

嵌入注意力机制的深度学习闪电短临预报方法研究

王超颖^{1,2}, 夏江江³, 蒋如斌^{1,4}, 武云飞⁴, 施红蓉⁴, 马建立⁵, 陈明轩⁵, 夏祥鳌^{1,2}

1 中国科学院大气物理研究所中层大气和全球环境探测重点实验室, 北京, 100029

2 中国科学院大学, 北京, 100049

3 中国科学院大气物理研究所东亚区域气候-环境重点实验室, 北京, 100029

4 中国科学院大气环境与极端气象重点实验室, 北京, 100029

5 北京城市气象研究院, 北京, 100089

摘要: 闪电的空间尺度变化范围广泛, 发生突然、生命史短且演变迅速, 其高时空分辨精细预报极为困难。本研究利用深度学习数据驱动的优势, 建立适应多种数据源的多层UNet结构神经网络并添加注意力机制, 以此构建华北地区闪电短临预报深度学习模型AME-UNet。使用国家电网闪电定位数据和新一代静止气象卫星FY-4A高时空分辨率数据, 引入表征云顶发展高度和冻结的具有明确物理意义的亮温通道差作为预报因子, 用以实现未来0-1h与1-2h闪电发生与否的逐像素预报。结果表明AME-UNet模型在闪电短临预报任务中展示了良好的应用潜力, 0-1h命中率最高达0.46, 虚警率为0.29, 1-2h命中率最高达0.41, 虚警率为0.44。本研究为基于深度学习开展闪电短临预报提供了新思路和新方法。

关键词: UNet结构, CBAM注意力机制, 闪电短临预报, FY-4A

收稿日期: 2024-10-28; 网络预出版日期

作者简介: 王超颖, 女, 1995.1 出生, 博士研究生, 主要从事雷暴云物理特征与闪电预报的研究, E-mail: wangcy_0113@163.com

通讯作者: 夏江江, E-mail: xiajj@tea.ac.cn 蒋如斌, E-mail: jiangrubin@mail.iap.ac.cn

资助项目: 国家自然科学基金 42275091

Funded by the National Natural Science Foundation of China (Project no. 42275091)

Deep Learning-Based Lightning Nowcasting with Embedded Attention Mechanisms

Wang Chaoying^{1,2}, Xia Jiangjiang³, Jiang Rubin^{1,4}, Wu Yunfei⁴, Shi Hongrong⁴, Ma
Jianli⁵, Chen Mingxuan⁵, Xia Xiang'ao^{1,2}

1 Key Laboratory of Middle Atmosphere and Global Environment Observation, Institute of
Atmospheric Physics, Chinese Academy of Sciences, Beijing, 100029

2 University of the Chinese Academy of Sciences, Beijing, 100049

3 Key Laboratory of Regional Climate-Environment for Temperate East Asia, Institute of
Atmospheric Physics, Chinese Academy of Sciences, Beijing, 100029

4 Key Laboratory of Atmospheric Environment and Extreme Meteorology, Chinese
Academy of Sciences, Beijing, 100029

5 Institute of Urban Meteorology, China Meteorological Administration, Beijing, 100089

Abstract: Lightning exhibits significant spatial variability, sudden occurrence, and rapid evolution with short life cycles, making high-resolution nowcasting particularly challenging. This study employs a deep learning approach to develop a multi-layer UNet architecture with an embedded attention mechanism AME-UNet, designed for high-resolution lightning nowcasting in North China. The model combines precise lightning location data from the State Grid of China with high spatiotemporal resolution data from the FY-4A geostationary meteorological satellite, creating a robust multi-source data foundation. Brightness temperature channel differences, which physically characterize cloud-top development heights and freezing levels, are employed as predictors for pixel-wise lightning nowcasting at 0–1h and 1–2h lead times. Results demonstrate AME-UNet's competitive performance, with a POD of 0.46 (0–1h) and 0.41 (1–2h), while maintaining FAR values of 0.29 and 0.45, respectively. This study presents novel deep learning approaches for lightning nowcasting, advancing the methodological toolkit for severe weather prediction.

Keywords: UNet Architecture, CBAM Attention Mechanism, Lightning Nowcasting, FY-4A

50 1. 引言

51 闪电是雷暴云中由复杂的动力、热力和微物理机制相互作用形成的产物。实验室研究和
52 外场观测表明，非感应起电机在雷暴云中的起电过程中起着主要作用。该理论认为，雷暴
53 云中的大霰粒子与小冰晶碰撞后会产生电荷分离，并通过云内上升气流、三维风切变和沉降
54 分离，最终形成强烈的电场，并最终导致闪电的产生（郗秀书等，2023）。闪电往往伴随有
55 破坏性的大风、冰雹和强降水等灾害天气，此外闪电自身也会造成人员伤亡、引发森林火灾、
56 损坏建筑物。闪电产生的电磁干扰也可能损坏电子电路，对航空航天、信息通讯等高科技领
57 域产生不利影响（Holle, 2008; Cervený et al., 2017; Cooper et al., 2019; 郗秀书等，2023）。由
58 于闪电具有发生突然、生命史短且演变迅速、空间尺度变化大等特点，使得对其进行高时空
59 分辨率的精细化预报极为困难。因此，研究准确且及时的闪电短临（0–2 小时）预报方法和
60 技术具有重要的科学意义和社会价值。

61 闪电短临预报方法主要是基于天气雷达和卫星观测资料的外推。天气雷达提供云内霰粒
62 子、冰晶、过冷水滴及云内上升速度等关键参数（Carey and Rutledge, 2000; Woodard et al.,
63 2012; Cui et al., 2022），而静止卫星则通过高时空分辨的观测数据，如云顶高度、云光学厚
64 度和冻结程度，监测对流运动的快速变化及其相关闪电活动（Harris et al., 2010; Matthee and
65 Mecikalski, 2013; Elsenheimer and Gravelle, 2019; Thiel et al., 2020）。由于闪电活动与雷暴的
66 发生密不可分，基于这些数据，国际上建立了多个雷暴短临预警方法，这些方法通过跟踪和
67 分析雷暴的演变过程，能够为闪电活动的预测提供重要依据，如雷暴识别、跟踪、分析和短
68 临预报系统（TITAN）（Dixon and Wiener, 1993）、风暴中心识别和跟踪系统（SCIT）（Johnson
69 et al., 1998）、基于光流方法的短临预报系统（Bechini and Chandrasekar, 2017; Woo and Wong,
70 2017）及基于目标云分析的系统（TOBAC）（Heikenfeld et al., 2019）等传统外推方法。近年
71 来，机器学习与深度学习以其强大的非线性特征提取能力和学习能力在图像领域取得了快速
72 发展，也逐渐被应用于气象领域（Han et al., 2021; 胡家晖等，2022; 张延彪等，2022a, 2022b;
73 徐景峰等，2023; Liu et al., 2024; 朱延和等，2024）。Mostajabi et al.（2019）根据地面气象
74 要素的变化能够一定程度上表征雷暴云发展的原理，将单点气象参数（温度、湿度、气压和
75 风速）作为 XGBoost（eXtreme Gradient Boosting）算法（Chen and Guestrin, 2016）的特征
76 变量，对未来 30 分钟闪电发生进行预报。Zhou et al.（2020）同时输入 Himawari-8 静止气
77 象卫星红外亮温、多普勒天气雷达回波强度与闪电定位数据，基于 Segnet 框架

(Badrinarayanan et al., 2017) 开发了一个 0–1 小时的地闪临近预报模型。Lu et al. (2024) 构建了一种新型闪电临近预报模型 MCGLN，将生成对抗网络与卷积长短期记忆网络 ConvLSTM (Convolutional Long-Short Term Memory) 相结合，利用雷达、闪电定位与地表信息预报宁波及其周边地区未来 1 小时闪电发生情况。此外，利用数值天气预报 (NWP, Numerical Weather Prediction) 模式预报大气的动力和热状态，能够将其预报产品作为预报因子输入模型中。Geng et al. (2021) 与 Zhou et al. (2022) 提出了预报模型 LightNet 与 LightNet+，同时引入历史闪电观测数据和数值天气预报 WRF (Weather Research and Forecasting) 模拟数据作为输入，预报华北地区未来 6 小时闪电发生情况。Guo et al. (2022) 在 ConvLSTM 基础上添加卷积神经网络 CNN (Convolutional Neural Network) 模块，构建闪电临近预报模型 CLSTM-LFN，结合历史闪电发生频次以及数值模型产品中与闪电发生显著相关的物理变量，预报中国中东部地区未来 0–3 小时的闪电发生区域。

尽管传统预报方法和人工智能方法各有优势，但它们仍存在可以改进的地方。传统的外推预报方法虽然能预测未来 0–2 小时内闪电的移动趋势，但往往忽略了其发生、发展和消散的物理机制，因此难以准确描述其演变过程；这些方法通常基于固定的规则和参数，缺乏自适应性，难以应对动态变化的天气条件；且其大多只依赖少量观测数据作为预报因子，难以有效处理大规模、多源的数据，尤其是无法充分利用卫星等丰富的观测资源。人工智能方法相较于传统外推方法在数据特征提取方面更具优势，然而其中 XGBoost 为代表的决策树类模型对时空位置建模能力欠缺，无法实现闪电的网格化预报。此外面对闪电预报的类别不平衡问题时——既包括卫星遥感数据与地面观测数据间的样本量差异，也包括闪电发生（正样本）与未发生（负样本）的极端比例失衡，简单的神经网络难以有效捕捉稀有事件规律，这可能是现有研究中虚警率 (FAR) 居高不下的原因之一。由于强雷暴系统生命史可持续数小时，相比于仅使用观测数据预报未来 0–1 小时闪电发生情况，使用 NWP 模式产品能够实现 0–3 h 甚至 0–12 h 的预报。然而，NWP 在短时尺度（尤其是 0–2 h 内）可能存在初始化偏差和计算延迟，影响预报的时效性和精度。使用观测数据进行 0–2 h 预报，既能避免 NWP 的缺陷，又能提供比 0–1 h 更长的反应时间，使防灾减灾措施能够更早介入，提高实际应用价值。

注意力机制通过赋予模型关注不同数据点的能力，能够增强对重要特征的识别和理解，从而更有效地提取空间和时间特征，提高预报模型的准确性和稳健性。Tao et al. (2021) 将注意力机制嵌入长短期记忆人工神经网络模型 (LSTM) 中，有效提高了长江流域 129 个站

点月降水的预报精度。Trebing et al. (2021) 将卷积块注意力模块 (CBAM, Convolutional Block Attention Module) 应用于逐像素降水预报任务, 显著提高了模型的预测性能。Luo et al. (2022) 将时间注意模块 (TAM) 和层注意模块 (LAM) 嵌入到循环卷积神经网络模型中, 保留更多的时间和空间信息, 提高了强降水的预报能力。Lin et al. (2019) 提出了一种添加了通道注意力机制的双源时空神经网络 (ADSNet), 结合 WRF 和历史闪电观测数据, 用于华北地区未来 12 小时闪电预报, 引入注意力机制后, 模型的平均绝对误差 (MAE) 和均方根误差 (RMSE) 都得到了显著降低。Zhou et al. (2022) 构建的 LightNet+ 使用基于 NLFU (Neural Local Feature Unit) 模块的注意力机制替代简单的卷积来融合双源数据, 使该模型能够捕捉特征网格之间的长距离时空连接, 预报效果有所提升。闪电作为强对流发展到一定程度的天气现象, 其发生往往伴随着降水的出现, 二者的特征与引发条件相似, 因此将注意力机制应用于闪电预报, 是提升闪电预报精度的一种可能途径。

使用静止气象卫星进行闪电短临预报具有重要意义。相比地基观测, 卫星具备广域覆盖、高时空分辨率和全天候观测的优势, 能够在全球范围内实时监测雷暴云的云顶状态及其演变过程, 为闪电预报提供连续的时空信息, 在地面设备难以部署或地形复杂的地区具有不可替代的应用价值。本研究使用中国新一代静止气象卫星 FY-4A 上搭载的多通道扫描成像辐射计 (AGRI, Advanced Geosynchronous Radiation Imager) 观测数据, 利用其提供的云发生发展探测信息, 开发嵌入注意力机制的深度学习方法, 构建 FY-4A 闪电预报模型, 并结合地基闪电定位数据, 实现华北地区未来 2 小时的格点闪电临近预报。相较于已有研究, 本研究构建的模型采用多层神经网络提取不同数据源特征, 嵌入 CBAM 三维注意力机制保证闪电特征不被海量冗余数据淹没, 能够预报未来 2 小时闪电发生情况, 更有助于安全保障和预警效率的提升。

2. 研究区域和数据

2.1 研究区域

华北地区 (113° – 120° E, 35° – 43° N; 图 1) 处于中纬度的沿海与内陆交接地带, 地形复杂, 汛期强对流天气活跃。同时, 城市快速扩张引起的热岛效应与空气污染也为雷暴的触发及加强提供了有利条件 (Jin et al., 2005)。华北地区在夏季由雷暴引起的极端天气造成的灾害损失巨大。基于以上原因, 本文选择华北地区作为深度学习算法开发和测试的研究区域。由图 1 所示的 2020–2021 年华北 5–9 月闪电发生频率热力图表明, 华北夏季闪电活动频繁区

域主要集中在北京东南部和沧州等地，反映出该区域雷暴活动的高发特征。

2.2 卫星遥感数据

AGRI 是搭载在 FY-4A 上的 14 通道成像仪，包含 2 个可见光通道、1 个近红外通道、3 个短波红外通道、2 个中波红外通道、2 个水汽通道和 4 个长波红外通道，能够有效探测云、气溶胶、水汽和地表等信息。相比上一代风云静止卫星，FY-4A 区域扫描时间分辨率提高到 5 min，空间分辨率最高提高到 0.5km，大幅提升了卫星对地观测效率。考虑到可见光通道和近红外通道仅白天工作，为了训练一个适应于全天的闪电预报模型，本研究中仅采用 AGRI 的 6 个长波通道于 2020–2021 年 5–9 月的观测数据作为深度学习模型的特征参数，并将原始 AGRI 数据插值到 4×4 km 的网格中，时间分辨率为 5 min (Shi et al., 2023)。

2.3 闪电定位数据

深度学习模型中需要闪电定位数据作为特征参数（过去时刻）和标签数据（预报时刻）。2020–2021 年 5–9 月闪电定位数据来自中国国家电网公司地闪定位系统 (LLS, Lightning Location System)，LLS 采用磁定向和到达时间差相结合的方法对地闪回击过程进行定位 (Chen et al., 2002)，闪电事件探测效率达到 94%，定位精度 < 1 km (Chen et al., 2012)。将 LLS 探测到的回击数据聚类为闪电，对于有多次回击的闪电，使用首次回击的时间、位置和电流强度作为该闪电的时间、位置和电流强度。




图 1 2020–2021 年华北 5–9 月闪电发生频率热力图。

Figure 1. Heatmap of lightning occurrence frequency in North China from May to September during 2020–2021.

155 3. 模型数据预处理

156 3.1 特征工程

157 考虑到闪电定位数据是离散数据点，为与 FY-4A 卫星的时空分辨率一致，根据闪电数
158 据的不同用途，分别采用以下方法将闪电数据进行格点化处理。当闪电作为模型预报因子时，
159 在预报起始时刻前 30 min，闪电数据按照 5 min 间隔进行处理，具体做法为在 5 min 时间段
160 内，格点一定范围 (R) 内有闪电发生，则标记此格点“闪电发生状态”为 1，如果没有闪电
161 发生，则记为 0。当闪电观测数据作为标签（预报量）时，若未来 0–1 h 或者 1–2 h 内，格
162 点一定范围 (R) 内有闪电观测记录，则标记此格点为 1，否则标记为 0。Zhou et al. (2020)
163 在研究中指出考虑到闪电天气一般发生在中 γ 尺度 (Orlanski, 1975)，预报测试结果表明如
164 果 R 太小，则漏报会较多；如果 R 太大，空报会较为严重。基于以上考虑，文中将 R 设置
165 为 20km。

166 表 1 用于闪电短临预报的卫星与闪电定位预报因子

167 Table 1. Selected satellite and lightning predictors for lightning nowcasting

数据来源	预报因子(μm)	物理性质	时间(min)和空间($^\circ$) 分辨率
卫星观测数据	6.25	中高层水汽	5/0.04
	7.1	中低层水汽	
	8.5	云相	
	10.8	云，地表温度等	
	12.0	云，总水汽量，地表温度	
	13.5	云顶高度	
	6.25-7.1	云厚	
	6.25-10.8	云厚	
	8.5-10.8	云顶冻结程度	
	(8.5-10.8)– (10.8-12.0)	云顶冻结程度	
闪电定位数据	闪电发生状态	闪电活动	

168 卫星红外通道亮温之间的差值对对流发生发展有很好的指示意义 (Matthee and
169 Mecikalski, 2013)。6.2 μm 和 7.3 μm 分别对应水汽强吸收通道和弱吸收通道，因此 6.2–7.3 μm
170 亮温差可指示云发展高度 (Adler et al., 1985)，6.2 μm 水汽通道和 10.8 μm (大气窗区) 通
171 道亮温差也对云发展高度有一定指示作用 (Roberts and Rutledge, 2003)。由于冰云和水云在
172 8.7–12 μm 范围内的吸收有明显差异 (Strabala et al., 1994; Baum et al., 2000)，8.7 与 10.8 μm
173 亮温差、以及 8.7 和 10.8 μm 亮温差与 10.8 和 12.0 μm 亮温差之差，已成为广泛应用于云顶
174 相态识别的重要参数 (Mecikalski et al., 2010a, 2010b)。这些观测测量以及导出量的大小和变

化速率与闪电始发有密切相关，广泛应用于对流初生短临预报（Matthee and Mecikalski, 2013）。本文使用 FY-4A 卫星 6 个红外通道亮温与以上 4 个亮温差作为预报因子，时间分辨率为 5min，空间分辨率为 0.04°（见表 1）。

3.2 构建数据集

本文的目标是建立一个基于深度学习的闪电格点预报模型。为了让模型能够充分提取观测数据中闪电随时间演变的信息，采用预报时刻前 30min 内 AGRI 提供的 6 通道亮温和亮温差格点数据以及闪电定位数据作为输入特征，共计 11 个预报因子（特征）。各预报因子时间分辨率均为 5min，空间分辨率为 0.04°。模型的标签是 LLS 提供的格点闪电数据。研究区域共计 192×176 个网格，每个匹配样本中的预报因子构成为 6(时次)×11(预报因子)×192×176，预测量为未来 0–1 h 和 1–2 h 的闪电活动格点预报（192×176）。

由于输入特征中卫星云顶亮温与闪电定位数据的数值范围不同且差距很大，可能导致某些特征在训练过程中占据主导地位，影响其他特征的贡献，也可能导致梯度消失或梯度爆炸现象的发生，影响模型的训练效果和预测性能。归一化有助于将输入数据缩放到合适的范围内，使数据在数值上更为一致，能够使模型训练更稳定，加快收敛速度。考虑到闪电定位数据为 0 或 1 的二分类数据，因此将卫星各个通道的亮温数据在输入模型前采取 z-score 标准化方法做归一化处理，使得原始数据集归一化为均值为 0、标准差 1 的数据集。公式如下：

$$x^* = \frac{x - \mu}{\sigma} \quad (1)$$

其中， μ 、 σ 分别为原始数据集的均值和标准差。 x 表示原始数据， x^* 表示归一化后的结果。

本文使用了 2020–2021 年 5–9 月的观测数据建模，考虑到闪电时空分布严重不平衡，将所有匹配样本中按照预报闪电数（格点出现闪电）和总格点数据之比分为 7 类，即 0%，0–1%，1–2%，2–3%，3–4%，4–5% 和 5% 以上，在 7 类样本中分别按照 10%，10%，10%，10%，5%，5%，50% 的比例随机抽取样本构成总样本（1733）。考虑到气象数据具有明显的时序性，总样本中按照逐月日序分为两个独立子样本集，分别作为训练集和测试集。训练集包含了每月中发生在 1–25 日的样本，样本总数为 1490 个，测试集则包含发生在 26–31 日的所有其他样本，共计 243 个。本文按照 50% 的比例选取了格点闪电超过 5% 的样本，这是由于此类个例是本文关注的重点，且这类样本在总样本中占比很少。

3.3 深度学习模型框架、模型训练和测试

本文提出应用于闪电短临预报的注意力增强多层编码 UNet 模型（AME-UNet，Attention-enhanced Multi-layer Encoder UNet），其架构如图 2 所示。该模型在经典 UNet（Ronneberger et al., 2015）的编码-解码及跳跃链接的框架基础上加入 CBAM 注意力模块（Woo et al., 2018），利用通道-空间双路径注意力机制实现闪电关键特征的动态筛选，有效缓解数据不平衡问题。




图 2 AME-UNet 模型结构。模型左部为编码器部分，由卷积模块、最大池化模块与注意力机制模块构成；右部为与编码器相对应的解码器部分，由反卷积模块和上采样模块构成。

Figure 2. AME-UNet model structure. The left part of the model is the encoder, consisting of convolutional modules, max pooling modules, and attention mechanism modules. The right part corresponds to the encoder and serves as the decoder, composed of deconvolution modules and upsampling modules.

3.3.1 UNet

根据静止卫星观测数据与闪电定位数据对闪电是否发生进行预报可视为一个语义分割问题。语义分割意为按像素将图像中的内容划分为不同的类别，UNet 是一个成熟的深度学习语义分割模型，使用 UNet 能够提取图片中的有效特征，具有简单、高效、易懂、容易构建等优点。

如图 2 所示，在卷积与反卷积模块中使用 3×3 卷积核滑动提取输入气象要素数据的局部特征，产生的特征图连接一个批归一模块（BN，Batch Normalization）将特征值进行变换，使得其均值接近于 0 而标准偏差接近于 1，从而加速模型的训练速度。经过归一化模块之后，将特征图输入激活函数 ReLU（Rectified Linear Unit）修正线性单元，用于提取其中的非线性特性。在编码器部分，以上步骤后连接最大池化层，缩小特征图尺寸，在保留气象特征的前提下减少后续层的计算量和参数数量，从而加速训练和推理速度，随后输入下一个卷积层。

而在解码器部分，以上步骤后输入上采样模块，将编码器中缩小的气象要素特征图进行尺寸还原，逐层恢复空间分辨率。值得注意的是跳跃连接将编码器的特征图与解码器的特征图进行连接，这样有助于在解码过程中传递更多的时空信息，从而更准确地恢复图像的细节。

模型的最后一层使用 $1 \times 1 \times 1$ 的三维卷积核将所有特征压缩到一个通道，使用 Sigmoid 分类，最终逐像素输出每个格点上的闪电发生概率。模型输出的结果为 0 到 1 之间的闪电概率预报，将 0.5 作为将概率预报转化为确定性预报的阈值，即概率 > 0.5 时闪电发生，否则闪电未发生。

3.3.2 CBAM

CBAM 是用于增强卷积神经网络性能的三维注意力机制，结合了通道注意力模块（CAM，Channel Attention Module）和空间注意力模块（SAM，Spatial Attention Module）两种注意力机制，能够增强模型对空间和通道信息的捕获能力，显著提升卷积神经网络的性能。在闪电预报的应用中，CBAM 有助于模型更精准地解析与闪电活动相关的气象特征，并在不同的时空尺度上动态调整对关键信息的关注。

如图 3 所示，CAM 主要关注于不同通道（即表 1 所示预报因子）之间的信息权重。通过计算每个通道的全局平均池化和最大池化特征，并将这些特征输入到全连接层生成通道权重，CAM 可以学习每个预报因子的相对重要性。这样，模型可以优先关注与闪电发展密切相关的通道特征，并削弱无关或噪声信息的影响。

SAM 主要关注于每张特征图中不同空间位置的信息关联。首先计算特征图的最大和平均池化特征，然后使用一个全连接层来计算空间权重。这样一来，模型能够动态地调整对图像中特定区域的关注，增强对闪电活跃区域的特征提取能力，有助于捕捉闪电频发区域的局部特性。

CBAM 的输出是通过将 CAM 和 SAM 的结果相乘得到的，能够灵活地学习和调整对通道和空间信息的关注程度，以提升对闪电预报相关特征的捕捉精度。同时，尽管加入了注意力机制，CBAM 对模型计算复杂度和参数量的增加非常有限，这使其在计算资源有限情况下也具有良好的适用性。因此，通过 CBAM 的增强，模型可以更有效地解析气象观测数据中的复杂模式和闪电发生的细微特征，提高闪电短临预报的准确性和可靠性。




图 3 CBAM 注意力机制结构与原理。(a) 为 CBAM 整体结构，输入特征先后通过通道注意力模块 (b) 和空间注意力模块 (c)，得到重新加权的特征输出。(b) 通道注意力模块，为通道赋予权重。(c) 空间注意力模块为空间赋予权重。

Figure 3. Structure and Principle of the CBAM Attention Mechanism. (a) Overall structure of CBAM, where the input features are sequentially processed through the channel attention module (b) and the spatial attention module (c), resulting in reweighted feature outputs. (b) Channel attention module assigns weights to channels. (c) Spatial attention module assigns weights to spatial dimensions.

3.3.3 试验设计

本文旨在充分利用多源观测数据（FY-4A 静止卫星与闪电定位数据）预测未来 0–1h 与 1–2h 闪电的发生情况，为了实现这一目标，我们设计了以下研究方案，如图 3 所示。

1. 首先对输入数据进行预处理并构建数据集，详见 3.1 与 3.2 节。

2. 然后将数据集输入不同模型进行训练与测试。根据闪电预报需求与多源输入数据特征，我们设计了强调特征整合的 ME-UNet 模型、引入注意力机制以聚焦重要特征的 AME-UNet 模型、提供基准评估的 Persistence 持续性模型和用于检验理想条件下的模型性能的 AME-UNet-leakage 数据泄露模型，设计方法见下文。

(1) ME-UNet 模型。由前文可知，历史闪电定位数据与卫星亮温都与闪电预报有密切联

系, 为了更准确地捕捉多源数据中影响闪电发生的关键因素, 本文设计了多层编码器处理结构模型 ME-UNet。具体做法为模型的编码器部分将卫星数据与闪电定位数据分为两个独立的部分分别输入模型, 这两部分数据分别经过编码器中的多层卷积和池化操作, 两层之间相互独立运行, 互不干扰。这种多路径的编码器结构可以确保模型在处理复杂时空数据时, 不仅能够有效保存闪电定位数据的重要特征, 还能充分提取卫星数据中与闪电发生密切相关的雷暴云信息, 不至于因为数据量的差异导致的特征淹没。此外, 通过将每层中的卫星数据和闪电定位数据的特征图与解码器中对应的特征图进行跳跃连接, 模型能够更有效地整合这些特征, 从而为后续的解码和预测提供更有力的支持。

(2) AME-UNet 模型。由于卫星多通道亮温数据特征多、数据量大, 而闪电是一种小概率事件, 为了更聚焦于与闪电相关的特征, 本文在 ME-UNet 结构的基础上设计添加 CBAM 注意力机制的模型 AME-UNet。具体做法为在每层编码器的原始数据和每次卷积操作之后添加 CBAM 模块, 为空间与通道添加权重, 能够保留原始数据信息, 放大每层图像上的重要特征并抑制不重要的特征, 避免因为闪电是小概率事件而导致的特征丢失, 从而增强模型对空间和通道信息的捕获能力。

(3) Persistence 持续性模型。为了评估模型的有效性, 本文设计 Persistence 持续性模型作为预报的基准, 即使用当前闪电定位数据作为未来 0-1h 与 1-2h 的预报结果。考虑到雷暴系统具有一定的持续性, 闪电活动在短时间内 (如 1-2h) 通常不会发生剧烈变化, 当前某个区域的闪电活动往往意味着未来一段时间内该区域或其附近区域仍然可能发生闪电活动。因此, 在雷暴系统尚未减弱或消散的情况下, 当前的闪电活动可以作为短期内雷暴继续存在的一个指示器。

(4) AME-UNet-leakage 数据泄露模型。若不考虑闪电的时序性, 模型随机在数据集中抽取训练集与测试集, 使得测试集上的数据与训练集上的数据在特征分布上更加一致。模型在训练过程中能够充分学习到整个数据集的特征, 因此在测试时, 模型的表现可以接近理论上的最佳性能。由于测试集中的样本分布与训练集相似, 这种方法往往被认为是模型能够达到的“上限”表现。

3. 最后评估 4 个模型的表现, 挑选最优闪电预报模型。




图 4 闪电预报流程图

Figure 4. Flowchart of the lightning nowcasting.

3.3.4 模型训练

模型选取交叉熵损失函数作为训练依据 (Golik et al., 2013), 公式如下:

$$Loss = \frac{1}{N} \sum_{i=1}^N \sum_{c=0}^1 y_c^i \log(p_c^i) \quad (2)$$

其中 N 为 192×176 网格点的数量, y_c^i 为格点 i 的标签值, c 代表闪电发生 ($c=1$) 与未发生 ($c=0$), p_c^i 为格点 i 处于 c 情况的概率。当损失函数降到最低时, 表示模型训练已完成。模型训练最多迭代 300 个周期, 当损失函数在 10 个周期训练过程中没有减少时, 则训练提前停止, 表示模型训练结束。本文选取 ADAM 优化器 (Kingma and Ba, 2014) 调整学习率, 初始学习率设置为 0.001, 当损失函数在 4 个周期训练过程中没有减少时, 将学习率降低到之前学习率的十分之一。本研究中模型批次大小为 2。

3.3.5 模型验证

本文使用以下经典气象预报检验因子对预报结果进行检验，包括 POD、FAR、准确率（Accuracy）、ETS（Equitable threat score）和 TS（Threat score）评分，其定义如下：

$$POD = \frac{TP}{TP + FN} \quad (3)$$

$$FAR = \frac{FP}{FP + TN} \quad (4)$$

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

$$TS = \frac{TP}{TP + FP + FN} \quad (6)$$

$$R = \frac{(TP + FN)(TP + FP)}{TP + FP + TN + FN} \quad (7)$$

$$ETS = \frac{TP - R}{TP + FP + TN - R} \quad (8)$$

其中，在网格的每个像素上成功预报闪电发生定义为真阳性（TP），即预报值为 1 且目标值也是 1；模型预报闪电发生但实际并未发生闪电的情况定义为假阳性（FP），即预报值为 1 但目标值为 0；模型正确预报未发生闪电（即实际没有发生闪电且模型也预报为未发生）的情况定义为真阴性（TN），即预报值为 0 且目标值也为 0；而如果实际发生了闪电但模型未能预报到的情况定义为假阴性（FN），即预报值为 0 但目标值为 1。

4. 模型结果

4.1 模型评估

基于 FY-4A 卫星观测数据，AME-UNet 以 5 min 时间间隔接收空间分辨率 4 km 的红外亮温观测，以过去半小时（5 min 时间分辨率）的历史数据生成未来 0–1h 与 1–2h 时效的 4km 闪电概率预报产品。在 NVIDIA V100 GPU 上单次预测的平均耗时为 1.2 秒，满足业务化应用的时效性需求。

本文将 2020–2021 年 5–9 月每月 26 号之后样本的预报结果采用格点对格点的检验方法进行了系统地检验，用于评估算法的性能，不同模型的检验评分结果在表 2 中给出。

Persistence 认为闪电活动在短时间内（0–2 小时）通常不会发生剧烈变化，假设当前时刻的闪电定位就是未来 0–1 小时和 1–2 小时的闪电预报结果，是一个较为简单的基线方法。

但该方法不考虑闪电的发生、发展与移动，也没有纳入气象条件的动态变化，因此它的预测效果受到较大限制，尤其在预测较长时间段的闪电活动时表现较差。

AME-UNet-leakage 通过随机构建数据集达到了最高的评分（0-1h 与 1-2h 预报结果准确率、POD、TS 与 ETS 评分最高，FAR 最低，如 0-1h POD 达到 0.66，FAR 仅有 0.21）。然而闪电活动本质上是一个受复杂气象条件和环境因素影响的时序过程，具有显著的时间依赖性。AME-UNet-leakage 忽略了这种时序性，尤其是在测试集与训练集存在显著重叠的情况下，AME-UNet-leakage 的高评分可能存在“信息泄露”的风险，即模型可能记住了训练数据中的特定模式，而非真正学会了闪电活动的复杂规律。

ME-UNet 和 AME-UNet 的各项评分落在 Persistence 与 AME-UNet-leakage 中间，相比 Persistence 预报结果有了显著提升（如准确率最高提升 5.7%）。ME-UNet 和 AME-UNet 虽然在评分上低于 AME-UNet-leakage，但它们在数据集的建立过程中充分考虑了闪电的时间依赖性，更符合实际闪电预报的需求，具有更强的实用价值。

相比 0-1h，各模型在 1-2h 预报的各项评分都有所下降（POD、准确率等评分下降，FAR 升高），表明随着时间的推移，气象条件可能已经发生了较大变化，使得模型基于当前数据预测未来状态的难度增加，导致预报的准确性下降。

添加了 CBAM 的 AME-UNet 模型相比于 ME-UNet 模型，在 0-1h 预报准确率方面表现相当，但 AME-UNet 模型 POD 较 Persistence 增长 100%，ME-UNet 较 Persistence POD 增长 91%，AME-UNet 模型 POD 增长幅度更大（9%），此外 TS 与 ETS 评分都有了更大的提升（AME-UNet 模型 TS 评分较 Persistence 的增长幅度分别为 75%，ETS 评分增长幅度为 83%，ME-UNet 模型 TS 与 ETS 评分增长幅度为 71%与 77%）。由 1-2h 预报结果可以看到，AME-UNet 模型相比 ME-UNet 展现出了更好的预报效果，具体表现为 AME-UNet 模型 POD 相比 Persistence 的增长幅度为 113%，ME-UNet 模型相比 Persistence 的增长幅度为 96%，AME-UNet 模型 POD 增长幅度更大（17%），TS 评分相比 0-1h 也展现了更大的提升幅度。以上结果表明注意力机制在长时间范围内更好地利用了时序信息，更有效地捕捉到了关键特征，使得模型能够更精确地聚焦于重要的时序特征。此外模型在长时间范围内表现出更高的稳定性和一致性，表明其在面对复杂气象条件下具有更强的适应能力。

综上所述，AME-UNet 模型在多源数据集成和注意力机制的应用下，在 0-1h 与 1-2h 均展示出较好的预报能力，能够提供更准确和可靠的闪电预报。

表 2 不同模型 0–1h 和 1–2h 闪电预报结果评估（空间分辨率：4km）
Table 2. Evaluation of 0–1-h and 1–2h lightning nowcasting results produced by different models
(spatial resolution: 4 km).

	准确率		POD		FAR		TS		ETS	
	0–1h	1–2h	0–1h	1–2h	0–1h	1–2h	0–1h	1–2h	0–1h	1–2h
Persistence	0.802	0.780	0.230	0.194	0.107	0.262	0.222	0.176	0.154	0.108
ME-UNet	0.849	0.813	0.440	0.381	0.245	0.325	0.379	0.302	0.273	0.192
AME-UNet	0.848	0.805	0.460	0.413	0.293	0.436	0.388	0.315	0.281	0.195
AME-UNet-leakage	0.941	0.931	0.661	0.618	0.205	0.211	0.603	0.565	0.551	0.513

4.2 个例分析评估

4.2.1 闪电发生、发展、运动和消散的预报

为了更直观地展示雷暴系统中闪电的发生、发展、运动和消散过程，本文提供了研究区域内一个典型个例进行说明。该雷暴活动中，雷暴系统从华北地区西北部河北与内蒙交界处始发，随后逐渐发展增强并向东南方向移动，一系列对流单体在期间发生聚合、分裂，各对流单体先后经历新生、发展、增强和消散，使雷暴系统维持了 15 个小时，为了便于分析，本文从整体上对雷暴系统的演变进行描述，系统自 9:55（UTC+8）始发，至 12:55 为发展增强阶段，随后进入成熟阶段，在 15:55 达到最强，之后，雷暴开始减弱，于 28 日 00:55 左右消散。

模型对闪电预报结果和观测值见图 5，左右两列分别为预报时刻之后 0–1h 和 1–2h 的结果。从预报和实况的分布来看，模型在雷暴的不同发展阶段，包括雷暴初生、成熟、消散等阶段，均展现出良好的预报效果。在雷暴发展阶段（~12:55），模型成功预测了闪电活动范围的扩大。在雷暴的成熟阶段（12:55-15:55），模型能够成功预报闪电活动区域的分裂和移动。在雷暴的消散阶段（27 日 15:55-28 日 00:55），模型较好的预报了闪电活动范围的缩小。针对此次雷暴过程，模型能够预报其运动方向与范围，表明预报性能优秀。此个例进一步表明，模型能够充分提取观测数据的信息，有效实现闪电的临近预报。




图 5 2021 年 5 月 27 日 0-1 小时 (a-e) 和 1-2 小时 (f-j) 闪电预报结果以及 LLS 的观测结果 (阴影部分为概率预测, 黑色散点为闪电观测, 评估分数在每个子图的右下角给出)。

Figure 5. 0-1 hour (a-e) and 1-2 hour (f-j) lightning nowcasting results and LLS observation results on May 27, 2021 (the shaded areas represent probability predictions, the black dots indicate lightning observations, and the evaluation scores are provided in the bottom right corner of each subplot).




图 6 2021 年 9 月 30 日 0-1 小时 (a-c) 和 1-2 小时 (d-f) 闪电预报结果以及 LLS 的观测结果 (阴影部分为概率预测, 黑色散点为闪电观测, 评估分数在每个子图的右下角给出)。
Figure 6. 0-1 hour (a-c) and 1-2 hour (d-f) lightning nowcasting results and LLS observation results on September 30, 2021 (the shaded areas represent probability predictions, the black dots indicate lightning observations, and the evaluation scores are provided in the bottom right corner of each subplot).

为了更直观地展示雷暴系统中闪电活动运动与合并过程，本文提供了如图 6 所示的发生在 2021 年 9 月 30 日 16:00–20:00 (UTC+8) 的雷暴过程进行说明，该过程包含了两个单体的合并和移动。首先，模型成功预报了左侧雷暴单体向东移动的轨迹，准确捕捉到了该系统的移动路径，表明模型在对单体雷暴的时空变化预测中具有较高的准确性。其次，模型对两个雷暴单体合并的过程也进行了较好的预测，准确反映了系统间的相互作用和动态变化，尤其在两个单体逐渐靠近并最终合并的过程中，模型较好地再现了其发展趋势。此个例进一步验证了模型在不同雷暴演化阶段的预报能力。

由此可见，通过构建 AME-UNet 模型，能够有效实现全局特征和局部特征综合提取，从而实现对于闪电的预报能力。

5. 结果与讨论

本文构建了一种针对多源数据特征提取的多层 UNet 结构卷积神经网络模型 AME-UNet，并在其中添加了 CBAM 注意力机制，使用闪电定位数据和与之对应的新一代静止气象卫星 FY-4A 高时空分辨率数据用于闪电的临近预报，能够提供华北地区未来 0–1h 和 1–2h 逐像素的闪电发生概率。

试验结果显示，AME-UNet 具有强大的特征学习能力，有效地实现多源数据的融合。首先，ME-UNet 模型通过利用多层结构整合多源数据，有效提升了准确率、POD、TS 和 ETS 评分，而添加了注意力机制的 AME-UNet 模型，进一步提升了上述预报性能指标，且对未来 1–2h 预报效果的提升比 0–1h 更明显，这表明注意力机制在长时间范围内更有效地利用了时序信息，使得模型能够更精确地聚焦于重要的时序特征。同时，AME-UNet 在长时间范围内表现出更高的稳定性和一致性，表明其在应对复杂气象条件方面具有更强的适应能力。此外，AME-UNet 模型可以很好地预测闪电活动区域的移动、合并、增长和衰减，表明该模型能够综合提取多源观测数据在不同时空尺度的信息，实现数据的最大化应用，展示了良好的应用潜力，为闪电预报应用提供了新的方法。

AME-UNet 模型使用卫星红外亮温与闪电定位数据，对未来闪电发生情况进行短临预报，能够在闪电发生前提供更及时的预报信息和更大的提前量，在缺乏地面设备部署或复杂地形地区具有重要的应用价值。在当前工作基础上，考虑到雷达直接观测到的雷暴云内粒子的相态、最大反射率、垂直液态水含量和最大雷达回波高度等参量，自动气象站提供的地面观测数据（如温度、湿度、风速、风向、气压等），和高分辨率数值天气预报数据，都与闪

电的发生紧密相连，未来若能结合更多类型的数据，进一步完善 AME-UNet，以提升模型对闪电发生机制的解析能力和预报性能。

在本研究中，AME-UNet POD 为 0.46，FAR 为 0.29，相比 Zhou et al. (2020) 使用葵花卫星红外通道与闪电定位数据预报未来 0–1h 闪电发生情况的研究结果 (POD 为 0.61，FAR 为 0.40)，二者的差异可能由数据源和处理方法的不同造成。具体而言，FY-4A 的时空分辨率 (4 km, 5 min) 相较于葵花 (2 km, 10 min)，可能导致对小尺度气象现象的捕捉能力不足。由于闪电发生的概率相对较小，导致正负样本分布极为不平衡，在不同的研究中，学者们针对此问题在构建数据集、闪电发生定义和模型训练方式上采取了不同的策略。本研究构建数据集方式详见 3.2 节，更聚焦于闪电发生概率超过 5% 的样本，同时也保留了未发生闪电的样本用于模型训练。通过设置闪电发生与未发生像素点的比例约为 1:4，能够在平衡数据集的同时，避免模型过度偏向于预测闪电未发生的情况，从而提升对少数正样本的识别能力。此外，本研究设计 AME-UNet-leakage 模型忽略闪电的时序性，在测试集与训练集存在显著重叠的情况下，模型在 0–1h 预报中的 POD 达到 0.66，而 FAR 仅有 0.21，高于 AME-UNet 模型。值得注意的是，本文模型较低的 FAR 表明模型在闪电预测中较为保守，这在实际应用中具有重要的价值。若后续研究采用标准化的闪电发生定义和数据集构建方法，这将更有利于闪电预报模型的对比和预报能力的提升。

致谢 感谢国家电网提供的闪电定位数据。

References

- Adler R F, Markus M J, Fenn D D. 1985. Detection of severe Midwest thunderstorms using geosynchronous satellite data[J]. *Monthly weather review*, 113(5): 769-781.
- Badrinarayanan V, Kendall A, Cipolla R. 2017. Segnet: A deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE transactions on pattern analysis and machine intelligence*, 39(12): 2481-2495.
- Baum B A, Kratz D P, Yang P, et al. 2000. Remote sensing of cloud properties using MODIS airborne simulator imagery during SUCCESS: 1. Data and models[J]. *Journal of Geophysical Research: Atmospheres*, 105(D9): 11767-11780.
- Bechini R, Chandrasekar V. 2017. An enhanced optical flow technique for radar nowcasting of precipitation and winds[J]. *Journal of Atmospheric and Oceanic Technology*, 34(12): 2637-2658.
- Carey L D, Rutledge S A. 2000. The relationship between precipitation and lightning in tropical island convection: A C-band polarimetric radar study[J]. *Monthly weather review*, 128(8): 2687-2710.
- Cervený R S, Bessemoulin P, Burt C C, et al. 2017. WMO assessment of weather and climate mortality extremes: lightning, tropical cyclones, tornadoes, and hail[J]. *Weather, climate, and society*, 9(3): 487-497.
- Chen L, Zhang Y, Lu W, et al. 2012. Performance evaluation for a lightning location system based on observations of artificially triggered lightning and natural lightning flashes[J]. *Journal of Atmospheric and Oceanic Technology*, 29(12): 1835-1844.
- Chen S M, Du Y, Fan L M, et al. 2002. Evaluation of the Guang Dong lightning location system with transmission line fault data[J]. *IEEE Proceedings-Science, Measurement and Technology*, 149(1): 9-16.
- 陈双,王迎春,张文龙,等. 2011. 复杂地形下雷暴增强过程的个例研究[J]. *气象*, 37(07):802-813.
- Chen Shuang, Wang Yingchun, Zhang Wenlong, et al. 2011. Intensifying mechanism of the convective storm moving from the mountain to the plain over Beijing area (in Chinese). *Meteorological Monthly*, 37(7):802-813.
- Chen T, Guestrin C. 2016. Xgboost: A scalable tree boosting system[C]//*Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*: 785-794.
- Cooper M A, Holle R L, Cooper M A, et al. 2019. Current Global Estimates of Lightning Fatalities and Injuries[J]. *Reducing Lightning Injuries Worldwide*: 65-73.
- Cui Y, Zheng D, Zhang Y, et al. 2022. Association of lightning occurrence with precipitation cloud column structure at a fixed position[J]. *Atmospheric Research*, 267: 105989.
- Dixon M, Wiener G. 1993. TITAN: Thunderstorm identification, tracking, analysis, and nowcasting-A radar-based methodology[J]. *Journal of atmospheric and oceanic technology*, 10: 785-785.
- Elsenheimer C B, Gravelle C M. 2019. Introducing lightning threat messaging using the GOES-16 day cloud phase distinction RGB composite[J]. *Weather and Forecasting*, 34(5): 1587-1600.

481 Geng Y, Li Q, Lin T, et al. 2021. A deep learning framework for lightning forecasting with multi-source
482 spatiotemporal data[J]. Quarterly Journal of the Royal Meteorological Society, 147(741):
483 4048-4062.

484 Golik P, Doetsch P, Ney H. 2013. Cross-entropy vs. squared error training: a theoretical and
485 experimental comparison[C]//Interspeech. 13: 1756-1760.

486 Guo S, Wang J, Gan R, et al. 2022. Experimental study of cloud-to-ground lightning nowcasting with
487 multisource data based on a video prediction method[J]. Remote Sensing. 27;14(3):604.

488 Han L, Chen M, Chen K, et al. 2021. A deep learning method for bias correction of ECMWF 24–240 h
489 forecasts[J]. Advances in Atmospheric Sciences, 38(9): 1444-1459.

490 Harris R J, Mecikalski J R, MacKenzie Jr W M, et al. 2010. The definition of GOES infrared lightning
491 initiation interest fields[J]. Journal of Applied Meteorology and Climatology, 49(12): 2527-2543.

492 Heikenfeld M, Marinescu P J, Christensen M, et al. 2019. toba 1.2: towards a flexible framework for
493 tracking and analysis of clouds in diverse datasets[J]. Geoscientific Model Development, 12(11):
494 4551-4570.

495 Holle R L. 2008. Annual rates of lightning fatalities by country[C]//20th International lightning
496 detection conference. 2425.

497 胡家晖, 卢楚翰, 姜有山, 等. 2022. 深度学习模型 TAGAN 在强对流回波临近预报中的应用[J].
498 大气科学, 46(4): 805–818. HU Jiahui, LU Chuhan, JIANG Youshan, et al. 2022. Application of
499 Deep Learning Model TAGAN in Nowcasting of Strong Convective Echo [J]. Chinese Journal of
500 Atmospheric Sciences (in Chinese), 46(4): 805–818.

501 Jin M, Shepherd J M, King M D. 2005. Urban aerosols and their variations with clouds and rainfall: A
502 case study for New York and Houston[J]. Journal of Geophysical Research: Atmospheres,
503 110(D10).

504 Johnson J T, MacKeen P L, Witt A, et al. 1998. The storm cell identification and tracking algorithm: An
505 enhanced WSR-88D algorithm[J]. Weather and forecasting, 13(2): 263-276.

506 Kingma D P, Ba J. 2014. Adam: A method for stochastic optimization[J]. arXiv preprint
507 arXiv:1412.6980.

508 Lin T, Li Q, Geng Y A, et al. 2019. Attention-based dual-source spatiotemporal neural network for
509 lightning forecast[J]. IEEE Access, 7: 158296-158307.

510 Liu Y, Yang L, Chen M, et al. 2024. A deep learning approach for forecasting thunderstorm gusts in the
511 Beijing–Tianjin–Hebei Region[J]. Advances in Atmospheric Sciences, 41(7): 1342-1363. Lu M,
512 Jin C, Yu M, et al. 2024. MCGLN: A multimodal ConvLSTM-GAN framework for lightning
513 nowcasting utilizing multi-source spatiotemporal data[J]. Atmospheric Research. 1;297:107093.

514 Luo C, Zhao X, Sun Y, et al. 2022. PredRANN: The spatiotemporal attention convolution recurrent
515 neural network for precipitation nowcasting[J]. Knowledge-Based Systems, 239: 107900.

516 Matthee R, Mecikalski J R. 2013. Geostationary infrared methods for detecting lightning-producing
517 cumulonimbus clouds[J]. Journal of Geophysical Research: Atmospheres, 118(12): 6580-6592.

518 Mecikalski J R, MacKenzie Jr W M, Koenig M, et al. 2010a. Cloud-top properties of growing cumulus

519 prior to convective initiation as measured by Meteosat Second Generation. Part I: Infrared
520 fields[J]. *Journal of Applied Meteorology and Climatology*, 49(3): 521-534.

521 Mecikalski J R, MacKenzie W M, König M, et al. 2010b. Cloud-top properties of growing cumulus
522 prior to convective initiation as measured by Meteosat Second Generation. Part II: Use of visible
523 reflectance[J]. *Journal of Applied Meteorology and Climatology*, 49(12): 2544-2558.

524 Mostajabi A, Finney D L, Rubinstein M, et al. 2019. Nowcasting lightning occurrence from commonly
525 available meteorological parameters using machine learning techniques[J]. *Npj Climate and*
526 *Atmospheric Science*, 2(1): 41.

527 Orlanski I. 1975. A rational subdivision of scales for atmospheric processes[J]. *Bulletin of the*
528 *American Meteorological Society*: 527-530.

529 郅秀书, 张义军, 张大林, 等. 2023. 雷电天气系统原理和预报[M], 北京: 科学出版社. Xie
530 Xiushu, Zhang Yijun, Zhang Daling, et al. 2023. Principles and Forecasting of Thunderstorm
531 Weather Systems (in Chinese) [M], Beijing: Science Press, 2023.

532 Roberts R D, Rutledge S. 2003. Nowcasting storm initiation and growth using GOES-8 and WSR-88D
533 data[J]. *Weather and Forecasting*, 18(4): 562-584.

534 Ronneberger O, Fischer P, Brox T. 2015. U-net: Convolutional networks for biomedical image
535 segmentation[C]//Medical image computing and computer-assisted intervention-MICCAI 2015:
536 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18.
537 Springer International Publishing: 234-241.

538 Shi H, Yang D, Wang W, et al. 2023. First estimation of high-resolution solar photovoltaic resource
539 maps over China with Fengyun-4A satellite and machine learning[J]. *Renewable and Sustainable*
540 *Energy Reviews*, 184: 113549.

541 Strabala K I, Ackerman S A, Menzel W P. 1994, Cloud Properties inferred from 8 12- μ m Data[J].
542 *Journal of Applied Meteorology and Climatology*, 33(2): 212-229.

543 Tao L, He X, Li J, et al. 2021. A multiscale long short-term memory model with attention mechanism
544 for improving monthly precipitation prediction[J]. *Journal of Hydrology*, 602: 126815.

545 Trebing K, Stańczyk T, Mehrkanoon S. 2021. SmaAt-UNet: Precipitation nowcasting using a small
546 attention-UNet architecture[J]. *Pattern Recognition Letters*, 145: 178-186.

547 Thiel K C, Calhoun K M, Reinhart A E, et al. 2020. GLM and ABI characteristics of severe and
548 convective storms[J]. *Journal of Geophysical Research: Atmospheres*, 125(17): e2020JD032858.

549 Woo S, Park J, Lee J Y, et al. 2018. CBAM: Convolutional Block Attention Module. Proceedings of the
550 European Conference on Computer Vision (ECCV), Munich, 8-14 September, 3-19.

551 Woo W, Wong W. 2017. Operational application of optical flow techniques to radar-based rainfall
552 nowcasting[J]. *Atmosphere*, 8(3): 48.

553 Woodard C J, Carey L D, Petersen W A, et al. 2012. Operational utility of dual-polarization variables in
554 lightning initiation forecasting[J]. *Electron. J. Oper. Meteor.*, 13: 79-102.

555 徐景峰, 宋林烨, 陈明轩, 等. 2023. 冬奥会复杂山地百米尺度 10m 风速预报的机器学习订正对比

556 试验[J]. 大气科学, 47(3): 805–824. Xu J F, Song L Y, Chen M X, et al. 2023. Comparative
557 Machine Learning-Based Correction Experiment for a 10 m Wind Speed Forecast at a 100 m
558 Resolution in Complex Mountainous Areas of the Winter Olympic
559 Games[J]. Chinese Journal of Atmospheric Sciences (in Chinese), 47(3): 805–824.

560 张延彪, 宋林烨, 陈明轩, 等. 2022a. 基于卷积神经网络的京津冀地区高分辨率格点预报偏差订
561 正试验[J].大气科学学报, 45(06):850-862. Zhang Y B, Song Y B, Chen M X, et al. 2022a. A
562 study of error correction for high-resolution gridded forecast based on a convolutional neural
563 network in the Beijing-Tianjin-Hebei Region[J]. Trans Atmos Sci, 45(6): 850-862.

564 张延彪, 陈明轩, 韩雷, 等. 2022b. 数值天气预报多要素深度学习融合订正方法[J].气象学报,
565 80(01):153-167. Zhang Y, Chen M, Han L, et al. 2022b. Multi-element deep learning fusion
566 correction method for numerical weather prediction[J]. Acta Meteorol. Sin, 80: 153-167.

567 Zhou K, Zheng Y, Dong W, et al. 2020. A deep learning network for cloud-to-ground lightning
568 nowcasting with multisource data[J]. Journal of Atmospheric and Oceanic Technology, 37(5):
569 927-942.

570 Zhou X, Geng YA, Yu H, et al. 2022. LightNet+: A dual-source lightning forecasting network with
571 bi-direction spatiotemporal transformation[J]. Applied Intelligence. 52(10):11147-59.

572 朱延和, 朱寿鹏, 夏平, 等. 2024. 基于 U-net 神经网络的新疆 10 m 风速预报订正研究[J]. 大
573 气科学, 48(6): 2300–2315. ZHU Yanhe, ZHU Shoupeng, XIA Ping, et al. 2024. Forecast
574 Calibration of 10-m Wind Speed over Xinjiang Based on a U-net Neural Network [J]. Chinese
575 Journal of Atmospheric Sciences (in Chinese), 48(6): 2300–2315.