

融合多尺度特征和梯度信息的云种类识别

金龄杰¹, 林志玮^{1,2,3,4,5*}, 洪宇^{2,4,5}¹福建农林大学计算机与信息学院, 福建 福州 350002;²福建农林大学林学院, 福建 福州 350002;³福建农林大学林学博士后流动站, 福建 福州 350002;⁴生态与资源统计福建省高校重点实验室, 福建 福州 350002;⁵福建农林大学海峡自然保护区研究中心, 福建 福州 350002

摘要 针对目前全天空成像仪云图特征提取方法繁琐的问题, 提出一种结合双线密集结构和梯度信息的云种分类模型, 即双线程梯度卷积神经网络(DGNet), 以优化网络对云图特征的学习能力。以双线程并行的密集模块搭建分类模型, 同时融入梯度算法于特征图中。实验结果表明, 所提模型的识别正确率与经典的模型相比有显著改进, 正确率达 67.00%。所提模型采用多线程、多尺度梯度密集模块结构, 减少特征信息损失; 利用梯度算法充分提取云图的梯度变化特征, 增强模型对云种识别的精度; 提出新云图数据集, 该数据集包含 10 类云图, 每类 100 张, 共 1000 张全天空成像仪图像; 与现有模型相比, 所提模型获得最佳精度, 证明了模型的可行性。

关键词 图像处理; 梯度; 全天空云图; 云图分类

中图分类号 TP399; P409

文献标志码 A

DOI: 10.3788/LOP202259.1810015

Cloud-Type Recognition Based on Multiscale Features and Gradient Information

Jin Lingjie¹, Lin Zhiwei^{1,2,3,4,5*}, Hong Yu^{2,4,5}

¹College of Computer and Information Sciences, Fujian Agriculture and Forestry University, Fuzhou 350002, Fujian, China;

²Forestry College, Fujian Agriculture and Forestry University, Fuzhou 350002, Fujian, China;

³Forestry Post-Doctoral Station, Fujian Agriculture and Forestry University, Fuzhou 350002, Fujian, China;

⁴Key Laboratory of Fujian Universities for Ecology and Resource Statistics, Fuzhou 350002, Fujian, China;

⁵Cross-Strait Nature Reserve Research Center, Fujian Agriculture and Forestry University, Fuzhou 350002, Fujian, China

Abstract Aiming at the complicated problem of cloud image feature extraction method of all-sky imager, we propose a cloud-type classification model, that is, a dual-path gradient convolutional neural network (DGNet), by combining a double-line dense structure and gradient information to optimize the ability of the network to learn features of cloud images. The classification model is constructed using dual-thread parallel dense modules, and a gradient algorithm is applied to the feature maps. Experimental results show that compared with classic models, the accuracy of the proposed model improves significantly, reaching 67.00%. The main contributions of this study are as follows: the proposed model adopts a multithread and multiscale gradient dense module structure to reduce the loss of feature information; The gradient algorithm is used to fully extract the gradient change features of the cloud image to enhance the model's accuracy for recognizing cloud species; A new data set of all-sky images is proposed, which contains 10 types of cloud images and 100 images of each type, accounting for 1000 images; Compared with the existing models, the proposed model shows the best accuracy, proving the feasibility of the proposed model.

Key words image processing; gradient; all-sky cloud image; cloud image classification

收稿日期: 2021-07-08; 修回日期: 2021-07-31; 录用日期: 2021-08-10

基金项目: 教育部人文社会科学研究项目(18YJCZH093)、海峡博士后交流资助计划、中国博士后科学基金面上项目(2018M632565)

通信作者: *cwlin@fafu.edu.cn

1 引言

近年来,云的分类研究被广泛应用于气象监控、野外观察和航天航空等领域,因此如何准确地对云的类型进行分类成为了一项有挑战性的任务。目前主流的地面观测云设备为全天空成像仪^[1-3],太湖和无锡站用该仪器收集地面观测资料,以分析不同天气情况下图像的成像特征^[4-5]。JOSEP^[6]利用两种不同全天空成像仪摄像设备(Whole-Sky Imager 和 Total-Sky Imager)开发分类器。另一种较为常用的设备是气象卫星^[7-8],然而气象卫星只是简单地提供云图像的光谱信息,并不像全天空成像仪提供的图像那样直观。

早期的云自动分类模型主要以光谱信息作为输入,通过最大似然分类方法对云类型进行自动分类^[9]。之后云图像分类的重点在于提取图像内的相关特征信息,建立能够抽取多光谱特征的模型,以揭示不同光谱带中云的特征^[4,10-11]。此外,早期的方法还包括决策矩阵和“温度+亮度”直方图,确定适当的阈值实现云特征分类^[12-13]。随着计算机硬件水平的提升,越来越多的机器学习方法如基于图像颜色和纹理统计特征的最近邻节点(KNN)算法能区分不同的天空状态^[14-15]。但如果仅使用纹理特征,可能无法为云分类提供充足的有效信息。因此,结合云图多元化特征的方法成为主流,例如提取彩色天空图像纹理和结构^[16]、云图的多视图^[17]、云图的直方图^[18]和LBP直方图确定最优图像^[19]等特征以增强分类能力。

近年来,深度卷积神经网络在图像研究方面得到广泛的应用。2017年提出的AlexNet^[20]是首个深度卷积神经网络,之后VGG^[21-22]、GoogleNet^[23]、ResNet^[24-25]、DenseNet^[26]和SENet^[27-28]在网络深度、宽度、特征使用方式上进行改进,均有效提高网络的分类能力。通过卷积神经网络,一些学者提出一种基于深度学习框架的云检测方法,以预测每个像素属于云区域的概率^[29],但该方法仅能提取较为简单的云图特征。为了提高方法对云图的分类性能,Ye等^[30]应用卷积神经网络和Fisher向量编码来提取和映射云图特征。之后一些学者利用改进的云模式挖掘方法^[31]、多层感知神经网络^[32]和浅层卷积神经网络^[33]区分图像特征。但是这些研究缺乏卷积神经网络端到端的分类过程,仅仅利用卷积神经网络提取云图特征信息。因此,有些学者搭建多个具有相同卷积操作的聚合分类框架^[34]、浅层卷积神经网络框架^[35]、结合多模态特征和注意力特征的网络架构^[36]、多通道神经网络和改进的帧差法^[37]提取云图特征,提高网络的分类性能。

虽然目前的云图种类识别研究已经取得了精度上的提升,但还存在两种问题:一是将卷积神经网络作为云图特征提取的工具,未能让网络学习到多尺度和多梯度的特征语义信息;二是大多数方法得到的云图像

类别都不能很好地匹配中国气象局规定的云种十属二十九类的标准。

为解决上述问题,本文提出了一种新的基于梯度算法的卷积神经网络模型,即双线程梯度卷积神经网络(DGNet),该框架由双线程密集块组成。为了有效利用云图的特征信息,采用梯度算法提取云图像素间的梯度特征,通过与云的特征图相结合的方式增强网络的学习和识别能力。根据国际气象组织标准,通过一系列的人工筛选和整理,形成一个全天空成像仪云图数据集。实验结果表明,所提模型框架可以在该数据集下提取更精细的云图边缘特征,实现更好的云图种类区分效果。

2 模型描述

所提基于梯度特征的双线程密集块云图种类分类模型(DGNet)借鉴了卷积神经网络特征重用的设计思想,采用DenseNet的密集块网络结构微基础框架。其中,密集块用于重复提取云图重要特征,梯度算法可以提取云图隐含的梯度信息,融合云图的卷积特征结果,得到云图种类识别结果。研究表明,卷积神经网络的深度和卷积模块、云图形状特征和梯度信息、损失函数等因素对基于梯度算法的DGNet性能均有较大的影响,因此在网络框架设计中综合考虑以上因素。为便于阐明,采用从全局框架到局部模块的方式介绍模型的设计思路。

图1展示简化的网络框架,用以说明DGNet的设计原理,该网络有两条密集块线程,每条线程都由4个不同大小的密集块组合而成,用以加强云图特征信息的重复利用。两条线程之间通过特征图的叠加融合信息,以此增强网络对云图的识别能力。在双线程的密集块基础上引入梯度算法,将云图的梯度信息与密集块融合,并在上述模块的基础上增加一组原特征图的信息叠加模块。最后,提出新的损失计算方法,在计算最后融合的总损失情况下,考虑两条线程和最后融合的总线程的损失,使总损失在反向传播时用于调整卷积权重,使网络对云图分类的拟合效果更好。

2.1 多尺度双线程网络

基于梯度信息的DGNet框架如图1所示,对应输入、特征图、密集块旁的括号内数字表示该处图片或特征图大小。该框架能够融合云图梯度信息与特征,结构特点为由密集块组成的双线程网络,继承了DenseNet能有效保留信息流的特点,加强了对特征信息的利用。与DenseNet不同的是,DGNet中两条线程均以最大池化层输出的特征图作为输入,但第二条线程的输入大小是最大池化层输出特征图大小的一半。因此,第二条线程的输入图大小是第一个通道输入图大小的一半。为了加强特征图的信息保留和传递过程,除了密集模块的作用以外,通过卷积操作将第一通道的输入分别与第二通道的相应位置特征图叠加。过

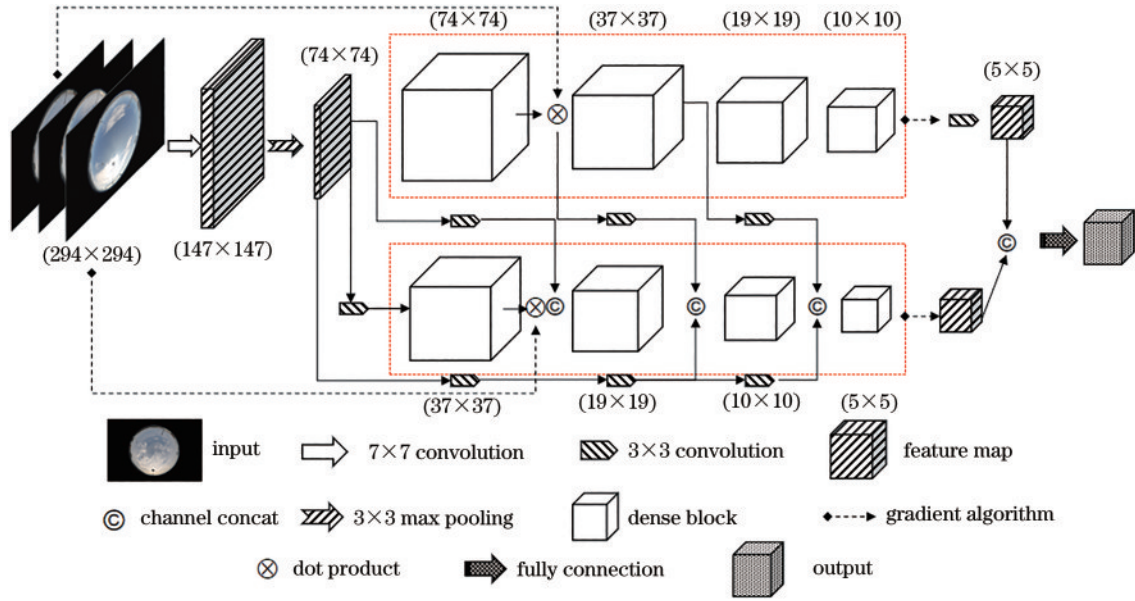


图 1 基于梯度算法的 DGNet 框架

Fig. 1 Framework of DGNet based on gradient algorithm

渡层是在每个密集块之间,由于它的作用,特征图的大小都会减半,图 1 中省略该层的设计。通过 5 个卷积核大小为 3×3、步长为 2 的卷积层卷积特征图,减小了特征图的大小,因此能与相同尺寸大小的特征图进行融合。此外,在网络的第一个、第四个密集块之后加入了一种梯度算法,该梯度算法能有效提取云图的边缘特征信息,增强不同云种之间的区别性。最后,将两个线程的特征图叠加,通过全连接层对 10 种云计算类别概率,再通过 Softmax 分类器生成归一化的类别概率。为了防止梯度消失和梯度爆炸,增强网络的非线性拟合能力,实验框架的每一个卷积层都统一应用卷积-批量标准化-ReLU 激活函数。

2.2 双线程特征融合

如图 1 所示,第二条线程采用了 3 次特征图叠加的操作,其中通过卷积操作统一尺寸大小后每一个密集块输出的特征图都与最大池化层输出的特征图叠加。特征图叠加部分表示为

$$F_{2k} = f([M_{2h}, I_{1k}, U_{2k}]), \quad (1)$$

式中: $F^{H \times W \times N}$ 表示特征图叠加后的结果; H 和 W 分别是特征图的高和宽, N 是特征图叠加操作后的张数; M_{2h} 表示最大池化层输出的特征图经过 h 次卷积后大小减半的结果, $h = \{3, 4\}$; I_{1k} 是第一条线程第 k 个密集块输入经 3×3 卷积后的结果; U_{2k} 是第二条线程第 k 个密集块的输出结果, $k = \{1, 2, 3, 4\}$; $f(\cdot)$ 表示卷积通道数叠加操作; F_{2k} 是第二条线程第 k 个密集块输出的特征图通道数叠加后的结果。注意,当 k 为 3 或 4 时, M_{2h} 才存在。每经过一个通道数叠加,特征图的通道数会变多,减小特征图大小的同时增加了特征图的张数。

2.3 双线程梯度信息

双线程梯度特征的输入由两种不同的方式生成:一种是原图生成的梯度图,作用在双线程的第 1 个密集块后,生成的梯度图用 T_{1i} 表示;第二种是通过特征图生成的梯度图,作用在双线程的第 4 个密集块后,生成的梯度图用 T_{4i} 表示。如图 2 所示,特征图梯度化以后用梯度信息特征图表示,梯度信息特征图会经一个 Softmax 操作,再与一个单位矩阵相加,此操作可以提

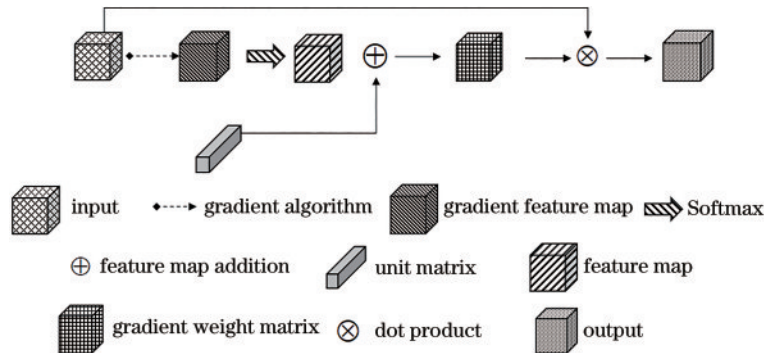


图 2 特征图梯度化提取过程

Fig. 2 Procedure of extracting gradient information from feature maps

取特征图梯度信息的权重。然后,用特征图梯度信息的权重与梯度信息特征图做点乘操作,生成最终的特征梯度信息图。设 U_{ik} 表示第 i 条线程第 k 个密集块的输出,特征图梯度信息 D_{ik} 可以表示为

$$D_{ik} = [\text{Softmax}C(T_{ik} + 1)] \otimes U_{ik}, \quad (2)$$

式中: $D^{H \times W \times P}$ 表示特征图的梯度信息, P 是梯度信息融合特征图的通道数; $i = \{1, 2\}$; $C(\cdot)$ 是 Canny 算子。双线程第一个密集块的梯度信息 T_{i1} 由原图直接生成,使密集块网络融合原云图的梯度特征。结合密集块卷积后的特征,在最后一个密集块处 T_{i4} 生成特征图的梯度信息与之结合,使网络能较好地学到云图的关键特征信息。

2.4 损失函数

考虑到网络两条线程共同的作用,设定了两种交叉熵损失函数计算方式。第一种,计算两条线程最终融合特征后的交叉熵损失 L_{SL} 和 L_2 ; 第二种,分别计算两条线程的交叉熵损失 L_{SL1} 和 L_{SL2} 、最终融合特征后的分类损失 L_{SL} 和 L_2 。交叉熵损失函数 L 的获取方式为

$$L = -\frac{1}{M} \sum_{m=0}^{M-1} \sum_{j=0}^{J-1} n_{m,j} \log p_{m,j}, \quad (3)$$

式中: M 是图片的最大张数; J 是云图最大种类数; $n_{m,j}$ 表示第 m 张图片第 j 类的真实标签; $p_{m,j}$ 表示第 m 张图片预测为 j 类的概率; L 表示实际值和期望值间的距离, L 值越小,两个概率分布就越接近。因此,两种损失的计算方法可以分别表示为

$$L_{DL1} = L_{SL} + L_2, \quad (4)$$

$$L_{DL2} = L_{SL1} + L_{SL2} + L_{SL} + L_2, \quad (5)$$

式中: L_{DL1} 为双线程最终融合特征的分类损失 L_{SL} 和最小平方差损失 L_2 之和,考虑全局损失的关系; L_{DL2} 为第一条线程的分类损失 L_{SL1} 、第二条线程的分类损失

L_{SL2} 、双线程最终融合特征的分类损失 L_{SL} 和最小平方差损失 L_2 之和,考虑的是全局和局部的损失关系。最小平方误差损失 L_2 对目标值 y_i 与估计值 $f(x)$ 的差值平方和进行最小化,其中 x 是输入, f 表示网络操作。

根据损失函数式(5),有

$$\frac{\partial L_{SL}}{\partial W_{FC}} = \frac{\partial L_{SL1}}{\partial f_s} \times \frac{\partial f_s}{\partial f_{FC}} \times O, \quad (6)$$

$$\frac{\partial L_{SL1}}{\partial W_1} = \frac{\partial L_{SL1}}{\partial C_{14}} \times \frac{\partial C_{14}}{\partial T_{13}} \times \frac{\partial T_{13}}{\partial C_{13}} \times \frac{\partial C_{13}}{\partial T_{12}} \times \frac{\partial T_{12}}{\partial C_{12}} \times \frac{\partial C_{12}}{\partial T_{11}} \times \frac{\partial T_{11}}{\partial C_{11}} \times C(I), \quad (7)$$

$$\frac{\partial L_{SL2}}{\partial W_2} = \frac{\partial L_{SL2}}{\partial C_{24}} \times \frac{\partial C_{24}}{\partial T_{23}} \times \frac{\partial T_{23}}{\partial C_{23}} \times \frac{\partial C_{23}}{\partial T_{22}} \times \frac{\partial T_{22}}{\partial C_{22}} \times \frac{\partial C_{22}}{\partial T_{21}} \times \frac{\partial T_{21}}{\partial C_{21}} \times C(I)_{1/2}, \quad (8)$$

式中: W_{FC} 是全连接层的权重; f_s 是特征图的 Softmax 操作; f_{FC} 是全连接卷积; O 是双线程密集块最终融合的结果; W_1 是第一条线程第一个密集块的权重; W_2 是第二条线程第一个密集块的权重; C_{ik} 是第 i 条线程第 k 个密集块的卷积操作; T_{ip} 是第 i 条线程第 p 个过渡层; $i = \{1, 2\}$, $p = \{1, 2, 3\}$; $C(I)$ 是第一条线程的输入, $C(I)_{1/2}$ 是第二条线程的输入。式(6)~(8)分别描述了网络在分类层、第一条线程和第二条线程倒传递进行梯度计算的过程,其中式(6)描述网络在最后的分类层倒传递过程对全连接层的权重调整,式(7)描述网络在第一条线程的损失倒传递过程对密集块权重的调整,式(8)描述网络在第二条线程的损失倒传递过程对密集块权重的调整。

2.5 DGNet 流程

DGNet 流程可以表示为

$$O_A = O^{1-4}(D_{11}), \quad (9)$$

$$O_B = P^4 \left\{ \text{Con}^3 \left\{ P^3 \left\{ \text{Con}^2 \left\{ P^2 \text{Con}^1 [D_{21}, C_{1/2}(I)], O_{A1/2}, C_{1/4}(I) \right\} \right\}, O_{A1/2}, C_{1/8}(I) \right\} \right\}, \quad (10)$$

$$O = \text{FC} \left\{ \text{Con} \left[\left[(\text{Softmax} O_A + 1) \cdot O_A \right]_{1/2}, \left[(\text{Softmax} O_B + 1) \cdot O_B \right] \right] \right\}, \quad (11)$$

式中: $I^{294 \times 294 \times 16}$ 表示长和宽都为 294、通道数为 16 的输入数据; $C(I)$ 表示数据经一层卷积和最大池化层输出的结果; O^{1-4} 表示第一条线程的输入经四个密集块后输出的特征图; P^k 表示第二条线程第 k 个密集块输出的特征图; $C_{1/2}(I)$ 表示 $C(I)$ 经一次卷积后特征图大小减半的结果, $C_{1/4}(I)$ 表示 $C(I)$ 经两次卷积后特征图大小减半的结果, $C_{1/8}(I)$ 表示 $C(I)$ 经三次卷积后特征图大小减半的结果; Con^q 表示第 q 次特征图通道数的叠加; O_A 是第一条线程密集块操作后的输出, O_B 是第二条线程密集块操作后的输出; $O_{A1/2}$ 是第一条线程第 k 个密集块经卷积后特征图大小减半的结果; $\text{FC}(\cdot)$ 是全连接层; O 表示最后融合的输出结果。通过以上多

个特征图的融合结果,所提框架能够增加云图的特征重用信息和梯度信息,解决云图分类的困难点。

3 实验结果及分析

提出基于梯度信息的 DGNet 框架,并展示实验中使用的全天空成像仪数据集,以及 DGNet 网络与经典的分类网络在自建数据集上的比较结果。首先,比较 DGNet、经典分类框架 ResNet 和 DenseNet 的分类性能;然后,介绍 DGNet 框架在不同损失计算方法上的比较结果;最后,通过消融实验,比较云图的梯度信息在 DGNet 不同密集块之间的效果。

3.1 实施细节

DGNet 框架有预加载的权重,其中第一条线程的卷积核大小和通道数与 DenseNet 一致,第二条线程的卷积核大小是第一条线程的一半。在网络训练中,所有网络都采用动量梯度下降法调整网络权重。激活函数是 ReLU,参与实验的训练和测试总张数是 1000,每个类别训练 70 张,测试 30 张。具体的参数设置是,对该数据量设置 200 次训练和测试,每批次训练和测试 16 张云图,图像大小统一缩小到 294×294 ,学习率设为 0.0001。实验代码采用的是 Tensorflow 函式库,实验中使用的显卡是 TITAN Xp。

3.2 数据集

全天空成像仪云图数据集由福州气象局收集提

供,数据拍摄于 2015 年 9 月至 2017 年 12 月。全天空成像仪拍摄时间跨度为早上 6:30 到下午 17:00。每张云图的拍摄时间间隔是 10 min,共采集 15763 张图片。通过人工标定云图类型,若云图模糊或图中云的类别多于一种,则将该云图替除,以确保每张图像是单一类型的云类别。但由于各类别图片数量差异过大,为了使每类云图片数据量平衡,经过滤筛选,每类云各取 100 张图,共 1000 张云图构成实验数据集。

图 3 为每种类型云图像的样例,云图的特征描述如表 1 所示。该数据集包含 10 个文件夹,每个文件夹涵盖一种云的图像数据,图像数据的像素是 4288×2848 。




图 3 10 类云图样例

Fig. 3 Patterns of 10 cloud types

表 1 10 种云的特征和数量

Table 1 Characteristics and number of each cloud type

Cloud type	Number of collected images	Number of experimental images	Characteristic description
Cirrus	1293	100	Relatively thin, pinnate, white filamentous
Cirrocumulus	391	100	Slight white wavy, scaly or globose cloud
Stratocirrus	317	100	White transparent filamentous structure
Cumulus	1889	100	The individual is noticeable, flat at the bottom, the light part is white, and the bottom is dark
Cumulonimbus	886	100	The clouds are thick and big, dark and messy
Stratocumulus	803	100	Clouds are large, in strips, sheets, or lumps
Nimbostratus	6681	100	The clouds form an even curtain, shielding the sun and moon
Alto cumulus	359	100	Clouds are small, usually oval, tile, or fish scale-shaped
Altostratus	2498	100	Clouds are grayish-white or gray with striated structures at the base
Stratus	646	100	Gray foggy

3.3 评估指标

为了评估不同损失计算对 DGNet 性能的影响,分析比较了两种损失 L_{sl} 和 L_{dl} 在所提研究框架中的实验结果。如表 2 所示,Top-1 代表网络学习结果中概率最高的类别是正确的概率,Top-5 代表网络在前 5 个预测中有正确标签的概率。计算 Top-1 精度的数学表达式为

$$P_1 = (n_{\text{correct}_1} / n_{\text{test}}) \times 100\%, \quad (12)$$

式中: n_{correct_1} 表示测试图片预测概率最高的标签与真实图片标签对应的张数; n_{test} 表示测试集中云图数据总数。计算 Top-5 精度的数学表达式为

$$P_2 = (n_{\text{correct}_5} / n_{\text{test}}) \times 100\%, \quad (13)$$

式中: n_{correct_5} 表示测试图片预测概率前五的标签中有与真实图片标签对应的张数。

表 2 经典分类框架的比较

Table 2 Comparison of classical classification frameworks

Method	Top-1 / %	Top-5 / %
Inception_v1	54.00	90.33
Inception_v2	54.30	91.67
Inception_v3	60.30	95.67
Inception_v4	50.70	90.33
ResNet50	63.70	95.33
ResNet101	61.00	94.33
DenseNet121	64.00	97.33
DGNet121	64.30	96.00

3.4 实验结果

3.4.1 经典分类框架比较

如表 2 所示,测试了 ResNet、Inception、DenseNet

和 DGNet121 在不同深度的实验效果,其中 DGNet121 表示网络不存在梯度融合的结构。这些实验有预载权重,与经典的分类框架相比,DGNet121 的 Top-1 准确率有一定的提升。

每种云的分类效果可以更好地反映卷积神经网络框架的性能。如表 3 所示,相较于 ResNet50 和 DenseNet121,DGNet121 网络显著提高了对层积云、积雨云、卷层云和卷积云的分类精度,对其他云类型的精度保持大致相等或较低。总之,DGNet121 取得了比其他分类框架更好的结果。图 4(a)显示不同分类框架在 200 步训练后均实现训练收敛,图 4(b)显示 200 步训练后 DGNet121 网络的测试分类 Top-1 优于其他分类框架,比 DenseNet121 网络高 0.3 个百分点。

表 3 经典分类框架对每种云类型的识别精度

Table 3 Identification accuracy of classical classification frameworks for each cloud type

unit: %

Method	Stratocumulus	Stratus	Altostratus	Alto cumulus	Cumulus	Cumulonimbus	Stratocirrus	Cirrocumulus	Cirrus	Nimbostratus
Inception_v1	46.67	86.67	3.33	73.33	46.67	80	60	53.33	46.67	43.33
Inception_v2	40.00	86.67	30.00	83.33	56.67	80	63.33	23.33	60.00	20.00
Inception_v3	43.33	90.00	33.33	76.67	53.33	70.00	80.00	73.33	53.33	30.00
Inception_v4	26.67	76.67	6.67	73.33	56.67	76.67	56.67	43.33	50.00	40.00
ResNet50	33.33	76.67	46.67	86.67	76.67	73.33	60.00	60.00	56.67	66.67
ResNet101	46.67	66.67	40.00	86.67	66.67	66.67	66.67	63.33	63.33	43.33
DenseNet121	53.33	76.67	36.67	83.33	70.00	63.33	66.67	73.33	60.00	56.67
DGNet121	60.00	73.33	33.33	83.33	70.00	76.66	70.00	76.67	60.00	40.00

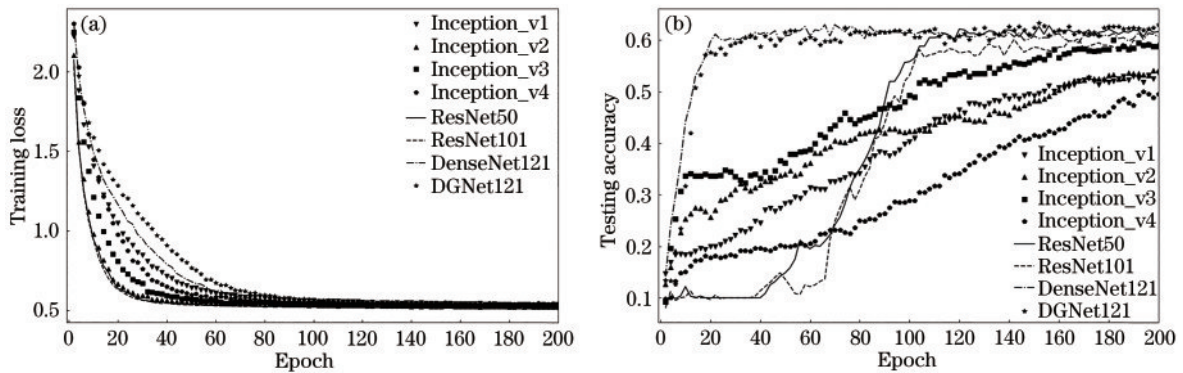


图 4 DGNet121 与经典分类框架比较。(a) 训练损失;(b) 测试精度

Fig. 4 Comparison between DGNet121 and classical classification networks. (a) Training loss; (b) testing accuracy

3.4.2 损失函数比较

根据式(4)和式(5),为了比较两种损失 L_{DL1} 和 L_{DL2} 对网络性能的影响,如表 4 所示,分别对采用两种损失计算方式的网络进行了 5 次实验,其中基于 L_{DL2} 损失的网路精度平均数比基于 L_{DL1} 损失的网路精度平均数高 0.12 个百分点,证明增加的损失量对网络的分类性

表 4 DGNet121 不同损失计算的比较

Table 4 Comparison of different loss calculations for DGNet121

Parameter	1	2	3	4	5	Mean	Variance
$L_{DL1} / \%$	64.30	64.30	63.70	69.70	63.30	65.06	0.06908
$L_{DL2} / \%$	66.30	65.00	67.30	64.30	63.00	65.18	0.02827

能有一定影响。

3.4.3 消融实验

在消融实验中,设计两组实验,分别探讨不同位置的梯度融合操作对模型分类精度的影响,以及不同训练及测试数据下模型的稳健性。

在实验 1 中,不同位置的梯度融合由两种数据生成,如图 5 中的序号 1 至 4 所示。1 表示双线程的第一个密集块之后的梯度由图像源数据生成,2、3、4 分别表示双线程的第二、三、四个密集块之后的梯度由该位置的特征图生成。因此,基于不同位置的梯度信息,测试不同模块位置的性能差异。梯度特征模块的比较结

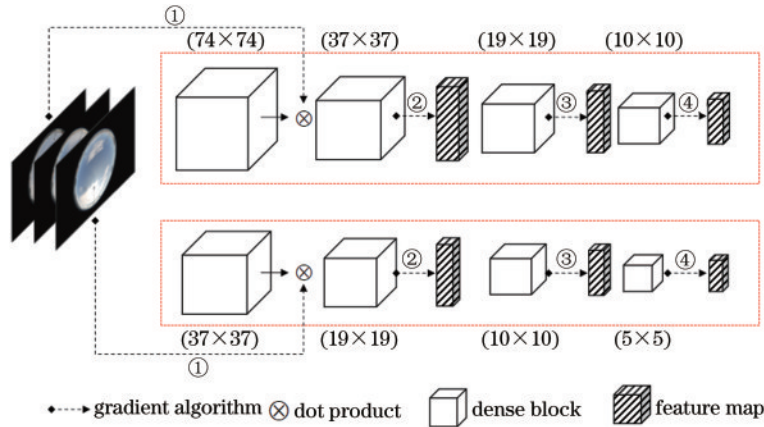


图 5 梯度信息的双线程结构

Fig. 5 Double-threaded structure with gradient information

果如表 5 所示。相比其他位置的模块, DGNet121_1+4 有更好的 Top-1 和 Top-5; DGNet121_1+4 的 Top-1 比多线程损失的 DGNet121_double_loss 网络提升 1 个百分点。如图 6 所示, DGNet121_1+4 在 60 步时达到最好的分类性能, 并随着实验步数的增加, 分类性能一直有明显的优势。DGNet121_1+2+3+4 表示在框架 DGNet121 的双线程密集块之间, 每个数字代表相应的梯度图生成的位置和途径。

表 5 在 DGNet121 网络上的梯度特征比较实验
Table 5 Comparison experiment of gradient features on DGNet121 network

Method	Top-1 / %	Top-5 / %
DGNet121_1+2	65.70	97.67
DGNet121_1+3	62.00	94.33
DGNet121_1+4	67.00	97.00
DGNet121_1+2+3	64.70	95.00
DGNet121_1+2+4	63.30	98.33
DGNet121_1+2+3+4	63.00	96.67

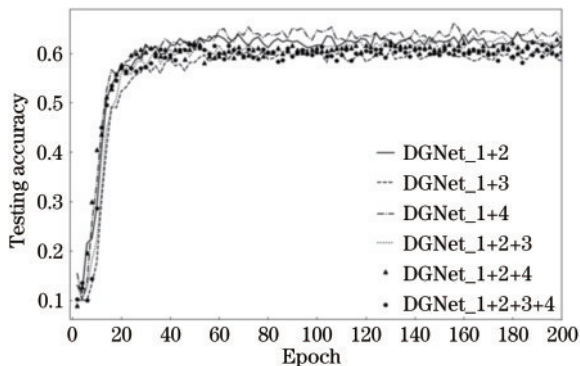


图 6 不同位置梯度特征的 DGNet 网络分类正确率

Fig. 6 Classification accuracy of DGNet network with different position gradient features

在实验 2 中, 从原始数据中整理出 5 组不同数据量的数据集, 采用 DGNet121 网络对 5 组数据集进行实验, 如表 6 所示, 其中 N_{training} 表示训练集中的图片数量,

N_{testing} 表示测试集中的图片数量, 对应的训练和测试损失曲线如图 7 所示。比较实验 A 和 B, 训练数据由 70 提升到 150 时, 训练损失收敛较慢, 但能显著提升识别正确率; 比较实验 C 和 D, 训练数据由 150 提升到 200 时, 虽然实验 D 的训练损失收敛速度较快, 但实验 C 和 D 两者在 200 步长时都达到稳定的状态, 且实验 C 的测试损失最小, 表明在小样本实验中, 实验 C 的组合识别效果最好, 因此达到最好的识别效果; 当固定训练数据为 200 张时比较实验 D 和 E, 当固定训练数据为 150 张时比对实验 B 和 C, 可知所提模型在不同训练数据量下提升了识别精度, 证明该模型具有稳健性。

表 6 不同比例的训练测试集在 DGNet121 网络上的比较实验
Table 6 Comparison experiment of different proportion training and test sets on DGNet121 network

Item	$N_{\text{training}} : N_{\text{testing}}$	Accuracy / %
A	70:30	64.00
B	150:30	69.30
C	150:50	74.40
D	200:50	64.70
E	200:100	67.90

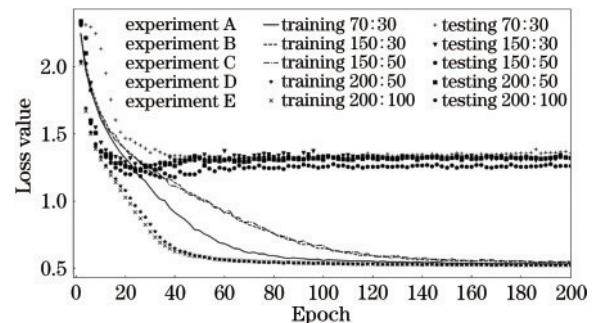


图 7 不同数据比例的训练测试损失曲线

Fig. 7 Training and testing loss with various data ratio

3.4.4 特征图可视化

最后, 以三个分类网络的可视化效果说明双线程密集块网络的有效性, 从 ResNet50、DenseNet121 和 DGNet121 网络中选取前几个卷积层和卷积块输出的

特征图作为可视化对象。如图 8 和图 9 所示,两种分类框架的第一张特征图都来自卷积核大小为 7×7 的卷积层,第二张特征图来自最大池化层的输出结果,蓝色表示晴天,绿色表示云的位置和大小,最后四张特征图分别来自 ResNet 的跳跃连接块和 DenseNet 的密集块。可以看出,图 9 的框架比图 8 更能提取到精细准确的云图特征,说明密集块适用于云图的特征提取。

最后,以可视化效果说明 ResNet50、DenseNet121

和 DGNNet121 三个分类网络的差异,分别如图 8~10 所示。ResNet50 和 DenseNet121 网络的第一张特征图都来自卷积核大小为 7×7 的卷积层,第二张特征图来自最大池化层的输出结果,最后四张特征图分别来自 ResNet 的跳跃连接块和 DenseNet 的密集块。对比图 8(c)和图 9(c),图 9(c)的特征图具有更为丰富的云图轮廓特征,说明 DenseNet121 描绘云图的能力比 ResNet50 优秀,能获得更多的云图特征信息。




图 8 ResNet50 网络的特征图可视化

Fig. 8 Visualization of characteristic graph of ResNet50 network




图 9 DenseNet121 网络的特征图可视化

Fig. 9 Visualization of characteristic graph of DenseNet121 network

图 10(a)~(d)表示第一条线程的密集块可视化,图 10(e)~(h)表示第二条线程的密集块可视化。对比同位置的图 10(f)和图 9(d),所提框架将云图的浅层

纹理特征和深层的语义信息相融合,不仅保留云图的浅层轮廓特征,而且将云图的多尺度特征也融入密集块网络,增强对云图特征的识别与分类性能。

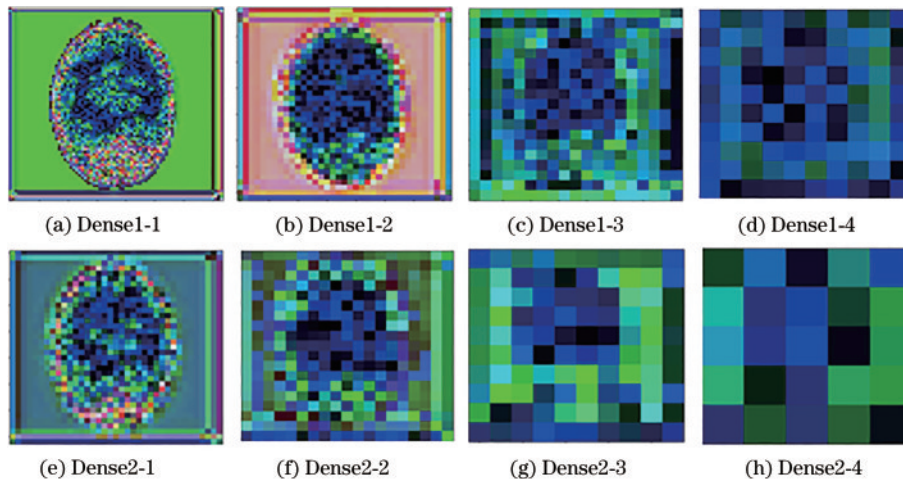


图 10 DGNNet121 网络的特征图可视化

Fig. 10 Visualization of characteristic graph of DGNNet121 network

4 结 论

随着计算机视觉技术的飞速发展,云图的种类识别技术得到了进一步的研究。另外,由于云图观测设

备的广泛使用,能够更为方便地获取大量的云图种类图像数据。云图种类识别区分作为气象观测研究的先验部分,采用智能识别技术对云图种类进行自动识别,将使气象观测研究的前期准备工作更便捷,也有助于

对极端天气的前期监控,方便人类社会的正常发展。

所提基于梯度算法的双线程密集块融合网络框架包含三个部分:改进密集块的线程结构,以双线程密集块融合的方式搭建新的模块;基于双线程的融合结构,增加网络损失函数计算的方式,使网络反向传播训练效果达到最优;首次将云图特征信息融合到梯度算法,得到不同尺寸大小的云图梯度信息融合图,并将双线程多尺度的梯度信息融合图通道数叠加,送入下一个密集块进行训练。该网络通过引入密集块卷积和梯度信息融合算法,能够有效提高云图种类分类准确性。以本研究形成的全天空成像仪云图数据库进行多组实验,实验结果表明,所提梯度信息融合算法能有效地将云图种类梯度特征与纹理信息结合,增强种类间差异性。与经典的图像分类框架 Inception_v3、ResNet50 和 DenseNet121 相比,所提框架的 Top-1 分别提升 4 个百分点、0.6 个百分点和 0.3 个百分点。通过增加损失函数,双线程密集块网络的平均精度可以提升 0.12 个百分点,方差更小更稳定。为进一步提高对云图分类精度,在今后的工作中将考虑更多的云图特征,通过改进网络的框架结构,进而更准确地实现对云图数据的自动分类。

参 考 文 献

- [1] Fabel Y, Nouri B, Wilbert S, et al. Applying self-supervised learning for semantic cloud segmentation of all-sky images[J]. *Atmospheric Measurement Techniques*, 2022, 15(3): 797-809.
- [2] Shaffery P, Habte A, Netto M, et al. Automated construction of clear-sky dictionary from all-sky imager data[J]. *Solar Energy*, 2020, 212: 73-83.
- [3] Azhar M A D M, Hamid N S A, Kamil W M A W M, et al. Daytime cloud detection method using the all-sky imager over PERMATApintar observatory[J]. *Universe*, 2021, 7(2): 41.
- [4] 孙学金, 刘磊, 高太长, 等. 基于模糊纹理光谱的全天空红外图像云分类[J]. *应用气象学报*, 2009, 20(2): 157-163.
Sun X J, Liu L, Gao T C, et al. Cloud classification of the whole sky infrared image based on the fuzzy uncertainty texture spectrum[J]. *Journal of Applied Meteorological Science*, 2009, 20(2): 157-163.
- [5] Cazorla A, Olmo F J, Alados-Arboledas L. Development of a sky imager for cloud cover assessment[J]. *Journal of the Optical Society of America A*, 2007, 25(1): 29.
- [6] Liu L, Sun X J, Chen F, et al. Cloud classification based on structure features of infrared images[J]. *Journal of Atmospheric and Oceanic Technology*, 2011, 28(3): 410-417.
- [7] Kaur R, Ganju A. Cloud classification in NOAA AVHRR imageries using spectral and textural features[J]. *Journal of the Indian Society of Remote Sensing*, 2008, 36(2): 167-174.
- [8] Li J, Menzel W P, Yang Z D, et al. High-spatial-resolution surface and cloud-type classification from MODIS multispectral band measurements[J]. *Journal of Applied Meteorology*, 2003, 42(2): 204-226.
- [9] 朱亚平, 白洁, 刘健文, 等. 基于 EOS/MODI 图像资料的多光谱云分类技术[M]//第十四届全国遥感技术学术交流会论文选集. 北京:中国海洋学会, 2003: 6.
Zhu Y P, Bai J, Liu J W, et al. Multi-spectral cloud classification based on EOS/MODI image data[M]//Selected Papers of the 14th National Academic Exchange Conference on Remote Sensing Technology. Beijing: Oceanographic Society of China, 2003: 6.
- [10] 朱亚平, 程周杰, 刘健文, 等. 多光谱云分类技术在锋面云系中的应用[J]. *热带气象学报*, 2009, 25(1): 66-72.
Zhu Y P, Cheng Z J, Liu J W, et al. Application of multi-spectral cloud classification technique in frontal cloud system[J]. *Journal of Tropical Meteorology*, 2009, 25(1): 66-72.
- [11] Jin W, Gong F, Tang B, et al. Cloud types identification for meteorological satellite image using multiple sparse representation classifiers via decision fusion[J]. *IEEE Access*, 2019, 7: 8675-8688.
- [12] Shenk W E, Holub R J, Neff R A. A multispectral cloud type identification method developed for tropical ocean areas with nimbus-3 MRIR measurements[J]. *Monthly Weather Review*, 1976, 104(3): 284-291.
- [13] Inoue T. A cloud type classification with NOAA 7 split-window measurements[J]. *Journal of Geophysical Research: Atmospheres*, 1987, 92(D4): 3991-4000.
- [14] 朱彪, 杨俊, 吕伟涛, 等. 基于 KNN 的地基可见光云图分类方法[J]. *应用气象学报*, 2012, 23(6): 721-728.
Zhu B, Yang J, Lü W T, et al. Ground-based visible cloud image classification method based on KNN algorithm[J]. *Journal of Applied Meteorological Science*, 2012, 23(6): 721-728.
- [15] Heinle A, Macke A, Srivastav A. Automatic cloud classification of whole sky images[J]. *Atmospheric Measurement Techniques*, 2010, 3(3): 557-567.
- [16] Zhuo W, Cao Z G, Xiao Y. Cloud classification of ground-based images using texture-structure features[J]. *Journal of Atmospheric and Oceanic Technology*, 2014, 31(1): 79-92.
- [17] Ye L, Cao Z G, Xiao Y, et al. Supervised fine-grained cloud detection and recognition in whole-sky images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(10): 7972-7985.
- [18] Tang Y Z, Yang P L, Zhou Z M, et al. Improving cloud type classification of ground-based images using region covariance descriptors[J]. *Atmospheric Measurement Techniques*, 2021, 14(1): 737-747.
- [19] Wang Y, Wang C H, Shi C Z, et al. A selection criterion for the optimal resolution of ground-based remote sensing cloud images for cloud classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(3): 1358-1367.
- [20] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.

- [21] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2021-05-04]. <https://arxiv.org/abs/1409.1556>.
- [22] 马圣杰, 郝士琦, 赵青松, 等. 基于深度卷积神经网络的大气湍流强度估算[J]. 中国激光, 2021, 48(4): 0401018.
Ma S J, Hao S Q, Zhao Q S, et al. Atmospheric turbulence intensity estimation based on deep convolutional neural networks[J]. Chinese Journal of Lasers, 2021, 48(4): 0401018.
- [23] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA. New York: IEEE Press, 2015.
- [24] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [25] 邓志良, 李磊. 基于改进残差网络的中式菜品识别模型[J]. 激光与光电子学进展, 2021, 58(6): 0610019.
Deng Z L, Li L. Chinese food recognition model based on improved residual network[J]. Laser & Optoelectronics Progress, 2021, 58(6): 0610019.
- [26] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [27] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.
- [28] 杨倩文, 周克. 基于改进双线性细粒度模型的压板状态识别[J]. 激光与光电子学进展, 2021, 58(20): 2010007.
Yang Q W, Zhou K. Press-plate state recognition based on improved bilinear fine-grained model[J]. Laser & Optoelectronics Progress, 2021, 58(20): 2010007.
- [29] Shi M Y, Xie F Y, Zi Y, et al. Cloud detection of remote sensing images by deep learning[C]//2016 IEEE International Geoscience and Remote Sensing Symposium, July 10-15, 2016, Beijing, China. New York: IEEE Press, 2016: 701-704.
- [30] Ye L, Cao Z G, Xiao Y, et al. Ground-based cloud image categorization using deep convolutional visual features[C]//2015 IEEE International Conference on Image Processing, September 27-30, 2015, Quebec City, QC, Canada. New York: IEEE Press, 2015: 4808-4812.
- [31] Ma J Y, Zhang T J, Jing G D, et al. Notice of violation of IEEE publication principles: ground-based cloud image recognition system based on multi-CNN and feature screening and fusion[J]. IEEE Access, 2020, 8: 173949-173960.
- [32] Ye L, Cao Z G, Xiao Y. DeepCloud: ground-based cloud image categorization using deep convolutional features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(10): 5729-5740.
- [33] Shi C Z, Wang C H, Wang Y, et al. Deep convolutional activations-based features for ground-based cloud classification [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(6): 816-820.
- [34] Phung V H, Rhee E J. A high-accuracy model average ensemble of convolutional neural networks for classification of cloud image patches on small datasets[J]. Applied Sciences, 2019, 9(21): 4500.
- [35] Zhang J L, Liu P, Zhang F, et al. CloudNet: ground-based cloud classification with deep convolutional neural network[J]. Geophysical Research Letters, 2018, 45(16): 8665-8672.
- [36] Liu S, Li M, Zhang Z, et al. Multi-evidence and multi-modal fusion network for ground-based cloud recognition [J]. Remote Sensing, 2020, 12(3): 464.
- [37] Zhao M Y, Chang C H, Xie W B, et al. Cloud shape classification system based on multi-channel CNN and improved FDM[J]. IEEE Access, 2020, 8: 44111-44124.