

مدل سازی رسانندگی حرارتی نانوسیال های حاوی نانولوله های کربنی بر پایه اتیلن گلیکول با استفاده از شبکه عصبی پرسپترون چند لایه ای

آمنه آهانگرپور^{۱*} و منصور فرید^۲

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۳۹۷/۱۰/۳۰ پذیرش مقاله: ۱۳۹۸/۰۴/۰۵	در تحقیق قبلی انجام شده [۱]، نانوسیال ها با استفاده از نانولوله های کربنی اولیه و نانولوله های کربنی عامل دار با زمان های رفلکس یک، دو و چهار ساعت و غلظت های ۰/۱، ۰/۲۵ و ۰/۵ درصد حجمی تهیه و رسانندگی حرارتی آن ها در دماهای ۲۰، ۳۰، ۴۰ و ۵۰ درجه ی سانتی گراد اندازه گیری شد. به دلیل پرهزینه و زمان بر بودن کارهای تجربی، معمولاً امکان بررسی گسترده آن ها وجود ندارد. یکی از بهترین روش ها برای بررسی کم هزینه و گسترده ی کارهای تجربی، استفاده از روش های مدل سازی است. از جمله این روش ها، روش شبکه های عصبی مصنوعی است که از مدل های اولیه ی فرآیندهای حسی مغز الهام می گیرد. با استفاده از شبکه های عصبی مصنوعی می توان آزمایشگاهی مجازی طراحی و نتایج را برای شرایط مشابه که به صورت تجربی اندازه گیری نشده اند، پیش بینی نمود. در این تحقیق، جهت طراحی آزمایشگاه مجازی و مدل سازی داده های تجربی شامل نتایج اندازه گیری رسانندگی حرارتی نانوسیال های حاوی نانولوله های کربنی بر پایه اتیلن گلیکول از شبکه عصبی پرسپترون چند لایه ای (MLP) استفاده گردید. جهت رسیدن به حداقل خطا، شبکه های عصبی با تعداد لایه های مخفی متفاوت (۱، ۲ و ۳ لایه) و تعداد نرون های متفاوت در هر لایه (۲، ۳، ۴، ۵، ۶، ۱۰ و ۱۵ نرون) مورد بررسی قرار گرفتند. کمترین درصد خطا که ۶/۵٪ بود برای شبکه عصبی شامل دو لایه مخفی که لایه اول دارای ۳ نرون و لایه دوم دارای ۲ نرون بود، به دست آمد. سپس از این شبکه جهت پیش بینی نتایج در شرایط نزدیک به شرایط آزمایش، استفاده شد و مشاهده گردید که نتایج پیش بینی شده با نتایج تجربی به دست آمده، سازگاری دارند.

۱-مقدمه

خود جلب کرده است. شبکه های عصبی مصنوعی از مدل های اولیه ی فرایندهای حسی مغز الهام گرفته شده اند. مغز انسان پیچیده ترین چیزی است که تاکنون زیاد مطالعه شده ولی با این حال در مجموع چندان شناخته شده نیست. شاید یکی از بارزترین ویژگی های مغز، توان فراگیری آن باشد. مغز می تواند به خود آموزش دهد. نرون، عنصر اصلی مغز است و به تنهایی مانند یک واحد پردازش منطقی عمل

یکی از بهترین روش های موجود برای بررسی مسائل مختلف، مدل سازی رایانه ای است. روش های مدل سازی به دلیل کم هزینه بودن و کنترل پذیر بودن نسبت به روش های آزمایشگاهی دارای برتری هستند. شبکه های عصبی مصنوعی یکی از پویاترین حوزه های تحقیق در دوران معاصر می باشد که افراد متعددی از رشته های گوناگون علمی را به

* پست الکترونیک نویسنده مسئول: a.ahangarpour@scu.ac.ir

۱. استادیار، گروه فیزیک، دانشکده علوم، دانشگاه شهید چمران اهواز، اهواز.

۲. استاد، گروه فیزیک، دانشکده علوم، دانشگاه شهید چمران اهواز، اهواز.

نانوسیال ها، نوع جدیدی از مواد مهندسی هستند که شامل ذرات نانو اندازه ی پراکنده شده در یک سیال پایه (آب، اتیلن گلیکول، روغن و ...) می باشند. نانوسیال ها در مقایسه با سوسپانسیون های معمول، دارای رسانندگی حرارتی بالاتر و اثرات خوردگی کمتری هستند. نانوذرات پراکنده شده در سیال های پایه، ممکن است نانوذرات فلزی (Ag, Au, Fe, Al, Cu) یا غیر فلزی (SiO_2 , SiC , TiO_2 , Fe_3O_4 , CuO , Al_2O_3) نانوفیبرها، نانومیله ها یا نانولوله ها باشند. به دلیل این که نانولوله های کربنی دارای رسانندگی حرارتی بسیار بالا (حدود 3000 W/m.K) و نسبت ظاهری بزرگ هستند، گزینه ای مناسب برای افزایش رسانندگی حرارتی سیال های پایه می باشند و توجه بسیاری از محققان به آن ها معطوف شده است.

در سال ۲۰۱۱، پپری و همکاران [۷]، مدل شبکه ی عصبی را برای تخمین رسانندگی حرارتی نانوسیال های حاوی نانولوله های کربنی چند جداره (MWCNTs) معلق شده در روغن، آب مقطر و اتیلن گلیکول و همچنین نانولوله های کربنی تک جداره (SWCNTs) در اپوکسی و پلی متیل متاکریل (PMMA) به کار بردند. نتایج به دست آمده با دیگر مدل های نظری و نیز با مقادیر تجربی مورد مقایسه قرار گرفتند و مشاهده شد رسانندگی های حرارتی پیش-گویی شده در توافق خوبی با مقادیر اندازه گیری شده در مقالات مختلف بوده است. در سال ۲۰۱۶، احمدلو و همکاران [۱۲] از یک شبکه ی عصبی مصنوعی با ۵ ورودی (قطر متوسط، کسر حجمی و رسانندگی حرارتی نانوذرات، رسانندگی حرارتی سیال پایه و دما) و یک خروجی (نسبت رسانندگی حرارتی نانوسیال به سیال پایه) برای پیش گویی رسانندگی حرارتی ۱۵ نوع نانوسیال مختلف که اطلاعات آن ها را از ۲۱ مقاله دریافت کرده بودند، استفاده نمودند. نتایج آن ها با درصد خطای مطلق متوسط ۱/۲۶٪ و ۱/۴۴٪ به صورت قابل قبولی قادر به پیشگویی نتایج تجربی بود. در سال ۲۰۱۶، همت اسفه و همکاران [۱۳ و ۲۰] از یک مدل شبکه عصبی پیش خور با سه لایه، برای پیشگویی رسانندگی حرارتی نانوسیالات حاوی نانولوله های کربنی عامل دار شده بر پایه آب بر مبنای داده های تجربی، استفاده نمودند. مقادیر تجربی رسانندگی حرارتی برای شش غلظت

می کند. یک شبکه ی عصبی مصنوعی می تواند با شبیه سازی شبکه ای از نرون های مدل در یک رایانه ساخته شود. با اعمال الگوریتم هایی که فرایندهای نرون های واقعی را تقلید می کنند، می توانیم شبکه ای را بسازیم که برای حل بسیاری از انواع مسائل آموزش دیده است. آنچه این مدل ها را قابل استفاده می کند، توانایی آن ها در فراگیری است. روش های فراگیری باید تا حد امکان ساده باشند که بهترین راه، الهام گرفتن از سیستم های عصبی واقعی است. نرون های مدل، که به طریقی ساده به یکدیگر متصل اند، پرسپترون^۱ نامیده می شوند. انواع مختلفی از شبکه های عصبی مصنوعی وجود دارند که یکی از پرکاربردترین آن ها، پرسپترون چند لایه ای^۲ (MLP) است. این شبکه، سه لایه دارد. یک لایه ی ورودی^۳، یک لایه ی خروجی^۴ و یک لایه بین آن ها که مستقیماً به داده های ورودی و نتایج خروجی متصل نیست. در واقع این لایه را لایه ی پنهان^۵ می نامند. روش کلی آموزش در شبکه های عصبی چند لایه ای به این صورت است که وقتی به شبکه ی آموزش ندیده ای الگویی را عرضه می کنیم، خروجی های تصادفی تولید می کند. ابتدا باید تابع خطایی را تعریف کنیم که تفاوت خروجی واقعی و خروجی مطلوب را نشان دهد. چون خروجی مطلوب مشخص است، این نوع فراگیری را فراگیری با سرپرست می نامند. برای موفق شدن در آموزش شبکه، باید خروجی آن به تدریج به خروجی مطلوب نزدیک شود. به عبارت دیگر باید میزان تابع خطا به طور دائم کاهش داده شود. برای این منظور ضرایب وزنی خطوط ارتباطی واحدها، تغییر داده می شوند [۲-۵].

به دلیل توانایی منحصر بفرد شبکه های عصبی در کسب مفاهیم از اطلاعات پیچیده و مبهم، از آن ها می توان به عنوان الگوهای مناسبی برای مسائلی که پیچیده تر از آن هستند که توسط انسان یا کامپیوترهای معمولی قابل حل باشند، استفاده نمود. از آن جایی که شبکه های عصبی راه حل های بسیار منطقی تری را ارائه می دهند، در بسیاری از کاربردهای مهندسی مورد استفاده قرار می گیرند. خصوصاً با مشاهده ی مقالات مختلف، معلوم شده است که استفاده از شبکه های عصبی مصنوعی در تجزیه و تحلیل خواص حرارتی نانوسیال های مختلف به کار گرفته شده اند [۶-۲۰].

⁴ Output Layer

⁵ Hidden Layer

¹ Perceptron

² Multilayer Perceptron

³ Input Layer

نانولوله‌های کربنی عامل‌دار با طول‌های مختلف را مورد بررسی قرار داد. در ادامه به جای متغیر طول نانولوله‌های کربنی از زمان رفلاکس استفاده شده است. شبکه‌های عصبی با تعداد نرون‌ها و تعداد لایه‌های پنهان متفاوت در بخش آموزش شبکه مورد بررسی قرار گرفتند و با در نظر گرفتن درصد خطای مقادیر پیش‌بینی شده در بخش سنجش شبکه، مناسب‌ترین شبکه عصبی انتخاب شد. سپس با استفاده از شبکه به دست آمده، شرایطی نزدیک به آزمایش‌های انجام شده مورد بررسی قرار گرفتند و نتایج پیش‌بینی شده توسط شبکه عصبی با نتایج تجربی موجود مقایسه گردید و مشاهده شد که با روند تغییرات آن‌ها در توافق خوبی است.

۲- روش کار


۲-۱- آماده سازی نانوسیال‌ها و اندازه‌گیری

رسانندگی حرارتی

داده‌های تجربی مورد استفاده در شبکه عصبی مصنوعی، داده‌های مربوط به تحقیق قبلی انجام شده بود [۱]. در تحقیق قبلی از روش دو مرحله‌ای جهت تهیه نانوسیال‌ها استفاده شد. چهار نوع نانولوله‌ی کربنی که عبارت بودند از نانولوله‌های کربنی اولیه (بدون عامل) و نانولوله‌های کربنی عامل‌دار شده با زمان‌های رفلاکس یک، دو و چهار ساعت مورد استفاده قرار گرفتند. فرایند رفلاکس به منظور عامل-دار سازی نانولوله‌ها جهت بهبود پایداری نانوسیال‌ها انجام شد. زیرا مشکل اصلی استفاده از نانولوله‌های کربنی در محیط‌های آبی، تمایل آن‌ها به توده‌شدگی و انباشتگی در این محیط‌ها و بنابراین قابلیت پخش پایین آن‌هاست. عامل‌دار سازی شیمیایی یکی از روش‌های مناسب برای اکسیداسیون سطح نانولوله‌های کربنی و بهبود قابلیت پخش آن‌ها می‌باشد. به دلیل وجود بارهای سطحی در سطح نانولوله‌های کربنی عامل‌دار شده، آن‌ها در محلول‌های آبی یکدیگر را دفع می‌کنند، بنابراین می‌توانند به صورت همگن پخش شده و محلول پایداری را بسازند. پیش از رفلاکس، فرایند خالص‌سازی روی نانولوله‌های کربنی انجام شد. به این ترتیب که ابتدا به نانولوله‌های کربنی اولیه، اسید هیدروکلریک اضافه گردید و نمونه به مدت یک ساعت در اولتراسونیک حمامی تحت تأثیر امواج مافوق صوت قرار گرفت. پس از آن، نانولوله‌ها با استفاده از دستگاه فیلتراسیون از اسید جدا شده و چندین بار با آب یون‌زدایی

ذره و دماهای مختلف اندازه‌گیری شدند. نتایج نشان دادند که مدل شبکه عصبی در توافق خوبی با داده‌های تجربی است و قادر است رسانندگی حرارتی نانوسیال‌های آب/CNTs را به طور مؤثر و خوبی تخمین بزند. در تحقیقی که در سال ۲۰۱۷ توسط وفایی و همکاران [۱۴] انجام شد، از شبکه عصبی مصنوعی برای پیش‌گویی نسبت رسانندگی حرارتی نانوسیالات هیبریدی MgO-MWCNTs/EG استفاده شد. آن‌ها از چهار شبکه‌ی عصبی با تعداد ۶، ۸، ۱۰ و ۱۲ نرون در لایه‌ی مخفی استفاده کردند و مشاهده نمودند که شبکه‌ای با ۱۲ نرون در لایه مخفی مناسب‌ترین مدل است. در سال ۲۰۱۷، همت اسفه و همکاران [۱۷] رفتار رئولوژیکی نانوسیال‌های روغن TiO₂-MWCNT را به صورت تجربی مورد بررسی قرار دادند. سپس از یک شبکه عصبی مصنوعی برای تخمین و پیش‌گویی گرانیوی بر حسب دما، کسر حجمی ذرات و استرس برشی استفاده نمودند. نتایج نشان دادند که مدل شبکه عصبی در توافق خوبی با داده‌های تجربی است. در تحقیق دیگری که توسط همت اسفه و همکاران [۱۹] در سال ۲۰۱۷ انجام شد، انتقال حرارت جابجایی نانوسیال عامل‌دار شده نانولوله کربنی بر پایه آب با عامل کربوکسیل در کسرهای حجمی پایین در جریان مغشوش، درون یک مبدل، مورد بررسی قرار گرفت. به علاوه، رسانندگی حرارتی و ویسکوزیته دینامیکی نانوسیال در دماها و کسرهای حجمی مختلف اندازه‌گیری شد. در سال ۲۰۱۸، افرند و همکاران [۲۰] با استفاده از شبکه‌های عصبی مصنوعی، رسانندگی حرارتی نانوسیال حاوی نانولوله کربنی چند جداره عامل‌دار بر پایه-ی آب را مدل‌سازی نمودند و رابطه تجربی جدیدی را به صورت تابعی از کسر حجمی و دما ارائه دادند. در این تحقیق از شبکه‌ی عصبی پرسپترون چند لایه‌ای (MLP) جهت مدل‌سازی رسانندگی حرارتی نانوسیال‌های حاوی نانولوله‌های کربنی بر پایه‌ی اتیلن گلیکول استفاده شده است. اثر دما، درصد حجمی نانولوله در سیال پایه و طول نانولوله‌های کربنی بر میزان رسانندگی حرارتی نانوسیال-های حاوی نانولوله‌های کربنی بر پایه‌ی اتیلن گلیکول مورد بررسی قرار گرفته است. در تحقیق قبلی انجام شده [۲۱] اثر زمان رفلاکس در فرایند عامل‌دارسازی نانولوله‌های کربنی بر طول آن‌ها مورد بررسی قرار گرفت و مشاهده شد که با افزایش زمان رفلاکس، طول نانولوله‌های کربنی کاهش می‌یابد. بنابراین با تغییر زمان رفلاکس می‌توان

نرون های هر لایه، عامل های مهمی در آموزش مناسب شبکه هستند. با توجه به این مقادیر است که شبکه وزن های مناسب را برای آموزش خود انتخاب می کند. به همین منظور باید تعداد مختلف لایه ها و نرون ها مورد بررسی قرار گیرند تا بهینه ی آن ها نهایتاً انتخاب شوند. به دلیل این که فرآیند آموزش رکن اصلی طراحی شبکه است، معمولاً تعداد بیش تری از آزمایش ها به این مرحله اختصاص می یابند تا شبکه به صورت کامل آموزش ببیند. پس از این که شبکه آموزش دید، باید به طریقی اطمینان حاصل شود که شبکه درست آموزش دیده است و می تواند شرایط آزمایشی دیگر را به خوبی پیش بینی کند. به این منظور تعدادی از آزمایش های انجام شده، برای سنجش شبکه نگه داشته می شوند. شبکه عددی را پیش بینی کرده و مقدار واقعی مورد آزمایش نیز مشخص است. به این ترتیب با محاسبه ی خطای نسبی می توان دریافت که چند درصد خطا در پیش بینی شبکه وجود داشته است.



لایه ی پنهان

شکل ۱- ساختار عمومی یک پرسپترون چند لایه ای

در این تحقیق، پارامترهای دما، درصد حجمی نانولوله در سیال پایه و زمان رفلکس به عنوان ورودی های شبکه و رسانندگی حرارتی به عنوان خروجی شبکه در نظر گرفته شدند. شبکه های عصبی با تعداد لایه های پنهان متفاوت (۱، ۲ و ۳ لایه) و تعداد نرون های متفاوت در هر لایه (۲، ۳، ۴، ۵، ۶، ۱۰ و ۱۵ نرون) مورد بررسی قرار گرفتند. از مجموع ۳۶ آزمایش مختلف، ۲۴ آزمایش برای بخش آموزش شبکه و ۱۲ آزمایش برای بخش سنجش شبکه مورد استفاده قرار گرفتند. آزمایش های انتخاب شده برای مراحل آموزش و سنجش شبکه به ترتیب در جدول های ۱ و ۲ آورده شده اند.

شده، شستشو داده شدند. جهت عامل دار کردن نانولوله های کربنی از مخلوط اسیدهای سولفوریک و نیتریک با نسبت سه به یک استفاده شد. نمونه به مدت ۳۰ دقیقه در دستگاه اولتراسونیک قرار داده شد. سپس توسط دستگاه رفلکس، نمونه در زمان های مختلف یک، دو و چهار ساعت در دمای ۸۰ درجه ی سانتی گراد نگه داشته شد. به این ترتیب نانولوله ها از محل نواقص و انتهای خود شکسته و گروه های عاملی دارای بار منفی $-COOH$ و $-OH$ به سطح آن ها متصل می گردند و بنابراین سطح نانولوله های کربنی به صورت آب دوست اصلاح شده و قابلیت انحلال می یابند. جهت تهیه نانوسیال های حاوی نانولوله های کربنی بر پایه اتیلن گلیکول، سه درصد حجمی ۰/۱، ۰/۲۵ و ۰/۵ تهیه و تمامی نمونه ها به مدت ۳ ساعت تحت تأثیر امواج مافوق صوت قرار داده شدند. در این تحقیق از دستگاه اندازه گیری رسانش گرمایی KD2-Pro thermal analyzer جهت اندازه گیری رسانندگی حرارتی استفاده شد. رسانش گرمایی نانوسیال ها در چهار دمای ۲۰، ۳۰، ۴۰ و ۵۰ درجه ی سانتی گراد اندازه گیری شدند. به منظور حصول اطمینان از صحت اندازه گیری های انجام شده، اندازه گیری در هر دمایی بین ۵ تا ۱۰ مرتبه تکرار گردید و مقادیر گزارش شده، در حقیقت مقدار متوسط این اندازه گیری ها می باشند. همچنین دستگاه KD2 علاوه بر اندازه گیری رسانندگی حرارتی و دما، ضریب خطایی را نیز محاسبه می کند. در صورتی عدد اندازه گیری شده برای رسانندگی حرارتی قابل قبول خواهد بود که ضریب خطا کمتر از ۰/۱ باشد. تمامی مقادیر رسانندگی حرارتی با در نظر گرفتن این ضریب خطا گزارش شده اند. نتایج اندازه گیری های رسانندگی حرارتی در جداول ۱ و ۲ ذکر شده اند.

۲-۲- طراحی شبکه عصبی مصنوعی

به منظور مدل سازی داده های تجربی، از شبکه ی عصبی پرسپترون چند لایه ای (MLP) و زبان برنامه نویسی متلب استفاده شد. در این تحقیق از فراخوانی کدهای پیش فرض موجود در محیط متلب استفاده شده است. شکل (۱) ساختار عمومی یک پرسپترون چند لایه ای را نشان می دهد. همان طور که مشاهده می شود، شبکه عصبی پرسپترون چند لایه ای، دارای یک لایه ی ورودی، یک لایه ی خروجی و یک یا چند لایه ی پنهان است که تعداد لایه های پنهان در بررسی های مختلف، متفاوت می باشد. انتخاب تعداد لایه های پنهان در هر شبکه ی عصبی چند لایه ای و تعداد

جدول ۱- آزمایش‌های انتخاب شده برای مرحله‌ی آموزش شبکه‌ی عصبی پرسپترون چند لایه‌ای.

ورودی‌های آموزش		خروجی آموزش	
غلظت (Vol%)	زمان رفلکس (ساعت)	دما (°C)	رسانندگی حرارتی (W/m.K)
۰.۵	۴	۵۰	۰.۲۸۹
۰.۲۵	۲	۳۰	۰.۲۹۱
۰.۵	۰	۴۰	۰.۲۶۶
۰.۲۵	۴	۲۰	۰.۳۰۳
۰.۱	۰	۵۰	۰.۲۷۱
۰.۵	۲	۳۰	۰.۲۹۶
۰.۱	۴	۴۰	۰.۲۶۲
۰.۱	۰	۲۰	۰.۲۶۵
۰.۲۵	۰	۵۰	۰.۲۵۸
۰.۱	۲	۳۰	۰.۲۶۲
۰.۵	۰	۲۰	۰.۲۶۳
۰.۵	۴	۴۰	۰.۲۸۷
۰.۵	۲	۵۰	۰.۳
۰.۲۵	۲	۴۰	۰.۲۹۲
۰.۱	۴	۳۰	۰.۲۶۲
۰.۲۵	۰	۴۰	۰.۲۵۸
۰.۲۵	۴	۳۰	۰.۳۰۳
۰.۲۵	۰	۲۰	۰.۲۵۶
۰.۱	۴	۵۰	۰.۲۶۷
۰.۵	۲	۲۰	۰.۲۹۱
۰.۱	۲	۴۰	۰.۲۶۲
۰.۱	۰	۳۰	۰.۲۶۹
۰.۲۵	۲	۵۰	۰.۲۹۳
۰.۵	۴	۲۰	۰.۲۸۵

جدول ۲- آزمایش‌های انتخاب شده برای مرحله‌ی سنجش شبکه‌ی عصبی پرسپترون چند لایه‌ای.

ورودی‌های سنجش		خروجی سنجش	
غلظت (Vol%)	زمان رفلکس (ساعت)	دما (°C)	رسانندگی حرارتی (W/m.K)
۰.۵	۰	۵۰	۰.۲۶۷
۰.۲۵	۲	۲۰	۰.۲۹۱
۰.۱	۲	۵۰	۰.۲۶۸
۰.۲۵	۴	۵۰	۰.۳۰۵
۰.۵	۰	۳۰	۰.۲۶۵
۰.۱	۴	۲۰	۰.۲۶۱
۰.۲۵	۰	۳۰	۰.۲۵۸
۰.۵	۲	۴۰	۰.۲۹۷
۰.۵	۴	۳۰	۰.۲۸۷
۰.۱	۰	۴۰	۰.۲۶۸
۰.۱	۲	۲۰	۰.۲۶۱
۰.۲۵	۴	۴۰	۰.۳۰۴

جدول ۳- نمونه‌هایی از شرایط مختلف بررسی شده به منظور یافتن مناسب‌ترین شبکه‌ی عصبی برای نانوسیال‌های حاوی نانولوله‌های کربنی بر پایه‌ی اتیلن گلیکول.

تعداد لایه‌های پنهان	تعداد نرون‌ها در هر لایه	بیش‌ترین درصد خطا
۱	۳	۱۹.۶
۱	۵	۱۹.۷
۱	۱۰	۲۲.۷۳
۲	(۵، ۵)	۱۱.۶۶
۲	(۳، ۲)	۶.۵۳
۲	(۱۰، ۱۵)	۳۲.۶
۳	(۲، ۲، ۳)	۱۱.۰۸
۳	(۳، ۳، ۲)	۱۴.۱
۳	(۳، ۳، ۳)	۱۸.۲

به منظور بررسی چگونگی درستی عملکرد شبکه، کافی است خطای شبکه که همان اختلاف بین مقادیر پیش‌بینی شده توسط شبکه و مقادیر تجربی است، محاسبه شود. با توجه به شکل (۲) ملاحظه می‌گردد، مقادیر پیش‌بینی شده توسط شبکه عصبی در توافق خوبی با مقادیر تجربی هستند. میزان خطای آزمایش و این که آیا شبکه به خوبی آموزش دیده است یا نه، به نوع آزمایش و انتظاری که فرد آزمایش‌گر از شبکه‌ی عصبی دارد، بستگی دارد. مثلاً در آزمایشی ممکن است خطای کمتر از ۱۰ درصد مطلوب باشد و در آزمایشی دیگر خطای کمتر از ۱ درصد. چنان چه پس از محاسبه‌ی خطا، مقدار به دست آمده از مقدار

پس از بررسی تمامی شرایط ذکر شده، مشاهده گردید که افزایش تعداد لایه‌های پنهان از یک لایه به دو لایه موجب کاهش درصد خطا و بهبود نتایج شده است ولی افزایش تعداد لایه‌ها به سه لایه، درصد خطا را افزایش داده است. همچنین افزایش تعداد نرون‌های هر لایه موجب افزایش درصد خطا در بخش سنجش شبکه می‌گردد. به دلیل زیاد بودن موارد بررسی شده، تعداد کمی از نتایج بدست آمده، به عنوان نمونه در جدول ۳ آورده شده‌اند. با توجه به نتایج به دست آمده، کم‌ترین درصد خطا (۶.۵٪) مربوط به شبکه‌ی عصبی شامل دو لایه‌ی پنهان که لایه اول دارای ۳ نرون و لایه دوم دارای ۲ نرون است، می‌باشد. در شکل (۲) مقادیر پیش‌بینی شده توسط این شبکه عصبی و مقادیر تجربی آورده شده‌اند.

سنجش شبکه مورد بررسی قرار گیرند. در صورتی که در تمامی موارد، خطای آزمایش از مقدار مورد نظر کم تر باشد، می توان گفت که تعداد لایه های مخفی و نرون ها به درستی انتخاب شده اند. به منظور اطمینان از نتایج به دست آمده، چهار چیدمان مختلف دیگر از داده های آزمایشی برای بخش های آموزش و سنجش مورد بررسی قرار گرفتند. نتایج حاصل در جدول ۵ آورده شده اند.

جدول ۴- نمونه هایی از شرایط مختلف بررسی شده با دو بار

تکرار داده های ورودی شبکه عصبی.

تعداد لایه های پنهان	تعداد نرون ها در هر لایه	بیش ترین درصد خطا
۱	۳	۲۲٫۲
۱	۵	۱۹٫۱
۱	۱۰	۱۵٫۸۵
۲	(۵، ۵)	۲۵٫۵
۲	(۳، ۲)	۱۰٫۹
۲	(۱۰، ۱۵)	۲۹٫۱
۳	(۲، ۲، ۳)	۱۸٫۹
۳	(۳، ۳، ۲)	۸٫۳۷
۳	(۳، ۳، ۳)	۱۸٫۵


جدول ۵- بیش ترین درصد خطا مربوط به پنج چیدمان مختلف از ورودی ها و خروجی ها برای شبکه ی عصبی با دو لایه ی مخفی که لایه ی اول شامل ۳ نرون و لایه ی دوم شامل ۲ نرون هستند در نانوسیال های بر پایه ی اتیلن گلیکول.

چیدمان	بیش ترین درصد خطا
اول	۶٫۵
دوم	۷٫۷
سوم	۸٫۶
چهارم	۷٫۷
پنجم	۷٫۷

همان گونه که در تمامی چیدمان های مختلف مورد بررسی می توان مشاهده نمود، بیش ترین خطای به دست آمده در هر مورد حدود ۶ تا ۸ درصد است که خطایی قابل قبول می باشد. بنابراین می توان نتیجه گرفت که شبکه ی عصبی شامل دو لایه ی پنهان که لایه اول دارای ۳ نرون و لایه دوم دارای ۲ نرون است، برای نانوسیال های بر پایه ی اتیلن گلیکول قادر به پیش بینی مناسب نتایج تجربی می باشد.

پس از یافتن شبکه عصبی با کم ترین درصد خطا، از این شبکه به منظور پیش بینی مقدار رسانندگی حرارتی در شرایط نزدیک به آزمایش های انجام شده، استفاده گردید. در حقیقت شبکه ی عصبی این امکان را فراهم می آورد که


مورد نظر بیش تر باشد، باید مراحل آموزش شبکه را مجدداً تکرار کنیم و عوامل مؤثر مانند تعداد آزمایش ها، تعداد لایه های مخفی و تعداد نرون ها را آنقدر تغییر دهیم تا نتیجه ی مطلوب حاصل گردد.



شکل ۲- مقایسه ی مقادیر پیش بینی شده توسط شبکه عصبی مصنوعی و مقادیر تجربی در بخش سنجش شبکه.

برای آموزش مناسب تر شبکه، بهتر است تعداد آزمایش ها زیاد باشد. در بعضی فرآیندها تعداد آزمایش ها از حد مشخصی فراتر نمی رود و با این تعداد آزمایش، شبکه به خوبی آموزش نمی بیند. در چنین شرایطی می توان همان آزمایش های قبلی انجام شده را مجدداً به عنوان داده های جدید وارد نمود. لازم به ذکر است که الزاماً تکرار چندین باره ی هر آزمایش موجب بهبود آموزش شبکه نخواهد شد و برای این تعداد تکرار، مقدار بهینه ای وجود دارد. به عنوان مثال، در شبکه ای ممکن است دو بار تکرار آزمایش ها بهینه باشد، در شبکه ای دیگر سه بار و در شبکه ای دیگر اصلاً نیازی به تکرار آزمایش ها نباشد. تعداد بهینه ی تکرار آزمایش ها را با استفاده از خطای محاسبه شده، می توان دریافت. به منظور آموزش بهتر شبکه و افزایش تعداد آزمایش های بخش آموزش، از تکرار داده های ورودی در این بخش استفاده گردید. نتایج نشان دادند که این روش تأثیر قابل ملاحظه ای در بهبود نتایج حاصل و کاهش درصد خطا ندارد و همچنان کم ترین درصد خطای به دست آمده (۶٫۵٪)، به یک بار تکرار ورودی ها در شبکه ی عصبی دارای دو لایه ی پنهان که لایه اول شامل ۳ نرون و لایه ی دوم دارای ۲ نرون است، تعلق دارد. برخی از نتایج مربوط به دو بار تکرار ورودی ها در جدول ۴ آورده شده اند.

پس از این که تعداد لایه های مخفی و نرون های بهینه برای هر شبکه مشخص شد، لازم است به منظور حصول اطمینان از صحت انتخاب، این تعداد لایه های مخفی و نرون های بهینه برای چندین چیدمان مختلف از اطلاعات آموزش و




شکل ۵- مقایسه‌ی مقدار پیش‌بینی شده توسط شبکه عصبی در دمای 60°C (▲) با مقادیر تجربی مربوط به سایر دماها (■) برای نانوسیال حاوی نانولوله‌های چهار ساعت رفلکس شده با غلظت ۰/۱ درصد حجمی.

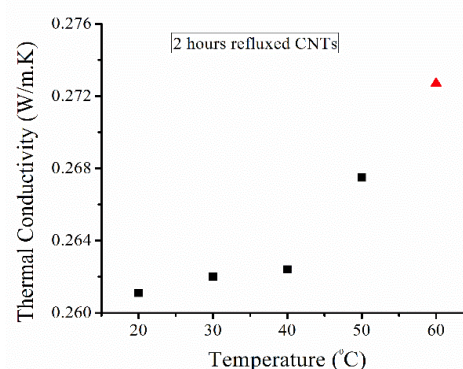
۳- نتیجه‌گیری

با طراحی و بررسی شبکه‌های عصبی مختلف، مشاهده گردید که افزایش تعداد لایه‌های پنهان از یک لایه به دو لایه موجب کاهش درصد خطا و بهبود نتایج شده است ولی افزایش تعداد لایه‌ها به سه لایه، درصد خطا را افزایش داده است. همچنین افزایش تعداد نرون‌ها در هر لایه، باعث افزایش درصد خطا در بخش سنجش می‌شود به طوری که کم‌ترین درصد خطا (۶/۵٪) برای شبکه عصبی شامل دو لایه پنهان که لایه اول دارای ۳ نرون و لایه دوم دارای ۲ نرون است، به دست آمد. به نظر می‌رسد با افزایش بیش‌تر تعداد لایه‌های پنهان و همچنین تعداد نرون‌های موجود در هر لایه، شبکه قادر به تعریف ضرائب وزنی مناسب برای تطبیق ورودی‌ها با خروجی‌ها نیست و به همین دلیل خطاهای مربوطه افزایش یافته‌اند. همچنین از یک بار و دو بار تکرار ورودی‌های آموزش شبکه، به منظور آموزش بهتر شبکه استفاده شد که البته مشاهده گردید تکرار ورودی‌ها تأثیر قابل ملاحظه‌ای در بهبود نتایج و کاهش درصد خطا ندارد. در ادامه از شبکه‌ی عصبی به دست آمده، جهت پیش‌بینی نتایج در شرایط نزدیک به شرایط آزمایش، استفاده شد و مشاهده گردید که مقدار پیش‌بینی شده توسط شبکه عصبی با روند تغییرات نتایج تجربی به دست آمده، در توافق خوبی است.

با انجام تعدادی آزمایش تجربی، آزمایشگاهی مجازی طراحی نموده و شرایط دیگر را با استفاده از آن به دست آورد. البته لازم به ذکر است که شرایط دیگری را که می‌خواهیم با استفاده از شبکه‌ی عصبی پیش‌بینی کنیم، از نظر محدوده‌ی تغییرات عوامل مختلف، نباید با شرایط آموزش شبکه خیلی تفاوت داشته باشند. نتایج حاصل از پیش‌بینی شبکه‌ی عصبی برای دمای 60°C درجه سانتی‌گراد و مقایسه این مقدار با مقادیر رسانندگی حرارتی در دماهای $50-20^{\circ}\text{C}$ درجه سانتی‌گراد، در شکل‌های (۳) تا (۵) نشان داده شده‌اند. همان‌طور که ملاحظه می‌گردد، مقدار پیش‌بینی شده توسط شبکه عصبی برای دمای 60°C درجه سانتی‌گراد مقداری است که با روند تغییرات مقادیر رسانندگی حرارتی تجربی اندازه‌گیری شده برای سایر دماها، در توافق خوبی است.



شکل ۳- مقایسه‌ی مقدار پیش‌بینی شده توسط شبکه عصبی در دمای 60°C (▲) با مقادیر تجربی مربوط به سایر دماها (■) برای نانوسیال حاوی نانولوله‌های اولیه با غلظت ۰/۱ درصد حجمی.



شکل ۴- مقایسه‌ی مقدار پیش‌بینی شده توسط شبکه عصبی در دمای 60°C (▲) با مقادیر تجربی مربوط به سایر دماها (■) برای نانوسیال حاوی نانولوله‌های دو ساعت رفلکس شده با غلظت ۰/۱ درصد حجمی.

مراجع

- [1] A. Ahangarpour, and M. Farbod, "The noble effect of aging on the thermal conductivity of modified CNTs-ethylene glycol nanofluids", *Physics and Chemistry of Liquids*, Vol. 56, N0. 1, 2018, pp. 9–15.
- [2] A. Krogh, "What are artificial neural networks", *Nature Biotechnology*, Vol. 26, No. 2, February 2008, pp. 195–197.
- [3] N.K. Kasabov, *Foundations of neural networks, Fuzzy Systems and knowledge Engineering*, 2th ed., The MIT press, Cambridge, Massachusetts, London, England, 1998.
- [۴] محمود البرزی، آشنایی با شبکه‌های عصبی، مؤسسه‌ی انتشارات علمی دانشگاه صنعتی شریف، تهران، ۱۳۸۹.
- [5] S. Berlemont, N. Burrus, D. Lesage, F. Maes, J.B. Mouret, B. Perrot, M. Rey, N. Tisserand, and A. Wang, "Neural Networks: Multi-Layer Perceptron and Hopfield Network", *Laboratoire de Recherche et Développement de l'Epita (LRDE)*, France, 2001.
- [6] M. Hojjat, S.Gh. Etemad, R. Bagheri and J. Thibault, "Thermal conductivity of non-Newtonian nanofluids: Experimental data and modeling using neural network", *International Journal of Heat and Mass Transfer*, Vol. 54, 2011, pp. 1017–1023.
- [7] M.M. Papari, F. Yousefi, J. Moghadasi, H. Karimi and A. Campo, "Modeling thermal conductivity augmentation of nanofluids using diffusion neural networks", *International Journal of Thermal Sciences*, Vol. 50, No. 1, 2011, pp. 44–52.
- [8] G.A. Longon, C. Zilio, E. Ceseracciu and M. Reggiani, "Application of Artificial Neural Network (ANN) for the prediction of thermal conductivity of oxide–water nanofluids", *Nano Energy*, Vol. 1, No. 2, 2012, pp. 290–296.
- [9] F. Yousefi, H. Karimi and M.M. Papari, "Modeling viscosity of nanofluids using diffusional neural networks", *Journal of Molecular Liquids*, Vol. 175, 2012, pp. 85–90.
- [10] M. Tajik Jamal-Abadi and A. H. Zamzaman, "Optimization of Thermal Conductivity of Al₂O₃ Nanofluid by Using ANN and GRG Methods", *International Journal of Nanoscience and Nanotechnology*, Vol. 9, No. 4, 2013, pp. 177–184.
- [11] S. Atashrouz, G. Pazuki and Y. Alimoradi, "Estimation of the viscosity of nine nanofluids using a hybrid GMDH-type neural network system", *Fluid Phase Equilibria*, Vol. 372, 2014, pp. 43–48.
- [12] E. Ahmadlo and S. Azizi, "Prediction of thermal conductivity of various nanofluids using artificial neural network", *International Communications in Heat and Mass Transfer*, Vol. 74, 2016, pp. 69–75.
- [13] M. Hemmat Esfe, K. Motahari, E. Sanatizadeh, M. Afranda, H. Rostamian and M.R. Hassani Ahangar, "Estimation of thermal conductivity of CNTs-water in low temperature by artificial neural network and correlation", *International Communications in Heat and Mass Transfer*, Vol. 76, 2016, pp. 376–381.
- [14] M. Vafaei, M. Afrand, N. Sina, R. Kalbasi, F. Sourani and H. Teimouri, "Evaluation of thermal conductivity of MgO-MWCNTs/EG hybrid nanofluids based on experimental data by selecting optimal artificial neural networks", *Physica E: Low-dimensional Systems and Nanostructures*, Vol. 85, 2017, pp. 90–96.
- [15] M. Hemmat Esfe, M. Bahraei, M.H. Hajmohammad and M. Afrand, "Rheological characteristics of MgO/oil nanolubricants: Experimental study and neural network modeling", *International Communications in Heat and Mass Transfer*, Vol. 86, 2017, pp. 245–252.
- [16] A. Alirezaie, S. Saedodin, M. Hemmat Esfe and S.H. Rostamian, "Investigation of rheological behavior of MWCNT (COOHfunctionalized)/MgO - Engine oil hybrid nanofluids and modelling the results with artificial neural networks", *Journal of Molecular Liquids*, Vol. 241, 2017, pp. 173–181.
- [17] M. Hemmat Esfe, H. Rostamian, M.R. Sarlak, M. Rejvani and A. Alirezaie, "Rheological behavior characteristics of TiO₂-MWCNT/10w40 hybrid nano-oil affected by temperature, concentration and shear rate: an experimental study and a neural network simulating", *Physica E: Low-dimensional Systems and Nanostructures*, Vol. 94, 2017, pp. 231–240.
- [۱۸] محمد همت اسفه و سیف الله سعدالدین، "بررسی تجربی و آزمایشگاهی تاثیر قطر نانوذرات و دما بر ضریب هدایت حرارتی نانوسیال آب/آهن در کسرهای حجمی پایین و ارائه مدل جدید بر مبنای مقادیر تجربی حاصله"، نشریه مدل‌سازی در مهندسی، دوره ۱۳، شماره 42، پاییز ۱۳۹۴، صفحه ۲۷–۴۲.

[۱۹] محمد همت اسفه، مجتبی بیگلری، سیف الله سعدالدین و سید هادی رستمیان، "ارزیابی تجربی خواص ترموفیزیکی، انتقال حرارت جایجایی و افت فشار در نانوسیال آب- نانولوله کربنی چند جداره عامل دار شده"، نشریه مدل سازی در مهندسی، دوره ۱۵، شماره 48، بهار ۱۳۹۶، صفحه ۷۳-۸۴.

[۲۰] مسعود افزند و محمد همت اسفه، "مدل سازی با استفاده از شبکه عصبی مصنوعی جهت پیش بینی هدایت حرارتی نانوسیال نانولوله کربنی چند جداره عامل دار - آب و ارائه رابطه تجربی جدید"، نشریه مدل سازی در مهندسی، دوره ۱۶، شماره ۵۳، تابستان ۱۳۹۷، صفحه ۶۷-۷۳.

[21] M. Farbod, A. Ahangarpour and S.Gh. Etemad, "Stability and thermal conductivity of water-based carbon nanotube nanofluids", Particuology, Vol. 22, 2015, pp. 59-65.