

张雪,贾克斌,刘钧,等,2023. 基于多任务学习的地基云图识别与分割技术[J]. 气象,49(4):454-466. Zhang X, Jia K B, Liu J, et al, 2023. Ground cloud image recognition and segmentation technology based on multi-task learning[J]. Meteor Mon, 49(4): 454-466(in Chinese).

## 基于多任务学习的地基云图识别与分割技术\*

张 雪<sup>1,2</sup> 贾克斌<sup>1,2</sup> 刘 钧<sup>3</sup> 张 亮<sup>1</sup>

1 北京工业大学信息与通信工程学院, 北京 100124

2 先进信息网络北京实验室, 北京 100124

3 华云升达气象科技有限公司, 北京 102299

**提 要:** 云在天气预报中扮演着一个至关重要的角色, 准确识别和分割地基云图可以有效指导天气预报。针对大部分现有数据集只适用于单任务学习, 地基云图识别和分割技术多以单任务实现, 识别检测效率低且算法鲁棒性差等问题, 构建了带标签且适合多任务学习的地基云图数据集(GBCD)和 GT 数据集(GBCD-GT), 在此基础上设计了一种基于多任务学习的地基云图识别与分割联合网络模型(GCRSegNet)。该模型首先通过卷积神经网络提取共享特征, 再为每个任务设计特定网络, 提取更具辨识度的特征, 分割网络通过学习共享特征实现地基云图分割, 识别网络通过结合共享特征和分割特征实现地基云图识别。经过多组对比试验表明, 该网络能准确表征地基云图特征, 使识别任务准确率达到 94.28%, 分割任务像素准确率达到 93.85%, 平均交并比达到 71.58%, 为实际应用提供了可能性。

**关键词:** 地基云图, 图像识别, 图像分割, 多任务学习

**中图分类号:** P412, TP308

**文献标志码:** A

**DOI:** 10.7519/j.issn.1000-0526.2022.081901

## Ground Cloud Image Recognition and Segmentation Technology Based on Multi-Task Learning

ZHANG Xue<sup>1,2</sup> JIA Kebin<sup>1,2</sup> LIU Jun<sup>3</sup> ZHANG Liang<sup>1</sup>

1 School of Information and Communication Engineering, Beijing University of Technology, Beijing 100124

2 Beijing Laboratory of Advanced Information Network, Beijing 100124

3 Huayun Shengda Meteorological Technology Co., Ltd., Beijing 102299

**Abstract:** Clouds play an important role in weather forecasting. Accurate identification and segmentation of ground-based cloud images can effectively guide weather forecasting. Now most of the existing datasets are only suitable for single task learning, and ground-based cloud image recognition and segmentation technologies are mostly implemented by single task, thus identification and detection efficiency are low and the robustness of the algorithm is poor. Considering these problems, we construct the ground-based cloud image datasets GBCD and GBCD-GT with labels and suitable for multi-task learning, and then on this basis, a ground-based cloud image recognition and segmentation joint network model GCRSegNet based on multi-task learning is designed. The model firstly extracts shared features through convolutional neural network, then a special network is designed for each task to extract more recognizable features. The segmentation network learns shared features to achieve ground-based cloud image segmentation, and the recognition network combines sharing features and segmentation features to achieve ground-based cloud image

\* 国家重点研发计划(2018YFF01010100)、北京市自然科学基金项目(4212001)共同资助

2021 年 12 月 16 日收稿; 2022 年 9 月 28 日收修定稿

第一作者: 张雪, 主要从事图像信息处理研究. E-mail: zhangxuezm@163.com

通讯作者: 贾克斌, 主要从事图像/视频信号与信息处理、生物医学信息处理研究. E-mail: kebinj@bjut.edu.cn

recognition. Multiple groups of comparative experiments indicate that the network in this paper can accurately represent the features of ground-based cloud image. Meanwhile, the accuracy of the recognition task can reach 94.28%, the pixel accuracy of segmentation task can reach 93.85%, and mean intersection over union reach 71.58%. These results can provide a possibility for practical application.

**Key words:** ground-based cloud image, image recognition, image segmentation, multi-task learning

## 引言

云作为降水的基础(王烁等, 2021; 程鹏等, 2022), 其形状及数量变化对天气预报有极其重要的指导作用(许健民, 2021), 所以准确观测云对降水预测(岳治国等, 2021; 桂海林等, 2019; 万夫敬和刁秀广, 2018)、天气预报、军事和社会保障等方面具有重要意义。目前, 云的观测方法有卫星遥感云观测和地基云观测, 地基云观测由地面向天空集中观测局部区域内云的分布和变化情况, 观测到的地基云图有较高的时空分辨率, 刻画了云体形状、结构和纹理等方面较多的细节信息, 为提升天气预报的准确性(智协飞等, 2021; 黄兴友等, 2020; 胡树贞等, 2020)提供了帮助。

云状和云量是地基云观测中的两个基本要素, 近几年, 大部分地基云观测方法还是人工观测, 由观测员根据自己的经验判断地基云图的云状和云量, 但观测员易受主观意识和情绪干扰, 使观测结果缺乏不确定性。为了解决上述问题, 地基云图自动观测方法随之发展起来, 而准确识别和分割地基云图是实现自动观测的关键点。目前, 地基云图识别和分割技术取得了一定的研究进展。在地基云图识别方面, Zhang et al(2018)提出基于深度卷积神经网络的地基云分类网络(ground-based cloud classification with deep convolutional neural network, CloudNet), 实现 11 类地基云图的分类, 但分类准确率还有待提高; 段向军和王敏(2020)利用迁移学习识别 11 类地基云图, 通过试验发现地基云图识别效果不均衡; 贾克斌等(2021)提出轻量化地基云分类网络(light-weight ground-based cloud image classification network, LCCNet), 提高了 11 类地基云图的分类准确率, 但存在地基云图混淆的情况。在地基云图分割技术方面, 毋立芳等(2018)提出一种基于超像素分析的全卷积网络-卷积神经网络(fully convolutional

networks-convolutional neural networks, FCN-CNN), 将每个像素点的聚类输入 FCN-CNN 网络, 实现准确的地基云图分割; 沈慧想等(2019)提出一种对称式密集连接卷积神经网络模型, 提高了地基云图分割精度, 但模型参数量太大, 容易发生过拟合; Dev et al(2019)提出一种昼夜云图分割网络(deep network for nychthemeron cloud image segmentation, CloudSegNet), 准确分割地基云图, 但用于模型研究的数据量少且没有考虑太阳光干扰, 导致网络对晴空下地基云图分割效果不好。

虽然现有地基云图识别和分割技术已经取得不错效果, 但这些技术或单独用于地基云图识别, 或单独用于地基云图分割, 对此本文提出一种地基云图识别与分割联合网络模型(joint network model of ground-based cloud image recognition and segmentation, GCRSegNet), 该模型利用识别与分割两个任务之间特征的相关性, 促进地基云图识别与分割泛化性能的提升, 相比单任务学习, 本文方法在一个网络中实现地基云图识别和分割两个任务, 并获得了 94.28% 的识别准确率和 93.85% 的分割准确率。

## 1 地基云图数据集 GBCD 和 GBCD-GT

### 1.1 初始标准地基云图数据集构建

本文数据来自全天空成像仪(total sky imager, TSI)每日在 06—18 时(北京时, 下同)采集的包含一种云或大部分云体属于一种类别的地基云图, 并利用 Zhang(2000)相机标定法处理采集的地基云图, 使其恢复正常的视觉感观。根据《地面气象观测规范》(中国气象局, 2003), 将预处理后的地基云图分为 10 种云类, 为保证后续试验的完整性, 增加一种无云天空作为第 11 类地基云图, 分类流程如图 1 所示。




图 1 初始标准地基云图数据集构建方法

(a) 建立标签模型的流程, (b) 标签模型的使用

Fig. 1 Construction method of initial standard ground cloud image dataset

(a) process of establishing label model, (b) use of label model

构建标准地基云图数据集的流程如图 1a 所示。首先在专业气象观测人员的指导下人工标注地基云图, 形成包含 11 类地基云图且具有一定专业性的原始数据集。为弥补人工标注中存在的错误分类, 借助视觉几何组 (visual geometry group network, VGG16) (Simonyan and Zisserman, 2014)、深度残差神经网络 (deep residual network, ResNet-152) (He et al, 2016)、稠密卷积网络 (dense convolutional network, DensNet-201) (Huang et al, 2017) 和 LCCNet 网络作为迁移学习模型辅助地基云图分类, 分别在不同解冻层数下的五种迁移学习模型中训练原始数据集, 表 1 展示了每个模型的最优准确率及其对应的解冻层数。对比表中结果发现, LCCNet 在解冻 2 层时准确率优于其他模型; 最后利用 LCCNet 辅助数据集二次分类, 得到初始标准地基云图数据集。

表 1 原始数据集下模型最优迁移学习效果对比

Table 1 Comparison of model optimal transfer learning effect under original dataset

| 网络模型         | 解冻层数/层 | 准确率/% |
|--------------|--------|-------|
| VGG16        | 3      | 86.50 |
| ResNet-152   | 2      | 87.10 |
| DenseNet-201 | 2      | 92.96 |
| LCCNet       | 2      | 93.52 |

利用 LCCNet 模型辅助分类的流程如图 1b 所示, 只需对比地基云图的实际标签与网络输出标签, 当且仅当 LCCNet 预测图片的置信度大于 0.9 则认为图片分类正确, 否则需要重新确认标签。在初始数据集上不断重复上述步骤, 当且仅当被 LCCNet 分类正确的地基云图数量占总地基云图数量的 95% 以上, 认为二次分类的地基云图数据具有专业参考性, 进而形成初始标准地基云图数据集。

## 1.2 标准 GT 数据集构建

基于原始标准地基云图数据集分割地基云图,并将分类标签一致的 GT 图归为同类,获得带分类标签的 GT 数据集,构建流程如图 2 所示。

为准确分割地基云图,需要预训练分割模型(Convolutional Networks for Biomedical Image Segmentation, UNet),流程如图 2a 所示。将开源的地基云图分割数据集 Singapore Whole sky Imaging SEGmentation Database(Dev et al, 2017a),

Singapore Whole sky Nighttime Imaging SEGmentation Database(Dev et al, 2017b)中的数据,通过翻转和固定角度旋转扩增到 6768 张,并作为 UNet 网络的训练数据。

由于初始标准地基云图数据集中大量白天地基云图包含强烈太阳光,严重影响 GT 数据集构建。经对比分析,发现太阳光的亮度高于云体亮度,如图 3a 所示,因此利用如图 2b 所示的流程,构建正确的 GT 图。首先经过 UNet 网络获得地基云图的 0/1 图像矩阵,同时经过阈值分割地基云图,将大于阈值




图2 标准 GT 数据集构建方法

(a) 预训练模型, (b) 图像分割与太阳光去除

Fig. 2 Construction method of standard GT dataset

(a) pre-training model, (b) image segmentation and sunlight removal




图3 GT 数据集效果图

(a) 原图, (b) UNet 分割图, (c) 太阳强光, (d) 本文分割图

Fig. 3 Effect diagram of GT dataset

(a) original image, (b) segmentation image of UNet, (c) the sun glare, (d) segmentation image of this paper

的部分判为太阳光,小于阈值的部分判为非太阳光,如图 3c 所示;最后将图像矩阵和阈值分割结果相与,得到去除太阳光的分割图,效果如图 3d 所示。为提高数据集置信度,人工逐张校准标注 GT 图,最后形成标准带标签的 GT 地基云图数据集。

### 1.3 数据集扩增

为保证后续试验中充分的数据支撑,利用翻转和固定角度旋转对初始标准地基云图数据集和 GT 数据集进行数据增强,形成最终的地基云图数据集 (GBCD) 和 GT 数据集 (GBCD-GT),数据构成如表 2 所示。

表 2 数据集 GBCD 和 GBCD-GT 构成

Table 2 Composition of datasets GBCD and GBCD-GT

| 云类   |    | 扩增前数据量/张 | 扩增后数据量/张 |
|------|----|----------|----------|
| 中文名称 | 简写 |          |          |
| 高积云  | Ac | 232      | 1392     |
| 高层云  | As | 222      | 1332     |
| 积雨云  | Cb | 64       | 384      |
| 卷积云  | Cc | 150      | 900      |
| 卷云   | Ci | 215      | 1290     |
| 卷层云  | Cs | 250      | 1500     |
| 积云   | Cu | 212      | 1272     |
| 雨层云  | Ns | 72       | 432      |
| 层积云  | Sc | 245      | 1470     |
| 雨层云  | St | 123      | 738      |
| 无云   | No | 216      | 1296     |
| 总和   | —  | 2001     | 12 006   |

## 2 基于多任务学习的地基云图识别与分割模型

### 2.1 多任务学习模型构建

多任务学习将多个相关任务放在一起学习并共享一个模型,在防止模型过拟合的同时,一定程度上减少了模型参数量;通过任务之间共享特征,相互助力,提升各项任务的效果;多个任务通过一次前向计算获取结果,提高多任务实现效率。

多任务学习模式的参数硬共享是指所有任务共享隐藏层参数,在一定程度上降低了模型过拟合的风险。故本文采用参数硬共享模式,将不同任务通过底层共享特征实现信息的相互补充,降低参数量,提升网络的泛化能力。

本文根据地基云图的形态特点,设计了基于多

任务学习的地基云图识别和分割联合网络模型,结构如图 4 所示。该模型首先通过 CNN 提取图像的共享特征,然后对共享特征进一步提取识别和分割两个任务的特定特征,最后识别网络结合共享特征和分割特征实现地基云图识别,以解决现有网络鲁棒性差的问题。

### 2.2 网络模型 GCRSegNet

根据模型设计原理,本文网络模型分为三个部分,如图 5 所示,图中不同的功能模块用不同的颜色表示。第一部分通过共享网络提取共享特征,在一定程度上降低网络过拟合的风险;第二部分通过分割网络学习不同尺度的共享特征,定位云体像素,输出地基云图掩膜 mask;第三部分通过识别网络融合多尺度共享特征和分割网络提供的大尺度特征,提取特定的特征信息进行地基云图分类,输出地基云图类别。

在网络优化学习过程中,整个网络的损失函数为两个任务损失函数之和,如式(1)所示:

$$L = L_{\text{cls}} + L_{\text{seg}} \quad (1)$$

式中: $L$  为总损失函数,包括用交叉熵损失函数计算的识别网络损失  $L_{\text{cls}}$  和用对数似然损失函数计算的分割网络损失  $L_{\text{seg}}$ 。

#### 2.2.1 共享网络

在共享网络中,首先利用普通卷积和池化提取图像浅层特征;然后利用 4 个 stage 模块提取图像深层特征,每个 stage 由不同数量的特征提取单元和一个下采样单元组成,特征提取单元如图 6 所示,用卷积块注意力模块(convolutional block attention module,CBAM)作注意力模块,下采样单元设计借鉴 LCCNet;最后经过  $1 \times 1$  卷积,整合特征信息,获得共享特征。

CBAM 结构如图 7 所示,由通道注意力和空间注意力串行连接组成,是一个轻量级模块,从通道和




图 4 多任务学习模型构建原理

Fig. 4 Principle of multi-task learning model construction




图 5 GCRSegNet 模型结构图

Fig. 5 GCRSegNet model structure diagram




图 6 stage 中的特征提取单元

Fig. 6 Feature extraction unit in stage




图 7 注意力模块 CBAM

Fig. 7 Attention module CBAM

空间两方面提取更多地基云图细节和位置信息,便于后续特征学习。

### 2.2.2 分割网络

分割网络需要将共享特征经过上采样还原到原始图像尺寸,让特征以分割图形式重现,故分割网络的主要组成部分是上采样单元。为尽量减少模型参数量,上采样单元 a 使用一个膨胀率为 1 的深度卷积,结构如图 8a 所示;相比上采样单元 a,上采样单元 b 用普通卷积代替深度卷积,如图 8b 所示。为弥补深度卷积带来的特征损失,采用 concatenate 通道聚合方法将共享网络与分割网络中具有相同尺度特征的通道进行合并,实现精细的图像特征重现。

### 2.2.3 识别网络

识别网络融合了共享特征和分割网络倒数第二层特征,结构如图 9 所示。首先共享特征经过  $1 \times 1$  卷积和池化,降低信息冗余,保留主要特征;接着分割网络倒数第二层特征经过残差块、平均池化和组卷积,既能缓解由网络过深引起网络性能下降的问题,提取高维特征信息,又能有效利用不同通道在相同空间位置上的特征信息,保留分割特征的全局信

息;最后将上述两种特征融合,经过全连接层对特征进行分类,达到分类地基云图的目的。




图 8 上采样单元结构

(a) 上采样单元 a, (b) 上采样单元 b

Fig. 8 Up-sampling unit structure

(a) up-sampling unit a, (b) up-sampling unit b




图 9 特征融合模块结构

Fig. 9 Feature fusion module structure

### 3 试验结果与分析

本节介绍试验配置,试验指标,试验结果及分析。

#### 3.1 试验配置

本文在 GBCD 和 GBCD-GT 数据集上进行试验,为了保证网络较好的特征学习能力,将两个数据集分别按 8:1:1 分成训练集、验证集和测试集,训练 batch\_size 为 32, epoch 为 100, 初始学习率为 0.001, 优化器为 Adam。

本文将准确率(Accuracy)、像素准确率(pixel accuracy, PA)、平均交并比(mean intersection over union, MIoU)作为试验评价指标,计算公式如下。

$$\text{Accuracy} = \frac{\sum_{i=1}^n \text{TP}(i)}{\text{total}} \quad (2)$$

$$\text{PA} = \frac{\text{TP} + \text{TN}}{\text{FN} + \text{FP} + \text{TN} + \text{TP}} \quad (3)$$

$$\text{MIoU} = \frac{1}{n+1} \sum_{i=1}^n \frac{\text{TP}}{\text{FN} + \text{FP} + \text{TP}} \quad (4)$$

式(2)中,  $i=1, 2, 3, \dots, n (n=11)$ , total 为图片总数量;式(3)和式(4)中, TP 为被模型分类正确的正样本, TN 为被模型分类正确的负样本, FN 为被模型分类错误的正样本, FP 为被模型分类错误的负样本,  $n$  为类别数。

#### 3.2 试验结果及分析

##### 3.2.1 识别对比试验

为了表明模型 GCRSegNet 能准确识别地基云图,将网络 GCRSegNet 与现有经典的单任务识别网络在准确率上进行对比,试验结果如表 3 所示。

表 3 分类网络性能比较

Table 3 Performance comparison of classified networks

| 网络模型         | 参考文献                | 准确率/% |
|--------------|---------------------|-------|
| Inception    | Szegedy et al(2016) | 76.96 |
| VGG16        | —                   | 86.90 |
| ResNet-152   | —                   | 89.56 |
| MobileNet-V2 | Sandler et al(2018) | 91.95 |
| DenseNet-201 | —                   | 93.18 |
| CloudNet     | —                   | 91.87 |
| LCCNet       | —                   | 93.86 |
| GCRSegNet    | —                   | 94.28 |

表中试验结果表明,虽然单任务学习模型 CloudNet 和经典分类网络(inverted residuals and linear bottlenecks, MobileNet-V2)的准确率均在 90%以上, LCCNet 甚至达到了 93.86%, 但 GCRSegNet 准确率高达 94.28%。由此证明该模型能在实现两个任务的前提下准确识别地基云图,为模型的实际应用提供了可能性。

从混淆矩阵分析模型 GCRSegNet 在地基云图识别中的效果,如图 10 所示。图中横轴为预测类别,纵轴为真实类别,横纵轴交点处的值为正确识别或错误识别率。图 10 表明,在模型 GCRSegNet 中,大多类别云体的识别率在 90%以上,只有 Ac 和 Ci 两种云的识别率在 90%以下,因为在 GCRSegNet 中存在 Ac 与 Cc 和 Sc、Ci 与 Cs 和 Cc 混淆的情况。

在实际地基云图中, Ac、Cc 和 Sc 存在相互转换的关系,并在某些时刻 Ac 与 Cc 和 Sc 结构相似,容易产生混淆,如图 11a 所示,红色框区域为 Sc,蓝色框区域为 Ac,黄色框区域为 Cc,因此 Ac 易被预测为 Cc 和 Sc;而 Ci、Cs 与 Cc 之间存在相互变换的关系,且变换频率较高,因此会导致一张地基云图包含两种或者三种云,如图 11b 所示,红色框区域为 Cc,蓝色框区域为 Cs,黄色框区域为 Ci,致使 Ci 可能被预测为 Cc 和 Cs。

卷云 Ci 颜色较浅,不利于网络提取足够多的特征进行学习,且在分割网络中将特征复原到分割图的过程可能会丢掉部分细节特征,导致颜色较浅的卷云不易被分割出来,如图 12 所示。比较共享网络




图 10 模型 GCRSegNet 的混淆矩阵

Fig. 10 Confusion matrix of GCRSegNet model




图 11 混淆地基云图

(a) Sc(红框)、Ac(蓝框)和 Cc(黄框), (b) Cc(红框)、Cs(蓝框)和 Ci(黄框)

Fig. 11 Confusion ground-based cloud images

(a) Sc (red frame), Ac (blue frame), and Cc (yellow frame), (b) Cc (red frame), Cs (blue frame), and Ci (yellow frame)




图 12 特征图展示

(a)原图, (b)卷积特征图  $256 \times 256$ , (c)最大池化特征图  $128 \times 128$ ,

(d)上采样单元 a 特征图  $128 \times 128$ , (e)上采样单元 b 特征图  $256 \times 256$

Fig. 12 Feature map display

(a) original image, (b) feature map of convolution of  $256 \times 256$ , (c) feature map of max pooling of  $128 \times 128$ ,

(d) feature map of up-sampling Unit a of  $128 \times 128$ , (e) feature map of up-sampling Unit b of  $256 \times 256$

和分割网络中尺度相同的特征图,如图 12b 和 12e,虽然具有相同尺度,但在图 12e 中难以识别出颜色较浅的云体,同样在图 12c 和 12d 中也存在分割网络难以把颜色浅的云体表示出来,如图 12d 所示。因此,颜色较浅的卷云分割特征会影响其在识别网络中起到的作用,进而影响卷云识别准确率。

因此,还需进一步优化 GCRSegNet 模型,以提高对较浅云体的识别效果,并进一步研究能同时识别与分割多种地基云图的多任务模型,减小不同地

基云图之间的相互影响。

### 3.2.2 分割对比试验

将网络 GCRSegNet 与现有经典的语义分割网络在像素准确率 PA 和平均交并比 MIOU 上进行对比,试验结果如表 4 所示。

从表中试验结果表明,分割网络(deep convolutional encoder-decoder architecture for image segmentation, SegNet)、UNet、深度非对称实时分割网络(depth-wise asymmetric bottleneck for real-time

表 4 分割网络性能对比

Table 4 Performance comparison of segmentation networks

| 网络模型        | 参考文献                       | 像素准确率/% | 平均交并比/% |
|-------------|----------------------------|---------|---------|
| SegNet      | Badrinarayanan et al(2017) | 91.18   | 69.55   |
| UNet        | Ronneberger et al(2015)    | 91.65   | 70.75   |
| DABNet      | Li et al(2019)             | 90.27   | 65.91   |
| CloudSegNet | —                          | 91.97   | 69.11   |
| GCRSegNet   | —                          | 93.85   | 71.58   |

semantic segmentation, DABNet) 和 CloudSegNet 的 PA 均达到 90% 以上,其中 CloudSegNet 网络的 PA 达到 91.97%,MIoU 达到 69.11%,但 GCR-SegNet 的 PA 达到 93.85%,比 CloudSegNet 高了近 1.88%,MIoU 达到 71.58%。从以上的对比试

验证明,网络 GCRSegNet 在实现多任务的同时,能准确分割地基云图。

将网络 UNet 和 GCRSegNet 的试验效果进行可视化,如图 13 所示。从对比结果中发现,GCR-SegNet 和 UNet 均难以辨认丝缕状云体,但对于地




图 13 地基云图分割结果

(a)原图,(b)真值图,(c)UNet 输出,(d)GCRSegNet 输出

Fig. 13 Segmentation results of ground-based cloud image

(a) original image, (b) GroundTruth, (c) output of UNet, (d) output of GCRSegNet

基云图边缘颜色较深的云体,GCRSegNet 分割精度高于 UNet,如图中红色框所示,进一步证明了 GCRSegNet 网络能准确分割出颜色结构不一样的地基云图。

3.2.3 联合检测有效性验证试验

为了证明地基云图识别和分割联合检测的有效性,把在模型 GCRSegNet 识别网络中没有融合分割特征,同时实现识别和分割两个任务的模型命名为 GCRSegNet \*。并将两模型 GCRSegNet \* 和 GCRSegNet 在 Accuracy、PA 和 MIoU 上进行对比,试验结果如表 5 所示。

表 5 多任务模型性能对比

Table 5 Comparison of multitasking model performance

| 模型          | 准确率/% | 像素准确率/% | 平均交并比/% |
|-------------|-------|---------|---------|
| GCRSegNet * | 84.81 | 81.12   | 66.65   |
| GCRSegNet   | 94.28 | 93.85   | 71.58   |




图 14 GCRSegNet \* 和 GCRSegNet 网络总损失函数对比

Fig. 14 Comparison of network Loss between GCRSegNet \* and GCRSegNet

从表中试验结果发现,GCRSegNet \* 没有在识别任务中加入分割特征,试验结果 Accuracy、PA 和 MIoU 分别低于 GCRSegNet 近 10%、12%和 5%,证明 GCRSegNet 模型对地基云图有较好的特征表达能力,为地基云图识别和分割联合的实际应用提供了一种可行方案。

从损失函数收敛情况来衡量 GCRSegNet \* 和 GCRSegNet 模型性能,如图 14 所示。从图中发现 GCRSegNet 模型的总损失函数收敛更快,进一步证明 GCRSegNet 模型泛化性和鲁棒性较好,能准确识别和分割地基云图。

3.3 模型应用分析

鉴于模型 GCRSegNet 最后输出地基云图类别和分割图,故利用模型 GCRSegNet 可以预测地基云图云状和云量,并根据云状和云量预测天气变化,实现自动地基云观测。将在 2018 年 9 月 6 日 08、12、16、18 时拍摄的地基云图经过预处理后,利用 GCRSegNet 模型的输出结果判断云状和云量,结果如表 6 所示。根据模型输出类别为积云,且只有一个时间段的云量超过 50%,其他时间段均在 50%以下,预测可能属于晴天的天气状况,并与当时真实天

表 6 模型预测天气结果:2018 年 9 月 6 日

Table 6 Model forecast weather results: 6 September 2018

| 时间/BT | 地基云图 | 类别 | mask | 云量/%  | 预测天气 | 实际天气 |
|-------|------|----|------|-------|------|------|
| 08    |      | 积云 |      | 44.18 | 晴    | 晴    |
| 12    |      | 积云 |      | 52.94 | 晴    | 晴    |
| 16    |      | 积云 |      | 41.72 | 晴    | 晴    |
| 18    |      | 积云 |      | 6.60  | 晴    | 晴    |

气预报对比,证明模型 GCRSegNet 对天气状况识别有一定的辅助作用。

## 4 结论与讨论

(1) 通过人工标注、迁移学习和数据增强,将 TSI 采集的地基云图分成包含 11 类地基云图的 GBCD 数据集,共 12 006 张;借助网络分割、去除太阳光和人工校准,将 GBCD 中地基云图分割成对应 GT 图,最后形成带标签的 GBCD-GT 数据集,为后续建模研究奠定了基础。

(2) 基于多任务学习,构建了地基云图识别和分割联合网络模型 GCRSegNet,并将该模型在准确率 Accuracy、像素准确率 PA 和平均交并比 MIoU 上与单任务模型进行对比,发现 GCRSegNet 模型 Accuracy 达到 94.28%,PA 达到 93.85%,MIoU 达到 71.58%,分别比最优的单任务模型提升了 0.42%、1.75%、0.78%。为了证明地基云图识别与分割联合检测的有效性,本文将模型 GCRSegNet\* 和 GCRSegNet 在 Accuracy、PA 和 MIoU 上进行对比,发现地基云图识别和分割联合检测的效果明显优于没有联合检测的效果。经过对比试验表明,GCRSegNet 是所有对比模型中效果最好的,证明了 GCRSegNet 可以在多任务联合检测的前提下实现准确的地基云图识别与分割,为后续天气预报领域的研究提供了一种可行方案。

虽然本文实现了地基云图识别与分割联合检测,但后续可以进一步研究一张地基云图存在多种云的情况,并利用语义分割方法优化模型,提高两个任务的性能,达到准确识别和分割地基云图的目的。

## 参考文献

- 程鹏,罗汉,甘泽文,等,2022. 大型无人机一次人工增雨试飞及催化响应分析[J]. 气象,48(8):1053-1061. Cheng P, Luo H, Gan Z W, et al, 2022. A large UAV artificial precipitation enhancement experiment and physical response analysis of the cloud seeding processes[J]. Meteor Mon, 48(8):1053-1061(in Chinese).
- 段向军,王敏,2020. 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,43(6):1257-1261. Duan X J, Wang M, 2020. An ground cloud image recognition method using AlexNet convolution neural network[J]. Chin J Electron Dev, 43(6):1257-1261(in Chinese).
- 桂海林,诸葛小勇,韦晓澄,等,2019. 基于 Himawari-8 卫星的云参数和降水关系研究[J]. 气象,45(11):1579-1588. Gui H L, Zhuge X Y, Wei X C, et al, 2019. Study on the relationship between Himawari-8-based cloud parameters and precipitation[J]. Meteor Mon, 45(11):1579-1588(in Chinese).
- 胡树贞,曹晓钟,陶法,等,2020. 船载毫米波云雷达观测西太平洋云宏观特征对比分析[J]. 气象,46(6):745-752. Hu S Z, Cao X Z, Tao F, et al, 2020. Comparative analysis of cloud macro characteristics from two shipborne millimeter wave cloud radars in the West Pacific[J]. Meteor Mon, 46(6):745-752(in Chinese).
- 黄兴友,陆琳,洪滔,等,2020. 利用毫米波云雷达数据反演层云微物理参数和云内湍流耗散率[J]. 大气科学学报,43(5):908-916. Huang X Y, Lu L, Hong T, et al, 2020. A case study on the retrieval of microphysical parameters and in-cloud stratus turbulent dissipation rate by millimeter-wave cloud radar measurement[J]. Trans Atmos Sci, 43(5):908-916(in Chinese).
- 贾克斌,张亮,刘鹏宇,等,2021. 基于轻量级神经网络的地基云图识别[J]. 北京工业大学学报,47(5):489-499. Jia K B, Zhang L, Liu P Y, et al, 2021. Ground-based cloud recognition based on lightweight neural network[J]. J Beijing Univ Technol, 47(5):489-499(in Chinese).
- 沈慧想,夏旻,施必成,等,2019. 对称式密集连接网络的地基云图分割方法[J]. 计算机工程与应用,55(17):207-213. Shen H X, Xia M, Shi B C, et al, 2019. Ground-based cloud image segmentation method based on symmetric convolutional neural network with dense connection[J]. Comput Eng Appl, 55(17):207-213(in Chinese).
- 万夫敬,刁秀广,2018. 两次 MCC 红外云图特征与天气实况异同性分析[J]. 气象,44(6):759-770. Wan F J, Diao X G, 2018. Comparative analysis on cloud evolution features and weather of two MCCs[J]. Meteor Mon, 44(6):759-770(in Chinese).
- 王烁,张佃国,王文青,等,2021. 初冬一次层状云较弱云区垂直结构的飞机观测[J]. 应用气象学报,32(6):677-690. Wang S, Zhang D G, Wang W Q, et al, 2021. Aircraft measurement of the vertical structure of a weak stratiform cloud in early winter[J]. J Appl Meteor Sci, 32(6):677-690(in Chinese).
- 毋立芳,贺娇瑜,简萌,等,2018. 局部聚类分析的 FCN-CNN 云图分割方法[J]. 软件学报,29(4):1049-1059. Wu L F, He J Y, Jian M, et al, 2018. Local clustering analysis based FCN-CNN for cloud image segmentation[J]. J Softw, 29(4):1049-1059(in Chinese).
- 许健民,2021. 用对流-辐射平衡理论理解对流云的外观表现[J]. 气象,47(1):1-10. Xu J M, 2021. Appearance of convective clouds explained by radiative-convective equilibrium[J]. Meteor Mon, 47(1):1-10(in Chinese).
- 岳治国,余兴,刘贵华,等,2021. 一次飞机冷云增雨作业效果检验[J]. 气象学报,79(5):853-863. Yue Z G, Yu X, Liu G H, et al, 2021. Effect evaluation of an operational precipitation enhancement in cold clouds by aircraft[J]. Acta Meteor Sin, 79(5):853-863(in Chinese).
- 智协飞,张珂珊,田烨,等,2021. 基于神经网络和地理信息的华东及华南地区降水概率预报[J]. 大气科学学报,44(3):381-393. Zhi X F, Zhang K J, Tian Y, et al, 2021. Probabilistic precipitation forecast in East and South China based on neural network and

- geographic information[J]. *Trans Atmos Sci*, 44(3):381-393 (in Chinese).
- 中国气象局, 2003. 地面气象观测规范[M]. 北京: 气象出版社. China Meteorological Administration, 2003. Standard of Surface Meteorological Observation[M]. Beijing: China Meteorological Press (in Chinese).
- Badrinarayanan V, Kendall A, Cipolla R, 2017. SegNet: A deep convolutional encoder-decoder architecture for image segmentation [J]. *IEEE Trans Pattern Anal Mach Intell*, 39(12):2481-2495.
- Dev S, Lee Y H, Winkler S, 2017a. Color-based segmentation of sky/cloud images from ground-based cameras[J]. *IEEE J-STARS*, 10(1):231-242.
- Dev S, Savoy F M, Lee Y H, et al, 2017b. Nighttime sky/cloud image segmentation[C]//2017 IEEE International Conference on Image Processing (ICIP). Beijing: IEEE; 345-349.
- Dev S, Nautiyal A, Lee Y H, et al, 2019. CloudSegNet: a deep network for nychthemeron cloud image segmentation [J]. *IEEE Geosci Remote Sens Lett*, 16(12):1814-1818.
- He K M, Zhang X Y, Ren S Q, et al, 2016. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas; IEEE; 770-778.
- Huang G, Liu Z, van der Maaten L, et al, 2017. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu; IEEE; 4700-4708.
- Li G, Yun I, Kim J, et al, 2019. DABNet: depth-wise asymmetric bottleneck for real-time semantic segmentation[C]//Proc. Brit. Mach. Vis. Conf. ; 1-12.
- Ronneberger O, Fischer P, Brox T, 2015. U-Net: convolutional networks for biomedical image segmentation[C]//18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer; 234-241.
- Sandler M, Howard A, Zhu M L, et al, 2018. MobileNetV2: inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City; IEEE; 4510-4520.
- Simonyan K, Zisserman A, 2014. Very deep convolutional networks for large-scale image recognition[C]//Int. Conf. Learn. Represent. , ICLR- Conf. Track Proc. ; 1-14.
- Szegedy C, Vanhoucke V, Ioffe S, et al, 2016. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas; IEEE; 2818-2826.
- Zhang J L, Liu P, Zhang F, et al, 2018. CloudNet: ground-based cloud classification with deep convolutional neural network[J]. *Geophys Res Lett*, 45(16):8665-8672.
- Zhang Z Y, 2000. A flexible new technique for camera calibration[C]//2000 IEEE Transactions on Pattern Analysis & Machine Intelligence. Redmond; IEEE; 1330-1334.

(本文责编: 戴洋)