

مدل‌سازی و پیش‌بینی ضریب انتقال حرارت نانوسیالات رقیق γ - Al_2O_3/H_2O به کمک سیستم عصبی-فازی

رقیه نظری¹، حسین بیکی^{2*}، مرتضی اسفندیاری³

1. دانشجوی کارشناسی ارشد، دانشکده مهندسی شیمی، دانشگاه مهندسی فناوری‌های نوین قوچان، ایران

2. استادیار، دانشکده مهندسی شیمی، دانشگاه مهندسی فناوری‌های نوین قوچان، ایران

3. استادیار، دانشکده مهندسی شیمی، دانشگاه بجنورد، ایران

دریافت: 96/3/7 پذیرش: 96/9/22

چکیده

در این پژوهش با استفاده از شبکه‌عصبی و عصبی-فازی ضریب انتقال حرارت در نانوسیالات جاری در یک لوله مدور در رژیم جریان آشفته مدل‌سازی و پیش‌بینی شده است. داده‌های ورودی به مدل، عدد رینولدز و کسر حجمی نرمال شده نانوذرات و خروجی آن ضریب انتقال حرارت نرمال شده است. در شبکه‌عصبی استفاده شده مقادیر متوسط خطای نسبی و متوسط مربع خطا نسبت به نتایج آزمایشگاهی به ترتیب برابر 0/002 و 0/0005 می‌باشد، در شبکه‌عصبی-فازی برای داده‌های آموزش این مقادیر خطا به ترتیب 0 و 0، و برای داده‌های تست 0/0027- و 0/00067 به دست آمده است. مقدار ضریب تبیین در شبکه‌عصبی 0/99 است که نشان دهنده پیش‌بینی مناسب این روش است. این مقدار در روش عصبی-فازی برای داده‌های آموزش 1 و برای داده‌های تست 0/988 می‌باشد. براساس این مقادیر می‌توان نتیجه گرفت استفاده از شبکه‌عصبی-فازی جهت پیش‌بینی ضریب انتقال حرارت در نانوسیالات مناسب‌تر است.

کلمات کلیدی: نانوسیالات، شبکه‌عصبی-فازی، ضریب انتقال حرارت

مقدمه

نانوسیالات، سوسپانسیون‌های حاوی ذرات کلئیدی در مقیاس نانو هستند [1]. این سیالات برای افزایش خواص ترموفیزیکی مانند هدایت گرمایی، نفوذ گرما، ویسکوزیته و ضریب انتقال حرارت جابجایی در مقیاسه

*hbeiki@qiet.ac.ir

با سیال پایه مانند روغن و آب ابداع شده‌اند [1]. استفاده از نانوسیالات یکی از روش‌های افزایش انتقال حرارت می‌باشد [2].

در سال 1995، چوی¹ از آزمایشگاه آرگن² با موفقیت با استفاده از نانوذرات مس نانوسیال تولید کرد. پس از ایجاد نقطه عطف در تاریخ علم نانو، نانوسیالات توجه تعداد زیادی از محققان جهان را به خود جلب کردند [2]. از ابتدای پیدایش نانوسیال در حدود دو دهه قبل، پتانسیل نانوسیالات در کاربردهای انتقال حرارت بیشتر جلب توجه کرده است. چوی و همکارانش با بررسی نظری نانوذرات مس و سیال پایه آب، به این نتیجه رسیدند که هدایت حرارتی نانوسیالات به کسر حجمی و شکل نانوذرات بستگی دارد [3]. مشابه این مطالعه را ژوان و همکاران با استفاده از سیال پایه آب و روغن، انجام دادند [4]. این نکته را نیز می‌توان بیان کرد که با کاهش اندازه نانوذره، هدایت حرارتی نانوسیال افزایش می‌یابد. فوتوکیان و نصر اصفهانی ضریب انتقال حرارت جایجایی اجباری نانوسیالات آب-اکسید آلومینیوم را در رژیم جریان آشفته درون لوله‌های مسی مستقیم به قطر 5 میلی‌متر و ضخامت 0/5 میلی‌متر اندازه‌گیری کردند [5]. آنها نشان دادند که با افزایش عدد رینولدز برای همه غلظت‌ها نسبت ضریب انتقال حرارت نانوسیال به سیال پایه کاهش می‌یابد. با این حال، با افزایش غلظت نانوذرات، افت فشار در لوله نسبت به شرایطی که از سیال پایه استفاده می‌شود، بیشتر است [5]. حجت و همکاران با استفاده از لوله‌ای با طول 2/11 متر، قطر داخلی 10 میلی‌متر و قطر خارجی 14 میلی‌متر که تحت شرایط شار یکنواخت قرار گرفته بود، انتقال حرارت جایجایی نانوسیالات غیر نیوتنی $Al_2O_3/TiO_2/CuO$ با سیال پایه آبی محلول کربوکسیلی متیل سلولز را بررسی کرده‌اند. با توجه به نتایج حاصل، با افزایش عدد رینولدز و پکلت ضریب انتقال حرارت نیز افزایش می‌یابد. در غلظت حجمی 0/5%، افزایش ضریب انتقال حرارت Al_2O_3 نسبت به دو نانوذره دیگر بیشتر است [6]. انتقال حرارت در نانوسیالات $Al_2O_3/TiO_2/H_2O$ با شرایط دمایی دیواره ثابت و رژیم جریان آشفته، توسط نصیری و همکارانش مورد مطالعه قرار گرفت. که نانوسیالات $Al_2O_3/TiO_2/H_2O$ مورد مطالعه قرار گرفتند. در این آزمایش از سه لوله هم مرکز استفاده شد. که نانوسیال در فضای بین لوله داخلی و میانی جریان می‌یابد. آنها نتیجه گرفتند که ضریب انتقال حرارت نانوسیال نسبت به سیال پایه 26/8% بیشتر است [7]. شیخ الاسلامی و همکارانش، انتقال حرارت نانوسیال Cu/H_2O را در جریان بین دو صفحه موازی به صورت عددی بررسی کرده‌اند و به این نتیجه رسیدند که بالا بودن ضریب نفوذ حرارتی³ موجب کاهش گرادیان دمایی و در نتیجه آن افزایش ضخامت لایه مرزی می‌شود و به تبع آن کاهش عدد ناسلت رخ می‌دهد [8]. اثر نانوذرات در انتقال حرارت مبدل‌های حرارتی مورد بررسی قرار گرفت که نتایج افزایش انتقال حرارت را پس از افزودن نانوذرات نشان می‌دهد [9, 10]. پیغمبرزاده با استفاده از نانوسیالات حاوی نانوذرات اکسید مس و اکسید آهن در مبدل حرارتی به این نتیجه دست یافت که با افزایش عدد Re، ضریب انتقال حرارت افزایش می‌یابد و همچنین بزرگ‌تر از ضریب انتقال حرارت آب در شرایط مشابه است. بیشترین درصد افزایش ضریب انتقال حرارت

¹ Choi

² Argonne laboratory

³ Thermal diffusivity

نسبت به آب خالص برای هر دو نانوسیال در کسر حجمی 0/65% مشاهده می‌شود. درصد افزایش در ضریب انتقال حرارت برای نانوسیال $\text{Fe}_2\text{O}_3/\text{H}_2\text{O}$ برابر 9% و نانوسیال $\text{CuO}/\text{H}_2\text{O}$ برابر 7% گزارش شده است [11]. ادنان حسین اثر نانوذرات SiO_2 و TiO_2 را بر عملکرد در رادیاتور خودرو بررسی کرد و نشان داد که با افزایش عدد رینولدز و غلظت نانوسیال، ضریب انتقال حرارت افزایش می‌یابد. حداکثر تغییر مقدار عدد ناسلت نانوسیال نسبت به سیال پایه، برای نانوسیال TiO_2 -Water، 25/12% می‌باشد، در حالیکه برای SiO_2 -Water، 30/06% است. [12].

در سیستم استنتاج فازی از قانون اگر- آنگاه استفاده می‌شود. این سیستم می‌تواند بدون به‌کار گرفتن تحلیل دقیق بخش کیفی دانش بشری را مدل‌سازی و فرآیندها را نتیجه‌گیری کند. انفیس به‌منظور مدل کردن تابع غیرخطی، معرفی اجزای غیرخطی مرتبط به سیستم و نتایج پر بازده مشخص در شبیه‌سازی به‌کار گرفته می‌شود [13]. صالحی و همکاران انتقال حرارت نانوسیال Al_2O_3 با سیال پایه آب را توسط انفیس مورد بررسی قرار دادند. آن‌ها این کار را با استفاده از شش کسر حجمی مختلف Al_2O_3 به‌عنوان ورودی و عدد ناسلت به‌عنوان خروجی انجام داده‌اند و نتایج حاصل را با عدد ناسلت به‌دست آمده از انفیس مقایسه کرده‌اند. براساس نتایج به‌دست آمده با افزایش کسر حجمی نانوذرات، اعداد Pe و Nu افزایش می‌یابند. همچنین، معادله سیدر-تیت، زمانیکه عدد Pe افزایش می‌یابد در پیش‌بینی عدد Nu موفق نمی‌شود [14]. بالچیران و همکاران¹ نیز نانوسیال TiO_2 را مورد بررسی قرار دادند [15]. امین الساداتی و همکارانش جابجایی ترکیبی آرام در حفره دو لبه پر شده از نانوسیال Al_2O_3 -آب را مورد بررسی قرار دادند. در این مطالعه، تاثیرات عدد ریچاردسون بین 0/01 تا 100، کسر حجمی جامد بین 0/01 تا 0/04 و نسبت ابعاد حفره 0/25 تا 4 روی جریان و دما و نرخ انتقال حرارت بررسی می‌شود. تحلیل‌ها برای آب خالص و نانوسیال با نانوذرات Al_2O_3 با قطر 38 nm انجام شده است. به‌دلیل تطابق خوب بین نتایج حاصل از انفیس و داده‌های آزمایشگاهی، می‌توان از انفیس به‌منظور پیش‌بینی مقادیر مورد نظر بدون انجام آزمایش استفاده کرد [16].

شنبدی و همکاران با مطالعه نانوسیال MWCNT در آب به این نتیجه رسیدند که مقاومت گرمایی با افزایش توان ورودی، کاهش می‌یابد و همچنین در توان ثابت، افزایش غلظت مقاومت گرمایی را تغییر نمی‌دهد. آن‌ها این بررسی را از طریق انفیس انجام دادند [17]. تاجیک و همکارانش نیز انتقال حرارت نانوذرات Al_2O_3 در آب را توسط شبکه‌عصبی مطالعه کردند [18]. آریانا و همکارانش نانوسیال Al_2O_3 را از طریق شبکه‌عصبی مورد مطالعه قرار دادند [19, 20]. خسروجردی و همکارانش داده‌های تجربی حاصل از انتقال حرارت نانوذرات گرفتن در آب یون‌زدایی شده را توسط شبکه‌عصبی شبیه‌سازی کرده‌اند و نتایج حاصل مطابقت خوب بین داده‌های شبکه‌عصبی و تجربی را نشان می‌دهند [21]. ابراهیم احمدلو و همکارانش نیز از شبکه‌عصبی به‌منظور شبیه‌سازی نتایج تجربی حاصل از نانوذرات Al ، Al_2O_3 ، Cu ، CuO ، TiO_2 و ZnO_2 در سیالات پایه آب، اتیلن گلیکل (EG)² و روغن استفاده کرده‌اند. نتایج این مطالعه نشان می‌دهد که مدل

¹ Balchilar et al.


² Ethylen Glycol

شبکه عصبی تطابق خوبی با داده‌های آزمایشگاهی دارد و هدایت گرمایی نانوسیالات را به خوبی پیش‌بینی می‌کند [22].

از آنجا که انجام آزمایش نیازمند صرف زمان و هزینه است، بهتر است جهت مطالعه و تجزیه و تحلیل پارامترهای موثر بر یک سیستم از مدل ریاضی استفاده شود. جهت مدل‌سازی سیستم‌های پیچیده، غیرخطی، چندمتغیره، همراه با درجه بالایی از عدم اطمینان و همچنین نبود دانش دقیق نمی‌توان از روش‌های مدل‌سازی مرسوم سود جوست. برای چنین سیستم‌هایی می‌توان از مدل‌سازی عصبی و یا عصبی-فازی استفاده کرد. مدل‌سازی عصبی-فازی ابزار توانمندی در مدل‌کردن چنین سیستم‌هایی می‌باشد. در این مطالعه از داده‌های آزمایشگاهی ارائه شده توسط فوتوکیان و همکاران [5] استفاده شده است و انفیس و شبکه عصبی به‌منظور پیش‌بینی ضریب انتقال گرما مورد استفاده قرار گرفته‌اند.

تئوری شبکه عصبی-فازی

در دهه گذشته، هوش محاسباتی¹ که شامل شبکه‌های عصبی مصنوعی و سیستم‌های فازی² است، تبدیل به ابزاری جهانی برای بسیاری از کاربردها شده است. به دلیل تقریب و قابلیت آموزش، شبکه‌های عصبی به‌طور گسترده برای مدل‌سازی فرآیندهای دینامیک، تعیین هویت، پیش‌بینی و کنترل استفاده شده‌اند [23]. تعداد زیادی از انواع شبکه‌های عصبی وجود دارد که یکی از متداول‌ترین آن‌ها پرسپترون چند لایه³ می‌باشد. این شبکه عصبی معمولاً توسط پس‌انتشار الگوریتم خطا، تابع بنیان شعاعی، نورون خطی تطبیقی و شبکه تطبیقی بر اساس سیستم استنتاجی فازی آموزش داده می‌شود [24].



شکل 1. معماری انفیس [25]

¹ Computational Intelligence (CI)

² Fuzzy System (FS)

³ Multi-layer perception (MLP)

شکل 1، لایه‌ها و ارتباط بین آن‌ها را نشان می‌دهد. کل سیستم شامل پنج لایه می‌باشد، رابطه بین ورودی و خروجی هر لایه در زیر خلاصه شده است:

لایه اول: هر گره i در این لایه گره مربعی است. تابع گره به صورت زیر می‌باشد.

$$O_{1,i} = \mu_{A_i}(x), i = 1, 2, 3 \quad (1)$$

$$O_{1,i} = \mu_{B_{i-3}}(y), i = 4, 5, 6$$

$$O_{1,i} = \mu_{C_{i-6}}(z), i = 7, 8, 9$$

x و y و z ورودی‌های گره i هستند و A_i ، B_i و C_i برچسب‌های زبانی مرتبط با تابع گره هستند. $O_{1,i}$ تابع عضویت A_i ، B_i و C_i می‌باشد [25].

لایه دوم: همه گره‌ها در این لایه با نشان Π مشخص شده‌اند، که با سیگنال‌های ورودی را در یکدیگر ضرب می‌کند و محصولات را به خروجی می‌فرستد [26].

$$O_{2,i} = W_i = \mu_{A_i}(x) \times \mu_{B_{i-3}}(y) \times \mu_{C_{i-6}}(z), i = 1, 2, \dots, 27 \quad (2)$$

هر خروجی قدرت تغییر قانون را مشخص می‌کند [25].

لایه سوم: گره‌های این لایه با دایره N مشخص شده‌اند. گره Δ نسبت قدرت تغییر قانون Δ را به جمع کل تغییر قوانین را محاسبه می‌کند [26].

$$O_{3,i} = \hat{W}_i = \frac{W_i}{W_1 + W_2 + \dots + W_{27}}, i = 1, 2, \dots, 27 \quad (3)$$

خروجی از این لایه به قدرت تغییر¹ نرمال شده معروف است [26].

لایه چهارم: هر گره در این لایه گره مربعی با تابع گره زیر است.

$$O_{4,i} = \hat{W}_i f_i = \hat{W}_i (p_i x + q_i y + r_i z + r r_i), i = 1, 2, \dots, 27 \quad (4)$$

\hat{W}_i خروجی لایه سوم است و $(p_i, q_i, r_i, r r_i)$ مجموعه پارامترها هستند. پارامترها در این لایه به پارامترهای نتیجه ارجاع داده می‌شوند [26].

لایه پنجم: تنها گره در این لایه گره‌ای است که با Σ نشان داده می‌شود که همه خروجی‌ها را به عنوان جمع همه سیگنال‌های ورودی محاسبه می‌کند [26].

$$\text{Overall output} = O_{5,i} = \sum_i \hat{W}_i f_i \quad (5)$$

نتایج و بحث

در این پژوهش ضریب انتقال حرارت نانوسیالات درون لوله در رژیم جریان آشفته به کمک شبکه عصبی فازی و شبکه عصبی پیش بینی شده است. از نتایج آزمایشگاهی موجود در مرجع [5] جهت آموزش، تست و اعتبار سنجی شبکه استفاده شده است. بیشینه عدم قطعیت در اندازه‌گیری ضریب انتقال حرارت نانوسیالات

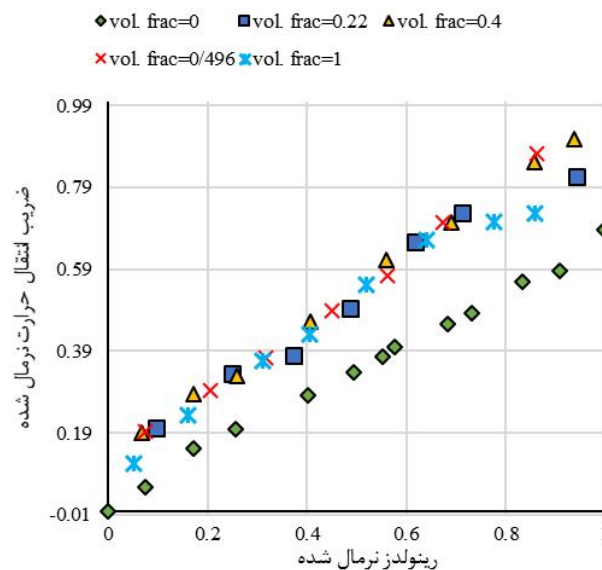
¹Firing strengths

درون لوله مدور در رژیم جریان آشفته معادل 4% می‌باشد [5]. ورودی‌های سیستم عصبی فازی، کسر حجمی نانوذرات و عدد رینولدز و خروجی آن ضریب انتقال حرارت و یا عدد ناسلت می‌باشد.

شبکه عصبی

به‌منظور پیش‌بینی ضریب انتقال حرارت توسط شبکه‌عصبی از نرم‌افزار متلب استفاده شده است. ابتدا ورودی‌ها و خروجی را به ترتیب با نام‌های input و output فراخوانی شده و سپس با وارد کردن کد nftool در این نرم‌افزار صفحه مربوط به شبکه‌عصبی باز می‌شود. این شبکه از قانون لونبرگ-مارگورت¹ استفاده می‌کند. تعداد لایه‌های مخفی، داده‌های آموزش، اعتبارسنجی و تست، پارامترهایی هستند که توسط کاربر وارد می‌شود، مقدار مناسب این پارامترها از طریق سعی و خطا به‌دست می‌آید، که در این مطالعه به‌ترتیب برابر 15، 75، 10% و 15% می‌باشند.

به‌منظور به‌کارگیری روش‌های شبکه‌عصبی و شبکه‌عصبی-فازی بهتر است که مقادیر ورودی و خروجی نرمال شوند. به‌همین دلیل در این بررسی با استفاده از معادله $x(N) = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}$ ، نرمال سازی برای عدد رینولدز، غلظت نانوذرات و ضریب انتقال حرارت انجام شده است. طبق این معادله، اعداد بین صفر و یک قرار می‌گیرند. بنابراین مابقی نمودارها برحسب پارامترهای نرمال شده ارائه می‌شود.




شکل 2. تغییرات ضریب انتقال حرارت نرمال شده برحسب عدد رینولدز نرمال شده در کسر حجمی‌های مختلف


شکل 2 تغییرات ضریب انتقال حرارت را برحسب عدد رینولدز در کسر حجمی‌های مختلف نمایش می‌دهد. همان‌طور که در این شکل مشاهده می‌شود، با افزایش عدد رینولدز ضریب انتقال حرارت پیش‌بینی شده

¹ Levenberg–Marquardt

توسط شبکه‌عصبی نیز افزایش می‌یابد. با توجه به اینکه تغییر چشمگیری در ضریب انتقال حرارت با مقادیر به‌کار رفته در این مطالعه مشاهده نمی‌شود، می‌توان نتیجه گرفت افزودن مقدار ناچیز از نانوذرات تاثیری روی ضریب انتقال حرارت ندارد. اما در عدد رینولدز مشخص با افزودن مقدار کمی از نانوذرات به سیال پایه خالص، ضریب انتقال حرارت افزایش یافته است.



شکل 3. ضریب انتقال حرارت تجربی بر حسب ضرایب انتقال حرارت پیش‌بینی شده



شکل 4. نمودار رگرسیون داده‌های تجربی و پیش‌بینی شده توسط شبکه‌عصبی

شکل 3، داده‌های تجربی را بر حسب مقادیر پیش‌بینی شده توسط شبکه‌عصبی نشان می‌دهد. همان‌طور که می‌دانید، قرار گرفتن داده‌ها روی خط مستقیم نمایانگر خطای کم می‌باشد. با توجه به اینکه ضریب تبیین (R^2) در شکل 4 برابر 0/99 می‌باشد، می‌توان نتیجه گرفت پیش‌بینی شبکه‌عصبی قابل قبول است. جدول 1، مقادیر خطای به‌دست آمده از شبکه‌عصبی را نشان می‌دهد. متوسط خطای نسبی و متوسط مربعات خطا در این بررسی ناچیز می‌باشد.


جدول 1. مقادیر خطا در شبکه عصبی

ARE	-0/003
MSE	0/0005
R ²	0/99

شبکه عصبی-فازی

روش دیگری که به منظور پیش‌بینی ضریب انتقال حرارت مورد استفاده قرار گرفته است، انفیس می‌باشد که مانند شبکه عصبی در متلب اجرا می‌شود. قابل ذکر است که ابتدا داده‌های تجربی به دو قسمت آموزش و تست تقسیم شده است. اعضای آموزش و تست پس از نرمال‌سازی به صورت تصادفی انتخاب می‌شوند. با وارد کردن anfisedit می‌توان وارد محیط انفیس شد. در این مطالعه، از سیستم استنتاج فازی سوگنو و الگوریتم ترکیبی شامل پس انتشار و کمترین مربعات خطا، استفاده شده است.


برای پیش‌بینی مقادیر مورد نظر انواع مختلف از توابع عضویت وجود دارد که با توجه به خطای حاصل باید مناسب‌ترین را انتخاب کرد. در اینجا روش مثلثی (trimf) انتخاب شده است. تعداد توابع عضویت [5 5] در نظر گرفته شده و نوع تابع عضویت خروجی به صورت خطی می‌باشد.




شکل 5. چپ: ضریب انتقال حرارت تجربی بر حسب مقادیر پیش‌بینی شده توسط انفیس آموزش راست: داده‌های ضریب انتقال حرارت تجربی بر حسب مقادیر تست پیش‌بینی شده توسط انفیس

در شکل 5، مقادیر ضریب انتقال حرارت پیش‌بینی شده توسط انفیس بر حسب مقادیر تجربی نشان داده شده است.

همان‌طور که در نمودار رگرسیون (شکل 6) مشاهده می‌شود، R² برای داده‌های آموزش و تست به ترتیب برابر 1 و 0/988 می‌باشد که نشان دهنده مطابقت بسیار خوب داده‌های تجربی و مقادیر پیش‌بینی شده توسط شبکه عصبی-فازی می‌باشد. جدول 2، خطای ARE، MSE را نشان می‌دهد. همان‌طور که مشاهده می‌شود بسیار نزدیک به صفر است و نشان دهنده مناسب بودن مدل مورد نظر است.



a

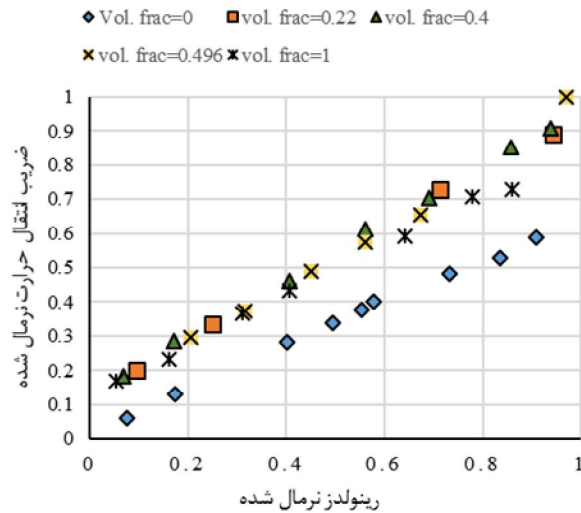


b

شکل 6. (a) رگرسیون داده‌های تجربی بر حسب داده‌های آموزش (b) رگرسیون داده‌های تجربی بر حسب مقادیر تست

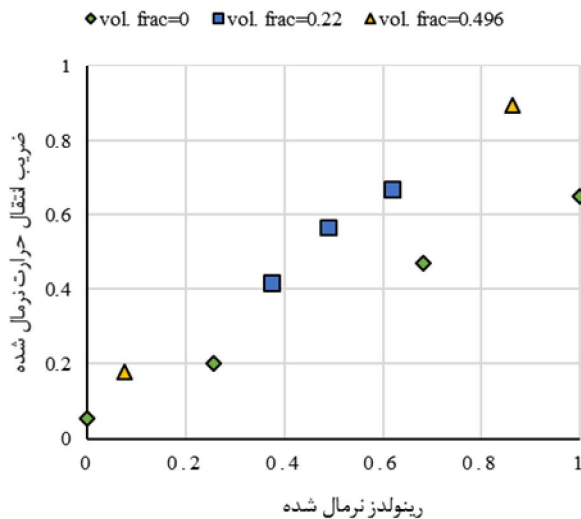
جدول 2. خطای حاصل از داده‌ها تست در شبکه عصبی-فازی

خطا	آموزش	تست
ARE	0	0/0027
MSE	0	0/00067
R^2	1	0/988



شکل 7. تغییرات ضریب انتقال حرارت نرمال شده برحسب عدد رینولدز نرمال شده در کسر حجمی های مختلف

شکل 7، تغییرات ضریب انتقال حرارت پیش‌بینی شده توسط انفیس را برحسب عدد رینولدز در کسر حجمی های مختلف نشان می‌دهد. مطابق شکل افزایش عدد رینولدز باعث افزایش ضریب انتقال حرارت می‌شود.



شکل 8. تغییرات ضریب انتقال حرارت نرمال شده برحسب عدد رینولدز نرمال شده

شکل 8 نیز افزایش ضریب انتقال حرارت را با افزایش عدد رینولدز نشان می‌دهد. همچنین افزودن نانوذرات به سیال پایه باعث افزایش ضریب انتقال حرارت می‌شود. شکل‌های 2 و 7 و 8 نتایج یکسانی را ارائه می‌دهند.

هر دو مدل شبکه‌عصبی و نرو-فازی برای پیش‌بینی داده‌های آزمایشگاهی مناسب هستند، و خطای موجود در آن‌ها بسیار ناچیز می‌باشد. به‌منظور مقایسه این دو روش با یکدیگر باید جداول 1 و 2 در نظر گرفته شود. همان‌طور که مشاهده می‌شود، خطای موجود در شبکه‌عصبی-فازی به خصوص برای داده‌های آموزش کمتر از شبکه‌عصبی می‌باشد. در نتیجه روش عصبی-فازی پیش‌بینی بهتری را ارائه می‌دهد.

نتیجه‌گیری

در این پژوهش به‌منظور کاهش زمان و هزینه‌های انجام آزمایش، ضریب انتقال حرارت نانوسیالات، به کمک شبکه‌های عصبی و عصبی-فازی مدل‌سازی و پیش‌بینی شده است. برای تشخیص انطباق داده‌های تجربی و مقادیر پیش‌بینی شده از متوسط خطای نسبی و متوسط مربع خطا استفاده شد. معیار آماری دیگری که بررسی شد، ضریب تبیین است. نتایج مدل‌سازی حاکی از آن است که در کسر حجمی مشخص با افزایش عدد رینولدز ضریب انتقال حرارت افزایش می‌یابد. به‌عنوان مثال در مدل شبکه‌عصبی در کسر حجمی نرمال شده 0/4 و عدد رینولدز نرمال شده 0/938، بیشترین مقدار ضریب انتقال حرارت نرمال شده 0/9 می‌باشد. همچنین در مدل عصبی-فازی برای داده‌های آموزش حداکثر ضریب انتقال حرارت نرمال شده در کسر حجمی نرمال شده 0/496 و رینولدز نرمال شده 0/969 برابر با 1 می‌باشد. و برای مقادیر تست در همین کسر حجمی، حداکثر ضریب انتقال حرارت نرمال شده، در عدد رینولدز 0/86 برابر با 0/89 می‌شود. در شبکه‌عصبی ARE و MSE و R^2 به ترتیب برابر با 0/002، 0/0005 و 0/99 می‌باشد. این مقادیر مطابقت داده‌های پیش‌بینی شده توسط شبکه‌عصبی و داده‌های تجربی را بیان می‌کند. خطای مقادیر پیش‌بینی شده توسط شبکه‌عصبی-فازی برای داده‌های آموزش صفر و برای داده‌های تست $ARE = -0/0027$ و 0/00067 و $MSE = 0/988$ و $R^2 = 0/988$ است. مطابق مقادیر خطای بیان شده برای هر دو روش و همچنین مقدار ضریب تعیین، می‌توان نتیجه گرفت که مدل شبکه‌عصبی-فازی نسبت به مدل شبکه‌عصبی پیش‌بینی بهتری را انجام می‌دهد.

منابع

- [1] Yu, W., H. Xie., A review on nanofluids: preparation, stability mechanisms and applications, Journal of Nanomaterials, 2012, pp 1.
- [2] Mukherjee, S., Preparation and Stability of Nanofluids-A Review. IOSR Journal of Mechanical and Civil Engineering (IOSR-JMCE), 2013.
- [3] Chol, S., Enhancing thermal conductivity of fluids with nanoparticles. ASME-Publications-Fed. Vol. 231, 1995, pp. 99-106..
- [4] Xuan, Y. and Q. Li, Heat transfer enhancement of nanofluids. International Journal Flow of Heat and Fluid, vol. 21(1), 2000, pp. 58-64
- [5] Fotukian, S. and M.N. Esfahany, Experimental investigation of turbulent convective heat transfer of dilute $\gamma\text{-Al}_2\text{O}_3$ /water nanofluid inside a circular tube. International Journal of Heat and Fluid Flow, vol.31(4), 2010, pp.612-660.



- [6] Hojjat, M., et al., Convective heat transfer of non-Newtonian nanofluids through a uniformly heated circular tube. *International Journal of Thermal Sciences*, vol. 50(4): 2011, pp. 525-531.
- [7] Nasiri, M., S.G. Etemad, and R. Bagheri, Experimental heat transfer of nanofluid through an annular duct. *International Communications in Heat and Mass Transfer*, vol. 38(7): 2011, pp. 958-963.
- [8] Sheikholeslami, M. and D. Ganji, Heat transfer of Cu-water nanofluid flow between parallel plates. *Powder Technology*, vol. 235, 2013, pp. 873-879.
- [9] شاه محمدی، پ.، بیکی، ح.، "بررسی افزایش انتقال حرارت سمت پوسته در مبدل حرارتی پوسته و لوله حاوی نانوسیال آب/آلومینا با استفاده از دینامیک سیالات محاسباتی"، فرآیند نو، شماره 51، 1394، 56-68.
- [10] شیخ زاده، ق. ع.، غفاری، پ.، "مدل سازی عددی اثر نانوذرات در جریان جابجایی ترکیبی نانوسیال با خواص متغیر در محفظه مربعی با درگاه ورود و خروج جریان"، مدل سازی در مهندسی، شماره 38، 1393، 102-83.
- [11] Peyghambarzadeh, S., et al., Experimental study of overall heat transfer coefficient in the application of dilute nanofluids in the car radiator. *Applied Thermal Engineering*, Vol.52(1), 2013 pp. 8-16.
- [12] Hussein, A.M., et al., Heat transfer augmentation of a car radiator using nanofluids. *Heat and Mass Transfer*, Vol.50(11), 2014, pp. 1553-1561.
- [13] Jang, J.-S.R., ANFIS: adaptive-network-based fuzzy inference system. *Systems, Man and Cybernetics, IEEE Transactions on*, vol.23(3), 1993, pp. 665-685.
- [14] Salehi, H., et al., Nero-fuzzy modeling of the convection heat transfer coefficient for the nanofluid. *Heat and Mass Transfer*, vol.49(4): 2013, pp. 575-583.
- [15] Balcilar, M., et al., Investigation of pool boiling of nanofluids using artificial neural networks and correlation development techniques. *International Communications in Heat and Mass Transfer*, Vol.39(3), 2012, pp. 424-431.
- [16] Aminossadati, S., Kargar, A., Ghasemi, B., Adaptive network-based fuzzy inference system analysis of mixed convection in a two-sided lid-driven cavity filled with a nanofluid. *International Journal of Thermal Sciences*, vol.52, 2012, pp. 102-111.
- [17] Shanbedi, M., et al., Modeling of heat transfer characterization of a two-phase closed thermosyphon using MWCNT/WATER and MWCNT-AG/WATER nanofluids., 15th Conference of Fluid Dynamics, 1392, Kermanshah, Iran.
- [18] Tajik Jamal-Abadi, M., Zamzamin, A., Optimization of thermal conductivity of Al₂O₃ nanofluid by using ANN and GRG methods. *International Journal of Nanoscience and Nanotechnology*, Vol.9(4): 2013, pp. 177-184.
- [19] Ariana, M., Vaferi, B., Karimi, G., Prediction of thermal conductivity of alumina water-based nanofluids by artificial neural networks. *Powder Technology*, vol.278 2015, pp. 1-10.
- [20] Balla, H.H., et al., Enhancement of heat transfer coefficient multi-metallic nanofluid with ANFIS modeling for thermophysical properties. *Thermal Science*, vol.19(5), 2015, pp. 1613-1620.
- [21] Vakili, M., Yahyaei, M., Kalhor, K., Thermal conductivity modeling of graphene nanoplatelets/deionized water nanofluid by MLP neural network and theoretical modeling

- using experimental results. *International Communications in Heat and Mass Transfer*, vol.74, 2016, pp 11-17.
- [22] Ahmadloo, E., Azizi, S., Prediction of thermal conductivity of various nanofluids using artificial neural network. *International Communications in Heat and Mass Transfer*, vol.74, 2016, pp. 69-75.
- [23] Baruch, I.S., et al., A fuzzy-neural multi-model for nonlinear systems identification and control. *Fuzzy sets and systems*, vol.159(20), 2008, pp. 2650-2667.
- [24] Abedini, R., et al., The prediction of undersaturated crude oil viscosity: An artificial neural network and fuzzy model approach. *Petroleum Science and Technology*, vol.30(19), 2012, pp. 2008-2021.
- [25] Varol, Y., et al., Prediction of flow fields and temperature distributions due to natural convection in a triangular enclosure using Adaptive-Network-Based Fuzzy Inference System (ANFIS) and Artificial Neural Network (ANN). *International Communications in Heat and Mass Transfer*, vol.34(7): 2007, pp. 887-896.
- [26] Sivakumar, R. Balu, K., ANFIS based distillation column control. *International Journal of Computer Applications Special issue on Evolutionary Computation*, 2010, p. 67-73.