

پیش بینی رسانایی گرمایی نانوسیال گرافن با مدل شبکه عصبی مصنوعی چند لایه پرسپترون

سهیلا خسروجردی

دانشجوی کارشناسی ارشد، دانشگاه آزاد اسلامی، واحد تهران مرکزی، باشگاه پژوهشگران جوان و نخبگان، تهران، ایران

آرش میر عبدالله لواسانی*

دانشیار، گروه مهندسی مکانیک، دانشگاه آزاد اسلامی واحد تهران مرکزی، تهران، ایران

مسعود وکیلی

کارشناسی ارشد، دانشکده مهندسی مکانیک، دانشگاه علم و صنعت ایران، تهران، ایران

چکیده

هدف از این مطالعه مدل سازی و پیش بینی رسانایی گرمایی نانو سیال گرافن به کمک شبکه عصبی مصنوعی چند لایه پرسپترون است. پارامترهای دمای نانوسیال، کسر حجمی و رسانایی گرمایی نانو ذره به عنوان ورودی شبکه در نظر گرفته شده است. با اطلاعات مربوط به اندازه گیری های تجربی محققین قبلی در مورد رسانایی گرمایی نانوسیال گرافن در دمای ۲۵ تا ۵۰ درجه سلسیوس و در کسر حجمی ۰/۰۰۵ تا ۰/۰۵۶ تست عملکرد شبکه انجام شده است. جهت بررسی میزان دقت مدل در پیش بینی رسانایی گرمایی نانوسیال، از شاخص های جذر میانگین مربعات خطا، ضریب تشخیص و درصد میانگین مطلق خطا استفاده شده است که این مقادیر به ترتیب ۹۹.۷ W/mK04/0 درصد و ۰/۲۶ درصد است. نتایج حاصل از شاخص ها، دقت و اطمینان مدل ارائه شده را در مقایسه با نتایج تجربی و مدل های تئوری را نشان می دهد.

واژه های کلیدی: رسانایی گرمایی، شبکه عصبی مصنوعی، نانوسیال، گرافن.

Predicting Thermal Conductivity of Graphene Nanofluid with Artificial Neural Networks Multilayer Perceptron

S. Khosrojerdi

Department of Mechanical Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran

A. Mirabdollah Lavasani

Department of Mechanical Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran

M. Vakili

Iran University of Science and Technology, Tehran, Iran

Abstract

The purpose of this study is to model and predict the thermal conductivity of graphene nano fluid through the artificial neural network of multilayer perceptron. Nano Fluid temperature, volumetric fractions and thermal conductivity of nanoparticles are considered as network inputs. According to the experimental data of previous experiments on thermal conductivity of graphene nanoparticles at the temperature of 25 to 50 ° C and the volume fraction of 0.055-0.066, the network performance tests were performed. In order to evaluate the accuracy of the model in predicting the thermal conductivity of the nanofluid, the root mean square error indices, detection coefficient and absolute error percentage are used. These values are 0.04 W/ mK, 99% and 0.26% , respectively. The results of the indicators show the accuracy and reliability of the proposed model in comparison with experimental results and theoretical models.

Keywords: thermal conductivity, artificial neural network, nanofluids, grapheme.


۱-مقدمه

با بررسی روش های تئوری، به این نتیجه رسیدند که روش ماکسول کلاسیک روش مناسبی برای پیش بینی رسانایی گرمایی نخواهد بود. آراویند و همکارانش [۴] با بررسی اثر گرافن در افزایش انتقال گرمای نانو سیال به نتیجه رسیدند که نانو سیال گرافن با کسر حجمی ۰/۱۴ درصد موجب افزایش ۶/۵ درصد در اتیلن گلیکول و ۱۳/۶ درصدی در آب مقطر در دمای ۲۵ سلسیوس خواهد شد. یو و همکارانش [۵] با استفاده از ذرات نانوگرافن در اتیلن گلیکول به این نتیجه رسیدند که نانو سیال در کسر حجمی ۵ درصد افزایش بیش از ۸۶ درصدی رسانایی گرمایی را نشان خواهد داد. انتقال گرمای نانو سیال ها با استفاده از روش های تجربی و عددی به دست می آید [۶]. گرچه روش های آزمایشگاهی از لحاظ دقت از روش های تئوری قابلیت اطمینان بیشتری دارند اما با توجه به نیاز به امکانات و تجهیزات

انگاره ی پراکنده سازی ذرات جامد در سیالات به منظور افزایش توانایی انتقال گرمای سیالات بیش از یک قرن پیش آغاز شده است. جیمز کلرک ماکسول، یک مدل تئوری برای رسانایی الکتریکی ذرات جامد در مخلوط های ناهمگن ارائه داد که از آن به بعد مدل کلاسیک ماکسول برای بررسی انتقال گرما در مخلوط های ذرات جامد در مایع به کار گرفته شد که محدود به ذرات با اندازه میلی متر و یا میکرومتر بود [۱]. طبق نتایج محققان افزودن ذرات جامد فلزی در مقیاس نانو به سیال پایه موجب افزایش ضریب انتقال گرما و در نتیجه بهبود خواص فیزیکی آن می شود [۲]. گوپتا و همکارانش [۳] با بررسی تجربی رسانایی گرمایی نانو سیال گرافن نشان دادند نانو سیال در کسر حجمی کم نیز موجب افزایش انتقال گرما خواهد شد. در ادامه

* نویسنده مکاتبه کننده، آدرس پست الکترونیکی: arashlavasani@iauctb.ac.ir

سیگنال ورودی را به لایه‌ی بعدی منتقل می‌کند. قدرت ارتباط هر نورون با نورون دیگر را وزن نورون گویند که تعداد نورون‌ها در هر لایه به وزن و مقدار نورون‌های لایه‌ی قبلی بستگی دارد. علاوه بر لایه‌ی ورودی، شبکه‌های عصبی متشکل از لایه‌های میانی و لایه‌ی خارجی نیز می‌باشد. لازم به ذکر است که تعداد لایه‌های میانی و نیز تعداد نورون‌های هر لایه می‌تواند به هر مقداری باشد ولی باید توجه داشت که اضافه نمودن هر نورون به لایه‌ی میانی بآنکه خطا را کاهش می‌دهد ولی باعث افزایش زمان محاسبات خواهد گشت. بنابراین باید به تناسب منطقی در انتخاب تعداد نورون‌ها دست یافت [۱۶].



شکل ۱- طرحواره نورون با توجه به چگونگی عملکرد و جایگاه پارامترهای موثر در مدل‌سازی

در این شکل، x_i پارامترهای ورودی شبکه و n تعداد پارامترهای ورودی است. همچنین j تعداد نورون‌های شبکه عصبی و w_{ji} وزن نورونی است که نشان‌دهنده‌ی قدرت سیناپس نورون i به نورون j می‌باشد. خروجی ترکیب خطی نیز u_j در نظر گرفته می‌شود که برابر است با:

$$u_j = \sum_{i=1}^n w_{ji} x_i \quad (1)$$

$$y_j = \varphi(u_j + b_j) \quad (2)$$

$$v_j = u_j + b_j \quad (3)$$

که در آن $\varphi(0)$ به‌عنوان تابع فعال‌سازی و b_j به‌عنوان تمایل تابع در نظر گرفته شده است [۱۷].

توابع مختلف فعال‌سازی تاکنون استفاده شده است که در این مطالعه از دو تابع فعال‌سازی Log-sigmoid [۲۰] و Tangent sigmoid برای لایه‌های پنهان و از تابع Purelin برای لایه خروجی استفاده شده است [۱۷] که در ذیل مشخص شده است:

$$\text{Tansig}(x) = \frac{2}{1 + \exp(-2x)} - 1 \quad (4)$$

$$\text{Logsig}(x) = \frac{1}{1 + \exp(-x)} \quad (5)$$

$$\text{Purelin}(x) = x \quad (6)$$

که x به‌عنوان ورودی تابع فعال‌سازی در نظر گرفته شده است. در حالت کلی یک شبکه مصنوعی همانند یک تابع عمل نموده و به تعداد نورون‌های لایه ورودی، متغیر ورودی دریافت و به تعداد نورون‌های لایه‌ی خارجی، خروجی می‌دهد. در این مطالعه پارامترهای ورودی شامل دمای نانو سیال و کسر حجمی است که در لایه اول

خاص معمولاً با دشواری انجام می‌شوند [۷]. شبکه‌های عصبی مصنوعی یکی از مباحث هوش مصنوعی است که از عملکرد مغز انسان در شناسایی پدیده‌ها الهام گرفته شده است و با کمک آن می‌توان در پیش‌بینی و مدل‌سازی پدیده‌ها استفاده نمود [۸]. یکی از کاربردهای آن در پیش‌بینی و مدل‌سازی میزان رسانایی گرمایی مواد اعم از گاز [۹] و مایع، جامد اتمی باشد [۱۰]. طبق تحقیقات صورت گرفته توسط پاپری و همکاران [۱۱] جهت تعیین رسانایی گرمایی نانوسیال‌هایی که شامل نانولوله‌های کربنی چند جداره به‌عنوان نانو ذره در روغن، آب مقطر، دکن و اتیلن گلیکول معلق شده است، به کمک شبکه‌های عصبی نشان داد که استفاده از مدل شبکه عصبی مصنوعی در مقایسه با روش‌های تئوری زو ۲۰۰۵، زو ۲۰۰۶ و مدل یو و چوی دارای دقت بیشتری بوده است که این میزان در شاخص متوسط خطای مطلق برابر ۳/۲۶ درصد بوده است و همبستگی بین مقدار اندازه‌گیری شده به‌صورت تجربی و مقدار پیش‌بینی برابر ۰/۹۹۱ بوده است. حجت و همکاران [۱۲] با بررسی رسانایی گرمایی سه نوع نانو سیال که شامل اکسید آلومینیوم، اکسید مس و اکسید تیتانیوم به کمک شبکه‌های عصبی مصنوعی نشان دادند مدل ارائه شده دارای تطبیق خوبی نسبت به روش آزمایشگاهی داشت که در مقایسه با مدل همیلتن کروسر که امکان بررسی اثر دمای سیال پایه و میزان کسر حجمی را ندارد از دقت بهتری برخوردار بود. لانگو و همکارانش [۱۳] به کمک شبکه عصبی نشان دادند که رسانایی گرمایی نانو سیال اکسید تیتانیوم و اکسید آلومینیوم بر پایه آب که انتخاب چهار پارامتر ورودی جهت آموزش شبکه که شامل کسر حجمی، میزان دمای نانو سیال، رسانایی گرمایی نانو ذره و اندازه توده نانو ذره است نتیجه‌ی بهتری در مقابل سه پارامتر و بدون در نظر گرفتن اندازه توده دارد. همت و همکارانش [۱۴] به کمک شبکه‌های عصبی اثر دما، کسر حجمی، اندازه نانو ذره بر روی رسانایی گرمایی نانو سیال اکسید منگنز بر پایه اتیلن گلیکول بررسی و نشان دادند دمای نانو سیال اثر کمتری را نسبت به بقیه پارامترهای مورد بررسی برافزایش رسانایی گرمایی خواهد داشت. همت و همکارانش [۱۵] مدلی با دقت بالا جهت پیش‌بینی رسانایی گرمایی نانو سیال اکسید زیرکونیوم بر پایه اتیلن گلیکول به کمک شبکه عصبی و با در نظر گرفتن پارامترهای دمای نانو سیال و کسر حجمی به‌عنوان ورودی شبکه ارائه دادند. در این مطالعه تجربی صورت گرفته ۹ کسر حجمی مختلف در محدوده ۰/۰۶۲۵ تا ۵ درصد بررسی شد. همچنین چهار دمای مختلف جهت آموزش و مدل‌سازی شبکه عصبی انجام شد. با توجه به اینکه تاکنون رسانایی گرمایی نانو سیال گرافن اکساید/آب دیونیزه با شبکه عصبی مصنوعی اندازه‌گیری نشده است و از آنجا که روش پیش‌بینی رسانایی گرمایی نانو سیال به کمک شبکه عصبی چندلایه پسپترون محاسباتی می‌باشد، در این پژوهش پیش‌بینی رسانایی حرارتی حاصل و با نتایج تجربی مقایسه شدند.

۲- مدل‌سازی

در یک شبکه عصبی مصنوعی چندلایه، نورون‌ها در لایه‌های مختلفی قرار می‌گیرند. لایه اول را لایه ورودی گویند که اطلاعات ورودی را دریافت نموده و برحسب قدرت ارتباطش با نورون لایه‌ی دیگر،

گرمایی نانوسیالها، نشان داد مدل تعمیم یافته ماکسول که توسط ن صورت گرفته است نتایج قابل قبولی را در جهت پیش بینی و تطابق با نتایج آزمایشگاهی از خود نشان داد. مطابق با مدل تعمیم یافته ن، رسانایی گرمایی نانو سیال مطابق با رابطه زیر محاسبه می شود:

$$K = K_f \frac{3 + \phi [2\beta_{11}(1-L_{11}) + \beta_{33}(1-L_{33})]}{3 - \phi(2\beta_{11}L_{11} + \beta_{33}L_{33})} \quad (11)$$

که در آن L_{ii} به عنوان فاکتور هندسی و ϕ کسر حجمی نانو سیال را نشان می دهد، همچنین B_{ii} با استفاده از رابطه زیر به دست می آید: برای گرافن مقادیر $L_{11}=0$ و $L_{33}=1$ می باشد. همچنین رسانایی گرمایی بین صفحه ی گرافن W/mK $6/8 \pm 0/8$ می باشد [5].

۳- نتایج

بهینه ترین حالت با استفاده از سعی و خطا و با تغییر نوع توابع، تعداد لایه های پنهانی و تعداد نورون های هر لایه، به دست آمده است. جدول ۱ نتایج حاصل از مدل سازی صورت گرفته با شرایط مختلف را در دست بندی های عنوان شده را نشان می دهد. بهینه ترین حالت که دارای خطای کمتری می باشد، استفاده از دولایه ی پنهان با ۷ نورون در لایه اول و ۱۴ نورون در لایه دوم که در هر کدام از لایه ها از تابع Logsig و در لایه خروجی از تابع انتقال خطی purelin استفاده شده است. با توجه به بررسی های صورت گرفته و با انتخاب بهترین مدل که مربوط به ANN-8 می باشد، مقدار تجربی رسانایی گرمایی گرافن با پایه آب با مدل ارائه شده در شکل ۲ مورد مقایسه قرار گرفته است. با توجه به بررسی های صورت گرفته و با انتخاب بهترین مدل که مربوط به ANN-8 می باشد، مقدار تجربی هدایت گرمایی گرافن با پایه آب با مدل ارائه شده در شکل ۲ مورد مقایسه قرار گرفته است.

مطابق با شکل ۲ نتایج حاصل از مدل ارائه شده، جذر میانگین مربعات خطای W/mK $0/04$ ، میانگین مطلق خطای $0/26$ درصد و ضریب تشخیص ۹۹ درصد می باشد که این مقادیر نشان از دقت بالا و نتایج قابل اطمینان مدل ارائه شده می دهد. ضریب همبستگی بین نتایج گرافن $0/9915$ می باشد. با توجه به اینکه ضریب همبستگی به عدد یک نزدیک می باشد نتایج پیش بینی در حالت مطلوبی قرار دارد. مقایسه نتایج حاصل از مدل تئوری ن و مقادیر تجربی و همچنین شبکه عصبی برای رسانایی گرمایی گرافن در شکل ۴ نشان داده شده است. اختلاف نتایج کار حاضر با مقادیر تجربی حدود $0/5$ تا 3 درصد است، در صورتی که اختلاف نتایج مدل تئوری با مقادیر تجربی در کسر حجمی های بالای $0/2$ درصد با روند رو به رشدی همراه بوده تا جایی که این اختلاف در کسر حجمی $0/056$ به حدود 20 درصد می رسد با مقایسه این مقادیر می توان نتیجه گرفت عملکرد شبکه عصبی در مقایسه با مدل تئوری مناسب تر است. با توجه به اینکه جهت آموزش شبکه عصبی از نتایج اندازه گیری های تجربی به صورت مستقیم استفاده شده است پیش بینی شبکه عصبی در کلیه سطوح کسر حجمی دقت مناسبی دارد در صورتی که مدل ن تنها در کسر حجمی ها کم دارای دقت نسبی بوده است.

قرار گرفته اند. با توجه به وزن های تعلق گرفته به نورون ها و همچنین تعداد نورون های مختلف در لایه های میانی، در انتها و در لایه نهایی ضریب هدایت گرمایی به عنوان خروجی شبکه در نظر گرفته شده است. در این تحقیق به کمک شبکه عصبی و با نرم افزار MATLAB R2013a مدل سازی انجام شده است. پارامترهای ورودی شبکه که به صورت تجربی اندازه گیری شده (که در بخش داده های تجربی و مدل تئوری تشریح شده است) و جهت آموزش شبکه مورد استفاده قرار گرفته است، سی نمونه بوده است که با استفاده از رابطه زیر در بازه -1 تا 1 نرمالیزه شده و سپس مورد استفاده در شبکه قرار گرفته است.

$$y = 2 \times \frac{x - x_{min}}{x_{max} - x_{min}} + 1 \quad (7)$$

۲-۲- تحلیل آماری

در این مطالعه برای سنجش میزان دقت و عملکرد مدل و شبکه از شاخص های آماری جذر میانگین مربعات خطا، درصد میانگین مطلق خطا و ضریب تشخیص، استفاده شده است. شاخص های جذر میانگین مربعات خطا و درصد میانگین مطلق خطا، شاخص های مناسبی برای تعیین میزان دقت مدل می باشند، بطوریکه هر چه میزان این دو شاخص به صفر نزدیک تر باشد نشان از دقت بالای مدل است. ضریب تشخیص بیانگر میزان احتمال همبستگی میان دودسته داده در آینده می باشد که این مقدار هر چه به عدد صد نزدیک باشد، نشان از عملکرد بهتر مدل می باشد. روابط مورد استفاده جهت محاسبه شاخص های فوق به صورت زیر تعریف می شوند:

$$RSMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (K_p - K_a)^2} \quad (8)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{(K_p - K_a)}{K_a} \right| \times 100 \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (K_a - K_p)^2}{\sum_{i=1}^n (K_a - \bar{K}_a)^2} \quad (10)$$

که K_p ضریب انتقال گرمایی پیش بینی شده و K_a ضریب انتقال گرمایی واقعی می باشد. \bar{K}_a میانگین ضریب انتقال گرمایی واقعی در دوره ی اندازه گیری شده و n تعداد نمونه های اندازه گیری شده می باشد.


۲-۱- داده های تجربی و مدل تئوری

برای آموزش و تست شبکه در این تحقیق از اطلاعات و نتایج تجربی بی بی و همکارش [۱۸] بر روی گرافن با پایه آب مقطر که اندازه گیری رسانایی گرمایی نانو سیال با استفاده از روش سیم داغ در دمای 25 تا 50 درجه سلسیوس در کسر حجمی $0/005$ تا $0/007$ ، $0/009$ ، $0/03$ ، $0/056$ درصد صورت گرفته، استفاده شده است.


علاوه بر اندازه گیری های تجربی در برخی از تحقیقات جهت پیش بینی رسانایی گرمایی نانو سیال ها از روش های تئوری استفاده می شود. نتایج تحقیقات صورت گرفته توسط 34 سازمان در سرتاسر دنیا [۱۹] بر روی تکمیل و تعیین یک الگو، جهت مطالعه بر روی رسانایی

جدول ۱- نتایج شاخص‌های اندازه‌گیری دقت مدل در بخش آموزش، اعتبارسنجی و آزمون شبکه با توجه به شرایط مختلف

Model	Function	Neuro ns	Train			Validation			Test			
			MAPE	RMSE	R ²	MAPE	RMSE	R ²	MAPE	RMSE	R ²	
ANN	1	Logsig-purelin	3-1	1.13	0.10	0.98	6.15	0.16	0.95	5.30	0.18	0.97
	2	Logsig-purelin	7-1	1.66	0.06	0.98	1.69	0.08	0.99	2.82	0.08	0.99
	3	Logsig-purelin	12-1	1.53	0.051	0.99	2.96	0.07	0.99	0.1	0.04	0.99
	4	Tansig-purelin	10-1	0.95	0.05	0.99	0.53	0.03	0.99	0.66	0.05	0.99
	5	Tansig-purelin	16-1	2.42	0.05	0.99	2.91	0.10	0.98	2.84	0.14	0.97
	6	Tansig-purelin	6-1	2.94	0.09	0.97	5.23	0.07	0.98	5.7	0.11	0.98
	7	Logsig-purelin	16	2.94	0.09	0.99	1.16	0.04	0.99	1.58	0.10	0.98
	8	Logsig - Logsig-purelin	7-14-1	0.08	0.02	0.99	1.01	0.05	0.96	0.95	0.09	0.99
	9	Logsig - Logsig-purelin	3-9-1	6.97	0.11	0.97	2.17	0.18	0.68	5.25	0.14	0.98
	10	Tansig-logsig-purelin	6-12-1	1.3	0.05	0.99	4.96	0.06	0.98	5.04	0.09	0.97
	11	Tansig-logsig-purelin	8-22-1	0.57	0.06	0.99	0.45	0.09	0.98	1.12	0.17	0.83
	12	Logsig-Tansig-purelin	11-8-1	0.68	0.04	0.99	4.8	0.09	0.98	8.62	0.11	0.98




شکل ۴- نتایج اندازه‌گیری تجربی، مدل تئوری ن و مدل شبکه عصبی نانو سیال گرافن



شکل ۵- نتایج تجربی و مقدار پیش‌بینی رسانایی گرمایی نانو سیال گرافن بر اساس کسر حجمی و دمای مختلف

۴- نتیجه‌گیری

در این مطالعه استفاده از عملکرد شبکه عصبی مصنوعی چندلایه پرسپترون جهت پیش‌بینی ضریب هدایت حرارتی نانو سیال گرافن بر پایه آب بررسی شده است. نتایج حاصل از مدل‌سازی صورت گرفته با نتایج تجربی مورد مقایسه قرار گرفت که نتایج حاصل از مدل نشان از دقت مورد اطمینان شبکه عصبی مصنوعی در مقایسه با مقادیر حاصل از اندازه‌گیری‌های تجربی و مدل‌سازی تئوری، دارد. اختلاف نتایج شبکه عصبی در مقایسه با نتایج تجربی حدود ۰/۵ تا ۳ درصد می‌باشد که این مقدار در مقایسه با اختلاف مدل تئوری Nan که حدود ۲۰ درصد است بسیار مناسب می‌باشد. این اختلاف مزیت مدل‌سازی به کمک شبکه عصبی نسبت به تئوری Nan را نشان می‌دهد. از آنجایی که انجام عملیات آزمایشگاهی جهت سنجش رسانایی گرمایی نانو سیال گرافن هزینه بالای دارد، استفاده از مدل پیش‌بینی کننده شبکه عصبی مصنوعی آرایه شده در این مطالعه پیشنهاد می‌گردد.



شکل ۶- نمودار همبستگی بین نتایج اندازه‌گیری و مدل شبکه عصبی مصنوعی نانو سیال گرافن

- [1] Das, Sarit K., et al., Nanofluids: science and technology. John Wiley & Sons, 2007.
- [2] Chol, S. U. S., Enhancing thermal conductivity of fluids with nanoparticles, ASME-Publications-Fed 231 PP. 99-106, 1995.
- [3] Gupta Soujit Sen, et al., Thermal conductivity enhancement of nanofluids containing graphene nanosheets, Journal of Applied Physics 110.8, 084302, 2011.
- [4] Aravind, SS Jyothirmayee, and S. Ramaprabhu. Surfactant free graphene nanosheets based nanofluids by in-situ reduction of alkaline graphite oxide suspensions., Journal of Applied Physics 110.12, 124326, 2011.
- [5] Yu, Wei, et al. Significant thermal conductivity enhancement for nanofluids containing graphene nanosheets, Physics Letters A. 375.10, 1323-1328, 2011.
- [6] Barbés, Benigno, et al. Thermal conductivity and specific heat capacity measurements of CuO nanofluids, Journal of Thermal Analysis and Calorimetry 115.2, 1883-1891, 2014.
- [7] Paul, G., et al., Techniques for measuring the thermal conductivity of nanofluids: a review, Renewable and Sustainable Energy Reviews 14.7 (): 1913-1924. nanofluids: A review, Renewable and Sustainable Energy Reviews 14, 1913–1924, 2010.
- [8] Eslamloueyan, R., and M. H. Khademi, Estimation of thermal conductivity of pure gases by using artificial neural networks, International Journal of Thermal Sciences 48.6, 1094-1101, 2009.
- [9] Najafi, Alireza, et al. Thermal Conductivity Prediction of Pure Liquids Using Multi-Layer Perceptron Neural Network, Journal of Thermophysics and Heat Transfer 29.1, 197-202, 2014.
- [10] Bhoopal, Rajpal S., et al. Applicability of artificial neural networks to predict effective thermal conductivity of highly porous metal foams, Journal of Porous Media 16.7, 2013..
- [11] Papari, Mohammad M., et al., Modeling thermal conductivity augmentation of nanofluids using diffusion neural networks, International Journal of Thermal Sciences 50.1, 44-52, 2011.
- [12] Hojjat, M., et al., Thermal conductivity of non-Newtonian nanofluids: experimental data and modeling using neural network, International Journal of Heat and Mass Transfer 54.5, 1017-1023, 2011.
- [13] Longo, Giovanni A., et al., Application of artificial neural network (ANN) for the prediction of thermal conductivity of oxide–water nanofluids, Nano Energy 1.2, 290-296, 2012.
- [14] Esfe, Mohammad Hemmat, et al., Thermal conductivity modeling of MgO/EG nanofluids using experimental data and artificial neural network, Journal of Thermal Analysis and Calorimetry 118.1, 287-294, 2014.
- [15] Esfe, Mohammad Hemmat, et al. Modeling of thermal conductivity of ZnO-EG using experimental data and ANN methods, International Communications in Heat and Mass Transfer 63, 35-40, 2015.
- [16] Haykin, Simon, and Neural Network., A comprehensive foundation, Neural Networks 2.2004, 2004.
- [17] Araghinejad, Shahab. Data-driven modeling: using MATLAB® in water resources and environmental engineering. Vol. 67. Springer Science & Business Media, 2013.
- [18] Baby, Tessa Theres, and Ramaprabhu S., Investigation of thermal and electrical conductivity of graphene based nanofluids, Journal of Applied Physics 108.12, 124308, 2010.
- [19] Buongiorno, Jacopo, et al. A benchmark study on the thermal conductivity of nanofluids, Journal of Applied Physics 106.9, 094312, 2009.