

# Journal of System Simulation

---

Volume 36 | Issue 6

Article 6

---

6-28-2024

## Simulation of Rice Disease Recognition Based on Improved Attention Mechanism Embedded in PR-Net Model

Yang Lu

*College of Information and Electrical Engineering, Heilongjiang Bayi Agricultural University, Daqing 163319, China, luyanga@sina.com*

Pengfei Liu

*College of Information and Electrical Engineering, Heilongjiang Bayi Agricultural University, Daqing 163319, China*

Siyuan Xu

*College of Information and Electrical Engineering, Heilongjiang Bayi Agricultural University, Daqing 163319, China*

Qiwang Liu

*College of Information and Electrical Engineering, Heilongjiang Bayi Agricultural University, Daqing 163319, China*

*See next page for additional authors*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact [xtfzxb@126.com](mailto:xtfzxb@126.com).

---

# Simulation of Rice Disease Recognition Based on Improved Attention Mechanism Embedded in PR-Net Model

## Abstract

**Abstract:** Aiming at the low accuracy of existing CNN models in identifying rice leaf diseases, a hybrid convolutional neural network model PRC-Net (parallel residual with coordinate attention network) combining parallel structure and residual structure is proposed. A parallel structure is introduced to improve the receptive field of convolution, and the residual structure is combined to achieve the complete and continuous transmission of feature information. An improved spatial attention mechanism is embedded into the backbone model PR-Net to enhance the degree of aggregation of lesion feature information at different scales. In order to further improve the accuracy of disease identification and reduce the training and reasoning time of the model, the model structure is optimized by changing the weighting method. Simulation results show that, compared to the classification models such as InceptionResNetV2, PRC-Net has fewer training parameters, shorter training time, and higher recognition accuracy, which is superior to the other crop disease identification models.

## Keywords

rice leaf disease, PRC-Net, convolution neural network, attention mechanism, image recognition

## Authors

Yang Lu, Pengfei Liu, Siyuan Xu, Qiwang Liu, Fuqian Gu, and Peng Wang

## Recommended Citation

Lu Yang, Liu Pengfei, Xu Siyuan, et al. Simulation of Rice Disease Recognition Based on Improved Attention Mechanism Embedded in PR-Net Model[J]. Journal of System Simulation, 2024, 36(6): 1322-1333.

# 改进注意力机制嵌入PR-Net模型的水稻病害识别仿真

路阳<sup>1</sup>, 刘鹏飞<sup>1</sup>, 许思源<sup>1</sup>, 刘启旺<sup>1</sup>, 顾福谦<sup>1</sup>, 王鹏<sup>2,3,4</sup>

(1. 黑龙江八一农垦大学 信息与电气工程学院, 黑龙江 大庆 163319;  
 2. 东北石油大学 黑龙江省网络化与智能控制重点实验室, 黑龙江 大庆 163318;  
 3. 东北石油大学 人工智能能源研究院, 黑龙江 大庆 163318; 4. 东北石油大学 三亚海洋油气研究院, 海南 三亚 572024)

**摘要:** 针对现有的CNN模型在水稻叶部病害的识别中准确率较低的问题, 提出了一种结合并行结构和残差结构的混合卷积神经网络模型 PRC-Net(parallel residual with coordinate attention network)。引入并行结构, 提高卷积的感受野; 结合残差结构, 使特征信息完整的连续传递; 在骨干模型 PR-Net 中嵌入改进的空间注意力机制, 增强对不同尺度病斑特征信息的凝聚程度; 为进一步提升病害识别的准确率, 并减少模型的训练时间和推理时间, 通过改变加权方式对模型结构进行优化。仿真结果表明: 与 InceptionResNetV2 等分类模型相比, PRC-Net 具有更少的训练参数、更短的训练时间和更高的识别精度, 性能优于其他作物病害识别模型。

**关键词:** 水稻叶部病害; PRC-Net(parallel residual with coordinate attention network); 卷积神经网络; 注意力机制; 图像识别

中图分类号: TP391 文献标志码: A 文章编号: 1004-731X(2024)06-1322-12

DOI: 10.16182/j.issn1004731x.joss.23-0322

引用格式: 路阳, 刘鹏飞, 许思源, 等. 改进注意力机制嵌入PR-Net模型的水稻病害识别仿真[J]. 系统仿真学报, 2024, 36(6): 1322-1333.

Reference format: Lu Yang, Liu Pengfei, Xu Siyuan, et al. Simulation of Rice Disease Recognition Based on Improved Attention Mechanism Embedded in PR-Net Model[J]. Journal of System Simulation, 2024, 36(6): 1322-1333.

## Simulation of Rice Disease Recognition Based on Improved Attention Mechanism Embedded in PR-Net Model

Lu Yang<sup>1</sup>, Liu Pengfei<sup>1</sup>, Xu Siyuan<sup>1</sup>, Liu Qiwang<sup>1</sup>, Gu Fuguan<sup>1</sup>, Wang Peng<sup>2,3,4</sup>

(1. College of Information and Electrical Engineering, Heilongjiang Bayi Agricultural University, Daqing 163319, China;  
 2. Heilongjiang Provincial Key Laboratory of Networking and Intelligent Control, Northeast Petroleum University, Daqing 163318, China;  
 3. Artificial Intelligence Energy Institute, Northeast Petroleum University, Daqing 163318, China;  
 4. Sanya Research Institute of Offshore Oil and Gas, Northeast Petroleum University, Sanya 572024, China)

**Abstract:** Aiming at the low accuracy of existing CNN models in identifying rice leaf diseases, a hybrid convolutional neural network model PRC-Net (parallel residual with coordinate attention network) combining parallel structure and residual structure is proposed. *A parallel structure is introduced to improve the receptive field of convolution, and the residual structure is combined to achieve the complete and continuous transmission of feature information. An improved spatial attention mechanism is embedded into the backbone model PR-Net to enhance the degree of aggregation of lesion feature information at different scales. In order to further improve the accuracy of disease identification and reduce the training and reasoning time of the model, the model structure is optimized by changing the*

收稿日期: 2023-03-21 修回日期: 2023-05-29

基金项目: 国家自然科学基金(U21A2019, 61873058, 61933007); 黑龙江省自然科学基金联合引导项目(LH2020F042); 黑龙江省博士后科研启动基金(LBH-Q17134); 海南省科技专项(ZDYF2022SHFZ105)

第一作者: 路阳(1976-), 男, 教授, 博导, 博士, 研究方向为复杂系统智能故障诊断及模式识别。E-mail: luyanga@sina.com

*weighting method.* Simulation results show that, compared to the classification models such as InceptionResNetV2, PRC-Net has fewer training parameters, shorter training time, and higher recognition accuracy, which is superior to the other crop disease identification models.

**Keywords:** rice leaf disease; PRC-Net; convolution neural network; attention mechanism; image recognition

## 0 引言

水稻是世界上主要的种植作物之一, 是世界上一半以上人口的主食<sup>[1]</sup>。水稻病害具有种类多、发生范围广、流行性高、危害严重等特点, 每年由病虫害造成的损失都是巨大的<sup>[2]</sup>。传统的水稻叶部病害识别方法主要由植物保护专家根据自己的经验和作物病害特征做出判断, 但这种方法受个人经验、作物生长阶段和天气条件等因素影响, 难以达到理想的识别效率和准确度。

水稻病害智能诊断是一个新兴的研究领域, 虽然已有一些成果发表, 但仍属起步阶段, 研究成果比较有限<sup>[3-5]</sup>。传统的机器学习算法在水稻病害识别上具有较高的准确率, 但该类算法需要人工提取病斑特征用于检测, 其性能一定程度上取决于研究人员的主观性。深度学习技术可以自动提取特征, 在处理大规模数据方面有较大的优势, 它通过不断增加网络深度和迭代次数, 达到从海量输入数据中自动提取数据特征并进行分类识别的目的。深度学习的卷积神经网络对于复杂图像的识别具有很好的效果, 经典的卷积神经网络包括VGG<sup>[6]</sup>、ResNet<sup>[7]</sup>、InceptionV3<sup>[8]</sup>和Inception-ResNetV2<sup>[9]</sup>。

水稻病害多出现于稻叶上, 而稻叶与其他常见作物的叶部结构不同呈长扁型, 不利于特征的提取, 识别率难以进一步提升。尽管网络越深、越宽, 可以获得的图像信息越多, 提取的特征越丰富, 但也会忽略更详细的图像信息。注意力机制的出现给予研究人员新的灵感, 注意力机制是一种新的资源分配方案, 可以解决信息过载的问题, 在计算能力有限的情况下, 它可以基于有限的计算资源处理更重要的信息<sup>[10]</sup>。

为了提高水稻叶部病害识别的准确率, 本文以稻瘟病、白叶枯病、胡麻斑病、纹枯病、条纹叶枯病等5种常见水稻病害为研究对象, 基于深度学习方法提出了一种结合并列结构和残差结构的混合卷积神经网络模型PRC-Net (parallel residual with coordinate attention network)。

PRC-Net由3个特征提取模块PR-Block组成, PR-Block的感受野与参数量随深度增长以保证运算效果。在PRC-Net中各模块的信息交汇处嵌入了改进的空间注意力机制, 增强对不同尺度病斑特征信息的凝聚程度。采用自制的水稻叶部病害数据集和PlantVillage<sup>[11]</sup>, 对模型的有效性和实用性进行了论证。

## 1 相关工作

### 1.1 水稻叶部病害识别

文献[12]通过将Fuzzy Logic和K-means分割技术相结合的方式来判断水稻叶部病害的严重程度, 准确率达到86.35%。文献[13]提出了一种仅使用颜色特征的基于图像的水稻植物病害分类方法, 并用支持向量机(SVM)分类器验证, 得到了94.65%的分类精度。该类机器学习方法虽有效降低了水稻病害识别的难度, 但图像特征需要人工提取, 效率低下且准确率不高。随着深度学习技术的发展, 文献[14]提出了一个custom-CNN深度CNN模型来对4种水稻叶部病害进行识别, 取得97.47%的准确率。一些研究人员发现注意力机制可以增强病斑特征的权重, 提高识别的准确率。文献[15]在改进的YOLOv5的基础上引入了SE模块, 提高了模型对信道特征的敏感度, 性能明显优于原始的YOLOv5和YOLOX\_nano模型。文献[16]选择在ImageNet上预训练MobileNet-V2作为骨干网络, 并添加了注意力机制, 使识别水稻病害的平均准确率达到了98.48%。注意力机制的引

入强化了模型对微小特征的学习能力，让水稻病害的识别更加准确。

## 1.2 卷积神经网络

常见的卷积神经网络包含3种模型结构：线性结构、残差结构和并行结构。传统的线性结构通过增加网络深度来提高图像分类的识别精度，会导致参数数量和训练时间的增加，并且会伴随梯度消失和梯度爆炸等问题。残差结构和并行结构都是在线性结构的基础上进行改进的，以取得技术突破。残差结构通过跳跃连接和激活函数来使后面层获得前面层的信息。并行结构通过层与层之间同步运算并将结果组合传输的方式来提高卷积的感受野。VGG16、ResNet50、InceptionV3和Inception-ResNetV2分别为线性、残差、并行及并行残差组合的代表模型。

## 1.3 空间变换神经网络

空间变换神经网络(spatial transformer networks, STN)<sup>[17]</sup>是空间注意力机制的代表模型，通过将图像网格化使所有图像处于同一空间，为不同特征标记坐标并计算位置信息。根据重要程度生成权重，使重要特征获得更多的关注，从而忽略不重要的特征，促进了基于空间注意力机制的发展。首先，使特征图根据 $[-1, 1]$ 进行网格划分得到坐标，生成 $(3, n)$ 的坐标矩阵。其次，对网络中的6个参数进行仿射变换，转化为参数矩阵 $\begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \end{bmatrix}$ ，记录旋转、缩放和平移信息，再与原坐标相乘获得新坐标。最后，对每个新坐标计算上下左右的坐标位置，与之前的特征按面积进行加权，生成最终的位置重标定特征图。

# 2 PRC-Net模型构建

## 2.1 PR-Block

本文使用残差结构和并行结构组合的方式构建了一个由2个渐进卷积块组成的特征提取的模

块，称为PR-Block。PR-Block中卷积块1包含3组并行卷积路线。其中，路线①中包含2个 $3\times 3$ 的卷积感受野，相当于一个 $5\times 5$ 卷积感受野，却具有更小的参数计算量，可以检测水稻病害图像中相对较大的病斑，并获得病害的全局特征信息。路线②中只有一个 $3\times 3$ 的卷积，它可以检测水稻病害图像中相对较小的病斑，获得病害的局部特征信息。线路①与线路②的组合减少了水稻病害特征信息的丢失，提高了识别精度。线路③利用了残差结构，为进一步展现残差结构在卷积层上的优势，更好地拟合输入数据，在这3条线路的开端和并行汇总的终端使用了 $1\times 1$ 卷积。 $1\times 1$ 卷积允许进行上采样和下采样操作，减少参数并灵活调整输出大小。图1展示了PR-Block的结构。

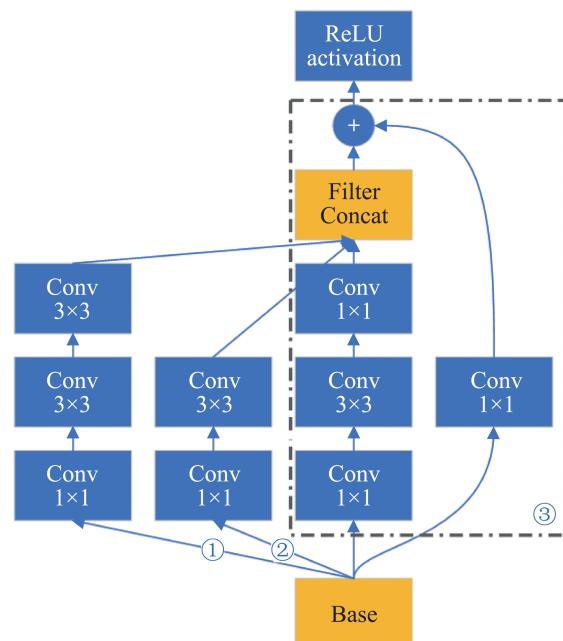


图1 PR-Block结构图  
Fig. 1 Structure of PR-Block

## 2.2 PR-Net

ResNet、InceptionV3和InceptionResNetV2等网络模型具有过深的模型深度、过多的训练参数，以及过长的训练时间。为了解决这些问题，本文构建了一个水稻病害识别模型，该模型包含3个逐步递进提取特征的PR-Block模块，PR-Net。

PR-Net中的每个PR-Block都将运算输出两倍于前层输入数量的特征图。将2.1节中构建的PR-Block作为初步特征提取阶段，称为PR-Block A模块。其后的PR-Block B模块将获得更大的运算量，为获得更好的特征提取效果，将 $3\times 3$ 的卷积，替换为 $7\times 7$ 的卷积，并将 $7\times 7$ 的卷积转换为 $7\times 1$ 的卷积接上 $1\times 7$ 的卷积，以降低运算资源和内存占用，它们具有相同的感受野，其结构如图2(a)所示。PR-Block C模块作为PR-Net的最后阶段，运算大量数据的同时也需要提取关键特征输出给后续层进行分类运算，所以效仿PR-Block B模块进行了卷

积转换，将并行结构中线路的末端进行了扩展，并将 $3\times 3$ 的卷积替换为并行的 $3\times 1$ 和 $1\times 3$ 的2个卷积，以此来进一步扩展模块的宽度，解决表征性瓶颈，增加提取能力的同时减少了特征信息的损失，其结构如图2(b)所示。由这样的3个PR-Block组成的递进提取特征模块可以对水稻病害图像中的病害特征进行局部特征提取，然后对提取到的特征信息进行进一步的融合操作以获得更完整的特征信息。因此，包含了该模块的PR-Net相比于同类模型具有更高的维度提取能力，更少的训练参数以及更小的运算量。表1展示了PR-Net结构的相关参数。

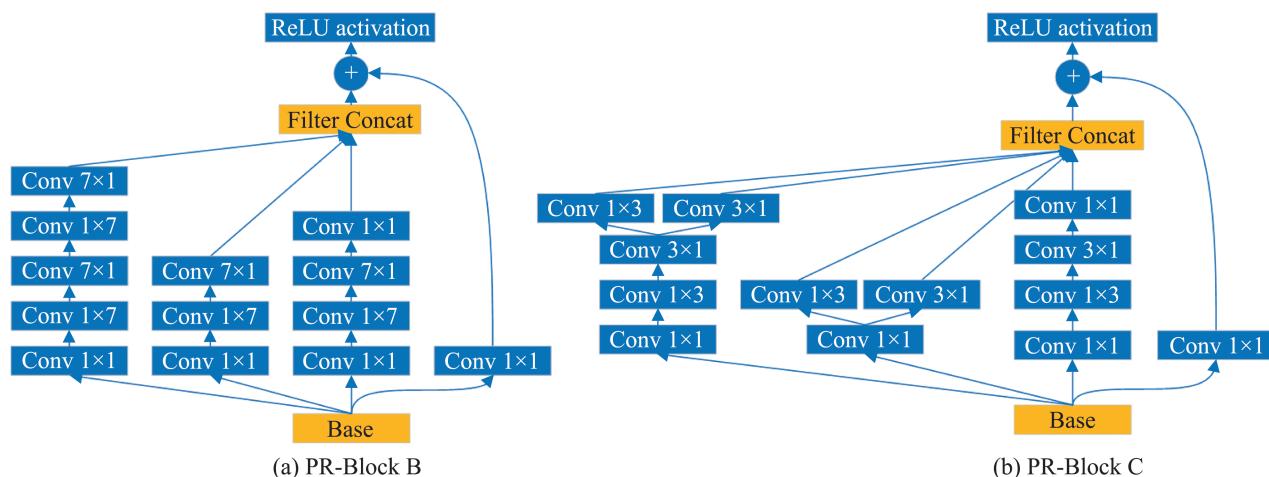


图2 PR-Block分支结构图  
Fig. 2 Branch structure of PR-Block

表1 PR-Net结构相关参数  
Table 1 Relevant parameters of PR-Net structure

层名	内核	步长	输出形状
Input			(None, 256, 256, 3)
Conv2D_1	$7\times 7$	2	(None, 128, 128, 128)
MaxPooling2D_1	$3\times 3$	2	(None, 64, 64, 128)
Conv2D_2	$3\times 3$	1	(None, 64, 64, 64)
MaxPooling2D_2	$3\times 3$	2	(None, 32, 32, 64)
PR-Block A			(None, 32, 32, 192)
PR-Block B			(None, 32, 32, 384)
PR-Block C			(None, 32, 32, 1280)
GlobalAveragePooling2D			(None, 1280)
Softmax			(None, 6)

注：None表示深度学习模型在训练过程中的批处理大小，将随着实际值变化进行动态调整。

## 2.3 注意力机制的引入

### 2.3.1 坐标注意力机制

CA<sup>[18]</sup>模块从前层获取的特征图包含了三维信息，也就是通道( $C$ )、高度( $H$ )和宽度( $W$ )。给定 $C\times H\times W$ 形状的特征图( $\mathbf{F}$ )将沿着水平和垂直方向计算一维平均池化，将原特征图拆分为2种形状的特征图， $\mathbf{M}_x(\mathbf{F})\in\mathbb{R}^{C\times H\times 1}$ ( $x$ 轴方向)和 $\mathbf{M}_y(\mathbf{F})\in\mathbb{R}^{C\times 1\times W}$ ( $y$ 轴方向)。分别沿2个空间方向捕获远程依赖关系，进行拼接和卷积操作，然后将得到的特征图单独编码成一对方向感知和位置敏感的空间注意力图，最后将2个方向上的特征图重新组合成原来的形状 $\mathbf{M}_s(\mathbf{F})\in\mathbb{R}^{C\times H\times W}$ ，通过

softmax激活函数后进行输出。

### 2.3.2 改进坐标注意力机制

由于CA模块接收的特征图信息是经过PR-Block高维拼接的，所以病斑的特征信息过于分散，不利于空间注意力权重分析。为提高特征图病斑信息的聚合程度，在特征图拆分之前加入了一个包含两个1D卷积的DCA(dual channel attention block)模块。1D卷积不涉及空间的降维，不会影响后续的空间远程依赖的捕获，它只是先行对病斑信息的重要程度进行加强。通过实验对1D卷积核的大小进行了定性分析，以便在取一定值时，可以更好地检测大小不同的病斑信息。在实验中，特征图在DCA块中分别计算了平均池化和最大池化，最后生成的通道注意力图 $M_C(F) \in \mathbb{R}^{C \times 1 \times 1}$ ，其本身就是病斑特征的权重信息，输入后续的空间注意力操作会对卷积计算的最大值和最小值产生影响，所以在模块整体上添加了加权操作以强调病斑信息。加权操作是对空

间注意力最终输出的 $M_s(F)$ 的权重与原始特征图 $(F)$ 通过矩阵相乘进行加权。通过加权操作，原始特征图中的病斑信息会进一步增强，DCA模块对其后续运算的影响也将降到最低，有利于提高模型对水稻叶部病害图像的识别精度。

## 2.4 PRC-Net

由于水稻叶片为绿色且具有长扁型的外观，且其上的病害又多为褐色或暗绿色的斑点，尤其是在病害早期病斑较小时相似度极高，PR-Net在识别这种症状相近、面积较小的水稻叶部病害样本时容易引起混淆。为了降低样本图像中无关的细节信息对模型识别能力的影响，本文提出在PR-Net模型中各模块的信息交汇处嵌入改进的CA模块，可以保留精确的病斑位置信息，增强模型的重要特征提取能力，称为PRC-Net，如图3所示。改进的CA模块是一个空间注意力模块，可以灵活地插入到PR-Net模型中，几乎没有增加额外的计算量。

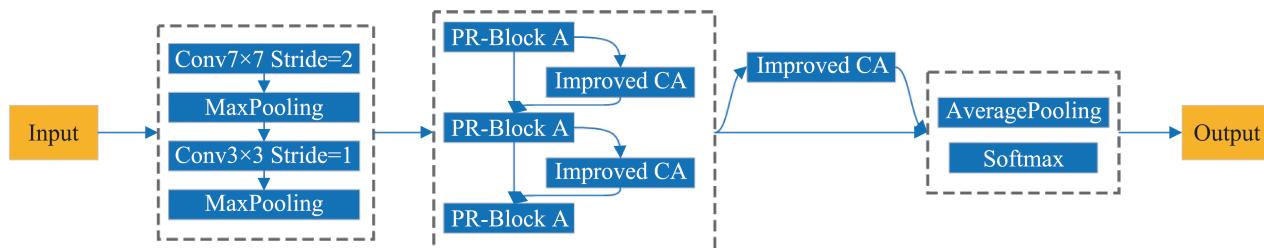


图3 PRC-Net结构图  
Fig. 3 Structure of PRC-Net

## 2.5 PRC-Net优化方法

考虑到改进后的CA中两个注意力块各自独立进行加权操作导致数据的冗余，并且DCA块最小核大小值的聚合效果并没有充分发挥作用，因此，改进后的CA整体赋予了加权并去掉了这两个注意力块中独立的加权操作，优化后的CA模块如图4所示，其中，虚线表示优化前的加权方案。这样做一方面丢弃了大量无用的非病斑特征信息，使病害识别精度进一步提升；另一方面，阻止了病

斑特征数据的多次重复迭代，大大减少了模型训练时间和推理时间。

## 2.6 损失函数

水稻叶部病害的识别属于多分类问题，其推导只与识别正确的概率相关，所以模型训练的损失函数使用Cross-Entropy。

$$\begin{aligned} p &= E_{x \sim P}[-\ln P(x)] \\ q &= E_{x \sim Q}[-\ln Q(x)] \\ H(p, q) &= E_{x \sim P}[-\ln Q(x)] \end{aligned} \quad (1)$$

式中:  $p$ 、 $q$ 、 $H$  分别表示真实样本、期望样本以及二者交叉的信息熵;  $P$  为真实的概率分布;  $Q$  为期望的概率分布。

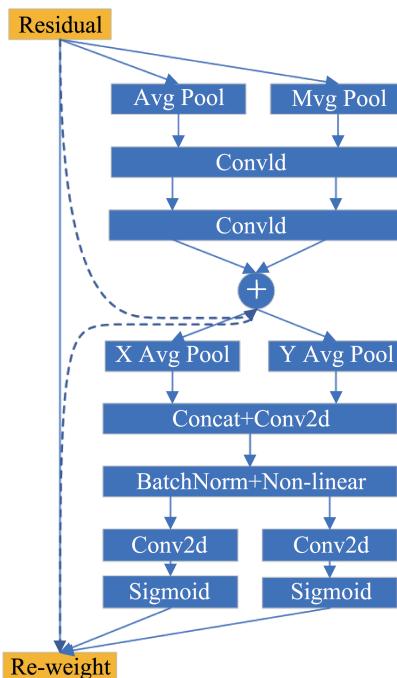


图4 优化后的CA模块结构  
Fig. 4 Structure of optimized CA module

### 3 实验仿真与分析

#### 3.1 实验环境

本实验运行环境处理器为 AMD Ryzen 9 5900X 12-Core 3.7 GHz Desktop CPU, 内存为 32 GB, 显卡为 Nvidia GeForce RTX 2080Ti, 显存为 11 GB, 操作系统 Windows 10。软件系统使用 Jupyter Notebook、python3.8.0、tensorflow-gpu2.4.0、Keras 库和 sklearn 库。

#### 3.2 实验数据集

数据集1: 自制数据集。该数据集根据水稻叶部病害的种类组织图像, 包含稻瘟病、白叶枯病、胡麻斑病、纹枯病、东格鲁病5种水稻叶部病害以及健康叶片图像, 共6个类别, 10 764幅图像, 如图5所示。图像来源于黑龙江八一农垦大学和

黑龙江农科院水稻试验田, 使用手机(HUAWEI Mate40 Pro)拍摄, 分辨率为 2 400 像素  $\times$  1 080 像素。通过 ImageDataGenerator 对图像数据进行批增强处理, 并使用了 WGAN-GP<sup>[19]</sup> 扩充数据集。此时, 数据集图像数量为 13 836 幅。



图5 数据集图像示例  
Fig. 5 Image example of dataset

数据集2: PlantVillage 数据集。包括 54 303 幅农作物健康和受感染的叶片图像, 分为 38 个类别。

#### 3.3 PRC-Net 模型训练

##### 3.3.1 训练过程

对于实验中无特殊说明的所有模型, 输入模型的图像尺寸均为 256 像素  $\times$  256 像素, 并在传输之前进行归一化处理。为了发挥实验设备的最大性能并克服大量数据的问题, 将 batch\_size 的值设置为 16。通过多次对训练集数据的训练迭代分析, 其结果曲线最后在迭代次数为 30 时由初始的未拟合状态逐渐进入过拟合状态。因此, 将 epoch 设置为 30, 并将最佳参数在训练过程中保存。优化算法使用 Adam optimizer 进行模型训练, 其实现简单、计算高效、内存需求低, 并且适用于梯度稀疏和大数据集场景。其中, 学习率设置为 0.001 以帮助模型训练, 提高收敛速度。使用随机选取的方式对数据集图像进行 8 : 2 的训练集与测试集划分, 具体划分如表2所示。

表2 数据集划分

Table 2 Dataset partitioning

类别	训练集数量	测试集数量
稻瘟病	1 689	422
白叶枯病	1 439	480
胡麻斑病	1 478	369
纹枯病	1 415	354
东格鲁病	1 329	332
健康叶片	3 623	906
合计	10 973	2 863

### 3.3.2 不同模型训练损失对比

本文模型训练过程与其过渡模型及 VGG16、ResNet50、InceptionV3、InceptionResNetV2 等经典分类模型在数据集 1 上训练对比，其训练过程严格按照 3.3.1 节中的设置。过渡模型为在 PRC-Net 构建过程中出现的一系列模型，如 PR-Net、CA+PR-Net、Improved CA + PR-Net 等模型。不同模型同坐标下的损失函数变化曲线对比如图 6 所示，随迭代次数的增加，本文模型的损失函数曲线下降最快，且趋势较为平稳。

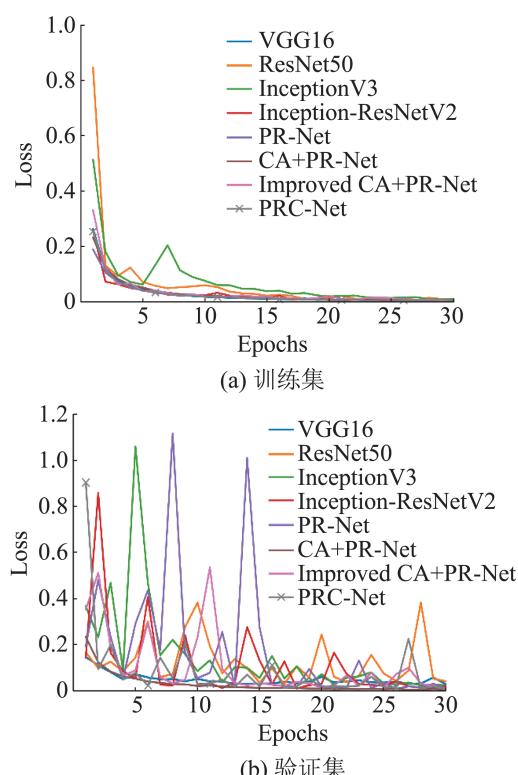


图6 不同模型训练损失对比

Fig. 6 Comparison of training losses of different models

### 3.4 评价指标

对于训练结果，使用准确率、精确率、召回率和 F1 值来评估模型的性能。其中，准确率是识别病害正确的样本数量占总样本数量的比例，是最直观的评价指标。精确率是对于某单一病害识别正确的样本数量占所有识别正确的样本总数的比例。召回率是对于某单一病害识别正确的样本数量占该病害样本总数的比例。F1 值是精确率和召回率的调和平均值，体现了模型的稳健性。

$$\begin{aligned} A &= \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \\ P &= \frac{T_p}{T_p + F_p} \\ R &= \frac{T_p}{T_p + F_n} \\ F_1 &= \frac{2 \times P \times R}{P + R} \end{aligned} \quad (2)$$

式中：A、P、R、 $F_1$  分别为准确率、精确率、召回率和 F1 值； $T_p$  为真阳性； $F_p$  为假阳性； $F_n$  为假阴性； $T_n$  为真阴性。

### 3.5 实验与分析

以 4 组实验为依托，对模型进行充分的训练与测试，对本文模型的有效性和可扩展性进行验证。数据集 2 为非水稻病害图像数据集，仅应用于实验 4，其余实验均使用数据集 1。首先，为验证本文模型的有效性，将其与构建时的过渡模型以及 4 种经典模型进行对比。其次，为验证 DCA 模块中 1D 卷积的核尺寸对 CA 注意力模块及模型整体的影响，训练时分别选取核尺寸大小为 1、2、3、4、5 进行对比研究，分析出适应本文数据集的核尺寸。再次，为验证模型的性能，即模型大小、训练时间和推理时间，将本文模型与其他模型进行对比。最后，为探究模型的可扩展性，使用数据集 2 将本文模型与实验中其他模型及文献[18, 20-23]中提出的模型进行对比。

### 3.5.1 实验1: 模型训练比较

将本文模型与其构建时的过渡模型以及4种经典模型进行对比。其中, CA+MobileNetV2为CA模块, 为文献[18]所提出的模型, 将其引入对比实验以体现本文模型对于水稻叶部病害图像识别的针对性。

由表3可知, PR-Net在测试集上的准确率为99.1%。当PR-Net模型中仅嵌入CA模块时, PR-Net模型于CA模块的集成较差, 这是由于水稻叶部病害病斑的特异性导致的, 测试集的分类准确率降低到了97.03%。然而, 当引入包含CA和DCA的改进的CA模块时, 测试集的准确率达到了99.27%, 对于原PR-Net模型有一定的提升,

说明DCA模块能够有效提升被PR-Block作用后过于分散的病斑特征的聚合程度。优化后得到PRC-Net在测试集上的准确率优于其他经典模型, 获得了最高值。其中, CA+MobileNetV2被应用于数据集1, 测试准确率仅为91.39%。仔细分析了数据, 并考虑了对于数据集1准确率存在差异的原因, 主要在于其模型基于MobileNet V2, 针对的是轻量级设备, 具有更少的参数数量和训练时间, 且其模型提出的目的是识别包含1 000个分类的ImageNet数据集, 研究目标具有很高的差异性, 因此, 实验结果之间存在一定的偏差。由表4可知, 本文模型在精确率和召回率上明显高于其他模型, 体现了本文模型在识别各个单一水稻叶部病害上的优势和模型训练的稳健性。

表3 不同模型训练对比  
Table 3 Comparison of different model training

模型	训练准确率/%	训练损失率	测试准确率/%	测试损失率
VGG16	99.61	0.0075	98.48	0.0283
ResNet50	99.82	0.0540	98.27	0.0410
InceptionV3	99.24	0.0096	98.13	0.0222
InceptionResNetV2	<b>99.87</b>	<b>0.0024</b>	98.51	0.0201
PR-Net	99.55	0.0060	99.10	0.0138
CA + PR-Net	99.62	0.0049	97.03	0.0352
Improved CA + PR-Net	99.56	0.0047	99.27	0.0076
PRC-Net	99.56	0.0054	<b>99.65</b>	<b>0.0073</b>
CA+MobileNetV2	99.36	0.0097	91.39	0.0805

注: 此时PRC-Net为优化结构后的Improved CA + PR-Net。

表4 不同模型评估对比  
Table 4 Comparison of evaluation of different models

模型	指标	0	1	2	3	4	5
VGG16	精确率	0.97	0.97	0.97	0.99	0.99	0.99
	召回率	0.98	0.98	0.96	0.99	0.99	0.99
ResNet50	精确率	0.98	0.98	0.99	0.97	0.99	0.97
	召回率	0.97	0.97	0.96	0.99	0.99	1.00
InceptionV3	精确率	0.97	0.95	1.00	1.00	0.99	1.00
	召回率	0.98	0.98	0.90	0.99	1.00	1.00
Inception-ResNetV2	精确率	0.98	<b>1.00</b>	0.95	1.00	1.00	1.00
	召回率	0.99	0.97	1.00	0.98	0.99	1.00
PRC-Net	精确率	<b>1.00</b>	0.99	<b>1.00</b>	<b>1.00</b>	<b>1.00</b>	<b>1.00</b>
	召回率	<b>0.99</b>	<b>1.00</b>	<b>1.00</b>	<b>1.00</b>	<b>1.00</b>	<b>1.00</b>

注: 0~5标签分别表示数据集1中5种水稻叶部病害以及健康叶片分类。

### 3.5.2 实验2: DCA模块中1D卷积核尺寸验证

为在不改变维度的条件下提高输入CA模块的特征图病斑信息的聚合程度，在DCA模块中引入了两个1D卷积。在实验中，通过调整1D卷积核的尺寸，定性地分析了PRC-Net模型对于水稻叶部病害的识别效果。为验证1D卷积对于改进的CA模块的影响，使用的实验模型为优化前的PRC-Net。实验结果表明：随着核大小值的增长，测试集的分类效果出现了规律性的下降，这是由于水稻叶部病害病斑的大小存在差异，不同类型的病害差异较大，同种类型的病害虽大小相近但仍有不同。随着核尺寸的增加，该模型在训练过程中提取病斑特征信息的范围也在增加，导致大量非病斑特征信息混入其中，在模型的最终分类阶段，非病斑特征信息作为一种干扰因素，阻碍了测试集的分类识别。研究结果表明，本文改进的CA模块对水稻叶部病害的识别具有较好的效果。通过定性核尺寸的实验，得出当核尺寸值为1时，该模型具有最佳的分类性能，因为此时模型以最小的特征信息提取范围获得了更好的特征信息凝聚性并最大限度地抵抗了水稻叶部病害的非病斑特征信息，具有更好的过滤能力。详细的训练结果如表5所示。

表5 不同卷积核尺寸训练对比

Table 5 Comparison of different convolution kernel size training

核尺寸	训练	训练	测试	测试
	准确率/%	损失率	准确率/%	损失率
1	<b>99.56</b>	<b>0.004 7</b>	<b>99.27</b>	<b>0.007 6</b>
2	99.47	0.005 1	98.67	0.011 2
3	99.51	0.005 6	98.53	0.012 6
4	98.95	0.009 3	98.44	0.011 2
5	98.93	0.008 5	98.42	0.012 9

为验证本文提出的改进注意力模块在水稻叶部病害分类与识别上的优势，将其与常见的注意力模块特征提取效果进行对比，并引入PR-Net观察其测试集的验证结果。由图7可知，实验中对比的3个模块，即基于单通道注意力机制的SE模块<sup>[20]</sup>、改进前的CA模块和双通道结合空间注意力

机制的CBAM模块<sup>[21]</sup>中，本文改进模块配合PR-Net取得了最好的效果。从各模块的特征提取效果图像可以发现，准确率较高的SE模块与本文模块的结果图样底色更接近于水稻叶片的原色，突出了病斑的特征信息，本文模块更适应水稻叶部图像，渲染效果更强，具备更好的水稻叶部病斑特征的筛选能力。

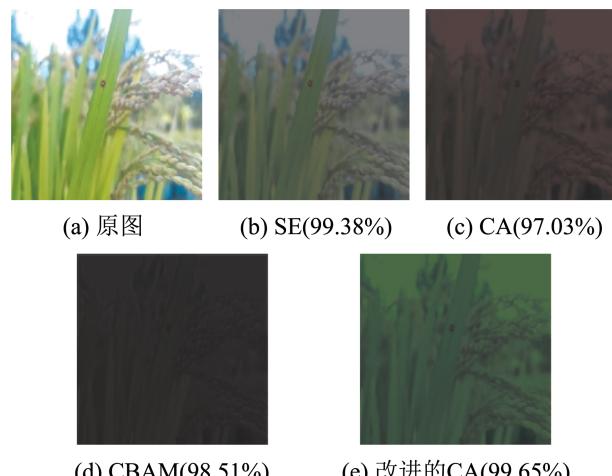


图7 不同注意力模块的特征提取效果和准确率对比  
Fig. 7 Comparison of feature extraction effect and accuracy of different attention modules

### 3.5.3 实验3: 模型性能比较

本文实验对各模型大小、平均迭代时间、总训练时间和推理时间进行了对比，其中，模型大小是模型中所有参数占内存的容量。总训练时间是模型训练从开始到结束所需的时间。每个迭代的时间并不是实际时间，而是总训练时间除以迭代次数的平均时间。推理时间是训练后保存最优参数的模型预测单张图像所需的时间。实验结果表明，PR-Net模型在所有指标均获得了最优的结果。

而将改进的CA模块嵌入PR-Net模块后，虽然模型对于水稻叶部病害的识别精度获得了一些提高，但是模型大小、训练时间、推理时间都出现了大幅度的增长，甚至超过一部分对照模型。考虑到改进的CA模块中两个注意力块各自独立进行加权操作导致数据的冗余，并且DCA模块使用的最小的1D卷积核的聚合效果并没有充分发挥作

用。而优化后的PRC-Net杜绝了这个问题, 使准确率进一步提升至99.65%, 模型训练时间和推理时间大大减少了。相较于其他的图像分类模型, 通过表6可以看出, 本文模型在模型大小, 训练时间和推理时间方面相对于VGG16、ResNet50、InceptionV3和Inception-ResNetV2具有一定的优势。研究表明, 本文模型所占内存更小, 训练时间更短, 识别精度更高。

表6 不同模型性能对比

Table 6 Performance comparison of different models

模型	模型尺寸/ MB	平均迭代时间/ min	总训练时间/ min	推理时间/ s
VGG16	172	1.42	42.72	0.012
ResNet50	285	1.36	40.72	0.013
InceptionV3	259	1.34	40.13	0.011
Inception-ResNetV2	630	2.93	87.90	0.024
PR-Net	<b>43.8</b>	<b>1.02</b>	<b>30.72</b>	<b>0.008</b>
CA+PR-Net	44.5	1.59	47.25	0.013
Improved CA+PR-Net	86.3	1.64	49.22	0.014
PRC-Net	86.3	1.29	38.72	0.010

为验证模型的抗干扰能力, 选取不同时段光线下采集的水稻叶部病害进行模型检验。病害类型选取在实验1测试结果准确率较低的白叶枯病, 模型的推理结果如图8所示。由结果可以看出, 取样时段在清晨和黄昏时结果准确, 但是当时段为正午时却将白叶枯病判断为东格鲁病, 由于正午光线过于强烈, 阳光反射使病斑颜色呈现棕红色导致2个病斑形状相似颜色不同的疾病混淆。该结果反映了本模型训练集存在提升空间, 可增加不同光照强度和模糊程度的样本以提升模型抗干扰能力。



图8 不同时间段推理对比  
Fig. 8 Comparison of reasoning in different time periods

### 3.5.4 实验4: 模型可扩展性验证

为了验证本文模型在作物叶部病害识别的可扩展性, 首先使用本文模型分别对数据集2中研究人员认可度较高的番茄、玉米和土豆进行识别。这3个数据集分别包含10、4和3种病害分类, 图像数量为18 215、3 876和2 160, 实验数据集的划分方式与数据集1相同为8:2。其中, 本文模型对番茄病害的总体识别精度最高, 为99.12%。该模型在识别番茄疮痂病和花叶病时具有100%的准确率。但是模型在识别早疫病时得到的准确率并不高, 仅为92%。尽管本文模型在早疫病的识别方面准确率低于其他模型, 但是总体的识别精度具有一定的优势。对于该方面的问题, 主要是因为早疫病的病斑具有类内差异大、类间差异小的特点, 且这种病害图像数量较少不能使模型充分学习到重要的病斑特征, 从而准确率降低。本文模型对玉米的总体识别精度仅为95.77%, 是这些作物病害中识别效果最差的。该模型对于玉米锈病和大斑病的表现较好, 召回率分别为98%和100%。然而, 并没有对灰叶斑病进行很好的分类, 召回率仅为79%。分析了玉米的混淆矩阵如图9所示, 模型将25幅叶斑病图像识别为了健康叶片, 1幅识别为大斑病。重新观察图像信息发现, 斑病与健康叶片之间的差异太小, 以至于重要的病斑特征信息获取不足, 无法正确的分类。实验结果表明: 相较于Inception-ResNetV2、InceptionV3、VGG16和ResNet50, 本文模型在番茄和土豆的病害识别上取得了最好的效果。尽管在玉米上的表现并不好, 准确率仅为95.77%, 但是与识别该作物效果最好的Inception-ResNetV2的95.9%相比, 误差仅为0.13%, 在可接受范围内, 且本文模型的识别效果要优于其他模型。表7为对番茄、玉米和土豆病害识别的详细结果。

为观察模型多分类任务的极限, 以数据集2整体为研究对象进行分类实验, 实验结果如表8所示。其中, Optimized DenseNet-121<sup>[22]</sup>和VGG-ICNN<sup>[23]</sup>

模型分别是2022和2023年提出的针对于数据集2的先进技术。实验证明本文模型在多分类任务的极限上还有提升空间。

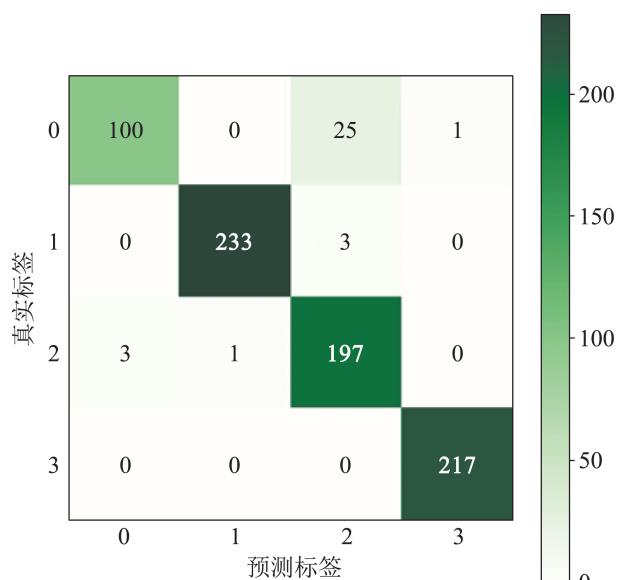


图9 玉米病害识别的混淆矩阵

Fig. 9 Confusion matrix for maize disease identification

表7 识别准确率  
Table 7 Comparison of different crop identification accuracy rates %

模型	番茄	玉米	土豆	%
VGG16	94.24	94.10	96.76	
ResNet50	92.56	94.62	95.37	
InceptionV3	94.54	94.62	97.69	
Inception-ResNetV2	96.16	95.90	96.06	
PRC-Net	99.12	95.77	99.07	

表8 多分类任务对比  
Table 8 Comparison of multi-class tasks

模型	数据集	准确率/%
Optimized DenseNet-121	2(14/38)	98.70
VGG-ICNN	2	99.16
PRC-Net	2	99.07

注：14/38表示该模型在原文仅完成14分类实验。

## 4 结论

针对水稻叶部病害的识别提出了一种结合并列结构和残差结构的混合卷积神经网络模型 PRC-Net。首先，使用残差结构和并行结构组合的

方式构建了一个由2个渐进卷积块组成特征提取模块 PR-Block，该模块具备了2种结构的优势。其次，基于3个PR-Block模块的PR-Net，引入改进的CA模块，增强了模型的重要特征提取能力和凝聚能力。最后，针对模型结构的复杂性，对模型整体结构进行优化处理。实验证明了本文模型高效的性能。PRC-Net相比于过渡模型及其他经典分类模型具有更少的模型参数和训练时间，以及更高的水稻叶部病害识别率，分别达到了86.3 MB、38.72 min 和 99.65%，同时具有面向其他作物病害的可扩展性和泛化能力，有一定的应用价值。在今后的工作中，将重点关注三项任务：第一项任务是扩展数据集中水稻叶部病害的种类，提高模型对于水稻病害的泛化性；第二项任务是在后续的实验中加入图像的干扰因素，增强模型的抗干扰能力；第三项任务是基于本文模型开发水稻病害识别系统，以满足现实场景对于水稻叶部病害识别的需求。

## 参考文献：

- [1] Leidy Rusinque, Carla Maleita, Isabel Abrantes, et al. Meloidogyne Graminicola—A Threat to Rice Production: Review Update on Distribution, Biology, Identification, and Management[J]. *Biology*, 2021, 10(11): 1163.
- [2] Qiu Jing, Lu Xiaolei, Wang Xingxing, et al. Research on Rice Disease Identification Model Based on Migration Learning in VGG Network[J]. *IOP Conference Series: Earth and Environmental Science*, 2021, 680(1): 012087.
- [3] Bashir K, Rehman M, Bari M. Detection and Classification of Rice Diseases: An Automated Approach Using Textural Features[J]. *Mehran University Research Journal of Engineering and Technology*, 2019, 38(1): 239-250.
- [4] Saha S, Ahsan S M M. Rice Disease Detection Using Intensity Moments and Random Forest[C]//2021 International Conference on Information and Communication Technology for Sustainable Development (ICICT4SD). Piscataway, NJ, USA: IEEE, 2021: 166-170.
- [5] Vikas Sharma, Aftab Ahmad Mir, Abid Sarwar. Detection of Rice Disease Using Bayes' Classifier and Minimum Distance Classifier[J]. *Journal of Multimedia Information System*, 2020, 7(1): 17-24.

- [6] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-scale Image Recognition[EB/OL]. (2015-04-10) [2022-10-28]. <https://arxiv.org/abs/1409.1556>.
- [7] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep Residual Learning for Image Recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 770-778.
- [8] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the Inception Architecture for Computer Vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 2818-2826.
- [9] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning[C]//Proceedings of the Thirty-first AAAI Conference on Artificial Intelligence. Palo Alto, CA, USA: AAAI Press, 2017: 4278-4284.
- [10] Niu Zhaoyang, Zhong Guoqiang, Yu Hui. A Review on the Attention Mechanism of Deep Learning[J]. Neurocomputing, 2021, 452: 48-62.
- [11] Hughes D P, Marcel Salathé. An Open Access Repository of Images on Plant Health to Enable the Development of Mobile Disease Diagnostics[EB/OL]. (2016-04-12) [2023-01-03]. <https://arxiv.org/abs/1511.08060>.
- [12] Prabira Kumar Sethy, Baishalee Negi, Nalini Kanta Barpanda, et al. Measurement of Disease Severity of Rice Crop Using Machine Learning and Computational Intelligence[M]//Sasikumar Gurumoorthy, Bangole Narendra Kumar Rao, Gao Xiaozhi. Cognitive Science and Artificial Intelligence: Advances and Applications. Singapore: Springer Singapore, 2018: 1-11.
- [13] Vimal K Shrivastava, Monoj K Pradhan. Rice Plant Disease Classification Using Color Features: A Machine Learning Paradigm[J]. Journal of Plant Pathology, 2021, 103(1): 17-26.
- [14] Subasish Mohapatra, Chandan Marandi, Amlan Sahoo, et al. Rice Leaf Disease Detection and Classification Using a Deep Neural Network[C]//Computing, Communication and Learning. Cham: Springer Nature Switzerland, 2022: 231-243.
- [15] Chen Zhaoyi, Wu Ruhui, Lin Yian, et al. Plant Disease Recognition Model Based on Improved YOLOv5[J]. Agronomy, 2022, 12(2): 365.
- [16] Chen Junde, Zhang Defu, Adnan Zeb, et al. Identification of Rice Plant Diseases Using Lightweight Attention Networks[J]. Expert Systems with Applications, 2021, 169: 114514.
- [17] Jaderberg M, Simonyan K, Zisserman A, et al. Spatial Transformer Networks[C]//Proceedings of the 28th International Conference on Neural Information Processing Systems. Cambridge, MA, USA: MIT Press, 2015: 2017-2025.
- [18] Hou Qibin, Zhou Daquan, Feng Jiashi. Coordinate Attention for Efficient Mobile Network Design[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2021: 13708-13717.
- [19] Gulrajani I, Ahmed F, Arjovsky M, et al. Improved Training of Wasserstein GANs[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2017: 5769-5779.
- [20] Hu Jie, Shen Li, Sun Gang. Squeeze-and-excitation Networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 7132-7141.
- [21] Sanghyun Woo, Jongchan Park, Joon Young Lee, et al. CBAM: Convolutional Block Attention Module[C]//Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 3-19.
- [22] Nandhini S, Ashokkumar K. An Automatic Plant Leaf Disease Identification Using DenseNet-121 Architecture with a Mutation-based Henry Gas Solubility Optimization Algorithm[J]. Neural Computing and Applications, 2022, 34(7): 5513-5534.
- [23] Poornima Singh Thakur, Tanuja Sheorey, Aparajita Ojha. VGG-ICNN: A Lightweight CNN Model for Crop Disease Identification[J]. Multimedia Tools and Applications, 2023, 82(1): 497-520.