

面向气象观测的全天空云状智能检测技术研究

赵尚卓^{1,2}, 张子怡^{1,3}, 崔娟^{1,4}

(1. 长治市气象局, 山西 长治 046000;

2. 南京信息工程大学 海洋科学学院, 南京 210044;

3. 南京信息工程大学 大气科学学院, 南京 210044;

4. 南京信息工程大学 应用气象学院, 南京 210044)

摘要: 为提升气象观测中云状检测的准确性, 提出一种基于改进深度学习的全天空云状智能检测技术; 在传统深度学习中引入多尺度特征金字塔融合模块, 自适应捕捉云层从细微纹理到宏观结构的多尺度特征; 同时添加注意力模块, 动态加权关键特征区域, 有效抑制不重要特征的干扰; 输入全天空云状图像到基于改进深度学习的智能检测模型当中, 计算每种云状类别的分布概率, 取最大值对应的结果作为检测结果; 基于华北地区的全天空观测数据, 构建了包含 10 类典型云状的数据集, 进行实验测试; 实验结果表明: 所提出的检测技术在消融实验中的交叉熵损失从 0.008 8 逐渐下降到 0.000 4; 对比实验中, Matthews 相关系数稳定在 0.91~0.98 之间, 性能显著更优, 检测准确性更高。

关键词: 云状特征; 全天空云状检测; 深度学习; 多尺度特征; 注意力机制

Research on Intelligent All-Sky Cloud Pattern Recognition Technology for Meteorological Observation

ZHAO Shangzhuo^{1,2}, ZHANG Ziyi^{1,3}, CUI Juan^{1,4}

(1. Changzhi Meteorological Bureau, Changzhi 046000, China;

2. School of Marine Sciences, Nanjing University of Information Science and Technology, Nanjing 210044, China;

3. School of Atmospheric Sciences, Nanjing University of Information Science and Technology, Nanjing 210044, China;

4. School of Applied Meteorology, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: To enhance the accuracy of cloud pattern recognition in meteorological observation, an intelligent all-sky cloud pattern recognition technology based on improved deep learning is proposed. A multi-scale feature pyramid fusion module is introduced into traditional deep learning, which adaptively captures the cross-scale features of clouds from fine textures to macroscopic structures. Meanwhile, an attention module is added to dynamically weight key feature regions, effectively suppressing the interference of unimportant features. The all-sky cloud pattern images are input into the intelligent recognition model based on improved deep learning to calculate the distribution probability of each cloud pattern category, with the maximum value taken as the recognition result. Based on all-sky observation data in North China, experimental testing is conducted on a dataset containing 10 typical cloud patterns. Experimental results show that the proposed technology gradually reduces the cross-entropy loss from 0.008 8 to 0.000 4 in the ablation experiment; In comparison experiments, the Matthews correlation coefficient is stably between 0.91 and 0.98, demonstrating a superior performance and higher recognition accuracy.

Keywords: cloud pattern characteristics; all-sky cloud pattern recognition; deep learning; multi-scale features; attention mechanism

收稿日期:2026-01-23; 修回日期:2026-02-10。

基金项目:山西省气象局青年基金项目(SXKQNF20205251)。

作者简介:赵尚卓(1988-),女,硕士,工程师。

通讯作者:崔娟(1993-),女,大学本科,工程师。

引用格式:赵尚卓,张子怡,崔娟. 面向气象观测的全天空云状智能检测技术研究[J]. 计算机测量与控制, 2026, 34(7): 52

0 引言

气象条件对众多领域的决策都有着直接的影响，小到人们的日常出行，工作安排，大到防灾减灾和农业规划等^[1]。因此，气象观测是气象部门一项重要的观测任务。气象观测任务包括多个维度，其中云状检测是气象观测的核心任务之一。天空云状不仅直观反映大气运动状态，更是天气预报模型的关键输入参数^[2]。因此，进行天空云状检测技术研究具有重要的现实意义。

国内外研究已尝试将机器学习、深度学习等方法应用于气象目标识别，如基于密度聚类^[3]、堆叠降噪自编码^[4]、贝叶斯分类器^[5]及残差网络等方法^[6]，但在云状多尺度特征提取、复杂形态建模与实时检测方面仍存在局限性。本文针对全天空云状智能识别问题，提出一种融合可变形卷积与空洞空间金字塔池化的多尺度特征提取方法，并结合注意力机制增强判别性特征表达，构建端到端的云状识别模型，以提升复杂气象条件下的识别精度与鲁棒性。

1 全天空云状智能检测研究

通过天空云状观测，可以提前预知气象信息，以便调整计划决策。为此，研究一种改进深度学习的全天空云状智能检测技术。在传统深度学习网络中引入多尺度特征金字塔融合模块以及全局注意力模块，以改善传统深度学习网络在云状特征提取方面的缺陷。

1.1 云状特征与形成机理分析

云作为大气中水汽凝结形成的可见聚集体，其形态结构直接反映了所在高度的温度、湿度、垂直运动及大气稳定度等物理条件。云状分类基于其宏观形态、微观结构及形成机理，目前主要分为高云、中云和低云 3 个云族，涵盖 10 类典型云状，每一类具有不同的特点，具体如表 1 所示。

从表 1 中可以看出，云状的形成与演变受大气热力、动力及微物理过程的共同控制。高云族（如卷云、卷积云、卷层云）形成于对流层中高层（>6 000 m），主要由冰晶组成，其形态往往与大尺度环流系统、高空急流、锋面抬升或波动过程相关。卷云（Ci）的纤维状结构常指示高空风切变与冰晶沉降轨迹；卷积云（Cc）的鱼鳞状纹理多与大气重力波或凯尔文－赫尔姆霍兹不稳定性引起的周期性波动有关；卷层云（Cs）则多伴随暖锋或高空辐合系统，表现为大范围均匀冰晶层，透光性强，常预示天气系统侵入。

中云族（如高积云、高层云）形成于中层大气（2 000～6 000 m），常由过冷水滴与冰晶混合组成，其结构与中层对流、波动或系统性抬升密切相关。高积云（Ac）的波状或块状排列反映了大气中层的稳定层结与波动传播；高层云（As）多与暖锋或大尺度抬升相联系，云

表 1 云状分类与特征

云族	名称	形态特点	检测难点
高云族 (高度>6 000 m)	卷云 (Ci)	纤维状、丝缕状，纹理高频、方向性强	纹理细微、方向多变，易与背景天空混淆
	卷积云 (Cc)	鱼鳞状或涟漪状，呈现小尺度、周期性的纹理图案	纹理周期性不明显、尺度小，易受光照影响
	卷层云 (Cs)	均匀薄幕，覆盖大面积天空，无明显云块或缝隙，其纹理平滑，缺乏层积云或高积云的块状结构	缺乏明显结构，与晴空或薄雾易混淆
中云族 (高度2 000 - 6 000m)	高积云 (Ac)	波浪状、块状，透光条纹，中等尺度，边缘清晰，常成行成波排列	块状结构多样，尺度变化大，透光部分易漏检
	高层云 (As)	灰白色或灰色云层，均匀覆盖天空，可能伴随细雨或雪	与雨层云外观相似，区分依赖细微纹理与透光性
低云族 (高度<2 000m)	层云 (St)	均匀灰色的云层，覆盖整个天空，细微的垂直条纹或波浪状纹理，垂直结构不明显，底部平坦，常伴随毛毛雨或雾	纹理平淡、对比度低，易与雾、霾混淆
	层积云 (Sc)	灰白色大云块，宏观结构分明，缝隙可见蓝天	云块间隙易误判为云类边界，需结合上下文判断
	雨层云 (Ns)	均匀幕状，低对比度，无定形纹理，常与雾霾混淆	缺乏明显特征，易与高层云、雾霾混淆
	积云 (Cu)	底部平坦、顶部凸起，呈花椰菜状，垂直发展旺盛，孤立或成群分布	垂直结构明显但形态多样，尺度变化大
	积雨云 (Cb)	庞大如山，垂直发展极盛，顶部砧状结构，纹理从底部粗糙到顶部光滑变化剧烈	结构复杂、尺度极大，顶部与底部纹理差异大

层较厚时遮蔽日月光，常为连续性降水的前兆。

低云族（如层云、层积云、雨层云、积云、积雨云）形成于边界层或低层大气（<2 000 m），直接受地表加热、湍流混合、对流活动及天气系统影响。层云（St）常在稳定大气中由辐射冷却、平流雾抬升或微弱抬升形成，结构均匀，易与雾、霾混淆；层积云（Sc）多出现在对流抑制环境下，由浅对流或湍流混合形成，云块间隙反映边界层内弱对流结构；雨层云（Ns）常与持续性降水系统（如暖锋、气旋）相伴，云层深厚且含水量高，底部常伴有降水拖曳；积云（Cu）由热力对流引发，垂直发展程度反映对流可用潜能（CAPE）

大小,常预示局地对流天气;积雨云(Cb)则为强烈对流发展的成熟阶段,云顶可达对流层顶,伴随雷电、强降水等剧烈天气,其砧状结构由高空风拉伸与冰晶扩散形成。

综上,云状的形态特征本质上是其形成过程中大气物理过程的外在表现。类内形态多变、类间外观相似的特点(如高层云与雨层云、层云与雾霾),给基于视觉的智能检测带来巨大挑战,要求模型不仅能捕捉多尺度视觉特征,还应具备对云物理过程的理解能力,以实现更具鲁棒性与可解释性的云状识别。

1.2 基于改进深度学习的智能检测模型

1.2.1 模型硬件架构与多尺度特征提取

为构建面向实时气象观测的端到端检测系统,本文设计了一套全天空自动化观测站硬件架构,并在此基础上实现了可变形卷积与空洞空间金字塔池化协同的多尺度特征提取流水线。系统数据流与计算分工如图1所示,展示了从数据采集到特征融合的硬件协同过程。




图1 全天空云状检测系统硬件架构与数据处理流程图

如图1所示,系统硬件架构由前端采集单元与边缘计算单元构成,采用FPGA+GPU异构计算模式实现高效分工:

1) 前端采集单元(FPGA控制):由全天空成像仪、多光谱/偏振传感器、红外测温单元及环境传感器组成^[7]。FPGA负责所有传感器的同步触发、原始数据采集、实时预处理以及数据打包^[8]。

2) 边缘计算单元:接收来自FPGA的预处理后图像数据,部署本文提出的改进深度学习模型,主要负责计算密集型的特征提取与检测任务,即可变形卷积、ASPP多尺度特征融合及注意力加权等算法模块的执行。

可变形卷积的硬件实现与作用如图2所示。

如图2所示,与标准卷积的固定采样网格不同,可变形卷积通过学习到的偏移量使卷积核采样点能自适应




图2 可变形卷积采样位置自适应示意图

贴合云状的复杂边缘形态^[9]。该操作在CPU/边缘AI推理单元上实时执行,FPGA负责采集、同步触发和预处理,其计算过程对应于公式(1):

$$b_{out} = \sum_{p=1}^p W(p_n) \times A_{out}(p_0 + p_n + \Delta_n) \quad (1)$$

式中, P 代表卷积核的固定网格(如 3×3); $W(p_n)$ 代表权重; p_0 代表全天空图像上的当前位置; Δp_n 代表可学习的位置偏移量; p_n 代表卷积核的标准偏移。

在可变形卷积中,每个采样位置 k 配备一个二维偏移量 Δp_k ,该偏移量由同一输入特征图通过一个额外的卷积层回归得到:

$$\Delta p_k = G_k(X) \quad (2)$$

式中, G_k 代表一个卷积层,用于预测偏移量图; X 代表输入特征图。 b_{out} 进入ASPP层,在该层中通过使用多个不同扩张率的并行空洞卷积以全面提取从云上细小纹理到宏大结构的多尺度特征^[10-11]。第 i 层空洞卷积金字塔的输出 a_i 为:

$$a_i = f_i^\delta(b_{out}) \quad (3)$$

式中, $f_i^\delta()$ 代表映射学习函数; δ 代表扩张率。

将每层空洞卷积金字塔的输出进行拼接融合,输出一个多尺度特征向量 C_{out} 为:

$$C_{out} = \text{Concat}(a_1, a_2, \dots, a_N) \quad (4)$$

式中, N 代表空洞卷积金字塔层数。这种机制使得卷积核能“感知”并适应云状边缘的局部形变,提升对卷云纤维结构、积云凸起顶部等不规则形态的建模能力。

在多尺度特征融合模块的设计中,空洞空间金字塔池化的扩张率选择是紧密结合大气物理学中云的尺度谱分布理论,以实现云状多尺度结构的物理一致性建模^[12-13]。

空洞空间金字塔池化通过多个并行的空洞卷积提取多尺度特征,其核心在于扩张率 r 的选择,该参数决定了卷积核的感受野大小^[14-15]。本文依据云状的多尺度大气物理特性与特征融合需求,选取 $r=6, 12, 18$ 三个扩张率,具体依据如下:

1) 小扩张率($r=6$):对应云中细微纹理与局部结构的捕捉,如卷积云(Cc)的鱼鳞状纹理、卷云(Ci)的纤维走向等微观特征^[16]。该尺度与云物理中“湍流耗散区”的尺度范围相对应,适于提取高频、局部的形

态信息。

2) 中扩张率 ($r=12$): 对应中等尺度云组织的感知, 如高积云 (Ac) 的波状云带、层积云 (Sc) 的云块间隙等中观结构^[17]。该尺度覆盖了云物理中“云胞”或“云街”的典型尺度, 是区分多数云类的关键尺度。

3) 大扩张率 ($r=18$): 对应宏观云系与整体布局的把握, 如积雨云 (Cb) 的砧状云顶、层云 (St) 的均匀幕状覆盖等大范围云场特征^[18]。该尺度与天气系统中“云团”或“云带”的尺度相匹配, 有助于检测与天气过程相关的云型。

通过将扩张率与云的物理尺度谱对齐, ASPP 模块能够以物理可解释的方式同步提取云状的多层次特征^[19-20]。在特征融合阶段, 各扩张率分支的输出被拼接为统一的多尺度特征向量 F_{multi} , 公式为:

$$F_{\text{multi}} = \text{Concat}[f_{r=6}(F), f_{r=12}(F), f_{r=18}(F)] \quad (5)$$

该设计使模型能同步捕获从纹理细节到宏观结构的全尺度信息, 形成具有物理一致性的多尺度特征表示, 为后续分类提供判别性更强的特征基础。

1.2.2 双卷积空间注意力模块设计

为动态增强云状判别性区域的特征表达并抑制背景与噪声干扰, 本文提出了一种轻量化的双卷积空间注意力 (DCSA, dual-convolution spatial attention) 模块。该模块属于空间注意力机制, 其核心是通过双卷积结构对特征图的空间维度进行自适应加权, 使模型能够聚焦于云状图像中的关键区域, 从而提升特征表达的区分性与鲁棒性^[21]。

该模块的结构组成如图 3 所示, 其输入为多尺度特征提取模块输出的特征图。




图 3 双卷积空间注意力块结构示意图

模块的具体计算流程如下。

通过双卷积对尺度特征向量进行降维, 即:

$$\begin{cases} D_{1,\text{out}} = W_1 * C_{\text{out}} + \epsilon_1 \\ D_{2,\text{out}} = W_2 * (D_{1,\text{out}}) + \epsilon_2 \end{cases} \quad (6)$$

式中, $D_{1,\text{out}}$ 、 $D_{2,\text{out}}$ 代表第一、二层卷积层的输出; W_1 、 W_2 代表第一、二卷积层核参数; ϵ_1 、 ϵ_2 代表第一、二卷积层偏置; 第一层卷积将通道数降至较低维度 (如 64 维), 第二层卷积进一步将通道数压缩为 1, 生成一个二维的空间显著性映射。

图中每个位置的权重计算公式如下:

$$U(u,v) = \frac{\exp[D_{2,\text{out}}(u,v)]}{\sum_{\epsilon_1} \exp[D_{2,\text{out}}(u,v)]} \quad (7)$$

式中, $U(u,v)$ 代表注意力权重图 U 中位置 (u,v) 的注意力权重; $D_{2,\text{out}}$ 代表 $D_{2,\text{out}}$ 中位置 (u,v) 的元素值。

将输入特征 C_{out} 与权重图 U 逐通道相乘, 得到:

$$\hat{C}_{\text{out}} = C_{\text{out}} \odot U \quad (8)$$

式中, $\hat{C}_{\text{out}}$ 代表注意力加权特征。经过上述操作, 模型能够自适应地聚焦于不同云状的关键形态与纹理特征, 有效提升了后续分类决策的准确性与稳定性。

该双卷积空间注意力模块结构轻量, 仅通过两级卷积实现特征降维与权重生成, 计算开销小, 非常适合嵌入到实时气象观测的端到端检测流程中。

1.2.3 改进模型训练与检测

结合上述两个模块, 对传统深度神经网络进行改进, 改进后的模型结构如图 4 所示。




图 4 基于改进深度学习的云状智能检测模型结构

为提升模型在不同光照与天气条件下的鲁棒性, 本文在模型训练阶段引入了动态对比度增强与自适应损失优化策略, 并在推理部署中实现了从预处理到分类决策的端到端自动化流程。本节的创新在于将训练过程的适应性改进与嵌入式部署的实时性要求相结合, 构建了一套适用于真实气象业务场景的检测系统。

基于改进深度学习的智能检测模型在应用前, 需要进行训练, 目的是优化调整模型参数, 使模型变得成熟, 能够很好地学习到特征与目标类别之间的映射关系。输入原始全天空云状图像为 A_m , 在输入层对其进行预处理, 增强云状图像的对比度。在模型输入预处理阶段, 采用动态对比度增强方法对原始全天空云状图像进

行自适应调整，公式为：

$$\tilde{A}_{out}(x,y)=\frac{A_{in}(x,y)-\min(A)}{\max(A)-\min(A)}(\alpha_{max}-\alpha_{min})+\alpha_{min}$$

(9)

式中， $\tilde{A}_{out}(x,y)$ 代表对比度增强后的全天空云状图像像素值； $A_{in}(x,y)$ 代表原始全天空图像像素值， $\min(A)$ 、 $\max(A)$ 代表全天空图像的最小/最大像素值； α_{min} 、 α_{max} 代表像素调整目标范围。

与传统固定参数拉伸不同，本文提出基于环境光照的自适应参数选取策略：目标范围参数 $\min(A)$ 和 $\max(A)$ 不再固定，而是根据图像采集时传感器同步记录的环境光强度 L_{env} 动态调整：

$$\begin{cases} \min(A)=\alpha\times\log(1+L_{env}) \\ \max(A)=\beta\times\log(1-e^{-L_{env}}) \end{cases}$$

(10)

对云状图像 $\tilde{A}_{out}$ 进行剪裁，统一输入尺寸，得到 A_{out} 。接着，让 A_{out} 通过引入的多尺度特征金字塔融合模块和注意力模块，输出 $\hat{C}_{out}$ 。 $\hat{C}_{out}$ 进入全局平均池化层，计算每个通道的平均值，得到全局平均池化后的全局特征向量，记为 Z ：

$$Z=GAP(\hat{C}_{out})=(z_1,z_1,\cdots,z_M)^T$$

(11)

式中， M 代表通道数； $GAP()$ 代表全局平均池化表示。经过特征提取与注意力加权的信息洪流，通过公式 (11) 的全局平均池化得到收敛。在部署于观测站机柜内的边缘 AI 推理设备中，这一步骤由专用张量核心高效完成，它将每张特征图压缩为一个最具代表性的数值。此举极大减少了后续全连接层的参数计算量，使得模型能够在有限的嵌入式算力下保持高速运行，这是算法能实现分钟级实时检测的关键工程优化之一。

最后进入全连接层，以归一化函数 Softmax 作为分类器，计算每个输出属于各个云状类别的分布概率：

$$s_k=\sum_{m=1}^M\mathbf{W}_{km}\ast z_m+\boldsymbol{\varepsilon}_k$$

(12)

$$y_k=\frac{\exp(s_k)}{\sum_{j=1}^K\exp(s_j)}$$

(13)

式中， s_k 、 y_K 代表全连接层的输出——第 k 种云状的得分、分布概率； $\mathbf{W}_{km}$ 、 $\boldsymbol{\varepsilon}_k$ 代表全连接层权重矩阵、偏置向量； K 代表云状类别数量。公式 (12) 和 (13) 所定义的全连接层与 Softmax 函数接管工作，执行最终的裁决。这些训练好的权重参数已固化在设备的存储器中。系统将池化后的特征向量与这些参数进行矩阵乘法与非线性变换，计算出当前天空属于十类云状及晴空的概率分布。在一次实际观测中，模型可能输出积云 (Cu)：0.02，层积云 (Sc)：0.18，高积云 (Ac)：0.75，…，这一串数字量化了算法对所有可能性的判断。

计算与预期之间的交叉熵损失，通过梯度下降算法进行反向传播训练，调整模型当中的和。完成训练后，

将检测模型部署到气象观测站，实现全天空云状的实时自动检测，最终取最大值对应的结果作为检测结果：

$$y^*=\arg\max_k(y_k)$$

(14)

式中， y^* 代表全天空云状智能检测结果。

2 实验结果与分析

为验证所提技术的有效性，基于华北地区观测数据开展实验，构建具有代表性的云状识别数据集，确定一致的实验环境与训练策略，评估识别性能，并对实验结果进行深入分析，确保实验结果的可比性与可靠性。

利用全天空成像仪采集华北地区（包括山西、河北、北京）2023~2025 年连续观测数据，包含层状云、积状云、高积云等典型云状图像，全天空观测设备示意图如图 5 所示。



图 5 全天空观测设备示意图

依据《地面气象观测规范》独立标注云状类别，最终标签以多数一致为准。从 2 500 幅标注图像中按 7：3 比例随机划分训练集（1752 幅）与测试集（748 幅），确保季节、时段分布均衡；实验在 Ubuntu 20.04 系统下进行，采用 PyTorch 1.12.1 框架，硬件平台为 Intel Core i910900K CPU 与 NVIDIA RTX TITAN 24G GPU（详见表 2）。使用 AdamW 优化器，初始学习率为 1×10^{-4} ，权重衰减 1×10^{-4} ，采用余弦退火学习率调度，训练 100 轮，批量大小为 16，包含 5 轮学习率预热。本次实验环境配置如表 2 所示。

表 2 实验环境配置

类别	名称	配置信息
硬件平台	CPU	Intel Core i9 10900K
	GPU	NVIDIA RTX TITAN 24G
	内存	32G
	显卡	24G
软件环境	操作系统	Ubuntu 20.04 LTS(服务器)
	深度学习框架	PyTorch 1.12.1+CUDA 11.3
	编程语言	Python 3.8.15
	开发工具	JupyterLab 3.5.0, VS Code 1.75.0, Git 2.34.1, Docker 20.10.21
	标注工具	LabelImg

模型使用 PyTorch 1.12.1 框架实现，在 NVIDIA

RTX TITAN 24G GPU 上进行训练。采用 AdamW 优化器, 其结合了 Adam 的自适应学习率与权重衰减正则化, 能有效缓解过拟合并提升泛化能力。通过对权重参数施加 L2 正则化约束, 防止模型在训练后期因权重过大而过拟合。学习率调度采用余弦退火策略, 训练总轮数为 100, 其中包含 5 轮线性学习率预热, 学习率从 1×10^6 线性增长至 1×10^4 , 避免训练初期因学习率过大导致梯度震荡。批量大小设为 16, 兼顾内存效率与梯度估计稳定性。

从观测数据中抽取 2 500 幅图像构建实验数据集, 然后邀请 3 名资深气象观测员, 依据《地面气象观测规范》对图像进行独立云状标注, 最终标签以多数一致为准。最后按 7 : 3 的比例随机划分训练集和测试集, 确保各季节、各时段数据分布均衡。样本分布如表 3 所示。

表 3 全天空云状样本分布

云状类别	总样本数	训练集样本数/个	测试集样本数/个
卷云(Ci)	275	193	82
卷积云(Cc)	125	88	37
卷层云(Cs)	100	70	30
高积云(Ac)	400	280	120
高层云(As)	150	105	45
层云(St)	300	210	90
层积云(Sc)	375	263	112
雨层云(Ns)	125	88	37
积云(Cu)	250	175	75
积雨云(Cb)	100	70	30
晴空/无云	300	210	90
总计	2 500	1 752	748


利用表 3 中训练集样本数在 PyTorch 框架上对改进深度学习网络模型进行训练。训练完成后, 用于技术应用测试。以其中一个云状图像样本为例, 进行云状检测, 如图 6 所示。

从图 6 中可以看出, 所构建模型应用下, 检测出示例图像中云状为卷积云 (Cc), 且检测成功, 证明了所研究技术的有效性。


1) 消融实验:

以交叉熵损失作为指标, 进行消融实验, 量化评估云状智能检测模型中 2 个改进模块的贡献。具体操作如下: 依次替换模型中的关键组件 (基础深度神经网络 (标准卷积)、多尺度特征金字塔融合模块、多尺度特征金字塔融合模块+注意力模块), 保持其他设置不变进行测试。通过性能下降幅度判断各模块重要性。消融实验结果如图 7 所示。

从图 7 中可以看出, 经过 100 次迭代, 3 个交叉熵损失曲线趋于平缓, 随着迭代次数的增加, 标准卷积 (基础深度神经网络) 在测试集上的交叉熵损失从 0.014 4 逐渐下降到 0.002 8; 引入多尺度特征金字塔融



(a) 检测模型输入



(b) 检测模型输出

图 6 云状检测结果




图 7 交叉熵损失曲线

合模块的深度神经网络在测试集上的交叉熵损失从 0.012 8 逐渐下降到 0.001 6; 引入多尺度特征金字塔融合模块+注意力模块的深度神经网络在测试集上的交叉熵损失从 0.008 8 逐渐下降到 0.000 4; 相比之下, 引入多尺度特征金字塔融合模块+注意力模块的深度神经网络最小, 损失值均小于其他 2 种网络模型, 改进效果最好。

2) 对比实验:

以 Matthews 相关性系数为指标, 以基于机器学习的检测技术、基于 SDAE 的检测技术、基于贝叶斯分类器的检测技术作为对比方法, 以所研究检测技术作为实验方法, 利用 4 种技术进行对比, 验证检测准确性。结果如图 8 所示。

从图 8 中可以看出, 所研究检测技术的 Matthews 相关性系数在 0.91~0.98 之间, 基于机器学习的检测技术的 Matthews 相关性系数在 0.79~0.90 之间, 基于 SDAE 的检测技术的 Matthews 相关性系数在 0.77~




图 8 Matthews 相关性系数对比

0.95 之间, 基于贝叶斯分类器的检测技术的 Matthews 相关性系数在 0.80~0.84 之间。相比之下, 所研究检测技术 Matthews 相关性系数整体数值相对更高, 且波动范围最小, 为 0.07, 说明所研究检测技术的准确性更高, 误检测率更低。这一优越性能主要得益于模型架构中的两个核心设计: 多尺度特征金字塔融合模块有效解决了云状检测的尺度敏感性问题; 注意力模块极大地提升了模型的特征选择与抗干扰能力。二者的协同作用构成了性能提升的关键, 使模型在面对复杂多变的真实气象场景时, 能够做出更准确、更稳定的判断。

3 结束语

研究中引入可变形卷积与空洞空间金字塔池化构建多尺度特征金字塔融合模块, 有效解决了传统卷积网络固定感受野难以兼顾局部细节与全局模式的局限; 同时, 通过设计注意力模块, 实现了对云状关键判别特征的自适应聚焦与增强, 显著提升了模型在复杂场景下的抗干扰能力与检测稳定性。在基于真实观测数据构建的华北地区云状数据集上进行的系统实验表明, 该模型在检测精度方面显著优于现有主流方法。然而, 研究仍存在一些局限性, 例如模型的计算效率需优化以适应边缘设备的实时性要求。因此, 未来将深入探究模型轻量化与压缩技术, 探索在嵌入式设备上的高效部署。

参考文献:

- [1] 冯 扬, 秦鹏程, 胡一阳, 等. 长江流域复合极端气候事件指标及检测方法综述 [J]. 人民长江, 2025, 56 (3): 95-105.
- [2] 孙 雪, 涂玉凤, 孙 劭, 等. 闽江流域复合极端气候事件的检测与时空格局特征 [J]. 水利水电技术 (中英文), 2025, 56 (3): 1-14.
- [3] 张志坚, 张 静, 伍光胜. 一种基于机器学习的自动气象观测站风向异常检测方法 [J]. 气象, 2025, 51 (4): 460-472.
- [4] 杨新湿, 罗秋晴, 张召悦. 基于 SDAE 的终端区气象场景模式检测方法 [J]. 河南科技大学学报 (自然科学版), 2024, 45 (2): 96-104.

- [5] 李 巧, 戚友存, 张 哲, 等. 基于贝叶斯分类器和回波物理特征的 C 波段雷达非气象回波检测方法和性能分析 [J]. 大气科学, 2024, 48 (3): 823-836.
- [6] 魏铁鑫, 司丽丽, 赵 亮, 等. 河北灾害性天气事件图像检测技术研究与应用 [J]. 热带气象学报, 2024, 40 (6): 983-992.
- [7] 欧阳彤, 汪 玲, 朱岱寅, 等. 融合 LightGBM 的 ResNeXt 气象目标细粒度检测方法 [J]. 系统工程与电子技术, 2024, 46 (12): 4034-4043.
- [8] 江旺玉, 王 乐, 姚叶鹏, 等. 多尺度特征聚合扩散和边缘信息增强的小目标检测算法 [J]. 计算机工程与应用, 2025, 61 (7): 105-116.
- [9] 帖 军, 龙吕佳, 郑 禄, 等. 融合多尺度特征和多重视觉力的棉田杂草检测研究 [J]. 中国农机化学报, 2025, 46 (10): 138-145.
- [10] 史世豪, 施群山, 周 杨, 等. 混合特征与多尺度融合的光学小目标检测算法 [J]. 地球信息科学学报, 2025, 27 (7): 1596-1607.
- [11] 林杰涛, 胡克勇, 袁天龙, 等. 高效注意力与多尺度特征聚合的遥感影像变化检测 [J]. 北京邮电大学学报, 2025, 48 (4): 59-64.
- [12] 张 波, 李孟新. 融合注意力与多尺度特征的微表情检测方法 [J]. 计算机工程与设计, 2025, 46 (11): 3248-3257.
- [13] 夏兴华, 王海光, 韩忠华. 基于多尺度注意力机制的光伏板缺陷检测 [J]. 计算机仿真, 2025, 42 (9): 390-396.
- [14] 郑 玉, 徐 芬, 王亚强. 基于 R2CNN 的天气雷达边界层辐合线检测算法 [J]. 应用气象学报, 2024, 35 (6): 654-666.
- [15] 刘冬韩, 史 军, 俞 玮, 等. 基于视频的天气现象检测及其应用研究 [J]. 太阳能学报, 2024, 45 (8): 441-447.
- [16] 董傲男, 窦 杰, 陶志刚, 等. 基于双路径特征融合的深度学习神经网络滑坡智能检测 [J]. 自然灾害学报, 2025, 34 (6): 106-117.
- [17] 刘丽景. 基于遥感卫星的极端气象观测数据安全预警系统 [J]. 计算机测量与控制, 2024, 32 (5): 193-200.
- [18] 张德玉, 胡树贞, 秦三杰, 等. 基于人工和地基器测数据的 AI 云识别方法 [J]. 干旱气象, 2025, 43 (5): 810-819.
- [19] 谢宁波, 许新桥, 王前鹏, 等. 面向智慧林草的天空地一体化监测技术研究进展 [J]. 林草资源研究, 2025 (3): 1-8.
- [20] 张玉洁. 基于空间结构函数的地面气象观测站网布局研究 [J]. 干旱气象, 2025, 43 (2): 329-336.
- [21] 叶寿洪, 李罗红, 周 若, 等. 基于低成本北斗终端且无温压观测依赖的实时大气水汽监测方法 [J]. 导航定位与授时, 2025, 12 (6): 136-146.