



Araştırma Makalesi / Research Article

Mum Çubuğu Grafik Gösterimi, Minimum Artıklık Maksimum İlgililik Algoritması ve XGBoost Modeline Dayalı Rüzgâr Hızı Tahmini

Wind Speed Forecasting Based on Candlestick Chart Representation, Minimum Redundancy Maximum Relevance Algorithm and XGBoost Model

Seçkin Karasu^{1*}¹ Zonguldak Bülent Ecevit Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, seckin.karasu@beun.edu.trORCID: <https://orcid.org/0000-0001-5277-5252>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 5 Haziran 2024
Revizyon 21 Kasım 2024
Kabul 25 Aralık 2024
Online 26 Mart 2025

Anahtar Kelimeler:

Rüzgâr Hızı Tahmini,
Mum Çubuğu Grafiği,
XGBoost,
MRMR,
Osilatörler

ÖZ

Günümüz elektrik şebekelerinde fosil enerji kaynaklarına bağımlılığı azaltmak için yenilenebilir enerji kaynaklarına dayalı elektrik üretim tesislerinin sayısı giderek artmaktadır. Rüzgâr türbinleri (RT) sayesinde rüzgâr enerjisi elektrik enerjisine çevrilmekte ve RT'lerin günlük elektrik ihtiyacını karşılama noktasında elektrik şebekesine entegrasyonu sağlanmaktadır. RT'nin yüksekliği, rüzgâr türbininin kanat yapısı, jeneratör çıkış gücü, mekanik ve elektrik dönüştürücü verimliliği gibi iç faktörler ile birlikte rüzgâr hızı ve yönü gibi dış faktörlere bağlı olarak RT'nin çıkış gücü etkilenmektedir. Rüzgâr hızını tahmin etmek rüzgâr çiftliği operatörlerinin elektrik üretimini optimize etmesine olanak tanımaktadır. Bu sayede rüzgâr enerjisi elektrik şebekesine daha iyi entegre edilebilmektedir. Mevcut çalışmalar, kısa vadeli tahmin yaklaşımlarının doğruluk açısından yetersiz kaldığını ve rüzgâr hızının doğrusal olmayan ve stokastik doğasının tam anlamıyla modellenemediğini ortaya koymaktadır. Bu nedenle, tekil modeller yerine hibrit modellerin kullanımı giderek yaygınlaşmakta ve daha yüksek tahmin performansı sağlamak amacıyla tercih edilmektedir. Bu çalışmada, rüzgâr hızını tahmin etmek için mum çubuğu gösterimi, özneliklerin Minimum Artıklık Maksimum Uygunluk (Minimum Redundancy Maximum Relevance-MRMR) yaklaşımı ile değerlendirildiği XGBoost modeline dayalı yeni bir yöntem önerilmektedir. RT'de bulunan Merkezi Denetleme Kontrol ve Veri Toplama (SCADA) sisteminden 10 dakikalık örnekleme zamanı için 1 yıllık zaman dilimi içerisinde toplanan veri seti kullanılmaktadır. Veri seti öncelikle ön işleme adımından geçirilerek rüzgâr yönü, rüzgâr hızı dağılımı gibi değerler ile istatistiksel değerlere bakılmaktadır. Daha sonra zaman serisine mum çubuğu gösterimi işlem adımı uygulanmaktadır. Elde edilen gösterim için trend ve osilatör tabanlı öznelikler uygulanarak MRMR yaklaşımı ile öznelik grubu değerlendirilmiştir. XGBoost yöntemi ile rüzgâr hızı tahmin modeli oluşturulmakta ve model karmaşıklığının az ve tahmin hatasının en düşük olduğu durum elde edilmektedir. Özellikle mum çubuğu grafik gösterimine dayalı olarak önerilen bu hibrit yaklaşım, kısa vadeli rüzgâr hızı tahmininde doğruluğu artırmayı ve geleneksel yöntemlerin sınırlamalarını aşmayı hedeflemektedir. Önerilen yöntem, tüm diğer modellere göre en düşük hata oranı (RMSE: 0.0644) ve en yüksek korelasyon katsayısı (R: 0.8601) ile en iyi performansı göstermektedir. Bu, modelin doğruluk ve hata oranları açısından üstün olduğunu göstermektedir.

ARTICLE INFO

Article history:

Received 5 June 2024
Received in revised form 21 November 2024
Accepted 25 December 2024
Available online 26 March 2025

Keywords:

Wind Speed Forecasting,
Candlestick Chart,
XGBoost,
MRMR,
Oscillators

Doi: 10.24012/dumf.1496080

* Sorumlu Yazar

ABSTRACT

In today's electricity networks, the number of electricity generation facilities based on renewable energy sources is increasing in order to reduce the dependence on fossil energy sources. Thanks to the Wind Turbine (WT), the wind energy is converted into electrical energy and the integration of WT into the electricity network is ensured at the point of meeting the daily electricity needs. WT output power is affected by external factors such as wind speed and direction, as well as internal factors such as WT's height, blade structure, generator output power, mechanical and electrical converter efficiencies. Forecasting wind speed allows wind farm operators to optimize electricity production. In this way, wind energy can be better integrated into the electricity network. Existing studies reveal that short-term forecasting approaches are inadequate in terms of accuracy and the nonlinear and stochastic nature of wind speed cannot be fully modeled. For this reason, the use of hybrid models, rather than standalone models, is becoming increasingly prevalent as they offer superior predictive performance. In this study, a novel approach based on candlestick representation, features evaluated with Minimum Redundancy Maximum Relevance (MRMR) approach and XGBoost model proposed for wind speed prediction. The dataset collected from the Supervisory Control and Data Acquisition (SCADA) system in WT for a sampling time of 10 minutes within a 1-year period is used. The data set is first passed through the preprocessing step and the wind direction, wind speed distribution and statistical values are examined. Then, the candlestick representation process step is applied to the time series. Afterwards, candlestick representation is utilized to derive trend and oscillator-based features, the feature group is evaluated with the MRMR approach. A wind speed prediction model is created with the XGBoost method and a situation with low model complexity and lowest prediction error is achieved. This proposed hybrid approach, especially based on candlestick chart representation, aims to increase the accuracy in short-term wind speed forecasting and overcome the limitations of traditional methods. The proposed method shows the best performance with the lowest error rate (RMSE: 0.0644) and the highest correlation coefficient (R: 0.8601) compared to all other models. This shows that the model is superior in terms of both accuracy and error rate.

Giriş

Temiz ve yeşil enerji olarak tanımlanan rüzgâr enerjisi, birçok ülke tarafından diğer enerji türlerine göre daha çok tercih edilmeye başlamıştır [1]. Son zamanlarda özellikle fosil kaynaklara bağımlı enerji üretim santrallerinin yerini yenilenebilir enerji kaynaklarına dayalı enerji üretim santralleri almaktadır [2]. Rüzgâr enerjisine dayalı santrallerin düşük maliyetli, verimli ve ileri teknoloji ürünü olması yatırımcılar için de tercih edilme sebepleri arasında sıralanmaktadır [2-3]. Rüzgâr santrali kurulumu yüksek başlangıç sermayesi gerektirse de özellikle Avrupa ve Amerika'da rüzgâr türbini maliyetleri giderek azalmaktadır. [4]. Tüm bu avantajlar göz önünde bulundurularak kuvvetli rüzgârların olduğu alanlarda rüzgâr çiftlikleri kurulumu giderek yaygınlaşmaktadır [5].

Rüzgâr hızının doğru tahmini, rüzgâr santrallerinin istikrarlı çalışması için kritik bir öneme sahiptir [6]. Doğru tahmin işlemi rüzgâr enerjisine dayalı elektrik üretimini optimize etmeyi ve kaynakları en etkin şekilde kullanmayı sağlamaktadır [6-8]. Böylelikle rüzgâr enerjisine bağlı elektrik üretim santrallerinin elektrik şebekesine entegre edilmesi için bu işlem daha iyi olanak sunmaktadır. Tahmin işlemi doğru bir şekilde yapılarak rüzgâr santrali operatörlerinin elektrik şebekesindeki talep dalgalanmalarını planlamasına katkı sağlamaktadır. Genel olarak incelendiğinde, rüzgâr hızının doğru tahmini ile rüzgâr enerjisinin bir elektrik kaynağı olarak etkin ve verimli kullanmak mümkün olmaktadır. Bunun yanında rüzgâr hızının tahmini ile türbinlerin ne zaman yüksek stres altında olacağını belirlenmesi sağlanarak durum tabanlı bakım yapılabilmektedir [9]. Aşırı rüzgâr hızlarının türbinlere zarar verme riski de tahminlerle önceden tespit edilerek, arıza önleme stratejileri geliştirilebilmektedir. Böylece bakım ve onarım gibi işlerinde planlanmasına yardımcı olmaktadır [2], [9]. Rüzgâr çiftliği operatörlerinin operasyonlarını yönetmelerine yardımcı olmanın yanı sıra, rüzgâr gücünün doğru tahmin edilmesi ile şebekedeki arz ve talebi dengelemek için kamu hizmetleri ve diğer elektrik şebekesi operatörleri tarafından da tahmin bilgisi kullanılabilir [4],[10]. Şebeke operatörleri, herhangi bir zamanda bir rüzgâr çiftliğinin ne kadar elektrik üreteceğini tahmin ederek, talebi karşılamak için diğer elektrik üretim kaynaklarının nasıl dağıtılacağı konusunda daha bilinçli kararlar alabilmektedir [4],[10].

Literatür incelendiğinde farklı yaklaşımlar kullanılarak rüzgâr hızının tahmini çalışmasının yapıldığı görülmektedir. Rüzgâr çiftliklerinin planlanması ve uygulanabilirliğini artırmak için rüzgâr hızını daha doğru tahmin etmek üzerine yeni bir yaklaşım önerilmiştir. Beş yıl boyunca bir dağlık bölgedeki rüzgârlı bir şehirden elde edilen veriler kullanılarak, çekirdek Ridge Regresyon (Ridge Regression-RR) modeli önerilmiş ve geleneksel Destek Vektör Makineleri (Support Vector Machines-SVM) ve Yapay Sinir Ağları (Artificial Neural Networks-ANN) gibi diğer tahmin modelleriyle karşılaştırılmıştır. Çalışmada RR yönteminin diğer yöntemlere kıyasla daha iyi sonuç verdiği gösterilmektedir [11]. Bir başka çalışmada yeni bir rüzgâr hızı tahmini yöntemi olan Ampirik Dalga Dönüşümü (Empirical Wavelet Transform-EWT) kullanılarak orijinal rüzgâr hızı sinyali birden çok İçsel Mod Fonksiyonu (Intrinsic

Mode Function-IMF)'na ayrılmıştır. Ardından, her bir modelin üstünlüğüne dayanarak, Otoregresif Entegre Hareketli Ortalamalar (Autoregressive Integrated Moving Average-ARIMA) istatistiksel modeli ile En Küçük Kareler Destek Vektör Makinesi (Least Squares Support Vector Machine-LSSVM) ve Gauss Süreç Regresyonu (Gaussian Process Regression-GPR) gibi yapay zekâ modelleri de dahil olmak üzere çeşitli tahmin modelleri kullanılarak IMF'nin sırayla düşük frekanslıdan yüksek frekanslıya kadar tahmin edilmesi amaçlanmıştır. Yapay zekâ tahmin modellerinin LSSVM ve GPR hiper parametrelerini optimize etmek için Diferansiyel Evrim (Differential Evolution-DE) ve Gri Kurt Optimizasyon (Grey Wolf Optimizer-GWO) yöntemlerinin birleşiminden oluşan DE-GWO algoritması kullanılmıştır. Önerilen yöntemin ölçüm verileriyle doğrulanarak hem doğruluk hem de kararlılık açısından üstün performans sergilediği gösterilmiştir [12]. Bir diğer çalışmada rüzgâr hızının zamana bağlı değişkenliğinin ve öngörülemezliğinin tahmin sonuçlarındaki olumsuz etkilerini gidermek için çoklu türbinler arasındaki mekânsal ve zamansal korelasyonların geliştirilmesi hedeflenerek, dijital ikiz ve nesnelerin interneti teknolojilerinin de kullanılması önerilmektedir. İlişkili türbinler için dinamik tarama ve tahmin sonuçlarının senkronize doğrulamasını içeren bir mimari önerilmekte ve çoklu türbinler korelasyon modeli, gerçek zamanlı rüzgâr hızı tahmini görevini formüle etmektedir. Çalışmanın sonuçları, tahmin modelinin doğruluğunu ve sağlamlığını artırdığını göstermektedir [13]. Bir başka çalışmada ise SCADA sisteminde rüzgâr hızını ve elektrik üretimini tahmin etmek için makine öğrenmesi tabanlı altı farklı tahmin modeli kullanılmıştır [14]. Ayrıca, makine öğrenmesi algoritmalarının sonuçları 4, 5 ve 10 kat çapraz doğrulama yöntemleri kullanılarak elde edilen sonuçlar birbirleriyle karşılaştırılmıştır. Üç aylık üretim gücünü tahmin etmede birlikte çalışma yönteminin 10 kat çapraz doğrulama ile en düşük RMSE değeri verdiği ve rüzgâr hızını tahmin etmede ise yine en düşük RMSE değeri ile elde edildiği belirtilmiştir [14]. Rüzgâr hızını tahmin etmek için gürültü (noise) işleme yöntemleri, istatistiksel teknikler, derin öğrenme çerçeveleri ve optimizasyon algoritmalarını içeren birlikte çalışma tahmin modeli sunulmuştur [15]. Önerilen birleşik model, gerçek dünya koşullarından elde edilen 10 dakikalık rüzgâr hızı verileriyle test edilmiştir. Sonuçlar, önerilen modelin 10 dakikalık tahmin sonuçlarında diğer modellere kıyasla %17'lik bir iyileşme sağladığı ortaya çıkartılmıştır [15]. Bir başka çalışmada bulanık bilgi granülasyon teknolojisi kullanılarak veri boyutu azaltılmış ve rüzgâr hızı verilerindeki fazlalık giderilmiştir [16]. Ayrıca, çok amaçlı yusufçuk algoritması ile alt modeller birleştirilmiş ve doğruluk artırılmıştır. Penglai rüzgâr çiftliğinde yapılan testler sonucunda, önerilen sistemin diğer modellere kıyasla en iyi tahmin performansı gösterdiği ve ortalama iyileştirme oranının çoklu adım tahmin aşaması için üç sitede %14.97, %16.48 ve %19.11 olduğu bulunmuştur [16]. Bir diğer çalışmada adaptif arama stratejisine sahip Geliştirilmiş Gri Kurt Optimizasyon Algoritması (Search Strategy Grey Wolf Optimizer-SAGWO) ve Uzun-Kısa Süreli Bellek (Long Short-Term Memory-LSTM) kombinasyonuna dayanan yeni bir yöntem önerilmiştir. İlk olarak, rüzgâr hızı verileri analiz edilerek yüksek benzerlik gösteren rüzgâr türbinleri seçilmiştir. Daha sonra, bu türbinlerin rüzgâr hızı verileri giriş olarak alınmış ve LSTM, SAGWO ile optimize edilerek

tahmin doğruluğu artırılmıştır. Son olarak, gürültü eklenmiş rüzgâr hızı verilerinin yeniden inşası için SAGWO-LSTM modeli oluşturulmuştur. Deneysel sonuçlar, önerilen yöntemin rüzgâr hızı tahmini konusunda referans modellere kıyasla daha iyi performans gösterdiğini ortaya koymuştur [17]. Bir başka çalışmada rüzgâr çiftliklerinde ultra-kısa süreli rüzgâr hızı tahminlerinin doğruluğunu artırmak için EWT ve birleştirilmiş model tabanlı bir yöntem önerilmektedir. İlk olarak, ampirik dalgacık dönüşümü kullanılarak ultra-kısa vadeli rüzgâr hızı zaman serileri bileşenlerine ayrıştırılmıştır. Daha sonra, örnek entropi ile bu bileşenlerin karmaşıklıkları hesaplanarak benzer seviyede karmaşıklığa sahip olanlar yeniden oluşturmuştur. Yeniden oluşturulan bileşenlerin analizi sonrası, Gelişmiş Serçe Arama Algoritması (Improved Sparrow Search Algorithm-ISSA) ile optimize edilmiş Aşırı Öğrenme Makinesi (Extreme Learning Machine-ELM) ve Kapılı Tekrarlayan Sinir Ağı (Gated Recurrent Neural Network-GRNN) tahmin modelleri kullanılmıştır. Son olarak her tahmin modelinin ağırlık katsayılarını optimize etmek için ISSA kullanılarak tahmin sonuçları elde edilmiştir. Deneysel doğrulamalar, önerilen yöntemin önceki tekli ve birleşik tahmin yöntemlerine göre daha yüksek doğruluk sağladığını göstermiştir [18]. Bir diğer çalışmada kentsel alanlardaki rüzgâr hızlarını tahmin etmek için bina yüksekliği, bina hacim oranı ve yüzey alanı oranı gibi kentsel morfolojik parametreler ile rüzgâr hızı arasındaki ilişki çoklu regresyon analizi ile incelenerek bir tahmin yaklaşımı önerilmiştir. Üç farklı yerleşim alanı için Hesaplamalı Akışkanlar Dinamiği (Computational Fluid Dynamics-CFD) ve Yerel Veri Asimilasyonu ve Tahmin Sistemi (Local Data Assimilation and Prediction System-LDAPS) yöntemleri ile kıyaslanmıştır. Önerilen yöntemin korelasyon katsayısı ortalama 0,805'lik benzerlik gösterdiği ortaya çıkartılmıştır [19]. Meteorolojik verilerin kullanıldığı ve Bayesyen Optimizasyon Algoritması (Bayesian Optimization Algorithm-BOA), Varyasyonel Mod Ayrıştırma (Variational Mode Decomposition-VMD), Temel Bileşen Analizi (Principal Component Analysis-PCA) ve Rastgele Orman (Random Forest-RF) yaklaşımlarının harmanlandığı bir yöntemde ise rüzgâr hızının tahmini çalışmasında model hata değerlerinden RMSE değeri 0,3736 ve R değeri 0,8200 olarak elde edilmiştir [20]. Meteorolojik verilerin kullanıldığı bir diğer çalışmada ise ANN yaklaşımı ve Bayesyen Düzenleme (Bayesian Regularization-BR) yaklaşımının küresel yatay ışınım ve rüzgar hızı tahminlerinde etkili bir yöntem olduğunu ve elde edilen model hata değerlerinin sırasıyla MSE değeri için 0.3023, RMSE değeri için 0.5498 ve korelasyon katsayısı değeri için ise 0.8353 olarak bulunduğu belirtilmiştir [21].

Rüzgâr hızı tahmin modelini oluşturmak için genel olarak belirli örnekleme hızında toplanan veriler model girişinde kullanılmaktadır. Bunun yanında mum çubuğu grafikleri, geleneksel bir grafikte hemen görünmeyebilecek kalıpları ve eğilimleri belirlemek için kullanılmaktadır. Bu gösterim finansal piyasaları analiz etmek için tüccarlar ve yatırımcılar arasında popüler bir araçtır. Ancak farklı alanlardaki çalışmalarda da bir araç olarak kullanıldığı görülmektedir [22-24]. Mikroblog faaliyetlerine dayalı olarak ergenlerdeki stres eğilimlerini tahmin etmek için mum çubuğu grafiklerinin kullanılması önerilmektedir. Çalışmada

ergenlerin mikroblog gönderilerinde ifade edilen düşünce ve duyguları analiz edilerek, stres seviyelerindeki eğilimleri belirlemek için mum çubuğu grafikleri kullanmanın mümkün olabileceği gösterilmektedir. Çalışmada test aşamasında, bir grup ergenden mikroblog verileri toplanmakta ve gönderilerden duygu durumu ile ilgili bilgi çıkartmak için doğal dil işleme teknikleri kullanılmaktadır. Daha sonra bu bilgilere dayalı olarak mum çubuğu grafikleri oluşturulmaktadır. Elde edilen veriler ile bildirilen stres seviyeleri birbiri ile karşılaştırılmaktadır. Genel olarak, mum çubuğu grafiklerinin popülasyondaki stres eğilimlerini tahmin etmek ve izlemek için yararlı bir araç olabileceği gösterilmektedir [22]. Bir diğer çalışmada mum çubuğu gösterimi kullanılarak PM2.5 (ince parçacıklı madde) seviyelerinin eğilimini tahmin etmek için bir yöntem sunulmaktadır. PM2.5 seviyelerinin doğru bir şekilde tahmin edilebilmesi halk sağlığı ve çevre yönetimi için önemli olduğu bildirilmektedir. PM2.5 verilerinden ayırt edici özellikleri çıkarmak için finansal piyasalardaki fiyat hareketlerinin grafiksel temsilleri olan mum çubuğu grafiklerinin kullanılması önerilmektedir. Ardından, çıkartılan özellikleri sınıflandırmak ve PM2.5 seviyelerinin eğilimini tahmin etmek için Görsel Geometri Grubu (Visual Geometry Group-VGG) modeli kullanılmaktadır. Mum çubuğu gösterimi içeren yöntemin eğilim tahmininde etkili olduğu gösterilmektedir [23]. Amerikan futbolu oyunlarının sonuçlarını tahmin etmek için mum çubuğu gösterimi ile makine öğrenimi tekniklerinin harmanlandığı bir çalışma önerilmektedir. Çalışmada takımlar, oyun yeri ve oyun sonucu hakkında bilgiler dâhil olmak üzere toplam 652 Amerikan futbolu maçından elde edilen veriler kullanılmaktadır. Mum çubuğu gösteriminin katkısı ile oluşturulan modelin oyunların sonucunu yaklaşık %70 doğrulukla doğru bir şekilde tahmin edebildiği gösterilmektedir [24]. Bir diğer çalışmada finansal analiz tekniklerinden trend çizgileri ile Japon mum çubuklarının rüzgâr hızı tahmininde uygulanabilirliği incelenmiştir. İtalya'daki Capo Mele ve İspanya'daki Los Montes del Cierzo lokasyonlarından 2016 ve 2017 yıllarına ait rüzgâr hızı verileri analiz edilmiştir. Los Montes del Cierzo'daki veriler 10 dakikalık çözünürlükte ve 2 m ile 10 m yüksekliklerde, Capo Mele'deki veriler ise saatlik çözünürlükte toplanmıştır. Çalışmada, destek ve direnç çizgileri kullanılarak rüzgâr hızındaki ani artış ve azalışların tahmini yapılmıştır. Japon mum çubuklarıyla trend dönüş noktaları ve dalgalanma örüntüleri analiz edilmiştir. Destek ve direnç çizgileri, rüzgâr hızındaki dönüş noktalarını belirlemede etkili bulunmuş ve Japon mum çubuklarının desenleri ile birleştirildiğinde daha hassas tahminler elde edilmiştir. Özellikle uzun beyaz gövdeli mum çubukları artış eğilimini, siyah gövdeli mum çubukları ise azalış eğilimini temsil etmiştir. Çalışmada bu tekniklerin makine öğrenimi tabanlı modellerle entegre edilmesi durumunda rüzgâr hızı tahminlerinin doğruluğunu artırdığını belirtilmiştir [25]. Bu doğrultuda mum çubuğu gösteriminin, farklı alanlarda kullanımı düşünüldüğünde, rüzgâr hızı tahmininde de güçlü ve görsel olarak zengin bir yaklaşım sunabileceği ve makine öğrenmesi algoritmaları ile tahmin çalışması yapılarak tahmin doğruluğunun artırılacağı öngörülmüştür.

Bu çalışmada, rüzgâr hızının tahmini için yenilikçi bir hibrit yöntem önerilmektedir. Önerilen yöntemde, zaman serisi

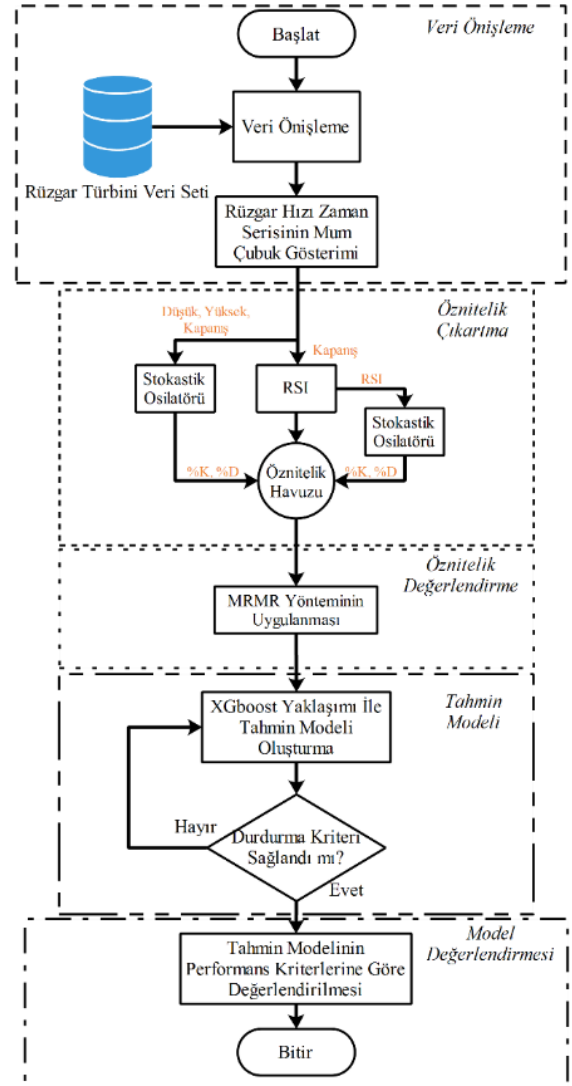
verileri üzerinde mum çubuğu gösterimi kullanılarak trend ve osilatör tabanlı göstergeler elde edilmiş ve bu öznitelikler Minimum Artıklık Maksimum Uygunluk (Minimum Redundancy Maximum Relevance-MRMR) yaklaşımı ile değerlendirilmektedir. Bu yaklaşım, öznitelik seçimini optimize ederek gereksiz verileri ortadan kaldırmakta ve rüzgâr hızı tahmini gibi doğrusal olmayan ve stokastik doğaya sahip karmaşık problemlerin çözümünde etkili olduğu kanıtlanan XGBoost modeli ile entegre edilmektedir. Literatürde, tek bir modelin rüzgâr hızının doğrusal olmayan ve dinamik doğasını tam anlamıyla yakalayamadığı belirtilmiştir; bu nedenle hibrit modellerin kullanımı giderek yaygınlaşmaktadır [8, 12]. Çalışmada, mum çubuğu gösteriminin görsel ve trend analizi avantajları ile MRMR ve XGBoost'un güçlü tahmin kapasitesinin birleştirilmesi, yöntemin tercih edilmesinin temel sebebidir. Önerilen hibrit yaklaşım, literatürde yaygın kullanılan yöntemlerin ötesine geçerek daha yüksek doğruluk ve düşük model karmaşıklığı sunmayı hedeflemektedir. Çalışmada rüzgâr türbinindeki Merkezi Denetleme Kontrol ve Veri Toplama (SCADA) sistemi kullanılarak, 10 dakikalık örnekleme zamanı için 1 yıllık bir veri seti kullanılmıştır. Veri seti, öncelikle ön işleme adımından geçirilmekte ve ardından, zaman serisine mum çubuğu gösterimi işlemi uygulanmıştır. Bu süreçte, elde edilen veriye trend ve osilatör tabanlı göstergeler uygulanarak öznitelik grubu elde edilmiştir. MRMR yaklaşımı ile öznitelikler kendi arasında değerlendirilerek 91 adet öznitelikten en yüksek skorlu 10 adet öznitelik belirlenmiştir. Geleneksel yöntemlerden Karar Ağaçları (Decision Trees-DT) modeli ile XGBoost modelinin performansları kıyaslanmış ve rüzgâr hızı tahmin modeli oluşturulmuştur. Sonuç olarak modelin karmaşıklığını azaltmak ve daha düşük tahmin hatası verecek bir model MRMR yaklaşımı ve XGBoost modeli ile elde edilmiştir. Oluşturulan model, farklı istatistiksel hata kriterleriyle değerlendirilmekte ve sonuç olarak rüzgâr hızı tahmininde yüksek performans sergilediği ortaya çıkarılmıştır. İkinci bölümde uygulanan metamateryal ve metotlar, üçüncü bölümde araştırma sonuçları ve tartışma, dördüncü bölümde ise sonuç detaylı olarak anlatılmıştır.

Materyal ve Metot

Çalışmada rüzgâr hızı tahmini için uygulanan adımlar Şekil 1'deki akış diyagramı ile verilmektedir. İşlem adımları veri ön işleme, öznitelik çıkartma, öznitelik değerlendirme, tahmin modeli oluşturma ve oluşturulan modelin değerlendirilmesi olmak üzere beş aşamadan oluştuğu söylenebilir. İlk aşamada veri, ön işleme adımına tabi tutulmaktadır. Daha sonra rüzgâr türbini zaman serisinin mum çubuk gösterimi yapılmaktadır. İkinci aşamada ise ayırt edici göstergeler işlenmiş zaman serilerine uygulanarak öznitelik çıkartma işlemi tamamlanmaktadır. Çıkarılan öznitelikler MRMR yaklaşımı ile değerlendirilmekte ve yüksek skorlananlar kullanılarak XGBoost yaklaşımı ile tahmin modeli oluşturulmaktadır. Model değerlendirme aşaması ile elde edilen modelin istatistiksel hata kriterlerine göre başarımı ölçülmektedir. MRMR yaklaşımı kullanılmadığı duruma göre tüm özniteliklerin başarıma olan etkisi de incelenmiştir. Ayrıca geleneksel makine öğrenmesi yaklaşımı olan DT ile XGBoost yaklaşımının performansı da kıyaslanmıştır. Devam eden kısımlarda bu bileşenler daha detaylı olarak açıklanmaktadır.

Rüzgâr Türbini Veri Seti

Çalışmada, konum bilgisi Şekil 2'deki gibi verilen Yalova ilinde bulunan rüzgâr türbininden 2018 yılı boyunca toplanan veri seti kullanılmıştır [26]. Veri toplamak için SCADA sistemi kullanılmıştır. SCADA sistemi, rüzgâr türbinlerinden veri toplamak, izlemek ve kontrol etmek için kullanılan kapsamlı bir otomasyon sistemidir. Rüzgâr türbinlerine entegre edilen sensörler, rüzgâr hızı, rüzgâr yönü, rotor dönüş hızı, jeneratör çıkış gücü gibi parametreleri gerçek zamanlı olarak ölçmektedir. Bu ham veriler, türbinlere bağlı programlanabilir mantık denetleyicileri (PLC) veya uzaktan terminal birimleri (RTU) tarafından toplanmakta ve dijitalleştirilerek SCADA sistemine iletilmektedir. Veriler, belirli aralıklarla örneklenmekte ve kaydedilmektedir [5,14, 26]. Elde edilen veri seti, rüzgâr hızı, rüzgâr yönü, teorik aktif güç ve gerçek aktif güç gibi temel giriş değişkenlerini içermektedir. Veriler, 10 dakikalık zaman aralıklarında toplanmış olup, toplam süre 1 Ocak 2018'den 31 Aralık 2018'e kadar uzanmaktadır. Bu süre boyunca toplanan veriler, rüzgâr türbinlerinin performansını incelemek, verimliliklerini ölçmek ve gelecekteki enerji üretimini tahmin etmek için değerli bir kaynak sunmaktadır.



Şekil 1. Çalışmada uygulanan yöntemin akış diyagramı




Şekil 2. Yalova ilinde bulunan rüzgâr türbininin konum gösterimi

Rüzgâr türbininin özelliklerinden bahsedilecek olursa Sinovel'in SL1500/90 modeli, 1.5 MW etiket gücüne sahip olup, 100 metre yüksekliğinde bir göbek ile donatılmıştır. Rotor yarıçapı 90 metre olan bu türbinin taranan alanı 6362 metrekaare olup, üç kanata sahiptir. Türbinin devreye girmesi için gereken rüzgâr hızı 3 m/s iken, etiket rüzgâr hızı 10 m/s ve devreden çıkma rüzgâr hızı 22 m/s olarak belirlenmiştir. Bu karakteristikler, türbinin performansını etkileyen temel faktörlerdir.

Rüzgâr Hızı Zaman Serisinin Mum Çubuğu Grafik Gösterimi

Mum çubuğu grafiği, bir menkul kıymetin, türevin veya para biriminin belirli bir süre için en yüksek, en düşük, açılış ve kapanış fiyatlarının gösterildiği grafik türüdür. Fiyat hareketlerini ve zaman içindeki eğilimleri görselleştirmek için genellikle teknik analizde kullanılmaktadır. Şekil 3'te mum çubuğu gösterimi verilmektedir.



Şekil 3. Mum çubuğu gösterimi

Kapanış fiyatı açılış fiyatından yüksekse, şamdan tipik olarak beyaz veya yeşil renkte gösterilmektedir. Kapanış fiyatı açılış fiyatından düşükse, şamdan tipik olarak siyah veya kırmızı olarak gösterilmektedir. Şamdan gövdesi,

açılış ve kapanış fiyatları arasındaki aralığı temsil ederken, fitil veya kuyruk, dönemin en yüksek ve en düşük fiyatlarını temsil etmektedir [27].

Bir mum çubuğu grafiğindeki her bir mum tipik olarak tek bir günlük veri değerini temsil edebildiği gibi farklı zaman dilimleri içinde mum çubuğu grafiği oluşturmak mümkündür. Çalışmada 10 dakikalık aralıklarla toplanan veriler kullanılacağı için 10 dakikalık veriler 1 saatlik verilere çevrilmektedir.

Mum Çubuğu Gösterimine Uygulanan Göstergeler

Basit hareketli ortalama filtresi ve eksponansiyel hareketli ortalama filtresi olmak üzere çeşitli trend göstergeleri ile göreceli güç endeksi ve stokastik osilatörü gibi osilatör tabanlı göstergeler bu kısımda çıkartılan öznelikler olarak bahsedilecektir.

Basit Hareketli Ortalama Filtresi

Bu filtre belirli bir zaman diliminde mum çubuğu gösterimindeki kapanış değerlerinin toplamının toplam gün sayısına bölünerek hesaplanmaktadır [28]. N zaman dilimi için ortalama kapanış değeri hesabı Denklem 1'deki gibi hesaplanmaktadır.

$$BHO_N = \frac{C_1 + C_2 + C_3 + \dots + C_N}{N} \quad (1)$$

Eksponansiyel Hareketli Ortalama Filtresi

Eksponansiyel hareketli ortalama filtresi, temel olarak basit hareketli ortalama filtresinin bir türevi olarak ifade edilebilir [29]. Basit hareketli ortalamaya göre hesaplanmasında son fiyat değerinin ağırlığı yüksek olmaktadır. Denklem (2)'deki gibi N periyodu için hesaplanmaktadır.

$$EHO_N = \alpha \times C_N + (1 - \alpha) \times C_2 + EHO_{N-1} \quad (2)$$

Burada son değerin hesaplanabilmesi için önceki değerin bilinmesi gerekmektedir. Önceki değerin hesabı için algoritma ilk kez çalıştırıldığında BHO değeri hesaplanarak kullanılmaktadır.

Stokastik Osilatörü

Stokastik indikatörü 1950'lerde George Lane tarafından geliştirilen bir momentum indikatörüdür [30]. Stokastik indikatörü belirli bir periyod içerisinde yüksek ve düşük değerlerin mevcut fiyata olan yakınlığını göstermektedir. Stokastik indikatörü ile oluşan fiyatların yükselmeye veya düşmeye başladığı trendlerin başlangıçları daha kolay tespit edilebilmektedir. Trend dönüşlerinin yanı sıra aşırı alım veya aşırı satım seviyelerinin de tespit edilmesinde bu indikatör kullanılmaktadır. Denklem (3)'teki gibi Stokastik değeri hesaplanmaktadır.

$$S = \frac{(Kapanış - Min(Kapanış))}{(Max(Kapanış) - Min(Kapanış))} \quad (3)$$

Bu ifadenin 100 ile çarpılmış hali %K değeri olarak isimlendirilmektedir. Bu değerin 3 günlük ortalaması alınarak hesaplanması durumunda ise %D çizgisi elde edilmektedir.

Göreceli Güç Endeksi İndikatörü

Göreceli Güç Endeksi (Relative Strength Index-RSI) bir finansal varlığın aşırı alım veya aşırı satım durumlarını belirlemek için kullanılan bir teknik göstergedir [31]. RSI, genellikle bir varlığın fiyat hareketlerinin hızını ve büyüklüğünü ölçmek için kullanılmaktadır RSI değeri Denklem (4)'teki gibi hesaplanmaktadır.

$$RSI = 100 - \frac{100}{1 + RS} \quad (4)$$

Burada RS, bir varlığın belirli bir dönemde yukarı yönlü hareketlerinin (örneğin kapanış değerinin önceki kapanış değerine göre artış) ortalamasının, aşağı yönlü hareketlerinin (kapanış değerinin önceki kapanış değerine göre azalma) ortalamasına oranı olarak Denklem (5)'teki gibi ifade edilmektedir.

$$RS = \frac{\text{Pozitif Kapanışların Ortalaması}}{\text{Negatif Kapanışların Ortalaması}} \quad (5)$$

Stokastik RSI

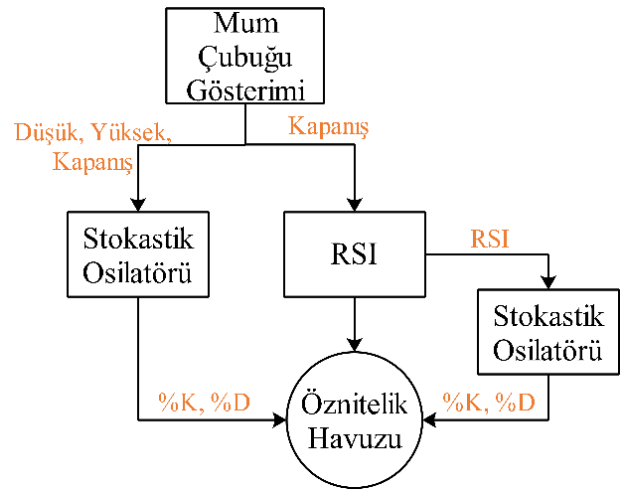
Stokastik RSI kavramından ilk defa, Stanley Kroll ve Tushar Chande tarafından ortaya çıkarılmıştır [32]. Stokastik RSI, bir enstrümanın fiyatını değil, doğrudan RSI değerini temel alarak o enstrümanın aşırı alım veya aşırı satım noktasında olup olmadığını anlamaya yarayan bir teknik analiz göstergesidir. Denklem 6'daki gibi ifade edilmektedir.

$$RSI = \frac{(RSI - Min(RSI))}{(Max(RSI) - Min(RSI))} \quad (6)$$

Finansal piyasalardaki bir varlık ile mum çubuğu gösterimi elde edilen rüzgâr türbininden toplanan veriler arasında bir

analoji kurulabilir. Örneğin rüzgâr enerji üretimi, rüzgâr hızının belirli bir aralıkta olmasıyla en verimli hale gelmektedir. Bir rüzgâr türbini, belirli bir rüzgâr hızında optimal verimlilik sağlar ve bu genellikle orta bir seviyededir. Eğer rüzgâr hızı çok düşükse, türbin dönmeyi ve enerji üretimi düşer, bu da aşırı satış benzeri bir duruma karışık gelmektedir. Aynı şekilde, rüzgâr hızı çok yüksekse, türbin aşırı yüklenir ve aşırı hızda dönmeye çalışır, bu da aşırı alım benzeri bir duruma işaret etmektedir. Stokastik RSI gibi bir gösterge, rüzgâr hızının genel eğilimini izleyerek, türbinin optimal performans noktasının nerede olduğunu belirlememize yardımcı olacaktır. Bu da rüzgâr enerji üretimi için etkin bir tahmin ve yönetim sağlamakla birlikte mum çubukları da belirli bir dönemdeki rüzgâr hızını temsil etmektedir. Bunun yanında Stokastik RSI gibi göstergeler daha genel bir perspektif sunmaktadır.

Çalışmada stokastik osilatörü, RSI ve Stokastik RSI göstergelerinin farklı periyotlar uygulanarak çıkartılan özneliklerinin oluşturduğu öznelik havuzunun gösterimi Şekil 4'teki gibidir.



Şekil 4. Mum çubuğu gösteriminden çıkartılan özneliklerden öznelik havuzunun oluşturulması

Karar Ağaçları Modeli

DT yaklaşımı hem sınıflandırma hem de regresyon problemlerinde kullanılan temel ve sezgisel bir makine öğrenimi algoritmalarından biri olarak tanımlanmaktadır [33]. Bu yaklaşımda veri dallara ayrılarak her düğümde bir özelliğe göre karar verilmekte ve sınıflandırma veya tahmin işlemi yapılmaktadır. Ağaç yapısında, kökten başlayarak veriyi dallara ayırmakta ve her yaprakta nihai bir sınıf ya da değer tahmin edilmektedir [33].

XGBoost Modeli

Gradyen Artırma (Gradient Boosting) algoritması birçok zayıf tahminciyi bir araya getirerek güçlü bir tahminci oluşturmayı amaçlayan bir makine öğrenimi tekniğidir [34]. Gradyen Artırma, zayıf öğrenicileri, genellikle karar ağaçları olarak bilinen basit modelleri kullanarak bir araya getirir ve ardışık olarak eğitmektedir. Tablo 1'de Gradyen Artırma algoritmasının sözde kodu (pseudo kodu) verilmiştir.

Tablo 1. Gradyen Artırma Algoritması

Gradyen Artırma Algoritması
1. Veri setini yükle
2. Hedef değişkeni belirle
3. Başlangıç tahmini yap (örneğin, ortalama değeri kullan)
4. Başlangıç artıkları hesapla: Hedeflenen- Başlangıç tahmini
5. Döngü başlat
a. Zayıf öğrenici oluştur
- Veri setini ve artıkları kullanarak bir karar ağacı eğit
b. Yeni tahmin yap: Önceki tahmin + Zayıf öğrenicinin tahmini
c. Yeni artıkları hesapla: Hedeflenen- Yeni tahmin
d. Artıkları güncelle
e. Döngüden çıkma kriterini kontrol et (örneğin, belirli bir iterasyon sayısı veya artıkların belirli bir eşiği)
6. Döngüyü sonlandır

İlk aşamada, basit bir tahminci olarak veri setinin ortalaması kullanılmaktadır. Ardından, bu başlangıç tahmini ile gerçek değerler arasındaki farklar, artıklar olarak adlandırılmaktadır. Bu artıkları tahmin etmek için bir dizi zayıf öğrenici eğitilir, bu aşamada genellikle karar ağaçları tercih edilmektedir. Her bir ağaç, önceki ağaçların gerçek değerlerle yapılan tahminler arasındaki farkları minimize etmeye odaklanmaktadır. Son olarak, tüm zayıf öğrenicilerin tahminleri ağırlıklı olarak birleştirilir ve toplu bir tahmin yapılmaktadır. Bu yöntem, hedef değişkeninin karmaşık ve doğrusal olmayan ilişkilerini modellemek için etkili bir yol sağlamakla birlikte sınıflandırma ile regresyon problemlerinde yaygın bir şekilde kullanılmaktadır.

XGBoost modeli, Gradyen Artırma algoritmasını kullanarak, ağaç tabanlı modellerin performansını artırmak için optimize edilmiş ve paralel hale getirilmiş bir makine öğrenmesi uygulamasıdır [34]. Sınıflandırma ve regresyon problemlerinde yüksek performans ve hızlı eğitim süreleri sunmaktadır. Bu çalışmada model eğitimi için oluşturulan program için Python programlama dili kullanılmış olup DT, XGBoost modelleri için scikit-learn kütüphanesi kullanılmıştır.

Minimum Artıklık Maksimum Uygunluk Yöntemi

MRMR yöntemi bir veri kümesindeki özellikler arasından en uygun olanları seçmek için kullanılmaktadır [35]. MRMR, özelliklerin birbirleriyle olan ilişkilerini minimize ederken hedef değişkenle maksimum ilişkiyi sağlayan özellikleri seçmektedir. Yöntemde her bir öznelik ayrı bir rastlantı değişkeni olarak ele alınarak ve iki öznelik, X ve Y, arasındaki benzerlik seviyesini ölçmek için aralarındaki karşılıklı bilgiyi (mutual information) kullanılmaktadır. MRMR algoritmasında kullanılan karşılıklı bilgi formülü şu şekildedir:

$$I(X, Y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (7)$$

Burada $I(X, Y)$ X ve Y arasındaki karşılıklı bilgiyi temsil etmektedir. $p(x, y)$ ise X ve Y'nin birlikte gözlemlenme

olasılığını ifade etmektedir. $p(x)$ ve $p(y)$ ise sırasıyla X ve Y rastlantı değişkenlerinin olasılık dağılım fonksiyonlarını göstermektedir.

Model Başarımının Değerlendirilmesi

Çalışmada model performansını ölçmek için literatürde genel olarak kullanılan Ortalama Kare Hatası (MSE), Kök Ortalama Kare Hatası (RMSE) ve Pearson korelasyon katsayısı (R) kullanılacaktır.

MSE, her tahminin gerçek değerden farkını almakta ve bunların karelerinin toplamının ortalamasını almaktadır. Denklem (8)'de MSE formülü verilmektedir. Burada x_i gerçek değerleri, y_i ise model tarafından tahmin değerlerini göstermektedir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \quad (8)$$

RMSE ise gerçek değerlerle tahmin edilen değerler arasındaki farkların karelerinin ortalamasının karekökü olarak Denklem (9)'daki gibi hesaplanmaktadır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (9)$$

Pearson korelasyon katsayısı iki değişken arasındaki ilişkinin gücünü ve yönünü ölçen istatistiksel bir ölçüdür. Denklem (10)'daki gibi hesaplanmaktadır. Burada \hat{x}_i ve \hat{y}_i sırasıyla gerçek ve tahmin edilen zaman serisinin ortalama değeri olarak hesaplanmaktadır.

$$R = \frac{\sum_{i=1}^n (x_i - \hat{x}_i)(y_i - \hat{y}_i)}{\sqrt{\sum_{i=1}^n (x_i - \hat{x}_i)^2} \sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)^2}} \quad (10)$$

Bu değer 1 olması pozitif ilişkiyi, -1 olması ise negatif ilişkiyi göstermektedir. 0 ise herhangi bir ilişkinin olmadığını göstermektedir.

Araştırma Sonuçları ve Tartışma

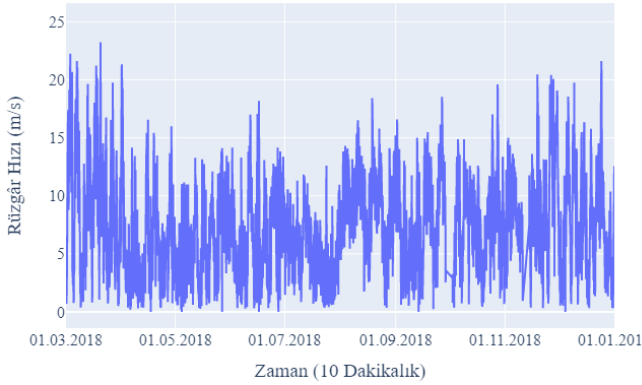
Bu çalışmada Yalova ilinde bulunan rüzgâr türbininden toplanan rüzgâr hızı verileri kullanılarak mum çubuğu gösterimi elde edilmiştir. Daha sonra bu gösterim kullanılarak trend ve osilatör tabanlı göstergeler ile öznelik havuzu oluşturulmuştur. MRMR algoritması ile özneliklerin kalitesi belirlenmiştir. Elde edilen özneliklerden yüksek skor değerine sahip olanlar kullanılarak makine öğrenimi yaklaşımlarından DT ve XGBoost modelleri ile rüzgâr hızının bir adım sonraki değerinin tahmini yapılmıştır. Farklı gösterge değerlerinin etkisi incelenerek tahmin başarımı yüksek bir model elde edilmiştir. Model doğrulama yaklaşımı olarak çapraz doğrulama methodu kullanılmıştır. Hata kriteri olarak MSE, RMSE ve R değerleri kullanılmıştır.

Veri seti 2018 yılını içerecek şekilde 1 yıl süre ile 10 dakikalık aralıklarla toplanan rüzgâr hızı, rüzgâr yönü, teorik güç eğrisi ve üretilen aktif güç değerlerinden oluşmaktadır [26]. Tablo 2'de toplanan verilerden rüzgâr hızının istatistiksel değerleri verilmektedir. Tablodaki

değerler incelendiğinde toplam örnek sayısı 50530, örneklerin ortalamasının 7.56, standart sapma değerinin 4.23, minimum değerinin 0 ve maksimum değerinin 25.21 olduğu görülmektedir. Ayrıca %25'lik, %50'lik ve %75'lik çeyreklikler incelendiğinde sırasıyla 4.20, 7.10 ve 10.30 olduğu görülmektedir. Şekil 5'te rüzgâr hızının zamana göre değişimi çizdirilmiştir.


Tablo 2. Rüzgâr hızının istatistiksel değerleri.

Toplam	Ortalama	Standart Sapma	Minimum	Maksimum
50530	7,56	4,23	0	25,21




Şekil 5. Rüzgâr hızının zamana göre değişimi grafiği

Bu bölgedeki rüzgâr hızının ve yönünün aynı grafikte görselleştirilmiş hali ise Şekil 6'daki gibi rüzgâr gülü grafiği ile verilmiştir. Kuzeydoğu doğu (NE-E) yönünde rüzgâr hızı 13.6 ile 22.6 arasında büyük bir dilim ile en güçlü rüzgarlar buradan esmekte olup, rüzgâr hızı genellikle yüksek ve sık görülmektedir. Kuzeydoğu (N-E) yönünde de benzer şekilde 13.6 ile 22.6 arasında dilimler mevcut olup, güçlü rüzgarlar esmektedir. Güneybatı batı (SW-W) yönünde rüzgâr hızı 9.1 ile 13.6 arasında değişmekte ve doğu ile kuzeydoğu doğuya kıyasla biraz daha az güçlü rüzgarlar esmektedir, ancak yine de önemli miktarda güçlü rüzgâr esmektedir.



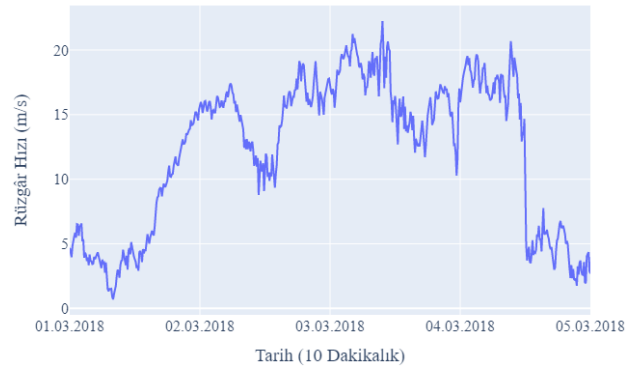
Şekil 6. Rüzgâr gülü grafiği

Rüzgâr hızının ağırlıklı olarak hangi aralıklarda yoğun olduğunu göstermek için ise Şekil 7'deki gibi histogram grafik kullanılmıştır. Rüzgâr hızı 0 ile 25 m/s arasında değişmektedir. En yüksek frekans 6000 civarında olup, bu değer 5-6 m/s aralığında gözlemlenmektedir. Bu durum, rüzgâr hızının en sık bu aralıkta görüldüğünü göstermektedir. Genel olarak, rüzgâr hızının frekansı 0 m/s'den başlayarak hızla artmakta, 5-6 m/s civarında zirveye ulaşmakta ve sonrasında rüzgâr hızı arttıkça frekans azalmaktadır, bu da daha yüksek rüzgâr hızlarının daha nadir olduğunu işaret etmektedir. Grafikte birkaç tepe noktası bulunmakta olup, rüzgâr hızının birden fazla modlu dağılım gösterdiği anlaşılmaktadır. Ayrıca, rüzgâr hızının yüksek değerlerinde (20 m/s ve üstü) frekans oldukça düşüktür, yani bu hızlar nadir olarak gözlemlenmektedir. Bu dağılım, rüzgâr hızının çoğunlukla düşük ve orta hızlarda seyrettiğini, ancak zaman zaman yüksek hızlara da çıkabildiğini göstermektedir.




Şekil 7. Rüzgâr hızının dağılımı grafiği

Şekil 8'de 01.03.2018-05.03.2018 tarihleri arasında çizgi grafik ile gösterim verilmiştir. Şekil 9'da ise yine bu zaman aralığındaki rüzgâr verisine uygulanan dönüşüm neticesinde elde edilen mum çubuğu gösterimi verilmiştir.



Şekil 8. 01.03.2018-05.03.2018 tarihleri arasında rüzgâr hızının zamana göre değişiminin çizgi grafiği

Tablo 3'te Basit Hareketli Ortalama (BHO) ve Eksponansiyel Hareketli Ortalama (EHO) yöntemlerinin MRRM yaklaşımı ile performans karşılaştırması yapılmıştır. EHO yöntemi ile genel olarak BHO yöntemine göre daha yüksek skorlar elde edildiği görülmüştür. Burada özellikler kısa dönemlerde, özellikle EHO(3) ile 1.6258 skoru en yüksek değeri gösterirken, BHO(3) 0.8279 skoru ile BHO yöntemindeki en yüksek değer elde edilmiştir.



Şekil 9. 01.03.2018-05.03.2018 tarihleri arasında rüzgâr hızının zamana göre değişiminin mum çubuğu grafiği

Tablo 4'te RSI yönteminin MRMR yaklaşımı ile elde edilen skor değerleri verilmiştir. RSI skorları dönem uzunluğu arttıkça daha iyi performans gösterdiği görülmektedir. BHO ve özellikle EHO yöntemlerine kıyasla skor değeri olarak daha düşük değer aldığı görülmektedir. En yüksek RSI skoru, RSI(15) ile 0.7366 olarak belirlenmişken, en düşük skor RSI(4) ile 0.2878'dir. Tablo 5'te Stokastik %K ve %D değerlerinin MRMR yaklaşımı ile elde edilen skorları incelendiğinde, en yüksek skor Stokastik %K(15) için 0.8282 iken, Stokastik %D(15) için 0.7086 olarak belirlenmiştir. Stokastik %K ile genellikle %D'ye göre daha yüksek değerler elde edildiği görülmüştür. BHO ve EHO ile karşılaştırıldığında, Stokastik %K'nın en yüksek skoru, BHO(3) ile benzer seviyede olup, EHO'ya göre skor değeri daha düşük kalmıştır.

Tablo 3. Basit hareketli ortalama ve Ekspansiyonel hareketli ortalama göstergelerinin MRMR yöntemine göre elde edilen skor değerleri

Basit Hareketli Ortalama		Ekspansiyonel Hareketli Ortalama	
	Skor		Skor
BHO(3)	0.8279	EHO(3)	1.6258
BHO(4)	0.7350	EHO(15)	0.8367
BHO(7)	0.7343	EHO(5)	0.7689
BHO(5)	0.7096	EHO(4)	0.7678
BHO(15)	0.6938	EHO(7)	0.7330
BHO(6)	0.6662	EHO(6)	0.6908
BHO(11)	0.6142	EHO(10)	0.6708
BHO(8)	0.6114	EHO(8)	0.6272
BHO(9)	0.5617	EHO(12)	0.6114
BHO(14)	0.5549	EHO(9)	0.6069
BHO(10)	0.5401	EHO(11)	0.5512
BHO(12)	0.4991	EHO(14)	0.5430
BHO(13)	0.4886	EHO(13)	0.5048

Tablo 4. RSI göstergelerinin MRMR yöntemine göre elde edilen skor değerleri

RSI	Skor
RSI(15)	0.7366
RSI(11)	0.6694
RSI(13)	0.6235
RSI(3)	0.5916
RSI(14)	0.5859
RSI(9)	0.5535
RSI(12)	0.5355
RSI(10)	0.4619
RSI(7)	0.4240
RSI(8)	0.3910
RSI(6)	0.3481
RSI(5)	0.3270
RSI(4)	0.2878

Tablo 5. Stokastik göstergelerinin MRMR yöntemine göre elde edilen skor değerleri

Stokastik %K	Skor	Stokastik %D	Skor
S-K(15)	0.8282	S-D(15)	0.7086
S-K(3)	0.7294	S-D(8)	0.6103
S-K(7)	0.6487	S-D(13)	0.4954
S-K(11)	0.5492	S-D(14)	0.4220
S-K(5)	0.4947	S-D(3)	0.3953
S-K(14)	0.4449	S-D(12)	0.3793
S-K(13)	0.4005	S-D(9)	0.3676
S-K(6)	0.3760	S-D(11)	0.3477
S-K(9)	0.3750	S-D(6)	0.3385
S-K(12)	0.3586	S-D(10)	0.3230
S-K(4)	0.3486	S-D(4)	0.3036
S-K(10)	0.3346	S-D(7)	0.3018
S-K(8)	0.3209	S-D(5)	0.2788

Tablo 6'da ise Stokastik RSI göstergelerinin MRMR yöntemine göre elde edilen skor değerleri verilmiştir. S-K ve S-D ile karşılaştırıldığında SRSI-K ve SRSI-D skorları oldukça farklı sonuçlar vermektedir. En yüksek skor, SRSI-K(6) ile 1.5358 olup, bu değer Stokastik %K'nın en yüksek skoru olan 0.8282'yi ve diğer yöntemlerin çoğunu (BHO'ya dahil ve EHO'ya yakın) önemli ölçüde aşmaktadır. SRSI-D(15) skoru da 1.4576 ile oldukça yüksektir. Genel olarak, SRSI-K'nın S-K'ya kıyasla en yüksek skoru aldığını göstermektedir. Ayrıca, SRSI-K ve SRSI-D skorlarının, S-K ve S-D ile elde edilen skor değerlerinden daha yüksek olduğu görülmüştür. Aynı zamanda RSI ile de kıyaslandığında skor değerinin yüksek olduğu görülmüştür.


Tablo 6. Stokastik RSI göstergelerinin MRMR yöntemine göre elde edilen skor değerleri

Stokastik RSI %K	Skor	Stokastik RSI %D	Skor
SRSI-K(6)	1.5358	SRSI-D(15)	1.4576
SRSI-K(9)	0.7638	SRSI-D(5)	0.2441
SRSI-K(8)	0.4522	SRSI-D(6)	0.2297
SRSI-K(5)	0.4379	SRSI-D(8)	0.2114
SRSI-K(7)	0.4047	SRSI-D(12)	0.2012
SRSI-K(13)	0.4040	SRSI-D(9)	0.1911
SRSI-K(14)	0.3828	SRSI-D(14)	0.1841
SRSI-K(10)	0.3802	SRSI-D(13)	0.1650
SRSI-K(12)	0.3727	SRSI-D(11)	0.1601
SRSI-K(15)	0.3672	SRSI-D(10)	0.1433
SRSI-K(11)	0.3425	SRSI-D(7)	0.1341
SRSI-K(4)	0.0000	SRSI-D(3)	0.0000
SRSI-K(3)	0.0000	SRSI-D(4)	0.0000

Şekil 10'da farklı teknik göstergelerin (BHO, EHO, Stokastik %K, Stokastik %D, RSI, SRSI %K, SRSI %D) Tablo 3-6'da elde edilen parametre değerlerinin MRMR yaklaşımı ile aldığı skor değerlerinin yüksekten düşüğe doğru sıralanmış üç boyutlu sütun grafiği gösterimi verilmiştir. MRMR yaklaşımı ile 91 adet öznelik skor değerleri için büyükten küçüğe doğru sıralandığında ilk 10 adet öznelik olan EMA(3), SRSI-K(6), SRSI-D(15), EMA(15), K(15), MA(3), EMA(5), EMA(4), SRSI-K(9) ve RSI(15) model eğitimi yapılmıştır. Tablo 7-9'da DT, MRMR-DT, XGBoost, MRMR-XGBoost model başarımlarının MSE, RMSE ve R ölçütlerine göre sunulmuştur. Modelin performans ölçümleri incelendiğinde önerilen MRMR-XGBoost modelinin oldukça yüksek bir doğruluk ve tutarlılık sergilediği görülmüştür. MSE ve RMSE değerlerinin düşük olması, modelin tahminlerinin genel olarak gerçek değerlere çok yakın olduğunu ve hataların tutarlı bir şekilde düşük olduğunu ifade etmektedir. R değerinin yüksek olması ise, tahmin edilen değerler ile gerçek değerler arasında güçlü bir pozitif korelasyon olduğunu ortaya çıkartmaktadır. Standart sapmaların düşük olması, bu performans ölçümlerinin tutarlılığını doğrulamaktadır.

Tablo 7-9 ve Şekil 11-13 birlikte incelendiğinde, DT modelinin ortalama MSE, RMSE ve R değerlerinin sırasıyla 0.008390, 0.091594 ve 0.717523 olduğu görülmektedir. Bu sonuçlar, DT modelinin diğer modellerle kıyaslandığında nispeten daha yüksek hata içerdiğini göstermektedir. MRMR-DT modelinin ortalama MSE, RMSE ve R değerleri sırasıyla 0.008223, 0.090677 ve 0.723312'dir. MRMR yaklaşımı kullanılarak elde edilen bu model, daha düşük MSE ve RMSE değerleri ile daha yüksek bir R değeri sunduğundan, bu modelin daha iyi sonuç verdiği söylenebilir. XGBoost modelinin ortalama MSE, RMSE ve R değerleri sırasıyla 0.004664, 0.068289 ve 0.842987'dir. Bu model, diğer iki modelle kıyaslandığında daha düşük hata ve daha yüksek performans sergilemektedir. MRMR yaklaşımı ile iyileştirilmiş XGBoost modelinin ortalama MSE değeri 0.004157, ortalama RMSE değeri 0.064473 ve ortalama R değeri 0.860123'tür. Bu sonuçlar, MRMR-

XGBoost modelinin en düşük MSE ve RMSE ile en yüksek R değerine sahip olduğunu ve bu nedenle diğer modellere göre en iyi performansı gösterdiğini ortaya koymaktadır. Bu model için rüzgâr hızının gerçek değer ile tahmin edilen değer üst üste çizdirilmiş hali Şekil 14'te verilmiştir. Elde edilen veriler doğrultusunda modelin genel olarak güvenilir ve hassas tahminler yaptığı ortaya çıkartılmıştır.



Şekil 10. Skor değerlerinin gösterge tiplerine göre büyükten küçüğe sıralanmış halinin üç boyutlu bar grafik gösterimi

Tablo 7. Model başarımlarının MSE ölçütüne göre değerlendirilmesi


Modeller	Ortalama ± Standart Sapma
DT	0.008390 ± 0.000147
MRMR-DT	0.008223 ± 0.000099
XGBoost	0.004664 ± 0.000037
MRMR-XGBoost	0.004157 ± 0.000013

Tablo 8. Model başarımlarının RMSE ölçütüne göre değerlendirilmesi


Modeller	Ortalama ± Standart Sapma
DT	0.091594 ± 0.000805
MRMR-DT	0.090677 ± 0.000547
XGBoost	0.068289 ± 0.000273
MRMR-XGBoost	0.064473 ± 0.000104

Tablo 9. Model başarımlarının R ölçütüne göre değerlendirilmesi


Modeller	Ortalama ± Standart Sapma
DT	0.717523 ± 0.004962
MRMR-DT	0.723312 ± 0.003335
XGBoost	0.842987 ± 0.001256
MRMR-XGBoost	0.860123 ± 0.000451




Şekil 11. Model başarımlarının MSE ölçütüne göre kutu bilyık grafiđi ile gösterimi



Şekil 12. Model başarımlarının RMSE ölçütüne göre kutu bilyık grafiđi ile gösterimi



Şekil 13. Model başarımlarının R ölçütüne göre kutu bilyık grafiđi ile gösterimi



Şekil 14. Rüzgâr hızının gerçek değeri ile tahmin edilen değerin üst üste çizdirimi

Tablo 10 incelendiđinde rüzgâr hızı tahmini için farklı yöntemlerin karşılaştırılması, önerilen MRMR-XGBoost modelinin üstünlüğünü açıkça ortaya koymaktadır. [19]'daki çalışmada Çoklu Regresyon (RMSE: 0.8700, R: 0.8050) temel bir yöntem olarak değerlendirilmiş ancak yüksek hata oranı nedeniyle sınırlı bir doğruluk sunmuştur. [20]'deki çalışmada BOA+VMD+PCA+RF yöntemi (RMSE: 0.3736, R: 0.8200) hata oranını azaltarak performansı iyileştirmiştir. [21]'de ANN-BR modeli (MSE: 0.3023, RMSE: 0.5498, R: 0.8353) daha iyi bir korelasyon katsayısı sunarken hata oranı hala yüksektir. Önerilen MRMR-XGBoost yöntemi ise en düşük hata oranı (MSE: 0.0041, RMSE: 0.0644) ve en yüksek doğruluk (R: 0.8601) ile diğer modelleri geride bırakmıştır. Bu sonuçlar, önerilen yöntemin, rüzgâr hızı tahmininde doğruluk ve güvenilirlik açısından literatürdeki mevcut yöntemlere kıyasla açık bir üstünlük sağladığını göstermektedir.

Tablo 10. Rüzgâr hızı tahmininde literatürdeki farklı modeller ile önerilen yöntemin performans karşılaştırması

Modeller	MSE	RMSE	R
Çoklu Regresyon [19]	-	0.8700	0,8050
BOA+VMD+PCA+RF [20]	-	0.3736	0,8200
ANN-BR [21]	0,3023	0,5498	0,8353
MRMR-XGBoost (Önerilen Yöntem)	0.0041	0.0644	0.8601

Sonuç

Bu çalışmada, Yalova ilinde bulunan rüzgâr türbininden elde edilmiş rüzgâr hızı verisi üzerinde mum çubuđu gösterimi uygulanarak 10 dakikalık veriler 1 saatlik veri haline getirilmiştir. Trend ve osilatör tabanlı finansal sinyal işleme yaklaşımları ile 91 adet öznitelik çıkartılmıştır. Trend tabanlı BHO ve EHO ile toplam 26 adet öznitelik çıkartılmıştır. Osilatör tabanlı RSI, stokastik ve stokastik RSI ile toplam 65 adet öznitelik çıkartılmıştır. Çıkartılan öznitelikler MRMR yaklaşımı ile değerlendirilmiştir. Model karmaşıklığını artırmamak için skor değeri yüksek olanlardan 10 adet öznitelik model girişine uygulanmıştır. Bir adım sonraki rüzgâr hızının tahmini için model doğrulama yaklaşımı 10 katlı çapraz doğrulama yapılarak ve 20 kere tekrarlı eğitim ve test süreci adımları uygulanarak zaman serisi tahmini işlemi tamamlanmıştır. Rüzgâr hızı verisine mum çubuđu gösterimi uygulayarak finansal sinyal işleme yaklaşımı uygulanabilir hale getirilmiştir. Özellikle osilatör tabanlı göstergeler rahatlıkla

uygulanmıştır. MRMR yaklaşımı ile EHO'ya bağlı özellikler BHO'ya göre daha çok seçildiği görülmüştür. Ayrıca, RSI ve Stokastik osilatörlere dayalı özniteliklerin yanı sıra, Stokastik RSI'dan daha yüksek skor değerleri elde edilerek ve ilk 10 öznitelik içinde diğer öznitelik gruplarına göre daha fazla seçilerek, daha fazla çeşitlilik kattığı anlaşılmıştır. MRMR yaklaşımının uygulanmadığı 91 öznitelige göre eğitilen DT ve XGBoost modellerinin MSE, RMSE ve R ölçütleri kullanılarak yapılan performans kıyaslamalarında, XGBoost modelinin DT modeline göre daha yüksek bir performans sergilediği görülmüştür. 91 adet öznitelik yerine 10 adet özniteliğin MRMR yaklaşımı ile temsil edildiği MRMR-DT ve MRMR-XGBoost modellerinin performansı incelendiğinde DT ve XGBoost modellerine göre model karmaşıklığının azaltıldığı ve performansın yüksek olduğu düşük MSE, RMSE ve yüksek R değerleri ile ortaya çıkartılmıştır. Önerilen yöntemin MSE (0.0041), RMSE (0.0644) ve korelasyon katsayısı ($R = 0.8601$) değerleri, literatürdeki diğer yöntemlerden (Çoklu Regresyon, BOA+VMD+PCA+RF ve ANN-BR gibi) anlamlı derecede daha iyi sonuçlar vermiştir. Bu sonuçlar, önerilen yöntemin yalnızca rüzgâr hızı tahmini doğruluğunu artırmakla kalmadığını, aynı zamanda hata oranını ciddi ölçüde düşürerek daha güvenilir bir tahmin aracı sunduğunu göstermektedir. Özetle, bu çalışmanın özgün katkısı, rüzgâr hızı tahmini için MRMR-XGBoost yönteminin birleştirilmiş bir model olarak hem düşük hata oranı hem de yüksek korelasyon katsayısı ile diğer yöntemleri geride bırakmasıdır. Literatürdeki mevcut yöntemlere kıyasla, önerilen modelin, özellikle tahmin doğruluğu gerektiren kritik uygulamalarda yeni bir standart belirlediği ve mevcut bilgi birikimine güçlü bir katkı sağladığı görülmüştür. Bu bağlamda, çalışma, rüzgâr hızı tahmininde daha yüksek doğruluk ve sağlamlık elde etmek için literatüre destekleyici ve yenilikçi bir yaklaşım sunmaktadır. Farklı model doğrulama ve optimizasyon yaklaşımlarının yanı sıra çeşitli modelleme tekniklerinin ve gerçek zamanlı uygulama imkanlarının araştırılması, gelecekteki çalışmalar için oldukça önemli olabilir. Bunun yanında tahmin modelinin genelleştirme kapasitesini artırmak adına tek bir rüzgâr santralinden alınan veriler yerine, farklı coğrafi bölgelerdeki birden fazla rüzgâr santralinden toplanan verilerin kullanılması düşünülebilir. Bu yaklaşım, modelin farklı rüzgâr rejimlerini ve çevresel koşulları daha iyi temsil etmesine olanak tanıyarak tahmin doğruluğunu artırabilir. Ayrıca, çeşitli santrallerden elde edilen verilerle mekânsal ve zamansal korelasyonların incelenmesi, model performansını ve güvenilirliğini daha da geliştirebilir.

Yazar katkı beyanı

Gerçekleştirilen çalışmada Seçkin Karasu fikrin oluşması, tasarım yapılması ve literatür taraması, gerekli kodların oluşturulması, elde edilen sonuçların değerlendirilmesi, sonuçların incelenmesi, yazım denetimi ve içerik açısından makalenin kontrol edilmesi başlıklarından sorumludur.

Etik kurul onayı ve çıkar çatışması beyanı

"Hazırlanan makalede etik kurul izni alınmasına gerek yoktur". "Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır".

Kaynakça

- [1] Behera, S., Sahoo, S., & Pati, B. B. (2015). A review on optimization algorithms and application to wind energy integration to grid. *Renewable and Sustainable Energy Reviews*, 48, 214-227.
- [2] Shafiullah, G. M., Oo, A. M., Ali, A. S., & Wolfs, P. (2013). Potential challenges of integrating large-scale wind energy into the power grid—A review. *Renewable and sustainable energy reviews*, 20, 306-321.
- [3] MansourLakouraj, M., Shahabi, M., Shafie-khah, M., & Catalão, J. P. (2022). Optimal market-based operation of microgrid with the integration of wind turbines, energy storage system and demand response resources. *Energy*, 239, 122156.
- [4] Msigwa, G., Ighalo, J. O., & Yap, P. S. (2022). Considerations on environmental, economic, and energy impacts of wind energy generation: Projections towards sustainability initiatives. *Science of the Total Environment*, 157755.
- [5] Lin, Z., Liu, X., & Collu, M. (2020). Wind power prediction based on high-frequency SCADA data along with isolation forest and deep learning neural networks. *International Journal of Electrical Power & Energy Systems*, 118, 105835.
- [6] Suo, L., Peng, T., Song, S., Zhang, C., Wang, Y., Fu, Y., & Nazir, M. S. (2023). Wind speed prediction by a swarm intelligence based deep learning model via signal decomposition and parameter optimization using improved chimp optimization algorithm. *Energy*, 276, 127526.
- [7] Gong, Y., Jiang, Q., & Baldick, R. (2015). Ramp event forecast based wind power ramp control with energy storage system. *IEEE Transactions on Power Systems*, 31(3), 1831-1844.
- [8] Neshat, M., Nezhad, M. M., Abbasnejad, E., Mirjalili, S., Groppi, D., Heydari, A., ... & Wagner, M. (2021). Wind turbine power output prediction using a new hybrid neuro-evolutionary method. *Energy*, 229, 120617.
- [9] Oh, S. Y., Joung, C., Lee, S., Shim, Y. B., Lee, D., Cho, G. E., ... & Park, Y. B. (2024). Condition-based maintenance of wind turbine structures: A state-of-the-art review. *Renewable and Sustainable Energy Reviews*, 204, 114799.
- [10] Kisvari, A., Lin, Z., & Liu, X. (2021). Wind power forecasting—A data-driven method along with gated recurrent neural network. *Renewable Energy*, 163, 1895-1909.
- [11] Zheng, Y., Ge, Y., Muhsen, S., Wang, S., Elkamchouchi, D. H., Ali, E., & Ali, H. E. (2023). New ridge regression, artificial neural networks and support vector machine for wind speed prediction. *Advances in Engineering Software*, 179, 103426.
- [12] Yang, Q., Huang, G., Li, T., Xu, Y., & Pan, J. (2023). A novel short-term wind speed prediction method based on hybrid statistical-artificial intelligence model with empirical wavelet transform and hyperparameter optimization. *Journal of Wind Engineering and Industrial Aerodynamics*, 240, 105499.

- [13] Li, Y., Shen, X., & Zhou, C. (2023). Dynamic multi-turbines spatiotemporal correlation model enabled digital twin technology for real-time wind speed prediction. *Renewable Energy*, 203, 841-853.
- [14] Malakouti, S. M. (2023). Improving the prediction of wind speed and power production of SCADA system with ensemble method and 10-fold cross-validation. *Case Studies in Chemical and Environmental Engineering*, 8, 100351.
- [15] Zhang, Z., Wang, J., Wei, D., Luo, T., & Xia, Y. (2023). A novel ensemble system for short-term wind speed forecasting based on Two-stage Attention-Based Recurrent Neural Network. *Renewable Energy*, 204, 11-23.
- [16] Wang, X., Wang, J., Niu, X., & Wu, C. (2024). Novel wind-speed prediction system based on dimensionality reduction and nonlinear weighting strategy for point-interval prediction. *Expert Systems with Applications*, 241, 122477.
- [17] Zhu, A., Zhao, Q., Yang, T., Zhou, L., & Zeng, B. (2024). Wind speed prediction and reconstruction based on improved grey wolf optimization algorithm and deep learning networks. *Computers and Electrical Engineering*, 114, 109074.
- [18] Wang, M., & Tian, Z. (2024). Ultra-short-term wind speed prediction based on empirical wavelet transform and combined model. *Earth Science Informatics*, 17(1), 539-560.
- [19] Wang, J. W., Yang, H. J., & Kim, J. J. (2020). Wind speed estimation in urban areas based on the relationships between background wind speeds and morphological parameters. *Journal of Wind Engineering and Industrial Aerodynamics*, 205, 104324.
- [20] Zhou, S., Gao, C. Y., Duan, Z., Xi, X., & Li, Y. (2023). A robust error correction method for numerical weather prediction wind speed based on Bayesian optimization, variational mode decomposition, principal component analysis, and random forest: VMD-PCA-RF (version 1.0. 0). *Geoscientific Model Development*, 16(21), 6247-6266.
- [21] Malik, P., Gehlot, A., Malik, P. K., & Singh, R. (2023, April). Global horizontal irradiance and wind speed prediction using ANN: Comprehensive Study. In *2023 IEEE Devices for Integrated Circuit (DevIC)* (pp. 190-193). IEEE.
- [22] Li, Y., Feng, Z., & Feng, L. (2015). Using candlestick charts to predict adolescent stress trend on micro-blog. *Procedia Computer Science*, 63, 221-228.
- [23] Xu, R., Liu, X., Wan, H., Pan, X., & Li, J. (2021). A Feature Extraction and Classification Method to Forecast the PM_{2.5} Variation Trend Using Candlestick and Visual Geometry Group Model. *Atmosphere*, 12(5), 570.
- [24] Hsu, Y. C. (2020). Using machine learning and candlestick patterns to predict the outcomes of American football games. *Applied Sciences*, 10(13), 4484.
- [25] Guilizzoni, M., & Maldonado Eizaguirre, P. (2022). Trend lines and Japanese candlesticks applied to the forecasting of wind speed data series. *Forecasting*, 4(1), 165-181.
- [26] Erisen, B. Wind Turbine Scada Dataset. 2018. Available online: <http://www.kaggle.com/berkerisen/wind-turbine-scada-dataset> (accessed on 10 May 2024).
- [27] Chande, T. S., & Kroll, S. (1994). The new technical trader: boost your profit by plugging into the latest indicators.
- [28] Johnston, F. R., Boyland, J. E., Meadows, M., & Shale, E. (1999). Some properties of a simple moving average when applied to forecasting a time series. *Journal of the Operational Research Society*, 50(12), 1267-1271.
- [29] Klinker, F. (2011). Exponential moving average versus moving exponential average. *Mathematische Semesterberichte*, 58, 97-107.
- [30] Lane, G. C. (1984). Lane's stochastics. *Technical Analysis of Stocks & Commodities*, 2(3), 87-90.
- [31] Gumparthi, S. (2017). Relative strength index for developing effective trading strategies in constructing optimal portfolio. *International Journal of Applied Engineering Research*, 12(19), 8926-8936.
- [32] Chande, T. S., & Kroll, S. (1994). The new technical trader: boost your profit by plugging into the latest indicators.
- [33] De Ville, B. (2013). Decision trees. *Wiley Interdisciplinary Reviews: Computational Statistics*, 5(6), 448-455.
- [34] Yeşilyurt, Sefa, & Dalkılıç, Hüseyin. (2021). Xgboost ve gradient boost machine ile günlük nehir akımı tahmini. In *3rd International Symposium of III Engineering Applications on Civil Engineering and Earth Sciences*, Karabük, Türkiye.
- [35] Gülgezen, G., Çataltepe, Z., & Yu, L. MRMR Algoritması Kullanılarak Kararlı Öznitelik Seçimi Stable Feature Selection Using MRMR Algorithm.