

三维小样本元学习模型的大豆食心虫虫害高光谱检测

桂江生¹, 费婧怡¹, 傅霞萍²

1. 浙江理工大学信息学院, 浙江 杭州 310018

2. 浙江理工大学机械与自动控制学院, 浙江 杭州 310018

摘要 为降低大豆食心虫对大豆产量以及品质的影响, 实现对大豆食心虫虫害的快速检测, 提出了一种基于三维关系网络小样本元学习(3D-RN)模型的大豆食心虫虫害的检测方法。首先分别对附着虫卵的, 附着食心虫幼虫的, 被啃食的及正常的大豆各 20 颗进行高光谱图像采集, 提取感兴趣区, 建立基于高光谱图像的 3D-RN 模型。最终模型的正确率达 $82\% \pm 2.50\%$ 。对比与模型无关的元学习和匹配网络元学习模型, 3D-RN 模型能够充分度量样本特征间的距离, 识别效果大大提升。研究表明, 基于高光谱图像的 3D-RN 模型能够在少量样本情况下实现对大豆食心虫虫害的检测, 将小样本元学习与高光谱结合的方法为虫害检测提供一种新思路。

关键词 虫害检测; 大豆食心虫; 高光谱; 卷积神经网络; 小样本元学习; 三维

中图分类号: S435.29 **文献标识码**: A **DOI**: 10.3964/j.issn.1000-0593(2021)07-2171-04

引言

大豆是世界上最重要的油料作物和人类最主要的植物蛋白源, 在两市供给和农业生产中占重要地位^[1]。然而, 在大豆生长以及存储过程中, 由于病虫害导致大豆的产量下降。中国大豆害虫达 400 余种, 虫害一直是影响大豆产量和质量的重要因素^[2]。大豆在生长存储过程主要面临的虫害主要有大豆食心虫、大豆蚜虫以及豆象科害虫等。

目前的作物病虫害检测方法主要有: 人工感官判断, 生物化学方法^[3-5], 图像处理和光谱数据检测^[6-8]。其中, 人工感官判断具有一定的局限性和主观性。生物化学方法对检测样本要求高, 且耗时长、成本高以及不利于大规模操作。图像处理需要采集大量的样本数据支持, 耗费大量的人力以及时间等。光谱数据的检测方法只对样本的光谱维度进行分析, 缺少空间维度的数据分析, 导致检测效果不佳。随着图像空间和光谱结合的高光谱技术的快速发展, 高光谱在农作物病虫害检测的应用越来越广泛。Zheng^[9]等提出了基于选取的植被指数的损失分量与芦苇绿叶干重量损失之间的关系建立了蝗虫损失估计模型。李翠玲^[10]等搭建了高光谱成像系统, 利用判别分析方法建立番茄叶片斑潜蝇虫害的判别模型。Lin^[11]等利用 R-CNNs 开发了一个基于知识的植物病虫害识别系统。表明高光谱结合神经网络的方法检测虫害具有

较为光明的前景。

目前大多数高光谱图像采用卷积神经网络进行分类。但是深度学习需要采集大量数据, 针对这个问题, 本文提出了一种三维关系网络小样本元学习模型的大豆食心虫虫害检测方法, 通过高光谱技术, 利用元学习关系网络具有在少量标记样本下处理数据和三维卷积神经网络高效提取高光谱图像特征的特点, 采用基于高光谱建立大豆食心虫虫害的三维小样本元学习模型, 对大豆食心虫虫害进行检测, 旨在探索高光谱图像处理技术以及小样本元学习模型在大豆食心虫虫害检测方面的应用。

1 实验部分

1.1 样本制备

实验用的大豆样本以及大豆食心虫幼虫来源于实际农业机构。将大豆食心虫幼虫放入温暖潮湿的箱子中等待大豆食心虫长成成虫后, 将 20 只成虫放入大豆中使其于大豆上产卵, 5 d 后采集附着虫卵的大豆, 10 d 后采集附着大豆食心虫幼虫的大豆, 30 d 后采集被啃食的大豆。分别对正常的大豆以及上述三种大豆拍摄高光谱图像, 每类样本数量为 20 颗大豆种子。

1.2 高光谱成像系统

实验使用的高光谱成像系统如图 1 所示, 主要包括高光

收稿日期: 2020-07-11, 修订日期: 2020-11-26

基金项目: 国家重点研发计划项目(2016YFD0700203), 浙江省自然科学基金项目(LY20C130008)资助

作者简介: 桂江生, 1978 年生, 浙江理工大学信息学院副教授 e-mail: jsgui@zstu.edu.cn

谱成像仪 (Imperx IPX-2M30)、CCD 相机、电控平移台、4 个 150 W 的卤素灯以及一台计算机。其中采集的光谱范围为 383.70~1 032.70 nm, 共包含 256 个光谱波段, 光谱分辨率为 2.73 nm, 使用 SpectraVIEW 软件采集获得高光谱图像。为避免环境光对采集到的图像产生影响, 整个试验采集过程在暗箱中完成。




图 1 高光谱成像系统
Fig. 1 Hyperspectral imaging system

1.3 数据处理

1.3.1 光谱预处理及感兴趣区提取

在采集图像过程中可能会由于光照不均匀而对实验结果造成影响, 所以对采集到的图像进行黑白校正。采集过程中为了降低物体漫反射, 样本不均匀, 基线漂移等问题, 避免噪声对实验结果的影响, 对大豆光谱维度数据进行 Savitzky-Golay 滤波处理, 使光谱更加平滑, 并保持光谱的形状和宽度不变, 对后续的建模和检测具有重要的意义。

高光谱图像由很多窄波段图像组成, 波段间的相关性比较大, 从而造成数据冗余, 造成大量的重复计算。为了避免数据冗余的影响, 对大豆高光谱图像进行主成分分析法降维处理, 选取前 30 个主成分高光谱波段作为特征波段。以样本为中心选取 50×50 像素的正方形区域作为感兴趣区域, 将数据转换成 $50 \times 50 \times 30$ 的高光谱数据。

1.3.2 小样本元学习模型原理

小样本元学习模型有规定的训练模式, 小样本元学习包含元训练数据和元测试数据, 两者均包含支撑集和查询集。给定一个 N-way K-shot 分类任务, 支撑集中含有 N 个类别, 且每个类别含有 K 个被标签的样本, 查询集中同样也包含 N 个类别以及未被标签的样本。

三维关系网络 (3D-relation network, 3D-RN)^[12] 是一种基于度量的元学习方法, 训练好模型后无需对模型进行调整, 也能对新的类别进行分类。3D-RN 主要是训练一个卷积神经网络来学习距离度量的方式, 而不是采用线性度量方法来度量距离。

将所有数据分成多个任务 $p(T)$, 每个任务包含支撑集 $S = \{(x_i, y_i)\}_{i=1}^k$ 和查询集 $Q = \{(x_j, y_j)\}_{j=1}^n$ 。每个任务的支撑集和查询集中的样本输入特征学习模块, 即三维卷积神经网络学习到各自的特征 $f(x_i), f(x_j)$, 然后将查询集样本与每类支撑集样本的特征向量拼接到一起, 最后将连接到一起的特征输入 3D-RN 度量距离, 并输出关系得分^[12]

$$r_{i,j} = g(C(f(x_i), f(x_j))) \quad (1)$$

式(1)中, $f(\cdot)$ 为三维卷积神经网络学习样本的特征, $g(\cdot)$ 为 3D-RN 网络度量两个样本间的距离, $C(\cdot)$ 将两个特征拼接。3D-RN 的网络结构如图 2。

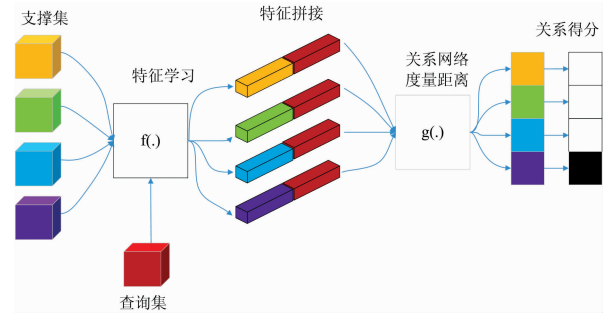


图 2 三维关系网络结构
Fig. 2 Structure of the 3D-Relation Network

与模型无关的元学习 (model-agnostic meta learning, MAML)^[13] 是一种基于模型的元学习方法, 通过训练一个模型, 使得这个模型能够最大程度的适应多分类任务, 即使面对未训练过的对象, 也不需要构建新的模型, 使用一样的学习模型也可以完成新任务的分类, 基本思想是寻找到对于模型更好的初始参数, 使得模型能够在该初始参数下快速高效的学习新的任务。

匹配网络 (matching network, MN)^[14] 是一种基于度量的元学习方法, 训练好一个模型后, 不需要对模型做调整, 也能对新的类别即训练中未出现的类别进行分类, 基本思想类似于端到端的近邻分类器。

2 结果与讨论

2.1 高光谱图像采集

高光谱图像采用 SpectraVIEW 软件采集, 采集图像时的曝光时间为 18 ms, 平台移动速度 $1.50 \text{ cm} \cdot \text{s}^{-1}$, 4 盏卤素灯与平台的夹角为 50° , 首先采集白板图像 W 和暗背景图像 B, 并依次对大豆样本进行图像采集。采集到的大豆样本如图 3。




图 3 大豆样本高光谱图像

(a): 正常大豆; (b): 附着虫卵的大豆;
(c): 附着幼虫的大豆; (d): 被啃食的大豆

Fig. 3 Hyperspectral images of soybean samples

(a): Normal soybean; (b): Soybean with egg;
(c): Soybean with larvae; (d): Gnawed soybean

2.2 模型建立与分析

使用 CAVE, iCVL 和 NUS 数据集作为元训练数据集。

CAVE 数据集是一个包含 32 个场景的哥伦比亚大学收集的多光谱数据集。iCVL 数据集是一个欧洲计算机视觉会议收集的高光谱数据集,数据集覆盖了室内、公园、植物、农村以及城市。NUS 数据集是一个包含一般场景和水果两大类的高光谱数据集。本文采集的四类大豆样本数据作为目标测试数据集。每个任务包含 4 个类,每个类共包含 20 个样本,分别对训练集包含每个类 1 个样本和 5 个样本两种情况进行研究。

3D-RN 模型由特征学习模块、特征拼接和关系网络组成,特征学习模块使用的网络模型为 ResNet18 或 Conv4。ResNet18 模型由 3D 卷积层、BatchNormal 归一化层、Relu 激活函数、最大池化层、常规残差模块和平均池化层组成。其中第一层的 3D 卷积层的卷积核为 $7 \times 7 \times 7$,共包含 8 个常规残差模块,常规残差模块中卷积层的卷积核为 $3 \times 3 \times 3$,最大池化层的卷积核为 $3 \times 3 \times 3$,损失函数为交叉熵损失函数。Conv4 模型由 3D 卷积层、BatchNormal 归一化层、Relu 激活函数和最大池化层组成,共 4 个卷积层,其中 3D 卷积层的卷积核为 $3 \times 3 \times 3$,最大池化层的卷积核为 $3 \times 3 \times 3$ 。关系网络由 2 个卷积层组成,两层的卷积核均为 $3 \times 3 \times 3$ 。每轮迭代方式为:卷积运算,归一化操作,再叠加两层全连接层,激活函数为 Relu。最后使用均方差误差损失函数输出关系得分。MAML 模型使用的网络模型为 ResNet18 或 Conv4。MN 模型特征提取网络为 ResNet18 模型和 Conv4 模型,训练数据使用的记忆网络为双向 LSTM,测试数据使用的记忆网络为 LSTM,距离度量网络使用余弦距离度量两个样本间的距离,注意力分类网络采用 softmax 损失函数分类。分类模型结果如表 1 所示。

结果表明,基于度量的小样本学习模型表现得比较好,其中 3D-RN 模型表现最好,5-shot 比 1-shot 表现更好。3D-RN 模型采用卷积网络度量查询集与支撑集中样本的距离,这种非线性的度量方法能够更好地度量样本之间的距离,且 3D-RN 模型不需要过低的学习率就能够得到很好的效果,说明在少量样本下 3D-RN 模型需要的算力和迭代更小。5-shot 将支撑集中每类的 5 个样本的特征结合在一起能够更好地表示样本的特征,从而使得分类的结果比 1-shot 更加优异。本模型训练好后可以用于工业应用,实际应用中不再需要训练,直接完成预测任务,耗时少,精度高,能够省去大量的人工检测成本。

每个任务中每类样本数量也是个重要的超参数,故分别对每类共含 10, 20 和 30 个样本使用 3D-RN 模型进行 4-way

5-shot 实验,实验结果显示在 10, 20 和 30 个样本条件下,准确率分别为 $69.27\% \pm 1.95\%$, $82.75\% \pm 2.50\%$ 和 $73.46\% \pm 1.44\%$ 。表明样本数量太小使得模型无法充分学习导致准确率不高,样本数量太大,任务复杂度超出模型的表达能力,导致准确率下降。

表 1 不同分类模型在 4-way 1-shot 和 4-way 5-shot 情况下的检测结果

Table 1 Detection results of different classification models in the cases of 4-way 1-shot and 4-way 5-shot

小样本学习模型	特征提取模型	学习率	正确率/%	
			1-shot	5-shot
MAML	ResNet18	0.01	50.98 ± 1.19	59.94 ± 0.56
		0.001	43.43 ± 0.55	48.03 ± 0.23
	Conv4	0.01	42.15 ± 0.38	52.65 ± 0.79
		0.001	35.15 ± 0.73	37.06 ± 0.58
MM	ResNet18	0.01	69.19 ± 1.21	78.65 ± 0.79
		0.001	56.58 ± 0.47	69.49 ± 0.82
	Conv4	0.01	52.46 ± 0.40	64.09 ± 0.70
		0.001	48.07 ± 0.97	60.21 ± 1.15
3D-RN	ResNet18	0.01	71.12 ± 0.61	82.75 ± 2.50
		0.001	65.90 ± 0.77	76.40 ± 1.23
	Conv4	0.01	57.31 ± 0.98	69.12 ± 0.31
		0.001	53.33 ± 0.96	65.15 ± 1.17

3 结论

目前,高光谱成像技术已经广泛应用于农业病虫害检测,但是对于小样本检测仍然面临很大的困难。利用高光谱图像技术采集正常大豆样本以及被大豆食心虫啃食的不同时期的大豆样本,建立了基于高光谱成像的大豆虫害三维关系网络小样本元学习检测模型。在三维关系网络模型中,三维卷积神经网络充分提取高光谱图像特征,卷积神经网络非线性距离度量模型,更有效的对比样本特征,因此,与 MAML 和 MN 元学习模型对比,3D-RN 模型的检测效果更精确,最终正确率在 5-shot 情况下正确率达到 $82.75\% \pm 2.50\%$ 。在样本数量不够,标记样本数量小的情况下,本模型表现优异。综上,小样本学习模型能够在高光谱成像技术上应用,解决实际问题,并且可以通过改进卷积网络模型以及其他参数进一步提高正确率。

References

- [1] LI Zhao-jun, TIAN Ru-mei, PU Yan-yan, et al(李照君,田汝美,蒲艳艳,等). Soybean Science(大豆科学), 2020, 39(4): 577.
- [2] GAO Yu, SHI Shu-sen(高宇,史树森). Soybean Science(大豆科学), 2016, 35(6): 1025.
- [3] DAI Yu-ting, ZHOU Bo, WANG Jun(代雨婷,周博,王俊). Transactions of the Chinese Society of Agricultural Engineering(农业工程学报), 2020, 36(3): 313.
- [4] Tanaka F, Magariyama Y, Miyano-shita A. Food Chemistry, 2020, 303, 125381.
- [5] Cui S, Ling P, Zhu H, et al. Sensors, 2018, 18(2): 378.
- [6] Nanni L, Maguolo G, Pancino F. Ecological Informatics, 2020, 57: 101089.

- [7] LUO Qing-qing, HUANG Tie-cheng, CHEN Shu-jiang, et al(罗青青, 黄铁成, 陈蜀江, 等). *Jiangsu Journal of Agricultural Sciences* (江苏农业学报), 2019, 35(4): 798.
- [8] Li W, Chen P, Wang B, et al. *Scientific Reports*, 2019, 9(1): 1.
- [9] Rustia D J, Lin C E, Chung J, et al. *Journal of Asia-Pacific Entomology*, 2020, 23(1): 17.
- [10] LI Cui-ling, JIANG Kai, MA Wei, et al(李翠玲, 姜 凯, 马 伟, 等). *Spectroscopy and Spectral Analysis*(光谱学与光谱分析), 2018, 38(1): 253.
- [11] Lin T L, Chang H Y, Chen K H. *Journal of Internet Technology*, 2020, 21(2): 605.
- [12] Sung F, Yang Y, Zhang L, et al. *Computer Vision and Pattern Recognition*, 2018, 2018: 1199 (doi: 10.1109/CVPR.2018.00131).
- [13] Finn C, Abbeel P, Levine S. *Proc of Machine Learning Research*, 2017, 70: 1126.
- [14] Vinyals O, Blundell C, Lillicrap T, et al. *Matching Networks for One Shot Learning*. *Proceedings of the Neural Information Processing Systems Conference*, 2016. 3630.

Hyperspectral Imaging for Detection of Leguminivora Glycinivorella Based on 3D Few-Shot Meta-Learning Model

GUI Jiang-sheng¹, FEI Jing-yi¹, FU Xia-ping²

1. School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China

2. Faculty of Mechanical Engineering & Automation, Zhejiang Sci-Tech University, Hangzhou 310018, China

Abstract In order to reduce the influence of leguminivora glycinivorella on soybean production and quality, and to realize the rapid detection of leguminivora glycinivorella, this paper proposed a leguminivora glycinivorella detection model based on 3D-Realtion Network (3D-RN) model. Firstly, collect the hyperspectral images of 20 soybeans that are attached to eggs, larvae, gnawed and normal soybeans, respectively, and extract the region of interest (ROI) to establish a 3D-RN model based on hyperspectral images. The accuracy of the final model reached $82\% \pm 2.50\%$. Compared to the Model-Agnostic Meta-Learning (MAML) and Matching Network (MN) models, the 3D-RN model can fully measure the distance between sample features, and the recognition effect is greatly improved. Thus, this research shows that the 3D-RN model based on the hyperspectral image can detect leguminivora glycinivorella in a small number of samples. The method of combining few-shot meta-learning with hyperspectral provides a new idea for pest detection.

Keywords Pest detection; Leguminivora glycinivorella; Hyperspectral; Convolutional neural network; Few-shot meta-learning; Three-dimensional

(Received Jul. 11, 2020; accepted Nov. 26, 2020)