

XGBoost (Aşırı Gradyan Artırılmış Karar Ağaçları) ile Hidroelektrik Enerji Tahmini

Bektaş Aykut ATALAY^{1,a}, Kasım ZOR^{1,b}

¹Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü, Adana

^aORCID: 0000-0003-4542-6104; ^bORCID: 0000-0001-6443-114X

Makale Bilgileri

Geliş : 01.11.2024

Kabul : 25.03.2025

DOI: 10.21605/cukurovaumfd.1666062

Sorumlu Yazar

Bektaş Aykut ATALAY

bektasaykut@gmail.com

Anahtar Kelimeler

HES

Hidroelektrik

Tahmin

XGBoost

Atıf şekli: ATALAY, B., A., ZOR, K., (2025). XGBoost (Aşırı Gradyan Artırılmış Karar Ağaçları) ile Hidroelektrik Enerji Tahmini. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 40(1), 205-218.

ÖZ

Hidroelektrik enerji, Türkiye'nin hızlı ekonomik ve nüfus artışıyla yükselen enerji talebinin karşılanmasında büyük önem taşır. Mevsimsel bağımlılığı nedeniyle hidroelektrik enerji tahmin algoritmaları için uygundur. Bu çalışma, Türkiye'de 100 MW'ın üzerinde güç üreten EÜAŞ Aslantaş HES'te enerji üretimini tahmin etmeyi amaçlamaktadır. Tahmin modeli, XGBoost (Aşırı Gradyan Artırılmış karar ağaçları) ile tarih-saat kayıtları, geçmiş enerji üretim verileri ve sıcaklık gibi çeşitli girdi kullanılarak oluşturulmuştur. Üretim verileri, EPIAŞ Şeffaflık Platformu'ndan alınmış ve Python ile işlenmiştir. XGBoost modeli, farklı ağaç sayıları ve öğrenme oranı (η) deneyerek optimize edilmiştir. Modelin etkinliği, belirleme katsayısı (R^2), Ortalama Mutlak Ölçekli Hata (MASE), Kök Ortalama Karesel Hata (RMSE), Ortalama Mutlak Hata (MAE) ve Ağırlıklı Mutlak Yüzdese Hata (WAPE) gibi çeşitli hata ölçümleri ile titizlikle değerlendirilmiştir. Bu çalışmada kullanılan yöntemler ve elde edilen sonuçlar, hidroelektrik enerji tahmininde makine öğrenimi algoritmalarının faydalı olabileceğini ve enerji yönetimi stratejilerinin optimize edilmesine yönelik önemli bilgiler sunabileceğini göstermektedir.

Hydroelectric Power Forecasting via XGBoost (Extreme Gradient Boosted Decision Trees)

Article Info

Received : 01.11.2024

Accepted : 25.03.2025

DOI: 10.21605/cukurovaumfd.1666062

Corresponding Author

Bektaş Aykut ATALAY

bektasaykut@gmail.com

Keywords

HPP

Hydroelectricity

Forecasting

XGBoost

How to cite: ATALAY, B., A., ZOR, K., (2025). Hydroelectric Power Forecasting via XGBoost (Extreme Gradient Boosted Decision Trees). Çukurova University, Journal of the Faculty of Engineering, 40(1), 205-218.


ABSTRACT

Hydropower energy is crucial for meeting Turkey's growing energy demand, driven by rapid economic and population growth. Its seasonal variability makes it suitable for forecasting algorithms. This study aims to predict energy production at the EÜAŞ Aslantaş Hydroelectric Power Plant, with a capacity exceeding 100 MW. A forecasting model was created using XGBoost (Extreme Gradient Boosted Decision Trees) incorporating inputs such as timestamp, historical energy production data, and temperature. Energy data source is the EPIAŞ Transparency Platform and the data was processed with Python. The model was optimized by varying the number of trees and learning rates (η). Its effectiveness was rigorously assessed using statistical metrics, including the coefficient of determination (R^2), Mean Absolute Scaled Error (MASE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), Weighted Absolute Percentage Error (WAPE). The results indicate that machine learning algorithms can significantly enhance hydropower energy forecasting and optimize energy management strategies.

1. GİRİŞ

Hidroelektrik enerji, önemli bir yenilenebilir enerji kaynağı olup küresel enerji üretiminde kritik bir rol oynamaktadır. Enerji üretiminin yanı sıra, taşkın kontrolü, sulama ve su temini gibi faydaları da bulunmaktadır. Hidroelektrik enerji; tarım, ekonomi, doğal afetlere karşı koruma ve temiz su temini açısından büyük bir öneme sahiptir.

T.C. Enerji ve Tabii Kaynaklar Bakanlığı'na göre, Türkiye'nin elektriğinin %36,3'ü kömürden, %21,4'ü doğalgazdan, %19,6'sı hidroelektrik enerjiden, %10,4'ü rüzgârdan, %5,7'si güneşten, %3,4'ü jeotermal enerjiden ve %3,2'si diğer kaynaklardan üretilmektedir. Şekil 1'de görüldüğü üzere, 2023 yılı itibarıyla Türkiye'nin elektrik enerjisi üretiminde hidroelektrik enerjinin payı beşte birdir [1].



Şekil 1. Türkiye'nin 2023 yılı elektrik üretim kaynakları


Hidroelektrik enerjinin elektrik üretimindeki payının yanı sıra elektrik üretim maliyeti ve yenilenebilir olması Türkiye için önemli faktörlerdir. Hidroelektrik enerji üretiminde suyun potansiyel ve kinetik enerjisi kullanıldığından elektrik enerjisi üretimi için sadece su ve suyun kontrolü yeterlidir; başka bir yakıtı ihtiyaç duyulmadığından çevre kirliliği oluşmaz.

Hidroelektrik enerji üretimi, birçok faktöre bağlıdır ve bu faktörler üretimin maksimize edilmesi ve sürdürülebilmesi için büyük önem taşır. Dolayısıyla hidroelektrik enerji üretiminin planlanması gereklidir. Bu planlama, elektrik piyasasının arz ve talep dengesi ile mevsimsel koşullara göre yapılmalıdır. Bu çalışmanın da temel motivasyonu hidroelektrik enerji üretiminin tahmin edilmesidir.

Hidroelektrik enerji, ülkenin en yaygın kullanılan yenilenebilir enerji kaynağı olmasına rağmen yağmur, kar yağışı ve kuraklık gibi etkenlere bağlıdır. Dolayısıyla, hidroelektrik enerji üretimi tahmini, enerji planlayıcılarının ve operatörlerinin bu etkenlerdeki değişimleri öngörmesine olanak tanıyarak ülke için güvenilir ve istikrarlı bir elektrik arzını destekler [2].

Hidroelektrik enerji üretiminin tahmini, şebeke operasyonlarının optimize edilmesi, istikrarlı bir enerji arzının sağlanması ve işletmecilik maliyetlerinin azaltılması açısından kritik bir etkidir [3].

Aslantaş HES, Ceyhan Nehri üzerinde kurulmuş olup, Doğu Akdeniz Bölgesi'nin ana su yollarından biridir. 138 MW kurulu güce sahip olan Aslantaş HES, yılda yaklaşık 569 GWh elektrik üretmektedir. Barajın oluşturduğu geniş rezervuar, ortalama su seviyesinde 1.150 milyon m³ kapasiteye sahiptir ve sulamada önemli bir rol oynar. Yaklaşık 149.849 hektar araziye sulayan baraj, Ceyhan Nehri boyunca taşkın yönetimi için de hayati öneme sahiptir. Aslantaş barajı, su akışının düzenlenmesine ve olası taşkın olaylarının azaltılmasına yardımcı olmaktadır.



Şekil 2. Kaynaklara göre enerji üretimi, Türkiye, 1990-2022 [4]



Şekil 3. Aslantaş Barajı ve HES konumu

Aslantaş Barajı ve Hidroelektrik Santrali'nin yapımına 1976 yılında başlanmış ve 1984 yılında tamamlanmıştır. Toprak dolgu tipinde inşa edilen barajın gövde hacmi 8.493.000 m³, kret uzunluğu 585 m ve yüksekliği 95 m'dir. Barajın maksimum su seviyesi 155 m, depolama kapasitesi 1.799 hm³ ve göl alanı 63 km²'dir. Santralde üretilen elektrik enerjisi, 154 kV'a kadar yükseltilerek ulusal elektrik şebekesine bağlanmaktadır [5].

Hidroelektrik santralleri, sel kontrolü ve su kaynaklarının yönetiminde kritik bir rol oynar. Doğru enerji üretimi tahmini, su akışının düzgün yönetilmesine yardımcı olarak sel risklerini azaltır.

Tahminler, sulama ve içme suyu temini için yeterli su sağlanmasına yardımcı olur, böylece sürdürülebilir su yönetimini destekler [6,7].

Daha iyi tahmin modelleri, hidroelektrik projeler için finansal planlama ve yatırım stratejilerini geliştirebilir, enerji üretimini doğru tahmin ederek ve bakım programlarını optimize ederek ekonomik verimliliği ve güvenilirliği artırır. Bu modeller, su kaynaklarının kullanımını optimize ederek sulama ve su teminini daha ekonomik ve etkili hale getirir [8,9].

Hidroelektrik üretiminin optimizasyonu için hidroelektrik tahminleri çok önemlidir ve rezervuar operasyonlarını ve enerji üretimini etkin bir şekilde yönetmek için kesin tahminler gerektirir. XGBoost gibi ileri makine öğrenimi tekniklerinin kullanılması, hidroelektrik tahminlerinin doğruluğunu artırabilir. Büyük veri kümelerini ele alma konusundaki ölçeklenebilirliği ve verimliliği ile bilinen XGBoost algoritması, çeşitli tahmin uygulamalarında umut verici sonuçlar göstermiştir [10].

Araştırmalar hidroelektrik operasyonlarında tahmin kalitesinin önemini vurgulamakta ve akarsu akışının kesin tahminlerinin hidroelektrik yönetimindeki karar alma süreçlerini doğrudan etkilediğini vurgulamaktadır [11].

Hidroelektrik tahminleri alanında XGBoost gibi makine öğrenimi yöntemlerinin kullanımı, taşkın tahminleri için giderek daha uygun hale gelmektedir. Bu, XGBoost'un hidroelektrik tahmin modellerinde verimli bir şekilde kullanılma potansiyelini göstermektedir [12-15].

2. LİTERATÜR ARAŞTIRMASI

Bu bölümde, son yıllarda çeşitli enerji tahmin problemlerinde kullanılan XGBoost algoritmasının etkinliğini ve uygulamalarını incelemektedir. Çalışmalar, rüzgar ve güneş enerjisi tahmininden hidroelektrik güç tahminine kadar geniş bir yelpazede XGBoost'un diğer makine öğrenme yöntemlerine kıyasla üstün performans sergilediğini göstermektedir. Ayrıca, literatür çalışmaları yıllara göre ayrı ayrı incelenmiş ve farklı uygulama alanları değerlendirilmiştir.

2.1. 2018 Yılı Literatürü

Zhang ve arkadaşları [16], özellikle açık deniz sahaları için rüzgar türbini güvenilirliğini ele alarak, arıza tespiti için random forests (RF) ve XGBoost yöntemlerini kullanmaktadır. RF, özellik önemini sıralarken, XGBoost belirli arızalar için sınıflandırıcıyı eğitir. Farklı rüzgar türbini modelleri ile yapılan simülasyonlar, bu yaklaşımın çok boyutlu veri işleme konusunda sağlam ve üstün performansını doğrulamaktadır ve destek vektör makinelerinden (SVM) daha iyi sonuçlar vermektedir.

Liu ve arkadaşları [17], geleneksel tahmin yöntemlerinde yüksek hesaplama maliyeti ve aşırı uyum sorunlarını ele almak için K-means kümeleme ve XGBoost'u birleştiren bir yöntem önermektedir. Çalışmada özellikler çıkarılır ve eksik değerler doldurulur. Yük sınıflandırılır ve XGBoost regresyon modelleri günlük yükü tahmin eder, bu da doğruluğun arttığını göstermektedir. Zheng ve Wu [18], kısa vadeli rüzgar gücü tahmini için hava durumu benzerlik analizi ve özellik mühendisliği içeren bir XGBoost modeli önermektedir. K-means kümeleme, tarihsel verileri kategorize eder ve önemsiz özellikler elenir. Model, tahmin doğruluğunda BPNN, CART, RF, SVR ve tek bir XGBoost modelinden daha iyi performans göstermektedir.

2.2. 2019 Yılı Literatürü

Abbasi ve arkadaşları [19], günlük verileri haftalık zaman serilerine dönüştürerek kısa vadeli yük tahmini için XGBoost kullanmaktadır. Özellik seçimi ve tahmin, XGBoost kullanılarak gerçekleştirilir ve bu yöntem hesaplama süresi, bellek kaynağı kullanımı ve ortalama yüzde hata metriğinde üstün performans sergiler. Suo ve arkadaşları [20], meteorolojik, nüfus ve coğrafi faktörleri dahil ederek yük tahmini için XGBoost'u tanıtmaktadır. Modelin paralellik ve aşırı uyum önleme özellikleri tahmin doğruluğunu artırır. Çok boyutlu model, yalnızca sıralı özellikleri dikkate alan modellere göre önemli bir doğruluk artışı gösterir. Li ve arkadaşları [21], güç yükü tahmin doğruluğunu artırmak için LSTM ve XGBoost'u birleştiren bir tahmin modeli önermektedir. Hata ters çevirme yöntemi, her iki modelin sonuçlarını birleştirir. Birleşik model, bireysel modellere kıyasla önemli ölçüde daha düşük tahmin hatası gösterir.

Liao ve arkadaşları [22], benzer günlere dayalı kısa vadeli yük tahmini için bir XGBoost modeli önermektedir ve meteorolojik ve günlük türlerin yük üzerindeki etkilerini analiz eder. Model, karmaşıklık ve aşırı uyumu kontrol etmek için ikinci dereceden Taylor genişlemesi ve kayıp fonksiyonunu içerir. Simülasyon sonuçları, modelin kısa vadeli yük tahmininde etkinliğini göstermektedir.

2.3. 2020 Yılı Literatürü

Guo ve arkadaşları [23], birden fazla makine öğrenimi algoritmasını entegre eden Stacking topluluk öğrenme yöntemi tabanlı bir fotovoltaik güç tahmin modeli önermektedir. Sonuçlar, Stacking modelinin XGBoost'tan daha iyi performans gösterdiğini ve 0.1007 olan kök ortalama kare hatası (RMSE) değerinin XGBoost'a göre %1.84 daha düşük olduğunu ve 90.85 puanının XGBoost'tan 1.49 daha yüksek olduğunu göstermektedir. Phan ve arkadaşları [24], kısa vadeli rüzgar gücü tahmini için XGBoost'un geleneksel yapay sinir ağı (ANN), uzun kısa süreli bellek (LSTM) ve zamansal evrişim ağı (TCN) modelleriyle performansını karşılaştırmaktadır. Çalışmadaki bulgular, XGBoost'un karşılaştırılan tüm modellerden daha iyi performans gösterdiğini göstermektedir.

2.4. 2021 Yılı Literatürü

Al Rayess ve Ülke Keskin [25], Almus Barajı'nda hidroelektrik enerji üretimini tahmin etmek için Karar Ağacı, Derin Öğrenme, Genelleştirilmiş Doğrusal Model, Gradient Boosted Trees ve Random Forest gibi çeşitli makine öğrenme tekniklerini kullanmıştır. Zhang ve arkadaşları [26], gri kurt optimizasyonunu (HGWO) XGBoost ile birleştiren hibrit bir yaklaşım kullanarak beton barajlar için yeni bir sızıntı izleme modeli önermektedir. HGWO-XGBoost modelinin, güçlü küresel optimizasyon yeteneği ve tatmin edici tahmin sonuçları gösterdiği sızıntıyı etkili bir şekilde tahmin ettiği belirtilmiştir. Ma ve arkadaşları [27], sel riski değerlendirmesi için En Küçük Kareler Destek Vektör Makinesi (LSSVM) modeli ile XGBoost modelini kullanmaktadır. Bu çalışma, XGBoost'un CPU'nun çoklu iş parçacıklarını verimli kullanması nedeniyle geliştirilmiş model eğitim hızı ve tahmin doğruluğunu vurgulamaktadır.

Osman ve arkadaşları [28], yağış, sıcaklık ve buharlaşma gibi önceden kaydedilmiş verileri kullanarak yeraltı suyu seviyelerini tahmin etmek için XGBoost tabanlı bir model önermektedir. Araştırma, Malezya'nın Selangor bölgesindeki yoğun nüfuslu kasabalarda azalan yeraltı suyu seviyelerine çözüm bulmayı hedeflemekte ve üç makine öğrenme modelinin performansını değerlendirmektedir.

Zhang ve arkadaşları [29], Jinshuitan Nehir Havzası'ndaki rezervuar akışlarını tahmin etmek için konvolüsyonel sinir ağları (CNN), XGBoost ve kısmi en küçük kareler modelini entegre eden bir yöntem sunmaktadır. Bu model, tekil modellere kıyasla kök ortalama kare hatasını (RMSE) önemli ölçüde azaltarak, akış tahminlerinde daha yüksek doğruluk sağlamıştır. Bae ve arkadaşları [30], sayaç arkasında (BTM) bulunan güneş PV jeneratörlerinin elektrik yükünde neden olduğu bozulmayı ele almak için XGBoost tabanlı bir yük tahmin algoritması önermektedir.

Wang ve arkadaşları [31], ham yük verilerini VMD ve SampEn (SVMD) kullanarak trend serileri ve dalgalanma alt serilerine ayıran ve tahmin için XGBoost'u kullanan endüstriyel müşteriler için kısa vadeli yük tahmini için hibrit bir yöntem önermektedir. Phan ve arkadaşları [32], bir saat ileriye yönelik güneş enerjisi tahminleri için Kernel Principal Component Analysis (PCA) ve XGBoost'a dayalı bir makine öğrenme modeli önermektedir. Model, tahmin doğruluğunu artırmak için sayısal hava tahmini (NWP) verilerini ve sağlam performans için karar ağaçlarının bir entegrasyonunu kullanmıştır.

Phan ve arkadaşları [33], sayısal hava tahmin (NWP) modellerini XGBoost ile birleştiren hibrit bir rüzgar gücü tahmin modeli önermektedir. Wang ve arkadaşları [34], petrol ve gaz keşfi bağlamında rezervuar sınıflandırması ve değerlendirilmesi için geliştirilmiş bir hiyerarşik XGBoost (h-XGBoost) modelleme yöntemi tanıtmaktadır. Xinjiang'daki Mahu bölgesindeki sıkışık konglomera rezervuarı üzerinde yapılan çalışma, h-XGBoost yönteminin farklı rezervuarlardan özellikler çıkarma ve hiyerarşik bir veri modeli oluşturma konusundaki etkinliğini göstermektedir.

Udo ve Muhammad [35], tarihsel SCADA verilerini kullanarak rüzgar türbinlerinin kestirimci bakımı için bir yöntem geliştirmiştir. Bu yöntemde, kritik rüzgar türbini bileşenlerinde anormallikleri izlemek ve tespit etmek için XGBoost ve Long Short-Term Memory (LSTM) modelleri kullanılır.

2.5. 2022 Yılı Literatürü

Chen ve arkadaşları [36], su türbini jeneratörlerinin mil kaçıklığı eğilimini tahmin etmek ve hidroelektrik birimlerindeki arızaları tespit etmek için XGBoost algoritmasını kullanmayı önermektedir. Hidroelektrik

santral içindeki sensörlerden gelen kaynak verileri ön işleme tabi tutularak regresyon ve sınıflandırma için XGBoost modeline giriş verisi olarak kullanılmıştır. Önerilen yöntem, potansiyel ekipman tehlikelerini etkili bir şekilde tanımlayarak hidroelektrik santralinin zekasını ve operasyonel optimizasyonunu artırmaktadır.

Fan ve arkadaşları [37], hava tahminlerini kullanarak rüzgar ve güneş gibi yeni enerji kaynaklarından enerji üretimini tahmin etmeye odaklanmaktadır. XGBoost ve LightGBM modellerini kullanılmıştır. Singh ve Rizwan [38], SCADA sisteminden elde edilen zaman serisi verilerini kullanarak rüzgar gücünü tahmin etmeyi amaçlamaktadır. Veri kümesi çeşitli tekniklerle incelenir ve görselleştirilir, ardından rüzgar gücünü tahmin etmek için XGBoost dahil olmak üzere makine öğrenme algoritmaları uygulanmıştır. Deneysel bulgular, XGBoost regresyon yaklaşımının yüksek tahmin doğruluğu sağladığını ve R^2 'nin yaklaşık 0.969 olduğunu, düşük MSE, RMSE, MAPE ve MAE değerleri ile göstermektedir.

Xue ve arkadaşları [39], Long Short-Term Memory (LSTM) ve XGBoost algoritmalarını entegre eden bir fotovoltaik güç tahmin modeli sunmaktadır. Her iki modelin avantajlarını birleştirerek, önerilen XGBoost-LSTM modeli daha doğru tahmin sonuçları elde etmektedir. Mohamed ve arkadaşları [40], Çoklu Doğrusal Regresyon (MLR) ve Pearson Korelasyon Katsayısı (PCC) kullanarak güneş gücü tahmini için hibrit bir makine öğrenme sistemi önermektedir. Xiong ve arkadaşları [41], kısa vadeli rüzgar gücü tahmini için Bayes hiperparametre optimizasyonu (BH-XGBoost) ile iyileştirilmiş bir XGBoost algoritması tanıtmaktadır. Bu yöntem, özellikle aşırı hava koşulları ve düşük rüzgar hızları nedeniyle meydana gelen rüzgar ramp olaylarında XGBoost, SVM, KELM ve LSTM'den daha iyi performans göstermektedir.

Wang ve arkadaşları [42], entegre ampirik mod ayrışımı, varyasyonel mod ayrışımı ve serçe arama algoritması ile optimize edilmiş XGBoost kullanarak hibrit bir tahmin modeli (ICEEMDAN-SE-VMD-SSA-XBoost-MLR) önermektedir. Model, geçmiş yük verileri ve hata düzeltme mekanizması ile doğrulanmış olup, pik yük tahmininde yüksek doğruluk sağlamaktadır.

2.6. 2023 Yılı Literatürü

Hong ve arkadaşları [43], meteorolojik koşullar nedeniyle güneş enerjisinin stokastik doğasıyla ilgili zorlukları ele almak için XGBoost algoritmasını kullanarak bir PV (fotovoltaik) güç tahmin yöntemi önermektedir. PV güç tahmin modeli oluşturulmuş ve bir vaka çalışmasıyla değerlendirilmiş olup, önerilen yöntemin etkinliğini göstermektedir. Zou ve arkadaşları [44], yatay olarak kırılmış kuyulardan hızlı ve kesin şist gazı üretimi tahmini için tasarlanmış veri odaklı bir model olan ASGA-XGBoost'u sunmaktadır. ASGA, XGBoost modelinin hiper parametrelerini optimize ederek tahmin performansını artırmaktadır. Model, 30 günlük kümülatif gaz üretimini en düşük ortalama mutlak hatayla tahmin ederek diğer yöntemlerden daha iyi performans göstermektedir.

Tran ve arkadaşları [45], XGBoost modelinin hiper parametrelerini optimize etmek için medyan hata kayıp değerlerine dayalı yeni bir grid arama algoritması tanıtmaktadır. Önerilen algoritmanın performansı, Ho Chi Minh City, Vietnam ve Tazmanya, Avustralya'dan alınan günlük elektrik yük verileriyle doğrulanmış olup orijinal grid arama algoritmasına göre daha küçük MSE göstermektedir. Sun ve arkadaşları [46], yük tahmininin doğruluğunu ve verimliliğini artırmak için hiyerarşik kümeleme ve XGBoost'u birleştiren bir yöntem önermektedir. Yöntem, özellik benzerliklerini belirlemek için hiyerarşik kümeleme ve özellik analizi için XGBoost kullanılmaktadır.

2.7. 2024 Yılı Literatürü

Wu ve arkadaşları [47], meteorolojik benzer günleri ve XGBoost modelini kullanarak hidroelektrik tahmin yöntemi sunmaktadır. Meteoroloji ve akış verileri ile hazırlanan benzer gün veri seti, XGBoost modelini eğitmek için kullanılmaktadır. Yöntem, Çin'in Yunnan bölgesinden alınan verilerle doğrulanmış olup yüksek tahmin doğruluğu ve istikrar göstermektedir.

Bashir ve arkadaşları [48], dinamik hava koşulları altında PV güç tahmininin doğruluğunu artırmak için konvolüsyonel sinir ağı (CNN) ve XGBoost modellerini birleştiren hibrit bir tahmin modeli önermektedir. Model, BAE'nin Şarja kentinde 2.88 kW şebeke bağlantılı PV sistemi üzerinde doğrulanmış olup, 44.18 RMSE ve 0.9962 R^2 ile üstün performans göstererek, tek başına XGBoost'a kıyasla tahmin doğruluğunu önemli ölçüde artırmaktadır.

3. MATERYAL VE METOT

Bu bölümde, hidroelektrik enerji üretimi tahmin modelinin geliştirilmesinde kullanılan yöntemler ve adımlar detaylandırılmıştır:

- EPIAŞ Şeffaflık Platformu'ndan alınan enerji üretim verileri ve MERRA-2 veri setlerinden alınan meteorolojik veriler Python ile işlenmiştir.
- XGBoost modeli, tarihsel enerji üretim verileri, meteorolojik veriler ve takvim değişkenleri kullanılarak oluşturulmuştur.
- Model, farklı ağaç sayıları ve öğrenme oranı (η) denenerek optimize edilmiştir.
- Modelin doğruluğu ve performansı, belirleme katsayısı (R^2), Ortalama Mutlak Ölçekli Hata (MASE), kök ortalama karesel hata (RMSE) ve ortalama mutlak hata (MAE) gibi istatistiksel performans ölçütleri kullanılarak değerlendirilmiştir.

Bu çalışmanın yapıldığı dizüstü bilgisayar Intel i7-10870H-2,20 GHz işlemci, 64 GB RAM, Nvidia RTX2070 8GB GDDR6 256-Bit ekran kartına sahiptir. Python kodları nvidia-cuda kütüphanesi aracılığıyla grafik kartın üzerinde çalıştırılmıştır.


Windows WSL2 sanallaştırma platformunda Ubuntu 22.04.3 işletim sisteminde anaconda platformu üzerinde jupyter notebook, python, xgboost, cuda, cuml, cupy kütüphaneleri kullanılarak model eğitilmiştir.

3.1. Materyal

Bu bölümde, hidroelektrik enerji tahmini için hazırlanan veri setinin ve değişkenlerin detaylı bir tanımlanması yapılmaktadır. Verilerin doğru seçimi ve uygun kategorilere ayrılması, tahmin modelinin başarısını doğrudan etkilemektedir. Bu nedenle, girdi değişkenleri enerji üretimi, meteorolojik ve takvim değişkenleri olmak üzere üç ana kategoriye ayrılmıştır. Ayrıca, hedef değişken olarak gerçek üretilen enerji belirlenmiştir.

Girdi değişken kategorileri enerji üretimi, meteorolojik ve takvim değişkenleridir. Enerji üretimi değişkenleri, hidroelektrik santrallerinin performansını anlamak ve gelecekteki enerji üretimini tahmin etmek için kritik öneme sahiptir. Aşağıda, bu değişkenlerin ve veri toplama sürecinin ayrıntıları sunulmaktadır:

- Hedef değişken olarak gerçek üretilen enerji seçilmiştir. Bu, modelin tahmin edeceği ve doğruluğunu belirleyeceği temel değerdir.
- Tarihsel elektrik enerjisi üretim değişkenleri, önceki 1 saat, önceki gün (önceki günün aynı saati) ve önceki hafta (önceki haftanın aynı günü ve saati) verilerini içermektedir. Bu veriler, zaman serisi analizinde kullanılan geçmiş verilerin bir örneğidir ve gelecekteki enerji üretimini tahmin etmede önemli rol oynamaktadır.
- Girdi veri toplama için seçilen dönem 01.01.2020 ile 01.01.2024 arasındadır. Bu dönem, yeterli miktarda veri sağlayarak modelin eğitilmesi ve test edilmesi için uygun bir zaman dilimini kapsamaktadır.
- Enerji üretim verileri EPIAŞ Şeffaflık Platformu'ndan alınmıştır [49]. Bu veriler 2020, 2021, 2022 ve 2023 yıllarını kapsayan saatlik kayıtlar şeklindedir. EPIAŞ verileri, Türkiye'nin enerji piyasasındaki şeffaflığı artırmak amacıyla sağlanan güvenilir ve detaylı verilerden oluşmaktadır.
- Meteorolojik veriler, hidroelektrik enerji üretimi üzerinde önemli bir etkiye sahiptir ve bu nedenle doğru bir şekilde toplanması ve kullanılması gerekmektedir [50, 51].
- Sıcaklık, radyasyon, nem, rüzgâr, yağış ve kısa dalga radyasyonunu içeren Meteorolojik değişkenler MERRA-2 veri setlerinden alınmıştır.
- Veriler Python scripti ile toplanmış olup, GES DISC portalı 2020, 2021, 2022 ve 2023 yılları için hava durumu verilerini almak amacıyla kullanılmıştır [52].
- Takvim değişkenleri ay, hafta, gün, saat ve gün tipi olarak belirlenmiştir. Bu değişkenler, enerji üretiminin zaman içindeki değişimlerini anlamak ve tahmin modeline dahil etmek için kullanılmıştır. Bu tür değişkenler, modelin doğruluğunu artırmak için önemli katkılar sağlamaktadır.
- 35064 örnek ve 16 değişkenden oluşan veri seti, 0,8/0,2 oranıyla eğitim ve test kümelerine ayrılmıştır. Değişkenler standartlaştırıldı ve eksik değerler ve NA değerleri düzeltildi.



Şekil 4. Aylık üretilen enerji miktarları

3.2. Metot

XGBoost (Extreme Gradient Boosting) algoritması yapılandırılmış verilerin işlenmesindeki hızı nedeniyle bu çalışma için seçilmiştir.

XGBoost, yüksek performans, esneklik ve taşınabilirlik sunmak üzere optimize edilmiş, açık kaynak kodlu bir gradyan artırma kütüphanesidir. Bu kütüphane, gradyan artırma çerçevesinde makine öğrenimi algoritmalarını uygular. XGBoost, paralel ağaç artırma (GBDT - Gradient Boosted Decision Trees veya GBM - Gradient Boosting Machines olarak da bilinir) yöntemiyle birçok veri bilimi problemini hızlı ve doğru bir şekilde çözüme yeteneğine sahiptir [53].

Regresyon, sınıflandırma, sıralama ve kullanıcı tanımlı tahmin problemlerinin çözümünde kullanılabilir. Platformlar arası uyumluluğu vardır. Windows, Linux ve OS X gibi farklı işletim sistemlerinde sorunsuz çalışır. Programlama dili desteği vardır. C++, Python, R, Java, Scala ve Julia gibi başlıca programlama dillerini destekler [54].


XGBoost, yüksek ölçeklenebilirlik için tasarlanmış, gradyan artırma tabanlı bir karar ağacı topluluğudur ve minimal kaynak kullanımıyla pratik uygulama ölçeğindeki sorunları çözüme kapasitesine sahiptir [10].

XGBoost, çeşitli tahmine dayalı modelleme görevlerindeki etkinliği ile yaygın olarak tanınan ağaç güçlendirmeye yönelik ölçeklenebilir bir makine öğrenimi sistemidir. XGBoost, denetimli öğrenme için kullanılan en iyi performans gösteren algoritmalarından biri olarak bilinen gradyan artırma makinelerinin (GBM) uygulamalarından biridir. Hem regresyon hem de sınıflandırma problemleri için kullanılabilir [12-15].

XGBoost, bir kayıp fonksiyonunu minimize ederek amaç fonksiyonunun eklemeli genişlemesini oluşturur. XGBoost, yalnızca karar ağaçlarını temel sınıflandırıcı olarak kullanması nedeniyle, ağaçların karmaşıklığını yönetmek için değiştirilmiş bir kayıp fonksiyonu kullanılır.

Bir ağaç topluluk modeli, n örnek ve m özellik içeren bir veri kümesi ile K eklemeli fonksiyon kullanarak çıktığı tahmin eder.

$$\hat{y}_i = \phi(x_i) = \sum_{k=1}^K f_k(x_i), f_k \in \mathcal{F} \quad (1)$$



Şekil 5. XGBoost çalışma konsepti

\hat{y}_i tahmin edilen değeri, f_k k . ağaç modelini, x_i girdi özelliğini, K ağaç sayısını ve \mathcal{F} ağaçları içeren fonksiyonel alanı ifade eder. XGBoost'taki amaç fonksiyonu, bir düzenleme terimi içerir.

$$\mathcal{L}(\phi) = \sum_{i=1}^K l(\hat{y}_i, y_i) + \sum_{i=1}^K \Omega(f_k) \quad (2)$$

l tahmin edilen \hat{y}_i ile y_i arasındaki farkı ölçen türevlenebilir bir kayıp fonksiyonudur. İkinci terim ise modelin karmaşıklığını derecelendirir [10].

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (3)$$

T ağacın yaprak sayısını ve w yaprakların çıktı skorlarını ifade eder. Bu kayıp fonksiyonu, karar ağaçlarının bölme kriterine entegre edilerek bir ön budama stratejisine yol açar. Daha yüksek λ değerleri, daha basit ağaçlarla sonuçlanır. γ değeri, bir iç düğümü bölmek için gereken minimum kayıp azaltma kazancını kontrol eder. Ağaçların karmaşıklığı, ağaçların derinliği gibi diğer stratejiler kullanılarak da sınırlanabilir.

Ağaç karmaşıklığının azaltılmasının bir başka avantajı, modellerin daha hızlı eğitilebilmesi ve daha az depolama alanı gerektirmesidir. XGBoost'ta, aşırı öğrenmeyi azaltmak ve eğitim süresini kısaltmak için rastgeleştirme teknikleri de kullanılır.

4. BULGULAR VE TARTIŞMA

XGBoost modeli hazırlanan veri seti ile eğitilmiştir. Modeli optimize etmek ve sonuçları karşılaştırmak için ağaç sayısı olarak 50, 100, 200, 300, 400, 500, 600, 700, 800, 900, 1000 değerleri ve öğrenme oranı olarak 0.05, 0.10, 0.15, ..., 0.90, 0.95, 1.00 değerleri kullanılmıştır. Bu model varyasyonlarının değerlendirilmesi, hidroelektrik enerji üretiminin tahmin edilmesindeki doğruluk ve güvenilirliklerinin karşılaştırılmasını içermektedir. Çalışmanın performansı çeşitli istatistiksel performans ölçütleri ve hata metrikleri kullanılarak değerlendirilmiştir:

- **Belirleme Katsayısı (R²):** Bağımsız değişkenlerden tahmin edilebilen bağımlı değişkendeki varyans oranını ölçer.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

- **Kök Ortalama Karesel Hata (RMSE):** Tahmin edilen ve gözlemlenen değerler arasındaki karesel farkların ortalamasının karekökü.

$$nRMSE = \frac{100}{\max(y_i) - \min(y_i)} \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

- **Ortalama Mutlak Hata (MAE):** Tahmin edilen ve gözlemlenen değerler arasındaki mutlak farkların ortalaması.

$$MAE = \frac{100}{\max(y_i) - \min(y_i)} \quad (6)$$

- **Ortalama Mutlak Ölçekli Hata (MASE):** Verilerin ölçeğini hesaba katan ortalama mutlak hatanın ölçeklendirilmiş bir versiyonu.

$$MASE = \frac{MAE}{MAE_{naive}} \quad (7)$$

$$MAE_{naive} = \frac{1}{n-1} \sum_{i=1}^n |y_i - y_{i-1}| \quad (8)$$

- **Ağırlıklı Mutlak Yüzesel Hata (WAPE):** Mutlak yüzde hatalarını gerçek değerlere göre ağırlıklandırılan ve tahmin doğruluğunun normalleştirilmiş bir ölçüsünü sağlayan bir metrik.

$$WAPE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{\sum_{i=1}^n |y_i|} \quad (9)$$

Çizelge 1’de görüldüğü gibi R² ve RMSE sonuçları modelin doğruluk ve güvenilirliğini yansıtmaktadır. Yüksek R² ve düşük RMSE değerleri, modelin hidroelektrik enerji üretimini doğru bir şekilde tahmin edebildiğini göstermektedir. Özellikle, öğrenme oranı 0.1 ve ağaç sayısı 1000 olan model, en iyi performansı sergilemiştir.

Çizelge 1. Performans sonuçları

Öğrenme oranı	Ağaç sayısı	RMSE (MWh)	R ² (%)	MAE (MWh)	MASE	WAPE (%)	Hesaplama süresi (s)
0.1	1000	7.293	96.138	3.043	0.074	7.712	4.902
Ortalama	Ortalama	7.928	95.419	3.709	0.090	9.398	2.565

Çalışmanın sonuçları, XGBoost modelinin hidroelektrik enerji üretimini tahmin etmede etkili bir araç olduğunu göstermektedir. Farklı parametreler kullanılarak yapılan optimizasyonlar, modelin performansını önemli ölçüde iyileştirmiştir. Bu bulgular, hidroelektrik santrallerinin enerji üretim tahminlerinin doğruluğunu artırmak ve enerji planlaması süreçlerini iyileştirmek için kullanılabilir. Bulguların genel olarak enerji üretim tahmininde kullanılabilirliği, modelin doğruluk ve güvenilirliğine bağlıdır.

Bu çalışmada elde edilen sonuçlar, XGBoost modelinin pratik uygulamalarda kullanılabilir olduğunu ve enerji üretim tahminlerinde güvenilir sonuçlar sağladığını göstermektedir.


5. SONUÇLAR

Araştırma, hidroelektrik enerji üretimini doğru bir şekilde tahmin etmek için XGBoost gibi gelişmiş makine öğrenimi tekniklerinin potansiyelini ortaya koymaktadır. Çeşitli giriş parametrelerinin bütünleştirilmesi ve modelin performansının optimize edilmesiyle, stratejik enerji planlaması ve yönetimi için yüksek doğruluk seviyelerine ulaşmak mümkündür.

Bu yöntem, hidroelektrik santrallerinin verimli işletilmesini desteklerken, aynı zamanda karbon emisyonlarını azaltma ve çevresel dengeyi koruma gibi daha geniş hedeflere de katkı sağlamaktadır.

Çalışmanın bulguları, yenilenebilir enerji kaynaklarının öngörülebilirliğini ve güvenilirliğini artırmak için veri odaklı modellerin önemini vurgulamakta ve daha sürdürülebilir enerji sistemlerine geçişi desteklemektedir.

Araştırma, hidroelektrik enerji tahmini konusundaki anlayışımızı ilerletmekte ve enerji sektöründeki karar vericiler için pratik çözümler sunmaktadır. Yenilenebilir enerji kaynaklarına artan talebi karşılamak için tahmin modellerine XGBoost gibi makine öğrenmesi algoritmalarının entegrasyonu kritik öneme sahiptir. Gelecek araştırmalar, AI tabanlı algoritmalar ve optimizasyon tekniklerini daha da geliştirerek çeşitli operasyonel ortamlarda tahmin doğruluğunu artırmayı hedefleyebilir.



Şekil 6. R^2 ve RMSE sonuçları

6. KAYNAKLAR

1. T.C. Enerji ve Tabii Kaynaklar Bakanlığı, *Elektrik Bilgi Merkezi*, <https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik>, Erişim tarihi: 23.09.2024.
2. Acaroğlu, H., Kartal, H. M. & García Márquez, F. P. (2023). Testing the environmental Kuznets curve hypothesis in terms of ecological footprint and CO2 emissions through energy diversification for Turkey. *Environmental Science and Pollution Research*, 30(22), 63289-63304.

3. Cassagnole, M., Ramos, M.-H., Zalachori, I., Thirel, G., Garçon, R., Gailhard, J. & Ouillon, T. (2021). Impact of the quality of hydrological forecasts on the management and revenue of hydroelectric reservoirs – a conceptual approach. *Hydrology and Earth System Sciences*, 25(2), 1033-1052.
4. IEA, *Energy Statistics Data Browser*, <https://www.iea.org/data-and-statistics/data-tools/energy-statistics-data-browser>, Erişim tarihi: 20.09.2024.
5. EÜAŞ Aslantaş HES. <https://www.euas.gov.tr/santraller/aslantas-hes>. Erişim tarihi: 20.09.2024.
6. Hamel, P., Bremer, L.L., Ponette-González, A.G., Acosta, E., Fisher, J.R.B., Steele, B., Cavassani, A. T., Blanski, E. & Brauman, K.A. (2020). The value of hydrologic information for watershed management programs: The case of Camboriú, Brazil. *Science of The Total Environment*, 705, 135871.
7. Ercüment Beyhun, N., Altıntaş, K.H. & Noji, E. (2005). Analysis of registered floods in Turkey. *International Journal of Disaster Medicine*, 3(1-4), 50-54.
8. O'Connor, R.E., Yarnal, B., Dow, K., Jocoy, C.L. & Carbone, G.J. (2005). Feeling at risk matters: water managers and the decision to use forecasts. *Risk Analysis*, 25(5), 1265-1275.
9. Özesmi, U. & Özesmi, S. (2003). A participatory approach to ecosystem conservation: fuzzy cognitive maps and stakeholder group analysis in uluabat lake, Turkey. *Environmental Management*, 31(4), 518-531
10. Chen, T. & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794. New York, NY, USA: ACM.
11. Anghileri, D., Monhart, S., Zhou, C., Bogner, K., Castelletti, A., Burlando, P. & Zappa, M. (2019). The Value of Subseasonal Hydrometeorological Forecasts to Hydropower Operations: How Much Does Preprocessing Matter? *Water Resources Research*, 55(12), 10159-10178.
12. Kumar, V., Kedam, N., Sharma, K.V., Mehta, D.J. & Caloiero, T. (2023). Advanced machine learning techniques to improve hydrological prediction: a comparative analysis of streamflow prediction models. *Water*, 15(14), 2572.
13. Szczepanek, R. (2022). Daily streamflow forecasting in mountainous catchment using XGBoost, LightGBM and CatBoost. *Hydrology*, 9(12), 226.
14. Tayfur, G., Singh, V., Moramarco, T. & Barbetta, S. (2018). Flood hydrograph prediction using machine learning methods. *Water*, 10(8), 968.
15. Hao, R. & Bai, Z. (2023). Comparative study for daily streamflow simulation with different machine learning methods. *Water*, 15(6), 1179.
16. Zhang, D., Qian, L., Mao, B., Huang, C., Huang, B. & Si, Y. (2018). A Data-driven design for fault detection of wind turbines using random forests and XGBoost. *IEEE Access*, 6, 21020-21031.
17. Liu, Y., Luo, H., Zhao, B., Zhao, X. & Han, Z. (2018). Short-term power load forecasting based on clustering and XGBoost method. *2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS)*, Beijing, China.
18. Zheng, H. & Wu, Y. (2019). A XGBoost model with weather similarity analysis and feature engineering for short-term wind power forecasting. *Applied Sciences*, 9(15), 3019.
19. Abbasi, R.A., Javaid, N., Ghuman, M.N.J., Khan, Z.A., Ur Rehman, S. & Amanullah (2019). Short term load forecasting using XGBoost, 1120-1131.
20. Suo, G., Song, L., Dou, Y. & Cui, Z. (2019). Multi-dimensional short-term load forecasting based on XGBoost and fireworks algorithm. *2019 18th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES)*, Wuhan, China.
21. Li, C., Chen, Z., Liu, J., Li, D., Gao, X., Di, F., Li, L. & Ji, X. (2019). Power load forecasting based on the combined model of LSTM and XGBoost. *PRAI '19: Proceedings of the 2019 the International Conference on Pattern Recognition and Artificial Intelligence*, New York, NY, USA: ACM.
22. Liao, X., Cao, N., Li, M. & Kang, X. (2019). Research on short-term load forecasting using XGBoost based on similar days. *2019 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS)*, 675-678, Changsha, China.
23. Guo, X., Gao, Y., Zheng, D., Ning, Y. & Zhao, Q. (2020). Study on short-term photovoltaic power prediction model based on the Stacking ensemble learning. *Energy Reports*.
24. Phan, Q.-T., Wu, Y.-K. & Phan, Q.-D. (2020). A comparative analysis of XGBoost and temporal convolutional network models for wind power forecasting.
25. Al Rayess, H.M. & Ülke Keskin, A. (2021). Forecasting the hydroelectric power generation of GCMs using machine learning techniques and deep learning (Almus Dam, Turkey). *Geofizika*, 38(1), 1-14.
26. Zhang, K., Gu, C., Gu, C., Zhu, Y., Chen, S., Dai, B. & Li, Y. (2021). A novel seepage behavior prediction and lag process identification method for concrete dams using HGWO-XGBoost model. *IEEE Access*.

27. Ma, M., Zhao, G., He, B., Li, Q., Dong, H., Wang, S. & Wang, Z. (2021). XGBoost-based method for flash flood risk assessment. *Journal of Hydrology*, 598, 126382.
28. Osman, A.I.A., Ahmed, A.N., Chow, M.F., Huang, Y.F. & El-Shafie, A. (2021). Extreme gradient boosting (XGBoost) model to predict the groundwater levels in Selangor Malaysia. *Ain Shams Engineering Journal*.
29. Zhang, W., Wei, Z., Wang, H., Hanyong, W., Lin, Y., Yemin, L., Liu, W. & An, X. (2021). Reservoir inflow predicting model based on machine learning algorithm via multi-model fusion: A case study of Jinshuitan river basin. *IET Cyber-Systems and Robotics*.
30. Bae, D.-J., Kwon, B.-S. & Song, K.-B. (2021). XGBoost-based day-ahead load forecasting algorithm considering behind-the-meter solar PV generation. *Energies*, 15(1), 128.
31. Wang, Y., Sun, S., Chen, X., Zeng, X., Kong, Y., Chen, J., Guo, Y. & Wang, T. (2021). Short-term load forecasting of industrial customers based on SVM and XGBoost. *International Journal of Electrical Power & Energy Systems*.
32. Phan, Q.-T., Wu, Y.-K. & Phan, Q.-D. (2021). Short-term solar power forecasting using XGBoost with numerical weather prediction. *IEEE International Future Energy Electronics Conference*, Taipei, Taiwan.
33. Phan, Q.T., Wu, Y.K. & Phan, Q.D. (2021). A hybrid wind power forecasting model with XGBoost, data preprocessing considering different NWP. *Applied Sciences*, 11(3), 1100.
34. Wang, B., Li, T., Xu, N., Zhou, H., Xiong, Z. & Long, W. (2021). A novel reservoir modeling method based on improved hierarchical XGBoost. *2021 IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, Chongqing, China.
35. Udo, W. & Muhammad, Y. (2021). Data-driven predictive maintenance of wind turbine based on SCADA data. *IEEE Access*, 9, 162370-162388.
36. Chen, Z., Xiao, J., Chen, S., Qiao, H., Chen, J. & Xu, X. (2022). Shaft run-out trend prediction of water turbine generators and fault identification of hydroelectric units based on XGBoost algorithm. *International Conference on Measuring Technology and Mechatronics Automation*, Changsha, China.
37. Fan, L., Wang, Y., Fang, X. & Jiang, J. (2022). To predict the power generation based on machine learning method. *Journal of Physics: Conference Series*, 2310(1), 012084.
38. Singh, U. & Rizwan, M. (2022). SCADA system dataset exploration and machine learning based forecast for wind turbines. *Results in Engineering*, 16, 100640.
39. Xue, J., Hu, X., Chen, H. & Zhou, G. (2022). Research on LSTM-XGBoost integrated model of photovoltaic power forecasting system.
40. Mohamed, M., Mahmood, F.E., Abd, M.A., Chandra, A. & Singh, B. (2022). Dynamic forecasting of solar energy microgrid systems using feature engineering. *IEEE Transactions on Industry Applications*, 58(6), 7857-7869.
41. Xiong, X., Guo, X., Zeng, P., Zou, R. & Wang, X. (2022). A short-term wind power forecast method via XGBoost hyper-parameters optimization. *Frontiers in Energy Research*, 10.
42. Wang, J., Gao, Z. & Ma, Y. (2022). Prediction model of hydropower generation and its economic benefits based on EEMD-ADAM-GRU fusion model. *Water*, 14(23), 3896.
43. Hong, Y., Yang, J., Yang, Z. & Yan, J. (2023). PV power prediction based on XGBoost algorithm. *2023 IEEE 5th International Conference on Civil Aviation Safety and Information Technology (ICCASIT)*, 930-933. IEEE.
44. Zou, Y., Chen, H., Zhang, Y., Wang, Z., Pang, L., Lan, X., Yitong, Z., Wang, B. & Peng, R. (2023). Multimode hydropower power prediction based on long short-term memory. *Sixth International Conference on Computer Information Science and Application Technology (CISAT 2023)*, Hangzhou, China.
45. Tran, N.T., Tran, T.T.G., Nguyen, T.A. & Lam, M.B. (2023). A new grid search algorithm based on XGBoost model for load forecasting. *Bulletin of Electrical Engineering and Informatics*, 12(4), 1857-1866.
46. Sun, S., Xing, J., Cheng, Y., Yu, P., Wang, Y., Yang, S. & Wang, S. (2023). Features analysis and prediction of electric load based on clustering and XGBoost. *Second International Conference on Energy, Power, and Electrical Technology (ICEPET 2023)*, Kuala Lumpur, Malaysia.
47. Wu, Y., Xie, Y., Xu, F., Zhu, X. & Liu, S. (2024). A runoff-based hydroelectricity prediction method based on meteorological similar days and XGBoost model. *Frontiers in Energy Research*, 11.
48. Bashir, S.B., Farag, M.M., Hamid, A.K., Adam, A.A., Abo-Khalil, A.G. & Bansal, R. (2024). A novel hybrid CNN-XGBoost model for photovoltaic system power forecasting. *2024 6th International Youth Conference on Radio Electronics, Electrical and Power Engineering*, Moscow, Russian Federation.

49. EPIAŞ, *Şeffaflık Platformu Gerçek Zamanlı Elektrik Üretim Verisi*, <https://seffaflik.epias.com.tr/electricity/electricity-generation/ex-post-generation/real-time-generation>, Erişim tarihi: 23.09.2024.
50. Global Modeling and Assimilation Office (GMAO) (2015). *MERRA-2 inst1_2d_asm_Nx: 2d, 1-Hourly, Instantaneous, Single-Level, Assimilation, Single-Level Diagnostics V5.12.4*. Greenbelt, MD, USA: Goddard Earth Sciences Data and Information Services Center (GES DISC). Erişim tarihi: 23.09.2024.
51. Global Modeling and Assimilation Office (GMAO) (2015). *MERRA-2 tavg1_2d_rad_Nx: 2d, 1-Hourly, Time-Averaged, Single-Level, Assimilation, Radiation Diagnostics V5.12.4*. Greenbelt, MD, USA: Goddard Earth Sciences Data and Information Services Center (GES DISC). Erişim tarihi: 23.09.2024.
52. Aiken, E. (2018). *Script to download data from MERRA-2 database based on lat/lon coordinates*. Github. <https://github.com/emilylaiken/merradownload>, Erişim tarihi: 01.03.2024.
53. DMLC, *eXtreme Gradient Boosting*. Distributed (Deep) Machine Learning Community, <https://github.com/dmlc/xgboost>, Erişim tarihi: 28.05.2024.
54. Morde, V. & Setty, A., *XGBoost Algorithm: Long May She Reign! Towards Data Science*. <https://towardsdatascience.com/https-medium-com-vishalmorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d>, Erişim tarihi: 23.09.2024.