



梁振清, 林子杨, 莫祖斯, 等. 2026. 基于深度学习的毫米波云雷达晴空回波识别 [J]. 大气科学, 50(4): 1088–1102. LIANG Zhenqing, LIN Ziyang, MO Zusi, et al. 2026. Clear-Air Echo Recognition of Millimeter Wavelength Cloud Radar based on Deep Learning [J]. Chinese Journal of Atmospheric Sciences (in Chinese), 50(4): 1088–1102. doi:10.3878/j.issn.1006-9895.2601.24136

基于深度学习的毫米波云雷达晴空回波识别

梁振清^{1,2} 林子杨³ 莫祖斯² 黄颖^{1,4} 孙云⁵

1 广西壮族自治区来宾市气象局, 来宾 546100

2 广西壮族自治区气象技术装备中心, 南宁 530022

3 广西壮族自治区富川县气象局, 贺州 542700

4 广西壮族自治区气象信息中心, 南宁 530021

5 广西壮族自治区隆林县气象局, 百色 533000

摘要 毫米波云雷达是探测云微物理特征的重要设备, 但易受飞虫、飞鸟、气溶胶等非气象目标影响产生晴空回波, 导致反演偏差。为提升晴空回波识别精度与普适性, 本文提出并实现了一种通用的毫米波云雷达晴空回波识别的深度学习模型——ATNN (Multi-Head Attention Neural Networks), 仅利用反射率因子、径向速度、相对高度三种数据产品实现垂直结构特征的自适应学习。基于广西百色市毫米波云雷达观测资料的测试表明: ATNN 在汛期的评分较高, 晴空回波识别率平均值为 91.98%, 气象回波保留率平均值为 94.28%; 在非汛期过渡到汛期期间, ATNN 评分稍低, 晴空回波识别率平均值为 87.56%, 气象回波保留率平均值为 86.38%; 相比 ATNN, NN (Neural Networks) 对晴空回波的识别率稍高, 但会把低空强度较低的大量气象回波误判为晴空回波, 在非汛期期间气象回波保留率平均仅有 54.96%。进一步利用全国 15 部云雷达资料评估验证, ATNN 平均晴空回波剔除率为 81.17%, 气象回波保留率达 93.89%, 展现出良好的区域适应性。

关键词 毫米波云雷达 深度学习 晴空回波 质量控制 ATNN (Multi-Head Attention Neural Networks)

文章编号 1006-9895(2026)04-1088-15

中图分类号 TP391.4; P412.25

文献标识码 A

doi:10.3878/j.issn.1006-9895.2601.24136

Clear-Air Echo Recognition of Millimeter Wavelength Cloud Radar based on Deep Learning

LIANG Zhenqing^{1,2}, LIN Ziyang³, MO Zusi², HUANG Ying^{1,4}, and SUN Yun⁵

1 Laibin Meteorological Bureau of Guangxi Zhuang Autonomous Region, Laibin 546100

2 Meteorological Technology and Equipment Center of Guangxi Zhuang Autonomous Region, Nanning 530022

3 Fuchuan County Meteorological Bureau of Guangxi Zhuang Autonomous Region, Hezhou 542700

4 Meteorological Information Center of Guangxi Zhuang Autonomous Region, Nanning 530021

5 Longlin County Meteorological Bureau of Guangxi Zhuang Autonomous Region, Baise 533000

Abstract Millimeter-wavelength cloud radar serves as a pivotal instrument for cloud microphysical characterization but is susceptible to clear-air echoes induced by insects, birds, and aerosols, leading to considerable retrieval biases. To enhance detection accuracy and generalizability, this study presents ATNN (Multi-Head Attention Neural Networks), a

收稿日期 2024-12-09; 网络预出版日期 2026-03-10

作者简介 梁振清, 男, 硕士研究生, 工程师, 主要从事遥感卫星定量降水评估、深度学习的降水短临预报、水文模拟方面的研究。E-mail: liangzhenqing163@163.com

通讯作者 黄颖, 博士研究生, 工程师, 主要从事大气探测、云降水物理、人工影响天气方面的研究。E-mail: 505618722@qq.com

资助项目 来宾市气象局气象研究计划项目来气科 202404

Funded by Meteorological Research Project of Laibin Meteorological Bureau (Grant Laiqi-Ke 202404)

universal deep learning framework that exclusively employs the reflectivity factor, radial velocity, and relative height for adaptive learning of vertical structural features. Evaluated on observations from Baise, Guangxi, ATNN demonstrates robust performance during the rainy season, achieving a clear-air echo detection rate of 91.98% and a meteorological echo preservation rate of 94.28%; during the non-flood season transition, these metrics are 87.56% and 86.38%, respectively. In contrast, conventional neural networks (NN) achieve marginally higher detection rates but misclassify numerous low-altitude, weak meteorological echoes as clear-air signals, yielding a preservation rate of only 54.96% in non-flood periods. Nationwide validation across 15 operational radar sites further confirms that ATNN attains an average clear-air echo removal rate of 81.17% while preserving 93.89% of meteorological echoes, thereby demonstrating strong regional adaptability.

Keywords Millimeter wavelength cloud radar, Deep learning, Clear-air echo, Quality control, ATNN (Multi-Head Attention Neural Networks)

1 引言

大气中不同相态和形状的水凝物组成的云,是天气预报和气候变化研究中最重要对象之一,在水循环、气候变化、航空安全方面起重要作用(彭杰等, 2023; 谭杰等, 2025)。因此,云的观测对防灾减灾,守护人民安全至关重要。

毫米波云雷达(波长 3~8 mm)凭借其短波长、高灵敏度与精细化时空分辨率优势,能够同时探测云的宏观结构和微物理属性(王洪等, 2022; 张静怡, 2022; Xiao et al., 2023; 张晋茹, 2023; 谭杰等, 2025),已成为反演冰云粒子谱、冰水含量及云滴数浓度等参数的重要遥感工具(刘黎平等, 2021; Lin et al., 2024; Griesche et al., 2024; 陈文姝等, 2025)。然而由于该雷达易受大气湍流、人类活动、昆虫等影响,常在无云的晴天探测到雷达回波(陶法等, 2020),这种回波一般称为晴空回波。此类回波若未被有效识别,会造成云水含量、粒子浓度等反演结果的偏差,进而影响云雷达探测结果的准确性。因此,精准区分晴空回波与气象回波是保障云雷达数据质量的关键环节。

目前,常用的晴空回波识别剔除方法主要有三种,分别是阈值法、机器学习、深度学习方法。阈值法的实现需要统计毫米波云雷达的气象回波与晴空回波在雷达基本反射率因子(Radar Reflectivity Factor, 简称 Z)、退偏比(Linear depolarization ratio, 简称 LDR)、高度(Height, 简称 H)等探测要素上的特征,通过设定相应的多个阈值对观测结果进行滤除(肖佩等, 2018; Yang et al., 2019; 陶法等, 2020; 曾正茂等, 2021; Ohigashi et al., 2021)。但是利用阈值法剔除晴空回波仍然存在一定的局限性,一方面,不同地区的晴空回波特征有一定差异,

且每台云雷达提供的观测资料并不完全相同,部分雷达不能提供退偏比数据。另一方面,气象回波和晴空回波在反射率因子上的特征并不总是有明显不同(Yang et al., 2020)。因此,若采用固定阈值剔除不同站点的晴空回波,可能会导致较大的误差。

关于机器学习在晴空回波识别中的应用(Hu et al., 2021),主要采用了诸如贝叶斯分类器等方法来区分低云和杂波,其所采用的判别因子为反射率因子、退偏比、谱宽(Spectral Width, SW),但是贝叶斯分类器需要计算先验概率,然而云和杂波未必总是按照既定的概率出现,对于缺少退偏比数据的情况,还需要利用空间相关性差异等方法来处理未决定的分类。

在深度学习领域,已有研究提出运用反向传播神经网络识别晴空回波(Yang et al., 2020)。该神经网络模型基于反射率因子、高度及主谱平均值识别晴空回波,但未充分利用其垂直结构特征(陶法等, 2020),也未引入径向速度信息(Radial Velocity, 简称 V)。在其他同类研究中(Williams et al., 2021),径向速度对于晴空回波识别同样重要。在对气象回波分类和云粒子分类的研究中,同样运用包含了径向速度的多普勒谱图(Schimmel et al., 2022; Romatschke and Vivekanandan, 2022)。由此可见,晴空回波除了与反射率因子、退偏比、高度、谱宽有关,还与径向速度相关。因此,为提高晴空回波识别的准确性,应综合运用多种具有判别能力的特征参数。

随着人工智能的快速发展,多种用于处理图像信息的模型被提出。自从多头注意力机制被提出后(Vaswani et al., 2017),其成为了自然语言处理领域的关键技术之一,在计算机视觉领域,特别是目标检测和识别任务中,也展现出了复杂场景下多

目标追踪的潜力（苑玉彬和吴一全, 2024）。如 DETR（DEtection TRansformer）通过使用多头自注意力机制来捕捉图像中的长距离依赖关系，提高了检测精度（Carion et al., 2020）。ViT（Vision Transformer）通过多头自注意力机制来捕捉图像中的空间关系，在图像分类任务上取得了优异的性能（Dosovitskiy et al., 2021）。Swin Transformer 通过引入层次化的窗口划分和移位窗口机制，有效地捕捉了图像中的局部和全局信息，在多个视觉任务上，包括目标检测和语义分割，都取得了显著的性能提升（Liu et al., 2021）。

综上所述，现有方法在适用广度与识别精度上仍存在提升空间，且评估体系多侧重晴空回波剔除率，对气象回波保留率的关注不足。为此，本文将利用毫米波云雷达共有的数据产品，结合注意力机制构建一个能够捕捉毫米波云雷达回波垂直结构特征的神经网络。

2 数据

本论文所使用的训练数据为百色市的毫米波云雷达观测数据，该雷达位于百色市气象局观测场内，具体位置如图 1 所示。该雷达的最窄脉冲宽度为 $0.21\ \mu\text{s}$ ，发射峰值功率为 $21.10\ \text{W}$ ($40\ \mu\text{s}$)，发射功率稳定度为 $0.02\ \text{dB}$ ，频谱宽度小于 $20\ \text{MHz}$ ，极限改善因子为 $40.84\ \text{dB}$ ，接收机增益大于 $30\ \text{dB}$ ，接收机噪声系数小于 $6\ \text{dB}$ ，接收系统线性动态范围大于 $80\ \text{dB}$ ，系统最小可测信号功率为 $-126\ \text{dBm}$

和 $-35.94\ \text{dBZ}$ ，系统相干性小于 0.4° ，机内强度自定标精度为 $0.42\ \text{dBZ}$ 。

如表 1 所示，该雷达主要有三种工作模式，分别为边界层模式、中云模式、卷云模式。边界层模式与其他两个模式区别在于脉冲宽度、脉压比、脉冲重复周期、相干积累数、探测盲区、最大不模糊距离、最大不模糊速度。而中云模式与卷云模式有明显区别的是脉冲宽度、脉压比、探测盲区。边界层通过短脉冲提高近地分辨率；中云模式则兼顾信噪比与分辨率；卷云模式使用最长脉冲增强信噪比以探测弱冰晶。中云模式和卷云模式采用脉冲压缩技术，在保持 $30\ \text{m}$ 分辨率的同时提升探测距离。三种模式由于上述关键参数的差异，可以用于探测不同高度的云。边界层模式主要探测 $30\ \text{m}$ 至

表 1 百色毫米波云雷达工作模式

Table 1 Operating modes of the Baise millimeter wavelength cloud radar

项目	边界层模式	中云模式	卷云模式
脉冲宽度	$0.2\ \mu\text{s}$	$8\ \mu\text{s}$	$24\ \mu\text{s}$
脉压比	1	40	120
距离分辨力	$30\ \text{m}$	$30\ \text{m}$	$30\ \text{m}$
脉冲重复周期	$60\ \mu\text{s}$	$120\ \mu\text{s}$	$120\ \mu\text{s}$
相干积累数	4	1	1
FFT点数	256	256	256
探测盲区	$30\ \text{m}$	$1200\ \text{m}$	$3600\ \text{m}$
最大不模糊距离	$9000\ \text{m}$	$18000\ \text{m}$	$18000\ \text{m}$
最大不模糊速度	$8.927\ \text{m s}^{-1}$	$17.85\ \text{m s}^{-1}$	$17.85\ \text{m s}^{-1}$




图 1 毫米波云雷达分布图。
Fig. 1 Distribution map of millimeter wavelength cloud radar.

7.5 km 高度内的低云、雾、气溶胶。中云模式用于探测 2~7 km 高度的水云或混合相态云（如高层云、高积云）。卷云模式专注于探测 5~15 km 高度的冰云（如卷云、卷积云）。在实际观测时，毫米波云雷达通过灵活组合上述模式，可实现从薄云到降水的全要素探测。

数据质量控制主要分为功率谱数据质量控制和基数据质量控制。而功率谱数据质量控制包括噪声处理和速度模糊处理；基数据质量控制包含异常回波处理（同频干扰、径向干扰、时间不连续、空间不连续等）、孤立回波处理。

该毫米波云雷达每分钟采集 638 个高度层的数据，每个高度层间隔 30 m。将一天内每分钟的观测值按时间顺序排列并可视化，可得到如图 2a 所示的图像，其中横坐标为时间（分钟），纵坐标表示目标相对于雷达的高度，下文统一简称为相对高度。

为实现可靠的模型训练，本研究制定了多源数据协同的标注方案，通过与同站址的激光雷达、雨量站、湿度、能见度仪对比，判断相应时间段内的雷达回波是否为晴空回波，具体判别依据如表 2 所示。最终做出的标签值如图 2 所示，用 0 表示气象回波（图 2b，青蓝色），1 表示晴空回波（图 2b，紫色），2 表示背景值。

其次，将雷达资料和制作好的标注数据分为训练数据和评估数据，训练数据为 2024 年 4 月 14 日至 6 月 23 日的观测资料，除去缺测、误测的数据后，共有 54 天，其中晴空回波的个数为 1539313 个，气象回波个数 5460896。训练的晴空回波占比 22%，以确保模型能有效学习其特征，不会出现极端偏向多数类的现象（Buda et al., 2018）。另外，在 54 天内共有 77740 个分钟样本可用于训练，其数量与已有研究中的样本规模相当（Yang et al., 2020）。此外，训练数据覆盖了多种典型天气过程，从而确保训练样本在时间和气象条件上的代表性。为了评估模型性能，选取 2024 年 2 月 14 日至 4 月 13 日（非汛期）以及 2024 年 6 月 25 日至 8 月 20 日（汛期）期间的观测资料作为评估数据。

最后，为验证模型在不同站点的适用性，本实验还使用了其他地区的 15 部毫米波云雷达资料进行测试评估，这些雷达站点的地理位置如图 1 所示，参与训练与验证的站点均采用与百色站完全一致的标注标准，各站点均配备符合中国气象局标准的 Ka 波段云雷达及配套地面观测设备，且所有雷达采用中国气象局统一的技术性能指标要求进行验收。时间范围为 2024 年 1~6 月，在此期间根据数据质量进一步筛选，最终得到共 1573 天的有效数

表 2 晴空判别依据

Table 2 Clear-air echo identification criteria

回波类型	判别依据
无云晴空	激光雷达无后向散射信号；能见度大于 10 km；相对湿度小于 60%；雨量为 0
低云或层状云	激光雷达有连续弱回波（高度 < 3 km）且能见度下降但无降水
降水	雨量站记录大于 0.1 mm h^{-1} 或双偏振雷达识别出降水特征
昆虫或生物回波	出现在白天边界层内（< 3 km）、具有强垂直梯度、与温度或者风速日变化相关，且激光雷达无对应云信号
地物或固定杂波	时空位置固定、多普勒速度接近 0、出现在近地面




图 2 2024 年 4 月 13 日实况与标注示意图：(a) 实况观测回波强度；(b) 标注值分布。

Fig. 2 Observation and label sketch map on April 13, 2024: (a) Observation of echo intensity; (b) label value distribution.

据。这些站点的观测结果也将按照 0、1、2 的标签值制作成标注数据，用于模型评估。

3 方法

3.1 NN (Neural Networks) 模型

本文以神经网络 (Neural Networks, NN) 模型为基准 (Yang et al., 2020)，用于衡量本文所提出的模型的性能提升程度。该神经网络包括 1 个输入层、2 个隐藏层和 1 个输出层。第一个隐藏层包含 8 个神经元单元，第二个隐藏层包含 6 个神经元单元，而输出层则有 2 个神经元单元。为了确定最终分类，本文在输出层之后再加入一层网络用于判断最终的输出类别。最终输出的数值表示数据点为晴空回波的概率，取值范围从 0.0 到 1.0。数值越高，表明模型判断为晴空回波的概率越大。

在神经网络的设计中，输入层接收的雷达资料包括雷达回波强度、径向速度和相对高度。这些特征是识别晴空回波的关键参数。在最终输出层之前的每一层中，激活函数采用 GELU (Gaussian Error Linear Unit) (Hendrycks and Gimpel, 2016)，它通过结合输入值与标准正态分布的累积密度函数 CDF (Cumulative Distribution Function)，为神经网络引入了非线性特征。这种设计可以让模型捕捉到数据中的复杂模式，且 GELU 在整个输入范围内连续可导，这有助于优化过程中的稳定性。最后的输出层的激活函数为 Sigmoid，确保输出范围限制在 0 到 1。

3.2 ATNN (Multi-Attention Neural Networks) 模型

如图 3 所示，本文基于多头注意力 (Multi-Head Attention) 和神经网络 (NN)，设计 ATNN (Multi-Head Attention Neural Networks) 模型，该模型不但能够具备 NN 的优势，还能借助注意力机制学习到晴空回波的垂直结构特征。

为了将多头注意力有效的融合进 NN 中，本文借鉴了 Transformer (Vaswani et al., 2017) 网络中的 Token 和 ViT 模型中的 Class Token。Token 在 Transformer 中代表输入序列中的一个元素或单元，而在本文中 (Z、V、H) 被视为一个 Token。Class Token 是一种特殊的 Token，通常被添加到序列的开始处，之后在整个网络的处理过程中与 Tokens 一起经历相同的变换。在 ATNN 中，Class Token 作为一个额外的学习参数加入到 Tokens 中，之后 Class Token 将与 Token (Z、V、H) 一起经历自注意力机制等操作。最终，经过多层 ATNN 之后，用 Class Token 的状态用来代表整个输入 (Z、V、H) 的信息，它将用于分类任务中的决策依据。

ATNN 中还加入了可学习的位置编码 (Position Embedding)，将位置编码作为模型的一部分，使其能够随着训练过程调整，从而使得模型得以理解输入元素之间的相对位置关系。位置编码会与输入嵌入相加，形成最终的输入向量，然后送入 ATNN 中。这种方法确保了模型不仅能够利用输入的内容信息，还能利用其结构信息，这对于处理高度这种




图 3 ATNN (Multi-Attention Neural Networks) 框架示意图。

Fig. 3 Multi-Attention Neural Networks (ATNN) framework.

有序数据至关重要。

在多头注意力模块中, 输入数据首先被线性变换多次, 然后被并行地输入到多个独立的注意力头 (Attention Heads) 中进行计算。每个注意力头关注输入的不同方面。之后, 这些头的结果会被拼接起来, 并再次经过一次线性变换以生成最终输出。这种设计可以让模型能够同时考虑来自同一序列内部不同位置的信息, 增强了模型对复杂模式的学习能力。

在每个 ATNN 块内运用了两次残差连接 (Residual Connections), 分别位于多头注意力机制之后和神经网络 NN 之后。残差连接可以帮助信息更好地流动, 保持较早层的信息不会因为深层网络而丢失, 并允许模型学习到更深层次的信息, 同时缓解了梯度消失问题, 更容易优化, 提高模型性能和稳定性。

3.3 训练方法

为了优化模型训练过程, 本文设定的初始学习率为 0.008, 并将最大训练周期数定为 300。每批次处理的数据量设定为 60。在损失函数的选择上, 采用了二元交叉熵 (Binary Cross-Entropy) 损失函数。整个优化过程基于随机梯度下降 (Stochastic Gradient Descent) 方法进行。此外, 本文采取余弦退火 (Cosine Annealing) 策略来动态调整学习率, 此策略允许学习率从起始值平滑下降至一个较低水平后迅速回升, 在学习周期内形成循环。通过这种方式, 不仅有助于模型跳出局部最小值点, 还能通过周期性地重置学习率加速训练的收敛进程, 促进模型更快地达到更优解, 并避免陷入局部最优。过拟合通常表现为训练损失持续下降, 而模型在验证集上的性能在训练后期开始恶化。为验证模型是否存在过拟合现象, 选取一个包含 22529 个晴空回波和 102665 个气象回波的典型个例进行实验。结合图 4、图 5、图 6 中可以看出, 损失持续下降, 虽然下降减缓, 但 2 个模型在训练后期 (如 epoch=300) 没有比早期 (epoch=100) 表现更差, 甚至持平或略优, 未观察到明显的过拟合迹象。这表明在 300 个训练周期内, 模型未出现明显的过拟合现象, 而是持续学习数据中的通用规律。

3.4 评估方法

本次论文的评估指标主要有晴空回波剔除率 (Clear-Air Echoes Recognition Rate, R_c) 和气象回波保留率 (Meteorology Echoes Retained Rate, R_m)。晴空回波剔除率, 表示模型将雷达回波中的

晴空回波识别成晴空回波的比值, 以定量的方式, 衡量模型对于晴空回波识别准确程度, 100% 为最高的识别率。气象回波保留率, 指的是模型成功将实际为云回波的数据点识别为云回波的比例, 作用在于评估和量化在识别晴空回波的同时, 模型能够正确地保留云回波的能力, 最高保留率为 100%, 保留率越高, 说明气象回波被错误识别为晴空回波的比例越少。它们的表达式如表 3 所示:

N_1 表示模型在一天内将雷达回波识别为晴空回波 (输出为 1), 并且与相应位置的标签值 (也为 1) 匹配的情况个数; N_{R1} 表示标签中一天内的晴空回波个数; N_0 表示模型在一天内将雷达回波识别为非晴空回波 (输出为 0), 并且与相应位置的标签值 (也为 0) 匹配的情况个数; N_{R0} 表示标签中气象回波的总量。

3.5 晴空回波特征参数选择

部分云雷达站点的观测资料没有提供 LDR 产品, 因此选择 Z、V、H、SW 作为模型判别晴空回

表 3 模型评估指标

评估指标	表达式	范围	最优值
晴空回波剔除率(R_c)	$\frac{N_1}{N_{R1}}$	0%~100%	100%
气象回波保留率(R_m)	$\frac{N_0}{N_{R0}}$	0%~100%	100%




图 4 ATNN 和神经网络 (NN) 训练损失。

Fig. 4 Training loss of ATNN and NN (Neural Networks).




图5 NN第100次、第200次、第300次训练周期效果。

Fig. 5 Performance of NN at the 100th, 200th, and 300th epochs.




图6 ATNN第100次、第200次、第300次训练周期效果。

Fig. 6 Performance of ATNN at the 100th, 200th, and 300th epochs.

波的特征输入。云雷达属于垂直探测，飞鸟、昆虫等生物目标的运动以水平分量为主，径向速度贡献极小，因此其对SW的影响可忽略不计。层云属于稳定云系，内部湍流弱，而弱湍流既可以是晴空特征，也可以是弱云的特征；对流云内部湍流强，

SW偏大，但是其回波强度通常也较大。因此，在大多数情况下，仅依据回波强度可有效与晴空回波区分。另外，通过观察数据发现，SW在反映晴空回波特征方面并不明显，为验证该推测，本文将包含SW特征的模型命名为NN4C，将不含SW特征

的模型命名为 NN3C, 并通过两者的对比实验分析其差异性影响。由于汛期和非汛期的云雷达回波特征有较大差别, 为验证模型在汛期和非汛期的适用性, 将该两个时期的结果进行对比。图 7 展示了使用了 SW 的 NN4C 与无 SW 特征输入的 NN3C 之间的区别, 两个模型的评分曲线(非汛期和汛期期间)基本重合, NN3C 和 NN4C 在整个汛期和非汛期的性能基本相同。NN3C 在非汛期的气象回波保留率的平均值为 54.19%, 平均晴空回波剔除率为 97.51%。NN4C 的气象回波保留率为 54.96%, 平均晴空回波剔除率为 97.4 9%。在汛期期间, NN3C 的气象回波保留率和晴空回波剔除率分别为 79.80% 和 98.21%。NN4C 的气象回波保留率为 79.43%, 晴空回波剔除率为 98.32%。在汛期期间和非汛期期间, NN3C 的剔除率和保留率基本都与 NN4C 持平。由此可见, SW 带来的提升不显著, 在以下结果中仅使用 Z, V, H 资料进行训练。

4 结果分析

4.1 ATNN 的识别效果

如表 4 所示, 注意力头数的增多, 有助于模型

性能的提升, 但是提升并不大, 过多的注意力头在网络加深的时候还会带来负面影响。随着网络加深, 与 1 个注意力头相比, 使用 2 个注意力头会导致气象回波保留率下降, 但晴空回波剔除率会升高, 且升幅大于降幅。于是, 将注意力头数设置为 2, 逐渐加深网络。当网络加深到 4 层后, 随着网络加深, 气象回波保留率开始不断升高, 晴空回波剔除率开始逐渐降低。由此可见, 模型注意力头为 2, 深度为 4 时的, 气象回波保留率和晴空回波剔除率在汛期和非汛期期间最高。

4.2 模型对百色毫米波云雷的适用性

如图 8 所示, 在汛期和非汛期期间, NN3C 晴空回波剔除率比较高, 基本维持在 95% 以上, 但是气象回波保留率远远低于 ATNN。ATNN 气象回波保留率曲线变化与 NN3C 大多情况下一致, 这说明 ATNN 面对同样的天气情况的保留率依然会下降, 但是错误识别的情况明显减少。ATNN 在汛期时的气象回波保留率和晴空回波剔除率大部分情况基本维持在 90% 以上。与 NN3C 相比, ATNN 在汛期的晴空回波剔除率有所下降, 但这一降幅远小于 NN3C 的气象回波保留率的降幅。从图 8a 能




图 7 NN3C 与 NN4C 在 (a) 非汛期和 (b) 汛期的气象回波保留率和晴空剔除率曲线变化。

Fig. 7 Meteorological echo retention rate and clear-air echo recognition rate curves of NN3C and NN4C during the (a) non-flood and (b) flood seasons.

表 4 注意力头数量 (Head) 与模型深度 (Depth) 的气象回波保留率和晴空回波剔除率对照表

Table 4 Comparison table of meteorological echo retention rate and clear-air echo recognition rate based on the number of attention heads and model depth

	2024年2月14日至2024年4月13日(非汛期)		2024年6月25日至8月20日(汛期)	
	气象回波保留率	晴空回波剔除率	气象回波保留率	晴空回波剔除率
Depth=1 Head=1	73.78%	76.98%	94.21%	85.83%
Depth=1 Head=2	74.04%	74.66%	94.19%	86.32%
Depth=1 Head=11	74.80	75.84	94.29%	86.47%
Depth=2 Head=1	86.71%	85.88%	94.51%	91.55%
Depth=2 Head=2	86.40%	86.58%	94.34%	91.85%
Depth=2 Head=11	86.50	86.06%	94.33%	91.53%
Depth=3 Head=1	86.82%	86.40%	94.52%	91.70%
Depth=3 Head=2	86.37%	87.14%	94.29%	91.95%
Depth=4 Head=2	86.38%	87.56%	94.28%	91.98%
Depth=5 Head=2	86.45%	87.54%	94.36%	91.83%
Depth=6 Head=2	86.91%	86.38%	94.39%	91.60%

注: 加粗显示所对应的参数配置, 即为本次验证评估环节所采用的模型参数。




图 8 ATNN 与 NN3C 在 (a) 非汛期和 (b) 汛期的气象回波保留率和晴空剔除率曲线变化。
Fig. 8 Meteorological echo retention rate and clear-air echo recognition rate curves of ATNN and NN3C during (a) non-flood and (b) flood seasons.

明显看到, 两种方法的气象回波保留率都有明显的下降, 甚至有些时段接近 0%。这是因为大部分晴朗天气出现在非汛期, 而在晴朗天气条件下, 气象回波保留率通常接近 0%。由于晴朗天气条件下的气象回波数量稀少, 而晴空回波相对较多, 且晴天的气象回波分布较为零散、强度较弱, 与晴空回波的特征相似度较高。

综上所述, 在晴空背景下, 即便是少量气象回波的错误识别也足以引起气象回波保留率的显著下降。因此, 在实际应用过程中, 应充分认识到模型的不完善之处, 并评估由此引发的系统性误差, 以确保模型输出的可靠性和准确性。

4.2.1 非汛期个例分析

为了对比 ATNN 和 NN (NN3C) 在非汛期期间的效果, 选择非汛期常见的天气情况进行分析, 图 9 给出了 2024 年 3 月 2 日的云雷达反射率因子及两种模型的识别结果。如图 9 所示, 晴空回波与气象回波之间的差异比较明显。在该天气情况下, ATNN 能有效的识别接地的晴空回波, 且对云回波有较好的保留。而 NN 虽然也能有效识别晴空回波, 但是除了滤除接地的晴空回波, 还会将大量强度较低的云回波的判定为晴空回波。这说明 ATNN 的注意力模块在非汛期期间对气象回波的保

留是有效的。

4.2.2 汛期个例分析

图 10 为 2024 年 7 月 2 日的汛期个例。由图 10 可看出, NN 和 ATNN 都能有效识别出晴空回波, 且对气象回波保留较好。与 ATNN 相比, NN 对强度较低的气象回波滤除比较多, 这说明高度较低时, 低空低强度的回波通常为晴空回波。因此回波在低空时, 强度特征对模型判别结果的影响较大, 这与前人关于晴空回波的强度和高度特征较为明显结论相符 (Yang et al., 2019, 2020), 而 ATNN 能保留 NN 消除的气象回波, 对晴空回波的识别效果相对 NN 有所降低, 但仍然能识别大部分的晴空回波。这说明 ATNN 通过注意力机制和加深的网络能分辨出气象回波与晴空回波的垂直结构特征, 对低强度的气象回波有所保留。这也是整个汛期期间, ATNN 气象回波保留率比 NN 相比较高的原因之一。

图 11 为 2024 年 7 月 30 日的汛期个例。如图 11 所示, ATNN 和 NN 都能识别大部分的晴空回波。但是, 从图 8 可以看出, 这个时间段内的 ATNN 在整个汛期表现最差, 晴空回波识别率为 60.08%, 这是因为在第 200~400 分钟处, 有大量接地的晴空回波没有滤除干净。结合图 10 的分析,




图 9 2024 年 3 月 2 日 (a) 反射率因子、(b) NN 的识别结果和 (c) ATNN 的识别结果。

Fig. 9 (a) Reflectivity factor of observation, (b) result of the reflectivity factor after filtering clear-air echoes by NN, and (c) result of the reflectivity factor after filtering clear-air echoes by ATNN on March 2, 2024.




图 10 2024 年 7 月 2 日 (a) 反射率因子、(b) NN 的识别结果和 (c) ATNN 的识别结果。

Fig. 10 (a) Reflectivity factor of observation, (b) result of the reflectivity factor after filtering clear-air echoes by NN, and (c) result of the reflectivity factor after filtering clear-air echoes by ATNN on July 2, 2024.

ATNN 依然不能有效识别出晴空回波与气象回波比较接近的情况, NN 则没有这种情况。这可能是由于训练数据中该种垂直结构的晴空回波样本较少。与之相对, ATNN 能保留第 100 分钟处的低空低强度气象回波, 而 NN 则没有把这部分的气象回波保留下来。

综上所述, ATNN 和 NN 在汛期期间, 对大部分晴空回波都能有效滤除, NN 由于没有学习晴空回波垂直结构特征, 会把大部分强度较低的云回波识别为晴空回波, 而 ATNN 不能有效识别云回波下, 且贴近云回波的晴空回波。因此, 还需要加入额外数据量学习该种情况的垂直结构特征。ATNN 虽然晴空剔除率相对 NN 较低, 但差距不大, 而 NN 存在汛期和非汛期都存在大量误判的情况。与之相比, ATNN 在整体上表现稳定, 适用于百色大

部分天气情况, 之后将分析 ATNN 在全国 15 个站点的泛用性。

4.3 模型对全国站点适用性

使用全国 15 个站点对 ATNN 进行分析, 各站点资料的时长都为 2024 年 1~6 月。经过筛选, 15 个站点一共获得 1573 天的样本。ATNN 在整个时间段内的气象回波保留率平均值为 93.89%。晴空回波剔除率为 81.17%。如表 5 所示, 大部分站点的气象回波保留率都比较好, 维持在 90% 左右, 表现最差的站点为汕头站, 仅 73.68%。说明该模型对东南沿海地区的气象回波误判情况比较高, 其次为在西藏自治区的定日和在黑龙江省的哈尔滨。晴空回波剔除率基本维持在 80% 左右, 最低的地方为衢州, 其次是巴塘和茫崖, 基本都只能识别 70% 左右的晴空回波。这可能是因为这些站点有

表 5 ATNN 和额外训练 ATNN_Extra 在全国 15 个毫米波云雷达站的气象回波保留率和晴空回波识别率表
Table 5 Meteorological echo retention rate and clear-air echo recognition rate of ATNN and Extra Trained ATNN at 15 millimeter wavelength cloud radar stations in China

站点名称(天数)	气象回波保留率	晴空回波剔除率	Extra Trained气象回波保留率	Extra Trained晴空回波剔除率
天津(54天)	99.67%	78.81%	99.46%	94.35%
射阳(55天)	98.15%	85.92%	98.21%	90.92%
汕头(142天)	73.68%	87.91%	71.29%	93.37%
衢州(122天)	94.22%	69.10%	93.18%	86.44%
郑州(150天)	95.78%	86.80%	95.46%	93.53%
哈尔滨(109天)	88.73%	89.90%	87.24%	96.75%
克拉玛依(163天)	94.12%	79.60%	93.71%	92.69%
温江(162天)	95.96%	82.17%	95.21%	87.62%
呼和浩特(120天)	98.46%	76.98%	98.12%	89.77%
贵阳(37天)	89.03%	87.51%	87.76%	91.92%
民丰(165天)	98.89%	81.83%	98.62%	94.05%
思茅(45天)	94.51%	88.87%	93.40%	94.31%
巴塘(98天)	99.30%	71.94%	98.83%	92.26%
茫崖(108天)	99.40%	72.86%	99.10%	94.81%
定日(43天)	88.50%	85.77%	87.51%	94.32%




图 11 2024 年 7 月 30 日 (a) 反射率因子、(b) NN 的识别结果和 (c) ATNN 的识别结果。
Fig. 11 (a) Reflectivity factor of observation, (b) result of the reflectivity factor after filtering clear-air echoes by NN, and (c) result of the reflectivity factor after filtering clear-air echoes by ATNN on July 30, 2024.

大量模型没有学习到的晴空回波垂直特征, 且部分晴空回波的分布情况与图 11 的比较相似, 都在近地面的云回波下, 且离云回波比较近的地方。因此, 为了提升模型的晴空回波识别率, 根据未能识别的情况, 选择衢州 10 天和巴塘的 25 天和百色原有的 54 天数据, 总共 89 天的数据, 进行额外训练。

额外训练后的模型性能表现如表 5 的第 4 和第 5 列所示, 以微小的气象回波损失, 换来显著的晴空回波剔除率提升。所有站点的晴空剔除率都有所下降, 大部分的站点的晴空回波剔除率都达到 90% 以上, 且射阳站气象回波保留率有所上升。这表明额外训练的数据中具有原训练集里没有的新特征, 且 ATNN 能通过学习这些额外数据的新特征, 提高在全国 15 个站的晴空回波识别率。

图 12 为额外训练后的 ATNN_Extra 和 ATNN 在百色毫米波云雷达站汛期和非汛期的气象回波保留率与晴空回波剔除率变化曲线图, 主要用于评估 ATNN_Extra 在经过额外训练后是否仍能在百色保持原有的性能。从整个曲线可以看出, 经过额外训练后的 ATNN 在百色, 尽管在部分时间段内气象回波保留率有轻微下降, 但该方法能够识别出之前无法识别的晴空回波。在非汛期的气象回波保留率由 86.38% 提升至 86.98%, 晴空回波剔除率从

87.56% 提升为 93.62%。汛期的气象回波保留率从 94.28% 降低为 92.82%, 晴空回波剔除率由 91.98% 提升为 96.65%。

图 13、图 14、图 15 中对应的是 4.2 节中的三个个例天气情况下的 ATNN 和经过额外训练的 ATNN (ATNN_Extra) 的反射率因子分布图。从图中可以看出, ATNN_Extra 能够有效消除 ATNN 所保留的晴空回波, 同时避免将空中低强度的气象回波误判为晴空回波, 并在非汛期更好地保留气象回波。从图 13 可以看出, ATNN_Extra 在非汛期依然保持了对晴空回波的有效识别能力, 能够去除大部分非气象回波, 同时保留更多的真实气象回波。在图 14b 中, 2024 年 7 月 2 日第 700 分钟时, ATNN 未能识别上方区域的晴空回波; 而图 14c 显示, ATNN_Extra 在该时刻成功识别出该区域的大部分晴空回波。这一改进也在图 15b 中得到印证, 在对应时间点, ATNN_Extra 的晴空回波剔除率明显提升。图 15b 展示了汛期个例 (2024 年 7 月 30 日)。在此期间, ATNN 在第 240 至第 400 分钟之间未能有效识别晴空回波; 相比之下, 图 15c 表明, ATNN_Extra 在相同时间段内成功识别出大部分晴空回波, 展现出更强的适应性和鲁棒性。综合分析表明, ATNN_Extra 相较于 ATNN 在晴空回波识别




图 12 ATNN 与 ATNN_Extra 在 (a) 非汛期和 (b) 汛期期间的气象回波保留率和晴空剔除率曲线变化。

Fig. 12 Meteorological echo retention rate and clear-air echo recognition rate curves of ATNN and ATNN_Extra during (a) non-flood and (b) flood seasons.




图 13 2024 年 3 月 2 日 (a) 反射率因子、(b) ATNN 的识别结果和 (c) ATNN_Extra 的识别结果。

Fig. 13 (a) Reflectivity factor of observation, (b) result of the reflectivity factor after filtering clear-air echoes by ATNN, and (c) result of the reflectivity factor after filtering clear-air echoes by ATNN_Extra on March 2, 2024.




图 14 2024 年 7 月 2 日 (a) 反射率因子、(b) ATNN 的识别结果和 (c) ATNN_Extra 的识别结果。

Fig. 14 (a) Reflectivity factor of observation, (b) result of the reflectivity factor after filtering clear-air echoes by ATNN, and (c) result of the reflectivity factor after filtering clear-air echoes by ATNN_Extra on July 2, 2024.




图 15 2024 年 7 月 30 日 (a) 反射率因子、(b) ATNN 的识别结果和 (c) ATNN_Extra 的识别结果。

Fig. 15 (a) Reflectivity factor of observations, (b) result of the reflectivity factor after filtering clear-air echoes by ATNN, and (c) result of the reflectivity factor after filtering clear-air echoes by ATNN_Extra on July 30, 2024.

方面具有明显改进, 不仅能有效去除 ATNN 遗漏的晴空回波, 还可准确区分低强度气象回波, 避免其被误判为晴空回波; 同时, 在非汛期时段, 该 ATNN_Extra 对云回波的保留能力也有所增强。

5 结论与讨论

云在气象研究中非常重要, 而毫米波云雷达是重要的云探测设备, 由于容易受到大气湍流、空气中的尘埃、飞虫等干扰, 从而产生非气象回波, 即晴空回波。本文根据前人的研究统计经验及所用方法, 采用雷达反射率强度, 径向速度, 高度等能用于区分晴空回波与气象回波的观测资料, 训练神经网络以识别晴空回波。为了能让神经网络学习到晴

空回波的垂直结构特征, 本文参考 Transformer 的 Token 和 Vision Transformer 的 Class Token, 将多头注意力机制与神经网络进行有效融合, 形成 ATNN 网络。通过本文的实验, 得出以下结论:

(1) ATNN 在整个百色站点的气象回波保留率和晴空回波保留率在汛期期间基本保持在 90% 以上, 说明 ATNN 在汛期期间的大多数情况下, 在保持气象回波的同时, 也能有效的识别大量晴空回波, 满足实际的数据质控业务需要。

(2) 用全国的 15 个站点对仅用百色数据训练的 ATNN 进行评估, 晴空回波识别率平均为 81.17%, 气象回波保留率平均为 93.89%, 在大部分站点取得较好识别效果, 具备推广应用潜力, 但

仍需结合各地特征进一步针对性优化。

(3) NN 会把低空强度较低的气象回波误判为晴空回波, 导致晴空回波被消除的同时损失气象回波, 在非汛期期间特别明显。

本文缺乏冬季及全年覆盖的训练数据, 模型仅能依赖冬末至夏末期间学习到的晴空回波特征进行识别任务, 而深度学习模型无法凭空推断未见过的冬季特有物理模式。因此, 相关系统性偏差主要源于冬季回波的强度及垂直高度维度上的分布形态、连续性与分层特征与暖季的显著差异。冬季的回波通常较弱, 且弱云、雾回波的强度与晴空湍流回波高度重叠, 从而易被模型误判为晴空回波。

致谢 感谢南京信息工程大学大气物理学院黄兴友教授和成都信息工程大学电子工程学院苏德斌教授在毫米波云雷达晴空回波识别方面的指导。

参考文献 (References)

- Buda M, Maki A, Mazurowski M A. 2018. A systematic study of the class imbalance problem in convolutional neural networks [J]. *Neural Networks*, 106: 249–259. doi:10.1016/j.neunet.2018.07.011
- Carion N, Massa F, Synnaeve G, et al. 2020. End-to-end object detection with transformers [C]//16th European Conference on Computer Vision. Glasgow: Springer, 213–229. doi:10.1007/978-3-030-58452-8_13
- 陈文姝, 黄兴友, 卜令兵, 等. 2025. 南京地区冰云个例微物理参数的地基毫米波云雷达观测反演分析 [J]. *气象学报*, 83(1): 115–128.
- Chen Wenshu, Huang Xingyou, Bu Lingbing, et al. 2025. Retrieval and analysis of ice-cloud microphysical parameters over Nanjing based on ground-based millimeter-wavelength cloud radar observations [J]. *Acta Meteorologica Sinica* (in Chinese), 83(1): 115–128. doi:10.11676/qxb.2025.20240054
- Dosovitskiy A, Beyer L, Kolesnikov A, et al. 2021. An image is worth 16×16 words: Transformers for image recognition at scale [C]//9th International Conference on Learning Representations. OpenReview. net, 1–21.
- Griesche H J, Seifert P, Engelmann R, et al. 2024. Cloud micro- and macrophysical properties from ground-based remote sensing during the MOSAiC drift experiment [J]. *Scientific Data*, 11(1): 505. doi:10.1038/s41597-024-03325-w
- Hendrycks D, Gimpel K. 2016. Gaussian error linear units (GELUs) [J]. *arXiv preprint arXiv: 1606.08415*. doi:10.48550/arXiv.1606.08415
- Hu X Y, Ge J M, Du J J, et al. 2021. A robust low-level cloud and clutter discrimination method for ground-based millimeter-wavelength cloud radar [J]. *Atmospheric Measurement Techniques*, 14(2): 1743–1759. doi:10.5194/amt-14-1743-2021
- Lin W Q, He Q S, Cheng T T, et al. 2024. A method for retrieving cloud microphysical properties using combined measurement of millimeter-wave radar and lidar [J]. *Remote Sensing*, 16(3): 586. doi:10.3390/rs16030586
- 刘黎平, 张杨, 丁晗. 2021. Ka/Ku 双波段云雷达反演空气垂直运动速度和雨滴谱方法研究及初步应用 [J]. *大气科学*, 45(5): 1099–1113.
- Liu Liping, Zhang Yang, Ding Han. 2021. Vertical air motion and raindrop size distribution retrieval using a Ka/Ku dual-wavelength cloud radar and its preliminary application [J]. *Chinese Journal of Atmospheric Sciences* (in Chinese), 45(5): 1099–1113. doi:10.3878/j.issn.1006-9895.2104.20200
- Liu Z, Lin Y T, Cao Y, et al. 2021. Swin transformer: Hierarchical vision transformer using shifted windows [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 9992–10002. doi:10.1109/ICCV48922.2021.00986
- Ohigashi T, Maesaka T, Suzuki S I, et al. 2021. Clear-air echoes observed by Ka-band polarimetric cloud radar: A case study on insect echoes in the Tokyo metropolitan area, Japan [J]. *J. Meteor. Soc. Japan*, 99(1): 101–112. doi:10.2151/jmsj.2021-006
- 彭杰, 王晓峰, 傅新姝, 等. 2023. 面向业务应用的上海地区毫米波云雷达观测质量评估 [J]. *大气科学学报*, 46(3): 466–480.
- Peng Jie, Wang Xiaofeng, Fu Xinshu, et al. 2023. Operational usage-oriented evaluation of millimeter radar observations in Shanghai [J]. *Transactions of Atmospheric Sciences* (in Chinese), 46(3): 466–480. doi:10.13878/j.cnki.dqkxb.20220623001
- Romatschke U, Vivekanandan J. 2022. Cloud and precipitation particle identification using cloud radar and lidar measurements: Retrieval technique and validation [J]. *Earth and Space Science*, 9(5): e2022EA002299. doi:10.1029/2022EA002299
- Schimmel W, Kalesse-Los H, Maahn M, et al. 2022. Identifying cloud droplets beyond lidar attenuation from vertically pointing cloud radar observations using artificial neural networks [J]. *Atmospheric Measurement Techniques*, 15(18): 5343–5366. doi:10.5194/amt-15-5343-2022
- 谭杰, 付丹红, 郭学良, 等. 2025. 青藏高原东南部一次典型降水性层状云的水凝物分类和过冷液态水含量分布特征 [J]. *大气科学*, 49(4): 1080–1097.
- Tan Jie, Fu Danhong, Guo Xuiliang, et al. 2025. Distribution characteristics of hydrometeor classification and supercooled liquid water content for a typical precipitating stratiform cloud on the southeastern Qinghai-Xizang Plateau [J]. *Chinese Journal of Atmospheric Sciences* (in Chinese), 49(4): 1080–1097. doi:10.3878/j.issn.1006-9895.2403.23134
- 陶法, 官莉, 张雪芬, 等. 2020. Ka 波段云雷达晴空回波垂直结构及变化特征 [J]. *应用气象学报*, 31(6): 719–728.
- Tao Fa, Guan Li, Zhang Xuefen, et al. 2020. Variation and vertical structure of clear-air echo by Ka-band cloud radar [J]. *Journal of Applied Meteorological Science* (in Chinese), 31(6): 719–728. doi:10.11898/1001-7313.20200607
- Vaswani A, Shazeer N, Parmar N, et al. 2017. Attention is all you need [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 6000–6010.
- 王洪, 张佃国, 王文青, 等. 2022. 基于多源资料的积层混合云降水微物理特征 [J]. *大气科学*, 46(4): 886–902.
- Wang Hong, Zhang

- Dianguo, Wang Wenqing, et al. 2022. Microphysical characteristics of stratiform precipitation with embedded convection based on multisource data [J]. Chinese Journal of Atmospheric Sciences (in Chinese), 46(4): 886–902. doi:10.3878/j.issn.1006-9895.2107.21043
- Williams C R, Johnson K L, Giangrande S E, et al. 2021. Identifying insects, clouds, and precipitation using vertically pointing polarimetric radar Doppler velocity spectra [J]. Atmospheric Measurement Techniques, 14(6): 4425–4444. doi:10.5194/amt-14-4425-2021
- Xiao M X, Wang H, Chen Z H, et al. 2023. Overview of the development of millimeter wave cloud radar technology [C]//2023 4th China International SAR Symposium (CISS). Xi'an: IEEE, 1–6. doi:10.1109/CISS60136.2023.10379900
- 肖佩, 霍娟, 毕永恒. 2018. 地基 Ka 波段云雷达数据质量控制方法研究分析 [J]. 成都信息工程大学学报, 33(2): 129–136. Xiao Pei, Huo Juan, Bi Yongheng. 2018. Ground-based Ka band cloud radar data quality control [J]. Journal of Chengdu University of Information Technology (in Chinese), 33(2): 129–136. doi:10.16836/j.cnki.jcuit.2018.02.005
- Yang L, Wang Y, Wang Z K, et al. 2020. Automatic identification of clear-air echoes based on millimeter-wave cloud radar measurements [J]. Advances in Atmospheric Sciences, 37(8): 912–924. doi:10.1007/s00376-020-9270-z
- Yang Q, Yang L, Xu Z X, et al. 2019. Analysis of clean-air echoes based on millimeter wave cloud radar measurements [C]//2019 International Conference on Meteorology Observations (ICMO). Chengdu: IEEE, 1–4. doi:10.1109/ICMO49322.2019.9026074
- 苑玉彬, 吴一全. 2024. 基于 Transformer 的无人机多目标跟踪算法研究 [J]. 兵器装备工程学报, 45(7): 11–18. Yuan Yubin, Wu Yiquan. 2024. Transformer-based multi-object tracking algorithm for UAV [J]. Journal of Ordnance Equipment Engineering (in Chinese), 45(7): 11–18. doi:10.11809/bqzbgcxb2024.07.002
- 曾正茂, 郑佳锋, 杨晖, 等. 2021. Ka 波段云雷达非云回波质量控制及效果评估 [J]. 应用气象学报, 32(3): 347–357. Zeng Zhengmao, Zheng Jiafeng, Yang Hui, et al. 2021. Quality control and evaluation on non-cloud echo of Ka-band cloud radar [J]. Journal of Applied Meteorological Science (in Chinese), 32(3): 347–357. doi:10.11898/1001-7313.20210307
- 张晋茹, 杨莲梅, 刘凡, 等. 2023. 基于 Ka 波段云雷达观测的中国西天山降雨云宏微观物理特征研究 [J]. 大气科学, 47(3): 756–768. Zhang Jinru, Yang Lianmei, Liu Fan, et al. 2023. Macro-micro physical characteristics of rainfall clouds in the West Tianshan Mountains based on Ka-Band cloud radar [J]. Chinese Journal of Atmospheric Sciences (in Chinese), 47(3): 756–768. doi:10.3878/j.issn.1006-9895.2112.21112
- 张静怡, 王改利, 郑佳锋, 等. 2022. 青藏高原东南部墨脱地区弱降水微物理特征的 Ka 波段云雷达观测研究 [J]. 大气科学, 46(5): 1239–1252. Zhang Jingyi, Wang Gaili, Zheng Jiafeng, et al. 2022. Study of the microphysical characteristics of weak precipitation in Mêdog, southeastern Tibetan Plateau using Ka-Band cloud radar [J]. Chinese Journal of Atmospheric Sciences (in Chinese), 46(5): 1239–1252. doi:10.3878/j.issn.1006-9895.2205.21185