

基于序列融合编码器的冬季降水相态

深度学习预报模型研究

李明^{1,2} 谌芸² 曹恒煜¹ 尹常红³ 姚望玲¹ 王义琴³

1 武汉市气象台, 武汉 430040

2 国家气象中心, 北京 100081

3 武汉国家基本气象站, 武汉 430040

提 要: 本文构建了一种基于序列融合编码器的深度学习模型, 该模型综合了卷积神经网络、卷积门控循环单元和 Transformer 编码器的优势, 旨在提高冬季降水相态预报的精度。通过使用 2010 至 2024 年冬季 15 年间武汉逐小时降水天气现象观测资料, 以及数值预报(ERA5)再分析数据, 经过样本处理和自定义分钟级的数据增强, 有效解决了模型数据不平衡问题。实验结果显示, 模型在预报固态降水中的表现优异, 对雨夹雪和雪的预报方面均展现出了高可靠性。通过对 2024 年 2 月复杂天气过程的检验, 验证了模型在降雪预报上的高精度, 但在快速降水相态转换时暴露出一定局限。本研究尝试为冬季降水相态的深度学习预报提供一种高效、智能的解决方案, 以提高台站雨雪相态预报能力。

关键词: 序列融合编码器, 冬季降水相态预报, 深度学习, 数据增强

中图分类号: P456

文献标志码: A

doi: 10.7519/j.issn.1000-0526.2025.071101

A Deep Learning Prediction Model for Winter Precipitation Types Based on Sequential Fusion Encoder

Li Ming^{1,2} CHEN Yun² CAO Hengyu¹ YIN Changhong³ YAO Wangling¹ WANG Yiqin³

1 Wuhan Meteorological Observatory, Wuhan 430040

2 National Meteorological Center, Beijing 100081

3 Wuhan National Basic Meteorological Observing Station, Wuhan 430040

Abstract: This paper constructs a deep learning model based on a sequence fusion encoder. This model combines the advantages of the convolutional neural network, the convolutional gated recurrent unit and the Transformer encoder, aiming to improve the accuracy of winter precipitation phase prediction. By using the hourly precipitation weather phenomenon observation data in Wuhan during the 15 winters from 2010 to 2024, as well as the Numerical Weather Prediction (ERA5) reanalysis data, and through sample processing and customized minute-level data

augmentation, the problem of model data imbalance has been effectively solved. The experimental results show that the model performs excellently in predicting solid precipitation and demonstrates high reliability in both sleet and snow forecasts. Through the verification of the complex weather process in February 2024, the high precision of the model in snowfall forecasts has been verified, but certain limitations have been exposed when the precipitation phase changes rapidly. This research attempts to provide an efficient and intelligent solution for the deep learning prediction of winter precipitation phases, so as to improve the precipitation phase prediction ability of rain and snow at meteorological stations.

Key words: sequential fusion encoder, winter precipitation type prediction, deep learning, data augmentation

引 言

降水相态的准确预报对于防灾减灾、农业生产规划、水资源管理及城市基础设施建设等方面具有至关重要的意义。特别是在冬季，降水相态的突然转变，往往会给社会经济带来不可预见的影响，如 2024 年春节前后在湖北省发生的两次雨雪冰冻天气，其间频繁出现雨、雪、冻雨、冰粒等形式的降水相态转换（俞小鼎等，2024），低温雨雪冰冻天气导致道路结冰从而出现大范围交通瘫痪。因此，发展高效、精准的冬季降水相态预测技术，已成为气象科学和应用领域亟待解决的关键课题之一（赵俊虎等，2025）。

传统的降水相态预报主要依赖于数值天气预报模型和统计学方法，往往使用地面至 850 hPa 温度、中底层位势厚度、0 °C 层高度等因子判别降水相态（仇会民，2023）。这些方法虽然在一定程度上能够提供初步的预测信息，但在面对复杂多变的天气系统时，其预报精度和时效性往往难以满足实际需求（Liu Y, et al, 2019; 徐红等，2023; 孙卉等，2024）。Ahrens C D 总结提出（Ahrens C D, 2000）“Top-Down Approach”降水相态分析法，其基本思路为：当大气环境已经具备了产生降水的基本条件时，通过从大气顶部开始，逐步追踪水汽凝结物的运动轨迹直至地面，可以有效地解析降水相态的演变过程。这一方法特别注重温度阈值的判断，尤其是在温度低于 -10 °C 的湿层和高于 0 °C 的暖层中，以及近地面冷层的状态分析，这些关键层的温度分布和厚度直接决定了降水到达地面时的相态。这些方法在实际应用中也取得了一定的效果（褚芸欣等，2023）。

近年来，随着人工智能技术的迅速发展，机器学习在气象业务工作中得到了广泛的应用。常见的使用卷积神经网络（CNN，Convolutional Neural Network）对卫星、雷达图像进行处

理，以预报短期降雨量和降水类型（Shi X, et al, 2015）；利用门控循环单元和长短期记忆网络（LSTM, Long Short-Term Memory）处理时间序列数据提高长期天气预报的准确性（黄天文等, 2024）；Transformer 模型也被引入到气象预报中，用于处理序列数据，尤其是在长期依赖性预报方面（Vaswani A, et al, 2017）。在降水相态预报的具体应用中，已有研究利用深度学习技术来区分雨、雪或雨夹雪等不同降水类型，通过分析气象雷达数据、卫星图像和其他气象变量（黄骄文等, 2021；赵渊明等, 2024；曾小团等, 2025）。

每种机器学习模型都有自身的优势和适用范围，如卷积神经网络适用于图像处理和识别；循环神经网络（RNN, Recurrent Neural Network）具有内部记忆功能，可以捕捉到输入数据中的时间依赖关系，在处理语言、语音、时间序列等序列数据方面特别有效（LeCun Y, et al, 2015）。为了充分发挥各种模型的特点，根据实际需要使用多个模型形成深度学习组合模型，以充分挖掘研究对象之间的内在联系，已成为当前的研究热点之一（杨子幸, 2023）。本文主要研究各气象要素对降水相态的影响，由于以往研究的缺点在于多数是静态分析、计算单个站点的部分地面、高空气象要素的空间分布、指标阈值等，处理高维空间数据时效率较低，且对空间特征的捕捉能力相对较弱。本文为了实现对时间依赖性和空间相关性的有效捕捉，尝试使用 CNN、RNN 及注意力机制等多种深度学习方法（Mohammed J& Mohsen G, 2024），完成对降水相态数据更全面、深入和精准的特征提取，试图寻找一种更为精细的降水相态订正预报方法。

1 模型设计

本文提出一种冬季降水相态预报模型（以下简称模型），主要利用深度学习技术在自动学习和提取数据中的复杂特征，处理非线性的关系，以及大规模数据集的高效计算能力。

1.1 结构设计

采用 CNN 提取出输入数据每个格点及其局部邻域的特征信息，如降水数据的空间分布、强度变化趋势等局部特征，以捕捉雨、雪、雨夹雪等不同降水相态在空间分布上可能存在的差异。通过卷积操作，CNN 可以在一定程度上平滑降水数据可能存在的噪声和异常值噪声，减少异常值对分析结果的影响，从而更好地提取出有效的特征。

采用卷积门控循环单元（ConvGRU, Convolutional Gated Recurrent Unit）。ConvGRU 则是在 CNN 的基础上增加了时间序列分析的能力（图 1）。




图 1 卷积门控循环单元架构示意图

Fig.1 Schematic diagram of the convolutional gated recurrent unit (ConvGRU) architecture

GRU 是一种循环神经网络（RNN）的变体，通过更新门和重置门控制信息的流动。ConvGRU 是一种用于处理时空序列数据的递归神经网络，它结合了卷积操作和 GRU 机制，在每个时间步上更新隐藏状态，学习降水数据在时间维度上的变化规律（林靖皓等，2021），比如降水强度的连续变化、降水区域的移动等。对于输入格点数据的时间序列，ConvGRU 可以捕捉到每个格点位置上降水随时间的变化情况，为降水相态的分析提供时间维度的信息支持。相比传统 RNN，ConvGRU 在处理长期依赖关系时表现更好，能够有效地避免梯度消失或梯度爆炸的问题。

引入 Transformer 模块，Transformer 的核心是自注意力（Self-Attention）机制，它允许模型关注输入序列中的所有位置，并确定它们之间的权重（图 2）。




图 2 Transformer Encoder 架构示意图

Fig.2 Schematic Diagram of the Transformer Encoder Architecture

Transformer 中的多头注意力机制允许模型从不同的角度关注输入序列（贺琳等，2021），Transformer 擅长对全局信息进行建模，通过自注意力机制，可以计算每个位置与其他位置之间的关联程度，如影响系统的整体结构、降水空间分布等全局特征，从而捕捉到局部降水的全局特征依赖关系，为降水相态的分析提供更全面的视角。且 Transformer 具有良好的并行计算能力，可以在较短的时间内处理大量的数据，提高分析的效率。

以上述这种混合架构构成序列融合编码器（SFE，Sequential Fusion Encoder），CNN、ConvGRU 和 Transformer 三种模型的结合，通过 CNN 提取的局部特征、ConvGRU 学习的时间序列信息以及 Transformer 捕捉的全局信息相互融合，从气象要素随时间变化和不同

气象要素之间的相互作用等不同的角度对数据进行分析和处理,为降水相态分析提供更丰富、更全面的特征表示,减少数据异常值、噪声等因素对分析结果的影响,提高分析的准确性和模型的鲁棒性(申晋祥和鲍美英,2021)。

1.2 流程设计

数据流经模型的过程如图 3:

(1) 输入数据准备

输入数据预期形状为(batch_size, seq_length, Input_Channel, Data_Height, Data_Width)。

(2) CNN 处理

CNN 通过二维卷积层、批量归一化层和最大池化层提取各输入二维气象要素场数据空间的深层特征:深度可分离卷积模块(DepthWise Separable ConvBlock)以减少计算量和模型参数、降低计算复杂度,每个模块包含 1 个深度卷积和 1 个逐点卷积;多级卷积和池化层(kernel_size=3, padding=1, stride=2<MaxPool>)逐步升维提取特征; 1x1 卷积调整最终输出通道数以适配后续的 ConvGRU 输入要求。设置根据输入数据和硬件情况设置 batch_size=24, seq_length=1。

(3) ConvGRU 处理

序列数据的时间维度组件对 CNN 提取的特征进行序列建模。ConvGRU 堆叠多个 ConvGRUCell 构成循环单元,每个 ConvGRUCell 包含门控机制(更新门、重置门)来控制信息流,使用卷积操作代替全连接。主要参数设计为:隐藏状态维度(hidden_dim)与输入维度相同;小卷积核(kernel_size=3)以避免显著增加计算负担;2 层堆叠(num_layers=2)避免导致梯度消失;采用 Sigmoid 激活函数将值压缩到[0, 1]之间,控制前一时刻的状态对当前时刻状态的影响程度,以捕捉时间依赖关系。

(4) Transformer Encoder

ConvGRU 输出经过重塑和转置形状为 (batch_size, Height*Width, d_model=512)以输入 Transformer Encoder。Transformer Encoder 层的作用是进一步处理序列数据,将输入数据沿空间维度展平,通过适配层调整至 d_model 的大小,捕捉各输入因子之间的全局依赖关系。数据由 6 层堆叠的 Transformer_Layers 变换器编码层处理,每层包含多头注意力机制和前馈网络,其中前馈神经网络采用 ReLU 激活函数以增强模型的表达能力。每个 Transformer 编码层在其多头注意力机制中使用 Num_Heads(8)个头,并且具有 FeedForward_Dim 的前馈维度。Transformer Encoder 层进一步增强了模型的能力,使模型能够关注并理解序列中各预报因子之间的复杂关系。

(5) 重新塑造用于反卷积并输出

Transformer Encoder 之后，输出数据被重新塑形回 2D 张量，转置卷积（反卷积）层采用 ReLU 函数在特征图上采样回原始或期望的分辨率。最终输出具有 Output_Channels 个通道的图形或单点的分类计算结果。




图 3 模型结构及数据流向设计

Fig.3 Design of model architecture and data flow direction

模型使用多分类交叉熵（Multi-class Cross-Entropy）损失函数。多分类交叉熵是深度学习中最常用的损失函数之一，尤其适用于处理具有多个类别的分类任务（Liu J et al, 2020）。此外在整个模型中根据数据和计算结果对上述过程中提及的各参数动态调整，并以 Dropout_Rate 的概率随机进行正则化以防止训练过程中的过拟合，同时利用反向传播算法，自动调整其参数，以最小化预报误差，从而在预报冬季降水相态时展现出更高的精度和鲁棒性（戈苗苗等，2021）。

2 资料处理

2.1 资料来源

武汉国家基本气象站（站号：57494）为武汉市代表站，2010 年在武汉市东西湖区新址（114.03 E，30.36 N）正式启用。根据观测数据统计，武汉站降雪初日历年平均为 12 月 20 日，终日为 2 月 21 日，年均降雪日数 9 天。本文选择 2010 年至 2024 年 1、2、12 月（2024 年仅 1、2 月）武汉市国家气象观测站的逐月报表数据（A 文件）和中国气象局的地面气象

站逐小时观测资料进行统计分析，两种数据互为补充订正，确保数据的准确和完整。

选择 ERA5 数据集提供的高分辨率的气象要素资料，包括温度、湿度、风速等，地理网格分辨率为 $0.25^{\circ} \times 0.25^{\circ}$ ，时间分辨率为 1 小时。

2.2 数据预处理

对各数据进行标准化处理，使之适用于深度学习模型的输入要求。预处理主要包括归一化、重编码和插值三个步骤。

归一化：采用 Min-Max 归一化方法，将各气象要素映射至[0,1]区间，消除不同量纲和数量级的影响，确保模型训练的稳定性和预报的准确性。

重编码：天气现象的编码需要转换为适合深度学习的格式。根据不同的降水相态，参考 EC 相态实况制定相应的天气现象编码分类（表 1），以便模型能够正确识别和处理。

表 1 不同降水相态对应的天气现象编码分类

Table 1 Weather code corresponding the precipitation types			
分类代码	降水相态	天气现象编码	EC 相态编码
3	雪	22, 26, 70~79, 85~88, 93~94	3, 4, 5, 6, 7, 12
2	雨夹雪	23, 68~69, 83~84, 89~90, 95, 97	2, 11
1	雨	20~21, 24~25, 50~67, 80~82, 91~92	1, 10
0	无	除以上外其它编码	0, 8, 9

插值：为了填补数据缺失和实现空间数据的一致性，采用 Cubic 插值方法。这是一种三次样条插值，能够提供平滑且自然的曲线，特别适用于时间序列数据和需要保持数据连续性的场景（Martín-Gil J, et al, 2019）。插值后的数据均转换为 $113.5^{\circ} \sim 115.5^{\circ} \text{E}$ ， $29.5^{\circ} \sim 31.5^{\circ} \text{N}$ 范围内经、纬度均为 0.01° 间隔的格点数据，以匹配模型的输入要求。

2.3 检验方法

（1）模型评价

采用准确率、召回率以及 F1 分数等评估指标以衡量模型性能。以模型预报结果与实际标签的比较，引入以下评估分类模型性能的基础概念：

根据真正例（TP, True Positives）、真负例（TN, True Negatives）、假正例（FP, False Positives）、假负例（FN, False Negatives）计算得到模型评价指标（袁凯等，2022）见表 2。

表 2 模型评价指标

Table 2 Model evaluation metrics		
指标	计算公式	说明
准确率 (A)	$(TP+TN) / (TP+FP+FN+TN)$	计算所有预报正确的样本数量占总样本数的比例来反映模型的整体精度

精确率(P)	$TP/(TP+FP)$	模型在正例预报上的准确性
召回率(R)	$TP/(TP+FN)$	所有实际正例中被模型正确识别为正例的比例
F1 分数 (F ₁)	$2 * (Precision * Recall) / (Precision + Recall)$	寻找精确率和召回率的最佳平衡点，展现模型的综合性能

以上指标的取值范围均为[0,1]，值越接近 1 表示模型在相应方面的性能越好。

（2）预报检验

本研究的主要目的是提高出现固态降水时相态变化的精准预报能力，以更好地适应气象服务的实际工作需求，同时考虑到预报为小范围、逐小时/分钟的时空分辨率，表 2 中模型评价指标并不能完全满足预报检验的需要，因此参考中国气象局短期天气预报评定标准，制定模型相态预报评分标准见表 3。

表 3 预报准确率（Fa）评分标准

Table 3 Forecast verification scoring criteria compared with actual conditions

实况预报	0	1	2	3
0	1	0	0	0
1	0	1	0	0
2	0	0	1	1
3	0	0	1	1

按照表 3 计算得到的得分之和除以预报样本数，即为预报得分，取值范围为[0,1]。可分别计算分类、总体的预报得分，得分越接近 1，说明预报准确率越高。与表 3 相比，此评分标准中主要是略降低了对类别 2、3 的判别要求，即预报为雨夹雪/雪，实况出现雪或雨夹雪，均判定为正确（得 1 分），主要是因原始数据质量（A 文件天气现象中有部分时段有重叠）和气象服务实际工作需求所致。

3 预报因子选择

统计武汉市 2010 年至 2024 年 1、2、12 月地面观测记录，按武汉站冬季降水雨、雨夹雪、雪三种类型进行统计分析。

3.1 气象要素特征分析

应用 00、12 时（世界时，下同）高空探测资料、地面观测资料，参考以往研究（陈双等，2019；王珊珊等，2023）成果，对各类降水相态在发生前、发生过程中从地面到高空各层温度、湿度、位势高度等要素进行计算和分析，计算得到武汉冬季不同降水相态类型气象要素平均值见表 4。

表 4 武汉站冬季不同相态降水气象要素各层特征值

Table 4 Statistical characteristics of every levels for winter precipitation at Wuhan

固定层	雨			雨夹雪			雪		
	温度(°C)	相对湿度(%)	高度(m)	温度(°C)	相对湿度(%)	高度(m)	温度(°C)	相对湿度(%)	高度(m)
500hPa	-14.3	39.4	5705	-16.4	47.8	5657	-17.4	41.9	5630
700hPa	-0.2	72.7	3078	-4.0	74.3	3056	-6.6	58.8	3044
850hPa	4.4	76.9	1506	-4.3	78.0	1522	-7.4	67.5	1529
925hPa	6.2	77.6	814	-3.1	79.7	854	-5.2	68.5	867
1000hPa	8.5	80.5	173	-0.2	78.4	234	-1.8	68.0	251
2m	9.0	85.5	1018.8(hPa)	1.3	84.5	1027.1(hPa)	-0.4	80.2	1029.4(hPa)

由表 4 可知，武汉冬季出现不同降水相态时的气象要素空间分布的不同主要表现在：温度：雨天各层温度较高，而雪天则温度较低，特别是在 925hPa 及以上层。雨天的最高温度约为-14.3℃，而雪天的达到-17.4℃。湿度：雨天的相对湿度最高，尤其是中低层(850-700hPa)，而雪天的湿度普遍较低，尤其是高空。

气压和位势高度方面的差别也比较明显：雪天的地面气压最高，与冷高压南侵的天气系统相关，而雨天的地面气压最低。雪天的 500hPa 和 700hPa 高度最低，降雪通常受到高空低槽或低涡的影响。在近地层到低层（1000~850hPa），雨夹雪和雪天的高度相对较低，地面到大气低层受冷高压控制。

3.2 预报因子确定

对于冬季降水相态的预报研究，漆梁波（漆梁波和张瑛，2012）总结了一套适合中国东部的冬季降水相态识别判据，主要以 700~1000hPa 各固定层位势高度和温度之间的差别作为判断条件，设定雨雪区分阈值。王珊珊（王珊珊等，2022）使用地面以上至 400hPa 附近各层的位势高度、温度、湿度等数据，利用机器学习算法对长江中游冬季降水相态预报方法进行研究，也取得了较好的效果。而陈媛（陈媛等，2024）通过对西南地区一次典型雨雪冰冻复合极端灾害天气事件的环流特征及降水相态差异分析发现，雨雪区和冰冻区的温度层结和垂直速度存在差异，降雪区以弱的向上正浮力为主要特征，降雨（冻雨）区上空的浮力在总向下的扰动气压梯度力和向上浮力相互平衡作用下，大气中低层垂直运动变化较小。

基于上述研究以及对武汉站地面和高空气象要素分布特征的分析，本文选择了 ERA5 数据集中包含的 9 层（500，600，700，800，850，900，925，950，1000hPa）的气温、位势高度、比湿、风向、风速、垂直速度，以及地面气温、海平面气压、相对湿度、露点温度、风向和风速等共计 60 个通道的格点数据作为预报因子输入。这些预报因子覆盖了大气垂直剖面的多个层次，基本能够表现“Top-Down Approach”降水相态分析法所要求的影响降水相

态形成的关键气象条件特征。

4 模型建立

4.1 样本选取和数据增强

选取 2010~2024 年共 15 年期间每年的 1、2、12 月武汉站逐小时降水天气现象观测逐小时资料，共 31767 个逐小时样本数据集中，雨、雨夹雪、雪样本数分别为 2434、82、346 例，各样本绝对数量显示数据集存在着明显的数据失衡。

定义武汉站月报表 A 文件中 W0 段天气现象记录时间段为一个降水阶段，统计得到武汉站此期间雨、雨夹雪、雪的出现次数分别为 1310、120、143 次，各降水阶段平均持续时长分别为 78.3、27.9、137.1 分钟。基于此本文采用了以下方法实现数据增强：

(1) 根据 24 小时雨量 $R_{24} > 0.0\text{mm}$ 或 A 文件中有降水时间段记录选择 394 个降水日 0~23 时的逐小时数据（简称小时数据）形成初始样本序列；

(2) 按 A 文件中天气现象记录起止时间，以雨 30 分钟、雨夹雪 1 分钟、雪 5 分钟（简称分钟数据）的时间间隔进行重新采样，重点对雨夹雪、雪两种相态进行数据增强。记录时段小于时间间隔的，将该降水记到最近的一个采样时间点，补充到降水相态时间序列。如分钟数据与小时数据有冲突，以分钟数据为准；天气现象时段有重叠的，按表 1 取其中较高类别记录。

(3) 采用三次样条方法对 ERA5 各要素再分析资料进行插值，得到上述样本对应时次地面、高空要素预报因子的格点场。

需要说明的是，2012 年 2 月以后 A 文件中没有在 W0 段中记录每天 12 时至次日 00 时天气现象时段，因此 2012 年以后的样本没有得到相应时段的数据增强。

经以上步骤最终得到样本数为 19932 个，无雨、雨、雨夹雪、雪的样本数分别为 6123、6421、3183、4205 个，占比 30.7%、32.2%、16.0%，21.1%。各样本数量比例分布见图 4。




图 4 数据增强前后样本数量比例分布

Fig.4 Distribution of sample percentages before and after data augmentation

从图 4 可见，数据增强处理明显增加了雨、雨夹雪和雪类别的样本数量，各类别样本数占比趋于平衡。这将有效增强模型对少数类别样本的识别能力，同时计算表明，数据重复率

在 0.5%以下，数据的多样化也有助于提高模型的整体泛化能力，以及降低过拟合的风险。

4.2 训练与验证

以武汉站地理坐标为中心，在 X、Y 轴方向选取 ± 32 个格点组成 64×64 个空间格点数据。考虑到输入数据时间分辨率为 1 分钟~1 小时，此空间范围应能足够表现天气影响时间范围内目标点周边地面观测和高空气象要素空间分布特征。

因 19932 个样本时间不完全连续，故设时间步长 Time_Step=1，以 80%:20%比例生成训练集和验证集，输入模型进行训练和验证得到准确率为 0.86，其它指标情况见表 4。

表 5 模型训练和验证结果

Table 5 Model training and validation results

分类	P		R		F ₁		Fa	
	训练	验证	训练	验证	训练	验证	训练	验证
0	0.78	0.63	0.73	0.58	0.75	0.52	0.73	0.51
1	0.79	0.67	0.79	0.61	0.79	0.55	0.81	0.64
2	0.9	0.81	0.92	0.74	0.92	0.67	0.93	0.73
3	0.91	0.82	0.92	0.75	0.93	0.68	0.92	0.72
平均	0.85	0.73	0.84	0.67	0.85	0.61	0.85	0.65

根据表 5 的结果来看，模型整体准确率达到 0.85，表明模型在预报降水形态时具有较好的可靠性。细化到具体相态，对于类别 2（雨夹雪）和类别 3（雪），模型的精确度与召回率达到 0.90 至 0.95，对应的 F1 也十分突出，位于 0.92 和 0.93 之间。这一结果显示模型在识别这两种类型时的预报准确性高而且几乎无遗漏的特点。表 5 显示模型在验证集上各指标均明显低于训练集 10~20%，表明模型的泛化能力还需提高。

采用主成分分析（Principal Component Analysis, PCA）提取每个要素场的特点，利用随机森林（Random Forest, RF）对各要素数据属性进行分析和预测（何恩业等，2023）方法（简称 PCA-RF）作为模型对比。结果显示（表略），PCA-RF 方法在训练集上各指标较模型得分略高 4~7%，但在验证集上不仅显著低于训练集，而且明显低于模型的验证集得分。相对于以小时数据为基础，采用 SMOTE（Synthetic Minority Oversampling technique）等解决数据不平衡问题（R.Rajakumar and Devi S,2024）的方法，同样条件下模型训练及对逐小时数据验证的结果显示，无雨准确率达到 0.91，雨准确率略有上升为 0.80，但雨夹雪、雪的准确率显著下降到 0.53、0.47。这说明本文采用的以分钟数据进行数据增强的方法，具有较短时间间隔，过采样得到的样本具有更好的真实性，预报因子插值形成新的格点时间序列数据，也避免了大量重复数据的情况，能够更好地满足降水相态预报分析的需要。

对于标记为类别 0（无雨）与类别 1（雨），模型的精确度和召回率分别为 0.78 与 0.79，这表明在处理这类相态时，模型虽能做出相对准确的判定，但存在一定程度的不确定性。本文主要目的是分析冬季降水的相态变化，因此降雨类别中包含了天气观测记录中的毛毛雨、冻雨等。鉴于降雨相态的多样性，一般来说可以通过增加更多的子类别来细化降雨分类标准，相较于 EC 实况分类达到 12 类，本文所使用的样本质量和数量尚不足以支撑更为精细的降雨分类标准，从而导致模型难以更进一步深入分析数据内在复杂性。

5 典型个例检验及分析

5.1 天气形势

2024 年 2 月 1 日~2024 年 2 月 6 日，受高空低槽、中低层切变线和地面冷空气南下影响，武汉市出现了明显降雪降温天气过程；2 月 3 日 00 时，850hpa 以下北风逐渐减弱，850hpa 以上的湿层逐渐变得深厚。至 3 日 12 时，武汉上空 850hPa 至 700hPa 附近存在明显的逆温层，整层温度均在 0℃线。850~700hpa 西南急流发展（图 5a）建立了水汽通道，800hpa 急流中心达 20m/s；武汉（图 5 中 o 处）处于急流出口的左侧；冷空气继续南下，地面偏北风（图 5b）使低层冷垫逐渐增厚，导致武汉出现大范围降雪。




图 5 武汉市 2024 年 2 月两次天气过程天气形势

a:2024 年 2 月 3 日 00 时 850hpa 位势高度，800hpa 风，850hpa 比湿； b:2024 年 2 月 3 日 00

时海平面气压, 10 米风, 2 米温度; c:2024 年 2 月 21 日 00 时 850hpa 位势高度, 800hpa 风, 850hpa 比湿; d:2024 年 2 月 21 日 00 时海平面气压, 10 米风, 2 米温度

Fig.5 Weather conditions during two weather processes in Wuhan in February 2024.

a: Geo-potential height at 850 hPa, wind at 800 hPa, and specific humidity at 850 hPa, 2/3/2024 00:00; b: Sea level pressure, wind at 10 meters, and temperature at 2 meters, 2/3/2024 00:00; c: Geo-potential height at 850 hPa, wind at 800 hPa, and specific humidity at 850 hPa, 2/21/2024 00:00; d: Sea level pressure, wind at 10 meters, and temperature at 2 meters, 2/21/2024 00:00.

2024 年 2 月 19 日 00 时-25 日 00 时, 受地面强冷空气、高空波动、中低层切变线和西南急流影响, 武汉又出现了一次强寒潮大风、强对流和持续性低温雨雪冰冻天气过程。2 月 21 日 00 时, 随着 850hPa 上 0°C 线南压至江汉平原-鄂东一带, 925hPa 温度降至 -6°C, 但 700hPa 一直在 3°C 左右, 融化层始终存在, 随着 0°C 线继续向南推进, 融化层厚度出现变化, 期间也出现了含冰粒的雨夹雪。21 日开始中底层急流南压(图 5c), 武汉市位于急流左侧和 850hPa 切变线附近。由于北方不断有冷空气补充南下(图 5d), 武汉市一直处于冷舌范围, 21 日晚冷空气强度相对较强, 21-22 日也是此轮大到暴雪过程的最强发生时段。强冷空气南下和发展旺盛中低层暖湿气流共同影响, 导致两次过程中均出现雨雪相态频繁转换情况, 其中以 2 月 3 日和 2 月 21 日两天降水相态最为复杂。

5.2 预报检验

采用中国气象局逐日下发的地面、高空实况资料, 结合 ECMWF 每日 12 时细网格产品中未来 24 小时逐小时的气象要素场数据, 用前述插值方法生成输入数据, 对 2024 年 2 月 3 日、2 月 21 日 00~12 时降水资料分别进行检验, 以武汉站对应的观测数据作为对比。

天气现象观测记录显示, 2024 年 2 月 3 日 00~12 时, 在 00:00~02:19 期间出现持续降雪, 后续在 02、03、04、05、07、08、11 时分别出现了 7 段降雪过程, 但持续时间均较短, 仅为 1~9 分钟; 雨夹雪分别在 01、04、08 时出现了 4 段, 持续时间为 3~9 分钟; 其间夹杂出现 4 段降雨过程, 每段时长为 1~41 分钟不等。

2024 年 2 月 21 日, 在 09:51~10:11 出现持续降雪, 另外在 00、02、03、06 时出现短时降雪, 持续时间 1~6 分钟; 雨夹雪有 00、01、03、09~10 时出现了 4 段, 其中 09~10 时的记录与降雪事件记录部分重叠; 00~01、10 时出现间断降雨, 02:22~03:00 出现毛毛雨。两日实况与预报对比见图 6。




图 6 武汉站 2024 年 2 月 3 日 (a)、21 日 (b) 0-12 时降水相态实况预报对比

Fig.6 Comparison of actual and forecast precipitation phase from 0~12 h in Wuhan on Feb.3 (a) and Feb.21 (b), 2024

模型在两个预报时段的精确率分别为 0.73、0.76，预报评分为 0.75、0.77。与此相对应，2 月 3 日 EC 预报结论为武汉站的降水相态均为雪，没能准确反应出复杂相态转换过程；且预报降水中心强度和落区均出现了偏差。2 月 21 日 EC 较为准确预报了 00 时适宜降雨（冻雨）的温度廓线以及转雨的时间，但对后续的雨夹雪、雪的预报错误。在两个检验时段中本模型对连续降水的相态预报结论与实况基本匹配，表明模型在预报降雪时具有较好的准确性。对于较长时间的稳定性降雪过程来说，如武汉站 2 月 4 日 00~12 时均以降雪为主，其间仅有 9:48~10:03、9:52~9:59 短暂出现雨夹雪、雨天气。对于此段降雪过程，本模型和 2024 年 2 月 4 日 00 时起报的 EC 逐 3 小时降水相态预报产品的结论均为降雪，没能准确区分其中短时相态的变化。

检验阶段模型总体得分不高，相较训练验证得分有明显下降。主要是模型高度依赖数值产品对天气形势和气象要素场预报，数值模式对天气系统描述的精准程度直接影响模型预报准确率。对比实况来看，EC 对 2 月 3 日（图略）500hPa、700hPa 的高空低槽、中底层切变线等影响系统预报的定位往西、北方向偏差，导致强降水中心落区预报较实况偏西北。对于 20~21 日（图略）的降水，EC 预报 500hPa 高度场低槽偏强；预报 700hPa 急流中心风速达 20m/s，实际风速为 16m/s；预报武汉站附近 850hPa 温度偏低。

此外，模型对短时的相态快速转变时段识别能力不足。从天气现象记录中可以看到，2 月 3、21 日均有多次持续时长不到 10 分钟的短时降雪、雨夹雪阶段，这些记录在小时数据中无法体现，样本时间精度不足可能是以往以小时数据为对象的研究难以有效提高准确率的主要原因。比较而言，本模型对短时降水过程有一定的识别能力，只是在起止时间上有一定

的偏差,说明模型对短时降雪和相态转换时间点的预报存在局限性,泛化能力有待进一步提高。综上所述,本模型所使用的方法应在分钟级观测数据和数值模式的基础上,作为数值模型输出结论冬季降水相态定点短时预报的补充方能取得最好的效果。

6 结论及讨论

本文通过利用 CNN 空间感知能力、ConvGRU 时间序列处理能力、Transformer 中注意力机制和并行计算优势,通过多层编码器协作,实现对降水相态数据的多层次特征提取,开发了一种基于序列融合编码器的深度学习模型。尤其是引入注意力机制后,不仅能够捕捉各气象要素的空间关联性以及短期波动、长期依赖,同时由于模型使用二维卷积层,不仅考虑了不同种类、层次气象要素之间相互作用的影响,同时也降低了对于硬件配置环境的要求,从而能够更好地提高冬季降水相态预报的精度。

降雪对于武汉地区来说为小概率事件,针对样本偏少、数据不平衡的情况,在 2010 至 2024 年冬季 15 年间武汉市逐小时降水天气现象观测资料和欧洲中心再分析数据(ERA5)的基础上,采用武汉国家基本气象站人工观测的天气现象记录,分别以 30 分钟、1 分钟、5 分钟的时间间隔对雨、雨夹雪、雪的降水资料进行过采样。经过模型训练和验证结果表明,这种数据增强处理有效克服了数据不平衡问题,明显提升了模型预报性能。对于冬季降水相态预报,使用分钟级数据虽然提高了计算量和预报难度,对观测数据也提出了更高的要求,但分钟级数据时间间隔短,气象要素时空分布特征影响更为显著,用于武汉站降水相态的数值预报和机器学习中较小时数据应更为有效。

通过验证数据集和对 2024 年 2 月 3 日、2 月 21 日 00~12 时两次过程的检验分析发现:模型的泛化能力还有待进一步提高,以及模型对降水相态快速转换的预报表现出了局限性,难以满足实际业务应用的需要。此外,模型高度依赖数值产品对天气形势和气象要素场预报,数值模式预报的偏差会直接影响模型预报准确率。改进的方法主要是采用更为精细的观测资料,如相控阵雷达等能够达到分钟级的观测资料和数值预报产品,构建三维卷积层等更精细的学习架构,以更准确、全面的大气真实状况提供预报支撑。

参考文献

- 陈双, 谌芸, 何立富, 等, 2019. 我国中东部平原地区临界气温条件下降水相态判别分析[J]. 气象, 45(8):1037-1051. Chen S, Shen Y, He L F, et al, 2019. Discrimination analysis of snow and rain occurring critical temperature conditions in central and eastern China[J]. Meteor Mon, 45(8):1037-1051(in Chinese).

-
- 陈媛, 周玉淑, 杨帅, 等, 2024. 西南地区一次典型冰冻雨雪复合极端灾害天气事件的环流特征及降水相态差异分析[J]. 大气科学, 48(2):417-430. Chen Y, Zhou Y S, Yang S, et al. 2024. Analysis of Circulation Characteristics and Precipitation Phase Difference during an Extreme Freezing Rain and Snow Weather Event in Southwest China [J]. Chinese Journal of Atmospheric Sciences, 48(2): 417-430 (in Chinese).
- 褚芸欣, 吴妮晏, 赵清越, 2023. “Top-Down-Approach”降水相态分析法在双流机场一次降雪过程中的应用[J]. 高原山地气象研究, 2023, 43(4):146-150. Chu Y X, Wu N Y, Zhao Q Y, 2023. Application of “Top-Down-Approach” Precipitation Phase Analysis Method on a Snowfall Process at Shuangliu Airport [J]. Plateau and Mountain Meteorology Research, 43(4):146-150 (in Chinese).
- 戈苗苗, 陆振宇, 梁邵阳, 等, 2021. 基于改进双阶段注意力机制的降水智能预报[J]. 南京信息工程大学学报 (自然科学版), 12(6):744-752. Ge M M, Lu Z Y, Liang S Y, et al, 2021. Intelligent precipitation forecast based on improved dual-stage attention mechanism [J]. Journal of Nanjing of information science & technology (Natural Science Edition), 13(6):744-752 (in Chinese).
- 何恩业, 李琼, 张聿柏, 等, 2023. 基于 PCA-BP 特征工程的近海单点海温预报技术及应用[J]. 海洋预报, 40(3):35-44. He E Y, Li Q, Zhang Y B, et al, 2023. Technology and application of offshore SST prediction based on PCA-BP feature engineering [J]. MARINE FORECASTS, 2023, 40(3):35-44 (in Chinese).
- 贺琳, 张雨, 巴韩飞, 2021. 基于注意力机制和深度学习模型的外来海洋生物命名实体识别[J]. 大连海洋大学学报, 36(03):503-509. He L, Zhang Y, Ba H F, 2021. Named entity recognition of exotic marine organisms based on attention mechanism and deep learning network [J]. Journal of Dalian Ocean University, 36(03):503-509 (in Chinese).
- 黄骄文, 蔡荣辉, 姚蓉, 等, 2021. 深度学习网络在降水相态判识和预报中的应用 [J]. 气象, 47(3):317-326. Huang J W, Cai R H, Yao R, et al, 2021. Application of the deep learning method to discrimination and forecasting of precipitation type [J]. Meteor Mon, 47(3):317-326 (in Chinese).
- 黄天文, 焦飞, 伍志方. 2024. 一种基于迁移学习和长短期记忆神经网络的降水预报方法[J]. 暴雨灾害, 43(1):45-53. Huang T W, Jiao F, Wu Z F. 2024. A precipitation forecast method based on transfer learning and Long Short Term Memory [J]. Torrential Rain and

Disasters,43(1):45-53 (in Chinese).

林靖皓,秦亮曦,苏永秀,等,2020.基于自注意力机制的双向门控循环单元和卷积神经网络的芒果产量预测[J].计算机应用,40(S1):51-55. Lin J H, Qin L X, Su Y X, et al, 2020. Mango yield prediction based on self-attention mechanism of bidirectional gated recurrent unit and convolutional neural network [J]. Journal of Computer Applications, 40(S1): 51-55(in Chinese).

漆梁波, 张琪,2012.中国东部地区冬季降水相态的识别判据研究[J].气象,38(1):96-102. Qi L B, Zhang Y,2012. Research on winter precipitation types discrimination criterion in Eastern China[J]. Meteor Mon,38(1):96-102(in Chinese).

申晋祥, 鲍美英, 2021.基于注意力机制的深度学习推荐算法[J]. 计算机系统应用, 30(6): 220-225. Shen J X, Bao M Y. Deep Learning Recommendation Algorithm Based on Attention Mechanism. Computer Systems and Applications, 2021, 30(6): 220-225(in Chinese).

孙卉,吴语燕,宣普,等,2024.池州地区冬季固态降水相态判别指标研究[J].气象与环境科学,47(2):9-15. Sun H, Wu Y Y, Xuan P, et al, 2024. Study on Phase Discrimination Index of Winter Solid Precipitation in Chizhou, Anhui Province[J]. Meteorological and Environmental Sciences, 47(2):9-15(in Chinese).

王珊珊,雷彦森,方鸿斌,等,2022.基于CatBoost算法的长江中游冬季降水相态预报方法研究[J].气象,48(9):1153-1161. Wang S S, Le iY S, Fang H B, et al. 2022. Method of winter precipitation type prediction in the middle reaches of the Yangtze River based on CatBoost algorithm[J]. Meteor Mon, 48(9):1153-1161(in Chinese).

王珊珊,钟敏,陈璇,等,2023.2022 年湖北省两次雨雪过程对比剂预报偏差分析[J].气象,49(7):819-829. Wang S S, Zhong M, Chen X, et al,2023.Comparison and forecast deviation of two snow and rain events in Hubei Province in 2022[J]. Meteor Mon,49(7):819-829(in Chinese).

徐红,房一禾,陈军庆,等,2023.辽宁地区雨雪转换天气的判别和分析.气象科学,43(2):262-269.Xu H, Fang Y H, Chen J Q, et al, 2023. Research on discrimination criterion and analysis of rain-snow weather in Liaoning. Journal of the Meteorological Sciences, 43(2): 262-269(in Chinese).

杨旗,张海鹏,吴建蓉,等,2024.对冬季云贵—华南准静止锋上一次多相态降水过程的模拟研究[J].干旱气象,42(1):75-83. Yang Q, Zhang H P, Wu J R, et al,2024. Simulation of a

-
- multi-phase precipitation process over Yungui-Huanan quasi-stationary front in winter [J].
Journal of Arid Meteorology,2024,42(1):75-83(in Chinese).
- 杨子幸,2023.基于混合 CNN-BiLSTM-AM 模型的短期风电功率预测研究[D].北京交通大学.Yang Zixing,2023. Research on Short-term Wind Power Prediction Based on Hybrid CNN-BiLSTM-AM Model[D]. Beijing Jiaotong University (in Chinese).
- 俞小鼎,费海燕,王秀明,2024.2024 年 2 月 17—23 日中国大范围强寒潮雨雪冰冻强对流过程涉及的若干问题[J].气象,50(9):1033-1042.YU X D, Fei H Y, Wang X M,2024. Some Issues Concerning the Large Area Rainstorm, Snowstorm, Sleet, Freezing Rain and Severe Convection Event over China from 17 to 23 February 2024[J].Meteor Mon,50(9):1033-1042(in Chinese).
- 袁凯,李武阶,李明,等,2022.四种机器深度学习算法对武汉地区雷达回波临近预报的检验和评估[J].气象,48(4):428-441. Yuan K, Li W J, Li M, et al,2022. Examination and evaluation of four machine learning algorithms for echo nowcasting in Wuhan Region[J]. Meteor Mon(4):428-441(in Chinese).
- 曾小团,谭肇,沈玉伟,等,2025.CastNet: 深度学习定量降水临近预报模型[J].气象,51(4):400-416.Zeng X T, Tan Z, Shen Y W, et al, 2025. CastNet: Deep-Learning-Based Model for Quantitative Precipitation Nowcasting[J]. Meteor Mon,51(4):400-416.
- 赵俊虎,赵语欣,贾小龙,等,2025.2024 年 2 月华东和华中大范围低温雨雪冰冻灾害的成因和可预报性分析[J].气象,51(1):17-29.Zhao J H, Zhao Y X, Jia X L, et al, 2025.Causes and Predictability of the High-Impact Large-Scale Cryogenic Freezing Rain and Snow Weather in East China and Central China in February 2024[J].Meteor Mon,51(1):17-29(in Chinese).
- 赵渊明,孙静,漆梁波,等, 2024.基于 L 波段探空观测的 FY-4A 云顶温度产品评估及其在冬季降水相态判识中的应用[J].气象, 50(1):59-70.Zhao Y M, Sun J, Qi L B et al,2024.Evaluation of FY-4A cloud top temperature product based on L-band radiosonde data and its application in winter precipitation type identification[J].Meteor Mon,50(1):59-70(in Chinese) .
- Ahrens C , D. Meteorology today: an introduction to weather, climate, and the environment[M]. USA: Brooks/Cole, 2000: 182-199.
- Cho K., van Merriënboer B., Gulcehre C., et al, 2014. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. In Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Doha, Qatar: Association for

Computational Linguistics (pp. 1724-1734).

Liu J, Sun Y, Han C, et al.2020.Deep representation learning on long-tailed data: A learnable embedding augmentation perspective[J].Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition:2967- 2976.

LeCun Y, Bengio Y, & Hinton, G, 2015. Deep learning[J]. Nature, 521(7553), 436-444.

Martín-Gil, J., Navarro-Medrano, J., & López-Sánchez, J. L. ,2019. Cubic spline interpolation for the correction of daily solar radiation data in Mediterranean locations[J]. Renewable Energy, 135, 329-337.

Pathak J., Hunt B., Girvan M., et al.,2018. Model-free prediction of large spatiotemporally chaotic systems from data: A reservoir computing approach. Physical review letters, 120(2), 024102.

R.Rajakumar ,Devi S .,2024.An Efficient Modelling of Oversampling with Optimal Deep Learning Enabled Anomaly Detection in Streaming Data[J].China Communications, 21(05):249-260.

Shi, X., Chen, Z., Wang, H., et al,2015. Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. In Advances in Neural Information Processing Systems (pp. 802–810).

Talatahari, S., Azizi, M., 2021. Chaos Game Optimization: a novel metaheuristic algorithm. Artif Intell Rev 54, 917-1004.

Vaswani, A., Shazeer, N., Parmar, N., et al, 2017. Attention is All You Need. In Advances in Neural Information Processing Systems (pp. 5998-6008).

Yoo, J., Kim, J., Lee, K., et al, 2019. Deep learning for nowcasting of short-term precipitation using weather radar images. Journal of Hydrology, 577, 123952.