

doi: 10.3969/j.issn.1000-8349.2024.02.11

基于深度学习的全天空相机成像 日间云量计算研究

车 蕾¹, 李磊磊¹, 刘立勇²

(1. 北京信息科技大学 信息管理学院, 北京 100192; 2. 中国科学院 国家天文台, 北京 100101)

摘要: 云量是天文领域中地基光电望远镜站址选择的重要评价参数之一。针对全天空相机成像的日间云量计算存在的问题, 提出一种基于深度学习的全天空相机成像日间云量计算模型。云检测层, 模型通过构建通道加权-特征融合 (channel weighting-feature fusion, CWFF) 结构, 从而加强对云层记忆能力和深层特征的提取能力以完成云检测任务; 云量计算层, 模型提出一种基于云检测模型的云量计算方法, 有效提高云量计算的误差率。实验表明, 该方法在云检测任务中的综合准确率超过 95%, 在云量计算任务中的平均绝对误差不超过 5%。

关键词: 全天空相机; 云量计算; 深度学习; U 型网络

中图分类号: TP391 **文献标识码:** A

1 引言

目前云量计算主要采用卫星探测和地基全天空云量相机监测等方式^[1]。卫星探测的优势在于数据获取方便、多波段探测和长周期的数据积累。然而, 基于卫星探测的云量计算受限于探测图像的空间分辨率和时间分辨率, 一般站点上空的云量在图像中仅被几个像素所覆盖, 并且探测的时间间隔为天或小时的量级。而基于地基的全天空相机具有稳定的性能和实时监测等特点, 因而被广泛应用于各个台址的云量计算和评价中^[2,3]。早期气象部门的云量计算主要由经过训练的观测人员肉眼评估, 随着计算机技术和大数据处理技术的发展, 云量计算方法也逐渐从传统的人工观测转向自动化和智能化处理, 目前主要有阈值法、聚类法、机器学习和深度学习等云量计算方法。

在阈值法方面, 研究者们积极探索不同的阈值设定和优化方法, 以提高其适用性和准确

收稿日期: 2023-10-25; 修回日期: 2024-03-07

资助项目: 国家重点研发计划 (YS2021YFC2203202); 国家自然科学基金 (11873063); 全国高等院校计算机基础教育研究会计算机基础教育教学研究课题 (2023-AFCEC-004)

通讯作者: 刘立勇, liuly@nao.cas.cn

性。霍娟和吕达仁^[4]通过建立像素 RGB 值与空间位置之间的相关性,并运用理论和经验值确定阈值,进行了云检测的初步实验。秦永等人^[5]利用云和雪在光谱上的不同特征对卫星图像进行处理,采用最大类间方差的方法对云层进行阈值化分割,并据此提取云的形状特征,成功地将云层从其他地物分离出来。马芳等人^[6]通过建立基于阈值法的通道综合运算云检测方法,极大地改善了地理位置对云检测的影响。

对于聚类法,研究者们尝试引入多维特征和多尺度信息,以提高云检测的准确性。陈思成等人^[7]针对云层信号检测,提出一种基于双阈值的算法。该算法能够有效地消除气溶胶信号的干扰,并准确地筛选出云层信号。李晓龙等人^[8]通过研究薄云识别和影响评估算法,结合模糊 C 均值聚类算法,对地基光学天文图像中的薄云进行有效识别和分析,从而实现了自动监测和实时评估云层分布和影响程度,并提高了地基光学天文观测的效率。

在机器学习方面,研究者们采用多种传统的机器学习方法,如支持向量机 (support vector machine, SVM)、反向传播神经网络 (backpropagation neural network, BP 神经网络) 等进行云检测。Joshi 等人^[9]提出了一种 STmask 的方法,该方法基于 SVM 模型。他们在多种地表类型的场景下应用该方法,成功地提高了分类效果。高军等人^[10]提出了一种基于归一化动云指数的动态阈值法,该方法用于初步云检测。此外,他们进一步提出了基于 BP 神经网络的云检测算法,该算法消除了阈值选取中的主观影响,并且在大范围复杂下垫面的遥感图像数据中表现出较好的云检测效果。

深度学习是一种试图使用包含复杂结构或由多重非线性变换构成的多个处理层,对数据进行高层抽象的算法。至今,已有数种深度学习框架被应用在计算机视觉、图像分割、自然语言处理等领域^[11-14],并获取了极好的效果。近些年来一部分国内外专家学者基于深度学习相关技术,开展云检测方面的研究。康晓光和孙龙祥^[15]运用神经网络自动云检测算法,实现了云与天空的语义分割,使得训练后的网络检测精度和泛化能力具有较高的提升。夏旻等人^[16]设计了一个由四个卷积层和一个全连接层组成的卷积神经网络,很好地提取了云的基本特征,其分割准确率为 85% 以上。裴亮等人^[17]基于全卷积神经网络 (fully convolutional network, FCN) 模型对全卷积网络进行多次上采样,将云检测准确率提升至 90.11%,基本实现了端到端像素级别的检测能力。

虽然深度学习在云检测方面具有很大优势,但是当应用于全天空相机所拍摄的云图时,由于云层的复杂性以及光线强度的不均匀性,其分割准确度受到很大的影响。随着云层复杂度的增加,分割准确度会变得越来越难以保证。此外,现有的语义分割模型只对某一特定场景有不错的准确率,对于全天空相机成像的云检测,则模型的泛化能力不足^[18]。另外,在卷积操作中,统一处理整张图像特征,会降低重要特征的提取关注度。为解决上述问题,针对日间云量,我们提出一种基于深度学习的全天空相机成像云量计算模型,主要贡献体现在三个方面:

(1) 在全天空相机成像的云检测中,本文以深度学习中的 U 型网络 (u-shaped network, U-Net) 神经网络为基础,提出基于 CWFF 特征提取结构,加强模型对深层语义的提取,使分割结果更能反映出全天空相机成像的特征信息。

(2) 提出一种基于云检测层的云量计算方法,直接通过特征矩阵计算出云量结果,有效

避免了成像后再对云量进行计算的过程, 提高了云量计算的效率。

(3) 依次选取云常规分布图像数据、云全天分布图像数据、云受光照干扰图像数据三种典型情况下的数据, 开展固定阈值、动态阈值、文献 [16] 方法、FCN、U-Net、U-Net+残差 (简称 “+残差”)、U-Net+注意力 (简称 “+注意力”)、本文提出的云量计算方法在云检测和云量计算中的对比实验。实验结果表明, 云量计算方法优于其他方法。

2 模 型

基于深度学习的全天空相机成像日间云量计算模型 (如图 1 所示) 主要包括三层。第一层为数据处理层: 对未经处理的原始数据进行预处理操作, 包括数据标准化和数据增强等操作; 第二层为云检测层: 将数据处理层处理好的数据送入云检测层, 在云检测层将通过基于 CWFF 特征提取结构的 U-Net 模型进行云检测; 第三层为云量计算层: 将云检测层提取的特征矩阵通过阈值分割确定全天空相机成像像素点, 最终实现云量计算。

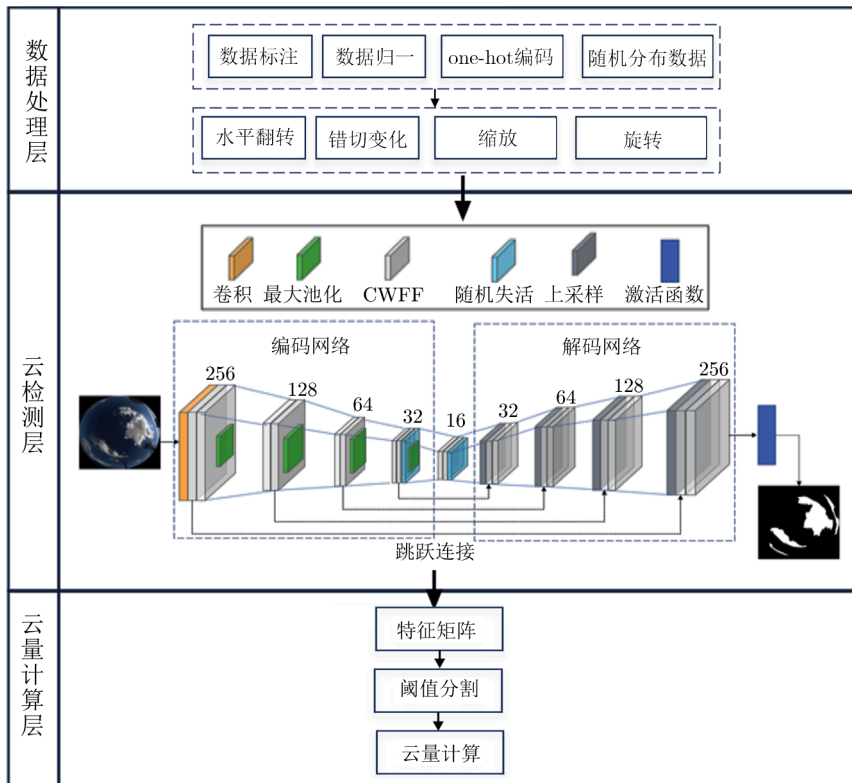


图 1 基于深度学习的全天空相机成像日间云量计算模型


2.1 数据预处理层

2.1.1 数据标注

因为全天空相机成像大小和位深度不统一，所以训练前需要通过程序将其统一处理。首先，对图像内的云对象进行内切圆裁剪，使云对象的上下左右边界与图像的边界相切且大小为 256×256 ；其次，将位深度统一处理成 24 位的 png 图像；最后，使用 LabelMe 软件对全天空相机成像中的有云像素进行标注。标注过程中，采用多闭合曲线标记云对象，以确保云对象和天空对象分布在曲线内外；设置云对象和天空对象依次为白色和黑色；将生成的 json 文件转为带标签的图像。

2.1.2 数据增强

恰当的数据增强技术有助于缓解过拟合现象，提高模型的鲁棒性和泛化能力，以及解决样本不均衡问题。在数据预处理阶段，采用随机旋转、平移、错切变换等方式，对图像数据进行不同程度的变换和扩充操作，以增强数据的多样性（见图 2）；然后，将扩充后的图像与其标签一一对应并生成图像数组。该预处理流程能够有效地提升图像数据的质量和数量，从而有助于提高模型的性能和鲁棒性。



注：a) 原图；b) 翻旋转拉伸；c) 旋转位移；d) 错切位移。

图 2 数据增强

2.2 云检测层

云检测本质上是一个语义分割任务，U-Net 是一种经典的语义分割模型，主要包括两个对称部分：编码网络和解码网络。编码网络用来抓取图像中的上下文信息；解码网络与编码网络基本对称，以达到输出图像分割的目的。通过融合下采样网络特征与上采样网络特征，U-Net 可获得更准确的上下文信息，达到更好的分割效果。然而在模型的前向传播过程中，

随着卷积层数的不断增加, U-Net 模型的对称结构可能会导致在信息传递过程中, 出现信息丢失和不同通道之间的相关性不同的情况。本文结合注意力^[19,20]和残差的思想, 在 U-Net 中融入基于 CWFF 特征提取结构的方法, 可解决下层卷积网络在特征提取时不能有效关注权重较大的重点特征, 以及在卷积过程中的模型退化问题。该方法首先通过通道加权单元为特征通道分配权重, 然后通过特征融合单元提取目标特征并适度记忆上层特征。由此, 我们可以获得更加准确和稳定的特征表示, 提升模型的性能和效率。基于 CWFF 的特征提取结构如图 3 所示。

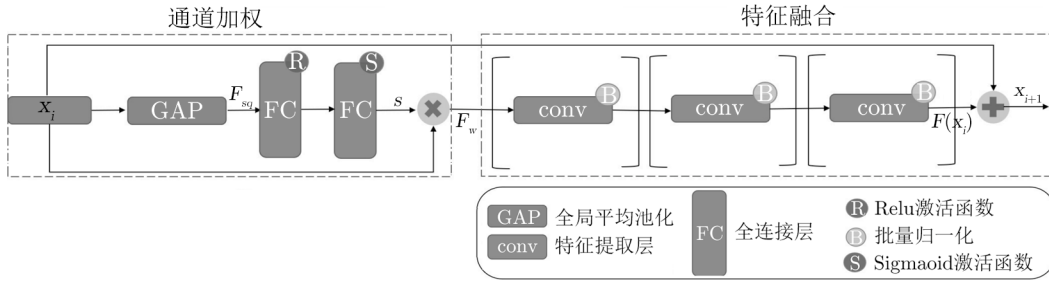


图 3 基于 CWFF 的特征提取结构

每个 CWFF 都包含特征融合单元和通道加权单元两部分。假设神经网络每一层输入的特征向量 x_i 维度为 $[h, w, c]$ 。在通道加权单元中, 采用全局平均池化将其压缩为 $[1, 1, c]$ 的特征向量 F_{sq} :

$$F_{sq} = \frac{1}{h \times w} \sum_{i=1}^h \sum_{j=1}^w u_k(i, j) \quad (1)$$

其中, u_k 表示特征层中第 k 个通道, $k \in [1, c]$ 。通过构建全连接层建立通道之间的相关性, 输出 c 个权重系数 s , 表示为:

$$s = \sigma(w_2 \delta(w_1 F_{sq})) \quad (2)$$

其中, w_1 乘以 F_{sq} 为第一次全连接层操作, $w_1 \in c/r \times c$, r 是一个降维系数, 旨在降低通道数以减少计算量; 接着, 通过激活函数 δ 输出的维度保持不变; 随后再进行一次全连接层操作, 即与 w_2 相乘, $w_2 \in c/r \times c$; 最后通过激活函数 σ , 得到权重 s , 以完成权重分配并与初始特征层相乘。

将经过权重分配的特征向量 F_w 输入到特征融合单元, 在特征融合单元内对其进行三轮卷积和批量归一化操作, 得到特征向量 $F(x_i)$ 。最后, 为避免学习到的特征接近于 0 时特征信息丢失而导致网络性能下降的情况, 本模型将输入 x_i 与 $F(x_i)$ 相加得到本层最终的输出向量 x_{i+1} , 表达式为:

$$x_{i+1} = f(H(x_i) + F(x_i)) \quad (3)$$

其中, x_i 和 x_{i+1} 分别表示第 i 个特征层特征融合单元的输入和输出, F 表示学习到的特征, f 是 δ 激活函数。 $H(x_i) = x_i$ 表示恒等映射, 即学习到的特征为 0。该处理既保证了梯度可

以更加直接地传递，还可以更好地适应深层网络的训练。至此完成一个完整的 CWFF 的过程提取，融入 CWFF 后的 U-Net 模型结构如图 4 所示。

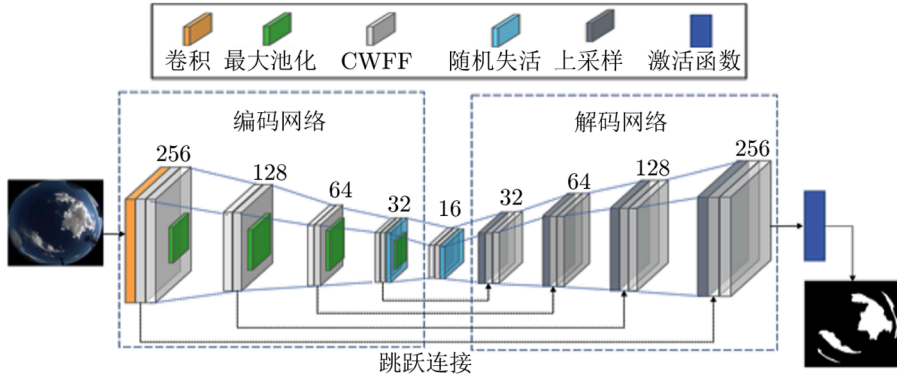


图 4 基于 CWFF 特征提取结构的 U-Net 模型

2.3 云量计算层

基于云检测层对全天空相机成像数据进行特征提取后，通过最后一层激活函数生成的特征矩阵：

$$\mathbf{A}_{m \times n} = \begin{pmatrix} \mathbf{a}_{0,0} & \cdots & \mathbf{a}_{0,n-1} \\ \vdots & \ddots & \vdots \\ \mathbf{a}_{m-1,0} & \cdots & \mathbf{a}_{m-1,n-1} \end{pmatrix}, \quad (4)$$

其中， $m, n \in [0, 255]$ ，每一个 $\mathbf{a}_{i,j}$ 都由 x 和 y 两项构成，即 $\mathbf{a}_{i,j} = (x \ y)$ ， x 表示当前像素点为天空背景的概率， y 表示当前像素点为云的概率， $i \in [0, m-1]$ ， $j \in [0, n-1]$ ， $x, y \in [0, 1]$ 。

云量计算层首先对特征矩阵进行阈值分割，如式 (5) 所示。 λ 为分割阈值，这里取 0.9 (本文取 0.5 为初始值，步长为 0.05，终止值为 0.95，当阈值取值为 0.9，云量统计准确率最接近标准值)，将 $y > \lambda$ 的 $\mathbf{a}_{i,j}$ 置为 (0 1)，将 $y \leq \lambda$ 的 $\mathbf{a}_{i,j}$ 置为 (1 0)。

$$\mathbf{a}_{i,j} = \begin{cases} (0, 1), & y > \lambda \\ (1, 0), & y \leq \lambda \end{cases}. \quad (5)$$

接着进行像素判定，引入一个矩阵 $\mathbf{B}_{1 \times 2} = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$ ，通过与 $\mathbf{a}_{i,j}$ 做相乘确定每个 $\mathbf{a}_{i,j}$ 属于云像素还是天空像素。结果为 0，则判定是天空像素，为 1 则判定是云像素：

$$\tilde{\mathbf{a}}_{i,j} = \mathbf{a}_{i,j} \times \mathbf{B}. \quad (6)$$

经过处理后的特征矩阵为：

$$\mathbf{A}_{m \times n} = \begin{pmatrix} \tilde{\mathbf{a}}_{0,0} & \cdots & \tilde{\mathbf{a}}_{0,n-1} \\ \vdots & \ddots & \vdots \\ \tilde{\mathbf{a}}_{m-1,0} & \cdots & \tilde{\mathbf{a}}_{m-1,n-1} \end{pmatrix}, \quad (7)$$

$A_{m \times n}$ 内元素已变成非 0 即 1 的向量, 1 代表云像素, 0 代表天空像素。

在预处理阶段, 训练标签已经被处理成大小为 $m \times n$ 的正方形图像。云像素点完全包含在该正方形图像内, 并且通过云检测模型生成的云特征矩阵也是大小为 $m \times n$ 的正方形。因此, 计算云像素点在全天空相机成像中的百分比, 即计算正方形矩阵中内切圆中云像素点所占内切圆比例, 如公式 (8) 所示。在特征矩阵中, 将所有云像素点的值进行求和, 并除以正方形矩阵内内切圆像素点的数量, 即可得到云像素点在全天空相机成像中的云量结果。

$$S = \frac{\sum_{i=0}^m \sum_{j=0}^n \tilde{a}_{i,j}}{\pi \times \left(\frac{n}{2}\right)^2} \quad (8)$$

2.4 损失函数

损失函数是在神经网络训练过程中计算预测结果与真实结果之间差异的工具, 其数值大小反映出预测结果与真实结果的接近程度。交叉熵作为一种常用的损失函数, 不仅可以有效解决在梯度下降中均方误差损失函数学习速率降低的问题, 而且可以很好地评估训练样本之间的相似性。本文的云量计算中的云检测问题本质属于二分类问题, 因此选择二值交叉熵作为损失函数:

$$loss = -\frac{1}{n} \sum_{i=1}^n x_i \lg y_i + (1 - x_i) \lg(1 - y_i) \quad (9)$$

其中, x_i 为真实值, y_i 为预测值。

3 实验

3.1 实验环境与数据集

本文所使用的实验环境见表 1。整个实验数据集包含 1500 张由同一台全天空相机成像云量仪拍摄的数据集。数据集包含了太阳在不同高度的图像, 并对地面建筑物进行部分扣除。数据集被随机划分为 1200 张训练集和 300 张测试集, 训练周期为 150 轮; 每个批次训练图像 8 张, 模型优化器为 Adam, 初始学习率为 0.0001, 每次减少学习率的因子为 0.5。

表 1 实验环境

设备名称	配置
系统	Windows 10 IoT 企业版
处理器	Intel Core i7 9xx (Nehalem Class Core i7) 2.40 GHz
运行内存	16.0 GB
Python	3.9.7
TensorFlow	2.6.0
Keras	2.6.0
编程软件	Pycharm

3.2 基于云检测模型的实验结果分析

3.2.1 评价指标

	云	天空
云	TP	FN
天空	FP	TN

云检测是云量计算的基础，云检测属于图像分割问题，其对应混淆矩阵如表 2 所示。其中， TP 表示将云像素预测为云像素， TN 表示将天空像素预测为天空像素， FP 表示将天空像素预测为云像素， FN 表示将云像素预测为天空像素。

根据混淆矩阵，我们可以得到像素准确率 (pixel accuracy, PA)、交并比 (intersection over union, IOU)、平均交并比 (mean intersection over union, MIOU) 等评价指标。

像素准确率 (PA) 计算公式：

$$PA = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

交并比 (IOU) 计算公式：

$$IOU = \frac{TP}{FN + FP + TP} \quad (11)$$

平均交并比 ($MIOU$) 计算公式：

$$MIOU = \frac{1}{k+1} \sum_{i=0}^k \frac{TP}{FN + FP + TP} \quad (12)$$

3.2.2 实验结果分析

实验对比基线如下：

- (1) 固定阈值，即通过确定数据的上下边界值，从而判断实际数据是否符合预期的阈值。
- (2) 动态阈值，即针对每个小区域计算对应阈值的方法，不同区域采用不同的阈值。
- (3) 文献 [16] 方法，即基于经过三次卷积的神经网络的方法。
- (4) FCN，即是将传统卷积神经网络全连接层替换为卷积层，并通过上采样来恢复原始尺寸的全卷积神经网络。
- (5) U-Net，即原始网络。
- (6) +残差，即在原始 U-Net 的结构基础上加上残差块。
- (7) +注意力，即在原始 U-Net 的结构基础上加注意力机制。
- (8) 本文方法。

云检测部分只对比深度学习方法，即 (3)–(8) 列出的 6 种方法。固定阈值和动态阈值属于云量计算方法，故用于 3.3 节的对比实验中。

表 3 罗列了云检测评价指标比对结果，可以看出，相比文献 [16] 中的方法、FCN、U-Net、+残差、+注意力，云量计算方法的 PA 指标相对提升了 (相对提升即 $(A - B)/B$) 6.45%、2.29%、1.19%、0.79%、0.87%， IOU 指标相对提升了 12.28%、4.53%、2.34%、

1.55%、1.7%, *MIOU* 指标相对提升 12.28%、4.51%、2.33%、1.51%、1.68%。可以看出, 本文方法优于其他方法。

表 3 云检测评价指标对比

	<i>PA</i>	<i>IOU</i>	<i>MIOU</i>
固定阈值	—	—	—
动态阈值	—	—	—
文献 [16]	0.931 6	0.876 0	0.584 0
FCN	0.969 5	0.941 0	0.627 4
U-Net	0.980 0	0.961 1	0.640 8
+残差	0.983 9	0.968 6	0.645 8
+注意力	0.983 1	0.967 1	0.644 7
本文	0.991 7	0.983 6	0.655 7

图 5 显示云检测训练过程中, 损失函数各个模型的收敛效果。文献 [16] 中的 *loss* 值在下降到 0.2 左右就不再下降; 由于 FCN、U-Net、+残差、+注意力都属于深层网络结构, 所以 *loss* 收敛相差不大, 但是可以看出+残差、+注意力所得结果略优于 FCN、U-Net; 本文收敛效果相对最佳。




图 5 损失函数收敛对比

3.3 基于云检测模型的云量计算实验结果分析

3.3.1 全局数据云量计算对比分析

为了评估本文提出的云量计算模型的有效性, 我们将 300 张测试集分别输入到表 4 中列出的云检测模型。在深度学习方法中, 由于文献 [16] 仅对特征进行简单的提取, 因此相较于其他深度学习方法, 其精度较低。在未添加注意力和残差的模型中, FCN 的精度比 U-Net 精度略高。本文所提出的方法表现出较高的精度, 达到了目前领先的水平, 精度值为 3.53, 这充分证实了本文所提出的实验方法的有效性。

表 4 所有测试集对标专家标注的云量计算平均绝对差

方法	固定阈值	动态阈值	文献 [16]	FCN	U-Net	+残差	+注意力	本文
对标专家标注(绝对差)	20.53	19.72	9.06	4.65	5.06	4.29	4.42	3.53

3.3.2 典型场景下具体实例云量计算对比分析

为进一步验证本文方法的有效性, 本文将从 300 张测试集中选出云常规分布图像数据、云全天分布图像数据、云受光照干扰图像数据三种典型情况下分析基于云检测模型的云量计算实验结果。云常规分布图像是最常见的云图, 云和边界较为分明; 云全天分布图像数据为阴天全云图像, 容易与雾霾和薄雾混淆; 云受光照干扰图像通常是太阳在云后照射造成视觉盲区, 容易导致误判。图 6—8 和表 5—7 分别给出在不同场景下原图、专家标注、固定阈值、动态阈值、文献 [16]、FCN、U-Net、+残差、+注意力和本文云量计算方法的检测结果和云量计算结果 S (计算方式见式 (8))、像素准确率 PA (计算方式见式 (10))、对标专家标注 (绝对差), 这里我们需要注意, 像素准确率是对每个像素判断模型是否预测正确的准确率, 云量计算结果与真值的差值并非完全相关。

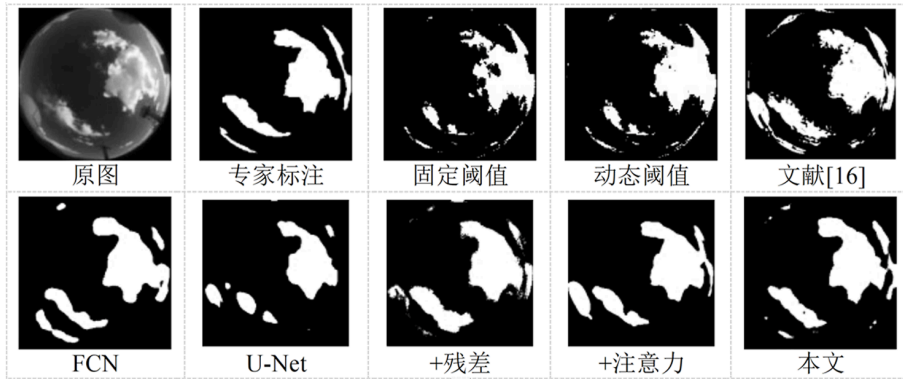


图 6 云常规分布情况下云检测图像结果比对




图 7 云全天分布云情况下检测结果比对

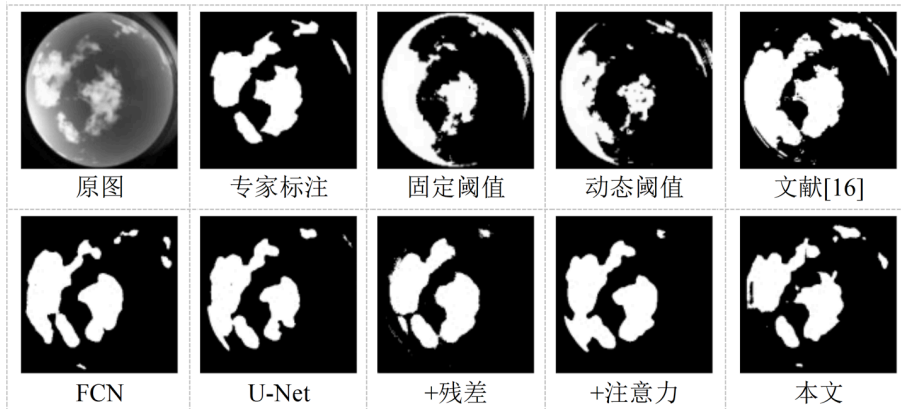


图 8 云受光照干扰情况下云检测结果比对

表 5 云常规分布情况下云量计算结果

方法	专家标注	固定阈值	动态阈值	文献 [16]	FCN	U-Net	+残差	+注意力	本文
云量计算结果 (S)/(%)	22.89	37.78	33.71	29.75	25.34	18.33	26.70	25.84	24.11
对标专家标注 (绝对差)	0	14.89	10.82	6.86	2.45	4.56	3.81	2.95	1.22
像素准确率 (PA)/(%)	100.00	76.90	76.89	90.80	94.07	92.93	93.31	93.38	96.06

表 6 云全天分布情况下云量计算结果

方法	专家标注	固定阈值	动态阈值	文献 [16]	FCN	U-Net	+残差	+注意力	本文
云量计算结果 (S)/(%)	90.44	94.74	86.70	93.63	90.05	91.46	88.08	92.63	89.92
对标专家标注 (绝对差)	0	4.3	3.74	3.19	0.39	1.02	2.36	2.19	0.52
像素准确率 (PA)/(%)	100	84.57	74.32	95.80	98.13	95.65	96.25	94.89	98.01

表 7 云受光照干扰情况下云量计算结果

方法	专家标注	固定阈值	动态阈值	文献 [16]	FCN	U-Net	+残差	+注意力	本文
云量计算结果 (S)/(%)	26.78	54.01	40.56	38.03	28.97	26.08	26.85	27.83	26.53
对标专家标注 (绝对差)	0	27.32	13.78	11.25	2.19	0.7	0.07	1.05	0.25
像素准确率 (PA)/(%)	100	66.26	70.54	89.70	91.39	92.24	94.56	92.82	95.93

图6和表5给出了云常规分布图像数据下各种云检测方法的比对。从中可以看出正常拍摄情况下深度学习方法显然比传统方法好,文献[16]只是简单的三层卷积,对深层语义的提取偏弱;而多层卷积神经和特征融合的神经网络(如FCN和U-Net)都可以较好地还原全天空相机成像的基本特征;但本文方法对全天空相机成像的描述更为细致,所得到的绝对差和像素准确率都是最高。

图7和表6给出了云全天分布图像数据下各种云检测方法的比对。全云遮盖情况下传统方法和深度学习方法差别不是很大。图7原图中用框线标注的1-5为白色建筑物,固定阈值、动态阈值、文献[16]、+注意力将左下方向白色建筑物1误识别成云,而FCN、U-Net、+残差、本文方法都可以识别出来。但FCN方法PA最接近专家标注为98.13%,其真值相差也最小为0.39。本文方法仅次于FCN方法,分别为98.01%、0.52。

在云量图像处理中,太阳在薄云后照射而造成大片盲区的情况较为常见,如何处理这-问题是云检测的重点和难点之一。图8和表7给出了云受光照干扰图像数据下各种云检测方法的比对。从图8中可以看出,在面对太阳光干扰情况下,固定阈值、动态阈值、文献[16]方法的像素准确率大大降低。而具有深层网络结构的神经网络依旧表现出优异的检测结果,虽然+残差方法绝对差最小为0.07,但其PA准确率为94.56%,低于本文方法的95.93%,可能原因是+残差方法将一部分天空背景或者太阳强光认为是云,导致其准确率低反而绝对差较小。

3.4 结论

针对全天空成像的日间云量计算问题,本文提出一种基于深度学习的全天空相机成像日间云量计算模型。该模型采用CFFF特征提取结构,以增强模型的代表学习能力和云检测效果。实验结果显示,本文模型在正常拍摄情况下,云检测模型的PA为0.9917,IOU为0.9836,MIU为0.6557。同时,该模型提出了一种基于云检测模的云量计算方法,云量计算的绝对差为3.53,与原始模型和其他语义分割模型相比,有显著的提升。本文在日间云量计算的研究中虽然取得一些成果,但在夜间由于光照不足,云的边缘和形状不够清晰,难以准确识别和计算。针对此类问题,后续工作将尝试基于已经训练好的日间模型,通过迁移学习技术迁移到夜间学习中。

参考文献:

- [1] 陶法,胡树贞. 气象水文海洋仪器, 2017, 34(04): 1
- [2] Skidmore W, Schock M, Sagnier E, et al. GAT, 2008: 862
- [3] Martinis C, Wilson J, Zablowski P, et al. PASP, 2013, 125(923): 56
- [4] 霍娟,吕达仁. 南京气象学院学报, 2002, 242: 246
- [5] 秦永,付仲良,周凡,等. 武汉大学学报(信息科学版), 2014, 39(02): 234
- [6] 马芳,张强,郭锐,等. 大气科学, 2007, 119: 128
- [7] 陈思成,常建华,刘振兴,等. 中国激光, 2022, 49(11): 154
- [8] 李晓龙,蔡洪波,黎华丽,等. 激光与光电子学进展, 2022, 59(16): 171
- [9] Joshi P P, Wynne R H, Thomas V A. IJAEOG, 2019, 82: 101898

- [10] 高军, 王恺, 田晓宇, 等. 红外与毫米波学报, 2018, 37(04): 477
- [11] 谌雨章, 黄逸姿, 张钧涵. 计算机工程, 2023, 49(6): 257
- [12] 李雪松, 张锬石, 宋呈群, 等. 计算机工程, 2023, 49(5): 1
- [13] 李松江, 耿兰兰, 王鹏. 计算机工程, 2023, 49(4): 272
- [14] 王春东, 孙嘉琪, 杨文军. 计算机工程, 2023, 49(2): 37
- [15] 康晓光, 孙龙祥. 解放军理工大学学报(自然科学版), 2005, 102: 106
- [16] 夏旻, 申茂阳, 王舰锋, 等. 系统仿真学报, 2018, 1623: 1630
- [17] 裴亮, 刘阳, 谭海, 等. 激光与光电子学进展, 2019, 56(05): 226
- [18] Tian J F, Ge L, Wu Y, et al. PASP, 2022, 134(1033): 035002
- [19] He K, Zhang X, Ren S, et al. IEEE, 2016, 770: 778
- [20] Hu J, Shen L, Sun G. IEEE, 2018, 7132: 7141

Research on Daytime Cloudiness Calculation for All-sky Camera Imagery Based on Deep Learning

CHE Lei¹, LI Lei-lei¹, LIU Li-yong²

(1. School of Information Management, Beijing Information Science and Technology University, Beijing 100192, China; 2. National Astronomical Observatories, Chinese Academy of Sciences, Beijing 100101, China)

Abstract: Cloudiness is one of the important evaluation parameters for the site selection of ground-based photoelectric telescopes in astronomical field. The traditional cloudiness calculation method has a large deviation in the accuracy of cloudiness calculation for all-sky camera imagery, which is difficult to meet the actual demand for the accuracy of cloudiness calculation in multiple fields, and there are some limitations in its detection model extraction capability. Aiming at the problems of daytime cloudiness calculation of all-sky camera imaging, a deep learning-based daytime cloudiness calculation model of all-sky camera imaging is proposed. In the cloudiness detection layer, the model constructs a Channel Weighting-Feature Fusion (CWFF) structure to enhance the cloud memory and deep feature extraction capability to accomplish the cloudiness detection task. In the cloudiness calculation layer, the model proposes a cloudiness calculation method based on the cloudiness detection model, which effectively improves the error rate of cloudiness calculation. Experiments show that the combined accuracy of this paper's method in the cloudiness detection task exceeds 95%, and the average absolute error in the cloudiness volume calculation task does not exceed 5%.

Key words: all-sky camera imagery; cloudiness calculation; deep learning; U-Net