

Ağaç Tabanlı ve Klasik Regresyon Modelleri Kullanılarak Temel PVT Parametrelerinin Makine Öğrenmesine Dayalı Tahmini

Kamil Neyfel ÇERÇİ¹, Sümeyye Büşra DURMAZ², Çağrı KAYMAK^{3*}, Ebru AKPINAR⁴

^{1,2}Makine Mühendisliği Bölümü, Mühendislik Fakültesi, Tarsus Üniversitesi, Tarsus, Mersin, Türkiye.

³Mekatronik Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye.

⁴Makine Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye.

¹kneymfelcerci@tarsus.edu.tr, ²sumeyye_durmaz@tarsus.edu.tr, ^{3*}ckaymak@firat.edu.tr, ⁴ebruakpinar@firat.edu.tr

(Geliş/Received: 27/10/2025;

Kabul/Accepted: 22/12/2025)

Öz: Küresel nüfusun sürekli artmasıyla birlikte enerji talebi hızla artmaktadır ve bu talep hala sınırlı rezervlere sahip fosil yakıtlarla karşılanmaktadır. Ancak fosil yakıtların çevresel etkileri sürdürülebilirlik açısından büyük zorluklar yaratmaktadır. Bu nedenle, enerji tüketimini azaltmak ve yenilenebilir enerji kaynaklarını teşvik etmek büyük önem taşımaktadır. Bunlar arasında güneş enerjisi, tükenmez ve çevre dostu bir kaynak olarak öne çıkmıştır. Aynı anda ısı ve elektrik üretebilen fotovoltaik-termal (PVT) paneller, iklimlendirme, ısıtma, soğutma ve kurutma gibi uygulamalar için önemli bir araştırma konusu olmuştur. PVT sistemlerinin etkili bir şekilde analiz edilebilmesi için doğru modelleme çok önemlidir. Bu çalışmada, PVT kolektörlerinin iki temel çıktı parametresi olan yüzey sıcaklığı (T_s) ve sıvı çıkış sıcaklığı (T_o) modellenmiş ve modellerin başarımlı regresyon performans ölçütleri üzerinden değerlendirilmiştir. COMSOL Multiphysics'te sonlu elemanlar analizi ile oluşturulan bir veri seti, Python'da Karar Ağacı (KA), Rastgele Orman (RO), Hafif Gradyan Güçlendirme Makinesi (HGGM) ve Aşırı Gradyan Güçlendirme (AGG) gibi makine öğrenmesi modellerini geliştirmek için kullanılmıştır. Ek olarak, doğrusal regresyon modeli bir temel olarak kullanılmıştır. Tüm modeller yüksek tahmin doğruluğu elde etmiş olup, AGG en iyi performansı göstermiştir (T_s için $R^2=0.9998$, RMSE=0.16, MAE=0.12; T_o için $R^2=0.9997$, RMSE=0.19, MAE=0.12).

Anahtar kelimeler: Fotovoltaik-termal (PVT) kolektörler, rastgele orman, hafif gradyan güçlendirme makinesi, aşırı gradyan güçlendirme, sonlu elemanlar.

Machine Learning-Based Prediction of Key PVT Parameters Using Tree-Based and Classical Regression Models

Abstract: With the continuous growth of the global population, energy demand is rapidly increasing, and this demand is still mainly supplied by fossil fuels with limited reserves. However, the environmental impacts of fossil fuels pose major challenges to sustainability. Therefore, reducing energy consumption and promoting renewable energy sources are of great importance. Among these, solar energy has gained prominence as an inexhaustible and environmentally friendly source. Photovoltaic-thermal (PVT) panels, capable of simultaneously generating heat and electricity, have attracted significant research interest for applications such as space conditioning, heating, cooling, and drying. To enable effective analysis of PVT systems, accurate modeling is essential. In this study, two main output parameters of PVT collectors, surface temperature (T_s) and fluid outlet temperature (T_o), were modeled, and the performance of the models was evaluated using regression performance metrics. A dataset generated through finite element analysis in COMSOL Multiphysics was used to develop machine learning models including Decision Tree (DT), Random Forest (RF), Light Gradient Boosting Machine (LightGBM), and Extreme Gradient Boosting (XGBoost) in Python. Additionally, a linear regression model served as a baseline. All models achieved high predictive accuracy, with XGBoost providing the best performance ($R^2=0.9998$, RMSE=0.16, MAE=0.12 for T_s ; $R^2=0.9997$, RMSE=0.19, MAE=0.12 for T_o).

Keywords: Photovoltaic-thermal (PVT) collectors, random forest, light gradient boosting machine, extreme gradient boosting, finite elements.

1. Giriş

Artan küresel enerji talebi, fosil yakıt rezervlerinin tükenme riski ve iklim değişikliğinin neden olduğu çevre sorunları, yenilenebilir enerji kaynaklarının kullanımını kaçınılmaz hale getirmektedir [1]. Sınırsız, temiz ve sürdürülebilir özellikleriyle güneş enerjisi bu alanda önde gelen bir seçenek olarak öne çıkmaktadır [2], elektrik ve ısıyı aynı anda üretebilen hibrit sistemler olan fotovoltaik-termal (PVT) kolektörler ise güneş enerjisinin kullanımını en üst düzeye çıkarma fırsatı sunmaktadır [3]. Bu çift modlu üretim, genel enerji verimliliğini artırarak geleneksel fotovoltaik panellere kıyasla daha yüksek enerji dönüşüm oranları elde etmektedir [4]. PVT sistemlerinin performansı, güneş ışınımı, ortam sıcaklığı, rüzgâr hızı, soğutucu kütle akış hızı, panel malzemesi ve tasarım gibi birçok parametreye bağlıdır [5]. Özellikle elektrik verimliliği hem sistem tasarımı hem de ekonomik

* Sorumlu yazar: ckaymak@firat.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-3126-707X, ² 0009-0008-1199-2750, ³ 0000-0001-5343-226X, ⁴ 0000-0003-0666-9189

fizibilite açısından kritik bir performans göstergesi olarak ortaya çıkmaktadır [5]. Ancak, bu parametreler arasındaki karmaşık ve doğrusal olmayan ilişkiler, bu verimliliği tahmin etmede geleneksel hesaplama yöntemlerinin doğruluğunu sınırlamaktadır [6]. Büyük veri setleri içindeki karmaşık ilişkileri öğrenme ve son derece doğru tahminler sağlama yetenekleri sayesinde, Makine Öğrenmesi (MÖ) teknikleri PVT kolektörlerinin elektrik verimliliğini analiz etmek için önemli bir araç haline gelmiştir [7]. Yapay Sinir Ağları (YSA), Destek Vektör Makineleri (DVM), Rastgele Orman (RO) ve Gradyan Güçlendirme Makinesi (GGM) algoritmaları gibi yöntemleri kullanan çalışmalar, bu yaklaşımların geleneksel modelleme tekniklerine kıyasla daha doğru sonuçlar verdiğini göstermiştir [6-8].

Literatürde, PVT kolektörlerinin çeşitli çıktı parametrelerini tahmin etmek için farklı girdi faktörlerini kullanan MÖ modellerini inceleyen çeşitli çalışmalar bulunmaktadır. Chaibi ve ark. [6], hava bazlı PVT kolektör sistemlerinin elektriksel ve termal verimliliklerini tahmin etmek için YSA tabanlı modeller geliştirmiştir. Ürdün’de bir yıl boyunca 10 dakikalık aralıklarla toplanan iklim verilerini kullanarak, model elektrik verimliliği için %0.0079 ve termal verimlilik için %3.3607 hata oranları elde etmiştir. Bu bulgular, modelin PVT hava kolektörleri için güçlü bir tahmin aracı olduğunu göstermektedir. Gharaee ve ark. [9], su soğutmalı PVT kolektörlerinin elektriksel çıktısını tahmin etmenin doğruluğunu artırmayı amaçlayan MÖ modelleri oluşturmuştur. Araştırmalarında kütle akış hızı, güneş radyasyonu yoğunluğu, ortam sıcaklığı, iç boru çapı, rüzgâr hızı, sıvı giriş sıcaklığı ve PVT yüzey alanı gibi girdiler kullanılmış ve önceki araştırmalardan 380’den fazla veri seti derlenmiştir. Çok Katmanlı Algılayıcı (ÇKA), RO ve Destek Vektör Regresyonu (DVR) kullanılarak oluşturulan modeller arasında, RO modeli en üstün sonuçları vermiştir. RO modelinin girdi parametreleri, Shapley Ekllemeli Açıklamalar (Shapley Additive Explanations–SHAP) uygulaması aracılığıyla Açıklanabilir Yapay Zekâ kısaca AYZ (Explainable Artificial Intelligence–XAI) bağlamında incelenmiş ve kütle akış hızı, iç boru çapı ve rüzgâr hızının en önemli girdi faktörleri olduğu ortaya çıkmıştır. Wang ve ark. [10], gözenekli bir toplayıcı içeren fotovoltaik sistemlerdeki sıcaklık dağılımını tahmin etmek için Hesaplamalı Akışkanlar Dinamiği (HAD) ile MÖ’yü entegre eden bir hibrit model sunmuştur. Değerlendirilen modeller arasında Gradyan Güçlendirme kısaca GG (Gradient Boosting–GB), Aşırı Gradyan Güçlendirme kısaca AGG (Extreme Gradient Boosting–XGBoost) ve Histogram tabanlı Gradyan Güçlendirme kısaca HGG (Histogram-based Gradient Boosting–HGB) yer almış ve hiperparametre optimizasyonu Su Döngüsü Algoritması kısaca SDA (Water Cycle Algorithm–WCA) kullanılarak gerçekleştirilmiştir. Sonuçlar, AGG yönteminin 0.99823 R^2 değeri ile en yüksek doğruluğu elde ettiğini göstermiş ve karmaşık fiziksel sistemler için veriye dayalı tahmin yeteneğinin geliştirilebileceğini ortaya koymuştur. Tripathi ve ark. [11], değişen çevre koşulları, yani güneş radyasyonu, ortam sıcaklığı ve bağıl nem altında güneş panellerinin güç çıkışını tahmin etmek için Çok Değişkenli Regresyon (ÇDR), Destek Vektör Makinesi Regresyonu (DVMR) ve Gauss Regresyonu (GR) yöntemlerinin karşılaştırmalı bir analizini gerçekleştirmiştir. Bulgular, DVMR yönteminin en yüksek belirleme katsayısını ($R^2 = 0.99$) elde ettiğini göstermiş ve bu yöntemin çevresel faktörlerin PV panel güç çıkışı üzerindeki etkilerini doğru ve güvenilir bir şekilde modelleme yeteneğini doğrulamıştır. Diwania ve ark. [12], saf su veya nanoakışkan ile soğutulan hibrit PVT sistemlerinin termoelektrik performansını tahmin etmek için MÖ tabanlı modeller geliştirmiştir. Çalışmada, nanoakışkan olarak Fe/H₂O kullanılmıştır. MATLAB ortamında yapılan analizler, kütle akış hızının 0.01 kg/s’den 0.1 kg/s’ye çıkarılmasının, su soğutmalı PVT sistemine kıyasla nanoakışkan soğutmalı sistemde elektrik verimliliğinde %7.11, termal verimlilikte %2.73 ve genel verimlilikte %9.84 iyileşme sağladığını ortaya koymuştur. Tahmin edilen sonuçlar ile deneysel veriler arasında yüksek düzeyde bir uyum gözlemlenmiştir. Ahmadi ve ark. [13], PVT sistemlerinin termal performansını tahmin etmek için YSA, nöro-bulanık mantık ve DVM’nin en küçük kareler sürümlü yöntemini kullanmışlardır. Giriş sıcaklığı, akış hızı ve mevcut güneş termal akısını girdi parametreleri olarak dikkate alarak, kullanılan yöntemin en uygun yöntem olduğunu bildirmiştir. Çerçi [14], NACA 8412 kanat profillerinin farklı yönlerde (akış yönünde ve akışa dik olarak) konumlandırılmasının enerji, ekserji, ekonomik ve çevresel etkilerini değerlendirmiş ve PVT kolektörler için temel çıktı göstergelerini, yani kolektör çıkış hava sıcaklığı, hücre sıcaklığı ve basınç düşüşünü tahmin etmek için YSA modelleri geliştirmiştir. Veri seti, çeşitli çalışma parametrelerini ve geometrik parametreleri kapsayan sonlu elemanlar yöntemi kullanılarak oluşturulmuştur. Bazı YSA modelleri, her bir çıktı parametresini ayrı ayrı tahmin etmek için tasarlanırken, diğerleri tüm çıktı parametrelerini aynı anda tahmin etmek için geliştirilmiştir. Sonuçlar, hem tek çıktı hem de çoklu çıktı YSA modellerinin yüksek doğruluk sağladığını göstermiştir; ancak, tek çıktı modeli her bir performans parametresi için daha yüksek hassasiyet sergilerken, çoklu çıktı modeli eşzamanlı tahmin avantajı sunmuştur. Son beş yılda, karmaşık çevresel ve operasyonel senaryolarda doğruluğu ve tahmin yeteneklerini geliştirmek için PVT sistemlerini modellemek üzere Yapay Zekâ (YZ) ve MÖ’nün yenilikçi kullanımlarını araştıran çalışmaların sayısı hızla artmıştır. Khan ve ark. [15], nano-geliştirilmiş Faz Değişim Malzemeleri kısaca FDM (Phase Change Materials–PCMs) kullanarak nanoakışkan tabanlı PVT sistemlerini iyileştirmek için Gauss Süreç Regresyonu kısaca GSR (Gauss Process Regression–GPR) ile Grasshopper

optimizasyonunu birleştiren birleşik bir YZ çerçevesi sunmuş ve etkileyici bir tahmin doğruluğu ve termodinamik optimizasyon elde etmiştir. Li ve ark. [16], çok amaçlı termal optimizasyon ve PROMETHEE karar verme süreci ile sınır ağlarını birleştirerek, akıllı modellemenin FDM entegre PVT kolektörlerinin termal tasarımında iyileştirmeleri kolaylaştırabileceğini göstermiştir. Başka bir çalışmada Nazeri ve ark. [17], çeşitli MÖ algoritmaları kullanarak yoğun kentsel alanlarda bulunan PVT sistemlerinin elektriksel ve termal çıktıları incelemiş ve kentsel ısı adası etkileri ile bina geometrilerinin performans tahminlerini nasıl etkilediğini ortaya koymuştur. Bu araştırma çabaları, geleneksel modelleme yaklaşımlarından daha akıllı, veriye dayalı çerçevelere geçişi vurgulamaktadır. Ek olarak, MÖ'nün optimizasyon yöntemleriyle entegrasyonu, karmaşık hibrit PVT sistemlerinde eşzamanlı tahmin ve performans iyileştirme elde etmek için umut verici bir yol olduğunu göstermektedir [18-21].

Bu çalışmada, PVT kolektörlerin iki temel çıktı parametresi olan yüzey sıcaklığı (T_s) ve sıvı çıkış sıcaklığı (T_o), çeşitli modelleme yaklaşımları kullanılarak tahmin edilmiş ve regresyon performans ölçütlerine göre değerlendirilmiştir. Veri seti, COMSOL Multiphysics'te gerçekleştirilen sayısal simülasyonlar yoluyla elde edilmiş, ardından Python'da Karar Ağacı (KA), Rastgele Orman (RO), Hafif Gradyan Güçlendirme Makinesi (HGGM) ve Aşırı Gradyan Güçlendirme (AGG) adlı MÖ modelleri uygulanmıştır. Özellikle, literatürde ilk kez bu dört model, bu çalışmanın kapsamında bir PVT toplayıcının iki çıktı parametresi için karşılaştırmalı olarak analiz edilmiştir. Geliştirilen modellerin tahmin performansı, yüksek doğruluğu ile tanınan geleneksel bir regresyon yöntemi olan doğrusal regresyon ile karşılaştırılarak daha da geliştirilmiştir.

2. Metodoloji

2.1. PVT kolektörünün sayısal modellemesi ve veri seti oluşturma

MÖ modelleri geliştirmek için öncelikle uygun bir veri seti oluşturmak gerekir. Bunun için PVT kolektörün hücre yüzey sıcaklığı ve çıkış sıvısı sıcaklığının belirlenmesi gerekir. Bu parametreler, PV panellerin elektrik gücü çıkışının ve PVT kolektörlerin soğutma kapasitesinin hesaplanmasını sağlar. Bu amaçla, PVT kolektör performansını etkileyen bir dizi parametre dikkate alınarak sayısal simülasyonlar gerçekleştirilmiştir. Dış faktörler arasında güneş ışınımı (I_r), suyun kütleli akış debisi ($\dot{m}_w$), rüzgâr hızı (v_w), ortam sıcaklığı (T_a) ve sıvı giriş sıcaklığı (T_i) yer almaktadır. Simülasyonlarda kullanılan çevre ve çalışma koşulları Tablo 1'de sunulmuştur.

Tablo 1. Sayısal simülasyonlar için girdi parametrelerinin çalışma aralıkları


Parametre	Birim	Sembol	Çalışma aralığı
Güneş ışınımı	W/m ²	I_r	200-1000
Suyun kütleli akış debisi	kg/s	$\dot{m}_w$	0.000779-0.03926
Rüzgâr hızı	m/s	v_w	0-4.82
Ortam sıcaklığı	°C	T_a	10-40
Sıvı giriş sıcaklığı	°C	T_i	10-40

Daha düşük ağ yoğunluklarıyla daha hızlı sonuçlar elde etmek için sayısal model, üzerine doğrudan monte edilmiş bir PV paneli bulunan tek bir kanaldan oluşmaktadır (Şekil 1). PV panelin genişliği 44 mm ve uzunluğu 1000 mm'dir. Panel yapısı, yukarıdan aşağıya doğru 3 mm kalınlığında cam kapak, 0.5 mm EVA, 0.3 mm güneş pili tabakası, 0.5 mm EVA, 0.1 mm Tedlar ve 1 mm bakır levhadan oluşmaktadır. Su akışını sağlamak için bakır levhanın altına iç çapı 10 mm, dış çapı 12 mm ve uzunluğu 1000 mm olan dairesel bir bakır boru takılmıştır. Simülasyonlar COMSOL Multiphysics kullanılarak gerçekleştirilmiştir. Kütle akış hızına bağlı olarak, bazı durumlar laminar akış koşulları altında modellenirken, diğerleri türbülanslı akış koşulları altında modellenmiştir; türbülans modellemesi için gerçekleştirilebilir k-ε modeli kullanılmıştır. PVT toplayıcının üst yüzeyinin radyasyon yoluyla ısı kazancı ve konveksiyon yoluyla ısı kaybı yaşadığı, yan ve alt yüzeylerin ise tamamen yalıtılmış olduğu varsayılmıştır. Kanalın iç yüzeyine kaymaz sınır koşulu uygulanmıştır. Sayısal analizlerde, toplam 3,645 farklı giriş senaryosu değerlendirilmiştir. Bu simülasyonlardan, çıkış sıcaklığı (T_o) için 729 veri noktası ve yüzey sıcaklığı (T_s) için ek 729 veri noktası oluşturulmuştur.



Şekil 1. Sayısal simülasyonda kullanılan tek tüplü PVT toplayıcının önden görünümü (a) ve izometrik görünümü (b)

Şekil 2, 1000 W/m² güneş ışınlımı, 12 W/m²K konvektif ısı transfer katsayısı ve 25 °C giriş suyu sıcaklığı altında farklı giriş akış hızlarında PVT toplayıcının sıcaklık dağılımlarını göstermektedir.



Şekil 2. Farklı akış giriş hızlarında (a-0,06 m/s, b-0,15 m/s) PVT kolektöründeki sıcaklık dağılımı

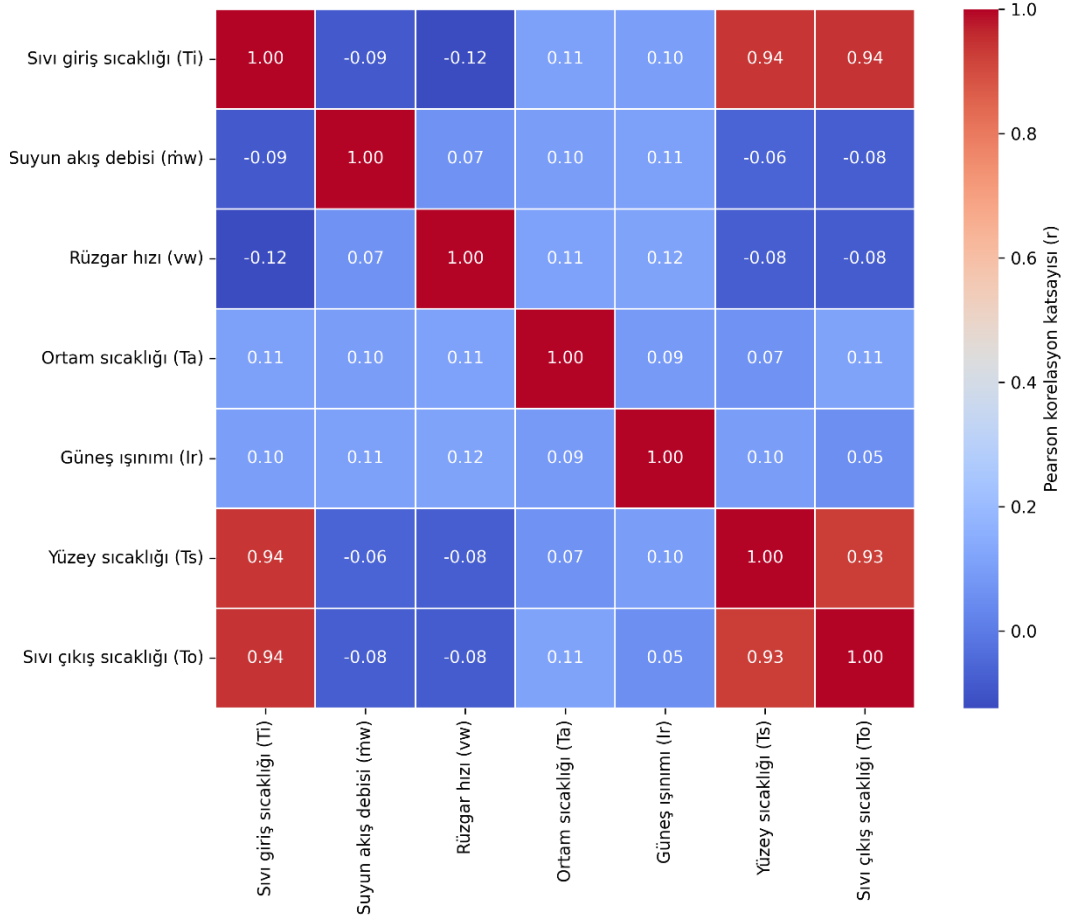
Tablo 2 veri setine ait istatistiksel özeti gösterirken, Şekil 3 ise değişkenler arası ilişkileri göstermektedir.

Tablo 2. Veri setine ait istatistiksel temel özellikler

Parametre	Ortalama	Standart Sapma	Min.	Max.
Sıvı giriş sıcaklığı (T_i)	25	12.25585754	10	40
Suyun kütleli akış debisi ($\dot{m}_w$)	0.0139549852	0.0132885245	0.0007793	0.03926
Rüzgâr hızı (v_w)	1.982444444	1.780338831	0	4.816
Ortam sıcaklığı (T_a)	25	12.25585754	10	40
Güneş ışınlımı (I_r)	600	326.8228676	200	1000
Yüzey sıcaklığı (T_s)	27.06143159	11.61499628	10.3749432	47.7973978
Sıvı çıkış sıcaklığı (T_o)	26.18802448	11.99397953	10.03665314	49.14478273

Regresyon modellerinin eğitiminden önce, girdi ve çıktı parametrelerinin temel istatistiksel özellikleri (ortalama, standart sapma, minimum ve maksimum değerleri) incelenmiştir. Tablo 2, veri setindeki her bir değişkenin dağılımını ve değişkenler arasındaki ölçek farklılıklarını ortaya koymaktadır.

Ek olarak, girdi değişkenleri ile çıktı parametreleri (T_s ve T_o) arasındaki ilişkileri incelemek için Pearson korelasyon analizi gerçekleştirilmiştir. Şekil 3'teki tam korelasyon ısı haritası, hem yüzey (T_s) hem de çıkış (T_o) sıcaklıklarının giriş sıcaklığı (T_i) ile güçlü bir korelasyon gösterdiğini ($r \approx 0.94$), T_s ve T_o 'nun da birbirleriyle yüksek korelasyon gösterdiğini ($r \approx 0.93$) görülmektedir. Kalan değişkenler ise zayıf düzeyde korelasyonlar göstermektedir. Bu analiz, giriş sıcaklığının PVT kolektörünün termal davranışı üzerindeki baskın etkisini vurgulamakta ve özellikler arasındaki çoklu doğrusallık düzeyinin kabul edilebilir bir aralıkta kaldığını doğrulamaktadır.




Şekil 3. Girdi ve çıktı parametreleri arasındaki Pearson korelasyon ısı haritası

2.2. Ağ bağımsızlık testi


Bu çalışmada, veri setini oluşturmak için COMSOL Multiphysics kullanılarak PVT toplayıcının bir hesaplama modeli oluşturulmuştur. Ayrıştırma aşamasında, bakır boru ve akışkan alt alanlarının sınırları için serbest tetrahedral ağ yöntemi kullanılırken, diğer sınır yüzeyleri için serbest üçgen elemanlar kullanılmıştır. Simülasyonun hassasiyetini artırmak için, bakır borunun iç duvarlarına bitişik bir sınır tabakası ağı uygulanmıştır.

Sonuçların ağ çözünürlüğünden etkilenmediğinden emin olmak için bir ağ bağımsızlık testi gerçekleştirilmiştir. Çalışma sıvısı, giriş hızı 0.5 m/s olan saf sudur. Hem ortam havası hem de giriş suyu sıcaklıkları 25 °C olarak ayarlanmış ve test boyunca güneş ışınlımı 1000 W/m² olarak tutulmuştur. Ek olarak, PV panelinin yüzeyine 12 W/m²K konvektif ısı transfer katsayısı uygulanmıştır.

Çıkış suyu sıcaklığı ve PV hücre yüzey sıcaklığı, 171,482 ila 1,083,251 eleman arasında değişen dört farklı ağ boyutu için değerlendirilmiştir. Ağ bağımsızlığı testinin sonuçları Şekil 4'te sunulmuştur. Görüldüğü gibi, 596,927 elemanlı ağ ile 1,083,251 elemanlı ağ arasında hücre yüzey sıcaklığı ve çıkış suyu sıcaklığındaki bağıl hatalar sırasıyla sadece %0.0040 ve %0.0037 olup, bu da ihmal edilebilir farklar olduğunu göstermektedir. Bu nedenle, sayısal simülasyonlar 596,927 elemanlı ağ kullanılarak gerçekleştirilmiştir (Şekil 5).




Şekil 4. PVT kolektörün sayısal analizinde kullanılan ağ yapısı



Şekil 5. PVT kolektöründeki eleman sayısına göre çıkış suyu sıcaklığı (a), PV panel yüzey sıcaklığı (b) ve bağıl hata değerlerinin değişimleri

2.3. Doğrulama

Ağ bağımsızlığı elde edildikten sonra, bu çalışmanın sonuçları, PVT kolektörle ilgili önceki bir çalışmada bildirilen deneysel verilerle karşılaştırılarak doğrulama işlemi gerçekleştirilmiştir. Şekil 6'da, bu çalışmada geliştirilen sayısal modelden elde edilen sonuçlar, Alous ve ark. [22] tarafından sunulan deneysel bulgularla karşılaştırılmıştır. PVT kolektör yüzey sıcaklığı ve su çıkış sıcaklığı için ortalama ve maksimum bağıl hatalar sırasıyla %4.80 ve %10.33 ile %4.17 ve %6.43 olarak bulunmuştur. Bu sonuçlar, literatürde bildirilen sayısal ve deneysel çalışmalar arasında iyi bir uyum olduğunu ve bağıl hata değerlerinin kabul edilebilir sınırlar içinde kaldığını göstermektedir.



Şekil 6. Sayısal sonuçların literatürdeki deneysel verilerle karşılaştırılması Alous ve ark. [22]

2.4. Makine öğrenmesi modelleri

Bu çalışmada, PV panel yüzey sıcaklığını ve çıkış sıcaklığını tahmin etmek için dört MÖ tabanlı regresyon yöntemi kullanılmıştır: Karar Ağacı (KA), Rastgele Orman (RO), Hafif Gradyan Güçlendirme Makinesi (HGGM) ve Aşırı Gradyan Güçlendirme (AGG). Bu dört model, girdi ve çıktı değişkenleri arasındaki doğrusal olmayan ilişkileri yakalamak için farklı topluluk ve güçlendirme mekanizmaları kullanan karar ağacı tabanlı yaklaşımlardır. KA basit ve yorumlanabilir tek ağaç yapısı sağlarken, topluluk tabanlı RO, HGGM ve AGG modelleri daha yüksek tahmin doğruluğu elde etmek ve genelleme hatasını azaltmak için sıralı veya paralel olarak birden fazla ağaç oluşturur. Ayrıca, ağaç tabanlı algoritmaların performansını karşılaştırmak için bir doğrusal regresyon modeli temel olarak uygulanmıştır. MÖ modellerinin geliştirilmesinde, veri setinin %80'i eğitim için ayrılmış ve geri kalan %20'si test için ayrılmıştır.

Karar ağacı (KA)

KA algoritması, belirli bir dağılım varsaymayan ve girdi özelliklerine dayalı basit karar kriterleri türeterek hedef değeri tahmin eden bir denetimli öğrenme tekniğidir [23]. Regresyon görevlerinde, girdi alanı sırayla daha küçük, tekdüze bölümlere ayrılır ve her bölümdaki hedef değişkenin ortalaması tahmin edilen değer olarak kullanılır.

Verilen bir veri seti $D = \{(x_i, y_i)\}_{i=1}^N$ için, karar ağacı, Denklem 1'deki safsızlık ölçüsünü (örneğin; ortalama karesel hata (MSE)) en düşük seviyeye indiren en iyi bölünme değişkenini ve eşiği seçerek özellik alanını bölümlere ayırır:

$$MSE(D) = \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2 \quad (1)$$

burada; N düğümdeki örneklerin sayısını, y_i gerçek hedef değeri ve $\bar{y}$ o düğümdeki ortalama hedef değeri temsil eder.

Her iç düğümde, veri seti Denklem 2'de D_{sol} ve $D_{sağ}$ olmak üzere iki gruba ayrılır:

$$x_j \leq t_j \rightarrow D_{sol}, x_j > t_j \rightarrow D_{sağ} \quad (2)$$

İdeal bölme, Denklem 3'teki gibi alt düğümlerdeki safsızlıkların ağırlıklı toplamını azaltır:

$$L(j, t_j) = \frac{|D_{sol}|}{|D|} MSE(D_{sol}) + \frac{|D_{sağ}|}{|D|} MSE(D_{sağ}) \quad (3)$$

Prosedür, sonlandırma kriteri (yaprakta minimum örnek sayısı veya ağacın maksimum derinliği gibi) karşılanana kadar yinelemeli olarak tekrarlanır. Her yaprak düğümü, tahmin edilen sonucun o bölgede bulunan eğitim örneklerinin ortalaması olduğu bir bölgeyi ifade eder.

Rastgele orman (RO)

RO, çok sayıda karar ağacının birleştirilmesiyle oluşturulan toplama (bagging) yaklaşımına dayanan bir toplu öğrenme tekniğidir [24]. Önyüklem (bootstrap) örnekleme kullanılarak, eğitim verilerinden birden fazla alt set oluşturulur. Daha sonra, regresyon problemleri için bir tahmin üretmek üzere her alt set üzerinde bağımsız karar ağaçları eğitilir. Nihai tahmin, tüm ağaçların tahminlerinin ortalaması alınarak elde edilir. Bu yaklaşım, tek bir karar ağacıyla ilişkili aşırı uyum riskini azaltır ve genelleme yeteneğini geliştirir. Matematiksel olarak, B ağaçtan oluşan bir RO modelinin tahmini, Denklem 4 ile ifade edilir:

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B h_b(x) \quad (4)$$

burada; $\hat{y}$ nihai tahmini, $h_b(x)$ b-inci ağacın tahmini ve B toplam ağaç sayısını temsil eder.

Hafif gradyan güçlendirme makinesi (HGGM)

HGGM, Gradyan Güçlendirme Karar Ağacı kısaca GGKA (Gradient Boosting Decision Tree–GBDT) algoritmasının optimize edilmiş bir sürümüdür [25]. GGKA’dan farklı olarak, HGGM özellik gruplandırma için histogram tabanlı bir yöntem kullanır ve büyüme için yaprak tabanlı bir yaklaşım benimser. Bu yaklaşım, daha düşük bellek kullanımı ve daha kısa eğitim süreleri sağlar. Matematiksel olarak, t -inci yinelemede, modelin tahmin fonksiyonu Denklem 5 kullanılarak güncellenir:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + \eta f_t(x_i) \quad (5)$$

burada; $\hat{y}_i^{(t)}$ t iterasyonda i -inci örnek için tahmini, η öğrenme oranını ve $f_t(x_i)$ t -inci zayıf öğreniciyi temsil eder.

Her yinelemede kayıp fonksiyonu, Denklem 6’da gösterildiği gibi ikinci dereceden Taylor açılımı kullanılarak yaklaşık olarak elde edilir:

$$\mathcal{L}^{(t)} \approx \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t(x_i)^2 \right] + \Omega(f_t) \quad (6)$$

burada; g_i birinci türev (gradyan), h_i ikinci türev (hessian) ve $\Omega(f_t)$ düzenleme terimini belirtir. Düzenleme terimi, Denklem 7 kullanılarak hesaplanır:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (7)$$

burada; T yaprak sayısı, ω_j j -inci yaprağın ağırlığı, γ ve λ ise düzenleme parametreleridir.

Aşırı gradyan güçlendirme (AGG)

AGG, düzenleme terimleri ve geliştirilmiş paralel hesaplama yetenekleri içeren GGKA’nın geliştirilmiş bir sürümüdür [26]. Aşırı uyumu önlemek için L1 (Lasso) ve L2 (Ridge) düzenleme terimleri kullanır. Ağaç yapısı, kayıp fonksiyonunun birinci ve ikinci türevleri (gradyan ve hessian) kullanılarak optimize edilir.

Matematiksel olarak, t -inci yinelemede, amaç fonksiyonu Denklem 8’de tanımlandığı gibi tanımlanır:

$$\mathcal{L}^{(t)} = \sum_{i=1}^n l\left(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)\right) + \Omega(f_t) \quad (8)$$

İkinci dereceden Taylor açılımı uygulandıktan sonra, amaç fonksiyonu HGGM’deki Denklem 6’ya benzer şekilde elde edilir. Deneysel çalışmalarda dört algoritma için kullanılan hiperparametreler Tablo 3’te sunulmuştur.

Tablo 3. Deneysel çalışmalarda kullanılan makine öğrenmesi modellerinin hiperparametreleri

Algoritma	Parametre	Değer
Karar Ağacı	Kriter	MSE
	Tekrarlanabilirlik için sabit tohum	42
	Bir yaprakta minimum örnek sayısı	1
	Öğrenme oranı	-
Rastgele Orman	Ağaç sayısı	100
	Tekrarlanabilirlik için sabit tohum	42
	Öğrenme oranı	-
Hafif Gradyan Güçlendirme Makinesi	Ağaç sayısı	100
	Bir yaprakta minimum örnek sayısı	1
	Bir yaprakta minimum veri sayısı	1
	Tekrarlanabilirlik için sabit tohum	42
	Öğrenme oranı	0.1
Aşırı Gradyan Güçlendirme	Ağaç sayısı	100
	Maksimum derinlik	3
	Öğrenme oranı	0.1
	Tekrarlanabilirlik için sabit tohum	42

2.5. Doğrusal regresyon modeli


Regresyon, bir çıktı değişkeni ile birkaç girdi değişkeni arasındaki ilişkiyi analiz etmek için kullanılan bir tekniktir ve basitliği nedeniyle tercih edilmektedir [27]. Bu çalışmada, T_s ve T_o değerlerini tahmin etmek için veri seti kullanılarak birinci dereceden doğrusal regresyon modeli oluşturulmuştur. Bu model, makine öğrenmesi modelleriyle karşılaştırma için temel bir referans olarak kullanılmıştır. En temel haliyle, birinci dereceden regresyon modeli Denklem 9 ile ifade edilebilir:

$$\hat{y} = c_0 + \sum_{i=1}^m c_i x_i \quad (9)$$

Eğitimden önce tüm girdi öznitelikleri ve hedef değişkenler (T_s ve T_o), doğrusal regresyon modelinde z-skor normalizasyonu kullanılarak standartlaştırılmıştır. Bu normalizasyon sayesinde, sayısal kararlılık artırılması ve ölçek yanlılığının önlenmesi hedeflenmiştir. Modelin eğitimi tamamlandıktan sonra, tüm tahminler orijinal sıcaklık ölçeğine ($^{\circ}\text{C}$) dönüştürülmüştür. Böylece, hata metriklerinin fiziksel açıdan anlamlı olması sağlanarak PVT sisteminin gerçek termal sapmaları doğrudan gösterilebilecektir.


3. Bulgular ve Tartışmalar

Geliştirilen modellerin yüzey sıcaklığı (T_s) ve çıkış sıcaklığı (T_o) için tahmin performansı, Şekil 7’de gösterildiği gibi sayısal simülasyon sonuçlarıyla doğrudan karşılaştırılarak değerlendirilmiştir. Tüm modellerde, tahmin edilen ve simüle edilen değerler 1:1 referans çizgisi boyunca birbirine çok yakın olup, sapmaların son derece düşük olduğunu göstermektedir.



Şekil 7. Tüm modeller için tahmin edilen ve sayısal sonuçların karşılaştırılması

Şekil 8’de sunulan hata dağılımları, HGGM ve AGG modellerinin hataları sıfıra yakın bir noktada yoğunlaştığını ve böylece en düşük kalıntı seviyelerine ulaştığını göstermektedir. Bu çalışmada, modellerin eğitimi ve testi Python programlama dili kullanılarak gerçekleştirilmiştir. Modelleme sürecinde scikit-learn, HGGM ve AGG gibi popüler makine öğrenmesi kütüphaneleri kullanılmıştır. Test verilerinden elde edilen tahmin sonuçları .csv formatında dışa aktarılmıştır. Bu veri dosyaları daha sonra MATLAB ortamına aktarılmış ve burada dağılım grafikleri (Sayısal ve Tahmin Edilen) ve hata histogramları oluşturulmuştur. Bu yaklaşım, hem sayısal metrikler hem de görsel çıktılar aracılığıyla model performansının kapsamlı bir değerlendirmesini mümkün kılmıştır.



Şekil 8. Tüm modeller için hata histogramı

Tablo 4'te özetlendiği gibi, temel doğrusal regresyon modeli her iki çıktı için de $R^2=0.9930$ değerine ulaşmış, T_s için Kök Ortalama Kare Hatası (Root Mean Square Error–RMSE) değeri $1.010\text{ }^\circ\text{C}$, T_o için ise $1.000\text{ }^\circ\text{C}$ olmuştur. Bu sonuçlar genel olarak yüksek bir tahmin yeteneği gösterse de, topluluk yöntemlerine kıyasla daha yüksek RMSE ve Ortalama Mutlak Hata (Mean Absolute Error–MAE) değerleri, doğrusal regresyonun girdi parametreleri arasındaki doğrusal olmayan ilişkileri temsil etmedeki sınırlarını ortaya koymaktadır. Karar Ağacı (KA) modeli de güçlü bir tahmin yeteneği sergilemiş ($R^2\approx 0.998$, $\text{RMSE}=0.61\text{ }^\circ\text{C}$, $\text{MAE}\approx 0.35\text{ }^\circ\text{C}$), temel doğrusal regresyonu geride bırakmış, ancak tek ağaç yapısı nedeniyle topluluk tabanlı modellerden biraz daha az doğru kalmıştır. T_s tahmini için Hafif Gradyan Güçlendirme Makinesi (HGGM) en yüksek performansı göstermiştir ($R^2=0.9998$, $\text{RMSE}=0.155\text{ }^\circ\text{C}$, $\text{MAE}=0.098\text{ }^\circ\text{C}$), onu Aşırı Gradyan Güçlendirme (AGG) ($R^2=0.9998$, $\text{RMSE}=0.160\text{ }^\circ\text{C}$, $\text{MAE}=0.120\text{ }^\circ\text{C}$) izlemiştir. Tahminde, AGG $R^2=0.9997$, $\text{RMSE}=0.190\text{ }^\circ\text{C}$ ve $\text{MAE}=0.120\text{ }^\circ\text{C}$ ile HGGM'yi biraz geride bırakırken, HGGM $R^2=0.9996$, $\text{RMSE}=0.242\text{ }^\circ\text{C}$ ve $\text{MAE}=0.106\text{ }^\circ\text{C}$ değerlerine ulaştı. Rastgele Orman (RO) modeli de yüksek doğruluğu ($R^2 \geq 0.9990$) korumuş, ancak güçlendirme tabanlı yöntemlere kıyasla biraz daha yüksek RMSE ve MAE değerleri sergilemiştir. Bu sonuç, karmaşık özellik etkileşimlerini modelleme sırasında toplama tabanlı ve güçlendirme tabanlı topluluk yöntemleri arasında bilinen performans farklılıklarıyla uyumludur.

Tablo 4. Tüm modellerin regresyon performans ölçütleri

Model	Çıktı	R^2	RMSE	MAE
Doğrusal Regresyon	T_s	0.9930	1.010	0.730
	T_o	0.9930	1.000	0.700
Karar Ağacı (KA)	T_s	0.9971	0.610	0.347
	T_o	0.9978	0.548	0.297
Rastgele Orman (RO)	T_s	0.9990	0.370	0.229
	T_o	0.9991	0.347	0.182
Hafif Gradyan Güçlendirme Makinesi (HGGM)	T_s	0.9998	0.155	0.098
	T_o	0.9996	0.242	0.106
Aşırı Gradyan Güçlendirme (AGG)	T_s	0.9998	0.160	0.120
	T_o	0.9997	0.190	0.120

Tablo 5, doğrusal regresyon modelinde her bir girdi parametresi için elde edilen sabit katsayıları göstermektedir. Regresyon katsayılarının fiziksel yorumlanabilirliğini korumak için, tabloda verilen katsayı değerleri normalleştirilmemiş öznitelik alanına karşılık gelmektedir. Böylece, orijinal değişkenler arasında fiziksel olarak anlamlı parametre ilişkilerinin korunması sağlanmıştır. Modelin birinci dereceden doğrusal yapısı, hesaplama sürecini basitleştirerek pratik bir araç sunmaktadır. Bu yapı, modeli sadece araştırma uygulamaları için uygun hale getirmekle kalmaz, aynı zamanda mühendislik uygulamalarında da doğrudan kullanılabilir hale getirir. Elde edilen performans ölçütleri kabul edilebilir sınırlar içindedir ve modelin daha karmaşık tahmin yöntemlerine alternatif olarak hızlı ve güvenilir sonuçlar sunma potansiyelini vurgulamaktadır.

Tablo 5. Doğrusal regresyon modellerinin katsayıları

Çıktı parametresi	T_i	$\dot{m}_w$	v_w	T_a	I_r
T_s	0.935862	-5.383880	-0.037546	0.061926	0.003419
T_o	0.965510	-7.319854	-0.011000	0.034183	0.002027

Genel olarak, sonuçlar HGGM ve AGG'nin her iki çıktı parametresi için de olağanüstü bir tahmin doğruluğu sağladığını doğrulamaktadır. Tüm çıktılar için 0.9996'nın üzerinde R^2 değerlerini korumak, düşük RMSE ve MAE değerleri ve Şekil 8'de gözlemlenen dar hata dağılımları ile birleştiğinde, PVT sistemlerinin gerçek zamanlı tahmini ve operasyonel optimizasyonu için güvenilirliklerini göstermektedir. Buna karşılık, RO ve KA modelleri de yüksek doğruluk elde etmiş, ancak biraz daha geniş hata payları göstermişlerdir. Bu da, topluluk değişkenliğinin etkilerini ve tek ağaç derinliğinin kısıtlamalarını göstermektedir. Bu sonuçlar, bu tür modellerin, özellikle tasarım optimizasyonu ve uyarlanabilir kontrol uygulamalarında, hesaplama açısından maliyetli sayısal simülasyonların yerini etkili bir şekilde alabileceğini göstermektedir. Ayrıca, oluşturulan MÖ çerçevesi, diğer hibrit yenilenebilir enerji sistemlerine de uyarlanabilir ve farklı iklim ve operasyonel senaryolar altında termodinamik performans metriklerinin hızlı bir şekilde değerlendirilmesine olanak tanır.

Ayrıca, yüzey ve çıkış sıcaklıklarını etkileyen en önemli girdi parametrelerini belirlemek için öznitelik önem analizi gerçekleştirilmiştir. Doğrusal regresyon modeli, her bir özneliğin doğrusal katkısını temsil eden açık katsayılar sağladığından, öznitelik önem analizi yalnızca ağaç tabanlı modeller (KA, RO, HGGM ve AGG) için yapılmış olup sonuçlar Tablo 6'da verilmiştir.

Tablo 6. Ağaç tabanlı regresyon modellerinde (kazanç tabanlı) öznitelik önemi

Öznitelik	KA	HGGM	RO	AGG
T_i	0.970953737	0.971139228	0.970922402	0.990582692
$\dot{m}_w$	0.015500037	0.019399701	0.016123057	0.004391813
v_w	0.001610371	0.00106276	0.001339578	0.000699057
T_a	0.004085104	0.002774358	0.003798533	0.001353598
I_r	0.00785075	0.005623954	0.007816429	0.00297284

Tablo 6'da gösterildiği gibi, giriş sıcaklığı (T_i) tüm ağaç tabanlı modellerde tutarlı bir şekilde en baskın öznitelik olarak belirlenmiş olup PVT sisteminin termal davranışını belirlemedeki kritik rolü doğrulanmıştır. Bunu kütle akış hızı ($\dot{m}_w$) ve güneş ışıınımı (I_r) ikincil etkenler olarak izlerken, ortam sıcaklığı (T_a) ve rüzgâr hızı (v_w) nispeten daha az etki göstermiştir. Genel olarak, modeller arasındaki sıralamanın tutarlılığı, öznitelik önem analizi sağlamlığını desteklemiş ve tüm algoritmaların PVT sistemine özgü baskın fiziksel ilişkileri yakaladığını göstermiştir.

4. Sonuçlar

Bu çalışmada, PVT kolektörünün yüzey sıcaklığı (T_s) ve çıkış sıcaklığı (T_o) tahmininde beş farklı modelleme yaklaşımı karşılaştırılmıştır: birinci dereceden doğrusal regresyon (temel model), Karar Ağacı (KA), Rastgele Orman (RO), Hafif Gradyan Güçlendirme Makinesi (HGGM) ve Aşırı Gradyan Güçlendirme (AGG). COMSOL Multiphysics'te oluşturulan 3,645 senaryoya dayalı olarak, her çıktı için 729 veri noktası elde edilmiş; verilerin %80'i eğitim için, %20'si ise test için kullanılmıştır.

İstatistiksel değerlendirmeler, tüm modellerin yüksek düzeyde tahmin doğruluğu elde ettiğini göstermiştir. KA modeli, tek bir ağaçla basit bir yapıya sahip olmasına rağmen, temel doğrusal regresyonu geride bırakarak güvenilir sonuçlar vermiştir, ancak topluluk tabanlı yaklaşımlara göre biraz daha az doğruluğa sahiptir. Topluluk

modeller arasında, HGGM ve AGG güçlendirme algoritmaları en iyi genel performansı sergilemiş ve 0.9996'yı aşan R^2 değerlerine ulaşırken, RMSE ve MAE değerleri çok düşük olmuştur. RO modeli de yüksek doğruluk sağlamış olup T_s için $R^2=0.9990$ (RMSE=0.370 °C, MAE=0.229 °C) ve T_o için $R^2=0.9991$ (RMSE=0.347 °C, MAE=0.182 °C) elde edilmiştir. Ancak bu hata değerleri, HGGM (T_s : RMSE=0.155 °C, T_o : RMSE=0.242 °C) ve AGG (T_s : RMSE=0.160 °C, T_o : RMSE=0.190 °C) güçlendirme modellerinin ürettiği daha düşük RMSE değerlerinden büyüktür.

Genel olarak, bulgular HGGM ve AGG'nin PVT sistemlerinin gerçek zamanlı izlenmesi, uyarlanabilir kontrolü ve tasarım optimizasyonu için karmaşık ve zaman alıcı sayısal simülasyonlara etkili alternatifler olduğunu göstermektedir. Ayrıca, KA ve RO modelleri, basitlik veya hızlı çıkarım öncelikli olduğunda yorumlanabilir ve hesaplama açısından verimli alternatifler sunmaktadır. Gelecekteki araştırmalar, daha fazla operasyonel ve çevresel değişkeni entegre etmeyi, çeşitli PVT konfigürasyonlarına uygulanabilirliğini değerlendirmeyi amaçlamaktadır. Ayrıca, modelleme çerçevesinin farklı sistem koşullarında geçerliliğini değerlendirmek için sunulan yaklaşımın deneysel ölçümler veya alternatif hibrit PVT tasarımları üzerinde de uygulanması yararlı olacaktır.

Teşekkür

Bu makale, 25-27 Eylül 2025 tarihlerinde Elazığ, Türkiye'de düzenlenen Uluslararası Mühendislikte Gelişmeler ve Yenilikler Konferansı'nda (International Conference on Advances and Innovations in Engineering –ICAIE 2025) sunulan bildirinin genişletilmiş ve revize edilmiş halidir.

Kaynaklar

- [1] S. Saidur, N. A. Rahim, M. R. Islam, and K. H. Solangi, "Environmental impact of wind energy," *Renew. Sustain. Energy Rev.*, vol. 16, no. 1, pp. 103–112, 2012.
- [2] S. A. Kalogirou, "Solar thermal collectors and applications," *Prog. Energy Combust. Sci.*, vol. 30, no. 3, pp. 231–295, 2004.
- [3] A. Tiwari and R. K. Mishra, "Performance evaluation of photovoltaic/thermal solar air collector," *Energy Convers. Manag.*, vol. 52, no. 1, pp. 98–105, 2011.
- [4] T. T. Chow, "A review on photovoltaic/thermal hybrid solar technology," *Appl. Energy*, vol. 87, no. 2, pp. 365–379, 2010.
- [5] J. K. Tonui and Y. Tripanagnostopoulos, "Improved PV/T solar collectors with heat extraction by forced or natural air circulation," *Renew. Energy*, vol. 32, no. 4, pp. 623–637, 2007.
- [6] Y. Chaibi, M. Malvoni, T. El Rhafiki, T. Kousksou, and Y. Zeraoui, "Artificial neural-network based model to forecast the electrical and thermal efficiencies of PVT air collector systems," *Cleaner Eng. Technol.*, vol. 4, p. 100132, 2021.
- [7] T. Khatib, A. Mohamed, and K. Sopian, "A review of solar energy modeling techniques," *Renew. Sustain. Energy Rev.*, vol. 45, pp. 530–543, 2019.
- [8] A. H. Abedin, M. A. Alim, A. Islam, and M. M. Rahman, "Machine learning approaches for solar radiation prediction: A review," *Renew. Sustain. Energy Rev.*, vol. 121, p. 109711, 2020.
- [9] A. Mellit and A. M. Pavan, "A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy," *Sol. Energy*, vol. 84, no. 5, pp. 807–821, 2010.
- [10] H. Gharraee, M. Erfaniantti, and A. M. Bahman, "Machine learning development to predict the electrical efficiency of photovoltaic-thermal (PVT) collector systems," *Energy Convers. Manag.*, vol. 315, p. 118808, 2024.
- [11] Y. Wang et al., "A hybrid CFD and machine learning study of energy performance of photovoltaic systems with a porous collector: Model development and validation," *Case Stud. Therm. Eng.*, vol. 69, p. 105998, 2025.
- [12] A. K. Tripathi et al., "Advancing solar PV panel power prediction: A comparative machine learning approach in fluctuating environmental conditions," *Case Stud. Therm. Eng.*, vol. 59, p. 104459, 2024.
- [13] S. Diwania et al., "Machine learning-based thermo-electrical performance improvement of nanofluid-cooled photovoltaic-thermal system," *Energy Environ.*, vol. 35, no. 9, pp. 1799–1817, 2024.
- [14] M. H. Ahmadi et al., "Machine learning prediction models of electrical efficiency of photovoltaic-thermal collectors," *Preprints*, 2019.
- [15] R. Khan, A. M. Mohsen, and A. Alizadeh, "AI-integrated design of nanofluid-based PVT systems containing nano-enhanced PCM: Combining optimized GPR models with grasshopper optimization," *Case Stud. Therm. Eng.*, 2025.
- [16] Y. Li, A. Basem, A. Alizadeh, P. K. Singh, and S. Dixit, "Artificial neural networks with multi-objective thermal exchange optimization and PROMETHEE decision-making to improve PCM-based photovoltaic thermal systems," *Case Stud. Therm. Eng.*, 2025.
- [17] A. Nazeri, A. Taheri, and Z. S. Zomorodian, "Predicting photovoltaic-thermal panel output in urban contexts using machine learning methods," *Res. Sq. (preprint)*, 2024.

- [18] M. Jabari, A. Rad, M. A. Nasab, and M. Zand, “Parameter identification of PV solar cells and modules using bio dynamics grasshopper optimization algorithm,” *IET Gener. Transm. Distrib.*, 2024.
- [19] S. F. Ali and D. Rakshit, “Genetic algorithm and grasshopper optimization algorithm with metaoptimization and RL-based parameter fine-tuning and their comparison for optimal thermal systems,” *J. Comput. Civ. Eng.*, 2025.
- [20] H. Moayedı and A. Mosavi, “Electrical power prediction through a combination of multilayer perceptron with water cycle, ant lion and satin bowerbird searching optimizers,” *Sustain.*, vol. 13, no. 4, p. 2336, 2021.
- [21] M. Jalal, I. U. Khalil, A. U. I. Haq, and A. Flah, “Advancements in PV array reconfiguration techniques,” *IEEE Access*, 2024.
- [22] K. N. Çerçi, “Energy, exergy, economic and enviro-economic analysis and artificial neural network modeling of an air-cooled PVT collector with NACA 8412 airfoils,” *Appl. Therm. Eng.*, vol. 277, p. 126955, 2025.
- [23] J. R. Quinlan, “Learning decision tree classifiers,” *ACM Comput. Surv.*, vol. 28, no. 1, pp. 71–72, 1996.
- [24] S. Alous, M. Kayfeci, and A. Uysal, “Experimental investigations of using MWCNTs and graphene nanoplatelets water-based nanofluids as coolants in PVT systems,” *Appl. Therm. Eng.*, vol. 162, p. 114231, 2019.
- [25] L. Breiman, “Random forests,” *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2012.
- [26] G. Ke et al., “LightGBM: A highly efficient gradient boosting decision tree,” *Adv. Neural Inf. Process. Syst.*, vol. 30, 2017.
- [27] T. Chen and C. Guestrin, “XGBoost: A scalable tree boosting system,” in *Proc. 22nd ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, pp. 785–794, 2016.