

دومین کنفرانس انرژی های تجدیدپذیر و تولیدپراکنده انرژی

10th Iranian Conference on Renewable Energy & Distributed Generation



دانشگاه صنعتی شاهرود

تاریخ ۱۴۰۱/۱۲/۲۵

گواهی ارائه مقاله

بدین وسیله گواهی می شود مقاله با عنوان

پیشبینی باردهی تبخیرسازهای خورشیدی به کمک شبکه های عصبی

نویسنده / نویسندگان : فرزاد عزیزی زاده - محمد مصطفی غفوریان - حمید نیازمند

در دهمین کنفرانس انرژیهای تجدیدپذیر و تولید پراکنده در تاریخ ۲۴ و ۲۵ اسفند ۱۴۰۱ در دانشگاه صنعتی شاهرود ارائه گردید. بدین وسیله از تلاش صورت گرفته در ارسال و ارائه مقاله قدردانی نموده و موفقیت های علمی و پژوهشی راز خداوند متعال آرزومندیم.



۰۹۴۳۹۹_۱۲۲۰



دکتر علی دستمان
دبیر اجرایی کنفرانس



دکتر مهدی باقرزاد
دبیر علمی کنفرانس

پیش‌بینی بازدهی تبخیرسازهای خورشیدی به کمک شبکه‌های عصبی

فرزد عزیزی زاده¹، محمد مصطفی غفوریان²، حمید نیازمند³

¹دانشجو کارشناسی ارشد، دانشگاه فردوسی مشهد، مشهد، farzad.azizade@alumni.um.ac.ir

²پسا دکتری، دانشگاه فردوسی مشهد، مشهد، m.m.ghafoorian@mail.um.ac.ir

³استاد، دانشگاه فردوسی مشهد، مشهد، niazmand@um.ac.ir

چکیده

به علت کمبود منابع آب شیرین و افزایش روز افزون جمعیت کره زمین، بشر نیازمند به دستگاه‌های آب شیرین‌ساز با بازدهی تبخیر بالا است. یکی از مهم‌ترین اجزا آب شیرین‌سازهای حرارتی خورشیدی، تبخیرساز است. یک نوع بسیار رایج تبخیرسازهای خورشیدی شامل تبخیرسازهای روش تبخیرسازهای روش حجمی است [7].

عوامل متعددی مانند دمای محیط، دمای بالک، دمای سطح، شدت تابش، حجم سیال، خواص حرارتی سیال و غیره در بازدهی تبخیرسازهای خورشیدی تاثیر گذارند [8, 9] که مقایسه نتایج و یافتن بهترین سیستم تبخیرساز خورشیدی، تحت شرایط یکسان را شوار می‌کند. لذا ارائه یک مدل برای پیش‌بینی عملکرد تبخیرسازهای خورشیدی و مقایسه نتایج حاصل، انگیزه و هدف اصلی این پژوهش است.

تا به امروز مطالعات آزمایشگاهی بسیاری در شرایط مختلف و با استفاده از مواد مختلف به منظور دستیابی به بالاترین بازدهی تبخیر ممکن انجام شده‌است. به عنوان مثال در روش تبخیر حجمی با استفاده از نانوذراتی همچون: ZnO [7]، GNP، MWCNT-OH [11]، rGO [10]، GO، MWCNT، SWCNT، Fe₃O₄، Fe₃O₄-CNT [13]، TiO₂ [12]، MWCNT-COOH [14]، و Ag-TiO₂ [15] به ترتیب با شدت تابش 3، 3.5، 3.5، 3.5، 3.5، 7، 3.5، 3.5، 10، و 5 کیلووات بر متر مربع به بازدهی تبخیر 26.40، 38.34، 44.22، 47.39، 22.5، 21.3، 60.3، و 19.5 درصد دست یافته‌اند.

یکی از روش‌های مدل‌سازی استفاده از شبکه‌های عصبی مصنوعی¹ است که در حوزه‌های مختلفی از جمله حوزه آب شیرین‌سازهای حرارتی خورشیدی کاربرد دارند. به عنوان نمونه حمدان و خلیل [16] در سال 2013 به کمک شبکه عصبی مصنوعی به پیش‌بینی بازدهی حرارتی یک سیستم خورشیدی استیل² با استفاده از دماهای محفظه، صفحه، هوای محیط و آب

مقایسه نتایج تجربی بازدهی تبخیر در شدت تابش‌های مختلف کاری دشوار است و انجام آزمایشات مجدد در شدت تابش یکسان هزینه بر خواهد بود. از این رو پیش‌بینی نتایج می‌تواند راه حل مناسبی در کاهش هزینه‌ها باشد. یکی از ابزارهای پیش‌بینی شبکه‌های عصبی مصنوعی هستند که در زمینه‌های مختلف به طور گسترده مورد استفاده قرار گرفته‌اند. در این مطالعه، یک شبکه عصبی مصنوعی منظور پیش‌بینی عملکرد تبخیر حجمی مواد مختلف تحت شدت تابش یکسان 1 کیلووات بر متر مربع، توسعه و مورد بررسی قرار گرفت. پس از 200 دوره آموزشی، مدل ایجاد شده بر اساس میانگین مربعات خطاهای مجموعه داده‌های آموزشی و اعتبارسنجی، عاری از مشکلات بیش‌آموزی و کم‌آموزی است. علاوه بر این، مشخص شد که در تمام زیر مجموعه‌های داده‌های آموزش، اعتبارسنجی و آزمودن، داده‌های پیش‌بینی شده به امتیاز $R^2=0.994$ دست می‌یابند و در پیش‌بینی نتایج داده‌های دیده نشده قابل اعتماد هستند. نهایتاً به کمک مدل ایجاد شده پیش‌بینی می‌شود که در شدت تابش $\frac{1 \text{ kW}}{m^2}$ بالاترین بازدهی تبخیر حجمی میان داده‌ها موجود به کمک نانوسیال Fe₃O₄ با درصد وزنی 2.6 و سیال پایه آب بدست خواهد آمد.

واژه‌های کلیدی

هوش مصنوعی، یادگیری ماشین، تبخیرسازهای خورشیدی، پیش‌بینی بازدهی، شبکه عصبی

مقدمه

دنیای امروز به سمتی پیش می‌رود که نیاز به پیش‌بینی کردن نتایج بیش از پیش حس می‌شود. یکی از ابزارهای پیش‌بینی استفاده از روش‌های یادگیری ماشین و روش‌های مبنی بر داده است [1, 2]. از جمله حوزه‌هایی که می‌توان از مدل‌سازی توسط یادگیری ماشین و هوش مصنوعی استفاده کرد، حوزه انرژی‌های تجدید پذیر [3, 4] و بخصوص سیستم‌های انرژی خورشیدی [5, 6] است.

² Solar still

¹ Artificial neural network

بازدهی انرژی یک سیستم خورشیدی استیل دارای المنت‌های حرارتی الکتریکی را با پارامترهای ورودی شامل زمان، قدرت فن، شدت تابش خورشیدی، دماها (دماهای هوا، آب، شیشه و حوضه) و کسر حجمی نانوذرات به کمک شبکه عصبی مصنوعی پیش‌بینی کرده‌اند. نتایج آن‌ها نشان داد که می‌توان به کمک روش بهینه سازی ازدحام ذرات⁶ عملکرد یک شبکه عصبی مصنوعی را تا حدی بهبود بخشید در این راستا آن‌ها نشان دادند که مقدار R2 دیتا آموزشی می‌تواند از 0.923 به 0.960 ارتقا یابد.

در هیچ‌کدام از کارهای انجام شده بطور خاص بر روی تبخیرسازهای خورشیدی حجمی تمرکز نشده است. بنابراین، در مطالعه پیش رو سعی بر آن است تا به کمک روش شبکه عصبی مصنوعی با داشتن پارامترهای ضریب رسانش حرارتی موثر، چگالی نانوذره و سیال پایه، ظرفیت گرمایی ویژه نانوذره و سیال پایه، درصد وزنی نانوذره، سطح تابش، طول زمان تابش، شدت تابش، ارتفاع سیال از کف ظرف، و لزجت سیال به عنوان به پیش-بینی بازدهی تبخیر در شدت تابش یکسان $1 \frac{\text{kW}}{\text{m}^2}$ پرداخته شود.

روش تحقیق

در این مطالعه به وسیله داده‌هایی از جنس داده‌های تجربی به آموزش یک شبکه عصبی مصنوعی پرسپترون چند لایه پرداخته می‌شود.

شبکه عصبی مصنوعی پرسپترون چند لایه از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است. هر لایه دارای تعداد مشخصی نورون⁷ یا گره است. نورون‌ها واحدهای محاسباتی کوچکی هستند که دارای تعدادی ورودی و یک خروجی اند. تعداد ورودی‌ها و خروجی‌های مدل به ترتیب تعداد نورون‌های لایه ورودی و خروجی را مشخص می‌کند. در طرف دیگر اما تعداد نورون‌های لایه‌های پنهان وابسته به معماری بهینه مدل منتخب است. خروجی هر نورون موجود در لایه ورودی، همان مقادیر ورودی مدل است اما خروجی نورون‌های لایه‌های پنهان و خروجی به پارامترهای وزن⁸ و بایاس⁹ بستگی دارد که باید در مرحله آموزش شبکه محاسبه شوند. برای درک بهتر آنچه که گفته شد، معماری یک شبکه عصبی مصنوعی پرسپترون چند لایه در شکل 1 نشان داده شده است.

در حوضه‌ها (بالایی، میانی و پایینی)، حجم تقطیر و شدت تابش به صورت تابعی از زمان پرداختند و نشان دادند که مدل شبکه عصبی نارس³ ($R2=0.999$) در مقایسه با مدل‌های پس‌خور (0.998) و المان⁴ (0.959) بهتر عمل می‌کند. در پژوهشی متعلق به سال 2015 از مشالی و همکاران [17] به پیش‌بینی میزان تولید آب، نسبت بازگردانی عملیاتی، و بازدهی حرارتی در یک سیستم خورشیدی استیل تک مرحله‌ای به کمک روش شبکه عصبی مصنوعی با ورودی‌های تعداد روز، رطوبت نسبی، سرعت باد، شدت تابش خورشیدی، شاخص فرابنفش، دمای تغذیه سیستم، دمای آب نمک، دمای هوای محیط، سختی کل آب تغذیه و سختی کل آب نمک، پرداخته شده است. آن‌ها توانستند با استفاده از تابع فعال‌سازی tanh و 15 لایه پنهان به R2 برابر با 0.993 دست یابند. از مزایای روش آن‌ها می‌توان به قابلیت اجرای راحت آن در اکثر زبان‌های برنامه نویسی اشاره کرد. در همان سال طی کاری دیگر از مشالی و همکاران [18] با دادن رطوبت نسبی، سرعت باد، شدت تابش خورشیدی، دمای آب تغذیه، دمای آب نمک، دمای هوای محیط، سختی کل آب خوراک و آب نمک به یک شبکه عصبی مصنوعی تولید آب شیرین روزانه یک سیستم خورشیدی استیل تک مرحله‌ای مورد مطالعه قرار گرفته است. در مطالعه آن‌ها مشخص شد که کمترین مقدار مجذور مربع متوسط خطا برابر با 0.024 با استفاده از الگوریتم یادگیری لوبنبرگ-مارکواردت⁵ حاصل می‌شود. در مطالعه‌های مشابه، سانتوز و همکاران [19] نیز تولید آب شیرین روزانه یک سیستم خورشیدی استیل تک مرحله‌ای را با استفاده از شبکه عصبی مصنوعی مطالعه کرده‌اند. انتخاب ورودی‌ها شامل شدت تابش، دمای محیط، حجم تقطیر، سرعت باد، جهت باد و میانگین روزانه پوشش ابر، تفاوت برجسته کار آن‌ها با کار قبلی است. در سال 2020، چوهان و همکاران [20] با فقط دو ورودی دمای آب و دمای پوشش شیشه‌ای داخلی، تعداد زیادی خروجی از جمله رسانش حرارتی، فشار جزئی بخار، انبساط حجمی، حرارت ویژه، گرمای نهان تبخیر، ویسکوزیته دینامیکی را برای یک سیستم خورشیدی استیل تک مرحله‌ای با استفاده از شبکه عصبی مصنوعی پیش‌بینی می‌کنند. آن‌ها نیز نشان دادند که الگوریتم لوبنبرگ-مارکواردت در مقایسه با سایر روش‌ها برای بررسی سیستم‌های خورشیدی استیل مناسب‌تر خواهد بود بطوری که در نتایج تمام خروجی‌ها، مقدار R2 بیشتر از 0.995 می‌شود. با ادامه تحقیقات در سال 2021، نظری و همکاران [21]

⁷ Neuron

⁸ Weight

⁹ Bias

³ NARX

⁴ Elman

⁵ Levenberg- Marquardt

⁶ PSO

$$J(w, b) = \left(\frac{1}{m}\right) * \text{sum}(L(y[i], y'[i])) \quad (2)$$

$$\begin{cases} w = w - \alpha * \frac{v \left[\frac{\partial(J(w, b))}{\partial w} \right]}{\sqrt{s \left[\frac{\partial(J(w, b))}{\partial w} \right]^2 + \varepsilon}} \\ b = b - \alpha * \frac{v \left[\frac{\partial(J(w, b))}{\partial b} \right]}{\sqrt{s \left[\frac{\partial(J(w, b))}{\partial b} \right]^2 + \varepsilon}} \end{cases} \quad (3)$$


$$v(t) = \frac{\beta * v(t-1) + (1-\beta) * \theta}{1-\theta^t} \quad (4)$$

$$s \left[\frac{\partial(J(w, b))}{\partial w} \right] = \beta * s \left[\frac{\partial(J(w, b))}{\partial w} \right] + (1-\beta) * \left[\frac{\partial(J(w, b))}{\partial w} \right]^2 \quad (5)$$

$$s \left[\frac{\partial(J(w, b))}{\partial b} \right] = \beta * s \left[\frac{\partial(J(w, b))}{\partial b} \right] + (1-\beta) * \left[\frac{\partial(J(w, b))}{\partial b} \right]^2 \quad (6)$$

که در آن J تابع هزینه، y' مقادیر تجربی، m تعداد داده موجود، v میانگین وزنی نمایی¹¹ و s ریشه میانگین مربع پشتیبان¹² نام دارند. همچنین در روابط فوق به β ، θ و ε فرآپارامتر گفته می‌شود که مقادیر آن‌ها قابل تنظیم هستند. معیارهای توقف آموزش متفاوت‌اند. از جمله این معیارها می‌توان به تعداد دوره‌ها (تکرارها) و حداکثر مقدار خطا اشاره کرد. در این مطالعه تعداد 200 دوره و حداکثر متوسط مربع خطا 0.2 به عنوان معیار انتخاب شده‌اند. پس از هر دوره آموزش از مجموعه داده اعتبارسنجی برای بررسی قابلیت پیش‌بینی مدل و در مرحله آزمون، از مجموعه داده‌های آزمون برای بررسی عملکرد نهایی مدل استفاده می‌شود [22]. مسئله پیش رو این تحقیق در واقع محاسبه مقادیر وزن‌ها و بایاس‌ها به کمک داده‌های تجربی است. به منظور حذف اثر متفاوت بودن مرتبه واحدها باید داده‌های تجربی را قبل از به کار بردن آن‌ها در فرایند آموزش شبکه عصبی به کمک (7) استاندارد کرد.

$$x_{\text{new}} = \frac{x - \text{mean}}{\text{standard deviation}} \quad (7)$$




شکل 1: ساختار یک شبکه عصبی مصنوعی پرسپترون چند لایه

شبکه عصبی مصنوعی پرسپترون یک شبکه پیشخور است. به این معنی که محاسبات از لایه ورودی به لایه خروجی بدون هیچ گونه حلقه بازخوردی ادامه می‌یابد.

به طور کلی، ایجاد یک مدل شبکه عصبی مصنوعی شامل سه مرحله آموزش، اعتبارسنجی و آزمون می‌شود که برای ایجاد آن باید مجموعه کل داده‌ها را به سه دسته مجموعه داده‌های آموزشی، مجموعه داده‌های اعتبارسنجی و مجموعه داده‌های آزمون تقسیم کرد. داده‌های آموزشی شامل بیشترین تعداد نقاط داده است و به دنبال آن مجموعه داده‌های اعتبارسنجی و آزمون قرار دارند. به طور معمول، 70 تا 80 درصد از داده‌ها برای آموزش استفاده می‌شوند، در حالی که داده‌های باقی مانده به طور مساوی به اعتبارسنجی و آزمون اختصاص می‌یابند. بجز داده‌های آموزشی سایر داده‌ها، داده‌های دیده نشده نامیده می‌شوند.

شکل 2 یک نورون را نمایش می‌دهد. اگر ورودی نورون x ، خروجی آن y ، مقدار وزن w ، مقدار بایاس b ، و تابع داخلی نورون f باشد، خواهیم داشت:

$$y = f(wx + b) \quad (1)$$



شکل 2: یک نورون به تنهایی

در مرحله آموزش، وزن‌های مرتبط با هر نورون پس از هر دوره¹⁰ تا زمانی که معیار توقف آموزش ارضا شود، به کمک (2) تا (6) به روزرسانی می‌شوند.

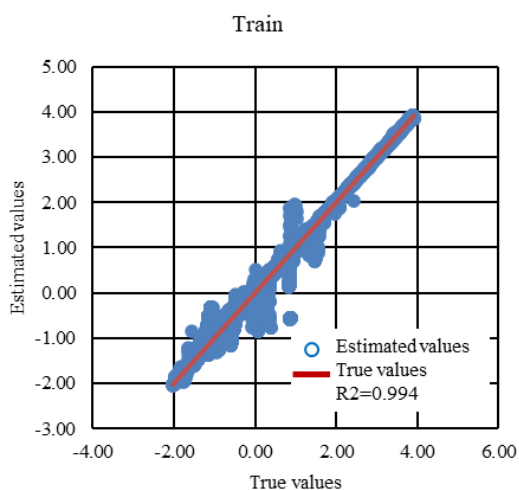
¹² Root mean square prop

¹⁰ Epoch


¹¹ Exponentially weighted average

یافته‌ها


شکل 3 نتایج متوسط مربع خطاها را برای دو زیرمجموعه داده‌های آموزشی (با رنگ قرمز) و اعتبارسنجی (با رنگ آبی) در 200 دوره آموزشی نشان می‌دهد. محورهای این شکل به دلیل استاندارد سازی داده‌ها قبل از آموزش، بدون بعد هستند. همانطور که مشاهده می‌شود، مقادیر متوسط مربع خطاها در پایان 200 دوره به حدود 0.01 رسیده است که قابل قبول ارزیابی می‌شود. همچنین از آنجایی که منحنی‌های هر دو مجموعه داده با تقریب خوبی برهم منطبق هستند، می‌توان نتیجه گرفت که مدل آموزش یافته معتبر و فاقد مشکلات بیش از حد آموزشی^{۱۳} و کم آموزشی^{۱۴} است.



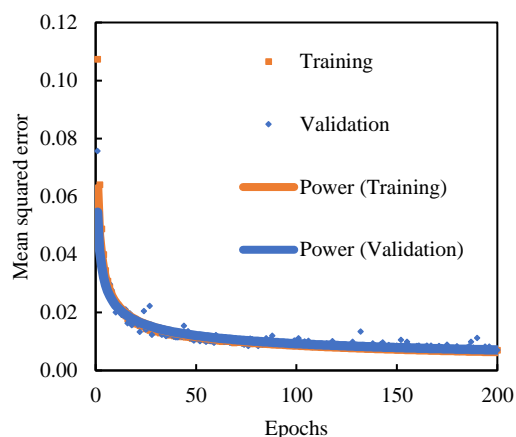
(الف)



(ب)



(پ)



شکل 3: متوسط مربع خطا در مقابل دوره آموزش

در شکل 4 مقادیر بدون بعد پیش‌بینی شده توسط مدل با رنگ آبی با مقادیر بدون بعد تجربی متناظر آن‌ها با رنگ قرمز در سه زیرمجموعه داده‌های آموزشی، اعتبارسنجی و آزمون مقایسه شده‌اند. در این شکل مشاهده می‌شود که پرکندگی داده‌های پیش‌بینی شده در طرف خط داده‌های تجربی برای تمام زیر مجموعه‌ها قابل قبول است و امتیاز $R^2=0.994$ در تمام آن‌ها اختلاف کمی با حالت ایده‌آل ($R^2=1.000$) دارد. بنابر این مدل ایجاد شده از تعمیم پذیری مناسبی برخوردار است و در پیش‌بینی داده‌های از قبل دیده نشده (داده‌های آزمون و اعتبارسنجی) عملکرد خوبی دارد.

شکل 4: مقایسه مقادیر پیش‌بینی شده و تجربی بازدهی تبخیر در (الف) نتایج داده‌های آموزشی، (ب) نتایج داده‌های آزمون و (پ) نتایج داده‌های اعتبارسنجی

¹⁴ Underfitting


¹³ Overfitting

تعداد داده موجود	m
ریشه میانگین مربع پشتیبان	s
میانگین وزنی نمایی	v
وزن	w
ورودی نورو	x
خروجی نورو	y
مقادیر تجربی	y'
علایم یونانی	
یک فرایارامتر	β
یک فرایارامتر	θ
یک فرایارامتر	ε

مراجع و منابع

- [1] B. Koti Reddy and A. K. Singh, "Optimal Operation of a Photovoltaic Integrated Captive Cogeneration Plant with a Utility Grid Using Optimization and Machine Learning Prediction Methods," *Energies*, vol. 14, no. 16, 2021, doi: 10.3390/en14164935.
- [2] P. Behnam, M. Faegh, and M. Khiadani, "A review on state-of-the-art applications of data-driven methods in desalination systems," *Desalination*, vol. 532, 2022, doi: 10.1016/j.desal.2022.115744.
- [3] T. Ma, Z. Guo, M. Lin, and Q. Wang, "Recent trends on nanofluid heat transfer machine learning research applied to renewable energy," *Renewable and Sustainable Energy Reviews*, vol. 138, p. 110494, 2021/03/01/ 2021, doi: <https://doi.org/10.1016/j.rser.2020.110494>.
- [4] A. Mosavi, M. Salimi, S. Faizollahzadeh Ardabili, T. Rabczuk, S. Shamshirband, and A. Varkonyi-Koczy, "State of the Art of Machine Learning Models in Energy Systems, a Systematic Review," *Energies*, vol. 12, no. 7, 2019, doi: 10.3390/en12071301.
- [5] A. Gonzalez Gonzalez, J. V. Alvarez Cabal, M. A. Vigil Berrocal, R. Peón Menéndez, and A. Riesgo Fernández, "Simulation of a CSP Solar Steam Generator, Using Machine Learning," *Energies*, vol. 14, no. 12, 2021, doi: 10.3390/en14123613.
- [6] A. H. Elsheikh, S. W. Sharshir, M. Abd Elaziz, A. Kabeel, W. Guilan, and Z. Haiou, "Modeling of solar energy systems using artificial neural network: A comprehensive review," *Solar Energy*, vol. 180, pp. 622-639, 2019. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S038092X19300465>.
- [7] M. M. Ghafurian *et al.*, "Low-cost zinc-oxide nanoparticles for solar-powered steam production: Superficial and volumetric approaches," *Journal of Cleaner Production*, vol. 280, 2021, doi: 10.1016/j.jclepro.2020.124261.
- [8] Y. Wang, L. Zhang, and P. Wang, "Self-Floating Carbon Nanotube Membrane on Macroporous Silica Substrate for Highly Efficient Solar-Driven Interfacial Water Evaporation," *ACS Sustainable Chemistry & Engineering*, vol. 4, no. 3, pp. 1223-1230, 2016, doi: 10.1021/acssuschemeng.5b01274.

شکل 5 بازدهی تبخیر پیش‌بینی شده در شدت تابش یکسان $1 \frac{kW}{m^2}$ را برای داده‌های مختلف نمایش می‌دهد. در این شکل حداکثر بازدهی پیش‌بینی شده برابر 58.4 درصد برای داده شماره 109 است. با مراجعه به مجموعه داده‌های جمع‌آوری شده می‌توان دریافت که داده شماره 109 مربوط به نانوسیال Fe_3O_4 با درصد وزنی 2.6 و سیال پایه آب می‌شود. برای سایر نقاط داده نیز به همین ترتیب می‌توان عملکرد و بدون انجام مجدد آزمایش تجربی به مقایسه بازدهی مواد مختلف در شدت تابش یکسان پرداخت. لازم به ذکر است که این روش محدود به شدت تابش $1 \frac{kW}{m^2}$ نخواهد بود.



شکل 5: نتایج بازدهی تبخیر پیش‌بینی شده در شدت تابش یکسان $1 \frac{kW}{m^2}$

نتیجه‌گیری

در این تحقیق به بررسی و ایجاد و یک مدل شبکه عصبی مصنوعی برای پیش‌بینی بازدهی تبخیر مواد مختلف در شدت تابش یکسان $1 \frac{kW}{m^2}$ پرداخته شد. با بررسی متوسط مربع خطاهای مجموعه داده‌های آموزشی و اعتبار سنجی مشخص شد که پس از 200 دوره آموزشی مدل ایجاد شده عاری از مشکلات بیش‌آموزی و کم‌آموزی است. همچنین در تمام زیر مجموعه‌ها آموزشی، اعتبار سنجی و آزمودن نتایج پراکندگی داده‌های پیش‌بینی شده در اطراف مقادیر صحیح نشان می‌دهند که مدل ایجاد شده عملکرد مناسبی ($R^2=0.994$) را در پیش‌بینی نتایج داده‌های دیده نشده ارائه می‌دهد و از تعمیم‌پذیری مناسبی برخوردار است. نهایتاً به کمک مدل ایجاد شده پیش‌بینی می‌شود که در شدت تابش $1 \frac{kW}{m^2}$ بالاترین بازدهی تبخیر حجمی میان داده‌ها موجود به کمک نانوسیال Fe_3O_4 با درصد وزنی 2.6 و سیال پایه آب بدست خواهد آمد.

فهرست علائم

b	بایاس
f	تابع داخلی نورو
J	تابع هزینه

- [16] M. A. Hamdan, H. R. A. Khalil, and E. A. M. Abdelhafez, "Comparison of neural network models in the estimation of the performance of solar still under Jordanian climate," *Journal of Clean Energy Technologies*, vol. 1, no. 3, pp. 238-242, 2013.
- [17] A. F. Mashaly, A. A. Alazba, A. M. Al-Awaadh, and M. A. Mattar, "Predictive model for assessing and optimizing solar still performance using artificial neural network under hyper arid environment," *Solar Energy*, vol. 118, pp. 41-58, 2015.
- [18] A. F. Mashaly and A. A. Alazba, "Comparative investigation of artificial neural network learning algorithms for modeling solar still production," *Journal of Water Reuse and Desalination*, vol. 5, no. 4, pp. 480-493, 2015.
- [19] N. I. Santos, A. M. Said, D. E. James, and N. H. Venkatesh, "Modeling solar still production using local weather data and artificial neural networks," *Renewable Energy*, vol. 40, no. 1, pp. 71-79, 2012.
- [20] R. Chauhan, S. Sharma, R. Pachauri, P. Dumka, and D. R. Mishra, "Experimental and theoretical evaluation of thermophysical properties for moist air within solar still by using different algorithms of artificial neural network," *Journal of Energy Storage*, vol. 30, p. 101408, 2020.
- [21] M. Bahiraei, S. Nazari, and H. Safarzadeh, "Modeling of energy efficiency for a solar still fitted with thermoelectric modules by ANFIS and PSO-enhanced neural network: A nanofluid application," *Powder Technology*, vol. 385, pp. 185-198, 2021.
- [22] J. Jawad, A. H. Hawari, and S. J. Zaidi, "Artificial neural network modeling of wastewater treatment and desalination using membrane processes: A review," *Chemical Engineering Journal*, vol. 419, p. 129540, 2021.
- [9] X. Wang, Y. He, G. Cheng, L. Shi, X. Liu, and J. Zhu, "Direct vapor generation through localized solar heating via carbon-nanotube nanofluid," *Energy Conversion and Management*, vol. 130, pp. 176-183, 2016.
- [10] M. M. Ghafurian, H. Niazmand, F. T. Dastjerd, and O. Mahian, "A study on the potential of carbon-based nanomaterials for enhancement of evaporation and water production," *Chemical Engineering Science*, vol. 207, pp. 79-90, 2019, doi: 10.1016/j.ces.2019.05.043.
- [11] X. Liu, X. Wang, J. Huang, G. Cheng, and Y. He, "Volumetric solar steam generation enhanced by reduced graphene oxide nanofluid," *Applied Energy*, vol. 220, pp. 302-312, 2018, doi: 10.1016/j.apenergy.2018.03.097.
- [12] M. M. Ghafurian, H. Niazmand, and E. Ebrahimi-Bajestan, "Improving steam generation and distilled water production by volumetric solar heating," *Applied Thermal Engineering*, vol. 158, 2019, doi: 10.1016/j.applthermaleng.2019.113808.
- [13] M. Ghafurian, H. Niazmand, A. Moallemi, and F. Tavakoli Dastjerd, "Experimental Investigation of Nanofluid Based on Titanium Dioxide Nanoparticles in Absorption Sunlight and Steam Generation," *Modares Mechanical Engineering*, vol. 20, no. 1, pp. 57-65, 2020.
- [14] L. Shi, Y. He, Y. Huang, and B. Jiang, "Recyclable Fe₃O₄@CNT nanoparticles for high-efficiency solar vapor generation," *Energy Conversion and Management*, vol. 149, pp. 401-408, 2017, doi: 10.1016/j.enconman.2017.07.044.
- [15] H. Li, Y. He, Z. Liu, Y. Huang, and B. Jiang, "Synchronous steam generation and heat collection in a broadband Ag@TiO₂ core-shell nanoparticle-based receiver," *Applied Thermal Engineering*, vol. 121, pp. 617-627, 2017.