

# 基于小样本学习的林业病害识别<sup>①</sup>

王宇, 方睿, 徐铭美, 罗鸣

(成都信息工程大学 计算机学院, 成都 610225)

通信作者: 方睿, E-mail: fangrui@cuit.edu.cn



**摘要:** 近年来, 国家越来越重视林业的发展, 而林业病害防治问题始终是林业发展过程中的一项重点工作. 针对传统林业病害识别方法存在数据需求量大、模型易过拟合、部分病害类别采样困难, 缺乏标准公开数据集等问题, 提出了一种基于小样本学习的林业病害识别模型 (DML-MB 模型), 实现了对于林业病害任务的识别. 首先, 利用从林业局获取的林业病害数据, 整理并建立了 7 类, 共 210 张林业病害图像数据集. 其次, 模型在训练分类器的过程中引入深度相互学习 (DML) 策略, 让不同网络在训练时不断分享学习经验, 提升了深度神经网络的性能. 最后, 删除分类器中的全连接层获得特征提取器并迁移到 DML-MB 模型的元学习网络中进行训练. 实验结果表明, DML-MB 模型在林业病害数据集上的 1-shot 和 5-shot 的测试精度分别为 61.38% 和 73.56%, 相较于主流的小样本模型, 精度最高提升了 2.78% 和 4.52%.

**关键词:** 林业病害识别; 小样本学习; 元学习; 深度相互学习; 迁移学习

引用格式: 王宇, 方睿, 徐铭美, 罗鸣. 基于小样本学习的林业病害识别. 计算机系统应用, 2023, 32(4): 170-176. <http://www.c-s-a.org.cn/1003-3254/9058.html>

## Forestry Disease Recognition Based on Few-shot Learning

WANG Yu, FANG Rui, XU Ming-Mei, LUO Ming

(School of Computer Science, Chengdu University of Information Technology, Chengdu 610225, China)

**Abstract:** In recent years, China has paid more and more attention to the development of forestry, and forestry disease prevention and control is always a key work in the process of forestry development. Traditional forestry disease recognition methods involve large data demand, easy overfitting of models, difficult sampling of some disease categories, and lack of standard public data sets. In view of these problems, this study proposes a forestry disease recognition model based on few-shot learning (DML-MB model), which realizes the recognition of forestry disease tasks. Firstly, the forestry disease data obtained from the Forestry Bureau are used to collate and establish seven categories and data sets with a total of 210 forestry disease images. Secondly, the model introduces deep mutual learning (DML) strategy in the process of classifier training so that different networks can constantly share learning experience during training, which improves the performance of deep neural networks. Finally, the fully connected layer in the classifier is deleted to obtain the feature extractor and transfer it to the DML-MB model's meta-learning network for training. The experimental results show that the 1-shot and 5-shot test accuracy of the DML-MB model on forestry disease data sets is 61.38% and 73.56%, respectively. Compared with that of the mainstream few-shot model, the accuracy of the DML-MB model is improved by 2.78% and 4.52%, respectively.

**Key words:** forestry disease recognition; few-shot learning; meta-learning; deep mutual learning; transfer learning

① 基金项目: 国家重点研发计划 (2020YFA0608000); 成都信息工程大学科研基金 (KYTZ202156)

收稿时间: 2022-08-19; 修改时间: 2022-10-21; 采用时间: 2022-11-16; csa 在线出版时间: 2023-02-24

CNKI 网络首发时间: 2023-02-26

林业资源对维护生态环境和促进国家经济发展具有重要意义,而林业病害防治是林业建设和发展过程中一项至关重要的基础性工作,精准的诊断林业病害可以及时减少林业病害对经济带来的损失.传统的林业病害识别工作主要以人工调查为主,工作人员不仅需要具备林业领域相关知识,并且整个工作流程存在成本高、数据存储量大、耗时久、效率低等问题,无法保证林区病害检测的轻量级、时效性和准确性.

随着计算机视觉技术的飞速发展,越来越多的学者开始关注于运用深度学习相关技术对林业病害进行识别,并且取得了不错的成果.如李浩等<sup>[1]</sup>提出的基于深度学习的松线虫病害松木识别,吴云志等<sup>[2]</sup>提出的一种植物病害图像识别卷积网络架构,牟文芊等<sup>[3]</sup>提出的基于 SENet 和深度可分离卷积胶囊网络的茶树叶部病害图像识别,Amara 等<sup>[4]</sup>提出的基于 LeNet 的卷积神经网络模型对香蕉病害进行识别以及 Brahim 等<sup>[5]</sup>采用迁移学习的方法,利用 GoogLeNet 和 AlexNet 模型识别 PlantVillage 数据集中的西红柿病害图像.以上的深度学习模型需要大量的数据样本才能训练出一个有着良好精确度的分类器,并且往往只针对某一种林业病害.目前网络上关于林业病害相关的标准公开数据集较少,一些不常见的林业病害往往只能获取到几张病害图片数据,这会导致模型在训练阶段遭遇过拟合问题.因此,如何利用少量的数据,让深度学习模型能够有效学习和泛化,成为当前亟需解决的问题.

针对上述问题,本文采用了小样本学习的方法,提出了一种基于深度相互学习策略的元基线模型(deep mutual learning-meta-baseline, DML-MB)对多种林业病害进行识别,其实验结果表明,DML-MB 模型能够在少量样本的情况下实现较好的分类精度.从而为林业病害识别领域提供了一种全新的解决方法.

## 1 材料和方法

### 1.1 材料

本文使用的数据集由宜宾市林业局提供,包含了黄葛树、小叶榕、马尾松等 8 种宜宾市范围内常见树种.首先,为了得到一个较为标准的林业病害数据集,对原始数据集按照病害种类进行二次分类,最终得到了一个包含 7 个病害种类的数据集.其次对数据集进行数据增强和归一化处理,对每类图片进行水平翻

转、随机旋转、添加噪声等操作增加每类样本数量.最终得到了一个新的林业病害数据集,该数据集包含 7 种病害类,每个类拥有 30 张图片,样本总量为 210 张.林业病害各类数据见表 1.

表 1 林业病害类型及图片

| 病害类型 | 原始图片数量 | 数据增强后图片数量 |
|------|--------|-----------|
| 白粉病  | 13     | 30        |
| 黑斑病  | 16     | 30        |
| 黄化病  | 20     | 30        |
| 炭疽病  | 25     | 30        |
| 松线虫病 | 7      | 30        |
| 锈病   | 14     | 30        |
| 叶斑病  | 16     | 30        |

部分林业病害图像如图 1 所示.




图 1 林业病害图像

### 1.2 方法

小样本学习主要利用训练任务之间的共性,通过学习少量的标签样本后获得一个有效的分类器,从而让模型具有学会学习的能力,对于新的类别,只需要少量的样本就能够实现较好精度的识别.小样本学习也是元学习在监督学习领域的应用.元学习是一种高层次的跨任务学习策略,可以天然地应用在各种小样本学习模型中.目前,常见的基于元学习框架的小样本学习策略<sup>[6,7]</sup>有以下 3 种:采用度量学习的策略、采用外部记忆的策略,以及采用参数优化的策略.

采用度量学习的策略指学习一个成对相似性度量,其代表了度量支持集样本和查询集样本之间相似性的度量模块,它可以是一个距离度量也可以是一个可学习的网络.Vinyals 等<sup>[8]</sup>提出的匹配网络和 Snell 等<sup>[9]</sup>提出的原型网络采用了固定的度量,Sung 等<sup>[10]</sup>提出的关系网络则采用了可学习的 CNN 来评估成对样本之间的相似性.

采用外部记忆的策略是指在模型中添加一个额外的记忆模块来保存从支持集中提取出来的特征信息,帮助网络进行学习,从而辅助后面的学习任务.如 Munkhdalai 等<sup>[11]</sup>提出了一种带有外部记忆模块的网

络, Ravi 等<sup>[12]</sup> 提出了将 LSTM 和元学习相结合的优化算法。

采用参数优化的策略是指通过一个学习算法来优化特定任务的模型。这种策略可以为模型元学习到一个好的初始化参数, 使得模型能够在少量样本下, 几次迭代就能够很好地适应新的任务。如 Finn 等<sup>[13]</sup> 提出了元学习 MAML 算法, 该算法通过跨任务训练策略为基础学习其找到一个良好的初始化参数, 从而模型能够更好地进行训练。

上述的基于元学习框架的小样本学习策略在图像领域已经取得了一定的成果, 但是随着 Chen 等<sup>[14]</sup> 基于元学习提出了一种新的元基线模型, 我们发现其表现出来的效果明显优于之前的几种小样本学习策略。所谓的基线就是指采用特征提取器+线性分类器的组合, 或者特征提取器+距离度量分类器组合, 而元基线模型就是将基线组合套入元学习框架中。但是, 在使用该元基线模型来对本文的小样本任务进行识别时, 发现其分类器识别精度不高, 不能够充分地提取到图像特征, 模型还有上升的空间。针对该问题, 本文引入了一种新的分类器改进, 即深度相互学习策略, 并提出了 DML-MB 模型。该模型结合了元基线模型和深度相互学习策略的思想, 提升了深度神经网络的泛化性, 获得了更多的图像特征, 解决了模型在少量样本训练下容易过拟合的问题, 识别精度得到了有效提升。

## 2 模型构建

### 2.1 模型建立

本文提出的 DML-MB 模型分为两个阶段: 第 1 个是预训练阶段, 即在一个带有大量标签的基类数

据集上训练出一个分类器, 并删除该分类器中的全连接层作为元学习阶段的特征提取器。第 2 个是元学习阶段, 在这个阶段新类图像数据会在元学习框架中进行训练。本文使用 CIFAR-100 作为基类数据集, 新类数据集是在林业局获取并整理后的林业病害数据集。

#### 2.1.1 分类器模型

传统的分类器模型在训练阶段需要大量数据, 其训练效果的优劣取决于是否能提取到充分的特征, 并且其模型参数量大, 执行可能缓慢, 需要大量内存进行存储。为了解决以上的问题, Hinton 等<sup>[15]</sup> 在 2015 年提出了知识蒸馏算法, 即利用一个预训练好的教师模型向一个未训练的学生模型进行单向知识转移。实验表明学生网络通过模仿教师网络的类别概率, 优化过程变得更为容易, 而且能够表现出与教师网络相近甚至更好的性能。但知识蒸馏算法需要提前预训练好的教师网络, 仅对学生网络进行单向的知识传递, 难以在学生网络学习的过程中获得反馈信息来对训练过程进行优化调整。

在本文的预训练阶段, 分类器模型引入了由 Zhang 等<sup>[16]</sup> 提出的深度相互学习 (deep mutual learning, DML) 策略。该策略采用多个网络同时进行训练, 每个网络之间相互进行学习, 在训练过程中不仅接受真值标记的监督, 还参考了同伴网络的学习经验来进一步提升泛化能力。每个网络由常规的监督学习损失和拟态损失来共同训练, 监督学习损失是为了度量网络预测目标类别与真实标签之间的差异, 拟态损失采用 KL 散度来度量两个网络预概率分布之间的差异。分类器模型训练的具体流程如图 2 所示。

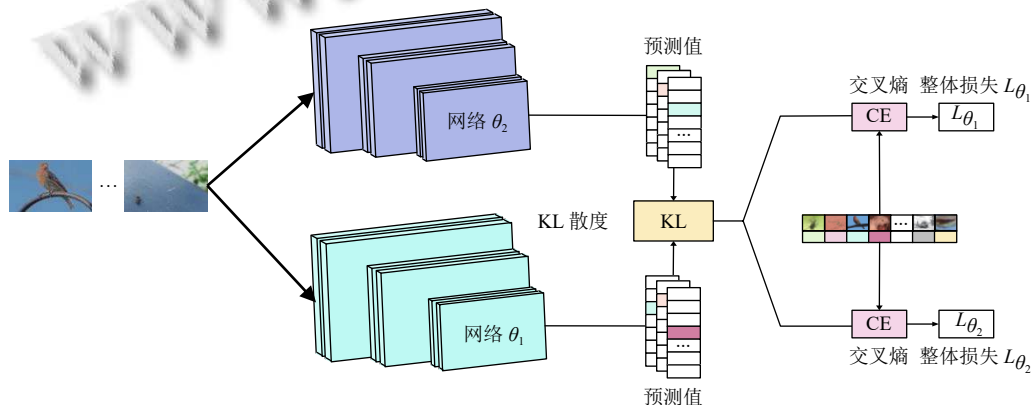


图 2 分类器模型框架

给定  $M$  个类中的  $N$  个样本  $x = \{x_i\}_{i=1}^N$ , 同一个输入, 分别经过  $\theta_1$  和  $\theta_2$  两个网络 (本文采用两个网络来描述所提出的方法, 也可以扩展到多个网络), 得到  $z_1$  和  $z_2$ , 随后得到预测的分布. 通过神经网络  $\theta_1$  给出的样本  $x_i$  属于类  $m$  的概率计算可见式 (1):

$$p_1^m(x_i) = \frac{\exp(z_1^m)}{\sum_{m=1}^M \exp(z_1^m)} \quad (1)$$

其中,  $z^m$  是神经网络  $\theta_1$  中 Softmax 层的输出. 最后, 送入 KL 散度计算这两个分布的相似性作为拟态损失, 与 label 比较计算标签损失.

Zhang 等<sup>[16]</sup> 的研究表明, DML 策略提供了一种简单有效的方法, 通过与其他网络协同训练提高了模型的泛化能力, 相较于传统分类器模型, 该策略能够提取到更多的图像特征.

### 2.1.2 DML-MB 模型

在进入元学习模型之前, 需要将训练之后的分类器网络去掉全连接层, 得到特征提取器. 采用元学习的策

略, 将林业病害数据集中的 4 个类划分成训练集, 3 个类划分成测试集. 该策略的好处在于, 模型在支持集的帮助下能够更好地学习查询集与标签之间的映射关系. 在元学习训练阶段, 每次会在训练集中采样得到不同任务, 在每个任务中, 从训练集中选择出  $N$  个类, 再从  $N$  类中选取  $K$  个样本 (即  $N$ -way  $K$ -shot) 构成了支持集  $N_{\text{support}}$ . 查询集  $N_{\text{query}}$  会在  $N$  个类中的剩余样本数据中采样得到. 采用任务机制使得模型学会不同任务中的共性部分, 让模型泛化性得到增强. 元训练阶段具体过程为: 首先, 将支持集的样本输入到特征提取器中提取出样本的特征. 然后, 计算支持集中每个类样本的平均特征, 同时在查询集也抽取一定数量的样本进行特征提取. 接下来使用余弦相似度分别计算查询集和支持集之间样本的相关程度. 最后将计算出的相关度分数与从查询集抽取的样本标签进行对比. 元学习模型框架如图 3 所示. 在元测试阶段, 按照同样的方法, 在测试集上抽取支持集和查询集用于二次训练<sup>[17]</sup>. 经过了上述两个阶段, 模型对于病害特征的识别性能得到了增强.

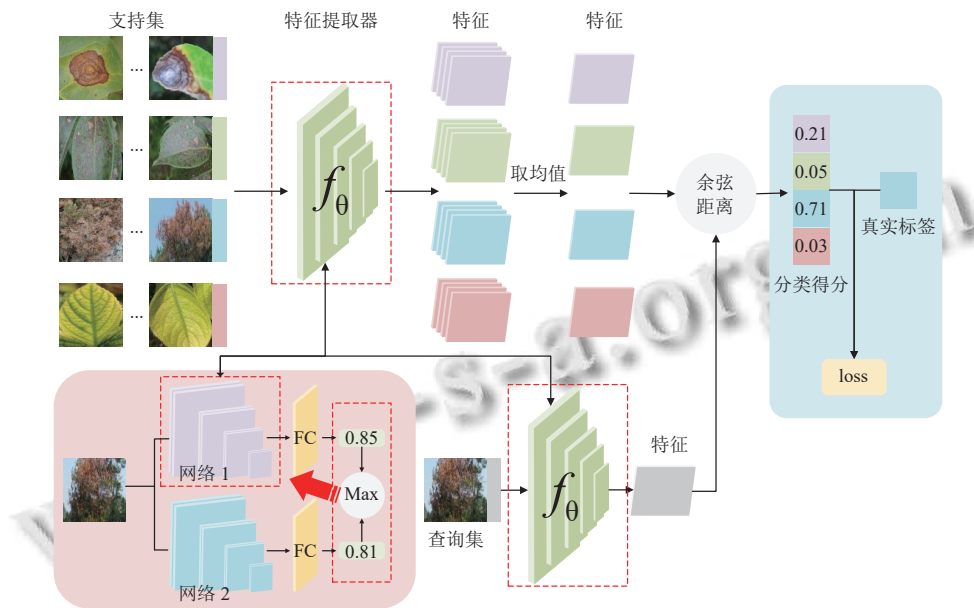


图 3 元学习模型框架

## 2.2 损失函数

本文采用 DML 策略的分类器模型在学习过程中有两个损失函数, 一个是传统的监督损失函数, 一个是网络间的拟态损失函数. 对于多类别分类, 将训练网络  $\theta_1$  的目标损失函数定义为预测值与真实标签之间的交叉熵损失, 见式 (2):

$$L_{C1} = - \sum_{i=1}^N \sum_{m=1}^M I(y_i, m) \ln(p_1^m(x_i)) \quad (2)$$

带有一个指标函数  $I$ , 定义见式 (3):

$$I(y_i, m) = \begin{cases} 1, & y_i = m \\ 0, & y_i \neq m \end{cases} \quad (3)$$

其中,  $y_i \in \{1, 2, \dots, M\}$  表示样本相应的标签集  $y = \{y_i\}_{i=1}^N$ .

拟态损失函数采用 KL 散度来度量两个网络 $\theta_1$ 和 $\theta_2$ 预测值 $p_1, p_2$ , 的匹配程度,  $p_2$ 对 $p_1$ 的 KL 散度见式 (4):

$$D_{KL}(p_2||p_1) = \sum_{i=1}^N \sum_{m=1}^M p_2^m(x_i) \ln \frac{p_2^m(x_i)}{p_1^m(x_i)} \quad (4)$$

最后, 网络 $\theta_1$ 的整体损失函数 $L_{\theta_1}$ 可见式 (5):

$$L_{\theta_1} = L_{C_1} + D_{KL}(p_2||p_1) \quad (5)$$

类似地, 网络 $\theta_2$ 的整体损失函数 $L_{\theta_2}$ 可见式 (6):

$$L_{\theta_2} = L_{C_2} + D_{KL}(p_1||p_2) \quad (6)$$

元学习框架的损失函数是由每个训练任务的损失函数一起构成的, 所以需要计算每个任务的损失函数. 首先, 在支持集中计算  $N$  个类的质心, 质心的定义见式 (7):

$$W_c = \frac{1}{|S_c|} \sum_{x \in S_c} F_{\theta}(x) \quad (7)$$

然后, 计算查询集中每个样本的预测概率分布, 具体定义见式 (8):

$$p(y = c|x) = \frac{\exp(\langle F_{\theta}(x), W_c \rangle)}{\sum_{c'} \exp(\langle F_{\theta}(x), W_{c'} \rangle)} \quad (8)$$

其中,  $S$  为支持集,  $S_c$  为在  $c$  类中选取的数据,  $W_c$  为计算出的特征平均值,  $F_{\theta}$  为特征提取器,  $x$  为输入的图像样本数据,  $\langle \cdot, \cdot \rangle$  表示两个向量的余弦相似度.  $p$  为计算出的余弦相似度, 也就是样本  $x$  属于类别  $c$  的概率.

最后, 损失函数为  $p$  和查询集样本标签计算的交叉熵损失, 具体定义见式 (9):

$$loss = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_{i,k} \ln(p_{i,k}) \quad (9)$$

### 3 实验结果与分析

本实验使用的是 Linux 操作系统, 采用 NVIDIA 的 RTX-A4000 16 GB 显卡、CUDA 11.0、Python 3.7、PyTorch 1.7.

具体实验分为 3 个部分: 采用 DML 策略的分类器网络, 与未采用 DML 策略的分类器网络、采用知识蒸馏的分类器网络进行实验精度的对比; 使用本文构建的 DML-MB 模型实现林业病害任务的识别, 并对比不同分类器网络对实验精度影响; 与目前主流的小样本学习模型以及元基线模型进行分类精度对比.

#### 3.1 分类器网络实验及分析

分类器网络采用了 DML 的策略, 为了对比不同网

络组合对于 DML-MB 模型分类精度的影响, 分别选择了 ResNet-32, MobileNetV3-Large, WRN-28-10 (表 2 和表 3 中用 Res、Mob、WRN 表示) 网络进行实验, 并在 CIFAR-100 数据集上进行精度对比. 训练的基本设置为: 迭代 200 次, 初始学习率为 0.1, 动量为 0.9, 学习率每 60 个 epochs 下降 0.1. 实验的具体结果如表 2、表 3 所示.

表 2 DML-Independent 结果对比 (%)

| Net 1 | Net 2 | Independent |       | DML   |       |
|-------|-------|-------------|-------|-------|-------|
|       |       | Net 1       | Net 2 | Net 1 | Net 2 |
| Res   | Res   | 71.00       | 71.00 | 72.60 | 72.82 |
| WRN   | Res   | 79.63       | 71.00 | 80.12 | 72.64 |
| Mob   | Res   | 74.12       | 71.00 | 77.02 | 73.02 |
| Mob   | Mob   | 74.12       | 74.12 | 77.13 | 77.30 |
| WRN   | Mob   | 79.63       | 74.12 | 81.04 | 77.94 |
| WRN   | WRN   | 79.63       | 79.63 | 81.10 | 81.18 |

注: 表 2 是在 CIFAR-100 数据集下得到的训练精度. Independent 代表使用一个网络进行训练, DML 代表网络间使用 DML 策略进行训练.

表 3 DML-知识蒸馏结果对比 (%)

| Net 1 | Net 2 | DML   |       | 1 distill 2 |
|-------|-------|-------|-------|-------------|
|       |       | Net 1 | Net 2 |             |
| WRN   | Res   | 80.12 | 72.64 | 71.43       |
| Mob   | Res   | 77.02 | 73.02 | 71.16       |

注: 表 3 比较了在 CIFAR-100 数据集下使用 DML 策略和知识蒸馏策略后网络精确度提升情况. 1 distill 2 代表使用网络 1 蒸馏网络 2.

由表 2 可知, 相较于单独用一个网络作为分类器而言, 分类器网络间采用 DML 策略后识别精度有着明显的提升, 精度提升最大的一组甚至达到 3.82%. 这表明 DML 策略是有效的, 我们关于分类器使用多种网络协调训练能够提升精度的设想可行性较大.

经研究发现, DML 策略与知识蒸馏策略有异曲同工之妙, 因此我们进一步对比了两种方法. 由表 3 结果可知, 采用 WRN-28-10、MobileNetV3-Large 作为教师网络蒸馏 ResNet-32 学生网络后, 学生网络的精度分别提升了 0.43% 和 0.16%, 而采用 DML 策略后 ResNet-32 网络精度分别提升了 1.64% 和 2.02%, 这表明 DML 策略在精度提升上明显优于知识蒸馏策略, 我们猜测是因为知识蒸馏是教师网络向学生网络知识的单向传递, 教师网络难以在学生网络学习的过程中获得反馈信息来对训练过程进行优化调整, 所以精度提升效果不佳. 而 DML 策略让网络间知识进行相互传递学习, 能够很好地解决了以上的问题.

#### 3.2 DML-MB 模型实验

本次实验采用的数据是由林业局获取并整理后的

病害数据集. 实验方法采用小样本学习中最常采用的 1-shot 和 5-shot 方式.

进行实验时, 选择采用了 DML 策略训练后精度最高的 ResNet32、WRN-28-10、MobileNetV3-Large 网络去掉全连接层作为元基线模型的特征提取器, 并用支持集数据进行 fine-tuning. DML-MB 具体的训练设置为: 迭代 20 次, 每个任务的批处理量为 4, 学习率为 0.001, 学习动量为 0.9, 权重衰减为  $1E-4$ , 优化器选择 SGD. 最后, 我们列出模型在 1-shot 和 5-shot 上的测试精度, 如表 4 所示.

表 4 不同分类器网络下 DML-MB 模型实验结果

| 分类器网络             | 1-shot | 5-shot | 参数量 (M) |
|-------------------|--------|--------|---------|
| ResNet32          | 0.5779 | 0.6886 | 22.5    |
| WRN-28-10         | 0.6442 | 0.7712 | 38.6    |
| MobileNetV3-Large | 0.6138 | 0.7356 | 3.78    |

注: 表4是不同分类器网络下DML-MB模型在林业病害数据集下得到的1-shot和5-shot训练精度.

由表 4 可知, 采用 WRN-28-10 网络作为特征提取器的模型精度显著高于另外两者, 因此, 可用其进行更深层次的分类精确度研究. 但考虑到 WRN-28-10 的参数数量高达 38.6 M, 并不能很好地满足林业病害识别领域轻量化的需求, 综合考虑下, 我们选择参数量仅有 3.78 M, 而精度却只稍逊 WRN 一筹的 MobileNetV3-Large 作为元基线模型的特征提取器进行实验. 模型的训练精度如图 4 所示.

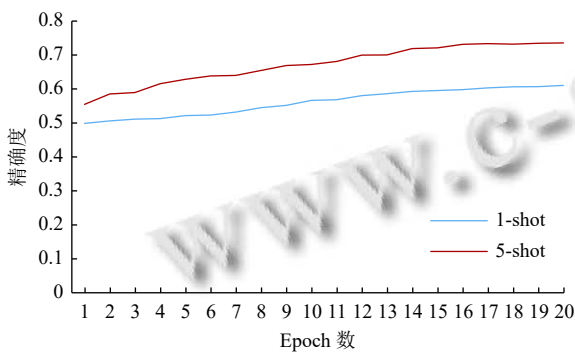


图 4 DML-MB 模型训练精度

由图 4 可知, 训练后的 DML-MB 模型 1-shot 和 5-shot 的训练精度分别为 61.38% 以及 73.56%.

### 3.3 与主流小样本学习模型及元基线模型对比试验及分析

在本节中, 主要选择了两种应用广泛的小样本模型—原型网络、匹配网络以及元基线模型与本文提出

的模型进行对比实验. 在进行实验时, 4 种模型训练的基本设置均为迭代 100 次, 学习率为 0.001, 并采用随机梯度下降法. 最后, 实验对比结果如表 5 所示.

表 5 与主流小样本学习模型实验对比

| shot | 匹配网络   | 原型网络   | 元基线模型  | DML-MB模型      |
|------|--------|--------|--------|---------------|
| 1    | 0.5860 | 0.5942 | 0.6073 | <b>0.6138</b> |
| 5    | 0.6904 | 0.6987 | 0.7174 | <b>0.7356</b> |

注: 表5表示在林业病害数据集下的不同模型的识别精度.

由表 5 可知, 匹配网络和原型网络在林业病害数据集上 1-shot 和 5-shot 识别精度皆低于元基线网络, 而本文提出的改进相较于元基线模型在 5-shot 上的识别精度提升了 1.82%, 这表明在深度学习小样本领域, 无法从数据层面提供可靠支持的情况下, 我们可以使用不同网络协同训练、相互学习, 来提升模型的泛化能力, 这不失为小样本领域提高精度的一个有效解决方案.

## 4 结论与展望

本文针对传统林业病害识别领域存在可用数据少、分类准确度低等问题, 建立了林业病害图像数据集, 并提出了一种基于小样本学习的改进元基线模型, DML-MB 模型, 该模型引入了 DML 策略, 提升了深度神经网络的泛化性, 提取到了更丰富的图像特征. 模型在林业病害图像数据集上 1-shot 和 5-shot 测试精度达到了 61.38% 和 73.56%, 相比于现有的基于小样本学习的模型拥有更好的识别精度, 为小样本林业病害识别领域提供了一个全新的解决办法. 下一步的研究工作可考虑从以下两方面着手.

(1) 建设公共林业病害数据集和统一的评估标准. 由于数据的采集方式各不相同, 得到的林业病害数据在质量、尺寸和数据方面都差异较大. 因此制定统一的林业病害数据集标准对林业病害识别领域至关重要.

(2) 结合 Transformer 模型的优点继续对 DML-MB 模型进行优化和改进. 通过利用 Transformer 模型结构中含有的自注意力层, 提升 DML-MB 模型感知关键区域的能力, 进而增强模型在小样本图像分类任务上的表现.

### 参考文献

- 李浩, 方伟泉, 李浪浪, 等. 基于深度学习的松材线虫病害虫识别. 林业工程学报, 2021, 6(6): 142-147.

- 2 吴云志, 刘翱宇, 朱小宁, 等. 一种植物病害图像识别卷积神经网络架构. 安徽农业大学学报, 2021, 48(1): 150–156.
- 3 牟文芊, 董萌萍, 孙文杰, 等. 基于 SENet 和深度可分离卷积胶囊网络的茶树叶部病害图像识别. 山东农业大学学报 (自然科学版), 2021, 52(1): 23–28.
- 4 Amara J, Bouaziz B, Algergawy A. A deep learning-based approach for banana leaf diseases classification. In: Mitschang B, Nicklas D, Leymann F, *et al.*, eds. Datenbanksysteme für Business, Technologie und Web (BTW 2017)-Workshopband. Bonn: Gesellschaft für Informatik, 2017. 79–88.
- 5 Brahimi M, Boukhalfa K, Moussaoui A. Deep learning for tomato diseases: Classification and symptoms visualization. Applied Artificial Intelligence, 2017, 31(4): 299–315. [doi: [10.1080/08839514.2017.1315516](https://doi.org/10.1080/08839514.2017.1315516)]
- 6 祝钧桃, 姚光乐, 张葛祥, 等. 深度神经网络的小样本学习综述. 计算机工程与应用, 2021, 57(7): 22–33. [doi: [10.3778/j.issn.1002-8331.2012-0200](https://doi.org/10.3778/j.issn.1002-8331.2012-0200)]
- 7 李新叶, 龙慎鹏, 朱婧. 基于深度神经网络的少样本学习综述. 计算机应用研究, 2020, 37(8): 2241–2247.
- 8 Vinyals O, Blundell C, Lillicrap T, *et al.* Matching networks for one shot learning. Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona: Curran Associates Inc., 2016. 3637–3645.
- 9 Snell J, Swersky K, Zemel R. Prototypical networks for few-shot learning. Proceedings of the 31st Conference on Neural Information Processing Systems. Long Beach: NIPS, 2017. 4077–4087.
- 10 Sung F, Yang YX, Zhang L, *et al.* Learning to compare: Relation network for few-shot learning. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 1199–1208.
- 11 Munkhdalai T, Yu H. Meta networks. Proceedings of the 34th International Conference on Machine Learning. Sydney: JMLR.org, 2017. 2554–2563.
- 12 Ravi S, Larochelle H. Optimization as a model for few-shot learning. Proceedings of the 5th International Conference on Learning Representations. Toulon: OpenReview.net, 2017. 1–11.
- 13 Finn C, Abbeel P, Levine S. Model-agnostic meta-learning for fast adaptation of deep networks. Proceedings of the 34th International Conference on Machine Learning. Sydney: PMLR, 2017. 1126–1135.
- 14 Chen YB, Wang XL, Liu Z, *et al.* A new meta-baseline for few-shot learning. arXiv:2003.04390v2, 2020.
- 15 Hinton G, Vinyals O, Dean J. Distilling the knowledge in a neural network. arXiv:1503.02531, 2015.
- 16 Zhang Y, Xiang T, Hospedales TM, *et al.* Deep mutual learning. Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 4320–4328.
- 17 肖伟, 冯全, 张建华, 等. 基于小样本学习的植物病害识别研究. 中国农机化学报, 2021, 42(11): 138–143.

(校对责编: 孙君艳)