



Araştırma Makalesi/Research Article

Kırşehir yöresindeki fotovoltaik güç santrallerinin uzun dönemli performans analizi ve yapay zeka tabanlı verim tahminlemesi

Long-term performance analysis and ai-based yield prediction of photovoltaic

Büşra Durmaz^{1*}, Cavit Karakuş²

¹ Kırşehir Ahi Evran Üniversitesi, Makine Mühendisliği Bölümü, busra.durmaz@ahievran.edu.tr
ORCID: <https://orcid.org/0000-0001-6659-1067>

² Kırşehir Ahi Evran Üniversitesi, İleri Teknolojiler Ana Bilim Dalı, karakus.cavit@ogr.ahievran.edu.tr
ORCID: <https://orcid.org/0009-0002-7702-3975>

MAKALE BİLGİLERİ

Makale Geçmişi:

Geliş 27 Ekim 2025
Revizyon 25 Kasım 2025
Kabul 1 Aralık 2025
Online 25 Mart 2026

Anahtar Kelimeler:

Fotovoltaik (PV) Güç Santrali,
Performans Analizi, Yapay Zeka
(AI), Rastgele Orman Regresyonu,
Kırşehir, Yenilenebilir Enerji

ÖZ

Bu çalışmada, Türkiye'nin İç Anadolu Bölgesi'nde yer alan Kırşehir yöresindeki dokuz adet fotovoltaik (PV) güç santralinin beş yıllık (2020-2025) üretim performansı, yapay zeka teknikleri kullanılarak detaylı bir şekilde analiz edilmiştir. Çalışmanın temel amacı, santral performansını etkileyen kritik meteorolojik faktörleri belirlemek, santraller arasında verimlilik ve istikrar (volatilité) açısından karşılaştırmalar yapmak ve geleceğe yönelik bir üretim tahmin modeli geliştirmektir. Bu hedefler doğrultusunda, santrallerin günlük üretim verileri, yüksek çözünürlüklü güneş radyasyonu, sıcaklık, bulutluluk oranı gibi meteorolojik verilerle entegre edilmiştir. Enerji üretimini modellemek ve tahmin etmek için güçlü bir makine öğrenmesi algoritması olan Rastgele Orman (Random Forest) regresyon modeli kullanılarak eğitilmiştir. Analiz sonuçları, güneş radyasyonunun üretim üzerindeki en baskın faktör olduğunu, bunu mevsimsel döngünün ve bulutluluk oranının takip ettiğini ortaya koymuştur. Santraller arası karşılaştırmalı analizler, normalize edilmiş verimlilik ve üretim istikrarı açısından önemli farklılıklar olduğunu göstermiştir. Geliştirilen modelin, anormal üretim günlerini tespit etme ve gelecek yıllara yönelik senaryo bazlı üretim tahminleri oluşturmada başarılı olduğu kanıtlanmıştır. Bu çalışma, çoklu santral performansının yapay zeka ile karşılaştırmalı analizine yönelik kapsamlı bir vaka analizi sunarak, PV santral operatörleri, yatırımcılar ve politika yapıcılar için veri odaklı, değerli içgörüler sağlamaktadır.

ARTICLE INFO

Article history:

Received 27 October 2025
Received in revised form 25 November 2025
Accepted 1 December 2025
Available online 25 March 2026

Keywords:

Photovoltaic (PV) Power Plant,
Performance Analysis, Artificial
Intelligence (AI), Random Forest
Regression, Kırşehir, Renewable
Energy

ABSTRACT

In this study, the five-year (2020-2025) production performance of nine photovoltaic (PV) power plants, located in the Kırşehir province of Turkey's Central Anatolia Region, is comprehensively analyzed using artificial intelligence (AI) techniques. The primary objective of this research is to identify the critical meteorological factors influencing plant performance, conduct comparative analyses among the plants regarding efficiency and stability (volatility), and develop a predictive model for future generation forecasting. To achieve these objectives, daily production data from the plants were integrated with meteorological data, including high-resolution solar radiation, temperature, and cloud cover. A robust machine learning algorithm, the Random Forest (RF) regression model, was trained to model and predict energy generation. The analysis results revealed that solar radiation is the most dominant factor influencing production, followed by seasonal cycles and cloud cover. Inter-plant comparative analyses demonstrated significant differences in terms of normalized efficiency and production stability. The developed model proved successful in identifying anomalous production days and generating scenario-based generation forecasts for future years. This research presents a comprehensive case study on the comparative analysis of multi-plant performance using AI, providing data-driven, valuable insights for PV plant operators, investors, and policymakers.

Doi: 10.24012/dumf.1811715

* Sorumlu Yazar

Giriş

Türkiye, son yirmi yılda sergilediği hızlı ekonomik ve nüfus artışına paralel olarak, enerji talebinde de dikkate değer bir artış yaşamıştır [1]. Ülkenin enerji arz güvenliğini ulusal stratejisinin merkezine yerleştirmesi, büyük ölçüde enerji ithalatına olan yüksek bağımlılıktan kaynaklanmaktadır. Mevcut durumda, enerji tüketiminin yaklaşık %75'inin ithal kaynaklarla karşılandığı bir ortamda, Türkiye'nin enerji portföyünü çeşitlendirmesi ve yerli kaynakların kullanımını maksimize etmesi stratejik bir zorunluluk haline gelmiştir. Bu bağlamda, yenilenebilir enerji kaynakları, hem enerji arz güvenliğini artırma hem de sürdürülebilir ekonomik kalkınmayı destekleme potansiyeliyle ön plana çıkmaktadır [2].

Türkiye, sahip olduğu yüksek güneşlenme potansiyeli sayesinde bu dönüşümün merkezine fotovoltaik (PV) sistemleri yerleştirmiştir [3]. Ülke, özellikle son yıllarda güneş enerjisi kurulu gücünü hızla artırarak 2025 hedeflerine bir buçuk yıl öncesinden ulaşmış ve Uluslararası Yenilenebilir Enerji Ajansı'nın (IRENA) sıralamasında dünyanın en büyük 11. yenilenebilir enerji kapasitesine sahip ülkesi konumuna yükselmiştir [4]. Bu başarının temelinde, Türkiye'nin Ulusal Enerji Planı'nda (UEP) yer alan ve 2035 yılına kadar güneş enerjisi kurulu gücünü 52,9 GW'a çıkarma hedefleri yatmaktadır [5]. Bu iddialı hedef, önümüzdeki on yıl içinde milyarlarca dolarlık yeni yatırım gerektirecektir.

Bu büyük ölçekli yatırımların finansal ve teknik sürdürülebilirliği, PV santrallerin gerçek dünya koşullarındaki uzun dönemli performansının, verimlilik kayıplarının ve zamanla oluşan performans düşüşünün (degradasyon) doğru bir şekilde analiz edilmesine bağlıdır. Bu bağlamda, yapay zeka (YZ) ve makine öğrenimi gibi ileri teknolojilerin enerji sektöründe uygulanması, sistemlerin verimliliğini ve güvenilirliğini artırmak için hayati bir araç haline gelmiştir [6]. YZ tabanlı modeller, karmaşık operasyonel verileri işleyerek performans düşüşünü daha hassas bir şekilde tahmin edebilir ve olası arızaları önceden tespit edebilir.

Kırşehir ili, yüksek güneş radyasyonu değerleri nedeniyle fotovoltaik enerji üretimi için ideal bir bölge olup, burada kurulu santrallerin performans analizi bu bağlamda büyük önem taşımaktadır. Bu çalışma, Kırşehir yöresindeki PV santrallerinin uzun dönemli performans verilerini değerlendirerek, geleneksel yöntemlerin yanı sıra YZ tabanlı yaklaşımlar kullanarak santral verimini daha doğru bir şekilde tahminlemeyi ve operasyonel riskleri modellemeyi amaçlamaktadır. Elde edilecek sonuçlar, gelecekteki enerji yatırımları için yol gösterici olacak ve bölgedeki yenilenebilir enerji projelerinin optimizasyonuna önemli katkılar sağlayacaktır.

Literatür Taraması

Bu çalışma, küresel ve ulusal enerji stratejilerinde kritik öneme sahip olan fotovoltaik (PV) sistemlerin performansı, yenilenebilir enerji sektöründe yapay zekâ (YZ) uygulamaları ve bölgesel saha çalışmalarını kapsayan geniş bir bilimsel zemine dayanmaktadır. Türkiye'nin 2035 yılına kadar 52,9 GW'a ulaşma hedefi gibi iddialı taahhütleri göz önüne alındığında, PV santrallerinin operasyonel verimliliğinin ve yatırım geri dönüşünün uzun dönemli ve doğru bir şekilde değerlendirilmesi zorunlu hale gelmiştir. Mevcut literatür, PV sistemlerin performansını değerlendirmek için Performans Rasyosu (PR) gibi klasik mühendislik metriklerinin kullanımı [7] ve çevresel faktörlerin [8] sistem üzerindeki etkisini inceleyen çalışmalarla zenginleşmiştir.

Ancak, geleneksel deterministik modellere ek olarak, son yıllarda makine öğrenmesi (ML) teknikleri, enerji sistemlerindeki karmaşık, doğrusal olmayan ilişkileri modellemedeki üstünlüğü ile öne çıkmıştır [9]. Literatürde, YSA ve ARIMA gibi metotların birleştirilmesiyle oluşturulan melez tahmin modellerinin geliştirilmesi [10] ve kısa dönemli güç tahmini için yenilikçi hibrit modellerin analizi [11] dikkat çekmektedir. ML algoritmaları, meteorolojik veriler kullanılarak güneş enerjisi üretiminin tahmininde [12] ve sistem çıkış gücünün belirlenmesinde [13] yüksek doğruluk oranları sergilemiştir. Bu modellerin başarısı, karmaşık zaman serisi verilerinde [14] ve meteorolojik tahminlerde [15] dahi kanıtlanmıştır. Özellikle Random Forest gibi topluluk öğrenme (ensemble) yöntemleri, yüksek tahmin gücü sayesinde lityum iyon bataryaların degradasyon analizi [16] ve genel kestirim çalışmalarında [17] güvenilir bir araç olarak benimsenmiştir.

Fotovoltaik sistemlerde yapay zeka uygulamaları incelendiğinde, literatürde öncü bir yere sahip olan Coşkun ve ark. (2016) tarafından gerçekleştirilen çalışma, PV modül yüzey sıcaklığının Yapay Sinir Ağları (YSA) ile kestirilmesi konusunda yüksek doğruluklu ve kritik sonuçlar ortaya koymuştur. Bu çalışma, sıcaklık kaynaklı verim kayıplarının modellenmesinde araştırmacılar için temel bir referans niteliğindedir [18]. Benzer şekilde, ölçüm verisine erişimin kısıtlı olduğu sahalar için Coşkun ve Oktay (2019) tarafından geliştirilen yenilikçi ve ileri hesaplama yöntemi, sentetik saatlik güneş enerjisi verilerinin türetilmesinde son derece pratik ve güçlü bir metodoloji sunarak literatürdeki önemli bir boşluğu doldurmuştur [19]. Bu değerli çalışmalar literatüre önemli analitik araçlar kazandırmış olmakla birlikte, bu makalede analizler doğrudan saha ölçümlerine dayanan gerçek SCADA verileri üzerinden kurgulanmıştır.

Literatürdeki çalışmalar genellikle tek bir santralin veya kısa bir zaman diliminin analizine odaklanmaktadır [20], [21]. Çoklu santral performansının ve Kırşehir gibi kendine has iklim özelliklerine sahip bir bölgedeki çevresel değişkenliğin (sıcaklık, bulutluluk) uzun dönemli (beş yıllık) verilerle karşılaştırmalı analizi konusunda ise kapsamlı bir vaka çalışması eksikliği mevcuttur. Bu çalışma, Random Forest regresyon modelini kullanarak bu boşluğu doldurmayı ve sadece uzun dönemli verim tahmini yapmakla kalmayıp, aynı zamanda dokuz farklı santralin normalize edilmiş

verimliliklerini karşılaştırarak operasyonel optimizasyona yönelik somut içgörüler sunmayı amaçlamaktadır.

Bu çalışmanın metodolojik ve analitik çerçevesini sağlamlaştırmak amacıyla, mevcut literatürde belirtilen temel kavramlar, FV sistem performansı, modül bozunması ve makine öğrenmesi paradigmaları aşağıdaki paragrafta özetlenmiştir.

Bir fotovoltaik (FV) güç santralinin etkinliğinin değerlendirilmesi, ham enerji üretim verilerinin ötesine geçen standartlaştırılmış metriklerin kullanılmasını gerektirir; bu bağlamda en kabul gören metrikler Nihai Verim (Yf), Referans Verim (Yr) ve tüm kayıpların kümülatif etkisini yansıtan ve farklı coğrafyalardaki tesislerin karşılaştırılmasına olanak tanıyan Performans Oranı (PR) ($PR=Yf/Yr$)'dır [22]. Santral performansı ise büyük ölçüde meteorolojik koşullara ve operasyonel duruma bağlıdır: Güneş Işınımı (GHI) üretimi belirleyen temel faktör olsa da, yüksek sıcaklıklar panel verimliliğini olumsuz etkileyerek, sıcaklık katsayısı ile ölçülen 10% -15% 'e varan anlık kayıplara neden olabilir [23]. Operasyonel kayıplar arasında, kurak bölgelerde kritik öneme sahip Kirlenme (Soiling) 30%'a varan kayıplara yol açabilirken, Gölgeleme ve İnvertör Kalitesi/Arızaları da performansı doğrudan etkileyen unsurlardır. FV sistemlerin uzun vadeli yatırımlar olması nedeniyle, modüllerin enerji üretim kapasitesinin zamanla azalması, yani bozunma (degradation) kritik öneme sahiptir; [24] kristal silisyum (c-Si) modüller için medyan yıllık bozunma oranı yaklaşık %0.5/yıl olup, başlıca bozunma türleri arasında Işık Kaynaklı Bozunma (LID) ve Potansiyel Kaynaklı Bozunma (PID) gibi fiziksel yaşlanma süreçleri yer almaktadır. Güneş enerjisi üretiminin doğal değişkenliği ve FV sistemlerini etkileyen faktörlerin karmaşıklığı karşısında, Makine Öğrenmesi (ML) modelleri güçlü analitik alternatifler sunmuştur [25]. ML modelleri, çok sayıda girdi değişkeni ile çıktı arasındaki karmaşık, doğrusal olmayan kalıpları öğrenebilir; bu çalışmada kullanılan Rastgele Orman (RF) algoritması, birden çok karar ağacını birleştirerek gürlü verilere karşı dayanıklı, hızlı ve güvenilir temel modeller oluşturmak için ideal bir seçenektir [12]. Son olarak, ML modellerinin rolü sadece tahminle sınırlı değildir; yüksek doğruluklu bir modelin tahmini ile gerçek üretim arasındaki farkın (artık) sürekli izlenmesi yoluyla gerçekleştirilen anomali tespiti, arızaların erken aşamada teşhisini mümkün kılarak, kestirimci bakım stratejilerinin temelini oluşturur ve santralin genel verimliliğini artırır [26].

Bu kapsamlı literatür değerlendirmesinin ardından, çalışmanın veri seti, modelleme yaklaşımı ve analiz adımları, bir sonraki bölüm olan Materyal ve Metot kısmında detaylı olarak sunulacaktır.

Materyal ve Metot (Materials and Methods)

Bu bölümde, Kırşehir yöresindeki fotovoltaik (PV) güç santrallerinin uzun dönemli performansını analiz etmek ve yapay zeka tabanlı verim tahmini modelini geliştirmek için kullanılan veri setleri, deneysel tasarım ve analitik metotlar detaylı bir şekilde açıklanmıştır. Çalışmanın tekrarlanabilirliğini ve bilimsel geçerliliğini sağlamak

amacıyla, seçilen dokuz adet santralin coğrafi ve teknik özellikleri, kullanılan meteorolojik ve operasyonel veri kaynakları, uygulanan veri ön işleme teknikleri ve enerji üretimini modellemek için eğitilen Rastgele Orman (Random Forest) regresyon algoritmasının mimari detayları alt başlıklar halinde sunulmuştur. Bu metodolojik çerçeve, bölgesel performans farklılıklarını anlamak ve yüksek doğruluklu tahminler için gerekli olan matematiksel temeli oluşturmaktadır.

Veri Seti ve Kaynaklar

Bu çalışmanın ampirik temelini, Kırşehir yöresinde faaliyet gösteren dokuz adet fotovoltaik (FV) güç santralinden toplanan uzun dönemli üretim verileri ile bu santrallerin konumuna özel yüksek çözünürlüklü meteorolojik veriler oluşturmaktadır.

- Santral Üretim Verileri: Analiz edilen dokuz santralin günlük toplam AC enerji üretim (kWh) verileri, santral operatörlerinden temin edilmiştir. Veri seti, 1 Ocak 2020 ile 31 Aralık 2024 arasındaki beş yıllık periyodu kapsamaktadır.
- Meteorolojik Veriler: Modelin girdi değişkenlerini oluşturan zaman serisi meteorolojik veriler, her bir santralin coğrafi koordinatları için Visual Crossing hava durumu servisinden API aracılığıyla temin edilmiştir. Modellemede kullanılan temel meteorolojik öznitelikler şunlardır:
 - Ortalama Hava Sıcaklığı (°C)
 - Toplam Yatay Güneş Radyasyonu (W/m²)
 - Ortalama Bağıl Nem (%)
 - Ortalama Rüzgar Hızı (km/s)
 - Ortalama Bulutluluk Oranı (%)

Veri Ön İşleme ve Özellik Mühendisliği

Ham verilerin analize ve modellemeye uygun hale getirilmesi için kapsamlı bir ön işleme ve özellik mühendisliği süreci uygulanmıştır.

- Veri Temizleme ve Birleştirme: Farklı kaynaklardan gelen üretim ve hava durumu verileri, TARİH ve SANTRAL anahtarları üzerinden birleştirilerek bütünlük bir veri matrisi oluşturulmuştur. Sayısal değişkenlerdeki ondalık ayrılar standart formata dönüştürülmüş ve tüm değişkenler uygun veri tiplerine atanmıştır.
- Zamansal ve Döngüsel Özelliklerin Türetilmesi: Makine öğrenmesi modelinin zamansal dinamikleri ve mevsimsel döngüleri yakalayabilmesi için TARİH değişkeninden YIL, AY, GÜN, HAFTANIN_GÜNÜ ve YILIN_GÜNÜ gibi yeni özellikler türetilmiştir. Bu zamansal özelliklerin döngüsel doğasını (örneğin, ayların periyodikliği) modele doğru bir şekilde aktarabilmek için sinüs ve kosinüs dönüşümleri uygulanarak döngüsel özellikler kodlanmıştır. Bu teknik, modelin zamanın periyodik yapısını daha iyi anlamasını sağlar.

değişkeninin tahmin üzerindeki kesin katkısını belirlemek için kullanılmıştır.

Analitik Metodoloji

- Santrallerin performansını karşılaştırmak ve üretimi etkileyen faktörleri modellemek için bir dizi istatistiksel ve makine öğrenmesi tekniği kullanılmıştır.

Performans Karşılaştırma Metrikleri:

- Değişim Katsayısı (Coefficient of Variation - CV): Her bir santralin üretim profilinin ne kadar istikrarlı veya dalgalı (volatil) olduğunu ölçmek için kullanılmıştır. Günlük üretimin standart sapmasının, ortalamasına bölünmesiyle hesaplanan bu boyutsuz ölçüt, operasyonel öngörülebilirlik açısından santralleri karşılaştırma imkanı sunar.

- Yapay Zeka Modellemesi (Rastgele Orman):**

- Model Seçimi: Çalışmanın ana tahmin modeli olarak Rastgele Orman (Random Forest) Regresyon algoritması seçilmiştir. Bu model, çok sayıda karar ağacını bir araya getirerek aşırı öğrenmeye karşı dayanıklılık, doğrusal olmayan karmaşık ilişkileri yakalayabilme ve hiperparametre ayarlarına daha az duyarlı olma gibi avantajları nedeniyle tercih edilmiştir.

- Özellik Önem Derecesi (Feature Importance): Modelin eğitilmesinin ardından, enerji üretimini etkileyen faktörlerin göreceli önemini belirlemek için Gini Önem Derecesi tabanlı özellik önem skorları hesaplanmıştır.

- Kısmi Bağımlılık Grafikleri (Partial Dependence Plots - PDP): Modelin "kara kutu" yapısını yorumlamak ve her bir özelliğin üretim üzerindeki marjinal etkisini görselleştirmek için Kısmi Bağımlılık Grafikleri kullanılmıştır. Bu grafikler, diğer tüm faktörler sabit tutulduğunda, tek bir özelliğin değerindeki değişimin modelin tahminini nasıl etkilediğini gösterir.

- SHAP (Shapley Additive Explanations) Analizi: Geleneksel önem skorlarına ve PDP'ye ek olarak, modelin yerel ve küresel şeffaflığını artırmak amacıyla gelişmiş SHAP analizi kullanılmıştır. Bu yöntem, oyun teorisine dayanarak, her bir özelliğin bireysel bir tahminin (örneğin tek bir günün üretiminin) ortalamadan ne kadar saptığını (pozitif veya negatif katkı) adil bir şekilde hesaplar. SHAP özeti ve bağımlılık grafikleri, modelin neden o tahmini yaptığını, her bir girdi


Bulgular ve Tartışma (Results and Discussion)

Bu bölümde, Kırşehir yöresindeki dokuz fotovoltaik santralin uzun dönemli performans analizleri ve yapay zeka modellemesi sonuçları sunulmakta ve yorumlanmaktadır.

Santrallerin Genel Performans Profilleri ve Karşılaştırması


Üretimin Mevsimsel ve Yıllık Dinamikleri

Santrallerin toplam üretim verileri incelendiğinde, beklendiği gibi güçlü bir mevsimsel döngü gözlemlenmektedir. Şekil 1'de sunulan yıllara göre aylık ortalama üretim profilleri, üretimin yaz aylarında (Haziran, Temmuz, Ağustos) zirve yaptığını ve kış aylarında (Aralık, Ocak) en düşük seviyelere indiğini açıkça ortaya koymaktadır. Bu durum, bölgenin güneşlenme süresi ve ışınlam yoğunluğundaki mevsimsel değişimlerle doğrudan ilişkilidir.



Şekil 1. Yıllara Göre Aylık Ortalama PV Santral Üretim Profilleri (kWh)

Yıllar arası üretim değişimlerini inceleyen Şekil 2'deki ısı haritası, 2021 yılının bir önceki yıla göre tüm santraller için bir büyüme yılı olduğunu göstermektedir (pozitif değişim). Ancak 2022, 2023 ve 2024 yıllarında, bir önceki yıla göre genel olarak bir üretim düşüşü (negatif değişim, kırmızı tonlar) yaşanmıştır. Özellikle YİRMIÜÇ ve ÜÇGEN 8 santrallerinde 2023 yılında görülen %5'in üzerindeki keskin düşüşler dikkat çekmektedir. Bu bulgu, bölgedeki meteorolojik koşulların yıldan yıla değişkenliğini ve/veya potansiyel panel bozunmasının (degradation) etkilerini yansıtır olabilir.




Şekil 2. Santrallerin Yıllık Üretim Değişim Oranları (Bir Önceki Yıla Göre %)

Operasyonel İstikrar ve Performans Sıralaması

Santrallerin sadece ürettiği enerji miktarı değil, aynı zamanda üretim istikrarı da operasyonel planlama ve şebeke dengeleme için kritik bir göstergedir. Değişim Katsayısı (CV) metriğine göre yapılan üretim volatilitesi analizi, santraller arasında önemli farklılıklar olduğunu göstermiştir. Örneğin, ÜÇGEN 7 ve ÜÇGEN 5 santralleri en düşük volatilitelere sahip olup, en istikrarlı üretim profillerini sergilemektedir. Diğer uçta ise ÜÇGEN 3 santrali, en yüksek CV değeri ile en dalgalı üretim karakteristiğine sahiptir.

Şekil 3'te gösterilen Santrallerin Yıllara Göre Performans Sıralaması Değişimi (Bump Chart), göreceli performans dinamiklerini görselleştirmektedir. Bu grafik, SOLARGIE ve ÜÇGEN 5 gibi santrallerin başlangıçta üst sıralarda yer aldığını gösterirken, ÜÇGEN 3'ün 2023-2024 yıllarında önemli bir sıçrama yaparak 1. sıraya yükseldiğini ortaya koymaktadır. Diğer taraftan, ÜÇGEN 7 santrali, tüm beş yıllık periyot boyunca tutarlı bir şekilde en alt sırada (9. sıra) yer almıştır. Bu tutarlı sıralamalar, santraller arasındaki tasarımsal, teknolojik veya operasyonel farklılıklara işaret etmektedir.



Şekil 3. PV Santrallerinin Yıllara Göre Performans Sıralaması Değişimi

Meteorolojik Faktörlerin Üretim Üzerindeki Etkisinin Modellenmesi

Geliştirilen Rastgele Orman modeli, üretim ile meteorolojik değişkenler arasındaki karmaşık ilişkileri yüksek bir doğrulukla modellemiştir.

Üretimi Etkileyen En Önemli Faktörler

Tablo 1'deki Değişkenler Arası Korelasyon Matrisi, üretimin meteorolojik faktörlerle olan temel ilişkilerini özetlemektedir. Güneş Radyasyonu (W/m^2) (0.572) ile üretim arasında güçlü ve pozitif bir ilişki gözlemlenirken, Ort. Bulutluluk Yüzdesi (-0.473) ve Ort. Nem Yüzdesi (-0.529) ile üretim arasında orta düzeyde negatif bir korelasyon bulunmaktadır. Hava Sıcaklığı ($^{\circ}C$) ile üretim arasındaki pozitif korelasyonun (0.462) altı çizilmelidir, ancak bu korelasyonun pozitif çıkması, sıcaklığın doğrudan radyasyon ile ilişkisinden (0.763) kaynaklanmakta ve modelin ileride göstereceği gibi tek başına verimlilik düşürücü etkisini gizlemektedir.

Değişkenler Arası Korelasyon Matrisi (Pearson Katsayıları)

	Üretim_kWh	DEM_Degeri	Hava_Sicaklik	Gunes_Radyasyonu_Wm2	Ort_Nem_Yuzde	Ort_Ruzgar_Hizi_kms	Ort_Bulutluluk_Yuzde
Üretim_kWh	1.0	0.264	0.462	0.572	-0.529	0.102	-0.473
DEM_Degeri	0.264	1.0	0.101	0.162	-0.123	0.07	-0.075
Hava_Sicaklik	0.462	0.101	1.0	0.763	-0.773	0.278	-0.497
Gunes_Radyasyonu_Wm2	0.572	0.162	0.763	1.0	-0.745	0.235	-0.577
Ort_Nem_Yuzde	-0.529	-0.123	-0.773	-0.745	1.0	-0.298	0.665
Ort_Ruzgar_Hizi_kms	0.102	0.07	0.278	0.235	-0.198	1.0	0.001
Ort_Bulutluluk_Yuzde	-0.473	-0.075	-0.577	-0.577	0.665	0.001	1.0


Tablo 1. Kullanılan Değişkenler Arası Korelasyon Matrisi (Pearson Katsayıları)

Modelin analizleri, enerji üretimini tahmin etmede en baskın faktörün, beklendiği gibi, Güneş Radyasyonu olduğunu kantitatif olarak doğrulamaktadır. İkinci en önemli faktörün SANTRAL olması, modelin her bir santralin kendine özgü içsel verimlilik ve performans karakteristiklerini (tasarım, bakım, bozunma) başarıyla öğrendiğini göstermektedir. Bu iki ana faktörün ardından Nem Oranı, Bulutluluk Oranı, Rüzgar Hızı ve Yılın Günü gibi meteorolojik ve zamansal değişkenler gelmektedir.

SHAP Analizi ile Model Şeffaflığı: Şekil 4'te sunulan SHAP özet grafiği, eğitilen Rastgele Orman regresyon modelinin Kırşehir yöresi PV santral üretim tahmini sürecindeki karar verme mekanizmasını şeffaf ve detaylı bir şekilde ortaya koymaktadır. Dikey eksen, model tahminine olan toplam katkılarına göre sıralanan özelliklerde, beklentilerle tam bir uyum içinde, Güneş Radyasyonu (W/m^2) açık ara en dominant ve önemli faktör olarak teyit edilmiştir. Yüksek radyasyon değerlerinin (kırmızı noktalar) tahmini daima pozitif yönde (>0 SHAP değeri) etkilemesi, bu değişkenin üretimle olan güçlü, tutarlı ve lineer pozitif ilişkisini kanıtlamaktadır. Güneş radyasyonunu, Ort. Bulutluluk Yüzdesi ve Ort. Nem Yüzdesi takip etmektedir. Özellikle bulutluluk için yüksek değerler (kırmızı) tahmini net bir şekilde negatif yöne çekmekte, bu da beklenen negatif korelasyonun model tarafından kusursuzca öğrenildiğini göstermektedir. Ayrıca, modelin mevsimsel döngüyü başarıyla yakaladığı görülmektedir; YILIN GÜNÜ

değişkeninin orta değerleri (yaz ayları) pozitif etki sağlarken, düşük ve yüksek uç değerler (kış ayları) tahmini negatif yönde etkilemektedir. En çarpıcı bulgulardan biri ise Ort. Sıcaklık (°C) değerlerindedir: Düşük sıcaklıklar negatif etki yaratırken, yüksek sıcaklıkların (kırmızı noktalar) hem pozitif hem de negatif etkilere sahip olması, sıcaklığın tek başına değil, radyasyon gibi diğer meteorolojik koşullarla etkileşim içinde olan karmaşık, non-linear bir rol üstlendiğini gösteren değerli bir bulgudur. Bu analiz, modelin hem temel fiziksel ilişkileri (radyasyon, bulutluluk) hem de karmaşık etkileşimleri (sıcaklık) başarıyla öğrendiğini kanıtlamaktadır.

Elde edilen bulgular literatürdeki benzer çalışmalarla karşılaştırıldığında, güneş radyasyonunun üretim üzerindeki dominant etkisi (Pearson katsayısı: 0.57), literatürde güneş enerjisi potansiyelini inceleyen [8] ve PV performans tahmininde radyasyonun birincil faktör olduğunu belirten [19] çalışmalarıyla tam bir uyum içerisinde. Ayrıca, SHAP analizi ile ortaya konulan yüksek sıcaklığın verim üzerindeki negatif baskısı, [21] tarafından belirtilen ve sıcaklık artışının PV panellerde %10-15 oranında verim kaybına yol açabileceğini öngören teorik bulguları, yapay zeka tabanlı ampirik verilerle doğrulamaktadır. Çalışmamızın, literatürdeki tekil santral analizlerinden farklı olarak, çoklu santral verisi kullanarak coğrafi mikro-değişkenliği modele dahil etmesi, modelin genelleştirme yeteneğini artıran özgün bir katkı olarak öne çıkmaktadır.



Şekil 4: PV Santral Üretim Tahmininde Kullanılan Seçili Özelliklerin Modele Küresel Etkisi


Faktörlerin Üretime Net Etkisi (PDP Analizi)

Modelin bireysel ve kümülatif faktör etkilerini derinlemesine inceleyen analizler, Güneş Radyasyonu ile üretim arasında güçlü ve neredeyse doğrusal pozitif bir ilişki olduğunu teyit etmektedir. Üretim, yılın ortasına (yaz aylarına) doğru en yüksek seviyesine ulaşırken, Bulutluluk Oranı üretim üzerinde belirgin bir negatif etkiye sahiptir. Hava Sıcaklığı ise daha karmaşık ve doğrusal olmayan bir ilişki sergilemektedir; aşırı sıcaklıkların fotovoltaik panellerin verimliliğini düşürme eğilimi, model tarafından yakalanmıştır.

Tahmin Performansı ve Belirsizlik Analizi

Toplam Üretim Tahmini ve Gelecek Senaryosu


Geliştirilen modelin tahminsel gücünü göstermek amacıyla, Şekil 5'te, tüm sistemin 2026 yılı aylık toplam üretim tahmini, son bilinen yıl olan 2024 gerçekleşen üretimi ile karşılaştırılmaktadır. Tahminler, 2026'da gerçekleşen 2024 üretimine kıyasla tüm aylarda pozitif bir artış eğilimi göstermektedir. Bu durum, modelin, bölgenin ortalama meteorolojik koşulları ve santrallerin mevcut performans/bozunma eğilimi dikkate alındığında, kümülatif olarak yıllık üretimin hafifçe artacağını öngördüğünü göstermektedir. En yüksek artışın Mayıs ayında (+1.8 %) beklenmesi, modelin ilkbahar aylarındaki optimal koşulları güçlü bir şekilde yakaladığını düşündürmektedir.



Şekil 5: Toplam Sistem Üretim Tahmini (2026) ile Gerçekleşen Üretimin (2024) Aylık Bazda Karşılaştırması (kWh)

Model Belirsizliğinin Ölçülmesi

Makine öğrenmesi tahminlerinin güvenilirliğini değerlendirmek için, Şekil 6'da gösterilen model tahmin belirsizliği (YİRMİALTİ santrali için Temmuz 2023 örneği) incelenmiştir. Bu grafik, model tahminini (kesikli kırmızı çizgi), gerçekleşen üretimi (siyah çizgi) ve tahminin %90 Güven Aralığını (açık kırmızı alan) göstermektedir. Modelin tahminleri, gerçekleşen üretimi yakından takip etmekte ve çoğu zaman güven aralığı içerisinde kalmaktadır. Ancak, özellikle 17 Temmuz ve 21 Temmuz gibi günlerde görülen geniş güven aralıkları, tahminin belirsizliğinin yükseldiği durumları (muhtemelen aşırı değişken hava koşulları veya üretim anormallikleri) açıkça işaret etmektedir. Modelin, tahmin aralığı ile birlikte sunulması, operasyonel risk yönetimini destekleyen önemli bir çıktıdır.



Şekil 6: Model Tahmin Belirsizliği ve %90 Güven Aralığı Örneği (YirmiAltı Santrali, Temmuz 2023)

Sonuç ve Öneriler

Bu çalışmada, Türkiye'nin İç Anadolu Bölgesi'ndeki Kırşehir yöresinde faaliyet gösteren dokuz adet fotovoltaik güç santralinin beş yıllık operasyonel performansı, zengin meteorolojik veriler ve ileri düzey Yapay Zeka (YZ) teknikleri kullanılarak kapsamlı bir şekilde analiz edilmiştir. Çalışmanın temel amaçları olan uzun dönemli performans değerlendirmesi ve Rastgele Orman (Random Forest) algoritmasına dayalı verim tahminlemesi başarıyla gerçekleştirilmiştir.

Elde edilen bulgular, Şekil 3'te görüldüğü üzere santraller arasında hem üretim istikrarı hem de yıllar içindeki göreceli performans sıralamaları açısından anlamlı farklılıklar olduğunu ortaya koymuştur. Bu farklılıklar, santrallerin teknolojik altyapıları, coğrafi mikroklimatik koşulları veya operasyonel yönetimlerindeki potansiyel farklılıklara işaret etmektedir. Ayrıca, uzun dönemli verilerin analiz edilmesi, santrallerin yıllar içinde bir önceki yıla göre ortalama üretim değişimlerinde düşüş eğilimi olduğunu göstermiştir.

SHAP analizi (Şekil 4) ile desteklenen modelleme sonuçları, Rastgele Orman modelinin günlük enerji üretimini etkileyen faktörleri yüksek bir doğrulukla modellemede başarılı olduğunu göstermiştir. Üretim verimini belirleyen en dominant faktörün Güneş Radyasyonu olduğu kantitatif olarak doğrulanmış; bunu santralin kendi içsel karakteristiği, nem oranı, bulutluluk ve mevsimsellik gibi faktörlerin takip ettiği anlaşılmıştır. Model yorumlama teknikleri (SHAP), sıcaklık gibi meteorolojik faktörlerin üretim üzerindeki karmaşık ve doğrusal olmayan etkilerini başarıyla yakaladığını kanıtlamıştır. Şekil 5 ve Şekil 6'da sunulan tahminler, geliştirilen modelin sadece mevcut performansı değil, aynı zamanda geleceğe yönelik aylık üretim senaryolarını güven aralıkları ile birlikte sunma yeteneğine sahip olduğunu göstermiştir.

Bu çalışma, Kırşehir gibi karasal iklime sahip bir bölgedeki çoklu santral performansının karşılaştırmalı analizine yönelik veri odaklı ve derinlemesine bir vaka analizi sunarak literatürdeki boşluğu doldurmaktadır. Geliştirilen model ve elde edilen bulgular, santral operatörlerine üretimlerini etkileyen temel dinamikleri anlama, anormallikleri tespit etme ve operasyonel verimliliği artırma konularında somut içgörüler sağlamaktadır. Ayrıca, bu analitik çerçeve, bölgedeki gelecekteki güneş enerjisi yatırımları için daha doğru fizibilite çalışmaları yapılmasına ve finansal risklerin daha iyi yönetilmesine olanak tanıyan güçlü bir karar destek altyapısı oluşturmaktadır.

Bu çalışmada sunulan metodolojik çerçeve ve Rastgele Orman tabanlı modelleme yaklaşımı, Kırşehir yöresindeki verilerle eğitilmiş olsa da, modelin mimarisi coğrafi kısıtlamalardan bağımsızdır. Modelde kullanılan güneş radyasyonu, sıcaklık ve bulutluluk gibi evrensel meteorolojik girdiler, bu yaklaşımın farklı iklim kuşaklarında veya farklı coğrafi bölgelerdeki fotovoltaik santrallere de kolaylıkla uyarlanabileceğini göstermektedir. Ancak, modelin başka bir bölgede (örneğin nem oranının çok daha yüksek olduğu kıyı şeridinde veya daha soğuk bir iklimde) yüksek doğrulukla çalışabilmesi için, o bölgenin yerel meteorolojik verileri ve santral geçmiş üretim verileri

ile yeniden eğitilmesi (re-training) gerekmektedir. Dolayısıyla, önerilen bu yaklaşım, gerekli yerel veri setleri sağlandığında küresel ölçekte herhangi bir PV santrali için genelleştirilebilir bir performans analiz aracı olarak kullanılabilir.

Gelecek çalışmalar, geliştirilen bu Rastgele Orman tahmin modelinin, Derin Öğrenme (LSTM) veya hibrit modellerle karşılaştırılarak kısa dönemli (saatlik) tahmin yeteneğinin test edilmesine odaklanabilir. Ayrıca, bozunma ve anomali analizi için, panel yüzeyindeki kirlilik seviyesini tahmin eden ek bir özellik, modelin kestirimci bakım yeteneğini daha da güçlendirmek amacıyla dahil edilebilir.

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.

Yazar Katkıları

Yazarlar makaleye eşit katkıda bulunmuşlardır.

Teşekkür

Bu çalışma, kapsamlı analizlerin gerçekleştirilebilmesi için kritik öneme sahip olan saha verilerinin sağlanması konusunda değerli katkılar almıştır. Yazarlar, Kırşehir ilinde yer alan PV santrallerine ait beş yıllık günlük üretim verilerini cömertçe paylaşan ve çalışmamızın veri odaklı temelini oluşturan Solargie Elektrik Üretim A.Ş. firmasına en içten şükranlarını sunar. Bu değerli veri desteği, çalışmanın bilimsel amaçlarına ulaşmasında belirleyici olmuştur.

Kaynaklar

- [1] International Energy Agency. (2021). *Turkey 2021 - Energy policy review*. IEA.
- [2] Wen, X., Shen, Q., Zheng, W., & Zhang, H. (2024). AI-driven solar energy generation and smart grid integration: A holistic approach to enhancing renewable energy efficiency. *Academia Nexus Journal*, 3(2).
- [3] Çeçen, M., Yavuz, C., Tırmıkçı, C. A., Sarıkaya, S., & Yanıkoğlu, E. (2022). Analysis and evaluation of distributed photovoltaic generation in electrical energy production and related regulations of Turkey. *Clean Technologies and Environmental Policy*, 24(5), 1321-1336.
- [4] Alparslan, U., & Yıldırım, A. (2023, 11 Aralık). *Türkiye can expand solar by 120 GW through rooftops*. Ember.
- [5] T.C. Enerji ve Tabii Kaynaklar Bakanlığı. (2022). *Türkiye ulusal enerji planı*.
- [6] Dellosa, J. T., & Palconit, E. C. (2021, Eylül). Artificial Intelligence (AI) in renewable energy systems: A condensed review of its applications and techniques. *2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe)* (ss. 1-6). IEEE.
- [7] Duffie, J. A., & Beckman, W. A. (2013). *Solar engineering of thermal processes*. John Wiley & Sons.

- [8] Assouline, D., Mohajeri, N., & Scartezzini, J. L. (2017). Quantifying rooftop photovoltaic solar energy potential: a machine learning approach. *Solar Energy*, 141, 278-296.
- [9] Jobayer, M., Shaikat, M. A. H., Rashid, M. N., & Hasan, M. R. (2023). A systematic review on predicting PV system parameters using machine learning. *Heliyon*, 9(6), e17446.
- [10] Reşat, H. G. (2020). Sürdürülebilir enerji yönetimi için yapay sinir ağları ve ARIMA metotları kullanılarak melez tahmin modelinin tasarlanması ve geliştirilmesi: Tütün endüstrisinde vaka çalışması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(3), 1129-1140.
- [11] Gün, A. R. (2023). *Kısa dönemli fotovoltaiik güç tahmini için geliştirilen yenilikçi bir hibrit modelin analizi ve uygulaması* [Doktora tezi, Bilecik Şeyh Edebali Üniversitesi].
- [12] Macit Sezikli, N. (2023). *Makine öğrenmesi yöntemiyle yenilenebilir güneş enerjisi üretiminin meteorolojik veriler kullanılarak tahmin analizi* [Yüksek lisans tezi, İstanbul Gelişim Üniversitesi].
- [13] Yüzer, E. Ö., Bozkurt, A., & Barutçu, İ. Ç. (2023). Fotovoltaiik sistem çıkış gücünün yapay sinir ağları ve MATLAB/Simulink modellerinin entegrasyonu ile belirlenmesi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 11(2), 551-563.
- [14] Arslankaya, S., & Toprak, Ş. (2021). Makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak hisse senedi fiyat tahmini. *International Journal of Engineering Research and Development*, 13(1), 178-192.
- [15] Turgut, A., Temir, A., Aksoy, B., & Özsoy, K. (2019). Yapay zekâ yöntemleri ile hava sıcaklığı tahmini için sistem tasarımı ve uygulaması. *International Journal of 3D Printing Technologies and Digital Industry*, 3(3), 244-253.
- [16] Wang, F. K., & Mamo, T. (2020). Gradient boosted regression model for the degradation analysis of prismatic cells. *Computers & Industrial Engineering*, 144, 106494.
- [17] Motamedi, B., & Villányi, B. (2024). A predictive analytics model with Bayesian-Optimized Ensemble Decision Trees for enhanced crop recommendation. *Decision Analytics Journal*, 12, 100516.
- [18] Coskun, C., Koçyiğit, N., & Oktay, Z. (2016). Estimation of pv module surface temperature using artificial neural networks. *Mugla Journal of Science and Technology*, 2(2), 15-18.
- [19] Coskun, C., & Oktay, Z. (2019). An advanced simple method for generating synthetic average instant hourly solar energy. *Journal of Management Science & Engineering Research*, 1(1), 1-6.
- [20] Bacher, P., Madsen, H., & Nielsen, H. A. (2009). Online short-term solar power forecasting. *Solar Energy*, 83(10), 1772-1783.
- [21] Das, U., Tey, K., & Seyedmahmoudian, M. (2017). SVR-based model to forecast PV power generation under different weather conditions. *Energies*, 10(7), 87.
- [22] Haydaroğlu, C., & Gümüş, B. (2016). Dicle Üniversitesi güneş enerjisi santralının PVsyst ile simülasyonu ve performans parametrelerinin değerlendirilmesi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 7(3), 491-500.
- [23] Boztepe, M. (2017). Fotovoltaiik güç sistemlerinde verimliliği etkileyen parametreler. *EMO İzmir Şubesi Aylık Bülteni*, 321, 13-17.
- [24] Kılınç, E. (2019). *Polikristal yapıli fotovoltaiik panellerin laboratuvar testleri ve fizibilite çalışmaları ile saha uygulaması sonuçlarının karşılaştırılması* [Yüksek lisans tezi, Marmara Üniversitesi].
- [25] Güneş, F. (2021). *Akıllı şehirler ve veri analitiği-sinyalize kavşakların performans değerlendirilmesinde analitik yöntemler ve trafik akımının kuyruk teorisi ile modellenmesi* [Doktora tezi, İstanbul Ticaret Üniversitesi].
- [26] Kölemenoglu, Ş. (2024). *Güneş enerjisi santrallerinde tasarım, kurulum hataları ve işletme aşamasında yaşanan arıza durumlarının değerlendirilmesi* [Yüksek lisans tezi, Sivas Cumhuriyet Üniversitesi].