



# Tekrarlayan Sinir Ağları Temelli Rüzgâr Hızı Tahmin Modelleri: Yalova Bölgesinde Bir Uygulama

Fuat Kosanoğlu<sup>1\*</sup>, Zeliha Nur Kiriş<sup>2</sup>, Ömer Faruk Beyca<sup>3</sup>

<sup>1</sup> Yalova Üniversitesi, Endüstri Mühendisliği Bölümü, Yalova, Türkiye

<sup>2</sup> İstanbul Teknik Üniversitesi, Endüstri Mühendisliği Bölümü, İstanbul, Türkiye

<sup>3</sup> İstanbul Teknik Üniversitesi, Endüstri Mühendisliği Bölümü, İstanbul, Türkiye

fuat.kosanoğlu@yalova.edu.tr, kiris17@itu.edu.tr, beyca@itu.edu.tr

## Öz

Küresel ısınma ve fosil yakıtların çevreye verdiği zararlardan dolayı son yıllarda yenilenebilir enerji kaynakları büyük önem kazanmıştır. Özellikle Paris İklim Anlaşmasıyla ülkeler çevreye zararlı gaz salınımını azaltmak konusunda taahhütlerde bulunmuşlardır. Günümüzde en önemli yenilenebilir enerji kaynaklarından biri de rüzgâr enerjisidir. Türkiye'nin sahip olduğu rüzgâr potansiyeli düşünüldüğünde enerji üretiminde rüzgâr enerjisi daha da önem kazanmaktadır. Rüzgâr enerjisi temiz bir enerji kaynağı olmasına rağmen rüzgârın değişken bir kaynak olması nedeniyle üretilen enerjinin verimli kullanılıp dağıtılabilmesi ve planlama yapılabilmesi sağlıklı rüzgâr enerjisi üretim tahminlerine dayanmaktadır. Bu çalışmada, dört farklı Tekrarlayan Sinir Ağları (TSA) modeli rüzgâr enerjisi üretim tahminlemesi için kullanılmıştır. Çalışmada, Türkiye'nin Yalova ilinde bulunan bir istasyondan elde edilen veriler kullanılarak kısa süreli rüzgâr hızı tahmini yapılmıştır. Analizde bir saat sonrası tahmin ederek oluşacak ani arıza ve bakım planlamalarına müdahale edilmesi amaçlanmıştır. Öncelikle istasyondan alınan veriler incelenmiş, veri analizleri yapılmış, var olan verilerden yeni veriler üretilmiş ve veri setleri modeller için uygun hale getirilmiştir. Modellerden elde edilen performans sonuçları kabul edilebilir aralıkta olup TSA yöntemlerinin rüzgâr hızı tahmininde başarılı bir şekilde kullanılabileceğini, ve geleneksel zaman serisi yöntemlerine göre daha iyi sonuçlar verdiği sonucuna varılmıştır.

**Anahtar kelimeler:** rüzgâr hızı tahmini, rüzgâr enerjisi, ARIMA, tekrarlayan sinir ağları

## Recurrent Neural Networks Based Wind Speed Forecasting Models: A Case Study of Yalova

### Abstract

Global warming and other adversarial effects caused by fossil fuel sources, renewable energy sources have been attracted more than ever. Especially, parties of Paris Climate Agreement countries pledge to reduce greenhouse gas emissions. Among renewable energy sources, wind energy is one of the significant and eligible source to produce energy sustainably. Wind energy is also one of the most important renewable energy source due to Turkey's notable wind energy potential. Although wind energy is one of the most important clean energy sources, there are several challenges, such as intermittent and uncertain nature of wind places. Therefore, efficient and reliable energy planning and distribution mostly rely on prediction of wind energy with high accuracy. In this study, we propose four Recurrent Neural Network (RNN) methods to predict short-term wind energy production. We utilize data obtained from a station located in Yalova, Turkey to assess the performance of proposed algorithms. In our analysis, we plan to improve maintenance planning and intervene the sudden breakdowns by predicting 1 hour ahead energy production. First, we analyze the data received from the station, and the data sets were made suitable for the models. The performance results obtained from the models are plausible. Our results indicate that RNN methods can be successfully used to predict wind speed.

**Keywords:** wind speed forecasting, wind energy, ARIMA, recurrent neural networks

\* Sorumlu yazar.  
E-posta adresi: fuat.kosanoğlu@yalova.edu.tr

Alındı : 24 Mayıs 2022  
Revizyon : 26 Ağustos 2022  
Kabul : 17 Eylül 2022

## 1. Giriş (Introduction)

Dünya nüfusunun artması ve teknolojik cihazların hayatımızda önemli yer alması, beraberinde enerjiye olan ihtiyacı da artırmaktadır. Bu ihtiyacı karşılamak için kullanılan kaynakların başında fosil yakıtlar olan petrol, doğalgaz ve kömür yer almaktadır. Bu kaynakların kısıtlı olması gerçeği, uzun vadede artan elektrik ihtiyacının karşılanmasında yeterli olmayacağı sonucunu ortaya koymaktadır. Bununla beraber, küresel ısınma ve fosil yakıtların çevreye verdiği zararlar fosil yakıtlara alternatif, temiz ve sürdürülebilir enerji kaynaklarına yönelimi zorunlu kılmıştır. Özellikle Paris İklim Anlaşmasıyla ülkeler çevreye zararlı gaz salınımını azaltmak konusunda taahhütlerde bulunmuşlardır. Bu nedenlerden dolayı son yıllarda yenilenebilir enerji kaynakları büyük önem kazanmış ve bu kaynaklardan enerji üretimi için yapılan yatırımlar hız kazanmıştır. Başlıca yenilenebilir enerji kaynakları, güneş enerjisi, rüzgâr enerjisi, jeotermal enerji olarak listelenebilir.

Türkiye’de toplam elektrik enerjisinin %7.4’ü rüzgâr enerjisi ile sağlanmaktadır. Rüzgâr yoğunluğuna bağlı olarak üretim miktarları değişen santraller için, konum ve iklim koşulları rüzgâr çiftlikleri kurulumu için önemli parametrelerdir. Türkiye’de kurulu rüzgâr enerjisi santrallerinin büyük çoğunluğu kıyı Ege ve doğu Marmara’da bulunmakta olup %19.2 oranıyla İzmir başta gelmektedir (*Türkiye Rüzgâr Enerjisi İstatistik Raporu*, 2019).

Yük tahmini, devletin ve enerji sağlayan şirketlerin arz-talep dengesini kurmak için gereken enerjiyi tahmin ettikleri bir tekniktir. Güç sistemlerinin etkin kullanılması ve planlanmasında, yük tahminin doğru yapılması büyük önem arz etmektedir. Enerji tahmininin yüksek yapılması, işletmenin inşası sırasında önemli ölçüde kaynak israfına sebep olmaktadır. Düşük tahmin gerçekleştiğinde ise enerjiden faydalanan kesimin enerji talebi karşılanamaz ve sistemin verimsiz bir şekilde çalışmasına neden olur (Wang, Guo ve Huang, 2011).

Dünyada, ülkelerin gelişmişlik düzeylerini ifade eden değişkenlerden biri enerji tüketimi olması sebebiyle Türkiye gibi gelişmekte olan ülkeler için enerji önemli bir ekonomik göstergedir. Bu gösterge neticesinde dışa bağımlılık, elektrik faturalarının artması, teminde aksaklık ve sıkıntı yaşanması gibi durumlar sebebiyle halkın refahı için bir sorun teşkil etmektedir. Bağımlı olunan enerjinin azaltılması için yerli kaynaklara yatırım yapılmalıdır. Bu nedenle rüzgâr enerjisi büyük önem arz etmektedir. Rüzgâr enerjisinden elektrik üretiminde ise doğru rüzgâr hızı tahminlemesi kritik öneme sahiptir.

Bu çalışmada farklı derin öğrenme metotları ve klasik zaman serisi metotları kullanılarak kısa dönemli rüzgâr hızı tahminlemesi yapılması amaçlanmıştır. Bu çalışma akademisyen ve uygulayıcılara rüzgâr hız

tahminlemesi yaparken veri ön işlemesi, veri modellemesi ve tahminleme yapmak için kılavuz sunmaktadır. Bu çalışma kapsamında 3 farklı derin öğrenme metodu ve 1 klasik zaman serisi metodu (ARIMA) Yalova ili rüzgâr verileri kullanılarak uygulanmıştır. Modellerin performansı Mutlak Hataların Ortalama Yüzdesi (MAPE), mutlak hataların ortalaması (MAE) ve hataların karelerinin ortalaması (MSE) ölççekleri kullanılarak karşılaştırılmıştır. Modellerde girdi olarak geçmiş 24 saatlik veriler kullanılarak bir sonraki saatin rüzgâr hızı tahminlemesi hedeflenmiştir.

Çalışmanın ikinci bölümünde detaylı yük tahminleme ile ilgili literatür taramasına yer verilmiştir. Üçüncü bölümde yük tahmini ve yük tahminine etki yapan faktörler ele alınmıştır. Dördüncü bölümde çalışmada kullanılan yöntemler anlatılmıştır. Beşinci bölümde Yalova ili için elde edilen veriler kullanılarak önerilen modeller test edilmiştir. Son bölümde elde edilen sonuçlar ve öneriler sunulmuştur.

## 2. Literatür Araştırması (Literature review)

Enerji endüstrisinde yük tahmini, üretim planlama ve fiyat tahmininde en önemli bileşen olarak karşımıza çıkmaktadır. Bu tahminler, hem güç sistemleri, hem ticari kuruluşlar tarafından kullanılmaktadır. 2010-2019 yılları arasında yapılan çalışmalara bakıldığında, enerji tahmin çalışmalarının yarısı yük tahmin çalışmalarıdır. Diğer çalışmalar, fiyat, rüzgâr ve güneş tahminleridir (Hong vd., 2020).

Rüzgâr hızı tahmin modelleri ile ilgili çalışmalar kısa dönem ve uzun dönem olmak üzere iki ana grupta sınıflandırılabilir. Kısa dönem tahmin modelleri 1 saatten birkaç günlük tahminleri içermekte iken uzun dönem tahminler ise 1 yıl sonrasına kadar uzanmaktadır. Her iki tahminleme dönemleri için istatistiksel yöntemler, fiziksel yöntemler, yapay zekâ ve hibrit modeller geliştirilmiştir (Lei vd., 2009). Geleneksel istatistiksel yöntemler optimum çözümü garanti etmemektedir. Fiziksel yöntemler ise kısa vadeli tahmin sağlayamamakta ve sayesinde rüzgâr enerjisi tahminlerinde gittikçe daha fazla kullanılmaktadır. Hibrit yöntemler ise farklı tahmin yöntemlerinin özelliklerini bir araya getirerek daha yüksek performans elde etmeyi hedefleyen yöntemlerdir.

Kısa dönem rüzgâr enerjisi tahminlemede istatistiksel yöntemlerin kullanıldığı ilk çalışmalardan biri Brown ve diğerleri, (1984) tarafından yapılmıştır. Bu çalışmada tahminlemede otoregresif zaman serileri modelleri (AR) kullanılmıştır. Torres v.d, (2005) otoregresif-hareketli ortalama modeli (ARMA) modeli kullanarak saatlik rüzgâr hızı tahminleri yapmışlardır. Rajagopalan & Santoso (2009) aynı yöntemi kullanarak rüzgâr hızı tahminleri yapmış ve elde ettikleri sonuçlar yöntemin 1 saat sonrası için tahminlemede başarılı olduğunu göstermiştir. Sfetos (2002) rüzgâr hızı tahminlemede otoregresif entegre hareketli ortalama

(ARIMA) modelini kullanmış, 10 dakika ve 1 saatlik ortalamalar kullanarak 1 saat sonrası için tahminleme yapmıştır. Bu çalışma 10 dakikalık ortalamaların kullanılmasının çok daha etkili olduğunu göstermiştir. Cadenas vd., (2016) rüzgar enerjisi tahmini için tek değişkenli ARIMA ve çok değişkenli NARX modellerini kullanmışlardır. NARX modelinin ARIMA modeline göre daha iyi sonuçlar verdiği gözlemlenmiştir. Ozkan ve Karagöz (2015) dinamik kümeleme ve doğrusal regresyon tekniklerinin birleştirildiği hibrit bir model ortaya koymuşlardır. Bu modelin öne çıkan en önemli özelliği daha az geçmiş veriye ihtiyaç duyması olarak belirtilmiştir. Xie vd., (2019) parametrik olmayan zaman serisi yöntemlerini kısa dönem rüzgâr enerjisi tahminlemede kullanmışlardır. Aasim, Singh ve Mohapatra (2019) tekrarlayan wavelet temelli ARIMA modeli kullanarak kısa dönem rüzgâr enerjisi tahmini yapmışlardır. Önerilen model 1, 3, 5, 7 ve 10 dakikalık zaman aralıklarının tahmini için test edilmiş ve süreklilik modeli ile kıyaslandığında daha iyi sonuçlar verdiği ortaya konmuştur.

Uzun dönem rüzgâr enerjisi tahminlemede istatistiksel yöntemlerin kullanıldığı çalışmaların sayısı nispeten daha azdır. Uzun dönem rüzgâr enerjisi tahminlemede, verilerin yapısı nedeniyle istatistiksel yöntemler tek başlarına çok etkili değildirler vd., (2014). Eldali ve diğerleri (2016) ARIMA tekniğini kullanarak uzun dönem rüzgâr enerjisi tahminleme çalışması yapmışlardır. Kavasseri ve Seetharaman (2009) kesirli-ARIMA tekniğini 1 gün sonrası için rüzgâr hızı tahminlemede kullanmışlardır. Barbosa de Alencar vd., (2017) ARIMA, Yapay Sinir Ağları (YSA) ve hibrit modelleri kullanarak kısa ve uzun dönem rüzgâr hızı tahminleri yapmışlardır. Dokuz vd., (2018) kümeleme yöntemleri ve ARIMA yöntemlerini kullanarak geliştirdikleri hibrit algoritmayı kullanarak 1 yıl sonrası rüzgâr hızı tahminlemesi yapmışlardır.

Yapay zekâ yöntemleri hem kısa hem de uzun dönem rüzgâr hızı tahminine olanak tanımaktadır. Dumitri ve Gligor (2017) YSA temelli FANN (İleri beslemeli yapay sinir ağları) modeli ile rüzgâr enerjisi tahmini yapmışlardır. Bu çalışmada Romanya verileri kullanılmış olup günlük rüzgâr hızı tahminleri yapılmıştır. Rüzgâr hızı tahmininde geçmiş yıllara ait günlük rüzgâr enerjisi üretimi ve meteorolojik veriler kullanılmıştır. Modelin tahminleme performansı RMSE ölçütü ile değerlendirilmiştir. Madhiarasan (2021) farklı YSA modelleri kullanarak uzun süreli rüzgar hızı tahmini yapmış ve modellerin tahminleme performanslarını kıyaslamıştır.

Yu vd., (2018) dalgacık dönüşümünü (wavelet transform) geçmiş yıllara ait rüzgâr hızı verilerini alt serilere sınıflandırmak için kullanmışlardır. Bu şekilde, rüzgâr hızı tahmininde alt seriler düşük frekansları, tekrarlayan sinir ağları (RNN) ise derin özelliklerin ortaya çıkarılmasında kullanılmıştır. Diğer bir çalışmada RNN ve hata düzeltme metotları kullanılarak

kısa süreli rüzgâr hızı tahmini yapılmıştır vd., (2021). LSTM ve GRU metotları daha derin özelliklerin ortaya çıkarılmasında kullanılmıştır. Higashiyama vd., (2017) evrişimli sinir ağları (CNN) mimarisini kullanarak rüzgâr enerjisi tahmininde sayısal hava tahmin verilerinin yüksek boyutlarından kaynaklanan problemlere çözüm bulmaya çalışmıştır. Liu vd., (2018) iki aşamalı bir model geliştirerek rüzgâr hızı tahmini yapmışlardır. İlk aşamada WPD (Wavelet Packet Decomposition) yöntemi kullanılarak rüzgâr hızı zaman serisi alt serilere ayrılmışlardır. İkinci aşamada, CNN yöntemi kullanılarak yüksek frekanslı alt serilerin tahmini yapılırken, CNNLSTM yöntemi ile daha düşük frekanslı olan alt katmanların tahmin yapılmıştır. Çalışmada önerilen model literatürdeki sekiz farklı modelle kıyaslanmış olup, rüzgâr hızı ani değişikliklerine karşılaştırılan modellere göre daha iyi performans gösterdiği belirtilmiştir. Neshat vd., (2021) çift yönlü LSTM yöntemini kullanarak kısa süreli rüzgar hızı tahmini yapmışlardır. Bu çalışmada parametrelerin tahmini için ayrıca bir optimizasyon algoritması kullanılmıştır.

Zhang vd., (2019) meteorolojik veriler ile rüzgar hızı arasındaki korelasyon ve nedenselliği incelenmiştir. Araştırmada kullanılan değişkenler rüzgâr hızı, hava basıncı, nem, sıcaklık ve diğerleri olarak belirtilmiştir. Karmaşık nedensellik ile modelin yorumlanabilirliğini arttırmak için standart Uzun Kısa Süreli Bellek Ağları (LSTM) yerine NLSTM (Neighborhood Gates) yöntemi kullanılmıştır.

Yu vd., (2019) rüzgâr enerjisi ve rüzgâr hızı tahminlerinde zaman serileri çalışmalarının aslında rüzgârın zamansal ve mekânsal değişimini yansıtmadığını ifade etmişlerdir. Bu nedenle zaman ve mekânsal özelliklere (STF) bağlı derin CNN yöntemini uygulamışlardır. Fu vd., (2019) rüzgâr enerjisi tahmini yapılırken rüzgâr hızı, rüzgâr yönü ve sıcaklık değişkenlerini kullanılmışlardır. Bu çalışmada yerel optimumdan kaçınmak için normla tavuk sürüsü algoritması yerine geliştirilmiş tavuk sürüsü algoritması kullanılmıştır. Demolli vd., (2019) farklı konumlardaki rüzgar verilerini kullanarak beş farklı makine öğrenmesi algoritmasını (LASSO, kNN, XGBoost, RF, ve SVR) karşılatılmışlardır. Çalışmada, model Niğde bölgesine ait veriler ile eğitilmiş ve dört farklı bölge için (Bozcaada, Çeşme, Mamak ve Silivri) rüzgâr hızı tahmin çalışması yapıp bu bölgelerin rüzgâr enerjisi için elverişliliği belirlenmiştir.

Bu çalışmada Yalova ilinde yer alan istasyondan elde edilen 01.06.2015 ve 31.05.2020 tarihleri arasındaki veriler kullanılarak rüzgâr hızı tahmini yapılması amaçlanmaktadır. Rüzgâr hızı tahmininde TSA temelli 3 farklı model kullanılmış olup, hangi modellerin daha etkin olduğu sorusuna cevap aranmaya çalışılmıştır. Bununla beraber klasik zaman serisi

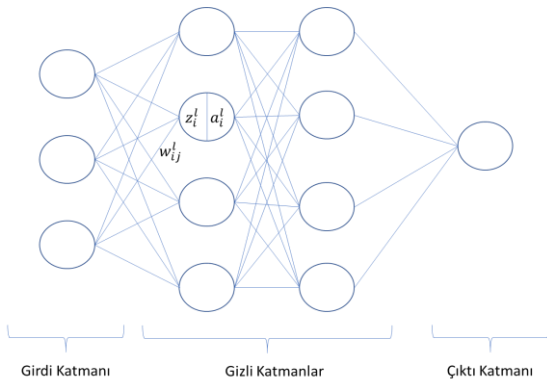
metodu ile kıyaslanarak TSA temelli modellerin performansı değerlendirilmiştir.

### 3. Metodoloji (Methodology)

Bu çalışmada meteorolojik veriler kullanılarak rüzgâr hızı tahmininin yapılması amaçlanmaktadır. Literatür araştırmasının da belirttiği üzere rüzgâr hızının tahmin edilmesinde yapay zekâ tekniklerinin geleneksel istatistiksel yöntemlere göre daha iyi sonuçlar vermektedir. Bu çalışmada uzun kısa süreli bellek (Long-Short Term Memory-LSTM) ve kapılı tekrarlayan hücre (Gated Recurrent Unit-GRU) temelli derin öğrenme algoritmaları kullanılmıştır.

#### 3.1. Yapay sinir ağları (Artificial neural networks)

Yapay zekâ ve makine öğrenimi alt uygulaması olan derin öğrenme, yapay sinir ağları adı verilen beyin yapısı ve işlevinden esinlenen algoritmalarla ilgilidir. Veri işleme ve karar vermede kullanılacak kalıpları oluştururken bu algoritmalar kullanılır. Makine öğreniminin gerçekleşmesi için hiyerarşik yapıda yapay sinir ağları kullanılır. Geleneksel modellerin veriyi doğrusal bir şekilde analiz etmesinin aksine, yapay sinir ağları algoritmaları hiyerarşik yapıları sayesinde veriyi doğrusal olmayan bir yapı ile işleyebilirler. Yapay sinir ağları geleneksel olarak üç çeşit katmandan oluşurlar; girdi katmanı, gizli katman(lar) ve çıktı katmanı. Aşağıdaki figürde klasik bir yapay sinir ağları mimarisi gösterilmiştir.



Şekil 1. Yapay Sinir Ağları Mimarisi (Artificial Neural Networks Architecture)

Yapay sinir ağlarında  $l$ 'ninci katmandaki  $i$ 'ninci nöronun girdisi bir önceki katmandaki nöronların ağırlıklı etkisi ile aşağıdaki gibi hesaplanır.

$$z_i^l = \sum_j \omega_{ij}^l a_j^{l-1} \quad (1)$$

Nöronlara gelen bilgi aktivasyon fonksiyonu sayesinde işlenerek diğer nöronlara aktarılır. Yapay sinir

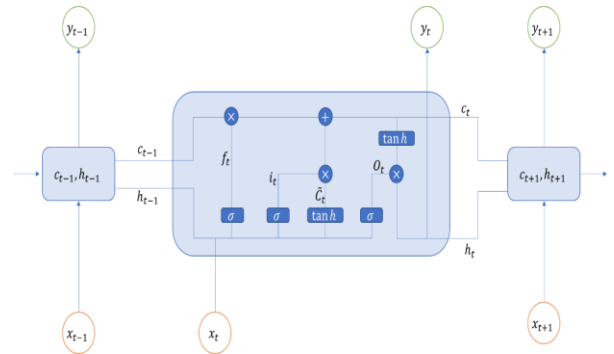
ağları literatüründe çeşitli fonksiyonları kullanılmaktadır. Bu çalışmada gizli katmanlarda RELU aktivasyonu fonksiyonu kullanılırken, çıktı katmanında lineer aktivasyon fonksiyonu kullanılmıştır.

$$\text{relu}(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2)$$

$$\text{linear}(x) = x \quad (3)$$

#### 3.1.1. Uzun kısa süreli bellek (Long-short term memory-LSTM)

Uzun Kısa Süreli Bellek (LSTM) mimarisi zaman serileri veya sıralı dizileri tahminleme için geliştirilmiş olan yapay sinir ağları mimarisidir. LSTM algoritmasında bir sonraki adımı tahminlemek için geçmiş durumların doğrudan veya dolaylı etkileri kullanılarak tahmin yapılır. LSTM mimarisi gradyan sönümlenmesini engellemek adına unutmaya kapılarını kullanarak işe yarayacak bilgileri kullanırken diğerlerini engeller. Tipik bir LSTM hücresi aşağıdaki gibidir.



Şekil 2. Uzun kısa süreli bellek mimarisi (LSTM architecture)

LSTM mimarisinde süreç unutmaya, yeni hafıza ve girdi, ve çıktı olmak üzere üç aşamadan oluşmaktadır. Birinci aşama girdi ( $X_t$ ) ve önceki gizli katman ( $h_{t-1}$ ) verilerini kullanarak unutmaya kapısında ( $f_t$ ) hangi bilgilerin kullanılmalı olduğunun karar verildiği aşamadır. Bu aşamada aktivasyon fonksiyonu olarak Eşitlik 4'te verilen sigmoid fonksiyonu kullanılır.

$$f_t = \sigma(W_{f,x}X_t + W_{f,h}h_{t-1} + b_f) \quad (4)$$

İkinci aşamada, birinci aşamada olduğu gibi girdi ( $X_t$ ) ve önceki gizli katman ( $h_{t-1}$ ) verilerini kullanarak hangi bilgilerin uzun dönem hafızaya ekleneceğine karar verilir. Bu aşamada  $\tanh$  fonksiyonu kullanılarak önceki gizli katman ve girdi ( $X_t$ ) verileri birleştirilir ve yeni bilgiyi oluşturacak aday bilgiler ( $\tilde{C}$ ) elde edilir. Girdi kapısında  $i_t$  sigmoid fonksiyonu kullanılarak hangi bilgilerin saklanmasına karar verilir.

Son olarak Eşitlik 7'de verildiği gibi yeni bilgiler oluşturulur.

$$\tilde{C}_t = \tanh(W_{c,x}X_t + W_{c,h}h_{t-1} + b_c) \quad (5)$$

$$i_t = \sigma(W_{i,x}X_t + W_{i,h}h_{t-1} + b_i) \quad (6)$$

$$C_t = C_{t-1}f_t + i_t\tilde{C}_t \quad (7)$$


Son aşamada yeni bilgiler, önceki gizli katman ve girdi verileri kullanılarak çıktı kapısında ( $o_t$ ) çıktı verileri (Eşitlik 8) ve yeni gizli katman (Eşitlik 9) elde edilir.

$$o_t = \sigma(W_{o,x}X_t + W_{o,h}h_{t-1} + b_o) \quad (8)$$

$$h_t = o_t \tanh(C_t) \quad (9)$$

### 3.1.2. Kapılı tekrarlayan hücre (Gated recurrent unit-GRU)

Kapılı tekrarlayan hücre (GRU) mimarisi LSTM'de olduğu gibi zaman serileri veya sıralı dizileri tahminleme için geliştirilmiş olan yapay sinir ağları mimarisidir. GRU mimarisi gradyan sönümlenmesini engellemek adına LSTM mimarisine benzer bir şekilde unutmaya kapılarını kullanarak işe yarayacak bilgileri kullanırken diğerlerini engeller. Şekil 3 GRU hücresi mimarisi gösterilmiştir.



Şekil 3. Kapılı tekrarlayan hücre mimarisi (GRU architecture)

Güncelleme kapısında ( $z_t$ ), girdi ( $X_t$ ) ve önceki gizli katman ( $h_{t-1}$ ) verilerini kullanarak geçmiş bilgilerin ne kadarını geleceğe aktarılacağına Eşitlik 10'da verilen sigmoid fonksiyonu ile karar verilir.

$$z_t = \sigma(W^{(z)}X_t + U^{(z)}h_{t-1}) \quad (10)$$

Daha sonra silme kapısında ( $r_t$ ), geçmiş bilgilerin ne kadarının silineceğine karar verilir.

$$r_t = \sigma(W^{(r)}X_t + U^{(r)}h_{t-1}) \quad (11)$$

Eşitlik 12'de yeni aday bilgiler, silme kapısı kullanılarak elde edilir.

$$h'_t = \tanh(W X_t + r_t U h_{t-1}) \quad (12)$$

Son aşamada yeni aday bilgiler arasından hangilerinin saklanmasına karar verilerek yeni gizli katman oluşturulur.

$$h_t = z_t h_{t-1} + (1 - z_t) h'_t \quad (13)$$

### 3.2. Performans ölçütleri (Evaluation metrics)

Bu çalışmada önerilen TSA modellerinin rüzgâr hızı tahminleme doğruluklarını ölçmek için üç farklı ölçüt kullanılmıştır. Bu ölçütler 14-16 denklemlerinde verilmiştir. Hata terimi  $e_j = y_j - \hat{y}_j$ ,  $y_j$  gözlem değeri;  $\hat{y}_j$  tahmin edilen değerdir.

$$\text{Ortalama Mutlak Hata (MAE)} = \frac{1}{n} \sum_{j=1}^n |e_j| \quad (14)$$

$$\begin{aligned} \text{Ortalama Mutlak Yüzde Hata (MAPE)} & \quad (15) \\ & = \frac{100}{n} \sum_{j=1}^n \frac{|e_j|}{|y_j|} \end{aligned}$$

$$\text{Ortalama Kare Hata (MSE)} = \frac{1}{n} \sum_{j=1}^n e_j^2 \quad (16)$$

## 4. Deneysel Çalışma (Experimental Study)

Bu çalışmada kullanılan modellerin uygulaması Python programlama dilinde yapılmıştır. Önerilen tekrarlayan sinir ağları yöntemlerinin kısa dönemli rüzgâr hızı tahminlemesi Yalova bölgesinde elde edilen veriler üzerinde uygulanmıştır.

Bu bölümde sırasıyla veri toplanması, veri ön işleme, modelin belirlenmesi, uygulanması, ve sonuçlar anlatılacaktır.

Teorik olarak bu veriler kullanılarak üretilebilecek rüzgâr enerjisi miktarları hesaplanabilmektedir. Bu nedenle çalışmada rüzgâr hızı tahminlemesi yapılmış ve istenildiği durumda üretilebilecek rüzgâr enerjisi değerleri elde edilebilmektedir. Akışkanlar mekaniği tanımına göre; rüzgâr türbininin güç göstergesi olan rüzgâr enerjisinin hesaplanması Eşitlik 17'de gösterilmiştir.

$$P = \frac{1}{2} C_p \rho A v^3 \quad (17)$$

$C_p$  Türbin performans katsayısı,  $P$  güç,  $\rho$  hava yoğunluğu,  $v^3$  türbin alanındaki rüzgâr hızını,  $A$  türbin kanadı alanını ifade etmektedir (Che vd., 2016).

### 4.1. Veri Toplanması (Data collection)

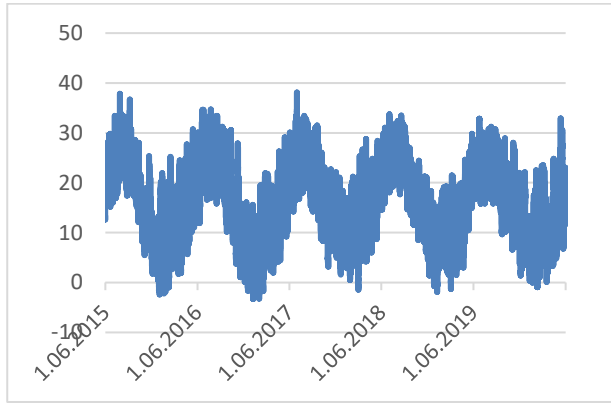
Rüzgâr hızı, sıcaklık, nem, basınç ve gün özelliği gibi parametreler enerji üretimini etkileyen faktörlerdir.

Kullanılan veriler 01.06.2015 ve 31.05.2020 tarihleri arası saatlik verilerden oluşmaktadır. Veri kümesi

toplamda 43848 adet veriden oluşmaktadır, bu verilerin %65'i ağırlık eğitilmesi, %15'i doğrulanması ve %20'si de test için kullanılmıştır. Yapay sinir ağlarında, rüzgâr hızı, sıcaklık, nem, basınç, rüzgâr yönü, saat ve ay bilgileri bir saat sonraki rüzgâr hızını tahmini için girdi olarak kullanılmıştır.

#### 4.1.1. Sıcaklık verileri (Temperature data)

Rüzgâr hızı sıcaklık değişimlerinden kaynaklandığı için rüzgâr hızına direkt etkisi vardır. Sıcaklık değerleri °C cinsinden ifade edilmektedir. Şekil 4'te gösterilen sıcaklık verilerine bakıldığında mevsimsellik görülmektedir.




Şekil 4. Sıcaklık veri dağılımı (Temperature data distribution)

#### 4.1.2. Nem verileri (Humidity data)

Nem miktarı, sıcaklığı etkilemekte olup dolaylı olarak rüzgâr hızına etki etmektedir. Sıcaklık ile nem arasındaki ilişkinin hissedilen sıcaklığa etkisi Şekil 5'te gösterilmiştir. Şekil 6'da ise zamana bağlı olarak bağıl nem grafiği gösterilmiştir.

		BAĞIL NEM (%)																			
		5	10	15	20	25	30	35	40	45	50	55	60	65	70	75	80	85	90	95	
HAVA SICAKLIĞI (°C)	50	45	48	53	58	66	69	76	83	91	99										
	49	44	47	51	55	61	66	72	79	86	94										
	48	43	46	49	53	58	63	68	75	81	88	96									
	47	42	45	48	51	55	60	65	70	76	83	90	98								
	46	41	43	46	48	53	57	62	67	72	78	85	91	99							
	45	41	43	45	48	52	56	62	65	70	76	82	88	96							
	44	40	42	44	46	49	52	57	61	66	71	77	83	89	96						
	43	39	40	42	44	47	50	54	58	62	67	72	77	83	90	97					
	42	38	39	41	43	45	48	51	54	58	62	67	72	78	83	90	96				
	41	37	38	39	41	43	45	48	51	55	59	63	67	72	78	83	89	96			
	40	36	37	38	39	41	43	46	48	51	55	59	63	67	72	77	83	88	95		
	39	35	36	37	38	39	41	43	46	48	51	55	58	62	67	71	76	81	87	93	
	38	35	35	36	37	38	40	42	44	47	50	53	56	60	64	68	73	78	83	89	
	37	34	34	35	36	37	38	40	42	44	46	49	52	56	59	63	67	72	76	81	
	36	33	33	34	34	35	36	38	39	41	43	46	48	51	55	58	62	66	70	74	
	35	32	32	33	33	34	35	36	37	39	41	43	45	48	50	53	57	60	64	68	
	34	31	31	32	32	33	34	35	37	38	40	42	44	46	48	52	55	59	63	67	
	33	31	31	31	31	32	32	33	34	36	37	39	40	42	45	47	49	52	55	58	
	32	30	30	30	30	31	31	32	33	34	35	36	38	39	41	43	45	47	50	53	
	31	29	29	29	29	30	30	31	32	33	34	35	36	38	40	41	43	45	47	49	
30	28	28	28	28	29	29	30	30	31	32	33	34	35	36	38	39	41	42	44		
29	27	27	27	27	28	28	28	28	29	30	30	31	32	33	34	36	37	38	40		
28	26	26	26	27	27	27	27	28	28	29	29	30	30	31	32	32	33	34	36		
27	26	26	26	26	26	27	27	27	27	28	28	28	29	29	30	30	31	31	32		
26	25	25	25	26	26	26	26	26	26	27	27	27	27	28	28	28	28	28	29		
25	25	25	25	25	25	25	26	26	26	26	26	26	26	27	27	27	27	27	27		


Şekil 5. Bağıl nem-sıcaklık ilişkisi (Relative humidity-temperature matrix)



Şekil 6. Saatlik bağıl nem dağılımı (Hourly relative humidity distribution)

#### 4.1.3. Basınç verileri (Pressure data)


Rüzgâr hızını etkileyen bir diğer faktör ise basınçtır. Atmosferin basıncına göre rüzgâr hızı değişmektedir. Şekil 7'de basınç verileri hPa cinsinden gösterilmektedir.



Şekil 7. Saatlik aktüel basınç dağılımı (Hourly actual pressure distribution)

#### 4.1.4. Rüzgâr hızı verileri (Wind speed data)

Rüzgâr hızı tahminlemesinin en önemli girdisi rüzgâr hızına ait geçmiş verilerdir. Yalova'nın 01.06.2015 ve 31.05.2020 tarihleri arasındaki saatlik rüzgâr hızı verileri Şekil 8'de ifade edilmiştir.

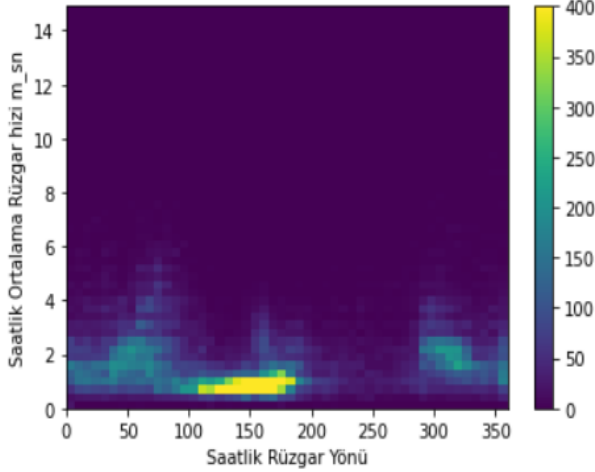


Şekil 8. Saatlik ortalama rüzgâr hızı dağılımı (Hourly average wind speed distribution)

#### 4.1.5. Rüzgâr yönü verileri (Wind direction data)

Rüzgâr yönü verisi açısal olarak verilmiştir. Açısal verileri direk olarak kullanmak bazı sorunlar oluşturmaktadır. Örnek olarak  $360^\circ$  ve  $0^\circ$  yön olarak birbirlerine yakın olmalarına rağmen sayısal olarak uzak gözükmektedir. Bu nedenle rüzgâr yönü bilgisi için bir önışlem yapılmıştır. Rüzgâr yönü bilgisi kullanılarak rüzgâr hızı X ve Y bileşenlerine ayrılmıştır.


Rüzgâr hızının rüzgâr yönüne göre dağılımı Şekil 9'da gösterilmiştir.



Şekil 9. Rüzgâr hızının rüzgâr yönüne göre dağılımı (Wind speed-wind direction distribution)

Rüzgâr yönünü açısal olarak aldığımız vakit  $0^\circ$  ile  $359^\circ$  yön olarak birbirlerine çok yakın olmalarına rağmen sayısal olarak birbirlerine uzak gözükmedirler. Bu yüzden rüzgâr hızlarını X ve Y koordinatlarına ayrılmış olarak kullandık Şekil 10'da

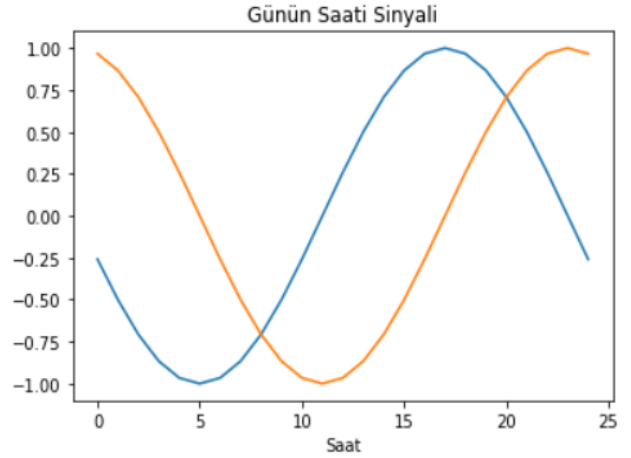
gösterildiği gibi.



Şekil 10. Rüzgâr yönünün X ve Y koordinat dağılımı (X and Y coordinate distribution of wind direction)

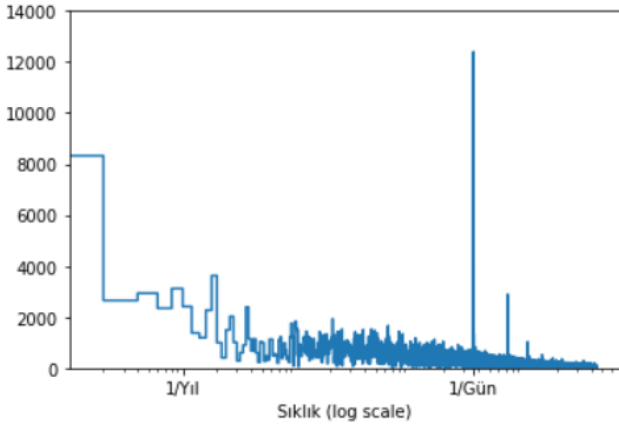
#### 4.1.6. Zaman verileri (Time data)

Rüzgâr verileri günlük ve yıllık mevsimsellik göstermektedir. Saat ve gün verilerini sinüs ve kosinüs değişimleri kullanarak Şekil 11'de gösterildiği gibi modele dahil ettik.



Şekil 11. Günlük saatin sinüs ve kosinüs dağılımları (Sine and cosine distribution of daily hour values)

Şekil 12'de rüzgâr hızının Fast Fourier Transform (FFT) analizi gösterilmiştir. FFT analizi göstermektedir ki rüzgâr hızında günlük bir periyotluk söz konusudur.



Şekil 12. Yıllık ve günlük sıcaklık dağılımı (Annual and daily temperature distribution)

#### 4.2. TSA modelleri (RNN models)

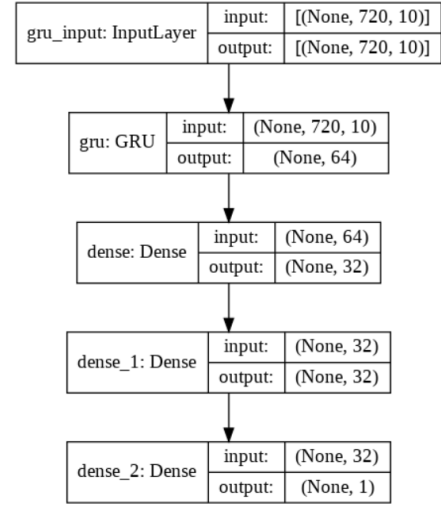
Bu çalışmada rüzgâr hızı tahmini için 3 model önerilmiş olup, modellerin mimari yapısı bu bölümde ifade edilecektir.

Meteorolojik veriler farklı birimlere ve aralıklara sahip olduklarından dolayı (örneğin sıcaklık verileri -4 ile +39 aralığında yer almakta iken basınç verileri 992 ile 1039 aralığında değerler almaktadır), bu verilerin öncelikle normalize edilmesi gerekmektedir. Değerler [0,1] arasında Eşitlik 18 deki gibi normalize edilmiştir.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (18)$$

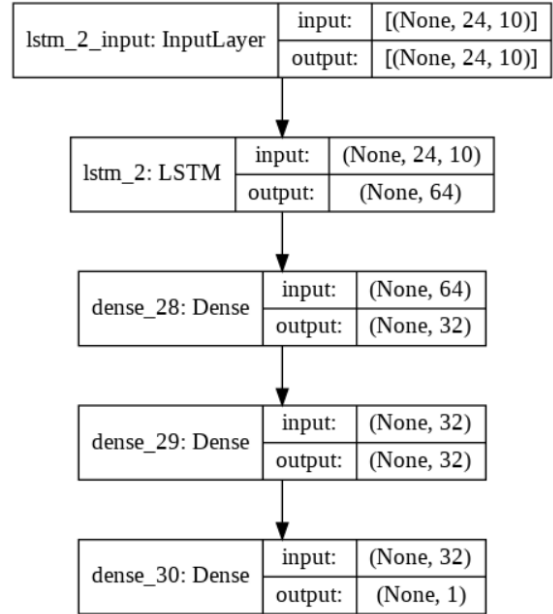
##### 4.2.1. TSA modellerinin oluşturulması ve eğitimi (RNN models creation and training)

Bu çalışmada rüzgâr hızı tahminlemede üç farklı TSA modeli kullanılmıştır. İlk modelde sıralı bir şekilde 1 GRU katmanı 3 tam bağlantılı katmandan oluşmaktadır. Gizli katmanlarda RELU aktivasyon fonksiyonu kullanılırken son katmanda doğrusal aktivasyon fonksiyonu kullanılmıştır. Şekil 13'te her bir katmanın hangi katman çeşidi olduğu kaç tane nöron sahip olduğu ve verinin akış yönü gösterilmiştir.



Şekil 13. Model 1 akış diyagramı (Model 1 flow diagram)


Kullanılan ikinci model, ilk modelden farklı olarak ilk katmanda GRU yerine LSTM katmanı tercih edilmiştir. Model 2 için akış diyagramı Şekil 14'te gösterilmiştir.



Şekil 24. Model 2 akış diyagramı (Model 2 flow diagram)

Kullanılan son TSA modelinde ise hem ileri doğru ilişkiyi hem de geriye doğru olan ilişkiyi kavrayabilmesi adına İki Yönlü LSTM katmanının 2 tam bağlantılı katman izlemişti. Model 3 için akış Şekil 15'te gösterilmiştir.





Şekil 35. Model 3 akış diyagramı (Model 3 flow diagram)

Bu çalışmada kullanılan veri setinin %80'i eğitim, %20'si test olarak ayrılmıştır. Eğitim veri setinin de %10 u doğrulama veri seti olarak kullanılmıştır.

#### 4.2.2. TSA modellerinin tahmin performansı (Performance of proposed TNN models)

Kullanılan TSA modelleri ve geleneksel zaman serisi modeli (ARIMA) kullanılarak, 1 saat sonrası için rüzgar hızı tahmini yapılmaya çalışılmıştır. Model eğitilirken 24 saatlik veri kullanılmıştır. Tablo 1'de her bir model için tahmin doğruluğunu gösteren MSE, MAPE, MAE ve  $R^2$  değerleri verilmiştir. Her bir kriter için LSTM (Model 2) modeli en iyi değerleri almıştır. Tablo 1'de gösterilen hata değerleri arasındaki farklar çok yüksek olmamakla beraber, yıllık rüzgâr enerjisi üretim miktarı (2021 yılı için 34250 GWh) ve üretici firmaların üretim tahmininde yaptıkları hataların ceza maliyetleri (Aksoy vd., 2013) göz önünde bulundurulduğunda yapılan iyileştirme büyük önem taşımaktadır.


Bu çalışmada zaman serileri için geliştirilmiş olan ve literatürde sıklıkla kullanılan geri beslemeli sinir ağı mimarilerinden LSTM ve GRU seçilmiştir. Bu ileri seviye metotlarla karşılaştırmak ve üstünlüğünü göstermek için klasik bir zaman serisi metodu olan ARIMA seçilmiştir. Derin öğrenme metotları için çeşitli katman sayısı ve nöron sayıları deneyerek optimum parametreler bulunmaya çalışılmıştır. Model parametrelerini optimize etmek için eğitim kümesinin %10'luk kısmı doğrulama kümesi olarak kullanılmıştır. Bulunan optimum parametreler şekiller 13,14 ve 15'te gösterilmiştir. ARIMA metotlarından mevsimsel ARIMA (sARIMA) metodu seçilmiştir. Parametre optimizasyonu (grid arama) yaparak optimum ARIMA parametreleri ( $p=1, d=1, q=0$ ) mevsimsel parametreler

ise ( $P=1, D=0, Q=0$ ) olarak bulunmuştur. Mevsimsel periyot ise 24 saat (1 gün) olarak belirlenmiştir.

Tablo 1. Modellerin tahminleme performansları (Performance of proposed ANN models)

Model	$R^2$	MSE	MAPE	MAE
GRU	0.7530	0.1243	18.9448	0.2533
LSTM	<b>0.7586</b>	<b>0.1215</b>	<b>18.4373</b>	<b>0.2485</b>
İki Yönlü GRU	0.7579	0.1219	18.4987	0.2503
ARIMA	0.7435	0.1291	20.2623	0.2621

Bununla beraber her model için tahmin değerleri ve gerçekleşen rüzgâr hızı değerleri 24 saatlik grafik üzerinde Şekil 16'da gösterilmiştir.



Şekil 16. 24 saatlik gerçek değer ile model tahminlerinin kıyası. (Comparison of actual and forecasted wind data for 24 hours)

## 5. Sonuç ve Öneriler (Conclusion and Future Research)

Bu çalışmada kısa dönemli rüzgâr hızı tahmininde modern makine öğrenmesi algoritmalarının performanslarını karşılaştırmak adına 3 farklı TSA modeli sunulmuştur. Ayrıca TSA modelleri klasik zaman serisi metodu (ARIMA) ile karşılaştırılmıştır.

Oluşturulan modellerle yapılan tahmin sonuçları  $R^2$ , MSE, MAPE ve MAE değerleri hesaplanmıştır. Bu değerlere bakıldığında; her model ile yapılan tahminlere ait değerlendirme kriterleri oranları kabul edilebilir bir aralık içerisinde olduğu görülürken bazı modellerde diğer modellere kıyasla daha düşük değerler elde edilmiştir. Genel olarak en düşük hata oranına sahip olan modeller TSA modelleri olup bunların içinden de en her üç değerlendirme kriteri içinde LSTM modeli en iyi sonucu vermiştir.

Bu çalışmada elde edilen sonuçlar ile, TSA yöntemlerinin rüzgâr hızı tahmininde başarılı bir şekilde kullanılabileceğini, ve geleneksel zaman serisi yöntemlerine göre daha iyi sonuçlar verdiği sonucuna varılmıştır.

Önerilen TSA modellerini geliştirmek ve tahminleme performansını artırmak için farklı optimizasyon metodlarının kullanılması yeni bir çalışma konusu olabilir. Ağırlıkların daha doğru belirlenmesi ile daha doğru sonuçlar elde edilebilir. Bu kapsamda sıklıkla kullanılan tahmin yöntemlerinin birlikte kullanılmasıyla hibrit modeller oluşturulabilir. Bu şekilde her yöntemin avantajları kullanılarak daha doğru ağırlıklara ulaşılabilir ve tahminlerin doğruluğu artırılabilir. Bununla beraber, modelin eğitilmesinde farklı veri setlerinin kullanılması ile daha düşük hata oranları elde edilebilir.

## Kaynaklar (References)

- Aasim, S.N. vd., (2019) 'Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting', *Renewable Energy*, 136, pp. 758–768.
- Aksoy vd., (2013) 'Rüzgâr gücü üretimi için tahmin ve teklif sistemi tasarımı', *Endüstri Mühendisli Dergisi*, 24(3), pp. 4–15.
- Azad, H. B., Mekhilef, S., Ganapathy, V. G. (2014) 'Long-Term Wind Speed Forecasting and General Pattern Recognition Using Neural Networks', *IEEE Transactions on Sustainable Energy*, 5(2), pp. 546–553.
- Barbosa de Alencar, D. vd., (2017) 'Different Models for Forecasting Wind Power Generation: Case Study', *Energies*
- Brown, B. G., Katz, R. W., Murphy, A. H. (1984) 'Time Series Models to Simulate and Forecast Wind Speed and Wind Power', *Journal of Climate and Applied Meteorology*. American Meteorological Society, 23(8), pp. 1184–1195.
- Cadenas, E. vd., (2016) 'Wind Speed Prediction Using a Univariate ARIMA Model and a Multivariate NARX Model', *Energies*
- Che, Y. vd., (2016) 'A wind power forecasting system based on the weather research and forecasting model and Kalman filtering over a wind-farm in Japan', *Journal of Renewable and Sustainable Energy*, 8(1), p. 13302
- Demolli, H. vd., (2019) 'Wind power forecasting based on daily wind speed data using machine learning algorithms', *Energy Conversion and Management*, 198, p. 111823.
- Dokuz, A. S. vd., (2018) 'Year-ahead wind speed forecasting using a clustering-statistical hybrid method', in *CIEA '2018 International Conference on Innovative Engineering Applications*, pp. 971–975.
- Duan, Jikai vd., (2021) 'Short-term wind speed forecasting using recurrent neural networks with error correction', *Energy*, 217, p. 119397.
- Dumitru, C.-D., Gligor, A. (2017) 'Daily Average Wind Energy Forecasting Using Artificial Neural Networks', *Procedia Engineering*, 181, pp. 829–836.
- Eldali, F. A. vd., (2016) 'Employing ARIMA models to improve wind power forecasts: A case study in ERCOT', in *2016 North American Power Symposium (NAPS)*, pp. 1–6.
- Fu, C. vd., (2019) 'Short-Term Wind Power Prediction Based on Improved Chicken Algorithm Optimization Support Vector Machine', *Sustainability*.
- Higashiyama, K., Fujimoto, Y., Hayashi, Y. (2017) 'Feature extraction of numerical weather prediction results toward reliable wind power prediction', in *2017 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe)*, pp. 1–6.
- Hong, T. vd., (2020) 'Energy Forecasting: A Review and Outlook', *IEEE Open Access Journal of Power and Energy*, 7, pp. 376–388.
- Kavasseri, R. G., Seetharaman, K. (2009) 'Day-ahead wind speed forecasting using f-ARIMA models', *Renewable Energy*, 34(5), pp. 1388–1393.
- Lei, M. vd., (2009) 'A review on the forecasting of wind speed and generated power', *Renewable and Sustainable Energy Reviews*, 13(4), pp. 915–920.
- Li, C. vd., (2018) 'Short-term wind power prediction based on data mining technology and improved support vector machine method: A case study in Northwest China', *Journal of Cleaner Production*, 205, pp. 909–922.
- Madhiarasan, M. (2021) 'Long-term wind speed prediction using artificial neural network-based approaches', *AIMS Geosciences*. AIMS Press, 7(4), pp. 542–552.
- Neshat, M. vd., (2021) 'A deep learning-based evolutionary model for short-term wind speed forecasting: A case study of the Lillgrund offshore wind farm', *Energy Conversion and Management*, 236, p. 114002.
- Ozkan, M. B., Karagoz, P. (2015) 'A Novel Wind Power Forecast Model: Statistical Hybrid Wind Power Forecast Technique (SHWIP)', *IEEE Transactions on Industrial Informatics*, 11(2), pp. 375–387.
- Rajagopalan, S., Santoso, S. (2009) 'Wind power forecasting and error analysis using the autoregressive moving average modeling', in *2009 IEEE Power & Energy Society General Meeting*, pp. 1–6.
- Sfetsos, A. (2002) 'A novel approach for the forecasting of mean hourly wind speed time series', *Renewable Energy*, 27(2), pp. 163–174. doi:
- Torres, J. L. vd., (2005) 'Forecast of hourly average wind speed with ARMA models in Navarre (Spain)', *Solar Energy*, 79(1), pp. 65–77.
- Türkiye Rüzgar Enerjisi İstatistik Raporu (2019). Available at: <https://tureb.com.tr/lib/uploads/4e77501b714739a9>

.pdf.

- Wang, X., Guo, P., Huang, X. (2011) 'A Review of Wind Power Forecasting Models', *Energy Procedia*, 12, pp. 770–778.
- Yu, C. vd., (2018) 'A novel framework for wind speed prediction based on recurrent neural networks and support vector machine', *Energy Conversion and Management*, 178, pp. 137–145.
- Yu, R. vd., (2019) 'Scene learning: Deep convolutional networks for wind power prediction by embedding turbines into grid space', *Applied Energy*, 238, pp. 249–257.
- Zhang, Z. vd., (2019) 'Long Short-Term Memory Network based on Neighborhood Gates for processing complex causality in wind speed prediction', *Energy Conversion and Management*, 192, pp. 37–51.