

基于卫星红外通道数据的闪电高密度区域识别^①



张慧¹, 宋琳^{2,3}, 曹伟^{2,4}, 王彪¹, 李杰¹, 肖萌萌¹, 张其林¹

¹(南京信息工程大学 自动化学院, 南京 210044)

²(中国气象局雷电重点开放实验室, 北京 100081)

³(青岛市生态与农业气象中心, 青岛 266003)

⁴(中国电力科学研究院有限公司, 武汉 430074)

通信作者: 宋琳, E-mail: qdsonglinyy@163.com

摘要: 闪电因破坏性强、致灾风险高, 其精准监测是防灾减灾的关键环节. 静止气象卫星 (如葵花-8) 凭借大范围、连续观测的优势, 为闪电监测提供了理想平台, 但卫星云图与闪电活动的物理关联机制尚未明确, 制约了实际应用. 本文利用葵花卫星数据和甚低频远距离闪电探测网数据, 提出 AE-UNet 模型, 实现基于卫星云图的闪电高密度区识别. AE-UNet 模型嵌入通道注意力机制和残差连接, 自适应深层融合卫星多通道特征; 在不同尺度特征拼接过程中嵌入通道-空间双重注意力机制, 充分挖掘空间关联关系. 实验结果表明, AE-UNet 的闪电识别准确率达 97.91%, 命中率 (*POD*) 达 67.47%, 虚警率 (*FAR*) 达 26.92%, 较基准模型性能提升显著. 该模型能根据卫星云图提供可靠的闪电活动信息, 有力支撑防灾减灾工作.

关键词: 闪电识别; 葵花卫星; 注意力机制; 防灾减灾

引用格式: 张慧, 宋琳, 曹伟, 王彪, 李杰, 肖萌萌, 张其林. 基于卫星红外通道数据的闪电高密度区域识别. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/10099.html>

Identification of High-density Lightning Area Based on Satellite Infrared Channel Data

ZHANG Hui¹, SONG Lin^{2,3}, CAO Wei^{2,4}, WANG Biao¹, LI Jie¹, XIAO Meng-Meng¹, ZHANG Qi-Lin¹

¹(School of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China)

²(Key Open Laboratory of Lightning of China Meteorological Administration, Beijing 100081, China)

³(Qingdao Ecological and Agricultural Meteorological Center, Qingdao 266003, China)

⁴(China Electric Power Research Institute Co, Ltd., Wuhan 430074, China)

Abstract: Due to its highly destructive nature and significant disaster risk, accurate lightning monitoring is a crucial component of disaster prevention and mitigation. Geostationary meteorological satellites, such as Himawari-8, provide an ideal platform for lightning monitoring with the advantages of broad coverage and continuous observation. However, the physical correlation mechanism between satellite cloud images and lightning activity remains unclear, which restricts practical application. This study proposes the AE-UNet model, which utilizes Himawari satellite data and VLF long-range lightning detection network data, identifying high-density lightning areas from satellite cloud images. The AE-UNet model incorporates a channel attention mechanism and residual connections to adaptively and deeply fuse the multi-channel satellite features. During the concatenation of multi-scale features, a channel-space dual attention mechanism is embedded to fully explore spatial correlations. The experimental results show that the AE-UNet model achieves a lightning identification accuracy of 97.91%, a probability of detection (*POD*) of 67.47%, and a false alarm rate (*FAR*) of 26.92%, demonstrating significant performance improvement over the benchmark model. The proposed model can provide reliable lightning activity information based on satellite cloud images, thereby strongly supporting disaster prevention and mitigation efforts.

^① 基金项目: 中国气象局雷电重点开放实验室开放课题 (2024KELL-B013)

收稿时间: 2025-08-31; 修改时间: 2025-09-22; 采用时间: 2025-10-14; csa 在线出版时间: 2026-01-15

Key words: lightning identification; Himawari satellite; attention mechanism; disaster prevention and mitigation

闪电作为最具破坏性的自然现象之一,其高能量放电不仅直接威胁人类生命安全,还可能引发山火、电力故障等次生灾害,对电力系统、航空安全和森林火灾防控构成重大挑战^[1]. 据统计,全球每年因雷电导致的伤亡人数超过 4000 人,经济损失高达数十亿美元^[2]. 因此,准确监测闪电的位置分布对于防灾减灾和保障社会安全至关重要. 传统闪电监测主要依赖低频/甚低频 (very low frequency, VLF) 地面闪电定位网络^[3,4],但这些方法受限于地形遮挡和区域覆盖不足^[5,6],在海洋、高原和偏远地区存在显著的监测盲区^[3],且原始数据多受商业版权限制,公共获取存在壁垒. 新一代静止气象卫星凭借其广覆盖、高时效、免费公开的观测特性^[7-9],为发展闪电监测算法、构建开放共享的监测体系提供了不可替代的数据基础.

近年来,闪电触发机制的研究表明,云顶亮温降低、水汽分布变化等特征与雷暴活动高度相关,这些特征可通过多光谱卫星观测数据捕捉并量化. Bruning 等人^[10]在 2024 年通过 TRACER 实测证实,云顶亮温降低和上升气流体积增加均显著提升闪电发生概率与强度. 静止气象卫星具备大范围、连续、高时空分辨率和多光谱观测优势,能够实时监测云层亮温、水汽分布、云顶高度等关键的对流性天气参数,为雷暴云团宏观结构和微观物理特性提供完整、连续的观测信息^[11,12]. 相较于地面观测,卫星遥感数据在海洋、高原及偏远地区覆盖能力更强,适合大区域强对流天气监测与闪电预报业务应用. 尤其是多通道亮温资料可同时反映云顶亮温、中高层水汽及云体内部辐射特性^[13,14],具备挖掘云物理特性与闪电活动关联关系的潜力. 然而在实际建模过程中,由于物理特性之间存在复杂、多尺度、非线性的相互作用关系,存在以下问题: 1) 强对流云团区域内特征复杂、多尺度叠加、云体边界模糊,导致模型难以有效聚焦雷暴核心区域,影响高密度闪电区域的定位精度; 2) 不同通道卫星观测数据对闪电发生的识别度存在差异,原始卷积结构无法动态感知通道间的重要性,限制了多通道特征融合效果.

针对以上问题,本文以 LF/VLF 广域闪电探测网的闪电时间数据为主要数据源,利用 TBB_09 通道表征的中高层水汽分布,结合 TBB_13 通道的云顶高度信息,

提出了 AE-UNet (attention enhanced U-Net) 模型,对闪电位置分布进行建模,基于深度学习方法挖掘对流层中高层水汽和云顶高度与闪电的物理关联,实现对闪电高密度区域识别. 首先,通过基于通道注意力的 Wea-FeatureEnhancer 模块增强多通道卫星数据的特征提取能力;其次,在编码器和解码器子模块中引入残差连接,有效优化深层特征融合过程,缓解梯度消失;最后,在不同尺度特征图拼接过程中嵌入融合通道-空间双重注意力机制的 CBAM 模块 (convolutional block attention module),充分挖掘空间关联关系.

1 数据来源与预处理

1.1 卫星数据

本研究所采用的卫星数据来源于日本气象厅新一代静止气象卫星葵花 8 号 (Himawari-8),该卫星搭载的先进葵花成像仪 (advanced Himawari imager, AHI) 具备多个观测通道,其中包含 3 个可见光通道、2 个近红外通道以及 10 个红外通道 (包括 3 个水汽通道及 7 个窗区通道). 由于可见光通道和近红外通道受昼夜条件限制,仅在白天提供观测数据,故本文选择全天候可用的红外通道进行闪电识别.

已有的多项研究表明,红外窗区通道 (尤其是 10.4 μm) 亮温降低与强对流活动及雷暴发生呈显著负相关,且亮温越低,闪电发生概率越高^[15-17]. 此外,已有研究基于多红外通道亮温及亮温差异开发对流初生识别方法,并验证了相关亮温特征对强对流及雷暴活动指示作用的有效性^[15]. 根据各红外通道的观测物理特性以及对强对流天气系统热力结构的表征能力,本文选取了 TBB_09 (6.9 μm 水汽通道) 和 TBB_13 (10.4 μm 窗区通道) 作为与闪电发生密切相关的关键参数通道. 如表 1 所示, TBB_09 通道可反映高空水汽含量及对流活动强弱, TBB_13 通道则常用于监测云顶亮温变化,进而指示对流单体发展强度.

1.2 闪电数据

由于目前大范围的地基闪电探测主要基于甚低频闪电探测网,而在中国区域 WWLLN (world wide lightning location network)^[18]已不再公开共享,且存在探测效率低等问题. 天基的公开的闪电数据集 (如风云 4A

闪电探测仪)存在数据完整性不足、探测效率低且服务已停运的问题. 这些数据集的不完备性严重影响了基于数据驱动的深度学习的训练与映射关系构建.

表1 本文选取的卫星通道

通道名称	定义	物理含义
TBB_09	6.9 μm 亮温	对流层中高层水汽
TBB_13	10.4 μm 亮温	云顶高度

因此本研究使用的闪电定位数据来源于南京信息工程大学团队自主研发的甚低频远距离闪电探测网(very low frequency long-range lightning location network, VLF-LLN)^[19,20]. 该探测网始建于2021年,并于2023年完成建设,其定位精度中值误差为1.81 km. VLF-LLN单站探测范围超过3000 km,组网覆盖范围可有效涵盖中国大陆及其周边地区,包括森林、高原、海洋等无人值守区域. 与其他闪电观测数据(FY-4A闪电探测仪、WVLLN等)相比,VLF-LLN提供了更加连续、稳定和高效的探测能力,为本研究提供了丰富的雷暴活动样本. 其输出的闪电事件数据包含时间、经纬度、极性、闪电回击峰值电流等信息^[21]. 本研究使用了2023年7月17日–2024年7月21日期间全国的闪电事件发生时间与经纬度数据.

对于每个时间段,将基于VLF-LLN收集的闪电数据根据经纬度信息投影到与葵花卫星数据相同的网格中,生成原始闪电散点图,并确保闪电图片与卫星图片在时间和空间上进行对齐,数据一一对应相互匹配. 但由于闪电的固有随机性,仅将闪电事件直接分配到格点中所生成的图片过于离散. 为克服闪电数据的稀疏性,本文对闪电数据进行扩散处理. 由于雷电事件通常具有空间上横向扩展性,因此本文使用高斯核雷电频次图进行平滑处理^[22],从而模拟雷电在大气中的横向扩展.

已有研究的统计结果表明^[23],大多数闪电分支延伸在3–10 km,但仍然有少部分的闪电可延伸至20 km,其距离分布近似于高斯分布,所以在这个二维高斯分布覆盖范围内的区域都应考虑闪电的影响. 因此,本文将高斯核的半径设置为20 km. 该分布既可以覆盖主要分布,又可以有效缓解单点标签过于稀疏的问题,平滑训练标签. 具体的高斯扩散公式如下:

$$Gaussian(x,y) = \exp\left(-\frac{x^2+y^2}{2\sigma^2}\right) \quad (1)$$

其中, σ 为高斯核的标准差,根据高斯分布的 3σ 规则

(约99.73%的数据会落在平均值的正负3个标准差范围内),设定为半径的1/3,即 $\sigma=20\text{ km}/3=6.67\text{ km}$.

然后,对每个网格点的闪电频次进行了归一化,通过式(2)将频次 D 映射为0–1之间的概率值.

$$D' = 1 - \frac{1}{e^D} \quad (2)$$

其中, D' 为归一化后的闪电发生概率, D 为闪电频次.

式(2)能够有效地将频次分布转化为一个概率分布图,处理后的图片为连续概率图,值范围为[0, 1],概率值高的区域(接近1)表示闪电高发区域,并以扩散后的闪电概率分布图作为模型训练的标签数据. 图1为样本数据的可视化,图1(a)和图1(b)为TBB_13和TBB_09通道的红外亮温图像,图1(c)为扩散处理后的标签,图1(d)为VLF-LLN的原始闪电定位点图像.

2 研究方法

由于雷电的发生机制复杂、受多尺度、多变量共同影响,传统显式物理模型难以全面刻画其发生规律. 因此,本文采用数据驱动的方式,建立水汽、云顶温度与闪电活动之间的空间关联映射关系,将多通道的卫星观测数据作为输入,闪电位置分布作为同尺寸单通道输出,建立端到端的映射模型AE-UNet. 模型可以更好地挖掘卫星云图与闪电分布之间的复杂空间关联关系,实现高精度闪电概率图的预测,其整体结构如图2所示.

2.1 模型构建

尽管传统的U-Net模型在像素级预测任务中表现优异^[24],凭借跳跃连接结构有效融合了深层语义信息与浅层空间细节,但其固定感受野的卷积操作难以捕捉长距离依赖特征,对复杂强对流云团、多尺度叠加和高密度闪电区域的识别能力有限. 除此之外,U-Net对不同通道观测数据的重要性无法动态感知,缺乏针对多通道卫星资料特征贡献差异的优化机制,容易导致对强对流核心区和高密度闪电区域的关注不足.

为克服上述问题,本文在U-Net基础上提出了一种融合注意力机制与特征增强模块的改进模型attention enhanced U-Net(AE-UNet). AE-UNet模型主体部分如图2(a)所示. 首先,AE-UNet将维度为 $2 \times 128 \times 128$ 的卫星图像输入WeaFeatureEnhancer模块得到 $32 \times 128 \times 128$ 的输出. 该输出随后进入图2(a)左侧由5层Encoder block组成的编码路径,通过连续的卷积

和池化操作提取多尺度特征,得到尺寸为 $1024 \times 128 \times 128$ 的特征图;图 2(a) 右侧由 4 层 Decoder block 组成的解码路径则采用上采样和卷积操作逐步恢复空间分辨率,最终得到 $1 \times 128 \times 128$ 的模型输出.此外,在编码器和解

码器特征图尺寸相同的对应层之间引入跳跃连接,即将不同层的编码器的特征图经过通道-空间双重注意力模块 (CBAM) 获取深层语义信息,并与对应尺度上的解码器给出的空间细节进行融合.

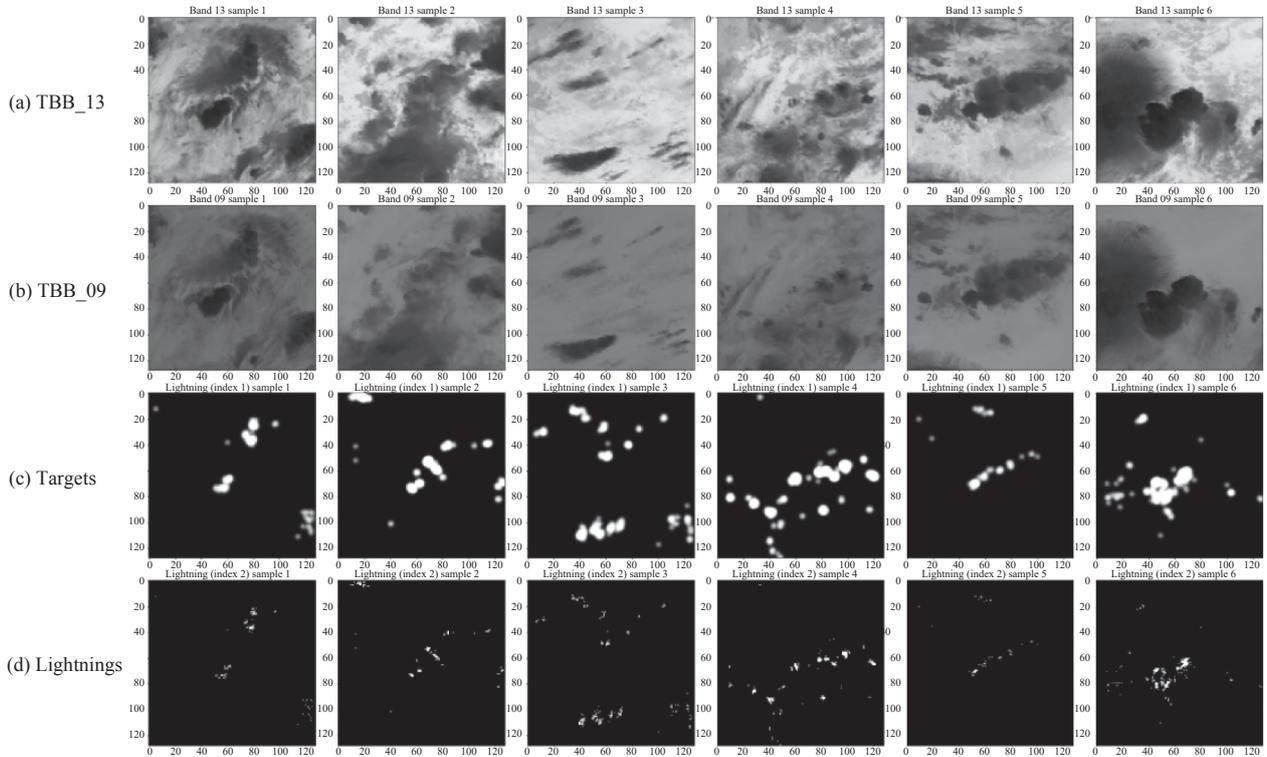


图 1 预处理后的样本数据

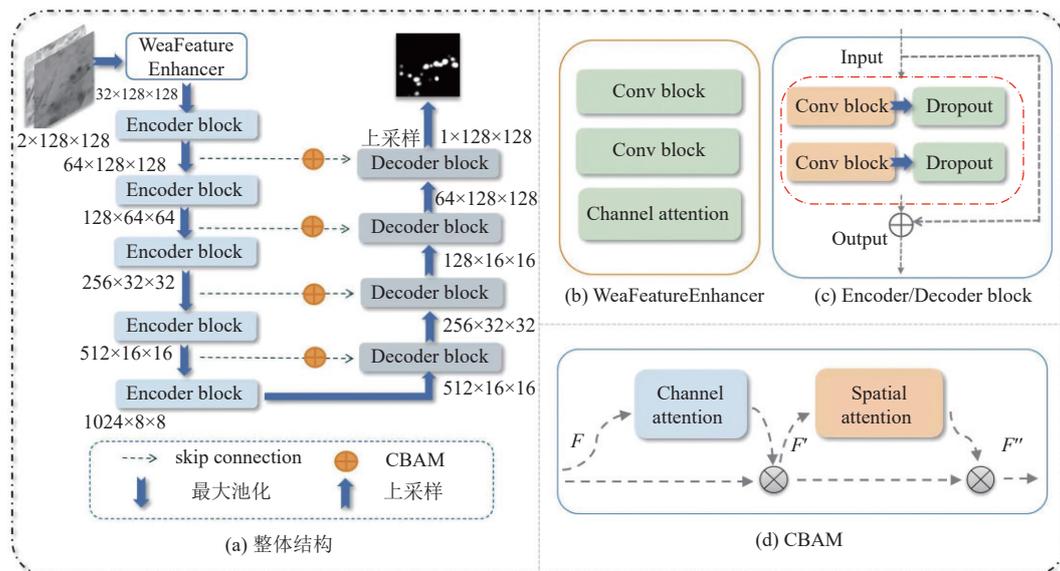


图 2 AE-UNet 结构

该模型在保持对称式编码器-解码器结构和跳跃连接机制的基础上,主要引入了以下改进.

(1) 在编码器中引入特征增强模块 (WeaFeature-Enhancer), 该模块由两层卷积与通道注意力层组成, 如

图 2(b) 所示. 该模块可以对输入特征进行逐层筛选和强化, 提升多通道卫星亮温数据中强对流云团特征、水汽分布及云顶温度信息的提取能力, 为后续闪电概率图预测提供更充分的特征支撑.

(2) 在编码器与解码器的卷积单元 (Encoder/Decoder block) 中采用残差结构 (如图 2(c) 所示). 在图 2(c) 红色虚线框内表示原始的两层卷积网络, 在此基础上将输入特征通过跨层连接方式与通过两层卷积的原始输出特征的叠加, 得到最终的输出, 其中“⊕”表示拼接操作. 该结构可以缓解梯度消失问题, 提高深层特征传递与融合效果, 从而提升训练稳定性与预测精度.

(3) 在每一层级的跳跃连接处嵌入了通道-空间双重注意力模块 CBAM, 该模块用于聚焦闪电高发区域以及动态调整多通道特征的重要性.

CBAM 是一种轻量且高效的注意力机制模块, 其核心思想是沿通道维度和空间维度顺序推断注意力权重, 并与输入特征逐元素相乘, 以实现自适应的特征优化^[25] (如图 2(d) 所示). 该机制能够在保持较低计算开销的同时突出关键区域特征表达, 聚焦强对流云团及

闪电高发区域, 抑制背景噪声, 从而弥补传统 U-Net 固定感受野及缺乏区域聚焦能力的不足. 在具体实现上, 设输入特征为 $F \in R^{C \times H \times W}$, CBAM 首先通过通道注意力生成权重 M_c , 并与输入特征相乘得到通道增强结果, 再将其作为输入送入空间注意力模块, 得到权重 M_s 并进一步优化, 最终输出表示为:

$$F' = M_c(F) \otimes F \tag{3}$$

$$F'' = M_s(F') \otimes F' \tag{4}$$

其中, \otimes 表示逐元素相乘.

通道注意力和空间注意力模块如图 3 所示. 通道注意力通过对输入特征分别进行全局平均池化和最大池化, 将其压缩为两个 $C \times 1 \times 1$ 的描述向量, 经多层感知机 (MLP) 映射并相加后, 通过 Sigmoid 函数生成通道注意力权重 M_c , 从而突出对预测贡献显著的通道并抑制冗余信息. 空间注意力则在通道维度进行平均池化和最大池化, 得到两个 $1 \times H \times W$ 的二维特征图, 拼接后通过 7×7 卷积生成空间注意力权重 M_s , 以强化关键区域的空间响应并削弱背景干扰.

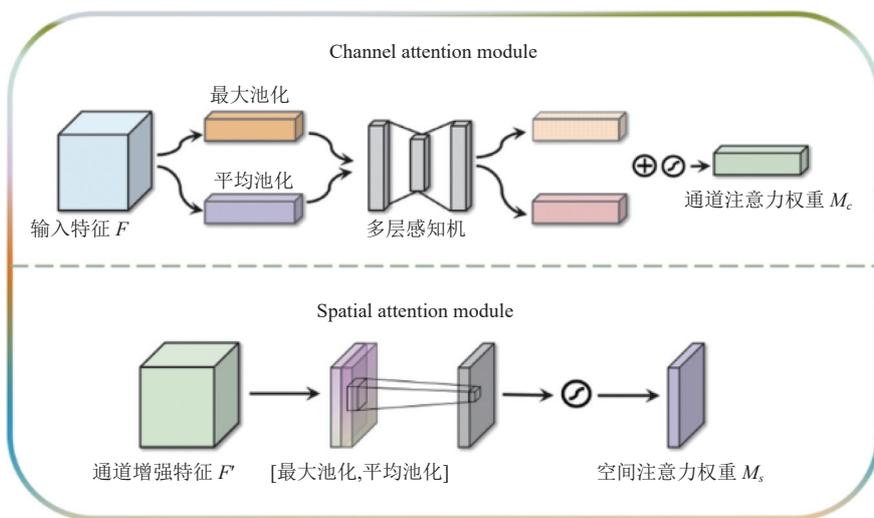


图 3 通道注意力与空间注意力

2.2 损失函数

在闪电分布识别任务中, 闪电现象通常占据图像中极少部分区域, 而大部分区域是无闪电的背景. 这种严重的不平衡性会导致模型在训练时倾向于优先预测背景区域, 从而忽视少量的闪电目标区域. 因此本文使用了 $DiceLoss$ 作为损失函数, 以解决闪电识别任务中正负样本不平衡的问题. $DiceLoss$ 基于 $Dice$ 系数, 旨

在优化预测闪电概率图与真实闪电概率图的重叠区域, 具体实现中, $DiceLoss$ 首先计算预测值和真实值之间的 $Dice$ 系数, 然后将其转换为损失值, 公式如下:

$$Dice = \frac{2 \sum_{i=1}^N (y_i \cdot \hat{y}_i) + \epsilon}{\sum_{i=1}^N y_i^2 + \sum_{i=1}^N \hat{y}_i^2 + \epsilon} \tag{5}$$

$$DiceLoss = 1 - Dice \tag{6}$$

其中, y_i 为真实标签, \hat{y}_i 为模型预测的概率, N 为像素总数, ϵ 为平滑因子, 避免分母为 0, 设定为 1×10^{-6} . $DiceLoss$ 通过最大化预测值和真实值之间的重叠区域, 鼓励模型在闪电稀疏地区中更好地学习特征.

3 实验过程及结果

3.1 实验细节

本研究基于 PyTorch 深度学习框架, 使用 NVIDIA RTX 3060 GPU 进行模型训练和测试. 输入为葵花卫星的 TBB_09 和 TBB_13 通道数据, 模型输出为与输入数据同一时刻的闪电识别概率图, 空间分辨率均为 128×128 . 模型训练过程中采用了 Adam 优化器进行参数优化, 初始学习率为 10^{-4} . 模型训练共进行 60 轮迭代, 并在验证集上选择性能最优的模型用于测试. 为避免过拟合, 本文引入了早停机制, 即当验证集上的损失连续 15 轮迭代未下降时停止训练. 为提升模型的泛化能力, 在训练过程中应用了数据增强技术, 包括随机水平翻转、随机垂直翻转和随机旋转 ($\pm 30^\circ$). 此外, 为了进一步保证训练的稳定性, 对梯度进行裁剪 (gradient clipping), 最大范数 (max norm) 设为 1.

图 4 展示了模型在训练过程中, 训练和验证损失随迭代轮次 (Epoch) 的变化, 模型在第 60 个 Epoch 内稳定收敛, 训练损失平滑下降, 验证损失总体随之下降并在后期趋于稳定, 此时模型有较好的泛化能力.

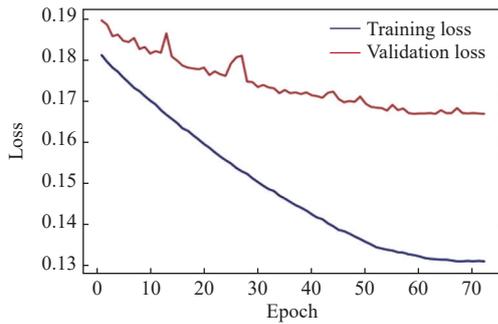


图 4 模型训练和验证损失曲线

3.2 评估指标

为全面评估 AE-UNet 模型在闪电高密度区识别任务中的性能, 本文设计了基于图像预测的指标和基于闪电预测的指标. 实验使用两种真实标签数据: (1) Lightnings, 即 VLF-LLN 数据提供的原始闪电点数据, 反映闪电事件的精确位置; (2) Targets, 通过扩散方法基于闪电散点生成的连续型概率分布图, 描述闪电高

发区域的空间概率特征. 本研究以 Targets 作为模型训练与主要评估标准, 衡量模型在闪电识别中的表现, 同时以 Lightnings 为辅助参考, 从闪电事件定位角度补充分析模型性能, 确保评估结果的全面性与客观性.

闪电识别任务可以看作是一个像素级二分类问题, 模型输出为识别出的闪电概率图. 本文以 Targets 标签为标准, 采用峰值信噪比 (PSNR) 和结构相似性 (SSIM) 评估输出的闪电概率图与真实闪电概率图之间的相似性. PSNR 通过比较预测图像与真实闪电概率图之间的均方误差 (MSE) 来衡量图像质量, PSNR 越高, 表示预测图像与真实图像越相似. SSIM 从亮度、对比度和结构这 3 个方面评估图像相似性, SSIM 值范围为 [0, 1], 值越接近 1 表示两幅图越相似. 公式表示如下:

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX^2}{MSE} \right) \quad (7)$$

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (8)$$

为评估模型在闪电高密度区域识别任务中的性能, 本文采用命中率 (POD)、虚警率 (FAR)、临界成功指数 (CSI)、偏差 (Bias)、准确率 (Accuracy) 作为评价指标, 阈值设为 0.5. 这些指标基于闪电事件的命中 (Hit)、误报 (False)、漏报 (Miss)、正确否定 (Correct Negative) 进行计算. Hit 表示预测闪电位置与真实闪电位置重叠, 即实际发生了闪电, 预测也发生了闪电; False 表示预测的闪电位置没有对应的真实闪电位置, 即实际没有发生闪电, 但预测发生了闪电; Miss 表示真实闪电位置未被预测到, 即实际发生了闪电, 但预测未发生闪电; Correct Negative 表示预测和真实均无闪电. 根据以上规则, 对预测方法进行评估, 公式表示为:

$$POD = \frac{Hit}{Hit + Miss} \quad (9)$$

$$FAR = \frac{False}{Hit + False} \quad (10)$$

$$CSI = \frac{Hit}{Hit + Miss + False} \quad (11)$$

$$Bias = \frac{Hit + False}{Hit + Miss} \quad (12)$$

$$Accuracy = \frac{Hit + Correct\ Negative}{Hit + Miss + False + Correct\ Negative} \quad (13)$$

3.3 结果分析

在 Targets 场景下, 本文提出的 AE-UNet 与多种

基线模型的定量比较结果如表 2 所示. 整体来看, AE-UNet 在综合性能上表现最为优异, 其 *CSI* 达到 0.5403, 相较其他方法提升 1.20%–2.11%. 在命中率 (*POD*) 方面, AE-UNet 的数值为 0.6747, 较现有模型提升幅度为 0.91%–3.45%, 表明其对闪电发生区域具有更强的探测能力. 虽然虚警率 (*FAR*) 略高于部分模型, 但整体水平接近, 且 *Bias* 值为 0.9239, 更接近理想值 1, 说明

模型在预测区域规模上与真实情况吻合度较高, 虚警得到了有效控制. 在图像预测质量方面, AE-UNet 的 *PSNR* 达 21.0049 dB, *SSIM* 高达 0.9991, 显示其在区域分布和边界刻画上均能保持较高的精度与结构相似性. 上述结果表明, AE-UNet 在保持较低虚警率的同时, 有效提升了位置识别性能, 能够更准确地表征闪电空间分布特征.

表 2 不同模型关键评估指标的定量对比

模型名称	<i>POD</i>	<i>FAR</i>	<i>CSI</i>	<i>Bias</i>	<i>Accuracy</i>	<i>SSIM</i>	<i>PSNR</i> (dB)
U-Net	0.6402	0.2668	0.5192	0.8738	0.9784	0.9990	20.8972
SegNet	0.6449	0.2624	0.5246	0.8746	0.9787	0.9991	20.9839
DeepLabV3	0.6656	0.2821	0.5283	0.9230	0.9783	0.9991	20.9909
Att-UNet	0.6510	0.2672	0.5261	0.8889	0.9716	0.9990	20.9950
AE-UNet	0.6747	0.2692	0.5403	0.9239	0.9791	0.9991	21.0049

识别结果与真实值 (ground truth) 及 U-Net、SegNet、DeepLabV3 和 Att-UNet 的预测对比如图 5 所示, 各样本相互独立且具有代表性. 整体结果与表 2 的定量评估一致: DeepLabV3 的预测中存在较为明显的虚警区域, SegNet 的预测偏向保守, 导致部

分强对流区域未能被有效识别; U-Net 在强对流区域的识别方面具备一定能力, 但预测轮廓存在模糊与偏移现象; Att-UNet 在引入注意力机制后, 虚警问题得到一定缓解, 边界较为清晰, 但仍然存在漏检情况.

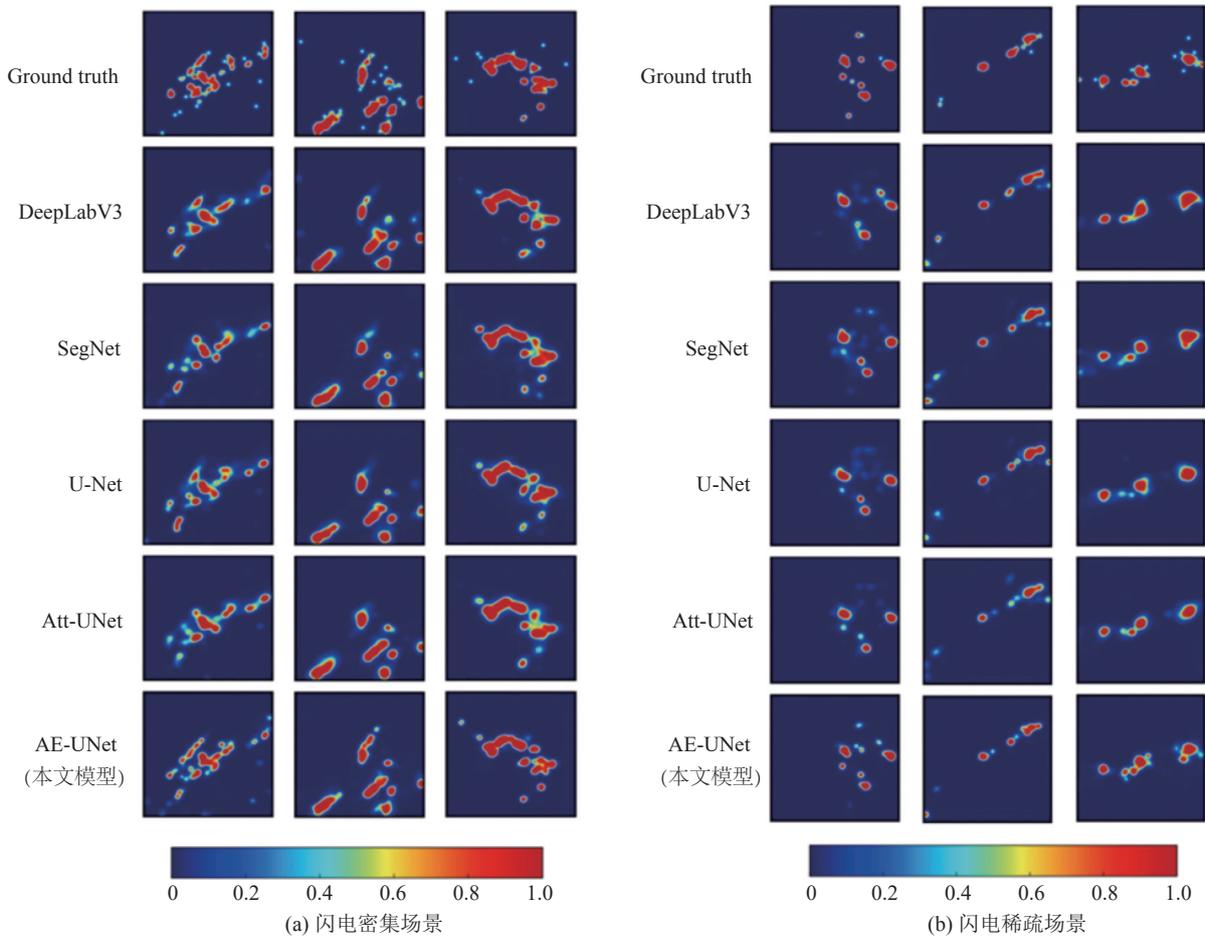


图 5 不同模型的闪电识别结果

相比之下,本文提出的 AE-UNet 在所有样本中均展现出更优越的预测性能. 无论是在闪电密集 (如图 5(a)), 还是稀疏分散 (如图 5(b)) 的场景下, AE-UNet 均能够准确捕捉高概率区域的形状、范围及分布特征, 其预测轮廓与真实值高度一致. 同时, 虚警显著减少, 预测结果整体更加完整、连贯. 上述性能提升主要得益于 AE-UNet 中引入的 WeaFeatureEnhancer 模块与通道-空间注意力模块, 这些设计增强了模型对闪电高

概率区域结构特征的敏感性, 并有效提升了对小尺度及弱信号区域的识别能力.

不同模型所识别的区域与真实观测闪电点的叠加如图 6 所示, 红色表示实际观测到的闪电位置, 蓝色区域为模型的预测输出. 可以看出, 该模型预测的分布不仅考虑到了极其稀疏的闪电事件对周围区域的影响, 并且概率密度较大的中心区域较好地覆盖了闪电发生的位置.

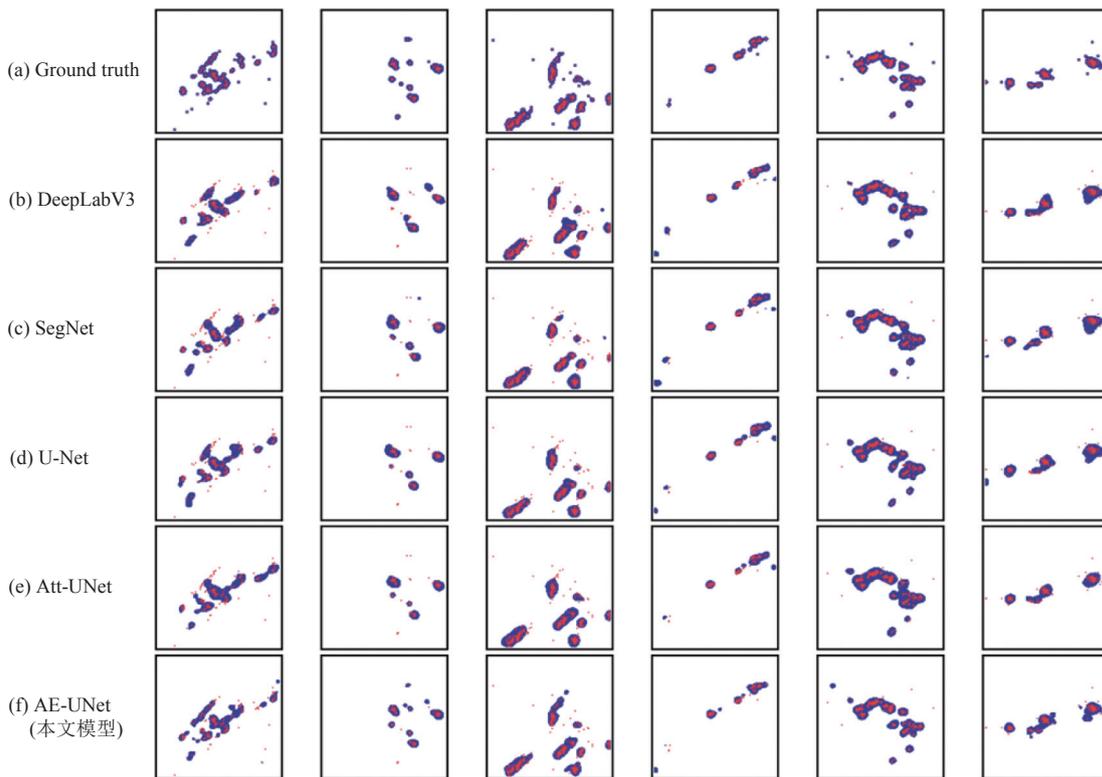


图 6 不同模型所识别的区域与真实观测闪电点的叠加

4 总结

本文针对闪电监测的空间覆盖不足与数据获取受限等问题, 提出了一种基于静止气象卫星红外观测的深度学习方法——AE-UNet, 用于实现闪电发生位置概率分布和高密度区的高精度识别. 该模型在经典 U-Net 框架的基础上引入了多项改进: 通过 WeaFeatureEnhancer 模块强化卫星多通道亮温特征提取能力; 在编码器与解码器中引入残差结构以提升深层特征传递与融合效果; 并在跳跃连接中嵌入 CBAM 模块, 实现通道与空间双重注意力的自适应建模, 从而增强对强对流云团及闪电高发区域的识别能力. 实验结果表明, AE-UNet 在多项评价指标上均显著优于现有对比模

型. AE-UNet 能够在不同分布形态下准确捕捉闪电高概率区域, 识别结果与观测值高度一致, 虚警显著减少且空间分布更加连贯.

未来的研究可从以下两方面进一步拓展. 首先, 本文未直接引入亮温阈值或亮温降低值等先验条件, 而是依赖深度学习自动学习亮温与闪电之间的非线性关系. 未来研究可考虑在深度学习框架中融入亮温阈值等气象学先验知识, 与数据驱动方法相结合, 以增强模型的物理解释性和区域适应性. 此外, 还可进一步探索多源卫星观测 (如可见光、近红外及水汽通道) 的联合建模, 以挖掘更丰富的云物理特征; 并在本文高密度区域识别模型的基础上增加前置的有无雷暴区域二分类

判断,增强模型对闪电发生演变过程的刻画能力,从而为强对流天气的精细化监测与预测提供更为全面的技术支持。

参考文献

- 1 郑栋, 张文娟, 姚雯, 等. 雷暴闪电活动特征研究进展. 热带气象学报, 2021, 37(3): 289–297. [doi: 10.16032/j.issn.1004-4965.2021.027]
- 2 Holle RL. A summary of recent national-scale lightning fatality studies. *Weather, Climate, and Society*, 2016, 8(1): 35–42. [doi: 10.1175/WCAS-D-15-0032.1]
- 3 Cummins KL, Murphy MJ. An overview of lightning locating systems: History, techniques, and data uses, with an in-depth look at the U.S.NLDN. *IEEE Transactions on Electromagnetic Compatibility*, 2009, 51(3): 499–518. [doi: 10.1109/TEMC.2009.2023450]
- 4 王宇, 郝秀书, 王东方, 等. 北京闪电综合探测网(BLNET): 网络构成与初步定位结果. *大气科学*, 2015, 39(3): 571–582. [doi: 10.3878/j.issn.1006-9895.1407.14138]
- 5 郑嘉怡, 陆高鹏, 刘非凡, 等. 基于全球闪电定位网的江淮闪电定位网探测效率分析: 以台风“利奇马”为例. *热带气象学报*, 2023, 39(1): 129–138. [doi: 10.16032/j.issn.1004-4965.2023.012]
- 6 Rudlosky SD. Evaluating ground-based lightning detection networks using TRMM/LIS observations. *Proceedings of the 23rd International Lightning Detection Conference & 5th International Lightning Meteorology Conference*. Tucson, 2014.
- 7 Bessho K, Date K, Hayashi M, *et al.* An introduction to Himawari-8/9—Japan’s new-generation geostationary meteorological satellites. *Journal of the Meteorological Society of Japan*. Ser. II, 2016, 94(2): 151–183. [doi: 10.2151/jmsj.2016-009]
- 8 Goodman SJ, Gurka J, DeMaria M, *et al.* The GOES-R proving ground: Accelerating user readiness for the next-generation geostationary environmental satellite system. *Bulletin of the American Meteorological Society*, 2012, 93(7): 1029–1040. [doi: 10.1175/BAMS-D-11-00175.1]
- 9 Yang J, Zhang ZQ, Wei CY, *et al.* Introducing the new generation of Chinese geostationary weather satellites, Fengyun-4. *Bulletin of the American Meteorological Society*, 2017, 98(8): 1637–1658. [doi: 10.1175/BAMS-D-16-0065.1]
- 10 Bruning EC, Brunner KN, van Lier-Walqui M, *et al.* Lightning and radar measures of mixed-phase updraft variability in tracked storms during the TRACER field campaign in Houston, Texas. *Monthly Weather Review*, 2024, 152(12): 2753–2769. [doi: 10.1175/MWR-D-24-0060.1]
- 11 Yamamoto Y, Ichii K, Higuchi A, *et al.* Geolocation accuracy assessment of Himawari-8/AHI imagery for application to terrestrial monitoring. *Remote Sensing*, 2020, 12(9): 1372. [doi: 10.3390/rs12091372]
- 12 王雪芹, 徐卫红, 向朔育, 等. 基于FY-4卫星资料分析暴雨云系特征. *高原山地气象研究*, 2020, 40(1): 36–40. [doi: 10.3969/j.issn.1674-2184.2020.01.006]
- 13 Zhang X, Yin Y, Kukulies J, *et al.* Revisiting lightning activity and parameterization using geostationary satellite observations. *Remote Sensing*, 2021, 13(19): 3866. [doi: 10.3390/rs13193866]
- 14 Kim M, Im J, Park H, *et al.* Detection of tropical overshooting cloud tops using Himawari-8 imagery. *Remote Sensing*, 2017, 9(7): 685. [doi: 10.3390/rs9070685]
- 15 Zhuge XY, Zou XL. Summertime convective initiation nowcasting over southeastern China based on Advanced Himawari Imager observations. *Journal of the Meteorological Society of Japan*. Ser. II, 2018, 96(4): 337–353. [doi: 10.2151/jmsj.2018-041]
- 16 Brodehl S, Müller R, Schömer E, *et al.* End-to-end prediction of lightning events from geostationary satellite images. *Remote Sensing*, 2022, 14(15): 3760. [doi: 10.3390/rs14153760]
- 17 Lee YJ, Suh MS, Eom HS, *et al.* Characteristics of brightness temperature of geostationary satellite on lightning events during summer over South Korea. *Journal of the Korean Earth Science Society*, 2009, 30(6): 744–758. [doi: 10.5467/JKES.2009.30.6.744]
- 18 Rafi MH, Holzworth RH, Mostafa MG. Evaluation of detection efficiency of world wide lightning location network in southeast Asian region. *Journal of Geophysical Research: Atmospheres*, 2024, 129(15): e2024JD041160. [doi: 10.1029/2024JD041160]
- 19 Li J, Dai BZ, Zhou JH, *et al.* Preliminary application of long-range lightning location network with equivalent propagation velocity in China. *Remote Sensing*, 2022, 14(3): 560. [doi: 10.3390/rs14030560]
- 20 Li J, Song L, Zhang QL, *et al.* Optimizing lightning location accuracy: A study of propagation velocity and time of arrival in long-range lightning location algorithms. *Measurement*, 2024, 234: 114754. [doi: 10.1016/j.measurement.2024.114754]
- 21 Li J, Zhang QL, Zhang MX, *et al.* Correction for remote estimation of return-stroke peak current using semi-supervised learning. *Atmospheric Research*, 2025, 317:

107968. [doi: [10.1016/j.atmosres.2025.107968](https://doi.org/10.1016/j.atmosres.2025.107968)]
- 22 Liu Y, Wang JL, Song Y, *et al.* Lightning nowcasting based on high-density area and extrapolation utilizing long-range lightning location data. *Atmospheric Research*, 2025, 321: 108070. [doi: [10.1016/j.atmosres.2025.108070](https://doi.org/10.1016/j.atmosres.2025.108070)]
- 23 张志孝, 郑栋, 张义军, 等. 闪电初始阶段和尺度判别方法及其特征. *应用气象学报*, 2017, 28(4): 414–426. [doi: [10.11898/1001-7313.20170403](https://doi.org/10.11898/1001-7313.20170403)]
- 24 Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. *Proceedings of the 18th International Conference on Medical Image Computing and Computer-assisted Intervention*. Munich: Springer, 2015. 234–241.
- 25 Woo S, Park J, Lee JY, *et al.* CBAM: Convolutional block attention module. *Proceedings of the 15th European Conference on Computer Vision*. Munich: Springer, 2018. 3–19.

(校对责编: 李慧鑫)