

基于残差网络的地基云图识别方法研究^{*}

宋文强^{1,2} 徐伟^{1,2} 冯琳^{1,2}

(1.南京信息工程大学气象灾害预报预警与评估协同创新中心 南京 210044;

2.南京信息工程大学江苏省气象探测与信息处理重点实验室 南京 210044)

摘要:地基云的精细化识别对气候预测和气象研究具有重要的意义。针对目前地基云识别准确率低、泛化性差、不利于边缘化部署的问题,提出了基于残差网络的地基云图识别模型,命名为GBcNet。设计的模型由1个卷积层、2个池化层、5个残差块以及1个全连接层构成,利用第1个卷积层和第1个池化层初步提取特征信息并降低特征图大小,通过残差块提取更多的特征信息,同时抑制网络的过拟合和梯度消失,最后利用另1个池化层降低特征图的大小,并通过全连接层输出识别结果。利用数据集对模型进行训练和测试,实验结果表明,GBcNet模型对数据集的综合平均准确率达到了96.02%,11种类别地基云的识别精确率均在93%~99%,且具有更好的泛化性,单个类别和整体识别性能均优于其他模型。进一步采用SWIMCAT数据集对模型进行实验,综合识别准确率达99.7%,证明模型对地基云图识别具有普适性。模型结构简单,相较于其他模型,更有利于边缘化部署。

关键词:地基云图;残差网络;CCSN数据集;边缘化部署

中图分类号:TP183;P412.15 **文献标识码:**A **国家标准学科分类代码:**520.2060

Research on ground-based cloud recognition method based on residual network

Song Wenqiang^{1,2} Xu Wei^{1,2} Feng Lin^{1,2}

(1. Collaborative Innovation Center on Forecast and Evaluation of Meteorological Disasters, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. Jiangsu Key Laboratory of Meteorological Observation and Information Processing, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: The fine identification of ground-based clouds is of great significance for climate prediction and meteorological research. Aiming at the current problems of low accuracy of ground-based cloud recognition, poor generalization, and detrimental deployment of marginalized deployment, a ground-based cloud map recognition model based on residual network is proposed, named GBcNet. The designed model consists of one convolutional layer, two pooling layers, five residual blocks and one fully connected layer, using the first convolutional layer and the first pooling layer to initially extract feature information and reduce the feature map size, and extract more feature information through the residual block, while suppressing the overfitting and gradient disappearance of the network, and finally using another pooling layer to reduce the size of the feature map, and finally output the recognition results through the fully connected layer. The experimental results show that the comprehensive average accuracy of GBcNet model on the dataset reaches 96.02%, and the recognition accuracy of 11 categories of ground-based clouds is between 93% and 99%, and has better generalization, and the recognition performance of single category and overall is better than that of other models. Furthermore, the SWIMCAT dataset was used to experiment with the model, and the comprehensive recognition accuracy reached 99.7%, which proved that the model was universally applicable to the recognition of ground-based cloud maps. The model has a simple structure, which is more conducive to marginalized deployment than other models.

Keywords: ground-based cloud map; residual network;CCSN dataset;marginalized deployment

0 引言

云是由大气中遇冷液化或凝华的水蒸气组成的可见聚

合物,覆盖了地球表面约60%的面积^[1],对地球的水文循环、气候和能量平衡有着巨大的影响^[2-3],因此,准确识别云的类别对气候预测和气象研究具有重要的意义。世界气象

组织针对云的形状、结构、特征和高度将云划分为 3 族 10 属 29 类,地基云图的识别主要按照云属进行分类,即 10 种类别的云。地基云具有种类多,变化快,相似、容易与天空背景融合的特点,且同一种类的云因受到地域、天气、时间等因素的影响也会呈现一定的差异性,这给地基云的精细化识别带来了很大的困难^[4]。

目前,部分气象观测站仍依靠观测员人工完成云分类,由于云的种类复杂且人工识别工作量大,给云识别带来了很大的困难,另外,人工识别容易受到观测员情绪和经验的影响,识别的准确率很难得到保证^[5]。为解决人工识别带来的弊端,近些年来,越来越多的研究人员开始进行自动化云识别的研究。2015 年,Dev 等^[6]创建了 SWIMCAT 数据集,并提出了一种改进的基于文本的分类方法,通过提取云的颜色和纹理信息实现云分类,准确率达到了 95%,但该数据集仅有 5 种云类别(包含纯天空),不符合世界气象组织对地基云图的标准分类;2018 年,Zhang 等^[7]创建了 CCSN 数据集,并提出了一种基于深度学习的卷积神经网络模型 CloudNet,准确率达到了 88%,CCSN 数据集在世界气象组织规定的 10 种标准类别的基础上又增加了一种尾迹云的类别,其应用价值较高,但模型识别准确率不高;2019 年,Fang 等^[8]创建了 HBMCD 数据集,并通过 DenseNet201 网络模型进行微调实现地基云图识别,准确率达到了 96.55%,但网络层数达到 201 层,难以实现边缘化部署;2020 年,Liu 等^[9]提出了一种基于多证据多模态融合网络的地基云识别方法,该方法通过在统一架构下融合异构特征来学习扩展云的信息,并利用自建 MGCD 数据集进行验证,准确率达到了 88.63%,其中 MGCD 数据集包含 7 种类别的地基云,不符合世界气象组织规定的标准类别,在实际应用过程中不具有泛化性;2022 年,Li 等^[10]提出了将 Transformer 和 CNN 模型结合的方法实现地基云分类,并在 ASGC、CCSN 和 GCD 3 个数据集上进行了验证,准确率分别达到了 94.24%、92.73% 和 93.57%,准确率较高,但对 CCSN 数据集中的卷层云和层云的识别准确率较低,分别为 89.14% 和 87.21%,其原因可能是两种云的形状和排列方式与其他地基云相似造成的。

综上,地基云图识别领域存在识别准确率低、泛化性差、所使用的数据集不是世界气象组织规定的标准类别和网络模型不利于边缘化部署的问题。深度学习算法为地基云图识别提供了一种新的途径。基于此,本文提出一种基于残差网络的卷积神经网络模型 GBcNet,并利用符合世界气象组织分类标准的 CCSN 数据集进行测试验证。

1 地基云图数据集 CCSN

1.1 CCSN 数据集的特点

CCSN 数据集是一个基于世界气象标准建立的数据集,并在 10 种标准地基云类别的基础上添加了一种尾迹云的类别,共 11 种类别,2 543 张云图,CCSN 数据集的详细

信息如表 1 所示。其中,尾迹云是由飞机发动机排放出来的废气与周围空气混合以及水蒸气的冷凝而形成的一种特殊云系,相比于自然形成的云层,它会影响对流层和平流层交汇处的卷云的覆盖率,从而对气候产生影响^[11]。CCSN 数据集中的尾迹云的类别提高了数据集的应用价值,同时也促进了尾迹云在气候变化领域的研究。

表 1 CCSN 数据集的详细信息

类别	简写	数量	特点
积云	Cu	182	棉花状,云体垂直向上
积雨云	Cb	242	花菜状或砧状,云底阴暗
层积云	Sc	340	云块分布松散,呈灰白色或灰色
层云	St	202	云体均匀成层,覆盖面积大,多呈灰色
雨层云	Ns	274	云层较厚且均匀,呈暗灰色
高层云	As	188	灰白色或灰色,像一种带有条纹的幕
高积云	Ac	221	扁圆形、瓦片状等,呈暗灰色
卷云	Ci	139	白色,呈丝状、羽毛、马尾、簇状等
卷层云	Cs	287	白色半透明的薄幕状
卷积云	Cc	268	似鳞片或球状的小云块,呈白色
尾迹云	Ct	200	飞机发动机废气产生的线状云

1.2 数据集扩充及划分

为减小模型在训练过程中出现的过拟合现象,提高模型的鲁棒性和泛化性,使用数据增强的方法对数据集进行扩充。利用图像模糊、对比度增强、镜像翻转、加入高斯噪声的方法将数据集扩充到 12 715 张,图像增强效果图如图 1 所示。另外,按照 9:1 的比例将扩充后的数据集划分为训练集和测试集。



图 1 图像增强效果图

2 基于残差网络的地基云图识别方法

2.1 残差网络原理

残差网络是由 He 等^[12]于 2016 年提出的一种卷积神经网络结构, 残差网络使用残差块作为网络的基本单元, 通过输入与输出相加的方式来引入所谓的“残差连接”。由于地基云图具有种类多, 变化快, 相似、容易与天空背景融合的特点, 普通的浅层卷积神经网络无法提取到更多的图像特征, 无法对其准确识别, 如果简单地通过增加网络深度来解决这个问题, 那么会造成网络模型难以收敛, 即恒等映射函数 $H(x) = x$ 很难实现拟合, 但是如果将网络设计为 $H(x) = F(x) + x$, 即直接把恒等映射作为网络的一部分, 那么可以直接将拟合恒等映射函数转化为拟合残差函数 $F(x) = H(x) - x$ 的问题, 只要将 $F(x)$ 拟合为 0, 就能构成一个恒等映射函数 $H(x) = x$, 这显然比拟合恒等映射函数更加容易^[13]。残差块结构如图 2 所示, 假设 x 和 $H(x)$ 分别为残差块的输入和输出, $F(x)$ 为学习的残差映射, 整个残差块就是将输入 x 经过若干个卷积和 ReLU 激活函数后, 通过跳链接将输入与输出叠加到一起^[14]。其中为了保持输入 x 与输出的维数相同, 通常需要利用 1×1 的卷积核 w 对输入 x 进行降维或升维处理, $H(x)$ 可表示为:

$$H(x) = F(x) + w \times x \quad (1)$$

输入数据的可以从任意低层直接传播到高层, 解决了由于网络层数加深而带来的梯度消失和网络退化的问题, 同时大幅度抑制过拟合现象, 提高训练速度和准确率^[15-16]。

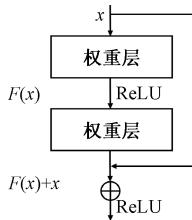


图 2 残差块结构

2.2 地基云识别网络模型的设计

为保证地基云图识别任务的高准确率和实时性, 在网络模型中加入残差网络结构, 搭建了基于残差网络的卷积神经网络模型 GBcNet, 在保证地基云图特征提取能力的同时使网络具有更快的训练速度和推理速度, 利用更少的网络层数实现更高的准确率。设计的模型 GbcNet 的网络结构如图 3 所示, 输入为一幅 224×224 的 3 通道 RGB 图像, 首先经过卷积核大小为 7×7 的卷积层提取浅层信息, 输出 64 通道 112×112 的特征图, 然后利用池化核为 3×3 的最大池化层降采样为 56×56 的特征图, 随后依次经过残差模块 Res_a 和 Res_b, 输出 256 通道 14×14 的特征图, 接着利用自适应平均池化层将特征图降采样为 1×1 的大小, 最后通过全连接层和 Softmax 分类器输出 11 种地基云图的预测概率。网络模型 GBcNet 所有的卷积操作之后均进行了

批归一化(batch normalization, BN)处理, 批归一化可以提高模型的泛化性能和训练速度。

残差模块 Res_a 的输入依次经过残差块 Res_a1 和残差块 Res_a2, 最终输出的特征图大小为 28×28 , 通道数为 128。首先经过残差块 Res_a1 的第 1 个卷积层提取更多的特征, 该卷积层的卷积核的大小为 1×1 , 通道数和特征图大小保持不变, 随后经过一个卷积核大小为 3×3 , 步长为 2 的卷积层, 并将通道数增加到 128, 输出的特征图大小为 28×28 , 最后将输出与残差块 Res_a1 的输入相加, 由于输出特征图的通道数和特征图大小发生了变化, 进行残差连接之前需要将残差块 Res_a1 的输入特征图经过一个卷积核大小为 1×1 , 步长为 2 的卷积层对其进行降采样, 并将通道数增加到 128, 残差块 Res_a1 最终输出的特征图大小为 28×28 , 通道数为 128。残差块 Res_a2 由两个卷积层构成, 第 1 个卷积层卷积核大小为 1×1 , 第 2 个卷积层卷积核大小为 3×3 , 步长均为 1, 对特征图的大小和通道数不做改变。

残差模块 Res_b 的输入(残差模块 Res_a 的输出)依次经过残差块 Res_b1、残差块 Res_b2 和残差块 Res_b3, 最终输出的特征图大小为 14×14 , 通道数为 256。首先将输入经过残差块 Res_b1 的第 1 个卷积层, 该卷积层的卷积核大小为 1×1 , 步长为 1, 保持通道数和特征图大小不变, 第 2 个卷积层的卷积核大小为 3×3 , 步长为 2, 输出通道数为 256, 特征图大小为 14×14 , 最后将输出与 Res_b1 降采样和通道数增加后的输入进行相加, Res_b1 的输出的特征图大小为 14×14 , 通道数为 256。残差块 Res_b2 和残差块 Res_b3 的结构相同, 且与残差模块 Res_a 中的残差块 Res_a2 相同, 均由两个卷积层构成, 对输入的通道数和特征图大小不做改变。

3 实验与分析

3.1 实验平台及训练参数

实验采用的 GPU 型号为 NVIDIA TELSA P100 16 G, 所用的工具包版本和硬件环境为 CUDA 11.4, PyTorch 1.13.0, Python 3.7.12。

为了提高训练速度, 训练使用等步长调整学习率, 初始学习率为 0.001, 每训练 30 次将学习率降低为原来的 0.5 倍, 训练迭代总次数为 300, 学习率变化曲线如图 4 所示。另外, 批处理大小设置为 128, 模型采用最常用的 Adam 优化器进行优化, 损失函数使用与 Softmax 分类器相结合的交叉熵损失函数, 其计算公式如式(2)所示。

$$L = \frac{1}{N} \sum_i L_i = \frac{1}{N} \sum_i -[y_i \cdot \log(p_i) + (1 - y_i) \cdot \log(1 - p_i)] \quad (2)$$

式中: y_i 表示样本 i 的标签, 正类为 1, 负类为 0; p_i 表示样本 i 预测为正的概率。

3.2 评价指标

评价指标能够客观地反映深度学习模型的有效性, 实

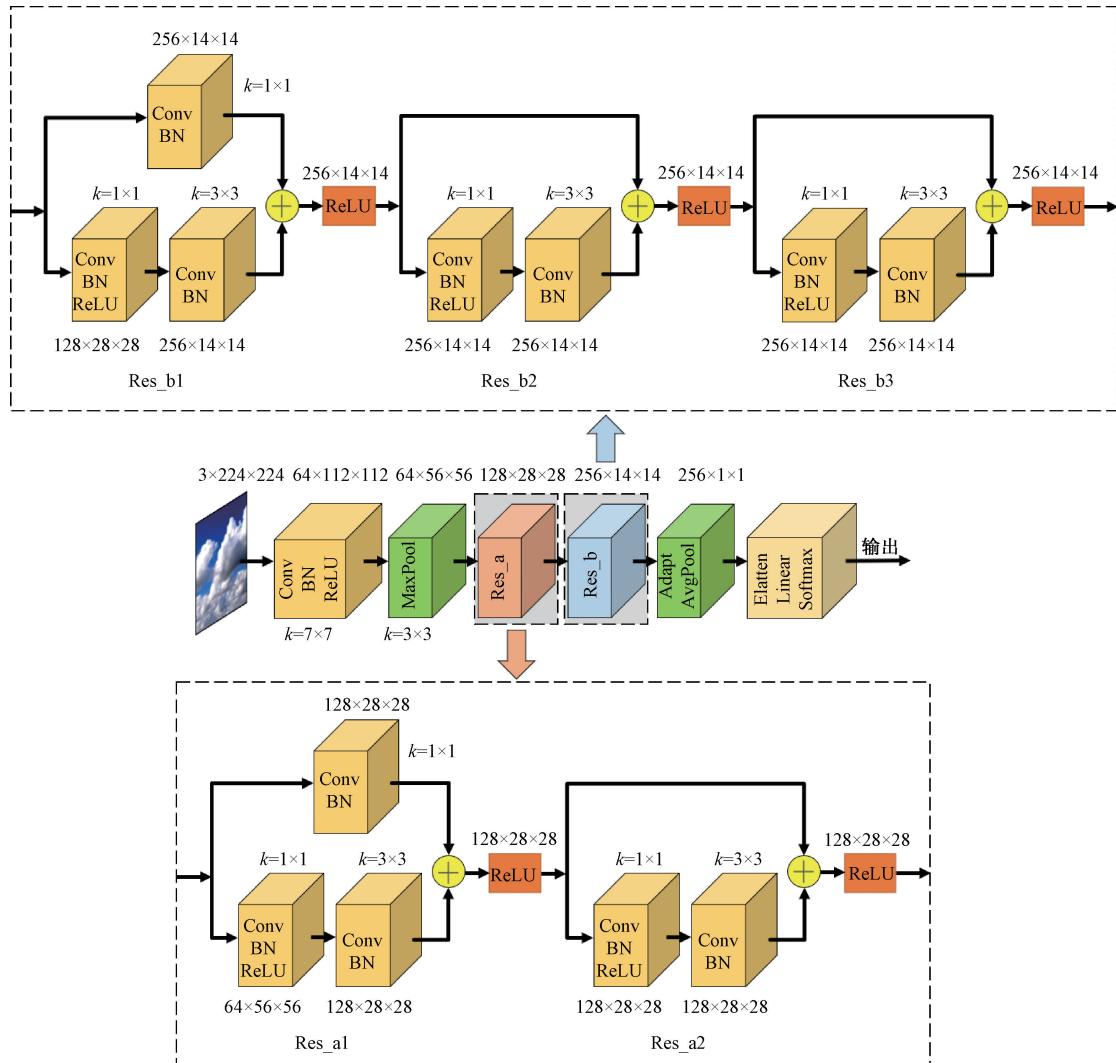


图 3 设计的模型 GBcNet 网络结构

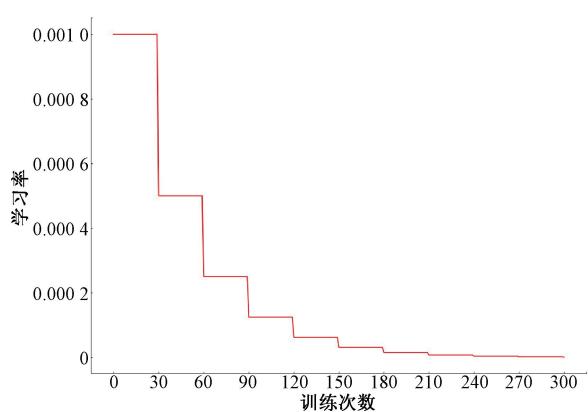


图 4 学习率变化曲线

验使用图像分类中最常用的混淆矩阵、准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1 值(F-measure)、宏平均(Macro-averaged)和微平均(Micro-average)等指标来

评价模型的有效性,其中混淆矩阵、精确率、召回率和 F1 值反映模型单个类别的分类性能,准确率、宏平均和微平均反映模型整体分类性能,计算公式如式(3)~(10)所示。

精确率:

$$Precision(P) = \frac{TP}{TP + FP} \quad (3)$$

召回率:

$$Recall(R) = \frac{TP}{TP + FN} \quad (4)$$

F1 值:

$$F1 = \frac{2 \times P \times R}{P + R} \quad (5)$$

准确率:

$$Accuracy(A) = \frac{\sum_{i=1}^n TP_i}{\sum_{i=1}^n TP_i + FN_i} \quad (6)$$

精确率宏平均:

$$P_{macro} = \frac{1}{n} \sum_{i=1}^n P(i) \quad (7)$$

召回率宏平均:

$$R_{macro} = \frac{1}{n} \sum_{i=1}^n R(i) \quad (8)$$

精确率微平均:

$$R_{micro} = \frac{\sum_{i=1}^n TP_i}{\sum_{i=1}^n TP_i + FP_i} \quad (9)$$

召回率微平均:

$$R_{micro} = \frac{\sum_{i=1}^n TP_i}{\sum_{i=1}^n TP_i + FN_i} \quad (10)$$

式中: TP 为正样本预测为正的数量, FP 为负样本预测为正的数量, FN 为正样本预测为负的数量, TN 为负样本预测为负的数量, n 为类别总数。

3.3 实验结果及分析

利用扩充后的 CCSN 地基云图数据集进行实验, 样本图像输入网络之前统一缩放至 224×224 的尺寸, 并对其进行归一化处理, 归一化使用的均值 $mean$ 和方差 std 分别如式(11)和(12)所示。式中的均值和方差根据数据集计算所得, 为 RGB 三通道的均值和方差。

$$mean = [0.477\ 687\ 37\ 0.524\ 547\ 68\ 0.567\ 016\ 96] \quad (11)$$

$$std = [0.219\ 461\ 8\ 0.194\ 070\ 78\ 0.178\ 665\ 02] \quad (12)$$

训练过程中网络模型在训练集上的损失函数曲线如图 5 所示, 模型迭代训练到 300 轮时, 损失函数已经拟合, 趋近于 0, 基本保持不变。模型训练过程中, 在训练集和测试集上的准确率的曲线如图 6 所示, 从图中可以看出, 模型在训练集和测试集上的准确率随着训练次数的增加已经拟合, 并且在训练集和测试集上均有较高的准确率, 泛化性较好。为更好地评价模型对单个类别的识别能力, 使用混淆矩阵、精确率、召回率以及 $F1$ 值对其进行评价。混淆矩阵如图 7 所示, 混淆矩阵反映了每一个类别的召回率, 即该类别中预测正确的个数占该类别总数的比例, 矩阵对角线颜色越深, 则识别效果越好, 图中每一个类别的召回率都在 96% 左右, 表明本模型对所有类别都有较高的识别召回率。每一个类别的精确率、召回率和 $F1$ 值如表 2 所示, 精确率反映预测为正的样本中实际为正的概率, 召回率反映实际为正的样本中被预测为正的概率, $F1$ 值是对精确率和召回率的综合, 即能体现精确率又能体现召回率。GBcNet 模型在精确率、召回率和 $F1$ 值上均表现出了优秀的性能, 尤其是尾迹云的识别精确率达到 100%。

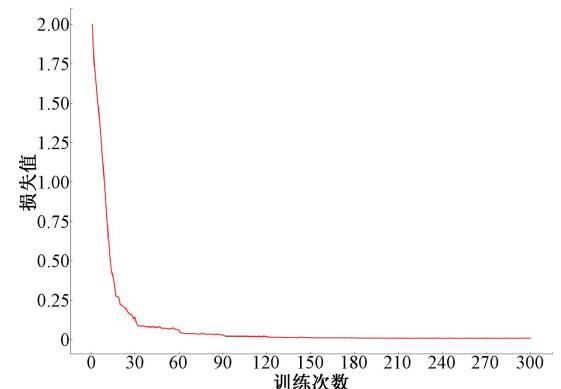


图 5 损失函数曲线

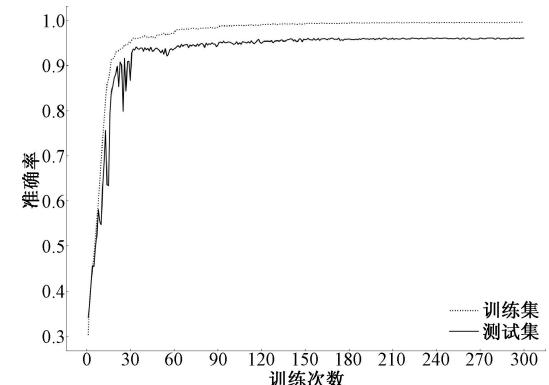


图 6 准确率曲线

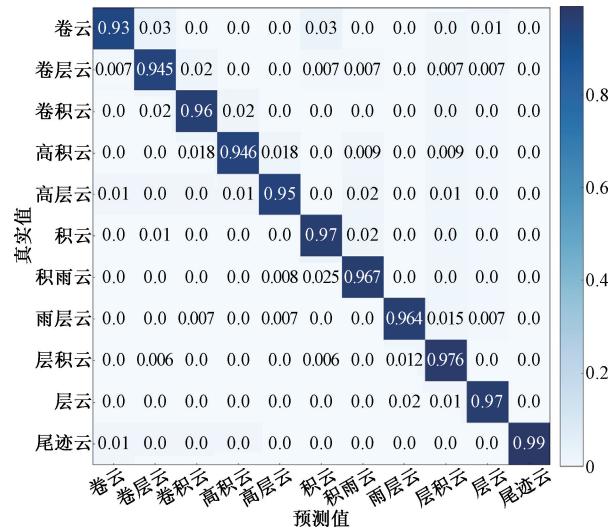


图 7 GBcNet 模型在数据集 CCSN 上混淆矩阵

另外, 为了更好的对 GBcNet 模型的整体性能做出评价, 采用宏平均和微平均来计算整体的精确率和召回率, 同时对宏平均和微平均求平均, 整体性能评估结果如表 3 所示, 模型的整体评分在 95.93%~96.06%, 平均分数在 96.02%, 证明了 GBcNet 模型的有效性和优秀的泛化性。

表 2 精确率、召回率、F1 值

云类别	精确率	召回率	F1 值
卷云	0.955	0.93	0.941
卷层云	0.951	0.945	0.947
卷积云	0.955	0.96	0.955
高积云	0.963	0.946	0.954
高层云	0.957	0.95	0.952
积云	0.926	0.967	0.946
积雨云	0.951	0.967	0.959
雨层云	0.971	0.964	0.98
层积云	0.965	0.976	0.97
层云	0.97	0.97	0.97
尾迹云	1	0.99	0.995

表 3 整体性能评估结果

P_{macro}	R_{macro}	P_{micro}	R_{micro}	平均
0.960 3	0.959 3	0.960 6	0.960 6	0.960 2

3.4 对比实验及分析

1) 模型对比分析

采用相同的 CCSN 地基云图数据集、相同的图像预处理方法和相同的训练训练方法对 AlexNet、VGG16、ResNet34、CloudNet 以及 Li 等提出的网络模型分别进行训练,采用召回率指标对模型的单个类别分类效果进行比较,对比试验各类别召回率散点图如图 8 所示。

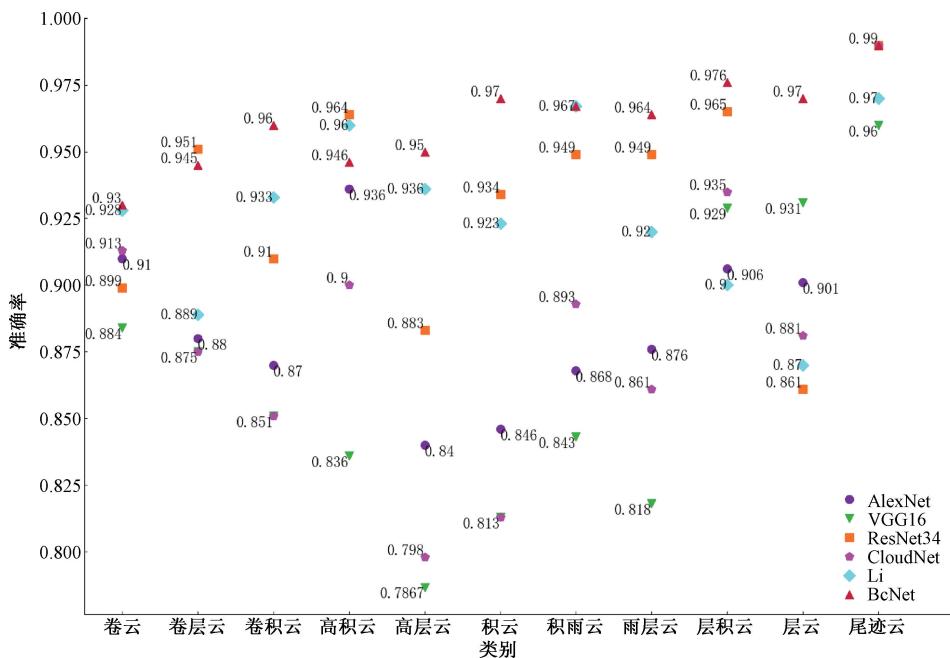


图 8 对比试验各类别准确率散点图

AlexNet^[17]是 Alex 等在 2012 年提出的经典卷积神经网络模型,在 ISLVRC 2012 竞赛上取得了冠军,将图像分类的准确率由传统的 70%+ 提升到了 80%+,自此,深度学习开始迅速发展。AlexNet 模型在卷云、高积云、层积云、层云和尾迹云上都有较高的召回率,分别达到了 91%、93.6%、90.6%、90.1% 和 99%,但在其他类别上的分类效果较差,其中对高层云和积云的识别率仅为 84%。

VGG16^[18]是 Simonyan 等在 2014 年提出的网络模型,由 13 层卷积层和 3 层全连接层构成,使用了较深的网络层。VGG16 模型在层积云、层云和尾迹云上的识别率较高,分别达到了 92.9%、93.1% 和 96%,但在其他类别上的分类效果很不理想,大部分类别地基云的识别率在 85% 以下,其中在高层云上的识别率仅有 78.67%。

ResNet34 是何凯明等于 2016 年提出的网络模型,首次引入了残差网络的概念,缓解了卷积神经网络中增加网络深度带来的梯度消失问题。ResNet34 模型对大部分类

别地基云的识别率均能达到 90% 以上,卷积云、高积云、层积云和尾迹云的识别率甚至达到了 95% 以上,分别为 95.1%、96.4%、96.5% 和 99%,但是层云的识别准确率不高,仅为 86.1%。

CloudNet 是 Zhang 等 2018 年针对 CCSN 数据集提出的网络模型。CloudNet 模型对于卷云、高积云、层积云和尾迹云的识别率较高,达到了 90% 以上,分别为 91.3%、90%、93.5% 和 99%,但其他类别的识别率不高,高层云的识别率仅有 79.8%。

Li 等 2022 年提出了 Transformer 和卷积神经网络相结合的网络模型。Li 的网络模型对 CCSN 数据集的大部分类别地基云的识别率都达到了 90% 以上,高积云、积雨云和尾迹云的识别准确率甚至达到了 95% 以上,分别为 96%、96.7% 和 97%,但是对于卷积云和层云的识别准确率不理想,仅为 88.9% 和 87%。

AlexNet、VGG16、ResNet34、CloudNet 以及 Li 等提

出的网络模型对于部分种类地基云的识别率较高,但是个别种类地基云的识别率较低,本文提出的 GBcNet 模型对于所有类别的识别率均在 95% 左右,大部分类别的识别准确率在 96% 以上,相比于其他模型具有明显优势。

为更好的评估各模型的整体性能,对宏平均准确率和微平均准确率求平均,得到平均准确率,各模型整体性能评估结果如表 4 所示。AlexNet、VGG16、ResNet34、CloudNet 以及 Li 等人提出的网络模型的平均准确率分别为 89.3%、86.8%、93.5%、88.4% 和 92.5%。本文提出的 GBcNet 模型的平均准确率为 96.02%,与经典网络模型 AlexNet、VGG16 和 ResNet34 相比,GBcNet 模型在地基云图识别方面具有明显优势,与 Zhang 等提出的 CloudNet 模型和 Li 等提出的网络模型相比平均准确率分别提高了 7.62% 和 3.52%,证明 GBcNet 模型具有更好的泛化性和更高的应用价值。

表 4 各模型的整体性能评估结果

模型	平均准确率
AlexNet	0.893
VGG16	0.868
ResNet34	0.935
CloudNet	0.884
Li	0.925
本文提出的模型 GBcNet	0.960 2

2) 普适性分析

为了验证 GBcNet 模型的普遍适用性,利用 SWIMCAT 数据集^[19]对模型进行训练,SWIMCAT 数据集共有 5 种类别的云,分别为 Clear sky、Patterned clouds、Thick dark clouds、Thick white clouds 和 Veil clouds,采用与 CCSN 数据集相同的扩充方法对 SWIMCAT 数据集进行扩充。

模型 GBcNet 在 SWIMCAT 数据集上的混淆矩阵如图 9 所示,从图中可以看出,除 Clear sky 外,其他类别的精

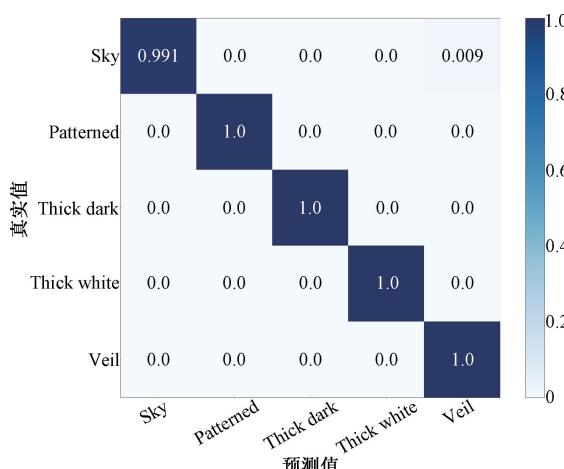


图 9 GBcNet 在 SWIMCAT 数据集上的混淆矩阵

度均达到了 100%。SWIMCAT 数据集中部分 Clear sky 类别的云图中存在云的噪点,和 Veil clouds 类似,导致 Clear sky 类别的性能不佳,但精度也达到了 99.1%。SWIMCAT 数据集上的整体性能评估结果如表 5 所示,从表中可以看出,模型 GBcNet 在 SWIMCAT 数据集上的整体性能优越,平均准确率达到了 99.7%。无论是单个类别的性能,还是整体性能,模型 GBcNet 在 SWIMCAT 数据集上均具有强大的分类能力,证明模型 GBcNet 具有较高的普遍适用性。

表 5 SWIMCAT 数据集上的整体性能评估结果

P_{macro}	R_{macro}	P_{micro}	R_{micro}	平均
0.995 4	0.998 2	0.997 3	0.997 3	0.997

4 结 论

利用基于残差网络的卷积神经网络模型 GBcNet 实现地基云图识别,相较于其他模型,具有以下优势:

世界气象标准数据集:利用基于世界气象标准建立的 CCSN 数据集训练模型,提高了模型的应用价值。由于 CCSN 数据集中包含一种尾迹云的类别,更有利于模型在气候预测方面的研究。

识别效果:本文提出的基于残差网络的卷积神经网络模型 GBcNet 在基地云图识别方面具有明显优势。使用 CCSN 数据集对 GBcNet 模型进行验证,将本文提出的模型与经典模型以及现有方法进行对比,准确率最高,达到了 96.02%,与经典网络模型 AlexNet、VGG16 和 ResNet34 相比,无论是单类别的识别精度还是整体分类精度,GBcNet 模型都表现出了明显的优势,证明了 GBcNet 模型在地基云图识别方面的有效性,与 Zhang 等提出的 CloudNet 模型和 Li 等提出的网络模型相比,平均准确率分别提高了 7.62% 和 3.52%,表明本文提出的模型 GBcNet 具有更好的泛化性。另外,利用 SWIMCAT 数据集对模型进行验证,仍然能够维持很高的准确率,表明模型具有较高的普适性。

硬件实施:本文提出的 GBcNet 模型仅使用 1 个卷积层、2 个池化层、5 个残差块和 1 个全连接层,网络层数较浅,边缘化部署难度较小,而且准确率较高,为后续的边缘化部署提供了可能。

论文中的模型通过 PC 端的 GPU 进行验证,在后续的研究中,可以将模型通过 FPGA 进行边缘化部署,从而进一步提高应用价值和扩大应用场景。

参考文献

- [1] TANG Y, YANG P, ZHOU Z, et al. Improving cloud type classification of ground-based images using region covariance descriptors [J]. Atmospheric Measurement Techniques, 2021, 14(1): 737-747.

- [2] NAUD C M, BOOTH J F, DEL GENIO A D. The relationship between boundary layer stability and cloud cover in the post-cold-frontal region[J]. *Journal of Climate*, 2016, 29(22): 8129-8149.
- [3] CUI F, JU R R, DING Y Y, et al. Prediction of regional global horizontal irradiance combining ground-based cloud observation and numerical weather prediction[J]. *Advanced Materials Research*, 2015, 1073: 388-394.
- [4] 王敏, 王康, 庄志豪, 等. 卷积神经网络地基云图识别的特征可视化方法[J]. *实验室研究与探索*, 2021, 40(11): 38-41.
- [5] 贾克斌, 张亮, 刘鹏宇, 等. 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*, 2021, 47(5): 489-499.
- [6] DEV S, LEE Y H, WINKLER S. Categorization of cloud image patches using an improved texton-based approach, 2015[C]. IEEE, 2015.
- [7] ZHANG J, 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.
- [8] FANG C, JIA K, LIU P, et al. Research on cloud recognition technology based on transfer learning[C]. IEEE, 2019.
- [9] 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.
- [10] LI X, QIU B, CAO G, et al. A novel method for ground-based cloud image classification using transformer[J]. *Remote Sensing*, 2022, 14(16): 3978.
- [11] 张敬林, 张国宇, 杨全, 等. 飞机尾迹云识别及其辐射强迫的研究进展[J]. *大气科学学报*, 2018, 41(5): 577-584.
- [12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 770-778.
- [13] 朱阳光, 刘瑞敏, 黄琼桃. 基于深度神经网络的弱监督信息细粒度图像识别[J]. *电子测量与仪器学报*, 2020, 34(2): 115-122.
- [14] 鲍光海, 林善银, 徐林森. 基于改进型卷积网络的汽车高度调节器缺陷检测方法[J]. *仪器仪表学报*, 2020, 41(2): 157-165.
- [15] 佟健颉, 黎英, 王一旋. 基于深度残差网络的短时交通流量预测[J]. *电子测量技术*, 2019, 42(18): 85-89.
- [16] 翟翔宇, 杨风暴, 吉琳娜, 等. 面向空中目标作战意图分析的标准化全连接残差网络模型[J]. *国外电子测量技术*, 2019, 38(12): 1-6.
- [17] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [18] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. ArXiv Preprint, 2014, ArXiv: 1409.1556.
- [19] DEV S, NAUTIYAL A, LEE Y H, et al. CloudSegNet: A deep network for nychthemeron cloud image segmentation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(12): 1814-1818.

作者简介

宋文强, 硕士研究生, 主要研究方向为信号处理及 FPGA 应用。

E-mail: songwq0105@163.co

徐伟(通信作者), 博士, 正高级实验师, 硕士生导师, 主要研究方向为气象观测方法及仪器。

E-mail: xw@nuist.edu.cn