

文章编号: 0258-1825(2025)05-0092-09

基于深度强化学习的箱梁涡激振动智能流动控制

邓晓龙¹, 胡钢^{1,*}, 陈文礼²

(1. 哈尔滨工业大学(深圳) 智能土木与海洋工程学院, 深圳 518055;

2. 哈尔滨工业大学 土木工程学院, 哈尔滨 150096)

摘要: 为抑制桥梁涡激振动从而提升桥梁抗风性能, 提出了一种基于深度强化学习的智能主动流动控制方法。研究利用合成射流对桥梁节段气动弹性模型尾流场的旋涡脱落进行扰动, 从而实现了对涡激振动的有效抑制。风洞试验结果验证了桥梁涡激振动在均匀稳定风场中的气动性能, 并建立了合成射流激励器控制电压与射流流量的映射关系。通过对控制电压的系统性分析发现, 控制电压与射流平均吹气速度近似线性正相关, 且更高的控制电压能够显著提升抑制效果。随后, 结合软演员-评论家(soft actor-critic, SAC)算法对合成射流的控制策略进行了优化, 快速训练得出最优控制电压, 并将振幅减少了 83%。研究结果表明, 合成射流结合深度强化学习算法能够高效抑制桥梁涡激振动, 为桥梁风工程的抗风设计提供智能化解决方案。

关键词: 桥梁风致振动; 主动流动控制; 涡激振动; 深度强化学习; 合成射流

中图分类号: V214.3; TP181; TU311.3 文献标识码: A doi: 10.7638/kqdlxxb-2025.0016

Deep reinforcement learning based intelligent flow control of vortex-induced vibration for box girder

DENG Xiaolong¹, HU Gang^{1,*}, CHEN Wenli²

(1. School of Intelligent Civil and Ocean Engineering, Harbin Institute of Technology(Shenzhen), Shenzhen 518055, China;

2. School of Civil Engineering, Harbin Institute of Technology, Harbin 150096, China)

Abstract: An intelligent active flow control method based on deep reinforcement learning (DRL) was proposed to suppress vortex-induced vibrations and enhance the wind resistance of bridges. This method employed synthetic jets to disturb the wake vortex shedding of an aeroelastic bridge section model, effectively suppressing vortex-induced vibrations. Wind tunnel tests were conducted to validate the aerodynamic performance of the model under uniform and steady wind conditions. Additionally, the relationship between the control voltage and synthetic jet flow rate was established. A systematic analysis showed that the control voltage was approximately linearly and positively correlated with the average jet velocity, with higher control voltages significantly improving the suppression effect. Subsequently, the synthetic jet control strategy was optimized using the Soft Actor-Critic (SAC) algorithm, which converged rapidly to the optimal control voltage, resulting in a maximum reduction of 83% in vibration amplitude. These findings demonstrate that combining synthetic jet technology with DRL algorithms provides an efficient and intelligent solution for suppressing bridge vortex-induced vibrations and offers an intelligent approach for wind-resistant bridge design.

Keywords: bridge wind-induced vibration; active flow control; vortex-induced vibration; deep reinforcement learning; synthetic jet

收稿日期: 2025-01-24; 修订日期: 2025-04-08; 录用日期: 2025-04-27; 网络出版时间: 2025-05-28

基金项目: 深圳市科技计划-稳定支持计划(GXWD20231129111527001)

作者简介: 邓晓龙(1995—), 男, 哈尔滨人, 博士生, 研究方向: 桥梁风工程. E-mail: 21B954013@stu.edu.cn

通信作者: 胡钢*, 教授, 研究方向: 风工程. E-mail: hugang@hit.edu.cn

引用格式: 邓晓龙, 胡钢, 陈文礼. 基于深度强化学习的箱梁涡激振动智能流动控制[J]. 空气动力学学报, 2025, 43(5): 92–100.

DENG X L, HU G, CHEN W L. Deep reinforcement learning based intelligent flow control of vortex-induced vibration for box girder[J]. Acta Aerodynamica Sinica, 2025, 43(5): 92–100(in Chinese). doi: 10.7638/kqdlxxb-2025.0016

0 引言

随着现代桥梁技术及工程材料学的进步,桥梁结构特点正朝着长、轻、柔和低阻尼等方向发展,但这带来了其风致振动特性愈加敏感。当风流经桥梁时,可能会出现流动分离和周期性的旋涡脱落现象,导致结构两侧表面出现交替变化的正负气压,由此产生名为涡激力的荷载。涡激力导致的桥梁限幅振动,称为涡激振动。涡激振动是一种典型的风致振动形式,具有强迫和自激两重特性^[1]。当旋涡脱落频率远离桥梁的自振频率时,涡激力表现为强迫力;而当旋涡脱落频率接近或等于结构的自振频率时,涡激力则表现为自激力^[2]。

持续的涡激振动可能引发桥梁的疲劳损伤。大跨度斜拉桥以及悬索桥的主梁、桥塔和缆索等结构,均可能在较低风速下发生较为明显的涡振现象。中国的西堠门大桥^[3]和虎门大桥、丹麦的大贝尔特东桥^[4]、日本的东京湾桥^[5]及加拿大的Lion Gate桥等^[6],都曾出现过较大幅度的涡激振动现象,对桥梁的结构安全和运营产生了一定影响。桥梁涡激振动的控制问题已成为桥梁风工程领域的重要研究课题,受到大量关注。

近年来,深度强化学习(deep reinforcement learning, DRL)凭借其深度神经网络的非线性拟合能力和强化学习的动态规划寻优控制策略,在复杂系统的主动控制领域展现出巨大潜力。特别是在流体力学与结构风工程领域,DRL已成功应用于流动控制问题的突破性研究。Ren等^[7]采用数据驱动的DRL方法对圆柱体绕流实施净零流量控制,使尾流区域的流向速度差降低了99.5%。Rabault等^[8]应用DRL训练的人工神经网络对圆柱绕流进行主动流动控制,在低雷诺数下,最优控制策略的阻力降低了约8%。这项工作证明了DRL可以实现主动闭环控制,显示了其在降低阻力方面的巨大潜力。为了提升学习效率,Wang等^[9]利用低雷诺数下的方柱绕流与圆柱绕流模型,搭建了OpenFOAM仿真软件与Tensorforce深度学习框架的耦合平台。Tang等^[10]采用近端策略优化方法控制对称布置在二维流场圆柱上下侧的4个合成射流的质量流量,在不同雷诺数下实现了最高38.7%的减阻效果。Fan等^[11]通过强化学习进行流动控制,并利用实验进行验证。该研究调整两个小型旋转圆柱的转速来实现主圆柱的流动控制,经过数十次强化学习实验探索,发现了可以最大化系统功率增益效率的最优

策略,实现了减阻和旋转摩擦功率损失之间的平衡。

在桥梁主动流动控制领域,Li等^[12]针对桥梁主动翼板气动控制措施开展了相关研究,发现主动驱动的气动控制措施在颤振控制方面高效、鲁棒,且能够实现时滞控制和多振型控制。然而,传统控制算法(如状态空间法)需对桥梁-翼板控制系统进行数学抽象,依赖无干扰假定及临界状态假定等简化模型,难以适应高雷诺数风场下流动控制问题的高维、非线性和非定常特性。相比之下,DRL算法的无模型化数据驱动特性可突破传统方法的局限,不仅能避免人为经验依赖和简化假设,还能通过自动寻优降低调参成本,并在复杂风场变化下实时调整控制策略,从而更有效地应对桥梁流动控制挑战。

对于桥梁的风振流动控制强化学习研究,Deng等^[13]在二维数值模拟下实现了均匀来流风场的桥梁尾缘主动吸气策略训练,基于流场状态信息智能调整主动吸气流量,使桥梁脉动阻力、升力、弯矩分别降低了73.7%、95.8%和99.1%。相较于传统控制算法,DRL能根据流场变化动态更新策略,控制策略的变化更加灵活,但在非均匀风场中的自适应策略训练仍显不足。尽管如此,DRL在桥梁风致振动控制领域的巨大应用潜力仍得到了初步验证。

为解决桥梁涡激振动问题,本研究设计了基于合成射流主动流动控制技术的气动弹性风洞试验,结合DRL算法优化控制参数。通过风洞试验,探究合成射流激励器对桥梁尾流场的扰动效应,并分析合成射流激励器控制电压与吹气流量的关系,研究控制电压与吹气频率对桥梁涡激振动抑制效果的影响。同时,利用DRL算法,在风洞试验与流动控制耦合框架中,自动化地快速训练得出最优控制策略,验证其在稳态控制环境最优控制参数下抑制涡激振动的效果。本研究不仅旨在探索合成射流技术结合深度强化学习算法在稳定风场条件下控制桥梁涡激振动的有效性,更致力于为实际复杂环境(如非均匀风场、阵风干扰)中的流动控制策略提供理论基础与方法支撑,从而推动主动流动控制技术向实际工程的广泛应用迈进。

1 风洞试验方法

1.1 多风扇风洞、桥梁模型及测量设备

风洞试验在哈尔滨工业大学(深圳)智能风工程实验室(artificial intelligence for wind engineering, AIWE)的多风扇主动控制风洞中进行。该风洞的动力由24行×32列风扇组成的风墙阵列提供,可调节风速范

围为 0.5~12 m/s, 流场湍流强度小于 5%, 试验段尺寸为 6.0 m(长)×2.6 m(宽)×2.0 m(高)。图 1 中所示部分包括风墙阵列和风洞试验段, 其中试验段位于风洞中央, 作为桥梁节段模型安装、气弹性试验及主动流动控制测试的区域。试验段与上游风墙阵列配合, 可实现均匀稳定的来流风场。

因为丹麦大贝尔特东桥相关的涡激振动风洞试验及数值模拟数据较为丰富, 所以选择其作为桥梁模型。大贝尔特桥梁模型采用 1:50 的几何缩尺比, 主梁截面宽度 620 mm、高度 88 mm, 风洞内部阻塞率为 2.54%, 满足阻塞率小于 5% 的风洞试验准确度要求。桥截面及栏杆附属设施几何尺寸如图 2 所示。桥梁模型及实桥的含量纲参数及无量纲空气动力学参数分别如表 1 和表 2 所示。




图 1 多风扇主动控制风洞

Fig. 1 Multi-fan active control wind tunnel




图 2 大贝尔特桥截面及其栏杆设施几何尺寸 (单位: mm)

Fig. 2 Geometrical dimensions of the cross-section of the Great Belt Bridge and its railing auxiliary facilities (units: mm)

表 1 桥梁模型和实桥的含量纲参数

无量纲参数	实桥参数值	缩尺比	模型参数值
长度 L/m	1624		2.8
宽度 B/m	31	1:50	0.62
高度 H/m	4.4	1:50	0.088
竖向振动频率/Hz	0.097		3.1

表 2 桥梁模型和实桥的无量纲空气动力学参数

Table 2 Dimensionless aerodynamic parameters for the sectional model and the real bridge

无量纲参数	实桥参数值	模型参数值
雷诺数 Re	$8.3 \times 10^6 \sim 2.5 \times 10^7$	$7.0 \times 10^4 \sim 1.2 \times 10^5$
斯特罗哈数 St	0.08~0.15	0.13
阻尼比		0.145%
流场阻塞率		2.54%

1.2 合成射流控制方法

相对于传统的气泵式气管吹气方式, 采用合成射流激励器作为流动控制设备具有占地面积小、电信号控制反应速度快、零质量射流等优点。采用的卧式合成射流激励器外形如图 3 所示, 其工作原理如图 4 所示。由于压电振子金属片的通电变形能力, 变形的压电片在激励器腔体内部振动挤压空间, 从而造成气压的变化, 在射流口处形成射流。控制电压可以影响合成金属形变的大小, 从而影响射流流量。将 8 个合成射流激励器沿着桥梁长度方向以 112 mm(1.27H) 为间隔排成一排布置于桥梁底板转角——半流线型箱梁的流动分离区, 如图 5 所示。




图 3 卧式合成射流激励器 (单位: mm)

Fig. 3 Horizontal synthetic jet actuator (Unit: mm)




图 4 双腔体卧式合成射流工作原理图 (图中箭头标注表示气流从压电片激励区向射流口方向的流动路径)

Fig. 4 Working principle diagram of double cavity horizontal synthetic jets (The arrows in the figure indicate that the airflow direction is from the piezoelectric vibration chamber toward the jet)

通过图 6 所示的 RIGOL-DG832 型信号函数生成器(主要由输出接口、调制频率旋钮、电压调节按钮




图 5 卧式合成射流激励器安置于桥梁底板转角

Fig. 5 Horizontal synthetic jet actuator positioned at the corner of the bridge bottom edge



图 6 信号函数生成器

Fig. 6 Signal function generator

及功能显示屏组成)对激励器施加波形电信号。信号生成器参数设置如下:谐波电信号调制频率为 0~20 Hz,电信号控制电压为 0~20 V。电信号调制频率会影响射流吹气的频率,而控制电压将影响射流的平均吹气流量。控制信号生成后,再经过电源放大器,将信号放大 15 倍后输出至合成射流激励器,实现频率与电压控制。

1.3 深度强化学习训练框架及方法

本文深度强化学习(DRL)最优控制训练仅考虑桥梁的稳态控制,即寻找在固定环境下的最优控制参数,该参数在后续不随时间或外部条件变化。在 DRL 的优化过程中,由于算法的随机性与策略网络的探索特性,训练结果主要为局部最优解。通过多次交互与策略更新,DRL 算法逐步逼近最优控制策略,实现较优的振动抑制效果。

本研究采用 DRL 算法在稳态风速环境下优化单一控制变量(控制电压)。在表面上这是一个简单的单变量优化问题,然而,DRL 在此场景中的优势体现在其自动化的深度神经网络自适应学习能力能够在缺乏先验知识的前提下,通过环境交互实现控制策略的自动优化。尽管传统优化方法在单变量稳态问题中具有较低计算成本和良好效果,但 DRL 具备更强

的泛化能力和拓展性,可为未来处理复杂、非稳态、多变量控制问题提供一种可迁移的智能化解决框架。本研究可视为将 DRL 拓展应用于复杂动态环境的理论铺垫与实践探索。

深度强化学习训练采用软演员-评论家(soft actor-critic, SAC)算法,该算法是基于最大熵思想的 DRL 算法,引入了一个熵系数,以最大化回报和最大化熵为目标^[14]。通过调整熵系数的大小,可以在探索和利用之间取得平衡。较大的熵系数更加强调探索,而较小的熵系数更加强调利用。此外,SAC 算法还采用了两个策略网络:一个用于执行动作的确定性策略网络,另一个用于计算动作的概率分布的随机策略网络。这种双重策略的算法通过最小化确定性策略的值函数来更新策略,同时最大化随机策略的熵。这种策略更新方式有效地减小了梯度的方差,增强了策略的稳定性。SAC 算法公式为:

$$\pi^* = \operatorname{argmax}_{\pi} E_{\tau \sim \pi} \left\{ \sum_{t=0}^{\infty} \gamma^t [R(s_t, a_t, s_{t+1}) + \alpha H(\pi(\cdot | s_t))] \right\} \quad (1)$$

式中: π 为策略函数,用于输出在状态 s_t 下采取动作 a_t 的概率分布;上标“*”表示所有策略中的最优; τ 表示一个轨迹,即智能体与环境交互过程中的状态-动作序列,形式上可以表示为 $\tau = (s_0, a_0, s_1, a_1, s_2, a_2, \dots)$,它是智能体在策略 π 下,从环境中采样得到的一个完整交互序列; $\tau \sim \pi$ 表示轨迹 τ 是根据策略 π 所采样的; s_t 为智能体在时刻 t 的状态; a_t 为智能体在时刻 t 所采取的动作; γ 为折扣因子,用于平衡即时奖励与未来奖励的重要性; $R(s_t, a_t, s_{t+1})$ 为在状态 s_t 采取动作 a_t 并转移至状态 s_{t+1} 后获得的即时奖励; α 为熵系数,决定熵系数项相对于奖励值的重要性; $H(\pi(\cdot | s_t))$ 代表策略的信息熵,用于衡量策略选择动作的随机性; $E\{\cdot\}$ 表示期望预算。在本研究中,SAC 算法中的熵系数 α 设置为 0.2,该数值为经验选取。较小的熵系数可以在保证策略探索能力的同时,增强对奖励的关注,从而提升控制性能的收敛速度和稳定性。

本研究在如图 7 所示的 DRLinWT 框架^[15]中进行风洞试验及 DRL 算法训练,该框架同时耦合了风洞试验与 DRL 算法训练,通过各类通讯协议,如串口通信、TCP/IP 协议等来实现风洞试验中的硬件设备与强化学习训练中的状态空间、动作空间、奖励函数等数据之间的交互,包括状态信息的采集、控制动作的下发及奖励值的返回。DRL 算法通过与环境的交互来学习最优控制动作策略并最大化自定义的奖励

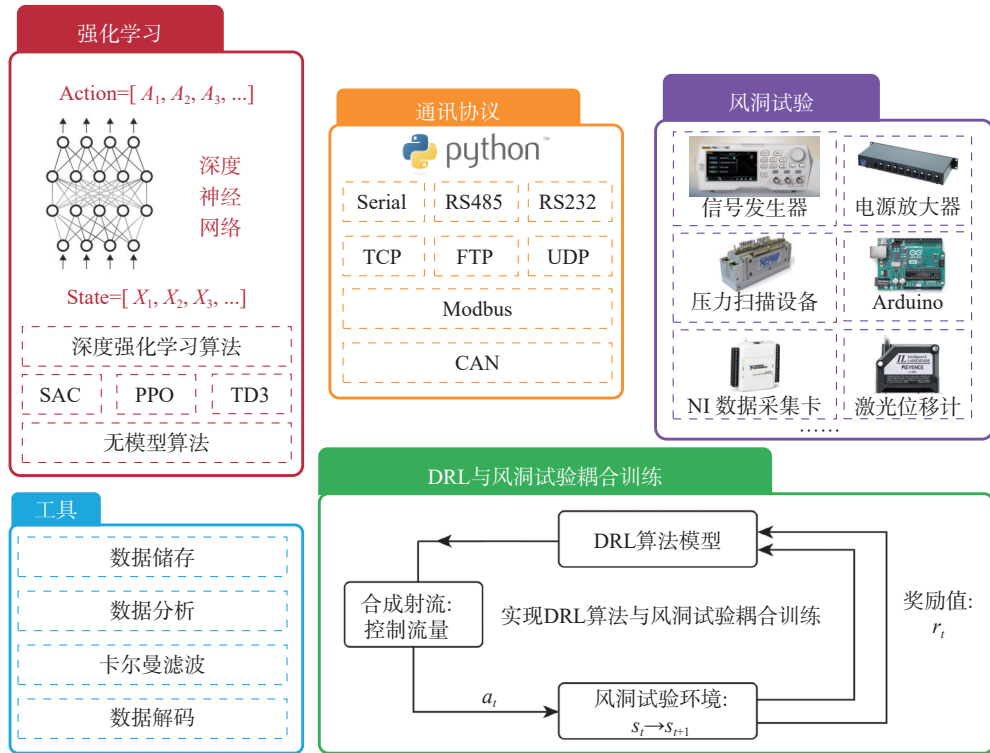


图 7 深度强化学习与风洞试验耦合框架 DRLinWT

Fig. 7 DRLinWT framework for deep reinforcement learning coupled with wind tunnel test

函数。在试验过程中，桥梁模型的振动状态由激光位移计实时采集，并通过数据采集系统传输至 DRL 训练平台，作为状态输入。DRL 算法根据当前状态生成最优控制电压作为动作信号，通过信号发生器输出至合成射流激励器。整个系统形成“状态感知-策略决策-控制执行”的闭环流程，实现深度强化学习与风洞试验平台的耦合。

DRL 训练中的状态空间数据为桥梁气动弹性振动的信息。在桥梁模型的 4 个对角上方安装激光位移计测量其位移状态信息，并进行深度强化学习训练，如图 8 所示。图中激光位移计自上向下垂直测量桥梁模型在竖向的振动位移，热线探针位于模型迎面上方，距离模型前缘约 30 mm，用于测量来流风速




图 8 风洞试验中的桥梁模型

Fig. 8 The bridge model in wind tunnel test

并建立控制反馈关系。桥梁风致振动位移通过公式 (2) 获得：

$$D = \frac{D_1 + D_2 + D_3 + D_4}{4} \quad (2)$$

式中： $D_1 \sim D_4$ 分别表示位于桥梁模型 4 个对角线上的激光位移计测量的位移数据。另外，图 8 中的热线探针将被用于测量桥梁的来流风速。

DRL 训练奖励函数设置如公式 (3) 所示：

$$r_t = -50 < D >_{RMS} \quad (3)$$

式中： $< \cdot >_{RMS}$ 表示对一个动作周期内的振动位移进行均方根 (root mean square, RMS) 计算；奖励函数取负数是为了随着振动幅度的减少令奖励值逐渐上升。为了平衡控制精度和计算效率，使算法能够稳定收敛，通过实验调参得出奖励函数缩放系数。本文通过在不同实验条件下多次调试，最终选取 50 作为最佳的系数值，以实现较好的控制性能和较快的收敛速度。

DRL 的控制动作值被设定为信号函数发生器的控制电压，其中控制电压与合成射流流量之间的映射关系将通过热线探针测量并于 2.2 节中展示。

DRL 训练参数设置如表 3 所示。其中每一个 DRL 训练步即为一个动作交互周期，合成射流吹气持续时间为 90 s，激光位移计测量的桥梁振动区间为每个 DRL 训练步的第 60~90 s。由于 DRL 训练随机性

大, 调参困难, 准确的 DRL 超参数设置可帮助训练取得更好的效果。其中, 缓冲区大小对于 DRL 经验回放起着关键作用。较大的缓冲区可以提供更多的样本, 使样本具有多样性, 本次训练将缓冲区大小设置为 5000。神经网络学习率是控制参数更新步长的重要超参数, 较小的学习率会导致收敛速度过慢, 而较大的学习率会导致训练不稳定甚至发散。DRL 训练过程中, 神经网络学习率建议设置在 0.01~0.001 之间, 以保证训练收敛, 本次训练选择相对保守的 0.001 作为神经网络学习率。

表 3 DRL 训练参数
Table 3 DRL training parameters

DRL训练参数	输入值
状态值输入	桥梁振动位移 (4个激光位移计测量)
动作值	控制电压0~20 V
每训练轮次中动作数	1
射流动作持续时间	90 s
批量大小(Batch Size)	128
缓冲区大小(Buffer Size)	5000
奖励函数折扣因子	0.99
Actor神经网络学习率	0.001
Critic神经网络学习率	0.001

2 结果和讨论

2.1 桥梁涡激振动气动弹性试验准确性验证

首先需要验证本次大贝尔特桥气动弹性涡激振动风洞试验的准确性。图 9 所示为桥梁在均匀稳定风场下, 涡激振动的无量纲位移与折减风速的关系。其中, 横坐标中 f 为桥梁振动频率, 下标 “v” 表示垂直方向。该图展示了本次试验与其他两种不同模型缩尺比的试验数据的对比, 其中, 1:80 与 1:175 模型缩尺比的测量数据分别来自于 Zhan 等^[16] 与 Larsen




图 9 风洞试验中桥梁涡激振动的无量纲位移与折减风速关系
Fig. 9 Relation between dimensionless vibration displacement and reduced wind speed of vortex-induced vibration of bridge in wind tunnel test

等^[5] 的研究。桥梁的涡激振动锁定风速区间范围为 1.5~2.3 m/s, 对应于图中的折减风速为 0.8~1.3。图 9 中涡激振动锁定区间的折减风速范围与参考文献的测量范围相对一致, 说明本次气动弹性试验结果可靠, 可用于后续 DRL 训练。

2.2 合成射流吹气流速与电压/频率的关系

开展控制效果参数化分析及 DRL 训练前, 首先需要探究卧式合成射流的吹气流量与控制电压之间的映射关系。采用大连航华科技有限公司 CTA-04 型号多通道热线风速仪进行流量测量, 热线探针布置于合成射流激励器的射流口外 2 cm 处。控制电压与合成射流流量的映射关系如图 10 所示, 呈正相关, 且近似于线性关系, 最大控制电压 20 V 时, 可以产生平均 2.0 m/s 的吹气流量。这可以归因于控制电压影响压电振子形变的程度, 进而影响射流强度。随着电压的增大, 压电振子的形变加剧, 导致更多空气被迫通过射流出口, 从而增加了射流的流量。在实际应用中, 通过控制电压来调节射流流量是一个有效的手段, 尤其在桥梁风致振动控制中, 通过增大电压可提高射流强度, 从而更好地抑制涡激振动。




图 10 电压与合成射流流量的映射关系图
Fig. 10 Variation of average flow rate of the synthetic jet with control voltage

2.3 合成射流控制效果参数化分析

为了确保测试条件的一致性, 本节及后续试验均在折减风速为 1.2 的风场下进行, 以保证桥梁涡激振动处于最大振幅附近。同时, 结合前文可知控制电压与合成射流的平均吹气流量成近似线性正相关关系, 后续分析中将控制电压作为变量参数, 用于评估合成射流的控制效果。

图 11 展示了不同控制电压对合成射流抑制涡激振动效果的影响, 其中纵坐标为振动位移幅值标准差 (standard deviation, STD)。从图中可以看出, 随着控制电压的增大 (即更高的吹气流量), 涡激振动位移振幅逐渐减小, 控制效果显著增强; 最优控制 (即控

制电压为 20 V、最大吹气流量为 2.0 m/s 时)下桥梁振动位移的标准差相较于无控制时减少了约 83%，证明了合成射流在抑制桥梁涡激振动方面的显著效果。最优控制下，振动位移时程变化如图 12 所示。合成射流激励信号在约 2 s 时刻开启，随着时间推移，振幅逐渐衰减，并在约 30~35 s 后振动位移被抑制至最小范围。从流动控制的物理机制分析，较强的射流流量能够更加有效地扰动桥梁尾流中的冯卡门涡街，促进交替脱落的旋涡破坏，从而显著降低涡激振动的能量。

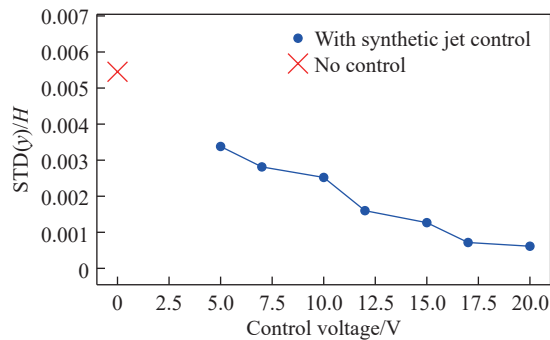


图 11 不同控制电压对合成射流抑制涡激振动效果的影响
Fig. 11 Variation of vortex-induced vibration displacement with the control voltages of synthetic jets




图 12 最优电压控制下桥梁无量纲振动位移时程曲线
Fig. 12 Time history of bridge nondimensional vibration displacement under optimal voltage control

谐波电信号的调制频率决定射流压电振子的振动频率，因此也决定了射流吹气的频率。将控制电压固定为 20 V，改变合成射流吹气频率，分析不同吹气频率对桥梁涡激振动控制效果的影响，得到如图 13 所示的结果。由图 13 可知，在最大吹气流量下，吹气频率对桥梁涡激振动的影响不明显，均可实现有效控制。这可能是由于尾流旋涡脱落的扰动主要受合成射流吹气流量控制，其具有决定性控制效果。相较于吹气流量，吹气频率对控制效果的影响较为次要。本组合射流控制试验在最大吹气流量(2.0 m/s)下已经展现出了相对稳定有效的控制效果，未来有必要在更精准的流量控制下，进一步研究合成射流吹气频率对控制效果的影响。

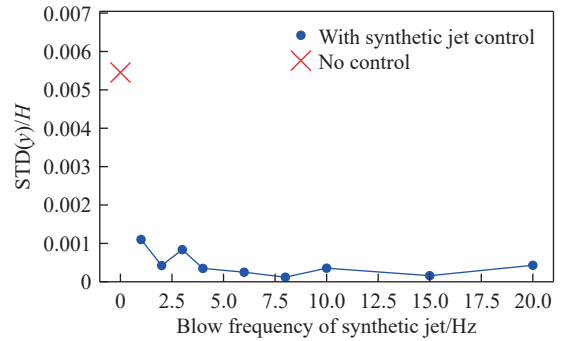


图 13 不同吹气频率对合成射流抑制涡激振动效果的影响
(纵坐标为振动位移幅值)

Fig. 13 Variation of vortex-induced vibration displacement with blow frequency of synthetic jets

2.4 深度强化学习训练稳态控制中电压参数

通过图 7 中深度强化学习与风洞试验流动控制耦合框架 DRLinWT 训练稳态环境下抑制桥梁涡激振动的最优控制电压。DRL 训练奖励值随训练步数变化的曲线如图 14 所示，其中横坐标 Steps 为训练步数，即训练中深度神经网络改变控制参数的次数。可知经 30 轮次训练后，奖励值曲线实现收敛。在稳态环境下，DRL 训练单一控制变量的过程较快，DRL 算法只需要尝试不同的控制电压并找到对应的桥梁涡激振动幅值映射关系即可。且如图 11 所示，流动控制效果与控制电压成正相关，该映射关系较为简单，DRL 算法可以很快找到最优的控制电压即为最大电压。




图 14 奖励值随 DRL 训练步数的变化
Fig. 14 Variation of reward value of the deep reinforcement learning with training steps

如图 15 所示，通过 SAC 算法进行训练时，控制电压在训练初期约 30 个训练步之前，波动较大。这主要是由 SAC 算法在初始阶段对环境的探索导致的。随着训练的进行，控制电压逐渐收敛并稳定在 19.7 V 附近，接近于设定的最大控制电压 20 V。训练步超过 30 步后，动作值的轻微波动可归因于 SAC 算法中固有的随机性(如探索策略的随机采样)以及环境状态和策略网络输出的细微变化。




图 15 控制电压动作值随 DRL 训练步数的变化

Fig. 15 Variation of control voltage of synthetic jets in the training process of deep reinforcement learning algorithm

DRL 训练结果表明,深度强化学习算法得出的最优控制电压接近最大电压,这一结论与合成射流控制参数化分析的结果一致,具体控制效果可参照图 12 最优电压控制下桥梁振动位移时程曲线,该结果从侧面验证了 DRL 算法在桥梁稳态控制训练中的可靠性与准确性。

3 结论

本文通过合成射流流动控制方法,扰动气动弹性桥梁节段模型尾流场的旋涡脱落。研究表明,该方法在稳定风场条件下能够有效抑制桥梁涡激振动,并显著提高桥梁的抗风性能。合成射流技术结合深度强化学习算法,利用自适应优化策略对控制电压进行调节,显著提高了控制效果。实验结果验证了该方法在一定条件下的优越性,为桥梁风工程提供了一种新的智能化解决方案。本研究包含合成射流对于桥梁的风致振动控制效果参数化分析以及深度强化学习(DRL)算法训练合成射流最优控制参数两部分,得到的主要结论如下:

1) 合成射流装置布置在桥梁底部尾缘转角的流动分离区域,通过压电振子在激励器内部振动产生的射流扰动尾流场,有效抑制了因旋涡脱落引起的涡激振动。在控制电压为 20 V、射流最大流量为 2.0 m/s 条件下,涡激振动振幅实现了约 83% 的显著降幅。

2) 合成射流控制电压与射流平均吹气速度成近似线性正相关关系,控制电压越大,吹气流量越高,对涡激振动的抑制效果越好。在最大控制电压条件下,射流频率对抑制效果影响不显著,这表明射流流量可能是抑制振动的决定性因素,而非射流频率。

3) 通过与风洞试验耦合的 DRL 流动控制训练框架进行最优控制电压训练。DRL 训练结果表明,算法在 30 个训练步内快速收敛,得出的最优控制电压为最大电压 20 V,与参数化分析的最优解一致,验

证了深度强化学习在合成射流桥梁稳态控制中的稳定性。

然而,本文方法仍然存在一定的局限性。首先,合成射流设备的实施成本较高,尤其在大规模应用时,需要安装多个激励器设备,这可能导致高昂的工程成本。其次,深度强化学习算法的计算复杂度较高,训练过程可能会消耗大量的时间和计算资源,这在实际工程中可能会成为瓶颈。

未来研究需进一步探索强化学习算法在复杂工况下的控制性能,特别是针对展向非均匀风场和非定常突变风场下桥梁涡激振动的研究。尝试引入多智能体深度强化学习方法,沿着桥梁底部尾缘展向间隔布置多个独立的合成射流激励器,并视为多个智能体进行训练,实现桥梁展向协作式流动控制。另外,对于合成射流的射流频率控制效果研究,应细化地考虑在不同吹气流量、来流风速、风致振动类型下的射流频率影响,实现精细化流动控制。

本文研究主要聚焦于合成射流在桥梁涡激振动控制中的应用,但合成射流技术在其他风敏结构领域同样具有潜在的应用前景,如高耸建筑的风致响应控制、海洋平台的结构振动抑制等。未来研究中,可进一步探索不同来流条件(如非定常风场、阵风扰动、紊流强度和偏角变化)对合成射流控制效果的影响,以增强该技术在复杂实际工况下的适应性和可靠性。

致谢: 特别感谢香港理工大学张洪福博士等长期以来对本团队研究工作给予的指导和帮助。

参 考 文 献:

- [1] 邓晓龙, 胡钢, 陈文礼, 等. 深度强化学习驱动下桥梁主动吸气流动控制[J]. 中国公路学报, 2023, 36(8): 66-75.
DENG X L, HU G, CHEN W L, et al. Active control of bridge aerodynamic flow driven by deep reinforcement learning[J]. China Journal of Highway and Transport, 2023, 36(8): 66-75(in Chinese).
- [2] 许福友, 丁威, 姜峰, 等. 大跨度桥梁涡激振动研究进展与展望[J]. 振动与冲击, 2010, 29(10): 40-49, 249.
XU F Y, DING W, JIANG F, et al. Development and prospect of study on vortex-induced vibration of long-span bridges[J]. Journal of Vibration and Shock, 2010, 29(10): 40-49, 249(in Chinese). doi: 10.3969/j.issn.1000-3835.2010.10.009
- [3] 赵林, 李珂, 王昌将, 等. 大跨桥梁主梁风致稳定性被动气动控制措施综述[J]. 中国公路学报, 2019, 32(10): 34-48.
ZHAO L, LI K, WANG C J, et al. Review on passive aerodynamic countermeasures on main girders aiming at wind-induced stabilities of long-span bridges[J]. China Journal of Highway and Transport, 2019, 32(10): 34-48(in Chinese).
- [4] 赵林, 刘丛菊, 葛耀君. 桥梁结构涡激共振的敏感性[J]. 空气动力学学报, 2020, 38(4): 694-704.
ZHAO L, LIU C J, GE Y J. Vortex-induced vibration sensitivity of bridge girder structures[J]. Acta Aerodynamica Sinica, 2020, 38(4): 694-704(in Chinese).

- doi: [10.7638/kqdlxxb-2020.0105](https://doi.org/10.7638/kqdlxxb-2020.0105)
- [5] LARSEN A, ESDAHL S, ANDERSEN J E, et al. Storebælt suspension bridge-vortex shedding excitation and mitigation by guide vanes[J]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2000, 88(2-3): 283-296.
doi: [10.1016/S0167-6105\(00\)00054-4](https://doi.org/10.1016/S0167-6105(00)00054-4)
- [6] 李永乐, 侯光阳, 向活跃, 等. 大跨度悬索桥钢箱主梁涡振性能优化风洞试验研究[J]. *空气动力学学报*, 2011, 29(6): 702-708.
LI Y L, HOU G Y, XIANG H Y, et al. Optimization of the vortex induced vibration for steel box girder of long span suspension bridges by wind tunnel test[J]. *Acta Aerodynamica Sinica*, 2011, 29(6): 702-708 (in Chinese).
doi: [10.3969/j.issn.0258-1825.2011.06.004](https://doi.org/10.3969/j.issn.0258-1825.2011.06.004)
- [7] REN F, WANG C L, TANG H. Bluff body uses deep-reinforcement-learning trained active flow control to achieve hydrodynamic stealth[J]. *Physics of Fluids*, 2021, 33(9): 093602.
doi: [10.1063/5.0060690](https://doi.org/10.1063/5.0060690)
- [8] RABAULT J, KUHNLE A. Accelerating deep reinforcement learning strategies of flow control through a multi-environment approach[J]. *Physics of Fluids*, 2019, 31(9): 094105.
doi: [10.1063/1.5116415](https://doi.org/10.1063/1.5116415)
- [9] WANG Q L, YAN L, HU G, et al. DRLinFluids: An open-source Python platform of coupling deep reinforcement learning and OpenFOAM[J]. *Physics of Fluids*, 2022, 34(8): 081801.
doi: [10.1063/5.0103113](https://doi.org/10.1063/5.0103113)
- [10] TANG H W, RABAULT J, KUHNLE A, et al. Roust active flow control over a range of Reynolds numbers using deep reinforcement learning[C]// 14th World Congress in Computational Mechanics and ECCOMAS Congress, Paris, France, 2020.
- [11] FAN D, YANG L, WANG Z, et al. Reinforcement learning for bluff body active flow control in experiments and simulations[J]. *Proceedings of the National Academy of Sciences*, 2020, 117(42): 26091-26098.
doi: [10.1073/pnas.2004939117](https://doi.org/10.1073/pnas.2004939117)
- [12] LI K, GE Y J, ZHAO L, et al. Numerical simulation of feedback flutter control for a single-box-girder suspension bridge by twin-winglet system[J]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2017, 169: 77-93.
doi: [10.1016/j.jweia.2017.07.013](https://doi.org/10.1016/j.jweia.2017.07.013)
- [13] DENG X L, HU G, CHEN W L. Intelligent active flow control of long-span bridge deck using deep reinforcement learning integrated transfer learning[J]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2024, 244: 105632.
doi: [10.1016/j.jweia.2023.105632](https://doi.org/10.1016/j.jweia.2023.105632)
- [14] HAARNOJA T, ZHOU A, ABBEEL P, et al. Soft actor-critic: Off-policy maximum entropy deep reinforcement learning with a stochastic actor[EB/OL]. 2018: 1801.01290. (2018)[2025-01-24].
<https://arxiv.org/abs/1801.01290v2>
- [15] DONG X H, WANG Z R, LIN P F, et al. An interactive platform of deep reinforcement learning and wind tunnel testing[J]. *Physics of Fluids*, 2024, 36(11): 115197.
doi: [10.1063/5.0238959](https://doi.org/10.1063/5.0238959)
- [16] ZHAN J, XIN D B, OU J P, et al. Experimental study on suppressing vortex-induced vibration of a long-span bridge by installing the wavy railings[J]. *Journal of Wind Engineering and Industrial Aerodynamics*, 2020, 202: 104205.
doi: [10.1016/j.jweia.2020.104205](https://doi.org/10.1016/j.jweia.2020.104205)

(本文责编: 周奇杰)