

DOI:10.16356/j.1005-2615.2021.06.019

## 基于人工神经网络的微重力流动冷凝换热预测

陈亚琴<sup>1</sup>, 彭浩<sup>1</sup>, 冯诗愚<sup>2</sup>

(1. 上海海事大学航运仿真技术教育部工程研究中心, 上海 201306; 2. 南京航空航天大学航空学院飞行器环境控制与生命保障工业和信息化部重点实验室, 南京 210016)

**摘要:** 微重力条件下管内流动冷凝换热系数是空间热交换器设计的基础依据, 但其实验数据稀缺, 故有必要建立精确的预测模型。文中提出了一种基于人工神经网络的微重力下管内流动冷凝换热预测模型。选取误差反向传播(Back propagation, BP)和径向基函数(Radial basis function RBF)两种神经网络, 以水力直径、饱和温度、质流密度、干度及与工质热物性有关的参数作为网络输入, 冷凝换热系数作为网络输出。结果显示, BP神经网络预测的均方根误差为 237、平均绝对百分误差为 4.32%; RBF神经网络预测的均方根误差为 165、平均绝对百分误差为 2.35%。相对于BP神经网络, RBF神经网络精度更高。基于RBF神经网络的微重力下管内流动冷凝换热模型预测值与 94% 的实验值和数值模拟结果的相对误差在±10%以内。

**关键词:** 微重力; 流动冷凝; 换热系数; 反向传播神经网络; 径向基函数神经网络

中图分类号: TK124 文献标志码: A 文章编号: 1005-2615(2021)06-0989-07

## Prediction of Flow Condensation Heat Transfer Under Microgravity Based on Artificial Neural Network

CHEN Yaqin<sup>1</sup>, PENG Hao<sup>1</sup>, FENG Shiyu<sup>2</sup>

(1. Engineering Research Center of Shipping Simulation (Ministry of Education), Shanghai Maritime University, Shanghai 201306, China; 2. Key Laboratory of Aircraft Environmental Control and Life Support Industry and Information Technology, College of Aerospace Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China)

**Abstract:** Heat transfer coefficients of flow condensation under microgravity are the basis for design of aerospace heat exchanger, but their experimental data are scarce; thus it is necessary to establish an accurate prediction model. In the present study, a prediction model of flow condensation heat transfer under microgravity is established based on artificial neural network. Two kinds of neural networks, i. e. back propagation (BP) and radial basis function (RBF) are adopted; the hydraulic diameter, saturation temperature, mass flux, vapor quality and parameter related to fluid thermophysical properties are used as network inputs, while the condensation heat transfer coefficient is taken as network output. The results show that for BP neural network model, the root mean square error (RMSE) and mean absolute percent error (MAPE) are 237 and 4.32%, respectively; while for RBF neural network model, RMSE and MAPE are 165 and 2.35%, respectively. Compared with BP neural network, RBF neural network has the higher accuracy. The flow condensation heat transfer coefficients predicted by RBF neural network model agree with 94% of experimental data and numerical results within the deviation of ±10%.

**基金项目:** 上海市自然科学基金(19ZR1422300)资助项目。

**收稿日期:** 2021-02-12; **修订日期:** 2021-05-10

**通信作者:** 彭浩, 男, 副教授, E-mail: hpeng@shmtu.edu.cn。

**引用格式:** 陈亚琴, 彭浩, 冯诗愚. 基于人工神经网络的微重力流动冷凝换热预测[J]. 南京航空航天大学学报, 2021, 53(6): 989-995. CHEN Yaqin, PENG Hao, FENG Shiyu. Prediction of flow condensation heat transfer under microgravity based on artificial neural network[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2021, 53(6): 989-995.



### 1.2 BP神经网络模型建立

BP神经网络模型采用具有单层、双层隐含层的两种网络结构。具有双层隐含层的BP神经网络结构为5-X-Y-1,如图1所示,其中输入参数为5个,第一和第二隐含层的神经元个数分别为X和Y,输出参数为1个。具有单层隐含层的神经网络结构相较于双层隐含层少了1个隐含层,即结构为5-X-1。选取双层隐含层X-Y为1-1至20-20、单层隐含层X为1-20进行反复训练学习以确定神经元的个数。单层隐含层的传递函数采用logsig函数




图1 预测流动冷凝换热系数的BP神经网络模型结构

Fig.1 Structure of BP neural network model for predicting flow condensation heat transfer coefficient

$$\varphi(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

双层隐含层的两层传递函数分别采用logsig函数和tansig函数

$$\varphi(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

输出层的函数采用purelin函数

$$\varphi(x) = x \quad (3)$$

具体的神经网络基本参数如表2所示。模型输出参数为流动冷凝换热系数,输入参数包括水力直径 $D_h$ 、饱和温度 $T_{sat}$ 、质流密度 $G$ 、干度 $x$ 以及与工质热物性有关的参数 $\phi$

$$\phi = \left( \frac{C_{pf}}{\mu_l} \right)^{0.4} k_l^{0.6} \quad (4)$$

式中: $C_{pf}$ 为液相定压比热容; $\mu_l$ 为动力黏度; $k_l$ 为导热系数。

随机选取80%的数据,即226组数据作为训练样本;剩余20%的数据,即57组数据作为测试样本。

表2 BP神经网络模型的基本参数

Table 2 Basic parameters of BP neural network model

序号	参数	参数值
1	单层隐藏层	1, 2, 3, ..., 18, 19, 20
2	单层隐含层的传递函数类型	logsig
3	双层隐藏层	[1, 1], [22], ..., [19, 19], [20, 20]
4	双层隐含层的传递函数类型	[logsig tansig]
5	输出层神经元激发函数	purelin
6	训练函数类型	trainlm
7	学习函数类型	learngdm
8	最大迭代次数	1 000
9	网络学习率	0.01
10	动量系数	0.95
11	网络训练目标误差	0.001

### 1.3 RBF神经网络模型建立

RBF神经网络模型的结构如图2所示,由5个输入参数、1个输出参数和1个隐含层组成,其输入和输出参数与BP神经网络模型相同。RBF神经网络的性能受扩展常数的影响,故本文选择不同的扩展常数,即1、1.1、1.2、1.3、1.4、1.5、1.6、1.7、1.8、1.9、2、3、4、5、6进行试验,以选出最合适的预测微重力下管内流动冷凝换热的RBF神经网络结构。RBF神经网络的目标训练误差设定为0.001。随机选取80%的数据,即226组数据作为训练样本;剩余20%的数据,即57组数据作为测试样本。

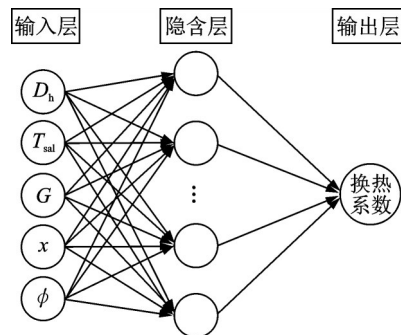


图2 预测流动冷凝换热系数的RBF神经网络模型结构

Fig.2 Structure of RBF neural network model for predicting flow condensation heat transfer coefficient

### 1.4 神经网络模型精度评价

神经网络模型的精度通过均方根误差(Root mean square error, RMSE)、平均绝对百分误差(Mean absolute percent error, MAPE)和决定系数(Coefficient of determination,  $R^2$ )等进行评价<sup>[14-15]</sup>,定义如下

$$RMSE = \sqrt{\frac{1}{N} \sum (Y_{Act,m} - Y_{Pred,m})^2} \quad (5)$$

$$MAPE = \frac{1}{N} \sum \frac{Y_{Act,m} - Y_{Pred,m}}{Y_{Act,m}} \quad (6)$$

$$R^2 = 1 - \frac{\sum (Y_{Act,m} - Y_{Pred,m})^2}{\sum (Y_{Act,m} - \bar{Y}_{Pred,m})^2} \quad (7)$$

式中： $Y_{Pred,m}$ 为人工神经网络模型预测值； $Y_{Act,m}$ 为真实值； $\bar{Y}_{Pred,m}$ 为预测值的平均值； $N$ 为数据点的数量。

## 2 结果与讨论

### 2.1 神经网络模型评估

图3(a~c)分别给出了BP神经网络模型的RMSE、MAPE和 $R^2$ 随隐含层神经元个数的变化。

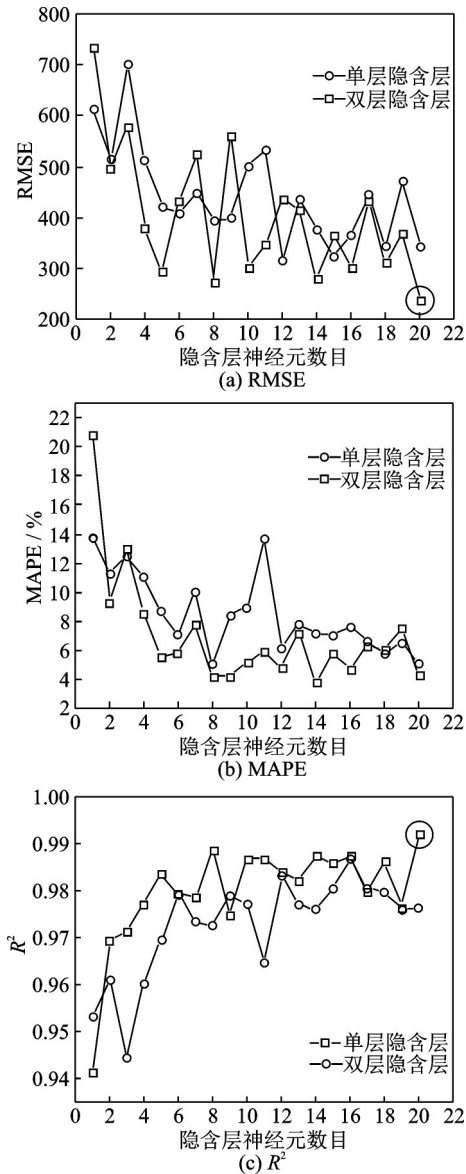


图3 隐含层神经元个数对BP神经网络模型精度的影响  
Fig.3 Influence of neuron number in hidden layer on accuracy of BP neural network model

可见,具有双层隐含层且神经元个数为[20 20]的BP神经网络模型精度最高,其RMSE为237,MAPE为4.32%, $R^2$ 为0.992 2。

表3给出了RBF神经网络模型的RMSE、MAPE和 $R^2$ 随扩展常数的变化。可见,扩展常数为1.5时RBF神经网络模型精度最高,其RMSE为165,MAPE为2.35%, $R^2$ 为0.995 3。

表3 扩展常数对RBF神经网络模型精度的影响

Table 3 Influence of distribution coefficient on accuracy of RBF neural network model

扩展常数	RMSE	MAPE	$R^2$
1.0	499	3.15	0.977 0
1.1	487	6.76	0.972 7
1.2	349	4.26	0.991 7
1.3	178	3.57	0.996 0
1.4	191	2.49	0.994 9
1.5	165	2.35	0.995 3
1.6	331	4.19	0.991 0
1.7	270	6.49	0.989 6
1.8	221	3.79	0.992 7
1.9	203	2.69	0.997 0
2.0	213	2.77	0.994 0
3.0	296	3.32	0.993 2
4.0	342	3.92	0.990 4
5.0	209	2.90	0.992 6
6.0	245	2.90	0.993 0

将选取的具有双层隐含层且神经元个数为[20 20]的BP神经网络模型和扩展常数为1.5时RBF神经网络模型进行比较,可见RBF神经网络模型精度更高,并且训练过程中发现RBF网络的训练速度较快,因此本文将重点讨论RBF神经网络模型的预测结果。

### 2.2 神经网络模型预测结果与原始值比较

图4给出了微重力条件下制冷剂R134a管内流动冷凝换热系数的RBF神经网络模型预测结果与原始值的比较。原始值来源于文献[7,11]的数值模拟结果,工况包括:饱和温度 $T_{sat}$ 为40℃,水力直径 $D_h$ 为1和0.577 mm,质流密度 $G$ 为50、100和800  $kg \cdot m^{-2} \cdot s^{-1}$ 。从图4中可以看出,RBF神经网络模型预测的不同水力直径条件下冷凝换热系数随干度、质流密度的变化规律与原始值相同,即换热系数随着干度或质流密度的增加而增大。90%的模型预测结果与原始值的相对误差在±5%以内。

图5给出了微重力条件下制冷剂R1234ze(E)




图 4 微重力下 R134a 流动冷凝换热系数的 RBF 神经网络模型预测结果与原始值的比较

Fig.4 Comparison of flow condensation heat transfer coefficient for R134a under microgravity between RBF neural network model predictions and raw data

管内流动冷凝换热系数的 RBF 神经网络模型预测结果与原始值的比较。原始值来源于 Wen 等<sup>[9]</sup>和 Gu 等<sup>[10,12]</sup>的数值模拟结果,工况包括:饱和温度  $T_{sat}$  为 40 °C,水力直径  $D_h$  为 1、2 和 4.57 mm,质流密度  $G$  为 300、400 和 600  $\text{kg}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$ 。从图 5 中可以看出,RBF 神经网络模型预测的不同水力直径条件下冷凝换热系数随干度、质流密度的变化规律与原始值相同,即换热系数随着干度或质流密度的增加而增大。99% 的模型预测结果与原始值的相对误差在  $\pm 5\%$  以内。

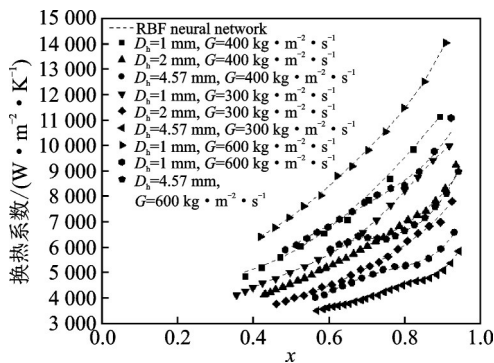


图 5 微重力下 R1234ze(E)流动冷凝换热系数的 RBF 神经网络模型预测结果与原始值的比较

Fig.5 Comparison of flow condensation heat transfer coefficient for R1234ze(E) under microgravity between RBF neural network model predictions and raw data

图 6 给出了微重力条件下制冷剂 HFE-7000 管内流动冷凝换热系数的 RBF 神经网络模型预测结果与原始值的比较。原始值来源于 Azzolin 等<sup>[8]</sup>的实验值,工况包括:饱和温度  $T_{sat}$  为 45 °C,水力直径  $D_h$  为 3.4 mm,质流密度  $G$  为 70、100 和 130

$\text{kg}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$ 。从图 6 中可以看出,RBF 神经网络模型预测的冷凝换热系数随干度、质流密度的变化规律与原始值相同,即换热系数随着干度或质流密度的增加而增大。90% 的模型预测结果与原始值的相对误差在  $\pm 5\%$  以内。

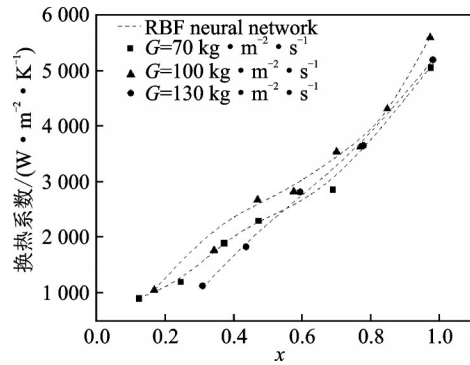


图 6 微重力下 HFE-7000 流动冷凝换热系数的 RBF 神经网络模型预测结果与原始值的比较

Fig.6 Comparison of flow condensation heat transfer coefficient for HFE-7000 under microgravity between RBF neural network model predictions and raw data

图 7 给出了微重力条件下制冷剂 FC-72 管内流动冷凝换热系数的 RBF 神经网络模型预测结果与原始值的比较。原始值来源于 Lee 等<sup>[13]</sup>的实验值,工况包括:饱和温度  $T_{sat}$  为 62 °C,水力直径  $D_h$  为 7.12 mm,质流密度  $G$  为 129~333  $\text{kg}\cdot\text{m}^{-2}\cdot\text{s}^{-1}$ 。从图 7 中可以看出,RBF 神经网络模型预测的冷凝换热系数随干度、质流密度的变化规律与原始值相同,即换热系数随着干度或质流密度的增加而增大。由图中的误差距离可以看出,RBF 神经网络模型的预测结果与实验值的误差较小,95% 的

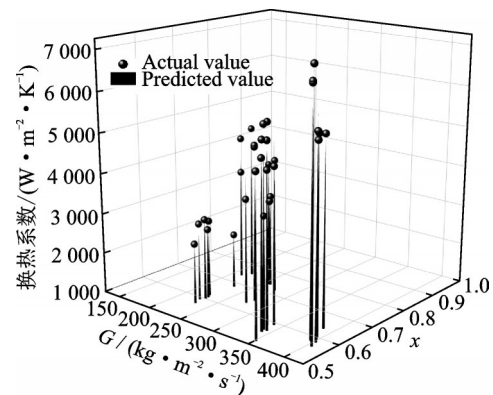


图 7 微重力下 FC-72 流动冷凝换热系数的 RBF 神经网络模型预测结果与原始值的比较

Fig.7 Comparison of flow condensation heat transfer coefficient for FC-72 under microgravity between RBF neural network model predictions and raw data

模型预测结果与原始值的相对误差在 $\pm 20\%$ 以内。

综合上述各工况,RBF神经网络模型预测结果与94%的实验值或数值模拟结果的相对误差在 $\pm 10\%$ 以内。

### 2.3 神经网络模型与关联式预测精度比较

目前尚没有专门针对微重力下管内流动冷凝换热系数的计算关联式,将4种常用的管内流动冷凝换热系数计算关联式,即Dobson-Chato关联

式<sup>[14]</sup>、Wang关联式<sup>[16]</sup>、Koyama关联式<sup>[17]</sup>和Kim-Mudawar关联式<sup>[18]</sup>拓展用于预测微重力下管内流动冷凝换热系数,并与本文建立的RBF神经网络模型进行预测精度比较,结果如表4所示。可以看出:Dobson-Chato关联式的预测精度在4个关联式中最高,RMSE为1 815,MAPE为23.4%, $R^2$ 值为0.583 5;而RBF神经网络模型的RMSE为165,MAPE为2.35%, $R^2$ 为0.995 3,其预测精度远高于传统关联式。

表4 RBF神经网络模型与传统关联式预测精度的比较

Table 4 Comparison of prediction accuracy between RBF neural network model and correlations

参数	Dobson-Chato 关联式 <sup>[14]</sup>	Wang 关联式 <sup>[16]</sup>	Koyama 关联式 <sup>[17]</sup>	Kim-Mudawar 关联式 <sup>[18]</sup>	RBF神经网络 模型
RMSE	1 815	2 857	3 316	2 021	165
MAPE/%	23.40	32.87	50.85	33.64	2.35
$R^2$	0.583 5	0.034 2	0.393 2	0.482 2	0.995 3

## 3 结 论

(1)建立的微重力条件下管内流动冷凝换热的BP神经网络预测模型RMSE、MAPE和 $R^2$ 分别为237、4.32%和0.992 2,RBF神经网络模型的RMSE、MAPE和 $R^2$ 分别为165、2.35%和0.995 3。相对于BP神经网络模型,RBF神经网络模型精度更高。

(2)RBF神经网络模型预测结果随输入参数的变化规律与实验值或数值模拟结果吻合良好。预测结果与94%的实验值或数值模拟结果的相对误差在 $\pm 10\%$ 以内,且预测精度远高于传统关联式。

### 参考文献:

- [1] 赵建福,彭浩.不同重力条件下管内冷凝现象研究进展[J].力学进展,2011,41(6):702-710.  
ZHAO Jianfu, PENG Hao. Review on in-tube condensation in different gravity conditions[J]. Advances in Mechanics, 2011, 41(6): 702-710.
- [2] HOSSEINI S H, MORADKHANI M A, VALIZADEH M, et al. A general heat transfer correlation for flow condensation in single port mini and macro channels using genetic programming[J]. International Journal of Refrigeration, 2020, 119: 376-389.
- [3] AZIZI S, AHMADLOO E. Prediction of heat transfer coefficient during condensation of R134a in inclined tubes using artificial neural network[J]. Applied Thermal Engineering, 2016, 106: 203-210.
- [4] KIM S M, MUDAWAR I. Universal approach to predicting saturated flow boiling heat transfer in mini/micro-channels—Part II. Two-phase heat transfer coefficient[J]. Heat Mass Transfer, 2013, 64: 1239-1256.
- [5] QIU Y, GARG D, ZHOU L W, et al. An artificial neural network model to predict mini/micro-channels saturated flow boiling heat transfer coefficient based on universal consolidated data[J]. International Journal of Heat and Mass Transfer, 2020, 149: 119211.
- [6] 文旭林,王辉涛,王华,等.基于RBF神经网络的水平光管内R407C流动沸腾换热预测[J].昆明理工大学学报(自然科学版),2012,37(4):57-62.  
WEN Xulin, WANG Huitao, WANG Hua, et al. Prediction of flow boiling heat transfer of R407C inside horizontal smooth tubes based on RBF neural network[J]. Journal of Kunming University of Science and Technology (Natural Science Edition), 2012, 37(4): 57-62.
- [7] ENRICO D R, DAVIDE D C. Effect of gravity during condensation of R134a in a circular minichannel[J]. Microgravity Science Technology, 2011, 23 (S1): S87-S97.
- [8] AZZOLIN M, BORTOLIN S, LAVIEILLE P, et al. Experimental investigation of in-tube condensation in microgravity[J]. International Communications in Heat and Mass Transfer, 2018, 96: 69-79.
- [9] WEN Jian, GU Xin, LIU Yuce, et al. Effect of surface tension, gravity and turbulence on condensation patterns of R1234ze (E) in horizontal mini/macro-

- channels[J]. *International Journal of Heat and Mass Transfer*, 2018, 125: 153-170.
- [10] GU Xin, WEN Jian, TIAN Jin, et al. Numerical study on condensation annular flow of R1234ze(E) inside an inclined tube[J]. *Applied Thermal Engineering*, 2019, 163: 114359.
- [11] LEI Yuchuan, CHEN Zhenqian, SHI Juan. Analysis of condensation heat transfer performance in curved triangle microchannels based on the volume of fluid method[J]. *Microgravity Science and Technology*, 2017, 29: 433-443.
- [12] GU Xin, WEN Jian, TIAN Jin, et al. Role of gravity in condensation flow of R1234ze(E) inside horizontal mini/macro-channels[J]. *Experimental and Computational Multiphase Flow*, 2019, 1(3): 219-229.
- [13] LEE H, MUDAWAR I, HASAN M M. Experimental and theoretical investigation of annular flow condensation in microgravity[J]. *International Journal of Heat and Mass Transfer*, 2013, 61: 293-309.
- [14] DOBSON M K, CHATO J C. Condensation in smooth horizontal tubes[J]. *Heat Transfer*, 1998, 120: 193-213.
- [15] 霍冠良,宁志华. 基于BP神经网络的含褶皱复合材料强度预测[J]. *南京航空航天大学学报*, 2020, 52(3): 460-467.
- HUO Guanliang, NING Zhihua. Strength prediction of laminates containing embedded fiber wrinkles using bp neural networks[J]. *Journal of Nanjing University of Aeronautics & Astronautics*, 2020, 52(3): 460-467.
- [16] WANG W W, RADCLIFF T D, CHRISTENSEN R N. A condensation heat transfer correlation for millimeter-scale tubing with flow regime transition[J]. *Experimental Thermal and Fluid Science*, 2002, 26: 473-485.
- [17] KOYAMA S, KUWAHARA K, NAKASHITA K, et al. An experimental study on condensation of refrigerant R134a in a multi-port extruded tube[J]. *Refrigeration*, 2003, 24: 425-432.
- [18] KIM S M, MUDAWAR I. Universal approach to predicting heat transfer coefficient for condensing mini/micro-channel flow[J]. *Heat Mass Transfer*, 2013, 56(1): 238-250.

(编辑:孙静)