

مدل پیش‌بینی عملکرد حرارتی نانو سیال Al_2O_3 توسط شبکه عصبی مصنوعی و سیستم استنتاج عصبی - فازی تطبیقی

^۱ دانیال خزایی، ^۲ داریوش جعفری، ^۳ مرتضی اسفندیاری*

چکیده

در سال‌های اخیر، استفاده از روش‌های مدل‌سازی که مستقیماً از داده‌های تجربی استفاده می‌کنند به دلیل دقت بالا در پیش‌بینی نتایج فرآیند، به جای روش‌های آماری رو به افزایش است. در این مقاله، توانایی مدل‌های شبکه عصبی مصنوعی (ANN) و سیستم استنتاج فازی - عصبی تطبیقی (ANFIS) در پیش‌بینی عملکرد حرارتی نانوسیال Al_2O_3 که توسط مقاومت حرارتی سنجیده می‌شود، بررسی شده است. داده‌های آزمایشگاهی از یکی از مقالات معتبر که عملکرد حرارتی نانوسیال Al_2O_3 را درون یک لوله حرارتی نوسانی بررسی کرده بود، استخراج شد. برای مدل‌سازی توسط ANN از یک شبکه پرسپترون چندلایه و برای ANFIS از یک مدل فازی سوگنو استفاده شد که هر دو از دقیق‌ترین و رایج‌ترین روش‌های مدل‌سازی هستند. مقایسه مقادیر هدف با مقادیر پیش‌بینی شده توسط هر دو مدل بسیار رضایت بخش بود و ضریب همبستگی برای هر دو بیش از ۰/۹۹ به دست آمد که نشان‌دهنده میزان بالای دقت این دو مدل است. در نهایت عملکرد هر دو مدل با هم مقایسه شد که عملکرد هر دو بسیار خوب و نزدیک به هم بود، ولی در مجموع ANN نسبت به ANFIS عملکرد بهتری از خود نشان داد.

تاریخ دریافت:

۱۳۹۷/۲/۱۸

تاریخ پذیرش:

۱۳۹۷/۱۲/۲۵

کلمات کلیدی:

مدل‌سازی،
شبکه عصبی،
سیستم استنتاج
فازی - عصبی تطبیقی،
مقاومت حرارتی،
نانوسیال،

Ub.chemical@gmail.com

Dariush.jafari@yahoo.com

M.esfandiyari@ub.ac.ir

۱. کارشناس ارشد، مهندسی شیمی، موسسه آموزش عالی خرد بوشهر، بوشهر، ایران

۲. استادیار، گروه مهندسی شیمی، دانشگاه آزاد اسلامی واحد بوشهر، بوشهر، ایران

۳. استادیار، گروه مهندسی شیمی، دانشگاه بجنورد، بجنورد، ایران (نویسنده مسئول)

۱. مقدمه

امروزه از سیالات انتقال حرارت معمول مانند نفت، آب و اتیلن گلایکول به شکل گسترده‌ای در صنایع مختلف از جمله انتقال و ذخیره انرژی، تهویه مطبوع، محصولات شیمیایی و خنک‌سازی قطعات الکترونیکی استفاده می‌شود که از مشکلات آن هدایت حرارتی پایین آن‌ها است. طی تحقیقات محققین برای بهبود خصوصیات حرارتی این سیالات، ایده پراکنده کردن نانو ذرات جامد با هدایت حرارتی بالاتر برای افزایش راندمان در سیستم‌های خنک‌سازی و گرمایشی در جهت رسیدن به عملکرد حرارتی بالاتر مطرح شد. نانو ذرات اکسید فلز به دلیل مقادیر بالای هدایت حرارتی و تولید آسان‌تر نسبت به نانو سیالات فلزی و به دلیل حساسیت پایین‌تر و سبکی ذرات اکسید از ذرات متراکم فلز برای جلوگیری از ایجاد اثرات کلوخگی^۱ برای نانوسیالات سوسپانسیونی مناسب‌تر و رایج‌تر هستند. به وسیله تعلیق ذرات با اندازه نانو به مقدار خیلی بسیار کم در یک سیال، عملکرد انتقال حرارت آن می‌تواند به طور قابل توجهی بهبود پیدا کند [۸]. به همین دلیل، استفاده از نانوسیال به جای سیالات انتقال حرارت معمول رو به افزایش است. بنابراین روش‌های مدل‌سازی به منظور بهینه‌سازی و پیش‌بینی فرآیند در کوتاه‌ترین زمان ممکن اهمیت پیدا می‌کند. در بررسی‌های آزمایشگاهی بهبود عملکرد حرارتی اکثراً از طریق کاهش در مقاومت حرارتی سنجیده می‌شود [۳ و ۱۴].

اخیراً، به دلیل بازدهی بالا و قابل اعتماد بودن و همچنین انعطاف‌پذیری، روش‌های مدل‌سازی جایگزین اکثر روش‌های آماری معمول شده است. بنابراین، روش‌های مختلف مدل‌سازی مانند الگوریتم ژنتیک، شبکه عصبی، منطق فازی و سیستم استنتاج عصبی - فازی تطبیقی تعریف شدند. با توجه به دقت بالا در پاسخ و خاصیت تعمیم‌پذیری در شرایط گوناگون، ANFIS و شبکه عصبی مصنوعی از عالی‌ترین ابزار جهت پیش‌بینی نتایج فرآیندها با استفاده از داده‌های آزمایشگاهی است [۲۲].

1. Agglomeration

یک فرآیند مدل‌سازی کارآمد منجر به بهینه‌سازی عملکرد فرآیند می‌شود، در حالی که از آزمایشات اضافی و گران و اتلاف وقت جلوگیری می‌کند. هنگامی که یک سیستم برای تفسیر پیچیده است و همچنین اطلاعات جزئی در دسترس نیست، یا فرآیند دارای یک متغیر زمان غیرخطی باشد، نتایج حاصل از مدل‌سازی تحلیلی با استفاده از روش‌های علمی و مبتنی بر دانش، ممکن است متقاعدکننده نباشند. برای چنین سیستم‌های پیچیده‌ای، فرضیات ساده کننده ممکن است دقت مدل‌های پیشنهاد شده را محدود کند. با این حال، برای بعضی از فرآیندها، امکان دارد یک مدل تحلیلی با دقت رضایت بخش به دست آید [۲۶]. این ابهامات موجب ایجاد تمایلات قوی برای استفاده از مدل‌سازی بر اساس استفاده مستقیم از داده‌های تجربی با استفاده از سیستم‌های هوشمند مانند شبکه عصبی مصنوعی، سیستم استنتاج عصبی - فازی تطبیقی و منطق فازی می‌شود [۲۳]. مدل‌های پیش‌بینی کننده ذکر شده نتایجی با همبستگی عالی فراهم کرده و می‌توان برای مدل کردن روابط غیرخطی بر روی یک بازه وسیع از متغیرهای ورودی استفاده شوند [۲۶]. توانایی این روش‌های مدل‌سازی قبلاً در اقتصاد، رباتیک، علم مواد، شیمی و صنایع شیمیایی، محیط زیست، منابع انرژی جدید، صنعت نفت و غیره اثبات شده است [۱]. اکثر معادلاتی که در مطالعات مدل‌سازی استفاده می‌شوند را نمی‌توان برای گستره‌ی وسیعی از فرآیندها در شرایط مختلف به کار برد، زیرا آنها فقط برای یک مجموعه معین از شرایط مناسب هستند و از آنها می‌توان تحت بعضی از فرضیات استفاده کرد. بنابراین اهمیت روش‌هایی که مستقیماً بر اساس داده هستند و خود را به منظور پیش‌بینی نتایج فرآیندها بهبود می‌دهند، مشهود است. در بین این روش‌های مدل‌سازی، شبکه عصبی مصنوعی یکی از عالی‌ترین ابزارها جهت پیش‌بینی نتایج فرآیندها با استفاده از داده‌های آزمایشگاهی است. مطالعات مشابه این واقعیت را تأیید می‌کنند [۲۲].

ANFIS نوعی از شبکه‌های عصبی با قدرت بالا هستند [۱۶]. ANFIS دارای توانایی یادگیری و پیش‌بینی بالایی هستند، که آن را به ابزاری کارآمد برای هر سیستمی که با ابهام مواجه می‌شوند تبدیل کرده است. ANFIS در سیستم‌های مهندسی مختلفی توسط محققین زیادی استفاده شده است. سیستم استنتاج فازی (FIS) بخش اصلی ANFIS را تشکیل می‌دهد [۱۵].

حکیم و همکاران [۹] عملکرد پروفایل دمایی یک جوش آور ترموسیفون عمودی را در شرایط عملیاتی مختلف به وسیله شبکه عصبی مصنوعی پیش‌بینی کردند که نتایج پیش‌بینی به وسیله ANN

به نتایج آزمایشگاهی بسیار نزدیک بود و میانگین خطای نسبی مطلق کمتر از $4/3$ درصد به دست آمد. شنبیدی و همکاران [۲۱] عملکرد دمایی یک ترموسیفون دو فازی بسته با دو نانوسیال نانولوله کربن (CNT) و نقره - نانولوله کربن (Ag-CNT) به وسیله شبکه عصبی مصنوعی با دقت خوبی پیش‌بینی کردند. شنبیدی و همکاران [۲۰] همین آزمایش را با CNT و CNT-اتیل دی آمین انجام دادند و سپس نتایج آزمایش را به وسیله ANFIS مدل‌سازی کردند که تطابق بسیار خوبی با داده‌های آزمایشگاهی داشتند. جعفری و نوعی [۱۱] بر روی کاربرد شبکه عصبی مصنوعی در پیش‌بینی رفتار ترمودینامیکی سیستم سدیم کلراید آبی حاوی غیر الکترولیت‌ها مطالعه کردند.

بنابراین، با توجه به مطالب ذکر شده، در این تحقیق تصمیم گرفته شد عملکرد حرارتی نانوسیال Al_2O_3 را به کمک دو روش ANN و ANFIS که مؤثرترین و دقیق‌ترین مدل‌های استفاده شده برای شبیه‌سازی روابط غیرخطی و به شدت پیچیده هستند، مدل‌سازی شود. به عبارت دیگر؛ در این مطالعه، هدف اصلی حصول مدل‌های ANN و ANFIS برای پیش‌بینی پاسخ متغیر هدف (مقاومت حرارتی) در طول یک فرآیند حرارتی و مقایسه عملکردشان است. همچنین تحلیل نتایج آزمایشگاهی مستخرج از مرجع معتبر [۱۷] به وسیله ANN و ANFIS منجر به آموزش یک شبکه بر اساس هوش مصنوعی می‌شود که می‌توان از آن در پیش‌بینی نتایج آزمایش بدون انجام فیزیکی آن بهره برد.

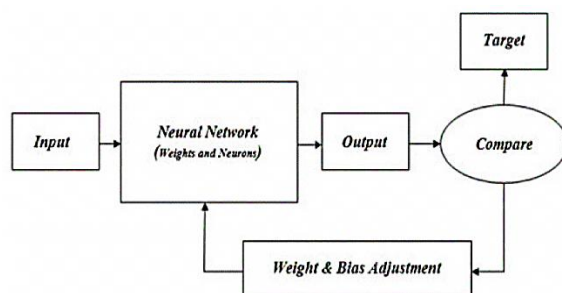
۲. تئوری

۲-۱. تئوری شبکه عصبی

شبکه‌های عصبی که به وسیله الهام از سیستم‌های بیولوژیکی ایجاد شده‌اند، یک سری الگوریتم‌های کامپیوتری‌اند که شامل اجزائی به اسم نرون هستند. آنها برای پردازش اطلاعات به کار برده می‌شوند. در واقع، آنها نرو - کامپیوترهایی با پردازشگرهای توزیع شده موازی هستند [۲]. نرون‌ها اجزاء اصلی شبکه‌های عصبی‌ها هستند که به وسیله یک مجموعه از اتصالات که هر یک دارای وزن‌های اختصاص داده شده هستند، به شبکه‌ها متصل شده‌اند. عملکرد یک شبکه به شدت به مقادیر وزن وابسته است. نرون‌ها در ورودی، خروجی و لایه‌های پنهان تقسیم بندی شده‌اند. یک شبکه عصبی امر مدل‌سازی را از طریق دریافت ورودی، جمع آنها با وزن‌شان و افزودن یک بایاس به نتایج جمع و

سپس فرستادن نتایج برای تابع انتقال انجام می‌دهد. خروجی نرون وابسته به نرون‌های ورودی و تابع انتقالش است [۲۵و۲۶].

در بین انواع شبکه‌های عصبی، پرسپترون چندلایه (MLP) یکی از رایج‌ترین آنها است. شبکه MLP دارای یک لایه ورودی، یک لایه خروجی و معمولاً یک لایه پنهان است. تعداد ورودی و خروجی متغیرهای شبکه به نوع فرآیند بستگی دارد [۱]. همان‌طور که در اکثر موارد گفته شده، یک شبکه با یک لایه پنهان منجر به نتایج رضایت‌بخشی می‌شود. بنابراین، تعداد لایه پنهان در این مقاله یک در نظر گرفته شده است. هر نرون در یک لایه معمولاً به نرون‌های لایه بعدی متصل شده است. آموزش شبکه با اختصاص یک الگو به عنوان الگوی ورودی انجام می‌شود، پس از آن، نتایج محاسبه‌ای که به سطح فعال‌سازی (آستانه گذاری) رسید به سمت لایه خروجی منتشر می‌شوند. واحدهای محاسبه، ورودی‌ها را جمع می‌کنند و از یک تابع برای محاسبه خروجی استفاده می‌کنند. در نهایت، خروجی شبکه در لایه خروجی به دست می‌آید. بهبود همگرایی شبکه به وسیله افزودن یک ترم ثابت توسط واحدهای بایاس ورودی و لایه‌های پنهان به مجموع وزن انجام می‌شود. هنگامی که خروجی‌های شبکه با مقادیر هدف مقایسه می‌شوند، خطاهای واحدهای پنهان تعیین می‌شود و سپس وزن‌هایشان برای به حداقل رساندن خطا تغییر داده می‌شود [۱۲]. این روند در شکل ۱ نشان داده شده است. به طور کلی، می‌توان ادعا کرد که کاهش خطای کلی ناشی از تنظیم وزن و بایاس با استفاده از الگوریتم آموزش صورت می‌گیرد.



شکل ۱. نمایی از مدل ANN و تنظیم وزن و بایاس

نورون k می‌تواند با استفاده از معادلات ریاضی (۱) و (۲) بیان شود:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (۱)$$

$$y_k = \varphi(u_k + b_k) \quad (۲)$$

که x_j سیگنال ورودی، w_{kj} وزن نرون، u_k ترکیب کننده خطی خروجی ناشی از سیگنال ورودی، b_k بایاس مربوطه، φ تابع فعال سازی و y_k سیگنال خروجی نرون است.

۲-۲. سیستم استنتاج عصبی - فازی تطبیقی

هدف اصلی یک نرم افزار کامپیوتری که بر اساس هوش مصنوعی کار می کند، دستیابی به یک مجموعه از روابط بین ورودی - خروجی است که فرآیندهای ویژه را تعریف می کنند. واژه ویژه بر فرآیندهایی دلالت دارد که مدل سازی ریاضی آنها مشکلاتی نظیر غیرخطی، یادگیری انطباقی و فرآیندهای زمان واقعی دارند [۲۷].

در واقع توانایی یادگیری شبکه های عصبی با مدل سازی فازی ترکیب شده و سیستم ANFIS به وجود آمده است، که در واقع یک استنتاج فازی در قالب شبکه های تطبیقی هستند [۱۳]. به عبارت دیگر، ANFIS یک سیستم ترکیبی عصبی - فازی است که از ویژگی های مناسب شبکه عصبی مصنوعی و مدل های منطق فازی استفاده کرده و همچنین خصوصیات نامناسب آنها تصحیح شده است [۶، ۷ و ۲۴]. ANFIS دارای یک ساختار منطق فازی است و از ANN برای تعیین شکل قانون استخراج^۱ و توابع عضویت^۲ استفاده می کند [۱۰]. می توان گفت که ANFIS ترکیبی از محاسبات سطح پایین ANN به همراه توانایی استدلال بالای یک سیستم منطق فازی است [۴ و ۵].

در مدل سازی سیستم های غیر خطی بر اساس ANFIS، فضای ورودی به تعداد زیادی مناطق محلی تقسیم می شود. یک منطقه ساده برای هر یک بر اساس توابع خطی یا ضرایب مقابل تنظیم توسعه یافته، پس از آن ANFIS از MFها برای تقسیم ابعاد هر ورودی استفاده می کند. چندین منطقه محلی می تواند به طور همزمان فعال شود، در حالی که فضای ورودی توسط MFهای دارای اشتراک

-
1. rule extraction
 2. MFs

پوشش داده می‌شود. MFها و لایه‌های ANFIS نقش مهمی در توانایی تخمین مدل ANFIS بازی می‌کنند [۲].

ANFIS شامل دو بخش است. بخش اول مقدمه است و بخش دوم بخش نتیجه‌گیری است. قوانین فازی مربوط به این دو بخش است.

برای یک مدل فازی سوگنو درجه اول، یک قانون فازی رایج اگر - آنگاه به شکل معادله زیر است:

$$\text{قانون ۱: اگر } x_1 \text{ باشد } A_1 \text{ و } x_2 \text{ باشد } B_1 \text{ و } \dots \text{؛ آنگاه } f_1 = p_1x_1 + q_1x_2 + \dots + r_1$$

$$\text{قانون ۲: اگر } x_2 \text{ باشد } A_2 \text{ و } x_2 \text{ باشد } B_2 \text{ و } \dots \text{؛ آنگاه } f_1 = p_2x_1 + q_2x_2 + \dots + r_2$$

که A_i ، B_i و f_i به ترتیب مجموعه‌های فازی و خروجی سیستم هستند. p_i ، q_i و r_i متغیرهای طراحی هستند که در طول آموزش تعیین می‌شوند (۱۹).

مدل سازی ANFIS در پنج لایه انجام می‌شود، که ساختارش جهت پیش‌بینی متغیر هدف در

شکل ۶ نشان داده شده است.

گره‌های لایه اول، گره‌های قابل تطبیق با معادله زیر هستند:

$$\mu_{A_i}(x) = e^{-\left(\frac{x-x^*}{\sigma^2}\right)} \quad (3)$$

که x^* و σ پارامترهای فرض شده‌ای هستند که به وسیله یک الگوریتم ترکیبی انطباق داده شده‌اند و x متغیر ورودی است. در لایه دوم، قدرت شلیک هر قاعده توسط اندازه‌گیری کمی داده ورودی هر قاعده تعیین می‌شود. خروجی یک لایه حاصل جبری سیگنال‌های ورودی است:

$$O_{2,i}(x) = \omega_i = \mu_{A_i}(x_1) * \dots * \mu_{C_i}(x_n) \quad (4)$$

نرمال سازی در لایه سوم انجام می‌شود، که توسط محاسبه نسبت نام قدرت شلیک قاعده (انتشار)

به مجموع همه نتایج قدرت شلیک انجام می‌شود که هر گره به وسیله معادله زیر محاسبه می‌شود:

$$O_{3,i}(x) = \bar{\omega}_i = \frac{\omega_i}{(\omega_i + \dots + \omega_n)} \quad (5)$$

خروجی هر گره در لایه چهارم به شکل زیر محاسبه می‌شود:

$$O_{4,i} = \sum \bar{\omega}_i f_i \quad (6)$$

خروجی کل از جمع همه سیگنال‌های ورودی در لایه پنجم حاصل می‌شود. محاسبه ارتفاع نوسان در لایه پنج با استفاده از معادله زیر انجام می‌شود [۱۸]:

$$O_{5,i} = \frac{\sum_{i=1}^n \omega_i f_i}{\sum_{i=1}^n \omega_i} \quad (7)$$

واضح است که لایه‌های اول و چهارم انطباقی هستند. C_i و O_i پارامترهای فرضی تابع عضویت‌های فازی ورودی در لایه (۱) هستند. همان‌طور که گفته شد، لایه پنجم خروجی کل را به شکل جمع همه سیگنال‌های ورودی می‌دهد.

۳. روش‌ها

در این مقاله از دو روش مدل‌سازی ANN و ANFIS با استفاده از نرم‌افزار Matlab با نسخه R2015b استفاده شده که برای مدل‌سازی از داده‌های آزمایشگاهی یکی از مقالات معتبر [۱۷] استفاده شده که در آن عملکرد حرارتی یک لوله حرارتی نوسانی (oscillating heat pipe (OHP)) از جنس استیل و آب به عنوان سیال پایه و نانو ذرات Al_2O_3 در آب پراکنده شده بود، بررسی شده بود؛ دلیل استفاده از لوله حرارتی نوسانی این است که با توجه به نوسان موجود درون OHP از ته نشینی ذرات نانو جلوگیری کرده و موجب باقی ماندن ذرات به حالت تعلیق می‌شود که یک مزیت نسبت به لوله‌های حرارتی معمولی^۱ می‌باشد. در آزمایش، اثرات نسبت پر شدن (FR)، کسر جرمی ذرات آلومینا و قدرت ورودی را بر روی مقاومت حرارتی کل OHP، که معیارهایی برای بررسی عملکرد حرارتی هستند، بررسی کردند. در این آزمایش از نانوسیال با پنج کسر جرمی متفاوت که شامل ۰/۱، ۰/۳، ۰/۶، ۰/۹ و ۱/۲ بودند، استفاده شد و آزمایش در سه نسبت پر شدن ۵۰٪، ۶۰٪ و ۷۰٪ انجام شد، که در مجموع ۱۹۸ نمونه بوده که هر نمونه شامل یک کسر وزنی، یک قدرت ورودی و یک نسبت پر شدن به عنوان داده‌های ورودی و یک عدد به عنوان مقاومت حرارتی کل به عنوان پارامتر خروجی است، که از مجموع این ۱۹۸ نمونه ۷۰٪ نمونه‌ها برای آموزش شبکه، ۱۵٪ برای اعتبارسنجی و ۱۵٪ مابقی

1. Traditional


برای تست نهایی اختصاص داده شد، لازم به ذکر است که این تقسیم‌بندی برای هر دو روش ANN و ANFIS به طور مشابه انجام گرفت و انتخاب نمونه‌ها به طور تصادفی انجام شد.

۴. نتایج مدل‌سازی

۴-۱. نتایج مدل‌سازی توسط ANN

شبکه عصبی MLP در این مطالعه استفاده شده، که به وسیله الگوریتم لونیبرگ - مارکوارت^۱ (LM) آموزش داده شده است. تابع انتقال لایه‌های پنهان سیگموئید در نظر گرفته شد که در مقایسه با تابع انتقال خطی خطای کمتری داشت و تابع انتقال لایه‌ی خروجی خطی purelin می‌باشد. الگوریتم آموزش حاضر پایین‌ترین میزان خطا را فراهم کرده است؛ در نتیجه، تعداد بهینه نرون‌های لایه پنهان به دست آمد. پارامترهای عملیاتی شامل نسبت پر شدن، قدرت ورودی دستگاه و کسر وزنی نانو سیال می‌باشند. بنابراین؛ تعداد نرون‌ها در لایه ورودی برابر با سه می‌باشد. پارامتر خروجی هم مقاومت حرارتی در نظر گرفته شد، که لایه خروجی را تشکیل می‌دهد؛ در نتیجه تعداد نرون‌ها در لایه خروجی یک می‌شود. تعداد نرون‌های لایه پنهان به وسیله آموزش چندین شبکه با تعداد مختلف نرون‌های لایه پنهان و مقایسه بین نتایج پیش‌بینی‌ها برای خروجی مورد نظر به دست آمد. برای انتخاب تعداد مناسب نرون‌های لایه پنهان با توجه به اینکه یک روش جامع و دقیق جهت تعیین تعداد بهینه نرون‌ها در لایه پنهان وجود ندارد و معمولاً با استفاده از سعی و خطا به دست می‌آید، که بهترین عملکرد در عدد ۲۴ به دست آمد. میزان کافی برای تعداد بهینه نرون‌ها به وسیله محاسبه میانگین مربع خطا^۲ بین خروجی شبکه و داده آموزش تعیین می‌شود.

-
1. Levenberg-Marquardt
 2. MSE




شکل ۲. ساختار مدل ANN برای پیش‌بینی مقاومت حرارتی

همان‌طور که قبلاً گفته شد متغیرهای ورودی کسر جرمی نانوسیال Al_2O_3 ، قدرت ورودی دستگاه و نسبت پر شدن^۱ است و پارامتر خروجی مقاومت حرارتی می‌باشد. ساختار ANN در این مطالعه در شکل (۲) نشان داده شده، همان‌طور که مشاهده می‌شود شبکه از سه لایه تشکیل شده که شامل لایه ورودی، پنهان و خروجی است. در لایه ورودی سه نرون مشاهده می‌شود که متناظر با سه پارامتر ورودی است. مقادیر ورودی در ابتدا مستقیماً از نرون‌ها به لایه پنهان که در این مقاله برابر یک در نظر گرفته شد به همراه وزن‌ها فرستاده می‌شود، که در آنجا پردازش اصلی بر روی داده‌ها به وسیله محاسبه مجموع ورودی‌های وزن‌دار انجام می‌گیرد. همچنین، مقادیر اولیه اختصاص داده شده به وزن‌ها در طول روند آموزش از طریق مقایسه داده‌های آزمایش (واقعی) و نتایج خروجی از مدل بهبود می‌یابند. کوچک‌سازی مقادیر خطا از طریق پس انتشار^۲ نتایج انجام می‌شود.

برای پیش‌بینی مقاومت حرارتی با استفاده از مدل ANN، ۷۰٪ از داده‌ها برای آموزش و مابقی برای اعتبارسنجی و تست مورد استفاده قرار گرفت. برای سنجش توانایی مدل ANN از نمونه‌هایی که


1. Filling ratios (FR)
2. Back propagation

در حین فرآیند آموزش مورد استفاده قرار نگرفته بود استفاده شد که مقاومت حرارتی توسط مدل ANN تخمین زده شد و سپس با مقادیر واقعی مقایسه شد. در شکل (۳) مقایسه بین مقادیر پیش‌بینی شده مقاومت حرارتی و مقادیر واقعی برای نمونه آموزش، اعتبارسنجی، تست و همه داده‌ها نشان داده شده است. همان‌طور که در شکل مشاهده مقدار R بیش از ۰/۹۹۷ به دست آمده که مبین آن است که مقادیر به دست آمده به وسیله مدل خیلی خوب هستند و پاسخ‌های شبکه رضایت بخش بوده است.



شکل ۳. نمودار رگرسیون داده‌های آموزش، اعتبارسنجی، تست و همه داده‌های پیش‌بینی

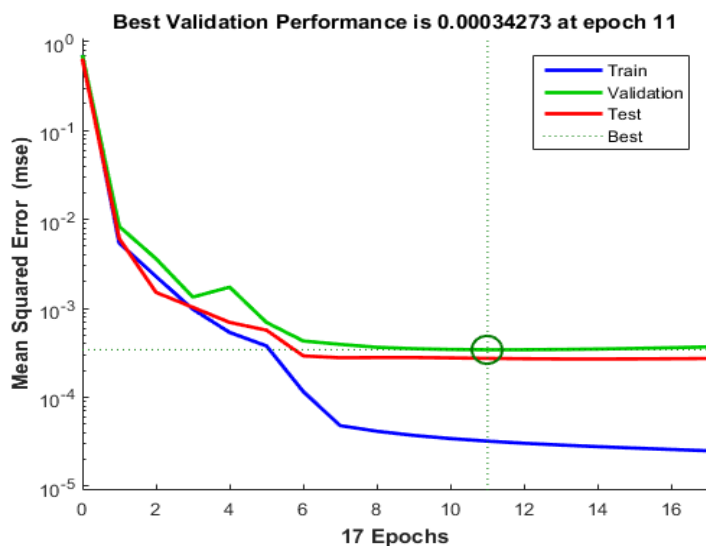
شکل (۴) نشان دهنده پیش‌بینی‌های ANN در برابر داده‌های واقعی مقاومت حرارتی است، که ضریب همبستگی^۱ بین خروجی‌ها و مقادیر هدف $R^2=0.9963$ به دست آمد که نشان دهنده تطابق خوب داده‌های پیش‌بینی شده با مقادیر واقعی است و دقت در پیش‌بینی توسط این مدل را تأیید می‌کند.



شکل ۴. مقایسه داده‌های واقعی (هدف) و داده‌های پیش‌بینی شده توسط ANN

برای تعیین الگوریتم یادگیری، الگوریتم‌های مختلفی تست شد که در میان الگوریتم‌های تست شده، الگوریتم LM عملکرد بهتری نسبت به الگوریتم‌های Scaled Conjugate Gradient (SCG) و Gradient descent with Variable Learning Rate Gradient Descent (GDX) و Gradient Descent with Momentum و adaptive learning rate backpropagation (GDA) (GDM) و Gradient Descent (GD) داشت که معیار این بررسی میزان پایین‌تر MSE و منحنی رگرسیون با مقدار R بالاتر بود؛ بنابراین الگوریتم LM برای مدل‌سازی عملکرد حرارتی Al_2O_3 انتخاب شد. شکل ۵ نشان دهنده روند خطای شبکه در آموزش، اعتبارسنجی و تست به عنوان تابعی از تعداد دوره‌های یادگیری است. هنگامی که خطای مجموعه داده‌های تست کمترین است، شبکه دارای همگرایی است. زمانی که شبکه همگرا شد آموزش متوقف می‌شود و MSE بعد از ۱۷ تکرار تقریباً ثابت شد. در این مقاله شبکه بعد از ۱۷ تکرار آموزش دید.

1. R2




شکل ۵. مقدار خطای MSE برای آموزش، اعتبارسنجی و تست در شبکه ANN

۴-۲. نتایج مدل سازی توسط ANFIS


در این مطالعه، سیستم ANFIS از نوع مدل فازی سوگنو درجه اول و همچنین ساختار کلاسترینگ کاهش^۱ استفاده شده است. الگوریتم هیبریدی که ترکیبی از الگوریتم پس انتشار^۲ و روش حداقل مربع خطا^۳ است برای آموزش ANFIS در نظر گرفته شد، که در مقایسه با روش پس انتشار، خطای کمتری تولید می‌کند. ضمناً آستانه همگرایی^۴ برابر ۰/۶۱۶ است. همچنین، توابع عضویت گوسی در این کار مورد استفاده قرار گرفت. ساختار مدل ANFIS جهت پیش‌بینی متغیر هدف در شکل ۶ نشان داده شده است.

1. Subtractive clustering
2. Backpropagation g radient descent
3. Least-squares method
4. coverage threshold





شکل ۶. ساختار یک مدل فازی سوگنو در جه اول با سه ورودی


بنابراین، مدل ANFIS بین داده‌های آزمایش و مقادیر پیش‌بینی شده یک رابطه به‌دست آورد. مشاهده می‌شود که نتایج ANFIS تطابق خوبی با اندازه‌گیری‌های آزمایشگاهی دارند. همچنین با توجه به شکل (۷) ضریب همبستگی $R^2=0.995$ نشان‌دهنده یک مطابقت رضایت‌بخش بین مقادیر پیش‌بینی شده و داده‌های آزمایش است.



شکل ۷. مقایسه داده‌های واقعی (هدف) و داده‌های پیش‌بینی شده توسط ANFIS

شکل (۸) مقایسه نموداری بین نتایج شبیه‌سازی مدل‌های ANN و ANFIS و داده‌های آزمایش (داده‌های واقعی) را نشان می‌دهد که نتایج براساس نسبت پر شدن در سه نمودار به تفکیک نشان داده شده که با توجه به تعداد زیاد داده‌ها، برای دیدن بهتر نتایج این کار انجام گرفته است. همان‌طور که ملاحظه می‌شود، نتایج مطابقت بسیار خوبی بین نتایج مدل و داده‌های واقعی از خود نشان می‌دهند.





شکل ۸. مقایسه داده‌های آزمایش و داده‌های پیش‌بینی توسط ANN و ANFIS

برای مقاومت حرارتی در نسب پر شدن (a) ۵۰٪، (b) ۶۰٪ و (c) ۷۰٪

نتایج مدل‌های ANN و ANFIS می‌تواند توسط جدول (۱) که در آن مقادیر R^2 و SD و SSE، RMSE گزارش شده، با مدل‌های دیگر مقایسه کرد. این پارامترهای آماری از طریق معادلات زیر محاسبه می‌شوند:

$$SD = \sqrt{\frac{1}{n-1} \sum_{i=1}^n \left(\left| \frac{y_{Exp,i} - y_{Model,i}}{y_{Exp,i}} \right| - AARE \right)^2} \quad (8)$$

$$AARE = \frac{1}{n} \sum_{i=1}^n \left(\left| \frac{y_{Exp,i} - y_{Model,i}}{y_{Exp,i}} \right| \right) \quad (9)$$

$$SSE = \sum_{i=1}^n (y_{Model,i} - y_{Exp,i})^2 \quad (10)$$


$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{Model,i} - y_{Exp,i})^2}{n}} \quad (11)$$

جدول ۱. پارامترهای آماری مدل‌های ANN و ANFIS

	R^2	SD	SSE	RMSE
ANN	۰/۹۹۶	۰/۰۱۸	۰/۰۱۷	۰/۰۰۹
ANFIS	۰/۹۹۵	۰/۰۲۱	۰/۰۲۲	۰/۰۱۱

مأخذ: نتایج تحقیق

در شکل (۹) میزان انحراف مقادیر پیش‌بینی شده توسط مدل‌های ANN و ANFIS نشان داده شده که همان‌طور که مشاهده می‌شود و با توجه به آمارهای گفته شده در جدول ۱ هر دو مدل عملکرد خوب و نزدیکی نسبت به هم دارند. میزان انحراف ANN و ANFIS به ترتیب (۰/۰۳۱ تا -۰/۰۴۴) و (۰/۰۵۹ تا -۰/۰۲۶) است. که انحراف ANFIS کمی بیشتر است. جدول بالا و همچنین شکل (۹) نشان می‌دهد که عملکرد ANN در پیش‌بینی مقاومت حرارتی بهتر بوده ولی با این حال عملکرد هر دو مدل بسیار به هم نزدیک بوده و هر دو نتایج بسیار خوب و قابل قبول ارائه دادند.



شکل ۹. میزان انحراف مقادیر پیش‌بینی شده توسط ANN و ANFIS نسبت به مقادیر واقعی (هدف)

۶. نتیجه‌گیری

امروزه تحقیقات در زمینه نانوسیالات ابعاد گسترده‌ای پیدا کرده است. تحقیقات نشان داده که استفاده از نانوذرات در سیال پایه باعث می‌شود که ضرایب انتقال حرارت و جرم افزایش یابد. افزایش ضرایب

انتقال حرارت و جرم سبب افزایش راندمان، کاهش اندازه تجهیزات و همچنین هزینه ساخت آنها می‌شود در نتیجه میزان مصرف انرژی را می‌توان را بهینه سازی نمود. در این مقاله عملکرد حرارتی نانوسیال آلومینا توسط ANN و ANFIS مدل سازی شد. که نتیجه حاصله بسیار دقیق و رضایت بخش بود و نشان داد که ANN و ANFIS می‌توانند در مدل سازی فرآیندهای حرارتی و دیگر نانوسیالات مورد استفاده قرار بگیرند و عملکرد بسیار فوق العاده‌ای از خود نشان دهند. نتایج مدل سازی نشان داد هر دو مدل عملکرد نزدیکی داشتند ولی ANN نتایج دقیق تر و قابل اطمینان تری در مقایسه با ANFIS فراهم می‌کند. نتایج مقایسه مقادیر واقعی و مدل هم نزدیک به یک بود و ضریب همبستگی برای هر دو بیش از ۰/۹۹ به دست آمد.

منابع

- [1] Abedini R. Esfandiyari et. al. (2012), "The Prediction of Undersaturated Crude Oil Viscosity: An Artificial Neural Network and Fuzzy Model Approach", *Petroleum Science and Technology*, vol. 30, pp. 2008-2021.
- [2] Aminossadati S. et. al. (2012), "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, pp. 102-111.
- [3] Chen Y.T. et. al. (2008), Effect of Nanofluid on Flat heat Pipe thermal Performance (2008). Twenty-fourth Annual IEEE Semiconductor Thermal Measurement and Management Symposium, pp. 16-19.
- [4] Dolatabadi M. et. al. (2018), "Modeling of Simultaneous Adsorption of dye and Metalion by Sawdust from Aqueous Solution using of ANN and ANFIS". *Chemometrics and Intelligent Laboratory Systems*, Vol. 181, pp. 72-78.
- [5] Esfandiyari et. al. (2018), "Prediction of Thiophene Removal from Diesel using [BMIM][AlCl₄] in EDS Process: GA-ANFIS and PSO-ANFIS modeling", *Petroleum Science and Technology*, pp. 1-7.
- [6] Esfandiyari et. al. (2016) "Neural Network and Neuro-fuzzy Modeling to Investigate the Power Density and Columbic Efficiency of Microbial Fuel cell". *Journal of the Taiwan Institute of Chemical Engineers*, Vol. 58, pp. 84-91.
- [7] Fazilat H. et. al. (2012), "Predicting the Mechanical Properties of Glass Fiber Reinforced Polymers via Artificial Neural Network and Adaptive Neuro-fuzzy Inference system", *Computational Materials Science*, Vol. 58, pp. 31-37.
- [8] Ghanbarpour et al. (2014), "Thermal Properties and Rheological Behavior of Water based Al₂O₃ Nanofluid as a Heat Transfer fluid", *Experimental Thermal and Fluid Science*, Vol 53, pp. 227-235.

- [9] Hakeem M. et al. (2008), "Prediction of Temperature Profiles using Artificial Neural Networks in a Vertical Thermosiphon Reboiler", *Applied Thermal Engineering*, Vol. 28, pp. 1572-1579.
- [10] Iyatomi H. and M. Hagiwara (2004), "Adaptive Fuzzy Inference Neural Network", *Pattern Recognition*, vol 37, pp. 2049-2057.
- [11] Jafari D. and S.M. Nowee (2015), "Studies on the Applicability of Artificial Neural Network (ANN) in Prediction of Thermodynamic Behavior of Sodium Chloride Aqueous System Containing a Non-Electrolytes". *World Academy of Science, Engineering and Technology, International Journal of Chemical, Molecular, Nuclear, Materials and Metallurgical Engineering*, Vol. 9, pp. 110-113.
- [12] Jafari M. et. al. (2017), "Energy Consumption and Heat Storage in a Solar Greenhouse: Artificial Neural Network Method", *Iranian Journal of Energy*, Vol. 20, pp. 5-22.
- [13] Jang J.S. (1993), "ANFIS: Adaptive-network-based Fuzzy Inference System. *IEEE Transactions on Systems*", *Man and Cybernetics*, Vol. 23, pp. 665-685.
- [14] Kang S.W. et. al. (2009), "Experimental Investigation of Nanofluids on Sintered Heat Pipe Thermal Performance". *Applied Thermal Engineering*, Vol.29, pp. 973-979.
- [15] Petković D. et. al. (2014), "Adaptive Neuro-fuzzy Prediction of Modulation Transfer Function of Optical Lens System". *Elsevier*. Vol. 50, pp. 89-97.
- [16] Pourtousi M. et. al. (2015), "A Combination of Computational Fluid Dynamics (CFD) and Adaptive Neuro-fuzzy System (ANFIS) for Prediction of the Bubble Column Hydrodynamics". *Powder Technology*, Vol.274, pp.466-481.
- [17] Qu J. et. al. (2010), "Thermal Performance of an Oscillating Heat Pipe with Al₂O₃-water Nanofluids". *International Communications in Heat and Mass Transfer*, Vol. 37, pp. 111-115.
- [18] Rahmanian B. et. al. (2012), "Prediction of MEUF process performance using artificial neural networks and ANFIS approaches". *Journal of the Taiwan Institute of Chemical Engineers*, Vol. 43, pp. 558-565.
- [19] Salehi H. et. al. (2013), "Neuro-fuzzy Modeling of the Convection Heat Transfer Coefficient for the Nanofluid". *Heat and Mass Transfer*, Vol.49, pp.575-583.
- [20] Shanbedi et. al. (2015), "Thermal Performance Prediction of Two-phase Closed Thermosyphon Using Adaptive Neuro-fuzzy Inference System". *Heat Transfer Engineering*, Vol. 36, pp. 315-324.
- [21] Shanbedi et. al. (2013), "Prediction of Temperature Performance of a Two-phase Closed Thermosyphon Using Artificial Neural Network". *Heat and Mass Transfer*, Vol. 49, pp. 65-73.
- [22] Soleymani A.R. et. al. (2011), "Artificial Neural Networks Developed for Prediction of dye Decolorization Efficiency with UV/K₂S₂O₈ process". *Chemical Engineering Journal*, Vol. 170, pp. 29-35.
- [23] Takassi M.A. et. al. (2011), "Fuzzy Model Prediction of Co (III) Al₂O₃ Catalytic behavior in Fischer-Tropsch Synthesis". *Journal of Natural Gas Chemistry*, Vol.20, pp. 603-610.

- [24] Tanhaei B. et. al. (2017), "Neuro-fuzzy Modeling to Adsorptive Performance of Magnetic Chitosan Nanocomposite". *Journal of Nanostructure in Chemistry*, Vol. 7, pp. 29-36.
- [25] Vasseghian Y. (2016), "Estimation of Global Solar Radiation using Artificial Neural Network in Kermanshah province". *Iranian Journal of Energy*, Vol 19, pp.1-10.
- [26] Xie H. et al. (1994) "Process Optimization using a Fuzzy Logic Response Surface Method". *IEEE Transactions on Components Packaging and Manufacturing Technology: Part A*, Vol. 17, pp. 202-211.
- [27] Yilmaz I. and O. Kaynar (2011), "Multiple Regression, ANN (RBF, MLP) and ANFIS Models for Prediction of Swell Potential of Clayey Soils". *Expert Systems with Applications*, Vol. 38, pp. 5958-5966.