

Araştırma Makalesi/Research Article

## Ayrık dalgacık dönüşümü ve Xgboost ile rüzgâr gücü tahmini

Mehmet Ali YELGEÇ<sup>1</sup>, Okan BİNGÖL<sup>2</sup>\*

<sup>1,2</sup> Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 32260, Isparta, Türkiye

### Anahtar Kelimeler

Rüzgâr gücü  
Rüzgâr gücü tahmini  
Ayrık dalgacık dönüşümü  
Xgboost

### Makale geçmişi:

Geliş Tarihi: 20.06.2022

Kabul Tarihi: 19.09.2022

**Öz:** Rüzgâr gücü tahmini, sistem işletmecisi ve santraller için gerilim ve frekans kontrolü, yük kontrolü, ünite planlaması, bakım planlaması ve elektrik marketi hareketleri için gereklidir. Süreksiz bir kaynak olan rüzgârdan elde edilen güce ait zaman serisi durağan bir yapıda değildir. Rüzgâr gücü zaman serisi çeşitli sebeplerden dolayı aykırı veriler barındırmaktadır. Bu durum tahmin modellerinde başarıyı düşürmektedir. Bu çalışmada rüzgâr gücü tahmin modelinin en iyi sonucu vermesi için rüzgâr gücü verisi ayrık dalgacık dönüşümü ile dönüştürülmüştür. Dönüştürülen veriler, karar ağacı tabanlı, gradyan arttırmaya dayanan bir algoritma olan Xgboost ile eğitilmiştir. Test için ayrılan veriler tahmin edilmiştir. Ayrık dalgacık dönüşümü-Xgboost modeli her mevsimden seçilen dört ay için ayrı ayrı tasarlanmış, ayrık dalgacık dönüşümü olmadan sadece Xgboost ile tasarlanan model ile MAE, RMSE ve R<sup>2</sup> hata metrikleriyle karşılaştırılmıştır. Ayrık dalgacık dönüşümü-Xgboost ile tasarlanan modeller daha başarılı sonuçlar vermiştir.

### Atf için/To Cite:

Yelgeç M.A. Bingöl O. Ayrık dalgacık dönüşümü ve Xgboost ile rüzgâr gücü tahmini. Ulusallararası Teknolojik Bilimler Dergisi, 14(2), 58-65. 2022.

## Wind power forecasting with discrete wavelet transform and Xgboost

### Keywords

Wind power  
Wind power forecasting  
Discrete wavelet transform  
Xgboost

### Article history:

Received: 20.06.2022

Accepted: 19.09.2022

**Abstract:** Wind power forecasting is necessary for system operator and wind farm for voltage and frequency control, load dispatch, unit commitment, maintenance planning and electricity market actions. Wind power time series, which is a intermittent source, is not stationary and contains various outliers. This situation reduces the success of forecasting models. In order for the wind power forecasting model to give the best results, in this paper the wind power data was transformed with discrete wavelet transform. Transformed data were trained and forecasted with Xgboost, a decision tree based, gradient boosting algorithm. Proposed model were designed separately for a selected month from each season. These models were compared with MAE, RMSE, R<sup>2</sup> error metrics by the models designed with Xgboost without discrete wavelet transform. Discrete wavelet and Xgboost model gave more successful results than Xgboost model.

### 1. Giriş

Gelişmekte olan ülkeler arasında yer alan ülkemizde enerjiye olan ihtiyaç giderek artmaktadır. Bu ihtiyaca çözüm olması için artan elektrik santrali kurulu gücü çeşitli kaynaklardan oluşmaktadır. 2022 yılı Mart itibariyle 100 000 MW'ı aşan kurulu gücün 10861 MW'ı rüzgâr santrallerinden oluşmaktadır [1]. Süreksiz ve dalgalı bir yapıya sahip olan rüzgâr enerjisi güç sistemi için stabil olmayan bir durum oluşturmaktadır. Rüzgâr gücü tahmini ile bu belirsizlik

azaltılarak rüzgâr gücünün güç sistemine entegrasyonu sağlanmaktadır. Rüzgâr santrallerinin üreteceği güç tahminini yapmak enerjide arz talep dengesini sağlamak için önemlidir ve doğru tahmin yapmak bu dengeyi sağlamak için gerekli olan rezerv gücü azaltmaktadır [2]. Rüzgâr gücü üretimi tahmini, santral ve sistem işletmecisi için üretim ve iletim bakım planı, sistem işletmesi için gerekli rezerv güç belirlenmesi, ünite programlaması, ekonomik dağıtım, enerji depolama optimizasyonu ve enerji ticareti gibi alanlarda kullanılmaktadır [3]. Kullanım amacına göre

\* İlgili yazar/Corresponding author: okanbingol@isparta.edu.tr

rüzgâr gücü tahmini çok kısa, kısa, orta ve uzun süreli olarak yapılmaktadır.

Çok kısa süreli tahminler, şebeke dengesi işlemleri ve gerilim kontrolü için saniyelerden 30 dakikaya kadar zaman ufunda yapılır, kısa süreli tahminler, yük dağıtımı, yük atma ve alma, rezerv kararı, operasyonel güvenlik ve gün öncesi piyasa hareketleri, generator açma-kapama kararı için 30 dakikadan 1 güne kadar zaman ufunda yapılır, orta süreli tahminler ünite programlaması için bir günden 1 aya kadar zaman ufunda yapılır, uzun süreli tahminler bakım planlaması, rüzgâr santrali dizaynı, market analizi için birkaç aylık zaman ufunda yapılmaktadır [4].

Rüzgâr gücü tahmin yöntemleri fiziksel, istatistiksel ve hibrit olarak üçe ayrılmaktadır. Fiziksel yöntemler, havanın rüzgâr hızı, rüzgâr yönü, basınç, sıcaklık, nem, arazi yapısı gibi meteorolojik verileri kullanılarak yapılmaktadır [5]. Nümerik değerlerle rüzgâr tahmini yaparak rüzgâr karakteristiği belirlenerek potansiyel rüzgâr santralleri için alan belirlenmesi [6], geniş ölçekli hava tahmini modelinden verileri sağlayan fiziksel yöntemle rüzgâr gücü tahmini [7], rüzgâr santralinin geçmiş nümerik hava verileriyle kümeleme algoritmasıyla rüzgâr gücü tahmini [8] fiziksel yöntemle yapılan çalışmalardır. İstatistiksel yöntemler, zaman serisi ve yapay sinir ağları modeli olmak üzere ikiye ayrılır. Otoregresif hareketli ortalama [9], otoregresif bütünleşik hareketli ortalama [10], üstel düzleştirme [11] yöntemleri ile zaman serisi modelleri ile rüzgâr gücü tahmini yapılmıştır. Yapay sinir ağları ile rüzgâr gücü tahmin çalışmaları yapılmıştır [12], [13], [14], [15]. Farklı yöntemler birlikte kullanılarak hibrit rüzgâr gücü tahmin modelleri yapılmaktadır. Genetik algoritma ve uzun kısa süreli bellekle rüzgâr gücü tahmini [16], deneysel mod ayrıştırması ve yapay sinir ağlarıyla rüzgâr gücü tahmini [17], evrişimli sinir ağları ve radyal tabanlı yapay sinir ağları ile rüzgâr gücü tahmini [18] gibi farklı hibrit modeller tasarlanarak rüzgâr gücü tahmini çalışmaları yapılmıştır.

Süresiz bir yapıya sahip olan rüzgâr gücünün tahmin edilmesi iletim sistemi operatörü, santral işletmesi ve elektrik marketi için gereklidir. Rüzgâr türbinini rüzgârdan enerji üretebilmesi için rüzgâr hızının türbin yapısına göre değişen devreye girme ve devreden çıkma hızları arasında olmalıdır [19]. Rüzgâr hızının bu hızlar arasında olmasına rağmen veri hataları veya hava şartlarının ani değişimi gibi nedenlerden dolayı enerji üretimi gerçekleşmez ve bu durum rüzgâr gücü verisinde aykırı verilere neden olur. Aykırı veriler rüzgâr gücü tahmin algoritmalarının başarısını düşürmektedir. Bu çalışmada bu verilerin etkisini azaltmak için rüzgâr gücü verisi ayırık dalgacık dönüşümü ile ayrıştırılmıştır.

Daha sonra hız ve performans için tasarlanan makine öğrenmesi algoritması ekstrem gradyan artırma (Xgboost) ile her mevsimden seçilen bir ay için eğitilmiş, seçilen hata metrikleriyle test için ayrılan verilerle önerilen modelin başarısı ölçülmüştür. Literatürde genellikle ayrı ayrı ve farklı modellerle kullanılan ayırık dalgacık dönüşümü ve Xgboost algoritmasıyla hibrit bir model tasarlanarak rüzgâr gücü tahmininde başarılı sonuçlar verdiği gösterilmiştir.

Rüzgârdan elektrik enerjisi elde edilmesi için kullanılan ifadeler verilmiş, çalışma kapsamında kullanılan ayırık dalgacık dönüşümü ve ekstrem gradyan artırma (Xgboost) algoritması açıklanmıştır. Rüzgâr santralinin türbin anemometresinden elde edilen rüzgâr gücü verisiyle ayırık dalgacık dönüşümü-Xgboost modeli tasarlanıp seçilen aylara uygulanmıştır.

## 2. Rüzgâr dan Elektrik Enerjisi Elde Edilmesi

Rüzgâr türbinlerinin bıçakları vasıtasıyla hareket halindeki havanın kinetik enerjisi kullanılarak elektrik enerjisi elde edilir. Hareket halindeki hava kütlesi,  $p$  hava yoğunluğu,  $x$  kalınlığında,  $A$  kesitine sahip yüzeye etki etmesiyle Denklem 1'deki gibi hesaplanır.

$$m = pAx \quad (1)$$

Türbindeki hava kütlesinin hızı, kayıplar ihmal edilerek hava kütlesinin türbin bıçaklarına çarpmadan önceki ve çarptıktan sonraki hızlarının ortalaması olarak kabul edilirse rüzgârdan elde edilen enerji Betz Kanunu olarak da bilinen Denklem 2 ile hesaplanır [20].

$$P = 0.593 \frac{1}{2} pAV^3 \quad (2)$$

Bu denklemde  $p$  hava yoğunluğunu,  $A$  rüzgârın etki ettiği kesit alanını,  $V$  ise hava kütlesinin türbin bıçağına çarpmadan önceki hızını göstermektedir. Betz kanununa göre rotor bıçaklarına çarpan hava kütlesinin %59'u enerjiyi çevrilebilse de pratikte bu verim çok daha düşüktür. Bu kayıpların tümü  $C_p$  adlı bir katsayı ile ifade edilerek Denklem 2, Denklem 3 şeklinde yazılabilir.

$$P = C_p \frac{1}{2} pAV^3 \quad (3)$$

## 3. Ayrık Dalgacık Dönüşümü

Dalgacık dönüşümü dalgacık denilen fonksiyonlar yardımıyla zaman serilerini ayrıştırmada kullanılır. Ayrıştırmanın amacı verinin boyutunu küçültmek ve gürültüyü azaltmaktır. Zaman serileri dalgacık dönüşümü vasıtasıyla farklı boyut ve frekansta

bileşenlere ayrılır [21]. Sürekli dalgacık dönüşümü zaman ölçekli örnekleme yapar ancak farklı frekanslarda filtreleme yapan ayrık dalgacık dönüşümü daha etkili bir kullanıma sahiptir.

Sürekli dalgacık dönüşümü,  $W(a,b)$  katsayısı orijinal sinyal ( $f(x)$ ) ile ayrıştırılmış ana dalgacık uyumunu gösterecek şekilde,  $\phi(x)$  ana dalgacı gösterirken Denklem 4'te gösterilmiştir. Ölçek parametresi  $a$  dalgacık genişliğini kontrol ederken  $b$  parametresi merkezi belirler.

$$W(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(x) \phi\left(\frac{x-b}{a}\right) dx \quad (4)$$

Sürekli dalgacık dönüşümü, ana dalgacı sürekli ölçeklendirirken gereksiz bilgiler de oluşturur bu durumun önüne geçmek için sürekli ölçeklendirmek yerine belirli bir ölçek ve pozisyon kullanılarak ayrık dalgacık dönüşümü olarak bilinen daha etkili yöntem kullanılabilir. Ayrık dalgacık dönüşümü genellikle ikinin kuvveti temel alınarak kullanılır. Bu durum Denklem 5'te gösterilmiştir [22].

$$W(m,n) = 2^{-(m/2)} \sum_{t=0}^{T-1} f(t) \phi\left(\frac{t-n.2^m}{2^m}\right) \quad (5)$$

Rüzgâr gücü üretimi, rüzgâr hızı, rüzgâr yönü, hava yoğunluğu, hava basıncı, türbin kayıpları gibi birçok doğal faktörlerden etkilenir ve süresiz ve durağan olmayan bir zaman serisi oluşur. Bu zaman serisi farklı frekanslarda bileşenler içerir. Bunlar düşük frekanslı bileşenler ve yüksek frekanslı bileşenlerdir [23]. Zaman serisi düşük ve yüksek frekans filtresinden geçerek yaklaşım (A) ve ayrıtma (D) katsayıları oluşur. Yaklaşım katsayısı yüksek ölçek ve düşük frekans, ayrıtma katsayısı ise düşük ölçek yüksek frekanslı bileşenlerdir. Genel kanı düşük frekanslı yaklaşım verisi orijinal veriye benzer bir seriyi ifade ederken, yüksek frekans ayrıtma verisi küçük değişikliklerle orijinal veriyi temsil eder ve her ikisi de önemlidir [24].

#### 4. Xgboost

Xgboost denetimli öğrenme problemleri için verilerin eğitim ve test için ayrılarak kullanılan bir algoritmadır. Xgboost gradyan arttırmaya dayanır, etkili ve ölçeklenebilirdir [25]. Karar ağacı tabanlı algoritmalar optimize edilerek geliştirilmiştir. Temelindeki fikir kayıp fonksiyonunu olabildiğince azaltarak daha iyi bir karar ağacı oluşturmaktır. Böylece diğer alternatiflerine göre daha etkili ve çözüme daha hızlı ulaşır [26].

Xgboost daha iyi bir karar ağacı oluşturarak amaç fonksiyonunu minimize etmeyi amaçlar. Xgboost çalışma prensibi Denklem 6 ve 7'de gösterilmiştir.  $L(\theta)$   $\hat{y}_i$  ile  $y_i$  değerleri arasındaki kayıp fonksiyonu,  $\Omega(\theta)$

düzenleme terimi,  $\gamma$  öğrenme katsayısı,  $T$  ağaçtaki yaprak sayısı,  $\lambda$  düzenleme katsayısı,  $w$  ise yaprakların ağırlıklarını ifade etmektedir.

$$F_{amac} = L(\theta) + \Omega(\theta) \quad (6)$$

$$L(\theta) = l(\hat{y}_i, y_i), \quad \Omega(\theta) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (7)$$

#### 4. Rüzgâr Tahmini Uygulaması

Bu çalışmada Türkiye'nin güneybatısında bulunan bir rüzgâr santraline ait 1 yıllık 10 dakikalık çözünürlükteki türbin anemometre verileri kullanılmıştır. Her mevsimden bir ay seçilerek hepsi için ayrı ayrı tahminler yapılmıştır. Verilerin ilk %80'i modelin eğitimi için kullanılmış kalan kısmı modelin testi için kullanılmıştır.


Test için ayrılan veriler MAE (Mean absolute error), RMSE (Root mean squared error) ve  $R^2$  (Coefficient of determination) hata metrikleriyle ölçülmüştür. Denklem 8 MAE, Denklem 9 RMSE, Denklem 10 ise  $R^2$  metriklerinin çalışma prensiplerini göstermektedir.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}| \quad (8)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y})^2} \quad (9)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2} \quad (10)$$

Süresiz bir kaynak olan rüzgârdan elde edilen gücün zaman serisi durağan değildir ve birçok aykırı veriden oluşmaktadır. Rüzgâr türbinleri güç üretimini belli rüzgâr hızları arasında yapmaktadır. Güç üretilen en düşük hıza devreye girme hızı, güvenlik için sınırlandırılan üretimin gerçekleştirildiği maksimum hıza devreden çıkma hızı denir. Devreye girme ve devreden çıkma hızları arasında türbinin güç üretmesi beklenirken çeşitli etkenlerden dolayı verilerde bu hızlar dışında da üretim gerçekleştiği görülmektedir. Bu nedenden dolayı rüzgâr gücü verisini ayrık dalgacık dönüşümü ile gürültüden ayırmak tahmin için daha doğru sonuçlar verecektir. Şekil 1'de önerilen modelin yapısı gösterilmiştir.



Şekil 1. Ayrık dalgacık dönüşümü-Xgboost modeli yapısı


Rüzgâr gücü verisi, ayrık dalgacık dönüşümü ile yaklaşım ve ayrıntı dizilerine ayrılmış, bu verilerin eğitim için ayrılan ilk %80'lik kısmı ile model, Xgboost algoritması ile Tablo 1'de verilen hiperparametrelere göre t-6, t-5, t-4, t-3, t-2, t-1 verileriyle t zaman adımını tahmin edecek şekilde eğitilmiştir. Daha sonra her bir dizi eski haline dönüştürülüp test için ayrılan verinin %20'lik kısmıyla seçilen hata metrikleri vasıtasıyla karşılaştırılmıştır. Önerilen bu model yine farklı hiperparametreler denenerek en iyi sonucu verdiği görülen Tablo 1'deki hiperparametrelerle tasarlanmış ancak dalgacık dönüşümü olmadan direkt Xgboost algoritmasıyla tasarlanan modelle karşılaştırılmıştır.

Tablo 1. Xgboost için seçilen hiperparametreler

Hiperparametre	Değer
n_estimators	1000
learning_rate	0.01
max_depth	4
min_child_weight	3
subsample	0.5


Kış mevsimi için seçilen Ocak ayı rüzgâr gücü verisi ve ayrık dalgacık dönüşümü sonrası oluşan yaklaşım ve ayrıntı katsayılarının grafikleri Şekil 2'de

görülmektedir. 10 dakikalık çözünürlükteki bu veri cA ve cD dizilerine ayrılmış ve bu diziler eğitim için belirlenen oranla Xgboost ile eğitilmiştir. Sonraki aşama olarak test için ayrılan veriler tahmin edilmiş ve rüzgâr gücü verisi eski haline döndürülerek orijinal verile karşılaştırılmıştır.




Şekil 2. Ocak rüzgâr gücü verisi


Şekil 3'te ayrık dalgacık dönüşümü ve Xgboost algoritmasıyla tasarlanan modelin test için ayrılan verilerin tahmini ve gerçek değerleri karşılaştırılırken, Şekil 4'te rüzgâr verisine herhangi bir işlem uygulanmadan direkt Xgboost ile eğitilerek tahmin ve gerçek değerler karşılaştırılmıştır. İlk model için MAE, RMSE ve R<sup>2</sup> değerleri sırasıyla 72.32, 112.99 ve 0.96 şeklinde gerçekleşirken ikinci model için sırasıyla 97.40, 158.28 ve 0.91 olarak gerçekleşmiştir. Bu durumda Ocak ayı için ayrık dalgacık dönüşümü ve Xgboost ile tasarlanan model daha başarılı sonuçlar vermiştir.



Şekil 3. Add-Xgboost Ocak rüzgâr gücü tahmini




Şekil 4. Xgboost Ocak rüzgâr gücü tahmini



Şekil 6. Add-Xgboost Nisan rüzgâr gücü tahmini

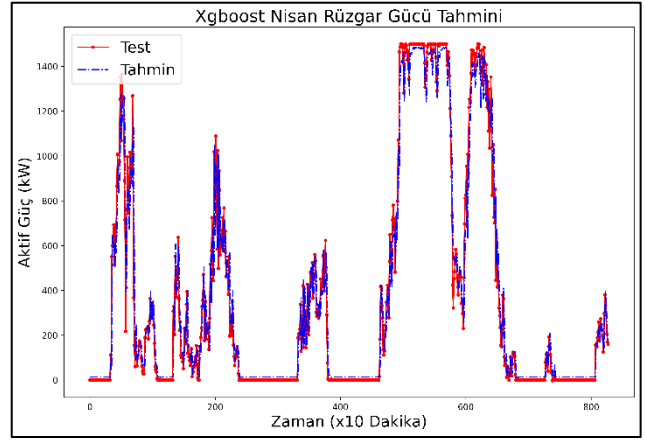
Kış mevsiminden Ocak ayı için tasarlanan modeller örnek olacak şekilde ilkbahar için Nisan, yaz için Temmuz ve sonbahar için Kasım ayı seçilerek aynı modeller aynı hiperparametreler ile aynı oranda eğitim ve test için ayrılarak tasarlanmış ve yine aynı hata metrikleriyle karşılaştırılmıştır.

Nisan ayı için rüzgâr gücü verisi ve ayrık dalgacık dönüşümü sonrası oluşan yaklaşım ve ayrıntı katsayılarının grafikleri Şekil 5'te görülmektedir.



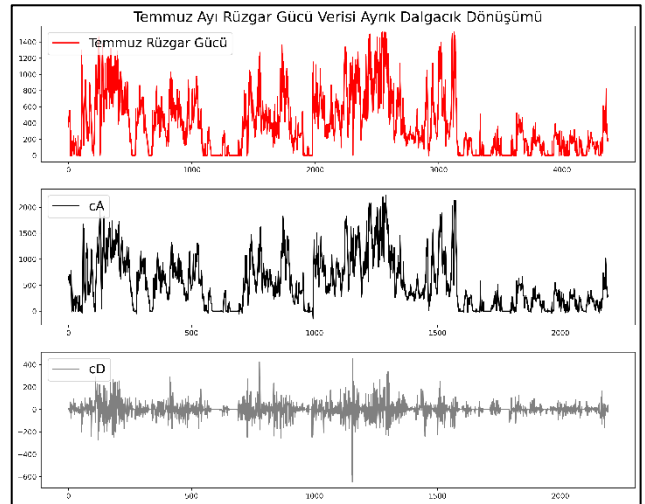
Şekil 5. Nisan rüzgâr gücü verisi

Şekil 6'da Nisan için ayrık dalgacık dönüşümü ve Xgboost modeli Şekil 7'de ise Xgboost modeli ile tasarlanan modelin tahmin grafikleri gösterilmiştir. İlk model için MAE, RMSE ve  $R^2$  değerleri sırasıyla 50.26, 78.14 ve 0.98 şeklinde gerçekleşirken ikinci model için sırasıyla 60.88, 104.77 ve 0.96 olarak gerçekleşmiştir. Bu durumda Nisan ayı için ayrık dalgacık dönüşümü ve Xgboost ile tasarlanan model daha başarılı sonuçlar vermiştir.



Şekil 7. Xgboost Nisan rüzgâr gücü tahmini


Temmuz ayı için rüzgâr gücü verisi ve ayrık dalgacık dönüşümü sonrası oluşan yaklaşım ve ayrıntı katsayılarının grafikleri Şekil 8'de görülmektedir.




Şekil 8. Temmuz rüzgâr gücü verisi

Şekil 9'da Temmuz için ayrık dalgacık dönüşümü ve Xgboost modeli Şekil 10'da ise Xgboost modeli ile tasarlanan modelin tahmin grafikleri gösterilmiştir. İlk

model için MAE, RMSE ve  $R^2$  değerleri sırasıyla 23.85, 35.45 ve 0.92 şeklinde gerçekleşirken ikinci model için sırasıyla 34.28, 52.98 ve 0.83 olarak gerçekleşmiştir. Bu durumda Temmuz ayı için ayırık dalgacık dönüşümü ve Xgboost ile tasarlanan model daha başarılı sonuçlar vermiştir.

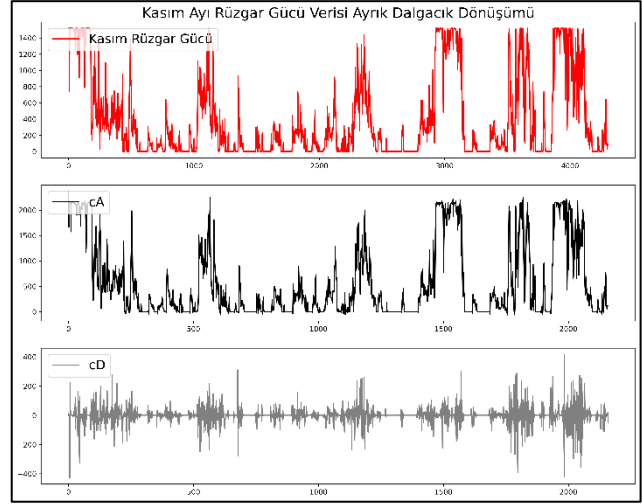


Şekil 9. Add-Xgboost Temmuz rüzgâr gücü tahmini



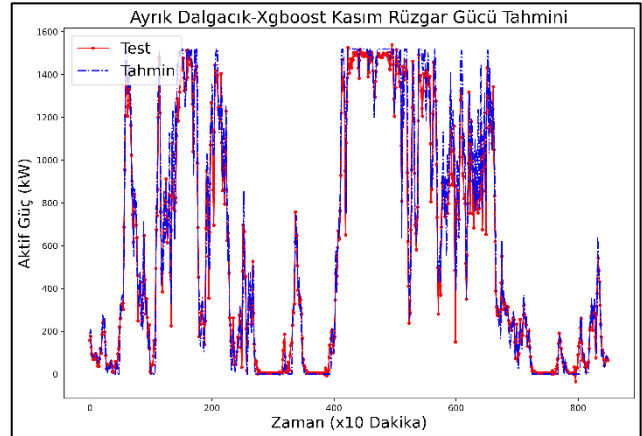
Şekil 10. Xgboost Temmuz rüzgâr gücü tahmini

Kasım ayı için rüzgâr gücü verisi ve ayırık dalgacık dönüşümü sonrası oluşan yaklaşım ve ayrıntı katsayılarının grafikleri Şekil 11'de görülmektedir.



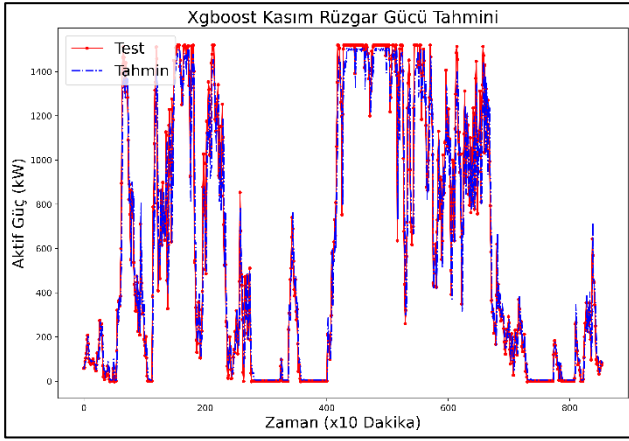
Şekil 11. Kasım rüzgâr gücü verisi

Şekil 12'de Kasım için ayırık dalgacık dönüşümü ve Xgboost modeli Şekil 13'te ise Xgboost modeli ile tasarlanan modelin tahmin grafikleri gösterilmiştir. İlk model için MAE, RMSE ve  $R^2$  değerleri sırasıyla 72.70, 111.10 ve 0.96 şeklinde gerçekleşirken ikinci model için sırasıyla 93.39, 150.94 ve 0.93 olarak gerçekleşmiştir. Bu durumda Kasım ayı için ayırık dalgacık dönüşümü ve Xgboost ile tasarlanan model daha başarılı sonuçlar vermiştir.



Şekil 12. Add-Xgboost Kasım rüzgâr gücü tahmini





Şekil 13. Xgboost Kasım rüzgâr gücü tahmin

Her mevsimden seçilen aylara ait hata metriklerini Tablo 2’de gösterilmiştir. Ayrik dalgacık dönüşümü ile birlikte Xgboost kullanılan model seçilen her ayda daha başarılı sonuç vermiştir.

Tablo 2. Modellerin karşılaştırılması

Aylar	Model	MAE	RMSE	R <sup>2</sup>
Ocak	ADD-Xgboost	72.32	112.99	0.96
	Xgboost	97.40	158.28	0.91
Nisan	ADD-Xgboost	50.26	78.14	0.98
	Xgboost	60.88	104.77	0.96
Temmuz	ADD-Xgboost	23.85	35.45	0.92
	Xgboost	34.28	52.98	0.83
Kasım	ADD-Xgboost	72.70	111.10	0.96
	Xgboost	93.39	150.94	0.93

#### 4. Sonuçlar

Sürekli bir kaynak olan rüzgârdan elde edilen güce ait zaman serisi durağan değildir ve çeşitli nedenlerden dolayı aykırı veriler oluşmaktadır. Karar ağacı temelli olan Xgboost algoritmasıyla her mevsimden seçilen bir aya ait 10 dakika zaman ufkunda tahmin yapmadan önce bu verinin ayrik dalgacık dönüşümü ile ayrıştırılıp daha sonra Xgboost algoritması ile tahmin yapılması yalnız Xgboost algoritması ile tahmin yapılmasına göre seçilen dört ayda da MAE, RMSE ve R<sup>2</sup> hata metrikleriyle karşılaştırılmış ve ayrik dalgacık dönüşümü-Xgboost modelinin daha başarılı sonuçlar verdiği görülmüştür.

Bu çalışma farklı sinyal işleme teknikleri kullanılarak geliştirilebileceği gibi farklı makine ve derin öğrenme algoritmalarıyla tasarlanıp karşılaştırılabilir. Seçilen modeller farklı eğitim algoritmaları ve optimizasyon algoritmalarıyla tasarlanıp başarıları karşılaştırılabilir.

#### Kaynaklar

- [1] Türkiye Elektrik İlerim A.Ş. Kurulu Güç Raporu Mart 2022. <https://www.teias.gov.tr/tr-TR/kurulu-guc-raporlari> (Erişim Tarihi: 27.04.2022).
- [2] Foley AM, Leahy PG, Marvuglia A, McKeogh EJ. Current methods and advances in forecasting of wind power generation. *Renewable Energy*, 37(1), 1-8, 2012.
- [3] Monteiro C, Bessa R, Miranda V, Botterud A, Wang J, Conzelmann G. Wind power forecasting: state-of-the-art. *Decision and Information Sciences*, 2009.
- [4] Santhosh, M., Venkaiah, C., & Vinod Kumar, D. M. (2020). Current advances and approaches in wind speed and wind power forecasting for improved renewable energy integration: A review. *Engineering Reports*, 2(6), e12178.
- [5] Potter CW, Negnevitsky M. Very short-term wind forecasting for Tasmanian power generation. *IEEE Transactions on Power Systems*, 21, (2), 965-972, 2006.
- [6] Nor KM, Shaaban M, Rahman HA. Feasibility assessment of wind energy resources in Malaysia based on NWP models. *Renewable Energy*, 62, 147-154, 2014.
- [7] Focken U, Lange M, Waldl H.-P.H.-P. Previento-A Wind Power Prediction System with an Innovative Upscaling Algorithm. In *Proceedings of the European Wind Energy Conference (EWEC)*, Copenhagen, Denmark, pp. 1-4, 2011.
- [8] Zhang Y, Li Y, Zhang G. Short-term wind power forecasting approach based on Seq2Seq model using NWP data. *Energy*, 213, 118371, 2020.
- [9] Wang J, Zhou Q, Zhang X. Wind power forecasting based on time series ARMA model. In *IOP Conference Series: Earth and Environmental Science Vol. 199, No. 2, p. 022015*. IOP Publishing, 2018.
- [10] Yatiyana E, Rajakaruna S, Ghosh A. Wind speed and direction forecasting for wind power generation using ARIMA model. In *2017 Australasian Universities Power Engineering Conference (AUPEC)* (pp. 1-6). IEEE, 2017.
- [11] Kusiak A, Zhang Z. Short-horizon prediction of wind power: A data-driven approach. *IEEE Transactions on Energy Conversion*, 25(4), 1112-1122, 2010.
- [12] Durán MJ, Cros D, Riquelme J. Short-term wind power forecast based on ARX models. *J. Energy Eng.* 133, 172-180, 2007.
- [13] Firat U, Engin SN, Sarcalar M, Ertuzum AB. Wind Speed Forecasting Based on Second Order Blind Identification and Autoregressive Model. In *Proceedings of the 2010 Ninth International*

- Conference on Machine Learning and Applications, Washington, DC, USA, 12–14, pp. 686–691, 2010.
- [14] Bilal B, Ndongo M, Adjallah KH, Sava A, Kebe CMF, Ndiaye PA, Sambou V. Wind turbine power output prediction model design based on artificial neural networks and climatic spatiotemporal data. In Proceedings of the IEEE International Conference on Industrial Technology 2018, Lyon, France, pp. 1085–1092, 2018.
- [15] Hong YY, Rioflorido CLPP. A hybrid deep learning-based neural network for 24-h ahead wind power forecasting. *Appl. Energy*, 250, 530–539, 2019.
- [16] Shahid F, Zameer A, Muneeb M. A novel genetic LSTM model for wind power forecast. *Energy*, 223, 120069, 2021.
- [17] Du P, Wang J, Yang W, Niu T. A novel hybrid model for short-term wind power forecasting. *Applied Soft Computing*, 80, 93–106, 2019.
- [18] Hong YY, Rioflorido CLPP. A hybrid deep learning-based neural network for 24-h ahead wind power forecasting. *Appl. Energy*, 250, 530–539, 2019.
- [19] Lydia M, Kumar S, Selvakumar A. A comprehensive review on wind turbine power curve modeling techniques. *Renewable and Sustainable Energy Reviews*, 452–460, 2014.
- [20] Shepherd W, Zhang L. *Electricity Generation Using Wind Power*. World Scientific, 2011.
- [21] Liu Y, Guan L, Hou C, Han H, Liu Z, Sun Y, Zheng M. Wind power short-term prediction based on LSTM and discrete wavelet transform. *Applied Sciences*, 9(6), 1108, 2019.
- [22] Catalão JDS, Pousinho HMI, Mendes VMF. Short-term wind power forecasting in Portugal by neural networks and wavelet transform. *Renewable energy*, 36(4), 1245–1251, 2011.
- [23] Chaovalit P, Gangopadhyay A, Karabatis G, Chen Z. Discrete wavelet transform-based time series analysis and mining. *ACM Computing Surveys (CSUR)*, 43(2), 1–37, 2011.
- [24] Wang W, Shi Y, Lyu G, Deng W. Electricity consumption prediction using Xgboost based on discrete wavelet transform. *DEStech Trans. Comput. Sci. Eng.*, 2017.
- [25] Chen T, Guestrin C. Xgboost: A scalable tree boosting system. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining (pp. 785–794), 2016.
- [26] Demolli H, Dokuz AS, Ecemis A, Gokcek M. Wind power forecasting based on daily wind speed data using machine learning algorithms. *Energy Conversion and Management*, 198, 111823, 2019.