

面向无人机适飞场景的多气象要素格点预报方法

杜 刚¹, 赵英燕², 顾芮冰¹, 胡昕童¹

¹江苏省气象数据中心, 江苏 南京

²南京瓴数科技有限公司, 江苏 南京

收稿日期: 2026年9月14日; 录用日期: 2026年10月7日; 发布日期: 2026年10月13日

摘 要

无人机低空飞行对气象条件具有高度敏感性, 精准短临格点预报是保障飞行安全与任务规划的关键。现有预报多聚焦单站点或单要素, 难以直接支撑面向适飞判断的多变量空间化分析。针对该问题, 本文提出一种面向无人机适飞分析的多要素气象格点预报方法。首先, 构建多阶段数据预处理流程, 将多站点不规则观测统一转换为 20×20 规则格点序列; 其次, 根据气象要素物理属性设计分组建模策略, 在统一时空预测框架下分别构建热力、风场与降雨分支, 其中风场采用水平风分量建模以规避风向角周期边界问题, 降雨采用对数变换与非负约束处理稀疏分布。基于研究区域多站点连续一年地面观测数据的实验表明, 模型对未来4 h逐15 min的多要素场具有稳定的预测能力, 温度、相对湿度与风速的MAE分别约为 1.45°C 、 5.09% 和 0.61 m/s , 能够有效保持各要素空间结构一致性。本文方法可为无人机适飞状态的空间化分析提供多要素格点预报基础。

关键词

无人机适飞, 短临气象预报, 时空预测, 格点化

A Grid-Based Forecasting Method of Multiple Meteorological Elements for UAV Flyable Scenarios

Gang Du¹, Yingyan Zhao², Ruibing Gu¹, Xintong Hu¹

¹Jiangsu Provincial Meteorological Data Center, Nanjing Jiangsu

²Nanjing Lingshu Technology Co., Ltd., Nanjing Jiangsu

文章引用: 杜刚, 赵英燕, 顾芮冰, 胡昕童. 面向无人机适飞场景的多气象要素格点预报方法[J]. 建模与仿真, 2026, 15(10): 62-78. DOI: 10.12677/mos.2026.1510145

Abstract

Low-altitude UAV flights are highly sensitive to meteorological conditions, and accurate short-term gridded forecasting is essential for ensuring flight safety and mission planning. Existing forecasts mainly focus on single-station or single-element predictions, making it difficult to directly support multivariable spatial analysis for flight-suitability assessment. To address this issue, this paper proposes a multi-element meteorological gridded forecasting method for UAV flight-suitability analysis. First, a multi-stage data preprocessing pipeline is constructed to convert irregular multi-station observations into uniform 20×20 regular gridded sequences. Second, a grouped modeling strategy is designed according to the physical properties of meteorological elements. Within a unified spatio-temporal prediction framework, separate thermal, wind, and rainfall branches are built: the wind branch adopts horizontal wind components to avoid the periodic boundary problem of wind direction angles, while the rainfall branch employs logarithmic transformation and non-negative constraints to handle sparse distributions. Experiments based on one year of continuous ground observation data from multiple stations in the study area show that the model achieves stable predictive capability for multi-element fields over the next 4 h at 15-min intervals, with MAEs of approximately 1.45°C for temperature, 5.09% for relative humidity, and 0.61 m/s for wind speed, while effectively preserving the spatial structural consistency of each element. The proposed method provides a multi-element gridded forecasting foundation for spatialized UAV flight-suitability analysis.

Keywords

UAV Flight Suitability, Short-Term Meteorological Forecasting, Spatiotemporal Prediction, Gridding

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

无人机低空飞行已广泛应用于农业植保、电力巡检、应急救援与物流配送等领域，其飞行安全与任务执行效率高度依赖于低空气象条件。温度、相对湿度、能见度、风场及降雨等要素的短时变化直接影响无人机姿态稳定性、航线跟踪精度与起降安全。然而，现有气象预报服务多以单站点观测或单要素数值预报为主，空间分辨率与更新频率难以满足无人机在局地区域内精细航线规划与实时适飞判断的需求。因此，构建面向无人机适飞分析的多要素、高时空分辨率格点预报方法，对于提升无人机自主飞行决策能力具有重要的应用价值。

在无人机低空气象服务方面，已有研究针对京津冀地区开展了无人机低空航路气象环境模拟，分析了不同航路高度层上的气象要素分布特征，为航线规划提供了气象环境参考[1]。另有研究从低空经济气象保障的角度出发，系统梳理了低空气象探测、短临预报与航路规划等前沿科技问题，指出当前气象服务需从常规预报向场景化精准保障升级[2]。上述研究主要从航路气象环境模拟或单要素阈值角度进行飞行条件判断，较少涉及面向适飞分析的多要素格点化联合预报。

近年来, 基于深度学习的时空预测方法在气象预报领域取得了显著进展。相关研究对基于深度学习的短临降水预报方法进行了系统综述, 梳理了生成式模型、循环神经网络与卷积神经网络在降水预报中的研究进展[3]; 也有研究进一步总结了深度学习在气象预报中的应用现状, 指出深度学习方法在挖掘气象数据时空特征方面具有优势[4]。在模型架构方面, SimVP [5]提出了一种完全基于卷积神经网络、以均方误差损失进行端到端训练的简单视频预测框架, 通过将空间表征学习与时间动态建模解耦, 在多个基准数据集上取得了良好的预测性能。ConvLSTM 将卷积操作嵌入长短期记忆网络, 实现了对降水回波时空序列的短临预报[6]。EarthFormer 探索了时空 Transformer 在地球系统预报中的应用, 提升了长程时空依赖的建模能力[7]。NowcastNet 基于物理约束的生成模型实现了对极端降水的精准短临预报[8]。PreDiff 则将潜在扩散模型引入降水短临预报, 进一步提升了极端降水事件的预报效果[9]。然而, 上述研究多聚焦于单一气象要素(如降水)的预报, 或基于数值模式输出进行单要素偏差订正, 较少涉及面向原始站点观测的端到端多要素联合建模。

原始气象观测数据通常来自空间分布不规则的地面站点, 存在缺测值、异常值与量纲差异等问题, 需经过质量控制与格点化后才能输入深度学习模型。相关研究对气象观测数据质量控制方法进行了探讨, 分析了气候极值检查、时间一致性检验与空间一致性检验等常用手段[10]; 另有研究系统研究了地面气象观测数据的综合质量控制方法, 提出了涵盖格式检查、缺测处理与异常值剔除的完整流程[11]。在空间格点化方面, 已有研究协同 ERA5 再分析数据对降水量进行了空间插值, 验证了辅助数据对提升插值精度的作用[12]; 也有研究将机器学习与空间插值相结合, 开展了城市风场的时序预测与空间插值, 为不规则站点数据向规则网格的转换提供了方法参考[13]。上述研究为数据预处理提供了基础, 但如何针对无人机适飞场景将多站点多要素数据统一转换为固定时空尺寸的样本, 仍需进一步探索。

在多要素联合预测与变量变换方面, 已有研究提出了数值天气预报多要素深度学习融合订正方法, 将温度、相对湿度与风速等多个要素同时输入网络进行融合建模, 实验表明多要素联合订正优于单要素独立订正[14]。多任务学习策略在气象预测中亦有应用, 通过共享底层特征提取层实现多任务协同, 能够在一定程度上提升模型的泛化能力。相关研究提出了基于多任务长短时卷积计算网络的降雨预测方法, 利用共享卷积层提取时空特征并分别输出多任务预测结果[15]。也有研究尝试利用长短期记忆网络对温度、能见度、露点、风速等多要素进行联合预测, 验证了深度学习在多要素时间序列建模中的有效性[16]。然而, 上述方法主要针对单站点时间序列, 未考虑空间格点化与要素间物理差异。此外, 不同气象要素在分布特征上存在显著差异, 例如降雨量具有明显的稀疏性与偏态分布, 直接建模容易导致训练不稳定。相关研究对比分析了年降水量数据的多种正态变换方法, 表明对数变换等策略能够有效改善降水数据的分布特性[17]。

本文提出一种面向无人机适飞分析的多要素气象格点预报方法。首先, 构建了涵盖数据质量控制、时间聚合、空间格点化、Patch 切分与样本切片的多阶段数据预处理流程, 将多站点不规则观测统一转换为 20×20 规则格点序列; 其次, 根据气象要素物理属性设计分组建模策略, 在统一时空预测框架下分别构建热力、风场与降雨分支, 其中风场采用水平风分量建模以规避风向角周期边界问题, 降雨采用对数变换与非负约束处理稀疏分布。实验结果表明, 本文方法能够有效实现未来 4 h 逐 15 min 的多要素格点预报, 可为无人机适飞状态的空间化分析提供数据支撑。

本文的主要贡献包括: (1) 构建了面向无人机适飞区域的多阶段数据预处理与格点样本构建流程, 解决了原始站点观测数据到规则时空张量的转换问题; (2) 提出了基于气象要素物理属性的分组建模策略, 在统一时空预测框架下实现热力、风场与降雨变量的差异化建模, 提升了多要素联合预报的稳定性。

2. 多阶段数据预处理

2.1. 数据来源与变量组成

本文使用的气象数据来源于江苏省多站点累计气象观测资料。原始数据以文本形式存储，数据记录包含站点编号、经纬度、时间及多种气象要素。数据集处理流程参考图 1，系统按照时间戳顺序读取并组织各站点的气象变量，由于后续训练模型时需要固定时间长度的连续输入序列，因此在数据读取阶段首先按照文件内部时间字段顺序对样本进行排序，并转换为连续时间序列。




Figure 1. Dataset processing flowchart

图 1. 数据集处理流程图

原始观测数据中涉及到多种形式的气象要素，如瞬时值、极值、极值出现时间、不同时间内的平均值等，针对无人机适飞与后续模型预测任务，主要选取变量瞬时值作为输入与输出。

本文重点选取温度、湿度和能见度来反映热力学与近地面空气状态，通过风速与风向变量来构建矢量风场，降水量来判断降水对无人机飞行的影响，此外还选取一些辅助相关变量用于后续模型训练。

在实际建模中本文并未将所有变量直接输入到同一个模型，而是根据变量的物理属性和预测目标来分组，具体分组与模型结构将在第四章中详细介绍。

2.2. 数据质控与时间处理

原始气象站观测数据中不可避免地存在缺测值、异常值以及局部无效记录。为了避免异常数据影响模型训练和实时预测，本文首先对原始观测数据进行质量控制。对于一些常见缺测值如 999999、65535 等，读取文件并排序时会统一转换为 NaN；随后再手动滤除一部分不合理值，如将降雨、能见度中的负值处理为 0 或者无效值。

在时间处理方面，原始数据时间分辨率为一分钟，综合考虑天气系统变化时间与模型设计问题，本文采取 15 min 一个时间步，并根据不同变量特性进行时间聚合，如温度等连续变量使用 15 分钟平均值，降雨采用求和计算 15 分钟累计降水量。

最终预测任务并以为利用过去 8 h 的气象状态预测未来 4 h 的气象变化，由于 8 h 历史数据在 15 min 分辨率下对应 32 个时间步，4 h 未来预报对应 16 个时间步，因此样本构造形式为：输入 32 帧历史气象场，输出 16 帧未来气象场，时间间隔为 15 min。

在样本切片过程中，系统沿时间轴滑动构造训练样本。对于每一个样本，前 32 个时间步作为模型输

入, 后 16 个时间步作为预测目标。这样可以将连续的历史观测数据转换为监督学习所需的输入-输出样本对。若某个时间段内缺少足够长度的历史序列, 或者未来目标序列不完整, 则该时间段不会被构造成为有效样本。

2.3. 格点化及样本切分

原始气象观测数据来自 2600 左右离散站点, 各站点在时间和空间上的分布并不规则, 存在站点暂时无数据情况, 而后续时空预测模型需要规则的二维网格输入。因此, 在完成数据质量控制和时间聚合后, 本文进一步将站点观测数据转换为规则格点数据。具体而言, 首先根据研究区域内有效站点的经纬度范围确定空间覆盖区域, 然后在该区域内建立规则二维网格。对于每一个时间步和每一个气象变量, 利用有效站点观测值进行空间插值, 将离散站点观测映射为连续的格点气象场。

在格点化过程中, 本文优先使用经过质量控制后的有效站点参与插值。对于质量控制后的缺测数据, 需进一步采用插补方法恢复其时空连续性。相关研究对比了反距离权重法、克里金插值以及基于时空相关性的统计插补等方法在区域自动气象站日气温缺测数据上的适用性, 表明不同方法在局地地形条件下的插补效果存在差异, 需结合站点密度与要素特性进行选择[18]。

本文在格点化阶段综合采用空间插值与背景场填充相结合的分层补全策略, 以保证格点场在空间上的完整连续。对于插值后仍为缺测的格点, 采用背景场进行填充。

创建经度[116.4, 121.9], 纬度[30.7, 35.2], 分辨率 0.1° 的网格, 即 56×46 共 2576 个格点的空白网格, 若格点周围有三个以上有效站点, 采用公式(1)中的线性插值方法, 取有效站点、等的线性加权值。若该格点附近不足 3 个有效格点, 则采用最近邻插值, 直接使用距离最近的有效点进行填充。

$$y = y_0 + \frac{y_1 - y_0}{x_1 - x_0}(x - x_0) \quad (1)$$

该方法将有效站点插值分布在网格上, 能够对一些因为临时遮挡或其他原因暂时异常的观测值进行填充。但存在某些区域无气象站点(如水域), 保留异常值会对模型训练造成影响。本文采用背景场的方式, 对这些格点进行填充, 保证数据集中不存在异常点。

背景场能够反映研究区域内各气象要素的气候态空间分布[19], 为缺测区域提供合理的初始估计, 从而保证每个时间步的格点场在空间上完整连续。经过该操作, 原始不规则站点观测被统一转换为规则二维气象场, 为后续样本构建提供基础。

背景场创建相同的空白网格, 对于某有效格点, 沿时间轴取该点全年平均值, 对于无效格点, 取有效格点全局平均值, 最终计算出一张 56×46 的全年平均值且无异常点的网格, 用于填充所有时间均为 nan 的格点, 防止影响训练效果。

考虑到无人机适飞分析通常关注局区域内的精细气象变化, 本文在完整格点场的基础上进一步进行空间 Patch 切分, 即从较大范围的格点气象场中裁剪出固定大小的局地区域作为模型样本的空间输入。

本文采用的 Patch 大小为 20×20 , 每一个 Patch 对应一个区域。通过 Patch 切分, 一方面可以将不同时间步和不同区域的数据统一为固定空间尺寸, 便于模型批量训练; 另一方面也能够突出局地温度、湿度、能见度、风场和降水等要素的空间分布特征。

Patch 切分完成后, 每个时间步的单变量气象场均被表示为一个 20×20 的二维矩阵, 多变量气象场则由多个变量通道共同组成。此时数据仍处于统一的多变量格点序列形式, 尚未按照热力、风场和降水任务进行分组。变量分组和不同预测任务的数据组织将在后续章节中进一步说明。

完成空间格点化后, 每个时间步的气象状态被表示为一个多通道二维场。随后根据 32 帧输入和 16 帧输出的时间窗口进行样本切分。对于不同任务分支, 输入变量和输出变量有所不同, 但空间分辨率均

保持为 20×20 。因此，最终样本可以表示为：

$$X \in \mathbb{R}^{32 \times 20 \times 20 \times C}, Y \in \mathbb{R}^{16 \times 20 \times 20 \times T} \quad (2)$$

其中， C 表示输入变量通道数， T 表示预测目标变量通道数。不同分支的 C 和 T 根据具体预测任务确定。例如，热力分支输入包含 7 个变量，输出包含 3 个变量；风场分支输入包含 3 个变量，输出包含 2 个风分量；降水分支则用于构建未来降水场或降水事件判断。

2.4. 数据集构建

在完成格点化和 Patch 切分后，本文进一步沿时间维度构建监督学习样本。由于本文面向短临气象预测任务，模型需要根据一段连续历史气象场预测未来一段时间内的气象变化。

为了保证模型评估结果的时间独立性，本文在样本划分时没有采用完全随机的样本级划分方式。由于滑动窗口样本之间存在时间重叠，若直接随机划分，训练集和测试集可能包含高度相邻甚至部分重叠的时间片段，从而造成信息泄漏。为降低这一风险，数据集采用按日期划分的方式。首先根据格点化后数据内部的时间信息解析每个样本对应的日期，然后以天为基本单位划分训练集、验证集和测试集，其中训练集取前 80% 的时间，验证与测试集各 10%。同一天内生成的所有滑动窗口样本会被分配到同一个数据子集，不会同时出现在训练集和测试集中。

具体划分时，首先对所有有效样本日期进行去重，得到独立日期集合；随后在固定随机种子下划分训练日期、验证日期和测试日期；最后根据每个样本所属日期将样本索引映射到对应的数据子集中。

通过上述处理，本文将原始多站点气象观测数据转换为适合模型训练和实时推理的规则化时空样本。该数据集构建过程具有三个特点：第一，空间上将不规则站点观测转换为固定大小的 20×20 局地 Patch；第二，时间上采用 32 帧输入和 16 帧输出的序列样本形式，支持未来 4 h 逐时效预测；第三，在样本组织上进一步形成热力、风场和降水三类任务数据集，为第 4 章的分组建模方法提供数据基础。最终样本可以表示为：

$$X \in \mathbb{R}^{32 \times 20 \times 20 \times C}, Y \in \mathbb{R}^{16 \times 20 \times 20 \times T} \quad (3)$$

其中， C 表示输入变量通道数， T 表示预测目标变量通道数。不同分支的 C 和 T 根据具体预测任务确定。例如，热力分支输入包含 7 个变量，输出包含 3 个变量；风场分支输入包含 3 个变量，输出包含 2 个风分量；降水分支则用于构建未来降水场或降水事件判断。

3. 面向气象要素的分组建模多任务预测方法

经过数据质量控制、时间聚合、格点化和样本构建后，原始站点观测数据已经被转换为规则的 20×20 局地格点序列。为了进一步实现面向无人机适飞分析的多气象要素预测，本文在统一数据基础上构建分组建模框架。该框架的核心思想是：不同气象要素具有不同的物理属性、变化尺度和预测难度，若将所有变量直接放入单一模型进行联合预测，容易造成不同任务之间的相互干扰。因此，本文根据变量相关性和预测目标，将气象要素划分为热力相关变量、风场变量和降水变量三类。

3.1. 总体框架

本文提出的多任务气象预测框架以统一的格点序列样本作为输入。对于每个样本，历史输入序列包含过去 8 h 的气象场，共 32 个时间步；预测目标为未来 4 h 的气象场，共 16 个时间步。每个时间步对应一个 20×20 的二维格点。模型整体输入和输出可以表示为：

$$X \in \mathbb{R}^{32 \times 20 \times 20 \times C}, Y \in \mathbb{R}^{16 \times 20 \times 20 \times T} \quad (4)$$

其中, T 为预测目标变量通道数。不同任务分支的 C 和 T 根据输入变量和目标变量确定。

整体框架由三个预测分支组成: 热力分支、风场分支和降水分支。热力分支主要预测温度、相对湿度和能见度等与近地面热湿状态相关的变量; 风场分支预测水平风分量, 并进一步转换为风速和风向; 降水分支通过对降水量进行 Log 变换值域来辅助预测未来降水量。三个分支的预测结果最终在时间维度和空间维度上对齐, 形成未来 4 h 内多气象要素的格点预报产品, 为后续无人机适飞判断提供参考。

与单一多输出模型相比, 分组建模具有两个优势。第一, 不同变量可以根据自身变化特征选择更合适的建模方式, 从而减少任务之间的负迁移。例如, 温度和湿度具有相对连续的时空演变过程, 而降水具有更强的稀疏性和突发性, 二者若直接使用同一回归模型学习, 可能导致降水预测被平滑化。第二, 分组建模便于在实时系统中独立更新不同模块。例如, 当风场模型或降水模型需要调整时, 可以在不影响其他分支的情况下单独替换, 提高系统维护和扩展的灵活性。

3.2. 基于相关性分析的变量分组

本文从各变量的物理含义与无人机适飞的实际需求出发, 以相关性分析实验为辅助, 对输入和预测变量进行分组。变量分组的目的是简单减少输入维度, 而是使每个预测分支内部的变量具有较高的物理一致性, 从而降低不同类型变量之间的任务冲突。

热力分支主要关注近地面大气热湿状态及能见度变化。温度、相对湿度和能见度是无人机适飞分析中的重要气象因子, 其中能见度直接影响目视飞行和环境感知, 温湿度则能够反映低空环境状态。露点温度、水汽压、气压和阵风风速等变量虽然不一定作为最终预测目标, 但能够为热力状态和能见度变化提供辅助信息, 因此被作为输入变量参与建模。

风场分支主要关注水平风场变化。风速过大或风向变化剧烈均可能影响无人机姿态稳定性和航线跟踪能力。由于风向是圆周变量, 直接对风向角进行回归会引入周期边界问题, 即 $0^{\circ}/359^{\circ}$ 虽然在数值上区别很大但是实际角度接近。因此, 本文在建模阶段采用水平风分量作为预测目标, 后续再由风分量计算风速和风向。

降水分支主要关注降水对飞行安全的影响。降雨量具有明显的非负性和稀疏性, 大量时间和空间位置降雨接近 0, 少量降雨事件则对适飞判断具有重要影响。为降低降雨分布偏态对模型训练的影响, 本文在降水分支中对降雨量进行非负变换, 并采用与其他分支一致的深度学习时空预测模型进行未来降雨场预测。

本文使用的主要变量如表 1 所示。

Table 1. Grouping of prediction models
表 1. 预测模型分组表

类别	变量名称	含义	单位	用途
Thermo	TEM	气温	$^{\circ}\text{C}$	输入/输出
Thermo	RHU	相对湿度	%	输入/输出
Thermo	VIS	能见度	m	输入/输出
辅助变量	DPT	露点温度	$^{\circ}\text{C}$	输入
辅助变量	PRS	气压	hPa	输入
辅助变量	VAP	水汽压	hPa	输入
辅助变量	GST	阵风风速	m/s	输入

续表

Wind	U-WIND	经向风分量	m/s	输入/输出
Wind	V-WIND	纬向风分量	m/s	输入/输出
Rain	PRE	降水量	mm/15min	输入/输出

表中变量的“输入/输出”表示其在对应分支中是否作为模型输入或预测目标。不同分支的具体输入输出组合并不完全相同，本文在模型设计中根据任务需求分别构建热力、风场和降雨数据集。

3.3. 模型架构

本文三个预测分支均采用统一的空间编码器-时序预测器-空间解码器的时空预测网络，其核心思想是在低维特征空间中解耦空间表征学习与时间动态建模。与传统循环结构不同，该模型不依赖逐时刻递归传播，而是将历史气象序列整体编码为潜在特征序列，并通过卷积式时序预测模块直接生成未来多步预报结果。该设计能够降低长序列递归预测中的误差累积问题，同时保持卷积网络对局地空间结构的建模能力。模型总体结构如图2所示。




Figure 2. Model architecture diagram

图2. 模型架构图

风场分支主要关注水平风场变化。风速过大或风向变化剧烈均可能影响无人机姿态稳定性和航线跟踪能力。由于风向是圆周变量，直接对风向角进行回归会引入周期边界问题，即 $0^\circ/360^\circ$ 虽然在数值上区别很大但是实际角度相同。因此，本文在建模阶段采用水平风分量作为预测目标，后续再由风分量计算风速和风向。设输入历史气象序列为：

$$X = \{X_1, X_2, \dots, X_{32}\}, X_t \in \mathbb{R}^{32 \times C_{in} \times 20 \times 20} \quad (5)$$

其中，32 表示以 15 min 为一帧，输入 8 小时历史序列共 32 个时间步，为输入变量通道数。模型目标是学习由历史序列到未来序列的非线性映射：

$$\hat{Y} = F_\theta(X), \hat{Y} \in \mathbb{R}^{16 \times C_{out} \times 20 \times 20} \quad (6)$$

其中，16 表示以 15 min 为一帧，预测 4 小时未来序列共 16 个时间步， C_{out} 为输出变量通道数。不同任

务分支共享相同的主体网络结构，区别主要体现在输入变量通道、输出变量通道以及输出后的物理量恢复方式。

从功能上看，模型由空间编码器、时序预测器、时间投影层和空间解码器四个部分组成。首先，空间编码器采用逐帧二维卷积结构，对输入序列中的每个时间步独立提取空间特征。该过程可表示为：

$$Z_t = \text{Encoder}(X_t), t = 1, 2, \dots, 32 \quad (7)$$

其中， $\text{Encoder}(\cdot)$ 表示空间编码器， Z_t 为第 t 个历史时刻的潜在空间特征。对于温度、湿度、能见度、风场和降雨等格点变量，其局部空间分布通常具有明显的连续性和邻域相关性，因此二维卷积能够有效捕捉局地梯度、边界和区域结构等空间信息。编码器在提取浅层空间特征的同时进行一次下采样，将输入格点场压缩到较低空间分辨率的潜在特征域，以减少后续时序建模的计算量。同时，编码器保留浅层空间特征作为跳跃连接，用于在解码阶段补充细粒度空间信息。

将逐帧编码后的特征沿时间维度重新组织，可得到历史潜在特征序列：

$$Z = \{Z_1, Z_2, \dots, Z_{32}\} \quad (8)$$

随后，时序预测器采用三维卷积结构对潜在特征序列进行时空建模：

$$U = \text{Translator}(Z) \quad (9)$$

其中， $\text{Translator}(\cdot)$ 表示 3D CNN Translator， U 表示预测器输出的时空联合特征。三维卷积同时在时间维度和空间维度上进行局部感受野聚合，能够学习气象场随时间移动、扩散、增强或减弱的动态变化。对于本文的短临预测任务，三维卷积预测器能够在不引入显式循环结构的情况下建模多帧之间的时空依赖关系。与仅使用二维卷积逐帧预测相比，该结构能够更好地利用历史序列中的连续演变信息。

在时序特征提取之后，模型通过时间投影层完成由历史序列到未来序列的映射。预测器输出的时间-通道联合特征首先被重组为二维特征表示，然后通过 1×1 卷积进行通道投影：

$$V = Q_\theta(\text{Flatten}_{T,C}(U)) \quad (10)$$

其中， $Q_\theta(\cdot)$ 表示时间投影层， $\text{Flatten}_{T,C}(\cdot)$ 表示将时间维度和通道维度进行联合展开。时间投影层将历史 32 帧对应的时序特征映射为未来 16 帧对应的潜在表示。该设计将时间长度变换集中在投影层中完成，使空间编码器始终只承担逐帧空间表征学习任务，避免在编码阶段过早压缩或混合时间信息。

最后，空间解码器将未来潜在特征恢复到原始格点分辨率。设时间投影后得到的未来潜在特征序列为：

$$V = \{V_1, V_2, \dots, V_{16}\} \quad (11)$$

则每一个未来时刻的输出可表示为：

$$\hat{Y}_k = \text{Decoder}(V_k, X_k), k = 1, 2, \dots, T_{16} \quad (12)$$

其中， $\text{Decoder}(\cdot)$ 表示空间解码器， X_k 表示与解码过程对齐的浅层空间跳跃连接特征。跳跃连接能够缓解下采样造成的细节损失，使预测结果在恢复整体空间结构的同时保留更清晰的局地分布特征。经过特征融合和输出卷积后，模型生成未来 16 个时间步的目标气象变量场。

经过空间编码器、3D CNN 时序预测器、时间投影层和空间解码器，即可从输入历史序列 $[B, 32, C_{in}, 20, 20]$ 中得出预测结果 $[B, 16, C_{out}, 20, 20]$ 。

3.4. 预报方法

具体预报过程中，本文根据不同变量的物理属性对输入输出形式、变量变换方式和结果后处理进行

了针对性设计。本节重点说明热力变量、风场变量和降雨变量在模型输入、输出以及物理量恢复过程中的处理方式。

3.4.1. 热力变量预报

热力分支主要面向温度、相对湿度和能见度等连续气象变量。这些变量在短时尺度上通常具有较强的时间连续性和空间平滑性，适合采用时空卷积预测模型进行建模。输入端使用过去 32 个时间步的热力相关变量，模型输出未来 16 个时间步的目标变量。

由于不同变量的量纲和数值范围差异较大，本文在训练前对输入和输出变量进行标准化处理，使其处于相对统一的数值尺度。模型输出后，再根据训练阶段保存的均值和标准差进行反标准化，将预测结果恢复到真实物理单位。对于相对湿度和能见度等具有实际取值范围约束的变量，在结果分析和可视化阶段进一步进行合理范围裁剪，以避免极端异常值影响适飞判断。

3.4.2. 风场变量预报与风速风向转换

风场分支不直接预测风速和风向，而是预测水平风分量 u -wind 和 v -wind。这样处理的原因在于风向角是圆周变量，直接回归风向角会导致周期边界不连续问题。例如， 1° 和 359° 在物理上方向非常接近，但若作为普通数值进行回归，其差值会被误认为接近 360° 。相比之下，水平风分量是连续变量，更适合神经网络进行回归建模。

在数据构建阶段，若原始风场记录以风速和风向形式给出，则首先将其转换为水平风分量。本文采用气象风向定义，即风向表示风“来自”的方向。设风速为 S ，风向为 D ，其中 D 的单位为度，则其对应的水平风分量可表示为：

$$u = -S \sin\left(\frac{\pi D}{180}\right), v = -S \cos\left(\frac{\pi D}{180}\right) \quad (13)$$

其中， u 表示东西向风分量， v 表示南北向风分量。当风向为 0° 时表示北风，此时风从北向南吹，对应 $v < 0$ ；当风向为 90° 时表示东风，此时风从东向西吹，对应 $u < 0$ 。通过上述转换，风速和风向被表示为连续的二维风矢量分量，作为风场分支的输入和预测目标。

模型输出未来 16 个时间步的水平风分量后，需要进一步转换回风速和风向，以便进行结果展示、误差评估和无人机适飞判断。根据预测得到的风分量和，风速计算公式为：

$$\hat{S} = \sqrt{\hat{u}^2 + \hat{v}^2} \quad (14)$$

风向则按照气象风向定义由水平风分量反算得到：

$$\hat{D} = \left[\arctan 2(-\hat{u}, -\hat{v}) \cdot \frac{180}{\pi} \right] \bmod 360 \quad (15)$$

其中， $\arctan 2(\cdot)$ 用于根据两个风分量确定风向所在象限，取模操作用于将风向约束在 $[0, 360)$ 范围内。通过这种方式，模型训练阶段避免了风向角的周期不连续问题，而结果分析阶段仍然能够得到具有物理意义的风速和风向。

在无人机适飞分析中，风速通常比单独的风分量更直观。较大的风速会影响无人机姿态稳定性、航线跟踪精度和起降安全，因此本文在预测后统一输出 WIN_S 和 WIN_D ，并在实验部分分别展示风速和风向的预测效果。对于风向误差评估，应采用圆周角误差而不是普通线性差值，以避免 0° 和 360° 附近的误差被放大。风向误差可表示为：

$$e_D = \left[(\hat{D} - D + 180) \bmod 360 \right] - 180 \quad (16)$$

该误差被限制在 $[-180, 180]$ 范围内, 能够更合理地反映预测风向与真实风向之间的角度差异。

3.4.3. 降雨变量预报及非负变换

降雨分支采用与热力分支和风场分支一致的深度学习时空预测模型架构, 输入为过去 32 个时间步的降雨相关气象变量, 输出为未来 16 个时间步的降水量预测场。由于降雨量具有明显的非负性、稀疏性和偏态分布特征, 本文在降雨建模过程中对降雨量进行非负变换, 以降低原始降雨分布对模型训练的影响。

具体而言, 本文对降雨量采用如下对数变换:

$$\text{PRE}_{\log} = \log(\text{PRE} + 1) \quad (17)$$

该变换能够压缩较大降雨值的数值范围, 减小强降雨样本与无雨样本之间的尺度差异, 同时保证在 $\text{PRE} = 0$ 时仍然有定义。模型在对数空间中学习未来降雨场的时空演变关系, 预测结果也首先以对数降雨形式输出。完成预测后, 再通过反变换恢复为原始降雨量:

$$\text{PRE} = \exp(\text{PRE}_{\log}) - 1 \quad (18)$$

由于降雨量在物理上应为非负值, 反变换后的结果进一步进行非负约束, 将小于 0 的异常值裁剪为 0。通过对数变换和非负裁剪, 降雨分支能够在保持物理意义的同时降低训练难度, 并输出可用于降雨事件评估和适飞判断的未来降水场。

4. 模型实验与性能验证

4.1. 实验设置与评价指标

本文实验数据来自研究区域内连续一年的多站点气象观测资料。原始观测数据经过数据质量控制、时间聚合、空间格点化和样本切片后, 被构建为固定空间尺寸和固定时间长度的格点序列样本。每个样本包含过去 8 h 的历史输入序列和未来 4 h 的预测目标序列, 时间分辨率为 15 min, 空间分辨率为 20×20 格点。模型输入长度为 32 帧, 输出长度为 16 帧。

为避免相邻滑动窗口样本之间的信息泄漏, 热力分支和风场分支按照样本日期进行训练集、验证集和测试集划分。即同一天内生成的样本全部分配到同一数据子集中, 避免高度相邻的样本同时出现在训练集和测试集中。降雨分支同样基于划分后的样本进行训练与测试, 并在测试集上计算降雨强度误差和降雨事件识别指标。三组预测任务数据集样本数量相同, 其中训练集 28,080 例, 验证集 3456 例, 测试集 3408 例。

模型训练过程中, 热力分支、风场分支和降雨分支均采用第 4 章所述时空预测结构。对于热力和风场变量, 模型在标准化空间中进行训练, 预测后再反标准化恢复到原始物理单位。对于降雨变量, 模型在 $\log(\text{PRE}+1)$ 变换空间中学习降雨场变化, 预测后通过指数反变换恢复为原始降雨量, 并对负值进行裁剪, 保证输出满足降雨量非负约束。

本文采用多种指标对预测结果进行评价。对于温度、相对湿度、能见度、风速、风向和降雨强度等连续变量, 采用 MAE、MSE、RMSE 和 SSIM 进行整体误差和空间结构评价。其中, MAE 反映预测值与真实值之间的平均绝对偏差, RMSE 对较大误差更加敏感, SSIM 用于衡量预测场与真实场之间的空间结构相似性。相关公式如下:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (19)$$

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (20)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (21)$$

其中, $\hat{y}$ 和 y 分别表示真实值和预测值, N 表示参与统计的样本数量。对于风向变量, 由于其具有圆周属性, 误差计算时采用圆周角误差:

$$e_D = \left[(\hat{D} - D + 180) \bmod 360 \right] - 180 \quad (22)$$

该误差被限制在 $[-180, 180)$ 范围内, 能够避免 0° 和 360° 附近的角度误差被错误放大。由于风向为圆周变量, 本文不直接计算其普通 SSIM 指标, 而在表中以/表示。

对于降雨预测, 除连续误差指标外, 还进一步采用 CSI、POD、FAR 和 HSS 等事件型指标评价模型对降雨事件的识别能力。设 TP 表示正确预测降雨事件的格点数, FP 误报降雨的格点数, FN 表示漏报降雨的格点数, TN 表示正确预测无雨的格点数, 则相关指标定义为:

$$\text{CSI} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \quad (23)$$

$$\text{POD} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (24)$$

$$\text{FAR} = \frac{\text{FP}}{\text{TP} + \text{FP}} \quad (25)$$

$$\text{HSS} = \frac{2(\text{TP} \cdot \text{TN} - \text{FP} \cdot \text{FN})}{(\text{TP} + \text{FN})(\text{FN} + \text{TN}) + (\text{TP} + \text{FP})(\text{FP} + \text{TN})} \quad (26)$$

其中, CSI 综合考虑命中、漏报和误报情况, POD 表示降雨事件被成功识别的比例, FAR 表示预测为降雨的格点中实际未发生降雨的比例, HSS 则用于衡量预测结果相对于随机预测的改进程度。本文以固定降雨阈值将连续降雨量转换为降雨事件, 并在测试集上计算上述指标。

4.2. 性能评估

4.2.1. 整体误差评价

表 2 给出了模型在测试集上的整体预测性能。由于连续变量和降雨事件指标的含义不同, 建议将性能评估表拆分为两个子表: 表 2(a) 给出连续变量的 MAE、MSE、RMSE 和 SSIM; 表 2(b) 给出降雨事件的 CSI、POD、FAR 和 HSS。

Table 2. Model prediction performance evaluation results. (a) Continuous variable prediction error; (b) rainfall event identification indicators

表 2. 模型预测性能评估。(a) 连续变量预测误差; (b) 降雨事件识别指标

(a)					
变量	单位	MAE	MSE	RMSE	SSIM
TEM	degC	1.453	3.900	1.975	0.488
RHU	%	5.091	49.558	7.040	0.603
VIS	m	2571.038	1.348E+07	3671.902	0.807
WIN_S	m/s	0.611	0.767	0.876	0.570
WIN_D	deg	33.321	2612.639	51.114	/
PRE	mm/15min	0.136	0.064	0.283	0.390

续表

变量	(b)			
	CSI	POD	FAR	HSS
PRE	0.241894	0.384011	0.604736	0.36971

从表 2(a)可以看出,模型对温度、相对湿度、风速等连续变量具有较稳定的预测能力。温度的 MAE 约为 1.45℃, RMSE 约为 1.97℃,说明模型能够较好地刻画局地温度场的整体变化。相对湿度的 MAE 约为 5.09%,在短临气象预测场景下具有一定可用性。风速的 MAE 约为 0.61 m/s, RMSE 约为 0.88 m/s,表明模型对风速大小具有较好的回归能力。




Figure 3. Guidance time prediction accuracy plot
图 3. 引导时间预测精度图

能见度的绝对误差相对较大,这与能见度变量本身的取值范围较宽、空间变化不均匀以及局地突变性较强有关。尽管如此,能见度的 SSIM 相对较高,说明模型在一定程度上能够保持能见度场的空间结构。风向的 MAE 和 RMSE 分别反映了预测风向与真实风向之间的圆周角误差。由于风向具有周期性,本文不直接计算普通 SSIM,而采用“/”表示该指标不适用于风向场。

从表 2(b)可以看出,模型对降雨事件具有一定识别能力,CSI 为 0.242,POD 为 0.384,说明模型能够捕捉部分实际降雨区域,但仍存在一定漏报。FAR 为 0.605,表明误报现象较为明显,这与降雨事件本身稀疏、局地性强和空间位置偏移敏感有关。HSS 为 0.370,说明模型结果相较随机预测仍具有一定改进。总体来看,降雨预测难度高于温湿度和 wind 等连续变量,在适飞分析中更适合作为风险提示因子,并应结合能见度和风速等要素综合判断。

为了进一步分析模型随预报时效增加的性能变化,本文统计了各变量在 15 min 至 240 min 不同预报时效(lead time)下的预测误差,结果如图 3 所示。图 3(a)~(e)分别展示了温度、相对湿度、能见度、风速和风向的 MAE 与 RMSE 变化曲线,图 3(f)展示了降雨事件指标 CSI、POD、FAR 和 HSS 随预报时

效的变化。

总体来看,随着预报时效从 15 min 增加到 240 min,各连续变量的 MAE 和 RMSE 均呈现逐渐增大的趋势。这符合短临气象预测的一般规律,即随着预测时间延长。


历史观测对未来状态的约束逐渐减弱,模型预测不确定性不断累积。温度和相对湿度误差增长相对平稳,说明模型能够较好地捕捉其连续演变规律。能见度误差随预报时效增加也逐渐增大,表明能见度受局地天气变化影响较强,远时效预测难度更高。

风速和风向误差同样随 lead time 增大而上升。其中风速误差增长幅度较为平滑,说明模型对风速大小的变化趋势具有一定预测能力;风向误差整体高于风速误差,主要原因在于风向本身具有圆周属性,且在低风速条件下方向变化容易表现出更强的不稳定性。因此,在无人机适飞判断中,风速预测通常比单独风向预测具有更直接的约束意义。

降雨事件指标随预报时效变化表现出更明显的不确定性。随着 time 增加,CSI、POD 和 HSS 整体呈下降趋势,说明模型对降雨事件位置和发生情况的识别能力随时间延长逐渐减弱;FAR 则呈上升趋势,表明远时效下误报风险增加。这一结果与降雨本身的稀疏性和局地突发性有关,也说明在适飞分析中需要对远时效降雨预报保持一定不确定性认识。

4.2.2. 预报结果可视化

为进一步直观分析模型对不同气象要素空间结构的预测能力,本文选取测试集中的典型样本进行可视化展示,结果如图 4 所示。图中分别给出了温度、相对湿度、能见度、降雨、风向和风速在多个预报时效下的真实场和预测场对比。每个变量均包含 Ground Truth 和 Prediction 两行,用于展示模型在不同 lead time 下对气象场空间分布的刻画能力。






Figure 4. Visualization of forecast results, including 5 time steps of 15 min/60 min/120 min/180 min/240 min, Ground Truth real data, Prediction predicted values, (a) temperature; (b) relative humidity; (c) visibility; (d) rainfall; (e) wind direction; (f) wind speed

图 4. 预报结果可视化, 包含 15 min/60 min/120 min/180 min/240 min 5 个时间步, Ground Truth 真实数据, Prediction 预测值, (a) 温度; (b) 相对湿度; (c) 能见度; (d) 降雨量; (e) 风向; (f) 风速

从图 4 可以看出, 模型能够较好地保持温度和相对湿度场的主体空间分布, 预测结果在整体梯度和主要高低值区域上与真实场较为一致。对于能见度变量, 模型能够捕捉主要低能见度区域和高能见度区域的空间格局, 但局部边界和小尺度变化仍存在一定平滑现象。该现象与能见度本身空间变化复杂、受局地天气影响明显有关。

风场结果显示, 模型对风速的主要空间分布具有较好的预测能力, 能够反映局地区域内风速强弱变化。风向预测在整体方向结构上与真实场保持一定一致性, 但在局部区域仍可能出现方向偏差。由于风向具有圆周特性, 颜色图中 0° 和 360° 附近可能出现视觉上的突变, 因此对风向结果的解读应结合圆周角误差而非普通线性差值。

降雨预测结果表明, 模型能够在一定程度上识别降雨区域的位置和范围, 但相较于温度、湿度等连续变量, 降雨预测仍然更具挑战性。降雨场具有明显的稀疏性和局地集中性, 强降雨区域的边界和强度变化更难准确刻画。因此, 除连续误差外, 本文进一步使用降雨事件指标评价模型对降雨发生情况的识别能力。

综合表 2、图 3 和图 4 可以看出, 本文方法能够在统一的格点预测框架下同时生成多种关键气象要素的未来预报结果。模型对温度、相对湿度、风速等变量具有较稳定的预测能力, 对能见度和降雨等复杂变量也能够给出具有一定空间结构一致性的预测结果。这为后续基于多气象要素的无人机适飞分析提供了数据基础。

5. 结语

本文面向无人机适飞分析需求, 提出了一种多要素气象格点预报方法。针对原始多站点观测数据存在缺测、异常、空间分布不规则等问题, 构建了涵盖质量控制、时间聚合、空间格点化、Patch 切分与样本切片的多阶段数据预处理流程, 将不规则站点观测统一转换为 20×20 规则格点序列。在此基础上, 根据气象要素物理属性设计分组建模策略, 在统一时空预测框架下分别构建热力、风场与降雨分支: 热力分支对温度、相对湿度和能见度进行连续场预测; 风场分支采用水平风分量建模, 有效规避了风向角周期边界问题; 降雨分支通过对数变换与非负约束处理降雨量的稀疏性与偏态分布。实验结果表明, 模型对未来 4 h 逐 15 min 的多要素场具有稳定的预测能力, 温度、相对湿度与风速的预测误差较小, 各要素空间结构一致性保持良好。本文方法能够为无人机适飞状态的空间化分析提供多要素格点预报基础, 支撑面向航线规划与任务决策的气象保障应用。

参考文献

- [1] 钟若媚, 廖小罕, 徐晨晨, 等. 京津冀地区无人机低空航路气象环境模拟研究[J]. 气象科技进展, 2021, 11(4): 147-155.
- [2] 郭建平, 张玮, 周博闻, 等. 低空经济气象前沿科技问题研究进展与展望[J]. 气象, 2025, 51(11): 1455-1476.
- [3] 马志峰, 张浩, 刘劼. 基于深度学习的短临降水预报综述[J]. 计算机工程与科学, 2023, 45(10): 1731-1753.
- [4] 刘雅忱. 人工智能下深度学习在气象预报中应用综述[J]. 计算机产品与流通, 2020(11): 121, 135.
- [5] Gao, Z., Tan, C., Wu, L. and Li, S.Z. (2022) SimVP: Simpler Yet Better Video Prediction. 2022 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, 18-24 June 2022, 3160-3170. <https://doi.org/10.1109/cvpr52688.2022.00317>
- [6] Shi, X., Chen, Z., Wang, H., et al. (2015) Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. *Proceedings of the 29th International Conference on Neural Information Processing Systems*, Montreal, 7-12 December 2015, 802-810.
- [7] Gao, Z., Shi, X., Wang, H., Zhu, Y., Wang, Y.Y., Li, M., et al. (2022) Earthformer: Exploring Space-Time Transformers for Earth System Forecasting. *Advances in Neural Information Processing Systems* 35, New Orleans, 28 November-9 December 2022, 25390-25403. <https://doi.org/10.52202/068431-1841>

-
- [8] Zhang, Y., Long, M., Chen, K., Xing, L., Jin, R., Jordan, M.I., *et al.* (2023) Skilful Nowcasting of Extreme Precipitation with Nowcastnet. *Nature*, **619**, 526-532. <https://doi.org/10.1038/s41586-023-06184-4>
 - [9] Gao, Z., Shi, X., Han, B., Wang, H., Jin, X., Maddix, D., *et al.* (2023) PreDiff: Precipitation Nowcasting with Latent Diffusion Models. *Advances in Neural Information Processing Systems* 36, New Orleans, 10-16 December 2023, 78621-78656. <https://doi.org/10.52202/075280-3439>
 - [10] 林磊, 任义方, 张建飞, 等. 气象观测数据质量控制方法的探讨[J]. 农业与技术, 2018, 38(17): 126-127.
 - [11] 范文波. 地面气象观测数据综合质量控制方法研究与实现[D]: [硕士学位论文]. 南京: 南京信息工程大学, 2016.
 - [12] 刘玉. 协同 ERA5 数据的江苏省降水量空间插值研究[J]. 水利科技与经济, 2025, 31(1): 37-40.
 - [13] 钟雨萍. 基于机器学习的城市风场时序预测与空间插值[D]: [硕士学位论文]. 北京: 中国科学院大学(中国科学院深圳先进技术研究院), 2021.
 - [14] 张延彪, 陈明轩, 韩雷, 等. 数值天气预报多要素深度学习融合订正方法[J]. 气象学报, 2022, 80(1): 153-167.
 - [15] 王军, 陈百艳, 程勇. 基于多任务长短时卷积计算网络的降雨预测[J]. 计算机工程与设计, 2022, 43(9): 2686-2693.
 - [16] 马景奕, 刘维成, 闫文君. 基于深度学习的气象要素预测方法[J]. 热带气象学报, 2021, 37(2): 186-193.
 - [17] 陈学君, 苏仲岳, 李仲龙, 等. 年降水量数据的正态变换方法对比分析[J]. 干旱气象, 2012, 30(3): 459-464.
 - [18] 孙越, 王海军, 周月华, 等. 三种插值方法对区域自动气象站日气温缺测数据插补的适用性研究[J]. 暴雨灾害, 2023, 42(1): 97-104.
 - [19] 宋林烨, 杨璐, 程丛兰, 等. 不同模式背景场对复杂山地百米级温度和风场融合预报影响的对比[J]. 大气科学, 2025, 49(3): 681-698.