

T.C.
BİNGÖL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DERİN ÖĞRENME YÖNTEMİ İLE BİNGÖL İLİNİN RÜZGÂR HIZI
TAHMİNİ

YÜKSEK LİSANS TEZİ

KADER OZAN

YENİLENEBİLİR ENERJİ SİSTEMLERİ ANABİLİM DALI

TEZ DANIŞMANI
Dr. Öğr. Üyesi. Dursun ÖZTÜRK

BİNGÖL-2024

ÖNSÖZ

Bu tezin konusunu belirlemede, deneysel çalışmaların yönlendirilmesinde, sonuçların değerlendirilmesi ve yazımı aşamasında yardımlarını ve bilgi birikimini esirgemeyen, çalışmaların tamamlanabilmesi için gerekli desteği veren danışman hocam Dr. Öğr. Üyesi Dursun ÖZTÜRK'e çok teşekkür ederim. Yüksek lisans eğitimim ve tez çalışma sürem boyunca bilgilerini ve yardımlarını eksik etmeyen değerli hocalarım Doç. Dr. Ömer Faruk ALÇİN ile Doç. Dr. Muzaffer ASLAN'a da teşekkür ederim. Tez çalışmasında kullanılan verileri sağlayan Bingöl Meteoroloji Müdürlüğü yönetimine katkılarından dolayı teşekkür ederim.

Bu günlere gelmemde emekleri olan, benim için çok fedakârlık yapan ve dualarını esirgemeyen aileme, tezin hazırlanması sırasında gösterdikleri sabır, fedakârlık ve desteklerinden dolayı teşekkür ederim. Ve sevgili arkadaşlarım, her zaman her koşulda desteğinizle yanımda olduğunuz için teşekkür ederim.

KADER OZAN

Bingöl 2024

İÇİNDEKİLER

ÖNSÖZ.....	i
İÇİNDEKİLER.....	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	iv
ŞEKİLLER LİSTESİ.....	vi
TABLolar LİSTESİ.....	ix
ÖZET.....	x
ABSTRACT.....	xi
1. GİRİŞ.....	1
2. KAYNAK ÖZETLERİ.....	5
3. RÜZGÂR ENERJİSİ.....	12
3.1. Türkiye’de Rüzgâr Enerjisi.....	12
3.2. Rüzgâr Türbinleri.....	14
3.2.1. Rüzgâr Türbinlerinin Sınıflandırılması.....	16
3.2.1.1. Eksenlerine Göre Rüzgâr Türbinleri.....	16
3.2.1.2. Kanat Sayısına Göre Rüzgâr Türbinleri	16
3.2.2. Rüzgâr Türbinlerinde Güç Kontrol Sistemleri.....	17
3.2.3. Rüzgâr Türbinlerinin Aerodinamiği.....	17
3.2.4. Rüzgâr Türbinlerinde Güç Üretimi.....	20
3.2.5. Rüzgâr Türbinlerinin Güç Eğrisi.....	22
4. 4. DERİN ÖĞRENME İLE TAHMİN YÖNTEMLERİ.....	24
4.1. Yapay Sinir Ağları.....	24
4.1.1. Yapay Sinir Ağlarında Öğrenme.....	26
4.2. Makine Öğrenmesi.....	27
4.3. Derin Öğrenme.....	28
4.3.1. Evrişimli Sinir Ağları (Convolutional Neural Network – CNN).....	28
4.3.2. Tekrarlayan Sinir Ağları (Recurrent Neural Network – RNN).....	29
4.3.3. Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory – LSTM)..	30
5. MATERYAL VE YÖNTEM.....	32

6. BULGULAR VE TARTIŞMA.....	39
6.1. Bir Saatlik Tahmin Sonuçları.....	39
6.2. Üç Saatlik Tahmin Sonuçları.....	42
6.3. Altı Saatlik Tahmin Sonuçları.....	45
6.4. Dokuz Saatlik Tahmin Sonuçları.....	48
6.5. On İki Saatlik Tahmin Sonuçları.....	51
7. SONUÇ VE ÖNERİLER.....	56
KAYNAKLAR.....	57
ÖZGEÇMİŞ.....	63

SİMGELER VE KISALTMALAR LİSTESİ

YSA	: Yapay Sinir Ağları
CNN	: Evrişimsel Sinir Ağları
RNN	: Tekrarlayan Sinir Ağları
LSTM	: Uzun – Kısa Süreli Hafıza Ağları
AE	: Otomatik Kodlayısı
RBM	: Kısıtlamalı Boltzman Makinesi
DBN	: Derin İnanç Ağları
I	: Akım
V, U	: Gerilim
$V_{uç}$: Kanat uç hızı
P	: Güç
P_R	: Rotor gücü
ρ	: Havanın yoğunluğu
λ	: Uç hız oranı
C_p	: Güç katsayısı
ω	: Kanat açısal hızı
R	: Kanat yarıçapı
r	: Aerofoilin kanat üzerindeki konumuna bağlı olarak değişen örnek yarıçapı
θ	: Kanat açısı
α	: Hücüm açısı
F_L	: Kaldırma kuvveti
F_D	: Sürüklenme kuvveti
C_L	: Kaldırma katsayısı
C_D	: Sürüklenme katsayısı
A_c	: Kanadın dik kesit alanı
E_K	: Kinetik enerji
m	: Kütle
\dot{m}	: Kütlesel debi

kW	: Kilowatt
SO ₂	: Kükürt dioksit
NO _x	: Nitrojen oksitler
CO ₂	: Karbondioksit
kWh	: Kilowatt saat
t	: Zaman
wh	: Watt saat
VMD	: Varyasyonel Mod Ayırıştırması
RMSE	: Kök Ortalama Kare Hatası
R^2	: Determinasyon Katsayısı
MAE	: Ortalama Mutlak Hata
YEK	: Yenilenebilir Enerji Kaynakları
TEİAŞ	: Türkiye Elektrik İletim Anonim Şirketi
EÜAŞ	: Elektrik Üretim Anonim Şirketi
REPA	: Rüzgâr Enerjisi Potansiyel Atlası
RES	: Rüzgâr Enerji Santrali

ŞEKİLLER LİSTESİ

Şekil 3.1.	Yıllık ortalama rüzgâr hızı dağılımı-100m.....	13
Şekil 3.2.	Türkiye’de 2021 yılı itibariyle RES’lerin bölgelere göre dağılımı	14
Şekil 3.3.	Rüzgâr türbinin iç yapısı	15
Şekil 3.4.	Rüzgâr türbini kanat uç-hız oranı	18
Şekil 3.5.	Rüzgâr türbini kanat açısı	19
Şekil 3.6.	Farklı kanat açılarına bağlı olarak değişen güç katsayısı ve uç-hız oranı eğrileri	20
Şekil 3.7.	Rüzgâr türbinlerinde enerji akışı	21
Şekil 3.8.	Rüzgâr türbinlerinin güç eğrisi	22
Şekil 4.1.	Yapay sinir ağı	24
Şekil 4.2.	Yapay sinir hücresi	25
Şekil 4.3.	Çok katmanlı ileri beslemeli sinir ağı mimarisi	26
Şekil 4.4.	Çok katmanlı geri beslemeli sinir ağı mimarisi	27
Şekil 4.5.	CNN mimarisi	29
Şekil 4.6.	RNN mimarisi	30
Şekil 4.7.	LSTM mimarisi.....	31
Şekil 5.1.	2020 yılı Ocak ayı rüzgâr hızı verileri	32
Şekil 5.2.	CNN Ağ Yapısı	34
Şekil 5.3.	VMD ile rüzgâr hızı verilerinin görüntüye dönüştürülmesi.	34
Şekil 5.4.	Bir saat ilerisi için tahmin üretme yöntemi	36
Şekil 5.5.	Üç saat ilerisi için tahmin üretme yöntemi	37
Şekil 5.6.	Altı saat ilerisi için tahmin üretme yöntemi	37
Şekil 5.7.	Dokuz saat ilerisi için tahmin üretme yöntemi	38
Şekil 5.8.	On iki saat ilerisi için tahmin üretme yöntemi	38
Şekil 6.1.	Bir saat ileri zamanlı rüzgâr hızı tahmini için kullanılan CNN ağı eğitim modeli	39

Şekil 6.2.	CNN modeli ile bir saat ileri zamanlı rüzgâr hızı tahmin grafiği (02.01.2020-01.02.2021)	40
Şekil 6.3.	CNN modeli ile bir saat ileri zamanlı rüzgâr hızı tahmin grafiği (25-31.05.2020)	41
Şekil 6.4.	CNN modeli ile bir saat ileri zamanlı rüzgâr hızı tahmin grafiği (05.06.2020)	41
Şekil 6.5.	CNN modeli ile bir saat ileri zamanlı rüzgâr hızı tahmin grafiği (01-31.12.2020)	42
Şekil 6.6.	Üç saat ileri zamanlı rüzgâr hızı tahmini için kullanılan CNN ağı eğitim modeli	42
Şekil 6.7.	CNN modeli ile üç saat ileri zamanlı rüzgâr hızı tahmin grafiği (02.01.2020-01.02.2021)	43
Şekil 6.8.	CNN modeli ile üç saat ileri zamanlı rüzgâr hızı tahmin grafiği (25-31.05.2020)	44
Şekil 6.9.	CNN modeli ile üç saat ileri zamanlı rüzgâr hızı tahmin grafiği (05.06.2020)	44
Şekil 6.10.	CNN modeli ile üç saat ileri zamanlı rüzgâr hızı tahmin grafiği (01-31.12.2020)	45
Şekil 6.11.	Altı saat ileri zamanlı rüzgâr hızı tahmini için kullanılan CNN ağı eğitim modeli	45
Şekil 6.12.	CNN modeli ile altı saat ileri zamanlı rüzgâr hızı tahmin grafiği (02.01.2020-01.02.2021)	46
Şekil 6.13.	CNN modeli ile altı saat ileri zamanlı rüzgâr hızı tahmin grafiği (25-31.05.2020)	47
Şekil 6.14.	CNN modeli ile altı saat ileri zamanlı rüzgâr hızı tahmin grafiği (05.06.2020)	47
Şekil 6.15.	CNN modeli ile altı saat ileri zamanlı rüzgâr hızı tahmin grafiği (01-31.12.2020)	48
Şekil 6.16.	Dokuz saat ileri zamanlı rüzgâr hızı tahmini için kullanılan CNN ağı eğitim modeli	48
Şekil 6.17.	CNN modeli ile dokuz saat ileri zamanlı rüzgâr hızı tahmin grafiği (02.01.2020-01.02.2021)	49

Şekil 6.18.	CNN modeli ile dokuz saat ileri zamanlı rüzgâr hızı tahmin grafiği (25-31.05.2020)	50
Şekil 6.19.	CNN modeli ile dokuz saat ileri zamanlı rüzgâr hızı tahmin grafiği (05.06.2020)	50
Şekil 6.20.	CNN modeli ile dokuz saat ileri zamanlı rüzgâr hızı tahmin grafiği (01-31.12.2020)	51
Şekil 6.21.	On iki saat ileri zamanlı rüzgâr hızı tahmini için kullanılan CNN ağı eğitim modeli	51
Şekil 6.22.	CNN modeli ile on iki saat ileri zamanlı rüzgâr hızı tahmin grafiği (02.01.2020-01.02.2021)	52
Şekil 6.23.	CNN modeli ile on iki saat ileri zamanlı rüzgâr hızı tahmin grafiği (25-31.05.2020)	53
Şekil 6.24.	CNN modeli ile on iki saat ileri zamanlı rüzgâr hızı tahmin grafiği (05.06.2020)	53
Şekil 6.25.	CNN modeli ile on iki saat ileri zamanlı rüzgâr hızı tahmin grafiği (01-31.12.2020)	54

TABLolar LİSTESİ

Tablo 6.1.	1 saat ileri zamanlı rüzgâr hızı tahmini hata oranları	40
Tablo 6.2.	3 saat ileri zamanlı rüzgâr hızı tahmini hata oranları	43
Tablo 6.3.	6 saat ileri zamanlı rüzgâr hızı tahmini hata oranları	46
Tablo 6.4.	9 saat ileri zamanlı rüzgâr hızı tahmini hata oranları	49
Tablo 6.5	On iki saat ileri zamanlı rüzgâr hızı tahmini hata oranları	52
Tablo 6.6	Rüzgâr hızı tahmini için tüm zamanlarda elde edilen hata oranlarının karşılaştırılması	54

DERİN ÖĞRENME YÖNTEMİ İLE BİNGÖL İLİNİN RÜZGÂR HIZI TAHMİNİ

ÖZET

Enerji talebindeki küresel artış, ülkelerin yenilenebilir enerji kaynaklarına yönelme ve bu kaynakları en etkili şekilde kullanma çabalarını beraberinde getirmiştir. Bu nedenle, hayatın her alanında var olan ve yaşamı kolaylaştıran teknolojik imkanların kullanılması, bu arayışta önemli bir role sahiptir. Yapılan çalışmalar, teknolojinin yenilenebilir enerji kaynaklarını etkili bir biçimde kullanabilme yeteneğini ve hatta kullanmaya başlamadan önce ne kadar enerji üretilebileceği konusunda öngöründe bulunabilme potansiyelini ortaya koymuştur.

Rüzgâr hızını ve dolayısıyla rüzgârdan elde edilecek gücü tahmin edebilmek oldukça güçtür. Doğası gereği kararsızdır ve birçok parametreye bağlı olarak değişiklik gösterebilmektedir. Zaman, mevsim, sıcaklık, nem ve hava durumu gibi birçok etken rüzgâr hızını etkileyen faktörlerdir. Bu yüzden rüzgârdan üretilebilecek enerjiyi önceden doğru bir şekilde tahmin edebilmek enerji üreticileri için önemli bir konudur. Üretim planlaması için en düşük hata payı ile en iyi tahminin yapılabilmesi gerekmektedir.

Günümüzde bu şartlarda rüzgâr gücü ve rüzgâr hızı tahmini yapabilecek en iyi yöntem derin öğrenme yöntemleri ile yapılan tahminlerdir. Bölgenin önceki dönemlere ait rüzgâr hızı verileri ile eğitilen derin öğrenme mimarileri ile geleceğe dair rüzgâr hızı tahminleri yapılabilmektedir. Bu çalışmada da Bingöl iline ait belli tarih aralığındaki rüzgâr hızı verileri Evrişimsel Sinir Ağı (Convolutional Neural Network-CNN) modeli ile işlenmiş ve kısa vadeli rüzgâr hızı tahmini yapılmıştır.

Tez çalışmasında Bingöl Meteoroloji Müdürlüğünden alınan, Bingöl iline ait 01.01.2020 ile 01.02.2021 tarihleri arasında ölçülen rüzgâr hızı verilerini derin öğrenme yöntemleri ile işlenerek, kısa vadeli rüzgâr hızı tahmini yapılmıştır. Çalışma bölgenin rüzgâr potansiyeli hakkında ve üretilebilecek rüzgâr gücü hakkında bilgi vermektedir.

Çalışma sonucunda bir derin öğrenme yöntemi olan CNN modeli, bölgeye ait geçmiş dönem rüzgâr hızı verileri ile eğitilmiş ve bölgenin gelecek zamana ait rüzgâr hızının nasıl olacağı hakkında ürettiği tahminler gözlemlenmiştir. Yapılan çalışma enerji yatırımcıları ve araştırmacılar tarafından birçok alanda kullanılmak üzere bölgenin rüzgâr potansiyeli hakkında bilgi vermektedir.

Anahtar Kelimeler: Derin Öğrenme, Evrişimsel Sinir Ağları, Rüzgâr Hızı Tahmini, Rüzgâr Türbini.

WIND SPEED ESTIMATION OF BINGOL PROVINCE WITH DEEP LEARNING METHOD

ABSTRACT

The global increase in energy demand has brought about the efforts of countries to turn to renewable energy sources and use these resources in the most effective way. Therefore, the use of technological opportunities that exist in every aspect of life and make life easier has an important role in this search. Studies have demonstrated the technology's ability to effectively use renewable energy sources and even its potential to predict how much energy can be generated before using them.

It is very difficult to predict the wind speed and therefore the power to be obtained from the wind. It is unstable in nature and can vary depending on many parameters. Many factors such as time, season, temperature, humidity, and weather conditions affect wind speed. Therefore, being able to accurately predict the energy that can be produced from wind is an important issue for energy producers. For production planning, it is necessary to make the best estimate with the lowest margin of error.

Today, the best method to estimate wind power and wind speed under these conditions is predictions made with deep learning methods. Future wind speed predictions can be made with deep learning architectures trained with the wind speed data of the region from previous periods. In this study, the wind speed data of Bingöl province within a certain date range was processed with the Convolutional Neural Network (CNN) model and a short-term wind speed forecast was made.

In the thesis study, short-term wind speed prediction was made by processing the wind speed data measured between 01.01.2020 and 01.02.2021 of Bingöl province, obtained from Bingöl Meteorology Directorate, with deep learning methods. The study provides information about the wind potential of the region and the wind power that can be produced.

As a result of the study, the CNN model, which is a deep learning method, was trained with past wind speed data of the region and the predictions it produced about the future wind speed of the region were observed. The study provides information about the wind potential of the region to be used in many areas by energy investors and researchers.

Keywords: Deep learning, Convolutional Neural Network, Estimation of Wind Speed, Wind Turbine.

1. GİRİŞ

Enerji, günümüzde modern toplumların vazgeçilmez bir temel unsurudur ve küresel düzeyde ekonomik kalkınma, sosyal ilerleme ve teknolojik yeniliklerin ana itici gücüdür. Bu nedenle, enerjinin önemi, gün geçtikçe artan bir şekilde vurgulanmakta ve küresel düzeyde stratejik bir konu haline gelmektedir. Günümüzde, enerji bir ülkenin kalkınma düzeyini belirleyen en önemli bir faktör olarak öne çıkmaktadır. Nüfus artışı, kentleşme ve endüstrileşme gibi faktörler, enerjiye olan ihtiyacı daha da artırmaktadır. Ancak, bu ihtiyacı karşılamak için kullanılan enerji kaynaklarının sürdürülebilirliği konusunda endişeler de gün geçtikçe artmaktadır.

Enerji, sadece ekonomik değil, aynı zamanda çevresel ve sosyal boyutlarıyla da yakından ilişkilidir. Uluslararası Enerji Ajansı'nın 2021 verilerine göre, küresel enerji tüketiminin yaklaşık %80'i fosil yakıtlardan sağlanmaktadır [1]. Fosil yakıtların çıkarılması, işlenmesi ve kullanılması sürecinde karbon dioksit (CO₂), kükürt dioksit (SO₂), nitrojen oksitler (NO_x) ve partikül madde gibi hava kirleticiler ortaya çıkmaktadır. Bu gazlar, küresel ısınmaya ve iklim değişikliğine katkıda bulunarak deniz seviyelerinin yükselmesi, aşırı hava olayları ve asit yağmurları gibi çeşitli olumsuz çevresel etkilere yol açmaktadır [2]. Ayrıca, solunum problemleri, kalp-damar hastalıkları ve diğer sağlık sorunlarına yol açarak insan sağlığı üzerinde zararlı etkileri bulunmaktadır [3].

Fosil yakıtlar, kömür, petrol ve doğal gaz gibi, milyonlarca yıl süren jeolojik süreçler sonucu oluşan sonlu kaynaklardır. Bu nedenle, fosil yakıtlara olan aşırı bağımlılık, gelecekteki enerji güvenliği açısından ciddi bir endişe kaynağıdır [4,5]. Fosil yakıtlara olan bu güçlü bağımlılık, jeopolitik çatışmaları tetikleyebilir ve enerji arzında kırılganlıklara neden olarak bir ülkenin enerji bağımsızlığını sınırlayabilir [6]. Ayrıca zaman zaman meydana gelen fiyat dalgalanmaları endüstrileri, işletmeleri ve tüketicileri ekonomik açıdan olumsuz etkileyebilmektedir.

Yukarıda sayılan tüm bu dezavantajların ortadan kaldırılması için daha temiz ve yenilenebilir enerji kaynaklarına geçiş büyük önem taşımaktadır. Yenilenebilir enerji;

güneş, rüzgâr, hidroelektrik, jeotermal ve biyokütle gibi doğal kaynaklardan elde edilen enerjiyi ifade etmektedir. Bu kaynaklar, sınırlı olmayan ve çevresel etkileri daha düşük olan enerji seçenekleri sunar. Özellikle karbon salınımını azaltarak atmosferdeki sera gazlarının etkilerini hafifletme potansiyeline sahiptir. Ayrıca, enerji arzını çeşitlendirmek, enerji güvenliğini artırmak ve sonlu olan fosil yakıt rezervlerine olan bağımlılığı azaltmak için etkili bir stratejidir. Bu, uzun vadeli sürdürülebilir enerji politikalarının temelini oluşturabilir. Tüm bu üstün özellikler, yenilenebilir enerji kaynaklarına olan ilgiyi artırmıştır.

Yenilenebilir ve temiz enerji kaynakları arasında öne çıkan rüzgâr enerjisi, çevresel sürdürülebilirlik, enerji güvenliği ve ekonomik avantajlarıyla küresel ölçekte önemli bir rol oynamaktadır. Rüzgâr türbinleri, elektrik üretimi sırasında sera gazı salınımını önemli ölçüde azaltarak iklim değişikliğiyle mücadelede etkili bir araç olabilir. Rüzgâr enerjisi, aynı zamanda yerli kaynaklardan elde edilen bir enerji türüdür. Ülkeler, rüzgâr enerjisi projelerini geliştirerek enerji arzlarını çeşitlendirebilir ve dışa bağımlılıklarını azaltabilirler. Bu da enerji güvenliğini artırır ve jeopolitik risklere karşı daha dirençli hale gelmeye katkı sağlar. Hızla gelişen teknoloji sayesinde rüzgâr türbinleri daha verimli hale gelmekte ve maliyetleri düşmektedir. Bu durum, rüzgâr enerjisinin enerji üretiminde daha belirgin bir rol oynamasına olanak tanımaktadır.

Enerji üretiminin tahmin edilebilmesi, güç santrallerinin etkin bir şekilde işletilmesi, yönetilmesi ve yeni santrallerin tasarlanması bakımından büyük kolaylıklar sağlamaktadır. Büyük rüzgâr türbinlerindeki kesinti ve belirsizlik güvenilir çalışmayı engelleyebilir, güç kalitesinde ciddi sorunlara yol açabilir ve dolayısıyla rüzgâr enerjisi üretiminin ekonomisini olumsuz etkileyebilir [7]. Rüzgâr enerjisinin temel kaynağı olan rüzgâr hızı, kararsız ve değişken doğası nedeniyle tahmin edilmesi oldukça zor olan bir parametredir. Zaman, mevsim, sıcaklık, nem ve hava durumu gibi birçok faktör rüzgâr hızını etkilemektedir. Bu nedenle rüzgâr hızını tahmin etmek için kullanılan modellerin yüksek doğruluk oranına sahip olması kritik öneme sahiptir [8]. Genel olarak rüzgâr enerjisi tahminleri dörde ayrılmaktadır. Çok kısa süreli tahminler, birkaç saniyeden yarım saate kadar olan zaman aralığındaki tahminleri ifade eder ve türbin çalışması kontrolü ile elektrik piyasasının belirlenmesi amacıyla gerçekleştirilir. Kısa süreli tahminler, 30 dakikadan 6 saate kadar zaman aralığında yapılan tahminlerdir. Yük arttırma/düşürme kararları gibi gün

içi piyasa işlemlerinin yönetim planlamasında kullanılır. Orta süreli tahminler, 6 saat ile bir güne kadarlık zaman aralığında gerçekleştirilen tahminlerdir. Gün sonu elektrik piyasasının düzenlenmesi için kullanılmaktadır. Son olarak 1-7 gün arası uygulanan tahminler uzun süreli tahminler olarak tanımlanır. Uzun süreli tahminler; bakımlarının planlanması, birim taahhüt kararları ve işletme maliyet hesaplamasında kullanılır [9,10].

Rüzgâr enerjisi tahmininde kullanılan yöntemler; süreklilik yöntemi, fiziksel yöntemler, istatistiksel yöntemler, yapay zekâ tabanlı yöntemler, mekansal korelasyon yöntemi ve hibrit yöntemler olmak üzere 6 başlıkta sınıflandırılabilir [11]. Kısa vadeli tahmin yapmak için istatistiksel yöntemler kullanılırken, uzun vadeli tahminlerde fiziksel yöntemler kullanılmaktadır. Hibrit yöntemler, güçlü rüzgâr gücü tahminleri elde etmek amacıyla hava durumu tahmin verilerini ve zaman serisi analizini bir araya getirerek fiziksel ve istatistiksel yöntemleri birleştirir [12].

Son zamanlarda rüzgâr enerjisi tahmini için yapılan birçok çalışmada derin öğrenme yöntemleri de kullanılmıştır. Derin öğrenme yöntemleri rüzgâr enerjisi gibi diğer yenilenebilir enerji üretim tahminlerinde de kullanılmakta ve başarılı sonuçlar elde edilmektedir [13-15]. Rüzgâr tahminlerinde önemli hale gelmeye başlayan derin öğrenme sinir ağlarında daha çok Otomatik Kodlayıcı (Autoencoder-AE), Uzun Kısa Vadeli Hafıza (Long Short-Term Memory-LSTM), Kısıtlı Boltzmann Makinesi (Restricted Boltzmann Machine-RBM) ve Evrişimli Sinir Ağı (Convolutional Neural Network-CNN) gibi yöntemler kullanılmıştır. Derin öğrenme fazladan denetimsiz ağlara ve veri ön işlemesine ihtiyaç duyulmadığı için, geleneksel sinir ağlarından daha iyi performans göstermektedir [16].

Bu tezin amacı, enerji yatırımcıları ve araştırmacılar başta olmak üzere birçok alanda kullanılmak üzere Bingöl ili için kısa vadeli rüzgâr hızı tahmini yapmaktır. Bu amaç doğrultusunda öncelikle Bingöl Meteoroloji Müdürlüğünden Bingöl iline ait 01.01.2020 ile 01.02.2021 tarihleri arasında ölçülen saatlik rüzgâr hızı verileri alınmıştır. Elde edilen veriler derin öğrenme yöntemlerinden biri olan CNN modeli ile işlenerek, kısa vadeli rüzgâr hızı tahmini yapılmıştır. Bu tez aynı zamanda, çalışma bölgesinin rüzgâr potansiyeli hakkında kapsamlı bir bilgi sunmayı amaçlamaktadır. Bu bağlamda, Bingöl ili için üretilebilecek rüzgâr gücü ve enerji potansiyeli üzerine bilgiler içermektedir. Derin

öğrenme tekniklerinin kullanılması, geleneksel yöntemlere göre daha yüksek performans sağladığı için, elde edilen tahminlerin güvenilir ve doğru olmasına katkıda bulunmaktadır. Bu çalışma, enerji sektöründe stratejik kararlar almak isteyen paydaşlara önemli bir bilgi kaynağı sunmaktadır.

Bu çalışmada hazırlanan tez altı bölümden oluşmaktadır. Giriş bölümünde; enerji ve enerji sürekliliğinin sağlanması, yenilenebilir enerji kaynakları, bu kaynakların önemi ve gerekliliği hakkında bilgiler verilmiştir. 2. Bölümde rüzgâr hızı tahmin yöntemleri ve derin öğrenmenin enerji sektöründe tahmin amaçlı kullanılması üzerine yapılan çalışmalar üzerine kaynak taraması yapılmıştır. 3. Bölümde; Rüzgâr enerjisi, Türkiye'nin rüzgâr potansiyeli ve rüzgâr türbinleri konuları ele alınmıştır. 4. Bölümde ise yapay sinir ağları, makine öğrenmesi, derin öğrenme ve derin öğrenme yöntemlerinden bahsedilmiş, bu yöntemler ile yapılan çalışmaların başarısından söz edilerek tahmin üretmek için neden tercih edildiği hakkında bilgiler verilmiştir. 5. Bölümde, çalışmada kullanılan materyal ve metoda yer verilmiştir. 6. Bölümde ise yapılan çalışmanın sonuçları paylaşılmış ve elde edilen grafikler sunulmuştur. Sonuç ve Öneriler Bölümünde ise yapılan tüm işlemler ve elde edilen sonuçlar değerlendirilmiş ve gelecekte yapılabilecek çalışmalar hakkında öneriler sunulmuştur.

2. KAYNAK ÖZETLERİ

Rüzgâr hızı tahminine yönelik ülkemizde yapılan bazı tez çalışmaları aşağıda sunulmuştur.

Özkay 2021 tarihli yüksek lisans tez çalışmasında, Bilecik Meteoroloji Müdürlüğü'nden alınan 10 yıllık (2010-2019) işlenmiş saatlik rüzgâr hızı verilerini derin öğrenme modelinde eğitime sokarak belirli zaman aralıkları için rüzgâr hızı tahminleri gerçekleştirmiştir. Meteorolojik verilerin %67'si eğitim ve %33'ü test için kullanılarak 3 katmanlı LSTM modelinde eğitilmiş ve daha sonra 1 gün, 2 gün, 1 hafta ve 1 aylık tahminler yapılmıştır. Daha iyi tahmin değerleri elde etmek amacıyla, tek değişkenli çift yönlü (Univariate Bidirectional) ve çok adımlı vektör çıkışlı (Multi-Step Vector Output) olmak üzere iki tip LSTM modeli kullanılmış ve saatlik rüzgâr hızı tahmininde hangisinin daha uygun olduğu araştırılmıştır. Ayrıca çalışmada LSTM modellerinde kullanılan farklı büyüklükteki 1 ve 10 yıllık saatlik rüzgâr hızları verilerinin modellerin doğruluğuna etkisi incelenmiş ve sonuçlar karşılaştırılmıştır [17].

Yazdi tarafından yapılan tez çalışmasında rüzgâr hızı tahmini için bir adaptif ağ tabanlı bulanık çıkarım sistemi sunulmuştur. Nem, basınç, sıcaklık ve günlük rüzgâr hızının geçmiş verilerine göre yüksek hassasiyetli çıkışa sahip adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS) yöntemi ile kısa ve orta vadeli bir tahmin modeli tasarlanmıştır. Bu çalışmada rüzgâr hızı tahmininde önemli özelliklerin belirlenmesi ve modelin karmaşıklığının azaltılması için Relieff, korelasyon ve seçim yöntemleri kullanılmıştır. Uygulanan yöntemin performansı, ortalama mutlak yüzde hatası açısından değerlendirilmiş ve geleneksel süreklilik tahmin modeliyle karşılaştırılmıştır. [18].

Kayabaşı "Yapay Sinir Ağları ve Çoklu Lineer Regresyon Yöntemleri ile Rüzgâr Gücü Tahmini" başlıklı tez çalışmasında [19], yapay sinir ağları ve çoklu lineer regresyon yöntemleri ile uygulamalar gerçekleştirerek rüzgâr gücü tahmini yapmıştır. Elde edilen sonuçlar Ortalama Mutlak Yüzde Hata (MAPE) ve Ortalama Karekök Hatası (RMSE) gibi hata ölçütleri yardımıyla karşılaştırılmış ve her iki yöntemin gerçeğe çok yakın tahminler yaptığı ancak YSA modelinin gerçek sonuçlara daha çok yaklaştığı ortaya konulmuştur.

Yazıcı tarafından yapılan 2021 tarihli yüksek lisans tez çalışmasında [20], kısa dönem rüzgâr gücü tahmini için hem statik hem dinamik yapıya sahip ve birbirinden farklı makine öğrenmesi algoritmalarına dayanan iki yeni hibrit model sunulmuştur. Geliştirilen statik modelde tahmin algoritmaları olarak destek vektör regresyonu, Karar ağacı ve Gauss süreç regresyonu kullanılmış ve bu algoritmaların optimum hiper parametre değerlerinin araştırılmasında Bayes optimizasyonu algoritmasından yararlanılmıştır. Optimize edilen makine öğrenmesi algoritmalarının tahmin performanslarını arttırmak amacıyla topluluk öğrenmesi algoritmalarından torbalama ve istifleme kullanılarak topluluk öğrenmesi modelleri oluşturulmuştur. Geliştirilen dinamik modelde ise LSTM sinir ağlarından yararlanılmıştır. Eğitim veri seti zamana bağlı değişen yapıda olup test günlerinden önceki 3 gün (72 saat), 5 gün (120 saat), 10 gününe (240 saat) ait verilerle oluşturulmuştur. Sonuçlar dinamik modelin ani değişim ve dalgalanmaların yaşandığı zaman dilimlerinde, statik yapıdaki torbalama modelinin ise genel olarak gerçek güç değerlerine daha yakın sonuçlar verdiğini göstermektedir.

Zorlu yaptığı tez çalışmasında [21], 1975-2010 yılları arasında kaydedilen Kırşehir iline ait sıcaklık, basınç ve nem değerlerini kullanarak rüzgâr hızı tahmini gerçekleştirmiştir. Çalışmada analiz yöntemi olarak ileri beslemeli geri yayımlı Yapay Sinir Ağları kullanılmış ve Levenberg - Marquardt ile Resilient Back Propagation algoritmaları karşılaştırılmıştır. Elde edilen sonuçlar her iki algoritmanın birbirine çok yakın performans gösterdiğini ama Resilient Back Propagation öğrenme algoritmasının nispeten daha iyi sonuçlar verdiğini ortaya koymuştur.

Minaz tarafından yapılan tez çalışmasında, önerilen tasarım modeli için ANFIS ile doğrusal çoklu regresyon analizi yöntemleri kullanılmış ve hangi yöntemin daha iyi performans sergilediği araştırılmıştır. Bilecik ili için 2000-2009 yıllarına ait sıcaklık, basınç ve rüzgâr hızı verileri kullanılarak 2010 yılı için tahminler yapılmıştır. Elde edilen tahminler gerçek değerler ile karşılaştırılmıştır. Rüzgâr hızı ve sıcaklık tahmininde ANFIS yönteminin daha iyi olduğu, basınç tahmininde ise doğrusal çoklu regresyon analizi yönteminin daha başarılı olduğu belirtilmiştir [22].

Tan tarafından yapılan “İkincil Ayrıştırma Tekniği Kullanarak Yapay Sinir Ağı Temelli Çok Adımlı Rüzgâr Hızı Tahmini” başlıklı tez çalışmasında [23], kümeleme, veri ön

işleme, değerlendirme ve tahmin olmak üzere 4 modülden oluşan hibrit bir tahmin modeli önerilmiştir. Gaziosmanpaşa Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi yerleşkesinde kurulan rüzgâr ölçüm istasyonunda bir yıl boyunca 10'ar dakika ara ile kaydedilen rüzgâr hızı verileri kullanılmıştır. Önerilen model ile elde edilen sonuçlar bazı geleneksel tahmin modellerine ait sonuçlar ile karşılaştırılarak performans analizi yapılmıştır.

Çok sayıda araştırmacı derin öğrenme yöntemiyle rüzgâr hızı tahminine yönelik çalışmalar yapmıştır. Bu çalışmalardan bazıları şunlardır.

Chandran ve arkadaşları 2021 yılında yaptıkları çalışmada, kısa vadeli rüzgâr enerjisi üretim tahmini için üç farklı derin öğrenme yöntemi kullanmışlardır. Çalışmada Brüksel-Belçika'da bulunan bir rüzgâr türbini referans olarak alınmıştır. Model LSTM, geçit referans birimi (Gated Recurrent Unit-GRU) ve tekrarlayan sinir ağı (RNN) algoritmaları ile oluşturulmuş ve rüzgâr hızı verileri modelde girdi olarak kullanılmıştır. Araştırma sonuçları aynı zamanda önerilen modelin bir bölgede santral kurulumu için gerekli koşulların sağlanıp sağlanmadığını değerlendirmede kullanılabileceğini de ortaya koymaktadır [24].

Görgel ve Kavlak tarafından yapılan çalışmada CNN ve LSTM yöntemlerinin hibrit olarak kullanılmış ve enerji üretim tahmini yapılmıştır. Çalışmada İzmir Urla'da bulunan bir rüzgâr türbinine ait günlük ve onar dakikalık gerçek veriler kullanılmıştır. Yapılan eğitim ve testlerde hem bir yıllık uzun zaman dilimine ait veriler hem de üç günlük kısa zaman dilimine ait veriler kullanılmıştır. Ayrıca hibrit yöntemin dışında karşılaştırma amaçlı olarak CNN, LSTM ve GRU yöntemleri tek tek uygulanıp sonuçlar grafik halinde gösterilmiştir. Geliştirilen hibrit CNN-LSTM öğrenme yapısı ile yapılan üretim tahmininde ortalama kare hata (Mean Square Error-MSE) 1,17'ye kadar düşürülmüştür [25].

Avrupa'daki İletim Sistemleri Operatörleri (TSO'lar), günlük piyasa takası öncesinde, rüzgâr tahminlerini yayımlayarak enerji santrallerinin planlama stratejilerini geliştirmeye destek sağlamaktadır. Toubeau ve arkadaşları, büyük ölçekli planlamalar için birden fazla modelin tahmin sonuçlarını birleştirerek daha etkili sonuçlar elde edilebileceği düşüncesiyle yeni bir derin öğrenme yöntemi geliştirmişlerdir. Bu yöntemin temel amacı,

bir sonraki günün rüzgâr enerjisi üretimini tahmin etmektir. İlk olarak veriyi işlemek için LSTM tabanlı üç farklı mimari (kodlayıcı, kod çözücü ve çift yönlü kod çözücü) geliştirilmiştir. İkinci aşamada, modelin fiili kullanımı sırasında yeniden kalibre edilmesi sağlanarak tahminlerin doğruluğu arttırılmıştır. Bu amaçla elde edilen yeni veriler zaman içinde eski verilere eklenerek modelin sürekli olarak eğitilmesi sağlanmıştır. Son olarak, tahmin hatalarının hem TSO hem de rüzgâr üreticileri üzerindeki mali etkisi ölçülmüştür [26].

Yıldız ve arkadaşları rüzgâr gücü tahmini için iki adımlı yeni bir derin öğrenme yöntemi sunulmuştur. Birinci aşama, varyasyonel mod ayrıştırma (Variational Mode Decomposition-VMD) tabanlı özellik çıkarımı ve bu özelliklerin görüntülere dönüştürülmesi süreçlerini içermektedir. İkinci aşamada, rüzgâr gücünü tahmin etmek için geliştirilmiş artık tabanlı CNN kullanılmıştır. Veri seti olarak 1 Ocak-31 Aralık 2018 tarihleri arasında Türkiye'deki bir rüzgâr santralinden temin edilen rüzgâr gücü, rüzgâr hızı ve rüzgâr yönü verileri kullanılmıştır. Önerilen yöntemin sonuçları, SqueezeNet, GoogLeNet, ResNet-18, AlexNet, ve VGG-16 gibi güncel derin öğrenme mimarilerinden elde edilen sonuçlarla karşılaştırılmıştır [27].

Lin ve arkadaşları yaptıkları çalışmada [28], zamansal evrişim ağı (Temporal Convolutional Network-TCN) algoritmasını kullanarak %10'dan daha düşük bir MAPE ile uzun vadeli (24-72 saat ileri) rüzgâr gücü tahmini gerçekleştirmişlerdir. Çalışmada geçmiş hava durumu verileri ile Türkiye'deki bir rüzgâr santralindeki rüzgâr türbininin elektrik üretim çıktıları kullanılarak TCN modelinin ön eğitimi gerçekleştirilmiş ve 72 saatlik rüzgâr gücü tahmini için %5,13'lük bir MAPE değeri elde edilmiştir. Son olarak, güç tahmini için LSTM, RNN ve GRU modelleri ile de ölçümler yapılarak TCN sonuçları ile karşılaştırılmıştır. Karşılaştırma sonuçları, TCN modelinin veri giriş hacmi, hata azaltma kararlılığı ve tahmin doğruluğu açısından diğer üç modelden daha iyi performans sergilediğini göstermektedir.

Liu ve arkadaşları tarafından yapılan çalışmada, modelleme süreci üç adımdan oluşan yeni bir hibrit rüzgâr hızı tahmin modeli önerilmektedir. Birinci aşamada ampirik dalgacık dönüşümü yöntemi, orijinal verileri birkaç alt seriye ayrıştırarak orijinal rüzgâr hızı verilerinin durağan olmama durumunu azaltır. İkinci aşamada, tahmin modelini oluşturmak

ve tüm alt serilerin tahmin sonuçlarını sırasıyla hesaplamak için LSTM, derin inanç ağları (Deep Belief Networks-DBN) ve yankı durum ağları (Echo State Networks-ESN) olmak üzere üç tür derin ağ kullanılır. Üçüncü aşamada ise üç tür derin ağ birleştirmek için takviyeli öğrenme yöntemi kullanılır. Nihai tahmin sonuçları LSTM, DBN ve ESN yöntemlerinin tahmin sonuçlarının birleştirilmesiyle elde edilmiştir [29].

Wang ve arkadaşları rüzgâr hızı tahmin performansını ve verimliliğini arttırmak amacıyla DBN, dalgacık dönüşümü (Wavelet Transform-WT) ve kantil regresyonu (Quantile Regression-QR) yöntemlerini hibrit bir modelde birleştirerek yeni bir yaklaşım geliştirmişlerdir. Çin ve Avustralya'daki gerçek rüzgâr santrali verilerinin kullanıldığı çalışmada, WT, ham rüzgâr hızı verilerini farklı frekans serilerine ayrıştırmak için kullanılır. Her frekansın doğrusal olmayan özellikleri ve değişmez yapıları, DBN ile tamamen çıkarılır. Daha sonra rüzgâr hızındaki belirsizlikler QR yöntemiyle istatistiksel olarak sentezlenmiştir. Elde edilen sonuçlar, rüzgâr hızı serisindeki üst düzey doğrusal olmayan ve durağan olmayan özelliğin daha iyi öğrenilebileceğini ve bu sayede rekabetçi performans elde edilebileceğini göstermektedir [30].

Tarek ve arkadaşları tarafından yapılan çalışmada [31], rüzgâr enerjisi üretim tahminini gerçekleştirmek için çeşitli derin ve makine öğrenme modelleri oluşturulmuştur. Bu regresyon modelleri; derin sinir ağı (Deep Neural Network-DNN), k-en yakın komşu (k-nearest neighbor KNN) regresörü, LSTM, ortalama modeli, rastgele orman (random forest-RF) regresörü, torbalama regresörü ve gradyan artırma (Gradient Boosting-GB) regresörüdür. Bu çalışmada kullanılan veri seti 4 özellik ve 50530 örnek içermektedir. Rüzgâr gücü değerlerini doğru bir şekilde tahmin etmek için, LSTM ağının parametrelerini optimize etmek amacıyla stokastik fraktal arama (Stochastic Fractal Search-SFS) ve parçacık sürüsü optimizasyonuna (Particle Swarm Optimization-PSO) dayalı yeni bir optimizasyon tekniği (SFS-PSO) önerilmiştir. Regresyon modellerinin etkinliğini tahmin etmek için beş değerlendirme kriteri kullanılmış ve elde edilen sonuçlar, SFS-PSO modelini kullanan LSTM'nin çok iyi performans sergilediğini göstermiştir.

Xiong ve arkadaşları tarafından 2023 yılında yapılan çalışmada [32], rüzgâr enerjisi tahmini için tamamlayıcı topluluk deneysel mod ayrıştırması (Complementary Ensemble Empirical Mode Decomposition-CEEMD), örnek entropi (Sample Entropy-SE), RF,

geliştirilmiş sürünge arama algoritması (Improved Reptile Search Algorithm-IRSA), çift yönlü uzun kısa süreli bellek (Bidirectional Long Short-Term Memory-BiLSTM) ağı ve aşırı öğrenme makinesini (Extreme Learning Machine-ELM) birleştiren hibrit bir model önerilmiştir. İlk olarak CEEMD kullanılarak durağan olmayan orijinal rüzgâr enerjisi dizisi nispeten durağan modal bileşenlere ayrıştırılır ve hesaplama karmaşıklığını azaltmak için örnek entropi birleştirme kullanılmıştır. İkinci olarak, rastgele orman özelliği seçimi yardımıyla gereksiz özellikler daha da ortadan kaldırılmıştır. Üçüncü adımda, BiLSTM modeli ve ELM modeli sırasıyla yüksek ve düşük frekanslı bileşenleri tahmin etmek için uygulanmıştır. IRSA ise modelin parametrelerini optimize etmek için kullanılmıştır. Son olarak, rüzgâr gücünün nihai tahmin değerine ulaşmak için her bir bileşenin tahmin edilen değeri toplanmıştır. Çalışma sonuçları, BiLSTM ve ELM'nin çift ölçekli topluluk modeli ile daha iyi tahmin doğruluğu elde edilebildiğini göstermektedir.

Christoforou ve arkadaşlarının yaptıkları çalışmada, CNN ve RNN sinir ağlarını birleştirerek yüksek doğrulukta gün öncesi ve kısa vadeli rüzgâr hızı tahminleri üretmişlerdir. Girdi tahminleri, geliştirilen bir hava durumu araştırma ve tahmin modeliyle elde edilmektedir. Eğitimde Yunanistan'daki beş rüzgâr çiftliğinden elde edilen geçmiş veriler kullanılmakta ve 5 aylık test süresi, en yüksek rüzgâr hızı değerlerinin sergilendiği kış aylarını içermektedir. Elde edilen sonuçlar, sunulan model yardımıyla tahmin doğruluğunun ortalama %19,4 oranında arttığını göstermektedir [33].

Yaghoubirad ve arkadaşları 2023 yılında yaptıkları çalışmada [34], LSTM, GRU, CNN ve CNN-LSTM olmak üzere dört farklı algoritmayı üç farklı uzun vadeli zaman perspektifi (6 ay, 1 yıl ve 5 yıl) için geliştirmişlerdir. Elde edilen sonuçlara bakıldığında GRU yönteminin diğer yöntemlere kıyasla daha yüksek derecede doğruluk gösterdiği görülmektedir. Ayrıca çok değişkenli veri seti kullanılması durumunda, tek değişkenli modele göre modelin doğruluğu artmaktadır. Önerilen algoritmaları karşılaştırmak için hesaplamalı bir maliyet analizi de yapılmıştır. Son olarak, Zabol şehrindeki rüzgâr santralinin enerji üretim kapasitesi gelecek beş yıl için hesaplanmıştır.

Xu ve arkadaşları yaptıkları çalışmada derin öğrenmeye dayalı kısa vadeli rüzgâr enerjisi tahmin modeli önermişlerdir. İlk olarak, verinin gürültüsünü gidermek için ayrık dalgacık dönüşümü (Discrete Wavelet Transform-DWT), daha sonra veri özelliklerini çıkarmak için

bir AE teknolojisi ve son olarak tahmin için BiLSTM kullanılmıştır. Önerilen DWT_AE_BiLSTM modelinin etkinliğini doğrulamak için üç farklı elektrik santrali incelenmiş ve sığ sinir ağı modeliyle karşılaştırılmıştır. Geleneksel geri yayılım (backpropagation-BP) modeliyle karşılaştırıldığında, önerilen modelin üç rüzgâr santrali için sırasıyla %3,86, %3,22 ve %3,42 oranında artış gösterdiği belirtilmiştir [35].

Tyass ve arkadaşları yaptıkları çalışmada [36], istatistiksel Mevsimsel Otomatik Gerilemeli Entegre Hareketli Ortalama (Seasonal Auto-Regressive Integrated Moving Average-SARIMA) modelini ve LSTM modelini kullanarak rüzgâr hızını tahmin etmişlerdir. Bu amaçla karşılaştırmalı bir analiz yapılmıştır. Her modelin etkinliğini değerlendirmek ve en iyiyi seçmek için MSE, RMSE, MAE ve MAPE hata ölçütleri kullanılmıştır. Elde edilen sonuçlar, LSTM modelinin SARIMA ile karşılaştırıldığında %14,05'lik MAPE ile daha iyi performans gösterdiğini ortaya koymuştur.


Literatürdeki çalışmalardan da anlaşılacağı üzere, rüzgâr enerjisinin tahmin edilmesi, enerji üretim stratejilerini belirleme sürecinde hayati bir öneme sahiptir. Ancak, bu süreç oldukça karmaşık ve zorlu bir uygulama alanını kapsamaktadır. Araştırmacılar, bu zorluğun üstesinden gelmek için çeşitli yöntemleri benimsemekle kalmamış, aynı zamanda sürekli olarak yeni yaklaşımlar geliştirme çabası içerisinde olmuşlardır.

3. RÜZGÂR ENERJİSİ

3.1. Türkiye’de Rüzgâr Enerjisi


Rüzgar, havanın yüksek basınçlı bölgeden alçak basınçlı bölgeye hareketi olarak tanımlanır. Türkiye yenilenebilir enerji kaynakları bakımından zengin bir ülkedir. Coğrafi yapısı rüzgâr potansiyelini arttırmaktadır. Özellikle kıyı bölgeleri rüzgâr potansiyeli bakımından oldukça güçlüdür. İç kesimlerde ise yüksek dağlık alanların olması rüzgâr potansiyelini arttırmaktadır. Tüm dünyada olduğu gibi Türkiye’de de rüzgâr enerjisi teknolojilerinin gelişmesine bağlı olarak bu sektöre yönelim artmış, daha fazla bölgede rüzgâr santralleri kurulmaya başlanmıştır. Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) tarafından yayımlanan Aralık 2022 kurulu güç raporuna göre ülkemizde 358 rüzgâr santrali mevcut olup bunların toplam kurulu güç değeri 11.396,2 MW’tır. Aynı raporda ülkemizin toplam kurulu güç değeri ise 103.809,3 MW olarak belirtilmiştir. Bu değerlere göre rüzgâr enerjisi toplam kapasitenin yaklaşık %11’ini oluşturmaktadır.

Her noktanın rüzgâr hızını ve potansiyelini ölçmek mümkün değildir. Ölçümlerin yapılamadığı yerlerde, orta ölçekli sayısal hava tahmini modeli ve mikro ölçekli rüzgâr akış modeli kullanılarak bölgenin rüzgâr potansiyelini gösteren rüzgâr haritaları çıkarılmıştır. Enerji ve Tabii Kaynaklar Bakanlığı’nın hazırlanmasına öncülük ettiği Rüzgâr Enerjisi Potansiyel Atlası (REPA) ile Türkiye genelinde her bölgenin ve ilin, yer seviyesinden 100 metre yükseklikteki yıllık ortalama rüzgâr hızı dağılımı, yıllık ortalama rüzgâr güç yoğunluğu dağılımı ve kapasite faktörü dağılımı görünür hale gelmiştir (Şekil 3.1).




Şekil 3.1. Yıllık ortalama rüzgâr hızı dağılımı-100m [37]

Türkiye’de rüzgâr kapasitesinin en fazla olduğu ve dolayısıyla en fazla rüzgâr santralinin kurulduğu bölgeler Marmara, Ege ve Akdeniz’in kıyı kesimleridir. Bu bölgelerden sonra rüzgâr santrallerinin en çok kurulduğu bölgeler sırasıyla İç Anadolu, Karadeniz, Güneydoğu Anadolu ve Doğu Anadolu bölgesidir (Şekil 3.2).



(a)



(b)

Şekil 3.2. Türkiye’de 2021 yılı itibariyle RES’lerin bölgelere göre dağılımı (a) Yüzdeler (b) Kurulu güç [38]

3.2. Rüzgâr Türbinleri

Rüzgâr türbinleri, rüzgâr enerjisini mekanik enerjiye dönüştüren cihazlardır. Bu türbinler genellikle büyük alanlarda, rüzgârın bol olduğu bölgelerde kurulurlar ve elektrik enerjisi üretmek için kullanılırlar. Türbinin başlıca kısımları ve görevleri şunlardır (Şekil 3.3).

Kanatlar: Türbinin temel kısımlarından olup rüzgârın sahip olduğu kinetik enerjiyi türbin rotorunu hareket ettirecek olan mekanik enerjiye dönüştürürler. Rüzgâr, kanadın aerodinamik yapısı sayesinde kanat üzerinde kaldırma ve sürüklenme kuvveti meydana getirir. Bu kuvvetler kanadın hareket etmesini sağlar. Kanatla beraber bağlı olduğu rotor da hareket etmeye başlar. Kanadın rüzgâr enerjisinden en iyi şekilde yararlanabilmesi için aerodinamik yapısının düzgün olması gerekir. Son dönemlerde kanat yapımında kompozit ve nano teknoloji ürünleri kullanılarak güçlü ve hafif kanatlar üretilmiştir. Kanat göbeği (hub), kanatların gövdeyle birleştiği yerdir. Pitch kontrol ve stall kontrol mekanizmaları bu gövde içerisinde yer almaktadır.

Gövde: Generatör, dişli kutusu, fren sistemi, yaw kontrol mekanizması, elektronik kontrol ekipmanları gibi elemanların içerisinde bulunduğu bölümdür. Tüm bu sistemi dış etkenlerden korur ve mukavemeti sağlar.

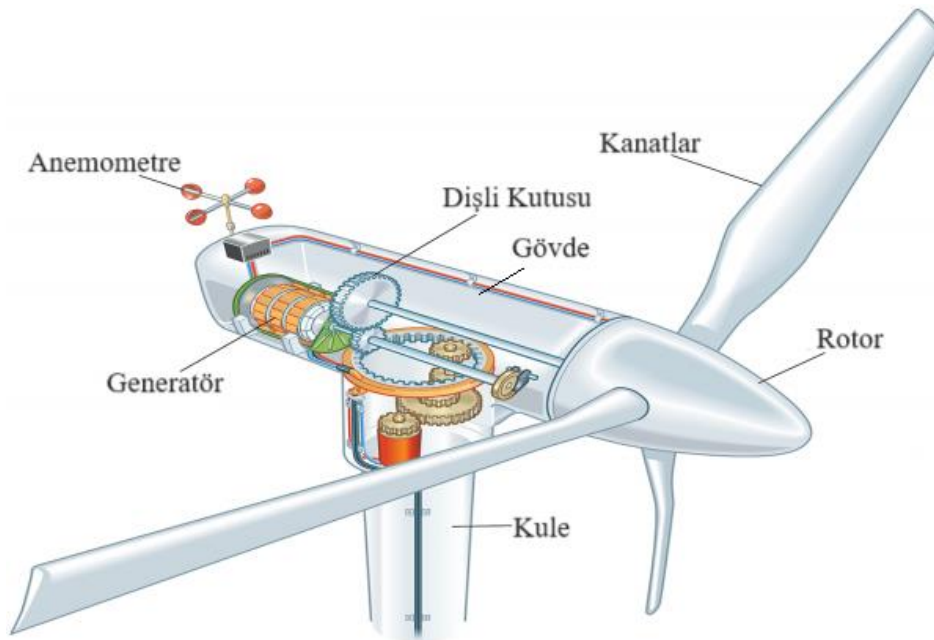
Kule: Türbinin gövde ve kanatlarını taşıyan yapıdır. Çelik veya beton malzemeden, kafes ya da silindir şeklinde üretilirler. Kötü hava koşullarına karşı dayanıklı yapılardır. Kule çapı aşağıda daha büyük olup, yukarı doğru gidildikçe küçülmektedir. Yeryüzünden yukarı doğru çıktıkça rüzgâr hızı artmaktadır. Buna bağlı olarak kulelerin de yüksek olması daha fazla enerji üretilmesini sağlayabilmektedir. Ancak kulenin yükseltilmesi maliyeti ve kule ağırlığını arttırmaktadır. Bu yüzden iyi hesaplamalarla optimum dengenin sağlanması gerekmektedir.

Rotor: Kanatların dönüştürdüğü mekanik enerjiyi dişli kutusuna ileten elemandır.

Dişli Kutusu: Dişli kutusu, rotordan aldığı düşük dönme hızını 1200-1500 devirlere yükselterek generatör çalışma hızına ulaştırır.

Generatör: Türbinde mekanik enerjiyi elektrik enerjisine dönüştürecek olan elektrik makineleridir. Rüzgâr türbinlerinde genellikle kullanılan jeneratörler çift beslemeli asenkron jeneratör, sincap kafesli asenkron jeneratör, sabit mıknatıslı senkron jeneratör ve rotoru sargılı senkron jeneratörlerdir.

Anemometre: Rüzgâr hızını ölçen cihazlardır. Sürekli ölçüm olarak elektronik kontrol sistemlerine ölçüm değerlerinin iletilmesini sağlar.



Şekil 3.3. Rüzgâr türbinin iç yapısı [39]

3.2.1. Rüzgâr Türbinlerinin Sınıflandırılması

Rüzgâr enerjisini en verimli şekilde kullanabilmek için farklı türbin modelleri tasarlanmıştır. Bu türbinler çeşitli kriterlere göre sınıflandırılmaktadır.

3.2.1.1. Eksenlerine Göre Rüzgâr Türbinleri

Rüzgâr türbinleri genellikle rotorun dönme eksenine göre sınıflandırılmaktadır. Bu sınıflamada türbinler yatay eksenli ve dikey eksenli olmak üzere iki ana kategoriye ayrılır. Yatay eksenli rüzgâr türbinlerinde dönme eksenini rüzgâr yönüne paralel, kanatlar ise dik şekilde konumlandırılmıştır. Bu türbinler yüksek güç katsayısına sahip oldukları için ticari alanlarda daha çok tercih edilmektedir [40]. Dikey eksenli rüzgâr türbinleri, dönme eksenini rüzgâr yönüne dik olacak şekilde kurulan türbinlerdir. Her yönden esen rüzgâr ile aynı verimde çalışabilme özelliğine sahiptirler. Yere yakın oldukları için aldıkları rüzgâr hızı ve dolayısıyla verimleri oldukça düşüktür. Bu sebeple ticari alanlarda kullanımı yaygın değildir [41]. Bu iki türbin türü dışında dönme eksenini ile kule arasında rüzgâr yönünde belli bir açı yapan türbinler vardır. Bunlara eğik eksenli rüzgâr türbinleri denir. Kullanımı neredeyse yok denecek kadar azdır [42].

3.2.1.2. Kanat Sayısına Göre Rüzgâr Türbinleri

Rüzgâr türbinlerini sınıflandırmak için kullanılan bir başka kriter kanat sayısıdır. Kanatların boyutu, şekli ve yapım malzemesi tasarımın bir parçasını oluşturur. Tek kanatlı rüzgâr türbinlerinde dönme hızı ve kanat uç hız oranı yüksek, sürtünme katsayısı ve maliyeti düşüktür. Fakat bu türbinlerde tek kanadın oluşturduğu denge sorununu çözmek için karşı tarafına bir ağırlık yerleştirilmelidir. Bu da tasarım ve aerodinamik problemlerine neden olduğu için kullanımda tercih edilmemektedir [43]. İki kanatlı rüzgâr türbinleri üç kanatlılara kıyasla daha yüksek kanat uç hız oranına ve verime sahiptir. Fakat gürültü seviyesinin daha fazla olduğu ve daha düşük rüzgâr hızlarında (3 m/s) çalıştığı için tercih edilmemektedir [44]. Üç kanatlı rüzgâr türbinleri tüm dünyada en çok tercih edilen türbin tipidir. Bu türbinlerin en büyük avantajı, dönme momentinin diğer iki türbin tipine göre daha düzgün olmasıdır. Kanat uç hız oranı düşüktür, dolayısıyla daha gürültüsüz çalışırlar [45]. Dört veya daha fazla kanattan oluşan rüzgâr türbinlerine çok kanatlı rüzgâr türbinleri

denir. Düşük hızda çalışır, verimleri oldukça düşüktür. Bu yüzden daha çok su pompalamak için kullanılırlar [42].

3.2.2. Rüzgâr Türbinlerinde Güç Kontrol Sistemleri

Rüzgâr türbinleri, 3-15 m/s aralığındaki rüzgâr hızlarında maksimum güç üretebilecek şekilde tasarlanmaktadır. Rüzgâr hızının 15 m/s değerini aştığı durumlarda türbinin zarar görmesini engelleyebilecek bir kontrol sistemine ihtiyaç duyulur. Kontrol sistemlerinin kullanılması türbinlerde rüzgâr hızının neden olabileceği sorunları kolay ve güvenli bir şekilde önleyebilmektedir. Aynı zamanda sistemin performansını ve dayanıklılığını arttırmaktadır. Güç kontrolü için kullanılan iki temel yöntem durdurma (stall) ve eğim (pitch) kontrolleridir. Stall kontrollü sistemlerde, rüzgâr hızının nominal değerlerin üzerine çıkması halinde kanat hücum açısı artırılır. Kanat, profilin üst yüzeyinde türbülans oluşacak pozisyona getirilir. Böylece rüzgâr akım çizgileri kanat yüzeyinden ayrılır ve kanat rüzgâra karşı direnç göstermeye başlar. Basınç düşer ve pervane gücü azalır, kanatlar yavaşlamaya başlar ve güvenli bir şekilde durdurma gerçekleşmiş olur. Rüzgâr hızı nominal değerlere indiği zaman türbin tekrar faaliyete geçer [45,46]. Pitch kontrollünün kullanıldığı türbinlerde, kanatlar kendi eksenleri etrafında dönebilecek şekilde tasarlanmıştır. Generatör çıkış gücü değerine göre kendini ayarlayan Pitch kontrolü, rüzgâr hızının nominal değerlerin üzerine çıkması halinde kanatları rüzgârın tersi yönüne hafifçe döndürür. Böylece kanat hızı düşürülerek güç kontrolü sağlanmış olur. Pitch kontrolü, rüzgâr hızının azaldığı zamanlarda da generatörden aldığı çıkış gücü değerine göre rüzgârın estiği yöne doğru dönebilmektedir [47].

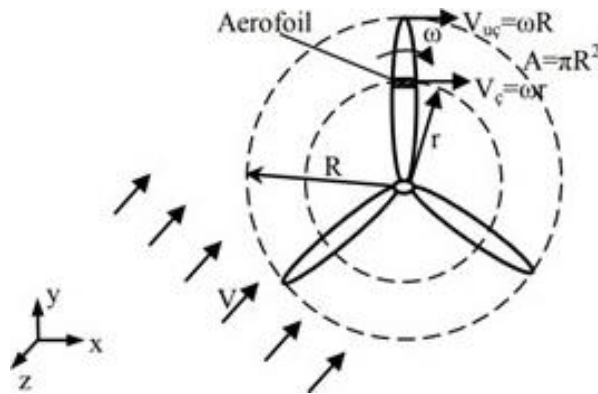
3.2.3. Rüzgâr Türbinlerinin Aerodinamiği

Rüzgâr türbinlerinin en iyi verimle çalıştığı yerler türbülansın en az olduğu hatta neredeyse olmadığı alanlardır. Türbülans gibi türbin aerodinamiği de verimi etkileyen en önemli faktörlerden biridir. Aerodinamik yapılar içerisinde önce kanat şeklinin yapısı gelmektedir. Çünkü enerjinin oluşması kanatlarda başlamaktadır ve maksimum enerji elde edebilmek için kanat yapısının en iyi şekilde tasarlanmış olması gerekmektedir. Enerji üretimini doğrudan etkilediği için günümüzde hala kanat tasarımları üzerinde analizler yapılmaktadır. Bir türbin kanadından, uzun ömürlü olması, tasarımı sayesinde üretilen

enerji verimini arttırması ve kötü hava koşullarında dahi yüzey kalitesinin bozulmaması beklenir.

Uç-Hız Oranı(λ): Eşitlik 3.1 ile elde edilen uç-hız oranı (λ), kanadın uç kısmına gelen çevresel rüzgâr hızının ($V_{uç}=\omega R$), rotora gelen rüzgâr hızına (V) oranıdır. Güç katsayısı C_p , kanat uç-hız oranı ile bağlantılı olarak değişmektedir. Güç katsayısını ve dolayısıyla kanat uç-hız oranını hesaplayabilmek, rüzgâr türbininin nasıl performansı göstereceği hakkında bilgi verebilmektedir [48].

$$\lambda = V_{uç}/V = \omega R/V \quad (3.1)$$



Şekil 3.4. Rüzgâr türbini kanat uç-hız oranı [49]

Türbin kanat uç-hız oranını gösteren Şekil 3.4'te;

V : Rüzgâr hızı (m/s)

$V_{uç}$; Kanat uç hızı (m/s)

ω : Kanat açısal hızı (rad/s)


R : Kanat yarıçapı (m)

r : Aerofoilin kanat üzerindeki konumuna bağlı olarak değişen örnek yarıçapı (m)

λ : Kanat uç-hız oranı

C_p : Güç katsayısını göstermektedir.

Kanat Açısı (θ): Yunuslama açısı olarak bilinen kanat açısı, kanadın kendi eksenini etrafında dönmesi sonucunda dönme eksenini ile aerofoilin referans eksenini arasında kalan açıdır [49].



Şekil 3.5. Rüzgâr türbini kanat açısı [50]

Türbin kanat açısını gösteren Şekil 3.5'te;

θ : Kanat açısı ($^{\circ}$)

α : Hücum açısı ($^{\circ}$)

F_L : Kaldırma kuvveti (N)

F_D : Sürüklenme kuvveti (N)

C_L : Kaldırma katsayısı

C_D : Sürüklenme katsayısı

A_c : Kanadın dik kesit alanı (m^2)

Kaldırma ve sürüklenme kuvvetleri sırasıyla Eşitlik 3.2 ve 3.3'e göre hesaplanmaktadır.

$$F_L = C_L \cdot \frac{\rho}{2} \cdot A_c \cdot V^2 \quad (3.2)$$

$$F_D = C_D \cdot \frac{\rho}{2} \cdot A_c \cdot V^2 \quad (3.3)$$

Güç Katsayısı (C_p): Eşitlik 3.4 yardımıyla hesaplanan C_p , kanatların rüzgârdan ürettiği gücün (P_R) rüzgâr gücüne (P) oranı olarak tanımlanmaktadır [51].

$$C_p = \frac{P_R}{P} = \frac{P_R}{\frac{1}{2} \cdot \rho \cdot \pi \cdot R^2 \cdot V^3} \quad (3.4)$$

P_R : Rotor gücü (W)

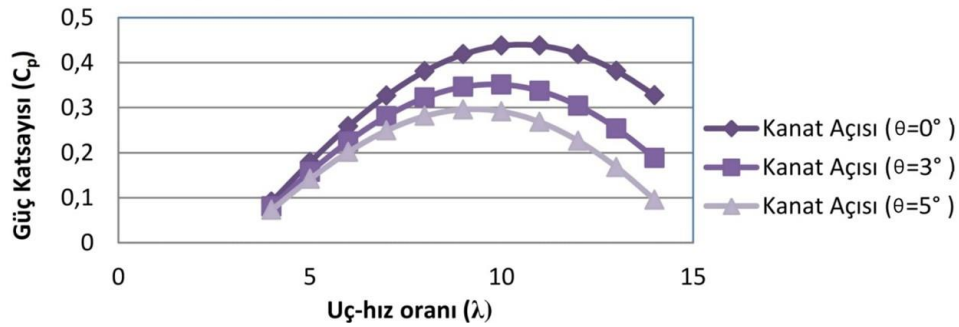
P : Rüzgâr gücü (W)

ρ : Hava yoğunluğu (kg/m^3)

V : Rüzgâr hızı (m/s)

Betz Kanunu; Rüzgâr türbinlerinin tasarımından bağımsız olarak rüzgârdan elde edilebilecek maksimum gücü ifade eder. Betz Kanuna göre teorik güç katsayısı $16/27$ yani 0.593 değerini aşmamaktadır. Bu değer bir üst sınır olarak kabul edilir ve kayıplar nedeniyle bu değere ulaşmak mümkün değildir. Aerodinamik eksiklikler, yaşanan mekanik ve elektriksel kayıplar bu değeri daha da düşürmektedir [52].

Rüzgâr türbinlerinin performansını değerlendirebilmek için C_p ve uç- λ eğrileri oluşturulur. Şekil 3.6'da farklı kanat açılara bağlı olarak değişen güç katsayısı ve uç-hız oranı eğrileri gösterilmektedir.



Şekil 3.6. Farklı kanat açılara bağlı olarak değişen güç katsayısı ve uç-hız oranı eğrileri [51]

3.2.4. Rüzgâr Türbinlerinde Güç Üretimi

Rüzgâr türbinleri, rüzgârın sahip olduğu kinetik enerjiyi önce mekanik enerjiye daha sonra elektrik enerjisine dönüştüren sistemlerdir. V hızıyla hareket eden m kütleli hava akımının sahip olduğu kinetik enerji Eşitlik 3.5'e göre hesaplanır.

$$E_K = \frac{1}{2} \cdot m \cdot V^2 \quad (3.5)$$

Belirli bir zaman aralığında, türbin kanatlarının süpürdüğü alandan geçen havanın kütlesi;


$$\dot{m} = \rho \cdot A \cdot V \quad (3.6)$$

Eşitlik 3.6'da; ρ hava yoğunluğunu ifade etmekte olup, 15 °C sıcaklık ve 1 atmosfer basınçta 1,225 kg/m³ olarak kabul edilmektedir. Birim zamanda akan enerji güç olarak tanımlandığından teorik rüzgâr gücü ($P_{\text{rüzgâr}}$) Eşitlik 3.7 ile ifade edilir.

$$P_{\text{rüzgâr}} = E_K = \frac{1}{2} \cdot \dot{m} \cdot V^2 = \frac{1}{2} \cdot \rho \cdot A \cdot V^3 \quad (3.7)$$

Buradaki eşitlikten rüzgâr gücünün, rüzgâr hızının küpüyle orantılı olduğu görülmektedir. Yani rüzgâr hızının artması rüzgâr gücün doğrudan arttırmaktadır. Fakat rüzgâr türbinleri %100 verimli değildir ve havanın sahip olduğu kinetik enerjinin tamamını elektrik enerjisine dönüştüremezler. Rüzgâr hızının tamamı elektrik enerjisine dönüştürülebilmiş olsaydı rotoru geçen rüzgâr hızının 0 m/s' ye düşmesi beklenirdi. Fakat bunun gerçekleşmesi mümkün değildir. Dolayısıyla rüzgâr türbinlerinde üretilen gerçek güç Eşitlik 3.8 yardımıyla hesaplanır [53].

$$P_{\text{rotor}} = \frac{1}{2} \cdot C_p \cdot \rho \cdot A \cdot V^3 \quad (3.8)$$



Şekil 3.7. Rüzgâr türbinlerinde enerji akışı [54]


Türbin kanatlarından geçen havanın enerjisi Şekil 3.7'de gösterilmektedir. Havanın kinetik enerjisi, türbin gücü ve değerleri sırasıyla Eşitlik 3.9 ve Eşitlik 3.10 yardımıyla hesaplanır [55].

$$E_k = \frac{1}{2} \rho A V_k (V_i^2 - V_0^2) \quad (3.9)$$

$$P_{\text{rotor}} = \frac{E_k}{t} = \frac{1}{2} \rho A V_k (V_i^2 - V_0^2) \quad (3.10)$$

3.2.5. Rüzgâr Türbinlerinin Güç Eğrisi

Bir türbinin güç eğrisi (Şekil 3.8), türbinin mekanik gücü ile rüzgâr hızı arasındaki bağlantıyı gösterir. Türbin üreticileri tarafından, farklı rüzgâr hızlarında yapılan ölçümler sonucunda belirlenmektedir. Güç eğrisi ile türbinden elde edilebilecek güç hesaplanabilmektedir. Güç eğrisi dört duruma ayrılabilir:



Şekil 3.8. Rüzgâr türbinlerinin güç eğrisi [58]

- Devreye alma (cut-in), türbinin çalışmaya başladığı ve elektrik üretmediği bölgedir.
- Kısmi yük bölgesinde rüzgâr türbini maksimum güç katsayısında çalışabilmek için rüzgârı aldığı pozisyonunu ve kanat açılarını ayarlamaktadır. Bu şekilde üretebileceği maksimum gücü üretmiş olur.
- Nominal güç (tam yük) bölgesi, türbinin tam verimde çalıştığı bölgedir. Rüzgâr hızı artar ve anma gücünü geçecek olursa türbinde aşırı elektriksel yük meydana gelir.

Bunun yaşanmaması için, stall ve pitch kontrolleri ile türbin hızı kontrol altında alınır ve güç anma değerinde sabit tutulur.

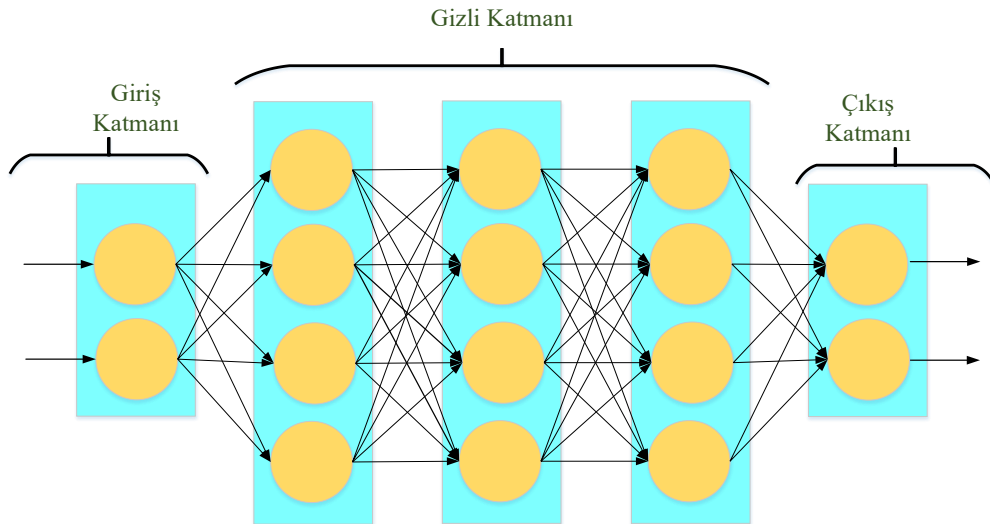
- Devreden çıkarma (cut-out), rüzgâr hızı türbinin tasarlandığı en yüksek hız sınırını aşacak olursa türbin güç üretmeyi kesmeli ve kapatılmalıdır. Bu şekilde yaşanacak herhangi bir hasar da engellenmiş olur [56,57].

4. DERİN ÖĞRENME İLE TAHMİN YÖNTEMLERİ

4.1. Yapay Sinir Ağları

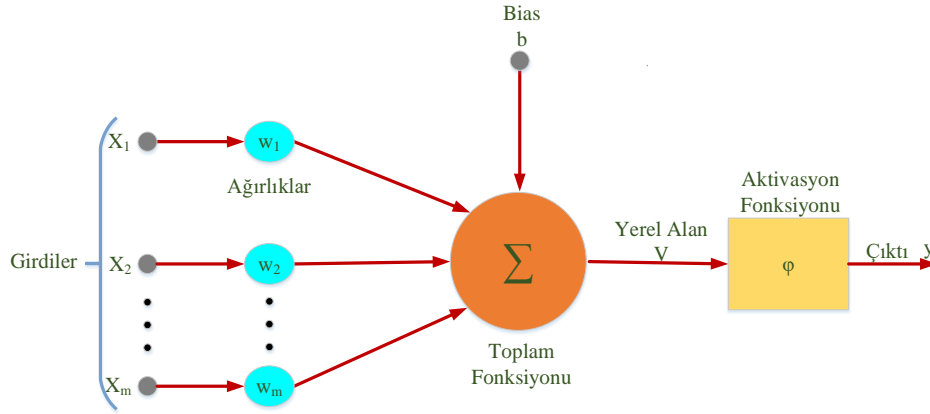
Yapay sinir ağları, insan beyni yapısından ilham alınarak oluşturulmuş modellerdir. Bilgiyi öğrenme, tanıma, işleme ve tüm bunların sonucunda bir karar verebilme özelliğine sahiptir.

Yapay sinir ağlarının yapıtaşları nöronlardır. Nöronlar girilen verileri bir aktivasyon fonksiyonuna alarak işlemekte ve bir çıkış verisi üretmektedir. Yapıları bakımından 2 veya 3 katmandan oluşabilmektedirler. Giriş katmanı, girdilerin ağa ilk işlendiği katmandır. Burada girilecek olan veri sayısı kadar nöron bulunmaktadır. Gizli katman, bir veya birden fazla katmandan oluşabilmektedir. Her katman kendinden önceki katmandan aldığı bilgiyi işleyerek bir sonraki katmana girdi olarak gönderir. Ve her katmanda farklı aktivasyon fonksiyonu kullanılmaktadır. Çıkış katmanı ise giriş verilerinden öğrendikleriyle bir çıkış değeri üretmesi beklenen katmandır. Sonuç olarak istenen parametrelere göre bir veya birden fazla çıktı değeri alınabilmektedir (Şekil 4.1).



Şekil 4.1. Yapay sinir ağı [59]

Yapay sinir ağlarının temeli olan nöronlar, biyolojik beyin hücrelerinden esinlenilerek oluşturulmuş matematiksel modellerdir. Bir araya gelen birçok nöron yapay sinir ağını oluşturur. Nöronlar arasındaki bilgi akışı ise ağırlıklar sayesinde gerçekleşir (Şekil 4.2).



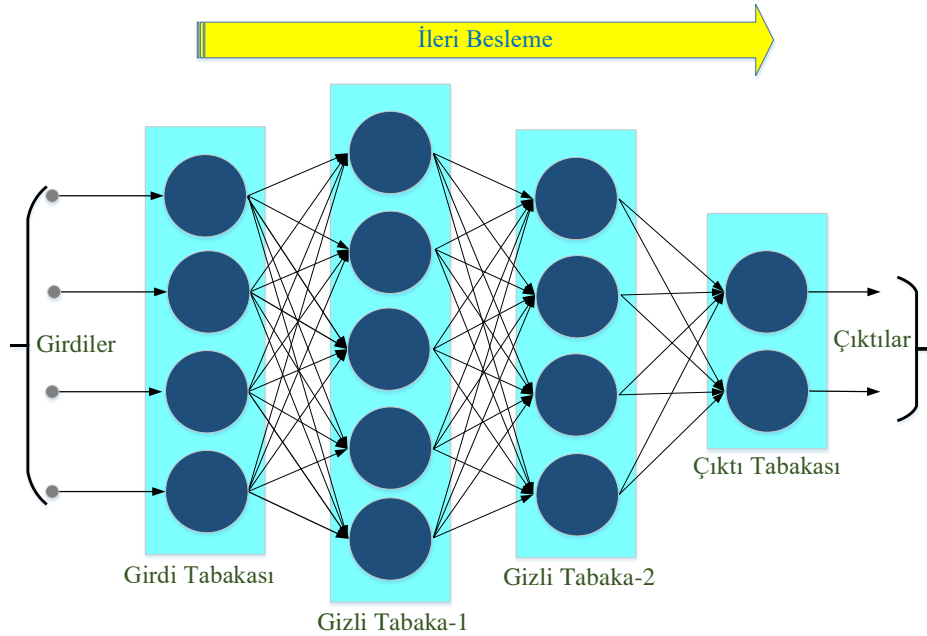
Şekil 4.2. Yapay sinir hücresi [60]

Yapay sinir ağını eğitmek için dışardan girilen verilere “girdiler” denir. Ağırlıklar, girilen verilerinin eğitimdeki önemi ve nöron üzerindeki etkisini belirler. Sinir ağı girilen veri üzerinde bir dizi matematiksel işlem gerçekleştirdikten sonra toplama fonksiyonuna gönderir. Geri yayılımlar ağırlıkların etkisinin ayarlanabilmesi ve çıktı verisinin daha sağlıklı sonuç vermesi için kullanılır. Sinir ağına nörona gelen tüm girdiler ağırlıklar ile çarpıldıktan sonra toplanır ve aktivasyon fonksiyonu için net girdiyi oluşturur. En sık kullanılan toplama fonksiyonları; toplam, çarpım, maksimum, minimum, çoğunluk, kümülatif toplam fonksiyonlarıdır. Hangi fonksiyonun kullanılacağı modeli oluşturacak tasarımcının kararına bağlıdır. Aktivasyon fonksiyonu, toplama fonksiyonundan aldığı veriyi işleyerek hücrenin üreteceği net çıktığı verecek olan fonksiyondur. En uygun fonksiyon seçimi kullanıcının neyi öğrenmesini istediğine göre değişebilmektedir. En sık kullanılan aktivasyon fonksiyonları; doğrusal fonksiyon, adım fonksiyonu, eşik fonksiyonu, sigmoid fonksiyonu, hiperbolik tanjant fonksiyonlarıdır. Çıktı, yapay sinir ağından aktivasyon fonksiyonu sonucunda çıktı olarak alınan birimdir. Bu sonuç ya cevap olarak kabul edilir ya da başka nöronlara girdi olarak gönderilebilir [61,62].

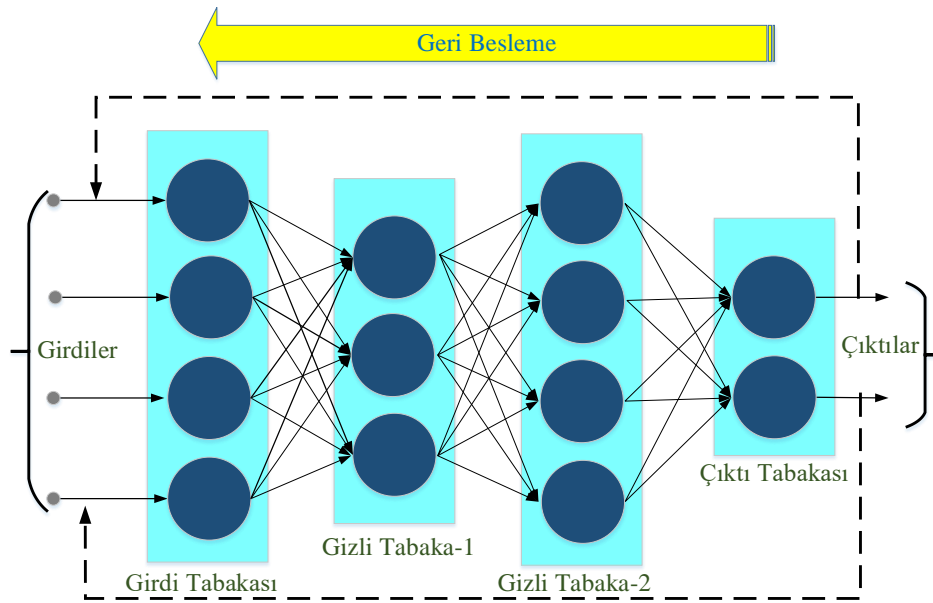
4.1.1. Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağları, dışarıdan girilen verileri aktivasyon fonksiyonunda işledikten sonra çıktı değerlerini üretir. Çıktı değerleri giriş verileri ile karşılaştırılarak hata oranı bulunur. Birbirinden farklı algoritmalar ile aynı işlemler gerçekleştirilerek en az hata oranı ile en iyi sonuçlar elde edilmeye çalışılır. Bu işlemler sırasında değişerek farklı hata oranlarını verecek olan parametre ağırlıklardır. En iyi hata oranı bulunduğu anda ise ağırlıklar sabit kalır ve ağırların eğitilmesi tamamlanmış olur.

Yapay sinir ağları yapılarına göre ileri besleme ve geri besleme şeklinde sınıflandırılırlar. Şekil 4.3'te gösterilen ileri beslemeli sinir ağlarında katmanlar arasında sadece giriş katmanından çıkış katmanına doğru tek yönlü bağlantılar vardır. Nöronun bir sonraki katmanda bulunan her bir nöronla arasında bağlantı varken, kendi katmanındaki nöronlarla hiçbir bağlantı bulunmamaktadır. Şekil 4.4'te gösterilen geri beslemeli sinir ağlarında ise, ara katman çıkışları ve çıkış katmanı kendinden bir önceki katmana girdi verisi olarak geri döner [61].



Şekil 4.3. Çok katmanlı ileri beslemeli sinir ağı mimarisi [63]



Şekil 4.4. Çok katmanlı geri beslemeli sinir ağı mimarisi [63]

4.2. Makine Öğrenmesi

Makine öğrenmesi, girilen veriler ile öğrenme yeteneği kazanan ve yeni çıktılar üretebilen bir dizi yöntemden oluşmaktadır. Girilen veriler sürekli olarak analiz edilerek öğrenme yeteneği geliştirilmektedir. Veri türüne ve çalışılan alana göre ağın geleceğe dair tahminlerde bulunması, görüntü işleme, desenler çıkarması gibi birçok konuda çıktı üretmesi beklenilir. Genellikle denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olarak üç ana kategoride incelenmektedir [64].

Denetimli öğrenmede ağın eğitilebilmesi için giriş verileri ile üretmesi beklenen çıkış değerlerinin birlikte girilmesi gerekmektedir. Giriş verilerini çıkış verilerine göre işleyerek en uygun ağırlık değerlerini bulmaya çalışır. Ağ hata oranını en aza indirene kadar işlem devam eder ve ağırlıklar sürekli olarak güncellenir. Denetimsiz öğrenmede ağa sadece giriş verileri girilmekte, hedef hakkında herhangi bir bilgi verilmemektedir. Ağ, sonuçları sınıflandırarak bir tahmin üretmekte ve çıktı değeri olarak sunmaktadır. Pekiştirmeli öğrenme türünde ağ ürettiği her tahmin ile bir değerlendirme yaparak en iyi sonuca ulaşmaya çalışır. Üretilen tahminlerin iyi ya da kötü olduğu konusunda ağa bilgi verilerek yeni değerler bulması istenir [65].

4.3. Derin Öğrenme

Derin öğrenme, esasında makine öğrenmesinin bir alt dalı olup, ileri beslemeli, çok katmanlı bir yapıya sahiptir. Hem denetimli öğrenme hem de denetimsiz öğrenme algoritmaları derin öğrenme ağının eğitilmesinde kullanılabilir. Makine öğrenmesinden farkı ise öznitelik çıkarma işlemine gerek duymamasıdır. Ağ bunu kendi başına yapabilmekte ve hangi özelliklerin önemli olduğuna karar verebilmektedir. Derin öğrenmede amaç insan gibi düşünebilen ve karar verebilen yapılar oluşturmaktır.

Birbirinin ardı sıra gelen birçok katmandan oluşan derin öğrenme, adını bu katmanların çokluğundan almaktadır. Katmanlar çoğaldıkça veriye ait en belirleyici özellikler seçilebilmektedir. Daha büyük veriler ve farklı parametreler işlenebilmekte, karmaşık yapılar çözülebilmekte ve etiketsiz veriler değerlendirilebilmektedir. Derin öğrenme, tüm bu işlemlerde diğer yöntemlere göre daha başarılı sonuçlar göstermektedir.

Derin öğrenme yaklaşımları; doğal dil işleme, sınıflandırma, konuşma, ses tanıma, otomatik sürüş, tıbbi teşhis, görüntü işleme ve tanıma gibi birçok alanda kullanılmaya uygundur.

Derin öğrenmede farklı türdeki verileri analiz edebilmek adına farklı yapılar geliştirilmiştir. En sık kullanılan denetimli derin öğrenme yapıları CNN), RNN, LSTM, DBN, Kısıtlı Boltzman Makinesi (Restricted Boltzman Machine-RBM) vb. şeklinde sıralanabilir [66]. Bu tez çalışmasında CNN yapısı kullanılmıştır.

4.3.1. Evrişimli Sinir Ağları (Convolutional Neural Network – CNN)

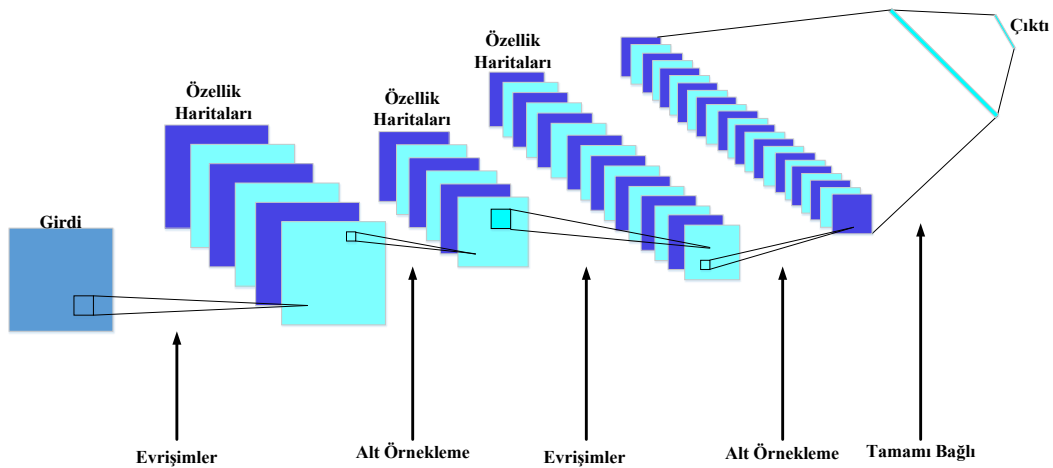
Yapısı bakımı ile özellikle görsel verilerin işlenmesinde ve analiz edilmesinde başarılı sonuçlar gösteren bir mimarıdır. Bunun yanında ses işleme, doğal dil işleme, biyomedikal, nesne tespiti ve yüz tanıma gibi birçok alanda da kullanılmaktadır. Yapı olarak evrişim, havuzlama ve tam bağlantılı katman olmak üzere üç bölümden oluşmaktadır (Şekil 4.5).

Evrişim katmanının amacı, girilen verilere ait özellikleri çıkarmaktır. Verinin bir görüntü olduğunu varsayarsak, evrişim katmanı görüntüye ait kenar, şekil, doku gibi özellikleri

tespit eder. Katmanı oluşturan filtreler, görüntü üzerinde dolaşır, farklı bölgelerin özelliklerini çıkartarak evrişim işlemi gerçekleştirir [67].

Havuzlama katmanı, ağıdaki parametre ve hesaplama miktarının azaltılması için evrişim katman çıktısını boyut olarak küçültür. Havuzlama katmanında genellikle iki yöntem kullanılır. Bunlar maksimum havuzlama (max pooling) ve ortalama havuzlama (average pooling) yöntemleridir. Maksimum havuzlamada belirlenen filtre aralığındaki maksimum değer alınırken, ortalama havuzlamada ortalama değer alınır. Böylece ağa ait yeterli bilgiyi verecek olan küçük boyutta çıktılar elde edilir [68].

Tam bağlı katmanda bulunan her bir nöron, bir önceki katmanda bulunan tüm nöronlarla bağlantılıdır. Bu katmanda çıktılar bir vektör matrisine dönüştürülür [65].




Şekil 4.5. CNN mimarisi [69]

4.3.2. Tekrarlayan Sinir Ağları (Recurrent Neural Network – RNN)

RNN, geleneksel yapay sinir ağlarından farklı olarak önceki katmanlarda girilen veriyi saklayarak sonraki katmanlarda kullanabilmektedir. Bu sayede zaman içerisinde değişiklik gösterebilen ve ardı sıra yenilenen verilerin işlenmesinde kullanıcıya kolaylık sağlayabilmektedir.

Şekil 4.6'da mimarisi gösterilen RNN, yapı olarak yapay sinir ağlarına benzese de giriş verisi olarak her bir zaman katmanının ürettiği çıktı verisini de işlemektedir. Bu özelliği

sayesinde veriler arasındaki bağlantı kesilmeden devam ederek bilginin sürekli olması sağlanmaktadır. RNN'nin bilgiyi hafızasında tutabilme özelliği, dil işleme, sınıflama, analiz etme gibi konularda tercih edilmesini ve başarılı sonuçlar elde edilmesini sağlamaktadır [11].



Şekil 4.6. RNN mimarisi [59]


4.3.3. Uzun-Kısa Süreli Hafıza Ağları (Long-Short Term Memory – LSTM)

LSTM, temelde RNN'nin bir türü olup, Hochreiter ve Schmidhuder tarafından 1997 yılında geliştirilmiştir. LSTM, temelde RNN'de yaşanan temel problem olan kaybolan gradyan sorununun üstesinden gelebilmektedir. LSTM'ler verileri koruyabilmek için hafızasında uzun süre depolayabilmekte ve kullanabilmektedir. Bu LSTM'lerin birbiri ile etkileşim halinde olan dört sinir ağı katmanı sayesinde mümkün olmaktadır (Şekil 4.7). Sinir ağı yapısında bulunan katmanlar; girdi kapısı (input gate), unutma kapısı (forget gate), çıktı kapısı (output gate) ve hücre durumudur (cell state).

Input gate, girilen verinin ağa eklenme miktarını ayarlayan katmandır. Tanh fonksiyonu sayesinde veriler -1 ile +1 değerleri arasına ayarlanmaktadır. Forget gate, hangi bilginin unutulması ve hangi bilginin tutulması gerektiğine karar verecek olan katmandır. Sıfır (0) değeri hiçbir bilginin geçişine izin verilmeyeceği, bir (1) değeri ise bilginin ağda tutulmaya devam edileceği anlamına gelmektedir. Gelen bilginin değeri sıfıra ne kadar yakın olursa unutulmaya o kadar yakındır. Yine aynı şekilde gelen bilginin değeri bire ne kadar yakınsa ağda tutulmaya o kadar devam edileceği anlamına gelmektedir. Cell state, ağda öğrenilmesi ve saklanması gereken bilginin taşınmasını sağlamaktadır. Bilgiyi önce hücre sonuna daha sonra da diğer hücelere taşımaktadır. Output gate, bir sonraki katmana gönderilecek olan

değerin ne olacağına ve ne kadar olacağına karar vermektedir. Katmanda elde edilen veriler, çıkış kapısının kontrolü ile ağın geri kalanına iletilmektedir.

LSTM'ler bu yapılar sayesinde RNN modelinden daha iyi öğrenebilmektedir. Bilgiyi saklayabilme özellikleri sayesinde zaman serisi tahmini, sağlıkta hasta durumunu takibi ve tahmini, dil modelleme, metin anlama ve çevirisi, konuşma tanıma ve çevirisi gibi birçok farklı alanda tercih edilmektedir [66,70,71,72].



Şekil 4.7. LSTM mimarisi [73]

5. MATERYAL VE YÖNTEM

Bu çalışmada Bingöl il merkezinde ölçülen geçmiş dönem rüzgâr hızı verileri kullanılarak kısa vadeli rüzgâr hızı tahmini yapılmıştır. Tahminler 1 saat, 3 saat, 6 saat, 9 saat ve 12 saat ilerisi için yapılmıştır. Tahmin yöntemi olarak CNN kullanılmıştır. Yapılan tahmin çalışmasında, Bingöl iline ait 01.01.2020 ile 01.02.2021 tarihleri arasındaki rüzgâr hızı verileri kullanılmıştır. Veriler Bingöl Meteoroloji Müdürlüğü'ne ait ölçüm istasyonlarında ölçülüp kaydedilen saatlik değerlerdir. Şekil 5.1'de çalışma için kullanılan Bingöl iline ait 17203 numaralı istasyonda 2020 Ocak ayında kaydedilmiş rüzgâr hızı verilerine yer verilmiştir.

T.C.
Tarım ve Orman Bakanlığı
Meteoroloji Genel Müdürlüğü

Yıl/Ay: 2020/1 İstasyon Adı/No: BİNGÖL/17203

Saatlik Rüzgâr Yönü ve Hızı (m+s)

Günaat	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
1	0.3	0.3	0.3	0.0	0.1	0.1	0.1	0.4	0.6	0.5	0.7	0.8	1.1	1.2	0.3	0.1	0.3	0.3	0.3	0.3	0.3	0.0	0.3	0.4
2	0.2	0.3	0.5	1.0	0.8	0.3	0.4	0.5	0.5	0.7	0.7	0.7	0.8	0.7	0.7	0.2	0.3	0.2	0.3	0.2	0.2	0.0	0.2	0.1
3	0.1	0.3	0.2	0.5	0.2	0.3	0.3	0.2	0.2	0.4	0.7	1.0	0.6	0.8	0.6	0.4	0.5	0.1	0.3	0.2	0.3	0.5	0.3	0.2
4	0.2	0.3	0.2	0.2	0.3	0.3	0.3	0.4	0.1	0.6	0.2	0.1	0.5	0.3	0.0			0.1	0.0	0.4	0.6	0.5	0.5	0.8
5	0.5	1.0	1	0.7	0.6	0.0	0.2	0.2	0.4	0.3	0.3	0.4	0.2	0.2	0.2	0.2	0.1	0.1	0.1	0.1	0.1	0.0	0.7	0.9
6	0.3	0.1	0.5	0.7	0.2	0.1	0.4	0.6	0.9	0.8	0.6	0.5	0.4	0.6	0.7	0.5	0.9	1	0.8	0.4	0.2	0.5	0.4	0.4
7	0.4	0.2	0.1	0.8	0.3	0.2	0.2	0.2	0.4	0.4	0.6	0.6	0.4	0.3	0.4	0.6	0.4	0.3	0.1	0.3	0.2	0.5	0.3	0.3
8	0.4	0.4	0.4	0.3	0.1	0.2	0.1	0.2	0.4	0.4	0.3	0.3	0.5	0.3	0.1	0.4	0.2	0.0	0.1	0.3	0.3	1.0	1.0	0.4
9	0.5	0.4	0.5	0.7	0.6	0.7	0.4	0.7	0.5	0.5	0.6	0.7	0.5	0.9	0.9	0.4	0.3	0.4	0.4	0.4	0.4	0.5	0.9	0.6
10	0.7	0.7	0.5	0.6	0.5	0.5	0.6	0.5	0.7	0.8	1	2.1	1.9	1.2	0.4	0.4	0.3	0.5	0.9	1.2	0.8	0.5	0.7	0.8
11	0.8	0.7	0.7	0.5	0.4	0.7	0.8	0.6	1	0.8	1.1	0.8	0.8	0.7	0.4	0.3	0.3	0.3	0.5	0.3	0.3	0.0	0.3	0.3
12	0.4	0.2	0.3	0.2	0.2	0.4	0.4	0.3	0.4	0.7	0.8	1.3	1.0	0.4	0.7	0.6	0.2	0.1	0.1	0.2	0.6	0.4	0.1	0.2
13	0.2	0.1	0.5	0.3	0.6	0.6	1	0.7	1.4	1.4	1.2	1.1	1.1	1.9	1.7	1.1	1.5	1.3	0.7	0.5	0.6	0.0	0.7	0.7
14	0.8	0.9	0.6	0.7	0.5	0.7	0.6	0.6	0.6	0.8	0.6	0.7	1.2	1.3	0.9	0.8	0.5	0.4	0.4	0.7	0.4	0.0	0.3	0.5
15	0.5	0.6	0.5	0.5	0.6	0.5	0.4	0.6	0.6	0.7	1.0	0.8	0.8	0.5	0.2	0.4	0.5	0.4	0.4	0.4	0.4	0.0	0.5	0.5
16	0.4	0.4	0.6	0.4	0.5	0.4	0.6	0.5	0.5	0.8	1.9	2.1	2.2	2	1.5	1.2	1.1	0.3	0.3	0.6	0.5	0.5	0.4	0.4
17	0.7	0.5	0.4	0.5	0.5	0.5	0.7	0.6	0.5	0.6	0.8	1	0.7	0.5	1.1	1.1	0.8	0.8	0.7	0.7	0.8	0.0	0.2	0.3
18	0.3	0.1	0.3	0.3	0.5	0.7	0.7	0.8	1.1	1.3	0.8	0.6	1.1	1.3	0.7	0.7	0.3	0.2	0.4	0.4	0.7	0.0	0.3	0.4
19	0.4	0.5	0.2	0.2	0.1	0.2	0.1	0.2	0.6	0.5	0.6	0.5	0.6	0.7	0.7	0.8	0.2	0.1	0.2	0.1	0.1	0.0	0.1	0.4
20	0.1	0.4	0.6	0.1	0.3	0.3	0.2	0.1	0.2	0.2	0.5	0.4	0.4	0.3	0.5	0.3	0.1	0.2	0.3	0.6	0.6	0.5	0.7	0.9
21	0.7	0.5	0.5	0.4	0.5	0.4	0.2	0.3	1	1.5	2.3	1.8	1.6	1.7	1.4	0.7	0.3	0.2	0.3	0.4	0.6	0.0	0.4	0.3
22	0.6	0.6	0.6	0.7	1	1	1.1	1.3	1.1	1.3	1.6	1.3	1	1.2	1.3	0.7	0.5	0.2	0.4	0.4	0.6	0.5	0.5	0.5
23	0.5	0.6	0.3	0.4	0.2	0.2	0.3	0.7	0.8	0.9	1	0.5	0.4	0.3	0.3	0.6	0.2	0.2	0.1	0.4	0.1	0.0	0.8	1
24	1.1	0.9	1.1	0.8	1.4	1.3	1.6	1.8	1.5	1.3	1.5	1.3	2.4	2.4	2.1	2.0	1.7	1.1	0.7	0.6	0.9	0.5	0.7	0.8
25	0.8	0.6	0.5	0.8	0.8	0.8	0.9	0.8	0.8	0.7	0.8	0.9	1.1	1.1	0.8	0.4	0.4	0.4	0.2	0.2	0.3	0.0	0.4	0.3
26	0.2	0.4	0.3	0.2	0.3	0.3	0.3	0.7	0.8	1	1.1	0.9	1	0.9	1.1	0.5	0.4	0.7	0.4	0.3	0.6	0.5	0.4	0.4
27	0.6	0.3	0.2	0.2	0.2	0.4	0.3	0.7	1	1	0.9	0.8	1	1.2	1.4	0.8	1.1	1.3	0.5	0.1	0.4	0.0	0.1	0.3
28	0.2	0.3	0.1	0.1	0.1	0.2	0.6	0.4	0.7	0.9	1	0.9	1.1	1.7	1.5	1.2	0.5	0.1	0.1	0.6	0.3	0.0	0.2	0.2
29	0.2	0.1	0.1	0.1	0.0	0.2	0.4	0.9	0.9	1.1	1	0.8	0.9	0.9	0.6	0.1	0.0	0.0	0.1	0.4	0.7	0.0	0.1	0.1
30	0.3	0.3	0.3	0.9	0.5	0.3	0.3	0.1	0.5	0.7	0.6	0.9	0.9	0.5	1.1	1.1	0.7	1.2	1.3	1.7	1.4	1	1.2	0.8
31	0.5	1.6	2.7	2.5	2.7	3	2.9	2.5	2	2	1	0.8	0.7	0.4	0.7	0.8	0.6	1.2	1.3	1.6	1.7	2.1	1.8	1.7

Şekil 5.1. 2020 yılı Ocak ayı rüzgâr hızı verileri

Verinin işlenmesi için MATLAB yazılım programı kullanılmıştır. Gerçek veriler ile üretilen tahmin verileri grafikler ile gösterilerek karşılaştırılmıştır. Ayrıca yapılan analizler sonucu elde edilen en düşük hata oranları da sunulmuştur.

RMSE (Kök Ortalama Kare Hatası); tahmin üretmek için nicel verilerin kullanıldığı çalışmalarda başvurulan bir hata oranı ölçme yöntemidir. Gerçek veriler ile tahmin değerleri arasındaki hata oranı Denklem 5.1 kullanılarak ölçülmektedir. Denklem sonucunun küçük olması, üretilen tahmin değerinin iyi olduğu anlamına gelir.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \widehat{y}_i)^2} \quad (5.1)$$

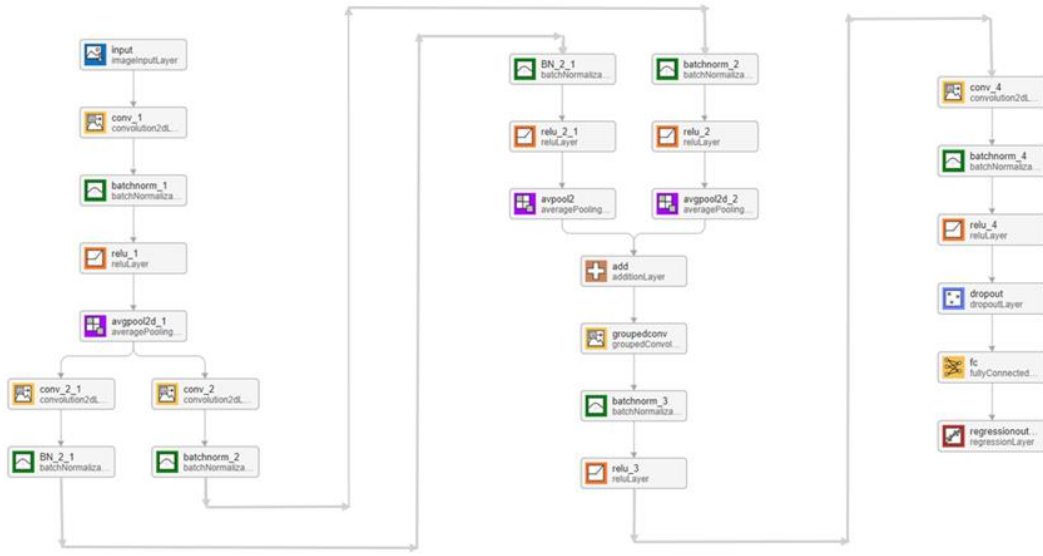
MAE (Ortalama Mutlak Hata); gerçek değerler ile üretilen tahmin sonuçları arasındaki değişimin ne oranda olduğunu ölçen yöntemdir (Denklem 5.2). Yine RMSE ile benzer şekilde denklem sonucunun küçük olması, tahmin değerlerinin iyi olduğu anlamına gelmektedir.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \widehat{y}_i| \quad (5.2)$$

R^2 (Determinasyon Katsayısı); gerçek değerler ile tahmin değerleri arasındaki ilişkinin derecesini ölçen yöntemdir. Denklem 5.3'e göre hesaplanan değer 0 ile 1 arasında olması beklenir. Sonucun 1 değerine yakın olması, tahmin değerlerinin daha iyi olduğunu, 0 değerine daha yakın olması ise tahmin değerlerinin daha kötü olduğunu göstermektedir [74].

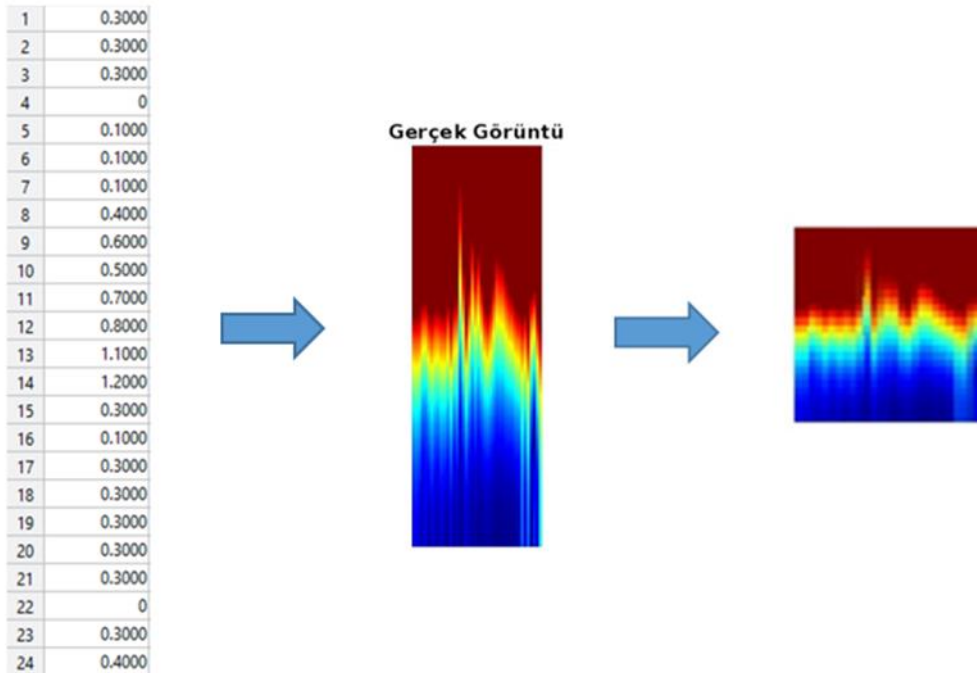
$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \widehat{y}_i)^2}{\sum_{i=1}^N (y_i - \overline{y})^2} \quad (5.3)$$

Kullanılan CNN modelinin ağ yapısı Şekil 5.2'de gösterildiği gibi tasarlanmıştır.



Şekil 5.2. CNN Ağ Yapısı

CNN derin öğrenme modeli, görüntü işleme konusunda daha iyi sonuçlar verdiği için dolayı çalışmada kullanılan rüzgâr hızı verileri önce görüntüye çevrilmiştir. Daha sonra bu görüntüler CNN modelinde işlenerek tahminler üretilmiştir. Verilerin %80'i modelin eğitilmesi, %10'u test, %10'u da doğrulama amaçlı kullanılmıştır.



Şekil 5.3. VMD ile rüzgâr hızı verilerinin görüntüye dönüştürülmesi

Verilerin görüntüye çevrilmesi işleminde Varyasyonel Mod Ayırıştırması (VMD) kullanılmıştır. VMD, giriş verisinin daha anlamlı bir şekilde temsil edilmesi için kullanılan önemli bir tekniktir. Bu yöntem, veriyi bileşenlerine ayırıştırarak ve bu bileşenlerin özelliklerini belirleyerek verinin yapısını ortaya çıkarır. Bu sayede, verinin içerdiği özelliklerin daha iyi anlaşılmasına olanak sağlar.

Geleneksel veri analizi yöntemlerinin aksine VMD, veri setinin karmaşıklığını azaltarak daha derin bir içgörü elde etmeyi hedefler. Bu yöntem, giriş verisindeki farklı bileşenleri veya örüntüleri belirleyerek, verinin içerdiği gizli yapının ortaya çıkarılmasını sağlar. Örneğin, bir zaman serisi verisinin VMD ile işlenmesi durumunda, verinin farklı frekanslardaki bileşenlere ayrıştırılması ve her bir bileşenin genlik ve frekansının belirlenmesiyle verinin içerdiği örüntülerin daha iyi anlaşılması sağlanır.

VMD'nin en büyük avantajlarından biri, giriş verisini daha az boyutlu bir temsil ile ifade ederek verinin daha anlamlı hale gelmesini sağlamasıdır. Bu, verinin daha iyi anlaşılmasını ve öznitelik değerlendirmesinin daha etkili bir şekilde yapılmasını sağlar.

Sonuç olarak VMD, verinin daha derinlemesine incelenmesini sağlayarak özniteliklerin ve yapısal özelliklerin daha iyi anlaşılmasını sağlar. Bu da veri analizi ve özellik çıkarımı gibi birçok uygulama alanında önemli bir araç haline gelmektedir.

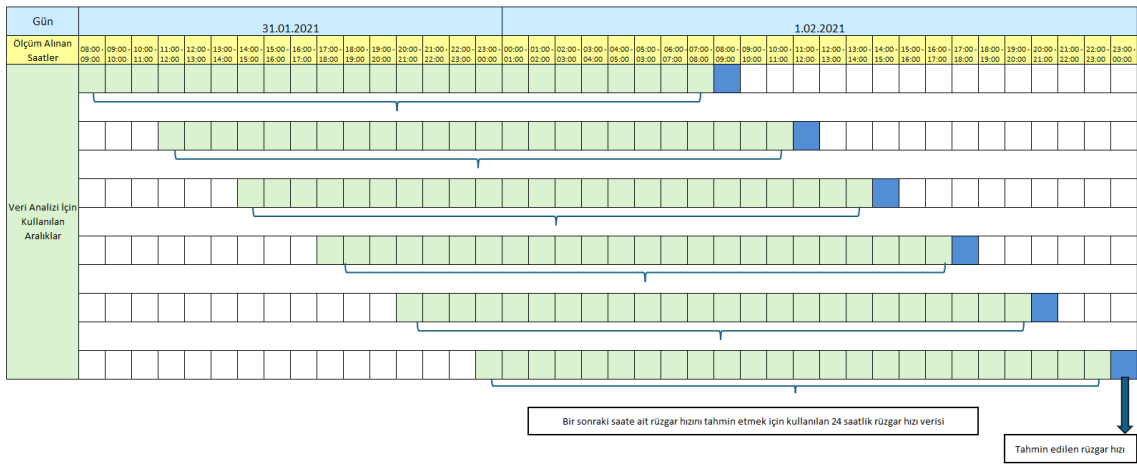
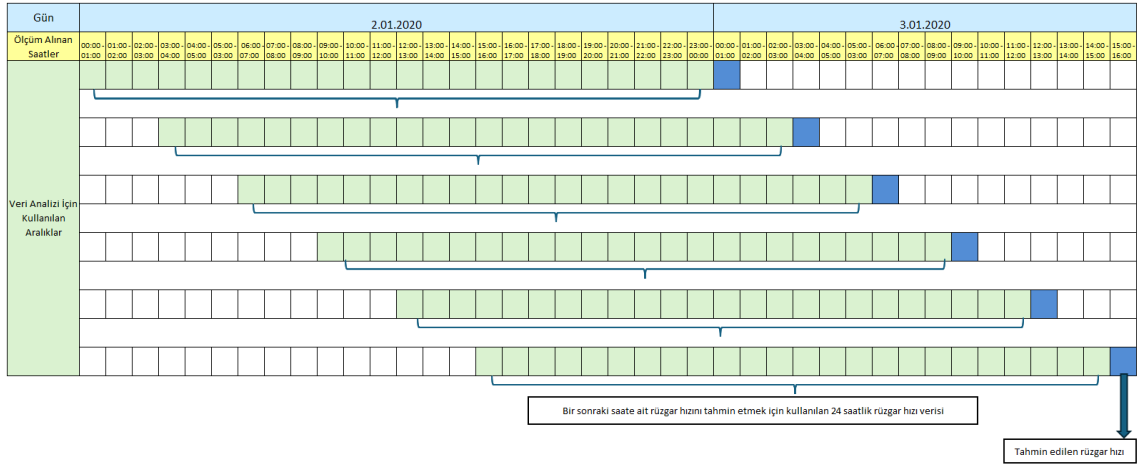
Şekil 5.3'te görüldüğü gibi 24 saatlik rüzgâr hızı verisi tek boyutlu veri halindedir. VMD ile bu 24 saatlik veri bir görüntü verisine dönüştürülmüştür. 24 saatlik verinin işlenmesi ile 25. saatin rüzgâr hızı verisi tahmin edilmektedir. Bu şekilde 365 günün rüzgâr hızı verileri görüntü verilerine dönüştürülerek tahminler üretilmiştir.



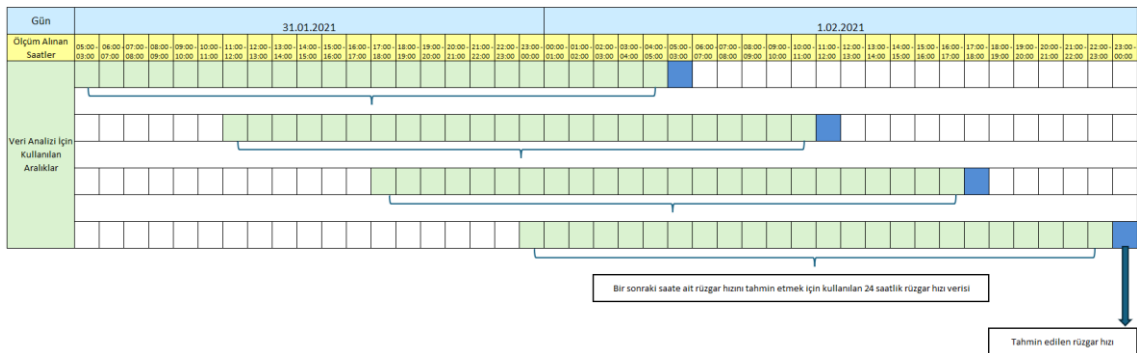
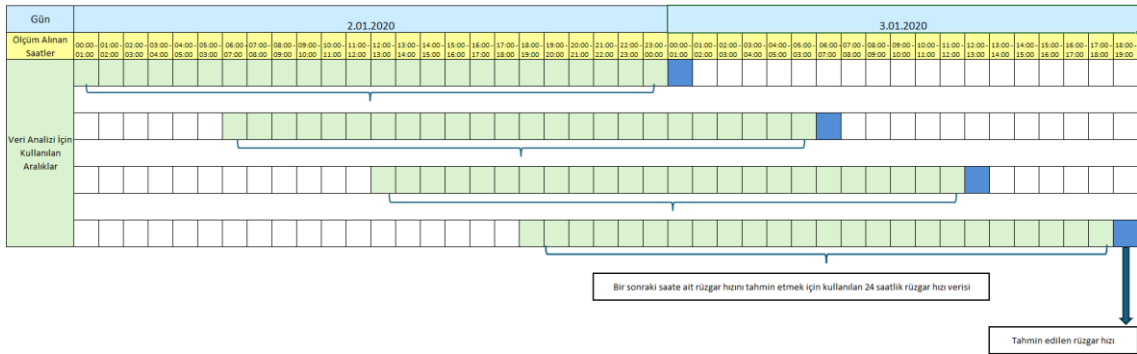
Şekil 5.4. Bir saat ilerisi için tahmin üretme yöntemi

İlk uygulamada 1 saat ilerisi için tahmin çalışması yapılmıştır. Bunun için 2 Ocak 2020'ye ait ilk 24 saate ait rüzgâr hızı verisi işlenerek 25. saat için rüzgâr hızı tahmini yapılmıştır. Bir sonraki adımda 1. saat kullanılmayıp bir sonraki 24 saatlik veri yani 2-25. saatlere ait veriler kullanılarak 26. saat için rüzgâr hızı tahmini yapılmıştır. 1'er saat atlayarak gerçekleştirilen işlemler Şekil 5.4'te gösterildiği gibi 01.02.2021'e kadar tekrarlanmıştır.

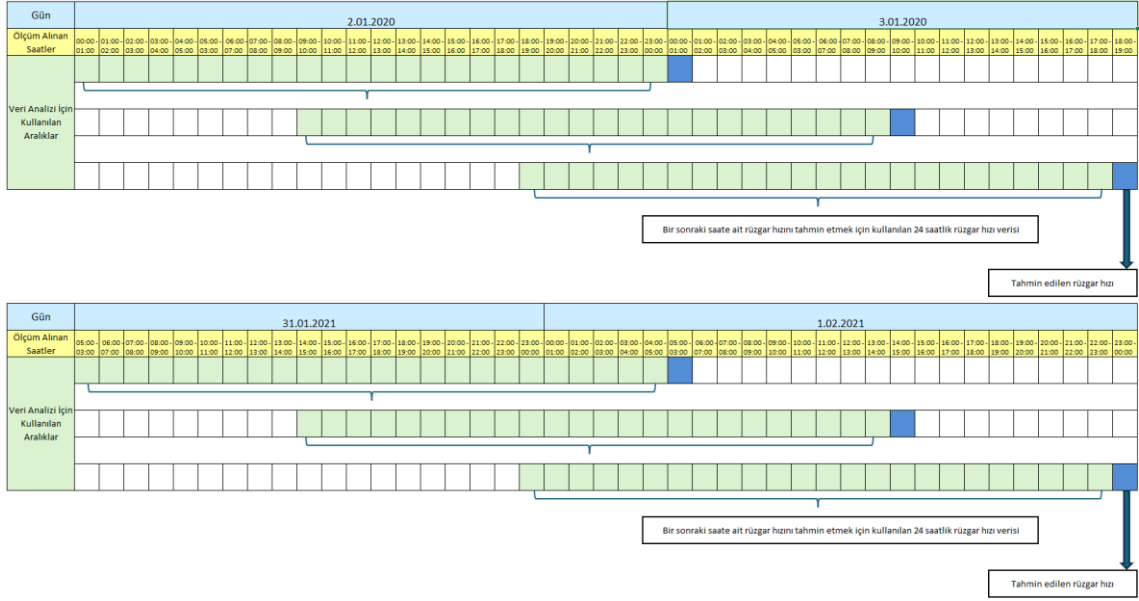
Benzer şekilde yukarıda açıklanan işlemler sırasıyla 3, 6, 9 ve 12 saatlik tahminler için tekrarlanmıştır. Bu işlemlere ait şekiller sırasıyla Şekil 5.5, 5.6, 5.7 ve 5.8'de gösterilmiştir.



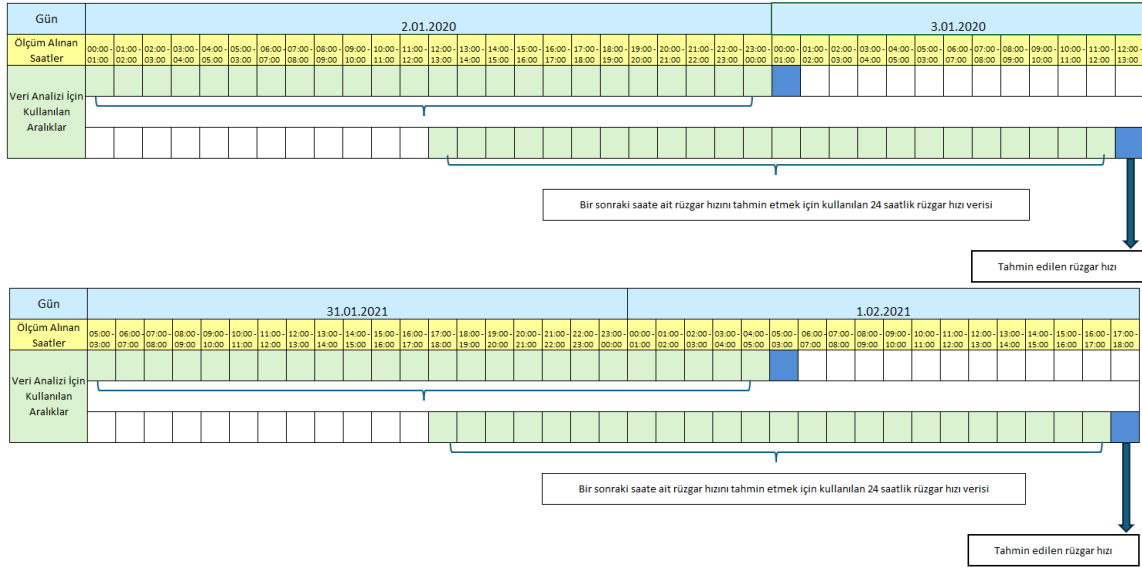
Şekil 5.5. Üç saat ilerisi için tahmin üretme yöntemi



Şekil 5.6. Altı saat ilerisi için tahmin üretme yöntemi



Şekil 5.7. Dokuz saat ilerisi için tahmin üretme yöntemi




Şekil 5.8. On iki saat ilerisi için tahmin üretme yöntemi

1. BULGULAR VE TARTIŞMA

6.1. Bir Saatlik Tahmin Sonuçları

Kullanılan CNN mimarisi eğitim modeli, MATLAB R2023b ile Intel® Core™ i9-13900H işlemcili, 32 GB belleğe ve 6 GB grafik kartına sahip bir dizüstü bilgisayarda gerçekleştirildi. GoogLeNet parametreleri (öğrenme hızı, doğrulama sıklığı ve dönem sayısı) eğitim süreci sırasında optimize edilmiştir. Bu amaçla çeşitli parametreler için uygun değerleri bulmak amacıyla birçok deneme gerçekleştirilmiştir. Buna göre başlangıç öğrenme oranı (initial learning rate), mini grup boyutu (mini batch size) ve maksimum epok (maximum epochs) değerleri 0,0001, 32 ve 120 olarak seçilmiştir. Öğrenilebilir parametreleri optimize etmek için ADAM Optimizasyon Algoritması kullanılmıştır.

CNN ağının eğitim modeli Şekil 6.1’de gösterilmektedir. Bir saatlik tahmin değerlerine ilişkin hata değerleri Tablo 6.1’de sunulmuştur.




Şekil 6.1. Bir saat ileri zamanlı rüzgâr hızı tahmini için kullanılan CNN ağı eğitim modeli

Tablo 6.1. Bir saat ileri zamanlı rüzgâr hızı tahmini için hata oranları

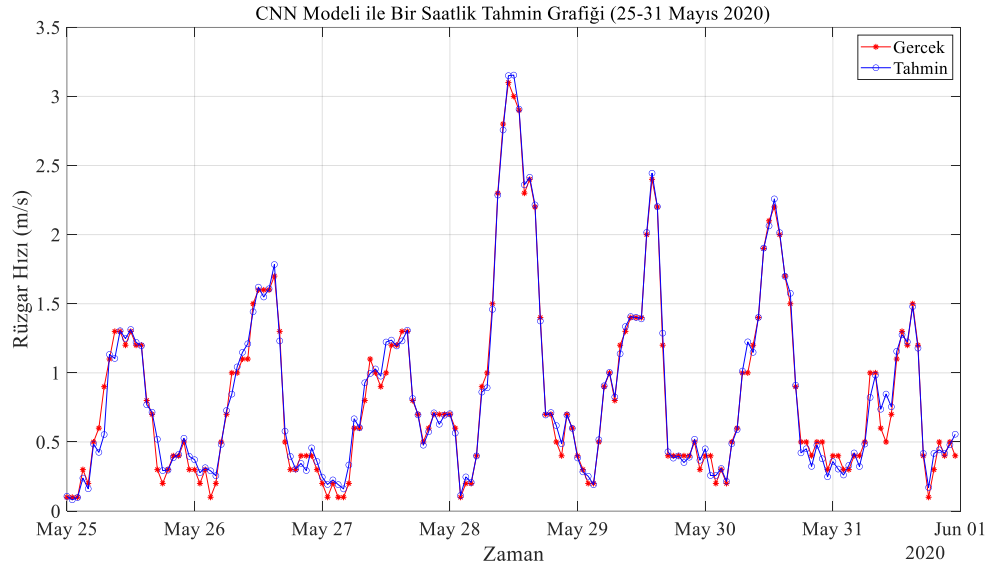
RMSE	0,0513
R^2	0,8999
MAE	0,0400

CNN modelinin 02.01.2020 ile 01.02.2021 tarihleri arasında ürettiği bir saatlik rüzgâr hızı tahmin verileri ve gerçek rüzgâr hızı verileri Şekil 6.2’de verilmiştir.




Şekil 6.2. CNN modeli ile bir saat ileri zamanlı rüzgâr hızı tahmin grafiği (02.01.2020-01.02.2021)


Tahmin verilerinin daha iyi analiz edilmesi için belirli zaman dilimleri seçilerek eğriler yeniden çizdirilmiştir. Bu amaçla seçilen 25-31 Mayıs günleri, 5 Haziran 2020 günü ve 2020 yılı aralık ayı için eğriler sırasıyla Şekil 6.3, Şekil 6.4 ve Şekil 6.5’te sunulmuştur.



Şekil 6.3. CNN modeli ile bir saat ileri zamanlı rüzgâr hızı tahmin grafiđi (25-31.05.2020)




Şekil 6.4. CNN modeli ile bir saat ileri zamanlı rüzgâr hızı tahmin grafiđi (05.06.2020)



Şekil 6.5. CNN modeli ile bir saat ileri zamanlı rüzgâr hızı tahmin grafiği (01-31.12.2020)

6.2. Üç Saatlik Tahmin Sonuçları

CNN ağının eğitim modeli Şekil 6.6'da gösterilmektedir. Üç saatlik tahmin değerlerine ilişkin hata değerleri Tablo 6.2'de sunulmuştur.




Şekil 6.6. Üç saat ileri zamanlı rüzgâr hızı tahmini için kullanılan CNN ağı eğitim modeli

Tablo 6.2. Üç saat ileri zamanlı rüzgâr hızı tahmini için hata oranları


RMSE	0,0791
R^2	0,8372
MAE	0,0611

CNN modelinin 02.01.2020 ile 01.02.2021 tarihleri arasında ürettiği üç saatlik rüzgâr hızı tahmin verileri ve gerçek rüzgâr hızı verileri Şekil 6.7’de verilmiştir.




Şekil 6.7. CNN modeli ile üç saat ileri zamanlı rüzgâr hızı tahmin grafiği (02.01.2020-01.02.2021)


Tahmin verilerinin daha iyi analiz edilmesi için belirli zaman dilimleri seçilerek eğriler yeniden çizdirilmiştir. Bu amaçla seçilen 25-31 Mayıs günleri, 5 Haziran 2020 günü ve 2020 yılı aralık ayı için eğriler sırasıyla Şekil 6.8, Şekil 6.9 ve Şekil 6.10’da sunulmuştur.



Şekil 6.8. CNN modeli ile üç saat ileri zamanlı rüzgâr hızı tahmin grafiği (25-31.05.2020)




Şekil 6.9. CNN modeli ile üç saat ileri zamanlı rüzgâr hızı tahmin grafiği (05.06.2020)



Şekil 6.10. CNN modeli ile üç saat ileri zamanlı rüzgâr hızı tahmin grafiği (01-31.12.2020)

6.3. Altı Saatlik Tahmin Sonuçları

CNN ağının eğitim modeli Şekil 6.11’de gösterilmektedir. Altı saatlik tahmin değerlerine ilişkin hata değerleri Tablo 6.3’te sunulmuştur.




Şekil 6.11. Altı saat ileri zamanlı rüzgâr hızı tahmini için kullanılan CNN ağı eğitim modeli

Tablo 6.3. Altı saat ileri zamanlı rüzgâr hızı tahmini için hata oranları


RMSE	0,0984
R ²	0,8142
MAE	0,0735

CNN modelinin 02.01.2020 ile 01.02.2021 tarihleri arasında ürettiği altı saatlik rüzgâr hızı tahmin verileri ve gerçek rüzgâr hızı verileri Şekil 6.12’de verilmiştir.




Şekil 6.12. CNN modeli ile altı saat ileri zamanlı rüzgâr hızı tahmin grafiği (02.01.2020-01.02.2021)


Tahmin verilerinin daha iyi analiz edilmesi için belirli zaman dilimleri seçilerek eğriler yeniden çizdirilmiştir. Bu amaçla seçilen 25-31 Mayıs günleri, 5 Haziran 2020 günü ve 2020 yılı aralık ayı için eğriler sırasıyla Şekil 6.13, Şekil 6.14 ve Şekil 6.15’te sunulmuştur.



Şekil 6.13. CNN modeli ile altı saat ileri zamanlı rüzgâr hızı tahmin grafiği (25-31.05.2020)




Şekil 6.14. CNN modeli ile altı saat ileri zamanlı rüzgâr hızı tahmin grafiği (05.06.2020)



Şekil 6.15. CNN modeli ile altı saat ileri zamanlı rüzgâr hızı tahmin grafiği (01-31.12.2020)

6.4. Dokuz Saatlik Tahmin Sonuçları

CNN ağının eğitim modeli Şekil 6.16'da gösterilmektedir. Dokuz saatlik tahmin değerlerine ilişkin hata değerleri Tablo 6.4'te sunulmuştur.




Şekil 6.16. Dokuz saat ileri zamanlı rüzgâr hızı tahmini için kullanılan CNN ağı eğitim modeli

Tablo 6.4. Dokuz saat ileri zamanlı rüzgâr hızı tahmini için hata oranları


RMSE	0,1197
R^2	0,6569
MAE	0,0903

CNN modelinin 02.01.2020 ile 01.02.2021 tarihleri arasında ürettiği 9 saatlik rüzgâr hızı tahmin verileri ve gerçek rüzgâr hızı verileri Şekil 6.17’de verilmiştir.

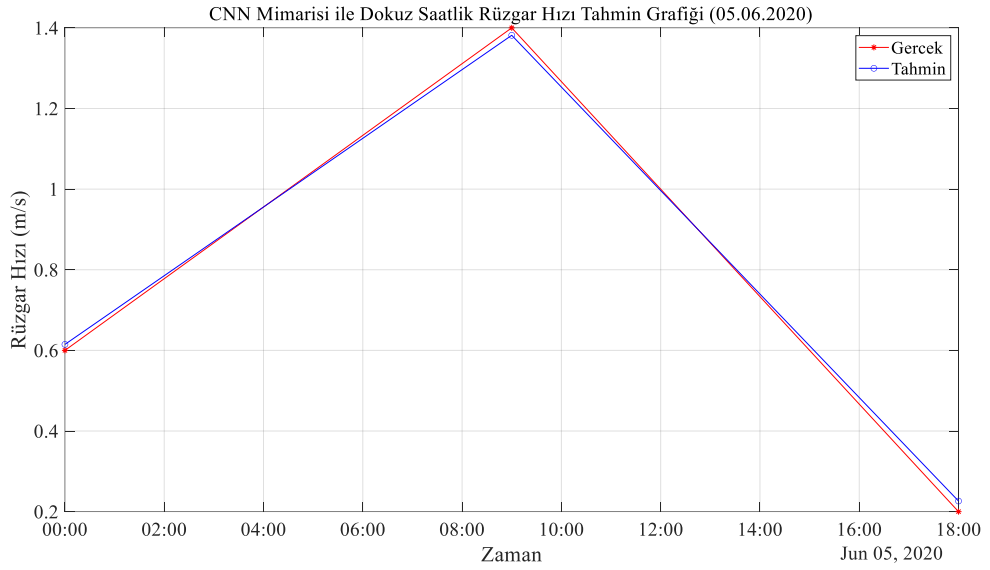


Şekil 6.17. CNN modeli ile dokuz saat ileri zamanlı rüzgâr hızı tahmin grafiği (02.01.2020-01.02.2021)


Tahmin verilerinin daha iyi analiz edilmesi için belirli zaman dilimleri seçilerek eğriler yeniden çizdirilmiştir. Bu amaçla seçilen 25-31 Mayıs günleri, 5 Haziran 2020 günü ve 2020 yılı aralık ayı için eğriler sırasıyla Şekil 6.18, Şekil 6.19 ve Şekil 6.20’de sunulmuştur.



Şekil 6.18. CNN modeli ile dokuz saat ileri zamanlı rüzgâr hızı tahmin grafiği (25-31.05.2020)




Şekil 6.19. CNN modeli ile dokuz saat ileri zamanlı rüzgâr hızı tahmin grafiği (05.06.2020)



Şekil 6.20. CNN modeli ile dokuz saat ileri zamanlı rüzgâr hızı tahmin grafiği (01-31.12.2020)

6.5. On İki Saatlik Tahmin Sonuçları

CNN ağının eğitim modeli Şekil 6.21'de gösterilmektedir. On iki saatlik tahmin değerlerine ilişkin hata değerleri Tablo 6.5'te sunulmuştur.




Şekil 6.21. On iki saat ileri zamanlı rüzgâr hızı tahmini için kullanılan CNN ağı eğitim modeli

Tablo 6.5. On iki saat ileri zamanlı rüzgâr hızı tahmini için hata oranları


RMSE	0,1074
R^2	0,8342
MAE	0,0817

CNN modelinin 02.01.2020 ile 01.02.2021 tarihleri arasında ürettiği 12 saatlik rüzgâr hızı tahmin verileri ve gerçek rüzgâr hızı verileri Şekil 6.22’de verilmiştir.




Şekil 6.22. CNN modeli ile on iki saat ileri zamanlı rüzgâr hızı tahmin grafiği (02.01.2020-01.02.2021)

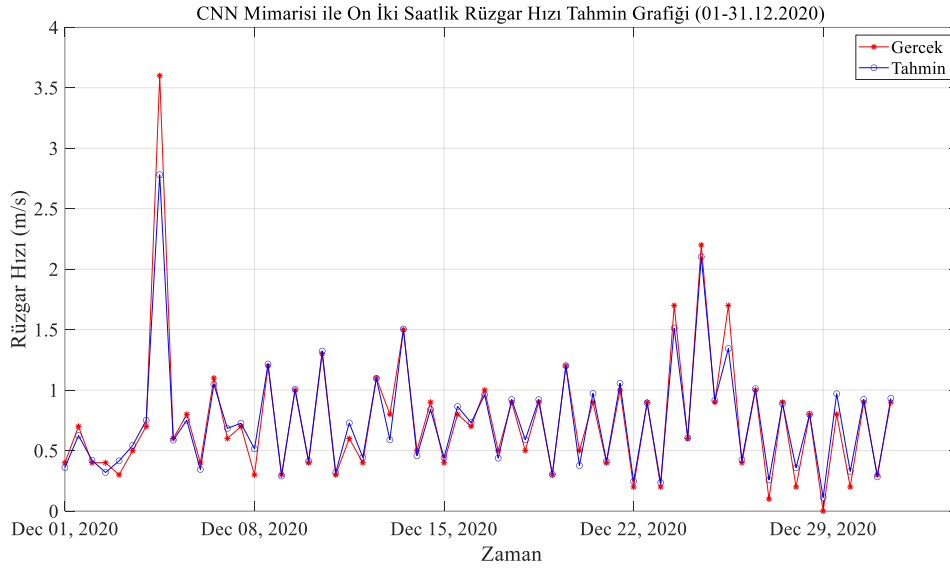
Tahmin verilerinin daha iyi analiz edilmesi için belirli zaman dilimleri seçilerek eğriler yeniden çizdirilmiştir. Bu amaçla seçilen 25-31 Mayıs günleri, 5 Haziran 2020 günü ve 2020 yılı aralık ayı için eğriler sırasıyla Şekil 6.23, Şekil 6.24 ve Şekil 6.25’te sunulmuştur.



Şekil 6.23. CNN modeli ile on iki saat ileri zamanlı rüzgâr hızı tahmin grafiği (25-31.05.2020)



Şekil 6.24. CNN modeli ile on iki saat ileri zamanlı rüzgâr hızı tahmin grafiği (05.06.2020)



Şekil 6.25. CNN modeli ile on iki saat ileri zamanlı rüzgâr hızı tahmin grafiği (01-31.12.2020)

Tablo 6.6'da farklı zaman aralıkları için yapılan tahminlerin hata oranları karşılaştırılmıştır. Bu karşılaştırma, 1, 3, 6, 9 ve 12 saat ileriye dönük tahminlerin performansını değerlendirmektedir. Analiz sonuçlarına göre, en başarılı tahmin sonuçları, 1 saat ilerisi için elde edilmiştir. Zaman aralığının artmasıyla birlikte, hata oranlarının arttığı ve tahmin değerlerinin gerçek değerlerden uzaklaştığı gözlemlenmektedir.

Tablo 6.6. Rüzgâr hızı tahmini için tüm zamanlarda elde edilen hata oranlarının karşılaştırılması

Zaman / Yöntem	RMSE	R^2	MAE
1 Saat	0,0513	0,8999	0,0400
3 Saat	0,0791	0,8372	0,0611
6 Saat	0,0984	0,8142	0,0735
9 Saat	0,1197	0,6569	0,0903
12 Saat	0,1074	0,8342	0,0817

Bu bulgular, kısa vadeli tahmin yöntemlerinin genellikle daha güvenilir olduğunu ve zaman aralığındaki uzamanın tahmin doğruluğunu olumsuz yönde etkileyebileceğini işaret etmektedir. Bu önemli bulgular, gelecekteki tahmin modellerinin geliştirilmesi için önemli bir katkı sağlayacaktır.

Bu çalışma, belirli zaman aralıklarında yapılan tahminlerin sonuçlarına ve bu tahminlerdeki hata oranlarına odaklanmaktadır. Analiz sonuçlarına göre, kısa vadeli tahmin yöntemleri, seçilen saat aralıklarında en iyi sonuçları üretmektedir. Ancak, zaman aralığı arttıkça, tahmin sonuçlarında belirgin sapmalar gözlemlenmekte ve bu durum sağlıklı tahmin sonuçlarına neden olmaktadır.

7. SONUÇ VE ÖNERİLER

Bu tez çalışmasında Bingöl ili için derin öğrenme yöntemi ile rüzgâr hızı tahmini yapılmıştır. Derin öğrenme modelini eğitmek ve rüzgâr hızı tahmini yapabilmek adına Bingöl Meteoroloji Müdürlüğü'nce 01.01.2020 ile 01.02.2021 tarihleri arasında kaydedilen rüzgâr hızı değerleri kullanılmıştır.

Farklı saat aralıklarında yapılacak olan tahmin değerlerinde oluşabilecek değişiklikleri gözlemlemek adına 1, 3, 6, 9 ve 12 saat ilerisi için tahminler üretilmiştir. Sonuçlar ile gerçek değerler karşılaştırılarak modelin başarısı ölçülmüştür. Elde edilen tüm veriler grafikler ve tablolar halinde sunulmuştur. Hata oranları her grup için ayrı verilmekle beraber tüm değerler ayrıca tek bir tablo halinde gösterilerek karşılaştırılmıştır.

Bu çalışmada belirlenen zaman aralığına ait tüm saatler bir bütün halinde ele alınmakla beraber istenilen bir tarihe özel tahminler yapılabileceği de gösterilmiştir. Bu durum farklı çalışmalar için veri alınabilecek zaman aralığının genişletilebileceğini, mevsimlere özel tahminler yapılabileceğini ya da sadece belirli rüzgâr hızı aralığı seçilerek tahminlerde bulunulabileceğini ortaya koymaktadır.

Bu çalışmanın temel alınmasıyla bir bölgede rüzgâr santrali kurulumu mümkün olabilir ve bu konuda ön bir araştırma yapmak oldukça değerli olabilir. Ayrıca, mevcut santraller bu çalışma doğrultusunda belirli bir zaman aralığındaki enerji üretimini hesaplayabilir, enerji piyasası koşullarına göre planlama yapabilir ve bakım zamanlarını daha etkili bir şekilde planlayabilir.

Bu esnek uygulama alanları, rüzgâr enerjisi sektöründe daha verimli ve öngörülebilir enerji üretimi için önemli bir adım olabilir. Gelecekteki çalışmalar, bu yöntemlerin daha geniş ölçekte uygulanabilirliğini ve rüzgâr enerjisi tesislerinin daha etkili yönetimini sağlamak adına daha fazla detay içerebilir.

KAYNAKLAR

- [1] <https://iea.blob.core.windows.net/assets/d0031107-401d-4a2f-a48b-9eed19457335/GlobalEnergyReview2021.pdf> (Erişim tarihi:06.12.2023)
- [2] Naim HA, Darwish AG, Maria GC, Maurizio C. Sustainable energy development. *Renewable and Sustainable Energy Reviews*. 1998; 2(3): 235-286.
- [3] Landrigan PJ, Fuller R, Acosta NJR, Adeyi O, Arnold R, Basu N, et al. The lancet commissions on pollution and health. *Lancet*. 2018; 391(10119): 462–512.
- [4] Paksoy HÖ. Thermal energy storage for sustainable energy consumption: Fundamentals, case studies and design. Dordrecht, NLD: Springer. 2007.
- [5] Bilgen S. Structure and environmental impact of global energy consumption. *Renewable and Sustainable Energy Reviews*. 2014; Volume 38: 890-902.
- [6] Lahlou S. System innovation for sustainability 4. Case studies in sustainable consumption and production: energy use and the built environment. Sheffield, GBR: Greenleaf Publishing. 2010.
- [7] Elyasichamazkoti F, Khajehpoor A. Application of machine learning for wind energy from design to energy-Water nexus: A Survey. *Energy Nexus*. 2021; Volume 2: 10001.
- [8] Shamsirband S, Rabczuk T and Chau KW. A survey of deep learning techniques: Application in wind and solar energy resources. *IEEE Access*. 2019; Volume 7: 164650-164666.
- [9] Chang W. A literature review of wind forecasting methods. *Journal of Power and Energy Engineering*. 2014; Volume 2: 161-168.
- [10] Kırbaş İ. İstatistiksel metotlar ve yapay sinir ağları kullanarak kısa dönem çok adımlı rüzgâr hızı tahmini. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 2010; 22 (1): 24-38.
- [11] Tekinay Ç. Türkiye'nin günlük rüzgâr enerjisi üretiminin derin öğrenme ile modellenmesi. Yüksek lisans tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü. 2022.

- [12] Wang X, Guo P, Huang X. A Review of wind power forecasting models. *Energy Procedia*. 2011; Volume 12: 770-778.
- [13] Zheng L, Lu W, Zhou Q. Weather image-based short-term dense wind speed forecast with a ConvLSTM-LSTM deep learning model. *Building and Environment*. 2023; Volume 239: 110446.
- [14] Zhang D, Hu G, Song J, Gao H, Ren H, Chen W. A novel spatio-temporal wind speed forecasting method based on the microscale meteorological model and a hybrid deep learning model. *Energy*. 2023; 288(1): 129823.
- [15] Jamil İ, Lucheng H, Iqbal S, Aurangzaib M, Jamil R, Kotb H, Alkuhayli A, AboRas KM. Predictive evaluation of solar energy variables for a large-scale solar power plant based on triple deep learning forecast models. *Alexandria Engineering Journal*. 2023; Volume 76: 51-73.
- [16] Hong YY, Rioflorido CLPP. A hybrid deep learning-based neural network for 24-h ahead wind power forecasting. *Applied Energy*. 2019; Volume 250: 530-539.
- [17] Özkay B. Derin öğrenme kullanılarak Bilecik İli rüzgâr hızı tahmini. Yüksek lisans tezi, Bilecik Üniversitesi, Fen Bilimleri Enstitüsü. 2021.
- [18] Yazdi AS. Short-term and medium-term wind speed forecasting via adaptive neuro-fuzzy inference systems. Master's thesis. Bahçeşehir Universty; Natural And Applied Sciences. 2019.
- [19] Kayabaşı E. Yapay sinir ağları ve çoklu lineer regresyon yöntemleri ile rüzgâr gücü tahmini. Yüksek lisans tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü. 2019.
- [20] Yazıcı K. Makine öğrenmesi yöntemleri kullanılarak kısa dönem rüzgâr gücü tahmini. Yüksek lisans tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü. 2021.
- [21] Zorlu E. İç Anadolu Bölgesi için modern kontrol yöntemleri ile rüzgâr hızı tahmini: Kırşehir bölgesi örneği. Yüksek lisans tezi, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü. 2015.
- [22] Minaz MR. Bilecik İlinin uyarlanırlı sinir bulanık çıkarım sistemi ile basınç, sıcaklık ve rüzgâr hızı tahmini. Yüksek lisans tezi, Bilecik Üniversitesi, Fen Bilimleri Enstitüsü. 2011.
- [23] Tan M. İkincil ayrıştırma tekniği kullanarak yapay sinir ağı temelli çok adımlı rüzgâr hızı tahmini. Yüksek lisans tezi, Gaziosman Paşa Üniversitesi, Fen Bilimleri Enstitüsü. 2020.

- [24] Chandran V, Patil CK, Manoharan AM, Ghosh A, Sumithra MG, Karthick A, Rahim R, Arun K. Wind power forecasting based on time series model using deep machine learning algorithms. *Materials Today: Proceedings*. 2021; 47(1): 115-126.
- [25] Görgel P, Kavlak E. Uzun kısa süreli hafıza ve evrişimsel sinir ağları ile rüzgâr enerjisi üretim tahmini. *DÜMF MD*. 2020; 11(1): 69–80.
- [26] Toubreau JF, Dapoz PD, Bottieau J, Wautier A, Grève ZD, Vallée F. Recalibration of recurrent neural networks for short-term wind power forecasting. *Electric Power Systems Research*. 2021; Volume 190: 106639.
- [27] Yıldız C, Acikgoz H, Korkmaz D, Budak Ü. An improved residual-based convolutional neural network for very short-term wind power forecasting. *Energy Conversion and Management*. 2021; Volume 228: 113731.
- [28] Lin, WH, Wang P, Chao, KM, Lin HC, Yang ZY, Lai YH. Wind power forecasting with deep learning networks: time-series forecasting. *Applied Sciences*. 2021; 11(21): 10335.
- [29] Liu H, Yu C, Wu H, Duan Z, Yan G. A new hybrid ensemble deep reinforcement learning model for wind speed short term forecasting, *Energy*. 2020; Volume 202: 117794.
- [30] Wang HZ, Wang GB, Li GQ, Peng JC, Liu YT. Deep belief network based deterministic and probabilistic wind speed forecasting approach. *Applied Energy*. 2016; Volume 182: 80-93.
- [31] Tarek Z, Shams MY, Elshewey AM, El-kenawy EM, Ibrahim A et al. Wind power prediction based on machine learning and deep learning models. *Computers, Materials & Continua*. 2023; 74(1): 715–732.
- [32] Xiong J, Peng T, Tao Z, Zhang C, Song S, Nazir MS. A dual-scale deep learning model based on ELM-BiLSTM and improved reptile search algorithm for wind power prediction. *Energy*. 2023; Volume 266: 126419.
- [33] Christoforou E, Emiris IZ, Florakis A et al. Spatio-temporal deep learning for day-ahead wind speed forecasting relying on WRF predictions. *Energy Systems*. 2023; 14(2): 473–493.
- [34] Yaghoubirad M, Azizi N, Farajollahi M, Ahmadi A. Deep learning-based multistep ahead wind speed and power generation forecasting using direct method. *Energy Conversion and Management*. 2023; Volume 281: 116760.

- [35] Xu P, Zhang M, Chen Z, Wang B, Cheng C, Liu R. A deep learning framework for day ahead wind power short-term prediction. *Applied Sciences*. 2023; 13(6): 4042.
- [36] Tyass I, Khalili T, Mohamed R, Abdelouahed B, Raihani A, Mansouri K. Wind speed prediction based on statistical and deep learning models. *International Journal of Renewable Energy Development*. 2023; 12(2): 288-299.
- [37] <https://repa.enerji.gov.tr/REPA/bolgeler/TURKIYE-GENELI.pdf> (Erişim tarihi: 01.01.2024)
- [38] <https://tureb.com.tr/lib/uploads/203243c7bdacc121.pdf> (Erişim tarihi:01.01.2024)
- [39] <https://www.ultraenerji.com/ruzgar-enerjisi/ruzgar-turbinleri-nasil-calisir.html> (Erişim tarihi:03.01.2024)
- [40] Nurbay N, Çınar A (2005 Ekim). Rüzgâr türbinlerinin çeşitleri ve türbinlerin birbirleriyle karşılaştırılması. 3.Yenilenebilir Enerji Kaynakları Sempozyumu ve Sergisi, Cilt.1: 164-168. Mersin, Türkiye.
- [41] Almaz R. Değişken kanat açılı düşey eksenli rüzgâr türbini tasarımı. Yüksek lisans tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü. 2020.
- [42] Elibüyük U, Üçgül İ. Rüzgar türbinleri, çeşitleri ve rüzgar enerjisi depolama yöntemleri, *Yekarum*, 2014; 2(3): 1-14.
- [43] Yıldız E. Türkiye’de yenilenebilir enerji kaynakları, uygulama: Güneş enerji santrali ve rüzgâr enerji santrali kuruluş maliyetleri. Yüksek lisans tezi, Trakya Üniversitesi, Sosyal Bilimler Enstitüsü. 2017.
- [44] Karadağ İH. Yenilenebilir enerji kaynakları arasında rüzgâr enerjisinin önemi ve rüzgâr türbini tasarımı. Yüksek lisans tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü. 2009.
- [45] Yıldırım U. Yatay eksenli helezonik rüzgâr türbini tasarımı ve protatip imalatı. Yüksek lisans tezi, Karabük Üniversitesi, Fen Bilimleri Enstitüsü. 2011.
- [46] Kırım S. Rüzgâr enerjisi uygulamaları. Yüksek lisans tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü. 2002.
- [47] Çelikkemir S, Özdemir M (2014 Ağustos). Rüzgâr türbin sistemlerinin karşılaştırılması, *URSI-TÜRKIYE 2014 VII. Bilimsel Kongresi*, Elazığ, Türkiye.
- [48] Almaz R. Değişken kanat açılı düşey eksenli rüzgâr türbini tasarımı. Yüksek lisans tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü. 2020.

- [49] Şenel MC, Koç E. Yatay eksenli rüzgâr türbinlerinin dinamik davranışı-teorik bir model. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi. 2014; 5(1): 69-80.
- [50] Koç E, Şenel MC. Yatay eksenli rüzgâr türbinlerinde optimum türbin parametrelerinin belirlenmesi-teorik yaklaşım. Mühendis ve Makine. 2016; 57(676): 32-40.
- [51] Koç E, Şenel MC (2011 Haziran). Yatay eksenli rüzgâr türbinleri mekanik tasarım esasları ve performans araştırması, Anadolu Enerji Sempozyumu. Elazığ, Türkiye.
- [52] Koç E, Şenel M C. Yatay Eksenli Rüzgâr Türbinlerindeki Aerodinamik, Mekanik ve Elektriksel Kayıpların Değerlendirilmesi. Rüzgâr Enerjisi Dergisi. 56-62.
- [53] Esen M. Rüzgâr türbini ve güneş pilinden oluşan bir güç üretim sisteminin tasarımı ve kontrolü. Yüksek lisans tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü. 2016.
- [54] Can TM. Rüzgâr ve güneş enerjisi ile bir pompanın ihtiyacı olan elektrik enerjisinin sağlanması. Yüksek lisans tezi, Mustafa Kemal Üniversitesi, Fen Bilimleri Enstitüsü. 2010.
- [55] Kerem A. Rüzgâr parametrelerinin değişiminin izlenmesi ve yapay zeka algoritmaları kullanılarak tahmini. Doktora tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü. 2018.
- [56] Şahin M, Yavrucuk İ (2019 Ekim). Rüzgâr türbini kanat yunuslama açısı kontrolcüsü tasarımı ve performans analizi. 5.İzmir Rüzgâr Sempozyumu, İzmir, Türkiye.
- [57] Terzioğlu H, Arslan M, Demirok HD. Rüzgâr enerjisi ile elektrik üretimi. Mühendislik Alanında Araştırma Makaleleri. Gece Akademi Yayınevi, 2019.
- [58] <https://web.itu.edu.tr/~kaymak/windpower.html> (Erişim tarihi: 05.01.2024)
- [59] Kalkavan Y, Özçakir F. Comparison of LSTM deep learning method and arima time series method through car rental sector data. International Marmara Sciences Congress (Spring). Kocaeli. 2020.
- [60] Öztemel E. Yapay Sinir Ağları (2. Baskı). Papatya Yayıncılık; 2006.
- [61] Arıkan Kargı VS. Yapay sinir ağ modelleri ve bir tekstil firmasında uygulama. Doktora tezi, Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü. 2013.
- [62] Akgül S. Yapay sinir ağları ile Türkiye elektrik enerjisi talep tahmini ve diğer yöntemlerle karşılaştırmalı analizi. Doktora tezi, Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü. 2013.

- [63] Atalay M. Zaman serilerinde yapay sinir ađları ve bulanık mantıđa dayalı tahmin ve bir uygulama. Doktora Tezi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü. 2015.
- [64] Şapcı B, Taşlı Pektaş Ş. Makine öğrenmesi aracılığı ile kullanıcı deneyimi bilgilerinin erken mimari tasarım süreçleriyle bütünleştirilmesi. *Journal Of Computational Design*. 2021; 2(1): 67-94.
- [65] Dođan F, Türkođlu İ. Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*. 2018; 1(1): 10-21.
- [66] Şeker A, Diri B, Balık HH. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme, *Gazi Mühendislik Bilimleri Dergisi*. 2017; 3(3): 47-64.
- [67] İnik Ö, Ülker E. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*. 2017; 6(3): 85-104.
- [68] Kızrak M A, Bolat B. Derin öğrenme ile kalabalık analizi üzerine detaylı bir araştırma. *Bilişim Teknolojileri Dergisi*. 2018; 11 (3): 263-286.
- [69] <https://www.kisiselgelisim.com/derin-gorsel-ogrenme-gorsel-noronlarin-diger-ogrenme-aglari-ile-iliskisi/> (Erişim tarihi: 18.01.2024)
- [70] Wei J, Wu X, Yang T, Jiao R. Ultra-short-term forecasting of wind power based on multi-task learning and LSTM. *International Journal of Electrical Power & Energy Systems*. 2023; Volume 149: 109073.
- [71] Shahid F, Zameer A, Muneeb M. A novel genetic LSTM model for wind power forecast. *Energy*. 2021; Volume 223: 120069.
- [72] Hochreiter S, Schmidhuber J. Long short-term memory, *Neural Computation*. 1997; 9(8): 1735-1780.
- [73] Xiao Y, Yin Y. Hybrid LSTM neural network for short-term traffic flow prediction. *Information*. 2019; 10(3): 105.
- [74] Singh SK, Jha SK, Gupta R. Enhancing the accuracy of wind speed estimation model using an efficient hybrid deep learning algorithm. *Sustainable Energy Technologies and Assessments*. 2024; Volume 61: 103603.