

文章编号: 1007-7294(2024)03-0319-09

非定常流场时程重构的深度学习方法

战庆亮^{1,2}, 白春锦¹, 吴智虎¹, 葛耀君²

(1. 大连海事大学 交通运输工程学院, 辽宁 大连 116026; 2. 同济大学 桥梁结构抗风技术交通行业
重点实验室, 上海 200092)

摘要: 高分辨率的流场数据对流动问题的研究具有重要意义。受测量方法、计算效率等多因素限制, 高分辨率流场的直接获取仍有一定困难。本文基于流场时程数据的低维表征模型, 提出非定常流动时程数据重构的深度学习方法。该方法直接面向样本时程数据, 凭借一维卷积的特性提取出样本中包含的时程特征; 然后, 建立物理空间与表征模型编码空间之间的映射关系; 最后, 利用一维反卷积对低维表征进行解码, 实现对流场中任意位置数据的重构。对 $Re_D=200$ 的非定常圆柱层流绕流流场进行低维表征与验证, 进而实现高分辨率流场时程数据的重构, 并证明方法的准确性。本文方法是一种无监督方法, 是一种时间维度上具有高精度的流场数据重构方法, 适用于基于传感器的时程数据处理。

关键词: 流场重构; 流场时程; 深度学习; 特征提取; 无监督模型

中图分类号: O357.5 **文献标识码:** A **doi:** 10.3969/j.issn.1007-7294.2024.03.001

Unsteady flow time history reconstruction based on deep learning

ZHAN Qing-liang^{1,2}, BAI Chun-jin¹, WU Zhi-hu¹, GE Yao-jun²

(1. College of Transportation and Engineering, Dalian Maritime University, Dalian 116026, China; 2. Key Laboratory of Transport Industry of Wind Resistant Technology for Bridge Structures, Tongji University, Shanghai 200092, China)

Abstract: High-resolution flow field data are of great significance to the study of fluid mechanics. Limited by measurement methods and calculation efficiency, it is still difficult to obtain high-resolution flow fields directly in some circumstances. A low-dimensional representation model for flow time history data was proposed, and a deep learning method for reconstruction of unsteady flow time history data was developed. The proposed method extracted the time-history features contained in the samples using one-dimensional convolution directly; then, the mapping from the physical space and the encoding space was built; and finally, the decoder in the representation model was utilized to generate flow time history data at unknown positions. Unsteady laminar flow with $Re_D=200$ was studied, and the accuracy of the method was verified. The method proposed in this paper, a new flow field data reconstruction method in an unsupervised training manner in the time dimension, can be widely used in point-based sensor data analysis.

Key words: flow reconstruction; flow time history; deep learning; feature extraction; unsupervised model

收稿日期: 2023-09-16

基金项目: 大连海事大学博联科研基金项目(3132023619); 国家自然科学基金项目(51978527);

桥梁结构抗风技术交通行业重点实验室(上海)开放课题(KLWRTBMC21-02);

辽宁省教育厅研究计划资助(LJKZ0052); 中央高校基本科研业务费专项资金资助(3132022189)

作者简介: 战庆亮(1987-), 男, 博士, 讲师, 通讯作者; E-mail: zhanqingliang@163.com;

葛耀君(1958-), 男, 博士, 教授。

0 引 言

高分辨率的流场数据对于流体力学的研究至关重要,如船舶绕流分析^[1-2]、海洋结构的绕流^[3-5]及流固耦合问题研究等。然而,高分辨率流场的直接获取往往存在一些困难:在数值模拟领域,实现高分辨率的流场数据需要增加计算网格的密度,而这也伴随着求解效率的降低;在流体实验方面,流场中的某些位置可能无法布设传感器,而 PIV 方法仍难以实现大范围的三维全场测量。针对这些问题,本文提出一种基于深度学习的高分辨率流场重构方法。

深度学习方法能够有效地分析复杂数据的内在规律,因而在处理流场的强非线性特性方面具有突出优势,为流体力学的研究提供了新的方法^[6]。例如在基于数据建模的湍流模型研究中发挥了重要作用^[7],将数据与物理信息相结合可得到更高精度的湍流模型^[8],是一种重要的新的研究方法^[9]。另一方面,深度学习方法在复杂流动的模式分解^[10]、流固耦合分析^[11]等方面得到了应用。同时,深度学习方法也可用作偏微分方程的求解新工具^[12],进一步实现流场与结构的耦合分析^[13]。

深度学习方法也成为了流场重构问题的新的研究方法^[14-15]。例如 Maulik 等^[16]提出了单层前馈人工神经网络模型,可以将低分辨率且包含噪声的流场数据还原得到可靠的高分辨率流场;Fukami^[17]提出了混合下采样跳过多尺度模型,同样实现了由低分辨率图像重建高分辨率的湍流流场数据,且该方法能较准确地保留湍流动能谱;Liu^[18]提出的多时间路径卷积神经网络以速度场时间序列作为输入,融合了连续流体场的时空信息,可精确提取时间相关信息,成功用于湍流和各向异性通道的超分辨率重构;Kim^[19]借助循环一致生成对抗网络成功地克服了监督学习的数据配对要求,能够使用未配对的湍流数据进行训练,以实现湍流场的超分辨率重建。

前述深度学习技术专注于处理流场的实验数据或模拟数据快照,运用图像重构技术以完成数据处理。本文从时程数据的特征提取与表征方式出发进行流场重构,其中文献[20-22]对流场时程特征的提取方法开展了研究,为本文的重构模型提供了依据。本文通过建立非定常流动数据的低维表征模型,构造物理空间与编码空间的对应关系,并采用解码器生成新的时程数据,方法面向时程数据且具有较高的时间维度准确性,相比于传统基于快照的重构方法具有一定的优势。

1 非定常流动的低维表征模型

流体受到固体表面的干扰后,会形成复杂的流动分离等现象,导致流场中不同区域内的流动特征各不相同,这种非定常流动系统不仅具有高度复杂性还蕴含了丰富的流动特征。前期的研究结果表明,一维卷积的深度学习模型可以准确地捕捉到时程的流动信息,并以更低的维度表征这些特征。因此,对时程的流动信息进行准确的低维表征是流场高分辨率重构的关键。在此基础上,本文提出基于一维卷积流场时程自动编码(flow time history autoencoder, FTH-AE)的流动低维表征模型,将高维时序特征映射到低维抽象空间内,简化流动系统的复杂度。

图 1 所示模型结构包含五个主要部分,即输入层、卷积编码器、特征代码层、卷积解码器以及输出层。输入层接收流场不同位置处的时程数据 x , 经过编码过程以提取和压缩特征,进而获得低维特征向量 λ ; 随后,特征代码经由卷积解码器进行还原,以产生与输入时程信号相等的输出 x' 。




图 1 FTH-AE 模型结构示意图

Fig.1 Architecture of FTH-AE model

为保证时程特征重构的准确性,在构建FTH-AE模型时,首先根据流场及其样本特征,选择合适的卷积编码器结构;其次,编码器与解码器需满足下式的变换,来保证特征代码 λ 可以准确表征输入 x 的特征:

$$\begin{aligned} \lambda &= F_e(x) \\ x' &\approx F_d(\lambda) \end{aligned} \tag{1}$$

式中, F_e 表示卷积编码器, F_d 代表卷积解码器, x 为输入的流场时程数据, λ 为流场时程的特征编码。由其结构可知,在FTH-AE模型中输入数据与输出数据具有相同的属性,即两者时程的长度与采样间隔是相同的。本文的FTH-AE模型采用无监督学习训练方法,模型输出时程后利用反向传播算法使其与输入时程尽可能相同,进而保证特征向量 λ 最大程度地保留了原有的数据信息。编码器中卷积层对输入数据的计算过程为

$$C_t^{n,k} = \varphi(\omega^{n,k} \times x_{t-l/2:t+l/2}^{n-1,k} + b^n) \forall t \in [1, T], k \in [1, K] \tag{2}$$

式中, T 为输入数据的长度, l 为卷积核的大小, K 为当前层的卷积通道个数。在计算过程中,各通道采用了“共权重值参数 w ”的方法,在减少模型参数个数的同时共享了偏置矩阵 b 。基于流场时程的编码卷积计算原理如图2所示,编码器通过卷积层从输入时程中逐层提取特征,且层数越深,特征的维度越低,抽象程度越高。在训练后,如果模型的输出数据与输入数据近似相等,则表明高维数据已成功映射到低维特征向量 λ 中。




图2 时程卷积的计算过程

Fig.2 Time-convolutional calculation procedure

2 流场时程数据的生成方法

FTH-AE模型建立了流场时程数据到其自身低维表征的映射关系,其中低维的特征向量 λ 、编码器与解码器共同实现了整个流场时程数据的低维表征。编码器建立了流场中不同位置处时程样本到低维度编码空间的映射,而解码器则将编码空间中的低维向量还原成物理空间对应位置处的时程信号。因此,求解出物理空间中任意点映射在编码空间的低维度特征向量,即可通过解码器生成该位置的流场时程样本,其原理如图3所示。




图3 时程的生成原理

Fig.3 Generation method of FTH

如图3所示,已知物理空间中测点 P_1 与测点 P_2 的空间坐标位置及其时程样本,则可以通过编码器

获得两个样本在编码空间中的编码 P_1' 和 P_2' 。对于物理空间中 P_1 和 P_2 附近的未知点 r , 即 r 点处的流场时程是未知的, 此时可以根据 P_1 、 P_2 与 r 之间的几何关系, 由 P_1' 和 P_2' 构造得到编码空间的 r' , 利用 r' 和解码器还原得到物理空间 r 处的时程样本, 即平均向量组合法 (average vector combination, AVC)。具体做法为: 在 r 附近选择多对已知样本点, 其坐标分量分别为 p_i 与 q_i , 采用两个物理空间中的已知样本点向量构造待求 r 向量, $\alpha p_i + \beta q_i = r$, 从而得到编码空间中待求像的位置为

$$r' = \frac{1}{n} \sum_{i=1}^n \alpha_i p_i' + \beta_i q_i' \tag{3}$$

式中, n 表示所进行平均的组数。

3 算例与分析

本文以低雷诺数下的圆柱绕流场为例, 采用数值模拟方法获得流场数据, 验证方法的准确性。计算域如图 4 所示, 雷诺数 $Re_D=200$ 。其中圆柱的直径为 D , 计算域的顺流向长为 $44D$, 横向长度为 $48D$, 上、下游长度均为 $22D$ 。圆柱周围矩形区域内使用较密的非结构化三角形网格, 距离圆柱较远的区域使用较稀疏的网格。左侧为来流入口边界, 右侧是压力出口边界。

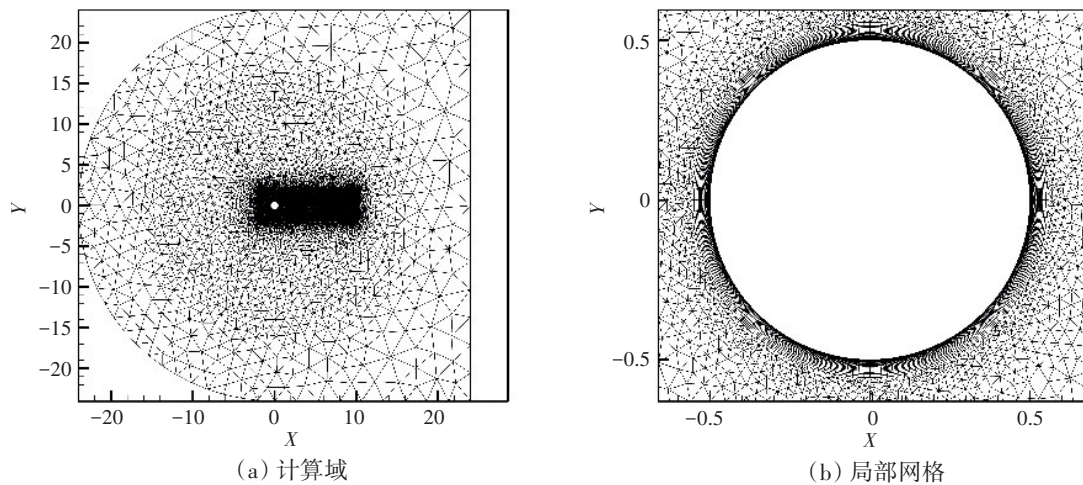


图4 整体及局部的网格划分

Fig.4 Global and local meshes distribution

考虑到圆柱周围区域的流场特征更加丰富多样, 在圆柱周围选取了 6892 个测点, 均匀分布在流场计算网格密集的矩形区域内, 测点分布如图 5 所示。在流场计算的每个时间步结束时, 输出各测点的流向速度与横向速度, 得到两物理量的时程集合。

3.1 FTH-AE 模型参数

FTH-AE 模型参数如表 1 所示, 编码器中三层卷积层的核数为 128、64 与 16, 并使用尺寸为 13 的大卷积核来获得更大的局部视野。经过卷积层逐层提取特征后输出样本的尺寸为 1000×16 。为了保留卷积权重与时程序列之间的对应关系, 本文使用 Flatten 层附加通道数为 2 的全连接层进行降维, 最终将单个时程样本压缩为 2 维空间中的一点。由于自编码器具有对称性, 模型的解码部分各参数与编码部分相对应。




图5 测点位置示意图

Fig.5 Location of sampling points

表1 自动编码特征降维模型参数

Tab.1 FTH-AE model parameters

Layer	Channel	Kernel size	Stride	Activation	Parameters
Conv 1	128	13	1	ReLU	1280
Conv 2	64	13	1	ReLU	73792
Conv 3	16	13	1	ReLU	9232
Flatten layer	/	/		/	0
Dense layer	2	/		ReLU	32002
Reshape layer	/	/	/	/	0
Conv_T 1	16	13	1	ReLU	2320
Conv_T 2	64	13	1	ReLU	9280
Conv_T 3	128	13	1	ReLU	73856
输出	1	13	1	ReLU	1153

本文在训练时使用无监督学习模式,并在流场时程数据中随机选取50%的样本进行训练,另外的样本用作模型预测结果的验证集。模型优化器为Adam并设置学习率为默认参数,可通过自适应调整学习率加速模型收敛。模型训练时,Batch_size大小设置为4,损失函数采用均方误差MSE,网络各层的激活函数均为ReLU。训练次数为200次的Loss曲线如图6所示,随着迭代次数的增加,网络在训练50次时Loss曲线开始趋于稳定,训练100次后Loss曲线达到收敛值0.0005,训练结束后保存Loss值最优模型。





图6 FTH-AE模型的训练损失值


Fig.6 Loss of FTH-AE with respect to epochs

3.2 模型表征的准确性验证

FTH-AE模型在训练过程中不需要带有标签的样本,也不需要成对的样本,其训练目标是自身的解码误差最小。本文选用MSE损失函数来衡量模型输入时程与输出时程的差异,损失值越小说明网络对输入数据特征提取越精准。为了直观展示模型的准确性,本文在整个流场区域随机选取了3条参数U、V的样本并比较原始曲线与模拟曲线的差异值。由图7可知,原始数据与由低维编码还原得到的时程曲线差异很小,两条曲线几乎重合,说明模型可以准确地提取到流场中各个测点处数据的低维度特征,验证了降维模型的可行性。



(a) 流向速度结果



(b) 流向速度结果的局部比较

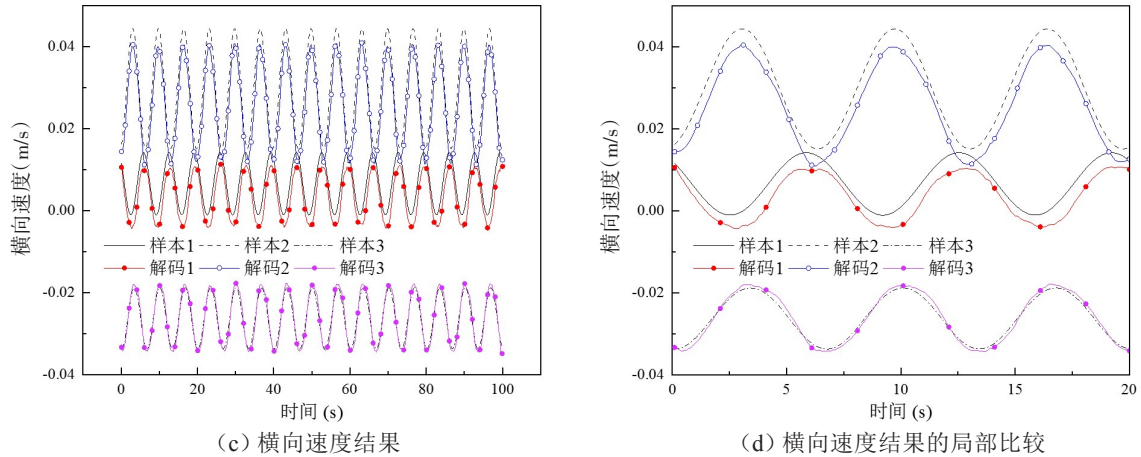


图 7 原始时程与 FTH-AE 模拟的时程

Fig.7 Original samples and FTH-AE result

为验证整个流场中的模型解码精度, 本文将各点位置处的输入时程与解码时程之间的相对误差进行无量纲化, 记为 R_{err} (relative error),

$$R_{err} = \sum_{i=1}^n \frac{(x_i - x'_i)}{n(x_{max} - x_{min})} \quad (4)$$

式中, x 为原始输入时程, x' 为输出的解码时程, n 为时程长度, max 与 min 分别为时程的最大值与最小值。由于数据集中的时程曲线形态多样, 相对误差 R_{err} 更加合理地表示了各点误差与时程振幅之间的相对关系, 直观地展示出解码时程对原始时程的拟合准确性。

将所得到的误差值赋予不同颜色并按照测点坐标绘制散点图, 如图 8 所示。其中绿色、蓝色、黄色、橘色和红色分别表示误差值为 0~0.1、0.1~0.15、0.15~0.2、0.2~0.3 和 0.3~0.5 的区域。由图可见, FTH-AE 模型很好地对输入时程数据进行了低维表征, 并准确地解码还原了输入时程。




图 8 模型解码的误差分布图

Fig.8 Error distribution of model reconstruction

3.3 模型预测的准确性验证

进一步对验证集中的测点物理坐标进行 AVC 组合, 获得这些点在编码空间中的坐标集。对坐标集中的编码坐标进行 FTH-generate 解码预测, 获得各点处的预测时程。同样随机选取了 6 条预测时程, 与 CFD 计算值进行了比较, 如图 9 所示。

对比图 9 中的结果可发现, 本文方法成功地对时程进行了预测, 并求得各时程预测结果的相对误差, 列于图 10。比较图 10 和图 8 可知, 预测时程的精度要低于还原时程精度, 尤其在上游来流区以及圆柱壁面附近, 相对误差较大。主要原因可分为两方面: 一方面根据相对误差的定义, 由于上游来流区域的流场波动较小, 导致式 (4) 时程的最大值与最小值相差较小, 因此相对误差较大; 另一方面, 圆柱表面附近流动梯度较大, 在训练样本较稀疏的情况下流场的预测时程难以准确预测分离区内部流场的变化, 导致相对误差较大。

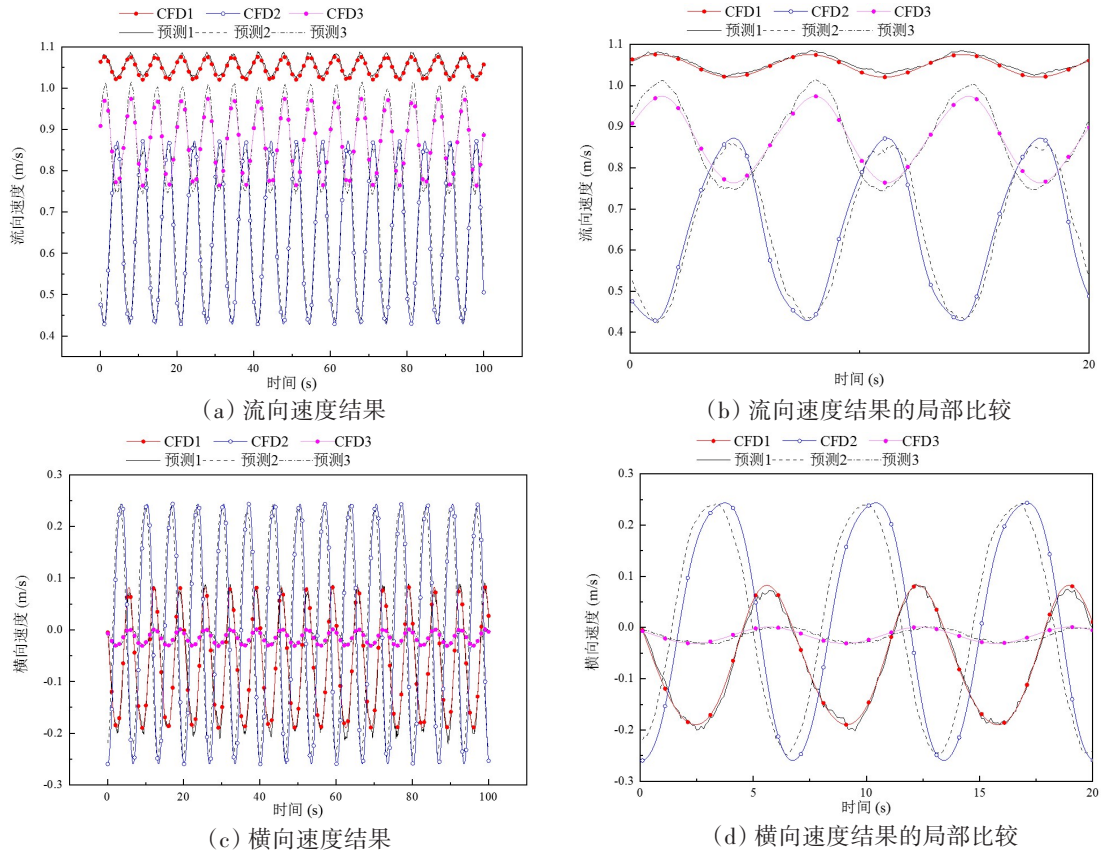


图9 模型的预测曲线

Fig.9 Original samples and FTH-AE result





图10 模型预测误差分布图

Fig.10 Error distribution of model prediction

进一步地,对所有预测的流场时程数据取同一瞬时的值,就可以得到整个流场的瞬态结果,见图11。其中图11(a)和(d)分别为流向速度与横向速度的输入样本分布,图11(b)和(d)为FTH-AE模型



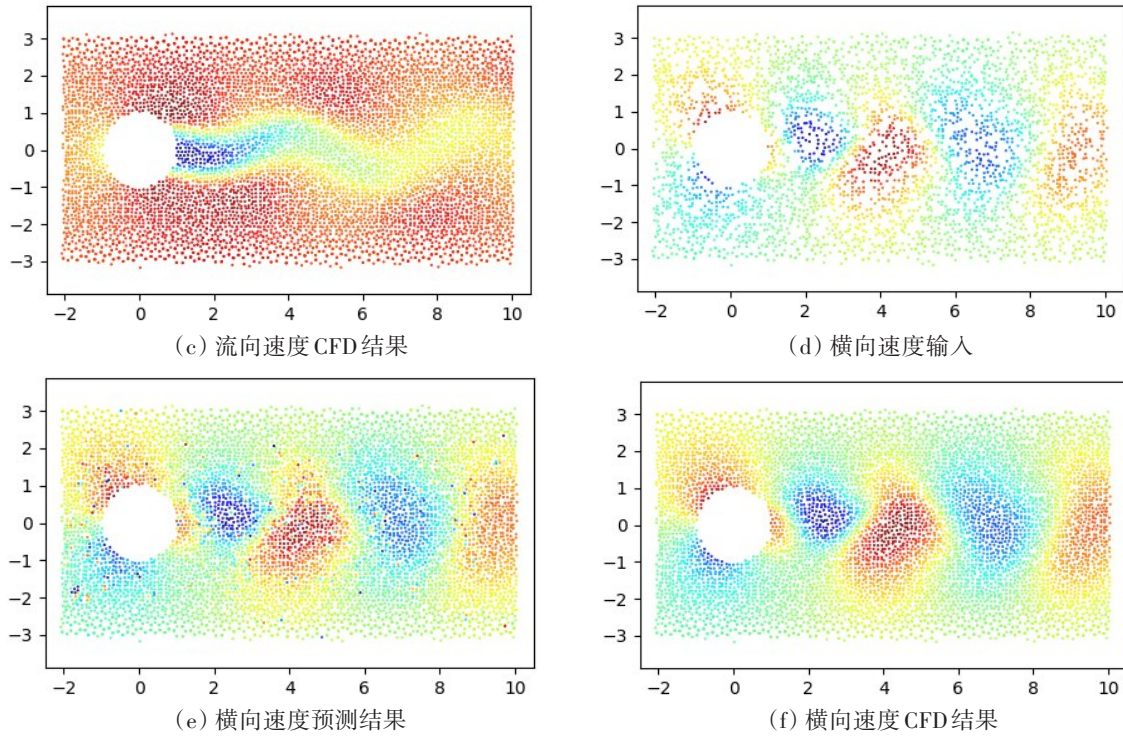


图11 重构时程的瞬态结果

Fig.11 Instantaneous results of FTH reconstruction

的预测结果,图11(c)和(f)为CFD计算结果。由图中结果可以发现,本文方法成功地对稀疏的输入流场进行了较准确的重构,然而在部分位置预测结果出现了一定差异,计算方法仍需改进。

4 结 论

本文提出了一种基于流场时程的FTH-AE模型,通过其实现了复杂流动的低维表征,并进一步实现了流场时程的重构,得到以下结论:

(1) 本文提出的FTH-AE模型,可较准确地将全场的流场时程投影到低维编码空间中,实现层流流场的低维表征。

(2) 利用FTH-AE模型结合AVC向量映射方法,可实现未知测点处流场时程的重构,并对 $Re_D=200$ 的圆柱绕流问题成功地实现了流场时程重构。

(3) 本方法是一种无监督学习方法,无需高空间分辨率样本,可广泛应用于基于单点时程的流动测量数据中,是一种全新的方法。

参 考 文 献:

- [1] 邓 辉, 张志宏, 王克彬, 等. 跨临界航速船舶水压场数值模拟研究[J]. 船舶力学, 2020, 24(11): 1383-1392.
Deng Hui, Zhang Zhihong, Wang Kebin, et al. Numerical calculation of hydrodynamic pressure field caused by a ship sailing at a transcritical speed[J]. Journal of Ship Mechanics, 2020, 24(11): 1383-1392. (in Chinese)
- [2] 沈文君, 赵志娟, 刘利琴, 等. 波浪周期对小型船舶动力响应的影响研究[J]. 船舶力学, 2022, 26(3): 342-352.
Shen Wenjun, Zhao Zhijuan, Liu Liqin, et al. Research of wave period effect on the dynamic response characteristics of a small ship[J]. Journal of Ship Mechanics, 2022, 26(3): 342-352. (in Chinese)
- [3] 李 臣, 孙培廷. 低雷诺数下襟翼缝隙几何参数对双元素翼帆推进特性的影响研究[J]. 船舶力学, 2022, 26(2): 192-201.

- Li Chen, Sun Peiting. Influence of slot geometry parameters of the flap on the propulsion characteristics of two-element wing-sail at low Reynolds number[J]. *Journal of Ship Mechanics*, 2022, 26(2): 192–201. (in Chinese)
- [4] 马哲, 程勇, 翟钢军. 基于CFD流固耦合理论的海上浮式结构物水动力性能分析[J]. *船舶力学*, 2017, 21(8): 950–959.
- Ma Zhe, Cheng Yong, Zhai Gangjun. Hydrodynamic performance of the floating body based on CFD fluid-body interaction theory[J]. *Journal of Ship Mechanics*, 2017, 21(8): 950–959. (in Chinese)
- [5] 张智奇, 任浩杰, 付世晓, 等. 均匀流作用下双柔性异管径立管响应特性试验研究[J]. *船舶力学*, 2021, 25(1): 16–28.
- Zhang Zhiqi, Ren Haojie, Fu Shixiao, et al. Experimental study on response characteristics of double flexible pipe with different diameters under uniform flow[J]. *Journal of Ship Mechanics*, 2021, 25(1): 16–28. (in Chinese)
- [6] 金晓威, 赖马树金, 李惠. 物理增强的流场深度学习建模与模拟方法[J]. *力学学报*, 2021, 53(10): 2616–2629.
- Jin Xiaowei, Laima Shujin, Li Hui. Physics-enhanced deep learning methods for modelling and simulating flow fields[J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2021, 53(10): 2616–2629. (in Chinese)
- [7] Duraisamy K, Iaccarino G, Xiao H. Turbulence modeling in the age of data[J]. *Annual Review of Fluid Mechanics*, 2019, 51(1): 357–377.
- [8] Ling J, Kurzawski A, Templeton J. Reynolds averaged turbulence modelling using deep neural networks with embedded invariance[J]. *Journal of Fluid Mechanics*, 2016, 807: 155–166.
- [9] Kutz J N. Deep learning in fluid dynamics[J]. *Journal of Fluid Mechanics*, 2017, 814: 1–4.
- [10] Murata T, Fukami K, Fukagata K. Nonlinear mode decomposition with convolutional neural networks for fluid dynamics[J]. *Journal of Fluid Mechanics*, 2020, 882: A13.
- [11] Omata N, Shirayama S. A novel method of low-dimensional representation for temporal behavior of flow fields using deep autoencoder[J]. *Aip Advances*, 2019, 9(1): 015006.
- [12] Raissi M, Karniadakis G E. Hidden physics models: Machine learning of nonlinear partial differential equations[J]. *Journal of Computational Physics*, 2018, 357: 125–141.
- [13] Raissi M, Wang Z, Triantafyllou M S, et al. Deep learning of vortex-induced vibrations[J]. *Journal of Fluid Mechanics*, 2019, 861: 119–137.
- [14] Callahan J, Maeda K, Brunton S L. Robust flow field reconstruction from limited measurements via sparse representation[J]. *Phys. Rev. Fluids*, 2019, 4(10): 103907.
- [15] Deng Z, He C, Liu Y, et al. Super-resolution reconstruction of turbulent velocity fields using a generative adversarial network-based artificial intelligence framework[J]. *Physics of Fluids*, 2019, 31(12): 125111.
- [16] Maulik R, San O. A neural network approach for the blind deconvolution of turbulent flows[J]. *Journal of Fluid Mechanics*, 2017, 831: 151–181.
- [17] Fukami K, Fukagata K, Taira K. Super-resolution reconstruction of turbulent flows with machine learning[J]. *Journal of Fluid Mechanics*, 2019, 870: 106–120.
- [18] Liu B, Tang J, Huang H, et al. Deep learning methods for super-resolution reconstruction of turbulent flows[J]. *Physics of Fluids*, 2020, 32(2): 025105.
- [19] Kim H, Kim J, Won S, et al. Unsupervised deep learning for super-resolution reconstruction of turbulence[J]. *Journal of Fluid Mechanics*, 2021, 910: A29.
- [20] 战庆亮, 白春锦, 葛耀君. 基于时程深度学习的流场特征分析方法[J]. *力学学报*, 2022, 54(03): 822–828.
- Zhan Qingliang, Bai Chunjin, Ge Yaojun. Fluid feature analysis based on time history deep learning[J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2022, 54(03): 822–828. (in Chinese)
- [21] 战庆亮, 白春锦, 张宁, 等. 基于时程卷积自编码的机翼绕流特征识别方法[J]. *航空学报*, 2022, 43(11): 126531.
- Zhang Qingliang, Bai Chunjin, Zhang Ning, et al. Feature extraction method of flow around wing based on time history convolutional autoencoder[J]. *Acta Aeronautica et Astronautica Sinica*, 2022, 43(11): 126531. (in Chinese)
- [22] 战庆亮, 葛耀君, 白春锦. 基于深度学习的流场时程特征提取模型研究[J]. *物理学报*, 2022, 71(07): 225–234.
- Zhan Qingliang, Ge Yaojun, Bai Chunjin. Flow feature extraction models based on deep learning[J]. *Acta Physica Sinica*, 2022, 71(07): 225–234. (in Chinese)