



Semnan University

Journal of Modeling in Engineering

Journal homepage: <https://modelling.semnan.ac.ir/>

ISSN: 2783-2538



Research Article

Determination of Effective Parameters on Flat Plate Collector Performance Using Machine Learning Method

Mahtab Salimi ^{a,*}, Saadat Zirak ^{a,*}

^a Faculty of Mechanical Engineering, Semnan University, Semnan, Iran

PAPER INFO

Paper history:

Received: 2025-09-06

Revised: 2025-11-23

Accepted: 2025-12-22

Keywords:

Flat plate collector;
Performance;
Machine learning;
Efficiency;
Random forest;
Decision tree.

ABSTRACT

In this paper, first, analytical relationships of flat plate collector absorption rate and solar-to-thermal energy efficiency are presented. For the considered collector, without the use of cooling water, the collector stagnation temperature is 132.5 degrees Celsius (absorber plate temperature) and by entering the cooling water of one liter per minute, the absorber plate temperature decreases to 33 degrees Celsius and the collector efficiency reaches to 77%. To predict the collector efficiency, three machine learning models were used: linear, random forest, and decision tree. Seven parameters of solar radiation intensity, collector tilt angle, wind speed, pipe diameter, number of pipes, ambient temperature, and cooling water flow rate, were selected as input parameters. Comparison of the predicted efficiency with actual values showed that the linear model has a weaker evaluation than the other two models. The random forest and decision tree models perform prediction with almost equal ability and high accuracy (the random forest model predicts negligibly better than the decision tree model). In addition, among the input parameters, changes in collector tilt angle, solar radiation and wind speed insignificantly affects the efficiency. The cooling water flow rate has the greatest effect. The pipe diameter, ambient temperature and the number of the tubes, have a moderate effect.

DOI: <https://doi.org/10.22075/jme.2025.38847.2897>

© 2026 Published by Semnan University Press.

This is an open access article under the CC-BY 4.0 license. (<https://creativecommons.org/licenses/by/4.0/>)

* Corresponding author.

E-mail address: s_zirak@semnan.ac.ir

How to cite this article:

S. Zirak and M. Salimi, "Determination of Effective Parameters on Flat Plate Collector Performance Using Machine Learning Method," Journal of Modeling in Engineering, 24 85 (2026): 53-65, doi: 10.22075/jme.2025.38847.2897

تعیین پارامترهای موثر بر عملکرد کلکتور خورشیدی صفحه تخت با استفاده از روش یادگیری ماشین

مهتاب سلیمی^۱، سعادت زیرک^{۱*}

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۴۰۴/۰۶/۱۵	در این مقاله، ابتدا روابط تحلیلی میزان جذب و راندمان تبدیل خورشیدی به حرارتی یک کلکتور خورشیدی آورده شده است. برای کلکتور در نظر گرفته شده، بدون استفاده از آب خنک کننده، دمای سکون کلکتور ۱۳۲.۵ درجه سانتیگراد می باشد (دمای صفحه جاذب) و با تزریق آب خنک کننده به میزان یک لیتر بر دقیقه، دمای صفحه جاذب به ۳۳ درجه سانتیگراد کاهش و راندمان کلکتور به ۷۷٪ خواهد رسید. برای پیش بینی راندمان کلکتور، سه مدل یادگیری ماشین: خطی، جنگل تصادفی، و درخت تصمیم، به کار برده شد. هفت پارامتر: شدت تابش خورشید، زاویه کلکتور با افق (زاویه نصب کلکتور)، سرعت باد، قطر لوله ها، تعداد لوله ها، دمای محیط، و دبی آب خنک کننده، بعنوان پارامترهای ورودی انتخاب شدند. مقایسه راندمان پیش بینی با مقادیر واقعی نشان داد که مدل خطی دارای ارزیابی ضعیف تری نسبت به دو مدل دیگر است. مدل های درخت تصمیم و جنگل تصادفی با توانایی تقریباً یکسان و با دقت بالایی پیش بینی را انجام می دهند (مدل جنگل تصادفی با اختلاف ناچیزی بهتر از مدل درخت تصمیم پیش بینی می کند). علاوه بر آن، در میان پارامترهای ورودی، تاثیر تغییرات زاویه نصب، شدت تابش و سرعت باد بر مقدار راندمان خیلی ناچیز است. بیشترین تاثیر را دبی آب خنک کننده دارد. قطر لوله های خنک کننده، دمای محیط و تعداد لوله ها، تاثیر متوسطی دارند.
واژگان کلیدی: کلکتور صفحه تخت، عملکرد، یادگیری ماشین، راندمان، جنگل تصادفی، درخت تصمیم.	

DOI: <https://doi.org/10.22075/jme.2025.38847.2897>

© 2026 Published by Semnan University Press.

This is an open access article under the CC-BY 4.0 license. (<https://creativecommons.org/licenses/by/4.0/>)

۱- مقدمه

انرژی مورد نیاز را تأمین می کنند و ۳۳٪ از گرمایش جهانی نیز بخاطر استفاده از این سوخت ها است. از بین تمام منابع انرژی های تجدیدپذیر، دسترس پذیری انرژی خورشیدی از همه بالاتر و بیشترین توجه را به خود جلب کرده است. یک کلکتور صفحه تخت با جذب انرژی تابشی خورشید، آن را به انرژی حرارتی تبدیل می کند. آبی که با انرژی خورشیدی گرم می شود، اقتصادی تر و سازگارتر با محیط زیست است زیرا از تابش خورشیدی حاصل می شود.

تقاضای جهانی انرژی هر روز در حال افزایش است. مقدار زیادی از این انرژی صرف گرم کردن آب در کلینیک ها، خانه ها و فرآیندهای بخش های مختلف صنعت می شود. منابع تجدیدپذیر تا حد زیادی می توانند جایگزین استفاده از سوخت های فسیلی برای تأمین این انرژی شوند و تولید دی اکسید کربن را کاهش دهند و به این صورت استفاده از انرژی های پاک در چرخه زندگی قرار می گیرد. طبق تحقیقات، سوخت های فسیلی در حال حاضر ۷۵٪ از

* پست الکترونیک نویسنده مسئول: s_zirak@semnan.ac.ir

۱. دانشکده مهندسی مکانیک، دانشگاه سمنان، سمنان، ایران

استناد به این مقاله:

کولانجلو^۴ و همکارانش [۲] نیاز به بازتاب کم و عبور زیاد تابش خورشیدی را در حین تولید انواع مختلف جاذب خورشیدی FPC گزارش کردند.

روش‌های دیگری که برای افزایش راندمان کلکتور وجود دارند عبارتند از: نوع پوشش لوله، طراحی کلکتور، زاویه نصب، عایق حرارتی، ذخیره‌سازی یکپارچه کلکتور، نرخ جریان سیال، استفاده از مواد تغییر فاز دهنده (PCM) و ذخیره‌سازی انرژی حرارتی [۳] و همچنین نصب نوارهای پیچ خورده [۴].

در تحقیقات قبلی، به طور خاص‌تر و با جزئیات بیشتر به تاثیر چندین پارامتر حرارتی بر پیش‌بینی نتایج سیستم‌های گرمایش حرارتی مانند نرخ جریان جرمی [۵]، زاویه نصب کلکتور [۶]، مقدار تابش [۷]، استفاده از نانوسیال [۸] و استفاده از مواد تغییر فاز دهنده [۹]، نیز پرداخته شده است.

۱-۱- زاویه نصب (زاویه شیب)

سیوم گودتا^۵ و همکاران در سال ۲۰۲۲ [۱۰]، تجزیه و تحلیل کردند که زاویه نصب تأثیر بیشتری بر جمع‌آوری انرژی دارد. این تحقیق در مکان‌های مختلف کشور اتیوپی که دارای زاویه‌های عرض جغرافیایی متفاوتی هستند انجام شده است.

آشیش^۶ و همکاران در سال ۲۰۲۳ [۶] یک آبگرمکن خورشیدی با کلکتور لوله‌ای تخلیه شده (ETC-SWH) را در ماه‌های گرم شهر هیسار هند ($29^{\circ}08'10''N$ $75^{\circ}44'22.0''E$) طراحی و آزمایش کرده‌اند. در ماه مه ۲۰۲۲، محاسبه عملکرد حرارتی بهبود یافته ETC-SWH در شش زاویه نصب مختلف ETC (15° ، 20° ، 25° ، 30° ، 35° و 40°) انجام شد و در زاویه نصب 15° ، بالاترین عملکرد حرارتی ETC-SWH با راندمان 75.04% بدست آمد.

۲-۱- سرعت باد

بالاجی^۷ و همکاران در سال ۲۰۱۸ [۱۱] با انجام آزمایشات تجربی دریافتند که تقویت‌کننده سرعت باد، توربولانس را افزایش می‌دهد و نرخ انتقال حرارت تا 15% بیشتر می‌شود.

۳-۱- استفاده از روش یادگیری ماشین

تای لاهون^۸ و همکاران در سال ۲۰۲۳ [۱۲]، اعلام کردند

یک کلکتور صفحه تخت تشکیل شده است از یک صفحه جاذب که معمولاً تیره رنگ است و قدرت جذب بالایی دارد و یک پوشش شیشه‌ای یا پلاستیکی در بالای آن که اشعه خورشید را بخوبی عبور می‌دهد و با اثر گلخانه‌ای مانع از برگشت انرژی خورشیدی به بیرون می‌شود. در اطراف و زیر صفحه جاذب از عایق پر می‌شود تا اتلاف حرارت به محیط اطراف به کمترین مقدار خود برسد.

راندمان و کارایی یک کلکتور صفحه تخت بستگی زیادی به موقعیت مکانی، پارامترهای طراحی و نحوه نصب آن دارد. پارامترهای طراحی یک کلکتور صفحه تخت عبارتند از: ابعاد و اندازه ها، ضرایب تشعشعی صفحه جاذب و پوشش شیشه‌ای کلکتور، اندازه و تعداد لوله‌های آب خنک‌کننده، و ضرایب انتقال حرارت قسمت‌های مختلف.

بنابراین راندمان و عملکرد یک کلکتور صفحه تخت می‌تواند با تغییر پارامترهای موثر بر آن افزایش یابد. علم استفاده از روش یادگیری ماشین^۲ بطور موثری پارامترهای اثرگذار بر کارکرد یک کلکتور خورشیدی را نمایان خواهد کرد و می‌توان راندمان آن را با استفاده از یادگیری ماشین افزایش داد.

کلکتورهای صفحه تخت (FPC) به طور گسترده و به راحتی قابل تهیه هستند و در مقایسه با سایر کلکتورهای حرارتی، به تعمیر و نگهداری کمتری نیاز دارند. آب گرم آنها برای نظافت، استحمام و استخرهای شنا استفاده می‌شود. معمولاً FPC برای منازل و مشاغل کوچک انتخاب می‌شود.

رایج‌ترین پیکربندی مورد استفاده، کلکتور لوله موازی است که هاتل و ویلیر^۳ عملکرد حرارتی آن را بررسی کردند [۱]. با این حال در این نوع کلکتور به علت ساختار لوله موازی، اتلاف گرما از کلکتور در نتیجه توزیع نامنظم سیال از طریق لوله‌ها و توزیع نابرابر دما بر روی سطح صفحه جاذب، افزایش می‌یابد. طبق نتایج بدست آمده، یک کلکتور با دو لوله موازی که در شرایط مشابه با یک کلکتور تک لوله کار می‌کنند، 10% راندمان بیشتر دارد. همچنین راندمان آن 6% بیشتر از کلکتور با لوله نوع مارپیچی است. افزایش نرخ انتقال حرارت در لوله‌ها یکی دیگر از عوامل مهم در بهبود راندمان FPC است.

⁶ Aashish

⁷ Balaji

⁸ Tilahun

² Machine Learning

³ Hottel and Whillier

⁴ Colangelo

⁵ Siyoum Gudeta

از آنجایی که سیستم‌های حرارتی خورشیدی صنعتی رفتار نامنظم، تصادفی و انعطاف‌پذیری دارند، مدیریت طراحی و تحلیل سیستم‌های خورشیدی وظیفه‌ای دشواری است و بنابراین محققان از روش یادگیری ماشین (ML) برای کمک به تصمیم‌گیری‌های کلان استفاده می‌کنند زیرا امکان نسخه‌های متعددی از یک یا چند ماژول را فراهم می‌کند. در نتیجه، رویکرد طراحی مبتنی بر عملیات برای ادغام سطح عرضه و فرآیند سیستم‌های خورشیدی امکان‌پذیر بود. به این ترتیب در طراحی‌ها، تجهیزات تا بیش از ۱۰ تا ۳۰ درصد کاهش می‌یابند. علاوه بر این، با بهبود مفهوم کنترل کلی سیستم، راندمان خورشیدی تا ۲۳.۷ درصد افزایش یافته است.

سعید^۹ و همکاران در سال ۲۰۲۲ [۸]، دبی جرمی‌های مختلف جریان با نانوسیال در نظر گرفتند. آنها با استفاده از درخت رگرسیون تقویت‌شده (BRT) و همچنین با تقویت گرادیان شدید (XG Boost)، مدل‌های پیش‌بینی برای هر پارامتر را توسعه دادند. استفاده از نمایش‌های گرافیکی تیلور امکان دستیابی به مقادیر R2 را فراهم کرد. مقادیر R2، که نشان‌دهنده قابلیت‌های تشخیصی بهبود یافته مدل‌های توسعه‌یافته هستند، توسط مدل‌های ساخته‌شده با استفاده از BRT از ۰.۹۶۱۹ به ۰.۹۹۹۴ و توسط مدل‌های مبتنی بر XG Boost از ۰.۹۹۱۴ به ۰.۹۹۹۷ افزایش یافت.

چاندان^{۱۰} و همکاران در سال ۲۰۲۲ [۱۳]، از یک مدل آماری عمیق کامپیوتری^{۱۱} برای ارزیابی پایداری سیستم‌های ذخیره‌سازی حرارتی استفاده کردند که منبع آن استفاده از رفتار، تجزیه و تحلیل خواص، تشخیص نقص، تشخیص خطا، پیش‌بینی عمر و تخمین حالت، بود. نتایج شبیه‌سازی ثابت کرد که در مقایسه با وضعیت فعلی، هم خطاهای کمتری در پیش‌بینی، و در عین حال به درجه بالاتری از دقت، دست یافته‌اند. در مقایسه با تکنیک‌های جایگزین، کاهش میزان زمان اختصاص داده شده به مدل‌سازی، ارزیابی‌ها و دستورالعمل‌ها نیز حاصل شده است. در این پژوهش، دقت مدل پیش‌بینی با استفاده از سه روش: جذر میانگین مربعات خطا، خطای مطلق متوسط، و همچنین میزان متوسط درصد خطا، اندازه‌گیری شد.

ژو^{۱۲} و همکاران در سال ۲۰۲۲ [۱۴]، روشی آسان برای پیش‌بینی راندمان حرارتی مبتنی بر نانوسیال FPSC را توسعه دادند. بر اساس این تحلیل، اساسی‌ترین تبدیل برای مدل‌سازی موضوع بررسی، ریشه سه‌چهارم راندمان حرارتی FPSC است. پس از آن، شبیه‌سازی‌های ماشین برای ایجاد رابطه‌های بین راندمان‌های تبدیل‌شده و اندازه‌گیری حرارت با میزان مصرف انرژی جذب‌شده و زاویه نصب کلکتور به کار برده شدند. مناسب‌ترین ابزار برای کار مورد نظر با عملکرد پیش‌بینی همبستگی‌های موجود، شبکه‌های عصبی مصنوعی (ANN)، رگرسیون بردار پشتیبان حداقل مربعات (LS-SVR) و سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) تعیین شدند. یافته‌ها نشان می‌دهد که دقت ارزیابی محاسباتی LS-SVR از عملکرد حرارتی FPSC از سایر همبستگی‌ها بیشتر است. با معیار مربعات خطا (MSE) برابر با ۰.۰۰۰۳۹، ضریب تعیین مرتبط (R2) برابر با ۰.۹۹۳۱ و میانگین مطلق انحراف نسبی (AARD) برابر با ۲.۷۷ درصد، دقیق‌ترین الگو ۵۴۵ مجموعه داده تجربی را پیش‌بینی می‌کند. نتایج این بررسی‌ها نشان داد که اثربخشی حرارتی کلکتورهای خورشیدی در بالاترین مقدار مجاز استفاده از نانوسیالات، حداکثر مقدار پارامترهای انرژی جذب شده و همچنین کمترین مقدار انرژی از دست رفته و متغیرهای دمای کاهش یافته، به حداکثر می‌رسد.


پارامترهای حرارتی و طراحی مختلفی از کلکتورهای صفحه تخت مانند نرخ جریان جرمی، زاویه نصب، مساحت سطح و خواص مواد، توسط محققان مورد مطالعه قرار می‌گیرند که پارامترهایی هستند که می‌توانند در مدل‌های یادگیری ماشین برای پیش‌بینی عملکرد کلکتور در نظر گرفته شوند. همچنین محققان از روش‌های مختلفی مانند جستجوی شبکه‌ای^{۱۳}، جستجوی تصادفی^{۱۴}، بهینه‌سازی بایزین^{۱۵} و اعتبارسنجی متقابل^{۱۶}، برای مدل‌های یادگیری ماشین اعمال شده و برای پیش‌بینی پارامترهای حرارتی کلکتور استفاده می‌کنند. پارامترهایی نیز توسط محققان برای ارزیابی پیش‌بینی‌های مدل‌های یادگیری ماشین استفاده می‌شوند که می‌توان به میانگین خطای مطلق^{۱۷} (MAE)، میانگین مربعات خطا^{۱۸} (MSE)، جذر میانگین مربعات

¹⁴ Random search¹⁵ Bayesian optimization¹⁶ Cross validation¹⁷ Mean Absolute Error¹⁸ Mean Square Error⁹ Said¹⁰ Chandan¹¹ Computer-deep-statistical model¹² Xu¹³ Grid search

است. محاسبه ضریب انتقال حرارت بین صفحه جاذب و پوشش شیشه‌ای، که پارامتر مهمی است، با استفاده از روابط دقیق تر ارائه شده است. این روش تحلیلی، مجموعه جواب جامع و معتبری را برای استفاده در روش یادگیری ماشین ایجاد می‌کند. در روش یادگیری ماشین بکار برده شده از یک روش آسان (روش خطی) در کنار دو روش دقیق تر (رئش درخت تصمیم و روش جنگل تصادفی) استفاده خواهد شد و نتایج آنها با هم مقایسه می‌شوند. در اینجا، پارامترهایی که تحت کنترل مستقیم طراح می‌باشند به عنوان پارامترهای ورودی انتخاب شده‌اند و درصد تاثیر آنها بر راندمان کلکتور به دست آمده است.

۲- کلکتور صفحه تخت و روابط تحلیلی

شکل (۱) یک کلکتور صفحه تخت را نشان می‌دهد که با زاویه β (Tilt angle) نسبت به افق قرار گرفته است. لوله‌های آب خنک‌کننده زیر صفحه جاذب از پایین به بالا در طول کلکتور نصب شده‌اند.



شکل ۱- کلکتور صفحه تخت با زاویه نصب مایل

در شکل (۲) سطح مقطع لوله‌ها با قطر d در عرض کلکتور (w) دیده می‌شوند. در صورتیکه تعداد لوله n باشد و فاصله بین مرکز تا مرکز لوله‌ها به اندازه یک قطر لوله خالی گذاشته شود بنابراین عرض کلکتور برابر خواهد بود با:

$$w = 2nd \quad (1)$$

در حالت کلی، دمای صفحه جاذب (T_p) یکنواخت نیست و تحت تاثیر فاصله لوله‌ها از همدیگر می‌باشد. در اثر جذب انرژی خورشیدی توسط صفحه جاذب، ناحیه‌ای که بین دو لوله قرار دارد گرم‌تر می‌شود و انتقال حرارت هدایت به سمت ناحیه لوله‌ها برقرار خواهد شد (در امتداد محور x) و

خطا^{۱۹} (RMSE) و خطاهای تعدیل شده مربع R^2 ^{۲۰} اشاره کرد. این پارامترها برای اعتبارسنجی قابلیت‌های پیش‌بینی مدل‌های یادگیری ماشین، به‌ویژه هنگام مواجهه با داده‌های محدود، مورد استفاده قرار می‌گیرند.

مدل‌های یادگیری ماشین که برای کلکتورهای صفحه تخت مورد استفاده قرار گرفته‌اند برای پیش‌بینی پارامترهای حرارتی در یک مکان جغرافیایی آموزش دیده‌اند و می‌توانند به مناطق دیگر با شرایط آب و هوایی مختلف نیز تعمیم داده شوند. یادگیری ماشین می‌تواند به پیش‌بینی نتایج یا روندها کمک کند. علاوه بر این، تکنیک‌های یادگیری ماشین می‌توانند وظایف را خودکار کنند و در زمان و منابع صرفه‌جویی نمایند. در نهایت، استفاده از یادگیری ماشین، دقت، کارایی و عمق تحلیل را افزایش می‌دهد و منجر به یافته‌های قوی‌تری خواهد شد. در زمینه‌های دیگر تجدیدپذیر نیز مثل انرژی خورشیدی، بادی و زمین‌گرمایی از مدل‌های یادگیری ماشینی برای پیش‌بینی پارامترهای حرارتی در پنل‌های خورشیدی، توربین‌های بادی و سیستم‌های زمین‌گرمایی برای افزایش تولید و کارایی انرژی استفاده می‌کنند.

علاوه بر یافته‌های ذکر شده تحقیقات قبلی به روش یادگیری ماشین، به این نکته نیز باید اشاره داشت که توانایی روش‌های یادگیری ماشین کاملاً وابسته به کیفیت دیتاهای آن است. بنابراین ممکن است داده‌ها در حدی ناقص باشند و یا از دقت کافی برخوردار نباشند که روش یادگیری ماشین نتایج قابل قبولی ندهد. علاوه بر آن روش یادگیری ماشین می‌تواند برای کاربر خود مثل یک جعبه سیاه (black box) عمل کند و فرایندهای انجام آن بخوبی قابل درک نباشند. در این صورت، احتمالاً تفسیر نتایج بدست آمده با یک بینش بالا انجام نمی‌شود.

در پژوهش حاضر، ابتدا به تحلیل حرارتی جامع تری از یک کلکتور صفحه تخت پرداخته می‌شود و راندمان کلکتور و دمای آب خروجی آن بر حسب سایر پارامترها تعیین می‌گردد. سپس، با استفاده از روش‌های ساده تر و پیچیده‌تر یادگیری ماشین، علاوه بر آنکه پارامترهای تاثیرگذار بر عملکرد کلکتور تعیین می‌شوند، نتایج پیش‌بینی مدل‌های مختلف نیز با هم مقایسه خواهند شد.

در پژوهش پیش رو، تحلیل حرارتی یک کلکتور با انسجام بیشتر و با ارائه قدم به قدم روابط حرارتی مربوطه بیان شده

²⁰ R square

¹⁹ Root Mean Square Error

جابجایی درون لوله‌ها بستگی دارد. بنابراین دمای خروجی آب از لوله (T_{fo}) برابر است با:

$$T_{fo} = T_p - (T_p - T_{fi}) \exp\left(-\frac{PL}{\dot{m}c_p} \bar{h}\right) \quad (۴)$$

در این رابطه دبی جرمی ظاهر شده در ترم نمایی، دبی آب خنک کننده درون هر لوله است و مقدار آن با توجه به تعداد لوله‌ها، درصدی از دبی کل معادله (۲) می‌باشد. P محیط لوله و L طول لوله‌ها در امتداد شیب کلکتور است. $\bar{h}$ متوسط ضریب انتقال حرارت جابجایی درون لوله‌ها است که با فرض توسعه یافتگی جریان بدست می‌آید. در جریان غیر توسعه یافته، ضریب انتقال حرارت بزرگتر است و بنابراین فرض توسعه یافتگی نتایج مطمئن تری را خواهد داد. در جریان آرام عدد نوسلت ($Nu = \frac{\bar{h}D}{k}$) برای لوله با دمای سطح ثابت برابر ۳.۶۶ و در جریان مغشوش از رابطه دیتوس- بولتر بدست می‌آید.

$$Nu = 0.023 Re^{0.8} Pr^{0.4} \quad (۵)$$


همانطور که در جمله دوم معادله (۲) دیده می‌شود اتلاف حرارتی کلکتور به محیط اطراف با ضریب انتقال حرارت کلی U_L صورت می‌گیرد ($q_{loss} = U_L(T_p - T_a)$). این ضریب، ترکیبی از انتقال حرارت جابجایی و تشعشعی بین صفحه جاذب و پوشش شیشه‌ای و همچنین بین پوشش شیشه‌ای و هوای محیط است. با توجه به شکل (۳) و قانون مقاومت‌های حرارتی، می‌توان نوشت:

$$U_L = \frac{1}{R_1 + R_2} \quad (۶)$$

که در آن:


$$\frac{1}{R_1} = h_w + h_{rad,c-a} \quad (۷)$$

$$\frac{1}{R_2} = h_{con,p-c} + h_{rad,p-c}$$



شکل ۳- مقاومت‌های حرارتی یک کلکتور صفحه تخت

بنابراین دما در ناحیه وسط بین دو لوله بزرگتر از دمای نواحی اطراف لوله‌هاست. در ناحیه مجاور لوله‌ها، به علت حضور لوله و جوش اتصال لوله با صفحه جاذب، تقریباً دمای ثابتی ایجاد می‌شود [۱۵]. از طرف دیگر، انرژی منتقل شده از صفحه جاذب به لوله‌های آب باعث افزایش دمای آب درون لوله می‌شود و بنابراین تغییرات دمای صفحه جاذب نسبت به محور y افزایشی خواهد بود.



شکل ۲- توزیع دما در صفحه جاذب

با اینکه توزیع دمای غیر یکنواختی در صفحه جاذب دیده می‌شود ولی در حوزه مسائل مهندسی، دمای صفحه جاذب (T_p) یکنواخت فرض می‌شود. بنابراین، سیال خنک کننده آب در لوله‌هایی حرکت می‌کند که دمای سطح ثابت T_p دارند.

صفحه جاذب انرژی خورشید را پس از عبور از پوشش شیشه‌ای (cover) دریافت می‌کند؛ قسمتی از آن به صورت اتلاف انرژی به محیط با دمای (T_a) پس داده می‌شود و بقیه آن که حرارت مفید است (Q_u) به آب منتقل و آن را گرم می‌کند.

$$Q_u = A_c [\tau \alpha I_T - U_L(T_p - T_a)] = \dot{m}c_p(T_{fo} - T_{fi}) \quad (۲)$$

که در آن، A_c دبی سطح مقطع کلکتور، τ و α به ترتیب ضریب عبور پوشش و ضریب جذب جاذب، I_T شدت تابش خورشیدی، و U_L ضریب افت حرارتی کلکتور است. $\dot{m}$ دبی آب خنک کننده، c_p گرمای ویژه، T_{fi} و T_{fo} به ترتیب دمای ورودی و خروجی آب خنک کننده می‌باشند.

راندمان یک کلکتور نشان دهنده میزان توانایی جذب انرژی خورشیدی و انتقال آن به سیال خنک کننده است.

$$\eta_c = \frac{Q_u}{I_T} = \tau \alpha - \frac{U_L(T_p - T_a)}{I_T} \quad (۳)$$

حرارت منتقل شده به آب باعث افزایش دمای آن در طول لوله‌ها می‌شود و مقدار افزایش دما به ضریب انتقال حرارت

است.

از روابط مشابهی می توان برای تعیین حرارت منتقل شده بین پوشش شیشه‌ای و هوای اطراف استفاده کرد. ضریب انتقال حرارت جابجایی شیشه و هوای محیط تابعی از سرعت باد است.

$$h_W = 2.8 + 3.0V_W \quad (۱۳)$$

که V_W سرعت باد می باشد.

تشعشع بین پوشش شیشه‌ای و محیط اطراف، با دمای آسمان (T_{sky}) محاسبه می‌شود و دمای آسمان به دمای هوای اطراف مرتبط است.

$$T_{sky} = 0.0559T_a^{1.5} \quad (۱۴)$$

بنابراین:

$$h_{rad,c-a} = \frac{\sigma \varepsilon_c (T_c + T_{sky})(T_c^2 - T_{sky}^2)(T_c - T_{sky})}{T_c - T_a} \quad (۱۵)$$

در اینجا نیز می‌توان q_{loss} را بر حسب پارامترهای بین شیشه و هوا بیان نمود:

$$q_{loss} = (h_W + h_{rad,c-a})(T_c - T_a) \quad (۱۶)$$

با توجه به اینکه برای تعیین بعضی از پارامترها، هم دمای جاذب و هم دمای شیشه مورد نیاز هستند. بنابراین محاسبات به روش تکرار و با حدس اولیه برای دمای صفحه جاذب و پوشش شیشه‌ای شروع و ادامه می یابد تا به روش تکرار، دماها به دماهای نهایی همگرا شوند.

دمای سکون (T_{st}) برای یک کلکتور صفحه تخت، دمای صفحه جاذب در حالتی است که انرژی جذب شده توسط صفحه جاذب به سیال خنک کننده منتقل نشود و تمام آن انرژی به صورت تبادل با محیط تلف شود. در اینصورت دمای صفحه جاذب به بالاترین مقدار خود یعنی دمای سکون^{۲۱} می‌رسد.

$$T_{st} = T_a + \frac{\tau \alpha I_T}{U_L} \quad (۱۷)$$

۳- نتایج دمای صفحه جاذب، دمای خروجی آب و راندمان کلکتور

کلکتور در نظر گرفته یک کلکتور صفحه تخت با صفحه جاذب از جنس مسی و با پوشش شیشه‌ای است. کلکتور بطور مایل با زاویه ۴۵ درجه در مقابل اشعه خورشید قرار

ضریب انتقال حرارت جابجایی بین صفحه جاذب (T_p) و پوشش شیشه‌ای (T_c) است. در فاصله هوایی بین صفحه جاذب و پوشش شیشه‌ای، سلول های جابجایی آزاد تشکیل می‌شوند و می توان ضریب انتقال حرارت جابجایی را برای کلکتوری که با زاویه β نسبت به افق نصب شده از رابطه (۸) بدست آورد. در اینجا عدد نوسلت بر حسب اعداد رایلی و پراتل بدست می‌آید [۱۵].

$$Nu = 1 + 1.44 \left[1 - \frac{1708(\sin 1.8\beta)^{1.6}}{Ra \cos \beta} \right] \times \left[1 - \frac{1708}{Ra \cos \beta} \right]^+ + \left[\left(\frac{Ra \cos \beta}{5830} \right)^{1/3} - 1 \right]^+ \quad (۸)$$

ضریب انتقال حرارت از عدد نوسلت قابل محاسبه است ($h = \frac{Nuk}{l}$) و l فاصله گپ هوایی بین جاذب و شیشه می‌باشد. این رابطه برای زوایای β بین صفر تا ۷۵ درجه کاربرد دارد.

عدد رایلی:

$$Ra = \frac{g\beta'\Delta T l^3}{\alpha \nu} \quad (۹)$$

ΔT اختلاف دمای جاذب و شیشه است. β' ضریب انبساط حجمی هوای محبوس شده بین جاذب و شیشه می‌باشد و می توان آن را با دمای متوسط جاذب و شیشه بدست آورد ($\beta' = 1/T$). ضریب ویسکوزیته سینماتیکی و ضریب نفوذ حرارتی هوا به ترتیب ν و α می‌باشند.

در رابطه (۸)، علامت باضافه در بالای کروشه ها نشان دهنده آن است که اگر مقدار محاسبه شده در کروشه مثبت باشد مقدار آن در محاسبات باقی می‌ماند و اگر منفی باشد کروشه برابر صفر است. عدد نوسلت برابر یک نشان دهنده انتقال حرارت هدایت در فضای بین جاذب و پوشش است. بنابراین بین جاذب و شیشه ترکیبی از انتقال حرارت جابجایی و تشعشع حاکم است:

$$q_{loss} = h_{con,p-c}(T_p - T_c) + \frac{\sigma(T_p^4 - T_c^4)}{\frac{1}{\varepsilon_p} + \frac{1}{\varepsilon_c} - 1} \quad (۱۰)$$

$$q_{loss} = (h_{con,p-c} + h_{rad,p-c})(T_p - T_c) \quad (۱۱)$$

$$h_{rad,p-c} = \frac{\sigma(T_p + T_c)(T_p^2 - T_c^2)}{\frac{1}{\varepsilon_p} + \frac{1}{\varepsilon_c} - 1} \quad (۱۲)$$

ε_p و ε_c به ترتیب ضریب صدور جاذب و شیشه می‌باشند. σ ثابت استفان-بولتزمن و مقدار آن $5.67 \times 10^{-8} W.m^{-2}K^{-4}$

²¹ Stagnation temperature

۴- استفاده از روش یادگیری ماشین برای تعیین

پارامترهای تاثیرگذار

بعضی از پارامترهای کلکتور صفحه تخت در محدوده‌های مشخصی، بهترین عملکرد کلکتور را تضمین می‌کنند. بعضی از پارامترها تاثیر خیلی بیشتری بر عملکرد کلکتور و بعضی دیگر تاثیر کمتری را خواهند داشت.

پارامترهای:

- شدت تابش خورشید (I_T)
- زاویه نصب کلکتور با افق (β)
- سرعت باد (V_W)
- قطر لوله‌ها (d)
- تعداد لوله‌ها (n)
- دمای محیط (T_a)
- دبی آب خنک‌کننده (m)

که از پارامترهای اصلی یک کلکتور می‌باشند بعنوان پارامترهای ورودی (inputs) انتخاب شده‌اند و می‌توانند در طراحی و در شرایط آب و هوایی مختلف، متغیر باشند. انتخاب این پارامترها به این خاطر است که می‌توانند توسط طراح قابل تغییر باشند. انتخاب شدت تابش نیز بیانگر انرژی حاصل از خورشید در مناطق مختلف است و بنابراین تاثیر منطقه جغرافیایی را نشان می‌دهد. در جدول ۲ محدوده قابل قبولی از پارامترهای ورودی در نظر گرفته شده است. راندمان کلکتور بعنوان پارامتر خروجی (outputs) در نظر گرفته شده است.

جدول ۲- بازه تغییرات پارامترهای ورودی

پارامتر	بازه
شدت تابش خورشید (I_T)	600, 800, 1000, 1200 (W/m^2)
زاویه نصب کلکتور (β)	15, 30, 45, 60, 75 (degree)
سرعت باد (V_W)	0, 5, 10, 15 (m/s)
قطر لوله‌ها (d)	6, 8, 10 (cm)
تعداد لوله‌ها (n)	6, 8, 10
دمای محیط (T_a)	15, 20, 25, 30, 35 ($^{\circ}C$)
دبی آب خنک‌کننده	0.2, 0.4, 0.6, 0.8, 1, 1.2 (lit/min)

۴-۱ روش یادگیری ماشین خطی

روش خطی یک روش ساده یادگیری ماشین است که می‌تواند با چند ورودی مورد استفاده قرار گیرد و به اختصار به آن MLR گفته می‌شود^{۲۲}.


گرفته است. آب خنک از پایین وارد و پس از گرم شدن از بالا خارج می‌شود. در جدول ۱ سایر مشخصات آورده شده است.

با مقادیر داده شده، دمای سکون کلکتور از رابطه (۱۷) برابر با $132.5^{\circ}C$ خواهد بود.

جدول ۱- مشخصات کلکتور صفحه تخت

پارامتر	مقدار
شدت تابش خورشید (I_T)	800 (W/m^2)
زاویه نصب کلکتور (β)	45 (degree)
دمای آب ورودی (T_{fi})	15 ($^{\circ}C$)
طول کلکتور (L)	2 m
ضریب عبور پوشش شیشه‌ای (τ)	0.8
ضریب جذب صفحه جاذب (α)	0.9
دبی آب خنک‌کننده	1 (lit/min)
ضریب صدور جاذب (ϵ_p)	0.95
ضریب صدور شیشه (ϵ_c)	0.88
دمای محیط (T_a)	25 ($^{\circ}C$)
سرعت باد (V_W)	5 (m/s)
فاصله گپ هوایی جاذب و شیشه (l)	15 (cm)
قطر لوله‌ها (d)	6 (cm)
تعداد لوله‌ها (n)	6

شکل (۴) تغییرات دمای صفحه جاذب، دمای آب خروجی و راندمان کلکتور را بر حسب دبی آب خنک‌کننده نشان می‌دهد. این نتایج از تحلیل‌های روابط حرارتی بیان شده قبلی بدست آمده‌اند. در شکل دمای آب ورودی، دمای هوای محیط و دمای سکون کلکتور نیز ترسیم شده تا محدوده کاری کلکتور نسبت به آنها نمایان شود. در دبی‌های کمتر از ۰.۲ لیتر بر ثانیه دمای صفحه جاذب بالاتر می‌رود و به دمای سکون نزدیک می‌شود.



شکل ۴- تغییرات دمای جاذب، دمای خروجی آب و راندمان کلکتور بر حسب دبی آب ورودی

میانگین خطای مطلق^{۲۴} (MAE) یک معیار رگرسیونی برای اندازه‌گیری خطا است که به جمع قدر مطلق اختلاف بین پیش‌بینی‌های یک مدل و داده‌های پایه که به طور میانگین در کل مجموعه داده‌ها محاسبه شده‌اند، نگاه می‌کند. برخلاف MSE، پارامتر MAE وزن‌دهی می‌شود و بنابراین وزن زیادی به داده‌های نامعتبر نمی‌دهد.

$$MAE = \left(\frac{1}{n}\right) \sum |predicted\ value - actual\ value| \quad (21)$$

RMSE یک معیار تخمینی از میزان انحراف مقادیر پیش‌بینی‌شده، به طور متوسط، از مقادیر واقعی در مجموعه داده‌ها ارائه می‌دهد. در یادگیری ماشین، داشتن یک عدد واحد برای قضاوت در مورد عملکرد یک مدل، چه در طول آموزش، اعتبارسنجی متقابل یا نظارت پس از استقرار، بسیار مفید است.

$$RMSE = \sqrt{\frac{\sum (predicted\ value - actual\ value)^2}{n}} \quad (22)$$

در خصوص شاخص‌های ارزیابی معرفی شده، MAE در برابر داده‌های پرت مقاوم‌تر است و میانگین خطا را در همان واحد داده‌ها ارائه می‌دهد و تفسیر آنها را آسان می‌کند. MSE خطاهای بزرگتر را تقویت می‌کند و این امر زمانی مفید است که خطاهای بزرگتر به طور خاص پرهزینه باشند و اغلب به عنوان یک تابع زیان در آموزش مدل استفاده می‌شود. RMSE مزایای MSE و MAE را ترکیب می‌کند و یک معیار خطا ارائه می‌دهد که خطاهای بزرگ را جریمه می‌کند و قابل تفسیر باقی می‌ماند.

در عمل، انتخاب بین MAE، MSE و RMSE به الزامات خاص مسئله مورد نظر بستگی دارد. اگر موضوع مورد بحث به یک معیار ساده و قابل تفسیر نیاز دارد، MAE ممکن است بهترین انتخاب باشد. اگر نیاز است که خطاهای بزرگتر به شدت جریمه شوند، MSE یا RMSE ممکن است مناسب‌تر باشند.

شاخص‌های ارزیابی مدل خطی عبارتند از:

$$\begin{aligned} MSE: 23.232777 \\ R^2: 0.849277 \\ MAE: 4.058011 \\ RMSE: 4.820039 \end{aligned}$$


معادله این روش به صورت:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon \quad (18)$$

که:

y : متغیر وابسته، x ها متغیرهای مستقل ورودی وابسته، β ها ضرایب شیب، β_0 عرض از مبدا، و ϵ ترم خطا است.

شکل (۵) راندمان پیش‌بینی شده با روش خطی را در مقابل راندمان واقعی نشان می‌دهد. خط چین رسم شده در شکل نیمساز ربع اول است و انحراف از آن نشان می‌دهد که با این روش به چه میزان مقادیر پیش‌بینی از مقادیر واقعی انحراف خواهند داشت.



شکل ۵- مقایسه مقادیر پیش‌بینی و مقادیر واقعی راندمان در روش یادگیری ماشین خطی

دقت رگرسیون را می‌توان با پارامتر خطای میانگین مربعات^{۲۳} (MSE) اندازه‌گیری کرد. این پارامتر متوسط اختلاف مربعات بین مقادیر پیش‌بینی و مقادیر واقعی را نشان می‌دهد و بعنوان یک ارزیابی از اینکه تا چه حد پیش‌بینی یک مدل به واقعیت نزدیک است را بدست می‌دهد. هر چه مقدار MSE کوچکتر باشد نشان از مدل بهتری برای پیش‌بینی است.

$$MSE = \left(\frac{1}{n}\right) \sum (predicted\ value - actual\ value)^2 \quad (19)$$

و n تعداد داده‌ها می‌باشد.


R^2 نشان دهنده درصد تغییر پذیری خروجی مدل نسبت به ورودی‌هاست. هر چه مقدار آن به عدد یک نزدیک‌تر باشد نشان می‌دهد که مدل بهتر می‌تواند داده‌ها را پوشش دهد.

$$\begin{aligned} R^2 &= 1 - \frac{SSR}{SST} \\ &= \frac{\sum (actual\ value - predicted\ value)^2}{\sum (actual\ value - actuals\ mean)^2} \quad (20) \end{aligned}$$

²⁴ Mean Absolute Error

²³ Mean Squared Error

در شکل (۷) تاثیر پارامترهای ورودی بر راندمان کلکتور نشان داده شده است. دیده می‌شود که تاثیر سه پارامتر: زاویه نصب، سرعت باد، و تابش خورشیدی بر مقدار راندمان بسیار ناچیز است. تعداد لوله‌ها و دمای محیط تاثیر متوسطی (هر کدام ۰.۷٪) بر راندمان دارند در حالیکه تاثیر شعاع لوله‌ها به حدود ۱۰٪ رسیده و تاثیرگذارترین پارامتر دبی جریان آب خنک‌کننده با تاثیر ۷۰٪ می‌باشد.



شکل ۷- مقایسه تاثیر پارامترهای ورودی بر راندمان کلکتور با مدل درخت تصمیم

۳-۴- روش یادگیری ماشین جنگل تصادفی^{۲۶}

جنگل تصادفی یک الگوریتم یادگیری ماشین پرکاربرد است و خروجی چندین درخت تصمیم را برای رسیدن به یک نتیجه واحد ترکیب می‌کند. سهولت استفاده و انعطاف‌پذیری این روش همراه با اثربخشی آن باعث افزایش محبوبیت آن شده است.

در روش کلی جنگل‌های تصمیم‌گیری تصادفی، از یک الگوریتم درخت تصمیم‌گیری تصادفی برای ایجاد چندین درخت و سپس ترکیب آنها با استفاده از رأی‌گیری اکثریت استفاده می‌کند. جنگل‌های درختانی که با ابرصفحه‌های مورب تقسیم می‌شوند، می‌توانند با رشد خود بدون آسیب دیدن از آموزش بیش از حد، دقت بیشتری کسب کنند مادامی که جنگل‌ها به طور تصادفی محدود به حساسیت فقط به ابعاد ویژگی انتخاب شده باشند.

پیش‌بینی‌های روش جنگل تصادفی نسبت به دو روش قبلی به مقادیر واقعی نزدیک‌تر می‌باشد بطوریکه شاخص‌های ارزیابی آن عبارتند از:


$$\begin{aligned} MSE: & 0.049623 \\ R^2: & 0.999678 \\ MAE: & 0.15825 \\ RMSE: & 0.222761 \end{aligned}$$

۲-۴- روش یادگیری ماشین درخت تصمیم^{۲۵}

رگرسیون درخت تصمیم غیرخطی است و به طور گسترده در یادگیری ماشین استفاده می‌شود. برخلاف رگرسیون خطی، درخت‌های تصمیم، فضای ویژگی‌ها را به روشی سلسله‌مراتبی و مبتنی بر قانون تقسیم می‌کنند که آنها را قادر می‌سازد روابط پیچیده و غیرخطی را ثبت کنند. این مدل به طور مداوم داده‌ها را بر اساس ویژگی‌هایی که منجر به کمترین خطای پیش‌بینی می‌شوند، به زیرمجموعه‌هایی تقسیم می‌کند و یک ساختار درخت مانند تشکیل می‌دهد.

این ساختار به مدل اجازه می‌دهد تا با تمرکز بر به حداقل رساندن خطاها از طریق تقسیم‌بندی‌ها، روابط غیرخطی در داده‌ها را ثبت کند.

رگرسیون‌های درخت تصمیم معمولاً از میانگین مربعات خطا (MSE) به عنوان معیاری برای به حداقل رساندن خطا استفاده می‌کنند. هنگام در نظر گرفتن تقسیم‌بندی در یک گره، هدف مدل کاهش MSE متغیر هدف است. با استفاده از این روش، پیش‌بینی نتایج راندمان کلکتور بدست آمده و در شکل (۶) نشان داده شده است.



شکل ۶- مقدار پیش‌بینی و مقدار واقعی راندمان با مدل درخت تصمیم

با مدل درخت تصمیم، شاخص‌های ارزیابی نسبت به مدل خطی تغییر زیادی دارند و عبارتند از:

$$\begin{aligned} MSE: & 0.073191 \\ R^2: & 0.999525 \\ MAE: & 0.199172 \\ RMSE: & 0.270538 \end{aligned}$$

²⁶ Random Forest Regression

²⁵ Decision Tree Regression

مقایسه شاخص های ارزیابی نشان می دهد که هر دو مدل درخت تصمیم و جنگل تصادفی به طور قابل توجهی نسبت به مدل خطی دقیق تر و ارزیابی بهتری را نشان می دهند. در اینجا، عملکرد مدل درخت تصمیم با مدل جنگل تصادفی تفاوت مشهودی ندارد و هر دو مدل برای تعیین راندمان کلکتور تقریباً به صورت مشابه ارزیابی داشته اند، ولی با اینحال، مدل جنگل تصادفی دقت بالاتری دارد.

۵- نتیجه گیری

در کار حاضر، ابتدا روابط تحلیلی و قوانین حاکم بر میزان جذب و راندمان تبدیل خورشیدی به حرارتی یک کلکتور صفحه تخت معرفی شد.

برای کلکتور در نظر گرفته شده، دمای سکون کلکتور برابر با ۱۳۲.۵ درجه سانتیگراد بود (دمای صفحه جاذب). در این شرایط دبی آب خنک کننده صفر است.


با افزایش دبی آب خنک کننده، دمای صفحه جاذب کاهش یافته و راندمان کلکتور بیشتر می شود بطوریکه در دبی آب یک لیتر بر دقیقه دمای صفحه جاذب به ۳۳ درجه سانتیگراد و راندمان کلکتور به ۷۷٪ خواهد رسید.

برای پیش بینی راندمان کلکتور با روش یادگیری ماشین، سه مدل: خطی، درخت تصمیم، و جنگل تصادفی، به کار برده شد. هفت پارامتر: شدت تابش خورشید (I_T)، زاویه کلکتور با افق (β)، سرعت باد (V_W)، قطر لوله ها (d)، تعداد لوله ها (n)، دمای محیط (T_a)، و دبی آب خنک کننده ($\dot{m}$)، بعنوان پارامترهای ورودی انتخاب شدند.

مقادیر شاخص های ارزیابی نیز در جدول ۳ با هم مقایسه شده اند. مقایسه راندمان پیش بینی در مقایسه با مقادیر واقعی و شاخص های ارزیابی نشان دادند که مدل خطی دارای ارزیابی ضعیف تری نسبت به دو مدل دیگر است. مدل های درخت تصمیم و جنگل تصادفی با توانایی تقریباً یکسان و با دقت بالایی پیش بینی را انجام می دهند (دقت مدل جنگل تصادفی با اختلاف ناچیزی بالاتر از مدل درخت تصمیم).


علاوه بر آن، در میان پارامترهای ورودی، تاثیر زاویه نصب، سرعت باد و تابش خورشیدی بر مقدار راندمان خیلی ناچیز است. بیشترین تاثیر را دبی آب خنک کننده دارد. سه پارامتر: تعداد لوله ها، دمای محیط، و قطر لوله ها، با تاثیر متوسط رو به پایین و تقریباً اثرگذاری هر سه یکسان است. به منظور استفاده از نتایج یک نمونه واقعی، در نظر است

شکل (۸) راندمان پیش بینی شده با روش جنگل تصادفی را نشان می دهد.



شکل ۸- مقدار پیش بینی و مقدار واقعی راندمان با مدل جنگل تصادفی

علاوه بر پیش بینی این روش، تاثیر ورودی ها نیز بر راندمان کلکتور در شکل (۹) آورده شده است. در اینجا نیز نتایج مشابهی با نتایج مدل درخت تصمیم دیده می شود. تاثیر زاویه نصب، سرعت باد و تابش خورشیدی روی راندمان خیلی ناچیز است و بیشترین تاثیر را دبی جرمی آب خنک کننده دارد. تعداد لوله ها، شعاع لوله ها و دمای محیط نیز تاثیر متوسط رو به پایین دارند.



شکل ۹- مقایسه تاثیر پارامترهای ورودی بر راندمان کلکتور با روش جنگل تصادفی

۴-۴- مقایسه شاخص های ارزیابی سه مدل

شاخص های ارزیابی که پیشتر معرفی شدند در جدول ۳ برای هر سه مدل مقایسه شده اند.

جدول ۳- مقایسه شاخص های ارزیابی سه مدل

مدل	MSE	R ²	MAE	RMSE
خطی	23.232777	0.849277	4.058011	4.820039
درخت تصمیم	0.073191	0.999525	0.199172	0.270538
جنگل تصادفی	0.049623	0.999678	0.15825	0.222761

تأییدیه اخلاقی

نویسندگان متعهد می‌شوند که مطالب این مقاله را در هیچ مجله دیگری به چاپ نرسانده‌اند.

مشارکت‌های نویسندگان

مهتاب سلیمی: انجام محاسبات و بدست آوردن نتایج
سعادت زیرک: تنظیم و نگارش مقاله، نظارت بر محاسبات

منابع مالی

از منابع مالی شخصی استفاده شده است.

که در کارهای آینده یک ست آپ آزمایشگاهی از این کلکتور ساخته شود و بر اساس داده‌های استخراج شده از آن، برنامه‌ریزی برای تنظیم روش یادگیری ماشین با داده‌های تجربی انجام شود.

تعارض منافع

نویسندگان اعلام می‌کنند که در مورد انتشار این مقاله تعارض منافع وجود ندارند.

مراجع

- [1] Hottel, Hoyte, and Austin Whillier. "Evaluation of flat-plate solar collector performance." Trans. Conf. Use Sol. Energy 3, (1954): 12–13.
- [2] Colangelo, Gianpiero, Ernani Favale, Paola Miglietta, and Arturo De Risi. "Innovation in flat solar thermal collectors: A review of the last ten years experimental results." Renewable and Sustainable Energy Reviews 57 (2016): 1141-1159.
- [3] Sharif, MK Anuar, A. A. Al-Abidi, Sohif Mat, Kamaruzzaman Sopian, Mohd Hafidz Ruslan, M. Y. Sulaiman, and M. A. M. Rosli. "Review of the application of phase change material for heating and domestic hot water systems." Renewable and Sustainable Energy Reviews 42 (2015): 557-568.
- [4] Jamar, A. M. Z. A. A., Z. A. A. Majid, W. H. Azmi, M. Norhafana, and A. A. Razak. "A review of water heating system for solar energy applications." International Communications in Heat and Mass Transfer 76 (2016): 178-187.
- [5] Pambudi, Nugroho Agung, Iksan Riva Nanda, and Andi Dwi Saputro. "The energy efficiency of a modified v-corrugated zinc collector on the performance of solar water heater (SWH)." Results in Engineering 18 (2023): 101174.
- [6] Kumar, Mahesh, Bhawan Singh Negi, Rahul Grewal, and Himanshu Manchanda. "Assessment of an ETC based solar water heater at different tilt angles." Materials Today: Proceedings (2023).
- [7] Ji, Yasheng, Jinzhi Zhou, Bisengimana Emmanuel, Lin Wang, Lin Lu, and Yanping Yuan. "Assessment of factors affecting the performance of a novel double condenser heat pipe Photovoltaic-thermal (PV/T) system in hot water mode: An experimental study in the lab." Thermal Science and Engineering Progress 37 (2023): 101607.
- [8] Said, Zafar, Prabhakar Sharma, L. Syam Sundar, Changhe Li, Duy Cuong Tran, Nguyen Dang Khoa Pham, and Xuan Phuong Nguyen. "Improving the thermal efficiency of a solar flat plate collector using MWCNT-Fe₃O₄/water hybrid nanofluids and ensemble machine learning." Case Studies in Thermal Engineering 40 (2022): 102448.
- [9] Pawar, Vivek R., and Sarvenaz Sobhansarbandi. "Heat transfer enhancement of a PCM-porous metal based heat pipe evacuated tube solar collector: An experimental study." Solar Energy 251 (2023): 106-118.
- [10] Siyoum, Mesay. "Performance analysis of solar water heater system with heat pipe evacuated tube collector on moha soft drink industries in ethiopia." (2020).
- [11] Balaji, K., S. Iniyan, and Ranko Goic. "Thermal performance of solar water heater using velocity enhancer." Renewable Energy 115 (2018): 887-895.
- [12] Tilahun, Fitsum Bekele. "Machine learning interfaces for modular modelling and operation-based design optimization of solar thermal systems in process industry." Engineering Applications of Artificial Intelligence 127 (2024): 107285.
- [13] Chandan, Radha Raman, C. R. Aditya, R. Elankeerthana, K. Anitha, R. Sabitha, Ravishankar Sathyamurthy, V. Mohanavel, and M. Sudhakar. "Machine learning Technique for improving the stability of Thermal Energy storage." Energy Reports 8 (2022): 897-907.

- [14] Xu, Lan, Aboozar Khalifeh, Amith Khandakar, and Behzad Vaferi. "Numerical investigating the effect of Al₂O₃-water nanofluids on the thermal efficiency of flat plate solar collectors." *Energy Reports* 8 (2022): 6530-6542.
- [15] Duffie, John A., and William A. Beckman. *Solar engineering of thermal processes*. John Wiley & Sons, 2013.