文章编号:2096-1472(2025)10-0058-05
DOI:10.19644/j.cnki.issn2096-1472.2025.010.012

基于改进 ResNet50 的马铃薯识别与分类方法研究

王健文[1]，刘成忠[1]，韩俊英[1]，曲亚英[2]，马柏雄[1]

(1.甘肃农业大学信息科学技术学院，甘肃 兰州 730070；
2.甘肃省农科院马铃薯研究所，甘肃 兰州 730070)

✉ 1341673306@qq.com; liucz@gsau.edu.cn; hanjy@gsau.edu.cn; 605314800@qq.com; 3126540493@qq.com

摘 要:针对自然条件下马铃薯块茎品种识别效率低、准确性差及化学分析法的不足,提出基于改进 ResNet50 模型的识别方法。该方法通过在主干网络引入注意力模块,调整网络结构,采用 AdamW 优化器,加入迁移学习等改进措施,有效提升了模型性能。实验基于 69 个品种、30 930 张图片的数据集,最终识别准确率达 99.42%,精确率、召回率、*F*1 值也表现优异,相比 MobileNet_V2、GoogLeNet 和 ResNet50 有显著提高,为马铃薯产业智能化管理提供了可靠技术支撑。

关键词:深度学习;ResNet50;马铃薯品种识别;注意力机制;迁移学习
中图分类号:TP391 **文献标志码**:A

Research on Potato Recognition and Classification Method Based on the Improved ResNet50

WANG Jianwen[1], LIU Chengzhong[1], HAN Junying[1], QU Yaying[2], MA Baixiong[1]

(1.*College of Information Science and Technology, Gansu Agricultural University, Lanzhou 730070, China*;
2.*Potato Research Institute, Gansu Academy of Agricultural Sciences, Lanzhou 730070, China*)

✉ 1341673306@qq.com; liucz@gsau.edu.cn; hanjy@gsau.edu.cn; 605314800@qq.com; 3126540493@qq.com

Abstract: To address the low efficiency and accuracy of potato tuber variety recognition under natural conditions, as well as the limitations of chemical analysis methods, this study proposes an identification approach based on an improved ResNet50 model. The method incorporates several enhancements: introducing an attention module into the backbone network, adjusting the network structure, adopting the AdamW optimizer, and integrating transfer learning. These improvements significantly boost model performance. Experiments were conducted on a dataset comprising 30 930 images across 69 potato varieties. The final recognition accuracy reached 99.42%, with outstanding results in precision, recall, and *F*1-score. Compared to MobileNet_V2, GoogLeNet, and the original ResNet50, the proposed model demonstrates substantial improvements, offering reliable technical support for intelligent management in the potato industry.

Key words: deep learning; ResNet50; potato variety identification; attention mechanism; transfer learning

0 引言(Introduction)

马铃薯(*Solanum tuberosum L.*)在我国国民经济中地位关键,其种植与加工产业重要。农业现代化催生大量马铃薯品种[1],而准确识别马铃薯品种对产业发展、种质资源保护和品质保障至关重要。传统识别方法[2]如依靠农业专家的肉眼观察和经验判断,主观性强、效率低且易受环境干扰。化学分析

收稿日期:2025-01-06
基金项目:国家自然科学基金项目(32360437);甘肃省高等学校产业支撑计划项目(2021CYZC-57)

法虽精确但操作复杂且不能无损检测[3]。机器视觉和数字检测技术因快速、高效、无损在图像分类识别领域得到广泛应用[4]。ResNet50 凭借其优势在图像识别中表现突出[5]。LIU 等[6]提出一种基于多尺度特征融合和增强双线性池化分类模型，该模型准确率达 97.0%。李冬睿等[7]优化模型后测试集指标显著提高。尹显明等[8]对比两种不同模型发现模型融合优势。王圆[9]改进 ResNet50 降低参数量且准确率达 97.4%。然而，CNN 在马铃薯品种识别方面研究尚浅。因此，本研究选取甘肃省农业科学院采集的 69 个品种构建数据集，基于 ResNet 改进：通过 CBAM 模块增加模型的双重注意力机制、自适应特征重标定、灵活性和通用性[10]；调整网络结构形成预激活层；替换优化器为 AdamW，集成权重衰减机制[11]；最终搭建为本研究块茎识别模型，实验结果表明该方法可高效准确识别不同品种。

1　材料与方法(Materials and methods)

1.1　数据集的建立与划分

本研究的图像数据采集于甘肃省农业科学院榆中马铃薯试验站(北纬 35.85°、东经 104.12°，海拔 1960 m，温带半干旱气候，年均温 6.7℃，降水量约 400 mm，无霜期约 120 d)。为确保结果的可靠性和准确性，减少人为偏差，采用随机抽样的方法选取 69 个马铃薯品种。考虑到环境因素对模型学习的影响，采集时选用蓝色背景，以突出马铃薯块茎的特征，便于后续的图像识别处理。

在 2023 年 10 月 25 日至 11 月 14 日期间，使用 Nikon COOLPIX B700 相机进行图像采集。每次随机挑选约 30 颗无病害的完整块茎，将其表面泥土清理干净后放置在蓝色纸板前，从多个角度拍摄 15 张照片，确保涵盖马铃薯的颜色、形状等关键特征。经过严格的筛选和裁剪处理，最终获得 30 930 张高质量图像。按照 6∶2∶2 的比例将这些图像划分为训练集、验证集和测试集[12]，其中，训练集用于模型的训练，验证集用于调整模型的参数和评估模型的性能，测试集用于最终检验模型的泛化能力和准确性。

1.2　数据预处理

将包含 30 930 张图像的数据集划分完毕后，在模型训练前对图像进行一系列预处理操作。首先进行随机裁剪，通过随机选取图像的一部分区域，增加图像的多样性，使模型能够学习到不同位置和尺度的特征；然后进行水平翻转操作，进一步扩充数据集，同时增强模型对图像旋转不变性的学习能力；接着将图像转换为张量形式，以便于在深度学习模型中进行处理；最后进行标准化处理，将图像的像素值归一化到特定的范围内，统一调整为 224×224 像素大小，满足模型输入要求，降低计算资源需求，提升模型泛化性能。

2　马铃薯块茎识别网络模型构建(Modeling of potato tuber recognition network)

2.1　ResNet 网络模型

ResNet 是由微软研究院提出的深度残差网络模型，其凭借创新性的残差学习框架，有效地攻克了传统网络在深度不断增加过程中所出现的性能衰退难题，于图像分类任务中彰显出极为显著的性能优势[13]。在该模型架构中，残差块作为核心基础单元，其工作原理可详述为输入数据在经过权重层的运算操作后，生成中间特征。此中间特征经线性整流函数(ReLU)实施激活操作后，与原始输入数据依循恒等映射法则进行相加运算，最终再次经由线性整流函数输出，进而构成了残差块完整且独特的运算逻辑体系，为 ResNet 模型的高效性能奠定了坚实基础。残差块是深度残差网络的基本单元，残差连接的输出公式为

$$H(x)=F(x)+x \tag{1}$$

通过这一机制，可有效规避梯度消失现象的发生，使得深层网络的梯度能够无阻碍地向上层传导，从而为浅层网络层参数提供有效的训练动力，保障整个网络的稳定训练与性能提升。残差块结构如图 1 所示。

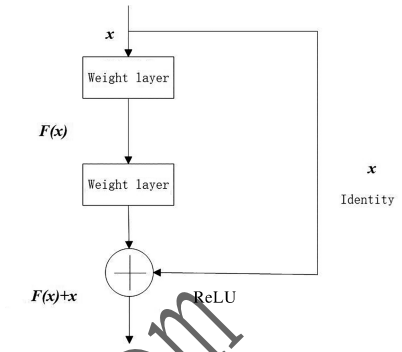

图 1　残差结构块

Fig. 1 Residual structure block

在图像分类方面，ResNet 网络具有一定优势。然而，浅层网络特征提取能力有限，对图像识别的精确度较低。深层网络所需参数较多，网络迭代较慢，不利于快速识别，且网络深度加深后不一定会提高准确率。经过初步实验发现 ResNet50 网络表现最佳，因此本文选择该网络为骨干网络进行改进。

2.2　卷积块注意力模块

由于不同品种的马铃薯在形状、大小及外观上存在差异，且同一品种内部也存在一定变化，甚至部分品种间外观差异小但内部差异大，这对模型的泛化能力提出了较高要求。本研究在原 ResNet50 模型中加入 CBAM 模块，借助通道和空间注意力机制强化模型对关键特征的聚焦与提取能力，从而提升分类准确性[14]。CBAM 包含通道与空间两个子模块。通道注意力模块的工作过程是：先对各通道执行全局最大池化与平均池化操作，生成对应向量来表征全局最大、平均特征。例如：对于一个输入特征图 $X\in\mathbb{R}^{C\times H\times W}$(其中，$C$ 为通道数，H 为高度，W 为宽度)，经过全局最大池化得到 $\boldsymbol{M}_{\max}^{c}\in\mathbb{R}^{C\times1\times1}$，经过全局平均池化得到 $\boldsymbol{M}_{\text{avg}}^{c}\in\mathbb{R}^{C\times1\times1}$。然后将这两个向量输入共享全连接层学习通道注意力权重，经融合与 Sigmoid 激活函数归一化后，与输入特征图逐通道相乘实现特征重加权，得到经过通道注意力调整后的特征图。空间注意力模块则有助于提取空间不同位置的关键信息，它通过对输入特征图在空间维度上进行池化操作，生成空间注意力权重图，再与输入特征图相乘，突出关键空间区域的特征。通道模块与空间模块在 CNN 中的连接方式如图 2 所示。

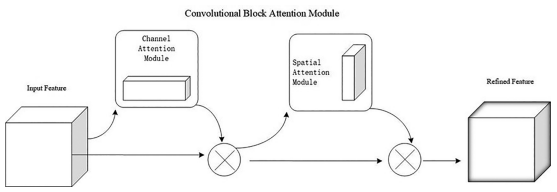

图 2　通道模块与空间模块在 CNN 中的连接

Fig. 2 The connection between the channel and spatial modules in CNN

在实际应用中发现，直接添加 CBAM 会改变网络结构，导致预训练参数无法复用。因此，在 ResNet50 首层及末层卷积后各添加一个 CBAM 模块。首层加入模块可迅速聚焦关键特征，引导网络在早期学习过程中关注重要信息；末层模块能够锐化高层语义特征，增强模型在分类决策时的准确性，从而有效提升分类效果，结构示意如图 3 所示。

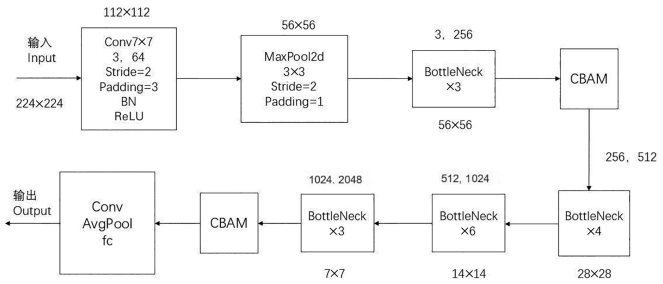

图 3 ResNet50-CBAM 网络结构

Fig. 3 ResNet50-CBAM network structure

2.3 网络结构调整

传统残差网络结构如图 4 所示，采用卷积层、标准化层、激活函数依次连接方式，存在未对输入样本归一化致使批标准层效能受限的问题。本研究对其进行优化：在第一个卷积层前添加批量归一化(Batch Normalization，BN)和激活函数(ReLU)，使数据流先经过预激活层再进入卷积层，改变数据分布并引入非线性特性，有助于网络更好地学习特征，形成了改进后的残差块网络结构如图 5 所示。通过此种方式，一方面可增大梯度，促使网络在学习进程中加速收敛，有效规避梯度消失问题；另一方面，成功保留了残差块结构中的恒等映射这一关键特性，进而增强网络在处理各类任务时的稳定性、高效性及适应性。

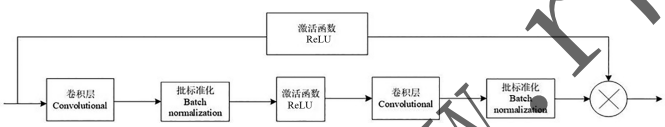

图 4 传统残差网络结构

Fig. 4 Traditional residual network structure

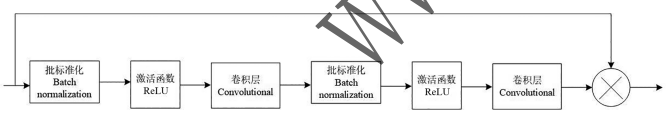

图 5 改进残差网络结构

Fig. 5 Improved residual network structure

2.4 AdamW 优化器

Adam 算法即自适应矩估计方法，是 Momentum 与 RMSProp 的结合并修正偏差。AdamW 在 Adam 基础上改进，将权重衰减单独应用于权重参数，而非直接加入梯度更新，避免对偏置参数产生不必要影响，从而提高模型训练效果。AdamW 通过修改更新规则，在计算梯度更新时考虑权重衰减系数 λ，使权重衰减独立于动量累积，更准确应用 L2 正则化，有效减小权重参数值[15]，提升模型泛化能力，适用于大规模数据处理。在 Adam 当中，weight_decay 是直接加入梯度当中：

$$g_t = g_t + \lambda\theta_{t-1} \tag{2}$$

其中：g_t 是当前 step 的梯度，θ_{t-1} 是上一个 step 中的模型权重，λ 是正则化系数。而在 AdamW 中，正则化变成了：

$$\theta_t = \theta_{t-1} - \lambda\theta_{t-1} \tag{3}$$

2.5 迁移学习

迁移学习作为一系列前沿方法，其核心在于挖掘新任务与已有任务的潜在关联，提取相似特征，有效解决过拟合问题。

由于 ResNet50 是已经预训练过的深度卷积神经网络，本文将迁移学习的方法应用于马铃薯块茎图像分类识别中，利用已有的预训练，针对马铃薯图像问题进行微调，避免从头训练模型，进而提高本实验分类模型的准确性和效率[16]，同时减少训练时间和数据需求。在卷积神经网络中，迁移学习主要有预训练模型微调、特征提取和模型架构迁移 3 种应用方式。本实验因数据集较大，采用预训练模型微调方法，加载预训练权重后冻结 layer1 和 layer2 层，修改最后的全连接层，再用小学习率微调未冻结层，充分利用预训练知识并适应新任务需求。

3 实验方法与结果分析(Experimental methods and analysis of results)

3.1 实验平台与训练参数

实验在 Python 3.9、PyTorch 1.8.0 环境下进行，硬件环境为 CPU Intel Core i9 13900HX(主频 2.20 GHz)、GPU NVIDIA GeForce GTX4090 16 GB 显卡内存)，操作系统为 Windows 11 专业版 64 位。所有模型训练超参数统一设置为：Batch-size 为 64，Epochs 为 100，优化器为 AdamW，学习率为 0.000 1，损失函数为 CrossEntropyLoss。

3.2 评价指标

采用准确率(Accuracy，A)、召回率(Recall，R)、精确率(Precision，P)、$F1$ 值($F1$-score)和特异度(specificity)评估网络性能。其中：准确率表示算法正确预测样本在总预测样本中的比例；召回率为正确预测的正样本在实际正样本中的比例；精确率指被判定为正样本的样本中实际为正样本的比例；$F1$ 值是综合评价指标；特异度表示识别出的负例在所有负例中的比例。具体计算公式如式(4)～式(8)所示：

$$A = \frac{TP + TN}{TP + FP + TN + FN} \tag{4}$$

$$R = \frac{TP}{TP + FN} \tag{5}$$

$$P = \frac{TP}{TP + FP} \tag{6}$$

$$F1 = \frac{2 \times P \times R}{P + R} \tag{7}$$

$$TNR = \frac{TN}{FP + TN} \tag{8}$$

3.3 准确率与损失率分析

模型准确率与训练损失结果如图 6 所示，其中：loss0 和 acc0 代表初始 ResNet 模型的损失与准确率；loss 和 acc 代表本研究方法训练后的损失与准确率。ResNet50 初始损失约 4.0，前 10 次迭代下降迅速，11～90 次下降缓慢，90 次后趋于稳定约 0.14；本研究方法初始损失约 1.7，前 20 次迭代快速下降，20～50 次缓慢下降，50 次后基本平稳，稳定值约 0.02。可见本研究方法模型损失下降速度快且更稳定。从准确率看：原模型 30 次迭代后趋于稳定，最高准确率 94.6%；改进后模型 30 次迭代后增长变缓，最终最高准确率达 99.67%。与原模型相比，改进后模型收敛速度加快且准确率更高。

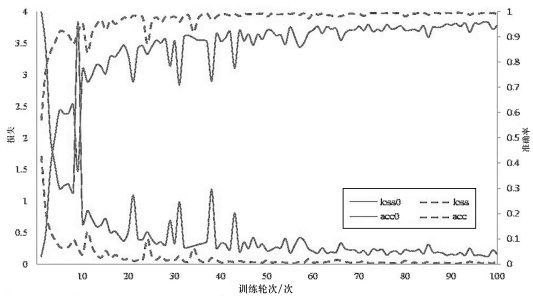

图 6　网络训练准确率与损失

Fig. 6 Network training accuracy and loss

3.4　对比与消融实验结果与分析

针对马铃薯块茎品种识别问题，对 ResNet50 进行了多方面的改进，包括添加卷积块注意力（CBAM）模块，调整网络结构以及采用 AdamW 优化器，这些改进措施相互协同，共同提升了模型的性能。引入 CBAM 模块对强化模型关键特征聚焦能力至关重要。由于马铃薯品种外观差异复杂，既有品种间不同，又有同品种内个体差异，甚至部分品种外观相近但内部特性变化大。CBAM 模块的通道注意力机制可自适应精修深度卷积块中间特征图，提升表达与聚焦关键信息能力，空间注意力机制还能辅助提取空间关键信息。在网络结构优化上，打破传统残差网络卷积、标准化、激活函数的连接常规，在首个卷积层前置批量归一化（BN）和激活函数（ReLU）构建预激活层。这样输入数据先经归一化调整分布，再引入非线性特性，使网络更高效地学习特征。优化算法方面，AdamW 将权重衰减独立作用于权重参数，区别于直接混入梯度更新的传统做法。处理大规模马铃薯图像数据时，这有效避开了对偏置参数的负面影响，精准落实 L2 正则化。通过在计算梯度更新时考虑权重衰减系数 λ，使得权重衰减独立于动量累积，有效减小权重参数值，防止模型过拟合。CBAM 模块、网络结构调整和 AdamW 优化器三者协同工作，从特征提取、网络学习能力和训练优化等多个方面提升了模型性能。在相同环境下对各模型训练，本研究构建的新模型通过融入 CBAM 注意力机制、调整网络结构和变更优化器形成，对马铃薯块茎品种分类精度达 99.42%，相比原始 ResNet50（96.37%）提升 3.05%，表明该网络可靠性高。而且 3 种改进策略应用于马铃薯块茎数据集时，准确率均超 MobileNet_V2、GoogLeNet 等网络模型，其中，AdamW 优化器提升效果最为显著。实验数据详见表 1。

表 1　不同模型的训练结果

Tab. 1 Training results of different models

分类模型	训练轮次/次	平均准确率/%	最高准确率/%
MobileNet_V2	100	91.97	92.30
GoogLeNet	100	95.35	95.40
ResNet50	100	96.37	97.12
ResNet50-CBAM	100	97.45	98.43
ResNet50-调整结构	100	98.10	98.99
本研究方法	100	99.42	99.99

进一步分析各模型在测试集上的准确率、精确率、召回率、特异度和 $F1$ 值见表 2。本研究方法精确率达 99.44%，比初始 ResNet50 高 2.96%，各分类间精确率差距小且稳定；召回率达 99.42%，比初始 ResNet50 高 3.08%，体现改进后模型识别稳定性；特异度方面，改进前后均高于 99.5%，表明模型适用于马铃薯品种分类；$F1$ 值可全面反映模型分类质量，本研究方法表现优异，详见表 2。

表 2　不同模型评估标准对比

Tab. 2 Comparison of evaluation criteria of different models

分类模型	准确率/%	精确率/%	召回率/%	特异度/%	$F1$ 值/%
MobileNet_V2	91.97	91.46	91.63	96.62	89.93
GoogLeNet	95.35	95.59	95.36	99.94	95.30
ResNet50	96.37	96.48	96.34	99.96	96.35
ResNet50-CBAM	97.45	97.64	97.41	99.97	97.44
ResNet50-调整结构	98.10	98.20	98.09	99.98	98.09
本研究方法	99.42	99.44	99.42	99.99	99.43

3.5　分类结果的混淆矩阵

混淆矩阵可直观展示分类模型预测结果与真实类别关联。本研究方法的混淆矩阵如图 7 所示，横轴表示马铃薯品种的正确类别，纵轴表示模型预测值。矩阵对角线表示其正确分类值，其余为混淆分类。对比本研究方法与原始模型 ResNet50 的混淆矩阵，原模型对多数马铃薯块茎品种分类效果较好。但部分品种如 L1725-1、Ly1879-5、Ly1517-8、Ly1879-5 分类效果欠佳，Ly1860-3 最差，89 张照片仅 60 张正确分类，原因可能是这些品种同属一大类且亲本相同，形状纹理相似增加分类难度。本研究方法整体识别效果更优，仅少量错误分类，分类效果较差的品种为 Ly1860-3 和 Ly1907-20，其中，Ly1907-20 易被误识别为 Ly1907-26。

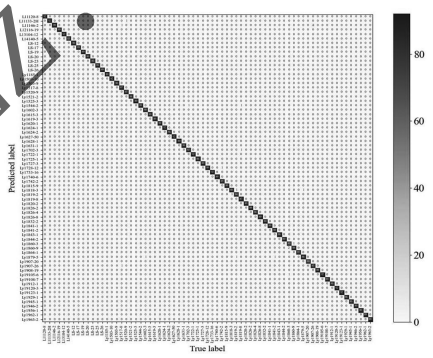

图 7　本研究方法的混淆矩阵

Fig. 7 The confusion matrix of this research method

4　结论（Conclusion）

本研究构建了一种以 ResNet50 为架构的马铃薯识别与分类方法，通过引入 CBAM 实现特征自适应细化，促使网络精准聚焦关键特征。对残差块内批标准层、激活函数与卷积块的连接顺序予以调整，显著提升特征提取效能。采用 AdamW 优化器并优化超参数，有效加快训练进程且增强模型泛化能力。经实验验证，改进后的网络在分类准确率上高达 99.42%，相较于 MobileNet_V2、GoogLeNet 及原始 ResNet50 优势明显。在精确率、召回率和 $F1$ 值等关键指标上均达到 99%，有力地证明了该方法在马铃薯块茎品种识别方面的准确性与高效性，为马铃薯产业智能化管理与精准分类提供了坚实可靠的技术支撑。同时也为其他农作物品种识别研究在模型架构设计、训练策略优化等方面树立了参考案例。然而，由于现有实验设备和技术能力的限制，无法引入马铃薯的光谱数据、纹理数据等信息，不能在复杂环境下实现精确的品种识别。今后应在模型轻量化与实时性方面进行深入探究，以期为农业生产实践提供更具适应性与实用性的技术解决方案。

参考文献（References）

[1] WANG F R，SU H W. The application of deep learning in

the whole potato production chain:a comprehensive review [J]. Agriculture, 2024,14(8):1225.
[2] 李守强,田世龙,李梅,等. 主成分分析和隶属函数法综合评价15种(系)马铃薯的营养品质[J].食品工业科技,2020,41(6):272-276,291.
[3] 王丽,句荣辉,杨洋,等. 马铃薯品质特性的相关性及主成分分析[J]. 食品工业, 2023,44(12):307-312.
[4] CHUN G B, NAN H, ZOU Y Q, et al. Development of deep learning methodology for maize seed variety recognition based on improved swin transformer [J]. Agronomy,2022,12(8):1843.
[5] 付雪婷,王新鑫,杨凡凡,等. 基于卷积神经网络的植物品种识别研究[J]. 南方农机, 2023,54(17):65-69.
[6] LIU M, HOU X, SHANG M, et al. A classification model for fine-grained silkworm cocoon images based on bilinear pooling and adaptive feature fusion[J]. Agriculture, 2024, 14(12):2363.
[7] 李冬睿,邱尚明,杨善友. 基于自适应权重优化的多任务深度学习模型在甘蔗病害识别中的应用[J]. 智能计算机与应用, 2024,14(3):163-167.
[8] 尹显明,棘玉,张日清,等. 深度学习在基于叶片的油茶品种识别中的研究[J]. 南京林业大学学报(自然科学版),2023,47(3):29-36.
[9] 王圆. 基于ResNet的植物病虫害识别方法研究[D].荆州:长江大学,2024.
[10] 刘芳军,李玥,武凌,等. 基于改进ResNet18的胡麻干旱胁迫识别与分类研究[J]. 江西农业大学学报, 2023,45(6):1517-1527.
[11] 常禧龙,梁琨,李文涛. 深度学习优化器进展综述[J]. 计算机工程与应用, 2024,60(7):1-12.
[12] 邢雪. 基于Vision Transformer的马铃薯品种识别方法研究[D]. 兰州:甘肃农业大学,2024.
[13] 黄英来,艾昕. 改进残差网络在玉米叶片病害图像的分类研究[J]. 计算机工程与应用, 2021,57(23):178-184.
[14] 左斌,李菲菲. 基于注意力机制和Inf-Net的新冠肺炎图像分割方法[J]. 电子科技, 2023,36(2):22-28.
[15] QIAN T, GUAN N L, JIN B B. Calibrating the adaptive learning rate to improve convergence of ADAM [J]. Neurocomputing, 2022, 481:333-356.
[16] 胡峻峰,张志超,赵亚凤,等. 基于迁移学习的竹片缺陷识别[J]. 西北林学院学报, 2021,36(5):190-196.

作者简介:

王健文(2000-),男(汉族),临洮,硕士生。研究领域:农作物品种识别,农业信息化。
刘成忠(1969-),男(汉族),天祝,教授,学士。研究领域:人工智能,农业信息化。本文通信作者。
韩俊英(1975-),女(汉族),兰州,教授,博士。研究领域:深度学习,精准农业。
曲亚英(1976-),女(汉族),平川,研究员,硕士。研究领域:马铃薯种质功能性差异研究。
马柏雄(1998-),男(汉族),通渭,硕士生。研究领域:农业信息化。

(上接第51页)

参考文献(References)

[1] 郭鹏,董兰芳,夏泽举. 地质数据的等值线绘制方法研究[J]. 计算机仿真,2009,26(9):168-171.
[2] TROELS L, JORN B J. Shallow gas depth-contour map of the Skagerrak-western Baltic Sea region[J]. Geo-marine letters,2007,27:127-141.
[3] 陈学工,付金华,马金金,等. 约束TIN生成带断层等值线图的方法[J]. 计算机工程与应用, 2011,47(33):198-201.
[4] BRADLEY D, HEIDRICH W, POPA T, SHEFFER A. View correspondence (jump link). High resolution passive facial performance capture(Article)[J]. ACM transactions on graphics,2010, 29(4):41.
[5]刘少华,程朋根,史文中. 约束Delaunay三角网生成算法研究[J]. 测绘通报, 2004(3):4-7.
[6] 陈学工,黄晶晶. Delaunay三角网剖分中的约束边嵌入算法[J]. 计算机工程, 2007,33(16):56-58.
[7] 刘少兵. 带断层地震数据的Delaunay三角剖分算法[J]. 煤田地质与勘探, 2008,36(6):70-72.
[8] 孙劲光,周勃. 曲线约束Delaunay三角剖分及在地形构建中的应用[J]. 计算机应用与软件, 2015,32(12):25-28,41.
[9] 王金鑫,秦子龙,曹泽宁,等. 基于八叉树的修正克里金空间插值算法[J]. 郑州大学学报(工学版), 2021,42(6):21-27.
[10] 方智勇,郭细伟,马亚涛,等. 基于距离限制的改进Kriging模型的可靠度计算方法[J]. 武汉理工大学学报(交通科学与工程版), 2022,46(3):489-494.
[11] 胡必鑫. 含断层的不规则散乱数据域的等值线绘制[J]. 长江大学学报(自然科学版),2009,6(2):66-68.
[12] JIA Q, LI W, CHE D. A triangulated irregular network constrained ordinary Kriging method for three-dimensional modeling of faulted geological surfaces[J]. IEEE Access,2020, 8:85179-85189.
[13] ZHANG Y, ZHENG X, WANG Z, et al. Implementation of a parallel GPU-based space-time Kriging framework [J]. International journal of Geo-information,2018,7(5):193-205.
[14] 王倩. 基于Delaunay的三维快速克里金插值[D]. 成都:电子科技大学,2015.
[15] TONG W T, LI L X, ZHOU X L. Efficient spatiotemporal interpolation with spark machine learning [J]. Earth science informatics,2019,12(1):87-96.

作者简介:

隋国华(1969-),男(汉族),东营,高级工程师,博士。研究领域:智能油田,勘探信息化。
董明辉(1999-),男(汉族),青岛,硕士生。研究领域:计算机视觉,深度学习。本文通信作者。
彭 英(1970-),男(汉族),迁安,高级工程师,博士。研究领域:油气勘探数据分析及勘探信息系统开发管理。
韩宗合(2001-),男(汉族),青岛,硕士生。研究领域:深度学习。
李子祥(1997-),男(汉族),威海,硕士生。研究领域:图形图像处理。