

吴洪昊, 孙娟. 基于迁移学习的多类别黄瓜叶片病害识别[J]. 智能计算机与应用, 2024, 14(10): 176-181. DOI: 10.20169/j.issn.2095-2163.241025

基于迁移学习的多类别黄瓜叶片病害识别

吴洪昊, 孙娟

(盐城农业科技职业学院, 江苏 盐城 224051)

摘要: 黄瓜病害识别存在准确率不高、计算耗时较长等问题, 本文提出一种用于黄瓜叶片病害识别的改进框架。首先在特征提取阶段, 对 VGG19 和 Inception V3 模型使用迁移学习进行训练, 采用并行最大协方差 (PMC) 进行信息融合, 其次利用鲸鱼优化算法进行特征优化, 最后使用监督学习算法对选定的最佳特征进行分类。利用本文构建的数据集, 算法准确率提高至 96.5%, 耗时 45.28 s, 优于传统算法。

关键词: 迁移学习; 鲸鱼优化算法; 病害识别

中图分类号: TP391.41

文献标志码: A

文章编号: 2095-2163(2024)10-0176-06

Multi-class cucumber leaf disease recognition based on transfer learning

WU Honghao, SUN Juan

(Yancheng Agricultural College, Yancheng 224051, Jiangsu, China)

Abstract: Cucumber disease identification faces challenges such as low accuracy and long computation time. This paper proposes a novel framework for cucumber leaf disease recognition. Firstly, in the feature extraction stage, VGG19 and Inception V3 models are trained using transfer learning, and Parallel Maximum Covariance (PMC) is employed for information fusion. Secondly, the Whale Optimization Algorithm (WOA) is utilized for feature optimization. Finally, supervised learning algorithms are used to classify the selected optimal features. Utilizing the dataset constructed in this paper, the algorithm achieves an accuracy of 96.5% with a computation time of 45.28 s, outperforming traditional algorithms.

Key words: transfer learning; Whale Optimization Algorithm; disease recognition

0 引言

受尺度变化、形状、对比度和颜色等因素的影响, 黄瓜病害分割识别是一项具有挑战性的任务。研究人员提出了很多方法来有效检测黄瓜病害。Zhang 等学者^[1]提出了一种用于黄瓜病害分类的稀疏编码技术 (F-KNN)。利用 K 均值聚类, 按部分和形状分割黄瓜叶片。通过减少计算量提高了分类准确率, 但鲁棒性较差。Zhang 等学者^[2]对黄瓜病害进行了基于支持向量机的分类 (C-SVM、Q-SVM), 模型泛化能力较强, 耗时长, 对于一些复杂的非线性问题, 需要使用更复杂的核函数或者其他方法。Zhang 等学者^[3]利用直方图导向梯度金字塔的对数频率变化 (P-HoG) 和期望最大化技术有效识别黄瓜病害, 取得了较好的分类效果。

Lin 等学者^[4]提出了一种基于语义分割的方法识别白粉病, 并且在单个种类的白粉病上实现了 96.8% 的平均准确度, 但存在数据需求量大等问题。Zhang 等学者^[5]提出的特征选择方法 (ESD) 对 3 种黄瓜病害进行识别, 准确率达到 96%, 但鲁棒性较差, 精度不稳定。Zhang 等学者^[6]提出了一种用于识别黄瓜病害的全局扩张 CNN 模型 (W-KNN)。该方法有效地识别了黄瓜的 6 种不同病害, 准确率达到 94.65%。Ma 等学者^[7]提出了一种基于深度 CNN 模型 (EB-Tree) 的黄瓜炭疽病、白粉病、叶斑病、霜霉病四种病害的识别方法, 准确率达到 93.4%。尽管以上研究在黄瓜病害识别率上均取得一定的进展, 但耗时较长。

本文为了进一步提升识别黄瓜病害的准确率, 提高计算效率, 将不同的深度 CNN 模型特征连接起

基金项目: 2024 年度江苏省青年科技人才托举工程 (盐城市科协资助); 2024 年盐城市重点研发计划。

作者简介: 吴洪昊 (1993-), 男, 硕士研究生, 主要研究方向: 智能控制, 人工智能。Email: ycswwhh@163.com

收稿日期: 2024-03-20

来以获得更好的精度。

通过选择稳定的特征进行分类,利用多种优化技术获得更好的结果。基于此提出了一种新的用于黄瓜叶片病害识别的改进框架。在这项工作中,取得了以下主要贡献:

- (1) 根据准备好的黄瓜叶病数据集,微调 VGG19 和 Inception V3。
- (2) 提出了一种新的特征融合方法—并行最大协方差(PMC)。
- (3) 实现了一种用于选择最佳特征的鲸鱼优化算法。

1 材料与方法

本文采用 ES-KNN 分类器(Ensemble of Subset of K-Nearest Neighbours)以较低的计算成本实现了具有竞争力的性能。设计的 ES-KNN 分类器,包括 3 个部分(如图 1 所示):

- (1) 使用迁移学习实现预训练的深度 CNN 模型,用于深度特征提取。
- (2) 对深度提取的特征进行融合。
- (3) 使用鲸鱼优化算法优化提取的特征,并执行分类。

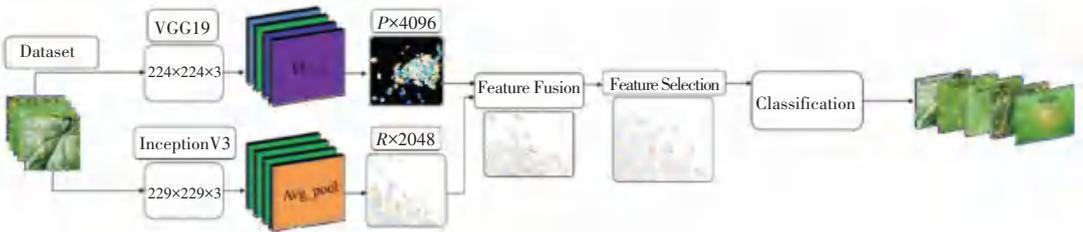


图 1 该项目的黄瓜病害识别方法

Fig. 1 Cucumber leaf disease recognition method in the paper

1.1 深度特征提取

CNN 模型^[8]主要由卷积层、池化层、全连接(FC)层以及一个 *ReLU* 激活函数组成^[9]。本文使用预先训练的深度 CNN 模型 Inception V3^[10] 和 VGG19^[11] 进行特征提取。研究中利用黄瓜数据集进行深层特征提取,并采用 70:30^[12] 的方式进行训练和测试。在此基础上,对输入层图像进行预处理,根据输入层的大小调整图像尺寸。在 VGG19 模型中,利用第一个卷积层作为输入层,在 FC 层上加以激活并进行特征提取,得到 1x4 096 的特征向量。 ψ^1 表示使用 VGG19

提取的特征向量。用于特征提取的结构如图 2 所示。同时还利用 Inception V3 进行特征提取。卷积层用作输入,平均池用于执行激活,进行特征提取。通过对平均池层进行激活,提取出 1x2 048 大小的特征图,特征向量用 ψ^2 表示。在训练和测试阶段,将从 Inception V3 和 VGG19 中提取的特征连接起来。Inception V3 的详细架构如图 3 所示,这里通过修改深度学习模型,使用 *Sigmoid*^[13] 作为训练函数。其他参数如下:历元数 200;每个历元的迭代次数为 30;最小批量为 64;学习率为 0.000 1。

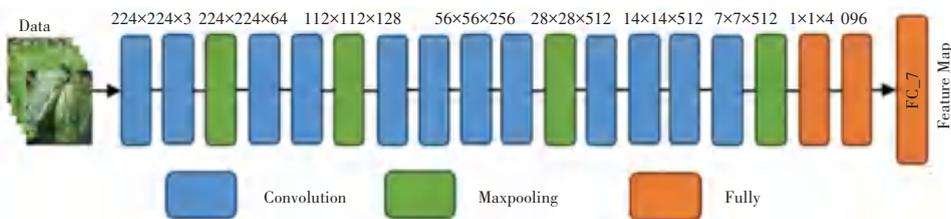


图 2 特征提取结构图

Fig. 2 Diagram of the structure of feature extraction

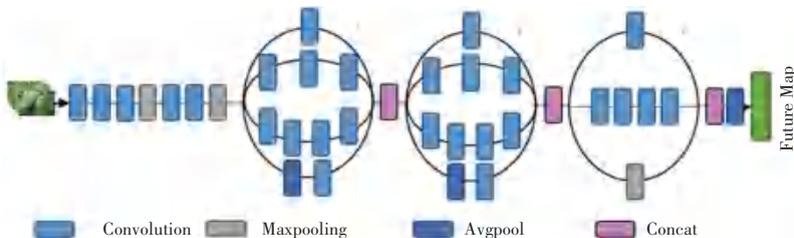


图 3 使用迁移学习进行特征提取的预训练 InceptionV3 架构

Fig. 3 Pre-trained InceptionV3 architecture for feature extraction using transfer learning

1.2 特征融合

特征融合是模式识别领域的一个热门研究课题^[14]。目标分类需要一个强大而稠密的特征空间,特征融合是解决这一问题的方法。特征融合在获得准确结果方面起着至关重要的作用,但会严重影响计算成本。本文提出了一种新的特征融合方法—并行最大协方差(PMC)^[15]。融合过程均衡了特征空间的大小,得到单一的特征向量,假设有2个由 ψ^1 和 ψ^2 表示的深度CNN特征空间,其维数为 $p \times q$ 和 $p \times r$ 。这里, p 表示特征映射中的图像, q 表示使用VGG19提取的特征向量 $p \times 4096$ 的维数。Inception V3^[16]特征图尺寸表示为 $r \times 2048$ 。研究中添加填充的平均值来均衡2个特征映射的长度。假设 \mathbf{a} 表示模式场 ψ_1 中的列向量 \mathbf{m} , \mathbf{b} 表示模式场 ψ_2 中的列向量,使用时间序列的行向量投影^[17]可由如下公式进行描述:

$$y_1 = \psi_1^T \psi^1 \quad (1)$$

$$y_2 = \psi_1^T \psi^2 \quad (2)$$

最大协方差为:

$$c = Cov[y_1, y_2] \quad (3)$$

$$c = Cov[\psi_1^T \psi^1, \psi_1^T \psi^2] \quad (4)$$

$$c = \frac{1}{n-1} Cov[\psi_1^T \psi^1, \psi_1^T \psi^2] \quad (5)$$

$$c = \psi_1 (C_{\psi_1 \psi_2}) \psi_2 \quad (6)$$

$$C_{\psi_1 \psi_2} = \frac{1}{n-1} (\psi^1 \psi^{(2)T}) \quad (7)$$

ψ_1 和 ψ_2 之间的协方差用 $C_{\psi_1 \psi_2}$ 表示,分别具有 i 和 j 特征 ψ_i 和 ψ_j 。最终融合的特征映射具有最大协方差 $C_{\psi_1 \psi_2}$ 。融合过程创造了添加冗余特征的机会。在本文提出的融合方法中,研究得到了最终的 $N \times 6145$ 维融合特征向量。

1.3 特征优化

特征优化技术的使用通过删除不相关和冗余的特征来提高机器算法的性能^[18]。在作物病害检测中,使用不同的算法来优化数据,有助于更好地诊断病害。针对作物病害分类,采用Whale优化算法(WOA)^[19]进行特征优化。在自然界中,座头鲸通常以群居为主。在捕食过程中,座头鲸会成群地将猎物围住,在螺旋运动的过程中不断吐出气泡,由此形成螺旋状的“泡泡网”^[7],进而将猎物越逼越紧,直至能一口吞下。

1.3.1 WOA 优化算法

由于最优设计在搜索空间中的位置不是先验已知的,WOA算法^[20]假设当前的最佳候选解是目标

猎物或接近最优解。在定义了最佳搜索代理后,其他搜索代理将因此尝试向最佳搜索代理更新其位置。这种行为由下列方程表示:

$$\mathbf{E} = |\mathbf{F} \cdot \mathbf{Y}^*(t) - \mathbf{Y}(t)| \quad (8)$$

$$\mathbf{Y}(t+1) = \mathbf{Y}^*(t) - \mathbf{B} \cdot \mathbf{E} \quad (9)$$

其中, t 表示迭代次数; $\mathbf{Y}^*(t)$ 表示当前最优解的位置向量; $\mathbf{Y}(t)$ 表示位置向量; \mathbf{B} 和 \mathbf{F} 分别表示系数向量,每次迭代过程中有更优解出现时就需要更新 $\mathbf{Y}^*(t)$ 。 \mathbf{B} 和 \mathbf{F} 向量计算公式可写为:

$$\mathbf{B} = 2 \cdot \mathbf{b} \cdot \mathbf{r} \cdot \mathbf{b} \quad (10)$$

$$\mathbf{F} = 2\mathbf{r} \quad (11)$$

其中, \mathbf{b} 在迭代过程中从2线性地下降至0(探索和利用阶段均如此), \mathbf{r} 表示 $[0,1]$ 之间的随机向量^[6]。通过降低式(10)中 \mathbf{b} 的值,实现对猎物的包围。搜索代理的新位置可以定义为代理原始位置与当前最优代理位置之间的任意位置。座头鲸通过在目标周围12m的半径内引发气泡来包围猎物,以形成气泡网。猎物的位置和鲸鱼之间的距离计算如下:

$$\mathbf{Y}(t+1) = \mathbf{E} \cdot e^{bl} \cdot \cos(2\pi) + \mathbf{Y}^*(t) \quad (12)$$

其中, $\mathbf{E} = |\mathbf{F} \cdot \mathbf{Y}^*(t) - \mathbf{Y}(t)|$; b 表示对数函数的常数,表示第 i 头鲸鱼与猎物(当前最优解)之间的距离; l 表示 $[-1,1]$ 之间的随机数。

1.3.2 具体步骤

本文结合WOA算法进行特征优化,算法流程如图4所示。

利用以上算法对神经网络卷积层(卷积核数量为 m ,大小 s ,批大小 $batch$,学习率 η)进行优化改进,将这4个参数对应为每个座头鲸的空间向量位置,第 i 头座头鲸的位置为:

$$X_i = (m_i, s_i, batch_i, \eta_i) \quad (13)$$

算法处理流程具体如下:

(1)数据预处理。对采集到的数据进行归一化处理。

(2)数据集划分。将数据集按3:1的比例分为训练集和测试集。

(3)鲸群初始化。本文将鲸种群个数设为30,迭代次数 N 设为20。

(4)捕食行为。捕食行为具体步骤为:

Step 1 对每只鲸鱼的位置进行更新。根据式(12)更新鲸鱼位置。

Step 2 计算更新位置后鲸鱼的适应度值。使用更新后的CNN结构参数,分别在训练集和测试集上进行训练与测试,筛选出与当前一代最佳适应度

值相对应的鲸鱼位置,并计算适应度值。

Step 3 判断结束条件。判断迭代次数是否满足 $t > N$, 如果条件不满足,则重新进行迭代计算,只有在满足条件时,局部深度搜索才会结束。

(5)进行猎物搜寻。经过 N 次迭代优化操作后,鲸群找到了平均损失值最小的一代。这一代对

应的鲸鱼位置就是全局最优解,即猎物位置。

(6)模型重构。得到全局最优鲸鱼 $X_i = (m_i, s_i, batch_i, \eta_i)$ 的位置后,使用最优的卷积核数量、大小、训练批次和学习率这 4 个参数,重新构建卷积神经网络模型,并分别在训练集和测试集上进行训练与测试。

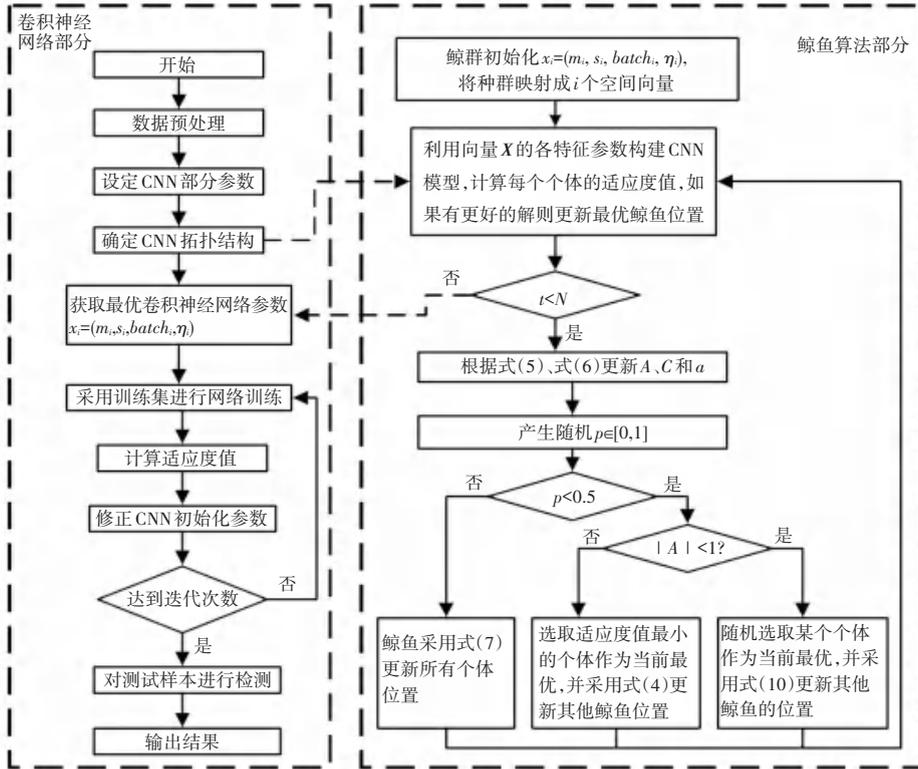


图 4 算法流程

Fig. 4 Flowchart of the algorithm

2 结果与分析

2.1 实验环境

提出的黄瓜病害识别方法已经在一个扩充的黄瓜数据集上实现。本文构建了包括 5 类黄瓜病害的数据集,包括角斑病(71 幅图像)、白粉病(43 幅图像)、霜霉病(104 幅图像)、枯萎病(54 幅图像)和炭疽病(67 幅图像),共计 339 张原始图像。通过扩充增加数据集大小并消除类别不平衡。所有图像都是 RGB(红、绿、蓝)格式,原始图像尺寸为 $256 \times 256 \times 3$ 。扩增过程后,每类图像的数量达到 500 张^[21]。来自黄瓜叶数据集的样本图像如图 5 所示。使用 70:30 方法以及 10 倍交叉验证来执行所提议的训练和测试方法。所提出的方法的仿真是在配备有 Intel i7 第八代计算机处理单元(CPU)、16 GB RAM 和 8 GB 图形卡的台式计算机上执行的。通过与不同分类器的对比,使用不同的评估方法(如准确性、

假负类率(FNR)和计算时间)来评估该方法的性能。



图 5 黄瓜叶片图像数据集中的样本图像

Fig. 5 Images of a sample in a cucumber leaf image dataset

2.2 实验结果

表 1 为本文方法深度特征融合的实验结果,使用预训练的深度 CNN 模型提取深度特征,并执行并行连接。将多个分类器应用于融合的特征空间以执行识别。表 1 结果表明,基于 KNN 和 SVM 的改进算法对样本数量依赖相对较小,均获得超过 93%的

准确率,如 ES-KNN 以 4.8% 的假负类率 (FNR) 实现了 95.2% 的准确率, C-SVM 获得 95.6% 的准确率。而对样本依赖较高的分类器,如 ESD、MG-SVM、W-KNN 和 EB-Tree 分别实现了 64.2%、93.3%、87.1% 和 89.4% 的准确率,相较于 ES-KNN、C-SVM 等算法,准确率偏低。

表 1 深度特征融合的黄瓜病害识别结果

Table 1 Cucumber disease identification results based on deep feature fusion

Method	Accuracy/%	FNR/%	Time/s
ES-KNN	95.2	4.8	250.630
F-KNN	94.6	5.4	58.365
C-SVM	95.6	4.6	175.360
Q-SVM	94.9	5.1	159.730
ESD	64.2	35.8	956.460
MG-SVM	93.3	6.7	204.980
W-KNN	87.1	12.9	59.113
EB-Tree	89.4	10.6	83.476

提出的特征优化方法通过减少计算时间来提高模式识别性能。使用 WOA 优化融合的特征向量来选择最佳特征。表 2 为基于特征优化方法的黄瓜病害识别结果。结果表明,ES-KNN 在 3.5% 的 FNR 下最高准确率达到 96.5%。从时间角度来看,时间减少意味着计算效率的增加。改进分类模型应用前后算法计算代价的降低,导致运行时间大大减少。以 ES-KNN 为例,计算时间减少了 82%。

表 2 基于特征优化方法的黄瓜病害识别结果

Table 2 Cucumber disease identification results based on feature optimization method

Method	Accuracy/%	FNR/%	Time/s
ES-KNN	96.5	3.5	45.280
F-KNN	94.2	5.8	11.460
C-SVM	93.8	6.2	32.508
Q-SVM	93.6	6.4	29.505
ESD	93.1	6.9	175.860
MG-SVM	93.0	7.0	38.444
W-KNN	86.5	13.5	11.278
EB-Tree	88.2	11.8	27.444

通过图 6 中的混淆矩阵进行了验证。图 7 显示了应用特征选择后平均分类精确度数据区域结果的箱线图。从中看出,在大多数情况下,ES-KNN 算法的结果具有较高的中位数值,同时能够保持较小的四分位数范围。证明 ES-KNN 算法在稳定性和鲁棒性方面优于其它算法。ES-KNN 算法的分类能

力优于其他算法,当样本容量小的时候,由于训练样本取值不均衡导致 ESD、MG-SVM、W-KNN 和 EB-Tree 等算法的分类能力大幅下降。

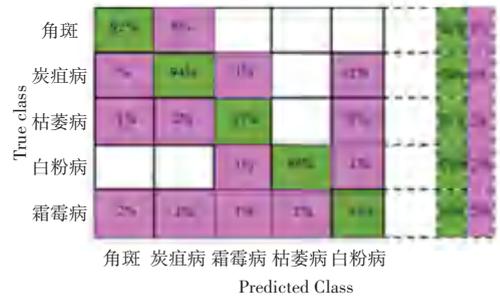


图 6 黄瓜病害识别混淆矩阵

Fig. 6 Confusion matrix of cucumber disease identification

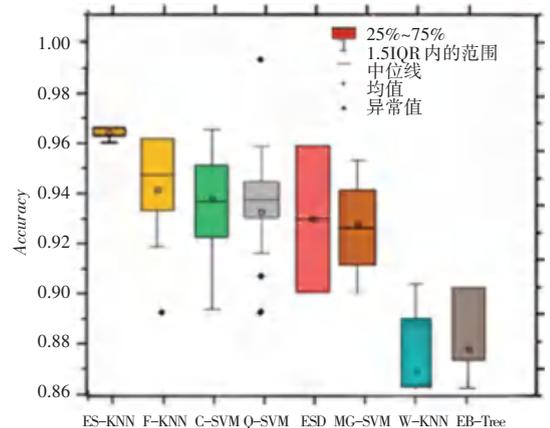


图 7 8 种分类器识别精度箱线图

Fig. 7 Box plots of 8 types of classifiers recognition accuracy

3 结束语

与现有的黄瓜病害识别方法相比,该方法在准确性和计算时间方面取得了更有竞争力的性能。与现有方法的综合比较,所提出的黄瓜病害深度特征融合和特征选择方法耗时更短(45.28 s),对角斑病、白粉病、霜霉病、枯萎病和炭疽病五种黄瓜病害的识别准确率达到 96.5%。

为了有效识别黄瓜病害,提出了一种包含特征融合的深度学习方法。使用 WOA 对所提出的深度特征融合方法进行优化。深度特征融合和选择方法包括 2 个阶段。在第一阶段,使用预训练的深度学习 CNN 模型(VGG19 和 InceptionV3)提取深度特征。对提取的深度特征进行融合,并采用不同的分类器进行识别。仿真结果表明 ES-KNN 算法的准确率达到 95.2%,计算时间为 250.63 s。在第二阶段进行特征选择以减少计算时间并提高识别精度。采用机器学习算法对使用 WOA 的优化特征进行分类,将 ES-KNN 的识别精度提高到 96.5%,计算时间降

至 45.28 s。结果表明,本文方法用于黄瓜病害识别具有较强的鲁棒性和较低的成本。

参考文献

- [1] ZHANG Shanwen, WU Xiaowei, YOU Zhuhong, et al. Leaf image based cucumber disease recognition using sparse representation classification [J]. *Computers and Electronics in Agriculture*, 2023, 134: 135-141.
- [2] ZHANG Jian, ZHANG Wei. Support vector machine for recognition of cucumber leaf diseases[C]//2010 2nd International Conference on Advanced Computer Control. Shenyang: IEEE, 2022: 264-266.
- [3] ZHANG Shanwen, ZHU Yihai, YOU Zhuhong, et al. Fusion of superpixel, expectation maximization and PHOG for recognizing cucumber diseases[J]. *Computers and Electronics in Agriculture*, 2021, 140: 338-347.
- [4] LIN Ke, GONG Liang, HUANG Yixiang, et al. Deep learning-based segmentation and quantification of cucumber powdery mildew using convolutional neural network[J]. *Frontiers in Plant Science*, 2022, 10: 155.
- [5] ZHANG Pan, YANG Ling, LI Daoliang. EfficientNet - B4 - ranger: A novel method for greenhouse cucumber disease recognition under natural complex environment [J]. *Computers and Electronics in Agriculture*, 2021, 176: 105652.
- [6] ZHANG Shanwen, ZHANG Subing, WANG Chuanlei, et al. Cucumber leaf disease identification with global pooling dilated convolutional neural network [J]. *Computers and Electronics in Agriculture*, 2022, 162: 422-430.
- [7] MA Juncheng, DU Keming, ZHENG Feixiang, et al. A recognition method for cucumber diseases using leaf symptom images based on deep convolutional neural network [J]. *Computers and Electronics in Agriculture*, 2023, 154: 18-24.
- [8] 蔡超志, 池耀磊, 郭璐彬. 神经网络搭载 Inception 模块的框架结构集成故障诊断[J]. *机械设计与制造*, 2024(6): 170-176.
- [9] 秦信芳, 魏嘉银, 姚林, 等. 基于 SVM-LSTM-ATTE 组合模型的高校录取分数线预测[J]. *智能计算机与应用*, 2024, 14(2): 177-182.
- [10] 王宇春, 王敏, 袁东华, 等. 基于 DWPSO-SVM 的 sEMG 手势动作识别[J]. *智能计算机与应用*, 2023, 13(12): 158-164.
- [11] 孔希阳, 窦江培. 基于 SE-Inception-v3 的星系形态分类模型 [J]. *天文学报*, 2024, 65(2): 30-43.
- [12] 周康渠, 刘田创, 辛玉, 等. 基于 Inception-LSTM 的退火窑辊道系统轴承故障诊断 [J]. *噪声与振动控制*, 2024, 44(1): 174-180.
- [13] 陆宏菊, 崔嘉. 基于感知偏序模型的图标视觉复杂度研究 [J]. *智能计算机与应用*, 2023, 13(11): 208-214.
- [14] 王梦珍, 张德生, 张晓. 基于加权局部密度的双超球支持向量机算法 [J/OL]. *计算机工程*: 1-9 [2024-05-10]. <https://doi.org/10.19678/j.issn.1000-3428.068887>.
- [15] 毛佳伟, 周敏, 张豪, 等. 基于 SSA-SVM 的刀具寿命预测 [J]. *智能计算机与应用*, 2023, 13(8): 114-119, 124.
- [16] 杨增荣, 王怀彬, 田密密, 等. 苹果早期瘀伤的近红外光谱和多波段相机成像检测 [J]. *光谱学与光谱分析*, 2024, 44(5): 1364-1371.
- [17] 王博, 闫娟, 杨慧斌, 等. 基于 PSO-SVM 的表面肌电信号多手势识别 [J]. *智能计算机与应用*, 2023, 13(7): 173-178.
- [18] 刘刚, 高成龙, 胡万君, 等. 基于 WOA-RBF 响应面模型的油浸式变压器绕组挡板结构优化 [J/OL]. *电工技术学报*: 1-13 [2024-04-18]. <https://doi.org/10.19595/j.cnki.1000-6753.tces.231064>.
- [19] 朱范炳, 陈泽, 张翔. 基于改进蜂群算法优化的支持向量机研究与应用 [J]. *智能计算机与应用*, 2023, 13(8): 197-200, 204.
- [20] 李永飞, 贺桂英, 张金. 基于 SVM 算法的生鲜农产品质量安全预警研究 [J]. *智能计算机与应用*, 2023, 13(7): 150-154.
- [21] 徐泽明, 李凯昂, 顾玉琦, 等. 基于鲸鱼算法优化 CNN 对叉车电池 SOH 进行预测 [J/OL]. *电源学报*: 1-13 [2024-04-26]. <https://link.cnki.net/urlid/12.1420.TM.20240426.1250.067>.
- [22] ASHRAF I, ALHAISONI M, DAMAŠEVĪCIUS R, et al. Multimodal brain tumor classification using deep learning and robust feature selection: A machine learning application for radiologists [J]. *Diagnostics*, 2023, 10: 565.
- [23] 李茹, 范冰冰. 基于混合策略改进的鲸鱼优化算法 [J]. *计算机与现代化*, 2022(6): 13-20.
- [24] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. *Advances in Engineering Software*, 2023, 95: 51-67.
- [25] 吴志远, 董育宁, 李涛. 基于置信度与级联结构的未知网络流量检测 [J]. *智能计算机与应用*, 2024, 14(3): 181-186.
- [26] 李花宁, 吴生彪, 冯丽, 等. 基于 AdaBoost-WOA-HKELM 的下肢关节角度预测 [J]. *机电工程技术*, 2024, 53(4): 36-40.