

文章编号: 2095-2163(2024)03-0163-05

中图分类号: TP391.41

文献标志码: A

基于自适应权重优化的多任务深度学习模型在甘蔗病害识别中的应用

李冬睿, 邱尚明, 杨善友

(广东农工商职业技术学院 计算机学院, 广州 510507)

摘要: 针对农业领域中甘蔗病害识别的准确率和任务间平衡的问题, 提出一种基于自适应权重优化的多任务深度学习模型。该模型采用包含3种病害和1种健康状态的甘蔗叶片图像数据集, 通过卷积神经网络(CNN)和多任务学习(MTL)实现病害识别。在模型训练过程中, 为应对不同任务间的不平衡问题, 引入了自适应权重优化方法。实验结果表明, 该模型能显著提高甘蔗病害识别准确率, 并在多任务之间实现平衡, 为甘蔗智能化种植发展提供一定的借鉴。

关键词: 深度学习; 甘蔗病害识别; 多任务学习; 自适应权重优化

Research on the application of multi-task deep learning model based on adaptive weight optimization in sugarcane disease identification

LI Dongrui, QIU Shangming, YANG Shanyou

(School of Computer, Guangdong Agriculture Industry Business Polytechnic, Guangzhou 510507, China)

Abstract: This work proposes a multi-task deep learning model based on adaptive weight optimization, in order to solve the problem of the accuracy of sugarcane disease recognition and the balance between tasks in the agricultural field. The model uses a sugarcane leaf image dataset containing 3 diseases and 1 health state, and realizes disease recognition through convolutional neural network (CNN) and multi-task learning (MTL). In the process of model training, in order to deal with the imbalance between different tasks, an adaptive weight optimization method is introduced. The experimental results show that the model can significantly improve the accuracy of sugarcane disease identification, and achieve the balance between multiple tasks, providing a certain reference for the development of sugarcane intelligent planting.

Key words: deep learning; sugarcane disease recognition; multi-task learning; adaptive weight optimization

0 引言

甘蔗是一种重要的经济作物, 被广泛种植于全球各地。然而, 甘蔗病害的发生和流行会造成严重的经济损失, 影响甘蔗的产量和质量。因此, 对甘蔗病害的及时识别和治疗具有重要意义。

传统的甘蔗病害识别方法主要依靠人工现场识别和专家判断, 但这种方法存在识别准确度低、诊断时间长、专业技能要求高等问题。随着深度学习技术的发展, 不少学者开始探索利用深度学习技术解决植物病害识别问题。如: 文献[1]利用计算机视觉技术从图像采集、预处理、分割、特征提取和分类

等多个环节对植物病害进行识别。文献[2]提出一种细粒度知识蒸馏模型, 将特征提取和细粒度知识表示能力迁移到轻量级网络, 提高苹果叶部病害的识别精度。文献[3]提出改进YOLOv3模型YOLO-SL, 融合注意力机制和小目标特征层, 在降低模型参数的同时提高葡萄叶病害检测精度。文献[4]提出多尺度特征融合和坐标注意力机制的MCA-MobileNet模型, 采用WGAN数据增强, 提高番茄病害识别准确率。文献[5]设计改进YOLOv5算法, 利用调整锚框、复合主干网和VarifocalLoss函数, 准确快速地检测苹果番茄叶片病害。文献[6]采用4种卷积神经网络模型和数据增强技术, 实现对农田

基金项目: 广东省教育厅普通高校重点领域专项(2022ZDZX1063, 2021ZDZX4116)。

作者简介: 邱尚明(1980-), 男, 硕士, 讲师, 主要研究方向: 图形图像处理、机器学习; 杨善友(1980-), 男, 硕士, 讲师, 主要研究方向: 图形图像处理、嵌入式开发。

通讯作者: 李冬睿(1983-), 男, 硕士, 副教授, 主要研究方向: 图形图像处理、人工智能。Email: ldr_1983@126.com

收稿日期: 2023-04-07

害虫图像的二分类识别。文献[7]提出了EWPRC结构,将改进的通道注意力机制应用于基于ResNet50的迁移学习模型中,在农作物病害分类任务上取得了比传统模型更好的性能表现。文献[8]针对谷子病害识别,提出了一种基于迁移学习和残差网络的方法,通过图像分割和数据增强,建立了高精度的谷子病害识别模型。文献[9]设计了DEFL模型解决苹果叶片病害识别中的难题,融合了并行特征提取网络和改进的损失函数,在提高识别精度的同时降低了模型复杂度,能够高效识别苹果病害。文献[10]提出了通过在深度学习模型中引入迁移学习,使复杂的自然环境下茶叶病害识别率得到有效提高。深度学习模型可以自动提取植物图像的病害特征,大幅度提高识别准确率,减少人工识别的工作量。

尽管前面介绍的文献在利用深度学习技术解决植物病害识别问题方面取得了一定进展,但却都存在共同的局限性:传统的深度学习模型通常只能针对单一任务进行训练,难以处理多任务的情况。在实际应用中,甘蔗病害识别常常涉及到多个病害类型的判断,需要考虑如何同时处理多个任务。为此,本文采用了多任务学习(Multi-Task Learning, MTL)^[11]的方法,利用一个模型同时学习多个任务,从而提高识别准确率。另外,在多任务学习中,不同任务之间的样本分布通常是不平衡的,这会导致模型在训练过程中偏向于处理样本数较多的任务,忽略样本数较少的任务。为了解决这个问题,本文提出了一种自适应权重优化的方法,可以自动调整不同任务之间的权重,从而平衡各个任务的重要性。

1 相关研究

1.1 深度学习

深度学习是一种基于神经网络的机器学习方法,具有强大的特征提取和模式识别能力。深度学习模型通常包括多个隐藏层,可以自动提取输入数据中的高层次特征。深度学习已经在图像识别、语音识别、自然语言处理等领域取得了重大进展。

卷积神经网络(Convolutional Neural Network, CNN)^[12]是深度学习中被广泛应用于图像处理的一种神经网络。CNN采用卷积层和池化层来提取图像特征,然后使用全连接层进行分类。CNN具有较强的图像特征提取能力和良好的分类性能,已经在许多图像识别任务中取得了优异的成绩。

1.2 多任务学习

多任务学习是指在一个模型中学习多个相关任务的过程。在多任务学习中,模型可以同时学习多个任务,共享模型的参数和特征表示,从而提高模型的泛化能力和效率^[13]。多任务学习已经被广泛应用于计算机视觉、自然语言处理、语音识别等领域。

在多任务学习中,不同任务之间的样本分布通常是不平衡的^[14]。这会导致模型在训练过程中偏向于处理样本数较多的任务,而对样本数较少的任务会被忽略。针对这些问题,可以使用加权损失函数、样本再平衡等技术解决。

2 基于自适应权重优化的多任务深度学习方法

2.1 多任务卷积神经网络模型

本文采用多任务学习的方法进行甘蔗病害识别。该模型由多个卷积层和全连接层组成,其中每个任务对应一个全连接层。在网络的前几层卷积层中,共享参数实现对不同任务的共享特征提取。在网络的后面几层,为每个任务分别设置全连接层,用于实现任务特定的分类。设总共有 K 个任务,则多任务学习的损失函数可以定义为:

$$L_{\text{total}} = \sum_{i=1}^K \alpha_i L_i \quad (1)$$

其中, L_i 表示第 i 个任务的损失函数, α_i 表示第 i 个任务的权重。

2.2 自适应权重优化

为了解决不同任务之间的样本分布不平衡问题,提出了一种自适应权重优化的方法,实现不同任务间权重的自动调整,从而平衡各个任务的重要性。采用了一种基于样本频率的自适应权重优化方法,对于第 i 个任务,可以计算出该任务中每个类别的样本频率,即:

$$f_{i,j} = \frac{N_{i,j}}{\sum_{k=1}^c N_{i,k}} \quad (2)$$

其中, $N_{i,j}$ 表示第 i 个任务中第 j 个类别的样本数, c 表示该任务中总的类别数。可以根据样本频率,计算出第 i 个任务的权重 α_i ,即:

$$\alpha_i = \frac{1}{\sqrt{\sum_{j=1}^c f_{i,j}^2}} \quad (3)$$

该权重计算方法可以使样本频率较低的类别在训练中获得更高的权重,从而平衡各个任务的重要性。在模型训练过程中,使用带权重的交叉熵损失函数作为每个任务的损失函数。设第 i 个任务有 N_i

个样本,其中第 j 个样本的标签为 $y_{i,j}$,则该任务的损失函数可以表示为:

$$L_i = -\frac{1}{N_i} \sum_{j=1}^{N_i} \sum_{k=1}^C w_{i,k} y_{i,j,k} \log p_{i,j,k} \quad (4)$$

其中, C 表示该任务中总的类别数; $w_{i,k}$ 表示第 i 个任务中第 k 个类别的权重; $y_{i,j,k}$ 表示第 j 个样本属于第 k 个类别的真实标签; $p_{i,j,k}$ 表示第 j 个样本属于第 k 个类别的预测概率。

为了使得不同任务的损失函数具有可比性,使用了加权损失函数,即:

$$L_{\text{total}} = \sum_{i=1}^K \beta_i L_i \quad (5)$$

其中, β_i 表示第 i 个任务的权重,可以通过交叉验证等方法进行调整。

2.3 模型架构

本文采用基于 ResNet^[15]的卷积神经网络作为多任务学习模型。该模型由多个 ResNet 模块和全连接层组成,其中每个任务对应一个全连接层。采用一个 18 层的 ResNet 模型作为基础网络,在 ResNet 模块的第一个卷积层中,使用 7×7 的卷积核,步长为 2,用于降低图像分辨率。在 ResNet 模块的每个残差块中,使用 1×1、3×3 和 1×1 的卷积核,用于提取图像特征。每个残差块由 2 个 3×3 的卷积层和一个 1×1 的卷积层组成,其中 1×1 的卷积层用于调整特征通道数。在模型的最后一层,使用了一个全局平均池化层和多个全连接层,用于实现任务特定的分类。

在训练过程中,使用随机梯度下降(Stochastic Gradient Descent,SGD)^[16]算法进行模型优化,采用了动量优化方法来加速模型收敛。初始学习率设置为 0.01,动量系数设置为 0.9。每个任务的权重和每个类别的权重都在训练过程中自适应调整。为了防止模型过拟合,采用了一些正则化技术,如随机裁剪、数据增强等。

3 实验结果分析

3.1 数据集

本文通过无人机和移动设备的实拍图片来构建甘蔗叶片图像数据集,数据集包括 3 种不同的病害和 1 种健康状态图像数据。每张图像都被标记为一种病害类型或健康状态。训练时输入图像的像素为 224×224。使用图像平移、旋转、随机裁剪和对比度增强等方法^[17]从每种病害样本中随机选择一部分进行增强数据集,经过数据增强后的数据集每种病

害类型和健康状态的样本数见表 1。

本文将数据集划分为训练集、验证集和测试集,其中训练集占总数据集的 70%,验证集占总数据集的 15%,测试集占总数据集的 15%。

表 1 数据集中每种病害类型和健康状态的样本数

Table 1 Number of samples for each disease type and health status in the dataset

序号	类别	样本数
1	健康状态	907
2	凤梨病	2 667
3	眼斑病	2 707
4	黄斑病	2 667

3.2 实验设置

本文基于 Python 的深度学习框架的 PyTorch 实现了所提出的多任务学习模型。在模型的训练过程中,采用随机裁剪、随机翻转的数据增强技术,以增加数据集的多样性,还将每个像素值除以 255,以将像素值归一化到[0, 1]的范围内。在训练过程中,使用批量大小为 64 的小批量随机梯度下降算法进行模型优化,训练轮数为 100 个 epoch。此外,采用正则化技术(如: dropout、L2 正则化^[18]),以防止模型过拟合。

为了评估所提出的多任务学习模型的性能,使用了准确率和混淆矩阵^[19]作为评价指标。准确率是指模型在测试集上正确分类的样本数占总样本数的比例;混淆矩阵是指将样本按照真实标签和预测标签^[20]进行分类,得到的一个二维矩阵。在混淆矩阵中,每一行表示真实标签,每一列表示预测标签,矩阵中的元素表示真实标签为行对应标签、预测标签为列对应标签的样本数。

将模型的训练集、验证集和测试集分别进行了五次交叉验证。在每次验证中,将数据集随机分为训练集、验证集和测试集,并分别进行模型训练、模型选择和模型测试。最终,将五次交叉验证的结果取平均,并计算准确率和混淆矩阵。

3.3 实验结果

本文采用 2 个基准模型进行比较,分别是单任务学习模型和基于 ResNet 的单任务学习模型。在单任务学习模型中,为每个病害类型分别训练一个单独的卷积神经网络;在基于 ResNet 的单任务学习模型中,采用 18 层的 ResNet 模型作为基础网络,为每个病害类型分别训练一个全连接层。

表2和表3分别给出了不同模型在测试集上的准确率和混淆矩阵。从表2中可以看出,多任务学习模型在测试集上的平均准确率为92.38%,明显高于单任务学习模型和基于ResNet的单任务学习模型。这表明多任务学习模型可以同时处理多种病害类型的识别问题,并具有更好的分类性能。

表2 不同模型在测试集上的准确率

Table 2 The accuracy of different models on the test set

模型	平均准确率/%
单任务学习模型	78.60
基于 ResNet 的单任务学习模型	88.27
多任务学习模型	92.38

表3 多任务学习模型在测试集上的混淆矩阵

Table 3 The confusion matrix of the multi-task learning model on the test set

真实标签	预测标签			
	健康状态	凤梨病	眼斑病	黄斑病
健康状态	134	0	0	2
凤梨病	2	359	38	1
眼斑病	0	57	348	1
黄斑病	2	0	0	398

由表3中可以看出,多任务学习模型在测试集上的混淆矩阵,对不同病害类型的识别效果较好,识别准确率均在90%以上。其中,对健康状态和黄斑病的识别效果最好,识别准确率分别为97.25%和94.75%。对于凤梨病和眼斑病的识别效果稍差,识别准确率分别为89.50%和87.25%。

此外,对多任务学习模型进行了不同参数设置的实验。分别调整了任务数量、自适应权重优化方法和基础网络结构,以评估这些参数对模型性能的影响。

分别将任务数量设置为2、3、4和5,以评估不同任务数量对模型性能的影响。不同任务数量下的模型准确率实验结果,见表4。由表4可以看出,当任务数量为2时,模型准确率最低,为87.25%;当任务数量为3时,模型准确率最高,为93.32%。随着任务数量的增加,由于多任务学习的复杂度增加导致训练难度加大,模型准确率逐渐降低。

分别将自适应权重优化方法改为均匀权重和固定权重,以评估不同权重优化方法对模型性能的影响,不同权重优化方法下的模型准确率见表5。由

表5可以看出,当使用自适应权重优化方法时,模型准确率最高,为92.38%;当使用均匀权重时,模型准确率较低,为89.74%;当使用固定权重时,模型准确率更低,为85.66%。表明自适应权重优化方法可以有效提高模型的性能。

表4 不同任务数量下的模型准确率

Table 4 Model accuracy under different number of tasks

任务数量	平均准确率/%
2	87.25
3	93.32
4	92.52
5	91.62

表5 不同权重优化方法下的模型准确率

Table 5 Model accuracy under different weight optimization methods

权重优化方法	平均准确率/%
自适应权重优化	92.38
均匀权重	89.74
固定权重	85.66

接下来,分别将基础网络结构改为ResNet-50和ResNet-101,以评估不同网络结构对模型性能的影响。不同网络结构下的模型准确率见表6。由表6可以看出,当使用ResNet-50作为基础网络时,模型准确率为91.93%;使用ResNet-101作为基础网络时,模型准确率略有提高,为92.83%。表明较深的基础网络可以提高模型的性能,但是也会增加模型的计算复杂度。

表6 不同基础网络结构下的模型准确率

Table 6 Model accuracy under different basic network structures

基础网络结构	平均准确率/%
ResNet-50	91.93
ResNet-101	92.83

综上所述,本文提出的基于自适应权重优化的多任务深度学习模型,在甘蔗病害识别中具有较好的性能。该模型可以同时处理多种病害类型的识别问题,且具有更好的分类性能。可以看出,任务数量、权重优化方法和基础网络结构等参数对模型性能具有一定的影响。因此,在实际应用中,需要根据具体情况进行参数调整。

4 结束语

本文提出了一种基于自适应权重优化的多任务深度学习模型用于甘蔗病害的识别。该模型可以同时处理多种病害类型的识别问题,且具有更好的分类性能。在实验中,将该模型与单任务学习模型和基于 ResNet 的单任务学习模型进行了比较,结果表明该模型在测试集上的平均准确率为 92.38%,明显高于其他模型。文中还对不同参数设置下的模型性能进行了实验,发现任务数量、权重优化方法和基础网络结构等参数对模型性能具有一定的影响。本文所提出的基于自适应权重优化的多任务深度学习模型在甘蔗病害识别中具有较好的性能和应用前景。

参考文献

- [1] 孙亮,柯宇航,刘辉,等. 计算机视觉技术在植物病害识别上的研究进展[J]. 热带生物学报, 2022, 13(6):651-658.
- [2] 李大湘,滑翠云,刘颖. 面向苹果叶部病害识别的细粒度蒸馏模型[J]. 农业工程学报, 2023, 39(7): 185-194.
- [3] 刘广,胡国玉,古丽巴哈尔·托乎提,等. 基于改进 YOLOv3 的葡萄叶部病虫害检测方法[J]. 微电子学与计算机, 2023, 40(2):110-119.
- [4] 王志强,于雪莹,杨晓婧,等. 基于 WGAN 和 MCA-MobileNet 的番茄叶片病害识别[J]. 农业机械学报, 2023, 54(5): 244-252.
- [5] 杨文姬,胡文超,赵应丁,等. 基于改进 Yolov5 植物病害检测算法研究[J]. 中国农机化学报, 2023, 44(1): 108-115.
- [6] 马鑫鑫,张巧雨,马越,等. 基于深度学习的农田害虫识别研究[J]. 信息与电脑(理论版), 2022, 34(24): 180-182.
- [7] 肖天赐,陈燕红,李永可,等. 基于改进通道注意力机制的农作物病害识别模型研究[J]. 江苏农业科学, 2023, 51(24): 168-175.
- [8] 张红涛,罗一铭,谭联,等. 基于迁移学习和残差网络的谷子病害识别研究[J]. 河南农业科学, 2023, 52(12): 162-171.
- [9] 王瑞鹏,陈锋军,朱学岩,等. 采用改进的 EfficientNet 识别苹果叶片病害[J]. 农业工程学报, 2023, 39(18): 201-210.
- [10] 谢森林,王春武,董晓庆,等. 基于深度迁移学习的凤凰单丛茶叶病害识别方法[J]. 韩山师范学院学报, 2023, 44(6): 12-17.
- [11] 黄宇琛,罗坚,阳强. 基于时空图像融合与多任务分类网络的步态识别研究[J]. 光学技术, 2023, 49(1):97-104.
- [12] 曲福恒,李婉婷,杨勇,等. 基于图像增强和注意力机制的作物杂草识别[J]. 计算机工程与设计, 2023, 44(3):815-821.
- [13] 郭政,吴武清,刘源,等. 基于多任务支持向量机的能源互联网数据深度融合方法[J]. 计算机应用与软件, 2023, 40(3): 22-27.
- [14] 范丽丽. 基于深度学习的视觉特征学习关键技术研究[D]. 长春:吉林大学, 2022.
- [15] 李华锋,黄永辉,梁诗维,等. 基于卷积神经网络的番茄主要病害识别方法研究[J]. 南方农机, 2023, 54(7):21-23.
- [16] 于沛宏. 基于元随机梯度下降的小样本 SAR 目标识别[C]//第十四届全国 DSP 应用技术学术会议. 北京:中国电子学会数字信号处理专家委员会, 2022:94-98.
- [17] 陈超. 机器学习在图像分析与识别中的应用研究[J]. 中国新技术新产品, 2023(24): 27-29.
- [18] 李建伟,郑永果. 基于 CNN 的动物识别研究[J]. 软件导刊, 2019, 18(3):30-33.
- [19] 马娜,郭嘉欣. 基于 LM 神经网络的小麦叶片病害识别[J]. 农学报, 2023, 13(2):60-66, 76.
- [20] 赵永强,金芝,张峰,等. 深度学习图像描述方法分析与展望[J]. 中国图象图形学报, 2023, 28(9): 2788-2816.