

基于全局特征提取的农作物病害识别模型

郭小燕 于帅卿 沈航驰 李 龙 杜佳举
(甘肃农业大学信息科学技术学院, 兰州 730070)

摘要: 针对现阶段特征提取网络当测试样本出现歪斜、模糊、缺损等变化时识别效果不够理想,利用训练样本扩充、变换、缩放等方式改善网络性能并不能动态地满足实际的复杂病害图像识别任务的问题,在 ResNet50 中引入双层注意力机制与通道特征提取机制,设计基于全局特征提取的深度学习网络(Global feature deep learning network, GFDL-Net),该网络包括通道特征提取子网络(Squeeze and excitation net, SE-Net)和双注意力特征提取子网络(Double feature extraction net, DFE-Net),分别从通道空间特征提取与平面关键点特征提取两方面改善了网络的全局特征提取能力。为了验证 GFDL-Net 的有效性,对辣椒、马铃薯、番茄等 15 种病害图像加入不同角度的旋转、色彩变换等测试,发现在样本加入旋转后与 ResNet50、BoTNet、EfficientNet 相比,平均识别准确率分别高出 20.05%、18.62%、21.97 个百分点;加入明暗度、饱和度、对比度变换后与 ResNet50、BoTNet、EfficientNet 相比,平均识别准确率分别高出 3.57%、0.53%、3.98 个百分点,而识别速度分别为 ResNet50、BoTNet、EfficientNet 的 4.4、4.9、2.0 倍。试验证明 GFDL-Net 在图像全局特征提取能力方面的改进能有效提升网络的泛化能力与鲁棒性,可将其应用于解决变化样本的农作物病害识别任务中。

关键词: 农作物病害; 识别; 全局特征; 多头注意力; 通道特征

中图分类号: S24; TP39 文献标识码: A 文章编号: 1000-1298(2022)12-0301-07 OSID: 

Deep Learning Network for Crop Disease Recognition with Global Feature Extraction

GUO Xiaoyan YU Shuaiqing SHEN Hangchi LI Long DU Jiaju
(College of Information Science and Technology, Gansu Agricultural University, Lanzhou 730070, China)

Abstract: In view of the fact that the recognition effect of the feature extraction network at this stage is not ideal when the test samples are skewed, fuzzy, defective and other changes, improving the network performance by expanding, transforming, scaling and other ways of training samples cannot dynamically meet the problem of the actual complex disease image recognition task, In ResNet50, a global feature deep learning network (GFDL-Net) based on global feature extraction was designed by introducing a two-layer attention mechanism and channel feature extraction mechanism. The network included channel feature extraction sub network (Squeeze and exception net, SE-Net) and double feature extraction net (DFE-Net), the global feature extraction ability of the network was improved from two aspects: channel space feature extraction and plane key point feature extraction. In order to verify the effectiveness of GFDL-Net, tests such as rotation at different angles and color transformation were added to the images of 15 diseases such as pepper, potato and tomato. It was found that the average recognition accuracy was 20.05 percentage points, 18.62 percentage points and 21.97 percentage points higher than that of ResNet50, BoTNet and EfficientNet respectively after adding rotation to the samples. Compared with ResNet50, BoTNet and EfficientNet, the average recognition accuracy was 3.57 percentage points, 0.53 percentage points and 3.98 percentage points higher, and the recognition speed was 4.4 times, 4.9 times and 2.0 times of ResNet50, BoTNet and EfficientNet respectively after adding the shading, saturation and contrast transformations. The experiment proved that the improvement of GFDL-Net in the global

收稿日期: 2022-07-09 修回日期: 2022-10-07
基金项目: 甘肃农业大学盛彤笙创新基金项目(GSAU-STs-2021-16)、甘肃农业大学青年导师基金项目(GAU-QDFC-2021-18)和甘肃省自然科学基金项目(20JR5RA023)
作者简介: 郭小燕(1976—),女,副教授,主要从事智能信息处理与农业信息化研究,E-mail: guoxy@gsau.edu.cn

feature extraction ability of images can effectively improve the generalization ability and robustness of the network, which can be used to solve the crop disease recognition task of changing samples.

Key words: crop diseases; recognition; global characteristics; MHSA; channel characteristics

0 引言

农作物病害严重影响农作物的产量和质量,对病害的有效识别可为农作物生产提供安全保障。随着人工智能的发展,将深度学习技术^[1]运用在农作物病害识别领域成为新的研究方向^[2],卷积神经网络^[3]作为深度学习技术的代表能够准确提取图像的关键特征,从而可有效完成分类和识别任务^[4-5],因此在农作物病害识别方面成为研究热点^[6-7]。

文献[8]搭建了一个 6 层卷积神经网络进行 6 类小麦病害识别,综合识别率可达 99% 以上。文献[9]采用一种基于迁移学习的卷积神经网络方法,对玉米健康叶、大斑病叶、锈病叶进行识别,识别准确率为 95.33%。文献[10]利用卷积神经网络,借助迁移学习对番茄的 8 类病害进行识别,准确率为 94.5%。对于病害类别较多的识别任务很多学者尝试加入残差块以解决网络层数增加时梯度消失的问题,文献[11]以常见的 6 种农作物共 19 类病害叶片图像为研究对象,采用 ResNet50 网络模型,利用迁移学习进行参数微调,识别准确率达到 91.24%。文献[12]利用 ResNetV1-101 对 61 类病害进行分类,最高识别准确率为 98.2%。余小东等^[13]提出了一种基于残差网络 ResNet50 的 CDCNNv2 算法,对 10 类作物的 3 万多幅病虫害图像进行建模,获得了病害严重程度分类模型,识别准确率为 91.51%。除此以外,一些基于卷积神经网络发展而来的经典深度学习网络模型也发挥了重要作用,文献[14]采用 AlexNet^[15]经典网络模型对茶叶部病害进行分类识别研究,平均准确率为 90%。文献[16]利用改进的 MobileNet-V2 进行田间农作物叶片病害识别,准确率达到 92%。文献[17]提出一种基于 Inception 与 Residual 结构组合的 Inception-resnet-v2 网络模型,用于农作物病虫害识别,准确率达到 96.67%,精确度达到 90.77%,召回率达到 89.72%。文献[18]提出了一种 YOLO-JD 深度学习网络检测黄麻病害,识别率为 96.63%。

利用卷积神经网络进行农作物病害识别已经取得一定的研究成果,但仍存在以下问题:当待检测图像清晰、端正、完整时识别率较高,但当待测样本与训练样本相比出现模糊、倾斜、局部缺失等变化的情况时识别效果并不理想,分析其主要原因发现,现阶段

对图像的特征提取多集中在利用卷积操作进行平面图像的局部特征提取,缺少对图像全局以及空间信息的捕捉。有学者通过在训练集中加入图像变换(旋转、裁剪)等扩充数据集的方法进行尝试^[19-20],但由于未在网络结构上有所突破,识别效果也受到了较大限制。本文采用 ResNet50^[21]作为基础网络引入通道特征提取机制(Squeeze-and-excitation, SE)和多头注意力(Multi-head self-attention, MHSA)^[22]机制,设计一个全局特征提取深度学习网络 GFDL-Net 进行农作物病害识别模型,将其应用于辣椒、马铃薯、番茄等 15 种病害的识别任务中,并和 BoTNet^[23]、ResNet50、EfficientNet^[24-25]模型进行对比。

1 GFDL-Net 网络模型

1.1 网络结构

以 ResNet50 作为基础网络,将 SE-Net 与 DFE-Net 嵌入其中设计农作物病害识别网络 GFDL-Net, GFDL-Net 由特征提取部分与分类部分组成,分别完成样本图像特征提取与病害分类识别任务。特征提取部分包含 5 个层次:保留原 ResNet50 的第 1 个特征提取层,将 SE-Net 作为 GFDL-Net 的第 2、3 个特征提取层,将 DFE-Net 作为 GFDL-Net 的第 4、5 个特征提取层;分类部分包括:全局平均池化层(Avg pooling)、全连接层(Full connection)、Softmax 层,如图 1 所示。

执行分类任务时,将一幅预处理好的农作物病害 RGB 图像映射为 $3 \times 64 \times 64$ 的特征向量送入网络模型,由 Layer1 ~ Layer5 进行全局特征提取,生成一个 $512 \times 4 \times 4$ 的特征向量(对应于 512 幅 4×4 的特征图),再将特征向量送入分类部分进行分类识别工作,最后生成一个 15×1 的特征向量作为分类结果,对应于辣椒、马铃薯、番茄 3 类农作物的 12 种病害,以及 3 种健康叶共 15 种类型,网络结构如表 1 所示。

1.2 通道特征提取子网络 SE-Net

1.2.1 SE-Net 网络结构

单纯在平面上的卷积操作忽略了通道空间特征信息,为了更好地将空间信息和平面信息融合,实现从全局感受野上捕获图像的整体特征,本文在 ResNet50 的第 2 个和第 3 个特征提取层的 Bottleneck block 中各加入了一个通道特征提取层 SE-Layers(Squeeze-and-excitation)^[26],设计了通道特征提取子网络 SE-Net,以提取输入图像通道中




图 1 GFDL-Net 网络构架图

Fig. 1 GFDL-Net network structure diagram

的空间特征,如图 2、3 所示。

表 1 GFDL-Net 网络结构
Tab. 1 Structure of GFDL-Net

层序号	网络结构		
	ResNet50	BoTNet	GFDL-Net
1	7 × 7, 64	7 × 7, 64	7 × 7, 64
2	3 × 3 max pool	3 × 3 max pool	3 × 3 max pool
3	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 32 \\ SE-Layer \\ 1 \times 1, 16 \end{bmatrix} \times 6$
4	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 64 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 64 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 48 \\ SE-Layers \\ 1 \times 1, 24 \end{bmatrix} \times 6$
5	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 32 \\ MHSA, 96 \\ 1 \times 1, 128 \end{bmatrix} \times 2$
6	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ MHSA, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 32 \\ MHSA, 128 \\ 1 \times 1, 128 \end{bmatrix} \times 2$




图 2 ResNet50 第 2、3 层结构

Fig. 2 ResNet50 2nd and 3rd layers structure

1.2.2 SE-Layer 工作步骤

(1) 标准卷积操作

给定一个通道数、宽、高分别为 C' 、 W' 、 H' 的图




图 3 SE-Net 网络结构

Fig. 3 SE-Net network structure

像 X , 经过标准卷积其维度变为 $C \times W \times H$ 的图像 U , 卷积公式为

$$X \rightarrow U \quad (X \in \mathbb{R}^{C' \times W' \times H'}, U \in \mathbb{R}^{C \times W \times H}) \quad (1)$$

$$U_c = V_c \times X = \sum_{s=1}^{C'} V_c^{(s)} \times X^{(s)} \quad (2)$$

式中 V_c ——第 c 个卷积核
 $X^{(s)}$ ——具有 s 个通道的 2 维图像
 U_c ——卷积后的图像
 $\mathbb{R}^{C' \times W' \times H'}$ ——输入样本空间
 $\mathbb{R}^{C \times W \times H}$ ——标准卷积后的样本空间

(2) Squeeze 操作

将维度为 $C \times W \times H$ 的张量进行全局平均池化 (Global average pooling, GAP), 转变为维度为 $C \times 1 \times 1$ 的张量 Z_c , 计算公式为

$$Z_c = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W U_c(i, j) \quad (3)$$

(3) Excitation 操作

提取通道中的特征信息, 计算公式为

$$S_c = \sigma(W_2 \delta(W_1 Z_c)) \quad (4)$$

式中 W_1 ——降维系数

δ ——ReLU 激活函数
 W_2 ——升维系数 σ ——Sigmoid 函数
 S_c —— $C \times 1 \times 1$ 的张量,为每个通道权重

$$\hat{x}_c = U_c \times S_c \tag{5}$$

(4) Fscale 操作
将通道权重映射到原始图像,计算公式为

1.2.3 SE-Layer 工作机制
SE-Layer 工作机制如图 4 所示,一幅 $32 \times 32 \times 32$ 的输入图像经过 SE-Layer 转换为一幅 $32 \times 16 \times 16$ 的图像。




图 4 SE-Layer 工作机制
Fig.4 SE-Layer working mechanism

1.3 双注意力平面特征提取子网络 (DFE-Net)

基于 Transformer 编码器-解码器构架的 MHSA 能对图像进行全局推理并生成预测,因此已有相关学者尝试在 ResNet 网络中加入 MHSA 以加强关键点的提取,从而提高网络的全局图像特征提取能力,文献[23]提出一种 BoTNet 网络,在 ResNet50 网络的最后一层用 MHSA 替换每个残差块 (Bottleneck block) 中的 3×3 卷积层 (Convolution layer),试验证明效果较好,为获取更多输入图像的细节特征,本文在 ResNet50 第 4、5 个特征提取层的每个 Bottleneck block 中均用 MHSA 代替一个 3×3 卷积层,设计一个双注意力平面特征提取子网络 DFE-Net,以提高网络的全局提取能力,如图 5、6 所示。




图 5 ResNet50 第 4、5 层
Fig. 5 ResNet50 4th and 5th layers




图 6 DFE-Net 网络模型
Fig. 6 DFE-Net network model

2 模型复杂性分析

MHSA 提供的全局感受野和注意力机制使网络为输入图像中的关键特征赋予更高的权重,避免了噪声干扰,因此具有高维映射能力和更强的网络表达性能。而 MHSA 的存在会导致网络计算成本增大,这在训练样本不变的情况下容易产生过拟合、导致网络的泛化能力下降,同时影响响应速度。ResNet50 参数量为 2.55×10^7 , BoTNet 为 $2.08 \times$

10^7 , 然而运行时间 ResNet50 为 1.65×10^5 ms, BoTNet 为 1.83×10^5 ms,分析 BoTNet 运行时间略高的原因,这与 MHSA 带来的新的运算量有关,可以断定在 Layer 4、Layer5 中的每个 Bottleneck block 加入 MHSA 会增加运算成本。EfficientNet 和标准卷积网络相比在网络的深度、宽度、分辨率 3 个维度均有提升,并通过一组固定的缩放系数缩放 3 个维度,在提高准确率的同时降低了网络的复杂度,其网络参数量仅为 5.3×10^6 ,是 ResNet50 的 20.7%,BoTNet 的 25.4%。而 GFDL-Net 为了进一步约简网络,提高响应速度,将每层 Bottleneck block 中卷积核的数量、尺寸以及 Bottleneck block 的尺寸都进行了调整、缩减与重新调配 (表 1),最终 GFDL-Net 网络的参数量为 1.2×10^6 ,仅为 ResNet50 的 4.7%、为 BoTNet 的 5.7%、为 EfficientNet 的 22.6%。

3 试验

3.1 试验数据集

在 PlantVillage 植物病害图像库中选取辣椒、马铃薯、番茄 3 类农作物,共计 20 950 幅图像 (15 种类别) 作为数据源,随机抽取 80% 的数据作为训练集,10% 作为测试集,10% 作为验证集,如表 2、图 7 所示。

3.2 试验环境

硬件环境为配置 NVIDIA Ge Force GTX 1080Ti 显卡的 GPU 图像工作站;软件环境为 Ubuntu 18.04 操作系统、PyTorch 深度学习框架以及 Python 语言。模型训练采用流水线方式,使用随机梯度下降方法优化整个网络模型。网络模型运行 100 个迭代周期 (epoch),选择自适应时刻估计方法 (Adaptive moment estimation) 作为优化器,设置动量因子为 0.90,权重衰减为 0.000 1,学习率为 0.1。

表 2 试验数据集
Tab. 2 Test dataset

编号	植物名称	病害名称	图像数量
A1	辣椒	细菌性斑点病	1 497
A2	辣椒	健康叶	1 478
A3	马铃薯	早疫病	1 000
A4	马铃薯	健康叶	1 520
A5	马铃薯	晚疫病	1 000
A6	番茄	细菌性斑点病	1 270
A7	番茄	早疫病	1 001
A8	番茄	健康叶	1 591
A9	番茄	晚疫病	1 909
A10	番茄	叶霉病	1 252
A11	番茄	斑枯病	1 771
A12	番茄	二斑叶螨病	1 676
A13	番茄	轮斑病	1 404
A14	番茄	花叶病	1 373
A15	番茄	黄曲叶病	1 208

3.3 试验设计

为了测试 GFDL-Net 网络的鲁棒性,设计了旋转测试、色彩变换测试;为了测试网络的响应速度、验证网络的参数约简后对于准确率的影响,设计了速度测试,分别进行 20 次试验取均值并将结果与 ResNet50、BoTNet、EfficientNet 进行比对。

3.3.1 旋转测试

利用原始病害样本训练好网络以后,将测试样本分别旋转 180°、120°、90°、60°、45°、30° 进行识别

测试,以验证模型对于测试样本任意角度旋转后的鲁棒性。从表 3 可以看出,在原始图像进行识别测试时, EfficientNet、ResNet50、BoTNet、GFDL-Net 4 种模型的准确率均较高,分别为 98.67%、98.92%、99.49%、99.32%。BoTNet 和 GFDL-Net 有一定优势(BoTNet 略高一些),可见 MHSA 的引入对于改善网络性能效果明显。当图像旋转 180°、120°、90°、60°、45°、30° 时,4 种网络模型的识别率都有所下降,在待测图像旋转 90°、180° 时 4 种模型的识别准确率下降都不是非常明显,在旋转 90° 时识别率都保持在 91% 以上,其中 BoTNet 和 GFDL-Net 优势明显,分别为 96.366% 和 96.705%,在旋转 180° 时 BoTNet 为 97.093%,GFDL-Net 为 96.705%,表明 MHSA 的加入增强了网络对于直角变换、平面变换的鲁棒性。但当原图像经过旋转 30°、45°、60°、120° 后, EfficientNet、ResNet50、BoTNet 识别准确率剧烈下降, GFDL-Net 优势明显,特别在旋转 45° 时,分别比 EfficientNet、ResNet50、BoTNet 高出 34.496、34.302、30.669 个百分点。GFDL-Net 平均识别率为 94.34%,与 EfficientNet、ResNet50、BoTNet 相比分别高出 21.97、20.05、18.62 个百分点,表明其对于样本旋转的鲁棒性优势明显,表现出更强的泛化能力和稳定性。

3.3.2 色彩变换测试

利用原始病害图像测试样本训练好网络以后,将测试样本分别加入 50% 的对比度、50% 的饱和度、50% 的亮度进行测试,以验证模型测试样本对于



图 7 数据集

Fig. 7 Dataset

表 3 旋转测试识别准确率

Tab.3 Recognition accuracy of rotation test								%
模型	原始图像	旋转 180°	旋转 120°	旋转 90°	旋转 60°	旋转 45°	旋转 30°	平均值
ResNet50 ^[21]	98.92	91.521	56.347	91.136	55.426	56.105	70.591	74.29
BoTNet ^[23]	99.49	97.093	57.413	96.366	57.510	59.738	62.403	75.72
EfficientNet ^[27]	98.67	89.826	52.422	91.764	52.471	55.911	65.552	72.37
GFDL-Net	99.32	96.705	91.231	96.705	90.407	90.407	95.591	94.34

色彩变化的鲁棒性,如表 4 所示。

表 4 色彩变换测试识别准确率

Tab.4 Recognition of color transformation test					%
模型	原始图像	增加对比度	增加饱和度	增加亮度	平均值
ResNet50 ^[21]	98.92	74.95	89.10	78.68	85.41
BoTNet ^[23]	99.46	75.40	92.13	86.81	88.45
EfficientNet ^[27]	98.67	74.80	88.69	77.85	85.00
GFDL-Net	99.32	80.67	91.09	84.84	88.98

从表 4 可以看出,在图像中增加 50% 的对比度、饱和度、亮度后,4 种模型的识别准确率都有所下降,表明样本色彩变换对于模型普遍有较为明显的影响。GFDL-Net 的平均识别准确率为 88.98%,较旋转测试均值 94.34% 有所下降,证明 GFDL-Net 对于色彩变换较为敏感。GFDL-Net 平均识别准确率与 EfficientNet、ResNet50、BoTNet 相比分别高出 3.98、3.57、0.53 个百分点,可见 GFDL-Net 对色彩变换的鲁棒性更好。

3.3.3 速度测试

模型参数量影响模型的速度,从图 8 可以看出,ResNet50 的参数量最大,BotNet 其次,EfficientNet 参数量相比前两种网络较小,GFDL-Net 由于在 BoTNet 的基础上进行了参数约简使得参数量大幅降低,然而识别准确率较其他 3 种模型相比却有较为明显的优势,如图 8 所示。




图 8 速度测试气泡图

Fig.8 Bubble chart of speed test

从图 8 可以看出,ResNet50 参数量最大,而识别准确率明显低于 BoTNet 和 GFDL-Net,略高于 EfficientNet,然而 EfficientNet 的参数量较小,仅为 ResNet50 的 1/5。BoTNet 识别准确率比 GFDL-Net 略低,参数量却为 GFDL-Net 的 17 倍。GFDL-Net

与 BoTNet 相当(BoTNet 略高一点),然而 GFDL-Net 参数量较 EfficientNet、ResNet50、BoTNet 有明显减少。为了测试 GFDL-Net 模型的响应速度,在 3.2 节所示的同样试验环境下进行速度测试,试验结果显示,BoTNet 的运行时间为 1.829×10^5 ms, ResNet50 为 1.645×10^5 ms, EfficientNet 为 7.47×10^4 ms, GFDL-Net 为 3.70×10^4 ms,可见参数数量的多少与模型的响应速度有直接关系。GFDL-Net 在保证模型较好识别性能的同时保持了较轻的体量,因此识别速度较其他 3 种模型有较为明显的优势,运行速度分别为 EfficientNet、ResNet50、BoTNet 的 2.0、4.4、4.9 倍。可见虽然在 ResNet50 中加入了 MHSA 和 SE-Layer,但 GFDL-Net 经过参数约简使得网络更加轻量高效,保证了病害识别的实时性。

4 结论

(1)设计了一个基于全局特征提取的农作物病害识别网络 GFDL-Net,旨在提高网络的全局特征提取及病害类别的识别能力,当输入样本出现倾斜、颜色失真等变化时保证正常的识别效果。

(2)在 ResNet50 的第 2 个和第 3 个特征提取层的 Bottleneck block 中加入了一个通道特征提取层 SE-Layers(Squeeze-and-excitation)设计通道特征的提取子网络 SE-Net,从而提升了网络全局特征提取能力;在 ResNet50 的基础上加入了 MHSA,设计了 DEF-Net 子网络以聚焦病害关键特征的提取,从而提升了网络的识别能力;在 ResNet50 中加入 MHSA 的同时调整 Bottleneck block 的个数以及卷积核的尺寸与数量,从而减少网络参数。

(3)旋转、颜色变换、速度测试表明 GFDL-Net 能够在样本颜色失真、倾斜等情况下准确识别农作物病害类别,与 ResNet50、BoTNet、EfficientNet 方法相比,平均识别准确率分别高出 20.05、18.62、21.97 个百分点,样本加入明暗度、饱和度、对比度变换后与 ResNet50、BoTNet、EfficientNet 相比,平均识别准确率分别高出 3.57、0.53、3.98 个百分点,而识别速度分别为 ResNet50、BoTNet、EfficientNet 的 4.4、4.9、2.0 倍。试验证明 GFDL-Net 在图像全局特征提取能力方面的改进可以有效提升网络的泛化能力与鲁棒性。

参 考 文 献

- [1] BAEK M, BAKER D. Deep learning and protein structure modeling[J]. *Nature Methods*, 2022, 19(1): 13–14.
- [2] 林羽, 刘斌琼. 图像识别技术在农业领域中的应用[J]. *福建畜牧兽医*, 2020, 42(2): 49–50.
LIN Yu, LIU Binqiong. Application of image recognition technology in agriculture [J]. *Fujian Animal Husbandry and Veterinary*, 2020, 42(2): 49–50. (in Chinese)
- [3] KATTENBORN T, LEITLOFF J, SCHIEFER F, et al. Review on convolutional neural networks (CNN) in vegetation remote sensing[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 173: 24–49.
- [4] 周清松, 唐秀忠. 图像识别处理技术在农业工程中的应用[J]. *现代电子技术*, 2017, 40(4): 107–110.
ZHOU Qingsong, TANG Xiuzhong. Application of image recognition processing technology in agricultural engineering [J]. *Modern Electronic Technology*, 2017, 40(4): 107–110. (in Chinese)
- [5] 刘斌, 徐皓玮, 李承泽, 等. 基于快照集成卷积神经网络的苹果叶部病害程度识别[J]. *农业机械学报*, 2022, 53(6): 286–294.
LIU Bin, XU Haowei, LI Chengze, et al. Apple leaf disease identification method based on snapshot ensemble CNN [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(6): 286–294. (in Chinese)
- [6] 吴华瑞. 基于深度残差网络的番茄叶片病害识别方法[J]. *智慧农业*, 2019, 1(4): 42–49.
WU Huarui. Method of tomato leaf diseases recognition method based on deep residual network [J]. *Smart Agriculture*, 2019, 1(4): 42–49. (in Chinese)
- [7] 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)
- [8] 张航, 程清, 武英洁, 等. 一种基于卷积神经网络的小麦病害识别方法[J]. *山东农业科学*, 2018, 50(3): 137–141.
ZHANG Hang, CHENG Qing, WU Yingjie, et al. A method of wheat disease identification based on convolutional neural network [J]. *Shandong Agricultural Sciences*, 2018, 50(3): 137–141. (in Chinese)
- [9] 许景辉, 邵明烨, 王一琛, 等. 基于迁移学习的卷积神经网络玉米病害图像识别[J]. *农业机械学报*, 2020, 51(2): 230–236, 253.
XU Jinghui, SHAO Mingye, WANG Yichen, et al. Recognition of corn leaf spot and rust based on transfer learning with convolutional neural network [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(2): 230–236, 253. (in Chinese)
- [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] 刘冬寒, 钱程. 基于迁移学习和残差网络的农作物病害识别[J]. *计算机科学与应用*, 2021, 11(4): 8.
LIU Donghan, QIAN Cheng. Identification of crop diseases based on transfer learning and residual network [J]. *Computer Science and Application*, 2021, 11(4): 8. (in Chinese)
- [12] 魏超, 范自柱, 张泓, 等. 基于深度学习的农作物病害检测[J]. *江苏大学学报(自然科学版)*, 2019, 40(2): 190–196.
WEI Chao, FAN Zizhu, ZHANG Hong, et al. Crop disease detection based on deep learning [J]. *Journal of Jiangsu University (Natural Science Edition)*, 2019, 40(2): 190–196. (in Chinese)
- [13] 余小东, 杨孟辑, 张海清, 等. 基于迁移学习的农作物病虫害检测方法研究与应用[J]. *农业机械学报*, 2020, 51(10): 252–258.
YU Xiaodong, YANG Mengji, ZHANG Haiqing, et al. Research and application of crop diseases detection method based on transfer learning [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2020, 51(10): 252–258. (in Chinese)
- [14] 孙云云, 江朝晖, 董伟, 等. 基于卷积神经网络和小样本的茶树病害图像识别[J]. *江苏农业学报*, 2019, 35(1): 48–55.
SUN Yunyun, JIANG Zhaohui, DONG Wei, et al. Image recognition of tea plant disease based on convolutional neural network and small samples [J]. *Jiangsu Journal of Agricultural Sciences*, 2019, 35(1): 48–55. (in Chinese)
- [15] AGARW A L, PATNI K, RAJESWARI D. Lung cancer detection and classification based on AlexNet CNN [C] // *International Conference on Communication and Electronics Systems (ICCES)*, 2021: 1390–1397.
- [16] 孙俊, 朱伟栋, 罗元秋, 等. 基于改进 MobileNet-V2 的田间农作物叶片病害识别[J]. *农业工程学报*, 2021, 37(22): 161–169.
SUN Jun, ZHU Weidong, LUO Yuanqiu, et al. Recognizing the diseases of crop leaves in fields using improved Mobilenet-V2 [J]. *Transactions of the CSAE*, 2021, 37(22): 161–169. (in Chinese)
- [17] 冯广, 孔立斌, 石鸣鸣. 基于 Inception 与 Residual 组合网络的农作物病虫害识别[J]. *广东工业大学学报*, 2020, 37(3): 6.
FENG Guang, KONG Libin, SHI Mingming. Crop pest recognition based on Inception and Residual combined network [J]. *Journal of Guangdong University of Technology*, 2020, 37(3): 6. (in Chinese)
- [18] LI D, AHMED F, WU N, et al. YOLO-JD: a deep learning network for jute diseases and pests detection from images [J]. *Plants*, 2022, 11(7): 937.