doi:10.6041/j.issn.1000-1298.2025.09.065

基于图像处理和卷积神经网络的大米加工精度识别方法研究

朱　锐[1]　夏　宇[1]　季　凡[1]　陈坤杰[1]　陈子轩[2]

(1.南京农业大学工学院, 南京 211800; 2.农业农村部南京农业机械化研究所, 南京 210014)

摘要: 快速准确地识别大米加工精度,是实现大米碾削加工自动控制的关键。采集不同碾削时间的大米图像,通过滤波及压缩等处理后,制成不同精度等级的数据集,再以经典卷积神经网络(Convolutional neural network,CNN)LeNet-5、AlexNet 和 VGG-16 为基础,分别采取了一系列针对性的优化策略,对模型进行改进和优化,得到 3 种改进的大米加工精度识别模型;通过试验比较了这些改进优化方法对模型性能的影响。结果表明,在引入卷积核尺寸为 9×9 和 11×11 的两个子卷积网络分支后,LeNet-5 模型识别准确率由 82.23% 提高到 92.53%;在对 AlexNet 模型去除两个全连接层,并采用普通池化后,模型识别准确率由 92.89% 提高到 96.73%;如果将 Dropout 层和组归一化(Group normalization,GN)层引入到 VGG-16 模型,并采取最大相关-最小冗余(Maximum relevance minimum redundancy,MRMR)特征选择算法对模型进行改进优化,模型准确率较原模型提升 7.56 个百分点,达到 98.87%,为所有测试模型中最高。这表明改进的 VGG-16 网络模型,可以用于对大米加工精度等级进行精准识别。

关键词: 大米加工; 精度识别; 卷积神经网络; 最大相关-最小冗余特征选择

中图分类号: TP391　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)09-0751-08　　**OSID**:

Rice Processing Precision Identification Method Based on Image Processing and Convolutional Neural Network

ZHU Rui[1]　XIA Yu[1]　JI Fan[1]　CHEN Kunjie[1]　CHEN Zixuan[2]

(1. *College of Engineering*, *Nanjing Agricultural University*, *Nanjing* 211800, *China*

2. *Nanjing Agricultural Mechanization Research Institute*, *Ministry of Agriculture and Rural Affairs*, *Nanjing* 210014, *China*)

Abstract: Rapid and accurate identification of the rice processing precision is essential for achieving automated control of rice milling process. Images of rice milled for different durations were collected and processed through filtering and compression to create datasets of various precision levels. Based on three classical convolutional neural network (CNN) architectures, including LeNet-5, AlexNet, and VGG-16, targeted optimization strategies were applied to develop three improved models for rice processing precision identification. Experimental analyses were conducted to compare the performance of these improved methods. The experimental results revealed that introducing two sub-convolutional network branches with kernel sizes of 9×9 and 11×11 to the LeNet-5 model led to the increase in recognition accuracy from 82.23% to 92.53%. Regarding the AlexNet model, removing two fully connected layers and adopting conventional pooling increased its recognition accuracy from 92.89% to 96.73%. Most notably, the VGG-16 model, after incorporating maximum relevance minimum redundancy (MRMR) feature selection, Dropout, and group normalization (GN) layers, achieved an accuracy of 98.87%. This represented a improvement of 7.56 percentage points over the original model, ultimately making improved VGG-16 the most accurate model among all tested models. Consequently, this demonstrated that the improved VGG-16 model was highly effective for accurate identification of rice processing

收稿日期: 2025-01-10　修回日期: 2025-04-14

基金项目: 江苏省科技支撑现代农业重点项目(BE2021305)

作者简介: 朱锐(1998—),男,博士生,主要从事农业信息检测与控制工程研究,E-mail: zhurui_199817@163.com

通信作者: 陈子轩(1988—),男,工程师,主要从事智能化农机装备研究,E-mail: 15651825182@163.com

precision levels.

Key words: rice processing; precision identification; convolutional neural networks (CNN); maximum relevance minimum redundancy (MRMR) feature selection

0 引言

科学合理的大米加工对于保障我国粮食产业的持续健康发展具有重要意义[1-6]。目前,大米加工精度等级主要依据国家制订的相关标准来确定。通常,加工精度较低的大米背沟处表皮保留更完整,色泽相对暗沉,营养价值更高;而加工精度较高的大米,其背沟则基本无皮,外观洁白无瑕,但营养成分损失较多。大米加工精度的分级不仅体现了大米的加工质量,为消费者提供选购依据,还促进了加工技术的不断进步与产业升级。通过科学的大米分级体系,能够有效减少粮食浪费,提升粮食利用效率,从而推动国家粮食产业的转型升级和可持续发展[7-8]。

传统大米加工精度的评估方法,如目测法、染色法及化学法等,存在主观性强、效率低、误差率高及样品损伤等问题,难以满足现代化农业高效精准的要求[9-11]。随着智慧农业的飞速发展,计算机视觉技术在农产品检测领域的应用日益广泛,为大米加工精度自动化检测提供了新的思路。传统的机器视觉方法多依赖预设算法进行特征提取(如颜色、形状、纹理等)[12]。然而,传统图像处理方法虽能提取出大米加工精度信息[13-15],但受特征提取算法的局限性和人为特征选择主观性的影响,难以精准地捕捉大米颗粒间的差别。

相比之下,基于深度学习的神经网络模型在大米加工精度检测领域展现出显著的应用潜力。这类模型通常采用端到端的学习模式,直接从原始图像数据中自主学习并提取重要的特征表示,无需复杂的人工特征设计[16-17]。这种特性使其在处理样本的细微特征时,能有效捕捉大米颗粒的深层次特征,包括细微纹理、颜色渐变及形态变异等,从而实现对大米加工精度更为精准且全面的识别。卷积神经网络(CNN)是基于深度学习的图像识别技术在农业领域应用的核心模型[18-19]。其在大米检测等方面的研究近些年开始受到人们重视[20-23]。尽管这些研究展现了较高的识别准确率,但多以原始图像为输入,且聚焦于大米加工精度检测这一细分领域的系统性研究仍显匮乏。

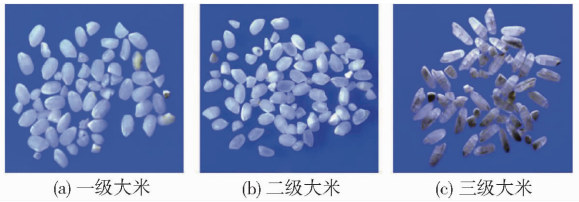
本文首先将大米原始图像进行预处理和压缩,以消除图像噪声并大幅消减冗余信息;然后选择几种典型 CNN 模型进行改进优化,通过试验比较各种改进优化措施对 CNN 模型性能的影响,最终得到结构简单、识别精度高的大米加工精度等级识别模型,以期为大米加工装备智能化和管理精细化提供技术支持。

1 材料和方法

1.1 样本数据

1.1.1 试验材料与装置

研究样本采用承德胜丝苗米长粒籼稻,含水率为 14.1%。试验前,先取 2 000 g 稻谷,用台州沃粮 WLJLG-2018 型砻谷机进行砻谷,得到 1 500 g 糙米。然后将糙米均分为 3 份,每份约 500 g,再用 JMN-3 型精白机分别进行 90、60、30 s 的碾削处理,制得 3 组精度分别与国标一级、二级和三级相当的样本,密封保存备用,如图 1 所示。



(a) 一级大米 (b) 二级大米 (c) 三级大米

图 1 不同加工精度的试验样本

Fig. 1 Test samples with different processing precisions

采用 1 台自制图像采集装置进行大米图像采集,如图 2 所示。该装置主要由 CCD 工业相机、机器视觉升降台、光源和遮光装置等构成。大米托盘置于升降台上,托盘下垫蓝色色卡,以增强图像对比度。升降台包括微调位移台和相机夹具等,便于调整相机和环形光源高度和角度。环形光源侧放于大米托盘附近,此外还有一个手持光源用于补光。工业相机固定于可升降操作台夹具,由控制终端驱动,进行大米图像采集。

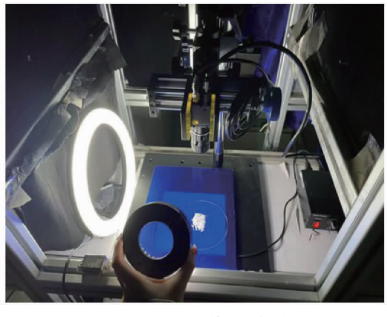


图 2 大米图像采集装置

Fig. 2 Rice image acquisition device

1.1.2 数据集制作

通过随机抽取方式,每次从 3 组密封样本中定

量取样约 10 g 大米，并将其置于托盘上进行图像采集。采集后的样本随即放回混匀再取，以确保样本多样性。每组样本采集 500 幅图像，总计 1 500 幅。数据集的 80% 作为训练集（每组 400 幅，共 1 200 幅），20% 作为测试集（每组 100 幅，共 300 幅）。

1.2　样本图像预处理方法

采集的图像受到噪声、尘埃杂质及色彩偏差等多重因素的影响，导致图像质量下降。采用灰度转换、中值滤波法及奇异值分解（Singular value decomposition，SVD）压缩法对采集的图像数据集进行预处理，以消除图像中的干扰因素，增强关键信息显著性。

利用加权平均法，将彩色图像进行灰度转换，使目标图像特征更加突出，并提高图像处理速度和效率。图像灰度（Gray）计算公式为

$$Gray = 0.299R + 0.587G + 0.114B \tag{1}$$

式中　R——图像红色通道强度

G——图像绿色通道强度

B——图像蓝色通道强度

选用中值滤波法，以消除大米图像中的噪声。该方法在高效抑制噪声的同时，能有效保留图像边缘信息。具体而言，该方法采用宽为 m、高为 n 的长方形模板，并以模板内像素灰度的中值来更新图像各点 (x, y) 灰度，通过二维滑动遍历整幅图像。其数学表达式为

$$g(x,y) = \mathrm{Med}\{f(x-i,y-j)\}\left(i \in \left\{-\left\lfloor\frac{m-1}{2}\right\rfloor,\cdots,\left\lfloor\frac{m}{2}\right\rfloor\right\};\ j \in \left\{-\left\lfloor\frac{n-1}{2}\right\rfloor,\cdots,\left\lfloor\frac{n}{2}\right\rfloor\right\}\right) \tag{2}$$

式中　$g(x,y)$——处理后图像在点 (x,y) 处的灰度

$f(x,y)$——原图像在点 (x,y) 处的灰度

Med——取中值操作

利用 SVD 压缩方法，对数据集图像进行压缩处理。SVD 压缩法可以在识别并保留数据本质特征的同时，实现将高维数据向低维空间映射。经 SVD 压缩降维后的数据可作为原始数据近似替代。

本文对数据集图像样本按奇异值总和的 60% 进行压缩，压缩后图像有效保留了大米形态、纹理等关键信息特征，可以近似替代原始数据，但其存储量仅约为原图的 13%。通过这种降低数据维度的方法，在保留图像关键特征、避免噪声及不相关信息潜在干扰的同时，有效提高模型训练效率。

1.3　基于经典卷积神经网络模型改进

1.3.1　基于 LeNet－5 模型改进

LeNet－5 模型[24]结构相对简单，在处理复杂图像识别任务时存在局限性。由于卷积核尺寸决定了单次卷积操作的图像局部感知范围，对图像特征提取具有显著影响。较大的卷积核能够在一次操作中捕获更丰富的空间上下文信息，而小的卷积核更适合提取图像局部细节。为了获得更丰富的空间信息及更多的局部细节，通过构建两个并行且独立的子卷积网络分支来代替原模型中单路径卷积结构，对 LeNet－5 模型进行改进。改进的 LeNet－5 模型结构如图 3 所示。

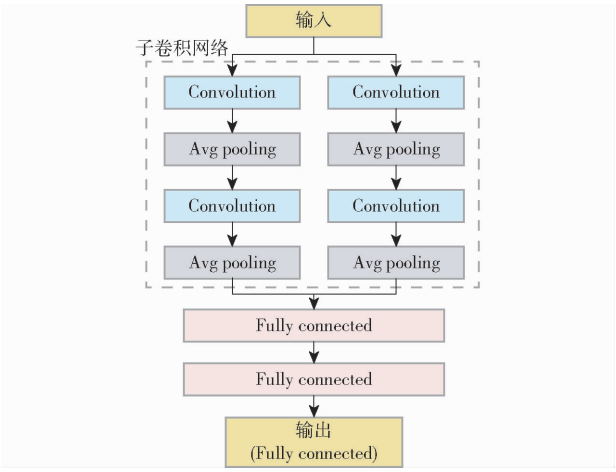


图 3　改进的 LeNet－5 模型网络结构

Fig. 3　Architecture of improved LeNet－5 model

为探索卷积核尺寸对模型性能的影响，设计了 5 组试验，包括初始的 LeNet－5 模型和 4 组具有子卷积网络结构的 LeNet－5 模型，试验方案如表 1 所示。

表 1　改进的 LeNet－5 模型试验方案

Tab. 1　Improved LeNet－5 model test scheme

试验方案序号	构造两个子卷积网络	卷积结构
1	否	5×5
2	是	双分支 5×5
3	是	双分支 9×9
4	是	双分支 11×11
5	是	9×9 和 11×11

1.3.2　基于 AlexNet 模型改进

AlexNet 模型[25]的网络结构较深，特征表达能力强，在复杂的大规模图像识别中表现优异。然而，其复杂的网络结构和过多的模型参数，往往引发计算资源消耗过大，并相应地增加过拟合的风险。为此，本文通过以下 3 个方法，对 AlexNet 模型结构进行优化：

（1）引入批归一化（Batch normalization，BN）层：在 ReLU 激活函数后加入 BN 层，通过将输入值缩放到一个合理的范围内，提升激活函数的响应效率，使模型更有效地进行梯度更新，从而解决在输入值极端情况下（过大或过小）可能出现的梯度消失问题。

同时,BN 层能有效降低模型对初始权重的敏感性,加快模型的收敛速度,减少迭代次数,加速训练过程。另外,由于 BN 层稳定了每一层的输入分布,减少了内部协变量偏移现象,可使训练过程变得更加平滑和稳定,进而提高模型泛化能力。

(2)去掉前两个全连接层。在 AlexNet 模型中,由于全连接层承载了绝大多数参数,而面对本研究中有限的训练数据,过多的参数易导致过拟合问题,影响模型泛化能力。因而去除前两个全连接层以减少模型承载参数数量。

(3)引入普通池化层。池化操作通过减少数据的空间维度和去除冗余信息,增强模型鲁棒性和泛化能力。将 AlexNet 模型中的池化层替换为普通池化操作,即将最大池化层的窗口大小设置为 2×2,步长设置为 2,以保留更丰富的特征信息。

改进的 AlexNet 模型结构如图 4 所示。为探索以上 3 种方法对 AlexNet 模型的改进效果,将 3 种优化方法进行组合,设置 8 组试验。第 1 组为对照组,保留原始 AlexNet 模型架构。其余 7 组分别为这些改进方法单独或组合应用,试验方案如表 2 所示。

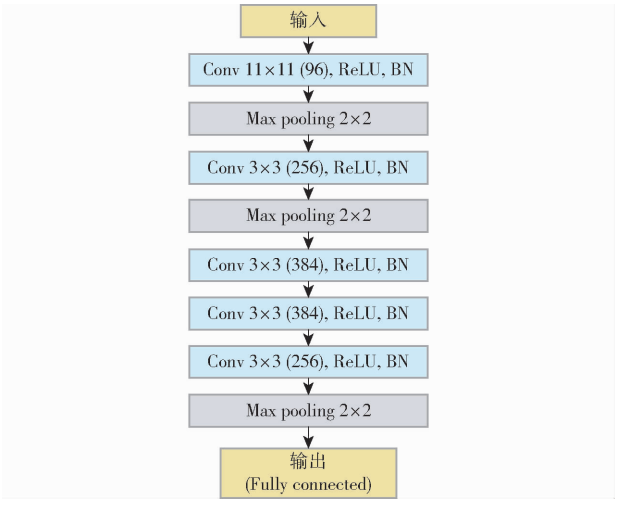


图 4 改进的 AlexNet 模型网络结构

Fig. 4 Architecture of improved AlexNet model

表 2 改进的 AlexNet 模型试验方案

Tab. 2 Improved AlexNet model test scheme

试验方案序号	加入 BN 层	去掉全连接层	采取池化操作
1	否	否	否
2	否	否	是
3	否	是	否
4	否	是	是
5	是	否	是
6	是	是	否
7	是	否	否
8	是	是	是

1.3.3 基于 VGG-16 模型改进

VGG-16 模型[26-29]以其突出的特征提取和抽象能力,在图像处理任务中表现优异。利用迁移学习的方法,将 TensorFlow 官方开源资源获取的预训练 VGG-16 模型作为基础网络,采用以下 3 种方法对原始 VGG-16 模型进行优化:

(1)添加 Dropout 层。Dropout 层能在模型的训练过程中,通过随机丢弃一定比例的神经元,来阻断部分网络连接的贡献,减少模型对特定神经元的依赖,防止过拟合,并提高模型的泛化能力。被随机丢弃的神经元比例由指定的概率确定,通常设定在 0.2~0.5 之间,本文设定概率为 0.3。

(2)引入组归一化(GN)层。GN 层可将特征图的通道分组,并独立计算各组的均值和方差,然后进行归一化处理。此方法不依赖于批处理大小,确保模型在处理小规模批数据时保持稳定的性能,以解决批归一化在小批量下的局限性,从而提高模型性能的稳定性和鲁棒性。

(3)引入 MRMR 特征选择算法[30]。用于大米加工精度识别的图像,样本中常出现大量相似和冗余的特征,增加了特征选择和分类复杂性。MRMR 算法无需遍历所有潜在特征组合,而是直接优化特征与目标的相关性,并最小化特征间冗余,快速筛选出关键特征子集,以提高模型特征选择的效率与识别性能。特征与目标类别之间的相似性由互信息 $M(x,y)$ 量化,其计算公式为

$$M(x,y)=\iint p(x,y)\lg\frac{p(x,y)}{p(x)p(y)}\mathrm{d}x\mathrm{d}y \tag{3}$$

式中 x、y——随机变量

$p(x)$、$p(y)$、$p(x,y)$——概率密度函数

大米图像样本特征集 A 与类 b 相关性为 A 中特征 f_i 与 b 之间所有互信息的平均值,计算公式为

$$D(A,b)=\frac{1}{|A|}\sum_{f_i\in A}M(f_i,b) \tag{4}$$

式中 $D(A,b)$——大米特征集 A 与类 b 相关性函数

$M(f_i,b)$——大米特征 f_i 和类 b 之间互信息

特征集 A 中所有特征冗余为特征 f_i 和特征 f_j 之间的所有互信息值平均值,计算公式为

$$R(A)=\frac{1}{|A|^2}\sum_{f_i,f_j\in A}M(f_i,f_j) \tag{5}$$

式中 $R(A)$——大米特征集 A 中所有特征冗余

$M(f_i,f_j)$——特征 f_i 和特征 f_j 之间的互信息

改进的 VGG-16 模型结构如图 5 所示。为研究以上 3 种改进措施对 VGG-16 模型性能的影响,按照 3 种策略组合,设置 8 组试验。以第 1 组为对照组,保留原始 VGG-16 模型架构。其余 7 组分别为这些策略单独或组合应用,如表 3 所示。

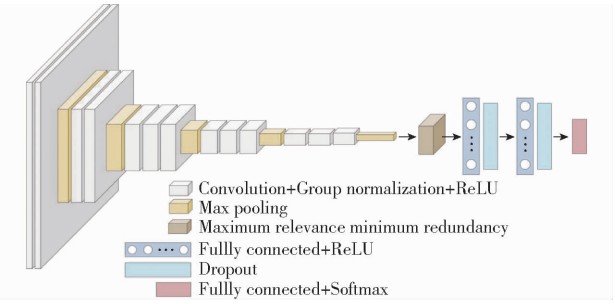


图 5　改进的 VGG－16 模型网络结构

Fig. 5　Architecture of improved VGG－16 model

表 3　改进的 VGG－16 模型试验方案

Tab. 3　Improved VGG－16 model experiment scheme

试验方案序号	添加 Dropout	加入 GN 层	应用 MRMR
1	否	否	否
2	否	是	否
3	否	否	是
4	否	是	是
5	是	否	否
6	是	是	否
7	是	否	是
8	是	是	是

1.4　环境配置和网络参数

在同一个 GPU 服务器下进行算法试验和测试，硬件环境为 Ge Force RTX 2080 Ti，内存容量为 10 GB；软件环境为 Windows 10 操作系统、PyTorch 1.7.1 和 Cuda 11.1。此外，设置学习率为 0.001，批处理大小为 32，迭代次数为 100。

1.5　评价指标

选用准确率、损失值、训练时间作为大米精度识别性能的评价指标，从不同角度反映模型分类能力。

2　试验结果与分析

2.1　改进的 LeNet－5 模型识别性能

改进的 LeNet－5 模型性能如表 4 所示，优化后的模型在识别准确率、损失值和训练时间等方面均优于原始 LeNet－5 模型。

表 4　改进前后 LeNet－5 模型性能对比

Tab. 4　Performance comparison of LeNet－5 model before and after improvement

试验方案序号	准确率/%	损失值	训练时间/s
1	82.23	0.216	1 915
2	91.34	0.197	1 783
3	91.66	0.187	1 652
4	86.34	0.235	1 843
5	92.53	0.163	1 457

进一步比较分析卷积核尺寸对模型性能的影响可知，双分支 9×9 子卷积结构的识别精度和效率均高于双分支 5×5 结构和双分支 11×11 结构。这说明卷积核过小或过大时，模型的精度都会受到不利影响。这可能是由于卷积核过小时感受野受限导致识别精度低；而当卷积核过大时，过拟合影响了模型精度。采用两个不同尺寸的子卷积核（9×9 和 11×11）改进的 LeNet－5 模型，在试验中取得了最优性能。该模型识别准确率达到 92.53%，损失值降低至 0.163，且训练时间最短，为 1 457 s。这表明同时引入具有不同卷积核的子卷积网络结构，可使模型通过特征互补减少关键信息的遗漏，从而提升识别效率和准确率。

2.2　改进的 AlexNet 模型识别性能

改进的 AlexNet 模型性能如表 5 所示。由表 5 可知，原模型经过任何一种或多种改进，都有利于其性能的提高。

表 5　改进前后 AlexNet 模型性能对比

Tab. 5　Performance comparison of AlexNet model before and after improvement

试验方案序号	准确率/%	损失值	训练时间/s
1	92.89	0.113	3 428
2	94.58	0.093	4 672
3	94.76	0.095	4 893
4	96.73	0.070	5 774
5	96.54	0.076	5 891
6	96.32	0.075	5 681
7	94.73	0.096	4 935
8	96.61	0.078	6 582

进一步比较分析可发现，在 ReLU 激活函数后加入 BN 层，提高了模型识别准确率，并降低了损失值，但训练时间几乎没有增加，这说明 BN 层在几乎不增加模型大小的情况下，解决了内部协变量偏移问题，从而提升了模型识别准确率。

表 5 还显示，在去掉前两个全连接层后，模型的准确率普遍有所提升，损失值均有所降低。然而，可能由于优化算法选择不当或网络参数设置不匹配，网络结构的改变导致模型的训练时间有所延长。

在保持其他网络结构不变的情况下，将模型中 3×3 最大池化层替换为 2×2 普通池化层后，可有效提升模型识别精度。通过缩小池化窗口尺寸，普通池化在局部感受野内融合更多特征响应，减少空间的信息丢失，使模型能保留更密集的局部关键特征。虽然新的池化操作可能会因特征抽象程度降低而增加模型的优化难度，延长训练时间，但该方法使模型能够捕捉图像中更细粒度的特征，从而提高识别性能。

在所有的模型中，仅采用去除 2 个全连接层和

普通池化方法改进的 AlexNet 模型识别准确率最高,达到 96.73%,略高于同时应用 3 种改进方法的模型。同时,该模型的损失值最低,训练时间也相对较短。在所有改进的 AlexNet 模型中,该方案展现出最优的大米加工精度识别性能。

2.3 改进的 VGG-16 模型识别性能

表 6 展示了改进前后 VGG-16 模型对大米加工精度识别结果。由表 6 可知,所有经过优化的模型,在性能指标上均实现了不同程度的改善。

表 6 改进前后 VGG-16 模型性能对比

Tab. 6 Performance comparison of VGG-16 model before and after improvement

试验方案	准确率/%	损失值	训练时间/s
VGG-16	91.31	0.107	10 018
VGG-16 + GN	94.02	0.067	9 841
VGG-16 + MRMR	97.82	0.045	9 005
VGG-16 + GN + MRMR	97.91	0.059	9 343
VGG-16 + Dropout	94.39	0.093	9 729
VGG-16 + Dropout + GN	95.86	0.063	9 921
VGG-16 + Dropout + MRMR	98.02	0.038	9 206
VGG-16 + Dropout + GN + MRMR	98.87	0.027	9 763

其中,在保持其他结构不变的情况下,仅添加 Dropout 层,模型识别准确率由 91.31% 提升到 94.39%。这可能是因为 Dropout 层可防止模型过拟合,减少神经元之间的互相依赖,并增强对关键特征的提取能力,从而使得模型识别准确率明显提高,损失值也有所降低。

在保持其他网络结构不变的情况下,仅引入 GN 层,模型识别准确率由 91.31% 提升到 94.02%。这是因为引入 GN 层后,同一组内的特征实现了标准化,增强了模型在处理批量数据时的稳定性和鲁棒性,从而提升了模型对大米加工精度的识别性能。

当仅采用 MRMR 特征选择算法时,模型在所有评价指标上的性能均显著优于基础模型。识别准确率提高 6.51 个百分点,同时损失值和训练时间分别降低 0.062 和 1 013 s。这可能是 MRMR 特征选择算法能够更有效地为模型筛选有效特征,减少冗余特征,从而加速模型学习进程与提高检测精度。

在所有模型中,集成 Dropout 层、GN 层及 MRMR 特征选择算法后改进的 VGG-16 模型虽然效率不是最高,但具有最优识别准确率(98.87%)。这表明,经此 3 个方面改进优化后,VGG-16 模型在大米加工精度检测任务中的性能获得了显著提高。

2.4 模型性能比较

以识别准确率和损失值为主要标准,分别选取改进后的 LeNet-5、AlexNet 和 VGG-16 模型中识别性能最优的一组模型进行模型之间及改进前后性能的比较,结果如图 6 所示。

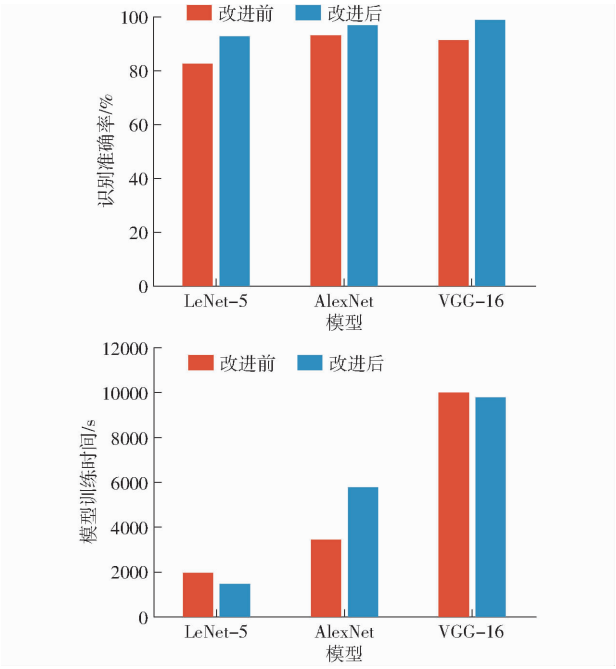


图 6 模型改进前后性能比较

Fig. 6 Performance comparison of models before and after improvement

由图 6 可知,改进前,AlexNet 模型识别准确率最高,达到 92.89%,LeNet-5 模型最低,仅有 82.23%;经过改进优化后,VGG-6 模型识别准确率最高,达到 98.87%,LeNet-5 模型最低,为 92.53%。经过优化改进,3 种模型识别准确率均得到显著提高。其中 LeNet-5 模型提高幅度最大,达到 10.3 个百分点;其次是 VGG-16 模型,提高 7.56 个百分点;最差的 AlexNet 模型提高 3.84 个百分点。

在训练时间上,改进的 LeNet-5 模型和 VGG-16 模型的训练时间均显著缩短,但 AlexNet 模型训练时间却有所增加。其中,LeNet-5 模型最短,仅用时 1 457 s,VGG-16 最长,达到 9 763 s,是 LeNet-5 模型的近 7 倍。这可能是由于 LeNet-5 模型结构较为简单、特征提取能力相对较弱,而 VGG-16 网络结构较深、特征提取能力相对较强但结构较为复杂。

文献[20]将大米加工精度划分为 4 个等级并开展识别分类研究,同时也选择 VGG-16 作为基础模型,通过一系列改进方法,实现了 97.32% 的识别准确率。相比之下,本文改进的 VGG-16 模型在类似的测试条件下,识别准确率为 98.87%,比文献[20]的模型高 1.55 个百分点,显示出更为准确的性能。此外,还选择 LeNet-5 和 AlexNet 两种经典 CNN 作为基础模型,并分别进行了有效的改进提升,为现有大米加工精度识别领域提供了相对全面的基准模型体系。

2.5　大米加工精度识别系统开发

基于改进 VGG－16 模型，开发了大米加工精度识别系统，其人机交互界面可实时向用户反馈加工精度等级。用户上传图像后，系统通过预训练模型自动识别大米精工精度等级并即时展示。界面开发流程包括 Django 环境搭建、项目与程序创建、存储模型与视图函数定义、前端集成及服务器部署。

本系统具体实现原理如图 7 所示。采用 Flask 框架将训练好的改进 VGG－16 模型部署到服务器，确保模型的运行与接口调用；Nginx 代理服务器负责接收前端上传的大米图像请求，将其转发至服务器进行识别，并实时回传识别结果；前端利用 JavaScript 进行解析并展示识别结果，实现 Web 页面高效检测与即时交互。

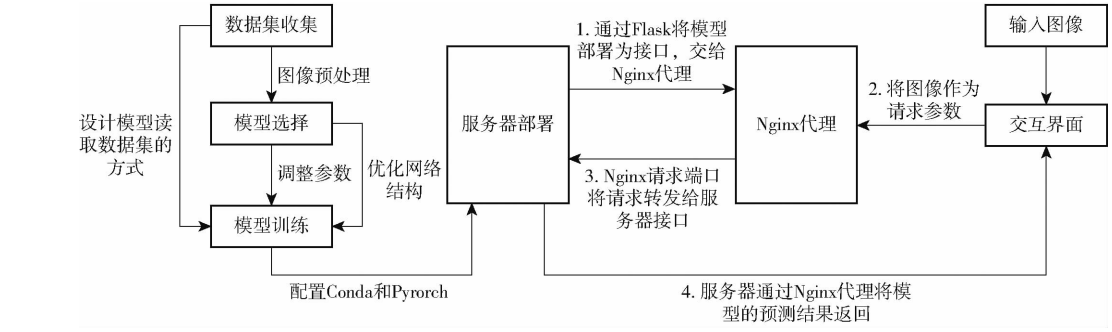


图 7　大米加工精度识别系统实现原理图

Fig. 7　Implementation principles of rice processing precision identification system

3　结论

（1）通过将 LeNet－5 模型的原单卷积结构替换为子卷积网络结构，验证了采用 9×9 与 11×11 子卷积网络分支可显著提升模型特征提取能力，使分类准确率提升 10.3 个百分点。

（2）在 AlexNet 中，通过去除部分全连接层和引入普通池化层，其识别性能得到显著提升。

（3）改进的 VGG－16 模型通过集成 Dropout 层、GN 层以及融入 MRMR 特征选择算法，对大米加工精度识别效果显著提升，分类准确率达到 98.87%。

（4）在 3 种优化模型中，改进的 VGG－16 模型对大米加工精度识别准确率最高，而改进的 LeNet－5 模型训练时间最短。

参　考　文　献

[1] 徐春春，纪龙，李凤博，等. 当前我国水稻产业发展形势与战略对策[J]. 华中农业大学学报，2022，41(1)：21－27.
XU Chunchun，JI Long，LI Fengbo，et al. Situation and strategies of rice industry development in China[J]. Journal of Huazhong Agricultural University，2022，41(1)：21－27.（in Chinese）

[2] MITTAL S，DUTTA M K，ISSAC A. Non-destructive image processing based system for assessment of rice quality and defects for classification according to inferred commercial value[J]. Measurement，2024，148：106969.

[3] 杨榕，吴建永，张水军，等. 加工精度对方便米饭理化性质的影响[J]. 中国食品学报，2021，21(6)：166－172.
YANG Rong，WU Jianyong，ZHANG Shuijun，et al. Effect of degree of milling on the physicochemical properties of instant rice[J]. Journal of Chinese Institute of Food Science and Technology，2021，21(6)：166－172.（in Chinese）

[4] 路乐乐，沈琴，郎双静，等. 加工精度对稻花香品质及方便米饭理化性质的影响[J]. 食品工业科技，2025，46(10)：220－227.
LU Lele，SHEN Qin，LANG Shuangjing，et al. Effect of degree of milling on the quality of daohuaxiang rice and physicochemical properties of instant rice[J]. Science and Technology of Food Industry，2025，46(10)：220－227.（in Chinese）

[5] 谢丹，金芝苹，葛志刚. 加工精度对大米品质和蒸煮特性的影响[J]. 粮食与油脂，2021，34(10)：15－18.
XIE Dan，JIN Zhiping，GE Zhigang. Effect of milling degree on the physico chemical properties and cooking characteristics of rice[J]. Cereals & Oils，2021，34(10)：15－18.（in Chinese）

[6] 张珊，洪滨，沙迪新，等. 稻米适度加工及其品质综合评价研究进展[J]. 食品科技，2023，48(6)：125－130.
ZHANG Shan，HONG Bin，SHA Dixin，et al. Research progress on moderate processing and comprehensive quality evaluation of rice[J]. Food Science and Technology，2023，48(6)：125－130.（in Chinese）

[7] 李心悦，黄文雄，周娜，等. 大米加工精度在线检测技术的研究进展[J]. 粮食与饲料工业，2022(3)：7－9，14.
LI Xinyue，HUANG Wenxiong，ZHOU Na，et al. Research progress of on-line detection technology for rice processing accuracy[J]. Cereal & Feed Industry，2022(3)：7－9，14.（in Chinese）

[8] 安红周，黄世豪，罗琼，等. 不同加工精度对大米主要储藏特性影响的研究[J]. 中国粮油学报，2020，35(10)：1－8.
AN Hongzhou，HUANG Shihao，LUO Qiong，et al. Influence of different milling degrees on the storage characteristics of polished rice[J]. Journal of the Chinese Cereals and Oils Association，2020，35(10)：1－8.（in Chinese）

[9] 吴建永，刘成梅，刘伟，等. 大米加工精度检测方法研究进展[J]. 食品工业科技，2015，36(18)：395－399.
WU Jianyong，LIU Chengmei，LIU Wei，et al. Research progress in methods for detecting milling degree of rice[J]. Science

and Technology of Food Industry, 2015, 36(18): 395 - 399. (in Chinese)
[10] 李心悦, 黄文雄, 周娜, 等. 计算机视觉在大米加工精度检测中的应用[J]. 粮食与饲料工业, 2022(2): 1 - 3, 11.
LI Xinyue, HUANG Wenxiong, ZHOU Na, et al. Application of computer vision in rice processing degree detection[J]. Cereal & Feed Industry, 2022(2): 1 - 3, 11. (in Chinese)
[11] 高岩, 石翠霞, 张越, 等. 大米加工精度检测新技术的研究[J]. 粮油食品科技, 2020, 28(3): 118 - 121.
GAO Yan, SHI Cuixia, ZHANG Yue, et al. Research on new technology for detection of rice milling degree[J]. Science and Technology of Cereals, Oils and Foods, 2020, 28(3): 118 - 121. (in Chinese)
[12] 张晋宁, 金毅, 尹君. 机器视觉技术在大米品质检测中的研究进展[J]. 中国粮油学报, 2022, 37(12): 302 - 310.
ZHANG Jinning, JIN Yi, YIN Jun. Research progress of machine vision technology in rice quality detection[J]. Journal of the Chinese Cereals and Oils Association, 2022, 37(12): 302 - 310. (in Chinese)
[13] SINGH K R, CHAUDHURY S. An efficient technique for rice grain classification using back propagation neural network and wavelet decomposition[J]. IET Computer Vision, 2016, 10(8): 780 - 787.
[14] KUO T Y, CHUNG C L, CHEN S Y, et al. Identifying rice grains using image analysis and sparse-representation-based classification[J]. Computers & Electronics in Agriculture, 2016, 127: 716 - 725.
[15] 崔雯雯, 孙永海, 王璐, 等. 基于图像纹理分析的大米加工等级检测方法[J]. 中国粮油学报, 2016, 31(6): 146 - 149.
CUI Wenwen, SUN Yonghai, WANG Lu, et al. Rice processing level detection method based on image texture analysis[J]. Journal of the Chinese Cereals and Oils Association, 2016, 31(6): 146 - 149. (in Chinese)
[16] 麻剑钧, 刘晓慈, 金龙新, 等. 基于机器视觉的农作物病害识别研究进展[J]. 湖南农业科学, 2023(9): 97 - 100.
MA Jianjun, LIU Xiaoci, JIN Longxin, et al. Research progress of crop disease recognition based on machine vision[J]. Hunan Agricultural Sciences, 2023(9): 97 - 100. (in Chinese)
[17] 樊湘鹏, 周建平, 许燕, 等. 基于改进卷积神经网络的复杂背景下玉米病害识别[J]. 农业机械学报, 2021, 52(3): 210 - 217.
FAN Xiangpeng, ZHOU Jianping, XU Yan, et al. Corn disease recognition under complicated background based on improved convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 210 - 217. (in Chinese)
[18] LAWRENCE S, GILES C L, TSOI A C, et al. Face recognition: a convolutional neural network approach[J]. IEEE Transactions on Neural Networks, 1997, 8(1): 98 - 113.
[19] 姜红花, 杨祥海, 丁睿柔, 等. 基于改进 ResNet18 的苹果叶部病害多分类算法研究[J]. 农业机械学报, 2023, 54(4): 295 - 303.
JIANG Honghua, YANG Xianghai, DING Ruirou, et al. Identification of apple leaf diseases based on improved ResNet18[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 295 - 303. (in Chinese)
[20] 戚超, 左毅, 陈哲琪, 等. 基于改进 VGG16 的大米加工精度分级方法研究[J]. 农业机械学报, 2021, 52(5): 301 - 307.
QI Chao, ZUO Yi, CHEN Zheqi, et al. Rice processing accuracy classification method based on improved VGG16 convolution neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(5): 301 - 307. (in Chinese)
[21] 成泞伸, 张聪, 魏志慧, 等. 改进目标检测模型在大米外观品质检测中的应用研究[J]. 中国粮油学报, 2024, 39(7): 181 - 188.
CHENG Ningshen, ZHANG Cong, WEI Zhihui, et al. Application research of improved object detection models in rice appearance quality inspection[J]. Journal of the Chinese Cereals and Oils Association, 2024, 39(7): 181 - 188. (in Chinese)
[22] LI B, LI S. Recognition algorithm of rice germ integrity base on improved Inception v3[C]//2019 International Conference on Intelligent Computing, Automation and Systems (ICICAS). Chongqing: IEEE, 2019: 497 - 501.
[23] YE J, HU Z, CHEN Y. Identification of broken rice rate based on grading and morphological classification[J]. LWT, 2025, 215: 117175.
[24] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278 - 2324.
[25] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84 - 90.
[26] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]// International Conference on Learning Representations (ICLR2015). arXiv, 2014: 1409.1556.
[27] MANNEPALLI P K, PATHRE A, CHHABRA G, et al. Diagnosis of bacterial leaf blight, leaf smut, and brown spot in rice leafs using VGG16[J]. Procedia Computer Science, 2024, 235: 193 - 200.
[28] 陈燕, 陆嘉豪, 胡小春, 等. 基于 VGG - UNet 的食用菌菌丝体表型参数自动测量方法[J]. 农业机械学报, 2024, 55(1): 233 - 240.
CHEN Yan, LU Jiahao, HU Xiaochun, et al. Automated measurement method of phenotypic parameters of edible mushroom mycelium based on VGG - UNet[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 233 - 240. (in Chinese)
[29] 孟志超, 贺磊盈, 杜小强, 等. 基于 Enhanced VGG16 的油茶品种分类[J]. 农业工程学报, 2022, 38(10): 176 - 181.
MENG Zhichao, HE Leiyin, DU Xiaoqiang, et al. Classification of *Camellia oleifera* based on Enhanced VGG16 network[J]. Transactions of the CSAE, 2022, 38(10): 176 - 181. (in Chinese)
[30] KAUR K, PATIL N. A fast and novel approach based on grouping and weighted mRMR for feature selection and classification of protein sequence data[J]. International Journal of Data Mining and Bioinformatics, 2020, 23(1): 47.