

T.C.
MALATYA TURGUT ÖZAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**TÜRKİYE'DE BULUNAN RÜZGÂR ENERJİ SANTRALLERİNDEKİ
ELEKTRİK ÜRETİMİNİN ARAŞTIRILMASI VE YAPAY ZEKÂDA
MODELENMESİ**

NURETTİN MİRKAN ÖNER

YÜKSEK LİSANS TEZİ
BİYOMEDİKAL MÜHENDİSLİĞİ DİSİPLİNLER ARASI ANA BİLİM DALI

OCAK 2025

ONUR SÖZÜ

Yüksek Lisans Tezi olarak sunduğum “TÜRKİYE’DE BULUNAN RÜZGÂR ENERJİ SANTRALLERİNDEKİ ELEKTRİK ÜRETİMİNİN ARAŞTIRILMASI VE YAPAY ZEKÂDA MODELLENMESİ” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuğunu belirtir, bunu onurumla doğrularım.

Nurettin Mirkan ÖNER

ÖZET

Yüksek Lisans Tezi

TÜRKİYE’DE BULUNAN RÜZGÂR ENERJİ SANTRALLERİNDEKİ ELEKTRİK ÜRETİMİNİN ARAŞTIRILMASI VE YAPAY ZEKÂDA MODELLENMESİ

Nurettin Mirkan Öner

Malatya Turgut Özal Üniversitesi

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Disiplinler Arası Ana Bilim Dalı

78+xv sayfa

2025

Danışman: Doç. Dr. Ahmet Beyzade DEMİRPOLAT

Rüzgâr enerji santralleri, çevre dostu ve sürdürülebilir enerji kaynakları arasında yer alarak elektrik üretimine önemli katkılar sağlamaktadır. Rüzgârın kinetik enerjisini elektrik enerjisine dönüştüren bu santraller, enerji portföyünü çeşitlendirirken istihdam yaratmakta ve yerel ekonomilere katkıda bulunmaktadır. Teknolojik gelişmelerle birlikte maliyetler düşmekte, rüzgâr enerjisi daha rekabetçi hale gelmektedir.

Hastanelerde rüzgâr enerjisi kullanımı, sürdürülebilirlik, enerji maliyetlerini azaltma ve kesintisiz hizmet sağlama açısından büyük önem taşır. Enerji kesintilerine karşı yedek kaynak sunarak hastanelerin güvenliğini artırır ve karbon ayak izini düşürerek çevresel sorumluluklarını yerine getirmelerine yardımcı olur.

Savaş, pandemi ve doğal afet gibi kriz durumlarında rüzgâr enerjisi, bağımsız ve yerel bir kaynak olarak enerji güvenliğini sağlamada kritik rol oynar. Afet bölgelerinde hızlıca kurularak sağlık hizmetleri, iletişim ve barınma gibi temel ihtiyaçların karşılanmasına yardımcı olur. Ayrıca, fosil yakıtlara bağımlılığı azaltarak uzun vadeli çevresel etkileri minimize eder. Bu nedenle rüzgâr enerjisi, sürdürülebilir ve güvenilir bir enerji kaynağı olarak büyük avantajlar sunmaktadır.

Yaptığımız bu çalışmada ülkemizde kurulu rüzgâr enerji santrallerine sahip illerdeki yaklaşık son on yılına ait gün gün değişen iklim koşullarını inceleyerek santrallerde ki üretilen elektrik enerjisi güçleri ve saha çalışmalarından elde edilen veriler üzerinden yapay zekâ algoritmalarını kullanıp önümüzdeki yıllarda çeşitli değişkenler göz önüne alınarak (radyasyon, nem, sıcaklık, rüzgâr) rüzgâr enerji santrallerinin üretebileceği enerji güç değerlerini tahmin edip gerçekte ortaya çıkacak

enerji miktarını optimum fayda sağlayacak durumda yönlendirilmesi amaçlanmıştır.

ANAHTAR KELİMELEER: Rüzgâr türbinleri, Yapay zekâ, Makine öğrenmesi, Verim, Enerji, Yenilebilir Enerji



ABSTRACT

M.Sc. Thesis

INVESTIGATION OF ELECTRICITY GENERATION IN WIND POWER PLANTS IN TÜRKİYE AND ITS MODELING IN ARTIFICIAL INTELLIGENCE

Nurettin Mirkan ÖNER

Malatya Turgut Özal University
Institute of Graduate Studies
Interdisciplinary Department of Biomedical Engineering

78+xv pages

2025

Supervisor: Assoc. Prof. Dr. Ahmet Beyzade DEMİRPOLAT

Wind power plants play a significant role in electricity generation as environmentally friendly and sustainable energy sources. These plants convert the kinetic energy of the wind into electrical energy, diversifying the energy portfolio while creating employment and contributing to local economies. With technological advancements, costs are decreasing, making wind energy more competitive.

The use of wind energy in hospitals is of great importance for sustainability, reducing energy costs, and ensuring uninterrupted service. It provides a backup power source against outages, enhances the security of hospitals, and helps them fulfill their environmental responsibilities by reducing their carbon footprint.

In times of crisis, such as war, pandemics, and natural disasters, wind energy plays a critical role in ensuring energy security as an independent and local source. It can be rapidly deployed in disaster areas to support essential needs such as healthcare services, communication, and shelter. Additionally, by reducing dependence on fossil fuels, it minimizes long-term environmental impacts. Therefore, wind energy offers significant advantages as a sustainable and reliable energy source.

In this study, we analyzed the daily changing climate conditions over the past ten years in provinces with established wind power plants in our country. Using artificial intelligence algorithms, we aimed to predict the potential energy output of wind power plants in the coming years by considering various variables (radiation, humidity, temperature, wind). Our goal is to optimize energy production by directing the generated electricity toward maximum efficiency based on real-world conditions.

KEYWORDS: Wind turbines, Artificial intelligence, Machine learning, Efficiency, Energy, Renewable energy



TEŞEKKÜR

Yüksek lisans eğitimim süresince sabır ve özveriyle bana rehberlik eden değerli hocam Doç. Dr. Ahmet Beyzade DEMİRPOLAT'a ve hayatım boyunca yanımda olan, desteklerini hiçbir zaman esirgemeyen aileme ve yol arkadaşlarıma en içten teşekkürlerimi sunarım.



İÇİNDEKİLER

ONUR SÖZÜ	i
ÖZET.....	ii
ABSTRACT	iv
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
SİMGELER DİZİNİ	xi
ŞEKİLLER DİZİNİ	xiii
ÇİZELGELER DİZİNİ	xv
1. GİRİŞ	1
1.1. Rüzgâr Enerji Santrali Kurulumunun Hastanelere Etkileri	9
1.1.1. Uygulama Örnekleri.....	9
1.1.2. Ortalama Elektrik Tüketimi	10
1.1.3. Rüzgâr Enerjisi Santralının Kapasitesi:.....	11
1.1.4. Hastanenin Elektrik İhtiyacının Rüzgâr Enerjisi ile Karşılanması:	11
1.2. Türkiye’de Rüzgâr Enerjisinin Durumu	12
1.2.1. Rüzgâr Enerji Santralleri	13
1.2.2. Türkiye’de Rüzgâr Enerjisi Potansiyeli	14
1.2.3. Türkiye’de Rüzgâr Enerjisinin Kullanımı	15
1.3. Yapay Sinir Ağları ve Sınıflandırılması.....	16
1.3.1. Tek Katmanlı Sinir Ağları	17
1.3.2. Çok Katmanlı Sinir Ağları.....	17
1.3.3. Geri Yayılım Algoritması.....	18
2. LİTERATÜR ARAŞTIRMASI	19

3. MATERYAL VE YÖNTEM	28
3.1. Makine Öğrenimi ve Regresyon Algoritmaları	28
3.1.1. Doğrusal Regresyon Algoritmaları	28
3.1.1.1. Çoklu doğrusal regresyon (multiple linear regression - mlr)	28
3.1.1.2. Temel bileşen regresyonu (principal component regression - pcr)	29
3.1.1.3. Kısmi en küçük kareler regresyon (partial least squares regression - plsr).....	29
3.1.1.4. Ridge regresyon (RR)	30
3.1.1.5. Lasso regresyonu (LR).....	30
3.1.1.6. ElasticNet	31
3.1.2. Doğrusal Olmayan Reglesyon Algoritmaları	31
3.1.2.1. K-en yakın komşu (k nearest neighbors - knn)	31
3.1.2.2. Çok katmanlı algılayıcı (multilayer perceptron – mlp)	31
3.1.2.3. Classification & regression tree (cart)	31
3.1.2.4. Rastsal orman (random forest – rf).....	32
3.1.2.5. LightGBM	32
3.1.2.6. Category boosting (catboost)	32
3.1.2.7. Destek vektör regresyonu (support vector regression — svr).....	32
3.1.2.8. Bagged trees	33
3.1.2.9. Xgboost	33
3.2. Performans Metrikleri	33
3.2.1. RMSE (Root Mean Squared Error).....	34
3.2.2. NRMSE (Normalized Root Mean Squared Error).....	34
3.2.3. MAE (Mean Absolute Error).....	34
3.2.4. MAPE (Mean Absolute Percentage Error).....	34

3.2.5. Belirleme Katsayısı (R^2).....	35
4. DENEYSEL SONUÇLAR VE TARTIŞMA	36
4.1. Akdeniz Bölgesi Tahmin Sonuçları	36
4.1.1. Osmaniye İli Tahmin Sonuçları	36
4.1.2. Mersin İli Tahmin Sonuçları.....	38
4.2. Marmara Bölgesi Tahmin Sonuçları	40
4.2.1. Çanakkale İli Tahmin Sonuçları	40
4.2.2. Balıkesir İli Tahmin Sonuçları.....	42
4.3. İç Anadolu Bölgesi Tahmin Sonuçları	43
4.3.1. Sivas İli Tahmin Sonuçları	43
4.3.2. Çankırı İli Tahmin Sonuçları	45
4.3.3. Kırıkkale İli Tahmin Sonuçları	47
4.3.4. Kırşehir İli Tahmin Sonuçları	49
4.4. Karadeniz Bölgesi Tahmin Sonuçları	51
4.4.1. Tokat İli Tahmin Sonuçları.....	51
4.4.2. Sinop İli Tahmin Sonuçları.....	53
4.5. Ege Bölgesi Tahmin Sonuçları	55
4.5.1. Manisa İli Tahmin Sonuçları	55
4.5.2. İzmir İli Tahmin Sonuçları	57
4.6. Doğu Anadolu Bölgesi Tahmin Sonuçları.....	59
4.6.1. Malatya İli Tahmin Sonuçları	59
4.6.2. Bingöl İli Tahmin Sonuçları	61
4.6.3. Van İli Tahmin Sonuçları	63
4.7. Güney Doğu Anadolu Bölgesi Tahmin Sonuçları	65
4.7.1. Gaziantep İli Tahmin Sonuçları	65

5. SONUÇ	68
KAYNAKLAR.....	70



SİMGELER DİZİNİ

Bp	: British Petroleum
REPA-V1	: Türkiye Rüzgâr Enerjisi Potansiyeli Atlası
RES	: Rüzgâr Enerjisi Santrali
KNN	: K Nearest Neighbors
LR	: Lasso Regresyonu
LM	: Levenberg-Marquardt
NRMSE	: Normalize Edilmiş Kök Ortalama Kare Hata
MAPE	: Ortalama Mutlak Yüzde Hata
MAE	: Ortalama Mutlak Hata
MLP	: Multilayer Perceptron
MLR	: Multiple Linear Regression
PLSR	: Partial Least Squares Regression
PCR	: Principal Component Regression
RF	: Random Forest
RT	: Regression Trees
RR	: Ridge Regresyon
RMSE	: Root Mean Square Error
RR	: Ridge Regresyon
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zekâ
TKA	: Tek Katmanlı Sinir Ağı Modeli
ANFIS	: Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi
ÇKA	: Çok Katmanlı Sinir Ağları
DVM	: Destek Vektör Makinesi
RBF	: Radyal Tabanlı Fonksiyon Kernel
PUK	: Pearson VII Kernel
MO	: Makine Öğrenimi
VC	: Vapnik-Chervonenkis
SVM	: Destek Vektör Makineleri
EPIAŞ	: Enerji Piyasaları İşletme A.Ş
CT	: Classification Tree
RT	: Regression Tree

GBDT : Gradient Boosting Decision Tree



ŞEKİLLER DİZİNİ

Şekil 1.1. 2013 ve 2023 Yılları için birincil enerji kaynaklarına göre Türkiye Kurulu Gücü [9].	4
Şekil 1.2. Elektrik üretiminin kaynaklara göre dağılımı (Türkiye Ocak-2024) [14].	5
Şekil 1.3. Küresel enerji talebi: Gerçek ve tahmin edilen (% yıllık değişim) [10].	6
Şekil 1.4. Rüzgâr Kurulu Kapasite Artışları (2010-2020) [10].	6
Şekil 1.5. Türkiye'nin rüzgâr enerjisi santralleri için kümülatif kurulum grafiği [16].	7
Şekil 1.6. Türkiye'deki rüzgâr enerjisi santralleri için yıllık kurulum [16].	8
Şekil 1.7. Türkiye'nin rüzgâr enerjisi potansiyel atlası 100 m yükseklikte yıllık ortalama (REPA) [31].	13
Şekil 1.8. Modern rüzgâr türbinlerinin yıllara göre gelişimi (rotor çapları metre (m), kapasiteleri kilovat (kW) ve megawat (MW) olarak) [32].	14
Şekil 1.9. Tek katmanlı sinir ağı modeli	17
Şekil 1.10. Çok katmanlı sinir ağı modeli [36].	18
Şekil 4.1. Osmaniye çoklu doğrusal regresyon grafiği	38
Şekil 4.2. Mersin çoklu doğrusal regresyon grafiği.....	39
Şekil 4.3. Çanakkale çoklu doğrusal regresyon grafiği	41
Şekil 4.4. Balıkesir çoklu doğrusal regresyon grafiği.....	43
Şekil 4.5. Sivas doğrusal regresyon grafiği.....	45
Şekil 4.6. Çankırı doğrusal regresyon grafiği.....	47
Şekil 4.7. Kırıkkale doğrusal regresyon grafiği.....	49
Şekil 4.8. Kırşehir doğrusal regresyon grafiği	51
Şekil 4.9. Tokat doğrusal regresyon grafiği	53
Şekil 4.10. Sinop doğrusal regresyon grafiği	55
Şekil 4.11. Manisa doğrusal regresyon grafiği.....	57

Şekil 4.12. İzmir doğrusal regresyon grafiği	59
Şekil 4.13. Malatya çoklu doğrusal regresyon grafiği	61
Şekil 4.14. Bingöl çoklu doğrusal regresyon grafiği	63
Şekil 4.15. Van çoklu doğrusal regresyon grafiği	65
Şekil 4.16. Gaziantep çoklu doğrusal regresyon grafiği	67



ÇİZELGELER DİZİNİ

Çizelge 1.1. Bölgelerimizin yıllık ortalama rüzgâr hızı ve yoğunluğu [32].	15
Çizelge 1.2. 50 metre yükseklikte toplam rüzgâr enerjisi potansiyeli [33].....	16
Çizelge 1.3. Tez çalışmamızda çalıştığımız illerin kurulu güç miktarları	16
Çizelge 4.1. Osmaniye iline ait makine öğrenmesi modellerinin karşılaştırması	36
Çizelge 4.2. Mersin iline ait makine öğrenmesi modellerinin karşılaştırması	38
Çizelge 4.3. Çanakkale iline ait makine öğrenmesi modellerinin karşılaştırması.....	40
Çizelge 4.4. Balıkesir iline ait makine öğrenmesi modellerinin karşılaştırması	42
Çizelge 4.5. Sivas iline ait makine öğrenmesi modellerinin karşılaştırması.....	44
Çizelge 4.6. Çankırı iline ait makine öğrenmesi modellerinin karşılaştırması	45
Çizelge 4.7. Kırıkkale iline ait makine öğrenmesi modellerinin karşılaştırması	47
Çizelge 4.8. Kırşehir iline ait makine öğrenmesi modellerinin karşılaştırması	49
Çizelge 4.9. Tokat iline ait makine öğrenmesi modellerinin karşılaştırması	51
Çizelge 4.10. Sinop iline ait makine öğrenmesi modellerinin karşılaştırması	53
Çizelge 4.11. Manisa iline ait makine öğrenmesi modellerinin karşılaştırması.....	55
Çizelge 4.12. İzmir iline ait makine öğrenmesi modellerinin karşılaştırması.....	57
Çizelge 4.13. Malatya iline ait makine öğrenmesi modellerinin karşılaştırması	59
Çizelge 4.14. Bingöl iline ait makine öğrenmesi modellerinin karşılaştırması.....	61
Çizelge 4.15. Van iline ait makine öğrenmesi modellerinin karşılaştırması.....	63
Çizelge 4.16. Gaziantep iline ait makine öğrenmesi modellerinin karşılaştırması	65

1. GİRİŞ

Rüzgâr enerjisi, sürdürülebilir enerji kaynakları arasında öne çıkan bir seçenek olup, enerji arz güvenliğini artırma ve fosil yakıtlara bağımlılığı azaltma açısından stratejik bir öneme sahiptir. Ancak, rüzgâr enerji santrallerindeki üretim verimliliği; meteorolojik koşullar, teknolojik sınırlamalar ve bölgesel farklılıklar gibi çeşitli faktörlere bağlı olarak değişkenlik göstermektedir. Bu bağlamda, çalışmada ilk olarak Türkiye genelindeki rüzgâr enerji santrallerinin coğrafi dağılımı, üretim verileri ve mevcut performans göstergeleri incelenmiştir. Ardından, yapay zekâ tabanlı modelleme teknikleri ile üretim performansını etkileyen faktörler analiz edilerek gelecekteki üretim potansiyellerine yönelik tahminlerde bulunulmuştur. Çalışma, yalnızca mevcut enerji üretim süreçlerini anlamayı değil, aynı zamanda yapay zekâ teknolojilerinin yenilenebilir enerji sektörüne nasıl entegre edilebileceğini göstermek açısından da önemli bir katkı sağlamayı hedeflemektedir. Böylece, enerji politikalarının oluşturulmasında ve santrallerin verimliliğinin artırılmasında yol gösterici bir kaynak oluşturulması amaçlanmaktadır.

İnsan hayatında sanayileşmenin hızlanması, teknolojik aletlerin günlük yaşamda yaygın bir şekilde kullanımının artması ve dünya nüfusundaki sürekli büyüme, enerjiye olan talebin önemli ölçüde yükselmesine yol açmıştır. Günümüzde enerji, fabrikalar, atölyeler, evlerdeki elektronik eşyalar, sokak aydınlatmaları, demiryolu taşımacılığı ve elektrikli araçlar gibi birçok alanda hayati bir ihtiyaç haline gelmiştir. Bu dinamikler, küresel enerji tüketiminin her yıl ortalama olarak %4-5 oranında artmasına sebep olmaktadır [1].

Kömür ve petrol gibi fosil yakıtların sınırlı kaynaklara sahip olması ve çevresel açıdan olumsuz etkiler yaratması, insanları sürdürülebilir enerji seçenekleri arayışına yönlendirmiştir. Bu kapsamda, güneş, rüzgâr, biyokütle, jeotermal, hidroelektrik, deniz dalgası ve gelgit enerjisi gibi yenilikçi enerji kaynakları ön plana çıkmaktadır. Bu kaynaklar, genellikle "sürdürülebilir", "çevre dostu", "yenilenebilir" ve "tükenmez" özellikleriyle dikkat çekmekte ve geleceğin enerji çözümleri arasında değerlendirilmektedir [2].

Rüzgâr enerjisi, çevresel etkileri son derece düşük ve yenilenebilir enerji

kaynakları arasında önemli bir yere sahip bir enerji türüdür. Fosil yakıtların elektrik üretiminde sebep olduğu çevresel zararlar, rüzgâr enerjisiyle karşılaştırıldığında oldukça belirgindir. Rüzgâr türbinleri, atmosfere zararlı gaz salınımı yapmaması ve doğal kaynakları tüketmemesi nedeniyle temiz ve sürdürülebilir enerji üretimi için ideal bir çözüm sunar. Bu özellikleriyle rüzgâr enerjisi, çevrenin korunmasına katkı sağlarken aynı zamanda uzun vadeli enerji ihtiyaçlarının karşılanmasında kritik bir rol almaktadır [3].

Rüzgâr enerjisi, tamamen temiz bir enerji kaynağı olup ne radyoaktif atık ne de başka bir atık üretir. Aynı zamanda sera gazı emisyonlarına yol açmadığı gibi, asit yağmurlarının oluşumunu da önler. Ek olarak, fosil yakıt kullanımını azaltması sayesinde dolaylı olarak sera gazı salınımının düşürülmesine katkı sağlar. Bu yönleriyle, rüzgâr enerjisi hem çevre dostu hem de sürdürülebilir enerji üretimi için kilit bir seçenek olarak öne çıkmaktadır [3].


Ekonomik açıdan en uygun ve yenilenebilir enerji kaynakları arasında en gelişmiş seçeneklerden biri rüzgâr enerjisidir. Teknolojideki ilerlemelerle birlikte kurulum ve işletim maliyetlerinin düşmesi, bu enerji türünü daha erişilebilir hale getirmiştir [4].

Yapay zekâ (YZ), insan zekâsını taklit eden düşünme, öğrenme ve karar verme yeteneklerini makineler ile bilgisayar sistemlerine kazandırmayı hedefleyen bir bilim dalıdır. YZ, analiz ettiği verilerden sonuç çıkararak yeni bilgiler öğrenebilmekte, problemleri çözebilmekte ve karar mekanizmaları oluşturabilmektedir. Yapay zekâ, yenilenebilir enerji kaynaklarının daha verimli hale getirilmesi ve sürdürülebilir bir enerji sistemi oluşturulması hedefiyle birçok farklı alanda kullanılmaktadır [5].

Dünya genelinde yenilenebilir enerjiye yönelik yatırımlar ve destek politikaları, özellikle elektrik üretimi alanında yoğunlaşmaktadır. Bu yatırımlar sayesinde, yenilenebilir enerjinin elektrik üretimindeki payı sürekli artmaktadır. 2013 itibarıyla Türkiye’de elektrik üretiminde yenilenebilir enerji kaynaklarının payı, özellikle hidroelektrik santrallerinin etkisiyle % 22.1’e ulaşmıştır. Yenilenebilir enerji üretim ve yatırımlarında ise Çin ve ABD, lider konumlarını giderek güçlendirmektedir [6]. 2009 Dünya Enerji Raporu’na göre, yüksek petrol fiyatları ve

ekonomik krizlerin etkisiyle enerji ithalatına bağımlı ülkeler daha büyük zorluklarla karşılaşmıştır (IEA, 2010: 60). Bu bağlamda, enerji bağımlılığı yüksek ülkelerin yenilenebilir enerjiye yönelmesinin önemi vurgulanmaktadır. Yenilenebilir enerjiye yapılan yatırımların 2030 yılı itibarıyla yıllık % 7.6 oranında bir büyüme göstermesi ve en hızlı büyüyen enerji kaynağı olması beklenmektedir [6].

Türkiye, stratejik coğrafi konumu ve çeşitli doğal özellikleri nedeniyle enerji üretimi ve tüketimi bakımından önemli bir ülke konumundadır [7]. Fosil yakıtların sınırlı ömürleri ve çevreye verdikleri zararlar, alternatif enerji kaynaklarının araştırılmasını zorunlu hale getirmiştir. Bu bağlamda, çevre kirliliği ve sürdürülebilirlik açısından fosil yakıtlara en güçlü alternatifler, yenilenebilir enerji kaynakları olmuştur. Özellikle son yıllarda, rüzgâr enerjisi, biyokütle, güneş enerjisi ve jeotermal enerji gibi doğal kaynaklar, elektrik üretiminde önemli birer seçenek olarak öne çıkmaktadır. Bu gelişmeler, enerji üretiminin çevre dostu ve sürdürülebilir hale gelmesine katkı sağlamaktadır [8]. Rüzgâr enerjisi, Türkiye'nin enerji karışımında önemli bir yer tutmakta ve sürdürülebilir enerji hedefleri doğrultusunda giderek daha fazla ön plana çıkmaktadır. Enerji ve Tabii Kaynaklar Bakanlığı, enerji bağımlılığını azaltmak için 2023 yılında hedeflediği yenilenebilir enerji kullanımını artırmayı, 2017'de ulaşmıştır. Bu başarı, güneş, rüzgâr ve jeotermal enerjilerindeki teknolojik ilerlemeler ve yapılan yatırımlar sayesinde elde edilmiştir [7]. Şekil 1.1'de 2013 ve 2023 yılları için birincil enerji kaynaklarına göre Türkiye Kurulu Gücü gösterilmiştir [9].



Şekil 1.1. 2013 ve 2023 Yılları için birincil enerji kaynaklarına göre Türkiye Kurulu Gücü [9].

Türkiye’de, nüfus artışı ve ekonomik büyüme nedeniyle enerji talebi hızla yükselmektedir. Bu artan enerji ihtiyacını karşılamak amacıyla Türkiye, Ulusal Enerji Planı’nda belirlediği bazı hedeflere sahiptir [10]. Temmuz 2024 itibarıyla Türkiye’nin toplam elektrik santrali kurulu gücü 100 GW seviyesine ulaşmıştır ve bu santrallere yönelik sağlanan teşviklerle birlikte güç kapasitesinde artış eğilimi devam etmektedir. Elektrik üretimindeki kaynak dağılımı, % 10.9 rüzgâr, % 15.6 güneş enerjisi, % 1.5 jeotermal enerji, % 19.3 kömür, % 28.5 hidrolik enerji, %21.9 doğal gaz, % 19.3 kömür ve % 2.4 diğer kaynaklar olarak sıralanmaktadır. Yenilenebilir enerji kaynaklarının payı, özellikle 2005 yılından sonra sürekli olarak artış göstermiştir. 2021 yılında, yenilenebilir enerji kaynaklarından elde edilen net kurulu güç artışı 3.160 MW seviyesinde gerçekleşmiş ve bu artışın büyük bir kısmı rüzgâr, güneş ve hidroelektrik santrallerinden sağlanmıştır. 485 MW’lık artış hidroelektrik santrallerinden, 1.420 MW’lık artış rüzgâr enerjisi santrallerinden ve 991 MW’lık artış ise güneş enerjisi santrallerinden gelmiştir. Aynı dönemde, doğal gaz ve çok yakıtlı santrallerin kurulu gücü 141 MW azalmıştır [11-12].

Türkiye, 2035 yılına kadar rüzgâr enerjisinde 29.6 GW kurulu elektrik üretim

kapasitesine ulaşmayı hedeflemektedir. Bu kapasitenin 24.6 GW'ı karasal rüzgâr enerjisinden, 5 GW'ı ise deniz üstü rüzgâr enerjisinden sağlanacaktır. Güneş enerjisinin kurulu kapasitesinin 2035 yılına kadar 52.9 GW'a ulaşması beklenmektedir. Türkiye, hidroelektrik enerjisi alanında da 2035 yılına kadar 35,1 GW kurulu kapasiteye ulaşmayı amaçlamaktadır. Ayrıca, Türkiye'nin Ulusal Enerji Planı çerçevesinde, jeotermal ve biokütle gibi diğer yenilenebilir enerji kaynaklarının toplam kurulu kapasitesinin 2035 yılına kadar 5.1 GW olması hedeflenmektedir [13]. Şekil 1.2'de elektrik üretiminin kaynaklara göre dağılımı (Türkiye Ocak-2024) gösterilmiştir [14].




Şekil 1.2. Elektrik üretiminin kaynaklara göre dağılımı (Türkiye Ocak-2024) [14].

Diğer gelişmiş ülkelerde olduğu gibi Türkiye de yenilenebilir enerjinin uzun vadeli entegrasyonuna yönelik hedefler belirlemiştir.

BP'nin, "Dünya Enerjisinin İstatiksel Görünümü 2019 ve 2022 de yayınladığı raporlarını incelediğimizde; kaçınılmaz bir enerji ihtiyacının olduğunu gözlemlenmektedir. Bu raporların sayısal verilerine göre birincil enerji tüketimi 2018 yılında son 10 yıl ortalaması olan %1.5 değerinin yaklaşık iki katı büyüyerek %2.9 olarak tespit edilmiştir. 2018 yılında dünyada 13864.9 Mtep enerji tüketilmiştir. Türkiye'de ise dünya genelinde toplam tüketilen enerjinin yaklaşık %1.2'sine tekabül eden 153.5 Mtep'tir [13].


Bp'nin 2022 yayınladığı Dünya Enerjisi 2022 istatistiksel incelemesine (Statistical Review of World Energy 2022) göre de yenilenebilir enerji kaynakları payının nükleer enerjiye oranla daha fazla olduğu gözlemlenmiştir. 2021 yılında

neredeyse %13'e ulaşan enerji üretiminde yenilenebilir enerji kaynaklarının payı %9.8 olan nükleer enerjiyi geçmiştir [10]. Şekil 1.3'de küresel enerji talebi: Gerçek ve tahmin edilen % yıllık değişim ifade edilmektedir [10].



Şekil 1.3. Küresel enerji talebi: Gerçek ve tahmin edilen (% yıllık değişim) [10].

İncelenen bu raporlara göre birincil enerji talebi 2019'da % 4.5 olan bu değer 2021 de %5.8'e ulaşmıştır. Ayrıca fosil yakıtlar, 2019'da %83 ve 2017'de %85 iken, 2021'de birincil enerji kullanımının % 82'sini oluşturdu. Elektrik üretiminde yenilenebilir enerji kaynaklarının payının arttığı gözlemlenmiştir. Şekil 1.4'te rüzgâr kurulu kapasite artışları (2010-2020) ifade edilmektedir [10].




Şekil 1.4. Rüzgâr Kurulu Kapasite Artışları (2010-2020) [10].

Yenilenemeyen enerji kaynaklarından olan petrol ve doğalgaza olan büyük ihtiyaçtan dolayı ülkeler için bu durum sorun haline gelmektedir. Ayrıca bu kaynakların tüketiminden kaynaklı çevreye verdiği zarar diğer bir dezavantajdır. Günümüzde birçok ülke yenilebilir enerji teknolojilerine geçerek enerji kaynağını kullanımında fosil yakıt tüketimini minimum düzeyde tutmaya çalışmayı hedeflemektedir. Bu doğrultuda rüzgâr enerjisinden elektrik üretmek coğrafi ve meteorolojik şartları uygun olan ülkeler için bir fırsattır. Türkiye'nin gerek coğrafi konumu gerekse meteorolojik durumu incelendiğinde Türkiye Rüzgâr Enerjisi Potansiyeli Atlasına göre (REPA-V1) 50 m yüksekliğe aşkın ve 7.5 m/s üzerindeki yıllık ortalama rüzgâr hız değerlerini sağlayan alanlarda 1km² başına 5MW büyüklüğünde RES (Rüzgâr Enerji Santrali) kurulabileceğinden rüzgâr enerji santrali yapılabilir bir yatırım kaynağı olduğu gözlenmektedir. Bahsedilen standartları sağlayıp ülkemizin yüz ölçümünün % 13'üne denk gelen kullanabilecek alanlarda oluşacak kümülatif rüzgâr enerjisi kapasitesini 47.85 GW'dir [15]. Türkiye'nin rüzgâr enerjisi santralleri için kümülatif kurulumu Şekil 1.5'de ve rüzgâr enerjisi santralleri için yıllık kurulumu da Şekil 1.6.'da gösterilmiştir.



Şekil 1.5. Türkiye'nin rüzgâr enerjisi santralleri için kümülatif kurulum grafiği [16].



Şekil 1.6. Türkiye’deki rüzgâr enerjisi santralleri için yıllık kurulum [16].

Yapay sinir ağları (YSA), biyolojik sinir sistemlerinden ilham alarak tasarlanmış, karmaşık bilgi işleme görevlerini gerçekleştirmek üzere kullanılan matematiksel model ve algoritmalar topluluğudur [17].

YSA, rüzgâr enerjisi tahmin analizlerinde kullanılan etkili bir araçtır. Bu analizler, rüzgâr enerjisi santrallerinin planlanması, işletilmesi ve enerji üretiminin optimize edilmesi gibi alanlarda önemli rol oynar. İşte bu tür bir analizi gerçekleştirmek için gereken adımlar:

- Veri Toplama ve Hazırlama
- Veri Analizi ve Görselleştirme
- Veri Ön İşleme
- Yapay Sinir Ağı Modelinin Seçimi
- Modelin Eğitimi
- Modelin Değerlendirilmesi
- Modelin Ayarlanması ve Optimizasyonu
- Sonuçların İncelenmesi ve Uygulanması [18-19] .

Enerji talebinin sürekli artması, dünya genelinde sürdürülebilir enerji kaynaklarına olan ihtiyacı daha da artırmaktadır. Rüzgâr enerjisi, bu bağlamda temiz, yenilenebilir ve çevre dostu bir enerji kaynağı olarak öne çıkmaktadır. Hastaneler, kritik hizmet sağlayıcıları olarak sürekli enerjiye ihtiyaç duyarlar ve bu nedenle rüzgâr enerjisi, hastanelerin enerji gereksinimlerini karşılamak için önemli bir alternatif sunmaktadır [20-21].

1.1. Rüzgâr Enerji Santrali Kurulumunun Hastanelere Etkileri

Enerji maliyeti: Rüzgâr enerjisi, uzun vadede hastanelerin enerji maliyetlerini önemli ölçüde azaltabilir. Geleneksel enerji kaynaklarına bağımlılığı azaltarak, hastaneler enerji fiyatlarındaki dalgalanmalara karşı daha dayanıklı hale gelirler.

Yer seçimi ve rüzgâr potansiyeli: Hastanelerin bulunduğu bölgenin rüzgâr potansiyelinin değerlendirilmesi kritik bir adımdır. Rüzgâr hızı ve yönü, enerji üretim verimliliğini etkileyen önemli faktörlerdir. Bu nedenle, rüzgâr ölçüm istasyonları ile detaylı analizler yapılmalıdır.

Altyapı ve entegrasyon: Rüzgâr türbinlerinin kurulumu, hastane altyapısının bir parçası olarak düşünülmelidir. Mevcut enerji altyapısının rüzgâr enerjisi ile entegre edilmesi, enerji yönetim sistemlerinin güncellenmesini gerektirebilir.

Finansal Destek ve Teşvikler: Birçok ülke, yenilenebilir enerji projelerine yönelik finansal teşvikler sunmaktadır. Hastaneler, bu desteklerden faydalananarak rüzgâr enerjisi sistemlerini daha uygun maliyetle kurabilirler.

Dünya genelinde rüzgâr enerjisi kullanan hastaneler, bu teknolojinin faydalarını göstermektedir [21].

1.1.1. Uygulama Örnekleri

Danimarka'daki bazı hastaneler, kendi rüzgâr enerji santrallerine sahiptir. Bu hastaneler, enerji maliyetlerini önemli ölçüde azaltmış ve çevresel sürdürülebilirlik hedeflerine ulaşmışlardır.

Almanya'da, rüzgâr enerjisi kullanarak elektrik üreten hastaneler, yenilenebilir enerji uygulamalarının sağlık sektörü üzerindeki olumlu etkilerini ortaya koymuştur. Bu hastaneler, enerji bağımsızlıklarını artırarak, çevresel etkilerini

azaltmayı başarmışlardır.

Amerika Birleşik Devletleri'nde bazı hastaneler, rüzgâr enerjisi projeleri ile kendi enerji ihtiyaçlarını karşılamakta ve bu sayede maliyetlerini minimize etmektedir.

Ülkemizde en yüksek enerji ihtiyacı olan hastanelerimiz şehir hastanelerimizdir. Şehir hastanelerimizi enerji ihtiyacı konusunda tam bağımsız veya yarı bağımsız bir hale getirmemiz ülkemizin gelişmesinde büyük önem teşkil etmektedir. Şehir hastanelerinin elektrik ihtiyacı, hastanenin büyüklüğüne, kapasitesine, kullanılan tıbbi cihazların sayısına, altyapı sistemlerine ve hizmetlerin çeşitliliğine bağlı olarak değişiklik gösterebilir. Ancak, genel bir kılavuz olarak, büyük bir şehir hastanesinin ortalama elektrik ihtiyacı şu faktörlere göre belirlenebilir:

1. Hastanenin büyüklüğü ve yatak kapasitesi: Daha büyük hastaneler, daha fazla aydınlatma, tıbbi cihazlar, HVAC sistemleri ve diğer enerji gereksinimlerini karşılamak zorundadır.
2. Tıbbi cihazlar ve ekipmanlar: MRI makineleri, CT tarayıcıları, ventilatörler, yaşam destek cihazları gibi ekipmanlar enerji tüketimini önemli ölçüde artırır.
3. Isıtma, havalandırma ve iklimlendirme (HVAC): Bu sistemler, özellikle hastane içindeki hava kalitesini ve sıcaklık dengesini korumak için kritik öneme sahiptir ve yüksek enerji tüketir.
4. Hastane hizmetleri: Mutfaklar, soğutma sistemleri, güvenlik, iletişim ve bilgisayar sistemleri de önemli enerji tüketicileridir [22-24].

1.1.2. Ortalama Elektrik Tüketimi

Bir şehir hastanesinin elektrik tüketimi, yatak kapasitesine göre değişiklik gösterse de, yıllık elektrik tüketimi yaklaşık 20 milyon kWh ile 50 milyon kWh arasında olabilir. Bu da günde ortalama 55000 kWh ile 140000 kWh elektrik tüketimine denk gelir. Bu değerler, hastanenin büyüklüğüne ve kullanılan teknolojiye göre daha da artabilir. Örneğin, yüksek teknolojiye sahip tıbbi cihazlar ve gelişmiş HVAC sistemleri olan bir hastane, bu ortalamaların üst sınırına yakın elektrik

tüketebilir [25].

Rüzgâr enerjisi ile bir şehir hastanesinin elektrik ihtiyacının ne kadarının karşılanabileceği, hastanenin elektrik tüketimine ve rüzgâr enerjisi santralının kapasitesine bağlıdır. Ancak genel bir hesaplama yaparak, rüzgâr enerjisinin potansiyel katkısını belirleyebiliriz.

Yukarıda belirttiğimiz gibi, büyük bir şehir hastanesinin yıllık elektrik tüketimi yaklaşık 20 milyon kWh ile 50 milyon kWh arasında olabilir. Bu, günlük 55000 kWh ile 140000 kWh enerji tüketimine karşılık gelir [26-28].

1.1.3. Rüzgâr Enerjisi Santralının Kapasitesi:

Bir rüzgâr türbininin üretim kapasitesi, türbinin büyüklüğüne ve yerel rüzgâr koşullarına göre değişir. Ortalama bir rüzgâr türbini, yılda 2.5 milyon kWh ile 6 milyon kWh arasında elektrik üretebilir. Bu, türbinin güç kapasitesine (örneğin 2-3 MW) ve verimliliğine bağlıdır [29-30].

1.1.4. Hastanenin Elektrik İhtiyacının Rüzgâr Enerjisi ile Karşılanması:

Rüzgâr enerjisi santrallerinin bir hastanenin elektrik ihtiyacını karşılama kapasitesini belirlemek için, türbinlerin üretim kapasitesini hastanenin yıllık elektrik tüketimiyle karşılaştırabiliriz.

- Düşük tüketim (20 milyon kWh/yıl): Ortalama bir rüzgâr türbini, yılda 2.5 milyon kWh üretirse, yaklaşık 8 türbin (20 milyon kWh / 2.5 milyon kWh) bu ihtiyacın karşılanması için yeterlidir.
- Yüksek tüketim (50 milyon kWh/yıl): Ortalama bir rüzgâr türbini, yılda 6 milyon kWh üretirse, yaklaşık 9 türbin (50 milyon kWh / 6 milyon kWh) gerekli olabilir [26-28].


Bu hesaplamalar, rüzgâr enerjisi santralının verimli bir şekilde çalıştığı ve yerel rüzgâr koşullarının uygun olduğu varsayılarak yapılmıştır. Ancak, rüzgâr enerjisinin değişken doğası nedeniyle, tam olarak sürekli bir enerji üretimi sağlanamayabilir. Bu durumda, rüzgâr enerjisi santrallerinden sağlanan enerji, hastanenin elektrik ihtiyacının önemli bir kısmını karşılayabilir, ancak tamamını karşılamak için ek enerji kaynaklarına (örneğin, güneş enerjisi, enerji depolama veya

şebeke bağlantısı) ihtiyaç duyulabilir.

Rüzgâr enerjisi, bir şehir hastanesinin elektrik ihtiyacının önemli bir kısmını karşılayabilir. Ortalama bir rüzgâr enerjisi santrali, hastanenin elektrik ihtiyacının %20 ile % 50 arasında bir kısmını karşılayacak kapasiteye sahip olabilir. Ancak, tam anlamıyla bağımsız enerji sağlamak için, farklı yenilenebilir enerji kaynaklarının ve enerji depolama sistemlerinin entegrasyonu gerekebilir. Bu tez çalışmamızda yaptığımız rüzgâr enerjisi üretiminin değerlerini tahmin edip gerçekte ortaya çıkacak enerji miktarını optimum fayda sağlayacak durumda yönlendirilmesi, yeni kurulacak hastanelerin yerlerinin belirlenmesinde rüzgâr enerji üretimine uygun yerler seçilmesinde veya halihazırda olan hastanelerimizin bulunduğu bölgelerde üretilebilecek rüzgâr enerjisi yapay zekâ modellerini elde ederek yatırım maliyetlerinin amortisman süresi, o bölgede rüzgâr enerjisi mi ya da farklı bir alternatif bir sürdürülebilir enerji kaynağının tercih edilmesi mi faydalı olur konusunda yapay zekâ modelinden faydalanılabileceği çalışmamız neticesinde elde edilen verilerin analizi sonucu görülmektedir.

1.2. Türkiye’de Rüzgâr Enerjisinin Durumu

Rüzgâr enerjisi, yenilenebilir enerji kaynakları arasında çevre dostu olmasının yanı sıra sürdürülebilir ve ekonomik bir seçenek olarak da dikkat çekmekte olup, enerji üretimi ve tüketimi açısından önemli bir rol oynamaktadır. Türkiye, sahip olduğu coğrafi konumu ve özellikle belirli bölgelerdeki rüzgâr potansiyeli sayesinde bu alanda büyük bir avantaja sahip olup, bu avantajı enerji sektöründeki yatırımlarla daha da etkili bir şekilde kullanma yolunda önemli adımlar atmaktadır. Son yıllarda gerçekleştirilen büyük ölçekli yatırımlar ve devlet teşvikleri, rüzgâr enerjisi kullanımının artmasını sağlamış ve bu enerji türünün enerji sektöründe önemli bir yer edinmesine katkıda bulunmuştur. Şekil 1.7’de Türkiye’nin rüzgâr enerjisi potansiyel atlası 100 m yükseklikte yıllık ortalama (REPA) gösterilmiştir [31] .




Şekil 1.7. Türkiye'nin rüzgâr enerjisi potansiyel atlası 100 m yükseklikte yıllık ortalama (REPA) [31].

Türkiye, sürdürülebilir enerji üretimi hedefleri doğrultusunda rüzgâr enerjisi gibi yenilenebilir kaynaklardan elde edilen enerji miktarını artırmayı amaçlamaktadır.

1.2.1. Rüzgâr Enerji Santralleri

Yenilenebilir enerji kaynakları arasında önemli bir konuma sahip olan rüzgâr enerjisi, dünya genelinde yaklaşık 80 ülkenin elektrik üretiminde kullanıldığı ve son zamanlarda ülkemizde de hızla gelişen bir alternatif enerji türüdür. Modern rüzgâr türbinleri, günümüzde elektrik enerjisi elde etmek için tasarlanmaktadır. Dünya çapında farklı boyut ve kapasitelerde birçok rüzgâr türbini bulunmaktadır. Teknolojinin ilerlemesi ve maliyetlerin düşmesiyle birlikte, enerji taleplerini karşılamak için daha büyük ve daha yüksek kapasiteli rüzgâr türbinleri geliştirilmektedir. Şekil 1.8'de özellikle son on beş yılda hızla gelişen modern rüzgâr türbinleri ve günümüzde tek bir kanadının bile Airbus 380 yolcu uçağından daha uzun (80 m) olan ticari türbinlerin üretildiği gözlemlenebilir. Şekil 1.8'de modern rüzgâr türbinlerinin yıllara göre gelişimi ifade edilmektedir [32].



Şekil 1.8. Modern rüzgâr türbinlerinin yıllara göre gelişimi (rotor çapları metre (m), kapasiteleri kilovat (kW) ve megavat (MW) olarak) [32].

1.2.2. Türkiye’de Rüzgâr Enerjisi Potansiyeli

Türkiye genelinde geniş bir yelpazeye sahip olan yenilenebilir enerji kaynakları arasında, özellikle rüzgâr enerjisi önemli bir rol oynamaktadır. Rüzgâr enerjisi potansiyeli, rüzgâr hızının küpü ve kullanılacak rüzgâr türbininin rotor süpürme alanı ile doğru orantılıdır. Güç elde etmede kritik bir faktör olan rüzgâr hızı, yerden yükseldikçe logaritmik bir artış göstermektedir. Bir bölgede kurulacak rüzgâr santralinden elde edilebilecek güç, yalnızca kullanılan türbin sayısı ve türbin büyüklüğü ile sınırlıdır, ancak bu potansiyel, doğal karakteri gereği sınırsızdır. Bölgelerimizin yıllık ortalama rüzgâr hızı ve yoğunluğu Çizelge 1.1’de gösterilmiştir [33].

Çizelge 1.1. Bölgelerimizin yıllık ortalama rüzgâr hızı ve yoğunluğu [32].

Bölge	Yıllık ortalama rüzgâr hızı (m/s)	Yıllık ortalama rüzgâr yoğunluğu (W/m ²)
Marmara Bölgesi	3.29	51.91
Ege Bölgesi	2.65	23.47
Akdeniz Bölgesi	2.45	21.36
İç Anadolu Bölgesi	2.46	20.14
Kara Deniz Bölgesi	2.38	21.31
Doğu Anadolu Bölgesi	2.12	13.19
Güney Doğu Anadolu Bölgesi	2.69	29.33
Ortalama	2.58	25.82

1.2.3. Türkiye’de Rüzgâr Enerjisinin Kullanımı

Türkiye, rüzgâr enerjisinin kullanımına uygun olan ülkeler arasında yer almaktadır. Hali hazırda, Türkiye'nin elektrik üreten 36 barajın 10 katı kadar rüzgâr enerjisine sahip olduğu söylenmektedir. Küresel gelişmelere paralel olarak, 2020 yılında Türkiye'nin tüketmesi beklenen elektrik enerjisinin % 10'unun rüzgârdan sağlanması hedeflenmektedir. Bu da 54 milyar kWh'lık elektrik enerjisinin rüzgârdan üretilmesi gerektiği anlamına gelir. Bu miktar için gerekli olan kurulu rüzgâr gücü, yaklaşık olarak Türkiye'nin ekonomik rüzgâr potansiyeline denk gelmektedir. Türkiye'de, 50 metre yükseklikteki rüzgârlı alanlar, rüzgâr enerji potansiyeli açısından düşük ve yüksek potansiyelli olmak üzere yedi farklı sınıfa ayrılmaktadır. Rüzgâr gücü ve hızı bakımından düşük olan birinci ve ikinci sınıf rüzgâr alanları göz ardı edildiğinde, diğer sınıflar şu tabloda görülebilir. Bu tablodaki rüzgâr enerji sınıfları zengin sınıflar olarak kabul edilmekte ve kurulabilecek rüzgâr santrallerinden elde edilebilecek rüzgâr gücü de hesaplanmıştır. Bu değerler Çizelge 1.2'de gösterilmektedir [33].

Çizelge 1.2. 50 metre yükseklikte toplam rüzgâr enerjisi potansiyeli [33]

Rüzgâr sınıfı	Rüzgâr gücü (W/m ²)	Rüzgâr hızı (m/s)	Toplam alan (km ²)	Toplam potansiyel (MW)
3	300-400	6.5-7.0	16.781,39	83.906,96
4	400-500	7.0-7.5	5.851,87	29.259,36
5	500-600	7.5-8.0	2.598,86	12.994,32
6	600-800	8.0-9.0	1.079,98	5.399,92
7	>800	>9.0	39,17	195,84
Toplam			26.351,28	131.756,40

Çalışmamızda modellemesini yapıp tahminsel analizlerini aldığımız Doğu ve Güney Doğu Anadolu bölgesinde rüzgâr enerji santrallerinin kurulu olduğu iller ve bu santrallerin kurulu güçleri Çizelge 1.3.'te gösterilmiştir.

Çizelge 1.3. Tez çalışmamızda çalıştığımız illerin kurulu güç miktarları

İl	Kurulu Güç (MW)
Osmaniye	235
Mersin	238
Çanakkale	1042
Balıkesir	1404
Sivas	150
Çankırı	50
Kırıkkale	40
Kırşehir	168
Tokat	136
Sinop	39
Manisa	712
İzmir	1813
Malatya	10
Bingöl	50
Van	50
Gaziantep	86

1.3. Yapay Sinir Ağları ve Sınıflandırılması


YSA, genellikle insan beyninin veya merkezi sinir sisteminin çalışma prensiplerini taklit eden bir bilgi işleme sistemidir [34]. Bu alandaki araştırmalar, başlangıçta biyolojik birimler olan nöronların modellenmesi ve bilgisayar sistemlerine uygulanmasıyla başlamıştır. Nöronlar, bağlantılar aracılığıyla birbirine bağlanır ve

her bağlantı, girdisinin gücünü veya başka bir deyişle önemini belirten sayısal bir ağırlığa sahiptir. Ağırlıklar, YSA'ların uzun vadeli belleğinin temel aracını oluşturur. Bir sinir ağı, bu ağırlıkların tekrar tekrar ayarlanması yoluyla öğrenme sürecini gerçekleştirir [35].

YSA'lar, genellikle tek katmanlı algılayıcılar ve çok katmanlı algılayıcılar olmak üzere iki temel kategoriye ayrılır.

1.3.1. Tek Katmanlı Sinir Ağları

Tek katmanlı yapay sinir ağları, genellikle doğrusal problemleri çözmek için kullanılır ve sadece girdi ve çıktı katmanlarından oluşur. Bu katmanlarda bir veya daha fazla nöron bulunabilir. Şekil 1.9'da, basit bir tek katmanlı algılayıcı modeli gösterilmektedir [36].




Şekil 1.9. Tek katmanlı sinir ağı modeli

Tek katmanlı sinir ağı modellerinin başında gelen önemli iki modelden söz edilebilir. Bunlar; Perceptron Modeli ve Adaline/Madaline Modelidir [37].

1.3.2. Çok Katmanlı Sinir Ağları

Tek katmanlı algılayıcıların doğrusal olmayan problemlerde başarısız olma eğilimi, çok katmanlı algılayıcıların (ÇKA) geliştirilmesine yol açtı. ÇKA'lar, bilgi girişinin yapıldığı girdi katmanı, bir veya daha fazla gizli (ara) katman ve bir çıktı katmanından oluşan daha karmaşık bir yapıya sahiptir. ÇKA'lar, katmanlar arasında ileri ve geri yayılım olarak adlandırılan geçişleri içerir. İleri yayılım safhasında, ağın çıktısı ve hata değeri hesaplanır. Geri yayılım safhasında ise hesaplanan hata değerini minimize etmek için katmanlar arası bağlantı ağırlık değerleri güncellenir. Şekil 1.10'da çok katmanlı sinir ağı modeli gösterilmiştir [36].



Şekil 1.10. Çok katmanlı sinir ağı modeli [36].

ÇKA modeli lineer perceptrondaki en küçük kareler algoritmasının genele uyarlanmasıyla olan geri yayılım öğrenme algoritmasından faydalanır [36].

1.3.3. Geri Yayılım Algoritması

Geri Yayılım Algoritması, yapay sinir ağlarında kullanılan bir öğrenme algoritmasıdır. Geri yayılım (backpropagation) algoritması, yapay sinir ağlarında ağırlıkların güncellendiği bir öğrenme sürecini ifade eder. Bu süreç, ağın çıktısının belirlendiği ileri besleme ve oluşan hatanın gradyanının azaltılması amacıyla geriye doğru yayılan geri besleme safhalarından oluşur. İleri besleme safhasında, eğitim setinin girdileri ağın giriş katmanına sunulur. Giriş katmanı, bu girdileri alan nöronları içerir, bu nedenle giriş katmanındaki nöron sayısı, veri setindeki girdi değeri sayısı ile aynı olmalıdır. Giriş katmanındaki nöronlar, girdi değerlerini doğrudan gizli katmana iletir. Gizli katmandaki her bir nöron, ağırlıklandırılmış girdi değerlerine eşik değeri de ekleyerek toplam değeri hesap eder ve bunları bir aktivasyon fonksiyonu ile işleyerek bir sonraki katmana veya doğrudan çıkış katmanına iletir. Katmanlar arasındaki ağırlıklar başlangıçta genellikle rasgele seçilir [36]. Temel amacı, ağın çıkışındaki hata miktarını minimize ederek öğrenmeyi sağlamaktır.

2. LİTERATÜR ARAŞTIRMASI

Gelişmekte olan dünyada, bilgisayarlar ve bilgisayar sistemleri hayatın vazgeçilmez bir parçası haline gelmiş durumda. Evimizdeki eşyalardan cep telefonlarına kadar birçok cihaz, bilgisayar sistemleri ile entegre bir şekilde çalışıyor. Bu durum, insan beyni ile cihazlar arasındaki etkileşimi kaçınılmaz kılıyor. Tüm bunları düşündüğümüzde, bilgisayar sistemleri ve yapay zekâya olan ilgi gün geçtikçe artıyor ve bu alanla ilgili yapılan çalışmalar da hızla çoğalıyor. Özellikle insansı robotlarla birlikte yapay zekâ ve yapay sinir ağları konusundaki çalışmalar büyük bir ivme kazanmış durumda. YSA'ları, biyolojik sinir ağlarının yapısına benzetilerek geliştirilmiştir [38].

YSA, günlük hayat problemlerinin çözümünde başarıyla kullanılan bir yöntemdir, özellikle sınıflandırma, modelleme ve tahmin gibi alanlarda etkili sonuçlar sağlar. Yapay sinir ağları, nöronlar arasındaki bağlantı ağırlıklarını ayarlayarak öğrenme sürecini gerçekleştirir [39].

Tekin çalışmasında, Çukurova Bölgesi'nden elde edilen gerçek kısa vadeli rüzgâr gücü verileri, inceleme konusu olarak seçilmiş ve MPE-MAPE tasarlanan tahmin modellerinin performans endekslerini karşılaştırmak amacıyla kullanılmıştır [40].

Dirik ve arkadaşlarının çalışmasında, yenilenebilir enerji kaynakları için yapay zekâ teknolojilerinin kullanımı detaylı bir şekilde incelenmiştir. Ayrıca, bu teknolojilerin yenilenebilir enerji kaynaklarındaki kullanımının avantajları ve dezavantajları titizlikle araştırılmıştır. Elde edilen sonuçlara göre, günümüzde yenilenebilir enerji kaynaklarına olan talep hızla artmakta ve yapay zekâ teknolojisinin bu kaynakların daha verimli bir şekilde kullanımına yardımcı olduğu gözlemlenmektedir. Yapay zekâ teknolojisi, enerji üretim verilerinin analizi ve tahmini için kullanılarak enerji üretiminde karşılaşılan zorluklara çözüm sunmaktadır. Bu teknoloji, sadece enerji üretimini artırmakla kalmayıp, aynı zamanda mevcut enerjinin sürdürülebilir bir şekilde kullanımına da katkıda bulunmaktadır. Ancak, yapay zekâ teknolojilerinin potansiyel dezavantajları göz önüne alınarak, yenilenebilir enerji kaynakları için bu teknolojilerin dikkatli bir

şekilde kullanılması önemlidir [41].

Özcan ve arkadaşları çalışmalarında, Isparta iline ait rüzgâr hızları, YSA ve ANFIS yöntemleriyle tahmin edilmiştir. Bu sayede farklı yıllar ve aylardaki rüzgâr hızlarının tahmini mümkün hale gelmiştir [42].

Durğun tez çalışmasında, Türkiye'nin 2023 elektrik enerjisi talebini regresyon analizi ve yapay zekâ teknikleri kullanarak tahmin etmiştir. Bu doğrultuda, Türkiye'nin enerji tüketimini öngörmek için 1980-2017 yılları arasındaki Gayri Safi Yurtiçi Hâsıla, nüfus ve meteorolojik değişken verileri (nem, sıcaklık, rüzgâr ve yağış) tahmin modelinin giriş verileri olarak çalışması kullanılmıştır. Regresyon analizi ve yapay zekâ teknikleri kullanılarak, özellikle Türkiye'nin 2018-2023 yılları arasındaki elektrik enerjisi tüketimi ile yukarıda belirtilen veriler tahmin edilmiştir [43].

Daş ve arkadaşları çalışmalarında, Türkiye'nin farklı bölgelerindeki Sinop ve Adıyaman illerinin rüzgâr enerjisi potansiyeli, 2008-2017 yılları arasında Devlet Meteoroloji İstasyon Müdürlüğü tarafından ölçülen verilere dayanarak istatistiksel olarak analiz edilmiştir. İstatistiksel analiz sürecinde, ortalama rüzgâr hızı, rüzgâr hızının standart sapması, maksimum rüzgâr hızı ve rüzgâr gücü yoğunluğu belirlenmiştir. Rüzgâr hızının dağılımı ve rüzgâr güç yoğunluğunun belirlenmesinde Weibull dağılım fonksiyonu kullanılmıştır. Çalışma sonucunda elde edilen güç yoğunluğu değerleri için DVM regresyonu ile tahminsel modeller oluşturulmuştur. DVM regresyonunda polinom kernel, normalize polinom kernel, radyal tabanlı fonksiyon (RBF) kernel ve Pearson VII (PUK) kernel modelleri kullanılmıştır. DVM regresyonu tahminleri için ortalama mutlak hata (MAE), kök ortalama karesel hata (RMSE), bağıl mutlak hata (RAE) ve kök bağıl karesel hata (RRSE) analizleri yapılmıştır. DVM regresyonu kullanılarak oluşturulan rüzgâr güç yoğunluğu tahminsel modeller arasında en iyi tahminin polinom kernel modeline ait olduğu gösterilmiştir [44].

Sibel tez çalışmasında, Sanayinin hızlı bir şekilde büyümesi ve geleneksel enerji kaynaklarının sınırlı olması, dünya genelindeki pek çok ülkeyi yenilenebilir enerjiye yönlendirmektedir. Türkiye, hızla gelişen ekonomisi ve artan nüfusu ile enerji talebini karşılamakta zorlanmaktadır. Bu bağlamda, enerji ihtiyacını

sürdürülebilir bir biçimde karşılamak için yenilenebilir enerji kaynaklarının daha etkin kullanılması elzemdir. Bu çalışma, Türkiye'deki yenilenebilir enerji kaynaklarının mevcut durumu ve potansiyeli üzerine derinlemesine bir inceleme sunmaktadır. Özellikle rüzgâr enerjisi ele alınarak, Balıkesir, Manisa ve Çanakkale illerindeki potansiyel bölgelerde fizibilite analizleri yapılmıştır. Bu analizler, enerji sektöründe sıklıkla tercih edilen RETScreen yazılımı kullanılarak gerçekleştirilmiştir. Fizibilite çalışmaları sonucunda, Çanakkale, Balıkesir ve Manisa illerindeki bölgeler arasında en uygun rüzgâr enerjisi santrali kurulumu için, yıllık 76.573 MWh enerji üretimi ile Çanakkale bölgesinin en verimli alan olduğu belirlenmiştir [45].

Cenk tez çalışmasında, Osmaniye ilinin Akdeniz Bölgesi'ndeki bir bölgenin rüzgâr enerjisi potansiyelini incelemeyi amaçlamaktadır. Rüzgâr hızı dağılımını belirlemek için Weibull ve Rayleigh dağılım modelleri kullanılmıştır. 2015 yılı boyunca 80 metrelik bir ölçüm direğinden alınan verilerle, bölgenin rüzgâr enerjisi potansiyeli hesaplanmış ve ortalama rüzgâr hızı 7.6 m/s, rüzgâr enerjisi potansiyeli ise 444.85 W/m² olarak bulunmuştur [46].

Ata Mert tez çalışmasında, rüzgâr enerjisi yatırımlarında karşılaşılan olası riskleri incelemek ve rüzgâr ölçüm verilerinin enerji üretimi tahminleri üzerindeki etkisini araştırmıştır. Çalışma, rüzgâr enerjisi projelerinin genel süreçlerini, maliyetlerini ve risk faktörlerini ele alırken, doğru ölçüm verilerinin, enerji üretimi tahminlerini daha güvenilir hale getirdiğini vurgulamaktadır. Veri analizi, aktif bir rüzgâr santralinden elde edilen 18 aylık rüzgâr ölçümleri ile yapılmıştır. Çalışmada, ölçüm süresi ve kullanılan ortalama rüzgâr hızlarının, enerji üretimi tahminleri üzerinde farklı etkiler yarattığı bulunmuştur. Uzun süreli ölçüm verileri ve kısa zaman dilimlerine ait ortalamaların daha doğru sonuçlar sağladığı gözlemlenmiştir. Bu sonuçlar, rüzgâr enerjisi projelerinin daha verimli ve güvenli bir şekilde yönetilebilmesi için doğru verilerin kullanılmasının önemini ortaya koymaktadır [47].

Çağatay tez çalışmasında, teknolojinin ve sanayinin hızla gelişmesiyle birlikte, elektrik talebi de artmaktadır. Elektriğin depolanamaması nedeniyle, üretim ile tüketim arasındaki dengeyi sağlamak çok önemli hale gelmiştir. Bu dengeyi

koruyabilmek ve doğru stratejiler geliştirebilmek için güçlü bir tahmin yeteneği gerekmektedir. Etkili tahminler yapabilmek için ise doğru ve kapsamlı verilere dayalı modeller oluşturulmalıdır. Bu çalışma, TEİAŞ tarafından sağlanan ve günlük olarak rüzgâr enerjisiyle üretilen elektrik miktarını içeren veri seti üzerinde yapılmıştır. Bu çalışmada, Türkiye'de günlük olarak üretilen rüzgâr enerjisiyle elde edilen elektriği tahmin edebilen bir derin öğrenme modeli oluşturmaktır. Derin öğrenme yöntemleri, pek çok tahmin problemünde başarılı sonuçlar elde edilmesini sağlamakta ve dünya genelinde giderek daha fazla kullanılmaktadır. Bu araştırmada, etkili bir tahmin modeli oluşturabilmek için bazı algoritmalar kullanılmış ve bu algoritmaların performansları karşılaştırılmıştır. Modellerin başarısını değerlendirmek amacıyla, farklı gecikme süreleri (lag size) ve düğüm sayıları (number of nodes) test edilmiştir. Başarıyı ölçmek için ise, Belirleme Katsayısı (R^2), (MSE), (RMSE) ve (MAE) gibi metrikler kullanılmıştır. Test verileri üzerinden yapılan değerlendirmelere göre, CNN algoritması en yüksek performansı sergileyen model olarak belirlenmiştir [48].

Ümit tez çalışmasında, çevre dostu ve sürdürülebilir bir alternatif olarak hızla yayılmakta olan rüzgâr enerjisinin; potansiyelini, yapay sinir ağları kullanılarak tahmin edilmiştir. Modelde rüzgâr hızı verileri test, türbin çıkış güçleri ise eğitim aşamasında kullanılmıştır. Yapılan analizlerde tahminlerin güvenilir ve tutarlı olduğu belirlenmiş, bölgedeki rüzgâr potansiyelinin yüksek olduğu ve kaliteli türbinlerle verimli enerji üretiminin mümkün olduğu görülmüştür. Ayrıca, enerji sektöründeki uzmanlar ve karar vericiler için, rüzgâr enerjisi projelerinde yapay sinir ağlarının etkili bir şekilde kullanılabileceği vurgulanmıştır [49].

Nilay tez çalışmasında, son yıllarda dünya genelinde yenilenebilir enerji kaynakları arasında önemli bir konum kazanmış rüzgâr enerjisi hakkında çalışmıştır. Rüzgâr enerjisinin temel özellikleri ve Türkiye'deki mevcut durumu üzerinde durmakta, aynı zamanda rüzgâr türbinleri ve jeneratörlerinin rolü de ele alınmaktadır. Türkiye'nin farklı illerinden seçilen Sinop, Bursa, Elazığ, İskenderun, Karaman, Adıyaman ve Muğla illerinde, Meteoroloji Genel Müdürlüğü tarafından 2005-2014 yılları arasında saatlik olarak ölçülen rüzgâr hızı verileri kullanılarak, bu illerin rüzgâr enerjisi potansiyeli istatistiksel yöntemlerle belirlenmiştir [50].

İbrahim Halil tez çalışmasında, Enerji, toplumların temel gereksinimlerini

karşlamak için kritik bir öneme sahiptir ve bu nedenle enerji politikaları, ülkelerin üretim kapasiteleri ile yaşam kaliteleri üzerinde doğrudan bir etkiye sahiptir. Rüzgâr enerjisi, son yıllarda hızla gelişen ve iklim değişikliğiyle mücadelede önemli bir rol üstlenen yenilenebilir bir enerji kaynağıdır. Türkiye'de, rüzgâr enerjisinin teşvik edilmesi amacıyla özel alım garantileri ve yerli ekipman kullanımı için ek teşvikler sunulmaktadır. Ancak, rüzgâr gibi yenilenebilir enerji kaynakları, verimlilik açısından dalgalanma gösterdiğinden, kesintisiz enerji sağlanabilmesi için enerji karışımında çeşitlilik gerekmektedir. APLUS Bilgisayar Programı, Türkiye elektrik piyasasında rüzgâr enerjisinin teşviklerinin fiyatlar üzerindeki etkilerini modellemektedir. Bu yazılım, arz ve talep dengesini inceleyerek, spot elektrik fiyatlarını öngörmeyi mümkün kılar. Sonuç olarak, yenilenebilir enerji kaynaklarının artışı, elektrik fiyatlarını düşürerek daha uygun maliyetli ve çevre dostu enerji üretimi sağlar, ancak sürdürülebilir bir enerji tedariki için dikkatli bir planlama ve teşvik sistemleri gereklidir [51].

Pelletier tez çalışmasında, son on yılda, rüzgâr enerji santrallerinin kapasite ve güç çıktısı önemli ölçüde artmıştır, bu da küçük güç artışlarını bile ekonomik olarak cazip kılmaktadır. Bu gelişmeyle birlikte, rüzgâr türbinlerinin güç eğrilerinin daha hassas bir şekilde değerlendirilmesi ihtiyacı da artmıştır. YSA, türbinlerin güç çıktısı ile parametreleri arasındaki karmaşık ilişkiyi modellemek için etkili bir yöntem olarak öne çıkmaktadır. Araştırmalar, çok katmanlı algılayıcı (MLP) kullanan modelleme tekniklerinin, geleneksel yöntemlere göre daha düşük hata oranları sağladığını göstermektedir. Ayrıca, YSA modeli, birden fazla parametreyi aynı anda işleyebilme yeteneğine sahip olup, altı parametreyle başarılı bir şekilde güç eğrisi modellemesi yapılmıştır. Bu parametreler, elliden fazla seçenek arasından seçilmiştir ve gerekirse yeni parametreler de eklenebilir [52].

Papathanassiou tez çalışmasında, rüzgâr enerjisi üretiminde Yapay Zekâ tekniklerinin iki önemli uygulamasını incelemektedir. İlk uygulama, 20 kW'lık bir rüzgâr türbini prototipi için kalıcı mıknatıs jeneratörünün tasarımını ele alırken, bu çalışma Yunanistan'daki bir araştırma projesi kapsamında dişlisiz bir türbinin tasarımı ve inşası üzerine odaklanmaktadır. İkinci uygulama ise rüzgâr çiftliklerinin yer aldığı ağların güvenlik değerlendirmesini konu almakta ve Avrupa Birliği'nin

JOULE-II araştırma programı çerçevesinde geliştirilmiştir. Bu çalışmada, YSA ve Karar Ağaçları kullanılarak Lemnos adasında enerji sisteminin hızlı güvenlik değerlendirmesi yapılmış ve sonuçlar karşılaştırmalı olarak sunulmuştur [53].

Jursa ve arkadaşları tez çalışmasında, rüzgâr enerjisinin kısa vadeli tahminini yapmak için evrimsel optimizasyon algoritmalarının kullanımını öneriyor. Yapay sinir ağları ve en yakın komşu arama gibi iki yaygın tahmin modeli, bu algoritmalarla otomatik olarak belirleniyor. Parçacık sürü optimizasyonu ve diferansiyel evrim gibi iki farklı algoritma karşılaştırılarak, rüzgâr çiftliğinin geçmiş verileri ve hava durumu verileri kullanılarak tahmin yapılmaktadır. Bu yöntem, geleneksel manuel değişken seçimlerine göre daha doğru sonuçlar veriyor ve model çıktılarının ortalamasını kullanarak hata payını daha da azaltabiliyor [54].

Xuenjing ve arkadaşları çalışmasında, rüzgâr enerjisi kararları için bir sistem geliştiriyor ve iki ana modül sunuyor: rüzgâr enerjisi potansiyeli analizi ve rüzgâr hızı tahmini. Sürü zekâsı optimizasyonu kullanılarak, rüzgâr enerjisi potansiyelini daha doğru değerlendirmek için Weibull dağılımı parametreleri optimize ediliyor. Ayrıca, veri ön işleme tekniğiyle rüzgâr hızı verilerindeki gürültü azaltılarak tahmin modelinin doğruluğu artırılıyor. Elde edilen sonuçlar, bu karar sisteminin rüzgâr enerjisi değerlendirmesini doğru ve etkili şekilde yaparken, rüzgâr hızı tahminlerinde de başarılı olduğunu ortaya koyuyor. Bu sistem, rüzgâr çiftliklerinin yönetimi ve karar alma süreçlerinde faydalı bir araç olabilir [55].

Duer tez çalışmasında, yapay sinir ağı kullanan akıllı sistemlerde teknik nesnelerin yenileme süreçlerinin kalitesini simülasyon yoluyla incelemektedir. Teknik nesneler, kullanım sırasında hasar görüp onarılmakta, bu da bakım gereksinimini doğurmaktadır. Makalede, bakım süreçlerinin etkinliğini değerlendirmek için bir simülasyon araştırma programı sunulmakta, bu programda nesnelerin işletim süreçleri ve bakım süreleri dikkate alınarak yenileme kalitesini ölçen kriterler belirlenmektedir. Elde edilen sonuçlar, yapay sinir ağı tabanlı bir sistemde nesnelerin yenilenmesinin etkilerini ortaya koymaktadır [56].

Jafarian ve arkadaşları çalışmasında, rüzgâr enerjisi üretimini tahmin etmek için Box-Jenkins ve YSA modelleri kullanılmış ve en iyi tahmin yöntemi belirlenmiştir. Araştırma, YSA ile iyileştirilmiş YSA-genetik algoritma (YSA-GA)

modelinin en iyi performansı gösterdiğini, ancak ARIMA modelinin daha düşük hata payı ve daha yüksek doğrulukla çok daha başarılı tahminler sunduğunu ortaya koymuştur. ARIMA yönteminin, diğer YSA tabanlı yöntemlere göre daha etkili olduğu sonucuna varılmıştır [57].

Bouabdallaoui ve arkadaşları bu çalışmasında, rüzgâr enerjisi tahmini için kullanılan YZ ve meta-heuristik algoritmalarını incelemektedir. İki ana kategoriye ayrılmaktadır: Birincisi, yaygın olarak kullanılan geleneksel yöntemler (YSA, SVM, bulanık mantık gibi), ikincisi ise bu klasik yöntemlerle meta-heuristik algoritmaların birleşiminden oluşan hibrit yaklaşımdır. Hibrit yöntemlerin, yalnızca klasik yöntemlerden daha yüksek performans sağladığı ve daha doğru tahminler sunabileceği vurgulanmaktadır. Her iki yaklaşımın avantajları ve sınırlamaları karşılaştırılmıştır [58].

Yeh ve arkadaşları çalışmasında, Tayvan'daki Mai Liao Rüzgâr Enerji Santrali'nden elde edilen verilerle rüzgâr enerjisi üretimini tahmin etmek amacıyla bir model geliştirilmiştir. Model, MLP kullanılarak oluşturulmuş ve geliştirilen Basitleştirilmiş Sürü Optimizasyonu (SSO) algoritması, ağırlıklar ve sapmaların düzeltilmesiyle iyileştirilmiştir. Ayrıca, önerilen algoritma, özellik seçiminde Temel Bileşen Analizi (PCA), Otokorelasyon Fonksiyonu (AF) ve Kısmi Otokorelasyon Fonksiyonu (PAF) bileşenlerini kullanarak modelin verimliliğini artırmıştır. Deneysel sonuçlar, önerilen iSSO algoritmasının diğer popüler algoritmalara kıyasla daha iyi bir performans sergilediğini göstermektedir [59].

Dinh Thanh Vietman bu çalışmasında, konvansiyonel enerji kaynaklarının hızla tükenmesi nedeniyle, yenilenebilir enerji kaynaklarının, özellikle de rüzgâr enerjisinin, elektrik piyasasında artan küresel enerji talebini karşılamak için daha fazla kullanılmasının önemi giderek artmaktadır. Ancak, hava koşullarındaki belirsizlikler rüzgâr enerjisi tahminlerinde büyük hatalara yol açabilir, bu da güç rezervasyon maliyetlerini artırır ve elektrik piyasasındaki yan hizmetlere ciddi etkilerde bulunabilir. Bu makalede, rüzgâr enerjisi üretimini kısa vadeli tahmin etmek amacıyla, yapay sinir ağı ve parçacık sürü optimizasyonu algoritması ile genetik algoritmanın birleştiği iki yeni model kullanarak daha doğru tahminler yapılmasını sağlamak için çift optimizasyon yaklaşımı önerilmektedir. Bu

modellerde, ilk olarak, doğruluğu artırmak için sinir ağı parametrelerini ayarlamak amacıyla parçacık sürü optimizasyonu algoritması kullanılır. Sonrasında ise, tahmin doğruluğunu daha da artırmak için genetik algoritma veya başka bir parçacık sürü optimizasyonu, ilk algoritmanın parametrelerini optimize eder. Modeller, Vietnam'daki Binh Thuan Eyaleti'nde bulunan Tuy Phong rüzgâr enerjisi santralinden alınan verilerle test edilmiştir. Testler, modelin doğruluğunun arttığını ve bu yaklaşımın diğer rüzgâr santrallerinde de etkili bir şekilde uygulanabileceğini göstermiştir [60].

Farrar ve arkadaşları çalışmalarında, modern enerji sistemlerinde şebeke bağlantılı rüzgâr santralleri giderek daha yaygın hale gelirken, rüzgâr enerjisi üretimini artırmak ve duruş sürelerini azaltmak için etkili yöntemler geliştirmek araştırmacılar için önemli bir konu olmuştur. Rüzgâr türbinlerinin karmaşıklığı ve rüzgâr hızlarının tahminindeki zorluklar nedeniyle YZ ve MÖ algoritmaları, denetleyici sistemlerin geliştirilmesinde temel araçlar haline gelmiştir. Bu alanda son yıllarda birçok inceleme yapılmış olsa da, hem YZ hem de MÖ teknolojilerini içeren kapsamlı bir çalışma bulunmamaktadır, özellikle de en son kontrol teknikleri ile ilgili. Bu eksiklikleri gidermek amacıyla bu makale, rüzgâr türbini sistemlerinde YZ ve MÖ kullanımına dair derinlemesine bir inceleme sunmaktadır. Makalede, rüzgâr enerjisi santrallerinde güç üretiminin optimize edilmesinin önemi, verimli kontrol sistemleri tasarlarırken karşılaşılan zorluklar ve kullanılan YZ ve MÖ algoritmalarının türleri ele alınmaktadır. Ayrıca, rüzgâr hızı ve güç tahmini, mekanik bileşenlerin izlenmesi ve arıza tespiti, elektriksel arıza öncesi tespiti gibi konularda YZ ve MÖ'nün nasıl uygulandığı da tartışılmaktadır. Bu inceleme, rüzgâr enerjisi üretimindeki mühendisler ve araştırmacılar için etkili kontrol şemalarının geliştirilmesine yardımcı olacaktır [61].

Li ve arkadaşları çalışmasında, rüzgâr türbini güç eğrilerinin tahmini için kullanılan regresyon ve yapay sinir ağı modellerini incelemekte ve karşılaştırmaktadır. İlk olarak, rüzgâr türbini güç üretiminin özellikleri araştırılmaktadır. Ardından, hem regresyon hem de sinir ağı yöntemleri kullanılarak türbin güç eğrisi tahmini için modeller sunulmakta ve karşılaştırılmaktadır. Regresyon modeli için parametre tahminleri ve sinir ağının eğitimi, rüzgâr enerjisi

santrali verileriyle tamamlanmakta ve iki modelin performansları incelenmektedir. Regresyon modelinin fonksiyon bağımlı olduğu gösterilirken, sinir ağı modeli güç eğrisini öğrenme yoluyla tahmin etmektedir. Sinir ağı modelinin, karmaşık etki faktörleri altında türbin güç eğrisi tahmini için regresyon modelinden daha iyi performans gösterdiği bulunmuştur [62].

Yousuf ve arkadaşları bu çalışmada, geleneksel yöntemlerin işletme ve sevk durumlarını karşılayamayacağı yerlerde, bu teknolojilerin nasıl kullanıldığı açıklanmaktadır. Ayrıca, bu yöntemler gerilim, stabilite, güç akışı ve yük frekansı gibi faktörleri kontrol ederek güç sisteminin işletimini ve verimliliğini artırır. Ayrıca, ağın otomasyonu, iyileştirme, arıza teşhisi, yönetim ve ağ güvenliğini destekler. Son olarak, yapay zekânın güç sistemlerinde sürdürülebilir kullanımını ele alır [63].

Porte ve arkadaşları bu çalışmada, rüzgâr enerjisinin, diğer yenilenebilir enerji kaynaklarıyla birlikte, önümüzdeki on yıllarda önemli bir büyüme göstermesi ve iklim değişikliğiyle mücadele ve enerji sürdürülebilirliğine katkı sağlaması beklenmektedir. Ancak, rüzgâr çiftliklerinin tasarımı, işletmesi, kontrolü ve şebeke entegrasyonunun optimize edilmesi, rüzgâr çiftlikleri ile atmosferik sınır tabakası (ABL) arasındaki karmaşık etkileşimler nedeniyle zorlu bir süreçtir. Bu inceleme, ABL akışının rüzgâr türbinleriyle etkileşimlerini daha iyi anlamamıza ve tahmin etme yeteneğimizi geliştirmemize katkı sağlayan araştırmaları özetlemektedir [64].

3. MATERYAL VE YÖNTEM

3.1. Makine Öğrenimi ve Regresyon Algoritmaları

Bilgisayar sistemlerinin belirli bir görevi, deneyim ve veri kullanarak öğrenmesini sağlayan yapay zekâ dallarından biri MO'dır. MO'nun temel amacı, bir modelin belirli bir görevi gerçekleştirmesini sağlamaktır. Ancak, bu modeller genellikle çok sayıda parametreye sahip olduğu için, veriye aşırı uyum (overfitting) gibi sorunlarla karşılaşabilirler. Bu tür sorunları ele almak için regresyon algoritmaları kullanılır.

Regresyon, bir modelin karmaşıklığını kontrol etmek ve aşırı uyum gibi sorunları önlemek için kullanılan bir tekniktir. İki yaygın regresyon türü şunlardır:

3.1.1. Doğrusal Regresyon Algoritmaları

3.1.1.1. Çoklu doğrusal regresyon (multiple linear regression - mlr)

Ekonomi ve işletmecilik alanlarında, bir bağımlı değişkeni sadece tek bir bağımsız değişkenle açıklamak genellikle yeterli değildir. Ekonomik modeller, genellikle bir sonuca ulaşmak için birden fazla faktörün etkileşimini içerir. Bir dizi değişken, bir başka değişkeni etkileyebilir ve bu değişkenler aynı zamanda birbirleriyle etkileşime girebilir. Bu nedenle, birden fazla değişkenin bir araya gelerek bir diğer değişkeni etkilemesi durumunda, tek bir bağımsız değişkenle yapılan regresyon analizi yeterli olmayabilir. Bu tür durumlarda, çoklu regresyon analizi kullanılır. Çoklu regresyon analizi, birden fazla bağımsız değişkenin bir bağımlı değişken üzerindeki etkisini değerlendirir. Bu analiz, karmaşık ilişkileri tanımlamak, değişkenler arasındaki etkileşimleri anlamak ve daha kapsamlı bir model oluşturmak için kullanılır. Çoklu regresyon analizi, ekonomik ve işletmecilik modellerini daha gerçekçi ve kapsamlı hale getirerek, çeşitli faktörlerin bir araya geldiği karmaşık ilişkileri anlamaya yardımcı olur. Bu analiz, iş kararları almak, ekonomik tahminlerde bulunmak veya belirli bir sonuca ulaşmak için kullanılan güçlü bir istatistiksel araçtır [65].

Çoklu regresyon denklemi genel olarak şu şekilde ifade edilir:

$$Y = a_0 + a_1X_1 + a_2X_2 + \dots + a_kX_k + e_i = a_0 + \sum_{r=1}^k a_r X_r + e_i \quad (3.1)$$

- Y : Bağımlı değişken,
- a_0 : Kesme terimi (intercept),
- $a_1, a_2, \dots, a_k$: Bağımsız değişkenlerin katsayıları,
- $X_1, X_2, \dots, X_3$: Bağımsız değişkenler
- e : Hata terimi (modelin açıklamadığı varyansı temsil eder).

3.1.1.2. Temel bileşen regresyonu (principal component regression - pcr)

PCR (Principal Component Regression), aslında bir doğrusal regresyon yöntemidir. Ancak, çoklu doğrusallıkla başa çıkmak için bağımlı değişken, bağımsız değişkenler yerine temel bileşenlere regresyon uygular. Temel bileşen sayısı, X 'in varyasyonunun maksimumunu elde edilerek belirlenir. Diyelim ki γ_i 'ler, korelasyon matrisi olan $X^T X$ 'in özdeğerleri ve $X^T X$ 'ler, 'in birim normlu özvektörleridir [66-70].

Vektör γ_i , X 'in PC Z 'leriyle ifade edilebilmesi için aşağıdaki formda kullanır.

$$X^T X \gamma_i = \lambda_i \gamma_i, \quad i = 1, 2, \dots, k$$

Tüm Z_i 'ler birbirine diktir ve PCR tahmincisi aşağıdaki eşitlikler yardımıyla bulunur:

$$Z_i = \gamma_{\{1i\}X_1} + \gamma_{\{2i\}X_2} + \dots + \gamma_{\{ki\}X_k}$$

$$\beta_{\{PCR\}} = V_m \alpha_m$$

Burada $\alpha_m = (Z_m^T Z_m)^{-1} Z_m^T y$, modelde tutulan PC sayısı, V_m ise ilk m birim-norm özvektörlerinden oluşan bir matristir.

3.1.1.3. Kısmi en küçük kareler regresyon (partial least squares regression - pls)

PLS (Partial Least Squares), açıklayıcı değişkenlerin çok sayıda ve yüksek derecede doğrusal ilişkili olduğu durumlarda öngörü modelleri oluşturmak için 1960'larda Herman Wold tarafından geliştirilen nispeten yeni bir yöntemdir [69,71,72]. PLS, herhangi bir sayıda açıklayıcı değişkenle kullanılabilir, hatta gözlem sayısından daha fazla olabilir. PLS, kimyacılar tarafından yoğun bir şekilde

tanıtılıp kullanılmasına rağmen, istatistikçiler tarafından genellikle bilinmez. Y değişkenlerini $X_1, \dots, X_p$ açıklayıcı değişkenleriyle regresyon yapmak için, PLS, X 'lerin yerine geçecek yeni faktörleri bulmaya çalışır. Bu yeni faktörler genellikle gizli değişkenler veya bileşenler olarak adlandırılır. Her bir bileşen, $X_1, \dots, X_p$ 'nin bir lineer kombinasyonudur. PCR ile bazı benzerlikler bulunmaktadır. Her iki yöntemde de Y değişkenleri ile regresyon yapılacak bazı faktörleri bulma çabaları vardır. Ana fark şudur: PCR, yeni faktörleri oluşturmak için yalnızca X 'in varyasyonunu kullanırken, PLS, açıklayıcı değişkenlerin rolünü üstlenecek yeni faktörleri oluşturmak için hem X 'in hem de Y 'in varyasyonunu kullanır. PLS'nin amacı, X değişkenlerinin çoğunu içeren bileşenleri oluşturmaktır [73]. Bu bileşenler, $Y_1, \dots, Y_q$ 'yi tahmin etmek için kullanışlı olan bilgiyi çoğunlukla yakalamaktadır, aynı zamanda regresyon probleminin boyutunu azaltarak X değişkenlerinin sayısından daha az sayıda bileşen kullanmaktır. Şimdi PLS'nin β ve B tahmincilerini türetmeye geçeceğiz. Matris X 'in aşağıdaki gibi bir bikatlı ayrışımı vardır;

$$X = t_1 p'_1 + t_2 p'_2 + \dots + t_p p'_p = TP' \quad [72].$$

3.1.1.4. Ridge regresyon (RR)

Ridge regresyon (RR) modelinde $X^T X$ matrisi korelasyon formunda olmak üzere $X^T X$ matrisinin köşegen öğelerine küçük k değerlerinin ($k \geq 0$) eklenmesiyle ridge regresyon elde edilir (Hoerl ve Kennard 1970). Bu tahminci, OLS "Ordinary Least Squares" (Normal En Küçük Kareler) ile benzerdir. Ancak, diyagonal elemanlara pozitif bir sayı k eklenmesi, $X^T X$ matrisinde tekil olmayan bir sorunu ele alır. k değerini belirlemek, ridge regresyonunun önemli bir kısmını oluşturur. Hedef, OLS tahmincisine göre varyansı azaltacak kadar büyük, ancak kabul edilebilir bir düşük önyargı üretecek kadar küçük olan bir k bulmaktır [74].

3.1.1.5. Lasso regresyonu (LR)

Lasso Regresyon, en küçük kareler (EKK) yöntemine alternatif bir yanlı tahmin yöntemi olarak öne çıkar. Bu yöntem, çoklu doğrusal bağlantı ve aşırı öğrenme sorunlarına etkili bir çözüm sunabilir. Lasso Regresyon, değişken seçimi ve regularizasyonun eş zamanlı olarak gerçekleştiği bir regresyon tekniği olarak bilinir. Yüksek etkinlik ve hızı sayesinde, özellikle büyük veri setlerinde geniş bir uygulama

alanına sahiptir. EKK modelinin uygulanmasının zor olduğu düşük gözlem sayısına sahip durumlarda, biyo istatistikte Lasso Regresyon sıkça tercih edilir. Çapraz doğrulama ve ceza parametresi kullanımı, modelin bu zorlu koşullarda dahi başarılı bir şekilde kurulabilmesine olanak tanır. Lasso Regresyon, Ridge regresyonda olduğu gibi bir ceza terimi kullanarak (L1 tipi cezalandırma), regresyon katsayılarını sıfıra doğru zorlar. Bu ceza terimi, regresyon katsayılarına uygulanacak büzülme miktarını belirler [74].

3.1.1.6. ElasticNet

Elastic net prosedürü, ridge regresyonu ile lasso arasında bir köprü sağlayan lineer regresyon için düzenlenmiş bir optimizasyon formudur. Ürettiği tahmin, elastic net cezasının şekli tarafından ima edilen bir önceki dağılım altında bir Bayesian posterior modu olarak görülebilir [75].

3.1.2. Doğrusal Olmayan Reglesyon Algoritmaları

3.1.2.1. K-en yakın komşu (k nearest neighbors - knn)

K-NN algoritması, T. M. Cover ve P. E. Hart tarafından önerilen bir sınıflandırma yöntemidir, bu yöntemde örnek veri noktasının bulunduğu sınıf ve en yakın komşuların k değerine göre belirlendiği. Bu algoritma, en bilinen, eski, basit ve etkili örüntü sınıflandırma yöntemlerinden biridir ve makine öğrenme algoritmaları arasında geniş bir popülerlik kazanmıştır [76].

3.1.2.2. Çok katmanlı algılayıcı (multilayer perceptron – mlp)

MLPNN (Çok Katmanlı Algılayıcı Sinir Ağı), birçok tespit ve tahmin işlemini gerçekleştiren parametrik olmayan bir yapay sinir ağı tekniğidir. MLPNN'de, her bir gizli katmandaki j nöronu, giriş işaretlerinin wji bağlantı ağırlığı ile çarpımlarının toplamını alır ve yj çıkışını bu toplamın bir fonksiyonu olarak hesaplar [77-78].

$$yj = f (\sum wji xi)$$

3.1.2.3. Classification & regression tree (cart)

Sınıflandırma ve regresyon ağacı yöntemi, analiz edilen verilerin özelliklerine göre farklı isimlerle adlandırılmaktadır. Bağımlı

değişken kategorik olduğunda Sınıflandırma Ağacı yöntemi kullanılırken, bağımlı değişken sürekli olduğunda ise Regresyon Ağacı yöntemi tercih edilmektedir [79].

3.1.2.4. Rastsal orman (random forest – rf)

Toplu sınıflandırma yöntemleri, bir sınıflandırıcı yerine bir dizi sınıflandırıcıdan oluşan ve ardından yeni veri noktalarını tahminlerini oylarıyla sınıflandıran öğrenme algoritmalarıdır. En yaygın kullanılan toplu sınıflandırıcılar arasında Bagging, Boosting yanısıra RF bulunmaktadır [80].

3.1.2.5. LightGBM

Gradient Boosting Decision Tree (GBDT), popüler bir makine öğrenme algoritmasıdır. XGBoost ve pGBRT gibi birkaç etkili uygulamaya sahiptir. Bu uygulamalarda birçok mühendislik optimizasyonu benimsenmiş olmasına rağmen, özellik boyutu yüksek ve veri boyutu büyük olduğunda verimlilik ve ölçeklenebilirlik hala tatmin edici değildir. Temel bir neden, her özellik için tüm veri örneklerini tarayarak tüm olası bölme noktalarının bilgi kazançlarını tahmin etmeleri gerektiğidir ki bu çok zaman alıcıdır [81].

3.1.2.6. Category boosting (catboost)

CatBoost'un Gradient Boosting'e yaptığı ilk geliştirme, yüksek kardinaliteye sahip kategorik değişkenlerle başa çıkma yöntemidir. Düşük kardinaliteye sahip kategorik değişkenler için, CatBoost one-hot encoding kullanır. Düşük kardinalitenin kesin tanımı, hesaplama ortamına ve kullanıcının CatBoost'u özel modlarda kullanıp kullanmadığına bağlıdır [82].

3.1.2.7. Destek vektör regresyonu (support vector regression — svr)

İstatistiksel öğrenme veya Vapnik-Chervonenkis (VC) teorisine dayanan destek vektör makineleri (SVM'ler), henüz görülmemiş verilere genelleme yapma konusunda iyi bir konumda bulunmaktadır. 3. bölümde sunulan SVM kavramları, regresyon problemlerine uygulanabilir hale gelmek üzere genelleştirilebilir. Sınıflandırmada olduğu gibi, destek vektör regresyonu (SVR), çekirdeklerin, seyrek çözümün ve VC'nin marj kontrolü ve destek vektör sayısının kullanımıyla karakterizedir [83].

3.1.2.8. Bagged trees

Bootstrap toplama veya bagging, Breiman (1996a) tarafından önerilen bir tekniktir ve birçok sınıflandırma ve regresyon yöntemi ile kullanılabilir. Bu teknik, tahminle ilgili varyansı azaltmak ve böylece tahmin sürecini iyileştirmek amacıyla kullanılır. Oldukça basit bir fikir üzerine kuruludur: mevcut veriden birçok bootstrap örneği çekilir, her bir bootstrap örneğine bir tahmin yöntemi uygulanır ve ardından sonuçlar, regresyon için ortalamaya ve sınıflandırma için basit bir oylamaya dayalı olarak birleştirilir. Bu şekilde, varyansın ortalamaya bağlı olarak azaltılmasıyla genel tahmin elde edilir [84].

3.1.2.9. Xgboost

Bu, R'deki xgboost paketini kullanmaya yönelik bir giriş dokümanıdır. xgboost, eXtreme Gradient Boosting paketinin kısaltmasıdır. Bu, (Friedman, 2001) ve (Friedman et al. 2000) tarafından geliştirilen gradyan artırma çerçevesinin verimli ve ölçeklenebilir bir uygulamasıdır. Paket, etkili bir lineer model çözücüsü ve ağaç öğrenme algoritması içermektedir. Regresyon, sınıflandırma ve sıralama dahil olmak üzere çeşitli amaç fonksiyonlarını destekler. Paket, genişletilebilir olacak şekilde tasarlanmıştır, bu nedenle kullanıcılar kendi amaçlarını kolayca tanımlayabilirler [85].

3.2. Performans Metrikleri

Performans metrikleri, bir modelin veya algoritmanın ne kadar iyi çalıştığını değerlendirmek için kullanılan ölçütlerdir. Hangi metriklerin kullanılacağı, belirli bir probleme ve kullanılan öğrenme görevine bağlı olarak değişebilir.

Son yıllarda, rüzgâr enerjisi sektöründeki gelişmeler, bölgesel rüzgâr rejimlerini daha hassas bir şekilde tahmin etmeyi gerektirmiştir. Bu bağlamda, rüzgâr hızı frekans dağılımlarını belirlemede kullanılan istatistiksel yöntemler arasında özellikle Weibull ve Rayleigh dağılımları öne çıkmaktadır. Bu dağılımların benzersiz avantajları, özellikle esnek yapıları ve parametrelerinin belirlenmesindeki kolaylık, rüzgâr enerjisi projelerinin planlamasında ve tasarımında önemli bir rol oynamaktadır.

Weibull ve Rayleigh dağılımlarının kullanımının yaygınlaşmasında etkili olan

bir diğerk faktör de, bu dağılımların hata analizlerinin sağlam bir temele dayanmasıdır. Belirleme katsayısı (R^2), RMSE ve X^2 gibi kriterlerle yapılan bu analizler, modellerin ne kadar doğru ve güvenilir olduğunu değerlendirmek adına önemli bir referans sağlamaktadır. Anderson–Darling ve Kolmogorov–Smirnov gibi testlerle dağılımların güç yoğunlukları ve ortalama hızları incelenerek, tahmin modellerinin gerçek dünya koşullarına ne kadar uygun olduğu daha detaylı bir şekilde değerlendirilebilmektedir [44].

RMSE (Root Mean Squared Error), NRMSE (Normalized Root Mean Squared Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error), ve R^2 , regresyon modellerinin performansını değerlendirmek için kullanılan yaygın regresyon ölçütleridir.

3.2.1. RMSE (Root Mean Squared Error)

Hata karelerinin ortalamasının karekökü alınarak hesaplanır. Genellikle hata miktarının büyüklüğünü ölçmek için kullanılır. Düşük RMSE değeri, modelin daha iyi performans gösterdiğini gösterir [86].

3.2.2. NRMSE (Normalized Root Mean Squared Error)

RMSE değerinin bir ölçütüdür ve genellikle farklı ölçeklerdeki verileri karşılaştırmak için kullanılır. Veri setinin varyansına oranlanarak normalize edilir. 0 ile 1 değerleri arasında bir değer alır, 0'a yaklaşan değer daha iyi bir uyum gösterir [87].

3.2.3. MAE (Mean Absolute Error)

Hata terimlerinin mutlak değerlerinin ortalamasıdır. Aykırı değerlere duyarlı değildir ve hata miktarının büyüklüğünü ölçer [88].

3.2.4. MAPE (Mean Absolute Percentage Error)

Hata oranlarının mutlak değerlerinin ortalamasıdır ve genellikle yüzde cinsinden ifade edilir.

Gerçek değerlere oranla hataların yüzdesel büyüklüğünü ölçer. Yüzde cinsinden ifade edildiği için ölçek bağımsızdır [88].

3.2.5. Belirleme Katsayısı (R^2)

Bağımlı değişkenin varyansının ne kadarının bağımsız değişkenler tarafından açıklandığını gösteren bir istatistik değeridir. 1'e yaklaşan değer, modelin veriyi çok iyi açıkladığını gösterir. 0 ise modelin hiç açıklama yapmadığını ifade eder.

Bu ölçütler, regresyon modellerinin performansını değerlendirmek ve karşılaştırmak için kullanılır. İdeal durumda, düşük RMSE, MAE, MAPE ve yüksek R^2 değerleri istenir ve NRMSE'nin 0'a yaklaşması beklenir [88].



4. DENEYSEL SONUÇLAR VE TARTIŞMA

Bu bölümde ülkemizde bölgelere göre rüzgâr enerji santrali bulunan illerde veriler alınarak eğitilen modellerle incelenmesi için metrik değerler ve tablo üzerinden karşılaştırma yapılmıştır. Belirlenen tüm iller için üretilen elektrik miktarının tahmin edilmesi için 12 çeşit makine öğrenmesi algoritması ile test yapılmıştır. 5 adet farklı metrik ile karşılaştırma yapılmış olup tablolarda sunulmuştur.

4.1. Akdeniz Bölgesi Tahmin Sonuçları

4.1.1. Osmaniye İli Tahmin Sonuçları

Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Osmaniye ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.1. Osmaniye iline ait makine öğrenmesi modellerinin karşılaştırması


	DOĞRUSAL REGRASYON ALGORİTMALARI											
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.43	10.76	9.78	11.17	9.35	10.68	8.08	9.23	9.31	10.63	8.05	9.19
RMSE	9.40	9.70	9.75	10.07	9.32	9.62	8.06	8.32	9.28	9.58	8.02	8.28
MAE	4.14	4.26	3.26	3.36	4.19	4.32	3.78	3.89	3.93	4.05	4.59	4.73
MAPE	17.81	18.54	14.04	14.61	18.05	18.79	16.27	16.94	16.92	17.62	19.77	20.59
R2	96.86	96.86	89.16	89.16	95.33	95.33	88.12	88.12	88.18	88.18	89.06	89.06
	DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI											
	GBM		CART		XGBOOST		LIGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.43	10.78	9.60	10.96	9.19	10.50	9.96	11.38	9.12	10.42	9.39	10.72
RMSE	9.41	9.71	9.57	9.88	9.17	9.46	9.93	10.25	9.09	9.38	9.36	9.66
MAE	3.74	3.85	3.31	3.40	3.02	3.11	3.27	3.36	3.58	3.69	3.14	3.23

Çizelge 4.1.'in devamı

MAPE	16.11	16.77	14.24	14.83	13.01	13.54	14.07	14.65	15.42	16.05	13.51	14.06
R2	94.82	94.82	88.96	88.96	92.19	92.19	91.08	91.08	88.85	88.85	95.24	95.24

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı herhangi bir regresyon yoktur. Bu sonuç bahsi geçen modellerin doğru çalıştığını göstermekle birlikte gerçeğe çok yakın tahmin modelleri olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Osmaniye için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R^2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modelleri MLR ve PLSR'dir. Doğrusal olmayan regresyonlarda ise yüksek R^2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan GBM ve KNN regresyonlardır. Osmaniye ilimiz için MLR regresyonu ile %96.8695 değerinde tahmin analizi yapılabilir.

Şekil 4.1 de Osmaniye doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Osmaniye ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.1. Osmaniye çoklu doğrusal regresyon grafiği

4.1.2. Mersin İli Tahmin Sonuçları


Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Mersin ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.2. Mersin iline ait makine öğrenmesi modellerinin karşılaştırması

DOĞRUSAL REGRASYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8.55	9.77	8.36	9.55	8.51	9.72	9.26	10.58	8.43	9.63	9.82	11.22
RMSE	8.53	8.80	8.33	8.60	8.48	8.76	9.23	9.53	8.4	8.67	9.8	10.11
MAE	3.29	3.39	3.71	3.82	3.38	3.48	3.57	3.67	4.13	4.25	3.69	3.80
MAPE	14.18	14.76	15.98	16.64	14.55	15.14	15.36	15.99	17.78	18.51	15.90	16.55
R2	88.04	88.04	93.30	93.30	88.34	88.34	92.79	92.79	89.90	89.90	92.51	92.51
DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LIGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8.67	9.90	8.47	9.68	9.71	11.09	9.64	11.01	9.64	11.01	9.28	10.60
RMSE	8.64	8.92	8.45	8.72	9.68	9.99	9.61	9.92	9.61	9.92	9.25	9.55
MAE	3.13	3.22	3.22	3.32	4.57	4.70	3.56	3.66	3.67	3.78	3.58	3.69
MAPE	13.49	14.04	13.88	14.45	19.65	20.45	15.32	15.95	15.79	16.45	15.43	16.06
R2	88.70	88.70	90.75	90.75	89.17	89.17	93.31	93.31	96.68	96.68	94.18	94.18

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı herhangi bir regresyon yoktur. Bu sonuç bahsi geçen modellerin doğru çalıştığını göstermekle birlikte gerçeğe çok yakın tahmin modelleri olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Mersin için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modelleri PCR, RIDGE, ELASTIC NET'dir. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan CATBOOST, KNN regresyonlardır. Mersin ilimiz için CATBOOST regresyonu en yüksek tahmin değerini vermiştir ve %96.685 değerinde tahmin analizi yapmıştır.

Şekil 4.2 de Mersin çoklu doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Mersin ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.2. Mersin çoklu doğrusal regresyon grafiği

4.2. Marmara Bölgesi Tahmin Sonuçları

4.2.1. Çanakkale İli Tahmin Sonuçları

Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Çanakkale ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.


Çizelge 4.3. Çanakkale iline ait makine öğrenmesi modellerinin karşılaştırması

DOĞRUSAL REGRASYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Trai n	Test	Train	Test	Train	Test	Trai n	Test	Trai n	Test	Trai n	Test
NRMSE	8.04	9.18	9.72	11.10	8.54	9.75	9.96	11.38	9.50	10.85	9.09	10.38
RMSE	8.01	8.27	9.69	10	8.51	8.79	9.93	10.25	9.47	9.78	9.06	9.35
MAE	4.85	4.99	4.95	5.10	3.55	3.65	4.7	4.84	4.12	4.24	4.74	4.88
MAPE	20.88	21.74	21.32	22.19	15.28	15.91	20.23	21.06	17.72	18.45	20.40	21.23
R2	91.80	91.80	88.68	88.68	89.85	89.85	89.70	89.70	95.35	95.35	96.30	96.30
DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LİGHTGBM		CATBOOST		KNN	
	Trai n	Test	Train	Test	Train	Test	Trai n	Test	Trai n	Test	Trai n	Test
NRMSE	9.54	10.89	9.22	10.53	9.62	10.99	9.84	11.24	8.03	9.18	8.62	9.85
RMSE	9.51	9.81	9.19	9.48	9.59	9.90	9.81	10.13	8.01	8.27	8.60	8.87
MAE	3.74	3.85	4.17	4.29	4.73	4.87	3.38	3.47	3.49	3.6	4.19	4.31
MAPE	16.10	16.76	17.93	18.66	20.35	21.19	14.53	15.13	15.04	15.66	18.04	18.78
R2	94.96	94.96	95.59	95.59	89.37	89.37	93.92	93.92	95.25	95.25	92.05	92.05

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı regresyonlar görülmektedir. Bu regresyonlar MLR, PCR, RİDGE, ELASTİC NET ve XGBOOST regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin

yanlış olduğunu göstermemekle birlikte gerçeğe en az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Çanakkale için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modelleri LASSO'dur. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan CART ve CATBOOST regresyonlardır. Çanakkale ilimiz için ELASTİC NET regresyonu en yüksek tahmin değerini vermiştir ve %96.3047 değerinde tahmin analizi yapmıştır fakat bu regresyonda MAPE değerimizin %20'nin üzerinde olması nedeniyle %95.5992 tahmin değeriyle CART regresyonu tercih edilebilir bir tahmin modeli olduğu gözlemlenmiştir.

Şekil 4.3 de Çanakkale çoklu doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Çanakkale ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.3. Çanakkale çoklu doğrusal regresyon grafiği

4.2.2. Balıkesir İli Tahmin Sonuçları

Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Balıkesir ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.


Çizelge 4.4. Balıkesir iline ait makine öğrenmesi modellerinin karşılaştırması

DOĞRUSAL REGRASYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.32	10.64	8.12	9.27	8.29	9.47	9.69	11.07	8.37	9.55	8.39	9.58
RMSE	9.29	9.59	8.09	8.35	8.27	8.53	9.66	9.97	8.34	8.61	8.37	8.63
MAE	3.16	3.25	4.7	4.83	4.55	4.68	4.41	4.54	4.07	4.19	3.28	3.37
MAPE	13.6	14.16	20.21	21.03	19.57	20.37	18.98	19.75	17.51	18.23	14.12	14.69
R2	96.1	96.1	96.76	96.76	90.19	90.19	92.25	92.25	92.97	92.97	88.52	88.52
DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LİGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.03	10.31	9.72	11.1	9.16	10.46	9.58	10.94	9.39	10.73	8.56	9.78
RMSE	9	9.29	9.69	10	9.13	9.42	9.55	9.86	9.37	9.67	8.53	8.81
MAE	3.49	3.59	3.3	3.39	4.17	4.29	4.29	4.41	4.78	4.92	4.22	4.34
MAPE	15.04	15.65	14.2	14.78	17.93	18.66	18.46	19.22	20.56	21.4	18.15	18.9
R2	91.59	91.59	95.05	95.05	94.61	94.61	93.78	93.78	88.05	88.0	90.01	90.01

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı regresyonlar görülmektedir. Bu regresyonlar PCR, PLSR ve CATBOOST regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe daha az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Balıkesir için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modelleri MLR ve PCR'dir. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan CART ve XGBOOST regresyonlarıdır. Balıkesir ilimiz için PCR regresyonu en

yüksek tahmin değerini vermiştir ve %96.7653 değerinde tahmin analizi yapmıştır fakat bu regresyonda MAPE değerimizin %20'nin üzerinde olması nedeniyle %96.1022 tahmin değeriyle MLR regresyonu tercih edilebilir bir tahmin modeli olduğu gözlemlenmiştir.

Şekil 4.4. de Balıkesir çoklu doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Balıkesir ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.4. Balıkesir çoklu doğrusal regresyon grafiği

4.3. İç Anadolu Bölgesi Tahmin Sonuçları

4.3.1. Sivas İli Tahmin Sonuçları

Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Sivas ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.


Çizelge 4.5. Sivas iline ait makine öğrenmesi modellerinin karşılaştırması

DOĞRUSAL REGRASYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.79	11.18	8.41	9.6	8.35	9.54	9.06	10.35	9.84	11.24	8.98	10.25
RMSE	9.76	10.07	8.38	8.65	8.33	8.59	9.03	9.32	9.81	10.12	8.95	9.24
MAE	4.12	4.24	4.82	4.96	4.74	4.87	4.91	5.05	4.86	5.01	3.03	3.11
MAPE	17.74	18.46	20.76	21.61	20.38	21.21	21.12	21.99	20.93	21.79	13.03	13.56
R2	95.98	95.98	95.73	95.7	96.10	96.10	89.33	89.33	93.11	93.11	96.1	96.1
DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LİGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.44	10.78	9.35	10.67	9.06	10.35	8.52	9.73	9.76	11.15	8.98	10.26
RMSE	9.41	9.71	9.32	9.62	9.03	9.32	8.49	8.76	9.74	10.05	8.95	9.24
MAE	3.03	3.12	4.34	4.47	4.63	4.76	4.46	4.59	3.51	3.61	3.11	3.2
MAPE	13.04	13.57	18.69	19.45	19.91	20.73	19.2	19.98	15.11	15.73	13.37	13.92
R2	90.04	90.04	93.87	93.87	93.06	93.06	90.13	90.13	90.84	90.84	91.54	91.54

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı regresyonlar görülmektedir. Bu regresyonlar PCR, PLSR, RİDGE, LASSO ve XGBOOST regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe daha az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Sivas ili için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modeli ELASTİC NET'dir. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan CART regresyonudur. Sivas ilimiz için ELASTİC NET regresyonu en yüksek tahmin değerini vermiştir ve %96.1016 değerinde tahmin analizi yapmıştır.

Şekil 4.5. de Sivas çoklu doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Sivas ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı

görülmektedir.



Şekil 4.5. Sivas doğrusal regresyon grafiği

4.3.2. Çankırı İli Tahmin Sonuçları


Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Çankırı ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.6. Çankırı iline ait makine öğrenmesi modellerinin karşılaştırması

DOĞRUSAL REGRASYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİCNET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.23	10.54	8.92	10.19	8.3	9.48	9.14	10.44	9.14	10.44	9.76	11.14
RMSE	9.20	9.49	8.89	9.18	8.28	8.54	9.12	9.41	9.11	9.4	9.73	10.04
MAE	4.27	4.39	4.25	4.38	4.12	4.24	3.32	3.42	3.78	3.89	3.34	3.44
MAPE	18.36	19.11	18.3	19.05	17.72	18.44	14.31	14.89	16.26	16.93	14.38	14.97
R2	95.92	95.92	95.49	95.49	91.6	91.6	92.8	92.8	90.8	90.86	90.82	90.82
DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LİGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.39	10.73	8.54	9.75	8.43	9.63	9.04	10.33	8.65	9.88	9.71	11.09
RMSE	9.37	9.66	8.51	8.79	8.41	8.68	9.02	9.31	8.63	8.90	9.68	9.99
MAE	4.69	4.83	3.48	3.59	3.75	3.86	4.47	4.6	4.13	4.25	4.57	4.7
MAPE	20.18	21.01	15.00	15.62	16.13	16.79	19.22	20.01	17.79	18.52	19.65	20.45
R2	95.35	95.35	92.71	92.71	92.72	92.72	88.28	88.28	88.78	88.79	92.82	92.82

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı regresyonlar görülmektedir. Bu regresyonlar GBM, LIGHTGBM regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe daha az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Çankırı için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modelleri MLR ve PCR'dir. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan CART ve XGBOOST regresyonlardır. Çankırı ilimiz için MLR regresyonu en yüksek tahmin değerini vermiştir ve %95.9258 değerinde tahmin analizi yapmıştır. Yanı sıra PCR regresyonunda MLR tahminine çok yakın bir değerle %95.4916 ile ikinci tahmin analizini yapmıştır.

Şekil 4.6. da Çankırı çoklu doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Çankırı ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.6. Çankırı doğrusal regresyon grafiği

4.3.3. Kırıkkale İli Tahmin Sonuçları

Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Kırıkkale ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.7. Kırıkkale iline ait makine öğrenmesi modellerinin karşılaştırması


DOĞRUSAL REGRASYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.47	10.82	8.68	9.91	9.67	11.05	9.79	11.18	8.93	10.19	8.83	10.09
RMSE	9.44	9.75	8.66	8.93	9.64	9.95	9.76	10.07	8.9	9.18	8.81	9.09
MAE	3.65	3.76	3.79	3.91	4.44	4.57	3.21	3.3	3.53	3.63	3.5	3.6
MAPE	15.71	16.36	16.33	17	19.11	19.90	13.82	14.39	15.19	15.81	15.07	15.69
R2	94.29	94.29	89.30	89.30	90.01	90.01	93.83	93.84	92.88	92.88	90.02	90.02
DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LIGHT GBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE(%)	9.28	10.60	9.2	10.5	9.58	10.94	8.4	9.59	8.36	9.55	9.86	11.27

Çizelge 4.7.'nin devamı

RMSE	9.25	9.55	9.17	9.46	9.55	9.86	8.37	8.64	8.34	8.61	9.83	10.15
MAE	4.71	4.84	4.69	4.83	3.08	3.17	3.01	3.10	4.65	4.79	3.07	3.16
MAPE	20.25	21.08	20.2	21.03	13.27	13.81	12.97	13.5	20.02	20.84	13.21	13.75
R2	92.74	92.74	91.14	91.14	96.83	96.83	94.53	94.53	92.23	92.23	95.99	95.99

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı regresyonlar görülmektedir. Bu regresyonlar GBM, CART, CATBOOST regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe daha az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Kırıkkale için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modeli MLR'dir. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan XGBOOST regresyonudur. Kırıkkale ilimiz için XGBOOST regresyonu en yüksek tahmin değerini vermiştir ve %96.8369 değerinde tahmin analizi yapmıştır.

Şekil 4.7. de Kırıkkale çoklu doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Kırıkkale ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.7. Kırıkkale doğrusal regresyon grafiği

4.3.4. Kırşehir İli Tahmin Sonuçları


Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Kırşehir ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.8. Kırşehir iline ait makine öğrenmesi modellerinin karşılaştırması

DOĞRUSAL REGRASYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.7	11.07	8.84	10.1	8.51	9.72	9.54	10.89	9.01	10.29	8.92	10.19
RMSE	9.67	9.98	8.81	9.1	8.48	8.75	9.51	9.81	8.98	9.27	8.89	9.18
MAE	4.16	4.29	3.91	4.02	4.99	5.13	4.91	5.05	3.04	3.13	4.01	4.13
MAPE	17.92	18.66	16.81	17.5	21.47	22.35	21.13	22	13.08	13.61	17.26	17.97
R2	90.96	90.96	95.5	95.5	88.06	88.06	94.36	94.36	95.5	95.5	94.38	94.38
DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LIGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8.89	10.16	9.91	11.32	8.09	9.23	8.84	10.09	9.32	10.65	8.31	9.49
RMSE	8.87	9.15	9.88	10.2	8.06	8.32	8.81	9.09	9.29	9.59	8.29	8.55
MAE	3.71	3.82	4.27	4.39	4.71	4.85	3.2	3.3	4.24	4.37	3.26	3.35
MAPE	15.98	16.63	18.37	19.12	20.27	21.1	13.79	14.36	18.26	19.01	14.03	14.61
R2	91.09	91.09	94.99	94.99	91.1	91.1	93.44	93.44	96.92	96.92	94.71	94.71

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı regresyonlar görülmektedir. Bu regresyonlar PLSR, RIDGE, XGBOOST regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe daha az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Kırşehir için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modelleri PCR ve LASSO dur. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan CATBOOST regresyonudur. Kırşehir ilimiz için XGBOOST regresyonu en yüksek tahmin değerini vermiştir ve %96.8369 değerinde tahmin analizi yapmıştır.

Şekil 4.8. de Kırşehir doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Kırşehir ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.8. Kırşehir doğrusal regresyon grafiği

4.4. Karadeniz Bölgesi Tahmin Sonuçları

4.4.1. Tokat İli Tahmin Sonuçları


Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Tokat ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.9. Tokat iline ait makine öğrenmesi modellerinin karşılaştırması

	DOĞRUSAL REGRASYON ALGORİTMALARI											
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİCNET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8.76	10.01	8.99	10.27	8.11	9.26	9.04	10.32	9.73	11.12	8.48	9.69
RMSE	8.74	9.02	8.97	9.25	8.08	8.34	9.01	9.3	9.71	10.02	8.46	8.73
MAE	4.13	4.25	3.44	3.54	4.54	4.67	3.53	3.63	4.61	4.75	3.24	3.33
MAPE	17.79	18.52	14.79	15.4	19.55	20.35	15.21	15.83	19.85	20.66	13.94	14.52
R2	95.16	95.16	95.2	95.2	96.42	96.42	95.01	95.01	95.92	95.92	90.61	90.61
	DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI											
	GBM		CART		XGBOOST		LİGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.6	10.97	8.91	9.17	9.23	10.54	9.21	10.52	8.32	9.51	9.86	11.26
RMSE	9.58	9.88	8.88	9.17	9.2	9.5	9.18	9.48	8.3	8.56	9.83	10.15
MAE	4.14	4.26	4.28	4.41	4.86	5.01	4.18	4.3	4.47	4.6	3.18	3.27
MAPE	17.81	18.54	18.44	19.2	20.93	21.79	17.98	18.72	19.25	20.04	13.67	14.23
R2	90.7	90.7	93.84	93.84	89.5	89.5	93.81	93.81	92.39	92.39	88.28	88.28

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı regresyonlar görülmektedir. Bu regresyonlar PLSR, LASSO, XGBOOST, CASTBOOST regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe daha az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Tokat için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R² tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modeli RİDGE'dir. Doğrusal olmayan regresyonlarda ise yüksek R² tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan CART regresyonudur. Tokat ilimiz için RİDGE regresyonu en yüksek tahmin değerini vermiştir ve %95.0137 değerinde tahmin analizi yapmıştır.

Şekil 4.9. da Tokat doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Tokat ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.9. Tokat doğrusal regresyon grafiği

4.4.2. Sinop İli Tahmin Sonuçları


Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Sinop ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.10. Sinop iline ait makine öğrenmesi modellerinin karşılaştırması

DOĞRUSAL REGRASYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	10.02	11.44	9.57	10.92	8.53	9.74	9.2	10.51	8.28	9.46	9.55	10.91
RMSE	9.99	10.31	9.54	9.84	8.5	8.78	9.17	9.46	8.26	8.52	9.52	9.83
MAE	4.83	10.31	4.36	4.49	4.03	4.15	4.56	4.69	3.39	3.49	3.12	3.21
MAPE	20.8	21.65	18.78	19.55	17.36	18.07	19.62	20.42	14.59	15.18	13.42	13.97
R2	89.14	89.14	94.03	94.03	91.53	91.53	94.37	94.37	88.5	88.5	92.22	92.22
DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LIGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8.42	9.62	8.58	9.8	8.54	9.75	9.94	11.35	8.45	9.66	8.63	9.86
RMSE	8.4	8.67	8.55	8.83	8.51	8.78	9.91	10.23	8.43	8.7	8.61	8.88
MAE	4.57	4.71	4.49	4.62	4.87	5.02	3.43	3.52	4.7	4.83	3.82	3.93
MAPE	19.68	20.49	19.31	20.1	20.98	21.84	14.74	15.35	20.21	21.03	16.46	17.13
R2	95.29	95.29	95.74	95.74	91.37	91.37	93.4	93.4	91.67	91.67	95.8	95.8

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı regresyonlar görülmektedir. Bu regresyonlar MLR, GBM, CART, XGBOOST, CASTBOOST regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe daha az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Sinop için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modeli RIDGE dir. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan KNN regresyonudur. Sinop ilimiz için KNN regresyonu en yüksek tahmin değerini vermiştir ve %95.8037 değerinde tahmin analizi yapmıştır.

Şekil 4.10. Sinop doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Sinop ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.10. Sinop doğrusal regresyon grafiği

4.5. Ege Bölgesi Tahmin Sonuçları

4.5.1. Manisa İli Tahmin Sonuçları

Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Manisa ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.11. Manisa iline ait makine öğrenmesi modellerinin karşılaştırması


DOĞRUSAL REGRASYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8.54	9.75	9.92	11.33	8.58	9.79	9.37	10.7	8.55	9.77	9.04	10.33
RMSE	8.52	8.79	9.89	10.2	8.55	8.82	9.34	9.64	8.53	8.8	9.02	9.31
MAE	3.25	3.35	3.17	3.26	3.96	4.08	3.61	3.71	3.36	3.46	4.92	5.06
MAPE	13.99	14.57	13.64	14.2	17.05	17.75	15.53	16.17	14.47	15.07	21.18	22.05
R2	91.06	91.06	96.87	96.87	93.35	93.35	89.41	89.41	91.42	91.42	90.52	90.52
DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LİGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.92	11.33	10.01	11.43	8.02	9.16	8.18	9.34	9.36	10.69	8.86	10.11
RMSE	9.89	10.21	9.98	10.3	8	8.25	8.15	8.42	9.33	9.63	8.83	9.11
MAE	3.83	3.94	4.88	5.02	4.83	4.97	3.02	3.11	3.91	4.02	4.90	5.04

Çizelge 4.11'in devamı

MAPE	16.47	17.14	20.98	21.84	20.78	21.64	13.01	13.54	16.82	17.51	21.08	21.94
R2	95.99	95.99	90.39	90.39	96.95	96.95	88.64	88.64	96.75	96.75	90.08	90.08

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı regresyonlar görülmektedir. Bu regresyonlar ELASTİC NET, CART, XGBOOST, KNN regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe daha az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Manisa için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modeli PCR'dir. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan CATBOOST regresyonudur. Manisa ilimiz için PCR regresyonu en yüksek tahmin değerini vermiştir ve %96.8706 değerinde tahmin analizi yapmıştır.

Şekil 4.11. de Manisa doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Manisa ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.11. Manisa doğrusal regresyon grafiği

4.5.2. İzmir İli Tahmin Sonuçları


Çalışmamızda elde edilen verilerin işlenmesi sonucunda, İzmir ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.12. İzmir iline ait makine öğrenmesi modellerinin karşılaştırması

DOĞRUSAL REGRASYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8.95	10.22	9.46	10.81	9.07	10.36	8.42	9.62	8.78	10.03	8.07	9.21
RMSE	8.92	9.21	9.44	9.74	9.04	9.33	8.4	8.66	8.76	9.04	8.04	8.3
MAE	4.48	4.61	3.98	4.09	3.99	4.1	3.55	3.65	3.17	3.26	4.57	4.7
MAPE	19.27	20.06	17.12	17.82	17.16	17.87	15.27	15.9	13.66	14.22	19.65	20.45
R2	91.76	91.76	88.24	88.24	91.11	91.11	92.5	92.5	93.44	93.44	88.63	88.63
DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LİGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.97	11.39	9.7	11.08	9.02	10.3	8.59	9.82	8.49	9.69	8.77	10.02
RMSE	9.94	10.26	9.67	9.98	8.99	9.28	8.57	8.84	8.46	8.73	8.74	9.02
MAE	4.88	5.02	3.9	4.02	3.8	3.91	4.54	4.67	3.14	3.23	3.74	3.84
MAPE	21.01	21.87	16.8	17.49	16.36	17.04	19.54	20.34	13.52	14.08	16.08	16.74
R2	88.66	88.66	91.16	91.16	89.17	89.17	89.55	89.55	95.07	95.07	93.5	93.5

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı regresyonlar görülmektedir. Bu regresyonlar MLR, ELASTİC NET, GBM, LIGHTGBM regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe daha az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında İzmir için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modeli LASSO dur. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan CATBOOST regresyonudur. Manisa ilimiz için PCR regresyonu en yüksek tahmin değerini vermiştir ve %95.0779değerinde tahmin analizi yapmıştır.

Şekil 4.12. de İzmir doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Sinop ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.12. İzmir doğrusal regresyon grafiği

4.6. Doğu Anadolu Bölgesi Tahmin Sonuçları

4.6.1. Malatya İli Tahmin Sonuçları


Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Malatya ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.13. Malatya iline ait makine öğrenmesi modellerinin karşılaştırması

DOĞRUSAL REGRESYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8.67	9.9	8.51	9.72	9.75	11.13	8.95	10.23	8.57	9.78	9.46	10.8
RMSE	8.65	8.92	8.49	8.76	9.72	10.03	8.93	9.21	8.54	8.81	9.43	9.73
MAE	3.82	3.93	4.66	4.79	3.07	3.15	3.87	3.98	3.44	3.54	4.57	4.7
MAPE	16.46	17.13	20.05	20.87	13.2	13.74	16.65	17.34	14.8	15.41	19.66	20.47
R2	91.61	91.61	89.67	89.67	93.57	93.57	96.23	96.23	93.76	93.76	94.41	94.41
DOĞRUSAL OLMAYAN REGRESYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LIGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8,56	9,78	9.25	10.56	9.44	10.79	8.89	10.15	9.83	11.23	9.91	11.31
RMSE	8,53	8,81	9.22	9.51	9.42	9.72	8.86	9.15	9.8	10.12	9.88	10.19
MAE	4,39	4,51	4.1	4.22	3.18	3.27	4.02	4.14	4.89	5.04	4.2	4.32
MAPE	18,87	19,65	17.64	18.36	13.69	14.25	17.31	18.02	21.06	21.92	18.07	18.81
R2	95,65	95,65	96.88	96.88	92.42	92.42	91.22	91.22	93.95	93.95	95.15	95.15

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı tek regresyonlar PCR ve CATBOOST regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe en az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Malatya için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modelleri PLSR, RIDGE'dir. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan GBM, CART, XGBOOST regresyonları daha tercih edilebilir regresyonlardır.

Şekil 4.13'de Malatya doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Malatya ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.13. Malatya çoklu doğrusal regresyon grafiği

4.6.2. Bingöl İli Tahmin Sonuçları

Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Bingöl ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.


Çizelge 4.14. Bingöl iline ait makine öğrenmesi modellerinin karşılaştırması

	DOĞRUSAL REGRESYON ALGORİTMALARI											
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİCNET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.32	10.65	9.05	10.33	8.95	10.22	8.91	10.17	8.28	9.46	8.49	9.70
RMSE	9.3	9.59	9.02	9.33	8.92	9.21	8.88	9.17	8.26	8.52	8.47	8.74
MAE	3.86	3.98	4.41	4.54	3.94	4.06	3.25	3.35	3.91	4.02	4.99	5.14
MAPE	16.63	17.31	18.97	19.74	16.98	17.67	14	14.57	16.81	17.50	21.48	22.36
R2	93.67	93.67	93.85	93.85	95.26	95.26	91.19	91.19	92.89	92.89	88.36	88.36
	DOĞRUSAL OLMAYAN REGRESYON ALGORİTMALARI											
	GBM		CART		XGBOOST		LİGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9,12	10,42	9,28	10,6	8,55	9,77	9,78	11,17	9,58	10,94	9,17	10,47
RMSE	9,09	9,38	9,25	9,55	8,52	8,8	9,75	10,07	9,55	9,86	9,14	9,43
MAE	3,24	3,34	4,62	4,75	4,95	5,09	3,61	3,71	3,04	3,13	4,22	4,34
MAPE	13,96	14,54	19,88	20,69	21,3	22,17	15,53	16,17	13,08	13,61	18,17	18,92
R2	88,86	88,86	94,88	94,88	94,86	94,86	91,31	91,31	95,27	95,27	89,93	89,93

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu Tablo 4’de ki sonuçlar göstermektedir.

MAPE değerinin %20’nin üstüne çıktığı tek regresyon ElasticNet regresyonudur. Bu regresyonda ise mevcut değeri 21.4802, tahmini değeri ise 22.3609 olduğu görülmektedir. Bu sonuç ElasticNet modelinin yanlış olduğunu göstermemekle birlikte gerçeğe en az yakın tahmin modelinin olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Bingöl için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda en yüksek R2 tahmin değerini vererek NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal 3 regresyon modeli PLSR, RIDGE, LASSO’dur. Doğrusal olmayan regresyonlarda ise en yüksek R2 tahmin değerini vererek NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan CATBOOST regresyonudur.

Şekil 4.14’de Bingöl doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Bingöl ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.14. Bingöl çoklu doğrusal regresyon grafiği

4.6.3. Van İli Tahmin Sonuçları


Çalışmamızda elde edilen verilerin işlenmesi sonucunda, Van ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.15. Van iline ait makine öğrenmesi modellerinin karşılaştırması

DOĞRUSAL REGRESYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8.5	9.71	9.7	11.07	8.05	9.19	8.57	9.78	9.96	11.38	8.8	10.05
RMSE	8.48	8.75	9.67	9.98	8.03	8.28	8.54	8.81	9.93	10.25	8.77	9.05
MAE	3.5	3.6	4.14	4.26	3.91	4.03	3.12	3.21	4.16	4.28	4.72	4.86
MAPE	15.06	15.67	17.82	18.55	16.84	17.53	13.45	14	17.91	18.64	20.31	21.14
R2	94.72	94.72	93.77	93.77	94.66	94.66	89.61	89.61	91.06	91.06	94.8	94.8
DOĞRUSAL OLMAYAN REGRESYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LİGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8,98	10,26	8,84	10,09	8,65	9,87	9,12	10,42	9,42	10,76	9,87	11,28
RMSE	8,96	9,24	8,81	9,09	8,62	8,9	9,1	9,39	9,40	9,7	9,85	10,16
MAE	3,91	4,02	4,19	4,31	4,48	4,61	4,41	4,54	3,29	3,38	4,76	4,9
MAPE	16,82	17,51	18,02	18,76	19,29	20,08	18,97	19,75	14,15	14,73	20,5	21,34
R2	91,69	91,69	96,96	96,96	95,51	90,55	94,07	94,07	91,39	91,39	89,61	89,61

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı tek regresyonlar ElasticNet, XGBOOST, KNN regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe en az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Van için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modeli PLSR'dir. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan CART regresyonudur.

Şekil 4.15'de Van doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Van ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.15. Van çoklu doğrusal regresyon grafiği

4.7. Güney Doğu Anadolu Bölgesi Tahmin Sonuçları

4.7.1. Gaziantep İli Tahmin Sonuçları


Çalışmamızda elde edilen verilerin işlenmesi sonucunda, İzmir ili verilerinin doğrusal regrasyon algoritmaları ve doğrusal olmayan regrasyon algoritmaları olmak üzere makine öğrenimine göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.16. Gaziantep iline ait makine öğrenmesi modellerinin karşılaştırması

DOĞRUSAL REGRASYON ALGORİTMALARI												
	MLR		PCR		PLSR		RİDGE		LASSO		ELASTİC NET	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	9.55	10.91	9.75	11.14	8.66	9.89	8.9	10.7	9.65	11.02	9.22	10.53
RMSE	9.52	9.83	9.72	10.03	8.64	8.91	8.87	9.16	9.62	9.93	9.2	9.49
MAE	4.69	4.83	3.77	3.88	3.8	3.92	3.82	3.93	3.76	3.87	3.92	4.04
MAPE	20.2	21.02	16.22	16.89	16.38	17.05	16.45	17.13	16.20	16.86	16.88	17.57
R2	95.77	95.77	96.63	96.63	95.80	95.80	96.66	96.66	88.55	88.55	95.54	95.54
DOĞRUSAL OLMAYAN REGRASYON ALGORİTMALARI												
	GBM		CART		XGBOOST		LIGHTGBM		CATBOOST		KNN	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	8.43	9.63	8.62	9.85	9.32	10.64	8.93	10.2	8.49	9.7	8.51	9.72
RMSE	8.41	8.68	8.6	8.87	9.29	9.58	8.91	9.19	8.47	8.74	8.48	8.75
MAE	4.45	4.58	4.04	4.16	4.79	4.93	4.39	4.51	4.27	4.39	3.91	4.02
MAPE	19.17	19.95	17.41	18.11	20.62	21.46	18.88	19.65	18.37	19.13	16.81	17.50
R2	96.96	96.969	92.75	92.75	94.65	94.65	92.82	92.82	89.87	89.87	88.73	88.73

Regresyonlarda NRMSE, RMSE, MAE, MAPE değerlerinin mevcut ve tahmini sonucu arasındaki farkın %1-2 arasında değişim gösterdiği saptanmıştır. Bu fark rüzgâr enerji üretiminin mevcut ve tahmini değerlerin yaklaşık olarak aynı değerlerde olduğunu göstermektedir. MAPE değerinin %20'nin üstüne çıktığı tek regresyonlar MLR ve XGBOOST regresyonlarıdır. Bu regresyonlarda da mevcut tahmini değerleri %20 değerine yakın sınır değerler olduğu görülmektedir. Bu sonuç bahsi geçen modellerin yanlış olduğunu göstermemekle birlikte gerçeğe en az yakın tahmin modeller olduğunu göstermektedir. Doğrusal regresyon algoritmalarında Gaziantep için tüm algoritmalar kullanılabilir bir eğilim göstermektedir. Doğrusal regresyonlarda yüksek R2 tahmin değerlerinden olup NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı en iyi tahmini yapan doğrusal regresyon modelleri PLSR, RIDGE'dir. Doğrusal olmayan regresyonlarda ise yüksek R2 tahmin değeri, NRMSE, RMSE, MAE, MAPE hata değerlerinin düşük olmasından dolayı iyi tahmini yapan GBM ve CART regresyonları daha tercih edilebilir regresyonlardır.

Şekil 4.16 ' da Gaziantep doğrusal regresyon grafiği gösterilmiştir ve görüldüğü gibi Gaziantep ili çoklu doğrusal regresyon grafiği incelendiğinde ise mevcut ve tahmini değerlerinin birbiri ile uyum içinde olduğu görülmektedir. Bu grafikte de gördüğümüz gibi tahmini değerlerin genel olarak gerçeğe %90 civarında yaklaştığı görülmektedir.



Şekil 4.16. Gaziantep çoklu doğrusal regresyon grafiği

5. SONUÇ

Bu araştırmada, rüzgâr enerjisinden elektrik üretiminde iklim koşullarının üretim sürecine olan etkisine odaklanılmıştır. Rüzgâr enerjisiyle üretilen elektrik miktarı birçok parametreye bağlı olarak değişkenlik göstermektedir. İl bazında, son 10 yıla ait meteorolojik veriler, Meteoroloji Genel Müdürlüğü'nden ve birçok zamanda yapılan saha çalışmaları ölçümleri ile elde edilmiştir. Üretilen elektrik miktarları ise üretime başlama tarihinden itibaren EPİAŞ tarafından sağlanmıştır. Ülkemizde bulunan 7 coğrafi bölgede ayrı ayrı çalışma yapılmış olup bu bölgelerde bulunan kurulu Rüzgâr Enerji Santralleri (RES) ile ilişkilendirilmiş illerdeki iklimsel verilere dayanarak, elektrik üretim miktarının tahmini için 12 farklı makine öğrenmesi algoritması test edilmiştir. Bu algoritmalar arasında 6 doğrusal ve 6 doğrusal olmayan algoritma bulunmaktadır.

Deney çalışmasında, Akdeniz Bölgesi çalışması için Osmaniye ve Mersin illeri, Marmara Bölgesi çalışması için Çanakkale ve Balıkesir illeri, İç Anadolu Bölgesi çalışması için Sivas, Çankırı, Kırıkkale, Kırşehir illeri, Karadeniz Bölgesi için Tokat ve Sinop, Ege Bölgesi için Manisa ve İzmir illeri Doğu Anadolu Bölgesi için Malatya, Bingöl ve Van illeri Güneydoğu Anadolu Bölgesi için Gaziantep ilimiz için çalışma gerçekleştirilmiş olup 12 farklı algoritma üzerinden test edilmiştir. Bu çalışmadaki tüm algoritmalar, eğitim seti ve test seti üzerinde değerlendirilmiştir ve bu değerlendirmeler tablolarda ve çizelgelerde karşılaştırmalı bir şekilde sunulmuştur. Bu yöntem, makine öğrenmesinin en temel sorunlarından biri olan aşırı öğrenme durumunun var olup olmadığını gözlemlemeye yönelik bir çaba içermektedir.

Bir algoritmanın eğitim setinde yani mevcutta ve test setinde yani tahminde paralel yüksek performans göstermesi oluşturulan modelin genelleme yeteneğinin yüksek olduğunu ve yeni veriler için başarılı sonuçlar vereceğini gösterir. Tüm algoritmaların eğitim ve test setleri için benzer bir performans sergilediği gözlemlenmiştir. MAPE değerinin %20'nin altında olması, modelin uydurma ve tahminle ilgili yüksek bir doğruluk oranına sahip olduğunu gösterir. Bu bağlamda, analiz edilen tüm yöntemlerin doğru sonuçlar elde etme yeteneği olduğu ve her

birinin gerek dnya kořullarında uygulanabilir olduėu gzlemlenmektedir.

MAPE deėerinin %20'nin stne ıktıėı modellerde ise deėerlerin ok sınır deėerler olmasından dolayı tm performans ltleri aısından diėerlerine srekli olarak stn olan tek bir model bulunmamakla birlikte, Osmaniye ili iin MLR regresyonu, Mersin ili iin CATBOOST regresyonu, anakkale ili iin CART regresyonu, Balıkesir ili iin MLR regresyonu, Sivas ili iin ELASTIC NET regresyonu, ankırı ili iin MLR regresyonu, Kırıkkale ve Kırřehir illeri iin XGBOOST regresyonu, Tokat ili iin RIDGE regresyonu, Sinop ili iin KNN regresyonu, Manisa ve İzmir illeri iin PCR regresyonu, Malatya ve Van illeri iin CART regresyonu, Bingl ili iin CATBOOST regresyonu, Gaziantep ili iin GBM regresyonu diėer regresyonlara gre daha iyi tahmin sonularında bulunmuřtur. En yksek tahmin %96.969 deėerinde Gaziantep ilinde GBM regresyonu ile gerekleřmiřtir.

Rzgrın srekli olmayan bir kaynak olması, enerji depolama sorunları, grsel ve evresel etkiler gibi konular, rzgr enerjisi santrallerinin uygulanabilirliėini etkileyen faktrler arasında yer alır. Ancak teknolojik geliřmeler ve srekli iyileřtirmelerle, rzgr enerjisi santrallerinin rol giderek artmaktadır. Bu alıřma kapsamında elde edilen bulgular doėrultusunda, gelecekte rzgr enerji santrallerinin elektrik retimindeki verimliliėi artırmak amacıyla modellerin dzenli olarak geniřletilip gncellenmesine olanak tanındıėı takdirde, gelecekteki retim deėerlerini tahmin ederek rzgr enerji santrallerinin bakımını zamanında ve dřk maliyetle gerekleřtirmek iin bir fırsat ortaya ıkabilir. İlerleyen yıllarda, tahmin edebilme altyapısı aylık periyodlara kadar indirgenerek, gemiř yıllarda aynı aylarda karřılařılan sorunların hızlı bir řekilde tespit edilmesinde kullanılabilir. Ayrıca, bu alıřma rzgr enerji santrallerinden elde edilen elektrik verilerini temel alarak aylık retimi, elektrik daėıtım řirketlerinin hedeflediėi aylık retimle karřılařtırarak ortaya ıkabilecek hataları minimize etmeyi amalayan bir sistem sunabilir. Rzgr enerji santrallerinin geriye dnk 10 yıllık verilerinin, optimum alıřma iin yeterli olduėu dřnldėnde, bu tr alıřmaların Yenilenebilir enerji santralleri iin nemli bir rol oynadıėı aıka grlmektedir.

KAYNAKLAR

- [1] Şenel, M. C., & Koç, E. (2015). Dünyada Ve Türkiye’de Rüzgâr Enerjisi Durumu- Genel Değerlendirme. Mühendis Ve Makina, 56(663), 46-56.
- [2] Hayli, S. (2001). Rüzgâr enerjisinin önemi Dünya’da ve Türkiye’deki durumu. Fırat Üniversitesi Sosyal Bilimler Dergisi, 11(1), 1-26.
- [3] Ahmet, Ö., Şaşmaz, M. Ü., & Bahtiyar, E. (2015). Türkiye’de Yeşil Ekonomi Açısından Yenilenebilir Bir Enerji Kaynağı: Rüzgâr Enerjisi. Karamanoğlu Mehmetbey Üniversitesi Sosyal Ve Ekonomik Araştırmalar Dergisi, 2015(1), 85-93.
- [4] Bayraç, H. N. (2011). Küresel rüzgâr enerjisi politikaları ve uygulamaları. Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 30(1), 37-57.
- [5] Dirik, R., Taşkesen, E., & Dirik, Ö. (2023). Yenilenebilir Enerji Kaynaklarında Yapay Zekâ Kullanımı. In International Conference on Recent Academic Studies (Vol. 1, pp. 28-35).
- [6] Mastny, Lisa (Ed.), Renewables 2014 Global Status Report, Paris: REN 21 Secretariat, 2014.
- [7] Alahmad, H., Taşkesen, E., Dumrul, H., & Arlı, F. (2024). Türkiye 2023 Yılı Rüzgâr Enerjisi Potansiyeli ve Üretim Gücü Araştırılması.
- [8] Amal, E., Yılmaz, K. & Özdemir, E. (2022). Rüzgâr Enerji Santrallerinin Elektrik Şebekesine Etkilerinin İncelenmesi. Kocaeli Üniversitesi Fen Bilimleri Dergisi, 5 (2) , 50-65.
- [9] Türkiye Elektrik Üretim-İletim İstatistikleri, TEİAŞ (Türkiye Elektrik İletim Anonim Şirketi), 2021. <https://www.teias.gov.tr/turkiye-elektrik-uretim-iletim-istatistikleri>
- [10] Looney, B. ve Dale, S. (2021). Statistical review of world energy 2021. Bp, (70), 1-72.

- [11] http-7. Elektrik, <https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik>, (Eriřim Tarihi: 22.08.2024).
- [12] EPDK (2022). Enerji Piyasaları D zenleme Kurumu- Elektrik Piyasası 2021 Yılı Piyasa Geliřim Raporu, <https://www.epdk.gov.tr/Detay/Icerik/3-0-24/elektrikyillik-sektor-raporu>, (Eriřim Tarihi: 20.06.2023).
- [13] Dudley, B. (2019). Bp energy outlook. Bp, 1-73.
- [14] İpek, E. Hakyemez C. Aylık Enerji B lteni (2021, 12 Aralık)
- [15] <https://tureb.com.tr/lib/uploads/203243c7bdacc121.pdf>
- [16] <https://tureb.com.tr/lib/uploads/011ae884354a9c5m.pdf>
- [17]  ztemel, E. (2003). Yapay sinir aęları. Papatya Yayıncılık, İstanbul.
- [18]  zt rk, K., & řahin, M. E. (2018). Yapay sinir aęları ve yapay zek 'ya genel bir bakıř. Takvim-i Vekayi, 6(2), 25-36.
- [19] Ataseven, B. (2013). Yapay sinir aęları ile  ng r  modellemesi.  neri Dergisi, 10(39), 101-115.
- [20] řimřek, E. F. (2023). Hastanelerin yapım s re lerinin  evresel s rd r lebilirlik a ısından deęerlendirilmesi ve yenilenebilir enerji uygulamalarının incelenmesi.
- [21]  zt rk,  . A. (2019). Hastanelerde enerji y netiminin modellenmesi (Master's thesis, Lisans st  Eęitim Enstit s ).
- [22] Eser, N. S. (2023). Yeřil Hastanelerin Maliyet Avantajı Bakımından Deęerlendirilmesi. Giriřimcilik ve Kalkınma Dergisi, 18(2), 54-64.
- [23] Vaziri, S. M., Rezaee, B., & Monirian, M. A. (2020). Utilizing renewable energy sources efficiently in hospitals using demand dispatch. Renewable Energy, 151, 551-562.
- [24] Burch, H., Anstey, M. H., & McGain, F. (2021). Renewable energy use in Australian public hospitals. Med J Aust, 215(4), 160-3.
- [25] S ę t, M. Z. (2023). Hastaneler i in  evresel s rd r lebilirlięin kriterleri; enerji verimlilięi ve y netmelięi.

- [26] Nourdine, B., & Saad, A. (2020, March). Energy consumption in hospitals. In 2020 International Conference on Electrical and Information Technologies (ICEIT) (pp. 1-6). IEEE.
- [27] Oliveira, G. P., Delgado, D. B. M., & Carvalho, M. (2024). Analysis and forecast of emissions associated with electricity consumption in hospitals: Encouraging a net zero healthcare roadmap in Brazil. *Energy and Buildings*, 324, 114785.
- [28] https://www.emo.org.tr/ekler/e8132461f529ea4_ek.pdf
- [29] Akkaş, A. A. (2001). Rüzgâr Enerjisi Sistemlerinin Performans Değerlendirmesi. *Rüzgâr Enerjisi Sempozyumu*, 75-84.
- [30] Erginel, E., & Timuralp, Ç. (2024). Üretilen Rüzgâr Enerjisi Tahmininde Hava Koşulu Verilerinin İstatiksel Analizi ve Modellenmesi. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 32(3), 1459-1469.
- [31] <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-ruzgar>
- [32] Akalın, H., Seçkiner, S. U. ve Eroğlu, Y. (2017). Efficiency evaluation for wind turbines using stochastic frontier analysis. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi* , 1311-1325.
- [33] İlkılıç, Z. (2016). Türkiye’de rüzgâr enerjisi ve rüzgâr enerji sistemlerinin gelişimi. *Yaşam Bilimleri Dergisi*,
- [34] Freeman, J. A., & Skapura, D. M. (1991). *Neural networks: algorithms, applications, and programming techniques*. Addison Wesley Longman Publishing Co., Inc..
- [35] M. Negnevitsky, (2005) *Artificial Intelligence: A Guide to Intelligent Systems*. Pearson Education,
- [36] Arı, A. ve Berberler, M. E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Dergipark*, 55-73.
- [37] Öztemel, P. E. (2012). *Yapay sinir ağları*. Papatya Yayıncılık Eğitim Bilgisayar Sis. San. Ve Tic. A.ş.

- [38]K. Ö. ve Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 25-36
- [39]Arı, A. ve Berberler, M. E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta Infologica*, 55-73.
- [40]Tekin, P. (2022). Çukurova bölgesi için kısa vadeli yapay zekâ tabanlı rüzgâr güç tahmini. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*.
- [41]Dirik, R., Taşkesen, E., & Dirik, Ö. (2023). YENİLENEBİLİR ENERJİ KAYNAKLARINDA YAPAY ZEKÂ KULLANIMI. In *International Conference on Recent Academic Studies* (Vol. 1, pp. 28-35).
- [42]Özcan, İ. Şahin, A. Dikmen, E. Bayram, G. (2013). Isparta ilinde rüzgâr hızı değerlerinin belirlenmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 109-112.
- [43]Durğun, S. (2018). Türkiye'nin enerji talebinin yapay zekâ teknikleriyle uzun dönem tahmini [Yayımlanmamış yüksek lisans tezi]. Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
- [44]M. D., Balpetek, N., Akpınar, E. K. ve Akpınar, S. (2019). Investigation of wind energy potential of different provinces found in turkey and establishment of predictive model using support vector machine regression with the obtained results. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 2203-2213.
- [45]Akkaya, S. (2007). Yenilenebilir enerji kaynaklarının Türkiye açısından önemi ve bir rüzgâr enerjisi uygulaması (Master's thesis, Fen Bilimleri Enstitüsü).
- [46]Öztürk, C. Osmaniye ili sınırları içerisindeki bir bölgenin rüzgâr enerjisi potansiyelinin analiz edilmesi (Master's thesis, Fen Bilimleri Enstitüsü).
- [47]Toker, A. M. (2017). Rüzgâr enerjisi yatırımlarındaki risk faktörleri ve enerji üretimi öngörüsünde rüzgâr ölçüm verisinin etkisi (Master's thesis, Enerji Enstitüsü).

- [48]Tekinay, Ç. (2022). Türkiye'nin günlük rüzgâr enerjisi üretiminin derin öğrenme ile modellenmesi.
- [49]Şenol, Ü. (2017). Rüzgâr enerjisi ve rüzgâr enerjisi potansiyelinin yapay sinir ağları yöntemiyle tahmini (Master's thesis, Fen Bilimleri Enstitüsü).
- [50]Balpetek, N. (2017). Rüzgâr enerjisi potansiyelinin araştırılmasında Weibull ve Rayleigh dağılımlarının kullanılması (Master's thesis, Fen Bilimleri Enstitüsü).
- [51]Halil, K. Türkiye'de Rüzgâr Enerjisi Santralleri İçin Teşvik Uygulamaları Ve Bilgisayar Programı İle İrdelenmesi.
- [52]Pelletier, F., Masson, C., & Tahan, A. (2016). Wind turbine power curve modelling using artificial neural network. *Renewable Energy*, 89, 207-214.
- [53]Papathanassiou, S. A., Kladas, A. G., & Tegopoulos, J. A. (2001). Applications of artificial intelligence techniques in wind power generation. *Integrated Computer-Aided Engineering*, 8(3), 231-242.
- [54]Jursa, R., & Rohrig, K. (2008). Short-term wind power forecasting using evolutionary algorithms for the automated specification of artificial intelligence models. *International Journal of Forecasting*, 24(4), 694-709.
- [55]Zhao, X., Wang, C., Su, J., & Wang, J. (2019). Research and application based on the swarm intelligence algorithm and artificial intelligence for wind farm decision system. *Renewable energy*, 134, 681-697.
- [56]Duer, S. (2020). Assessment of the operation process of wind power plant's equipment with the use of an artificial neural network. *Energies*, 13(10), 2437
- [57]Jafarian-Namin, S., Goli, A., Qolipour, M., Mostafaeipour, A., & Golmohammadi, A. M. (2019). Forecasting the wind power generation using Box–Jenkins and hybrid artificial intelligence: A case study. *International journal of energy sector management*, 13(4), 1038-1062.

- [58]D Bouabdallaoui, T Haidi, M El Jaadi Indones. J. Electr. Eng. Comput. Sci – 2023
- [59]WC Yeh, YM Yeh, PC Chang, YC Ke, V Chung International Journal of Electrical Power & Energy Systems- 2014
- [60]DT Viet, VV Phuong, MQ Duong, QT Tran Energies – 2020
- [61]Farrar, N. O., Ali, M. H., & Dasgupta, D. (2023). Artificial intelligence and machine learning in grid connected wind turbine control systems: A comprehensive review. *Energies*, 16(3), 1530.
- [62]Li, S., Wunsch, D. C., O’Hair, E., & Giesselmann, M. G. (2001). Comparative analysis of regression and artificial neural network models for wind turbine power curve estimation. *J. Sol. Energy Eng.*, 123(4), 327-332.
- [63]Yousuf, H., Zainal, A. Y., Alshurideh, M., & Salloum, S. A. (2020). Artificial intelligence models in power system analysis. In *Artificial intelligence for sustainable development: Theory, practice and future applications* (pp. 231-242). Cham: Springer International Publishing.
- [64]Porté-Agel, F., Bastankhah, M., & Shamsoddin, S. (2020). Wind-turbine and wind-farm flows: a review. *Boundary-layer meteorology*, 174(1), 1-59.
- [65]https://acikders.ankara.edu.tr/pluginfile.php/117326/mod_resource/content/1/11-Coklu%20Regresyon%201.pdf
- [66]O. T. (2016). A comparative study on regression methods in the presence of multicollinearity. *İstatistikçiler Dergisi*, 47-53.
- [67]P. Geladi, B. Kowalski, 1986, Partial Least-Squares Regression: A Tutorial, *Analytica Chimica Acta*, 185, 1–17.
- [68]J. G. ve Romeraa, D. P. A. R. (2008). A robust partial least squares regression method with applications. *Research Article*, 78-90.
- [69]I. S. Helland, 1990, Partial Least Squares Regression and Statistical Models, *Scandinavian Journal of Statistics*, 17(2), 97–114.

- [70]Yeniay, Ö. ve Göktaş, A. (2002). A comparison of partial least squares regression with other prediction methods. Hacettepe Journal Of Mathematics And Statistics, (31), 99-111.
- [71]Helland, I. S. On the structure of partial least squares regression, Communications in Statistics, Simulations and Computation 17, 581–607, 1988.
- [72]Phatak, A. and Jong, S. D. The geometry of partial least squares, Journal of Chemometrics 11, 311–338, 1997.
- [73]Garthwaite, P. H. An interpretation of partial least squares, Journal of the American Statistical Association 89, 122–127, 1994.
- [74]S. Toker, S. Kaçiranlar, 2013, On the Performance of Two Parameter Ridge Estimator under the Mean Square Error Criterion, Applied Mathematics And Computation, vol.219, 4718-4728.
- [75]Chris Hans (2011) Elastic Net Regression Modeling With the Orthant Normal Prior, Journal of the American Statistical Association, 106:496, 1383-1393, DOI: 10.1198/jasa.2011.tm09241
- [76]E. T. ve Onan, A. En yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi. Research Article.
- [77]U. O., , M. H. ve Özer, M. Eeg dışaretlerinin çok-katmanlı algılayıcı yapay sinir ağı modeli ile sınıflandırılmasında ayırıklaştırma yaklaşımı. Research Article.
- [78]Đ., Güler, E. D., Übeyli, “Adaptive neuro-fuzzy inference system for classification”, Journal of –euroscience Methods, vol. 148, pp. 113–121, 2005.
- [79]M. K. ve Boysan, M. (2008). Bilişsel yatkınlık ile depresyon düzeyleri ilişkisinin sınıflandırma ve regresyon ağacı analizi ile incelenmesi. Hacettepe Üniversitesi Eğitim Fakültesi Dergisi, 168-177.
- [80]Akar, Ö. ve Güngör, O. (2012). Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması. Article İn Journal Of Geodesy And Geoinformation, 1(2), 105 - 112. 10.9733/jgg.241212.1t

- [81]Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., ... & Liu, T. Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. *Advances in neural information processing systems*, 30.
- [82]Hancock, J. T., & Khoshgoftaar, T. M. (2020). CatBoost for big data: an interdisciplinary review. *Journal of big data*, 7(1), 1-45.
- [83]Awad, M., & Khanna, R. (2015). *Efficient learning machines: theories, concepts, and applications for engineers and system designers* (p. 268). Springer nature.
- [84]Sutton, C. D. (2005). Classification and regression trees, bagging, and boosting. *Handbook of statistics*, 24, 303-329.
- [85]Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., ... & Zhou, T. (2015). Xgboost: extreme gradient boosting. *R package version 0.4-2*, 1(4), 1-4.
- [86]Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE). *Geoscientific model development discussions*, 7(1), 1525-1534.
- [87] Li, Z., Ye, L., Zhao, Y., Song, X., Teng, J., & Jin, J. (2016). Short-term wind power prediction based on extreme learning machine with error correction. *Protection and Control of Modern Power Systems*, 1(1), 1-8.
- [88] Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *Peerj computer science*, 7, e623.