

## 基于扩散模型的流场超分辨率重建方法

韩 阳, 朱军鹏, 郭春雨, 范毅伟, 汪永号

### A FLOW FIELD SUPER-RESOLUTION RECONSTRUCTION METHOD BASED ON DIFFUSION MODEL

Han Yang, Zhu Junpeng, Guo Chunyu, Fan Yiwei, and Wang Yonghao

在线阅读 View online: <https://doi.org/10.6052/0459-1879-23-167>

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 物理增强的流场深度学习建模与模拟方法

PHYSICS-ENHANCED DEEP LEARNING METHODS FOR MODELLING AND SIMULATING FLOW FIELDS

力学学报. 2021, 53(10): 2616-2629

#### 基于SBFEM和深度学习的裂纹状缺陷反演模型

CRACK-LIKE DEFECT INVERSION MODEL BASED ON SBFEM AND DEEP LEARNING

力学学报. 2021, 53(10): 2724-2735

#### 基于尾流时程目标识别的流场参数选择研究

STUDY ON FLOW FIELD PARAMETERS OF WAKE TIME HISTORY TARGET RECOGNITION

力学学报. 2021, 53(10): 2692-2702

#### 基于深度学习和细观力学的颗粒材料本构关系研究

CONSTITUTIVE RELATIONS OF GRANULAR MATERIALS BY INTEGRATING MICROMECHANICAL KNOWLEDGE WITH DEEP LEARNING

力学学报. 2021, 53(9): 2404-2415

#### 基于场力的驾驶员影响因素交通流动力学模型

TRAFFIC FLOW DYNAMIC MODEL CONSIDERING THE INFLUENCES ON DRIVERS BASED ON FIELD FORCE

力学学报. 2018, 50(5): 1219-1234

#### 基于多层分块算法的激波干扰流场预测

PREDICTION OF SHOCK INTERFERENCE FLOW FIELD STRUCTURE BASED ON THE MULTI-LEVEL BLOCK BUILDING ALGORITHM

力学学报. 2021, 53(12): 3284-3297



关注微信公众号, 获得更多资讯信息

基于扩散模型的流场超分辨率重建方法<sup>1)</sup>韩 阳 \* 朱军鹏<sup>†, 2)</sup> 郭春雨<sup>†</sup> 范毅伟 \* 汪永号 \*

\* (哈尔滨工程大学船舶工程学院, 哈尔滨 150001)

† (哈尔滨工程大学青岛创新发展基地, 山东青岛 266000)

**摘要** 低分辨率的流场数据具有较少的信息量, 不能充分捕捉流场中的细节演化过程. 尤其对于湍流的随机脉动特征和小尺度涡旋细节特征更加难以获取, 这限制了对流场演化机理进行深入研究. 为了解决这一局限性, 并从低分辨率流场中重建高分辨率数据, 文章提出一种流场超分辨率重建的生成扩散模型 FlowDiffusionNet. 该模型以低分辨率流场数据输入作为约束条件, 采用去噪分数匹配方法, 来实现高分辨率流场数据的复现. FlowDiffusionNet 在结构设计上充分考虑了流场数据的低频信息与高频空间特征, 采用基于扩散过程的建模方法, 用于重建高分辨率流场数据的残差. 该模型结构便于实现迁移学习, 可在不同程度的退化流场上应用. 将该方法在多种经典流场数据集上进行测试, 并与双三次插值 (bicubic)、超分辨率生成对抗网络 (SRGAN)、超分辨率卷积神经网络 (SRCNN) 等方法进行比较. 结果表明, 该方法在各种流场上的重建性能达到最佳水平, 特别是对于包含小尺度涡结构的 4 倍下采样流场数据, 客观评价指标 SSIM 达到 0.999.

**关键词** 流场超分辨率重建, 条件扩散模型, 深度学习, 流场残差, 迁移学习

中图分类号: U661.1 文献标识码: A doi: 10.6052/0459-1879-23-167

A FLOW FIELD SUPER-RESOLUTION RECONSTRUCTION METHOD BASED ON DIFFUSION MODEL<sup>1)</sup>Han Yang \* Zhu Junpeng<sup>†, 2)</sup> Guo Chunyu<sup>†</sup> Fan Yiwei \* Wang Yonghao \*

\* (College of Shipbuilding Engineering, Harbin Engineering University, Harbin 150001, China)

† (Qingdao Innovation and Development Base, Harbin Engineering University, Qingdao 266000, Shandong, China)

**Abstract** Low-resolution flow field data contains limited information, which fails to fully capture the detailed evolutionary processes of the flow field. Especially for the random turbulent features and small-scale vortex details in turbulence, they are even more challenging to obtain, thereby restricting the in-depth investigation of flow field evolution mechanisms. In order to address this limitation and reconstruct high-resolution data from low-resolution flow fields, this paper proposes a generative diffusion model called FlowDiffusionNet for flow field super-resolution reconstruction. The model takes the low-resolution flow field data input as the constraint condition, and utilizes a denoising fraction matching method to reproduce high-resolution flow field data. FlowDiffusionNet's structural design takes into consideration both the low-frequency information and high-frequency spatial features of flow field data, employing a diffusion-based modeling technique to reconstruct the residuals for high-resolution data. The proposed model's architecture is amenable to transfer learning, allowing its application to degraded flow fields at different levels. The performance of

2023-05-04 收稿, 2023-07-28 录用, 2023-07-29 网络版发表.

1) 国家自然科学基金资助项目 (52371306).

2) 通讯作者: 朱军鹏, 博士研究生, 主要研究方向为流场超分辨率重构. E-mail: junpengzhu@163.com

引用格式: 韩阳, 朱军鹏, 郭春雨, 范毅伟, 汪永号. 基于扩散模型的流场超分辨率重建方法. 力学学报, 2023, 55(10): 2309-2320

Han Yang, Zhu Junpeng, Guo Chunyu, Fan Yiwei, Wang Yonghao. A flow field super-resolution reconstruction method based on diffusion model. *Chinese Journal of Theoretical and Applied Mechanics*, 2023, 55(10): 2309-2320

FlowDiffusionNet is evaluated on various classical flow field datasets and compared against other methods such as bicubic interpolation, super-resolution generative adversarial network (SRGAN), and super-resolution convolutional neural network (SRCNN). The results demonstrate that the proposed method achieves the best reconstruction performance on various flow fields, especially for flow field data with small-scale vortex structures down sampled by a factor of 4, where the objective evaluation index structural similarity index measure (SSIM) reaches 0.999.

**Key words** super-resolution reconstruction of flow field, conditional diffusion model, deep learning, flow field residuals, transfer learning

## 引言

在流体力学领域,通过实验或数值模拟手段都难以获得复杂湍流速度场信息,因此如何能简便地获取高保真、高分辨率的流场信息是研究人员长期以来的追求目标.流场的超分辨率重建技术可将低分辨率流场数据通过预先训练好的神经网络模型直接重建成高分辨率的流场数据,相较于计算流体动力学方法(CFD)可以节约大量计算资源和时间成本.在本文中,提出一种具有广泛适用性的神经网络模型,可以将低分辨率的流场信息提高其分辨率并还原各种经典流场的流动细节.

深度学习作为一种新兴技术在图像处理、自然语言处理、语音识别和多模态学习<sup>[1]</sup>等领域发展迅速.近年来,该技术被应用于实验流体力学方向,处理大量复杂非线性和高维度流场数据<sup>[2-3]</sup>.通过深度学习方法可以对流体运动进行估计,从而提升流体速度场的分辨率.例如,Guo等<sup>[4]</sup>研发了一种实时预测的卷积模型,以低错误率为代价,预测速度比CFD快了两个数量级.Lee等<sup>[5]</sup>开发了一个4级回归卷积网络,从输入两张图像中获取速度场.Cai等<sup>[6]</sup>基于卷积神经网络对PIV粒子图像对进行流动估计.然而这些基于卷积神经网络对流体运动估计缺乏先验物理规律.为了弥补基于卷积神经网络对流动估计性能的不足,Lagemann等<sup>[7]</sup>提出了基于光流架构的递归全场变换(RAFT)模型,在低密度颗粒密度和光照强度变化的条件下表现良好,并且可以端到端地学习位移场.

除此之外许多研究专注于利用深度学习其强大的流动信息特征提取与数据同化的能力,对低分辨率流场进行超分辨率重建.在计算机视觉领域,超分辨率(SR)是一种通过数字信号处理的方法提高图像空间分辨率的技术.2014年Dong等<sup>[8]</sup>首次在SR问题上使用深度学习方法,提出用于单图像超分

辨率的SRCNN模型,执行端到端的超分辨率任务.随后多种超分辨率模型被设计出来,例如超深超分辨率网络VDSR<sup>[9]</sup>、超分辨率生成对抗网络SRGAN<sup>[10]</sup>、稠密连接超分辨率网络SRDenseNet<sup>[11]</sup>和深度残差通道注意力网络RCAN<sup>[12]</sup>等模型.SR已成为计算机视觉领域的研究热点.受此启发,研究人员将深度学习应用于流场的超分辨率重建.

例如, Lee等<sup>[13]</sup>提出了基于生成对抗网络(GAN)的湍流小尺度建模方法,该方法可以凭借较少的计算成本对未处理的模拟数据进行结构预测. Deng等<sup>[14]</sup>将超分辨率生成对抗网络(SRGAN<sup>[10]</sup>)和增强型SRGAN(ESRGAN<sup>[15]</sup>)应用于流场的超分辨率重建任务中,以增强两个并排圆柱后面复杂尾流的空间分辨率,结果表明可以把粗流场的空间分辨率显著提高 $4^2$ 和 $8^2$ 倍,能够准确地重建高分辨率(HR)流场. Fukaimi等<sup>[16]</sup>开发了一种混合下采样跳跃连接/多尺度模型,对二维圆柱绕流进行测试,仅仅需要50个训练数据,就可以极大地提高空间分辨率.但是该研究的工况和所搭建的模型都比较简单. Liu等<sup>[17]</sup>设计了静态卷积神经网络(SCNN)和多时间路径神经网络(MTPC),可以高精度重建强制各向同性湍流的高分辨率流场. Kong等<sup>[18]</sup>做了类似的工作,提出了多路径超分辨率卷积神经网络(MPSRC),可以捕捉温度场的空间分布特征,成功超分辨率重建超燃冲压发动机燃烧室的温度场. Ferdian等<sup>[19]</sup>提出一种新型超分辨率4DFlowNet模型,通过学习从有噪声的低分辨率(LR)图像到无噪声HR相位图像的映射,能够产生清晰解剖区域的无噪声超分辨率相位图像. 2021年Fukaimi等<sup>[20]</sup>开发了用于时空SR分析的深度学习方法,可以从空间和时间上的少量数据点重建高分辨率流场.但是其模型训练十分复杂,并严重依赖训练数据的时空关系. Bi等<sup>[21]</sup>设计由多个多尺度聚合块(LMAB)组成的FlowSRNet模型,

同时做了轻量化设计, 提出 LiteFlowSRNet 架构, 对各种经典流场进行超分辨率重建, 达到了先进 SR 性能. 为了对流场进行物理约束, Raissi 等<sup>[22]</sup> 提出了基于物理的神经网络 (PINN), 可以用偏微分方程描述给定数据集的物理规律, 并在圆柱绕流的示例中展示其解决高维逆问题的能力. 随后 Raissi 等<sup>[23]</sup> 将流体力学基本方程 N-S 方程编码到神经网络里, 通过自动微分技术对模型输出求导, 并带入 N-S 方程计算残差, 最终反向传播优化模型参数, 实现通过软约束对颅内动脉瘤影像的生物流场重构. Shu 等<sup>[24]</sup> 提出一种仅在训练时使用高保真数据的扩散模型, 用于从低保真 CFD 数据输入重建高保真 CFD 数据, 并且可以通过使用已知偏微分方程的物理信息来提高计算准确性, 然而文中并未将扩散模型与其他深度学习模型进行详细的流场重建性能对比.

与上述工作不同, 本文提出了一种适用于流场超分辨率重建的生成模型 FlowDiffusionNet(FDiffNet), 该模型是基于扩散概率模型提出的. 扩散概率模型(扩散模型)<sup>[25-26]</sup> 是一种生成模型, 其使用马尔科夫链将简单分布(如高斯分布)中的潜在变量转换为复杂分布的数据. 扩散模型已经在诸如图像合成和超分辨率图像重建等领域中大放异彩. 其中, 谷歌团队提出的 SR3<sup>[27]</sup> 模型和浙江大学提出的单张图片超分辨率扩散模型 SRdiff<sup>[28]</sup> 均在图像超分辨率上取得了优异的结果. 受此启发利用扩散模型对低保真的流场数据进行重建, 所提出的模型主要由低分辨率(LR)编码器和模型主体构成, 利用残差特征蒸馏模块(RFDB)<sup>[29]</sup> 作为 LR 编码器对低保真数据进行编码, 模型主体选用 Unet 作为架构并增加自注意

力层, 使得模型在深层次里获得更大的感受野. 对所提出的 FlowDiffusionNet 模型在多个经典流场数据集上进行了测试, 并比较了直接预测高保真流场数据进行流场重建与预测高保真数据残差后进而重建流场的性能. 并且在推理过程中, 为了加快推理速度, 引入了 Dpm-solver<sup>[30]</sup> 求解器. 总结为以下 3 项贡献:

- (1) 提出了便于迁移训练的 FlowDiffusionNet 软约束扩散模型, 用于精准地进行流场超分辨率重建, 为了更好提取 LR 流场的特征, 选用了 RFDB 模块作为 LR 编码器;
- (2) 提高了模型的流场超分辨率重建速度, 将 DPM-solver 求解器应用到推理过程, 提高了模型的效率;
- (3) 全面评估该模型的性能, 构建了多种经典 SR 流场数据集, 并根据不同因素对复杂流场进行降采样, 从而验证模型的适用性与稳定性.

## 1 研究方法

### 1.1 总体框架

扩散模型作为一种新兴的生成式模型, 避免以往对抗神经网络难以收敛以及崩溃的问题, 因此更适用于处理比较大的流场数据信息. 并且扩散模型相较于卷积神经网络与物理神经网络, 更易进行不同降采样倍率的迁移学习, 其适用性和泛化性更强. 本文方法总体框架如图 1 所示, 包括两个过程: 前向扩散过程在上面用绿色箭头表示, 为无参数学习; 反向扩散过程在下面用蓝色箭头表示, 进行参数优化. 图中  $y_0$  表示预测流场的残差, 参数  $\theta$  是由神经网络模型拟合的.

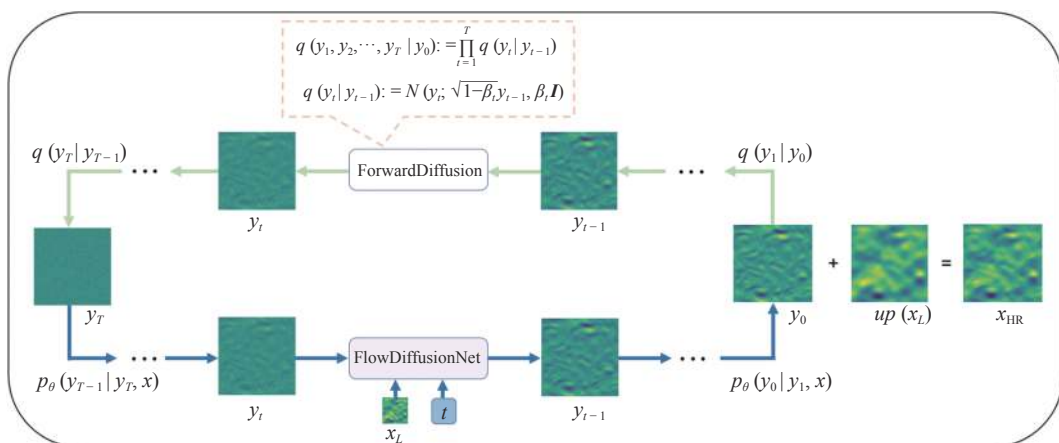


图 1 FlowDiffusionNet 模型重建高保真流场的原理

Fig. 1 The principle of FlowDiffusionNet model to reconstruct high-fidelity flow field

## 1.2 扩散模型

在本节中,介绍扩散模型的基本概念<sup>[25]</sup>.扩散模型是一类概率生成模型,采用参数化马尔可夫链,通过变分推理训练,学习如何逆转逐渐退化训练数据结构的过程.扩散模型训练过程分为两个阶段:前向扩散过程和反向去噪过程.

前向扩散过程可以描述为逐渐破坏数据结构的前向加噪处理,通过不断向输入的数据中添加低水平的噪声(高斯噪声),直到全部变成高斯噪声.给定原始的训练样本满足 $y_0 \sim q(y_0)$ ,通过预先设置好的一组数据 $\beta_1, \beta_2, \dots, \beta_T \in [0, 1)$ ,将数据分布 $q(y)$ 转换成潜在变量 $q(y_T)$

$$q(y_1, y_2, \dots, y_T | y_0) := T_{n=1}^T q(y_t | y_{t-1}) \quad (1)$$

$$q(y_t | y_{t-1}) := \mathcal{N}(y_t; \sqrt{1 - \beta_t} y_{t-1}, \beta_t \mathbf{I}), \forall t \in \{1, 2, \dots, T\} \quad (2)$$

其中 $T$ 是扩散总步数, $\beta_t$ 可看作控制扩散步骤方差的超参数, $\mathbf{I}$ 是与输入数据 $y_0$ 具有相同维度的矩阵, $\mathcal{N}(y; \mu, \sigma)$ 表示均值为 $\mu$ 且方差为 $\alpha$ 的正态分布.前向过程可对任意的时间步 $t$ 处进行采样

$$q(y_t | y_0) = \mathcal{N}(y_t; \sqrt{\bar{\alpha}_t} y_0, (1 - \bar{\alpha}_t) \mathbf{I}) \quad (3)$$

其中 $\alpha_t := 1 - \beta_t$ ,  $\bar{\alpha}_t := T_{n=1}^t \alpha_n$ ,任意时刻 $y_t$ 数据状态都可以根据原始数据 $y_0$ 采样得到.式(3)可参数重整化为

$$y_t(y_0, \epsilon) = \sqrt{\bar{\alpha}_t} y_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, \quad \epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{I}) \quad (4)$$

反向扩散过程可以描述为学习从噪声输入中恢复原始数据的反向去噪处理,采用类似的迭代过程,通过每一步去除噪声,最终重建原始数据.然而,由于 $q(y_{t-1} | y_t)$ 取决于整个数据分布,扩散模型使用神经网络作如下近似

$$p_\theta(y_{t-1} | y_t) := \mathcal{N}(y_{t-1}; \mu_\theta(y_t, t), \sigma_\theta(y_t, t)) \quad (5)$$

其中 $p_\theta(y_{t-1} | y_t)$ 为参数化的高斯分布,他们的均值和方差由训练的网络 $\mu_\theta(y_t, t)$ 和 $\sigma_\theta(y_t, t)$ 确定.

在训练阶段,我们最大化负对数似然的变分下界(ELBO),并引入KL散度和方差缩减<sup>[25]</sup>

$$\begin{aligned} \mathbb{E}[-\lg p_\theta(y_0)] \leq L := & \underbrace{\mathbb{E}_q[D_{KL}(q(y_T | y_0) \| p(y_T))]}_{L_T} + \\ & \sum_{t>1} \underbrace{D_{KL}(q(y_{t-1} | y_t, y_0) \| p_\theta(y_{t-1} | y_t))}_{L_{t-1}} - \underbrace{\lg p_\theta(y_0 | y_1)}_{L_0} \end{aligned} \quad (6)$$

方程(6)使用KL散度直接将 $p_\theta(y_{t-1} | y_t)$ 与前向

过程后验分布 $q(y_{t-1} | y_t, y_0)$ 进行比较

$$q(y_{t-1} | y_t, y_0) = \mathcal{N}(y_{t-1}; \tilde{\mu}_t(y_t, y_0), \sigma^2 \mathbf{I}) \quad (7)$$

$$\tilde{\mu}_t(y_t, y_0) = \frac{\sqrt{\bar{\alpha}_t - 1} \beta_t}{1 - \bar{\alpha}_t} y_0 + \frac{\sqrt{\bar{\alpha}_t(1 - \bar{\alpha}_t - 1)}}{1 - \bar{\alpha}_t} y_t \quad (8)$$

$$\sigma^2 = \frac{1 - \bar{\alpha}_t - 1}{1 - \bar{\alpha}_t} \beta_t \quad (9)$$

根据式(3)、式(5)和式(7)得知,等式(6)所有KL散度是高斯分布之间的比较.当 $t > 1$ 且 $C$ 为常量时,可以得到

$$L_{t-1} = \mathbb{E}_q \left[ \frac{1}{2\sigma_t^2} \|\tilde{\mu}_t(y_t, x_0) - \mu_\theta(y_t, t)\|^2 \right] + C$$

可将方程(6)简单优化后进行训练,有利于提高样本生成质量

$$L_{\text{simple}}(\theta) = \mathbb{E}_{y_0, \epsilon, t} [\|\epsilon - \epsilon_\theta(\sqrt{\bar{\alpha}_t} y_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, t)\|^2] \quad (10)$$

其中 $\epsilon_\theta$ 为噪声预测因子.

在推理过程中,首先从高斯分布 $\mathcal{N}(\mathbf{0}, \mathbf{I})$ ,采样潜在变量 $y_T$ ,然后根据等式(5)进行采样 $y_{t-1} \sim p_\theta(y_{t-1} | y_t)$ 其中

$$\begin{aligned} \mu_\theta(y_t, t) := & \tilde{\mu}_t(y_t, \frac{1}{\sqrt{\bar{\alpha}_t}} (y_t - \sqrt{1 - \bar{\alpha}_t} \epsilon_\theta(y_t, t))) = \\ & \frac{1}{\sqrt{\bar{\alpha}_t}} \left( y_t - \frac{\beta_t}{\sqrt{1 - \bar{\alpha}_t}} \epsilon_\theta(y_t, t) \right) \end{aligned} \quad (11)$$

$$\sigma_\theta(y_t, t) := \sqrt{\frac{1 - \bar{\alpha}_t - 1}{1 - \bar{\alpha}_t}} \beta_t \quad (12)$$

## 1.3 条件扩散模型

在本节中,将在扩散模型的基础上介绍条件扩散模型.条件扩散模型的前向过程与扩散模型基本一致,目的是将原始数据分布 $y_0$ 转换成潜在变量 $y_T$ .反向过程是从潜在变量 $y_T$ 开始,利用原始数据 $x$ 的附加信息,来优化去噪神经网络的 $\epsilon_\theta$ ,从而恢复无噪声的原始数据 $y_0$ .该模型是将原始数据 $x$ 和由式(4)得到 $y_t$ 数据状态作为输入,通过训练来预测噪声向量 $\epsilon$ .在训练过程,参数化 $\mu_\theta$ 有许多不同的办法,显然可以使用神经网络预测 $\epsilon_\theta(y_t, t, x)$ ,之后通过等式(11)得到 $\mu_\theta(y_t, t, x)$ ,根据Saharia等<sup>[27]</sup>建议,可将训练 $\epsilon_\theta$ 的目标函数设定为

$$\begin{aligned} \mathbb{E}_{(x, y)} \mathbb{E}_{\epsilon, t} [\|\epsilon - \epsilon_\theta(\sqrt{\bar{\alpha}_t} y_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, t, x)\|^2] \\ \epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{I}) \end{aligned} \quad (13)$$

本文选用的参数重整化方法是通过神经网络预测  $y_0$ , 输出的结果可以根据等式 (8) 和式 (11) 产生  $\mu_\theta(y_t, t, x)$ . 其训练  $f_\theta$  的目标函数可以表示为

$$\mathbb{E}_{(x,y)} \mathbb{E}_{\epsilon,t} \left[ \left\| y_0 - f_\theta \left( \sqrt{\bar{\alpha}_t} y_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, t, x \right) \right\|^2 \right] \quad \epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{I}) \quad (14)$$

推理过程是通过神经网络预测在每个时间步长处去除的噪声, 从而逐步重建数据来生成目标数据

$$p_\theta(y_0, y_1, \dots, y_T | x) = p(y_T) \prod_{t=1}^T p_\theta(y_{t-1} | y_t, x) \quad (15)$$

$$p(y_T) = \mathcal{N}(y_T; \mathbf{0}, \mathbf{I}) \quad (16)$$

$$p_\theta(y_{t-1} | y_t, x) = \mathcal{N}(y_{t-1}; \mu_\theta(y_t, t, x), \sigma_t^2 \mathbf{I}) \quad (17)$$

根据神经网络学习高斯条件分布  $p_\theta(y_{t-1} | y_t, x)$  定义整个推理过程. 如果前向过程噪声方差设置足够小, 那么反向过程  $p(y_{t-1} | y_t, x)$  近似高斯分布, 即证明了在推理过程选择高斯条件可以为真实反向过程提供合理的拟合. 并且  $1 - \bar{\alpha}_t$  应该足够大, 使得潜在变量  $y_T$  满足等式 (16).

### 1.4 FlowDiffusionNet

FlowDiffusionNet 是一种条件扩散模型, 总体框架如图一所示. 建立在  $T$  步扩散模型之上, 该模型包含两个过程: 扩散过程和反向扩散过程. 不是直接预

测 HR 流场, 而预测 HR 流场  $x_H$  和上采样 LR 流场  $up(x_L)$  之间的差异, 并将差异表示为输入残差流场  $y_0$ . 扩散过程通过向残差流场  $y_0$  不断添加高斯噪声, 如方程 (4) 表示, 直到变成高斯分布  $y_T$ . 反向扩散过程通过使用条件残差流场预测器, 以低分辨率编码器 (简称 LR 编码器) 对 LR 的流场编码输出为条件, 在有限时间步迭代去噪, 将高斯分布  $y_T$  变成残差流场  $y_0$ . SR 流场是通过将生成的残差流场  $y_0$  添加到上采样 LR 流场  $up(x_L)$  来进行重建的.

在接下来的小节中, 将介绍条件残差流场预测器、LR 编码器、训练和推理的框架.

#### 1.4.1 条件残差流场预测器

根据式 (15) ~ 式 (17) 构成条件残差流场预测器, 定义  $x$  是输入模型里面的条件, 在超分辨率流场重构任务中  $x$  代表 LR 流场  $x_L$ . 根据神经网络学习高斯条件分布  $p_\theta(y_{t-1} | y_t, x)$  进行推断 HR 流场  $x_H$ . 如图 2 所示, 使用 U-Net 作为主体, 以 2 通道  $y_t (u,v)$ 、扩散时间步长  $t$  以及 LR 编码器的输出作为输入, 其中“res block”, “downsample”, “attention block”, “upsample”分别表示残差块、下采样块、自注意力块和上采样块; “DS”和“US”分别表示下采样步骤和上采样步骤; 其中“DS”和“US”后面括号里 (c, 2c, 4c) 表示每个步骤通道数量.

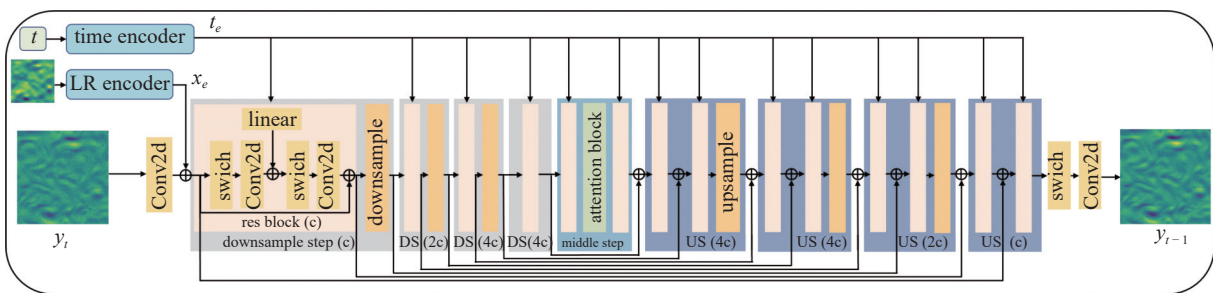


图 2 FlowDiffusionNet 的总体网络框架

Fig. 2 The overall network framework for FlowDiffusionNet

首先通过一个二维卷积层将  $y_t$  转换到激活状态, 之后把隐藏状态  $y_t$  与经过编码的 LR 流场信息在通道上进行融合, 并将其输入到 UNet 模型里面. 通过正弦位置编码将时间步长  $t$  编码至隐藏状态  $t_e$  [31], 并将  $t_e$  输入到每一个残差模块中. 下采样路径由一个残差模块和一个下采样层构成, 上采样路径由两个残差模块和一个上采样层构成, 这样不对称的设置有利于设置更加密集的多尺度跳跃残差连接, 从而保证条件残差流场预测器稳定. 第 2 和第

3 下采样路径中将通道尺寸加倍, 并在每个下采样路径中将特征图的空间尺寸减半, 以求降低模型的参数量, 并提高其采样速度. 中间路由两个残差块和一个自注意力模块组成, 这有利于模型在增大感受野同时降低参数量. 最后将上采样路径输出, 应用 swich 函数进行激活, 并通过卷积预测  $y_{t-1}$  的残差流场.

#### 1.4.2 LR 流场编码器

采用 LR 流场编码器对上采样 LR 流场  $up(x_L)$  信息进行编码, 并将其添加到每个反向步骤中以引

导生成到相应的 HR 流场. 在本文中, 选择使用残差蒸馏网络 (RFDN) 模型<sup>[29]</sup> 的 RFDB 架构, 如图 3 所示, “SRB”表示浅层残余模块, “CCA Layer”表示规范相关分析, 该架构的特征提取层和信息蒸馏层, 可以全面提取上采样 LR 流场  $up(x_L)$  信息. 并且舍弃掉 RFDN 模型的最后一个上采样层, 因为经过测试证明这样做的效果要优于将直接 LR 流场  $x_L$  输入 RFDB 模块, 较低分辨率输入会使得不同的特征提取层输出信息更加相似, 且在上采样层会破坏原始 LR 流场  $x_L$  信息.




图 3 RFDB 架构  
Fig. 3 RFDB architecture

1.4.3 训练与推理过程

在训练阶段, 如图 4 所示, 从训练集中输入相应 LR-HR 流场对, 用于训练总扩散步长为  $T$  的 Flow-DiffusionNet. 将  $x_L$  上采样为  $up(x_L)$ , 并计算流场残差  $HR-up(x_L)$ . 第 1 步: 将流场残差  $y_0$  输入正向扩散模块采样出任意  $t$  时刻流场残差状态  $y_t$ , 并输入模型里, 值得注意的是这步没有可学习的参数, 所有参数都是预先设置好的. 第 2 步: 通过 LR 流场编码器将

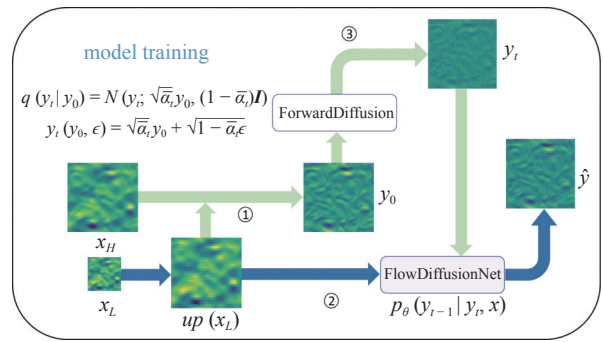


图 4 模型的训练过程  
Fig. 4 The training process of the model

$up(x_L)$  编码为  $x_e$ , 并输入模型. 第 3 步: 计算模型输出  $\hat{y}$  和目标输出  $y_0$  的均方误差 MSEloss, 并反向优化 FlowDiffusionNet 的参数.

推理过程如图 5 所示, 使用 DPM-solver<sup>[30]</sup> 快速采样器, 极大加快了模型的采样速度, 使得该模型可以在短时间内处理大量流场数据信息. 如图 5 所示, 第 1 步: FlowDiffusionNet 模型在推理过程中将上采样 LR 流场  $up(x_L)$  与从标准高斯分布中采样得到的潜在变量  $y_T$  作为输入, 预测  $t = 0$  时刻的残差流场; 第 2 步: 将神经网络预测的流场  $\hat{y}$  输入到 DPM-solver 快速采样器里面, 从而采样出  $t$  时刻的残差流场  $y_t$ ; 第 3 步: 将残差流场  $y_t$  和上采样 LR 流场  $up(x_L)$  再次输入到神经网络里, 预测  $t = 0$  时刻的残差流场. 随后重复第 1 和第 2 步直至采样出原始残差流场  $y_0$ . 最终在上采样 LR 流场  $up(x_L)$  添加残差流场  $y_0$  来恢复 SR 流场.

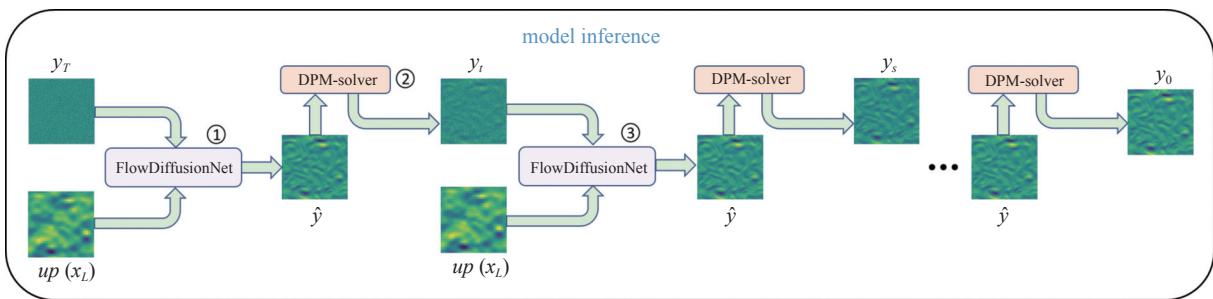


图 5 模型的推理过程  
Fig. 5 The inference process of the model

2 数据集构建和训练及采样过程细节

在本节中, 首先描述制作数据集的原理和过程, 随后介绍模型训练及采样的一些细节.

2.1 数据集构建

本文根据参考文献收集了 5 个经典流场, 包括:

二维湍流运动<sup>[32]</sup>(DNS 湍流)、地表准地转流<sup>[33]</sup> (SQG) 和约翰霍普金斯湍流数据库<sup>[34]</sup>(JHTDB) 等复杂流场, 其可以从公开文献中获得. 表 1 列出了不同经典流场的用于训练和测试的数据集数量, 并且 SR 数据集流场数据不具有严格时间连续性.

接下来我们通过一种常用的降采样策略来降低

流场数据的分辨率, 生成低分辨率流场数据从而构建 LR-HR 数据对

$$x_L = (x_H \otimes G) \downarrow_{\alpha} \quad (18)$$

其中  $G$  代表退化模糊操作,  $\alpha$  代表下采样因子, 通过经典的高斯模糊结合双 3 次下采样方案, 高斯模糊核函数的公式如下

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (19)$$

其中  $\sigma$  设置为 5, 高斯核大小设置为  $16 \times 16$ , HR 流场数据与 LR 流场数据之间的差异可以用下采样因子  $\alpha$  表示

$$\alpha = M_{LR}/M_{HR} = N_{LR}/N_{HR} \quad (20)$$

其中  $M$  表示流向速度矢量的数量,  $N$  表示展向速度矢量的数量. 为了综合评价模型在不同分辨率下的重建能力, 选择了 3 种不同的下采样因子, 即 4, 8 和

表 1 不同流场 SR 训练集与测试集数量

Table 1 Number of SR training and test sets for different flow fields

Cases nos.	Case name	Train data	Test data
1	DNS turbulence	1600	400
2	JHTDB channel	1520	380
3	JHTDB isotropic	1600	400
4	JHTDB MHD	640	160
5	SQG	1200	300

16. 构建的 SR 数据集包含复杂的湍流结构 (DNS 湍流和 JHTDB) 和小尺度涡流结构 (SQG 和 DNS 湍流), 这使得流场重建任务具有挑战性. 如图 6 所示, 展示了在  $\alpha = 8$  下构建的 SR 流场数据集.

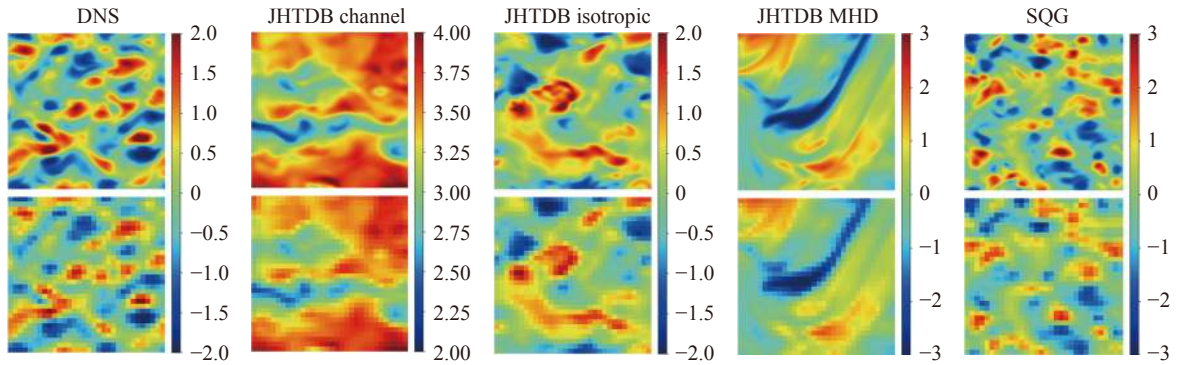


图 6 超分辨率流场数据集

Fig. 6 Super-resolution flow field datasets

## 2.2 训练细节

FlowDiffusionNet 模型是在一台 NVIDIA 3060 GPU 的电脑上面通过 pytorch 实现的. 在训练阶段, 选择 MSE 作为损失函数, 并应用 Adam 优化器, 初始学习率设置 0.00003, dropout 设置为 0.1 来优化模型参数. 模型训练超参数设置包括设置扩散步长  $T = 1000$ , 并把前向过程的方差设置成随步长动态增大, 从 0.0001 线性增加到 0.02. 首先在  $32 \times 32$  空间分辨率  $\rightarrow 256 \times 256$  空间分辨率的数据集上训练, 随后将在  $32 \times 32$  空间分辨率  $\rightarrow 256 \times 256$  空间分辨率训练好的参数, 分别迁移至  $64 \times 64$  空间分辨率  $\rightarrow 256 \times 256$  空间分辨率的数据集上和  $16 \times 16$  空间分辨率  $\rightarrow 256 \times 256$  空间分辨率的数据集上

进行训练, 模型的总参数量为 69.7 M.

## 2.3 采样细节

在本文的推理过程中, 采用了 DPM-solver 采样方法<sup>[30]</sup>. 该采样方法具有多种优点, 包括不需要任何训练即可适用于扩散模型的采样, 并且相较于先进的无训练采样方法, 可实现约 10 倍的加速. DPM-solver 利用扩散常微分方程的半线性, 通过由噪声预测模型的指数加权积分, 直接近似扩散常微分函数的精确解. 该采样器可以采用 1 阶、2 阶和 3 阶模式来近似噪声预测模型的指数加权积分, 其中 1 阶模式与 DDIM<sup>[35]</sup> 采样过程相同. 为了兼顾采样质量和速度, 设置了预测  $x_{start}$  的离散噪声序列 DPM 2 阶求解器, 并应用自适应采样方法.



### 3 实验

在本节中将对 FlowDiffusionNet 模型的性能进行评估, 首先介绍定量及定性评估模型的标准, 随后比较了不同模型重建流场的精度, 最后可视化涡量场并验证其重建效果.

#### 3.1 评估标准

借鉴评估图像相似度的两个重要指标, 峰值信噪比 (PSNR) 及结构相似度指标 (SSIM). PSNR 表示精度的破坏性噪声功率的比值, 是衡量原始图像与处理后图像数据质量的重要标准, 一般认为其值高于 40 质量极好, 30 ~ 40 之间质量是可接受的. 具体的公式如下

$$PSNR = 10 \cdot \lg(Max_I^2 / MSE) \quad (21)$$

其中  $Max_I$  表示原始数据的最大像素值,  $MSE$  表示原始数据与重建数据之间的均方误差.

SSIM 是感知模型, 可以衡量图片的失真程度, 也可以衡量两张图片的相似程度. 具体的公式如下

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (22)$$

其中  $\mu_x$  和  $\mu_y$  分别表示原始数据  $x$  和重建数据  $y$  的平均值,  $\sigma_x$  和  $\sigma_y$  分别表示  $x$  和  $y$  的标准差,  $\sigma_{xy}$  则表示  $x$  和  $y$  的协方差,  $c_1$  和  $c_2$  是常数避免分母为 0.

在定性评估中, 通过可视化重建流场数据的速度场和涡量场分布, 从而直观地观察到重建流场的详细信息.

#### 3.2 流场重建精度比较

首先, 对提出的 FlowDiffusionNet 模型进行了评估, 比较其在预测流场残差和直接预测原始流场时对于不同流场的重建性能. 为了凸显该模型在流场重建方面的优越性, 同时选取了几种常用的流场超分辨率 (SR) 方法进行比较, 包括传统的双三次插值方法 (bicubic)<sup>[36]</sup>, 基于卷积神经网络 (CNN) 的 SRCNN 方法<sup>[8]</sup> 和基于生成对抗网络 (GAN) 的 SRGAN 方法<sup>[14]</sup>. 为了评估流场在不同分辨率尺度下的重建能力, 选取了  $\alpha$  为 4 (中分辨率水平)、8 (低分辨率水平) 和 16 (超低分辨率水平).

如表 2 所示 (表中 SRGAN 和 SRCNN 性能效果来源于文献 [21]), 其中 FDiffNet\_res 表示预测 HR 流场残差, FDiffNet\_Nres 表示直接预测 HR 流

场, 性能最高值加粗表示, 所提出的模型在不同的流场数据集中均展现出了最优秀的性能表现. 具体而言, 对于涉及复杂湍流的流场, 双三次插值方法的 PSNR 普遍难以超过 30, 且其流场重建效果较差, 与深度学习方法相比仍存在显著差距. 特别是对于包含小尺度涡结构的流场数据集, 例如 DNS 和 SQG, 传统方法在重建精度方面表现最低, 相应的 PSNR 和 SSIM 评价指标仅分别为 20.096/0.758 和 22.113/0.728. 这说明在局部小尺度涡旋重建任务中, 传统方法的性能相对于本文提出的模型仍存在明显的差距. 可以看到, SRGAN 和 SRCNN 在  $\alpha = 4$  中等分辨率下, 流场重建精度 SSIM 可以达到 0.9 以上. 同样基于生成的模型, SRGAN 的流场重建效果比 FDiffNet 效果要差, 这是因为生成对抗模型训练需要达到纳什均衡, 并且对于超参数较为敏感, 需要调整模型是适用的超参数设定. 相反, 对于同是生成模型的 FDiffNet 训练十分简单, 只需去拟合反向扩散过程中的条件分布, 而且模型不易陷入过拟合. SRCNN 模型在  $\alpha = 4$  中等分辨率和  $\alpha = 8$  低等分辨率流场重建精度 SSIM 相差 0.023 ~ 0.037, 而 FDiffNet\_res 重建精度 SSIM 仅相差 0.002 ~ 0.014, 这表示提出的模型在不同分辨率的流场重建上, 具有更好的精度保持性. FDiffNet 预测高分辨率流场的残差重建效果要优于直接预测原始高分辨率流场, 并且在训练时预测残差能让模型更快收敛.

FDiffNet 模型主体结构是 UNet 模型, 输入与输出大小是一致的, 因此只需简单改动输入 LR 流场上采样倍数, 无需修改其他任何参数即可进行迁移学习, 这将为训练节省大量时间. 为了证明 FDiffNet 模型在迁移学习方面的优越性, 在 DNS 流场重建上, 对比了 FDiffNet\_res 直接在  $\alpha = 4$  下训练 65 000 步与 FDiffNet\_res 在  $\alpha = 8$  下训练 45 000 步之后迁移  $\alpha = 4$  下训练 65 000 步的客观评价指标, 如图 7 所示. 经过迁移学习 FDiffNet 模型在训练的稳定性提高, 相比随机初始化的 FDiffNet 模型训练方式, 其重建精度 PSNR 与 SSIM 值提升更快, 可以大幅节省模型的训练时间与成本. FDiffNet 模型在训练  $\alpha = 8$  低等分辨率的流场重建过程中已经学习到该种流场分布规律, 因此在迁移到  $\alpha = 4$  中等分辨率流场时可以更快适应由下采样因子变化引起学习分布的差异.

表 2 在下采样因子为 4, 8, 16 下不同方法的性能表现

Table 2 Performance of different methods with downsampling factors of 4, 8, 16

$\alpha$	Flow cases	Bicubic	SRGAN	SRCNN	FDiffNet_Nres	FDiffNet_res
		<i>PSNR/SSIM</i>	<i>PSNR/SSIM</i>	<i>PSNR/SSIM</i>	<i>PSNR/SSIM</i>	<i>PSNR/SSIM</i>
4	DNS turbulence	20.057/0.760	31.373/0.920	35.314/0.957	50.259/0.997	58.048/0.999
	JHTDB channel	34.824/0.893	40.324/0.922	45.733/0.971	44.419/0.983	47.272/0.983
	JHTDB isotropic	25.514/0.821	34.974/0.935	36.028/0.946	48.284/0.995	50.371/0.996
	JHTDB MHD	24.986/0.837	32.049/0.901	32.351/0.916	37.373/0.968	38.078/0.973
	SQG	22.190/0.730	33.718/0.897	37.143/0.937	51.597/0.997	60.659/0.999
8	DNS turbulence	16.408/0.618	31.115/0.912	32.988/0.934	41.708/0.989	48.267/0.997
	JHTDB channel	31.347/0.820	38.539/0.899	41.193/0.944	41.753/0.974	46.562/0.978
	JHTDB isotropic	22.131/0.723	22.164/0.723	33.363/0.912	38.945/0.977	42.738/0.982
	JHTDB MHD	21.592/0.748	29.636/0.855	31.059/0.887	34.445/0.953	35.499/0.961
	SQG	18.676/0.595	31.634/0.850	34.468/0.900	42.722/0.986	46.004/0.991
16	DNS turbulence	9.464/0.321	28.902/0.877	31.165/0.914	32.163/0.958	37.413/0.979
	JHTDB channel	26.168/0.647	30.638/0.709	30.795/0.744	32.505/0.813	33.191/0.819
	JHTDB isotropic	16.626/0.514	24.074/0.687	25.132/0.723	30.418/0.872	31.642/0.881
	JHTDB MHD	16.305/0.555	21.286/0.609	22.831/0.674	22.957/0.754	24.589/0.776
	SQG	12.637/0.336	29.163/0.804	29.972/0.826	39.073/0.981	42.534/0.987

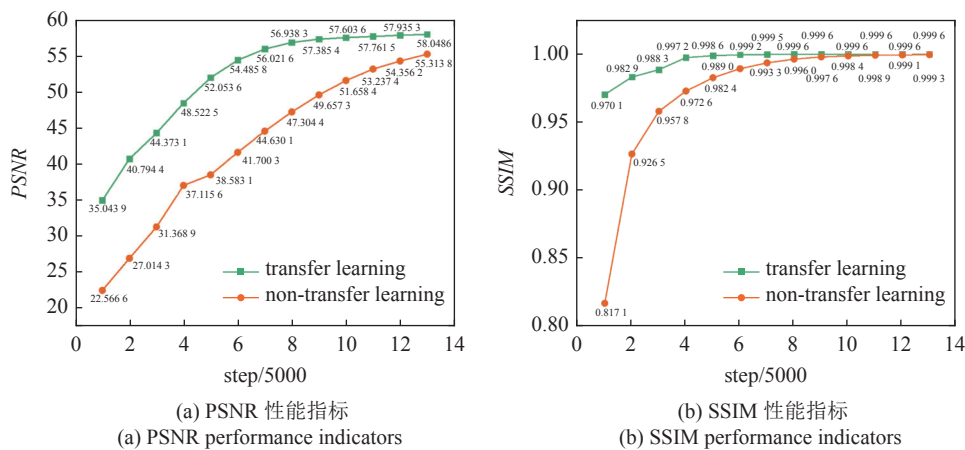


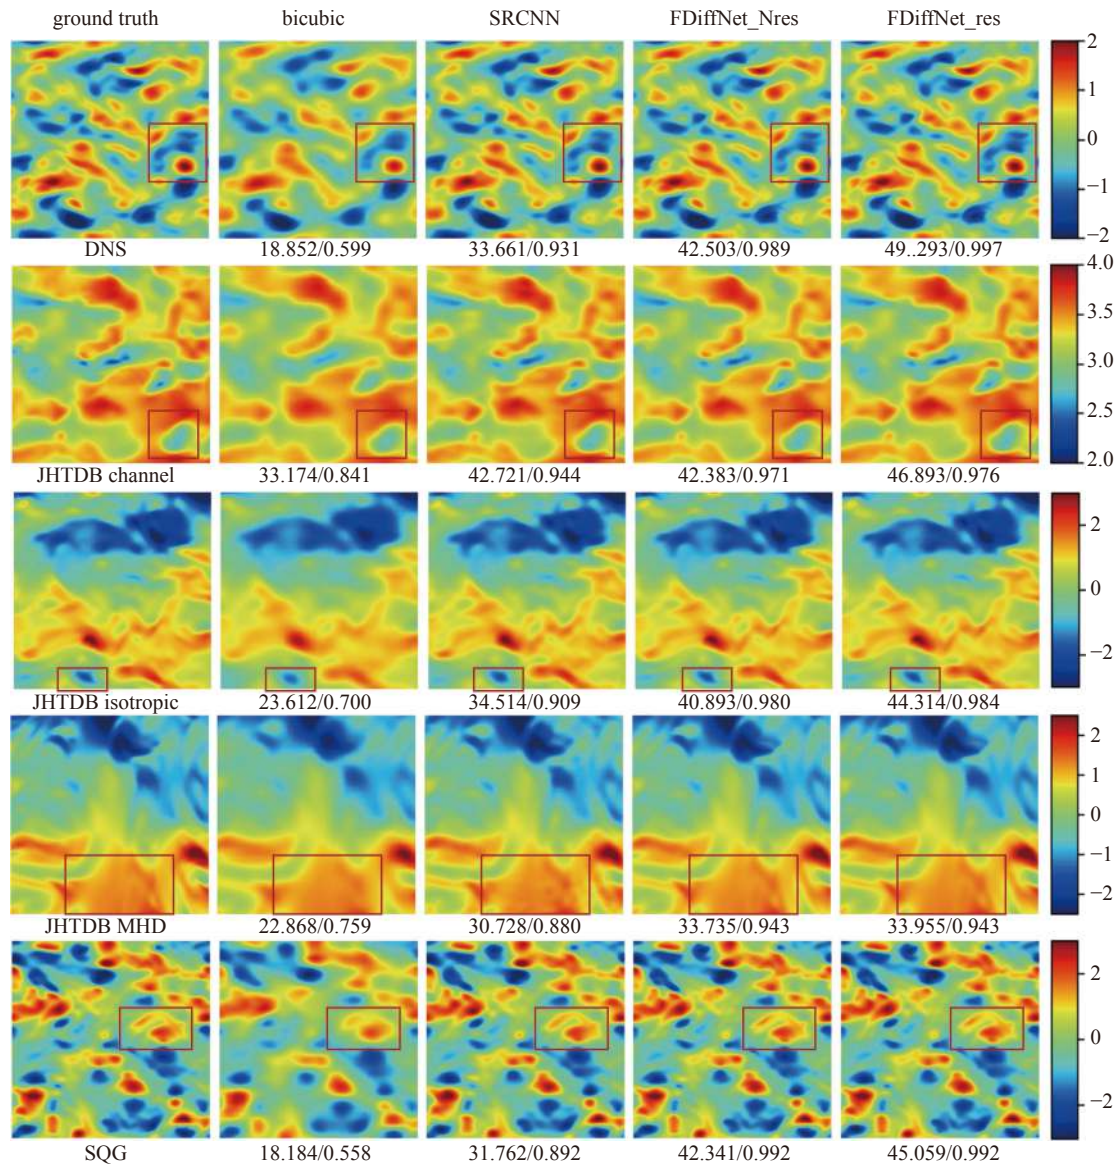
图 7 FDiffNet 在迁移学习和非迁移学习上性能表现

Fig. 7 FDiffNet performs on transfer learning and non-transfer learning

### 3.3 速度场重建精度评价

为直观展示不同方法流场重建能力, 选取传统 Bicubic 方法、深度学习 SRCNN 方法、FDiffNet\_Nres 方法以及 FDiffNet\_res 方法进行对比, 在低分辨率  $\alpha = 8$  下速度场的重建可视化结构如图 8 所

示, 其中颜色条表示速度  $u$  的大小. 对于每个流动情况,  $PSNR$  和  $SSIM$  值都在重建的流场下面给出. 通过双三次插值方法重建的流场相对平滑, 相比之下深度学习方法会展现更多流场细节. 其中 FDiffNet 方法性能表现最优, 相较 SRCNN 方法可以优化流

图 8 不同方法在  $\alpha = 8$  下重建速度场的比较Fig. 8 Comparison of different methods to reconstruct velocity fields at  $\alpha = 8$ 

场中更加精细化的结构,例如在 JHTDB channel 流场数据红框内的涡流应是纺锤型,而 SRCNN 直接重建成一个点,相比之下 FDiffNet 则完整重建了涡结构.这是由于所用 LR 编码器充分提取了低分辨率流场特征,并在重建流场的过程中并不是一步重建,而是通过 DPM-solver 采样器从噪声中逐步恢复流场的.用 FDiffNet 预测 HR 流场残差性能略优于直接预测 HR 流场,在重建流场数据方面是与原始 HR 流场更具有有一致性,在图像上也可直观地看出 FDiffNet\_res 重建的流场更贴合真实流场.

### 3.4 涡量场重建精度评价

由于在训练过程中未直接考虑涡度,因此涡度

可作为评估模型学习表现的良好指标.在低分辨率  $\alpha = 8$  下涡量场的重建可视化结构如图 9 所示,其中颜色条表示涡量的大小, DNS 湍流和 SQG 包含更多的涡结构,可以显著揭示重建流场的细节.类似于速度场的重建结果,使用 FDiffNet 预测 HR 流场残差,其重建效果最优.相比之下,双三次方法重建的涡量场十分模糊,缺乏流场信息,而 SRCNN 方法重建的涡量场很粗糙,并且无法正确估计涡边缘结构.然而, FDiffNet 则可以有效重建涡量场的细节部分,并且和真实涡量场一样平滑,这证明了 FlowDiffusionNet 模型的实用性.

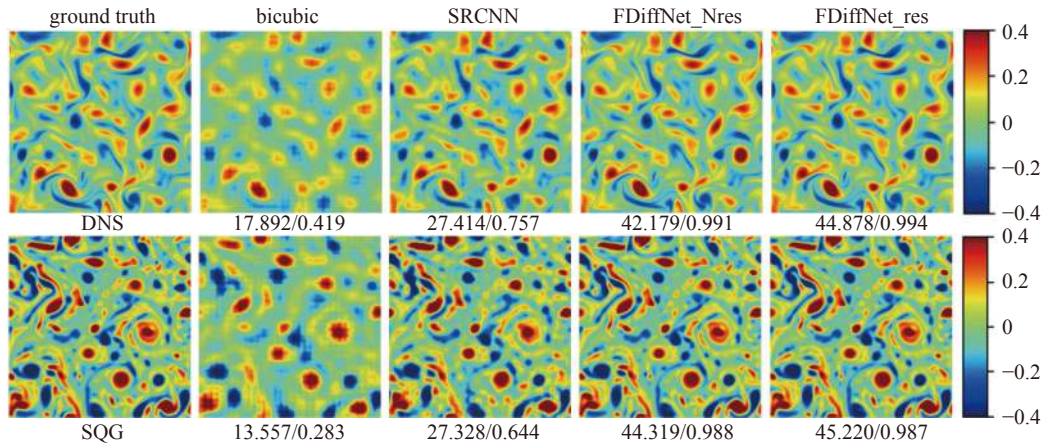


图 9 不同方法在  $\alpha = 8$  下重建涡量场的比较

Fig. 9 Comparison of different methods to reconstruct vortex fields at  $\alpha = 8$

### 3.5 计算效率对比

根据运行时间和模型大小评估了模型的计算效率, 如表 3 所示. 为了公平比较, 每种方法都在同一台机器上配备了相同的 Intel Core i7-12700 CPU 和 NVIDIA RTX 3060 GPU. 另外, 我们以超低分辨率  $\alpha = 16$  的 DNS 湍流流场为例. 注意运行时间是 100 个测试流场的累计时间.

表 3 不同方法的计算效率对比

Table 3 Comparison of computational efficiency of different methods

Model	Running time/ms	Model size/kB
bicubic	1	—
SRGAN	328	5939
SRCNN	21	472
FlowDiffusionNet	58213	69703

如表 3 所示, 可以看出 FlowDiffusionNet 模型在计算效率上存在一定劣势, 与基线的生成模型 SRGAN 相比, 推理过程更加耗时, 这是因为 GAN 的采样只需要一次神经网络前馈过程, 而扩散模型则需要多步神经网络前馈. 即使本文已经使用了最先进的采样方法将原始的上百步前馈缩小至 10 步以内, 但在推理 100 测试流场所用总时间仍达到了 58 s.

## 4 结论

本文提出了一种基于扩散模型的方法, 用于不同流场数据集的超分辨率重建. 该模型优化了原始

的 DDPM 网络结构, 增加了自注意力层, 并应用 LR 编码器高效提取 LR 流场信息. 为了提高模型重构 HR 流场速度, 选用了 DPM-solver 采样器进行推理. 本研究得到以下结论.

(1) 针对输入的不同低分辨率流场数据, 与传统插值方法、基于深度学习的 SRGAN 和 SRCNN 方法相比, 所提出的 FlowDiffusionNet 模型可以高精度地重建流场数据. 在各种经典流场重建中, 应用提出的模型 FlowDiffusionNet 预测 HR 流场残差的性能表现比直接预测 HR 流场更加优异.

(2) FlowDiffusionNet 模型具有良好的泛化能力, 适用于多种复杂湍流流场的超分辨率重建工作. 在实验中, FlowDiffusionNet 模型表现十分稳定, 在  $\alpha = 4$  和  $\alpha = 8$  不同分辨率流场重建任务上, 客观评价指标 SSIM 波动值小于 0.014.

(3) FlowDiffusionNet 模型可以高精度地重建涡结构, 对于 DNS 和 SQG 流场, 即使在  $\alpha = 16$  超低分辨率下, 其客观评价指标也可以达到 0.98 以上. FlowDiffusionNet 模型还具有较好的迁移性, 在训练阶段可以节省大量时间.

(4) 与文中其他方法相比, FlowDiffusionNet 模型在速度场和涡量场可视化中展示了更多流场重建细节. 尤其对于在训练中未直接考虑的涡量场, FlowDiffusionNet 模型仍然具有较好的重建效果, 而其他方法的重建性能则大幅降低.

该工作证明了扩散模型在流场超分辨率重建任务中的巨大潜力. 未来将研究模型轻量化, 从而实现低成本和高精度的重建.

## 参 考 文 献

- 1 Yang L, Zhang ZL, Song Y, et al. Diffusion models: A comprehensive survey of methods and applications. arXiv, 2022: 2209.00796
- 2 Yu C, Bi X, Fan Y. Deep learning for fluid velocity field estimation: A review. *Ocean Engineering*, 2023, 271: 113693
- 3 陈皓, 郭明明, 田野等. 卷积神经网络在流场重构研究中的进展. *力学学报*, 2022, 54(9): 2343-2360 (Chen Hao, Guo Mingming, Tian Ye, et al. Progress of convolutional neural network in flow field reconstruction. *Chinese Journal of Theoretical and Applied Mechanics*, 2022, 54(9): 2343-2360 (in Chinese))
- 4 Guo X, Li W, Iorio F. Convolutional neural networks for steady flow approximation//22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco. Assoc Computing Machinery, 2016: 481-490
- 5 Lee Y, Yang H, Yin Z. PIV-DCNN: cascaded deep convolutional neural networks for particle image velocimetry. *Experiments in Fluids*, 2017, 58: 1-10
- 6 Cai S, Liang J, Gao Q, et al. Particle image velocimetry based on a deep learning motion estimator. *IEEE Transactions on Instrumentation and Measurement*, 2019, 69(6): 3538-3554
- 7 Lagemann C, Lagemann K, Mukherjee S, et al. Deep recurrent optical flow learning for particle image velocimetry data. *Nature Machine Intelligence*, 2021, 3(7): 641-651
- 8 Dong C, Loy CC, He K, et al. Image super-resolution using deep convolutional networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 38(2): 295-307
- 9 Kim J, Lee J K, Lee KM. Accurate image super-resolution using very deep convolutional networks//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 29th IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas. Institute of Electrical and Electronics Engineers Inc, 2016: 1646-1654
- 10 Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 30th IEEE Conference on Computer Vision and Pattern Recognition, Honolulu. Institute of Electrical and Electronics Engineers Inc, 2017: 4681-4690
- 11 Tong T, Li G, Liu X, et al. Image super-resolution using dense skip connections//Proceedings of the IEEE international conference on computer vision, 16th IEEE International Conference on Computer Vision, Venice. Institute of Electrical and Electronics Engineers Inc, 2017: 4799-4807
- 12 Zhang Y, Li K, Li K, et al. Image super-resolution using very deep residual channel attention networks//Lecture Notes in Computer Science, 15th European Conference on Computer Vision (ECCV), Munich. Springer Verlag, 2018: 286-301
- 13 Lee J, Lee S, You D. Deep learning approach in multi-scale prediction of turbulent mixing-layer. arXiv, 2018: 1809.07021
- 14 Deng Z, He C, Liu Y, et al. Super-resolution reconstruction of turbulent velocity fields using a generative adversarial network-based artificial intelligence framework. *Physics of Fluids*, 2019, 31(12): 125111
- 15 Wang X, Yu K, Wu S, et al. Esrgan: Enhanced super-resolution generative adversarial networks//Lecture Notes in Computer Science, 15th European Conference on Computer Vision, Munich, 2018. Springer Verlag, 2019: 63-79
- 16 Fukami K, Fukagata K, Taira K. Super-resolution reconstruction of turbulent flows with machine learning. *Journal of Fluid Mechanics*, 2019, 870: 106-120
- 17 Liu B, Tang J, Huang H, et al. Deep learning methods for super-resolution reconstruction of turbulent flows. *Physics of Fluids*, 2020, 32(2): 025105
- 18 Kong C, Chang JT, Li YF, et al. Deep learning methods for super-resolution reconstruction of temperature fields in a supersonic combustor. *AIP Advances*, 2020, 10(11): 115021
- 19 Ferdian E, Suinesiaputra A, Dubowitz DJ, et al. 4 DFlowNet: super-resolution 4D flow MRI using deep learning and computational fluid dynamics. *Frontiers in Physics*, 2020, 8: 138
- 20 Fukami K, Fukagata K, Taira K. Machine-learning-based spatio-temporal super resolution reconstruction of turbulent flows. *Journal of Fluid Mechanics*, 2021, 909: A9
- 21 Bi X, Liu A, Fan Y, et al. FlowSRNet: A multi-scale integration network for super-resolution reconstruction of fluid flows. *Physics of Fluids*, 2022, 34(12): 127104
- 22 Raissi M, Perdikaris P, Karniadakis GE. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 2019, 378: 686-707
- 23 Raissi M, Yazdani A, Karniadakis GE. Hidden fluid mechanics: Learning velocity and pressure fields from flow visualizations. *Science*, 2020, 367(6481): 1026-1030
- 24 Shu D, Li Z, Farimani AB. A physics-informed diffusion model for high-fidelity flow field reconstruction. *Journal of Computational Physics*, 2023, 478: 111972
- 25 Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models. *Advances in Neural Information Processing Systems*, 2020, 33: 6840-6851
- 26 Song Y, Sohl-Dickstein J, Kingma DP, et al. Score-based generative modeling through stochastic differential equations. arXiv, 2020: 2011.13456
- 27 Saharia C, Ho J, Chan W, et al. Image super-resolution via iterative refinement. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 45(4): 4713-4726
- 28 Li H, Yang Y, Chang M, et al. Srdiff: Single image super-resolution with diffusion probabilistic models. *Neurocomputing*, 2022, 479: 47-59
- 29 Liu J, Tang J, Wu G. Residual feature distillation network for lightweight image super-resolution//Computer Vision –ECCV 2020 Workshops, Glasgow, 2020. Springer International Publishing, 2020: 41-55
- 30 Lu C, Zhou Y, Bao F, et al. Dpm-solver: A fast ode solver for diffusion probabilistic model sampling in around 10 steps. arXiv, 2022: 2206.00927
- 31 Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need//Proceedings of the 31st International Conference on Neural Information Processing Systems, December 2017: 6000-6010
- 32 Carlier J. Second set of fluid mechanics image sequences. European Project Fluid Image Analysis and Description, Project No. FP6-513663, 2005
- 33 Resseguier V, Mémin E, Chapron B. Geophysical flows under location uncertainty, Part II: Quasi-geostrophy and efficient ensemble spreading. *Geophysical & Astrophysical Fluid Dynamics*, 2017, 111(3): 177-208
- 34 Li Y, Perlman E, Wan M, et al. A public turbulence database cluster and applications to study Lagrangian evolution of velocity increments in turbulence. *Journal of Turbulence*, 2008, 9: N31
- 35 Song J, Meng C, Ermon S. Denoising diffusion implicit models. arXiv, 2020: 2010.02502
- 36 Keys R. Cubic convolution interpolation for digital image processing. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1981, 29(6): 1153-1160