

基于双节点-双边图神经网络的茶叶病害分类方法

张艳 车迅 汪芃 汪玉凤 胡根生

(安徽大学电子信息工程学院, 合肥 230601)

摘要: 传统茶叶病害分类主要依赖人工方法, 此类方法费工费时, 同时茶叶病害样本较少使得现有的机器学习方法的模型训练不充分, 病害分类准确率不够高。针对茶炭疽病、茶黑煤病、茶饼病和茶白星病 4 类病害, 提出一种基于双节点-双边图神经网络的茶叶病害分类方法。首先通过两分支卷积神经网络提取 RGB 茶叶病害特征和灰度茶叶病害特征, 两分支均采用 ResNet12 作为骨干网络, 参数独立不共享, 两类特征作为图神经网络的两个子节点, 以获得不同域样本所包含的病害信息; 其次构建相对度量边和相似性边两类边, 从而强化节点对相邻节点所含病害特征的聚合能力。最后, 经过双节点特征和双边特征更新模块, 实现双节点和双边交替更新, 提高边特征对节点距离度量的准确性, 从而实现训练样本较少条件下对茶叶病害的准确分类。本文方法和小样本学习方法进行了对比实验, 结果表明, 本文方法获得更高的准确率, 在 miniImageNet 和 PlantVillage 数据集上 5way-1shot 的准确率分别达到 69.30% 和 88.42%, 5way-5shot 准确率分别为 82.48% 和 93.04%。同时在茶叶数据集 TeaD-5 上 5way-1shot 和 5way-5shot 准确率分别达到 84.74% 和 86.34%。

关键词: 茶叶; 病害分类; 图神经网络; 双节点; 相对度量边; 相似性边

中图分类号: TP391.41

文献标识码: A

文章编号: 1000-1298(2024)03-0252-11

OSID:



Tea Disease Classification Method Based on Graph Neural Network with Dual Nodes – Dual Edges

ZHANG Yan CHE Xun WANG Peng WANG Yufeng HU Gensheng

(School of Electronic and Information Engineering, Anhui University, Hefei 230601, China)

Abstract: The classification of traditional tea diseases mainly relies on manual categorization. Such methods are labor-intensive and time-consuming. Furthermore, insufficient availability of tea disease samples hampers the adequate training of existing machine learning models, resulting in decreased accuracy in disease classification. To address this problem, a tea disease classification method was proposed for four types of tea diseases, including tea anthracnose, tea black rot, and others. This method was based on a dual node – dual edge graph neural network. Firstly, RGB tea disease features and grayscale tea disease features were extracted by using two branches of convolutional neural networks, both branches employed ResNet12 as the backbone network, with independent parameters. The two types of features acted as two sub-nodes within the graph neural network, aiming to obtain disease information from different domains. Secondly, two types of edges, including relative metric edges and similarity edges, were created to improve the aggregation capability of disease features from neighboring nodes. Finally, with the dual node and dual edge feature updating modules, a dual-node and dual-edge alternate updating process was achieved. This process aimed to enhance the accuracy of edge features in measuring node distances. This resulted in achieving accurate classification of tea diseases, even when training samples were limited. Comparative experiments were conducted between the proposed methods, which were based on small-sample learning method. The results indicated that the proposed method achieved superior accuracy in tea disease classification. Specifically, on the miniImageNet and PlantVillage datasets, the proposed method achieved the accuracy of 69.30% and 88.42% in the 5way-1shot, respectively. In the 5way-5shot, the accuracy was improved to 82.48% and 93.04% on the

收稿日期: 2023-08-02 修回日期: 2023-10-06

基金项目: 安徽省中央引导地方科技发展专项(202107d06020001)和国家自然科学基金项目(32372632)

作者简介: 张艳(1982—), 女, 副教授, 博士, 主要从事农业领域图像等多源数据分析处理与应用研究, E-mail: zhangyan@ahu.edu.cn

通信作者: 胡根生(1971—), 男, 教授, 博士, 主要从事农业信息处理与应用研究, E-mail: hugs2906@sina.com

miniImageNet and PlantVillage datasets. Furthermore, on the TeaD-5 tea dataset, the accuracy of the proposed method reached 84.74% in the 5way-1shot and 86.34% in the 5way-5shot.

Key words: tea; disease classification; graph neural network; dual nodes; relative metric edge; similarity edge

0 引言

茶叶作为我国重要的经济作物,是保证茶农经济收入的重要产业^[1]。然而茶叶在生长过程中常受病害的感染导致减产,如果不能对茶叶病害进行绿色、有效、精准地防治而滥用农药,会严重影响茶叶的品质,给茶农收益带来巨大损失^[2]。因此,茶叶病害正确、及时的诊断对提升茶叶产量和增加茶农收入具有重要意义。目前,茶叶病害的诊断经常依靠有经验的茶农和具有丰富植物病理知识的专家进行主观判断,这种诊断方式需要投入大量人力。随着图像处理技术的发展,传统机器学习和深度学习的方法已经被广泛地应用于农作物病害识别。文献[3]使用数据集规模为每类几十幅,可一定程度上解决小样本学习问题,但此类方法通常需要人工对图像进行分割,以获得感兴趣区域,但是由于农作物叶片病斑的复杂性,区分病斑和正常叶片之间的界限可能并不清晰。因此该类方法存在鲁棒性低、泛化能力弱等问题^[4]。深度卷积神经网络不需要人工提取特征,采用深度学习方法进行病害分类的准确率非常高^[5-7],但此类方法需要充足的样本训练,对小样本学习针对性不够,在样本数据较少情况下会造成过拟合现象。邢鹏康等^[8]提出基于小样本学习的马铃薯叶片病害检测算法,数据集为 5 类共 1 135 幅,将任务感知注意力模块用于融合小样本学习网络中的双分支输入特征,实现了 93.92% 的准确率。李子茂等^[9]提出一种基于迁移学习的 SE-DenseNet-FL 茶叶病害识别方法,在预训练模型上使用自建茶叶病害数据集进行参数微调,茶叶数据集为 5 类 2 175 幅,以缓解样本数据过少带来的过拟合影响。小样本数据集通常指的是每个类别相对规模较小的数据集,但具体的界定可能因任务和领域而有所不同。针对茶叶数据集,每个类别样本在几十到几百幅之间训练模型可称为小样本学习^[10-11]。小样本学习方法只需要通过少量数据就可以发掘出样本与样本之间的关系,通过给定的标记样本来预测其他未标记样本,缓解了大规模数据集训练网络所带来的局限性。

图神经网络(Graph neural network, GNN)^[12]正在被应用于图像分类的各个方面。刘颖等^[13]引入卷积注意力模块,用更具表征力的特征来优化图神

经网络,在小样本监督和半监督分类任务上取得较好效果。GNN^[14]的目标是学习节点之间的关系和图的全局结构,以进行图数据的特征提取、节点分类、图分类等任务,可采用小样本学习的特点设计图卷积神经网络,通过图结构的聚合更新进行标签信息的传播,实现查询集样本的分类任务。EGNN^[15]进一步利用样本间的相似性和不相似性特征,提出了标签图神经网络,在元训练框架下学习支持集样本与查询集样本间的联系,进一步提高了网络的分类性能。DPCN^[16]则在分布学习方法影响下,将原有单一的图结构拆分为分布图与点图的结合,构建了分布传播图神经网络,在两个不同功能的图结构中,对节点和特征交替更新,传播样本的标签信息,实现查询集样本的精确分类。CHEN 等^[17]将图神经网络应用于复杂工业故障诊断中,通过图结构的特点表述了工业过程中复杂的相互作用,并实现了效果的改善。基于小样本学习的研究中采用图神经网络方法的比例正在逐渐增加。上述基于小样本学习的图神经网络方法仅关注于提取 RGB 图像信息,忽略了样本其他域中可能包含的信息。在训练样本充足的情况下,随着网络层数的加深,较深层神经网络能达到非常好的分类效果,但由于茶叶病害发病的不确定性和不规则性,给数据采集带来高难度,导致训练网络的数据样本不够充分。基于图神经网络的小样本学习能够利用病害特征初始化图结构,通过图神经网络的聚合功能更新节点特征来传播标签信息,最终将含标签信息的支持集病害样本信息传播到不含标签的查询集样本,得到未知查询集样本的预测结果。

本文针对数据集样本不充分,且训练网络时易忽略除 RGB 图像以外的其他域可能包含的信息,构建一种基于双节点-双边图神经网络的茶叶病害分类模型。首先对数据进行数据增强,其次采用 ResNet12 提取样本 RGB 域和灰度域茶叶病害特征,通过两类特征构造具有双节点和双边的图,其中茶叶 RGB 图像特征和茶叶灰度图像特征分别构成 2 个子节点,节点间的相似性边和相对度量边^[18]构成图的两条边。最后双节点和双边交替更新,以提取不同域所包含的信息,双节点更新和双边更新时能够聚合更多信息以提高边特征对节点距离度量的准确性,从而更好地在支持集和查询集之间建立关联。

1 材料与方法

1.1 数据采集和预处理

实验数据采集于安徽省金寨县油坊店乡安态茶园(31°06′~31°28′N,115°22′~115°42′E,海拔 206 m)。

图像采集设备包括佳能 EOS 80 SLR 型数码相机和 DJI Phantom 4pro 型无人机,采集了 4 种常见的茶叶病害图像和健康茶叶图像。4 种茶叶病害分别为茶黑煤病、茶饼病、茶白星病和茶炭疽病,共采集病害图像 1 427 幅和健康图像 420 幅。相机像素为 2 420 万,拍摄的图像分辨率在 720 像素×480 像素~6 000 像素×4 000 像素之间。无人机镜头像素可达 2 000 万,在水平方向飞行高度为 5 m 的情况下进行拍摄,采集图像分辨率分别为 5 472 像素×3 648 像素、4 846 像素×3 648 像素和 5 472 像素×3 078 像素。由于采集到的图像分辨率过大,同时可能包含多片叶片,需对图像进行预处理。相机采集的单片叶片若背景噪声大进行背景裁剪,无人机采集到的图像首先需将一幅大图等分为 6 幅或 9 幅小图,再将小图中包含茶叶病害的图像裁剪出来,针对不同种类的茶叶病害进行类别的鉴定和划分,将裁剪划分后的图像构建茶叶数据集。本文构建了包含 4 类病害和健康茶叶共 5 类图像的数据集 TeaD-5,数据集部分样本图像如图 1 所示。



Fig.1 Sample images of tea dataset TeaD-5

为了一定程度上解决样本较少以及样本分布不均匀的问题,提高模型对数据集的泛化能力,故对 TeaD-5 数据集进行数据增强。本文主要采用以下几种增强方法:①随机旋转:对图像随机进行水平 180°旋转、竖直 90°旋转,不会改变病害的相对位置,模拟相机不同拍摄角度拍摄到的图像。②添加椒盐噪声:对图像添加概率为 0.05 的椒盐噪声得到不同清晰度的图像,模拟不同拍摄质量。③Retinex 数据增强:可在动态范围压缩、边缘增强和颜色恒常 3 方面达到平衡,模拟不同光照亮度下拍摄到的图像。④随机擦除:对图像随机擦除 12 像素×12 像素区域,模拟被遮挡时所拍摄到的图像。增强后的样本共 9 235 幅。以茶白星病为例,数据增强后的茶白星病样本如图 2 所示。数据增强前后 5 类茶叶样本数据量及每类样本在数据集中占比如表 1 所示。

本文研究方法是基于小样本学习的茶叶病害分



图 2 数据增强后的茶白星病样本图像

Fig.2 Images of tea white star disease sample after data enhancement

表 1 不同类型茶叶病害样本图像数量和占比

Tab.1 Number and proportion of samples of different types of tea diseases

类型	数量/幅	增强后数量/幅	在数据集中占比/%
茶白星病	364	1 820	19.7
茶黑煤病	381	1 905	19.7
茶炭疽病	401	2 005	21.7
茶饼病	281	1 405	15.2
健康	420	2 100	22.7

类,因此选取了标准的小样本学习数据集 miniImageNet 和公开的农作物病害数据集 PlantVillage 进行实验。miniImageNet 数据集是 ImageNet 数据集的子集,共包含 100 个不同类别,每个类别中分别包含 600 幅尺寸为 84 像素×84 像素×3 的 RGB 图像,共计 60 000 幅图像。PlantVillage 数据集是植物病害图像数据库,常作为基础数据集用于农作物病害及植物病害的相关研究。该数据库的图像都是在实验室中拍摄,目前数据集中有 54 305 幅植物病害叶片图像,其中包含 13 种植物共 26 类病害叶片。该数据集中有 38 个类别的样本图像。

1.2 基于图神经网络的小样本学习

小样本分类任务的目标是训练出一个只需要少量训练样本参与训练的情况下,就可以拥有良好分类表现的分类器。每个小样本学习任务 T 都包含一个给定的数据集,该数据集被划分为两部分:①支持集 S :包含 N 个不同的类,每个类中包含 K 个标记样本,记为: $S = \{(x_i, y_i)\} (i = 1, 2, \dots, NK)$ (这种设置方式又被称为小样本学习中的 N way- K shot 分类问题)。②查询集 Q :包含 q 个待分类样本,记为: $Q = \{(x_i, y_i)\} (i = NK + 1, NK + 2, \dots, NK + q)$,其中对于每个任务都有 $T = S \cup Q$ 。

具体而言,在元学习^[19]的每轮训练中, N way- K shot 分类任务又被细分成训练阶段和测试阶段,设整个数据集样本共包含 C 个不同的类别,有 $C^{train} \subset C, C^{test} \subset C$,且 $C^{train} \cap C^{test} = \emptyset$ 。在训练阶段,给定训练集样本,其中包含支持集 $S \subset C^{train}$ 和查询集 $Q \subset C^{train}$ 对网络进行训练,通过反向传播对网络参

数不断更新,提升分类器在训练集中的分类能力^[20]。测试阶段,则给定测试集样本,同样包含支持集 $S \subset C^{test}$ 和查询集 $Q \subset C^{test}$,其目的是利用训练阶段训练好的分类模型,在支持集 $S \subset C^{test}$ 时,使用少量的支持集样本将查询集样本 $Q \subset C^{test}$ 准确地映射到正确的标签上,实现准确高效的分类任务。

图神经网络是一种针对图数据进行学习和推理的深度学习模型。在小样本学习场景下,数据样本有限,模型难以很好地拟合数据。在这种场景下,GNN 模型可处理少量的训练样本,同时具备很强的泛化能力^[21],能够对未见过的数据进行良好的预测。GNN 还具有很强的特征传播能力^[22],通过迭代更新节点特征,使节点能够聚合和传播相邻节点的信息。这种特征传播机制能够在图结构中传递信息,使得节点能够获得更全局的上下文信息,从而提高模型的表示能力和预测性能^[23-24]。本文基于边标签图神经网络进行小样本学习,边特征作为节点间相似程度的度量方式,通过节点特征和边特征的更新来提高边在预测节点类别时的准确率。

2 双节点双边茶叶病害分类模型

本文提出的双节点-双边茶叶病害分类方法框图(DNDE-GNN)如图 3 所示。图 3 以 2way-2shot 的分类任务为例,实线图形表示已标记的支持集样本,虚线图形表示未标记的查询集样本,彩色图形代表 RGB 图像,灰色图形代表预处理后的灰度图像。初始化图后对双节点和双边进行更新。主要包含 7

个模块:①图初始化模块,通过 ResNet12 网络提取茶叶 RGB 图像特征和茶叶灰度图像特征,作为图的双节点。相似性度量和相对度量两种方式构建图的双边,完成图的初始化。②双节点更新模块,双节点更新时对 2 个子节点分别进行更新,子节点聚合边相连的其他子节点信息,结合自身节点特征完成子节点特征更新,子节点分别更新后拼接 2 个子节点完成双节点更新。③双边更新模块,相对度量边由错位相减节点间距离度量编码实现,相似性边由节点直接进行距离度量编码实现。双边更新后采用边特征对节点分类。

2.1 图初始化模块

本文为获得除茶叶 RGB 图像域外的其他域病害信息,充分利用样本中不同域包含的信息,将 RGB 和灰度双域图像作为嵌入网络的输入。嵌入网络由 2 个独立的卷积神经网络 ResNet12 构成,分别提取 RGB 图像 x_{RGB} 和灰度图像 x_{gray} 的特征。对于 2 个不同域的图像,初始化病害特征为

$$\begin{cases} \boldsymbol{u}_{RGB}^0 = \text{ReLU}(\text{BN}(\text{Conv}(\boldsymbol{x}_{RGB}, \boldsymbol{\theta}_{emb1}) + \boldsymbol{x}_{RGB})) \\ \boldsymbol{u}_{gray}^0 = \text{ReLU}(\text{BN}(\text{Conv}(\boldsymbol{x}_{gray}, \boldsymbol{\theta}_{emb2}) + \boldsymbol{x}_{gray})) \end{cases}$$

(1)

式中 $\boldsymbol{u}_{RGB}^0$ 、 $\boldsymbol{u}_{gray}^0$ ——RGB 域和灰度域图像由 ResNet12 提取到的特征的特征向量

Conv——2 个参数不共享的卷积神经网络

ResNet12

双边更新模块




图 3 双节点-双边茶叶病害分类方法框图

Fig. 3 Diagram of two node - two edge tea disease classification method

$\theta_{emb1}、\theta_{emb2}$ ——对应卷积神经网络的参数集

节点初始化:本文采用 u_{RGB}^0 和 u_{gray}^0 作为图的初始化节点,每个节点表示支持集 S 和查询集 Q 通过嵌入模块得到的特征,如式(1)所示,为获得除 RGB 域图像外的其他域所包含的信息,灰度图像提取到的特征作为一个子节点,再结合 RGB 子节点构成双节点。

边初始化:根据节点和边可构造图 $G(V,E)$,其中 $V = \{u_i | i = 1, 2, \dots, NK + q\}$ 表示节点集合, $E = \{e_{ijn} | i = 1, 2, \dots, NK + q; j = 1, 2, \dots, NK + q; n = 1, 2, \dots\}$ 表示边集合, e_{ijn} 表示节点 i 和节点 j 之间有 n 条边。为提高图神经网络在节点更新时能够聚合更多的节点信息,增加节点间的相对度量信息构成节点间一条边,称为相对度量边 e_{ij1} ,表示节点 i 和节点 j 之间第 1 个维度边特征,再和节点间的相似性边 e_{ij2} 、不相似性边 e_{ij3} 共同构成图的双边,其中 e_{ij2} 和 e_{ij3} 都表示节点间的相似程度,因此可看成 1 条边。相对度量边由初始化双节点 u_i^0 错位相减后计算节点间的相对度量得到。初始化节点错位相减表示为

$$u_i^0 = u_{i_{RGB}}^0 || u_{i_{gray}}^0 \quad (i = 1, 2, \dots, NK + q) \quad (2)$$
$$v_i^0 = \begin{cases} u_i^0 - u_{i+1}^0 & (i = 1, 2, \dots, NK + q - 1) \\ u_i^0 - u_1^0 & (i = NK + q) \end{cases} \quad (3)$$

式中 $u_{i_{RGB}}^0、u_{i_{gray}}^0$ ——第 i 个初始化 RGB 节点和灰度节点

$||$ ——拼接符号

v_i^0 ——错位相减后的节点

构建初始化相对度量表示边 e_{ij1}^0 为

$$e_{ij1}^0 = 1 - \frac{\|v_i^0 - v_j^0\|}{\sum_k \|v_i^0 - v_k^0\|_2} \quad ((x_i, y_i) \in S \cup Q) \quad (4)$$

式中 $v_i^0、v_j^0、v_k^0$ ——双节点特征错位相减后 3 个任意的节点向量

$\|\cdot\|_2$ ——二范式

$\|\cdot\|$ ——取模

基于相对度量表示边特征再结合节点间两两相似结构 e_{ij2}^0 和不相似结构 e_{ij3}^0 来对图的边进行初始化。因此边特征可用不同的度量方式表示为

$$e_{ij}^0 = \begin{cases} [e_{ij1}^0 || e_{ij2}^0 = 1 || e_{ij3}^0 = 0] & (y_i = y_j, (x_i, y_i) \in S) \\ [e_{ij1}^0 || e_{ij2}^0 = 0 || e_{ij3}^0 = 1] & (y_i \neq y_j, (x_i, y_i) \in S) \\ [e_{ij1}^0 || e_{ij2}^0 = 0.5 || e_{ij3}^0 = 0.5] & (\text{其他}) \end{cases} \quad (5)$$

式中 e_{ij}^0 ——初始化后的边特征

相似性边 e_{ij2}^0 和不相似性边 e_{ij3}^0 根据支持集 S 中样本的标签信息和查询集 Q 中的样本信息 (x_i, y_i) 进行初始化。

2.2 双节点更新模块

基于构造的初始化图,双节点-双边图神经网络方法通过更新节点和边特征,优化图结构。每层图神经网络进行更新,即对节点和边进行更新,经过 k 层图神经网络更新后图结构达到最优, k 由网络训练而来。图神经网络更新过程中的层数用 l 表示, $l \in \{1, 2, \dots, k\}$ 。最后通过边特征度量查询集和支持集节点之间的关系实现查询集样本的分类。本文方法按照先对节点进行更新再对边进行更新的顺序进行。

由于 DNDE - GNN 网络模型的节点由 RGB 子节点和灰度子节点构成,本文方法对 RGB 节点和灰度节点分别更新后进行拼接完成双节点的更新。如图 4 所示。




图 4 双节点更新示意图

Fig.4 Diagram of two-node update

节点通过边特征连接的邻接子节点特征分别聚合到 RGB 子节点和灰度子节点中,聚合后的节点输入节点特征更新网络实现 RGB 节点和灰度节点的

维度标准化。本文构造图的子节点均由节点特征更新模块映射为 128 维,最后 2 个子节点融合成新的 256 维节点,完成双节点更新。RGB 子节点和灰度

子节点特征更新公式为

$$\begin{cases} u_{\text{gray},i}^l = f_{u1} \left(\left[\sum_j e_{ij1}^{l-1} u_{\text{gray},j}^{l-1} \parallel \sum_j e_{ij2}^{l-1} u_{\text{gray},j}^{l-1} \parallel \sum_j e_{ij3}^{l-1} u_{\text{gray},j}^{l-1} \right], W_{u1}^l \right) \\ u_{\text{RGB},i}^l = f_{u2} \left(\left[\sum_j e_{ij1}^{l-1} u_{\text{RGB},j}^{l-1} \parallel \sum_j e_{ij2}^{l-1} u_{\text{RGB},j}^{l-1} \parallel \sum_j e_{ij3}^{l-1} u_{\text{RGB},j}^{l-1} \right], W_{u2}^l \right) \end{cases} \quad (6)$$

式中 $u_{\text{gray},j}^{l-1}$ 、 $u_{\text{RGB},j}^{l-1}$ ——第 $l-1$ 层的灰度和 RGB 节点特征

$u_{\text{gray},i}^l$ 、 $u_{\text{RGB},i}^l$ ——第 l 层的灰度和 RGB 节点特征

由第 $l-1$ 层的节点特征 $u_{\text{gray},j}^{l-1}$ 和 $u_{\text{RGB},j}^{l-1}$ 更新第 l 层的节点特征 $u_{\text{gray},i}^l$ 和 $u_{\text{RGB},i}^l$ 。第 $l-1$ 层每个子节点通过边汇聚邻接节点特征来更新子节点特征,更新后的子节点特征作为第 l 层的节点特征。 e_{ij1}^{l-1} 、 e_{ij2}^{l-1} 和 e_{ij3}^{l-1} 表示第 $l-1$ 层的节点间边特征,由于边特征可表示节点间的相同程度,因此通过汇聚邻接节点特征可充分利用类内节点的相似性和类间节点的差异性,提高节点特征的度量能力。由于本文的双节点特性,子节点通过汇聚后进行拼接,因此 $\sum_j e_{ij1}^{l-1} u_{\text{gray},j}^{l-1} \parallel \sum_j e_{ij2}^{l-1} u_{\text{gray},j}^{l-1} \parallel \sum_j e_{ij3}^{l-1} u_{\text{gray},j}^{l-1}$ 表示灰度子节点汇聚通过边特征连接的邻接灰度子节点特征, $\sum_j e_{ij1}^{l-1} u_{\text{RGB},j}^{l-1} \parallel \sum_j e_{ij2}^{l-1} u_{\text{RGB},j}^{l-1} \parallel \sum_j e_{ij3}^{l-1} u_{\text{RGB},j}^{l-1}$ 表示 RGB 子节点汇聚通过边特征连接的邻接 RGB 子节点特征。RGB 子节点和灰度子节点分别汇聚邻接节点特征后,子节点特征维度发生变化,通过子节点特征更新网络 MLP 模块后依然保持为 128 维, f_{u1} 和 f_{u2} 表示节点特征网络 MLP, W_{u1}^l 和 W_{u2}^l 分别表示子节点特征更新网络的参数集。RGB 子节点和灰度子节点分别完成更新后获得新的 l 层节点特征 $u_{\text{gray},i}^l$ 和 $u_{\text{RGB},i}^l$,将子节点特征拼接完成双节点特征 u_i^l 的更新公式为

$$u_i^l = u_{\text{gray},i}^l \parallel u_{\text{RGB},i}^l \quad (7)$$

2.3 双边更新模块

本文图结构的边由相对度量边和相似性边构成。对于相对度量边,双节点错位相减得到相对度量节点 v_i^l 为

$$v_i^l = \begin{cases} u_i^l - u_{i+1}^l & (i = 1, 2, \dots, NK + q - 1) \\ u_i^l - u_1^l & (i = NK + q) \end{cases} \quad (8)$$

式中, u_i^l 表示相似性节点,当 $i = 1, 2, \dots, NK + q - 1$ 时,第 i 个相似性节点减第 $i-1$ 个相似性节点得到相对度量节点,当 $i = NK + q$,即最后一个相似性节点减去第 1 个相似性节点得到相对度量节点。 v_i^l 表示相对度量节点,用于更新相对度量边。根据 u_i^l 得到相对度量节点 v_i^l 后,再对相对度量节点进行距离度量编码,最后将距离编码通过 MLP 模块映射成表

示节点间相对度量的特征,从而实现相对度量边 e_{ij1}^l 特征更新。

$$e_{ij1}^l = f_1^l(\|v_i^l - v_j^l\|_2, W_1^l) \quad (9)$$

式中 e_{ij1}^l ——更新后的相对度量边,由相对度量节点 v_i^l 间距离度量特征映射得到

f_1^l ——特征映射函数

W_1^l —— f_1^l 的网络参数

对于相似性边,直接使用更新后双节点的距离度量编码,同样将距离度量编码通过 MLP 模块,使距离度量编码映射成表示节点间相似性的特征向量,从而更新相似性边 e_{ij2}^l 为

$$e_{ij2}^l = f_2^l(\|u_i^l - u_j^l\|_2, W_2^l) \quad (10)$$

式中 e_{ij2}^l ——更新后的相似性边,由更新后节点特征 u_i^l 间距离度量特征映射得到

f_2^l ——特征映射函数

W_2^l —— f_2^l 的网络参数

边更新过程聚合了节点间不同域信息,MLP 作为节点距离度量编码的特征映射网络,该网络由 n 个 Conv - BN - ReLU 卷积块组成,本文中 $n = 2$,使节点间的距离度量编码映射成表示节点间相对度量和相似性的边特征。经过特征映射后,相似性边和相对度量边聚合了节点间的多维信息,并且包含 RGB 子节点和灰度子节点的距离度量信息以及上一层图中自身边缘信息,提高了边特征对同类节点间的度量能力和不同类节点间的区分能力,使边特征具有更强的表征能力。

2.4 损失函数

图神经网络元学习通常将图神经网络作为分类器或者特征适应模块调整特征嵌入后再分类,本文特征适应模块即为双节点和双边更新模块,图神经网络在整体训练过程中相当于元模型,所有任务的图神经网络共享元参数。首先将每个 $N\text{way} - K\text{shot}$ 分类任务的支持集和查询集样本构造全连接图,基于节点的基本分类思想,将全连接图经过图神经网络对查询样本进行分类,即可得到每个任务中查询样本的预测结果,最终通过预测结果与真实结果的损失值训练图神经网络。在训练过程中,每个任务都构建一个图,如 $5\text{way} - 1\text{shot}$ 实验设置,支持集节点为 5 个,查询集节点为 1 个,图节点为 6 个,选择使所有任务的总损失最小的模型参数作为图神经网络模型的最优参数。

本文查询集样本的分类预测结果通过边标签预测与支持集样本标签来获得, DNDE - GNN 对图结构进行 l 层更新后得到的边特征输入 Softmax 函数进行计算, 采用双边共同预测查询集标签, 概率计算公式为

$$p_{ij} = f_s \left(\sum_{j=1}^{NK} (e_{ij1}^l || e_{ij2}^l) \text{one-hot}(y_j) \right) \quad (11)$$

式中 p_{ij} ——样本 x_i 属于样本 x_j 的概率
 f_s ——Softmax 函数
 $\text{one-hot}(y_j)$ ——样本 x_j 的标签, 通过 one-hot 编码实现

本文网络采用端到端的方式进行训练, 根据预测结果最小化损失函数 L 为

$$L = L_{BCE}(y_j, p_{ij}) \quad (12)$$

式中 L_{BCE} ——二元交叉熵损失函数
 y_j ——真实标签

本文图结构上包含多个类别病害的节点, 图结构的真实边标签为第 i 个节点和第 j 个节点属于同类别的概率, 同类节点边标签为 1, 不同类节点边标签为 0。测试时, 查询集和支持集节点构成预测的边标签, 由于图结构上包含多个类别, 若预测的边标签和真实的边标签对应值越接近, 说明查询集节点属于某个类别的概率预测的越准确, 采用二元交叉熵损失来约束真实边标签和预测的边标签, 实际就是提高查询集节点属于某个类别的预测概率, 因此查询集节点与每个类别的节点计算边标签作为预测的边标签, 与某个类的边标签越大即认为查询集节点属于该类的概率越大, 最后取概率最大的类作为最终结果。

3 结果与分析

3.1 实验设置

本文实验运行配置为 i9 - 12900K CPU, GeForce RTX3090 - OX24G GPU, 具体实验设置如下: 2 个独立的 ResNet12 嵌入模块提取特征为 128 维的 2 个特征向量构成节点特征。根据元学习训练方法, 优化器均采用 Adam 优化器, 初始学习率为 10^{-3} , 权重衰减为 10^{-6} , 最终结果采用每 1 000 轮的平均准确率表示。DNDE - GNN 网络模型的实验评估在数据集 miniImageNet、PlantVillage 和茶叶数据集 TeaD - 5 上进行, 采用的评价方法遵循图神经网络小样本学习中提出的评价方法^[25], 给出随机抽取任务的平均准确率。

3.2 对比实验

3.2.1 不同网络模型分类结果

首先, 为验证骨干网络的选取对本文分类性能

的影响, 在 miniImageNet 上做了不同骨干网络的对比实验, 如表 2 所示。其次, 为验证本文分类方法的有效性, 在 miniImageNet 数据集、PlantVillage 数据集和采集的茶叶病害 TeaD - 5 数据集上对比了几种不同小样本学习方法, 包括具有图结构和非图结构的小样本学习方法。如表 3 ~ 5 所示, 分别是在 miniImageNet 数据集、PlantVillage 数据集和 TeaD - 5 数据集上 5way - 1shot 和 5way - 5shot 的分类准确率, 其中在 miniImageNet 上对比了不同骨干网络的分类结果, 其中 ConvNet - 4 主要由 4 个不同大小卷积块组成, 每个卷积块均包含 Conv - BN - ReLU 结构, 卷积核大小为 3×3 。通过多次堆叠卷积层和池化层来逐渐提取图像的特征。

表 2 miniImageNet 数据集上不同骨干网络的分类准确率
Tab. 2 Classification accuracy of different backbone networks on miniImageNet dataset %

骨干网络	5way - 1shot	5way - 5shot
ConvNet - 4	63. 68	80. 48
ResNet18	61. 18	78. 54
ResNet34	60. 19	76. 65
ResNet50	59. 26	74. 83
VGG16	58. 26	73. 35
DenseNet	59. 64	75. 06
本文方法	69. 30	82. 48

表 3 miniImageNet 数据集上小样本分类的准确率
Tab. 3 Accuracy of small sample classification on miniImageNet dataset %

方法	Backbone	5way - 1shot	5way - 5shot
PROTO NET ^[26]	ConvNet	49. 42	68. 20
MAML ^[27]	ConvNet - 4	48. 70	55. 31
GNN ^[14]	ConvNet - 4	50. 33	66. 41
EGNN ^[15]	ConvNet - 4	59. 63	76. 34
HGNN ^[28]	ConvNet - 4	60. 03	79. 64
DPGN ^[16]	ConvNet - 4	66. 01	82. 83
本文方法	ConvNet - 4	63. 68	80. 48
TADAM ^[29]	ResNet12	58. 50	76. 70
FEAT ^[30]	ResNet12	62. 96	78. 49
MDE - GNN ^[31]	ResNet12	62. 23	78. 83
DPGN ^[16]	ResNet12	67. 77	84. 60
本文方法	ResNet12	69. 30	82. 48

表 2 展示了不同骨干网络对分类准确率的影响, 发现骨干网络不宜选择较深层的网络, 原因是训练数据集较小, 使用较深层的网络会导致过拟合 (如 ResNet50), 而使用 ResNet12 能够避免这种情况, 并且本文不同茶叶病害特征区分度大, 特征复杂程度不高, 因此较浅的网络足够提取所需信息, 而较深网络可能会导致过度拟合。

表 4 PlantVillage 数据集上小样本分类的准确率

Tab.4 Accuracy of small sample classification on

PlantVillage dataset		%
方法	5way-1shot	5way-5shot
MATCHING NETS ^[32]	78.86	85.47
PROTO NET ^[26]	80.65	90.71
RELATION NET ^[33]	82.18	91.63
EGNN ^[15]	74.98	82.56
HGNN ^[26]	84.56	89.78
DPGN ^[16]	86.18	90.73
本文方法	88.42	93.04

表 5 茶叶数据集 TeaD-5 上小样本分类的准确率

Tab.5 Accuracy of small sample classification on

TeaD-5 dataset		%
方法	5way-1shot	5way-5shot
MATCHING NETS ^[32]	61.12	66.76
PROTO NET ^[26]	69.74	75.84
RELATION NET ^[33]	76.34	81.25
EGNN ^[15]	74.19	79.36
HGNN ^[26]	77.42	80.52
DPGN ^[16]	82.25	84.06
本文方法	84.74	86.34

根据表 3 和表 4 可知,在公共数据集 miniImageNet 和 PlantVillage 上,与目前主流的图神经网络对比,5way-1shot 的分类准确率分别达到 69.30% 和 88.42%,分别提升了 1.53、2.24 个百分点,5way-5shot 的分类准确率分别达到 82.48% 和 93.04%,表明在公共数据上具有良好的性能表现。根据表 5 可知,在茶叶数据集 TeaD-5 上,本文方法的 5way-1shot 和 5way-5shot 的分类准确率分别达到 84.74% 和 86.34%。与目前较好的非图网络小样本学习算法和图网络小样本学习算法相比均取得较好效果。与经典的小样本非图网络对比,如原型网络(Prototypical networks)、匹配网络等,小样本非图网络训练时没有类别间关系信息,DNDE-GNN 由于图结构的边特征引入类别相同程度信息,从而增加了类别间关系信息,因此较小样本非图网络的效果有所提升。与单节点图网络小样本学习(如 EGNN)相比,双节点特性提升了节点特征的表征能力,使节点包含茶叶病害多维度的信息。与单边图神经网络(如 DPGN)相比,5way-1shot 实验设置下茶叶数据集 TeaD-5 较 DPGN 提升 2.49 个百分点,本文由于双边特性,提高了边对节点的度量能力,从而使预测的边标签更加准确,但 5way-5shot 实验设置下效果没有达到最好,原因可能是 DPGN 的双图结构较本文单图效果明显。实验表明本文改进的网络能较好地针对茶叶病害数据的

特点实现病害分类。

3.2.2 显著性区域可视化

针对本文嵌入模块 ResNet12 最后一个卷积块提取到的特征,选取 4 种茶叶病害样本的 RGB 图像与灰度图像进行了显著性区域可视化,实验目的是分析不同域图像特征显著性区域差别,实验结果如图 5 所示,表明 RGB 图像和灰度图像关注的信息区域不同。颜色越深的区域代表显著性越高,从不同域显著性区域可视化图中可知,同一样本的 RGB 图像和灰度图像显著性差别较大,使用 2 个域的图像可充分提取样本中所含的病害特征,增加不同域图像的显著性信息。




图 5 RGB 图像和灰度图像显著性区域可视化

Fig.5 RGB image and grayscale image significance area visualization

3.3 消融实验

双节点和双边图结构是本文 DNDE-GNN 网络结构的重要构成部分。为了验证本文双节点和双边结构的有效性,分析了加入灰度节点和相对度量边对网络分类性能的影响。为此分别在 5way-1shot 和 5way-5shot 进行 4 组消融实验讨论改进部分的有效性,实验在茶叶数据集 TeaD-5 上进行,4 组实验组合方式和分类结果如表 6 所示,其中√表示该部分存在于网络结构中。

表 6 灰度节点、相对度量边消融实验准确率

Tab.6 Gray node and relative metric edge ablation

experiment		%	
灰度节点	相对度量边	5way-1shot	5way-5shot
√		74.19	79.36
		76.38	82.54
	√	81.51	84.23
√	√	84.74	86.36

表 6 表明增加灰度节点和相对度量边对网络性能均有提升。结果验证了灰度子节点可有效提高网络对茶叶病害特征的表征能力,并且双节点结构可有效聚合更新病害特征,增加的相对度量边能提高边特征对节点的度量能力,使边特征度量节点类别时更加准确,从而提高茶叶病害分类的准确率。

3.4 超参数讨论

DNDE-GNN 构造了具有双节点的图神经网络

络,增加了节点中包含的灰度信息。图构造时需初始化节点维度,并且需选取双节点更新时的节点维度。为了讨论节点维度对网络性能的影响,本文在茶叶数据集 TeaD-5 上进行超参数实验,首先确定双节点更新时效果最好的子节点维度,通过控制节点初始化时嵌入模块提取到的图像特征维度,在 5way-1shot 的实验设置下进行 5 组实验,结果如图




图 6 TeaD-5 数据集上不同节点维度的实验结果

Fig. 6 Experimental results of different node dimensions on TeaD-5 dataset

本文方法和其他图神经网络方法在茶叶数据集 TeaD-5 上的 5way-1shot 和 5way-5shot 分类损失函数曲线如图 7 所示。由图 7 可知,本文双节点-双




图 7 不同图神经网络的损失函数对比图

Fig. 7 Comparison of loss functions of neural networks with different graphs

法分别直到 41 000 步和 32 000 步后才开始趋于稳定。同样在 5way-5shot 的实验设置下,DNDE-GNN 模型较其他两种算法收敛更快。

4 结束语

提出了一种双节点-双边图神经网络的茶叶病害分类方法,该网络采用不同域的图像作为图结构的 2 个子节点,分别为 RGB 子节点和灰度子节点,充分利用样本不同域图像存在的多维特征信息,提

6a 所示。选择效果最好的初始化节点维度,通过设置双节点更新时子节点特征维度,同样在 5way-1shot 的实验设置下进行 5 组实验,结果如图 6b 所示。结果表明,初始化节点维度和节点更新时子节点维度均取 128 维时,5way-1shot 分类效果最佳。因此,本文初始化节点维度和节点更新时子节点维度均设置为 128 维。

边结构相对其他图神经网络在训练期间表现更好,并且在 5way-1shot 实验设置下,DNDE-GNN 模型在 30 000 次迭代后趋于稳定,而 DPGN 和 EGNN 算

高了节点特征对样本的表达能力。同时为提高边特征对节点的距离度量能力,增加了相对度量边构成双边。初始化图结构后对双节点和双边进行交替更新,使节点聚合更多邻接节点包含的病害信息,通过更新后节点的距离编码更新边特征,使边特征包含丰富的节点度量信息,提高了边特征度量节点类别的准确性。大量实验结果表明,在小样本茶叶病害分类领域,DNDE-GNN 的分类性能优于其他先进的小样本分类方法。

参 考 文 献

[1] 王亚辉. 脱贫攻坚与茶乡村振兴衔接的路径研究[J]. 福建茶叶, 2023, 45(3): 6-8.
WANG Yahui. Research on the connecting path between poverty alleviation and revitalization of tea villages[J]. Fujian Tea, 2023, 45(3): 6-8. (in Chinese)

[2] 林彬彬,邱新法,何永健,等. 茶树病害智能诊断识别算法研究[J]. 江苏农业科学,2019,47(6):85-91.
LIN Binbin, QIU Xinfa, HE Yongjian, et al. Study on intelligent diagnosis and recognition algorithm for tea diseases[J]. Jiangsu Agricultural Sciences, 2019, 47(6): 85-91. (in Chinese)

[3] 宋凯,孙晓艳,纪建伟. 基于支持向量机的玉米叶部病害识别[J]. 农业工程学报,2007,23(1):155-157.
SONG Kai, SUN Xiaoyan, JI Jianwei. Corn leaf disease recognition based on support machine method[J]. Transactions of the CASE, 2007,23(1): 155-157. (in Chinese)

[4] CHAUDHARY A, KOLHE S, KAMAL R. An improved random forest classifier for multi-class classification[J]. Information Processing in Agriculture, 2016, 3(4): 215-222.

[5] 张建华,孔繁涛,吴建寨,等. 基于改进 VGG 卷积神经网络的棉花病害识别模型[J]. 中国农业大学学报,2018,23(11):161-171.
ZHANG Jianhua, KONG Fantao, WU Jianzhai, et al. Cotton disease recognition model based on improved VGG convolutional neural network[J]. Journal of China Agricultural University, 2018,23(11): 161-171. (in Chinese)

[6] 刘合兵,鲁笛,席磊. 基于 MobileNetV2 和迁移学习的玉米病害识别研究[J]. 河南农业大学学报,2022,56(6):1041-1051.
LIU Hebing, LU Di, XI Lei. Maize disease recognition based on MobileNetV2 and transfer learning[J]. Journal of Henan Agricultural University, 2022,56(6): 1041-1051. (in Chinese)

[7] 姜红花,杨祥海,丁睿柔,等. 基于改进 ResNet18 的苹果叶部病害多分类算法研究[J]. 农业机械学报,2023,54(4):295-303.
JIANG Honghua, YANG Xianghai, DING Ruirou, et al. Research on multi-classification algorithm of apple leaf diseases based on improved ResNet18[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023,54(4): 295-303. (in Chinese)

[8] 邢鹏康,李久朋. 基于小样本学习的马铃薯叶片病害检测[J]. 江苏农业科学,2023,51(15):203-210.
XING Pengkang, LI Jiupeng. Potato leaf disease detection based on small sample learning[J]. Jiangsu Agricultural Sciences, 2023, 51(15): 203-210. (in Chinese)

[9] 李子茂,徐杰,郑禄,等. 基于改进 DenseNet 的茶叶病害小样本识别方法[J]. 农业工程学报,2022,38(10):182-190.
LI Zimao, XU Jie, ZHENG Lu, et al. Small sample identification method of tea diseases based on improved DenseNet[J]. Transactions of the CASE, 2022, 38(10): 182-190. (in Chinese)

[10] 祝钧桃,姚光乐,张葛祥,等. 深度神经网络的小样本学习综述[J]. 计算机工程与应用,2021,57(7):22-33.
ZHU Juntao, YAO Guangle, ZHANG Gexiang, et al. A review of small sample learning for deep neural networks[J]. Computer Engineering and Applications, 2021,57(7): 22-33. (in Chinese)

[11] 赵凯琳,靳小龙,王元卓. 小样本学习研究综述[J]. 软件学报,2021,32(2):349-369.
ZHAO Kailin, JIN Xiaolong, WANG Yuanzhuo. A review of small sample learning[J]. Journal of Software,2021, 32(2): 349-369. (in Chinese)

[12] 王淑栋,安迪,庞善臣. 基于图神经网络的多维度池化图分类[J]. 计算机系统应用,2023,32(6):22-31.
WANG Shudong, AN Di, PANG Shanchen. Multi-dimensional pooling graph classification based on graph neural network[J]. Computer System Applications, 2023, 32(6): 22-31. (in Chinese)

[13] 刘颖,车鑫. 基于图网络优化及标签传播的小样本图像分类算法[J]. 信号处理,2022,38(1):202-210.
LIU Ying, CHE Xin. Small sample image classification algorithm based on graph network optimization and label propagation [J]. Signal Processing, 2022, 38(1): 202-210. (in Chinese)

[14] GARCIA V, BRUNA J. Few-shot learning with graph neural networks[J]. arXiv preprint arXiv:1711.04043, 2017.

[15] KIM J, KIM T, KIM S, et al. Edge-labeling graph neural network for few-shot learning[C] // IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 11-20.

[16] YANG L, LI L, ZHANG Z, et al. DPGN: distribution propagation graph network for few-shot learning[C] // IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 13387-13396.

[17] CHEN Dongyue, LIU Ruonan, HU Qinghua, et al. Interaction-aware graph neural networks for fault diagnosis of complex industrial processes[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021(4): 1-14.

[18] 郭文,游思思,高君宇,等. 深度相对度量学习的视觉跟踪[J]. 中国科学:信息科学,2018,48(1):60-78.
GUO Wen, YOU Sisi, GAO Junyu, et al. Visual tracking of depth relative metric learning[J]. Science in China: Information Science, 2018,48(1): 60-78. (in Chinese)

[19] 李凡长,刘洋,吴鹏翔,等. 元学习研究综述[J]. 计算机学报,2021,44(2):422-446.
LI Fanchang, LIU Yang, WU Pengxiang, et al. A review of meta-learning research[J]. Journal of Computer Science,2021, 44(2):422-446. (in Chinese)

[20] LÜ Qiujie, CHEN Guanxing, YANG Ziduo, et al. Meta learning with graph attention networks for low-data drug discovery[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023(8): 158-176.

[21] WU Yue, HU Xidao, FAN Xiaolong, et al. Learning data-driven propagation mechanism for graph neural network[J]. Electronics,2022,12(1): 46-60.

[22] 邵云飞,宋友,王宝会. 基于社交网络图节点度的神经网络个性化传播算法研究[J]. 计算机科学,2023,50(4):16-21.

SHAO Yunfei, SONG You, WANG Baohui. Research on neural network personalized propagation algorithm based on node degree of social network graph[J]. Computer Science, 2023,50(4): 16 – 21. (in Chinese)

[23] 李凡. 基于图神经网络的小样本图像分类算法研究[D]. 邯郸:河北工程大学,2022.
LI Fan. Research on small sample image classification algorithm based on graph neural network[D]. Handan:Hebei University of Engineering, 2022. (in Chinese)

[24] 刘杰,尚学群,宋凌云,等. 图神经网络在复杂图挖掘上的研究进展[J]. 软件学报,2022,33(10):3582 – 3618.
LIU Jie, SHANG Xuequn, SONG Lingyun, et al. Research progress of graph neural network in complex graph mining[J]. Journal of Software, 2022, 33(10): 3582 – 3618. (in Chinese)

[25] YE Hanjia, HU Hexiang, ZHAN Dechuan, et al. Learning embedding adaptation for few-shot learning[J]. arXiv preprint arXiv:1812.03664, 2018.

[26] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[J]. Advances in Neural Information Processing Systems, 2017(6): 30 – 44.

[27] LAKE B M, SALAKHUTDINOV R, TENENBAUM J B. Human-level concept learning through probabilistic program induction [J]. Science, 2015, 350(6266): 1332 – 1338.

[28] CHEN C, LI K, WEI W, et al. Hierarchical graph neural networks for few-shot learning[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2021, 32(1): 240 – 252.

[29] BORIS N O, PAU R, ALEXANDRE L. Tadam: task dependent adaptive metric for improved few-shot learning[J]. In Advances in Neural Information Processing Systems, 2018, 21(7): 721 – 731.

[30] WAH C, BRANSON S, WELINDER P, et al. The caltech-ucsd birds-200-2011 dataset [J]. California Institute of Technology, 2011, 21(2): 101 – 120.

[31] XIONG C, LI W, LIU Y, et al. Multi-dimensional edge features graph neural network on few-shot image classification[J]. IEEE Signal Processing Letters, 2021, 28(5): 573 – 577.

[32] VINIYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[J]. Advances in Neural Information Processing Systems, 2016, 16(8): 29 – 46.

[33] SUNG F, YANG Y, ZHANG L, et al. Learning to compare: relation network for few-shot learning[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 1199 – 1208.

~~~~~

(上接第 242 页)

[18] YAN B, FAN P, LEI X, et al. A real-time apple targets detection method for picking robot based on improved YOLO v5[J]. Remote Sensing, 2021, 13(9): 1619.

[19] MA J, LU A, CHEN C, et al. YOLO v5-lotus an efficient object detection method for lotus seedpod in a natural environment [J]. Computers and Electronics in Agriculture, 2023, 206: 107635.

[20] HU Weixin, XIONG Juntao, LIANG Junhao, et al. A method of citrus epidermis defects detection based on an improved YOLO v5[J]. Biosystems Engineering, 2023, 227: 19 – 35.

[21] CAO Z, MEI F, ZHANG D, et al. Recognition and detection of persimmon in a natural environment based on an improved YOLO v5 model[J]. Electronics, 2023, 12(4): 785.

[22] 龙燕,杨智优,何梦菲. 基于改进 YOLO v7 的疏果期苹果目标检测方法[J]. 农业工程学报,2023,39(14):191 – 199.  
LONG Yan, YANG Zhiyou, HE Mengfei. Recognizing apple targets before thinning using improved YOLO v7 [J]. Transactions of the CSAE, 2023, 39(14): 191 – 199. (in Chinese)

[23] LU S, CHEN W, ZHANG X, et al. Canopy-attention-YOLO v4-based immature/mature apple fruit detection on dense-foliage tree architectures for early crop load estimation[J]. Computers and Electronics in Agriculture, 2022, 193: 106696.

[24] WANG X, WU Z, JIA M, et al. Lightweight SM – YOLO v5 tomato fruit detection algorithm for plant factory[J]. Sensors, 2023, 23(6): 3336.

[25] HU X, ZHANG Y, CHEN Y, et al. Lightweight pear detection algorithm based on improved YOLO v5 [C] // International Conference on Mechatronics Engineering and Artificial Intelligence (MEAI 2022). SPIE, 2023: 490 – 494.

[26] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLO v7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[J]. arXiv e-prints, arXiv: 2207. 02696, 2022.

[27] CHEN J, KAO S, HE H, et al. Run, don't walk: chasing higher FLOPS for faster neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 12021 – 12031.

[28] WANG Q, WU B, ZHU P, et al. ECA – Net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020: 11534 – 11542.

[29] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering an Open Access Journal, 2020, 8(1):22 – 34.