

基于 ResNet-50 深度卷积网络的果树病害 智能诊断模型研究

金 瑛¹, 叶 飒^{2*}, 李洪磊¹

(1. 辽宁师范大学 大数据与商务智能实验室, 大连 116029; 2 中国农业科学院 农业信息研究所, 北京 100081)

摘 要: [目的 / 意义]果树病害危及农业生产安全, 运用人工智能技术帮助果农及时准确地识别果树病害对保障农业安全生产具有重要意义。[方法 / 过程]采用 10 000 张果树叶片病斑图像数据集, 通过旋转、污化、增噪、切割等图像增强手段, 提高样本图像的多样性; 使用 ResNet-50 深度卷积网络模型, 进行机器学习, 获得果树病害识别模型, 并基于此模型开发了应用软件提供在线诊断服务。[结果 / 结论]实验结果表明: 该模型对 4 种果树病害的平均识别率达到 92.9%, 和相关研究成果相比具有较好的诊断效果。

关键词: ResNet-50; 图像识别; 果树疾病; 智能诊断

中图分类号: G249.2

文献标识码: A

文章编号: 1002-1248 (2021) 04-0058-10

引用本文: 金瑛, 叶飒, 李洪磊. 基于 ResNet-50 深度卷积网络的果树病害智能诊断模型研究[J]. 农业图书情报学报, 2021, 33 (4): 58-67.

The Intelligent Diagnosis Model of Fruit Tree Disease Based on ResNet-50

JIN Ying¹, YE Sa^{2*}, LI Honglei¹

(1. School of Government Management, Liaoning Normal University, Dalian 116029;

2. Institute of Agricultural Information, Chinese Academy of Agricultural Sciences, Beijing 100081)

Abstract: [Purpose/Significance] Fruit tree diseases endanger the safety of agricultural production, and the use of artificial intelligence technologies to help fruit growers identify fruit tree diseases in a timely and accurate manner is of great significance to ensure safe agricultural production. [Method/Process] Using 10 000 fruit tree leaf diseased spots image

收稿日期: 2020-07-28

基金项目: 中国工程科技知识中心建设项目“农业专业知识服务系统”(CKCEST-2020-1-20)

作者简介: 金瑛 (ORCID: 0000-0001-7973-3693), 女, 硕士研究生, 辽宁师范大学管理科学与工程, 研究方向为系统建模与优化。李洪磊 (ORCID: 0000-0002-7080-873X), 男, 博士, 特聘教授, 硕士研究生导师, 辽宁师范大学, 研究方向为系统建模与仿真、智能信息处理

*通信作者: 叶飒 (ORCID: 0000-0002-1339-9060), 女, 馆员, 中国农业科学院农业信息研究所, 研究方向为数值分析与数据挖掘。Email: yesa@caas.cn

data sets, through image enhancement methods such as rotation, pollution, noise enhancement, and cutting to improve the diversity of sample images; using the ResNet-50 deep convolutional network model to perform machine learning to obtain the fruit tree diseases identification model, and develop application software based on this model to provide on-line diagnostic services. [Results/Conclusions] The experimental results show that the average recognition rate of the four fruit tree diseases reached 92.9%, which has a better diagnostic effect compared with related research results.

Keywords: ResNet-50; image recognition; fruit tree disease; intelligent diagnosis

1 引 言

果树病害因受到全球气候和环境条件变化呈现出爆发式上升趋势。由于病害的传播速度取决于环境条件和植物的易感染性,果树在生长周期中容易受到多种疾病的入侵。在实际的果树病害检测识别中,种植户通常依赖于人眼观察和靠经验诊断,这种方法不仅耗时、主观性强、而且误判率高。因此能够使用高科技手段,在复杂的农业生态环境中及时准确的诊断果树所患疾病具有积极意义。

互联网的普及应用,以及与机器学习技术的结合,为果树病害的远程诊断提供了有力支撑。相关研究表明,利用机器学习,特别是深度学习技术自动识别果树病害图像是可行的。如祁钊等提出了主成分分析和支持向量机组合的方法识别室外玉米叶部病害的图像,并用 Retinex 算法,对图像进行了增强,总识别精度达到 90.74%^[1]。刘浩洲等使用 K-means 聚类图像分割方法,识别猕猴桃花朵,该算法成功率为 92.5%^[2]。毕傲睿提出了利用改进的中值滤波方法去除噪声,并有效的保留了边缘信息的预处理方法,采用直方图均衡化方法,对图像进行了增强,提高动态范围和比较高的对比度,将受到不同影响的图像转化为较统一的形式;使用模糊 C 均值聚类算法分割病斑图像,对图像的特征提取方法上选择 15 类特征参数,最后选用基于支持向量机的病害识别模型^[3]。屈赟等对病斑图像分割时运用了最大类间方差法 (Otsu) 提取出重要的颜色、纹理和形状特征,最后利用支持向量机 (SVM) 方法分类病斑,并且建立了苹果叶部病害特征库^[4]。刘双以 Gentle AdaBoost 算法为基础,从梯度和纹理的角度更

全面地描述,筛选出最佳的特征后,将训练好的各层分类器按照一定的筛选率组合成级联检测器,快速排出背景值;最后引入 SIFT 模板匹配算法对检测出的结果进行二次筛选确定检测目标^[5]。卢柳江等应用机器学习理论,利用 Haar-like 提取的图像特征构建弱分类器,并通过 AdaBoost 算法将弱分类器集合升级为强分类器,运用级联的方法合成 AdaBoost 分类器来识别农作物虫害。根据背景的复杂程度,模型的识别率保持在 95.71%和 86.67%区间内,解决了农作物虫害的预防工作强度大、耗时长、效率低的问题^[6]。

近几年来,在农业领域中深度学习备受广大研究者的青睐,相对于传统机器学习,深度学习 (Deep Learning, DL) 可以从原始数据中自动提取特征,将较低层次的特征组合成高层次的特征^[7]。该网络的特征提取和结构化数据的显著优势,有效地推动了农业智能机械装备的开发,其相应研究成果不断涌现^[8]。黄双萍等针对水稻穗瘟病的图像检测问题,采用了深度卷积神经网络 GoogLeNet 模型,模型的最高识别准确率达到 92%^[9]。李艳等使用卷积神经网络对马铃薯疾病进行了分类,该算法成功应用于农作物病害的识别,显示了深度学习技术在农业任务中的潜力^[10]。李森等利用了 ImageNet 数据集和 PlantVillage 网络公开数据集,以黄瓜和水稻病害为研究对象开展研究,通过采用知识迁移和深度学习方法,提高了相关领域的图像识别效率^[11]。王细萍等通过引入卷积、采样算子的方法,提出时变冲量学习的苹果病变图像识别方法,正确率高达 97.45%^[12]。张建华等提出了棉花病害的识别模型,采用微型迁移的策略共享模型中的卷积层和池化层的参数,以此来优化 VGG 的结构和权值,并且用 6 标签分类器实现图像识别,总体准确率达到

89.51%^[13]。蒋丰千等通过对病害图像的二值化和轮廓分割等预处理,利用 Caffe 框架对优化后的网络模型进行了识别率等方面的实验验证,开发了大豆疾病检测系统^[14]。王梅嘉等在苹果叶部病害识别方面通过扩展对比度,去除叶面绒毛,锐化图像,去除光照影响完成预处理。利用遗传算法优化模糊 C 均值聚类,提取了 8 个参数作为有效特征。通过构建 BP、RBF、DBN 三种网络和支持向量机(SVM)实现病斑识别^[15]。邱靖等利用深度卷积网络建立 3 种水稻病害的识别模型,对数据归一化处理,并运用深度学习框架 Keras 进行深度 CNN 训练,统一用 9×9 卷积核尺寸和最大池化函数,经过一定次数的迭代,其识别准确率达到 90%以上,以较高的识别率实现了 3 种水稻分类,泛化能力较强、准确率较高、鲁棒性较好^[16]。

综合上述研究,虽然在图像识别方面广大研究者已经相应地取得了进展,但多集中于单一病种的诊断识别。部分研究是基于公共数据集训练的,数据质量可靠度不高,导致模型在实际应用中出现较大偏差。

本研究基于卷积神经网络中的 ResNet-50 模型,以梨黑斑病、梨锈病、苹果花叶病、苹果锈病这 4 种患病叶片图像为对象进行模型训练,实验数据集数量达到近 10 000 张,数据来源真实可靠,图像本身上具有全面性和完整性,以此训练的诊断模型可靠性更具说服力。随后在果树病害图像识别模型的基础上开发相应的应用软件,通过互联网提供诊断服务。

2 实验数据与实验环境

2.1 样本数据

本研究数据来源于农业专业知识服务系统的果树病害图谱库^[17]。该图谱库包含 10 000 张果树病害叶片图像,其中包括梨黑斑病、梨锈病、苹果花叶病、苹果锈病各 2 500 张,样本数据分布平衡。这 4 种果树疾病是常见多发疾病,其中梨锈病发生普遍,是梨树的重要病害类型,在发病严重时,个别梨园梨树感病品种的病叶率在 60%以上。梨锈病主要危害叶片、新梢

和幼果。叶片受害,叶正面形成橙黄色圆形病斑,并密生橙黄色针头大的小点,后期小粒点变为黑色;梨黑斑病也是梨树重要的病害,在中国主要梨区普遍发生。西洋梨、日本梨、酥梨、雪花梨最易感病,发病严重时会引起早期落叶和嫩梢枯死,致使裂果和早期落果;苹果花叶病在各地均有发生,陕西关中地区有些果园的病株率高达 30%以上,危害较严重。病叶表现 5 种症状:斑驳型、花叶型、条斑型、环斑型和镶边型,诊断有一定困难;苹果锈病近年来在一些地区发生有明显上升趋势。苹果锈病可引起落叶、落果和嫩枝折断,各苹果产区均有发生。主要为害幼叶、叶柄、新梢及幼果等幼嫩绿色组织。初期叶片正面产生橙黄色有光泽的小斑点,随后发展成直径为 0.5~1.0cm 的橙黄色圆形病斑,病斑边缘常呈红色,稍肥厚。严重时,一片叶子上可有十几个病斑。

该图谱库中的叶片图像由专业人士在果树展叶期从果园采摘,根据上述病症表现,精心挑选病斑清晰的叶片,在室内摄影棚内拍摄。背景为纯白色。色温在 5 200~5 500。每个叶片分全景、局部、正位拍摄。图片库图片分辨率高,细节清晰,达到高分辨率标准,但对于机器学习而言,场景不够多样化、自然化,会影响诊断模型的泛化能力。为了弥补这个缺陷,本文通过在线收集的方式,收集到 100 余张关于 4 种病害的网络图像,与上述图谱库相结合,进行样本数据增强。这些图像包括梨黑斑病 25 张、梨锈病 27 张、苹果花叶病 28 张、苹果锈病 24 张。图 1 为农业知识服务系统图谱库样例,图 2 是线上收集的公共图像数据集,并经过专业人士鉴别后用于数据增强。

上述数据集按 8:2 比例分割为训练集、验证集。网络收集的数据做测试集。其中训练集用于模型训练,验证集用于模型参数调优,测试集用于测试模型的泛化能力。为了降低数据规模,加快模型训练过程,在本研究中所有图像被统一压缩至 640×480 尺寸。

2.2 数据增强

鉴于本研究获取的图像均为采摘后在纯净环境中拍摄,背景不够丰富,图像过于精美和标准,色彩、

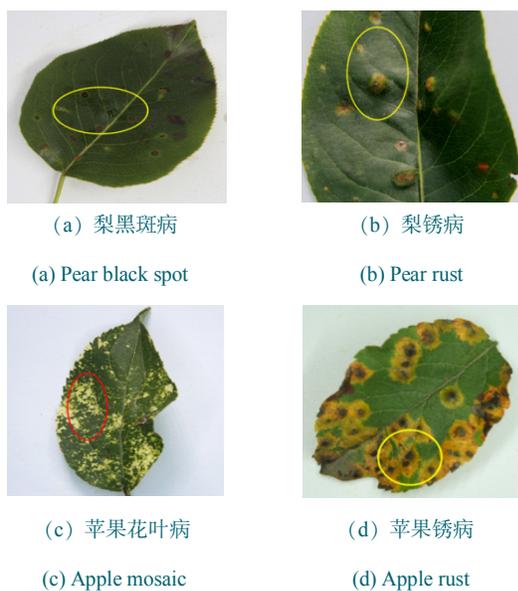


图 1 样本数据图像 (农业知识服务系统图谱库)

Fig.1 Image samples(Agricultural Knowledge Service System Image Library)



图 2 果树病害公共图像 (源于网络)

Fig.2 Public images of fruit tree diseases (from the Internet)

亮度多样性差, 将会对模型的泛化能力产生很大影响^[18,19]。因此本研究对上述样本数据进行了数据增强处理, 提高图像样本数据的多样性水平, 从而在一定程度上保证了模型的泛化能力。这些处理包括如下方式。

(1) 旋转方向。即通过旋转和位移等方式提高病变叶子的图像相对位置的多态性, 该多态性采用与标准图像的夹角或矢量位移的描述。本研究每隔 30 度进

行一次旋转采样, 即 1 张原始图片会产生 12 张旋转后的图片。

(2) 颜色抖动^[20]。由于不同空间相对位置和日照条件不同, 同一对象会采集得到不同亮度、饱和度、对比度等模式, 在颜色平衡区间上呈现出不同图像的复杂性, 提升算法的鲁棒性。本研究对每张图片进行 3 次颜色抖动的随机处理。

(3) 随机切割。在保留足够病害叶子主要信息的情况下, 对图片进行裁剪, 减少部分背景信息, 从而增加形态上的多样性, 提高模型的泛化能力。本研究对每张图片进行 3 次切割处理。

(4) 污化处理。对多所采集的图像进行随机污化, 以防训练中出现过拟合的现象, 降低模型的泛化能力。本文对污化处理添加了随机污化、1:1 污化和不放回污化。本研究对每张图片各进行 3 次污化处理。

(5) 增噪处理。由于深度神经网络模型是高度非线性的, 图像的一个像素微调可影响对抗样本, 因此本研究引入了随机白噪声来模拟拍摄不同清晰度的样本数据。本研究对每张图片进行 1 次随机增噪处理。

(6) 背景叠加。将果树叶片与其生长背景进行叠加, 丰富图片的背景信息。本研究对每张原始图片进行 1 次背景叠加。

2.3 实验环境

本研究在大型计算机服务器上进行。该服务器 8 核 CPU, 内存 128G, 运行 Linux 操作系统。在 Python3.6 的环境下, 安装了 TensorFlow^[21]、Keras 深度学习软件包和 OpenCV 图像处理软件包。

TensorFlow 是谷歌公司推出的基于数据流编程 (Dataflow Programming) 的符号数学系统, 被广泛应用于各类机器学习 (Machine Learning) 算法的编程实现, 其前身是谷歌的神经网络算法库 DistBelief。TensorFlow 拥有多层次结构, 可部署于各类服务器、PC 终端和网页并支持 GPU 和 TPU 高性能数值计算。TensorFlow 的 Python 版本支持 Linux、Windows、macOS 操作系统。TensorFlow 提供 Python 语言下的 4 个不同版本: CPU 版本 (Tensorflow)、包含 GPU 加速的版本

(Tensorflow-Gpu), 以及它们的每日编译版本 (Tf-Nightly、Tf-Nightly-Gpu)。安装 Python 版 TensorFlow 可以使用模块管理工具 Pip/Pip3 或 Anaconda 并在终端直接运行。

OpenCV 是一个基于 BSD 许可 (开源) 发行的跨平台计算机视觉和机器学习软件库, 主要倾向于实时视觉应用。OpenCV 可以运行在 Linux、Windows、Android 和 Mac OS 操作系统上。OpenCV 由一系列 C 函数和少量 C++ 类构成, 同时提供了 Python、Ruby、MATLAB 等语言的接口, 实现了图像处理和计算机视觉方面的很多通用算法。OpenCV 具有轻量级、高效率、便于应用的优点, 因而深得图像处理专业人士青睐。

在图像和视觉智能处理领域, TensorFlow 与 OpenCV 组合使用非常流行。本研究将 TensorFlow 用于诊断模型训练, 而 OpenCV 用于实现图像样本的数据增强处理以及其他预处理操作。

3 模型训练

3.1 ResNet 简介

传统的深度学习算法一般采用数据初始化 (Normalized Initialization) 和正则化 (Intermediate Normalization)^[22]来解决计算资源消耗高、模型容易过拟合和梯度消失/梯度爆炸问题。这种方法虽然在一定程度上解决了梯度问题, 但是后续又出现了网络退化等现象, 于是 HE 等提出了一种残差学习框架 ResNet^[23]。随着网络深度的增加, 使用 ResNet 有助于模型预测性能的显著提高, 同时模型训练时间没有明显增加, 因此 ResNet 成为目前应用最为广泛的卷积神经网络。

ResNet 通常设置 18、34、50、101 等多种层数选择, 考虑到实验环境和数据规模, 本研究选择 50 层的 ResNet。

ResNet-50 包括一个跨层连接, 如图 3 所示^[24]。该跨层连接通过快捷连接 Shortcut 跨层传递输入信息, 然后将其添加到卷积输出中以完全训练底层网络, 相当于直接执行了恒等映射。在恒等映射函数中, 假设

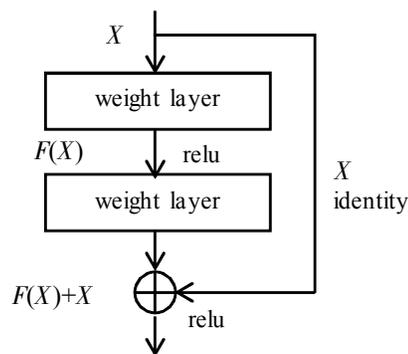


图 3 残差网络示意图

Fig.3 Diagram of a residual network

残差网络的最优结果输出为 $H(X)$, 经过卷积操作后的输出 $F(X)$, 由于 $F(X)=H(X)-X$, 因此最优结果为 $H(X)=F(X)+X$ 。假设残差映射比原映射更易优化, 那么在极端情况下就很容易将残差推至 0, 即 $F(X)=0$, 这就变成了恒等映射函数 $H(X)=X$, 这比将映射逼近另一个映射要简单得多, 可以从时间、效果等多方面满足要求。因此 ResNet 在训练中额外的参数和计算复杂度不会因此而增加, 模型相当于退化为一个浅层网络, 从而随着深度的增加而大大提高了准确性, 不用过多地担心网络的“退化”问题。只要训练数据足够, 逐步加深网络, 就可以获得更好的性能表现。换言之, ResNet 可以在网络深度增加时, 预测偏差减小 (准确度上升), 而方差也不会显著增加 (泛化能力不受影响)。方差与偏差同时被优化, 这在机器学习算法中极为难得。

3.2 四分类函数

为了高效准确的识别常见果树病害的图像, 本研究将分类器改进为 4 目标 Softmax 分类器。Softmax 分类器是把一种目标变量分成多个种类的算法, 可以接受全连接层输入的特征矩阵, 输出输入目标对应的每个种类的不同概率值。例如, 有 N 个输入目标 $\{x_i \cdot y_i\}_{i=1}^k$, 每个目标的标记 $y_i \in \{1, 2, 3, \dots\}$, k 为模型输出类别的种类数 ($k \geq 2$)。本文做梨黑斑病、梨锈病、苹果花叶病、苹果锈病的四分类器, k 值取值为 4。对于给定的输入 x_i , 用假设函数 $f_\theta(x_i)$ 估计对应类别概率 j 值 $P(y_i=j|x_i)$ 。则函数为

$$f_{\theta}(x_i) = \begin{bmatrix} P(y_i = 1 | x_i; \theta) \\ P(y_i = 2 | x_i; \theta) \\ P(y_i = 3 | x_i; \theta) \\ P(y_i = 4 | x_i; \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T x_i}} \begin{bmatrix} e^{\theta_1^T x_i} \\ e^{\theta_2^T x_i} \\ e^{\theta_3^T x_i} \\ e^{\theta_4^T x_i} \end{bmatrix} \quad (1)$$

θ 是 Softmax 分类器的参数, 为保证概率和为 1, 使用

$$\frac{1}{\sum_{j=1}^k e^{\theta_j^T x_i}} \quad (2)$$

进行归一化, Softmax 分类器的损失函数为

$$J(x, y, \theta) = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^k 1_{\{y_i = j\}} \left[\log_2 \left(\frac{e^{\theta_j^T x_i}}{\sum_{j=1}^k e^{\theta_j^T x_i}} \right) \right] \quad (3)$$

其中 $1_{\{y_i = j\}}$ 为指示性函数, 其取值与括号内的真值保持一致, 即 $y_i = j$ 成立时函数值为 1, 否则为 0。

3.3 参数设计

本研究经过多次试验对比后, 对模型的参数设置如下表所示。模型优化器为 Adam。Adam 优化算法采用框架默认参数, 其所占内存少, 计算效率高, 适用于非稳态目标等诸多优势, 由于本研究对象果树病害样本数据规模大, 非常适合本研究对象果树病害样本的大规模图像数据^[25]。

表 1 模型参数设计表

Table 1 Model parameters

训练参数	参数值	说明
Conv number	50	网络层数
Batch size	64	样本批量
Epochs	100	训练次数
Learning rate	0.001	学习率

4 实验结果及分析

4.1 查准率

查准率 (Precision) 指的是预测为正例的集合中真正例的比例, 其定义如下:

$$P = \frac{TP}{TP + FP} \quad (4)$$

公式 (4) 中 TP (True Positive) 指模型识别出的正类数量、 TN (True Negative) 指模型识别出的负类数量、 FP (False Positive) 指模型误报的数量, 即将负类图像预测为正类的数量、 FN (False Negative) 指模型的漏报数量, 即未识别出的正类数量。

4.2 查全率

查全率 (Recall Ratio), 也叫召回率, 是预测结果中真正例与实际所有整理的比值。

$$R = \frac{TP}{TP + FN} \quad (5)$$

4.3 F-Score

在实际应用中, 查准率和查全率会出现悖反现象, 即此消彼长。 F -Score 是查准率与查全率的加权调和平均, 在评价模型预测性能时综合性更强。

$$F = \frac{(\alpha^2 + 1)P \times R}{\alpha^2(P + R)} \quad (6)$$

应用实践中, 常设置 $\alpha=1$, 即 $F1$ 指标。

$$F1 = \frac{2 \times P \times R}{P + R} \quad (7)$$

4.4 Accuracy

模型精度 (ACC) 是分类正确的样本数占总样本数的比例, 可从总体上反应一个模型的预测能力, 其定义如下:

$$ACC = \frac{TP + TN}{TP + FP + TN + FN} \quad (8)$$

4.5 实验结果分析

从实验数据集中抽取 80% 的数据作为训练集, 20% 数据作为验证集, 经过迭代后训练效果如图 4 所示。横轴为训练周期 (Epochs), 纵轴为误差 / 精度 (Loss/Acc)。由图 4 可知, 随着迭代次数越多, 模型的精度越来越高, 误差越来越低, 大约在第 22 代训练周

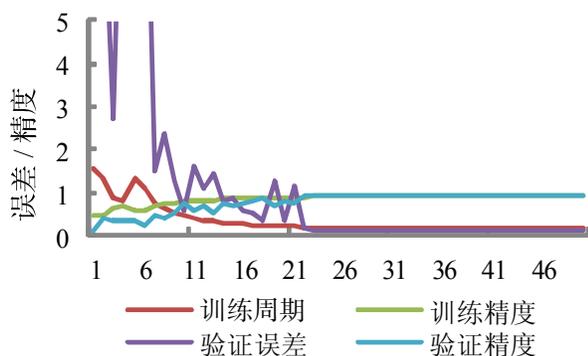


图4 模型收敛过程

Fig.4 Model convergence process

期后趋于平稳，误差逐渐趋向于0，而精度逐渐趋向于1。训练集和验证集的两项指标近似重合，说明模型的偏差、方差和精度均收敛于理想水平。

表2 混淆矩阵

Table 2 Confusion matrix

真值/ 预测值	梨黑斑	梨锈病	苹果花叶病	苹果锈病	合计
梨黑斑	504	12	9	0	525
梨锈病	96	444	12	3	555
苹果花叶病	1	6	449	0	456
苹果锈病	1	0	1	436	438
合计	602	462	471	439	

在表2的混淆矩阵中，行表示预测类别，列表示真实类别。从混淆矩阵中可以看出，基于当前的样本集合，梨锈病和梨黑斑病表征有一定的相似性，在梨黑斑识别过程中容易误判为梨锈病。

表3显示模型的性能指标。苹果花叶病和苹果锈病的识别准确度较高，而梨锈病与梨黑斑的识别性能稍微逊色，模型的总体精度ACC为92.9%。

表3 模型评价指标 (数据增强)

Table 3 Model evaluation metrics (data augmentation)

疾病名称	精确度/%	召回率/%	F1 Score/%
梨黑斑病	83.17	96.00	89.12
梨锈病	93.67	80.00	86.30
苹果花叶病	98.25	98.46	98.36
苹果锈病	99.77	99.54	99.66

而对于未经图片增强的原始数据集，本研究使用

相同的参数进行 ResNet-50 模型训练，结果发现模型的精确度、召回率、和 F1 Score 显著下降。如表4所示。

表4 模型评价指标 (原始数据)

Tab. 4 Model evaluation metrics (raw data)

疾病名称	精确度/%	召回率/%	F1 Score/%
梨黑斑病	81.25	91.50	86.07
梨锈病	90.16	82.50	86.16
苹果花叶病	93.32	95.75	94.52
苹果锈病	94.15	95.26	94.70

5 果树病害图像识别系统开发

该软件系统基于上述 ResNet-50 模型，使用 Java 和 Python 语言开发，采用 B/S 系统构架。系统技术结构如图5所示。

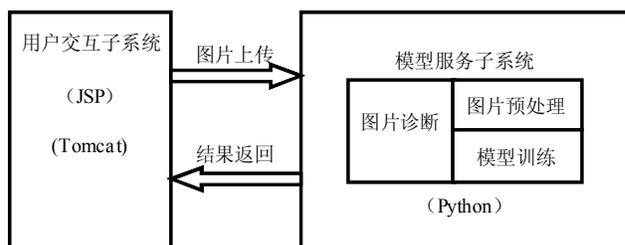


图5 果树病害识别系统技术结构图

Fig.5 Technical structure diagram of fruit tree disease recognition system

用户交互子系统使用 Java 开发，其主要功能为建立用户与系统的交互界面。使用该子系统，用户可以上传需要诊断的图片，并获得诊断结果。模型服务子系统则提供样本图片处理、模型训练和模型应用服务(图片诊断)。该系统采用复合技术构架是为了充分发挥 Java 与 Python 在网络计算和模型运算方面的各自优势，同时较好地实现了运算负载的均衡。

该系统的两个子系统可以共用 1 台硬件服务器，也可以分别安装到不同的服务器，两个子系统通过 http 协议进行数据通信。

模型服务子系统还动态存储了用户上传的图片，这样模型训练模块就可以根据系统在使用过程中图片数据的积累对模型进行重新训练，使模型得到持续完

善, 诊断性能获得不断提升。系统的工作流程如图 6 所示。

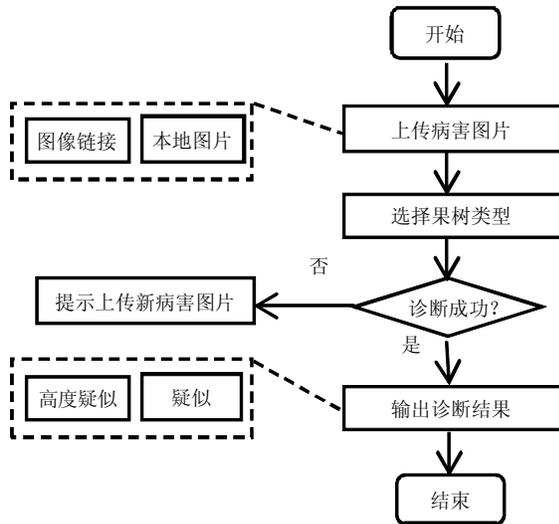


图 6 果树病害识别系统流程图

Fig.6 Flow chart of the fruit tree disease recognition system

用户采集到病害图像后, 可通过上传本地图片或指定图片地址, 模型即可获得输入的图片, 之后再行预测。ResNet-50 模型使用了 Softmax 函数, 输出 4 种分类的概率。本文选择其中最大概率分类作为诊断结果。诊断结果根据不同概率水平分为高度疑似 (大于 0.75)、疑似 (大于 0.3) 和不确定 3 种水平, 为用户判断提供参考价值。系统工作界面如图 7 所示。



图 7 果树病害智能诊断系统界面

Fig.7 The interface of the intelligent diagnosis system for fruit tree diseases

6 结 语

本研究使用 ResNet-50 训练了病害智能诊断模型, 为果树病害图像识别提供了一种可操作可借鉴的试验经验。鉴于样本图像拍摄场景单一、色彩、清晰度、亮度趋同、多样性差的特点, 该研究采用数据增强技术对样本图像进行了预处理, 提高了样本数据的多样化水平。实验证明, 该做法显著提高了模型的预测性能。基于上述诊断模型, 开发了果树病害智能诊断系统, 在线提供果树病害诊断服务。

实验还发现, 受图像数据集样本多样性不足的影响, 该模型的泛化能力还需进一步提高。通过搜集到的互联网公共图像测试, 该模型的整体精度下降到 85.2% 水平。这说明尽管本研究对样本进行了数据增强操作, 但样本的多样性水平仍然没有达到理想水平, 这需要在今后的研究中进一步丰富样本多样性, 同时在模型训练中, 进一步优化参数设置, 从数据优化和模型优化两个方向出发, 努力提高诊断模型的预测精度。

参考文献:

- [1] 祁钊, 江朝晖, 杨春合, 等. 基于图像技术的玉米叶部病害识别研究[J]. 安徽农业大学学报, 2016, 43(2):167-172.
QI Z, JIANG Z H, YANG C H, et al. Identification of maize leaf diseases based on image technology[J]. Journal of Anhui agricultural university, 2016, 43(2): 167-172.
- [2] 刘浩洲, 陈礼鹏, 穆龙涛, 等. 基于 K-means 聚类的猕猴桃花朵识别方法[J]. 农机化研究, 2020, 42(2): 22-26.
LIU H Z, CHEN L P, MU L T, et al. A recognition method of kiwifruit flowers based on K-means clustering [J]. Journal of agricultural mechanization research, 2020, 42(2): 22-26.
- [3] 毕傲睿. 苹果叶子病害图像识别系统的设计与实现[D]. 西安: 西安建筑科技大学, 2014.
BI A R. Design and implementation of apple-leaf disease image recognition system [D]. Xi'an: Xi'an university of architecture and technology, 2014.
- [4] 屈赞, 陶晔, 王政嘉, 等. 基于 Android 的苹果叶部病害识别系统

- 设计[J]. 河北农业大学学报, 2015, 38(6): 102-106.
- QU Y, TAO B, WANG Z J, et al. Design of apple leaf disease recognition system based on Android[J]. Journal of Hebei agricultural university, 2015, 38(6): 102-106.
- [5] 刘双. 基于数字图像的农业害虫精准检测算法的研究——以菜蚜检测为例[D]. 雅安: 四川农业大学, 2014.
- LIU S. Study on exact pest detection algorithm based on digital image - Illustrated by the case of Eurydema dominulus. Yaan: Sichuan agricultural university, 2014.
- [6] 卢柳江, 匡迎春, 陈兰鑫, 等. 基于级联 AdaBoost 分类器的农作物虫害图像识别研究[J]. 中国农机化学报, 2019, 40(8): 127-131.
- LU L J, KUANG Y C, CHEN L X, et al. Research on pest recognition based on cascaded AdaBoost classifier[J]. Journal of Chinese agricultural mechanization, 2019, 40(8): 127-131.
- [7] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [8] 吕盛坪, 李灯辉, 冼荣亨. 深度学习在我国农业中的应用研究现状[J]. 计算机工程与应用, 2019, 55(20): 24-33, 51.
- LV S P, LI D H, XIAN R H. Research Status of Deep Learning in Agriculture of China [J]. Computer engineering and applications, 2019, 55(20): 24-33, 51.
- [9] 黄双萍, 孙超, 齐龙, 等. 基于深度卷积神经网络的水稻穗瘟病检测方法[J]. 农业工程学报, 2017, 33(20):169-176.
- HUANG S P, SUN C, QI L, et al. Rice panicle blast identification method based on deep convolution neural network[J]. Transactions of the Chinese society of agricultural engineering, 2017, 33(20): 169-176.
- [10] 李艳. 基于改进 CNN 的马铃薯病害识别算法[J]. 信息通信, 2017, 6: 46-48.
- LI Y. Potato disease recognition algorithm based on improved CNN[J]. Information & communications, 2017, 6: 46-48.
- [11] 李森, 王敬贤, 李华龙, 等. 基于 CNN 和迁移学习的农作物病害识别方法研究[J]. 智慧农业, 2019, 1(3): 46-55.
- LI M, WANG J X, LI H L, et al. Method for identifying crop disease based on CNN and transfer learning[J]. Smart agriculture, 2019, 1(3): 46-55.
- [12] 王细萍, 黄婷, 谭文学, 等. 基于卷积网络的苹果病变图像识别方法[J]. 计算机工程, 2015, 41(12): 293-298.
- WANG X P, HUANG T, TAN W X, et al. Apple lesion image recognition method based on convolutional network [J]. Computer engineering, 2015, 41(12): 293-298.
- [13] 张建华, 孔繁涛, 吴建寨, 等. 基于改进 VGG 卷积神经网络的棉花病害识别模型[J]. 中国农业大学学报, 2018, 23(11): 167-177.
- ZHANG J H, KONG F T, WU J Z, et al. Cotton disease identification model based on improved VGG convolution neural network[J]. Journal of China agricultural university, 2018, 23(11): 167-177.
- [14] 蒋丰千, 李旸, 余大为, 等. 基于 Caffe 卷积神经网络的大豆病害检测系统[J]. 浙江农业学报, 2019, 31(7): 1177-1183.
- JIANG F Q, LI Y, YU D W, et al. Soybean disease detection system based on convolutional neural network under Caffe framework[J]. Acta agriculturae Zhejiangensis, 2019, 31(7): 1177-1183.
- [15] 王梅嘉, 何东健, 任嘉琛. 基于 Android 平台的苹果叶病害远程识别系统[J]. 计算机工程与设计, 2015, 36(9): 2585-2590.
- WANG M J, HE D J, REN J C. Remote recognition of apple leaf disease based on Android platform[J]. Computer engineering and design, 2015, 36(9): 2585-2590.
- [16] 邱靖, 刘继荣, 曹志勇, 等. 基于卷积神经网络的水稻病害图像识别研究[J]. 云南农业大学学报(自然科学), 2019, 34(5): 884-888.
- QIU J, LIU J R, CAO Z Y, et al. Rice disease image recognition research based on convolutional neural network[J]. Journal of Yunnan agricultural university (natural science), 2019, 34(5): 884-888.
- [17] 中国工程科技知识中心. 农业专业知识服务系统作物病虫害图谱库[EB/OL].[2020-05-21]. <http://agri.ckcest.cn/specialtyresources/list29-1.html>.
- CKCEST. Image database of crop disease of agricultural knowledge service system[EB/OL]. [2020-05-21]. <http://agri.ckcest.cn/specialtyresources/list29-1.html>.
- [18] BRUZZONE L, SERPICO S B. Classification of imbalanced remote-sensing data by neural networks [J]. Pattern recognition letters, 1997, 18(11): 323-328.
- [19] FRANCISCO J P, ANTONIO J R, FRANCISCO C, et al. On the impact of imbalanced data in convolutional neural networks performance[C]. International conference on hybrid artificial intelligence systems, Springer, Cham, 2017: 220-232.

- [20] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C]//International conference on neural information processing systems. Curran associates Inc. 2012: 1097–1105.
- [21] Google brain. TensorFlow: A system for large-scale machine learning[C]. International conference on learning representations, 2016: 1–18.
- [22] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [EB/OL].[2018–12–29]. <https://arxiv.org/abs/1502.03167>.
- [23] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. In proceedings of the IEEE conference on computer vision and pattern recognition, 2016: 770–778.
- [24] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]. 2017 IEEE Conference on computer vision and pattern recognition (CVPR). USA: IEEE, 2017: 6517–6525.
- [25] 杨观赐, 杨静, 李少波, 等. 基于 Dropout 与 ADAM 优化器的改进 CNN 算法[J]. 华中科技大学学报(自然科学版), 2018, 46(7):122–127.
- YANG G, YANG J, LI S B, et al. Improved CNN algorithm based on dropout and ADAM optimizer[J]. Journal of Huazhong university of science and technology (Natural science edition), 2018, 46(7): 122–127.