



مروری بر مدل های یادگیری ماشین نظارت شده در بهینه سازی سیستم های ذخیره سازی حرارت نهان PMC

چکیده: در این پژوهش، مروری جامع بر کاربرد مدل های یادگیری ماشین نظارت شده در پیش بینی و بهینه سازی عملکرد سیستم های ذخیره سازی حرارت نهان با استفاده از مواد تغییر فاز انجام شده است. هدف اصلی مطالعه، شناسایی مدل های پرکاربرد، مقایسه دقت آن ها و بررسی نوآوری های طراحی هندسی و بهبود انتقال حرارت در این سیستم ها می باشد. نتایج نشان داد که شبکه های عصبی مصنوعی و عمیق به عنوان محبوب ترین مدل ها اغلب در ترکیب با الگوریتم های تکاملی نظیر الگوریتم ژنتیک و بهینه سازی ازدحام ذرات برای بهینه سازی همزمان به کار گرفته شده اند. سایر مدل های مؤثر شامل جنگل تصادفی و رگرسیون بردار پشتیبان برای داده های محدود و مدل های تقویتی (XGBoost و LightGBM) برای بهبود دقت و تفسیرپذیری می باشند. همچنین، رگرسیون فرایند گاوسی با قابلیت تخمین عدم قطعیت در برخی مطالعات به کار رفته است. این مرور بیان می کند که یادگیری ماشین توانسته محدودیت های مدل سازی دینامیک سیالات محاسباتی را جبران کرده و روابط پیچیده میان پارامترهای هندسی و عملیاتی را با دقت بالا مدل سازی نماید. در نهایت، استفاده از مدل های ترکیبی و رویکردهای چندهدفه، راهکار مؤثری برای بهینه سازی سیستم های ذخیره سازی حرارت نهان مبتنی بر مواد تغییر فاز خواهد بود.

واژه های راهنما: مدل سازی سیستم های انرژی، ذخیره ساز حرارت انرژی نهان، مواد تغییر فاز دهنده، یادگیری ماشین، مدل های یادگیری ماشین نظارت شده

امیرعلی سیف الدین*

دانشیار،
دانشکده انرژی و منابع پایدار،
دانشکده های علوم و فناوری های
میان رشته ای/
رئیس مؤسسه فناوری های نرم،
دانشگاه تهران

شیدا نادعلی پور کلد

دانشجوی کارشناسی ارشد

محمدعلی اله ربی شیرازی

دانشجوی دکتری،
دانشکده انرژی و منابع پایدار،
دانشکده های علوم و فناوری های
میان رشته ای، دانشگاه تهران

مقاله مروری

دریافت: ۱۴۰۴/۰۶/۲۶

بازنگری: ۱۴۰۴/۱۰/۱۵

پذیرش: ۱۴۰۴/۱۱/۲۵

Amirali Saifoddin*

Associate Professor,
School of Energy
Engineering and Sustainable
Resources,
College of Interdisciplinary
Science and Technology/
Head of Soft Technologies
Institute,
University of Tehran

Sheida

Nadalipour Kaldeh
M.Sc. Student

Mohammadali

Allahrabbi Shirazi
PhD Candidate,
School of Energy
Engineering and Sustainable
Resources,
College of Interdisciplinary
Science and Technology,
University of Tehran

A Review of supervised machine learning models in the optimization of latent heat thermal energy storage systems using PCM

Abstract: This study introduces a simple geometric model for evaluating the effect of shadow on the solar radiation received by photovoltaic (PV) systems. In this method, the shadow effect is modeled by separating beam and diffuse irradiance, where shadowed regions are defined as areas with no direct beam. The beam radiation coefficient is defined as the ratio of the sun-exposed area to the total system surface, while the diffuse radiation coefficient is determined using the view factor between the system and the obstacle to account for sky radiation. The simplicity of the geometric relations enables rapid and reasonably accurate radiation estimation under different shadow conditions. Comparison with a numerical case using reliable data shows a mean absolute difference of 11%. The proposed model performed better than the analytical model considered. Despite its simplicity, the model provides sufficient accuracy for engineering applications and supports estimating incident radiation on building-integrated photovoltaic thermal system.

Keywords: Energy system modeling, Latent heat thermal energy storage, Phase change materials, Machine learning, Supervised machine learning models

۱- مقدمه و مرور ادبیات

گذار جهانی به سوی نظام‌های انرژی کم‌کربن و افزایش بهره‌گیری از منابع تجدیدپذیر، چشم‌انداز انرژی را به‌طور بنیادین دگرگون ساخته است؛ فرآیندی که با پیشرفت‌های فناوری، تغییرات سیاستی و اولویت‌های نوین اجتماعی-اقتصادی هدایت می‌شود [۱-۳]. با وجود مزایای فراوان منابع تجدیدپذیر، ناپایداری ذاتی آنها موجب ایجاد شکاف میان عرضه و تقاضای انرژی شده و چالش‌هایی جدی در تضمین تأمین پایدار انرژی به وجود آورده است [۴]. در این میان، سیستم‌های ذخیره‌سازی انرژی نقش کلیدی در پر کردن فاصله زمانی میان تولید و مصرف ایفا می‌کنند [۴]. ذخیره‌سازی حرارتی^۱، به‌ویژه به عنوان یکی از مهم‌ترین فناوری‌ها، از طریق ذخیره حرارت مازاد (معمولاً حاصل از منابع تجدیدپذیر) و آزادسازی آن در زمان اوج تقاضا در افزایش تاب‌آوری سیستم، کاهش وابستگی به منابع فسیلی و ارتقای بهره‌وری انرژی مؤثر است [۵].

از میان انواع فناوری‌های ذخیره‌سازی حرارتی، ذخیره‌سازی انرژی حرارت نهان^۲ با استفاده از مواد تغییر فاز دهنده^۳ به دلیل چگالی بالای ذخیره‌سازی انرژی و پایداری حرارتی، در دهه‌های اخیر توجه گسترده‌ای را به خود جلب کرده است [۶-۸]. شبیه‌سازی عددی فرآیندهای ذوب و انجماد PCM معمولاً به کمک دینامیک سیالات محاسباتی^۴ انجام می‌شود. اگرچه روش CFD دقت بالایی دارد، اما پرهزینه، زمان‌بر و پیچیده بوده و برای طراحی‌های تکرار شونده یا بهینه‌سازی‌های محدودیت‌هایی را ایجاد می‌کند [۹]. بنابراین، نیاز به ابزارهای پیش‌بینی سریع‌تر و کارآمدتر بیش از پیش احساس می‌شود.

در سال‌های اخیر، مدل‌های یادگیری ماشین نظارت‌شده^۵ به عنوان جایگزین یا مکملی سریع و دقیق برای مدل‌های CFD و داده‌های آزمایشگاهی مطرح شده‌اند [۱۰، ۱۱]. این مدل‌ها با آموزش روی داده‌های ورودی-خروجی به‌دست‌آمده از شبیه‌سازی یا آزمایش قادر هستند عملکرد سیستم را با هزینه محاسباتی ناچیز پیش‌بینی و حتی بهینه‌سازی کنند. الگوریتم‌های متداول در این حوزه و به صورت کلی مهندسی انرژی، شامل شبکه‌های عصبی مصنوعی^۶، شبکه‌های عصبی عمیق^۷، درخت تصمیم^۸ و مدل‌های جنگل تصادفی^۹، رگرسیون

بردار پشتیبان^{۱۰} و روش‌های مبتنی بر گرادیان^{۱۱} نظیر بوستینگ گرادیان^{۱۲} پیشرفته^{۱۳} و ماشین بوستینگ گرادیان^{۱۴} سبک^{۱۵} هستند که مطالعات خوبی در این زمینه هم انجام شده است [۱۲-۱۴]. افزون بر این، ترکیب شبکه‌های عصبی با الگوریتم‌های تکاملی^{۱۶} نظیر الگوریتم ژنتیک^{۱۵} و بهینه‌سازی ازدحام ذرات^{۱۶} امکان جست‌وجوی فضای طراحی و یافتن پیکربندی‌های بهینه را فراهم می‌سازد [۱۵، ۱۶]. پژوهش‌های اخیر در حوزه PCM نشان می‌دهد مسیر پیشرفت این حوزه عمدتاً در دو جهت اصلی ارتقای خواص مواد و طراحی‌های نوآورانه و بهره‌گیری از ابزارهای عددی و هوش مصنوعی جهت پیش‌بینی و بهینه‌سازی عملکرد دنبال می‌شود. یکی از محورهای تحقیق، بهبود ویژگی‌های حرارتی PCM با افزودنی‌های نوین است. برای نمونه، Kottala و همکاران نشان داده‌اند افزودن گرافیت منبسط شده (EG) به PCM نه تنها رسانایی حرارتی را افزایش می‌دهد؛ بلکه مدل‌سازی مبتنی بر یادگیری ماشین راهکاری سریع و دقیق برای پیش‌بینی عملکرد TES ارائه می‌دهد [۱۷]. سبه همین ترتیب، Bharathiraja و همکاران با استفاده از نانوذرات BN و ZnO توانستند رسانایی PCM را تا ۶۰ درصد افزایش داده و بازده کلکتور خورشیدی تخت را بهبود دهند [۱۸]. در مطالعاتی دیگر Kazaz و همکاران با طراحی نانومعماری [۱۹] و Nandi و همکاران با بررسی افزودنی‌هایی مانند گرافن، Al_2O_3 و CuO موفق به بهبود چشمگیر انتقال حرارت و عملکرد ذخیره‌سازی انرژی شدند [۲۰]. این تحقیقات نشان می‌دهد مهندسی مواد یک مسیر کلیدی برای رفع محدودیت‌های PCM در کاربردهای صنعتی و هم‌افزایی با مدل‌های یادگیری ماشین است. در گروهی دیگر از مطالعات، تمرکز بر مدل‌سازی عددی قرار گرفته است. پژوهشی در سال ۲۰۲۵ که ترکیب CFD و FEM را به کار گرفته، نشان داده این رویکرد برای هندسه‌های پیچیده PCM‌های چاپ سه‌بعدی محدودیت‌های مدل‌های کلاسیک CFD را کاهش می‌دهد [۲۱]. Huang و همکاران نیز با شبیه‌سازی CFD چندفازی و الگوریتم‌های بهینه‌سازی، اثر ساختارهای ترکیبی PCM را مورد بررسی قرار داده‌اند [۲۲]. Lee و همکاران با ترکیب شبیه‌سازی دیجیتال و روش‌های تجربی نشان دادند که جریان مجدد PCM با سرعت 0.22 m/s می‌تواند زمان ذوب کامل را تا 48% کاهش

⁹ Random Forest (RF)¹⁰ Support Vector Regression (SVR)¹¹ Gradient Boosted Models (GBM)¹² XGBoost¹³ LightGBM¹⁴ Evolutionary Optimization¹⁵ Genetic Algorithm (GA)¹⁶ Particle Swarm Optimization (PSO)¹ Thermal Energy Storage (TES)² Latent Heat Thermal Energy Storage (LHTES)³ Phase Change Materials (PCMs)⁴ Computational Fluid Dynamic (CFD)⁵ Supervised Machine Learning (SML)⁶ Artificial Neural Networks (ANNs)⁷ Deep Neural Networks (DNNs)⁸ Decision Tree

عملکرد NePCM به دست آورده‌اند [۳۲]. Izgi نیز از MLP و NSGA-II برای بهینه‌سازی زمان ذوب بهره برده است [۳۳]. Tian و همکاران پتانسیل یادگیری ماشین را در تحلیل ساختار و خواص ترموفیزیکی نمک‌های یونکتیک ناهمگن به کار گرفته‌اند [۳۴]. همچنین Ran و Anagnostopoulos با الگوریتم‌های ترکیبی ANN+GA و DL+Harmony Search مسیرهای جدیدی برای طراحی TES ارائه کردند [۳۵، ۳۶]. Balakrishnan و Kumaresan نیز نشان دادند که مدل‌های CatBoost و DL می‌توانند جایگزین سریع CFD باشند [۳۷]. این شواهد تأکید می‌کند که ML چه به‌طور مستقل و چه در ترکیب با روش‌های دیگر، آینده طراحی TES مبتنی بر PCM را شکل خواهد داد.

همان‌طور که پیش‌تر اشاره شد، مدل‌های یادگیری ماشین نظارت‌شده به دو دسته اصلی رگرسیون^۱ و طبقه‌بندی^۲ تقسیم می‌شوند. در رگرسیون، مدل به پیش‌بینی متغیرهای پیوسته مانند دما، زمان یا میزان ذخیره انرژی می‌پردازد و پرکاربردترین روش‌ها برای مسائل حوزه PCM-LHTES همین گروه هستند، زیرا اغلب خروجی مورد نظر عددی و پیوسته است. در مقابل، مدل‌های طبقه‌بندی برای دسته‌بندی نمونه‌ها به گروه یا کلاس‌های گسسته به کار می‌روند؛ اما در کاربردهای این حوزه، موارد استفاده آن‌ها اندک است. در میان مدل‌های رگرسیونی، روش‌هایی چون رگرسیون خطی، رگرسیون چندجمله‌ای، رگرسیون کمترین مربعات جزئی و رگرسیون درخت تصمیم، بسته به ویژگی‌های داده و مسئله به کار می‌روند. همچنین، مدل‌های پیشرفته‌تر مانند شبکه‌های عصبی مصنوعی و شبکه‌های عصبی عمیق به دلیل توانایی بالا در مدل‌سازی روابط غیرخطی و پیچیده، انتخاب اصلی پژوهشگران بوده‌اند و قابلیت تطبیق مدل با روابط پیچیده میان متغیرها را دارند. مدل‌های تصمیم‌گیری همچون درخت تصمیم، جنگل تصادفی و الگوریتم‌های مبتنی بر تقویت مانند XGBoost و LightGBM نیز نقش مهمی در این زمینه دارند؛ به ویژه، RF و XGB برای داده‌های محدود یا نیاز به تحلیل اهمیت ویژگی‌ها کاربرد قابل توجهی یافته‌اند، چون می‌توانند ویژگی‌های اساسی اثرگذار بر خروجی را شناسایی کنند و تفسیرپذیری نسبی مدل را افزایش دهند.

مدل بردار پشتیبان رگرسیون معمولاً برای مسائل با داده کم و مدل‌سازی دقیق در فضاهای با ابعاد بالا مناسب است و به واسطه استفاده از کرنل‌ها، امکان یادگیری روابط غیرخطی پیچیده را در داده‌های محدود فراهم می‌کند. روش‌های مبتنی بر گرادایان مانند XGBoost و LightGBM به دلیل دقت بالا،

و توان میانگین تخلیه را تا ۱۳۲/۶٪ افزایش دهد [۲۳]. این یافته‌ها اهمیت استراتژی‌های کنترل دقیق در طراحی PCM و محدودیت‌های CFD را روشن می‌سازد. در نتیجه، اگرچه CFD ابزاری توانمند است؛ اما به‌تنهایی پاسخگوی نیازهای بهینه‌سازی سریع نیست. بنابراین، محققان به استفاده همزمان از CFD و یادگیری ماشین گرایش یافته‌اند. برای مثال، Yan و همکاران با بهره‌گیری از ANN، CFD و الگوریتم ژنتیک، هندسه بهینه سیستم‌های خورشیدی مجهز به PCM را شناسایی کردند [۲۴]. Vaferi و تیمش عملکرد تانک فین‌دار با PCM را با ترکیب شبیه‌سازی CFD، شبکه عصبی و الگوریتم بهینه‌سازی Pareto مورد ارزیابی قرار دادند و دریافتند که طراحی بهینه فین‌ها به تعادل مناسبی بین زمان شارژ/دشارژ و عملکرد حرارتی دست می‌یابد [۱۳]. این مجموعه مطالعات اهمیت هم‌افزایی CFD و ML را در ارتقای دقت و سرعت مدل‌سازی تأیید می‌کند. بعد از محور مواد و مدل‌سازی، بخشی از تحقیقات به طراحی هندسی نوآورانه TES اختصاص یافته است. Abdellatif و همکاران با بررسی هندسه‌های غیردایره‌ای و فین‌های بهینه، بهبود قابل توجهی در نرخ انتقال حرارت گزارش کردند [۲۵]. Agrebi و همکاران با طراحی مدل‌های مارپیچی نشان دادند که ایجاد جریان‌های گردابی کارایی سیستم را افزایش می‌دهد [۲۶]. Almadhor و همکاران نیز جایگزینی ساختارهای داخلی به جای فین‌های سنتی را پیشنهاد داده و عملکرد ذوب را با کمک مدل ANN پیش‌بینی و بهینه کردند [۲۷]. این مطالعات بیانگر آن است که طراحی خلاقانه در کنار الگوریتم‌های ML می‌تواند عملکرد TES را متحول کند. مسیر دیگر پژوهش‌ها بر ادغام PCM با سیستم‌های انرژی متمرکز است Soliman و همکاران نشان دادند که پنجره‌های PV حاوی PCM می‌توانند دمای داخلی ساختمان را تا ۴۶ درصد کاهش دهند [۲۸]. Elenga و همکاران اثر مثبت PCM بر کاهش بار سرمایشی در نماهای ساختمانی مناطق گرمسیری را گزارش کردند [۲۹]. Issa و Thirunavukkarasu نیز نشان دادند که استفاده از PCM کپسوله‌شده در CSP باعث افزایش ظرفیت ذخیره‌سازی می‌شود [۳۰]. بنابراین، ادغام TES مبتنی بر PCM با سیستم‌های انرژی نوین نقش مهمی در ارتقای پایداری دارد. در نهایت، بخش مهمی از پژوهش‌ها به توسعه مستقیم مدل‌های ML اختصاص یافته است. Sharma و همکاران مرور گسترده‌ای از الگوریتم‌هایی نظیر ANN، SVR و Gradient Boosting ارائه داده‌اند که در پیش‌بینی رفتار PCM موفق عمل کرده‌اند [۳۱]. Basem و تیمش با ترکیب MLPNN با الگوریتم‌های تکاملی PSO و GA دقت بالایی در پیش‌بینی

^۱ Regression^۲ Classification

آموزش محدود باشد و معماری مدل پیچیده انتخاب شود. برای غلبه بر این مشکلات، استفاده از روش‌های یادگیری ماشین آگاه از فیزیک^{۱۰} که قوانین فیزیکی را در فرآیند آموزش دخالت می‌دهند، یادگیری انتقالی^{۱۱} برای استفاده مجدد از مدل‌های آموزش‌دیده و مدل‌های هیبریدی که ترکیب CFD و ML را به کار می‌گیرند، پیشنهاد می‌شود. در آینده، توسعه مدل‌های سریع و سبک برای کنترل بلادرنگ^{۱۲} سیستم‌های TES و بهینه‌سازی هوشمند عملکرد آن‌ها اهمیت فزاینده‌ای خواهد داشت.

با وجود این پیشرفت‌ها، پژوهش‌های مرتبط با کاربرد یادگیری ماشین در PCM عمدتاً پراکنده و متمرکز بر جنبه‌های خاص مانند بهینه‌سازی هندسی یا ادغام با سیستم‌های فتوولتائیک می‌باشد و تاکنون مرور نظام‌مندی که این مطالعات را بطور جامع دسته‌بندی کند ارائه نشده است. پژوهش حاضر با هدف پر کردن این خلأ، ۱۷ مقاله منتشر شده در سال‌های اخیر را بررسی و تحلیل می‌کند. این مقالات در دو دسته اصلی طبقه‌بندی شده‌اند:

۱. بهینه‌سازی هندسه PCM (پره، محفظه، فوم فلزی)
 - هدف غالب: بهبود بازده حرارتی، کاهش زمان ذوب/انجماد
 - مدل‌های رایج: SVR, XGB, RF, DNN, ANN
۲. تحلیل و پیش‌بینی رفتار حرارتی PCM با تمرکز بر خواص ماده و شرایط کاری شامل: پیش‌بینی ضریب انتقال حرارت، دمای مرزی، نرخ ذوب بر اساس خواص PCM و شرایط جریان سیال این مرور ضمن تحلیل روش‌ها، ورودی‌ها و خروجی‌های مدل‌ها، ارزیابی دقت پیش‌بینی، قابلیت تعمیم و نقش یادگیری ماشین در بهینه‌سازی و طراحی هوشمند سیستم‌های ذخیره‌سازی حرارت نهان را انجام داده و مسیرهای توسعه آینده برای مدل‌های سریع، دقیق و مقاوم در کاربردهای صنعتی را ترسیم می‌کند.

۲- روش‌شناسی

این پژوهش بر مبنای یک مرور نظام‌مند طراحی شده است تا نقش و کارایی مدل‌های یادگیری ماشین نظارت‌شده در طراحی و بهینه‌سازی سامانه‌های ذخیره‌سازی حرارت نهان مبتنی بر مواد تغییر فاز دهنده را بررسی و دسته‌بندی کند. هدف اصلی،

کنترل بیش‌برازش و امکان محاسبه اهمیت ویژگی‌های مدل مورد توجه قرار گرفته‌اند و اخیراً کاربرد گسترده‌ای در شبیه‌سازی و بهینه‌سازی عملکرد ذخیره‌سازهای حرارتی نهان یافته‌اند.

در مدل‌های طبقه‌بندی نیز الگوریتم‌هایی مانند رگرسیون لجستیک، نزدیک‌ترین همسایه و دسته‌بندی مبتنی بر درخت رایج هستند که البته در حوزه PCM-LHTES کمتر به کار رفته‌اند، زیرا عمده مسائل این حوزه ماهیت کمی (عدد پیوسته) دارند. هر کدام از این الگوریتم‌ها برای سناریوهای متفاوت و بسته به نوع داده و هدف مسئله انتخاب می‌شوند. انتخاب مدل متناسب، بر اساس ویژگی‌های داده و پیچیدگی رابطه میان متغیرها، موجب افزایش دقت پیش‌بینی و تفسیرپذیری نتایج خواهد شد.

آموزش مدل‌های یادگیری ماشین نظارت‌شده شامل چند مرحله کلیدی است:

۱. پیش‌پردازش داده‌ها: پاک‌سازی داده، نرمال‌سازی یا استانداردسازی و انتخاب ویژگی‌های مؤثر.
۲. انتخاب مدل و ساختار: تعیین نوع الگوریتم، معماری شبکه (در ANN)، یا عمق و تعداد درخت‌ها (در RF/XGB)
۳. تنظیم ابرپارامترها^۱ استفاده از روش‌هایی مانند جست‌وجوی شبکه‌ای^۲، جست‌وجوی تصادفی^۳ یا بهینه‌سازی تکاملی^۴ نظیر الگوریتم ژنتیک^۵ و بهینه‌سازی ازدحام ذرات^۶ برای یافتن بهترین تنظیمات.
۴. آموزش مدل: تغذیه داده‌ها به مدل و به‌روزرسانی پارامترها (وزن‌ها و بایاس‌ها در ANN) بر اساس کاهش تابع خطا^۷.
۵. اعتبارسنجی: ارزیابی عملکرد مدل با استفاده از داده‌های آزمون یا اعتبارسنجی متقابل^۸ با معیارهایی مانند R^2 , RMSE, MAE و MAPE. در مطالعات PCM، ترکیب مدل‌های ANN با الگوریتم‌های بهینه‌سازی مانند ANN-GA یا ANN-PSO متداول است، زیرا علاوه بر پیش‌بینی، امکان جست‌وجوی فضای طراحی و یافتن پیکربندی‌های بهینه را فراهم می‌کند. اگرچه مدل‌های نظارت‌شده در حوزه PCM نتایج چشمگیری به‌دست آورده‌اند، اما چالش‌هایی نیز وجود دارد. یکی از مهم‌ترین چالش‌ها کمبود داده‌های واقعی آزمایشگاهی است، زیرا بیشتر داده‌های آموزشی از شبیه‌سازی CFD تولید شده‌اند و این ممکن است دقت مدل را در شرایط عملی کاهش دهد. همچنین، برخی مدل‌ها دچار بیش‌پردازش^۹ می‌شوند، به‌ویژه زمانی که داده‌های

⁷ Loss function

⁸ Cross-validation

⁹ Overfitting

¹⁰ Physics-informed machine learning

¹¹ Transfer learning

¹² Real-time control

¹ Hyperparameters

² Grid search

³ Random search

⁴ Evolutionary optimization

⁵ Genetic Algorithm (GA)

⁶ Particle Swarm Optimization (PSO)

استخراج شامل نوع مدل یادگیری ماشین به کار رفته، هدف مدل، ویژگی‌های ورودی، منبع و حجم داده‌ها، روش اعتبارسنجی، معیارهای عملکرد در داده آزمون، روش‌های بهینه‌سازی ترکیبی، نتایج کمی کلیدی و محدودیت‌های پژوهش بود. ۴۴۴۹۰۶

۲-۵- طبقه‌بندی موضوعی

پس از کدگذاری، مقالات در دو دسته اصلی تقسیم شدند:

- دسته اول: بهینه‌سازی هندسه PCM که شامل ۱۲ مقاله با تمرکز بر تغییرات هندسی شامل پره‌ها، محفظه‌ها و فوم فلزی بود.
- دسته دوم: یکپارچه‌سازی PCM با سیستم‌های انرژی که شامل ۵ مقاله به بررسی ترکیب TES با سیستم‌های فتوولتائیک (PV)، فتوولتائیک حرارتی (PVT) یا سیستم‌های متمرکز خورشیدی (CSP) می‌پرداختند.

۳- نتایج و بحث

۳-۱- تمرکز بر طراحی و بهینه‌سازی هندسه سامانه‌های ذخیره‌سازی حرارت نهان مبتنی بر مواد تغییر فاز دهنده

دسته اول شامل ۱۲ مقاله است که عمدتاً بر طراحی و بهینه‌سازی هندسه سامانه‌های ذخیره‌سازی حرارت نهان مبتنی بر مواد تغییر فاز دهنده تمرکز دارند. موضوعات اصلی شامل تغییر شکل محفظه، طراحی و آرایش پره‌ها و کاربرد فوم فلزی به منظور بهبود هدایت حرارتی و یکنواخت‌سازی جبهه ذوب می‌باشد. در برخی مطالعات به طور خاص، سناریوهای فوم فلزی بررسی شده و اثر ناهمگنی تخلخل و چیدمان فوم در تسریع ذوب و افزایش انتقال حرارت تحلیل شده است.

در این حوزه، مدل‌های یادگیری ماشین نظارت‌شده غالباً شامل شبکه‌های عصبی مصنوعی و شبکه‌های عصبی عمیق بوده‌اند که به دلیل توانایی بالا در مدل‌سازی روابط غیرخطی پیچیده میان متغیرهای هندسی و حرارتی، بیشترین کاربرد را داشته‌اند. علاوه بر آن، استفاده از مدل‌های جنگل تصادفی، XGBoost و رگرسیون بردار پشتیبان نیز گزارش شده است. الگوریتم‌های مبتنی بر درخت، به‌ویژه زمانی که ویژگی‌های ورودی به خوبی مهندسی شده باشند، دقتی برابر یا حتی بیش از شبکه‌های عصبی ارائه داده‌اند؛ اما در مسائلی که داده‌های بیشتری موجود باشد و روابط پیچیده‌تر باشند، ANN و DNN بهترین عملکرد را کسب کرده‌اند. لازم به ذکر است داده‌های

گردآوری و تحلیل مطالعات پراکنده‌ای است که از ML برای پیش‌بینی یا بهینه‌سازی عملکرد این سیستم‌ها بهره برده‌اند.

۲-۱- تعیین دامنه و چارچوب مطالعه

در گام نخست، دامنه مطالعه به‌طور واضح تعیین شد. هدف اصلی مرور، شناسایی و دسته‌بندی پژوهش‌هایی بود که در آن‌ها از مدل‌های یادگیری ماشین نظارت‌شده مانند شبکه‌های عصبی مصنوعی (ANN)، شبکه‌های عصبی عمیق (DNN)، جنگل تصادفی (RF)، رگرسیون بردار پشتیبان (SVR)، تقویت گرادیانی (XGBoost) و رگرسیون فرایند گاوسی (GPR) برای پیش‌بینی یا بهینه‌سازی عملکرد سیستم‌های PCM-TES استفاده شده است. برای تمرکز بیشتر، تنها مقالاتی انتخاب شدند که داده‌های آن‌ها از شبیه‌سازی‌های CFD، آزمایش‌های حرارتی یا ترکیبی از هر دو استخراج شده باشد و خروجی مدل‌ها به شاخص‌های کلیدی عملکرد سیستم‌های ذخیره‌سازی حرارت نهان مانند زمان ذوب/انجماد، بازده حرارتی، نرخ انتقال حرارت، دمای مرزی یا بازده الکتریکی سیستم‌های ترکیبی مرتبط باشد.

۲-۲- جست‌وجوی مقالات

جست‌وجوی مقالات مرتبط در پایگاه داده Scopus انجام شد. کلیدواژه‌های استفاده شده شامل ترکیبی از عبارات latent heat thermal energy storage, supervised learning, CFD, PCM, machine learning بودند. بازه زمانی انتشار مقالات از سال ۲۰۲۳ تا ۲۰۲۵ تعیین گردید تا تمرکز بر تازه‌ترین مقالات و تحولات اخیر یادگیری ماشین و ذخیره‌سازی حرارت باشد. علاوه بر این، فیلترهای دسته‌بندی مهندسی و انرژی و همچنین فیلتر مقالات پژوهشی اعمال شد تا مجموعه‌ای از مقالات مرتبط و با کیفیت گردآوری گردد.

۲-۳- غربالگری و انتخاب مقالات

در اولین گام غربالگری، تعداد ۷۸ مقاله شناسایی شد. پس از حذف موارد تکراری و بررسی چکیده‌ها بر اساس معیارهای ورود، تعداد ۴۳ مقاله جهت مطالعه کامل انتخاب شدند. نهایتاً ۱۷ مقاله که کاملاً معیارهای تعیین شده را برآورده می‌ساختند، به‌عنوان مبنای مطالعه انتخاب و تحلیل گردیدند.

۲-۴- کدگذاری و استخراج داده‌ها

برای هر مقاله انتخاب شده، داده‌ها به شیوه‌ای نظام‌مند استخراج و در جداول مربوط به بخش نتایج ثبت شدند. متغیرهای کلیدی

تقسیم گردید. پارامترهای کلیدی ورودی مدل شامل متغیرهای هندسی ارتفاع (Z)، قطر (D) و زاویه (θ) بودند. اعتبارسنجی مدل با روش Hold-out انجام شد و نتایج حاصل نشان دادند که شبکه عصبی مصنوعی قادر است زمان ذوب را با دقت بسیار بالا (ضریب تعیین R^2 در محدوده ۰/۹۹۶ تا ۰/۹۹۸) و خطای RMSE بین ۳/۵ تا ۲۳/۶ ثانیه پیش‌بینی کند. علاوه بر این، برای بهینه‌سازی هندسه از الگوریتم ژنتیک استفاده شد که منجر به کاهش ۷۳/۵ درصدی زمان ذوب کامل شد.

در مطالعه Vaferi و همکاران [۱۳] از یک شبکه عصبی مصنوعی برای مدل‌سازی فرآیند شارژ و دشارژ در سیستم‌های ذخیره‌سازی انرژی حرارتی استفاده شد. داده‌های ورودی شامل پارامترهایی از قبیل ارتفاع (H)، قطر (D)، زاویه پره‌ها (θ) و تعداد پره‌ها (N_f) بودند. این داده‌ها از طریق شبیه‌سازی دینامیک سیالات محاسباتی (CFD) به دست آمده و شامل ۸۱ نمونه می‌شد که به نسبت ۷۰/۱۵/۱۵ به مجموعه‌های آموزش، اعتبارسنجی و آزمون تقسیم شدند. اعتبارسنجی مدل بر اساس روش Hold-out انجام شد و دقت بسیار بالایی معادل $R^2=0.999$ با خطای RMSE برابر با ۶/۷۸ ثانیه به دست آمد. همچنین، بهینه‌سازی چندهدفه با به‌کارگیری الگوریتم ژنتیک چندهدفه (MOGA) شکل گرفت که امکان یافتن تعادل میان کاهش زمان شارژ و دشارژ و سایر پارامترهای عملکردی را فراهم ساخت. از نقاط قوت این مطالعه می‌توان به استفاده مؤثر از رویکرد چندهدفه همراه با یادگیری ماشین اشاره کرد. با وجود این، محدودیت مهم مطالعه، تکیه کامل بر داده‌های شبیه‌سازی CFD و عدم ارائه گزارش دقیق از درصد بهبود عملکرد در شرایط واقعی می‌باشد.

در مطالعه Shen و همکاران [۱۴] مقایسه‌ای میان چندین الگوریتم یادگیری ماشین از جمله XGBoost، جنگل تصادفی (RF)، رگرسیون بردار پشتیبان (SVR) و شبکه عصبی مصنوعی (ANN) انجام شد. هدف اصلی این مطالعه پیش‌بینی زمان ذوب در محفظه‌های مستطیلی بود. داده‌های ورودی شامل عدد رینولدز، نسبت ابعاد محفظه، دمای ورودی و دبی جریان بودند. این داده‌ها از طریق شبیه‌سازی دینامیک سیالات محاسباتی (CFD) به دست آمده و شامل ۱۲۰۰ نمونه بود. اعتبارسنجی مدل‌ها با روش اعتبارسنجی متقاطع ده بخشی (۱۰-fold cross-validation) صورت گرفت که ضامن تعمیم‌پذیری می‌باشد. نتایج نشان داد XGBoost بهترین عملکرد را با ضریب تعیین R^2 تقریباً ۰/۹۹۸ و خطای RMSE حدود ۶/۱ ثانیه ارائه داده است. این مطالعه از محدود پژوهش‌هایی است که در آن علاوه بر شبکه عصبی مصنوعی یک مقایسه جامع بین چند الگوریتم صورت گرفته و نشان داده شده است که در برخی

آموزشی این مدل‌ها عمدتاً از شبیه‌سازی‌های CFD حاصل شده و در موارد اندکی با داده‌های آزمایشگاهی تکمیل شده‌اند. فرآیند مرور این مقالات شامل دسته‌بندی بر اساس موضوع و هدف مدل‌سازی و استخراج متغیرهای کلیدی مانند ویژگی‌های ورودی (زاویه و ضخامت پره‌ها، ابعاد محفظه، تخلخل و تعداد منافذ فوم فلزی، دبی جریان و دمای ورودی)، متغیرهای هدف، ساختار مدل‌ها، روش‌های پیش‌پردازش داده، حجم و تقسیم‌بندی داده‌ها، شیوه‌های اعتبارسنجی مانند Hold-out یا k-fold و معیارهای سنجش عملکرد بوده است. همچنین تحلیل حساسیت و رتبه‌بندی اهمیت ویژگی‌ها به منظور شناسایی پارامترهای تعیین‌کننده در عملکرد سیستم انجام شده است. نتایج حاکی از آن است که پارامترهای هندسی، به ویژه زاویه و ضخامت پره‌ها، موقعیت نسبی لایه‌های فوم فلزی و شکل کلی محفظه تأثیر قابل توجهی بر نرخ انتقال حرارت و زمان ذوب-انجماد دارند. برای مثال، آرایش ناهمگن فوم فلزی، که در آن تخلخل در پایین کمتر و در بالا بیشتر است موجب تقویت جابجایی طبیعی و کاهش چشمگیر زمان ذوب (تا حدود ۷۰٪ در برخی مطالعات) شده است. همچنین در طراحی پره‌ها، ترکیب یادگیری ماشین با الگوریتم‌های بهینه‌سازی تکاملی مانند الگوریتم ژنتیک، NSGA-II و روش‌های چندهدفه Pareto منجر به یافتن طرح‌های بهینه شده‌ای شده است که کاهش زمان ذوب و افزایش بازده حرارتی بین ۱۰ تا ۳۰ درصد را به همراه داشته‌اند.

با وجود دستاوردهای مذکور، محدودیت اساسی در مطالعات دسته اول، تکیه صرف بر داده‌های شبیه‌سازی CFD و فقدان داده‌های آزمایشگاهی قابل اتکا در مقیاس صنعتی است. این امر ممکن است قابلیت تعمیم مدل‌ها را به شرایط عملی واقعی کاهش دهد. با این حال، روند پژوهش‌ها نشان می‌دهد که گرایش به سمت استفاده از مدل‌های پیچیده‌تر DNN و ترکیب آن‌ها با بهینه‌سازها در حال افزایش است و این مسیر چشم‌اندازی روشن برای کاربرد صنعتی این مدل‌ها در طراحی سیستم‌های TES فراهم آورده است.

خلاصه نتایج مقالات دسته اول در جدول (۱) ارائه شده است. علاوه بر آن، در ادامه به اختصار نتایج کلیدی برخی از این مطالعات مطرح می‌گردد.

Ran و همکاران در منبع [۳۵] یک شبکه عصبی مصنوعی برای مدل‌سازی و پیش‌بینی زمان ذوب در هندسه‌های الهام‌گرفته از زیست‌ساختار مورد استفاده قرار داده‌اند. داده‌های ورودی این مدل از شبیه‌سازی دینامیک سیالات محاسباتی (CFD) استخراج شده و شامل ۲۷ نمونه بوده است که مطابق نسبت ۷۰/۱۵/۱۵ به بخش‌های آموزش، اعتبارسنجی و آزمون

اعتبارسنجی و آزمون تقسیم شده است. اعتبارسنجی مدل به روش Hold-out انجام گردیده و دقت پیش‌بینی مدل با ضریب تعیین (R^2) حدود ۰/۹۹۴ و خطای RMSE برابر با ۰/۰۰۵۶ گزارش شده است که نشان‌دهنده توان بالای ANN در مدل‌سازی رفتار ذوب در این نوع هندسه است.

مطالعه Yan و همکاران [۴۱] بر تأثیر پره‌های دوار بر بازده حرارتی تمرکز داشته است. در این مطالعه، مدل ANN برای پیش‌بینی بازده رهایش حرارت استفاده شده است. داده‌های ورودی شامل سرعت چرخش پره‌ها، زاویه و ضخامت پره‌ها، دمای اولیه و نهایی می‌باشد. داده‌ها از شبیه‌سازی CFD استخراج شده و شامل ۵۱۲ نمونه بود که با نسبت تقسیم ۷۰/۱۵/۱۵ برای آموزش داده شد. اعتبارسنجی مدل بر اساس روش Hold-out انجام شده و دقت‌های بالایی مانند $R^2 \approx 0.995$ ، $RMSE \approx 0.0038$ و $MAE \approx 0.0029$ گزارش شده است. در این مطالعه، روش جست‌وجوی شبکه‌ای (Grid Search) برای تنظیم ابرپارامترها به کار گرفته شده است که موجب افزایش عملکرد مدل شده است. اگرچه محدودیت اصلی پژوهش تکیه کامل به داده‌های شبیه‌سازی است و محدودیت‌های مکانیکی و هزینه‌ای پره‌های دوار در شرایط واقعی بررسی نشده است، نتایج نشان می‌دهند که پره‌های متحرک می‌توانند در کنار تکنیک‌های یادگیری ماشین، راهکاری مؤثر برای بهبود عملکرد حرارتی سیستم‌های TES باشند.

Sultan و همکاران در مطالعه [۴۲] به بررسی تأثیر فوم فلزی ناهمگن در مخازن PCM پرداخته و عملکرد آن را با استفاده از مدل ANN تحلیل کرده‌اند. متغیرهای ورودی شامل نوع آرایش لایه‌ها، تخلخل در بالا و پایین و نسبت لایه‌ها بوده‌اند. داده‌های مورد استفاده از شبیه‌سازی CFD استخراج شده و شامل ۱۲۰ نمونه بود. داده‌ها بر اساس سهم تقسیم ۷۰/۱۵/۱۵ برای آموزش، اعتبارسنجی و آزمون تقسیم شده بودند و ارزیابی با روش Hold-out انجام شده است. عملکرد مدل بسیار قوی گزارش شده و دقت آن با $R^2 > 0.98$ و RMSE کمتر از ۲ درصد به صورت نسبی بوده است. برای بهبود پایداری مدل، تنظیم ابرپارامترها با روش Grid Search صورت گرفت.

در مطالعه [۴۳] انجام شده توسط Zheng و همکاران، تأثیر طراحی پره‌ها و قطر مخزن بر زمان شارژ کامل PCM بررسی شده است. در این پژوهش از مدل شبکه عصبی مصنوعی (ANN) برای پیش‌بینی زمان شارژ استفاده گردید. داده‌های ورودی شامل دمای ورودی، دبی جرمی، تعداد و ضخامت پره‌ها و قطر مخزن بودند. این داده‌ها از شبیه‌سازی دینامیک سیالات محاسباتی (CFD) استخراج شده و شامل ۳۵۰ نمونه بود که با نسبت ۷۰/۱۵/۱۵ به مجموعه‌های آموزش، اعتبارسنجی و آزمون

شرایط روش‌های مبتنی بر گرادیان مانند XGBoost حتی برتری نسبت به ANN دارند. از نقاط قوت این کار می‌توان به استفاده از اعتبارسنجی ده بخشی و مقایسه چندمدلی اشاره کرد. مطالعه Nokhosteen و همکاران [۳۸] نیز به بررسی چندین مدل یادگیری ماشین از جمله ANN، RF، XGBoost و SVR برای پیش‌بینی زمان ذوب پرداخت. داده‌های ورودی شامل خواص ترموفیزیکی مواد نظیر ضریب هدایت حرارتی، ظرفیت گرمایی ویژه، چگالی و شرایط مرزی مانند دمای دیواره و ویژگی‌های هندسی بودند. این داده‌ها شامل ۱۰۰۰ نمونه از شبیه‌سازی CFD بود که به نسبت ۷۰/۱۵/۱۵ برای آموزش، اعتبارسنجی و آزمون تقسیم شدند. علاوه بر این، روش اعتبارسنجی متقاطع پنج بخشی (۵-fold cross-validation) برای بهبود قابلیت تعمیم‌پذیری نتایج به کار رفت. در میان این الگوریتم‌ها، شبکه عصبی مصنوعی با ضریب تعیین R^2 معادل ۰/۹۹۷ و خطای RMSE حدود ۷/۲ ثانیه بهترین عملکرد را ارائه نمود.

مطالعه Vaferi و همکاران [۳۹] بر طراحی و بهینه‌سازی هندسی سیستم‌های ذخیره‌سازی حرارتی متمرکز بود و از شبکه عصبی مصنوعی به عنوان مدل اصلی بهره برد. داده‌های ورودی شامل پارامترهایی چون قطر و ضخامت فین‌ها، تعداد فین‌ها، نرخ جرمی جریان و دمای ورودی بودند. مجموعه داده شامل ۷۶۸ نمونه CFD بود که به نسبت ۷۰/۱۵/۱۵ به بخش‌های آموزش، اعتبارسنجی و آزمون تقسیم شد. روش اعتبارسنجی Hold-out به کار گرفته شد. دقت مدل بسیار بالا و با ضریب تعیین R^2 معادل ۰/۹۹۷ و خطای RMSE حدود ۰/۰۰۴۸ گزارش گردید. علاوه بر این، میزان خطای نسبی (MAPE) کمتر از ۱ درصد بود که نشان‌دهنده قابلیت پیش‌بینی بالای شبکه عصبی در این زمینه است. نتایج نشان داد طراحی بهینه فین‌ها با استفاده از الگوریتم بهینه‌سازی چندهدفه NSGA-II توانسته است توان خروجی سیستم را تا ۱۷ درصد افزایش و زمان شارژ را حدود ۱۴ درصد کاهش دهد. این مطالعه به خوبی نشان داد که ترکیب شبکه عصبی مصنوعی با الگوریتم‌های چندهدفه تکاملی می‌تواند تعادل مناسبی بین سرعت شارژ، توان حرارتی و راندمان کلی ایجاد کند. Abdellatif و همکاران در مطالعه [۴۰] به بررسی عملکرد حرارتی در هندسه محفظه‌های مایل سیستم‌های PCM با استفاده از مدل شبکه عصبی مصنوعی (ANN) پرداخته‌اند. ورودی‌های مدل شامل زاویه محفظه، دمای سطح دیواره و مشخصات هندسی بودند. داده‌های مورد استفاده از شبیه‌سازی دینامیک سیالات محاسباتی (CFD) استخراج شده که شامل ۴۵۰ نمونه بود و مطابق نسبت ۷۰/۱۵/۱۵ برای آموزش،

سیستم انرژی بهبود یابد. مدل‌های یادگیری ماشین نظارت‌شده مورد استفاده در این دسته شامل ANN، GBDT/XGBoost، RF، GPR، اغلب همراه با بهینه‌سازی‌های تکاملی مانند PSO، GA یا NSGA-II بودند. این مدل‌ها برای پیش‌بینی شاخص‌هایی نظیر زمان ذوب و دشارژ PCM، بازده الکتریکی و حرارتی، کاهش دمای مازول PV، و افت فشار در بسترهای پر شده توسعه یافتند.

فرآیند مرور مقالات این دسته به این صورت انجام شد که ابتدا نوع ترکیب فناوری PCM با سیستم‌های انرژی شناسایی و سپس داده‌های ورودی شدت تابش خورشیدی، سرعت باد، خصوصیات PCM، هندسه واحد ذخیره‌سازی و ویژگی‌های پنل و متغیرهای هدف (مانند بازده، دما و توان خروجی) استخراج گردید. علاوه بر آن، منبع داده‌ها شبیه‌سازی CFD، داده‌های آزمایشگاهی یا هبیری، روش‌های پیش‌پردازش، تقسیم‌بندی داده‌ها و شاخص‌های اعتبارسنجی ثبت شد. نتایج دسته ب نشان داد که مدل‌های یادگیری ماشین می‌توانند با دقتی بالاتر از ۰/۹۹ شرایط محیطی و طراحی را پیش‌بینی کرده و از طریق الگوریتم‌های بهینه‌سازی چندهدفه، طرح‌هایی ارائه دهند که همزمان باعث کاهش دمای مازول PV، بهبود بازده انرژی و افزایش طول عمر سیستم شوند.

نتایج کمی و ویژگی‌های کلیدی مقالات این دسته در جدول (۲) ارائه شده است. به‌منظور درک بهتر، در ادامه خلاصه‌ای تفصیلی از هر مقاله ذکر گردیده است.

در مطالعه Anagnostopoulos و همکاران [۳۶]، شبکه عصبی مصنوعی توسعه داده شد تا زمان ذوب PCM و همزمان افت فشار در سیستم ذخیره‌سازی حرارتی بستر پر شده پیش‌بینی شود. ورودی‌های اصلی شامل قطر ذرات فلزی، کسر حجمی فلز و دمای ورودی سیال بودند. داده‌ها به طور کامل از شبیه‌سازی دویعدی دینامیک سیالات محاسباتی (CFD) به دست آمده و شامل ۶۴ سناریو برای آموزش، اعتبارسنجی و آزمون مدل بود. در مطالعه Anagnostopoulos و همکاران [۳۶]، شبکه عصبی مصنوعی توسعه داده شد تا زمان ذوب PCM و همزمان افت فشار در سیستم ذخیره‌سازی حرارتی بستر پر شده پیش‌بینی شود. ورودی‌های اصلی شامل قطر ذرات فلزی، کسر حجمی فلز و دمای ورودی سیال بودند. داده‌ها به طور کامل از شبیه‌سازی دویعدی دینامیک سیالات محاسباتی (CFD) به دست آمده و شامل ۶۴ سناریو برای آموزش، اعتبارسنجی و آزمون مدل بود. مدل شامل یک لایه مخفی با ۱۵ نورون و الگوریتم آموزش Levenberg-Marquardt (LM) بود که پس از نرمال‌سازی داده‌ها و تنظیم مناسب الگوریتم، به دقت بسیار بالایی معادل ضریب تعیین ۰/۹۹۸ دست یافت.

تقسیم شدند. مدل از طریق روش اعتبارسنجی Hold-out سنجش شد و نتایج عملکرد بسیار خوبی را با ضریب تعیین $R^2 \approx 0.994$ ، خطای $RMSE \approx 0.015$ ثانیه و خطای $MAE \approx 0.010$ ثانیه نشان داد. به منظور بهینه‌سازی، روش چندهدفه (MOO) Pareto به کار گرفته شد که توازن بین کاهش زمان شارژ و افزایش راندمان سیستم را بهبود بخشید. نتایج حاکی از کاهش ۱۸ درصدی زمان شارژ و افزایش ۷ درصدی راندمان کلی سیستم پس از بهینه‌سازی هستند.

در مطالعه Almadhor و همکاران [۲۷]، اثر طراحی لوله‌ها و پایه‌ها در یک مخزن TES مجهز به PCM مورد بررسی قرار گرفت. هدف اصلی بهبود بازده ذوب و کاهش زمان فرآیند ذخیره‌سازی بود. ورودی‌های مدل شامل قطر، تعداد و فاصله لوله‌ها، ارتفاع پایه و دمای ورودی بودند. این داده‌ها از شبیه‌سازی CFD حاصل شده و شامل ۴۲۰ نمونه بود که با نسبت ۷۰/۱۵/۱۵ برای فرآیند آموزش، اعتبارسنجی و آزمون مورد استفاده قرار گرفتند. اعتبارسنجی از روش Hold-out بهره برد و مدل ANN به کار رفته، عملکرد بسیار مطلوبی با ضریب تعیین $R^2 \approx 0.993$ ، خطای $RMSE \approx 0.0041$ و خطای $MAE \approx 0.0032$ ارائه داد. برای بهینه‌سازی، ترکیبی از روش‌های Pareto و Grid Search به کار گرفته شد که امکان بررسی هم‌زمان چندین هدف طراحی را فراهم آورده است.

مطالعه İzgi و همکاران [۴۴] به طراحی و تحلیل پره‌های متحرک در مخزن PCM اختصاص داشت. از مدل ANN برای پیش‌بینی دو متغیر کلیدی، یعنی زمان ذوب و بازده حرارتی، استفاده شد. ورودی‌های مدل شامل سرعت و دامنه حرکت پره‌ها، دمای ورودی و خواص ترموفیزیکی PCM مانند ضریب هدایت حرارتی بود. داده‌های مورد استفاده از شبیه‌سازی CFD استخراج شده و شامل ۳۰۰ نمونه بود. ارزیابی عملکرد مدل با روش Hold-out انجام شد و دقت بسیار بالایی با ضریب تعیین $R^2 \approx 0.994$ و $RMSE \approx 0.0045$ و $R^2_{eff} \approx 0.992$ ثبت گردید. در این مطالعه، Grid Search برای تنظیم ابرپارامترهای شبکه و یافتن شرایط بهینه حرکت پره‌ها به کار گرفته شد.

۳-۲- تمرکز بر بر مدل‌سازی و بهینه‌سازی سامانه‌های ذخیره‌سازی حرارت نهان در ترکیب با فناوری‌های دیگر

دسته دوم شامل مقالاتی است که تمرکز اصلی آن‌ها بر مدل‌سازی و بهینه‌سازی سامانه‌های ذخیره‌سازی حرارت نهان در ترکیب با فناوری‌های دیگر قرار داشت. در این پژوهش‌ها، PCM به‌طور یکپارچه با سیستم‌های فتوولتائیک، فتوولتائیک-حرارتی و یا سامانه‌های خنک‌سازی غیرفعال ترکیب شده تا کارایی کلی

جدول ۱ خلاصه مدل‌های یادگیری ماشین نظارت‌شده مورد استفاده در مقالات دسته اول
(تمرکز بر مدل‌سازی و پیش‌بینی عملکرد PCM در شرایط مختلف)

نتایج کمی کلیدی	بهینه‌سازی	عملکرد روی Test	اعتبارسنجی	منبع / حجم داده	ورودی‌های کلیدی	هدف مدل	مدل ML	مرجع جدول (۱ و ۲)
73.5% - زمان ذوب کامل؛ $\theta \approx 126^\circ$ ، $Z=D=$ حداکثر طراحی بهینه H : کم، $\theta \approx 120^\circ$ (130° کاهش چشمگیر زمان‌ها)	GA	$R^2 \approx 0.996 - 0.998$ $RMSE \approx 3.5 - 23.6$ s	Hold-out	CFD، ۲۷ نمونه، ۱۵/۱۵/۷۰	θ ، D، Z (bio inspired)	زمان لازم برای ذوب $\phi=0.5/0.8/1$	ANN	[35]
بهبود ۳۵-۴۰٪ با انتخاب Re و نسبت ابعاد	—	XGB: $R^2=0.998$; $RMSE \approx 6.1$ s	k-fold=	CFD، ۱۲۰۰، ۱۵/۱۵/۷۰	Re، Aspect Ratio، T_in، دبی	زمان ذوب در محفظه مستطیلی	XGBoost (/ RF / SVR / ANN / ANN)	[14]
کاهش ~۴۵٪ زمان با افزایش T_wall (نمونه موردی)	—	ANN: $R^2=0.997$; $RMSE \approx 7.2$ s	k-fold=5	CFD، ۱۰۰۰، ۱۵/۱۵/۷۰	T_wall، Cp، k، h، هندسه، ρ	زمان ذوب	(برتر / RF / XGB / SVR)	[38]
17%+ توان، -۱۴٪ زمان شارژ	NSGA-II	$R^2=0.997$; $RMSE=0.004$ 8 ; MAPE=0.95 %	Hold-out	CFD، ۷۶۸، ۱۵/۱۵/۷۰	قطر/ضخام تعداد/تعداد فین، $\dot{m}$ ، T_in	توان/زمان شارژ- دشارژ	ANN	[39]
زاویه بهینه $\approx 60^\circ$ ؛ -۱۲٪ زمان، +۹٪ HT	—	$R^2_{melt}=0.99$ 4 ($RMSE=0.00$ 56)	Hold-out	CFD، ۴۵۰، ۱۵/۱۵/۷۰	زاویه محفظه، T_wall، هندسه ...	زمان ذوب، نرخ انتقال حرارت (محفظه مایل)	ANN	[40]
بازده ۹۶،۷٪ @ ۱۲ rpm، 45° بازده، -۱۱٪ زمان	Grid Search	$R^2=0.995$; $RMSE=0.003$ 8 ; MAE=0.0029	Hold-out	CFD، ۵۱۲، ۱۵/۱۵/۷۰	rpm، زاویه/ضخام ت پره، T_f، T_0	بازده رهایش حرارت	ANN	[41]
32% - نسبت به فوم یکنواخت؛ -۷۱٪ نسبت به بدون فوم؛ +۲۵٪ HT اولیه	Grid Search	$R^2 > 0.98$; $RMSE < 2\%$ نسبی	Hold-out	CFD، ۱۲۰، ۱۵/۱۵/۷۰	نوع آرایش، ε بالا/پایین، نسبت لایه‌ها	زمان ذوب، نرخ HT (فوم ناهمگن)	ANN	[42]
18% - زمان؛ +۷٪ راندمان	Pareto (MOO)	$R^2=0.994$; $RMSE=0.015$ s ; MAE=0.010 s	Hold-out	CFD، ۳۵۰، ۱۵/۱۵/۷۰	T_in، $\dot{m}$ ، تعداد/ضخام ت فین، قطر ...	زمان شارژ کامل	ANN	[43]
13%+ بازده؛ -۱۵٪ زمان ذوب	Pareto + Grid	$R^2=0.993$; $RMSE=0.004$ 1 ; MAE=0.0032	Hold-out	CFD، ۴۲۰، ۱۵/۱۵/۷۰	قطر/تعداد/فا صله لوله، ارتفاع پایه، T_in	بازده ذوب	ANN	[27]
18% - زمان ذوب؛ +۱۱٪ کارایی	Grid Search	$R^2_{melt}=0.99$ 4 ($RMSE=0.00$ 45) $R^2_{eff}=0.992$	Hold-out	CFD، ۳۰۰، ۱۵/۱۵/۷۰	سرعت/دامنه حرکت پره، T_in، k_PCM، ...	زمان ذوب و کارایی (پره متحرک)	ANN	[44]

از ۴۲/۵ به ۳۴/۸ درجه سانتی‌گراد کاهش و یکنواختی حرارتی به میزان حدود ۲۵ درصد بهبود یافته است.

در مطالعه انجام شده توسط Yang و همکاران [۴۷]، شبکه عصبی مصنوعی توسعه یافته است تا عملکرد یک سیستم ذخیره‌سازی حرارتی آبشاری بستر پر شده، که با ذخیره‌سازی انرژی با هوای فشرده آدیاباتیک کوپل شده است، پیش‌بینی شود. ورودی‌های مدل شامل ابعاد بخش‌های مختلف بستر، دمای ورودی، دبی جرمی و چیدمان لایه‌های مواد تغییر فاز دهنده (PCM) بودند. داده‌ها از ترکیبی از شبیه‌سازی دینامیک سیالات محاسباتی (CFD) و تحلیل ترمودینامیکی استخراج شده‌اند و شامل ۶۰۰ سناریو می‌باشند. آموزش مدل با استفاده از یک شبکه دارای دو لایه پنهان و الگوریتم Levenberg-Marquardt (LM) انجام شده است. دقت مدل بسیار بالا گزارش شده است؛ به‌ویژه برای بازده ($R^2=0.994$) و افت فشار ($R^2=0.992$). بهینه‌سازی طراحی با کمک الگوریتم ژنتیک چندهدفه انجام شد تا بازده و افت فشار همزمان بهبود یابند.

مطالعه Yang و همکاران در منبع [۴۸] نیز از مدل رگرسیون فرایند گاوسی (GPR) به همراه الگوریتم بهینه‌سازی ازدحام ذرات (PSO) برای پیش‌بینی و بهینه‌سازی یک سیستم چندانیه PCM آبشاری با فوم کربنی استفاده نمود. ورودی‌های مدل شامل خواص ترموفیزیکی PCM ها، ضخامت لایه‌ها، چگالی فوم و شرایط کاری سیال بود. داده‌ها از شبیه‌سازی CFD استخراج شده و شامل ۴۲۰ نمونه بوده است. اعتبارسنجی مدل با روش اعتبارسنجی متقاطع-k بخشی ($k\text{-fold}=5$) انجام گردیده است. دقت بالای مدل با ضریب تعیین ۰/۹۹۳ گزارش شده است. علاوه بر پیش‌بینی، مدل GPR قابلیت برآورد عدم قطعیت را نیز دارد که امکان طراحی محافظه‌کارانه و مطمئن‌تر را فراهم می‌سازد.

۴- نتیجه‌گیری

بررسی مقالات منتخب نشان داد که پژوهشگران حوزه ذخیره‌سازی حرارت نهان با مواد تغییر فاز دهنده عمدتاً از مدل‌های یادگیری ماشین نظارت‌شده محدود اما قدرتمند استفاده کرده‌اند. شبکه‌های عصبی مصنوعی و عمیق به دلیل توانایی مدل‌سازی روابط غیرخطی پیچیده بین پارامترهای هندسی و شرایط عملیاتی، پرکاربردترین مدل‌ها هستند. این مدل‌ها اغلب همراه با الگوریتم‌های بهینه‌سازی تکاملی مانند الگوریتم ژنتیک و بهینه‌سازی ازدحام ذرات برای یافتن طرح‌های بهینه ترکیب شده‌اند.

مدل شامل یک لایه مخفی با ۱۵ نورون و الگوریتم آموزش Levenberg-Marquardt (LM) بود که پس از نرمال‌سازی داده‌ها و تنظیم مناسب الگوریتم، به دقت بسیار بالایی معادل ضریب تعیین ۰/۹۹۸ دست یافت. نقطه کلیدی این تحقیق ترکیب ANN با الگوریتم ژنتیک چندهدفه برای همزمان کاهش زمان ذوب و کمینه‌سازی افت فشار بود.

در مطالعه انجام شده توسط Xenitopoulos و همکاران در منبع [۴۵]، به جای تمرکز صرف بر دقت، بر این موضوع تأکید شده که مدل‌های یادگیری ماشین باید تفسیرپذیر باشند. در این راستا، از الگوریتم‌های جنگل تصادفی (Random Forest) و تقویت گرادیانی (Gradient Boosting) برای پیش‌بینی زمان ذوب، فشار و بازده حرارتی سیستم بستر پر شده استفاده شده است. داده‌های آموزشی شامل ۲۵۰ سناریوی شبیه‌سازی دوبعدی و سه‌بعدی CFD بود و ورودی‌ها عواملی مانند قطر ذرات PCM، تخلخل، دمای ورودی و دبی جرمی سیال را شامل می‌گردیدند. برای افزایش قابلیت اعتماد مدل‌ها، از اعتبارسنجی متقاطع پنج‌بخشی استفاده شده و هر دو مدل به دقتی در حدود ۰/۹۹۵ در داده آزمون دست یافتند. ویژگی متمایز این مطالعه استفاده از تکنیک SHAP برای تحلیل اهمیت ویژگی‌ها بود که نشان داد دبی جرمی مهم‌ترین پارامتر و پس از آن دمای ورودی و تخلخل بیشترین تأثیر را داشته‌اند. اگرچه بهینه‌سازی صریح انجام نشده بود، تحلیل SHAP پیشنهاد کرد که می‌توان زمان ذوب را تا حدود ۳۲ درصد کاهش داد. این کار نشان داد که مدل‌های جنگل تصادفی و تقویت گرادیانی علاوه بر دقت بالا، درک عمیق‌تری از فیزیک پنهان مسئله فراهم می‌کنند. با این حال، وابستگی شدید به داده‌های CFD و نبود داده تجربی از محدودیت‌های آن بود.

مطالعه Zhang و همکاران [۴۶] شامل بررسی بهبود مدیریت حرارتی باتری با استفاده از نانو PCM ها بود؛ داده‌ها به روش Lattice Boltzmann شبیه‌سازی شدند (۱۲۰۰ سناریو) و با مدل Gradient Boosting Regressor (GBR) و مقایسه با RF و SVR تحلیل گردیدند. ورودی‌های کلیدی این مدل‌ها شامل نسبت پرشدگی نانو PCM، رسانایی گرمایی PCM، ابعاد و چینش هندسی بسته‌ها و ویژگی‌های نانو ذرات بود. مدل GBR بهترین عملکرد را نشان داد و به دقتی معادل ۰/۹۹۲ در داده آزمون دست یافت. این پژوهش فراتر از پیش‌بینی، از الگوریتم بهینه‌سازی چندهدفه NSGA-II نیز بهره برد. اهداف این بهینه‌سازی شامل کمینه‌سازی دمای بیشینه سلول‌ها و بهبود یکنواختی دما بود. نتایج نشان داد که با طرح بهینه، دمای بیشینه

جدول ۲ خلاصه مدل‌های یادگیری ماشین نظارت‌شده در مقالات دسته دوم (سیستم‌های ترکیبی PCM با فناوری‌های دیگر و بهینه‌سازی چندهدفه)

نتایج کمی کلیدی	بهینه‌سازی	عملکرد روی Test	اعتبارسنجی	منبع/حجم داده	ورودی‌های کلیدی	هدف مدل	مدل ML	مرجع
طراحی متوازن زمان ذوب/افت فشار (اعداد موردی، بدون درصد صریح) پیشنهاد کاهش 32% زمان ذوب با تنظیم دبی/تخلخل	MOGA (Pareto)	$R^2=0.998$ RMSE=8.22 s MAE=4.15 s	Hold-out	CFD 2D 64 نمونه، ۱۵/۱۵/۷۰	قطر ذرات d، کسر حجمی فلز Vf، دمای ورودی T_in	زمان ذوب PCM و افت فشار در LHTES بستر پرسده (ذرات فلزی)	ANN	[36]
پیشنهاد کاهش 32% زمان ذوب با تنظیم دبی/تخلخل	(تحلیل SHAP)	RF: $R^2=0.995$ RMSE=15.3 s — GB: $R^2=0.994$ RMSE=17.1 s	k-fold=5	CFD 2D/3D 250 نمونه، ۲۰/۸۰	دبی جرمی، T_in، تخلخل، قطر ذره، طول بستر... قطر کپسول، ارتفاع بستر، سرعت سیال، T_in، خواص PCM	زمان ذوب/دشارژ و کارایی بستر پرسده	RF / GB	[45]
14% بازده، 22% افت فشار	NSGA-II	GBDT: $R^2=0.991$ RMSE=0.15°C MAE=0.09°C — XGB: $R^2=0.992$ RMSE=0.14°C	k-fold=5	CFD 900 نمونه، ۲۵/۷۵	سرعت سیال، T_in، خواص PCM	بازده حرارتی و افت فشار در Packed-Bed PCM با کپسوله	GBDT (اصلی) / XGBoost / RF	[46]
بازده 97.2% 18% افت فشار؛ 9% زمان شارژ	GA چندهدفه	بازده: $R^2=0.994$ RMSE=0.0045 ; MAE=0.0032 — افت فشار : $R^2=0.992$; RMSE=0.0051	Hold-out	CFD + آنالیز ترمودینامیک، 600 نمونه، ۱۵/۱۵/۷۰	قطر/ارتفاع هر سکشن، T_in، دبی، چیدمان چند PCM	بازده کلی ذخیره‌سازی و افت فشار	ANN (Cascade d + ACAES)	[47]
راندمان 95.8% 12% زمان ذوب	PSO	$R^2=0.993$; RMSE=0.0046 ; MAE=0.0031	k-fold=5	CFD 420 نمونه، ۱۵/۱۵/۷۰	Cp, k, T_melt لايه‌ها، ضخامت‌ها، چگالی فوم، T_in، دبی	راندمان ذخیره‌سازی و زمان ذوب کل	GPR (RBF) + PSO (Cascade d + Carbon Foam)	[48]

۴- نتیجه‌گیری

علاوه بر ANN و DNN، مدل جنگل تصادفی در شرایط داده محدود و برای تحلیل اهمیت ویژگی‌ها به منظور افزایش تفسیرپذیری به کار رفته است. رگرسیون بردار پشتیبان (SVR) نیز در مواقع کمبود داده یا وجود نویز مفید بوده و برای بهبود دقت آن، روش‌هایی همچون جستجوی شبکه‌ای و بهینه‌سازی بیزی به کار رفته‌اند. مدل‌های تقویتی مانند XGBoost و LightGBM، به دلیل دقت بالا و قابلیت تفسیر ویژگی‌ها، به عنوان مکمل یا جایگزین ANN مطرح شده‌اند. رگرسیون فرایند گاوسی در برخی مطالعات به عنوان مدلی برای پیش‌بینی همراه با تخمین عدم قطعیت استفاده شده است که امکان طراحی محافظه‌کارانه و ایمن‌تر را فراهم می‌کند.

بررسی مقالات منتخب نشان داد که پژوهشگران حوزه ذخیره‌سازی حرارت نهان با مواد تغییر فاز دهنده عمدتاً از مدل‌های یادگیری ماشین نظارت‌شده محدود اما قدرتمند استفاده کرده‌اند. شبکه‌های عصبی مصنوعی و عمیق به دلیل توانایی مدل‌سازی روابط غیرخطی پیچیده بین پارامترهای هندسی و شرایط عملیاتی، پرکاربردترین مدل‌ها هستند. این مدل‌ها اغلب همراه با الگوریتم‌های بهینه‌سازی تکاملی مانند الگوریتم ژنتیک و بهینه‌سازی ازدحام ذرات برای یافتن طرح‌های بهینه ترکیب شده‌اند.

۵- فهرست علائم و اختصارات

علائم انگلیسی	
ACAES	ذخیره‌سازی انرژی هوای فشرده آدیباتیک
ANN	شبکه عصبی مصنوعی
CatBoost	کت‌بست (یک الگوریتم تقویتی)
CFD	دینامیک سیالات محاسباتی
DNN	شبکه عصبی عمیق
DL	یادگیری عمیق
Early Stopping	توقف زودهنگام (روش اعتبارسنجی)
FEM	روش المان محدود
GA	الگوریتم ژنتیک
GBR	رگرسیون بوستینگ گرادینتی
GBDT	درخت تصمیم تقویت‌یافته
GPR	فرگرسون فرایند گاوسی
Grid Search	جست‌وجوی شبکه‌ای (تنظیم ابرپارامتر)
Hold-out	اعتبارسنجی هولد-اوت
k-fold	اعتبارسنجی متقاطع k-تایی
LHTES	ذخیره‌سازی انرژی حرارت نهان
LM	الگوریتم لونبرگ-مارکوارت
LightGBM	لایت‌جی‌بی‌ام
MLP	پرسمپترون چندلایه
MLPNN	شبکه عصبی پرسپترون چندلایه
ML	یادگیری ماشین
MOGA	الگوریتم ژنتیک چندهدفه
Nano-PCM (NePCM)	ماده تغییر فاز دهنده نانو تقویت‌شده
NSGA-II	الگوریتم ژنتیک مرتب‌سازی بدون تسلط
Overfitting	بیش‌پردازش
Pareto	بهینه‌سازی پارتو
Physics-Informed ML	یادگیری ماشین آگاه از فیزیک
PPI	تعداد منافذ در هر اینچ
PCM	ماده تغییر فاز دهنده
PCM-LHTES	ذخیره‌سازی انرژی حرارت نهان با مواد تغییر فاز دهنده
PV	فتوولتائیک
PVT	فتوولتائیک حرارتی
RF	جنگل تصادفی
RMSE	خطای میانگین مربعات ریشه‌دار
SML	یادگیری ماشین نظارت‌شده
SHAP	تفسیرپذیری مدل با استفاده از ارزش شاپلی
SVR	رگرسیون بردار پشتیبان
TES	ذخیره‌سازی حرارتی
XGBoost	نسبت بوستینگ گرادینتی پیشرفته

۶- مراجع

[1] C. Lamnatou, C. Cristofari, and D. Chemisana, "Renewable energy sources as a

با وجود موفقیت‌ها، عمده مدل‌ها بر اساس داده‌های شبیه‌سازی CFD ساخته شده‌اند و اعتبارسنجی گسترده با داده‌های تجربی صنعتی کمتر صورت گرفته است. اکثر مطالعات بر ANN تمرکز داشته‌اند و مدل‌های دیگر کمتر به کار رفته‌اند. نیاز جدی به توسعه رویکردهای یادگیری ماشین آگاه از فیزیک وجود دارد تا قوانین فیزیکی در مدل‌سازی دخالت داده شده و خطاهای یادگیری صرف داده‌محور کاهش یابد.

تحقیقات آینده باید بر تلفیق داده‌های آزمایشگاهی و شبیه‌سازی، گسترش مدل‌های متنوع و استفاده از ML آگاه از فیزیک تمرکز کنند تا به مدل‌های سریع‌تر، دقیق‌تر، مقاوم‌تر و قابل پیاده‌سازی صنعتی دست یابند. این راهبردها می‌توانند منجر به بهبود طراحی و بهینه‌سازی سیستم‌های PCM پایدار و کارآمد شوند. به همین دلیل، پیشنهاد می‌شود تحقیقات آتی در سه مسیر عمده حرکت کنند: (۱) تلفیق داده‌های آزمایشگاهی و صنعتی با شبیه‌سازی‌ها برای ارتقای قابلیت اطمینان مدل‌ها، (۲) گسترش استفاده از مدل‌های کمتر رایج اما قدرتمند مانند GPR و مدل‌های تقویتی برای افزایش تنوع و کاهش وابستگی به ANN، و (۳) بهره‌گیری از ML آگاه از فیزیک برای دستیابی به پیش‌بینی‌های دقیق‌تر و قابل اعتمادتر در شرایط عملیاتی پیچیده. این مسیرها می‌توانند به توسعه سیستم‌های ذخیره‌سازی حرارت نهان پایدارتر، بهینه‌تر و با قابلیت پیاده‌سازی صنعتی بالاتر منجر شوند.

لازم به ذکر است که در حالی که بسیاری از مدل‌های یادگیری ماشین مطرح شده در این مرور پژوهش‌های مبتنی بر داده‌های شبیه‌سازی شده است، نسل جدیدی از رویکردها به نام یادگیری ماشین آگاه از فیزیک (Physics-Informed Machine Learning) یا شبکه‌های عصبی آگاه از فیزیک (PINN) به سرعت در حال توسعه هستند. این روش‌ها با بهره‌گیری مستقیم از قوانین فیزیکی در فرایند آموزش، نه تنها چالش کمبود داده‌های آزمایشگاهی واقعی را کاهش می‌دهند، بلکه امکان ایجاد مدل‌های دقیق‌تر و مقاوم‌تر را فراهم می‌آورند. با وجودی که مقالات مرتبط با این روش‌ها در بازه زمانی ۲۰۲۳ تا ۲۰۲۵ با توجه به پارامترهای خاص مدنظر در این مرور یافت نشدند، اهمیت این رویکرد در توسعه مدل‌های ذخیره‌سازی حرارتی آینده بسیار حیاتی بوده و پیشنهاد می‌شود تحقیقات آتی به‌طور گسترده به بررسی و کاربرد آن‌ها اختصاص یابد.

catalyst for energy transition: Technological innovations and an example of the energy transition in France," *Renewable Energy*, vol. 221, p. 119600,

- 2024, doi: <https://doi.org/10.1016/j.renene.2023.119600>.
- [2] K. K. Sen, S. C. Karmaker, A. J. Chapman, and B. B. Saha, "Women's empowerment in driving the energy transition for sustainable development in developing nations," *Renewable and Sustainable Energy Reviews*, vol. 216, p. 115647, 2025, doi: <https://doi.org/10.1016/j.rser.2025.115647>.
- [3] S. Nadalipour Kaldeh, H. Yousefi, Y. Noorollahi, and M. Abdoos, "Integration of renewable sources in buildings: A review of energy savings, feasibility, and challenges," *Energy Reports*, vol. 14, pp. 3905–3934, 2025/12/01/ 2025, doi: <https://doi.org/10.1016/j.egyr.2025.10.046>.
- [4] Y. Manoharan, K. Olson, and A. J. Headley, "Sensitivity of energy storage system optimization program to the source of renewable energy in the presence of demand side management: A behind-the-meter case study," *Applied Energy*, vol. 388, p. 125557, 2025, doi: <https://doi.org/10.1016/j.apenergy.2025.125557>.
- [5] T. B. K. Christensen, H. Lund, and P. Sorknæs, "The role of thermal energy storages in future smart energy systems," *Energy*, vol. 313, p. 133948, 2024, doi: <https://doi.org/10.1016/j.energy.2024.133948>.
- [6] A. Nassar *et al.*, "Enhancing the thermal transfer properties of phase change material for thermal energy storage by impregnating hybrid nanoparticles within copper foams," *Results in Engineering*, vol. 21, p. 101885, 2024, doi: <https://doi.org/10.1016/j.rineng.2024.101885>.
- [7] H. M. Ali *et al.*, "Advances in thermal energy storage: Fundamentals and applications," *Progress in Energy and Combustion Science*, vol. 100, p. 101109, 2024, doi: <https://doi.org/10.1016/j.peccs.2023.101109>.
- [8] S. Nadalipour Kaldeh, H. Yousefi, M. Abdoos, M. Allahrabbi Shirazi, and Y. Noorollahi, "Mapping thermal energy storage research in buildings (2020–2025): a bibliometric analysis of trends, themes, and global collaboration," *Energy Conversion and Management: X*, vol. 28, p. 101345, 2025/10/01/ 2025, doi: <https://doi.org/10.1016/j.ecmx.2025.101345>.
- [9] V. K. Sonker, P. Sharma, R. Ram, and A. Sarkar, "A CFD simulation analysis of the effects of PCM and nanoparticles stored in copper cylinders inside a solar still," *Journal of Energy Storage*, vol. 108, p. 115091, 2025, doi: <https://doi.org/10.1016/j.est.2024.115091>.
- [10] S. Xie, C. Xu, W. Li, Y. Kang, X. Feng, and W. Wu, "Machine learning accelerated the performance analysis on PCM-liquid coupled battery thermal management system," *Journal of Energy Storage*, vol. 100, p. 113479, 2024, doi: <https://doi.org/10.1016/j.est.2024.113479>.
- [11] W. Li *et al.*, "Optimisation of PCM passive cooling efficiency on lithium-ion batteries based on coupled CFD and ANN techniques," *Applied Thermal Engineering*, vol. 259, p. 124874, 2025, doi: <https://doi.org/10.1016/j.applthermaleng.2024.124874>.
- [12] A. Naziri, A. R. Tahavvor, M. A. Shirazi, and R. Zahedi, "Feasibility study on heat recovery from gas turbine exhaust for absorption chiller operation and efficiency enhancement using neural networks," *Thermal Science and Engineering Progress*, vol. 67, p. 104210, Nov. 2025, doi: <https://doi.org/10.1016/j.tsep.2025.104210>.
- [13] K. Vaferi, S. Nekahi, S. Nekahi, and H. Ghaebi, "Charging/Discharging Performance Examination in a Finned-tube Heat Storage Tank: Based on Artificial Neural Network, Pareto Optimization, and Numerical Simulation," *Case Studies in Thermal Engineering*, p. 106388, 2025, doi: <https://doi.org/10.1016/j.csite.2025.106388>.
- [14] S. Shen, C. Wu, and F. Duan, "Machine learning for predicting the PCM melting process in a rectangular enclosure energy storage," *AI Thermal Fluids*, vol. 1, p. 100001, 2025, doi: <https://doi.org/10.1016/j.aitf.2024.100001>.
- [15] A. A. R. Darzi, S. M. Mousavi, M. Razbin, and M. Li, "Utilizing neural networks and genetic algorithms in AI-assisted CFD for optimizing PCM-based thermal energy storage units with extended surfaces," *Thermal Science and Engineering Progress*, vol. 54, p. 102795, 2024, doi: <https://doi.org/10.1016/j.tsep.2024.102795>.
- [16] A. Saifoddin, N. Mirzaei, M. Allahrabbi Shirazi, and H. Yousefi, "Comparative Applications of Supervised and Unsupervised Machine Learning Models in Energy Systems," (in en), *Journal of Energy Management and Technology*, vol. 9, no. 4, pp. 284–290, 2025, doi: <https://doi.org/10.22109/jemt.2025.547118.1573>.
- [17] R. K. Kottala, B. K. Ramaraj, J. BS, M. G. Vempally, and M. Lakshmanan, "Experimental investigation and neural network modeling of binary eutectic/expanded graphite composites for medium temperature thermal energy storage," *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, vol. 47, no. 2, p. 2043490, 2025, doi: <https://doi.org/10.1080/15567036.2022.2043490>.

- [18] R. Bharathiraja, T. Ramkumar, M. Selvakumar, and K. Sasikumar, "Experimental and numerical analysis of hybrid nano-enhanced phase change material (PCM) based flat plate solar collector," *Journal of Energy Storage*, vol. 96, p. 112649, 2024, doi: <https://doi.org/10.1016/j.est.2024.112649>.
- [19] O. Kazaz and E. Abu-Nada, "Thermal performance of nano-architected phase change energetic materials for a next-generation solar harvesting system," *Energy Conversion and Management*, vol. 327, p. 119541, 2025, doi: <https://doi.org/10.1016/j.enconman.2025.119541>.
- [20] A. Nandi and N. Biswas, "Melting dynamics and energy efficiency of nano-enhanced phase change material (NePCM) with graphene, Al₂O₃, and CuO for superior thermal energy storage (TES)," *Journal of Energy Storage*, vol. 109, p. 115076, 2025, doi: <https://doi.org/10.1016/j.est.2024.115076>.
- [21] A. Vedrtam *et al.*, "Combined CFD and FEM analysis of 3D printed PCM integrated concrete panels for passive thermal management in buildings," *Applied Thermal Engineering*, vol. 279, p. 127544, 2025, doi: <https://doi.org/10.1016/j.applthermaleng.2025.127544>.
- [22] X. Huang *et al.*, "Multi-phase flow and heat transfer characteristics of composite heat storage materials during melting process: simulation and optimization," *International Journal of Heat and Mass Transfer*, vol. 253, p. 127599, 2025, doi: <https://doi.org/10.1016/j.ijheatmasstransfer.2025.127599>.
- [23] Y.-T. Lee, Y.-R. Liao, L.-H. Chien, F.-B. Cheung, and A.-S. Yang, "Performance enhancement of latent heat thermal energy storage systems via dynamic melting process of PCM under different control strategies," *Applied Thermal Engineering*, vol. 259, p. 124903, 2025, doi: <https://doi.org/10.1016/j.applthermaleng.2024.124903>.
- [24] G. Yan *et al.*, "Solar-powered compact thermal energy storage system with rapid response time and rib-enhanced plate via techniques of CFD, ANN, and GA," *Journal of Energy Storage*, vol. 105, p. 114807, 2025, doi: <https://doi.org/10.1016/j.est.2024.114807>.
- [25] H. E. Abdellatif, A. Belaadi, A. Arshad, B. X. Chai, and D. Ghernaout, "Enhancing thermal energy storage system efficiency: Geometric analysis of phase change material integrated wedge-shaped heat exchangers," *Applied Thermal Engineering*, vol. 262, p. 125268, 2025, doi: <https://doi.org/10.1016/j.applthermaleng.2024.125268>.
- [26] S. Agrebi, B. Tashtoush, and A. Guizani, "Performance analysis of helical coil heat exchangers for latent heat thermal storage in solar applications," *Energy Conversion and Management*, vol. 343, p. 120205, 2025, doi: <https://doi.org/10.1016/j.enconman.2025.120205>.
- [27] A. Almadhor *et al.*, "Optimizing novel thermal energy storage systems: Enhancing melting efficiency with tubes, stands, and advanced machine learning techniques," *Journal of Energy Storage*, vol. 124, p. 116908, 2025, doi: <https://doi.org/10.1016/j.est.2025.116908>.
- [28] A. S. Soliman, A. Radwan, M. S. Fouda, A. A. Sultan, and O. Abdelrehim, "Energy assessment of a sliding window integrated with PV cell and multiple PCMs," *Journal of Energy Storage*, vol. 86, p. 111341, 2024, doi: <https://doi.org/10.1016/j.est.2024.111341>.
- [29] R. G. Elenga, L. Zhu, and S. Defilla, "Performance evaluation of different building envelopes integrated with phase change materials in tropical climates," *Energy and Built Environment*, vol. 6, no. 2, pp. 332–346, 2025, doi: <https://doi.org/10.1016/j.enbenv.2023.11.008>.
- [30] O. O. Issa and V. Thirunavukkarasu, "Experimental study on charging and discharging behavior of PCM encapsulations for thermal energy storage of concentrating solar power system," *Journal of Energy Storage*, vol. 85, p. 111071, 2024, doi: <https://doi.org/10.1016/j.est.2024.111071>.
- [31] A. Sharma, P. K. Singh, E. Makki, J. Giri, and T. Sathish, "A comprehensive review of critical analysis of biodegradable waste PCM for thermal energy storage systems using machine learning and deep learning to predict dynamic behavior," *Heliyon*, vol. 10, no. 3, 2024, doi: <https://doi.org/10.1016/j.heliyon.2024.e25800>.
- [32] A. Basem *et al.*, "Integrating artificial intelligence-based metaheuristic optimization with machine learning to enhance Nanomaterial-containing latent heat thermal energy storage systems," *Energy Conversion and Management: X*, vol. 25, p. 100835, 2025, doi: <https://doi.org/10.1016/j.ecmx.2024.100835>.
- [33] B. İzgi, "Machine learning predictions and optimization for thermal energy storage in cylindrical encapsulated phase change material," *International Journal of Energy Studies*, vol. 9, no. 2, pp. 199–218, 2024, doi: <https://doi.org/10.58559/ijes.1420875>.
- [34] W. Zhang, H. Tian, and T. Liu, "Unraveling the structure and thermophysical property of heterogeneous eutectic salt by machine learning potential for solar thermal energy storage,"

- Sustainable Materials and Technologies*, vol. 45, p. e01451, 2025, doi: <https://doi.org/10.1016/j.susmat.2025.e01451>.
- [35] L. Ran *et al.*, "Advancing solar thermal utilization by optimization of phase change material thermal storage systems: A hybrid approach of artificial neural network (ANN)/Genetic algorithm (GA)," *Case Studies in Thermal Engineering*, vol. 64, p. 105513, 2024, doi: <https://doi.org/10.1016/j.csite.2024.105513>.
- [36] A. Anagnostopoulos, T. Xenitopoulos, Y. Ding, and P. Seferlis, "An integrated machine learning and metaheuristic approach for advanced packed bed latent heat storage system design and optimization," *Energy*, vol. 297, p. 131149, 2024, doi: <https://doi.org/10.1016/j.energy.2024.131149>.
- [37] V. K. Venkatraman Balakrishnan and K. Kumaresan, "Thermal analysis of PCM magnesium chloride hexahydrate using various machine learning and deep learning models," 2023, doi: <https://doi.org/10.1016/j.engappai.2023.107159>.
- [38] A. Nokhosteen and S. Sobhansarbandi, "Melting behavior prediction of latent heat storage materials: A multi-pronged solution," *Journal of Energy Storage*, vol. 65, p. 107018, 2023, doi: <https://doi.org/10.1016/j.est.2023.107018>.
- [39] K. Vaferi, A. Farajollahi, T. Gholizadeh, and M. Rostami, "Enhancing charging and discharging performance in a novel latent heat storage via design optimization and artificial neural network modeling," *Journal of Energy Storage*, vol. 114, p. 115757, 2025, doi: <https://doi.org/10.1016/j.est.2025.115757>.
- [40] H. E. Abdellatif, S. A. Khan, A. Belaadi, and D. Ghernaout, "Enhancing thermal energy storage: The impact of inclined enclosure geometry and artificial neural network based modeling on phase change material melting performance," *Journal of Energy Storage*, vol. 114, p. 115750, 2025, doi: <https://doi.org/10.1016/j.est.2025.115750>.
- [41] C. Yan *et al.*, "Heat release efficiency Betterment inside a novel-designed latent heat exchanger featuring arc-shaped fins and a rotational mechanism via numerical model and artificial neural network," *Case Studies in Thermal Engineering*, vol. 61, p. 105093, 2024, doi: <https://doi.org/10.1016/j.csite.2024.105093>.
- [42] H. S. Sultan *et al.*, "Improving phase change heat transfer in an enclosure filled by uniform and heterogenous metal foam layers: A neural network design approach," *Journal of Energy Storage*, vol. 85, p. 110954, 2024/04/30/ 2024, doi: <https://doi.org/10.1016/j.est.2024.110954>.
- [43] Z. Zheng *et al.*, "Optimizing and investigating the charging time of phase change materials in a compact-latent heat storage using pareto front analysis, artificial neural networks, and numerical simulations," *Journal of Energy Storage*, vol. 102, p. 113966, 2024, doi: <https://doi.org/10.1016/j.est.2024.113966>.
- [44] B. İzgi and H. Z. Demirağ, "Optimizing thermal energy storage in rectangular unit: Exploring the impact of moving fin with phase change material," *Journal of Energy Storage*, vol. 99, p. 113452, 2024, doi: <https://doi.org/10.1016/j.est.2024.113452>.
- [45] T. Xenitopoulos, A. Anagnostopoulos, G. Gaidajis, Y. Ding, and P. Seferlis, "Insights into advanced packed bed latent heat storage systems through explainable artificial intelligence techniques," *International Journal of Heat and Mass Transfer*, vol. 253, p. 127577, 2025, doi: <https://doi.org/10.1016/j.ijheatmasstransfer.2025.127577>.
- [46] Y. Zhang, Z. He, W. Guo, and P. Zhang, "Data-driven optimization of packed bed thermal energy storage heating system with encapsulated phase change material," *Journal of Energy Storage*, vol. 79, p. 110017, 2024, doi: <https://doi.org/10.1016/j.est.2023.110017>.
- [47] X. Yang, J. Cui, Y. Li, H. Chi, and J. Xie, "Multi-factor analysis and optimization design of a cascaded packed-bed thermal storage system coupled with adiabatic compressed air energy storage," *Energy Conversion and Management*, vol. 300, p. 117961, 2024, doi: <https://doi.org/10.1016/j.enconman.2023.117961>.
- [48] X. Yang, Y. Li, Y. Ma, J. Cui, and J. Xie, "Optimization of thermal storage performance of cascaded multi-PCMs and carbon foam energy storage system based on GPR-PSO algorithm," *Journal of Energy Storage*, vol. 83, p. 110626, 2024, doi: <https://doi.org/10.1016/j.est.2024.110626>.