

## پیش‌بینی ضریب انتقال حرارت در جریان آشفته نانو‌سیالات مختلف

### درون لوله‌های دایره‌ای، با استفاده از شبکه عصبی مصنوعی

محمد آخوندزاده<sup>۱</sup>

سعید اسفندیار<sup>۲</sup>

محمد همت اسفه<sup>۱</sup>

دانشکده فنی مهندسی مکانیک

باشگاه پژوهشگران جوان و نخبگان، واحد نجف آباد،

گروه مهندسی مکانیک، دانشکده فنی

دانشگاه کاشان

دانشگاه آزاد اسلامی، واحد نجف آباد، ایران

دانشگاه امام حسین (ع)

(تاریخ دریافت: ۱۳۹۶/۰۲/۰۳؛ تاریخ پذیرش: ۱۳۹۶/۱۰/۱۵)

#### چکیده

هدف این پژوهش مدل‌سازی انتقال حرارت جابجایی نانو‌سیالات در جریان آشفته داخل یک لوله دایره‌ای با شرایط مرزی دما ثابت و شار حرارتی ثابت است. این مدل‌سازی با روش شبکه عصبی مصنوعی انجام شده است. تعداد ۶۱۰ داده از نتایج مطالعات محققان مختلف جمع‌آوری شده و برای آموزش شبکه عصبی مورد استفاده قرار گرفته است. نانوذراتی که در این پژوهش مورد بررسی قرار گرفته اند عبارتند از  $\text{TiO}_2$ ,  $\text{Al}_2\text{O}_3$ ,  $\text{Fe}_3\text{O}_4$ ,  $\text{SiO}_2$ ,  $\text{CuO}$ ,  $\text{SiC}$ , Graphene,  $\text{Cu}$  و  $\text{Fe}_3\text{O}_4$  که سیال پایه در تمام این موارد آب است. این شبکه دارای شش ورودی است که عبارتند از چگالی نانوذره، اندازه نانوذره، عدد رینولدز جریان، نوع شرایط مرزی شار- ثابت یا دما- ثابت و با توجه به نوع مسئله مقدار شار ثابت دیواره یا دمای ثابت آن است. همچنین، خروجی شبکه عصبی طراحی شده عدد ناسلت جریان نانو‌سیال است. از مقایسه نتایج این مدل شبکه عصبی با نتایج پژوهش‌های گذشته مشاهده می‌شود که مدل شبکه عصبی پیشنهاد شده تطابق بسیار خوبی با نتایج حاصل از پژوهش‌های آن‌ها دارد. در این پژوهش، برای انتخاب پیکربندی مناسب شبکه عصبی، ۴۰۰ پیکربندی مختلف مورد بررسی قرار گرفت که از میان آن‌ها شبکه عصبی با بالاترین میزان دقت تخمین و با  $R^2=0.9998$  انتخاب شد.

**واژه‌های کلیدی:** نانو‌سیال، جریان آشفته، عدد ناسلت، شبکه عصبی مصنوعی

## Forecasting of Convective Heat Transfer Coefficient in Turbulent Flow of Different Nanofluids in Circular Tubes, Using Artificial Neural Network

M. Hemmat Esfe

Mechanical Eng. School Group  
Imam Hossein University

S. Esfandeh

Young Researchers and Elite Club,  
Najafabad Branch, Islamic Azad  
University, Najafabad Branch, Iran

M. Akhoondzadeh

Mechanical Engineering Department  
University of Kashan

(Received: 23/April/2017; Accepted: 5/January/2018)

#### ABSTRACT

Modeling of turbulent convective heat transfer of nanofluids in circular tubes with constant temperature and constant heat flux boundary condition have been performed using artificial neural network. 610 sets of data have been gathered using previous investigations and have been used to train neural network (ANN). The investigated nanoparticles are:  $\text{TiO}_2$ , Graphene,  $\text{SiC}$ ,  $\text{CuO}$ ,  $\text{SiO}_2$ ,  $\text{Fe}_3\text{O}_4$ , and  $\text{Cu}$ . The base fluid for all these nanofluids is water. The neural network used has 6 inputs, which includes: nanoparticle density, nanoparticle size, nanoparticle volume fraction, flow Re number, type of boundary condition (constant heat flux or constant temperature) and the amount of heat flux or temperature related to these boundary conditions. Also, the output of neural network is Nusselt number. Comparing our results with previous investigation, showed that the proposed ANN topology are in good agreement. In this study, the proposed topology of  $R^2=0.9998$  have been chosen between 400 examined ones.

**Keywords :** Nanofluid, Turbulent Flow, Nusselt Number, Artificial Neural Network

۱- استادیار (نویسنده پاسخگو): m.hemmatesfe@gmail.com

۲- دانشجوی دکتری: saeedesfandeh.uk@gmail.com

روابطی تجربی برای آن پیشنهاد شده است. در جدول ۱ برخی از این روابط لیست شده است.

برخی از محققین نیز به مدل‌سازی ریاضی انتقال حرارت جابجایی نانوسیال پرداخته‌اند [۱۲]. برخی از آن‌ها نانوسیال را به صورت تک‌فازی در نظر گرفته‌اند و میانگینی از خواص فیزیکی نانوذره و سیال پایه را به عنوان خواص نانوسیال در نظر گرفته‌اند [۱۳-۱۵] و گروه دیگری از محققان نانوسیال را به صورت دوفازی در نظر گرفته و به مدل‌سازی آن پرداخته‌اند [۱۶-۱۸].

از آنجاکه در کاربردهای صنعتی، سیال یا نانوسیالی که برای انتقال حرارت مورد استفاده قرار می‌گیرد معمولاً به صورت جریان آشفته در لوله دایره‌ای مدل می‌شود، مقالات متعددی به بررسی این نوع جریان پرداخته‌اند. برای مثال منصور [۱۹]، نامبرو [۲۰] و مایگا [۲۱] با فرض تک‌فازی بودن نانوسیال به مدل‌سازی جریان آشفته داخل لوله دایره‌ای پرداختند و بهزادمهر [۲۲] نانوسیال را به صورت دوفازی در نظر گرفت و آن را مدل‌سازی کرد. روش دیگری که می‌تواند برای مدل‌سازی این نوع جریان مورد استفاده قرار گیرد، روش شبکه عصبی مصنوعی است. این روش که به صورت گستردۀ برای مدل‌سازی خواص نانوسیال مورداستفاده قرار گرفته است [۲۳-۲۶]، داده‌های تجربی موجود را با استفاده از ترکیب روابط ریاضی پیچیده مدل می‌کند و می‌تواند رفتار مسئله را در شرایط جدید پیش‌بینی کند.

هدف این پژوهش، مدل‌سازی انتقال حرارت جابجایی نانوسیال در جریان آشفته داخل لوله دایره‌ای با شرایط مرزی دما ثابت و شار ثابت است. برخلاف کارهای قبلی که برای بررسی رفتار انتقال حرارت جریان آشفته نانوسیال از روش‌های تجربی، عددی یا تحلیلی استفاده شده است، در این کار روش مدل‌سازی شبکه عصبی مصنوعی به کار گرفته شده است که این تغییر می‌تواند باعث بهبود بسیار چشم‌گیر هزینه زمانی و مالی در دست‌یابی به پارامترهای انتقال حرارتی جریانات آشفته در لوله‌های دایره‌ای گردد. استفاده از تعداد ورودی‌های بالا برای شبیه‌سازی مسئله بیان شده در پژوهش حاضر با شبکه عصبی از مزایای شبکه عصبی طراحی شده می‌باشد. وجود ورودی‌های هر چه بیشتر در شبیه‌سازی خود سبب جامع‌تر شدن شبکه عصبی طراحی شده خواهد شد.

## فهرست علائم و اختصارات

$m^2$	مساحت ،	A
$^{\circ}\text{C}$	دما،	T
$y_i$	داده‌های تجربی	
$\bar{y}_i$	مقدار متوسط داده‌های تجربی	
$R^2$	ضریب همبستگی	
MSE	خطای میانگین استاندارد	
MAE	میانگین قدر مطلق خط	
Nu = $h l/k$	عدد ناسلت	

## علائم یونانی

$\rho$	چگالی،	$\text{kg}/\text{m}^3$
$\varphi$	کسر حجمی	
<b>زیرنویس‌ها</b>		
$f$	سیال	
$nf$	نانوسیال	

## ۱- مقدمه

نانوسیال‌ها ترکیبات همگنی هستند که به‌وسیله توزیع یک نانوذره در سیال پایه ساخته می‌شوند. نانوذرات به کار رفته، قطری کمتر از ۱۰۰ نانومتر دارند و می‌توانند از نوع فلز، اکسید فلز یا غیرفلز باشند. از آنجاکه ضریب هدایت حرارتی نانوذراتی که مورد استفاده قرار می‌گیرند به‌مراتب بزرگ‌تر از ضریب هدایت حرارتی سیال پایه است، ضریب هدایت حرارتی نانوسیال بزرگ‌تر از سیال پایه خالص است. میزان افزایش ضریب هدایت حرارتی نانوسیال به عوامل مختلفی مثل غلظت نانوذره جامد، دما، اندازه نانوذرات، جنس نانوذره و سیال پایه، PH و ... بستگی دارد.

یکی از متغیرهایی که در تجهیزاتی که از جریان نانوسیال برای انتقال حرارت استفاده می‌کنند بسیار مهم است، ضریب انتقال حرارت جابجایی نانوسیال است. از آنجاکه هم میزان هدایت حرارتی و هم انتقال حرارتی جابجایی در توزیع دمای جریان مؤثر است، معمولاً در مقالات تغییرات عدد ناسلت که نسبت بی‌بعد این دو مقدار است مورد بررسی قرار می‌گیرد. در سال‌های اخیر مطالعات زیادی روی انتقال حرارت جابجایی در جریان آرام [۱-۴] و معشوش [۵-۱۱] انجام شده است و

جدول (۱): نتایج روابط تجربی عدد ناسلت در تحقیقات گذشته.

محقق	رابطه پیشنهادی	
پاک و چو [۲۷]	$Nu = 0.021 Re^{0.8} Pr^{0.5}$	
ژوان و لی [۲۸]	$Nu = 0.4328(1 + 11.285\varphi^{0.754} Pe_p^{0.001}) Re_{nf}^{0.333} Pr_{nf}^{0.4}$ $Nu = 0.0059(1 + 7.6286\varphi^{0.6886} Pe_p^{0.001}) Re_{nf}^{0.9238}$	برای جریان آرام برای جریان آشفته
مایگا و همکاران [۲۹]	$Nu = 0.86 Re^{0.55} Pr^{0.5}$ $Nu = 0.86 Re^{0.35} Pr^{0.36}$	برای شار حرارتی ثابت برای شرایط دما ثابت
[۳۰-۳۱]	$Nu = \frac{(f/8)(Re - 1000) Pr}{1 + \delta_v^+ \sqrt{(f/8)(Pr_v^{2/3} - 1)}}$	-
مایگا و همکاران [۳۲]	$Nu = 0.085 Re^{0.71} Pr^{0.35}$	برای جریان آشفته کاملاً توسعه یافته
گراتز [۳۳]	$Nu_x = \frac{h_x d}{k_{eff}} = \frac{\sum_{n=1}^{\infty} A_n e^{-\lambda_n^2 \xi}}{\sum_{n=1}^{\infty} \frac{A_n}{\lambda_n^2} e^{-\lambda_n^2 \xi}}$	برای دمای ثابت دیواره
	$Nu_x = \frac{h_x d}{k_{eff}} = \left[ \frac{11}{48} - \frac{1}{2} \sum_{n=1}^{\infty} \frac{e^{-\beta_n^2 \xi}}{A_n \beta_n^4} \right]^{-1}$	برای شار حرارتی ثابت
	$Nu_x = \frac{h_x d}{k_{eff}} = \frac{0.5 + 4 \sum_{n=1}^{\infty} \frac{C_n}{2} \frac{R'_n(1)}{\lambda_n^4} e^{-\lambda_n^2 \xi}}{\frac{88}{768} + 8 \sum_{n=1}^{\infty} \frac{C_n}{2} \frac{R'_n(1)}{\lambda_n^4} e^{-\lambda_n^2 \xi}}$	برای دمای خطی دیواره

در جدول ۲ تعداد و مشخصات داده‌های تجربی مورد استفاده به همراه مرجع آن‌ها نمایش داده شده است.

جدول (۲): بررسی دقیق‌تر مجموعه داده‌های مورد استفاده به عنوان ورودی شبکه عصبی.

جنس نانوذرات	سیال پایه	تعداد داده‌های استخراجی	شماره مرجع
$\gamma$ -Al <sub>2</sub> O <sub>3</sub>	آب	۴۴	[۳۴]
TiO <sub>2</sub>	آب	۳۰	[۳۵]
Graphene	آب	۹۶	[۳۶]
TiO <sub>2</sub> , Al <sub>2</sub> O <sub>3</sub> , SiO <sub>2</sub>	آب	۸۰	[۳۷]
TiO <sub>2</sub> , SiC	آب	۱۲۳	[۳۸]
Cu	آب	۵۰	[۳۹]
CuO	آب	۵۸	[۴۰]
SiO <sub>2</sub>	آب	۴	[۴۱]
$\gamma$ -Al <sub>2</sub> O <sub>3</sub> , TiO <sub>2</sub>	آب	۵۰	[۲۰]
Fe <sub>3</sub> O <sub>4</sub>	آب	۵۱	[۴۲]
Al <sub>2</sub> O <sub>3</sub> , TiO <sub>2</sub>	آب	۲۴	[۴۳]

## ۲- داده‌های مسئله

آزمایش‌هایی که نتایج آن‌ها به عنوان داده‌های پژوهش حاضر در نظر گرفته شد در برخی زمینه‌ها با یکدیگر تفاوت داشتند. یکی از مهم‌ترین تفاوت‌ها شار ثابت بودن و یا دما ثابت بودن دیواره لوله بود. بنابراین، بسته به شرط مرزی مسئله موردنرسی، ورودی‌ها به صورت زیر در نظر گرفته شد. ورودی در مسائل با شرط مرزی دما ثابت دیواره به صورت چگالی نانوذره، اندازه نانوذره، غلظت نانوذره، عدد رینولدز، نوع شرط مرزی مسئله و مقدار دمای ثابت دیواره در نظر گرفته شد و در مسائل با شرط مرزی شار ثابت دیواره ورودی‌ها به صورت چگالی نانوذره، اندازه نانوذره، غلظت نانوذره، عدد رینولدز، نوع شرط مرزی مسئله و مقدار شار ثابت دیواره در نظر گرفته شد. خروجی نیز عدد ناسلت (نسبت مقاومت هدایتی به مقاومت جابجایی) است. برای این مدل‌سازی ۶۱۰ داده تجربی از بررسی مقاومت گذشته جمع‌آوری شده است. این داده‌ها مربوط به نانوذرات Graphene, TiO<sub>2</sub>, Al<sub>2</sub>O<sub>3</sub>, CuO, SiC, Fe<sub>3</sub>O<sub>4</sub>, SiO<sub>2</sub> هستند و سیال پایه در همه این ترکیب‌ها آب است. این مسئله برای دو شرط مرزی دماثابت و شار ثابت بررسی شده است.

است. در شبکه‌های MLP هر نورون با چند نورون دیگر که در همسایگی آن قرار دارد در ارتباط است و با تغییر ضرایب وزنی، میزان تأثیر هر نورون ورودی نسبت به سایر نورون‌های ورودی تنظیم می‌شود. پس از ضرب شدن ورودی‌ها در ضرایب وزنی حاصل آن‌ها باهم جمع می‌شوند و حاصل آن به‌وسیله یکتابع فعال‌سازی به نورون‌های لایه مخفی بعدی منتقل می‌شود و این کار تا لایه آخر که همان خروجی شبکه است ادامه پیدا می‌کند [۴۵].

$$\gamma_{jk} = F_k \left( \sum_{i=1}^{N_{k-1}} w_{ijk} \gamma_{i(k-1)} + \beta_{jk} \right) \quad (2)$$

در رابطه (۲) مقدار نورون‌ها در  $\gamma$  قرار می‌گیرد و  $k$  شماره لایه را نشان می‌دهد. ضرایب وزنی با  $w$  و مقدار بایاس با  $\beta$  نشان داده شده و  $F$  معرف تابع فعال‌سازی است. همان‌طور که در رابطه دیده می‌شود مقادیر نورون‌های لایه قبل پس از ضرب شدن در ضرایب وزنی و جمع با مقدار بایاس باهم جمع می‌شوند و در تابع فعال‌سازی قرار می‌گیرند تا مقدار نورون لایه بعد به‌دست آید. تابع فعال‌سازی توسط کاربر انتخاب می‌شود و مقادیر ضرایب وزنی در مرحله آموزش شبکه عصبی با سعی خطابه گونه‌ای انتخاب می‌شوند که خروجی شبکه عصبی کمترین خطابه را نسبت به خروجی‌های به‌دست آمده از داده‌های تجربی داشته باشد.

در این مدل‌سازی تعداد ۶۱۰ داده تجربی با بررسی تاریخچه پژوهش‌های صورت گرفته برای نانو سیالات مختلف استخراج شده و برای مدل‌سازی آنها به‌وسیله شبکه عصبی مصنوعی از نرم‌افزار متلب استفاده شده است. در این مدل‌سازی ۱۵ درصد این داده‌ها برای مرحله آموزش، ۱۵ درصد برای مرحله تست و ۱۵ درصد باقی‌مانده برای مرحله اعتبارسنجی مورد استفاده قرار گرفت. برای شبکه عصبی دو لایه مخفی درنظر گرفته شد و برای حالت‌هایی که تعداد نورون‌های هر لایه مخفی بین یک تا ده باشد نتایج شبکه عصبی مورد بررسی قرار گرفت که این خود بررسی صد پیکربندی شبکه متفاوت است؛ علاوه بر این ۱۰۰ حالت، چهار حالت مختلف نیز برای تابع انتقال مورد بررسی قرار گرفت. جدول ۴ اطلاعاتی در مورد نوع توابع انتقال آزمایش شده (۴) حالت مختلف) در لایه‌های مخفی اول و دوم به‌دست می‌دهد. حالتی که از میان ۴۰۰ پیکربندی مورد بررسی کمترین خطاب را داشت به‌عنوان پیکربندی شبکه عصبی انتخاب شد. در شکل ۱ شماتیکی از پیکربندی شبکه عصبی انتخاب شده ارائه شده است. توابع انتقال بهینه برای هر دو لایه مخفی شبکه عصبی

هر یک از این داده‌ها شامل پارامترهای چگالی نانوذره، قطر نانوذرات، غلظت نانو سیال و عدد رینولدز جریان و اندازه عدد ناسلت به‌دست آمده از آزمایش‌ها و اندازه شار یا دمای ثابت اعمال شده در آزمایش است. علاوه بر این پارامترها، با توجه به شرایط مرزی مسئله که شار ثابت یا دما ثابت است، یک پارامتر دیگر به‌عنوان «نوع شرایط مرزی» به داده‌ها اضافه می‌شود.

از نظر مرتبه بزرگی، داده‌های ورودی با هم تفاوت زیادی دارند. برای مثال عدد رینولدز از مرتبه  $10^4$  است و غلظت نانو سیال مرتبه  $10^{-2}$  دارد. در جدول ۳ بازه تغییرات داده‌ها نشان داده شده است. برای این‌که این اختلاف در مرتبه بزرگی داده‌های ورودی اخلالی در مدل‌سازی شبکه عصبی ایجاد نکند و همه ورودی‌ها تأثیر مشابهی در تولید جواب خروجی داشته باشند لازم است این داده‌ها بی‌بعد شوند. برای این کار با استفاده از رابطه (۱) داده‌ها بی‌بعد می‌شوند.

$$D = \frac{d - 0.5(d_{max} + d_{min})}{0.5(d_{max} - d_{min})} \quad (1)$$

در این رابطه،  $D$  نشان‌دهنده پارامتر بی‌بعد شده است،  $d$  مقدار پارامتری است که قرار است بی‌بعد شود.  $d_{max}$  و  $d_{min}$  مقدار بیشینه و کمینه آن پارامتر هستند. با استفاده از این رابطه همه داده‌ها بین یک و منفی یک قرار می‌گیرند و مرتبه بزرگی آن‌ها برابر می‌شود.

**جدول (۳):** بازه تغییرات پارامترهای ورودی درنظر گرفته شده برای شبکه عصبی.

پارامتر	بازه تغییرات
دماهای دیواره مبدل حرارتی (شرط مرزی دما ثابت)	$90-100^{\circ}\text{C}$
شار دیواره مبدل حرارتی (شرط مرزی شار ثابت)	$1273-175810 \text{ (W/m}^2\text{)}$
عدد رینولدز	$819-88800$
قطر نانوذرات	$13-2000 \text{ (nm)}$
کسر حجمی نانوذره	$0/00008-0/0316 \text{ (Kg/m}^3\text{)}$
چگالی	$300-8960$

**۳- شبکه عصبی مصنوعی**  
شبکه MLP<sup>۱</sup> به‌عنوان یک شبکه رایج و پرکاربرد برای طراحی شبکه عصبی [۴۴] در پژوهش حاضر مورد استفاده قرار گرفته

$$MSE = \frac{\sum_{i=1}^n e_i^2}{n} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n |e_i|}{n} = \frac{\sum_{i=1}^n |(y_i - \hat{y}_i)|}{n} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (5)$$

جدول (۵): مشخصات شبکه عصبی بهینه انتخاب شده از میان ۴۰۰ شبکه عصبی مورد بررسی.

تمام داده‌ها	
MAE	۱/۰۲۱۳
MSE	۲/۲۸۱۷
R <sup>2</sup>	۰/۹۹۹۸
داده‌های تست	
MAE	۱/۹۷۷۰
MSE	۳/۸۱۹۸
R <sup>2</sup>	۰/۹۹۹۴
داده‌های اعتبارسنجی	
MAE	۱/۵۴۷۱
MSE	۳/۳۵۱۱
R <sup>2</sup>	۰/۹۹۹۶
داده‌های آموزشی	
MAE	۰/۷۸۴۵
MSE	۱/۱۵۵۳
R <sup>2</sup>	۰/۹۹۹۹

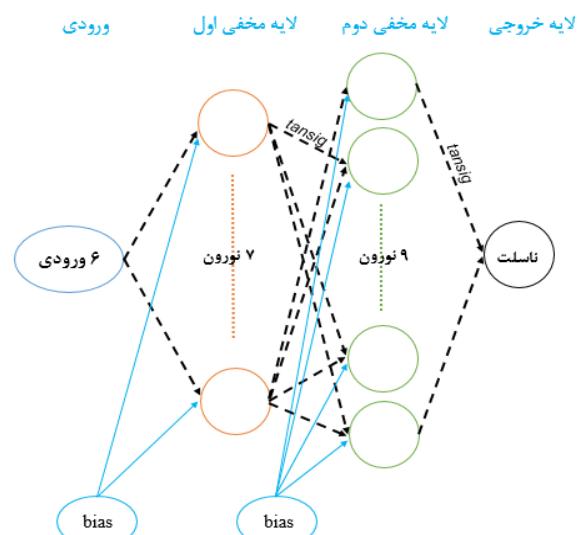
#### ۴- نتایج و بحث

در این مطالعه، یک مدل برای پیش‌بینی انتقال حرارت جابجایی در جریان آشفته (پیش‌بینی عدد ناسلت) ارائه شده است و برای این کار از روش طراحی شبکه عصبی مصنوعی استفاده شده است. ورودی‌های این مدل سازی چگالی نانوذره، اندازه نانوذره، غلظت نانوذره، عدد رینولدز جریان، نوع شرایط مرزی شار- ثابت یا دما- ثابت و مقدار شار ثابت دیواره یا دمای ثابت آن هستند. برای مدل سازی این مسئله دو لایه

انتخابابی تائزات سیگموئید درنظر گرفته شد. در انتخاب ساختار بهینه برای شبکه عصبی نزدیک‌تر بودن هرچه بیشتر مقدار R<sup>2</sup> به عدد یک معیار عمل قرار گرفت.

جدول (۴): توابع انتقال انتخابی و تعداد نورون‌های بهینه لایه‌های مخفی.

حالات	شماره لایه	نوع تابع انتقال
حالات اول	لایه مخفی اول	Logsigmoidal
	لایه مخفی دوم	Logsigmoidal
حالات دوم	لایه مخفی اول	Logsigmoidal
	لایه مخفی دوم	Tansigmoidal
حالات سوم	لایه مخفی اول	Tansigmoidal
	لایه مخفی دوم	Logsigmoidal
حالات چهارم	لایه مخفی اول	Tansigmoidal
	لایه مخفی دوم	Tansigmoidal



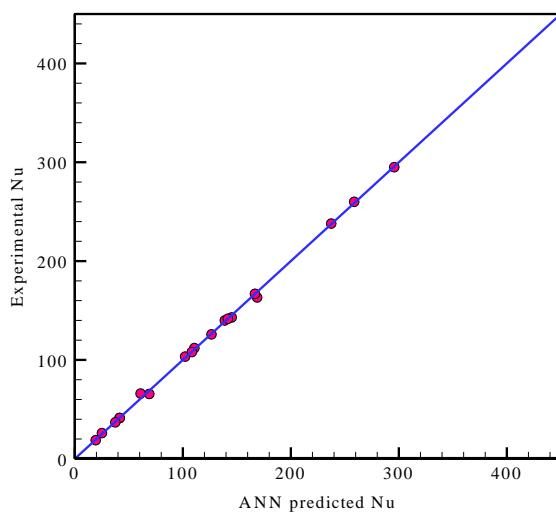
شکل (۱): پیکربندی شبکه عصبی.

معیارهای مربع خطای میانگین استاندارد (MSE)، میانگین قدر مطلق خطأ (MAE) و ضریب تعیین (R<sup>2</sup>) برای نشان دادن خطای بین خروجی‌های پیش‌بینی شده و خروجی مطلوب درنظر گرفته شده‌اند و برای محاسبه آنها از روابط (۳) تا (۵) استفاده شده است. در این روابط n تعداد پیش‌بینی‌ها،  $y_i$  داده‌های پیش‌بینی شده،  $\hat{y}_i$  داده‌های تجربی و  $\bar{y}_i$  مقدار متوسط داده‌های تجربی را نشان می‌دهند. جدول ۵ نیز مقادیر MSE، MAE و R<sup>2</sup> برای مراحل آموزش، تست و اعتبارسنجی شبکه عصبی بهینه نشان می‌دهد.

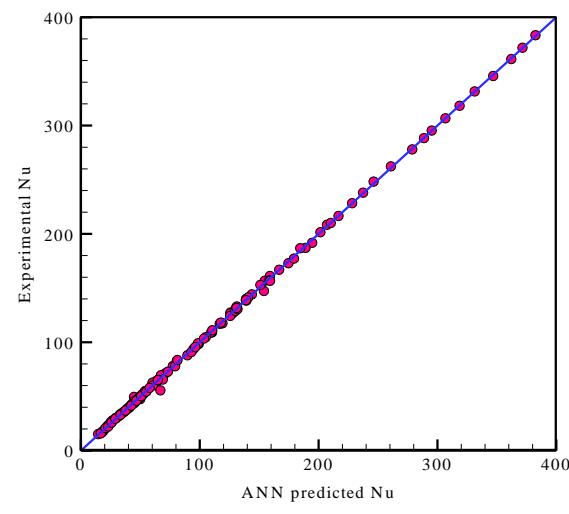
مدل‌سازی انجام‌شده اختلاف ناچیزی نسبت به نتایج مطالعات تجربی محققان مختلف دارد. در شکل ۲ تطبیق مقادیر عدد ناسلت تجربی بر حسب مقادیر ناسلت پیش‌بینی شده به‌وسیله شبکه عصبی برای همه داده‌ها، شامل داده‌های مرحله تست، آموزش و اعتبارسنجی نشان داده شده‌اند. شکل ۳ نیز میزان انطباق نتایج حاصل از شبکه عصبی ارائه شده در پژوهش حاضر با نتایج آزمایشگاهی انجام شده در تحقیقات مختلف را نشان می‌دهد.

همان‌طور که مشخص است برای نانوسيالات پایه آبی  $\text{Cu}$ ,  $\text{Fe}_3\text{O}_4$ ,  $\gamma\text{-Al}_2\text{O}_3$ ,  $\text{CuO}$ ، شبکه عصبی طراحی شده از دقت بسیار بالایی برخودار است.

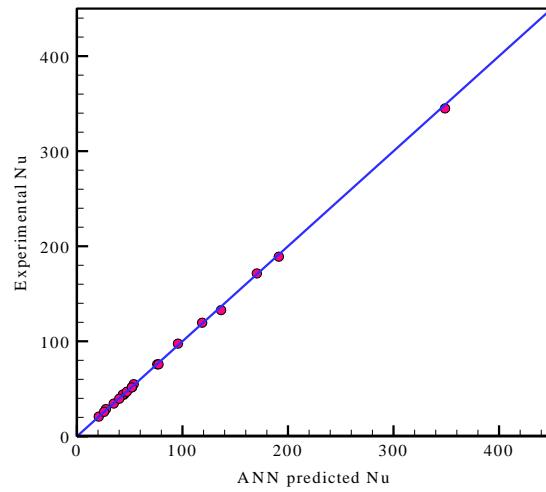
مخفى درنظر گرفته شد و تعداد نورون‌های هر لایه مخفى بین یک تا ده تغییر داده شد و در هر یک از این صد حالت چهار تابع انتقال مختلف مورد بررسی قرار گرفت و در نهایت بهترین پیکربندی و تابع انتقال از بین ۴۰۰ حالت بررسی شده، به عنوان پیکربندی و تابع انتقال نهایی مدل درنظر گرفته شد. تعداد نورون‌های بهینه در دو لایه مخفى و نیز توابع انتقال مورد استفاده در ساختار شبکه عصبی به ترتیب ۷ و ۹ نورون برای لایه‌های مخفى اول و دوم و تابع انتقال تائزانت سیگموئید برای هر دو لایه مخفى درنظر گرفته شد. مقایسه نتایج به‌دست آمده از مدل‌سازی انجام‌شده و داده‌های تجربی جمع‌آوری شده ( $R^2=0.9998$ ) نشان می‌دهد خروجی‌های



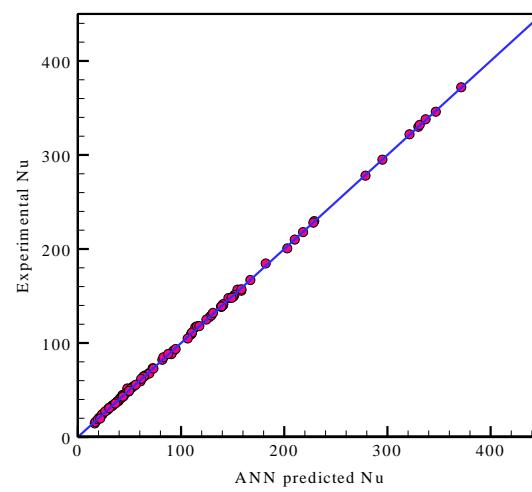
(ب)



(الف)



(د)

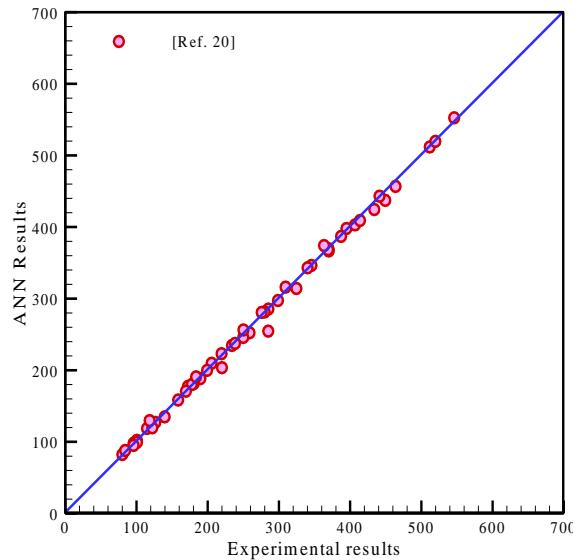


(ج)

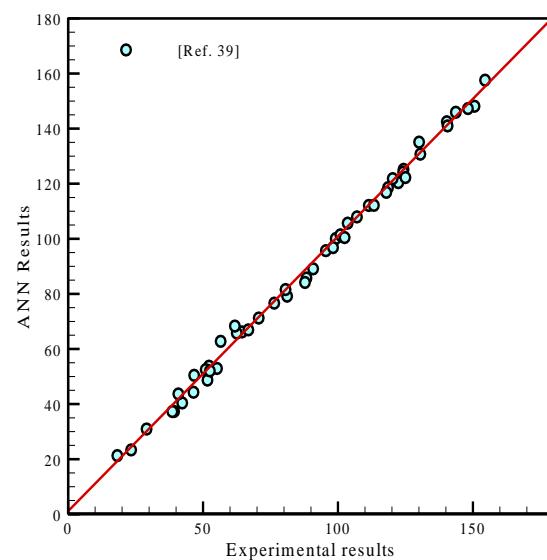
شکل (۲): مقایسه مقادیر ناسلت به‌دست آمده از شبکه عصبی و داده‌های تجربی (الف): همه داده‌ها، (ب): مرحله تست، (ج): مرحله آموزش، (د): مرحله اعتبارسنجی.

تغییرات عدد ناسلت با تغییر قطر نانوذرات پرداخته و قدرت پیش‌بینی تغییر عدد ناسلت با تغییر قطر ذرات را توسط شبکه عصبی مورد آزمایش قرار داده است. در این شکل نیز انطباق پیش‌بینی‌های شبکه عصبی با نتایج کارهای گذشته کاملاً مشهود است.

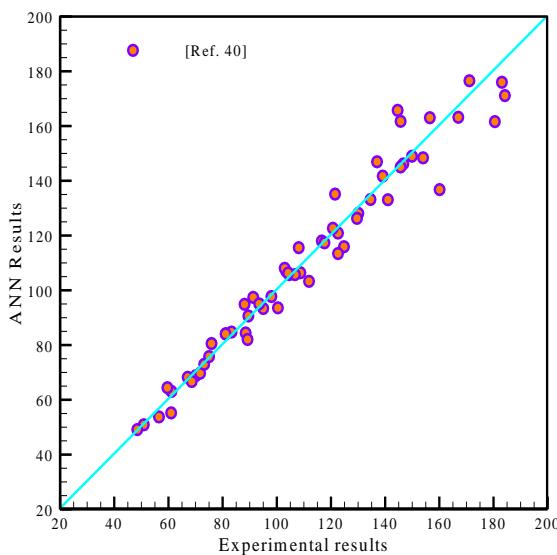
شکل‌های (۴-۶) نیز تغییرات عدد ناسلت بر حسب عدد رینولدز به دست آمده از نتایج آزمایشگاهی و نتایج شبکه عصبی مصنوعی را نشان می‌دهد. همان‌طور که مشاهده می‌شود شبکه عصبی طراحی شده تطابق بسیار خوبی با مقادیر حاصل شده از آزمایش‌های محققان مختلف دارد. شکل ۷ نیز به بررسی



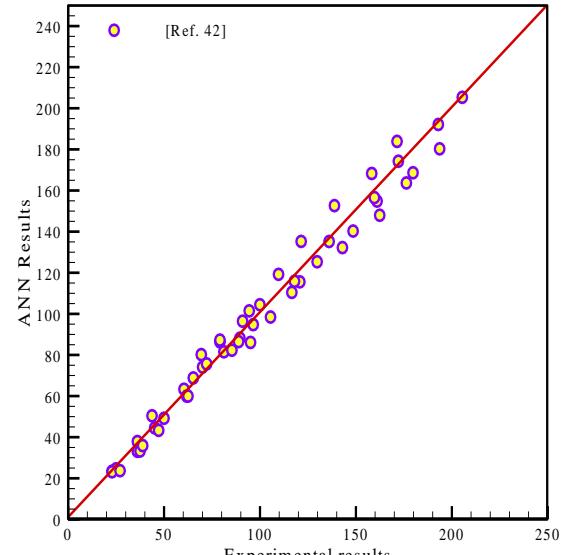
(ب)



(الف)

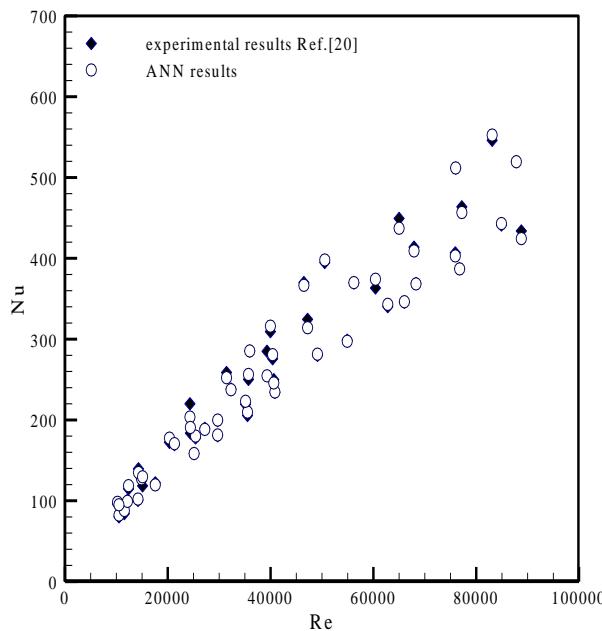


(د)

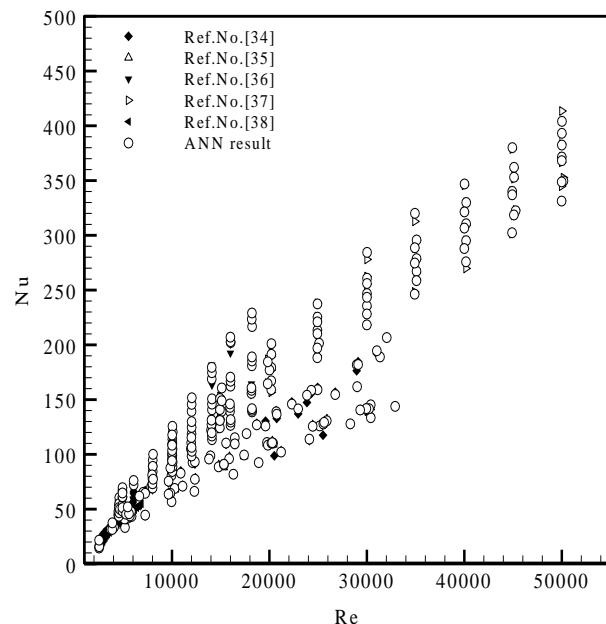


(ج)

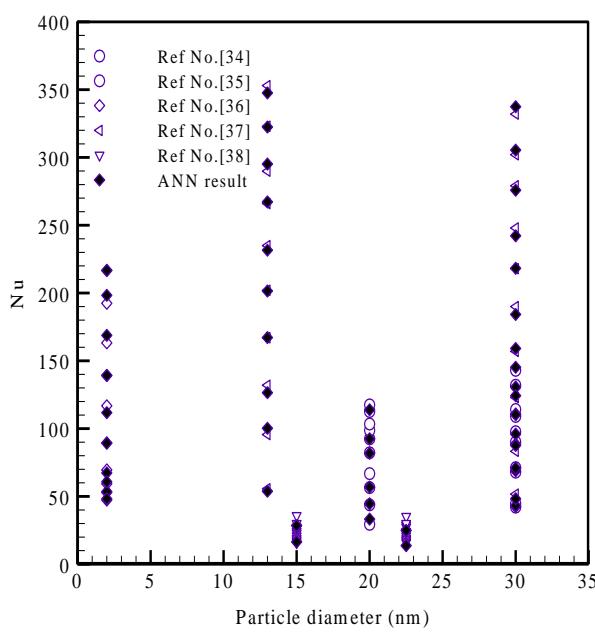
شکل (۳): مقایسه مقادیر ناسلت حاصله از شبکه عصبی با نتایج مراجع [۲۰، ۳۹، ۴۰ و ۴۲].



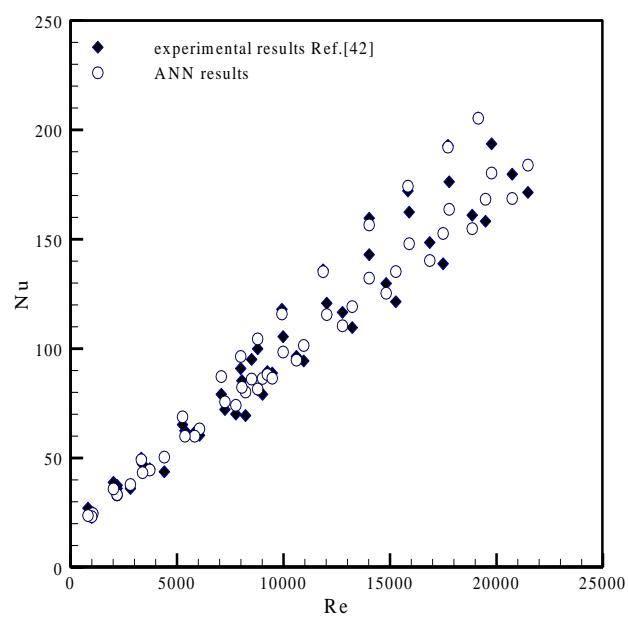
شکل (۵): مقایسه مقادیر تغییرات عدد ناسلت بر حسب عدد رینولدز، به دست آمده از شبکه عصبی و داده های تجربی مرجع [۲۰] (آلومینیم اکسید و اکسید تیتانیوم).



شکل (۴): مقایسه مقادیر ناسلت به دست آمده از شبکه عصبی و داده های تجربی بر حسب عدد رینولدز.



شکل (۷): مقایسه مقادیر ناسلت به دست آمده از شبکه عصبی و داده های تجربی بر حسب قطر نانوذره.



شکل (۶): مقایسه مقادیر تغییرات عدد ناسلت بر حسب عدد رینولدز، به دست آمده از شبکه عصبی و داده های تجربی مرجع [۴۲] (اکسید آهن).

6. Eastman, JA., Choi, SUS., Li, S., Soyez, G., Thompson, LJ., and DiMelfi, RJ. "Novel Thermal Properties of Nanostructure Materials", *Mater. Sci. Forum*, Vol. 312, pp. 629–634, 1999.
7. Esfe, M.H., Saedodin, S., Mahian, O., and Wongwises, S. "Heat Transfer Characteristics and Pressure Drop of COOH-Functionalized Dwcnts/Water Nanofluid in Turbulent Flow at Low Concentrations", *Int. J. Heat Mass Tran.*, Vol. 73, pp. 186-194, 2014.
8. Esfe, M.H., Saedodin, S., and Mahmoodi, M. "Experimental Studies on the Convective Heat Transfer Performance and Thermophysical Properties of Mgo-Water Nanofluid Under Turbulent Flow", *Exp. Therm Fluid Sci.*, Vol. 52, pp. 68-78, 2014.
9. Esfe, M.H., Akbari, M., Karimipour, A., Afrand, M., Mahian, O., and Wongwises, S. "Mixed-convection Flow and Heat Transfer in an Inclined Cavity Equipped to a Hot Obstacle Using Nanofluids Considering Temperature-Dependent Properties", *Int. J. Heat Mass Tran.*, Vol. 85, pp. 656-666, 2015.
10. Esfe, M.H. and Saedodin, S. "Turbulent Forced Convection Heat Transfer and Thermophysical Properties of Mgo-Water Nanofluid with Consideration of Different Nanoparticles Diameter, an Empirical Study", *J. Therm. Anal. Calorim*, Vol. 119, pp. 1205-1213, 2015.
11. Esfe, M.H., Saedodin, S., Mahian, O., and Wongwises, S. "Thermophysical Properties, Heat Transfer and Pressure Drop of COOH-Functionalized Multi Walled Carbon Nanotubes/Water Nanofluids", *Int. Commun. Heat Mass.*, Vol. 58, pp. 176-183, 2014.
12. Godson, L., Raja, B., Lal, D. M., and Wongwises, S. "Enhancement of Heat Transfer Using Nanofluids-An Overview", *Renew Sust. Energ. Rev.*, Vol. 14, pp. 629-641, 2010.
13. Pak, B.C. and Cho, Y.I. "Hydrodynamic and Heat Transfer Study of Dispersed Fluids with Submicron Metallic Oxide Particles", *Exp. Heat Tran. Int. J.*, Vol. 11, pp. 151-170, 1998.
14. Landau, L.D. and Lifshitz, E.M. "Course of Theoretical Physics", Electro. Cont. Med., Oxford, Vol. 8, 1960.
15. Choi, S.U.S., Zhang, Z.G., Yu, W., Lockwood, F. E., and Grulke, E.A. "Anomalous Thermal Conductivity Enhancement in Nanotube Suspensions", *Appl. Phys. Lett.*, Vol. 79, pp. 2252-2254, 2001.
16. Xuan, Y. and Roetzel, W. "Conceptions for Heat Transfer Correlation of Nanofluids", *Int. J. Heat Mass Tran.*, Vol. 43, pp. 3701-3707, 2000.
17. Khanafer, K., Vafai, K., and Lightstone, M. "Buoyancy-driven Heat Transfer Enhancement in a

## ۵- نتیجه‌گیری

در مقاله حاضر با استفاده از روش شبکه عصبی مصنوعی یک مدل انتقال حرارت جابجایی در لوله برای جریان آشفته نانوسيالات مختلف ارائه شد. چگالی نانوذره، اندازه نانوذره، غلظت نانوذره، عدد رینولدز جریان، نوع شرایط مرزی و مقدار ثابت شار یا دمای دیواره لوله به عنوان ورودی‌های شبکه عصبی و عدد ناسلت جریان به عنوان خروجی درنظر گرفته شد. جریان نانوسيالاتی که با این شبکه عصبی مصنوعی مدل شده‌اند دارای نانوذرات متفاوتی بودند، شرایط مرزی آنها نیز یکسان نبود و عدد رینولدز آنها نیز برابر نبود. با این وجود شبکه عصبی مصنوعی طراحی شده توانست مدل‌سازی دقیقی از این جریانات داشته باشد و ضریب تعیین<sup>۲</sup> مقادیر پیش‌بینی شده به‌وسیله مدل شبکه عصبی نسبت به داده‌های تجربی برابر ۰/۹۹۹۸ گزارش شد که نشان دهنده قدرت بالای شبکه عصبی مصنوعی در مدل‌سازی این مسئله است. در صورت تحقق امکان طراحی شبکه عصبی مناسب برای تمامی نانوسيالات می‌توان به این امر امیدوار بود تا در آینده نیازی هر چه کمتر به استفاده از آزمایشات تجربی جهت دستیابی به خصوصیات انتقال حرارتی نانوسيالات احساس گردد.

## ۶- مراجع

1. Zeinali Heris, S., Etemad, S.Gh., and Nasr Esfahany, M. "Experimental Investigation of Oxide Nanofluid Laminar Flow Convective Heat Transfer in Circular Tube", *Int. Commun. Heat. Mass.*, Vol. 33, pp. 529–533, 2006.
2. Zeinali Heris, S., Nasr Esfahany, M., and Etemad, S.Gh. "Experimental Investigation of Convective Heat Transfer of Al<sub>2</sub>O<sub>3</sub>/Water Nanofluid in Circular Tube", *Int. J. Heat. Fluid. Flow*, Vol. 28, pp. 203–210, 2007.
3. Esfe, M.H., Arani, A.A.A., Niroumand, A.H., Yan, W.M., and Karimipour, A. "Mixed Convection Heat Transfer from Surface-Mounted Block Heat Sources in a Horizontal Channel with Nanofluids", *Int. J. Heat Mass. Tran.*, Vol. 89, pp. 783-791, 2015.
4. Esfe, M.H., Arani, A.A.A., Azizi, T., Mousavi, S.H., and Wongwises, S. "Numerical Study of Laminar-Forced Convection of Al<sub>2</sub>O<sub>3</sub>-Water Nanofluids Between Two Parallel Plates", *J. Mech. Sci. Tech.*, Vol. 31, No. 2, pp. 785-796, 2017.
5. Hetsroni, G. and Rozenblit, R. "Heat Transfer to a Liquid-Solid Mixture in a Flume", *Int. J. Multiph. Flow*, Vol. 20, No. 4, pp. 671–689, 2005.

- Nanofluids in Forced Convection Flows”, Int. J. Heat Fluid Fl., Vol. 26, pp. 530–46, 2005.
30. Buongiorno, J. “Convective Transport in Nanofluids”, J. Heat Transfer, Vol. 128, pp. 240–250, 2006.
31. Buongiorno, J. “Convective Heat Transfer Enhancement in Nanofluids”; Heat Mass Tran. Conf. Washington, USA, 2006.
32. Bécaye Maïga, S., Tam Nguyen, C., Galanis, N., Roy, G., Maré, T., and Coqueux, M. “Heat Transfer Enhancement in Turbulent Tube Flow, Using Al<sub>2</sub>O<sub>3</sub> Nanoparticle Suspension”, Int. J. Num. Method, Vol. 16, pp. 275-292, 2006.
33. Kakac, S. and Pramuanjaroenkij, A. “Review of Convective Heat Transfer Enhancement with Nanofluids”, Int. J. Heat Mass Trans., Vol. 52, pp. 3187-3196, 2009.
34. Fotukian, S.M. and Esfahany, M.N. “Experimental Investigation of Turbulent Convective Heat Transfer of Dilute  $\Gamma$ -Al<sub>2</sub>O<sub>3</sub>/Water Nanofluid Inside a Circular Tube”, Int. J. Heat Fluid Flow, Vol. 31, pp. 606-612, 2010.
35. Sajadi, A.R. and Kazemi, M.H. “Investigation of Turbulent Convective Heat Transfer and Pressure Drop of TiO<sub>2</sub>/Water Nanofluid in Circular Tube”, Int. Commun. Heat Mass Transf., Vol. 38, pp. 1474-1478, 2011.
36. Sadeghinezhad, E., Togun, H., Mehrali, M., Nejad, P.S., Latibari, S.T., Abdulrazzaq, T., and Metselaar, H. S.C. “An Experimental and Numerical Investigation of Heat Transfer Enhancement for Graphene Nanoplatelets Nanofluids in Turbulent Flow Conditions”, Int. J. Heat Mass Trans., Vol. 8, pp. 41-51, 2015.
37. Hussein, A.M., Sharma, K.V., Bakar, R.A., Kadrigama, K. “The Effect of Nanofluid Volume Concentration on Heat Transfer and Friction Factor Inside a Horizontal Tube”, J. Nano mat., Vol.1, pp. 1-12, 2013.
38. Celata, G.P., D’Annibale, F., Mariani, A., Saraceno, L., D’Amato, R., and Bubbico, R. “Heat Transfer in Water-Based Sic and TiO<sub>2</sub> Nanofluids”, Heat Transfer Eng., Vol. 34, pp. 1060-1072, 2013.
39. Xuan, Y. and Li, Q. “Investigation on Convective Heat Transfer and Flow Features of Nanofluids”, J. Heat Tran., Vol. 125, pp. 151-155, 2003.
40. Fotukian, S.M. and Esfahany, M.N. “Experimental Study of Turbulent Convective Heat Transfer and Pressure Drop of Dilute CuO/Water Nanofluid Inside a Circular Tube”, Int. Commun. Heat Mass trans., Vol. 37, pp. 214-219, 2010.
41. Azmi, W.H., Sharma, K.V., Sarma, P. K., Mamat, R., Anuar, S., and Rao, V.D. “Experimental Determination of Turbulent Forced Convection Heat Transfer and Friction Factor with SiO<sub>2</sub> Two-dimensional Enclosure Utilizing Nanofluids”, Int. J. Heat Mass Tran., Vol. 46, pp. 3639-3653, 2003.
18. Das, S.K., Choi, S.U., and Patel, H.E. “Heat Transfer in Nanofluids—A Review”, Heat Transfer Eng., Vol. 27, pp. 3-19, 2006.
19. Mansour, R.B., Galanis, N., and Nguyen, C.T. “Effect of Uncertainties in Physical Properties on Forced Convection Heat Transfer with Nanofluids”, Appl. Therm. Eng., Vol. 27, pp. 240-249, 2007.
20. Namburu, P.K., Das, D.K., Tanguturi, K.M., and Vajjha, R.S. “Numerical Study of Turbulent Flow and Heat Transfer Characteristics of Nanofluids Considering Variable Properties”, Int. J. Therm. Sci., Vol. 48, pp. 290-302, 2009.
21. Maiga, S.E.B., Nguyen, C.T., Galanis, N., and Roy, G. “Heat Transfer Behaviours of Nanofluids in a Uniformly Heated Tube”, Superlattice Microst., Vol. 35, pp. 543-557, 2004.
22. Behzadmehr, A., Saffar-Avval, M., and Galanis, N. “Prediction of Turbulent Forced Convection of a Nanofluid in a Tube With Uniform Heat Flux Using a Two Phase Approach”, Int. J. Heat Fluid Flow, Vol. 28, pp. 211-219, 2007.
23. Heidari, E., Sobati, M.A., and Movahedirad, S. “Accurate Prediction of Nanofluid Viscosity, Using a Multilayer Perceptron Artificial Neural Network (MLP-ANN)”, Chemometr. Intell. Lab., Vol. 155, pp. 73-85, 2016.
24. Esfe, M.H., Saedodin, S., Bahiraei, M., Toghraie, D., Mahian, O., and Wongwises, S. “Thermal Conductivity Modeling of MgO/EG Nanofluids, Using Experimental Data and Artificial Neural Network”, J. Therm. Anal. Calorim., Vol. 118, pp. 287-294, 2014.
25. Esfe, M.H., Saedodin, S., Sina, N., Afrand, M., and Rostami, S. “Designing an Artificial Neural Network to Predict Thermal Conductivity and Dynamic Viscosity of Ferromagnetic Nanofluid”, Int. Commun. Heat Mass, Vol. 68, pp. 50-57, 2015.
26. Hojjat, M., Etemad, S.G., Bagheri, R., and Thibault, J. “Thermal Conductivity of Non-Newtonian Nanofluids: Experimental Data and Modeling Using Neural Network”, Int. J. Heat Mass Tran., Vol. 54, pp. 1017-1023, 2011.
27. Pak, BC. and Cho, IY. “Hydrodynamic and Heat Transfer Study of Dispersed Fluids with Sub-Micron Metallic Oxide Particles”, Exp. Heat Tran., Vol. 11, pp. 151–170, 1998.
28. Xuan, Y. and Li, Q. “Investigation on Convective Heat Transfer and Flow Features of Nanofluids”, J. Heat Trans. Vol. 125, pp. 151–155, 2003.
29. Maiga, S., Palm, S., Nguyen, C., Roy, G. and Galanis, N. “Heat Transfer Enhancements, Using

44. Moghadassi, A., Parvizian, F., and Hosseini, S. "A New Approach Based on Artificial Neural Networks for Prediction of High Pressure Vapor-Liquid Equilibrium", *A. J. B. A. S.*, Vol. 3, pp. 1851-1862, 2009.
45. Collobert, R. and Bengio, S. "Links between Perceptrons, Mlp's and Svms"; *Proc. Int'l Conf. on Machine Learning (ICML)*, 2004.
46. Nanofluid", *Exp. Therm. Fluid Sci.*, Vol. 51, pp. 103-111, 2013.
42. Sundar, L.S., Naik, M.T., Sharma, K.V., Singh, M. K., and Reddy, T.C.S. "Experimental Investigation of Forced Convection Heat Transfer and Friction Factor in a Tube with Fe<sub>3</sub>O<sub>4</sub> Magnetic Nanofluid", *Exp. Therm. Fluid Sci.*, Vol. 37, pp. 65-71, 2012.
43. Haghghi, E.B., Utomo, A.T., Ghanbarpour, M., Zavareh, A.I., Poth, H., Khodabandeh, R., and Palm, B.E. "Experimental Study on Convective Heat Transfer of Nanofluids in Turbulent Flow: Methods of Comparison of Their Performance", *Exp. Therm. Fluid Sci.*, Vol. 57, pp. 378-387, 2014.