

基于区域自由的地基云图云种类识别方法

李逸超¹, 郭 睿¹, 张少迪², 寿泽锋³, 陈 静³, 刘翼飞³

- (1. 国家电网上海市电力公司浦东供电公司,上海 200000;
2. 上海电器科学研究所(集团)有限公司 上海市智能电网需求响应重点实验室,上海 200000;
3. 上海电力大学 自动化学院,上海 200000)

摘 要:准确识别云种类有助于提高预测光伏发电功率精度。针对地基云图云种类识别目标候选框选择复杂、识别速度慢等问题,提出了基于区域自由的地基云图云种类识别方法。首先以 Center Net 为地基云图云种类识别的基本架构,通过热力图预测,关键点预测、中心点预测和候选框预测构建了区域自由的地基云图云种类识别流程。然后,设计了云种类识别模型的主干网络、损失函数和候选框预测方法。最后,以 CenterNet-Resdcn101 为模型,从算法识别精度、候选框预测置信度和识别速度等方面与主流目标识别方法和云种类识别方法进行了分析比较。实验结果表明本文所提方法具有更高的识别精度和更快的识别速度。

关键词:云分类;云种类识别;区域自由;Center Net

DOI:10. 15938/j. jhust. 2023. 02. 015

中图分类号: TP 391. 4 **文献标志码:** A **文章编号:** 1007-2683(2023)02-0128-08

Ground Based Cloud Recognition with an Anchor Free Method

LI Yichao¹, GUO Rui¹, ZHANG Shaodi², SHOU Zefeng³, CHEN Jing³, LIU Yifei³

- (1. State Grid Shanghai Electric Power Company Pudong Power Supply Company, Shanghai 200000, China;
2. Shanghai Key Laboratory of Smart Grid Demand Response, Shanghai Electrical Apparatus Research Institute(Group) Co. Ltd., Shanghai 200000, China;
3. College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: Accurate recognition of cloud type is helpful to improve the forecasting accuracy of photovoltaic power production. In order to solve the problems of cloud type recognition of the ground-based cloud such as complex target candidate box selection and slow detection speed, a recognition method of cloud types in ground-based cloud map based on anchor free is proposed. First, the paper takes Center Net as the basic architecture of cloud type recognition. Based on thermodynamic diagrams prediction, key point prediction, center point prediction and candidate box prediction, a anchor free ground-based cloud type detection process is constructed. And then, the main network, loss function and candidate box prediction method of cloud type recognition model are designed. Finally, take CenterNet-Resdcn101 as the model, compared the algorithm recognition accuracy, candidate boxes predict confidence and identify speed with mainstream target recognition methods and cloud type recognition method. The results showed that the cloud type recognition method of the paper has higher recognition accuracy and faster recognition speed.

Keywords: cloud classification; cloud type recognition; anchor free; center net

收稿日期: 2021-11-10

基金项目: 国网上海电力公司 2021 年营销专项(6409212000ND);国家自然科学基金青年基金(51607111)。

作者简介: 李逸超(1991—),男,硕士;

张少迪(1984—),男,高级工程师。

通信作者: 郭睿(1977—),男,高级工程师,E-mail:Jeanskiller@163.com.

0 引言

随着短期光伏发电功率预测技术的快速发展,功率预测结果的准确性逐渐提高,但如何降低天气条件对光伏发电的影响依然是一个亟需解决的问题。研究表明,光伏发电功率受到两个因素影响:云量和云的种类^[1]。云的种类通过影响光伏组件接收到的直接太阳辐照度,来影响光伏发电功率。不同种类的云具有不同的大小与厚度,云的大小决定了地面上阴影区域的大小,而云的厚度影响阳光的透射能力。当云急剧增多时,光伏发电量会出现明显的下降。极端情况下,5s内下降幅度高达70%。如果没有进行适当的补偿,云层变化会导致电网不稳定。因此,对云进行精确的识别对光伏发电预测具有重要意义。

地基云图主要是针对局部区域内从地面观测到的云层分布、运动和变化情况。地基云图可以更有效地判断云的种类、高度等信息,并且更加有效地辅助局部区域内的天气预测,如图1所示。实际地基云图像与这些普通场景的图像存在较大的区别:①其呈现出一定的特征差异,这导致很难找到一种特征区分各类云状;②天空出现多种不同类型的云状,基于图像分割的识别方法无法精确地对其分类。

传统的云识别方法一般通过不同的特征提取方式结合颜色、纹理和结构等特征,然后使用KNN分类器(k-nearest neighbor)和支持向量机(SVM)等分类器进行识别^[2]。然而这些方法需要消耗大量人力进行特征提取,而且只能识别单一类型的云。对于地基云图像的特征提取,所提取的图像特征表达能力和判别能力越强,则分类识别的效果越好。这大大增加了特征提取的要求和难度。针对传统云识别方法的不足之处,各种智能算法被大量应用于云图分类^[3-6]。

近年来随着人工智能的快速发展,深度学习在图像识别领域取得了成功,深度学习方法能够从图像数据中自动的提取特征^[7-11],因此不需要任何特征提取方法。Shi等^[12]使用深度卷积激活的云图像的特征进行地基云识别,实验结果超过了大部分传统方法。这类基于区域候选的云识别方法都是基于图像分类方法,其需要先对地基云图区域云分割并生成候选框,然后采用候选框的图像块进行云识别。Girshick^[13]提出了一种区域候选的Fast R-CNN算法,进行联合学习分类目标对象和细化对象

空间位置,并将特征提取、边界框分类和回归的功能合并成一个整体。由于地基云图中的云目标分布不均匀、方向任意,这将导致在云分割候选框的选择将对识别结果的干扰^[2]。

进一步,目前的地基云图像云状识别算法所针对的基本都是一幅图像中只存在一种云状或完全无云的情况,在实际观测中,天空往往会同时存在多种不同类型的云,且各云状的区域形状、大小均存在不确定性,多种云之间的分界十分模糊不易区分。目前的地基云图像识别算法所针对的基本都是一种云类型或完全无云的情况,在使用地基云图实验测试时效果要差很多^[14]。

综上所述,针对地基云图云种类识别区域候选预测问题,本文首次引入一种区域自由的地基云图云种类识别方法。该方法以Center Net^[15]为基础框架,以地基云图中不同的云目标中心点为基础进行构建识别模型,通过热力图、关键点、中心点和尺度预测候选框,实现了区域自由的地基云图云种类目标识别。进一步,当地基云图多种类云共存时,通过本文方法可以自动提取图像中的多个区域特征,从而实现对地基云图多个云种类单次识别。

1 地基云图

地基云图主要是针对局部区域内从地面观测到的云层分布、运动和变化情况。地基云图可以更有效地判断云的种类、高度等信息,并且更加有效地辅助局部区域内的天气预测,如图1所示。实际地基云图像与这些普通场景的图像存在较大的区别:(1)其呈现出一定的特征差异,这导致很难找到一种特征区分各类云状。(2)天空出现多种不同类型的云状,基于图像分割的识别方法无法精确地对其分类。




图1 地基云图和传统云图

Fig. 1 The foundation cloud and traditional cloud

2 云种类识别

云种类的不同会对光伏发电产生不同情况和不同程度的影响。随着云分类研究领域的热门,云分类具有多种标准。传统上,根据云的高度不同,云可以分为不同类别^[16],如图2所示。




图2 不同种类的地基云图

Fig. 2 Different kinds of cloud images

3 基于区域自由的云种类识别模型

针对地基云图云种类识别问题,本文以 Center Net 作为基于区域自由的云状识别的网络框架,根据云的图像特征,对该框架下的 Resdcn Net 训练模型进行测试,识别出云的种类。

基于区域自由的云种类识别分为3个阶段:
①热力图生成:通过卷积网络得到图片的热力图,再将关键点通过高斯核函数计算对应到热力图上;
②关键点计算:根据热力图上的值选出100个大于或等于周围8个相邻值的点作为初步预测的中心关键点,对每个关键点都进行8个类别的置信度计算,以及关键点偏移的预测和候选框的长宽确定;
③预测输出:根据置信度选择最终的预测结果。

3.1 基于区域自由的云种类识别流程

在云种类识别流程中,待识别的云状类别数为 c ,首先通过以 Resdcn Net 为主干的特征提取网络获得初步特征信息进行预测,预测结果分为3部分:热力图预测,关键点预测和中心点预测。在热力图的预测中,获得每一个热力点目标是否存在以及目标的类别和概率信息。在中心点预测中,输出每一个目标中心与热力点距离的偏移情况。在尺度的预测中,输出每一个目标宽高的预测情况。结合预测结果的3部分,进一步识别地基云图的中心点以及基于中心点生成候选框。

最后,在正向推理过程中,选出关键点热图中的峰值,每个类别的 n 个关键点的集合 $\hat{P} = \{(\hat{x}_i, \hat{y}_i)\}_{i=1}^n$ 。将关键点坐标处的预测值 $\hat{Y}_{xyz}$ 作为识别的准确度。图3给出基于区域自由的云种类识别流程。图4给出了地基云图热力图、关键点和尺度的预测结果。




图3 基于区域自由的云种类识别流程

Fig. 3 Cloud types detection process based on Anchor-free




图4 云种类识别输出结果

Fig. 4 Result of Cloud types detection

3.2 云种类识别模型设计

本文以 Centernet 为基线模型,具体主干网络热力图生成、关键点预测、中心点预测、损失函数和候选框预测设计如下:

3.2.1 主干网络热力图生成

本文使用 Resdcn Net 作为目标识别的主干网络来生成热力图,用以提取特征。本文所采用的 Resdcn Net 在 Xiao 等^[17]的基础上添加了3个由可变形卷积 DCNv2^[18]形成的网络,简单的说首先使用可变形卷积来改变通道,然后采用反卷积对特征图进行上采样。Resdcn Net 网络结构如图5所示。




图5 主干网络结构

Fig. 5 Backbone network structure

3.2.2 关键点预测

在生成热力图的过程中,首先输入云图的特征向量为 $I \in \mathbb{R}^{(W \times H \times 3)}$ 。其中 R 、 H 、 W 分别为下采样因子、图片长和宽。分别计算每个类别 (C) 云图的 Ground truth 中的真实关键点 p 对应的下采样关键点 $\tilde{p}$ 。其中下采样的计算公式为

$$\tilde{p} = \left\lfloor \frac{p}{R} \right\rfloor \quad (1)$$

将所有下采样关键点以 $Y \in [0, 1]^{\frac{W}{R} \times \frac{H}{R} \times C}$ 的形式输入给高斯核函数计算得到关键点的热力图为 $\hat{Y} \in [0, 1]^{\frac{W}{R} \times \frac{H}{R} \times C}$ 。高斯核函数公式为

$$Y_{xyz} = \exp \left(-\frac{(x - \tilde{p}_x)^2 + (y - \tilde{p}_y)^2}{2\sigma_p^2} \right) \quad (2)$$

式中: σ_p 为目标大小是否自适应相关的标准差。当同一类别的两个高斯函数重合时,取像素的最大值。本文采用下采样因子 $R=4$ 、 $C=8$ 用于 8 类云的识别。当预测的热力图 $\hat{Y}_{xyz} = 0$ 时,识别结果为背景;热力图 $\hat{Y}_{x,y,z} = 1$ 时,识别结果为云图的关键点。

关键点预测采用修正的 Focal 损失函数^[19]。解决正负样本分布不均的问题。关键点损失函数公式为

$$L_k = \frac{-1}{N} \sum_{xyz} \begin{cases} (1 - \hat{Y}_{xyz})^\alpha \log(\hat{Y}_{xyz}) & Y_{xyz} = 1 \\ (1 - \hat{Y}_{xyz})^\beta (\hat{Y}_{xyz})^\alpha \log(1 - \hat{Y}_{xyz}) & \text{其他} \end{cases} \quad (3)$$

式中: α, β 为 Focal loss 的超参数; N 为云图 I 中关键点的个数; $\hat{Y}_{xyz}$ 为预测值; Y_{xyz} 为负样本。本文将超参数设置为 $\alpha=2, \beta=4$ 。

为了消除下采样带来的误差,需要预测每个关键点的偏移量 $\hat{O} \in \mathbb{R}^{\frac{W}{R} \times \frac{H}{R} \times 2}$ 。每种云种类采用相同的偏离量预测,偏移损失函数为

$$L_{\text{off}} = \frac{1}{N} \sum_p \left| \hat{O}_p - \left(\frac{p}{R} - \tilde{p} \right) \right| \quad (4)$$

3.2.3 中心点预测

选取类别为 C_k 目标 k 的边界框坐标为 $(x_1^{(k)}, y_1^{(k)}, x_2^{(k)}, y_2^{(k)})$, 根据关键点预测出所有中心点,其中心点 $p_k = (\frac{x_1^{(k)} + x_2^{(k)}}{2}, \frac{y_1^{(k)} + y_2^{(k)}}{2})$ 。在训练开始前回归出每个目标 k 的尺度 $s_k = (x_2^{(k)} - x_1^{(k)}, y_2^{(k)} - y_1^{(k)})$, 同时为了减少计算量,每类云采用同一个尺度预测 $\hat{S} \in \mathbb{R}^{\frac{W}{R} \times \frac{H}{R} \times 2}$, 尺度损失函数为

$$L_{\text{size}} = \frac{1}{N} \sum_{k=1}^N |\hat{S}_{p_k} - s_k| \quad (5)$$

3.2.4 候选框预测

在候选框预测过程中,首先单独提取每个类别的热力图的峰值,与其连接的 8 个临近点进行比较,选出 100 个大于或等于这 8 个临近点的值作为初步预测的关键点。令类别 c 的 n 个关键点的集合为 $\hat{P} = \{(\hat{x}_i, \hat{y}_i)\}_{i=1}^n$, 其中 (x_i, y_i) 表示每个关键点的位置坐标。用关键点的 $\hat{Y}_{x,y,c}$ 表示预测的置信度在指定位置生成候选框,候选框的坐标为

$$\begin{aligned} &(\hat{x}_i + \delta\hat{x}_i - \hat{w}_i/2, \hat{y}_i + \delta\hat{y}_i - \hat{h}_i/2, \\ &\hat{x}_i + \delta\hat{x}_i + \hat{w}_i/2, \hat{y}_i + \delta\hat{y}_i + \hat{h}_i/2) \end{aligned} \quad (6)$$

其中 $\hat{O}_{\hat{x}_i, \hat{y}_i} = (\delta\hat{x}_i, \delta\hat{y}_i)$ 为偏移预测, $\hat{S}_{\hat{x}_i, \hat{y}_i} = (\hat{w}_i, \hat{h}_i)$ 为尺度预测。

3.2.5 损失函数设计

本文借鉴 CenterNet 中原有的损失函数,面向地基云图云状识别任务,构建 CenterNet 基线模型。整个训练的损失函数为 $L_{\text{det}} = L_k + \lambda_{\text{size}} L_{\text{size}} + \lambda_{\text{off}} L_{\text{off}}$ 。本文采用 $\lambda_{\text{size}} = 0.1, \lambda_{\text{off}} = 1$, 分别 L_k 、 L_{size} 和 L_{off} 分别为关键点损失函数,偏移量损失函数和尺度损失函数。

4 仿真实验与结果分析

4.1 实验数据集与方法实现

1) 云图采集:数据集中云的图像采集于上海电力大学杨浦校区微网楼楼顶。相机获取了 2019 年 4 月至 2020 年 1 月的图像。这些照片呈现了一天中的不同时间云图。本文所有图像采用海康威视 DS-2CD3955FWD-IWS 海康 500 万鱼眼全景网络摄像机进行拍摄,1 分钟采集一次图像并保存为 .jpg 格式,分辨率为 1 280 × 960 像素。

2) 数据集制作:本文从拍摄的云图中选取天气状况较好的图片共 4 000 张,每张图片包含一种或多种云,并将识别类型设置为 8 种。数据集具体样本信息如表 1 所示。

3) 模拟环境及训练参数设置:该培训平台为一台配备 Windows10 系统台式电脑,配置显卡为 GeForce RTX 2080Ti,内存为 16GB,使用的软件工具包括 CUDA 10.0.130 和 Python3.6。

表 1 8 种云样本数量统计

Tab. 1 Eight kinds of cloud sample number statistics

	训练集	验证集	测试集
高积云	386	53	61
高层云	392	47	60
卷积云	571	69	54
卷层云	394	63	43
卷云	474	67	57
积雨云	407	43	50
积云	1 485	152	191
层积云	406	49	45

4.2 主流算法对比实验

为了验证本文所提算法的性能,本文进行仿真实验。分别从识别精度、候选框预测置信度和识别速度 3 个方面将本文方法与其他主流目标识别算法和云种类识别算法进行了仿真结果的对比分析,其中用 CenterNet-Resdcn101 代表本文的主干网络,所用神经网络框架为 Pytorch。

4.2.1 识别精度分析

为了分析本文所提算法的识别精度,在本文数据集上使用 Faster R - CNN 以及云种类识别算法 CloudNet^[20]进行对比实验,分别比较各云种类所对应的召回率(Recall)和 F1 值,如表 3 所示。

从表 2 可知,针对表中的 8 个不同云种类进行识别,由于层积云特征不明显识别较难,层积云在 4 种网络下的召回率和 F1 值均低与平均水平,本文方法针对此种云状的召回率和 F1 值可以达到 0.86 和 0.85,效果略优于另外几种云识别网络。对于其他类云状,本文方法召回率均在 0.90 以上,F1 值均在 0.94 以上。

4.2.2 候选框预测分析

图 6 给出了本文提出的 CenterNet-Resdcn101 和 Fast-R-CNN 方法在典型情况下候选框预测的置信度水平。从图中可知,CenterNet-Resdcn101 候选框的置信度水平明显高于 Fast-R-CNN 方法。并且,CenterNet-Resdcn101 去除了大量错误的候选框如图 6(h)、(i)、(j)所示。因此,基于区域自由的云种类识别方法能够更好的预测出候选框,从而保证了云种类识别的准确度。

4.2.3 识别速度分析

为了分析本文所提算法的识别速度,本文使用 Res101 网络对 Faster R-CNN 进行训练,与本文 Cen-

terNet-Resdcn101 云种类识别方法的速度进行对比分析,分析结果如表 2 所示。与 Faster R-CNN 方法相比,本文方法对于 8 个云种类的识别速度明显更高,Faster R-CNN 对于每张图片的识别时间均在 0.3 s 以上,而本文方法的识别速度几乎均在 0.12 s 左右。




图 6 候选框置信度比较分析(左为 Center Net 识别结果,右为 Faster R-CNN 识别结果)

Fig. 6 Comparative analysis of confidence of candidate box(Center Net identification results on the left and Faster R-CNN identification results on the right)

表 2 不同方法的识别速度
Tab. 2 Recognition speed of different methods

云种类	Faster R-CNN/s	CenterNet-Resdcn101/s
高积云	0.341	0.120
高层云	0.342	0.119
卷积云	0.350	0.121
卷层云	0.350	0.131
卷云	0.350	0.123
积雨云	0.339	0.219
积云	0.337	0.117
层积云	0.350	0.117

表 3 4 种模型下的召回率和 F1 值 单位:%
Tab. 3 Recall rates and F1 values of models

云种类	CenterNet- Resdcn101		Faster R-CNN		CloudNet		Yolov3	
	召回率	F1	召回率	F1	召回率	F1	召回率	F1
高积云	0.96	0.98	0.88	0.85	0.98	0.98	0.97	0.97
高层云	0.98	0.99	0.82	0.76	0.99	0.99	0.98	0.99
卷积云	0.97	0.97	0.95	0.94	0.99	0.99	0.83	0.79
卷层云	0.98	0.99	0.95	0.93	0.98	0.98	0.98	0.99
卷云	0.91	0.95	0.96	0.98	0.99	0.99	0.94	0.96
积雨云	0.92	0.94	0.99	0.99	0.99	0.99	0.91	0.95
积云	0.90	0.95	0.85	0.91	0.92	0.96	0.76	0.82
层积云	0.86	0.85	0.80	0.76	0.62	0.77	0.85	0.79

4.3 算法有效性分析

为了验证本文所提方法有效性,本文从中心点预测和多种云种类共存的情景分析了本文算法的有效性。

4.3.1 中心点预测分析

传统的方法根据云的颜色、形状和纹理不同对云进行识别存在以下问题:一张图像的光谱特征并不能提供任何关于云的空间分布的信息;仅仅使用颜色不足以区分一些云的类型,如高积云和层积云;层状云可以形成积雨云,它们会显示相同的特征从而难以区分。针对上述问题,本文采用的目标识别方法依然可以准确的识别出每幅云图的云的种类,判断其云的位置和中心点位置,如图 6 和图 7 所示,并计算出相应的置信度,最高置信度达到 0.973。




图 7 各类云中心点位置

Fig. 7 The center positions of various cloud

4.3.2 多种云共存的云种类识别

在实际地基云图的云种类识别中存在多个云种类共存于一张云图的情景。因此,本文在输入云图片包含多个云种类的情景下与 Faster R-CNN 算法进

行了比较分析。图 8(a)为本文方法单次识别并标记出的积云和卷层云两种云状及对应置信度,图 8(b)、(c)为 Faster R-CNN 的分次识别结果和对应置信度。结果表明对于存在多种云种类的情况,Faster R-CNN 只能对地基云图中的云种类进行分次识别识别并且较容易会出现如图 8 候选框位置偏差较大且置信度较低的情况,处理速度相对较差,而本文所提方法能够同时快速识别识别出地基云图中的多种云类型。




图 8 多种云类型识别比较

Fig. 8 comparison of multiple cloud types identification

4.4 算法主干网络分析

为了验证本文所提方法主干网络结构的影响,本文从识别精度和收敛速度两个方面分析了主干网络的影响。

4.4.1 识别精度分析

为了分析各种网络结构对本文所提方法的影响,本文分析了分别采用 Hourglass、Resdcn18 和 Resdcn101 网络模型的训练效果。其中训练回合为 300,选取不同的学习率进行训练,并统一各模型的学习率,选取不同的 Batch-size 进行训练,并统一各模型的 Batch-size。

本文采用平均精度 AP 作为云种类识别精度的评价指标对测试集进行测试。对于不同网络结构的

不同 IoU 的测试结果如表 4 所示,Resdcn101 的平均精度 AP 均高于平均水平。

表 4 不同网络的平均精度

Tab. 4 Average accuracy of different networks			
	AP	$AP50$	$AP75$
Hourglass	0.914	0.969	0.923
Resdcn101	0.920	0.973	0.927
Resdcn18	0.916	0.972	0.933

针对选取的 8 类云状,本文 CenterNet 框架下分别使用 3 种不同的网络结构云进行识别,识别结果做置信度分析,单类云识别的置信度如表 5 所示。在对卷积云、卷云、积雨云、积云和层积云识别时,Resdcn101 网络结构置信度最高;在对高积云识别时,Hourglas 网络结构的置信度最高;对卷层云识别时,Resdcn18 网络结构的置信度最高。结果表明 Resdcn18 网络对大部分云种类的识别置信度高于其他网络。

表 5 不同网络的置信度

Tab. 5 The confidence of different networks			
	Hourglass	Resdcn101	Resdcn18
高积云	0.934	0.918	0.893
高层云	0.879	0.909	0.920
卷积云	0.856	0.946	0.871
卷层云	0.867	0.893	0.914
卷云	0.930	0.969	0.894
积雨云	0.800	0.966	0.925
积云	0.964	0.967	0.965
层积云	0.815	0.921	0.896

4.4.2 收敛速度分析

为了分析本文方法收敛特性,本文就使用不同的网络模型对数据集进行训练,不同网络结构的训练集损失和验证集损失如图 9 所示。





图 9 不同网络损失曲线

Fig. 9 The loss of different networks

由图 9 可知,本文所提的模型在 100 次开始收敛,收敛速度较快。可以看到,本文模型在训练数据集上收敛速度最快且效果最好,并有继续收敛的趋势,说明本文模型能够有效收敛,较好处理云种类识别问题。

5 结 论

针对地基云图目标候选框预测问题,本文引入了区域自由的云种类识别方法。该技术通过对地基云图的热力图进行分析,获取地基云图的关键点,根据云图的关键点进行中心点预测、偏移预测和尺度预测,从而获得更准确的目标候选框。实验结果表明,基于区域的目标识别方法相比,本文采用的基于区域自由的云种类识别方法具有较好的精度和置信度以及更快的识别速度,可以推广在气象研究方面使用。进一步,对于多个类型云共存的情况,本文方法依然可以实现对每一类云的准确识别,这也更便于云种类识别在天气预测和光伏预测等方面应用。

参 考 文 献:

[1] KAZANTZIDIS A, TZOUMANIKKAS P, BAIS A. F, et al. Cloud Detection and Classification with the Use of Whole-sky Ground-based Images [J]. Atmospheric Research, 2012;80.

[2] XIAO Y, CAO Z, ZHUO W, et al. mCLOUD: A Multi-view Visual Feature Extraction Mechanism for Ground-based Cloud Image Categorization [J]. Journal of Atmospheric & Oceanic Technology, 2015, 33 (4):151209140713007.

[3] TANG J, LV Z, ZhANG Y, et al. An Improved Cloud

- Recognition and Classification Method for Photovoltaic Power Prediction Based on Total-sky-images [J]. The Journal of Engineering, 2019, 2019(18): 4922.
- [4] YE L, CAO Z, XIAO Y. DeepCloud: Ground-based Cloud Image Categorization Using Deep Convolutional Features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(10): 5729.
- [5] 张敏靖,白琮,张敬林等. 基于对抗和迁移学习的灾害天气卫星云图分类[J]. 北京航空航天大学学报, 2021, 47(3): 585.
- ZHANG Minjing, BAI Cong, ZHANG Jinglin, et al. Classification of Satellite Cloud Images of Disaster Weather Based on Adversarial and Transfer Learning[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(3): 585.
- [6] 段向军,王敏. 迁移深度学习地基云图自动识别的网络微调学习过程[J]. 电子器件, 2020, 43(6): 1257.
- DUAN Xiangjun, WANG Min. An Ground Cloud Image Recognition Method Using AlexNet Convolution Neural Network[J]. Chinese Journal of Electron Devices, 2020, 43(6): 1257.
- [7] SHANG L, YANG Q, WANG J, et al. Detection of Rail Surface Defects Based on CNN Image Recognition and Classification[C]//2018 20th International Conference on Advanced Communication Technology (ICACT). IEEE, 2018: 45.
- [8] TRAORE B B, KAMSU-Foguem B, TANGARA F. Deep Convolution Neural Network for Image Recognition[J]. Ecological Informatics, 2018, 48: 257.
- [9] 李晓峰,李东,王妍玮. 基于全卷积神经网络的医疗图像弱边缘识别算法[J]. 哈尔滨理工大学学报, 2021, 26(3): 65.
- LI Xiaofeng, LI Dong, WANG Yanwei. Weak Edge Detection Algorithm for Medical Images Based on Full Convolution Neural Network[J]. Journal of Harbin University of Science and Technology, 2021, 26(3): 65.
- [10] 晏铭,朱良宽,景维鹏. 融合贝叶斯的压缩 CNN 植物叶片识别模型[J]. 哈尔滨理工大学学报, 2021, 26(3): 83.
- YAN Ming, ZHU Liangkuan, JING Weipeng. Compressed CNN Plant Leaf REcognition Model Fused with Bayesian[J]. Journal of Harbin University of Science and Technology, 2021, 26(3): 83.
- [11] 刘九庆,项前,王宇航. 基于 SIFT 算法和改进的 RANSAC 算法对森林火灾的图像识别与试验研究[J]. 森林工程, 2022, 38(6): 96.
- LIU Jiuqing, XIANG Qian, WANG Yuhang. Image Recognition and Experimental Research on Forest Fire Based on SIFT Algorithm and Improved RANSAC Algorithm[J]. Forest Engineering, 2022, 38(2): 96.
- [12] SHI C, WANG C, WANG Y, et al. Deep Convolutional Activations-Based Features for Ground-Based Cloud Classification[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(6): 816.
- [13] GIRSHICK R. Fast R-CNN [C]//Proceedings of the IEEE International Conference on Computer Vision, Santiago, December 7 - 13, 2015: 1440.
- [14] 庄志豪,王敏,王康,等. 基于深度学习的地基云分类技术研究进展[J]. 南京信息工程大学学报(自然科学版): 2022, 14(5): 566.
- ZHUANG Zhihao, WANG Min, WANG Kang, et al. Research Progress of Deep Learning-based Cloud Classification Technology[J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition): 2022, 14(5): 566.
- [15] 叶亮. 地基云图像的云状识别技术研究[D]. 武汉:华中科技大学, 2019.
- [16] JING C, CHENGGANG C, Nan Y, et al. Region-Free Cloud Recognition Based on Center Net [C]//2020 5th International Conference on Power and Renewable Energy (ICPRE). IEEE, 2020: 553.
- [17] XIAO Bin, WU Haiping, WEI Yichen. Simple Baselines for Human Pose Estimation and Tracking [C]// ECCV. Springer, Cham, 2018: 466.
- [18] ZHU Xizhou, HU Han, LIN Stephen, et al. Deformable ConvNets v2: More Deformable, Better Results[J]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9308.
- [19] LIN Tsung-Yi, GOYAL Priya, GIRSHICK Ross, et al. Focal Loss for Dense Object Detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017 (99): 2999.
- [20] ZHANG J. L, LIU P, ZHANG F, SONG Q. Q. Song. CloudNet: Ground-based Cloud Classification with Deep Convolutional Neural Network [J]. Geophysical Research Letters, 2018, 45: 8665.

(编辑:温泽宇)