

## مدلسازی با استفاده از شبکه عصبی مصنوعی جهت پیش بینی هدایت حرارتی نانوسیال نانولوله کربنی چند جداره عامل دار - آب و ارائه رابطه تجربی جدید

مسعود افرند<sup>۱</sup> و محمد همت اسفه<sup>۲\*</sup>

اطلاعات مقاله	چکیده
دریافت مقاله: ۱۳۹۴/۰۸/۲۱ پذیرش مقاله: ۱۳۹۶/۰۳/۱۷	در این مقاله، بر اساس نتایج آزمایشگاهی، و با استفاده از روش برازش منحنی و شبکه عصبی مصنوعی اثر دما و کسر حجمی نانولوله‌ها بر ضریب هدایت حرارتی نانوسیال نانولوله کربنی چند جداره عامل دار-آب بررسی شد. یک رابطه دقیق به صورت تابعی از کسر حجمی و دما برای پیش بینی ضریب هدایت حرارتی نانوسیال ارائه شد. همچنین شبکه های عصبی مختلفی به منظور مدلسازی ضریب هدایت حرارتی نانوسیال طراحی شد. در این شبکه‌ها دما و کسر حجمی به عنوان متغیرهای ورودی و ضریب هدایت حرارتی به عنوان متغیر خروجی در نظر گرفته شد. شبکه عصبی بهینه با در نظر گرفتن حداقل خطا در پیش بینی ضریب هدایت حرارتی نانوسیال به دست آمد. مقایسه‌ها نشان داد که شبکه عصبی مصنوعی می‌تواند پیش بینی دقیق‌تری نسبت به روش برازش منحنی در تخمین ضریب هدایت حرارتی این نانوسیال ارائه کند. همچنین نتایج نشان داد که رابطه تجربی ارائه شده به وسیله روش برازش منحنی دارای دقت قابل قبولی است.
<b>واژگان کلیدی:</b> مدلسازی، شبکه عصبی، هدایت حرارتی، رابطه تجربی، نانوسیال، نانولوله کربنی چند جداره.	

### ۱-مقدمه


هدایت حرارتی نانوسیالات به دما، شکل و اندازه نانوذرات، کسر حجمی نانوذرات و نوع سیال پایه بستگی دارد [۲] تا [۱۰]. از آنجایی که آزمایش‌های مورد نیاز برای اندازه‌گیری ضریب هدایت حرارتی نانوسیالات فرایندی وقت‌گیر و هزینه‌بر است، تعدادی از پژوهشگران تلاش کردند تا روابطی برای تخمین ضریب هدایت حرارتی نانوسیالات مختلف ارائه کنند. از جمله این پژوهشگران می‌توان چون و همکاران [۱۱]، لی و پترسون [۱۲]، واجها و داس [۱۳]، دانگ‌تانگ‌سوک و ونگویز [۱۴]، تنگ و همکاران [۱۵]، قنبرپور و همکاران [۱۶]، طغرابی و همکاران [۱۷]، سلطانی‌مهر و افرند [۱۸]، سربلوک زاده و همکاران [۱۹] و همت و همکاران [۲۰] را نام برد.

مایعاتی مانند آب، روغن و اتیلن گلیکول نقشی کلیدی در بسیاری از کاربردهای مهندسی نظیر فرایندهای ریخته‌گری، مبدل‌های حرارتی و سیستم‌های خنک‌کاری تجهیزات الکترونیکی دارند. به دلیل پایین بودن ضریب هدایت حرارتی این مایعات روش‌های زیادی با هدف افزایش ضریب انتقال حرارت آن‌ها به کار گرفته شده اند. یکی از روش‌های بهبود ضریب انتقال حرارت این مایعات، افزودن نانوذرات جامد به آن‌هاست که اولین بار توسط چوی [۱] در سال ۱۹۹۵ به کار گرفته شد. بسیاری از دانشمندان آزمایش‌های متعددی در اندازه‌گیری ضریب هدایت حرارتی نانوسیالات انجام داده‌اند. آن‌ها گزارش کرده‌اند که ضریب

\* پست الکترونیک نویسنده مسئول: m.hemmatesfe@gmail.com

۱. استادیار، گروه مهندسی مکانیک، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران  
۲. دانشگاه آزاد اسلامی، واحد خمینی شهر، باشگاه پژوهشگران جوان و نخبگان، اصفهان، ایران

داده‌های آزمایشگاهی برای نسبت هدایت حرارتی نانوسیال نانولوله کربنی چند جداره عامل دار - آب در شکل (۱) نشان داده شده‌اند [۲۰]. آزمایش‌ها در بازه دمایی ۲۵ تا ۶۰ درجه سانتیگراد و برای کسرهای حجمی ۰/۰۵، ۰/۱، ۰/۲، ۰/۴ و ۰/۸ و ۱ درصد انجام شده است.



شکل ۱- نسبت هدایت حرارتی بر حسب کسر حجمی نانولوله‌ها برای دماهای مختلف [۲۰]

به منظور تخمین نسبت ضریب هدایت حرارتی نانوسیال یک رابطه تجربی بر اساس داده‌های آزمایشگاهی پیشنهاد می‌شود. این رابطه دارای دقت بالایی است و به صورت زیر بیان می‌شود:

$$\frac{k_{nf}}{k_{bf}} = 0.9997 + 0.0205 (\phi^{1.139})(T^{0.7616}) \quad (1)$$

که در آن که  $k_{nf}$  و  $k_{bf}$ ، به ترتیب هدایت حرارتی نانوسیال و هدایت حرارتی سیال پایه هستند. همچنین،  $T$  دما بر حسب درجه سانتیگراد و  $\phi$  کسر حجمی نانوسیال بر حسب درصد است. رابطه پیشنهادی به وضوح اثرات دما و کسر حجمی نانولوله‌ها را بر ضریب هدایت حرارتی نشان می‌دهد.

### ۳- شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی یکی از پرکاربردترین مدل‌های تحلیل غیر خطی است و علت این امر دقت بالای این روش به همراه کاهش هزینه و زمان است. شبکه عصبی مصنوعی در واقع یک شبکه پردازش موازی است که برای تعیین روابط خطی و غیر خطی بین پارامترهای فرآیند و پیش بینی متغیرهای خروجی استفاده می‌شود.

شبکه‌های عصبی مصنوعی با خصوصیات زیر بیان می‌شوند:

با پیشرفت‌هایی که در علوم کامپیوتر و نرم افزار به وجود آمده است، پژوهشگران با بکارگیری روش‌های محاسبات نرم افزاری نظیر شبکه‌های عصبی مصنوعی (ANN)، منطق فازی و الگوریتم‌های ژنتیک سعی کردند ضریب هدایت حرارتی نانوسیالات را مدلسازی کنند. در همین راستا، پاپری و همکاران [۲۱] با استفاده از شبکه عصبی ضریب هدایت حرارتی نانوسیالات مختلف را مدلسازی کردند. حجت و همکاران [۲۲] ابتدا با روش‌های آزمایشگاهی ضریب هدایت حرارتی نانوسیالات مختلف حاوی نانوذرات اکسید آلومینیوم، دی‌اکسید تیتانیوم و اکسید مس را اندازه گیری کردند. سپس با استفاده از شبکه عصبی نتایج حاصل از کار آزمایشگاهی را مدل کردند. ایشان دما و کسر حجمی نانوذرات را به عنوان متغیرهای ورودی و ضریب هدایت حرارتی نانوسیال را به عنوان متغیر خروجی در نظر گرفتند. لونگو و همکاران [۲۳] دو شبکه عصبی برای تعیین ضریب هدایت حرارتی نانوسیالات حاوی اکسید آلومینیوم و دی اکسید تیتانیوم پیشنهاد کردند. متغیرهای ورودی عبارت بودند از: دما، کسر حجمی و قطر نانوذرات. اخیراً همت و همکاران [۲۴] و افرند و همکاران [۲۵] در کارهایی متفاوت به مدلسازی ضریب هدایت حرارتی نانوسیالات مختلف با استفاده از شبکه عصبی و ارائه روابط تجربی برای پیش‌بینی آن پرداخته‌اند.

مروری بر پژوهش‌های پیشین نشان داد که ارائه رابطه تجربی و مدلسازی به کمک شبکه عصبی روشی مناسب است که مورد توجه پژوهشگران زیادی قرار گرفته است. این روش‌ها می‌توانند جایگزین آزمایش‌های مکرر، که وقت‌گیر و هزینه‌بر هستند، شوند. از این رو در این پژوهش ابتدا با استفاده از نتایج آزمایشگاهی یک رابطه تجربی به منظور تخمین ضریب هدایت حرارتی نانوسیال نانولوله کربنی چند جداره عامل دار - آب با استفاده از روش برازش منحنی ارائه می‌شود. سپس با در نظر گرفتن دما و کسر حجمی نانولوله‌ها به عنوان متغیرهای ورودی و ضریب هدایت حرارتی نانوسیال به عنوان متغیر خروجی، شبکه‌هایی با تعداد نرون‌های مختلف مورد بررسی قرار گرفته و شبکه مناسب و بهینه انتخاب می‌شود. در پایان خروجی شبکه عصبی با نتایج حاصل از رابطه تجربی پیشنهادی و نتایج آزمایشگاهی مقایسه می‌شوند.


### ۲- داده‌های آزمایشگاهی و رابطه تجربی

شبکه عصبی مصنوعی بهینه شده با در نظر گرفتن حداقل خطای پیش بینی با تغییر تعداد نرون‌های لایه مخفی، توابع انتقال و تکرار پذیری مرحله آموزش شبکه بدست آمده است. به منظور محاسبه و تعیین بهترین تعداد نرون در لایه مخفی، ساختارهای متفاوتی مورد بررسی قرار گرفت. شکل (۳) نشان دهنده خطای هر ساختار شبکه عصبی مصنوعی بر حسب تغییر تعداد نرون‌ها در لایه مخفی است. همانطور که مشاهده می‌شود شبکه عصبی مصنوعی با تعداد ۱۱ نرون در لایه مخفی، کمترین مقدار میانگین مربعات خطا (MSE) را دارد.

رابطه ۴ بیانگر تابع میانگین مربعات خطا است:

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_{Pred} - Y_{Exp})^2 \quad (4)$$

که در آن  $Y_{Exp}$  داده آزمایشگاهی،  $Y_{Pred}$  خروجی شبکه عصبی مصنوعی و  $N$  تعداد آزمایش‌های انجام شده است.



شکل ۳- میانگین مربعات خطا بر اساس تعداد نرون ها در لایه مخفی

دقت شبکه عصبی مصنوعی با استفاده از داده‌های آزمایش در جدول ۱ مورد بررسی قرار گرفته است. داده‌های آزمایش بصورت تصادفی از بین تمامی داده‌ها انتخاب شده و در مرحله آموزش از آنها استفاده نشده است. میانگین خطای مطلق نسبت هدایت حرارتی برابر با ۰/۸۹۶۹ درصد است. این مقدار خطا بیانگر دقت بالای مدل شبکه عصبی مصنوعی است.

#### ۴- نتایج و بحث

در این بخش ابتدا یک رابطه تجربی برای تخمین نسبت

• ساختار شبکه که بیانگر نحوه ارتباط لایه ها و نرون‌های هر لایه است.

• الگوریتم یادگیری که مشخص کننده وزن اتصالات است.

• تابع انتقال (فعالسازی)

در این مطالعه تابع تانژانت - سیگموئید و تابع خطی به عنوان توابع انتقال به ترتیب در لایه‌های مخفی و خروجی استفاده شده اند. رابطه ۲ تابع انتقال تانژانت را نشان می‌دهد.

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (2)$$

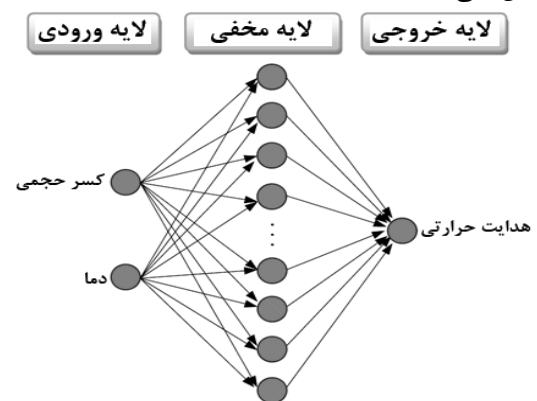
الگوریتم پیش رونده پس انتشار (FFBP) بعنوان الگوریتم آموزشی در شبکه عصبی مصنوعی مورد استفاده قرار گرفته است. پارترهای دما و کسر حجمی نانولوله‌ها به عنوان متغیرهای ورودی و نسبت هدایت حرارتی بعنوان متغیر خروجی انتخاب شده اند. مجموعاً ۳۰ داده آزمایشگاهی به منظور تغذیه مدل شبکه عصبی مصنوعی مورد استفاده قرار گرفته‌اند. این مجموعه داده ها به دو دسته داده‌های آموزش و داده‌های آزمایش تقسیم بندی شده‌اند که به ترتیب ۸۰ و ۲۰ درصد داده‌های آزمایشگاهی را شامل می‌شوند.

همه داده های آزمایش حاصل با استفاده از رابطه ۳ نرمالیزه شده و در بازه (۱-۱) قرار گرفته اند. علت این امر استفاده از تابع تانژانت سیگموئید بعنوان تابع انتقال است.

$$X_{norm} = 2 \times \frac{X - X_{min}}{X_{max} - X_{min}} - 1 \quad (3)$$


تعداد لایه‌ها، تعداد نرون‌های هر لایه و نحوه ارتباط نرون‌ها بین لایه‌های مختلف در شکل (۲) نشان داده شده است.

هدف از آموزش شبکه عصبی مصنوعی بدست آوردن بهترین مقادیر وزن‌ها با توجه به حداقل مقدار خطای پیش‌بینی است.




شکل ۲- ساختار بهینه شده شبکه عصبی مصنوعی

(۵) مقایسه شده است. با توجه به شکل (۵) تمامی داده‌ها بر روی نیمساز قرار دارند. این امر نشان می‌دهد که تطابق بسیار خوبی بین خروجی‌های شبکه عصبی مصنوعی و داده‌های تجربی وجود دارد.



شکل ۵- مقایسه داده‌های تجربی و نتایج بدست آمده از مدل شبکه عصبی مصنوعی

نتایج حاصل از رابطه تجربی، خروجی شبکه عصبی و داده‌های آزمایشگاهی در شکل (۶) در مقایسه با یکدیگر نشان داده شده‌اند. خروجی شبکه عصبی مطابقت بسیار خوبی با داده‌های آزمایشگاهی دارد. از طرفی نتایج حاصل از رابطه تجربی پیشنهادی دارای انحراف بسیار کمی از داده‌های آزمایشگاهی است.



شکل ۶- مقایسه داده‌های تجربی، نتایج بدست آمده از مدل شبکه عصبی مصنوعی و رابطه تجربی.


به منظور نشان دادن دقت رابطه پیشنهادی، منحنی‌های به دست آمده از رابطه تجربی پیشنهادی بر روی داده‌های

هدایت حرارتی نانوسیال پیشنهاد شد. سپس یک شبکه عصبی بهینه برای مدلسازی ضریب هدایت حرارتی نانوسیال طراحی شد که در آن دما و کسر حجمی به عنوان متغیرهای ورودی و ضریب هدایت حرارتی به عنوان متغیر خروجی در نظر گرفته شد. ۳۰ داده آزمایشگاهی به منظور تغذیه شبکه عصبی مورد استفاده قرار گرفت.

جدول ۱- مقایسه مقادیر نسبت هدایت حرارتی حاصل از آزمایش‌های تجربی و مدل شبکه عصبی مصنوعی

متغیرهای ورودی		هدایت حرارتی		
$\phi$ (%)	دما (°C)	داده‌های تجربی	مدل شبکه عصبی	درصد خطای مطلق
۰/۲	۲۵	۱/۰۳۵۵	۱/۰۴۴۰	۰/۸۲۰۹
۰/۱	۳۵	۱/۰۲۰۷	۱/۰۳۰۲	۰/۹۳۰۷
۰/۰۵	۴۵	۱/۰۱۱۴	۱/۰۲۱۰	۰/۹۴۹۲
۰/۱	۴۵	۱/۳۷۴۰	۱/۳۸۵۰	۰/۸۰۰۶
۰/۴	۵۵	۱/۱۵۶۵	۱/۱۶۷۰	۰/۹۱۲۳
۰/۴	۶۵	۱/۱۷۸۲	۱/۱۸۹۶	۰/۹۶۷۶
میانگین درصد خطای مطلق				۰/۸۹۶۹

شکل (۴) مقایسه بین داده‌های تجربی و نتایج به دست آمده از رابطه تجربی را نشان می‌دهد. همانطور که مشاهده می‌شود بیشتر داده‌ها نزدیک به خط نیمساز هستند یا روی آن قرار دارند. با وجود اندکی انحراف بین داده‌های تجربی و خروجی‌های رابطه تجربی وجود دارد.







شکل ۴- مقایسه داده‌های تجربی و نتایج بدست آمده از رابطه تجربی

به منظور ارزیابی دقت شبکه عصبی مصنوعی، نتایج حاصل از این مدل با نتایج حاصل از آزمایش‌های تجربی در شکل

است که این امر بیانگر دقت قابل قبول رابطه تجربی پیشنهادی است.

آزمایشگاهی و خروجی شبکه عصبی عبور داده شده اند شکل (۷). این شکل نشان می‌دهد که خروجی رابطه پیشنهادی در اکثر حالت‌ها بر داده‌های آزمایشگاهی منطبق



شکل ۷- عبور منحنی‌های به دست آمده از رابطه تجربی پیشنهادی بر روی داده‌های آزمایشگاهی و خروجی شبکه عصبی

متغیرهای ورودی و نسبت هدایت حرارتی به عنوان متغیر خروجی در نظر گرفته شد. شبکه عصبی بهینه با لحاظ کردن تعداد نرون‌های مختلف در لایه مخفی و با در نظر گرفتن کمترین خطای پیش‌بینی به دست آمد. شبکه بهینه حاوی ۱۱ نرون در لایه مخفی بود که کمترین میانگین مربعات خطا را داشت.

در مقایسه‌ای که بین خروجی شبکه عصبی، خروجی رابطه پیشنهادی و داده‌های آزمایشگاهی انجام شد مشخص شد که دقت شبکه عصبی و رابطه تجربی پیشنهادی بسیار

## ۵- نتیجه‌گیری

در این مطالعه، بر اساس داده‌های آزمایشگاهی، با استفاده از برازش منحنی و شبکه عصبی مصنوعی اثرات دما و کسر حجمی نانولوله‌ها بر ضریب هدایت حرارتی نانوسیال نانولوله کربنی چند جداره عامل دار - آب بررسی شد. ابتدا با استفاده از داده‌های آزمایشگاهی یک رابطه تجربی برای تخمین ضریب هدایت حرارتی پیشنهاد شد. سپس مدل‌سازی با استفاده از شبکه عصبی بر روی داده‌های آزمایشگاهی انجام شد. دما و کسر حجمی به عنوان

### تقدیر و تشکر

نویسندگان از دانشگاه آزاد اسلامی، واحد نجف آباد برای حمایت مالی از طرح پژوهشی که این مقاله مستخرج از آن است تشکر و قدردانی می‌نمایند.

بالاست. همچنین این مقایسه نشان داد که شبکه عصبی مصنوعی دارای دقت بالاتری نسبت به رابطه تجربی پیشنهادی در پیش بینی ضریب هدایت حرارتی نانوسیال است. با این وجود نتایج نشان داد که دقت رابطه تجربی پیشنهادی نیز برای کاربردهای مهندسی قابل قبول است.

### مراجع

- [1] S.U.S. Choi, "Enhancing thermal conductivity of fluids with nanoparticles", ASME-Publications-Fed, Vol. 231, 1995, pp. 99–106.
- [2] M. Chandrasekar, S. Suresh, A. Chandra Bose, "Experimental investigations and theoretical determination of thermal conductivity and viscosity of  $Al_2O_3$ /water nanofluid", Experimental Thermal and fluid Science, Vol. 34, No. 2, 2010, pp. 210–216.
- [3] M.S. Liu, M.C.C. Lin, C.C. Wang, "Enhancements of thermal conductivities with Cu, CuO, and carbon nanotube nanofluids and application of MWNT/water nanofluid on a water chiller system", Nanoscale Research Letter, Vol. 6, No. 1, 2011, pp. 297.
- [4] S. Harish, K. Ishikawa, E. Einarsson, S. Aikawa, S. Chiashi, J. Shiomi, S. Maruyama, "Enhanced thermal conductivity of ethylene glycol with single-walled carbon nanotube inclusions", International Journal of Heat and Mass Transfer, Vol. 55, No. 13–14, 2012, pp. 3885–3890.
- [5] M.C.S. Reddy, V. Vasudeva, Rao, "Experimental studies on thermal conductivity of blends of ethylene glycol-water-based  $TiO_2$  nanofluids", International Communications in Heat and Mass Transfer, Vol. 46, 2013, pp.31–36.
- [6] L.S. Sundar, M.K. Singh, A.C.M. Sousa, "Investigation of thermal conductivity and viscosity of  $Fe_3O_4$  nanofluid for heat transfer applications", International Communications in Heat and Mass Transfer, Vol. 44, 2013, pp. 7–14.
- [7] J. Jeong, C. Li, Y. Kwon, J. Lee, S. Hyung Kim, R. Yun, "Particle shape effect on the viscosity and thermal conductivity of ZnO nanofluids", International journal of Refrigeration, Vol. 36, No. 8, 2013, pp. 2233–2241.
- [8] M.A. Hachey, C.T. Nguyen, N. Galanis, C.V. Pop, "Experimental investigation of  $Al_2O_3$  nanofluids thermal properties and rheology – Effects of transient and steady-state heat exposure", International Journal of Thermal Sciences, Vol. 76, 2014, pp. 155–167.
- [9] C. Pang, J.W. Lee, Y.T. Kang, "Review on combined heat and mass transfer characteristics in nanofluids", International Journal of Thermal Sciences, Vol. 87, 2015, pp. 49–67.
- [10] M. Hemmat Esfe, M. Afrand, A. Karimipour, W.-M. Yan, N. Sina, "An experimental study on thermal conductivity of MgO nanoparticles suspended in a binary mixture of water and ethylene glycol", International Communications in Heat and Mass Transfer, Vol. 67, 2015, pp. 173–175.
- [11] C.H. Chon, K.D. Kihm, S.P. Lee, S.U.S. Choi, "Empirical correlation finding the role of temperature and particle size for nanofluid ( $Al_2O_3$ ) thermal conductivity enhancement", Applied Physics Letter, Vol. 87, No. 15, 2005.
- [12] C.H. Li, G.P. Peterson, "Experimental investigation of temperature and volume fraction variations on the effective thermal conductivity of nanoparticle suspensions (nanofluids)", Journal of Applied Physics, Vol. 99, No. 8, 2006.

- [13] R.S. Vajjha, D.K. Das, "Measurement of thermal conductivity of three nanofluids and development of new correlations", *International Journal of Heat and Mass Transfer*, Vol. 52, No. 21–22, 2009, pp. 4675–4682.
- [14] W. Duangthongsuk, S. Wongwises, "Measurement of temperature-dependent thermal conductivity and viscosity of TiO<sub>2</sub>-water nanofluids", *Experimental Thermal and Fluid Science*, Vol. 33, No. 4, 2009, pp. 706–714.
- [15] T.P. Teng, Y.H. Hung, T.Ch. Teng, H.E. Mo, H.G. Hsu, "The effect of alumina/water nanofluid particle size on thermal conductivity", *Applied Thermal Engineering*, Vol. 30, No. 14–15, 2010, pp. 2213–2218.
- [16] M. Ghanbarpour, E. Bitaraf Haghigi, R. Khodabandeh, "Thermal properties and rheological behavior of water based Al<sub>2</sub>O<sub>3</sub> nanofluid as a heat transfer fluid", *Experimental Thermal and Fluid Science*, Vol. 53, 2014, pp. 227–235.
- [17] D. Toghraie, V.A. Chaharsoghi, M. Afrand, "Measurement of thermal conductivity of ZnO–TiO<sub>2</sub>/EG hybrid nanofluid", *Journal of Thermal Analysis and Calorimetry*, Vol. 125, No. 1, 2016, pp. 527–535.
- [18] M. Soltanimehr, M. Afrand, "Thermal conductivity enhancement of COOH-functionalized MWCNTs/ethylene glycol–water nanofluid for application in heating and cooling systems", *Applied Thermal Engineering*, Vol. 105, 2016, pp. 716–723.
- [19] S. Sarbolookzadeh Harandi, A. Karimipour, M. Afrand, M. Akbari, A. D'Orazio, "An experimental study on thermal conductivity of F-MWCNTs–Fe<sub>3</sub>O<sub>4</sub>/EG hybrid nanofluid: Effects of temperature and concentration", *International Communications in Heat and Mass Transfer*, Vol. 76, 2016, pp. 171–177.
- [20] M. Hemmat Esfe, S. Saedodin, O. Mahian, S. Wongwises, "Thermophysical properties, heat transfer and pressure drop of COOH-functionalized multi walled carbon nanotubes/water nanofluids", *International Communications in Heat and Mass Transfer*, Vol. 58, 2014, pp. 176–183.
- [21] M.M. Papari, F. Yousefi, J. Moghadasi, H. Karimi, 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.
- [22] M. Hojjat, S.Gh. Etemad, R. Bagheri, J. Thibault, "Thermal conductivity of non-Newtonian nanofluids: experimental data and modeling using neural network", *International Journal of Heat and Mass Transfer*, Vol. 54, No. 5–6, 2011, pp. 1017–1023.
- [23] G.A. Longo, C. Zilio, E. Ceseracciu, 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.
- [24] M. Hemmat Esfe, S. Saedodin, M. Bahiraei, D. Toghraie, O. Mahian, S. Wongwises, "Thermal conductivity modeling of MgO/EG nanofluids using experimental data and artificial neural network", *Journal of Thermal Analysis and Calorimetry*, Vol. 118, No. 1, 2014, pp. 287–294.
- [25] M. Afrand, D. Toghraie, N. Sina, "Experimental study on thermal conductivity of water-based Fe<sub>3</sub>O<sub>4</sub> nanofluid: Development of a new correlation and modeled by artificial neural network", *International Communications in Heat and Mass Transfer*, Vol. 75, 2016, pp. 262–269.