

DOI:10.19651/j.cnki.emt.2313609

# 基于 SE-ResNet34 的红火蚁巢穴判别模型<sup>\*</sup>

袁嘉辉<sup>1</sup> 刘蕊<sup>2</sup> 梁虹<sup>1</sup> 周祥<sup>3</sup>

(1. 云南大学信息学院 昆明 650504; 2. 云南大学地球科学学院 昆明 650504; 3. 海南大学植物保护学院 海口 570228)

**摘要:** 红火蚁是近年来侵害我国南方的主要外来入侵物种之一,精确识别红火蚁巢穴是防控红火蚁的关键所在。为解决传统红火蚁防控依赖人工巡视、高风险、效率低的问题,降本增效实现红火蚁巢穴的智能检视,提出了一种基于 ResNet34 改进的红火蚁巢穴判别模型。该模型借助采集于不同地貌特征下的红火蚁巢穴图像,结合数据增强技术进行训练,通过在 ResNet34 的第 1 层卷积层之后和全连接层之前加入 SE 注意力机制模块,提升网络的自适应选择和通道权值调整能力,以提取红火蚁巢穴表面局部非线性的纹理特征。经过 K 折交叉验证试验和超参数探究消融试验,将 SE-ResNet34 与 AlexNet、VGG-16、ResNet18、ResNet34、ResNet50 进行对比,分析得出 SE-ResNet34 的峰值准确率达到了 98.76%,比 ResNet34 的准确率提高了 2.17%,较其他测试模型有训练时间短、识别精度高的特点,同时展现出较强的鲁棒性和稳定性。该方法在减少人工成本的同时可降低杀虫剂的使用,为红火蚁巢穴判别提供了一种便捷高效的解决方案。

**关键词:** 红火蚁巢穴判别;全地形红火蚁巢穴数据集;SE-ResNet34 模型;K 折交叉验证

**中图分类号:** TP391.41 **文献标识码:** A **国家标准学科分类代码:** 520.6

## Red fire ant nest classification model based on SE-ResNet34

Yuan Jiahui<sup>1</sup> Liu Rui<sup>2</sup> Liang Hong<sup>1</sup> Zhou Xiang<sup>3</sup>

(1. School of Information, Yunnan University, Kunming 650504, China; 2. School of Earth Sciences, Yunnan University, Kunming 650504, China; 3. School of Plant Protection, Hainan University, Haikou 570228, China)

**Abstract:** The red imported fire ant (*solenopsis invicta buren*) is one of the major invasive species that has been causing damage in southern China in recent years. Accurately identifying the nests of red imported fire ants is crucial for their prevention and control. In this paper, an improved red fire ant nest identification model based on ResNet34 is proposed to solve the problems of traditional red fire ant prevention and control relying on manual inspection, high risk and low efficiency, so as to realize intelligent inspection. This model uses red imported fire ant nest images collected from different terrain features, combined with data augmentation techniques for training. By adding an SE attention mechanism module after the first convolutional layer of ResNet34 and before the fully connected layer, the model can enhance its adaptive selection and channel weighting adjustment capabilities to extract local nonlinear texture features on the surface of red imported fire ant nests. Through K-fold cross-validation tests and ablation tests to explore hyperparameters, SE-ResNet34 is compared with AlexNet, VGG-16, ResNet18, ResNet34, and ResNet50, and the results show that SE-ResNet34 achieves a peak accuracy of 98.76%, which is 2.17% higher than ResNet34. It has the characteristics of short training time, high recognition accuracy, strong robustness, and stability compared to other tested models. This method provides a convenient and efficient solution for distinguishing red fire ant nests while reducing manual labor and minimizing the use of insecticides.

**Keywords:** red imported fire ant nest discrimination; all-terrain red imported fire ant nest dataset; SE-ResNet34 model; K-fold cross-validation

## 0 引言

红火蚁(*solenopsis invicta buren*)属于膜翅目切叶蚁亚

科火蚁属,起源于拉丁美洲亚马逊原始森林巴拉那河流域,于 20 世纪 40 年代随南美运载农产品船只带入北美洲<sup>[1]</sup>,2000 年后,经由船载运输等途径输入澳大利亚。因红火蚁

收稿日期:2023-05-12

<sup>\*</sup> 基金项目:云南大学第二届专业学位研究生实践创新项目(ZC-22222790)资助

习性凶猛、繁殖能力强,被世界自然保护联盟(International Union for Conservation of Nature, IUCN)列入了 100 种最具有破坏力的入侵生物名单。2003 年我国首次在台湾的桃源和嘉义地区发现红火蚁<sup>[2]</sup>。近年来我国红火蚁疫区数量的增速呈明显上升趋势,据《全国农业植物检疫性有害生物分布行政区名录》显示,红火蚁疫区已覆盖华南、华东、和西南超过 12 个省(区、市)、579 个县(市、区)。

传统的红火蚁防治方法主要采用目视法调查蚁丘数,饵剂诱集法监测红火蚁灾害级别<sup>[3]</sup>,同时施以触杀法和毒饵法消灭蚁群<sup>[4]</sup>。依赖人工巡察的传统防治手段效率较低,且具有一定危险性。为实现无人化红火蚁巢穴巡检,一套高效的识别算法模型尤为重要。

随着图像识别技术的发展,基于深度学习的图像识别技术在农林业以及病虫害防治等领域的应用日渐成熟。Coulbaly 等<sup>[5]</sup>基于 Inception-v3 进行改进,综合迁移学习和数据集增强技术将轻量化处理后的 Inception-v3 模型在 IP102 数据集训练识别多种害虫,其综合准确率达到了 67.88%;龙满生等<sup>[6]</sup>使用随机梯度下降法优化 AlexNet 模型,通过大量对比试验论证了深度卷积神经网络可以较好地提取油茶病害特征,对各病害类别的平均识别准确率达到 96.53%;谢州益等<sup>[7]</sup>提出基于 ResNet18 的特征编码器,引入注意力机制构建残差网络模型<sup>[8]</sup>,对常见的水稻病虫害具有良好的描述效果。与之前使用神经网络算法研究传统的病虫害防治不同,红火蚁在筑巢的过程中改变了土壤的颜色和结构,较周围土壤更为干燥、多孔密度小,蚁穴外部隆起呈土堆状,内部呈蜂窝状,表面土壤颗粒细碎均匀,有明显的纹理特征<sup>[9]</sup>。并且红火蚁巢穴会被落叶、灌木丛干扰,部分蚁穴倚靠路灯、交通指示牌等设施建造,增加了图像识别网络选择的难度。目前国内对红火蚁的研究大多数停留在讨论红火蚁的入侵状况和防治方法上,鲜有运用深度学习技术检测野外环境中的红火蚁巢穴。吴伟斌等<sup>[10]</sup>对红火蚁巢穴建立 HSV 彩色空间模型,根据红火蚁巢穴土壤样本和周边土壤样本的色调通道平均值的差异来鉴定红火蚁巢穴,因输入图像的 HSV 分量值受光照条件、拍摄角度、阴影干扰等多重因素影响,该方法评价结果具有一定局限性;朱立学等<sup>[11]</sup>通过在草坪环境下压缩红火蚁巢穴图像的背景区域,使用超绿模型分割过滤背景噪声,利用红火蚁巢穴与背景的显著差异来鉴定红火蚁巢穴,最终红火蚁巢穴识别的交并比达到了 96.87%,但该方法对于复杂背景条件下的红火蚁巢穴识别局限性较大,缺乏泛化能力。

为解决复杂环境下的红火蚁巢穴识别准确率低的问题,本文提出一种基于 34 层的残差网络(residual network, ResNet)改进的红火蚁巢穴识别模型,该方法引入了压缩与激励网络(squeeze-and-excitation networks, SENet)<sup>[12]</sup>,在 ResNet34 的第 1 层卷积层之后和全连接层之前加入该模块。经 K 折交叉验证试验和超参数消融试验显示,本文

模型能更高效地提取图像特征,加快模型的训练拟合,在红火蚁巢穴识别任务中达到了 98.76% 的准确率,较好地完成了识别任务。

## 1 图像采集与数据集生成

### 1.1 研究区域和数据源

红火蚁巢穴因各地不同的气候条件和土壤类型,其颜色具有差异,考虑到数据集的广泛适用性,本文研究数据集采集自受红火蚁侵害严重的海南省海口市(110°18'51"E、20°4'19"N,海拔 4 m)和云南省昆明市(102°51'19"E、24°49'38"N,海拔 1 843 m)。海口市位于热带地区,气候湿热,主要的土壤类型为砖红壤与赤红壤。昆明市地处亚热带,较热带地区略干燥少雨,土壤以红壤和黄壤为主。从上述两地采集的红火蚁巢穴样本基本能覆盖我国现存的红火蚁巢穴类型。

红火蚁巢穴数据集的拍摄使用 1 200×10<sup>4</sup> pixels 后置摄像头,数据集样本入组标准如下:

- 1) 蚁穴整体图像清晰,人眼观察其需具备纹理特征。
- 2) 花草灌木遮挡不大于图片的 70%,若遮挡超过 50%,需对同一个蚁穴进行至少 3 个角度的拍摄。
- 3) 基于红壤、砖红壤等筑成棕红色的红火蚁巢穴须占数据集的 40%;基于黄壤、黄红壤等以筑成黄色的红火蚁巢穴须占数据集的 50%;以灰钙土或在较干旱的土壤条件下构筑成浅色甚至白色的红火蚁巢穴须占数据集的 10%。

按照上述标准最终筛选出了 527 张图像作为红火蚁巢穴正样本,同时拍摄了 482 张类红火蚁巢穴土壤图样、草木稀疏的土地图像作为类蚁穴负样本,数据集的示例如图 1 所示。




图 1 数据集示例

### 1.2 图像预处理及数据集增强

红火蚁巢穴的精确识别面临诸多问题:一方面受到天气、拍摄角度、设备噪声等因素的影响;另一方面,灌木和草丛环境中存在土壤环境多变、背景不同、遮挡、光影等因素干扰,因此不同红火蚁巢穴之间在轮廓信息,纹理特征等方面都存在着一定差距,不能直接将拍摄的图像送入模型中训练。

为模拟上述因素的影响,使得本文的数据集尽可能符

合实际应用场景,减少训练出模型的过拟合风险,需要增强现有数据集。本文对原始图像进行色彩重置(对比度和亮度增强30%/减弱30%)以模拟不同天气情况,添加高斯噪声以模拟图像采集时的设备噪声,对原图水平镜像、旋转90°、旋转180°和仿射变换以模拟拍摄状态的变化。综合以上方法得到的增强后的数据集数据量是原来的8倍,数据集增强效果如图2所示,将输入模型数据集的图像尺寸统一调整为 $512 \times 512$  pixels,增强后整个数据集有正样本3410张,负样本1960张。




图2 图像增强示例

## 2 研究方法

### 2.1 分类网络模型

图像分类是深度学习(deep learning)的应用场景之一,其思想是利用已有的数据集训练得到一个神经网络模型,且该模型能够尽量拟合所需要的预测结果。卷积神经网络(convolutional neural networks, CNN)是深度学习的主要方法,它能够从输入图像中自动获取特征,通过共享权重和局部连接来减少或解决过拟合问题,使得其对于图像分类问题有着良好的适应性<sup>[13]</sup>。卷积神经网络模型由输入层(Input Layer)、卷积层(Conv Layer)、池化层(Pooling Layer)、全连接层(FC Layer)以及输出层(Output Layer)几部分组成,其中,卷积层是构造卷积神经网络的关键,主要功能是提取包含多重卷积核的输入数据的特征。池化层通常在连续的卷积层之后,主要是一种下采样操作,以减少特征映射的特征空间和网络结构中的参数量<sup>[14]</sup>。全连接层通常位于最后,完成最后的图像分类。

#### 1) 残差网络

残差网络解决了传统卷积神经网络层数增多时的梯度消失和梯度爆炸问题<sup>[15]</sup>。最常用的残差网络是ResNet34、ResNet50、ResNet101,其中ResNet34在兼顾了识别精度和实时性的同时,较好的适配了本文识别出图像中的红火蚁巢穴这一目的。ResNet34模型的主体网络结构由多个卷积层组成,其具体参数如表1所示。每个卷积层又由数量不等的残差块(Residual Block)构成。

假设模型的拟合目标函数为 $H(x)$ ,非线性叠加层为 $P(x)$ ,经典的神经网络模型是使 $P(x)$ 逼近 $H(x)$ 。但是

表1 ResNet34网络结构参数

层级名称	块尺寸/pixel	输出尺寸/pixel
Conv1	$7 \times 7$	$112 \times 112$
Max pool	$3 \times 3$	$56 \times 56$
Conv2_x	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$56 \times 56$
Conv3_x	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$28 \times 28$
Conv4_x	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$14 \times 14$
Conv5_x	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$7 \times 7$
Average pool	$3 \times 3$	$1 \times 1$
FC-1000, softmax		

随着网络层数的增加,逼近 $H(x)$ 的效果难以满足要求,因此模型使用了残差块,其结构如图3所示。




图3 残差块

通过捷径连接(shortcut connection)的方式,使得 $P(x)$ 逼近 $H(x)-x$ ,让浅层特征恒等映射到深层,并且在反向传播的过程中深层梯度可以直接传回浅层,有效避免了网络退化问题的发生,且保证了主线输出特征矩阵的高、宽、深度一致。最终通过不断堆叠网络层数,获得深度较大的网络模型和更好的网络性能<sup>[16]</sup>。

用数学符号可详细定义残差块的工作原理,假设第 $l$ 个残差块的输出特征为 $y_l$ ,则有:

$$y_l = h(x_l) + F(x_l, w_l) \quad (1)$$

$$x_{l+1} = f(y_l) \quad (2)$$

其中, $x_l$ 是第 $l$ 个残差单元的输入, $F$ 表示残差单元的计算过程, $w_l = \{w_{l,k} | 1 \leq k \leq K\}$ 是第 $l$ 个残差单元的系列权重, $h(x_l) = x_l$ 表示 shortcut 回路, $f$ 表示激活函数。若令 $x_{l+1} = f(y_l) = y_l$ ,忽略激活函数的影响,对任意第 $L$ 层有:

$$x_{l+1} = x_l + F(x_l, w_l) \quad (3)$$

$$X_L = x_l + \sum_{i=1}^{L-1} F(x_i, w_i) = x_0 + \sum_{i=0}^{L-1} F(x_i, w_i) \quad (4)$$

根据反向传播的链式法则,有:

$$\frac{\partial \epsilon}{\partial x_i} = \frac{\partial \epsilon}{\partial x_L} \cdot \frac{\partial x_L}{\partial x_i} = \frac{\partial \epsilon}{\partial x_L} \left( 1 + \frac{\partial}{\partial x_i} \sum_{i=1}^{L-1} F(x_i, w_i) \right) = \frac{\partial \epsilon}{\partial x_L} + \frac{\partial \epsilon}{\partial x_L} \cdot \frac{\partial}{\partial x_i} \sum_{i=1}^{L-1} F(x_i, w_i) \quad (5)$$

式(5)是残差网络可以有效提取复杂特征信息的理论根基,其中  $\epsilon$  为损失函数,它度量了模型的预测输出与实际标签之间的差异。对于 ResNet34 的第  $L$  层的输出  $x_i$ ,本文希望计算关于损失函数  $\epsilon$  的梯度  $\frac{\partial \epsilon}{\partial x_i}$ ,从而了解损失函数相对于模型参数的变化情况,以指导参数的更新方向和幅度。

由式(5)可知,深层  $L$  的梯度可以直接传递到次级浅层,导致信息可以在各层级间相互传递,且求和项不能恒等于 -1,因此残差网络中不会出现梯度消失的问题。

## 2) 注意力机制

红火蚁巢穴大多分布在灌木、树林、草原、荒地等复杂的环境下,样本图片背景复杂多样,且图片背景信息占整幅图片的大部分,在 ResNet34 网络大量卷积层迭代时,图像背景的不断重复会形成大量的冗余信息,影响模型对红火蚁巢穴的特征学习。为进一步提升模型的准确率和有效性,本文根据红火蚁巢穴独特的纹理形态特征,在原有的网络框架中加入了注意力机制层,将模型特征提取的注意力集中在核心区域,为不同的特征分配权重。SENet 模块,通过建模卷积特征通道之间的相互依赖关系提高网络的表达能力,是通道注意力机制的典型实现<sup>[17]</sup>,结构如图 4 所示,




图 4 SENet 结构

将 SENet 模块插入到 Conv1 和 Conv5 之后,将赋权重的特征输入全连接层进行分类输出,最终得到本文用于红火蚁巢穴图像判别的 SE-ResNet34 模型结构,如图 5 所示。其中批归一化(batch normalization, BN)层对输入图像进行标准化处理,加速模型收敛。在浅层卷积(Conv1)后加入 SENet 模块,能有效提高模型对红火蚁巢穴特征的重点关注,减少冗余信息和噪声对深层网络的干扰,同时加快模型的训练速度。使用 Grad-CAM 方法可视化最后一个卷积层(Conv5)的语义信息,得到本文模型对红火蚁巢穴特征提取的热力图,原图与热力图对比如图 6 所示。其中颜色越深则表示语义信息越丰富,对识别的贡献率越高。观察得出图中红线区域内为颜色最深部分,与左侧原图中红火蚁巢穴在图中的位置基本重合,因此可初步肯定本文模型的特征提取能力。

其主要工作原理步骤如下:

(1) Squeeze 将特征  $U$  跨空间维度  $H \times W$  的特征映射进行聚合,生成一个通道描述符  $z_c$ ,将全局空间信息运用全局池化的方法压缩到通道描述符中,如式(6)所示。

$$z_c = F_{sq}(t_c) = \frac{1}{H \times W} \sum_{i=1}^W \sum_{j=1}^H t_c(i, j) \quad (6)$$

式中:  $t_c$  表示输入特征图的通道描述符,  $i$  和  $j$  分别代表各通道和空间维度的索引。

(2) Excitation 将步骤(1)得到的  $z_c$  通过一个全连接层,将得到结果输入到 ReLU 激活函数中,再通过一个全连接层,最后通过 Sigmoid 激活函数,如式(7)、(8)所示。

$$\text{Sigmoid}(z) = \frac{1}{1 + e^{-z}} \quad (7)$$

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z)) \quad (8)$$

式中:  $\delta$  代表 ReLU 激活函数,  $\sigma$  代表 Sigmoid 激活函数,  $W_1$ 、 $W_2$  为全连接层,  $W_1$  的维度为  $C \times r \times C$ ,  $W_2$  的维度为  $C \times r \times C$ 。

(3) Reweight 操作将每个通道的权重  $S_c$  和特征图  $u_c$  按照通道相乘得到加权后的  $\tilde{t}_c$ ,最终得到按通道加权的输出  $\tilde{T}$ 。如式(9)、(10)所示。

$$\tilde{t}_c = F_{scale}(U_c, S_c) = S_c u_c \quad (9)$$

$$\tilde{T} | \tilde{t}_1, \tilde{t}_2, \tilde{t}_3 | \quad (10)$$

式中:  $F_{scale}(u_c, s_c)$  表示对输入特征图  $u_c$  中的每个通道进行逐元素乘法。

## 2.2 试验设计

### 1) 试验方法——K 折交叉验证

为探究更加适合红火蚁巢穴分类识别的模型,同时减少数据集损失,提高样本使用效率,减少模型在某一段特定的数据集上表现好的可能性,本文使用 K 折交叉验证(K-fold cross-validation)<sup>[18]</sup>的试验方法,该方法原理如图 7 所示。该方法是指将数据集划分为容量相等、内容互斥的  $K$  个子集,其中每个子集都不重复地作为一次测试集,其余的  $K-1$  个子集则组成训练集。这样,可以进行  $K$  轮训练和测试,每轮都使用不同的测试集和训练集。最后,将这  $K$  次测试结果的平均值作为模型的性能指标。本文对红火蚁巢穴数据集进行 5 折验证,每一折的测试准确率输出为  $E_k$ ,  $k \in [1, 5]$  最后取每次训练结果的平均值,如式(11)所示,作为评价各分类模型对红火蚁巢穴的识别能




图 5 本文模型整体结构




图 6 原图像与 Grad-CAM 热力图

力的评价标准。

$$\bar{E} = \frac{1}{5} \sum_{k=1}^5 E_k \quad (11)$$

2) 试验环境

本文试验环境基于 Windows10 专业版操作系统,硬件配置为 12th Gen Intel(R) Core(TM) i9-12900K 3.20 GHz 处理器和 NVIDIA GeForce RTX 3070 显卡,显存大小为 8 GB,驱动程序版本为 31.015.2698。采用 Pytorch1.13.0 深度学习框架进行训练学习,并配置 Cuda11.7 版本和 CudNN8.5.0 版本对训练加速,Python 版本为 3.9.15,训练的同时用 TensorBoard 2.10.0 同步监测准确率(Acc)的数值动态和收敛趋势。

3) 参数设置与试验设计

(1)为探究 SE-ResNet34 模型加入注意力机制对本文红火蚁巢穴数据集的分类效果较其他模型的提升,在设置所有超参数一致时用本文模型与 AlexNet、VGG-16、

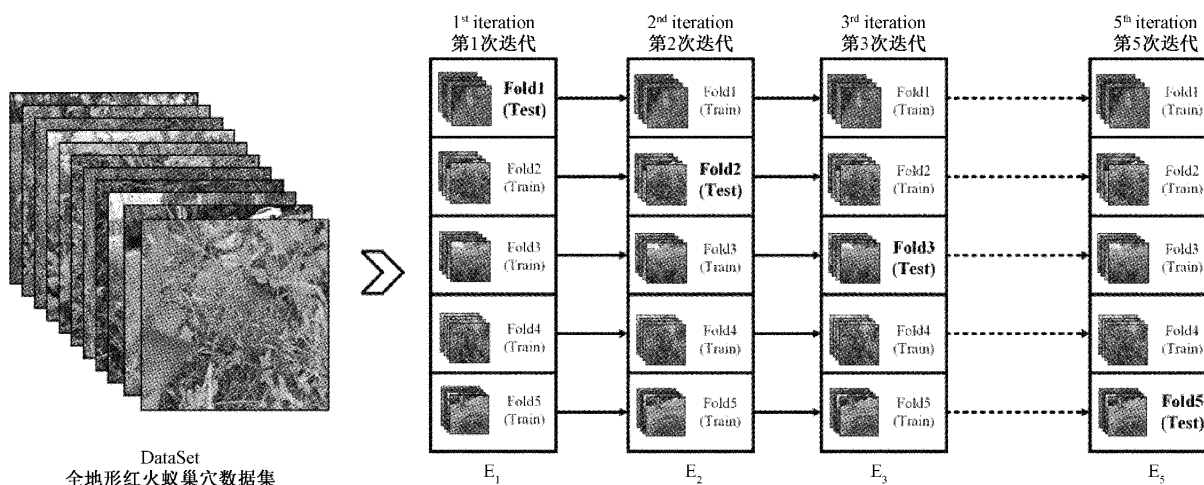


图 7 K 折交叉验证示意图

ResNet18、ResNet34、ResNet50 进行 6 组 5 折交叉验证对比。模型训练和测试均通过 GPU 加速,综合考虑硬件性能和训练时间,测试和训练的批次样本数(Batch-Size)均设置为 16,最大训练轮数为 50 个 epoch,每一个 epoch 输出一测试准确率,初始学习率设置为 0.001,同时选择改进了梯度滑动平均和偏差修正的自适应矩估计优化器(adaptive moment estimation, Adam)<sup>[19]</sup>,根据训练过程中

的梯度信息自动调整学习率,从而平衡训练速度和模型性能的关系。损失函数选择交叉熵损失(cross entropy loss)函数,维持正向积极的学习速率。

(2)在 5 折交叉验证试验的基础上,为探究 Batch-Size 的设定对红火蚁巢穴数据集训练效率的影响,训练出最佳红火蚁巢穴检测模型,综合考虑试验复杂程度,在其他超参数与试验(1)相同的情况下,用本文模型与移除 SENet

模块后的 ResNet34 设置 3 种批次样本数 (Batch-Size = 8、16、32) 共进行 6 组消融试验, 从原始数据集中以 7:3 划分训练集和测试集, 用前文试验得出的最优模型在 3 759 张红火蚁巢穴数据集上训练, 在 1 611 张数据集中测试, 增加训练次数至 100 个 epoch, 同时验证 5 折交叉验证试验结果的正确性。

### 3 结果与分析

#### 3.1 交叉验证

通过 5 折交叉验证评估 2.2 节引中各模型对红火蚁巢穴数据集在测试集上的平均峰值准确率, 作为本轮试验的

评价指标。各模型综合测试准确率如表 2 所示, 6 种模型的测试准确率曲线如图 8 所示。

表 2 各模型测试集的平均峰值准确率

神经网络	训练时间/h	测试准确率/%
AlexNet	0.72	90.01
VGG16	1.23	92.05
ResNet18	0.93	92.28
ResNet34	0.90	94.13
ResNet50	0.89	95.74
本文模型	0.81	97.17




图 8 5 折交叉验证测试准确率曲线

结合表 2 和图 8 可知, AlexNet 在约 20 个 epoch 后趋于收敛, 因其结构层级较为简单, 完成分类任务的时间最短, 准确率很快达到一定阈值且处于较低水平, 因此 AlexNet 在执行红火蚁巢穴识别任务时效果一般; VGG16 模型收敛速度较慢, 约在 20 个 epoch 以后收敛, 35 个 epoch 后趋于稳定, 其准确率与 ResNet18 相近, 但整体训练时间较后者更长; ResNet18 在约 15~20 个 epoch 后趋于收敛, 其准确率在  $90\% \pm 5\%$  的区间内变化, 较其他模型震荡幅度较大, 且每一折的准确率曲线大部分不重合, 无法满足红火蚁巢穴识别需稳定、高效的要求; ResNet34、ResNet50 在训练任务中表现相似, 在约 10 个 epoch 后趋于收敛, 在本文二分类的目的下展示出较快的收敛速度, 但在 30 个 epoch 后, ResNet34 准确率曲线较 ResNet50 重合率更高, 峰值准确率高于后者约 1.61%, 因此 ResNet34 在本文红火蚁巢穴数据集中展现出了更高鲁棒性和更强的泛化能力。在 ResNet34 中按图 5 所示的方式添加 SE

注意力机制, 模型分类能力得到了进一步提升, 以较短的时间完成了训练, 峰值准确率达到到了 97.17%, 各折曲线没有较大震荡且重合度较高。综上, 可初步判断本文模型对红火蚁巢穴图片的判别能力较优, 但 K 折交叉验证是在较少的数据子集上进行的, 模型的性能可能对特定的数据划分和验证集选择敏感。因此还需进一步试验来评估本文模型的泛化能力和稳定性。

#### 3.2 最优超参数与模型预测

对比不同超参数设定的 6 组试验, 各组测试结果如表 3 所示, 各组测试准确率曲线如图 9 所示。

结合表 3 和图 9 可知, 对 ResNet34 模型添加 SE 注意力机制可以增强模型对红火蚁巢穴的识别能力, 同时提高模型的鲁棒性和稳定性。编号为 4、5、6 的试验组整体准确率高于 1、2、3 组, 提升效果最好的一组可提高准确率 2.75 个百分点 (试验编号 3、6)。批次样本数的设置最高会使测试结果有 1.92% 的偏差 (试验编号 2、3)。当 Batch-Size 为

表 3 超参数探究消融试验结果

编号	神经网络	批次样本数	训练时间/h	识别准确率/%
1		8	1.51	95.93
2	ResNet34	16	1.08	96.59
3		32	0.92	94.67
4		8	1.32	97.84
5	本文模型	16	0.81	98.76
6		32	0.79	97.42

8 时,因为每次迭代使用的样本数较少,模型的参数更新会受到部分噪声干扰,相比其他组曲线震荡幅度更大,识别准确率比同模型最高准确率组低 0.92%(试验编号 4、5);当 Batch-Size 设置为 32 时模型在约 15 个 epoch 趋于收敛,收敛速度最快(试验编号 3、6),但模型对训练数据过于拟合,整体准确率在同组表现最差,若继续上调 Batch-Size 过拟合现象会更严重;当 Batch-Size 设置为 16 时模型可达到最佳识别效果,且测试准确率曲线在同模型下最为稳定(试验编号 2、5),打印 2 组和 5 组的由 Adam 优化器优化模型完成训练后修正的学习率为 0.000 1。




图 9 各组试验测试准确率曲线

综上,使用 SE-ResNet34 模型设置批次样本数为 16 的一组表现出最优秀的性能,对红火蚁巢穴的识别准确率达到了 98.76%(试验编号为 5)。

## 4 结 论

根据红火蚁巢穴所处环境的复杂地貌特征,本文基于 ResNet34 神经网络模型进行改进,引用 Squeeze-and-Excitation 注意力机制提出了一种红火蚁巢穴判别模型。最终在本文原创红火蚁巢穴数据集上进行训练和测试,改进的 SE-ResNet34 模型的识别准确率高于 ResNet34 模型 2.17%,达到了 98.76%,体现了该模型复杂地貌特征下红

火蚁巢穴识别的优越性。在后续的研究中将继续丰富红火蚁巢穴数据集,以进一步提升模型的泛化能力和准确性。

## 参考文献

- [1] 陆永跃,曾玲. 发现红火蚁入侵中国 10 年:发生历史、现状与趋势[J]. 植物检疫, 2015, 29(2): 1-6.
- [2] 杨天赐,刘晓辉,徐晓霞,等. 外来入侵红火蚁持续扩散现状及影响因素[J]. 中华卫生杀虫药械, 2022, 28(3): 270-274.
- [3] ASCUNCE M S, YANG C C, OAKEY J, et al. Global invasion history of the fire ant *Solenopsis invicta*[J]. Science, 2011, 331(6020): 1066-1068.
- [4] 罗全丽. 黔南州红火蚁监测及防控措施[J]. 现代农业科技, 2019, 746(12): 89-90.
- [5] COULIABLY S, KAMSU-FOGUEM B, KAMISSOKO D, et al. Explainable deep convolutional neural networks for insect pest recognition [J]. Journal of Cleaner Production, 2022: 133638.
- [6] 龙满生,欧阳春娟,刘欢,等. 基于卷积神经网络与迁移学习的油茶病害图像识别[J]. 农业工程学报, 2018, 34(18): 194-201.
- [7] 谢州益,冯亚枝,胡彦蓉,等. 基于 ResNet18 特征编码器的水稻病虫害图像描述生成[J]. 农业工程学报, 2022, 38(12): 197-206.
- [8] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition, Washington DC: IEEE, 2016: 770-778.
- [9] 陆永跃,曾玲,许益鏖,等. 外来物种红火蚁入侵生物学与防控研究进展[J]. 华南农业大学学报, 2019, 40(5): 149-160.
- [10] 吴伟斌,游展辉,洪添胜,等. 基于计算机视觉技术的红火蚁巢穴探测[J]. 河南农业大学学报, 2017, 51(2): 184-188.
- [11] 朱立学,黄培峰,黄伟锋,等. 基于图像处理技术的红火蚁检测识别[J]. 农业工程学报, 2022, 38(11): 344-350.
- [12] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 42(8): 2011-2023.
- [13] MAEDA-GUTIERREZ V, GALVAN-TEJADA C E, ZANELLA-CALZADA L A, et al. Comparison of convolutional neural network architectures for classification of tomato plant diseases [J]. Applied Sciences, 2020, 10(4): 1245.
- [14] ZHAO X, LI K Y, LI Y X, et al. Identification

- method of vegetable diseases based on transfer learning and attention mechanism [J]. Computers and Electronics in Agriculture, 2022, 193(4): 106703.
- [15] GENG L, XU WL, ZHANG F, et al. Dried jujube classification based on a double branch deep fusion convolution neural network [J]. Food Science and Technology Research, 2018, 24(6): 1007-1015.
- [16] 孙龙清,王新龙,王泊宁,等. 基于 ResNet-CA 的鱼群饱腹程度识别方法 [J]. 农业机械学报, 2022, 53(S2): 219-225,277.
- [17] 刘韵婷,于清淞,李绅科,等. 基于深度学习的多模型融合图像智能检测方法研究[J]. 电子测量技术, 2021, 44(20):168-174.
- [18] NTI I K, NYARKO-BOATENG O, ANING J. Performance of machine learning algorithms with different K values in K-fold cross-validation [J]. International Journal of Information Technology and Computer Science, 2021, 13(6): 61-71.
- [19] 董正琪,姜杰,赵雪成,等. Adam 优化的 BP 神经网络地铁空调环境模式检测[J]. 电子测量技术, 2022, 45(24): 111-117.

### 作者简介

**袁嘉辉**, 硕士, 主要研究方向为图像分类及目标检测的相关应用。

E-mail:joseph\_yung@sina.com

**刘蕊**(通信作者), 博士, 副教授, 主要研究方向为环境遥感和图像处理。

E-mail:ruil529@ynu.edu.cn

**梁虹**, 教授, 主要研究方向为深度学习和信号处理。

E-mail:liangh@ynu.edu.cn

**周祥**, 教授, 主要研究方向为农业昆虫与病虫防治。

E-mail:zhouxiang017@Hainanu.edu.cn