

doi: 10.19562/j.chinasae.qcgc.2024.07.017

基于LSTM-POD的汽车湍流尾迹的高时间分辨 速度场重构*

杨志刚^{1,2,3}, 李侯静^{1,2}, 夏超^{1,2}, 王梦佳^{1,2}, 余磊^{1,2}

(1. 同济大学汽车学院, 上海 201804; 2. 同济大学上海地面交通工具风洞中心, 上海 201804;

3. 北京民用飞机技术研究中心, 北京 102211)

[摘要] 本文针对方背 Ahmed 汽车标模的湍流尾迹, 建立基于长短时记忆法(long short-term memory, LSTM)和本征正交分解(proper orthogonal decomposition, POD)相结合的深度学习模型LSTM-POD。通过建立非时间分辨平面速度场POD模态系数和若干离散点的时间分辨速度信号的映射关系, 实现了方背 Ahmed 汽车标模湍流尾迹流场的高时间分辨率重构, 并对比了不同时间步长配置, 即单时间步长(LSTM-Sin)和多时间步长(LSTM-Mul)对重构效果的影响。研究表明:LSTM-POD模型在时间序列重构中具有较强的学习和泛化能力。另外,LSTM-Mul考虑到了时间上的连续性和相关性, 相较于LSTM-Sin, 其重构出的低阶模态系数和速度场与POD的重构结果更吻合。本研究提出的深度学习模型可以缓解通过实验及高精度数值模拟获取高时间分辨率流场数据资源消耗大、计算效率低等问题。

关键词: 汽车湍流尾迹; 深度学习; 流场重构; 本征正交分解; 长短时记忆法

A High Time-Resolution Reconstruction on the Automotive Turbulent Wake Based on LSTM-POD

Yang Zhigang^{1,2,3}, Li Yujing^{1,2}, Xia Chao^{1,2}, Wang Mengjia^{1,2} & Yu Lei^{1,2}

1. School of Automotive Studies, Tongji University, Shanghai 201804;

2. Shanghai Automotive Wind Tunnel Center, Tongji University, Shanghai 201804;

3. Beijing Aeronautical Science & Technology Research Institute, Beijing 102211

[Abstract] A deep-learning LSTM-based POD model (LSTM-POD) based on long short-term memory (LSTM) and proper orthogonal decomposition (POD) is developed for the turbulent wake of the square-back Ahmed automotive general model. A high time-resolution reconstruction is achieved by establishing the mapping relationship between the POD modal coefficients of the non-time-resolved planar velocity field and the time-resolved velocity signals at a number of discrete points, and the effect of different time-step configurations, i.e., the single time step (LSTM-Sin) and multiple time steps (LSTM-Mul) on the reconstruction results is compared. The results show that the LSTM-POD model has strong learning and generalization ability in time series reconstruction. In addition, LSTM-Mul considers temporal continuity and correlation, the reconstructed mode coefficients (lower order) and velocity fields of which are more consistent with the POD reconstructed results compared with that of LSTM-Sin. The deep learning model proposed in this study can alleviate the problems of high resource consumption and low computational efficiency in obtaining high time resolution flow field data through experiments and high-precision numerical simulation.

Keywords: turbulent wake of automobiles; deep learning; reconstruction of flow fields; POD; LSTM

* 国家自然科学基金(52372360)、国家重点研发计划项目(2022YFE0208000)、上海市地面交通工具空气动力与热环境模拟重点实验室(23DZ2229029)和中央高校基本科研业务费专项资金资助。

原稿收到日期为2023年11月26日, 修改稿收到日期为2024年01月19日。

通信作者: 夏超, 硕士生导师, 博士, E-mail: chao.xia@tongji.edu.cn。

前言

汽车是典型的三维钝体结构,其尾部气流分离,会形成复杂的非定常湍流尾迹,结构主要有3种^[1-3],分别为:长时间尺度的双稳态尾迹现象^[4]($T \approx 1000H/U_\infty$, H 为车高, U_∞ 为来流速度)、较低频的 Pumping 抽吸现象($S_i = f \times H/U_\infty = 0.07 \sim 0.08$, f 为涡脱落频率)^[5]和典型的涡脱落现象($S_i = 0.12 \sim 0.18$)^[6],通常呈现出强非线性、高维、多尺度和随机性等特征。在湍流尾迹流动研究中,一些高精细化实验测量和高精度数值模拟方法在流体力学领域被广泛应用。实验测量的典型方法有粒子图像测速技术(particle image velocimetry, PIV)^[7]。在高精度数值模拟方法方面,代表性的有直接数值模拟(direct numerical simulation, DNS)和非直接数值模拟,如大涡模拟(large eddy simulation, LES)、分离涡模拟(detached eddy simulation, DES)等^[8]。为了充分阐明湍流流动动力学特性,人们一直致力于对流场进行高时间和空间分辨率的测量。然而,同时测量兼具高时间和空间分辨率的流场是具有挑战性的。例如,粒子图像测速(PIV)具有较高的空间精度,但其采样频率通常小于 15 Hz,远低于湍流等复杂流动的频率带宽。尽管已经提出了时间分辨粒子图像测速(TR-PIV),但高速相机和高重复激光都很昂贵,并且 TR-PIV 的测量范围有限。此外,高精度非定常数值模拟,如 DNS、LES 和 DES,原则上可以获取时间分辨率的空间流场数据,但数据存储需要占用大量硬盘空间,成本较高,同时也会降低计算效率,严重制约了高时间分辨流场数据的生成。例如 Longa 等^[9]为了捕获大时间尺度的双模稳态行为,使用 LES 方法在帝国理工学院和 ARCHER(英国国家超级计算服务)集群上的数千个核心上运行了长达 8-10 天的模拟。Fan 等^[10]使用 IDDES(improved delayed detached eddy simulation)的方法,成功捕捉到了双稳态尾迹转换现象,但持续时间 $T=20.2$ s(即 $T^*=t/(H/U_\infty)=5612$),消耗约 14 万核时。杨志刚等^[11]同样使用 IDDES 的方法捕捉了更多次的双稳态尾迹转换过程,对于有无车轮的算例进行 40 s($T^*=5555.6$)长周期的非定常数值仿真计算,分别消耗约 40 万核时和 28 万核时。因此,迫切须考虑基于非时间分辨的流场来重构高时间分辨流场的新技术。

近年来,深度学习(deep learning, DL)在许多领

域都被成功应用,其具有以下 3 大特征:①更强的非线性描述能力;②很好的捕捉瞬态、间断和多尺度特征的能力;③平移、尺度和旋转不变性。因此,DL 拥有捕提高维输入和高维输出之间非线性映射的能力,特别适用于非线性动力学系统建模。2017 年,He 等^[12]提出了一种基于本征正交分解(proper orthogonal decomposition, POD)的空间细化方法,该方法使用具有低空间分辨率的 TR-PIV 和具有高空间分辨率的非 TR-PIV 来提高 TR-PIV 的空间分辨率。然而,它仍然需要 TR-PIV 测量,成本比较高昂。Deng 等^[13]随后将 TR-PIV 只用于测量几个离散下游位置的速度时间序列,具有高空间精度的 PIV 被用来测量全局流场,以获得 POD 模态和系数,然后使用长短时记忆法(long short-term memory, LSTM)将具有高时间分辨的速度时间序列映射到具有高空间分辨率的前几个 POD 系数中。训练完模型后, LSTM-POD 模型就可以获得具有高空间分辨率的时间分辨 POD 系数,最后通过 POD 处理就可以重构高时空分辨率的流场。Jin 等^[14]也同样应用了这个方法,只不过将 LSTM 网络替换为具有门控循环单元的双向循环神经网络(Bidirectional-GRU)。这样可以根据速度时间序列与速度空间分布之间的关系,使用“多对一”架构的循环神经网络来学习 POD 系数。但目前大部分 DL 模型都是用于雷诺数较低的二维基础形体层流流动,而工业应用中面对较多的是雷诺数较高的三维钝体湍流绕流。湍流具有强非线性、高自由度、多尺度、有序性与随机性并存的特点,尤其是针对本文所研究的方背 Ahmed 汽车模型非定常湍流尾迹,存在水平方向上长时间尺度不对称的双稳态现象、全局振荡以及回流区的抽吸现象 3 种不同的流动结构。DL 在此三维钝体的复杂湍流尾迹中的适用性还不清楚。

因此,本文探索将 DL 模型应用于更复杂的方背 Ahmed 汽车标模的非定常湍流尾迹高精度流动重构中,提高时间分辨流场数据的生成效率,期望可以节约风洞实验 PIV 高频测量和非定常数值计算的成本。

1 研究方法

1.1 深度学习模型的基本原理及实现方法

本文提出了一种基于 LSTM 的本征正交分解 POD 深度学习模型。基本原理及实现方法如图 1 所

示,分为3个部分。

第1部分,如图1绿色虚线框内所示,同步收集足够的非时间分辨(non-TR)仿真数据(蓝色矩形)与时间分辨(TR)速度信号(深黄色矩形),然后对由non-TR获得的流场执行POD,产生1组POD模态和non-TR模态系数。接着使用和non-TR数据相同的采样频率和时间步长对原始TR信号进行下采样,得到non-TR速度信号(浅黄色矩形)。将每组POD时间系数与其相应的速度信号配对来建立non-TR数据集。

第2部分,如图1红色虚线框内所示,构建一个

基于LSTM的回归模型来学习速度信号和POD时间系数之间的关系,并使用non-TR数据集进行训练。non-TR的速度信号 v 作为模型的输入,而系数是输出。

第3部分,如图1蓝色虚线框内所示,回归模型训练完毕,进入测试阶段。采用时间分辨的速度信号作为输入来评估模型,由于LSTM-POD模型只在低频下建立关系,因此测试样本应重新取样,使其具有与训练样本相同的频率。最终可使用时间分辨的系数和它们相应的模态来重构时间分辨的全局流场。

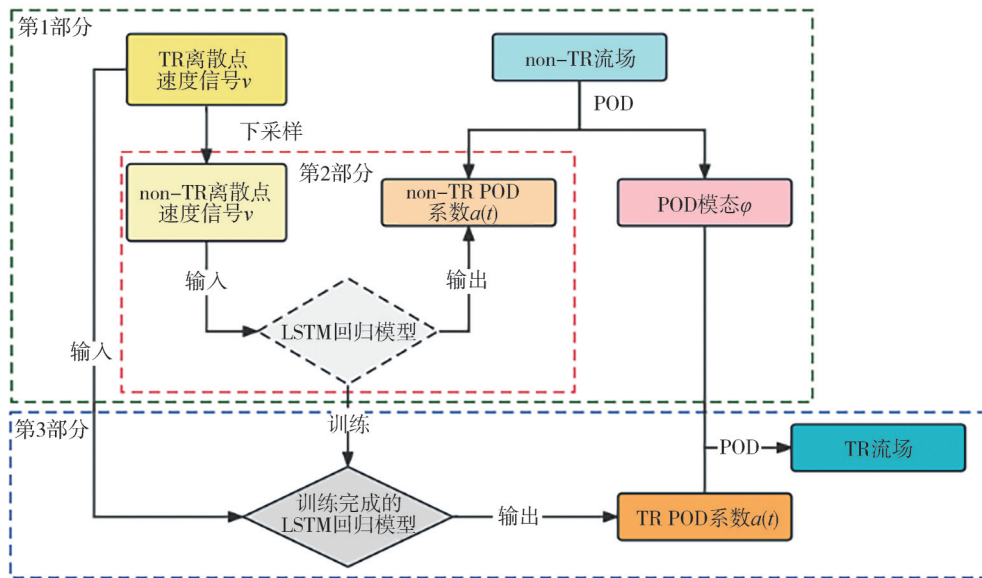


图1 LSTM-POD模型重构时间分辨流场实现方法

1.2 LSTM模型架构

模型的整体架构如图2所示,由3层LSTM网络层和2层批量归一化层BatchNormalization^[15]网络层组成。由于该问题是一个回归问题,因此选择均方

误差(mean square error, MSE)作为损失函数。在给定的输入速度信号及其对应的输出POD系数的情况下,网络的目标是寻找最优的权值和偏差,以最小化损失函数。

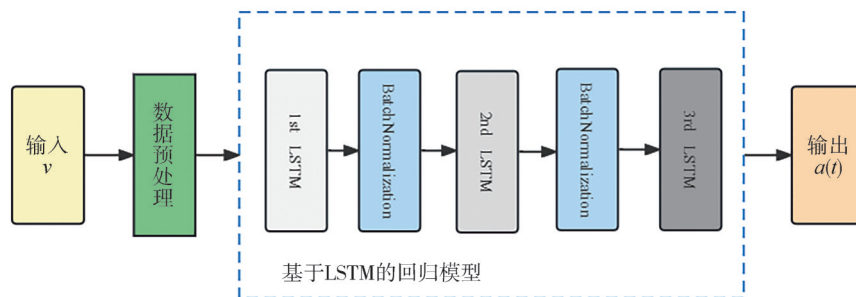


图2 基于LSTM的回归模型

数据预处理后被送到第1个LSTM层进行训练,随后采用BatchNormalization层将每层输入的均值和

方差固定在一定范围内,以加速深度神经网络的训练过程。它还可以起到正则化器的作用,减轻过拟

合的问题,提高神经网络的泛化能力。随后是 1 组 LSTM 层和 BatchNormalization 层,最后通过第 3 个 LSTM 层输出对应 POD 系数。

为了研究基于 LSTM-POD 模型的鲁棒性,采

用了 2 种不同配置的 LSTM-POD:单时间步长和多时间步长,如图 3 所示,蓝色虚线矩形表示单时间步长的结构,红色实线矩形表示多时间步长的结构。

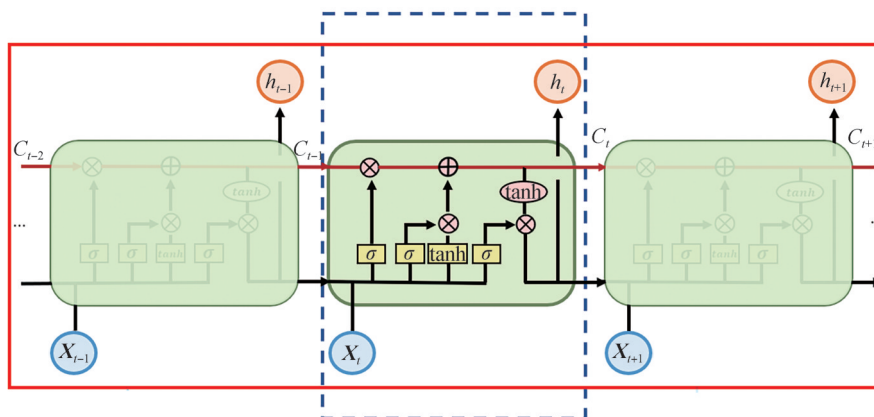


图3 2种配置的LSTM网络

1.3 LSTM模型训练

前面提及用到 2 类配置的 LSTM-POD 模型:单时间步长和多时间步长,在训练时每类配置都应用了 5 个 LSTM-POD 模型,共包含了前 100 阶 POD 时间系数,即每类配置中的每个模型包含 20 阶系数。

单时间步长和多时间步长的具体网络结构分别如表 1 和表 2 所示。表 1 中输入维度的 $(1, n_p)$, 数字 1 代表单个时刻,即单时间步长, n_p 代表流场中的离散点数,每个点的值都是单个时刻在该点处的速度信号,本次研究中 n_p 为 12,具体分布在下一节介绍。表 2 中输入维度的 $(5, n_p)$, 数字 5 代表 5 个时刻,也就是多时间步长数设置为 5。优化器均选用 Adam, LSTM 层的激活函数均为 tanh。每个包含 20 个时间系数输出的 LSTM-POD 模型都经过 2 000 轮次的训练,以训练误差曲线作为收敛的判据。训练样本被随机分为两组,80% 用于训练,20% 用于验证。

表1 LSTM网络结构(单时间步长)

网络层	输出维度
输入	(1, 12)
1st LSTM	(1, 128)
1st BatchNormalization	(1, 128)
2nd LSTM	(1, 64)
2nd BatchNormalization	(1, 64)
输出: 3rd LSTM	(1, 20)

表2 LSTM网络结构(多时间步长)

网络层	输出维度
输入	(5, 12)
1st LSTM	(5, 128)
1st BatchNormalization	(5, 128)
2nd LSTM	(5, 64)
2nd BatchNormalization	(5, 64)
输出: 3rd LSTM	(5, 20)

2 数据获取与预处理

2.1 数值设置及验证

采用 1/4 缩比的方背式 Ahmed 汽车标准模型,它的长度 L 、高度 H 和宽度 W 分别为 261、72 和 97.25 mm,如图 4 所示。本文研究的工况为:自由来流速度 $U_\infty=20$ m/s,雷诺数为 $Re_H=U_\infty H/\nu=9.2 \times 10^4$, ν 为运动黏度,在该雷诺数下,方背式 Ahmed 汽车标模的尾迹呈现出复杂的三维非定常湍流特性。

湍流尾迹数据通过非定常数值仿真计算获取,计算基于三维不可压缩 Navier-Stokes 方程,采用非




图4 1/4缩比的方背式 Ahmed 汽车标模

结构化有限体积求解器STARCCM+开展研究,该软件已经在三维钝体湍流尾迹的数值模拟中得到广泛验证^[10,16]。本研究采用LES开展非定常数值模拟,亚格子模型采用壁面自适应局部涡流黏性模型(WALE)^[17],对流通量由2阶精度的98%中心差分 and 2%迎风的混合格式来离散。数值模拟计算域的大小为 $40H$ (长) $\times 9.4H$ (宽) $\times 5H$ (高),入口和出口到模型头部和尾部的距离分别是 $11H$ 和 $25.4H$,模型的阻塞度为2.93%,如图5所示。边界条件规定如下:入口和出口分别为速度入口和压力出口,地面设置为无滑移壁面,其他计算域边界设置为对称边界条件。计算网格的拓扑结构是切割体网格,它在壁面边界处包含棱柱层,在计算域的其余部分包含完美的六面体网格。棱柱层通过切割连接到六面体网格。Ahmed模型上的面网格在 $1\text{--}1.25\text{ mm}$ 之间变化,在计算域边界上最大可达 10 mm ,尾迹区域中的网格也被细化到 1 mm 。Ahmed方背体上有25层棱柱层,地面壁面有15层。Ahmed体上的第一个网格




图5 计算域和边界条件

2.2 TR流场数据获取

本文考虑用平面 $z^*=z/H=0.67$ 的水平横截面速度场数据来训练神经网络,速度场的瞬时数据在 $2\ 500\text{ Hz}$ 的高频采样下获得,作为TR的流场数据。如图6(a)所示,区域为 $-0.5\leq x^*\leq 2.7$ 和 $-1.0\leq y^*\leq 1.0$ 。在 $z^*=0.67$ 平面空间放置 $N_x(224)\times N_y(160)$ 个格状采样点,采用三次插值法插值,如图6(b)中的红点,每个采样点提取三维速度分量 u 、 v 和 w 。因此,每个瞬时场数据的维度为 $N_x\times N_y\times 3$,并用作深度学习模型的输入。使用 $4\ 000$ 个快照(即瞬时速度场)作为训练数据和验证数据,另外 $1\ 000$ 个快照用于测试(不包括在上述 $4\ 000$ 个快照中)。快照以大约 $\Delta t^*=8\Delta t_{\text{LES}}^*$ 的时间间隔进行采样,这足以捕捉方背Ahmed汽车标模的尾迹中的主要瞬态特征,如全局振荡和Pumping抽吸现象^[20]。值得注意的是,在方背Ahmed汽车标模的尾迹中可以看到长期的双稳态行为($T\approx 1000H/U_\infty$),这代表了回流区在两个对称打破破缺(reflectional symmetry breaking, RSB)位

点高度设置为 0.03 mm ,以确保 $y^+\approx 1$,网格数量为 $2\ 220$ 万,这与Fan等^[10]使用的细网格一致。时间步长为 $\Delta t_{\text{LES}}^*=\Delta t_{\text{LES}}U_\infty/H=0.0139$ 。

采用的LES方法在之前针对三维圆柱绕流的研究中已进行了充分的实验验证^[18-19]。针对本研究的方背Ahmed模型,表3列出了LES数值仿真算例的气动阻力系数 C_d 值,背部阻力贡献 C_b (C_b 的定义见式(1)),尾迹回流区长度 L_r 与风洞实验^[20]结果的比较。对于 C_d 和 C_b 而言,LES的结果均比实验结果略大。而在回流区长度方面,仿真比实验结果偏小。总体来看,仿真结果与实验结果吻合较好。

$$C_b = -\frac{1}{N} \sum_{i=1}^N C_p \quad (1)$$

表3 LES数值计算方法与实验结果对比

方法	C_d	C_b	L_r
LES数值计算	0.328	0.221	1.39
实验 ^[20]	0.320	0.220	1.50

置之间的随机移动,这两个位置相对于垂直中心平面对称,从而导致统计学上对称的尾迹^[10]。然而,为了避免两个RSB状态的随机转换,这项课题中考虑的总共 $5\ 000$ 个快照都是 $z^*=0.67$ 平面中的不对称尾流,这意味着它们都位于相同的一侧RSB状态。




图6 计算网格和采样平面

2.3 non-TR流场数据获取

研究对象方背Ahmed汽车标准模型尾迹中的涡脱落频率 $f_0\approx 50\text{ Hz}$ 。根据奈奎斯特-香农采样定

理^[21-22]:为了真实准确地看到信号的各种特性,采样频率应该大于等于原始模拟信号中最高频率的2倍,否则将发生混叠,即相位模糊,因此选择 $f_i=50$ Hz的频率作为低频 non-TR 采样频率,显然 $f_i \leq 2f_0$,不能满足奈奎斯特-香农采样定理,也就表明在低采样率下 f_i 的 non-TR 流场不能像 TR 流场一样解析时间尺度特性,而这正是本研究需要的 non-TR 数据。

为了充分利用原始TR的CFD数据,在流场的不同时间步长处进行了下采样,这个过程看作是模拟在不同时间步长重复 non-TR 流场测量的过程。因此,最终可以将5 000个速度场下采样为50个样本(即每隔50个快照取一张),每个样本包括100个速度场,采样率为50 Hz。

离散的TR速度信号可以从TR速度场中的12个点提取获得,该过程模拟了使用热线探针获得的TR速度信号。与生成 non-TR 流场数据的过程类似,可以将速度信号下采样到相同的频率,并将特定的时间步长与 non-TR 流场测量相匹配。上述12个高频监测点的分布如图7所示,分别在 $x/H=0.25, 0.75, 1.25, 1.5$ 和 $y/H=-0.5, 0, 0.5$ 的区域。尾迹回流区、分离自由剪切层和尾迹回流区外构成了3个复杂的区域,它们在尾迹流动中相互作用。因此,在每个区域选择一个有代表性的位置来展示速度场的时间分辨重构,其中 p_1, p_2, p_4, p_5, p_8 在回流区里,尾迹最重要的特征就在回流区,背部负压就是因为回流区带来的,回流区越大,背部阻力越小。 $p_6, p_7, p_9, p_{10}, p_{12}$ 在剪切层附近, p_3, p_{11} 在回流区外。LSTM-POD模型的性能对速度信号探针的位置很敏感,放置灵敏度的具体研究超出了本项工作的范围,具体放置规则可参考Cole等^[23]和Cohen等^[24]的研究。

2.4 数据标准化处理

在本研究中,随机选取了10个样本(即总共1 000张快照)作为训练数据集,其余40个样本(即总共4 000张快照)作为测试数据集。

时间系数是通过对所有训练和测试样本执行POD处理获得的。根据Tu等^[25]的研究,假设有足够多的统计学独立快照时,TR速度场计算的POD模态与随机采样速度场计算的POD模态相同。进行简单验证后的结果表明,训练数据集和测试数据集在分别进行POD处理后能收敛到相同的特征值,POD模态型态也一致。

在得到训练所需数据后,为了保证网络性能,需要对数据进行预处理,以消除奇异样本数据的影响。




图7 瞬时流向速度 U 及12个离散高频监测点分布

因此速度信号和时间系数都采用了最大最小归一化:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

直接从实际流动中提取的原始信号含有大量的脉动项,这些都是降阶流场难以捕捉到的,因此还需要对原始速度信号进行数据平滑降噪处理。此处的平滑处理是基于卷积算子的。总的来说,数据预处理过程可以在一定程度上提高LSTM-POD模型的性能。

3 结果分析

3.1 POD分析

对流场进行了POD分析,以确定该流动形态中的主要流动结构。每个模态包含的能量百分比 η_i 为

$$\eta_i = \frac{\lambda_i}{\sum_{j=1}^{N_i} \lambda_j} \quad (3)$$

式中:特征值 λ_i 反映了对应模态对湍动能(TKE)的贡献; N_i 是POD模态的总数。图8显示了前100个POD模态的能量占比。从蓝色虚线可以看出,单个模态的能量占比在前20个模态中先快速下降,然后再缓慢下降。而红线所显示的捕获总能量的分布则呈现出相反的趋势,总能量占比在前50个模态中包含41%的能量,在前100阶模态总共包含51%的能

量。虽然50个POD模态总共只捕获了10%的能量,但这些模态的系数具有很大的复杂性,可以用来测试基于LSTM-POD模型的学习能力和可行性。因此,对应地选择前100阶POD系数作为输出来研究模型的性能。

接下来看模态分布云图,从图9上面一行的低阶模态中均能看到大尺度相干结构:Mode 1表征偏一侧的双稳态不对称状态,Mode 3和Mode 5是全局振荡引起的。后面高阶的Mode 30、Mode 50和Mode 90中包含分布相对均匀的小相干结构,但其物理意义尚不清楚。




图8 前100阶POD模态捕获的能量分布和总能量




图9 流向速度U不同POD模态云图

3.2 训练误差分析

本研究同时应用了5个LSTM-POD模型,每个模型输出20个POD系数,共包含前100个POD系数。模型的训练误差通过均方误差(MSE)来衡量,表达式为

$$\delta_{\text{MSE}} = \frac{1}{N} \sum_{i=1}^N (y_i - \tilde{y}_i)^2 \quad (4)$$

式中: y_i 为真实的POD系数; \tilde{y}_i 为模型输出系数; N 为总样本数。

通过在模型中改变不同的输出配置,研究了LSTM-POD模型的学习能力和鲁棒性,训练误差收敛曲线和最后一个Epoch后的训练误差分别如图10和表4所示。图例中以“Sin”开头的虚线以及表中“LSTM-Sin”代表单时间步长,以“Mul”开头的实线以及表中“LSTM-Mul”代表多时间步长。从每种配置的误差曲线可以看出,高阶POD模态系数的模型的训练误差远大于低阶POD模态的训练误差,这可以归因于高阶模态的POD系数具有很大的复杂性和非线性,表明高阶POD系数与速度信号之间的相关性是中等的。结合图10和表4可知,LSTM-Mul比LSTM-Sin具有更快的收敛速度和更低的收敛值,表明多时间步长的配置可以促进模型的收敛,并在一定程度上提高模型的性能。

3.3 重构结果分析

3.3.1 POD系数重构分析

重构时间分辨流场的关键是尽可能准确地恢复时间分辨POD系数,这也是评估模型性能的重要指标。在获得了不同时间步长下的non-TR时间系数后,就可以将这些系数整合成TR时间系数,重构的TR系数时间序列如图11所示。重构的5000个时刻TR系数的时间序列结果与之前的non-TR测试集相似。LSTM-Mul生成的低阶TR系数与实际POD系数更一致,尤其是在很多峰值处,LSTM-Sin生成的系数偏小一点,但是演变趋势一致。对于高阶POD时间系数的重构,LSTM-Mul演变趋势一致,而LSTM-Sin预测都偏小,趋势也难以捕捉,模型输出存在的一些相当大的误差,LSTM-Sin失去预测能力,一种可能的解释是,LSTM-Sin仅考虑了当前时间步的数据,这可能会影响数据之间的连续性。

为了进一步比较LSTM-Mul和LSTM-Sin的性能,对重构的TR时间系数进行了误差分析,如图12所示。这里为了加强不同POD模态下系数的可比性,使用标准化后并缩放到[0,10]范围的POD系数




图10 LSTM-POD模型中使用不同输出配置的训练误差曲线

表4 LSTM-POD模型在不同输出配置下的最后一轮的训练误差

POD 系数	LSTM-Sin	LSTM-Mul
Modes1-20	0.005 52	0.001 17
Modes21-40	0.007 00	0.001 74
Modes41-60	0.007 65	0.002 06
Modes61-80	0.008 85	0.002 39
Modes81-100	0.008 95	0.002 60

计算均方误差MSE。由结果可知,随着模态数量的增加,误差以振荡的方式增加,尽管如此,大多数高阶模态的误差还是大于低阶模态的误差。这与训练误差分析的结果是一致的,表明高阶POD模态系数与速度信号之间的相关性是中等的,因此较难预测。不过高阶POD模态在该范围内的误差是完全可接受的,因为这些模态仅为流动提供少量能量。另一方面,LSTM-Mul的误差均小于LSTM-Sin,这表明LSTM-Mul在POD系数重构中具有更好的性能,因为它考虑了时间序列数据之间的时间相关性。

3.3.2 降阶流场重构分析

图13显示了测试集里一个任意时刻的瞬时速度云图。结果表明,利用POD系数重构的流场可以很容易地捕捉到大尺度流动结构,然而真实流(第1列)和降阶流(后3列)之间还是存在一些显著差异的,因为真实流中有更多的流动细节。另外,使用LSTM-Mul重构的流场更类似于使用真实POD系数重构的流场,如图中回流区轮廓和滞止点区,中下游的正向流速分布。这可能是由于LSTM-Mul在估计高阶POD模态系数方面的性能更好,而这些模态包含了分布在下流的较小相干结构。但是,由于重构所用的阶数较少,因此都无法捕捉到真实流中小尺度流动结构。

3.3.3 相对重构误差分析

最后进行瞬时相对重构误差的分析,计算如式(5)所示。

$$\varepsilon_r = \sqrt{\frac{[u'(x) - u_0(x)]^2}{[u_0(x)]^2}} \quad (5)$$

式中: u_0 为实际POD系数重构的速度,此处不用真实速度场是因为LSTM-POD模型输出为估计的POD系数,所以用实际的POD系数重构的速度场更能体现模型的回归性能; u' 为使用LSTM-Mul或LSTM-Sin估计的速度。

图14展示了测试集中的某个瞬时重构误差的空间分布。纵向来看,任意方向的速度重构误差中LSTM-Mul的误差都小于LSTM-Sin的误差,这表明LSTM-Mul重构的TR速度场与POD计算的重构场更吻合。对于流向速度来说,较大的相对误差(颜色较深部分)都集中在大型流动结构(回流区)的边缘附近,这是因为边缘附近的速度量级非常小,接近于0,当式(3)中的分母为0时, ε_r 就会非常大了。图15为3个方向速度重构的时均RMSE误差云图,误差计算公式如下:

$$TRMSE = \frac{1}{W} \sum_{i=1}^W \sqrt{\frac{\sum_{t=1}^N (v_i^{(t)} - \tilde{v}_i^{(t)})^2}{N}} \quad (6)$$

式中: W 为快照数量; N 为每张快照中的采样点数; $v_i^{(t)}$ 是第*i*个采样点在*t*时刻的数据; $\tilde{v}_i^{(t)}$ 是POD系数重构速度场的 $v_i^{(t)}$,不是真实速度场值,而是参考值。同样可以看到LSTM-Mul的重构误差明显小于LSTM-Sin。对于流向速度,较大的时均误差都在剪切层附近,因为剪切层速度波动大;对于另外两个方向的速度,较大的时均误差主要在回流区下游。

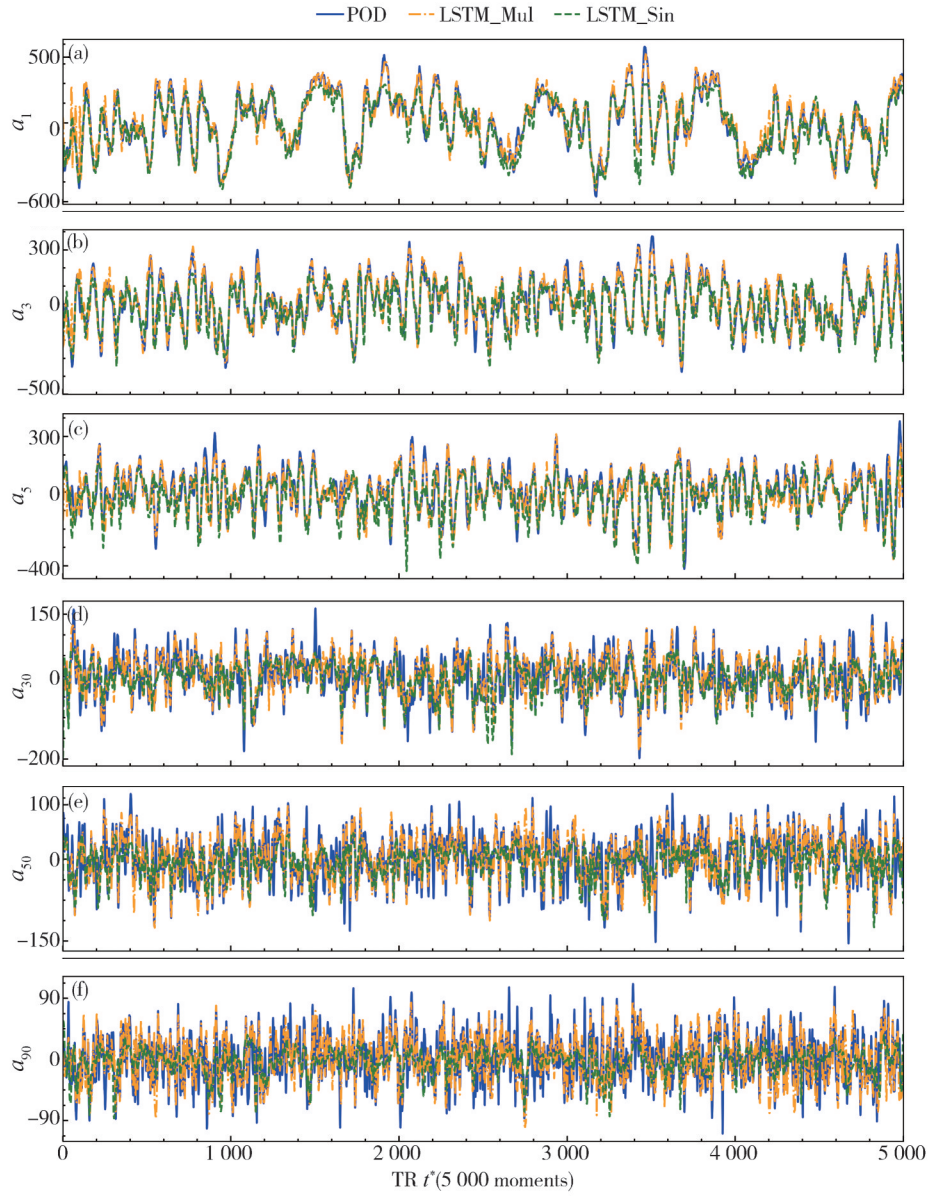


图 11 LSTM-POD 模型计算的 TR 模态系数时间序列

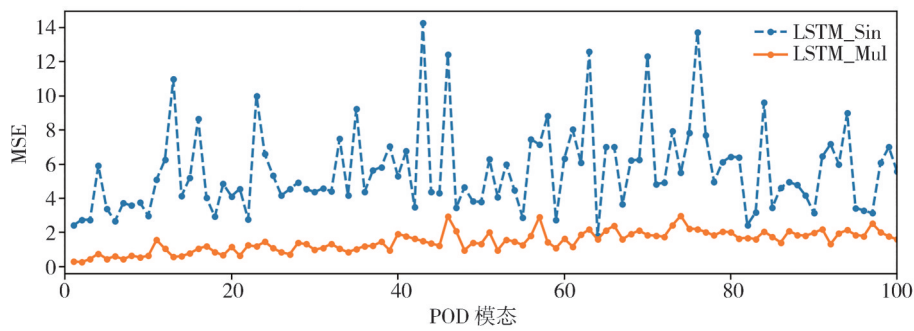


图 12 实际 POD 系数和两种配置的 LSTM-POD 模型估计的系数之间的 MSE 误差

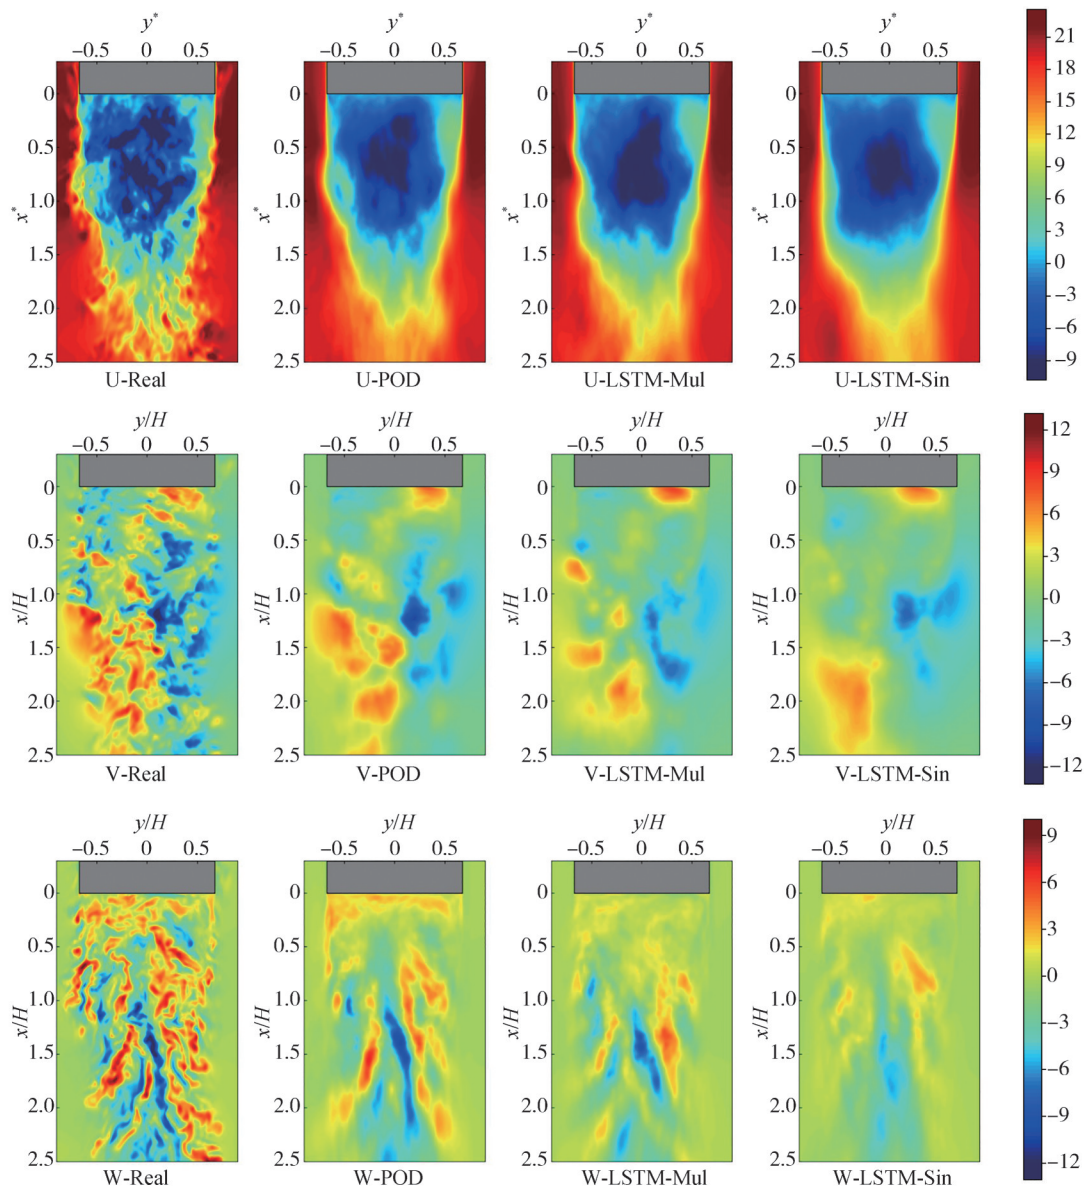


图13 不同LSTM-POD模型重构瞬时速度场云图(测试样本)

4 结论

本文提出基于LSTM-POD的深度学习模型,将低频采样的非时间分辨速度场数据和若干离散点的高时间分辨速度场数据相结合,成功实现了方背Ahmed汽车标模湍流尾迹的时间分辨流场重构。首先,通过对原始时间分辨流场(2 500 Hz采样)进行下采样,得到采样率为50 Hz的非时间分辨数据集;其次训练深度学习模型,建立了离散点速度信号与POD模态系数之间的关系,同时为了考察其鲁棒性和学习能力,重点对比了不同时间步长配置的影响,

即单时间步长(LSTM-Sin)和多时间步长(LSTM-Mul);最后,验证了该方法对时间分辨POD模态系数、时间分辨全局流场的重构效果。以上研究得到的主要结论如下。

(1)LSTM-POD模型在时间序列重构中具有较强的学习能力和泛化能力。它可以在很大程度上成功地重构前几阶POD时间分辨系数。最后通过结合POD模态系数和相应的模态,就可以获得时间分辨的降阶流场。

(2)LSTM-Mul因为采用多个时间步长,考虑到了时间上的连续性和相关性,因此相较于LSTM-Sin,其重构出的时间分辨模态系数,尤其是低阶模

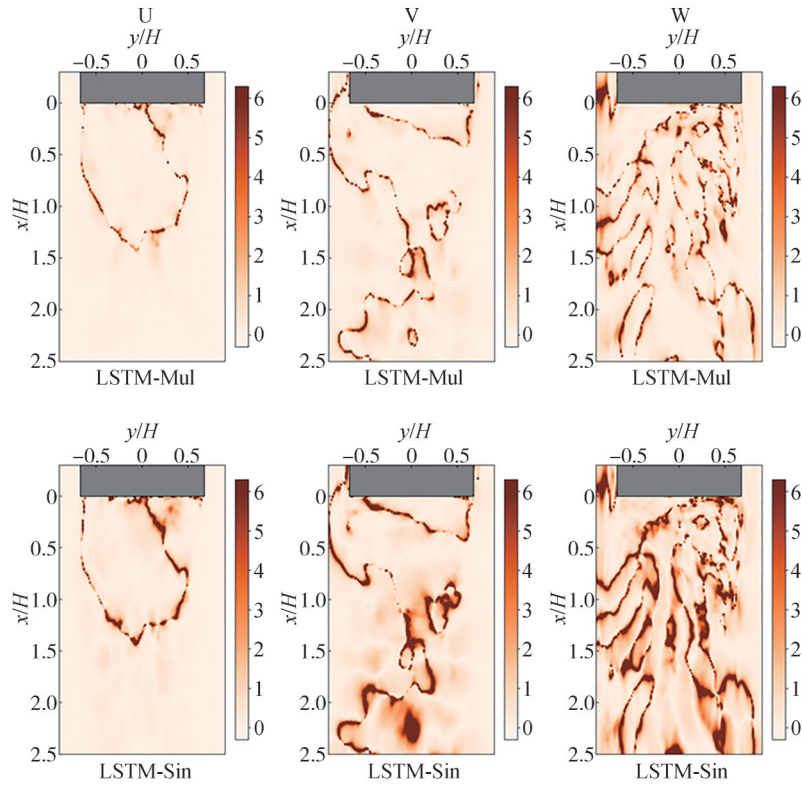


图 14 测试样本中某个瞬时相对重构误差的分布云图




图 15 测试样本的时均RMSE误差的分布云图

态系数,与实际POD模态系数更一致;同时重构出的流场也与POD重构流场更接近。

(3)两种配置的模型对高阶POD时间系数的估算还存在较大的误差,主要是高阶模态缺乏拟序性和能量占比较小导致的。

因此,本文提出的深度学习模型可以为汽车复杂湍流尾迹流场高时间分辨率重构提供新的方法,对解决风洞PIV流场测量及高精度数值模拟中高时间分辨率流场获取成本高、计算效率低等问题具有重要借鉴意义。但目前本方法还是针对简化汽车标模的湍流尾迹开展流场重构,后续可以尝试在更高雷诺数的实际车辆复杂湍流尾迹中进行高时间分辨率流场重构,以为实际工程应用提供更多指导。

参考文献

- [1] MINGUEZ M, PASQUETTI R, SERRE E. High-order large-eddy simulation of flow over the “ahmed body” car model[J]. *Physics of Fluids*, 2008, 20(9): 095101.
- [2] ROUMÉAS M, GILLIÉRON P, KOURTA A. Analysis and control of the near-wake flow over a square-back geometry[J]. *Computers & Fluids*, 2009, 38(1): 60–70.
- [3] 范亚军,夏超,葛典典,等.方背Ahmed模型非定常尾迹的实验研究[J].*实验流体力学*,2019,33(6):84–89.
FAN Y J, XIA C, GE D D, et al. Experimental investigation of the unsteady wake of the square-back Ahmed model[J]. *Experiments in Fluid Mechanics*, 2019, 33(6): 84–89.
- [4] GRANDEMANGE M, CADOT O, GOHLKE M. Reflectional symmetry breaking of the separated flow over three-dimensional bluff bodies[J]. *Physical Review E*, 2012, 86(3): 035302.
- [5] GRANDEMANGE M, GOHLKE M, CADOT O. Turbulent wake past a three-dimensional blunt body. part 1. global modes and bi-stability[J]. *Journal of Fluid Mechanics*, 2013, 722: 51–84.
- [6] DUELL E G, GEORGE A R. Experimental study of a ground vehicle body unsteady near wake [J]. *SAE Transactions*, 1999: 1589–1602.
- [7] WESTERWEEL J, ELSINGA G E, ADRIAN R J. Particle image velocimetry for complex and turbulent flows[J]. *Annual Review of Fluid Mechanics*, 2013, 45: 409–436.
- [8] 张兆顺,崔桂香,许春晓.湍流理论与模拟[M].北京:清华大学出版社,2005.
ZHANG Z S, CUI G X, XU C X. Theory and modeling of turbulence[M]. Beijing: Tsinghua University Press, 2005.
- [9] LONGA L D, EVSTAFYEVA O, MORGANS A S. Simulations of the bi-modal wake past three-dimensional blunt bluff bodies [J]. *Journal of Fluid Mechanics*, 2019, 866: 791–809.
- [10] FAN Y, XIA C, CHU S, et al. Experimental and numerical analysis of the bi-stable turbulent wake of a rectangular flat-backed bluff body[J]. *Physics of Fluids*, 2020, 32(10): 105111.
- [11] 杨志刚,余磊,夏超,等.车轮对方背汽车双稳态非定常尾迹特性的影响[J].*中南大学学报*,2023,12: 1–16.
YANG Z G, YU L, XIA C, et al. Effects of wheels on the bi-stable wake of a square-back automotive [J]. *Journal of Central South University*, 2023, 12: 1–16.
- [12] HE C, LIU Y. Proper orthogonal decomposition-based spatial refinement of TR-PIV realizations using high-resolution non-TR-PIV measurements [J]. *Experiments in Fluids*, 2017, 58(7): 1–22.
- [13] DENG Z, CHEN Y, LIU Y, et al. Time-resolved turbulent velocity field reconstruction using a long short-term memory (LSTM)-based artificial intelligence framework [J]. *Physics of Fluids*, 2019, 31(7): 075108.
- [14] JIN X, LAIMA S, CHEN W L, et al. Time-resolved reconstruction of flow field around a circular cylinder by recurrent neural networks based on non-time-resolved particle image velocimetry measurements[J]. *Experiments in Fluids*, 2020, 61: 1–23.
- [15] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]. *International Conference on Machine Learning*. PMLR, 2015: 448–456.
- [16] HE K, MINELLI G, SU X, et al. On state instability of the bi-stable flow past a notchback bluff body[J]. *Journal of Fluid Mechanics*, 2022, 931: R6.
- [17] NICOU D, DUCROS F. Subgrid-scale stress modelling based on the square of the velocity gradient tensor [J]. *Flow, Turbulence and Combustion*, 1999, 62(3): 183–200.
- [18] CHU S J, XIA C, WANG H F, et al. Three-dimensional spectral proper orthogonal decomposition analyses of the turbulent flow around a seal-vibrissa-shaped cylinder [J]. *Physics of Fluids*, 2021, 33(2): 025106.
- [19] WEI Z, YANG Z, XIA C, et al. Cluster-based reduced-order modelling of the wake stabilization mechanism behind a twisted cylinder[J]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2017, 171: 288–303.
- [20] VOLPE R, DEVINANT P, KOURTA A. Experimental characterization of the unsteady natural wake of the full-scale square back Ahmed body: flow bi-stability and spectral analysis [J]. *Experiments in Fluids*, 2015, 56(5): 99.
- [21] NYQUIST H. Certain topics in telegraph transmission theory [J]. *Transactions of the American Institute of Electrical Engineers*, 1928, 47(2): 617–644.
- [22] SHANNON C E. Communication in the presence of noise [J]. *Proceedings of the IRE*, 1949, 37(1): 10–21.
- [23] COLE D R, GLAUSER M N, GUEZENNEC Y G. An application of the stochastic estimation to the jet mixing layer [J]. *Physics of Fluids A: Fluid Dynamics*, 1992, 4(1): 192–194.
- [24] COHEN K, SIEGEL S, MCLAUGHLIN T. A heuristic approach to effective sensor placement for modeling of a cylinder wake [J]. *Computers & Fluids*, 2006, 35(1): 103–120.
- [25] TU J H, GRIFFIN J, HART A, et al. Integration of non-time-resolved PIV and time-resolved velocity point sensors for dynamic estimation of velocity fields [J]. *Experiments in Fluids*, 2013, 54: 1–20.