

融合高阶信息增强模块的复杂背景 植物叶片图像分类

游梓童, 吴福明, 赵 淼, 业 宁

(南京林业大学信息科学技术学院, 江苏 南京 210037)

[摘要] 植物叶片对植物种类分辨与认知具有重大研究作用. 提出了一种充分提取植物叶片特征信息的高阶信息增强模块, 使用包含高阶信息增强模块的卷积神经网络模型对植物叶片图像进行多感受野特征提取. 以复杂背景下的植物叶片图像为研究对象, 从中国植物图像库中获取样本来源不同的植物叶片图像构成含有 9 种叶片的 PLD_amp 数据集, 采用添加高斯噪声、数据增广技术平滑和增扩数据集, 增强数据的可操作性. 与现有传统卷积网络相比, 所提出的包含高阶信息增强模块的 CNN 模型最佳分类准确率可达 88.7%, 具有较高可行性与高分类准确率.

[关键词] 植物叶片, 叶片分类识别, 特征提取, CNN, 深度学习

[中图分类号] TP391.41 **[文献标志码]** A **[文章编号]** 1672-1292(2022)03-0045-08

Classification of Complex Background Plant Leaf Images Combined with High-Level Information Enhancement Module

You Zitong, Wu Fuming, Zhao Miao, Ye Ning

(College of Information Science and Technology, Nanjing Forestry University, Nanjing 210037, China)

Abstract: Plant leaves play an essential role in the study of plant species discrimination and cognition. This paper proposes a high-level information enhancement module that fully extracts the feature information of plant leaves, and uses the convolutional neural network containing this module to extract the features of plant leaf images from multiple receptive fields. The experiment takes the plant leaf images in complex background as the research object, and plant leaf images from different sample sources are obtained from Plant Photo Bank of China (PPBC). These images constitute the PLD_amp data set containing nine kinds of leaves. The techniques of adding Gaussian noise and data augmentation are used to smooth and expand the data set, thereby enhancing the data set's operability. The CNN model's best classification accuracy with a high-order information enhancement module proposed in this paper for plant leaf image classification in complex backgrounds reaches 88.7%. Compared with the existing traditional convolutional network, it has higher feasibility and classification accuracy, and it provides a new idea for plant leaf image recognition under complex background.

Key words: plant leaves, classification and identification of leaves, feature extraction, CNN, deep learning

为了更有针对性地保护植物, 对植物种类进行有效地自动分类越来越受到人们的关注. 植物的不同器官均可作为识别分类的依据. 由于植物的花朵、果实、种子都是三维形状的, 且同一植物在不同生长阶段以及不同季节均会呈现出一定的差异性, 在生长非成熟期内不易收集到样本, 因而识别起来较为复杂. 相较而言, 植物叶片基本上处于平面状态, 适合于进行二维图像处理, 且不同植物的叶型、叶片纹理、颜色等特性在各自生长环境中会产生较大差异^[1], 因此可以通过叶片形状对不同种类的叶片进行分类识别^[2].

近年来, 植物叶片分类已成为计算机视觉领域的研究热点. 国内外绝大多数的植物叶片图像识别分类任务以理想情况下的单独叶片为研究对象, 对于在自然状态下获得的复杂背景下的植物叶片分类研究相对较少. 田诗晨等^[3]采用集成学习方法, 将概念神经网络(PNN)作为弱分类器对叶片数据进行分类. 孙

收稿日期: 2021-08-31.

基金项目: 国家重点研发计划项目(2016YFD0600101)、江苏省大学生创新实践项目(202110298039).

通讯作者: 业宁, 博士, 教授, 研究方向: 数据挖掘、机器学习. E-mail: yening@njfu.edu.cn

丽萍等^[4]提出用改进的局部三值特征(LTP)与梯度方向直方图(HOG)特征进行纹理特征融合,并使用 DBN 网络^[5]作为分类器进行树木叶片分类识别. Alessandrini 等^[6]采用卷积神经网络对健康叶片与病害叶片进行了二分类研究. Song 等^[7]使用近红外反射光谱(NIRS)对茶叶特征进行提取,并结合计算机视觉(CVS)对茶叶进行分类评估. Nandhini 等^[8]提出了一种改进的帝王蝶优化算法对 VGG16 和 Inception V3 网络进行优化,对 4 种病理番茄叶片进行分类,达到了较高的分类精度. Akter 等^[9]使用三层卷积神经网络提取了 10 种医用叶片的特征,对其进行分类. El-Maged 等^[10]使用高斯优化算法对卷积神经网络(CNN)中的超参数进行优化. Kheirkhah 等^[11]通过主成分分析(PCA)算法选择出叶片主要特征对植物叶片进行分类. 张帅等^[12]将卷积神经网络(CNN)与支持向量机(SVM)、SoftMax 分类器结合进行训练,对单一背景下的叶片的分类精度可达 91.11%,但对复杂背景下的叶片图像的识别率仅有 34.38%. 绝大部分现有研究只对单一背景下的叶片有良好的分类效果,但在自然状态下进行植物叶片采集工作所获得的叶片背景大多较为复杂,利用传统的图像识别方法识别植物叶片图像存在特征难以设计和提取、识别准确率较低等不足.

本文提出一种改进的基于卷积神经网络的复杂背景下的叶片分类策略,通过对从中国植物图像库(Plant Photo Bank of China, PPBC)中获取的数据集添加高斯噪声、平滑和增扩数据集,增强数据的可操作性;而后采用一种抽取多个卷积层进行下采样处理,将其组织为高阶信息增强模块的方法,使用融合级联结构的卷积神经网络模型对植物叶片图像进行多感受野特征提取,最终分类准确率达到 87.2%. 与现有传统卷积网络对比可知,该模型针对复杂背景下的植物叶片图像分类任务具有可行性与高分类准确率.

1 背景知识

1.1 卷积神经网络模型

卷积神经网络是一种深度学习模型,能够隐式地从数据中不断学习并提取深度特征信息,在计算机视觉、图像识别等领域具有很强的泛化能力^[13]. 卷积神经网络在训练过程中至少有一个卷积层用于特征提取,且卷积层级之间的神经元具有局部连接和权值共享的特性,以减少训练计算量,提升模型的训练速度.

卷积神经网络的核心为卷积运算,包含卷积层可提取图像的局部特征. 卷积层的核心为卷积核,当前层的特征图经卷积核处理之后,经激励函数可得到下一层的特征图. 卷积运算的过程可描述为:

$$x_m^{l+1} = f_{\text{act}} \left(\sum_{n \in U_m} x_n^l \oplus k_{nm}^{l+1} + b_m^{l+1} \right), \quad (1)$$

式中, x_m^{l+1} 表示下一层第 m 个神经元的输出值; U_m 为输入特征的映射集合; $f_{\text{act}}(\cdot)$ 为非线性激活函数; k_{nm}^{l+1} 为卷积核(权重矩阵); b_m^{l+1} 为偏置项.

非线性激活函数用于将非线性特征引入网络中,以提高神经网络对模型的表达能力. 常见的激活函数有 Sigmoid 函数、tanh 函数、ReLU 函数等,其中 ReLU 函数的收敛速度远大于 Sigmoid 函数和 tanh 函数. ReLU 函数的表达式为:

$$\text{ReLU}(x) = \max(0, x). \quad (2)$$

在卷积层之后的池化层用于对当前卷积层输出的激活数据进行降维处理,在一定程度上减少神经网络的计算量,扩大感知野,维持激活数据特征尺寸的局部不变性,同时提高模型的容错性. 池化方法按池化窗口输出值分为最大值池化和平均池化两种.

特征矩阵经卷积层与池化层多次交替连接后与全连接层相连. 全连接层用于对提取的特征矩阵进一步降维处理,最后将特征矩阵输入 SoftMax 分类器中进行分类标注.

1.2 神经元感受野

神经元感受野表示的是网络内部不同位置的神经元对原图像的感受范围的大小^[14]. 低层卷积层的感受野较大,表示其接收到的原始图像的范围越大,语义信息表达能力越强(如植物叶片所在方位、清晰度、背景亮度等),但经卷积之后的特征图分辨率较低,几何信息的表达能力较弱;相反,高层卷积层的感受野较小,其提取到的特征更为细致,几何信息^[15]表达能力较强(如植物叶片的形状轮廓特征、纹理特征等),但语义信息表达能力较弱.

神经元感受野的大小与当前层(第 k 层)卷积核的大小及步长有关,也与第 $k+1$ 层感受野的大小有

关. 感受野采用从最高层(靠近输出层)卷积层依次低层计算,通过公式可逐层计算卷积层感受野的大小:

$$F(i) = (F(i+1) - 1) \times \text{Stride}_i + \text{Ksize}_i, \quad (3)$$

式中, $F(i)$ 为第 i 层卷积层的感受野大小; $F(i+1)$ 为第 $i+1$ 层卷积层的感受野大小; Stride_i 为卷积运算的步长; Ksize_i 为当前层卷积核的大小.

2 融合高阶信息增强模块的卷积神经网络模型

2.1 高阶信息增强模块的提出

由于复杂背景下的植物叶片图像背景极易覆盖叶片的特征信息,会对植物叶片特征提取工作造成干扰. 因此,如何充分利用现有信息使网络学习到植物叶片特征之间的相关性尤为重要^[16]. 复杂背景下的植物叶片图像中叶片区域占总图像区域比例不同,这将导致图片中叶片所占像素区域大的更偏好带有更大感受野的卷积核,所占像素区域越小的越偏好带有更小感受野的卷积核^[17],故在卷积神经网络中不同卷积层所提取的局部特征也各不相同. 对于植物叶片而言,其形状特征、纹理特征、颜色特征均可用作分类的特性依据^[18].

本文提出一种高阶信息增强模块,以充分提取叶片的形状、纹理和颜色等特征.

高阶信息增强模块通过对卷积神经网络处理过程中的不同阶段卷积层提取的叶片形状、纹理和颜色特征等多特征进行矩阵元素级相加,防止卷积神经网络向前卷积过程中丢失信息. 通过对低层卷积层和高层卷积层进行一阶、二阶和三阶信息增强实现对复杂背景植物叶片特征的充分提取. 实验验证了一阶、二阶和三阶信息增强均不同程度地增强了卷积神经网络对复杂背景植物叶片的特征表达能力. 因此,本文将以上 3 种信息增强部分统称为高阶信息增强模块.

在卷积神经网络向前卷积过程中,高阶信息增强模块抽取卷积层对低层特征图通过卷积进行下采样,将卷积神经网络中高分率低语义信息的低层特征图与低分辨率高语义信息的高层特征图进行融合,将融合后的多特征作为高阶信息增强模块的特征,融合后的特征图包含了在卷积神经网络的传播中可能会丢失的低层细节信息,增强了高阶卷积层所获取的复杂背景下的植物叶片信息,使感受野更丰富,以提高特征的表达能力与特征的可区分性.

高阶信息增强模块对卷积神经网络中部分卷积层进行特征相加,通道数保持不变. 将每层池化层之前的卷积层进行下采样,通过计算将卷积层下采样后得到的特征图与最后一层池化层前的卷积层得到的特征图尺寸及通道数调整一致. 如图 1 所示,设需要下采样处理的卷积层的特征图为 $X_i, X_i \in \mathbf{R}^{\text{VGG16}}$, 尺寸为 $[h, w, c]$, 高阶信息增强模块中最后一层卷积层特征图尺寸为 $X_i[h', w', c']$. 通过确定下采样参数,并改变通道数,将高阶信息增强模块中经下采样获得的各个卷积层特征图的尺寸调整为 $X'_i[h^{(2)}, w^{(2)}, c^{(2)}]$, 将各个卷积层获得的特征图矩阵元素级相加即构成高阶信息增强模块.

需要注意的是,高阶信息增强模块经下采样后的卷积层特征图尺寸应与最后一层卷积层特征图尺寸保持一致,即: $h' = h^{(2)}, w' = w^{(2)}, c' = c^{(2)}$.

2.2 高阶信息增强参数的确定

依照高阶信息增强模块中最后一个卷积层所得特征图的尺寸,对每层池化层之前的卷积层进行下采样,通过卷积运算将每层池化层之前的卷积层所得特征图的尺寸与最后一个卷积层所得特征图的尺寸保持一致,此时卷积运算中卷积核的大小为:

$$\text{conv}_{\text{size}} = \frac{\text{conv}_i}{\text{conv}_{\text{last}}}, \quad (4)$$

式中, $\text{conv}_{\text{size}}$ 为卷积核的大小; conv_i 为不同卷积层特征图的尺寸, i 为不同卷积层的层序号; $\text{conv}_{\text{last}}$ 为最后一层池化层前的卷积层特征图的尺寸.

以 VGG16 为例,最后一层池化层前的卷积层特征图尺寸为 14×14 , 其计算下采样过程所采用的卷积核大小参数如表 1 所示.




图 1 高阶信息增强模块的形成过程
Fig. 1 The formation process of enhanced high-order information module

表 1 下采样过程所采用的卷积核大小参数

Table 1 The size parameter of the convolution kernel used in the downsampling process

The number of the convolutional layer	The size of the feature map	The size of the convolution kernel	The size of the feature map after downsampling
down_sample_1	224×224×64	(2,2)	112×112×128
down_sample_2	112×112×128	(2,2)	56×56×256
down_sample_3	56×56×256	(2,2)	28×28×512
down_sample_4	28×28×512	(2,2)	14×14×512

2.3 融合高阶信息增强模块的卷积网络模型的建立

为了更好地提取植物叶片图像中来自低层卷积层和高层卷积层的特征信息,本文对卷积神经网络模型进行改进,使用融合高阶信息增强模块的卷积神经网络对复杂背景下的植物叶片图像特征进行提取. 图 2 为模型结构流程图,由于全连接层不具备特征提取能力,故只对部分卷积层进行特征相加. 将从卷积层获得的特征信息分别通过下采样处理输送至特征提取路径,下采样过程需通过计算将卷积层下采样后得到的特征图与最后一层池化层前的卷积层得到的特征图尺寸调整一致. 然后将卷积层下采样后得到的特征图送至高阶信息增强模块进行特征整合,通过矩阵元素级相加,获得不同神经元感受野下的特征图. 将从高阶信息增强模块中获取的信息输送至全连接层对特征空间进行降维,最后结合 Softmax 分类器对植物叶片图像进行分类.

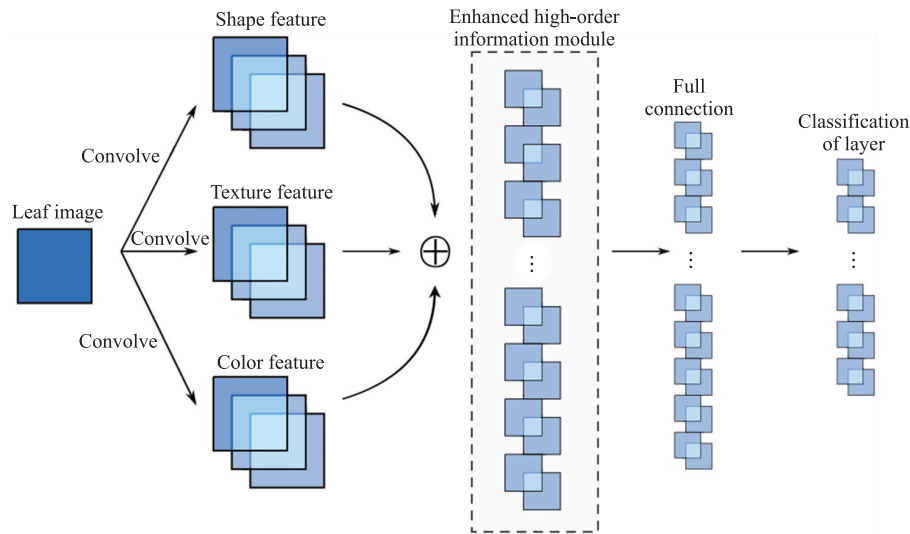


图 2 融合高阶信息增强模块的卷积神经网络

Fig. 2 Convolutional neural network with the enhanced high-order information module

针对本文数据集背景较为复杂、特征不易提取等特性,使用融合高阶信息增强模块的 VGG16 模型对数据集进行训练,通过高阶信息增强模块对植物叶片图像来自低层卷积层和高层卷积层的特征进行整合,融合高阶信息增强模块后的 VGG16 模型结构如图 3 所示.

融合高阶信息增强模块结构的 VGG16 模型:采用 224×224×3 尺寸的植物叶片图像作为输入,首先通过两层卷积(卷积核数量为 64,核尺寸为 3×3,步长为 1)将原始图像的通道数变为 64,高、宽不变,保留 VGG16 第二个卷积层的结果,尺寸为 224×224×64,命名为 layer_1;继续使用卷积层对 layer_2 的特征图下采样,得到 layer_4,对应尺寸为 112×112×128;同理按照 VGG16 原始模型继续下采样,分别取出第 7、10、13 卷积层结果,命名为 layer_7、layer_10、layer_13,对应尺寸为(56×56×256)、(28×28×512)、(14×14×512).

一阶信息增强模块:取出 layer_2,使用 Kernel_size=(2,2),Strides=2 的卷积核对 layer_2 下采样,再使用数量为 128、卷积核尺寸为 1×1、步长为 1 的卷积层对下采样结果平滑处理,增加特征图的 channel,得到的结果与 layer_4 相加,命名为 level_1_node_1;继续对 level_1_node_1 使用最大池化下采样与平滑操作,得到的结果与 layer_7 相加,命名为 level_1_node_2;同理得到 level_1_node_3.

二阶信息增强模块:使用 Kernel_size=(2,2),Strides=2 的卷积核对 level_1_node_1 下采样,之后平滑操作,与 level_1_node_2 相加,结果命名为 level_2_node_1;重复对 level_2_node_1 进行相同操作,得到 level_2_node_2.




图3 融合高阶信息增强模块的 VGG16 模型

Fig.3 VGG16 model with the enhanced high-order information module

三阶信息增强模块:使用 $\text{Kernel_size}=(2,2)$, $\text{Strides}=2$ 的卷积核对 level_2_node_2 下采样并平滑操作,然后与 level_1_node_2 相加,结果命名为 level_3_node_1 。

信息融合模块:调整 level_1_node_3 、 level_2_node_2 、 level_3_node_1 特征图尺寸与 channel 数量,使得与 layer_13 一致,之后对三维矩阵相加,结果传入全连接层后续进行 Softmax 处理。

3 实验与分析

3.1 实验数据

3.1.1 植物叶片数据集的来源

本文数据集来自中国科学院植物研究所植物标本馆设立的专职植物图片管理机构-中国植物图像库 (Plant Photo Bank of China, PPBC)。PPBC 的植物图片由全国各地植物爱好者和科研人员拍照上传,相比于大部分研究直接使用的单一或空白背景的植物图像,来自 PPBC 的植物叶片图像受拍摄地、拍摄季节、拍摄角度等各种因素的影响,背景多变,因而在图像分类过程中更具挑战性。

本研究从 PPBC 中收集关键词为“绿萝” (*Epipremnum aureum*)、“冰川茶藨子” (*Ribes glaciale*)、“侧柏” (*Platycladus orientalis*)、“鹅掌楸” (*Liriodendron chinense*)、“福禄桐” (*Polyscias guilfoylei*) 等 9 种植物图像,每种植物挑选约 300 张图像,构建 2 700 张初始植物叶片数据集。

3.1.2 数据集的优化与划分

由于初始植物数据集来自 PPBC 中差异较大的数据源,可能出现样本尺寸不一致、样本重复等问题,从而影响深度学习模型的执行效率。为了解决该问题,本文通过以下方法提高数据置信度:

首先,对来自 PPBC 的植物叶片图像进行清洗,剔除清晰度较差的图片,减小低质量数据对模型训练的影响。在剔除不规范样本之后,得到每类约 200 张图片组成植物叶片数据集,命名为 PLD 数据集。

其次,对数据集进行归一化处理,将所有植物叶片图像尺寸调整为 448×448 像素;再将样本尺寸统一压缩为 224×224 以提高训练速度。对植物叶片图像添加高斯噪声,达到对植物叶片图像进行合理地近似仿真效果,增强模型的学习能力,提高模型鲁棒性。

丰富的数据集有助于挖掘数据价值^[19],实现更好的训练效果;当训练数据不足时,模型从原始数据中所获信息较少,易产生过拟合。本文使用数据增广技术^[20]增强 PLD 数据集,通过水平翻转、垂直翻转、镜像等方

式对植物叶片图像进行扩增,实现数据增强. 扩增后的数据集共 7 308 张,命名为 PLD_amp 数据集.

最后,从 PLD_amp 数据集中选取 20%作为测试集,并使用留一法将 PLD_amp 数据集剩余部分划分为训练集和验证集.

3.2 实验评价指标

通过整体准确率(total accuracy, TA)、平均准确率(average accuracy, AA)、准确率(ACC)3 个指标对 9 种复杂背景下的植物叶片图像的分类结果进行评估. 整体准确率表示被正确分类的样本占数据样本总数的百分比,平均准确率为植物叶片各个类别分类准确率的平均值.

3.3 实验内容

本文通过采用融合高阶信息增强模块的卷积神经网络充分提取植物叶片图像信息,对 9 种复杂背景下的植物叶片图像进行分类. 将 PLD_amp 数据集中已划分好的训练集输入至 VGG16、使用一阶信息增强模块的 VGG16_h1 模型、使用二阶信息增强模块的 VGG16_h2 模型和使用三阶信息增强模块的 VGG16_h3 模型中进行训练,通过测试集获得模型的准确率.

实验 1 在实验过程中,设置迭代次数为 100,学习率为 0.001. PLD_amp 数据集在各模型中的训练准确率和验证准确率的表现情况如图 4 所示.




图 4 4 种模型的分类准确率
Fig. 4 Classification accuracy of the four models

从实验结果可看出,相比于 VGG16,融合高阶信息增强模块的卷积神经网络模型在迭代 50 次后准确率曲线趋近平稳,而 VGG16 模型在后期仍持续震荡,证明融合高阶信息增强模块的卷积神经网络模型稳定性更好. 如表 2 所示,从 ACC 指标来看,在迭代 100 次后,使用融合高阶信息增强模块的卷积神经网络模型预测准确率均高于 VGG16 模型. 且相较于 VGG16 模型,使用融合高阶信息增强模块的卷积神经网络对测试集的测试准确率均有所提升,精度提升范围为 2.1%~2.3%. 对比实验证明,融合高阶信息增强模块的卷积神经网络对复杂背景下的植物叶片图像分类任务可以达到较高的准确率.

表 2 4 种模型的预测准确率对比	
Table 2 Comparison of prediction accuracy of the four models	
Model	Validation accuracy/%
VGG16	86.4
VGG16_h1	88.5
VGG16_h2	88.3
VGG16_h3	88.7

实验 2 在模型训练过程中,对 PLD_amp 数据集进行 3 次训练,每次训练进行 500 次循环迭代,设置学习率为 0.001,获得最优训练结果. 图 5 为采用 VGG16_h1、VGG16 模型对 PLD_amp 数据集分类得到的最优训练准确率和验证准确率的对比曲线.

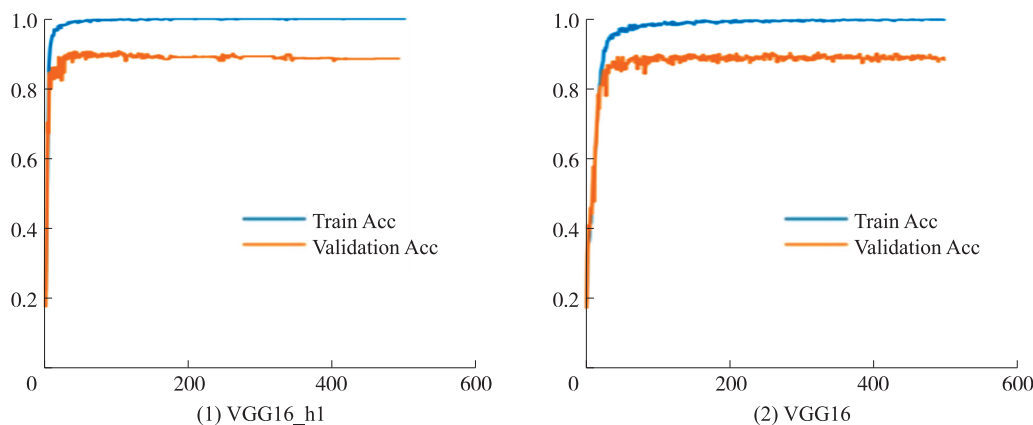


图 5 VGG16_h1 和 VGG16 模型分类准确率对比曲线

Fig. 5 Comparison curve of classification accuracy of VGG16_h1 and VGG16

从图中可以看出,相比于 VGG16,使用 VGG16_h1 模型获得的准确率曲线在迭代 200 次后趋近平稳,而 VGG16 模型在后期仍持续震荡,证明 VGG16_h1 模型的稳定性更好. 从 ACC 指标来看,在迭代 500 次后,VGG16 模型训练准确率为 99.1%,VGG16_h1 模型训练准确率为 99.8%;VGG16 模型预测准确率为 86.6%,VGG16_h1 模型预测准确率为 88.3%. 对比证明,通过 VGG16_h1 模型对复杂背景下的植物叶片图像分类任务可以达到较高的准确率.

实验 3 采用“K 折交叉验证法”^[21](cross validation)将数据集进行划分,将 PLD_amp 数据集划分为 K 个大小相似的互斥子集,通过分层采样使每个子集尽可能保持数据分布的一致性;每次使用 K-1 个子集作为训练集,余下的子集做为测试集,获取 K 组训练集与

表 3 VGG16_h1 交叉验证分类结果

Table 3 Cross-validated classification results on VGG16_h3

VGG16_h1	5-fold cross validation/%	10-fold cross validation/%
TA	87.9	86.5
AA	88.1	86.8

测试集,进行 K 次训练和测试,最终返回 K 次测试结果的均值作为性能指标,以评估 VGG16_h1 模型的鲁棒性. 本实验使用 K=(5,10)对 PLD_amp 数据集进行划分,表 3 所示为不同交叉验证的分类结果.

3.4 实验分析

根据实验 1 的 4 组对比结果,PLD_amp 数据集在 VGG16 模型上进行训练,准确率为 86.4%,而在 VGG16_h1、VGG16_h2、VGG16_h3 模型上准确率分别达到 88.5%、88.3%和 88.7%,相较于在 VGG16 模型上准确率均提高约 2.1%,且准确率曲线也相对平稳. 在实验 2 对 VGG16_h1 模型训练过程中,迭代 500 次后,3 组实验均表现了较高的准确率,最优准确率达到 88.3%,相较于 VGG16 模型准确率提升了 1.7%. 实验 3 采用 5、10 折交叉验证法对 VGG16_h1 模型鲁棒性进行测试,结果表明二者均对模型准确率有所提升,5 折交叉验证下准确率更好,模型准确率提升约 1.4%. 以上 3 组实验均证明了使用含高阶信息增强模块的 VGG16 模型的鲁棒性,及在复杂背景下的植物叶片分类任务中改进的 VGG16 模型准确率有所提升.

4 结论

本文使用复杂背景下的植物叶片图像作为研究对象,运用数据增广技术对图像进行预处理,构建 PLD_amp 数据集,提出了一种将底层特征通过下采样与顶层特征进行融合,将其组织为高阶信息增强模块的方法,并使用融合高阶信息增强模块的卷积神经网络模型对植物叶片图像进行多感受野特征提取. 研究表明,基于融合高阶信息增强模块对复杂背景下的植物叶片图像进行分类,在迭代次数为 100 和学习率为 0.001 时,准确率达到 88.7%,验证了此融合高阶信息增强模块的卷积神经网络模型在特征提取阶段的优势,表明融合高阶信息增强模块的卷积神经网络模型对复杂背景下的植物叶片图像分类任务具有较高的可行性和高分类准确率.

[参考文献](References)

- [1] AZLAH M A F, CHUA L S, RAHMAD F R, et al. Review on techniques for plant leaf classification and recognition[J]. Computers, 2019, 8(4): 77.
- [2] 李俞利. 植物叶片分类方法研究[D]. 兰州: 西北师范大学, 2021.
- [3] 田诗晨, 徐玉丹, 李瑀馨. 基于 Bagging-PNN 算法的树叶分类方法优化[J]. 自动化与仪表, 2020, 35(8): 52-55, 61.
- [4] 孙丽萍, 陈泓钢, 岳琪, 等. 依据特征融合和深度学习的树木叶片分类方法[J]. 东北林业大学学报, 2020, 48(6): 51-55, 65.
- [5] HUA Y M, GUO J H, ZHAO H. Deep belief networks and deep learning[C]//Proceedings of 2015 International Conference on Intelligent Computing and Internet of Things. Harbin, China: IEEE, 2015.
- [6] ALESSANDRINI M, RIVERA R C F, FALASCETTI L, et al. A grapevine leaves dataset for early detection and classification of Esca disease in vineyards through machine learning[J]. Data in Brief, 2021, 35: 106809.
- [7] SONG Y, WANG X Z, XIE H L, et al. Quality Evaluation of Keemun black tea by fusing data obtained from near-infrared reflectance spectroscopy and computer vision sensors[J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2021, 252: 119522.
- [8] NANDHINI S, ASHOKKUMAR K. Improved crossover based monarch butterfly optimization for tomato leaf disease classification using convolutional neural network[J]. Multimedia Tools and Applications, 2021, 80: 18583-18610.
- [9] AKTER R, HOSEN M I. CNN-based Leaf Image Classification for Bangladeshi Medicinal Plant Recognition[C]//Proceedings of 2020 Emerging Technology in Computing, Communication and Electronics(ETCCE). Bangladesh: IEEE, 2021.
- [10] EL-MAGED L M A, DARWISH A, HASSANIEN A E. Artificial Intelligence-Based Plant Diseases Classification[M]//HASSANIEN A E, DARWISH A. Machine Learning and Big Data Analytics Paradigms: Analysis, Applications and Challenges. Switzerland: Springer Cham, 2021: 45-61.
- [11] KHEIRKHAH F M, ASGHARI H. Plant leaf classification using gist texture features[J]. IET Computer Vision, 2019, 13(4): 369-375.
- [12] 张帅, 淮永建. 基于分层卷积深度学习系统的植物叶片识别研究[J]. 北京林业大学学报, 2016, 38(9): 108-115.
- [13] ZOUMPOURLIS G, DOUMANOGLU A, VRETOS N, et al. Non-linear convolution filters for CNN-based learning[C]//Proceedings of 2017 International Conference on Computer Vision. Venice, Italy: IEEE, 2017.
- [14] XIN Y A, LZ B, SY A, et al. A multi-scale convolutional neural network with context for joint segmentation of optic disc and cup[J]. Artificial Intelligence in Medicine, 2021, 113: 102035.
- [15] LI L, ZHAO K Y, SUN R Z, et al. Research for an adaptive classifier based on dynamic graph learning[J]. Neural Processing Letters, 2021[2021-08-31]. <http://link.springer.com/article/10.1007/S11063-021-10452-7>.
- [16] YANG K L, ZHONG W Z, LI F G. Leaf segmentation and classification with a complicated background using deep learning[J]. Agronomy, 2020, 10(11): 1721.
- [17] MOHTASHAMIAN M, KARIMIAN M, MOOLA F, et al. Automated plant species identification using leaf shape-based classification techniques: a case study on Iranian maples[J]. Iranian Journal of Science and Technology: Transactions of Electrical Engineering, 2021, 45: 1051-1061.
- [18] KADIR A, NUGROHO L E, SUSANTO A, et al. Leaf classification using shape, color, and texture features[J]. International Journal of Computer Trends and Technology, 2011, 1(3): 225-230.
- [19] 陆健健, 江开忠. 融合数据增广技术与机器学习算法的个人信用评分研究[J]. 软件导刊, 2020, 19(8): 40-43.
- [20] 高强, 张凤荔, 王瑞锦, 等. 轨迹大数据: 数据处理关键技术研究综述[J]. 软件学报, 2017, 28(4): 959-992.
- [21] LV L Y, SONG X G, SUN W. Modify leave-one-out cross validation by moving validation samples around random normal distributions: move-one-away cross validation[J]. Applied Sciences, 2020, 10(7): 2448.

[责任编辑: 严海琳]