

基于迁移学习的水稻病虫害识别*

范春全, 何彬彬[※]

(电子科技大学, 四川成都 611731)

摘要:【目的】水稻病虫害是引起水稻减产的重要因素。准确地识别水稻病虫害类型, 及时采取有效的针对性预防措施, 有助于避免因水稻减产带来的经济损失。然而, 聚焦于人脸和花草等常见事物的识别技术, 在农业领域特别是水稻病虫害识别领域应用较少, 而目前已有的水稻病虫害识别研究存在数据量小和数据种类不够丰富等问题。【方法】文章搜集了 2.0372 万张水稻病虫害图片, 并以此构建了完整的水稻病虫害识别数据集, 基于迁移学习的思想, 在 ResNet50 的预训练模型基础上构建了一个针对 16 种主要水稻病虫害识别的深度模型。同时, 考虑实际应用的需要, 搜集了 9 928 张其他图片 (包括人像、汽车等), 结合 9 675 张水稻病虫害图片, 构建了一个二分类数据过滤模型, 以此来避免非水稻病虫害图片被识别为某一类病虫害的不合理结果。【结果】有预训练模型验证结果的 top-1 准确率达到 95.23%, F1 系数为 77.83%, 相较无预训练模型 top-1 准确率提升了 24.51%, F1 系数提升了 56.66%。数据过滤模型的过滤准确度达到了 99.60%。【结论】基于迁移学习的水稻病虫害识别模型, 使水稻病虫害识别结果更加准确。非水稻病虫害过滤模型, 有效地解决了实际应用中非水稻病虫害图片被错分为某一类水稻病虫害的问题。

关键词: 水稻病虫害识别; 深度学习; 迁移学习; PyTorch; ResNet

DOI: 10.12105/j.issn.1672-0423.20200204

0 引言

水稻是我国主要粮食作物之一, 是国家粮食安全的基石。在水稻生长周期内, 伴随着多种病虫害的发生, 由此引起的水稻产量损失严重。目前水稻病虫害的识别主要依靠人工观察的方法, 不仅识别效率低下, 而且容易误诊并延误最佳诊断时间, 直接影响水稻病虫害防治的准确性和时效性^[1]。随着机器学习与人工智能的不断成熟, 越来越多的学者尝试将其扩展到水稻病虫害识别领域中。

为了提高识别准确率与效率, 传统的机器学习方法被一些学者应用于水稻病虫害识别研究中。传统机器学习方法的主要思路为: 首先基于数据集提取不同的水稻病虫害特

收稿日期: 2020-01-23

第一作者简介: 范春全 (1993—), 博士研究生。研究方向: 深度学习和水稻病虫害识别。

Email: 201911070403@std.uestc.edu.cn

※ 通信作者简介: 何彬彬 (1972—), 博士、教授。研究方向: 定量遥感、时空大数据挖掘。Email: binbinhe@uestc.edu.cn

* 基金项目: 国家重点研发计划课题“药肥精准施用跨境跨区域大数据平台”(2018YFD0200301)

2020年4月

征,常用的特征提取方法有 GIST^[2]、SIFT^[3]和 SURF^[4]等,然后采取以支持向量机^[5]和 K 近邻分类方法^[6]为代表的机器学习方法对特征进行分类,进而达到识别病虫害类别的目的。此类方法依赖于特征参数的准确提取,一旦错误的特征被提取,机器学习模型就难以精确识别特征相似的病虫害。而且此类方法一般仅提取几种典型的特征来表征病虫害的所有信息,然后在小数据集上进行分类识别验证。而实际的水稻生长过程中病虫害种类丰富多样,只通过提取少量典型特征的水稻病虫害识别方法效果不佳,并且人工提取特征比较耗时。

近年来,深度学习模型在众多图像识别中取得了较优结果。自 Krizhevsky 使用 AlexNet 模型^[7]在 ILSVRC (ImageNet Large-Scale Visual Recognition Challenge)^[8]中应用开始,深度学习在全世界掀起了研究热潮。卷积神经网络 (Convolutional Neural Networks, CNN) 模型如 GoogLeNet^[9]、VGGNet^[10]、ResNet^[11]等在图像分类中取得一定进展,部分学者逐渐将卷积神经网络应用到水稻病虫害识别之中。Liu 等使用深度卷积网络对 5 136 张图片 (包含 12 种水稻虫害) 进行了虫害识别^[12],识别准确度约为 95%。Lu 等使用卷积神经网络对 500 张图片 (包括 10 种水稻病害) 进行了病害识别^[13],分类准确度达到 95.48%。Liang 等基于相同的方法对 5 808 张图片 (其中 2 906 张为稻瘟病) 进行了稻瘟病识别^[14],识别准确度为 95.83%。Wu 等构建了一个用于农作物虫害识别的数据集 IPO2^[15],并在 IPO2 上对比了 AlexNet、GoogLeNet、VGGNet 和 ResNet4 种经典卷积神经网络的识别效果,ResNet 网络的识别效果明显优于其他 3 种网络结构,但由于数据集中的虫害图片并未经过严格的筛选,该农作物虫害分类准确度仅达到 49.4%。虽然水稻病虫害识别领域已经取得一定进展,但已有研究还存在以下不足:(1) 实验数据集小,小样本数据集很难有效地优化深度学习模型中存在的大量模型参数;(2) 参与实验的水稻病虫害种类较少,目前已有的基于深度学习的水稻病虫害识别研究仅关注病害或者仅关注虫害,并且种类只有一种或者几种,水稻病虫害种类的丰富程度远远不能满足实际的应用需求。

文章首先基于地面采集和网络搜集的方式,针对水稻常见的 4 种病害和 12 种虫害,构建水稻病虫害数据集,包括病虫害图片和健康水稻图片。同时考虑在实际应用场景中规避非水稻图片的影响,该文基于部分水稻病虫害数据集和非水稻数据构建了过滤数据集,并在模型应用过程中增加了一个过滤模型,用于剔除与水稻病虫害无关的识别过程,从而避免不合理的识别结果。基于水稻病虫害数据集和过滤数据集,采用迁移学习的深度模型 ResNet50 进行水稻病虫害识别。

1 研究数据与方法

1.1 研究数据

(1) 水稻病虫害识别数据集

该文使用的水稻病虫害识别数据集共包括 2.3275 万张水稻图片,其中 2.0372 万张不同病虫害类型的水稻图片,2 903 张正常水稻图片。16 种水稻病虫害类型如图 1 所示,不

同病虫害所包含的图片数量如表 1 所示。数据集中图片的来源主要包括稻田实地采集和网络搜集 2 种方式。稻田实地采集共获得 1.2367 万张病虫害图片和 2 903 张正常水稻图片，其中自主实验采集获得 1 012 张病虫害图片和 2 903 张正常水稻图片，其余 1.1355 万张病虫害图片在全国农业技术推广中心的帮助下，在全国主要稻区采得。网络搜集共获得 8 005 张病虫害图片，其中通过百度搜索引擎和谷歌搜索引擎共获得 465 张病虫害图片，其余 7 540 张病虫害图片根据相关论文^[14-15]使用的水稻病虫害数据集，剔除无关图片后获得。该数据集主要用于 ResNet50 预训练模型的训练和验证。



图 1 水稻病虫害数据样例: a. 虫害; b. 病害

Fig.1 Samples of rice diseases and insect pests

表 1 不同水稻病虫害类型及图片数量

Table 1 Different types of rice diseases and insect pests and the number of pictures

病虫害类型	图片数量 (张)	病虫害类型	图片数量 (张)	病虫害类型	图片数量 (张)
稻纵卷叶螟	1 085	三化螟	245	稻苞虫	86
稻潜叶蝇	91	稻瘿蚊	315	稻秆蝇	68
稻水象甲	736	二化螟	243	稻飞虱	2 086
大螟	94	稻叶蝉	324	禾蓟马	169
稻瘟病	9 616	稻曲病	4 876	白叶枯	186
纹枯病	152	正常水稻	2 903		

(2) 非水稻病虫害过滤数据集

为了避免在实际应用过程中无关图片 (比如人脸、汽车等) 被错分为水稻病虫害, 从而影响水稻病虫害的识别精度, 该文抽取已经构建的水稻病虫害数据集中的部分样本, 结合网络搜得的其他非水稻图片 (包含汽车、人像等其他图片) 构建了一个用于训练过滤模型的数据集。其中, 从 2.3275 万张水稻病虫害数据集随机抽取 9 675 张图片作为水

2020年4月

稻及水稻病虫害样本集，然后通过网络获取 9 928 张汽车、人像等其他图片作为非水稻图片集。该数据集主要用于过滤掉输入识别图片中与水稻无关的图片，从而避免不合理的识别结果。

1.2 研究方法

传统的深度学习模型为了保证结果的准确性和可靠性，都基于 2 个基本假设：(1) 用于深度模型训练和测试的样本都需满足独立同分布的条件；(2) 必须有足够多的训练样本才能学习到一个优秀的深度分类模型^[16]。然而在实际应用中，这 2 个条件往往很难满足。这个问题在水稻病虫害数据集构建过程中尤为突出，能否采集到水稻病虫害图片，往往取决于水稻生长周期内是否发生病虫害，而且经常需要跨地区采集，其过程不仅耗费大量的人力物力成本，同时也难以采集足够多的数据供深度模型学习使用。

有效的深度学习算法仍然依赖于大规模的数据集，例如包含数百万训练实例的 ImageNet。为了训练优秀的水稻病虫害识别模型，需要大规模的水稻病虫害图片。迁移学习是运用已存有的知识对不同但相关领域问题进行求解的一种新的机器学习方法。它放宽了传统机器学习中的两个基本假设，目的是迁移已有的知识来解决目标领域中仅有少量有标签样本数据甚至没有的学习问题^[16]。运用迁移学习可以用少量水稻病虫害数据训练出相对精准的水稻病虫害识别模型。

按照迁移学习方法采用的技术划分，迁移学习可以分为 3 类：(1) 基于特征选择的迁移学习；(2) 基于特征映射的迁移学习；(3) 基于权重的迁移学习^[16]。该文为了研究迁移学习是否有助于提升水稻病虫害的识别效果，采用基于权重的迁移学习方法，选择 2015 年 ILSVRC 比赛的冠军模型 ResNet50 为基础网络结构，将其在 ImageNet 数据集上的预训练模型作为水稻病虫害识别的预训练模型，进行迁移学习在水稻病虫害识别上的研究探索。ResNet50 模型共有 50 层，由大小不同的残差块构成，其通过特征映射的方式大大缓解了梯度消失的问题，ResNet50 网络的一般结构如图 2 所示。




图 2 ResNet50 结构

Fig.2 ResNet50 network architectures

该文应用迁移学习的过程如图 3 所示。由于 ResNet50 预训练模型在 ImageNet 数据集上用于 1 000 种分类，而该文仅针对 16 种水稻病虫害加正常水稻共 17 种分类类别，因此对 ResNet50 预训练模型进行了适用性改造。首先将其顶层的完全连接层及其参数删除，同时保留其他层的模型参数，以获得预训练模型学得的知识；然后在此基础上重新设计针对水稻病虫害和正常水稻共 17 种分类的完全连接，并随机初始化参数，在水稻病虫害数据上训练得到水稻病虫害识别模型（预训练）。为了对比研究迁移学习的效果，该文基

于非迁移学习的思路，用同样的病虫害数据在 ResNet50 原始网络上从零训练，得到水稻病虫害识别模型（非预训练）。

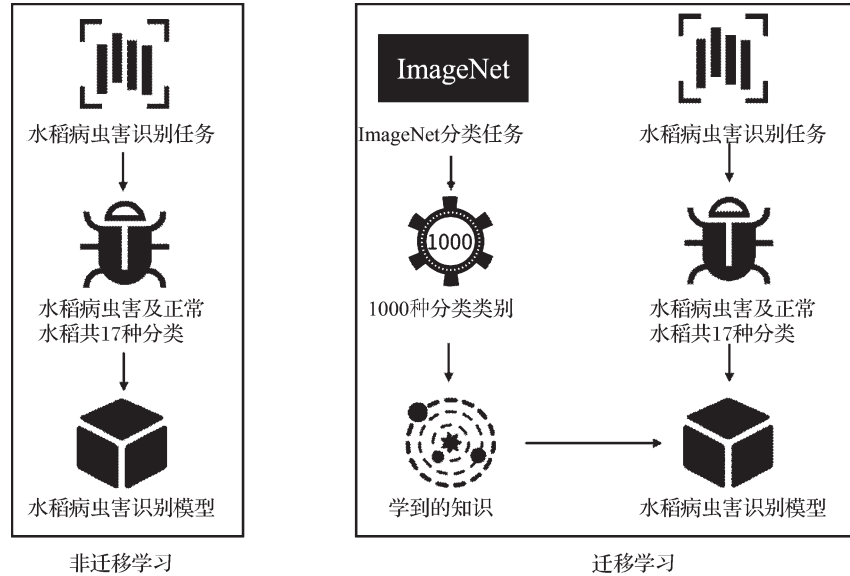


图 3 迁移学习框架

Fig.3 Schematic diagram of transfer learning

2 实验与分析

2.1 实验设置

由于所用的卷积神经网络最后一层为全连接层，所以将所有图片的输入尺寸固定到 224×224 像素，同时根据分层抽样的规则将每类水稻病虫害图片以 7:1:3 的比例划分为训练集、验证集与测试集。训练集与验证集参与模型的训练过程，测试集只用于模型的精度评价。该实验设定 ResNet50 预训练模型的训练迭代次数为 10，批处理数量 (batchsize) 设置为 64，学习率为 0.003。ResNet50 非预训练模型的训练迭代次数为 4 000，批处理数量 (batchsize) 设置为 64，学习率为 0.003。该实验基于深度学习框架 PyTorch^[17] 进行，采用 ubuntu 16.04 操作系统。

2.2 实验分析

由于该文所构建数据集中各类水稻病虫害比例分布不均衡，因此采用精确率、召回率、F1 系数、top-1 准确率、top-5 准确率和 kappa 系数指数 6 个常用指标来评价所构建水稻病虫害识别模型的测试结果。其中精确率指预测为某一类结果中预测的分类为真实分类的比率，召回率指该类所有样本中分类结果为真实分类结果的比率。F1 系数是模型测试结果精确率与召回率的调和平均，平衡了二者之间的优劣性。top-1 准确率、top-5 准确率为计算机视觉分类任务常用的评价标准，top-1 准确率指所有图片识别出的概率最大的分类结果与真实类别相符的比率，top-5 准确率指所有图片识别出的概率值排名前五

2020年4月

的分类结果中包含真实类别的比率。Kappa 系数是基于混淆矩阵计算的精度评价指标，主要用于结果的一致性检验。

2.3 实验结果

使用训练后的 ResNet50 模型（预训练）对测试集进行测试，测得的每一类水稻病虫害的精确率、召回率与 F1 系数如表 2 所示。从表 2 可以看出，该模型对稻飞虱、稻瘿蚊、稻水象甲、稻纵卷叶螟、稻瘟病、稻曲病识别效果较好。主要是由于这 6 种病虫害在数据集中数量相对较多，所以其识别精度较高。

表 2 水稻病虫害识别模型精确率、召回率及 F1 系数

Table 2 Precision, recall and F1 coefficient of rice diseases and insect pests identification model

评价指标	精确率 (%)	召回率 (%)	F1 (%)	评价指标	精确率 (%)	召回率 (%)	F1 (%)
大螟	57.69	71.43	63.83	稻潜叶蝇	64.00	55.17	59.26
二化螟	66.67	80.00	72.73	稻水象甲	85.57	92.47	88.89
三化螟	77.61	69.33	73.24	稻纵卷叶螟	92.57	89.25	90.88
稻飞虱	90.33	87.12	88.70	稻瘟病	99.31	98.12	98.71
稻秆蝇	36.84	58.33	45.16	白叶枯	78.43	80.00	79.21
稻瘿蚊	89.53	91.67	90.59	纹枯病	58.54	68.57	63.16
稻叶蝉	68.18	74.07	71.01	稻曲病	99.92	99.63	99.77
禾蓊马	78.26	94.74	85.71	正常水稻	97.47	98.09	97.78
稻苞虫	39.13	90.00	54.55				

对该模型测得的 top-1 准确率、top-5 准确率、Kappa 系数和 F1 系数如表 3 所示。从表 3 可以看出基于迁移学习构建的水稻病虫害识别模型 top-1 准确率为 95.23%，top-5 准确率为 96.33%，Kappa 系数为 0.936 8，F1 系数为 77.83%，说明了所构建的深度模型能够准确识别水稻病虫害类型。同时为了更好地说明迁移学习在水稻病虫害识别过程中的有效性，该文基于 ResNet50（非预训练模型），采用相同的训练集和测试集进行了水稻病虫害的识别实验，并对识别结果进行精度评价，将 ResNet50 的预训练模型和非预训练模型的精度评价结果进行比较可知（表 3），基于迁移学习的 ResNet50 预训练模型很大程度上提升了水稻病虫害的识别精度，其中 top-1 准确率提升了 24.51%，top-5 准确率提升了 22.02%，Kappa 系数提升了 0.349 2，F1 系数提升了 56.66%。

表 3 水稻病虫害识别模型精度评价

Table 3 Evaluation metrics of rice diseases and insect pests identification model

ResNet50 模型	top-1 准确率 (%)	top-5 准确率 (%)	Kappa 系数	F1 系数 (%)
预训练模型	95.23	96.33	0.936 8	77.83
非预训练模型	70.72	74.31	0.587 6	21.17
差值	24.51	22.02	0.349 2	56.66

此外，为了排除非水稻图片内容对识别结果产生影响，该文基于 ResNet50 模型构建了非水稻过滤模型，用于在具体应用过程中过滤人像、汽车等其他干扰图片。基于非水

稻病虫害过滤数据集的测试验证，该模型的 top-1 准确率为 99.60%，说明该过滤模型能够很好地完成非水稻病虫害图片的过滤任务。

2.4 模型应用

在实际应用中，将该文构建的过滤模型和水稻病虫害识别模型进行结合，形成最终的水稻病虫害识别系统（图 4）。水稻病虫害识别具体流程为：将待识别图片输入到过滤模型中进行二分类，如果过滤模型判断图片结果为人像、汽车等其他干扰图片，则直接输出为非水稻病虫害结果，否则就将该图片输入到水稻病虫害识别模型，识别该图片的水稻病虫害类别，并输出为相应病虫害类别的识别结果。通过这两个模型的联合应用，可以有效避免其他图片被错分为某一类水稻病虫害类别而导致实际应用过程中模型效果差的问题。




图 4 水稻病虫害识别系统
Fig.4 Rice diseases and insect pests identification system

3 结论

该文针对 16 种常见水稻病虫害，通过实地采集和网络搜集的方式获取了 20 372 张水稻病虫害图片，2 903 张正常水稻图片，以此构建了水稻病虫害深度学习数据集。然后运用迁移学习的思想，采用 ResNet50 的预训练模型，构建了一个有效的水稻病虫害识别模型，并对比验证了迁移学习对于深度学习分类模型的提升效果。与已有的相关研究工作相比，该文不但丰富了水稻病虫害数据的数量和种类，构建了完整的水稻病虫害数据集，而且基于迁移学习的思想，缓解了深度模型对于大数据集的需求。除此之外，根据实际应用过程中的需求，该文首先加入正常水稻图片，解决目前研究中未考虑正常水稻的分类问题；然后基于 ResNet50 模型和非水稻病虫害过滤数据集训练了一个二分类过滤模型，成功避免了不合理的识别结果。

深度学习在病虫害识别任务中取得了不错的效果，但同时仍存在以下挑战：（1）更适合水稻病虫害识别任务的网络结构尚待研究；（2）有效的模型仍然依赖大量的数据，该文采用迁移学习的思路缓减了这个问题，但用少量数据获取最优参数的方法仍值得进一步研究。

2020年4月

参考文献

- [1] 袁媛, 陈雷, 吴娜, 等. 水稻纹枯病图像识别处理方法研究. 农机化研究, 2016, 38(6): 84–87, 92.
- [2] Oliva A, Torralba A. Modeling the shape of the scene: a holistic representation of the spatial envelope. *International Journal of Computer Vision*, 2001, 42(3): 145–175.
- [3] David G L. Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 2004, 60(2): 91–110.
- [4] Herbert B, Tinne T, Luc V G. SURF: speeded up robust features. *European Conference on Computer Vision, Graz, Austria*, 2006: 404–417.
- [5] Corinna C, Vladimir V. Support-vector networks. *Machine Learning*, 1995, 20(3): 273–297.
- [6] Cover T M, Hart P E. Nearest neighbor pattern classification. *IEEE Transaction on Information Theory*, 1967, 13(1): 21–27.
- [7] Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 2012, 25(2): 1097–1105.
- [8] Deng J, Dong W, Richard S, et al. ImageNet: a large-scale hierarchical image database. *2009 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2009: 248–255.
- [9] Christian S, Liu W, Jia Y Q, et al. Going deeper with convolutions. *IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 1–9.
- [10] Karen S, Andrew Z. Very deep convolutional networks for large-scale image recognition. *International Conference on Learning Representations*, 2015.
- [11] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 770–778.
- [12] Liu Z Y, Gao J F, Yang G G, et al. Localization and classification of paddy field pests using a saliency map and deep convolutional neural network. *Scientific reports*, 2016, 6(1): 1–12.
- [13] Lu Y, Yi S J, Zeng N Y, et al. Identification of rice diseases using deep convolutional neural networks. *Neurocomputing*, 2017, 267(1): 378–384.
- [14] Liang W J, Zhang H, Zhang G F, et al. Rice blast disease recognition using a deep convolutional neural network. *Scientific reports*, 2019, 9(1): 1–10.
- [15] Wu X P, Zhan C, Lai Y K, et al. Ip102: a large-scale benchmark dataset for insect pest recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2019: 8787–8796.
- [16] 庄福振, 罗平, 何清, 等. 迁移学习研究进展. 软件学报, 2015, 26(1): 26–39.
- [17] Adam P, Sam G, Francisco M, et al. PyTorch: an imperative style, high-performance deep learning library. *Advances in Neural Information Processing Systems*, 2019: 8024–8035.

Identification of rice diseases and insect pests using transfer learning

Fan Chunquan, He Binbin*

(University of Electronic Science and Technology of China, Sichuan Chengdu 611731, China)

Abstract: [Purpose] Rice diseases and insect pests are important factors causing rice yield losses. Accurate recognition of rice diseases and insect pests facilitates timely preventive measures to avoid economic losses. However, the existing identification technologies mainly focus on common objects. It is seldom used in agriculture, especially in rice diseases and insect pests identification. The existing researches on rice diseases and insect pest identification have problems of small data volume and insufficient data types. [Method] In this paper, 20 372 pictures of rice insect pests and diseases were collected to build a complete dataset for rice diseases and insect pests identification. Based on transfer learning, a deep recognition model for 16 major rice



diseases and insect pests was built on ResNet50 pre-training model. In addition, for practical application, with 9 928 other pictures (including portraits, cars, etc.) and 9 675 pictures of rice diseases and insect pests, this paper constructed a binary filtering model based on ResNet50 pre-training model to avoid the pictures of others from being misclassified into a certain type of rice diseases and insect pests. **[Result]** The top-1 accuracy of the rice diseases and insect pests classification model achieves 95.23%, the top-5 accuracy achieves 96.33%, the kappa coefficient is 0.936 8 and the F1 coefficient is 77.83%. Compared with the non-pre-training model, the accuracy of top-1 increased by 24.51%, the top-5 accuracy increased by 22.02%, the kappa coefficient increased 0.349 2 and the F1 coefficient increased by 56.66%. It shows that transfer learning does contribute to the outstanding performance of the rice diseases and insect pests identification. And the filtering model's top-1 accuracy is 99.60%. **[Conclusion]** 20 372 pictures of rice diseases and insect pests were collected to build a complete dataset through field and network, including 16 common rice diseases and insect pests. The rice diseases and insect pests identification model based on transfer learning makes the identification of rice diseases and insect pests more accurate. In addition, the filtering model effectively solves the problem of non-rice pictures being misclassified into a certain type of rice diseases and insect pests.

Key words: identification of rice diseases and insect pests; deep learning; transfer learning; PyTorch; ResNet