研究论文

DOI：10.11949/0438-1157.20251428

融合物理约束与分布式架构的提升管流场重构方法

郭建豪[1]，朱春梦[1,2]，柳楠[1]，吉鲁东[1]，赵云鹏[1]，石孝刚[1]，蓝兴英[1]

（[1]中国石油大学（北京）重质油全国重点实验室，北京 102249；[2]中国石油大学（北京）人工智能学院，北京 102249）

摘要： 面向循环流化床（circulating fluidized bed，CFB）提升管复杂气固流场的快速高精度预测需求，针对传统计算流体力学（computational fluid dynamics，CFD）计算成本高、数据驱动模型易出现守恒性不足等问题，构建经实验验证的多工况CFD数据集，提出融合物理约束与分布式并行编码器-解码器结构的物理信息神经网络（distributed parallel encoder-decoder physics-informed neural network，DPED-PINN）流场重构方法。该方法将基于介尺度曳力模型的质量与动量守恒方程以软约束形式嵌入损失函数，并结合特征解耦、多解码器结构及基于残差的自适应采样策略，以增强对高梯度区域和多尺度流动特征的表征能力。数值结果表明，与标准PINN及常规模型相比，DPED-PINN在已知与外推工况下具有更高的预测精度和物理一致性，能够较为准确地描述壁面颗粒聚团及典型“环-核”结构。此外，固定测点固含率时间序列对比与独立实验测点数据的外部对照进一步验证了模型的时间一致性与外推泛化能力。同时，所提出的方法相对于逐工况CFD模拟，显著提升了计算效率，为CFB提升管复杂气固流场的高效数值模拟提供了一种可行途径。

关键词： 循环流化床；多相流；物理信息约束；流场重构

中图分类号： TP 183　　**文献标志码：** A

文章编号： 0438-1157（2026）10-5801-17

A deep learning framework integrating physical constraints and distributed architecture for flow field reconstruction in CFB risers

GUO Jianhao[1], ZHU Chunmeng[1,2], LIU Nan[1], JI Ludong[1], ZHAO Yunpeng[1], SHI Xiaogang[1], LAN Xingying[1]

([1]*State Key Laboratory of Heavy Oil Processing, China University of Petroleum, Beijing* 102249, *China*; [2]*College of Artificial Intelligence, China University of Petroleum, Beijing* 102249, *China*)

Abstract: To address the demand for real-time, high-fidelity reconstruction of gas-solid flow fields in circulating fluidized bed (CFB) risers, this study develops a physics-data fusion deep learning framework. The method targets two main limitations of current simulations: the high computational cost and poor real time performance of traditional computational fluid dynamics (CFD), and the lack of physical consistency in purely data driven models without explicit physical constraints. An experimentally validated CFD model is first used to construct a multi condition three-dimensional spatiotemporal dataset that covers a wide range of gas velocities and particle fluxes. On this basis, a distributed parallel encoder-decoder physics-informed neural network (DPED-PINN) is proposed. In terms of architecture, a parallel multi decoder structure is adopted to decouple feature extraction and alleviate gradient conflicts in multi task learning. In terms of physical mechanisms, mass and momentum conservation

收稿日期： 2025-12-18　　**修回日期：** 2026-02-17

通信作者： 蓝兴英(1977—)，女，博士，教授，lanxy@cup.edu.cn

第一作者： 郭建豪(1999—)，男，博士研究生，2024310321@student.cup.edu.cn

基金项目： 国家重点研发计划项目(2024YFE0212400)；中国石油大学(北京)科研基金项目(2462025XKBH001)

引用本文： 郭建豪, 朱春梦, 柳楠, 吉鲁东, 赵云鹏, 石孝刚, 蓝兴英. 融合物理约束与分布式架构的提升管流场重构方法[J]. 化工学报, 2026, 77(10): 5801-5817

Citation: GUO Jianhao, ZHU Chunmeng, LIU Nan, JI Ludong, ZHAO Yunpeng, SHI Xiaogang, LAN Xingying. A deep learning framework integrating physical constraints and distributed architecture for flow field reconstruction in CFB risers[J]. CIESC Journal, 2026, 77(10): 5801-5817

equations based on a mesoscale drag model are embedded into the loss function as soft constraints in order to enforce physical consistency. Furthermore, an adaptive sampling strategy based on residual probability density, combined with a dynamic loss weighting scheme, is introduced to enhance learning in high gradient regions. Numerical results show that, compared with the standard PINN and conventional models, DPED-PINN exhibits higher prediction accuracy and physical consistency under known and extrapolated conditions, and can accurately describe wall particle agglomeration and typical "ring-core" structures. For a representative extrapolated case, the model achieves a solid volume fraction structural similarity index (SSIM) of about 0.887, which is approximately 15% higher than that of a standard PINN, and accurately reconstructs near wall particle clusters and the characteristic core annulus structure. Moreover, the temporal evolution of solids holdup at fixed probes and external comparisons with independent experimental measurements further corroborate the temporal consistency and generalization performance of the proposed approach. Compared with case-by-case CFD simulations, the proposed framework significantly improves computational efficiency, providing a feasible approach for efficient numerical simulation and analysis of complex gas-solid flows in CFB risers.

Keywords: circulating fluidized bed; multiphase flow; physics-informed constraints; flow field reconstruction

引 言

循环流化床(CFB)凭借燃料适应性强、传热传质效率高等优势,在能源化工领域得到广泛应用[1-4],其内部颗粒聚团、环-核结构等复杂流动状态直接决定了装置的运行稳定性与反应效率。随着"双碳"战略与工业数智化的推进,实现对CFB内时空高度演化的介尺度流场的高保真感知成为关键。然而,受限于高温、高固含率及设备不透明等因素,现有实验测量技术难以保证传感器的准确性与耐久性[5],无法获取全场瞬态信息,难以满足数字孪生对复杂工况下流场实时、连续监测的需求[6]。

目前,基于计算流体力学CFD的数值模拟方法已成为研究流态化多相流的主要工具。欧拉-欧拉双流体模型能够在连续介质假设下给出气固两相的速度、压力和体积分数等局部分布,为揭示颗粒聚团、环-核结构形成机理提供了重要手段。然而,在工业尺度反应器和多工况参数空间内进行全局计算时,CFD面临着网格规模大、时间步长小、计算成本高等问题。尤其是在需要进行大量工况扫描或实时响应的场景中,传统CFD难以满足过程工业对快速仿真和在线优化的需求[7]。

近年来,基于数据驱动的机器学习和深度学习方法被广泛用于构建流化床等多相流装置的替代模型,通过从高维流场数据中挖掘输入-输出之间的非线性映射,实现对速度场、固含率场等物理量的快速预测[8-9]。Upadhyay等[10]利用人工神经网络预测不同颗粒循环量下的轴向固含率,并通过实验验证了模型精度。黄正梁等[11]基于深度学习建立气液固三相反应器图像分析模型,用于流型识别及压降和均匀性预测。Zhong等[12]通过改进网络结构并引入预测范围约束,显著提升了循环流化床内固含率的预测精度。Bazai[13]将CFD与编码器-解码器卷积神经网络结合,实现了pseudo-2D流化床固含率场的时序预测。这些研究表明,深度学习方法在一定程度上能够实现流化床流场预测的模型降阶和加速。

然而,传统深度学习方法(如ANN、CNN)在多相流动预测中缺乏明确的物理约束,在高梯度区域、颗粒聚团及"环-核"结构等复杂流动特征建模中容易出现预测失真和物理不一致性,尤其在外推工况下泛化能力较差。为提高物理一致性,Raissi等[14-15]提出了物理信息神经网络框架,通过将控制方程及初边值条件以软约束形式嵌入损失函数,使网络在学习数据特征的同时满足相应的物理守恒定律,并在多类非线性偏微分方程问题中展现出良好稳定性和泛化能力。Buhendwa等[16]将PINNs应用于不可压两相流场反演,验证了物理约束深度学习在两相流场重构中的可行性;张橙等[17]系统总结了PINNs在两相流模拟中的技术路线与挑战,指出通过显式嵌入质量守恒和动量守恒方程可显著提高预测的物理合理性。然而,在多物理场耦合问题中,不同物理约束项之间往往存在梯度病态,导致模型难以收敛[18]。针对这一问题,Anagnostopoulos等[19]提出基于残差注意力的PINNs训练策略,从损失分布角度改善了多物理量、多区域耦合问题中的

训练效率与收敛性，为复杂流场中的自适应加权和采样提供了新的思路。

尽管上述研究表明物理信息神经网络在保持物理一致性的同时具有较好的泛化能力，但将标准PINNs直接应用于CFB提升管这类三维、非均匀气固流动时仍面临多重挑战：(1)提升管内颗粒聚团和“环-核”结构导致局部梯度剧烈变化，若采用固定或简单随机采样策略，容易造成关键高残差区域样本不足，影响模型对复杂流动特征的学习效率和收敛性能；(2)气固两相速度、压力和固含率等物理量在数值尺度和空间分布上存在显著差异，若采用单一网络同时预测所有变量，易出现梯度冲突和优化不均衡问题，从而削弱模型的整体预测精度与物理一致性[20-21]。因此，简单的网络堆叠无法奏效，亟须构建一种既能融入流体力学物理约束，又能适应CFB提升管多工况、强非均匀流动特征的高效深度学习建模框架。

基于上述背景，本文以CFB提升管为研究对象，构建覆盖不同气体入口速度与颗粒质量通量的多工况流动数据集；在此基础上，提出分布式并行编码器-解码器物理信息神经网络流场重构方法。该方法通过工况参数编码器与时空坐标编码器的并行设计实现操作条件与时空信息的特征融合，在损失函数中以软约束形式引入质量守恒和动量守恒方程，并基于能量最小多尺度(energy minimization multi scale，EMMS)曳力模型计算气固相间耦合项[22-23]。同时，引入基于残差的概率密度自适应采样(residual based probability density sampling，RPDS)和动态损失权重机制，增强模型对高梯度区域的学习能力。通过系统评估DPED-PINN在内插与外推工况下的预测精度、物理一致性及计算效率，考察该方法在CFB提升管气固流场快速预测与多工况分析中的适用性。

1 计算方法

1.1 控制方程

循环流化床提升管反应器内的气固两相流动可以通过双流体模型(Euler-Euler方法)描述，将气固相看作是连续的，气固相为拟流体，可相互之间渗透，并服从流体力学基本方程组，固相压力、固相黏度等由KTGF(kinetic theory of granular flow)[24]进行封闭。为构建物理约束的神经网络模型，本研究将以下方程作为PINNs的正则化条件嵌入损失函数，以强化解的物理一致性。

气相质量守恒方程：

$$\frac{\partial}{\partial t}\left(\varepsilon_{\mathrm{g}}\rho_{\mathrm{g}}\right)+\nabla\cdot\left(\varepsilon_{\mathrm{g}}\rho_{\mathrm{g}}\boldsymbol{u}_{\mathrm{g}}\right)=0 \tag{1}$$

颗粒相质量守恒方程：

$$\frac{\partial}{\partial t}\left(\varepsilon_{\mathrm{s}}\rho_{\mathrm{s}}\right)+\nabla\cdot\left(\varepsilon_{\mathrm{s}}\rho_{\mathrm{s}}\boldsymbol{u}_{\mathrm{s}}\right)=0 \tag{2}$$

式中，ε_{g}和ε_{s}分别代表气相和颗粒相的体积分数；$\boldsymbol{u}_{\mathrm{g}}$和$\boldsymbol{u}_{\mathrm{s}}$分别代表气相和颗粒相的速度矢量。

气相动量守恒方程：

$$\frac{\partial}{\partial t}\left(\varepsilon_{\mathrm{g}}\rho_{\mathrm{g}}\boldsymbol{u}_{\mathrm{g}}\right)+\nabla\cdot\left(\varepsilon_{\mathrm{g}}\rho_{\mathrm{g}}\boldsymbol{u}_{\mathrm{g}}\boldsymbol{u}_{\mathrm{g}}\right)=-\varepsilon_{\mathrm{g}}\nabla p+\nabla\cdot\boldsymbol{\tau}_{\mathrm{g}}+\varepsilon_{\mathrm{g}}\rho_{\mathrm{g}}\boldsymbol{g}-\beta\left(\boldsymbol{u}_{\mathrm{g}}-\boldsymbol{u}_{\mathrm{s}}\right) \tag{3}$$

颗粒相动量守恒方程：

$$\frac{\partial}{\partial t}\left(\varepsilon_{\mathrm{s}}\rho_{\mathrm{s}}\boldsymbol{u}_{\mathrm{s}}\right)+\nabla\cdot\left(\varepsilon_{\mathrm{s}}\rho_{\mathrm{s}}\boldsymbol{u}_{\mathrm{s}}\boldsymbol{u}_{\mathrm{s}}\right)=-\varepsilon_{\mathrm{s}}\nabla p+\nabla p_{\mathrm{s}}+\nabla\cdot\boldsymbol{\tau}_{\mathrm{s}}+\varepsilon_{\mathrm{s}}\rho_{\mathrm{s}}-g\beta\left(\boldsymbol{u}_{\mathrm{g}}-\boldsymbol{u}_{\mathrm{s}}\right) \tag{4}$$

在欧拉-欧拉双流体模型中，气固两相动量守恒方程的封闭性依赖于相间曳力模型。该模型的选择直接决定了动量传递，进而显著影响全场流场预测的准确性。本研究采用EMMS曳力模型进行模拟，与基于均匀化假设的经验模型不同，EMMS基于结构-能量协调原理，在宏观尺度上建立考虑颗粒聚团效应的曳力关系式。在物理损失计算中，相间曳力并非常数，而是由网络预测的局部滑移速度和固含率代入关联式在线计算，使介尺度结构对动量传递的影响通过曳力项显式体现在动量残差中[25]。在物理损失函数的计算过程中，相间曳力项F_{drag}是根据神经网络实时预测的局部气固滑移速度$\left(\boldsymbol{u}_{\mathrm{g}}-\boldsymbol{u}_{\mathrm{s}}\right)$和固含率$\varepsilon$代入EMMS曳力关联式在线计算得到的，从而将介尺度物理机制显式地施加于动量残差约束中。根据EMMS曳力模型公式：

$$F_{\mathrm{drag}}=\beta(\boldsymbol{u}_{\mathrm{g}}-\boldsymbol{u}_{\mathrm{s}})=\frac{3}{4}C_{\mathrm{D}}\frac{\rho_{\mathrm{g}}\varepsilon_{\mathrm{s}}|\boldsymbol{u}_{\mathrm{g}}-\boldsymbol{u}_{\mathrm{s}}|}{d_{\mathrm{p}}}(\boldsymbol{u}_{\mathrm{g}}-\boldsymbol{u}_{\mathrm{s}}) \tag{5}$$

式中，ρ_{g}为气相密度；d_{p}为颗粒直径；$\left|\boldsymbol{u}_{\mathrm{g}}-\boldsymbol{u}_{\mathrm{s}}\right|$为气固之间的滑移速度的模。值得注意的是，模型中的曳力系数C_{D}并非经验常数，而是通过求解结构-能量最小化问题获得，其值随局部空隙率和滑移速度动态变化，从而真实反映介尺度结构对动量传递的调控作用。

1.2 研究对象及模拟参数

本研究以文献[26]冷模实验装置的等径提升管为模拟对象，直径D为0.076 m，高度H为10 m，颗粒粒

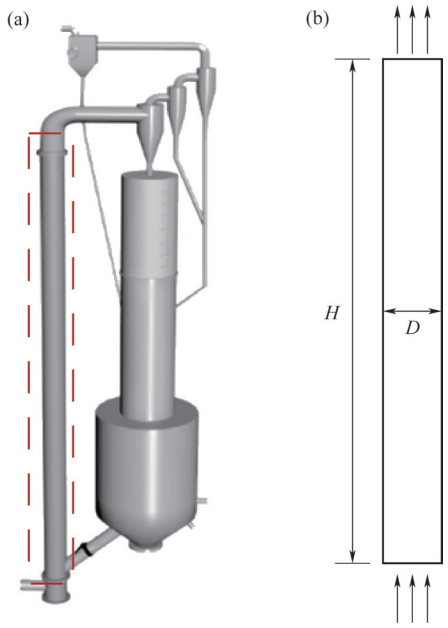


图1 (a)实验装置简图;(b)模拟结构简图

Fig.1 (a)Schematic diagram of the experimental setup; (b) Schematic diagram of the simulation structure

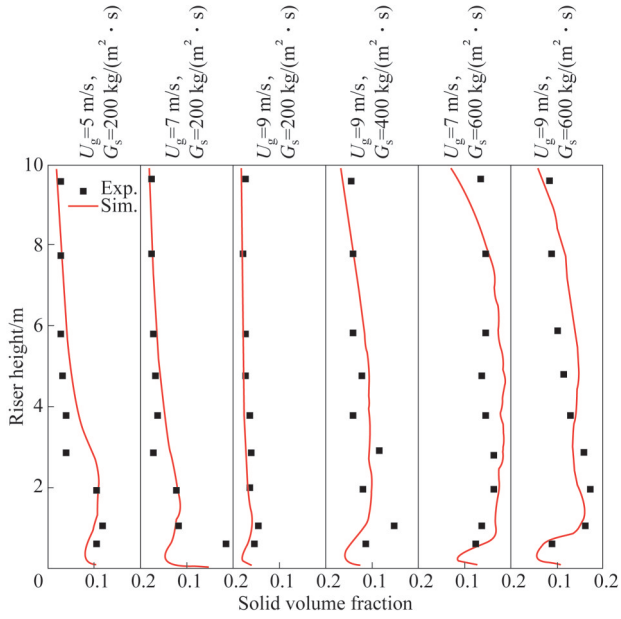


图2 不同操作条件下提升管内轴向时均固含率分布曲线与实验数据的对比

Fig.2 Comparison of axial time-averaged solid holdup distribution curves in the riser under different operating conditions with experimental data

径d_p=76 μm。模拟工况及边界条件设置基于实验测量数据,以确保数值模拟与实验研究的物理一致性,几何结构如图1所示。

模拟采用商业软件Fluent进行,气固两相入口采用速度入口条件,出口设为压力出口条件,边壁条件设为无滑移,壁面反射系数为0.0005,计算步长设置为0.001 s。计算中采用结构化网格对计算域进行离散,通过对不同网格数量的算例进行对比分析完成网格无关性验证后,综合考虑计算精度与计算成本,最终选取约8万个单元的网格划分用于后续计算。计算25 s后系统达到统计稳定状态,并取25~35 s的结果进行时均统计,用于后续模型验证。

1.3 模型验证

在进行模拟构建数据集之前,需要对基准模型进行模型验证。模拟参数与设置如2.2节所示。图2和图3分别为不同操作条件下提升管内部轴、径向上的时均固含率分布与实验数据的对比,其中实验数据引自文献[26]。原文献未提供重复实验的标准差/置信区间等离散度统计,故未绘制误差棒。

从图中可以看出,CFD模拟结果与实验数据展现出良好的一致性,这说明本研究建立的流动模型能够可靠地模拟和预测不同工况下提升管内的复杂气固两相流动特性。

1.4 数据集构建

为了确保模型能够覆盖并重构出符合工业实际的高密度均匀流特征,本研究设定了覆盖低通量到高通量的操作参数范围,即气体入口速度U_g为5、7、9 m/s,颗粒质量通量G_s在200~1000 kg/(m^2·s)。采用拉丁超立方采样(Latin hypercube sampling, LHS)[27]方法在上述区间内随机抽取13个不同操作条件的组合(如表1 case1~ case13所示),确保输入参数在多维空间均匀分布,避免训练数据偏差。此外,为了验证模型的内插以及外推能力,选择两组未参与训练的工况作为测试集:其中一组参数在操作条件范围内,用于检验模型的插值能力;另一组参数组合超出原有操作条件范围,用以考察模型的外推性能,如表1中的case14、case15。

为描述流场从发展到稳定的动态演化过程,选取5~25 s的瞬态数据作为训练样本,时间步长为0.1 s,每个工况生成200帧流场快照。每帧包含约8.0×10^{4}个网格节点及其气固两相在三维方向上的速度、压力和固含率,实现多工况、全时空域的数据覆盖。考虑到不同物理量在数值量级上的差异,本文对所有输入输出变量进行无量纲化处理:空间坐标归一化至[-1, 1],各物理量采用Min-Max归一化映射至[0, 1],预测输出再通过反归一化还原为物理量,用于误差分析。

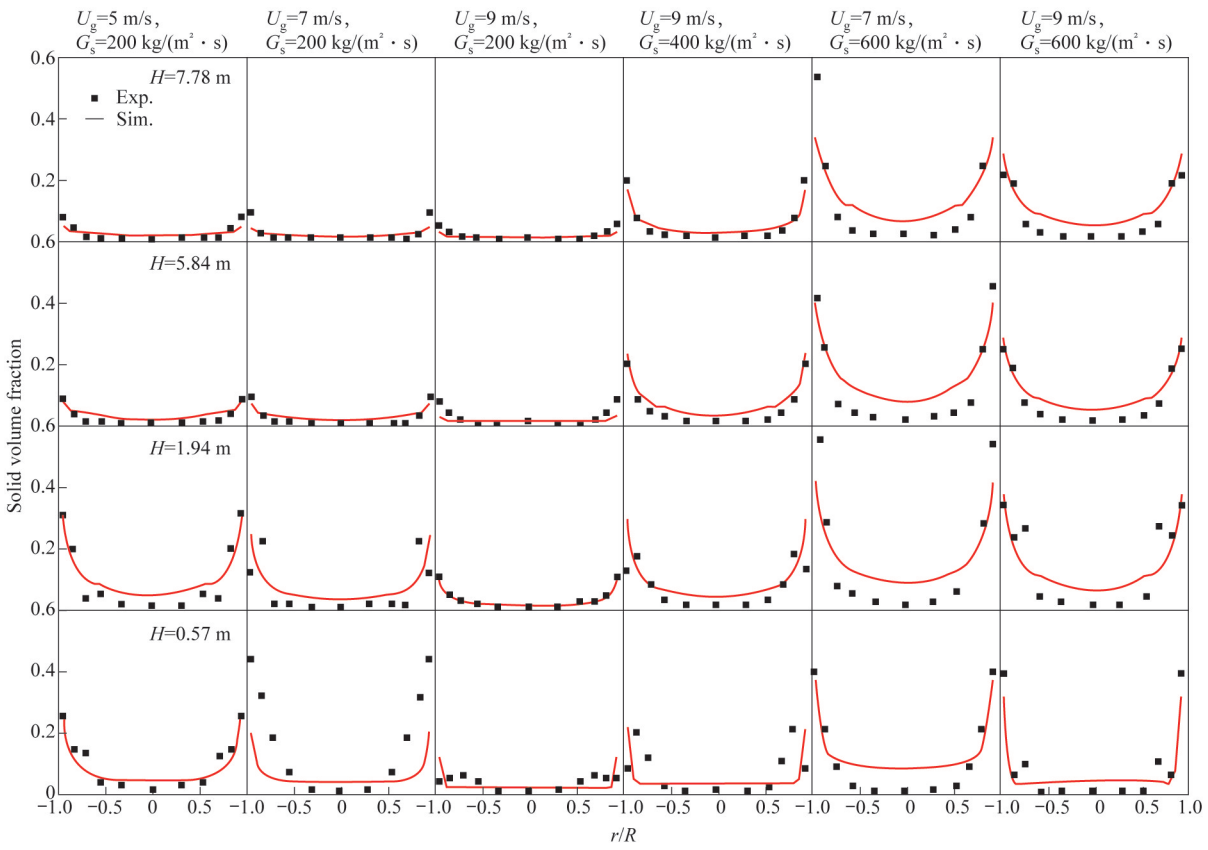


图3 不同操作条件下提升管内不同高度下径向时均固含率分布曲线与实验数据的对比

Fig.3 Comparison of radial time-averaged solid holdup distribution curves at different heights in the riser under different operating conditions with experimental data

表1 模拟工况参数

Table 1 Simulation condition parameters

Case	气体入口速度 U_g/(m/s)	颗粒质量通量 G_s/(kg/(m²·s))
1	5.2	203.8
2	5.5	826.9
3	5.8	688.5
4	6.1	757.7
5	6.4	134.6
6	6.7	273.1
7	7.0	619.2
8	7.3	896.2
9	7.6	480.8
10	7.9	411.5
11	8.2	550
12	8.5	965.4
13	8.8	342.3
14	6.5	955.6
15	11.4	1159.9

2 模型结构参数及训练

2.1 基于物理信息的人工神经网络

本文采用基于物理信息的前馈全连接神经网络，将气固两相流动的控制方程直接嵌入损失函数，实现数据驱动与物理约束的统一。对于给定的工况参数和时空坐标输入，神经网络以参数集合为自变量，给出目标物理量的预测值。

对于给定的工况参数与空间-时间坐标，前馈全连接神经网络 F_Φ 的映射关系可表示为：

$$\boldsymbol{y} = F_{\Phi}(\boldsymbol{s},\boldsymbol{\mu}) \tag{6}$$

对于给定工况参数 $\boldsymbol{\mu} = \left[U_g, G_s\right]$ 与时空坐标 $\boldsymbol{s} = (x,y,z,t)$，前馈全连接神经网络将输入映射为目标物理量的预测值，其中 $\boldsymbol{\Phi}$ 为网络全部可训练参数（各层权重与偏置）集合，仅决定网络结构与映射形式，并不作为输入变量。

在PINNs中，总损失由数据损失和物理损失两部分组成，设 Ω 为输入定义域，Ω_d 与 Ω_f 分别为数据监督点集合与物理约束点集合。在PINNs中，总损失由数据损失与物理损失两部分组成，如式(7)~式(9)所示。数据损失 L_{data} 表示在数据监督点集合 Ω_d 上，网络预测值与CFD参考值之间的均方误差；物理损失 L_{phy} 表示在物理约束点集合 Ω_f 上，将网络预

测的物理量代入质量守恒与动量守恒方程后得到的残差平方的平均值，并通过权重系数控制各残差项的相对贡献。考虑到L_{data}与L_{phy}在数值尺度上可能存在差异，固定权重可能导致优化不均衡、影响收敛性。为此，本文采用动态损失权重策略[28]：训练初期增大ω_{data}减小ω_{phy}以引导网络优先拟合CFD数据获得合理初值；随后逐步提高ω_{phy}，增强对守恒方程的约束，从而提升预测结果的物理一致性与泛化能力。总损失定义如下：

$$L_{\text{total}} = \omega_{\text{data}}(k)L_{\text{data}} + \omega_{\text{phy}}(k)L_{\text{phy}} \tag{7}$$

数据损失为：

$$L_{\text{data}} = \frac{1}{N_{\text{d}}}\sum_{i=1}^{N_{\text{d}}}\left\| \boldsymbol{y}(\boldsymbol{s}_i,\boldsymbol{\mu}_i) - \boldsymbol{y}^{\text{CFD}}(\boldsymbol{s}_i,\boldsymbol{\mu}_i)\right\|_2^2, (\boldsymbol{s}_i,\boldsymbol{\mu}_i) \in \Omega_{\text{d}} \tag{8}$$

物理损失由气相/颗粒相质量守恒与动量守恒残差构造。定义质量守恒残差$e_{m,\text{g}}$,$e_{m,\text{s}}$与动量守恒残差$\boldsymbol{e}_{u,\text{g}}$,$\boldsymbol{e}_{u,\text{s}}$如下：

$$\begin{aligned}
e_{m,\text{g}} &= \frac{\partial\left(\varepsilon_{\text{g}}\rho_{\text{g}}\right)}{\partial t} + \nabla\cdot\left(\varepsilon_{\text{g}}\rho_{\text{g}}\boldsymbol{u}_{\text{g}}\right)\\
e_{m,\text{s}} &= \frac{\partial\left(\varepsilon_{\text{s}}\rho_{\text{s}}\right)}{\partial t} + \nabla\cdot\left(\varepsilon_{\text{s}}\rho_{\text{s}}\boldsymbol{u}_{\text{s}}\right)\\
\boldsymbol{e}_{u,\text{g}} &= \frac{\partial\left(\varepsilon_{\text{g}}\rho_{\text{g}}\boldsymbol{u}_{\text{g}}\right)}{\partial t} + \nabla\cdot\left(\varepsilon_{\text{g}}\rho_{\text{g}}\boldsymbol{u}_{\text{g}}\otimes\boldsymbol{u}_{\text{g}}\right) + \varepsilon_{\text{g}}\nabla p - \nabla\cdot\boldsymbol{\tau}_{\text{g}} - \varepsilon_{\text{g}}\rho_{\text{g}}\boldsymbol{g} - \boldsymbol{F}_{\text{drag}}\\
\boldsymbol{e}_{u,\text{s}} &= \frac{\partial\left(\varepsilon_{\text{s}}\rho_{\text{s}}\boldsymbol{u}_{\text{s}}\right)}{\partial t} + \nabla\cdot\left(\varepsilon_{\text{s}}\rho_{\text{s}}\boldsymbol{u}_{\text{s}}\otimes\boldsymbol{u}_{\text{s}}\right) + \varepsilon_{\text{s}}\nabla p - \nabla\cdot\boldsymbol{\tau}_{\text{s}} - \varepsilon_{\text{s}}\rho_{\text{s}}\boldsymbol{g} + \boldsymbol{F}_{\text{drag}}
\end{aligned} \tag{9}$$

式中，$\boldsymbol{F}_{\text{drag}}$为基于EMMS模型计算的气固相间曳力项。基于上述残差，物理损失定义为：

$$L_{\text{phy}} = \frac{1}{N_{\text{f}}}\sum_{i=1}^{N_{\text{f}}}\left(\left|e_{m,\text{g}}^{(i)}\right|^2 + \left|e_{m,\text{s}}^{(i)}\right|^2\right) + \frac{1}{N_{\text{f}}}\sum_{i=1}^{N_{\text{f}}}\left(\left\|\boldsymbol{e}_{u,\text{g}}^{(i)}\right\|_2^2 + \left\|\boldsymbol{e}_{u,\text{s}}^{(i)}\right\|_2^2\right), (\boldsymbol{s}_i,\boldsymbol{\mu}_i) \in \Omega_{\text{f}} \tag{10}$$

动态权重采用logistic调度：

$$\omega_{\text{phy}}(k) = \frac{\omega_{\text{phy}}^{\max}}{1 + \exp\left[-\alpha(k - k_0)\right]},\quad \omega_{\text{data}}(k) = 1 - \omega_{\text{phy}}(k) \tag{11}$$

式中，$\omega_{\text{phy}}^{\max}$为物理权重上限；$\alpha$和$k_0$分别控制增长速率与拐点位置。

本文取$\omega_{\text{phy}}^{\max} = 0.6$，$\alpha = 2.0\times10^{-4}$，$k_0 = 0.5K$，其中$K$为总迭代步数。

2.2 结构超参数及训练策略

本文提出的分布式并行编码器-解码器(DPED)架构通过工况编码器和时空编码器并行提取操作参数与时空特征，并在输出端设立独立解码器分支，解耦不同物理量的预测过程，减少梯度冲突，提高训练稳定性和精度。该解耦式多任务输出结构在保持物理量间内在关联的同时，降低了梯度耦合带来的训练干扰，有利于提高各物理量预测的

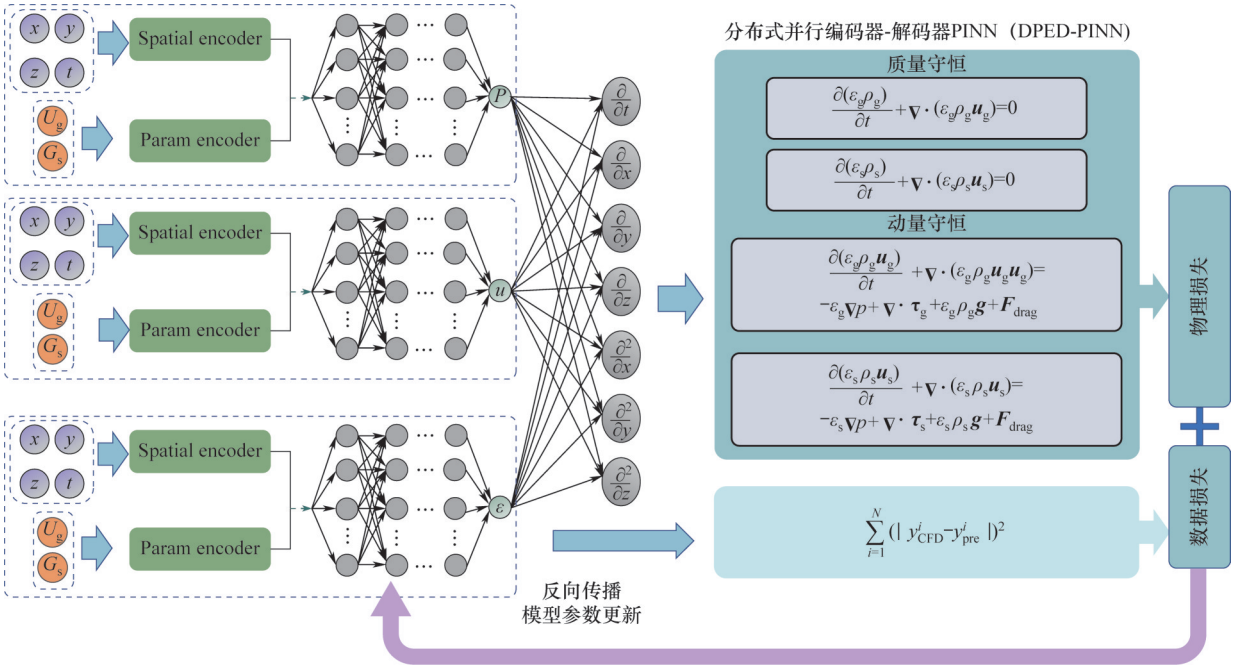


图4 DPED-PINN模型架构与训练流程示意图

Fig.4 Architecture and training workflow of the DPED-PINN model

稳定性和精度。

如图4所示，DPED-PINN以$\boldsymbol{\mu}=\left[U_{\mathrm{g}},G_{\mathrm{s}}\right]$与$\boldsymbol{s}=\left(x,y,z,t\right)$为输入。模型包含两个编码器：空间-时间编码器提取$\boldsymbol{s}$的时空特征，工况编码器提取$\boldsymbol{\mu}$的工况特征；两者的特征在融合后送入多个并行解码分支。每个解码分支对应一种目标物理量（p、$\boldsymbol{u}_{\mathrm{g}}$、$\boldsymbol{u}_{\mathrm{s}}$、$\boldsymbol{\varepsilon}_{\mathrm{s}}$等），从共享特征中解码得到相应预测值，实现多物理量的协同重构。在训练阶段，模型分别在数据监督点集$\boldsymbol{\Omega}_{\mathrm{d}}$与物理监督点集$\boldsymbol{\Omega}_{\mathrm{f}}$上计算$L_{\mathrm{data}}$与$L_{\mathrm{phy}}$，并构造总损失$L_{\mathrm{total}}$。通过反向传播计算梯度，使用优化器（如Adam）迭代更新共享编码器与各并行解码器的全部参数$\boldsymbol{\Phi}$。因此，参数更新回路代表的是“损失→梯度→参数更新”，输入参数在训练中保持不变。

模型预测结果的准确性通过峰值信噪比（peak signal to noise ratio，PSNR）和结构相似性指数（structural similarity index，SSIM）进行定量评估，其计算形式见式（12）、式（13）。

$$\mathrm{PSNR}=10\log_{10}\left(\frac{\mathrm{MAX}_I^2}{\mathrm{MSE}}\right) \tag{12}$$

$$\mathrm{SSIM}(I,K)=\frac{(2\mu_I\mu_K+C_1)(2\sigma_{IK}+C_2)}{(\mu_I^2+\mu_K^2+C_1)(\sigma_I^2+\sigma_K^2+C_2)} \tag{13}$$

式中，MAX_I是图像像素的最大可能值；MSE为均方误差；μ_I，μ_K分别为图像I和图像K的均值；σ_I，σ_K分别为图像I和图像K的标准差；σ_{IK}为协方差；C_1，C_2为常数。

PSNR值越大、SSIM值越接近1，说明重构流场与参考CFD结果之间的差异越小。网络参数采用Xavier-Glorot方法初始化[29]，优化器选用Adam，损失函数为均方误差，学习率设为1×10^{-5}；模型基于Pytorch实现，并在支持CUDA的GPU上完成训练。

2.3 考虑残差的概率密度自适应采样算法

由于数据包含时空-时序多尺度、多维度信息，如果对所有的数据点计算数据损失以及物理损失，将会大大增加计算成本。因此，采用合适的采样策略对于模型收敛、计算效率都会有明显提升。常见的采样方法主要包含随机采样以及基于考虑残差的自适应采样算法。随机采样是指在整个计算域内均匀或分层随机选取一定数量的样本点进行训练，而不考虑物理方程的残差大小。这种方法实现简单，计算开销较低，能够较好地覆盖全局数据分布。然而，由于所有点的选取均为随机分布，高误差区域可能采样不足，导致模型在这些区域的学习能力较弱，影响整体预测精度。基于残差的自适应采样方法则是在训练过程中计算物理方程残差，并优先选择残差较大的点进行训练，以增强模型对高误差区域的学习能力。这种方法能够有效减少物理方程残差，提高模型在局部复杂区域的预测能力。然而，该算法仍存在一定的局限性：首先，在每轮训练中均需计算全局残差，并调整采样分布，导致计算成本较高；其次，采样点可能过度集中在高残差区域，而低残差区域的样本，影响全局预测能力；此外，在训练初期，由于网络参数尚未优化，残差分布可能较为随机，导致采样点偏差较大，影响训练稳定性。

为避免因采样点过度集中于高残差区域而可能导致的模型局部过拟合问题，本研究引入了一种基于残差的概率密度自适应采样（residual-based probability density adaptive sampling，RPDS）策略。该方法通过构造残差加权的概率密度函数，在高残差区域增加采样点的同时，确保部分采样点来自低残差区域，使得新增训练点的分布更加均衡。具体而言，该方法根据残差值计算每个点的采样概率，并依据该概率从样本集中筛选训练点，以保证在高残差区域选取更多样本，而在低残差区域适当保留部分采样点[11]。具体公式如下所示。

基于对数的概率密度函数：

$$P(X)=\frac{\max\left(\lg\left(|r(X)|/\varepsilon\right),0\right)}{\int_{\Omega}\max\left(\lg\left(|r(X)|/\varepsilon\right),0\right)\mathrm{d}x} \tag{14}$$

式中，$r(X)$代表残差值，这里对残差取对数的原因是确保高残差点的采样概率更大，但不会过度集中；ε代表过滤小残差值的容差，主要用于过滤低残差点，防止数值噪声的影响。具体实现步骤如下。

（1）在当前模型参数下，对候选采样点集合$\chi=\prod_{i=1}^{N}x_i$中的点，计算其对应的综合残差：

$$r\left(X_i\right)=\sum_{k=1}^{K}\omega k\left|R_k(X_i)\right| \tag{15}$$

式中，$R_k(X)$表示第k项损失；ω_k^i为其对应的权重。

（2）为避免残差极大值主导采样权重，同时提升高误差区域采样概率，对残差进行对数变换并加设截断阈值ε，计算每个点的权重。

（3）将权重向量$p_i(X)$归一化，构造每个点的采样概率：

$$P_i = \frac{p_i}{\sum_{j=1}^{N} P_j}, \quad i = 1,2,3,\cdots,N \tag{16}$$

(4)根据构造的残差概率分布$P = \{P_i\}_{i=1}^{N}$，从候选点集合中以权重的方式采样N_s个点，加入原始训练集中构成下一轮的新训练集，用于更新模型参数。

(5)为实现动态更新采样策略，RPDS方法在每隔T轮训练后，重新评估候选点集合的残差值，更新采样权重与概率分布，从而实现对当前模型误差分布的自适应响应。

3 结果与讨论

3.1 DPED-PINN收敛性与计算效率分析

为评估提出的DPED-PINN模型的训练效果及收敛性能，本节记录并分析了模型在训练过程中的损失函数变化情况。

图5展示了训练过程中数据损失和物理损失的变化情况。可以看到，各损失项均随训练轮次整体下降，其中数据损失由约0.9收敛至约0.2，表明模型较好地学习了CFD数据所表征的时空映射关系；质量守恒和动量守恒相关损失在训练后期也收敛至较低水平，说明在动态权重策略作用下，物理约束逐步发挥正则化作用，使预测结果在提高数据拟合精度的同时更好地满足流体力学基本方程。为评估模型在过程模拟中的计算效率，本文对比了传统CFD方法与DPED-PINN的计算成本(表2)。在32核CPU上，欧拉-欧拉双流体模型计算单个工况约需15 h；相比之下，DPED-PINN虽需数小时的离线训练时间，但在训练完成后单工况流场重构时间约为数秒，相当于相同硬件配置下较逐工况CFD模拟实现$10^3 \sim 10^4$量级的加速，为CFB提升管多工况分析提供了高效的计算工具。

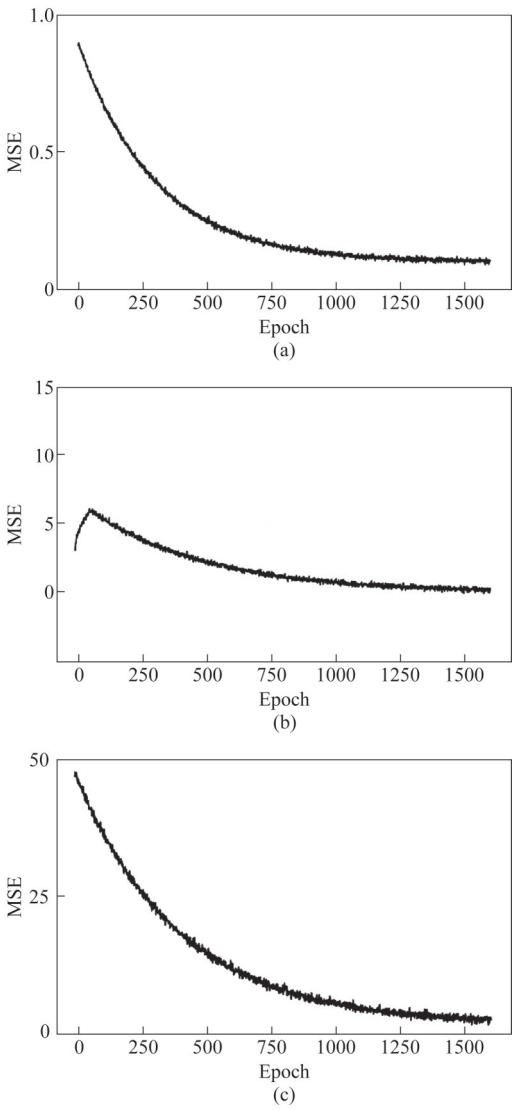


图5 DPED-PINN模型训练过程中各项的损失曲线：(a)数据损失；(b)质量损失；(c)动量损失

Fig.5 Loss curves of each term during the training of the DPED-PINN model: (a) data loss; (b) mass loss; (c) momentum loss

表2 CFD方法与DPED-PINN模型的计算时间对比

Table 2 Comparison of computational time between CFD and DPED-PINN model

方法	计算硬件	单工况计算/训练耗时	单工况预测(推理)耗时	计算加速比
CFD	CPU	15 h	—	1×
DPED-PINN	GPU	5 h	5 s	约10^4

3.2 流场重构与内插性能分析

为验证模型在训练参数范围内的重构精度，选取未经训练的内插工况case 14进行测试。

图6展示了提升管中部截面(z=0)处的流场预测结果。气固两相速度和固含率的分布与CFD结果一致，特别是能够准确捕捉流场中的速度梯度，展示了模型在复杂流动特征捕捉上的能力。误差图显示，绝大部分区域的预测误差接近零，表明模型具有较高的逐点精度。固含率方面，模型成功再现了“核-环”非均匀结构，中心稀相区和壁面颗粒聚团现象与CFD结果的偏差小于5%，进一步验证了DPED-PINN在复杂颗粒分布重构中的高精度。

图7展示了不同轴向位置(H= 2、5、8 m)处的流场重构结果。模型准确捕捉了流场中的涡旋、颗粒

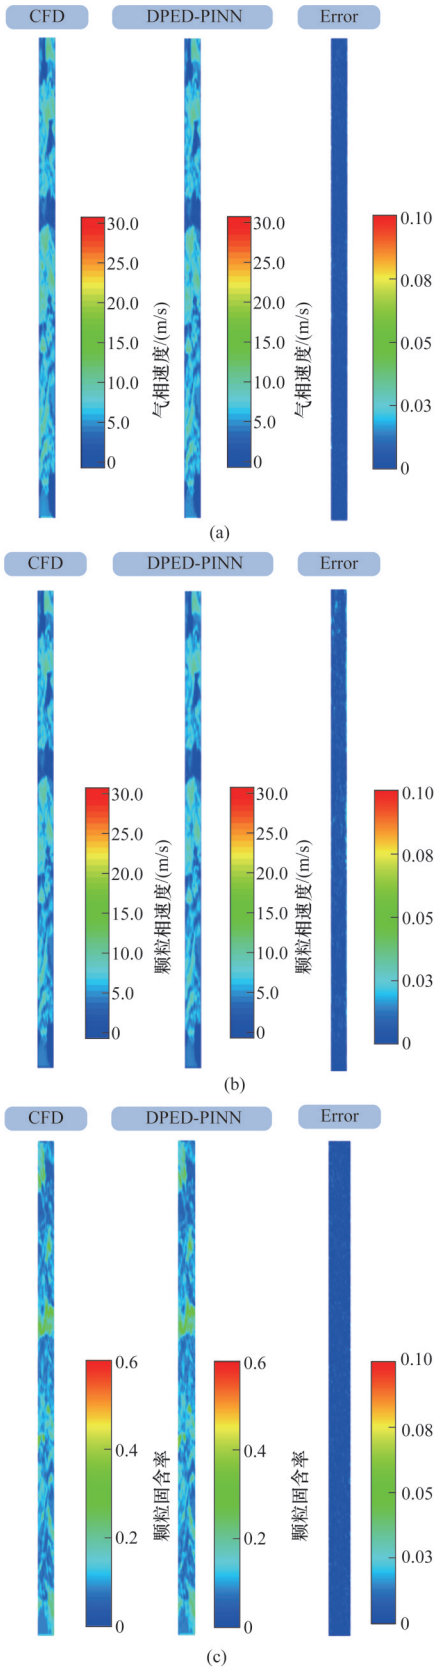


图6 t=15 s时DPED-PINN模型的气固两相流瞬态预测结果(case 14)

Fig.6 Transient prediction results of gas-solid two-phase flow by DPED-PINN model at t=15 s(case 14)

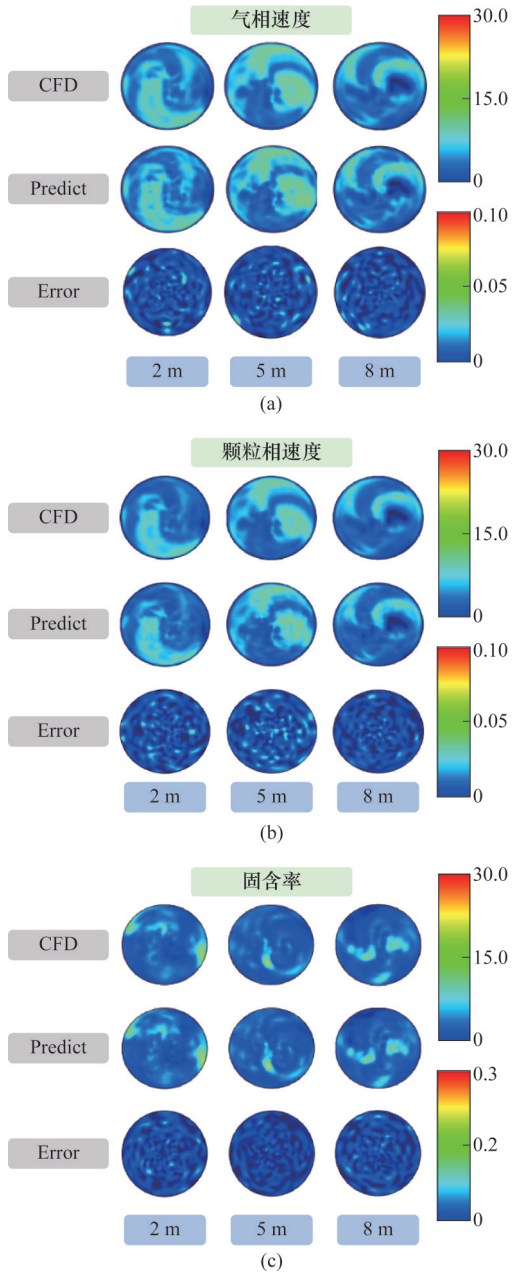


图7 不同高度(2、5、8 m)截面气固两相流参数的DPED-PINN瞬态预测与CFD对比结果(case 14)

Fig.7 Transient prediction results of gas-solid two-phase flow parameters at different height cross-sections (2, 5, 8 m) by DPED-PINN model, with comparisons to CFD simulations and prediction error distributions(case 14)

聚团等复杂流动特征,特别是能够精确再现涡旋核心的位置和颗粒团簇的几何形态。随着轴向位置的变化,瞬态涡旋和颗粒聚团的形态、尺寸和分布均发生变化,模型成功预测了这一动态演变过程。

为进一步从统计学意义上评估模型的内插性能,图8展示了case 14工况下时均固含率在轴向和不同高度径向上的分布曲线对比。从图中可以看

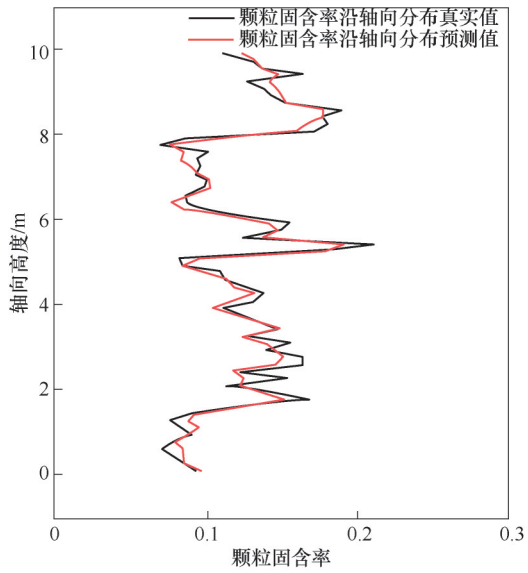


图8 颗粒固含率轴向分布真实值与预测值对比(case 14)

Fig.8 Comparison of the true value and predicted value of the axial distribution of particle solids content(case 14)

出,模型不仅准确捕捉了固含率沿提升管高度的整体变化趋势,而且其径向分布的峰值与宽度均与CFD结果吻合良好。定量上证实了模型具备高精度重构关键流动机理的能力。

3.3 流场泛化外推性能分析

在实际工程应用中,往往由于测量手段的限制或工况的多样性,无法获得所有条件下的完备数据。因此,模型必须能够基于有限的训练数据,学习其内在的物理演化规律,并据此对未知工况进行推断。为此,本节针对case 15进行评估。

图9展示了case 15外推工况下的瞬态流场重构结果,并与CFD基准数据进行对比。模型成功捕捉了高流速下的复杂瞬态流动及固含率的拖尾与聚团结构。与内插工况相比,外推工况预测误差有所增加且呈区域性集中,主要位于流动发展剧烈的提升管入口区,这归因于高通量下强湍流脉动与非线性相间作用。尽管如此,绝大部分区域逐点误差仍控制在0.1以内,表明模型在超出训练范围的极端工况下整体预测未发生显著偏离,这一预测结果也与Wang[26]关于高通量流型的实验发现契合,即当固体循环速率超过700 kg/(m^2·s)时,提升管内的气固流动将呈现出区别于低通量工况的高密度均匀流特征。如图9(c)所示,DPED-PINN重构出了全截面较高固含率且分布相对均匀的流场形态,而非低通量下典型的"环-核"结构。这种对流型转变机制的准确捕捉,证实了模型在工业级高通量操作下的

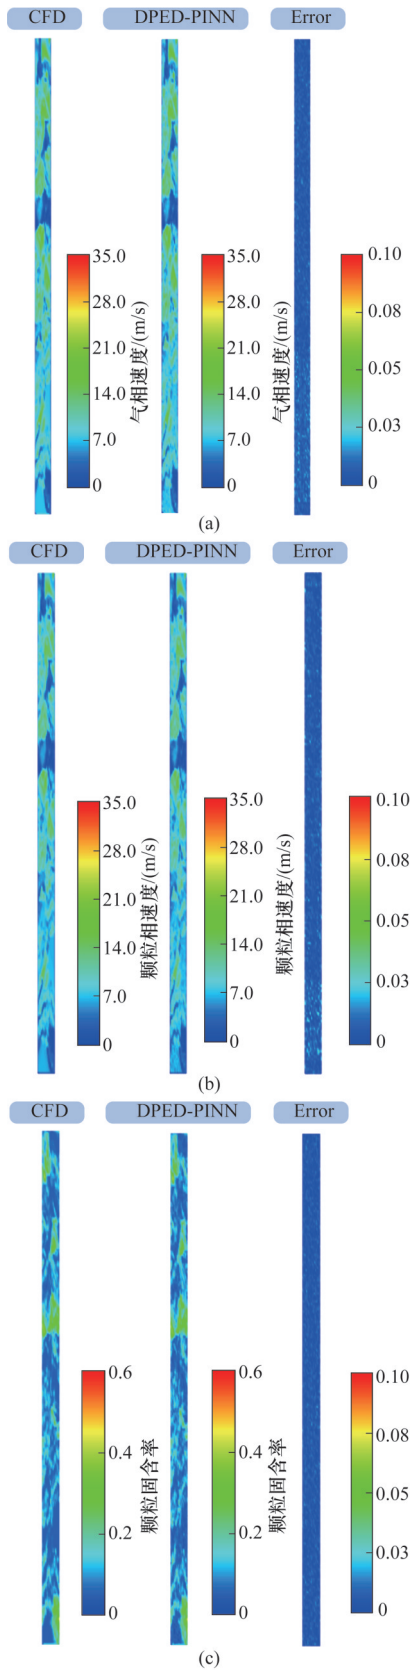


图9 t=15 s时DPED-PINN模型的气固两相流瞬态预测结果(case 15)

Fig.9 Transient prediction results of gas-solid two-phase flow by the DPED-PINN model at t=15 s(case 15)

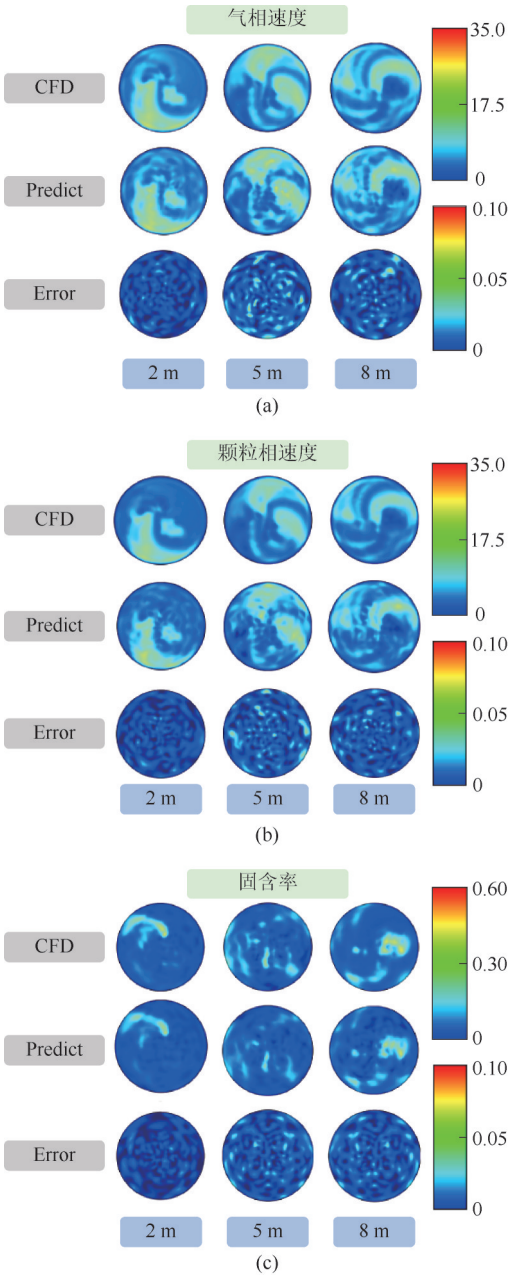


图10 不同高度(2、5、8 m)截面气固两相流参数的DPED-PINN瞬态预测与CFD对比结果(case 15)

Fig.10 Transient prediction results of gas-solid two-phase flow parameters at different height cross-sections (2, 5, 8 m) by DPED-PINN model, with comparisons to CFD simulations and prediction error distributions(case 15)

物理保真度。在对纵向流场进行分析后,进一步选取横向截面来评估模型在外推工况下的局部细节重构能力如图10所示。

从宏观分布来看,模型的预测展现出一定的物理合理性:高固含率与高速区域分布趋势正确,预测未明显偏离真实情况。模型的不足主要体现在对精细流动结构的捕捉上。具体而言,模型预测的速度场出现较多高频、颗粒化纹理,难以还原涡旋的连贯性;固含率未能再现紧凑、边界清晰的颗粒聚团,而是预测出较为弥散的高浓度区域。这些现象反映了模型在外推任务中的固有限制:当进入训练数据未覆盖的极端工况,数据驱动部分对具体流动模式的学习能力减弱,模型更依赖于其内嵌的物理约束。通过引入质量与动量守恒方程作为正则项,即使在无法准确还原局部结构的情况下,仍能有效保持速度场与浓度场在宏观上的物理合理性和数值稳定性。

图11展示了case 15颗粒通量为1159.9 kg/(m^2·s)的固含率沿提升管轴向的分布曲线对比。整体呈现出全床范围内的高密度悬浮流特征,截面平均固含率在0.15~0.25,且未出现明显的S型稀相区。模型在未知工况下仍能紧密贴合真实波动并捕捉局部峰值,验证了物理约束对提升泛化性能的关键价值。

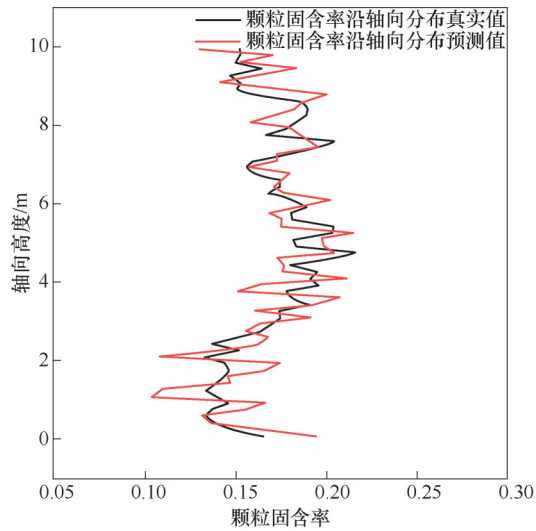


图11 颗粒固含率轴向分布真实值与预测值对比(case 15)

Fig.11 Comparison of the true value and predicted value of the axial distribution of particle solids content(case 15)

以上结果给出了t=15 s时刻流速与固含率的空间分布对比。为进一步展示特征物理量随时间的变化情况,本文在外推工况下补充给出固定测点的固含率时间序列对比,如图12所示。在轴向高度y≈7.78 m的截面上,选取r/R=0(中心)与r/R≈0.95(近壁)两处固定测点,提取t=5~25 s(Δt=0.1 s)的$\varepsilon_s(t)$固含率序列,并与CFD结果进行对比。由图12可见,模型能够较好捕捉固含率随时间演化的趋势与幅值变化,从而进一步验证了本文方法的时间一致性与泛化能力。

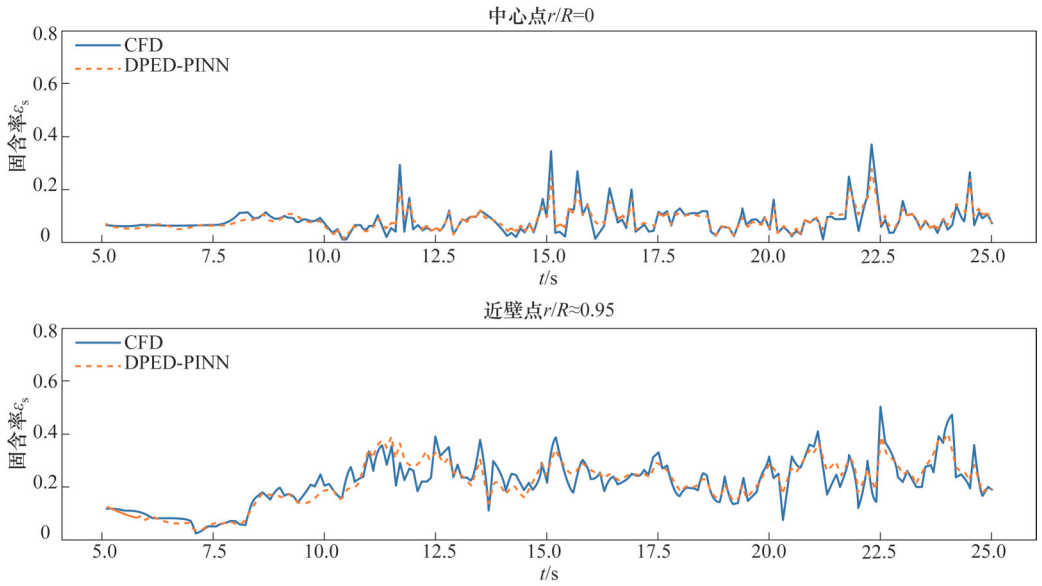


图12 外推工况固定测点固含率时间序列对比(y≈7.78 m, Δt=0.1 s)

Fig.12 Time-series comparison of solids holdup at two fixed probes for the extrapolation case (y≈7.78 m, Δt=0.1 s)

3.4 外部实验数据对比验证分析

为进一步评估所提方法在真实实验条件下的外部泛化能力,本文补充采用独立实验数据开展外部对照验证。实验数据取自文献[26]Appendix 1所公布的冷模提升管测量结果,包含不同表观气速U_g与颗粒质量通量G_s下,在多个轴向高度z与径向位置r/R的固含率与固体通量等测点数据。所选外部工况覆盖U_g=5、7、9 m/s及G_s=100~800 kg/(m^2·s)的典型操作窗口,并保证各工况在相同测点位置可对齐对比。

本文在外部验证中选取两处具有代表性的轴向高度y=3.77 m与y = 7.78 m展示径向剖面对比:在每个工况下,将模型在相同测点(z, r/R)的预测结果与实验测值逐点对照。图13给出了不同工况下固含率的径向分布对比结果;图14给出了不同工况下固体通量的径向分布对比结果。固体通量按实验口径计算,定义为:

$$J_{s,z} = \rho_s \varepsilon_s u_{s,z} \tag{17}$$

式中,ρ_s为颗粒密度;ε_s和$u_{s,z}$分别为模型预测的固含率与颗粒轴向速度分量。为避免仅凭曲线趋势判断,本文进一步给出外部对照的定量误差统计。对每一工况,将两处高度下的全部径向测点合并,计算MAPE与NRMSE,结果汇总于表3。

3.5 考虑残差的概率密度自适应采样算法的有效性分析

采样策略是影响物理信息神经网络训练效率与最终预测精度的关键因素之一。为了清晰地展示RPDS算法相较于随机采样方法的优越性,本节将其与传统的随机采样(RS)策略在模型训练的效率与效果上进行了直接对比。除采样策略外,模型的所有网络结构、超参数及训练配置均保持一致。

表3 外部实验对照的误差评价指标汇总

Table 3 Error statistics for external experimental validation

(U_g,G_s)	MAPE/%		NRMSE/%	
	固含率	固体通量	固含率	固体通量
(5, 100)	7.8	12.0	5.3	8.7
(5, 200)	8.1	12.8	5.9	9.4
(7, 200)	6.6	11.2	4.9	8.3
(7, 300)	8.9	13.7	6.5	10.1
(9, 400)	9.6	13.6	6.9	10.4
(9, 800)	9.3	11.8	6.8	8.7

图15对比了随机采样(RS)和RPDS采样在空间分布及训练收敛过程中的差异。随机采样在整个计算域内近似均匀分布,难以体现不同区域物理复杂度的差异;而RPDS采样在入口、出口等高残差区域布置了更多样本点,突出局部难点区域。相应地,两种策略下模型的损失收敛行为也存在差别:在相同训练轮次内,RPDS采样可更快降低均方误差,并获得更低的最终残差,说明该策略在给定采样预算下更有利于提高训练效率和流场预测精度。

3.6 消融实验

为深入探究物理机制约束与多目标变量解耦架构的有效性,本节进行了系统的消融实验。对比

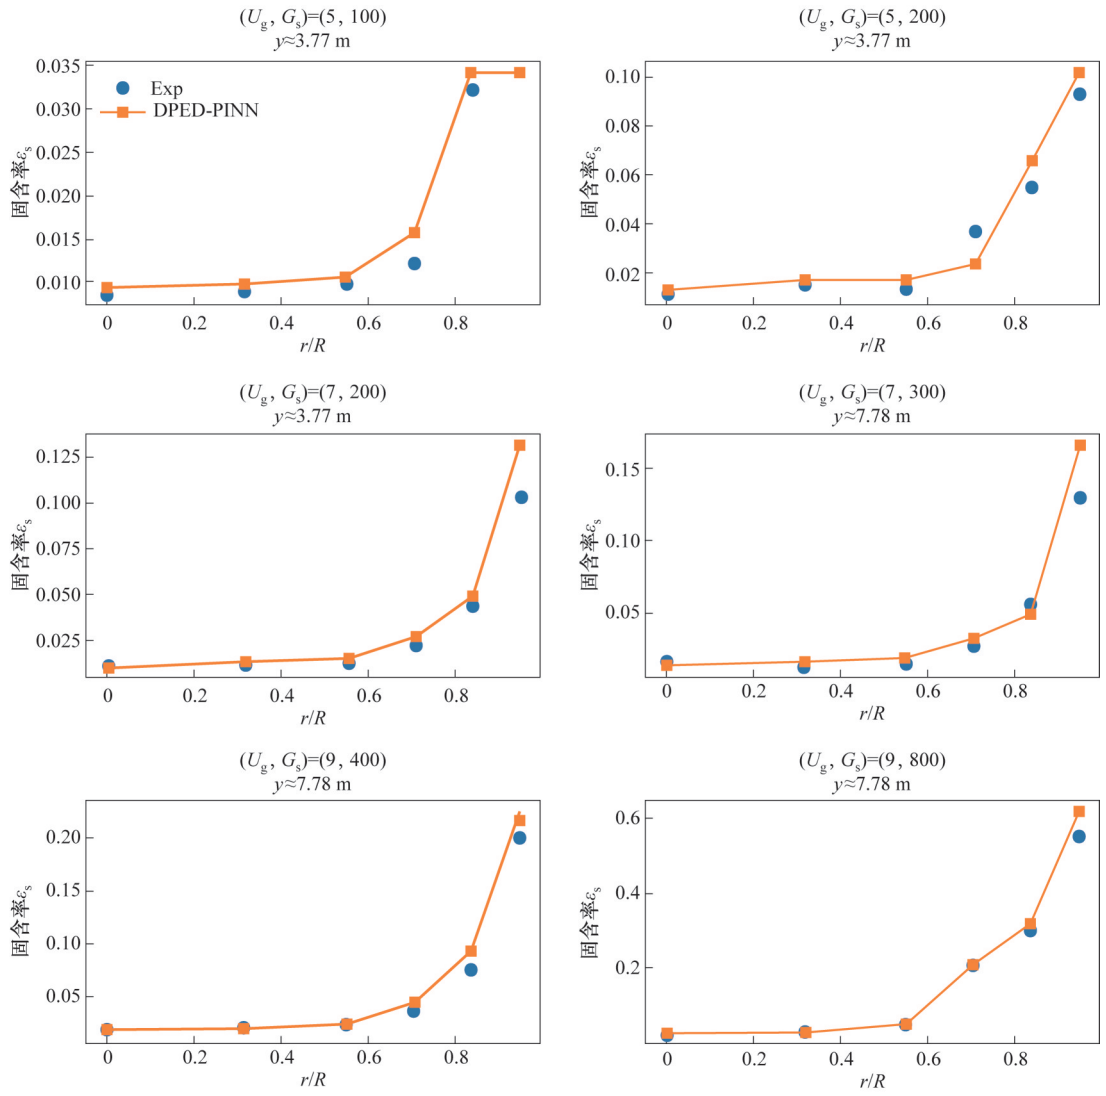


图13 实验数据验证:固含率沿径向分布对比

Fig.13 Experimental validation: radial profiles of solids holdup

模型均保持同量级的可训练参数,并采用一致的动态权重与RPDS采样算法来排除模型容量与训练策略差异的干扰。基准模型设置如下。

(1)纯数据驱动ANN模型(Baseline-1):网络结构与DPED-PINN保持一致,但损失函数仅包含数据项,用于评估物理约束对模型泛化能力的贡献。

(2)标准PINN模型(Standard PINN / Baseline-2):采用传统的全连接网络架构拼接输入单一网络,输出所有物理量。损失函数包含物理约束,但通过共享权重同时映射多物理场,旨在评估DPED分布式架构在解决多变量梯度冲突方面的优势。

如图16所示,3种模型的训练收敛行为存在明显差异。纯数据驱动ANN虽能快速降低数据损失,但物理损失始终维持在较高水平,动量残差甚至出现发散,说明其预测结果并不满足守恒方程。标准PINN在引入物理约束后物理损失有所降低,但数据损失和动量损失均出现平台期和高频振荡,表明在单网络多输出结构下,多物理量之间存在显著梯度冲突。相比之下,DPED-PINN通过多解码器结构在保持共享特征的同时部分解耦了不同物理量的优化过程,使数据损失和物理损失均能较平缓地收敛到较低水平。图17给出了3种模型在典型截面上的流场重构结果。ANN预测中存在明显的非物理高频噪声,固含率场中出现大量离散误差点;标准PINN虽消除了噪声,但固含率云图呈现显著过度平滑,颗粒聚团边界被模糊化,难以解析介尺度结构。DPED-PINN在保证流场整体平滑性的同时保留了壁面附近颗粒聚团和高梯度区域的细节,其预测结果与CFD参考场在结构上更为接近。

上述瞬态流场云图直观地揭示了两种模型在

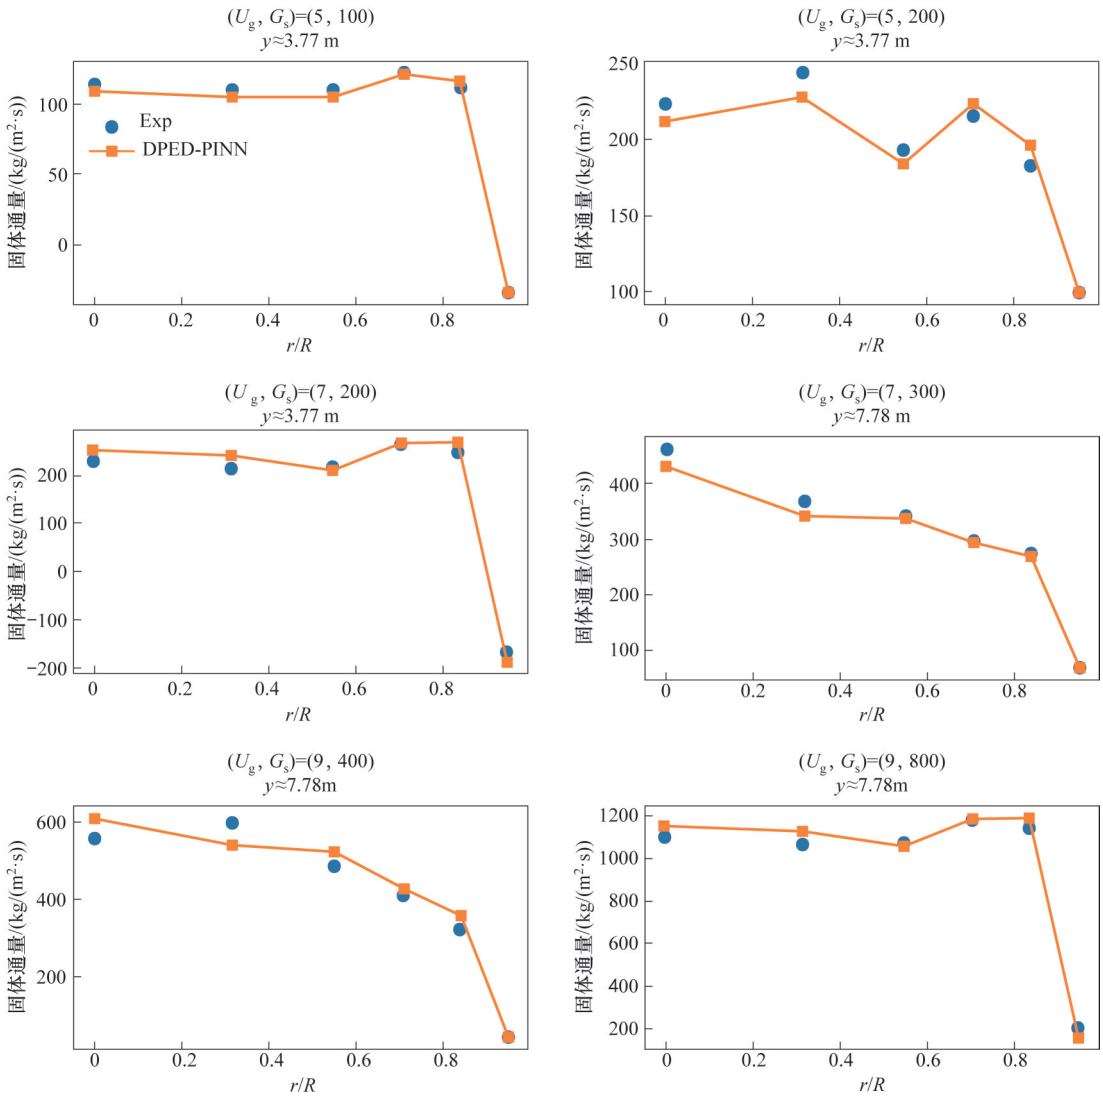


图14 实验数据验证:固体通量沿径向分布对比

Fig.14 Experimental validation: radial profiles of solids flux

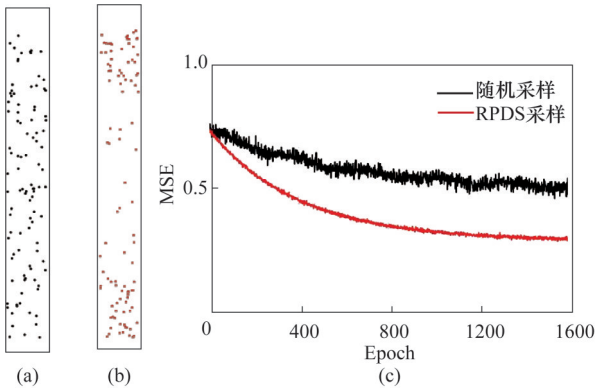


图15 (a)随机采样;(b)RPDS采样;(c)两种采样策略下的训练过程残差收敛曲线

Fig.15 (a) Random sampling; (b) RPDS sampling; (c) Convergence curves of MSE during training process under the two sampling strategies

重构流场空间结构能力上的对比。对此差异进行定量的分析,表4呈现了DPED-PINN、标准PINN与ANN在测试集case 14和case 15上的SSIM与PSNR指标对比。

在内插工况case 14下,标准PINN的SSIM和PSNR指标虽优于ANN,但仍显著低于DPED-PINN。更关键的是在外推工况case 15下,DPED-PINN依然保持了较高的预测精度,而标准PINN的性能下降幅度较大。

在此基础上,为进一步明确本文方法在更强数据驱动替代模型下的性能边界,本文选取DeepONet[30]与时空Transformer[31]作为对比模型,并在外推工况case 15下以固含率场为代表进行补充对比。相关结果从重构精度(PSNR/SSIM)、后验物

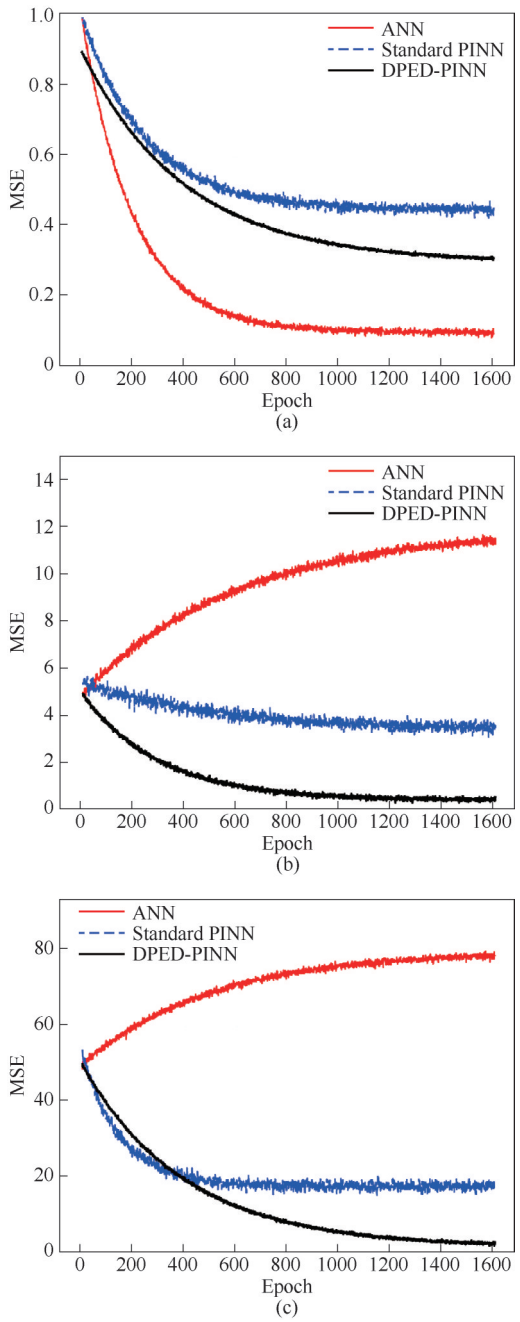


图16 DPED-PINN、Standard PINN与ANN的损失对比：(a)数据损失；(b)质量损失；(c)动量损失

Fig.16 Loss comparison of DPED-PINN, Standard PINN and ANN: (a) data loss; (b) mass loss; (c) momentum loss

理一致性L_{phy}以及模型规模与训练时长等方面进行综合评估，具体见表5。其中，后验物理一致性指标L_{phy}通过将各模型预测场代入质量与动量守恒方程并在测试采样点统计残差均方（经尺度归一化）计算得到。

由表5可见，在外推工况case 15下，DeepONet与Transformer在固含率场的PSNR/SSIM指标上能够取得较好的重构精度，但DPED-PINN的PSNR/SSIM仍保持优势。同时，DPED-PINN的后验物理一致性指标明显低于两类强基线，说明其预测固含率场在外推条件下对质量与动量守恒约束的满足程度更高。就训练代价而言，3种方法的参数量与训练耗时处于同一量级，DPED-PINN未以明显增加计算开销为代价获得性能提升。综合来看，本文方法在外推工况下不仅保持较高的场重构精度，同时能够更好地兼顾物理一致性，从而体现出相对于强数据驱动替代模型的优势边界。

表4 DPED-PINN和ANN、PINN的PSNR和SSIM值的平均值和标准差

Table 4 The average and standard deviation of PSNR and SSIM values of DPED-PINN, ANN and PINN

模型	Case	评价指标	气速	颗粒速度	固含率
DPED-PINN	case14	PSNR	$34.2_{\pm3.5}$	$37.7_{\pm3.2}$	$36.2_{\pm4.2}$
		SSIM	$0.908_{\pm0.035}$	$0.923_{\pm0.033}$	$0.911_{\pm0.025}$
	case15	PSNR	$32.6_{\pm5.5}$	$33.7_{\pm2.2}$	$32.8_{\pm3.2}$
		SSIM	$0.883_{\pm0.05}$	$0.891_{\pm0.051}$	$0.887_{\pm0.037}$
PINN	case14	PSNR	$28.5_{\pm2.1}$	$29.3_{\pm1.8}$	$29.8_{\pm2.5}$
		SSIM	$0.815_{\pm0.04}$	$0.822_{\pm0.05}$	$0.835_{\pm0.03}$
	case15	PSNR	$25.8_{\pm2.8}$	$26.5_{\pm1.5}$	$26.2_{\pm2.1}$
		SSIM	$0.765_{\pm0.05}$	$0.76_{\pm0.06}$	$0.772_{\pm0.04}$
ANN	case14	PSNR	$24.9_{\pm1.3}$	$25.1_{\pm1.4}$	$25.7_{\pm1.9}$
		SSIM	$0.758_{\pm0.045}$	$0.755_{\pm0.051}$	$0.779_{\pm0.043}$
	case15	PSNR	$22.1_{\pm1.85}$	$21.7_{\pm0.802}$	$22.3_{\pm1.75}$
		SSIM	$0.721_{\pm0.043}$	$0.708_{\pm0.056}$	$0.733_{\pm0.042}$

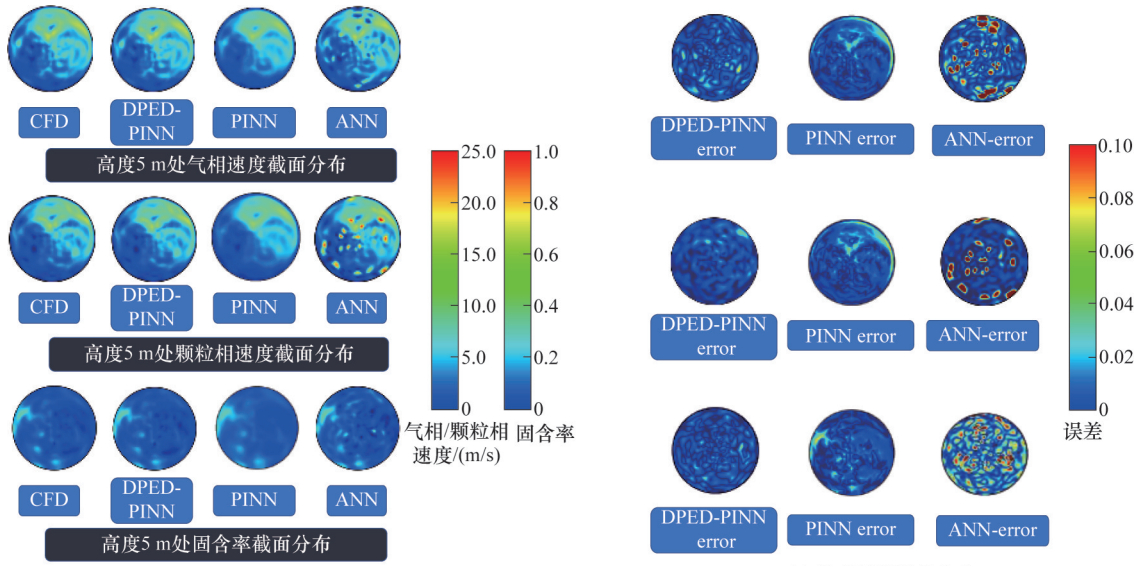
表5 外推工况（case 15）下DPED-PINN与强替代模型的综合评估指标对比

Table 5 Comprehensive comparison metrics of DPED-PINN and strong baselines under extrapolation case (case 15)

模型	Params	Time/h	ε_s-SSIM	ε_s-PSNR	L_{phy}
DeepONet	1.2×10^6	5.8	$0.845_{\pm0.05}$	$29.6_{\pm3.1}$	$2.05_{\pm0.32}\times10^{-2}$
Transformer	3.5×10^6	7.4	$0.856_{\pm0.041}$	$30.2_{\pm3.0}$	$2.28_{\pm0.35}\times10^{-2}$
DPED-PINN	2.0×10^6	5.0	$0.887_{\pm0.037}$	$32.8_{\pm3.2}$	$0.85_{\pm0.18}\times10^{-2}$

4 结 论

本研究针对循环流化床提升管内复杂气固两相流场建模困难的问题，提出融合质量与动量守恒约束的分布式并行编码器-解码器物理信息神经网络（DPED-PINN）。该方法通过特征解耦、多解码器输出和基于残差的自适应采样策略，缓解了多物理量求解中的梯度冲突，提高了模型收敛稳定性和预



(a) 不同模型的流场预测结果 (b) 模型预测误差分布

图17 H=5 m截面处气固两相流场的重构效果对比:(a) 不同模型的流场预测结果;(b) 模型预测误差分布

Fig.17 Comparison of reconstruction results of gas-solid flow field at H=5 m section: (a) flow field prediction results of different models; (b) distribution of prediction errors

测精度。结果表明,DPED-PINN能有效克服标准PINN在复杂流场预测中存在的优化停滞和过度平滑问题;在外推工况case 15下,固含率预测的结构相似性指标SSIM约为0.89,较标准PINN提高约15%,且仍能重构壁面颗粒聚团及典型流动结构,在提升外推稳定性与物理一致性方面发挥作用。除空间分布快照对比外,固定测点固含率时间序列对比表明,中心与近壁位置的固含率随时间演化趋势及主要波动幅值与CFD参考结果一致性较好。进一步引入文献公开的独立实验测点数据(未参与模型训练)进行外部对照,在多组气速与颗粒质量通量条件下,固含率与固体通量的径向分布预测与实验测值总体吻合;MAPE与NRMSE的误差统计范围分别为6.6%~13.7%与4.9%~10.4%。总体而言,该物理-数据融合框架为CFB提升管多工况分析和计算加速提供了兼具物理一致性与计算效率的建模途径。面向更复杂的工程应用,将此类框架与传热传质过程及反应动力学方程进一步耦合,并结合工业装置运行数据与过程系统级模型,有望提升其在复杂工况下的适用性,并拓展至多相反应器的数字化建模与优化分析。

符 号 说 明

C_D——曳力系数

d_p——颗粒聚团当量直径,μm

F_{drag}——气固相间曳力

G_s——颗粒质量通量,kg/(m^2·s)

g——重力加速度,m/s^2

L_{total},L_{data},L_{pht}——分别为总损失,数据损失,物理损失

N——采样点数量

P_i——采样概率

r/R——无量纲径向坐标

t——时间,s

U_g——表观气速,m/s

$\boldsymbol{u}$——速度矢量

x,y,z——空间坐标, m

ε_s——固相体积分数(固含率)

ρ——密度,kg/m^3

τ——应力张量,Pa

Φ——神经网络可训练参数集合

Ω——输入定义域

ω——损失函数权重

参考文献

[1] Chew J W, LaMarche W C Q, Cocco R A. 100 years of scaling up fluidized bed and circulating fluidized bed reactors[J]. Powder Technology, 2022, **409**: 117813.

[2] Razzak S A. Flow characteristic studies on the gas-liquid-solid circulating fluidized bed based on system stability[J]. International Journal of Multiphase Flow, 2019, **113**: 279-288.

[3] 金涌, 程易, 白丁荣, 等. 中国流态化技术研发史略[J]. 化工进展, 2023, **42**(6): 2761-2780.
Jin Y, Cheng Y, Bai D R, et al. Fluidization research and development in China[J]. Chemical Industry and Engineering

Progress, 2023, **42**(6): 2761-2780.

[4] 岳光溪, 吕俊复, 徐鹏, 等. 循环流化床燃烧发展现状及前景分析[J]. 中国电力, 2016, **49**(1): 1-13.
Yue G X, Lu J F, Xu P, et al. The up-to-date development and future of circulating fluidized bed combustion technology[J]. Electric Power, 2016, **49**(1): 1-13.

[5] Zhu X L, Xu Y, Tu Q Y, et al. Advanced measurement techniques for gas-solids fluidized beds in the power and energy industry — a review[J]. Measurement: Energy, 2024, **4**: 100030.

[6] 徐硕, 毕可鑫, 邱彤, 等. 智能过程系统工程(iPSE): 当过程系统工程与新一代人工智能相遇[J]. 化工进展, 2026, **45**(4): 1877-1889.
Xu S, Bi K X, Qiu T, et al. Intelligent process systems engineering (iPSE): When process systems engineering meets new generation artificial intelligence[J]. Chemical Industry and Engineering Progress, 2026, **45**(4): 1877-1889.

[7] Alobaid F, Almohammed N, Massoudi Farid M, et al. Progress in CFD simulations of fluidized beds for chemical and energy process engineering[J]. Progress in Energy and Combustion Science, 2022, **91**: 100930.

[8] Brunton S L, Noack B R, Koumoutsakos P. Machine learning for fluid mechanics[J]. Annual Review of Fluid Mechanics, 2020, **52**: 477-508.

[9] Zhu L T, Chen X Z, Ouyang B, et al. Review of machine learning for hydrodynamics, transport, and reactions in multiphase flows and reactors[J]. Industrial & Engineering Chemistry Research, 2022, **61**(28): 9901-9949.

[10] Upadhyay M, Nagulapati V M, Lim H. Hybrid CFD-neural networks technique to predict circulating fluidized bed reactor riser hydrodynamics[J]. Journal of Cleaner Production, 2022, **337**: 130490.

[11] 黄正梁, 王超, 李少硕, 等. 基于深度学习的气液固三相反应器图像分析方法及应用[J]. 化工学报, 2020, **71**(1): 274-282.
Huang Z L, Wang C, Li S S, et al. Development and application of image analysis method based on deep-learning in gas-liquid-solid three-phase reactor[J]. CIESC Journal, 2020, **71**(1): 274-282.

[12] Zhong H B, Sun Z N, Zhu J, et al. Prediction of solid holdup in a gas-solid circulating fluidized bed riser by artificial neural networks[J]. Industrial & Engineering Chemistry Research, 2021, **60**(8): 3452-3462.

[13] Bazai H, Kargar E, Mehrabi M. Using an encoder-decoder convolutional neural network to predict the solid holdup patterns in a pseudo-2D fluidized bed[J]. Chemical Engineering Science, 2021, **246**: 116886.

[14] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational Physics, 2019, **378**: 686-707.

[15] Raissi M, Yazdani A, Karniadakis G E. Hidden fluid mechanics: learning velocity and pressure fields from flow visualizations[J]. Science, 2020, **367**(6481): 1026-1030.

[16] Buhendwa A B, Adami S, Adams N A. Inferring incompressible two-phase flow fields from the interface motion using physics-informed neural networks[J]. Machine Learning with Applications, 2021, **4**: 100029.

[17] 张橙, 李雪, 叶茂, 等. 物理信息神经网络在两相流中的应用[J]. 化工学报, 2024, **75**(11): 3835-3856.
Zhang C, Li X, Ye M, et al. Application of physics-informed neural network in two-phase flow[J]. CIESC Journal, 2024, **75**(11): 3835-3856.

[18] Wang S F, Teng Y J, Perdikaris P. Understanding and mitigating gradient flow pathologies in physics-informed neural networks[J]. SIAM Journal on Scientific Computing, 2021, **43**(5): A3055-A3081.

[19] Anagnostopoulos S J, Toscano J D, Stergiopulos N, et al. Residual-based attention in physics-informed neural networks[J]. Computer Methods in Applied Mechanics and Engineering, 2024, **421**: 116805.

[20] Yang M Y, Foster J T. Multi-output physics-informed neural networks for forward and inverse PDE problems with uncertainties [J]. Computer Methods in Applied Mechanics and Engineering, 2022, **402**: 115041.

[21] Yu J, Lu L, Meng X H, et al. Gradient-enhanced physics-informed neural networks for forward and inverse PDE problems [J]. Computer Methods in Applied Mechanics and Engineering, 2022, **393**: 114823.

[22] Ge W, Li J H. Physical mapping of fluidization regimes: the EMMS approach[J]. Chemical Engineering Science, 2002, **57**(18): 3993-4004.

[23] 陈恺成, 田于杰, 李飞, 等. 基于EMMS的循环流化床流域研究[J]. 化工学报, 2020, **71**(7): 3018-3030.
Chen K C, Tian Y J, Li F, et al. EMMS-based flow regime study of circulating fluidized beds[J]. CIESC Journal, 2020, **71**(7): 3018-3030.

[24] Gidaspow D, Bacelos M S. Kinetic theory based multiphase flow with experimental verification[J]. Reviews in Chemical Engineering, 2018, **34**(3): 299-318.

[25] Yang N, Wang W, Ge W, et al. CFD simulation of concurrent-up gas-solid flow in circulating fluidized beds with structure-dependent drag coefficient[J]. Chemical Engineering Journal, 2003, **96**(1/2/3): 71-80.

[26] Wang C. High density gas-solids circulating fluidized bed riser and downer reactors[D]. Ontario: The University of Western Ontario, 2013.

[27] Garud S S, Karimi I A, Kraft M. Design of computer experiments: a review[J]. Computers & Chemical Engineering, 2017, **106**: 71-95.

[28] Li S R, Feng X L. Dynamic weight strategy of physics-informed neural networks for the 2D Navier-Stokes equations[J]. Entropy, 2022, **24**(9): 1254.

[29] Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks[C]//Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics, 2010: 249-256.

[30] Lu L, Jin P Z, Pang G F, et al. Learning nonlinear operators *via* DeepONet based on the universal approximation theorem of operators[J]. Nature Machine Intelligence, 2021, **3**(3): 218-229.

[31] Zhou H Y, Zhang S H, Peng J Q, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, **35**(12): 11106-11115.