



郭小燕,尚皓玺. 基于元学习的植物虫害识别原型网络 VGG-ML[J]. 南京农业大学学报,2024,47(2):392-401.

GUO Xiaoyan, SHANG Haoxi. Plant pest identification prototype network based on meta-learning[J]. Journal of Nanjing Agricultural University, 2024, 47(2):392-401.

## 基于元学习的植物虫害识别原型网络 VGG-ML

郭小燕\*, 尚皓玺

(甘肃农业大学信息科学技术学院, 甘肃 兰州 730070)

**摘要:** [目的]为解决使用深度学习技术对植物虫害识别时依赖大量训练样本的问题,本文基于元学习的思想设计一个VGG原型网络(VGG-meta learning, VGG-ML),用于在小样本背景下植物虫害种类识别。[方法]采用VGG16作为嵌入单元提取虫害样本特征与类别特征,为提高网络对于新类别的识别能力,采用训练集与测试集异域方式进行模型训练,以解决在小样本情况下植物虫害识别准确率低、新类别虫害无法识别的问题。将测试集划分为支持集(获取类原型)与查询集(样本原型),以欧式距离度量样本原型与类原型之间的相似性,从而判定样本所属类别。[结果]以公开数据集IP102中玉米、甜菜、苜蓿等11种植物的蚜虫、黏虫、跳甲等24类农业虫害图片作为训练数据,以稻纵卷叶螟、稻叶毛虫、亚洲稻螟、稻瘿蚊、稻秆蝇、稻水象甲、稻叶蝉、稻苞虫8类常见的水稻虫害作为测试数据,在5-way、1-shot与5-way、5-shot情况下VGG-ML识别准确率分别为67.98%与81.5%,与原始原型网络相比提高3.53与4.4个百分点。5-way、5-shot试验与基于迁移学习的ResNet50与VGG16网络对比,准确率分别提高28.65与25.94个百分点。[结论]VGG-ML在进行小样本植物虫害类型识别时有效可靠,可适用于小样本植物识别问题。

**关键词:**深度学习;原型网络;植物虫害;元学习

中图分类号:S431;TP391.41

文献标志码:A

文章编号:1000-2030(2024)02-0392-10

## Plant pest identification prototype network VGG-ML based on meta-learning

GUO Xiaoyan\*, SHANG Haoxi

(College of Information Science and Technology, Gansu Agricultural University, Lanzhou 730070, China)

**Abstract:** [Objectives] To solve the problem of relying on a large number of training samples when using deep learning technology to identify plant pests, a VGG (visual geometry group) prototype network (VGG-meta learning, VGG-ML) based on the idea of meta-learning was proposed in this paper to identify plant pest types in small sample backgrounds. [Methods] VGG16 was used as the embedding unit to extract the characteristics and category characteristics of the plant pest sample. In order to improve the recognition ability of the network for new categories, and solve the problem of low recognition accuracy of plant pests and unrecognizable new categories of pests in the case of small samples, the dataset that the training set and the test set from different data categories was adopted in this paper. The test set was divided into a support set (obtaining class prototypes) and a query set (sample prototypes), and the similarity between sample prototypes and class prototypes was measured by Euclidean distance to determine the category to which the samples belong. [Results] Twenty four kinds of agricultural insect pests such as aphids, armyworms and flea beetles of 11 plants such as corn, sugar beet, and alfalfa in the public dataset IP102 were used as training data, and 8 kinds of common aquatic rice pests such as rice leaf roller, rice leaf caterpillar, Asian rice borer, rice gall midge, rice stem fly, rice water weevil, rice leaf hopper, and rice bract were used as test data. The recognition accuracy of VGG-ML was 67.98% and 81.5% respectively under 5-way, 1-shot and 5-way, 5-shot conditions, which was 3.53 and 4.4 percentage points higher than the original prototype network, respectively. Compared with the ResNet50 and VGG16 networks based on transfer learning, the accuracy of the 5-way and 5-shot tests increased by 28.65 and 25.94 percentage points, respectively. [Conclusions] VGG-ML was effective and reliable in the identification of plant pest types in small samples, and it could be applied to the identification of small samples of plants.

**Keywords:** deep learning; prototype network; plant pest; meta learning

收稿日期:2023-04-14

基金项目:甘肃农业大学青年导师基金项目(QAU-QDFC-2021-18);甘肃农业大学科技创新基金项目(盛彤笙创新基金)(GSAU-STC-2021-16)

\*通信作者:郭小燕,博士,教授,硕导,研究方向为智能信息处理和人工智能, E-mail: guoxy@gsau.edu.cn.

虫害是影响植物生长的关键因素之一<sup>[1-2]</sup>,快速、准确发现并识别虫害类别是进行及时防治的前提<sup>[3]</sup>。随着人工智能的发展,基于深度学习的植物虫害识别越来越引起学者的重视<sup>[4-6]</sup>。郭阳等<sup>[7]</sup>选用 2 500 张水稻虫害图片,采用 YOLO v3 对红袖蜡蝉、稻绿蝽、稻螟蛉等 5 种水稻虫害进行识别,平均识别率为 92%;赵志焱等<sup>[8]</sup>建立一种卷积神经网络虫害识别模型,对 1 013 张玉露香梨叶虫害图像的金龟子、梨木虱、梨瘿蚊 3 种虫害进行识别,准确率为 81.18%;Liu 等<sup>[9]</sup>用 67 953 幅森林害虫图像构建了一个虫害识别模型,试验效果较好;Huang 等<sup>[10]</sup>利用 VGG16 对 8 类番茄害虫进行分类,准确率为 94.95%。这些基于深度学习技术的研究方法解决了利用机器视觉客观、高效识别植物虫害的问题,然而由于深度学习模型结构的复杂性以及网络层数的要求,为保证识别的准确性与泛化效果,往往需要大量的虫害样本数据进行模型的训练与参数优化,而植物虫害具有随机性、季节性、地域性,样本数据的采集存在许多实际困难。因此研究如何在病虫害样本量有限的情况下,利用深度学习技术进行植物病虫害识别已经越来越引起学者的关注<sup>[11-12]</sup>。元学习<sup>[13]</sup>是一种利用已有“认知”快速学习新任务的思想,基于元学习设计的神经网络可以通过模拟人类智能,在少量样本中完成分类任务<sup>[14-15]</sup>。Finn 等<sup>[16]</sup>提出一种通用的、模型无关的元学习算法,探索了一种利用少量样本实现新的学习任务方法。Ravi 等<sup>[17]</sup>提出使用长短期记忆网络(long short-term memory, LSTM)更新分类器参数的元学习方法,实现对每种类别的少量样本快速泛化,从而完成小样本分类任务。简涛等<sup>[18]</sup>提出了一种基于损失加权修正的识别方法,并将其应用到舰船目标元学习任务中,在 20 个样本的情况下识别率可以达到 86.4%。

从以上研究成果发现,元学习已被广泛应用于小样本图像分类任务中<sup>[19]</sup>,解决样本量不足的分类问题。近年已经有学者探索将其应用于植物病虫害分类识别中<sup>[20-21]</sup>,然而研究成果较少,大部分已有文献所涉及的模型训练集与测试集均来自同一个域<sup>[22]</sup>。本文研究设想,如果虫害模型的训练数据与测试数据来自不同植物的不同虫害类别,则可以解决某些稀少样本虫害的识别问题。基于元学习思想,本文设计了 VGG 原型网络模型(VGG-meta learning, VGG-ML),该模型拟采用 VGG16<sup>[23-24]</sup>卷积神经网络作为嵌入单元提取虫害样本特征与类别特征,利用欧式距离<sup>[25-27]</sup>度量样本原型向量与类原型向量之间的相似性,从而判定样本所属类别。以期解决稀少样本的植物虫害识别问题。

## 1 材料与方法

### 1.1 数据集

**1.1.1 训练集** 利用训练集训练 VGG-ML 模型的“学习能力”,并使其将“原知识”保留至“新认知”,使其具有对于新类别的识别能力。在植物虫害识别公开数据集 IP102<sup>[28]</sup>中选择玉米、甜菜、苜蓿等 11 种植物的蚜虫、黏虫、跳甲等 24 类农业虫害,共计 7 200 幅图像进行裁减(224×224)、旋转等预处理操作,最后存储为 \*.jpg 图像格式制作训练集,样本通过不同的文件夹区分样本所属类别,如表 1 和图 1 所示。

表 1 训练集详情

Table 1 The detail of training set

标签 Labels	标签名称 Label name	样本数量 Number of samples	标签 Labels	标签名称 Label name	样本数量 Number of samples
1	玉米螟 Corn borer	300	13	麦红吸浆虫 Wheat blossom midge	300
2	黏虫 Army worm	300	14	麦圆蜘蛛 Penthaleus major	300
3	跳甲 Flea beetle	300	15	麦叶蜂 Wheat sawfly	300
4	甜菜象甲 Beet weevil	300	16	甜菜潜叶花蝇 Beet fly	300
5	芫菁 Blister beetle	300	17	网锥额野螟 Meadow moth	300
6	大青叶蝉 Cicadella viridis	300	18	苜蓿叶象甲 Alfalfa weevil	300
7	蝼蛄 Mole cricket	300	19	蓟马 Thrips	300
8	铁线虫 Wireworm	300	20	刺蛾 Limacodidae	300
9	小地蚕 Black cutworm	300	21	柑橘凤蝶 Papilio xuthus	300
10	红蜘蛛 Red spider	300	22	红蜡蚧 Eroplastes rubens	300
11	蚜虫 Aphids	300	23	堆蜡粉蚧 Ipaecoccus vastalor	300
12	桃蛀螟 Peach borer	300	24	斜纹夜蛾 Prodenia litura	300

**1.1.2 测试集** 为了验证 VGG-ML 对新知识的认知识别能力,所选用的测试集与训练集不产生交集。从 IP102 数据集中选用稻纵卷叶螟、稻叶毛虫、亚洲稻螟、稻瘿蚊、稻秆蝇、稻水象甲、稻叶蝉、稻苞虫 8 类常见的水稻虫害,每类样本大约 40 幅图像,共计 316 幅图像作为测试集,如表 2 和图 2 所示。



图 1 训练集虫害类别

Fig. 1 Pest categories in training set

数据来源 Data resource: GitHub-xpwu95/IP102; IP102: A large-scale benchmark dataset for insect pest recognition.

表 2 测试集详情

Table 2 Details of test set

标签 Labels	标签名称 Label name	测试样本数量 Number of samples	标签 Labels	标签名称 Label name	测试样本数量 Number of samples
0	稻纵卷叶螟 Rice leaf roller	43	4	稻秆蝇 Rice stemfly	40
1	稻叶毛虫 Rice leaf caterpillar	36	5	稻水象甲 Rice water weevil	39
2	亚洲稻螟 Asiatic rice borer	36	6	稻叶蝉 Rice Leafhopper	45
3	稻瘿蚊 Rice gall midge	37	7	稻苞虫 Rice shell pest	40



图 2 测试集类别

Fig. 2 Pest categories in test set

1.2 原型网络

基于元学习思想, Snell 等<sup>[29]</sup> 2017 提出一种原型网络, 并在 Omniglot 和 MiniImageNet 数据集上进行了试验测试, 其网络结构如图 3 所示, 一张 224×224×64 的图片送入嵌入单元进行特征提取, 经过 4 层卷积与池化变为 28×28×64 的原型向量。




图 3 原始原型网络

Fig. 3 Original prototype network

输入样本经过嵌入单元提取特征后转换为原型向量,再送入度量单元进行特征度量,原始原型网络原理如公式(1)–(3):

$$c_k = \frac{1}{|s_k|} \sum_{(x_i, y_i) \in S_k} f_\phi(x_i) \quad (1)$$

$$d(f_\phi(x), c_k) = \sqrt{(f_\phi(x), c_k)^2} \quad (2)$$

$$p_\phi(y=k|x_i) = \frac{\exp(-d(f_\phi(x_i), c_k))}{\sum_k \exp(-d(f_\phi(x_i), c_k))} \quad (3)$$

式中:  $x_i$  为输入样本向量;  $f_\phi(x_i)$  为嵌入单元, 输出为样本  $x_i$  的原型向量;  $s_k$  为属于第  $k$  类样本集合;  $|s_k|$  为属于第  $k$  类样本的数量;  $c_k$  为第  $k$  类样本的类原型向量;  $d(f_\phi(x), c_k)$  为样本原型向量  $f_\phi(x_i)$  与类原型向量  $c_k$  之间的欧式距离;  $p_\phi(y=k|x_i)$  为样本  $x_i$  属于第  $k$  种类型的概率。

### 1.3 VGG-ML 原型网络

文献[29]对原始原型网络提出了一种小样本类别检测的框架,在训练数据集与检测数据集来自同一个域时识别效果较好,然而当训练数据集与检测数据集来自不同域时,识别精度为 54.6%。为了提升异域数据集的识别效果,本文设计一个基于小样本的 VGG-ML 植物虫害识别模型,训练数据采用玉米、甜菜、苜蓿等 11 种植物的蚜虫、黏虫、跳甲等 24 类农业虫害,测试集采用 8 种常见水稻虫害数据,模型结构如图 4 所示。

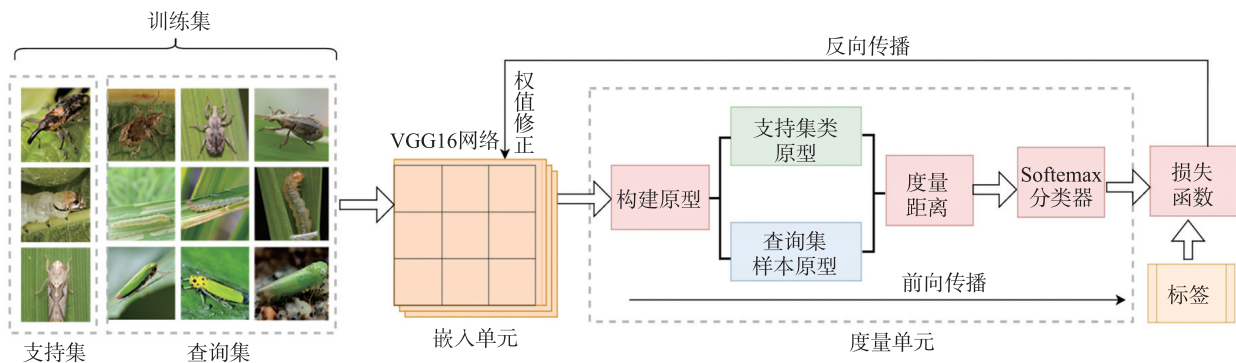


图 4 VGG-ML 网络结构

Fig. 4 VGG-ML network structure

将训练集分为支持集与查询集,在前向传播阶段,将支持集和查询集样本通过嵌入单元提取特征,形成支持集类原型与查询集样本原型,度量单元计算支持集类原型与查询集样本之间的欧式距离并判断其所属类别。在反向传播阶段,计算预测类别和真实类别之间的误差,使用梯度下降法对嵌入单元进行权值修正。

**1.3.1 嵌入单元** 嵌入单元将虫害图像非线性映射为原型向量,对应于公式(1)中的  $f_\phi(x_i)$ ,其主要功能是对输入样本进行特征提取。采用 VGG16 卷积神经网络作为嵌入单元,为了与原型网络匹配,去除了 VGG16 网络的 softmax 分类器,如图 5 所示。




图 5 VGG16 网络结构示意图

Fig. 5 VGG16 Network structure diagram

**1.3.2 度量单元** 嵌入单元将样本映射为原型向量之后送入度量单元,利用嵌入单元 $f(x_i)$ 分别计算支持集原型  $C_k$  (见公式(1))与查询及样本原型 $f(x_i)$ 之间的欧式距离  $d$  (公式(2)),使用 softmax 函数预测查询集样本属于某个类别的概率(公式(3))。如图 6 所示,查询样本  $X$  属于  $S3$  类。

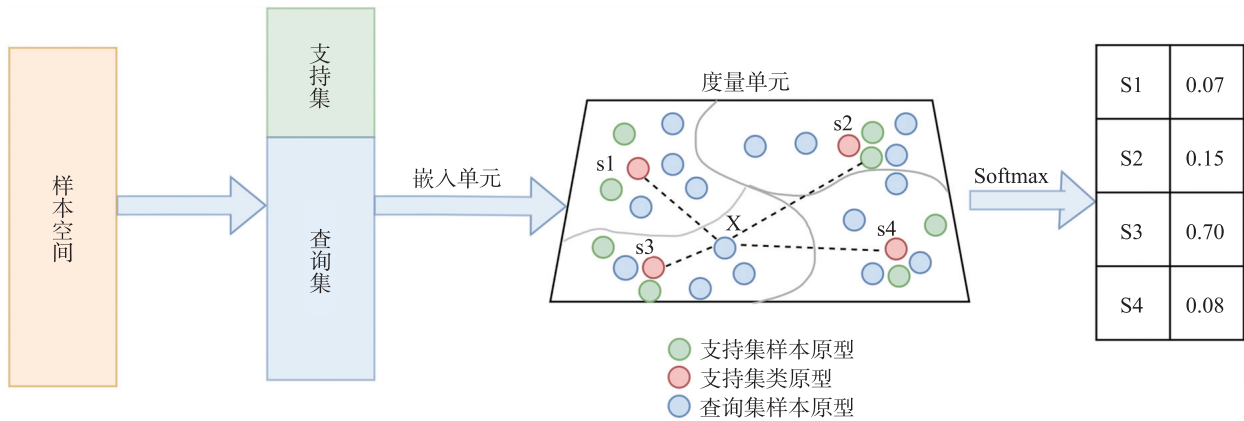


图 6 度量单元

Fig. 6 Measurement unit

**1.4 试验环境**

硬件环境为 Inter(R) Xeon(R) W-2123 CPU@ 3.6GHz, 16GB RAM, NVIDIA GeForce GTX 1080 GPU, 8GB Video Memory。软件环境为 CUDA Toolkit 10.1, CUDNN 10.1, Windows 10 64bit, Python 3.7, Tensorflow 2.4.0。

**1.5 数据预处理**

为了减少计算量、防止梯度爆炸、加速模型收敛,首先对测试集、训练集虫害样本数据进行预处理,将样本图像的尺寸统一处理为 224×224,再采用 90°×4 随机旋转以增强数据,对训练集中每张图像 RGB 通道的像素值减去训练集图像相应通道的像素均值,最后对每个通道像素进行归一化处理。

**1.6 模型训练**

模型训练基于元学习的思想采用小批次训练方法,将一个训练任务划分为若干个元任务,每个元任务均划分支持集与查询集,若支持集中包含  $N$  种类别,每种类别有  $M$  个样本,则此次原任务试验为  $N$ -way、 $M$ -shot 试验,具体训练过程如图 7 所示。分别采用 5-way、1-shot 与 5-way、5-shot 试验来进行模型的训练与检测。其中 5-way、1-shot 试验中,选取 80 张图片作为训练集,每轮训练任务中随机选取 5 类虫害,每类 1 张图片作为支持集,其余作为查询集;5-way、5-shot 试验中,选取 100 张图片作为训练集,每轮训练任务中随机选取 5 类农业虫害图像,每类 5 张图片作为支持集,其余作为查询集,模型采用 Adam 梯度下降算法训练模型,初始学习速率设为  $V_0 = 10^{-3}$ ,动量项指数衰减率  $\beta_3 = 0.9$ ,扰动项  $\epsilon_{adam} = 10^{-8}$ ,训练集迭代次数  $t = 20\ 000$ ,采用负对数损失函数(negative logarithmic loss function)。

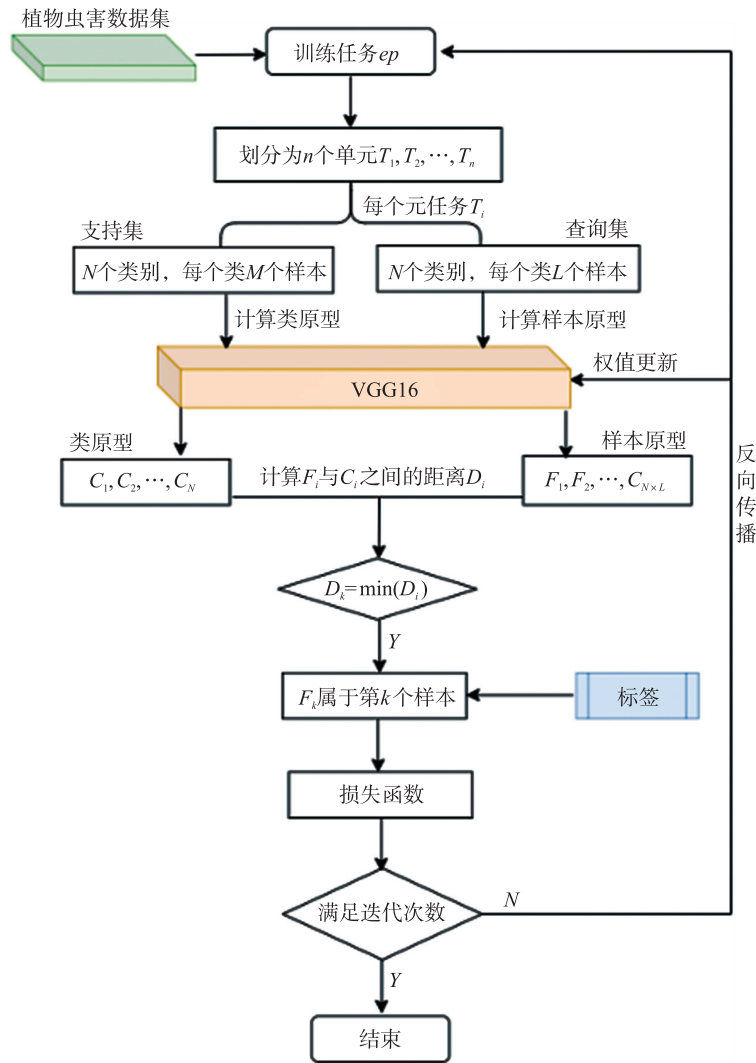


图 7 训练过程  
Fig. 7 Training process

1.7 模型评价

模型的评价采用准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall)、查全率 (F1-Score) 4 项指标。准确率为预测正确的结果占总样本的比例,精确率是在预测正样本占实际正样本的比例,召回率是正样本中被预测为正样本的概率,F1-Score 同时考虑精确率和召回率,其计算如公式(4)~(7):

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \tag{4}$$

$$Precision = \frac{TP}{TP+FP} \tag{5}$$

$$Recall = \frac{TP}{TP+FN} \tag{6}$$

$$F1-Score = \frac{2PR}{P+R} \tag{7}$$

式中:TP 为判断正确的正样本;TN 为判断正确的负样本;FP 为判断错误的负样本;FN 为判断错误的正样本;P、R 为精确率、召回率。

2 结果与分析

2.1 试验结果

将原始原型网络与 VGG-ML 原型网络在同样的测试集与训练集进行 5-way、1-shot 与 5-way、5-shot 试

验,结果如表 3 所示。原始原型网络 5-way、1-shot 平均识别准确率为 64.45%,5-way、5-shot 平均识别准确率为 77.11%。VGG-ML 原型网络 5-way、1-shot 平均识别准确率为 67.98%,5-way、5-shot 平均识别准确率为 81.51%,可见 VGG-ML 对于嵌入单元的改进具有明显效果,具体表现为网络在识别准确率方面占有优势。对比 2 组试验发现,5-way、5-shot 从识别准确率来看普遍高于 5-way、1-shot,可见在支持集中,每类样本的数量选取影响最终识别结果。

表 3 模型识别准确率

Table 3 Comparison of model recognition accuracy

%

标签名称 Label name	识别准确率 Recognition accuracy			
	原始原型网络 Original prototype network		VGG-ML 原型网络 VGG-ML prototype network	
	5-way、1-shot	5-way、5-shot	5-way、1-shot	5-way、5-shot
稻纵卷叶螟 Rice leaf roller	58.92	72.70	62.52	76.37
稻叶毛虫 Rice leaf caterpillar	61.44	71.81	64.32	77.74
亚洲稻螟 Asiatic rice borer	60.39	72.55	64.79	76.16
稻瘿蚊 Rice gall midge	65.81	79.41	70.07	83.67
稻秆蝇 Rice stemfly	67.49	80.25	69.11	85.79
稻水象甲 Rice water weevil	71.62	83.79	73.69	87.85
稻叶蝉 Rice Leafhopper	65.79	82.57	70.06	86.64
稻苞虫 Rice shell pest	64.17	73.84	69.28	77.91
平均 Average	64.45	77.12	67.98	81.52

从图 8 看出,在 5way、1-shot 试验中,在整个迭代周期 VGG-ML 均占优势;在 5way、5-shot 试验中,在迭代初期原始原型网络准确率略高于 VGG-ML 网络。在迭代 15 轮时原始原型网络占有一定优势,30 轮时 VGG-ML 准确率超过原始原型网络,在迭代到 45 轮左右时 VGG-ML 准确率趋于稳定,而原始原型网络则在 35 轮时的准确率再没有明显上升。其原因与 VGG-ML 采用特征提取能力更强的 VGG16 作为嵌入单元有关。由于 VGG16 模型较原始原型网络嵌入单元更为复杂,这使得 VGG-ML 在训练后期优势明显。从图 8 可见,在 N-way、M-shot 试验中,4 条曲线损失函数均在模型迭代 35 轮左右时变得平缓并开始收敛,其中 VGG-ML 5-way、5-shot 的收敛效果最好,其次为原始原型网络 5-way、5-shot,效果最差的为原始原型网络 5-way、1-shot。可见 VGG-ML 总体优于原始原型网络,但试验结果同样表明支持集中每种类别样本的数量对于结果有明显影响。

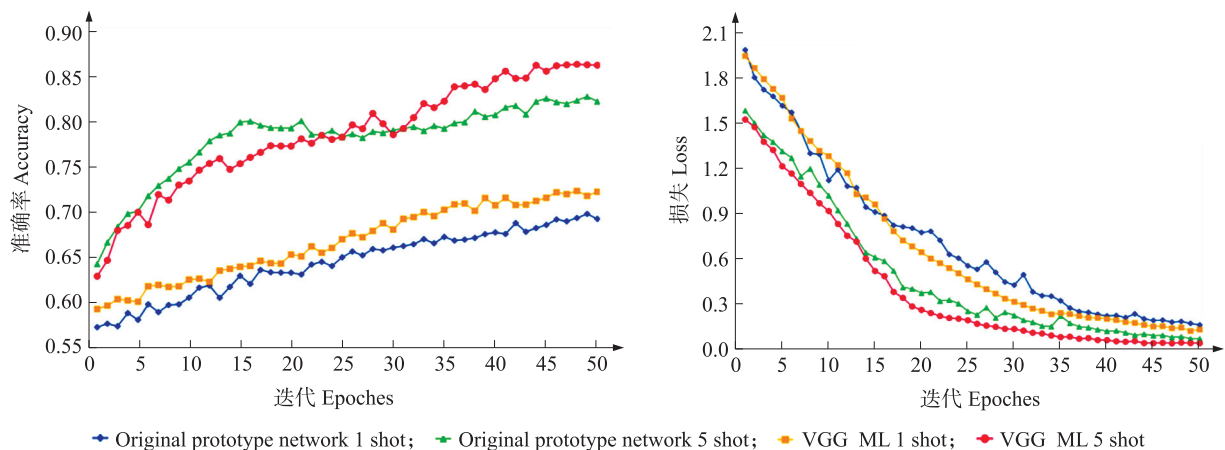


图 8 准确率与损失函数对比

Fig. 8 Comparison of accuracy and loss function

## 2.2 对比试验

为了验证 VGG-ML 模型的优越性,将 VGG-ML 模型与 Cosine classifier、RENet、DeepEMD 三个小样本模型进行对比,发现 F1-Score、Recall、Precision 在 VGG-ML 模型均有优越表现。迁移学习也是一种将旧知识迁移至新知识的技术,从某种程度上也可以缓解样本量不足的问题,为了对比 VGG-ML 与迁移学习的差异,1.1.1 节所示的训练集先对 VGG16 与 ResNet50<sup>[30-31]</sup> 网络进行预训练,再用 1.1.2 节所示的测试集进

行测试,试验结果如表 4 所示。

表 4 与基线模型识别对比

Table 4 Comparison with baseline model recognition

模型 Model	F1-score	Recall	Precision	模型 Model	F1-score	Recall	Precision
Cosine classifier <sup>[32]</sup>	70.12	70.01	70.23	VGG_ML(ours)	82.84	82.33	83.35
RENet <sup>[33]</sup>	75.10	71.33	79.30	VGG16(迁移学习)	57.25	62.44	52.86
DeepEMD <sup>[34]</sup>	77.43	82.15	73.22	ResNet50(迁移学习)	59.91	65.01	55.57

从表 4 可见:基于迁移学习的 VGG16 和 ResNet50 网络在解决测试基于训练集不相交情况下的小样本农业虫害识别问题时,效果并不理想,相比之下 VGG-ML 原型网络有明显优势。从图 9 的 5-way、5-shot VGG-ML 模型和 ResNet50 迁移学习试验混淆矩阵分类可视结果看,ResNet50 迁移学习对每种类型都有较多的错分案例,VGG-ML 原型网络则提高了各个类型的分类精度,说明在解决小样本植物虫害分类问题时,VGG-ML 原型网络优于迁移学习。

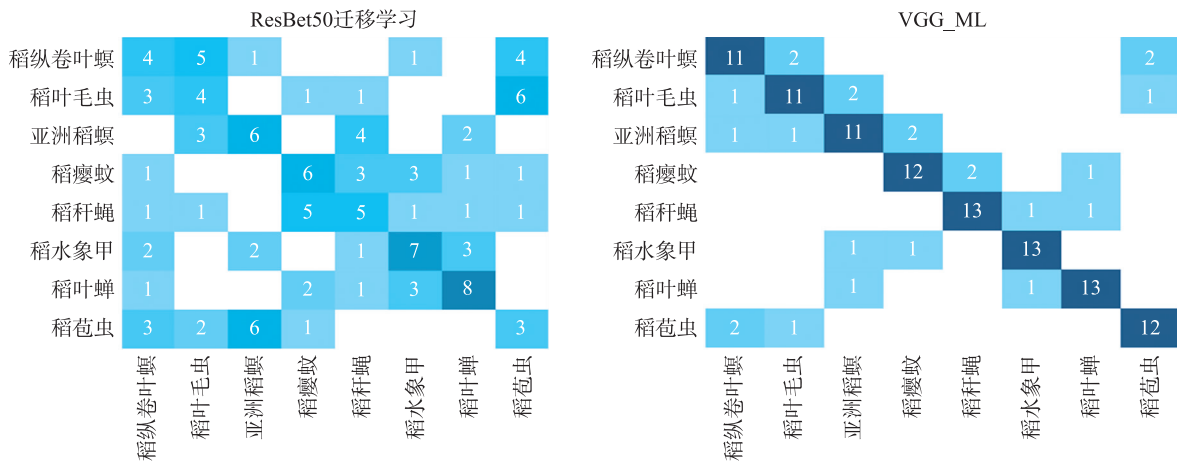


图 9 混淆矩阵对比

Fig. 9 Comparison of confusion matrix

### 3 结论与讨论

利用深度学习技术进行植物虫害识别时需要大量虫害样本进行模型训练,然而虫害样本的获取受到季节、地域的限制。研究表明小样本的提出可解决诸多领域中数据有限和获取难度较大的问题<sup>[35]</sup>。本研究将原型网络与 VGG16 卷积神经网络结合,构建一个 VGG-ML 原型网络模型,解决了植物虫害小样本分类问题;采用 N-way、M-shot 学习方法训练 VGG-ML 模型,将训练样本分成若干个元任务  $T_1, T_2, \dots, T_n$ ,每个原任务均划分为支持集( $N$  个类别, $M$  个样本)与查询集( $N$  个类别, $L$  个样本),利用支持集中的样本计算类原型,利用查询集中的样本进行类别度量。为了实现模型对于新样本的识别能力,本文采用训练集与测试集异域的方式进行训练,选择玉米、甜菜、苜蓿等 11 种植物的蚜虫、黏虫、跳甲等 24 类农业虫害作为训练集,采用稻纵卷叶螟、稻叶毛虫、亚洲稻螟等 8 类样本数据较少的水稻虫害进行测试识别,使用 5-way、5-shot 试验准确率为 81.51%,与原始原型网络相比提高 4.4 百分点,与 VGG16 迁移学习和 ResNet50 迁移学习对比,识别准确率分别提高 28.64 与 25.94 百分点,这表明 VGG-ML 可以提升小样本水稻植物虫害识别的准确率。在试验中发现 5-way、5-shot 结果明显优于 5-way、1-shot,其他基线模型也表现出此特征,表明在 N-way、M-shot 试验中支持集样本的数量对于结果有明显影响。由于元学习模型训练旨在使得网络具有从特定样本中抽取类别特征的能力,因此网络具有快速适应新学习任务的能力,从而降低对样本的需求量<sup>[36]</sup>。本研究在模型的训练集与测试集不存在交集的情况下采用元学习的方式建立模型,可提高识别的准确率,可以用于解决小样本分类问题。

本文解决的小样本识别问题是通过充足样本或者公开数据集样本进行模型的训练,训练的目标不仅限于对于图像特征的抽取能力,更加关注模型自身的学习能力,即通过对旧样本的分类,提升模型对于新类别学习的归纳能力,再将训练好的模型应用于样本数量不充足的小样本植物虫害识别问题中。本文利

用蚜虫、黏虫、跳甲等11种、24类农业虫害,共计7200幅图像作为训练样本(样本量充足),利用稻纵卷叶螟、稻叶毛虫、亚洲稻螟、稻瘿蚊、稻秆蝇、稻水象甲、稻叶蝉、稻苞虫8类常见的水稻虫害,共计316幅图像作为测试集(样本量不充足)进行测试识别,可解决样本量不充足、样本获取困难的小样本虫害识别问题。但本文的研究只涉及样本类型的识别问题,对于小样本植物虫害目标检测与语义分割问题尚未涉及,这也是今后的研究方向。

#### 参考文献 References:

- [1] 车琳,蒋沁宏,王也,等.我国水稻五大产区虫害发生及防控情况差异的比较分析[J].植物保护,2022,48(3):233-241.  
Che L, Jiang Q H, Wang Y, et al. Comparative analysis of occurrence and control of pests in five rice producing regions in China[J]. Plant Protection, 2022, 48(3): 233-241 (in Chinese with English abstract).
- [2] 梁万杰,曹宏鑫.基于卷积神经网络的水稻虫害识别[J].江苏农业科学,2017,45(20):241-243,253.  
Liang W J, Cao H X. Identification of rice pests based on convolutional neural network[J]. Jiangsu Agricultural Sciences, 2017, 45(20): 241-243, 253 (in Chinese).
- [3] 宿恒硕,吕军,丁志平,等.基于改进残差神经网络的木材识别算法[J].林业科学,2021,57(12):147-154.  
Su H S, Lü J, Ding Z P, et al. Wood identification algorithm based on improved residual neural network[J]. Scientia Silvae Sinicae, 2021, 57(12): 147-154 (in Chinese with English abstract).
- [4] 周焱,刘文萍,骆有庆,等.基于深度学习的小目标受灾树木检测方法[J].林业科学,2021,57(3):98-107.  
Zhou Y, Liu W P, Luo Y Q, et al. Small object detection for infected trees based on the deep learning method[J]. Scientia Silvae Sinicae, 2021, 57(3): 98-107 (in Chinese with English abstract).
- [5] 孙钰,脱小倩,蒋琦,等.基于轻量级神经网络的2种害虫钻蛀振动识别方法[J].林业科学,2020,56(3):100-108.  
Sun Y, Tuo X Q, Jiang Q, et al. Drilling vibration identification technique of two pest based on lightweight neural networks[J]. Scientia Silvae Sinicae, 2020, 56(3): 100-108 (in Chinese with English abstract).
- [6] 马盼,杨子恒,万虎,等.基于YOLOv8网络的棉蚜图像识别算法及软件系统设计[J].智能化农业装备学报(中英),2023,4(3):42-49.  
Ma P, Yang Z H, Wan H, et al. A new cotton aphid image recognition algorithm and software based on YOLOv8[J]. Journal of Intelligent Agricultural Mechanization, 2023, 4(3): 42-49 (in Chinese with English abstract).
- [7] 郭阳,许贝贝,陈桂鹏,等.基于卷积神经网络的水稻虫害识别方法[J].中国农业科技导报,2021,23(11):99-109.  
Guo Y, Xu B B, Chen G P, et al. Rice insect pest recognition method based on convolutional neural network[J]. Journal of Agricultural Science and Technology, 2021, 23(11): 99-109 (in Chinese with English abstract).
- [8] 赵志焱,杨华,胡志伟,等.基于TACNN的玉露香梨叶虫害识别[J].计算机工程与应用,2021,57(9):176-181.  
Zhao Z Y, Yang H, Hu Z W, et al. Identification model of pests on Yuluxiang pear leaves based on TACNN[J]. Computer Engineering and Applications, 2021, 57(9): 176-181 (in Chinese with English abstract).
- [9] Liu Y, Liu S A, Xu J W, et al. Forest pest identification based on a new dataset and convolutional neural network model with enhancement strategy[J]. Computers and Electronics in Agriculture, 2022, 192: 106625.
- [10] Huang M L, Chuang T C, Liao Y C. Application of transfer learning and image augmentation technology for tomato pest identification[J]. Sustainable Computing: Informatics and Systems, 2022, 33: 100646.
- [11] McNeish D. On using Bayesian methods to address small sample problems[J]. Structural Equation Modeling: A Multidisciplinary Journal, 2016, 23(5): 750-773.
- [12] 张旭,周云成,刘忠颖,等.基于改进ShuffleNet V2模型的苹果叶部病害识别及应用[J].沈阳农业大学学报,2022,53(1):110-118.  
Zhang X, Zhou Y C, Liu Z Y, et al. Identification and application of apple leaf diseases based on improved ShuffleNet V2 model[J]. Journal of Shenyang Agricultural University, 2022, 53(1): 110-118 (in Chinese with English abstract).
- [13] Wang J X. Meta-learning in natural and artificial intelligence[J]. Current Opinion in Behavioral Sciences, 2021, 38: 90-95.
- [14] Huisman M, van Rijn J N, Plaat A. A survey of deep meta-learning[J]. Artificial Intelligence Review, 2021, 54(6): 4483-4541.
- [15] Ma Y, Zhao S L, Wang W X, et al. Multimodality in meta-learning: a comprehensive survey[J]. Knowledge-Based Systems, 2022, 250: 108976.
- [16] Finn C, Abbeel P, Levine S. Model-agnostic meta-learning for fast adaptation of deep networks[C]//Proceedings of the 34th International Conference on Machine Learning; Volume 70. August 6-11, 2017, Sydney, NSW, Australia. New York: ACM, 2017: 1126-1135.
- [17] Ravi S, Larochelle H. Optimization as a model for few-shot learning[C]//San J, Puerto R. International Conference on Learning Representation. 2016: 1-11.
- [18] 简涛,王哲昊,王海鹏,等.基于损失加权修正的舰船目标HRRP小样本元学习识别方法[J].信号处理,2022,38(12):2460-2468.  
Jian T, Wang Z H, Wang H P, et al. Ship target HRRP meta-learning recognition with small samples based on loss weighted correction[J]. Journal of Signal Processing, 2022, 38(12): 2460-2468 (in Chinese with English abstract).
- [19] 李庆旭,王巧华.基于原型网络的小样本禽蛋图像特征检测方法[J].农业机械学报,2021,52(11):376-383.  
Li Q X, Wang Q H. Feature detection method of small sample poultry egg image based on prototypical network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(11): 376-383 (in Chinese with English abstract).

- [20] Wang Y T, Wang S F. IMAL: an improved meta-learning approach for few-shot classification of plant diseases [C]//2021 IEEE 21st International Conference on Bioinformatics and Bioengineering (BIBE). October 25–27, 2021, Kragujevac, Serbia. IEEE, 2021: 1–7.
- [21] Argüeso D, Picón A, Irusta U, et al. Few-shot learning approach for plant disease classification using images taken in the field [J]. *Comput Electron Agric*, 2020, 175: 105542.
- [22] 桂江生, 费婧怡, 傅霞萍. 三维小样本元学习模型的大豆食心虫虫害高光谱检测 [J]. *光谱学与光谱分析*, 2021, 41(7): 2171–2174. Gui J S, Fei J Y, Fu X P. Hyperspectral imaging for detection of *Leguminivora glycinivorella* based on 3D few-shot meta-learning model [J]. *Spectroscopy and Spectral Analysis*, 2021, 41(7): 2171–2174 (in Chinese with English abstract).
- [23] Theckedath D, Sedamkar R R. Detecting affect states using VGG16, ResNet50 and SE-ResNet50 networks [J]. *SN Computer Science*, 2020, 1(2): 79.
- [24] Yang H Y, Ni J G, Gao J Y, et al. A novel method for peanut variety identification and classification by Improved VGG16 [J]. *Scientific Reports*, 2021, 11: 15756.
- [25] 党倩, 崔阿军, 尚闻博, 等. 采用欧式形态距离的负荷曲线近邻传播聚类方法 [J]. *西安交通大学学报*, 2022, 56(1): 165–176. Dang Q, Cui A J, Shang W B, et al. Affinity propagation clustering method of typical load curve with euclidean morphological distance [J]. *Journal of Xi'an Jiaotong University*, 2022, 56(1): 165–176 (in Chinese with English abstract).
- [26] 蔺万科, 宋华, 南新元, 等. 一种基于最优聚类中心与权重欧式距离的多源异质传感器数据融合方法 [J]. *传感技术学报*, 2022, 35(1): 49–56. Lin W K, Song H, Nan X Y, et al. A multi-source heterogeneous sensor data fusion method based on optimal clustering center and weighted euclidean distance [J]. *Chinese Journal of Sensors and Actuators*, 2022, 35(1): 49–56 (in Chinese with English abstract).
- [27] Liu Z H, Li H Y, Li R X, et al. Graph embedding based on euclidean distance matrix and its applications [C]//Proceedings of the 30th ACM International Conference on Information & Knowledge Management. New York: ACM, 2021: 1140–1149.
- [28] Wu X P, Zhan C, Lai Y K, et al. Ip102: a large-scale benchmark dataset for insect pest recognition [C]//2019 IEEE/CVF conference on computer vision and pattern recognition. Long Beach, CA, USA. IEEE, 2019: 8787–8796.
- [29] Snell J, Swersky K, Zemel R. Prototypical networks for few-shot learning [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. New York: ACM, 2017: 4080–4090.
- [30] Ali Alnuaim A, Zakariah M, Shashidhar C, et al. Speaker gender recognition based on deep neural networks and ResNet50 [J]. *Wireless Communications and Mobile Computing*, 2022, 2022: 1–13.
- [31] Higuchi N, Hiraga H, Sasaki Y, et al. Automated evaluation of colon capsule endoscopic severity of ulcerative colitis using ResNet50 [J]. *PLoS One*, 2022, 17(6): e0269728.
- [32] Luo X, Wu H, Zhang J, et al. A closer look at few-shot classification again [EB/OL]. arXiv Preprint: 2301. 12246, 2023.
- [33] Kang D, Kwon H, Min J H, et al. Relational embedding for few-shot classification [C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). October 10–17, 2021, Montreal, QC, Canada. IEEE, 2022: 8802–8813.
- [34] Zhang C, Cai Y J, Lin G S, et al. DeepEMD: few-shot image classification with differentiable earth mover's distance and structured classifiers [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 13–19, 2020, Seattle, WA, USA. IEEE, 2020: 12200–12210.
- [35] 安胜彪, 郭昱岐, 白宇, 等. 小样本图像分类研究综述 [J]. *计算机科学与探索*, 2023, 17(3): 511–532. An S B, Guo Y Q, Bai Y, et al. Survey of few-shot image classification research [J]. *Journal of Frontiers of Computer Science and Technology*, 2023, 17(3): 511–532 (in Chinese with English abstract).
- [36] 张立, 陈江涛, 熊芬芬, 等. 基于元学习的多可信度深度神经网络代理模型 [J]. *机械工程学报*, 2022, 58(1): 190–200. Zhang L, Chen J T, Xiong F F, et al. Meta-learning based multi-fidelity deep neural networks metamodel method [J]. *Journal of Mechanical Engineering*, 2022, 58(1): 190–200 (in Chinese with English abstract).

责任编辑: 沈 波