

پیش‌بینی ویژگی‌های انتقالی (هدایت گرمایی و گرانیروی) نانوسیال‌ها با استفاده از روش شبکه‌ی عصبی مصنوعی

مجید موسوی⁺، آزاده دانشور، خدیجه فیروزی راد

گروه شیمی فیزیک، دانشکده شیمی، دانشگاه اصفهان، اصفهان، ایران

چکیده: در این پژوهش، از شبکه‌های عصبی مصنوعی (ANN) پس‌انتشار پیش‌خور برای پیش‌بینی روند تغییرهای هدایت گرمایی نسبی و گرانیروی نسبی بازه گسترده‌ای از نانوسیال‌ها با سیال‌های پایه و نانوذره‌های متفاوت، استفاده شده‌است. در اولین مدل ANN، هدایت گرمایی نانوسیال‌ها بر اساس هدایت گرمایی سیال پایه، هدایت گرمایی نانوذره، درصد کسرحجمی نانوذره، دما و اندازه‌ی متوسط نانوذره مدل‌سازی شده‌است. ۴۸۳ داده‌ی تجربی جمع‌آوری و برای طراحی این شبکه مورد استفاده قرار گرفت و ساختار شبکه به صورت (۵-۱۸-۱) کم‌ترین خطا را در پیش‌بینی هدایت گرمایی نانوسیال نشان داد و نتیجه‌های AARD% برای داده‌های آموزش، ارزیابی و تست به ترتیب ۲/۶، ۲/۲ و ۲/۳ به دست آمد. در شبکه‌ی عصبی مصنوعی دیگری که برای پیش‌بینی گرانیروی نانوسیال طراحی شد، پارامترهای گرانیروی سیال پایه، نسبت چگالی سیال پایه به نانوذره، درصد کسرحجمی نانوذره، دما و اندازه‌ی متوسط نانوذره به‌عنوان ورودی‌های شبکه استفاده شد. تعداد ۵۱۰ داده‌ی تجربی برای طراحی این شبکه مورد استفاده قرار گرفت و ساختار بهینه‌ی شبکه به صورت (۵-۱۹-۱) به دست آمد. نتیجه‌های AARD% برای داده‌های آموزش، ارزیابی و آزمون به ترتیب ۲/۹، ۳/۲ و ۳/۱ به دست آمد. نتیجه‌های به دست آمده از این دو شبکه‌ی عصبی مصنوعی توانمند بودن آن‌ها را در پیش‌بینی ویژگی‌های هدایت گرمایی و گرانیروی نانوسیال‌ها نشان می‌دهد. مقایسه‌ای بین پیش‌بینی مدل‌های پیشنهادی و پیش‌بینی مدل‌های مرسوم مانند، ماکسول، براگمن، انیشتین، کرینگر و... (در مورد هدایت گرمایی) و مدل‌های اینشتین، کریگر، نیلسن، باتچلر و برینکمن (در مورد گرانیروی) نشان داد که مدل‌های پیشنهادی این پژوهش در توافق بیش‌تری با مقادارهای تجربی هستند. این دو مدل همچنین ما را در پیش‌بینی هدایت گرمایی و گرانیروی نسبی نانوسیال‌های تازه با مشخصه‌های گوناگون توانمند می‌سازند.

کلید واژه‌ها: نانوسیال، هدایت گرمایی، گرانیروی، شبکه‌ی عصبی مصنوعی.

KEYWORDS: Nanofluid, Thermal conductivity, Viscosity, ANN.

مقدمه

دارای هدایت گرمایی بالایی هستند، به همین علت سرعت انتقال گرما در آن‌ها بسیار زیاد است. همان‌گونه که نتیجه‌های پژوهش‌های بسیاری از پژوهشگران نشان می‌دهد، هدایت گرمایی نانوسیال

نانوسیال‌ها به منظور افزایش هدایت گرمایی و بهبود عملکرد انتقال گرما، با پخش و منتشر کردن ذره‌ها در اندازه‌های نانومتری در سیال‌های متداول منتقل‌کننده‌ی گرما، ساخته می‌شوند. نانوسیال‌ها به طور عموم

+E-mail: m.mousavi@sci.ui.ac.ir

* عهده دار مکاتبات

(شامل روغن α -اولفین، دکان، آب مقطر و اتیلن گلیکول) و نانولوله‌های کربنی تک‌دیواره‌ی پخش شده در اپوکسی و پلی متیل متاکریلات، مدل شبکه‌ی عصبی مصنوعی را با ۴۳ داده‌ی موجود در مقاله‌ها طراحی کردند. در این کار تنها اثر کسر حجمی مورد بررسی قرار گرفت ولی اثر اندازه‌ی ذرات و دما مورد بررسی قرار نگرفت. حجت^{۱۰} و همکاران [۲۰] نیز هدایت گرمایی نانوسیال‌های به دست آمده از پخش نانو اکسیدهای فلزی گوناگون در آب را با این روش مدل کردند. آن‌ها از داده‌های تجربی در دماهای ۵، ۱۵، ۳۵ و ۴۵ درجه‌ی سلسیوس برای آموزش شبکه استفاده کردند، در حالی که تنها از داده‌های به دست آمده در دمای ۲۵ درجه‌ی سلسیوس برای ارزیابی شبکه استفاده نمودند. نتیجه‌ها تنها به صورت کیفی ارائه شدند به گونه‌ای که تنها از درصد میانگین خطا برای ارزیابی نتیجه‌ها استفاده شد. یوسفی^{۱۱} و همکاران [۲۱]، با استفاده از ۱۸۲ داده‌ی تجربی یک شبکه‌ی عصبی مصنوعی برای پیش‌بینی گرانیوی نسبی نانوسیال‌ها شامل نانوذره‌های CuO پخش شده در اتیلن گلیکول / آب، SiO₂ پخش شده در آب، SiO₂ پخش شده در اتانول، Al₂O₃ پخش شده در آب و TiO₂ پخش شده در آب، طراحی کردند، و نتیجه‌های به دست آمده با داده‌های تجربی و مدل‌های نظری مقایسه شدند. کورت و کیفی^{۱۲} [۲۲]، از روش شبکه‌ی عصبی مصنوعی برای پیش‌بینی هدایت گرمایی نانوسیال‌ها با سیال پایه‌ی اتیلن گلیکول / آب استفاده کردند. آن‌ها از ۴۰ داده‌ی اندازه‌گیری شده توسط خودشان در طراحی شبکه‌ی عصبی مصنوعی استفاده کرده و ۸۰٪ از این داده‌های تجربی موجود را به طور تصادفی برای آموزش شبکه و ۲۰٪ باقیمانده را برای ارزیابی مورد استفاده قرار دادند. نتیجه‌های به دست آمده بر اساس میانگین درصد خطای مطلق، RMSD، مجموع مربع‌های خطا و ضریب‌های تعیین آماری (R²)، مورد ارزیابی قرار گرفت. لونگو^{۱۳} و همکارانش [۲۳]، از دو مدل شبکه‌ی عصبی با سه ورودی و چهار ورودی برای پیش‌بینی هدایت گرمایی نانوسیال‌ها شامل اکسیدهای فلزی در سیال پایه‌ی آب استفاده کردند. در هر دو مدل، دما، کسر حجمی نانوذره‌ها و هدایت گرمایی نانوذره‌ها به عنوان ورودی استفاده شد. در مدل با چهار ورودی افزون بر سه ورودی پیشین، میانگین اندازه‌ی نانوذره‌ها نیز در نظر گرفته شد.

به متغیرهای گوناگونی همچون دما، هدایت گرمایی سیال پایه، هدایت گرمایی نانوذره، کسر حجمی نانوذره، شکل، اندازه و مساحت سطح نانوذره بستگی دارد. به نظر می‌رسد که در بین این متغیرها کسر حجمی، اندازه‌ی نانوذره و دما از همه‌ی عامل‌ها مهم‌تر هستند [۹-۱۱].

از آنجا که هنوز هیچ مدل دقیقی برای تعیین هدایت گرمایی نانوسیالات وجود ندارد، از مدل‌هایی چون ماکسول^۱، جفری^۲، براگمن^۳، واسپ^۴، هامیلتون و کراسر^۵ و کو و کلینستروتر^۶ استفاده می‌شود. در بیش‌تر این مدل‌ها، اثر اندازه‌ی ذره‌ها، حرکت‌های براونی ذره‌ها، لایه‌بندی سیال و اثر خوشه‌ای شدن نانوذره‌ها در نظر گرفته نشده است. افزون بر این هنوز بهترین مدل برای محاسبه‌ی هدایت گرمایی نانوسیال‌ها تعیین نشده است. افزون بر هدایت گرمایی، گرانیوی یک نانوسیال هم در مقایسه با سیال پایه‌ی آن افزایش می‌یابد. از داده‌های موجود در مقاله‌ها چنین به نظر می‌رسد که افزایش در گرانیوی نانوسیال بیش‌تر از افزایش در هدایت گرمایی آن‌ها می‌باشد. گرانیوی نانوسیال را می‌توان با استفاده از معادله‌ی انیشتین^۷ و معادله‌ی برینکمن^۸ که برای مخلوط‌های دو فاز به دست آمده‌اند، محاسبه کرد [۱۰]. به هر حال، این معادله‌ها، هدایت گرمایی و گرانیوی نانوسیال را تا حد زیادی کم‌تر از میزان واقعی تخمین می‌زنند.

در سال‌های اخیر روش‌هایی با عنوان محاسبه‌های نرم معرفی شده‌اند که به گردآوری و مدیریت داده‌ها، تجزیه و تحلیل آن‌ها و پیش‌بینی می‌پردازند. در واقع، این روش‌ها با بهره‌گیری از ابزارهای تجزیه و تحلیل داده‌ها به کشف الگوها و رابطه‌های معتبری که تاکنون شناخته نشده‌اند، می‌پردازند. این ابزارهای مورد استفاده ممکن است مدل‌های آماری، الگوریتم‌های ریاضی و روش‌های یادگیرنده‌ی همچون شبکه‌های عصبی مصنوعی باشند. در سال‌های اخیر، روش شبکه‌ی عصبی مصنوعی برای پیش‌بینی ویژگی‌های سامانه‌های گوناگون [۱۱-۱۸] از جمله هدایت گرمایی و گرانیوی تعداد محدودی از نانوسیال‌ها به کار رفته است ولی تاکنون هیچ مطالعه‌ی جامعی برای ارائه یک شبکه‌ی مناسب که گستره‌ی وسیعی از نانو سیال‌ها را در برگیرد، انجام نشده است.

پاپری^۹ و همکاران [۱۹]، برای تخمین افزایش هدایت گرمایی نانولوله‌های کربنی چنددیواره‌ی پخش شده در چندین سیال پایه

(۱) Maxwell

(۲) Jeffrey

(۳) Bruggman

(۴) Wasp

(۵) Hamilton & crosser

(۶) Koo and Kleinstreuer

(۷) Einstein equation

(۸) Brinkman

(۹) Papari

(۱۰) Hojjat

(۱۱) Yousefi

(۱۲) Kurt and kayfeci

(۱۳) Longo

به شبیه‌سازی فرآیندهای ویژه‌ای از یادگیری انسانی است. در واقع، شبکه‌های عصبی، الگوریتم‌های غیرخطی محاسبه‌ای برای پردازش تصویر، سیگنال و داده‌های عددی هستند. در طول چند دهه‌ی گذشته، از شبکه‌های عصبی مصنوعی به‌طور گسترده‌ای در زمینه‌های گوناگون استفاده شده است [۲۶]. چندین مشخصه‌ی شبکه‌های عصبی مانند دینامیک درونی شبکه‌های عصبی در پیش‌بینی، تغییرهای خطای اطلاعات و نیاز نداشتن به اطلاعاتی افزون بر داده‌های ورودی، استفاده از شبکه‌ی عصبی را در بسیاری از مسئله‌های مهندسی جذاب می‌کند. شبکه‌های عصبی با استفاده از داده‌های واقعی ورودی و خروجی، الگوریتم‌های آموزشی را به‌کار می‌گیرند تا ارتباط‌های پنهانی میان داده‌های ورودی و خروجی را از طریق ضریب‌های وزنی، بایاس‌ها و تابع‌های اعمالی به خروجی‌های هر لایه، شکل دهند. ساختار شبکه‌های عصبی به‌صورت لایه‌ای است و از یک لایه‌ی ورودی، یک لایه‌ی خروجی و یک یا چند لایه‌ی میانی تشکیل شده‌اند. هر لایه شامل تعدادی گره یا نورون است که گره‌ها در قالب شبکه و با وزن‌های متفاوت به هم مربوط شده‌اند.

نتیجه‌ها و بحث

هدایت گرمایی

پیش‌بینی هدایت گرمایی نانوسیال‌ها به وسیله‌ی شبکه‌ی عصبی مصنوعی
داده‌های هدایت گرمایی نانوسیالات مورد استفاده در این کار از نتیجه‌های مطالعه‌های تجربی بسیاری به‌دست آمده‌اند. بسیاری از مطالعه‌هایی که بر روی مدل‌سازی هدایت گرمایی نانوسیال‌های گوناگون با استفاده از شبکه‌ی عصبی مصنوعی انجام گرفته است، دارای چهار ورودی دما، درصد کسر حجمی نانوذره، هدایت گرمایی نانوذره و هدایت گرمایی سیال پایه هستند. از آنجایی که لونگو^۳ و همکاران [۳۳] نشان دادند که در نظر گرفتن اندازه‌ی متوسط ذره‌ها می‌تواند عملکرد شبکه‌ی طراحی شده را بهبود بخشد، این پارامتر به‌عنوان یکی از ورودی‌های شبکه‌ی ساخته شده در نظر گرفته شد. بنابراین تعداد ورودی‌های شبکه به دست آمده به ۵ پارامتر افزایش یافت. وارد کردن این ویژگی از نانوذره به‌عنوان ورودی شبکه، داده‌های تجربی در دسترس را کاهش می‌دهد چرا که بیش‌تر مطالعه‌ها تأثیر این ویژگی مهم را بررسی نکرده‌اند. همه داده‌های ورودی در این کار از مطالعه‌های تجربی جمع‌آوری شده‌اند و از داده‌های به دست آمده از مطالعه‌های نظری استفاده نشده است.

نتیجه‌های آن‌ها نشان داد که هر دو مدل در توافق قابل پذیرشی با داده‌های تجربی هستند ولی مدل با چهار ورودی کارایی بهتری نشان داد. ژالو^۱ و همکاران [۲۴]، برای پیش‌بینی گرانشی دو سامانه نانوسیال Al_2O_3 پخش شده در آب و CuO پخش شده در آب، دو مدل شبکه‌ی عصبی با چهار و پنج ورودی طراحی کردند. در هر دو مدل، کسر حجمی نانوذره‌ها، قطر نانوذره‌ها، چگالی نانوذره‌ها و گرانشی سیال پایه به‌عنوان ورودی استفاده شد. در مدل با پنج ورودی افزون بر چهار ورودی پیشین، دما نیز به‌عنوان ورودی پنجم در نظر گرفته شد. نتیجه‌ها نشان داد که هر دو مدل در توافق خوبی با داده‌های تجربی هستند ولی مدل با پنج ورودی کارایی بهتری نشان داد. همت^۲ [۲۵]، برای پیش‌بینی هدایت گرمایی نسبی نانوذره TiO_2 در سیال پایه‌ی آب/اتیلن‌گلیکول در محدوده‌ی دمایی ۳۰ تا ۷۰ درجه‌ی سلسیوس و بازه‌ی کسر حجمی ۰/۲ - ۱ درصد دو مدل شبکه‌ی عصبی استفاده و نتیجه‌ها را با هم مقایسه کرد.

هنوز هیچ نظریه‌ی دقیقی برای تعیین هدایت گرمایی و گرانشی نانوسیال‌ها وجود ندارد و مدل‌های کلاسیکی موجود درباره‌ی مخلوط‌های مایع - جامد که برای نانوسیال‌ها نیز به‌کار می‌روند از درستی خوبی برخوردار نیستند. به‌تازگی، روش‌های گوناگون داده‌کاوی برای پیش‌بینی هدایت حرارتی و گرانشی تعداد محدودی از نانوسیال‌ها (تعداد محدودی از نانوذره‌ها با سیال‌های پایه‌ی خاص) و در شرایط دمایی، کسر حجمی و اندازه‌ی محدود به‌کار رفته‌است. هیچ مطالعه‌ی جامعی برای ارایه یک شبکه‌ی مناسب که گستره‌ی وسیعی از سیال‌های پایه و نانوذره‌های گوناگون (و در نتیجه انواع نانو سیال‌ها) را دربرگیرد وجود ندارد. در این پژوهش، با استفاده از داده‌های تجربی موجود در مقاله‌ها و در نظر گرفتن عواملی چون کسر حجمی، دما، هدایت گرمایی یا گرانشی سیال پایه، هدایت گرمایی نانوذره‌ها و اندازه‌ی نانوذره‌ها به‌عنوان ورودی شبکه و تقسیم داده‌ها به سه قسمت آموزش، ارزیابی و آزمون، شبکه‌های مناسبی برای پیش‌بینی هدایت گرمایی و گرانشی نانوسیال‌ها طراحی خواهیم کرد. این شبکه‌ها که به‌عنوان مدل‌های پیش‌بینی کننده‌ی مناسب و آسان برای مهندسان قابل استفاده خواهد بود، به طراحی نانوسیال‌های جدید نیز کمک خواهد کرد.


بخش نظری

یک شبکه‌ی عصبی از تعداد زیادی واحد پردازنده به نام نورون و اتصالات بین نورون‌ها (رشته‌های سیناپسی) تشکیل شده و قادر

(۱) Zhao

(۲) Hemmat

(۳) Longo



شکل ۱- ساختار مدل ANN مورد استفاده.

۱۵٪ برای تست تقسیم شدند. تأثیر تخصیص داده‌ها به سه زیرگروه گوناگون بردقت مدل ANN توسط قره‌قیصی^۱ مطالعه شده است [۵۴]. قره‌قیصی نشان داد که گروه تست باید ۱۵٪ تا ۴۰٪ داده‌ها را به خود اختصاص دهد. اگر این درصد بسیار کم باشد، دقت مدل در طی آموزش بیش‌تر از آزمون خواهد بود، هم‌چنین، اگر این درصد بسیار زیاد باشد، مدل به‌دست آمده در پیش‌بینی هدف‌ها (targets) از دقت کاملی برخوردار نخواهد بود. به عبارت دیگر، کار او نشان داد که درصد بهینه‌ی گروه آزمون به ماهیت مسئله بستگی دارد. درصد بهینه، درصدی است که دقت و صحت مدل در گروه‌های تست و آموزش در نزدیکی هم باشند.

شبکه‌ی عصبی مورد استفاده

در این پژوهش، شبکه‌های عصبی پیش‌خور با معماری پس‌انتشار مورد استفاده قرار گرفت. این نوع شبکه‌ها در مدل کردن رابطه‌ی غیرخطی بین متغیرها بسیار کارا می‌باشند. از آنجا که هدف، پیش‌بینی هدایت گرمایی نسبی نانوسیال‌ها می‌باشد، خروجی شبکه‌ی عصبی، هدایت گرمایی نسبی نانوسیال‌ها تعیین شد، و پارامترهای موثر بر آن یعنی درصد کسر حجمی نانوذره، دما، اندازه‌ی متوسط نانوذره، هدایت گرمایی نانوذره و هدایت گرمایی سیال پایه به عنوان ورودی‌های شبکه‌ی عصبی انتخاب شدند. در زمان اجرای الگوریتم آموزش، داده‌های ورودی به‌عنوان خوراک به لایه‌ی ورودی شبکه‌ی عصبی وارد شدند و تفاوت بین خروجی شبکه (outputs) و خروجی مطلوب (targets) به‌عنوان معیاری برای تصحیح وزن و بایاس‌ها مورد استفاده قرار گرفت. شایان ذکر است که در آغاز کلیه‌ی وزن‌ها و بایاس‌ها به‌طور تصادفی مقداردهی می‌شوند.

نانوسیال‌ها انتخاب شده برای مطالعه شامل چهار نوع سیال پایه و یازده نوع نانوذره هستند. این نانوسیال‌ها براساس نوع سیال پایه به چهار نوع، آب مقطر (سیال پایه) و $Ag, Al_2O_3, CuO, TiO_2, SiC$ (نانوذره‌ها) $Cu, silica$ (نانوذره‌ها) [۲۷-۲۹، ۳۰، ۳۱، ۳۳، ۳۹، ۴۱، ۵۳-۴۹] و $Al_2O_3, CuO, TiO_2, SiC, Cu, Fe, UDD, WO_3$ (نانوذره‌ها) و Al_2O_3, Al (نانوذره‌ها) [۲۷، ۳۹] و روغن مبدل (سیال پایه) و روغن موتور (سیال پایه) و Cu (نانوذره‌ها) [۲۸] تقسیم‌بندی شده‌اند. سرانجام، مجموعه‌ای از ۴۸۳ داده از ۱۸ نانوسیال متفاوت از ۳۱ منبع جمع‌آوری و یک شبکه‌ی عصبی پس‌انتشار پیش‌خور برای پیش‌بینی هدایت گرمایی نسبی نانوسیال‌ها به‌صورت تابعی از هدایت گرمایی سیال پایه (k_{BF})، هدایت گرمایی نانوذره (k_{NP})، دما (T)، اندازه‌ی متوسط ذره‌ها (d_{NP}) و درصد کسر حجمی نانوذره ($\phi\%$)، استفاده شد. ساختار مدل شبکه‌ی عصبی مصنوعی (ANN) مورد استفاده در این پژوهش در شکل ۱ آورده شده‌است. نرمال‌سازی یکی از پیش‌پردازش‌های مهم در مدل‌سازی شبکه‌های عصبی مصنوعی به‌شمار می‌رود. این کار باعث می‌شود تا آموزش شبکه به صورت سریع‌تر و با عملکرد بهتری انجام شود. با این کار به همه متغیرها در مدل‌سازی توجه یکسانی می‌شود. در این مطالعه، نرمال‌سازی داده‌ها بین ۰/۱ و ۰/۹ با استفاده از معادله‌ی زیر صورت پذیرفته است.

$$v = \frac{v - \text{Min}(v)}{\text{Max}(v) - \text{Min}(v)}(U - L) + L \quad (1)$$

که در آن v' ماتریس داده‌های نرمال، v ماتریس داده‌های اولیه، L و U حدود بالا و پایین نرمال‌سازی می‌باشند

تقسیم داده‌ها

داده‌های ورودی به‌صورت تصادفی به سه زیرگروه آموزش، ارزیابی و تست تقسیم شدند. گروه آموزش، برای ساختن ساختار شبکه‌ی عصبی مورد استفاده قرار می‌گیرد. شبکه‌ی عصبی در زمان فرایند آموزش، وزن‌ها و بایاس‌ها را در پاسخ به اطلاعات اولیه اصلاح می‌کند. گروه ارزیابی برای بهینه‌سازی و گروه تست برای بررسی درستی و قابلیت پیش‌بینی مدل مورد استفاده قرار می‌گیرند. از آن جهت که داده‌های آزمون هیچ‌گونه تأثیری بر روند آموزش شبکه ندارند، معیاری مستقل از عملکرد شبکه خواهند بود. تعداد ۴۸۳ داده‌ی تجربی مورد استفاده جهت طراحی شبکه‌ی مورد نظر به‌صورت تصادفی به سه گروه ۷۰٪ برای آموزش، ۱۵٪ برای ارزیابی و

(۱) Gharagheizi

جدول ۱- مورد استفاده برای پیش‌بینی هدایت گرمایی نانو سیال‌های مورد مطالعه ANN جدول ... وزن‌ها و بایاس‌های بهینه برای شبکه.

نورون‌های ورودی	هدایت گرمایی سیال پایه	هدایت گرمایی نانوذره	دما	اندازه نانوذره	درصد کسر حجمی	بایاس
نورون ۱	-۲/۴۶۲۸۱	-۲/۰۵۱۴۴	-۰/۶۴۲۴۸	۱/۱۶۸۳۹۹	۲/۴۰۰۳۷۲	۱/۶۴۹۳۶
نورون ۲	-۱/۹۵۲۵۱	-۰/۷۱۵۸۶	-۰/۶۱۷۰۲	۱/۸۰۵۶۱	۳/۴۱۰۴۹۳	۳/۴۵۹۰۱۹
نورون ۳	۰/۰۹۱۵۵۸	-۳/۰۰۴۱۸	-۱/۴۲۱۶۳	۱/۴۳۰۶۱۹	۱/۳۷۸۶۸۳	-۱/۳۹۲۶۹
نورون ۴	۰/۰۶۰۰۹۱	-۱/۷۶۴۶۶	-۰/۳۰۱۸۸	۱/۱۱۵۱۸۵	۲/۲۷۵۹۰۶	۳/۷۳۳۱۷۵
نورون ۵	۰/۵۴۳۵۵۶	-۳/۵۸۹۹۱	-۱/۲۶۲۴۱	۲/۱۰۶۰۴۸	-۰/۸۳۸۳۳	-۰/۰۵۸۱۲
نورون ۶	-۰/۳۴۳۷۱	-۴/۷۲۷۳۳	-۱/۲۸۷۲۵	۱/۵۴۶۲۲۵	-۱/۰۹۷۰۶	-۲/۷۸۰۲۸
نورون ۷	۴/۰۰۵۰۴	۰/۱۵۷۵۷۱	-۲/۸۲۸۳۱	۳/۳۱۳۶۷۸	۱/۰۸۹۹۱۵	-۱/۴۵۱۹۴
نورون ۸	-۰/۱۳۱۹۶	۱/۷۸۳۷۰۲	-۰/۳۳۱۷۱	-۳/۳۹۷۳۴	۲/۹۷۶۰۹۲	۱/۰۴۸۴۲۷
نورون ۹	-۰/۲۲۲۱	۰/۱۴۷۱۳۸	۱/۴۵۲۶۶۲	۲/۲۶۵۷۹۶	۲/۸۰۹۳۳۷	-۰/۸۵۹۶۵
نورون ۱۰	۰/۹۴۹۲۸۴	-۳/۰۸۷۹۹	-۲/۰۹۹۰۲	-۰/۴۳۹۹۸	-۱/۸۸۲۳۲	۰/۵۸۰۷۲۲
نورون ۱۱	-۰/۰۹۵۹۱	۱/۰۶۰۹۵	-۱/۷۳۱۲۵	۴/۷۳۴۴۵۶	-۲/۸۰۸۷۸	۳/۸۷۱۸۱۸
نورون ۱۲	-۲/۶۶۵۲۸	-۰/۵۰۲۷۱	۲/۵۲۳۰۱۳	-۳/۸۴۹۲۶	۰/۶۳۷۲۱۴	-۰/۰۵۹۶۴
نورون ۱۳	۰/۷۲۰۶۷۶	۵/۰۰۲۰۳۴	۱/۶۸۴۴۵۲	۱/۲۱۳۱۷۹	-۲/۹۷۸۹۷	۱/۰۵۶۱۰۹
نورون ۱۴	۱/۲۷۷۳۲	۱/۷۶۵۱۷۳	۰/۸۹۲۱۱۱	-۱/۸۰۲۶۴	-۲/۰۹۴۵۶	-۰/۹۴۳۶۹
نورون ۱۵	-۱/۰۶۳۵	۴/۰۸۵۷۱۹	-۲/۰۱۱۸۳	-۳/۸۷۲۹۴	-۰/۰۴۱۳۷	-۰/۹۴۰۸۳
نورون ۱۶	۲/۱۲۰۸۶۵	۰/۴۵۸۹۷۷	-۱/۷۸۲۳۶	۲/۲۴۹۶۳۸	۰/۶۱۳۲۸۹	۱/۸۰۶۳۳
نورون ۱۷	-۰/۲۳۶۲۶	-۲/۱۵۰۶۷	۰/۰۱۵۳۰۳	-۵/۴۸۶۷	۲/۹۳۹۵۶۳	-۶/۱۵۲۲۱
نورون ۱۸	۱/۰۲۶۳۳۲	-۳/۸۳۱۶	۱/۸۱۷۸۰۶	۳/۲۳۵۷۰۱	۱/۰۲۷۶۴۶	۱/۷۳۹۰۷۷

مقایسه‌ی هدایت‌گرمایی پیش‌بینی‌شده‌ی نانوسیال‌ها توسط شبکه‌ی عصبی با مقادیر تجربی

فهرستی از داده‌های تجربی نانوسیالات گوناگون مورد استفاده در مدل ANN شامل محدوده‌های دمایی، درصد کسرهای حجمی و اندازه‌ی متوسط ذرات در جدول ۲ آورده شده است. نمودار مقایسه‌ی هدایت‌گرمایی نسبی تجربی و پیش‌بینی‌شده‌ی سامانه‌های نانوسیال مورد مطالعه برای داده‌های آموزش، ارزیابی و آزمون در شکل ۲ ارائه شده همان گونه که در این شکل مشخص است، مقدارهای پیش‌بینی‌شده و تجربی در تطابق خوبی با یکدیگر هستند که بیانگر درستی مدل استفاده شده در این پژوهش است. افزون بر این، انحراف مدل در مقایسه با مقدارهای تجربی هدایت گرمایی نسبی در شکل ۳ برای داده‌های آموزش، ارزیابی و تست ارائه شده است. همان‌طور که شکل‌های ۲ و ۳ نشان می‌دهند، دقت قابل‌قبولی از پیش‌بینی‌های هدایت گرمایی نسبی با استفاده از

آموزش شبکه توسط الگوریتم بهینه‌سازی لونیگ - مارکواد انجام می‌گیرد که به وسیله‌ی آن مقدارهای بهینه‌ی وزن‌ها و بایاس‌ها پیدا می‌شوند. از برتری‌های این الگوریتم سرعت و دقت آن در فرآیند آموزش شبکه‌ی عصبی می‌باشد. نوع‌های متفاوتی از تابع‌های انتقال مانند تابع انتقال خطی^۱، لوگ‌سیگ^۲ و تنسیگ^۳ برای شبکه‌های عصبی مصنوعی پیشنهاد شده‌اند [۵۴]. در مطالعه‌ی حاضر، ترکیب‌های متفاوتی از این تابع‌های انتقال آزموده شد تا بهترین تابع انتقال برای لایه‌های ورودی و خروجی انتخاب شوند. سرانجام، تابع‌های انتقال (tansig-purelin) با ۱۸ نورون کم‌ترین خطا را تولید کردند. بنابراین، این ساختار برای طراحی مدل ANN مورد استفاده قرار گرفت و ساختار بهترین شبکه به صورت (۵-۱۸-۱) به دست آمد. جدول (۱) وزن‌ها و بایاس‌های بهینه برای شبکه‌ی ANN مورد استفاده برای پیش‌بینی هدایت گرمایی نانوسیال‌های مورد مطالعه را نشان می‌دهد.

(۱) Levenberg-Marquardt
(۲) Purelin

(۳) Logsig
(۴) Tansig

جدول ۲- محدوده‌های دمایی، T، اندازه‌ی متوسط نانوذره‌ها، d، و درصد کسر حجمی، ϕ%، انواع سامانه‌های نانوسیال برای طراحی مدل ANN.

BF	NP	T(K)-range	d(nm)-range	ϕ%-range
DW	Al ₂ O ₃	۲۹۳/۳۳۳-۱۵/۲۰	۱۵۰-۱۱	۸-۰
	CuO	۲۷۸/۳۲۴-۱۵/۱۵	۲۳/۴۰-۶	۶-۰
	TiO ₂	۲۷۸/۳۱۸-۱۵/۱۵	۳۴-۱۰	۵-۰/۰۱۶
	SiC	۲۷۷/۲۹۵-۱۵/۱۵	۱۰۰-۲۶	۰/۴-۱۴۷/۱۸۹
	Cu	۲۹۸/۱۵	۲۰۰-۷۵	۰/۷-۱/۴۹
	Ag	۲۹۸/۱۵	۱۲	۰-۰/۳۹۶
	Silica	۲۹۸/۱۵	۱۸	۳-۰/۹۵۸
EG	Al ₂ O ₃	۲۹۳/۳۳۳-۱۵/۱۹	۹/۳۰۲-۸۷۳	۸-۰/۰۱۶
	CuO	۲۹۸-۲۹۷/۱۵	۲۳-۲۳/۶	۱۴-۰/۷۴۴
	TiO ₂	۲۹۳/۳۱۳-۱۵/۱۵	۲۶۰-۲۵	۱-۰/۸
	SiC	۲۷۷/۱۵	۲۶	۰/۳-۸۹۴/۴۹۳
	Cu	۲۹۸/۱۵	۲۰۰-۱۰	۲-۰
	Fe	۲۹۸/۱۵	۱۰	۰/۰-۲/۵۵
	UDD	۲۹۸/۱۵	۴۰	۱-۰/۳۲۶
	WO ₃	۲۹۸/۱۵	۳۸	۰/۰-۰۵/۳
EO	Al	۲۹۴/۳۳۳-۱۲/۱۷	۸۰	۳-۱
	Al ₂ O ₃	۲۹۷-۲۹۷/۱۵	۲۸	۷-۰/۵
Oil	Cu	۲۹۸/۱۵	۱۰۰	۲/۷-۵۰۸/۵۲۲

نسبی تجربی و پیش‌بینی شده، میانگین درصد خطای نسبی مطلق و تعداد داده‌های مورد استفاده برای نانوسیالات متفاوت را نشان می‌دهد. پارامترهای آماری بهترین ساختار شبکه (۵-۱۸-۱) برای داده‌های آموزش، ارزیابی و آزمون در جدول ۴ آورده شده‌اند.

مقایسه‌ی هدایت گرمایی پیش‌بینی شده توسط شبکه عصبی مصنوعی برای نانوسیال‌هایی با نانوذره‌های یکسان و نانوسیال‌های با سیال پایه یکسان

شکل ۴، مقایسه‌ی بین هدایت گرمایی نسبی تجربی و پیش‌بینی شده توسط مدل شبکه‌ی عصبی مصنوعی نانوسیال‌ها شامل نانوذره Al₂O₃ را با متوسط اندازه‌ی ذره‌ی ۲۸ نانومتر در سیال‌های پایه‌ی متفاوت آب خالص، اتیلن‌گلیکول و روغن موتور در دمای ۲۹۷/۱۵ کلوین نشان می‌دهد. همچنین، در شکل ۵ مقایسه بین هدایت گرمایی نسبی تجربی و پیش‌بینی شده‌ی مدل ANN برای نانوسیال‌ها شامل نانوذره‌های Fe و Cu با اندازه‌ی متوسط ذره‌ی ۱۰ نانومتر در سیال پایه اتیلن‌گلیکول در دمای ۲۹۸/۱۵ کلوین نشان داده شد. همان‌گونه که

مدل پیشنهادی برای انواع متفاوت نانوسیال‌های مورد مطالعه، به‌دست آمده است. دقت مدل در تکرارپذیری و پیش‌بینی هدایت گرمایی نسبی سامانه‌های نانوسیال را می‌توان توسط پارامترهای آماری [۵۷-۵۵]، مانند میانگین درصد خطای نسبی مطلق (AARD%)، میانگین درصد خطای نسبی (bias) و جذر میانگین مربعات خطا (RMSE) ارزیابی کرد. این پارامترها به صورت زیر تعریف می‌شوند:

$$\text{bias\%} = \frac{1}{N} \sum_{i=1}^N 100 \times \left(\frac{k_{\text{exp},i} - k_{\text{pre},i}}{k_{\text{exp},i}} \right) \quad (2)$$


$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (k_{\text{exp},i} - k_{\text{pre},i})^2} \quad (3)$$

$$\text{AARD\%} = \frac{1}{N} \sum_{i=1}^N 100 \times \left| \frac{k_{\text{exp},i} - k_{\text{pre},i}}{k_{\text{exp},i}} \right| \quad (4)$$


AARD% نشان می‌دهد که مقدارهای محاسبه شده تا چه اندازه به مقدارهای تجربی نزدیک هستند. bias%، توزیع داده‌های محاسبه شده را در اطراف نقطه‌های تجربی نشان می‌دهد. جدول ۳ محدوده‌ی هدایت گرمایی

جدول ۳- بازه‌های هدایت گرمایی نسبی تجربی و پیش‌بینی شده، میانگین درصد خطای نسبی مطلق (AARD%) و تعداد داده‌های مورد استفاده برای انواع نانوسیال‌های مورد مطالعه.

BF	NP	$(k_{NF}/k_{BF})^{exp}$ range	$(k_{NF}/k_{BF})^{pre}$ range	AARD%	N
DW	Al ₂ O ₃	۱/۱-۰۰۰/۲۹۸	۰/۱-۹۹۷/۲۸۹	۲/۷۴۰	۱۳۰
	CuO	۱/۱-۰۰۰/۵۶۲	۱/۱-۰۰۱/۵۱۰	۳/۵۹۱	۹۰
	TiO ₂	۱/۱-۰۰۰/۴۱۶	۱/۱-۰۰۳/۴۲۴	۲/۴۱۸	۹۹
	SiC	۱/۱-۰۲۷/۱۶۱	۱/۱-۰۲۵/۱۷۱	۱/۰۸۷	۱۰
	Cu	۱/۱-۱۱۰/۷۵۳	۱/۱-۱۰۴/۷۴۹	۰/۸۵۵	۶
	Ag	۱/۱-۰۰۰/۱۱۱	۱/۱-۰۵۴/۰۶۳	۳/۱۲۳	۵
	Silica	۱/۱-۰۰۰/۰۵۰	۱/۱-۰۲۸/۱۳۵	۶/۰۷۸	۵
EG	Al ₂ O ₃	۱/۱-۰۰۰/۴۷۷	۱/۱-۰۰۲/۴۷۹	۲/۲۲۴	۵۳
	CuO	۱/۱-۰۰۰/۵۷۴	۱/۱-۰۰۸/۵۴۷	۲/۸۴۹	۱۱
	TiO ₂	۱/۱-۰۰۰/۱۴۶	۱/۱-۰۰۱/۱۳۸	۰/۷۰۲	۲۲
	SiC	۱/۱-۰۴۱/۱۳۰	۱/۱-۰۳۶/۱۱۶	۱/۸۵۳	۴
	Cu	۱/۱-۰۰۰/۱۲۸	۰/۱-۹۸۰/۰۹۹	۱/۹۹۱	۱۰
	Fe	۱/۱-۱۳۴/۱۸۰	۱/۱-۱۳۰/۱۸۱	۰/۷۲۷	۸
	UDD	۱/۱-۰۰۰/۷۵۲	۱/۱-۰۶۶/۰۸۵	۱/۱۸۴	۵
WO ₃	۱/۱-۰۵۰/۱۳۴	۱/۱-۰۶۶/۰۸۵	۱/۹۱۸	۴	
EO	Al	۱/۱-۰۹۳/۳۶۹	۱/۱-۰۷۰/۳۷۵	۰/۹۲۸	۱۰
	Al ₂ O ₃	۱/۱-۰۰۰/۳۰۱	۱/۱-۰۰۶/۳۰۴	۰/۷۶۵	۸
Oil	Cu	۱/۱-۱۲۱/۴۳۰	۱/۱-۱۱۹/۴۲۹	۰/۱۰۸	۳



شکل ۲- نمودار مقایسه‌ی هدایت گرمایی نسبی تجربی و پیش‌بینی شده‌ی مدل ANN سامانه‌های نانوسیال مورد مطالعه.



شکل ۳. درصد خطای نسبی هدایت گرمایی نسبی محاسبه شده از مدل ANN در مقایسه با مقادیرهای تجربی نانوسیال‌های مورد مطالعه.

جدول ۴. پارامترهای آماری بهترین ساختار شبکه (۵-۱۸-۱).

Statistical parameters	
Training set	
R ²	۰/۸۳۱۷۲
AARD%	۲/۶۱۵۷۸
bias	۰/۲۸۲۹۶
RMSE	۰/۰۵۰۷۷
N	۳۳۹
Test set	
R ²	۰/۸۷۵۳۶
AARD%	۲/۲۵۹۶۴
bias	-۰/۳۳۳۸۲
RMSE	۰/۰۳۸۲۲
N	۷۲
Validation set	
R ²	۰/۸۹۴۸۶
AARD%	۲/۲۰۱۹۹
bias	۰/۳۱۰۷۲
RMSE	۰/۰۳۶۵۳
N	۷۲
Total	
R ²	۰/۸۴۵۳۸
AARD%	۲/۵۰۱۰۱
bias	۰/۱۹۵۱۶
RMSE	۰/۰۴۷۱۸
N	۴۸۳

این نمودارها نشان می‌دهند، توافق خوبی بین داده‌های تجربی و نتایج‌های پیش‌بینی‌شده‌ی به دست آمده از مدل ANN وجود دارد.

بررسی کارایی مدل شبکه‌ی عصبی مصنوعی و مدل‌های کلاسیکی شناخته شده در پیش‌بینی هدایت گرمایی نانوسیال‌های گوناگون

برای اثبات کارایی مدل ANN پیشنهادی در پیش‌بینی هدایت گرمایی نسبی سامانه‌های نانوسیال، برای هر کدام از سامانه‌های نانوسیال مورد مطالعه، مقادیرهای AARD% بین هدایت گرمایی نسبی تجربی و مقادیرهای پیش‌بینی‌شده‌ی مدل ANN و محاسبه‌شده‌ی مدل‌های ماکسول (معادله‌ی (۵)) و براگمن (معادله‌ی (۶)) در جدول ۵ آورده شده‌اند. مدل‌های ماکسول و براگمن به صورت زیر تعریف می‌شوند:


$$\frac{k_{nf}}{k_f} = \frac{k_p + 2k_f + 2(k_p - k_f)\phi}{k_p + 2k_f - (k_p - k_f)\phi} \quad (5)$$

$$\phi \left(\frac{k_p - k_{nf}}{k_p + 2k_{nf}} \right) + (1 - \phi) \left(\frac{k_p - k_{nf}}{k_p + 2k_{nf}} \right) = 0 \quad (6)$$


در این معادله‌ها، هدایت گرمایی سیال پایه، هدایت گرمایی نانوذره، هدایت گرمایی نانوسیال و کسر حجمی ذره به ترتیب به صورت k_f ، k_p ، k_{nf} و ϕ نشان داده شده‌اند. نمودارهای مقایسه‌ی بین هدایت گرمایی نسبی پیش‌بینی‌شده‌ی مدل ANN نانوسیال‌ها با سیال‌های پایه‌ی آب مقطر، روغن موتور، اتیلن گلیکول و روغن با مقادیرهای تجربی و همچنین با مقادیرهای محاسبه‌شده‌ی مدل‌های ماکسول و براگمن در شکل‌های ۶ تا ۹ آورده شده‌اند. همان گونه که در این نمودارها

جدول ۵ - مقایسه‌ی بین AARD% حاصل از مدل ANN، ماکسول و براگمن برای نانوسیال‌های متفاوت در پیش‌بینی هدایت گرمایی نسبی.





BF	NP	AARD%			N
		ANN	Maxwell model	Bruggeman model	
DW	Al ₂ O ₃	۲/۷۴۰	۴/۰۶۷	۴/۲۰۳	۱۳۰
	CuO	۳/۵۹۱	۷/۳۳۵	۷/۱۶۱	۹۰
	TiO ₂	۲/۴۱۸	۲/۹۴۰	۳/۷۱۶	۹۹
	SiC	۱/۰۸۷	۱/۳۸۳	۱/۲۴۲	۱۰
	Cu	۰/۸۵۵	۱۸/۸۶۰	۱۸/۱۹۲	۶
	Ag	۳/۱۲۳	۴/۷۶۰	۴/۷۹۰	۵
	Silica	۶/۰۷۸	۰/۸۰۴	۲/۴۶۶	۵
EG	Al ₂ O ₃	۲/۲۲۴	۴/۸۲۷	۴/۲۲۶	۵۳
	CuO	۲/۸۴۹	۲/۴۸۲	۴/۱۳۴	۱۱
	TiO ₂	۰/۷۰۲	۳/۲۴۸	۳/۸۲۶	۲۲
	SiC	۱/۸۵۳	۱/۲۹۳	۰/۹۴۲	۴
	Cu	۱/۹۹۱	۲/۹۷۶	۲/۹۳۹	۱۰
	Fe	۰/۷۲۷	۱۳/۰۵۶	۱۳/۱۱۶	۸
	UDD	۱/۱۸۴	۱۵/۵۶۶	۱۵/۵۵۴	۵
	WO ₃	۱/۹۱۸	۷/۳۱۸	۱۰/۰۵۱	۴
EO	Al	۰/۹۲۸	۱۲/۴۸۱	۱۲/۲۳۰	۱۰
	Al ₂ O ₃	۰/۷۶۵	۳/۹۵۸	۲/۸۵۲	۸
Oil	Cu	۰/۱۰۸	۸/۸۴۰	۷/۱۴۲	۳
Overall		۲/۵۰۱	۵/۰۰۶	۵/۱۶۱	۴۸۳

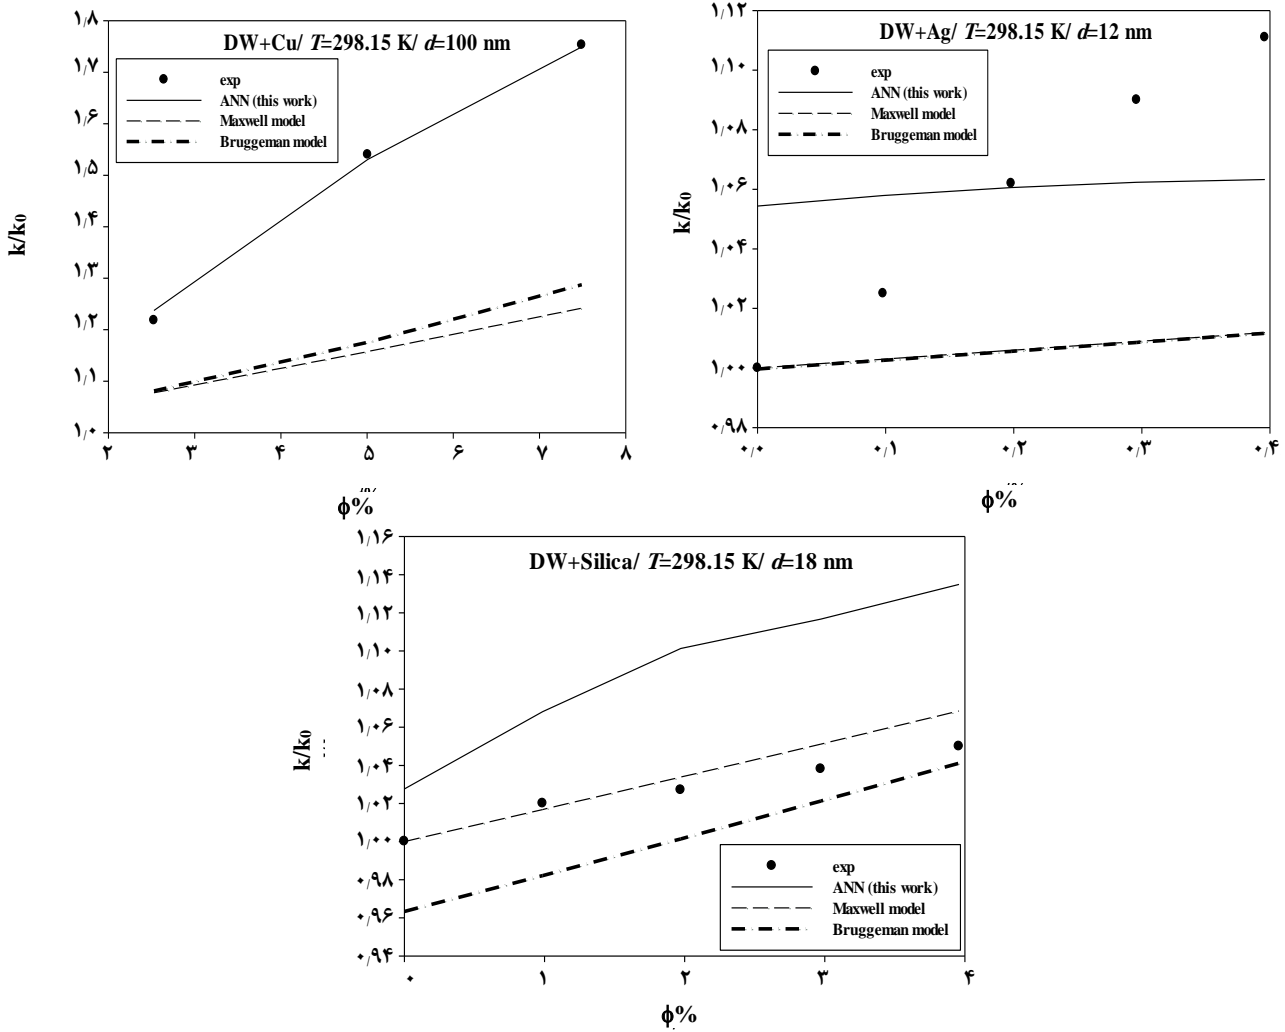


شکل ۴- مقایسه‌ی هدایت گرمایی نسبی تجربی و پیش‌بینی شده‌ی مدل ANN برای نانوسیال‌های شامل نانوذره‌ی Al₂O₃ با اندازه‌ی متوسط ذره‌ی ۲۸ نانومتر در سیال‌های پایه‌ی DW, EG, EO در دمای ۲۹۷/۱۵ کلوین.




شکل ۵ - مقایسه‌ی هدایت گرمایی نسبی تجربی و پیش‌بینی شده‌ی مدل ANN برای نانوسیال‌ها شامل نانوذره‌های Fe و Cu با متوسط اندازه‌ی ۱۰ نانومتر در سیال پایه EG در دمای ۲۹۸/۱۵ کلوین.















شکل ۶ - مقایسه‌ی هدایت گرمایی نسبی نانوسیال‌ها با سیال پایه‌ی آب با مقدارهای تجربی و پیش‌بینی شده با مدل‌های ماکسول و براگمن.




شکل ۷ - مقایسه‌ی هدایت گرمایی نسبی نانوسیال Cu در روغن با مقدارهای تجربی و پیش‌بینی شده با مدل‌های ماکسول و براگمن.



شکل ۸ - مقایسه‌ی هدایت گرمایی نسبی نانوسیال‌ها با سیال پایه‌ی اتیلن گلیکول با مقادیرهای تجربی و پیش‌بینی شده با مدل‌های ماکسول و براگمن.



شکل ۹. مقایسه‌ی هدایت گرمایی نسبی نانوسیال‌ها با سیال پایه‌ی روغن موتور با مقدارهای تجربی و پیش‌بینی شده با مدل‌های ماکسول و براگمن.



شکل ۱۰- ساختار مدل ANN مورد استفاده.

گروه ارزیابی برای بهینه‌سازی و گروه آزمون برای بررسی درستی و قابلیت پیش‌بینی مدل مورد استفاده قرار گرفتند. تعداد ۵۱۰ داده‌ی تجربی مورد استفاده برای طراحی شبکه‌ی مورد نظر در اینجا هم به‌صورت تصادفی به سه گروه ۷۰٪ برای آموزش، ۱۵٪ برای ارزیابی و ۱۵٪ برای آزمون تقسیم شدند.

شبکه‌ی عصبی مورد استفاده

در این قسمت از کار هم یک شبکه‌ی عصبی پیش‌خور با معماری پس‌انتشار مورد استفاده قرار گرفت، با این تفاوت که در این مدل گرانبوی نسبی نانوسیال‌ها به عنوان خروجی شبکه‌ی عصبی تعیین شد و پارامترهای موثر بر آن یعنی درصد کسر حجمی، دما، اندازه‌ی متوسط نانوذره، چگالی نسبی سیال پایه به نانوذره و گرانبوی سیال پایه به‌عنوان ورودی‌های شبکه‌ی عصبی انتخاب شدند. تابع هدف مورد استفاده‌ی ما

مشخص است، مدل ANN در بیشتر موارد بهتر از مدل‌های ماکسول و براگمن می‌تواند هدایت گرمایی نسبی نانوسیال مورد مطالعه را پیش‌بینی کند.

گرانبوی

پیش‌بینی گرانبوی نانوسیال‌ها به وسیله‌ی شبکه‌ی عصبی مصنوعی

داده‌های گرانبوی نانوسیال‌های مورد استفاده در این کار نیز از نتیجه‌های مطالعه‌های تجربی پژوهش‌های علمی بسیاری به‌دست آمده‌اند [۴۴-۳۴]. تمامی داده‌های ورودی در این کار از مطالعات تجربی جمع‌آوری شده‌اند و از داده‌های به دست آمده از مطالعه‌های نظری استفاده نشده است. نانوسیال‌ها انتخاب شده جهت مطالعه شامل چهار نوع سیال پایه و چهار نوع نانوذره هستند. این نانوسیال‌ها براساس نوع سیال پایه به چهار نوع، آب مقطر (سیال پایه) و $Al_2O_3, CuO, TiO_2, SiO_2$ (نانوذرات) [۵۸، ۲۰، ۱۹]، اتیلن‌گلیکول (سیال پایه) و Al_2O_3 (نانوذره) [۲۰]، PG (سیال پایه) و Al_2O_3 (نانوذره) [۲۱] و EG/DW (سیال پایه) و CuO (نانوذره) [۲۱] تقسیم‌بندی شده‌اند. سرانجام مجموعه‌ای از ۵۱۰ داده از ۷ نانوسیال متفاوت جمع‌آوری شد و با این داده‌ها یک شبکه‌ی عصبی پس‌انتشار پیش‌خور برای پیش‌بینی گرانبوی نسبی نانوسیال‌ها به‌عنوان تابعی از گرانبوی سیال پایه (η_{BF})، چگالی نسبی سیال پایه به نانوذره (ρ_{BF}/ρ_{NP})، دما (T)، سایز نانوذره (d_{nm}) و درصد کسر حجمی ($\phi\%$) طراحی شد. ساختار مدل شبکه‌ی عصبی مصنوعی (ANN) مورد استفاده در این پژوهش در شکل ۱۰ آورده شده است.

تقسیم داده‌ها

داده‌ها همانند قسمت پیش‌بینی هدایت گرمایی به سه زیر گروه آموزش، ارزیابی و آزمون تقسیم شدند و نقش هر گروه از داده‌ها به دقت به همان صورت پیشین، گروه آموزش برای ساختن ساختار شبکه‌ی عصبی،

جدول ۶ - وزن‌ها و بایاس‌های بهینه برای شبکه ANN مورد استفاده جهت پیش‌بینی گرانروی نانوسیال‌های مورد مطالعه.


وزنهای ورودی	گرانروی سیال پایه	نسبت چگالی سیال پایه به نانوذره	دما	اندازه نانوذره	درصد کسر حجمی	بایاس
نورون ۱	۱/۲۳۹۵۷۵	۰/۷۶۵۴۸۲	۰/۵۴۴۴۳۴	۲/۸۵۲۵۸	۱/۸۸۰۹۶۸	۲/۲۴۲۳۲۷
نورون ۲	۱/۳۵۷۵۵	۰/۶۸۳۶۷۹	۰/۱۴۵۹۲۳	۰/۴۹۸۰۲	۲/۱۷۶۹۷۴	۱/۳۳۲۶۴۳
نورون ۳	-۱/۵۹۱۳۹	۱/۶۴۱۰۴۱	۲/۰۳۹۳۹۶	-۰/۸۹۷۷	-۱/۷۴۱۹۵	۱/۵۶۱۹۹۳
نورون ۴	۱/۸۹۹۴۷۴	-۱/۰۹۵۴۲	-۰/۰۶۱۷	-۳/۷۲۶۸۱	۱/۱۴۶۹۶۸	۳/۰۹۳۳۹۳
نورون ۵	-۰/۹۵۵۳۴	-۰/۲۳۰۵۸	-۰/۱۳۸۸۹	-۰/۱۴۶۲۸	۱/۸۸۱۳۴۹۴	۱/۹۳۶۹۴۵
نورون ۶	۱/۴۵۹۰۲۳	-۱/۵۵۱۵۱	-۰/۱۷۷۵۳	۱/۳۴۵۵۷	-۲/۳۳۲۷۸	۰/۶۴۹۸۲۴
نورون ۷	-۳/۲۰۱۷۴	۱/۹۴۴۲۸	۲/۰۲۶۴۴۶	-۲/۰۸۵۷۱	-۰/۴۲۶۶۹	۲/۰۵۹۸۵۸
نورون ۸	-۰/۰۷۶۱۳	۰/۷۱۲۴۹۳	-۰/۳۴۷۶۶	-۳/۳۷۵۵۴	۱/۵۷۱۰۳۳	-۰/۱۴۱۸۱
نورون ۹	-۲/۵۵۱۴۶	-۱/۸۳۳۴۱	-۰/۳۶۶۷۷	۱/۸۴۹۰۶۲	۲/۴۸۱۷۳۹	۰/۷۴۸۹۸۸
نورون ۱۰	۰/۰۱۵۸۸۸	۰/۶۷۲۱۲۷	۰/۰۶۵۹۸۸	-۱/۲۶۹۵۲	-۳/۷۴۶۵۱	۱/۵۴۲۲۵۸
نورون ۱۱	-۲/۱۳۴۰۶	۲/۶۸۲۸۴۸	-۲/۱۹۶۳	-۰/۵۵۴۰۷	-۰/۱۴۰۸۷	۰/۹۲۶۶۹۵
نورون ۱۲	۰/۰۳۶۰۲۲	۰/۶۳۷۳۳۶	۰/۰۶۳۲۱	۲/۱۹۲۳۷	۳/۴۸۵۵۳۲	۰/۱۰۳۳۰۳
نورون ۱۳	-۲/۲۵۱۶۱	۰/۶۶۷۴۴۵	۰/۰۹۱۴۰۳	-۱/۳۳۲۹	-۱/۵۵۹۵۶	-۱/۰۳۹۳۲
نورون ۱۴	۱/۸۳۲۹۶۲	-۱/۰۸۷۳۹	۱/۸۰۳۵۷۵	۰/۷۲۵۷۹۲	-۶/۳۰۱۸۳	-۰/۸۶۱۹۱
نورون ۱۵	۱/۸۴۵۱۴۲	۰/۷۳۰۰۲۱	-۰/۰۳۰۲۱	-۳/۱۴۸۵۶	۰/۶۳۲۷۹	۱/۶۱۳۰۲۹
نورون ۱۶	-۰/۰۰۹۵۹	۰/۷۰۷۷۱۴	۱/۶۲۴۳۲۷	-۰/۷۹۳	-۳/۹۱۹۰۱	-۱/۱۰۲۷۷
نورون ۱۷	۱/۵۸۱۷۵۷۹	-۰/۳۶۹۳۴	۲/۰۸۹۹۵	۰/۴۲۳۰۹۴	۰/۷۲۳۷۵۹	۲/۸۳۶۵۴۵
نورون ۱۸	۱/۱۸۳۸۵	۰/۵۶۲۲۷	۱/۷۸۰۹۷۹	۰/۱۱۱۴۷۶	-۱/۸۲۳۲۲	۲/۸۴۷۲۹۷
نورون ۱۹	-۱/۹۰۵۱۴	۷/۲۶۴۳۱۹	-۰/۱۴۸۶۹	۰/۰۲۳۴۵	۰/۸۸۹۱۶۴	۴/۲۱۸۴۰۷

جدول ۷ - محدوده‌های دمایی، اندازه‌ی متوسط نانو ذره‌ها و درصد کسر حجمی انواع سامانه‌های نانوسیال برای طراحی مدل ANN.


BF	NP	T(K)-range	d(nm)-range	$\varphi\%$ -range
DW	Al ₂ O ₃	۲۸۳/۳۴۲-۱۵/۳۴	۴۷-۸	۰/۱۳-۰/۰۴۲
	CuO	۲۹۳/۳۳۹-۱۸/۴۲	۲۹	۰/۱۲-۰/۰۵۳/۰۲۰
	TiO ₂	۲۸۸/۳۰۸-۱۴/۲۴	۲۱	۰/۲-۲۰/۰۰۰
	SiO ₂	۲۹۳/۳۲۳-۰/۸/۳۰	۱۲	۰/۴-۴۵/۰۰۰
EG	Al ₂ O ₃	۲۸۳/۳۲۳-۱۵/۱۵	۴۳	۰/۰-۰/۱۵/۰۴۸
PG	Al ₂ O ₃	۳۰۳/۳۳۳-۰/۰/۳۰	۵۰-۲۷	۰/۳-۵۰/۰۰۰
EG + DW	CuO	۲۳۸/۳۲۳-۲۴/۱۳	۲۹	۱/۶-۰۰۰/۱۲۰

جدول ۸ - محدوده‌های گرانبوری نسبی تجربی و پیش‌بینی‌شده، میانگین درصد خطای نسبی مطلق (AARD%) و تعداد داده‌های مورد استفاده برای انواع نانوسیال‌های مورد مطالعه.

BF	NP	$(\mu_{NF}/\mu_{BF})^{exp}$ range	$(\mu_{NF}/\mu_{BF})^{pre}$ range	AARD%	N
DW	Al ₂ O ₃	۱/۵-۰۰۶۵/۴۶۳۸	۱/۵-۰۴۴۱/۶۶۰۹	۲/۹۲	۲۶۹
	CuO	۰/۲۱-۹۴۵۲/۷۹۳۵	۰/۲۱-۹۶۲۰/۷۷۸۷	۱/۹۵	۸۶
	TiO ₂	۱/۱-۰۲۸۲/۱۷۵۰	۱/۱-۰۰۱۵/۱۸۱۶	۱/۶۳	۱۵
	SiO ₂	۱/۵-۰۹۸۰/۲۰۶۹	۱/۵-۰۹۸۶/۱۵۰۵	۱/۳۷	۲۱
EG	Al ₂ O ₃	۱/۱-۲۰۵۴/۷۶۵۸	۱/۱-۴۰۳۰/۵۱۴۱	۹/۱۰	۲۷
PG	Al ₂ O ₃	۱/۱-۰۴۷۳/۳۷۷۵	۰/۱-۹۹۸۵/۳۹۶۳	۲/۷۸	۳۴
EG + DW	CuO	۱/۲-۰۳۵۵/۲۷۲۲	۰/۲-۹۹۴۴/۱۷۱۵	۲/۹۶	۵۸



شکل ۱۱ - نمودار مقایسه‌ی گرانبوری نسبی تجربی و پیش‌بینی‌شده‌ی مدل ANN سامانه‌های نانوسیال مورد مطالعه.



شکل ۱۲ - درصد خطای نسبی گرانبوری نسبی محاسبه‌شده از مدل ANN در مقایسه با مقدارهای تجربی نانوسیال‌های مورد مطالعه.

جدول ۹- پارامترهای آماری بهترین ساختار شبکه (۵-۱۹-۱).

Statistical parameters	
Training set	
R ²	۰/۹۹۸۰
AARD%	۲/۹۰۲۸
bias	-۰/۲۷۶۴
RMSE	۰/۱۳۸۷
N	۳۵۵
Test set	
R ²	۰/۹۹۹۲
AARD%	۳/۲۵۳۰
bias	۰/۱۹۵۵
RMSE	۰/۰۸۳۵
N	۷۸
Validation set	
R ²	۰/۹۹۵۳
AARD%	۳/۰۵۶۴
bias	۰/۰۱۲۴
RMSE	۰/۱۰۸۷
N	۷۷
Total	
R ²	۰/۹۹۸۱
AARD%	۲/۹۷۹۵
bias	-۰/۱۶۰۸
RMSE	۰/۱۲۷۶
N	۵۱۰

مقایسه‌ی گرانروی پیش‌بینی‌شده توسط شبکه‌ی عصبی مصنوعی برای نانوسیال‌هایی با نانوذره‌های یکسان

شکل ۱۳، مقایسه‌ی بین گرانروی نسبی تجربی و پیش‌بینی‌شده توسط مدل شبکه‌ی عصبی مصنوعی نانوسیال‌ها شامل نانوذره‌ی CuO با متوسط اندازه‌ی ۲۹ نانومتر را در سیال‌های پایه‌ی متفاوت آب خالص و اتیلن گلیکول / آب خالص در دمای ۳۰/۴/۰۰ کلوین، نشان می‌دهد. در این شکل توافق بسیار خوبی بین داده‌های تجربی و نتیجه‌های مدل ANN طراحی شده دیده می‌شود.

میانگین مربع خطاها (MSE) میان مقدارهای هدف (targets) و خروجی‌های شبکه‌ی عصبی (outputs) بوده و فرایند بهینه‌سازی به وسیله‌ی الگوریتم لونیگ - مارکواد انجام گرفته و توابع انتقال (tansig-purelin) با ۱۹ نورون کم‌ترین خطا را تولید کردند. سرانجام، این ساختار برای طراحی مدل ANN مورد استفاده قرار گرفت و ساختار بهترین شبکه به صورت (۵-۱۹-۱) به دست آمد. جدول ۶، وزن‌ها و بایاس‌های بهینه برای شبکه ANN مورد استفاده جهت پیش‌بینی گرانروی نانوسیال‌های مورد مطالعه را نشان می‌دهد.



مقایسه‌ی گرانروی پیش‌بینی‌شده‌ی نانوسیال‌ها توسط شبکه‌ی عصبی با مقدارهای تجربی

فهرستی از داده‌های تجربی نانوسیال‌های گوناگون مورد استفاده در مدل ANN شامل محدوده‌های دمایی، درصد کسرهای حجمی و اندازه‌ی متوسط ذره‌ها [۵۹-۶۲، ۴۳، ۳۸] در جدول ۷ آورده شده است. نمودار مقایسه‌ی بین گرانروی نسبی تجربی و پیش‌بینی‌شده‌ی سامانه‌های نانوسیال مورد مطالعه برای داده‌های آموزش، ارزیابی و آزمون در شکل ۱۱ ارایه شد. همان‌گونه که در این شکل مشخص است، مقدارهای پیش‌بینی‌شده و تجربی در تطابق خوبی با یکدیگر هستند که بیان‌گر صحت مدل استفاده شده در این پژوهش است. افزون بر این، انحراف مدل در مقایسه با مقدارهای تجربی گرانروی نسبی در شکل ۱۲ برای داده‌های آموزش، ارزیابی و آزمون ارایه شده است. همان‌گونه که شکل‌های ۱۱ و ۱۲ نشان می‌دهند، دقت قابل‌پذیرشی از پیش‌بینی‌های گرانروی نسبی با استفاده از مدل پیشنهادی برای انواع متفاوت نانوسیال مورد مطالعه، به دست آمده است.


همانند قسمت پیشین پژوهش، دقت مدل در تکرارپذیری و پیش‌بینی گرانروی نسبی سامانه‌های نانوسیال‌ها را می‌توان توسط پارامترهای آماری، مانند میانگین درصد خطای نسبی مطلق (AARD%)، درصد میانگین خطای نسبی (bias) و جذر میانگین مربعات خطا (RMSE) ارزیابی کرد (روابط (۲)، (۳) و (۴)). جدول ۸ بازه‌ی گرانروی نسبی تجربی و پیش‌بینی‌شده، میانگین درصد خطای نسبی مطلق و تعداد داده‌های مورد استفاده برای نانوسیال‌های متفاوت را نشان می‌دهد. همچنین، پارامترهای آماری بهترین ساختار شبکه (۵-۱۹-۱) برای داده‌های آموزش، ارزیابی و آزمون در جدول ۹ آورده شده‌اند. مقدارهای AARD% برای آموزش، ارزیابی و آزمون به ترتیب مقدارهای ۲/۹، ۳/۲ و ۳/۱ است. نتیجه‌ها نشان می‌دهند که مدل ANN می‌تواند به دقت آموزش داده شود و ساختار منتخب توانایی خوبی جهت پیش‌بینی گرانروی نسبی نانوسیال‌ها دارد.

جدول ۱۰- مقایسه‌ی بین $AARD\%$ حاصل از مدل ANN و مدل‌های کلاسیکی نانوسیال‌های متفاوت در پیش‌بینی گرانبوری نسبی.

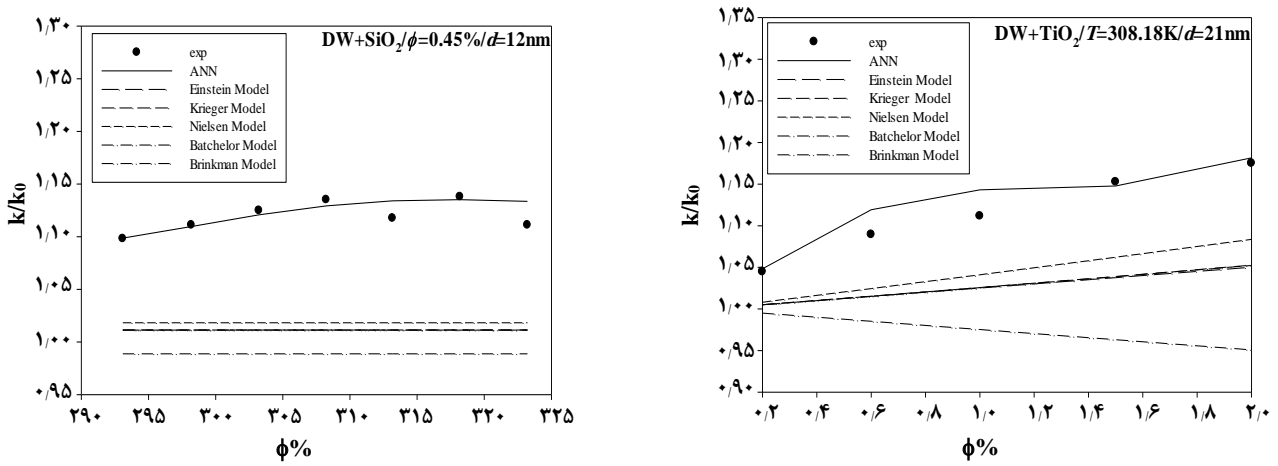
N	AARD%						NP	BF
	Brinkman Model	Batchelor model	Nielsen model	Krieger model	Einstein model	ANN		
۲۶۹	۴۷/۱۴	۳۵/۹۸	۳۲/۶۵	۳۶/۰۴	۳۶/۸۰	۲/۹۲	Al ₂ O ₃	DW
۸۶	۶۳/۴۶	۵۵/۹۰	۵۳/۷۶	۵۵/۹۴	۵۶/۴۷	۱/۹۵	CuO	
۱۵	۱۰/۱۱	۵/۲۴	۳/۹۲	۵/۲۶	۵/۳۳	۱/۶۳	TiO ₂	
۲۱	۴۷/۷۴	۴۴/۰۱	۴۲/۸۸	۴۴/۰۳	۴۴/۱۲	۱/۳۷	SiO ₂	
۲۷	۲۹/۹۹	۲۹/۸۹	۲۹/۸۵	۲۹/۸۹	۲۹/۸۹	۹/۱۰	Al ₂ O ₃	EG
۵۸	۲۹/۹۹	۱۷/۳۲	۱۳/۵۲	۱۷/۴۰	۱۷/۹۷	۲/۹۶	CuO	EG/DW(60:40)
۳۴	۱۹/۰۰	۱۱/۲۹	۸/۹۵	۱۱/۳۲	۱۱/۵۲	۲/۷۸	Al ₂ O ₃	PG
۵۱۰	۳۶/۲۴	۲۸/۲۹	۲۵/۹۴	۲۸/۳۳	۲۸/۷۰	۲/۲۷		Overall




شکل ۱۳- مقایسه‌ی گرانبوری نسبی تجربی و پیش‌بینی شده‌ی مدل ANN برای نانوسیال‌ها شامل نانوذره‌ی CuO با متوسط اندازه‌ی خوشه‌ی 29 نانومتر در سیال‌های پایه‌ی DW، EG/DW در دمای ۳۰۴/۰۰ کلوین.




شکل ۱۴- مقایسه‌ی گرانبوری نسبی نانوسیال‌ها با سیال پایه‌ی اتیلن گلیکول با مقدارهای تجربی و پیش‌بینی شده با مدل‌های کلاسیکی.



شکل ۱۵- مقایسه‌ی گرانشی نانوسیال‌ها با سیال پایه‌ی آب مقطر با مقدارهای تجربی و پیش‌بینی شده با مدل‌های کلاسیکی.



شکل ۱۶- مقایسه‌ی گرانشی نانوسیال‌ها با سیال پایه‌ی آب مقطر / اتیلن گلیکول با مقدارهای تجربی و پیش‌بینی شده با مدل‌های کلاسیکی.



شکل ۱۷- مقایسه‌ی گرانشی نانوسیال‌ها با سیال پایه‌ی پروپیلن گلیکول با مقدارهای تجربی و پیش‌بینی شده با مدل‌های کلاسیکی.

کلاسیکی در شکل‌های ۱۴ تا ۱۷ آورده شده‌اند. همان‌گونه که در این نمودارها مشخص است، مدل ANN در بیش‌تر موارد بهتر از مدل‌های کلاسیکی گرانروی نسبی نانوسیال مورد مطالعه را پیش‌بینی می‌کند.

نتیجه‌گیری

به‌طور کلی نتیجه‌های به دست آمده از این پژوهش، نشان دهنده‌ی قدرت و توانایی شبکه‌های عصبی مصنوعی در مدل کردن هدایت گرمایی و گرانروی سامانه‌های متفاوت نانوسیال با سیال‌های پایه و نانوذره‌های متفاوت و دقت بالاتر این روش‌ها نسبت به مدل‌های تجربی می‌باشد. در مورد هدایت گرمایی، ۴۸۳ داده‌ی تجربی جمع‌آوری و برای طراحی شبکه مورد استفاده قرار گرفت و ساختار شبکه به صورت (۵-۱۸-۱) کم‌ترین خطا را در پیش‌بینی هدایت گرمایی نانوسیال نشان داد و نتایج AARD% برای داده‌های آموزش، ارزیابی و تست به ترتیب ۲/۶، ۲/۲ و ۲/۳ به دست آمد. در شبکه‌ای که برای گرانروی نانوسیال‌های طراحی شد، ۵۱۰ داده‌ی تجربی مورد استفاده قرار گرفت و ساختار بهینه‌ی شبکه به صورت (۵-۱۹-۱) به دست آمد. نتیجه‌های AARD% برای داده‌های آموزش، ارزیابی و تست به ترتیب ۲/۹، ۳/۲ و ۳/۱ به دست آمد. مقایسه‌ای بین پیش‌بینی مدل‌های پیشنهادی و پیش‌بینی مدل‌های مرسوم مانند، ماکسول، براگمن، انیشتین، کریگر، نیلسن، و... (در مورد هدایت گرمایی) و مدل‌های انیشتین، کریگر، نیلسن، باتچلر و برینکمن (در مورد گرانروی) نشان داد که مدل‌های پیشنهادی این پژوهش در توافق بهتری با مقدارهای تجربی هستند. این دو مدل همچنین ما را در پیش‌بینی هدایت گرمایی و گرانروی نسبی نانوسیال‌های جدید با مشخصه‌های گوناگون توانمند می‌سازند.

بررسی کارایی مدل شبکه‌ی عصبی مصنوعی و مدل‌های کلاسیکی شناخته شده در پیش‌بینی گرانروی نانوسیال‌های گوناگون

برای اثبات نمایش کارایی مدل ANN پیشنهادی در پیش‌بینی گرانروی نسبی سامانه‌های نانوسیال، برای هر کدام از سامانه‌های نانوسیال مورد مطالعه، مقدارهای AARD% بین گرانروی نسبی تجربی و پیش‌بینی شده توسط مدل ANN و محاسبه شده با مدل‌های انیشتین (معادله‌ی (۷))، کریگر و همکاران (معادله‌ی (۸))، نیلسن (معادله‌ی (۹))، باتچلر (معادله‌ی (۱۰)) و برینکمن (معادله‌ی (۱۱)) در جدول ۱۲ آورده شده‌است. این مدل‌ها به صورت زیر می‌باشند.

$$\frac{\eta_{nf}}{\eta_{bf}} = 1 + 2.5\phi \quad (7)$$

$$\frac{\eta_{nf}}{\eta_{bf}} = \left(1 - \frac{\phi}{0.605}\right)^{-1.5} \quad (8)$$

$$\frac{\eta_{nf}}{\eta_{bf}} = (1 + 1.5\phi)e^{\phi/(0.395)} \quad (9)$$

$$\frac{\eta_{nf}}{\eta_{bf}} = 1 + 2.5\phi + 6.5\phi^2 \quad (10)$$

$$\frac{\eta_{nf}}{\eta_{bf}} = (1 - \phi)^{2.5} \quad (11)$$

در این معادله‌ها، η_{nf} ، η_{bf} و ϕ به ترتیب گرانروی سیال پایه، گرانروی نانوسیال و کسر حجمی نانوذره می‌باشند. نمودارهای مقایسه بین گرانروی نسبی پیش‌بینی شده توسط مدل ANN نانوسیال‌ها با سیال‌های پایه‌ی آب مقطر، اتیلن گلیکول، آب مقطر/ اتیلن گلیکول و پروپیلن گلیکول با مقدارهای تجربی و همچنین با مقدارهای پیش‌بینی شده‌ی مدل‌های

تاریخ دریافت: ۱۳۹۶/۷/۲ ؛ تاریخ پذیرش: ۱۳۹۷/۵/۶

مراجع

- [1] Ghadimi A., Saidur R., Metselaar, H. A Review of Nanofluid Stability Properties and Characterization in Stationary Conditions, *Int. J. Heat Mass Transfer* **54**: 4051-4068 (2011).
- [2] Paul, G.; Philip, J.; Raj B., Das P.K., Manna I., *Synthesis, Characterization, and Thermal Property Measurement of Nano-Al 95 Zn 05 Dispersed Nanofluid Prepared by a Two-Step Process*, *Int. J. Heat Mass Transfer* **54**: 3783-3788 (2011).

- [3] Suresh, S.; Venkataraj, K.; Selvakumar, P.; Chandrasekar, M. *Synthesis of Al₂O₃-Cu/water Hybrid Nanofluids Using Two Step Method and Its Thermo Physical Properties*, *Colloid. Surface. A.* **388**: 41-48 (2011).
- [4] Ding, Y.; Wen, D. *Particle Migration in a Flow of Nanoparticle Suspensions*, *Powder Technol.* **149**: 84-92 (2005).
- [5] Koo J., Kleinstreuer C., *Impact Analysis of Nanoparticle Motion Mechanisms on the Thermal Conductivity of Nanofluids*, *Int. Commun. Heat Mass Transfer* **32**: 1111-1118 (2005).
- [6] Wen D., Ding Y., *Effect of Particle Migration on Heat Transfer in Suspensions of Nanoparticles Flowing Through Minichannels*, *Microfluidics Nanofluidics* **1**: 183-189 (2005).
- [7] Lee D., Kim J.-W., Kim B.G., *A new Parameter to Control Heat Transport in Nanofluids: Surface Charge State of the Particle in Suspension*, *J. Phys. Chem. B* **110**: 4323-4328 (2006).
- [8] Vadasz P., *Heat Conduction in Nanofluid Suspensions*, *J. Heat Transfer* **128**: 465-477 (2006).
- [9] Wang B.-X., Zhou L.-P., Peng X.-F., *A fractal Model for Predicting the Effective Thermal Conductivity of Liquid With Suspension of Nanoparticles*, *Int. J. Heat Mass Transfer* **46**: 2665-2672 (2003).
- [10] Mansour R.B., Galanis N., Nguyen C.T., *Effect of Uncertainties in Physical Properties on Forced Convection Heat Transfer With Nanofluids*, *Appl. Therm. Eng.* **27**: 240-249 (2007).
- [۱۱] کریمی زاد گوهری، فاطمه؛ شاهسوند، اکبر، بررسی عملکرد شبکه عصبی مصنوعی MLP، RBF و ORN در یک کانال افقی همراه با انتقال جرم و انتقال حرارت همزمان، نشریه شیمی و مهندسی شیمی ایران، (۲) ۳۵: ۱۵۱ تا ۱۶۸ (۱۳۹۵).
- [۱۲] ذوقی، محمدجواد؛ گنجی دوست، حسین؛ مختارانی، نادر؛ آیتی، بیتا، بهینه سازی فرایند تثبیت و جامدسازی سیمانی لجن صنایع آبکاری توسط شبکه عصبی مصنوعی و روش سطح پاسخ، نشریه شیمی و مهندسی شیمی ایران، (۲) ۳۴: ۹۷ تا ۱۰۹ (۱۳۹۴).
- [۱۳] ترجمان نژاد، علی؛ یاسم، مهناز، پیش بینی حلالیت اکسیژن در حلال های آلی با استفاده از شبکه عصبی مصنوعی، نشریه شیمی و مهندسی شیمی ایران، (۱) ۳۳: ۴۹ تا ۵۵ (۱۳۹۳).
- [۱۴] حسن آبادی، مرتضی؛ مطهری، سید مهدیا؛ ندری پری، مهدی، طراحی شبکه عصبی برای بهینه سازی اندازه سطح مقطع شیرهای درون چاهی با اندازه ی ثابت درچاه هوشمند با الگوریتم پرندگان، نشریه شیمی و مهندسی شیمی ایران، (۲) ۳۱: ۵۵ تا ۶۹ (۱۳۹۱).
- [15] Yousefi F., Mohammadiyan S., Karimi H., *Application of Artificial Neural Network and PCA to Predict the Thermal Conductivities of Nanofluids*. *Heat Mass Transfer*, **52**: 2141-2154 (2016).
- [16] Yousefi F., Karimi H., Mohammadiyan S., *Viscosity of Carbon Nanotube Suspension Using Artificial Neural Networks with Principal Component Analysis*. *Heat Mass Transfer*, **52**: 2345-2355 (2016).
- [17] Yousefi F., Amoozandeh Z., *Statistical Mechanics and Artificial Intelligence to Model the Thermodynamic Properties of Pure and Mixture of Ionic Liquids*. *Chin. J. Chem. Eng.* **24**: 1761-1771 (2016).

- [18] Zolfaghari H., Yousefi F., Thermodynamic Properties of Lubricant/refrigerant Mixtures Using Statistical Mechanics and Artificial Intelligence. *Int. J. Refrig.* **80**: 130–144 (2017).
- [19] Papari M.M., Yousefi F., Moghadasi J., Karim H., Campo A., [Modeling Thermal Conductivity Augmentation of Nanofluids Using Diffusion Neural Networks](#), *Int. J. Therm. Sci.*, **50**: 44-52 (2011).
- [20] Hojjat M., Etemad S.G., Bagheri R., Thibault J., [Thermal Conductivity of Non-Newtonian Nanofluids: Experimental Data and Modeling Using Neural Network](#), *Int. J. Heat Mass Transfer*, **54**: 1017-1023 (2011).
- [21] Yousefi F., Karimi H., Papari M.M., [Modeling Viscosity of Nanofluids Using Diffusional Neural Networks](#), *J. Mol. Liq.* **175**: 85-90 (2012).
- [22] Kurt H., Kayfeci M., [Prediction of Thermal Conductivity of Ethylene Glycol–Water Solutions by Using Artificial Neural Networks](#), *Appl. Energy*, **86**: 2244-2248 (2009).
- [23] Longo G.A., Zilio C., Ceseracciu E., Reggiani, M. [Application of Artificial Neural Network \(ANN\) for the Prediction of Thermal Conductivity of Oxide–Water Nanofluids](#), *Nano Energy*, **1**: 290-296 (2012).
- [24] Zhao N., Wen X., Yang J., Li S., Wang Z., [Modeling and Prediction of Viscosity of Water-Based Nanofluids by Radial Basis Function Neural Networks](#), *Powder Technol.*, **281**: 173-183 (2015).
- [25] Esfe M.H., [Designing an Artificial Neural Network Using Radial Basis Function \(RBF-ANN\) to Model Thermal Conductivity of Ethylene Glycol–Water-Based TiO₂ Nanofluids](#), *J. Therm. Anal. Calorim.*, **127**: 2125-2131 (2017).
- [26] Safamirzaei M., Modarress H., [Correlation and Predicting of Low Pressure Solubility of Gases in \[bmim\]\[PF6\] by Neural Network Molecular Modeling](#), *Thermochimica Acta*, **545**: 125-130 (2012).
- [27] Lee S., Choi S.S., Li S., Eastman J., [Measuring Thermal Conductivity of Fluids Containing Oxide Nanoparticles](#), *J. Heat Transfer*, **121**: 280-289 (1999).
- [28] Xuan Y., Li Q., [Heat Transfer Enhancement of Nanofluids](#), *Int. J. Heat Fluid Flow*, **21**: 58-64 (2000).
- [29] Lee D., Kim J.W., Kim B.G., [A New Parameter to Control Heat Transport in Nanofluids: Surface Charge State of the Particle in Suspension](#), *J. Phys. Chem. B* **110**: 4323-4328 (2006).
- [30] Kang H.U., Kim S.H., Oh J.M., [Estimation of Thermal Conductivity of Nanofluid Using Experimental Effective Particle Volume](#), *Exp. Heat Transfer* **19**: 181-191 (2006).
- [31] Wang X., Xu X., Choi S.U., [Thermal Conductivity of Nanoparticle-Fluid Mixture](#), *J. Thermophys. Heat Transfer* **13**: 474-480 (1999).
- [32] Das S.K., Putra N., Thiesen P., Roetzel W., [Temperature Dependence of Thermal Conductivity Enhancement for Nanofluids](#), *J. Heat Transfer*, **125**: 567-574 (2003).
- [33] Xie H., Wang J., Xi T., Liu Y., Ai F., Wu Q., [Thermal Conductivity Enhancement of Suspensions Containing Nanosized Alumina Particles](#), *J. Appl. Phys.*, **91**: 4568-4572 (2002).
- [34] Wen D., Ding Y., [Experimental Investigation Into Convective Heat Transfer of Nanofluids at the Entrance Region Under Laminar Flow Conditions](#), *Int. J. Heat Mass Transfer* **47**: 5181-5188 (2004).

- [35] Chon C.H., Kihm K.D., Lee S.P., Choi S.U., [Empirical Correlation Finding the Role of Temperature and Particle Size for Nanofluid \(\$\text{Al}_2\text{O}_3\$ \) Thermal Conductivity Enhancement](#), *Appl. Phys. Lett.*, **87**: 3107 (2005).
- [36] Murshed S., Leong K., Yang C., [Enhanced Thermal Conductivity of \$\text{TiO}_2\$ —Water Based Nanofluids](#), *Int. J. Therm. Sci.*, **44**: 367-373 (2005).
- [37] Liu M.S., Lin M.C.C., Tsai C., Wang C.C., [Enhancement of Thermal Conductivity with Cu for Nanofluids Using Chemical Reduction Method](#), *Int. J. Heat Mass Transfer*, **49**: 3028-3033 (2006).
- [38] Li C.H., Peterson G., [The Effect of Particle Size on the Effective Thermal Conductivity of \$\text{Al}_2\text{O}_3\$ -Water Nanofluids](#), *J. Appl. Phys.*, **101**: 44312 (2007).
- [39] Yoo D.H., Hong K., Yang H.S., [Study of Thermal Conductivity of Nanofluids for the Application of Heat Transfer Fluids](#), *Thermochim. Acta*, **455**: 66-69 (2007).
- [40] Lu W.Q., Fan Q.M., [Study for the Particle's Scale Effect on Some Thermophysical Properties of Nanofluids by a Simplified Molecular Dynamics Method](#), *Eng. Anal. Bound. Elem.*, **32**: 282-289 (2008).
- [41] Murshed S., Leong K., Yang C., [Investigations of Thermal Conductivity and Viscosity of Nanofluids](#), *Int. J. Therm. Sci.*, **47**: 560-568 (2008).
- [42] Anoop K., Sundararajan T., Das S.K., [Effect of Particle Size on the Convective Heat Transfer in Nanofluid in the Developing Region](#), *Int. J. Heat Mass Transfer*, **52**: 2189-2195 (2009).
- [43] Duangthongsuk W., Wongwises S., [Measurement of Temperature-Dependent Thermal Conductivity and Viscosity of \$\text{TiO}_2\$ -Water Nanofluids](#), *Exp. Therm Fluid Sci.*, **33**: 706-714 (2009).
- [44] Turgut A., Tavman I., Chirtoc M., Schuchmann H., Sauter C., Tavman S., [Thermal Conductivity and Viscosity Measurements of Water-Based \$\text{TiO}_2\$ Nanofluids](#), *Int. J. Thermophys.*, **30**: 1213-1226 (2009).
- [45] Chandrasekar M., Suresh S., Bose A.C., [Experimental Investigations and Theoretical Determination of Thermal Conductivity and Viscosity of \$\text{Al}_2\text{O}_3\$ /Water Nanofluid](#), *Exp. Therm Fluid Sci.*, **34**: 210-216 (2010).
- [46] Duangthongsuk W., Wongwises S., [An Experimental Study on the Heat Transfer Performance and Pressure Drop of \$\text{TiO}_2\$ -Water Nanofluids Flowing Under a Turbulent Flow Regime](#), *Int. J. Heat Mass Transfer*, **53**: 334-344 (2010).
- [47] Lee S.W., Park S.D., Kang S., Bang I.C., Kim J.H., [Investigation of Viscosity and Thermal Conductivity of SiC Nanofluids for Heat Transfer Applications](#), *Int. J. Heat Mass Transfer*, **54**: 433-438 (2011).
- [48] Pastoriza-Gallego M.J., Lugo L., Legido J.L., Piñeiro M.M., [Thermal Conductivity and Viscosity Measurements of Ethylene Glycol-Based \$\text{Al}_2\text{O}_3\$ Nanofluids](#), *Nanoscale Res. Lett.*, **6**: 1-11 (2011).
- [49] Wen D., Ding Y., [Formulation of Nanofluids for Natural Convective Heat Transfer Applications](#), *Int. J. Heat Fluid Flow*, **26**: 855-864 (2005).

- [50] Eastman J.A., Choi S., Li S., Yu W., Thompson L., [Anomalously Increased Effective Thermal Conductivities of Ethylene Glycol-Based Nanofluids Containing Copper Nanoparticles](#), *Appl. Phys. Lett.* **78**: 718-720 (2001).
- [51] Hong T.K., Yang H.S., Choi C., [Study of the Enhanced Thermal Conductivity of Fe Nanofluids](#), *J. Appl. Phys.*, **97**: 064311 (2005).
- [52] Chen H., Ding Y., He Y., Tan C., [Rheological Behaviour of Ethylene Glycol Based Titania Nanofluids](#), *Chem. Phys. Lett.*, **444**: 333-337 (2007).
- [53] Chen H., Ding Y., Lapkin A., Fan X., [Rheological Behaviour of Ethylene Glycol-Titanate Nanotube Nanofluids](#), *J. Nanopart. Res.*, **11**: 1513-1520 (2009).
- [54] Gharagheizi F., [QSPR Analysis for Intrinsic Viscosity of Polymer Solutions by Means of GA-MLR and RBFNN](#), *Comput. Mater. Sci.*, **40**: 159-167 (2007).
- [55] Giuliani G., Kumar S., Zazzini P., Polonara F., [Vapor Pressure and Gas Phase PVT Data and Correlation for 1, 1, 1-Trifluoroethane \(R143a\)](#), *J. Chem. Eng. Data* **40**: 903-908 (1995).
- [56] Li J., Tillner-Roth R., Sato H., Watanabe K., [An Equation of State for 1, 1, 1-Trifluoroethane \(R-143a\)](#), *Int. J. Thermophys.* **20**: 1639-1651 (1999).
- [57] Amato F., González-Hernández J.L., Havel J., [Artificial Neural Networks Combined with Experimental Design: A “Soft” Approach for Chemical Kinetics](#), *Talanta*, **93**: 72-78 (2012).
- [58] Vasileva-Stojanovska T., Vasileva M., Malinovski T., Trajkovik V., [An ANFIS Model of Quality of Experience Prediction in Education](#), *Appl. Soft Comput.* **34**: 129-138 (2015).
- [59] Prasher R., Song D., Wang J., Phelan P., [Measurements of Nanofluid Viscosity and Its Implications for Thermal Applications](#), *Appl. Phys. Lett.* **89**: 133108 (2006).
- [60] Namburu P.K., Kulkarni D.P., Misra D., Das D.K., [Viscosity of Copper Oxide Nanoparticles Dispersed in Ethylene Glycol and Water Mixture](#), *Exp. Therm Fluid Sci.*, **32**: 397-402 (2007).
- [61] Nguyen C., Desgranges F., Roy G., Galanis N., Maré T., Boucher S., Mintsa H.A., [Temperature and Particle-Size Dependent Viscosity Data for Water-Based Nanofluids—Hysteresis Phenomenon](#), *Int. J. Heat Fluid Flow* **28**: 1492-1506 (2007).
- [62] Tavman I., Turgut A., Chirtoc M., Schuchmann H., Tavman S., [Experimental Investigation of Viscosity and Thermal Conductivity of Suspensions Containing Nanosized Ceramic Particles](#), *Arch. Mater. Sci.* **34**: 99-104 (2008).