



ارزیابی کارایی مدل‌های شبکه‌های عصبی مصنوعی برای تخمین و محاسبه ضریب انتقال حرارت هدایتی در نانوسیالات

حسن امیراحمدی^{۱*}، محمدحسن نوبختی^۲، غلامرضا صالحی^۳

*۱- دانشجوی دکتری تخصصی، گروه مهندسی مکانیک، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران، hasan.amirahmadi@srbiau.ac.ir

۲- استادیار، گروه مهندسی مکانیک، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران، m.nobakhti@srbiau.ac.ir

۳- دانشیار، گروه مهندسی مکانیک، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران، Rezasalehi20@gmail.com

دریافت: ۱۴۰۴/۲/۲۸، بازنگری: ۱۴۰۴/۵/۲۳، پذیرش: ۱۴۰۴/۶/۱

چکیده

در این مقاله سعی شده است، داده‌های مربوط به نانوسیالات با استفاده از مدل‌های هوش مصنوعی توسعه داده شود و مدلی بهینه به جهت تخمین و محاسبه ضریب هدایت حرارتی برای نانوسیالات معرفی شود. لذا داده‌های تجربی آزمایشات مبتنی بر نانوذرات CuO ، Al_2O_3 ، Fe_2O_3 ، TiO_2 در سیال پایه آب مقطر برای درصدهای حجمی ۰/۲ تا ۲ در دماهای مختلف اندازه‌گیری شد و به همراه داده‌های کتابخانه‌ای به‌عنوان ورودی مدل‌ها استفاده شد. غلظت نانوسیال، دما، چگالی و ویسکوزیته اطلاعات ورودی به مدل‌ها بودند و پارامتر ضریب هدایت حرارتی نانوسیال خروجی مدل‌ها می‌باشد. در مجموع ۲۶۸ سری داده به‌عنوان ورودی مدل‌ها تعریف شد، که ۷۰ درصد صرف آموزش و ۳۰ درصد برای صحت‌گذاری استفاده شد. با پنج حالت مختلف شامل شبکه عصبی مصنوعی با تابع فعالسازی ANN-Trainbr، ANN-Trainlm، ANN-Trainscg، شبکه حافظه کوتاه مدت طولانی (LSTM) و رگرسیون بردار پشتیبان (RVS) برای مدل‌سازی بررسی شد. نتایج نشان داد، LSTM تطابق بسیار مطلوب‌تری با داده‌های تجربی دارد، زیرا مقادیر ارزیابی شامل ضریب رگرسیون (R^2)، خطای جذر میانگین مربعات (RSME) و درصد میانگین مطلق خطا (MAPE) به ترتیب مقادیر ۰/۹۷۶۴، ۰/۰۳۱۳ و ۰/۰۸۱۹ را به خود اختصاص دادند.

*عهده‌دار مکاتبات: hasan.amirahmadi@srbiau.ac.ir

کلمات کلیدی: نانوسیال، شبکه عصبی مصنوعی، ضریب هدایت حرارتی، مدل‌سازی

نحوه استناد به این مقاله حسن امیراحمدی، محمدحسن نوبختی، غلامرضا صالحی. ارزیابی کارایی مدل‌های شبکه‌های عصبی مصنوعی برای تخمین و محاسبه ضریب انتقال حرارت هدایتی در نانوسیالات. مهندسی مکانیک تبدیل انرژی. ۱۴۰۴؛ ۱۲ (۲): ۸۶-۶۹.

۱- مقدمه

نانوسیالات ترکیبات همگنی هستند، که به وسیله توزیع یکنواخت یک نانوذره در سیال پایه ساخته می‌شوند. نانوذرات به کار رفته، به طور کلی قطری کم‌تر از ۱۰۰ نانومتر دارند و می‌توانند از نوع فلز، اکسید فلز یا غیرفلز باشند که افزودن نانوذرات مختلف بر خواص ترموفیزیکی سیال تأثیر می‌گذارد [۱]. تحقیقات نشان داده است، که معمولاً استفاده از نانوذرات در سیال پایه باعث بهبود ضرایب انتقال حرارت و سایر خواص می‌شود [۲، ۳]. ضریب انتقال حرارت نانوذراتی که مورد استفاده قرار می‌گیرند به مراتب بزرگ‌تر از ضریب انتقال حرارت سیال پایه است، بنابراین ضریب انتقال حرارت نانوسیال بزرگ‌تر از سیال پایه خالص است [۴]. کاربرد نانوسیالات در زمینه‌های بسیاری از علوم مکانیک و مهندسی از جهت جذب گرما و حرارت سبب پژوهش‌های گسترده‌ای در این زمینه شده است [۵]. افزایش خواص نانوسیالات باعث افزایش راندمان، کاهش اندازه تجهیزات و هم‌چنین هزینه ساخت آن‌ها می‌شود [۶].

پارامترهای متعددی از قبیل سرعت جریان نانوسیال ورودی به مبدل، نوع نانوذرات، غلظت نانوذره در سیال پایه، اندازه نانوذره، دمای نانوسیال، سیال پایه و عوامل خارجی (از قبیل نیروی مغناطیس، همگن‌سازی و ...) بر خواص ترموفیزیکی نانوسیال موثر خواهد بود [۷].

برای اندازه‌گیری خواص ترموفیزیکی نانوسیالات، باید آزمایشاتی برای تغییر هر یک از پارامترهای فوق انجام شود، که هزینه‌بر و زمان‌بر است. یکی از بهترین روش‌ها برای برآورد پارامترها مدل‌سازی کامپیوتری است. روش‌های مدل‌سازی به دلیل هزینه کم و سرعت بالا نسبت به روش‌های آزمایشگاهی، توجهات بسیاری را به خود معطوف ساخته است. لذا، بسیاری از محققان عملکرد رگرسیون غیرخطی و هوش مصنوعی را در برآورد پارامترهای مختلف بررسی کرده‌اند [۸]. شبکه‌های عصبی مصنوعی^۱ در الگوریتم‌های مختلف به توسعه داده‌های تجربی کمک می‌کنند. شبکه‌های عصبی کانولوشن^۲، شبکه‌های حافظه کوتاه‌مدت طولانی^۳، شبکه‌های عصبی مکرر^۴، شبکه‌های تابع پایه شعاعی^۵، پرسپترون‌های چندلایه^۶، نقشه‌های خودسازماندهی^۷، شبکه‌های عصبی بازگشتی^۸، شبکه‌های متخاصم مولد^۹، شبکه‌های تابع پایه شعاعی^{۱۰}، پرسپترون‌های چندلایه^{۱۱}، شبکه‌های باور عمیق^{۱۲}، ماشین‌های محدود بولتزمن^{۱۳} از این قبیل به شمار می‌آید [۹-۱۱].

میرعبداله لواسانی و همکاران [۱۲] در تحقیقی به مدل‌سازی و پیش‌بینی رسانایی گرمایی نانوسیال گرافن به کمک شبکه عصبی مصنوعی چند لایه پرسپترون پرداختند. پارامترهای دمای نانوسیال، کسر حجمی و رسانایی گرمایی نانو ذره به عنوان ورودی شبکه در نظر گرفته شد. با اطلاعات مربوط به اندازه‌گیری‌های تجربی محققین قبلی در مورد رسانایی گرمایی نانوسیال گرافن در دمای ۲۵ تا ۵۰ درجه سلسیوس و در کسر حجمی ۰/۰۰۵ تا ۰/۰۵۶ تست عملکرد شبکه انجام شد. جهت بررسی میزان دقت مدل در پیش‌بینی رسانایی گرمایی نانوسیال، از شاخص‌های جذر میانگین مربعات خطا، ضریب تشخیص و درصد میانگین مطلق خطا استفاده شد که این مقادیر به ترتیب ۰/۰۴، ۰/۹۹ و ۰/۲۶ درصد است.

قهدریجانی و همکاران [۱۳] تأثیر نانوسیال بر عملکرد انتقال گرما و افت فشار یک مبدل را مورد بررسی قرار دادند. ایشان از نانوسیالات آبی Al_2O_3 و CuO به عنوان سیال خنک‌کاری استفاده کردند. در این تحقیق از شبکه‌های عصبی مصنوعی برای

¹ Artificial Neural Network (ANN)

² Convolutional Neural Networks (CNNs)

³ Long Short Term Memory Networks (LSTMs)

⁴ Recurrent Neural Networks (RNNs)

⁵ Radial Basis Function Networks (RBFNs)

⁶ Multilayer Perceptrons (MLPs)

⁷ Self Organizing Maps (SOMs)

⁸ Recurrent Neural Networks (RNNs)

⁹ Generative Adversarial Networks (GANs)

¹⁰ Radial Basis Function Networks (RBFNs)

¹¹ Multilayer Perceptrons (MLPs)

¹² Deep Belief Networks (DBNs)

¹³ Restricted Boltzmann Machines (RBMs)

پیش‌بینی عملکرد مبدل، پیش‌بینی انتقال گرمای جابه‌جایی و افت فشار در نانوسیالات استفاده شد. از داده‌های تجربی برای ایجاد مدل شبکه عصبی استفاده شد. نتایج نشان داد که ساختار بهینه برای پیش‌بینی ضریب انتقال حرارت جابه‌جایی، شبکه عصبی با یک لایه مخفی و ۱۰ نورون است، که با الگوریتم LM^1 برای آموزش مدل استفاده شد. مقادیر پیش‌بینی افت فشار توسط شبکه MLP با دو لایه پنهان و ۶ نورون در هر لایه از الگوریتم آموزش LM استفاده می‌کند. نتایج، نشان‌دهنده همبستگی مطلوب بین مقادیر پیش‌بینی شده توسط شبکه عصبی و نتایج آزمایشگاهی بود.

مداح و همکاران [۱۴] در تحقیقی کارایی انتقال حرارت نانوسیال آب و اکسید آهن در مبدل حرارتی دو لوله‌ای را به صورت تجربی بررسی کردند. آزمایشات تحت جریان آرام و آشفته برای رینولدز در محدوده ۱۰۰۰ تا ۶۰۰۰ انجام شد و غلظت نانوسیال ۰/۰۱، ۰/۰۲ و ۰/۰۳ درصد وزنی بود. به منظور مدل‌سازی و پیش‌بینی بازده انتقال حرارت، از شبکه عصبی مصنوعی استفاده شد. دمای سیال گرم (نانوسیال)، دمای سیال سرد (آب)، دبی جرمی سیال داغ (نانوسیال)، دبی جرمی سیال سرد (آب)، غلظت نانوسیال و نسبت پیچش لوله‌ها به عنوان ورودی شبکه عصبی استفاده شدند. خروجی شبکه عصبی نیز میزان انتقال حرارت بود. نتایج آزمایشگاهی نشان داد، که راندمان انتقال حرارت در حضور ۰/۰۳ درصد وزنی نانوسیال ۳۰ درصد افزایش یافت. به منظور توسعه نتایج مدل‌سازی خواص نانوسیال صورت گرفت. پیاده‌سازی ساختارهای مختلف شبکه عصبی با تعداد مختلف نورون در لایه میانی نشان داد که آرایش ۱-۱۰-۶ با ضریب همبستگی 0.99181^2 و خطای جذر میانگین مربع 0.001621^3 به عنوان آرایش مطلوب پیشنهاد شد.

داده‌های تجربی ضریب انتقال حرارت برای نانوسیالات آبی MgO با استفاده از شبکه عصبی مصنوعی برای ۴ نوع نانوذره با قطر ۲۰، ۴۰، ۵۰ و ۶۰ نانومتر در ۴ کسر حجم ۰/۵، ۱، ۱/۵ و ۲ توسط آرائی و همکاران [۱۵] توسعه داده شد. برای انجام این تحقیق، ابتدا داده‌های تجربی به ازای اندازه‌های مختلف و غلظت‌های مختلف نانوذرات به صورت آزمایشگاهی اندازه‌گیری شدند. سپس بر اساس سه پارامتر مؤثر، یعنی کسر جرمی نانوذرات، اندازه ذرات و عدد رینولدز به عنوان ورودی مدل تخمین‌گر استفاده شدند. سپس یک شبکه پرسپترون چند لایه پیشرو برای مدل‌سازی داده‌ها استفاده شد. این شبکه دارای ۳ نورون در لایه اول و ۵ نورون در لایه دوم بود. ضریب رگرسیون^۴ برای مدل‌سازی داده‌های تجربی برابر با ۰/۹۹۷ بود.

زری و همکاران [۱۶] در تحقیقی به پیش‌بینی ضریب انتقال حرارت جوش استخری برای نانومبردهای مختلف با استفاده از شبکه‌های عصبی مصنوعی پرداختند. در این تحقیق اثرات شار حرارتی، فشار اشباع، هدایت حرارتی نانوذرات، هدایت حرارتی سیال پایه، غلظت نانوذرات، اندازه نانوذرات بر روی ضریب انتقال حرارت نانوسیالات در طیف وسیعی از شرایط عملیاتی بررسی شد. شبکه عصبی دارای یک لایه پنهان با ۱۹ نورون با استفاده از توابع فعال‌سازی $tansig$ و $purelin$ در لایه‌های مخفی به عنوان مدلی با بهترین عملکرد معرفی شد. نتایج نشان داد، که مدل حاضر می‌تواند به طور دقیق ضریب انتقال حرارت نانوسیالات را با ضریب همبستگی ۰/۹۹۴۸ و میانگین خطای مربع کلی ۰/۰۱۵۲۹ تخمین بزند.

آلاد و همکاران [۱۷] در تحقیقی ضریب انتقال حرارت ویژه نانوسیالات CuO آب را با استفاده از رگرسیون بردار پشتیبان و شبکه عصبی مصنوعی مدل‌سازی کردند. بخش حجمی نانوذرات CuO در نظر گرفته شده بین ۰/۴ تا ۲ درصد حجمی متغیر بود، در حالی که محدوده دما در بازه ۲۹۳ تا ۳۳۸ درجه کلوین بود. نتایج به دست آمده نشان داد، که مدل رگرسیون بردار پشتیبان در مقایسه با مدل ANN دقت بیشتری از خود نشان داد. با این حال، هر دو مدل رگرسیون بردار پشتیبان و مدل شبکه عصبی مصنوعی پیش‌بینی بهتری را برای ظرفیت گرمایی ویژه نانوسیال‌های CuO / آب در مقایسه با مدل‌های نظری موجود ارائه داد. در این تحقیق، یک مدل جامع برای برآورد و توسعه نتایج خواص ترموفیزیکی نانوسیالات ارائه شد. بر همین اساس داده‌های تجربی حاصل از آزمایشات تجربی و داده‌های کتابخانه‌ای سایر مطالعات به عنوان ورودی مدل استفاده شد. جنبه جدید تحقیق حاضر، پیاده‌سازی مدلی است که بدون نیاز به انجام تست‌های آزمایشگاهی بتواند خواص ترموفیزیکی نانوسیالات را براساس

¹ Levenberg -Marquardt

² Correlation

³ Root Mean Squard Error (RMSE)

⁴ Regression

اطلاعات مربوط به نانوذره و سیال پایه تخمین بزند. در این مقاله هدف، بررسی مدل‌های شبکه عصبی با تابع‌های فعال‌ساز Trainlm، Trainbr و Trainscg و مدل شبکه حافظه کوتاه‌مدت طولانی و رگرسیون بردار پشتیبان برای تخمین ضریب هدایت حرارتی نانوسیالات بر پایه آب با نانوذرات Fe_2O_3 ، TiO_2 ، CuO ، Al_2O_3 است، که بر اساس دقت و کارایی هریک مورد ارزیابی قرار بگیرد. لذا تاکنون این روش در هیچ تحقیق مشابهی انجام نشده است.

۲- روش تحقیق

۲-۱- داده‌های آزمایشگاهی

به منظور ساخت یک نانوسیال نیاز به یک سیال پایه و نانوذرات به‌عنوان افزودنی به سیال پایه می‌باشد. در این پژوهش آب به‌عنوان سیال پایه انتخاب شد. همچنین از اکسید تیتانیوم (TiO_2)، اکسید آهن (Fe_2O_3)، اکسید آلومینیوم (Al_2O_3) و اکسید مس (CuO) در غلظت‌های حجمی ۰/۰۲ تا ۲ درصد استفاده شد و در دماهای مختلف کار داده‌برداری صورت گرفت. یکی از عوامل بسیار مؤثر بر روی خواص نانوسیالات، میزان پراکندگی و پایداری نانوذرات درون سیال پایه است. اگر پراکندگی ذرات درون سیال پایه یکنواخت نباشد، ممکن است انباشتگی یا آگلومره^۱ شدن و رسوب نانوذرات اتفاق بیفتد، در این صورت ذرات درشت ایجاد شده، همانند مواد ناخالص، موجب آسیب دیدن سطوح اصطکاکی و خطا در نتایج می‌شود، برای رفع این مشکل از حمام آلتراسونیک استفاده شد. دستگاه اولتراسونیک حمامی به کار رفته در این تحقیق برای آماده‌سازی نمونه‌ها از مدل P120h، Elmasonic بود.

اندازه‌گیری ضریب هدایت حرارتی با استفاده از دستگاه KD2 که ساخت شرکت Decagon Devices آمریکا انجام شد. این دستگاه از روش سیم داغ حالت ناپایا استفاده می‌کند.

برای محاسبه ضریب انتقال حرارت نانوسیال با این دستگاه از روابط (۱) تا (۵) استفاده می‌شود [۱۸]. اگر مقدار ثابتی از گرما به هیتز بدون وزنی در دوره زمانی مشخص t_1 داده شود، پاسخ دمایی به‌صورت رابطه (۱) نوشته می‌شود:

$$\Delta T = -\frac{q}{4\pi\lambda} Ei\left(\frac{-r^2}{4Dt}\right), 0 < t \leq t_1 \quad (1)$$

$$Ei(x) = \int_{-\infty}^x \frac{e^t}{t} dt \quad (2)$$

محاسبه تغییر دما بعد از این که شار گرما قطع شد، به‌صورت رابطه (۳) می‌باشد:

$$\Delta T = -\frac{q}{4\pi\lambda} \left[Ei\left(\frac{-r^2}{4Dt}\right) + Ei\left(\frac{-r^2}{4D(t-t_1)}\right) \right] \quad (3)$$

$$\Delta T = -\frac{q}{4\pi\lambda} \int_{r^2}^{\infty} u^{-1} \exp(-u) \exp\left[-\frac{a}{r^2}\right] \left(\frac{2au}{r}\right) \operatorname{erf}\left(\frac{b}{r}\sqrt{u}\right) du \quad (4)$$

اغلب آزمایش‌ها تحت دمای ثابت روی نمی‌دهد. لذا فرض می‌شود که افزایش دمای محیط با زمان، خطی است و از یک پارامتر تنظیم شونده دیگر استفاده می‌شود. این کار خطاها را به‌طور قابل ملاحظه‌ای کاهش داد. برای یک منبع استوانه‌ای گرم شده با شعاع a و طول $2b$ که دما در مرکز آن اندازه گرفته می‌شود، افزایش دما در بازه $0 < t < t_1$ به‌صورت رابطه (۴) است:

$$\Delta T = -\frac{q}{4\pi\lambda} \int_{\frac{r^2}{4Dt}}^{\frac{r^2}{4D(t-t_1)}} u^{-1} \exp(-u) \exp\left[-\frac{a}{r^2}\right] \left(\frac{2au}{r}\right) \operatorname{erf}\left(\frac{b}{r}\sqrt{u}\right) du \quad (5)$$

^۱ Agglomeration

۲-۲- داده‌های کتابخانه‌ای

برای تأمین داده‌های بیش‌تر برای ورودی مدل از داده‌های پژوهش سایر محققین استفاده شده است. در جدول (۱) این داده‌ها مشاهده می‌شود.

جدول ۱: مطالعات تجربی صورت گرفته

ردیف	محقق	سیال پایه	نانوذرات
۱	آشوتوش و همکار [۱۰]	آب	CuO/ Al ₂ O ₃
۲	یاکوب و همکار [۲۱]	آب	Fe ₂ O ₃
۳	فیلیپ و همکار [۲۲]	آب	Fe ₃ O ₄
۴	وانگ و همکاران [۲۳]	آب	Fe ₃ O ₄ /CNT
۵	رشیدی و همکاران [۲۴]	آب/ اتیلن گلیکول	Al ₂ O ₃
۶	لی و همکاران [۲۵]	آب	TiO ₂

۲-۳- استانداردسازی داده‌ها:


با توجه به این‌که محدوده غلظت، اندازه و سایر مشخصات ورودی به مدل هوش مصنوعی یکسان نیست. لذا عملیات نرمال‌سازی داده‌ها انجام گردید. روش‌های مختلفی برای استانداردسازی وجود دارد. در تمامی این روش‌ها، داده‌ها به‌گونه‌ای تبدیل می‌شوند که شرایط موردنظر را داشته باشند. یکی از مهم‌ترین روش‌های استانداردسازی، تبدیل داده‌ها به مجموعه داده جدیدی است که میانگین و واریانس به‌ترتیب صفر و واحد هستند. برای این منظور از رابطه زیر استفاده می‌شود:

$$\tilde{x}_i = \frac{x_i - \bar{x}}{\sigma} \quad (i = 1, 2, \dots, N) \quad (۶)$$

۲-۳- مدل‌سازی


مدل‌های هوش مصنوعی به ازای ورودی‌های مشخص، یک خروجی یا چندین خروجی را برای ما تخمین می‌زنند. در این تحقیق ورودی‌های مدل هوش مصنوعی شامل نوع نانوذره، غلظت نانوذره، دمای نانوسیال، اندازه نانوذره در سیال پایه، ضریب انتقال حرارت نانوذره، ضریب انتقال حرارت سیال و خروجی مدل شامل ضریب انتقال حرارت نانوسیال خواهد بود. در این تحقیق از چندین مدل مختلف هوش مصنوعی جهت تخمین ضریب انتقال حرارت نانوسیال استفاده شد، که شامل شبکه عصبی مصنوعی، رگرسیون بردار پشتیبان و LSTM هستند. فلوچارت کلی تمامی این مدل‌ها مشابه شکل (۱) است. شبکه‌ی LSTM نوع خاصی از شبکه‌ی RNN است که مشکل حافظه‌ی بلندمدت شبکه‌ی RNN را حل می‌کند. شبکه‌ی LSTM سازوکارهایی داخلی به اسم گیت^۱ دارد. این گیت‌ها جریان اطلاعات را کنترل می‌کنند و در عین حال توالی داده‌ها را در اولویت قرار می‌دهد و حفظ و یا حذف داده‌ها را میسر می‌کند. به این شکل، شبکه‌ی اطلاعات مهم را در طول زنجیره‌ی توالی عبور می‌دهد تا خروجی مدنظر حاصل شود.

^۱ Gate



شکل ۱: فلوچارت مدل تخمین ضریب انتقال حرارت نانوسیالات

در شکل (۲)، توپولوژی شبکه عصبی مورد استفاده نشان داده شده است. از شبکه LSTM جهت تخمین ضریب انتقال حرارت نانوسیالات استفاده شد. از ۲۵۶ داده تجربی برای ورودی مدل استفاده شد که از این تعداد ۳۰ درصد از دیتا موجود به آزمون اختصاص داده شد و ۷۰ درصد دیتاها نیز به آموزش داده تعلق گرفت.



شکل ۲: معماری مدل شبکه‌های حافظه کوتاه مدت طولانی


به منظور ارزیابی و تعیین دقت مدل‌های استفاده شده جهت تخمین هدایت حرارتی نانوسیال، از شاخص‌های مختلفی استفاده شد که شامل ضریب رگرسیون R^2 ، خطای جذر میانگین مربعات RMSE و درصد میانگین مطلق خطا MAPE هستند. هر قدر مقدار ضریب رگرسیون به عدد یک نزدیک‌تر باشد و مقادیر RMSE و MAPE به صفر نزدیک‌تر باشند، کارایی مدل مورد نظر نیز بهتر است در روابط (۷) تا (۹) فرمول محاسبه شاخص‌های ارزیابی ارائه شده است [۲۶].

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_p - x_o)^2}{\sum_{i=1}^n (x_o - \bar{x}_o)^2} \quad (۷)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (x_p - x_o)^2}{n}} \quad (۸)$$

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{x_o - x_p}{x_o} \right|}{n} \times 100 \quad (۹)$$


که در آن X_p و X_o به ترتیب مقدار داده‌های واقعی و پیش‌بینی شده هستند. در قسمت پیوست این مقاله قسمتی از کد متلب مربوط به LSTM ارائه گردیده است. یک شبکه عصبی مصنوعی، از سه لایه ورودی، خروجی و پردازش‌گر تشکیل می‌شود. هر لایه شامل گروهی از نورون‌ها است که عموماً با کلیه نورون‌های لایه‌های دیگر در ارتباط هستند ولی نورون‌های هر لایه با سایر نورون‌های همان لایه، ارتباطی ندارند. لایه ورودی^۱ شامل نورون‌هایی است که کاری به جز دریافت ورودی‌ها و منتقل کردن آن‌ها به دیگر لایه‌ها انجام نمی‌دهند. لایه خروجی ویژگی نهایی را پیش‌بینی می‌کن. n در میان لایه ورودی و خروجی لایه‌های پنهان بسته به نوع مدل قرار دارند. لایه‌های پنهان شامل محدوده وسیعی از نورون‌ها می‌شوند. نورون‌ها در لایه پنهان، تبدیل‌ها را پیش از انتقال ورودی‌ها روی آن‌ها اعمال می‌کنند. شبکه عصبی مصنوعی مورد مطالعه لایه ورودی شامل پنج عصب، در لایه پنهان این مدل از ۲۰ عصب استفاده می‌شود و لایه خروجی شامل یک عصب است. در شکل (۳)، معماری شبکه عصبی مورد استفاده نشان داده شده است. به منظور آموزش مدل شبکه عصبی از سه تابع فعال‌سازی Trainlm، Trainbr و trainscg استفاده شد که نتایج تخمین ضریب انتقال حرارت هدایتی نانوسیالات را به عنوان خروجی نشان می‌دهد.



شکل ۳: معماری شبکه عصبی استفاده شده در این تحقیق

معماری مدل رگرسیون بردار پشتیبان نیز در شکل (۴) نشان داده شده است. در مدل رگرسیون بردار پشتیبان، به ازای کرنل‌های مختلف (کرنل خطی، پایه شعاعی گوسی و چند جمله‌ای)، دقت مدل تغییر خواهد کرد، لذا در این مقاله فقط کرنل خطی بررسی شد.


^۱ Input layer




شکل ۴: ساختار رگرسیون بردار پشتیبان

۳- نتایج

در شکل (۵) نتایج ضریب همبستگی بین مقادیر واقعی برای ضریب انتقال حرارت نانوسیال با مدل ANN-Trainlm مشاهده می‌شود. شکل (۶) اختصاص به نمودار مقایسه ۲۶۸ داده تجربی و مدل‌سازی برای ضریب انتقال حرارت هدایتی (K) دارد. خط افقی نمودار بیانگر تعداد داده‌ها است و خط عمودی ضریب انتقال حرارت هدایتی را نشان می‌دهد. خط آبی‌رنگ مختص داده‌های واقعی و خط سبز پیش‌بینی ANN را نشان می‌دهد. مقادیر R^2 ، RSME، MAPPE برای این مدل به ترتیب ۰/۹۱، ۰/۰۸۱ و ۰/۷ می‌باشد.




شکل ۵: نتایج ضریب همبستگی بین مقادیر واقعی برای ضریب انتقال حرارت هدایتی نانوسیال با مدل ANN-Trainlm




شکل ۶: مقایسه‌ای بین مقادیر واقعی و مقادیر ANN برای ضریب انتقال حرارت هدایتی نانوسیال با تابع Trainlm

در شکل (۷) نتایج ضریب همبستگی بین مقادیر واقعی برای ضریب انتقال حرارت نانوسیال با مدل ANN-Trainbr مشاهده می‌شود. شکل (۸) اختصاص به نمودار مقایسه ۲۶۸ داده تجربی و مدل‌سازی برای ضریب انتقال حرارت هدایتی (K) دارد. خط افقی نمودار بیانگر تعداد داده‌ها است و خط عمودی ضریب انتقال حرارت هدایتی را نشان می‌دهد. خط آبی رنگ مختص داده‌های واقعی و خط سبز پیش‌بینی ANN را نشان می‌دهد. مقادیر R^2 ، RSME، MAPPE برای این مدل به ترتیب ۰/۹۵۶۴، ۰/۰۵۴۳ و ۰/۴۹۰۶ می‌باشد.




شکل ۷: نتایج همبستگی بین مقادیر واقعی برای تخمین ضریب انتقال حرارت نانوسیال با مدل ANN-Trainbr




شکل ۸: مقایسه بین نتایج مقادیر واقعی و تخمین ضریب انتقال حرارت هدایتی نانوسیال با مدل ANN-Trainbr

در شکل (۹) نتایج ضریب همبستگی بین مقادیر واقعی برای ضریب انتقال حرارت نانوسیال با مدل ANN-Trainscg مشاهده می‌شود. شکل (۱۰) اختصاص به نمودار مقایسه ۲۶۸ داده تجربی و مدل‌سازی برای ضریب انتقال حرارت هدایتی (K) دارد. خط افقی نمودار بیانگر تعداد داده‌ها است و خط عمودی ضریب انتقال حرارت هدایتی را نشان می‌دهد. خط آبی‌رنگ مختص داده‌های واقعی و خط سبز پیش‌بینی ANN را نشان می‌دهد. مقادیر R^2 ، RSME، MAPPE برای این مدل به ترتیب ۰/۷۸۴۱، ۰/۱۱۹۵ و ۱/۰۴۶ می‌باشد. نتایج به دست آمده این قسمت اصلاً مصلوب نمی‌باشد.




شکل ۹: نتایج همبستگی بین مقادیر واقعی برای ضریب انتقال حرارت نانوسیال با مدل ANN- Trainscg




شکل ۱۰: مقایسه بین نتایج مقادیر واقعی و تخمین ضریب انتقال حرارت هدایتی نانوسیال با مدل ANN- Trainscg

در شکل (۱۱) نتایج ضریب همبستگی بین مقادیر واقعی برای ضریب انتقال حرارت نانوسیال با رگرسیون بردار پشتیبان (SVR) مشاهده می‌شود.

شکل (۱۲) اختصاص به نمودار مقایسه ۲۶۸ داده تجربی و مدل سازی برای ضریب انتقال حرارت هدایتی (K) دارد. خط افقی نمودار بیانگر تعداد داده‌ها است و خط عمودی ضریب انتقال حرارت هدایتی را نشان می‌دهد. نقاط سبزرنگ مختص داده‌های واقعی و نقاط قرمز رنگ پیش‌بینی SVR را نشان می‌دهد. مقادیر R^2 ، RSME، MAPPE برای این مدل نشان داده شده است، که مقدار هریک به ترتیب ۰/۸۸۷، ۰/۰۹۳۸ و ۰/۰۵۹۱ می‌باشد.




شکل ۱۱: نتایج ضریب همبستگی بین مقادیر واقعی برای ضریب انتقال حرارت هدایتی نانوسیال با SVR



شکل ۱۲: مقایسه بین نتایج مقادیر واقعی و تخمین ضریب انتقال حرارت هدایتی نانوسیال با SVR

در شکل (۱۳) نتایج ضریب همبستگی بین مقادیر واقعی برای ضریب انتقال حرارت نانوسیال با LSTM مشاهده می‌شود. مقادیر R^2 ، RSME، MAPPE برای این مدل به ترتیب ۰/۹۷۶۴، ۰/۰۳۱۳ و ۰/۰۸۱۹ می‌باشد.



شکل ۱۳: نتایج ضریب همبستگی بین مقادیر واقعی برای ضریب انتقال حرارت هدایتی نانوسیال با LSTM

در جدول (۲) تنها ۱۰ سری از داده‌های مربوط به تخمین K را که با مدل LSTM محاسبه شده است، مشاهده می‌شود

جدول ۲: نمونه داده‌های تخمین زده شده توسط LSTM

K	Knp	ρ	μ	دما (°C)	غلظت نانو ذره (%)
۰/۸۱	۰/۸	۳/۰۱	۲	۵۵	۰/۲۴
۰/۹	۱/۰۹	۴/۸	۱۲	۲۵	۱/۲
۰/۲۵	۰/۷۶	۴/۳۶	۳۲	۷۳	۰/۲
۰/۲۴	۱/۰۱	۳/۴	۱۲	۳۶	۱/۲
۰/۳۷	۱	۴/۱۲	۲۸	۴۳	۰/۵۵
۰/۳۱	۱/۰۵	۴/۰۸	۲۲	۴۰	۰/۷
۰/۲۲	۱/۱	۳/۶	۱۲	۳۵	۰/۶
۰/۱۲	۱/۰۴	۳/۴۹	۱۸	۳۸	۰/۴۵
۰/۲۳	۰/۶۱	۴/۲۲	۲۸	۷۶	۰/۰۵
۰/۲۹	۰/۳۶	۴/۱۷	۱۳	۱۴	۰/۸۵

در جدول (۳) نتایج تحقیق حاضر با ادبیات پیشین در این حوزه مقایسه شد. مدل شبکه LSTM برای تخمین و محاسبه ضریب انتقال حرارت هدایتی از دقت مطلوبی برخوردار است.

جدول ۳: مقایسه نتایج تحقیقات گذشته با تحقیق حاضر

مرجع	روش پیشنهادی	R2	RMSE	MAPE
لواسانی و همکاران [۱۲]	شبکه عصبی مصنوعی چند لایه پرسپترون	۰/۹۹	۰/۰۴	۰/۲۶
مداح و همکاران [۱۴]	شبکه عصبی مصنوعی	۰/۹۹۱۶	۰/۰۰۱۶	--
زری و همکاران [۱۶]	شبکه عصبی مصنوعی	۰/۹۹۴۸	۰/۰۱۵۲۹	--
آرانی و همکاران [۱۵]	شبکه عصبی مصنوعی چند لایه پرسپترون	۰/۹۹۷	--	--
تحقیق حاضر	شبکه LSTM	۰/۹۷۶۴	۰/۰۳۱۳	۰/۰۸۱۹

۴- نتیجه‌گیری

در تحقیق حاضر، چند رویکرد تخمین هدایت حرارتی برای نانوسیال‌های مبتنی بر اکسید فلزی به‌صورت تعمیم یافته ایجاد شده است. در مجموع ۲۶۸ سری داده تجربی به‌عنوان ورودی مدل‌ها تعریف شد، که ۷۰ درصد صرف آموزش و ۳۰ درصد برای آزمون استفاده شد. با پنج حالت مختلف شامل شبکه عصبی مصنوعی با تابع فعال‌سازی ANN-Trainbr، ANN-Trainlm، ANN-Trainscg، شبکه حافظه کوتاه‌مدت طولانی (LSTM) و رگرسیون بردار پشتیبان (RVS) مدل‌سازی واکاوی شد. نتایج نشان داد، LSTM تطابق بسیار مطلوب‌تری با داده‌های تجربی دارد، زیرا مقادیر ارزیابی شامل ضریب رگرسیون (R^2)، خطای جذر میانگین مربعات (RSME) و درصد میانگین مطلق خطا (MAPE) به‌ترتیب مقادیر ۰/۹۷۶۴، ۰/۰۳۱۳ و ۰/۰۸۱۹ را به خود اختصاص دادند و در نقطه مقابل شبکه عصبی مصنوعی با تابع فعال‌سازی Trainbr با مقادیر ارزیابی آماری R^2 ، RSME، MAPPE به‌ترتیب ۰/۷۸۴۱، ۰/۱۱۹۵ و ۱/۰۴۶ اصلاً قابل قبول نمی‌باشد. هم‌چنین نتایج حاصل از مدل‌سازی LMST با سایر

مدل‌های ادبیات پیشین مقایسه شد و می‌توان نتیجه گرفت مدل حاضر از دقت کافی برای تخمین ضریب هدایت حرارتی برخوردار است.

فهرست علائم

علائم انگلیسی	
M	جرم، kg
T	دما، °C
L	طول، m
A	مساحت، m ²
K	ضریب رسانش حرارتی، (W.m°C ⁻¹)
Cp	گرمای ویژه در فشار ثابت، (J.kg.°C ⁻¹)
علائم یونانی	
ρ	چگالی، kg/m ³
μ	ویسکوزیته، mPa.s

مراجع

- [1] H., Babar, H. M., Ali, Towards hybrid nanofluids: preparation, thermophysical properties, applications, and challenges, Journal of Molecular Liquids, 281 (2019), 598-633.
- [2] I., Tlili, Impact of thermal conductivity on the thermophysical properties and rheological behavior of nanofluid and hybrid nanofluid, Mathematical Sciences, (2021), 1-9.
- [3] Z., Said, L. S., Sundar, A. K., Tiwari, H. M., Ali, M., Sheikholeslami, E., Bellos, H., Babar, Recent advances on the fundamental physical phenomena behind stability, dynamic motion, thermophysical properties, heat transport, applications, and challenges of nanofluids, Physics Reports, (2021).
- [4] D., Dey, P., Kumar, S., Samantaray, A review of nanofluid preparation, stability, and thermophysical properties. Heat Transfer—Asian Research, 46(8) (2017), 1413-1442.
- [5] A., Kapicioğlu, H., Esen, Experimental investigation on using Al₂O₃/ethylene glycol-water nanofluid in different types of horizontal ground heat exchangers, Applied Thermal Engineering, 165 (2020), 114559.
- [6] H., Ahmad, K., Al-Khaled, A., Hammad, Experimental investigation for automotive radiator heat transfer performance with ZnO–Al₂O₃/water-based hybrid nanoparticles: An improved thermal model, International Journal of Modern Physics B, 37(05) (2023), 2350050.
- [7] Rahul Jibhakate, Nilesh Nirwan, Yogesh Nandanwar, (2023), Thermal analysis of hybrid nanofluid flowing inside the automobile radiator, <https://doi.org/10.1016/j.matpr.2023.06.200>
- [8] M. H., Esfe, M. H., Kamyab, D., Toghraie, Statistical review of studies on the estimation of thermophysical properties of nanofluids using artificial neural network (ANN), Powder technology, (2022), 117210.
- [9] C., Kamsuwan, X., Wang, P., Piumsomboon, Artificial neural network prediction models for nanofluid properties and their applications with heat exchanger design and rating simulation, International Journal of Thermal Sciences, 184, (2023), 107995.
- [10] A., Pare, S., K., Ghosh., A unique thermal conductivity model (ANN) for nanofluid based on experimental study, Powder Technology, 377 (2021), 429-438

- [11] M., Hemmat Esfe, M. H., Kamyab, D., Toghraie, Statistical review of studies on the estimation of thermophysical properties of nanofluids using artificial neural network (ANN), Powder Technology, 400 (2022), 117210
- [12] S., Khosrojerdi, A., MirAbdollah Lavasani, M., Vakili, Predicting Thermal Conductivity of Graphene Nanofluid with Artificial Neural Networks Multilayer Perceptron, Mechanical Engineering of Tabriz University, 47(3) (2017), 319-323.
- [13] A. M., Ghahdarijani, F., Hormozi, A. H., Asl, Convective heat transfer and pressure drop study on nanofluids in double-walled reactor by developing an optimal multilayer perceptron artificial neural network, International Communications in Heat and Mass Transfer, 84 (2017), 11-19.
- [14] H., Maddah, N., Ghasemi, Experimental evaluation of heat transfer efficiency of nanofluid in a double pipe heat exchanger and prediction of experimental results using artificial neural networks, Heat and Mass Transfer, 53(12) (2017), 3459-3472.
- [15] A. A. A., Arani, A., Alirezaie, M. H., Kamyab, S. M., Motalebi, Statistical analysis of enriched water heat transfer with various sizes of MgO nanoparticles using artificial neural networks modeling. Physica A: Statistical Mechanics and its Applications, 554 (2020), 123950.
- [16] M., Zarei, H., Ansari, P., Keshavarz, M., Zerafat, Prediction of pool boiling heat transfer coefficient for various nano-refrigerants utilizing artificial neural networks. Journal of Thermal Analysis and Calorimetry, 139(6) (2020), 3757-3768.
- [17] I. O., Alade, M. A., Abd Rahman, Z., Abbas, Y., Yaakob, T. A., Saleh, Application of support vector regression and artificial neural network for prediction of specific heat capacity of aqueous nanofluids of copper oxide. Solar Energy, 197 (2020), 485-490.
- [18] N., Chavda, Effect of nanofluid on heat transfer characteristics of double pipe heat exchanger: part-II: effect of copper oxide nanofluid, International Journal of Research in Engineering and Technology, 4(4) 2015, 688-697.
- [19] I., Nurdin, I. I., Yaacob, M. R., Johan, Enhancement of thermal conductivity and kinematic viscosity in magnetically controllable maghemite ($\gamma\text{-Fe}_2\text{O}_3$) nanofluids, Experimental Thermal and Fluid Science, 77 (2016), 265-271.
- [20] S., Vinod, J., Philip, Experimental evidence for the significant role of initial cluster size and liquid confinement on thermo-physical properties of magnetic nanofluids under applied magnetic field, Journal of Molecular Liquids, 257 (2018), 1-11.
- [21] L., Shi, Y., He, Y., Hu, X., Wang, Thermophysical properties of $\text{Fe}_3\text{O}_4@ \text{CNT}$ nanofluid and controllable heat transfer performance under magnetic field, Energy Conversion and Management, 177 (2018), 249-257.
- [22] M.M., Rashidi, M., Alhuyi Nazari, I., Mahariq, N., Ali., Modeling and Sensitivity Analysis of Thermal Conductivity of Ethylene Glycol-Water Based Nanofluids with Alumina Nanoparticles, (2023), <https://doi.org/10.1007/s40799-022-00572-7>
- [23] W., Cui, Z., Cao, X., Li, L., Lu, Experimental investigation and artificial intelligent estimation of thermal conductivity of nanofluids with different nanoparticles shapes, Powder Technology, 398 (2022), 117078
- [24] M., Vijh, D., Chandola, V. A., Tikkiwal, A., Kumar, Stock closing price prediction using machine learning techniques, Procedia computer science, 167 (2020), 599-606.

پیوست:

```
%%
clc
close all
%Standardize Data
%For a better fit and to prevent the training from diverging,
%standardize the training data to have zero mean and unit variance.
%Standardize the test data using the same parameters as the training data.

%
Data=Input(:,1);
mu = mean(Data);
```

```

sig = std(Data);
data = (Data - mu) / sig;

In=Input';
data=data';
clear IN Data

%Data Prepration
numTimeStepsTrain = floor(0.9*numel(data));
XTrain = In(1:numTimeStepsTrain);
YTrain = data(2:numTimeStepsTrain+1);
XTest = In(numTimeStepsTrain+1:end-1);
YTest = data(numTimeStepsTrain+2:end);
%%
%Define LSTM Network Architecture
%Create an LSTM regression network.
%Specify the LSTM layer to have 200 hidden units.
inputSize = 1;
numResponses = 1;
numHiddenUnits = 50;
%%
layers = [ ...
    sequenceInputLayer(inputSize)
    lstmLayer(numHiddenUnits)
    fullyConnectedLayer(numResponses)
    regressionLayer];
%bidirectional
layers = [ ...
    sequenceInputLayer(inputSize)
    bilstmLayer(numHiddenUnits)
    fullyConnectedLayer(numResponses)
    regressionLayer]
%%
%Specify the training options.
%Set the solver to 'adam' and train for 100 epochs.
%To prevent the gradients from exploding, set the gradient threshold to 1.
%Specify the initial learn rate 0.005, and drop the learn rate after 125 epochs by multiplying by a factor of 0.2.
opts = trainingOptions('adam', ...
    'MaxEpochs',1000, ...
    'GradientThreshold',1, ...
    'InitialLearnRate',0.005, ...
    'LearnRateSchedule','piecewise', ...
    'LearnRateDropPeriod',125, ...
    'LearnRateDropFactor',0.2, ...
    'Verbose',0, ...
    'Plots','training-progress');
%Train LSTM Network
%Train the LSTM network with the specified training options by using trainNetwork.
net = trainNetwork(XTrain,YTrain,layers,opts);

%%
%Forecast Future Time Steps
net = predictAndUpdateState(net,XTrain);
[net,YPred] = predictAndUpdateState(net,YTrain(end));

numTimeStepsTest = numel(XTest);
for i = 2:numTimeStepsTest
    [net,YPred(1,i)] = predictAndUpdateState(net,YPred(i-1));
end
%Unstandardize the predictions using mu and sig calculated earlier.

YPred = sig*YPred + mu;

```

%The training progress plot reports the root-mean-square error (RMSE) calculated from the standardized data. Calculate the RMSE from the unstandardized predictions.

```

rmse = sqrt(mean((YPred-YTest).^2))
%Plot the training time series with the forecasted values.

figure
plot(data(1:numTimeStepsTrain))
hold on
idx = numTimeStepsTrain:(numTimeStepsTrain+numTimeStepsTest);
plot(idx,[data(numTimeStepsTrain) YPred],'-')
hold off
xlabel("Month")
ylabel("Cases")
title("Forecast")
legend(["Observed" "Forecast"])
%Compare the forecasted values with the test data.
figure
subplot(2,1,1)
plot(YTest)
hold on
plot(YPred,'-')
hold off
legend(["Observed" "Forecast"])
ylabel("Cases")
title("Forecast")
subplot(2,1,2)
stem(YPred - YTest)
xlabel("Month")
ylabel("Error")
title("RMSE = " + rmse)
%% ANN
clc
close all
clear
load('Data.mat')

x = Input';
t = Output';
%%trainscg
%trainbr
trainFcn = 'trainbr';
hiddenLayerSize = 50;
net = fitnet(hiddenLayerSize,trainFcn);
% Train the Network
[net,tr] = train(net,x,t);

% Test the Network
y = net(x);
fit=y;
%% plot
figure,plot(t(1,:), 'linewidth',2);title('Heat Capacity')
hold on;plot(fit(1,:), '-r');legend('Actual Data','Predicted by ANN')
hold off
figure,plotregression(t(1,:),y(1,:))
%%
figure,plot(t(2,:), 'linewidth',2);title('Thermal Conductivity')
hold on;plot(fit(2,:), '-g');legend('Actual Data','Predicted by ANN')
hold off
figure,plotregression(t(2,:),y(2,:))
%%
figure,plot(t(3,:), 'linewidth',2);title('Viscosity')
hold on;plot(fit(3,:), '-y');legend('Actual Data','Predicted by ANN')
hold off
figure,plotregression(t(3,:),y(3,:))
Validation

```

Evaluating the effectiveness of artificial neural network models for estimating and calculating the conductive heat transfer coefficient in nanofluids

Hasan Amirahmadi^{*1}, Mohammadhasan Nobakhti², GholamReza Salehi³

^{1,2} Department of Mechanical Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

³ Department of Mechanical Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran

Received: spring 2025 Accepted: summer 2025

Abstract

In this article, it has been tried to develop the data related to nanofluids using artificial intelligence models and introduce an optimal model to estimate and calculate the coefficient of thermal conductivity for nanofluids. Therefore, the experimental data of experiments based on Al_2O_3 , CuO , TiO_2 , Fe_2O_3 nanoparticles in the base fluid of distilled water for volume percentages of 0.2 to 2 were measured at different temperatures and were used as input to the models along with library data. The type of nanoparticle, temperature, density and viscosity were the input data to the models, and the thermal conductivity parameter of the nanofluid is the output of the models. A total of 268 data series were defined as input to the models, 70% of which were used for training and 30% for testing. It was investigated with five different modes including artificial neural network with activation function ANN-Trainlm, ANN-Trainbr, ANN-Trainscg, long short term memory network (LSTM) and support vector regression (RVS) for modeling. The results showed that LSTM has a much better match with the experimental data, because the values of regression coefficient (R^2), root mean square error (RSME) and mean absolute percentage error (MAPE) values are 0.9764, 0.0313 and 0.0819, respectively.

Key words: Nanofluid, artificial neural network, thermal conductivity coefficient, modeling

*corresponding author: hasan.amirahmadi@srbiau.ac.ir

Cite this article as: Hasan Amirahmadi, Mohammadhasan Nobakhti, GholamReza Salehi, Evaluating the effectiveness of artificial neural network models for estimating and calculating the conductive heat transfer coefficient in nanofluids. **Journal of Energy Conversion**, 2025, 12(2), 69-86.