



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS PROGRAMI

**DERİN ÖĞRENME TABANLI HİBRİT TAHMİNLEME MODELİ
KULLANARAK RÜZGAR HIZI TAHMİNLEMESİ**

YÜKSEK LİSANS TEZİ

Muhammed Musa FINDIK

Danışman: Doç. Dr. Cem Emeksiz

TOKAT- 2022

ETİK SÖZLEŞME



JÜRİ KABUL VE ONAY



ÖNSÖZ

Tezimin hazırlanmasında danışmanlığımı yapan, tez için kullandığım verileri temin eden, bilgisini ve tecrübesini çalışmamın her aşamasında benimle paylaşan, çok değerli hocam Sayın Doç. Dr. Cem EMEKSİZ'e, Tez Değerlendirme Jürisi olarak yaptıkları değerli katkılar sebebiyle hocalarım Sayın Dr. Öğr. Üyesi Özkan İNİK'e ve Sayın Dr. Öğr. Üyesi Mehmet EKİCİ'ye teşekkürlerimi sunarım. Öğrenim hayatım boyunca bana emek veren, iyi ve güzel işler yapmanın önemini hayatıma dâhil ettiren tüm hocalarıma, arkadaşlarıma ve en önemlisi aileme teşekkürlerimi ve saygılarımı sunarım.

MUHAMMED MUSA FINDIK
30 HAZİRAN 2022

ÖZET

DERİN ÖĞRENME TABANLI HİBRİT TAHMİNLEME MODELİ KULLANARAK RÜZGAR HIZI TAHMİNLEMESİ

Fındık, Muhammed Musa
Yüksek Lisans, Elektrik-Elektronik Mühendisliği Anabilim Dalı
Tez Danışmanı: Doç. Dr. Cem Emeksiz
Haziran 2022, xiii + 81 sayfa

Günümüzde enerjiye ihtiyaç gün geçtikçe artmaktadır. Bu talebin karşılanabilmesi için fosil temelli kaynaklara göre daha çevreci bir yapıya sahip olan yenilenebilir enerji kaynakları ön plana çıkmaktadır. Bu enerji kaynaklarının başında gelen rüzgar enerjisine, sahip olduğu ekonomik ve çevresel birçok avantajlardan dolayı araştırmacılar tarafından son yıllarda yoğun ilgi gösterilmektedir. Özellikle rüzgar enerjisi çevrim sistemlerinin en önemli girdisini rüzgar hızı oluşturmaktadır. Rüzgar hızının değişkenlik gösteren doğası gereği, enterkonnekte sistemlere dahil edilmesinde sorunlarla karşılaşmaktadır. Karşılaşılan bu sorunların çözülmesinde rüzgar hızının doğru ve güvenilir bir şekilde tahminlemesi üzerinde yoğun çalışmalar gerçekleştirilmektedir. Gerçekleştirilen bu çalışmalar ile yüksek doğrulukta tahmin edilen rüzgar hızı kullanılarak başarılı, verimli enerji sistemleri ve bu sistemlerin optimizasyonu sağlanabilmektedir. Bu tez çalışmasında derin öğrenme yöntemleri ile rüzgar hızı tahmini için hibrit bir model önerilmektedir. Önerilen model Evrişimsel Sinir Ağları (CNN) ve Kapılı Tekrarlayan Birim (GRU) modellerinden oluşmaktadır. Bu tez çalışmasında yer alan rüzgar hızı verileri Tokat Gaziosmanpaşa Üniversitesi Mühendislik ve Mimarlık Fakültesi yerleşkesinde yer alan ölçüm istasyonundan elde edilmiştir. İstasyonda yer alan sensörler aracılığı ile 1'er saat aralıklar ile 3 yıllık (2018-2020) veri seti oluşturulmuştur. Oluşturulan veri seti kullanılmadan önce normalizasyon işlemi ile veri ön işlemesine tabi tutulmuştur. Sonrasında 3 farklı vaka çalışması için veriler haftalık, aylık ve yıllık olmak üzere ayrılmıştır. Önerilen modelin doğruluğu ve güvenilirliği performans kriterleri (MAPE, R^2 , RMSE) ile test edilmiştir. Modelin başarısını ölçmek için 5 farklı derin öğrenme yöntemleri (CNN-LSTM, CNN-RNN, LSTM-GRU, LSTM, GRU) ile kıyaslanması yapılmıştır. Rüzgar hızı tahminlemesi alanında ilk kez kullanılan CNN-GRU hibrit modeli yapılan kıyaslamalar neticesinde yüksek bir başarı yüzdesi elde ettiği gözlemlenmiştir.

Anahtar Kelimeler: Yenilenebilir Enerji, Rüzgar Enerjisi, Rüzgar Hızı Tahmini, Derin Öğrenme Yöntemleri, Hibrit Tahminleme Modeli

ABSTRACT
**WIND SPEED FORECASTING USING A DEEP LEARNING-BASED HYBRID
FORECASTING MODEL**

FINDIK, Muhammed Musa
Master Thesis, Department of Electrical-Electronics Engineering
Supervisor: Assoc. Prof. Dr. Cem Emeksiz
June 2022, xiii + 81 pages

Nowadays, the need for energy is increasing day by day. In order to meet this demand, renewable energy sources that have a more environmentally friendly structure than fossil-based sources come to the fore. Due to the many economic and environmental advantages that wind energy, which is one of the leading energy sources, has in recent years, researchers have been paying great attention to it. In particular, the most important input of wind energy cycle systems is wind speed. Due to the variable nature of the wind speed, problems are encountered with its inclusion in interconnection systems. In solving these problems, intensive studies are being carried out on accurate and reliable forecasting of wind speed. With the help of these studies, successful, efficient energy systems and optimization of these sites can be achieved by using the wind speed estimated with high accuracy. In this thesis, a hybrid model for wind speed estimation with deep learning methods is proposed. The proposed model consists of Convolutional Neural Networks (CNN) and Gated Recurrent Unit (GRU) models. The wind speed data in this thesis study were obtained from the measurement station located at the Faculty of Engineering and Architecture campus of Tokat Gaziosmanpasa University. A 3-year (2018-2020) data set has been created with December intervals of 1 hour through the sensors located at the station. The generated data set was subjected to data preprocessing by normalization process before being used. Then, the data were divided into weekly, monthly and yearly for 3 different case studies. The accuracy and reliability of the proposed model were tested by performance criteria (MAPE, R^2 , RMSE). In order to measure the success of the model, a comparison was made with 5 different deep learning methods (CNN-LSTM, CNN-RNN, LSTM-GRU, LSTM, GRU). It has been observed that the CNN-GRU hybrid model, which was used for the first time in the field of wind speed forecasting, achieved a high percentage of success as a result of comparisons made.

Keywords: Renewable Energy, Wind Energy, Wind Speed Forecasting, Deep Learning Methods, Hybrid Forecasting Model

İÇİNDEKİLER

	Sayfa
ETİK SÖZLEŞME.....	I
JÜRİ KABUL ve ONAY	II
ÖNSÖZ.....	III
ÖZET	IV
ABSTRACT	V
İÇİNDEKİLER.....	VI
SİMGELER ve KISALTMALAR	VIII
ŞEKİL LİSTESİ	XI
ÇİZELGE LİSTESİ	XIII
1) GİRİŞ	1
2) LİTERATÜR ÖZETLERİ.....	6
3) YENİLENEBİLİR ENERJİ KAYNAKLARI	15
3.1. Rüzgar Enerjisi	15
3.2. Güneş Enerjisi.....	18
3.3. Hidrolik Enerji.....	21
3.4. Jeotermal Enerji	22
3.5. Biyokütle Enerjisi	23
3.6. Dalga ve Gelgit Enerjisi	24
4) DÜNYA ve TÜRKİYE’DEKİ RÜZGAR ENERJİSİNİN POTANSİYELİ	26
5) RÜZGAR HIZI TAHMİNLEMESİ	31
6) MATERYAL ve YÖNTEM	36
6.1. Verilerin Elde Edilmesi	36
6.2. Evrimsel Sinir Ağları (CNN).....	41
6.3. Tekrarlayan Sinir Ağları (RNN)	44
6.4. Uzun-Kısa Vadeli Bellek (LSTM)	45

6.5. Kapılı Tekrarlayan Birim (GRU)	50
6.6. Performans Kriterleri	55
7) BULGULAR.....	57
7.1. 1. Vaka Çalışması (Haftalık Rüzgar Hızı Tahmini)	57
7.2. 2. Vaka Çalışması (Aylık Rüzgar Hızı Tahmini)	61
7.3. 3. Vaka Çalışması (Yıllık Rüzgar Hızı Tahmini).....	65
8) SONUÇLAR	70
9) KAYNAKÇA	72
ÖZGEÇMİŞ	81



SİMGELER ve KISALTMALAR

SİMGELER

σ : Sigma
C: Bellek Hücresi
F: Unutma Kapısı
GW: Gigawatt
GWh: Gigawatt Saat
 h_t : Çıktı Verisi
i: Giriş Kapısı
KW: Kilowatt
kWh: Kilowatt Saat
m: Metre
MW: Megawatt
o: Çıkış Kapısı
s: Saniye
tanh: Tanjant Hiperbolik Fonksiyonu
TWh: Terawatt saat
W: Watt
Wm: Rüzgar Gücü
Ws: Rüzgar Hızı
 x' : Normalize edilen veri
 x_i : Normalize edilecek veri
 $x_{\max}$: En büyük veri
 $x_{\min}$: En küçük veri
 x_t : Girdi Verisi
 z_t : Güncelleme Geçidi
 y_i : Gözlemlenen Rüzgar Hızı
N: Toplam Örnek Sayısı

KISALTMALAR

AE: Otomatik Kodlayıcı
AGRU: Dikkat Temelli Kapılı Tekrarlayan Birim

ANN: Yapay Sinir Ağ

AR: Otoregresif

ARD: Otomatik Alaka Düzeyi Belirleme

ARIMA: Otoregresif Entegre Hareketli Ortalama

ARMA: Otoregresif hareketli ortalama

BiLSTM: Çift Yönlü Kısa Uzun Vadeli Bellek

BP: Geri Yayılım (Back Propagation)

BPNN: Geri Yayılımlı Sinir Ağı (Back Propagation Neurol Network)

CEEMDAN: Uyarlanabilir Gürültülü Bütünleşik Ampirik Mod Ayırıştırma (Complete Ensemble Empirical Mode Decomposition Adaptive Noise)

COVID-19: Yeni Koronavirüs

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

ELDER: Elektrik Dağıtım Hizmetleri Derneği

EPDK: Enerji Piyasası Düzenleme Kurulu

ETKB: Enerji ve Tabii Kaynaklar Bakanlığı

EWT: Ampirik Dalgacık Dönüşümü (Empirical Wavelet Transform)

f-ARIMA: Kesirli Otoregresif Entegre Hareketli Ortalama

FFBPN: İleri Beslemeli Geri Yayılım Ağı

GA: Genetik Algoritma

GFNN: Genelleştirilmiş İleri Beslemeli Sinir Ağı

GLSTM: Genetik Uzun Kısa Vadeli Bellek

GPU: Grafik İşlem Ünitesi

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

GWEC: Küresel Rüzgar Enerjisi Konseyi (Global Wind Energy Council)

GWO: Gri Kurt Optimizasyonu

IMF: İçsel Salınım Fonksiyonlarına (Intrinsic Mode Function)

LMD: Yerel Ortalama Ayırıştırması (Local Mean Decompositon)

LSTM: Uzun Kısa Vadeli Bellek (Long Short Term Memory)

MAPE: Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percent Error)

MATLAB: Matrix Laboratory

MGM: Meteoroloji Genel Müdürlüğü

MSE: Ortalama Karesel Hata (Mean Square Error)

MTA: Maden Tetkik ve Arama Genel Müdürlüğü

MTEP: Milyon Ton Eşdeğer Petrol
NN: Sinir Ağı (Neural Network)
NWP: Sayısal Hava Tahmini
PM: Kalıcılık Modeli
 R^2 : Determinasyon Katsayısı (Determination Coefficient)
RBFNN: Radyal Temel Fonksiyon Sinir Ağı
RBM: Kısıtlı Boltzman Makineleri
RAM: Rastgele Erişimli Hafıza (Random Access Memory)
REN21: 21. Yüzyıl için Yenilenebilir Enerji Politikası Ağı (Renewable Energy Policy Network for the 21st Century)
RES: Rüzgar Enerji Santrelleri
RİTM: Rüzgar Gücü İzleme ve Tahmin Merkezi
RMLP: Çok Katmanlı Algılayıcı Sinir Ağları
RMSE: Ortalama Karesel Hatanın Karekökü (Root Mean Square Error)
RNN: Tekrarlayan Sinir Ağı (Recurrent Neural Network)
SCADA: Merkezi Denetim ve Veri Toplama (Supervisory Control and Data Acquisition)
SSA: Tekil Spektrum Analizi
STLF: Kısa Vadeli Yük Tahmini
SVR: Destek Vektör Regresyon
TEİAŞ: Türkiye Elektrik İletim Anonim Şirketi
TEP: Ton Eşdeğer Petrol
TÜREB: Türkiye Rüzgar Enerjisi Birliği
VAE: Varyasyonlu Otomatik Kodlayıcı
VMD: Varyasyonel Mod Ayrıştırma (Validation Mode Decomposition)
WNN: Dalgacık Sinir Ağı (Wavelet Neural Network)
WPD: Dalgacık Paket Dönüşümü (Wavelet Packet Decomposition)
WRNN: Dalgacık Tekrarlayan Sinir Ağı
YSA: Yapay Sinir Ağı

ŞEKİL LİSTESİ

Şekil No	Sayfa
Şekil 1.1: Enerji kaynaklarının genel sınıflandırılması.....	2
Şekil 3.1: Rüzgar enerjisi küresel kapasitesi ve yıllık ilaveleri 2010-2020.....	16
Şekil 3.2: Türkiye rüzgar atlası.....	17
Şekil 3.3: Türkiye ortalama güneşlenme haritası.....	20
Şekil 3.4: Türkiye aylık ortalama güneşlenme süresi.....	20
Şekil 3.5: Türkiye'nin jeotermal kaynaklar ve uygulama haritası.....	23
Şekil 3.6: Türkiye'nin biyokütle potansiyel haritası.....	24
Şekil 4.1: Rüzgar enerjisi kapasitesi ve 2020 yılı ilaveleri ile ilk 10 ülke.....	28
Şekil 4.2: Türkiye rüzgar enerjisi potansiyel atlası (100m).....	29
Şekil 4.3: Türkiye'nin yıllara göre rüzgar santrali kurulu güç.....	30
Şekil 6.1: Ölçüm direği.....	37
Şekil 6.2: Güç kutusu.....	38
Şekil 6.3: Haftalık rüzgar hızı verilerinin histogram grafiği.....	39
Şekil 6.4: Haftalık rüzgar hızı verilerinin dağılım grafiği.....	39
Şekil 6.5: Aylık rüzgar hızı verilerinin histogram grafiği.....	40
Şekil 6.6: Aylık rüzgar hızı verilerinin dağılım grafiği.....	40
Şekil 6.7: Yıllık rüzgar hızı verilerinin histogram grafiği.....	41
Şekil 6.8: Yıllık rüzgar hızı verilerinin dağılım grafiği.....	41
Şekil 6.9: Evrimsel sinir ağ mimarisi.....	43
Şekil 6.10: Tekrarlayan sinir ağlarının temel açılımı.....	44
Şekil 6.11: LSTM genel yapısı.....	46
Şekil 6.12: LSTM başlangıç adımı.....	47
Şekil 6.13: Saklanacak yeni bilgilerin karar verilmesi aşaması.....	48
Şekil 6.14: Hücre güncellemesi.....	49
Şekil 6.15: Çıktı karar durumu.....	50
Şekil 6.16: GRU notasyonları.....	51
Şekil 6.17: Kapalı tekrarlayan birim mimarisi.....	51
Şekil 6.18: GRU kapı güncelleme.....	52
Şekil 6.19: Sıfırlama kapısı.....	53

Şekil 6.20: Geçerli bellek işlemi.....	54
Şekil 6.21: Mevcut birim için bilgiyi tutan ve ileten fonksiyonun hesaplanması.....	55
Şekil 7.1: Haftalık tahminleme performans grafiği.....	58
Şekil 7.2: CNN-GRU tahminleme grafiği.....	58
Şekil 7.3: CNN-LSTM tahminleme grafiği.....	59
Şekil 7.4: CNN-RNN tahminleme grafiği.....	59
Şekil 7.5: LSTM-GRU tahminleme grafiği.....	59
Şekil 7.6: GRU tahminleme grafiği.....	60
Şekil 7.7: LSTM tahminleme grafiği.....	60
Şekil 7.8: Gerçek rüzgar hızı ile tüm modellere göre tahminlenen rüzgar hızları değişimi.....	61
Şekil 7.9: Aylık tahminleme performans grafiği.....	62
Şekil 7.10: CNN-GRU tahminleme grafiği.....	62
Şekil 7.11: CNN-LSTM tahminleme grafiği.....	63
Şekil 7.12: CNN-RNN tahminleme grafiği.....	63
Şekil 7.13: LSTM-GRU tahminleme grafiği.....	63
Şekil 7.14: GRU tahminleme grafiği.....	64
Şekil 7.15: LSTM tahminleme grafiği.....	64
Şekil 7.16: Gerçek rüzgar hızı ile tüm modellere göre tahminlenen rüzgar hızları değişimi.....	65
Şekil 7.17: Yıllık tahminleme performans grafiği.....	66
Şekil 7.18: CNN-GRU tahmin grafiği.....	66
Şekil 7.19: CNN-LSTM tahminleme grafiği.....	67
Şekil 7.20: CNN-RNN tahminleme grafiği.....	67
Şekil 7.21: LSTM-GRU tahminleme grafiği.....	67
Şekil 7.22: GRU tahminleme grafiği.....	68
Şekil 7.23: LSTM tahminleme grafiği.....	68
Şekil 7.24: Tüm modellerin kıyaslama grafiği.....	69

ÇİZELGE LİSTESİ


Çizelge No	Sayfa
Çizelge 3.1: Yenilenebilir enerji çeşitleri ve kaynakları.....	15
Çizelge 3.2: Türkiye'nin 50m'de rüzgar enerjisi potansiyeli (ortalama rüzgar hızı > 7,0 m/s).....	18
Çizelge 3.3: Güneş enerjisi kurulu güç(MW) ilk 10 ülke.....	19
Çizelge 3.4: Hidroelektrik kurulu güç (MW) ilk 20 ülke.....	21
Çizelge 3.5: Jeotermal enerji kurulu güç ilk 20 ülke.....	22
Çizelge 4.1: Dünya geneli rüzgar türbini kurulu güç (Kara).....	26
Çizelge 4.2: Dünya geneli rüzgar türbini kurulu güç (Deniz-Okyanus).....	27
Çizelge 4.3: Bölgelere göre kurulu güç.....	29
Çizelge 5.1: Rüzgar tahmini için zaman ölçeği sınıflandırması.....	32
Çizelge 6.1. Model parametreleri.....	44
Çizelge 7.1: Haftalık tahminleme performans kıyaslaması.....	57
Çizelge 7.2: Aylık tahminleme performans kıyaslaması.....	61
Çizelge 7.3: Yıllık tahminleme performans kıyaslaması.....	65

1) GİRİŞ

Sosyal ve ekonomik sürdürülebilirlik açısından enerji kaynakları toplumların yaşamında son derece önemli bir yere sahiptir. Dünya üzerinde artan nüfus ile birlikte doğru orantılı artan enerji talepleri gün geçtikçe çok yüksek boyutlara ulaşmaktadır. Bununla birlikte ülkelerin sosyal ve ekonomik gelişiminin en önemli göstergelerinden bir tanesi enerji üretimi ve kullanımındır (Tan, 2020). Endüstri Devrimi ile gelişmiş ve gelişmekte olan toplumların enerjiye olan ilgisi ve talebi artmıştır. Bu artış bulunduğumuz yüzyılda hızla devam etmektedir. Enerji ihtiyacının giderilebilmesi, toplumların ve bireylerin varlığını devam ettirebilmesi adına önem arz etmektedir (Emeksiz ve Fındık, 2021). Gelişmekte olan ülkelerin birçoğu halen enerjiye olan ihtiyacını karşılayabilmek ve sanayileşme ile üretim kapasitelerini artırabilmek için petrol, kömür, doğalgaz gibi fosil türevli geleneksel enerji kaynaklarını tercih etmektedir (Yüksel, 2020). Günümüzde ise ülkeler açısından enerji temini sorunu yaşanmakta ve hammadde eksikliği yaşayan ülkeler enerji ihtiyacını, ithalat ile karşılamak durumunda kalmaktadır. Uzun vadede enerji kaynaklarında dışa bağımlılığın ekonomik açıdan sürdürülebilmesi hiçbir ülke ve toplum için mümkün değildir.

Günümüzde, gelişmekte olan ülkelerin karşılaştığı en önemli problemlerden bir tanesi enerjinin sürekliliğinin sağlanması ve güvenli bir şekilde temin edilebilmesidir. Gelişmekte olan ülkelerin, mevcut enerji politikaları ile enerji devamlılığını sağlaması mümkün değildir. Devamlılığı mümkün olmayan yapının nedenleri arasında, enerji temininin çoğu ülke genelinde fosil temelli kaynaklardan elde edilmesinin bir neticesidir. Sanayi devrimi ile beraber, ağır sanayide üretimin sebep olduğu yüksek enerji ihtiyacı, beraberinde toplumların teknolojiye çok çabuk entegre olmasını da gerektirmektedir. Günümüz teknolojisi enerji tüketen makinalara bağımlıdır. Yaygın olarak kullanılan teknolojik cihazlar, ısınmadan barınmaya, ulaşımdan haberleşmeye kadar günlük yaşamda enerji kaynaklarına dayalı tüketim büyük ölçüde artmıştır (Emeksiz ve Fındık, 2021). Ülkelerin ve toplumların varlığını sürdürebilmesi ve refah seviyesini yükseltmesi adına bu artışın karşılanabilmesi gerekmektedir. Fosil yakıtların hammadde açısından gelecek yüzyıllarda temin edilemez olması ve çevreye verdiği zararlı etkiler ile hem ekonomik açıdan hem de çevresel açıdan sürdürülemez bir hale gelmiştir. Ülkelerin ve toplumların giderek artmakta olan bu enerji ihtiyaçlarını karşılayabilmesi ve sürdürülebilirliğini sağlaması adına uzun vadeli planlar ve gerekli bilimsel çalışmalar yapılmalıdır (Tan, 2020).

Enerji kaynakları kullanılışlarına ve dönüştürülebilirliklerine göre ikiye ayrılmaktadır. Şekil 1.1’de bu enerji kaynakları genel olarak sınıflandırılmıştır. Uluslararası Enerji Ajansı’nın yapmış olduğu çalışmalar incelendiğinde Dünya’daki birincil enerji gereksinimi eşdeğer petrol cinsinden yaklaşık 14 milyar ton olarak hesaplanmaktadır. Bu şartlar altında bakılacak olursa gelişen teknoloji ile beraber enerjiye olan talebin giderek artması ve tüketim hızının da artması öngörülmektedir. Aynı zamanda ülkelerin enerjinin kullanımına yönelik mevcut politikaları devam edecek olursa gelecekteki 20-25 yıla yakın bir zamanda %45 oranında bir artışla 20,3 milyar ton eşdeğer petrol (TEP) seviyelerine ulaşabilmesi mümkün görülmektedir (Emeksiz ve Fındık, 2021). Enerji tüketim miktarları incelendiğinde ülkeler arasındaki sıralamada Çin Halk Cumhuriyeti birinci sırada bulunmaktadır. Aynı sıralamada 129,3 milyon ton eşdeğer petrol birincil enerji tüketimi ile Türkiye 2015 yılında 19.sırada yer almaktadır (Türkiye Doğalgaz Birliği, 2016). 2020 yılı itibariyle Türkiye en fazla enerji tüketen ülkeler listesinde gelişmekte olan bir ülke olarak 2 sıra yükselerek 17. sırada kendine yer bulmuştur. (Worldometer, 2021)



Şekil 1.1. Enerji kaynaklarının genel sınıflandırılması (Koç ve Kaya, 2015)

Son yıllarda gelişen teknoloji ve ağır sanayiye yapılan yatırımlar ile birlikte enerjinin toplumlar için vazgeçilmez bir kaynak olduğu kanıtlanmıştır. Fosil temelli kaynakların başta çevre olmak

üzere ülkelere vermiş olduğu olumsuz etkileri, hem çevresel hem de ekonomik açıdan ciddi sorunlara sebep olmaktadır. Fosil temelli kaynakların yerine, yenilenebilir enerji kaynakları toplumların kalkınması adına ekonomik açıdan daha avantajlıdır ve bunun yanı sıra doğa dostu bir enerji kaynağıdır. Gelecek yıllarda yenilenebilir enerji kaynakları önemli bir potansiyele sahiptir.

Son dönemde yenilenebilir enerji kaynakları, toplumların enerji ihtiyacının ve talebin karşılanmasında aktif olarak rol almaya başlamıştır. Yenilenebilir enerji kaynakları yatırım maliyetlerini kısa sürede amorti etmesi, hammaddesini doğadan karşılıyor olabilmesi, petrol ve türevi hammaddelerin atmosferimize sera gazı salınımı olmasına karşın yenilenebilir enerji kaynaklarında bu gibi problemlerin olmaması hem çevresel açıdan hem de ekonomik açıdan daha sürdürülebilir bir enerji politikası izlenebilmesi adına hayati öneme sahiptir. Son yıllarda yenilenebilir enerji kaynaklarına olan ilgi ile yatırımlar ve yeni çalışmalar artmaktadır. Yenilenebilir enerji kaynakları mevcut güneş sistemimiz ve dünya ekosistemimiz var olması ile kendi kendini yenileyebilen bir enerji kaynağıdır (Demir, 2019). Gelecekte enerji ihtiyacının karşılanabilmesi ve sürdürülebilir olması adına yapılacak olan çalışmaların büyük bir kısmı yenilenebilir enerji kaynaklarına yapılacak olan yatırımlar çerçevesinde gerçekleşmesi gerekmektedir.

COVID-19 pandemisinin etkilerine rağmen 2020’de yenilenebilir enerji yeni elektrik kapasitesinde rekor kırdı. Yenilenebilir enerji kapasitesine yönelik hedeflenen yatırım son yıl göreceli olarak az miktarda olmasına karşın ardı ardına üç yıl artış gösterdi ve birçok firma yenilenebilir elektrik tedarikinde rekorlar kırarak büyüme sağladı. Birçok ülke, ısının elektrifikasyonu için yenilenebilir kaynaklara yöneldi. Çin Halk Cumhuriyeti, küresel anlamda karşı karşıya kaldığımız iklim değişikliğine karşı eylem planlarını ve vaatlerini güçlendiren ve karbon nötr bir hedef belirleyen ülkeler arasında yer aldı. ABD, 2021’in başlarında Paris Anlaşması’na yeniden katıldı (REN21, 2021). Dünya’da ve ülkemizde yenilenebilir enerjiye olan ilgi gitgide artmaktadır. Yenilenebilir enerji alanında yapılan çalışma ve yatırımlar artarak devam etmektedir. Son dönemde yenilenebilir enerji kaynaklarının önemi bir kez daha anlaşılmıştır.

Yenilenebilir enerji kaynakları günümüzde biyokütle, güneş, rüzgar, jeotermal, deniz-okyanus(gel-git), hidrojen ve hidrolik enerji gibi kaynaklardan meydana gelmektedir. Yenilenebilir enerji kaynaklarına ciddi yatırımlar yapan ülkelerin, bu çevre dostu kaynakları

geliştirmeye ve yüksek verim elde etmesine yönelik çeşitli Ar-Ge çalışmaları başlattıkları ve önem verdikleri görülmektedir (Demir, 2019).

Yenilenebilir enerji kaynakları arasında rüzgar enerjisi incelenecek olursa, hem kurulum maliyeti hem de üretebildiği elektrik enerjisi açısından ön plana çıkmaktadır. Rüzgar enerjisi, yenilenebilen enerji kaynakları içinde Dünya üzerinde ticari olarak ve gelişmişlik açısından elverişli enerji türleri arasında önde gelmektedir (Albostan ve ark., 2009). Dünya genelinde son on yılda rüzgar enerjisi kurulu gücü artarak büyümektedir. 2020 yılında Dünya üzerinde kurulu güç 650 GW'tan 743 GW seviyelerine ulaşmıştır (REN21, 2021). Dünya genelinde rüzgar enerjisinden elde edilen elektrik enerjisinin gün geçtikçe artması öngörülmektedir.

Rüzgar enerjisi diğer yenilenebilir enerji kaynakları ile karşılaştırıldığında hem kurulum hem de işletme maliyeti bakımından fazlasıyla avantajlıdır. Rüzgar enerjisinden elektrik üretilecek santraller, ilk olarak santralin kurulum aşamasında kapsamlı bir Ar-Ge çalışması yapılması gerekmektedir (Demir, 2019). Rüzgar enerjisinden elektrik üretiminin yapılması planlanan bölgelerin belirlenmesinde çevresel ve meteorolojik koşullar göz önünde bulundurulmalıdır. Bu koşullar santralin kurulacağı bölgede rüzgar hızı, rüzgar yönü ve basınç gibi parametrelerden meydana gelmektedir. Bu parametrelerin yanı sıra günümüzde rüzgar enerjisinden faydalanmak için rüzgarın dakika, saat ve aylık vb. gibi hangi zaman aralıklarında, hangi sıklık ile estiği önemlidir (Tan, 2020). Kısacası rüzgar enerjisi santrali projesinin ilk adımı, santralin kurulumu yapılacak olan bölgeden alınacak olan gerçek zamanlı verilerin analiz edilerek değerlendirilmesi ile işe başlanmalıdır. Yapılacak olan değerlendirmeler neticesinde bölgenin rüzgar enerjisi santrali kurulumu için elverişli olup olmadığı anlaşılabacaktır.

Bu tez çalışmasında rüzgar hızı tahminlemede kullanılan klasik yöntemlere alternatif derin öğrenme tabanlı hibrit bir model önerilmiştir. Önerilen hibrit model Evrimsel Sinir Ağı (CNN) ve Kapılı Tekrarlayan Birim (GRU) sinir ağının birleşmesinden oluşmaktadır. Benzer şekilde bağımsız derin öğrenme yöntemlerinin kullanıldığı literatür çalışmalarına rastlanılmakla birlikte, özellikle oluşturulan hibrit yapı rüzgar hızı tahminlemesi alanında ilk defa denenmiştir. Bu durum çalışmanın en temel özgün yanını oluşturmaktadır. Ayrıca derin öğrenme yöntemlerinin kullanılması ile elde edilen hibrit tahminleme modeli, rüzgar hızı tahminlemelerinde daha performanslı sonuçlar göstermiştir. Önerilen model 5 farklı derin öğrenme yöntemleri ile kıyaslanmıştır. Tüm kıyaslamalarda önerilen modelin daha doğru ve güvenilir sonuçlar verdiği gözlenmiştir. Performans metrikleri olarak literatürde yaygın

kullanılan ortalama mutlak yüzde hata (Mean Absolute Percentage Error - MAPE), determinasyon katsayısı (Determination Coefficient - R^2), kök ortalama kare hata (Root Mean Square Error - RMSE) tercih edilmiştir.



2) LİTERATÜR ÖZETLERİ

Li ve Shi (2010), yaptıkları bir çalışmada rüzgar enerjisi dönüşüm sistemleri için güç sisteminin programlanması ve rüzgar türbininin hareketli kontrolü gibi konularda rüzgar hızı tahmininin önemine vurgu yapmışlardır. Yaptıkları çalışmada 1 saat ileri rüzgar hızı tahmininde farklı yapay sinir ağlarının uygulanması üzerine kapsamlı bir karşılaştırma sunmaktadırlar. Bu karşılaştırmalar; uyarlamalı doğrusal eleman, geri yayılım ve radyal temel fonksiyon olmak üzere üç tip tipik sinir ağı yapılarından oluşmaktadır. Elde edilen optimal modeller arasında, belirli bir değerlendirme metriği açısından göreceli fark % 20'ye kadar çıkabilir. Bu, bir son işleme yöntemi uygulayarak tek bir sağlam ve güvenilir tahmin üretme ihtiyacını gösterir.

Yu ve ark., (2021), yaptıkları çalışmada, rasyonel tarımsal sulama için mısır kök bölgesindeki farklı derinliklerdeki toprak suyu içeriğini tahmin etmenin önemine vurgu yapmışlardır. Yaptıkları çalışmada güçlü özellik ifade kapasitesine sahip bir evrişimsel sinir ağı (CNN) ile güçlü bellek kapasitesine sahip bir kapılı tekrarlayan birim (GRU) sinir ağını birleştiren hibrit bir evrişimsel sinir ağı kapılı tekrarlayan birim (CNN-GRU) entegre derin öğrenme modeli önermişlerdir. Hibrit CNN-GRU modelinin tahmin doğruluğu ve yakınsama oranı açısından bağımsız CNN veya GRU modelinden daha iyi bir performans verdiğini göstermiştir.

Liviers ve ark., (2020), yaptıkları bir çalışmada altın fiyatlarındaki dalgalanmayı tahmin etmek üstüne hibrit bir derin öğrenme modeli kullanmışlardır. Önerilen model, yararlı bilgiler elde etmek ve zaman serisi verilerinin dahili temsilini öğrenmek için kıvrımlı katmanların yeteneğinin yanı sıra kısa süreli ve uzun vadeli bağımlılıkları tanımlamak için uzun kısa vadeli bellek (LSTM) katmanlarının etkinliğini kullanır. Bir dizi deney sonucunda önerilen modeli en son teknolojiye sahip derin öğrenme ve makine öğrenme modellerine karşı değerlendirilmesi yapılmıştır. Ön deneysel analiz, LSTM katmanlarının ilave kıvrımlı katmanlarla birlikte kullanılmasının tahmin performansını arttırmada önemli bir destek sağlayabileceğini göstermiştir.

Somon ve ark., (2010), yaptıkları çalışmada son yıllarda, çevresel hususlar, rüzgar enerjisinin yenilenebilir bir enerji kaynağı olarak kullanılmasını teşvik etmiştir. Bununla birlikte, rüzgar gücünü elektrik şebekesine entegre etmedeki en büyük zorluk, kesintili olması üzerine rüzgar kesintisi ile başa çıkmak için bir yaklaşım öne sürmüşlerdir. Bu yaklaşım rüzgar enerjisi

retiminin gelecekteki deęerlerini tahmin etmektir. Yapılan alıřmada, sayısal hava tahmini (NWP), istatistiksel yaklařımlar, yapay sinir aęı (YSA) ve farklı zaman leklerinde hibrit tekniklere dayanan rzgar gc ve hızı ile ilgili en nde gelen tahmin teknikleri hakkında fikir vermektedir.

Liu ve ark., (2020), yaptıkları bir alıřmada, rzgar hızı tahmin performansını ve kararlılıęını daha da geliřtirmek iin, bir veri n iřleme stratejisine, deęiřtirilmiř bir ok amalı optimizasyon algoritmasına ve eřitli tahmin modellerine dayalı bir tahmin sistemi geliřtirmiřlerdir. Daha spesifik olarak, bir rzgar hızı serisinin baskın eęilimini belirlemek ve grlt giriřimini kontrol etmek iin bir veri n iřleme stratejisi yrtmektedirler. ok amalı optimizasyon algoritması, daha tatmin edici tahmin kesinlięi ve istikrarı elde etmeye yardımcı olabilmektedir. oklu tahmin modelleri, rzgar hızı tahmini iin birleřik bir model oluřturmak zere entegre edilmiřtir. Geliřtirilen tahmin sisteminin zelliklerini doęrulamak iin, in, Shandong Yarımadası'ndaki 4 bitiřik rzgar iftlięinden 10 dakikalık rzgar hızı verileri vaka alıřmaları olarak kabul edilmiřtir. Nokta tahmini ve aralık tahmininin sonuları, tahmin sisteminin tahmin kesinlięi ve istikrarı aısından tm karřılařtırmalı modelleri olumlu bir řekilde ařtıęını ortaya koymaktadır.

Chandran ve ark., (2021), yapmıř oldukları bir alıřmada, rzgar hızı verilerinden kısa vadeli rzgar enerjisi retimini tahmin etmek iin  derin ęrenme algoritması kullanmıřlardır. Makine ęrenimi algoritmalarını kullanarak rzgar enerjisinin rzgar gc deęerlerini etkili bir řekilde tahmin edecek bir sistem nerilmiřtir. Bu alıřma iin benimsenen makine algoritmaları Uzun Kısa Vadeli Bellek (LSTM), Kapılı Tekrarlayan Birimi (GRU) ve Tekrarlayan Sinir Aęıdır (RNN). nerilen modeller, rzgar santrali retiminin projeksiyonuna altı kez uygulanmıřtır. Performansı ve dięer yaklařımları dengelemek iin hata analizi yapılır. Kısa vadeli rzgar enerjisi tahminlerinin doęruluęunun iyileřtirilmesi konusunda daha fazla tartıřılmaktadır. Ayrıca, sonular makine ęrenimi modellerinin modeller dıřındaki yerlerde kullanılabileceęini gstermiřtir. Yapılan arařtırma, temel konum modelinin makul olması durumunda, rzgar santrallerinin bilinmeyen bir coęrafi alana kurulmasından nce makine ęrenme algoritmalarının verimli bir řekilde kullanılabileceęini gstermiřtir.

Hossain ve ark., (2021), yaptıkları bir çalışmada, Avustralya'nın Yeni Güney Galler kentinde bulunan Bodangora rüzgar çiftliği için çok kısa vadeli rüzgar enerjisi üretiminin tahmin doğruluğunu artırmak adına yeni bir hibrit derin öğrenme modeli önerilmiştir. Hibrit model, kıvrımlı katmanlardan, kapılı tekrarlayan birim (GRU) katmanlarından ve tamamen bağlı bir sinir ağından oluşur. Kıvrımlı katmanlar, ham verilerden karmaşık özellikleri otomatik olarak öğrenme yeteneğine sahipken, GRU katmanları birden fazla paralel girdi verisi dizisini doğrudan öğrenme yeteneğine sahiptir. Rüzgar santralinden 5 dakikalık aralıklarla veri setleri, önerilen modelin uzun kısa vadeli bellek, GRU, otoregresif entegre hareketli ortalama ve sonucu optimize edecek şekilde ayarlanmış destek vektör makinesi dahil olmak üzere diğer gelişmiş mevcut modellere karşı etkinliğini göstermek için vaka çalışmalarında kullanılır. Önerilen modelin etkinliğini daha fazla değerlendirmek için, Avustralya'daki Sermaye rüzgar çiftliğinden alınan başka bir veri seti kullanılmaktadır. Hibrit derin öğrenme modeli rüzgar enerjisi tahmin doğruluğu, sayısal Bodangora rüzgar çiftliği için, ortalama mutlak hata yüzde 1.59 kadar ortalama mutlak hata yüzdesi, yüzde ortalama karekök hata yüzde 3.73 ve 8.13 geliştirmek için diğer tahmin modelleri üzerinde hem veri setleri üstün bir performans sergilediği görülmektedir.

Zang ve ark., (2020), yaptıkları bir çalışmada, derin öğrenmeye dayalı bir mekansal-zamansal korelasyon modeli önererek doğru kısa vadeli güneş ışıınımı tahmini yapmaktadır. Önerilen model ilk olarak, bir hedef bölge ve komşu bölgelerle ilişkili meteorolojik parametrelerden oluşan iki boyutlu bir matristen uzamsal özellikleri çıkarmak için bir evrişimsel sinir ağı (CNN) uygular. Daha sonra, hedef bölgeyle ilişkili tarihsel güneş ışıınımı zaman serisi verilerinden zamansal özellikleri çıkarmak için uzun kısa vadeli bellek (LSTM) ağı uygulanır. Son olarak, mekânsal-zamansal korelasyonlar, küresel yatay ışıınımı bir saat önceden tahmin etmek için birleştirilir. Önerilen CNN-LSTM modelinin tahmin performansı ve genelleme kabiliyeti, farklı mevsimler ve hava koşulları altında bir yıl içinde değerlendirilir. Teksas, ABD'deki üç farklı iklim bölgesine yayılmış 34 lokasyondan toplanan vaka çalışmaları için üç veri seti yer almaktadır. Ayrıca, CNN-LSTM modelinin performansı, beş değerlendirme metriğine dayanan CNN, LSTM ve diğer kıyaslama modelleri kullanılarak elde edilenlerle karşılaştırılmıştır. Sonuçlar, önerilen modelin dikkate alınan diğer modellere göre avantajlara sahip olduğunu ve kısa vadeli güneş radyasyonu tahmini için iyi bir alternatif sağladığını göstermektedir.

Belavadi ve ark., (2020), yaptıkları bir çalışmada, çeşitli yerlerden gerçek zamanlı hava kirletici konsantrasyon verilerini izlemek ve toplamak ve bu verileri gelecekteki hava kirletici konsantrasyonlarını tahmin etmek için kullanmak için ölçeklenebilir bir mimari önermektedir. Zaman serisi verileriyle kanıtlanmış başarı sicili nedeniyle, hava kalitesi tahmini görevini gerçekleştirmek için Uzun Kısa Vadeli Bellek (LSTM) Tekrarlayan Sinir Ağı (RNN) modeli seçildi. Bu makale, hava kalitesinde zamansal değişimlerde önemli bir farklılık sergileyen iki bölgede modelin performansını eleştirel olarak analiz etmektedir. Bu varyasyonlar arttıkça model, uyarlanabilir modelleme gerektiren performans düşüşüne maruz kalır.

Kim ve ark., (2019), yaptıkları bir çalışmada, sensör verilerini kullanarak şüpheli kaçak yer(ler)ini gerçek zamanlı olarak tahmin eden bir model önerilmişlerdir. Kurulan sensörlerden toplanan verileri öğrenen ileri beslemeli sinir ağı ve uzun kısa vadeli belleğe sahip tekrarlayan sinir ağı, ilk 5 noktayı en yüksek olasılık sırasına göre tahmin etmek için önerilmiştir. Sinir ağlarını eğitmek ve doğrulamak için, gerçek bir kimya tesisi için hesaplamalı akışkanlar dinamiği simülasyonlarından üretilen sensör verileri kullanılır. Tasarlanan model, kaza senaryoları için ters problem çözme öğrenir ve sızıntı noktasını çok yüksek doğrulukla tahmin eder.

Shadid ve ark., (2021), yaptıkları bir çalışmada, kısa süreli rüzgar gücünü tahmin etmek için uzun kısa vadeli bellek ve genetik algoritmadan (GA) oluşan yeni bir genetik uzun kısa vadeli bellek (GLSTM) modeli önerilmiştir. Önerilen GLSTM modelinde, sıralı verilerden özellikleri otomatik olarak öğrenme yeteneği nedeniyle LSTM'nin gücü kullanılırken, global optimizasyon stratejisi LSTM katmanlarında pencere boyutunu ve nöron sayısını optimize etmek için GA'dan yararlanır. GLSTM'den elde edilen tahmin, gerçek güç, destek vektörü regresör tahminleri ve standart performans endeksleri açısından rapor edilen tekniklerle karşılaştırılmıştır. GLSTM ve varyantlarının, Avrupa'daki yedi rüzgar çiftliğinin rüzgar enerjisine ilişkin doğru, güvenilir ve sağlam tahminler sağladığı karşılaştırmadan değerlendirilebilir. Yüzde iyileştirme açısından, GLSTM, mevcut tekniklerin aksine rüzgar enerjisi tahminlerini ortalama olarak %6'dan %30'a yükseltir. Wilcoxon işaretli sıra testi, GLSTM'nin standart LSTM'den önemli ölçüde farklı olduğunu gösterir.

Gao ve ark., (2020), yaptıkları bir çalışmada, saatlik ışıınım tahmini için yeni bir CEEMDAN–CNN–LSTM modeli önermektedir. İlk olarak, veri özelliklerini çıkarmak için orijinal geçmiş verileri bir dizi kurucu seriye ayrıştırmak için eksiksiz topluluk deneysel mod ayrıştırma uyarlamalı gürültüsü (CEEMDAN) kullanılır. İkinci olarak, bir sonraki saatteki güneş ışıınımını tahmin etmek için evrişimsel sinir ağına (CNN) ve uzun kısa vadeli bellek ağına (LSTM) dayalı bir derin öğrenme ağı kullanılır. Ayrıca, bu çalışmada, güneş ışıınımını tahminleri için çeşitli CNN–LSTM tabanlı stratejiler sistematik olarak araştırılmaktadır. Önerilen modelin tüm potansiyelini değerlendirmek için farklı iklim türleri hakkında dört gerçek dünya veri seti kullanılmıştır. Çoklu karşılaştırmalı deneyler, önerilen CEEMDAN–CNN–LSTM modelinin güneş ışıınımını doğru bir şekilde tahmin edebildiğini ve çok sayıda alternatif yöntemden daha iyi performans gösterdiğini göstermektedir. 38,49 W/m ortalama RMSE², CEEMDAN–CNN–LSTM modelinin farklı iklim koşullarında nispeten kararlı bir tahmin performansına sahip olduğunu göstermektedir.

Seccad ve ark., (2020), yaptıkları bir çalışmada, önerilen model doğru enerji tüketimi tahmini için birleşik bir çerçevede Evrişim Sinir Ağı (CNN) ve Kapılı Tekrarlayan Birimleri (GRU) kullanan hibrit sıralı öğrenme tabanlı bir enerji tahmin modeli geliştirerek enerji tahminini gerçekleştirmektedir. Önerilen modelin iki ana aşaması vardır: (1) Veri iyileştirme ve (2) veri iyileştirme aşamasının ham veriler üzerinde ön işleme stratejileri uyguladığı eğitimidir. Eğitim aşamasında, CNN özellikleri girdi veri setinden çıkarılır ve kapsamlı deneylerden sonra optimal olarak seçilen ve gelişmiş dizi öğrenme yeteneklerine sahip olduğu gözlemlenen GRU'ya beslenir. Önerilen model, CNN'lerin temsili özneteliklerinin çıkarma potansiyelleri ve çok katmanlı GRU'nun etkin kapılı yapısı nedeniyle, hesaplama karmaşıklığı ve tahmin doğruluğu açısından önceki hibrit modellere etkili bir alternatiftir. Mevcut enerji tahmini veri kümeleri üzerindeki deneysel değerlendirme, kesinlik ve verimlilik açısından önerilen yöntem daha iyi performansını ortaya koymaktadır.

Liu ve ark., (2019), yaptıkları bir çalışmada, Tekil Spektrum Analizi (SSA) yöntemi, Evrişimsel Sinir Ağı (CNN) yöntemi, Kapılı Tekrarlayan Birim (GRU) yöntemi ve Destek Vektör Regresyon (SVR) temelli yeni bir hibrit kısa vadeli rüzgar hızı tahmin modeli önerilmiştir. Önerilen yöntem SSA–CNNGRU–SVR modelinde, SSA, orijinal rüzgar hızı serisini birkaç bileşene ayrıştırmak için kullanılır: bir trend bileşeni ve birkaç detay bileşeni; CNNGRU trend

bileşenini tahmin etmek için kullanılırken, SVR detay bileşenlerini tahmin etmek için kullanılır. Önerilen modelin tahmin performansını araştırmak için, ARIMA modeli, PM modeli, GRU modeli, LSTM dahil olmak üzere birçok model kıyaslama modeli olarak kullanılmıştır. CNN-GRU modeli, hibrit SSA-SVR modeli ve hibrit SSA-CNN-GRU modeli, deneysel sonuçlar önerilen modelde, CNN-GRU'nun ana trend bileşeni tahmininde iyi tahmin performansına sahip olabileceğini, SVR'nin ayrıntılı bileşen tahmininde iyi tahmin performansına sahip olabileceğini ve önerilen modelin rüzgar hızı tahmininde iyi sonuçlar elde edebileceğini göstermektedir.

Altan ve ark., (2021), yaptıkları bir çalışmada, tek modellerin sınırlamalarının üstesinden gelmek ve rüzgar hızı tahmin performansını artırmak için hibrit modeller önermişlerdir. Önerilen model, uzun kısa vadeli bellek (LSTM) ağı ve gri kurt iyileştirici (GWO) ile ayrıştırma yöntemlerine dayanan yeni bir hibrit rüzgar hızı tahminleme modeli geliştirilmiştir. Ön işleme aşamasında, eksik veriler ağırlıklı hareketli ortalama yöntemi ile doldurulur, rüzgar hızı zaman serisi verileri ağırlıklı hareketli ortalama filtrelemesi ile düzeltilir ve düzeltilen veriler, puan sonrası normalleştirme olarak model girişi olarak kullanılır. Tahmin modeli, bir ayrışma yöntemi ve gelişmiş bir optimizasyon algoritmasının birleşiminden oluşur. Ardışık olarak, karma rüzgar hızı tahmin modeli, LSTM ve ayrıştırma yöntemlerini birleştirerek ve içsel mod işlevi (IMF) tahmini çıktılarını gri kurt iyileştiricisi (GWO) ile optimize ederek geliştirilmiştir. Geliştirilen doğrusal olmayan hibrit model, Türkiye'nin Marmara Bölgesi'ndeki beş rüzgar santralinden toplanan veriler üzerinde kullanılmıştır. Elde edilen deneysel sonuçlar, önerilen hibrit modelin, rüzgar hızı zaman serilerinin doğrusal olmayan özelliklerini yakalayabildiğini ve doğruluk açısından tek tahmin modellerinden daha iyi tahmin performansı elde edebileceğini göstermiştir.

Zeroual ve ark., (2020), yaptıkları bir çalışmada, yeni koronavirüs (COVID-19) yeni vakaların ve iyileşen vakaların sayısını tahmin etmek için beş derin öğrenme yönteminin karşılaştırmalı bir çalışmasını sunmaktadır. Basit Tekrarlayan Sinir Ağı (RNN), Uzun Kısa Vadeli Bellek (LSTM), Çift Yönlü LSTM (BiLSTM), Kapılı Tekrarlayan Birimler (GRU'lar) ve Varyasyonlu Otomatik Kodlayıcı (VAE) algoritmaları, COVID-19 vakalarının küresel olarak tahmin edilmesi için uygulanmıştır. Çalışmada, İtalya, İspanya, Fransa, Çin, ABD ve Avustralya olmak üzere altı ülkeden toplanan günlük doğrulanmış ve iyileşen vakalara dayanmaktadır. Sonuçlar,

derin öğrenme modelinin COVID-19 vakalarını tahmin etmedeki umut verici potansiyelini göstermektedir. Bu çalışma, İtalya, İspanya, Fransa, Çin, ABD ve Avustralya olmak üzere altı ülkeden toplanan günlük doğrulanmış ve iyileşen vakalara dayanmaktadır. Derin öğrenme modelinin COVID-19 vakalarını tahmin etmedeki başarı potansiyelini göstermekte ve diğer algoritmalarla kıyasla VAE'nin üstün performans sergileyebildiğini vurgulamaktadır.

Emeksiz ve Tan (2022), yaptıkları bir çalışmada, Topluluk Ampirik Mod Ayırışma Uyarlamalı Gürültü (CEEMDAN), Yerel Ortalama Ayırışma (LMD), Hurst ve Geri yayılım Sinir Ağından (BPNN) oluşan hibrit bir model önermektedir. İlk olarak rüzgar hızı zaman serileri CEEMDAN tekniği ile alt bileşenlerine ayrıştırılır. CEEMDAN yoluyla ayırışma sonucu elde edilen en yüksek frekansa sahip imf'lerin en az düzensiz ve sistematik olmayışı LMD tekniği kullanılarak ikincil ayırışmaya tabidir. Elde edilen bileşenler mikro, meso ve makro ölçek serilerine dönüştürülmek üzere Hurst analizine tabi tutulur. Bu seriler daha sonra geri besleme yapay sinir ağlarına uygulanır. Analiz sonuçları, önerilen modelin tahmin doğruluğu açısından karşılaştırılan geleneksel tahmin yöntemlerinden (EEMD-VDM BPNN ve EEMD-EWT-BPNN) daha iyi bir performansa sahip olduğunu göstermektedir. Önerilen hibrit model üzerinden elde edilen MAPE değerlerinin geleneksel modeller kullanılarak elde edilenlere göre %41.16 ve %78.80 oranında azaldığı gözlenmiştir.

Neshat ve ark., (2021), yaptıkları bir çalışmada, rüzgar hızı tahmininin doğruluğunu arttırmak amacıyla yeni bir hibrit derin öğrenmeye dayalı evrimsel yaklaşım benimsenmiştir. Bu hibrit model, çift yönlü uzun kısa vadeli bellek sinir ağı, etkili bir hiyerarşik evrimsel ayırıştırma tekniği ve hiper parametre ayarı için geliştirilmiş, genelleştirilmiş normal dağılım optimizasyon algoritmasından oluşur. Önerilen hibrit yaklaşım, Baltık Denizi'nde bulunan bir İsveç rüzgar çiftliğine kurulan açık deniz rüzgar türbininden toplanan veriler üzerinde iki tahmin ufkuyula eğitildi ve test edildi. Deneysel sonuçlar, yeni yaklaşımın diğer altı uygulamalı makine öğrenme modelinden ve yedi performans kriteri ile ölçülen yedi hibrit modelden daha üstün olduğunu göstermiştir.

Jiang ve ark., (2021), yaptıkları bir çalışmada, rüzgar hızlarını tahmin etmek için çok sayıda tahmin yaklaşımı kullanılmıştır. Bu çalışmada, optimal alt model seçimi, değiştirilmiş çok amaçlı optimizasyon algoritmasına dayalı nokta tahmini, dağılım uydurmaya dayalı aralık

tahmini ve tahmin sistemi deęerlendirmesi olmak üzere drt blmden oluřan birleřik bir tahmin sistemi nerilmiřtir. Geliřtirilen birleřik sistem, alt modellerin zelliklerini btnleřtirir ve doęru nokta ve aralık tahmin performansı saęlar. Deneysel sonular, nerilen kombine tahmin sisteminin etkili rzgar hızı noktası ve aralıęı tahminleri saęlayabileceęini ortaya koymaktadır. Nokta tahmin iin nerilen sistemin mutlak yzde hata deęerleri, bir, iki ve  ařamalı tahminler iin site 1'de %2,9220, %3,1696 ve %4,8358 ve site 2'de %2,2719, %2,5882 ve %3,4799'dur. nerilen sistem, elektrik g sistemlerinin programlanması ve ynetimi iin dięer kıyaslama modellerine gre daha kullanıřlı grlmektedir.

Wang ve ark., (2021), derin ęrenme yntemleri ile ilgili yapmıř oldukları bir alıřmada, rzgar hızı ve rzgar gcnn (WS/WP) doęru tahmin edilmesi, sistem sevk planlamasında rzgar gc dalgalanmalarının azaltılmasında nemli bir rol stlenmiřtir. Yapay zeka teknolojilerinin, zellikle derin ęrenmenin geliřmesiyle, karmařık doęrusal olmayan problemlerle bařa ıkmadaki stn yetenekleri nedeniyle, WS/WP tahmini iin artan sayıda derin ęrenme tabanlı modeller dřnlmektedir. Yapılan alıřmada, veri iřleme, zellik ıkarma ve iliřki ęrenme ařamaları dahil olmak üzere WS/WP tahmininde kullanılan eřitli derin ęrenme teknolojilerini kapsamlı bir řekilde gzden geirmektedir. Bazı popler modellerin tahmin performansı, iki gerek dnya rzgar veri seti kullanılarak test edilmiř ve karřılařtırılmıřtır. Bu gzden geirmede, karmařık kořullar altında doęru WS/WP tahminine ynelik  zorluk tanımlanmıřtır: bunlar, veri belirsizlikleri, eksik zellikler ve karmařık doęrusal olmayan iliřkiler. Ayrıca, gelecekteki arařtırma ynergeleri, WS/WP tahminlerinin doęruluęunu artırmak iin bir kılavuz olarak zetlenmiřtir.

Wu ve ark., (2020), yaptıkları bir alıřmada, kısa vadeli yk tahmini (STLF), g sisteminin alıřmasının ekonomisini ve istikrarını iyileřtirmede ok nemli bir rol oynamaktadır. STLF'nin daha iyi doęruluęu iin, kapılı tekrarlayan birim (GRU) ve evriřimsel sinir aęlarını (CNN) birleřtiren bir GRU-CNN hibrit sinir aęı modeli nerilmiřtir. Zaman dizisi verilerinin zellik vektr GRU modl tarafından, dięer yksek boyutlu verilerin zellik vektr ise CNN modl tarafından ıkarılır. nerilen model gerek dnya deneyinde test edildi ve GRU-CNN modelinin ortalama mutlak yzde hatası (MAPE) ve kk ortalama kare hatası (RMSE) BPNN, GRU ve CNN tahmin yntemleri arasında en dřk seviyededir. nerilen GRU-CNN

modeli verileri daha eksiksiz kullanabilir ve daha doğru kısa vadeli yük tahmini elde edebilmektedir.



3) YENİLENEBİLİR ENERJİ KAYNAKLARI

Fosil temelli kaynakların günümüzde ve gelecekte devam ettirilebilir bir gelişim sağlaması olası görünmemektedir. Fosil kaynaklı üretim ilk olarak dış kaynaklara bağımlıdır, ikinci olarak ise hem ekonomik hem de çevre açısından sürdürülemez bir yapıdadır (Ayan ve Pabuçcu, 2013). Yenilenebilir enerji kaynakları, önümüzdeki dönemde tükenmeden kalabilecek, kendi kendini yenileyebilen kaynaklar olarak tanımlanmaktadır (Koç ve Şenel, 2013). Yenilenebilir enerji kaynakları günümüzde rüzgar, güneş, biyokütle, hidrolik, dalga (gel-git), hidrojen ve jeotermal enerji olarak sınıflandırılmaktadır (Koç ve Kaya, 2015). Bu enerji kaynakları ülkelerin kalkınmalarını ve enerji ihtiyaçlarını karşılamak adına önemli potansiyele sahiptir. Fosil temelli yakıtlara göre sera gazı salınımının asgari düzeylerde olduğu ve çevreye zararının minimum seviyelerde olması son dönemlerde yenilenebilir enerji kaynaklarına olan ilginin ve talebin artmasına neden olmuştur. Çizelge 3.1’ de verilen enerji çeşitleri ve bu enerji çeşitlerine karşılık gelen enerji kaynakları görülmektedir.


Çizelge 3.1. Yenilenebilir enerji çeşitleri ve kaynakları

Yenilenebilir Enerji Çeşitleri	Enerji Kaynağı
Rüzgar Enerjisi	Rüzgar
Güneş Enerjisi	Güneş
Biyokütle Enerjisi	Biyolojik Atıklar
Hidrolik Enerji	Akarsular
Dalga Enerjisi	Okyanus ve Denizler
Hidrojen Enerjisi	Su ve Hidroksitler
Jeotermal Enerji	Yer Altı Suları

3.1. Rüzgar Enerjisi

Rüzgar enerjisi kaynağının temelini güneşten alan bir enerji türüdür. Güneşten yerküreye ulaşabilen enerjinin yaklaşık olarak %2’si rüzgar enerjisine dönüşmektedir (Ayan ve Pabuçcu, 2013). Yüksek bir basınçtan daha alçak bir basınç merkezine doğru hareketin gerçekleşmesi olayına ise rüzgar denir (Yapar, 2014). Dünya üzerindeki dağlar, okyanuslar ve ovalar gibi coğrafi oluşumlar da rüzgarın meydana gelmesinde etkilidir (Kademli, 2021). Rüzgar enerjisi hız ve yön olmak üzere iki farklı değişken ile tanımlanabilmektedir. Yükseklik arttıkça rüzgar hızı artmaktadır. Ayrıca rüzgarın teorik gücü, hızın küpü ile paralel olarak değişmektedir (Enerji ve Tabii Kaynaklar Bakanlığı, 2022). Rüzgar enerjisinden yararlanılarak, rüzgar türbinleri vasıtasıyla elektrik enerjisi üretilmektedir. Rüzgar enerjisi kullanılarak

gerçekleştirilen elektrik üretiminde karşı karşıya kalınan problemlerin başında yeterince yüksek olmayan kapasite etkenleri, üretim tesislerinde yatırımının bütçe ekonomisi açısından fazla olması ve değişkenlik gösteren enerji üretimi gelmektedir. Bu gibi dezavantajlı durumların yanı sıra ciddi avantajları da vardır. Bu avantajlar; İşletme ve bakım masrafları asgari düzeyde olması, maliyeti günümüz güç santralleriyle rekabet edebilecek düzeyde olması, işletmeye alınması kısa sürede gerçekleşiyor olabilmesi gibi çok fazla avantaj sağlamaktadır. Bunların yanı sıra yenilenebilir ve çevre dostu bir enerji kaynağıdır. Ülkemizde ve Dünyada rüzgar enerjisinden elektrik üretimi için kullanılacak santral sayısı ve bu sektör üzerine yapılan çalışmalar gün geçtikçe artmaktadır. Rüzgar enerjisi çağımızda petrol türevli yakıtların yerini almakta en büyük potansiyele sahip yenilenebilir enerji kaynağıdır. Rüzgar enerjisinin önemi tüm Dünya genelinde de son dönemde artmıştır. Şekil 3.1’de Dünya genelinde rüzgar enerjisi kapasitesi ve bir önceki yıla göre ilave kapasiteler görülmektedir. Grafikte görüldüğü üzere global ölçekte rüzgar enerjisine yapılan yatırımlar yıllar geçtikçe artarak büyümektedir. 2020 yılında rüzgar enerjisi kapasitesine 93 MW’lık ilave ile rekor kırılmıştır (REN21, 2021).



Şekil 3.1. Rüzgar enerjisi küresel kapasitesi ve yıllık ilaveleri 2010-2020 (REN21, 2021)

Rüzgar enerjisi, dört mevsimi yaşayabilen ülkemiz adına çok önemli bir potansiyeli vardır. Ayrıca günümüzde etkili bir biçimde değerlendirilen bir yenilenebilir enerji kaynağıdır. Türkiye deniz üstünde 10 GW ve karasal alanlarda 37.8 GW olarak toplam da 47.8 GW mevcut rüzgar enerjisi potansiyeline sahiptir (Kademli, 2021). Ülkemizin 2021 yılı sonuna gelindiğinde

rüzgar enerjisi alanında yaklaşık 10,6 GW kurulu güç mevcuttur (Türkiye Elektrik İletim A.Ş., 2022). Şekil 3.2’de verilen harita Türkiye’nin 50 metre yükseklikteki ortalama yıllık rüzgar hızlarının dağılımını vermektedir. Harita incelendiğinde Türkiye’nin kıyı kesimlerinde rüzgar enerjisi adına önemli potansiyeli olduğu görülmektedir. Özellikle Ege kıyıları rüzgar enerjisi açısından son derece büyük bir potansiyele sahiptir.



Şekil 3.2. Türkiye rüzgar atlası (MGM, 2022)

Çizelge 3.2’de Türkiye’nin 50 metre yükseklikte rüzgar enerjisi potansiyeli ortalama rüzgar hızı, güç yoğunluğu ve kapasitesi görülmektedir. Çizelge 3.2 incelendiğinde 50m yükseklik için Türkiye’nin yıllık ortalama rüzgar hızı kapasitesinin en yüksek olduğu aralık 7 m/s ile 7.5 m/s aralığıdır. Bu aralıkta yaklaşık 29,3 MW’lık bir kapisteye sahiptir.

Çizelge 3.2. Türkiye'nin 50m'de rüzgar enerjisi potansiyeli (ortalama rüzgar hızı > 7,0 m/s) (Emeksiz ve Fındık, 2021)

Yıllık Ortalama Rüzgar Hızı -50 m (m/s)	Güç Yoğunluğu – 50 m (W/m ²)	Kapasite (MW)
7.0 - 7.5	400 - 500	29.259,36
7.5 - 8.0	500 - 600	12.994,32
8.0 - 9.0	600 - 800	5.399,92
> 9.0	> 800	195,84

3.2. Güneş Enerjisi

Dünya için son derece önemli bir temel yaşam kaynağı olan güneş, yenilenebilir enerji içinde ciddi bir potansiyele sahip bir enerji kaynağıdır. Birincil enerji kaynakları arasında yerini alan güneş enerjisi, güneşin merkezinde gerçekleşen füzyon tepkimesi ve beraberinde ışıma enerjisi ile meydana gelmektedir (Acaroğlu, 2003). Güneş enerjisinden yararlanan birçok canlı türü mevcuttur. Bunların başında bitkiler, fotosentez yaparak güneş enerjisinden yararlanmaktadırlar. İnsanlar ise kentsel planlama, ısıtma, mimari, tarım, yakıt üretimi ve ulaştırma gibi alanlarda sıklıkla güneş enerjisinden faydalanmaktadırlar (Karabağ ve ark., 2021). Son yıllarda ise ülkeler güneş enerjisine daha da önem vermektedirler. Güneş enerjisinin mevcut potansiyelinden yararlanmak adına güneşten gelen fotonların güneş panelleri üzerine düşerek fotovoltaiik yöntem ile elektrik enerjisi üretilmektedir. Kaynağını güneşten alan bu enerji türü; doğa dostu olması ve hammadde açısından hiçbir ülke tarafından sorun teşkil etmeksizin kullanılabilir olması gibi çeşitli avantajlara sahiptir. Elektrik enerjisi üretiminin yanı sıra güneşin ısı enerjisinden de faydalanılarak birçok kullanım sahası ortaya konulduğu bilinmektedir.

Dünya'nın atmosferinin dış katmanında güneş enerjisinin şiddeti, yaklaşık olarak 1370 W/m² seviyesindedir, ancak yerküre üzerine ulaşabilen güneş enerjisi şiddetinin miktarı yaklaşık olarak 0-1100 W/m² değerindedir. Güneş enerjisi şiddetinin bu seviyelere kadar azalmasının nedenleri arasında atmosfer tabakasında güneş fotonlarının absorbe edilerek soğurulmasından kaynaklanmaktadır. Bu enerjinin dünya üzerine ulaşan küçük bir bölümü, yeryüzünde tüketilen mevcut enerjiden çok daha fazladır. Güneş enerjisinden faydalanma adına yapılan çalışmalar 1970'ler sonrası dönemde özellikle hız kazanmıştır. Güneş enerjisi sistemleri düşük maliyetli olup gelişen teknoloji ile büyük avantajlar sağlamaktadır. Kurulumundan sonra düşük maliyet

gerektirmesi ve temiz bir enerji kaynağı olması itibariyle güneş enerjisi son derece önemli bir yenilenebilir enerji kaynağıdır (Enerji ve Tabii Kaynaklar Bakanlığı, 2021).

2021 yılına gelindiğinde güneş enerjisi kurulu güç verilerine bakıldığında ilk sırada son yıllardaki büyük yatırımları ve 254,355 MW'lık kurulu güç kapasitesi ile Çin Halk Cumhuriyeti gelmektedir. İkinci sırada 75,572 MW'lık kurulu güç kapasitesine sahip olan Amerika Birleşik Devletleri yer almaktadır. Asya kıtasının önemli ekonomilerinden birisi olan Japonya 67,0 MW'lık kapasitesi ile sıralamada üçüncü sırada yer almaktadır. Türkiye ilk 10'da kendisine yer bulamamış olsa da 6,668 MW'lık kurulu güç kapasitesine sahiptir. Önümüzdeki yıllarda yapılacak yatırımlar ile bu listede kendisine yer bulacaktır. Güneş enerjisi kurulu güç ilk on ülke Çizelge 3.3'de detaylı olarak verilmiştir.

Çizelge 3.3. Güneş enerjisi kurulu güç(MW) ilk 10 ülke


Sıra	Ülkeler	Kurulu Güç(MW)
1	Çin	254,355
2	ABD	75,572
3	Japonya	67,000
4	Almanya	53,783
5	Hindistan	39,211
6	İtalya	21,600
7	Avusturalya	17,627
8	Vientam	16,504
9	Güney Kore	14,575
10	İspanya	14,089

Türkiye, Kuzey Yarım Kürede bulunduğu konum itibariyle güneş enerjisi açısından büyük bir potansiyele sahiptir. Ülkemizin yıllık güneşlenme haritası Şekil 3.3'te görüldüğü gibidir. Şekil 3.3 incelendiğinde Ülkemizin güney bölgeleri, kuzey bölgelerine göre güneş ışığından daha fazla yararlanmaktadır. Özellikle Akdeniz bölgesi ve Güneydoğu Anadolu bölgesi yıllık güneşlenme süresi bakımından ülkemizdeki diğer bölgelere göre daha avantajlı konumdadır.



Şekil 3.3. Türkiye ortalama güneşlenme haritası (MGM, 2022)

1991-2020 yılları arasında ortalama aylık güneşlenme süresi Türkiye ölçeğinde incelendiğinde Şekil 3.4’de görüldüğü gibidir. Şekil 3.4 incelenecek olursa güneşlenme süresi Türkiye ortalamasında Mayıs ve Eylül arasındaki beş aylık dönemde maksimum seviyelerde diğer aylarda ise bu aylara oranla daha az güneş ışınlarından daha az faydalanabilmektedir.



Şekil 3.4. Türkiye aylık ortalama güneşlenme süresi (MGM, 2022)

Güneş enerjisi diğer ülkelerde olduğu gibi Türkiye için önemli bir potansiyele sahiptir. Hammaddesini doğadan karşılıyor olması ve doğa dostu olması sebebiyle ülkemiz açısından hammadde eksikliği hissedilen petrol ve doğal gaz gibi enerji kaynaklarına en büyük alternatif

bir yenilenebilir enerji kaynağıdır. Ayrıca çağımızın sorunu olan petrol türevli kaynakların sera gazı salınımına karşı etkili ve kalıcı bir çözüm sunmaktadır. Türkiye’de diğer alternatif enerji kaynaklarına yönelen ülkeler gibi güneş enerjisi alanına yatırımlarını artırmaktadır ve bu alana yönelik çeşitli Ar-Ge çalışmaları yürütmektedir.

3.3. Hidrolik Enerji

Evrenimizin dörtte üçü sular ile çevrilidir. Yaşam kaynağı olarak başlıca ihtiyaçlarda kullanılan hammadde sudur. Biyolojik ihtiyaç ve yaşamın sürdürülmesinin yanı sıra elektrik enerjisinin üretiminde de etkili bir biçimde kullanılan bir yenilenebilir enerji hammaddesidir (Demir, 2019). Hidroelektrik enerji, elektrik üretmek için hareket halindeki su kütlesinin doğal akışını kullanan en büyük ve en eski yenilenebilir enerji kaynaklarından biridir.

Yenilenebilir enerji kaynaklarından hidrolik enerji, elektrik üretiminde yaygın olarak kullanılmaktadır. Hidrolik enerjinin genel kullanımı, ırmak, nehir ve genel olarak akarsular üzerine inşa edilen barajlar vasıtasıyla su kütlesini biriktirebilmek, biriken su kütlesinin potansiyelinden mekanik enerji elde edilmektedir. Mekanik enerji ile jeneratörleri döndürmek için jeneratörün türbinleri tahrik edilir ve elektrik enerjisi elde etmek adına üretim gerçekleşmiş olur. Bu gerçekleşen durum kurulan hidroelektrik santraller vasıtasıyla gerçekleştirilmektedir (Koç ve Kaya, 2015).

Çizelge 3.4 incelenecek olursa Dünya ölçeğinde 2020 yılı için en yüksek seviyede kurulu güç kapasitesine sahip olan ülke 356,6 MW ile Çin Halk Cumhuriyeti’dir. Beraberinde Brezilya ve Amerika Birleşik Devletleri gelmektedir. Türkiye ise bu sıralamada kendisine 9. Sırada yer bulmuştur (Anonim 1, 2022).

Çizelge 3.4. Hidroelektrik kurulu güç (MW) ilk 20 ülke

Sıra	Ülkeler	Kurulu Güç(MW)
1	Çin	356,4
2	Brezilya	109,1
3	ABD	102,8
4	Kanada	81,4
5	Hindistan	50,1
6	Japonya	49,9
7	Rusya	49,9
8	Norveç	32,7
9	Türkiye	28,5
10	Fransa	25,6

Hidrolik enerji Dünya'nın genelinde olduğu gibi Türkiye içinde önem arz etmektedir. Hidrolik enerji bakımından Türkiye'nin potansiyeli yaklaşık olarak 160 TWh/yıl olarak tahmin edilmektedir (Koç ve ark., 2018). Ülkemizde mevcut hidroelektrik santral sayısı 2018 yılsonu itibariyle 653 adettir (Enerji ve Tabii Kaynaklar Bakanlığı, 2022). Gelecek yıllarda devreye alınması planlanan yeni hidroelektrik santraller ile mevcut listede kurulu güç kapasitesini artırması ve sıralamada daha üst seviyelerde yer alması mümkündür.

3.4. Jeotermal Enerji


Jeotermal enerji, bazı ülkelerde yemek pişirmek ve ısı enerjisinden faydalanmak adına binlerce yıldır kullanılmıştır ve hali hazırda kullanılmaktadır. Yerkabuğunun farklı derinliklerinde yer altında bulunan ısı altında sıvı duruma geçmiş(magma), maddeden kaynaklı sıcaklığın meydana getirdiği, sıcaklıkları genel olarak bölgesel ortalama ısının çok daha üzerinde olan ve ayrıca etrafındaki yerüstü ve yeraltı sularına nazaran daha fazla çeşitli tuz, erimiş mineral ve gaz içeren buhar ve sıcak su olarak tanımlanmaktadır (Kademli, 2021). Jeotermal enerji, yeraltı buhar ve sıcak su rezervuarları, elektrik üretmek veya binaları doğrudan ısıtmak ve soğutmak için kullanılabilir. Özetle, Dünya'nın iç ısısından elde edilen güç olarak ifade edilebilir.

Dünya genelinde 2020'de toplam 202 MW'lık kurulu güç eklenmiştir. Bugüne kadarki en büyük büyüme, 168 MW ilave kapasiteye sahip olan Türkiye'de gerçekleşmiştir. Gelecek yıllarda keşif ve sondaj işlemlerinin yanı sıra tesis inşaatı konusunda faaliyetlerin artması beklenmektedir (Richter, 2021). Çizelge 3.5 incelenecek olursa Amerika Birleşik Devletleri 3,714 MW kurulu güç ile listenin ilk sırasında yer almaktadır. Türkiye bu listede 1,526 MW ile dördüncü sırada yer almaktadır.

Çizelge 3.5. Jeotermal enerji kurulu güç ilk 20 ülke

Sıra	Ülkeler	Kurulu Güç(MW)
1	ABD	3,714
2	Endonezya	2,133
3	Filipinler	1,918
4	Türkiye	1,526
5	Yeni Zelanda	1,005
6	Meksika	963
7	İtalya	944
8	Kenya	861
9	İzlanda	755
10	Japonya	603

Şekil 3.5’de Türkiye’nin jeotermal kaynaklar ve uygulama haritası görüldüğü gibidir. Harita incelendiğinde Ege bölgesi, İç Anadolu’nun belirli kesimleri (Ankara ve Çankırı çevresi), Erzurum ve çevresi, Van ve Ağrı’nın belirli bölgelerinde jeotermal kaynaklar açısından yoğunluklar gözlemlenmektedir. Ülkemiz son yıllardaki yatırımları ile kurulu güç kapasitesini önemli ölçüde artırmıştır ve artırmaya yönelik devam eden politikaları mevcuttur.




Şekil 3.5. Türkiye’nin jeotermal kaynaklar ve uygulama haritası (MTA,2022)

3.5. Biyokütle Enerjisi

İçerdiği karbonhidrat bileşikleriyle hayvansal ve bitkisel temelli maddelerden elde edilebilen enerji kaynağına Biyokütle enerji denir. 100 yıldan kısa bir sürede kendisini yenileyebilmektedir. Karada ve suda yetişen bitkiler, orman ürünleri (yaprak, talaş vb.), doğada cansız hayvan artıkları, çeşitli kentsel atıklar ve besin endüstrisi atıklarını da barındıran organik maddelerin tamamıdır (Kumbur ve ark., 2005). Biyokütle enerji kaynakları günümüzde kullanılarak biyogaz, biyodizel ve biyoetanol, gibi yakıtlar ortaya çıkmaktadır. Biyogaz, organik maddelerin (hayvansal ve bitkisel artıklar, endüstriyel ve kentsel atıklar) oksijenin net sıfır olduğu şartlar altında fermentasyon neticesinde meydana gelen ve büyük bir çoğunluğu karbondioksit ve metandan oluşan bir gazdır (Koç ve Kaya, 2015). Biyodizel ve biyoetanol hayvansal yağlar veya çeşitli bitkiler kullanılarak üretilen farklı biyokütle yakıt çeşitleridir.

Biyokütle enerji kaynakları, ulaşım ve taşımacılıkta kullanılabilir bir alternatif kaynak olmanın yanı sıra elektrik üretimi, konut ve daire ısıtmalarında kullanılıyor olabildiği gibi çok çeşitli alanda ülke ekonomisinin gelişmesine ve büyümesine önemli ölçüde katkı vermektedir. Çoğu ülke biyokütle enerji kaynaklarından farklı şekillerde faydalanmaktadır. Şekil 3.6’da görüldüğü üzere Türkiye’nin biyokütle potansiyel atlası verilmektedir. Harita incelendiğinde Türkiye’nin hemen hemen her bölgesinin biyokütle enerjisi potansiyeli oldukça yüksek olduğu görülmektedir. Enerji ve Tabii Kaynaklar Bakanlığı tarafından biyokütle enerji potansiyelin belirlenmesi amacıyla hazırlanan Biyokütle Enerjisi Potansiyel Atlası verilerine bakıldığında atıkların genel ekonomik enerji eşdeğeri ton eşdeğer petrol (TEP) cinsinden yaklaşık olarak 3,9 MTEP/yıl olarak hesaplanmaktadır (Enerji ve Tabii Kaynaklar Bakanlığı, 2022).



Şekil 3.6. Türkiye’nin biyokütle potansiyel haritası

3.6. Dalga ve Gelgit Enerjisi

Dalga enerjisinin temeli rüzgar enerjisine dayanmaktadır. Dalga enerjisi, rüzgarın okyanus ve denizlerin üst tabakalarında hareketi neticesinde meydana gelen dalgalanma hareketi ile oluşan bir enerji çeşididir. Rüzgar etkisiyle meydana gelen dalgalar, deniz ve okyanus yüzlerinde herhangi bir düzen olmaksızın yukarı ve aşağı hareket etmesini sağlar. Bu doğrultuda dalganın oluşturduğu hareket vasıtasıyla elektrik enerjisi üretilebilmektedir (Anonim 2, 2022). Kaynağını doğadan alıyor olması itibarıyla deniz ve okyanusa kıyısı olan birçok ülke için büyük bir potansiyel taşımaktadır.

Gelgit enerjisi, Güneş, Dünya ve Ay arasındaki yerçekimsel etkileşimin neden olduğu gelgitlerin doğal yükselişi ve düşüşü tarafından üretilen bir güç şeklidir. Su bir daralmadan geçtiğinde meydana gelir ve suyun daha hızlı hareket etmesine neden olur ve yeterli enerjiye sahip gelgit akımları meydana gelir. Fiziki şartları uygun yerlerde özel olarak tasarlanmış jeneratörler kullanılarak, gelgit enerjisinden başta elektrik olmak üzere daha farklı ve faydalı güç formlarına dönüştürülebilir. Bunlara örnek olarak; sürekli okyanus akıntıları ve deniz suyundaki sıcaklık ve tuzluluktaki farklılıklar da dahil olmak üzere okyanustan başka enerji biçimleri de üretilir (Anonim 3, 2022).

Dünya üzerinde okyanusa ve denizlere kıyısı olan ülkeler açısından dalga ve gelgit enerjisi önem arz etmektedir. Kaynağını doğrudan doğadan alıyor olması önemli bir avantajdır. Türkiye de üç tarafı denizle ile çevrili olması nedeniyle dalga enerji potansiyeli olan ülkeler arasındadır.



4) DÜNYA ve TÜRKİYE'DEKİ RÜZGAR ENERJİSİNİN POTANSİYELİ

Karasal rüzgar türbin kurulu güçleri açısından ülkelerin kıyaslanması Çizelge 4.1'de sunulmaktadır. Çin Halk Cumhuriyeti 278,324 MW'lık kurulu güç kapasitesi ile listenin ilk sırasında yer almaktadır. İkinci sırada ise 122,275 MW'lık kurulu güç kapasitesi ile dünyanın en büyük ekonomilerinden olan Amerika Birleşik Devletleri gelmektedir. Üçüncü sırada ise Avrupa kıtasında yenilenebilir enerji kaynaklarına önem veren ve ciddi yatırımlar yapan Almanya 55,122 MW'lık kurulu güç kapasitesi ile yer almaktadır. Türkiye bu listede 9,280 MW'lık kurulu güç kapasitesi ile onuncu sırada kendisine yer bulmuştur (GWEC, 2021). Ülkemizde son dönemde artan yatırımlar ile sıralamadaki yerini daha üst basamaklara taşıyacağı öngörülmektedir.

Çizelge 4.1. Dünya geneli rüzgar türbini kurulu güç (Kara)


Sıra	Ülkeler	Kurulu Güç(MW)
1	Çin	278,324
2	ABD	122,275
3	Almanya	55,122
4	Hindistan	38,625
5	Fransa	17,946
6	Brezilya	17,750
7	Birleşik Krallık	13,731
8	Kanada	13,577
9	İsveç	9,811
10	Türkiye	9,280

Deniz ve Okyanus yüzeylerinde kurulan rüzgar türbinleri için kurulu güçlerin kıyaslanması Çizelge 4.2'de sunulmaktadır. Listenin ilk sırasında bir ada ülkesi topluluğu olan ve İngiltere-İskoçya-Galler-Kuzey İrlanda dörtlüsünden oluşan Birleşik Krallık 10,06 MW'lık kurulu güç ile yer almaktadır. Çin Halk Cumhuriyeti onshore (kara) türbinlerde olduğu gibi deniz ve okyanus üzerinde rüzgar enerjisinden son derece önemli seviyede faydalanmaktadır ve bu sıralamada 9,996 MW 'lık kurulu güç kapasitesi ile sıralamada ikinci basamakta yer almaktadır. Diğer Avrupa ülkelerine nazaran yenilenebilir enerji kaynaklarının potansiyeline oldukça fazla yatırım yapan ve önem veren ülke olan Almanya, deniz üstü rüzgar türbinlerinde de oldukça önemli bir kurulu güç kapasitesine sahiptir. Almanya, bu listede 7,728 MW'lık kapasitesi ile sıralamada üçüncü basamakta yer almaktadır (GWEC, 2021).

Çizelge 4.2. Dünya geneli rüzgar türbini kurulu güç (Deniz-Okyanus)

Sıra	Ülkeler	Kurulu Güç(MW)
1	Birleşik Krallık	10,206
2	Çin	9,996
3	Almanya	7,728
4	Hollanda	2,611
5	Belçika	2,262
6	Danimarka	1,703
7	Diğer Avrupa Ülkeleri	327
8	Diğer Asya Ülkeleri	282
9	Güney Kore	136
10	ABD	42


Rüzgar enerjisi, geçtiğimiz yıllarda çok sayıda ülkede elektrik üretiminin önemli seviyedeki bir bölümünü temin etmektedir. 2020 yılında Avrupa Birliği (AB) üyesi 27 ülkedeki yıllık elektrik üretiminin tahmini %15'ini ve en az beş üye ülkede çok daha yüksek payları karşılamaya yetecek seviyede rüzgar enerjisi üretmiştir. Rüzgar enerjisi, 2020 yılında Danimarka'nın elektrik talebinin yaklaşık olarak %48'ini karşılamıştır. Ayrıca rüzgar enerjisi Danimarka'nın toplam üretiminin yaklaşık olarak %58,6 'lık kısmını oluşturmuştur. 2020 yılı için rüzgar üretiminde kapasitesi %20'nin üzerinde olan diğer Avrupa ülkeleri arasında İrlanda %38, Birleşik Krallık %24,2, Portekiz %24, Almanya %23,2 ve İspanya %21,9'luk oranlar ile rüzgar enerjisinde önemli derecede paya sahip ülkelerdir. Bu ülkelerin yanı sıra Amerika kıtasında yer alan Uruguay %40,4 ve Nikaragua %27,6'lık oranlarda rüzgar enerjisinden büyük bir üretim payı elde eden ülkelerdir. Küresel ölçekte mevcut işletmedeki rüzgar enerjisi kapasite, 2020 yılında toplam elektrik üretiminin yaklaşık olarak %6'sından fazlasını oluşturmuştur (REN21, 2021). Şekil 4.1'de Rüzgar enerjisi kapasitesi ve 2020 yılı ilaveleri ile ilk 10 ülke verilmektedir.



Şekil 4.1. Rüzgar enerjisi kapasitesi ve 2020 yılı ilaveleri ile ilk 10 ülke (REN21,2021)

Türkiye bulunduğu coğrafi konum itibarıyla Asya'dan ve Ortadoğu'dan Avrupa'ya enerji nakliyesi sağlamak adına son derece kritik bir bölgede yer almaktadır. Başta petrol ve doğalgaz gibi fosil türevli kaynakların ülkemiz üzerinden nakliyesi karadan ve denizden olmak üzere çeşitli yollar ile gerçekleşmektedir. Giderek gelişen ve büyüyen şehir hayatının yanı sıra ilerleyen teknoloji ve sanayileşme enerji talebinde ciddi artışlara neden olmaktadır. Bulunduğu konum itibarıyla Türkiye yenilenebilir enerji kaynaklarından faydalanma konusunda önemli bir potansiyele sahiptir. Mevcut yenilenebilir enerji potansiyelini kullanarak enerji ihtiyacını karşılayarak enerji ihtiyacı konusunda dışa bağımlılığını azaltmasının yanı sıra ürettiği fazla enerjiyi diğer ülkelere ihraç ederek önemli bir gelir kaynağı elde etmiş olacaktır.

Türkiye geneli elektrik enerjisinin üretildiği santrallere bakıldığında 2022 Ocak ayı itibarıyla 10.549 santral ve 99,734 MW'lık kurulu güce sahiptir. Santral türlerine göre bakıldığında rüzgar enerjisi 355 adet santral ve 10,682.8 MW'lık kurulu güç kapasitesine sahiptir (TEİAŞ, 2022). Türkiye üzerinde bölgesel olarak rüzgar enerjisi potansiyel atlası 100 metre için Şekil 4.2'de görüldüğü gibidir. Ege kıyıları ve deniz açıkları rüzgar enerjisinden faydalanmak adına önemli potansiyele sahiptir.




Şekil 4.2. Türkiye rüzgar enerjisi potansiyel atlası (100m)

Türkiye'nin rüzgar enerjisinin bölgesel olarak kurulu güç verileri Çizelge 4.3'de verilmektedir. Tablo incelenecek olursa Marmara bölgesi 4,243 MW kapasite ile ilk sırada yer almaktadır. Marmara bölgesini 3,701 MW'lık kurulu güç kapasitesi ile Ege bölgesi takip etmektedir. Diğer bölgeler ise sırasıyla Akdeniz, İç Anadolu, Karadeniz ve Güneydoğu Anadolu olarak sıralanmaktadır.

Çizelge 4.3. Bölgelere göre kurulu güç

Sıra	Bölge	Kurulu Güç(MW)
1	Marmara	4243
2	Ege	3701
3	Akdeniz	1143
4	İç Anadolu	967
5	Karadeniz	370
6	Güneydoğu Anadolu	93

Türkiye'nin 2010 yılından bu yana rüzgar enerjisi kurulu güç grafiği Şekil 4.3'de görüldüğü gibidir. İlk olarak 2010 yılında 1,320 MW olan kurulu güç kapasitesi mevcuttur. Kurulu güç kapasitesi 2020 yılının sonu için 8,832 MW olarak hesaplanmıştır ve bu süreçte ortalama elektrik üretimi 24,828 GWh olarak gerçekleşmiştir. 2021 yılına gelindiğinde rüzgar enerjisinin kurulu gücü 10,100 MW olarak gerçekleşmiştir ve üretilen elektrik miktarı 29,137 GWh olarak tahmin edilmektedir. 2022 yılında rüzgar enerjisi kurulu güç kapasitesinde 800 MW'lık artış ile toplam kapasiteyi 10,900 MW seviyelerine çıkarmak için hedefler belirlenmiştir (ELDER, 2022).



Şekil 4.3. Türkiye'nin yıllara göre rüzgar santrali kurulu güç

Eldeki imkanlar ve veriler değerlendirildiğinde rüzgar enerjisi yatırımları önümüzdeki yıllarda Ülkemizde önemli yatırımlar olarak hem kapasite artışının sağlanması hem de elektrik üretiminin daha yüksek seviyelere çıkması beklenmektedir. Rüzgar enerjisinden faydalanmak Ülkemiz için başta ekonomik ve çevresel açıdan çok büyük kazanımlar elde etmesini sağlayacaktır.

5) RÜZGAR HIZI TAHMİNLEMESİ

Elektrik enerjisi üretiminde kullanılan rüzgar enerjisinin, elektrik üretimini gerçekleştirilebilmesi için belirli bir rüzgar hızı potansiyeline sahip olması gerekmektedir ve elektrik enerjisi üretimini sağlayacak olan potansiyel rüzgar hızını belirlemek son derece önemlidir. Rüzgar enerjisi çevrim sistemlerinin en önemli girdisi olan rüzgarın kaotik davranış sergilemesi ve kesintili olması hem güç sistemin güvenilirliğini azaltmakta hem de üretim maliyetini artırmaktadır (He ve ark., 2019; Yang ve ark., 2018). Ayrıca rüzgarda meydana gelen bu dalgalanmalar şebekedeki giriş çıkış gücünün dengelenmesini zorlaştırmaktadır. Dolayısıyla, rüzgar enerjisi üretim sistemleri için güvenilir ve doğru bir rüzgar hızı tahmini hayati önem taşımaktadır. Böylece hem güç sistemleri için istikrar sağlanmış olur hem de rüzgar enerjisi endüstrisine yapılacak olan yatırımlar için duyulan kaygılar giderilmiş olur (Yang ve ark., 2017; Zafar ve ark., 2020). Ayrıca bu alanda yapılan çalışmalarda, rüzgar enerjisi tahminlerinin geliştirilmesi ile önemli ekonomik ve teknik avantajların sağlanabileceği bildirilmektedir (Quian ve ark., 2019; Liu ve ark., 2018). Bu sebeple son yıllarda birçok bilim insanı rüzgar hızı tahminlemesi alanında çeşitli tahmin modelleri geliştirmişlerdir ve bu alanda derinlemesine çalışmalar yapmışlardır. Özellikle rüzgar hızı tahminlemesi için geliştirilen bu modeller temel olarak 4 ana başlıkta değerlendirilmektedir. Bu başlıklar sırasıyla; fiziksel modeller, istatistiksel modeller, yapay zeka modelleri ve hibrit modellerdir (Aggarwal ve Gupta, 2013).

Fiziksel modeller sıcaklık, rüzgar hızı, rüzgar yönü vb. hava durumu verilerini kullanarak tahminlemelerin gerçekleştirildiği sayısal hava tahmin modelleridir (NWP) (Allen ve ark., 2017). Tahminleme sürecinde sınır koşulları ve fiziksel yasalar kullanılarak meteorolojik süreçler simülasyonu gerçekleştirilir. Özellikle uzun dönem rüzgar hızı tahminlemesinde NWP modellerinin iyi performans sergilediği görülmektedir. Ancak bu modellerin kullanılmasında geniş ve çeşitli tarihsel verilere ihtiyaç duyulur (Giorgi ve ark., 2011; Howard ve Clark, 2007).

Değişken bir parametre olan rüzgar hızı ve potansiyeli, tahminleme işleminin uygulanabilmesi için belirli bir dönem boyunca (bir ay, bir yıl gibi) verilerin doğru bir istatistik ile kaydedilmiş olmasına bağlıdır. Rüzgar hızı tahmini rüzgar santrali kurulumu için değerlendirme yapılabilmesi adına son derece önemlidir. Bir rüzgar çiftliği kurulmadan önce tesisin kurulması planlanan bölge için gerekli ölçüm istasyonları kurulmalı ve veriler toplanmalıdır. Ülkemizde Rüzgar Gücü İzleme ve Tahmin Merkezi (RİTM) çatısı altında, değişkenlik gösteren rüzgar

hızının karakteristik yapısını inceleyip, güç potansiyeli hakkında tahminleme yapacak ve bu sistemi enterkonnekte şebek sistemine dahil edecek bir proje başlatılmıştır. Rüzgar Gücü İzleme ve Tahmin Merkezine bağlantı işlemi tamamlanan rüzgar enerjisine dayalı üretim tesislerinde bulunan rüzgar türbinlerinin rüzgar hızı, ünite gücü, ünite çalışma durumu, rüzgar esme yönü gibi veriler SCADA vasıtası ile 10 dakikalık aralıklarla merkeze aktarılmaktadır. Bu veriler ile orta ölçekli sayısal işlemler yapılarak elektriksel güç tahminleri gerçekleştirilmektedir (RİTM, 2022).

Rüzgar enerjisi tahminleme işlemlerinde metodolojiye veya zaman ölçeklerine göre farklı sınıflandırma yöntemleri literatürde yer almaktadır. Literatürdeki çalışmalar incelendiğinde genel olarak rüzgar enerjisi tahmin yöntemleri zaman ölçeklerine göre dört ayrı başlık altında ayrılmaktadır (Chang, 2014). Bu başlıklar Çizelge 5.1’de görüldüğü gibidir. Sırasıyla çok kısa süreli dönem, kısa süreli dönem, orta süreli dönem ve uzun süreli dönem şeklinde dört ana katagoride ayrılmıştır. Tabloda hangi zaman aralığında ayrıldığı ve hangi dönemin hangi uygulama alanlarında yararlandığı görülmektedir.

Çizelge 5.1. Rüzgar tahmini için zaman ölçeği sınıflandırması

Zaman Ölçeği	Aralık	Uygulama Alanları
Çok Kısa Süreli Dönem	Birkaç dakika ile 1 saat arası	• Elektrik piyasası takası
		• Gerçek zamanlı şebeke işlemleri
		• Düzenleme işlemleri
Kısa Süreli Dönem	Bir saatten daha uzun süreler	• Ekonomik yük dağıtım planlaması
		• Makul kararları almakta
		• Elektrik piyasasında operasyonel güvenlik
Orta Süreli Dönem	Birkaç saatten 1 haftaya kadar olan süreler	• Birim taahhüt kararları
		• Zorunlu karşılık kararları
		• Oluşturucu çevrimiçi/çevrimdışı kararları
Uzun Süreli Dönem	Bir haftadan daha uzun 1 yıllık süreler	• Operasyon Yönetimi
		• Optimum işletme maliyeti
		• Rüzgar çiftliğinin tasarımı için fizibilite çalışması

Fiziksel modellere göre daha fazla tercih edilen istatistiksel modeller zaman-uzay veya geçmiş verileri kullanarak tahminleme işlemi gerçekleştirir. Özellikle basınç, sıcaklık, rüzgar yönü, rüzgar hızı vb. verileri girdi olarak kullanıp çıkış verisi olan rüzgar hızı arasında matematiksel bir ilişkiyi kurar. Böylece bu modeller kısa vadeli rüzgar hızı tahminlemelerinde başarılı sonuçlar ortaya koymaktadır (Ouyang ve ark., 2017). Kalıcılık modeli (PM), otoregresif (AR) model, otoregresif hareketli ortalama (ARMA) modeli ve otoregresif entegre hareketli ortalama

(ARIMA) modelleri istatistiksel model olarak bilinen ve kullanılan en yaygın yöntemlerdir (Wang ve Hu, 2015). Cadenas ve Rivera yapay sinir ağıları (ANN) ve ARIMA metodlarını karşılaştırmışlardır. Çalışmalarında La Venta, Oaxaca, Mexico'daki 7 yıllık rüzgar hızı verilerini kullandılar (Cadenas ve Rivera, 2007). Kavaseri ve Seetharaman kesirli bir f-ARIMA modeli üzerinde çalışma yürüttüler. Bu model ile rüzgar güç üretimini ve rüzgar hızını 24 ve 48 saat öncesinden tahmin etmeyi amaçladılar. Elde ettikleri sonuçları kalıcılık modeli (PM) ile karşılaştırdılar. Önerilen yöntemin daha başarılı olduğunu tespit ettiler (Kavaseri ve Seetharaman, 2009). Diğer bir çalışmada ARMA modellerine dayalı modeller kullanılarak rüzgar hızı tahminlemesi yapılmış ve bu yaklaşımların performansları karşılaştırılmıştır (Erdem ve Shi, 2011). Kamal ve Jafri rüzgar hızı tahminlemesi için ARMA modelini tercih ettiler. Çalışmalarında durağan olmayan rüzgar hızı veri setini kullandılar. Elde edilen sonuçlara göre rüzgar ve varyans tahminlerinin kabul edilir aralıkta olduğunu tespit ettiler (Kamal ve Jafri, 1997). Ding ve arkadaşları rüzgar hızı zaman serisine ön işleme sürecinde ikincil ayrıştırma yöntemi uyguladılar. Ayrıştırılan seri ile tahminleme yapmak için ARIMA modelini genel yapıya adapte ettiler (Ding ve ark., 2021). Torres ve arkadaşları tarafından ARMA ve PM modeli karşılaştırılarak saatlik ortalama rüzgar hızı tahmini yaptılar. Elde edilen sonuçlarda ARMA modelinin performansının daha iyi olduğu gözlenmiştir. Özellikle ARMA modelindeki hata oranlarının daha düşük olduğu vurgulanmıştır (Torres ve ark., 2005).

Günümüzde bilim insanları istatistiksel modellerin doğruluğunu artırmak için birçok çalışma gerçekleştirmektedirler. Bu çalışmalarda istatistiksel ve yapay zeka modellerini birleştirerek farklı yaklaşımlar sunmaktadırlar (Cadenas ve Rivera, 2010). Özellikle ANN birçok alanda yaygın olarak kullanılan ve içerisinde optimizasyon, tahmin, regresyon, kümeleme, otomatik kontrol vb. işlemleri barındıran karmaşık makine öğrenme modelleridir (Gou ve ark., 2012, Hamdan ve ark., 2017; Moghaddamnia ve ark., 2009). ANN yaklaşık elli yıl önce geliştirilmiş bir yapıdır fakat bilim ve teknoloji alanında efektif olarak son yıllarda kullanılmaya başlanmıştır (Sözen ve ark., 2008). Bununla birlikte rüzgar hızı tahminlemesinde kullanılan ANN'lere geri yayılım sinir ağı (BPNN) (Yang ve Wang, 2019), genelleştirilmiş ileri beslemeli sinir ağı (GFNN) (Babu ve Mohan, 2017), dalgacık sinir ağı (WNN) (Moreno ve do Santos Coelho, 2018) ve genel regresyon sinir ağı (GRNN) (Song ve ark., 2018) örnek verilebilir. Sideratos ve Hatziargyriou tarafından sinir ağıları ve bulanık mantık yöntemini birleştiren bir tahmin modeli geliştirmişlerdir (Sideratos ve Hatziargyriou, 2007). Kalogirou yenilenebilir enerji sistemlerinde ANN kullanılmasını incelemiş ve bir fizibilite çalışması yapmıştır.

Özellikle yapmış olduğu çalışmada rüzgar hızı ve güneş radyasyonu tahmini fotovoltaiik sistemler güneş enerjili su ısıtma sistemleri ve güneş buhar tesisleri alanında araştırmalar yapılmıştır (Kalogirou, 2001). Yayla ve Harmancı çalışmalarında yeni bir ANN modeli önerdiler. Modelde tahminleme işlemi için iki istasyondan toplanan saatlik rüzgar hızı verilerini kullanmışlar (Yayla ve Harmancı, 2021). Başka bir çalışmada dalgacık tekrarlayan sinir ağıları (WRNN) kullanıldı. Belirlenen ve kabul edilebilir bir hata sınırları içerisinde tahminleme işlemi gerçekleştirildi (Capizzi ve ark., 2012). Li çalışmasında rüzgar enerjisi üretimini tahminledi. Çalışmada tekrarlayan çok katmanlı algılayıcı sinir ağıları (RMLP) kullanıldı. Ağ eğitilirken Kalman tabanlı geri yayılım algoritması denendi. Tahminleme sonuçları kıyaslandığında uzun dönem tahminleme için önerilen metodun daha faydalı olduğu belirlendi (Li, 2003). Alam ve arkadaşları Hindistan meteorolojik çalışma koşullarını kullanarak bir çalışma gerçekleştirmişlerdir. Çalışmada tahminleme işlemlerinde kullanmak üzere bir ileri beslemeli geri yayılım ağı (FFBPN) oluşturmuşlardır. Mabel ve Fernandez çalışmalarında ANN modeli kullanmışlardır. Modelde kullanılan girdiler üretim saati, bağıl nem ve rüzgar hızı olarak belirlenmiştir. Elde edilen sonuçların tatmin edici olduğu vurgulanmıştır (Mabel ve Fernandez, 2008). Bosch ve arkadaşları çalışmalarında ANN için en uygun değişkenleri belirlemeyi amaçladılar. Bu gerçekleştirmek için otomatik alaka düzeyi belirleme (ARD) metodunu kullandılar (Bosch ve ark., 2008).

Rüzgarın sahip olduğu uzun vadeli bağımlılık gibi karmaşık özelliklerin tanımlanmasında birtakım sıkıntılar yaşanabilmektedir. Özellikle geleneksel sinir ağıları (NN) bu tanımlamayı yaparlarken yetersiz kalmaktadırlar. Bu nedenle son dönemde rüzgar hızı tahminlemesinde bazı derin öğrenme yöntemleri kullanılmaya başlanmıştır (Yang ve ark., 2021). Aktarım öğrenimi (Hu ve ark., 2016), sinir ağı yapısal öğrenme (Mi ve Zhao, 2020), kısa-uzun vadeli bellek (LSTM) (Li ve ark., 2018), tekrarlayan sinir ağı (RNN) (Cheng ve ark., 2018), evrimsel sinir ağıları (CNN) (Zhao ve ark., 2020) vb., derin öğrenme yöntemlerine örnek olarak gösterilebilir. Bedi ve Toshniwal elektrik enerjisi talebini tahminlemek için LSTM kullandılar. Uzun dönem tahminlemede mevsimsel verilerden faydalanarak çok girişli ve çok çıkışlı bir yapı oluşturdular (Bedi ve Toshniwal, 2019). Bir çalışmada (Abedinia ve ark., 2020) yazarlar kısa ve uzun dönem rüzgar enerjisinin tahminlenmesi için 2 boyutlu bir CNN yapısı önerdiler. Veri ön işleminde dalgacık dönüşümünden faydalandılar. Ayrıca CNN ağırlıklarını parçacık sürü optimizasyon algoritması kullanarak belirlediler. Niu ve arkadaşları kısa dönem rüzgar enerjisi tahminlemek için bir dikkat temelli kapılı tekrarlayan birim (AGRU) metodunu önerdiler (Niu ve ark., 2020).

Başka bir çalışmada zaman serisi verileri ayrıklaştırıldı. Ayrıklaştırılan veriler kullanılarak sınıflandırma ve karmaşıklık hesaplandı. Bu işlemlerin gerçekleştirilmesinde LSTM ve bulanık entropi kullanıldı (Mardani ve ark., 2015). Myoungsoo Kim ve arkadaşları güç tüketimini esas alarak diğer faktörleri de değerlendirip hibrit bir tahminleme metodu önerdiler. Bu metot CNN ve LSTM birleştirilerek kurgulanmış ve tahminleme işlemleri bu yapı üzerinden gerçekleştirilmiştir (Kim ve ark., 2019). Qin ve arkadaşları çalışmalarında LSTM kullanarak rüzgar hızı tahminlemesi gerçekleştirdiler. Rüzgar hızı otokorelasyonunu belirlemek için maksimum bilgi katsayısı yaklaşımını uyguladılar (Qin ve ark., 2019).




6) MATERYAL ve YÖNTEM

Bu tez çalışmasında rüzgar hızı verisi ile geliştirilen hibrit model ile rüzgar hızı tahminlemesi gerçekleştirilmiştir. Rüzgar hızı tahminlemesinde önerilen hibrit model oluşturulmasında Evrişimsel Sinir Ağı ve Kapılı Tekrarlan Birim (CNN-GRU) kombinasyonu tercih edildi. Önceki bölümlerde de belirtildiği üzere bu kombinasyon rüzgar hızı tahminlemesinde ilk defa kullanıldı. Benzer şekilde derin öğrenme yöntemlerinin birlikte kullanıldığı diğer literatür çalışmalarındaki kombinasyonlarda test edildi. Literatürde yaygın olarak kullanılan ve önerilen model ile karşılaştırılmalı olarak test edilen yapılar, Evrişimsel Sinir Ağları – Uzun Kısa Vadeli Bellek (CNN-LSTM), Evrişimsel Sinir Ağları – Tekrarlayan Sinir Ağları (CNN-RNN) ve Uzun Kısa Vadeli Bellek – Kapılı Tekrarlayan Birim (LSTM-GRU) şeklinde seçildi. Bununla birlikte bu yöntemler tahminlemede bağımsız olarak da kullanılarak tahminleme performansı karşılaştırıldı. Önerilen hibrit model iki boyutlu CNN ile GRU ağlarının birleştirilmesi ile elde edilmiştir. CNN'nin temsil öz niteliklerini çıkarma potansiyeli ve GRU'nun etkin kapılı yapısı nedeni ile hibrit modelin tahmin doğruluğu artmıştır. Bu şekilde çalışmada kullanılan yöntemler, verilerin elde edilmesi ve verilere uygulanan ön işleme adımları aşağıdaki bölümlerde detaylı bir şekilde açıklanmıştır. Yapılan deneysel çalışmalar intel i7 işlemcili, 1650ti ekran kartına sahip, 16 gigabyte RAM kapasiteli olan bilgisayar ile MATLAB yazılımı ile gerçekleştirilmiştir.


6.1. Verilerin Elde Edilmesi

Bu çalışmada ilk olarak Tokat Gaziosmanpaşa Üniversitesi Taşlıçiftlik yerleşkesinde yer alan ölçüm istasyonundan rüzgar hız verileri elde edilmiştir. Rüzgar hızı elde edilen ölçüm istasyonuna ait ölçüm direği Şekil 6.1'de verilmektedir.



Şekil 6.1. Ölçüm direği (Tan, 2020)

Mevcut olan ölçüm direği 12m yüksekliğe sahip olmak ile birlikte üzerinde 1 adet rüzgar yönü ölçüm sensörü ve 2 adet rüzgar hızı ölçüm sensörüne sahiptir. Nem, sıcaklık ve basınç sensörleri ölçüm direğinin alt bölümünde yer alan güç kutusunun içerisine yerleştirilmiştir. Güç kutusu Şekil 6.2’de görülmektedir. Sensörler için ihtiyaç duyulan enerji 10 W’lık güce sahip bir güneş paneli ile karşılanmaktadır. Ayrıca sonrasında planlanan rüzgar gücü analizleri çalışmalarında kullanılmak üzere rüzgar türbini ölçüm direğinin üzerine bir adet marina tipi AIRX-400W’lık rüzgar türbini yerleştirilmiştir.



Şekil 6.2. Güç kutusu (Tan, 2020)


Çalışmada kullanılan rüzgar hızı verileri ölçüm istasyonu üzerinden 1'er saat aralıklar ile toplanan 3 yıllık veri seti kullanılmıştır. Toplanan veriler ortalama haftalık, aylık ve yıllık olarak gruplara ayrılmıştır. Ayrılan veriler içerisinde gürültü içeren değerleri ortadan kaldırmak ve daha net bir sonuç elde etmek için 0-1 arası normalizasyon işlemi uygulanmıştır. Normalizasyon işlemi, daha doğru analiz yapılabilmesi için veri aralıklarını belirleyebilmek ve ayrıca regresyon işleminin başarısını artırmak adına son derece önemlidir. Eldeki verilerin daha düzenli bir formata dönüşebilmesi amacıyla normalizasyon işlemi uygulanır. Verileri doğrusal olarak normalize etmek için denklem 6.1'de verilen işlemler uygulanmaktadır (Demir, 2019).

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (6.1)$$


x' , normalize edilen veriyi temsil etmektedir. x_i normalize edilecek veriyi ifade etmektedir. x_{min} ve x_{max} veriler arasında yer alan en düşük değer ile en yüksek değeri temsil etmektedir.

Gruplandırma ve normalizasyon işlemi neticesinde elde edilen rüzgar hızı verilerinin haftalık, aylık ve yıllık histogram grafiği oluşturulmuştur. Şekil 6.3 ve 6.4'de haftalık verilerin histogram

grafığı ve bu verilere ait dağılımı görölmektedir. Haftalık veriler oluşturulurken analizlerde standart sağlamak için ve literatür çalışmalarıyla uyumlu olması açısından her ayın ilk 4 haftası olacak şekilde seçilmiştir. Böylece ortalama haftalık 48 adet veri seti oluşturulmuştur. Ortalama haftalık veriler üzerinden tahminleme yapılmasındaki esas gaye düşük sayıda veri setinin ağ performansı üzerindeki etkisini de gözlemlemek amaçlanmıştır. Bu veri setinde 36 adet rüzgar hızı verisi (%75) eğitim 12 adet rüzgar hızı verisi (%25) ise tahminleme için kullanılmıştır.




Şekil 6.3. Haftalık rüzgar hızı verilerinin histogram grafiğı




Şekil 6.4. Haftalık rüzgar hızı verilerinin dağılım grafiğı

Şekil 6.5 ve 6.6’da aylık ortalama rüzgar hızlarının histogram grafiğı ve dağılımı görölmektedir. Bu veri seti oluşturulurken de 3 yılın her ayının kendi içerisinde ortalamaları alınarak toplam 8760 adet rüzgar hızı verisi kullanılmıştır. Bu verilerden ilk 9 aya ait olan 6570 sayıdaki veri eğitim verisi (%75), son 3 aya ait 2190 sayıdaki veri (%25) ise test verisi olarak ayrılmıştır.




Şekil 6.5. Aylık rüzgar hızı verilerinin histogram grafiği




Şekil 6.6 Aylık rüzgar hızı verilerinin dağılım grafiği

Şekil 6.7 ve 6.8’de yıllık tahminleme için kullanılan verilerin histogram grafiği ve dağılımı görülmektedir. 2018 ve 2019 yılına ait olan toplam 17520 saatlik rüzgar hızı verisi (%66,6) eğitim, 2020 yılına ait olan 8760 adet veri de test verisi (%33,3) olarak uygulamada kullanılmıştır.



Şekil 6.7. Yıllık rüzgar hızı verilerinin histogram grafiği



Şekil 6.8 Yıllık rüzgar hızı verilerinin dağılım grafiği


6.2. Evrişimsel Sinir Ağları (CNN)

Derin evrişimsel sinir ağları kullanan ve bir makine öğrenmesi alt dalı olan derin öğrenme, çok katmanlı algılayıcı ağ yapısı ile oluşturulan evrişimsel sinir ağları (CNN) içermektedir (Türkoğlu ve ark., 2021). Evrişimsel Sinir Ağları (CNN), derin öğrenme yöntemleri arasında, sınıflandırma, tanımlama, tahminleme (Carcagni ve ark., 2018) ve benzeri birçok alanda işlem yapabilen derin sinir ağları yapısıdır (Sevli, 2019). Evrişimsel ağlar, örneğin üç renk kanalında piksel yoğunlukları içeren üç tane 2 boyutlu diziden oluşan bir renkli görüntü gibi birden çok dizi biçiminde gelen verileri işlemek üzere tasarlanmıştır. Birçok veri yöntemi birden çok dizi biçimindedir: Dil içerikli sinyaller ve diziler için bir boyutlu (1D), görüntüler veya ses

spektrogramları için iki boyutlu (2D) ve video veya hacimsel görüntüler için ise üç boyutlu (3D) kullanılır (LeCun ve ark., 2015).

Evrşimsel sinir ağlarını temele alan ağ modellerinin çeşitli avantajları mevcuttur. Bunlardan bir kaç nesneleri tanımlarken, ön işlem aşaması uygulamadan nesneleri arka plandan ayırma, geleneksel yöntemlerle yapılan görüntü tanımlama işlemlerine kıyasla daha yüksek performans sağlaması ve zaman serisine dayalı işlemlerinde yüksek doğruluk oranında tahminleme yapabiliyor olması en önemli artılarındandır. Derin sinir ağlarının avantajları olduğu gibi dezavantajlarda mevcuttur. En önemli dezavantajı donanımsaldır. Derin sinir ağlarının daha verimli çalışması istendiğinde güçlü Grafik İşleme Ünitesi (GPU) kartlarına ve yüksek bellek kapasitelerine ihtiyaç duymasıdır. Son yıllarda piyasaya çıkan daha güçlü GPU kartları ve daha yüksek kapasiteli bellekler sayesinde karşılaşılabilecek sorunlar ortadan kaldırılabilir. Gelişen teknoloji ile beraberinde yüksek kapasiteli belek ve güçlü GPU kartları ile bu dezavantaj ortadan kaldırılarak çözüme ulaştırılabilir (Türkoğlu ve ark., 2021).

CNN mimarisi, derin öğrenme kavramına ait temel bir mimari olarak kabul görür. Evrşimsel sinir ağları birden fazla parametre ve katmandan meydana gelmektedir. Katmanlı yapısı sayesinde öz nitelik tespitinde oldukça başarılı sonuçlar elde etmektedir (Somuncu ve Atasoy, 2022). Şekil 6.9’da evrşimsel sinir ağı mimarisi verilmiştir. Bu mimariye göre ilk birkaç aşama evrşim ve ortaklama katmanlarından oluşmaktadır. Son aşama ise Tam Bağlantı katmanından meydana gelmektedir ve akabinde Sınıflandırma katmanı mevcuttur. Kısaca CNN’ler ardı ardına yerleştirilmiş birden fazla eğitilebilir bölümlerden oluşmaktadır. Devamında eğitici bir sınıflandırıcı ile devam edilir. CNN’de giriş verilerini aldıktan sonra katman katman işlemler yapılarak eğitim süreci gerçekleştirilir. En sonunda doğru sonuç ile karşılaştırma yapmak için bir final çıktısı verir. Üretilen sonuç ile istenen sonucun farkı kadar bir hata oluşur. Bu hatanın bütün ağırlıklara aktarılması için geriye yayılım algoritması kullanılır. Her bir iterasyonla ağırlıkların güncellenmesi yapılarak hatanın azaltılması sağlanır (İnik ve Ülker 2017). Şekil 6.9’da örnek bir evrşimsel sinir ağı mimarisi görülmektedir.



Şekil 6.9. Evrişimsel sinir ağı mimarisi

Evrişimli sinir ağları, çok adımlı zaman serisi tahmini için kullanılabilir. Evrişimli katmanlar, girdi verilerinin dizilerini okuyabilir ve özellikleri otomatik olarak çıkarabilir. Havuzlama katmanları, çıkarılan özellikleri damıtabilir ve dikkati en göze çarpan öğelere odaklayabilir. Tamamen bağlı katmanlar, dahili temsili yorumlayabilir ve birden çok zaman adımını temsil eden bir vektörün çıktısını alabilir. Yaklaşımın temel faydaları, otomatik özellik öğrenme ve modelin doğrudan çok adımlı bir vektör çıktısı verme yeteneğidir. CNN'ler, modelin tek adımlı tahminler yaptığı ve çıktıların sonraki tahminler için girdi olarak beslendiği ve tahmin edilecek her bir zaman adımı için bir modelin geliştirildiği özyinelemeli veya doğrudan tahmin stratejisinde kullanılabilir. Alternatif olarak, CNN'ler tüm vektörün tek adımlı bir tahmini olarak tüm çıktı dizisini tahmin etmek için de kullanılabilir. Bu, ileri beslemeli sinir ağlarının genel bir faydasıdır (Brownlee, 2018).

CNN'leri kullanmanın önemli bir ikincil yararı, bir tahmin yapmak için birden fazla 1 boyutlu girişi destekleyebilmeleridir. Bu, çok adımlı çıkış dizisinin birden fazla giriş dizisinin bir fonksiyonu olması durumunda kullanışlıdır. Bu, iki farklı model konfigürasyonu kullanılarak elde edilebilir. Çoklu giriş kanalları, her giriş dizisinin, bir görüntünün farklı kanalları gibi (örneğin mavi, kırmızı ve yeşil) ayrı bir kanal olarak okunduğu yerdir. Çoklu giriş kafaları, her giriş dizisinin farklı bir CNN alt modeli tarafından okunduğu ve iç temsillerin yorumlanmadan ve bir tahmin yapmak için kullanılmadan önce birleştirildiği yerdir (Brownlee, 2018).


Bu çalışmada oluşturulan hibrit modele ait parametreler Çizelge 6.1'de özetlenmektedir.

Çizelge 6.1. Model parametreleri

Evrişim katmanı 1	Filtre sayısı: 32 MiniBatch boyutu: 64
Evrişim katmanı 2	Filtre sayısı: 32 MiniBatch boyutu: 64
Evrişim katmanı 3	Filtre sayısı: 32 MiniBatch boyutu: 64
Evrişim katmanı 4	Filtre sayısı: 32 MiniBatch boyutu: 64
Evrişim katmanı 5 + Havuzlama	Filtre sayısı: 32 MiniBatch boyutu: 64 Havuzlama metodu: Ortalama havuzlama
Gru katmanı	Filtre sayısı: 128 MiniBatch boyutu: 64 Dropout: 0.25

6.3. Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan Sinir Ağları (RNN), yaygın olarak kullanılan yapay sinir ağlarının bir türüdür. Tekrarlayan sinir ağında sadece ağı girdi olarak verilen giriş verilerinin değil önceki zaman serilerinin içerisinde yer alan giriş verilerini kullanır. Genel anlamda bu tekrarlayan sinir ağlarının çalışma prensibi sıralı olarak birbiri ardına gelen verileri kullanmasıdır (Doğan ve Türkoğlu, 2019). Tekrarlayan sinir ağları ileri beslemeli ağlar ve geleneksel sinir ağlarından farklı olarak, girdi verileri üzerinde işlem yapmaktayken kendi hafıza donanımından faydalanmaktadır (Metin ve Karasulu, 2019). Bu sinir ağları konuşma, aktivite ve el yazısı sınıflandırmaları gibi benzeri çalışma alanlarında eldeki zaman serisi verileri için işleme tabii tutma yeteneği ile ön plana çıkmaktadır (Mikolov ve ark., 2010). Şekil 6.10’da tekrarlayan sinir ağlarının temel açılımı görülmektedir.



Şekil 6.10. Tekrarlayan sinir ağlarının temel açılımı (Metin ve Karasulu, 2019)

Standart tekrarlayan sinir ağı (RNN) modeli, Şekil 6.10'da gösterildiği gibi gizli ünite üzerinde bir döngüye sahiptir. Üç tür katmanı vardır: giriş katmanı x , gizli katman h ve çıkış katmanı y olarak verilmektedir. Bu döngüyü açarsak, standart RNN aynı yapıyı birden çok kez kopyalamak olarak düşünülebilir ve her kopyanın h durumu ardılına girdi olarak alınır.

Giriş katmanını, gizli katmanı ve çıkış katmanını t zamanında sırasıyla $x(t)$, $h(t)$ ve $y(t)$ olarak ifade ederek, çıkış $y(t)$ şu şekilde hesaplanabilir:

$$a(t) = b_t + Wh(t-1) + Ux(t) \quad (6.2)$$

$$h(t) = \sigma(a^{(t)}) \quad (6.3)$$

$$y(t) = b_2 + Vh(t) \quad (6.4)$$


b_1 ve b_2 'nin önyargı vektörleri olduğu durumlarda, U , V ve W sırasıyla giriş-gizli bağlantının, gizli-çıkış bağlantısının ve gizli-gizli bağlantının ağırlık matrisleridir ve σ (sigma) bir etkinleştirme işlevidir (Feng ve ark., 2017). Standart RNN'leri eğitmek, gradyan kaybolma ve patlama problemi nedeniyle zor bir iştir (Bengio ve ark., 1994). Bu zorluğu gidermek için Hochreiter ve Schmidhuber uzun kısa vadeli bellek (LSTM) modelini tanıttı (Hochreiter ve Schmidhuber, 1997).

6.4. Uzun-Kısa Vadeli Bellek (LSTM)

Yapay sinir ağları (ANN), makine öğrenimi çalışmalarında oldukça geniş bir kullanım alanı mevcuttur. Çeşitli talepler ve ihtiyaçlar nedeniyle zamanla birçok yapay sinir ağ modelleri geliştirilmiştir. Bu sebeple çeşitli yapay sinir ağ modelleri, farklı veri çeşitlerini işlenmesi adına önemli başarılar elde etmiştir. Evrişimli sinir ağları, görüntü gibi matris tipi veriler için yaygın olarak kullanılmaya başlanmıştır. Öte yandan, dizi türündeki verileri işlemek için tekrarlayan sinir ağları (Recurrent Neural Network-RNN) geliştirilmiştir. Geleneksel ileri beslemeli ANN'ler, girdi olarak sadece maruz kaldıkları mevcut örnekleri dikkate alır. RNN'ler ise bunlardan farklı olarak mevcut girdilerin yanı sıra zaman içerisinde algıladıkları örnekleri de girdi olarak kullanırlar (Hochreiter ve Schmidhuber 1997). 1997 yılına gelindiğinde Juergen Schmidhuber'in ortaya atılan Uzun Kısa Vadeli Bellek (LSTM) hücreleri, uzun dönemli bağımlılık problemlerine ve vanishing gradien (kaybolan gradyan) problemlerini ortadan kaldırmak adına bir çözüm olarak ileri sürülmüş tekrarlayan sinir ağ yapısının bir türüdür. Özellikle zaman serileri verilerinde tekrarlayan sinir ağlarına kıyasla daha iyi ve daha tutarlı bir performans veren özel iç kapılarına (unutma kapısı) sahip bir ağ yapısıdır. Doğal dil işlem, hava

durumu tahminleri ve konuşma tanıma durumlarındaki gibi zaman serileri içeren problemlerde evrimsel sinir ağları (CNN), kısıtlı boltzman makineleri (RBM) ve otomatik kodlayıcı (AE) gibi diğer ağ yapıları ile karşılaştırıldıklarında uzun kısa vadeli bellek yapısının oldukça başarılı performans sergilemektedir (Metin ve Karasulu, 2019). Gradyanların zaman boyunca kolaylıkla akışını sağlayan ağ tasarımıdır (Hochreiter ve Schmidhuber 1997).

LSTM ağ yapısının RNN ağ yapısından büyük farklılıkları yoktur. Ancak LSTM ağlarında gizli durumu hesaplayabilmek için bir yapı kullanılmaktadır. İçerisinde hafıza hücreleri barındıran LSTM, girdi verisi ve bir önceki durum bilgisini hafızasında tutan bir hücredir. Ağ mimarisinde mevcut olan bu hücreler hangi verilerin silineceğini veya hangi verilerin hafızada tutulacağına karar vermektedirler. Diğer bir aşamada giriş verisi ile önceki durum mevcut belleği birleştirilir. Girdi verilerinin uzun süre hafızada tutabilme işlemini uzun kısa vadeli bellek hücreleri sağlamaktadır. Şekil 6.11’de uzun kısa vadeli bellek yapısının genel görünümü verilmiştir. Birbirine bağlı 4 katman bulunmaktadır. Dışarıdan hücreye yazılabilen, depolanabilen ve okunabilen bilgileri alabilen bir yapıya sahiptir. İç yapısında kullanılan kapılar vasıtası ile hangi bilgiyi sileceğini, okuyacağını ve depolama işlemlerini gerçekleştirme zamanına karar verir. İçerdiği kapılar ile aktivasyon fonksiyonun gerçekleştiği bir ağ yapısı mevcuttur. Girdi verisini belirli bir ağırlık durumuna göre durdurma ve geçirme özelliği gösterir (Chung ve ark., 2014). Ağırlıklar tekrarlanan ağı öğrenmesi durumunda hesaplanmaktadır. Bu ağ yapısının vasıtası ile hücre, gelen veriyi alabilir, iletebilir veya silme işlemlerini öğrenebilir (Görgel ve Kavlak, 2020).




Şekil 6.11. LSTM genel yapısı (Olah, 2015)

LSTM, kapı adı verilen yapılar tarafından dikkatlice hazırlanan hücre durumuna bilgileri ekleme veya kaldırma kabiliyetine sahiptir. Kapılar, isteğe bağlı olarak bilginin geçmesine izin vermenin bir yoludur. Noktasal çarpma işleminden ve bir sigmoid sinir ağı katmanından meydana gelmektedirler. Sigmoid katman, her bir bileşen için geçmesi gerektiği kadarı ile alakalı olarak açıklama yapar ve bir ile sıfır arasındaki sayıları çıkarır. Birin değeri “her şeyin geçmesine izin ver” anlamı taşırken, sıfırın değeri “hiçbir şeyin geçmesine izin verme” anlamı taşımaktadır. Bir LSTM, hücrenin durumunu kontrol etmek ve korumak için bu kapılardan 3 tanesine sahiptir (Doğan ve Türkoğlu, 2019).

Şekil 6.12’de uzun kısa vadeli belleğimizdeki başlangıç adımı, hücre durumundan hangi bilgileri atacağımıza karar vermektir. Bu karar, “kapı katmanını unut” adı verilen bir sigmoid katman tarafından verilir.” h_{t-1} ve x_t ’ye bakar ve C_{t-1} hücre durumundaki her sayı için 0 ile 1 arasında bir sayı çıkarır. 0, “bundan tamamen kurtulmayı” temsil ederken, 1, “bunu tamamen sakla” yı temsil eder (Olah, 2015). x_t ve h_t sırası ile girdi ve çıktı verilerini temsil eder. C_t ve $\bar{C}_t$ sırasıyla bellek hücresi ve yeni bellek hücresini temsil etmektedir. f ise unutma kapısını temsil etmektedir.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (6.5)$$




Şekil 6.12. LSTM başlangıç adımı (Olah, 2015)

Devam eden işlemler neticesinde ise hücre durumunda hangi yeni bilgileri saklayacağımıza karar vermek gerekmektedir. Bu durum iki bölüme ayrılmaktadır. Şekil 6.13. Bu durumdan ilki, “giriş kapısı katmanı” adı verilen bir sigmoid katman, hangi değerleri güncelleyeceğimize karar verir. İkinci durum ise, bir tanh katmanı, duruma eklenebilecek yeni bir aday değer vektörü olan $\bar{C}_t$ oluşturur. Bir sonraki adımda, duruma bir güncelleme oluşturmak için bu ikisi birleştirilecektir (Olah, 2015).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (6.6)$$

$$\bar{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (6.7)$$




Şekil 6.13. Saklanacak yeni bilgilerin karar verilmesi aşaması (Olah, 2015)

Diğer bir aşamada eski hücre durumu olan C_{t-1} 'i yeni hücre durumu C_t 'ye güncelleme yapılması gerekmektedir. Önceki adımlarda ne yapılacağına sistem karar vermiştir, bu süreçte sadece uygulama gerekmektedir. Eski durum f_t ile çarpılır ve sonrasında daha önce unutulmaya karar verilen bilgiler unutulur (Greff ve ark., 2016). Sonra $i_t * \bar{C}_t$ ilave edilir. Bu, her bir durum

değerini güncellemeye ne kadar karar verildiğine göre ölçeklenen yeni aday değerlerdir (Olah, 2015). Şekil 6.14.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (6.8)$$




Şekil 6.14. Hücre güncellemesi (Olah, 2015)

Son olarak, ne çıkarılacağına karar verilmelidir. Bu çıktı hücre durumumuza dayanacak, ancak filtrelenmiş bir sürüm olmak durumundadır. Şekil 6.15 incelendiğinde ilk olarak, hücre durumunun hangi kısımlarının çıkarılacağına karar veren bir sigmoid katman çalıştırılmaktadır. Daha sonra, hücre durumu tanh'den geçirilir (değerleri -1 ile 1 arasında olacak şekilde sıkıştırmak için) ve sigmoid kapının çıktısı ile çarpma işlemi uygulanır. Böylece yalnızca karar verilen kısımlar çıkarılmış olur (Olah, 2015).

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (6.9)$$

$$h_t = o_t * \tanh(C_t) \quad (6.10)$$




Şekil 6.15. Çıktı karar durumu (Olah, 2015)

6.5. Kapılı Tekrarlayan Birim (GRU)

LSTM mimarisinin günümüzde çok farklı varyasyonları bulunmaktadır. Bu varyasyonlardan birisi olan ve genellikle en çok tercih edileni Kapılı Tekrarlayan Birim (GRU)'dir. Klasik tekrarlayan yapay sinir ağı ile beraberinde gelen kaybolan gradyan sorununu çözümlenmeyi hedeflemektedir. GRU ve LSTM, benzer şekilde tasarlandığından ve özellikle bazı durumlarda çok başarılı sonuçlar üretebilmektedirler (Görgel ve Kavlak, 2020). GRU mimarisinin yapısında unutma kapısı ve giriş kapısı birleştirilmiştir. Temel olarak, bunlar çıktıya hangi bilgilerin iletilmesi gerektiğine karar veren iki vektördür. Kapılar ile ilgili özel olan durum, bilgiyi zaman içinde yıkamadan veya tahminle ilgisi olmayan bilgileri silmeden uzun zaman öncesinden saklamak için eğitilebilmeleridir. Kapılı tekrarlayan birim, örneğin konuşma tanımda bellek ve kümeleme ile ilişkili makine öğrenme görevlerini gerçekleştirmek için bağlantıları bir dizi düğüm aracılığıyla kullanmayı amaçlayan belirli bir tekrarlayan sinir ağı modelinin parçasıdır. Kapılı tekrarlayan birim, tekrarlayan sinir ağlarındaki sıklıkla karşılaşılan yok olan gradyan sorununu çözmede sinir ağı giriş ağırlıklarının ayarlanmasına yardımcı olur (Ahmetoğlu ve Daş 2020). Şekil 6.16 ve Şekil 6.17 incelendiğinde GRU'da kullanılan notasyonlar ve GRU mimarisi verilmiştir.



Şekil 6.16. GRU notasyonları (Kostadinov, 2017)




Şekil 6.17. Kapılı tekrarlayan birim mimarisi (Kostadinov, 2017)

GRU’larda ilk olarak kapıyı güncelleme işlemi gerçekleşir. Aşağıda verilen formül ile z_t güncelleme geçidi hesaplanır.

$$z_t = \sigma(W^{(z)}x_t + U^{(z)}h_{t-1}) \quad (6.11)$$

x_t ağ birimine eklendiğinde, kendi ağırlığı $W^{(z)}$ ile çarpılır. Aynı durum önceki $t-1$ birimleri için bilgileri tutan ve kendi ağırlığı $U^{(z)}$ ile çarpılan h_{t-1} içinde geçerlidir. Her iki sonuç birlikte eklenir ve sonucu 0 ile 1 arasında sıkıştırmak için bir sigmoid aktivasyon fonksiyonu uygulanır. Güncelleme kapısı, modelin önceki zaman adımlarındaki geçmiş bilgilerin ne kadarının ileriye yönelik aktarılması gerektiğini belirlemesinde yardımcı olur (Dey ve Salem, 2017). Model geçmişten gelen tüm bilgilerin kopyalama ve kaybolan gradyan problemini ortadan kaldırması gibi çok büyük avantajlar sağlamaktadır (Kostadinov, 2017). Şekil 6.18’de GRU mimarisindeki kapı güncelleme işlemi modellenmiştir.




Şekil 6.18. GRU kapı güncelleme (Kostadinov, 2017)

Sıfırlama kapısında, model üzerinde geçmiş bilgilerin ne kadarını unutacağına karar vermek için kullanılır. Bu işlem için 6.12'deki denklemdaki hesaplamalar yapılmaktadır (Görgel ve Kavlak, 2020).

$$r_t = \sigma(W^{(r)}x_t + U^{(r)}h_{t-1}) \quad (6.12)$$

Kullanılan formül güncelleme kapısı ile aynıdır. Formüller arasındaki farklılık, ağırlık ve kapının kullanımında ortaya çıkmaktadır. Şekil 6.19'da sıfırlama kapısının nerede yer aldığını göstermektedir.




Şekil 6.19. Sıfırlama kapısı (Kostadinov, 2017)

Önceki işlemlerde de yapıldığı gibi, h_{t-1} ve x_t değerlerine karşılık gelen ağırlıkları çarpılarak sonucunu toplanır ve sonrasında sigmoid fonksiyonu uygulanır.

Geçerli bellek içeriğinde, geçitlerin nihai çıktısı tam olarak nasıl etkileyeceğine göz atacak olursanız; İlk olarak, sıfırlama kapısının kullanımı ile başlanır. Geçmişten ilgili bilgileri depolamak için sıfırlama kapısını kullanacak yeni bir bellek içeriği sunulur. 6.13’de verilen denklemdeki işlemler uygulanır (Kostadinov, 2017). Yapılan işlemlerin görseli Şekil 6.20’de verilmektedir.

$$h'_t = \tanh(Wx_t + r_t \cdot Uh_{t-1}) \quad (6.13)$$




Şekil 6.20. Geçerli bellek işlemi (Kostadinov, 2017)

h_{t-1} ve r_t eleman bazında çarpımını gerçekleştirilir ve ardından sonucu x_t girişi ile toplanır. Son olarak, h'_t üretmek için tanh kullanılır.

Geçerli zaman adımında son bellek, son adım olarak ağı, mevcut birimi için bilgiyi tutan ve ağa ileten h_t vektörünü hesaplaması gerekmektedir. Bu işlemin yapılabilmesi için güncelleme kapısına ihtiyaç vardır. Geçerli bellek içeriğinden nelerin toplanacağını belirler. Bu işlemler 6.14'de verilen denklem ile hesaplanmaktadır (Kostadinov, 2017). Verilen denklemin görseli Şekil 6.21'de görülmektedir.

$$h_t = z_t \cdot h_{t-1} + (1 - z_t) \cdot h'_t \quad (6.14)$$



Şekil 6.21. Mevcut birim için bilgiyi tutan ve ileten fonksiyonun hesaplanması (Kostadinov, 2017)

$1 - z_t$ 'yi hesaplamak için z_t 'nin nasıl kullanıldığını görülmektedir. h'_t ile birleştğinde koyu kırmızı olan çizgide bir sonuç üretmektedir. z_t , öge bazında çarpmada h_{t-1} mavi çizgi ile de kullanılır. Son olarak, h_t mavi çizgi, kırmızı çizgilere karşılık gelen çıktıların toplamının bir sonucu olarak elde edilmektedir (Kostadinov, 2017).

6.6. Performans Kriterleri

Literatürde tahminleme işlemlerinin doğruluğunu ölçeklendirebilmek adına genel olarak üç tane değerlendirme endeksi kullanılır. Bu endeksler sırasıyla Ortalama Karesel Hatanın Karekökü (RMSE, Root Mean Square Error), Ortalama Mutlak Hata Yüzdesi (MAPE, Mean Absolute Percent Error) ve Determinasyon Katsayısı (R^2 , Determination Coefficient) şeklindedir. Bu endeksler ile performans değerlendirilmesi gerçekleştirilir. RMSE ve MAPE hata metriklerinin 0'a yakınsaması ve R^2 hata metriğinin 1'e yakınsaması başarılı tahminler yapıldığını göstermektedir. Yukarıda verilen performans kriter endekslerine ait denklemler sırası ile 6.15, 6.16 ve 6.17'de verildiği gibidir (Sun ve ark., 2018):

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{x}_t)^2} \quad (6.15)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{(y_i - \hat{x}_i)}{y_i} \right| \quad (6.16)$$

$$R^2 = \left(\frac{\sum(xy) \frac{(\sum x)(\sum y)}{n}}{\sqrt{\left[\sum x^2 - \frac{(\sum x)^2}{n} \right] \left[\sum y^2 - \frac{(\sum y)^2}{n} \right]}} \right)^2 \quad (6.17)$$

Denklemlerde yer alan y_i ve $\bar{x}_i$ sırası ile gözlemlenen ve tahmin edilen rüzgar hızlarının temsil etmektedir ve ayrıca N değeri, toplam örnek sayısını ifade etmektedir.

7) BULGULAR


Çalışmada önerilen hibrit CNN-GRU modeli bağımsız olarak haftalık, aylık ve yıllık tahminlemelerde kullanılmıştır. Elde edilen sonuçlar yorumlanarak değerlendirilmiştir. Bununla birlikte belirtilen 3 bağımsız vaka tahminleme çalışmasında önerilen hibrit modelin performansı oluşturulan GRU, LSTM, LSTM-GRU, CNN-LSTM ve CNN-RNN ağ yapılarıyla kıyaslanmıştır. Vaka çalışmalarına ait bulgular detaylı bir şekilde aşağıdaki bölümlerde sunulmaktadır.

7.1. 1. Vaka Çalışması (Haftalık Rüzgar Hızı Tahmini)

Çalışmanın birinci aşamasını oluşturan haftalık tahminleme için önerilen hibrit tahminleme modeli, yapılan deneysel çalışmalar neticesinde diğer modellere göre daha yüksek doğruluk oranı ile tahminleme işlemini gerçekleştirmiştir. Çizelge 7.1’de önerilen hibrit model ile diğer modellerin performanslarının karşılaştırılması sunulmaktadır. Önerilen hibrit modeldeki RMSE değeri 0.0306 olup bu hata değerine en yakın değer LSTM modeli ile elde edilmiştir. En yüksek hata oranı ise bağımsız GRU modelinde ortaya çıkmıştır. Çizelge incelenecek olursa hata metriklerindeki değerler, bazı modeller ile çok yakın sonuçlar verdiği gözlemlenmiştir. Oluşan bu küçük farklar rüzgar gücünün hesaplanmasında, rüzgar hızının küpü ile orantılı olduğu için elde edilen hata metriklerindeki en küçük değişimler dahi büyük önem taşımaktadır. Modellerin hata metriklerinin değişimi ve regresyon oranları Şekil 7.1’de açıkça görülmektedir.


Çizelge 7.1. Haftalık tahminleme performans kıyaslaması

Metrik	GRU	LSTM	LSTM-GRU	CNN-GRU	CNN-LSTM	CNN-RNN
MAPE	0.227	0.1165	0.1395	0.1106	0.1254	0.1746
R ²	0.9142	0.983	0.9732	0.9841	0.9769	0.9681
RMSE	0.0695	0.0309	0.0397	0.0306	0.0387	0.0483




Şekil 7.1. Haftalık tahminleme performans grafiği


Şekil 7.2 – 7.7’de tüm modellere ait tahminlenen rüzgar hızları değişimlerinin gerçek rüzgar hızı değişimleri ile kıyaslanması gösterilmektedir. Modellere ait tahminleme grafikleri incelendiğinde; 48 haftadan oluşan veri seti içerisinde tahminlemesi gerçekleştirilen 12 haftalık veri grubunun değişimi görülmektedir.




Şekil 7.2. CNN-GRU tahminleme grafiği




Şekil 7.3. CNN-LSTM tahminleme grafiği




Şekil 7.4. CNN-RNN tahminleme grafiği



Şekil 7.5. LSTM-GRU tahminleme grafiği




Şekil 7.6. GRU tahminleme grafiği



Şekil 7.7. LSTM tahminleme grafiği

Bununla birlikte gerçek rüzgar hızı verileri ile tahminlenen rüzgar hızı verilerinin toplu değişim Şekil 7.8’de gösterilmektedir. Şekil 7.8 incelendiğinde önerilen modelin gerçek rüzgar hızı verileri değişimine daha yakın bir trend sergilediği görülmektedir.




Şekil 7.8. Gerçek rüzgar hızı ile tüm modellere göre tahminlenen rüzgar hızları değişimi

7.2. 2. Vaka Çalışması (Aylık Rüzgar Hızı Tahmini)

Çalışmanın ikinci aşamasını oluşturan aylık rüzgar hızı tahminlemesi için önerilen hibrit model, yapılan deneysel çalışmalar neticesinde diğer modellere kıyasla daha düşük hata oranı sergileyerek tahminleme işlemini başarıyla gerçekleştirmiştir. Çizelge 7.2’de önerilen hibrit model ile diğer modellerin performanslarının karşılaştırılması sunulmaktadır. Önerilen hibrit modelle elde edilen RMSE değeri 0.0127 olup bu hata değerine en yakın değer CNN-LSTM modeli ile elde edilmiştir. En yüksek hata oranı ise LSTM-GRU modelinde ortaya çıkmıştır. Modellerin hata metriklerinin değişimi ve regresyon oranları Şekil 7.9’da açıkça görülmektedir.


Çizelge 7.2. Aylık tahminleme performans kıyaslaması

Metrik	GRU	LSTM	LSTM-GRU	CNN-GRU	CNN-LSTM	CNN-RNN
MAPE	0.3797	0.3492	0.3544	0.0409	0.0498	0.0526
R ²	0.8316	0.8658	0.7966	0.9977	0.9923	0.9893
RMSE	0.1087	0.097	0.1194	0.0127	0.0189	0.0206




Şekil 7.9. Aylık tahminleme performans grafiği


Şekil 7.10 – 7.15’de tüm modellere ait tahminlenen rüzgar hızları değişimlerinin gerçek rüzgar hızı değişimleri ile kıyaslanması gösterilmektedir. Bununla birlikte önerilen hibrit modeldeki tahminleme sonuçları gerçek rüzgar hızı verilerinin değişimine daha yakın bir davranış sergilediği görülmektedir. Özellikle grafiklerden LSTM-GRU, GRU ve LSTM (Şekil 7.13-7.15) grafiklerinin incelenmesi sonucunda bu modellerde yapılan tahminlemelerde modelin ezberleme yaptığı ve sürekli belirli aralıkta osilasyon davranışı gösterdiği tespit edilmiştir.




Şekil 7.10. CNN-GRU tahminleme grafiği




Şekil 7.11. CNN-LSTM tahminleme grafiği




Şekil 7.12. CNN-RNN tahminleme grafiği



Şekil 7.13. LSTM-GRU tahminleme grafiği




Şekil 7.14. GRU tahminleme grafiği



Şekil 7.15. LSTM tahminleme grafiği

Bununla birlikte gerçek rüzgar hızı verileri ile tahminlenen rüzgar hızı verilerinin toplu değişim Şekil 7.16’da gösterilmektedir. Şekil 7.16 incelendiğinde önerilen modelin gerçek rüzgar hızı verileri değişimine daha yakın bir trend sergilediği görülmektedir.




Şekil 7.16. Gerçek rüzgar hızı ile tüm modellere göre tahminlenen rüzgar hızları değişimi

7.3. 3. Vaka Çalışması (Yıllık Rüzgar Hızı Tahmini)

Çalışmanın son aşamasını oluşturan yıllık rüzgar hızı tahminlemesinde önerilen hibrit model daha doğru ve güvenilir sonuçlar vermiştir. Çizelge 7.3’de önerilen hibrit model ile diğer modellerin performanslarının karşılaştırılması sunulmaktadır. Önerilen hibrit modeldeki R^2 değeri 0.9915 olup bu değere en yakın regresyon değeri 0.9911 ile CNN-RNN modelinde elde edilmiştir. En düşük R^2 değeri ise bağımsız GRU modeli ile hesaplanmıştır. Modellerin hata metriklerinin değişimi ve regresyon oranları Şekil 7.17’de açıkça görülmektedir.


Çizelge 7.3. Yıllık tahminleme performans kıyaslaması

Metrik	GRU	LSTM	LSTM-GRU	CNN-GRU	CNN-LSTM	CNN-RNN
MAPE	1.155	1.052	1.018	0.5324	0.8562	0.7656
R^2	0.4704	0.7636	0.7542	0.9915	0.9868	0.9911
RMSE	0.1548	0.1034	0.1054	0.0198	0.0236	0.0218




Şekil 7.17. Yıllık tahminleme performans grafiği


Şekil 7.18 – 23’de tüm modellere ait yıllık tahminlenen rüzgar hızları değişimlerinin gerçek rüzgar hızı değişimleri ile kıyaslanması gösterilmektedir.




Şekil 7.18. CNN-GRU tahmin grafiği




Şekil 7.19. CNN-LSTM tahminleme grafiği




Şekil 7.20. CNN-RNN tahminleme grafiği



Şekil 7.21. LSTM-GRU tahminleme grafiği




Şekil 7.22. GRU tahminleme grafiği



Şekil 7.23. LSTM tahminleme grafiği

Bununla birlikte gerçek rüzgar hızı verileri ile tahminlenen rüzgar hızı verilerinin toplu değişim Şekil 7.24’de gösterilmektedir. Şekil 7.24 incelendiğinde önerilen modelin gerçek rüzgar hızı verileri değişimine daha yakın bir trend sergilediği görülmektedir.



Şekil 7.24. Tüm modellerin kıyaslama grafiği

8) SONUÇLAR

Günümüz tüketim toplumlarında, enerji son derece önemli bir yere sahiptir. Toplumların kalkınması ve sürdürülebilir bir yaşam için enerjiye ihtiyaç duyulmaktadır. Artan enerji taleplerinin karşılanabilmesi için ekonomik ve çevre dostu yaklaşımların kullanıldığı birçok başarılı model günümüzde oldukça önemli bir noktaya gelmiştir. Özellikle enerji ihtiyacının büyük bir kısmının karşılanması için sınırlı rezervlere sahip fosil temelli yakıtlar kullanılmaktadır. Bu sınırlı olan kaynaklara alternatifi olarak daha çevreci ve sürdürülebilir olan yenilenebilir enerji kaynakları gösterilmektedir. Dolayısıyla yenilenebilir enerji alanında son yıllarda çok önemli çalışmalar ve ilerlemeler kaydedilmiştir. Bu kaynaklar içerisinde yer alan rüzgar enerjisinin sahip olduğu avantajları göz önünde bulundurulduğunda diğer kaynaklara göre daha çok tercih edildiği görülmektedir. Özellikle kaotik bir davranış sergileyen rüzgar enerjisi için elektrik üretiminde, bilhassa sistem girdisi olan rüzgar hızının tahminlenmesi son derece önemli bir yere sahiptir. Bu durum rüzgar enerjisinin daha verimli kullanılabilmesi için rüzgar hızı tahminlemesi alanında araştırmacıların farkı ve faydalı modelleri geliştirmesine imkan sağlamaktadır. Dolayısıyla bu çalışmada derin öğrenme yöntemlerinden faydalanılarak rüzgar hızı tahminlemesi için ilk defa kullanılan hibrit bir tahminleme modeli önerilmiştir.

Bu çalışmada kullanılan rüzgar hızı verileri Tokat Gaziosmanpaşa Üniversitesi Mühendislik ve Mimarlık Fakültesi yerleşkesinde kurulan ölçüm istasyonundan toplanmıştır. Bu veriler 2018-2020 yılları aralığında olup 1'er saatlik zaman dilimleri ile ölçülmüştür. Birbirinden bağımsız olarak 3 ayrı vaka çalışması kurgulanmış olup, ilk vaka çalışmasında haftalık tahminlemeler gerçekleştirilmiştir. Kullanılan verilerden 3 yıla ait haftalık verilerin ortalaması alınarak toplam 48 haftalık bir veri seti oluşturulmuştur. Benzer şekilde ikinci vaka çalışmasını oluşturan aylık tahminleme işleminde de 12 aylık veri seti oluşturulmuştur. Son vaka çalışması olan yıllık rüzgar hızı tahminlemesi için 3 yıla ait olan verinin tamamı yıllık veri setinde kullanılmıştır. Önerilen hibrit model iki boyutlu CNN ile GRU ağlarının birleştirilmesi ile elde edilmiştir. Önerilen hibrit model 3 vaka çalışmasında da ayrı ayrı tahminleme işleminde kullanılmış ve bu vaka çalışmalarında göstermiş olduğu performans, belirlenen performans kriterlerine göre (MAPE, R^2 , RMSE) değerlendirilmiştir. Ayrıca önerilen modelin performansının yorumlanmasının daha anlamlı olması açısından literatürde yer alan 5 farklı derin öğrenme modeliyle (CNN-LSTM, CNN-RNN, LSTM-GRU, GRU, LSTM) kıyaslanması gerçekleştirilmiştir.

Birinci vaka çalışmasını oluşturan haftalık rüzgar hızı tahminle işleminde elde edilen sonuçlarda hibrit modelin daha doğru ve güvenilir sonuçlar sergilediği gözlenmiştir (MAPE: 0.1106, RMSE: 0.0306, R^2 : 0.9841).

İkinci vaka çalışmasını oluşturan ayık rüzgar hızı tahminlemede de önerilen hibrit modelin diğer modellere kıyasla daha iyi performans sergilediği elde edilen performans kriterlerine göre açıkça görülmektedir (MAPE: 0.0409, RMSE: 0.0127, R^2 : 0.9977). Aylık rüzgar hızı tahminlemede karşılaştırma amaçlı kullanılan bazı modellerde (LSTM-GRU, LSTM, GRU) yapının tahminlemeden ziyade ezberlemeye gittiği gözlemlenmiştir.

Son vaka çalışmasını oluşturan yıllık rüzgar hızı tahminleme çalışmasında da önerilen hibrit model daha iyi tahminleme işlemi gerçekleştirmiştir. Özellikle elde edilen performans kriterleri sonuçlarına bakıldığında (MAPE: 0.5324, RMSE: 0.0198, R^2 : 0.9915) yine diğer modellere kıyasla yüksek regresyon değerine sahip olduğu belirlenmiştir. Aylık rüzgar hızı tahminlemede olduğu gibi yıllık tahminleme işleminde de bazı modellerin ezberleme yaptığı gözlemlenmiştir.

Bu tez çalışmasında rüzgar hızı tahminlemesi için ilk defa önerilen hibrit modelin daha başarılı sonuçlar sergilediği görülmüştür. Özellikle elde edilen sonuçlar literatürde kullanılan diğer modellerle de kıyaslanarak doğrulama işlemi yapılmıştır. Çalışmada elde edilen önemli çıkarımlardan biri özellikle rüzgar hızı tahminlemesi alanında tercih edilecek modellerin bağımsız kullanılmasının daha yüksek hata sonuçlarını doğurduğudur. Bir başka ifade ile hibrit tahminleme modellerinin daha çok tercih edilmesi gerekliliğinin vurgulanmasıdır. Bu nedenle ilerleyen dönemlere ait planlanan çalışmalarda önerilen tahminleme modeline ek olarak verilere uygulanacak farklı veri ön işleme yöntemleri ile performans değerlendirilmesinin yapılması planlanmaktadır.

9) KAYNAKÇA

- Abedinia, O., Bagheri, M., Naderi, M. S. ve Ghadimi, N., 2020. A new combinatory approach for wind power forecasting. *IEEE Systems Journal*, 14(3), 4614-4625.
- Acaroğlu, M., 2003. *Alternatif Enerji Kaynakları*. İstanbul: Nobel Yayınevi, 622 s, İstanbul.
- Aggarwal, S. K. ve Gupta, M., 2013. Wind power forecasting: A review of statistical models-wind power forecasting. *International Journal of Energy Science*, 3(1), 1-10.
- Ahmetoğlu, H. ve Resul, D., 2020. Türkçe Otel Yorumlarıyla Eğitilen Kelime Vektörü Modellerinin Duygu Analizi ile İncelenmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 24(2), 455-463.
- Albostan, A., Çekiç, Y. ve Levent, E., 2009. Rüzgâr enerjisinin Türkiye'nin Enerji arz güvenliğine etkisi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 24(4), 641-649.
- Allen, D. J., Tomlin, A. S., Bale, C. S. E., Skea, A., Vosper, S. ve Gallani, M. L., 2017. A boundary layer scaling technique for estimating near-surface wind energy using numerical weather prediction and wind map data. *Applied Energy*, 208(15), 1246-1257.
- Altan, A., Karasu, S. ve Zio, E., 2021. A new hybrid model for wind speed forecasting combining long short-term memory neural network, decomposition methods and grey wolf optimizer. *Applied Soft Computing*, 100(2021), 106996.
- Anonim 1, 2022. Hydropower Generation Industry: Top 20 Hydropower Producing Countries in the World 2020.
<https://blog.bizvibe.com/blog/uncategorized/top-hydropower-producing-countries> (17.02.2022).
- Anonim 2, 2022. Gelgit Enerjisi Nedir?.
<https://www.pnnl.gov/explainer-articles/tidal-energy#:~:text=Tidal%20energy%20is%20a%20form,the%20sun%2C%20and%20the%20moon.&text=Because%20water%20is%20denser%20than,turbine%20diameter%20and%20rotor%20speed.> (20.02.2022).
- Anonim 3, 2022. Yozgat Bozok Üniversitesi Web Sayfası.
https://pbs.bozok.edu.tr/indir.php?file_id=483#:~:text=Dalga%20enerjisi%2C%20r%C3%BCzgar%C4%B1n%20deniz%20ve,a%C5%9Fa%C4%9F%C4%B1%20hareket%20etmesine%20neden%20olur. (20.02.2022).
- Ayan, T. Y. ve Pabuçcu, H., 2013. Yenilenebilir Enerji Kaynakları Yatırım Projelerinin Analitik Hiyerarşi Süreci Yöntemi İle Değerlendirilmesi Evaluation Of The Renewable Energy Investment Project With Analytic. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(3), 89-110.
- Babu, N. R. ve Mohan, B. J., 2017. Fault classification in power systems using EMD and SVM. *Ain Shams Engineering Journal*, 8(2), 103-111.
- Bedi, J. ve Toshniwal, D., 2019. Deep learning framework to forecast electricity demand. *Applied Energy*, 238(2019), 1312-1326.

- Belavadi, S. V., Rajagopal, S., Ranjani, R. ve Mohan, R., 2020. Air Quality Forecasting using LSTM RNN and Wireless Sensor Networks. *Procedia Computer Science*, 170(2020), 241-248.
- Bengio, Y., Simard, P. ve Frasconi, P., 1994. Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, 5(2), 157-166.
- Bosch, J. L., Lopez, G. ve Batlles, F. J., 2008. Daily solar irradiation estimation over a mountainous area using artificial neural networks. *Renewable Energy*, 33(7), 1622-1628.
- Brownlee, J., 2018. Convolutional Neural Networks for Multi-Step Time Series Forecasting. <https://machinelearningmastery.com/how-to-develop-convolutional-neural-networks-for-multi-step-time-series-forecasting/> (28.04.2022).
- Cadenas, E., ve Rivera, W., 2007. Wind speed forecasting in the south coast of Oaxaca, Mexico. *Renewable Energy*, 32(12), 2116-2128.
- Cadenas, E. ve Rivera, W., 2010. Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA–ANN model. *Renewable Energy*, 35(12), 2732-2738.
- Capizzi, G., Napoli, C. ve Bonanno, F., 2012. Innovative second-generation wavelets construction with recurrent neural networks for solar radiation forecasting. *IEEE Transactions on neural networks and learning systems*, 23(11), 1805-1815.
- Carcagni, P., Cuna, A. ve Distanto, C., 2018. A Dense CNN approach for skin lesion classification. *arXiv preprint arXiv:1807.06416*.
- Chandran, V., Patil, C. K., Manoharan, A. M., Ghosh, A., Sumithra, M. G., Karthick, A., Rahim, R. ve Arun, K., 2021. Wind power forecasting based on time series model using deep machine learning algorithms. *Materials Today: Proceedings*, 47(2021), 115-126.
- Chang, W. Y., 2014. A literature review of wind forecasting methods. *Journal of Power and Energy Engineering*, 2(04), 161-168.
- Cheng, L., Zang, H., Ding, T., Sun, R., Wang, M., Wei, Z. ve Sun, G., 2018. Ensemble recurrent neural network based probabilistic wind speed forecasting approach. *Energies*, 11(8), 1958.
- Chung, J., Gulcehre, C., Cho, K. ve Bengio, Y., 2014. Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:1412.3555*.
- Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Meteoroloji Genel Müdürlüğü, 2022. Türkiye rüzgar atlası. <https://www.mgm.gov.tr/genel/ruzgar-atlasi.aspx> (15.02.2022).
- Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Meteoroloji Genel Müdürlüğü, 2022. Türkiye ortalama güneşlenme haritası. <https://mgm.gov.tr/kurumici/turkiye-guneslenme-suresi.aspx> (16.02.2022).
- Çevre, Şehircilik ve İklim Değişikliği Bakanlığı Meteoroloji Genel Müdürlüğü, 2022. Türkiye aylık ortalama güneşlenme süresi.

- <https://mgm.gov.tr/kurumici/turkiye-guneslenme-suresi.aspx> (16.02.2022).
- De Giorgi, M. G., Ficarella, A. ve Tarantino, M., 2011. Error analysis of short term wind power prediction models. *Applied Energy*, 88(4), 1298-1311.
- Demir, İ., 2019. Farklı Regresyon Modelleri Kullanarak Etkin Parametrelere Göre Rüzgar Hızı Tahminlemesi.(Yüksek Lisans Tezi), Tokat Gaziosmanpaşa Üniversitesi. Elektrik Elektronik Mühendisliği Anabilim Dalı, Tokat.
- Dey, R. ve Salem, F. M., 2017. Gate-variants of gated recurrent unit (GRU) neural networks. In 2017 IEEE 60th international midwest symposium on circuits and systems (MWSCAS), Boston.
- Ding, M., Zhou, H., Xie, H., Wu, M., Liu, K. Z., Nakanishi, Y. ve Yokoyama, R., 2021. A time series model based on hybrid-kernel least-squares support vector machine for short-term wind power forecasting. *ISA Transactions*, 108(2021), 58-68.
- Doğan, F. ve Türkoğlu, İ., 2019. Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445.
- ELDER, 2022. 2022 Yılı Cumhurbaşkanlığı Yıllık Programı Enerji Sektörü Özet Raporu. https://www.elder.org.tr/Content/edergi/2022%20YILI%20CUMHURBASKANLIGI%20YILLIK%20PROGRAMI_ENERJI%20SEKTORU%20OZETI.pdf (06.03.2022).
- Emeksiz, C. ve Fındık, M. M., 2021. Sürdürülebilir Kalkınma İçin Yenilenebilir Enerji Kaynaklarının Türkiye Ölçeğinde Değerlendirilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 155-164.
- Emeksiz, C. ve Tan, M., 2022. Multi-step wind speed forecasting and Hurst analysis using novel hybrid secondary decomposition approach. *Energy*, 238(2022), 121764.
- Enerji ve Tabii Kaynaklar Bakanlığı, 2022. Biyokütle. <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-biyokutle> (20.02.2022).
- Enerji ve Tabii Kaynaklar Bakanlığı, 2022. Hidrolik. <https://enerji.gov.tr/bilgi-merkezi-enerji-hidrolik> (17.02.2022).
- Erdem, E. ve Shi, J., 2011. ARMA based approaches for forecasting the tuple of wind speed and direction. *Applied Energy*, 88(4), 1405-1414.
- Feng, W., Guan, N., Li, Y., Zhang, X. ve Luo, Z. 2017. Audio visual speech recognition with multimodal recurrent neural networks. In 2017 International Joint Conference on Neural Networks (IJCNN), Anchorage.
- Gao, B., Huang, X., Shi, J., Tai, Y. ve Zhang, J., 2020. Hourly forecasting of solar irradiance based on CEEMDAN and multi-strategy CNN-LSTM neural networks. *Renewable Energy*, 162(2020), 1665-1683.
- Global Wind Energy Council (GWEC), 2021. Global Wind Energy Report 2021.

<https://gwec.net/global-wind-report-2021/> (24.02.2022).

- Görgel, P. ve Kavlak, E., 2020. Uzun kısa süreli hafıza ve evrimsel sinir ağları ile rüzgar enerjisi üretim tahmini. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 11(1), 69-80.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R. ve Schmidhuber, J., 2016. LSTM: A search space odyssey. IEEE transactions on neural networks and learning systems, 28(10), 2222-2232.
- Guo, Z., Zhao, W., Lu, H. ve Wang, J., 2012. Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model. Renewable Energy, 37(1), 241-249.
- Hamdan, M. A., Abdelhafez, E. ve Ghnaimat, O., 2017. Prediction of Hourly Solar Radiation in Amman-Jordan by Using Artificial Neural Networks. Int. J. of Thermal & Environmental Engineering, 14(2), 103-108.
- He, X., Chu, L., Qiu, R. C., Ai, Q., Ling, Z. ve Zhang, J., 2019. Invisible units detection and estimation based on random matrix theory. IEEE Transactions on Power Systems, 35(3), 1846-1855.
- Hochreiter, S. ve Schmidhuber, J., 1997. Long short-term memory. Neural computation, 9(8), 1735-1780.
- Hossain, M. A., Chakraborty, R. K., Elsayah, S. ve Ryan, M. J., 2021. Very short-term forecasting of wind power generation using hybrid deep learning model. Journal of Cleaner Production, 296(2021), 126564.
- Howard, T. ve Clark, P., 2007. Correction and downscaling of NWP wind speed forecasts. Meteorological Applications: A journal of forecasting, practical applications, training techniques and modelling, 14(2), 105-116.
- Hu, Q., Zhang, R. ve Zhou, Y., 2016. Transfer learning for short-term wind speed prediction with deep neural networks. Renewable Energy, 85(2016), 83-95.
- İnik, Ö. ve Ülker, E., 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri . Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6(3), 85-104.
- Jiang, P., Liu, Z., Niu, X. ve Zhang, L., 2021. A combined forecasting system based on statistical method, artificial neural networks, and deep learning methods for short-term wind speed forecasting. Energy, 217(2021), 119361.
- Kademli, M., 2021. Yenilenebilir Enerji Kaynaklarının Sürdürülebilir Kalkınma ve Ekonomik Büyümedeki Rolü ve Önemi. Yeni Türkiye, 27(117), 218-227.
- Kalogirou, S. A., 2001. Artificial neural networks in renewable energy systems applications: a review. Renewable and Sustainable Energy Reviews, 5(4), 373-401.
- Kamal, L. ve Jafri, Y. Z., 1997. Time series models to simulate and forecast hourly averaged wind speed in Quetta, Pakistan. Solar Energy, 61(1), 23-32.
- Karabağ, N., Kayıkcı, C. B. Ç. ve Öngen, A., 2021. % 100 Yenilenebilir Enerjiye Geçiş Yolunda Dünya ve Türkiye. Avrupa Bilim ve Teknoloji Dergisi, (21), 230-240.

- Kavasseri, R. G. ve Seetharaman, K., 2009. Day-ahead wind speed forecasting using f-ARIMA models. *Renewable Energy*, 34(5), 1388-1393.
- Kim, H., Park, M., Kim, C. W. ve Shin, D., 2019. Source localization for hazardous material release in an outdoor chemical plant via a combination of LSTM-RNN and CFD simulation. *Computers & Chemical Engineering*, 125(2019), 476-489.
- Kim, M., Choi, W., Jeon, Y. ve Liu, L., 2019. A hybrid neural network model for power demand forecasting. *Energies*, 12(5), 931.
- Koç, A., Yağlı, H., Yıldız, K. ve Uğurlu, İ., 2018. Dünyada ve Türkiye’de enerji görünümünün genel değerlendirilmesi. *Mühendis ve Makina*, 59(692), 86-114.
- Koç, E. ve Kaya, K., 2015. Enerji Kaynakları–Yenilenebilir Enerji Durumu. *Mühendis ve Makina*, 56(668), 36-47.
- Koç, E., ve Şenel, M. C., 2013. Dünyada ve Türkiye’de Enerji Durumu - Genel Değerlendirme, *Mühendis ve Makina*, 54(639), 32-44.
- Kostadinov, S., 2017. Understanding GRU Networks.
<https://towardsdatascience.com/understanding-gru-networks-2ef37df6c9be>
(06.05.2022).
- Kumbur, H., Özer, Z., Özsoy, D. H. ve Avcı, E. D., 2005. Türkiye’de Geleneksel ve Yenilenebilir Enerji Kaynaklarının Potansiyeli ve Çevresel Etkilerinin Karşılaştırılması. III. Yenilenebilir Enerji Kaynakları Sempozyumu ve Sergisi, Mersin.
- LeCun, Y., Bengio, Y. ve Hinton, G., 2015. Deep learning. *nature*, 521(7553), 436-444.
- Li, G. ve Shi, J., 2010. On comparing three artificial neural networks for wind speed forecasting. *Applied Energy*, 87(7), 2313-2320.
- Li, H., Wang, J., Lu, H. ve Guo, Z., 2018. Research and application of a combined model based on variable weight for short term wind speed forecasting. *Renewable Energy*, 116(2018), 669-684.
- Li, S., 2003. Wind power prediction using recurrent multilayer perceptron neural networks. In 2003 IEEE Power Engineering Society General Meeting, Toronto.
- Liu, H., Mi, X., Li, Y., Duan, Z. ve Xu, Y., 2019. Smart wind speed deep learning based multi-step forecasting model using singular spectrum analysis, convolutional Gated Recurrent Unit network and Support Vector Regression. *Renewable energy*, 143(2019), 842-854.
- Liu, H., Wu, H. ve Li, Y., 2018. Smart wind speed forecasting using EWT decomposition, GWO evolutionary optimization, RELM learning and IEWT reconstruction. *Energy Conversion and Management*, 161(2018), 266-283.
- Liu, Z., Jiang, P., Zhang, L. ve Niu, X., 2020. A combined forecasting model for time series: Application to short-term wind speed forecasting. *Applied Energy*, 259(2020), 114137.
- Livieris, I. E., Pintelas, E. ve Pintelas, P., 2020. A CNN–LSTM model for gold price time-series forecasting. *Neural Computing and Applications*, 32(23), 17351-17360.
- Mabel, M. C. ve Fernandez, E., 2008. Analysis of wind power generation and prediction using ANN: A case study. *Renewable Energy*, 33(5), 986-992.

- Mardani, A., Jusoh, A., Zavadskas, E. K., Cavallaro, F. ve Khalifah, Z., 2015. Sustainable and renewable energy: An overview of the application of multiple criteria decision making techniques and approaches. *Sustainability*, 7(10), 13947-13984.
- Mi, X. ve Zhao, S., 2020. Wind speed prediction based on singular spectrum analysis and neural network structural learning. *Energy Conversion and Management*, 216(2020), 112956.
- Mikolov, T., Karafiát, M., Burget, L., Cernocký, J. ve Khudanpur, S., 2010. Recurrent neural network based language model. In *Interspeech*, 2(3), 1045-1048.
- Moghaddamnia, A., Remesan, R., Kashani, M. H., Mohammadi, M., Han, D. ve Piri, J., 2009. Comparison of LLR, MLP, Elman, NNARX and ANFIS Models—with a case study in solar radiation estimation. *Journal of Atmospheric and Solar-Terrestrial Physics*, 71(8-9), 975-982.
- Moreno, S. R. ve dos Santos Coelho, L., 2018. Wind speed forecasting approach based on singular spectrum analysis and adaptive neuro fuzzy inference system. *Renewable Energy*, 126(2018), 736-754.
- Neshat, M., Nezhad, M. M., Abbasnejad, E., Mirjalili, S., Tjernberg, L. B., Garcia, D. A., Alexander, B. ve Wagner, M., 2021. A deep learning-based evolutionary model for short-term wind speed forecasting: A case study of the Lillgrund offshore wind farm. *Energy Conversion and Management*, 236(2021), 114002.
- Niu, Z., Yu, Z., Tang, W., Wu, Q. ve Reformat, M., 2020. Wind power forecasting using attention-based gated recurrent unit network. *Energy*, 196(2020), 117081.
- Olah, C., 2015. Understanding LSTM Networks.
<https://colah.github.io/posts/2015-08-Understanding-LSTMs/> (05.05.2022).
- Ouyang, T., Zha, X. ve Qin, L., 2017. A combined multivariate model for wind power prediction. *Energy Conversion and Management*, 144(2017), 361-373.
- PK, F. A., 1984. Learning Outcomes of Classroom Research. What is Artificial Intelligence?, Ed: Karthikeyan, J., Hie, T.S., ve Jin, N.Y. New Delhi, 65-73.
- Qian, Z., Pei, Y., Zareipour, H. ve Chen, N., 2019. A review and discussion of decomposition-based hybrid models for wind energy forecasting applications. *Applied Energy*, 235(2019), 939-953.
- Qin, Q., Lai, X. ve Zou, J., 2019. Direct multistep wind speed forecasting using LSTM neural network combining EEMD and fuzzy entropy. *Applied Sciences*, 9(1), 126.
- REN21, 2018. Yenilenebilir Enerji Küresel Durum Raporu 2021.
<https://www.ren21.net/reports/global-status-report/> (01.03.2022).
- Richter A., 2021. ThinkGeoEnergy's Top 10 Geothermal Countries 2020 – installed power generation capacity (MWe).
<https://www.thinkgeoenergy.com/thinkgeoenergys-top-10-geothermal-countries-2020-installed-power-generation-capacity-mwe/> (18.02.2022).

Rüzgar Gücü İzleme ve Tahmin Merkezi, 2022. Rüzgârdan Üretilen Elektriksel Güç İzleme ve Tahmin Sistemi Projesi.

<https://ritm.enerji.gov.tr/aboutUs/ritm.php> (19.03.2022).

Sajjad, M., Khan, Z. A., Ullah, A., Hussain, T., Ullah, W., Lee, M. Y. ve Baik, S. W., 2020. A novel CNN-GRU-based hybrid approach for short-term residential load forecasting. *Ieee Access*, 8, 143759-143768.

Sevli, O., 2019. Evrişimsel Sinir Ağları ile Bal Arısı Irklarının Tahminlenmesi. In *Proceedings on 2nd International Conference on Technology and Science*, Vienna.

Shahid, F., Zameer, A. ve Muneeb, M., 2021. A novel genetic LSTM model for wind power forecast. *Energy*, 223(2021), 120069.

Sideratos, G. ve Hatziargyriou, N. D., 2007. An advanced statistical method for wind power forecasting. *IEEE Transactions on Power Systems*, 22(1), 258-265.

Soman, S. S., Zareipour, H., Malik, O. ve Mandal, P., 2010. A review of wind power and wind speed forecasting methods with different time horizons. In *North American power symposium 2010*, Arlington.

Somuncu, E. ve Atasoy, N. A., 2022. Evrişimli tekrarlayan sinir ağı ile metin görüntüleri üzerinde karakter tanıma uygulaması gerçekleştirilmesi. *Journal of the Faculty of Engineering & Architecture of Gazi University*, 37(1), 17-27.

Song, J., Wang, J. ve Lu, H., 2018. A novel combined model based on advanced optimization algorithm for short-term wind speed forecasting. *Applied Energy*, 215(2018), 643-658.

Sözen, A., Menlik, T. ve Ünvar, S., 2008. Determination of efficiency of flat-plate solar collectors using neural network approach. *Expert Systems with Applications*, 35(4), 1533-1539.

Sun, N., Zhou, J., Chen, L., Jia, B., Tayyab, M. ve Peng, T., 2018. An adaptive dynamic short-term wind speed forecasting model using secondary decomposition and an improved regularized extreme learning machine. *Energy*, 165(2018), 939-957.

Tan, M., 2020. İkincil Ayırıştırma Tekniği Kullanarak Yapay Sinir Ağı Temelli Çok Adımlı Rüzgar Hızı Tahmini. (Yüksek Lisans Tezi), Tokat Gaziosmanpaşa Üniversitesi. Elektrik Elektronik Mühendisliği Anabilim Dalı, Tokat.

Torres, J. L., Garcia, A., De Blas, M. ve De Francisco, A., 2005. Forecast of hourly average wind speed with ARMA models in Navarre (Spain). *Solar Energy*, 79(1), 65-77.

Türkiye Cumhuriyeti Enerji ve Tabii Kaynaklar Bakanlığı, 2022.

<https://enerji.gov.tr/bilgi-merkezi-enerji-ruzgar> (13.02.2022).

Türkiye Doğalgaz Dağıtıcıları Birliği, 2016. Dünyada ve Türkiye’de Enerji Durumu.

<https://www.gazbir.org.tr/uploads/page/Dunya-ve-Turkiye-Enerji-Gorunumu.pdf> (22.04.2021).

Türkiye Elektrik İletim A.Ş., 2022. Türkiye kurulu güç raporu.

<https://www.teias.gov.tr/tr-TR/kurulu-guc-raporlari> (05.03.2022).

Türkoğlu, M., Hanbay, K., Sivrikaya, I. S. ve Hanbay, D., 2021. Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9(1), 334-345.

Visual Capitalist, 2022 Mapped: Solar Power by Country in 2021.

<https://www.visualcapitalist.com/mapped-solar-power-by-country-in-2021/> (16.02.2022).

Wang, J. ve Hu, J., 2015. A robust combination approach for short-term wind speed forecasting and analysis—Combination of the ARIMA (Autoregressive Integrated Moving Average), ELM (Extreme Learning Machine), SVM (Support Vector Machine) and LSSVM (Least Square SVM) forecasts using a GPR (Gaussian Process Regression) model. Energy, 93(2015), 41-56.

Wang, Y., Zou, R., Liu, F., Zhang, L. ve Liu, Q., 2021. A review of wind speed and wind power forecasting with deep neural networks. Applied Energy, 304(2021), 117766.

Worldometer, 2020. Energy.

<https://www.worldometers.info/energy/> (16.05.2021).

Wu, L., Kong, C., Hao, X. ve Chen, W., 2020. A short-term load forecasting method based on GRU-CNN hybrid neural network model. Mathematical Problems in Engineering, 2020.

Yang, B., Yu, T., Shu, H., Dong, J. ve Jiang, L., 2018. Robust sliding-mode control of wind energy conversion systems for optimal power extraction via nonlinear perturbation observers. Applied Energy, 210(2018), 711-723.

Yang, B., Zhang, X., Yu, T., Shu, H. ve Fang, Z., 2017. Grouped grey wolf optimizer for maximum power point tracking of doubly-fed induction generator based wind turbine. Energy Conversion and Management, 133(2017), 427-443.

Yang, B., Zhong, L., Wang, J., Shu, H., Zhang, X., Yu, T. ve Sun, L., 2021. State-of-the-art one-stop handbook on wind forecasting technologies: An overview of classifications, methodologies, and analysis. Journal of Cleaner Production, 283(2021), 124628.

Yang, Z. ve Wang, J., 2018. A combination forecasting approach applied in multistep wind speed forecasting based on a data processing strategy and an optimized artificial intelligence algorithm. Applied Energy, 230(2018), 1108-1125.

Yapar, M., 2014. Türkiye’de İktisat Politikaları Çerçevesinde Rüzgar Enerjisi Politikalarının Etkinliğinin Analizi: Bir Uygulama (Yüksek Lisans Tezi). İstanbul Üniversitesi. Sosyal Bilimler Enstitüsü, İstanbul.

Yayla, S. ve Harmanci, E., 2021. Estimation of target station data using satellite data and deep learning algorithms. International Journal of Energy Research, 45(1), 961-974.

Yu, J., Zhang, X., Xu, L., Dong, J. ve Zhangzhong, L., 2021. A hybrid CNN-GRU model for predicting soil moisture in maize root zone. Agricultural Water Management, 245(2021), 106649.

- Yüksel,A., 2020. Yenilikçi Hibrit Çok Kriterli Karar Verme Yaklaşımı Yöntemi Kullanarak Sürdürülebilir Biyoenerji Üretim Tesisi İçin Uygun Yer Seçimi.(Yüksek Lisans Tezi), Tokat Gaziosmanpaşa Üniversitesi. Elektrik Elektronik Mühendisliği Anabilim Dalı, Tokat.
- Zafar, M. W., Shahbaz, M., Sinha, A., Sengupta, T. ve Qin, Q., 2020. How renewable energy consumption contribute to environmental quality? The role of education in OECD countries. *Journal of Cleaner Production*, 268(2020), 122149.
- Zang, H., Liu, L., Sun, L., Cheng, L., Wei, Z. ve Sun, G., 2020. Short-term global horizontal irradiance forecasting based on a hybrid CNN-LSTM model with spatiotemporal correlations. *Renewable Energy*, 160(2020), 26-41.
- Zeroual, A., Harrou, F., Dairi, A. ve Sun, Y., 2020. Deep learning methods for forecasting COVID-19 time-Series data: A Comparative study. *Chaos, Solitons & Fractals*, 140(2020), 110121.
- Zhao, X., Jiang, N., Liu, J., Yu, D. ve Chang, J., 2020. Short-term average wind speed and turbulent standard deviation forecasts based on one-dimensional convolutional neural network and the integrate method for probabilistic framework. *Energy Conversion and Management*, 203(2020), 112239.

ÖZGEÇMİŞ

