134 numaralı Yüksek Lisans Öğrencisi Buğra KAPLAN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “RÜZGAR TÜRBİN GÜÇLERİNİN MAKİNE ÖĞRENMESİ MODELLERİYLE TAHMİN EDİLMESİ VE SANTRALDAKİ KONUMLARININ ETKİSİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Nurdil Eskin**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Yakup Erhan Böke**
İstanbul Teknik Üniversitesi

Prof. Dr. Derya Burcu Özkan
Yıldız Teknik Üniversitesi

Teslim Tarihi : 27 Aralık 2022

Savunma Tarihi : 05 Ocak 2023





Sevgili Annem Filiz KAPLAN'a ve Sevgili Babam Erdoğan KAPLAN'a



ÖNSÖZ

Yenilenebilir enerji kaynaklarının ve rüzgâr enerjisinin önemini her geçen gün arttırdığı bu çağda makine öğrenmesi modelleri kullanılarak rüzgâr enerjisinin tahmin edilmesi üzerine yaptığım bu çalışma literatürde öncü bir adım olarak düşünülebilir.

Yüksek lisans tez çalışması olarak yürüttüğüm “Rüzgâr Türbini Güçlerinin Makine Öğrenmesi Modelleriyle Tahmin Edilmesi ve Santraldaki Konumlarının Etkisi” isimli çalışmamda benden yardımlarını esirgemeyen hocam Sayın Prof. Dr. Nurdil Eskin’e teşekkürü bir borç bilirim.

Tüm öğrencilik hayatım boyunca sevgi, merhamet ve desteklerini üzerimden esirgemeyen sevgili annem Filiz Kaplan’a ve sevgili babam Erdoğan Kaplan’a minnettarım.

Ocak 2023

Buğra Kaplan
Makine Mühendisi & İnşaat Mühendisi



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
KISALTMALAR	xiii
SEMBOLLER	xv
ÇİZELGE LİSTESİ.....	xvii
ŞEKİL LİSTESİ.....	xix
ÖZET.....	xxiii
SUMMARY	xxv
1. GİRİŞ.....	1
1.1. Bir Enerji Çeşidi Olarak Rüzgâr	1
1.2. Rüzgâr Enerjisinin Tarihsel Gelişimi	5
1.3. Küresel Ölçekte Rüzgâr Enerjisi	6
1.4. Türkiye'nin Rüzgâr Enerjisi Bakımından Değerlendirilmesi	10
1.5. Tez Çalışmasının Amaçları	16
1.6. Tez Çalışmasının Yöntemi	18
2. ENERJİ DÖNÜŞÜM MAKİNELERİ OLARAK RÜZGÂR TÜRBİNLERİ.....	21
2.1. Rüzgâr Türbini Çeşitleri ve Sınıflandırılmaları.....	23
2.1.1. Rüzgâr türbinlerinin dönme eksenlerine göre sınıflandırılmaları.....	24
2.1.2. Rüzgâr türbinlerinin kanat sayılarına göre sınıflandırılmaları	25
2.1.3. Rüzgâr türbinlerinin devir sayılarına göre sınıflandırılmaları	27
2.1.4. Rüzgâr türbinlerinin güçlerine göre sınıflandırılmaları.....	27
2.1.5. Rüzgâr türbinlerinin rüzgâr alış açılarına göre sınıflandırılmaları	27
2.1.6. Rüzgâr türbinlerinin dişli kutusu sistemlerine göre sınıflandırılmaları	28
2.1.7. Rüzgâr türbinlerinin kurulum bölgelerine göre sınıflandırılmaları	28
3. RÜZGÂR GÜCÜ VE RÜZGÂR ENERJİSİ POTANSİYELİ	31
3.1. Rüzgâr Enerjisinin ve Gücünün Hesaplanmasında Kullanılan Denklemler	31
3.2. Rüzgâr Gücünü ve Rüzgâr Enerjisini Belirleyen Etmenler.....	36
3.2.1. Rüzgâr hızı ve yükseklik ilişkisi.....	36
3.2.2. Rüzgâr hızı ve pürüzlülük ilişkisi	37
3.2.3. Rüzgâr hızı ve türbülans ilişkisi	38

3.2.4.	Rüzgâr hızı ve rüzgâr engelleri ilişkisi	39
3.2.5.	Rüzgâr hızı ve art izi etkisi	39
3.5.2.1.	Jensen iz modeli	40
3.3.	Rüzgâr Türbinlerinin Santral İçerisindeki Konumlarının Etkisi	41
4.	RÜZGÂR TÜRBİNİ KONTROL SİSTEMLERİ.....	47
4.1.	Açı Kontrol Sistemi	47
4.2.	Yön Kontrol Sistemi	48
4.3.	Fırtına ve Güç Kontrol Sistemi.....	48
4.3.1.	Pasif stall kontrol sistemleri.....	49
4.3.2.	Aktif stall kontrol sistemleri	50
4.3.3.	Pasif pitch kontrol sistemleri	50
4.3.4.	Aktif pitch kontrol sistemleri.....	51
4.4.	Şebeke Kontrol Sistemi	51
4.5.	Üreteç Kontrol Sistemi	52
4.6.	Uzaktan Erişim Kontrol Sistemi.....	52
5.	MAKİNE ÖĞRENMESİ KURAMI.....	55
5.1.	K'nci Mertebeden En Yakın Komşular Algoritması (KEK)	56
5.1.1.	Öklid yöntemi	57
5.1.2.	Manhattan yöntemi	57
5.1.3.	Minkowski yöntemi	57
5.2.	Rastgele Orman Algoritması (RSO).....	61
5.3.	Ekstra Ağaç Algoritması (ETA)	64
5.4.	Gradyan Yükseltme Algoritması (GRY).....	67
6.	VAKA ÇALIŞMASI İÇİN VERİ SETİNİN HAZIRLANMASI.....	71
6.1.	Veri Setinin Tahmin Modelleri İçin Hazırlanması	72
7.	YAPILAN ANALİZLER VE ELDE EDİLEN SONUÇLAR	93
7.1.	Rüzgâr Türbinlerinin Üretebilecekleri Güçlerin Geliştirilen Modellerle Tahmin Edilmesi	93
7.1.1.	K'nci mertebeden en yakın komşular algoritması (KEK) temelli modelin tahmin sonuçları	93
7.1.2.	Rastgele orman algoritması temelli modelin (RSO) tahmin sonuçları.....	105
7.1.3.	Ekstra ağaç algoritması (ETA) temelli modelin tahmin sonuçları	116
7.1.4.	Gradyan yükseltme algoritması (GRY) temelli modelin tahmin sonuçları.....	129
7.1.5.	Geliştirilen KRM modelinin tahmin sonuçları	142
7.2.	Rüzgâr Santrallarının Enerji Üretimlerinin İyileştirilebilmesi İçin Türbin Konumlarının Geliştirilen Modelle Belirlenmesi.....	159
8.	SONUÇLAR VE GELECEKTEKİ ÇALIŞMALAR İÇİN ÖNERİLER ..	167

KAYNAKLAR	171
------------------------	------------





KISALTMALAR

AR	: Otoresif Model
DVM	: Destek Vektör Makinesi
ETA	: Ekstra Ağaç Algoritması
GRY	: Gradyan Yükseltme Algoritması
KA	: Karar Ağacı Algoritması
KEK	: K'nci Mertebeden En Yakın Komşular Algoritması
KRM	: Karma Model
LR	: Lineer Regresyon
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MSE	: Mean Squared Error (Ortalama Hataların Karesi)
NACA	: Natural Advisory Committee On Aerodynamic
R²	: R Kare
REPA	: Rüzgar Enerjisi Potansiyeli Atlası
RMSE	: Root Mean Squared Error (Ortalama Hataların Karekökü)
RSO	: Rastgele Orman Algoritması
YSA	: Yapay Sinir Ağları Algoritması



SEMBOLLER

$^{\circ}$	: Derece
C_d	: Sürüklenme Katsayısı
C_l	: Kaldırma Katsayısı
C_p	: Rüzgar Türbini Güç Faktörü
C_t	: Rüzgar Türbini İtki Faktörü
F	: Kuvvet
F_d	: Sürüklenme Kuvveti
F_l	: Kaldırma Kuvveti
E_k	: Kinetik Enerji
GW	: Gigawatt
GWh	: Gigawatt saat
MW	: Megawatt
m	: Kütle
s	: Saniye



ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1 : Dünya Çapında Rüzgâr Kurulu Gücünün Senelik Bazda Değişimi.....	8
Çizelge 1.2 : 2021 Yılı Rüzgâr Enerjisi Kurulu Güçlerinin Ülke Bazlı Sıralamaları.	10
Çizelge 1.3 : Türkiye'nin Tükettiği Enerjinin Enerji Kaynakları Üzerine Dağılımı.	11
Çizelge 1.4 : Türkiye'de Yenilenebilir Enerji Kaynaklarından Üretilen Enerjinin 1965-2021 Yılları Arasındaki Mutlak Değişimi.....	12
Çizelge 1.5 : Türkiye'nin Rüzgâr Enerjisi Kurulu Gücü.	13
Çizelge 1.6 : Türkiye'nin Kurulu Güç Bakımından En Büyük İlk On Rüzgâr Enerjisi Santrali.....	15
Çizelge 2.1 : 2021 Dünya Offshore Rüzgâr Enerjisi Kurulu Gücü	28
Çizelge 3.1 : Helmann Katsayısının Coğrafi Koşullara Göre Aldığı Değerler.	36
Çizelge 6.1 : Veri Seti Öznitelikleri.	72
Çizelge 6.2 : Veri Seti Öz Niteliklerinin İstatiksel Durumu.....	73
Çizelge 6.3 : Tarih Özniteliğinin Numerikleştirilmesi Sonrası Veri Seti.	74
Çizelge 6.4 : Ham Veri Setindeki Özniteliklerin Kayıp Veri Ya Da Boş Veri Sayıları.	84
Çizelge 6.5 : Anlamlı Veri Setinin İstatistiksel Özellikleri.	89
Çizelge 6.6 : Anlamlı Veri Setinin Ölçeklendirme İşlemi Öncesi Değerleri.	90
Çizelge 6.7 : Anlamlı Veri Setinin Ölçeklendirme Sonrası Değerleri.	90
Çizelge 6.8 : Anlamlı Veri Setinin Ölçeklendirme İşlemi Sonrası Özniteliklerinin Durumları.	90
Çizelge 7.1 : K Sayısının Algoritma Başarı Ölçüm Kriterlerine Göre Etkileri.	95
Çizelge 7.2 : KEK Algoritmasının En Başarılı Tahmin Sonuçlarına Ulaştığı Hiper Parametreler.....	102
Çizelge 7.3 : KEK Algoritması Temelli Modelin Tahmin Başarısı.	102
Çizelge 7.4 : Ay Bazlı Üretilen Ortalama Güçler ve KEK Temelli Modelin Tahmin Ettiği Ortalama Güçler.	105
Çizelge 7.5 : Rastgele Orman Algoritması Temelli Tahmin Modelinin En Başarılı Sonuçlara Ulaştığı Hiper Parametreler.	113
Çizelge 7.6 : Hiper Parametreleri Ayarlanmış Rastgele Orman Algoritması Temelli Tahmin Modelinin Tahmin Performansı.	113
Çizelge 7.7 : Ay Bazlı Üretilen Ortalama Güçler ve RSO Temelli Modelin Tahmin Ettiği Ay Bazlı Ortalama Güçler.	115
Çizelge 7.8 : Ekstra Ağaç Algoritması Temelli Tahmin Modelinin En Başarılı Sonuçlara Ulaştığı Hiper Parametreler.	126
Çizelge 7.9 : Hiper Parametreleri Ayarlanmış Ekstra Ağaç Algoritması Temelli Tahmin Modelinin Tahmin Performansı.	126
Çizelge 7.10 : Ay Bazlı Üretilen Ortalama Güçler ve ETA Temelli Modelin Tahmin Ettiği Ay Bazlı Ortalama Güçler.	128

Çizelge 7.11 : Gradyan Yükseltme Algoritması Temelli Tahmin Modelinin En Başarılı Sonuçlara Ulaştığı Hiper Parametreler.	139
Çizelge 7.12 : Hiper Parametreleri Ayarlanmış Gradyan Yükseltme Algoritması Temelli Tahmin Modelinin Tahmin Performansı.....	139
Çizelge 7.13 : Ay Bazlı Üretilen Ortalama Güçler ve GRY Temelli Modelin Tahmin Ettiği Ay Bazlı Ortalama Güçler.	141
Çizelge 7.14 : Karma Modelin İçine Gömülü Alt Modellerin En Başarılı Sonucu Veren Hiper Parametre Kombinasyonları.	153
Çizelge 7.15 : Alt Modellerinin Hiper Parametreleri Ayarlanmış Karma Modelinin (KRM) Tahmin Performansı.	153
Çizelge 7.16 : Ay Bazlı Üretilen Ortalama Güçler ve Karma Modelin (KRM) Tahmin Ettiği Ay Bazlı Ortalama Güçler.	156
Çizelge 7.17 : Geliştirilen Tüm Modellerin Tahmin Performansları.....	157
Çizelge 7.18 : Rüzgâr Türbinlerinin Üretebilecekleri Yıllık Güç ve Yıllık Enerji Değerleri.	160
Çizelge 7.19 : Geliştirilen Modelin Belirlediği Rüzgâr Türbini Konumlarına Göre Rüzgâr Santralının Üretebileceği Enerji ve Güç Değerleri.	163

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : Dünya Geneline Yenilenebilir Enerji Üretiminin Değişimi (2020-2021).	2
Şekil 1.2 : Ülkelerin Enerji Üretiminde Yenilenebilir Enerjinin Payı.....	3
Şekil 1.3 : Çeşitli Ülkelere Göre Rüzgâr Enerjisinin 1966 -2021 Yılları Arasındaki Değişimi.	4
Şekil 1.4 : 2021 Senesinde Rüzgâr Enerjisinden Elde Edilen Elektrik Enerjisinin Dünya Üzerindeki Dağılımı.	7
Şekil 1.5 : Rüzgâr Enerjisi Potansiyelinin Dünya Üzerindeki Dağılımı TWh (2021).	8
Şekil 1.6 : Rüzgâr Enerjisi Kurulu Gücünün Dünya Genelineki Değişimi (1996 – 2021).....	9
Şekil 1.7 : Ülkelerin Rüzgâr Enerjisi Kurulu Güçleri (2021).	9
Şekil 1.8 : Türkiye’de Tüketilen Enerjinin Enerji Kaynakları Üzerine Dağılımı.....	11
Şekil 1.9 : Türkiye’nin Yenilenebilir Enerji Kaynaklarından Ürettiği Enerjinin Yıllara Göre Değişimi.	12
Şekil 1.10 : Türkiye Rüzgâr Enerjisi Potansiyeli Atlası (100 m yükseklik / Ortalama Hız)......	14
Şekil 1.11 : Türkiye’nin Rüzgâr Enerjisi Kurulu Güçleri GW (2011-2021).	14
Şekil 1.12 : Türkiye’de Rüzgâr Enerjisinin Elektrik Üretimindeki Payı.....	15
Şekil 1.13 : Türkiye Rüzgâr Santralleri Atlası.....	16
Şekil 2.1 : La Cour Rüzgâr Türbini.	22
Şekil 2.2 : Rüzgâr Türbinlerinin Zamanla Değişimi.	23
Şekil 2.3 : Rüzgâr Türbini Çeşitleri ve Sınıflandırılmaları.....	24
Şekil 2.4 : Eksenlerine Göre Rüzgâr Türbinleri.	25
Şekil 2.5 : Kanat Sayılarına Göre Rüzgâr Türleri.....	26
Şekil 2.6 : Vindeby Açık Deniz Rüzgâr Santrali.....	29
Şekil 2.7 : Dünyanın İlk Resmi Onshore Rüzgâr Santrali (New Hampshire).	29
Şekil 2.8 : Dünyanın En Büyük Kurulu Güçlü Rüzgâr Santrali (Çin/2021).	30
Şekil 3.1 : Rüzgâr Türbini Üzerinden Akan Havanın Görselleştirilmesi.	31
Şekil 3.2 : Rüzgâr Türbinleri Üzerindeki Hava Akımları.....	33
Şekil 3.3 : $C_p - v_2/v_1$ Grafiği.....	35
Şekil 3.4 : Rüzgâr – Yükseklik İlişkisi.	37
Şekil 3.5 : Dağ Yamacında Oluşan Türbülans Akımları.	39
Şekil 3.6 : Rüzgâr Türbini Art İzleri.....	40
Şekil 4.1 : Açık Kontrol Sistemi.....	47
Şekil 4.2 : Yön Kontrol Sistemi.....	48
Şekil 4.3 : Fırtına Kontrol Sistemi.....	48
Şekil 4.4 : Ana İşlem Birimi.	49
Şekil 4.5 : Aktif Stall Kontrol Sistemi ve Aktif Pitch Kontrol Sistemi Kanat Açılarının Rüzgâr Hızı İle Değişimi.....	50
Şekil 4.6 : Şebeke Kontrol Sistemi.	51

Şekil 4.7 : Üreteç Kontrol Sistemi.....	52
Şekil 4.8 : Uzaktan Erişim Kontrol Sistemi.....	53
Şekil 5.1 : KEK Algoritmasının Çalışma Mekanizması.....	58
Şekil 5.2 : Rastgele Orman Algoritmasının Çalışma Mekanizması.....	62
Şekil 5.3 : Ekstra Ağaç Algoritmasının Çalışma Mekanizması.....	65
Şekil 5.4 : Gradyan Yükseltme Algoritmasının Çalışma Mekanizması.....	68
Şekil 6.1 : Verileri Kullanılan Enerji Santrali.....	72
Şekil 6.2 : Ham Veri Setindeki Rüzgâr Hızı Verilerinin Dağılımı.....	75
Şekil 6.3 : Ham Veri Setindeki Rüzgâr Yönü Verilerinin Dağılımı.....	75
Şekil 6.4 : Ham Veri Setindeki Teorik Güç Verilerinin Dağılımı.....	76
Şekil 6.5 : Ham Veri Setindeki Üretilen Güç Verilerinin Dağılımı.....	76
Şekil 6.6 : Ham Veri Setindeki Ay, Gün, Saat ve Dakika Verilerinin Dağılımları.....	77
Şekil 6.7 : Ham Veri Setindeki Rüzgâr Hızlarının Rüzgâr Yönlerine Göre Dağılımları.....	78
Şekil 6.8 : Rüzgâr Türbininin Rüzgâr Hızlarına Göre Üretebileceği Teorik Güçler.....	78
Şekil 6.9 : Rüzgâr Türbininin Rüzgâr Hızlarına Göre Ürettiği Güçler.....	79
Şekil 6.10 : Ham Veri Setindeki Aykırı Değerler-1.....	80
Şekil 6.11 : Ham Veri Setindeki Teorik Güç ve Üretilen Güç Verileri.....	80
Şekil 6.12 : Ham Veri Setindeki Aykırı Değerler-2.....	81
Şekil 6.13 : Ham Veri Setindeki Üretilen Güç Verilerinin Rüzgâr Yönlerine Göre Dağılımları.....	81
Şekil 6.14 : Ham Veri Setindeki Teorik Olarak Üretililecek Güç Verilerinin Rüzgâr Yönlerine Göre Dağılımları.....	82
Şekil 6.15 : Ham Veri Setindeki Rüzgâr Türbini Tarafından Üretilen Güç Verilerinin Rüzgâr Hızı ve Rüzgâr Yönlerine Göre Dağılımları.....	83
Şekil 6.16 : Aylık, Günlük, Saatlik ve Dakikalık Ortalama Güç Üretimleri.....	84
Şekil 6.17 : Ham Veri Setindeki Özniteliklerin Korelasyonları.....	85
Şekil 6.18 : Ham Veri Setindeki Teorik Olarak Üretililecek Güç ve Üretilen Güç Verilerinin Rüzgâr Hızlarına Göre Dağılımları.....	86
Şekil 6.19 : Ham Veri Setindeki Aykırı Değerler-3.....	87
Şekil 6.20 : Veri Seti Özniteliklerindeki Aykırı Değerlerin Dağılımları.....	87
Şekil 6.21 : Aykırı Değerler Temizlendikten Sonra Veri Setindeki Özniteliklerin Durumu.....	88
Şekil 6.22 : Aykırı Değerler Temizlendikten Sonra Veri Setindeki Teorik Olarak Üretililecek Güç ve Üretilen Güç verilerinin Rüzgâr Hızlarına Göre Dağılımları.....	89
Şekil 7.1 : KEK Algoritması İçin Tasarlanan Model.....	93
Şekil 7.2 : K Sayısı Parametresinin ve Metrik Parametrelerinin RMSE Değerlerine Etkileri.....	95
Şekil 7.3 : K Sayısı Parametresinin ve Metrik Parametrelerinin MSE Değerlerine Etkileri.....	96
Şekil 7.4 : K Sayısı Parametresinin ve Metrik Parametrelerinin MAE Değerlerine Etkileri.....	97
Şekil 7.5 : K Sayısı Parametresinin ve Metrik Parametrelerinin R2 Değerlerine Etkisi.....	98
Şekil 7.6 : K Sayısı Parametresinin ve Ağırlık Parametrelerinin RMSE Değerlerine Etkileri.....	99
Şekil 7.7 : K Sayısı Parametresinin ve Ağırlık Parametrelerinin MSE Değerlerine Etkileri.....	100

Şekil 7.8 : K Sayısı Parametresinin ve Ağırlık Parametrelerinin MAE Değerlerine Etkisi.....	101
Şekil 7.9 : K Sayısı Parametresinin ve Ağırlık Parametrelerinin R ² Değerlerine Etkisi.	101
Şekil 7.10 : KEK Algoritması Temelli Modelin Tahmin Sonuçları-1.....	103
Şekil 7.11 : KEK Algoritması Temelli Modelin Tahmin Sonuçları-2.....	104
Şekil 7.12 : KEK Algoritması Temelli Modelin Tahmin Sonuçları-3.....	104
Şekil 7.13 : RSO Algoritması İçin Tasarlanan Model.	106
Şekil 7.14 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.	107
Şekil 7.15 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.	108
Şekil 7.16 : Derinlik Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.	109
Şekil 7.17 : Derinlik Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.	110
Şekil 7.18 : Derinlik Parametresinin ve Özellik Parametrelerinin MAE Değerlerine Etkileri.	111
Şekil 7.19 : Derinlik Parametresinin ve Özellik Parametrelerinin R ² Değerlerine Etkileri.	112
Şekil 7.20 : RSO Algoritması Temelli Modelin Tahmin Sonuçları-1.....	113
Şekil 7.21 : RSO Algoritması Temelli Modelin Tahmin Sonuçları-2.....	114
Şekil 7.22 : RSO Algoritması Temelli Modelin Tahmin Sonuçları-3.....	115
Şekil 7.23 : ETA Algoritması İçin Tasarlanan Model.	116
Şekil 7.24 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.	118
Şekil 7.25 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.	119
Şekil 7.26 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin MAE Değerlerine Etkileri.	120
Şekil 7.27 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin R ² Değerlerine Etkileri.	121
Şekil 7.28 : Derinlik Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.	122
Şekil 7.29 : Derinlik Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.	123
Şekil 7.30 : Derinlik Parametresinin ve Özellik Parametrelerinin MAE Değerlerine Etkileri.	124
Şekil 7.31 : Derinlik Parametresinin ve Özellik Parametrelerinin R ² Değerlerine Etkileri.	125
Şekil 7.32 : ETA Algoritması Temelli Modelin Tahmin Sonuçları-1.....	126
Şekil 7.33 : ETA Algoritması Temelli Modelin Tahmin Sonuçları-2.....	127
Şekil 7.34 : ETA Algoritması Temelli Modelin Tahmin Sonuçları-3.....	128
Şekil 7.35 : GRY Algoritması İçin Tasarlanan Model.	129
Şekil 7.36 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.	131
Şekil 7.37 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.	132
Şekil 7.38 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin MAE Değerlerine Etkileri.	133

Şekil 7.39 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin R^2 Değerlerine Etkileri.	134
Şekil 7.40 : Derinlik Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.	135
Şekil 7.41 : Derinlik Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.	136
Şekil 7.42 : Derinlik Parametresinin ve Özellik Parametrelerinin MAE Değerlerine Etkileri.	137
Şekil 7.43 : Derinlik Parametresinin ve Özellik Parametrelerinin R^2 Değerlerine Etkileri.	138
Şekil 7.44 : GRY Algoritması Temelli Modelin Tahmin Sonuçları-1.	140
Şekil 7.45 : GRY Algoritması Temelli Modelin Tahmin Sonuçları-2.	140
Şekil 7.46 : GRY Algoritması Temelli Modelin Tahmin Sonuçları-3.	141
Şekil 7.47 : Geliştirilen KRM Modelinin Çalışma Mekanizması.	142
Şekil 7.48 : K Sayısı Parametresi ve Metrik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.	144
Şekil 7.49 : K Sayısı Parametresi ve Metrik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.	145
Şekil 7.50 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.	146
Şekil 7.51 : Derinlik Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.	147
Şekil 7.52 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.	149
Şekil 7.53 : Derinlik Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.	150
Şekil 7.54 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.	151
Şekil 7.55 : Derinlik Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.	152
Şekil 7.56 : KRM Modelin Tahmin Sonuçları-1.	154
Şekil 7.57 : KRM Modelin Tahmin Sonuçları-2.	155
Şekil 7.58 : KRM Modelin Tahmin Sonuçları-3.	155
Şekil 7.59 : Geliştirilen Modellerin Ortalama Mutlak Hata (MAE) Sonuçlarına Göre Karşılaştırılması.	157
Şekil 7.60 : Geliştirilen Modellerin Ortalama Hataların Karesi (MSE) Sonuçlarına Göre Karşılaştırılması.	158
Şekil 7.61 : Geliştirilen Modellerin Ortalama Hataların Karekökü (RMSE) Sonuçlarına Göre Karşılaştırılması.	158
Şekil 7.62 : Verileri Kullanılan Rüzgâr Santralının Uydu Görüntüsü.	160
Şekil 7.63 : Rüzgâr Türbinlerinin Yıllık Güç Üretimleri (GW).	161
Şekil 7.64 : Rüzgâr Türbinlerinin Yıllık Enerji Üretimleri (GWh).	161
Şekil 7.65 : Santralin Enerji Üretimini İyileştirmek İçin Geliştirilen Modelin Çalışma Mekanizması.	162
Şekil 7.66 : Yeni Türbin Konumlarında Rüzgâr Türbinlerinin Üretebilecekleri Yıllık Güçler (GW).	164
Şekil 7.67 : Yeni Türbin Konumlarında Rüzgâr Türbinlerinin Üretebilecekleri Yıllık Enerjiler (GWh).	164
Şekil 7.68 : Eski Türbin Konumları ve Yeni Türbin Konumları.	165

RÜZGAR TÜRBİN GÜÇLERİNİN MAKİNE ÖĞRENMESİ MODELLERİYLE TAHMİN EDİLMESİ VE SANTRALDAKİ KONUMLARININ ETKİSİ

ÖZET

Fosil yakıt olarak tanımlanan kömür, petrol, doğalgaz gibi enerji kaynaklarının dünya genelindeki miktarlarının sınırlı olmaları ve günden güne azalmaları, enerji üretimi sırasında sebep oldukları sera gazları nedeniyle çevreye verdikleri zararlar, kaynakların eşit olmayan dağılımları ve bölgesel olaylardan kolayca etkilenip teminlerinin zorlaşmaları gibi nedenlerden dolayı insanlık alternatif enerji kaynakları arayışına girmiştir. Bahsedilen olumsuzlukların önüne geçebilecek yenilenebilir enerji kaynaklarından en büyük yükselişi gösteren rüzgâr enerjisi dünyadaki çoğu ülkede olduğu gibi Türkiye’de de önemli bir büyüme göstermektedir. Bu nedenle rüzgâr enerjisinden elektrik enerjisi eldesi için kullanılan rüzgâr santrallerinin sahip oldukları rüzgâr türbinlerinin santral arazisinde en uygun konumlara yerleştirilmeleri ve rüzgâr türbinlerinin üretebilecekleri rüzgâr güçlerinin kurulum aşaması öncesinde değişen hızlarda tahmin edilmeleri rüzgâr enerjisi uygulamaları için oldukça elzem iki konudur.

Bu çalışmada Bursa’da bulunan ve faal olarak elektrik enerjisi üreten bir rüzgâr santralının rüzgâr türbinlerinin verileri kullanılarak rüzgâr türbinlerinin rüzgâr hızlarına bağlı olarak üretebilecekleri güçler yapay zekâ kuramının bir kolu olan makine öğrenmesi modelleriyle tahmin edilmiştir. Makine öğrenmesi modelleri olarak denetimli öğrenme sınıfının topluluk öğrenmesi modelleri ve bireysel öğrenme modelleri dahil olmak üzere toplamda 5 farklı model üzerinde çalışılmış, hiper parametreleri optimize edilmiş ve tahmin modellerinin başarıları 4 farklı başarı ölçüm metriği kullanılarak karşılaştırılmıştır. Çalışmanın sonucunda, makine öğrenmesinin topluluk öğrenmesi ve bireysel öğrenme sınıflarına mensup modellerin çalışma prensiplerine dayanan ve bu çalışma için geliştirilen karma tahmin modeli, %0.36 gibi düşük bir ortalama hataların karesi değeriyle kullanılan veri setinin %99.49’luk kısmını yüksek doğrulukla temsil etmektedir.

Bu çalışmanın ikinci kısmında faal olarak elektrik enerjisi üretimine devam eden bir başka rüzgâr santralının verileri kullanılarak, bahsi geçen rüzgâr santralının yıllık enerji üretimini ve yıllık üretebileceği rüzgâr gücünü arttırmak adına rüzgâr türbinlerinin arazi üzerindeki konumlarını belirleyen bir iyileştirme modeli geliştirilmiştir. Geliştirilen modelde rüzgâr türbinlerinin iz bölgelerini incelemek adına Jensen iz modeline bağlı kalınmıştır. Çalışmanın sonucunda, geliştirilen modelin belirlediği konumlara göre yerleştirilecek rüzgâr türbinleri, verileri kullanılan rüzgâr santralının GWh cinsinden yıllık enerji üretimini %2.1 arttırmaktadır.



PREDICTION OF WIND TURBINE POWER BY MACHINE LEARNING MODELS AND THE EFFECT OF THEIR LOCATIONS IN THE WIND FARM

SUMMARY

Today, 83% of the energy which produced worldwide is produced from traditional energy sources and 17% from renewable energy sources. This situation is valid in Turkey as well as in all countries of the world. 85% of the energy produced in Turkey is produced from traditional energy sources such as coal, oil and natural gas, which we call fossil fuels, and 15% from renewable energy sources.

Although the center of energy production seems to be traditional energy sources, traditional energy sources have handicaps that cannot be ignored. The first of these is the limited amount of traditional energy sources due to their low self-renewal rate. Another important disadvantage is that while producing energy using traditional energy sources, greenhouse gases and CO₂ emissions which are harmful to the environment, nature and the habitat where we live is quite high. Another important disadvantage is that traditional energy sources do not exhibit an equal and fair distribution in the world. Due to the unequal distribution, the control of traditional energy resources is under the protection of some states.

For all these reasons, in the last few quarters of the century, humanity has turned to the search for alternative energy sources that are environmentally friendly and have no limits, and have little harm to the world where they live in. As a result of this search, humanity increase the use of renewable energy sources worldwide.

The use of renewable energy sources is increasing day by day around the world. As one of the biggest indicators of this increase, the share of renewable energy sources in the energy consumed per person can be shown. 31 MWh of the energy consumed per capita in Canada is produced from renewable energy sources. 4 MWh of the energy consumed per capita in our country is produced from renewable energy sources.

Renewable energy sources are also in competition among themselves. In 1990, the energy obtained from hydro energy was 2159 TWh, while the energy obtained from wind energy was only 4 TWh. However, by 2021, hydro energy grew by 98% and reached 4274 TWh, while wind energy showed a growth of 51158% and reached 1862 TWh energy production. This situation shows that wind energy is taking firm steps towards becoming the locomotive type among renewable energy sources.

Wind energy is taking firm steps forward to become the most efficient renewable energy source by easily standing out in terms of investments and development from renewable energy sources. The United States obtained 378.2 TWh of electricity from wind in 2021. Likewise, China, its biggest political rival, obtained 655.6 TWh of electricity from wind. This situation is also valid for our country. Turkey obtained 31 TWh of electrical energy from wind in 2021.

While wind energy is growing in this way, companies that produce electrical energy from wind energy have some problems that need to be solved in order to continue this rise.

The first of these problems is the estimation of the power values that the wind turbines which to be installed in the wind farm can produce under various wind speed conditions before the wind farms are established.

Another important problem which faced by energy companies in the wind energy industry is determining the most suitable locations where the wind turbines will be placed on the wind farm land in order to achieve the best energy production values for the wind farm.

Within the scope of this thesis, it is focused on the solution of two important problems described in detail above, and solutions are suggested. While creating solutions, one-year data of two different wind farms in Turkey that are actively producing electricity were used.

First of all, machine learning models, which is a branch of artificial intelligence theory, were applied to predict the power values that wind turbines can produce under various wind speeds. To solve this problem, five different models have been developed using algorithms from the main groups of machine learning theory such as bagging, boosting and ensemble learning of the supervised learning class.

In order to measure the estimation success of each developed model, basic estimation algorithm success measurement metrics such as the root mean squared errors, the mean squared errors, the mean absolute errors, and R^2 were used and the estimation performances of the five different models developed were compared.

The first model that was developed for estimating the power that wind turbines can produce at various wind speed conditions is the model based on the KEK algorithm. This developed model achieved a prediction success of 99.140% in the data set with the value of mean squared errors of 0.611%.

Another model that was developed to estimate the power that wind turbines can produce at various wind speed conditions is the RSO algorithm-based model. This developed model represents 99.24% of the data set with high accuracy, with the value of mean squared errors of 0.538%.

The model based on the ETA algorithm is another model that was developed to predict the power that wind turbines can produce at various wind speeds. The model based on the ETA algorithm makes predictions with an accuracy of 99.17% on the data set, with the mean squared error value of 0.585%.

Another model developed to predict the power values that wind turbines can produce at various wind speeds is the GRY algorithm based model. This model makes predictions on the data set, with a mean squared error value of 0.525% and an accuracy of 99.26%.

Finally, the model that was developed for estimating the power values that wind turbines can produce under various wind speed conditions is the hash model, which operates the four different models described above as sub-models. The developed hash model makes predictions with an accuracy of 99.49% with a mean squared error of 0.36% on the data set.

In the models that were developed to predict the power values that wind turbines can produce under various wind speed conditions, the most successful result was the hash model with an accuracy value of 99.49%. The hash model follows the GRY algorithm-based model with 99.26% accuracy, the RSO algorithm-based model with 99.24% accuracy, the ETA algorithm-based model with 99.17% accuracy, and the KEK algorithm-based model with 99.14% accuracy.

In the second study carried out within the scope of this thesis, a model that determines the positions of the wind turbines has been developed for the improvement of the energy production of the wind farms by using the one-year data of a wind farm in Turkey, which with 16 wind turbines produces actively electrical energy.

In the developed model, the Jensen model is used to calculate the wake traces of wind turbines. If the wind turbine locations suggested by the developed model are used, it has been proven that the wind farm whose data is used has an energy increase of 2.1% GWh in one-year energy production.





1. GİRİŞ

1.1. Bir Enerji Çeşidi Olarak Rüzgâr


İnsanlığın ilerlemesinin, hayatın sürekliliğinin ve yaşamdaki gelişmelerin neredeyse tamamının temelini enerji ve enerjinin efektif olarak kullanılması oluşturmaktadır. İnsanlık tarihinin başlangıcından beri türümüzün yaşam kalitesini artırma ve türünün devamlılığını sürdürebilecek, kendisini baskın tür yapabilecek yaşam standartlarını yaratma isteği her geçen gün artan enerji talebini oluşturmuştur[1,2]. Bu talebin zamandan bağımsız olarak kümülatif bir şekilde artarak devam etmesi sadece bizim türümüz için değil bu gezegeni paylaştığımız bütün diğer türler için de yadsınamaz sorunları da beraberinde su yüzüne çıkarmıştır. Bu problemlerin en çarpıcı örnekleri, günümüz konjonktüründen bakıldığında enerji üretimi için birinci sırada kullanılan geleneksel enerji kaynağı olarak tanımladığımız kömür, petrol ve doğalgaz gibi kaynakların önemli çevre sorunlarına yol açmaları, dünya üzerinde eşit olmayan dağılımları sebebiyle birkaç devletin kontrolü altında olmaları ve bölgesel krizlerden kolaylıkla etkilenmeleridir[3]. Bu olumsuz tablo karşısında insanlık, tanımlanan problemlerin çözülmesi adına başvurulabilecek en iyi alternatiflerden biri olan yenilenebilir enerji kaynakları arayışına girmiştir.

Kendilerini yenileme hızları geleneksel enerji kaynakları olarak tanımlanan fosil yakıtlara göre oldukça yüksek olan yenilenebilir enerji kaynaklarının gel-git enerjisi ve jeotermal enerji gibi türlerin dışındaki bütün türlerinin temelini Güneş oluşturmaktadır. Yenilenebilir enerji kaynaklarının temelini oluşturan Güneş adını verdiğimiz yıldız yerküreye 3.9×10^{26} GW güç gönderir ve bu gücün oransal olarak %1'i ila %2'si rüzgâr enerjisine dönüşür[4].

Şekil 1.1'de dünya üzerinde 2021 senesinde yapılan ve bir önceki seneye kıyasla yenilenebilir enerji üretiminin değişimi görülmektedir. Şekil 1.2'de ise yenilenebilir enerji ile üretilen elektriğin yüzdesel olarak ülkelere göre dağılımı görülebilir. Şekil 1.1 incelendiğinde dünya üzerinde bulunan çoğu ülkenin 2020 senesine kıyasla bir senelik süreçte yenilenebilir enerji kaynaklarını kullanarak ürettikleri elektrik enerjisinin artışı


bariz bir şekilde göze çarpmaktadır. En büyük artışı 706 TWh enerji ile Çin Halk Cumhuriyeti gösterirken onu 162 TWh ile Amerika Birleşik Devletleri izlemektedir[5].

Şekil 1.2 incelendiğinde 2021 senesinde, dünya çapında bulunan çoğu ülkenin elektrik enerjisi için yenilenebilir enerji kaynaklarından faydalandığı görülmektedir. Bir takım Afrika kıtası ülkeleri %20 oranından az ve yine bir takım Afrika ülkeleri %100 oranına yakın olmakla birlikte elektrik enerjisi eldelerini yenilenebilir enerji kaynaklarından sağlamaktadırlar. İçerisinde bulunduğumuz Türkiye devleti de toplam elektrik üretiminin %35'lik kısmını yenilenebilir enerji kaynaklarından karşılamaktadır[5].



Şekil 1.1 : Dünya Geneline Yenilenebilir Enerji Üretiminin Değişimi (2020-2021)[5].

Rüzgâr enerjisi, rüzgârın kinetik enerjisinden faydalanılarak kullanılan bir tür yenilenebilir enerji formudur. Bu enerjiye ismini veren rüzgâr dediğimiz olgu, güneşin karaları, okyanusları ve atmosfer adını verdiğimiz sekiz katmandan oluşan dünyamızın çevresini saran gaz sarmalını aynı nicelikte ısıtamamasından dolayı meydana gelen sıcaklık farkları sebebiyle, hava adını verdiğimiz gaz karışımının yüksek basınç bölgesinden düşük basınç bölgesine doğru hareket etmesi sonucu oluşur[6].




Şekil 1.2 : Ülkelerin Enerji Üretiminde Yenilenebilir Enerjinin Payı[5].

Yenilenebilir enerji kaynakları arasında düşünüldüğünde rüzgâr enerjisi sürekli yatırım alan ve gelişim yönünden diğer kaynaklara oranla daha hızlı bir yükseliş gösteren lokomotif bir yenilenebilir enerji türü olmuştur. Şekil 1.3 incelendiğinde yıllara göre rüzgâr enerjisinden üretilen enerji değişimi çeşitli Avrupa ülkeleri için görülebilir[7].

Şekil 1.3 incelendiğinde Türkiye Devletinin yaklaşık olarak 31TWh elektrik enerjisini rüzgâr enerjisi kullanarak ürettiği görülmektedir. Yine aynı şekilde Şekil 1.3 incelendiğinde dünya ekonomisine yön veren G20 ülkelerinin birçoğunun rüzgâr enerjisinden faydalanarak elektrik enerjisi ürettiği görülmektedir. Bu durum şüphesiz büyük devletlerin enerji hususunda dışa bağımlılıklarını azaltmak adına yürüttükleri politik bir durumdur[5].

2021 yılında dünya çapında üretilen toplam 7931 TWh yenilenebilir enerjinin 1862 TWh'lık kısmını rüzgâr enerjisinin oluşturduğu görülmektedir ve Şekil 1.3'ten de görüleceği gibi 2021 senesinde Avrupa ülkeleri arasında rüzgâr enerjisi kullanımı bakımından Türkiye'nin 31.14 TWh ile üçüncü sırada olduğu görülmektedir[5].



Şekil 1.3 : Çeşitli Ülkelere Göre Rüzgâr Enerjisinin 1966 -2021 Yılları Arasındaki Değişimi[5]..

Rüzgâr enerjisinden faydalanmanın çeşitli sebepleri bulunmaktadır. Bu sebepler aşağıda kısaca tanımlanabilir[8];

- Enerjiyi oluşturan hava akımı “rüzgâr” ücretsizdir.
- Enerji kaynağının kendini yenileme hızı diğer alternatiflere göre oldukça yüksektir.
- Maliyeti düşüktür.
- Kirlenici etkisi az olan bir enerji kaynağıdır, çevrecidir, CO2 salınımı oldukça düşüktür.
- Enerji kaynağı açısından devletlerin dışa bağımlılığını azaltır.
- Millidir.
- Modülerdir, kurulum süreci hızlıdır.
- Çok yönlü arazi kullanımına uygun bir enerji türüdür.
- Hibrit sistemlere kolaylıkla entegre edilebilir.
- Uzun ömürlüdür.

Tüm bu olumlu özelliklerinin yanı sıra minilimize edilebilecek birtakım handikapları da mevcuttur. Bunlar kısaca şöyle tanımlanabilir[9];

- Gürültü ve görüntü kirliliği yaratma ihtimallerinin olması.
- Ekosisteme uyumsuz olabilmeleri.
- Kuş Türleri gibi canlılar üzerindeki olumsuz etkilere sahip olmaları.

Dünyanın geri kalanında olduğu gibi Türkiye Devletinde de elektrik enerjisi ihtiyacı sosyal-kültürel ve ekonomik gelişimlerin ve ilerlemelerin bir sonucu olarak yadsınamaz bir hızla yükseliş eğilimini sürdürmektedir. Ülkemizin içinde bulunduğu coğrafik konum itibarıyla sahip olduğu iklimsel özellikler düşünüldüğünde ve Türkiye Devletinin yenilenebilir enerji sektöründeki teşvikleri de göz önünde bulundurulduğunda rüzgâr enerjisi her geçen gün daha cazip bir enerji kaynağı olmaktadır[10].

Ülkemizin tabii kaynaklarının korunması, canlı habitatının devamlılığı, çevresel kirliliklerin minimize edilmesi ve enerji üretimi konusunda dışa bağımlılığının azaltılması hususunda bütün yenilenebilir enerji kaynaklarının sahip olduğu gibi rüzgâr enerjisinin de sahip olduğu önemli bir sorumluluğu ve gücü vardır. Kısaca tüm dünya devletleri adına, yenilenebilir enerji kaynaklarının kullanılmasında çevresel etkenlerin korunarak insan türünün yaşamını idame ettirmesinin önemi kadar ulus devletlerinin varlığını sürdürebilmeleri adına enerji hususunda dışa bağımlılığını da azaltması önemli bir etken olmuştur[8,10].

1.2. Rüzgâr Enerjisinin Tarihsel Gelişimi

İnsanlığın rüzgâr enerjisiyle tanışması, milattan önce 5000’li yıllarda bugünkü Mısır ülkesinde Nil nehrinde su araçlarının hareket ettirilmesinin istemesi sonucu olmuştur. Daha sonraki dönemlerde milattan önce 2000’li yıllarda uzak doğuda suyun iki farklı yükseklik arasında transferi için kullanılmıştır. Tarih çizgisi günümüze yaklaştıkça rüzgâr enerjisinin kullanımının verimini arttıran rüzgâr türbinlerinin de tarih sayfalarında yer aldığı görülmüştür. İlk rüzgâr türbini örneklerinin milattan önce 700’lü yıllarda Mezopotamya’da ortaya çıkmış olduğu düşünülmekle beraber kayıt altına alınan ilk rüzgâr türbinleri de milattan önce 200 ile 300 yılları arasında bugünkü Makedonya topraklarında hüküm sürmüş Büyük İskender dönemine aittir[8,9].

Avrupa kıtasında hüküm süren devletlerin rüzgâr enerjisini herhangi bir başka enerji çeşidine çeviren makinelerle tanışması ise haclı seferlerine dayanmaktadır. Mezopotamya ve Anadolu yarımadasına düzenlenen haclı seferleri neticesinde Avrupalı kavimler doğunun teknolojisi olan rüzgâr türbinleriyle tanışmış oldular. Bu tanışma sonrasında rüzgâr enerjisinden yararlanmak Avrupalılar için çeşitli amaçlar ışığında düşünüldü. 11. yüzyılın sonunda ve 12. yüzyılın başlarında Birleşik Krallıkta

rüzgâr türbinlerinin ilkel hali diyebileceğimiz rüzgâr milleri kuyulardan su eldesi için kullanılmıştır[11].


Rüzgâr türbinleri buhar makineleri kadar ön plana çıkmasalar da önemli yatırımlar olarak ilk sanayileşme evrelerini 19. Yüzyılın başlarında yaşamışlardır. Rüzgâr enerjisinden elektrik enerjisi eldesi için kullanılan ilk rüzgâr türbini yaklaşık 17 metre çapında ve 145 adet rotor kanadından oluşmaktaydı. Bu türbinin imalatçısı günümüzde de Amerika Birleşik Devletlerinde elektrik üretim pazarında önemli bir konuma sahip olan General Electrics şirketinin kurucu üyelerinden Amerikalı elektrik mühendisi F. C. Brush'tır[12]. Avrupa devletleri arasında ise yazılı kayıta geçen ilk rüzgâr türbininin kurucusu Meteorolog Poul La Courdur. Danimarkalı meteorolog bu türbini 19. Yüzyılın son çeyreğinde faaliyete geçirmiştir. Avrupa'da kurulan bu ilk rüzgâr türbininden sonra ikinci dünya savaşı ve sonrasında iki ya da daha fazla türbin kanadına sahip birçok rüzgâr türbini kurulmuştur. Bu dönemde faaliyete alınan üç rotor kanatlı türbinlerin sayısı döneme göre oldukça yüksek sayılara ulaşınca dünya çapında üç rotor kanatlı rüzgâr türbinleri Danimarka modeli olarak kabul görmüştür. Zaman skalası günümüze doğru yaklaştırıldığında ise modern rüzgâr türbinlerinin temeli olarak 1957 yılında P. L. Courun öğrencisi Johanes Juul tarafından tasarlanan ve imal edilen yaklaşık 200 kW'lık bir asenkron jeneratöre sahip ve yönelim manevraları yapabilen rüzgâr türbini gösterilebilir[12,13].

20. yüzyılın son çeyreğinde bireysel konutların ihtiyaçlarına karşılamak adına küçük rotor kanadı çaplı düşey ve yatay eksenli rüzgâr türbinleri tasarlanmış, imal edilmiş ve faaliyete geçirilerek elektrik enerjisi elde edilmiştir. Zamanla birlikte küresel çaplı çalışmalar çeşitli kurum ve kuruluşlarca yürütülmüş ve rüzgâr enerjisinden faydalanılarak elektrik enerjisi üretimi için büyük ölçekli rüzgâr santralleri kurulmuştur[14].

1.3. Küresel Ölçekte Rüzgâr Enerjisi

Yukarıdaki başlıklarda detaylıca anlatılan çevresel, siyasi ve ekonomik etkenlerden dolayı rüzgâr enerjisine yatırım yapma, Ar-Ge çalışmaları yürütme ve teknolojik entegrasyonlar geliştirme çabası 21. yüzyılın ilk çeyreğinde bulunan Türkiye gibi ekonomisi tarım ve sanayiye dayalı gelişmekte olan ülkeler için geçerli olduğu kadar dünya çapında bulunan 208 bağımsız ülke için de geçerlidir. Bu çalışmalar günden güne hızını arttırmakla beraber çeşitli konularda da teknolojik doygunluğa ulaşmaya

yaklaşmış bulunmaktadır[15]. Şekil 1.4 incelendiğinde dünya genelinde ülkelerin rüzgâr enerjisinden faydalanma durumları görülmektedir. Amerika Birleşik Devletleri ve Çin Halk Cumhuriyeti gibi küresel alanda üretim konusunda birbirleriyle rekabet eden iki büyük devletin yaklaşık 225 TWh ve üzerinde elektrik enerjisini rüzgâr enerjisinden elde ettikleri görülmektedir. Ülkelerin enerji konusunda dışa bağımsız olma çabaları için yenilenebilir enerji kaynaklarının önemi Şekil1.4'te de göze çarpmaktadır[5].



Şekil 1.4 : 2021 Senesinde Rüzgâr Enerjisinden Elde Edilen Elektrik Enerjisinin Dünya Üzerindeki Dağılımı[5].

21. yüzyılın ilk çeyreğinde yapılan çalışmalar dünyadaki potansiyel rüzgâr enerjisinin yaklaşık 53000 TWh olarak ortaya koymaktadır. Bu rüzgâr enerjisi potansiyelinin dünya üzerindeki dağılımı şekil 1.5'te görülmektedir. Şekil 1.5 incelendiğinde rüzgâr potansiyelinin en fazla olduğu bölge %26'lık pay ile Kuzey Amerika olurken, rüzgâr potansiyelinin en düşük olduğu bölge %6'lık pay ile Okyanusya olmuştur[5].

Şekil 1.6 ve Çizelge1.1 incelendiğinde, dünya çapında rüzgâr kurulu gücünün 1996 senesinden 2021 senesine kadar olan değişimi görülmektedir. Bu bilgiler ışığında rüzgâr kurulu gücünün artış hızının trendini koruyacağını ve önümüzdeki senelerde 900 GW ve üzeri değerlere ulaşacağı tahmin edilmektedir.

DÜNYA RÜZGAR POTANSİYELİ DAĞILIMI TWH




Şekil 1.5 : Rüzgâr Enerjisi Potansiyelinin Dünya Üzerindeki Dağılımı TWh (2021)[5].


Çizelge 1.1 : Dünya Çapında Rüzgâr Kurulu Gücünün Senelik Bazda Değişimi[5].

Yıl	Kurulu Güç (GW)	Yıl	Kurulu Güç (GW)
1996	6.07	2009	150.17
1997	7.62	2010	180.92
1998	9.94	2011	220.12
1999	13.43	2012	267.1
2000	17.3	2013	300.29
2001	23.98	2014	349.67
2002	30.98	2015	416.24
2003	38.39	2016	466.86
2004	49.61	2017	514.37
2005	58.44	2018	563.83
2006	73.15	2019	622.25
2007	91.5	2020	733.28
2008	115.35	2021	824.87

Şekil 1.7 ve Çizelge 1.2 incelendiğinde, 2021 senesinde dünya üzerinde en çok rüzgâr kurulu güç kapasitesine sahip olan 15 ülke ve bu ülkelerin rüzgâr kurulu güç kapasiteleri görülmektedir. İlk sırada 328.97 GW ile Çin rüzgâr enerjisinin lokomotifliğini yaparken onun hemen ardından küresel ekonomide en büyük rakibi olan Amerika Birleşik Devletleri 132.74 GW kurulu güç kapasitesiyle gelmektedir. Türkiye Devleti de 2021 senesinde 10.61 GW rüzgâr kurulu güç kapasitesi ile dünya üzerinde yer alan 208 ülke içinde 11. Sırada yer almaktadır.



Şekil 1.6 : Rüzgâr Enerjisi Kurulu Gücünün Dünya Genelindeki Değişimi (1996 – 2021)[5].



Şekil 1.7 : Ülkelerin Rüzgâr Enerjisi Kurulu Güçleri (2021)[5].


Çizelge 1.2 : 2021 Yılı Rüzgâr Enerjisi Kurulu Güçlerinin Ülke Bazlı Sıralamaları.

Sıralama	Ülke	Kurulu Güç (GW)	Sıralama	Ülke	Kurulu Güç (GW)
1	Çin	328.97	8	Kanada	14.30
2	ABD	132.74	9	İsveç	12.08
3	Almanya	63.76	10	İtalya	11.28
4	Hindistan	40.07	11	Türkiye	10.61
5	İspanya	27.50	12	Hollanda	7.80
6	B. Krallık	27.13	13	Finlandiya	3.26
7	Fransa	18.68	14	Rusya	1.96

1.4. Türkiye'nin Rüzgâr Enerjisi Bakımından Değerlendirilmesi

Enerji, tıpkı dünya üzerinde yer alan bütün resmi ülkelerde olduğu gibi Türkiye’de de ekonomik kalkınma, sosyal & kültürel kalkınma ve hayat kalitesinin iyileştirilebilmesi için oldukça elzem bir konudur. Enerji, yaşam standartlarındaki çeşitliliğin ya da diğer bir deyişle yaşam zenginliğinin yaratılmasında en temel etmen ve aynı zamanda ekonomik kalkınmada, önemi yadsınamaz çarpıcı bir faktör olarak kabul edilir. Enerji, Türkiye'nin en önemli kalkınma önceliklerinin başında yer almaktadır[16].

Artan nüfusa ve yaşanan teknolojik ilerlemelere bağımlı olarak yurtiçi enerji talebindeki hızlı artışlar, Türkiye’yi enerjide dışa bağımlılığını artırmaya ve 21. yüzyılın sonunu da kapsayacak şekilde gelecek asırda ciddi bir enerji kıtlığı tehlikesiyle karşı karşıya kalmaya zorlamıştır. Bu tehlikenin en belirgin işaretçisi Şekil 1.8’de gösterilen Türkiye’nin birincil enerji üretimi için kullandığı enerji kaynaklarıdır[2,16]. Şekil 1.8 ve Çizelge 1.3 incelendiğinde görüleceği üzere, Türkiye’nin tükettiği enerjinin %84’lük kısmı dış devletlere bağımlı enerji kaynaklarından üretilmektedir. Tüketilen enerjinin %31’lik kısmı doğalgaz, %28’lik kısmı petrol ve yine %26’lik kısmı kömür olmak üzere fosil yakıtlardan elde edilirken %7’lik kısmı hidro-enerji, %4’lük kısmı rüzgâr enerjisi %1’lik kısmı güneş enerjisi ve %1’lik kısmı diğer geleneksel olmayan kaynaklar olmak üzere yenilenebilir enerji kaynaklarından üretilmektedir.



Coal: Kömür, **Oil:** Petrol, **Gas:** Doğal Gaz, **Hydropower:** Hidro Enerji, **Wind:** Rüzgar Enerjisi, **Solar:** Güneş Enerjisi, **Other Renewables:** Diğer Yenilenebilir Enerji Kaynakları, **Turkey:** Türkiye

Şekil 1.8 : Türkiye’de Tüketilen Enerjinin Enerji Kaynakları Üzerine Dağılımı[5].

Çizelge 1.3 : Türkiye’nin Tükettiği Enerjinin Enerji Kaynakları Üzerine Dağılımı[5].


Enerji Kaynakları	Birincil Enerji İhtiyaçları İçin Kullanım Yüzdeleri
Doğalgaz	%30.79
Benzin	%28.18
Kömür	%26
Hidro enerji	%7.83
Rüzgâr Enerjisi	%4.38
Güneş Enerjisi	%1.80
Diğer Yenilenebilir Enerjiler	%1.01

Dünya tarihinin, milli devlet anlayışının giderek önem kazandığı 21. yüzyılının bu ilk çeyreğinde ulus devletleri de dahil olmak üzere her devletin enerji hususunda yaşadığı bu dışa bağımlılık yenilenebilir enerji kaynaklarının önemini gözler önüne sermektedir.

Türkiye’nin 1965 ve 2020 yılları arasında yenilenebilir enerji kaynaklarından ürettiği enerji senelik olarak değişimi şekil 1.19’da verilmektedir. Görüldüğü üzere Türkiye başta hidro enerji olmak üzere rüzgâr enerjisi, güneş enerjisi ve çeşitli yenilenebilir enerji kaynaklarını kullanmaktadır. Bir diğer önemli bulgu ise, yarım asrı geçen bu süreçte yenilenebilir enerji kaynaklarında hidro enerjinin birincilik konumunu

korumasıdır. Hidro enerji kullanılarak 1965 senesinden 2021 yılına kadar senelik olarak 2 TWh ile 89 TWh arasında enerji üretilmiştir[5].

Şekil 1.9 incelendiğinde göze çarpan bir diğer önemli detay ise hidro enerji dışındaki diğer enerji kaynaklarından üretilen enerjinin (rüzgâr , güneş, biokütle, jeotermal vb.) 2010 senesine kadar yıllık olarak 1 TWh enerjinin üzerine çıkamamış olmasıdır. Ek olarak Çizelge 1.4 incelendiğinde yenilenebilir enerji kaynaklarının 1965 senesinden 2021 senesine kadar olan mutlak değişimleri görülebilir. Yarım asrı aşkın bu süreç zarfında güneş enerjisinden üretilen enerji yaklaşık olarak 13 TWh, rüzgâr enerjisinden üretilen enerji yaklaşık olarak 31 TWh diğer yenilenebilir enerji kaynaklarından üretilen enerji %19 TWh ve hidro enerjiden üretilen enerji 54 TWh artmıştır.



Şekil 1.9 : Türkiye’nin Yenilenebilir Enerji Kaynaklarından Ürettiği Enerjinin Yıllara Göre Değişimi[5].

Çizelge 1.4 : Türkiye’de Yenilenebilir Enerji Kaynaklarından Üretilen Enerjinin 1965-2021 Yılları Arasındaki Mutlak Değişimi[5].

Yenilenebilir Enerji Kaynağı	1965 Yılı Enerji Üretimi (TWh)	2021 Yılı Enerji Üretimi (TWh)	Enerjideki Mutlak Değişim (TWh)
Rüzgâr	0	31	31
Güneş	0	13	13
Hidro enerji	2	56	54
Diğer	0	19	19


Türkiye Enerji ve Tabii Kaynaklar Bakanlığının Aralık 2020 sonu ile yayınladığı yayında belirtildiği üzere, Türkiye sınırları içerisinde yerden 50 m yükseklikte ve minimum 7.5 m/s rüzgâr hızına sahip her bölgede kilometrekare başına 5 MW güce sahip rüzgâr santrali kurulabileceği belirtilmiştir. Bu kabuller ışığında ülke çapında yapılan çalışmaların sonucu olarak Türkiye Rüzgâr Enerjisi Potansiyeli Atlası ya da diğer bir adıyla R.E.P.A. oluşturulmuştur. Yapılan çalışmalar sonucunda Aralık 2020 itibariyle Türkiye Cumhuriyeti Devletinin rüzgâr enerjisi potansiyeli yaklaşık olarak 48000 MW olarak saptanmıştır[4].

Çizelge 1.5 incelendiğinde Türkiye genelinde sınıflandırılmış rüzgâr türlerinin ve o sınıflara ait rüzgârların yaratabileceği toplam rüzgâr gücü kapasitesi belirtilmiştir. Türkiye'nin rüzgâr enerjisi potansiyelinin yaklaşık %61.14' lük kısmını 7.0 – 7.5 m/s hıza sahip 4 numaralı rüzgâr sınıfı oluşturmaktadır. Türkiye'nin, yaklaşık 48000 MW değerindeki bu toplam rüzgâr gücü kapasitesini topraklarının yalnızca %1.30'unu kullanarak elde ettiğini gözden kaçırmamak rüzgâr enerjisinin diğer enerji kaynakları arasındaki önemini bir kere daha gözler önüne sermektedir.

Çizelge 1.5 : Türkiye'nin Rüzgâr Enerjisi Kurulu Gücü[17].


Rüzgâr Sınıfı	Yıllık Güç Yoğunluğu (W/m ²)	Yıllık Ortalama Rüzgâr Hızı (m/s)	Toplam Kapasite (MW)
4	400 – 500	7.0 -7.5	29259.36
5	500 – 600	7.5 – 8.0	12994.32
6	600 – 800	8.0 – 9.0	5399.92
7	>800	>9.0	195.84
Toplam Kapasite			47849.44
			Karasal:37836
			Deniz Üstü: 10013

Türkiye sahip olduğu bu toplam rüzgâr kurulu gücünün arttırılabilmesi efektif şekilde çalışacak rüzgâr enerjisi santrallerine bağlıdır. Kurulacak olan yeni rüzgâr enerjisi santrallerinin fizibilite çalışması için Türkiye rüzgâr enerjisi potansiyeli atlasının kullanılması elzem bir husustur. Şekil 1.10 incelendiğinde Türkiye için oluşturulmuş rüzgâr enerjisi potansiyeli atlası görülmektedir. Bu atlas, zeminden 100 metre yükseklikteki ortalama rüzgâr hızı verilerini içermektedir. Türkiye genelinde 4.5 m/s ve üzerinde rüzgâr hızlarına ulaşmak mümkündür. Konum itibariyle ülkenin batı kesimi rüzgâr enerjisi potansiyeli bakımından oldukça avantajlı konumdadır. Ayrıca konum itibari ile sadece karasal rüzgâr enerjisi santrali değil aynı zamanda deniz üstü rüzgâr enerji santralleri açısından da Türkiye büyük bir avantaja sahiptir[18].




Şekil 1.10 : Türkiye Rüzgâr Enerjisi Potansiyeli Atlası (100 m yükseklik / Ortalama Hız) [15].

Türkiye, gerek çevresel etmenler gerek siyasal etmenler gerekse de teknolojik gelişmelerin bir sonucu olarak rüzgâr enerjisi kurulu gücünü her geçen senede kümülatif olarak arttırmıştır. Her geçen seneye birlikte rüzgâr enerjisinin toplam elektrik enerjisi üretimindeki payı da yadsınamaz bir artış göstermektedir. Şekil 1.15 incelendiğinde 2011 – 2022 arasında Türkiye’nin sahip olduğu rüzgâr kurulu gücünün değişimi görülmektedir. 2011 senesinde 1.7 GW olan rüzgâr kurulu gücünün 2022 yılında 10.97 GW değerlerine ulaşarak yaklaşık olarak %545 oranında büyüdüğü görülmektedir. Şekil 1.16 incelendiğinde görüleceği üzere, 2011 senesinde Türkiye genelinde toplam elektrik üretiminin sadece % 3.27’lik kısmı rüzgâr enerjisinden sağlanırken 2022 senesinde bu oran %230 oranında büyüyerek %10.81 değerine ulaşmıştır[5].



Şekil 1.11 : Türkiye’nin Rüzgâr Enerjisi Kurulu Güçleri GW (2011-2021)[5].



Şekil 1.12 : Türkiye’de Rüzgâr Enerjisinin Elektrik Üretimindeki Payı[5].

Türkiye’de 2022 yılı itibariyle 267 tanesi lisanslı 17 tanesi lisanssız olmak üzere toplam 284 santrale ve toplamda 4101 adet rüzgâr türbinine sahip 129 yatırımcı firma rüzgâr enerjisi üzerine çalışmaktadır. Çizelge 1.6’da Türkiye Cumhuriyeti Devleti topraklarında bulunan, kurulu güç bakımından en büyük ilk on rüzgâr santrali ve teknik bilgileri incelenebilir. Bu türbinlerin işletmeye geçiş tarihlerinin Türkiye’nin yenilenebilir enerji sektörüne keskin bir geçiş yaptığı yıl olan 2010 ve sonrasına tekabül etmeleri yenilenebilir enerji teşviklerinin önemini bir kere daha gözler önüne sermektedir[16,19].

Çizelge 1.6 : Türkiye’nin Kurulu Güç Bakımından En Büyük İlk On Rüzgâr Enerjisi Santrali[19].

Sıra	Santral Adı	İl	Firma	Kurulu Güç (MW)
1	Soma R.E.S.	Manisa	Polat Enerji	288
2	Karaburun R.E.S.	İzmir	Alto Holding	227
3	Dinar R.E.S.	Afyon	Güriş Holding	200
4	İstanbul R.E.S.	İstanbul	Universal Enerji	200
5	Geycek R.E.S.	Kırşehir	Polat Enerji	168
6	Balıkesir R.E.S.	Balıkesir	Enerjisa	143
7	Gökçedağ R.E.S.	Osmaniye	Zorlu Enerji	135
8	Saros R.E.S.	Çanakkale	Borusan Enerji	133
9	Kangal R.E.S.	Sivas	Ece Tur İnşaat	128
10	Şamlı R.E.S.	Balıkesir	Fernas Enerji	127

Şekil 1.13 incelendiğinde Türkiye’de yer alan lisanslı ve lisanssız rüzgâr enerji santrallerinin konumu görülebilir. Rüzgâr enerji santrallerinin büyük bir kısmı Türkiye’nin batı kesiminde yer almaktadır.



Şekil 1.13 : Türkiye Rüzgâr Santralleri Atlası[19].

1.5. Tez Çalışmasının Amaçları

Yürütülen bu bilimsel çalışmanın amaçlarından ilki yukarıda detaylıca anlatılan fosil enerji kaynakları olarak adlandırdığımız geleneksel enerji kaynaklarının enerji üretim sürecinde oluşturdukları sera gazlarının çevreye olumsuz etkileri, dünya genelinde eşit olmayan dağılımları sebebiyle birkaç devletin kontrolünde olmaları, lokal olaylardan kolaylıkla olumsuz olarak etkilenmeleri ve miktarlarının sınırlı olmasından kaynaklanan sorunları ortadan kaldıracak en önemli alternatif yenilenebilir enerji kaynağı olan rüzgâr enerjisinin gelişim sürecini ve günümüz konjonktüründe dünya genelinde enerji kaynakları arasındaki konumunu tanımlayan kapsamlı bir literatür araştırmasını yapmaktır.

Yürütülen çalışmanın diğer bir amacı ise rüzgâr enerjisinin en önemli elemanı olan rüzgâr türbinlerinin gelişim süreçleri ve çalışma prensipleri üzerine kapsamlı bir literatür çalışması yürütmek ve rüzgâr türbinlerinin çeşitli coğrafik şartlar altında üretebilecekleri güçlerin tahmin edilmesi adına yapay zeka kuramının makine öğrenmesi kolu kullanılarak çeşitli tahmin modelleri geliştirmek ve geliştirilen tahmin

modellerinin çeşitli başarı kriterlerine göre değerlendirip en başarılı tahminlerde bulunan makine öğrenmesi modelini önermektir.

Bu tez kapsamında yürütülen bir diğer çalışmanın amacı ise birçok rüzgâr türbininden oluşan rüzgâr santrallerinin yıllık enerji üretimi ve güçlerini arttırmak amacıyla rüzgâr türbinlerinin arazi içerisindeki yerleşim planını tanımlayan bir konumlandırma modeli geliştirmektir.

Rüzgâr enerjisinin ve rüzgâr türbinlerinin kümülatif bir şekilde gelişimini sürdürdüğü göz önünde bulundurularak bu çalışmanın kapsamı Bursa'da ve İstanbul'da bulunan ve faal olarak elektrik üretimine devam eden rüzgâr santrallerinin verileri kullanılarak üretilen rüzgâr gücü tahmini modelleri oluşturmak ve rüzgâr türbinlerinin maksimum enerji üretecek şekilde araziye yerleştirilmeleri üzerine bir model geliştirmek olarak sınırlandırılmıştır.

Yukarıda açıklanan, geleneksel enerji kaynaklarının sebep olduğu problemler nedeniyle dünyanın genelinde olduğu gibi Türkiye'de de rüzgâr enerjisine önemli bir yönelim olmuştur. Özellikle devlet teşviklerinin arttırıldığı 2010'lu senelerde çoğu enerji firması resmi rüzgâr santralleri kurabilmek adına Türkiye Cumhuriyeti Enerji ve Tabii Kaynaklar Bakanlığına başvurmuştur. Rüzgâr santrallerinin lisans alabilmeleri için kurulacakları bölgedeki saha çalışmalarının tamamlanmış olması son derece önemlidir. Çoğu enerji firmasının bu çalışmalara yüksek derecede önem verdikleri görülmektedir. Aksi takdirde enerji üretimi istenilen planda ilerlemez ve bu da enerji firmalarının ağır mali tablolar altında ezilmelerine yol açabilir. Bu saha çalışmalarının şüphesiz en önemli iki unsuru rüzgâr türbinlerinin kurulacak arazideki konumlarının belirlenmesi ve rüzgâr türbinlerinin kurulacakları bölgede üretebilecekleri rüzgâr enerjisinin ya da rüzgâr gücünün tahmin edilmesidir. Bu sebeplerden dolayı yürütülen bu çalışmanın literatürde enerji firmaları için oldukça elzem bir konu üzerine olması nedeniyle gelecekteki çalışmalar için bir temel oluşturabileceği düşünülmektedir.

Kısaca özetlemek gerekirse yürütülen bu çalışmanın iki esas amacı bulunmaktadır. Bu amaçlardan ilki, Bursa'da bulunan bir rüzgâr santralının verilerini kullanarak rüzgâr türbinlerinin üretebilecekleri güçlerin makine öğrenmesi ve yapay zekâ algoritmaları kullanılarak tahmin edilebileceği doğruluğu ve kesinliği yüksek bir algoritma modeli oluşturmaktır. Çalışmanın diğer bir amacı ise İstanbul'da bulunan ve faal olarak

elektrik üretimine devam eden bir rüzgâr santralının verileri kullanılarak rüzgâr çiftliğinin enerji üretimini arttıracak yeni bir yerleşim planı oluşturmaktır.

1.6. Tez Çalışmasının Yöntemi

Rüzgâr enerjisi, rüzgâr türbinleri ve rüzgâr santralleri üzerine yapılan bu çalışmada kullanılmış olan yöntemler ve izlenilen yol haritası şu şekilde açıklanabilirler;

İlk olarak, yenilenebilir enerji kaynaklarının öneminin ve bu enerji kaynaklarına olan büyük talebin somut delilleri üzerinde kapsamlı bir literatür çalışması yürütülerek rüzgâr enerjisinin tarihi, gelişim süreçleri, dünya genelindeki ve ülkemizdeki durumu detaylıca incelenmiştir. Rüzgâr enerjisinden faydalanabilmek adına kullanılan rüzgâr türbinlerinin tarihleri, gelişim süreçleri, çalışma prensipleri ve günümüz konjonktüründen bakıldığındaki konumları kapsamlı bir şekilde araştırılmıştır.

Sonrasında, Bursa’da bulunan ve faal olarak elektrik üretimine devam eden lisanslı bir rüzgâr santralının rüzgâr türbinlerinin belirli bir zaman aralığında ölçülmüş verileri kullanılarak ilgili rüzgâr türbinlerinin çeşitli rüzgâr hızları altında üretebilecekleri rüzgâr güçlerinin ve rüzgâr enerjilerinin tahmin edilmesi adına yapay zeka kuramının makine öğrenmesi kolunun çeşitli tahmin algoritmalarını temel alan çeşitli tahmin modelleri geliştirilmiş ve her bir modelin tahmin başarısı çeşitli başarı ölçüm metrikleri ile test edilmiş ve rüzgâr türbinlerinin üretebileceği güçleri en yüksek doğrulukta tahmin eden model tespit edilmeye çalışılmıştır. Bu kısımda açık kaynak kodlu olması nedeniyle Python yazılım dili ve arayüz gelişmişliği nedeniyle Spyder tümleşik geliştirme ortamı tercih edilmişlerdir.

Sonrasında, İstanbul’da bulunan ve faal olarak elektrik üretimine devam eden lisanslı bir rüzgâr santralının rüzgâr türbinlerinin verileri kullanılarak ilgili rüzgâr santralının yıllık üretebileceği enerji miktarı ve gücü arttırılmaya çalışılmıştır. Çalışmanın bu kısmında açık kaynak kodlu olması sebebiyle Python programlama dili ve arayüz gelişmişliği sebebiyle Spyder tümleşik geliştirme ortamı tercih edilmiştir.

Yukarıda bahsedilen çalışmaların her biri yürütülürken, internet yardımıyla konu ile alakalı birçok veri tabanı taranmış ve elektronik kitaplar, makaleler, bildiriler, panel ve sempozyum sunumları irdelenerek kapsamlı bir araştırma içerisine girilmiştir. Ek olarak rüzgâr enerjisi ile ilgili çalışmalarda bulunan akademisyenlerle ve araştırmacılarla bilgi alışverişinde bulunulmuştur. Tüm bunların yanı sıra gerek rüzgâr

santrallerinin verilerinin temini kısmında gerekse de rüzgâr türbinleri hakkında kataloglardan ya da yazılı kaynaklardan elde edilmesi zor olan bilgilerin eldesi kısmında enerji sektöründe uzun yıllardır çalışan nitelikli rüzgâr santrali idari personelleri ve teknik personelleriyle sohbetler edilerek bilgi alışverişinde bulunulmuştur.





2. ENERJİ DÖNÜŞÜM MAKİNELERİ OLARAK RÜZGÂR TÜRBİNLERİ

Rüzgâr türbinleri, teorik olarak rüzgâr hızından faydalanarak bir hareket sağlayan ve bu hareketi çeşitli mekanik ekipmanlarla güçlendirerek rüzgâr enerjisini çoğunlukla elektrik enerjisine dönüştüren elektronik ve mekanik temelli bir enerji dönüşüm teknolojisidir. Kesin olarak dünya tarihi sahnesine çıkışları bilinmese de rüzgâr enerjisinin kullanımının Mısır tarihi yazıtlarıyla insanlığa sunulduğu düşünülmektedir[13].

Rüzgâr enerjisinin ilk kullanımı Nil nehri üzerinde gemilerin seyir süreçlerinde rol alırken görülmüştür. Deniz üzerinde bu şekilde kullanılan rüzgâr enerjisi, karalarda ise tarım amaçlı faaliyetlerde kullanılmıştır. Tarım amaçlı ilk örnekleri yine kadim uygarlıklardan biri olan Mısır medeniyetinde göze çarpmaktadır. Antik Mısır döneminde, buğday, mısır, arpa gibi çeşitli tahıl ürünlerinin öğütülmesi için yapılan değirmenlerde rüzgâr türbinleri ve rüzgâr enerjisi aktif olarak kullanılmışlardır[20].

Şark medeniyetlerinde de yukarıda bahsi geçen şekillerde rüzgâr enerjisi kullanılmış ve zamanla kullanılan cihazlar ve yöntemler geliştirilmiştir. M.Ö. on yedinci yüzyılda kurulan ve UNESCO dünya mirası listesinde yer alan Babil krallığında rüzgâr türbini ve rüzgâr enerjisinin izleri görülmektedir. Kral Hamurabi döneminde, Babil'in asma bahçelerinin sulama sistemlerinde dönemin imkanlarıyla basit rüzgâr türbinlerinin kullanıldığı bilinmektedir. Mezopotamya topraklarında bu şekilde gelişim gösteren rüzgâr enerjisi aynı zaman diliminde Çin krallığında da tarım amaçlı kullanılmıştır. Türki kavimlerin ve perslerin rüzgâr enerjisi ile tanışmaları ise M.S. yedinci yüzyıla tekabül etmektedir. Şark medeniyetlerinin aksine batı medeniyetlerinin rüzgâr enerjisi ile yada başka bir deyişle rüzgâr türbinleri ile tanışmaları tarih sahnesinde şark medeniyetlerinden sonra olmuştur[21].

Haçlı seferleri sırasında ilk defa rüzgâr türbinleriyle tanışan batı medeniyetleri, ilk ilkel rüzgâr türbinlerini M.S. on ikinci yüzyılda kullanmaya başlayabilmişlerdir. Batı medeniyetlerinin ilk rüzgâr türbini örneklerini İngiltere'de ve Fransa'da su pompalamak ve çeşitli tarımsal gıdaları öğütmek amacıyla kullanıldıkları görülmektedir. Buhar devrimi olarak adlandırılan sanayi devrimine kadar Avrupa'da

rüzgâr türbinlerinin sayısı katastrofik şekilde artış göstermektedir. M.S. 18. Yüzyılın sonunda sadece Hollanda'da 10.000'in üzerinde yel değirmeni bulunduğu bilinmektedir[20,21].

Avrupa'da Rüzgâr türbini kullanarak elektrik üretimi gerçekleştiren ilk insan Danimarkalı bir fizikçi ve aynı zamanda meteoroloji uzmanı olan Paul La Courdur. Cour 1891 yılında yaklaşık 18kW güce ulaşan ve 4 türbin kanatlı ilk rüzgâr türbinini üretmiştir[12]. Şekil 2.1'de Cour tarafından elektrik üretmek amacıyla üretilen yatay eksenli rüzgâr türbini görülmektedir.




Şekil 2.1 : La Cour Rüzgâr Türbini(12).

La Cour'un rüzgâr türbini kullanarak elektrik üretebileceğini kanıtlamasının ardından çeşitli bilim insanları tarafından farklı tasarımlarla rüzgâr türbinleri üretilmiştir. Modern rüzgâr türbinlerini temelini ise yine Danimarka menşeli bir şirket olan Gedser firmasının, üç türbin kanatlı, asenkron jeneratörlü, fren sistemli ilk türbini olan yaklaşık 200 kW güce sahip olan Gedser türbinidir. Gedser türbinin faaliyete geçiş ya da başka bir deyişle ilk elektrik ürettiği tarih 1957 olarak yazılı tarihimizde yerini almıştır[12].

Milenyuma yaklaştıkça, rüzgâr türbini teknolojisinde yadsınamayacak gelişmeler yaşanmıştır. 1990lı yılların içerisinde türbin kanatlarının tasarımı ve kule yüksekliği konularında oldukça çarpıcı gelişmeler yaşanmıştır. Örneğin elektrik üretilen ilk rüzgâr türbinlerinin yükseklikleri 20 metre civarındayken günümüzde rüzgâr türbinlerinin yükseklikleri 200 metreye yaklaşmaktadır[14]. Ek olarak rüzgâr türbini


kanatlarının tasarımının da oldukça deđiřtiđini, ilk dnemlerde kullanılan ilkel kanatlar yerine NACA profillerinin kullanıldığını syleyebiliriz[22]. Tm bu teknolojik geliřmeler sonucunda, rzgr trbini teknolojisi La Courtun 18 kW gcndeki rzgr trbininden 15 MW gcndeki modern rzgr trbinlerine hızlıca ulařmıřtır. řekil 2.2’de rzgr trbinlerinin geliřimlerinin zaman skalasındaki deđiřimi gsterilmektedir[23].



řekil 2.2 : Rzgr Trbinlerinin Zamanla Deđiřimi[23].

2.1. Rzgr Trbini eřitleri ve Sınıflandırılmaları

Rzgr trbinleri eřitli sınıflandırma yntemleriyle sınıflandırılabilirler. Bu yntemler temel olarak eksen, gc, kanat sayısı, rzgr alıř aısı, diřli sistemi, kurulum blgesi, devir olarak tanımlanabilirler. řekil 2.3’te bu sınıflandırma ve alt bařlıklar incelenebilir.



Şekil 2.3 : Rüzgâr Türbini Çeşitleri ve Sınıflandırılmaları[24].

2.1.1. Rüzgâr türbinlerinin dönme eksenlerine göre sınıflandırılmaları


Genel itibariyle rüzgârın hızını kullanarak rüzgâr enerjisini öncelikli olarak mekanik enerjiye ve daha sonra çeşitli elektriksel ekipmanlarla mekanik enerjiyi elektrik enerjisine çeviren rüzgâr türbinleri dönme eksenine itibariyle iki ana sınıfa ayrılabilirler. Bunlar sırasıyla yatay eksenli rüzgâr türbinleri ve düşey eksenli rüzgâr türbinleridir.

Yatay eksenli olarak tabir edilen rüzgâr türbinlerinin isimi hub dediğimiz türbinlerin baş kısmının türbinin yerleştirildiği zemine paralel olmasından gelmektedir. Bu tarz türbinlerde türbin kanatlarının dönme eksenine rüzgârın esiş doğrultusuna paraleldir. Türbin kanatları rüzgâr esiş doğrultusuna dik olacak şekilde konumlandırılmışlardır. Bu tarz türbinlerin elektrik üretebilmeleri için sürekli olarak türbin kanatlarının konumlarının rüzgârın esiş doğrultusuna göre dik olacak şekilde ayarlanmaları gerekmektedir[24]. Bu önemli ayarın yapılabilmesi için ekstra olarak yatay eksenli rüzgâr türbinlerinde YAW mekanizması adı verilen bir sistem kullanılmaktadır. Bu sistem sayesinde hâkim rüzgâr yönü belirlenerek türbinin hub diye adlandırılan baş kısmı çeşitli yardımcı motorlar vasıtasıyla kule üzerinde döndürülerek hâkim rüzgâr yönünü doksan derecelik bir açıyla karşılayacak pozisyona getirilir. İlk örnekleri antik Mısır, Babil gibi önemli Mezopotamya kültürlerinde görülen yatay eksenli rüzgâr türbinlerinin verimleri teknolojinin gelişmesiyle beraber %45 seviyelerine ulaşmıştır[21].

Bu sınıflandırmanın diğer bir önemli üyesi olan düşey eksenli rüzgâr türbinleri isimlerinden de anlaşılabilceği üzere dönme eksenini yerleştirildikleri zemine dik olan rüzgâr türbinleridir. Yatay eksenli rüzgâr türbinleri gibi rüzgârı dik olarak karşılamak adına konum değiştirici bir yardımcı mekanizmaları yoktur. Rüzgârı, yapıları gereği her zaman esiş yönüne dik olacak şekilde karşılarlar. Ticari amaçla kullanımları oldukça az olmakla birlikte genellikle akademik ve bilimsel çalışmalarda deneysel olarak kullanılırlar. Boyutları yatay eksenli rüzgâr türbinlerine kıyasla oldukça düşüktür. Savenius ve Darreius olmak üzere iki farklı çeşitleri bulunmaktadır[25].



Yatay Eksenli Rüzgar Türbini



Düşey Eksenli Rüzgar Türbini

Şekil 2.4 : Eksenlerine Göre Rüzgâr Türbinleri[26,27].

2.1.2. Rüzgâr türbinlerinin kanat sayılarına göre sınıflandırılmaları

Rüzgâr türbinlerinin önemli bir sınıflandırma biçimi de içerdikleri türbin kanatlarının sayısıdır. Türbin kanatlarının sayısı direkt olarak atalet momentini ilgilendirdiği için türbinin üreteceği gücü belirlemekte önemli bir parametredir. Genel olarak rüzgâr türbinleri dönme ekseninden bağımsız olarak tek kanatlı, iki kanatlı, üç kanatlı ve çok kanatlı olmak üzere dört ana grupta kümelenebilirler[24]. Şekil 2.5'te tek kanatlı, iki kanatlı, üç kanatlı ve çok kanatlı rüzgâr türbinleri görülebilir.


Tek kanatlı rüzgâr türbinleri yapısı gereğince sadece yatay eksenli rüzgâr türbinlerinde kullanılırlar. Kanat maliyeti az olmasından dolayı diğer çok kanatlı yatay eksenli rüzgâr türbinlerine kıyasla daha ekonomik oldukları bir gerçektir ancak bu avantajının

yanı sıra tek kanadın yarattığı statik dengesizlik sebebiyle ekstra stabilizasyon mekanizmalarına ihtiyaç duyarlar. Tek kanatlı rüzgâr türbinleri elektrik üretmek maksadından ziyade genellikle su pompalamak gibi tarımsal faaliyetlerde kullanılırlar[21,24].

İki kanatlı rüzgâr türbinleri, tek kanatlı rüzgâr türbinlerinde karşılaşılan dinamik stabilizasyon sorunu ve gürültü sorununa alternatif bir çözüm olarak üretilen rüzgâr türbinleridir. Kanat sayılarının tek kanatlılara göre fazla olması nedeniyle ataletten kaynaklanan sebeplerden ötürü kanat ucu hızı tek kanatlı türbinlere göre daha düşüktür ve bu sebepten yarattıkları gürültü de tek kanatlı türbinlere göre büyük ölçüde azdır. Bu sebeple elektrik üretimi maksatlı olmayan uygulamalarda kullanılırlar[21,24].

Üç kanatlı rüzgâr türbinleri, günümüzde dünya üzerinde en çok kullanılan rüzgâr türbinleridir. Ataları olan tek kanatlı ve iki kanatlı rüzgâr türbinlerinin yarattığı gürültü ve stabilizasyon problemlerini büyük ölçüde çözmeyi başarmışlardır. Üç kanatlı yapıları nedeniyle rüzgâr hızından bağımsız olarak kanatlar çalışma sürecinde sabit atalet momentine sahiptirler. Bu sebepten dolayı diğer rüzgâr türbinleri gibi stabilizasyon problemini aşmak adına pahalı ekstra parça veya sistem gereksinimi duymazlar. Üç kanatlı modern rüzgâr türbinleri uygun koşullar altında 6 MW mertebelerinde güç üretimi sağlayabilirler[21,24].

Çok kanatlı rüzgâr türbinleri yatay eksenli rüzgâr türbinlerinin atası olarak kabul edilirler. Kanat sayılarının fazla olması sebebiyle atalet momentleri büyüktür. Bu durum kanatların tahrik ettirdiği milin dönme hızının düşük olmasına sebep olur. Bu sebepten ötürü, bu tarz türbinler elektrik üretimi için uygun değildir. Çok kanatlı rüzgâr türbinleri sadece su pompalamak, iletmek ve tahıl ürünlerini öğütmek amacıyla günümüzden çok eski zamanlarda kullanılmışlardır[21].



Şekil 2.5 : Kanat Sayılarına Göre Rüzgâr Türleri[24].

2.1.3. Rüzgâr türbinlerinin devir sayılarına göre sınıflandırılmaları

Devir sayılarına göre rüzgâr türbinleri düşük devirli veya yüksek devirli olarak iki ana başlık altında toplanabilirler. Düşük devirli rüzgâr türbinleri elektrik üretmek açısından maliyetli rüzgâr türbinleridir bu nedenle tarımsal işler ya da sulama işlemleri için kullanılırlar. Yüksek devirli rüzgâr türbinleri ise elektrik üretimi için uygun olup rüzgâr santrallerinde elektrik üretimi için kullanılırlar[28].

2.1.4. Rüzgâr türbinlerinin güçlerine göre sınıflandırılmaları

Rüzgâr türbinleri ürettikleri güç bakımından küçük, orta ve büyük olarak üç ana sınıfta toplanabilirler. Küçük güçlü rüzgâr türbinleri kişisel amaçla kullanılan rüzgâr türbinleridir. Güçleri 1 kW ile 30 kW arasında değişen türbinlerdir. Boyutları diğer güçlerdeki türbinlere kıyasla küçüktür. Orta güçlü rüzgâr türbinleri, endüstriyel amaçlarla kullanıma uygun olmayan genellikle bireysel amaçlarla kullanılan rüzgâr türbinleridir. Ürettikleri güçler 30 kW ile 100 kW arasında değişmektedir. Genellikle düşey eksenli rüzgâr türbinleri ve modern olmayan yatay eksenli rüzgâr türbinleri bu sınıfta yer alırlar. Büyük güçlü rüzgâr türbinleri, endüstriyel amaçlı kullanılan rüzgâr türbinleridir. Günümüzde kullandığımız üç kanatlı yatay eksenli rüzgâr türbinleri bu sınıfta yer alırlar. Ürettikleri güçler 100 kW ile 6 MW arasında değişiklik gösterebilirler. Boyut olarak diğer rüzgâr türbinlerinden oldukça büyüktürler[24,29].

2.1.5. Rüzgâr türbinlerinin rüzgâr alış açılara göre sınıflandırılmaları

Rüzgâr türbinleri rüzgâr diye tanımlanan nitelikli hava kütlesi hareketinin enerjisinden maksimum düzeyde yararlanabilmek için bahsi geçen hava hareketine dik olacak şekilde konumlandırılırlar. Bu konumlandırma işlemi sonucunda rüzgârı ön kısımdan ya da arka kısımdan karşılayacak şekilde iki ana grup altında toplanabilirler. Rüzgârı arkadan karşılayan rüzgâr türbinleri, genellikle elektrik üretmek amaçlı kullanılmayan ve tarımsal faaliyetlerde kullanılan türbinler olarak bilinirler. Tek kanatlı rüzgâr türbinleri bu sınıfın en bilindik rüzgâr türbinleridir. Rüzgârı önden karşılayan rüzgâr türbinleri, genellikle endüstrilerde ticari amaçlarla kullanılan boyut olarak büyük ve güçlü türbinlerdir. Günümüzde elektrik üretmek amacıyla kullandığımız modern üç kanatlı rüzgâr türbinleri bu sınıfın en önemli üyeleridir[30].

2.1.6. Rüzgâr türbinlerinin dişli kutusu sistemlerine göre sınıflandırılmaları

Rüzgâr enerjisini elektrik enerjisini döndürmek için kullanılan rüzgâr türbinleri rüzgâr hızı potansiyeline ve kullanılan jeneratör tipine bağlı olarak Dişli kutusu bulundurma bakımından iki ana başlık altında toplanabilirler. Bunlar sırasıyla Dişli kutusuna sahip rüzgâr türbinleri ve dişli kutusu bulundurmayan rüzgâr türbinleridir. Dişli kutusuna sahip olan rüzgâr türbinleri maliyetin düşük olması sebebiyle az kutuplu yüksek devirli jeneratörlere sahip olan türbinlerdir. Bu türbinlerin dişli kutusu yardımıyla jeneratöre ulaşan milin dönüş hızını genellikle 1/50 ya da 1/70 oranında arttırmaları gerekmektedir. Dişli kutusu olmayan rüzgâr türbinlerinde çok kutuplu düşük devirli jeneratörler kullanılmaktadır. Bu sebeple düşük hızlarda da elektrik üretilbildiğinden dişli kutusuna ihtiyaç duyulmamaktadır[30,31].

2.1.7. Rüzgâr türbinlerinin kurulum bölgelerine göre sınıflandırılmaları

Rüzgâr türbinleri bilindiği üzere rüzgâr denilen hava hareketini kullanarak önce mekanik enerji daha sonra da elektrik enerjisi üreten teknolojik aletlerdir. Bu nedenle rüzgâr potansiyelinin ve coğrafi koşulların uygun olduğu her alana kurulumları gerçekleştirilebilirler. Genel olarak rüzgâr türbinlerini kuruldukları bölgeye göre deniz üstü offshore ve kara üstü onshore olarak iki ana başlık altında toplamak mümkündür. Rüzgâr türbinlerinin açık deniz üzerine kurulduğu uygulamaları Offshore olarak adlandırılmaktadır. Avrupa kıtasında yaygın olarak kullanılan Offshore rüzgâr türbinlerinin ilk örnekleri 1991 yılında Danimarka'da görülmüştür. Çizelge 2.1 incelendiğinde Dünya genelinde açık deniz rüzgâr enerjisinin kullanım durumu görülebilir. Ayrıca Şekil 2.6 incelendiğinde Dünya üzerindeki ilk açık deniz rüzgâr santrali olan Vindeby santrali incelenebilir[32].


Çizelge 2.1 : 2021 Dünya Offshore Rüzgâr Enerjisi Kurulu Gücü [33].

Ülke	Toplam Kurulu Güç (MW)
Birleşik Krallık	9723
Almanya	7493
Belçika	1556
Danimarka	1703
Hollanda	1118
Diğer Avrupa Ülkeleri	310
Çin	6838
Güney Kore	292
Diğer Asya Ülkeleri	30
Amerika	30



Şekil 2.6 : Vindeby Açık Deniz Rüzgâr Santrali[34].

Okyanus ya da açık deniz üzerine inşa edilmeyen ve kara parçaları üzerine inşa edilen rüzgâr türbinleri onshore türbinler olarak adlandırılırlar. Tarihteki ilk onshore rüzgâr santrali 1980 yılında Amerika Birleşik Devletleri'nin New Hampshire eyaletinde 30 kW gücündeki 20 rüzgâr türbini kullanılarak oluşturulmuştur. İlk defa toplam kurulu güçleri 600 kW olarak karşımıza çıkan Onshore rüzgâr santralleri teknolojinin gelişmesiyle birlikte önemli yol kat etmişlerdir[35,36]. Günümüzde en büyük kapasiteli Onshore rüzgâr santrali Çinin Jiuquan şehrinde bulunan, yaklaşık 7000 rüzgâr türbinine sahip ve 20 GW kurulu güç hedefi olan ve günümüzde nihai 8 GW kurulu gücü olan Gansu rüzgâr santralidir. Şekil 2.8 ve Şekil 2.9 incelendiklerinde Dünyadaki ilk onshore rüzgâr santrali ve günümüzdeki en büyük onshore rüzgâr santrali görülebilir[37].



Şekil 2.7 : Dünyanın İlk Resmi Onshore Rüzgâr Santrali (New Hampshire)[38].



Şekil 2.8 : Dünyanın En Büyük Kurulu Güçlü Rüzgâr Santrali(Çin/2021)[37].


3. RÜZGÂR GÜCÜ VE RÜZGÂR ENERJİSİ POTANSİYELİ

3.1. Rüzgâr Enerjisinin ve Gücünün Hesaplanmasında Kullanılan Denklemler

Güç olarak ifade edilen olgu kısaca enerjinin birim zaman formunda tanımlanma biçimi olarak açıklanabilir. Bu tanım rüzgârdan elde edilecek güç için de geçerlidir. Rüzgâr gücünün tanımını oluşturmak için rüzgârın arkasında yatan enerji türünü belirlemek gerekmektedir. Rüzgâr denilen meteorolojik olgu irdelendiğinde, rüzgârın basınç farklarından doğan nitelikli hava hareketi olarak tanımlandığı görülmektedir. Bu bilgiden yola çıkarak rüzgâr enerjisinin aslında nitelikli hava parçacıklarının hareketinden oluşan kinetik enerjiye dayandığı görülebilir. Denklem 3.1 yardımıyla hareket halinde olan akışkan parçacıkları için kinetik enerji formülü kolaylıkla yazılabilir.

$$E_k = \frac{1}{2} mv^2 \quad (3.1)$$

Denklem 3.1’de, m hareket halindeki havanın kütlesini, v hareket halindeki havanın hızını E_k ise toplam kinetik enerjisini ifade etmektedir. Şekil 3.1’de rüzgâr türbini üzerinden akan havanın hacmi basitçe silindirik bir akış hacmi olarak tasvir edilmiştir.



Şekil 3.1 : Rüzgâr Türbini Üzerinden Akan Havanın Görselleştirilmesi.

Şekil 3.1 incelenerek açıklanmaya çalışılan rüzgâr türbini üzerindeki hava akımı kaynaklı enerji denklemi çeşitli bağıntılar yardımıyla hava akımından elde edilecek güç denklemine çevrilebilir.

$$\rho = \frac{m}{V} \quad (3.2)$$

Denklem 3.2 ile rüzgâr türbini üzerindeki hava kütleinin yoğunluk ve hacim cinsinden ifade edilişi görülebilir. ρ akışkanın öz kütleini ifade ederken, m akışkanın kütleini ve V akışkanın hacmini ifade etmektedir.

Eğer Denklem 3.2'yi Denklem 3.1 içerisine yazarsak enerji denklemini akışkanın kolayca hesaplanabilen alan ve kolayca belirlenebilen özkütle bilgilerine indirgemiş oluruz.

$$E_k = \frac{1}{2} \rho V v^2 \quad (3.3)$$

Denklem 3.4'ün ve Denklem 3.5'in yardımlarıyla şekil 3.1'deki rüzgâr türbini üzerindeki akış hacminin sahip olduğu toplam kinetik enerji kolayca hesaplanabilir.

$$V = A L \quad (3.4)$$


$$L = v t \quad (3.5)$$

Denklem 3.4'te V , Şekil 3.1'de tasarlanan kontrol hacminin hacmini, A , hava hareketine dik kesit alanını, L , akış hacminin boyunu temsil etmektedir. Denklem 3.4 ve Denklem 3.5 Denklem 3.3'ün içerisine yazıldığında Şekil 3.1'de görselleştirilen rüzgâr türbini üzerindeki akış olayının toplam kinetik enerjisi hesaplanır.

$$E_k = \frac{1}{2} \rho A t v^3 \quad (3.6)$$

Denklem 3.6'daki enerji denklemi birim zamana indirgenirse rüzgâr türbini üzerinden akan havadan elde edilebilecek teorik güç hesaplanmış olur.

$$P = \frac{1}{2} \rho A v^3 \quad (3.7)$$



Şekil 3.2 : Rüzgâr Türbinleri Üzerindeki Hava Akımları[39].

Şekil 3.2 de yatay eksenli bir rüzgâr türbinin üzerinden akan hava akımının kontrol hacmi görselleştirilmiştir. Buna göre A1 alanı rüzgâr türbininin önünde kalan alanı, A bölgesi Türbin kanatlarının da içinde bulunduğu rüzgâr türbininin süpürdüğü alanı, A2 bölgesi ise rüzgâr türbininin arkasında kalan alanı ifade etmektedir. A1 bölgesindeki hız v_1 , A bölgesindeki hız v ve A2 bölgesindeki hız v_2 olarak tanımlanmışlardır.

Şekil 3.2’deki kontrol hacmi incelendiğinde kütle korunumu kanunu göz önüne alındığında havanın kütleli debisinin sabit kalacağı görülebilir. Bu bilgi Denklem 3.8 ile yazılabilir. Denklem 3.8’deki $\dot{m}$ ifadesi havanın kütleli debisini ifade etmektedir.

$$\dot{m} = \rho v_1 A_1 = \rho v A = \rho v_2 A_2 \quad (3.8)$$

A bölgesinde bulunan türbin kanatlarına uygulanan kuvvet momentum değişiminden Denklem 3.9’daki gibi kolayca hesaplanabilir.

$$F = \dot{m} (v_1 - v_2) \quad (3.9)$$

Ek olarak türbin kanatlarına uygulanan kuvvet türbinin yerleştirildiği A bölgesinin hemen önündeki P_1 basıncı ve A bölgesinin hemen arkasındaki P_2 basınçları yardımıyla basınç farkları üzerinden de kolayca hesaplanabilir.

$$F = (P_1 - P_2)A \quad (3.10)$$

Denklem 3.9, Denklem 3.10’da yerine yazılırsa türbinin yerleştirildiği A bölgesinin önu ve arkasındaki basınç farkı kolayca hesaplanabilir.

$$\Delta P = \rho v (v_1 - v_2) \quad (3.11)$$

Rüzgârın türbine temas etmeden önceki bölgede ve temas ettikten sonra ayrıldığı bölgede Bernoulli yaklaşımı uygulandığında rüzgâr türbini üzerinden akan havanın hızı kolayca hesaplanabilir.

$$P_{\text{çevre}} + \frac{1}{2} \rho v_1^2 = P_1 + \frac{1}{2} \rho v^2 \quad (3.12)$$

$$P_2 + \frac{1}{2} \rho v^2 = P_{\text{çevre}} + \frac{1}{2} \rho v_2^2 \quad (3.13)$$

Denklem 3.12 ve Denklem 3.13 beraber çözüldüğünde türbin üzerinden akan havanın hızı v , Denklem 3.14'deki gibi ifade edilebilir.

$$v = \frac{1}{2} (v_1 + v_2) \quad (3.14)$$

Türbinden elde edilecek gücün hesaplanması için Denklem 3.14 Denklem 3.7'nin içerisine yazıldığında aşağıdaki bağıntı elde edilir.

$$P = \frac{1}{4} \rho A (v_1 + v_2)(v_1^2 - v_2^2) \quad (3.15)$$

Türbinin üretebileceği maksimum güç hesabı için Denklem 3.15 incelendiğinde iki çıkarım yapılabilir. Bunlardan ilki maksimum güç için türbin üzerinden geçen rüzgâr hızı v , türbine gelen rüzgâr hızı v_1 'e eşit olmalıdır ya da türbinden çıkan v_2 hızı 0 olmalıdır. Türbinden çıkan havanın belirli bir hızda yol aldığı düşünülürse maksimum güç için $v = v_1$ olmalıdır.

$$\frac{\partial P}{\partial v_2} = 0 \quad (3.16)$$

$$\frac{\partial P}{\partial v_2} = \frac{1}{4} \rho A (v_1 + v_2)(v_1 - 3v_2) \quad (3.17)$$

Denklem 3.16 ve Denklem 3.17 birlikte çözüldürse $v_2 = -v_1$ ve $v_2 = v_1/3$ olarak iki kök bulunur. $v_2 = -v_1$ olamayacağından dolayı $v_2 = v_1/3$ olarak kabul edilir ve maksimum güç denklemi yeniden Denklem 3.18'deki gibi yazılabilir.

$$P_{maks,türbin} = \frac{8}{27} \rho A v_1^3 \quad (3.18)$$


Denklem 3.7 kullanılarak rüzgârdan elde edilebilecek maksimum güç $v = v_1$ şartı altında yazılarak Denklem 3.19’da verilmiştir.

$$P_{maks,rüzgar} = \frac{1}{2} \rho A v_1^3 \quad (3.19)$$

Denklem 3.18 ve Denklem 3.19 oranlanarak rüzgâr türbinlerinin güç katsayısı C_p değeri için maksimum limit olarak adlandırılan Betz limiti hesaplanmış olur.

$$C_p = \frac{P_{maks,türbin}}{P_{maks,rüzgar}} = \frac{\frac{8}{27} \rho A v_1^3}{\frac{1}{2} \rho A v_1^3} = \frac{16}{27} = 0.59259 = \%59.259 \quad (3.20)$$

Şekil 3.3 incelendiğinde rüzgâr türbinin üretebileceği maksimum güç ve rüzgârdan elde edilebilecek maksimum gücün oranı olarak tanımlanan C_p değerinin rüzgâr türbini öncesindeki rüzgâr hızının rüzgâr türbini sonrasındaki rüzgâr hızına oranına göre değişimi görülebilir.



Şekil 3.3 : $C_p - v_2/v_1$ Grafiği[13].

Şekil 3.3 incelendiğinde görüleceği üzere, rüzgâr türbininin üretebileceği maksimum güç rüzgârdan elde edilecek maksimum gücün sadece %59.259’luk kısmı kadardır. Bu değer teoride bir rüzgâr türbininin elde edebileceği maksimum verimdir. Ancak unutulmamalıdır ki rüzgâr enerjisini mekanik enerjiye çeviren rüzgâr türbinleri bu mekanik enerjiyi elektrik enerjisine çevirmek için de çeşitli ekipmanlar kullanırlar.

Mekanik enerjinin elektrik enerjisine çevrilmesi sırasında kullanılan jeneratör, dişli kutusu ve iletim elemanlarının verimleri sebebiyle pratikte rüzgâr türbinlerinin verimi Betz limiti olarak tanımlanan %59.295’lik verimden daha düşük seviyelerdedirler.

3.2. Rüzgâr Gücünü ve Rüzgâr Enerjisini Belirleyen Etmenler

Rüzgâr enerjisini ve dolayısıyla rüzgârdan elde edilebilecek gücü etkileyen bir takım kontrol edilebilir faktörler vardır. Bu faktörler kısaca aşağıda açıklanmışlardır.

3.2.1. Rüzgâr hızı ve yükseklik ilişkisi

Rüzgâr enerjisinin yaygın olarak kullanılmadığı dönemlerde, rüzgâr türbinlerinin lokasyonlarının tayininde söz sahibi olacak temel parametreler olan rüzgâr hızı ve hâkim rüzgâr yönünün belirlenmesi için sahalarda 10, 30 ve 50 metre yüksekliklerde birer dakikalık veyahut onar dakikalık ölçümler yapılırdı. Ölçümlerin yapılacağı bu yükseklikler yerleştirilecek olan rüzgâr türbininin hub kısmından daha düşük seviyelerde oldukları için hub yüksekliğindeki rüzgâr hızlarının belirlenmesi için güç yasası denilen bir yaklaşım kullanılırdı. Denklem 3.21’de ve Denklem 3.22’de güç yasası verilmiştir[40].

$$\frac{v_2}{v_1} = \left(\frac{z_2}{z_1} \right)^\alpha \quad (3.21)$$

Denklem 3.21’ de görülen v_1 ölçülen ve ölçüldüğü noktanın yerden yüksekliği bilinen rüzgâr hızını, v_2 yerden yüksekliği bilinen bir noktanın ölçüm yapılmadığı için belirlenmek istenen rüzgâr hızını, z_1 hız ölçümü yapılan noktanın yerden yüksekliğini, z_2 hızı belirlenmek istenen noktanın yerden yüksekliğini ifade etmektedir. Güç yasasında katsayı olarak belirlenen α ise Helmann parametresi olarak bilinmektedir. Helmann parametresi rüzgâr hızının tahmin edilmeye çalışıldığı bölgenin coğrafi özelliklerine göre tayin edilen bir parametredir. Çizelge 3.1 incelendiğinde α parametresinin değerleri görülebilir.


Çizelge 3.1 : Helmann Katsayısının Coğrafi Koşullara Göre Aldığı Değerler[40].

Coğrafi Koşullar	Helmann Katsayısı
Açık Denizler & Okyanuslar	0.14
Çalılık & Düz Araziler	0.18
Ağaçlık Alanlar	0.28
Yüksek Yapılar ve Orman Arazileri	0.40

Havanın yoğunluğunun değişmediği kabul edilirse, Denklem 3.21'deki yaklaşıma uygun bir benzeşim kurularak Denklem 3.22 ile güç yasası kolaylıkla türetilir.

$$\frac{P_2}{P_1} = \left(\frac{z_2}{z_1} \right)^{3\alpha} \quad (3.22)$$

Rüzgâr hızı Denklem 3.21 yardımıyla atmosfer boyunca hesaplanırsa şekil 3.4'teki rüzgâr hızı dağılımı elde edilir. Şekil 3.4'ten de anlaşılacağı üzere rüzgâr hızı yükseklikle artmakta ve belirli bir değerden sonra yükseklik artsa bile hız değişmemektedir.



Şekil 3.4 : Rüzgâr – Yükseklik İlişkisi.

3.2.2. Rüzgâr hızı ve pürüzlülük ilişkisi

Rüzgâr gücünü direkt olarak etkileyen önemli parametrelerden biri de pürüzlülük katsayısıdır. Dünya üzerindeki her bölgenin coğrafi koşulları aynı olmadığı için yüzey pürüzlülükleri de aynı değildir. Bir bölgenin pürüzlülük sınıfı ve pürüzlülük kat sayısı o bölgenin coğrafyasını oluşturan coğrafi elemanlara bağlıdır. Bir bölgenin pürüzlülüğü üzerinde etkisi olan coğrafi elemanlar kısaca bölgenin arazi formu, bölgede bulunan bitki örtüleri, bölgenin yapılaşma formu olarak sınıflandırılabilirler[21].

Bir bölgedeki coğrafi elemanlar pürüzlülük katsayısını direkt olarak etkileyebilirler ve yüksek pürüzlülük katsayıları bölge içerisindeki rüzgâr hızının azalmasına sebep olabilir. Rüzgâr gradyanını bu şekilde etkileyebilen ve α olarak ifade edilen pürüzlülük katsayısı coğrafi bölgelere göre değişiklik göstermekle birlikte genel olarak üç farklı

yöntemle hesaplanabilir. Bahsi geçen üç yöntem sırasıyla Denklem 3.23'te, Denklem 3.24'te ve Denklem 3.25'te incelenebilir[41–43].

$$\alpha = \frac{0.37 - 0.88 \ln(v_{referans})}{1 - 0.88 \ln\left(\frac{z_{referans}}{10}\right)} \quad (3.23)$$

Denklem 3.23'te pürüzlülük katsayısı referans hız değeri ve referans konum yüksekliği cinsinden kolaylıkla hesaplanabilir.

$$\alpha = 0.096 \log_{10}(z_0) + 0.016(\log_{10}(z_0))^2 + 0.24 \quad (3.24)$$

Denklem 3.24'te pürüzlülük katsayısı pürüzlülük uzunluğu olarak ifade edilen z_0 cinsinden kolaylıkla hesaplanabilir.

$$\alpha = z_0 \left[1 - 0.55 \log_{10}(v_{referans}) \right] \quad (3.25)$$

Denklem 3.25 incelendiğinde pürüzlülük katsayısı referans hız ve pürüzlülük uzunluğu cinsinden kolayca yazılabilir.


3.2.3. Rüzgâr hızı ve türbülans ilişkisi

Rüzgârdan enerji eldesini direkt olarak etkileyen önemli parametrelerden biri de türbülans kavramıdır. Türbülans kısaca belirli bir akım çizgisini izleyen akışkan parçacıklarının çeşitli nedenlerden dolayı aniden sergiledikleri çok küçük ölçekli ve modellenmesi oldukça zor olan akışkan parçacığı davranışdır. Türbülans akımlarının yoğunluğu rüzgâr hızı değerlerinin standart sapmalarının ortalama rüzgâr hızına oranı olarak ifade edilebilir[21].

Rüzgâr türbinlerinin verimini düşüren ve mikro ölçekte gösterdikleri düzensizliklerle türbin kanatlarının yorulma hasarı almalarına sebep olan türbülans akımları yüzey pürüzlülüğünden ve yükseklikten etkilenirler. Yükseklik arttıkça türbülans yoğunluğunda azalma görülmekle beraber yüzeye yakın konumlarda pürüzlülük etkisiyle türbülans akımlarında artış görülmektedir.

Türbin kanatları, rüzgâr türbinlerini mekanik yorulmalardan korumak ve rüzgârdan elde edilecek enerjiyi maksimuma çıkarmak adına zemin seviyesinden yukarda kalacak şekilde taşıyıcı kuleler üzerine yerleştirilirler[21].

Şekil 3.5'te bir dağın yamacının aşılması ardından oluşan türbülans akımları görselleştirilmiştir.



Şekil 3.5 : Dağ Yamacında Oluşan Türbülans Akımları.

3.2.4. Rüzgâr hızı ve rüzgâr engelleri ilişkisi

Rüzgâr denilen nitelikli hava hareketi herhangi bir engelle karşılaşmadığı müddetçe etki alanı oldukça geniş bölgelere tekabül eden bir meteorolojik hava olayıdır. Herhangi bir engelle karşılaşan hava parçacıklarının gradyanı kolayca bozulur ve böylelikle düzenli ve tahmin edilebilir bir davranış sergileyen hava parçacıkları bu yetilerini yitirerek türbülans akımları yaratabilirler.

Türbülans akımlarına sebep olan, rüzgâr hızını azaltan, rüzgâr gradyanını değiştiren rüzgâr engelleri temel olarak beşeri ve doğal engeller olarak sınıflandırılabilirler. Beşeri engeller insan yapımı olan evler, köprüler, barajlar ve büyük ölçekli yapılardır. Doğal engeller ise coğrafi koşullardan ortaya çıkan bitki örtüleri, yer yüzü şekilleri gibi yapılardır[21].

Doğal engeller poroz yapıda olabildikleri için kimi zaman rüzgârı geçirebilirler fakat insan yapımı yapay engeller çoğu zaman rüzgâr geçişine izin vermez ve rüzgâr rejiminin değişmesine sebep olabilirler. Bu sebeple rüzgâr enerjisinden yararlanmak amacıyla kurulacak rüzgâr türbinleri, bahsi geçen doğal engeller ve yapay engellerin bulunmadığı veya bulunuyorlarsa bile engellerin rüzgâr gradyanı üzerindeki etkileri göz önünde bulundurularak engellerden yeterince uzak konumlara konumlandırılırlar[21].

3.2.5. Rüzgâr hızı ve art izi etkisi

Daha önceki bölümlerde detaylıca anlatıldığı üzere rüzgâr türbinleri rüzgâr hızını kullanarak rüzgâr enerjisini önce mekanik enerjiye daha sonra elektrik enerjisine

çeviren teknolojik makinelerdir. Enerjinin korunumu yasası göz önüne alındığında türbin kanatlarına belirli bir hızla çarpan hava parçacıkları türbin kanatlarının dönmesine sebep olarak enerjilerinin bir kısmını rüzgâr türbinine aktarırlar ve türbinden ayrılan hava parçacıklarının hızının türbine giren hava parçacıklarına kıyasla oldukça düşük seviyelerde olduğu kabul edilmektedir. Bu sebeple rüzgâr türbinleri arkalarında enerji bakımından düşük hava parçacıkları bırakarak bir kuyruk izi etkisi yaratırlar[44].

Rüzgâr santralleri gibi çok sayıda rüzgâr türbinlerinin bulunduğu yerleşim alanlarında rüzgâr türbinlerinin birbirlerinin kuyruk izleri üzerine yerleştirilmemeleri adına çeşitli çalışmalar yapılmakta ve optimizasyon yöntemleri geliştirilmektedir. Genel olarak bir rüzgâr türbininin, önündeki rüzgâr türbininin rotor çapının minimum 2 ile 5 katı arasında bir mesafe bırakılacak şekilde konumlandırılması gerekmektedir. Şekil 3.6 incelendiğinde rüzgâr türbinlerinin art izleri görülebilir.



Şekil 3.6 : Rüzgâr Türbini Art İzleri[45].

3.5.2.1. Jensen iz modeli

Rüzgâr enerjisi uygulamaları için kullanılan Wasp, Windpro gibi ticari yazılımların rüzgâr türbinlerinin art izi etkilerini hesaplamak için kullandıkları en temel yöntem 1983 yılında N.O. Jensen tarafından bulunan ve momentumun korunumu ilkesine dayanarak oluşturulan Jensen yöntemi[46]. Bu yöntem, daha sonra I. Katic ve diğerleri tarafından geliştirilerek kütlenin korunumu ilkesine dayanan bir modele evriltilmiştir[47]. Günümüzde rüzgâr enerjisi uygulamalarında art izi etkilerinin incelenmesi için I. Katic tarafından geliştirilmiş Jensen modeli kullanılmaktadır[48].

Jensen modeline göre art izi bölgesindeki rüzgâr hızı şiddeti Denklem 3.26 ile hesaplanabilir.

$$U_w = U_\infty \left(1 - \frac{2a}{\left(1 + k_w \left(\frac{x}{r_1}\right)\right)^2} \right) \quad (3.26)$$

Denklem 3.26’da U_w art izi bölgesinde ve art izi oluşturan türbine x mesafe uzakta bulunan bir noktanın rüzgâr hızını, U_∞ art izi oluşturan rüzgâr türbininin hub kısmına gelen rüzgâr hızını, x art izinde incelenen konumun art izini oluşturan rüzgâr türbinine mesafesini, r_1 art izi bölgesi yayılma yarıçapını, k_w art izi sönüm katsayısını, a ise akış indüksiyon faktörünü temsil etmektedir. Akış indüksiyon faktörü Denklem 3.27 yardımıyla rüzgâr türbini itki katsayısına bağlı olarak yazılabilir.

$$a = \left(\frac{1 - \sqrt{1 - C_T}}{2} \right) \quad (3.27)$$

Denklem 3.26’da kullanılan ve genişleyen art izi bölgesinin yarıçapını temsil eden r_1 ifadesi Denklem 3.28 ile hesaplanabilir.

$$r_1 = r_r \sqrt{(1 - a)(1 - 2a)} \quad (3.28)$$

Denklem 3.28’de r_r art izine sebep olan rüzgâr türbininin rotor yarıçapını temsil etmektedir.

Jensen iz modeli art izinin sabit bir sönümleme katsayısı ile lineer olarak genişlediğini kabul etmektedir. Bu yaklaşımla sönümleme katsayısı ve art izi yayılma yarıçapı Denklem 3.29 ve Denklem 3.30 ile hesaplanabilir.

$$k_w = \left(\frac{1}{2 \ln \left(\frac{z_h}{z_0} \right)} \right) \quad (3.29)$$

$$r_w = r_r + k_w x \quad (3.30)$$

Denklem 3.29’da z_h türbin yüksekliğini, z_0 pürüzlülük katsayısını ifade etmektedir.

3.3. Rüzgâr Türbinlerinin Santral İçerisindeki Konumlarının Etkisi

Rüzgâr türbinleri teorik olarak rüzgâr hızından kaynaklanan kinetik enerjiyi türbin kanatları vasıtasıyla önce mekanik enerjiye daha sonra jeneratörler yardımıyla elektrik

enerjisine çeviren elektro mekanik cihazlardır. Bölüm 3.1’de de açıklandığı üzere rüzgâr türbinleri, rüzgârdan elde edilebilecek olan teorik gücün en fazla %59’unu kullanabilirler bu nedenle rüzgâr enerjisinden üretilecek elektrik enerjisinin bağlı olduğu çeşitli parametreler türbin verimlilikleri için elzem hususlardır. Bu parametreler türbinlerin bulunduğu konumun pürüzlülük katsayısı, türbinlerin yüksekliği, bulunulan bölgenin rüzgâr hızı potansiyeli, türbin kanatlarının bulunduğu yükseklikteki havanın yoğunluğu, türbin kanatlarının oluşturduğu türbin süpürme alanı gibi direkt ölçümlerle veyahut hesaplamalarla belirlenebilecek parametreler olabilirken türbinlerin birbirleri ardına yerleştirildikleri konumlar gibi çeşitli simülasyon programları vasıtasıyla denetlenebilen parametreler olabilirler.

Rüzgâr türbinleri, türbin kanatlarına temas ederek üzerlerinden akan havanın enerjisinin bir kısmını alırlar. Bu nedenle rüzgâr türbininin hemen ön bölgesindeki havanın niteliği ile türbinin hemen arkasındaki havanın nitelikleri birbirlerinden farklıdır. Enerjinin korunumu yasası gereği türbin öncesindeki rüzgâr hızının türbin sonrasındaki rüzgâr hızından fazla olması gerektiğini biliyoruz. Bu durum sebebiyle rüzgâr türbinlerinde, rüzgâr gücünden mekanik iş elde edildiğinden dolayı türbinlerin arka kısmında, çeşitli formlarda iz bölgeleri oluşur. Bahsi geçen iz bölgelerinde konumlandırılmış rüzgâr türbinlerine ulaşan rüzgâr hızları iz bölgelerinin dışarısında kalan rüzgâr türbinlerine ulaşan rüzgâr hızı değerlerinden düşük olmalarından mütevellit, iz bölgelerine yerleştirilen türbinler daha düşük verim değerlerinde çalışırlar.

Rüzgâr türbinlerinin iz etkisinden kurtulmak amaçlı türbinlerin arasındaki mesafeler çok büyük olacak şekilde ayarlanırlarsa bu durum rüzgâr türbinlerinin park sorunlarına sebep olur. Park sorunu kısaca elektrik enerjisi üretecek olan türbine ulaşım problemi yaratırken aynı zamanda türbinde üretilen elektriğin hatlar vasıtasıyla iletilmesinde birtakım kayıplara sebep olabilmektedir. Bu nedenle türbinlerin iz bölgelerine yerleştirilmemeleri için yapılan çalışmalar türbin verimliliğinin artırılması adına önemli adımlar olarak göze çarpmaktadırlar.

Jensen tarafından 1983 yılında rüzgâr türbini ardında oluşan türbin izlerinin modellenmesi üzerine yapılan çalışmada rüzgâr türbinlerinin türbülans etkilenmemeleri adına birbirlerine düşey doğrultuda minimum 7 rotor çapı kadar ve yatay doğrultuda ise minimum 2 rotor çapı kadar uzak mesafelere konumlandırılmaları sonucuna varılmıştır[46].

Moskalenko tarafından yapılan çalışmada türbinlerin arka kısmında kalan türbülans bölgelerinin üç ana başlık altında, yakın iz bölgesi (1 rotor çapı mesafesi uzaklık), orta iz bölgesi (2 ile 3 rotor çapı mesafesi arası uzaklık) ve uzak iz bölgesi (5 rotor çapı mesafesi ve daha fazla uzaklık) olarak adlandırılabilceği savunulmuştur. Bu üç bölgeye yerleştirilecek türbinlerin konumlarının verimlerinin sırasıyla yüksekte düşüğe olacak şekilde uzak iz bölgesi, orta iz bölgesi ve yakın iz bölgesi olduğu savunulmuştur[49]. Aynı çalışmanın kanıtladığı bir diğer sonuç ise Danimarka'daki Horns-Rev I rüzgâr santralının iz etkisi olamadan üreteceği rüzgâr enerjisinin, iz etkisinde ürettiği rüzgâr enerjisinden %12 daha fazla olduğudur[49].

Mosetti ve arkadaşları tarafından yapılan çalışmada genetik algoritmanın büyük rüzgâr santrallerindeki rüzgâr türbini konumlarının optimizasyon problemini çözmede kullanılabilecek bir yol olduğunu kanıtlamıştır. Yapılan çalışmada düzenli bir şekilde yerleştirilen rüzgâr türbinlerinin oluşturduğu rüzgâr santralının verimi %50 seviyelerinde olurken, genetik algoritma kullanılarak oluşturulan rüzgâr türbini konumları sayesinde rüzgâr santralının verimi %40 artmıştır. Jensen tarafından yapılan çalışmada rüzgâr santralı mikro konumlandırma probleminde söz sahibi olan parametreler belirlenmiştir. Bu parametreler rüzgâr hızı verileri ve türbinlerin düşey eksenindeki konumlarıdır[50].

Dabbabi ve arkadaşları tarafından yapılan çalışma rüzgâr santrallerinin enerji üretim maliyetlerinde rüzgâr türbini konumlarının önemli bir yere sahip olduğunu kanıtlamıştır. Yapılan çalışmada enerji üretim maliyetini düşürmek adına türbin konumlarının belirlenmesi için genetik algoritma yöntemi kullanılmıştır. Genetik algoritma yöntemiyle konumlandırılan rüzgâr türbinlerinde iz etkisi görülmemektedir ve bu şekilde rüzgâr çiftliğinin her bir MWh enerji üretiminin maliyeti 101.48€ olarak hesaplanmıştır. Öte yandan iz etkisinin görüldüğü konumlandırmada rüzgâr çiftliğinin MWh enerji üretim maliyeti 139.64€ olarak hesaplanmıştır[51].

Hoxha ve arkadaşlarının yaptığı çalışmada rüzgâr türbinlerinin araziye yerleştirilecekleri şekillere ve aralarındaki mesafelere bağlı olarak değişen kapasite faktörleri üzerine çalışılmıştır. Araziye türbinler ark, I, L, M ve V şeklinde, aralarında sırasıyla düşey yönde 2 rotor çapı, üç rotor çapı ve beş rotor çapı olacak şekilde yerleştirilip kapasite faktörleri incelenmiştir. Yapılan çalışmanın sonucuna göre verimi en düşük yerleşim formu M şeklinde olan formdur. V şeklindeki yerleşim için, 2 rotor çaplı mesafe bırakılarak yerleşim sağlanırsa yıllık enerji üretimi 95.909 GWh olarak

hesaplanmıştır. Aynı şekilde V yerleşim şekli için türbin mesafeleri sırasıyla 3 rotor çapı ve 5 rotor çapı bırakılarak yapılan konumlandırma işlemlerinin yıllık enerji üretimleri ise sırasıyla 96.931 GWh ve 87.457 GWh olarak hesaplanmıştır. Yapılan çalışmada optimal yerleşim şekli V formunda ve türbünler arası açıklık 3 rotor çapı mesafede olacak şekilde belirlenmiştir[52].

Nguyen ve arkadaşları tarafından yürütülen çalışmada rüzgâr santrallerinin üretebilecekleri enerji miktarlarını makine öğrenmesi algoritmalarıyla tanımlamak üzerine araştırmalar yapılmıştır. RMSE (ortalama hatanın karekökü) değerleri bakımından değerlendirilen makine öğrenmesi algoritmalarının başarı sıralamaları başarısı yüksek algoritmadan düşük algoritmaya olacak şekilde sırasıyla 0.177'lik değerle karar ağacı algoritması, 0.227'lik değerle rastgele orman algoritması, 0.131'lik değerle yükseltilmiş gradyan regresyon ağacı ve 0.264'lük değerle yapay sinir ağı çok katmanlı algılayıcıdır[53].

Shereiqi ve arkadaşları tarafından yapılan çalışmada güney ummanda kurulacak bir rüzgâr santralının mikro konumlandırma optimizasyon çalışması genetik algoritma yardımıyla yapılmıştır. Türbinlerin kurulacağı arazideki hâkim rüzgâr doğrultusunun kuzey doğu olduğu belirlenmiştir. Kuzey doğu doğrultusuna doğru yönlendirilecek rüzgâr türbinleri konumlarının 203.915 GWh yıllık enerji üreteceği hesaplanmıştır[54].

Charles ve arkadaşları tarafından yapılan çalışmada rüzgâr türbini mikro konumlandırmalarının türbülans yoğunluğu üzerindeki etkisi araştırılmıştır. Yapılan çalışmanın sonucuna göre türbin arasındaki mesafeler arttıkça türbülans yoğunlukları azalmaktadır. Örnek olarak 7m/s rüzgâr hızı için türbinler arası mesafe 4 rotor çapı kadar ayarlanırsa türbülans yoğunluğu %30 olarak hesaplanmıştır. Öte yandan türbinler atası mesafeler sırasıyla 5 rotor çapı boyu ve 7 rotor çapı boyu olarak ayarlanırsa türbülans yoğunlukları sırasıyla %22.5 ve %17.5 değerlerine düşmektedir(55).Yine aynı çalışmanın devamında rüzgâr hızı ile türbülans yoğunluğu arasındaki ilişki açıklanmaya çalışılmıştır. Çalışmanın sonucuna göre türbinler arası mesafe 7 rotor çapı olarak sabit tutulur ve sırasıyla 7,8,9 ve 10 m/s hızlarında rüzgâra tabii tutulurlarsa türbülans yoğunluğu seçilen türbin için sırasıyla %18.1, %17.2, %16.8, ve %15.6 olarak hesaplanmıştır[55].

Kumar ve arkadaşları tarafından yapılan çalışmada rüzgâr türbini mikro konumlandırma çalışmaları için iz modelleri araştırılmıştır. Çalışmanın sonucuna göre türbin izlerinin modellenmesi için literatürde Jensen iz modeli, Larsen iz modeli, Lissaman modeli, Fuga modeli gibi modellerin yanısıra olasılıksal yaklaşım olarak nokta tahmin yöntemi, Monte-Carlo simülasyon yöntemi gibi yöntemler de kullanılmaktadır[56].

Hayat ve arkadaşları tarafından rüzgâr santralleri mikro konumlandırılması çalışmasında heterojen rüzgâr türbini dağılımına sahip rüzgâr santrallerinin homojen rüzgâr türbini dağılımına sahip rüzgâr santrallerine kıyasla gelişmiş ortalama hız ve daha düşük türbülans yoğunluğu özelliklerini gösterdiği savunulmuştur. Çalışmada farklı hub yüksekliklerine ve farklı rotor çaplarına ve farklı türbin kanadı sayılarına sahip rüzgâr türbinlerinin çeşitli varyasyonları kullanılmıştır[57].

Chatterjee ve Peet tarafından yapılan ve rüzgâr santralleri için rüzgâr türbini konumlandırma problemini temel alan çalışmada hub yüksekliği aynı olan rüzgâr türbinlerinin arasına hub yükseklikleri onlara kıyasla daha düşük olan rüzgâr türbinleri yerleştirilerek Large Eddy Simulation adı verilen CFD analizi uygulanmış ve rüzgâr santralının performansı incelenmiştir. Sonuçlara göre yüksek rüzgâr türbinleri arasına yerleştirilen görece düşük hub yüksekliğine sahip rüzgâr türbinleri yerlerine yerleştirilebilecek yüksek hub seviyelerine sahip rüzgâr türbinlerinden daha verimli çalışarak rüzgâr santralının performansını arttırmışlardır[58].

Stanley ve arkadaşları farklı yüksekliklere sahip rüzgâr türbinleri kullanımının aynı yükseklikteki rüzgâr türbinleri kullanma duruma göre farklılıklarını rüzgâr santralleri için incelemişlerdir. Yapılan çalışmanın sonucuna göre ard arda yerleştirilmiş farklı yüksekliklerdeki rüzgâr türbinleri kullanımının kendi çalışmalarında enerji üretim maliyetinde %4.9'luk bir azalma yarattığını kanıtlamışlardır. Yine aynı çalışmada tek yükseklik yerine farklı yüksekliklerde yerleştirilen rüzgâr türbinlerinin birbirleri arasındaki mesafeler 3 rotor çapı mesafeye kadar çıkarılırsa üretilecek enerjinin maliyetinde %11.2'lik bir azalma olduğu kanıtlanmıştır[59].

Wu ve arkadaşları tarafından yapılan çalışmada 120 rüzgâr türbini kullanılarak üç farklı yerleşim düzeni incelenmiş ve yerleşim düzenlerinin türbülans yoğunluğu ve üretilecek güç gibi parametreler üzerindeki etkileri araştırılmıştır. Yapılan çalışma sonucunda art arda yerleştirilirken kademeli olarak yatayda belirli bir doğrultuda

ötelenerek konum deęiřtiren yerleřim formunun bir dięerinin direkt olarak tam arkasına yerleřtirilen forma kıyasla %60 oranında daha fazla performans sergiledięi kanıtlanmıřtır. Yine aynı alıřmada dūřey doęrultuda türbinler arasındaki mesafenin kademeli olarak arttırıldıęı yerleřim düzeninin de türbülans yoğunluęu açısından en düşük yoğunluk deęerlerine sahip olarak en başarılı sonuçları elde ettięi kanıtlanmıřtır[60].




4. RÜZGÂR TÜRBİNİ KONTROL SİSTEMLERİ

Rüzgâr enerjisini mekanik enerjiye ve daha sonra elektrik enerjisine çeviren rüzgâr türbinleri rejim değiştiren ve sürekli aynı nitelikte olmayan rüzgârlar nedeniyle genel işleyişin yönetilmesi adına bir takım kontrol sistemlerine sahiptirler. Bu kontrol sistemlerinin temel amacı her iklim şartı altında üretim işleminin devamlılığını sağlayarak ekstrem koşullar altında türbinin güvenliğini sağlamaktır. Rüzgâr türbini kontrol sistemleri genel olarak aşağıdaki gibi alt başlıklara bölünebilirler[61].

- Açık kontrol sistemi.
- Yön kontrol sistemi.
- Fırtına / güç kontrol sistemi.
- Şebeke kontrol sistemi.
- Üreteç kontrol sistemi.
- Uzaktan erişim kontrol sistemi.

4.1. Açık Kontrol Sistemi


Kanatların pozisyonunu ayarlayarak olabilecek her rüzgâr hızında türbinin maksimum verimlilikte çalışmasını sağlayan kontrol sistemi açık kontrol sistemi olarak adlandırılır. Açık kontrol sistemi ile kanatların rüzgârı karşılama pozisyonları değiştirilerek güvenli rüzgâr hızı sınırları dışında kalan rüzgâr hızlarında türbin güvenliği sağlanırken güvenli rüzgâr hızlarında da rüzgâr gücünden verimli faydalanma sağlamaktadır. Şekil 4.1’ de açık kontrol sisteminin diyagramı incelenebilir[62].



Şekil 4.1 : Açık Kontrol Sistemi.

4.2. Yön Kontrol Sistemi


Yön kontrol sistemi, rüzgâr türbininin hub kısmının yönünü her zaman hâkim rüzgâr yönüne dik olarak ayarlamak maksadıyla türbinin hub kısmını döndürmeye yarayan sistemdir. Gün içerisinde dahi hâkim yönü değişebilen rüzgârlara karşı rüzgâr türbinin hub kısmını daima hâkim rüzgâr yönüne dik olarak ayarlamaya yarayan yön kontrol sistemi rüzgâr türbinin her rüzgar yönü şartında verimli çalışmasını sağlamaktadır. Şekil 4.2’de yön kontrol sisteminin diyagramı incelenebilir[13].




Şekil 4.2 : Yön Kontrol Sistemi.

4.3. Fırtına ve Güç Kontrol Sistemi

Rüzgâr türbinleri çoğunlukla 3m/s hız ile 25m/s hız aralığında çalışan rüzgâr enerjisini elektrik enerjisine çeviren teknolojik cihazlardır. Bu nedenle 25 m/s rüzgâr hızının üstündeki hız değerlerinde türbinin güvenliği açısından türbin kanatlarının kontrol altında tutulması gerekir. Bu güvenlik kontrolü fırtına kontrol sistemi adındaki kontrol ünitesiyle sağlanır. Fırtına kontrol ünitesi, rüzgâr türbinini olası mekanik hasarlardan korusa da olumsuz hava şartları sonlandığında devreden çıkarılıp, türbin tekrar çalıştırılmaya başladığında türbinin nominal çalışma performansına yaklaşması zaman alacağından dolayı rüzgâr türbinin verimini olumsuz etkilemektedir. Şekil 4.3 ve Şekil 4.4 incelendiğinde fırtına kontrol sisteminin çalışma diyagramı incelenebilir[62].



Şekil 4.3 : Fırtına Kontrol Sistemi.



Şekil 4.4 : Ana İşlem Birimi.


Ek olarak fırtına kontrol sistemi, fiziki olarak türbin kanatlarını korurken aynı zamanda türbin kanatlarının aerodinamik performanslarını da düşürerek jeneratörde elektrik üretilirken güvenli rüzgâr hızı bölgesinin dışında kalan rüzgâr hızlarından kaynaklanan aşırı yükleme sorununu da ortadan kaldırır. Bu amaçla temel olarak fırtına kontrol ya da diğer bir deyişle güç kontrol sistemleri pasif stall kontrol sistemi, aktif stall kontrol sistemi, pasif pitch kontrol sistemi ve aktif pitch kontrol sistemi olarak dört ana grupta toplanabilirler[62].

4.3.1. Pasif stall kontrol sistemleri

Pasif stall kontrol sistemlerindeki ana amaç güvenli bölge dışındaki rüzgâr hızlarında türbin kanatlarının aerodinamik performanslarını düşürerek türbini kontrol altına almaktır. Türbin kanatlarının aerodinamik performanslarını etkileyen iki önemli parametre vardır bunlar sırasıyla C_L kaldırma kuvveti katsayısı ve C_D sürüklenme kuvveti katsayısıdır. Pasif stall kontrollü rüzgâr türbinlerinde türbin kanatları hub'a sabit bir açıyla bağlandıkları için türbin kanatları tasarım aşamasında belirlenen çalışma hızı aralığı dışındaki hızlarda sürüklenme kuvveti artacak ve kaldırma kuvveti azalacak şekilde tasarlanırlar. Tasarım aşamasındaki bu yöntemle, pasif stall kontrollü sistemler güvenli rüzgâr hızı bölgesinin dışındaki rüzgâr hızlarında türbin kanatlarında, C_D değeri artarken C_L değeri azalır ve hub bağlantı noktasından başlamak üzere fazla yüklenmeye maruz kalan türbin kanatları stabil bir pozisyon olarak güvenli pozisyonda kalmış olurlar[63–65].

4.3.2. Aktif stall kontrol sistemleri

Aktif stall kontrolüne sahip rüzgâr türbinlerinde pasif stall kontrollü türbinlerin aksine türbin kanatları hareket ederek açısını değiştirebilmektedirler. Aktif stall kontrollü rüzgâr türbinlerinde rüzgâr türbini tasarım hızlarının dışında kalan rüzgâr hızı şartlarında kanatlar hücum açısını yükselterek stabil bir konumda bulunmaya çalışırlar. Böylelikle kanatlar üzerindeki sürüklenme katsayısı ve sürüklenme kuvveti artarken, kaldırma kuvveti ve kaldırma kuvveti katsayısı azalmaktadır. Aktif stall kontrolünde türbin kanatlarının hareket açısı aktif pitch kontrolündeki hareket açısının tam tersi şeklindedir. Kanat açıları farklılıkları aktif stall kontrolüne aktif pitch kontrolüne göre daha fazla avantaj sağlamaktadır. Rüzgâr hızı, rüzgâr türbini tasarım hızının üzerine çıktıkça aktif stall kontrol sisteminin türbin kanatlarını değiştirme açısı aktif pitch kontrolüne göre oldukça düşüktür. Aktif stall ve aktif pitch kontrol sistemlerinin türbin güvenliğini sağlamak adına rüzgâr türbini kanatlarının pozisyonlarını rüzgâr hızlarına göre değiştirme açıları Şekil 4.5'te gösterilmiştir[63–65].



Şekil 4.5 : Aktif Stall Kontrol Sistemi ve Aktif Pitch Kontrol Sistemi Kanat Açılarının Rüzgâr Hızı İle Değişimi[64].

4.3.3. Pasif pitch kontrol sistemleri

Pasif pitch kontrollü rüzgâr türbinlerinde türbin kanatlarının hub'a bağlantı açıları pasif stall kontrol sistemine sahip türbinlerin aksine değişkendirler. Bu sebepten dolayı tasarım hızlarının dışına çıkan rüzgâr hızlarında türbinin güvenliğini sağlamak adına türbin kanatlarının burulmasına denetimli olarak izin verilir. Burulma sonucunda


türbin kanatları istenilen açıya ulaşarak sürüklenme kuvvetinin artmasına ve kaldırma kuvvetinin azalmasına neden olarak stabil bir pozisyonda kalırlar[63–65].

4.3.4. Aktif pitch kontrol sistemleri

Aktif pitch kontrol sistemli rüzgâr türbinlerinde, türbin tasarım hızlarının dışındaki rüzgâr hızı şartlarında türbin kanatları belirli açılarda döndürülerek türbin güvende tutulmaya çalışılır. Aktif pitch kontrollü sistemlerin en önemli özellikleri değişken rüzgâr hızına çabuk tepki verebilmeleridir. Mekanik olarak problem yaratacak rüzgar hızı şartlarında türbin kanatları saniyede 5 derece olacak şekilde açı değiştirebilirler. Bu şekilde kuvvetli rüzgârlarda güvenli bölgeye kolay ve hızlıca geçilir[63–65].

4.4. Şebeke Kontrol Sistemi


Şebeke kontrol sistemi rüzgâr türbinlerini kolayca devreye alan ya da tam tersi olacak şekilde kolayca devreden çıkaran kontrol sistemi olarak tanımlanabilir. Şebeke kontrol sisteminin en önemli avantajlarından biri ani devreye sokma ya da ani devreden çıkarma özelliği olması nedeniyle jeneratöre ya da diğer aksamla binebilecek ani güçlerin kontrolünü sağlayarak türbinin güvenli alanda tutulmasıdır. Şebeke kontrol sisteminin bir diğer önemli avantajı ise rüzgâr türbininin kurulu olduğu alanda birden fazla rüzgâr türbini olması durumunda o türbinlerin verilerini de işleyerek işlem yapma özelliğidir. Şekil 4.6’da şebeke kontrol sisteminin diyagramı görülebilir[62].



Şekil 4.6 : Şebeke Kontrol Sistemi.

4.5. Üreteç Kontrol Sistemi


Üreteç kontrol sistemi, rüzgâr türbinlerinin rüzgâr enerjisinden elektrik enerjisi üretmesi işleminden sonra jeneratörden üretilen elektrik enerjisinin şebekeye aktarılırken denetimini yapan kontrol birimidir. Şebeke kontrol sisteminin ana görevi jeneratörden üretilen elektriğin akım, voltaj, frekans büyüklüklerinin şebekenin akım, voltaj ve frekans büyüklüğüne uygun olmasını sağlamaktır. Üreteç kontrol sistemi herhangi bir uyumsuzlukta rüzgâr türbinini durdurarak zararların önüne geçmektedir. Şekil 4.7’incelendiğinde üreteç kontrol sisteminin diyagramı görülebilir[62].



Şekil 4.7 : Üreteç Kontrol Sistemi.

4.6. Uzaktan Erişim Kontrol Sistemi

Uzaktan erişim kontrol sistemi temel olarak rüzgâr türbininin herhangi bir zaman dilimindeki bütün parametrelerini fiziksel olarak rüzgâr türbininin yakınında olmadan dünya üzerinde herhangi bir noktada internet vasıtasıyla kontrol edebilme imkanı sağlayan kontrol birimidir. Uzaktan erişim kontrol sistemiyle rüzgâr türbinin anlık verileri kolaylıkla takip edilip olumsuz durumlarda müdahale edilerek maddi zararların önüne geçilmektedir. Bunlara ek olarak, uzaktan erişim kontrol sistemiyle maddi zararların önüne geçilmekle beraber ayrıca bakım & onarım gibi hizmetlerde gerçekleştirilebilirler. Şekil 4.8’de rüzgâr türbinlerinin uzaktan erişim kontrol sistemi diyagramı incelenebilir[62].



řekil 4.8 : Uzaktan Eriřim Kontrol Sistemi.



5. MAKİNE ÖĞRENMESİ KURAMI

İnsanlık sanayi devriminin başından bu zamana kadar geçen sürede yaşamını sürdürebilmek, kolaylaştırabilmek ve yükünü hafifletebilmek adına kullandığı teknolojiyi sürekli geliştirmiş ve ilerletmiştir. Teknolojideki bu gelişmeler en başta insan merkezli olup insanın karar verme yetisine muhtaç olan süreçler ışığında sonuçlar verseler de geçtiğimiz son birkaç çeyrek asırda geliştirilen teknolojilerin insan bilincine ihtiyaç duymadan kullanılabilir olmaları üzerine yoğunlaşmıştır. İşte bu noktada, insan merkeziyetçiliğinin dışında kalacak şekilde geliştirilen en önemli teknolojik yenilik, tıpkı insanlar gibi bir karar verme mekanizması olan ve hiçbir canlının direktiflerini almadan seçimler yapabilecek yapay bir zeka kuramı olmuştur. Temel mantığı insanı ve direktiflerini ortadan kaldırarak bağımsız bir bilinç yaratmak üzerine kurulu olan yapay zeka kuramının en önemli alt dalını makine öğrenmesi ve bileşenleri oluşturmaktadır[66,67].

Basit olarak makine öğrenmesi, çeşitli verilerle eğitilebilen, insan direktiflerinden ve yönlendirmelerinden bağımsız bir şekilde karar verebilen bilgisayar algoritmaları olarak tanımlanabilirler. Makine öğrenmesi modelleri, çalışabilmek için tek bir önemli girdiye ihtiyaç duymaktadırlar. Bu girdi veri olarak adlandırdığımız çalışılan problem üzerinde daha önceden uygulanmış ve bir sonuç vermiş anlamlı örneklerdir. Makine öğrenmesi algoritmaları bu verilerle eğitilir ve daha sonra bu verilerin bir kısmıyla test edilir ve geliştirilmeye çalışılırlar. Nihai sonuç olarak daha önce herhangi bir veri kümesiyle eğitilmiş makine öğrenmesi algoritmaları bu eğitimden kazandıkları deneyimle gelecek hakkında tahmin yapabilecek noktaya gelirler[66–68].

Çalışma mekaniği bu şekilde tanımlanabilecek olan makine öğrenmesi, gündelik hayatta birçok disiplin için kullanılmaktadır. Bankalar için müşteri portföylerinin geliştirilmesi adına kullanılan makine öğrenmesi uygulamalarında müşterilerin bankalar ile olan işlemlerini değerlendirerek ilgili müşteriyle çalışılıp çalışılmayacağına karar verilmeye çalışılır. Makine öğrenmesi uygulamalarının sıklıkla rastlandığı bir diğer önemli disiplin de Tıp bilimidir. Tıp uygulamalarının birçoğunda makine öğrenmesi modellerine rastlanmaktadır. Özellikle hastalık teşhisi

ve tedavi yöntemi seçimi gibi durumlarda geçmiş hastaların verileri kullanılarak eğitilen makine öğrenmesi algoritmaları önemli başarılar yakalamakta ve hekimler tarafından sıklıkla tercih edilmektedirler. Makine öğrenmesi modellerinin kullanıldığı diğer bir önemli endüstri ise ticarettir. Çoğu büyük marka ürün satabilecekleri müşteri portföyü oluşturmak ve oluşturulan portföydeki müşterilere maksimum sayıda ürün satabilmek için onların ilgi duyacağı ürünleri tahmin etmeye ve onlara önermeye çalışan makine öğrenmesi modelleri geliştirirler[67,69–71].

Yukarıda detaylıca açıklanan makine öğrenmesi kuramı içerisinde barındırdığı denetimli öğrenme, topluluk öğrenmesi gibi birçok alt başlığa ayrılarak dallanmaktadır. Bu tez kapsamında kullanılacak olan denetimli öğrenme algoritmaları ve topluluk öğrenmesi algoritmaları sırasıyla ileriki başlıklarda tanıtılacaklardır [72,73].

5.1. K'nci Mertebeden En Yakın Komşular Algoritması (KEK)

Denetimli öğrenme yöntemlerinin temelini oluşturan KEK algoritması, 1967 yılında bilgisayar bilimcisi P. Hart ve elektrik mühendisi T. Cover tarafından geliştirilmiş ve dünyaya sunulmuştur[74]. Kendisinden sonra geliştirilen yapay sinir ağları, destek vektör makineleri, karar ağaçları, lineer regresyon gibi tahmin algoritmalarının temelini oluşturmaktadır. KEK algoritmasında herhangi bir özelliğinin değeri, tahmin edilecek örneklemin belirlenen k adet konum olarak en yakın komşularının değerlerine bakılarak ve bu değerlerin ortalaması alınarak belirlenir[75,76].

KEK algoritmasında veri setindeki herhangi bir örneklemin istenilen özelliğinin tahmin edilebilmesi için, belirli mesafede bulunan konum olarak en yakın komşularının değerleri kullanılmaktadır, bu sebepten ötürü veri setindeki her bir örneklemin birbirlerine olan uzaklıklarının hesaplanması gerekmektedir. KEK algoritması, veri seti içerisindeki her bir örneklemin birbirine göre uzaklıklarını aşağıda tanımlanan üç farklı yöntemle hesaplayabilir[77,78];

- Öklid uzaklık hesabı yöntemi.
- Manhattan uzaklık hesabı yöntemi.
- Minkowski uzaklık hesabı yöntemi.

5.1.1. Öklid yöntemi

KEK gibi denetimli öğrenme tahmin algoritmalarında uzaklık ölçümü için kullanılan temel yöntem Öklid yöntemidir. Öklid yöntemi uzayda herhangi iki nokta arasında bulunan doğrusal uzaklık olarak tanımlanır. $A = (x_1, x_2, x_3, x_4, \dots, x_n)$ ve $B = (y_1, y_2, y_3, y_4, \dots, y_n)$ olarak tanımlanan iki örneklem arasındaki öklid uzaklığı Denklem 5.1 ile bulunabilir[77].

$$\sqrt{\sum_{j=1}^N (x_j - y_j)^2} \quad (5.1)$$

5.1.2. Manhattan yöntemi

Temel denetimli öğrenme algoritmalarının veri seti içerisindeki örneklemelerin birbirlerine göre uzaklıklarını hesaplarken kullandıkları bir diğer yöntem de Manhattan yöntemidir. Manhattan methodunda n boyutlu iki noktanın bütün bileşenlerinin farklarının mutlak değerlerinin toplanması yöntemiyle uzaklıklar hesaplanır. $A = (x_1, x_2, x_3, x_4, \dots, x_n)$ ve $B = (y_1, y_2, y_3, y_4, \dots, y_n)$ olarak tanımlanan iki örneklem arasındaki Manhattan uzaklığı Denklem 5.2 ile bulunabilir[77].

$$\left| \sum_{j=1}^n x_j - y_j \right| \quad (5.2)$$


5.1.3. Minkowski yöntemi

Minkowski uzaklığı, KEK algoritmasının kullandığı ilk uzaklık yöntemidir. Öklid uzaklık yöntemi ve Manhattan uzaklık yöntemi Minkowski uzaklık yönteminin özel formlarıdır. Minkowski uzaklık hesaplama yöntemi, n elemanlı bir veri seti için n boyutlu uzayda tanımlı iki nokta arasındaki uzaklığın saptanması için kullanılan temel bir dizidir. Minkowski yöntemi uzaklıkları hesaplanmak istenilen iki noktanın bütün bağımsız değişkenlerinin farklarının mutlak değerlerinin toplamalarının üst kuvvetleri olarak tanımlanabilir. $A = (x_1, x_2, x_3, x_4, \dots, x_n)$ ve $B = (y_1, y_2, y_3, y_4, \dots, y_n)$ olarak tanımlanan iki örneklem arasındaki Minkowski uzaklığı Denklem 5.3 ile bulunabilir[78].

$$\left(\sum_{j=1}^n (x_j - y_j)^m \right)^{1/m} \quad (5.3)$$

Denklem 5.3'ten de anlaşılacağı üzere Öklid ve Manhattan yöntemleri Minkowski yönteminin özel formlarıdır. Minkowski yönteminin $m=1$ formu Manhattan yöntemini, $m=2$ formu ise Öklid yöntemini tanımlamaktadır.

KEK tahmin algoritmasının bir diğer önemli parametresi ise k olarak adlandırılan ve tahmin yapılırken hesaplamalarda kullanılacak komşu örneklemelerin sayısını belirleyen pozitif tam sayıdır.. $K=1$ durumunda örneklemin en yakın komşusu kullanılarak tahmin işlemi yapılırken $K=n$ durumunda veri seti içerisindeki n adet konum olarak en yakın örneklemeler kullanılarak tahmin işlemi yapılmaktadır.



Şekil 5.1 : KEK Algoritmasının Çalışma Mekanizması.

KEK algoritmasının çalışma prensibine örnek olması için hazırlanan ve Şekil 5.1’de görselleştirilen örnekte, veri seti içerisinde bulunan yeşil renkteki örneklemin herhangi bir özelliği, konum olarak en yakın üç komşusuna bakılarak Denklem 5.4 yardımıyla kolaylıkla hesaplanabilir.

$$\text{Yeşil Örneklemin Değeri} = \frac{x_4 + x_5 + x_6}{3} \quad (5.4)$$

Şekil 5.1’de görselleştirilen örnekten de anlaşılacağı üzere KEK algoritması temel olarak dört adımda çalışmaktadır. Bu adımlar sırasıyla;

- i. Özelliği belirlenmek istenilen örneklemin, veri seti içerisindeki bütün örneklemelere olan uzaklığının hesaplanması.
- ii. K parametresinin belirlenmesi.
- iii. Seçilen K parametresi kadar, en yakın konumdaki örneklemelerin tahmin edilmek istenilen özelliklerinin değerlerine bakılması.
- iv. Bakılan örneklemelerin değerlerini kullanarak özelliği belirlenmek istenilen örneklemin değerinin istatistiksel yöntemlerle hesaplanması.

Tahmin ve sınıflandırma uygulamaları için sıklıkla kullanılan k’nci mertebeden en yakın komşu (KEK) algoritması literatürde çeşitli alanlarda çeşitli disiplinlerce kullanılmıştır. Bu çalışmada, rüzgâr enerjisi üzerine çalışıldığı için aşağıda k’nci mertebeden en yakın komşu (KEK) algoritmasının rüzgâr enerjisi üzerine kullanıldığı çalışmaların kısa bir özeti incelenebilir.

R. Morisson ve diğerleri tarafından gerçek rüzgâr santralı verileri kullanılarak rüzgâr türbinlerinin güç üretimlerindeki anormalliklerin tespiti üzerine yapılan çalışmada KEK tahmin algoritmasının bölgesel ayırık değer algoritmasına kıyasla daha başarılı sonuçlar elde ettiği kanıtlanmıştır[79]. C.R. Chen ve U.T. Katrini tarafından meteorolojik veriler kullanılarak güneş enerjisinin tahmini için yapılan çalışmada yapay sinir ağları ile güçlendirilmiş KEK algoritmasının ortalama hatanın karesi değerinin (RMSE), temel KEK algoritmasına kıyasla daha düşük olduğunu kanıtlamıştır[80]. M. Yeşilbudak ve diğerleri tarafından rüzgâr santralı ve meteorolojik veriler kullanılarak rüzgâr türbinlerinin kanatlarının pitch açılarının tahmini için yapılan çalışmada Manhattan yöntemi kullanılarak oluşturulan tahmin modelinin Öklid ve Minkowski yöntemlerine kıyasla daha düşük ortalama mutlak hata değerine sahip olduğu kanıtlanmıştır[81]. A.E. Hendouzi ve A. Bourouhou tarafından sistem verileri ve meteorolojik veriler kullanılarak fotovoltaik sistemlerin üretebilecekleri güçlerin tahmini üzerine yapılan çalışmada ortalama kare hatalar göz önünde bulundurulduğunda KEK algoritmasının söz konusu çalışma için yazılan “kalıcı” tahmin algoritmasına göre daha başarılı sonuçlar aldığı kanıtlanmıştır[82]. M. Demirtaş ve diğerleri tarafından sıcaklık, nem ve basınç verileri kullanılarak güneş enerjisi tahmini üzerine yapılan çalışmada Öklid uzaklık yöntemi kullanılan KEK modelinin Manhattan ve Minkowski yöntemleri kullanılarak oluşturulan KEK


modellerine göre daha düşük ortalama mutlak hata ve ortalama hataların karesi değerlerine sahip olduğu kanıtlanmıştır[83]. A. Kusiak ve diğerleri tarafından rüzgâr hızı verileri kullanılarak rüzgâr gücü tahmini üzerine yapılan çalışmada ortalama bağıl hata değerleri baz alındığında KEK algoritmasının torbalama algoritma modellerinden daha başarılı sonuçlar elde ettiği görülmüştür[84]. S. Sağırlioğlu ve diğerleri tarafından rüzgâr hızı, rüzgâr yönü ve hava sıcaklığı verileri kullanılarak rüzgâr gücü tahmini üzerine yapılan çalışmada çeşitli k değerleri ve Öklid, Manhattan, Minkowski uzaklık hesaplama yöntemleri kullanılmıştır. Çalışmanın sonucuna göre ortalama mutlak hata değerleri göz önünde bulundurulduğunda en başarılı sonuçları $k=4$, ve Manhattan uzaklık ölçüm yöntemi yakalamıştır[85]. J. An ve diğerleri tarafından rüzgâr hızı ve rüzgâr gücü verileri kullanılarak çeşitli rüzgâr hızları için rüzgâr türbinlerinin üretebilecekleri güçlerin tahmin edildiği çalışmada ortalama hataların karesi göz önünde bulundurulduğunda KEK ile güçlendirilmiş DVM(Destek Vektör Makinesi) algoritmasının YSA(Yapay Sinir Ağları) ile güçlendirilmiş DVM algoritmasından daha başarılı sonuçlar elde ettiği görülmüştür[86]. M. Yeşilbudak ve diğerleri tarafından rüzgâr hızı, rüzgâr yönü, rotor hızı, ve hava sıcaklığı verileri kullanılarak rüzgâr türbini yaw pozisyonlarının tahmini üzerine yapılan çalışmada çeşitli k değerleri için Öklid, Manhattan ve Minkowski uzaklık yöntemleri test edilmiştir. Çalışmanın sonucuna göre ortalama mutlak hata (MAE) değeri baz alındığında en başarılı sonuca $k=3$ değeri için Manhattan yöntemi ulaşmıştır[87]. H.T.C. Pedro ve diğerleri tarafından solar güç ve global ışıınım verileri kullanılarak solar güç tahmini üzerine yapılan çalışmada KEK tahmin algoritması ve kalıcı model kıyaslanmıştır. Çalışmanın sonucunda ortalama kare hata değerleri (RMSE) baz alındığında KEK algoritmasının kalıcı modelden daha başarılı sonuçlar elde ettiği görülmüştür[88]. Yine aynı çalışmada, rüzgâr gücü ve telemetri verileri kullanılarak rüzgâr tahmini üzerine yapılan araştırmada KEK tahmin algoritmasının ortalama hataların karesi değerinin kalıcı modelin ortalama hataların karesi değerine göre daha düşük olduğu kanıtlanmıştır[88]. A.D. Mehr ve arkadaşları tarafından rüzgâr hızı, nem, deniz seviyesindeki basınç verileri kullanılarak rüzgâr hızı tahmini çalışmasında KEK algoritması ve DVM (Destek Vektör Makinesi) tahmin algoritması kullanılmıştır. Ortalama hataların karesi değerleri baz alındığında KEK algoritmasının DVM algoritmasından daha başarılı tahminler yaptığı kanıtlanmıştır[89]. O. Eyecioğlu ve arkadaşları tarafından rüzgâr hızı, rüzgâr yönü, basınç ve hava sıcaklığı verileri kullanılarak rüzgâr gücü tahmini üzerine yapılan çalışmada KEK algoritması, karar

ağacı algoritması (KA) ve lineer regresyon modeli kıyaslanmıştır (LR). R^2 sonuçlarına göre en başarılı algoritma KEK olurken KEK algoritmasını sırayla KA ve LR algoritmaları takip etmektedir[90]. Y. Wen ve diğerleri tarafından rüzgâr hızı ve rüzgâr gücü verileri kullanılarak rüzgâr gücü tahmini üzerine yapılan çalışmada üç farklı tahmin algoritması kullanılmıştır. Kullanılan algoritmalar ortalama hataların karesi (RMSE) değerlerine göre kıyaslanmıştır. Çalışmanın sonucuna göre en başarılı sonuçları KEK ve otoregresif (AR) model alırken bu hibrit algoritmayı sırasıyla temel KEK ve temel AR algoritması takip etmektedir[91]. T. Ahmad ve diğerleri tarafından solar güç ve meteorolojik veriler kullanılarak solar güç tahmini üzerine yapılan çalışmada farklı tahmin algoritmaları denenmiştir. Yapılan çalışmanın sonucuna göre ortalama hataların karesi (RMSE) değerleri göz önüne alındığında KEK algoritmasının KA algoritmasından daha başarılı tahminler yaptığı görülmektedir[92]. H. Demolli ve diğerleri tarafından günlük rüzgâr hızı verileri kullanılarak rüzgâr gücü tahmini üzerine yapılan çalışmada çeşitli tahmin algoritmaları kullanılmıştır. Tahmin algoritmalarının başarı kıyaslamaları adına R^2 parametresi kullanılmıştır. Çalışmanın sonucuna göre KEK algoritmasının Lasso algoritmasından daha başarılı tahminler yaptığı görülmüştür[93].

5.2. Rastgele Orman Algoritması (RSO)

Makine öğrenmesinin denetimli öğrenme sınıfının temel üyelerinden olan rastgele orman algoritması tipik bir ağaç formu algoritması olarak, çeşitli karar mekanizmaları ile veri seti özniteliklerini kullanarak tahminlerde bulunan sınıflandırma ve regresyon algoritması olarak tanımlanabilir[94]. Rastgele orman algoritması topluluk öğrenmesi algoritmalarının torbalama üyelerinin yaptıkları gibi veri setini birçok alt kümelerle böler. Bölünmüş her bir veri seti için kök hücrelere, karar hücrelere ve yaprak hücrelere sahip karar ağaçları oluşturur. Oluşturulan karar ağaçları kullanılarak herhangi bir örneklemin belirlenmek istenilen özelliği tahmin edilmeye çalışılır. Eğer tahmin edilecek özellik bir matematiksel ifade ise her bir karar ağacının tahmininin ortalaması alınır. Eğer tahmin edilecek özellik bir sınıf ataması ise her bir karar ağacının belirlediği sınıflar oylamaya tabii tutulur ve en çok oyu alan sınıf, türü belirlenmek istenilen örneklemin sınıfı olarak tayin edilir[95]. Rastgele orman algoritmasının atası olan karar ağacı algoritmasından temel farkı ise rastgele orman algoritmasındaki karar ağaçlarının her birinin veri seti alt kümeleriyle dolayısıyla

farklı öznitelik sayısındaki farklı veri seti kümeleriyle eğitiliyor oluşlarıdır. Bu sayede birbirlerine paralel bağlanan karar ağaçları farklı özniteliklerle test edildikleri için birbirlerinden daha az etkilenmekte ve daha yüksek tahmin doğrulukları kazanmaktadırlar[96].



Şekil 5.2 : Rastgele Orman Algoritmasının Çalışma Mekanizması.

Şekil 5.2’de temel olarak çalışma mekaniği görselleştirilen rastgele orman algoritması aşağıda sıralanan adımlarla tahmin işleminde bulunur:

- Veri setini alt veri seti kümelerine bölünmesi.
- Alt veri seti kümelerinin test ve eğitim veri seti olarak iki kısma ayrılması.
- Her bir alt veri seti kümesi için birbirlerinden bağımsız çalışan karar ağaçları oluşturulması.
- Her bir karar ağacının kendisi ile ilintili alt veri seti kümesinin test ve eğitim verilerini kullanarak tahminde bulunması.
- Bütün karar ağacı tahminlerinin ortalaması alınarak nihai sonuca ulaşılması.

Tahmin ve sınıflandırma uygulamaları için sıklıkla kullanılan rastgele orman (RSO) algoritması literatürde çeşitli alanlarda çeşitli disiplinlerce kullanılmıştır. Bu

çalışmada, rüzgâr enerjisi üzerine çalışıldığı için aşağıda rastgele orman (RSO) algoritmasının rüzgâr enerjisi üzerine kullanıldığı çalışmaların kısa bir özeti incelenebilir.


Z. Zhou ve diğerleri tarafından rüzgâr gücü tahmini üzerinde yapılan çalışmada tahmin algoritması olarak rastgele orman algoritması kullanılmıştır. Yapılan çalışmada algoritma başarısının ölçülmesi adına ortalama mutlak hata değeri kullanılmıştır. Çalışmanın sonucuna göre karar ağacı sayısı arttıkça ortalama mutlak hata değerinin azaldığı görülmüştür[97]. Ö. E. Yürek ve diğerleri tarafından yapılan çalışmada rüzgâr gücü tahmini için çeşitli makine öğrenmesi algoritmaları kullanılmıştır. Çalışmanın sonucuna göre rastgele orman algoritmasının ekstra ağaç algoritmasına göre daha doğru tahminler yaptığı görülmüştür[98]. Z. Sun ve diğerleri tarafından rüzgâr hızı ve rüzgâr gücü tahmini üzerine yapılan çalışmada rastgele orman algoritması kullanılmıştır. Çalışmanın sonucuna göre rastgele orman algoritması rüzgâr hızı ve rüzgâr gücü tahmininde yüksek doğrulukta başarılar yakalamıştır[99]. G. V. Drisya ve arkadaşları tarafından yapılan çalışmada rüzgâr hızı tahminleri için rastgele orman algoritması kullanılmıştır. Çalışmanın sonucunda rüzgâr hızı tahminlerinde rastgele orman algoritmasının düşük ortalama hataların karesi değerlerine sahip olarak yüksek doğrulukta tahminler yaptığı kanıtlanmıştır[100]. A. Alonso ve arkadaşları tarafından rüzgâr enerjisi tahmini üzerine yapılan çalışmada tahmin algoritması olarak rastgele orman ve gradyan yükseltme algoritması ve destek vektör mekanizması algoritması kullanılmıştır. Çalışmanın sonucunda rastgele orman algoritmasının ve gradyan yükseltme algoritmasının destek vektör makinesi algoritmasına kıyasla daha düşük ortalama kare hata değerlerine sahip oldukları görülmüştür[101]. P. P. Revheim ve H. G. Beyer tarafından rüzgâr gücü tahmini üzerine yapılan çalışmada rastgele orman algoritması kullanılmıştır. Çalışmada üç farklı tahmin algoritması kullanılmış ve en başarılı sonuçları rastgele orman algoritması yakalamıştır[102]. K. Shi ve diğerleri tarafından yapılan çalışmada rüzgâr gücü tahmini için rastgele orman algoritması iyileştirilmeye çalışılmıştır. Çalışmanın sonucunda rastgele orman algoritması temel formuna kıyasla daha yüksek doğrulukta tahminler yapmaktadır[103]. A. Lahouar ve J.B.H. Slama tarafından yapılan rüzgâr gücü tahmini çalışmasında rastgele orman algoritması ve yapay sinir ağları algoritması kullanılmıştır. Çalışmada kullanılan algoritmaların başarıları ortalama hataların karesi değerlerine bakılarak kıyaslanmıştır. Çalışmanın sonucuna göre rastgele orman algoritması yapay sinir ağlarından daha

düşük ortalama hataların karesi değerlerine sahip olmuştur[104]. G. Lannace ve diğerleri tarafından rüzgâr türbinlerinin gürültü tahmini üzerine yapılan çalışmada rastgele orman algoritması kullanılmıştır. Çalışmanın sonucuna göre rastgele orman algoritması %91 oranında pozitif korelasyon yakalayarak doğru tahminlerde bulunmuştur[105]. V.A. Natarajan ve N. S. Kumari tarafından rüzgâr gücü tahmini için paralel rastgele orman algoritması tekniği geliştirilmiş ve geliştirilen algoritmanın tahmin başarısı temel tahmin algoritmalarıyla kıyaslanmıştır. Çalışmanın sonucunda geliştirilen algoritmanın destek vektör makinesi algoritmasından daha doğru tahminlerde bulunduğu görülmüştür[106]. A. Tubulekas tarafından yürütülen çalışmada kısa süreli rüzgâr gücü tahmini için çeşitli makine öğrenmesi algoritmaları kullanılmıştır. Çalışmanın sonucunda rastgele orman algoritmasının lasso algoritmasından daha yüksek doğrulukta tahminler yaptığı görülmüştür[107]. Z. Wenting ve diğerleri tarafından rüzgâr gücü tahmini üzerine bir çalışma yapılmıştır. Yapılan çalışmada rüzgâr güçlerini tahmin etmek için rastgele orman algoritması kullanılmıştır. Çalışmanın sonucuna göre, rastgele orman algoritmasının yüksek doğrulukta tahminlerde bulunduğu görülmüştür[108]. L. Da ve S. Kun tarafından güneş enerjisi tahmini üzerine yapılan çalışmada çeşitli makine öğrenmesi algoritmaları kullanılmıştır. Çalışmanın sonucunda ortalama mutlak hata değerleri kıyaslandığında rastgele orman algoritmasının yapay sinir ağlarına kıyasla daha doğru tahminlerde bulunduğu kanıtlanmıştır[109].

5.3. Ekstra Ağaç Algoritması (ETA)

İsmi ekstra rastgele ağaçlar anlamına gelen “extra randomized trees” açılımından alan ekstra ağaçlar (ETA) algoritması, tıpkı karar ağacı ve rastgele orman algoritması gibi makine öğrenmesi kuramının denetimli öğrenme sınıfının topluluk öğrenmesi sınıfına ve bu sınıfın da torbalama yöntemine üye temel algoritmalarındandır. Çalışma mekanikleri ataları olan karar ağacı ve rastgele orman algoritmalarına çok benzemekle beraber karar ağacı algoritmasından veri setinin tamamını her denetim mekanizmasında kullanmayarak ayrılır. Rastgele orman algoritmasından ise her bir karar ağacının düğüm noktalarında en iyi ayrımı sağlayacak veri seti özneliliğinin kullanılması yerine tamamen rastgele seçilen bir veri seti özneliliği kullanılarak ayırım yapılması bakımından ayrılmaktadır. Ekstra ağaç algoritmasında veri seti tıpkı rastgele orman algoritmasında olduğu gibi çeşitli alt veri seti kümelerine ayrılmaktadır. Her bir

alt küme için oluşturulan karar ağaçlarında yaprak hücrelere doğru ilerlenirken düğüm noktalarında dallanmaları belirleyecek olan veri seti özelliklikleri seçilirken tamamen rastgelelik olacak şekilde seçimler yapılmaktadır. Bu yöntem sayesinde farklı veri seti kümeleriyle eğitilen her bir karar ağacının birbirlerini taklit etme olasılıkları azaltılmaya çalışılarak tahmin sonuçlarında farklılıklar yaratılmaya çalışılmaktadır[110,111].



Şekil 5.3 : Ekstra Ağaç Algoritmasının Çalışma Mekanizması.

Şekil 5.3'te ekstra ağaç algoritmasının çalışma mekaniği incelenebilir. Görüleceği üzere ham veri seti birçok alt veri seti kümesine ayrıştırılmıştır. Her bir alt veri seti kümesi için karar ağaçları oluşturulmuştur. Her bir karar ağacı dallanırken en iyi ayrılma ilkesinden bağımsız olarak ayrılmış karar ağaçlarının benzerlikleri azaltılarak karar ağaçlarının birbirlerini taklit etmesi önlenmeye çalışılmıştır. Şekil 5.3'te temel olarak çalışma mekaniği görselleştirilen rastgele orman algoritması aşağıda sıralanan adımlarla tahmin işleminde bulunur[111]:

- i. Veri setini alt veri seti kümelerine bölünmesi.
- ii. Alt veri seti kümelerinin test ve eğitim veri setleri olarak ikiye ayrılması.
- iii. Her bir alt veri seti kümesinin eğitim ve test verilerini kullanarak bağımsız karar ağaçlarının oluşturulması.

- iv. Her bir karar ağacının kendileriyle ilintili veri setleriyle eğitilerek tahminlerde bulunması.
- v. Bütün karar ağacı tahminlerinin ortalamasını alarak nihai sonuca ulaşılması.

Tahmin ve sınıflandırma uygulamaları için sıklıkla kullanılan ekstra ağaç (ETA) algoritması literatürde çeşitli alanlarda çeşitli disiplinlerce kullanılmıştır. Bu çalışmada, rüzgâr enerjisi üzerine çalışıldığı için aşağıda ekstra ağaç (ETA) algoritmasının ağırlıkla rüzgâr enerjisi üzerine kullanıldığı çalışmaların kısa bir özeti incelenebilir.

Ö.E.Yürek ve arkadaşları tarafından rüzgâr enerjisi üzerine yapılan çalışmada çeşitli makine öğrenmesi algoritmaları kullanılarak rüzgâr güçleri tahmin edilmeye çalışılmıştır. Çalışmanın sonucuna göre ekstra ağaç algoritması daha düşük ortalama mutlak hata değeri ile ridge, lasso, konvansiyonel sinir ağları ve karar ağacı algoritmalarından daha başarılı tahmin sonuçlarında bulunmuştur[98]. M.W. Ahmad ve diğerleri tarafından solar termal enerji sistemlerinin üretebilecekleri güçlerin tahmin edilmesi üzerine yapılan çalışmada destek vektör makineleri, rastgele orman, ekstra ağaç ve regresyon ağacı algoritmaları kullanılmıştır. Çalışmanın sonucunda kullanılan algoritmaların tahmin başarılarını ölçmek için ortalama karekök hata değerleri incelenmiştir. Çalışmanın sonucunda en yüksek doğruluklarda tahmin yapan makine öğrenmesi algoritmasının ekstra ağaç olduğu kanıtlanmıştır[112]. S. M. Malakouti tarafından rüzgâr türbinlerinin üretebilecekleri güçler üzerine yapılan çalışmada ekstra ağaç algoritması, adaptif yükseltme algoritması, ridge algoritması, karar ağacı algoritması, gradyan yükseltme algoritması, rastgele orman algoritması test edilmiştir. Çalışmanın sonucuna göre, en başarılı tahmin sonuçlarını %99 doğrulukla ekstra ağaç algoritması yakalamıştır[113]. M. Tang ve diğerleri tarafından rüzgâr türbini jeneratörlerinin çevrim içi arızalarının tespiti üzerine çalışılmıştır. Çalışmanın sonucuna göre ekstra ağaç algoritması gradyan yükseltme ve rastgele orman algoritmasından daha yüksek doğrulukta tahminlerde bulunmuştur[114]. D.P.P. Meddage ve diğerleri tarafından rüzgâr gücünün binalar üzerindeki basıncını tahmin etmek üzerine yapılan çalışmada ekstra ağaç ve rastgele orman algoritmalarıyla oluşturulmuş modelin yapay sinir ağları modeline göre başarısı karşılaştırılmıştır. Çalışmanın sonucuna göre ekstra ağaç ve rastgele orman algoritması kullanılarak oluşturulan model yapay sinir ağlarından daha yüksek doğrulukta sonuçlar vermektedir[115]. Ö. Mintemur ve İ. Gürkaynak tarafından yapılan çalışmada


Fransanın Sceaux bölgesinin 4 senelik verileri kullanılarak evlerin günlük enerji kullanımları tahmin edilmeye çalışılmıştır. Çalışmada ekstra ağaç algoritması ve rastgele orman algoritması kullanılmıştır. Çalışmanın sonucuna göre ekstra ağaç algoritması rastgele orman algoritmasından daha düşük ortalama hataların karekökü sonuçlarına ulaşarak daha yüksek doğrulukta tahminler yapmışlardır[116]. A.N.Alkawaz ve diğerleri tarafından bir sonraki gün için elektrik ücretinin tahmin edilmesi üzerine yapılan çalışmada ekstra ağaç algoritması ve lineer regresyon algoritması temelli yeni bir model oluşturulmuştur. Çalışmanın sonucuna göre oluşturulan yeni hibrit model iki algoritmanın bireysel kullanılmış hallerinden daha yüksek doğrulukta sonuçlar vermektedir[117]. A. Abdelatif ve diğerleri tarafından solar panellerin üretebilecekleri güçlerin tahmin edilmesi üzerine yapılan çalışmada adaptif yükseltme, ekstra ağaç, karar ağacı, rastgele orman algoritması olmak üzere çeşitli algoritmalar test edilmiştir. Çalışmanın sonucuna göre ekstra ağaç algoritması karar ağacı algoritması ve rastgele orman algoritmasından daha yüksek doğrulukta sonuçlar vermektedir[118]. S.M. Malakouti ve A.R. Ghiasi tarafından Basel rüzgâr çiftliğinin üretebileceği rüzgâr enerjisinin belirlenmesi için rüzgâr hızlarının tahmin edilmeye çalışıldığı çalışmada makine öğrenmesi olarak ekstra ağaç ve zayıf gradyan yükseltme algoritmaları kullanılmıştır. Çalışmanın sonucuna göre ekstra ağaç algoritması 2.52'lik ortalama mutlak hata değeriyle zayıf gradyan yükseltme algoritmasından daha yüksek doğrulukta tahminlerde bulunmuştur[119].

5.4. Gradyan Yükseltme Algoritması (GRY)

Amerikalı istatistikçi L.Breiman tarafından öne sürülen ve daha sonra J.H. Friedman tarafından geliştirilen gradyan iyileştirme ya da başka bir deyişle gradyan yükseltme algoritması, makine öğrenmesinin topluluk öğrenmesi sınıfının iyileştirme gurubunun en önemli algoritmalarından biridir[120]. Gradyan yükseltme algoritmasında da tıpkı diğer topluluk öğrenmesi algoritmalarında olduğu gibi ağaç formu kullanılmaktadır. Gradyan yükseltme algoritmasında tahmin ya da sınıflandırma yapabilmek için tıpkı torbalama algoritmaları gibi birden çok karar ağaçları oluşturulur ve her bir karar ağacının sonucu değerlendirilir. Gradyan yükseltmesi algoritmasını diğer torbalama algoritmaları olan rastgele orman ya da ekstra ağaç algoritmalarından ayıran en önemli özellik ise gradyan yükseltme algoritmasında karar ağaçlarının paralel bağlanmak yerine seri bağlanarak birbirlerine bağımlı olarak tahminler yapmalarıdır. İlk yaratılan

karar ağacının veri seti üzerine yaptığı tahminler ışığında hesaplanan hata değerleri kullanılarak yeni yaratılacak olan karar ağacının veri seti oluşturulur ve oluşturulan bu veri seti kullanılarak yeni yaratılacak karar ağacı sınanır daha sonra yeni yaratılacak karar ağacının tahmin sonuçları kullanılarak hesaplanan hata değerleri ışığında başka bir karar ağacı için başka bir veri seti oluşturulur. Bu işlem izin verilen iterasyona kadar devam ettirilir. Bu işlem sayesinde yaratılan her bir karar ağacı kendisinden bir önce yaratılan karar ağacının hatalarına göre eğitildiği için daha yüksek doğrulukta tahminler vermektedir. Bu yöntemle zayıf tahmin edici özelliğindeki her bir karar ağacı güçlü tahmin edici özelliğine kavuşturulur[120–122].

Şekil 5.4'te gradyan yükseltmesi algoritmasının çalışma prensibi verilmiştir. Görüleceği üzere, veri seti üzerinde denenen ilk karar ağacı algoritmasının hata değerleriyle revize edilen veri seti başka bir karar ağacıyla sınanmaktadır. Bu sayede zayıf tahmin edici olan karar ağaçlarının hata değerleri her adımda azalarak tahmin edilmeye çalışılan değere yaklaşılmaktadır.



Şekil 5.4 : Gradyan Yükseltme Algoritmasının Çalışma Mekanizması.

Şekil 5.4'te temel olarak çalışma mekanizması görselleştirilen gradyan yükseltme algoritması aşağıda sıralanan adımlarla tahminlerde bulunmaktadır:

- i. Veri setinin yüklenmesi.
- ii. Karar ağacı oluşturulması.

- iii. Karar ağacının hata sonuçları kullanılarak veri setinin revize edilmesi.
- iv. Revize edilen veri setiyle yeni bir karar ağacının test edilmesi.
- v. Yeni karar ağacının hata değerleriyle veri setinin yeniden revize edilmesi.
- vi. ii, iii, iv, ve v numaralı adımların belirlenen iterasyon sayısı boyunca tekrarlanması.
- vii. Sonuncu iterasyondaki karar ağacının tahmin sonucunun nihai sonuç olarak atanması.

Tahmin ve sınıflandırma uygulamaları için sıklıkla kullanılan gradyan yükseltme (GRY) algoritması literatürde çeşitli alanlarda çeşitli disiplinlerce kullanılmıştır. Bu çalışmada, rüzgâr enerjisi üzerine çalışıldığı için aşağıda gradyan yükseltme (GRY) algoritmasının ağırlıklı olarak rüzgâr enerjisi üzerinde kullanıldığı çalışmaların kısa bir özeti incelenebilir.

Y.Fan ve W. Lei tarafından rüzgâr enerjisi üzerine yapılan çalışmada rüzgâr hızı verileri tahmini için adaptif yükseltme, karar ağacı, gradyan yükseltme ve lineer regresyon algoritmaları kullanılmış ve tahmin başarıları ortalama mutlak hata, ortalama hataların karekökü ve r kare sonuçlarına göre değerlendirilmiştir. Çalışmanın sonucuna göre en düşük ortalama mutlak hata ve en yüksek r kare sonuçlarına ulaşan gradyan yükseltme algoritması diğer algoritmalarından daha yüksek doğrulukta tahminlerde bulunmuştur[123]. R.Cai ve diğerleri tarafından rüzgâr hızı tahmini üzerine yapılan çalışmada gradyan yükseltme algoritması lineer regresyon ve geri beslemeli yapay sinir ağları algoritmaları kullanılmış ve tahmin başarılarının kıyaslanması için metrik parametreleri olarak ortalama mutlak hata, ortalama hataların karesi ve ortalama hataların karekökü sonuçlarına bakılmıştır. Çalışmanın sonucuna göre gradyan yükseltme algoritması diğer iki algoritmaya kıyasla daha yüksek doğrulukta tahminler yapmaktadır[124]. R. Baile ve J.F. Muzy tarafından rüzgâr hızı tahmini üzerine yapılan çalışmada uzun kısa süreli hafıza modeli, gradyan yükseltme algoritması modeli ve lineer regresyon modeli kullanılmıştır. Çalışmanın sonucuna göre en başarılı tahminleri lineer regresyon yaparken lineer regresyonu gradyan yükseltme algoritması ve uzun kısa süreli hafıza modeli takip etmektedir[125]. S.B. Fonseca ve diğerleri tarafından rüzgâr enerjisi üzerine yapılan çalışmada rüzgâr hızlarının tahmin edilmesi için çeşitli makine öğrenme algoritmaları kullanılmıştır. Çalışmanın sonucuna göre gradyan yükseltme algoritması ekstra ağaç, destek vektör

makinesi k 'nci mertebeden en yakın komşular ve çok katmanlı algılayıcı algoritmalarına kıyasla daha düşük hata sonuçlarına ulaşarak daha yüksek doğrulukta tahminlerde bulunmuştur[126]. R. L. Bailey ve diğerleri tarafından rüzgâr enerjisi ve güneş enerjisinin hibrit olarak kullanıldığı sistemde üretilecek güçlerin tahmin edilmesi üzerine yapılan çalışmada gradyan yükseltme algoritması kullanılmıştır. Çalışmanın sonucunda gradyan yükseltmesi algoritmasının tatmin edici tahmin başarısı yakaladığı belirtilmiştir[127]. N. Bagalkot ve diğerleri tarafından rüzgâr enerjisi üzerinde yapılan çalışmada yatay eksenli rüzgâr türbinlerinin türbin kanatlarındaki kuvvet dağılımının tahmin edilmesi üzerine çalışılmıştır. Çalışmada gradyan yükseltmesi ile yapılan tahminlerin CFD programıyla kıyaslanması yapılmıştır. Çalışmanın sonucuna göre gradyan yükseltmesi algoritması tatmin edici tahmin sonuçlarına ulaşmıştır[128].

6. VAKA ÇALIŞMASI İÇİN VERİ SETİNİN HAZIRLANMASI

Bu çalışma kapsamında Bursa’da yer alan, bünyesinde 8 adet rüzgâr türbini barındıran ve faal olarak elektrik üretiminde bulunan rüzgâr santralının verileri kullanılmıştır. Tez, iki ana araştırma konusu üzerinde ilerletilmiştir. Bunlardan ilki, bahsi geçen rüzgâr santralının içerisinde bulunan rüzgâr türbinlerinin bir senelik verilerini göz önünde bulundurularak, rüzgâr türbinlerinin çeşitli rüzgâr hızlarında üretebilecekleri güçlerin tahmin edilmesi amacıyla çeşitli makine öğrenmesi algoritmaları baz alınarak oluşturulan modelleri test etmek, test edilen her modelin en başarılı tahminlerde bulunacağı hiper parametreleri tespit etmek, başarıları test edilen modellerin çalışma prensiplerini baz alarak test edilen modellerden daha başarılı olabilecek bir makine öğrenmesi modeli tasarlamaktır.

Çalışmanın birinci kısmı için k’nci mertebeden en yakın komşular (KEK) temelli, rastgele orman (RSO) temelli, ekstra ağaç (ETA) temelli ve gradyan yükseltme (GRY) temelli modeller test edilip iyileştirilmiş ve bahsi geçen modellerin çalışma prensiplerine dayanan yeni bir tahmin modeli oluşturulmuştur. Yapılan çalışmada iyileştirilen her bir modelin ve tasarlanan yeni tahmin modelinin tahmin başarıları ortalama mutlak hata (MAE), ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE) ve R^2 gibi çeşitli başarı ölçütlerine göre kıyaslanmıştır.

Bu tez kapsamında çalışılan bir diğer konu ise, bünyesinde 16 adet rüzgâr türbini barındıran ve faal olarak elektrik üretiminde bulunan bir başka rüzgâr santralının verileri kullanılarak bahsi geçen rüzgâr santralının senelik elektrik enerjisi üretimini arttırmak amaçlı türbin konumlarının iyileştirilmesi işlemidir. Çalışmanın ikinci kısmında rüzgâr santralının türbin konumlarını belirlemek amaçlı yeni bir model tasarlanmıştır. Rüzgâr türbinlerinin konumlarının belirlenmesi işleminde literatürde sıklıkla kullanılan ve temel iz modellerinden olan Jensen iz modeline bağlı kalınmıştır. Tasarlanan modelde açık kaynak kodlu olması nedeniyle Python yazılım dili ve arayüz gelişmişliği nedeniyle Spyder tümleşik geliştirme ortamı tercih edilmişlerdir.

6.1. Veri Setinin Tahmin Modelleri İçin Hazırlanması

Çalışmanın bu kısmında, birinci araştırma konusu ve vaka çalışması olan rüzgâr türbinlerinin üretebilecekleri güçlerin tahmini için geliştirilen makine öğrenmesi modellerinin test ve eğitimleri için kullanılacak ham verinin faydalı veri haline dönüştürülmesi işlemi açıklanmıştır. Şekil 6.1 incelendiğinde verileri kullanılan rüzgâr santralının ve barındırdığı rüzgâr türbinlerinin konumları incelenebilir.



Şekil 6.1 : Verileri Kullanılan Enerji Santrali.

Yukarıda vaka çalışmasında kullanılan rüzgâr santralının arazisi ve santral içerisindeki rüzgâr türbinlerinin dağılımları görülebilmektedir. Veri gizliliği sebebiyle rüzgâr santralında bulunan rüzgâr türbinlerinin modelleri ve konumları tez çalışmasında spesifik olarak belirtilmeyecektir ayrıca rüzgâr türbinlerinin ürettiği güç verileri birimsiz ve boyutsuz olarak verilecektir.

Makine öğrenmesi modellerini eğitebilmek amacıyla Şekil 6.1’de konumları belirtilen rüzgâr türbinlerinin kayıt altında tutulan bir senelik verileri kullanılmıştır. Kullanılan verilerin cinsi ve miktarları Çizelge 6.1 kullanılarak incelenebilir.

Çizelge 6.1 : Veri Seti Öz nitelikleri.

Veri Adı	Adedi
Üretilen Güç	52560
Teorik Olarak Üretilebilecek Güç	52560
Rüzgâr Hızı	52560
Rüzgâr Yönü	52560
Tarih	52560

Görüleceği üzere veri seti içerisinde literatürde de sıklıkla kullanımına rastlanılan yöntemlerden olan bir rüzgâr türbininin bir senelik ölçümleri bulunmaktadır. Veri seti

öznitelikleri olarak adlandırılan üretilen güç, teorik olarak üretilebilecek güç, rüzgâr hızı, rüzgâr yönü ve tarih özelliklerinin numerik olanlarının standart sapmaları ve ortalamalarına bakılmış ve ham veri seti hakkında bilgi sahibi olunmaya çalışılmıştır.

Denklem 6.1 ve Denklem 6.2 yardımıyla veri seti özniteliklerinin standart sapmaları ve ortalama değerleri hesaplanmıştır.

$$\sigma = \sqrt{\frac{\sum_{j=1}^N (y_j - \bar{y})^2}{N - 1}} \quad (6.1)$$

Denklem 6.1’de N örneklem sayısını, y_j veri setindeki j’nci örnekleme, $\bar{y}$ örneklemelerin ortalamasını ifade etmektedir.

$$\bar{y} = \frac{\sum_{j=1}^N (y_j)}{N} \quad (6.2)$$

Denklem 6.2’ de N veri setindeki örneklem sayısını, y_j veri setindeki j’nci örnekleme, ifade etmektedir.

Denklem 6.1 ve Denklem 6.2 veri seti içerisindeki özniteliklere uygulanmıştır. Sonuçlar Çizelge 6.2’ de görülebilir.

Çizelge 6.2 : Veri Seti Öz Niteliklerinin İstatiksel Durumu.

	Üretilen Güç	Teorik Olarak Üretilebilecek Güç	Rüzgâr Hızı (m/s)	Rüzgâr Yönü (°)
Ortalama Değer	0.87	0.99	7.5	124
Standart Sapma	0.87	0.91	4.2	93.5
Maksimum Değer	2.39	2.4	25	359
Minimum Değer	0	0	0	0
%25	0.03	0.10	4.21	50
%50	0.55	0.70	7.11	74
%75	1.65	1.97	10.4	202

Çizelge 6.2 incelendiğinde veri seti içerisinde bulunan öz niteliklerin istatiksel durumları görülebilir. Üretilen güç ve teorik olarak üretilebilecek güç verileri, veri gizliliği kapsamında belirli bir kuvvet çarpanı ile çarpılmışlardır.

Veri seti içerisindeki üretilen güçlerin en küçük değeri 0 ve maksimum değeri 2.39 büyüklüğündedir. Teorik olarak üretilebilecek güçlerin değeri ise 0 ile 2.4 değerleri arasında değişmektedir. Veri setindeki rüzgâr hızları incelendiğinde hız değerlerinin 0 m/s ile 25 m/s arasında, ve rüzgâr yönlerinin ise 0° ile 359° derece arasında değiştiği görülmektedir.


Veri setindeki üretilen güç örneklemelerinin ortalama değeri ve standart sapması 0.87 değerindedir. Teorik olarak üretilebilecek güçlerin ortalaması 0.99 değerini alırken standart sapması 0.91 değerini almaktadır. Aynı şekilde rüzgâr hızı verileri incelendiğinde ortalamalarının 7.5 m/s ve standart sapmalarının ise 4.2 m/s olduğu görülmektedir. Rüzgâr yönlerine bakıldığında örneklemelerin standart sapmasının 93.5° ortalamasının da 124° olduğu görülmektedir.

Ek olarak Çizelge 6.2’de %50 olarak tanımlanan değer örneklemelerin medyanına karşılık gelmektedir. Sırasıyla üretilen güç verilerinin, teorik olarak üretilebilecek güç verilerinin, rüzgâr hızı ve rüzgâr yönü verilerinin medyan değerleri 0.55, 0.70, 7.11 m/s ve 74° değerlerinde olduğu görülebilir. Yukarıda yer alan %25’lik ve %75’lik değerler de özniteliklerin maksimum değerleri baz alınarak oluşturulmuş %25’lik ve %75’lik değerleridir. Bu değerler veri seti içerisindeki aykırı değerlerin ayrılması sırasında direkt olarak kullanılacaklardır. Bu sebepten ötürü hesaplanmış ve Çizelge 6.2’ ye dahil edilmişlerdir. Veri seti incelendiğinde numerik olmayan tarih verisinin numerik değerlere çevrilmesi ihtiyacı görülmüştür. Bu şekilde veri seti hakkında bilgi sahibi olmak için aylık, günlük, saatlik ve dakikalık güç üretimi kolayca görselleştirilebilir. Bu sebeple veri setindeki tarih özelliği numerik değerlere dönüştürülmüştür. Veri setinin yeni görünümü Çizelge 6.3’ te gösterilmiştir.

Çizelge 6.3 : Tarih Özniteliğinin Numerikleştirilmesi Sonrası Veri Seti.


Gün	Ay	Saat	Dakika	Üretilen Güç	Teorik Olarak Üretilebilecek Güç	Rüzgâr Hızı (m/s)	Rüzgâr Yönü (°)
1	4	22	10	0.46	0.48	6.31	24
1	4	22	20	0.55	0.57	6.52	20
1	4	22	30	0.59	0.61	6.81	25
1	4	22	40	0.60	0.61	6.78	30
1	4	22	50	0.36	0.37	5.76	29

Veri seti hakkında bilgi sahibi olmak adına rüzgâr hızı verileri incelenmiştir. Şekil 6.2 incelendiğinde ham veri seti içerisindeki rüzgâr hızı büyüklükleri ve miktarlarına ulaşılabilir.




Şekil 6.2 : Ham Veri Setindeki Rüzgâr Hızı Verilerinin Dağılımı.

Görüleceği üzere veri seti içerisinde en yüksek oranda görülen hızlar 5 m/s ve 10 m/s büyüklükleri arasındaki hız verileri olup sayıları 1400 ile 1600 arasında değişmektedir. Şekil 6.2’den edinilecek bir diğer önemli bilgi ise veri setinde 20 m/s ve üzerindeki rüzgâr hızlarının diğer rüzgâr hızlarına kıyasla çok az miktarda bulunuyor olmalarıdır.




Şekil 6.3 : Ham Veri Setindeki Rüzgâr Yönü Verilerinin Dağılımı.

Şekil 6.3 incelendiğinde veri setindeki rüzgâr yönü verilerinin dağılımları görülebilmektedir. En yüksek oranda görülen rüzgâr yönü dereceleri 10° ile 80° dereceleri arasında yer almakta ve sayıları 1000 ila 5000 arasında değişmektedir.



Şekil 6.4 : Ham Veri Setindeki Teorik Güç Verilerinin Dağılımı.

Teorik olarak üretilebilecek güçlerin en fazla görüldüğü değerlerin 0 ile 0.5 arasında oldukları görülmüştür. Bu durumun sebebi dataları kullanılan rüzgâr türbininin modeli ve çalışma koşullarıyla açıklanmaktadır. Rüzgâr hızı dağılımı incelendiğinde rüzgâr hızlarının büyük bir kısmının 0 m/s ve 10 m/s arasında yoğunlaştığı görülmektedir. Dataları kullanılan rüzgâr türbininin kesme hızı olarak adlandırılan (cut speed) değerinin 3 m/s olduğu düşünüldüğünde Şekil 6.4’deki dağılımın tutarlı olduğu sonucuna varılabilir. Ek olarak, görüleceği üzere rüzgâr türbini bir senelik periyotta yaklaşık olarak 9000 defa maksimum güç değerini yakalamışken 12000’den fazla olacak sefer de güç üretiminde bulunamamıştır.




Şekil 6.5 : Ham Veri Setindeki Üretilen Güç Verilerinin Dağılımı.


Şekil 6.5 incelendiğinde veri seti içerisindeki üretilen güçler datalarının dağılımı görülebilir. Üretilen güçlerin büyük bir kısmı 0 ile 0.5 değerleri arasında yer almaktadır bunun en büyük sebebi ise rüzgâr hızı verilerinin büyük bir çoğunluğunun 0 m/s ile 10 m/s arasında yer almalarıdır. Üretilen güç dataları ile teorik olarak üretililecek güç dataları karşılaştırıldıklarında da görüleceği üzere benzer bir eğilim göstermektedirler. Aralarındaki tek fark üretilen güç datalarının 2 ile 2.5 arasındaki değerlerinin sayısının teorik olarak üretililecek güç değerleri sayısından az olmasıdır. Bu durumun esas nedeni ise rüzgâr türbininin yüksek rüzgâr hızı koşullarında mekanik hasarlardan korunma amaçlı ve çeşitli güvenlik önlemleri gereğince güç üretimlerinin durduruluyor olmasıdır.

Ham veri setindeki ay, gün, saat ve dakika verilerinin dağılımları Şekil 6.6’da görselleştirilmiştir. En eşit dağılım dakika verilerinde görülürken gün ve ay datalarında ufak da olsa dağılım farklılıkları göze çarpmaktadır.

Aylar, Günler, Saatler ve Dakikaların Dağılımları




Şekil 6.6 : Ham Veri Setindeki Ay, Gün, Saat ve Dakika Verilerinin Dağılımları.



Şekil 6.7 : Ham Veri Setindeki Rüzgâr Hızlarının Rüzgâr Yönlerine Göre Dağılımları.


Ham veri setindeki rüzgâr hızlarının 0 m/s ile 25 m/s arasında ve rüzgâr yönü ($^{\circ}$) verilerinin ise 0° ile 359° arasında değerler aldıkları görülebilir(Şekil 6.7) . 10 m/s ve 20 m/s arasındaki rüzgâr hızı verileri 0° ile 100° arasında yığılmaktadırlar. Aynı şekilde 20 m/s ile 25 m/s arasındaki rüzgâr hızı verileri ise 125° ile 225° dereceler arasında yığılım göstermişlerdir.



Şekil 6.8 : Rüzgâr Türbininin Rüzgâr Hızlarına Göre Üretebileceği Teorik Güçler.

Şekil 6.8 incelendiğinde tahmin modellerinin eğitimi için kullanılan rüzgâr türbininin teorik olarak üretebileceği güçler görülmektedir. Rüzgâr türbini 15 m/s ve üstündeki


hızlarda maksimum güç değeri olan 2.5'e ulaşmaktadır. Ayrıca 3 m/s ve altındaki hızlarda herhangi bir güç üretimi yapamamaktadır. Veri gizliliği sebebi ile rüzgâr türbininin üretebileceği teorik ve gerçek güç değerleri belirli bir çarpanla çarpılıp yeniden boyutlandırılarak birimsiz hale çevrilmişlerdir.




Şekil 6.9 : Rüzgâr Türbininin Rüzgâr Hızlarına Göre Ürettiği Güçler.

Şekil 6.9'da ham veri seti içerisindeki rüzgâr hızı verilerine karşılık gelen rüzgâr türbini tarafından üretilen güç verileri görselleştirilmiştir. Görüldüğü gibi, rüzgâr türbini tıpkı teorik olarak üretilebilecek güç grafiğinde olduğu gibi 15 m/s ve üzerindeki hızlarda 2 ile 2.5 değerleri arasında birbirlerine çok yakın güç değerleri üretmektedir. 3 m/s ve altındaki hızlarda ise güç üretememektedir. Bu bilgiler ışığında, Şekil 6.8'de göz önüne getirildiğinde rüzgâr türbini tarafından üretilen güç verilerinin rüzgâr türbini tarafından üretilebilecek teorik güç verileriyle genel konjonktürde benzer bir dağılım sergilediği söylenebilir. Lakin Şekil 6.9'da görüleceği üzere veri seti içerisinde aykırı değerler bulunmaktadır. Bu aykırı değerlerin Şekil 6.8'de görselleştirilen teorik olarak üretilebilecek güç değerlerinden belirli bölgelerde sapmalara yol açtığı göz ardı edilmemelidir.

Yukarıda görselleştirilen veri seti içerisindeki aykırı değerlerin yadsınamayacak bir kısmı Şekil 6.10'da 1 numara olarak işaretlenen alanda yer almaktadır. Buradaki aykırı değerlerin en büyük olası sebebi belirtilen rüzgâr hızlarında türbinin kanatlarının bakım ya da güvenlik gibi kısıtlarla durdurulmuş olmalarıdır.




Şekil 6.10 : Ham Veri Setindeki Aykırı Değerler-1.




Şekil 6.11 : Ham Veri Setindeki Teorik Güç ve Üretilen Güç Verileri.

Ham veri setindeki, rüzgâr türbini tarafından üretilen güç verileri ve rüzgâr türbini tarafından teorik olarak üretililecek güç verileri Şekil 6.11’ de görselleştirilmiştir. Şekil 6.11’de de tıpkı şekil 6.10’da görüldüğü gibi aykırı değerlerin varlığı saptanmıştır.




Şekil 6.12 : Ham Veri Setindeki Aykırı Değerler-2.

Yukarıda görüleceği üzere, rüzgâr türbini tarafından üretilebilecek teorik güç verileri ile rüzgâr türbini tarafından üretilen güç verilerin bir takım aykırı değerler barındırsalar da genel olarak benzer bir dağılım sergiledikleri söylenebilir. Şekil 6.12’de 1 numara olarak tanımlanan bölgedeki aykırı değerler incelendiğinde üretilen güç değerleri 0 iken teorik olarak üretilebilecek güç değerlerinin 0 ile 2.5 arasında değerler aldıkları görülmüştür. Bu durumun en büyük olası sebebi rüzgâr türbinine çeşitli hız değerleri ulaşmış olsa da rüzgâr türbini kanatlarının bakım, onarım, güvenlik gibi çeşitli sebeplerden dolayı bilinçli olarak durdurulmasıdır.



Şekil 6.13 : Ham Veri Setindeki Üretilen Güç Verilerinin Rüzgâr Yönlerine Göre Dağılımları.


Şekil 6.13'te rüzgâr türbini tarafından üretilen güçlerin rüzgâr yönlerine göre dağılımları gösterilmiştir. Yalnızca 100° ile 176° arasındaki yönlerde 1 üzerinde güç değerlerine rastlanmamıştır. Daha önce de açıklandığı gibi veri gizliliği kapsamında rüzgâr türbininin ürettiği güçler ve üretebileceği teorik güçler belirli bir çarpanla çarpılıp boyutsuz ve birimsiz olarak kullanılmıştır.



Şekil 6.14 : Ham Veri Setindeki Teorik Olarak Üretilebilecek Güç Verilerinin Rüzgâr Yönlerine Göre Dağılımları.


Şekil 6.14'te rüzgâr türbininin çeşitli rüzgâr yönlerinde üretebileceği teorik güç verilerinin dağılımı görselleştirilmiştir. Şekil 6.13'de görselleştirilen üretilmiş güçlerin rüzgâr yönlerine göre dağılımlarıyla büyük oranda benzerlik göstermektedir. Teorik güç verilerinin de 100° ile 150° dereceleri arasında 1 ve üzerinde teorik güç değerlerine ulaşmadığı görülmektedir. Bu durumun en önemli sebebinin 100° ile 150° dereceler arasında rüzgâr hızı verilerinin 5 m/s ve daha düşük değerlerde olmasıdır.

Şekil 6.15'te rüzgâr türbini tarafından üretilen güçlerin rüzgâr hızı ve rüzgâr yönlerine göre dağılımları görülebilir. Görüldüğü üzere rüzgâr türbinine ulaşan hızlar 0 m/s mertebelerinden başlayıp 25 m/s mertebelerine kadar ulaşmaktadır. Rüzgâr türbinlerine ulaşan rüzgâr hızlarının doğrultusu da büyük bir oranla Kuzeydoğu – Güneybatı (KD-GB) doğrultusundadır. Şekil 6.15'teki her bir nokta veri setindeki her bir örneklemin üretilmiş güç verilerini ifade etmektedir. En koyu lacivert renkte olan noktalar 2.5 büyüklüğüne yakın değerler olarak tanımlanırken en açık sarı renkte olan noktalarsa yaklaşık 0 büyüklüğündeki güç değerlerini ifade etmektedirler.



Şekil 6.15 : Ham Veri Setindeki Rüzgâr Türbini Tarafından Üretilen Güç Verilerinin Rüzgâr Hızı ve Rüzgâr Yönlerine Göre Dağılımları.

Rüzgâr türbininin ay bazında en fazla ortalama güç ürettiği aylar Mart, Ağustos ve Kasım aylarıdır(Şekil 6.16). Aynı şekilde günlük bazlı düşünüldüğünde rüzgâr türbininin ortalama olarak en fazla güç değerlerine ulaştığı günler ikinci, on dokuzuncu ve on üçüncü günlerdir. Ham veri seti saatlik bazda incelendiğinde, rüzgâr türbininin ortalama en fazla güç üretimi değerlerini 17:00 ile 23:00 saatleri arasında yakaladığı görülmüştür. Ek olarak dakika bazında eşit bir ortalama güç üretimi dağılımı gözlenmiştir.



Şekil 6.16 : Aylık, Günlük, Saatlik ve Dakikalık Ortalama Güç Üretimleri.


Veri seti içerisindeki özniteliklerin dağılımları teker teker incelenip veri seti hakkında bilgi sahibi olunduktan sonra veri setinde nihai olarak aykırı değerler olduğu kararına varılmıştır. Aykırı değerlerin yanı sıra kayıp değer kontrolü yapılan veri setinde, veri setinin hiçbir özniteliğinde kayıp değer olmadığı anlaşılmıştır. Çizelge 6.4’te veri seti üstünde yapılan kayıp değer araştırmasının sonuçları verilmiştir.

Çizelge 6.4 : Ham Veri Setindeki Özniteliklerin Kayıp Veri Ya Da Boş Veri Sayıları.

Veri Seti Öznitelikleri	Kayıp Veri Ya Da Boş Veri Sayısı
Rüzgâr Hızı (m/s)	0
Rüzgâr Yönü (°)	0
Üretilen Güç	0
Teorik Olarak Üretilebilecek Güç	0
Yıl	0
Ay	0
Gün	0
Saat	0
Dakika	0

Veri setindeki her bir özneliğin birbirleri üzerindeki korelasyonlarına bakılarak çalışmanın nihai tahmin hedefi olan üretilen güç verilerinin etkilendiği öznelilikler incelenmişlerdir.


Şekil 6.17 incelendiğinde tahmin edilmeye çalışılacak olan üretilecek güç değerinin Hedef olarak yeniden adlandırıldığı görülebilir. Göze çarpan ilk konunun, çoğu özneliğin birbirleri üzerlerinde ya %90'ın üzerinde pozitif yönlü korelasyona ya da %0'ın altında negatif yönlü korelasyona sahip olduklarıdır. Şekil 6.17'den anlaşılacağı üzere üretilen güç verileri rüzgâr hızı verileriyle %91 oranında pozitif yönlü korelasyona, teorik olarak üretilebilecek güç verileriyle de %95 oranında pozitif yönlü korelasyona sahiptir. Dolayısıyla bu iki öznelilik üretilecek güç değerlerini tahmin edilmesinde daha fazla söz sahibi olacaklardır. Ayrıca üretilen güç değerlerinin rüzgâr yönü, ay, gün, saat ve dakika verileriyle kuvvetli bir pozitif yönlü ya da negatif yönlü bir korelasyona sahip olmadıkları görülmektedir.



Şekil 6.17 : Ham Veri Setindeki Özneliliklerin Korelasyonları.


Veri seti öz niteliklerinin korelasyonlarıyla ilgili bilgiler belirlendikten sonra yüksek korelasyona sahip rüzgâr hızı, teorik olarak üretilebilecek güç verileri ve daha düşük korelasyonlu olan rüzgâr yönü verilerinin aykırı değerlere sahip olup olmadıkları incelenmiştir.

İlk olarak ham veri集中的 rüzgâr hızı, üretilen güçler ve teorik olarak üretilebilecek güçler verilerinin dağılımlarına bakılmış ve aykırı değerlerin hangi öz nitelikte olabileceğine karar verilmeye çalışılmıştır.




Şekil 6.18 : Ham Veri Setindeki Teorik Olarak Üretilebilecek Güç ve Üretilen Güç Verilerinin Rüzgâr Hızlarına Göre Dağılımları.

Şekil 6.18’de, çeşitli rüzgâr hızlarında rüzgâr türbini tarafından üretilen güçlerin rüzgâr türbini tarafından teorik olarak üretilebilecek güçlerle genel konjonktürde benzer bir dağılım sergiledi görülmüştür. Fakat üretilen güçlerin ana kümelerinden kopan her bir ölçüm ve 5 m/s üzerindeki hızlarda 0 güç üretiminde bulunan her bir ölçüm ham veri setinin aykırı değerleri olarak tanımlanmışlardır. Şekil 6.19’da aykırı değer olarak tanımlanan verilerin işaretlenmiş biçimleri görülebilir.




Şekil 6.19 : Ham Veri Setindeki Aykırı Değerler-3.

Şekil 6.19’da görüleceği üzere ham veri seti içerisindeki aykırı değerlerin büyük bir kısmı mavi ile belirtilen alanın içerisinde yer almaktadır. Makine öğrenmesi modellerinin başarılarının artırılması için veri setinin test ve eğitim olarak iki kısma ayrılmadan evvel aykırı değerlerden temizlenmesi gerekmektedir.




Şekil 6.20 : Veri Seti Özniteliklerindeki Aykırı Değerlerin Dağılımları.

Ham veri setinde bulunan özniteliklerin her birinin sahip olduğu aykırı değerler Şekil 6.20’de görülebilir. Öznitelikler arasında aykırı değerlere sahip olan tek özelliğin rüzgâr hızı verileri olduğu görülmüştür. Bu nedenle veri seti test ve eğitim olarak iki ana kısma ayrılmadan önce rüzgâr hızı özniteliğine ait olan aykırı değerlerin veri setinden temizlenmesi gerekmektedir.



Şekil 6.21 : Aykırı Değerler Temizlendikten Sonra Veri Setindeki Özniteliklerin Durumu.

Rüzgâr hızı verisindeki aykırı değerlerin temizlenmesinden sonra veri setindeki özniteliklerin dağılımı şekil 6.21’de incelenebilir. Aykırı değerlerin temizlenmesinden önce 25 m/s ve üzerinde rüzgâr hızlarına rastlanan veri setinde aykırı değerlerin temizlenmesinden sonra en yüksek 20 m/s mertebelerinde hızlara rastlanılmaktadır.



Şekil 6.22 : Aykırı Değerler Temizlendikten Sonra Veri Setindeki Teorik Olarak Üretilebilecek Güç ve Üretilen Güç verilerinin Rüzgâr Hızlarına Göre Dağılımları.

Ham veri seti içerisinde aykırı değerlerin temizlenmesi işlemi sonrasında veri seti içerisindeki üretilen güç ve teorik olarak üretilebilecek güçlerin çeşitli rüzgâr hızlarına göre dağılımları şekil 6.22’de görülebilir. Veri setinin yeni halinde toplamda 37391 adet anlamlı veri bulunmaktadır. Çizelge 6.5’ te anlamlı veri setinin istatistiksel özellikleri incelenebilir.

Çizelge 6.5 : Anlamlı Veri Setinin İstatistiksel Özellikleri.

	Rüzgâr Hızı (m/s)	Rüzgâr Yönü (°)	Üretilen Güç	Teorik Olarak Üretilebilecek Güç
Adet	37391	37391	37391	37391
Ortalama Değer	8.91	115.41	1.17	1.26
Standart Sapma	3.67	85.38	0.83	0.86
Minimum Değer	2.40	0	0.01	0.02
%25	6.05	49.56	0.37	0.42
%50	8.29	69.89	1.04	1.13
%75	11.33	197.028	2.032	2.25
Maksimum Değer	20.96	359	2.41	2.42

Ham veri setindeki aykırı değerler ayıklanıp veri seti anlamlı bir forma dönüştürüldükten sonra yapılan incelemede anlamlı veri seti içerisindeki özneliklerin

değerlerinin birbirlerinden ölçek olarak çok farklı boyutlarda oldukları görüldü. Kullanılacak algoritmaların başarılarının artırılması adına anlamlı veri seti içerisindeki verilere ölçeklendirme işlemi uygulanmıştır. Her bir özneliğin ölçeklendirilmesi için literatürde büyük veriler için sıklıkla tercih edilen standart ölçeklendirme yöntemi tercih edilmiştir. Anlamlı veri seti içerisindeki dataların standart ölçeklendirme öncesindeki ve sonrasındaki değerleri Çizelge 6.6’da görülebilir.

$$y_{yeni} = \frac{(y - \bar{y})}{\sigma} \quad (6.3)$$

Denklem 6.3’te standart ölçeklendirmenin formülü gösterilmiştir. Burada y_{yeni} herhangi bir öznelik sütununa ait bir verinin standart ölçeklendirme sonrasındaki yeni değerini, y aynı verinin standart ölçeklendirme öncesindeki değerini, $\bar{y}$ aynı verinin bulunduğu öznelik sütunundaki verilerin ortalamasını, σ öznelik sütununun standart sapmasını temsil etmektedir.

Çizelge 6.6 : Anlamlı Veri Setinin Ölçeklendirme İşlemi Öncesi Değerleri.

Rüzgâr Hızı (m/s)	Rüzgâr Yönü (°)	Teorik Olarak Üretililecek Güç
5.62	209	0.33
15.90	62	2.4
11.18	66	2.22
6.66	40	0.58
7.68	47	0.90

Çizelge 6.7 : Anlamlı Veri Setinin Ölçeklendirme Sonrası Değerleri.

Rüzgâr Hızı (m/s)	Rüzgâr Yönü (°)	Teorik Olarak Üretililecek Güç
-0.89	1.09	-1.05
1.95	-0.61	1.32
0.64	-0.57	1.11
-0.60	-0.88	-0.77
-0.32	-0.79	-0.40

Çizelge 6.8 : Anlamlı Veri Setinin Ölçeklendirme İşlemi Sonrası Özneliklerinin Durumları.

	Rüzgâr Hızı (m/s)	Rüzgâr Yönü (°)	Teorik Olarak Üretililecek Güç
Ortalama Değer	1.13×10^{-16}	-1.17×10^{-16}	-3.28×10^{-16}
Standart Sapma	1.0007	1.0007	1.0007

Çizelge 6.6 incelendiğinde anlamlı veri seti öznitelik değerlerinin birbirlerine kıyasla ölçeklendirme problemleri yaşadığı görülmektedir. 5.62 m/s hız değeri için rüzgâr yönü 209° değerindeyken teorik olarak üretilebilecek güç yalnızca 0.33 değerindeydi. Anlamlı veri seti üzerine yapılan standart ölçeklendirme işlemi sonrası aynı örneklemin değerleri sırasıyla -0.89, 1.09 ve -1.05 gibi birbirlerine yakın değerler almıştır. Ayrıca standart ölçeklendirme işlemi sonrasında anlamlı veri seti özniteliklerinin ortalamaları 0 değerine ve standart sapmaları da 1 değerine yaklaştırılmıştır. Bu sayede anlamlı veri setinde kalabilecek birkaç artık verinin olumsuz etkisi azaltılmaya çalışılmıştır.

Özet olarak, çalışmanın bu kısmında kısaca ham veri seti incelenmiştir. Ham veri seti üzerinde boş veya kayıp veri analizi yapılmıştır. Ham veri setinin öznitelikleri irdelenmiş ve numerik değerlere sahip olmayan öznitelikler numerik formlara dönüştürülmüştür. Her bir özneliğin istatistiksel incelemesi yapılmıştır. Her bir özneliğin birbirlerine etkisi irdelenmiş ve tahmin edilecek hedef özellik olan rüzgâr türbinleri tarafından üretilebilecek güç özneliğinin değerini belirleyen yüksek korelasyonlara sahip öznitelikler saptanmıştır.

Daha sonra ham veri setindeki özniteliklerin aykırı değerleri araştırılmıştır. Yapılan çalışma sonucunda tespit edilen aykırı değerler ham veri setinden ayıklanmıştır. Bu sayede ham veri seti anlamlı veri setine dönüştürülmüştür. Sonrasında, anlamlı veri seti öznitelikleri incelenmiş ve özniteliklerin değerlerinin birbirlerine kıyasla orantısız büyüklüklere sahip oldukları saptanmıştır. Bu durumun giderilmesi adına veri seti öznitelikleri standart ölçeklendirme yöntemiyle ölçeklendirilmiştir. Son olarak kullanılacak algoritmaların test ve eğitim işlemleri için hazır hale gelen anlamlı veri seti, veri sayısı göz önünde bulundurularak %20 test ve %80 eğitim olacak şekilde iki ana kümeye ayrılmıştır.




7. YAPILAN ANALİZLER VE ELDE EDİLEN SONUÇLAR

7.1. Rüzgâr Türbinlerinin Üretebilecekleri Güçlerin Geliştirilen Modellerle Tahmin Edilmesi

Bu kısımda 6 numaralı başlıkta detaylıca irdelenen veri seti kullanılarak k'nci mertebeden en yakın komşular (KEK) algoritması temelli, rastgele orman (RSO) algoritması temelli, ekstra ağaç (ETA) algoritması temelli, gradyan yükseltme (GRY) algoritması temelli ve bu algoritmaların çalışma prensiplerine dayanan yeni bir karma model (KRM) olmak üzere toplamda beş farklı tahmin modeli kullanılarak rüzgâr türbinlerinin çeşitli rüzgâr hızlarında üretebilecekleri güçler tahmin edilmeye çalışılmıştır. Test edilen bütün modellerin hiper parametreleri düzenlenmiş ve tahmin başarıları ortalama mutlak hata (MAE), ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE) ve r kare sonuçlarına bakılarak kıyaslanmıştır.

7.1.1. K'nci mertebeden en yakın komşular algoritması (KEK) temelli modelin tahmin sonuçları

Çalışma kapsamında ilk kullanılan makine öğrenmesi modeli, temelleri 1967 yılında P. Hart ve T. Cover tarafından atılan k'nci mertebeden en yakın komşular algoritması temelli modeldir[74]. Bu modelin çalışma mekaniği kısaca aşağıdaki adımlardan oluşturulmuştur.



Şekil 7.1 : KEK Algoritması İçin Tasarlanan Model.

KEK algoritmasının yüksek doğruluklu tahminlerde bulunması için çalışılan probleme göre düzenlenmesi gereken üç önemli hiper parametre vardır. Bu parametreler sırasıyla en yakın komşu sayısının belirlendiği “k” parametresi, veriler arasındaki uzaklığın hesaplanması için kullanılan “metrik” parametresi ve belirlenmiş k adet veri kullanılırken, k adet veri içerisindeki her bir verinin tahmin sonucu üzerindeki ağırlığını belirleyecek olan “ağırlık” parametresidir.


Çalışma kapsamında KEK algoritmasının ilk olarak düzenlenen parametresi kaç adet komşunun verilerinin kullanılarak tahmin yapılacağını belirleyen k parametresi olmuştur. Bu parametre 1 ile 250 arasında birer birer arttırılarak tahminler yapılmış ve en düşük ortalama hataların karekökü değerine sahip olan k parametresi bulunmaya çalışılmıştır. KEK algoritmasının düzenlenen diğer bir parametresi ise metrik parametresidir. Metrik parametresi KEK algoritmasında veri seti içerisindeki noktaların birbirlerine göre uzaklıklarının nasıl hesaplanacağını belirleyen matematiksel yöntemi tanımlamaktadır. Bu çalışmada metrik parametresi için iki yöntem test edilmiştir. Bu yöntemlerin ilki “Manhattan” yöntemidir. Manhattan yönteminin formülü Denklem 5.1’de görülebilir. Test edilen diğer bir uzaklık hesabı yöntemi ise “Öklid” yöntemidir. Öklid yönteminin formülü de Denklem 5.2’de görülebilir. Son olarak KEK algoritmasının ağırlık parametresi düzenlenmiştir. Ağırlık parametresi belirlenen k sayısı kadar parametrenin tahmin sonucunu nasıl etkileyeceklerini belirleyen parametredir. Ağırlık parametresi için kullanılan iki farklı yöntem bulunmaktadır. Bu yöntemlerden ilki “eşit” diğeri ise “uzaklık” yöntemidir. “Eşit” yönteminde k adet veri eşit ağırlıklarda sonucu etkilemektedir ancak “uzaklık” yönteminde ise k adet veri içerisindeki her bir veri tahmin edilecek veriye yakınlıklarıyla doğru orantılı olacak şekilde artan bir tahmin ağırlığı ile sonucu etkilemektedirler. Yani “uzaklık” yönteminde k adet veri içinde değeri tahmin edilmek istenilen veriye en yakın verinin sonuç üzerindeki ağırlığı diğer verilerden daha fazladır.

Çizelge 7.1 incelendiğinde çeşitli k sayısı parametreleri altında tahmin modelinin hata sonuçlarının ve r kare sonuçlarının değişimi incelenebilir. Görüldüğü gibi k parametresi 1’den başlayıp 15’e kadar kademeli olarak arttırıldığında hata değerleri azalmış ve r kare değerleri artmıştır ancak k parametresi 15 ile 250 arasında kademeli olarak arttırıldığında hata değerleri artmaya ve r kare değerleri azalmaya devam etmişlerdir. Şekil 7.2, Şekil 7.3, Şekil 7.4 ve Şekil 7.5 incelendiğinde çeşitli k sayısı

parametrelerinin ve metrik parametrelerinin hata sonuçları ve r kare sonuçları görülebilir. Ayrıca Şekil 7.6, Şekil 7.7, Şekil 7.8 ve Şekil 7.9 incelendiğinde çeşitli k sayısı parametrelerinin ve ağırlık parametrelerinin hata sonuçları ve r kare sonuçları görülebilir.


Çizelge 7.1 : K Sayısının Algoritma Başarı Ölçüm Kriterlerine Göre Etkileri.

K Sayısı	Ortalama Mutlak Hata (MAE)	Ortalama Hataların Karesi (MSE)	Ortalama Hataların Karekökü (RMSE)	R-Kare
1	0.0680591	0.0105751	0.1028354	0.9851228
10	0.0521868	0.0061742	0.0785761	0.9913140
50	0.056666	0.0076276	0.0873362	0.9892694
100	0.0656743	0.0111382	0.1055378	0.9843306
150	0.0737998	0.0146040	0.12084702	0.97945498
200	0.0812382	0.0177173	0.13310634	0.97507517
250	0.08788694	0.020462576	0.14304746	0.97121310



Şekil 7.2 : K Sayısı Parametresinin ve Metrik Parametrelerinin RMSE Değerlerine Etkileri.


Şekil 7.2’de çeşitli k sayısı parametresi değerlerinin iki farklı metrik parametresi olan Manhattan ve Öklid uzaklık hesaplama yöntemleri kullanıldığında elde ettikleri ortalama hataların karekökü (RMSE) değerleri incelenebilir. Görüleceği üzere k sayısı parametresi minimum RMSE sonuçlarını 1 ile 15 aralığında almaktadır. K sayısı 15’ten başlayıp kademeli olarak 250’ye kadar arttırıldığında her bir adımda ortalama hataların karekökü (RMSE) değerlerinin arttıkları görülmüştür. Ayrıca her k sayısı değeri için metrik parametrelerinden Manhattan uzaklık hesaplama yönteminin, Öklid uzaklık hesaplama yönteminden daha düşük ortalama hataların karekökü (RMSE) değerlerine sahip olduğu görülebilir. Şekil 7.2 incelendiğinde görüleceği üzere, en küçük ortalama hataların karekökü (RMSE) değeri olan 0.07817 değerine k sayısı parametresinin 15 olduğu noktada metrik parametresinin Manhattan yöntemiyle ulaşılmıştır.



Şekil 7.3 : K Sayısı Parametresinin ve Metrik Parametrelerinin MSE Değerlerine Etkileri.

Çeşitli k sayısı değerlerinin iki farklı metrik parametresi olan Manhattan ve Öklid uzaklık hesaplama yöntemleri kullanıldığında elde ettikleri, bu çalışmanın başarı ölçüm kriterlerinden biri olan ortalama hataların karesi (MSE) değerleri Şekil 7.3’te görselleştirilmiştir. Görselden anlaşılacağı üzere, tıpkı RMSE sonuçlarında olduğu gibi, k sayısı parametresi minimum MSE sonuçlarını 1 ile 15 aralığında almaktadır.


Görsel detaylıca incelendiğinde K sayısı parametresi 15'ten başlayıp kademeli olarak 250'ye kadar arttırıldığında her bir adımda ortalama hataların karesi (MSE) değerlerinin de arttıkları görülmektedir. Ayrıca ek olarak şekil incelendiğinde her k sayısı değeri için metrik parametrelerinden Manhattan uzaklık hesaplama yönteminin, Öklid uzaklık hesaplama yönteminden daha düşük ortalama hataların karesi (MSE) değerlerine sahip olduğu sonucuna varılmıştır. Sonuç olarak, en küçük ortalama hataların karesi (MSE) değeri olan 0.00611 değerine k sayısı parametresi 15 ve metrik parametresi Manhattan olduğunda ulaşılmıştır(Şekil 7.3).



Şekil 7.4 : K Sayısı Parametresinin ve Metrik Parametrelerinin MAE Değerlerine Etkileri.


Çeşitli k sayısı parametrelerinin ve ayrıca Manhattan ve Öklid uzaklık hesaplama yöntemi olmak üzere iki farklı metrik parametresinin bu çalışmanın başarı ölçüm kriterlerinden biri olan ortalama mutlak hata ölçütüne göre sonuçları Şekil 7.4'te incelenebilir. Yukarıdan görüleceği üzere minimum MAE sonuçlarına k sayısı parametresinin 1 ile 15 aralığındaki değerlerinde ulaşılmıştır. Fakat, k sayısı 15'ten başlayıp kademeli olarak 250'ye kadar arttırıldığında her bir adımda ortalama mutlak hata (MAE) değerlerinin arttıkları da gözden kaçmamalıdır. Ayrıca şekil detaylıca

analiz edildiğinde ise, her k sayısı değeri için metrik parametrelerinden Manhattan uzaklık hesaplama yönteminin, Öklid uzaklık hesaplama yönteminden daha düşük ortalama mutlak hata (MAE) değerlerine sahip olduğu sonucuna varılmıştır. Şekil 7.4 incelendiğinde en küçük ortalama hataların karekökü (MAE) değeri olan 0.051857 metrik parametresinin Manhattan ve k sayısı parametresinin ise 15 olduğu konfigürasyonda ulaşıldığı görülmektedir.



Şekil 7.5 : K Sayısı Parametresinin ve Metrik Parametrelerinin R2 Değerlerine Etkisi.

Şekil 7.5' değerlendirildiğinde çeşitli k sayısı parametresi değerlerinin iki farklı metrik parametresi olan Manhattan ve Öklid uzaklık hesaplama yöntemleri kullanıldığında elde ettikleri r kare başarı ölçüm kriteri değerleri görülebilir. K sayısı parametresi maksimum r kare sonuçlarını 1 ile 15 aralığında almaktadır. Görselden elde edilen bir diğer bulgu da, k sayısının 15'ten başlayıp kademeli olarak 250'ye kadar durumda her bir adımda r kare değerinin azaldığıdır. Ayrıca diğer bir önemli bulgu ise, her k sayısı değeri için metrik parametrelerinden Manhattan uzaklık hesaplama yönteminin, Öklid uzaklık hesaplama yönteminden daha yüksek r kare değerlerine sahip olduğudur. Şekil 7.5 üzerine yapılan detaylı incelemenin sonucunda en yüksek r kare değeri olan 0.9914 değerine k sayısının 15 olduğu noktada Manhattan yöntemiyle ulaşılmıştır.



Şekil 7.6 : K Sayısı Parametresinin ve Ağırlık Parametrelerinin RMSE Değerlerine Etkileri.

Şekil 7.6’da çeşitli k sayısı değerlerinin iki farklı ağırlık parametresi olan uzaklık ve eşitlik yöntemleri kullanıldığında elde ettikleri, bu çalışmanın başarı ölçüm kriterlerinden biri olan ortalama hataların karekökü (RMSE) değerleri görselleştirilmiştir. Şekilden anlaşılabacağı üzere k sayısı parametresi minimum RMSE sonuçlarını 1 ile 15 aralığında yakalayabilmiştir. Ek olarak, görsel detaylıca incelendiğinde k sayısı parametresi 15’ten başlayıp kademeli olarak 250’ye kadar artırıldığında her bir adımda ortalama hataların karekökü (RMSE) değerlerinin arttıkları sonucuna varılmıştır. Ayrıca her k sayısı parametresi için ağırlık parametrelerinden uzaklık yönteminin, eşitlik yönteminden daha düşük ortalama hataların karekökü (RMSE) değerlerine sahip olduğu görselden elde edilecek bir diğer önemli bilgidir. Görsel üzerinde yapılan detaylı incelemenin sonucunda en küçük ortalama hataların karekökü (RMSE) değeri olan 0.07817 değerine k sayısı parametresinin 15 olduğu ve ağırlık parametresinin uzaklık yöntemi olduğu konfigürasyonda elde edilmiştir.



Şekil 7.7 : K Sayısı Parametresinin ve Ağırlık Parametrelerinin MSE Değerlerine Etkileri.


Çeşitli k sayısı parametresi değerlerinin iki farklı ağırlık parametresi olan uzaklık ve eşitlik yöntemleri kullanıldığında elde ettikleri ortalama hataların karesi (MSE) değerleri Şekil 7.7’de kolaylıkla incelenebilirler. Minimum ortalama hataların karesi (MSE) sonuçlarına k sayısının 1 ile 15 arasındaki değerlerinde ulaşılmaktadır. Bunun yanı sıra, k sayısı 15’ten başlayıp kademeli olarak 250’ye kadar arttırıldığında her bir adımda (MSE) değerlerinin arttıkları sonucuna varılmıştır. Ayrıca her k sayısı değeri için ağırlık parametrelerinden uzaklık yönteminin, eşitlik yönteminden daha düşük (MSE) değerlerine sahip olduğu kanıtlanmıştır. Şekil 7.7 incelendiğinde en küçük ortalama hataların karesi (MSE) değeri olan 0.00611 değerine k sayısı parametresinin 15 olduğu noktada ağırlık parametresinin uzaklık yöntemiyle ulaşılmıştır.

Çeşitli k sayısı parametrelerinin ve ayrıca uzaklık ve eşitlik yöntemi olmak üzere iki farklı ağırlık parametresinin bu çalışmanın başarı ölçüm kriterlerinden biri olan ortalama mutlak hata ölçütüne göre sonuçları Şekil 7.8’de görselleştirilmiştir. Görüleceği üzere, k sayısı parametresi minimum MAE sonuçlarını 1 ile 15 aralığında elde etmektedir. Bu duruma ek olarak k sayısı 15’ten başlayıp kademeli olarak 250’ye kadar arttırılırsa her bir adımda ortalama mutlak hata (MAE) değerlerinin arttıkları kanıtlanmıştır. Ek olarak ise, her k sayısı değeri için ağırlık parametrelerinden uzaklık

yönteminin, eşitlik yönteminden daha düşük ortalama mutlak hata (MAE) değerlerine sahip olduğu belirlenen bir diğer önemli bulgudur. Şekil 7.8 incelendiğinde en küçük ortalama hataların karekökü (MAE) değeri olan 0.051857 değerine k sayısının 15 olduğu noktada uzaklık yöntemiyle ulaşılmıştır.



Şekil 7.8 : K Sayısı Parametresinin ve Ağırlık Parametrelerinin MAE Değerlerine Etkisi.



Şekil 7.9 : K Sayısı Parametresinin ve Ağırlık Parametrelerinin R2 Değerlerine Etkisi.

Şekil 7.9’ incelendiğinde farklı k sayısı parametresi değerlerinin iki farklı ağırlık parametresi olan uzaklık ve eşitlik yöntemleri kullanıldığında elde ettikleri r kare değerleri görülebilir. Yukarıdaki şekilden k sayısı parametresi maksimum r kare sonuçlarını 1 ile 15 aralığında ulaştığı sonucuna varılmıştır. K sayısı 15’ten başlayıp kademeli olarak 250’ye kadar arttırıldığında ise her bir adımda r kare değerlerinin azaldıkları fark edilen bir diğer önemli bulgu olmuştur. Ayrıca her k sayısı değeri için ağırlık parametrelerinden uzaklık yönteminin, eşitlik yönteminden daha yüksek r kare değerlerine sahip olarak daha başarılı olduğu belirtilmelidir. En yüksek r kare değeri olan 0.9914 değerine k sayısının 15 olduğu noktada uzaklık yöntemiyle ulaşılmıştır(Şekil 7.9).

Şekil 7.2, Şekil 7.3, Şekil 7.4, Şekil 7.5, Şekil 7.6, Şekil 7.7, Şekil 7.8 ve Şekil 7.9 incelendiklerinde k sayısı parametresi ile MAE, MSE, RMSE değerlerinin doğru, r kare değerlerinin ters orantılı olarak değiştiği görülmektedir. Ayrıca Manhattan yönteminin Öklid yöntemine kıyasla, ve uzaklık yönteminin ise eşitlik yöntemine kıyasla daha düşük MAE, MSE, RMSE ve daha yüksek r kare değerlerine sahip olarak daha başarılı tahminlerde bulundukları görülmüştür. Yapılan hiper parametre düzenleme işlemi sonrasında KEK algoritmasının en başarılı tahmin sonuçlarına ulaştığı kombinasyon Çizelge 7.2’de incelenebilir.

Çizelge 7.2 : KEK Algoritmasının En Başarılı Tahmin Sonuçlarına Ulaştığı Hiper Parametreler.


K Sayısı	Uzaklık Hesaplama Yöntemi	Ağırlık Yöntemi
15	Manhattan	Uzaklık

Çizelge 7.3 incelendiğinde sırasıyla “15”, “Manhattan”, “Uzaklık” hiper parametreleri ile tahmin yaptırılmış en başarılı KEK algoritması temelli tahmin modelinin ortalama mutlak hata (MAE), ortalama hataların karesi(MSE), ortalama hataların karekökü(RMSE) ve r kare gibi başarı ölçüm kriterleri sonuçları görülebilir.

Çizelge 7.3 : KEK Algoritması Temelli Modelin Tahmin Başarısı.


Başarı Ölçüm Kriterleri	Sonuçlar
Ortalama Mutlak Hata (MAE)	0.05185
Ortalama Hataların Karesi (MSE)	0.00611
Ortalama Hataların Karekökü (RMSE)	0.07817
R Kare	0.99140

Çizelge 7.3 incelendiğinde k sayısı olarak 15, uzaklık hesaplama yöntemi olarak Manhattan ve ağırlık yöntemi olarak uzaklık hiper parametreleri düzenlenmiş KEK algoritması temelli modelinin tahmin başarısı görülmektedir. Çizelge 7.3 detaylıca incelendiğinde, KEK algoritması temelli tahmin modelinin 0.05185 ortalama mutlak hata, 0.00611 ortalama hataların karesi, 0.07817 ortalama hataların karekökü değerleri ile %99.14'lük doğrulukta tahminlerde bulunduğu görülebilir.




Şekil 7.10 : KEK Algoritması Temelli Modelin Tahmin Sonuçları-1.

Şekil 7.10 incelendiğinde KEK algoritması temelli modelin tahmin sonuçlarının rüzgâr türbininin çeşitli rüzgâr hızlarında ürettiği güç verileri ve rüzgâr türbininin çeşitli rüzgâr hızlarında teorik olarak üretebileceği güç verilerine göre dağılımı görülebilir. Görselde siyah noktalar çeşitli rüzgâr hızlarında rüzgâr türbininin gerçekte ürettiği güç değerlerini, yeşil noktalar çeşitli rüzgâr hızlarında rüzgâr türbininin teorik olarak üretebileceği güç değerlerini ve kırmızı noktalar ise KEK temelli tahmin algoritmasının çeşitli rüzgâr hızlarında tahmin ettiği üretilebilecek güç değerlerini ifade etmektedir. Şekil 7.10 incelendiğinde tahmin değerlerinin başarılı bir şekilde üretilen güç değerleriyle eşleştiği görülmektedir. Veri gizliliği sebebiyle güç değerleri birimsiz ve boyutsuz olarak sunulmuştur.



Şekil 7.11 : KEK Algoritması Temelli Modelin Tahmin Sonuçları-2.

KEK algoritması temelli makine öğrenmesi modelinin tahmin ettiği üretilebilecek güç değerlerinin rüzgâr türbininin ürettiği güç değerlerine göre dağılımı Şekil 7.11’ de görülebilir. Görselden anlaşılabacağı üzere KEK algoritması temelli makine öğrenmesi modelinin tahmin sonuçlarının gerçekte üretilmiş güç değerleri ile yüksek doğrulukta eşleşmiştir.



Şekil 7.12 : KEK Algoritması Temelli Modelin Tahmin Sonuçları-3.

Şekil 7.12’de rüzgâr türbininin aylık ortalama ürettiği güç değerleri ile KEK algoritması temelli makine öğrenmesi modelinin aylık ortalama üretilebilecek güç değerleri tahminleri kullanılarak ortalama güç eğrileri oluşturulmuştur KEK algoritması temelli makine öğrenmesi modeli yüksek bir doğrulukla gerçekte üretilmiş ortalama güç değerlerine yakın sonuçlar elde etmiştir.


Çizelge 7.4 : Ay Bazlı Üretilen Ortalama Güçler ve KEK Temelli Modelin Tahmin Ettiği Ortalama Güçler.

Aylar	Gerçekte Üretilen Ortalama Güçler	KEK Modelinin Tahmin Ettiği Ortalama Güçler
Ocak	1.397183	1.362683
Şubat	1.381640	1.332809
Mart	1.626527	1.611460
Nisan	0.904909	0.917021
Mayıs	0.780199	0.791566
Haziran	0.937986	0.961720
Temmuz	0.458805	0.489760
Ağustos	1.428677	1.457731
Eylül	1.179781	1.181456
Ekim	1.071986	1.068315
Kasım	1.401421	1.374591
Aralık	1.423192	1.382032

Çizelge 7.4 incelendiğinde aylık bazda ortalama üretilen güç değerleri ile o değerlere karşılık gelen KEK algoritması temelli makine öğrenmesi modelinin tahmin ettiği ortalama üretilebilecek güç değerleri görülebilir. Veri gizliliği nedeniyle güç değerleri boyutsuz ve birimsiz olarak verilmiştir.

7.1.2. Rastgele orman algoritması temelli modelin (RSO) tahmin sonuçları

Çalışma kapsamında kullanılan diğer bir makine öğrenmesi modeli, temelleri 1990’lı yıllarda Çinli bilgisayar bilimci Tin Kam Ho tarafından atılan ve 2000’li yıllarda istatistik bilimcisi Leo Breiman tarafından geliştirilen rastgele orman algoritması temelli modeldir[94]. Rastgele orman algoritması makine öğrenmesi kuramının denetimli öğrenme sınıfının, topluluk öğrenmesi gurubunun ve torbalama yöntemi alt kümesine kayıtlı en temel tahmin ve sınıflandırma algoritmalarındandır. Bu çalışma için geliştirilmiş rastgele orman algoritması temelli modelin çalışma mekaniği kısaca aşağıdaki adımlardan oluşturulmuştur.



Şekil 7.13 : RSO Algoritması İçin Tasarlanan Model.


Rastgele orman algoritması birbirlerinden bağımsız şekilde tahminlerde bulunan karar ağaçlarından oluşan topluluk öğrenmesi algoritmalarındandır. Rastgele orman algoritması kullanılan tahmin modellerinin başarılı tahminlerde bulunabilmeleri için rastgele orman algoritmasının üç önemli parametresinin mutlaka düzenlenmesi gerekmektedir. Rastgele orman algoritmasının tahmin başarısını doğrudan katastrofik bir şekilde etkileyen parametrelerden ilki tahmin edici sayısı parametresidir. Tahmin edici sayısı parametresi rastgele orman algoritmasında kullanılacak olan karar ağacı sayısını ve doğal olarak veri setinin bölüneceği alt veri seti kümesi sayısını belirleyen parametredir. Bu çalışmada veri setindeki örneklem sayıları ve literatürde yapılmış çalışmalar göz önünde bulundurularak makine öğrenmesi modelinin tahmin doğruluğunu arttırmak adına rastgele orman algoritmasındaki karar ağacı sayısı 100 ile 150 arasındaki tamsayı değerleriyle sınanmış ve en düşük RMSE, MSE, MAE, ve en yüksek r kare değerlerine sahip olan tahmin edici sayısı tespit edilmeye çalışılmıştır.

Rastgele orman algoritması temelli tahmin modelinin performansını arttırmak adına düzenlenen bir diğer önemli parametre ise kök hücrelerden yaprak hücrelere doğru olacak dallanmada en iyi ayrımın yapılabilmesi için kullanılacak maksimum öznelilik sayısının belirlendiği özellik parametresidir. Bu çalışmada maksimum doğrulukta tahmin performansına ulaşabilmek adına özellik parametresi için otomatik, logaritmik ve karekök yöntemleri uygulanarak en iyi dallanma ya da başka bir deyişle en iyi ayrım

oluşturulmaya çalışılmıştır. En iyi ayrımın oluşturulması için belirlenecek maksimum özellik sayısı, otomatik yöntemde veri setindeki öznitelik sayısı kadar, logaritmik yöntemde veri setindeki öznitelik sayısının log2 tabanındaki karşılıkları kadar, karekök yönteminde de veri seti içerisindeki öznitelik sayısının karekökü kadar olacak şekilde işlem yapılır. Bu çalışmada en iyi ayrım sonuçlarına ulaşip en yüksek doğrulukta tahmin performansını yakalamak adına maksimum özelliğin belirlenmesi için özellik parametresi olarak otomatik yöntem, logaritmik yöntem ve karekök yöntemi sınanmış ve en başarılı sonucu veren özellik parametresi bulunmaya çalışılmıştır.


Rastgele orman algoritması temelli tahmin modellerinin tahmin başarılarını etkileyecek diğer bir önemli parametre ise derinlik sayısı parametresidir. Derinlik sayısı karar ağacının kök hücresinden başlayarak en son kademe olan yaprak hücresine kadar gidilecek en uzun yolu ifade etmektedir. Bu çalışmada veri setinin boyutu düşünülerek derinlik sayısı 1 ile 10 arasında değişen tam sayı değerleri kullanılıp maksimum doğrulukta tahmin performansına ulaşılmaya çalışılmıştır.

Şekil 7.14, Şekil 7.15 incelendiklerinde karar ağacı sayısını belirleyen tahmin edici sayısı parametresinin ve en iyi ayrımın yapılması için maksimum özellik sayısını belirleyen özellik parametresinin ortalama hataların karekökü (RMSE) ve ortalama hataların karesi (MSE) değerleri üzerindeki etkileri görülebilir.



Şekil 7.14 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.

Şekil 7.14 incelendiğinde çeşitli tahmin edici sayısı parametresi değerlerine ve çeşitli özellik parametresi yöntemlerine göre geliştirilen tahmin modelinin ortalama hataların karekökü (RMSE) sonuçları görülebilir. 100 ile 150 arasında değişen tahmin edici sayısı parametreleri incelendiğinde en düşük ortalama hataların karekökü (RMSE) sonucuna tahmin edici sayısının 125 olduğu noktada ulaşılmıştır. Ayrıca görsel detaylıca incelendiğinde, özellik parametreleri arasında otomatik yöntemin logaritmik ve karekök yöntemlerine kıyasla daha yüksek ortalama hataların karekökü (RMSE) değerlerine sahip olduğu, logaritmik ve karekök yöntemlerinin çeşitli tahmin edici sayılarında birbirlerine çok yakın ortalama hataların karekökü (RMSE) değerlerine sahip oldukları belirlenmiştir. Şekil 7.14 incelendiğinde en düşük ortalama hataların karekökü (RMSE) sonucu olan 0.0733'lük değere tahmin edici sayısı parametresinin 125 ve özellik parametresinin karekök yöntemi kombinasyonları ile ulaşılmıştır.




Şekil 7.15 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.

Çeşitli tahmin edici sayısı parametreleri ve özellik parametrelerinin ortalama hataların karesi (MSE) sonuçlarının görüldüğü Şekil 7.15'te tahmin edici sayısı parametresi 100 ile 150 arasında birer birer artırılmıştır. Bir diğer parametre olan özellik parametresi ise otomatik yöntem, logaritmik yöntem ve karekök yöntemi olarak denenmektedir. Değişen tahmin edici sayısı parametreleri incelendiğinde ortalama hataların karesi sonuçları göz önünde bulundurulduğunda en başarılı sonuca tahmin edici sayısı parametresinin 125 olduğu noktada ulaşılmıştır. Ek olarak, görselden görüleceği gibi

özellik parametrelerinden olan otomatik yöntemin ortalama hataların karesi (MSE) sonuçları diğer yöntemler olan karekök yöntemi ve logaritmik yönteme kıyasla daha büyüktür. Ayrıca, özellik parametreleri olan karekök yöntemi ve logaritmik yöntemin çeşitli tahmin edici sayısı parametrelerinde birbirlerine yakın sonuçlar elde ettiklerini belirtmek gerekir. En küçük ortalama hataların karesi (MSE) değeri olan 0.005384 değerine tahmin edici sayısının 125, özellik parametresinin karekök yöntemi olduğu kombinasyonda ulaşılmıştır.


Şekil 7.16 - Şekil 7.19 incelendiklerinde karar ağacı sayısını belirleyen tahmin edici sayısı parametresinin ve kök hücreden yaprak hücrelere uzanan en uzun yolu belirleyen derinlik parametresinin başarı ölçüm kriterleri olan (RMSE), (MSE), (MAE) ve r kare değerleri üzerindeki etkileri görülebilir.



Şekil 7.16 : Derinlik Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.

Şekil 7.16 incelendiğinde çeşitli derinlik parametresi değerlerine ve çeşitli özellik parametresi yöntemlerine göre geliştirilen tahmin modelinin ortalama hataların karekökü (RMSE) sonuçları görülmektedir. 1 ile 10 arasında değişen derinlik parametreleri incelendiğinde en düşük ortalama hataların karekökü (RMSE) sonucuna derinliğin 10 olduğu noktada ulaşılmıştır. Ayrıca, özellik parametreleri arasında otomatik yöntemin derinliğin 6 olduğu noktaya kadar logaritmik ve karekök yöntemlerine kıyasla daha düşük ortalama hataların karekökü (RMSE) değerlerine


sahip olduğu, logaritmik ve karekök yöntemlerinin tüm derinliklerde birbirlerine çok yakın ortalama hataların karekökü (RMSE) değerlerine sahip oldukları belirtilmelidir. Şekil 7.16 incelendiğinde en düşük ortalama hataların karekökü (RMSE) sonucu olan 0.0733'lük değere derinlik parametresinin 10 özellik parametresinin karekök yöntemi olduğu kombinasyonla ulaşılmıştır.



Şekil 7.17 : Derinlik Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.


Çeşitli derinlik parametreleri ve özellik parametreleri koşullarında rastgele orman algoritması temelli modelin ortalama hataların karesi (MSE) sonuçlarının görüldüğü Şekil 7.17’de derinlik parametresi 1 ile 10 arasındaki tam sayılar kullanılacak şekilde değiştirilmiştir. Bu şartlar altında özellik parametresi ise, otomatik yöntem, logaritmik yöntem ve karekök yöntemi olacak şekilde farklı değerler olarak denlenmektedir. Değişen derinlik parametreleri incelendiğinde ortalama hataların karesi sonuçları göz önünde bulundurulduğunda en başarılı sonuca derinlik parametresinin 10 olduğu noktada ulaşılmıştır. Şekil detaylıca incelendiğinde görüleceği üzere özellik parametrelerinden olan otomatik yöntemin ortalama hataların karesi (MSE) sonuçları, derinlik değerinin 6 olduğu noktaya kadar diğer yöntemler olan karekök yöntemi ve logaritmik yönteme kıyasla daha küçüktür. Ayrıca özellik parametreleri olan karekök yöntemi ve logaritmik yöntemin çeşitli derinlik parametrelerinde birbirlerine yakın

sonular elde ettiklerini belirtmek gerekir. Őekil 7.17 incelendiĐinde en kk ortalama hataların karesi (MSE) deĐeri olan 0.005384 deĐerine derinliĐin 10 olduĐu noktada karekk yntemiyle ulaşıldıĐı sonucuna varılmıřtır.



Őekil 7.18 : Derinlik Parametresinin ve zellik Parametrelerinin MAE DeĐerlerine Etkileri.

Farklı derinlik parametresi deĐerlerine ve eřitli zellik parametresi yntemlerine gre geliřtirilen tahmin modelinin incelendiĐi Őekil 7.18’de ortalama mutlak hata (MAE) sonuları grselleřtirilmiřtir. 1 ile 10 arasında deĐiřen derinlik parametreleri incelendiĐinde, en dřk ortalama mutlak hata (MAE) sonucuna derinliĐin 10 olduĐu noktada ulařılmıřtır. Ayrıca, zellik parametreleri arasında otomatik yntemin derinliĐin 6 olduĐu noktaya kadar logaritmik ve karekk yntemlerine kıyasla daha dřk ortalama mutlak hata (MAE) deĐerlerine sahip olduĐu, logaritmik ve karekk yntemlerinin eřitli derinliklerde birbirlerine ok yakın ortalama mutlak hata (MAE) deĐerlerine sahip oldukları belirlenene diĐer bir nemli tespittir. Őekil 7.18 incelendiĐinde en dřk ortalama mutlak hata (MAE) sonucu olan 0.04935’lik sonuca derinlik parametresinin 10 zellik parametresinin karekk yntemi olduĐu noktada ulařılmıřtır.



Şekil 7.19 : Derinlik Parametresinin ve Özellik Parametrelerinin R^2 Değerlerine Etkileri.

Farklı derinlik parametreleri ve özellik parametrelerinin r-kare sonuçlarının görüldüğü Şekil 7.19’da derinlik parametresi 1 ile 10 arasında birer birer artmaktadır ve özellik parametresi olarak da otomatik yöntem, logaritmik yöntem ve karekök yöntemi denenmektedir. Değişen derinlik parametreleri incelendiğinde görüleceği üzere r-kare sonuçları göz önünde bulundurulduğunda en başarılı sonuca derinlik parametresinin 10 olduğu noktada ulaşılmıştır. Ek olarak, şekil detaylıca incelendiğinde görüleceği üzere özellik parametrelerinden olan otomatik yöntemin r kare sonuçları, derinlik değerinin 6 olduğu noktaya kadar diğer yöntemler olan karekök yöntemi ve logaritmik yöntemle kıyasla daha yüksektir. Ayrıca özellik parametreleri olan karekök yöntemi ve logaritmik yöntemin çeşitli derinlik parametrelerinde birbirlerine yakın sonuçlar elde ettiklerini vurgulamak gerekir. Şekil 7.19 incelendiğinde en yüksek r kare değeri olan 0.9924 değerine derinliğin 10 olduğu noktada karekök yöntemiyle ulaşılmıştır.

Şekil 7.14’te, Şekil 7.15’te, Şekil 7.16’da, Şekil 7.17’de, Şekil 7.18’de ve Şekil 7.19’da görselleştirilen rastgele orman algoritması temelli modelin hiper parametrelerinin düzenlenmesi işleminden sonra rastgele orman algoritması temelli tahmin modelinin en düşük (MSE), (RMSE),(MAE) değerlerine ve en yüksek r kare değerine sahip olduğu hiper parametre kombinasyonu Çizelge 7.5’ te gösterilmiştir.

Çizelge 7.5 : Rastgele Orman Algoritması Temelli Tahmin Modelinin En Başarılı Sonuçlara Ulaştığı Hiper Parametreler.


Tahmin Edici Sayısı Parametresi	Özellik Parametresi	Derinlik Parametresi
125	Karekök Yöntemi	10

Çizelge 7.5’te sunulan rastgele orman algoritması temelli tahmin modelinin en başarılı sonuçlara ulaşabileceği hiper parametre kombinasyonunun veri seti üzerine uygulandığında rastgele orman algoritması temelli modelin elde ettiği başarı ölçüm kriteri sonuçları Çizelge 7.6’da incelenebilir.

Çizelge 7.6 : Hiper Parametreleri Ayarlanmış Rastgele Orman Algoritması Temelli Tahmin Modelinin Tahmin Performansı.


Başarı Ölçüm Kriteri	Sonuçlar
Ortalama Mutlak Hata (MAE)	0.0493539449
Ortalama Hataların Karesi (MSE)	0.0053841355
Ortalama Hataların Karekökü (RMSE)	0.0733766693
R-Kare	0.9924255605

Çizelge 7.6 incelendiğinde tahmin edici sayısı parametresi 125, özellik parametresi karekök yöntemi, derinlik parametresi 10 olan rastgele orman temelli tahmin modeli 0.004933’lük ortalama mutlak hata, 0.005384’lük ortalama hataların karesi, 0.073376’lık ortalama hataların karekökü sonuçlarıyla %99.242556’lık doğrulukta tahminler yapmaktadır.




Şekil 7.20 : RSO Algoritması Temelli Modelin Tahmin Sonuçları-1.

Şekil 7.20 incelendiğinde RSO algoritması temelli modelin tahmin sonuçlarının rüzgâr türbininin çeşitli rüzgâr hızlarında ürettiği güç verileri ve rüzgâr türbininin çeşitli rüzgâr hızlarında teorik olarak üretebileceği güç verilerine göre dağılımı görülebilir. Görselde siyah noktalar çeşitli rüzgâr hızlarında rüzgâr türbininin gerçekte ürettiği güç değerlerini, yeşil noktalar çeşitli rüzgâr hızlarında rüzgâr türbininin teorik olarak üretebileceği güç değerlerini ve kırmızı noktalar ise RSO temelli tahmin algoritmasının çeşitli rüzgâr hızlarında tahmin ettiği üretilebilecek güç değerlerini ifade etmektedir. Şekil 7.20 incelendiğinde tahmin değerlerinin başarılı bir şekilde üretilen güç değerleriyle eşleştiği görülmektedir. Veri gizliliği sebebiyle güç değerleri birimsiz ve boyutsuz olarak kullanılmıştır.



Şekil 7.21 : RSO Algoritması Temelli Modelin Tahmin Sonuçları-2.

Şekil 7.21 incelendiğinde RSO algoritması temelli makine öğrenmesi modelinin tahmin ettiği üretilebilecek güç değerlerinin rüzgâr türbininin ürettiği güç değerlerine göre dağılımı görülebilir. RSO algoritması temelli makine öğrenmesi modeli 0.07337666'lık ortalama hataların karekökü (RMSE) değeriyle veri setinin %99.24'lük kısmını temsil edebilmektedir(Şekil 7.21). Bu sonuçlara dayanarak tahmin sonuçlarının gerçekte üretilmiş güç değerleri ile yüksek doğrulukta eşleştiği söylenebilir.



Şekil 7.22 : RSO Algoritması Temelli Modelin Tahmin Sonuçları-3.


Şekil 7.22’de rüzgâr türbininin aylık ortalama ürettiği güç değerleri ile RSO algoritması temelli makine öğrenmesi modelinin aylık ortalama üretilebilecek güç tahmini değerleri kullanılarak ortalama güç eğrileri oluşturulmuştur. RSO algoritması temelli makine öğrenmesi modeli yüksek bir doğrulukla gerçekte üretilmiş ortalama güç değerlerini tahmin etmiştir(Şekil 7.22).

Çizelge 7.7 : Ay Bazlı Üretilen Ortalama Güçler ve RSO Temelli Modelin Tahmin Ettiği Ay Bazlı Ortalama Güçler.

Aylar	Gerçekte Üretilen Ortalama Güçler	RSO Modelinin Tahmin Ettiği Ortalama Güçler
Ocak	1.397183	1.362889
Şubat	1.381640	1.337865
Mart	1.626527	1.618036
Nisan	0.904909	0.916477
Mayıs	0.780199	0.794703
Haziran	0.937986	0.965278
Temmuz	0.458805	0.491595
Ağustos	1.428677	1.459584
Eylül	1.179781	1.183214
Ekim	1.071986	1.070035
Kasım	1.401421	1.376176
Aralık	1.423192	1.388489

7.1.3. Ekstra ağaç algoritması (ETA) temelli modelin tahmin sonuçları

Ekstra ağaç algoritması makine öğrenmesinin topluluk öğrenmesi sınıfına dahil olan ve denetimli öğrenme mekanizmalarıyla çalışan temel bir sınıflandırma ve regresyon algoritmasıdır (Şekil 7.23). Ekstra ağaç algoritması tıpkı atası olan rastgele orman algoritmasında olduğu gibi birbirlerinden bağımsız şekilde eğitilen karar ağaçları kullanarak tahminlerde bulunur. Ekstra ağaç algoritmasının rastgele orman algoritmasından en temel farkı düğüm noktalarındaki ayrışmaların rastgele özellikler kullanılarak yapılıyor olmasıdır. Bu sayede her bir karar ağacı birbirinden çok farklı dallanmalara sahip olabileceklerdir. Ekstra ağaç algoritmasının regresyon ya da sınıflandırma tahmini başarısını arttırmak adına çeşitli hiper parametrelerinin düzenlenmesi gerekmektedir. Literatürde yapılan çalışılarda da kanıtlandığı üzere ekstra ağaç algoritmasının tahmin başarısını arttırmak için üç önemli parametrenin çalışılan proje özelliklerine göre düzenlenmesi gerekmektedir. Bu hiper parametreler sırasıyla tahmin edici sayısı parametresi, özellik parametresi ve derinlik parametresidir.



Şekil 7.23 : ETA Algoritması İçin Tasarlanan Model.

Bu çalışmada ekstra ağaç temelli tahmin modelinin tahmin performansının artırılması için yapılan ilk düzenleme tahmin edici sayısı parametresi üzerinde olmuştur. Tahmin edici sayısı parametresi 100 ile 150 arasındaki tam sayılar olacak şekilde denenmiş ve


en düşük ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve en yüksek r kare sonuçlarını veren tahmin edici sayısı bulunmaya çalışılmıştır.

Bu çalışma kapsamında, ekstra ağaç algoritması temelli makine öğrenmesi tahmin modelinin düzenlenen bir diğer parametresi ise düğüm noktalarında veri setini ayırmaya yarayan özellik parametresidir. Özellik parametresi yöntemleri kullanılarak düğüm noktalarında veri setini ayırabilmek için en fazla kaç adet veri seti özneliği kullanılacağı hesaplanır. Bu çalışmada özellik parametreleri olarak otomatik yöntem, logaritmik yöntem ve karekök yöntemi kullanılmıştır. Otomatik yöntemde düğüm noktalarında veri seti öznelikleri sayısı kadar özneliğe bakılarak ayırım gerçekleştirilir. Logaritmik yöntemde ise veri seti öznelikleri sayısının $\log_2$ tabanındaki karşılığına bakılarak maksimum özellik sayısı belirlenir. Karekök yönteminde ise her bir düğüm noktasında ayırım için kullanılacak maksimum özellik sayısını belirlemek için veri seti içerisindeki öznelik sayısının karekökü kullanılır.

Bu çalışmada ekstra ağaç algoritması temelli tahmin modelin tahmin başarısının artırılması için düzenlenen son hiper parametre derinlik parametresidir. Derinlik parametresi her bir bağımsız karar ağacının kök hücresinden yaprak hücrelerine kadar uzanacak olan en uzun yolu ifade etmektedir. Derinlik parametresinin belirlenmesi için 1 ile 10 arasındaki tam sayı değerleri kullanılarak tahmin modelinin ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve r kare değerlerine bakılmıştır.


Kısaca ekstra ağaç algoritması temelli makine öğrenmesi tahmin modelinin tahmin edici sayısı parametresi, özellik parametresi ve derinlik parametresi çeşitli değerlerle denenmiş ve en düşük ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve r kare sonuçlarına bakılmıştır.

Şekil 7.24, Şekil 7.25, Şekil 7.26 ve Şekil 7.27 incelendiklerinde karar ağacı sayısını belirleyen tahmin edici sayısı parametresinin ve en iyi ayırımın yapılması için maksimum özellik sayısını belirleyen özellik parametresinin ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve r kare değerleri üzerindeki etkileri görülebilir.




Şekil 7.24 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.

Şekil 7.24’te farklı tahmin edici sayısı parametresi değerlerine ve farklı özellik parametresi yöntemlerine göre geliştirilen ekstra ağaç temelli tahmin modelinin ortalama hataların karekökü (RMSE) sonuçları görülmektedir. 100 ile 150 arasında değişen tahmin edici sayısı parametreleri incelendiğinde en düşük ortalama hataların karekökü (RMSE) sonucuna tahmin edici sayısının 124 olduğu noktada ulaşıldığı görülmektedir. Ek olarak, görüleceği gibi özellik parametreleri arasında otomatik yöntemin logaritmik ve karekök yöntemlerine kıyasla daha düşük ortalama hataların karekökü (RMSE) değerlerine sahip olduğu, logaritmik ve karekök yöntemlerinin çeşitli tahmin edici sayılarında birbirlerine yakın ortalama hataların karekökü (RMSE) değerlerine sahip oldukları belirlenmiştir. En düşük ortalama hataların karekökü (RMSE) sonucu olan 0.0765’lik sonuca tahmin edici sayısı parametresinin 124 ve özellik parametresinin otomatik yöntem olduğu durumda ulaşılmıştır.




Şekil 7.25 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.

Çeşitli tahmin edici sayısı parametreleri ve özellik parametrelerinin ortalama hataların karesi (MSE) sonuçlarının görüldüğü Şekil 7.25'te tahmin edici sayısı parametresi 100 ile 150 arasındaki tam sayılar olarak test edilmiştir. Düğüm noktalarındaki ayrımı etkileyen özellik parametresi ise otomatik yöntem, logaritmik yöntem ve karekök yöntemi olacak şekilde üç farklı kombinasyonda sınanmıştır. Değişen tahmin edici sayısı parametreleri incelendiğinde ortalama hataların karesi sonuçları göz önünde bulundurulursa, en başarılı sonuca tahmin edici sayısı parametresinin 124 olduğu noktada ulaşılacağı görülmektedir. Ek olarak, görsel detaylıca incelendiğinde görüleceği üzere, özellik parametrelerinden olan otomatik yöntemin ortalama hataların karesi (MSE) sonuçları diğer yöntemler olan karekök yöntemi ve logaritmik yöntemle kıyasla daha düşüktür. Ayrıca, özellik parametreleri olan karekök yöntemi ve logaritmik yöntemin çeşitli tahmin edici sayısı parametrelerinde birbirlerine yakın sonuçlar elde ettiklerini belirtmek gerekir. Şekil 7.25 incelendiğinde en küçük ortalama hataların karesi (MSE) değeri olan 0.005859 değerine tahmin edici sayısı parametresinin 124, özellik parametresinin ise otomatik yöntem olduğu kombinasyonunda erişilmiştir.



Şekil 7.26 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin MAE Değerlerine Etkileri.


Farklı tahmin edici sayısı parametresi değerlerine ve çeşitli özellik parametresi yöntemlerine göre geliştirilen tahmin modelinin ortalama mutlak hata (MAE) sonuçları Şekil 7.26’da görselleştirilmiştir. Tahmin edici sayısı parametresi 100 ile 150 arasında değişirken en düşük ortalama mutlak hata (MAE) sonucuna tahmin edici sayısı parametresinin 124 olduğu noktada ulaşılmaktadır. Ayrıca, özellik parametreleri arasında otomatik yöntemin logaritmik ve karekök yöntemlerine kıyasla daha düşük ortalama mutlak hata (MAE) değerlerine sahip olduğu, ve logaritmik ve karekök yöntemlerinin ise çeşitli tahmin edici sayısı parametrelerinde birbirlerine yakın ortalama mutlak hata (MAE) değerlerine sahip oldukları sonucuna varılmıştır. Şekil 7.26 incelendiğinde görüleceği gibi, en düşük ortalama mutlak hata (MAE) sonucu olan 0.0517616’lık değere tahmin edici sayısı parametresinin 124, özellik parametresinin ise otomatik yöntem olduğu koşullarda ulaşılmaktadır.



Şekil 7.27 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin R^2 Değerlerine Etkileri.


Farklı tahmin edici sayısı parametreleri ve özellik parametrelerinin r kare sonuçlarının görüldüğü Şekil 7.27’de tahmin edici sayısı parametresi 100 ile 150 arasında birer birer artmaktadır ve özellik parametresi olarak da otomatik yöntem, logaritmik yöntem ve karekök yöntemi test edilmektedir. Değişen tahmin edici sayısı parametreleri incelendiğinde r kare sonuçları göz önünde bulundurulursa, en yüksek r kare sonucu tahmin edici sayısı parametresinin 124 olduğu noktada elde edilmektedir. Ek olarak, şekil üzerinde yapılan incelemede özellik parametrelerinden olan otomatik yöntemin r kare sonuçlarının diğer yöntemler olan karekök yöntemi ve logaritmik yöntemle kıyasla daha yüksek olduğu saptanmaktadır. Ayrıca, özellik parametreleri olan karekök yöntemi ve logaritmik yöntemin çeşitli tahmin edici sayısı parametrelerinde birbirlerine yakın sonuçlar elde ettikleri tespit edilmiştir. En yüksek r kare değeri olan 0.991757’lik sonuca tahmin edici sayısı parametresinin 124, özellik parametresinin otomatik yöntem olduğu kombinasyonda ulaşılmıştır.

Şekil 7.28, Şekil 7.29, Şekil 7.30 ve Şekil 7.31 incelendiklerinde kök hücreden yaprak hücreye uzanan en uzun yolu belirleyen derinlik parametresinin ve en iyi ayrımın yapılması için maksimum özellik sayısını belirleyen özellik parametresinin başarı ölçüm kriterleri olan ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve r kare sonuçları üzerindeki etkileri görülebilir.




Şekil 7.28 : Derinlik Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.

Şekil 7.28’de çeşitli derinlik parametresi değerlerine ve çeşitli özellik parametresi yöntemlerine göre geliştirilen ekstra ağaç algoritması temelli tahmin modelinin ortalama hataların karekökü (RMSE) sonuçları incelenebilir. Derinlik parametreleri 1 ile 10 arasında değişmektedirler. En düşük ortalama hataların karekökü (RMSE) sonucuna derinliğin 10 olduğu noktada ulaşıldığı tespit edilmiştir. Ek olarak, görsel detaylıca incelendiğinde görüleceği üzere, özellik parametreleri arasında otomatik yöntemin derinlik parametresinin tüm değerlerinde logaritmik ve karekök yöntemlerine kıyasla daha düşük ortalama hataların karekökü (RMSE) değerlerine sahip olduğu sonucuna varılmıştır. Ayrıca, logaritmik ve karekök yöntemlerinin çeşitli derinliklerde birbirlerine çok yakın ortalama hataların karekökü (RMSE) değerlerine sahip olduklarını tespit edilen bir diğer önemli bulgudur. Sonuç olarak, en düşük ortalama hataların karekökü (RMSE) sonucu olan 0.076545’lik değere derinlik parametresinin 10, özellik parametresinin otomatik yöntem olduğu kombinasyonda ulaşıldığı tespit edilmiştir.




Şekil 7.29 : Derinlik Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.

Çeşitli derinlik parametreleri ve özellik parametrelerinin ortalama hataların karesi (MSE) sonuçlarının görüldüğü Şekil 7.29’da derinlik parametresi 1 ile 10 arasında değerler almaktadır. Özellik parametresi olarak da otomatik yöntem, logaritmik yöntem ve karekök yöntemi test edilmektedir. Değişen derinlik parametreleri incelendiğinde ortalama hataların karesi sonuçları göz önünde bulundurulursa, en başarılı sonuca derinlik parametresinin 10 olduğu noktada ulaşılmıştır. Ek olarak, özellik parametrelerinden olan otomatik yöntemin ortalama hataların karesi (MSE) sonuçları, derinlik değerinin tüm noktalarında diğer yöntemler olan karekök yöntemi ve logaritmik yöntemle kıyasla daha küçüktür. Ayrıca özellik parametreleri olan karekök yöntemi ve logaritmik yöntemin çeşitli derinlik parametrelerinde birbirlerine yakın sonuçlar elde ettikleri sonucuna varılmıştır. Şekil 7.29 incelendiğinde en küçük ortalama hataların karesi (MSE) değeri olan 0.005859 sonucuna derinliğin 10 olduğu noktada otomatik yöntemle ulaşılmıştır.



Şekil 7.30 : Derinlik Parametresinin ve Özellik Parametrelerinin MAE Değerlerine Etkileri.

Şekil 7.30’da çeşitli derinlik parametresi değerlerine ve çeşitli özellik parametresi yöntemlerine göre geliştirilen ekstra ağaç algoritması temelli tahmin modelinin ortalama mutlak hata (MAE) sonuçları görselleştirilmiştir. 1 ile 10 arasında değişen derinlik parametreleri incelendiğinde en düşük ortalama mutlak hata (MAE) sonucuna derinliğin 10 olduğu noktada ulaşılmıştır. Ayrıca, görsel detaylıca incelendiğinde anlaşılabacağı üzere özellik parametreleri arasında otomatik yöntemin derinliğin her noktasında logaritmik ve karekök yöntemlerine kıyasla daha düşük ortalama mutlak hata (MAE) değerlerine sahip olduğu, logaritmik ve karekök yöntemlerinin çeşitli derinliklerde birbirlerine çok yakın ortalama mutlak hata (MAE) değerlerine sahip oldukları sonucuna varılmıştır. En düşük ortalama mutlak hata (MAE) sonucu olan 0.0517616’lık değere derinlik parametresinin 10 özellik parametresinin otomatik yöntem olduğu noktada ulaşılmaktadır.



Şekil 7.31 : Derinlik Parametresinin ve Özellik Parametrelerinin R^2 Değerlerine Etkileri.

Çeşitli derinlik parametreleri ve özellik parametrelerinin r kare sonuçlarının görüldüğü Şekil 7.31’de derinlik parametresi 1 ile 10 arasındaki tam sayılar ve özellik parametresi otomatik yöntem, logaritmik yöntem ve karekök yöntemi olacak şekilde ayarlanmıştır. Değişen derinlik parametreleri incelendiğinde ortalama hataların karesi sonuçları göz önünde bulundurulduğunda en başarılı sonuca derinlik parametresinin 10 olduğu noktada ulaşılmıştır. Şekil incelendiğinde görüleceği üzere, özellik parametrelerinden olan otomatik yöntemin r kare sonuçları, derinlik değerinin tüm noktalarında diğer yöntemler olan karekök yöntemi ve logaritmik yöntemle kıyasla daha yüksektir. Ayrıca özellik parametreleri olan karekök yöntemi ve logaritmik yöntemin çeşitli derinlik parametrelerinde birbirlerine yakın sonuçlar elde ettikleri belirtilmelidir. Şekil 7.31 incelendiğinde en yüksek r kare değeri olan 0.9917 değerine derinliğin 10 olduğu noktada karekök yöntemiyle ulaşılmıştır.

Şekil 7.24’te, Şekil 7.25’te, Şekil 7.26’da, Şekil 7.27’de, Şekil 7.28’de, Şekil 7.29’da, Şekil 7.30’da ve Şekil 7.31’de görselleştirilen ekstra ağaç algoritması temelli modelin hiper parametrelerinin düzenlenmesi işleminden sonra ekstra ağaç algoritması temelli tahmin modelinin en düşük ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE), ortalama mutlak hata (MAE) değerlerine ve en yüksek r kare değerine sahip olduğu hiper parametre kombinasyonu Çizelge 7.8’de gösterilmiştir.

Çizelge 7.8 : Ekstra Ağaç Algoritması Temelli Tahmin Modelinin En Başarılı Sonuçlara Ulaştığı Hiper Parametreler.


Tahmin Edici Sayısı Parametresi	Özellik Parametresi	Derinlik Parametresi
124	Otomatik Yöntem	10

Çizelge 7.8’de verilen ekstra ağaç algoritması temelli tahmin modelinin en başarılı sonuçlara ulaşabileceği hiper parametre kombinasyonunun veri seti üzerine uygulandığında ekstra ağaç algoritması temelli modelin elde ettiği başarı ölçüm kriteri sonuçları Çizelge 7.9’da incelenebilir.

Çizelge 7.9 : Hiper Parametreleri Ayarlanmış Ekstra Ağaç Algoritması Temelli Tahmin Modelinin Tahmin Performansı.


Başarı Ölçüm Kriteri	Sonuçlar
Ortalama Mutlak Hata (MAE)	0.0517616949
Ortalama Hataların Karesi (MSE)	0.0058591501
Ortalama Hataların Karekökü (RMSE)	0.0765450859
R-Kare	0.9917573066

Çizelge 7.9 incelendiğinde tahmin edici sayısı parametresi 124, özellik parametresi otomatik yöntem, derinlik parametresi 10 olan ekstra ağaç temelli tahmin modeli 0.0517616949’luk ortalama mutlak hata, 0.0058591501’lik ortalama hataların karesi, 0.0765450859’luk ortalama hataların karekökü sonuçlarıyla %99.17573066’lık doğrulukta tahminler yapmaktadır.




Şekil 7.32 : ETA Algoritması Temelli Modelin Tahmin Sonuçları-1.

Şekil 7.32 incelendiğinde ETA algoritması temelli modelin tahmin sonuçlarının rüzgâr türbininin çeşitli rüzgâr hızlarında ürettiği güç verileri ve rüzgâr türbininin çeşitli rüzgâr hızlarında teorik olarak üretebileceği güç verilerine göre dağılımı görülebilir. Şekil 7.32’de siyah noktalar çeşitli rüzgâr hızlarında rüzgâr türbininin gerçekte ürettiği güç değerlerini, yeşil noktalar çeşitli rüzgâr hızlarında rüzgâr türbininin teorik olarak üretebileceği güç değerlerini ve kırmızı noktalar ise ETA temelli tahmin algoritmasının çeşitli rüzgâr hızlarında tahmin ettiği üretilebilecek güç değerlerini ifade etmektedir. Şekil 7.32 incelendiğinde tahmin değerlerinin başarılı bir şekilde üretilen güç değerleriyle eşleştiği görülmektedir. Veri gizliliği sebebiyle güç değerleri birimsiz ve boyutsuz olarak sunulmuştur.



Şekil 7.33 : ETA Algoritması Temelli Modelin Tahmin Sonuçları-2.

Şekil 7.33 incelendiğinde ETA algoritması temelli makine öğrenmesi modelinin tahmin ettiği üretilebilecek güç değerlerinin rüzgâr türbininin ürettiği güç değerlerine göre dağılımı görülebilir. Şekil 7.33’ten anlaşılabacağı üzere ETA algoritması temelli makine öğrenmesi modeli 0.0765450859’luk ortalama hataların karekökü (RMSE) değeriyle veri setinin %99.17’lik kısmını temsil edebilmektedir. Bu sonuçlara dayanarak tahmin sonuçlarının gerçekte üretilmiş güç değerleri ile yüksek doğrulukta eşleştiği söylenebilir.



Şekil 7.34 : ETA Algoritması Temelli Modelin Tahmin Sonuçları-3.


Şekil 7.34’te rüzgâr türbininin aylık ortalama ürettiği güç değerleri ile ETA algoritması temelli makine öğrenmesi modelinin aylık ortalama üretilebilecek güç tahmini değerleri kullanılarak ortalama güç eğrileri oluşturulmuştur. Şekil 7.34’ten görüleceği üzere ETA algoritması temelli makine öğrenmesi modeli yüksek bir doğrulukla gerçekte üretilmiş ortalama güç değerlerini tahmin etmiştir.

Çizelge 7.10 : Ay Bazlı Üretilen Ortalama Güçler ve ETA Temelli Modelin Tahmin Ettiği Ay Bazlı Ortalama Güçler.

Aylar	Gerçekte Üretilen Ortalama Güçler	ETA Modelinin Tahmin Ettiği Ortalama Güçler
Ocak	1.397183	1.360914
Şubat	1.381640	1.339015
Mart	1.626527	1.617138
Nisan	0.904909	0.919172
Mayıs	0.780199	0.792539
Haziran	0.937986	0.967387
Temmuz	0.458805	0.494139
Ağustos	1.428677	1.460131
Eylül	1.179781	1.183246
Ekim	1.071986	1.069473
Kasım	1.401421	1.379036
Aralık	1.423192	1.388197

7.1.4. Gradyan yükseltme algoritması (GRY) temelli modelin tahmin sonuçları

Çalışma kapsamında kullanılan makine öğrenmesi modellerinden bir diğeri de, makine öğrenmesi kuramının topluluk öğrenmesi sınıfına ve yükseltme sınıfına mensup olana gradyan yükseltme algoritması temelli modeldir. Temelleri 1998 yılında Amerikalı bilim insanı istatistikçi Leo Breiman tarafından atılan ve 2000’li yıllarda Amerikalı fizikçi Jerome Isaac Friedman tarafından geliştirilen gradyan yükseltme algoritması denetimli öğrenme sınıfında zayıf tahmin edicilerin güçlendirilmesi mantığına dayanan bir çalışma metodu izlemektedir[120]. Gradyan yükseltme algoritmasının torbalama sınıfına mensup diğer topluluk öğrenmesi algoritmalarından olan rastgele orman ya da ekstra ağaç algoritmalarından farkı bünyesindeki karar ağaçlarını torbalama algoritmalarının yaptığı gibi paralel bağlı olarak kullanmak yerine seri bağlı olarak kullanmasıdır. Gradyan yükseltme modelinde her bir karar ağacı aynı veri seti kümesi ile eğitilir ve bir önceki karar ağacının artık tahminleri kullanılarak zayıf doğrulukta tahminlerde bulunan karar ağaçlarının yüksek doğrulukta tahminlerde bulunabilen karar ağacı algoritmalarına çevrilmeye çalışılır. Bu çalışma için geliştirilmiş gradyan yükseltme algoritması temelli modelin çalışma mekaniği kısaca aşağıdaki adımlardan oluşturulmuştur.



Şekil 7.35 : GRY Algoritması İçin Tasarlanan Model.

Makine öğrenmesi okulunun denetimli öğrenme kolunun topluluk öğrenmesi sınıfına ve yükseltme sınıfına mensup olan gradyan yükseltme algoritması temel sınıflandırma ve regresyon algoritmalarından bir tanesidir. Diğer topluluk öğrenmesi algoritmaları gibi birçok karar ağacı yapısından oluşan gradyan yükseltme algoritması, topluluk öğrenmesinin torbalama sınıfına mensup rastgele orman ve ekstra ağaç algoritmalarından bünyesinde bulunan karar ağaçları yapısının kullanımı bakımından birtakım farklara sahiptir. Torbalama algoritmalarında karar ağaçları paralel olarak birbirlerinden bağımsız tahminlerde bulunurken yükseltme algoritmalarında yaratılan karar ağaçları seri şekilde birbirlerine bağlanırlar. Her bir karar ağacının tahmini sonucu oluşan artık değerler bir sonraki karar ağacının eğitilmesi için kullanılırlar. Bu sayede baştan sona doğru karar ağaçlarının tahmin performansı arttırılmış ve zayıf doğrulukta tahmin yeteneği bulunan karar ağaçları nihai sonuçta yüksek doğrulukta tahminlerde bulunmuşlardır. Çalışma mekaniği yukarıda kısaca açıklanan gradyan yükseltme algoritmasının tahmin performansının geliştirilebilmesi için bir takım hiper parametrelerinin çözülmeye çalışılan probleme bağlı olarak düzenlenmesi gerekmektedir. Gradyan yükseltme algoritmasının başarı performansını etkileyen üç önemli hiper parametre bulunmaktadır. Bu parametreler sırasıyla, oluşturulacak karar ağaçlarının sayılarını belirlemeye yarayan tahmin edici sayısı parametresi, karar ağacı düğümlerinde en iyi ayrımı sağlamaya yarayan, kullanılacak maksimum öznitelik sayısının belirlenmesine yarayan özellik parametresi ve son olarak her bir karar ağacının kök hücresinden başlayıp yaprak hücresine kadar uzanan en uzun yolu belirleyen derinlik parametresidir.


Bu çalışma kapsamında geliştirilen gradyan yükseltme algoritması temelli modelin düzenlenen ilk parametresi oluşturulacak karar ağacı sayısını belirleyen tahmin edici sayısı parametresidir. Tahin edici sayısı parametresi veri setinin içerdiği örneklem sayısı göz önünde bulundurularak 100 ile 150 arasındaki tam sayılar olarak denenmiş ve her bir tahmin edici sayısı parametresinin tahmin performansı ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve r kare sonuçlarına göre değerlendirilmiştir.

Gradyan yükseltme algoritması temelli modelin tahmin performansının iyileştirilmesi adına düzenlenen bir diğer parametre ise düğüm noktalarındaki en iyi ayrımı sağlamaya yarayacak olan kullanılacak maksimum öznitelik sayısının belirlenmesini sağlayan özellik parametresidir. Bu çalışma kapsamında özellik parametresini

belirlemek adına otomatik yöntem, logaritmik yöntem ve karekök yöntemi kullanılarak en düşük ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve en yüksek r kare değerleri bulunmaya çalışılmıştır. Otomatik yöntemde düğüm noktalarındaki maksimum özellik sayısı öznitelik sayısına eşit olacak şekilde kullanılırken, logaritmik yöntemde maksimum özellik sayısı veri setindeki öznitelik sayısının $\log_2$ tabanındaki formu şeklinde, karekök yönteminde ise veri setindeki öznitelik sayısının karekökü şeklinde kullanılmaktadır.


Geliştirilen modelin tahmin performansının geliştirilmesi adına yapılan son hiper parametre düzenlemesi de kök hücreden yaprak hücrelere uzanabilecek en uzun yolun belirlenmesine yarayan derinlik parametresidir. Derinlik parametresi veri seti göz önünde bulundurularak 1 ile 10 arasındaki tam sayı değerlerince değerlendirilip en düşük hata değerlerine ve en yüksek r kare değerlerine sahip olacak şekilde düzenlenmeye çalışılmıştır.

Şekil 7.36, Şekil 7.37, Şekil 7.38 ve Şekil 7.39 incelendiklerinde karar ağacı sayısını belirleyen tahmin edici sayısı parametresinin ve en iyi ayrımın yapılması için maksimum özellik sayısını belirleyen özellik parametresinin ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve r kare değerleri üzerindeki etkileri görülebilir.



Şekil 7.36 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.


Şekil 7.36’da farklı tahmin edici sayısı parametresi değerlerine ve çeşitli özellik parametresi yöntemlerine göre geliştirilen gradyan yükseltme algoritması temelli tahmin modelinin ortalama hataların karekökü (RMSE) sonuçları görülmektedir. 100 ile 150 arasında değişen tahmin edici sayısı parametreleri incelendiğinde en düşük ortalama hataların karekökü (RMSE) sonucuna tahmin edici sayısının 131 olduğu noktada ulaşıldığı görülmektedir. Ayrıca, özellik parametreleri arasında otomatik yöntemin logaritmik ve karekök yöntemlerine kıyasla daha düşük ortalama hataların karekökü (RMSE) değerlerine sahip olduğu ve buna ek olarak logaritmik ve karekök yöntemlerinin çeşitli tahmin edici sayılarında birbirlerine yakın ortalama hataların karekökü (RMSE) değerlerine sahip oldukları sonucuna varılmıştır. En düşük ortalama hataların karekökü (RMSE) sonucu olan 0.07246’lık değere tahmin edici sayısı parametresinin 131 olduğu noktada ve özellik parametresinin otomatik yöntemiyle ulaşılmıştır.



Şekil 7.37 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.

Farklı tahmin edici sayısı parametreleri ve özellik parametrelerinin ortalama hataların karesi (MSE) sonuçlarının görüldüğü Şekil 7.37’de tahmin edici sayısı parametresi 100 ile 150 arasındaki tam sayılar olacak şekilde ve özellik parametresi de otomatik


yöntem, logaritmik yöntem ve karekök yöntemi olacak şekilde test edilmektedir. Değişen tahmin edici sayısı parametreleri incelendiğinde ortalama hataların karesi sonuçları göz önünde bulundurulursa en başarılı sonuca, tahmin edici sayısı parametresinin 131 olduğu noktada ulaşıldığı görülmektedir. Ek olarak, görselden anlaşılacağı üzere özellik parametrelerinden olan otomatik yöntemin ortalama hataların karesi (MSE) sonuçları diğer yöntemler olan karekök yöntemi ve logaritmik yönteme kıyasla daha düşüktür. Ayrıca, özellik parametreleri olan karekök yöntemi ve logaritmik yöntemin çeşitli tahmin edici sayısı parametrelerinde birbirlerine yakın sonuçlar elde ettikleri tespit edilen bir diğer önemli bulgudur. Sonuç olarak, Şekil 7.37 incelendiğinde görüleceği üzere en küçük ortalama hataların karesi (MSE) değeri olan 0.005250 sonucuna tahmin edici sayısının 131 olduğu noktada otomatik yöntemle ulaşılmıştır.



Şekil 7.38 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin MAE Değerlerine Etkileri.

Şekil 7.38’de görüleceği üzere, farklı tahmin edici sayısı parametresi değerlerine ve çeşitli özellik parametresi yöntemlerine göre geliştirilen gradyan yükseltme algoritması temelli tahmin modelinin ortalama mutlak hata (MAE) sonuçları çeşitli değerler almaktadır. 100 ve 150 arasında değişen tahmin edici sayısı parametreleri incelendiğinde en düşük ortalama mutlak hata (MAE) sonucuna tahmin edici sayısının 131 olduğu değerde ulaşıldığı görülmektedir. Ek olarak, Şekil 7.38 detaylıca

incelendiğinde özellik parametreleri arasında otomatik yöntemin logaritmik ve karekök yöntemlerine kıyasla daha düşük ortalama mutlak hata (MAE) değerlerine sahip olduğu, ve ayrıca logaritmik ve karekök yöntemlerinin çeşitli tahmin edici sayılarında birbirlerine yakın ortalama mutlak hata (MAE) değerlerine sahip oldukları görülmüştür. Sonuç olarak, görsel incelendiğinde görüleceği üzere en düşük ortalama mutlak hata (MAE) sonucu olan 0.048471'lik değere tahmin edici sayısının 131 ve özellik parametresinin otomatik yöntem olduğu kombinasyonda ulaşılmıştır.




Şekil 7.39 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin R^2 Değerlerine Etkileri.

Farklı tahmin edici sayısı parametreleri ve özellik parametrelerinin r kare sonuçlarının görüldüğü Şekil 7.39'da tahmin edici sayısı parametresi 100'den başlayıp 150'ye kadar birer birer artmaktadır. Özellik parametresi olarak da otomatik yöntem, logaritmik yöntem ve karekök yöntemi test edilmektedir. Değişen tahmin edici sayısı parametreleri incelendiğinde r kare sonuçlarına bakılırsa en başarılı sonuca tahmin edici sayısı parametresinin 131 olduğu noktada ulaşıldığı görülecektir. Ayrıca, Şekil 7.39 detaylıca incelendiğinde görüleceği üzere özellik parametrelerinden olan otomatik yöntemin r kare sonuçları diğer yöntemler olan karekök yöntemi ve logaritmik yöntemle kıyasla daha yüksektir. Ek olarak, özellik parametreleri olan karekök yöntemi ve logaritmik yöntemin çeşitli tahmin edici sayısı parametrelerinde birbirlerine yakın sonuçlar elde ettiklerini belirtmek yanıltıcı bir ifade olmayacaktır.

Sonuç olarak, en yüksek r kare değeri olan 0.992613 sonucuna tahmin edici sayısının 131 olduğu noktada özellik parametresinin otomatik yöntem değerinde ulaşılmıştır.


Şekil 7.40, Şekil 7.41, Şekil 7.42 ve Şekil 7.43 incelendiklerinde kök hücreden yaprak hücreye uzanan en uzun yolu belirten derinlik parametresinin ve en iyi ayrımın yapılması için maksimum özellik sayısını tanımlayan özellik parametresinin ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve r-kare değerleri üzerindeki etkileri görülebilir.



Şekil 7.40 : Derinlik Parametresinin ve Özellik Parametrelerinin RMSE Değerlerine Etkileri.

Çeşitli derinlik parametresi değerlerine ve çeşitli özellik parametresi yöntemlerine göre geliştirilen GRY algoritması temelli tahmin modelinin ortalama hataların karekökü (RMSE) sonuçları Şekil 7.40’da görülmektedir. Derinlik parametreleri 1 ile 10 arasındaki tam sayılar olacak şekilde değişmektedir. Değişen derinlik parametreleri incelendiğinde görüleceği gibi, en düşük ortalama hataların karekökü (RMSE) sonucuna derinliğin 5 olduğu noktada ulaşılmaktadır. Ayrıca, özellik parametrelerinden olan otomatik yöntemin derinliğin 5 olduğu konuma kadar logaritmik ve karekök yöntemlerine kıyasla daha düşük ortalama hataların karekökü (RMSE) değerlerine sahip olduğu, buna ek olarak logaritmik ve karekök yöntemlerinin


çeşitli derinliklerde birbirlerine çok yakın ortalama hataların karekökü (RMSE) değerlerine sahip oldukları belirlenmiştir. Sonuç olarak, Şekil 7.40 incelendiğinde görüleceği üzere, en düşük ortalama hataların karekökü (RMSE) sonucu olan 0.072462'lik değere derinlik parametresinin 5, özellik parametresinin otomatik yöntem olduğu kombinasyonla ulaşılmaktadır.



Şekil 7.41 : Derinlik Parametresinin ve Özellik Parametrelerinin MSE Değerlerine Etkileri.


Çeşitli derinlik parametreleri ve özellik parametrelerinin ortalama hataların karesi (MSE) sonuçlarının görüldüğü Şekil 7.41'de derinlik parametresi 1 ile 10 arasında birer birer artmaktadır ve özellik parametresi olarak da otomatik yöntem, logaritmik yöntem ve karekök yöntemi test edilmektedir. Değişen derinlik parametreleri incelendiğinde ortalama hataların karesi sonuçlarına bakıldığında en başarılı sonuca derinlik parametresinin 5 olduğu noktada ulaşılmıştır. Ek olarak ifade etmek gerekirse, Şekil 7.41'den anlaşılabileceği üzere özellik parametrelerinden olan otomatik yöntemin ortalama hataların karesi (MSE) sonuçları, derinlik değerinin 5 olduğu noktaya kadar diğer yöntemler olan karekök yöntemi ve logaritmik yöntemle kıyasla daha küçüktür. Ayrıca özellik parametreleri olan karekök yöntemi ve logaritmik yöntemin çeşitli derinlik parametrelerinde birbirlerine yakın sonuçlar elde ettiklerini belirtmek gerekir. Sonuç olarak, en küçük ortalama hataların karesi (MSE) değeri olan 0.005250

sonucuna ulaşabilmek için derinlik parametresinin 5 olduğu ve özellik parametresinin otomatik yöntem olduğu kombinasyonun kullanılması gerekmektedir.



Şekil 7.42 : Derinlik Parametresinin ve Özellik Parametrelerinin MAE Değerlerine Etkileri.

Şekil 7.42 incelendiğinde, farklı derinlik parametresi değerlerine ve çeşitli özellik parametresi yöntemlerine göre geliştirilen GRY algoritması temelli tahmin modelinin ortalama mutlak hata (MAE) sonuçları görülebilir. 1 ile 10 arasında değişen derinlik parametreleri incelendiğinde en düşük ortalama mutlak hata (MAE) sonucuna derinliğin 5 olduğu noktada ulaşıldığı görülmektedir. Ayrıca, görsel detaylıca incelendiğinde fark edileceği üzere, özellik parametreleri arasında otomatik yöntemin derinliğin 5 olduğu noktaya kadar logaritmik ve karekök yöntemlerine kıyasla daha düşük ortalama mutlak hata (MAE) değerlerine sahip olmuştur, ve buna ek olarak logaritmik ve karekök yöntemlerinin çeşitli derinliklerde birbirlerine çok yakın ortalama mutlak hata (MAE) değerlerine sahip oldukları görülmüştür. Şekil 7.42 incelendiğinde en düşük ortalama mutlak hata (MAE) sonucu olan 0.048471'lik değere derinlik parametresinin 5, ve özellik parametresinin otomatik yöntem olduğu kombinasyonla ulaşılmaktadır.



Şekil 7.43 : Derinlik Parametresinin ve Özellik Parametrelerinin R2 Değerlerine Etkileri.

Farklı derinlik parametreleri ve özellik parametrelerinin r kare sonuçlarının görüldüğü Şekil 7.43'te derinlik parametresi 1 ile 10 arasında birer birer artmaktadır. Özellik parametresi olarak da otomatik yöntem, logaritmik yöntem ve karekök yöntemi test edilmektedir. Değişen derinlik parametreleri incelendiğinde ortalama hataların karesi sonuçları göz önünde bulundurulduğunda en başarılı sonuca derinlik parametresinin 5 olduğu konumda ulaşılmıştır. Ayrıca, görselden görüleceği üzere özellik parametrelerinden olan otomatik yöntemin r kare sonuçları, derinlik değerinin ilk beş noktasında diğer yöntemler olan karekök yöntemi ve logaritmik yöntemle kıyasla daha yüksektir. Buna ek olarak, özellik parametreleri olan karekök yöntemi ve logaritmik yöntemin çeşitli derinlik parametrelerinde birbirlerine yakın sonuçlar elde ettiklerini belirtmek gerekir. Sonuç olarak, en yüksek r kare değeri olan 0.9926 sonucuna derinliğin 5 olduğu noktada, otomatik yöntemle ulaşılmaktadır.

Şekil 7.36'da, Şekil 7.37'de, Şekil 7.38'de, Şekil 7.39'da, Şekil 7.40'da, Şekil 7.41'de, 7.42'de ve Şekil 7.43'de görselleştirilen gradyan yükseltme algoritması temelli modelin hiper parametrelerinin düzenlenmesi işleminden sonra gradyan yükseltme algoritması temelli tahmin modelinin en düşük ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE), ortalama mutlak hata (MAE) değerlerine ve en

yüksek r kare değerine sahip olduğu hiper parametre kombinasyonu Çizelge 7.11’de gösterilmiştir.

Çizelge 7.11 : Gradyan Yükseltme Algoritması Temelli Tahmin Modelinin En Başarılı Sonuçlara Ulaştığı Hiper Parametreler.

Tahmin Edici Sayısı Parametresi	Özellik Parametresi	Derinlik Parametresi
131	Otomatik Yöntem	5


Çizelge 7.11’de verilen gradyan yükseltme algoritması temelli tahmin modelinin en başarılı sonuçlara ulaşabileceği hiper parametre kombinasyonunun veri seti üzerine uygulandığında gradyan yükseltme algoritması temelli modelin elde ettiği başarı ölçüm kriteri sonuçları Çizelge 7.12’de incelenebilir.

Çizelge 7.12 : Hiper Parametreleri Ayarlanmış Gradyan Yükseltme Algoritması Temelli Tahmin Modelinin Tahmin Performansı.


Başarı Ölçüm Kriteri	Sonuçlar
Ortalama Mutlak Hata (MAE)	0.0484718553
Ortalama Hataların Karesi (MSE)	0.0052507708
Ortalama Hataların Karekökü (RMSE)	0.0724622028
R-Kare	0.9926131789

Çizelge 7.12 incelendiğinde tahmin edici sayısı parametresi 131, özellik parametresi otomatik yöntem, derinlik parametresi 5 olan gradyan yükseltme temelli tahmin modeli 0.048471855’lik ortalama mutlak hata, 0.0052507708’lik ortalama hataların karesi, 0.0724622028’lik ortalama hataların karekökü sonuçlarıyla %99.26131789’luk doğrulukta tahminler yapmaktadır.

Şekil 7.44 incelendiğinde GRY algoritması temelli modelin tahmin sonuçlarının rüzgâr türbininin çeşitli rüzgâr hızlarında ürettiği güç verileri ve rüzgâr türbininin çeşitli rüzgâr hızlarında teorik olarak üretebileceği güç verilerine göre dağılımı görülebilir. Şekil 7.44’te siyah noktalar çeşitli rüzgâr hızlarında rüzgâr türbininin gerçekte ürettiği güç değerlerini, yeşil noktalar çeşitli rüzgâr hızlarında rüzgâr türbininin teorik olarak üretebileceği güç değerlerini ve kırmızı noktalar ise GRY temelli tahmin algoritmasının çeşitli rüzgâr hızlarında tahmin ettiği üretilebilecek güç değerlerini ifade etmektedir. Şekil 7.44 incelendiğinde tahmin değerlerinin başarılı bir şekilde üretilen güç değerleriyle eşleştiği görülmektedir. Veri gizliliği sebebiyle güç değerleri birimsiz ve boyutsuz olarak sunulmuştur.




Şekil 7.44 : GRY Algoritması Temelli Modelin Tahmin Sonuçları-1.



Şekil 7.45 : GRY Algoritması Temelli Modelin Tahmin Sonuçları-2.

Şekil 7.45 incelendiğinde GRY algoritması temelli makine öğrenmesi modelinin tahmin ettiği üretililecek güç değerlerinin rüzgâr türbininin ürettiği güç değerlerine göre dağılımı görülebilir. Görselden anlaşılacağı üzere, GRY algoritması temelli makine öğrenmesi modeli 0.0724622028’lik ortalama hataların karekökü (RMSE) değeriyle veri setinin %99.26’lık kısmını temsil edebilmektedir. Bu sonuçlara

dayanarak tahmin sonuçlarının gerçekte üretilmiş güç değerleri ile yüksek doğrulukta eşleştiği söylenebilir.



Şekil 7.46 : GRY Algoritması Temelli Modelin Tahmin Sonuçları-3.


Şekil 7.46’da rüzgâr türbininin aylık ortalama ürettiği güç değerleri ile GRY algoritması temelli makine öğrenmesi modelinin aylık ortalama üretilebilecek güç tahmini değerleri kullanılarak ortalama güç eğrileri oluşturulmuştur. Şekil 7.46’dan görüleceği üzere GRY algoritması temelli makine öğrenmesi modeli yüksek bir doğrulukla gerçekte üretilmiş ortalama güç değerlerini tahmin etmiştir.

Çizelge 7.13 : Ay Bazlı Üretilen Ortalama Güçler ve GRY Temelli Modelin Tahmin Ettiği Ay Bazlı Ortalama Güçler.

Aylar	Gerçekte Üretilen Ortalama Güçler	GRY Modelinin Tahmin Ettiği Ortalama Güçler
Ocak	1.397183	1.364153
Şubat	1.381640	1.336056
Mart	1.626527	1.619126
Nisan	0.904909	0.914477
Mayıs	0.780199	0.795393
Haziran	0.937986	0.964387
Temmuz	0.458805	0.490457
Ağustos	1.428677	1.460113
Eylül	1.179781	1.182765
Ekim	1.071986	1.071507
Kasım	1.401421	1.374925
Aralık	1.423192	1.391759

7.1.5. Geliştirilen KRM modelinin tahmin sonuçları

Çalışma kapsamında geliştirilen son makine öğrenmesi modeli de makine öğrenmesi kuramının denetimli öğrenme sınıfının çeşitli algoritmalarının çalışma mekanizmalarının aynı anda aynı örneklem üzerine uygulanması temeline dayanarak oluşturulmuş karma algoritma (KRM) modelidir. Geliştirilen bu modelde denetimli öğrenme sınıfının üç temel üyesi ve alt grupları beraber kullanılarak yeni bir karma algoritma modeli oluşturulmaya çalışılmıştır. Tasarlanan karma modelde denetimli öğrenme sınıfının temel üyelerinden olan temel algoritmaların yanı sıra topluluk öğrenmesi grubunun torbalama algoritmaları ve yükseltme algoritmaları kullanılmıştır. Geliştirilen modelde kullanılan denetimli öğrenme sınıfına mensup algoritmalar k'nci mertebeden en yakın komşular (KEK), rastgele orman (RSO), ekstra ağaç (ETA), gradyan yükseltme (GRY) algoritmalarıdır. Dayanağı yukarıda açıklanan, bu çalışma için geliştirilmiş karma algoritma modelinin çalışma mekanizması kısaca aşağıdaki adımlardan oluşmuştur (Şekil 7.47).




Şekil 7.47 : Geliştirilen KRM Modelinin Çalışma Mekanizması.


Şekil 7.47’den anlaşılacağı üzere bu çalışma için geliştirilen karma algoritma modeli (KRM) içerisine gömülmüş topluluk öğrenmesi algoritmalarının, torbalama grubuna mensup rastgele orman algoritması temelli, ekstra ağaç algoritması temelli, yükseltme grubuna mensup gradyan yükseltme algoritması temelli ve en temel denetimli öğrenme sınıfı üyelerinden biri olan k’nci mertebeden en yakın komşular algoritması temelli 4 farklı alt modelden oluşmaktadır.

Karma modelin tahmin başarısının artırılması için ilk olarak k’nci mertebeden en yakın komşular algoritması temelli alt modelin hiper parametreleri düzenlenmeye çalışılmıştır. Bu alt modelin düzenlenecek parametreleri veri setinde bakılacak olan örneklem sayısının belirlendiği k sayısı parametresi, veri setindeki örneklemelerin birbirlerine göre uzaklıklarının hesaplanacağı metrik parametresi ve son olarak k adet örneklem tahmin sonucuna nasıl etki edeceklerini belirleyen ağırlık parametresidir. Geliştirilen modelde k sayısı parametresi için 1-250 arasındaki her bir tam sayı değeri, metrik parametreleri için Manhattan ve Öklid uzaklık hesabı yöntemleri, ağırlık parametresi için ise eşit ve uzaklık yöntemleri test edilip en düşük ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE), ortalama mutlak hata (MAE) ve en yüksek r kare değerlerini veren kombinasyon bulunmaya çalışılmıştır. Şekil 7.48’de ve Şekil 7.49’da KNN algoritması temelli alt modelin hiper parametrelerinin çeşitli başarı ölçüm kriterlerine göre sonucu görülebilir.

Şekil 7.48 ve Şekil 7.49 incelendiğinde 1 ile 250 arasında değişen k sayısı parametreleri, Manhattan uzaklık hesaplama yöntemi ile Öklid uzaklık hesaplama yöntemi olarak değişen metrik parametreleri ve ayrıca eşit ve uzaklık yöntemi olarak değişen ağırlık parametrelerinin tahmin başarılarının test edildiği ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE), ortalama mutlak hata (MAE) ve r kare değerleri görülebilir. En düşük ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve en yüksek r kare değerleri sırasıyla, 0.078173, 0.006111, 0.051857 ve 0.991402 değerleridir. Bu değerlere k sayısı parametresinin 15, metrik parametresinin Manhattan uzaklık hesabı yöntemi ve ağırlık parametresinin uzaklık olduğu kombinasyonda ulaşılmıştır.




Şekil 7.48 : K Sayısı Parametresi ve Metrik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.




Şekil 7.49 : K Sayısı Parametresi ve Metrik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.

Karma modelin tahmin performansının geliştirilmesi için ikinci olarak, rastgele orman (RSO) temelli alt modelin hiper parametreleri düzenlenmeye çalışılmıştır. Bu alt modelin düzenlenecek hiper parametreleri, tahmin için kullanılacak karar ağacı sayısını belirleyen tahmin edici sayısı parametresi, oluşturulacak bütün karar ağaçlarının düğüm noktalarında ayrılma işlemi yapılırken bakılacak öznelilik sayısını belirleyen özellik parametresi ve bütün karar ağaçlarının kök hücrelerinden yaprak hücrelerine kadar uzanacak olan en uzun yolu belirleyen derinlik parametresidir. Karma model (KRM) için geliştirilen alt modelde tahmin edici sayısı parametresi için veri setinin büyüklüğü göz önünde bulundurularak 100 - 150 arasındaki her bir tam sayı değeri, özellik parametreleri için otomatik yöntem, logaritmik yöntem ve karekök yöntemi, derinlik parametresi için ise 1 ile 10 arasındaki tam sayı değerleri test edilip en düşük ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE), ortalama mutlak hata (MAE) ve en yüksek r kare değerlerini veren kombinasyon bulunmaya çalışılmıştır. Şekil 7.50’de ve Şekil 7.51’de rastgele orman algoritması temelli alt modelin hiper parametrelerinin çeşitli başarı ölçüm kriterlerine göre elde ettikleri sonuçlar görülebilir.



Şekil 7.50 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.




Şekil 7.51 : Derinlik Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.

Şekil 7.50 ve Şekil 7.51 incelendiğinde 1 ile 10 arasında değişen derinlik parametresi, 100 ile 150 arasında değişen tahmin edici sayısı parametresi ve ayrıca otomatik yöntem, logaritmik yöntem, karekök yöntemi olarak değişen özellik parametrelerinin tahmin başarılarının test edildiği ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE), ortalama mutlak hata (MAE) ve r kare değerleri görülebilir. En düşük ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve en yüksek r kare sonuçları sırasıyla, 0.073376, 0.005384, 0.049353 ve 0.992425 değerleridir. Bu değerlere tahmin edici sayısı


parametresinin 125, özellik parametresinin karekök yöntemi ve derinlik parametresinin 10 olduğu kombinasyonda ulaşılmıştır.

Karma modelin tahmin sonuçlarının iyileştirilmesi için ekstra ağaç (ETA) temelli alt modelin hiper parametreleri düzenlenmeye çalışılmıştır. Bu alt modelin düzenlenen parametreleri, tahmin için kullanılacak karar ağacı sayısının belirlendiği tahmin edici sayısı parametresi, oluşturulacak bütün karar ağaçlarının düğüm noktalarında ayrılma işlemi yapılırken bakılacak öznetelik sayısının belirlendiği özellik parametresi ve bütün karar ağaçlarının kök hücrelerinden yaprak hücrelerine kadar olan en uzun yolu tanımlayan derinlik parametresidir. Karma model (KRM) için geliştirilen alt modelde tahmin edici sayısı parametresi için veri setinin büyüklüğü göz önünde bulundurularak 100 - 150 arasındaki her bir tam sayı değeri, özellik parametreleri için otomatik yöntem, logaritmik yöntem ve karekök yöntemi, derinlik parametresi için ise 1 ile 10 arasındaki tam sayı değerleri test edilip, en düşük ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE), ortalama mutlak hata (MAE) ve en yüksek r kare değerlerini veren kombinasyon bulunmaya çalışılmıştır. Şekil 7.52’de ve Şekil 7.53’te ekstra ağaç algoritması temelli alt modelin hiper parametrelerinin çeşitli başarı ölçüm kriterlerine göre elde ettikleri sonuçlar görülebilir.

Şekil 7.52’de ve Şekil 7.53’te, 1 ile 10 arasında değişen derinlik parametresi, 100 ile 150 arasında değişen tahmin edici sayısı parametresi ve bunlara ek olarak otomatik yöntem, logaritmik yöntem, karekök yöntemi olarak değişen özellik parametrelerinin tahmin başarılarının test edildiği ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE), ortalama mutlak hata (MAE) ve r kare değerleri verilmiştir. En düşük ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve en yüksek r kare sonuçları sırasıyla, 0.076545, 0.005859, 0.051761 ve 0.991757 değerleridir. Bu değerlere tahmin edici sayısı parametresinin 124, özellik parametresinin otomatik yöntem ve derinlik parametresinin 10 olduğu kombinasyonda ulaşılmıştır.




Şekil 7.52 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.




Şekil 7.53 : Derinlik Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.

Karma modelin tahmin sonuçlarının iyileştirilmesi için karma modelde (KRM) kullanılan gradyan yükseltme (GRY) temelli alt modelin hiper parametreleri düzenlenmeye çalışılmıştır. Bu alt modelin düzenlenen hiper parametreleri, tahmin için kullanılacak karar ağacı sayısının belirlendiği tahmin edici sayısı parametresi,

oluşturulacak bütün karar ağaçlarının düğüm noktalarında ayrılma işlemi yapılırken bakılacak öznitelik sayısının belirlendiği özellik parametresi ve bütün karar ağaçlarının kök hücrelerinden yaprak hücrelerine kadar olan en uzun yolu tanımlayan derinlik parametresidir. Karma model (KRM) için geliştirilen alt modelde tahmin edici sayısı parametresi için veri setinin büyüklüğü göz önünde bulundurularak 100 - 150 arasındaki her bir tam sayı değeri, özellik parametreleri için otomatik yöntem, logaritmik yöntem ve karekök yöntemi, derinlik parametresi için ise 1 ile 10 arasındaki tam sayı değerleri test edilip, en düşük ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE), ortalama mutlak hata (MAE) ve en yüksek r kare değerlerini veren kombinasyon bulunmaya çalışılmıştır. Şekil 7.54'te ve Şekil 7.55'te gradyan yükseltme algoritması temelli alt modelin hiper parametrelerinin çeşitli başarı ölçüm kriterlerine göre sonuçları görülebilir.



Şekil 7.54 : Tahmin Edici Sayısı Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.



Şekil 7.55 : Derinlik Parametresinin ve Özellik Parametrelerinin Tahmin Başarısı Ölçüm Kriterlerine Etkileri.

Şekil 7.54 ve Şekil 7.55 incelendiğinde 1 ile 10 arasında değişen derinlik parametresi, 100 ile 150 arasında değişen tahmin edici sayısı parametresi ve ayrıca otomatik yöntem, logaritmik yöntem, karekök yöntemi olarak değişen özellik parametrelerinin tahmin başarılarının test edildiği ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE), ortalama mutlak hata (MAE) ve r kare değerleri görülebilir. En

düşük ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve en yüksek r kare sonuçları sırasıyla, 0.0724622, 0.005250, 0.048471 ve 0.992613 değerleriyle tahmin edici sayısı parametresinin 131, özellik parametresinin otomatik yöntem ve derinlik parametresinin 5 olduğu kombinasyonda ulaşılmıştır.

Çizelge 7.14 incelendiğinde karma model (KRM) için geliştirilen alt modellerin en başarılı tahmin sonuçlarına ulaştıkları hiper parametre özelliklerine ve o hiper parametre özellikleri altında elde ettikleri ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve r kare sonuçlarına ulaşılabilir.

Çizelge 7.14 : Karma Modelin İçine Gömülü Alt Modellerin En Başarılı Sonucu Veren Hiper Parametre Kombinasyonları.


Topluluk Öğrenmesi Temelli Algoritma Modelleri							
Geliştirilen Model	Tahmin Edici Sayısı	Özellik	Derinlik	MAE	MSE	RMSE	R²
RSO Modeli	125	Karekök yöntemi	10	0.0493	0.0053	0.0733	0.9924
ETA Modeli	124	Otomatik Yöntem	10	0.0517	0.0058	0.0765	0.9917
GRY Modeli	131	Otomatik Yöntem	5	0.0484	0.0052	0.0724	0.9926
Bireysel Öğrenme Temelli Algoritma Modeli							
Geliştirilen Model	K Sayısı	Metrik	Ağırlık	MAE	MSE	RMSE	R²
KEK Modeli	15	Manhattan Yöntemi	Uzaklık Yöntemi	0.0518	0.0061	0.0781	0.9914

Çizelge 7.15 incelendiğinde alt modellerinin hiper parametre optimizasyonu tamamlanmış karma modelin, veri seti üzerindeki tahminlerine göre ortalama hataların karesi (MSE), ortalama hataların karekökü (RMSE), ortalama mutlak hata (MAE) ve r kare sonuçları görülebilir.

Çizelge 7.15 : Alt Modellerinin Hiper Parametreleri Ayarlanmış Karma Modelinin (KRM) Tahmin Performansı.


Başarı Ölçüm Kriteri	Sonuçlar
Ortalama Mutlak Hata (MAE)	0.0357109500
Ortalama Hataların Karesi (MSE)	0.0036059085
Ortalama Hataların Karekökü (RMSE)	0.060049217
R-Kare	0.994927182

Çizelge 7.15 incelendiğinde topluluk öğrenmesi algoritmaları temelli modellerle ve bireysel öğrenme algoritması temelli modellerle güçlendirilen karma modelin (KRM) binde 3.6'lık ortalama hataların karesi sonucuyla veri seti üzerinde %99.49 doğrulukta tahminler yapmaktadır.




Şekil 7.56 : KRM Modelin Tahmin Sonuçları-1.

Şekil 7.56 incelendiğinde çeşitli algoritma modelleriyle güçlendirilmiş karma modelin (KRM) tahmin sonuçlarının rüzgâr türbininin çeşitli rüzgâr hızlarında ürettiği güç verileri ve rüzgâr türbininin çeşitli rüzgâr hızlarında teorik olarak üretebileceği güç verilerine göre dağılımı görülebilir. Şekil 7.56'da siyah noktalar çeşitli rüzgâr hızlarında rüzgâr türbininin gerçekte ürettiği güç değerlerini, yeşil noktalar çeşitli rüzgâr hızlarında rüzgâr türbininin üretebileceği teorik güç değerlerini ve kırmızı noktalar ise karma modelin (KRM) çeşitli rüzgâr hızlarında tahmin ettiği üretilebilecek güç değerlerini ifade etmektedir. Şekil 7.56 incelendiğinde tahmin değerlerinin başarılı bir şekilde üretilen güç değerleriyle eşleştiği görülmektedir. Veri gizliliği sebebiyle güç değerleri birimsiz ve boyutsuz olarak sunulmuştur.



Şekil 7.57 : KRM Modelin Tahmin Sonuçları-2.

Şekil 7.57 incelendiğinde karma modelinin (KRM) tahmin ettiği üretilebilecek güç değerlerinin rüzgâr türbininin ürettiği güç değerlerine göre dağılımı görülebilir. Şekil 7.57’den anlaşılabileceği üzere karma model (KRM) 0.06004921’lik ortalama hataların karekökü (RMSE) değeriyle veri setinin %99.49’luk kısmını temsil edebilmektedir. Bu sonuçlara dayanarak tahmin sonuçlarının gerçekte üretilmiş güç değerleri ile yüksek doğrulukta eşleştiği söylenebilir.



Şekil 7.58 : KRM Modelin Tahmin Sonuçları-3.

Şekil 7.58’de rüzgâr türbininin aylık ortalama ürettiği güç değerleri ile karma modelin (KRM) tahmin ettiği aylık ortalama üretilebilecek güç değerleri kullanılarak ortalama güç eğrileri oluşturulmuştur. Şekil 7.58’den görüleceği üzere geliştirilen karma model (KRM) yüksek bir doğrulukla gerçekte üretilmiş ortalama güç değerlerini tahmin etmiştir.

Çizelge 7.16 : Ay Bazlı Üretilen Ortalama Güçler ve Karma Modelin (KRM) Tahmin Ettiği Ay Bazlı Ortalama Güçler.


Aylar	Gerçekte Üretilen Ortalama Güçler	KRM Modelinin Tahmin Ettiği Ortalama Güçler
Ocak	1.397183	1.364153
Şubat	1.381640	1.336056
Mart	1.626527	1.619126
Nisan	0.904909	0.914477
Mayıs	0.780199	0.795393
Haziran	0.937986	0.964387
Temmuz	0.458805	0.490457
Ağustos	1.428677	1.460113
Eylül	1.179781	1.182765
Ekim	1.071986	1.071507
Kasım	1.401421	1.374925
Aralık	1.423192	1.391759

Sonuç olarak, yüksek lisans tezinin bu kısmında Bursa’da bulunan ve faal olarak elektrik üretiminde kullanılan 8 adet rüzgâr türbini barındıran bir rüzgâr santralının rüzgâr türbinlerinden ölçülmüş, 52560 adet veriden oluşan veri seti kullanılarak makine öğrenmesi kuramının çeşitli disiplinlerini temel alan 5 farklı tahmin modeli geliştirilmiş ve bu tahmin modellerinin başarıları ortalama hataların karekökü (RMSE), ortalama hataların karesi (MSE), ortalama mutlak hata (MAE) ve r kare gibi çeşitli başarı ölçüm kriterleriyle değerlendirilerek en başarılı tahmin sonuçlarına ulaşacak model belirlenmeye çalışılmıştır. Çalışma içinde kullanılan her bir modelin tahmin başarılarını arttırmak için hiper parametrelerinin iyileştirilmesi üzerine alt çalışmalar yapılmıştır. Çizelge 7.17 incelendiğinde çalışma için geliştirilmiş ve hiper parametreleri optimize edilmiş her bir modelin başarı ölçüm kriterlerine göre aldıkları sonuçlar görülebilir.


Çizelge 7.17 : Geliştirilen Tüm Modellerin Tahmin Performansları.

Geliştirilen Model	MAE	MSE	RMSE	R ²
KEK Temelli Model	0.0518576	0.0061110	0.0781733	0.9914029
ETA Temelli Model	0.0517616	0.0058591	0.0765450	0.9917573
RSO Temelli Model	0.0493539	0.0053841	0.0733766	0.9924255
GRY Temelli Model	0.0484718	0.0052507	0.0724622	0.9926131
Karma Model	0.0357109	0.0036059	0.0600492	0.9949271


Şekil 7.59, Şekil 7.60 ve Şekil 7.61’de geliştirilen algoritmaların çeşitli başarı ölçüm kriterlerine göre elde ettikleri tahmin başarılarının görselleştirilmesi ve karşılaştırılması görülmektedir..



Şekil 7.59 : Geliştirilen Modellerin Ortalama Mutlak Hata (MAE) Sonuçlarına Göre Karşılaştırılması.



Şekil 7.60 : Geliştirilen Modellerin Ortalama Hataların Karesi (MSE) Sonuçlarına Göre Karşılaştırılması.



Şekil 7.61 : Geliştirilen Modellerin Ortalama Hataların Karekökü (RMSE) Sonuçlarına Göre Karşılaştırılması.


Çizelge 7.17, Şekil 7.59, Şekil 7.60 ve Şekil 7.61 incelendiğinde geliştirilen modellerin başarıları hakkında birçok yoruma ulaşılabilir. Öncelikle tablo ve grafiklerden elde edilecek ilk bilgi makine öğrenmesi kuramının topluluk öğrenmesi ve bireysel öğrenme sınıflarına mensup algoritmaları alt model olarak eğitip aynı anda tahminler yaptıran karma modelin binde üçlük ortalama hataların karesi değeri ile %99.49'luk doğrulukta tahminler yaptığı görülmektedir. Bu saptamanın dışında, tablolar ve grafikler incelendiğinde topluluk öğrenmesi sınıfına ait algoritmalar olan rastgele orman algoritması temelli modelin, ekstra ağaç algoritması temelli modelin ve gradyan yükseltme algoritması temelli modelin, bireysel öğrenme sınıfına ait olan k'nci mertebeden en yakın komşular algoritması temelli modelden daha düşük hata sonuçları ve daha yüksek r kare sonuçlarıyla daha başarılı tahminler yaptıkları görülmüştür. Ayrıca son olarak topluluk öğrenmesi sınıfının iki farklı grubundan biri olan yükseltme grubunun üyesi olan gradyan yükseltme algoritması temelli modelin, topluluk öğrenmesi sınıfının diğer bir grubu olan torbalama grubunun üyeleri olan rastgele orman algoritması temelli model ve ekstra ağaç algoritması temelli modelden daha düşük hata değerleri elde ederek daha yüksek doğrulukta tahminler yaptığı görülmüştür.

Sonuç olarak, rüzgâr türbinlerinin üretebilecekleri güçlerin tahmin edilmesi üzerinde yapılan çalışmalarda düşük hata değerleri ile yüksek doğrulukta tahminler yapılabilmesi için, topluluk öğrenmesi sınıfının torbalama, ve yükseltme gruplarına ve ek olarak bireysel öğrenme sınıfına üye algoritmalarından oluşturulacak alt modellerin birlikte kullanılmasıyla oluşturulacak karma modeller önerilmektedir.

7.2 Rüzgâr Santrallerinin Enerji Üretimlerinin İyileştirilebilmesi İçin Türbin Konumlarının Geliştirilen Modelle Belirlenmesi

Tezin bu kısmında İstanbul'da yer alan ve 16 adet rüzgâr türbini barındıran ve faal olarak elektrik üretiminde bulunan bir rüzgâr santralının verileri kullanılarak ilgili rüzgâr santralının yıllık enerji üretiminin iyileştirilmesi adına rüzgâr türbinlerinin arazi içerisindeki konumlarının belirlenmesi için bir model geliştirilmiştir. Geliştirilen modelde literatürde en çok kullanılan Jensen iz modeline bağımlı kalınarak hesaplamalarda bulunulmuştur. Öncelikle, geliştirilen modelin kıyaslanabilmesi adına rüzgâr santralının orijinal durumu ile ilgili yapılan incelemeler açıklanacak daha sonra geliştirilen model tanıtılıp sonuçları yorumlanacaktır.


Şekil 7.62 incelendiğinde çalışmada kullanılan rüzgâr santralının sahip olduğu rüzgâr türbinlerinin arazi içerisindeki dağılımları görülebilmektedir. Şekil 7.62’den anlaşılabacağı üzere rüzgâr santrali sınırları içerisinde 16 adet rüzgâr türbini bulunmakta ve bu türbinlerin birbirlerinin enerji potansiyelini engellememeleri adına çeşitli konumlarda birbirlerine göre belirli bir düzen içerisinde yerleştikleri görülmektedir. Ayrıca Çizelge 7.18 incelendiğinde rüzgâr santralında bulunan rüzgâr türbinlerinin üretebilecekleri güçler ve enerjiler görülebilir.




Şekil 7.62 : Verileri Kullanılan Rüzgâr Santralının Uydu Görüntüsü.

Çizelge 7.18 : Rüzgâr Türbinlerinin Üretebilecekleri Yıllık Güç ve Yıllık Enerji Değerleri.

Türbin Numarası	Üretilen Yıllık Güç (GW)	Üretilen Yıllık Enerji (GWh)
1	0.001019780040	8.933273148537
2	0.001001736760	8.775214018821
3	0.000997309685	8.736432838440
4	0.001009905338	8.846770763398
5	0.001012110233	8.866085643768
6	0.000984007835	8.619908638000
7	0.001010821342	8.854794960022
8	0.001008273125	8.832472572327
9	0.001007030487	8.821587066650
10	0.001016918182	8.908203277588
11	0.000891342163	7.808157348633
12	0.001007462502	8.825371513367
13	0.001010933876	8.855780754089
14	0.001004608154	8.800367431641
15	0.000993419647	8.702356109619
16	0.000953865051	8.355857849121
Toplam	0.015929524422	139.542633934021




Şekil 7.63 : Rüzgâr Türbinlerinin Yıllık Güç Üretimleri (GW).



Şekil 7.64 : Rüzgâr Türbinlerinin Yıllık Enerji Üretimleri (GWh).

Şekil 7.63 ve Şekil 7.64 incelendiklerinde rüzgâr türbinlerinin bir senelik rüzgâr hızı verileri baz alınarak yapılan hesaplamalarda üretebilecekleri bir senelik toplam güç ve bir senelik toplam enerji verilerine ulaşılabilir. Çizelge 7.18 incelendiğinde santralin yıllık güç üretiminin 15.9 GW, yıllık enerji üretiminin 139.542 GWh olduğu saptanmıştır. Rüzgâr türbinlerinin en fazla güç ve enerji üreteni 8.93 Gwh yıllık enerji üretimi değeri ve yıllık 1.01 GW güç üretimiyle 1 numaralı türbin olmuştur. Rüzgâr santralının en az güç ve enerji üretiminde bulunan türbini 0.89 GW güç değeri ve 7.80 GWh enerji üretimiyle 11 numaralı rüzgâr türbini olmuştur.

Rüzgâr santralının üretebilecekleri yıllık toplam güç ve yıllık toplam enerji değerlerinin iyileştirilmeleri adına geliştirilen modelin çalışma prensibi şekil 7.65'te gösterilmiştir.



Şekil 7.65 : Santralin Enerji Üretimini İyileştirmek İçin Geliştirilen Modelin Çalışma Mekanizması.

Şekil 7.65 incelendiğinde santraldeki türbin konumlarının belirlenmesi için geliştirilen modelin çalışma mekanizması incelenebilir. Geliştirilen model A ve B grubu olmak üzere iki blokta incelenebilir. A bloğunda verilen türbin koordinatları, rüzgâr hızı ve rüzgâr yönü bilgileri kullanılarak santralin üretebileceği senelik güç ve senelik enerji değerleri hesaplanmaktadır.

Geliştirilen modelin B bloğunda ise santralin enerji üretimini iyileştirmek adına mevcut türbinlerin santral arazisindeki konumları rüzgâr hızı ve rüzgâr yönü verileri kullanılarak yeniden belirlenir.


Santralin enerji üretimini iyileştirmek için geliştirilen modele göre belirlenen rüzgâr türbini konumları kullanıldığında rüzgâr türbinlerinin üretebilecekleri güç ve enerji değerlerine çizelge 7.19'dan ulaşılabilir.

Çizelge 7.19 : Geliştirilen Modelin Belirlediği Rüzgâr Türbini Konumlarına Göre Rüzgâr Santralının Üretebileceği Enerji ve Güç Değerleri.


Türbin Numarası	Üretilen Yıllık Güç (GW)	Üretilen Yıllık Enerji (GWh)
1	0.001019780040	8.933273148537
2	0.001019107223	8.927379269600
3	0.001019339561	8.929414558410
4	0.001019152880	8.927779226303
5	0.001018747330	8.924226608277
6	0.001017122746	8.909995250702
7	0.001017282486	8.911394577026
8	0.001017127991	8.910041198730
9	0.001017393112	8.912363662720
10	0.001017575264	8.913959312439
11	0.001017387390	8.912313537598
12	0.001013022423	8.874076423645
13	0.001013966560	8.882347068786
14	0.001013857841	8.881394691468
15	0.001014982224	8.891244277954
16	0.001015196800	8.893123970032
Toplam	0.016271041871	142.534326782227

Çizelge 7.19 incelendiğinde geliştirilen modelin belirlediği konumlara yerleştirilen rüzgâr türbinlerinin üretebilecekleri yıllık güç ve yıllık enerji verileri incelenebilir. Geliştirilen modelin belirlediği rüzgâr türbini konumları kullanıldığında rüzgâr santralının yıllık güç üretimi 16.2 GW ve yıllık enerji üretimi 142.534 GWh olmuştur. Geliştirilen modelin önerdiği türbin konumlarında en fazla güç ve enerji üretimi değerlerine 1.01 GW yıllık güç ve 8.93 GWh yıllık enerji üretimiyle 1 numaralı rüzgâr türbini ulaşmıştır. Her bir rüzgâr türbini incelendiğinde geliştirilen modelin önerdiği konumlarda ürettikleri güç ve enerji değerlerinin iyileştiği görülmüştür. En büyük iyileşmeyi %12.38'lik bir iyileşmeyle, 7.80 GWh yıllık enerji üretimi değerinden 8.91 GWh yıllık enerji üretimi değerine ulaşan 11 numaralı rüzgâr türbini göstermiştir.

Şekil 7.66 ve Şekil 7.67 incelendiklerinde rüzgâr türbinlerinin geliştirilen modelin belirlediği konumlardaki enerji üretimi ve güç üretimi verileri incelenebilir.




Şekil 7.66 : Yeni Türbin Konumlarında Rüzgâr Türbinlerinin Üretebilecekleri Yıllık Güçler (GW).



Şekil 7.67 : Yeni Türbin Konumlarında Rüzgâr Türbinlerinin Üretebilecekleri Yıllık Enerjiler (GWh).

Şekil 7.68 incelendiğinde Rüzgâr santralindeki rüzgâr türbinlerinin orijinal konumları ve geliştirilen modelin belirlediği konumlar incelenebilir.



Şekil 7.68 : Eski Türbin Konumları ve Yeni Türbin Konumları.

Şekil 7.68 incelendiğinde rüzgâr türbinlerinin orijinal konumları ve geliştirilen modelin santralin yıllık enerji üretimini iyileştirmek için belirlediği konumları görülmektedir. Mavi renkli konumlar rüzgâr türbinlerinin yeni konumlarını kırmızı renkli konumlar ise eski konumlarını ifade etmektedir.

Sonuç olarak bu kısımda İstanbul'da bulunan bir rüzgâr santralının verileri kullanılarak santralin yıllık enerji üretimini iyileştirmek için rüzgâr türbinlerinin konumlarını belirleyen bir model geliştirilmiştir. Geliştirilen model iki farklı alt modelden oluşmaktadır. İlk modelde, rüzgâr hızı, rüzgâr türbini konumları ve rüzgâr türbini güç eğrisi verileri kullanılarak santraldaki her bir rüzgâr türbininin

üretebilecekleri yıllık güçler ve yıllık enerjiler hesaplanmakta ve bu veriler toplanarak santralin toplam üretebileceği yıllık güç ve yıllık enerji verileri belirlenmektedir. Daha sonra yukarıda tanımlanan alt model diğer modelin içerisinde çalıştırılarak üretilen çeşitli rüzgâr türbini konumları için santralin üretebileceği yıllık güç ve yıllık enerji değerleri hesaplanmaktadır. Belirtilen iterasyon sayısına ya da enerji üretiminde bir değişim olmayana kadar model çalışmaktadır. Yukarıda alt modelleri açıklanan ve santralların enerji üretimini iyileştirmek için geliştirilen bu model orijinal pozisyonlarında 139.542 GWh yıllık enerji üretimi olan rüzgâr santralının türbin konumlarını yeniden belirleyerek yıllık enerji üretimini %2.1 iyileştirerek 142.534 GWh mertebesine ulaştırmıştır.



8. SONUÇLAR VE GELECEKTEKİ ÇALIŞMALAR İÇİN ÖNERİLER

Bu tez kapsamında rüzgâr türbinlerinin çeşitli rüzgâr hızı koşulları altında üretebilecekleri güçlerin makine öğrenmesi modelleri kullanılarak tahmin edilmesi ve rüzgâr türbini konumlarının rüzgâr santralının enerji üretimine etkisinin incelenmesi ile ilgili çalışmalar yapılmıştır. Yapılan çalışmalarda halen Türkiye’de faaliyette olan ve elektrik üreten iki farklı rüzgâr santralının verileri kullanılmıştır. Verileri kullanılan rüzgâr enerjisi firmalarının istekleri doğrultusunda rüzgâr türbinlerinin ürettikleri güç değerleri belirli bir çarpanla çarpılarak birimsiz olarak kullanılmışlardır. Bu nedenle tez kapsamında veri kategorisindeki tüm güç değerleri birimsiz olarak verilmiştir.

Yapılan bu çalışmalardan tez kapsamında elde edilen sonuçlar aşağıda maddeler halinde sunulmaktadır.

- I. Rüzgâr türbinlerinin çeşitli rüzgâr hızları altında üretebilecekleri güç değerlerinin tahmin edilmesi için 5 farklı makine öğrenmesi modeli oluşturulmuş ve her bir modelin hiper parametreleri düzenlenerek tahmin başarıları kıyaslanmıştır.
- II. Rüzgâr türbinlerinin çeşitli rüzgâr hızı koşullarında üretecekleri güçlerin tahmin edilmesi için geliştirilen ilk makine öğrenmesi modeli k’nci mertebeden en yakın komşular algoritması temelli modeldir. Hiper parametreleri düzenlenen bu model %99.14 doğrulukta tahmin başarısı elde etmiştir.
- III. Rüzgâr türbinlerinin çeşitli rüzgâr hızlarında üretebilecekleri güçlerin tahmin edilmesi için geliştirilen bir diğer model de makine öğrenmesinin topluluk öğrenmesi sınıfına mensup rastgele orman algoritması temelli modeldir. Hiper parametreleri düzenlenerek geliştirilen bu model %99.24 doğrulukta tahminlerde bulunmaktadır.
- IV. Ekstra ağaç algoritması temelli model rüzgâr türbinlerinin çeşitli rüzgâr hızı koşulları altında üretebilecekleri güçlerin tahmin edilmesi için geliştirilen bir

diğer modeldir. Ekstra ağaç algoritmali modelin düzenlenen hiper parametreleri sayesinde tahmin başarısı %99.17'dir.

- V. Gradyan yükseltme algoritması temelli model rüzgâr türbinlerinin üretebilecekleri güçleri tahmin edilmesi için geliştirilen modellerden biridir. Gradyan yükseltme algoritması temelli model hiper parametrelerinin düzenlenmesinden sonra %99.26 doğrulukta tahmin başarısı elde etmiştir.
- VI. Rüzgar türbinlerinin çeşitli rüzgar hızı koşulları altında üretebilecekleri güçlerin tahmin edilmesi için geliştirilen en son model, II, III, IV ve V numaralı maddelerde açıklanan k'nci mertebeden en yakın komşular algoritması temelli modeli, rastgele orman algoritması temelli modeli, ekstra ağaç algoritması temelli modeli, ve gradyan yükseltme algoritması temelli modeli alt model olarak çalıştıran karma modeldir. Karma model %99.49 doğrulukta tahmin başarısına ulaşmıştır.
- VII. Tez kapsamında araştırılan ilk konu olan rüzgar türbinlerinin çeşitli rüzgar hızı şartları altında üretebilecekleri güçleri tahmin edilmesi çalışmasında en başarılı sonucu %99.49 tahmin doğruluğu başarısına ulaşan karma model yakalamıştır. Karma modeli %99.26, %99.24, %99.17 ve %99.14 doğruluk değerleriyle sırasıyla, gradyan yükseltme algoritması temelli model, rastgele orman algoritması temelli model, ekstra ağaç algoritması temelli model ve k'nci mertebeden en yakın komşular algoritması temelli model takip etmektedir.
- VIII. Tez kapsamında araştırılan bir diğer konu da rüzgâr türbinlerinin konumlarının rüzgâr santrallarının enerji üretimindeki etkileridir. Bu çalışma kapsamında rüzgâr santrallarının yıllık enerji üretimlerini hesaplayan ve daha sonrasında türbin konumlarını değiştirerek türbinin arka iz tesirini minimize eden ve yıllık enerji üretimlerini iyileştirmeye çalışan bir model geliştirilmiştir.
- IX. Rüzgâr santrallarının yıllık enerji üretimini iyileştirmek amacıyla türbin konumlarını belirlemek için geliştirilen modelin sonuçlarına göre, verileri kullanılan rüzgâr santralının türbinlerinin, modelin önerdiği türbin konumlarına yerleştirilmesi durumunda santralın yıllık enerji üretimi %2.1 GWh artmaktadır.

Yukarıda maddeler halinde açıklanan sonuçlarda, rüzgâr enerjisinin etkin bir şekilde kullanılması üzerine enerji firmalarının ihtiyaçlarına karşılık verebilecek makine

öğrenmesi modelleri geliştirilmiş ve başarıları faal olarak elektrik üretiminde bulunan rüzgâr santrallerinin verileri kullanılarak kanıtlanmıştır. Bu sebeple bu tez kapsamında yapılan çalışmaların ve elde edilen sonuçların gelecekteki çalışmalara ışık tutacağı ve öncülük edeceği düşünülmektedir.

Rüzgâr enerjisinin efektif bir şekilde kullanımını sağlamak adına gelecekte yapılacak olan çalışmalarda, bu tez kapsamında değerlendirilen rüzgâr hızı, rüzgâr yönü, teorik olarak üretilebilecek güç değerleri, gerçekte rüzgâr türbinleri tarafından üretilen güç değerleri, rüzgâr türbini konumları gibi parametrelere ek olarak, rüzgâr santralının kurulduğu arazinin topografik özellikleri, rüzgâr türbinlerinin çalıştırıldığı hava sıcaklıkları, nem koşulları gibi çevresel etkenlerin, türbinlerin arkasındaki iz bölgesinin tesirinin de göz önünde bulundurulması önerilmektedir.

Tüm bunlara ek olarak bu tez kapsamında yürütülen çalışmaların sonucuna dayanarak rüzgâr enerjisinin ülkelerin enerji konusunda dışa bağımlılıklarının azaltılmasında son derece elzem bir role sahip olduğu belirtilmelidir. Bu sebeple ülkelerin kendi milli varlıklarını sürdürebilmeleri adına rüzgâr enerjisine gereken önemi vermeleri gerekmektedir. Ayrıca rüzgâr enerjisini önce mekanik enerjiye ve daha sonra elektrik enerjisine çevirmek için kullanılan rüzgâr türbinlerinin de ülkelerin kendi imalatı olması ülkelerin milli kaynaklarının yurt içinde kalmasını ve toplumsal kalkınmayı olumlu yönde etkileyeceğinden yerli rüzgâr türbini üretiminin yadsınamaz önemi göz ardı edilmemelidir.



KAYNAKLAR

- [1] **Yıldız, S. S. (2021).** Balıkesir İli Rüzgâr Hızı Haritalarının Hazırlanması ve Rüzgâr Enerjisi Potansiyeli Açısından İncelenmesi. *Geomatik*. <https://doi.org/10.29128/geomatik.737567>.
- [2] **Kaya, K., Şenel, M. C., & Koç, E. (2018).** DÜNYADA VE TÜRKİYE'DE YENİLENEBİLLER ENERJİ KAYNAKLARININ DEĞERLENDİRİLMESİ. *NWSA Academic Journals*, 13(3), 219-234. <https://doi.org/10.12739/NWSA.2018.13.3.2A0152>
- [3] **Uyar, T. S., (2001).** Enerji Sorunu nedir? Alternatif Enerji çözüm müdür? . NEU-CEE 2001 Electrical, Electronics Computer Engineering Symposium and Exhibition (pp.23-26). Lefkoşa, Cyprus (Kktc)
- [4] **Url-1** < <https://enerji.gov.tr/bilgi-merkezi-enerji-ruzgar> >, Erişim tarihi: 25.12.2022.
- [5] **BP.,(2021).** BP Statistical Review Of World Energy 71th Edition. <https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/statistical-review/bp-stats-review-2021-full-report.pdf>, Erişim Tarihi: 25.12.2022.
- [6] **İlkılıç, C. (2003).** RÜZGÂR ENERJİSİ VE KULLANIMI . Fırat Üniversitesi Doğu Araştırmaları Dergisi , 2 (1) , 44-48 . Retrieved from <https://dergipark.org.tr/tr/pub/fudad/issue/46988/589824>
- [7] **Özdamar, A., (2000).** Dünya ve Türkiye'de rüzgâr enerjisinden yararlanılması üzerine bir araştırma, *Mühendislik Bilimleri Dergisi*, 6(2-3), 133 – 145.
- [8] **Elibüyük, U., Yakut, A. K., & Üçgül, İ. (2016).** Süleyman Demirel Üniversitesi Rüzgâr Enerjisi Santrali Projesi. *Yekarum* , 3 (2)
- [9] **Özgener, Ö. (2002).** Türkiye’de ve Dünya’da Rüzgâr Enerjisi Kullanımı, *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 4 (3) , 159-173.
- [10] **Kaya, H. İ. (2020).** Birleşik Krallık Açık Deniz Rüzgâr Enerjisi Politikalarının Değerlendirilmesi ve Türkiye İçin Politika Önerileri, *Niğde Ömer Halisdemir Üniversitesi Sosyal Bilimler Enstitüsü Dergisi* , 2 (2) , 138-157
- [11] **Demircan, N. & Bayraktar, B. (2020).** Rüzgâr Enerjisi ve Balıkesir Bölgesindeki Potansiyeli, *Balıkesir Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* , 1 (2) , 84-105.

- [12] **Gipe, P., & Möllerström, E. (2022).** An overview of the history of wind turbine development: Part I—The early wind turbines until the 1960s. *Wind Engineering*, 46(6), 1973-2004. <https://doi.org/10.1177/0309524X221117825>
- [13] **Manwell J. F. McGowan J. G. & Rogers A. L. (2009).** Wind energy explained : theory design and application (2nd ed.). Wiley.
- [14] **Gipe, P., & Möllerström, E. (2022).** An overview of the history of wind turbine development: Part II—The 1970s onward. *Wind Engineering*, 0309524X2211225. <https://doi.org/10.1177/0309524X221122594>
- [15] **Akdağ, SA., Güler, O., (2010).** Evaluation of wind energy investment interestand electricity generation cost analysis for Turkey. *Applied Energy*, vol. 87, p. 2574–2580, DOI:10.1016/j.apenergy.2010.03.015.
- [16] **Bacak, S. , Külcü, R. & Ekinci, K. (2009).** Türkiye ve AB Ülkelerinde Yenilenebilir Enerji Kaynakları Politikaları ve Hedefler . *Tarım Makinaları Bilimi Dergisi*, 5 (1), 9-14.
- [17] **Malkoç, Y., (2007).** Türkiye Elektrik Enerjisi İhtiyacının Karşılmasında Rüzgâr Enerjisinin Yeri, EİE İdaresi Genel Müdürlüğü, Sayı 3, sayfa 45–50.
- [18] **Akusta, E., & Cergibozan, R. (2020).** Yenilenebilir Enerji ve Ekonomik Büyümenin Çevre Üzerindeki Etkisi: Türkiye Örneği, *Öneri Dergisi*, <https://doi.org/10.14783/maruoneri.771658>
- [19] **Url-2**< <https://www.tureb.com.tr/>>, Erişim tarihi: 25.12.2022.
- [20] **Kocatürk, A. S. & Ünsan, Y. (2015).** Rüzgâr Enerji Santrallerinin Tarihsel Gelişimi ve Açık Deniz Rüzgâr Enerji Santrallerinin Tipleri, *GİDB Dergi*, (02) , 3-16 .
- [21] **Durak, M., Özer, S., (2012).** Rüzgâr Enerjisi: Teori ve Uygulama (2. Baskı), Enermet.
- [22] **Yılmaz, İ. , Çam, Ö. , Taştan, M. & Karıcı, A. (2016).** Farklı Rüzgâr Türbin Kanat Profillerinin Aerodinamik Performansının Deneysel İncelenmesi . *Politeknik Dergisi* , 19 (4) , 577-584 .
- [23] **Pisanò, F. (2019).**Input of advanced geotechnical modelling to the design of offshore wind turbine foundations. In: *European Conference on Soil Mechanics and Geotechnical Engineering - ECSMGE2019, Reykjavik. Proceedings... Icelandic Geotechnical Society (IGS).*
- [24] **Elilibüyük, U. & Üçgül, İ. (2014).** Rüzgâr Türbinleri, Çeşitleri Ve Rüzgâr Enerjisi Depolama Yöntemleri . *Yekarum* , 2 (3) .
- [25] **Aslam Bhutta, M. M., Hayat, N., Farooq, A. U., Ali, Z., Jamil, Sh. R., & Hussain, Z. (2012).** Vertical axis wind turbine – A review of various configurations and design techniques. *Renewable and Sustainable*

- [26] **Url-3**< <https://www.nordex-online.com/en/product/n131-3600/>>, Erişim tarihi: 25.12.2022.
- [27] **Url-4**< <https://windside.com/gallery/>>, Erişim tarihi: 25.12.2022.
- [28] **Canpolat, Ş., (2013).** Rüzgâr Enerjisi ve Isparta Şartlarında Prototip Bir Rüzgâr Türbini Tasarımı (yüksek lisans tezi), Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Isparta.
- [29] **Url-5**< <https://www.goldwind.com/en/>>, Erişim tarihi: 25.12.2022.
- [30] **Nurbay, N., Çınar, A., (2005).** Rüzgâr Türbinlerinin Çeşitleri ve Birbirleriyle Karşılaştırılması. Retrieved from [https:// www.emo.org.tr / ekler / 4986d86a17424ee_ek .pdf](https://www.emo.org.tr/ekler/4986d86a17424ee_ek.pdf), Erişim Tarihi: 25.12.2022
- [31] **Kurt, G., (2011).** Dişli Kutulu ve Dişli Kutusuz Rüzgâr Türbini-Generatör Sistemlerinin Karşılaştırılması. Elektrik-Elektronik ve Bilgisayar Sempozyumu, 5-7 Ekim, Elazığ, 112115.
- [32] **Huvaj, N., Caceoğlu, E., Baidol, Y., (2019).** Deniz Üstü Rüzgâr Türbinleri: Temel Tipi Seçimi ve Deniz Tabanı Zemin Araştırmaları, 3-5 Ekim 2019, İzmir.
- [33] **Url-6**<<https://windeurope.org/about-wind/wind-energy-today/>>, Erişim tarihi: 25.12.2022.
- [34] **Nikolaou N (2018).** Deep Water Offshore Wind Technologies (Yüksek Lisans Tezi), University of Strathclyde, Energy System and Environment , Glasgow.
- [35] **Url-7** < <https://www.umass.edu/windenergy/about/history/alumni> >, Erişim tarihi: 25.12.2022.
- [36] **Url-8** < [https:// web.archive.org /web /20100527173013](https://web.archive.org/web/20100527173013/) >, Erişim tarihi: 25.12.2022.
- [37] **Petrescu, R. V. V., Aversa, R., Aonio, A., & Petrescu, F. I. T. (2017).** GREEN ENERGY TO PROTECTING THE ENVIRONMENT/ ENERGIA VERDE PARA PROTEGER O MEIO AMBIENTE. Revista Gestão Inovação e Tecnologias, 7(1), 3722-3743. <https://doi.org/10.7198/S2237-072220170001011>
- [38] **Url-9** < https://www.farmshow.com/a_article.php?aid=4771>, Erişim tarihi: 25.12.2022.
- [39] **De Lellis, M., Reginatto, R., Saraiva, R., & Trofino, A. (2018).** The Betz limit applied to Airborne Wind Energy. Renewable Energy, 127, 32-40. <https://doi.org/10.1016/j.renene.2018.04.034>

- [40] **Örgen, F. K., Dikmen, E., & Tuncer, A. D. (t.y.).(2019).** Statistical analysis of Wind Energy Potential of Ağlasun, Turkey, ECSAC'19 IVth EUROPEAN CONFERENCE ON SCIENCE, ARTCULTURE,537-542.
- [41] **Bairamvand, R., Motevalli, S., Ghobadi, G. J., & Derafshi, K. (2022).** Analysis of the Characteristics of Wind Power and Topography Influence on It, With an Approach to Renewable Energy Generation (Synoptic Meteorological Stations of Mazandaran Province—Northern Iran) [Preprint]. In Review. <https://doi.org/10.21203/rs.3.rs-1266604/v1>
- [42] **Counihan, J. (1975).** Adiabatic atmospheric boundary layers: A review and analysis of data from the period 1880-1972, *Atmospheric Environment*, vol. 9, no. 10, pp. 871–905. doi:10.1016/0004-6981(75)90088-8.
- [43] **D.A. (2009).** Wind turbine technology : fundamental concepts of wind turbine engineering, Second Edition, ASME Press, Doi: <https://doi.org/10.1115/1.802601>.
- [44] **Sun, H., Gao, X., & Yang, H. (2020).** A review of full-scale wind-field measurements of the wind-turbine wake effect and a measurement of the wake-interaction effect. *Renewable and Sustainable Energy Reviews*, 132, 110042. <https://doi.org/10.1016/j.rser.2020.110042>
- [45] **Hasager, C., Rasmussen, L., Peña, A., Jensen, L., & Réthoré, P.-E. (2013).** Wind Farm Wake: The Horns Rev Photo Case. *Energies*, 6(2), 696-716. <https://doi.org/10.3390/en6020696>.
- [46] **Jensen, N. O. (1983).** A note on wind generator interaction, Risø National Laboratory, ISSN:0418-6435
- [47] **Katic, I., Højstrup, J., & Jensen, N. O. (t.y.). (1987)** A SIMPLE MODEL FOR CLUSTER EFFICIENCY, EWEC'86. Proceedings. Vol. 1.
- [48] **Shakoor, R., Hassan, M. Y., Raheem, A., & Wu, Y.-K. (2016).** Wake effect modeling: A review of wind farm layout optimization using Jensen's model. *Renewable and Sustainable Energy Reviews*, 58, 1048-1059. <https://doi.org/10.1016/j.rser.2015.12.229>
- [49] **N. Moskalenko, K. Rudion and A. Orths, (2010).** Study of wake effects for offshore wind farm planning, 2010 Modern Electric Power Systems, pp. 1-7.
- [50] **Mosetti, G., Poloni, C., & Diviacco, B. (1994).** Optimization of wind turbine positioning in large windfarms by means of a genetic algorithm. *Journal of Wind Engineering and Industrial Aerodynamics*, 51(1), 105-116. [https://doi.org/10.1016/0167-6105\(94\)90080-9](https://doi.org/10.1016/0167-6105(94)90080-9)
- [51] **Dabbabi, A., Bourguet, S., Loisel, R., & Machmoum, M. (2020).** Offshore wind farm layout optimization considering wake effects. 2020 22nd

European Conference on Power Electronics and Applications, P.1-P.10.
<https://doi.org/10.23919/EPE20ECCEEurope43536.2020.9215642>.

- [52] **Hoxha, B., Shesho, I. K., & Filkoski, R. V. (2022).** Analysis of Wind Turbine Distances Using a Novel Techno-Spatial Approach in Complex Wind Farm Terrains. *Sustainability*, 14(20), 13688. <https://doi.org/10.3390/su142013688>
- [53] **Nguyen, T., Toubeau, J.-F., Jaeger, E. D., & Vallee, F. (2021).** Machine Learning Proxies Integrating Wake Effects in Offshore Wind Generation for Adequacy Studies, 2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), 1-6. <https://doi.org/10.1109/EEEIC/ICPSEurope51590.2021.9584611>.
- [54] **Al Shereiqi, A, Mohandes, B, Al-Hinai, A, Bakhtvar, M, Al-Abri, R, El-Moursi, M, Albadi, M., (2021).** Co-optimisation of wind farm micro-siting and cabling layouts. *IET Renew. Power Gener.* 1848– 1860. <https://doi.org/10.1049/rpg2.12154>.
- [55] **Charles, M., Oyedokun, D. T. O., & Dlodlo, M. (2020).** Wind Farm Density Effects on Turbulence Intensity for Large Hexagonal Farm Arrays. 2020 6th IEEE International Energy Conference (ENERGYCon), 1-6. <https://doi.org/10.1109/ENERGYCon48941.2020.9236441>
- [56] **Kumar, S., Saket, R. K., Dheer, D. K., Sanjeevikumar, P., Holm-Nielsen, J. B., & Blaabjerg, F. (2021).** Layout optimisation algorithms and reliability assessment of wind farm for microgrid integration: A comprehensive review. *IET Renewable Power Generation*, 15(10), 2063-2084. <https://doi.org/10.1049/rpg2.12060>.
- [57] **Hayat, I., Chatterjee, T., Liu, H., Peet, Y. T., & Chamorro, L. P. (2019).** Exploring wind farms with alternating two- and three-bladed wind turbines. *Renewable Energy*, 138, 764-774. <https://doi.org/10.1016/j.renene.2019.01.123>
- [58] **Chatterjee, T., & Peet, Y. (2019).** Exploring the benefits of vertically staggered wind farms: Understanding the power generation mechanisms of turbines operating at different scales. *Wind Energy*, 22(2), 283-301. <https://doi.org/10.1002/we.2284>
- [59] **Stanley, A. P. J., Ning, A., & Dykes, K. (2019).** Optimization of turbine design in wind farms with multiple hub heights, using exact analytic gradients and structural constraints. *Wind Energy*, 22(5), 605-619. <https://doi.org/10.1002/we.2310>
- [60] **Wu, Y.-T., Liao, T.-L., Chen, C.-K., Lin, C.-Y., & Chen, P.-W. (2019).** Power output efficiency in large wind farms with different hub heights and configurations. *Renewable Energy*, 132, 941-949. <https://doi.org/10.1016/j.renene.2018.08.051>

- [61] **Alagöz, İ. (2021).** Rüzgâr elektrik santrallerinin kontrolü için kullanılabilecek doğrulamalı kod kütüphanesi geliştirilmesi, El-Cezeri Fen ve Mühendislik Dergisi, <https://doi.org/10.31202/ecjse.881359>
- [62] **Ataseven, M.S., Ataseven, S.,(2007).** Senkron Rüzgâr Türbinleri ve Kontrol Sistemleri, Elektrik Mühendisleri Odası 4. Otomasyon Sempozyumu.
- [63] **Yeter. P., (2011).** Rüzgâr Karakteristiği ve Enerjisine Etki Eden Faktörlerin İncelenmesi(yüksek lisans tezi), İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- [64] **Burton, T., Jenkins, N., Sharpe, D., Bossanyi, E.,(2001).** Wind Energy Handbook. John Wiley & Sons, Ltd., Hoboken.
- [65] **Nak, H., (2013).** Değişken Hızlı Değişken Açılı Rüzgâr Türbinlerinin Kontrolü (yüksek lisans tezi), İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü,İstanbul.
- [66] **Alpaydın, E., (2016).** Machine Learning The New AI, MIT Press, London, England.
- [67] **Alpaydın, E., (2011).** Yapay Öğrenme, Boğaziçi Üniversitesi Yayınevi, İstanbul, Türkiye.
- [68] **Özdemir, Ş. & Örsülü, S. (2019).** Makine Öğrenmesinde Yeni Bir Bakış Açısı: Otomatik Makine Öğrenmesi (AutoML) . Journal of Information Systems and Management Research , 1 (1) , 23-30 .
- [69] **Sarızeybek, A. T., & Seveli, O. (2022).** A Comparative Analysis of Bank Customers' Loan Propensity Using Machine Learning Methods. Journal of Intelligent Systems: Theory and Applications, 5(2), 137-144. <https://doi.org/10.38016/jista.1036047>
- [70] **Acı, M., & Ayyıldız Doğanşoy, G. (2021).** Makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak e-perakende sektörüne yönelik talep tahmini. Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi. <https://doi.org/10.17341/gazimmfd.944081>
- [71] **Saygın, E., & Baykara, M. (2021).** Karaciğer Yetmezliği Teşhisinde Özellik Seçimi Kullanarak Makine Öğrenmesi Yöntemlerinin Başarılarının Ölçülmesi. Fırat Üniversitesi Mühendislik Bilimleri Dergisi. <https://doi.org/10.35234/fumbd.832264>
- [72] **Kızılkaya, Y. M., & Oğuzlar, A. (2018).** BAZI DENETİMLİ ÖĞRENME ALGORİTMALARININ R PROGRAMLAMA DİLİ İLE KIYASLANMASI. Dergi Karadeniz, 37(37), 90-98. <https://doi.org/10.17498/kdeniz.405746>
- [73] **Kapucu, C., & Çubukçu, M. (2019).** Fotovoltaik Sistemlerde Topluluk Öğrenmesi Temelli Hata Tespiti. Bilişim Teknolojileri Dergisi, 12(2), 83-91. <https://doi.org/10.17671/gazibtd.508475>

- [74] **Cover, T., & Hart, P. (1967).** Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21-27. <https://doi.org/10.1109/TIT.1967.1053964>
- [75] **Du, S., & Li, J. (2019).** Parallel Processing of Improved KNN Text Classification Algorithm Based on Hadoop. 2019 7th International Conference on Information, Communication and Networks (ICICN), 167-170. <https://doi.org/10.1109/ICICN.2019.8834973>
- [76] **Metin, S. (2021).** OECD Endüstriyel Üretim Verilerinde Bulunan Kayıp Verilerin kNN Yöntemi İle Tahmini. *Anemon Muş Alparslan Üniversitesi Sosyal Bilimler Dergisi*. <https://doi.org/10.18506/anemon.888642>
- [77] **Idri, A., Abnane, I., & Abran, A. (2016).** Missing data techniques in analogy-based software development effort estimation. *Journal of Systems and Software*, 117, 595-611. <https://doi.org/10.1016/j.jss.2016.04.058>
- [78] **Chomboon, K., Chujai, P., Teerarassammee, P., Kerdprasop, K., & Kerdprasop, N. (2015).** An Empirical Study of Distance Metrics for k-Nearest Neighbor Algorithm. *The Proceedings of the 2nd International Conference on Industrial Application Engineering 2015*, 280-285. <https://doi.org/10.12792/iciae2015.051>
- [79] **Morrison, R., Liu, X., & Lin, Z. (2022).** Anomaly detection in wind turbine SCADA data for power curve cleaning. *Renewable Energy*, 184, 473-486. <https://doi.org/10.1016/j.renene.2021.11.118>
- [80] **Chen, C.-R., & Kartini, U. (2017).** K-Nearest Neighbor Neural Network Models for Very Short-Term Global Solar Irradiance Forecasting Based on Meteorological Data. *Energies*, 10(2), 186. <https://doi.org/10.3390/en10020186>
- [81] **Yesilbudak, M., Kabalci, E., Sagioglu, S., & Colak, I. (2013).** Very short term pitch angle optimization in wind turbines: A machine learning approach. 4th International Conference on Power Engineering, Energy and Electrical Drives, 886-889. <https://doi.org/10.1109/PowerEng.2013.6635727>
- [82] **Hendouzi, A. E., & Bourouhou, A. (2017).** Contribution to the Management of Microgrids by the Application of Short Term Photovoltaic Power Forecasting. 2017 International Renewable and Sustainable Energy Conference (IRSEC), 1-6. <https://doi.org/10.1109/IRSEC.2017.8477310>
- [83] **Demirtas, M., Yesilbudak, M., Sagioglu, S., & Colak, I. (2012).** Prediction of solar radiation using meteorological data. 2012 International Conference on Renewable Energy Research and Applications (ICRERA), 1-4. <https://doi.org/10.1109/ICRERA.2012.6477329>

- [84] **Kusiak, A., Zheng, H., & Song, Z. (2009).** Models for monitoring wind farm power. *Renewable Energy*, 34(3), 583-590. [https:// doi.org/ 10.1016/j.renene.2008.05.032](https://doi.org/10.1016/j.renene.2008.05.032)
- [85] **Yesilbudak, M., Sagioglu, S., & Colak, I. (2017).** A novel implementation of kNN classifier based on multi-tupled meteorological input data for wind power prediction. *Energy Conversion and Management*, 135, 434-444. <https://doi.org/10.1016/j.enconman.2016.12.094>
- [86] **An, J., Chen, Z., Wu, M., She, J., & Ding, M. (2018).** A Multi-Source Wind Speed Fusion Method for Wind Power Prediction Based on kNN-SVR. *IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*, 4245-4250. <https://doi.org/10.1109/IECON.2018.8591552>
- [87] **Yesilbudak, M., Sagioglu, S., & Colak, I. (2015).** A novel intelligent approach for yaw position forecasting in wind energy systems. *International Journal of Electrical Power & Energy Systems*, 69, 406-413. <https://doi.org/10.1016/j.ijepes.2015.01.030>
- [88] **Pedro, H. T. C., Lim, E., & Coimbra, C. F. M. (2018).** A database infrastructure to implement real-time solar and wind power generation intra-hour forecasts. *Renewable Energy*, 123, 513-525. <https://doi.org/10.1016/j.renene.2018.02.043>
- [89] **Mehr, A. D., Farhangi, R., & Ghiasi, A. R. (2021).** The Validity of Deep Learning Computational Model for Wind Speed Simulation. 2021 7th International Conference on Control, Instrumentation and Automation (ICCIA), 1-5. <https://doi.org/10.1109/ICCIA52082.2021.9403583>
- [90] **Eyecioglu, O., Hangun, B., Kayisli, K., & Yesilbudak, M. (2019).** Performance Comparison of Different Machine Learning Algorithms on the Prediction of Wind Turbine Power Generation. 2019 8th International Conference on Renewable Energy Research and Applications (ICRERA), 922-926. <https://doi.org/10.1109/ICRERA47325.2019.8996541>
- [91] **Wen, Y., Song, M., & Wang, J. (2016).** A combined AR-kNN model for short-term wind speed forecasting. 2016 IEEE 55th Conference on Decision and Control (CDC), 6342-6346. <https://doi.org/10.1109/CDC.2016.7799245>
- [92] **Ahmad, T., Manzoor, S., & Zhang, D. (2021).** Forecasting high penetration of solar and wind power in the smart grid environment using robust ensemble learning approach for large-dimensional data. *Sustainable Cities and Society*, 75, 103269. <https://doi.org/10.1016/j.scs.2021.103269>
- [93] **Demolli, H., Dokuz, A. S., Ecemis, A., & Gokcek, M. (2019).** Wind power forecasting based on daily wind speed data using machine learning

- algorithms. *Energy Conversion and Management*, 198, 111823. <https://doi.org/10.1016/j.enconman.2019.111823>
- [94] **Breiman, L. (2001).** Random Forests, *Machine Learning* 45, 5–32 <https://doi.org/10.1023/A:1010933404324>
- [95] **Archer, K. J., & Kimes, R. V. (2008).** Empirical characterization of random forest variable importance measures. *Computational Statistics & Data Analysis*, 52(4), 2249-2260. <https://doi.org/10.1016/j.csda.2007.08.015>
- [96] **Ekelik, H. & Altaş, D. (2019).** DİJİTAL REKLAM VERİLERİNDEN YARARLANARAK POTANSİYEL KONUT ALICILARININ RASTGELE ORMAN YÖNTEMİYLE SINIFLANDIRILMASI . *Journal of Research in Economics* , 3 (1) , 28-45.
- [97] **Zhou, Z., Li, X., & Wu, H. (2016).** Wind Power Prediction based on Random Forests. *Proceedings of the 2016 4th International Conference on Electrical & Electronics Engineering and Computer Science (ICEEECS 2016)*. 2016 4th International Conference on Electrical & Electronics Engineering and Computer Science (ICEEECS 2016), Jinan, China. <https://doi.org/10.2991/iceeecs-16.2016.73>
- [98] **Yürek, Ö., Birant, D., & Yürek, İ. (2021).** Makine Öğrenmesi Algoritmalarını Kullanarak Rüzgâr Enerjisi Üretimi Tahmini. *Deu Muhendislik Fakültesi Fen ve Muhendislik*, 23(67), 107-119. <https://doi.org/10.21205/deufmd.2021236709>
- [99] **Sun, Z., Sun, H., & Zhang, J. (2018).** Multistep Wind Speed and Wind Power Prediction Based on a Predictive Deep Belief Network and an Optimized Random Forest. *Mathematical Problems in Engineering*, 2018, 1-15. <https://doi.org/10.1155/2018/6231745>
- [100] **Drisya, G. V., Asokan, K., & Kumar, K. S. (2022).** Wind speed forecast using random forest learning method, *International Journal on Computer Science and Engineering (IJCSE)*, <https://doi.org/10.48550/arXiv.2203.14909>.
- [101] **Alonso, Á., Torres, A., & Dorronsoro, J. R. (2015).** Random Forests and Gradient Boosting for Wind Energy Prediction. *İçinde E. Onieva, I. Santos, E. Osaba, H. Quintián, & E. Corchado (Ed.), Hybrid Artificial Intelligent Systems (C. 9121, ss. 26-37)*. Springer International Publishing. https://doi.org/10.1007/978-3-319-19644-2_3
- [102] **Beyer, H., Revheim, p., (2014).** Using Random Forests for Wind Power Ramp Forecasting, *EWEA 2014*, Barcelona, Spain.
- [103] **Shi, K., Qiao, Y., Zhao, W., Wang, Q., Liu, M., & Lu, Z. (2018).** An improved random forest model of short-term wind-power forecasting to enhance accuracy, efficiency, and robustness. *Wind Energy*, 21(12), 1383-1394. <https://doi.org/10.1002/we.2261>.

- [104] **Lahouar, A., & Ben Hadj Slama, J. (2017).** Hour-ahead wind power forecast based on random forests. *Renewable Energy*, 109, 529-541. <https://doi.org/10.1016/j.renene.2017.03.064>
- [105] **Iannace, G., Ciaburro, G., & Trematerra, A. (2019).** Wind Turbine Noise Prediction Using Random Forest Regression. *Machines*, 7(4), 69. <https://doi.org/10.3390/machines7040069>
- [106] **Natarajan, V. A., & Kumari, N. S. (2019).** Wind Power Forecasting Using Parallel Random Forest Algorithm. *Soft Computing for Problem Solving*, 209–224. https://doi.org/10.1007/978-981-15-0035-0_16.
- [107] **Tubulekas, A. (2022).** Exploring Machine Learning Techniques for Short-Term Wind Power Forecasting of Multiple Wind Parks (Dissertation). Retrieved from <http://urn.kb.se/resolve?urn=urn:nbn:se:uu:diva-481472>
- [108] **Wenting, Z., Jie, L., Yalong, L., & Yingyu, L. (2021).** Short-term wind power forecasting model based on random forest algorithm and TCN. 2021 40th Chinese Control Conference (CCC), 5776-5781. <https://doi.org/10.23919/CCC52363.2021.9550052>
- [109] **Liu, D., & Sun, K. (2019).** Random forest solar power forecast based on classification optimization. *Energy*, 187, 115940. <https://doi.org/10.1016/j.energy.2019.115940>
- [110] **Geurts, P., Ernst, D., & Wehenkel, L. (2006).** Extremely randomized trees. *Machine Learning*, 63(1), 3-42. <https://doi.org/10.1007/s10994-006-6226-1>
- [111] **Emanet, S., Karataş Aydoğmuş, G., & DemiR, Ö. (2021).** Öznitelik Seçme Yöntemlerinin Makine Öğrenmesi Tabanlı Saldırı Tespit Sistemi Performansına Etkileri. *DÜMF Mühendislik Dergisi*, 743-755. <https://doi.org/10.24012/dumf.1051340>
- [112] **Ahmad, M. W., Reynolds, J., & Rezgui, Y. (2018).** Predictive modelling for solar thermal energy systems: A comparison of support vector regression, random forest, extra trees and regression trees. *Journal of Cleaner Production*, 203, 810-821. <https://doi.org/10.1016/j.jclepro.2018.08.207>
- [113] **Malakouti, S. M. (2022).** Use machine learning algorithms to predict turbine power generation to replace renewable energy with fossil fuels. *Energy Exploration & Exploitation*, 014459872211381. <https://doi.org/10.1177/01445987221138135>
- [114] **Tang, M., Chen, Y., Wu, H., Zhao, Q., Long, W., Sheng, V. S., & Yi, J. (2021).** Cost-Sensitive Extremely Randomized Trees Algorithm for Online Fault Detection of Wind Turbine Generators. *Frontiers in Energy Research*, 9, 686616. <https://doi.org/10.3389/fenrg.2021.686616>

- [115] **Meddage, D. P. P., Ekanayake, I. U., Weerasuriya, A. U., & Lewangamage, C. S. (2021).** Tree-based Regression Models for Predicting External Wind Pressure of a Building with an Unconventional Configuration. 2021 Moratuwa Engineering Research Conference (MERCon), 257-262. [https:// doi.org/ 10.1109/ MERCon 52712.2021. 9525734](https://doi.org/10.1109/MERCon52712.2021.9525734)
- [116] **Mintemur, O., & Gurkaynak, I. A. (2022).** Daily Energy Usage Estimation Using Regression Based Ensemble Methods. 2022 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA), 1-5. [https:// doi.org/ 10.1109/ HORA55278. 2022.9799942](https://doi.org/10.1109/HORA55278.2022.9799942)
- [117] **Alkawaz, A. N., Abdellatif, A., Kanesan, J., Khairuddin, A. S. M., & Gheni, H. M. (2022).** Day-Ahead Electricity Price Forecasting Based on Hybrid Regression Model. IEEE Access, 10, 108021-108033. <https://doi.org/10.1109/ACCESS.2022.3213081>
- [118] **Abdellatif, A., Mubarak, H., Ahmad, S., Hammoudeh, A., Mekhilef, S., & Mokhlis, H. (2022).** Forecast of Solar Photovoltaic Power Output Based on Polycrystalline Panel-based Employing Various Ensemble Machine Learning Methods. 2022 IEEE Global Conference on Computing, Power and Communication Technologies (GlobConPT), 1-6. [https:// doi.org/ 10.1109/GlobConPT57482.2022.9938348](https://doi.org/10.1109/GlobConPT57482.2022.9938348)
- [119] **Malakouti, S. M., & Ghiasi, A. R. (2022).** Evaluation of the Application of Computational Model Machine Learning Methods to Simulate Wind Speed in Predicting the Production Capacity of the Swiss Basel Wind Farm. 2022 26th International Electrical Power Distribution Conference (EPDC), 31-36. <https://doi.org/10.1109/EPDC56235.2022.9817304>
- [120] **Friedman, J. H. (2001).** Greedy function approximation: A gradient boosting machine. The Annals of Statistics, 29(5). [https:// doi.org/ 10.1214/aos/1013203451](https://doi.org/10.1214/aos/1013203451)
- [121] **Alshari, H., Saleh, A., Odabaş, A., (2021).** Comparison of Gradient Boosting Decision Tree Algorithms for CPU Performance, Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi, Cilt 37, Sayı 1.
- [122] **Friedman, J. H. (2002).** Stochastic gradient boosting. Computational Statistics & Data Analysis, 38(4), 367-378. [https://doi.org/10.1016/S0167-9473\(01\)00065-2](https://doi.org/10.1016/S0167-9473(01)00065-2)
- [123] **Fan, Y., & Lei, W. (2022).** Wind Speed Prediction Based on Gradient Boosting Decision Tree. 2022 International Conference on Big Data, Information and Computer Network (BDICN), 93-97. [https:// doi.org/ 10.1109/BDICN55575.2022.00025](https://doi.org/10.1109/BDICN55575.2022.00025)
- [124] **Cai, R., Xie, S., Wang, B., Yang, R., Xu, D., & He, Y. (2020).** Wind Speed Forecasting Based on Extreme Gradient Boosting. IEEE Access, 8, 175063-175069. <https://doi.org/10.1109/ACCESS.2020.3025967>

- [125] **Baile, R., & Muzy, J.-F. (2022).** Leveraging data from nearby stations to improve short-term wind speed forecasts (arXiv:2207.14679). arXiv. <http://arxiv.org/abs/2207.14679>
- [126] **Fonseca, S. B., de Oliveira, R. C. L., & Affonso, C. M. (2021).** Short-term Wind Speed Forecasting using Machine Learning Algorithms. 2021 IEEE Madrid PowerTech, 1-6. <https://doi.org/10.1109/PowerTech46648.2021.9494848>
- [127] **Bailey, R. L., Reiss, M. A., Arge, C. N., Möstl, C., Henney, C. J., Owens, M. J., Amerstorfer, U. V., Amerstorfer, T., Weiss, A. J., & Hinterreiter, J. (2021).** Using Gradient Boosting Regression to Improve Ambient Solar Wind Model Predictions. Space Weather, 19(5). <https://doi.org/10.1029/2020SW002673>
- [128] **Bagalkot, N., Keprate, A., & Orderløkken, R. (2021).** Combining Computational Fluid Dynamics and Gradient Boosting Regressor for Predicting Force Distribution on Horizontal Axis Wind Turbine. Vibration, 4(1), 248-262. <https://doi.org/10.3390/vibration4010017>

ÖZGEÇMİŞ

Ad – Soyad : Buğra Kaplan

ÖĞRENİM DURUMU:

- Işık Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü (ENG) (2018)
- Işık Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü (ENG) (2019)

YÜKSEK LİSANS TEZİNDEN ÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

Kaplan, B., Eskin, N.(2022). Rüzgar Türbinlerinin Güç Üretimlerinin Farklı Regresyon Modelleri Kullanılarak Makine Öğrenmesi Algoritmalarıyla Tahmin Edilmesi, 2nd International World Energy Conference-IWEC 2022, Kayseri, Türkiye.