



基于图神经网络的四旋翼风扰观测与敏捷控制

王宝栋¹, 祝海^{2,3*}, 朱效洲^{2,3}, 贾真¹, 刘贞报^{1,4}, 姚雯^{2,3}, 陈小前^{3*}

1. 西北工业大学民航学院, 西安 710072

2. 中国人民解放军军事科学院国防科技创新研究院, 北京 100071

3. 智能博弈与决策实验室, 北京 100071

4. 西北工业大学深圳研究院, 深圳 518057

* E-mail: zhuhaili@alumni.nudt.edu.cn; chenxiaqian@nudt.edu.cn

收稿日期: 2025-04-15; 接受日期: 2025-08-11; 网络版发表日期: 2025-09-05

国家自然科学基金项目(批准号: U2433208, 52072309, 62303486)、陕西省自然科学基金基础研究计划项目(编号: 2024JC-YBQN-0521)和西北工业大学博士论文创新基金项目(编号: CX2024088)资助

摘要 在疾强风的干扰下保持灵活可靠的飞行, 是无人机抗干扰控制的主要目标之一. 传统的基于观测器的抗干扰控制方法未能有效建模疾强风对无人机运动的影响, 因而在复杂动态风扰下控制性能显著下降. 本文根据四旋翼无人机的微分平坦特性, 设计基于自适应通道提取的轻量化图神经网络作为风效应预测器, 使用无人机历史飞行轨迹构建训练数据集, 从而对无人机飞行过程中的复杂风效应进行实时预测, 并结合模型预测控制实现无人机的抗疾强风轨迹跟踪控制. 具体地, 分别在持续风、阵风、切向风等不同场景下收集无人机的仿真飞行轨迹以及期望飞行轨迹, 以二者的995650组残差作为预测模型的输入, 以150000组残差作为测试集对比风效应预测的性能, 并对使用不同预测器的抗风扰控制方法的性能进行了比较. 结果表明, 所提出风效应预测模型的预测精度优于领域先进模型14.9%, 同时基于该预测模型的风扰模型预测控制性能优于领域先进模型50.35%. 最后, 使用自主搭建的四旋翼无人机平台进行了实机飞行实验, 对无人机的抗风性能进行验证. 结果表明, 本文所提出的抗干扰控制方法在轨迹跟踪精度上获得了27.35%的性能提升.

关键词 风效应预测, 抗干扰控制, 图神经网络, 模型预测控制

1 引言

无人机(unmanned aerial vehicle, UAV)凭借其简单、高效和适应性强的设计, 在快递运输、农业养殖、能源巡检等方面得到了广泛的应用^[1,2]. 然而, 这些应用场景往往都要求无人机在复杂恶劣的环境中仍保持足够的可靠性, 甚至是保持一定程度的工作能力. 最

具代表性也最常见的复杂环境就是动态强风环境. 在强风中对无人机进行可靠和准确的飞行控制是至关重要的, 同时该课题一直是机器人领域的重要挑战之一^[3-5].

为了提高旋翼无人机在强风扰环境中的性能, 在设计控制系统时必须考虑风对无人机运动的影响. 这需要对风的影响进行高精度的建模与估计. 近年来, 神经网络凭借其处理不确定性的能力, 已逐步成为干

引用格式: 王宝栋, 祝海, 朱效洲, 等. 基于图神经网络的四旋翼风扰观测与敏捷控制. 中国科学: 技术科学, 2025, 55: 1490–1501
Wang B D, Zhu H, Zhu X Z, et al. Agile control of a quadrotor with disturbance observation based on graph neural networks (in Chinese). Sci Sin Tech, 2025, 55: 1490–1501, doi: 10.1360/SST-2025-0079

扰预测的主流方法之一。现有的基于神经网络的风扰预测方法, 通常是使用无人机历史状态数据来计算外界风力大小, 并使用这些数据训练模型, 然后根据已完成训练的模型来预测无人机即将受到的风力^[6]。首先, 这种方式忽略了无人机历史状态数据(通常包括13个状态变量)的重要固有特性——微分平坦特性^[7], 即状态变量之间存在相互依赖关系, 部分变量可由其子集推导得到。此外, 大多数基于神经网络的估计方法侧重于预测风力, 然后将其应用于无人机动力学模型。这种方式忽略了风与无人机动力学耦合效应, 导致预测结果与真实动力学模型存在偏差^[8]。

针对上述问题, 本文提出一种基于图神经网络的风效应预测模型, 并将其与模型预测控制(model predictive control, MPC)紧密融合, 以提升敏捷飞行时旋翼无人机的抗风性能。首先, 使用基于MPC控制器的旋翼无人机在仿真环境中生成敏捷飞行轨迹数据集。然后将风效应预测问题建模为时间序列预测问题, 设计了基于改进型图神经网络(graph neural network, GNN)的轻量化预测模型。该模型输入无人机历史状态序列, 隐式学习其标称动力学特征, 并利用历史状态差异对当前状态残差进行预测。相较于多层感知机等一般预测网络, 图神经网络特有的邻接矩阵能更精准地表征无人机状态变量间的空间依赖关系。通过生成的训练数据, 模型可准确预测风扰对无人机未来运动状态的影响。最终, 将该风效应预测模型整合至MPC框架中, 实现动态强风环境下的无人机高精度轨迹跟踪控制。仿真和实验表明, 融合风效应预测模型与MPC框架可将无人机轨迹跟踪偏差控制在厘米级, 即使在强风环境下沿复杂轨迹飞行, 无人机仍能保持高精度轨迹跟踪。

本文的主要创新点总结如下: (1) 将强风对无人机的影响建模为可被神经网络高精度预测的残差动力学; (2) 提出一种基于改进型图神经网络的风效应预测模型, 该模型能够预测多种风况下无人机未来的状态偏移; (3) 通过将风效应预测模型融合到MPC框架中, 提升了无人机在疾强风环境下的抗干扰控制能力。

2 相关工作

2.1 抗风控制

近年来, 机器人领域出现了大量无人机抗风抗控

制的相关研究。典型的方法包括基于滑模控制的方法^[9]、基于反步法^[10]、基于几何控制的方法^[11]和自适应控制^[6]。其中, 文献^[9]选择非奇异终端滑模控制作为基准, 结合自适应阻力系数产生补偿控制信号, 以抵消模型的不确定性和风估计误差。滑模控制虽具有对有界扰动的固有鲁棒性, 但存在严重的抖振现象, 且高频切换可能损坏执行器, 且需要提前知道扰动界限。即使引入模糊补偿器, 在处理时变扰动和多源扰动时性能下降明显。文献^[10]采用自适应估计逼近系统模型中的未知参数, 并设计抗干扰环节抵消外部环境的负面影响, 补偿了无人机旋翼的控制输入, 提高了无人机轨迹跟踪的精度和稳定性。自适应控制能够调整参数以适应变化的工况, 但其参数收敛需要持续激励条件, 在某些场景下无法保证收敛性。更重要的是, 适应过程中的计算复杂度随适应机制增加而显著提升。文献^[11]利用多层神经网络对几何自适应控制进行扩充, 并根据自适应律在线调整神经网络的权值。同时也出现了基于学习方法进行抗风扰的技术路线, 如深度强化学习^[12-14]。通过强化学习框架^[15]驱动的无人机策略优化, 以马尔可夫决策过程为理论基础, 将长期累积奖励函数最大化作为优化目标, 从而有效规避短视决策行为。文献^[16]提出了一种风险敏感的“演员”-“评论家”架构, 该方法在文献^[17]的深度强化学习框架基础上进行扩展, 通过集成并行深度Q网络^[18]实现风险策略分化, 其中风险规避型“演员”与风险寻求型“评论家”通过双流网络结构协同优化策略。然而, 现有方法在处理安全关键型状态约束时, 其基于惩罚函数的约束处理机制难以同时满足动态控制系统的硬约束条件与李雅普诺夫稳定性要求, 尤其在状态空间存在非凸约束区域时, 这常常导致策略收敛于次优解。相比之下, 模型预测控制采用滚动时域优化, 通过在有限时域内在线求解带约束的优化问题, 将硬约束直接嵌入优化模型, 并借助反馈校正机制确保动态约束可行, 具有更强的灵活性和最优性。传统MPC在处理风扰时存在扰动建模的限制, 多数MPC实现将风扰简化为加性白噪声或有界常值扰动, 这忽略了风效应的时空相关性。同时传统方法无法预测未来时刻的风效应演化, 只能被动响应。另外, 强风条件下的非线性气动效应使线性MPC模型失效, 风扰改变了系统的有效参数(如阻力系数), 固定模型的MPC无法适应这种变化。标准MPC的预测基于标称模型, 无法利用实时风扰信息更

新预测, 未能有效利用历史风扰数据改进未来预测. 这些局限性凸显了将数据驱动的风效应预测模型与MPC深度融合的必要性. 本文通过引入基于图神经网络的风效应预测器, 实现了对风效应的前瞻性建模和主动补偿, 给出一种能够提升被动响应特性的方案.

2.2 风效应预测

本文提出的方法将无人机在复杂强风环境中的飞行控制分为风效应预测和基于预测的控制两部分. 该解耦式控制理念与文献[8,19,20]中的扰动-控制分离架构形成理论呼应; 区别在于这些研究只预测了轻微的气动干扰, 而没有考虑真实风况. 近年来, 预测气动干扰已成为抗干扰研究的一个关键焦点. 风效应预测的早期工作通常是基于模型的, 如非线性干扰观测器^[21], 其通过基于频率的增益设计和将阵风与不确定性及其他干扰隔离, 来对影响无人机的阵风进行建模. 后来出现了采用数据驱动的方法, 如基于高斯过程的MPC^[20]方法中采用高斯过程对风扰进行建模与预测. 该模型随后被推广并适用于建模轻微气动干扰, 如桨涡干扰和地面效应干扰等, 而未考虑风对无人机运动轨迹的影响^[8].

尽管目前在风对无人机的影响建模问题上缺乏足够的研究, 但风力发电预测的相关研究已经产生了较多的可借鉴成果. 在预测问题中, 领域先进方法大多都是基于学习的方案. 其中一些包括径向基神经网络^[22]、基于多层感知机(multi-layer perceptron, MLP)的网络^[23]、基于长短期记忆的网络^[24~28]、基于GNN的模型^[29~32]、基于编码器-解码器的模型^[33]、基于Transformer的模型^[34~36]等, 这些模型可离线准确预测风效应, 但多难以在线实时运行. 实时神经网络(real-time neural, RTN)^[8]可以在线预测气动力影响, 但其预测性能无法与上述离线方法相比.

风对无人机的影响可直接由其13个状态量反映. 这些状态量存在微分平坦特性, 即状态量之间存在相互依赖关系, 部分变量可由子集推导得到. 这些关系在时间和空间维度上都存在. 传统的神经网络(如MLP网络)没有明确地对这些变量间的相互依赖性进行建模, 导致预测精度降低. GNN可利用邻接矩阵来有效地捕获固有的依赖关系, 从而能够显著改善变量之间复杂关系的建模. 得益于GNN在复杂系统建模领域展现出的显著优势, 其已成功应用于风力发电预测^[25]和交通流分析^[26]等场景, 本研究在文献[8]的基础上提出

改进型GNN, 通过自适应关系提取机制提升预测精度. 具体而言, 首先建立无人机动态残差的风况预测模型, 继而将预测结果融入控制器架构设计, 最终实现抗风性能的优化提升.

3 风效应预测模型与轨迹跟踪控制

3.1 动力学模型

本文将四旋翼无人机建模为一个具有6个自由度的刚体, 其质量定义为 m , 惯性特性为对角惯性矩阵 $\mathbf{J} = \text{diag}(\mathbf{J}_x, \mathbf{J}_y, \mathbf{J}_z)$, 各个旋翼推力为 $\mathbf{T}_i$, $i \in [0, 3]$, 控制输入用 $\mathbf{u} = [\mathbf{T}_0, \mathbf{T}_1, \mathbf{T}_2, \mathbf{T}_3]^T \in \mathbb{R}^4$ 表示. 四旋翼动力学可由下式表达:

$$\dot{\mathbf{x}} = \begin{bmatrix} \dot{\mathbf{p}}_w \\ \dot{\mathbf{q}}_{WB} \\ \dot{\mathbf{v}}_w \\ \dot{\boldsymbol{\omega}}_B \end{bmatrix} = f_{\text{dyn}}(\mathbf{x}, \mathbf{u}) = \begin{bmatrix} \mathbf{v}_w \\ \mathbf{q}_{WB} \begin{bmatrix} 0 \\ \frac{\boldsymbol{\omega}_B}{2} \end{bmatrix} \\ \frac{1}{m} \mathbf{q}_{WB} \odot \mathbf{T}_B + \mathbf{g}_w \\ \mathbf{J}^{-1}(\tau_B - \boldsymbol{\omega}_B \times \mathbf{J} \boldsymbol{\omega}_B) \end{bmatrix}, \quad (1)$$

其中, $\mathbf{p}_w \in \mathbb{R}^3$ 表示四旋翼质心在世界坐标系下的位置向量, $\mathbf{q}_{WB} \in \mathbb{H}$ 表示从机体坐标系到世界坐标系的单位四元数, $\mathbb{H}$ 表示四元数集(quaternion), $\mathbf{v}_w \in \mathbb{R}^3$ 表示四旋翼在世界坐标系下的速度向量, $\boldsymbol{\omega}_B \in \mathbb{R}^3$ 表示四旋翼在机体坐标系下的角速度向量, m 为四旋翼总质量, 引力矢量 $\mathbf{g}_w = [0, 0, -9.8]^T \text{ m/s}^2$ 表示地球引力, 变量 D , $\mathbf{T}_B = \left[0, 0, \sum_{i=0}^3 \mathbf{T}_i\right]^T$ 和 $\tau_B \in \mathbb{R}^3$ 分别表示状态空间维数、集总推力和集总力矩, $\odot$ 表示四元数对向量的旋转操作, $\times$ 表示向量叉乘. 本文通过四阶显式龙格-库塔法获得离散动力学模型, 其结果如式(2)所示:

$$\begin{aligned} \mathbf{x}_{k+1} &= f_{\text{RK4}}(\mathbf{x}_k, \mathbf{u}_k, \delta t) \\ &= \mathbf{x}_k + \frac{\delta t}{6}(\mathbf{k}_1 + 2\mathbf{k}_2 + 2\mathbf{k}_3 + \mathbf{k}_4), \\ \mathbf{k}_1 &= f_{\text{dyn}}(\mathbf{x}_k, \mathbf{u}_k), \\ \mathbf{k}_2 &= f_{\text{dyn}}\left(\mathbf{x}_k + \frac{\delta t}{2}\mathbf{k}_1, \mathbf{u}_k\right), \\ \mathbf{k}_3 &= f_{\text{dyn}}\left(\mathbf{x}_k + \frac{\delta t}{2}\mathbf{k}_2, \mathbf{u}_k\right), \\ \mathbf{k}_4 &= f_{\text{dyn}}(\mathbf{x}_k + \delta t \mathbf{k}_3, \mathbf{u}_k), \end{aligned} \quad (2)$$

其中, $\mathbf{x}_k = [\mathbf{p}_W, \mathbf{q}_{WB}, \mathbf{v}_W, \boldsymbol{\omega}_B] \in \mathbb{R}^{13}$ 为初始状态, $\mathbf{u}_k \in \mathbb{R}^4$ 为控制输入, δt 是积分步长.

3.2 风效应动力学

在无风情况下, 无人机的动力学(1)可以在离散化之后由式(3)表示:

$$\mathbf{x}_{k+1} = f_{\text{RK4}}(\mathbf{x}_k, \mathbf{u}_k, \delta t) = f_{\text{nominal}}(\mathbf{x}_k, \mathbf{u}_k). \quad (3)$$

当无人机受到风干扰时, 其动力学模型可以描述为如下形式:

$$\mathbf{x}_{k+1} = f_{\text{cor}}(\mathbf{x}, \mathbf{u}) = f_{\text{dyn}}(\mathbf{x}, \mathbf{u}) + f_{\text{res}}(\mathbf{x}, \mathbf{u}), \quad (4)$$

其中 $f_{\text{res}}(\mathbf{x}, \mathbf{u})$ 为残差动力学, 表征风对四旋翼无人机的影响. 风效应可以建模为无人机状态在标称动力学基础上受风影响产生的偏移 $\Delta \mathbf{x}_{k+1}$, 如图1所示. 对式(4)进行离散化, 可得到风扰下旋翼无人机的离散动力学方程:

$$\begin{aligned} \mathbf{x}_{k+1} &= f_{\text{RK4}}(\mathbf{x}_k, \mathbf{u}_k, \delta t) = f_{\text{wind}}(\mathbf{x}_k, \mathbf{u}_k) \\ &= f_{\text{nominal}}(\mathbf{x}_k, \mathbf{u}_k) + \Delta \mathbf{x}_{k+1}. \end{aligned} \quad (5)$$

3.3 风效应预测问题构造

如式(5)所示, 采用神经网络 h_θ 作为风效应预测模型, 估计风引起的无人机状态偏移量 $\Delta \mathbf{x}_{k+1}$. 可将风效应预测问题转化为无人机状态偏移量的预测问题. 因此, 目标问题为, 找到一个用于预测状态偏移的模型 h_θ , 保证其可以给出风扰下无人机未来的状态偏移 $\Delta \mathbf{x}_{k+1}$. 模型 h_θ 是从历史状态 $\mathbf{x}_{k-t_h:k}$ 与模型预测控制器曾经给出预测状态 $\hat{\mathbf{x}}_{k-t_h:k}$ 的残差 $\mathbf{X}_{\text{in}}$, 获得的有效信息进行推理, 并对无人机的状态偏移 $\Delta \mathbf{x}_{k+1}$ 进行适当的预测, 其中 t_h 是预测范围. 因此, 风效应预测(状态偏移预测)模型 h_θ 可由下式给出:

$$\Delta \mathbf{x}_{k+1} = h_\theta(\mathbf{X}_{\text{in}}), \quad (6)$$

其中, θ 为模型参数.

3.4 风效应预测模型

本研究所提出的风效应预测模型采用双通道时空特征融合架构(如图2所示), 其核心由基于GNN的空域特征提取模块与时域特征挖掘模块构成, 二者通过特




图1 (网络版彩图)风对旋翼无人机的影响

Figure 1 (Color online) Effects of wind on UAVs.




图2 (网络版彩图)风效应预测模型

Figure 2 (Color online) Wind effect prediction model.

征张量拼接实现模态互补. 下面分别叙述各子模块的数学表征及创新机理.

3.4.1 自适应图结构空域特征提取

空域特征提取模块采用改进型GNN, 其核心创新在于构建动态可调的自适应邻接矩阵, 实现无人机多状态变量间隐式耦合关系的无监督挖掘. 传统静态邻接矩阵在无人机动力学系统建模中存在根本性缺陷, 包括内容如下. (1) 时不变性假设的局限: 经典GNN架构预设固定的节点连接关系, 这与无人机系统中状态变量耦合的时变特性相矛盾. 飞行过程中, 气动力耦合、控制耦合以及环境扰动导致的相互作用随飞行状

态动态演化, 静态图结构无法准确表征这种动态依赖关系. (2) 先验知识依赖: 静态拓扑需要领域专家显式定义状态变量间的连接模式, 不仅增加了建模复杂度, 还可能因主观偏见而遗漏关键的隐式依赖关系或引入冗余连接. (3) 多工况适应性缺失: 无人机在不同飞行模式(悬停、巡航、急转弯等)下, 状态变量间的耦合强度和模式存在显著差异. 固定的图结构无法适应这种工况相关的耦合变化.

为应对上述挑战, 本文提出基于可学习节点嵌入的自适应邻接矩阵生成机制. 图神经网络的前向传播过程表示为

$$\mathcal{H}^{(l+1)} = \sigma\left(\tilde{\mathbf{D}}^{-\frac{1}{2}}\tilde{\mathbf{A}}_{\text{ada}}\tilde{\mathbf{D}}^{-\frac{1}{2}}\mathcal{H}^{(l)}\mathbf{W}^{(l)}\right), \quad (7)$$

其中, 归一化后的度矩阵 $\tilde{\mathbf{D}}$ 为对角矩阵, 其对角元素 $\tilde{D}_{ii} = \sum_j \tilde{\mathbf{A}}_{\text{ada},ij}$ 表示节点的度, $\mathcal{H}^{(l)}$ 为第 l 层的节点特征矩阵, $\mathbf{W}^{(l)}$ 为第 l 层的权重矩阵, $\sigma(\cdot)$ 为非线性激活函数, 自适应邻接矩阵 $\tilde{\mathbf{A}}_{\text{ada}}$ 通过可学习节点嵌入字典动态生成, 具体而言:

$$\tilde{\mathbf{A}}_{\text{ada}} = \text{SoftMax}\left(\text{ReLU}\left(\mathbf{D}_p, \mathbf{D}_n^T\right)\right), \quad (8)$$

其中, $\mathbf{D}_p, \mathbf{D}_n \in \mathbb{R}^{O \times c}$ 分别为源节点与目标节点. 这种方式摒弃传统GNN依赖预定义图结构的局限性, 通过 $\mathbf{D}_p$ 与 $\mathbf{D}_n$ 的矩阵内积自动捕获状态变量间的非线性空间关联. 这种端到端的基于数据驱动的拓扑发现方式可确保获取的耦合关系将直接服务于下游预测任务. 邻接矩阵随输入数据动态调整, 能够捕获不同飞行阶段和工况下的耦合模式变化. 理论上, 该机制具有逼近任意时变图结构的表达能力. 采用ReLU激活函数对弱连接进行硬阈值滤波, 保留强相关边, 同时, 通过Soft-Max归一化确保邻接矩阵的扩散稳定性. 通过这种自适应图结构学习机制, 模型能够根据实际飞行数据自主发现最优的状态变量依赖关系, 显著提升了对无人机复杂动态系统的建模精度和泛化能力.

3.4.2 多尺度时域特征提取

时域处理模块采用深度多层感知机, 其层级化结构可有效捕获风效应信号的时序多尺度特性. 定义第 l 层变换为

$$\begin{aligned} \mathbf{z}^{(l)} &= \mathbf{W}_{\text{time}}^{(l)} \mathbf{z}^{(l-1)} + \mathbf{b}^{(l)}, \\ \text{time } \mathbf{z}^{(l)} &= f^{(l)}(\mathbf{z}^{(l)}), \end{aligned} \quad (9)$$

其中, $\text{time } \mathbf{z}^{(0)} = \mathbf{X}_{\text{out}}$ 是带有空间特征的输入向量, $\mathbf{W}^{(l)} \in \mathbb{R}^{d_l \times d_{l-1}}$ 是第 l 层的权重矩阵, $\mathbf{b}^{(l)} \in \mathbb{R}^{d_l}$ 是第 l 层的偏置向量, $f^{(l)}$ 是第 l 层的激活函数.

3.4.3 联合优化策略

时空特征向量经拼接后输入全连接回归层, 采用均方误差(MSE)与平滑正则项构成复合损失函数:

$$\mathcal{L}_{\text{MSE}} = \frac{1}{P} \sum_{p=1}^P \|\hat{\mathbf{z}}_p - \mathbf{z}_p\|^2 + \lambda \sum_{(i,j) \in \mathcal{E}} |\tilde{\mathbf{A}}_{\text{ada},ij}|, \quad (10)$$

其中, P 为训练样本总数, $\mathbf{z}_p$ 为模型对第 p 个样本的预测空间特征向量, 正则项系数 λ 控制邻接矩阵的稀疏度, 通过交叉验证设定为0.03. 采用Adam优化器进行端到端训练, 初始学习率为 10^{-4} 并配合早停策略完成训练.

3.5 模型预测控制

将连续时间系统的时间域 $[0, T]$ 上进行离散化处理, 采用 N 个等间距时间步长实现离散, 其中单个时间步长满足 $\delta t = T/N$. 在每个控制周期重新求解 N 步预测时域内的优化问题, 通过代价函数中的权重矩阵 $\mathbf{Q}$ 和 $\mathbf{R}$ 实现状态跟踪与能耗的平衡.

本文将第3.3节所述的图神经网络风效应预测模型 h_θ 直接集成到MPC的动力学约束中. 具体而言, 在传统MPC框架基础上, 我们将系统动力学模型扩展为 $\mathbf{x}_{k+1} = f_{\text{nominal}}(\mathbf{x}_k, \mathbf{u}_k) + h_\theta(\mathbf{X}_{\text{in}})$. f_{nominal} 表示四旋翼的标称动力学模型, $h_\theta(\mathbf{X}_{\text{in}})$ 为基于当前历史状态 $\mathbf{X}_{\text{in}}$ 的风效应预测输出, 代表了风扰动导致无人机跟踪轨迹时产生的状态偏移量 $\Delta \mathbf{x}_{k+1}$. 这种前馈补偿机制可以通过神经网络 h_θ 预测未来的风致状态偏移, 使MPC能够提前调整控制输入以抵消预期的风扰动影响. 作为一种统一优化框架, 可令风效应不再作为外部扰动处理, 而是作为可预测的动力学组成部分纳入优化过程, 使得控制器能够在考虑风影响的情况下提升轨迹跟踪性能. 并且在每个MPC求解周期, 仅需调用一次训练好的神经网络进行前向推理, 计算开销可控.

构建的模型预测控制(MPC)框架可表述为

$$\begin{aligned}
& \max_{\mathbf{u}} \quad \mathbf{x}_N^T \mathbf{Q} \mathbf{x}_N + \sum_{k=1}^N \mathbf{x}_k^T \mathbf{Q} \mathbf{x}_k + \mathbf{u}_k^T \mathbf{R} \mathbf{u}_k \\
& \text{subject to} \quad \mathbf{x}_{k+1} = \mathbf{f}_{\text{nominal}}(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{h}_{\theta}(\mathbf{X}_{in}), \\
& \quad \mathbf{x}_0 = \mathbf{x}_{\text{init}}, \\
& \quad \mathbf{u}_{\min} \leq \mathbf{u}_k \leq \mathbf{u}_{\max},
\end{aligned} \quad (11)$$

其中, $\mathbf{x}_0$ 表示初始状态, $\mathbf{u}_{\min}$ 和 $\mathbf{u}_{\max}$ 分别为最小和最大允许输入. 输入约束 $\mathbf{u}_{\min} \leq \mathbf{u}_k \leq \mathbf{u}_{\max}$ 直接嵌入优化问题, 确保执行机构饱和和特性不被突破. 初始状态 $\mathbf{x}_0$ 在每次迭代时更新为实际测量值, 从而实现闭环控制.

4 仿真与实验结果

4.1 实现细节

分别在仿真环境和自建测试平台下对本文所提出的风效应预测模型及抗风扰控制器进行验证. 自主搭建的四旋翼抗风实验系统包括一个由10台相机组成的运动捕捉系统(ViCON)、多台工业风扇(AUX)和一个四旋翼无人机(1.9 kg). 该无人机使用了Tmotor U3 KV700无刷电机, 由4S(120C)LiPo电池为整机供电, 由4S(75C)LiPo电池为机载计算机单独供电, 机身轴距为480 mm, 配备了直径为12英寸(304.8 mm)螺距为4英寸(101.6 mm)的碳纤维螺旋桨, 整机推重比为3.4. 无人机平台如图3所示.

该四旋翼同时搭载运行PX4的CUAV V5 nano飞行控制器和运行MAVROS的Jetson Xavier NX机载计算机. 在测试开始时, 首先使用基于离散四旋翼动力学的MPC控制器令无人机跟随设定的工作轨迹, 以收集



图3 (网络版彩图)四旋翼抗风平台

Figure 3 (Color online) Autonomous quadrotor wind-resistant testbed.

用于训练风效应预测模型的样本数据. 该预测模型在配备了Intel Core i7-13700K, Nvidia RTX 4070 Ti的地面站上训练, 并在机载计算机上进行推理预测. 仿真实验使用的四旋翼参数与真实自建实验使用的四旋翼参数完全相同.

本文采用ACADOS(高级控制与优化软件)框架对公式(11)中所构建的MPC问题进行求解, 该框架为非线性最优控制提供了高效的结构利用算法实现. 具体而言, 采用实时迭代(RTI)方案, 配合高性能内点法(high-performance interior point method, HPIPM)作为二次规划(quadratic programming, QP)求解器. 非线性规划问题通过序列二次规划(sequential quadratic programming, SQP)方法求解, 并采用高斯-牛顿法进行海森矩阵近似. 系统动力学和约束条件使用CasADi进行符号建模, 实现梯度计算的自动微分. 预测时域设定为20步, 采样时间为0.05 s, 对应的预测窗口为1 s. 该参数选择平衡了计算效率与轨迹跟踪任务所需的预测能力. 通过实验经验确定预测时域长度, 一般来讲较短的预测时域会导致跟踪性能下降, 而较长的预测时域仅带来边际改善, 却会显著增加计算负担. MPC优化问题在Intel Core i7-13700K处理器上以20 Hz频率求解, 问题构建与线性化的平均时间为1.2±0.3 ms, 通过高性能内点法求解二次规划的平均时间为2.8±0.5 ms, 平均总优化时间为4±0.6 ms. 上述计算时间确保了50 ms控制周期内的实时可行性, 并留有充足裕度.

受文献[8]的启发, 本文利用MPC优化过程中状态变量在相邻迭代间变化有限这一特性, 将全局非线性神经网络模型 h_{θ} 在当前工作点 $\mathbf{X}_{in}^i$ 处进行泰勒展开, 其中 i 是序列二次规划的迭代次数, 得到局部线性化近似:

$$h_{\theta}(\mathbf{X}_{in}) \approx h_{\theta}(\mathbf{X}_{in}^i) + \frac{\partial h_{\theta}}{\partial \mathbf{x}} \Big|_{\mathbf{x}=\mathbf{X}_{in}^i} (\mathbf{x} - \mathbf{X}_{in}^i). \quad (12)$$

这种近似将原本需要 $N \times E$ 次(其中 N 为预测时域, E 为积分步数)的神经网络前向传播简化为单次批处理计算, 显著降低了计算负担. 更为重要的是, 该方法实现了神经网络评估与二次规划求解的计算解耦: 在数据驱动动力学准备阶段, 利用GPU并行计算能力批量获取所有离散节点的函数值和雅可比矩阵; 随后在二次规划构建阶段, 仅需执行轻量级的线性运算即可完成优化问题的构建. 文献[8]表明, 这种局部近似策略

在保持控制性能的同时, 能够支持参数量高达4000倍的复杂神经网络模型在50 Hz频率下稳定运行, 为在嵌入式平台上部署大规模深度学习模型提供了可行的技术路径。

4.2 训练数据生成

本研究通过系统化的数据采集流程构建训练数据集, 具体步骤如下: 基于名义动力学模型(如刚体动力学)的模型预测控制器执行预设轨迹, 同步记录飞行器状态变量(位置、速度、姿态角)与执行器控制输入(电机推力), 形成原始状态-控制时序数据; 随后, 通过数值重仿真计算名义模型预测状态与实际状态的加速度残差, 作为数据驱动模型的训练数据。

对动力学模型施加本文设计的专有的风干扰模型, 以尽可能地模拟实际风场。当四旋翼整机搭建完毕后, 风扰力的大小只与风速的大小有关, 二者关系为

$$F_{wd} = k_w \cdot V_m^2, \quad (13)$$

其中, k_w 为风扰阻力系数。同时风干扰的来源方向是随机的。如图4所示, 四旋翼受到的风可表示为

$$\mathbf{F}_{wind} = \begin{bmatrix} F_x \\ F_y \\ F_z \end{bmatrix} = \begin{bmatrix} F_{wd} \cos(\theta_{windx}) \cos(\theta_{windy}) \\ F_{wd} \cos(\theta_{windx}) \sin(\theta_{windy}) \\ F_{wd} \sin(\theta_{windx}) \end{bmatrix}, \quad (14)$$

其中, θ_{windx} 是三维空间中来风方向与平面 xOy 之间的角度, 角度 θ_{windx} 表示风在平面 xOy 上的投影与 y 轴方向之间的测量值。

4.3 风效应预测评估

对本文所提方法与领域先进方法RTN^[20]的预测性能进行对比评估。使用平均绝对误差(MAE)、均方误差(MSE)和均方根误差(RMSE)作为预测评估指标。利用早停策略令训练在第100回合停止^[37], 同时设置算法的学习率为 10^{-4} 。使用Adam优化器和995650个样本进行训练, 对150000个样本进行测试。同时在该过程中, 无人机保持平均飞行速度8 m/s, 峰值飞行速度11 m/s的敏捷飞行状态。

图5给出了部分经风效应预测修正后的无人机参考状态量(绿色虚线)与测试数据集内的无人机标称状态量(黑色实线)的比较。不难看出, 风效应预测修正后的结果几乎与标称量重合。表1量化了风效应预测性

能, 其中最优的模型指标用粗体表示。Our-2-32的预测误差在所有模型参数中具有最小的预测误差。本文提




图4 (网络版彩图)四旋翼抗风平台受力状况

Figure 4 (Color online) Force dynamics on a UAV in windy conditions.




图5 (网络版彩图)风效应预测效果

Figure 5 (Color online) Wind effect prediction performance.

表1 风效应预测评估

Table 1 Wind effects prediction performance evaluation

模型	MAE	MSE	RMSE
RTN	0.40300	0.35211	0.74028
Our-1-32	0.08851	0.01471	0.00154
Our-1-64	0.08470	0.01351	0.00134
Our-2-32	0.06748	0.00949	0.00092
Our-2-64	0.10825	0.02110	0.00252
Our-4-32	0.10601	0.02091	0.00284
Our-4-64	0.11738	0.02525	0.00398

出的方法与RTN^[8]方法在相同的风况下对比仍然可以实现准确的风效应预测. 从表1可以看出MAE, MSE和RMSE分别为0.06748, 0.00949和0.00092, 与RTN方法相比, 分别提高了83.3%, 97.3%和99.8%.

上述结果表明, 与领域先进模型RTN相比, 所提出的模型面对相同的预测目标时, 能够作出更准确的预测. 实验数据验证了改进型GNN的优越性, 其核心优势在于自适应捕获变量间的隐式耦合关联. 此外, 用于表征变量间依赖关系的自适应邻接矩阵 $\tilde{\mathbf{A}}_{\text{ada}}$ 可视化后如图6所示. 显然网络的输入特征之间存在相关性, 提取并利用该相关性对提升预测性能有直接影响.

4.4 抗风控制性能评估

采用本文所提出的融合了风效应预测模型的MPC方法与领域先进的RTN-MPC方法分别跟踪相同的预设轨迹(圆轨迹与双曲轨迹), 并对比二者的跟踪误差以评估控制器的跟踪性能.

在性能评估过程中, 保持两种方案的MPC频率与成本矩阵一致, 同时, 二者的预测模型在相同的数据集上进行训练. 根据公式(10)(其中 $k_w = 0.029025$)与公式(11)建立风场模型来模拟风向与风速的随机过程, 合计建立三种风型: 持续风 V_t 、阵风 V_g 和切向风 V_{gr} . 每种风型共计仿真5次(取5个不同的随机种子), 取5次仿真的平均值计入表格, 其中最优的模型指标用粗体表示.

4.4.1 持续风

持续风是指风速的大小随着时间的推移保持不变, 可表示为

$$V_t = c, \tag{15}$$

其中 c 表示在给定时间内保持恒定的风流速度, t 表示时间. 模拟结果记录在表2中.

仿真结果表明, 在低速持续风场中, 本文提出的抗风控制器性能最优, 随着风速增加, 抗风控制器性能逐渐下降. 在四种风速下所提方案的平均轨迹跟踪误差比领域先进的RTN-MPC降低了27.1%.

4.4.2 阵风

阵风是指风突然出现, 风速逐渐上升到一个峰值, 然后逐渐下降, 直到风停止, 可表示为




图 6 (网络版彩图)风效应预测模型输入通道关系
Figure 6 (Color online) Input channel correlation architecture in wind effect prediction model.

表 2 持续风下无人机轨迹跟踪误差

Table 2 Trajectory tracking error of UAVs under sustained winds				
风速 (m/s)	轨迹	RTN-MPC ^[8] (m)	本文	提升 (%)
3	圆	0.46320	0.12784	72.4
	双曲	0.33022	0.11920	63.9
6	圆	0.64036	0.44260	30.9
	双曲	0.51694	0.42840	17.1
8	圆	1.01382	0.85492	15.7
	双曲	0.98562	0.90138	8.5
10	圆	2.42500	2.32396	4.2
	双曲	2.60556	2.50264	4.0

$$V_w = \begin{cases} 0, & t < 2.4, \\ \frac{V_{w\max}}{2} \left(1 - \cos \left[2\pi \left(\frac{t-2.4}{8.1} \right) \right] \right), & 2.4 \leq t \leq 10.5, \\ 0, & t > 10.5, \end{cases} \tag{16}$$

其中, $V_{w\max}$ 是阵风的最大速度. 模拟结果记录在表3中.

仿真结果表明, 在低速阵风风场中, 本文提出的抗风控制器性能最优, 随着风速增加, 抗风控制器性能逐渐下降. 在四种风速下所提方案的平均轨迹跟踪误差比领域先进的RTN-MPC降低了22.7%.

4.4.3 切向风

切向风的风速不会突然出现或消失, 而是随着时

间的推移逐渐增加或减少. 风速随时间波动, 可表示为

$$V_g = \begin{cases} 0, & t < 2.4 \text{ 或 } t > 8.1, \\ \frac{V_{g\max}}{2} \frac{t-2.4}{4.6}, & 2.4 \leq t \leq 7, \\ V_{g\max}, & 7 < t \leq 8.1, \end{cases} \quad (17)$$

其中, $V_{g\max}$ 是渐变风的最大速度. 仿真结果记录在表4中.

仿真结果表明, 在低速切向风风场中, 本文提出的抗风控制器性能最优, 随着风速增加, 抗风控制器性能逐渐下降. 在四种风速下所提方案的平均轨迹跟踪误差比领域先进的RTN-MPC降低了43.8%.

4.4.4 实机验证

使用工业风扇充当风源, 以风速计测量并保持向无人机施加约5 m/s的风. 令自主搭建的四旋翼无人机在该风场中跟随圆轨迹与双曲轨迹飞行(见图7), 无人

表3 阵风下无人机轨迹跟踪误差

Table 3 Trajectory tracking error of UAVs under wind gusts

风速 (m/s)	轨迹	RTN-MPC ^[8] (m)	本文	提升 (%)
3	圆	0.30052	0.11872	60.5
	双曲	0.28754	0.12995	54.8
6	圆	0.42769	0.33446	21.8
	双曲	0.40784	0.34547	15.3
8	圆	0.68051	0.60692	10.8
	双曲	0.61181	0.67101	8.8
10	圆	1.78969	1.81407	1.3
	双曲	1.74896	1.59052	9.1

表4 切向风下无人机轨迹跟踪误差

Table 4 Trajectory tracking error of UAVs under crosswind

风速 (m/s)	轨迹	RTN-MPC ^[8] (m)	本文	提升 (%)
3	圆	0.26659	0.09292	65.1
	双曲	0.23914	0.09595	59.9
6	圆	0.44445	0.22428	49.5
	双曲	0.37048	0.22781	38.5
8	圆	0.66957	0.38638	42.3
	双曲	0.66099	0.39458	40.3
10	圆	1.32998	1.04026	21.8
	双曲	1.44386	0.96313	33.3

机针对两种预设轨迹的三轴跟踪误差随时间的变化分别被计入图8和9, 最后将轨迹跟踪误差计入表5.

实机飞行实验表明, 与标称MPC方法相比, 使用风效应预测补偿后的MPC跟踪圆轨迹的误差下降了30.1%, 跟踪双曲轨迹的误差下降了24.6%, 在两种不同的飞行轨迹下平均轨迹跟踪误差下降27.35%.




图7 (网络版彩图)无人机抗风扰飞行轨迹
Figure 7 (Color online) Wind-resistant UAV flight trajectory.




图8 (网络版彩图)无人机圆轨迹跟踪误差
Figure 8 (Color online) UAV loop trajectory error under wind.




图 9 (网络版彩图)无人机双曲轨迹跟踪误差
Figure 9 (Color online) UAV lemniscate trajectory error under wind.

5 结论

本文提出了一种基于残差动力学学习的自适应模型预测控制框架, 通过融合图神经网络增强对动态风场的建模与预测能力, 实现了四旋翼无人机的抗风扰

表 5 无人机实机飞行轨迹跟踪误差

Table 5 Real-world UAV trajectory tracking error

风速 (m/s)	轨迹	MPC (m)	本文 (m)	提升 (%)
5	圆	0.8340	0.5832	30.1
	双曲	0.4305	0.3248	24.6

高精度敏捷飞行. 该框架创新性地将风扰效应建模为名义动力学模型的残差项, 并利用改进图神经网络预测无人机状态偏移量. 实验表明, 所提出的控制方法在几种典型风扰场景下轨迹跟踪误差分别降低27.1%, 22.7%与43.8%, 在实机实验中, 相比标称MPC轨迹跟踪误差下降了27.35%. 其核心优势在于, 通过在线预测风致状态偏移量, 动态修正MPC指令, 从而显著提升无人机在动态风场中的飞行精度与敏捷性. 本研究为复杂环境下的无人机抗扰控制提供了可扩展的解决方案, 尤其适用于物流运输和野外搜救等对鲁棒性要求严苛的实际场景.

基于当前研究成果, 未来工作将着重于引入标准化大气湍流模型及风况随机模型以提升风扰表征的真实性, 并开展系统性风洞试验验证, 以更深入地探索能够应对具有强时变扰动特征的自适应控制策略.

致谢 自主搭建的四旋翼无人机平台在王心宇工程师的通力协助下得以顺利试飞, 在此深表谢忱.

参考文献

1 Lyu Y, Kang T N, Pan Q, et al. UAV sense and avoidance: Concepts, technologies, and systems (in Chinese). *Sci Sin Inform*, 2019, 49: 520–537 [吕洋, 康童娜, 潘泉, 等. 无人机感知与规避: 概念, 技术与系统. 中国科学: 信息科学, 2019, 49: 520–537]

2 Zhu H, Chen Q, Zhu X, et al. Edge computing powers aerial swarms in sensing, communication, and planning. *Innovation*, 2023, 4: 100506

3 Wang S, Chen X, Wei H, et al. Heading adjustment by admittance control for lifting-wing quadcopters in strong winds. *IEEE Robot Autom Lett*, 2025, 10: 3558–3565

4 Gong J, Fan Y. Active disturbance rejection control method for UAV autonomous aerial refueling based on reflected pigeon-inspired optimization (in Chinese). *Sci Sin Tech*, 2025, 55: 1–13 [巩嘉玮, 范彦铭. 基于反射鸽群优化算法的无人机自主空中加油自抗扰控制方法. 中国科学: 技术科学, 2025, 55: 1–13]

5 Liao J, He J, Jia L, et al. Robust formation tracking control of multi-UAV system under time-delay conditions (in Chinese). *Sci Sin Tech*, 2024, 54: 2017–2029 [廖剑, 何静, 贾临生, 等. 时延条件下多无人机系统鲁棒编队跟踪控制. 中国科学: 技术科学, 2024, 54: 2017–2029]

6 O’Connell M, Shi G, Shi X, et al. Neural-fly enables rapid learning for agile flight in strong winds. *Sci Robotics*, 2022, 7: 65–97

7 Mellinger D, Kumar V. Minimum snap trajectory generation and control for quadrotors. In: *Proceedings of the 2011 IEEE International Conference on Robotics and Automation*. Shanghai, 2011. 2520–2525

8 Salzmann T, Kaufmann E, Arrizabalaga J, et al. Real-time neural MPC: Deep learning model predictive control for quadrotors and agile robotic platforms. *IEEE Robot Autom Lett*, 2023, 8: 2397–2404

- 9 Xing Z, Zhang Y, Su C Y. Active wind rejection control for a quadrotor UAV against unknown winds. *IEEE Trans Aerosp Electron Syst*, 2023, 59: 8956–8968
- 10 Hou Y, Chen D, Yang S. Adaptive robust trajectory tracking controller for a quadrotor UAV with uncertain environment parameters based on backstepping sliding mode method. *IEEE Trans Automat Sci Eng*, 2025, 22: 4446–4456
- 11 Bisheban M, Lee T. Geometric adaptive control with neural networks for a quadrotor in wind fields. *IEEE Trans Contr Syst Technol*, 2021, 29: 1533–1548
- 12 Ma B, Liu Z, Dang Q, et al. Deep reinforcement learning of UAV tracking control under wind disturbance environments. *IEEE Trans Instrum Measure*, 2023, 72: 1–13
- 13 Ma B, Liu Z, Zhao W, et al. Target tracking control of UAV through deep reinforcement learning. *IEEE Trans Intell Transp Syst*, 2023, 24: 5983–6000
- 14 Caffyn Yuste P, Iglesias Martínez J A, Sanchis de Miguel M A. Simulation-based evaluation of model-free reinforcement learning algorithms for quadcopter attitude control and trajectory tracking. *Neurocomputing*, 2024, 608: 128362
- 15 Zhu H, Claramunt F M, Brito B, et al. Learning interaction-aware trajectory predictions for decentralized multi-robot motion planning in dynamic environments. *IEEE Robot Autom Lett*, 2021, 6: 2256–2263
- 16 Pan X, Seita D, Gao Y, et al. Risk averse robust adversarial reinforcement learning. In: *Proceedings of the 2019 International Conference on Robotics and Automation*. Montreal, 2019. 8522–8528
- 17 Pinto L, Davidson J, Sukthankar R, et al. Robust adversarial reinforcement learning. In: *Proceedings of the 34th International Conference on Machine Learning*. Sydney, 2017. 2817–2826
- 18 Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning. *Nature*, 2015, 518: 529–533
- 19 Kabzan J, Hewing L, Liniger A, et al. Learning-based model predictive control for autonomous racing. *IEEE Robot Autom Lett*, 2019, 4: 3363–3370
- 20 Torrente G, Kaufmann E, Fohn P, et al. Data-driven MPC for quadrotors. *IEEE Robot Autom Lett*, 2021, 6: 3769–3776
- 21 Asignacion A, Suzuki S, Noda R, et al. Frequency-based wind gust estimation for quadrotors using a nonlinear disturbance observer. *IEEE Robotics Automat Lett*, 2022, 38: 9224–9231
- 22 Li D, Zhou J, Huang J, et al. State prediction and anti-interference-based flight path-following for UAVs. *IEEE Trans Intell Transp Syst*, 2023, 24: 15236–15247
- 23 Wang H, Mo Y, Dai H, et al. FTMLP: MLP with feature-temporal block for multivariate time series forecasting. *Neurocomputing*, 2024, 607: 128365
- 24 Ruan G, Kirschen D S, Zhong H, et al. Estimating demand flexibility using Siamese LSTM neural networks. *IEEE Trans Power Syst*, 2022, 33: 2360–2370
- 25 Li M-W, Xu D-Y, Geng J, et al. A hybrid approach for forecasting ship motion using CNN-GRU-AM and GCWOA. *Appl Soft Comput*, 2022, 37: 2360–2370
- 26 Li M, Yang M, Yu Y, et al. Short-term wind power forecast based on continuous conditional random field. *IEEE Trans Power Syst*, 2023, 39: 2185–2197
- 27 Jia Z, Li Z, Zhao K, et al. CNN-DBLSTM: A long-term remaining life prediction framework for lithium-ion battery with small number of samples. *J Energy Storage*, 2024, 97: 112947
- 28 Zaraket K, Harb H, Bennis I, et al. Hyper-Flophet: A neural Prophet-based model for traffic flow forecasting in transportation systems. *Simul Model Pract Theor*, 2024, 134: 102954
- 29 Liu X, Zhang Y, Zhen Z, et al. Spatio-temporal graph neural network and pattern prediction based ultra-short-term power forecasting of wind farm cluster. *IEEE Trans Industry Appl*, 2023, 6: 1794–1803
- 30 Liu J, Wang X, Xie F, et al. Condition monitoring of wind turbines with the implementation of spatio-temporal graph neural network. *Eng Appl Artif Intelligence*, 2023, 121: 106000
- 31 Shen G, Zhou W, Zhang W, et al. Bidirectional spatial-temporal traffic data imputation via graph attention recurrent neural network. *Neurocomputing*, 2023, 531: 151–162
- 32 Xu H, Zhang Y, Zhen Z, et al. Adaptive feature selection and GCN with optimal graph structure-based ultra-short-term wind farm cluster power forecasting method. *IEEE Trans Ind Appl*, 2023, 60: 1804–1813

- 33 Zheng Z, Zhang Z. A stochastic recurrent encoder decoder network for multistep probabilistic wind power predictions. *IEEE Trans Neural Networks Learn Syst*, 2023, 35: 9565–9578
- 34 Chang Y, Yang H, Chen Y, et al. A Hybrid model for long-term wind power forecasting utilizing NWP subsequence correction and multi-scale deep learning regression methods. *IEEE Trans Sustain Energy*, 2023, 15: 263–275
- 35 Liao X, Liu Z, Zheng X, et al. Wind power prediction based on periodic characteristic decomposition and multi-layer attention network. *Neurocomputing*, 2023, 534: 119–132
- 36 Jia Z, Wang S, Zhao K, et al. An efficient diagnostic strategy for intermittent faults in electronic circuit systems by enhancing and locating local features of faults. *Measure Sci Tech*, 2023, 35: 036107
- 37 Prechelt L. Early stopping—but when? In: *Neural Networks: Tricks of the Trade*. Lecture Notes in Computer Science, vol. 1524. Berlin, Heidelberg: Springer, 2012. 53–67

Agile control of a quadrotor with disturbance observation based on graph neural networks

WANG BaoDong¹, ZHU Hai^{2,3}, ZHU XiaoZhou^{2,3}, JIA Zhen¹, LIU ZhenBao^{1,4},
YAO Wen^{2,3} & CHEN XiaoQian³

¹ School of Civil Aviation, Northwestern Polytechnical University, Xi'an 710072, China

² Defense Innovation Institute, Chinese Academy of Military Sciences, Beijing 100071, China

³ Intelligent Game and Decision Laboratory, Beijing 100071, China

⁴ Shenzhen Research Institute, Northwestern Polytechnical University, Shenzhen 518057, China

Robust and agile flight under strong wind disturbances remains one of the primary objectives in disturbance-rejection control for unmanned aerial vehicles (UAVs). Conventional observer-based control approaches often fail to effectively model the influence of aggressive wind fields on UAV dynamics, leading to significant performance degradation in complex wind scenarios. This paper proposes a lightweight wind-effect predictor based on a graph neural network (GNN) with adaptive channel extraction, leveraging the differential flatness property of quadrotors. The predictor is trained using historical flight trajectories to enable real-time estimation of complex wind disturbances encountered during flight. A model predictive control (MPC) scheme is then developed to achieve disturbance-aware trajectory tracking. Specifically, flight data are collected under various wind conditions, including sustained winds, gusts, and crosswinds. A total of 995650 trajectory residual samples are used to train the predictor, and 150000 samples are reserved for testing and benchmarking against state-of-the-art models. Experimental results show that the proposed wind-effect predictor achieves a 14.9% improvement in prediction accuracy compared to existing methods. Moreover, the wind-aware MPC based on this predictor improves trajectory tracking performance by 50.35% under aggressive wind disturbances. Finally, real-world flight experiments on a custom-built quadrotor platform validate the effectiveness of the proposed method, demonstrating a 27.35% enhancement in trajectory tracking accuracy under wind disturbances.

wind effect prediction, anti-disturbance control, graph neural network, model predictive control

doi: [10.1360/SST-2025-0079](https://doi.org/10.1360/SST-2025-0079)