



Comparison of Perceptron and Radial Basis Function Neural Networks in Modeling Heat Exchangers with Rectangular Helical Channels

Reza Beigzadeh*

Department of Chemical Engineering, Faculty of Engineering, University of Kurdistan, Sanandaj, Iran

ABSTRACT: In this research, computational fluid dynamics method was used to investigate the effect of geometrical parameters of rectangular spiral channels on heat transfer coefficient. Two artificial neural networks including perceptron (MLP) and radial basis function (RBF) models were used to model the heat transfer in helical channels. The model inputs included the Reynolds number and geometric parameters of the channels, and output was the Nusselt number. 135 data were generated by Computational Fluid Dynamics (CFD) simulation and after validation were used for training and evaluation of neural network models. The results of the research showed that the accuracy of MLP was slightly higher than RBF, however, both models were acceptable. Due to the high and acceptable accuracy of these two models, they can be well used in future research and applications. In this research, the main innovation is comparing two different methods for modelling the heat exchanger with a rectangular helical channel. This research shows that the use of perceptron neural network and radial basis function can both be effective in improving the performance and efficiency of the heat exchanger. This research can be used as a guide to choose the appropriate method for modeling heat exchangers and help to improve technologies related to this field.

Review History:

Received: Dec. 02, 2023

Revised: Jul. 12, 2024

Accepted: Oct. 06, 2024

Available Online: Oct. 12, 2024

Keywords:

Rectangular Spiral Channels

Perceptron Neural Network

Radial Basis Function

Computational Fluid Dynamics

Heat Exchanger

1- Introduction

Heat exchangers are essential in industrial processes for effective heat transfer between fluids. The rectangular helical channel heat exchanger has gained popularity due to its superior heat transfer performance and smaller size [1, 2]. It is widely used in industries needing precise temperature control, such as chemical manufacturing, HVAC systems, and the food industry. These exchangers feature large surface areas for efficient thermal management. This study focuses on modeling these exchangers using artificial neural networks to predict their thermal performance, helping engineers optimize design and efficiency in various applications. In recent years, artificial intelligence techniques, particularly neural networks, have gained traction in chemical engineering for modelling complex relationships between variables [3-6]. Rinoso and colleagues [7] utilized artificial neural networks to predict heat exchanger performance parameters, achieving high accuracy and reduced computational time compared to traditional methods, focusing on a cross-flow heat exchanger and utilizing the Perceptron model.

This research compares Perceptron and Radial Basis Function networks in modelling rectangular helical channel heat exchangers, focusing on accuracy, efficiency, and generalization.

2- Modelling by Computational Fluid Dynamics

The study examines the geometric dimensions of a rectangular corrugated channel, featuring a 1 cm diameter with ten turns and varying lengths (7, 10, and 13 cm) and bend angles (10 to 90 degrees). A boundary layer mesh enhances accuracy, with simulations using water and Reynolds numbers between 20,000 and 60,000. Fluent software was employed, ensuring convergence with a minimum accuracy of 8^{-10} . Validation against reference data confirmed simulation reliability, while grid independence tests indicated that a mesh size over 400,000 had minimal effects on results.

3- The Difference Between Perceptron and Radial Base Neural Network

Radial basis and perceptron neural networks have distinct characteristics that make them suitable for different modelling scenarios. Perceptron is better at complex pattern recognition tasks.; But they may lack interpretability. On the other hand, radial basis networks offer simplicity and local modeling capabilities, but may not handle complex relationships effectively. The choice between the two depends on the requirements of the particular problem and the trade-off between interpretability and performance.

*Corresponding author's email: r.beigzadeh@uok.ac.ir






Fig. 1. Velocity distribution along channels with different bending angles.

4- Results and Discussion

The purpose of this research is to compare the performance of two perceptron and radial basis neural networks in estimating the Nusselt number in a rectangular spiral channel as a function of the geometric dimensions of the channel. The required data were created by computational fluid dynamics simulation and used for neural network modeling after validation.

Figure 1 shows the velocity distribution for the examined channel at a Reynolds number of 60,000 and bend angles of 10, 50, and 90 degrees. As can be seen, at low angles, the velocity gradient is very small, and as a result, the secondary flow is also weak. Therefore, the curvature of the bends at low angles has a significant effect on the non-realization or dimming of the flow disturbance and the increase of heat transfer.

From the total of 135 data obtained by computational fluid dynamics simulation, seventy percent (95 data) were considered for training two perceptron and radial basis neural networks and thirty percent (40 data) were considered for validating the models. Input data include Reynolds number (Re), bend angle and channel straight length ratio. The Nusselt number (Nu) was considered as the output variable.

Overfitting of the neural network model occurs when the model has a high complexity (a large number of neurons) or a small amount of training data is involved in the training process. In this situation, the neural network is only able to estimate the training data and the error of the validation data increases greatly. In this regard, Table 5 reports the error values for two trained neural networks for training and validation data sets. The validation data were not involved in the training process and the low error values for this set confirm the correctness of the models.

5- Conclusions

This study employed two neural network models, Perceptron and Radial Basis Function, to model heat transfer in rectangular helical channels. The input variables included

Table 1. Comparison of the accuracy of MLP and RBF networks.

Model	Data	Number of data	MRE (%)	MSE
MLP	Training	95	0.196	0.319
	Validation	40	0.334	1.085
	All	135	0.237	0.546
RBF	Training	95	0.29	0.776
	Validation	40	0.361	1.094
	All	135	0.311	0.872

Reynolds number and channel geometric parameters, while the output variable represented the Nusselt number. Data for the models were derived from computational fluid dynamics simulations, with 135 simulation data points divided into training (95 data) and evaluation (40 data) sets. The Perceptron model is a multilayer neural network optimized with a sigmoid activation function, capable of recognizing complex patterns and providing high accuracy. The Radial Basis Function architecture consists of a hidden layer with Gaussian activation functions, where each group is defined by a center and radius. Results indicated that both Perceptron and Radial Basis Function models are suitable for modeling heat transfer in rectangular corrugated channels, with the Perceptron showing slightly higher accuracy, likely due to its ability to detect complex patterns and nonlinear interactions among variables. Overall, using neural networks for heat transfer modeling in these channels yields high and acceptable accuracy, effectively accommodating variations in input and output parameters while automatically identifying patterns.

References

- [1] V. Irabatti, Y. Patil, S. Kore, V. Barangule, A. Kothe, Comprehensive review of spiral heat exchanger for diverse applications, *Materials Today: Proceedings*, 72 (2023) 1328-1334.
- [2] S. Soltanian, R. Beigzadeh, Computational fluid dynamics and fuzzy logic for modeling conical spiral heat exchangers, *Chemical Engineering & Technology*, 46(4) (2023) 747-755.
- [3] R. Beigzadeh, S. Eiamsa-ard, Fuzzy logic to thermal and friction characteristics of turbulent air-flow over diamond-shaped turbulators, *International Communications in Heat and Mass Transfer*, 120 (2021) 105001.
- [4] M. Rastegarmoghaddam, M. Rajabi, S.D. Nikkhoy Tanha, Use of Artificial Intelligence to Identify Adhesive Joints Defects by Using Ultrasonic, *Amirkabir Journal of Mechanical Engineering*, 54(2) (2022) 377-390.

- [5] M. Sridharan, Applications of artificial intelligence techniques in heat exchanger systems, in: *Advanced Analytic and Control Techniques for Thermal Systems with Heat Exchangers*, Elsevier, 2020, pp. 325-334.
- [6] M. Mohanraj, S. Jayaraj, C. Muraleedharan, Applications of artificial neural networks for thermal analysis of heat exchangers—a review, *International Journal of Thermal Sciences*, 90 (2015) 150-172.
- [7] E. Reynoso-Jardón, A. Tlatelpa-Becerro, R. Rico-Martínez, M. Calderón-Ramírez, G. Urquiza, Artificial neural networks (ANN) to predict overall heat transfer coefficient and pressure drop on a simulated heat exchanger, *International Journal of Applied Engineering Research*, 14(13) (2019) 3097-3103.

مقایسه شبکه عصبی پرسپترون و تابع پایه شعاعی در مدل‌سازی مبدل حرارتی با کانال ماریپیچ مستطیلی

رضا بیگزاده*

دانشکده مهندسی، دانشگاه کردستان، سنندج، ایران.

تاریخچه داوری:

دریافت: ۱۴۰۲/۰۹/۱۱
بازنگری: ۱۴۰۳/۰۴/۲۲
پذیرش: ۱۴۰۳/۰۷/۱۵
ارائه آنلاین: ۱۴۰۳/۰۷/۲۱

کلمات کلیدی:

کانال ماریپیچ مستطیلی
شبکه عصبی پرسپترون
تابع پایه شعاعی
دینامیک سیالات محاسباتی
مبدل حرارتی

خلاصه: در این تحقیق از شبیه‌سازی دینامیک سیالات محاسباتی برای بررسی تاثیر پارامترهای هندسی کانال‌های ماریپیچ مستطیلی بر ضریب انتقال حرارت استفاده شد. دو مدل شبکه عصبی مصنوعی پرسپترون و تابع پایه شعاعی برای مدل‌سازی انتقال حرارت در کانال‌های ماریپیچ مستطیلی استفاده شد. ورودی‌های مدل شامل عدد رینولدز و پارامترهای هندسی کانال و خروجی آن‌ها عدد ناسلت در نظر گرفته شد. ۱۳۵ داده توسط شبیه‌سازی دینامیک سیالات محاسباتی ایجاد و پس از تایید اعتبار برای آموزش و ارزیابی مدل‌های شبکه عصبی استفاده شد. نتایج حاصل از تحقیق نشان داد که دقت شبکه عصبی پرسپترون کمی بالاتر از تابع پایه شعاعی بود و در کل دو مدل قابل قبول بودند. با توجه به دقت قابل قبول این دو مدل، آن‌ها را می‌توان به‌خوبی در تحقیقات آینده و برنامه‌های کاربردی استفاده کرد. نوآوری اصلی در مقایسه دو روش مختلف برای مدل‌سازی مبدل حرارتی با کانال ماریپیچ مستطیلی و ارائه نتایج برای هر دو روش است. این پژوهش نشان می‌دهد که استفاده از شبکه عصبی پرسپترون و تابع پایه شعاعی می‌تواند در بهبود عملکرد و بهره‌وری مبدل حرارتی موثر باشد. این تحقیق می‌تواند به عنوان راهنمایی برای انتخاب روش مناسب برای مدل‌سازی مبدل‌های حرارتی مورد استفاده قرار گیرد و به بهبود فناوری‌های مرتبط با این حوزه کمک کند.

۱- مقدمه

غذایی و آشامیدنی، صنایع داروسازی و بسیاری از کاربردهای دیگر که کنترل دقیق دما مورد نیاز است نیز استفاده می‌شود. کانال‌های ماریپیچی سطح بزرگی را برای انتقال حرارت ایجاد می‌کنند که امکان خنک‌سازی یا گرمایش سریع و کارآمد سیال درون مبدل را فراهم می‌کند. برای بهینه‌سازی طراحی و عملکرد این مبدل‌های حرارتی، تکنیک‌های مدل‌سازی دقیق مورد نیاز است. در این تحقیق، مدل‌سازی مبدل‌های حرارتی با کانال‌های ماریپیچ مستطیلی توسط شبکه عصبی مصنوعی^۱ بررسی شده و اصول اساسی و روش‌های مورد استفاده برای پیش‌بینی عملکرد حرارتی آنها را مورد بحث قرار گرفته است. با درک و پیش‌بینی دقیق رفتار این مبدل‌های حرارتی، مهندسان می‌توانند تصمیمات مناسبی در مورد طراحی و عملکرد آن‌ها اتخاذ کنند که منجر به بهبود راندمان و مقرون‌به‌صرفه بودن در کاربردهای مختلف صنعتی می‌شود.

در سال‌های اخیر، تکنیک‌های هوش مصنوعی در مهندسی شیمی مورد توجه قرار گرفته‌اند [۳-۵]. در میان این تکنیک‌ها، شبکه‌های عصبی

مبدل‌های حرارتی اجزای حیاتی در فرایندهای مختلف صنعتی هستند، زیرا انتقال موثر گرما بین دو سیال را تسهیل می‌کنند. یکی از انواع مبدل‌های حرارتی که در سال‌های اخیر مورد توجه قرار گرفته است، مبدل حرارتی کانال ماریپیچ است [۱، ۲]. این طراحی نوآورانه چندین مزیت را نسبت به دیگر مبدل‌های حرارتی ارائه می‌دهد، از جمله افزایش عملکرد انتقال حرارت و کاهش اندازه مورد نیاز مبدل. یکی از کاربردهای کلیدی مبدل‌های حرارتی کانال ماریپیچ در فرایندهای صنعتی است که نیاز به کنترل دقیق دما دارند. به عنوان مثال، در صنایع شیمیایی از مبدل‌های حرارتی کانال ماریپیچ برای خنک کردن یا گرم کردن ترکیبات شیمیایی مختلف در حین حرکت در خط تولید استفاده می‌شود. یکی دیگر از کاربردهای رایج این مبدل‌های حرارتی در سیستم‌های تهویه مطبوع است. این مبدل‌های حرارتی برای انتقال گرما بین جریان‌های هوا مورد استفاده قرار می‌گیرند و به گرمایش و خنک کردن کارآمد ساختمان‌ها کمک می‌کنند. مبدل‌های حرارتی کانال ماریپیچ در صنایع

1 Artificial Neural Network, ANN


* نویسنده عهده‌دار مکاتبات: r.beigzadeh@uok.ac.ir

جین و همکاران [۱۲] از داده‌های صنعتی برای پیش‌بینی میزان خوردگی در مبدل‌های حرارتی توسط مدل تابع پایه شعاعی استفاده کردند. در این تحقیق با در نظر گرفتن سیستم واکنش هیدروژناسیون نفت در یک شرکت پالایشی، پارامترهای کلیدی خوردگی جریان مبدل حرارتی با استفاده از این روش، پیش‌بینی می‌شوند. جی و همکاران [۱۳] از شبکه عصبی پایه شعاعی همراه با الگوریتم بهینه‌سازی ژنتیک چند هدفه برای انجام بهینه‌سازی چندهدفه پروانه توربین و به منظور بهبود کارایی پمپ گریزمرکز استفاده کردند. در واقع در این تحقیق از شبکه عصبی پایه شعاعی برای برازش رابطه بین متغیرهای بهینه‌سازی و از الگوریتم ژنتیک برای بهینه‌سازی چندهدفه استفاده شد. وو [۱۴] از شبکه عصبی پایه شعاعی برای مدل‌سازی دینامیکی یک توربین گازی استفاده کرد. مشاهده شد که از طریق روش شبیه‌سازی عملکرد دینامیکی مبتنی بر شبکه عصبی پایه شعاعی، می‌توان بازده عملیاتی توربین گازی را بهبود بخشید و نیز از وقوع حوادث عملیاتی جلوگیری کرد. دو نوع محبوب شبکه‌های عصبی مورد استفاده برای مدل‌سازی مبدل حرارتی، شبکه‌های چند لایه پرسپترون^۲ چندلایه و تابع پایه شعاعی هستند. مدل شبکه عصبی پرسپترون به‌عنوان یک شبکه عصبی چندلایه، قابلیت یادگیری و تشخیص الگوهای پیچیده و توالی‌های داده‌ها را دارد که در مسائل پیچیده و با داده‌های بزرگ بسیار مؤثر است. این مدل به دلیل توانایی تطبیق با داده‌های آموزشی و توانایی تعمیم به داده‌های جدید، می‌تواند در پیش‌بینی و مدل‌سازی سیستم‌های انتقال حرارت با دقت و صحت بالا عمل کند. همچنین، پرسپترون دارای تعداد زیادی پارامتر است که امکان بهینه‌سازی مدل را فراهم می‌کند و از آنجا که قابلیت تنظیم پارامترها و ساختار شبکه وجود دارد، می‌توان به راحتی برای بهبود عملکرد مدل‌ها از آن استفاده کرد. در نتیجه، استفاده از مدل شبکه عصبی پرسپترون در یک تحقیق می‌تواند به تضمین دقت و کارایی مدل‌ها در پیش‌بینی و شبیه‌سازی سیستم‌های انتقال حرارت کمک کند و نتایج قابل اعتماد و معتبری ارائه دهد. مدل شبکه عصبی پایه شعاعی یک روش مدل‌سازی غیرخطی است که به دلیل توانایی خود در تطبیق با الگوهای غیرخطی و توالی‌های داده‌ها، در مسائلی که رفتاری غیرخطی دارند، استفاده می‌شود. این مدل به دلیل استفاده از توابع پایه شعاعی و توزیع‌های چندجمله‌ای، قادر به تقریب دقیق‌تر الگوهای داده‌ها و پیش‌بینی دقیق‌تر سیستم‌های انتقال حرارت است. همچنین، پایه شعاعی به‌عنوان یک روش ساده‌تر نسبت به پرسپترون، از تعداد کمتری پارامتر برای تنظیم و بهینه‌سازی استفاده می‌کند که این امر می‌تواند استفاده

به‌عنوان ابزار قدرتمندی برای گرفتن روابط پیچیده بین متغیرهای ورودی و خروجی ظاهر شده‌اند [۶].

رینوسو و همکاران [۷] از شبکه‌های عصبی مصنوعی برای پیش‌بینی عملکرد مبدل حرارتی استفاده کردند. این مقاله یک رویکرد جدید با استفاده از شبکه‌های عصبی مصنوعی برای پیش‌بینی پارامترهای عملکرد مبدل حرارتی مانند ضریب انتقال حرارت، افت فشار و نرخ کلی انتقال حرارت ارائه می‌کند. نویسندگان مدل شبکه عصبی را با استفاده از یک مجموعه داده بزرگ به دست آمده از اندازه‌گیری‌های تجربی آموزش دادند. نتایج نشان داد که شبکه‌های عصبی مصنوعی می‌توانند عملکرد مبدل حرارتی را با دقت بالا و کاهش زمان محاسباتی در مقایسه با روش‌های سنتی به طور دقیق پیش‌بینی کنند. پژوهش انجام شده یک مبدل حرارتی با جریان متقاطع را بررسی می‌کند. در این مطالعه جنس فلز استفاده شده در مبدل به‌عنوان ورودی شبکه در نظر گرفته شده است. همچنین فقط شبکه عصبی پرسپترون را به‌عنوان مدل پیش‌بینی کننده بررسی کرده است.

در تحقیق دیگری از سیستم کنترل منطق فازی برای تنظیم دمای مبدل حرارتی استفاده شد [۸]. یک مدل منطق فازی توسعه داده شد که از قوانین فازی برای تعیین اقدامات کنترلی مناسب بر اساس متغیرهای ورودی مانند دمای ورودی، سرعت جریان و دمای خروجی مطلوب استفاده می‌کرد. نتایج تجربی نشان داد که کنترل مبتنی بر منطق فازی به طور قابل توجهی دقت و پایداری تنظیم دما را در مقایسه با کنترل کننده‌های معمولی بهبود می‌بخشد. یو و همکاران [۹] به کارگیری شبکه عصبی پایه شعاعی^۱ برای پیش‌بینی عملکرد حرارتی دو مبدل حرارتی جدید پوسته و لوله با جریان موازی را بررسی کردند. مشخص شد که شبکه پایه شعاعی نسبت به سایر مدل‌ها عملکرد بهتری دارد. همچنین برای پایه شعاعی، این درست نیست که هر چه داده‌های آموزش بیشتر باشد، دقت پیش‌بینی بیشتر است و پارامتر گسترش در مدل پایه شعاعی باید برای بهینه‌سازی نتایج پیش‌بینی تنظیم شود. رامکومار و همکاران [۱۰] از سیستم‌های استنتاج تطبیقی - فازی برای مدل‌سازی لوله حرارتی استفاده کردند. نتایج نشان داد که دقت پیش‌بینی مدل بسیار بالا بوده و خروجی مدل به نتایج تجربی نزدیک است. شیلپا و لالا [۱۱] از یک مدل شبکه عصبی مصنوعی برای مدل‌سازی انتقال گرما و جرم در یک استوانه شیب‌دار با وجود تولید گرما و واکنش شیمیایی استفاده کردند. نتایج بیانگر دقت بالای شبکه عصبی پرسپترون با شیوه آموزش لونیگ-مارکورت نسبت به داده‌های هدف می‌باشد.



شکل ۱. پارامترهای هندسی کانال مارپیچ مستطیلی.

Fig. 1. Geometric parameters of rectangular helical channel.

جمله روش‌های سنتی انعطاف‌پذیر و کارآمد برای بهبود عملکرد مبدل‌های حرارتی می‌باشند. به عنوان مقایسه، روش‌های یادگیری عمیق نیز به عنوان روش‌های پیشرفته مدل‌سازی و پیش‌بینی مورد استفاده قرار می‌گیرند. این روش‌ها از شبکه‌های عصبی ژرف با توانایی یادگیری پیچیدگی‌های بیشتر استفاده می‌کنند. با این حال، استفاده از شبکه عصبی پرسپترون و تابع پایه شعاعی نیز به دلیل انعطاف‌پذیری و قابلیت تطبیق بهتر با داده‌های موجود، می‌توانند مزایای خاصی در مدل‌سازی مبدل‌های حرارتی داشته باشند. این موضوع نشان دهنده اهمیت و جایگاه این دو روش سنتی در حوزه مدل‌سازی مبدل‌های حرارتی است و نشان می‌دهد که این روش‌ها همچنان به عنوان گزینه‌های موثر در بهبود عملکرد و بهره‌وری مبدل‌های حرارتی قابل توجه محسوب می‌شوند.

۲- مدل‌سازی به روش دینامیک سیالات محاسباتی^۱

در شکل ۱، ابعاد هندسی کانال مارپیچ مستطیلی مشاهده می‌شود. قطر کانال یک سانتی‌متر و تعداد گام‌های کانال ۱۰ در نظر گرفته شد. همچنین طول قسمت ورودی و خروجی کانال یکسان و ۱۵ سانتی‌متر می‌باشد. در هندسه نمایش داده‌شده در شکل، زاویه خم (α) قابل مشاهده است. در این تحقیق سه مقدار برای L_s شامل ۷، ۱۰ و ۱۳ سانتی‌متر و ۹ زاویه خم در محدوده ۱۰ تا ۹۰ با فاصله ۱۰ درجه در نظر گرفته شد.

در این تحقیق از مش لایه‌مرزی برای افزایش دقت مدل‌سازی و تخمین عملکرد در نزدیکی دیوارها استفاده شد. برای همه کانال‌های شبیه‌سازی شده شرایط مرزی شامل دمای سیال ورودی ۲۹۸ کلین و دمای دیواره ۳۵۳

از آن را برای محققان و مهندسان ساده‌تر کند.

هدف این تحقیق مقایسه عملکرد شبکه‌های پرسپترون و پایه شعاعی در مدل‌سازی مبدل‌های حرارتی با کانال مارپیچ مستطیلی و با در نظر گرفتن عواملی مانند دقت، بازده محاسباتی و قابلیت تعمیم است. با درک نقاط قوت و ضعف این دو رویکرد، محققان و مهندسان می‌توانند تصمیمات آگاهانه‌ای را هنگام انتخاب یک معماری شبکه عصبی مناسب برای کاربردهای مدل‌سازی مبدل حرارتی اتخاذ کنند. این پژوهش از ترکیب مدل‌سازی دینامیک سیالات محاسباتی و شبکه عصبی مصنوعی برای مدل‌سازی مبدل حرارتی استفاده می‌کند. این ترکیب نیاز به تحلیل و پیش‌بینی دقیق تر رفتار سیالات و انتقال حرارت در مبدل‌های حرارتی را برآورده می‌کند و به محققان امکان می‌دهد تا بهبودهای بیشتری در طراحی و بهره‌وری این انواع تجهیزات حرارتی داشته باشند. همچنین در این تحقیق عملکرد دو روش شبکه عصبی پرسپترون و پایه شعاعی از نظر دقت پیش‌بینی و عملکرد مقایسه شدند.

در این پژوهش، مبدل‌های حرارتی با کانال‌های مارپیچ مستطیلی به عنوان مورد مطالعه انتخاب شده‌اند تا عمومیت و کارایی این روش‌های مدل‌سازی برای این نوع تجهیزات بررسی شود. انتخاب یک نوع خاص از مبدل‌های حرارتی، یعنی مبدل‌های با کانال‌های مارپیچ مستطیلی، به پژوهشگران این امکان را می‌دهد که با دقت بیشتری اثرات و عملکرد روش‌های مختلف مدل‌سازی را ارزیابی کنند و نتایج را با یکدیگر مقایسه نمایند. این انتخاب موضوع و منحصر به فرد بودن آن، به افزایش دقت و ارتقاء دانش در حوزه مدل‌سازی مبدل‌های حرارتی کمک می‌کند و می‌تواند خلاقیت و پیشرفت در این زمینه را ترویج دهد.

تکنیک‌های مدل‌سازی شبکه عصبی پرسپترون و تابع پایه شعاعی از

جدول ۱. نتایج اعتبارسنجی.

Table 1. Validation results.

عدد رینولدز	عدد ناسلت شبیه‌سازی	عدد ناسلت مرجع [۱۵]	درصد خطا
۲۰۰۰۰	۱۱۰/۰۷	۱۰۸/۱۴	۱/۷۸
۳۰۰۰۰	۱۵۵/۱	۱۵۶/۵۳	۰/۸۹
۴۰۰۰۰	۱۹۷/۸	۲۰۳/۵۱	۲/۷۷
۵۰۰۰۰	۲۳۸/۹۴	۲۴۹/۴۸	۴/۲۲

داده شده‌است، در تعداد مش‌های تقریباً برابر با ۴۱۰۰۰۰، تغییرات کمتر از ۵ پاسکال (زیر ۱ درصد) در متغیر هدف مشاهده شد. بنابراین، نتیجه این آزمون برای مدل‌سازی کانال‌ها مورد استفاده قرار گرفت.

۳- تفاوت شبکه عصبی پرسپترون و پایه شعاعی

شبکه‌های عصبی پرسپترون (پرسپترون چندلایه) و پایه شعاعی (تابع پایه شعاعی) دو تکنیک محبوبی هستند که برای مدل‌سازی روابط پیچیده در داده‌ها استفاده می‌شوند. درحالی‌که هر دو دارای معماری شبکه‌های عصبی هستند، اما در ساختار، روش‌های آموزشی و کاربردهایشان متفاوت می‌باشند [۱۶]. در ادامه، تفاوت‌های کلیدی بین شبکه‌های عصبی پرسپترون و پایه شعاعی برای مدل‌سازی بررسی شده‌اند.

۳-۱- ساختار

پرسپترون: از یک لایه ورودی، یک یا چند لایه پنهان با چند نورون و یک لایه خروجی تشکیل شده است. هر نورون در لایه‌های پنهان از یک تابع فعال‌سازی برای تبدیل مجموع وزنی ورودی‌های خود استفاده می‌کند. پایه شعاعی: معمولاً از سه لایه تشکیل شده است - یک لایه ورودی، یک لایه پنهان با نورون‌های تابع پایه شعاعی و یک لایه خروجی.

۳-۲- تابع فعال‌سازی

پرسپترون: توابع فعال‌سازی رایج شامل سیگموئید هستند. پایه شعاعی: توابع پایه شعاعی مانند گاوسی یا معکوس چنددرجه‌ای

کلوین و آب به‌عنوان سیال عامل در نظر گرفته شد. همچنین شبیه‌سازی برای اعداد رینولدز بین ۲۰۰۰۰ تا ۶۰۰۰۰ انجام گرفت.


در این معادلات ρ چگالی، u بردار سرعت، P فشار، μ ویسکوزیته و k_{eff} هدایت حرارتی مؤثر می‌باشند. از نرم‌افزار فلوئنت برای شبیه‌سازی دینامیک سیالات محاسباتی استفاده گردید. از مدل آشفتگی کا اسیلون استاندارد^۱ و الگوریتم سیمپل^۲ استفاده شد. همچنین در دیواره‌ها شرط توابع دیواره استاندارد^۳ ($30 < Y^+ < 300$) در نظر گرفته شده است. در این مطالعه حداقل دقت برای همگرایی^۴ برای متغیرهای هدف برابر با 10^{-8} انتخاب شد. برای تایید اعتبار نتایج شبیه‌سازی از داده‌های مرجع [۱۵] مربوط به جریان سیال در یک لوله مستقیم استفاده شد (معادله ۱). نتایج مقایسه در جدول ۱ ارائه شده‌است.

$$Nu = 0.00881 Re^{0.8991} Pr^{0.3911} \quad (1)$$

Valid for: $3 \times 10^3 \leq Re \leq 10^6$, $3 < Pr \leq 1000$

همچنین نتایج آزمون استقلال از مش نشان داد که تعداد مش بیشتر از ۴۰۰۰۰۰ تاثیر زیادی بر روی نتایج شبیه‌سازی ندارد. در این تحقیق استقلال از مش با بررسی تغییرات افت فشار انجام شد. همانطور که در شکل ۲ نشان

- 1 Standard k-ε, SKE
- 2 SIMPLE
- 3 Standard wall function
- 4 Minimum Convergence Criterion



شکل ۲. آزمون استقلال از مش

Fig. 2. Mesh independence test.

به عنوان توابع فعالسازی استفاده می‌شوند.

۳-۳- روش آموزش

پرسپترون: فرایند آموزش شامل پس انتشار خطا است که در آن خطا به عقب شبکه منتشر می‌شود تا وزن‌ها را با استفاده از روش بهینه‌سازی گرادیان نزولی تنظیم کنند. پایه شعاعی: آموزش معمولاً با استفاده از الگوریتم‌های یادگیری بدون نظارت مانند خوشه‌بندی k برای تعیین مراکز توابع پایه شعاعی انجام می‌شود. سپس وزن‌های اتصال لایه‌های مخفی و خروجی با استفاده از رگرسیون خطی یا روش‌های دیگر محاسبه می‌شوند.

۳-۴- تفسیرپذیری

پرسپترون: به دلیل ساختار پیچیده آن با چندین لایه پنهان و توابع فعالسازی غیرخطی، تفسیر روابط می‌تواند چالش برانگیز باشد. پایه شعاعی: سادگی شبکه‌های پایه شعاعی امکان تفسیر آسان‌تر را فراهم می‌کند، زیرا هر تابع پایه شعاعی منطقه‌ای از نفوذ را نشان می‌دهد.

۳-۵- تعمیم

پرسپترون: ظرفیت بالایی برای یادگیری الگوهای پیچیده دارند، اما اگر


به درستی منظم نشوند، ممکن است مستعد بیش از حد برازش شوند.

پایه شعاعی: شبکه‌های پایه شعاعی به دلیل ماهیت محلی خود تمایل به تعمیم خوبی دارند و آن‌ها را برای مدل‌سازی با داده‌های آموزشی محدود مناسب می‌کند.

۳-۶- برنامه‌های کاربردی

پرسپترون: پرسپترون‌ها به طور گسترده برای کارهای مختلفی مانند طبقه‌بندی، رگرسیون و تشخیص الگو در زمینه‌هایی مانند پردازش تصویر، پردازش زبان طبیعی و امور مالی استفاده می‌شوند. پایه شعاعی: شبکه‌های پایه شعاعی معمولاً در سیستم‌های تقریب تابع، پیش‌بینی سری‌های زمانی و سیستم‌های کنترل که در آن مدل‌سازی محلی مورد نظر است، استفاده می‌شود.

به طور خلاصه، شبکه‌های عصبی پرسپترون و پایه شعاعی دارای ویژگی‌های متمایزی هستند که آن‌ها را برای سناریوهای مختلف مدل‌سازی مناسب می‌کند. پرسپترون‌ها در وظایف پیچیده تشخیص الگو برتر هستند؛ اما ممکن است فاقد قابلیت تفسیر باشند. از سوی دیگر، شبکه‌های پایه شعاعی سادگی و قابلیت‌های مدل‌سازی محلی را ارائه می‌کنند، اما ممکن است روابط پیچیده را به طور مؤثر مدیریت نکنند. انتخاب بین این دو بستگی به الزامات مسئله خاص و مبادله بین تفسیرپذیری و عملکرد دارد.



شکل ۳. توزیع سرعت در طول کانال‌هایی با زاویه خم متفاوت.

Fig. 3. Velocity distribution along channel with different bending angles.

۴- بحث و بررسی نتایج

مسئله بهبود انتقال حرارت جابجایی بین سیال و دیواره را در پی خواهد داشت. از طرفی، هرچه LS افزایش یابد، عدد ناسلت کمتر می‌شود که دلیل آن کاهش تلاطم ایجاد شده توسط خم‌ها است. وجود قسمت‌های مستقیم بعد از خم‌ها به تضعیف قدرت چرخش گردابه‌های ایجاد شده در خم‌ها منجر می‌شود و به سیال فرصت می‌دهد تا دوباره حرکت آرام و لایه‌ای خود را بازیابد. افزایش این قسمت‌های مستقیم بین خم‌ها باعث تضعیف بیشتر گردابه‌ها و در نتیجه کاهش ضریب انتقال حرارت می‌شود.

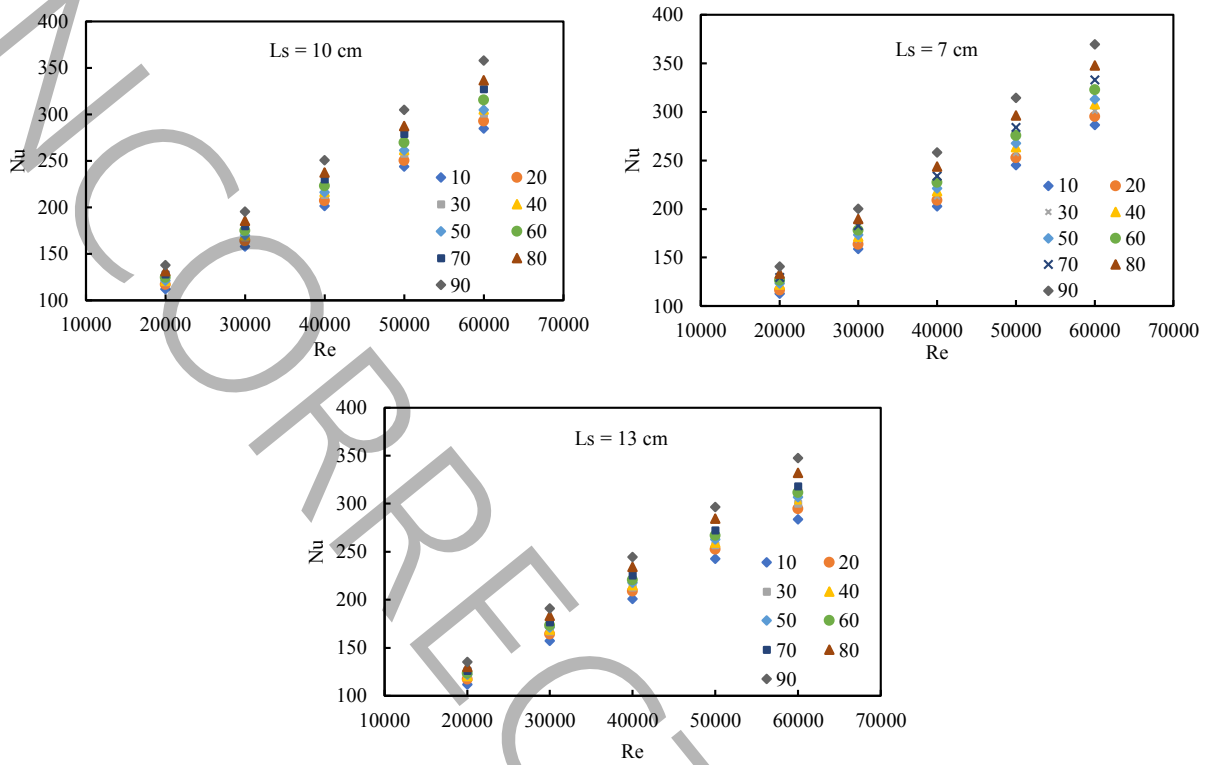
از مجموع ۱۳۵ داده بدست آمده توسط شبیه‌سازی دینامیک سیالات محاسباتی هفتاد درصد (۹۵ داده) برای آموزش دو شبکه عصبی پرسپترون و پایه شعاعی و سی درصد (۴۰ داده) برای اعتبارسنجی مدل‌ها اختصاص داده شد. داده‌های ورودی شامل عدد رینولدز (Re)، زاویه خم (α) و نسبت طول مستقیم کانال (Ls/X) هستند. متغیر خروجی نیز عدد ناسلت (Nu) در نظر گرفته شد. با توجه به متفاوت بودن محدوده متغیرها و برای سرعت بیشتر فرایند مدلسازی همه داده‌ها بین صفر تا یک نرمالیزه شدند. جدول ۲ محدوده متغیرهای مورد استفاده را نشان می‌دهد.

تعداد نورون‌های لایه پنهان در دو شبکه پرسپترون و پایه شعاعی توسط روش سعی و خطا بهینه شدند. شکل‌های ۵ و ۶ مقادیر خطای بدست آمده توسط دو شبکه به‌ازای تعداد متفاوت نورون پنهان را نشان می‌دهد. در این

هدف این تحقیق مقایسه عملکرد دو شبکه عصبی پرسپترون و پایه شعاعی در تخمین عدد ناسلت در کانال ماریچج مستطیلی به‌عنوان توابعی از ابعاد هندسی کانال می‌باشد. داده‌های مورد نیاز توسط شبیه‌سازی دینامیک سیالات محاسباتی ایجاد و پس از تایید اعتبار برای مدلسازی شبکه عصبی استفاده شدند.

شکل ۳ توزیع سرعت برای کانال مورد بررسی در عدد رینولدز ۶۰۰۰ و زاویه‌های خم ۱۰، ۵۰ و ۹۰ درجه را نمایش می‌دهد. همان‌طور که مشاهده می‌شود در زاویه‌های کم، گردایان سرعت نمود بسیار کمی داشته و در نتیجه جریان ثانویه نیز ضعیف است. بنابراین انحنای خم‌ها در زاویه‌های کم تأثیر بسزایی در عدم تحقق و یا کم‌رنگ شدن آشفتگی جریان و افزایش انتقال حرارت دارد.

در شکل ۴ تغییرات عدد ناسلت بر حسب عدد رینولدز برای کانال‌های ماریچج مستطیلی در طول‌های مستقیم LS ۷، ۱۰ و ۱۳ سانتی‌متر مشاهده می‌شود. با افزایش عدد رینولدز برای زاویه‌های خم بین ۱۰ تا ۹۰ درجه، عدد ناسلت افزایش می‌یابد که علت آن بیشتر شدن آشفتگی جریان و افزایش ضریب انتقال حرارت است. همچنین افزایش زاویه خم منجر به تقویت جریان ثانویه و در نتیجه تضعیف ضخامت لایه‌مرزی خواهد شد که این



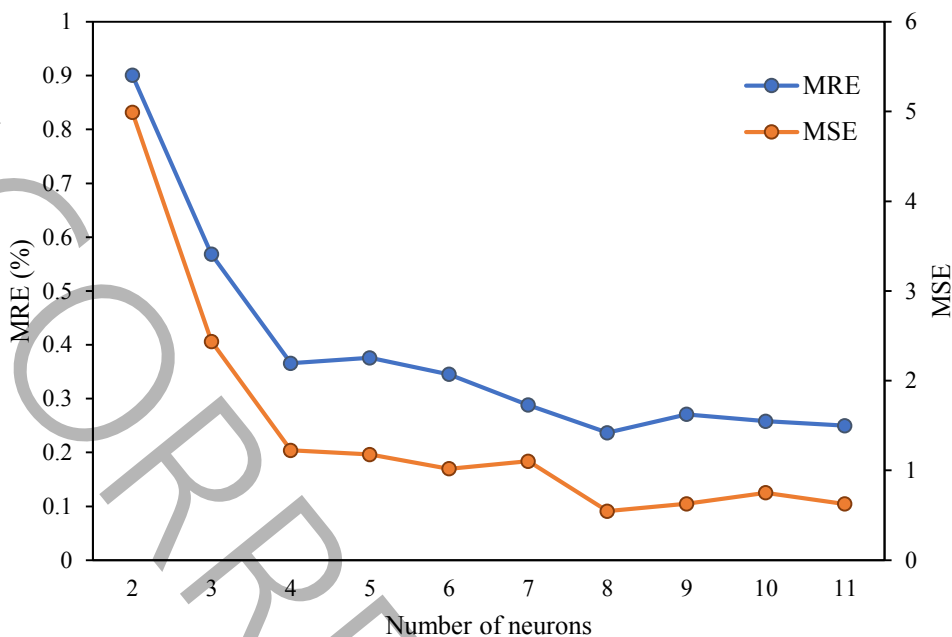
شکل ۴. تغییرات عدد ناسلت برحسب عدد رینولدز برای تمامی ابعاد هندسی شبیه‌سازی شده.

Fig. 4. Nusselt number in terms of Reynolds number for all simulated geometric dimensions.

جدول ۲. محدوده متغیرها.


Table 2. Range of variables.

متغیر	مینیمم	ماکزیمم
Re	۲۰۰۰۰	۶۰۰۰۰
α/π	۰/۰۵۵۶	۰/۵
Ls/X	۰/۷	۱/۳
Nu	۱۱۱/۸۸	۳۶۹/۷۱



شکل ۵. مقادیر خطا برای شبکه پرسپترون آموزش دیده با تعداد نورون‌های مختلف در لایه پنهان.

Fig. 5. Error values for MLP network trained with different number of neurons in hidden layer.



شکل ۶. مقادیر خطا برای شبکه پایه شعاعی آموزش دیده با تعداد نورون‌های مختلف در لایه پنهان.

Fig. 6. Error values for RBF network trained with different number of neurons in hidden layer.

جدول ۳. پارامترهای شبکه عصبی پرسپترون.

Table 3. MLP neural network parameters.

b _k =۱/۴۸۷		W _{ji}			نورون
W _{kj}	b _j	Re	α/π	Ls/X	
-۰/۲۲۲	-۳/۸۴۵	-۰/۳۹۵	۳/۷۲۷	۵/۰۵۳	۱
-۲/۱۵۹	۳/۱۰۴	-۰/۳۲	-۱/۶۶۱	۰/۲۲۳	۲
۰/۰۰۸	-۵/۰۷۹	۶/۶۲۷	-۱/۵۸	-۰/۳۰۹	۳
۰/۵۰۷	-۳/۲۳	-۰/۲۹۱	۲/۷۳۴	۳/۷۱۷	۴
-۰/۰۱۲	۴/۰۵۷	-۳/۳۰۷	-۲/۴۲	۰/۳۵۲	۵
-۰/۵۹۳	-۰/۹۲۷	-۰/۳۰۵	۱/۰۱۶	-۰/۲۵۳	۶
۰/۲۹۳	۳/۵۶۴	۰/۳۰۴	-۲/۸۴۷	-۳/۵۴۵	۷
۱/۶۷۹	۰/۱۴۶	۰/۳۹۶	۰/۲۵	-۰/۰۵۹	۸

زیر تعریف می‌شود:

$$F_t(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (۳)$$

خروجی نهایی شبکه توسط رابطه زیر محاسبه می‌گردد:

$$Y = \sum_{j=1}^n W_{kj} y_j + b_k \quad (۴)$$

که در آن n تعداد نرون‌های لایه پنهان و اندیس k مربوط به خروجی می‌شود. روابط مربوط به شبکه عصبی پایه شعاعی به صورت زیر تعریف می‌شوند:

$$Y = \sum_{j=1}^n W_{kj} h_j + b_k \quad (۵)$$

تحقیق از دو مقدار درصد متوسط خطای نسبی^۱ و متوسط مربع خطا^۲ برای تحلیل نتایج استفاده شد. همان‌طور که در شکل‌ها مشخص است به ترتیب ۸ و ۲۵ نورون در لایه پنهان به عنوان تعداد بهینه انتخاب گردید. در جداول ۳ و ۴ وزن‌ها (W) و بیاس‌های (b) مربوط به شبکه‌های عصبی پرسپترون و پایه شعاعی گزارش شده است. در شبکه پرسپترون برای یافتن خروجی مدل می‌بایست از روابط زیر استفاده کرد:

$$y_j = F_t \left(\sum_{i=1}^m W_{ji} X_i + b_j \right) \quad (۲)$$

که در آن y_j خروجی نرون j ام، X ورودی شبکه، W وزن، b بیاس، m تعداد ورودی‌ها و i و j به ترتیب مربوط به لایه‌های ورودی و پنهان می‌شوند. F_t تابع انتقال تانژانت‌هایپربولیک سیگموئید^۳ است که به صورت

- 1 Mean Relative Error (MRE)
- 2 Mean Squared Error (MSE)
- 3 Hyperbolic tangent sigmoid

جدول ۴. پارامترهای شبکه عصبی پایه شعایی.

Table 4. RBF neural network parameters.

$b_j = 0.1833, b_k = 0.108$		W_{ji}			نورون
W_{kj}	Re	α/π	L/X		
۲۲/۰۶	۱	۱	۰/۵	۱	
-۲۷/۰۱	۰/۵	۱	۰/۵	۲	
۱۵/۷۷	۱	۰	۰/۵	۳	
۹/۷۳	۰/۷۵	۰/۶۲۵	۰/۵	۴	
۲۰۴/۱۳	۱	۱	۱	۵	
۳۳/۴۲	۱	۱	۱	۶	
-۵۶/۰۸	۰/۷۵	۱	۰/۵	۷	
-۵۴۰/۹۶	۱	۰/۸۷۵	۰	۸	
۴۸۸/۰۵	۱	۰/۷۵	۰	۹	
-۶۴/۸۹	۰	۰	۰/۵	۱۰	
-۵۳/۲۷	۰/۲۵	۰/۳۷۵	۰/۵	۱۱	
-۶/۶۶	۰	۰/۷۵	۰/۵	۱۲	
۳۸/۱۴	۰/۲۵	۰	۰/۵	۱۳	
-۲۸/۹۱	۱	۰	۱	۱۴	
-۳۹/۲۳	۱	۰/۸۷۵	۱	۱۵	
۰/۰۶	۰/۵	۱	۰	۱۶	
۰/۳	۰/۵	۱	۱	۱۷	
-۱۸/۳۴	۰/۷۵	۰	۰/۵	۱۸	
۳۷/۳۲	۱	۰/۱۲۵	۱	۱۹	
۸۴/۴۳	۰/۵	۰/۸۷۵	۰/۵	۲۰	
-۱/۴۱	۰/۲۵	۰/۶۲۵	۱	۲۱	
-۱/۳	۰/۲۵	۰/۶۲۵	۰	۲۲	
۶۹/۴۳	۰	۰/۱۲۵	۰/۵	۲۳	
-۱۴۷/۶۷	۱	۰/۶۲۵	۰	۲۴	
-۱۵/۲۳	۱	۰/۳۷۵	۰/۵	۲۵	

جدول ۵. مقایسه دقت دو شبکه پرسپترون و پایه شعایی.

Table 5. Comparison of the accuracy of MLP and RBF networks.

MSE	MRE (%)	دسته‌بندی	تعداد داده‌ها	دسته‌بندی	مدل
۰/۳۱۹	۰/۱۹۶	آموزش	۹۵	آموزش	پرسپترون
۱/۰۸۵	۰/۳۳۴	اعتبارسنجی	۴۰	اعتبارسنجی	
۰/۵۴۶	۰/۲۳۷	کل	۱۳۵	کل	
۰/۷۷۶	۰/۲۹۰	آموزش	۹۵	آموزش	پایه شعایی
۱/۰۹۴	۰/۳۶۱	اعتبارسنجی	۴۰	اعتبارسنجی	
۰/۸۷۲	۰/۳۱۱	کل	۱۳۵	کل	

شبکه عصبی آموزش داده‌شده برای مجموعه داده‌های آموزش و اعتبارسنجی گزارش شده‌است. داده‌های اعتبارسنجی در فرایند آموزش شرکت نداشته‌اند و مقادیر پایین خطا برای این مجموعه، صحت مدل‌ها را تایید می‌کند. در مجموع دقت پیش‌بینی هر دو مدل بسیار بالاست ولی شبکه پرسپترون کمی دقت بالاتری را ارائه کرده‌است. در شکل‌های ۷ و ۸، مقادیر عدد ناسلت حاصل از دینامیک سیالات محاسباتی و پیش‌بینی شده توسط شبکه عصبی پرسپترون برای داده‌های آموزشی و اعتبارسنجی مقایسه شده‌اند. نزدیکی پراکندگی نقاط به خط نیم‌ساز نشان‌دهنده دقت بالای مدل است.

۵- نتیجه‌گیری

در این تحقیق، دو مدل شبکه عصبی پرسپترون و پایه شعایی برای مدل‌سازی انتقال حرارت در کانال‌های ماریچ مستطیلی استفاده شد. در این مدل‌ها، متغیرهای ورودی شامل عدد رینولدز و پارامترهای هندسی کانال بودند و متغیر خروجی عدد ناسلت را نشان می‌داد. از روش شبیه‌سازی دینامیک سیالات محاسباتی برای بدست آوردن داده‌های مورد نیاز استفاده شد. ۱۳۵ داده شبیه‌سازی به دو بخش آموزش (۹۵ داده) و ارزیابی (۴۰ داده) تقسیم شدند. مدل پرسپترون یک شبکه عصبی چند لایه است که توسط تابع فعال‌ساز سیگموئید بهینه‌سازی می‌شود. این مدل قادر است الگوهای پیچیده را تشخیص داده و به خروجی دقت بالایی بدهد. معماری پایه شعایی شامل

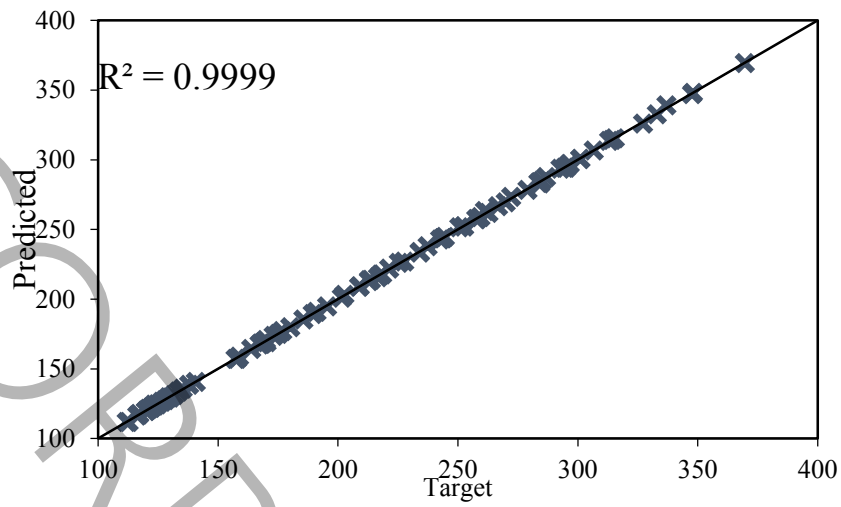
$$h_j = \exp\left(-\frac{(z_j - c_j)^2}{2\sigma^2}\right) \quad (6)$$

$$z_j = \sum_{i=1}^m W_{ji} X_i + b_j \quad (7)$$

$$c_j = \frac{\sum_{i=1}^m W_{ji} X_i}{\sum_{i=1}^m W_{ji}} \quad (8)$$

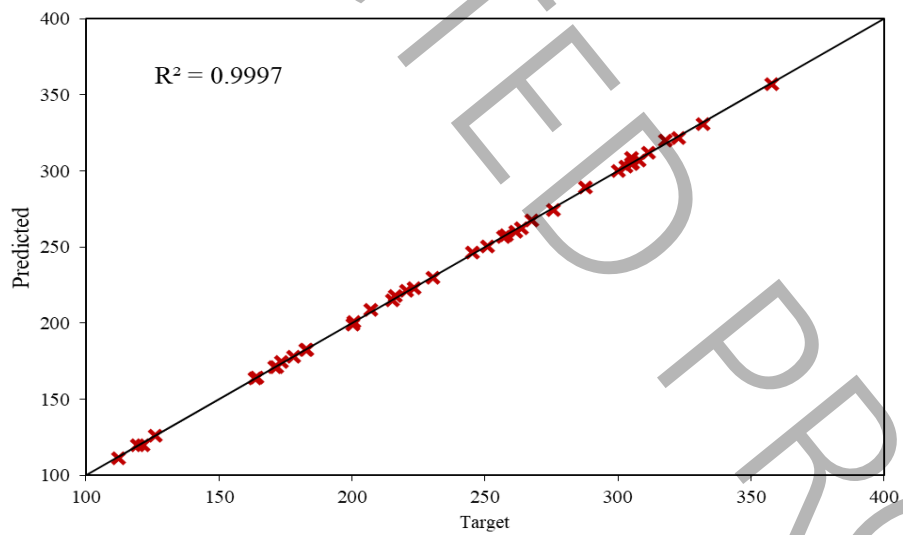
در این روابط Y خروجی نهایی، h_j خروجی هر نورون پنهان، Z_j ورودی هر نورون پنهان، c_j مرکز تابع گاوسی برای هر نورون و σ عدد گسترش می‌باشد که در این مطالعه مقدار یک در نظر گرفته شده‌است.

برازش بیش از حد مدل شبکه عصبی زمانی رخ می‌دهد که مدل پیچیدگی زیادی داشته باشد (تعداد زیاد نورون‌ها) یا تعداد داده‌های آموزشی کمی در فرایند آموزش شرکت داشته داده شوند. در این شرایط، شبکه عصبی تنها قادر به تخمین داده‌های آموزشی بوده و خطای داده‌های اعتبارسنجی به شدت افزایش می‌یابد. در همین راستا در جدول ۵ مقادیر خطا برای دو



شکل ۷. دقت پیش‌بینی شبکه پرسپترون برای داده‌های آموزشی.

Fig. 7. Prediction accuracy of MLP network for training data.



شکل ۸. دقت پیش‌بینی شبکه پرسپترون برای داده‌های اعتبارسنجی.

Fig. 8. Prediction accuracy of MLP network for validation data.

منابع

- [1] V. Irabatti, Y. Patil, S. Kore, V. Barangule, A. Kothe, Comprehensive review of spiral heat exchanger for diverse applications, *Materials Today: Proceedings*, 72 (2023) 1328-1334.
- [2] S. Soltanian, R. Beigzadeh, Computational fluid dynamics and fuzzy logic for modeling conical spiral heat exchangers, *Chemical Engineering & Technology*, 46(4) (2023) 747-755.
- [3] R. Beigzadeh, S. Eiamsa-ard, Fuzzy logic to thermal and friction characteristics of turbulent air-flow over diamond-shaped turbulators, *International Communications in Heat and Mass Transfer*, 120 (2021) 105001.
- [4] M. Rastegarmoghaddam, M. Rajabi, S.D. Nikkhoy Tanha, Use of Artificial Intelligence to Identify Adhesive Joints Defects by Using Ultrasonic, *Amirkabir Journal of Mechanical Engineering*, 54(2) (2022) 377-390.
- [5] M. Sridharan, Applications of artificial intelligence techniques in heat exchanger systems, in: *Advanced Analytic and Control Techniques for Thermal Systems with Heat Exchangers*, Elsevier, 2020, pp. 325-334.
- [6] M. Mohanraj, S. Jayaraj, C. Muraleedharan, Applications of artificial neural networks for thermal analysis of heat exchangers—a review, *International Journal of Thermal Sciences*, 90 (2015) 150-172.
- [7] E. Reynoso-Jardón, A. Tlatelpa-Becerro, R. Rico-Martínez, M. Calderón-Ramírez, G. Urquiza, Artificial neural networks (ANN) to predict overall heat transfer coefficient and pressure drop on a simulated heat exchanger, *International Journal of Applied Engineering Research*, 14(13) (2019) 3097-3103.
- [8] J. Shieh, H. Chen, L. Ferng, Application of a fuzzy logic controller in temperature control of a pilot high-temperature short-time heat exchanger, *Food Control*, 3(2) (1992) 91-96.
- [9] C. Yu, Y. Wang, H. Zhang, B. Gao, Y. He, Thermal-

لایه پنهان با تابع فعال ساز گاوسین است. در این معماری، هر گروه بندی با یک مرکز و شعاع مشخص می شود.

با توجه به نتایج، هر دو مدل پرسپترون و پایه شعایی قابل استفاده در مدل سازی انتقال حرارت در کانال های مارپیچ مستطیلی هستند. با این حال، پرسپترون دقت کمی بالاتر را نشان داد. این نتایج ممکن است به علت قابلیت پرسپترون در تشخیص الگوهای پیچیده و تعاملات غیرخطی بین عوامل مختلف باشد. به طور کلی، استفاده از شبکه های عصبی برای مدل سازی انتقال حرارت در کانال های مارپیچ مستطیلی به دقت بالا و قابل قبول منجر شده است. این روش ها قادر به تحمل تغییرات پارامترهای ورودی و خروجی هستند و به صورت خودکار الگوبرداری را انجام می دهند.

۶- فهرست علائم

بیاس	b
مرکز تابع گاوسی	c_j
تابع انتقال تانزانت هایپربولیک سیگموئید	F_t
خروجی هر نورون پنهان	h_j
هدایت حرارتی مؤثر	k_{eff}
طول مستقیم	L_s
تعداد ورودی شبکه	m
تعداد نرون های لایه پنهان	n
عدد ناسلت	Nu
فشار	p
عدد رینولدز	Re
حروف یونانی	
سرعت	u
وزن	W
خروجی شبکه عصبی	X
زاویه خم	α
ویسکوزیته	μ
چگالی	ρ
عدد گسترش	σ

- [13] Y. Ji, Z. Yang, J. Ran, H. Li, Multi-objective parameter optimization of turbine impeller based on RBF neural network and NSGA-II genetic algorithm, *Energy Reports*, 7 (2021) 584-593.
- [14] B. Wu, Dynamic performance simulation analysis method of split shaft gas turbine based on RBF neural network, *Energy Reports*, 7 (2021) 947-958.
- [15] D. Taler, J. Taler, Simple heat transfer correlations for turbulent tube flow, in: *E3S Web of conferences*, EDP Sciences, 2017, pp. 02008.
- [16] A.H. Fath, F. Madanifar, M. Abbasi, Implementation of multilayer perceptron (MLP) and radial basis function (RBF) neural networks to predict solution gas-oil ratio of crude oil systems, *Petroleum*, 6(1) (2020) 80-91.
- hydraulic performance prediction of two new heat exchangers using RBF based on different DOE, *Open Physics*, 19(1) (2021) 285-304.
- [10] P. Ramkumar, C. Vivek, S. Ramasamy, A. Kajavali, M. Sivasubramanian, Experimental and numerical study using ANFIS-neuro fuzzy model on heat pipe heat exchanger, *Materials Today: Proceedings*, 62 (2022) 2152-2162.
- [11] B. Shilpa, V. Leela, An artificial intelligence model for heat and mass transfer in an inclined cylindrical annulus with heat generation/absorption and chemical reaction, *International Communications in Heat and Mass Transfer*, 147 (2023) 106956.
- [12] H. Jin, M. Wang, H. Xiang, X. Liu, C. Wang, D. Fu, A PSO-RBF prediction method on flow corrosion of heat exchanger using the industrial operations data, *Process Safety and Environmental Protection*, 183 (2024) 11-23.

چگونه به این مقاله ارجاع دهیم

Reza Beigzadeh, *Comparison of Perceptron and Radial Basis Function Neural Networks in Modeling Heat Exchangers with Rectangular Helical Channels*, *Amirkabir J. Mech Eng.*, 56(5) (2024) 699-716.

DOI: [10.22060/mej.2024.22833.7684](https://doi.org/10.22060/mej.2024.22833.7684)



UNCORRECTED PROOF