基于可解释性神经网络的界面面积浓度预测

周钰浩[1,3] 许汪涛[1,3] 刘 丽[1,3] 朱隆祥[1,2,3] 张卢腾[1,3] 潘良明[1,3]

1（重庆大学 低品位能源利用技术及系统教育部重点实验室 重庆 400044）

2（重庆大学 动力工程及工程热物理博士后科研流动站 重庆 400044）

3（重庆大学 核工程与核技术系 重庆 400044）

摘要 界面面积浓度（Interfacial Area Concentration，IAC）是两相流动的封闭两流体模型中界面传递项的关键参数，用于表征气液界面传输能力的强弱。对界面面积浓度的建模预测通常有经验关联式和界面面积输运方程等方法，但这些方法都有较大的数据依赖性。而对神经网络模型增添可解释性可以为模型修正提供方向，严谨提升预测精度。为更好地预测两相流动的IAC，基于神经网络建立了IAC的预测模型，结合不同气泡行为、物理关系及统计分布并利用事后可解释性方法，对比分析了不同输入特征组合的神经网络模型预测能力；并通过神经网络每层的结构参数大小，分析输出比重挑选合适的数据预处理方法。通过事后可解释性分析得到空泡份额是IAC预测的重要因素，而对训练数据进行对数变换预处理能够显著提高模型对真实数据的预测能力。

关键词 界面面积浓度，两相流，神经网络模型，事后可解释性

中图分类号 TL334

DOI: 10.11889/j.0253-3219.2024.hjs.47.080502

Prediction of interfacial area concentration based on interpretable neural network

ZHOU Yuhao[1,3] XU Wangtao[1,3] LIU Li[1,3] ZHU Longxiang[1,2,3] ZHANG Luteng[1,3] PAN Liangming[1,3]

1(*Key Laboratory of Low-grade Energy Utilization Technologies and Systems*, *Ministry of Education*, *Chongqing University*, *Chongqing 400044*, *China*)

2(*Postdoctoral Station of Power Engineering and Engineering Thermophysics at Chongqing University*, *Chongqing 400044*, *China*)

3(*Department of Nuclear Engineering and Technology*, *Chongqing University*, *Chongqing 400044*, *China*)

Abstract **[Background]** Interfacial area concentration (IAC) is a key parameter of the interface transfer term in the closed two-fluid model of two-phase flow, which characterizes the strength of the gas-liquid interface transport capacity. There are usually some methods for modeling and predicting the interface area concentration, such as empirical correlation formula and interface area transport equation, but these methods have large data dependence. **[Purpose]** This study aims to provide direction for model revision and improve the prediction accuracy of IAC by adding interpretability to the neural network model. **[Methods]** The prediction model of IAC based on a neural network was firstly established for better prediction of IAC with two-phase flow. Then, different bubble behavior, physical relationships, and statistical distribution were combined, and the predictive ability of the neural network

国家自然科学基金(No.12205031)、中国博士后科学基金(No.2022M720564)、低品位能源利用技术及系统教育部重点实验室基金(No.LLEUTS-2024002)资助

第一作者：周钰浩，男，2000年出生，2022年毕业于重庆大学，现为硕士研究生，能源动力专业

通信作者：朱隆祥，E-mail：lxzhu@cqu.edu.cn

收稿日期：2024-03-15，修回日期：2024-04-08

Supported by National Natural Science Foundation of China (No.12205031), China Postdoctoral Science Foundation (No.2022M720564), Low grade Energy Utilization Technology and System Key Laboratory Fund of the Ministry of Education (No.LLEUTS-2024002)

First author: ZHOU Yuhao, male, born in 2000, graduated from Chongqing University in 2022, master student, major in engery and power

Corresponding author: ZHU Longxiang, E-mail: lxzhu@cqu.edu.cn

Received date: 2024-03-15, revised date: 2024-04-08

model with different input feature combinations was compared and analyzed by the post-interpretability method. Finally, based on the structure parameter size of each layer of the neural network, the appropriate data preprocessing method was selected by analyzing the output proportion. **[Results]** The post explanatory analysis show that the maximum prediction accuracy of the neural network reaches 95.62% when the inputs of the neural network are the gas superficial velocity (j_g), liquid superficial velocity (j_f), and void fraction (α). The void fraction is an important factor in IAC prediction, and logarithmic transformation preprocessing of training data can significantly improve the model's predictive ability for real data. **[Conclusions]** The results of this study provide reference for future interpretability research on interface area concentration.

Key words Interfacial area concentration, Two-phase flow, Neural network model, Post interpretability

气液两相流动现象广泛存在于核电、化工、石油运输等领域，在反应堆系统程序中，通常使用两流体模型来描述两相流，对气相、液相分别建立质量、动量和能量守恒方程，并用界面传递项表征各物理量在气相、液相之间的传递[1]。Ishii等[2]指出，质量、动量和能量的界面传递项均可表示为：界面传递项=界面面积浓度（Interfacial Area Concentration，IAC）×驱动力[3]，IAC是两流体模型中决定界面质量、动量和能量传递量的关键因素。因此，为了更好地封闭界面传递项以构建两流体模型，有必要对IAC等进行预测研究。

两相流动的IAC特性受气泡核化、扩张、破碎、聚合、冷凝等各种气泡行为的影响，也与流型、相态分布、湍流强度等流动特性紧密相关。IAC的预测较为复杂，实验测量仍然是对其进行研究的主要手段，学者们通常是基于低参数下的IAC测量实验数据建立经验关系式、半经验关联式或界面面积输运方程。Sun[4]对直径为10.2 cm竖直圆管中界面面积浓度数据进行了测量，并用于评估一群气泡界面面积输运方程（Interfacial Area Transport Equation，IATE）模型。Worosz等[5]使用四传感器电导探针对5.08 cm竖直圆管中局部两相参数进行了测量，对IAC分布特性进行了分析。传统两相流研究方法仅根据几个有限的参数对两相流复杂问题进行拟合，具有预测精度低等缺点。如Vasavada等[6]对界面面积浓度模型进行评估，发现预测值与实验值之间的最大误差为22%。人工神经网络在拟合复杂问题如两相流方面具有优势，因此本研究采用神经网络对界面面积浓度预测进行研究。

近年来，人工神经网络（Artificial Neural Network，ANN）在解决各种工程问题的成功实例和发展，使人们开始关注其在两相流系统问题中的潜在应用。Huang等[7]使用ANN对圆管的临界热流密度（Critical Heat Flux，CHF）数据进行了分析，发现ANN方法相较于传统预测模型，具有更强的容错率与预测精度；Zhao等[8]通过设计神经网络耦合算法架构，提升了偏离核态沸腾（Departure from Nucleate Boiling，DNB）型CHF的预测准确率。虽然存在不同的神经网络结构，但双隐藏层反向传播神经网络模型已经成功用于预测两相流系统中的压降与CHF问题，如Nasseh等[9]等使用神经网络对5种不同文丘里洗涤器中的压降进行了预测，并得到了较好的结果。但是这些研究均未对神经网络进行解释，无法为物理预测模型提供修正方向。

因此，本文基于神经网络对竖直圆管内IAC进行预测，同时建立了IAC的预测模型，并在物理解释层面对比分析了不同输入特征组合的神经网络模型预测能力，通过可解释性的机器学习方法对两相流相界面演变机制进行了研究，有利于为研究复杂两相流问题提供新思路。

1 神经网络模型

1.1 神经网络

一般而言，神经网络只是基于生物学的神经元网络的基本原理而建立的一种信息处理模型，为了完成各种任务而设计的一种数学技术，神经网络可以以各种方式进行配置，以执行包括模式识别、数据挖掘、分类和过程建模在内的一系列任务。ANN是基于动物神经网络行为特征，由相互关联的简单单元（节点）组成的网络，能够开发对象或数据之间的关联、转换或映射。它只是一种模拟人类神经系统特定功能的计算机模型，模拟的是简单的生物学习过程（Bishop[9]，Fauset[10]），神经网络的基本要素是神经元及其连接权值。

ANN的优点是：即使输入和输出数据集之间的映射关系是未知的，但也被认为是存在的，网络可以被训练来学习这种关系，不需要像传统方法那样事先假设，这种映射关系被认为是最终的黑箱模型[11]。

神经网络的体系结构由输入层、隐藏层和输出层组成，第一层由若干个与输入数据或信息数量相等的神经元组成，最后一层表示期望输出。在输入

层和输出层之间，可以使用多个隐藏层，输入层的每个神经元与隐藏层的所有神经元相连，隐藏层的神经元与输出神经元相连。

神经网络主要分为两个传播方向过程：前向传播和反向传播。反向传播方法是一种以监督方式训练多层神经网络的技术，也称为误差反向传播算法，是基于误差修正学习规则（Principe等[12]），它要经过神经网络的两个传播方向，先前向传播后反向传播。在前向传播中，对网络的输入节点输入信号，然后通过神经网络逐层传播，最后产生一组输出作为网络的实际响应。

在神经网络中，给定一个表达神经元如何连接的网络拓扑结构，一个学习算法以及一些初始连接权重（通常是随机数）作为初始模型。在反向传播过程中，训练结果将导致连接权重的更新，因此，通过数值迭代会更新产生最终模型，而给定的一组输入数据可以使用训练好的模型产生预测输出。

通过增加模型的输入信息的规模，神经网络模型的预测精度可以得到显著提高，再进一步训练，神经网络学习到的特征会不断丰富最终导致预测模型的输出与原始数据本身相当。

1.2 神经网络模型结构

本研究使用的双隐藏层神经网络的简化示意图如图1所示。

首先，对训练集的训练数据进行归一化预处理。归一化方法泛指把数据特征转换为相同尺度的方法，比如把数据特征映射为服从均值为0、方差为1的标准正态分布。通过把数据归一化为相同尺度后，大部分位置的梯度方向会近似于最优搜索方向，这样在梯度下降求解时，每一步梯度的方向都基本指向最小值（导数为0的点），训练效率大大提高。同时在神经网络中添加神经网络中的偏置（bias），有利于更好地拟合数据。在本研究中，数据归一化方法采用Z-score化方法，如式（1）所示：

$$x^* = \frac{x - \bar{x}}{\sigma} \tag{1}$$

式中：$\bar{x}$与σ分别为训练数据的平均值和标准差。

其次，本文神经网络模型的预测对象是界面面积浓度（Interfacial Area Concentration，IAC），因此设置输出层为界面面积浓度a_i，而输入特征采用气相表观流速j_g、液相表观流速j_f和空泡份额α不同组合。对于弹状气泡，随着j_g的增加，气泡的数目、尺寸均会增加，会引起更强的尾流效应；而随着液相流速的增加，气泡尺寸减小、频率降低，同时也导致更多、更小的空泡份额波动峰值，导致更强的湍流强度、更多的漩涡[13]。这些气液相表观流速的变化都促进了气泡的破碎，导致了界面面积浓度的变化。最后神经网络的两个隐藏层均设置了32个神经元，步长为0.003，迭代次数为50 000次，损失采用MSELoss损失函数，前两层采用ReLU（Rectified Linear Unit）函数，最后一层不激活。

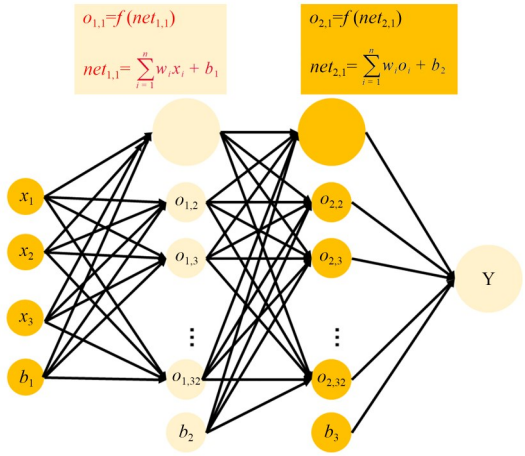

图1 双隐藏层神经网络图示

Fig.1 Diagram of double hidden layer neural network

为探究选取不同输入特征对IAC预测的影响，通过对不同IAC预测精度进行事后可解释性分析。在物理上，结合输入特征与输出特征之间的物理关系和输入特征的统计分布，得到影响IAC的主要影响参数；在数理统计上，通过逐步分析神经网络计算过程，计算每一层的输出比重，选择恰当的数据预处理方法。

2 结果分析

研究采用137个训练数据[5,14–21]来评估人工神经网络模型的预测能力，表1给出了调研训练数据的参数范围，并选取了5组不同输入特征组合进入神经网络模型进行训练。本研究认为误差在±20%之内的界面面积浓度数据预测准确。表2给出了不同神经网络模型的预测正确率，图2（a~e）给出了不同神经网络的预测结果，对模型预测数据与实验数据进行了比较。

2.1 空泡份额与j_g

将图2（a）与（b）进行对比，输入特征的数目均为2，图2（a）的输入特征为j_f与j_g，图2（b）输入特征为j_f与α，后者神经网络模型的预测能力明显优于后者。根据以下分析可得，空泡份额α是影响IAC变化的主要因素。

空泡份额对IAC变化的影响特性可以从两方面解释：首先，可从界面面积输运方程层面来解释，

表1 训练数据的参数范围
Table 1 The parameter range of training data

作者 Author	年份 Year	截面平均数据量 Data size	j_f / m·s^{-1}	j_g / m·s^{-1}	管道直径 Geometry / mm
Worosz *et al*.[5]	2015	9	2	0.18~0.29	50.8
Shen *et al*.[14]	2012	27	0.051~0.31	0.013~0.373	200
Dang[15]	2017	15	0.3~1.0	0.2~10	25.4
Schlegel *et al*.[16]	2012	16	0.39~1	0.19~3.06	152，203
Wang *et al*.[17]	2017	10	1.25~2.14	0.08~11	25.4
Wang *et al*.[18]	2020	24	0.5~2	0.092~5.04	25.4
Qiao *et al*.[19]	2017	12	4	0.108~0.284	50.8
Smith *et al*.[20]	2012	9	0.3	0.15~1	152
Smith *et al*.[21]	2012	15	0.05~1.03	0.052~8	102，152

表2 不同输入特征组合预测准确率
Table 2 Prediction accuracy of different input feature combinations

序号 Number	输入特征 Input features	预测正确率 Prediction accuracy / %
1	j_f、j_g	64.23
2	j_f、α	80.29
3	j_f/j_g、α	63.50
4	j_f、j_g、α	90.51
5	$\lg(j_f)$、$\lg(j_g)$、$\lg(\alpha)$	95.62

IAC定义为两相流流动中单位体积的界面面积，式(2)为一维界面面积输运方程的一般形式。Ishii等[22]指出，一群界面输运方程的源项和汇项主要包括三类气泡作用机理：湍流作用引起的气泡破裂、涡流引起的气泡随机碰撞合并、尾流引起的气泡合并。

$$\frac{\partial a_i}{\partial t}+\frac{\mathrm{d}}{\mathrm{d}z}(a_i v_i)=\frac{1}{3\psi}\left(\frac{\alpha}{a_i}\right)^2\{(\phi_B-\phi_C)+(\phi_{PN}-\phi_{PC})\}+\left(\frac{2a_i}{3\alpha}\right)\left\{\frac{\partial\alpha}{\partial t}+\frac{\mathrm{d}}{\mathrm{d}z}(\alpha v_i)\right\} \tag{2}$$

式中：ϕ_B、ϕ_C、ϕ_{PN}和ϕ_{PC}分别为气泡破裂、气泡合并、气泡成核与气泡冷凝导致的气泡数目密度变化率，

$$\begin{aligned}a_i&=\left[K_B\left\{1-\frac{K_C}{K_B}D_b^{2.5}\left(\frac{\sigma}{\rho_f}\right)^{-1.5}\varepsilon\right\}\right]^{-0.6}\times\left[6\alpha\left\{\ln\frac{\gamma_B(1-\alpha)}{\gamma_C\alpha}\right\}^{0.6}\right](\frac{\sigma}{\rho_f})^{-0.6}\varepsilon^{0.4}\\&\approx\varsigma\left[K_B\left\{1-\frac{K_C}{K_B}D_b^{2.5}\left(\frac{\sigma}{\rho_f}\right)^{-1.5}\varepsilon\right\}\right]^{-0.6}\times\left(\frac{\sigma}{\rho_f}\right)^{-0.6}\alpha^{\theta}\varepsilon^{0.4}\end{aligned} \tag{6}$$

则方程可进一步改写为[22]：

$$a_i\approx\varsigma'(\frac{\sigma}{\rho_f})^{-\eta}\alpha^{\theta'}\varepsilon^{X} \tag{7}$$

式中：ς'为系数；η、θ和X分别为σ/ρ_f或$\sigma/\Delta\rho$、α和ε的指数。

此即Hibiki和Ishii[22]的IAC经验关系式的一般形式(式(7))，每单位质量能量耗散率根据机械能方程推导得到：$\varepsilon=\frac{j}{\rho_m}\left(-\frac{\mathrm{d}P}{\mathrm{d}z}\right)_F$。摩擦引起的每单位长度压力损失由Lockhart-Martinelli关联式得到，将此式(7)与上述结合可得到下列一般形式：

$$a_i=Z'\left(\frac{\sigma}{\rho_f}\right)^{-H}\frac{\alpha^{\Theta}}{(1-\alpha)^{X}}\left\{\frac{f_f\Phi_f^2}{D_H}(j_g+j_f)j_f^2\right\}^{X} \tag{8}$$

式中：Z'、f_f、Φ_f^2、D_H、j_g和j_f分别代表系数、液相摩擦系数、液相摩擦乘子、水力当量直径、表观气体流速和右边最后一项为体积膨胀项。故气泡合并破裂与IAC变化有很大关系。

气泡破碎引起的气泡数密度增加率ϕ_B可表示为：

$$\phi_B=\frac{\gamma_B\alpha(1-\alpha)\varepsilon^{1/3}}{D_b^{11/3}(\alpha_{max}-\alpha)}\exp\left(-\frac{K_B\sigma}{\rho_f D_b^{5/3}\varepsilon^{2/3}}\right) \tag{3}$$

式中：ε、D_b、α_{max}、K_B、σ和ρ_f分别代表单位质量的能量耗散率、气泡直径、最大空泡份额、常数、表面张力和液体密度。

气泡合并引起的气泡数密度减小率可表示为：

$$\phi_C=\frac{\gamma_C\alpha^2\varepsilon^{1/3}}{D_b^{11/3}(\alpha_{max}-\alpha)}\exp\left(-\frac{K_C\rho_f^{1/2}D_b^{5/6}\varepsilon^{1/3}}{\sigma^{1/2}}\right) \tag{4}$$

式中：K_C、γ_C为通过实验确定的可调参数。

由式(3、4)可得，空泡份额会影响气泡合并的剧烈程度，从而会对IAC造成影响。

其次，可从IAC经验关系式角度来解释。对于绝热稳定发展的泡状流条件，ϕ_{PN}和ϕ_{PC}均等于0，故气泡数密度输运方程为：

$$\phi_B-\phi_C=0 \tag{5}$$

通过式(3~5)，可得到：

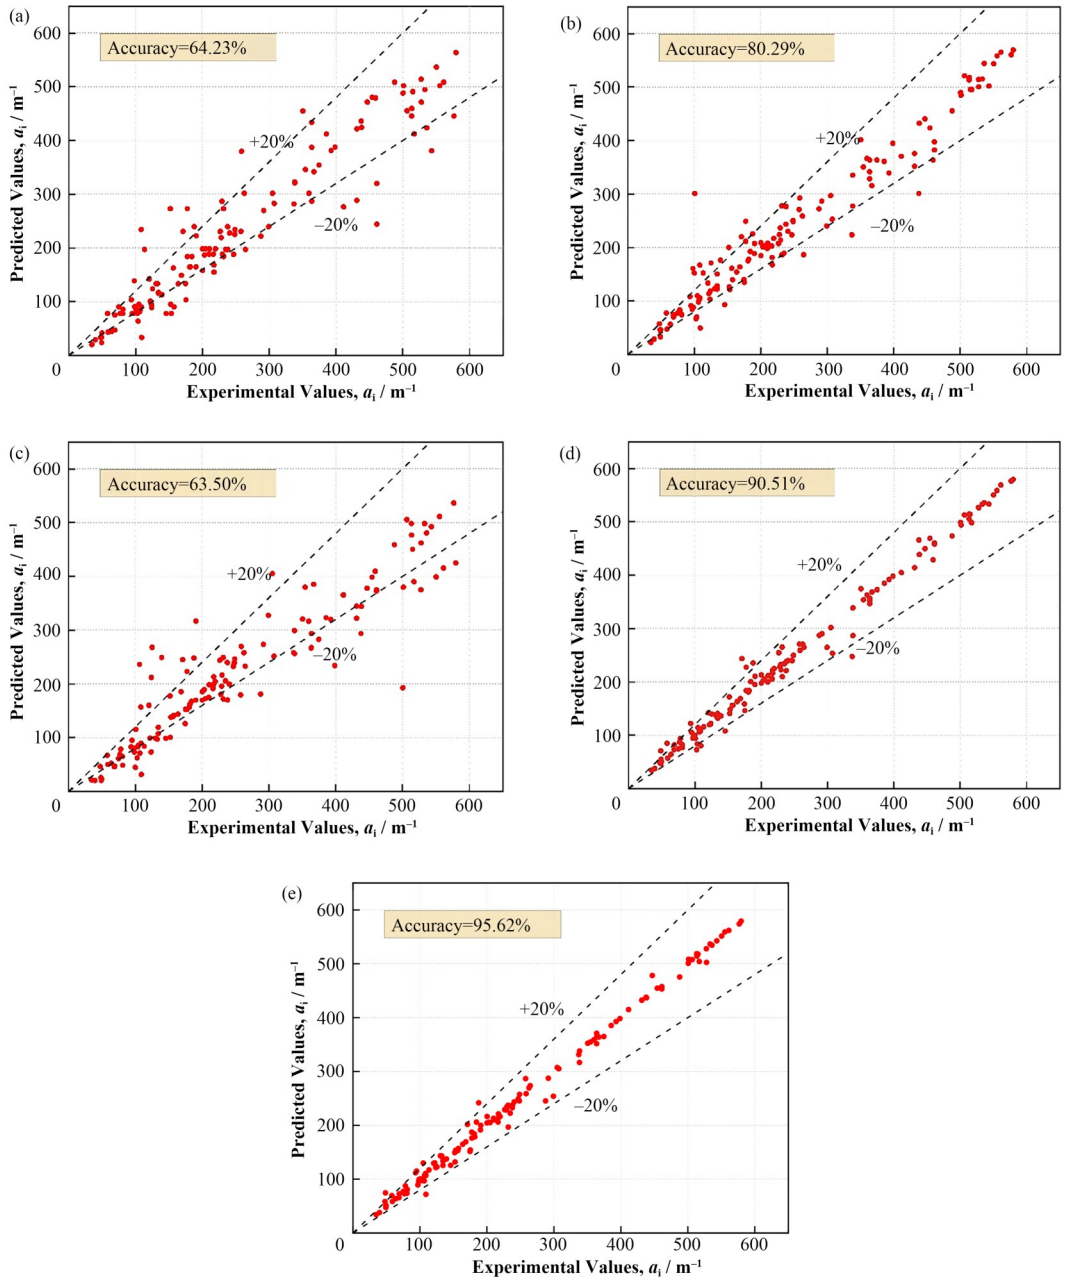

图2　输入项为5组不同输入特征时的预测值与实验值对比

(a) 输入特征为j_f与j_g，(b) 输入特征为j_f与α，(c) 输入特征为j_f/j_g与α，(d) 输入特征为j_f、j_g与α，(e) 输入特征为lg(j_f)、lg(j_g)与lg(α)

Fig.2　Comparison between predicted and experimental values for 5 different input features

(a) Input features are j_f and j_g, (b) Input features are j_f and α, (c) Input features are j_f/j_g and α, (d) Input features are j_f, j_g and α, (e) Input features are lg(j_f), lg(j_g) and lg(α)

液体流速。

在下列两种极端情况下，经验关系式为：

$$a_i = Z''\left\{\frac{f_f\Phi_f^2}{D_H}j_f^2\right\}^X\left(\frac{\sigma}{\rho_f}\right)^{-II}\alpha^{\Theta'}j_g^X,\ 当 j_g \gg j_f 时 \quad (9)$$

$$a_i = Z''\left\{\frac{f_f\Phi_f^2}{D_H}j_f^2\right\}^X\left(\frac{\sigma}{\rho_f}\right)^{-II}\alpha^{\Theta'}j_f^{3X},\ 当 j_g \ll j_f 时 \quad (10)$$

表3给出了σ/ρ_f或$\sigma/\Delta\rho$、α和ε、j_f或j_g在现有的界面面积相关性和模型中的指数。

通过表3可以得出，在现有的IAC经验关系式中，将Calderbank、Viswanathan、Akita和Yoshida等的α指数和j_g指数进行对比，发现α的指数比j_g的指数大。故相较于j_g，空泡份额是影响IAC的主要因素。

2.2　j_f/j_g与流型划分

将图2(b)与(c)进行对比，图2(b)的预测结果也明显优于图2(c)。图2(b)的输入特征为j_f与α，

表3 现有界面面积相关性中系数指数
Table 3 Coefficient index of existing interfacial area correlation

作者 Author	σ/ρ_f指数 σ/ρ_f index	α指数 α index	ε, j_f或j_g指数 ε, j_f, j_g index
Hibiki, Ishii[23]	−0.5	0.847	0.070 7(ε)
Millies *et al.*[24]	−0.6	0.83	0.4(ε)
Kocamustafaogullari *et al.*[25]	−0.33	0.78	0.22(ε)
Tabei *et al.*[26]	—	0.847	0(ε)
Calderbank[27]	−0.33	0.775	0.125(j_g)
Serizawa, Kataoka[28]	—	0.87	0.2(j_f)
Viswanathan[29]	−0.6	1	−0.085(j_g)
Akita, Yoshida[30]	−0.5	1	0.12(j_g)

而在气液两相流动实验中，是通过改变j_f和j_g（即液相和气相流量的工况组合）以达到引起IAC变化的目的。故尝试采用j_f/j_g与α作为输入特征，但结果未能达到期望，这说明j_f/j_g并不适用于IAC预测，是不恰当的。

为更好理解j_f/j_g在IAC预测中的作用，图3显示了j_f/j_g值与流动形态划分的关系，曲线为Mishima-Ishii模型的流型转变曲线。由于气泡之间的相互作用会导致流型的变化，故流型的转变在一定程度上能够反映IAC的变化。根据牛海宁等[31]研究，在相同气相表观速度下，在搅混流区域界面面积明显高于弹状-环状流区域，这是由于在搅混流区域，气液表观流速都比较大，两相湍动程度明显高于弹状-环状流区域。在图3中，在流型图所示流型为泡状流时，j_f/j_g在右侧彩色条中全覆盖，流型为弹状流-环状流时，j_f/j_g值均小于4.638，这表示colorbar所表示的j_f/j_g值变化边界与流型转变模型不符。

2.3 输入特征数量

将图2(b)与(d)进行对比，图2(d)的预测率为90.51%，高于图2(b)的80.29%。这是由于增添了j_g作为新的输入特征。这说明通过增加输入特征的数量，可以使得神经网络模型更好地学习到训练数据的特征；这也说明输入特征中j_g也是影响IAC的因素。在本研究中，为达到拟合速度与预测精度相平衡，那么神经网络的结构不能过于复杂，故仅选择了至多三种参数作为神经网络的输入特征。

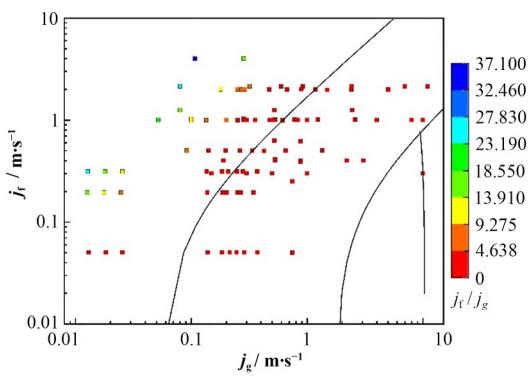

图3 j_f/j_g值与流动形态划分的关系（彩图见网络版）
Fig.3 Relationship between value and flow pattern division (color online)

2.4 数据预处理-对数变换

将图2(d)和(e)进行对比，图2(e)对(j_f、j_g、α)进行了对数变换的数据预处理。这说明对数据合适的预处理能够使得预测精度得到较好的改善。

而从统计学方面分析，由于lg函数的作用，如表4所示，能够缩小训练数据的绝对数值，同时也使得训练数据的方差大大缩小，使得模型预测能力增强，故选取合理的神经网络输入特征，这更有利于模型的拟合。

表4 对数变换前后平均值与方差比较
Table 4 Comparison of mean and variance before and after logarithmic transformation

	j_g	j_f	$\lg(j_g)$	$\lg(j_f)$
平均值 Average	1.222	1.121	−0.408	−0.176
方差 Variance	5.748	1.203	0.409	0.240

从使用的数学公式进行分析，在单层隐藏层神经网络的计算过程中，神经网络的输出是通过以下公式进行计算的：

$$WX = \sum_{i=1}^{n} w_i x_i \tag{11}$$

$$Y = WX + b \tag{12}$$

那么，如图1所示，对于双层隐藏层的神经网络，$O_{1,1}$由以下公式得到：

$$\begin{aligned} o_{1,1} &= f(\mathrm{net}_{1,1}) \\ \mathrm{net}_{1,1} &= \sum_{i=1}^{n} w_i x_i + b_1 \end{aligned} \tag{13}$$

若分别将j_f、j_g、α与$\lg(j_f)$、$\lg(j_g)$、$\lg(\alpha)$代入公式(10)中，则可得：

$$W_1 X_1 = j_g w_{111} + j_f w_{121} + \alpha w_{131} \tag{14}$$

$$W_1 X_2 = \lg(j_g^{\,w_{111}}) + \lg(j_f^{\,w_{121}}) + \lg(\alpha^{w_{131}}) \tag{15}$$

可以看出，对于式(14)，w_{111}、w_{121}与w_{131}作为j_f、j_g与α的多项式系数，对于式(15)，w_{111}、w_{121}与w_{131}作为j_f、j_g与α的指数系数，能够较好地放大j_f、j_g与α的影响，所以对于IAC预测有着良好的优化。而$O_{2,1}$由以下公式得到：

$$O_{2,1}=f(\mathrm{net}_{2,1})$$
$$\mathrm{net}_{2,1}=\sum_{i=1}^{n}w_iO_i+b_2 \tag{16}$$

然后引入Adam自适应算法对梯度下降法改进，让学习率能够自适应地根据损失函数的改变而变化，提高收敛速度[32]，而随着神经网络的训练，j_f与j_g的意义将不断放大，对IAC的影响也会不断增强。

对神经网络训练过程的定量分析如图4所示，图4展示了随着神经网络前向传播的不断进行，经过网络第一层隐藏层的计算过程中，对数变换初始化$j_f^{w_{111(lg)}}$、$\alpha^{w_{111(lg)}}$、$j_g^{w_{111(lg)}}$三者特征与未对数变换$j_f\times w_{111}$、$\alpha\times w_{111}$、$j_g\times w_{111}$三者的大小，可以看到绝对数值远大于后者。说明“WX”中的“X”对第一层隐藏层的输出结果影响较大，有利于真实物理数据对神经网络模型的训练。

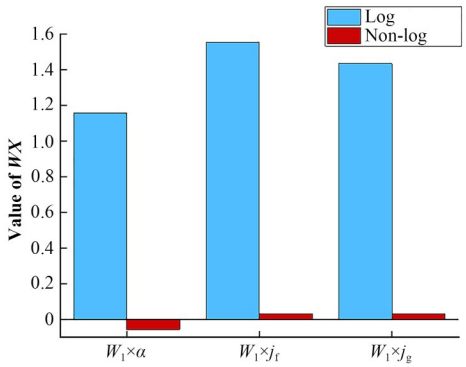

图4　三个输入特征第一层计算结果
Fig.4　First layer calculation results of three input features

可以看出，通过对输入特征进行对数变换，将会弱化神经网络权重的影响，增加神经网络输入特征的影响，对于j_f、j_g、α物理信息数据的放大也会不断增加，这有利于模型的拟合。

表5展示了样本1在两个神经网络模型训练过程中，数据第一、二、三次与权重计算后，得到的数值矩阵大小分别是1×32、1×32、1×1。

表5　神经网络训练过程矩阵大小
Table 5　Size of neural network training process matrix

	输入矩阵 Input matrix	权重矩阵 Weight matrix	输出矩阵 Output matrix
第一次参数计算 First parameter calculation	1×3	3×32	1×32
第一次参数计算 Second parameter calculation	1×32	32×32	1×32
第一次参数计算 Third parameter calculation	1×32	32×1	1×1

而在未添加偏置与未激活的情况下，分别将每个矩阵中所有元素求和，计算过程与式(10)对应。得到表6关于神经网络每层计算前一步的大小，可以看出对数变换各值均为正值，且绝对数值均大于未对数变换。神经网络输出结果为$Y=WX+b$，在添加偏置和激活后，由表中可以看到对数变换输出层前“W_3X”大于偏置b_3，而未对数变换的前者小于后者，说明对数变换弱化了最后一层偏置的作用，提高了“WX”的影响。

表6　每层前计算与偏置b_3数值
Table 6　Calculated and biased b_3 values before each layer

	隐藏层1前 Before hidden layer 1 $\sum_{i=1}^{32}W_1X$	隐藏层2前 Before hidden layer 2 $\sum_{i=1}^{32}W_2X$	输出层前 Before output layer W_3X	偏置 Bias b_3
对数变换 Logarithmic transformation	88.319	252.909	0.947	0.154
未对数变换 Non-logarithmic transformation	−0.008	8.494	−0.292	0.639

综上所述，通过对数变换的方法，可以有效地提高对输入特征j_f、j_g、α三者物理信息对神经网络结果的影响，有利于真实物理数据对神经网络的训练，使得神经网络对于真实数据的拟合和预测有着更好的结果。

3　结语

本研究应用神经网络的预测方法，对IAC数据库进行了训练，建立了可靠的神经网络模型，在物理上结合气泡行为以及数据的统计分布，通过对结果进行事后可解释性分析。在数学计算及神经网络结构上，逐步计算分析神经网络内部结构参数，计算每一层的输出比重，得到了如下结论：

1）空泡份额α相较于液相表观流速和气相表观流速，是影响IAC变化的主要因素。j_f/j_g不能作为神经网络输入的特征，其变化边界与流型转变模型不符。

2）对于神经网络，不同的数据预处理会得到不同的预测结果。事先对数据进行对数变换，可以放大物理信息，显著增强神经网络的预测能力。

3）同时选取$\lg(\alpha)$、$\lg(j_f)$、$\lg(j_g)$作为输入特征时，神经网络的预测效果最好，预测精度可以达到95.62%。

本研究提出了基于可解释性理论修正神经网络模型的指导思路，可用于构建高精度反应堆流动换

热参数预测神经网络中。

作者贡献声明 周钰浩负责概念化、方法论、调查、软件、写作初稿；许汪涛负责调查、初稿审阅修改；刘丽负责研究、初稿审阅修改；朱隆祥负责方法、调查、初稿审阅修改；张卢腾负责资金获取；潘良明负责监督。

参考文献

1 Shen X, Hibiki T. Interfacial area concentration in gas–liquid bubbly to churn flow regimes in large diameter pipes[J]. International Journal of Heat and Fluid Flow, 2015, **54**: 107–118.

2 Ishii M, Hibiki T. Thermo-fluid dynamics of two-phase flow[M]. New York, NY: Springer New York, 2011. DOI: 10.1007/978-1-4419-7985-8.

3 Ishii M, Kim S, Uhle J. Interfacial area transport equation: model development and benchmark experiments [J]. International Journal of Heat and Mass Transfer, 2002, **45**(15): 3111–3123. DOI: 10.1016/s0017-9310(02)00041-8.

4 Sun X D, Smith T R, Kim S, *et al*. Interfacial area of bubbly flow in a relatively large diameter pipe[J]. Experimental Thermal and Fluid Science, 2002, **27**(1): 97–109. DOI: 10.1016/s0894-1777(02)00220-0.

5 Worosz T, Kim S, Hoxie C. Experiments in cap-bubbly two-phase flows for two-group IATE development[J]. Nuclear Technology, 2015, **190**(3): 264–273. DOI: 10.13182/nt14-71.

6 Vasavada S, Sun X, Ishii M, *et al*. Benchmarking of the one-dimensional one-group interfacial area transport equation for reduced-gravity bubbly flows[J]. International Journal of Multiphase Flow, 2009, **35**(4): 323–334. DOI: 10.1016/j.ijmultiphaseflow.2009.01.006.

7 Huang Y P, Shan J Q, Chen B D. Application of artificial neural networks in analysis of CHF experimental data in round tubes[J/OL]. Researchgate, 2004, **15**(4). https://www.researchgate.net/publication/237570255.

8 Zhao X G, Shirvan K, Salko R K, *et al*. On the prediction of critical heat flux using a physics-informed machine learning-aided framework[J]. Applied Thermal Engineering, 2020, **164**: 114540. DOI: 10.1016/j.applthermaleng.2019.114540.

9 Bishop C. Neural networks for pattern recognition[M]. New York: Oxford University Press, 1995.

10 Fausett L. Fundamentals of neural networks[M]. Prentice Hall, NJ, USA, 1994.

11 Nasseh S, Mohebbi A, Jeirani Z, *et al*. Predicting pressure drop in venturi scrubbers with artificial neural networks [J]. Journal of Hazardous Materials, 2007, **143**(1–2): 144–149. DOI: 10.1016/j.jhazmat.2006.09.005.

12 Principe J, Euliano N, Lefebvre W. Neural and adaptive systemfundamentals through simulations[M]. IEEE Transactions on Neural Networks, 2000.

12 Shen X Z, Hibiki T, Nakamura H. Developing structure of two-phase flow in a large diameter pipe at low liquid flow rate[J]. International Journal of Heat and Fluid Flow, 2012, **34**: 70–84. DOI: 10.1016/j. ijheatfluidflow. 2012.02.004.

13 刘靖宇. 气液两相流动界面输运过程研究[D]. 哈尔滨: 哈尔滨工程大学, 2013.
LIU Jingyu. Research on interfacial transport of gas-liquid two phase flow[D]. Harbin: Harbin Engineering University, 2013.

14 Shen X, Hibiki T, Nakamura H. Developing structure of two-phase flow in a large diameter pipe at low liquid flow rate[J]. International Journal of Heat and Fluid Flow, 2012, **34**: 70–84.

15 Dang Z R, Wang G Y, Ju P, *et al*. Experimental study of interfacial characteristics of vertical upward air-water two-phase flow in 25.4 mm ID round pipe[J]. International Journal of Heat and Mass Transfer, 2017, **108**: 1825–1838. DOI: 10.1016/j.ijheatmasstransfer.2017.01.040.

16 Schlegel J P, Miwa S, Chen S, *et al*. Experimental study of two-phase flow structure in large diameter pipes[J]. Experimental Thermal and Fluid Science, 2012, **41**: 12–22. DOI: 10.1016/j.expthermflusci.2012.01.034.

17 Wang G Y, Dang Z R, Ju P, *et al*. Experimental study on interfacial structure and interfacial area transport in downward two-phase flow[J]. International Journal of Heat and Mass Transfer, 2017, **106**: 1303–1317. DOI: 10.1016/j.ijheatmasstransfer.2016.10.112.

18 Wang G Y, Zhang M H, Ishii M. Flow structure of bubbly to slug transition flow in a small pipe[J]. International Journal of Heat and Mass Transfer, 2020, **147**: 118943. DOI: 10.1016/j.ijheatmasstransfer.2019.118943.

19 Qiao S X, Mena D, Kim S. Inlet effects on vertical-downward air-water two-phase flow[J]. Nuclear Engineering and Design, 2017, **312**: 375–388. DOI: 10.1016/j.nucengdes.2016.04.033.

20 Smith T R, Schlegel J P, Hibiki T, *et al*. Mechanistic modeling of interfacial area transport in large diameter

pipes[J]. International Journal of Multiphase Flow, 2012, **47**: 1 – 16. DOI: 10.1016/j.ijmultiphaseflow.2012.06.009.

21 Smith T R, Schlegel J P, Hibiki T, *et al*. Two-phase flow structure in large diameter pipes[J]. International Journal of Heat and Fluid Flow, 2012, **33**(1): 156 – 167. DOI: 10.1016/j.ijheatfluidflow.2011.10.008.

22 Hibiki T, Ishii M. Interfacial area concentration in steady fully-developed bubbly flow[J]. International Journal of Heat and Mass Transfer, 2001, **44**(18): 3443 – 3461. DOI: 10.1016/s0017-9310(00)00365-3.

23 Hibiki T, Ishii M. One-group interfacial area transport of bubbly flows in vertical round tubes[J]. International Journal of Heat and Mass Transfer, 2000, **43**(15): 2711 – 2726. DOI: 10.1016/s0017-9310(99)00325-7.

24 Milliest M, Drew D A, Lahey R T. A first order relaxation model for the prediction of the local interfacial area density in two-phase flows[J]. International Journal of Multiphase Flow, 1996, **22**(6): 1073 – 1104. DOI: 10.1016/0301-9322(96)00031-6.

25 Kocamustafaogullari G, Huang W D, Razi J. Measurement and modeling of average void fraction, bubble size and interfacial area[J]. Nuclear Engineering and Design, 1994, **148**(2 – 3): 437 – 453. DOI: 10.1016/0029-5493(94)90124-4.

26 Tabei K, Hasatani M, Kuroda M. Elective gas±liquid interfacial area in a mobile-bed contactor[J]. International Chemical Engineering, 1989, **29**: 679 – 688.

27 Calderbank P H. Gas absorption from bubbles[J]. Chemical Engineering, 1967, **43**: CE209 – CE233.

28 Serizawa A, Kataoka I. Phase distribution in two-phase flow[M]. Transient Phenomena in Multiphase Flow, Hemisphere, Washington, DC, 1988: 179 – 224.

29 Viswanathan K. Flow patterns in the bubble[M]. Cheremisino N P, Ed. Encyclopedia of Fluid Mechanics. Vol.3, Gulf Publishing, 1985: 1180 – 1215.

30 Akita K, Yoshida F. Bubble size, interfacial area, and liquid-phase mass transfer coefficient in bubble columns [J]. Industrial & Engineering Chemistry Process Design and Development, 1974, **13**(1): 84 – 91. DOI: 10.1021/i260049a016.

31 牛海宁, 潘立卫, 王树东. 微通道气液两相流型及界面面积测定[J]. 现代化工, 2009, **29**(5): 60 – 64.
NIU Haining, PAN Liwei, WANG Shudong. Flow pattern and gas-liquid interfacial area in a microchannel contactor [J]. Modern Chemical Industry, 2009, **29**(5): 60 – 64.

32 冀南, 易金豪, 赵鹏程, 等. 基于自适应RBF神经网络预测堆芯热工水力参数的方法研究[J]. 核技术, 2022, **45** (9): 090601. DOI: 10.11889/j. 0253-3219.2022. hjs. 45. 090601.
JI Nan, YI Jinhao, ZHAO Pengcheng, *et al*. Research on adaptive RBF neural network prediction method for core thermal-hydraulic parameters of fast reactor[J]. Nuclear Techniques, 2022, **45**(9): 090601. DOI: 10.11889/j.0253-3219.2022.hjs.45.090601.