

基于时空序列模型的流量计计量性能预测方法*

郭素娜^{1,2} 王千慧^{1,2} 韩佳文^{1,2} 方立德^{1,2}

(1. 河北大学质量技术监督学院 保定 071002; 2. 零碳能源建筑与计量技术教育部工程研究中心 保定 071002)

摘要:针对传统计算流体力学(computational fluid dynamics, CFD)方法在流量计计量性能分析中计算效率低、网格依赖性强、实时性不足等问题,引入深度学习技术,构建了一种基于时空序列模型 PredRNN_V2 的流量计计量性能预测方法。在单边文丘里流量计内部流场预测任务中,将稳态 CFD 求解过程中的迭代流场演化建模为时空序列预测问题,构建了从数据获取、预处理到模型训练与评估的完整流程。选取 ConvLSTM、PredRNN 与 PredRNN_V2 进行对比,并采用均方误差(mean squared error, MSE)、结构相似性(structural similarity index, SSIM)、感知损失(learned perceptual image patch similarity, LPIPS)和峰值信噪比(peak signal-to-noise ratio, PSNR)作为评价指标对预测性能进行定量评估。结果表明, PredRNN_V2 输出的 MSE 增长最缓,平均 PSNR 达 36.8,显著高于 PredRNN 和 ConvLSTM, PredRNN_V2 的平均 SSIM 为 0.92、LPIPS 为 0.069,表明其预测结果噪声更低、速度云图边界更加清晰,在保持较高计算效率的同时,其预测精度显著优于其他两个模型。PredRNN_V2 的预测结果与仿真结果的相对误差在 $\pm 5\%$ 以内,表明其在流场预测中具有可靠性和准确性。

关键词: 时空序列模型; 性能预测; 单边文丘里流量计; CFD 仿真

中图分类号: TH701; TP183; TN98 **文献标识码:** A **国家标准学科分类代码:** 460.4020

Measurement performance prediction method for flowmeters based on spatio-temporal sequence model

Guo Suna^{1,2} Wang Qianhui^{1,2} Han Jiawen^{1,2} Fang Lide^{1,2}

(1. College of Quality and Technical Supervision, Hebei University, Baoding 071002, China; 2. Engineering Research Center of Zero-carbon Energy Buildings and Measurement Techniques, Ministry of Education, Baoding 071002, China)

Abstract: To the problems of low computational efficiency, strong grid dependence, and insufficient real-time performance in the traditional computational fluid dynamics (CFD) method for flowmeter performance analysis, deep learning technology was introduced to construct a flowmeter performance prediction method based on a spatiotemporal sequence model PredRNN_V2. In the task of predicting the internal flow field of a unilateral Venturi flowmeter, the iterative flow field evolution during the steady-state CFD solution process was modeled as a spatiotemporal sequence prediction problem, and a complete process from data acquisition, preprocessing to model training and evaluation was constructed. ConvLSTM, PredRNN, and PredRNN_V2 were selected for comparison, and mean squared error (MSE), structural similarity index (SSIM), learned perceptual image patch similarity (LPIPS), and peak signal-to-noise ratio (PSNR) were used as evaluation indicators to quantitatively assess the prediction performance. The results showed that the MSE output by the PredRNN_V2 model increased the most slowly, with an average PSNR of 36.8, significantly higher than PredRNN and ConvLSTM. The average SSIM of PredRNN_V2 was 0.92, and the LPIPS was 0.069, indicating that its prediction results had lower noise and clearer cloud boundary, and its prediction accuracy was significantly superior to the other two models while maintaining a high computational efficiency. The relative error between the prediction results of the PredRNN_V2 model and the simulation results was within $\pm 5\%$, indicating the reliability and accuracy of the model in predicting the flow field.

Keywords: spatio-temporal sequence model; performance prediction; unilateral venturi flowmeter; CFD simulation

0 引言

近年来深度学习技术发展迅速,为克服传统计算流体力学 (computational fluid dynamics, CFD) 仿真方法在计算效率、网格依赖性和实时性方面的固有局限提供了新的思路。深度学习模型凭借其强大的非线性表达能力和自动特征提取能力,正逐步革新传统数值计算的范式。

郭素娜等^[1]基于传统 CFD 仿真方法研究了 DN16 圆柱齿轮流量计性能随装配间隙变化的规律,分析了装配间隙对圆柱齿轮流量计测量性能的影响机理。李中翔等^[2]针对双管型科氏质量流量传感器结合有限元仿真与实验分析,揭示了结构刚度对非线性响应的关键影响。马馨玥等^[3]利用 CFD 仿真的方法研究了非标准音速喷嘴的流动特性。

为追求更高效率,研究者尝试构建端到端的深度学习模型来近似甚至替代传统求解器。Maulik 等^[4]探索构建基于机器学习的代理模型替代传统湍流模型,通过增大松弛因子显著提升稳态求解器收敛效率(提速约 5 倍),但主要针对特定模型或稳态问题,对瞬态、复杂非稳态流动的普适性及长期预测能力有待验证,且对整体计算流程的加速程度有限。Tompson 等^[5]利用卷积神经网络 (convolutional neural network, CNN) 近似线性投影过程,将流体求解重构为无监督学习问题,在二维/三维验证中展示了高精度与高效性。Kochkov 等^[6]开发的机器学习增强求解器,通过替换对分辨率敏感的组件,在网格分辨率降低一个数量级时仍保持高精度,计算效率提升约 80 倍。其主要挑战在于模型的可解释性、对复杂边界条件和物理约束的严格满足能力,以及长时间序列预测的误差累积问题。

为了在加速的同时更好地融入物理知识,Obiols-Sales 等^[7]提出的 CFDNet 将 RANS 模拟与 CNN 耦合,有效提升整体仿真收敛速度。Zhong 等^[8]基于反向传播神经网络建立预测模型,利用多相流 CFD 数据训练,显著降低了反应器组分分布预测耗时。Jeon 等^[9]开发的有限体积法神经网络 (FVMN) 则融合了物理信息损失函数,用于高效预测非稳态反应流的瞬态特性。

除了模型架构创新,实现深度学习模型与 CFD 软件的高效集成至关重要,这关系到方法的实用性和推广潜力。Weiner 等^[10]开发的 flowTorch 软件包增强了流体仿真数据分析与后处理的灵活性。Maulik 等^[11]利用 TensorFlow C API 构建数据模块,实现了深度学习模型与 OpenFOAM 的实时集成。Jeon 等^[12]建立了基于 OpenFOAM 的 ML-CFD 交叉耦合迁移学习框架。

为解决传统 CFD 数值计算方法计算机资源消耗、前处理流程复杂和计算效率低的问题,并针对现有深度学

习流场预测方法在长时间序列、精细局部特征捕捉和物理一致性方面的挑战,本文将深度学习技术深度引入到单边文丘里流量计内部流场的预测任务中,利用时空序列模型 PredRNN_V2 的特性,构建高效、高精度的流场预测框架,以期对复杂流场的实时或近实时预测奠定理论基础,同时也为流量计的性能预测与优化设计开拓新的思路。

1 基于时空序列模型的流场预测方法

1.1 方法思路和步骤

基于时空序列模型的流场预测方法具体思路为:首先借助 Fluent 软件开展数值模拟工作,获取流场数据。运用 Python 程序对所得数据进行预处理,并且把数据划分为训练集、验证集和测试集。依据递归神经网络设计网络架构,完成参数配置以及模型参数的初始化。利用数据加载器导入训练数据后,使用准备好的数据对模型进行训练,生成初步预测结果。在这个过程中,通过对比预测帧与真实帧之间的误差,借助反向传播算法计算误差梯度,并且以此来更新模型参数配置,最终保存表现最优的模型参数配置。训练结束后,使用测试集中的新数据对模型进行验证,将输入数据送入模型,快速生成流场预测结果。

1.2 记忆解耦与学习策略

PredRNN_V2^[13]网络是一种针对时空序列建模优化的深层时序递归结构,具有更强的时空记忆能力,用于预测未来帧。PredRNN_V2 引入了一种结合反向计划采样和计划采样^[14]的动态学习策略。该策略是用来平衡训练稳定性和泛化性,避免误差累计,决定在训练过程中何时使用真实帧或者模型预测的帧作为下一时间步的输入。

PredRNN_V2 引入记忆解耦机制,把短期记忆和长期记忆解耦,让双向记忆通道的时空 LSTM (spatiotemporal LSTM, ST-LSTM) 模块能够同时处理短期细节和长期动态。PredRNN_V2 还引入了一个显式解耦损失函数,该函数使短期记忆和长期记忆在隐空间中的距离最大化,防止二者纠缠,用余弦相似度定义解耦损失,让两个存储状态增量在任何时间步长都正交。解耦损失函数定义如下:

$$\Delta C_t^l = W_{\text{decouple}} \cdot (i_t \odot g_t) \quad (1)$$

$$\Delta M_t^l = W_{\text{decouple}} \cdot (i_t' \odot g_t') \quad (2)$$

$$\mathcal{L}_{\text{decouple}} = \sum_i \sum_l \sum_c \frac{|< \Delta C_t^l, \Delta M_t^l >_c|}{\|\Delta C_t^l\|_c \cdot \|\Delta M_t^l\|_c} \quad (3)$$

式中: W_{decouple} 是所有 ST-LSTM 单元共享的 1×1 卷积; $< \cdot, \cdot >_c$ 和 $\|\cdot\|_c$ 分别表示通道 c 上的点积和平坦特

征图的 L_2 范数。

通过最小化 $\mathcal{L}_{\text{decouple}}$, ST-LSTM 鼓励短期记忆和长期记忆在隐空间中保持正交性,从而充分发挥两者的建模能力。最终模型以完全无监督的方式进行端到端训练。总体训练目标如式(4)所示。

$$\mathcal{L}_{\text{final}} = \sum_{t=2}^{T+K} \|\chi_t - \chi_t\|_2^2 + \beta \mathcal{L}_{\text{decouple}} \quad (4)$$

式中: $\sum_{t=2}^{T+K} \|\chi_t - \chi_t\|_2^2$ 是在每个时间步对网络输出起作用的重建损失; β 是解耦损失权重; $\mathcal{L}_{\text{decouple}}$ 是解耦正则项。

1.3 预测效果评价方法

为了定量地评估模型的预测结果,选择均方误差(mean squared error, MSE)、结构相似性(structural similarity index, SSIM)^[15]、感知损失(learned perceptual image patch similarity, LPIPS)^[16]、峰值信噪比(peak signal-to-noise ratio, PSNR)作为指标对所训练的模型性能进行评估。

MSE 是真实帧与预测帧之间每个对应像素差值平方的平均值,其计算公式如式(5)所示。

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 \quad (5)$$

式中: Y 表示真实帧中第 i 个像素的值; $\hat{Y}$ 表示预测帧中第 i 个像素的值; $\hat{Y}$ 表示总像素数(图像高度×宽度×通道数)。

SSIM 用来衡量 2 张图像的结构相似度。SSIM 越接近 1,预测图像与真实图像的结构相似度越高,其计算公式如式(6)所示。

$$\text{SSIM}(x, g) = \frac{(2\mu_x\mu_g + c_1)(2\sigma_{xg} + c_2)}{(\mu_x^2 + \mu_g^2 + c_1)(\sigma_x^2 + \sigma_g^2 + c_2)} \quad (6)$$

式中: x 和 g 分别是真实图像和生成图像; μ_x 和 μ_g 分别是图像 x 和 g 的平均亮度; σ_x^2 和 σ_g^2 分别是图像 x 和 g 的方差; σ_{xg} 是图像 x 和 g 之间的协方差; c_1 和 c_2 是常数,用于避免分母为 0。

LPIPS 用来衡量图像的感知差异, LPIPS 值越小,说明预测图像与真实图像在感知上的相似度越高,其计算公式如式(7)所示。

$$\text{LPIPS}(x, y) = \frac{1}{N} \sum_{i=1}^N w_i \cdot d_i(x, y) \quad (7)$$

式中: N 是特征图的数量; w_i 是每个特征图的权重; $d_i(x, y)$ 是第 i 个特征图上的距离度量。

PSNR 用于衡量图像的质量的指标。数值越大,意味着生成图像与真实图像越接近。一般认为当 PSNR 大于 30 时,图像质量处于较好的水平^[17]。其计算公式如式(8)所示。

$$\text{PSNR}(x, g) = 10 \cdot \lg\left(\frac{\text{MAX}^2}{\text{MSE}(x, g)}\right) \quad (8)$$

式中: MAX 是图像的最大像素值; $\text{MSE}(x, g)$ 是真实图像 x 和生成图像 g 之间的均方误差。

2 性能预测方法应用实例

2.1 研究对象

以 DN50 单边文丘里流量计为对象,实验样机如图 1 所示。




图 1 单边文丘里流量计实验样机

Fig. 1 Experimental prototype of Venturi flowmeter

通过测量差压值计算出单边文丘里流量计的流量值,如式(9)所示。

$$q_v = \frac{C}{\sqrt{1-\beta^4}} \frac{\pi}{4} d^2 \sqrt{\frac{2}{\rho} \Delta P_1} \quad (9)$$

式中: C 为流出系数, β 为孔径比; ρ 为流体介质的密度; d 为节流件的开孔直径; ΔP_1 为 P_1 与 P_2 的差值。

根据单边文丘里流量计实验样机结构参数,运用三维建模软件 Solidworks 建立仿真模型。为确保流入单边文丘里管段的流体达到充分发展状态,分别在上游和下游增加 $5D$ (D 为管道直径) 和 $10D$ 的直管段。三维仿真模型如图 2 所示。



图 2 单边文丘里流量计模型

Fig. 2 Unilateral Venturi flowmeter model diagram

将三维模型导入 Gambit 软件,对其内部流场进行网格划分。在前后直管段区域,选用结构化网格。由于流动较为复杂,在单边文丘里所在区域则采用非结构化网格。经过划分后,网格总数达到 1 021 万。

2.2 数据集构造

利用 Fluent 软件对单边文丘里流量计内部流场进行仿真,以获取流场数据。流体介质为常温水,流量分别为 4、7、10、14、21 和 30 m^3/h 。在数据采集过程中,每个工况的稳态仿真计算共迭代 10 000 步,每迭代 10 步输出一帧完整的流场信息。样本构造采用滑动窗口技术,每个样本包含 20 帧连续迭代数据,其中前 10 帧作为模型输

入,后 10 帧作为预测目标。

数据采集通过 Tecplot 软件后处理实现,将流场特征参数以时间序列 PNG 图像格式导出。使用 Python 程序对收集的图像进行统一处理,具体处理步骤如下。

1)数据预处理,采用 Python 图像处理库将原始图像转换为三维张量结构(高度×宽度×通道)。

2)数据集划分,按照连续迭代区间对数据进行划分,将不同迭代区间的数据按照 8 : 1 : 1 的比例将样本分配至训练集、验证集和测试集。

3)时序特征提取,应用滑动窗口算法对长时序数据进行分段处理。核心原理是通过固定长度窗口在时间轴上的连续滑动,将原始序列划分为具有局部相关性的子序列。设置窗口长度为 20 帧,滑动步长为 1 帧。

4)特征降维处理,对单帧图像实施分块操作,将高维图像数据转换为低维特征序列,显著降低计算复杂度。最后构建数据迭代器,实现批量化数据供给。

2.3 网络训练

PredRNN_V2 采用自适应学习率算法进行学习率自下降。PredRNN_V2 网络训练参数如表 1 所示。

表 1 PredRNN_V2 网络训练参数

Table 1 Training parameters of the PredRNN_V2 network

训练参数	优化器	损失函数	训练轮次	批量大小	学习率	解耦系数
参数值	Adam	MSE+ $\mathcal{L}_{\text{decouple}}$	1 000 (早停)	4	0.000 1	0.01

将处理好的样本数据输送到 PredRNN_V2 网络进行训练。经过训练,得到了可以预测流场时间序列的模型,其损失值 Loss 经过 200 轮迭代后下降非常缓慢,逐渐趋于稳定。在经过 400 轮迭代后, Loss 下降到 0.000 4,实现了很好的拟合效果,停止训练。

2.4 效果评价

ConvLSTM^[18-19]是一种专为时空序列预测设计的递归神经网络变体,其核心创新在于将传统 LSTM 单元中的全连接操作替换为卷积操作。PredRNN^[20]是一种专为长时序时空预测设计的高级递归神经网络,被视为 ConvLSTM 的进阶架构,通过引入双记忆流机制显著提升了复杂动态系统的建模能力。为验证 PredRNN_V2 网络对内流场的预测性能效果,针对流量为 21 m³/h 的流场,将迭代次数为 1~10 次与 140~150 次的仿真结果作为输入,所有流场云图对比均基于相同的模型输入帧数与预测步长生成,在可视化过程中不同输入采用不同的色标范围,分别采用 3 种方法进行预测并与仿真结果对比,如图 3 所示。

由图 3 可知, PredRNN 模型能捕捉基本结构,但在压力梯度变化显著处的细节存在不足; ConvLSTM 模型的预测结果与真实图像差异较大; 相较于 PredRNN 和




图 3 3 种模型预测结果与仿真结果对比图

Fig. 3 Comparison chart of prediction results from three models and simulation results

ConvLSTM, PredRNN_V2 生成的压力分布图像在颜色表征和区域界定上最接近真实情况,其在压力分布预测的准确性和流场动态捕捉能力上具有显著优势。

使用 1.3 节中定义的指标对 3 种模型的预测结果进行定量评估,结果如图 4 所示。





图 4 不同模型的逐帧预测结果对比图

Fig. 4 Frame-wise prediction results of different models


由图 4 可知,随着时间步的增加,3 种模型的 MSE 与 LPIPS 均在逐渐增加,但是 PredRNN_V2 的 MSE 的上升斜率最缓,说明其对流量计高速流动突变特征的鲁棒建模能力强。PredRNN_V2 的 PSNR 平均值为 36.8,远高

于 PredRNN 和 ConvLSTM, 表明其预测结果噪声更低、速度云图边界更清晰。PredRNN_V2 的平均 SSIM 达 0.92, 明显优于另外两个模型, 表明该模型能够精准捕捉流量计内部的复杂流动特征。PredRNN_V2 的 LPIPS 平均值仅为 0.069, 表明该模型的预测结果在人类视觉层面与真实流场高度一致。

为了验证 PredRNN_V2 模型对流量计性能的预测效果, 分别从预测流场和仿真流场中提取压力信息, 并计算前差压和后差压。前差压为 P_1 与 P_2 的差值, 表征单边文丘里流量计的灵敏度; 后差压为 P_3 与 P_2 的差值, 表征单边文丘里流量计的压损大小。借助图例解析算法提取预测帧的数据, 进行数据处理。将迭代次数为 1~10 次与 9 970~9 980 次的仿真结果作为输入, 将预测与仿真得到的前后差压结果进行对比如图 5 所示。



(a) 迭代次数为 1~10 次
(a) The number of iterations ranges from 1 to 10 times



(b) 迭代次数为 9 970~9 980 次
(b) The number of iterations ranges from 9 970 to 9 980 times

图 5 预测与仿真得到的差压随迭代次数变化曲线

Fig. 5 Curve of differential pressure varying with the number of iterations obtained by prediction and CFD simulation

由图 5 可知, PredRNN_V2 模型的预测趋势与仿真模拟的整体趋势保持一致, 该模型的预测结果与仿真结果之间的相对误差在 $\pm 5\%$ 之内。在低迭代次数区间, 预测结果与仿真结果的最大相对误差为 3.6%, 而在高迭代次数区间, 最大相对误差为 -1.6%。这表明 PredRNN_V2 模型在处理高迭代次数情况下的预测能力优于其在低迭代次数区间的表现, 从而证明了该模型对于长时间序列动态演化的强鲁棒性。

在相同硬件与网格分辨率条件下, 传统 CFD 稳态求解单次计算耗时约 10 h, 而基于深度学习的 PredRNN_V2 模型仅需约 1.5 h 完成一次性离线训练, 训练完成后单步流场推理时间小于 0.5 s, 几乎可忽略不计。以稳态

预测阶段为对比基准, PredRNN_V2 相较传统 CFD 方法实现约 $10^3 \sim 10^4$ 量级的计算加速, 体现出显著的时间效率优势; 且随空间分辨率或预测序列长度增加, 传统数值方法计算成本急剧上升, 而神经网络推理复杂度增长相对平缓, 其效率优势将进一步放大。

3 方法验证

3.1 实流实验装置

为进一步验证 PredRNN_V2 模型的实用性, 在河北大学流量实验室水流量装置进行了实流实验。实验装置结构示意图如图 6 所示。实验介质为常温水, 采用标准表法, 其中 DN40 管段配置科里奥利流量计 (Endress + Hauser H, 精度为 $\pm 0.1\%$), DN32 与 DN10 管段配置电磁流量计 (科隆 (KROHNE) 测量仪器 (上海) 有限公司, 00T1FLUX2300, 精度为 $\pm 0.2\%$)。在实验过程中, 使用两台差压变送器采集差压信号。前差压采用北京天星盛世科技有限公司生产的 TXY820-3051DP 型号差压变送器, 其测量范围为 0~200 kPa, 精度为 $\pm 0.1\%$ 。后差压采用横河川仪有限公司生产的 EJA110A 型号差压变送器, 其测量范围为 0~500 kPa, 精度为 $\pm 0.075\%$ 。




图 6 实验装置结构示意图

Fig. 6 Structural schematic diagram of the experimental facility

3.2 实验结果及分析

参照仿真工况设置实验流量点。每调整一个流量点, 系统至少运行 5 min, 待流量稳定后采集并保存差压信号, 每个流量点采集时间为 30 s, 并重复 3 次取平均作为实验结果。将其与仿真结果及预测结果进行对比, 如图 7 所示。




图 7 预测结果与实验及仿真结果对比

Fig. 7 Comparison prediction with experimental and CFD simulation results

由图 7 可以看出,针对前差压,PredRNN_V2 模型的预测结果与实验结果及仿真结果趋势一致。预测值与实验测量值相对误差优于 $\pm 5\%$,与仿真结果的相对误差则小于 $\pm 2\%$ 。对于后差压,该预测数据同样与实验测量值及仿真结果高度吻合,其相对于实验测量值的误差在 $\pm 4\%$ 以内,相对于仿真结果的误差在 $\pm 3\%$ 以内。

4 结 论

为流量计计量性能进行预测,本研究基于时空序列模型提出了一种新的方法,并开发了完整的数据处理与模型训练评估流程。通过多指标评估发现,PredRNN_V2 在流场预测任务中的计算效率和精度均优于 ConvLSTM 和 PredRNN。该方法在目标应用上展现出高准确性,且预测结果与仿真结果的相对误差保持在 $\pm 5\%$ 范围内,有效支撑了对流量计内流场及其性能的可靠预测。

参考文献

- [1] 郭素娜,张珊,孙萃鸿,等. 基于 CFD 仿真圆柱齿轮流量计性能影响因素分析[J]. 电子测量与仪器学报, 2023, 37 (11): 33-40.
- GUO S N, ZHANG SH, SUN C H, et al. Performance influence factors analysis of cylindrical gear flowmeter based on CFD simulation [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (11): 33-40.
- [2] 李中翔,郑德智,胡纯,等. 双管型科氏质量流量传感器非线性影响抑制研究[J]. 仪器仪表学报, 2022, 43 (1): 35-45.
- LI ZH X, ZHENG D ZH, HU CH, et al. Research on non-linear suppression of dual-tube Coriolis mass flowmeter[J]. Chinese Journal of Scientific Instrument, 2022, 43 (1): 35-45.
- [3] 马馨玥,谢代梁,徐志鹏,等. 不同结构微小音速喷嘴的数值模拟与特性对比[J]. 电子测量与仪器学报, 2020, 34 (9): 188-195.
- MA X Y, XIE D L, XU ZH P, et al. Numerical simulation and characteristic comparison of micro-sonic nozzles in different structures [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34 (9): 188-195.
- [4] MAULIK R, SHARMA H, PATEL S, et al. A turbulent eddy-viscosity surrogate modeling framework for Reynolds-averaged Navier-Stokes simulations [J]. Computers & Fluids, 2021, 227: 104777.
- [5] TOMPSON J, SCHLACHTER K, SPRECHMANN P, et al. Accelerating eulerian fluid simulation with convolutional networks [C]. Proceedings of the 34th International Conference on Machine Learning, New York: ACM, 2017: 3424-3433.
- [6] KOCHKOV D, SMITH J A, ALIEVA A, et al. Machine learning accelerated computational fluid dynamics [J]. Proceedings of the National Academy of Sciences, 2021, 118(21): e2101784118.
- [7] OBIOLS-SALES O, VISHNU A, MALAYA N, et al. CFDNet: A deep learning-based accelerator for fluid simulations [C]. Proceedings of the 34th ACM International Conference on Supercomputing, New York: ACM, 2020: 1-12.
- [8] ZHONG H, XIONG Q, YIN L, et al. CFD-based reduced-order modeling of fluidized-bed biomass fast pyrolysis using artificial neural network [J]. Renewable Energy, 2020, 152: 613-626.
- [9] JEON J, LEE J, KIM S J. Finite volume method network for the acceleration of unsteady computational fluid dynamics: Nonreacting and reacting flows [J]. International Journal of Energy Research, 2022, 46(8): 10770-10795.
- [10] WEINER A, SEMAAN R. FlowTorch—A Python library for analysis and reduced-order modeling of fluid flows [J]. Journal of Open Source Software, 2021, 6(68): 3860.
- [11] MAULIK R, SHARMA H, PATEL S, et al. Deploying deep learning in OpenFOAM with TensorFlow [C]. Proceedings of the AIAA Scitech 2021 Forum, Reston: AIAA, 2021: 2021-1485.
- [12] JEON J, LEE J, EIVAZI H, et al. Physics-informed transfer learning strategy to accelerate unsteady fluid flow simulations [J]. Available at SSRN 4149526, 2022.
- [13] WANG Y B, WU H X, ZHANG J J, et al. PredRNN: A recurrent neural network for spatiotemporal predictive learning [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(2): 2208-2225.
- [14] BENGIO S, VINYS O, JAITLEY N, et al. Scheduled sampling for sequence prediction with recurrent neural networks [C]. International Conference on Neural Information Processing Systems, MIT Press, 2015: 1171-1179.
- [15] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: From error visibility to structural similarity [J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [16] ZHANG R, ISOLA P, EFROS A A, et al. The

- unreasonable effectiveness of deep features as a perceptual metric [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018: 586-595.
- [17] SHIN D, GUPTA S K. A new circuit simplification method for error tolerant applications [C]. 2011 Design, Automation & Test in Europe. IEEE, 2011: 1-6.
- [18] SHI X J, CHEN Z R, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [C]. Proceedings of the 28th International Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2015: 802-810.
- [19] SHI X J, GAO Z H, LAUSEN L, et al. Deep learning for precipitation nowcasting: A benchmark and a new model [C]. Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: Curran Associates Inc., 2017: 5622-5632.
- [20] WANG Y B, LONG M S, WANG J M, et al. PredRNN: Recurrent neural networks for predictive learning using spatiotemporal LSTMs [C]. Advances in Neural Information Processing Systems, 2017.

作者简介



郭素娜(通信作者), 2007 年于河北工业大学获得硕士学位, 2016 年于天津大学获得博士学位, 现为河北大学副教授, 主要研究方向为流量检测技术与标准装置、CFD 仿真技术与流场分析。

E-mail: guosunatju@163.com

Guo Suna (Corresponding author) received her M. Sc. degree from Hebei University of Technology in 2007, and Ph. D. degree from Tianjin University in 2016. Now she is an associate professor at Hebei University. Her main research interests include flow detection technology and standard equipment, CFD simulation technology and flow field analysis.