

## مقاله پژوهشی

# مدل سازی و بهینه سازی ویسکوزیته و هدایت گرمایی نانوسیال هیبریدی سه تایی $\text{CuO}/\text{CaCO}_3/\text{SiO}_2$ مبتنی بر آب با استفاده از شبکه عصبی مصنوعی و الگوریتم NSGA-II

علی مختاریان<sup>۱</sup> و مجتبی رحیمی<sup>۲،\*</sup>

۱- گروه مهندسی مکانیک، واحد خمینی شهر، دانشگاه آزاد اسلامی، خمینی شهر، ایران

۲- گروه مهندسی نفت، واحد خمینی شهر، دانشگاه آزاد اسلامی، خمینی شهر، ایران

۳- مرکز تحقیقات سنگ، واحد خمینی شهر، دانشگاه آزاد اسلامی، خمینی شهر، ایران

تاریخ ثبت اولیه: ۱۴۰۳/۰۸/۱۸، تاریخ دریافت نسخه اصلاح شده: ۱۴۰۳/۱۰/۲۸، تاریخ پذیرش قطعی: ۱۴۰۴/۰۱/۱۸

## چکیده

هدف از این تحقیق، مدل سازی و بهینه سازی ویسکوزیته و هدایت حرارتی نانوسیال هیبریدی سه تایی  $\text{CuO}/\text{CaCO}_3/\text{SiO}_2$  با نسبت حجمی ۶۰، ۳۰ و ۱۰ درصد برای به ترتیب هریک از نانوذرات  $\text{CuO}$ ،  $\text{CaCO}_3$  و  $\text{SiO}_2$  بر مبنای تغییرات دو پارامتر ورودی دمای نانوسیال و کسر حجمی نانوذرات بکار رفته در سیال پایه است. دامنه تغییرات مجاز برای دمای نانوسیال بین ۱۵ تا ۶۰ °C و برای کسر حجمی کلی نانوذرات ۱/۵ تا ۰/۵ درصد، بر مبنای داده های آزمایشگاهی در دسترس، در نظر گرفته شده است. مدل سازی رفتار نانوسیال مغناطیسی ذکر شده با استفاده از طراحی و آموزش دو شبکه عصبی مصنوعی (ANN) پیشخور دو لایه با هدف تخمین دقیق ویسکوزیته و هدایت گرمایی نانوسیال برای مقادیر دلخواه ورودی دما و کسر حجمی در بازه تعیین شده انجام شده است. برای هر شبکه طراحی شده، نمودارهای رگرسیون متناظر هر دسته از داده های آموزش، اعتبارسنجی و آزمون، گویای عملکرد مطلوب شبکه بوده اند. بطوریکه میزان درصد خطای نسبی میانگین و بیشینه بدست آمده برای داده های آزمون شبکه نظیر ویسکوزیته به ترتیب برابر ۰/۹۵۹۲ و ۲/۲۹۳۵ و نظیر هدایت گرمایی به ترتیب برابر ۰/۰۹۸۱ و ۰/۲۰۱۸ حاصل شده است. همچنین، بر مبنای مدل توسعه داده شده، یک مسئله بهینه سازی چند هدفه در راستای تعیین همزمان مقادیر کمینه ویسکوزیته و بیشینه هدایت حرارتی نانوسیال تعریف شده و با استفاده از روش فرایندکاری الگوریتم ژنتیک رتبه بندی نامغلوب (NSGA-II) حل شده است و در پی آن مقادیر بهینه توابع هدف و پارامترهای ورودی نظیر تعیین شده و نمودار نقاط بهینه پارتو ترسیم شده است.

**واژه های کلیدی:** نانوسیال، ویسکوزیته، قابلیت هدایت حرارتی، شبکه عصبی مصنوعی، بهینه سازی چند هدفه.

## ۱- مقدمه

ترموفیزیکی برتر خود در مقایسه با نانوسیالات تک جزیی

متعارف توجه قابل توجهی را به خود جلب کرده اند [۱]. این

خواص بهبود یافته شامل هدایت حرارتی ارتقاء یافته، ضرایب

انتقال حرارت افزایش یافته و پایداری بهتر است، که

نانوسیالات هیبریدی، که با پراکنده کردن چندین نانوذرات

در یک سیال پایه ساخته می شوند، به دلیل خواص

\* عهده دار مکاتبات: مجتبی رحیمی

نشانی: گروه مهندسی نفت، واحد خمینی شهر، دانشگاه آزاد اسلامی، خمینی شهر، ایران

تلفن: ۰۳۱-۳۶۶۵۰۲۵۶۵، دورنگار: ۰۳۱-۳۳۶۶۰۰۸۸، پست الکترونیکی: mrahimi@iau.ac.ir

حساس به غلظت نانوذرات، دما و پایداری پراکندگی هستند. همچنین، رفتار غیرخطی نانوسیالات هیبریدی، توسعه روابط همبستگی تجربی عمومی را پیچیده می‌کند. برای غلبه بر این محدودیت‌ها، شبکه‌های عصبی مصنوعی (ANNs) به عنوان یک ابزار محاسباتی قدرتمند برای پیش‌بینی دقیق خواص نانوسیال بدون آزمایش‌های گسترده ظهور کرده‌اند. ANNs می‌توانند روابط پیچیده و غیرخطی بین پارامترهای ورودی و پاسخ‌های خروجی را با دقت بالایی مدل‌سازی کنند [۸-۱۰]. علاوه بر این، تکنیک‌های بهینه‌سازی مانند الگوریتم ژنتیک مرتب‌سازی نامغلوب (NSGA-II) امکان شناسایی ترکیبات بهینه نانوذرات و شرایط عملیاتی را فراهم می‌کنند که هدایت حرارتی را به حداکثر می‌رسانند و در عین حال تلفات پمپاژ مرتبط با ویسکوزیته را به حداقل می‌رسانند. ادغام ANN و NSGA-II یک چارچوب قوی برای طراحی و کاربرد کارآمد نانوسیالات هیبریدی سه‌تایی در سیستم‌های صنعتی فراهم می‌کند. این رویکرد نوآورانه نه تنها عملکرد سیالات انتقال حرارت را بهبود می‌بخشد، بلکه با کاهش مصرف انرژی و بهبود کارایی سیستم، راه را برای راه‌حل‌های انرژی پایدار هموار می‌کند [۱۱-۱۳].

همت و همکاران [۱۴] به بررسی اثرات کسر حجمی نانوذرات (بین ۰ تا ۲ درصد) بر خواص نانوسیال هیبریدی Ag-MgO/آب پرداختند. آنها روابط همبستگی تئوری و تجربی موجود برای هدایت حرارتی و ویسکوزیته را با داده‌های تجربی مقایسه کردند و خاطرنشان کردند که روابط همبستگی قبلی تمایل به کم‌برآورد کردن این خواص دارند. آنها روابط همبستگی جدیدی را معرفی کردند که دقت بهبود یافته‌ای در پیش‌بینی خواص ترمودینامیکی از خود نشان دادند. همت و همکاران [۱۵] به بررسی تجربی هدایت حرارتی نانوسیالات هیبریدی Cu و TiO<sub>2</sub> با استفاده از یک روش دو مرحله‌ای برای پراکنده کردن نانوذرات در مخلوط آب/EG پرداختند. آنها جزئیات اندازه‌گیری این خواص را در غلظت‌ها و دماهای مختلف شرح دادند و دو رابطه همبستگی جدید برای پیش‌بینی هدایت حرارتی بر اساس

نانوسیالات هیبریدی را به یک راه حل امیدوارکننده برای کاربردهای مختلف در سیستم‌های خنک‌کننده، ذخیره‌سازی انرژی و فرآیندهای صنعتی تبدیل می‌کند [۲]. محققان بطور فعال در حال بررسی ترکیبات بهینه نانوذرات و سیالات پایه برای به حداکثر رساندن این مزایا هستند، که منجر به نوآوری‌هایی می‌شود که می‌تواند فناوری‌های مدیریت حرارتی را در صنایع مختلف متحول کند [۳]. در میان ترکیبات هیبریدی گوناگون، نانوسیالات هیبریدی سه‌تایی که شامل سه نانوذره متمایز هستند به دلیل اثرات هم‌افزایی بین نانومواد، بهبودهای بیشتری را در عملکرد انتقال حرارت ارائه می‌دهند. این هم‌افزایی می‌تواند منجر به افزایش هدایت حرارتی و بهبود ویسکوزیته شود و امکان بازدهی بیشتر در فرآیندهای تبادل حرارت را فراهم کند [۴]. نانوذرات دی‌اکسید سیلیسیم (SiO<sub>2</sub>)، کربنات کلسیم (CaCO<sub>3</sub>) و اکسید مس (CuO) معمولاً در کاربردهای مختلفی از جمله تصویربرداری زیست‌پزشکی، دارورسانی و بهبود خواص انتقال سیال استفاده می‌شوند. دی‌اکسید سیلیسیم، فراوان‌ترین اکسید در پوسته زمین، به دلیل خواص حرارتی و هیدرودینامیکی خود، توجه محققان را در زمینه‌های مختلف به خود جلب کرده است [۵]. کربنات کلسیم به دلیل مزایای خود، از جمله مقرون به صرفه بودن، سمیت کم، سازگاری زیستی، حساسیت به pH، تجزیه‌پذیری ملایم و سازگاری با محیط زیست، مورد توجه قرار گرفته است. علاوه بر این، نانوذرات کربنات کلسیم دارای پتانسیل افزایش پایداری سایر نانوذرات در نانوسیالات را با عملکردی به عنوان یک تثبیت‌کننده یا ارائه یک پوشش محافظ دارند [۶]. اکسید مس با خواص منحصربفردی مانند رسانایی بالا و حرکت براونی زیاد به همراه ویسکوزیته کم، می‌تواند راندمان کلی انرژی سیستم را افزایش دهد. با این حال، دستیابی به پایداری نانوذرات SiO<sub>2</sub>، CaCO<sub>3</sub> و CuO در نانوسیالات می‌تواند چالش‌برانگیز باشد، زیرا این مواد تمایل دارند در شرایط مختلف آگلومره شده/تجمع یافته و ته‌نشین شوند [۷]. علاوه بر این، اندازه‌گیری‌های آزمایشگاهی اغلب زمان‌بر، پرهزینه و

مدل های ANN و داده های تجربی ارائه کردند. نتایج این پژوهش اثربخشی مدل ها را در پیش بینی هدایت حرارتی نشان داد. همت و همکاران [۱۶] در مورد طراحی یک ANN برای پیش بینی هدایت حرارتی و ویسکوزیته نانوسیالات فرومغناطیسی تحقیق کردند. این مطالعه شامل استفاده از داده های تجربی برای آموزش ANN بود. نتایج نشان داد که ANN کمترین خطا را در پیش بینی های خود نشان می دهد و حداکثر خطای ۲٪ برای هدایت حرارتی و ۲/۵٪ برای ویسکوزیته به دست آمد. همت و همکاران [۱۲] به بررسی بهینه سازی چند هدفه نانوسیالات  $Al_2O_3$  در مخلوطی از آب و اتیلن گلیکول پرداختند. آنها از الگوریتم NSGA-II برای تنظیم دما و کسر حجمی نانوذرات به منظور افزایش هدایت حرارتی و کاهش ویسکوزیته استفاده کردند. این محققان از ANN برای پیش بینی ویسکوزیته و هدایت حرارتی بر اساس داده های تجربی استفاده کردند. نتایج نشان داد که مقادیر بهینه برای ویسکوزیته و هدایت حرارتی در حداکثر دما به دست می آیند. بحیرایی و همکاران [۱۷] در مورد اثربخشی روش های هوش مصنوعی (AI) به عنوان رویکردهای جایگزین در حل مسائل پیچیده مرتبط با نانوسیالات بحث کردند. آنها با تأکید بر قابلیت های یادگیری، تحمل خطا و سرعت عمومی سازی، بر پتانسیل AI در پیش بینی و بهینه سازی جنبه های مختلف نانوسیالات تأکید کردند. علاوه بر این، توجه را به چالش ها و مسیرهای تحقیقاتی آینده در استفاده از تکنیک های AI برای پیشبرد درک و کاربردهای نانوسیالات جلب کردند. اخگر و همکاران [۱۸] بر توسعه ANN های نامشابه برای پیش بینی هدایت حرارتی نانوسیالات هیبریدی  $MWCNT-TiO_2$ /آب-اتیلن گلیکول تمرکز کردند. این مطالعه با استفاده از تحلیل حساسیت، معماری ها و الگوریتم های آموزشی مناسب را به کار گرفت و چگونگی اثر تغییرات دما و غلظت بر هدایت حرارتی را بررسی کرد. نتایج نشان داد که خروجی های ANN در مقایسه با روش های همبستگی سنتی، تطابق بهتری با داده های تجربی دارند. کاظمی و همکاران [۱۹] یک مطالعه تجربی مقایسه ای در

مورد رفتار رئولوژیکی تک نانوسیال ها و نانوسیال های هیبریدی حاوی نانوپودرهای گرافن و سیلیس ارائه دادند. آنها بر اثرات این نانوذرات بر ویسکوزیته آب در غلظت های مختلف (۰/۰۵ تا ۱ درصد) و دماهای (۲۵-۵۰ °C) تمرکز کردند. این مطالعه نتیجه گرفت که ویسکوزیته نانوسیال های هیبریدی بین ویسکوزیته نانوسیال های تک قرار می گیرد، و یک رابطه همبستگی برای تخمین رفتار رئولوژیکی نانوسیال هیبریدی  $G-SiO_2$  (۳۰-۷۰ درصد)/آب پیشنهاد شد. دزفولی زاده و همکاران [۲۰] در مورد ویژگی ها و رفتار نانوسیال های هیبریدی سه تایی  $Cu-SiO_2-MWCNTs$  که از سه نوع مختلف نانوذرات پراکنده در یک سیال پایه تشکیل شده اند تحقیق کردند. آنها تحقیقات تجربی در مورد اثرات غلظت حجمی و دما بر ویسکوزیته و هدایت حرارتی مخلوط های مختلف را برجسته کردند. حداکثر خطاهای مدل های ریاضی پیشنهادی برای نتایج تجربی ۱/۱۶۷ و ۱/۳۲۷ درصد برای روابط همبستگی هدایت حرارتی و ویسکوزیته (با مقادیر  $R^2$  به ترتیب برابر با ۰/۹۹۹۴ و ۰/۹۹۸۷) بودند. کائو و همکاران [۲۱] به بحث در مورد بهینه سازی و پیش بینی هدایت حرارتی و ویسکوزیته در مخلوط بیوگلیکول/آب حاوی نانوذرات  $SiO_2$  با استفاده از ترکیبی از روش رویه پاسخ (RSM) و NSGA-II پرداختند. نویسندگان معادلات مربوط به هدایت حرارتی و ویسکوزیته را به عنوان تابعی از دما و کسر حجمی  $SiO_2$  بدست آوردند و نشان دادند که این بهینه سازی منجر به بالاترین هدایت حرارتی در ۰/۵۷۶ W/m.K و کمترین ویسکوزیته در ۰/۶۱ mPa.s می شود. این مطالعه بر تعادل (Trade-off) بین هدایت حرارتی و ویسکوزیته با افزایش کسر حجمی  $SiO_2$  تأکید کرد و پیشنهاد داد که شرایط بهینه به الزامات خاص سیستم مورد تجزیه و تحلیل بستگی دارد. همت و همکاران [۲۲] یک مطالعه تجربی در مورد نسل جدیدی از نانوسیال های هیبریدی سه تایی ارائه دادند که بر هدایت حرارتی نسبی یک ترکیب خاص از نانولوله های کربنی چند جداره (MWCNT)، اکسید منیزیم (MgO) و اکسید روی

(ZnO) در آب تمرکز داشت. این مطالعه نشان داد که هدایت حرارتی نسبی بطور قابل توجهی با دما و کسر حجمی جامد تغییر می کند و به مقدار اوج ۳۲/۷۰ درصد در شرایط بهینه می رسد. این تحقیق از روش RSM برای پیش بینی نتایج تجربی استفاده کرد، که منجر به ضریب همبستگی ( $R^2=0.9959$ ) شد. گوته و همکاران [۲۳] به بررسی ویسکوزیته و خواص رئولوژیکی نانوسیالات ترکیبی دی اکسید تیتانیوم-اکسید روی (TiO<sub>2</sub>-ZnO) پرداختند تا تعیین کنند که چگونه تغییرات در نسبت TiO<sub>2</sub>-ZnO بر این ویژگی ها تأثیر می گذارد. این محققین از پراش اشعه ایکس (XRD) برای تجزیه و تحلیل اولیه استفاده کردند و نانوسیال را با استفاده از مخلوط ۵۵/۴۵ آب/اتیلن گلیکول تولید کردند. نتایج تجربی نشان داد که ترکیب ۵۵/۴۵ TiO<sub>2</sub>-ZnO بیشترین ویسکوزیته را ایجاد می کند، در حالی که ترکیب ۴۵/۵۵ کمترین ویسکوزیته را ایجاد می کند. علاوه بر این، آن ها مشاهده کردند که حداکثر ویسکوزیته با افزایش دما از ۰ به ۹۰ °C به طور قابل توجهی (به میزان ۸۷/۲ درصد) کاهش می یابد و تمام مخلوط ها رفتار سیال نیوتنی از خود نشان می دهند. یک مدل ANN برای پیش بینی ویسکوزیته با دقت بالا توسعه داده شد که توانست مقادیر همبستگی بیشتر از ۹۹/۱ درصد ایجاد نماید. آجنا و همکاران [۲۴] بر تعیین ویسکوزیته یک نانوسیال با ترکیب معین (ZrO<sub>2</sub>/SiC) مبتنی بر آب مقطر) با بررسی رئولوژی نانوسیال تمرکز کردند. در این راستا، یک روش دو مرحله ای برای پراکندگی نانوذرات در سیال پایه به کار گرفته شد. پودر نانو از ZrO<sub>2</sub> و SiC به نسبت ۱:۱ تشکیل شده بود. این تحقیق نشان داد که بین ویسکوزیته نانوسیال و عوامل دما و کسر حجمی جامد رابطه وجود دارد. نتایج نشان دهنده افزایش ویسکوزیته در غلظت های جامد بالاتر و دماهای پایین تر است. افزایش ویسکوزیته نانوسیال در ۲۰ و ۶۰ °C ثبت شد که به ترتیب نشان دهنده افزایش ۲۹/۶ درصد و ۶۴/۲ درصد در ویسکوزیته در حضور ۰/۰۲۵ درصد نانوذرات در نانوسیال بود. این بدان معناست که ویسکوزیته نانوذرات در دماهای

بالا حساس تر می شود. علاوه بر این، این مطالعه یک همبستگی جدید برای تعیین ویسکوزیته نانوسیال ترکیبی با استفاده از داده های تجربی (دما و کسر حجمی جامد) ارائه داد. مقدار دقت همبستگی ریاضی ۹۸/۹۲ درصد بدست آمد. ومین و همکاران [۲۵] به بررسی خواص حرارتی و الکتریکی نانوسیال های کامپوزیتی سه تایی که از پراکندگی نانوذرات ZnO، MgO و MWCNT در آب با نسبت های وزنی مختلف ایجاد شده بودند، پرداختند. این تحقیق بر روی پایداری نانوسیال ها متمرکز بود که از طریق آزمایش های ویسکوزیته و بازرسی های چشمی تعیین شد و نشان دهنده پایداری خوب آنها بود. یافته ها نشان داد که افزایش نسبت جرمی MgO و ZnO منجر به بهبود هدایت حرارتی و ویسکوزیته می شود. این مطالعه بر مزایای استفاده از نانوسیال های کامپوزیتی سه تایی برای کاربردهای مهندسی به دلیل خواص بهبود یافته آن ها نسبت به نانوسیال های تکی تأکید کرد. لیو و همکاران [۲۶] به توسعه و ارزیابی یک نانوسیال هیبریدی سه تایی شامل Al<sub>2</sub>O<sub>3</sub>، TiO<sub>2</sub> و CuO برای بهبود عملکرد سرمایشی سیستم های مدیریت حرارتی باتری های لیتیومی پرداختند. از طریق آزمایش های اورتوگونال برای بهینه سازی ترکیب نانوذرات، دوز پراکنده، و کسر جرمی، این مطالعه نسبت جرمی نانوذرات مطلوب ۰/۷۵ درصد را برای حداکثر کردن هدایت حرارتی شناسایی کرد، در حالی که یک افزایش متناظر در ویسکوزیته نیز قابل مشاهده بود.

بطور خلاصه، بر طبق مرور پژوهش های پیشین که در بند قبلی ذکر شد، می توان گفت که اگرچه مطالعات کم و بیش مشابهی در ده سال اخیر (۲۰۱۵ تا ۲۰۲۵) در مقایسه با پژوهش پیش رو انجام شده است، اما هیچ یک از این مطالعات به بررسی و بهینه سازی خواص رئولوژیکی و حرارتی نانوسیال هیبریدی سه تایی CuO/CaCO<sub>3</sub>/SiO<sub>2</sub> با استفاده از شبکه های عصبی ANN و الگوریتم بهینه سازی NSGA-II پرداخته اند. در راستای پر کردن این شکاف تحقیقاتی، مدل سازی و بهینه سازی ویسکوزیته و هدایت

## ۲- فعالیت های تجربی


شبکه های عصبی مصنوعی مورد استفاده در این تحقیق از نوع پیشخور هستند. شبکه عصبی مصنوعی پیشخور یکی از دو نوع گسترده شبکه عصبی مصنوعی است که با جهت جریان یک طرفه اطلاعات بین لایه های آن مشخص می شود. بر خلاف شبکه های عصبی بازگشتی، در این نوع شبکه، اطلاعات ورودی مدل از گره های لایه ورودی به گره های لایه های پنهان (در صورت وجود) و سپس به گره های لایه خروجی، بدون ایجاد هیچ چرخه یا حلقه ای، جریان می یابد. شبکه های پیشخور مدرن با استفاده از روش پس انتشار، آموزش داده می شوند [۲۷].

برای ارائه مدل های تخمین هدایت گرمایی و ویسکوزیته نانوسیال هیبریدی سه تایی آبی  $\text{CuO}/\text{CaCO}_3/\text{SiO}_2$ ، دو شبکه عصبی مصنوعی پیشخور متمایز دو لایه (با شماییک کلی نشان داده شده در شکل ۲) همراه با چهار نورون در لایه پنهان برای شبکه پیشگوی ویسکوزیته و همراه با سه نورون در لایه پنهان برای شبکه پیش بین هدایت حرارتی، با استفاده از نرم افزار متلب پیکربندی و آماده تغذیه و آموزش شده اند. در واقع این شبکه ها وظیفه پیدا کردن رابطه ای بین دسته ویژگی های ورودی شامل دمای نانوسیال و کسر حجمی نانوذرات درون سیال، و کمیت خروجی هدف (ویسکوزیته یا هدایت گرمایی نانوسیال) را دارند.

## ۳- نتایج و بحث

در این پژوهش، متناظر با هر یک از کمیت های خروجی هدایت گرمایی و ویسکوزیته نانوسیال، ۶۰ دسته داده در آزمایشگاه بدست آمده است که ۶۰ درصد داده ها برای آموزش، ۲۰ درصد برای اعتبارسنجی آموزش و ۲۰ درصد باقیمانده نیز برای آزمودن شبکه متناظر استفاده شده است. همچنین، از الگوریتم بهینه سازی لوونبرگ-مارکواردت (Levenberg-Marquardt) برای آموزش شبکه به روش

حرارتی نانوسیال هیبریدی سه تایی آبی  $\text{CuO}/\text{CaCO}_3/\text{SiO}_2$  بر مبنای دو پارامتر ورودی دمای نانوسیال و کسر حجمی نانوذرات در پژوهش حاضر به انجام رسیده است. در این راستا، ابتدا این دو خاصیت ترموفیزیکی با استفاده از طراحی و آموزش دو شبکه عصبی مصنوعی پیشخور دو لایه بر مبنای اطلاعات آزمایشگاهی بدست آمده در مرجع [۵] با دقت بسیار بالایی مدل سازی می شوند. در ادامه عملکرد مطلوب هر یک از شبکه ها در تخمین ویسکوزیته و هدایت حرارتی نانوسیال، با استفاده از روش های متعددی از جمله بررسی نمودارهای رگرسیون متناظر هر دسته از داده های آموزش، اعتبارسنجی و آزمون مورد ارزیابی قرار می گیرد. همچنین بر مبنای مدل های تخمینگر طراحی شده و آموزش دیده، بهینه سازی خواص ترموفیزیکی (ویسکوزیته و هدایت حرارتی) با استفاده از روش بهینه سازی فراابتکاری NSGA-II با هدف دستیابی به یک دسته نقاط بهینه (که هر یک با در نظر گرفتن درجه اهمیت دلخواه برای هر یک از ویژگی ها قابل انتخاب است) صورت گرفته است. بلوک دیاگرام نشان داده شده در شکل ۱ فرآیند کلی مدل سازی و بهینه سازی انجام شده در این مطالعه را بیان می کند.



شکل ۱: بلوک دیاگرام کلی مدل سازی شبکه عصبی و بهینه سازی تکاملی ویسکوزیته و هدایت حرارتی نانوسیال هیبریدی سه تایی آبی  $\text{CuO}/\text{CaCO}_3/\text{SiO}_2$ .

$$\nabla f = 2J^T \cdot e \quad (4)$$


که در آن  $e$  بردار مقادیر خطا است. در نهایت، ماتریس هسین ( $H$ ) می تواند با استفاده از عبارت زیر تقریب زده شود:

$$H \approx 2J^T \cdot J + \lambda I \quad (5)$$

که در آن  $\lambda$  یک عامل میرایی است که مثبت بودن ماتریس هسین را تضمین می کند و  $I$  نمایانگر ماتریس همانی است. فرآیند بهبود پارامترها می تواند با استفاده از الگوریتم لوونبرگ-مارکوارت به صورت زیر تعریف شود:

$$w^{(i+1)} = w^{(i)} - (J^{(i)T} \cdot J^{(i)} + \lambda^{(i)} I)^{-1} \cdot (2J^{(i)T} \cdot e^{(i)}) \quad (6)$$

در راستای کمک به عملکرد بهتر شبکه، پیش از پردازش اطلاعات، کلیه مقادیر ورودی و خروجی جمع آوریشده از آزمایشات در بازه صفر تا ۱ نرمالیزه شده اند. توابع تبدیل در لایه های پنهان و خروجی نیز به ترتیب تانژانت سیگموئید و خطی نظر گرفته شده اند. همچنین شرط توقف آموزش، رسیدن تعداد دفعات شکست عملکرد اعتبارسنجی (Validation Performance) به عدد ۱۰ است.



شکل ۲: معماری شبکه عصبی پس انتشار دو لایه برای پیش بینی ویسکوزیته و هدایت حرارتی.

یکی از مهمترین شاخص هایی که وضعیت روند آموزش ANN را بیان می کند، نمودار عملکرد شبکه است که

پس انتشار خطا و در واقع برای به روزرسانی مقادیر وزن و بایاس (Bias) و از تابع خطای میانگین مربعات (MSE) بین خروجی شبکه و مقادیر هدف به عنوان شاخص عملکرد (Performance Index) مطابق رابطه (۱) استفاده شده است.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (1)$$

که در این رابطه  $n$  تعداد داده های آزمایشگاهی،  $Y_i$  مقدار خروجی واقعی و  $\hat{Y}_i$  مقدار خروجی پیش بینی شده توسط ANN متناظر با داده  $i$  ام هستند.

الگوریتم بهینه سازی لوونبرگ-مارکوارت به منظور تنظیم دقیق پارامترهای مدل شامل وزن ها و بایاس ها در طول فرآیند آموزش برای شبکه استفاده می شود. الگوریتم لوونبرگ-مارکوارت به طور خاص برای کار با توابع زیان (Loss Functions) تعریف شده بر اساس مجموع مربعات خطا طراحی شده است. این الگوریتم بدون محاسبه دقیق ماتریس هسین (Hessian Matrix) کار می کند. به جای آن، از بردار گرادیان به همراه ماتریس جاکوبین ( $J$ ) استفاده می کند. تابع زیان ( $f$ ) به فرم مجموع مربعات خطا به صورت زیر در نظر گرفته می شود:

$$f = \sum_{i=1}^m e_i^2 \quad (2)$$



که در آن  $m$  تعداد نمونه های آموزش است. ماتریس جاکوبین تابع زیان می تواند به عنوان ماتریسی تعریف شود که مشتقات خطاها نسبت به وزن های شبکه را در بر دارد:

$$l_{ij} = \frac{\partial e_i}{\partial w_j} \quad (3)$$

For  $i = 1, \dots, m$  and  $j = 1, \dots, p$ .

که در آن  $p$  تعداد پارامترها در شبکه عصبی است. بردار گرادیان تابع زیان را می توان به صورت زیر محاسبه کرد:

یک ANN ها برای هر دسته از داده ها دارای دقت قابل قبولی بوده و به میزان کافی به مقادیر هدف نزدیک هستند.





شکل ۳: نمودار عملکرد ANN در طی مراحل بهینه سازی شاخص MSE متناظر هر دسته از داده های آموزش، اعتبارسنجی و آزمون تخمین ویسکوزیته (a) و هدایت حرارتی (b) نانوسیال.

مقدار ضریب همبستگی برای هر یک از دسته داده های آموزش، اعتبارسنجی و آزمون و نیز کل داده ها برای ANN متناظر با خروجی ویسکوزیته (مطابق شکل ۴) به ترتیب 0.99967، 0.99943، 0.99964، 0.99958 و برای ANN متناظر با خروجی هدایت گرمایی (مطابق با شکل ۵) به ترتیب 0.99989، 0.99997، 0.99992، 0.99991 حاصل شده است که همگی آنها به مقدار ایده آل یک بسیار نزدیک

تغییرات MSE در طی مراحل آموزش شبکه را نشان می دهد. این نمودار برای هر یک از شبکه های تخمین ویسکوزیته و هدایت گرمایی نانوسیال به ترتیب در شکل های ۳(a) و ۳(b) ارائه شده است. روند مطلوب کاهشی مقدار شاخص عملکرد MSE برای هر دسته از داده های مربوط به آموزش، اعتبارسنجی و آزمون شبکه در هر یک از شکل ها مشهود است. همچنین، بهترین مقدار بدست آمده برای شاخص عملکرد متناظر با داده های اعتبارسنجی در طی مراحل آموزش با یک دایره سبز رنگ در هر یک از شکل ها مشخص شده است. بهترین عملکرد اعتبارسنجی بدست آمده برای ANN های تخمین گر ویسکوزیته و هدایت گرمایی نانوسیال به ترتیب  $5.5231 \times 10^{-5}$  در تکرار 48 و  $4.3048 \times 10^{-6}$  در تکرار 31 می باشد. همچنین کمترین MSE مربوط به کل داده ها برای ANN با خروجی ویسکوزیته مقدار  $4.9645 \times 10^{-5}$  و برای ANN با خروجی هدایت گرمایی مقدار  $1.2924 \times 10^{-5}$  حاصل شده است.


شاخص دیگر برای تعیین وضعیت آموزش ANN، نمودارهای رگرسیون و ضریب همبستگی بین داده های خروجی واقعی و مقادیر هدف است که برای هر یک از شبکه های آموزش دیده متناظر با خروجی های ویسکوزیته و هدایت گرمایی نانوسیال به ترتیب در شکل های ۴ و ۵ ارائه شده اند. هر یک از این شکل ها بیانگر مقادیر نهایی خروجی بدست آمده از شبکه متناظر برای هر دسته از داده های آموزش، اعتبارسنجی و آزمون (محور قائم) در مقابل مقادیر واقعی نظیر آنها (محور افقی) است. بدیهی است در یک شبکه آموزش یافته، حالت ایده آل هنگامی رخ می دهد که مقادیر خروجی واقعی و شبکه برای همه داده ها کاملاً یکسان باشند که این به معنای دستیابی به مقدار صفر برای شاخص عملکرد MSE است. بنابراین برای یک شبکه ایده آل مقدار ضریب همبستگی (R) برابر با ۱، مقدار شیب خط برازش برابر با ۱ و مقدار عرض از مبدأ (bias) خط برازش برابر صفر می باشد. با توجه به مقادیر شاخص های مندرج بر روی هر یک از شکل های ۴ و ۵ می توان دریافت که مقادیر خروجی هر

نمودارهای انطباقی (Fitting Plots) و درصد خطای نسبی (نسبت اختلاف مقدار واقعی و خروجی شبکه به مقدار واقعی) شبکه آموزش دیده متناظر با هر یک از خروجی ویسکوزیته و هدایت حرارتی نانوسیال برای داده‌های آزمون به ترتیب در شکل‌های ۶(a) و ۶(b) آورده شده‌اند. تطابق بسیار خوب بین مقادیر واقعی و خروجی ANN ها و به دنبال آن مقادیر قابل اغماض بدست آمده برای درصد خطاهای نسبی متناظر، نشان دهنده عملکرد مطلوب شبکه‌ها در پیش-بینی هدایت گرمایی و ویسکوزیته نانوسیال مورد مطالعه در این پژوهش است.




شکل ۶: نمودارهای انطباقی و درصد خطای مقادیر واقعی ویسکوزیته (a) و هدایت حرارتی (b) در مقایسه با خروجی‌های ANN های متناظر، برای داده‌های آزمون.

هستند. این بدان معناست که مدل‌های شبکه عصبی طراحی شده با دقت بسیار بالایی می‌توانند ویسکوزیته و هدایت گرمایی نانوسیال حاوی کسرهای حجمی متفاوت نانوذرات مورد مطالعه در این تحقیق را در دماهای مختلف تخمین بزنند.




شکل ۴: نمودار رگرسیون ANN متناظر با خروجی ویسکوزیته نانوسیال برای هر دسته از داده‌های آموزش، اعتبارسنجی و آزمون




شکل ۵: نمودار رگرسیون ANN متناظر با خروجی هدایت حرارتی نانوسیال برای هر دسته از داده‌های آموزش، اعتبارسنجی و آزمون.

بدست آمده می تواند تأییدی بر عدم بروز برازش بیش از حد (Overfitting) در طی آموزش هر یک از شبکه های معماری شده باشد. این بدان معناست که مدل های آموزش دیده را می توان با دقت بالایی برای تعیین ویسکوزیته و هدایت حرارتی نانوسیال برای مقادیر دلخواه ورودی در بازه تغییرات مجاز تعیین شده بکار برد.



(a)



(b)

شکل ۷: مقادیر قدر مطلق خطای تخمین ویسکوزیته (a) و هدایت حرارتی (b) بر حسب دمای نانوسیال و کسر حجمی نانوذرات در سیال پایه برای همه داده های آزمایشگاهی

بیشینه درصد خطای نسبی مربوط به داده های آزمون شبکه در خصوص هر یک از ANN های تخمین گر ویسکوزیته و هدایت گرمایی نانوسیال به ترتیب ۲/۲۹۳۵، ۰/۲۰۱۸ و همچنین میانگین درصد خطای نسبی این داده ها به ترتیب ۰/۹۵۹۲، ۰/۰۹۸۱ بدست آمده است که بیانگر دقت بالای شبکه های طراحی شده و آموزش دیده در تخمین ویسکوزیته و هدایت گرمایی نانوسیال به ازای مقدار دلخواه کسر حجمی نانوذرات بکاررفته در سیال پایه و در دمای مورد نظر است.

همچنین نقاط مشخص شده در نمودارهای ارائه شده در شکل های (a) و (b) به ترتیب بیانگر قدر مطلق خطای بین خروجی مدل های آموزش دیده شبکه عصبی با مقادیر واقعی ویسکوزیته و هدایت حرارتی برای کلیه داده های آزمایشگاهی موجود در این تحقیق هستند که بر حسب دمای نانوسیال و کسر حجمی نانوذرات در سیال پایه ترسیم شده اند. کمترین، بیشترین و میانگین قدر مطلق خطای تخمین ویسکوزیته به ترتیب  $4.1727 \times 10^{-4}$  cP، 0.0223 cP و 0.0070 cP بدست آمده است. همچنین کمترین، بیشترین و میانگین قدر مطلق خطای تخمین هدایت حرارتی به ترتیب  $5.7081 \times 10^{-6}$  W/mK، 0.0044 و  $9.6921 \times 10^{-4}$  W/mK تعیین شده است. مقدار ناچیز خطای تخمین ویسکوزیته و هدایت گرمایی نانوسیال گویای دقت بالای مدل های آموزش دیده ANN جهت پیشگویی این دو ویژگی نانوسیال مورد مطالعه است.

علاوه بر این، رویه های پیوسته مقادیر خروجی مدل های ANN معماری شده و آموزش دیده نظیر هر یک از ویژگی های ویسکوزیته و هدایت حرارتی نانوسیال مورد مطالعه، بر حسب تغییرات پیوسته ورودی های دمای نانوسیال و کسر حجمی نانوذرات بکار رفته در سیال پایه به ترتیب در شکل های (a) و (b) ترسیم شده اند. در واقع، سطح یکنواخت (Smooth) و بدون برآمدگی یا تورفتگی رویه های

NSGA است که قبلاً توسط سرینیواس و دب در سال ۱۹۹۵ پیشنهاد شده بود [۳۰]. NSGA-II در زمینه‌های مختلفی، از جمله طراحی مهندسی که در آن اهداف متضاد متعددی باید بهینه‌سازی شوند، به کار رفته است. در ساختار NSGA-II، علاوه بر عملگرهای ژنتیکی، مانند تلاقی (Crossover) و جهش (Mutation)، دو عملگر و مکانیزم ویژه چندهدفه زیر تعریف و استفاده می‌شوند:


۱) مرتب‌سازی نامغلوب (Non-dominated Sorting): جمعیت مرتب‌سازی و به جبهه‌ها ( $F_1$ ،  $F_2$  و غیره) تقسیم می‌شود، بطوریکه  $F_1$  (جبهه اول) نشان‌دهنده جبهه پارتو (Pareto Front) تقریب زده شده است.

۲) فاصله ازدحامی (Crowding Distance): این یک مکانیزم برای رتبه‌بندی در میان اعضای یک جبهه است که در آن هیچ عضوی توسط دیگر اعضا مغلوب نمی‌شود. این مکانیزم‌های رتبه‌بندی همراه با عملگرهای انتخاب ژنتیکی برای ایجاد جمعیت نسل بعدی استفاده می‌شوند.


فلوچارت الگوریتم NSGA-II بکار رفته در شکل ۹ نمایش داده شده است. در این پژوهش نیز توابع هدف متضاد شامل ضریب ویسکوزیته و هدایت حرارتی بوده و متغیرهای بهینه‌سازی شامل دمای نانوسیال و کسر حجمی نانوذرات بکار رفته در سیال پایه است. مقادیر پارامترهای تنظیمی الگوریتم بهینه‌سازی مورد استفاده در جدول ۱ ارائه شده است. همچنین کد مورد استفاده جهت پیاده‌سازی الگوریتم در نرم‌افزار متلب نوشته شده است [۳۱].

جدول ۱: مقادیر پارامترهای تنظیمی الگوریتم بهینه‌سازی NSGA-II.

| مقدار | پارامتر            |
|-------|--------------------|
| ۱۰۰۰  | حداکثر تعداد تکرار |
| ۴۰    | اندازه جمعیت       |
| ۷۰٪   | درصد تلاقی         |
| ۴۰٪   | درصد جهش           |
| ۰/۰۲  | نرخ جهش            |




(a)



(b)

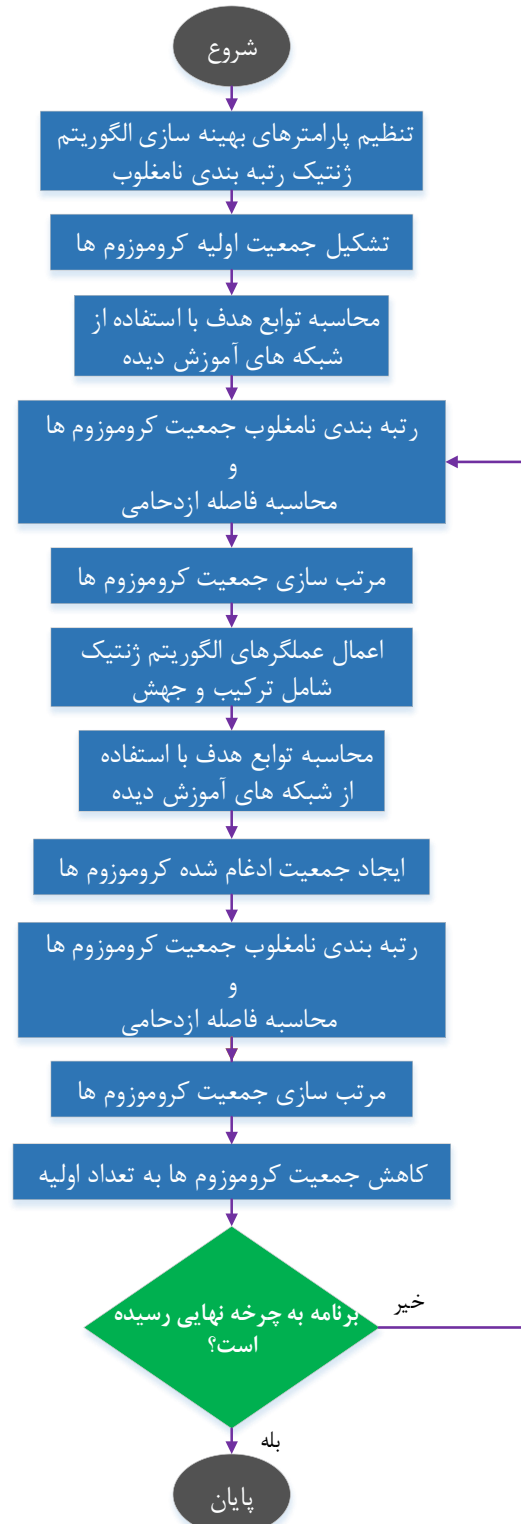
شکل ۸: رویه‌های ویسکوزیته (a) و هدایت حرارتی (b) تخمین زده شده توسط مدل‌های ANN بر حسب دمای نانوسیال و کسر حجمی نانوذرات در سیال پایه در دامنه پیوسته تغییرات تعیین شده.

در ادامه این تحقیق نیز قصد داریم بر پایه مدل‌های ANN طراحی شده و آموزش دیده، یک مسئله بهینه‌سازی چند هدفه به منظور دستیابی به کمترین مقدار ضریب ویسکوزیته و بیشترین مقدار هدایت حرارتی نانوسیال مورد مطالعه را با استفاده از روش فراابتکاری الگوریتم ژنتیک رتبه‌بندی نامغلوب معروف به NSGA-II (Non-dominated Sorting Genetic Algorithm II) حل کنیم [۲۸، ۲۹]. NSGA-II از جمله روش‌های مستقیم حل مسائل بهینه‌سازی چند هدفه است که برخلاف روش‌های سنتی مبتنی بر تجزیه مسئله به چند مسئله بهینه‌سازی تک هدفه سریعتر بوده و قادر به دستیابی به مجموعه‌ای از پاسخ‌ها می‌باشد و در واقع این امکان تصمیم‌گیری را به کاربر می‌دهد که بر اساس اولویت‌بندی توابع هدف مورد نظر، پاسخ بهینه مناسب را انتخاب کند. NSGA-II یک الگوریتم ژنتیک چندهدفه است که توسط دب و همکاران در سال ۲۰۰۲ پیشنهاد شده است [۲۹]. این الگوریتم یک توسعه و بهبود الگوریتم




شکل ۱۰: مرز نقاط پارتو حاصل از بهینه سازی ویسکوزیته و هدایت حرارتی نانوسیال با استفاده از الگوریتم NSGA-II.

پارتو حاصل از بهینه سازی در شکل ۱۰ ارائه شده است. همچنین مقادیر توابع هدف (ضریب ویسکوزیته و هدایت حرارتی نانوسیال) متناظر با نقاط بهینه پارتو بدست آمده در پایان فرایند بهینه سازی و نیز مقادیر متغیرهای مسئله (دمای نانوسیال و کسر حجمی نانوذرات) متناظر آنها در جدول ۲ آورده شده است. همانطور که در این جدول مشاهده می شود، مقادیر بهینه دمای نانوسیال نظیر نقاط پارتو در کل بازه تغییرات آن یعنی از  $15^{\circ}\text{C}$  تا  $60^{\circ}\text{C}$  پراکنده شده اند در حالیکه کسر حجمی بهینه نظیر همگی این نقاط معادل 0.5 درصد یعنی حد بالایی دامنه تغییرات کسر حجمی نانوذرات، حاصل شده است. همچنین، بازه تغییرات ویسکوزیته کمینه بین 0.4702 cP تا 0.7484 cP و بازه تغییرات هدایت حرارتی بیشینه بین 0.6514 W/mK تا 0.9382 W/mK بدست آمده است. بطور کلی، انتخاب نقطه بهینه مطلوب از بین این نقاط به تصمیم کاربر در اولویت بندی و در نظر گرفتن درجه اهمیت برای هر یک از توابع هدف ویسکوزیته و هدایت حرارتی نانوسیال وابسته است. واضح است بر اساس نتایج بدست آمده، در بین نقاط بهینه پارتو افزایش هر چه بیشتر هدایت حرارتی با افزایش بیشتر ویسکوزیته و کاهش هر چه بیشتر هدایت حرارتی با کاهش بیشتر ویسکوزیته همراه است (چنین رفتاری همواره در بین نقاط پارتو با توجه به تعریف مفهوم غلبه (Dominance) و اینکه هیچ یک از نقاط پارتو بر دیگری غلبه نمی کند قابل انتظار است).



شکل ۹: فلوچارت کلی الگوریتم NSGA-II.

جهت مشاهده چگونگی رابطه بین مقادیر توابع هدف در نقاط بهینه پارتو و پراکندگی این نقاط در فضای هدف، جبهه



(b)

شکل ۱۱: نمودارهای مقادیر بهینه توابع هدف ویسکوزیته (a) و هدایت حرارتی (b) نانوسیال در مقابل مقادیر بهینه ورودی برای نقاط پارتو متناظر بدست آمده از الگوریتم NSGA-II.

## ۴- نتیجه گیری


هدف این مطالعه ایجاد مدل‌های رگرسیونی دقیق برای پیش‌بینی هدایت حرارتی و ویسکوزیته نانوسیال ترکیبی سه‌تایی آبی  $\text{CuO}/\text{CaCO}_3/\text{SiO}_2$  با در نظر گرفتن دمای نانوسیال و کسر حجمی نانوذرات به عنوان ورودی مدل‌ها بوده است. برای دستیابی به این هدف، دو شبکه عصبی مصنوعی (ANN) دو لایه طراحی و آموزش داده شدند. علاوه بر این، مدل‌های ANN برای شناسایی مقادیر بهینه دمای نانوسیال و کسر حجمی نانوذرات با هدف حداقل کردن ویسکوزیته و حداکثر کردن هدایت حرارتی مورد استفاده قرار گرفتند. این مقادیر بهینه با استفاده از الگوریتم بهینه‌سازی NSGA-II تعیین شدند. انتخاب هر یک از نقاط بهینه بدست آمده جهت پیاده‌سازی و بکارگیری در محیط‌های صنعتی منوط به تصمیم کاربر منطبق بر نیاز صنعتی موردنظر خواهد بود. نتایج کلی بدست آمده از این تحقیق را می‌توان در قالب موارد زیر خلاصه کرد:

(۱) ANN توانست به طور مؤثری ویسکوزیته نانوسیالات را تخمین بزند و در تکرار ۴۸ بهترین عملکرد اعتبارسنجی را با MSE برابر با  $5.5231 \times 10^{-5}$  به دست آورد. حداقل MSE کلی برابر با  $4.9645 \times 10^{-5}$  نشان می‌دهد که ANN طراحی شده با دقت بالایی پیش‌بینی‌های قابل اعتمادی را با حداقل خطا فراهم می‌آورد.

جدول ۲: مقادیر بهینه دما و کسر حجمی متناظر با نقاط پارتو بدست آمده برای کمترین ویسکوزیته و بیشترین هدایت حرارتی نانوسیال مورد مطالعه در این پژوهش.

| شماره نقطه بهینه | دمای بهینه (°C) | کسر حجمی بهینه | ویسکوزیته کمینه بهینه (cP) | هدایت حرارتی بهینه (W/mK) |
|------------------|-----------------|----------------|----------------------------|---------------------------|
| 1                | 60.0000         | 0.5000         | 0.7484                     | 0.9382                    |
| 2                | 15.0000         | 0.5000         | 0.4702                     | 0.6514                    |
| 3                | 15.0000         | 0.5000         | 0.4702                     | 0.6514                    |
| 4                | 60.0000         | 0.5000         | 0.7484                     | 0.9382                    |
| 5                | 37.6458         | 0.5000         | 0.5869                     | 0.8204                    |
| 6                | 22.8781         | 0.5000         | 0.5394                     | 0.7700                    |
| 7                | 18.9963         | 0.5000         | 0.5120                     | 0.7246                    |
| 8                | 50.9188         | 0.5000         | 0.6494                     | 0.9018                    |
| 9                | 45.3710         | 0.5000         | 0.6152                     | 0.8833                    |
| 10               | 42.3900         | 0.5000         | 0.6023                     | 0.8436                    |
| 11               | 27.2972         | 0.5000         | 0.5584                     | 0.7925                    |
| 12               | 53.1177         | 0.5000         | 0.6677                     | 0.9144                    |
| 13               | 17.9423         | 0.5000         | 0.5025                     | 0.7074                    |
| 14               | 15.9876         | 0.5000         | 0.4821                     | 0.6710                    |
| 15               | 56.4280         | 0.5000         | 0.7017                     | 0.9286                    |
| 16               | 20.2122         | 0.5000         | 0.5217                     | 0.7417                    |
| 17               | 40.8991         | 0.5000         | 0.5969                     | 0.8351                    |
| 18               | 57.8815         | 0.5000         | 0.7194                     | 0.9331                    |
| 19               | 55.3401         | 0.5000         | 0.6896                     | 0.9246                    |
| 20               | 46.7293         | 0.5000         | 0.6222                     | 0.8730                    |
| 21               | 16.7157         | 0.5000         | 0.4902                     | 0.6851                    |
| 22               | 17.4093         | 0.5000         | 0.4974                     | 0.6980                    |
| 23               | 58.8727         | 0.5000         | 0.7324                     | 0.9357                    |
| 24               | 48.1096         | 0.5000         | 0.6502                     | 0.8828                    |
| 25               | 31.2613         | 0.5000         | 0.5704                     | 0.8029                    |
| 26               | 27.7019         | 0.5000         | 0.5598                     | 0.7938                    |
| 27               | 16.2319         | 0.5000         | 0.4847                     | 0.6756                    |
| 28               | 21.8509         | 0.5000         | 0.5328                     | 0.7602                    |
| 29               | 54.3642         | 0.5000         | 0.6796                     | 0.9204                    |
| 30               | 49.4050         | 0.5000         | 0.6385                     | 0.8919                    |
| 31               | 17.0674         | 0.5000         | 0.4939                     | 0.6917                    |
| 32               | 59.3714         | 0.5000         | 0.7394                     | 0.9368                    |
| 33               | 53.8893         | 0.5000         | 0.6749                     | 0.9182                    |
| 34               | 47.6354         | 0.5000         | 0.6273                     | 0.8795                    |
| 35               | 31.9585         | 0.5000         | 0.5722                     | 0.8045                    |
| 36               | 49.3803         | 0.5000         | 0.6383                     | 0.8917                    |
| 37               | 31.9585         | 0.5000         | 0.5722                     | 0.8045                    |
| 38               | 22.0893         | 0.5000         | 0.5343                     | 0.7624                    |
| 39               | 20.8176         | 0.5000         | 0.5260                     | 0.7491                    |
| 40               | 20.8176         | 0.5000         | 0.5260                     | 0.7491                    |

همچنین در شکل‌های (a) و (b)، به ترتیب نمودارهای تغییرات مقادیر کمینه ویسکوزیته و بیشینه هدایت حرارتی برحسب مقادیر بهینه دمای نانوسیال و کسر حجمی نانوذرات، نظیر نقاط بهینه پارتو بدست آمده ارائه شده است. همانطور که مشاهده می‌شود و از جدول ۲ نیز قابل استناد است، پایین‌ترین مقدار کمینه ویسکوزیته نانوسیال نظیر نقطه بهینه با کمترین مقدار دما و بالاترین مقدار بیشینه هدایت نانوسیال نظیر نقطه بهینه با بیشترین مقدار دمای نانوسیال است.



(a)

(ادامه دارد)

۸) مدل ANN طراحی شده برای هدایت حرارتی، خطاهای حداقل، حداکثر و میانگین برابر با  $5.7081 \times 10^{-6}$ ، 0.0044 و  $9.6921 \times 10^{-4}$  W/mK را گزارش داد که نشان دهنده دقت و قابلیت اطمینان بالای مدل است.

۹) رویه های یکنواخت خروجی بدست آمده از ANN های طراحی شده برای هر یک از ویژگی های ویسکوزیته و هدایت حرارتی نانوسیال گویای عدم بروز برازش بیش از حد (Overfitting) در طی فرایند آموزش هر یک از آنهاست.

۱۰) برای همگی نقاط بهینه پارتو بدست آمده از بهینه سازی چند هدفه فراابتکاری ویسکوزیته و هدایت حرارتی نانوسیال، مقادیر بهینه دمای نانوسیال در کل دامنه تغییرات مجاز آن یعنی از  $15^{\circ}\text{C}$  تا  $60^{\circ}\text{C}$  درصد توزیع شده اند.

۱۱) برای همگی نقاط بهینه پارتو بدست آمده از الگوریتم بهینه سازی NSGA-II، مقدار بهینه کسر حجمی معادل 0.5 (یعنی حد بالایی دامنه تغییرات این پارامتر) برای رسیدن به حداقل ویسکوزیته و بیشترین هدایت حرارتی تعیین شد.

۱۲) مقادیر حداقل ویسکوزیته به طور قابل توجهی از cP 0.7484 به cP 0.4702 کاهش یافت که مربوط به تمام نقاط بهینه پارتو است.

۱۳) مقادیر حداکثر هدایت حرارتی نانوسیالات برای تمام نقاط پارتو از 0.6514 W/mk تا 0.9382 W/mK متغیر است.

## مراجع

- [1] J. Sarkar, P. Ghosh, A. Adil, *Renewable and Sustainable Energy Reviews*, **43**, 2015, 164.
- [2] L.S. Sundar, K.V. Sharma, M.K. Singh, A. Sousa, *Renewable and Sustainable Energy Reviews*, **68**, 2017, 185.
- [3] E.V. Timofeeva, *Two phase flow, phase change and numerical modeling*, **11**, 2011, 435.
- [4] A.A. Minea M.G. Moldoveanu, *Journal of Engineering Thermophysics*, **27**, 2018, 507.
- [5] M. Mousavi, A. Pouranfard, P. Darvishi, *Colloids and Surfaces A: Physicochemical and Engineering Aspects*, **686**, 2024, 133367.
- [6] S. Pugalenth, J. Devaraj, J. Kadarkaraihangam, *Journal of Molecular Liquids*, **370**, 2023, 121056.
- [7] M. Khooshechin, S. Fathi, F. Salimi, S. Ovaysi, *International Journal of Heat and Mass Transfer*, **154**, 2020, 119783.

۲) ANN قادر بود به طور مؤثری هدایت حرارتی نانوسیالات را پیش بینی کند و در تکرار 31 بهترین عملکرد اعتبارسنجی را با MSE برابر با  $4.3048 \times 10^{-6}$  به دست آورد. حداقل MSE کلی برابر با  $1.2924 \times 10^{-5}$  نشان می دهد که ANN طراحی شده دارای عملکرد قابل قبولی می باشد.

۳) ANN پیش بینی کننده ویسکوزیته نانوسیالات توانست بالاترین دقت را با ضرایب همبستگی 0.99967 (آموزش)، 0.99943 (اعتبارسنجی)، 0.99964 (آزمون) و 0.99958 (کل) به دست آورد که توافق خوبی بین مقادیر پیش بینی شده و مقادیر واقعی را نشان می دهد.

۴) ANN پیش بینی کننده هدایت حرارتی نانوسیالات قادر بود بیشترین دقت را با ضرایب همبستگی 0.99989 (آموزش)، 0.99997 (اعتبارسنجی)، 0.99992 (آزمون) و 0.99991 (کل) به دست آورد که توافق عالی بین مقادیر پیش بینی شده و مقادیر واقعی را نشان می دهد.

۵) نمودارهای رگرسیون برای شبکه های ANN که ویسکوزیته و هدایت حرارتی نانوسیالات را پیش بینی می کنند، همبستگی های قوی بین مقادیر پیش بینی شده و واقعی برای داده های آزمون را با درصدهای خطای نسبی پایین نشان دادند که اثربخشی و عملکرد بهینه مدل ها برای پیش بینی دقیق ویسکوزیته و هدایت حرارتی را تأیید می کند.

۶) مدل ANN پیش بینی کننده هدایت حرارتی، حداکثر خطای نسبی 0.2018% و یک میانگین 0.0981% را ثبت کرد، در حالیکه مدل ANN طراحی شده برای ویسکوزیته حداکثر خطای نسبی 2.2935% و یک میانگین 0.9592% را برای داده های آزمون نشان داد.

۷) برای مدل ANN طراحی شده متناظر خروجی ویسکوزیته، خطاهای حداقل، حداکثر و میانگین ثبت شده به ترتیب برابر با  $4.1727 \times 10^{-4}$  cP، 0.0223 cP و 0.0070 cP بودند که قابلیت اطمینان و دقت مدل را برای برآورد ویسکوزیته در کاربردهای عملی تأیید می کند.

- [19] I. Kazemi, M. Sefid, M. Afrand, *Powder Technology*, **366**, 2020, 216.
- [20] A. Dezfuzizadeh, A. Aghaei, A. H. Joshaghani, M.M. Najafizadeh, *Powder Technology*, **389**, 2021, 215.
- [21] Y. Cao, A. Khan, A. Abdi, M. Ghadiri, *Arabian Journal of Chemistry*, **14**, 2021, 103204.
- [22] M.H. Esfe, E.M. Ardeshtiri, D. Toghraie, *Case Studies in Thermal Engineering*, **34**, 2022, 101940.
- [23] M.M. Gutte, N. Zade, Y. Hande, S.M. Bondar, P.C. Bhosale, *Nano World Journal*, **9**, 2023, S323.
- [24] A.M. Ajeena, I. Farkas, P. Víg, *Powder Technology*, **431**, 2024, 119069.
- [25] M. Momin, C. Nwaokocha, M. Sharifpur, G. Cheraghian, J. Meyer, M. Abd El-Rahman, *Results in Physics*, **15**, 2025, 108139.
- [26] Q. Liu, *Journal of Energy Storage*, **109**, 2025, 115234.
- [27] J. Schmidhuber, *Neural Networks*, **61**, 2015, 85.
- [28] C.A.C. Coello, *Evolutionary algorithms for solving multi-objective problems*. Springer, 2007.
- [29] K. Deb, A. Pratap, S. Agarwal, T. Meyarivan, *IEEE transactions on evolutionary computation*, **6**, 2022, 182.
- [30] N. Srinivas, K. Deb, *Evolutionary computation*, **2**, 1994, 221.
- [31] K. Mostapha, "NSGA-II in MATLAB (URL: <https://yarpiz.com/56/ypea120-nsga2>)," ed: Yarpiz, 2015.
- [8] M. Hemmat Esfe and M. Afrand, *Journal of Thermal Analysis and Calorimetry*, **140**, 2020, 501.
- [9] H. Karimi, F. Yousefi, *Fluid Phase Equilibria*, **336**, 2012, 79.
- [10] M. Ma, Y. Zhai, J. Wang, P. Yao, H. Wang, *Powder Technology*, **362**, 2020, 257.
- [11] M. Amani, P. Amani, O. Mahian, P. Estellé, *Journal of Cleaner Production*, **166**, 2017, 350.
- [12] M.H. Esfe, *International Communications in Heat and Mass Transfer*, **82**, 2017, 154.
- [13] C. Kamsuwan, X. Wang, P. Piumsomboon, Y. Pratumwal, S. Otarawanna, B. Chalermisinsuwan, *International Journal of Thermal Sciences*, **184**, 2023, 107995.
- [14] M.H. Esfe, A.A.A. Arani, M. Rezaie, W.M. Yan, A. Karimipour, *International Communications in Heat and Mass Transfer*, **66**, 2015, 189.
- [15] M. H. Esfe, *International Communications in Heat and Mass Transfer*, **66**, 2015, 100.
- [16] M.H. Esfe, S. Saedodin, N. Sina, M. Afrand, S. Rostami, *International Communications in Heat and Mass Transfer*, **68**, 2015, 50.
- [17] M. Bahiraei, S. Heshmatian, H. Moayedi, *Powder Technology*, **353**, 2019, 276.
- [18] A. Akhgar, D. Toghraie, N. Sina, M. Afrand, *Powder Technology*, **355**, 2019, 602.