

基于域对抗自适应学习的旋翼无人机姿态稳定方法

李凤岐^{1,2} 金佳玉^{1,2} 杜学峰^{2,3} 张鑫^{1,2} 徐凤强^{1,2} 王德广^{1,2}

摘要 针对复杂海风环境下旋翼无人机姿态控制不稳定的问题, 提出姿态稳定方法 (SymTAL-POP). 该方法包括离线学习和在线预测两个部分. 在离线学习阶段, 引入对称式时序域对抗自适应学习算法 SymTAL. 结合域对抗学习、对称网络和双向时序网络, SymTAL 有效解决了海风环境中无人机姿态稳定问题. 利用深度学习优化加速框架和改进的 Adam 优化器, 提升了 SymTAL 的学习能力和计算效率. 在线预测阶段, 设计风场预测模型 POP, 实现海风环境的实时感知与预测. POP 采用变分模态分解技术处理风速信号, 通过特征选择策略预测不同风况下的风速, 增强了无人机的环境适应能力. 测试结果表明, SymTAL 在学习效率和控制精度方面均优于其他姿态稳定算法, POP 在连续风、间歇风和湍流风的多风况条件下的预测精度优于其他模型. 仿真实验表明 SymTAL-POP 在轨迹跟踪误差上表现突出, 平均值降低 23.5%, 均方根误差减少 55.2%.

关键词 旋翼无人机, 复杂海风环境, 姿态稳定, 域对抗学习, 风场预测

引用格式 李凤岐, 金佳玉, 杜学峰, 张鑫, 徐凤强, 王德广. 基于域对抗自适应学习的旋翼无人机姿态稳定方法. 自动化学报, 2025, 51(5): 1103–1117

DOI 10.16383/j.aas.c240186

CSTR 32138.14.j.aas.c240186

Domain Adversarial Adaptive Learning Based Attitude Stabilization Method for Rotary Wing Unmanned Aerial Vehicles

LI Feng-Qi^{1,2} JIN Jia-Yu^{1,2} DU Xue-Feng^{2,3} ZHANG Xin^{1,2} XU Feng-Qiang^{1,2} WANG De-Guang^{1,2}

Abstract To address the problem of unstable attitude control of rotary wing unmanned aerial vehicles (UAVs) in complex sea breeze environments, the attitude stabilization method named SymTAL-POP is proposed. The method consists of two parts: Offline learning and online prediction. In the offline learning phase, a symmetric temporal domain adversarial adaptive learning algorithm named SymTAL is introduced. By combining domain adversarial learning, symmetric networks and bidirectional temporal networks, SymTAL effectively solves the problem of UAVs attitude stabilization in the sea breeze environments. Utilizing a deep learning optimization acceleration framework and an improved Adam optimizer, the learning capability and computational efficiency of SymTAL are enhanced. In the online prediction phase, a wind field prediction model named POP is designed for real-time sea breeze environment perception and prediction. POP utilizes variational mode decomposition technology to process wind speed signals and predicts wind speeds under various wind conditions via a feature selection strategy, improving environmental adaptability of UAVs. Test results show SymTAL outperforms other attitude stabilization algorithms in terms of learning efficiency and control precision, and POP exhibits excellent prediction accuracy under multiple wind conditions of continuous, intermittent and turbulent winds. Simulation experiments show that SymTAL-POP excels in trajectory tracking error, with mean reduction of 23.5% and root mean square error reduction of 55.2%.

Key words Rotary wing unmanned aerial vehicles, complex sea breeze environment, attitude stabilization, domain adversarial learning, wind field prediction

Citation Li Feng-Qi, Jin Jia-Yu, Du Xue-Feng, Zhang Xin, Xu Feng-Qiang, Wang De-Guang. Domain adversarial adaptive learning based attitude stabilization method for rotary wing unmanned aerial vehicles. *Acta Automatica Sinica*, 2025, 51(5): 1103–1117

收稿日期 2024-04-08 录用日期 2025-02-08

Manuscript received April 8, 2024; accepted February 8, 2025

辽宁省国际科技合作计划 (2022JH2/10700012), 辽宁省应用基础研究计划 (2023JH2/101300188, 2022JH2/101300269), 辽宁省教育厅基础研究项目 (JYTMS20230011), 辽宁省科研基金项目 (LJKQZ20222447) 资助

Supported by International Science and Technology Cooperation Program of Liaoning Province (2022JH2/10700012), Applied Basic Research Program of Liaoning Province (2023JH2/101300188, 2022JH2/101300269), Basic Research Project of Liaoning Educational Department (JYTMS20230011), and

Research Foundation of Liaoning Province (LJKQZ20222447)

本文责任编辑 许斌

Recommended by Associate Editor XU Bin

1. 大连交通大学软件学院 大连 116028 2. 大连市区块链应用技术实验室 大连 116028 3. 大连交通大学机械工程学院 大连 116028

1. School of Software, Dalian Jiaotong University, Dalian 116028 2. The Dalian Key Laboratory of Blockchain Technology and Application, Dalian 116028 3. School of Mechanical Engineering, Dalian Jiaotong University, Dalian 116028

旋翼无人机在海上作业时面临复杂变化的海风环境. 由于无人机体积小、重量轻, 容易产生机身剧烈摇晃, 导致控制失效^[1-4]. 尽管增加机身尺寸和提升配置可以增强抗风性能, 但这会增加载重、降低无人机的灵活性^[5-6]. 因此, 在保证无人机轻便灵活的前提下提升抗风能力, 成为当前研究的重要方向. 部分研究集中于开发和优化控制算法来提升无人机的性能^[7], 但在海上环境的应用中仍存在显著挑战. 首先, 这些算法难以适应海风的突变特性; 其次, 增强抗风能力通常以增加计算负载和降低机动性为代价^[8]. 以上挑战表明, 提高无人机在复杂海上任务中的稳定性和安全性十分重要.

为实现无人机海上稳定飞行, 亟须解决现有算法难以有效响应风力变化且缺乏自适应调节的问题. 传统的气动力建模主要依赖明确的气动模型^[9], 在动态环境中存在误差大、迁移能力差的问题. 此外, 这类模型缺乏自适应控制策略. 为此, 文献 [10-11] 提出基于扰动观测器 (Disturbance observer-based, DOB) 和自抗扰控制 (Active disturbance rejection control, ADRC) 算法, 用于补偿系统扰动并改善输入与输出之间的匹配性能. 然而, 这些方法高度依赖于对扰动的精确估计, 误差可能导致控制结果下降. 为提升无人机的抗风能力, 多项研究工作致力于优化风感知、风阻抗调整算法和风场预测策略. Sziroczak 等^[12] 提出轻量化风感知方案, 但其在复杂风场中的学习效果不佳. Xue 等^[13] 采用深度强化学习和域随机化相结合的方法, 但其在多变风场中的适应性有限. Song 等^[14] 通过模型预测控制 (Model predictive control, MPC) 实时调整正则化参数, 提升无人机的抗风能力. 然而, 这些方法仍未充分解决风场变化的预测问题. 为此, Yan 等^[15] 提出 FlowDrone 模型, 通过热线传感器和风感知残差控制器进行风场估计, 但其泛化能力有限. Zha 等^[16] 采用门控循环单元 (Gated recurrent unit, GRU) 和时间卷积网络 (Temporal convolutional network, TCN) 组合优化风场预测性能, 但其模型复杂且需要精确调参. 综上所述, 现有研究虽在风场感知和抗风控制方面取得进展, 但在应对复杂海风环境时仍存在旋翼无人机的控制算法适应性不足、计算复杂度高和飞行姿态不稳定的问题, 因此, 亟须提升算法的适应性、优化风场预测性能, 并降低计算负担, 以确保无人机在复杂海风环境下稳定飞行.

为此, 本文提出一种具有抗风特性的域对抗自适应姿态稳定方法 SymTAL-POP (Symmetric temporal adversarial learning-partitioned online prediction), 旨在提升无人机对复杂海风环境的适应

能力, 确保飞行姿态的稳定性. 风场概念图如图 1 所示. 该方法包含离线的对称式时序域对抗自适应学习算法 SymTAL 和在线风场预测模型 POP. SymTAL 利用域对抗学习捕捉气动共享特征和全面信息, 结合对称网络和双向时序网络, 有效减少了网络层的复杂度, 提升了学习效率和算法性能. 为提升计算效率, 引入深度学习加速技术及改进的 Adam 自适应优化器, 实现精准的飞行姿态控制. 此外, 通过正则化超参数调整优化对抗性框架, 进一步增强了抗风能力. 在线风场预测模型 POP 通过变分模态分解 (Vibration modedecomposition, VMD) 技术对风速信号进行分解, 以便准确捕捉风速特征. 模型池根据风速特征进行决策, 选择 GRU-TCN 或支持向量回归 (Support vector regression, SVR) 模型来捕捉风速信号, 从而提升了预测真实性. 该方法增强了无人机在面对不同风力条件下的适应性, 实现复杂海风环境下的自适应稳定飞行.



图 1 风场概念图

Fig.1 Wind field concept map

本文的主要创新点如下:

- 1) 提出一种具有抗风特性的自适应飞行控制方法: 将离线域对抗自适应学习算法 SymTAL 和在线风场预测模型 POP 相结合, 解决了海面风力变化导致无人机不稳定的问题;
- 2) 优化离线学习算法: SymTAL 在域对抗学习算法中引入对称网络和双向长短期记忆 (Bi-directional long short-term memory, BiLSTM) 网络, 并通过深度学习加速技术改进 Adam 优化器, 优化对抗性框架, 提升了算法性能和计算效率;
- 3) 提升在线风场预测能力: POP 使用变分模态分解技术分解风速信号, 并根据特性选择适当的预测模型, 大幅度提高了预测的精确度.

1 相关工作

为确保无人机在海风环境下稳定飞行, 研究者在不扩大体积和调整配置的情况下, 致力于提升控

制算法的性能. 文献 [17–18] 提出对称神经网络结构, 在无人机几何自适应控制中展现出优异性能, 特别在处理多级数据改善和抑制风扰动方面表现出色. Shi 等^[19] 研究结合具有对称特性的深度神经网络 (Deep neural networks, DNN) 的控制算法, 通过考虑风向的对称性, 明显减小了跟踪误差. 除此之外, 域对抗学习被应用于提高无人机在不同风域中的性能. O'Connell 等^[20] 提出 Neural-Fly 算法, 使用域对抗不变元学习减小了跟踪误差, 实现精确的飞行控制, 使无人机能更好地适应复杂多变的风场环境. Sun 等^[21] 引入具有对称性的网络层, 结合鲸鱼优化算法 (Whale optimization algorithm, WOA) 和多层感知机模型, 提高了风速预测的精度, 从而控制无人机稳定飞行.

Kim 等^[22] 提出一种 MemN2N 架构, 引入 BiLSTM 以更好地捕捉时间特征. Ma 等^[23] 研究基于堆叠长短期记忆 (Long short-term memory, LSTM) 网络的多输出迭代预测模型, 利用多输出迭代预测策略有效减少了长期时间序列预测的误差累积和误差传播问题. Guo 等^[24] 集成 BiLSTM 预测模型, 通过获得稳定的时间序列作为模型输入数据, 有效消除了大范围特征值的影响, 从而提升算法性能.

利用深度学习能够显著提高算法性能. Samadianfar 等^[25] 提出基于深度学习的层次化自适应策略, 该策略通过优化大批量训练过程有效减少了深度神经网络的训练数据需求. Dhakal 等^[26] 研发 GSTuner 自适应调优框架, 可自动确定 GPU 模型全局优化空间的最优参数设置, 有效加快了任务速度. 此外, Filippini 等^[27] 提出一种 GPU 服务系统, 利用深度学习训练方法得到最佳速度曲线, 最小化能耗并有效减小了预测偏差. You 等^[28] 使用混合深度模型, 采用不同的编码器-解码器 LSTM 展现出优于其他学习模型的任务完成速度. 在此基础上, 改进的 Adam 自适应优化器能够进一步自动调整学习率, Kingma 等^[29] 采用 Adam 优化算法来解决大规模数据和参数的优化问题, 可以针对不同参数设定不同的学习率, 以实现自适应优化. Liu 等^[30] 采用基于深度学习的轨迹映射网络 (Trajectory mapping network, TMN) 和 L2 正则参数调整相结合以提高规划效率与鲁棒轨迹跟踪. L2 正则化方式可有效降低损失函数, 减小预测误差.

海风环境是多变的, 为应对复杂的海风, 需要进一步提高算法的适应性, 深化对风场的理解. 当前, 无人机风场预测和建模的方法主要包括水平空速归零法、解析测风法、航位推算法以及皮托-静压管测风法等. Ma 等^[31] 通过改进低延迟 K-means 聚

类算法来优化无人机数据收集任务, 实现对不同风速的快速分类. Lv 等^[32] 提出基于优化变分模态分解和非线性加权组合深度学习算法的风电功率预测方法, 显著提升了预测精度. Dudukcu 等^[33] 提出混合深度神经网络架构, 利用变分模态分解和长短期记忆技术来减少误差传播并提升了模型的泛化能力. Zhang 等^[34] 提出基于循环神经网络 (Recurrent neural network, RNN) 架构的 TCN 来解决混沌时间序列预测问题, 以应对环境的复杂性和不可预测性. Zhang 等^[35] 采用时空深度学习的方法研发 MT-DETrajGRU 模型可同时修正风速和风向, 使不配备风传感器的四旋翼无人机能够进行风估计和修正. Bai 等^[36] 提出新颖 VMD-A-LSTM-SVR 模型, 解决了超前预测问题. Sikkil 等^[37] 提供两种不同的旋翼无人机在线风估计方法, 能够仅使用少量数据来准确地预测风速分量. 以上风估计方法为风场预测研究提供基础, 而风场预测模型则为控制算法的优化提供支持.

2 预备知识

2.1 变分模态分解 (VMD)

VMD 被广泛用于分解具有不同振动模式的信号^[32]. 具体表达式如下:

$$s_i(t) = A_i(t) \cos(2\pi f_i t + \phi_i(t)) \quad (1)$$

其中, t 是时间; $A_i(t)$ 是幅度; f_i 是中心频率; $\phi_i(t)$ 是相位. 将 VMD 用于处理实时风速信号, 通过选择合适的调谐参数和带宽参数, 对信号进行调谐分解, 进而产生一系列窄带信号. 通过对每个窄带信号进行带通滤波, 提取出该频带内的有效信息:

$$y(t) = F^{-1}[F[x(t)]] \times F[b(t)] \quad (2)$$

其中, $F[x(t)]$ 和 $F[b(t)]$ 表示傅里叶变换; $x(t)$ 是时域信号; $b(t)$ 是带通滤波器. 在完成滤波处理之后, 采用迭代优化策略对每个风信号的窄带分量进行调整. 重复上述过程, 不断逼近最优解, 直至达到收敛状态. 最终, 通过将所有经过调谐分解的风信号分量累加重构出风速信号:

$$\hat{x}(t) = \sum_{i=1}^N x_i(t) \quad (3)$$

2.2 时间卷积网络 (TCN)

TCN 擅长捕捉长期依赖关系^[16], 通过因果卷积来处理风速序列, 从前序风速 $x_1, x_2, \dots, x_t$ 预测未来风速 $y_1, y_2, \dots, y_t$, 实现长期风速预测. 风速 x_t

处的因果卷积为 $(F * X)_{(x_t)} = \sum_{k=1}^K f_k x_t - K + k$, 其中, K 为卷积核; X 为输入序列; “ $*$ ”表示卷积操作; 滤波器为 $F = (f_1, f_2)$. 计算未来风速如下:

$$y_t = f_1 x_{t-1} + f_2 x_t \quad (4)$$

因果卷积进行严格的时间约束, 其结构是单向的, 从而确保在每个时间点仅能访问当前及之前的风速信息, 未来数据则被屏蔽. 针对风速数据的海量且非线性特征, TCN 采用残差连接技术, 可以有效缓解梯度消失问题, 提升网络训练的稳健性.

2.3 门控循环单元 (GRU)

GRU 是循环神经网络的一种高效变体^[6]. GRU 的门控机制能够有效增强网络对时间序列中长期依赖关系的捕捉和记忆能力, 解决风速中的梯度消失问题, 同时减少参数量; 并且 GRU 能够在每个时间步根据当前输入和前一个隐藏状态来更新当前隐藏状态, 同时通过重置门和更新门来控制风速信息的流动. 这种结构使得 GRU 在处理风速时间序列数据时, 既能够捕捉到长期依赖关系, 又能够有效地传递信息, 与 LSTM 相比, GRU 在保持相当效果的同时, 训练更为简便, 显著提升训练效率.

3 方法的整体框架

面对复杂海风环境下无人机飞行控制误差较大的挑战, 本研究实现了一种具有抗风特性的自适应

姿态稳定控制方法. 该方法融合域对抗学习、对称网络和双向时序网络的无人机姿态稳定算法 SymTAL, 以及在线实时预测风场模型 POP. 整体架构示意图详见图 2. 首先, 无人机通过 POP 实时处理风速数据, 使用 K-means 聚类 and VMD 技术对风速信号进行分解, 从模型池选取合适的模型, 根据风速信号特征, 选择 TCN-GRU 模型捕捉长短期依赖关系, 使用 SVR 处理非线性关系, 获取预测风速 W_1 . 同时, 传感器收集当前风况下无人机的状态数据, 包括速度、四元数和脉冲宽度调制 (Pulse width modulation, PWM), 并将上述数据传输至离线 SymTAL 中. SymTAL 将得到的共性基函数 Q 与风相关系数 a 相乘, 计算出风效应力. 基于此结果, 确定期望力, 并将其发送至无人机飞行控制器, 从而实现无人机在线自适应稳定飞行. 此外, 由于风速和阻力之间存在复杂的关系, 且在不同海拔下风速动态变化, 无人机根据风速计算得到当前高度下的风速 k_z , 从而选择最优的飞行区域.

3.1 无人机气动理论建模与控制算法

3.1.1 无人机气动理论建模

传统的气动力建模方法虽然在物理意义上表现出色, 但其在迁移性方面的不足及参数获取过程中存在误差的问题, 使实时气动力 (矩) 预测变得困难.

因此, 本研究提出基于对称式时序域对抗自适应学习的无人机控制算法. 该算法使用深度神经网络




图 2 无人机抗风自适应总体框架图

Fig. 2 Overall framework diagram of UAVs wind resistance adaptation

络, 不仅具有强大的学习能力和自动提取物理特征的能力, 并且通过域对抗自适应学习方法提升模型的迁移能力和泛化能力. 这种设计不仅适用于不同风力条件, 且能支持实时气动力建模, 从而克服传统方法在多场景中的局限性和测量误差的问题. 无人机动力学模型如下:

$$M(q)\ddot{q} + C(q, \dot{q})\dot{q} + \mathcal{L}(q) = u + f(q, \dot{q}, \nu) \quad (5)$$

其中, q 、 $\dot{q}$ 和 $\ddot{q} \in \mathbf{R}_n$ 分别表示 n 维的位置、速度和加速度矢量; $M(q)$ 为对称的正定惯性矩阵; $C(q, \dot{q})$ 是科里奥利矩阵; $\mathcal{L}(q)$ 是重力矢量, 仅与 q 相关; $u \in \mathbf{R}_n$ 是控制力; $f(q, \dot{q}, \nu)$ 是未建模的动力学, 其中 $\nu \in \mathbf{R}_n$ 是一个未知的隐藏状态, 是风速矢量, 用于表示时序变化的潜在环境条件. 根据多元函数的切比雪夫级数理论, 多元函数可分解为不同变量的多项式乘积之和. 文献 [15] 证明

$$f(q, \dot{q}, \nu) \approx Q(q, \dot{q})a(\omega) \quad (6)$$

其中, $Q(\cdot, \cdot)$ 是所有风条件共享的基函数, 捕获未建模动力学对机器人状态的依赖; $a(\omega)$ 是针对每个条件更新的一组线性系数. 对于任何解析函数 $f(q, \dot{q}, \nu)$ 都存在一个 $Q(q, \dot{q})a(\omega)$. 考虑到四旋翼无人机的动力学中全局位置 $p \in \mathbf{R}^3$ 、速度 $v \in \mathbf{R}^3$ 、物体角速度 $\omega \in \mathbf{R}^3$ 给出的状态, 四旋翼飞行器的动力学如下:

$$\begin{cases} \dot{p} = v \\ m\dot{v} = mg + Rf_u + f \end{cases} \quad (7)$$

$$\begin{cases} \dot{R} = RS(\omega) \\ J\dot{\omega} = J\omega \times \omega + \tau_u \end{cases} \quad (8)$$

其中, m 为质量; R 为旋转矩阵; J 为四旋翼的惯性矩阵; $S(\cdot)$ 为斜对称映射; $f_u = [0, 0, \bar{T}]^T$ 和 $\tau_u = [\tau_x, \tau_y, \tau_z]^T$ 为由标称模型预测的四旋翼的总推力和机体力矩, $\bar{T}$ 表示无人机在机体坐标系中沿 z 轴方向施加的推力; g 为重力矢量; $f = [f_x, f_y, f_z]^T$ 是由不同的风条件而产生的未建模空气动力. 将上述无人机位置动态 (7)、(8) 与动力学模型 (5) 相结合, 其中 $M(q) = mI$, $C(q, \dot{q}) \equiv 0$, $u = Rf_u$. 因此在位置控制中, 通过该方法计算期望的力 u_d , 动力学将期望的力分解为期望的姿态 R_d 和期望的推力 T_d , 并将其发送到无人机的飞行控制器中, 以控制无人机飞行. 同时除了无人机速度 v , 气动效应还取决于无人机姿态和旋翼转速, 因此在算法中, 基函数 Q 的设计考虑这些因素, 该算法的输入状态 X 是由 11 维向量组成的深度神经网络, 包括 3 维的无人机速度 v 、4 维的姿态四元数和 4 维的飞行控制的脉冲宽度调制 PWM. 此外, 风效应力 f 的三个分量

f_x 、 f_y 和 f_z 高度相关并具有共同的特征, 因此所受阻力系数相同, $Q(q, \dot{q})$ 在对角矩阵的对角元素均为 $Q(X)$, 风效应力 f 近似为:

$$f \approx \begin{bmatrix} Q(X) & 0 & 0 \\ 0 & Q(X) & 0 \\ 0 & 0 & Q(X) \end{bmatrix} \begin{bmatrix} a_x \\ a_y \\ a_z \end{bmatrix} \quad (9)$$

其中, a_x 、 a_y 和 $a_z \in \mathbf{R}^4$ 是风效应力的每个分量的线性系数.

本文采用对称式时序域对抗自适应学习算法对共性基函数 Q 进行离线提取, 并应用到实时风况 ω 条件下进行训练. 在此基础上, 将计算所得的期望力传输至无人机的飞行控制器中. 基于该算法不仅能够增强了迁移能力, 也确保了无人机姿态的稳定控制.

3.1.2 无人机控制算法

在本节中, 我们将详细讨论上文提到的对称式时序域对抗自适应学习算法, 见算法 1. 与其他自适应学习算法不同, SymTAL 的目标是学习一个共性基函数 Q , 以确保在海面不同风况下都能保持其普适性. 该算法通过域对抗学习提取气动共享特征作为生成器, 并在网络结构中结合具有对称性的网络结构和双向长短期记忆网络, 以共享参数来提升速度和鲁棒性. 同时, 双向长短期记忆网络能够捕捉更全面的信息, 从而适应不同环境下的数据. 判别器则引入最小化域分类器来提取错误特征, 用于判别不同的风况类型, 从而达到在基函数提取中保持物理特征不变性的目标. 以下是算法的细节及优化方法.

算法 1. 对称式时序域对抗自适应学习算法

输入. 数据集 $P = \{P_{f1}, \dots, P_{fk}\}$, $\alpha = 0.001$, $0 < \eta \leq 1$, 生成器 Q , 判别器 R .

输出. 训练后的 Q 和 R .

- 1) 从数据库中随机抽取样本集 P_{fk} ;
- 2) 从样本集 P_{fk} 中随机划分适应集 D_a 和训练集 D ;
- 3) 使用最小二乘法求解

$$a^* = \arg \min_{i \in D_a} \sum \|y_k^{(i)} - Q(x_k^{(i)})a_k\|^2$$

- 4) 当 $\|a^*\| > \gamma$, $a^* \leftarrow \gamma \times \frac{a^*}{\|a^*\|}$, γ 是预设的阈值, 是标量常数;
- 5) 训练生成器 Q 和 R , 使用 BiLSTM 提取特征值

$$lstm_{\text{feature}} = \text{BiLSTM}(\text{sym}_{\text{feature}}, a_j)$$

- 6) 使用改进 Adam 优化器, 引入梯度的二阶矩估计;
- 7) 用随机梯度下降和谱归一化, 计算损失

$$\max_{Q, \{a_j\}} \min_j \sum_i \| \text{BiLSTM}(\text{sym}(Q(x_{cj}^{(i)})), a_j) - f(x_{cj}^{(i)}, a_j) \|^2 - \alpha \times \text{Loss}(R(Q(x_{cj}^{(i)})), j)$$

8) 如果 $\text{rand}() \leq \eta$ 训练判别器 R , 达到

$$\sum_{i \in D} \text{Loss} \left(R \left(Q \left(x_{cj}^{(i)} \right) \right), j \right)$$

9) 重复步骤 1) ~ 步骤 8) 直到损失收敛.

在给定的数据集下, 对抗自适应学习的目标是在任何风力条件下, 都存在一个潜在变量 $a(\omega)$, 允许 $Q(x)a(\omega)$ 可以更好地近似真实的数值 $f(x, \omega)$.

$$\min_{Q, a_1, \dots, a_K} \sum_{k=1}^K \sum_{i=1}^{N_k} \left\| y_k^{(i)} - Q \left(x_k^{(i)} \right) a_k \right\|^2 \quad (10)$$

其中, y 是气动力 (矩); x 是由 3 维的无人机速度 v 、4 维的姿态四元数和 4 维的飞行控制的脉冲宽度调制 PWM 组成的矢量向量, 也是深度神经网络的输入数据; $a_k \in \mathbf{R}_h$ 是潜在的一个线性系数, 并且最佳权重 a_k 是特定于每种风力条件的, 最优的结果由风力条件所共享. 在该算法中, 使用 DNN 来训练 Q , 拥有足够多的神经元就可以使用 $Q(x)a(\omega)$ 在任意的精度逼近真实的数值 $f(x, \omega)$, 从而得到风效应力 f , 其中 Q 的结构是一个深度神经网络, 具有输入层、对称网络层、BiLSTM 层和输出层. 输入层接收 11 维的输入数据; 对称网络层由 2 个对称的分支组成, 每个分支由一个包含 25 个神经元的全连接层和 ReLU 激活函数构成; BiLSTM 层使用 50 个 LSTM 单元; 输出层包含 4 个神经元, 对应于 4 维输出. 其中对称网络层通过共享权重和拼接操作来减少参数量, 以此降低训练量, 进而提升训练的稳定性.

ω 的变化会导致产生域位移. 在真实的场景中, 风的变化也会导致飞行轨迹改变. 例如, 无人机顶风飞行时会产生仰俯倾斜, 并且其仰俯倾斜的平均程度取决于风的条件. 风场状态中的风速分量 x 具有强非线性特征, 其剧烈变化会导致状态空间的分布漂移更加剧烈, 这给深度学习方法带来巨大挑战. DNN 可以记忆 x 在不同风状态下的分布, 使得动力学 $\{f(x, \omega_1), f(x, \omega_2), \dots, f(x, \omega_k)\}$ 不是通过风的状况 $\{\omega_1, \omega_2, \dots, \omega_k\}$, 而是通过 x 的分布来反映情况. 这样就导致过度拟合, 并且可能无法准确找到适合不同风况下无人机相对稳定的飞行姿态. 为解决上述问题, 受到 Ganin 等^[38] 的工作启发, 本文提出对抗性优化框架:

$$\max_{Q, a_j, \dots, a_K} \min_{a_1, \dots, a_K} \sum_{j=1}^K \sum_{i=1}^{N_k} \left\| y_k^{(i)} - \text{BiLSTM} \left(\text{sym} \left(Q \left(x_{cj}^{(i)} \right) \right), a_j \right) \right\|^2 - \alpha \times \text{Loss} \left(R \left(Q \left(x_{cj}^{(i)} \right) \right), j \right) \quad (11)$$

其中, R 是另一个 DNN, 作为判别器来预测 j 个风

条件之外的环境指数, 其网络层包含三层: 输入层有 4 个神经元, 隐藏层有 126 个神经元, 输出层有 6 个神经元, 同样使用 ReLU 激活函数; $\text{Loss}(\cdot, \cdot)$ 是分类损失函数; α 为控制正则化程度的超参数, 本文中 α 为 0.1; j 是风条件指数; $\text{sym} \left(Q \left(x_{cj}^{(i)} \right) \right)$ 表示具有对称性的网络层结构, 具体解释见算法 1; $\text{BiLSTM} \left(\text{sym} \left(Q \left(x_{cj}^{(i)} \right) \right), a_j \right)$ 表示通过双向长期记忆 (BiLSTM) 网络提取对称化特征. 直观上, R 和 Q 是对抗学习和生成式对抗网络 (Generative adversarial network, GAN) 思想的结合, Q 是生成器, R 是判别器, 生成器 Q 通过最小化第一项 $\|f(x) - Q(x)a\|_2^2$ 试图生成与目标函数 $f(x)$ 相似的输出, 作为提取的基函数. R 用于判别不同的风况类型, 从而达到特征不变性, 便于在线风场预测模型传递不同风况时的判别, 实现不同风况的迁移. $R(Q(x))$ 在分类任务中难以区分, 为使 $\alpha \times \text{Loss} \left(R \left(Q \left(x_{cj}^{(i)} \right) \right), j \right)$ 达到最大化, 因此通过 R 判别器正确地区分 Q 生成的样本和真实的 $f(x)$, 该实验中 $\text{Loss}(\cdot, \cdot)$ 使用交叉熵损失, 具体如下:

$$\text{CrossEntropy} \left(R \left(Q \left(x_{cj}^{(i)} \right) \right), j \right) = - \sum_c y_{cj} \log \left(R_c \left(Q \left(x_{cj}^{(i)} \right) \right) \right) \quad (12)$$

其中, y_{cj} 为独热编码, 如果 $j = c$, 则 $c_j = 1$, 否则为 0; c_j 为标准的基函数; $R_c(\cdot)$ 表示 $R(\cdot)$ 的第 c 个输出.

算法 1 在生成器中使用 $\text{BiLSTM} \left(\text{sym} \left(Q \left(x_{cj}^{(i)} \right) \right), a_j \right)$, 通过 BiLSTM 网络提取对称化特征, 具体如下:

$$\text{BiLSTM} \left(\text{sym} \left(Q \left(x_{cj}^{(i)} \right) \right), a_j \right) = \text{Concat} \left(\vec{h}_t, \overleftarrow{h}_t \right) \quad (13)$$

在时刻 t 处, $\vec{h}_t$ 表示前向传播, LSTM 隐藏状态的计算公式如下:

$$\begin{cases} \vec{i}_t = \sigma \left(\vec{W}_{ii}x_t + \vec{b}_{ii} + \vec{W}_{hi}\vec{h}_{t-1} + \vec{b}_{hi} \right) \\ \vec{f}_t = \sigma \left(\vec{W}_{if}x_t + \vec{b}_{if} + \vec{W}_{hf}\vec{h}_{t-1} + \vec{b}_{hf} \right) \\ \vec{g}_t = \tanh \left(\vec{W}_{ig}x_t + \vec{b}_{ig} + \vec{W}_{hg}\vec{h}_{t-1} + \vec{b}_{hg} \right) \\ \vec{o}_t = \sigma \left(\vec{W}_{io}x_t + \vec{b}_{io} + \vec{W}_{ho}\vec{h}_{t-1} + \vec{b}_{ho} \right) \\ \vec{c}_t = \vec{f}_t \odot \vec{c}_{t-1} + \vec{i}_t \odot \vec{g}_t \\ \vec{h}_t = \vec{o}_t \odot \tanh \left(\vec{c}_t \right) \end{cases} \quad (14)$$

其中, x_t 是当前时间步的输入向量; $\vec{h}_{t-1}$ 是上一时间步的隐藏状态; $\vec{c}_{t-1}$ 是上一时间步的记忆单元状

态; $\vec{W}_{ii}$ 、 $\vec{W}_{if}$ 、 $\vec{W}_{ig}$ 、 $\vec{W}_{io}$ 和 $\vec{W}_{hi}$ 、 $\vec{W}_{hf}$ 、 $\vec{W}_{hg}$ 、 $\vec{W}_{ho}$ 分别是输入和隐藏状态的权重矩阵; $\vec{b}_{ii}$ 、 $\vec{b}_{if}$ 、 $\vec{b}_{ig}$ 、 $\vec{b}_{io}$ 和 $\vec{b}_{hi}$ 、 $\vec{b}_{hf}$ 、 $\vec{b}_{hg}$ 、 $\vec{b}_{ho}$ 是对应的偏置项; $\vec{i}_t$ 是输入门; f_t 是遗忘门; $\vec{g}_t$ 是候选记忆单元; $\vec{o}_t$ 是输出门; $\vec{c}_t$ 是当前时间步的记忆单元状态; $\vec{h}_t$ 是当前时间步的隐藏状态; $\tanh$ 为双曲正切激活函数; σ 表示 Sigmoid 函数; $\odot$ 表示元素相乘. 后向 LSTM 更新如下:

$$\begin{cases} \vec{i}_t = \sigma \left(\vec{W}_{ii}x_t + \vec{b}_{ii} + \vec{W}_{hi}\vec{h}_{t-1} + \vec{b}_{hi} \right) \\ \vec{f}_t = \sigma \left(\vec{W}_{if}x_t + \vec{b}_{if} + \vec{W}_{hf}\vec{h}_{t-1} + \vec{b}_{hf} \right) \\ \vec{g}_t = \tanh \left(\vec{W}_{ig}x_t + \vec{b}_{ig} + \vec{W}_{hg}\vec{h}_{t-1} + \vec{b}_{hg} \right) \\ \vec{o}_t = \sigma \left(\vec{W}_{io}x_t + \vec{b}_{io} + \vec{W}_{ho}\vec{h}_{t-1} + \vec{b}_{ho} \right) \\ \vec{c}_t = \vec{f}_t \odot \vec{c}_{t-1} + \vec{i}_t \odot \vec{g}_t \\ \vec{h}_t = \vec{o}_t \odot \tanh(\vec{c}_t) \end{cases} \quad (15)$$

合并前向和后向的隐藏状态, 使其连接成一个单一的隐藏状态:

$$h_t = \begin{bmatrix} \vec{h}_t; \overleftarrow{h}_t \end{bmatrix} \quad (16)$$

对于训练的结果使用改进的 Adam 优化器, 其中包含的参数表示为:

$$\begin{cases} m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \\ \hat{m}_t = \frac{m_t}{1 - \beta_1^t} \\ \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \\ \theta_{t+1} = \theta_t - \frac{\mu}{\sqrt{\hat{v}_t} + \epsilon} \hat{m}_t \end{cases} \quad (17)$$

其中, m_t 和 v_t 分别是梯度的一阶和二阶估计; β_1 和 β_2 是衰减率, 分别设置为 0.9 和 0.999; β_1^t 和 β_2^t 是 β_1 和 β_2 的 t 次方; g_t 是当前步骤的梯度; $\hat{m}_t$ 和 $\hat{v}_t$ 是修正后的一阶和二阶矩估计; 学习率 μ 控制参数更新的步长; ϵ 是一个很小的常数, 用于避免分母为零; 模型参数 θ_t 通过更新规则 $\theta_{t+1} = \theta_t - (\mu / \sqrt{\hat{v}_t} + \epsilon) \times \hat{m}_t$ 进行迭代优化. 通过修正 v_t 使其始终保持为历史的梯度平方最大值

$$v_t = \max(v_{t-1}, g_t^2) \quad (18)$$

来减少学习率过大问题, 从而提升算法的稳定性. 步骤 7) 通过调整正则化超参数, 结合随机梯度下降和谱归一化技术, 以增强算法的鲁棒性. 此外在每次迭代更新中概率 $\eta \leq 1$, 以提高算法的收敛性.

3.2 实时风场预测模型

鉴于复杂海风环境下, 离线训练模型难以涵盖所有可能的风况场景, 因此引入实时在线风场预测模型. 该模型能够动态预测风速, 并将预测风速数据传输至离线 SymTAL 算法中, 以更新算法中的参数 ω . 通过这种方式, 确保无人机能够及时响应风速变化, 实现自适应稳定控制.

3.2.1 在线风场预测模型

本节详细介绍上文提到的在线风场预测模型, 首先通过 K-means 算法进行数据预处理, 风的时间序列 v_{date} 对应数据点 x_i , 将其分割成 K 个簇, 每个簇的中心为 c_j , 每个簇包含相似度较高的数据点, 用式 (19) 来计算它们之间的距离.

$$d(x_i, c_j) = \sqrt{\sum_{k=1}^n (x_{i,k} - c_{j,k})^2} \quad (19)$$

其中, n 是风的数据点 x_i 的特征维度. 之后将数据点 x_i 分配到离它最近的簇中心 c_j 所属的簇.

$$\text{Cluster}(x_i) = \arg \min_j d(x_i, c_j) \quad (20)$$

而后使用 VMD 对 x_i 进行分解, 将信号分解成多个本征模态函数. 继续进行风信号镜像扩展, 对输入信号 $x(t)$ 进行周期性的镜像扩展, 从而形成镜像序列 $f(t)$:

$$f(t) = \begin{cases} x\left(t - \frac{T}{2}\right), & t \in \left[0, \frac{T}{2}\right) \\ x(t), & t \in \left[\frac{T}{2}, \frac{3T}{2}\right) \\ x\left(t + \frac{T}{2}\right), & t \in \left[\frac{3T}{2}, 2T\right) \end{cases} \quad (21)$$

其中, T 是信号的长度. 对 VMD 进行初始化, 初始化平衡参数 δ 和频谱镜像 $f_{hat plus}$:

$$\begin{cases} \delta = \delta \times 1_K \\ f_{hat plus} = fftshift(fft(f(t))) \end{cases} \quad (22)$$

其中, $fft(\cdot)$ 是快速傅里叶变换函数; $fftshift(\cdot)$ 是频谱搬移函数; 1_K 是大小为 K 的全一向量, 通过 VMD 迭代调整模态和中心的频率, 不断优化能量函数:

$$\min_{u_1, \dots, u_K} \sum_{i=1}^K \|u_i\|_1 + \delta_i \sum_{i=1}^K \frac{\|u_i\|_2^2}{2} \quad (23)$$

其中, u_i 是第 i 个模态; δ_i 是平衡参数. 最后进行风场速度重构, 通过逆傅里叶变换将模态的频谱转换回时域, 得到每个模态对应的风场速度信号:

$$u_i(t) = \text{Re}(ifft(fftshift(\hat{u}_i(t)))) \quad (24)$$

其中, $ifft(\cdot)$ 是快速逆傅里叶变换函数; $ifftshift(\cdot)$ 是逆频谱搬移函数; $\text{Re}(\cdot)$ 表示实部; $\hat{u}_i(t)$ 表示频域中的复数频谱信号. 将 $u_i(t)$ 输入到模型池, 在模型池中通过风速信号的赫斯特指数 (Hurst exponent, HURST) 来选择模型. 由于连续风速具有强烈的连贯性, 因此通过时间序列的 R/S 分析法^[39] 计算出 $\text{HURST} = 0.9$. 当 HURST 指数小于 0.9 时, 将 $u_i(t)$ 输入到 TCN-GRU 模型中, 表示为 $X = \{x_1, x_2, \dots, x_{\text{seq_len}}\}$, seq_len 代表输入的序列长度, 通过 TCN 捕捉风长速度时间序列的长期依赖关系, 输出 $H = \{h_1, h_2, \dots, h_{\text{seq_len}}\}$, 训练公式如下:

$$h_t = \Gamma(W_k \times x_{t-k} + b_k) \quad (25)$$

其中, W_k 是卷积核, 数量为 10, 且卷积核大小为 2; b_k 是偏差; Γ 是激活函数. 卷积操作通过训练得到短期依赖关系, 包含隐藏单元数量为 32, 而后返回一个时间步输出, 通过式 (26) 输出 g_t :

$$g_t = \text{GRU}(h_t) \quad (26)$$

g_t 是一个集合 $G = \{G_1, G_2, \dots, G_{\text{seq_len}}\}$, 该模型使用三个全连接层, 并且每层都具有 ReLU 激活函数. 这些层的输出分别为:

$$\begin{cases} FC_1 = \text{ReLU}(U_1 \times G + b_1) \\ FC_2 = \text{ReLU}(U_2 \times FC_1 + b_2) \\ FC_3 = \text{ReLU}(U_3 \times FC_2 + b_3) \end{cases} \quad (27)$$

其中, U_1 、 U_2 和 U_3 是全连接层的权重矩阵, b_1 、 b_2 和 b_3 是偏差; ReLU 表示修正线性单元激活函数, 其中每一层的神经元数量分别为 16、8、4; FC_1 、 FC_2 和 FC_3 分别表示三个全连接层的输出, 最后通过式 (28) 计算, 输出最终的风速序列结果 final_result .

$$\text{final_result} = W_{\text{out}} \times FC_3 + b_{\text{out}} \quad (28)$$

其中, W_{out} 是输出层的矩阵权重; b_{out} 是偏差.

当 HURST 指数大于 0.9 时, 表明其具有强长期相关性, 此时采用网格搜索方法优化支持向量回归 (SVR) 模型的超参数. 将 $u_i(t)$ 划分为 X 和 Y 数据集, $X = \{x_1, x_2, \dots, x_{\text{seq_len}}\}$ 是时间序列风速数据, $Y = \{y_1, y_2, \dots, y_{\text{seq_tm}}\}$ 是预测的风速数据, 其中 seq_tm 表示该序列的总时间步数, 即数据点的数量. 定义一组候选的 C 和 ψ 值, 对于每个组合执行以下步骤: 将数据集 X 和 Y 划分为训练集和测试集, 使用 X 来训练 SVR, 其中核函数使用 RBF:

$$K(x, x') = e^{\left(-\frac{\|x-x'\|^2}{2\psi^2}\right)} \quad (29)$$

其中 $K(x, x')$ 是核函数的值; x 和 x' 是输入空间中的两个样本点; $\|x - x'\|$ 是这两个样本点之间的

欧氏距离; ψ 是控制核宽度的参数, 初始设定 ψ 为 0.1. SVR 可以表述为:

$$\min_{w, b, \xi, \xi^*} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (30)$$

使得

$$\begin{cases} y_i - \langle w, \phi(x_i) \rangle - b \leq \zeta + \xi_i, & \xi_i \geq 0 \\ \langle w, \phi(x_i) \rangle + b - y_i \leq \zeta + \xi_i^*, & \xi_i^* \geq 0 \end{cases} \quad (31)$$

其中, y_i 表示第 i 个样本的真实标签 (目标值), 是回归问题中需要拟合的目标; w 是模型的权重向量, 用于定义回归超平面的方向; $\phi(x_i)$ 是将输入特征 x_i 映射到高维特征空间的函数, 通过核函数实现非线性映射; b 是模型的偏置项, 用于调整回归超平面的位置; ζ 是误差带的宽度, 表示允许的误差范围; ξ_i 和 ξ_i^* 分别是第 i 个样本的上界和下界松弛变量, 用于衡量样本点超出误差带的程度, 且均为非负值; $\langle w, \phi(x_i) \rangle$ 表示权重向量 w 与映射后的特征向量 $\phi(x_i)$ 的内积, 即模型对第 i 个样本的预测值.

通过寻找 C 和 ψ 的最优组合, 再使用 Y 来评估模型性能, 从而得到最好的模型. 最后预测新的时间点 t_{new} , 使用学习到的最优模型进行预测:

$$\hat{y}_{\text{new}} = \langle w, \phi(t_{\text{new}}) \rangle + b \quad (32)$$

从而得到最终的风速序列结果 final_result , 具体实现如算法 2 所述.

算法 2. 在线风场预测模型

输入. 风的时间序列 v_{date} , VMD 分解的模态数量 vmd_k , 输入序列长度 seq_len .

输出. 预测的风时间序列 final_result .

1) K-means 聚类 $\text{perform}_{k\text{means}} \leftarrow v_{\text{date}}$;

2) VMD 分解:

$\text{function vmd}(\text{signal}, \alpha, \text{tau}, K, DC, \text{init}, \text{tol})$

其中, signal 表示待分解的原始信号; α 表示带宽约束参数; tau 表示时间步长参数; K 表示模态数量; DC 表示直流分量标志, 若为 True, 则第一个模态为信号的直流分量 (低频基线); init 表示初始化方式; tol 表示收敛容差.

3) for $i = 1$ to vmd_k

根据 R/S 分析法计算 HURST, 得到 hurst_value ;

4) 判断 hurst_value , 选择模型

if $\text{hurst_value} > \text{threshold}$: $\text{flag} = 1$

$\text{model} = \text{function tcn_gru}()$

else: $\text{flag} = 2$

$\text{model} = \text{function svr}()$

5) 结果组合

$\text{final_result} = \text{combine}_r(\text{date}, \text{predicted}_{\text{date}})$

4 实验与结果分析

为验证 SymTAL-POP 无人机飞行控制算法在抑制大风扰动方面的有效性, 设计以下实验: 1) SymTAL 离线部分实验, 评估其在遭受大风干扰时保持姿态稳定的能力; 2) POP 在线部分实验, 对风速预测算法进行验证, 评估其在实时预测风速变化方面的准确性; 3) 整体方法实验, 定量比较 SymTAL-POP 与非线性基线方法和两种最先进的自适应飞行控制方法的轨迹跟踪误差的性能, 评估本文方法在大风中的控制能力。

4.1 实验数据

本实验的数据集由两部分组成: 离线数据和在线数据。离线数据来源于文献 [20], 涵盖无人机在 0 km/h 至 45 km/h 范围内均匀且稳定的风速条件下的性能参数, 给定输入包括无人机速度 v 、角速度 ω 和飞控系统输出的脉冲宽度调制 PWM。这些数据以 50 Hz 的频率采集, 总计 36 000 个数据点。在线数据则来源于美国南德克萨斯州近海的风能数据资源。在此选取 2014 年 1 月 1 日至 2014 年 2 月 3 日期间的数据作为训练集, 2014 年 2 月 4 日至 2014 年 2 月 11 日期间的数据则用作测试集。在此期间, 每间隔 1 h 进行一次数据采集和测试。

4.2 SymTAL 无人机控制算法的验证

本研究通过基于离线数据集的训练优化深度神经网络模型, 以学习共性基函数的特征表示。具体地, 将离线数据集划分为适应集和测试集两个部分进行模型训练与验证。SymTAL 算法通过对称网络层结构和权重共享有效减少模型参数量, 进而显著提升模型的收敛速度, 使得训练过程更为迅速且易于达到收敛状态, 从而更有效地适配训练数据。

该实验旨在验证 SymTAL 算法中对称式对抗网络层结构的稳定性。为此将算法 1 中的判别器 R 输出的联合对抗损失与 Neural-Fly (N-F) 算法的对抗损失进行比较, 结果如图 3 所示。使用交叉熵损失作为性能评估指标, 以有效衡量模型性能。

实验结果显示, SymTAL 算法在训练初期迅速收敛, 前 300 轮即达到较低损失值 1.778, 并在后续训练中持续稳定下降, 至 1000 轮时损失值为 1.772。相比之下, Neural-Fly 算法的损失在训练的第 150 至 450 轮之间波动, 范围约为 1.779 到 1.797, 后期的 750 轮损失值在 1.762 到 1.791 之间剧烈波动。综上所述, SymTAL 算法在较少的迭代次数内便能学习到有效的控制策略, 并且随着训练轮数的增加, 其性能呈现稳定提升的趋势。




图 3 对抗损失 (Loss_c)

Fig.3 Adversarial loss (Loss_c)

为验证算法使用改进 Adam 优化器后, $Q(x)a(\omega)$ 是否足够逼近真实的数值 $f(x, \omega)$, 以均方误差 (Mean squared error, MSE) 为衡量指标, 比较 SymTAL 与 Neural-Fly (N-F) 算法的 Loss_f, 结果如图 4 所示。




图 4 预测损失 (Loss_f)

Fig.4 Prediction loss (Loss_f)

在训练的起始阶段, SymTAL 与 Neural-Fly 两种算法的损失值表现出相似的趋势。对于 SymTAL 算法, 其生成器 Q 的损失值在前 200 轮训练中迅速下降, 并最终稳定在 0.485。而 Neural-Fly 算法的损失值在大约 170 轮训练后开始趋于稳定。为深入比较这两种算法, 进一步分析它们的收敛值以及完成 1 000 轮训练所需的运行时间, 结果如表 1 所示。

根据图 4 与表 1 的数据分析, 在训练前 150 轮时, SymTAL 算法的 Loss_f 的损失值迅速降低, 随

表 1 Loss_f 值分析表
Table 1 Loss_f value analysis table

	方法	收敛轮次	收敛值	运行时间 (s)
Loss_f	N-F	150	$0.863\ 8 \pm 0.044$	149.2 ± 1.37
	SymTAL	160	$0.481\ 8 \pm 0.045$	116.6 ± 1.15

后下降速度逐渐放缓并趋于稳定. 在此期间, Neural-Fly 算法展现出较快的收敛速度. 然而, Neural-Fly 算法的最终收敛值为 0.863 8, 而 SymTAL 算法的收敛值则为 0.481 8, 这意味着 SymTAL 算法在收敛阶段的性能提升大约 44%. 这一结果证实改进的 Adam 优化器在训练初期采用较高学习率的策略是有效的. 随着训练轮次的增加, 学习率逐渐降低, 有效缓解了梯度消失的问题. 此外, 尽管 Neural-Fly 算法在收敛速度上领先, 但 SymTAL 算法由于采用深度学习方法, 在训练时间上的表现更出色, 其速度比 Neural-Fly 算法快 21.8%. 综合各项指标, 改进后的 Adam 优化器不仅提升了 SymTAL 算法的精度, 使其预测值更接近真实值, 而且在训练效率上也实现显著增强. 这些结果共同表明, SymTAL 算法在精确度和效率两个维度上均展现出明显的优势.

为评估 SymTAL 算法中神经网络学习效果对抗损失的影响, 采用均方误差作为评价指标, 分别在不同的风速下对比平均输出损失、N-F 学习后损失以及 SymTAL 学习后损失, 如图 5 所示. 通过拟合曲线可以明显看出, 在不同的风速下, 未学习状态下的输出损失最高, 经过神经网络学习后损失均有减少. 特别值得注意的是, 在最高风速 45 km/h 的条件下, SymTAL 算法的均方误差降低至 2.8, 而 N-F 算法的均方误差为 3.2, 相比之下, SymTAL 算法比 N-F 算法均方误差降低 12.5%.




图 5 抗风算法学习损失对比

Fig.5 Comparison of learning loss of wind resistance algorithms

4.3 POP 算法的风速预测验证

在海面上, 风场受到多种外界条件的影响, 如地形、大气压力等, 导致风速呈现出连续风、湍流风和间歇风等不确定性特征. 为应对这些复杂情况, 本实验设计一个基于近海风场数据的预测模型. 该

模型通过训练集数据进行训练, 旨在预测未来 200 h 内的风速状况, 如图 6 所示. 实验结果表明, 该模型在包含多种复杂特征的海面风速场景中显示出良好的适应性和较低的预测误差. 即便风速在 70 ~ 120 h 区间内发生突变, 且伴随着不规则的气流波动, 模型仍能维持有效的预测性能.




图 6 风速预测结果

Fig.6 Wind speed prediction results

为精确评估算法在风速预测方面的准确性, 本研究针对连续风、湍流风和间歇风这三种不同的风速模式进行预测分析. 在评估风速预测精度时, 采用结合信号分解和深度学习技术的方法^[40-43], 这一方法通过一系列误差度量指标对不同算法进行定量评估. 具体的数据和分析结果见表 2, 这些数据为 POP 模型在不同风速条件下的预测性能提供科学的量化依据.

平均值 (Mean) 是描述数据集中心趋势的一种常用方法, 而低平均值表示预测结果能较好地捕捉风速变化规律, 从整体看 POP 算法的平均值低于其他预测模型的平均值. 均方误差 (MSE) 通过平方误差确保预测误差的重要性, 其中较低的 MSE 值意味着预测值与真实值之间的平均差异较小. POP 算法在风速预测中展现出的低 MSE 平均值 (0.051 9) 表明其具有较高的预测精度, 且优于其他算法. 平均绝对误差 (Mean absolute error, MAE) 衡量预测值与真实值之间绝对差的平均值, 反映预测值与真实值的接近程度. POP 算法的 MAE 平均值 (0.175 2) 不仅是所有算法中最低的, 而且与 VMD-LSTM 算法相比, 有 24% 的显著提升, 这进一步验证了其预测结果的稳定性. 均方根误差 (Root mean square error, RMSE) 是误差平方的平均值的平方根, 提供对风速预测误差的一种直观度量. POP 算法的 RMSE 平均值 (0.219 4) 显著低于其他模型, 表明预测结果偏差更小, 进一步证实了其精准的预测能力. 标准差 (Standard deviation, SD) 是衡量

预测值变异程度的关键指标, 低的标准差说明预测结果稳定. POP 算法在 MAE 和 RMSE 上的低标准差进一步证实了其结果的稳定性和可靠性. 平均绝对百分比误差 (Mean absolute percentage error, MAPE) 是预测值与真实值之间的平均相对偏差. 尽管 VMD-LSTM 算法在 Mean 上表现最佳, 但 POP 算法在标准差上提升 41.6%, 表明其在预测精度相当的情况下, 具有更高的稳定性. 最大绝对误差 (Maximum absolute error, MAXE) 反映在最坏情况下的预测误差, POP 算法的 MAXE 平均值 (0.610 6) 表明即使在极端情况下, 预测误差也能得到有效控制. 平均相对误差 (Absolute relative error, ARE), 即平均绝对误差与真实值的比率, 衡量预测误差占真实值的比例, 体现模型的相对准确度. POP 算法在 ARE 上的表现虽然较 VMD-TCN-LSTM 有所提高, 但仍在可接受范围内, 证明了其

对风速变化快速响应的能力.

综上所述, POP 算法在风速预测上的表现通过各项性能指标得到全面验证. 其不仅在 Mean 上表现优异, 而且在误差波动和极端误差控制方面也展现了出色的性能, 这充分证明了 POP 算法在风速预测领域的优越性和稳健性.

间歇风是指风速在间歇性的增减, 即风速会突然增加然后又突然减小, 风速变化剧烈且频繁. 湍流风是指风速和风向在空间和时间上均呈现不规则的变动, 风速变化随机且无规律. 表 3 展示 POP 算法与其他对比算法在间歇风场中的风速预测结果. 表 4 展示 POP 算法与其他对比算法在湍流风场中的风速预测结果. 通过观察表 3 和表 4, 在极端风速条件下, POP 算法相比其他算法具有更高的预测精度. 在湍流风场中, 由于风速会突然降至接近零的情况, 导致 MAPE 和 ARE 的计算式分母为零, 因

表 2 连续风场算法性能比较
Table 2 Performance comparison of continuous wind field algorithms

评估指标		CNN-LSTM ^[40]	VMD-AM-LSTM	VMD-CNN ^[41]	VMD-CNN-LSTM ^[42]	VMD-GRU ^[43]	VMD-LSTM	VMD-TCN-LSTM	POP
MSE	Mean	0.065 3	0.065 4	0.059 6	0.061 8	0.062 5	0.054 5	0.061 6	0.051 9
	SD	0.049 0	0.049 0	0.040 0	0.042 0	0.046 0	0.039 0	0.039 0	0.028 0
MAE	Mean	0.199 9	0.200 0	0.191 4	0.195 5	0.195 4	0.182 7	0.195 4	0.175 2
	SD	0.080 1	0.080 4	0.069 4	0.072 7	0.076 2	0.067 3	0.067 9	0.050 8
RMSE	Mean	0.243 4	0.243 5	0.234 6	0.238 4	0.238 8	0.224 3	0.239 1	0.219 4
	SD	0.078 0	0.078 0	0.067 0	0.070 0	0.074 0	0.065 0	0.066 0	0.050 0
MAPE	Mean	66.937 3	66.192 4	61.298 0	61.047 5	63.094 2	51.917 7	65.228 5	56.036 8
	SD	23.014 0	22.006 0	17.574 0	17.063 0	19.845 0	15.665 0	19.310 0	9.155 0
MAXE	Mean	0.649 1	0.641 6	0.642 1	0.644 4	0.641 3	0.641 8	0.648 1	0.610 6
	SD	0.112 0	0.110 0	0.110 0	0.109 0	0.109 0	0.109 0	0.105 1	0.096 0
ARE	Mean	0.616 3	0.644 1	0.649 1	0.555 8	0.633 0	0.634 0	0.611 6	0.540 6
	SD	0.181 0	0.202 0	0.211 0	0.085 0	0.202 0	0.205 0	0.154 0	0.078 0

表 3 间歇风场算法性能比较
Table 3 Performance comparison of intermittent wind field algorithms

评估指标		CNN-LSTM ^[40]	VMD-AM-LSTM	VMD-CNN ^[41]	VMD-CNN-LSTM ^[42]	VMD-GRU ^[43]	VMD-LSTM	VMD-TCN-LSTM	POP
MSE	Mean	0.048 2	0.051 4	0.052 1	0.046 5	0.053 0	0.049 7	0.051 4	0.044 9
	SD	0.022 0	0.027 0	0.034 0	0.018 0	0.023 0	0.023 0	0.018 0	0.014 0
MAE	Mean	0.175 6	0.172 3	0.174 7	0.171 2	0.174 8	0.170 3	0.170 3	0.157 4
	SD	0.046 1	0.053 1	0.056 9	0.043 6	0.044 8	0.044 8	0.037 5	0.023 9
RMSE	Mean	0.224 2	0.218 5	0.221 6	0.219 1	0.225 6	0.215 4	0.223 1	0.194 4
	SD	0.047 0	0.050 0	0.054 0	0.044 0	0.045 0	0.045 0	0.041 0	0.015 0
MAPE	Mean	66.310 8	73.116 7	72.469 7	68.695 6	64.579 8	72.091 8	59.104 4	58.541 8
	SD	25.331 0	32.797 0	33.599 0	26.133 0	24.647 0	30.289 0	14.528 0	12.135 0
MAXE	Mean	0.715 6	0.684 3	0.692 6	0.703 2	0.735 5	0.703 9	0.753 7	0.688 2
	SD	0.113 0	0.097 0	0.106 0	0.107 0	0.108 0	0.104 0	0.101 4	0.063 0
ARE	Mean	0.684 3	0.731 2	0.734 3	0.687 0	0.674 4	0.720 9	0.591 0	0.585 4
	SD	0.262 0	0.328 0	0.348 0	0.261 0	0.255 0	0.303 0	0.145 2	0.121 0

表 4 湍流风场算法性能比较
Table 4 Performance comparison of turbulent wind field algorithms

评估指标		CNN-LSTM ^[40]	VMD-AM-LSTM	VMD-CNN ^[41]	VMD-CNN-LSTM ^[42]	VMD-GRU ^[43]	VMD-LSTM	VMD-TCN-LSTM	POP
MSE	Mean	0.2799	0.2974	0.2760	0.2741	0.2943	0.2966	0.2966	0.2494
	SD	0.0950	0.0720	0.0740	0.0820	0.0720	0.0770	0.0770	0.0690
MAE	Mean	0.3963	0.4064	0.4072	0.3965	0.4083	0.4117	0.4038	0.3482
	SD	0.0605	0.0581	0.0611	0.0618	0.0616	0.0622	0.0631	0.0125
RMSE	Mean	0.5215	0.5283	0.5334	0.5085	0.5346	0.5337	0.5337	0.4742
	SD	0.0890	0.0670	0.0720	0.0780	0.0720	0.0730	0.0680	0.0460
MAPE	Mean	—	—	—	—	—	—	—	—
	SD	—	—	—	—	—	—	—	—
MAXE	Mean	0.8268	0.8610	0.8482	0.8261	0.8760	0.8774	0.8700	0.7614
	SD	0.1420	0.1240	0.1310	0.1440	0.1230	0.1300	0.1080	0.0710
ARE	Mean	—	—	—	—	—	—	—	—
	SD	—	—	—	—	—	—	—	—

此这两种误差评估指标在这种情况下不适用, 并未记录. 通过使用不同的风况和误差衡量指标来定量和全面地评估 POP 算法的预测准确性, 这些结果进一步验证了在线风场预测模型 POP 算法的有效性和精确性, 表明 POP 算法在复杂多变的风场环境下具有优越的预测能力.

4.4 SymTAL-POP 姿态稳定方法的验证

为验证在多变海风环境下, 整体 SymTAL-POP 姿态稳定方法的性能优势. 本研究设计一个实验, 通过量化评估不同控制算法在 0 km/h、15 km/h、30 km/h 和 45 km/h 恒定风速下的轨迹跟踪误差的性能. 实验中, 无人机飞行时间为 2 min, 完成 6 圈闭环环绕圈飞行. 本文选取非线性跟踪控制 N-T^[44]、自适应非线性预测控制 N-MPC^[45]、增量非线性动力学反演控制 INDI^[46]、L1 自适应控制 L1-A^[47] 以及本文 SymTAL-POP (S-P) 控制算法进行性能比较.

首先对各算法的轨迹跟踪误差的 RMS (Root mean square) 进行分析, 如图 7 所示. 定量结果表明, 随着风速的增加, 各种控制算法的气动幅度变化更加明显, 其性能也更易受到风速的影响. 在所有测试的控制算法中, 随着风速的增加, 气动力变化较大, 非线性 N-T 算法性能大幅下降. L1-A、N-MPC 和 INDI 在风速低于 12 km/h 时相比 N-T 有所改善, 但是在风速达到 20 km/h 时, L1-A 算法的 RMS 高达 17, 比 N-MPC 和 INDI 算法的 RMS 大, 飞行控制逐渐不稳定. 此时 S-P 算法在该风速下 RMS 仅为 4.5, 相比 N-MPC 算法提高 55.2%. 在最具挑战的 45 km/h 的风速下, S-P 算法的 RMS 仍然保持在 10 以下, 实验测得本算法的执行时间与通信延迟稳定维持在 15 ms 至 30 ms 之间. 结果




图 7 抗风算法跟踪误差

Fig. 7 Wind resistance algorithm tracking error

表明, 相较于其他算法, S-P 算法在不同风况下不仅表现出卓越的稳定性, 同时实现了快速响应.

抗风算法的平均位置误差的 Mean 值如表 5 所示. 在 15 km/h 的风速下, N-MPC、INDI 和 S-P 相比其他算法的 Mean 值较小. 当风速达到 30 km/h 时, N-MPC 和 INDI 的 Mean 值逐渐增大, 此时 S-P 算法的 Mean 值比 INDI 算法提升 15.6%. 当风速达到最大 45 km/h 时, S-P 算法的 Mean 值仍低于 10, 相较于其他算法稳定性较好. 轨迹跟踪实验结果表明, RMS 和 Mean 两个评价指标呈现出一致的趋势变化, 自适应控制算法大大优于依赖积分控制的非线性跟踪控制, 而在自适应控制算法中 SymTAL-POP 算法优于其他最佳控制算法, 性能提升 23.5%.

为便于分析, 如表 6 所示, 本文采用三个等级 (优、中、差) 来评估算法的抗风性能, 以平均值 9 cm 和 15 cm 作为区分这些等级的分界点^[48]. 在无风条件下, 除 N-T 控制算法外, 所有算法的误差都低于

表 5 抗风算法的平均位置误差 (cm)
Table 5 The average position error of
wind resistance algorithm (cm)

风速 (km/h)	N-T Mean	N-MPC Mean	INDI Mean	L1-A Mean	S-P Mean
0	10.8	4.5	6.8	4.2	2.9
15	13.6	7.6	8.1	11.1	4.1
30	22.6	11.3	10.3	21.4	8.7
45	34.7	16.7	12.6	28.6	8.9

表 6 抗风算法可控范围风速等级
Table 6 Wind resistance algorithm controllable
range wind speed level

方法	无风 (0 ~ 1 级)	微风 (2 ~ 3 级)	劲风 (4 ~ 5 级)	强风 (> 5 级)
N-T	中	差	差	中
N-MPC	优	优	中	差
INDI	优	优	中	中
L1-A	优	中	差	差
S-P	优	优	优	中

9 cm, 因此被评定为优等级. 然而, 随着风速增加到微风级别, N-T 算法的误差增加到 15.4 cm, 降级为差等级. L1-A 算法的性能也有所下降, 误差达到 12.1 cm, 被评定为中等级. 尽管风速增加, 但其他算法的误差依然保持在 9 cm 以下, 显示出良好的控制能力. 当风速进一步增加到劲风水平时, 除本研究提出的 S-P 算法外, 其他算法的控制性能均有所下降. L1-A 算法的误差上升至 22.7 cm, 评级为差等级; N-MPC 和 INDI 算法的误差分别为 11.6 cm 和 10.9 cm, 评级为中等级. 在强风条件下, 所有算法的误差都超过 10 cm, 性能都降至中等水平以下. 但是, S-P 算法相比 INDI 算法误差低 23.6%, 这进一步验证了本文算法在飞行控制方面的显著优势.

4.5 最佳高度区域选择

本文引入轨迹跟踪误差作为阈值. 一旦飞行误差超过阈值, 则需调整飞行高度确保在稳定可控的风场下正常执行任务. 基于旋翼无人机的最大上升速率特性, 本研究将阈值设定为 5 m. 根据海拔高度对风速的影响, 使用风速随高度变化的关系进行计算^[49]:

$$V(z) = V_0 \left(\frac{z}{z_0} \right)^\lambda \quad (33)$$

其中, $V(z)$ 是高度 z 处的风速; V_0 是参考高度 z_0 处的风速; z 是观测的高度; λ 是幂指数, 描述风速随高度变化的速率. 已知 $\lambda = 0.18$ m, 并且通过在线

风场数据计算得出参考高度 $z_0 = 50$ m 处的平均风速 $V_0 = 8.23$ m/s. 不同海拔高度的风速如表 7 所示. 结合第 4.4 节实验中轨迹跟踪误差值与风速信息, 得出结论: 当飞行高度超过 60 m 时, 无人机无法稳定执行任务. 为确保稳定性, 必须降低飞行高度. 当飞行高度低于 60 m 且该高度的风速不超过 8.50 m/s 时, 无人机无需进行高度调整.

表 7 高度与风速的关系
Table 7 Relationship between height and wind speed

高度 (m)	风速 (m/s)
10	6.16
20	6.97
30	7.50
50	8.23
60	8.50
70	8.74
80	8.95
90	9.14
100	9.32
110	9.48
120	9.63

5 结束语

本文介绍了一种具有抗风特性的域对抗自适应飞行控制方法 SymTAL-POP, 结合离线对称式时序域对抗学习算法与在线风场预测技术, 提升无人机在海上复杂风况中的稳定性和适应性.

论文的主要贡献包括:

- 1) 提出无人机飞行控制方法 SymTAL-POP, 其中包括离线域对抗自适应学习和在线风场预测两个关键部分, 旨在增强无人机在复杂海风环境中的稳定性和抗风性能;
- 2) 设计离线 SymTAL 算法, 结合域对抗学习、对称网络和双向时序网络, 以提取气动共享特征并提升模型的学习能力;
- 3) 设计在线风场预测模型 POP, 使用变分模态分解技术处理风场速度信号, 并根据风信号特性选择模型池中的 TCN-GRU 或 SVR 进行风速预测;
- 4) 通过实验验证, SymTAL-POP 算法较其他算法在闭环轨迹跟踪误差性能上有更好的表现.

未来将继续优化该方法, 重点研究变风速和变风向条件下如何实现旋翼无人机的姿态稳定控制, 并将该方法应用到实际无人机系统中.

References

- 1 Yang T T, Jiang Z, Sun R J, Cheng N, Feng H L. Maritime

- search and rescue based on group mobile computing for unmanned aerial vehicles and unmanned surface vehicles. *IEEE Transactions on Industrial Informatics*, 2020, **16**(12): 7700–7708
- 2 Zhang Y F, Lyu J B, Fu L Q. Energy-efficient trajectory design for UAV-aided maritime data collection in wind. *IEEE Transactions on Wireless Communications*, 2022, **21**(12): 10871–10886
 - 3 Li J Q, Zhang G Q, Jiang C Y, Zhang W D. A survey of maritime unmanned search system: Theory, applications and future directions. *Ocean Engineering*, 2023, **285**: Article No. 115359
 - 4 Lee J, Ryu S, Kim H J. Stable flight of a flapping wing micro air vehicle under wind disturbance. *IEEE Robotics and Automation Letters*, 2020, **5**(4): 5685–5692
 - 5 Sorbelli F B, Corò F, Das S K, Pinotti C M. Energy-constrained delivery of goods with drones under varying wind conditions. *IEEE Transactions on Intelligent Transportation Systems*, 2021, **22**(9): 6048–6060
 - 6 Zhu H, Nie H, Zhang L M, Wei X H, Zhang M. Design and assessment of octocopter drones with improved aerodynamic efficiency and performance. *Aerospace Science and Technology*, 2020, **106**: Article No. 106206
 - 7 Zuo Z Y, Liu C J, Han Q L, Song J W. Unmanned aerial vehicles: Control methods and future challenges. *IEEE/CAA Journal of Automatica Sinica*, 2022, **9**(4): 601–614
 - 8 Hong D, Lee S, Cho Y H, Baek D, Kim J, Chang N. Energy-efficient online path planning of multiple drones using reinforcement learning. *IEEE Transactions on Vehicular Technology*, 2021, **70**(10): 9725–9740
 - 9 Wang Shi-Zhang, Xian Bin, Yang Sen. Anti-swing controller design for an unmanned aerial vehicle with a slung-load. *Acta Automatica Sinica*, 2018, **44**(10): 1771–1780
(王诗章, 鲜斌, 杨森. 无人机吊挂飞行系统的减摆控制设计. 自动化学报, 2018, **44**(10): 1771–1780)
 - 10 Li Fan-Biao, Yang Hao-Yue, Wang Hong-Xin, Yang Chun-Hua, Liao Li-Qing. Model predictive control of aircraft braking system under asymmetric motion based on disturbance estimation. *Acta Automatica Sinica*, 2022, **48**(7): 1690–1703
(李繁彪, 杨皓月, 王鸿鑫, 阳春华, 廖力清. 基于干扰估计的非对称运动下飞机刹车系统模型预测控制. 自动化学报, 2022, **48**(7): 1690–1703)
 - 11 Li Xiang-Yang, Ai Wei, Tian Sen-Ping. Active disturbance rejection control of cascade inertia systems. *Acta Automatica Sinica*, 2018, **44**(3): 562–568
(李向阳, 袁薇, 田森平. 惯性串联系统的自抗扰控制. 自动化学报, 2018, **44**(3): 562–568)
 - 12 Sziroczak D, Rohacs D, Rohacs J. Review of using small UAV based meteorological measurements for road weather management. *Progress in Aerospace Sciences*, 2022, **134**: Article No. 100859
 - 13 Xue J, Liu Z N, Liu G J, Zhou Z Y, Zhang K W, Tang Y, et al. Robust wind-resistant hovering control of quadrotor UAVs using deep reinforcement learning. *IEEE Transactions on Intelligent Vehicles*, DOI: 10.1109/TIV.2023.3324687
 - 14 Song Y L, Scaramuzza D. Policy search for model predictive control with application to agile drone flight. *IEEE Transactions on Robotics*, 2022, **38**(4): 2114–2130
 - 15 Yan Y X, Chen X J, Shi M W, Li R. A decision support system architecture for intelligent driven unmanned aerial vehicles maritime search and rescue. In: Proceedings of the 10th International Symposium on System Security, Safety, and Reliability (ISSSR). Xiamen, China: IEEE, 2024. 424–428
 - 16 Zha W T, Liu J, Li Y L, Liang Y Y. Ultra-short-term power forecast method for the wind farm based on feature selection and temporal convolution network. *ISA Transactions*, 2022, **129**: 405–414
 - 17 Tagliabue A, Paris A, Kim S, Kubicek R, Bergbreiter S, How J P. Touch the wind: Simultaneous airflow, drag and interaction sensing on a multirotor. In: Proceedings of 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems. Las Vegas, USA: IEEE, 2020. 1645–1652
 - 18 Bisheban M, Lee T. Geometric adaptive control with neural networks for a quadrotor in wind fields. *IEEE Transactions on Control Systems Technology*, 2021, **29**(4): 1533–1548
 - 19 Shi G Y, Hönig W, Shi X C, Yue Y S, Chung S J. Neural-swarm2: Planning and control of heterogeneous multirotor swarms using learned interactions. *IEEE Transactions on Robotics*, 2022, **38**(2): 1063–1079
 - 20 O'Connell M, Shi G Y, Shi X C, Azizzadenesheli K, Anandkumar A, Yue Y S, et al. Neural fly enables rapid learning for agile flight in strong winds. *Science Robotics*, 2022, **7**(66): Article No. eabm6597
 - 21 Sun Q X, Liu Y, Yang H L, Jiang Z H, Luan Z Z, Qian D P. Adaptive auto-tuning framework for global exploration of stencil optimization on GPUs. *IEEE Transactions on Parallel and Distributed Systems*, 2024, **35**(1): 20–33
 - 22 Kim B, Chung K, Lee J, Seo J, Koo M W. A Bi-LSTM memory network for end-to-end goal-oriented dialog learning. *Computer Speech & Language*, 2019, **53**: 217–230
 - 23 Ma C X, Dai G W, Zhou J B. Short-term traffic flow prediction for urban road sections based on time series analysis and LSTM_BILSTM method. *IEEE Transactions on Intelligent Transportation Systems*, 2022, **23**(6): 5615–5624
 - 24 Guo K, Wang N, Liu D T, Peng X Y. Uncertainty-aware LSTM based dynamic flight fault detection for UAV actuator. *IEEE Transactions on Instrumentation and Measurement*, 2023, **72**: Article No. 3502113
 - 25 Samadianfard S, Hashemi S, Kargar K, Izadyar M, Mostafaeipour A, Mosavi A, et al. Wind speed prediction using a hybrid model of the multi-layer perceptron and whale optimization algorithm. *Energy Reports*, 2020, **6**: 1147–1159
 - 26 Dhakal R, Yosfovand M, Prasai S, Sedai A, Pol S, Parameswaran S, et al. Deep learning model with probability density function and feature engineering for short term wind speed prediction. In: Proceedings of 2022 North American Power Symposium (NAPS). Salt Lake City, USA: IEEE, 2022. 1–6
 - 27 Filippini F, Lattuada M, Ciavotta M, Jahani A, Ardagna D, Amaldi E. A path relinking method for the joint online scheduling and capacity allocation of DL training workloads in GPU as a service systems. *IEEE Transactions on Services Computing*, 2023, **16**(3): 1630–1646
 - 28 You Y, Li J, Reddi S, Hseu J, Kumar S, Bhojanapalli S, et al. Large batch optimization for deep learning: Training BERT in 76 minutes. In: Proceedings of the 8th International Conference on Learning Representations. Addis Ababa, Ethiopia: ICLR, 2020. 1–38
 - 29 Kingma D P, Ba J. Adam: A method for stochastic optimization. arXiv: 1412.6980, 2014.
 - 30 Liu Y H, Wang H L, Fan J X, Wu J F, Wu T C. Control-oriented UAV highly feasible trajectory planning: A deep learning method. *Aerospace Science and Technology*, 2021, **110**: Article No. 106435
 - 31 Ma T, Zhou H B, Qian B, Fu A Y. A large-scale clustering and 3D trajectory optimization approach for UAV swarms. *Science China Information Sciences*, 2021, **64**: Article No. 140306
 - 32 Lv L L, Wu Z Y, Zhang J H, Zhang L, Tan Z Y, Tian Z H. A VMD and LSTM based hybrid model of load forecasting for power grid security. *IEEE Transactions on Industrial Informatics*, 2022, **18**(9): 6474–6482
 - 33 Dudukcu H V, Taskiran M, Taskiran Z, Yildirim T. Temporal convolutional networks with RNN approach for chaotic time series prediction. *Applied Soft Computing*, 2023, **133**: Article No. 109945

- 34 Zhang K F, Cao H, Thé J, Yu H S. A hybrid model for multi-step coal price forecasting using decomposition technique and deep learning algorithms. *Applied Energy*, 2022, **306**: Article No. 118011
- 35 Zhang W, Jiang Y Y, Dong J Y, Song X J, Pang R B, Guoan B, et al. A deep learning method for real-time bias correction of wind field forecasts in the western North Pacific. *Atmospheric Research*, 2023, **284**: Article No. 106586
- 36 Bai S J, Kolter J Z, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. arXiv preprint arXiv: 1803.01271, 2018.
- 37 Sikkil L, de Croon G, de Wagter C, Chu Q P. A novel online model-based wind estimation approach for quadrotor micro air vehicles using low cost MEMS IMUs. In: Proceedings of 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Daejeon, Korea (South): IEEE, 2016. 2141–2146
- 38 Ganin Y, Ustinova E, Ajakan H, Germain P, Larochelle H, Laviolette F, et al. Domain-adversarial training of neural networks. *Journal of Machine Learning Research*, 2017, **17**(1): 2096–2030
- 39 Mandelbrot B B, Wallis J R. Robustness of the rescaled range R/S in the measurement of noncyclic long run statistical dependence. *Water Resources Research*, 1969, **5**(5): 967–988
- 40 Lu C X, Wang Z, Wu Z L, Zheng Y X, Liu Y X. Global ocean wind speed retrieval from GNSS reflectometry using CNN-LSTM network. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, **61**: Article No. 5801112
- 41 He N, Yang Z Q, Qian C. A lithium-ion battery RUL prediction method based on improved variational modal decomposition and integrated depth model. In: Proceedings of the 35th Chinese Control and Decision Conference. Yichang, China: IEEE, 2023. 1268–1273
- 42 Tao J J, Zhou J, Tao Y Q, Zhang H L, Jiang X, Hu Y Q. Time series updating forecasting method of energy consumption based on VMD-LSTM. In: Proceedings of 2021 IEEE Conference on Energy Internet and Energy System Integration (EI2). Taiyuan, China: IEEE, 2021. 3604–3609
- 43 Wang K, Zhang H R, Wang X Y, Li Q Q. Prediction method of transformer top oil temperature based on VMD and GRU neural network. In: Proceedings of 2020 IEEE International Conference on High Voltage Engineering and Application (ICHVE). Beijing, China: IEEE, 2020. 1–4
- 44 Gilbert E, Kolmanovsky I. Nonlinear tracking control in the presence of state and control constraints: A generalized reference governor. *Automatica*, 2002, **38**(12): 2063–2073
- 45 Kamel M, Burri M, Siegwart R. Linear vs nonlinear MPC for trajectory tracking applied to rotary wing micro aerial vehicles. *IFAC-PapersOnLine*, 2017, **50**(1): 3463–3469
- 46 Tal E, Karaman S. Accurate tracking of aggressive quadrotor trajectories using incremental nonlinear dynamic inversion and differential flatness. *IEEE Transactions on Control Systems Technology*, 2021, **29**(3): 1203–1218
- 47 Pravitra J, Ackerman K A, Cao C Y, Hovakimyan N, Theodorou E A. L1-adaptive MPPI architecture for robust and agile control of multirotors. In: Proceedings of 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems. Virtual Event: IEEE, 2020. 7661–7666
- 48 Liu Y, Li S, Chan P W, Chen D. Empirical correction ratio and scale factor to project the extreme wind speed profile for offshore wind energy exploitation. *IEEE Transactions on Sustainable Energy*, 2018, **9**(3): 1030–1040
- 49 Solano J C, Montaña T, Maldonado-Correa J, Ordóñez A, Pesantez M. Correlation between the wind speed and the elevation to evaluate the wind potential in the southern region of Ecuador. *Energy Reports*, 2021, **7**: 259–268



李凤岐 大连交通大学软件学院教授。主要研究方向为区块链, 工业物联网和智能信息系统。本文通信作者。E-mail: Fengqi-Li@outlook.com

(**LI Feng-Qi** Professor at the School of Software, Dalian Jiaotong University. His research interest covers blockchain, industrial internet of things and intelligent information systems. Corresponding author of this paper.)



金佳玉 大连交通大学软件学院硕士研究生。主要研究方向为无人机智能算法。E-mail: 15142212689@163.com

(**JIN Jia-Yu** Master student at the School of Software, Dalian Jiaotong University. Her main research interest is UAVs intelligent algorithm.)



杜学峰 大连交通大学机械工程学院博士研究生。主要研究方向为无人机智能群集, 分布式协同控制。E-mail: xuefeng.du@outlook.com

(**DU Xue-Feng** Ph.D. candidate at the School of Mechanical Engineering, Dalian Jiaotong University. His research interest covers UAVs intelligent clustering and distributed collaborative control.)



张鑫 大连交通大学软件学院硕士研究生。主要研究方向为无人机智能算法。E-mail: zx8292@outlook.com

(**ZHANG Xin** Master student at the School of Software, Dalian Jiaotong University. Her main research interest is UAVs intelligent algorithm.)



徐凤强 大连交通大学软件学院讲师。主要研究方向为区块链和计算机视觉。E-mail: xfq@djtu.edu.cn

(**XU Feng-Qiang** Lecturer at the School of Software, Dalian Jiaotong University. His research interest covers blockchain and computer vision.)



王德广 大连交通大学软件学院副教授。主要研究方向为信息安全, 机器学习。E-mail: wdg@djtu.edu.cn

(**WANG De-Guang** Associate professor at the School of Software, Dalian Jiaotong University. His research interest covers information security and machine learning.)