

# 基于渐进式学习和增强原型度量的小样本农作物病害识别方法

杜海顺<sup>1,2</sup> 安文昊<sup>1</sup> 张春海<sup>1</sup> 周毅<sup>1,2</sup>

(1. 河南大学人工智能学院, 郑州 450046; 2. 河南省车联网协同技术国际联合实验室, 郑州 450046)

**摘要:** 为了开展低成本、通用、灵活的农作物病害识别, 提出了一种基于渐进式学习和增强原型度量的小样本农作物病害识别网络 (Few-shot crop disease recognition network based on progressive learning and enhanced prototype metric, FPE-Net)。首先, 利用设计的增强原型度量模块, 计算能够准确表示类别中心的增强原型, 并充分利用增强原型中的丰富类别信息对农作物病害进行识别; 其次, 采用设计的渐进式学习策略对模型进行训练, 以帮助模型更好地适应农作物病害识别任务, 提升模型小样本农作物病害识别精度。在自制小样本农作物病害数据集 FSCD-Base、FSCD-Complex 以及 FSCD-Base 到 FSCD-Complex 的跨域设置上, FPE-Net 的 5-way 1-shot 平均识别准确率分别达到 70.65%、53.47% 和 49.58%, 5-way 5-shot 平均识别准确率分别达到 83.02%、66.15% 和 64.21%。实验结果表明, 本文提出的 FPE-Net 明显优于其他小样本农作物病害识别模型, 在训练样本不足的情况下能够更准确识别农作物病害。

**关键词:** 农作物; 病害识别; 小样本学习; 渐进式学习策略; 增强原型度量

中图分类号: TP181

文献标识码: A

文章编号: 1000-1298(2024)12-0344-10

OSID:



## Few-shot Crop Disease Recognition Based on Progressive Learning and Enhanced Prototype Metric

DU Haishun<sup>1,2</sup> AN Wenhao<sup>1</sup> ZHANG Chunhai<sup>1</sup> ZHOU Yi<sup>1,2</sup>

(1. School of Artificial Intelligence, Henan University, Zhengzhou 450046, China

2. International Joint Laboratory for Cooperative Vehicular Networks of Henan, Zhengzhou 450046, China)

**Abstract:** At present, crop disease recognition is mostly realized based on convolutional neural network. However, due to the lack of training data in actual agricultural production, these crop disease recognition methods based on convolutional neural network often have limited applications and perform poorly. In order to carry out the low-cost, general and flexible crop disease recognition, a few-shot crop disease recognition network based on progressive learning and enhanced prototype metric was proposed. Specifically, an enhanced prototype metric module was firstly designed to compute the enhanced prototype that can accurately represent the category center, and make full use of its rich category information to recognize the crop disease. Then, a progressive learning strategy was designed to train the model to help it better adapt to the crop disease recognition, and further improve the few-shot crop disease recognition accuracy. On the self-made few-shot crop disease datasets FSCD-Base, FSCD-Complex and the cross-domain setting from FSCD-Base to FSCD-Complex, the 5-way 1-shot average recognition accuracy of the FPE-Net reached 70.65%, 53.47% and 49.58%, and the 5-way 5-shot average recognition accuracy of the FPE-Net reached 83.02%, 66.15% and 64.21%, respectively. These experimental results showed that the FPE-Net was significantly better than other few-shot crop disease recognition models, which can recognize crop diseases more accurately when the training data was insufficient.

**Key words:** crop; disease recognition; few-shot learning; progressive learning strategy; enhanced prototype metric

收稿日期: 2024-07-10 修回日期: 2024-08-29

基金项目: 国家自然科学基金项目(62176088)和河南省科技发展计划项目(222102110135)

作者简介: 杜海顺(1977—),男,教授,博士,主要从事计算机视觉、模式识别和机器学习等研究, E-mail: jddhs@vip.henu.edu.cn

## 0 引言

农作物病害是影响粮食产量和质量的重要因素,及时识别农作物病害并合理喷施农药是治理农作物病害的重要手段<sup>[1]</sup>。随着人工智能技术的不断进步,学者提出了许多基于经典卷积神经网络的农作物病害识别方法<sup>[2-6]</sup>。此外,一些学者采用特征融合和注意力机制对经典卷积神经网络进行改进,进一步提升了农作物病害识别精度<sup>[7-11]</sup>。虽然与基于传统机器学习的农作物病害识别方法相比,这些基于卷积神经网络的农作物病害识别方法的特征提取过程更加简单,病害识别准确度更高,但实际应用却十分受限。这主要是因为:①深度学习模型需要大量的训练样本才能表现出出色的性能,但农作物病害图像的收集和标注成本十分昂贵<sup>[12-13]</sup>。②对于新出现的农作物病害,需要向数据集中及时添加足够多的新病害图像以重新训练模型。

为了解决上述问题,近年来研究者提出了一些小样本农作物病害识别方法<sup>[14-23]</sup>。目前,小样本农作物病害识别大多采用度量学习与元学习<sup>[24]</sup>相结合的方式实现。这种方式首先利用特征提取器分别从支持集和查询集提取支持特征和查询特征,然后通过计算支持特征和查询特征的相似性来判断查询集中病害图像的类别。目前,基于卷积神经网络的农作物病害识别方法通常使用类别相同的病害图像对它们的模型进行训练和测试,且只有在训练样本充足的情况下,模型才能表现出优异性能;小样本农作物病害识别方法通常使用训练样本丰富的常见病害对模型进行训练,使用仅含有少量带标签图像的全新的病害类别对模型进行测试。因此,在病害训练样本不足的情况下,小样本农作物病害识别方法具有明显优势。然而,现有小样本农作物病害识别模型大多专注于提升模型小样本学习能力,而忽略了模型对农作物病害识别任务的适应问题。此外,

这些模型大多采用原型网络作为基线,而原型网络不仅在计算原型时没有考虑不同样本代表性的差异,也没有充分利用原型中丰富的类别信息。

为了解决上述问题,本文提出一种基于渐进式学习和增强原型度量的小样本农作物病害识别网络,主要由一个特征提取器和一个增强原型度量模块组成。其中,特征提取器负责提取农作物病害图像的特征;增强原型度量模块负责计算能够准确表示类别中心的增强原型,并充分利用增强原型中的丰富类别信息对农作物病害进行识别。此外,本文还设计一种渐进式学习策略对模型进行训练,以期使模型更好地适应农作物病害识别任务。

## 1 数据集构建与识别模型建立

### 1.1 数据集

在 Kaggle 官方网站 (<https://www.kaggle.com/>) 搜集了大量农作物病害数据集,并进行了汇总、筛选和整理,最后根据病害图像的背景复杂度进行划分,制作了两个专门用于小样本农作物病害识别的数据集 FSCD-Base 和 FSCD-Complex。

#### (1) FSCD-Base 小样本农作物病害数据集

该数据集有 22 种农作物的 66 类病害图像共 6 311 幅,每个类别约包含 100 幅病害图像。该数据集中部分病害图像如图 1 所示。在实验中,该数据集中的苹果、蓝莓、樱桃、玉米等 17 种农作物的 45 类病害共 4 212 幅图像用于元训练,橙子、桃、胡椒、茶叶、番茄 5 种农作物的 21 类病害共 2 099 幅图像用于元测试。该数据集具体划分设置如表 1 所示。表 1 中,类型为元训练的农作物表示该农作物所有病害类别的病害图像都用于元训练,类型为元测试的农作物表示该农作物所有病害类别的病害图像都用于元测试。例如,4 类苹果病害图像都被用于元训练,10 类番茄病害图像都被用于元测试。



图 1 FSCD-Base 数据集中部分农作物病害图像

Fig. 1 Some disease images in FSCD-Base dataset

#### (2) FSCD-Complex 小样本农作物病害数据集

该数据集有 8 种农作物的 25 类病害图像共 4 202 幅,每个类别包含约 200 幅病害图像。该数据集中部分病害图像如图 2 所示。由图 2 可以看出,

与 FSCD-Base 数据集中的病害图像相比,该数据集中病害图像的背景更加复杂。在实验中,该数据集中的木薯、辣椒、甘蔗、小麦 4 种农作物的 15 类病害共 2 444 幅图像用于元训练,咖啡、黄瓜、向日葵、

表1 FSCD - Base 数据集划分设置

Tab.1 Split settings for FSCD - Base dataset

农作物	病害种类	类型	农作物	病害种类	类型
苹果	4	元训练	覆盆子	1	元训练
蓝莓	1	元训练	水稻	5	元训练
樱桃	2	元训练	大豆	5	元训练
玉米	4	元训练	南瓜	1	元训练
番石榴	2	元训练	草莓	2	元训练
葡萄	4	元训练	甘蔗	3	元训练
黑莓	2	元训练	橙子	1	元测试
柠檬	2	元训练	桃	2	元测试
芒果	2	元训练	胡椒	2	元测试
石榴	2	元训练	茶叶	6	元测试
马铃薯	3	元训练	番茄	10	元测试



图2 FSCD - Complex 数据集中部分农作物病害图像

Fig.2 Some disease images in FSCD - Complex dataset

表2 FSCD - Complex 数据集划分设置

Tab.2 Split settings for FSCD - Complex dataset

农作物	病害种类	类型	农作物	病害种类	类型
木薯	5	元训练	咖啡	3	元测试
辣椒	5	元训练	黄瓜	2	元测试
甘蔗	2	元训练	向日葵	3	元测试
小麦	3	元训练	大豆	2	元测试

集  $I_s$  和一个查询集  $I_q$ , 其中  $I_s = \{(x_i^s, y_i^s)\} (i = 1, 2, \dots, NK)$ , 含有  $N$  个类别, 每个类别仅含有少量  $K$  幅带标签图像, 而  $I_q = \{x_i^q\} (i = 1, 2, \dots, M)$ , 含有  $M$  幅无标签图像。在小样本学习中, 这样的任务被称为  $N$ -way  $K$ -shot 小样本分类任务, 其目标就是利用从  $N \times K$  幅少量带标签图像中学习到的知识, 准确地预测  $M$  幅无标签图像类别。

### 1.3 病害识别模型建立

本文提出的 FPE - Net 整体框架如图 3 所示。FPE - Net 主要由一个特征提取器和一个增强原型度量模块组成, 并且 FPE - Net 的模型参数通过渐进式学习策略训练得到。在渐进式学习策略前 2 个阶段, 分别在 miniImageNet<sup>[25]</sup> 和元训练集  $D_{train}$  上采用传统监督方式对特征提取器  $f_\theta$  进行优化, 得到其参数  $\theta_a$  和  $\theta_b$ ; 在渐进式学习策略第 3 阶段, 在元训练集  $D_{train}$  上采用元学习范式对模型进行优化, 得到特征提取器参数  $\theta_c$  和增强度量模块参数  $\phi$ 。

特别地, 在渐进式学习策略第 3 阶段, 首先, 将支持集和查询集分别送入特征提取器得到支持特征

大豆 4 种农作物的 10 类病害共 1 758 幅图像用于元测试。该数据集具体划分设置如表 2 所示。表 2 中的类型含义与表 1 相同。

### 1.2 问题定义

在小样本学习中, 通常采用标准的元学习范式训练和评估网络。训练过程以及用到的数据分别称为元训练阶段和元训练集  $D_{train} = \{(x_i, y_i), y_i \in C_{train}\}$ , 评估过程以及用到的数据分别称为元测试阶段和元测试集  $D_{test} = \{(x_i, y_i), y_i \in C_{test}\}$ 。特别地, 元训练集和元测试集含有不同的图像类别, 即  $C_{train} \cap C_{test} = \emptyset$ 。根据元学习范式, 元训练和元测试都由若干元任务组成, 每个元任务都包含一个支持

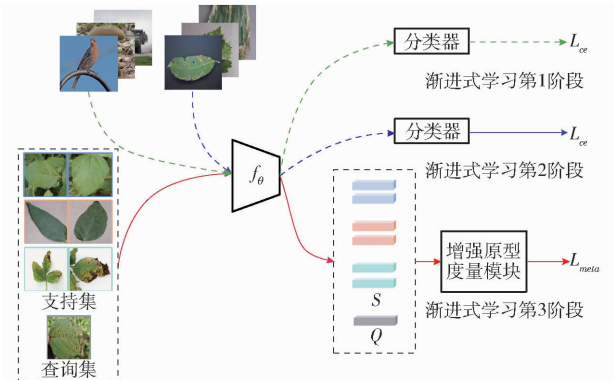


图3 FPE - Net 整体框架

Fig.3 Overall framework of FPE - Net

$S$  和查询特征  $Q$ ; 然后, 将  $S$  和  $Q$  送入增强原型度量模块计算得到查询集的农作物病害类别预测概率输出  $\hat{y}_1$  和  $\hat{y}_2$ 。在元训练阶段, 对  $\hat{y}_1$  和  $\hat{y}_2$  分别采用交叉熵损失监督, 并设计了一个正交损失用以单独监督增强原型  $P$ 。在元测试阶段, 引入一个可学习的参数自适应地平衡  $\hat{y}_1$  和  $\hat{y}_2$ , 以得到查询集的最终农作物病害类别预测概率输出  $\hat{y}$ 。

#### 1.3.1 特征提取器

特征提取器在小样本农作物病害识别模型中起着至关重要的作用, 其提取特征的质量会直接影响病害识别的准确率以及模型的泛化能力。为了平衡模型复杂度及其泛化能力, 选用 Conv4 作为特征提取器, 其具体结构如图 4 所示。具体地, 该特征提取器由 4 个卷积核为  $3 \times 3$ 、输出通道数为 64 的二维




图 4 特征提取器结构图

Fig. 4 Structure of feature extractor

卷积层组成。特别地,每个二维卷积层都接有 BatchNorm (BN) 归一化和 ReLU 激活函数。此外,为了避免模型过拟合,在渐进式学习前 2 个阶段,对前 2 个二维卷积层分别进行了 Dropblock 操作<sup>[26]</sup>。

### 1.3.2 增强原型度量模块

原型网络<sup>[27]</sup>是基于度量学习的小样本学习经典网络,它主要根据查询特征与原型间的相似度来预测查询图像的类别。在原型网络中,原型表示类别中心,一般为每类支持特征的均值。然而,支持集中的样本通过随机采样而来,部分样本可能类别特征明显、代表性较强,部分样本可能类别特征不明显、代表性较弱。原型网络在计算每类支持特征的均值时,没有考虑不同样本代表性的差异,因此其原型并不能准确地表示类别中心。为了得到能够准确表示类别中心的原型并充分利用原型中丰富的类别信息,本文设计了一个增强原型度量模块,如图 5 所示。

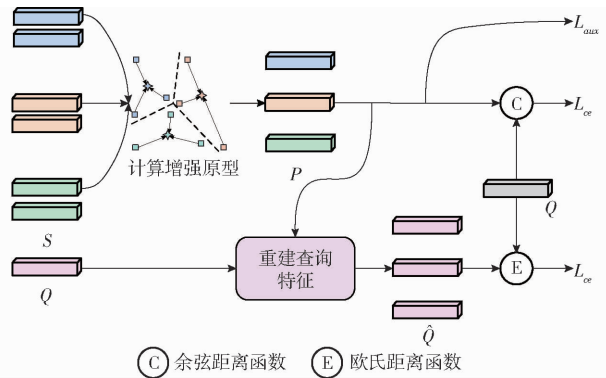


图 5 增强原型度量模块

Fig. 5 Enhanced prototype metric module

给定支持集  $I_s$  和查询集  $I_q$ ,首先将它们分别送入特征提取器  $f_{\theta_c}$  得到支持特征  $S \in \mathbf{R}^{N \times K \times HW \times C}$  和查询特征  $Q \in \mathbf{R}^{M \times HW \times C}$  ( $C, H, W$  为特征图通道数、高、宽);其次,引入一个可学习的权重矩阵  $W \in \mathbf{R}^{N \times K}$  并采用 Softmax 函数对其进行处理;最后,采用  $W$  对支持特征  $S$  进行加权求和得到增强原型  $P = \{P_1, P_2, \dots, P_N\}$ 。综上,类别  $n$  增强原型计算过程为

$$P_n = \sum_{k=1}^K \text{Softmax}(W_{n,k}) S_{n,k} \quad (1)$$

式中下角  $n$  表示类别序号, $k$  表示类别内样本序号。

得到增强原型后,首先根据其于查询特征的相似性,得到查询集的农作物病害类别预测概率输出

$\hat{y}_1 \in \mathbf{R}^{M \times N}$ ,其中, $\hat{y}_1^{m,n}$  表示查询集中第  $m$  幅病害图像属于第  $n$  类的概率,具体计算公式为

$$\begin{cases} \hat{y}_1^{m,n} = \text{Softmax}(-\cos(r(Q_m), r(P_n))) \\ \cos(a, b) = \frac{ab}{\|a\| \|b\|} \end{cases} \quad (2)$$

式中  $r(\cdot)$ ——将张量转换为向量的变形操作符,

$$r(Q_m), r(P_n) \in \mathbf{R}^{H \times W \times C}$$

$\cos(\cdot)$ ——余弦距离函数

$a, b$ ——距离函数输入,均为向量

然后,利用增强原型重建查询特征,并根据重建查询特征的质量得到查询集农作物病害类别预测输出  $\hat{y}_2 \in \mathbf{R}^{M \times N}$ 。具体地,给定类别  $n$  的增强原型  $P_n \in \mathbf{R}^{HW \times C}$  以及查询集中第  $m$  幅图像的查询特征  $Q_m \in \mathbf{R}^{HW \times C}$ ,首先采用一个线性变换矩阵  $W_{m,n} \in \mathbf{R}^{HW \times HW}$  将  $P_n$  变换为重建查询特征  $\hat{Q}_{m,n} \in \mathbf{R}^{HW \times C}$ 。为了寻求一个最优的  $W_{m,n}$  使得重建查询特征  $\hat{Q}_{m,n}$  与原查询特征  $Q_m$  的差异尽可能地小,需求解岭回归问题,即

$$\hat{W}_{m,n} = \underset{W_{m,n}}{\text{argmin}} \|Q_m - W_{m,n} P_n\|_F^2 + \alpha \|W_{m,n}\|_F^2 \quad (3)$$

式中  $\alpha$ ——可学习的正标量

显然,式(3)有封闭解为

$$\hat{W}_{m,n} = Q_m P_n^T (P_n P_n^T + \alpha I)^{-1} \quad (4)$$

式中  $I$ —— $HW \times HW$  单位矩阵

进而,得到重建查询特征为

$$\hat{Q}_{m,n} = \hat{W}_{m,n} P_n = Q_m P_n^T (P_n P_n^T + \alpha I)^{-1} P_n \quad (5)$$

此外,额外引入一个可学习的参数  $\beta$  对  $\hat{Q}_{m,n}$  进行约束,即

$$\hat{Q}_{m,n} = \hat{W}_{m,n} P_n = \beta Q_m P_n^T (P_n P_n^T + \alpha I)^{-1} P_n \quad (6)$$

如果利用类别  $n$  的原型  $P_n$  可以更好地重建查询特征  $Q_m$ ,即由  $P_n$  重建得到的查询特征  $\hat{Q}_{m,n}$  与原查询特征  $Q_m$  差值最小,则说明对应的查询输入  $x_m^Q$  与类别  $n$  的相关度最高。因此,查询集中第  $m$  幅病害图像属于第  $n$  类的预测概率  $\hat{y}_2^{m,n}$  可以计算得到,公式为

$$\begin{cases} \hat{y}_2^{m,n} = \text{Softmax}(-\text{euc}(r(Q_m), r(\hat{Q}_{m,n}))) \\ \text{euc}(a, b) = \|a - b\|^2 \end{cases} \quad (7)$$

式中  $\text{euc}(\cdot)$ ——欧氏距离函数

在得到查询集的预测概率输出  $\hat{y}_1$  和  $\hat{y}_2$  后,引入一个可学习的标量  $w$  对  $\hat{y}_1$  和  $\hat{y}_2$  自适应地加权求



和,得到查询集的最终农作物病害类别预测概率  $\hat{y} \in \mathbf{R}^{M \times N}$  为

$$\hat{y} = w\hat{y}_1 + (1 - w)\hat{y}_2 \quad (8)$$

为了提升  $\mathbf{P}$  中不同原型的类别差异性,设计了一个正交损失  $L_{orth}$  对  $\mathbf{P}$  进行监督,即

$$L_{orth} = \sum_{i \in N} \sum_{j \in N, i \neq j} \| \mathbf{P}_i \mathbf{P}_j \|^2 \quad (9)$$

### 1.3.3 渐进式学习策略

现有小样本农作物病害识别模型大多专注于提升模型小样本学习能力,而忽略了模型对农作物病害识别任务的适应问题。为了使模型可以更好地适应农作物病害识别任务,并进一步提升小样本农作物病害识别精度,设计了一种渐进式学习策略。

如图3所示,所提出的渐进式学习策略共分为3个阶段。第1阶段,为了使模型学习到通用的分类知识,该策略首先在特征提取器后设置一个全连接层作为分类器  $h$ ,然后在 miniImageNet<sup>[25]</sup> 数据集上采用传统的监督学习方式对特征提取器和分类器进行训练,得到特征提取器参数  $\theta_a$  和分类器参数  $\varphi_a$  为

$$(\theta_a, \varphi_a) = \operatorname{argmin}_{\theta, \varphi} L_{cc}(y^a, h_{\varphi}(f_{\theta}(x^a))) \quad (10)$$

$$L_{cc}(q, p) = - \sum_{i=1}^B \sum_{j=1}^Z q_j^i \lg(p_j^i) \quad (11)$$

式中  $x^a, y^a$ ——miniImageNet 数据集中的图像输入及其对应真实标签

$L_{cc}$ ——交叉熵损失

$B, Z$ ——1个批次中的图像数量和类别数量

$q_j^i$ ——第  $i$  幅图像属于第  $j$  类真实标签值

$p_j^i$ ——第  $i$  幅图像预测为第  $j$  类概率

第2阶段,为了使模型学习到关于农作物病害识别的专家级知识,该策略同样首先在特征提取器后设置一个全连接层作为分类器  $\tilde{h}$ ,然后在元训练集  $D_{train}$  上,对第1阶段训练得到的特征提取器以及分类器  $\tilde{h}$  采用传统的监督学习方式训练,得到特征提取器参数  $\theta_b$  和分类器  $\tilde{h}$  的参数  $\varphi_b$  为

$$(\theta_b, \varphi_b) = \operatorname{argmin}_{\theta, \varphi} L_{cc}(y^b, \tilde{h}_{\varphi}(f_{\theta}(x^b))) \quad (12)$$

式中  $x^b, y^b$ —— $D_{train}$  中的图像输入及其对应真实标签

第3阶段,为了将前2个阶段学习到的通用知识和专家级知识迁移到小样本学习任务上,该策略首先将全连接层分类器替换为所设计的增强原型度量模块,然后在元训练集  $D_{train}$  上采用元学习范式对模型进行训练,得到特征提取器参数  $\theta_c$  和增强原型度量模块参数  $\phi_c$  为

$$(\theta_c, \phi_c) = \operatorname{argmin}_{\theta, \phi} L_{meta}(y^o, g_{\phi}(f_{\theta_b}(x^s), f_{\theta_b}(x^o))) \quad (13)$$

$$L_{meta}(y^o, \hat{y}_1, \hat{y}_2) = [wL_{cc}(y^o, \hat{y}_1) + (1 - w)L_{cc}(y^o, \hat{y}_2)] + \lambda L_{orth} \quad (14)$$

式中  $L_{meta}$ ——元训练阶段网络总损失

$g_{\phi}$ ——增强原型度量模块

$\lambda$ ——平衡参数,用于平衡交叉熵损失与正交损失

$y^o$ —— $D_{train}$  查询集中图像的真实标签

在元训练结束后,根据式(8)预测查询集  $D_{test}$  中图像的农作物病害类别,并以所有元任务识别准确率平均值作为评价模型性能的指标。

## 2 实验与结果分析

### 2.1 实验过程

本文所有实验均使用 Pytorch 1.90 深度学习框架实现,并在配置 i7-10700F CPU 和 NVIDIA 3090 GPU 的计算平台上训练和测试。所有图像分辨率均调整为 84 像素  $\times$  84 像素。对于渐进式学习策略的前2个阶段,使用权重因子为  $5 \times 10^{-4}$  的 SGD 优化器分别对模型训练 100 轮次。在每个阶段,学习率初始值设置为 0.1,并在第 40、70 次时分别衰减为 0.01、0.001。对于渐进式学习策略的第3个阶段,采用标准的元学习范式以及 5-way 1-shot 和 5-way 5-shot 的任务设置对模型进行训练和评估。在元训练阶段,使用权重因子为  $5 \times 10^{-4}$  的 SGD 优化器对模型训练 50 轮次,每个轮次从元训练集中随机采样共计 400 个元任务。在该阶段中,学习率初始值设置为  $7 \times 10^{-4}$ ,并每隔 5 个轮次衰减为原来的 9/10。在元测试阶段,从元测试集中随机采样 1000 个元任务进行模型评估,并取所有元任务分类准确率平均值作为评价模型性能的指标。

对于 5-way 1-shot 任务,每个元任务中的支持集和查询集含有相同的 5 种病害类别,且每种病害类别分别包含 1 幅和 15 幅病害图像,即利用从  $5 \times 1$  幅带标签的支持集图像学习到的知识,准确地预测  $5 \times 15$  幅查询集图像的疾病类别。类似地,对于 5-way 5-shot 任务,每个元任务中的支持集和查询集含有相同的 5 种病害类别,且每种病害类别分别包含 5 幅和 15 幅病害图像,即利用从  $5 \times 5$  幅带标签的支持集图像学习到的知识,准确地预测  $5 \times 15$  幅查询集图像的疾病类别。

### 2.2 对比实验

为了验证 FPE-Net 有效性,分别在 FSCD-

Base、FSCD-Complex 数据集上将其与其它先进模型进行对比。为了保证对比的公平性,所有模型均采用 Conv4 作为特征提取器进行特征提取。

FPE-Net 与目前 6 种先进模型在 FSCD-Base 数据集上的实验结果如表 3 所示。由表 3 可知,在 FSCD-Base 数据集上,FPE-Net 的 5-way 1-shot 任务和 5-way 5-shot 任务的平均识别准确率分别达到 70.65% 和 83.02%,比其它先进模型分别至少提高 2.98 个百分点和 2.96 个百分点。这说明 FPE-Net 达到了目前小样本农作物病害识别的先进水平,在训练样本不足的情况下(每个病害类别仅含 1 幅或 5 幅带标签的病害图像)能够更加准确地识别农作物病害。

表 3 FSCD-Base 数据集上 FPE-Net 和 6 种先进模型对比实验结果

Tab. 3 Experimental results of FPE-Net and six state-of-the-art models on FSCD-Base dataset %

模型	平均识别准确率	
	5-way 1-shot	5-way 5-shot
Meta-LSTM <sup>[28]</sup>	66.31	79.65
ProtoNet <sup>[27]</sup>	62.48	77.34
MatchNet <sup>[29]</sup>	65.19	75.89
FEAT <sup>[30]</sup>	65.34	77.36
HTS <sup>[31]</sup>	67.67	80.06
文献[17]	65.22	78.26
FPE-Net	70.65	83.02

FPE-Net 与目前 6 种先进模型在 FSCD-Complex 数据集上的实验结果如表 4 所示。由表 4 可知,在 FSCD-Complex 数据集上,FPE-Net 的 5-way 1-shot 任务和 5-way 5-shot 任务的平均识别准确率分别达到 53.47% 和 66.15%,比其它先进模型分别至少提高 3.92 个百分点和 3.46 个百分点。这进一步说明 FPE-Net 达到了目前小样本农作物病害识别的先进水平,在训练样本不足的复杂场景下仍能够更加准确地识别农作物病害。

表 4 FSCD-Complex 数据集上 FPE-Net 和 6 种先进模型对比实验结果

Tab. 4 Experimental results of FPE-Net and six state-of-the-art models on FSCD-Complex dataset %

模型	平均识别准确率	
	5-way 1-shot	5-way 5-shot
Meta-LSTM <sup>[28]</sup>	44.78	55.30
ProtoNet <sup>[27]</sup>	46.78	54.31
MatchNet <sup>[29]</sup>	47.51	54.38
FEAT <sup>[30]</sup>	44.97	57.52
HTS <sup>[31]</sup>	47.98	61.78
文献[17]	49.55	62.69
FPE-Net	53.47	66.15

为了进一步验证 FPE-Net 的泛化性能,本文在从 FSCD-Base 到 FSCD-Complex 的跨域设置下将其与其它先进模型进行了对比,实验结果如表 5 所示。从 FSCD-Base 到 FSCD-Complex 的跨域设置指在 FSCD-Base 数据集上训练模型并在 FSCD-Complex 数据集上进行评估。

表 5 FPE-Net 和 6 种先进模型跨域实验结果

Tab. 5 Experimental results of FPE-Net and six current state-of-the-art models on cross-domain setting %

模型	平均识别准确率	
	5-way 1-shot	5-way 5-shot
Meta-LSTM <sup>[28]</sup>	40.75	53.63
ProtoNet <sup>[27]</sup>	42.34	54.44
MatchNet <sup>[29]</sup>	43.33	54.58
FEAT <sup>[30]</sup>	41.67	55.92
HTS <sup>[31]</sup>	45.55	58.38
文献[17]	44.01	57.04
FPE-Net	49.58	64.21

由表 5 可知,FPE-Net 在跨域设置下的 5-way 1-shot 任务和 5-way 5-shot 任务的平均识别准确率分别达到 49.58% 和 64.21%,比其它先进模型分别至少提高 4.03 个百分点和 5.83 个百分点。这充分说明 FPE-Net 具有良好的泛化能力。

### 2.3 消融实验

为了评估增强原型度量模块(EPMM)和渐进式学习策略(PLS)对 FPE-Net 整体性能的贡献,在 FSCD-Base 数据集上进行了消融实验。具体地,采用 ProtoNet 作为基线(Baseline),并以此为基础构建 3 个网络:Baseline + EPMM、Baseline + PLS、Baseline + EPMM + PLS(本文提出的 FPE-Net)。消融实验结果如表 6 所示。

表 6 FSCD-Base 数据集上消融实验结果

Tab. 6 Results of ablation experiments on FSCD-Base dataset %

Baseline	EPMM	PLS	平均识别准确率	
			5-way 1-shot	5-way 5-shot
√	×	×	62.48	77.34
√	√	×	67.18	80.19
√	×	√	67.91	82.09
√	√	√	70.65	83.02

注:√表示使用模块,×表示未使用模块。

从表 6 可知,与 Baseline 相比,Baseline + EPMM 的 5-way 1-shot 和 5-way 5-shot 任务的平均识别准确率分别提高 4.70 个百分点和 2.85 个百分点,这说明通过增强原型度量模块有助于提升小样本农作物病害识别的精度。与 Baseline 相比,Baseline + PLS 的 5-way 1-shot 和 5-way 5-shot

任务的平均识别准确率分别提高 5.43 个百分点和 4.75 个百分点,这说明渐进式学习策略可以使模型更好地适应农作物病害识别任务。与 Baseline 相比,Baseline + EPMM + PLS 的 5-way 1-shot 和 5-way 5-shot 任务的平均识别准确率分别提高 8.17 个百分点和 5.68 个百分点,这说明 EPMM 和 PLS 的共同作用能够显著提高模型性能。

## 2.4 超参数分析

为了探究式(14)中的损失函数平衡参数  $\lambda$  对 FPE-Net 性能的影响,在 FSCD-Base 数据集上进行了实验,结果如图 6 所示。




图 6 平均识别准确率随损失函数平衡参数  $\lambda$  的变化曲线

Fig. 6 Curves of average recognition accuracy variations with changes in balancing parameter  $\lambda$  of loss function

由图 6 可以看出,FPE-Net 的 5-way 1-shot 和 5-way 5-shot 任务的平均识别准确率均有明显提升,这说明正交损失可以有效提升模型性能。随着  $\lambda$  逐渐增大,FPE-Net 的 5-way 1-shot 和 5-way 5-shot 任务的平均识别准确率均变化较小,这说明当  $\lambda > 0$  时, $\lambda$  的取值对模型性能影响不大。因此,取  $\lambda = 1$ 。

## 2.5 综合性能评价

为了对 FPE-Net 进行更全面的评估,表 7 给出了模型内存占用量、训练时间、推理时间等性能指标。

表 7 FPE-Net 综合性能

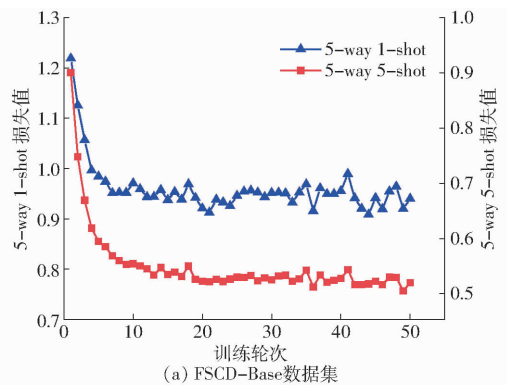
Tab. 7 Comprehensive performance of FPE-Net

数据集	内存占用量/ kB	5-way 1-shot		5-way 5-shot	
		训练时 间/min	推理 时间/s	训练时 间/min	推理 时间/s
FSCD-Base	113.1	199.8	21.4	201.2	23.3
FSCD-Complex	113.1	185.2	20.8	186.9	23.7

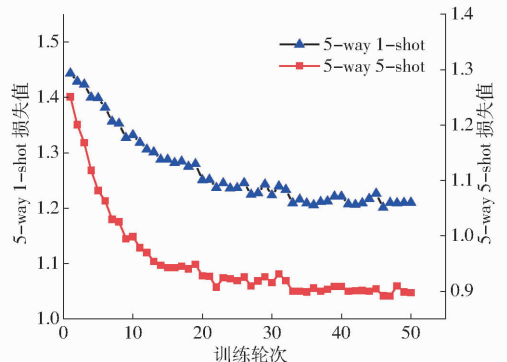
由表 7 可知,FPE-Net 的内存占用量仅为 113.1 kB,这表明 FPE-Net 为参数量极少的轻量化模型,能够在移动设备等资源受限的场景中部署。由表 7 可以看出,FPE-Net 在 FSCD-Base 数据集上训练 5-way 1-shot 和 5-way 5-shot 任务分别用时 199.8、201.2 min,在 FSCD-Complex 数据集上

训练 5-way 1-shot 和 5-way 5-shot 任务分别用时 185.2、186.9 min,这表明尽管 FPE-Net 采用渐进式学习策略进行 3 个阶段的训练,但总的训练时间仍然能够控制在较短的时间。需要说明的是,表 7 展示的推理时间为 1 000 个 5-way 1-shot 或 5-way 5-shot 元任务所需的推理时间,即识别 75 000 幅病害图像共计用时。FPE-Net 在 FSCD-Base 数据集上推理 1 000 个 5-way 1-shot 和 5-way 5-shot 元任务分别用时 21.4、23.3 s;在 FSCD-Complex 数据集上推理 5-way 1-shot 和 5-way 5-shot 任务分别用时 20.8、23.7 s。这表明 FPE-Net 平均每秒能够识别 3 164 ~ 3 605 幅病害图像,可以快速识别农作物病害。

此外,为了得到 FPE-Net 在元训练阶段的损失变化情况,绘制了其在 FSCD-Base 和 FSCD-Complex 数据集上损失值变化曲线,如图 7 所示。从图 7 可以看出,5-way 5-shot 任务的损失值始终比 5-way 1-shot 任务的损失值更低。此外,5-way 1-shot 和 5-way 5-shot 任务的损失值都能在训练初期迅速下降,并随着训练轮次的继续增加,逐渐进入伴有小幅波动的相对稳定状态。由于每个训练轮次内的所有元任务都是从元训练集随机采样而来,因此,损失波动可能是不同元任务间的训练难度差异所致。



(a) FSCD-Base数据集



(b) FSCD-Complex数据集

图 7 损失值变化曲线

Fig. 7 Loss variation curves

对于从 FSCD-Base 到 FSCD-Complex 的跨域设置,由于模型在 FSCD-Base 数据集上进行训练

并在 FSCD - Complex 数据集上进行评估,因此其训练时间和损失收敛情况可参考 FSCD - Base 数据集上的实验结果,推理时间可参考 FSCD - Complex 数据集上的实验结果,在此不再作详细分析。

### 2.6 可视化实验

为了直观地说明 FPE - Net 的有效性,分别对 Baseline (ProtoNet)和 FPE - Net 输出的查询特征进行了 t - SNE 和 Grad - CAM 特征可视化。

#### (1) t - SNE 特征可视化

如图 8 所示,在 FSCD - Base 数据集上分别对 5 - way 1 - shot 和 5 - way 5 - shot 任务的查询特征使用 t - SNE 可视化其空间分布。从图 8 可以看出,与 Baseline 相比,FPE - Net 输出的属于同一类别的查询特征紧凑聚集在一起,这说明 FPE - Net 对类的分离效果更好,可以更加准确地区分不同类型的农作物病害。

#### (2) Grad - CAM 特征可视化

如图 9 所示,在 FSCD - Base 和 FSCD - Complex 数据集上使用 Grad - CAM 可视化了部分查询特

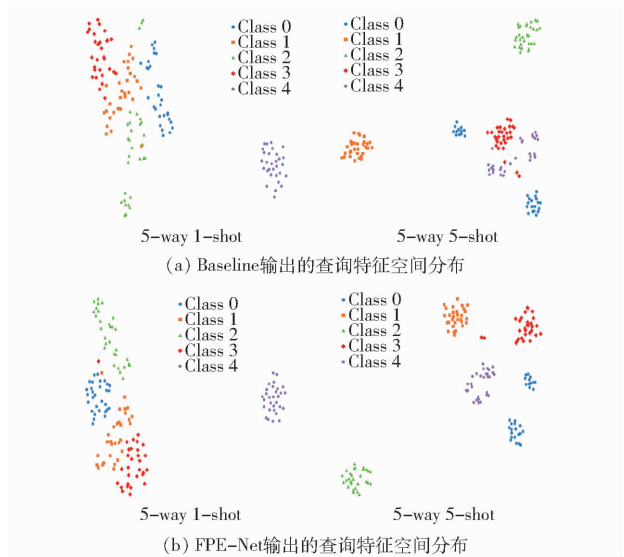


图 8 t - SNE 特征可视化结果

Fig. 8 t - SNE features visualization results

征的热力图。从图 9 可以看出,与 Baseline 相比,FPE - Net 对病斑等关键部位的关注更加准确、全面。




图 9 Grad - CAM 特征可视化结果

Fig. 9 Grad - CAM features visualization results

## 3 结论

(1) 提出了一种基于渐进式学习和增强原型度量的小样本农作物病害识别网络 (FPE - Net)。设计了一个增强原型度量模块,计算得到了能够准确表示类别中心的增强原型,并充分利用增强原型中的丰富类别信息对农作物病害进行了识别;设计了一种渐进式学习策略对模型进行训练,使模型能够更好地适应农作物病害识别任务,进一步提升了小样本农作物病害识别精度。

(2) 在自制小样本农作物病害数据集 FSCD -

Base、FSCD - Complex 以及 FSCD - Base 到 FSCD - Complex 的跨域设置上,FPE - Net 的 5 - way 1 - shot 平均识别准确率分别达到 70.65%、53.47%、49.58%,比其它先进模型分别至少提高 2.98、3.92、4.03 个百分点,5 - way 5 - shot 平均识别准确率分别达到 83.02%、66.15%、64.21%,比其它先进模型分别至少提高 2.96、3.46、5.83 个百分点。实验结果表明,本文提出的 FPE - Net 可以实现低成本、通用、灵活的农作物病害识别,在训练样本不足的情况下仍然能够更准确地识别农作物病害。



## 参 考 文 献

- [1] MANAVALAN R. Automatic identification of diseases in grains crops through computational approaches: a review [J]. *Computers and Electronics in Agriculture*, 2020, 178: 105802.
- [2] 樊湘鹏, 周建平, 许燕, 等. 基于改进卷积神经网络的复杂背景下玉米病害识别[J]. *农业机械学报*, 2021, 52(3): 210–217.  
FAN Xiangpeng, ZHOU Jianping, XU Yan, et al. Corn disease recognition under complicated background based on improved convolutional neural network [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(3): 210–217. (in Chinese)
- [3] 樊湘鹏, 许燕, 周建平, 等. 基于迁移学习和改进 CNN 的葡萄叶部病害检测系统[J]. *农业工程学报*, 2021, 37(6): 151–159.  
FAN Xiangpeng, XU Yan, ZHOU Jianping, et al. Detection system for grape leaf diseases based on transfer learning and updated CNN [J]. *Transactions of the CSAE*, 2021, 37(6): 151–159. (in Chinese)
- [4] 李书琴, 陈聪, 朱彤, 等. 基于轻量级残差网络的植物叶片病害识别[J]. *农业机械学报*, 2022, 53(3): 243–250.  
LI Shuqin, CHEN Cong, ZHU Tong, et al. Plant leaf disease identification based on lightweight residual network [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(3): 243–250. (in Chinese)
- [5] RAHMAN C R, ARKO P S, ALI M E, et al. Identification and recognition of rice diseases and pests using convolutional neural networks [J]. *Biosystems Engineering*, 2020, 194: 112–120.
- [6] XING S, LEE H J. Crop pests and diseases recognition using DANet with TLDP [J]. *Computers and Electronics in Agriculture*, 2022, 199: 107144.
- [7] XU W, LI W. Deep residual neural networks with feature recalibration for crop image disease recognition [J]. *Crop Protection*, 2024, 176: 106488.
- [8] 黄林生, 罗耀武, 杨小冬, 等. 基于注意力机制和多尺度残差网络的农作物病害识别[J]. *农业机械学报*, 2021, 52(10): 264–271.  
HUANG Linsheng, LUO Yaowu, YANG Xiaodong, et al. Crop disease recognition based on attention mechanism and multi-scale residual network [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(10): 264–271. (in Chinese)
- [9] 王泽钧, 马凤英, 张瑜, 等. 基于注意力机制和多尺度轻量型网络的农作物病害识别[J]. *农业工程学报*, 2022, 38(增刊1): 176–183.  
WANG Zejun, MA Fengying, ZHANG Yu, et al. Crop disease recognition using attention mechanism and multi-scale lightweight network [J]. *Transactions of the CSAE*, 2022, 38(Supp.1): 176–183. (in Chinese)
- [10] 杜海顺, 张春海, 安文昊, 等. 基于多层信息融合和显著性特征增强的农作物病害识别[J]. *农业机械学报*, 2023, 54(7): 214–222.  
DU Haishun, ZHANG Chunhai, AN Wenhao, et al. Crop disease recognition network based on multi-layer information fusion and saliency feature enhancement [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(7): 214–222. (in Chinese)
- [11] JIN H, CHU X, QI J, et al. Learning multiple attention transformer super-resolution method for grape disease recognition [J]. *Expert Systems with Applications*, 2024, 241: 122717.
- [12] 李云红, 张蕾涛, 李丽敏, 等. 基于 CycleGAN-IA 方法和 M-ConvNext 网络的苹果叶片病害图像识别[J]. *农业机械学报*, 2024, 55(4): 204–212.  
LI Yunhong, ZHANG Leitao, LI Limin, et al. Image recognition of apple leaf disease based on CycleGAN-IA method and M-ConvNext network [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(4): 204–212. (in Chinese)
- [13] ZHONG F, CHEN Z, ZHANG Y, et al. Zero-and few-shot learning for diseases recognition of *Citrus aurantium* L. using conditional adversarial autoencoders [J]. *Computers and Electronics in Agriculture*, 2020, 179: 105828.
- [14] LI Y, YANG J. Meta-learning baselines and database for few-shot classification in agriculture [J]. *Computers and Electronics in Agriculture*, 2021, 182: 106055.
- [15] HUANG Y, CHANG F, TAO Y, et al. Few-shot learning based on Attn-CutMix and task-adaptive transformer for the recognition of cotton growth state [J]. *Computers and Electronics in Agriculture*, 2022, 202: 107406.
- [16] CAO Y, CHEN L, YUAN Y, et al. Cucumber disease recognition with small samples using image-text-label-based multi-modal language model [J]. *Computers and Electronics in Agriculture*, 2023, 211: 107993.
- [17] NUTHALAPATI S V, TUNGA A. Multi-domain few-shot learning and dataset for agricultural applications [C] // *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2021: 1399–1408.
- [18] LIANG Weijian, GUO Qingwen, WANG Chuntao, et al. Few-shot pest classification using spatial-attention-enhanced ResNeSt-101 network and transfer-based meta-learning [J]. *Transactions of the CSAE*, 2024, 40(6): 285–297.
- [19] 满超, 饶元, 张敬尧, 等. 基于改进 Inception 网络的复杂环境下小样本黄瓜叶片病害识别[J]. *华中农业大学学报*, 2023, 42(3): 152–160.

- MAN Chao, RAO Yuan, ZHANG Jingyao, et al. Recognition of cucumber leaf disease with small samples in complex environment based on improved Inception network[J]. *Journal of Huazhong Agricultural University*, 2023, 42(3): 152 – 160. (in Chinese)
- [20] 田甜, 程志友, 鞠薇, 等. 基于 SimAM – ConvNeXt – FL 的茶叶病害小样本分类方法研究[J]. *农业机械学报*, 2024, 55(3): 275 – 281.  
TIAN Tian, CHENG Zhiyou, JU Wei, et al. Small sample classification of tea diseases based on SimAM – ConvNeXt – FL[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(3): 275 – 281. (in Chinese)
- [21] 李蛟, 王紫薇, 范丽丽, 等. 针对苹果树叶病害图像分类的小样本学习方法[J]. *吉林大学学报(理学版)*, 2022, 60(4): 906 – 910.  
LI Jiao, WANG Ziwei, FAN Lili, et al. Few-shot learning method for image classification of apple leaf diseases[J]. *Journal of Jilin University (Science Edition)*, 2022, 60(4): 906 – 910. (in Chinese)
- [22] REZAEI M, DIEPEVEEN D, LAGA H, et al. Plant disease recognition in a low data scenario using few-shot learning[J]. *Computers and Electronics in Agriculture*, 2024, 219: 108812.
- [23] ZHANG L, FU M, WANG Y. SProtoNet: self-supervised ProtoNet for plant leaf disease few-shot classification[C] // *Fourth International Conference on Computer Vision and Data Mining (ICCVDM 2024)*. SPIE, 2024: 138 – 141.
- [24] HUISMAN M, VAN RIJN J N, PLAAT A. A survey of deep meta-learning[J]. *Artificial Intelligence Review*, 2021, 54(6): 4483 – 541.
- [25] QIAO S, LIU C, SHEN W, et al. Few-shot image recognition by predicting parameters from activations[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 7229 – 7238.
- [26] GHIASI G, LIN T, LE Q. DropBlock: a regularization method for convolutional networks[C] // *Proceedings of the 32nd International Conference on Neural Information Processing Systems*, 2018: 10750 – 10760.
- [27] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C] // *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 2017: 4080 – 4090.
- [28] MUNKHDALAI T, YU H. Meta networks[C] // *International Conference on Machine Learning*. PMLR, 2017: 2554 – 2563.
- [29] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning[C] // *Proceedings of the 30th International Conference on Neural Information Processing Systems*, 2016: 3637 – 3645.
- [30] YE H, HU H, ZHAN D, et al. Few-shot learning via embedding adaptation with set-to-set functions[C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 8808 – 8817.
- [31] ZHANG M, HUANG S, LI W, et al. Tree structure-aware few-shot image classification via hierarchical aggregation[C] // *European Conference on Computer Vision*, 2022: 453 – 470.

---

(上接第 277 页)

- [31] WEIGAND M, STAAB J, WURM M, et al. Spatial and semantic effects of LUCAS samples on fully automated land use/land cover classification in high-resolution Sentinel – 2 data [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2020, 88: 102065.
- [32] NI R, TIAN J, LI X, et al. An enhanced pixel-based phenological feature for accurate paddy rice mapping with Sentinel – 2 imagery in Google Earth Engine[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 178: 282 – 296.
- [33] BERA B, SAHA S, BHATTACHARJEE S. Forest cover dynamics (1998 to 2019) and prediction of deforestation probability using binary logistic regression (BLR) model of Silabati watershed, India[J]. *Trees, Forests and People*, 2020, 2: 100034.
- [34] TUCKER C J. Red and photographic infrared linear combinations for monitoring vegetation [J]. *Remote Sensing of Environment*, 1979, 8(2): 127 – 150.
- [35] HUETE A, DIDAN K, MIURA T, et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices[J]. *Remote Sensing of Environment*, 2002, 83(1 – 2): 195 – 213.
- [36] MERZLYAK M N, GITELSON A A, CHIVKUNOVA O B, et al. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening[J]. *Physiologia Plantarum*, 1999, 106(1): 135 – 141.
- [37] 高祖新, 言方荣. 概率论与数理统计[M]. 南京: 南京大学出版社, 2020.
- [38] YANG G, LI X, LIU P, et al. Automated in-season mapping of winter wheat in China with training data generation and model transfer[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 202: 422 – 438.