

doi:10.6041/j.issn.1000-1298.2021.05.033

基于改进 VGG16 的大米加工精度分级方法研究

戚超 左毅 陈哲琪 陈坤杰

(南京农业大学工学院, 南京 210031)

摘要: 为了准确识别大米精度等级,结合超列技术(Hyper column technology, HCT)、最大相关-最小冗余(Max-relevance and min-redundancy, MRMR)特征选择算法和极限学习机(Extreme learning machine, ELM),提出了基于改进 VGG16 卷积神经网络的大米分级检测方法。首先,使用机器学习中的 OneHot 格式进行编码,对数据进行归一化;然后采用 VGG16 卷积神经网络结合 HCT 技术作为特征提取器,从而保证从不同的深层结构中提取出局部鉴别特征,共提取 5 248 个大米特征信息;采用 MRMR 特征选择算法剔除大量冗余的大米图像特征,筛选出最有效的 500 个特征;最后,利用 ELM 技术进行大米加工精度分级。将 5 848 个样本图像按 6:3:1 的比例随机分为训练集、测试集与验证集,对模型进行训练与测试,结果表明,基于改进 VGG16 卷积神经网络的大米加工精度分级模型对 1 755 个测试集大米样本分类的总体准确率达到 97.32%,对大米加工精度的分级预测速度在 85 t/h 以上,基本满足大米生产线的分级要求。

关键词: 大米加工;精度分级;卷积神经网络;超列技术;最大相关-最小冗余特征选择

中图分类号: TS212.2; S24

文献标识码: A

文章编号: 1000-1298(2021)05-0301-07

OSID:



Rice Processing Accuracy Classification Method Based on Improved VGG16 Convolution Neural Network

QI Chao ZUO Yi CHEN Zheqi CHEN Kunjie

(College of Engineering, Nanjing Agricultural University, Nanjing 210031, China)

Abstract: Classification of rice processing precision is an important link in rice processing. In order to accurately identify the grade of rice processing precision, by combining the hyper column technology (HCT), max-relevance and min-redundancy (MRMR) feature selection algorithm and extreme learning machine (ELM) technique, an improved VGG16 convolutional neural network was proposed. First of all, the OneHot format in machine learning was used for coding and normalization of data; then, combining HCT, the VGG16 convolutional neural network was used as the feature extractor, which can extract local differentiating features from deep structure at different levels. Totally 5 248 rice features were extracted, the MRMR feature selection algorithm was employed to eliminate massive redundant rice image features, and 500 most effective features were selected. Finally, the ELM technique was used to classify the processing grade of rice. The 5 848 sample images were randomly divided into the training set, test set and verification set according to the ratio of 6:3:1 for training and test of model. The results showed that when the rice processing grade classification model built based on the improved VGG16 convolutional neural network was used to classify the 1 755 rice samples in the test set, the overall accuracy can reach 97.32%, and the classification prediction speed of rice processing precision can reach approximately 85 t/h, which basically satisfied the requirement of rice production line.

Key words: rice processing; accuracy classification; convolutional neural network; hyper column technology; max-relevance and min-redundancy feature selection

收稿日期: 2020-06-26 修回日期: 2020-07-21

基金项目: 苏北科技专项-富民强县项目(SZ-YC2019002)

作者简介: 戚超(1993—),男,博士生,主要从事机器视觉与图像处理研究, E-mail: 584758071@qq.com

通信作者: 陈坤杰(1963—),男,教授,博士生导师,主要从事农产品加工及无损检测技术研究, E-mail: kunjiechen@njau.edu.cn

0 引言

水稻产量占世界谷物总产量的1/3左右。全世界种植水稻的国家有100多个,全世界约1/3的人口以大米为主食,大米品质对人类生活及健康至关重要^[1-3]。

稻谷经清理、砻谷、碾米等工序后制成大米。除与品种、产地、生长气候等因素有关外,大米品质还与加工精度密切相关。市场上销售的大米通常按照GB/T 1354—2018标准进行分级,即大米的加工精度分成3个不同等级。对于按照原标准加工的4级大米则不允许流入市场,但掺入4级大米进入市场的情况非常普遍。由于大米加工精度的准确分级直接影响消费者的利益,因此有必要对4级大米进行检测。中国每年出口大米100万t以上,由于大米品质检测低效、分级精度不高等问题,导致中国大米在国际市场上竞争力不足,落后于美国、日本、泰国等国家。因此,急需一种快速、高效的大米加工精度分级检测方法^[4-6]。

机器视觉技术具有非破坏性、成本低、速度快等特点^[7-10]。传统的机器视觉分类方法通常根据设定的特征提取规则提取多个特征,并用于训练分类模型,其弊端是对有效信息造成损失。KUO等^[11]提出了一种非破坏性的方法,采用图像处理和基于稀疏表示的分类(SRC)来区分30个品种的稻谷。DEVI等^[12]提取形态图像特征,并将其输入实时的神经网络系统中,对印度香米进行分级,得到更高的分级准确性。SINGH等^[13]提出使用图像处理和机器学习的方法,根据形状和纹理特征对4种不同的稻谷图像进行分类,然后将特征向量反馈到SVM,以进行多类分类。VGG16卷积神经网络是牛津大学视觉几何组提出的深层特征提取网络,通过增加网络深度能够提升网络的最终性能,可直接将原始图像信息作为网络输入,由卷积层训练数据进行特征学习,从而充分提取了有效信息,在图像识别领域获得了广泛应用^[14-19]。

本文以大米生产线分级环节中的大米为研究对象,采集4个等级的大米图像信息,提出基于改进VGG16卷积神经网络的大米分级检测方法,对大米加工品质的4个等级进行检测与识别,探究大米加工精度等级检测的可行性。

1 材料和方法

1.1 样本数据

1.1.1 试验材料

从南京市六合区远望富硒大米专业合作社采购

1、2、3级远望稻花香系列富硒大米各100kg,采购远望稻花香系列富硒大米的稻谷100kg作为4级大米,在南京农业大学博远楼A304实验室对稻谷进行砻谷和碾米,碾米机的碾白度设置为最高值9。

1.1.2 试验仪器与设备

LGJ4.5型检验砻谷机(浙江省台州市粮仪厂),JN MJ3型检验碾米机(浙江省台州市粮仪厂),维视MV-EM510C型工业相机及4.0mm焦距镜头(陕西维视数字图像技术有限公司),黑色背景布(娇颖布艺公司),试验台(南京农业大学),MSI便携式计算机(台湾微星科技公司)。

1.1.3 图像采集

根据大米图像的采集需求,自主设计了一套图像采集装置,试验装置由试验台、工业相机、计算机、光源、暗箱、黑色背景布等组成。采用MV-EM510C型工业相机及4.0mm焦距镜头,像素尺寸 $3.45\mu\text{m}\times 2.2\mu\text{m}$,帧率15f/s,曝光时间为 $30\sim 5\,000\,000\mu\text{s}$,以太网与计算机相连,相机通过云台夹固定在暗箱顶端,距离被测物体约30cm,照明光源采用两个LED灯;黑色背景布平铺在试验台上,抓取任意数量的1级大米,随机放置在黑色背景布上,进行图像采集工作,将采集完的大米取出放入对应等级的袋子中,黑色背景布上重新放置大米,所有大米图像都采集完记为采集一轮,总共进行13轮。1~4级大米依次操作,有效图像共5848幅,部分样本图像如图1所示。

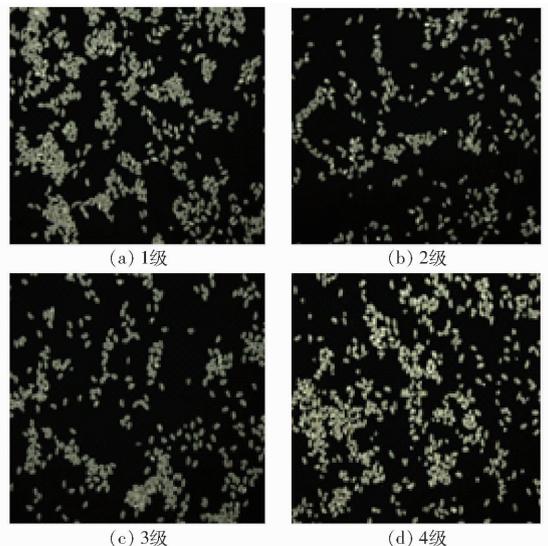


图1 4种等级大米样本图像

Fig.1 Images of four grades of rice samples collected

1.1.4 训练环境配置

操作系统为Windows 10,Python版本为3.6.4,使用pip进行Python包的管理和安装。软件为基于Tensorflow-gpu 1.14.0的Keras 2.2.4。硬件平台

使用 i7 - 8700CPU, 显卡为 NVIDIA 公司的 Geforce GTX 1070 显卡, 8GB 显存版本。CUDA 为 10.0 版本, 对应 cudnn 为 7.6.5.32 版本。

1.1.5 数据集制作

为了增加样本的多样性, 防止训练过程中过拟合现象出现, 使用有监督的数据增强方法, 对单样本数据进行增强, 将分辨率为 $2592 \text{ 像素} \times 1944 \text{ 像素}$ 的大米图像裁剪成分辨率为 $224 \text{ 像素} \times 224 \text{ 像素}$ 的 RGB 三通道彩色图像, 为了便于计算, 使用机器学习中的 OneHot 格式进行编码, 用 4 位状态寄存器编码 4 个状态, 每个状态都有独立的寄存器位, 且这些寄存器位中只有一位有效, 图像的具体数量和对应编码如表 1 所示。

表 1 4 种级别大米数据图像数量和对应的 OneHot 编码

Tab.1 Number of rice data pictures of four levels and corresponding OneHot code

级别	图像数量/幅	编码
1 级	1 508	1000
2 级	1 488	0100
3 级	1 396	0010
4 级	1 456	0001

本文图像像素尺度为 $0 \sim 255$, 但种类尺度为 $0 \sim 3$, 为了方便将所有样本数据放在同一尺度下进行衡量和避免梯度消失或有梯度爆炸问题, 需要对数据进行归一化, 将所有数据限制在尺度相同的范围内。归一化主要有两种方案, 一种为标准归一化, 可以将数据更改为均值为 0、方差为 1 的正态分布, 大部分数据都集中在 $-1 \sim 1$ 区间内, 便于求导求梯度, 但这种方法需要对数据的均值和方差预先求值。另一种为最大最小归一化, 本文图像像素的最大值为 255, 最小值为 0, 因此使用最大最小归一化法。

本文模型利用数据进行学习、调参和测试, 其中 60% 数据 (3 509 幅大米图像) 作为训练集, 30% 数据 (1 755 幅大米图像) 作为测试集, 10% 的数据 (584 幅大米图像) 作为验证集。验证集没有参与反向传播过程, 不会影响测试集评价的客观性和准确度, 仅供进行调参工作, 随机均匀地从 3 个数据集中抽样, 每个数据集的抽样比例都与原数据集相同。

1.2 VGG16 网络结构

VGG16 网络结构如图 2 所示, 输入分辨率为 $224 \text{ 像素} \times 224 \text{ 像素}$ 的 3 通道大米图像进入卷积层。在结束卷积操作后, 对输入数据批归一化处理, 作用是在经过非线性函数映射后, 将取值区间向极限饱和和区靠拢。强制拉回到均值为 0、方差为 1 的标准正态分布。最后进入池化层, 逐渐忽略局部特征信息。循环 4 轮以上操作, 在卷积操作完成后, 大米特

征信息进入全连接层, 将包含有局部信息的特征图, 包括特征图的高、宽、通道数全部映射到 4 096 维度, 最后针对本文多分类任务, 在输出层使用 4 个神经元, 配合 Softmax 分类器进行大米加工精度分级。VGG16 网络结构中, 卷积层均采用 3×3 卷积核, 步长为 1, 填充方式为 SAME, 使每一个卷积层与上一层保持相同的宽和高。池化层均采用 2×2 池化核, 填充方式为 SAME, 激励函数为 ReLU。

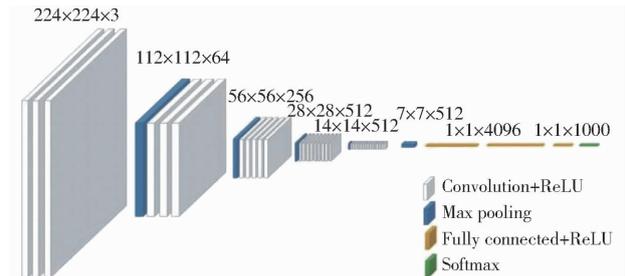


图 2 VGG16 网络结构

Fig.2 VGG16 network structure

1.3 改进 VGG16 卷积神经网络

1.3.1 超列技术

本文将靠近输入的卷积层称为底层卷积层, 靠近输出的卷积层称为高层卷积层。在卷积神经网络中, 越底层的卷积层包含的特征信息越具体, 如大米的空间位置、清晰度、背景亮度等, 越高层的卷积层包含的特征信息越抽象。在传统的卷积神经网络中, 通常使用最后一层的输出作为特征表示, 但是同一种类大米与很多特征明显的物体不同, 因为背景图像、米粒形状、颜色等相似, 使得高层卷积层的大米特征信息在通道维度中太粗糙, 分类效果较差。基于此, 本文提出基于超列技术^[20]的特征提取方法, 如图 3 所示。VGG16 模型中有 16 层权重层, 其中包括 13 层卷积层和 3 层全连接层, 超列技术针对 13 层卷积层, 最后 3 层全连接层在 VGG16 模型中作为分类器, 不具备特征提取能力。对于输入图像通道 i 位置的像素, 每一个通道相同位置的像素都对应着大米特征信息, 称之为大米特征的超列。将 13 层卷积层中的所有通道 i 位置的特征加起来, 同时加上全连接神经网络的 1 024 个深层特征, 对 5 248 ($1\ 024 + 64 \times 2 + 128 \times 2 + 256 \times 3 + 512 \times 6$) 个大米特征进行分类。

超列技术是一种掩蔽技术, 在原始图像上叠加了从卷积神经网络模型的前 13 层中获得的有效特征。这使得原始图像更加可见, 并增加了特征数量。通过超列技术从 1 ~ 4 级大米图像中获取掩码图像的热力图, 如图 4 所示, 超列掩模在卷积神经网络结构中将原始图像的每一个像素作为一系列向量来承载底层的特征。在本研究中, 由于在掩蔽步骤中使

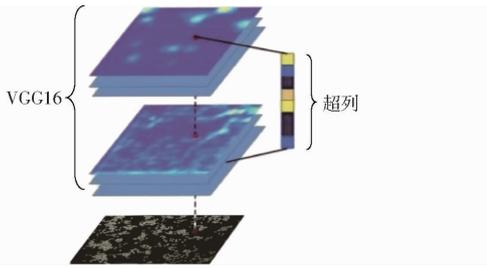


图3 超列技术结构

Fig.3 Technical structure of supercolumn

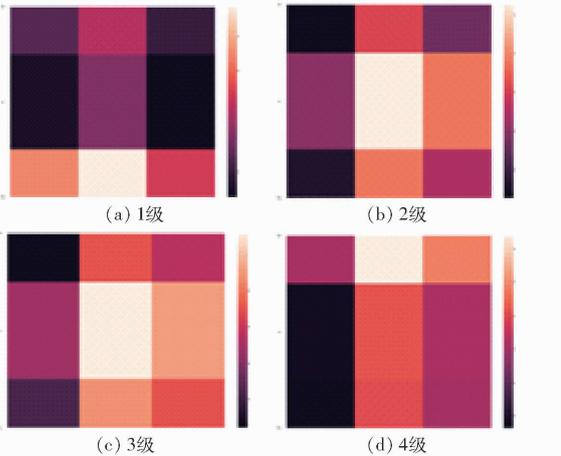


图4 4种不同等级大米的热力图

Fig.4 Heatmaps of four different grades of rice

用了3个主要的彩色通道,因此获得了彩色掩模,目标是产生更有效的特性,因为颜色通道会影响输入图像的深度和分辨率。

1.3.2 最大相关-最小冗余特征选择

分类问题中,在相关图像特征中选择有效的特征数据集是非常重要的,选择出好的图像特征具有减少特征数量、减少GPU处理时间、减少噪声、检测到更有特色特征等优点。图像特征在经过卷积、池化、超列等操作后,由于大米图像的特殊性,造成大米特征图像大量相似,产生大量冗余特征,选择传统的特征选择方法往往需要花费大量的时间,故本文使用最大相关-最小冗余(MRMR)特征选择算法^[21-22]进行特征选择。

MRMR算法根据特征与类标记的相关性列出特征,旨在使用所选的特征集选择最不相关的特征向量,目的是在存在其他所选特征的情况下通过其冗余来惩罚特征的相关性。MRMR算法原理如下:

MRMR算法通过消除大米特征数据集中的无关特征,计算特征和特征标记之间的相似性,得到互信息 $M(x,y)$ 。给定两个随机变量 x 和 y ,他们的概率密度函数(对应于连续变量)为 $p(x)$ 、 $p(y)$ 、 $p(x,y)$,则互信息计算公式为

$$M(x,y) = \iint p(x,y) \lg \frac{p(x,y)}{p(x)p(y)} dx dy \quad (1)$$

大米特征集 A 与类 b 的相关性由大米特征 f_i 和类 b 之间的所有互信息值的平均值定义。

$$D(A,b) = \frac{1}{|A|} \sum_{f_i \in A} M(f_i;b) \quad (2)$$

式中 $D(A,b)$ ——大米特征集 A 与类 b 的相关性函数

$M(f_i;b)$ ——大米特征 f_i 和类 b 之间的互信息

特征集 A 中所有特征的冗余是特征 f_i 和特征 f_j 之间的所有互信息值的平均值,计算公式为

$$R(A) = \frac{1}{|A|^2} \sum_{f_i, f_j \in A} M(f_i;f_j) \quad (3)$$

式中 $R(A)$ ——大米特征集 A 中所有特征的冗余

$M(f_i;f_j)$ ——特征 f_i 和特征 f_j 之间的互信息

1.3.3 极限学习机分类器

传统的一些基于梯度下降的算法,需要在迭代过程中调整所有参数,极大地增加了大米特征的处理速度,而在大米加工应用领域,大米等级判定的速度直接和利益挂钩,所以需要选择一种能够快速分类图像特征的分类器。本文提出使用极限学习机(ELM)分类器^[23]进行特征选择后的分类工作,工作原理如图5所示。

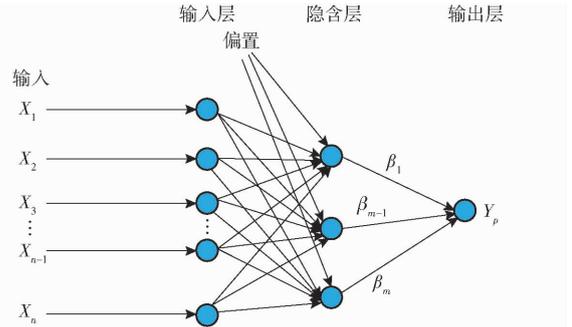


图5 ELM工作原理图

Fig.5 Working principle diagram of ELM

ELM是一种快速分类算法,对于单隐层神经网络,ELM可以随机初始化输入权重和偏置并得到相应的输出权重。假设有 N 个任意样本 $(\mathbf{x}_i, \mathbf{t}_i)$,其中 $\mathbf{x}_i = [x_{i1} \ x_{i2} \ \dots \ x_{in}]^T \in \mathbf{R}^n$, $\mathbf{t}_i = [t_{i1} \ t_{i2} \ \dots \ t_{in}]^T \in \mathbf{R}^m$ 。一个有 L 个隐含层节点的单隐层神经网络,可以表示为

$$O_j = \sum_{i=1}^L \beta_i g(W_i X_j + b_i) \quad (j=1, 2, \dots, N) \quad (4)$$

式中 L ——隐含层节点数量

g ——激活函数

β_i ——第 i 个大米特征的输出权重

W_i ——第 i 个大米特征的输入权重

\mathbf{X}_j ——大米特征矩阵

b_i ——第 i 个隐含层单元的偏置

O_j ——第 j 个大米特征隐含层节点预测输入
单隐层神经网络学习的目标是使输出误差最小, 可以表示为

$$\sum_{j=1}^N \| O_j - t_j \| = 0 \quad (5)$$

式中 t_j ——第 j 个大米特征隐含层节点真实输入
即存在 β_i 、 W_i 和 b_i 使得

$$\sum_{i=1}^L \beta_i g(W_i X_j + b_i) = t_j \quad (6)$$

所以预测输出矩阵为

$$H\beta = T \quad (7)$$

式中 H ——隐含层节点的输出矩阵

β ——输出权重

T ——期望输出矩阵

为了能够训练单隐层神经网络, 需满足

$$E = \sum_{j=1}^N \left[\sum_{i=1}^L \beta_i g(W_i X_j + b_i) - t_j \right]^2 \quad (8)$$

式中 E ——最小化损失函数

在 ELM 算法中, 一旦输入权重 W_i 和隐含层偏置 b_i 被随机确定, 隐含层输出矩阵 H 就被唯一确定。训练单隐层神经网络可以转化为求解一个线性系统 $H\beta = T$, 并且输出权重 β 可以被确定为

$$\beta = H^{-1}T \quad (9)$$

且可证明求得解的范数 $\hat{\beta}$ 最小且唯一。

1.3.4 改进 VGG16 网络结构

改进 VGG16 网络结构由 3 部分组成。首先使用图像增强技术确保数据在类之间均匀分布, 以提取出更有效的特征。然后利用平衡数据集上的超列技术, 使图像特征更加突出。在 VGG16 模型中, 从前几层得到的特征以向量格式保存在全连接层中, 利用 MRMR 对全连接层的 5 248 个深层特征进行评价。最后采用极限学习机分类器算法提升大米现实加工问题的泛化性能。改进 VGG16 网络结构如图 6 所示。

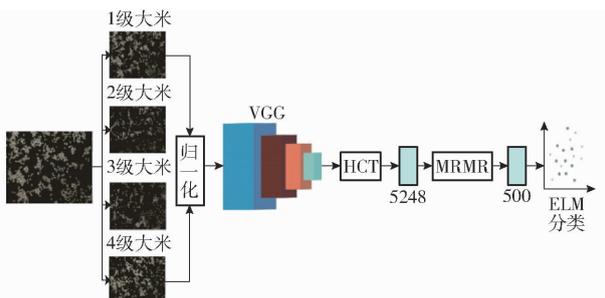


图 6 改进 VGG16 网络结构图

Fig.6 Improved VGG16 network structure

1.3.5 模型训练

本文采用交叉验证的方法来训练模型, 对于改

进 VGG16 网络结构, ELM 分类器采用 ReLU 激活函数应用 MRMR 算法选择最大相关最小相关特征, 跳过传统 MRMR 算法利用增量搜索方法逐步寻找最优特征子集, 而是直接对于每一个特征利用式 (4) 计算其重要性, 然后对大米特征的重要性降序排列, 分别提取最重要的前 100、500、1 000、2 000、3 000、4 000、5 248 个特征子集, 传递给极限学习机分类器进行比较。

1.3.6 评价指标

为对大米加工品质等级分类模型的性能进行评价, 选定召回率 (Recall, R)、精确度 (Precision, P)、F1 测度 (F1 score, F_1) 和准确率 (Accuracy, A) 作为模型预测性能的评价指标。

2 试验结果与分析

2.1 改进 VGG16 模型性能评估

将 MRMR 算法应用于 5 248 个大米特征集合。5 248 个特征被划分为 7 个包含 5 248、4 000、3 000、2 000、1 000、500、100 个特征的特征集, 并映射到 ELM 分类器, ELM 结构中的隐藏节点在训练过程中具有重要作用, 采用试差法, 选取具有 ReLU 激活函数的 3.5 万个隐藏节点作为研究对象。结果如表 2 所示。

表 2 7 种不同特征集分类结果

Tab.2 Classification results of seven different feature sets

特征集特征数量/个	GPU 平均执行时间/s	隐藏节点数量/个	测试准确率/%
5 248	0.089 2	35 000	94.31
4 000	0.082 3	35 000	95.01
3 000	0.076 1	35 000	95.54
2 000	0.074 2	35 000	95.61
1 000	0.066 2	35 000	96.03
500	0.054 2	35 000	97.32
100	0.050 2	35 000	88.23

从表 2 中可以看出, 包含 500 个特征的特征集的分类效果最优, 准确率最高为 97.32%。为了找出最优特征子集, 在 500 个特征子集中, 每 100 个特征子集进行一次试验, 选取包含 200、300、400、500、600、700、800、900 个特征共 8 种特征子集进行试验, 采用相同训练环境, 试验结果如表 3 所示。

从表 3 中可以看出, 特征集特征数量为 500 时准确率最高。从试验结果可以看出, 特征数量并不总是对分类性能产生积极影响, 相反会导致低效特征的增加。为了消除这一影响, 需要采用特征选择算法。利用 MRMR 算法筛选出最优的 500 个特征,

表3 8种特征子集分类结果

Tab.3 Classification results of eight feature subsets

特征集 特征数量/个	GPU 平均执行 时间/s	隐藏节点 数量/个	测试准确 率/%
900	0.065 1	35 000	96.23
800	0.062 3	35 000	96.36
700	0.058 8	35 000	97.01
600	0.056 2	35 000	97.31
500	0.054 2	35 000	97.32
400	0.053 4	35 000	96.03
300	0.052 2	35 000	94.23
200	0.051 1	35 000	92.91

测试准确率为 97.32%。

根据最优特征选择的 500 个特征和改进 VGG16 大米加工精度分级模型对测试集的 1 755 幅大米测试样本的等级进行预测,其结果如表 4 所示。由表 4 可知,基于改进 VGG16 的大米加工精度分级模型对 3 级大米的预测召回率最高,达到 98.63%,其原因可能是训练集中该类别样本数大于其他 3 个类别,使得召回率虚高。模型对 1 级大米的预测召回率次之,为 96.82%;对 2 级大米的预测召回率最低,为 96.15%。就模型的总体分类性能而言,基于

改进 VGG16 大米加工精度分级模型对 1 级大米的总体分类性能最佳(F1 测度为 97.34%),其原因可能是 1 级大米的形态特征相较于其他 3 个类别更易于区分。基于改进 VGG16 大米加工精度分级模型预测的总体准确率为 97.32%,GPU 预测单幅图像的平均时间为 0.054 2 s,每小时可以完成 85 t 大米的等级分类。

表4 改进的 VGG16 大米等级分类模型结果

Tab.4 Results of improved VGG16 rice classification model

级别	样本数 量/幅	召回率/ %	精确度/ %	F1 测 度/%	总体准确 率/%	单幅图像 预测时间/s
1 级	443	96.82	98.83	97.34		
2 级	420	96.15	96.53	96.36	97.32	0.054 2
3 级	452	98.63	98.21	96.56		
4 级	440	96.36	96.42	96.82		

2.2 改进 VGG16 模型和经典分类模型的对比

为了充分比较改进 VGG16 模型的性能,本文将 ImageNet 预训练模型、VGG16 模型、ALEXNET 模型和 BP 模型^[24]的超参数在原参数值基础上进行反复调参,最优超参数如表 5 所示。

表5 3种预训练模型的超参数

Tab.5 Super parameters of three pre training models

模型	优化器	学习率	衰减率	迭代次数	损失值	批尺寸
VGG16	RMS	0.000 01	0.2	500	categorical_crossentropy	30
ALEXNET	RMS	0.000 1	0.2	500	categorical_crossentropy	30
BP	RMS	0.000 1	0.3	500	categorical_crossentropy	30

从 keras.optimizers 中选取所需的优化器,优化器可以根据得到的导数结果选择合适的优化方向,使用 RMS 优化器优化,相较于 Adam 优化器精确度更高,相较于梯度优化器速度更快。学习率代表每次沿梯度方向修改的长度;衰减率用于计算迭代过程中的学习率,能够让学习率越来越小。损失值用于计算模型预测值与真实值的不一致程度;批尺寸表示一次训练所选取的样本数,影响模型的优化程度和速度。

VGG16、ALEXNET、BP 3 种分类模型都是在图像分类领域表现优秀的模型,与改进 VGG16 模型进行分类性能比较,结果如表 6 所示。

表6 4种模型分类结果对比

Tab.6 Comparison of classification results of models

模型	平均召回 率/%	平均精 确度/%	平均 F1 测度/%	总体准确 率/%	单幅图像 分类时间/s
改进 VGG16	96.99	97.50	97.27	97.32	0.054 2
VGG16	93.23	92.12	91.26	91.31	0.088 3
ALEXNET	92.16	90.83	88.76	89.93	0.089 6
BP	89.23	87.62	88.80	88.65	0.063 2

从表 6 可以看出,改进 VGG16 模型各项性能明显优于 VGG16 模型,总体准确率比 VGG16 模型提高了 6.01 个百分点,平均单幅大米图像分类时间比 BP 模型缩短了 0.009 s,说明改进 VGG16 模型能够有效地对大米等级进行分类。

3 结束语

提出了用于大米加工精度分类的改进 VGG16 模型,并进行了试验验证。结果表明,改进 VGG16 模型的总体准确率达到 97.32%,比 VGG16 模型提高了 6.01 个百分点。卷积操作产生的冗余大米特征会影响结合了超列技术的改进 VGG16 模型分类精度,为此引入 MRMR 算法,筛选出最有效的 500 个大米特征。改进 VGG16 模型在 GPU 上预测单幅大米图像的分类时间为 0.054 2 s,比 BP 模型缩短了 0.009 s,对大米加工精度的分级预测速度高于 85 t/h。改进 VGG16 模型的性能基本满足大米加工生产线精度分级要求,可为后续研制大米加工精度在线分级系统提供理论支持。

参 考 文 献

- [1] LUO Y H, JIANG P, XIE K, et al. Research on optimal predicting model for the grading detection of rice blast [J]. *Optical Review*, 2019, 26: 118 – 123.
- [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*, 2019, 148:106969.
- [3] 安红周,陈会会,薛义博,等.不同碾磨时间对粳糙米加工特性的影响研究[J].*食品科技*,2019,44(8):169–173.
- [4] LIU Y, LI N, ZHANG Z T, et al. The central trend in crop yields under climate change in China: a systematic review [J]. *Science of the Total Environment*, 2020, 704: 135355.
- [5] WENG S Z, TANG P P, YUAN H C, et al. Hyperspectral imaging for accurate determination of rice variety using a deep learning network with multi-feature fusion[J]. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 2020, 234:118237.
- [6] 胥保文,蔡健荣,张文松,等.稻米加工装备工艺控制系统设计[J].*食品工业*,2018,39(2):225–228.
- [7] KARLEKAR A, SEAL A. SoyNet: soybean leaf diseases classification[J]. *Computers and Electronics in Agriculture*, 2020, 172:105342.
- [8] QUAN Q, WANG J X, LIU L L. An effective convolutional neural network for classifying red blood cells in malaria diseases [J]. *Interdisciplinary Sciences-Computational Life Sciences*, 2020, 12: 217 – 225.
- [9] SHIM J, KANG S, CHO S. Active learning of convolutional neural network for cost-effective wafer map pattern classification [J]. *IEEE Transactions on Semiconductor Manufacturing*, 2020, 33(2): 258 – 266.
- [10] XIE W, MA G N, ZHAO F, et al. Poisar image classification via a novel semi-supervised recurrent complex-valued convolution neural network[J]. *Neurocomputing*, 2020, 388: 255 – 268.
- [11] KUO T Y, CHUNG C L, CHEN S Y, et al. Identifying rice grains using image analysis and sparse-representation-based classification [J]. *Computers and Electronics in Agriculture*, 2016, 127: 716 – 725.
- [12] DEVI T G, NEELAMEGAM P, SUDHA S, et al. Machine vision based quality analysis of rice grains [C] // 2017 IEEE International Conference on Power, Control, Signals and Instrumentation Engineering. New York: IEEE, 2017.
- [13] SINGH K R, CHAUDHURY S. Efficient technique for rice grain classification using back-propagation neural network and wavelet decomposition[J]. *IET Computer Vision*, 2016, 10(8): 780 – 787.
- [14] KRISHNASWAMY R, ARAVIN D, RAJA P. Disease classification in eggplant using pre-trained VGG16 and MSVM [J]. *Scientific Reports*, 2020, 10(1): 1 – 11.
- [15] KRISTIANI E, YANG C T, HUANG C Y. ISEC: an optimized deep learning model for image classification on edge computing [J]. *IEEE Access*, 2020, 8: 27267 – 27276.
- [16] RAGHU S, SRIRAM N, TEMEL Y, et al. Eeg based multi-class seizure type classification using convolutional neural network and transfer learning[J]. *Neural Networks*,2020, 124: 202 – 212.
- [17] VALAN M, MAKONYI K, MAKI A, et al. Automated taxonomic identification of insects with expert-level accuracy using effective feature transfer from convolutional networks[J]. *Systematic Biology*, 2020, 68(6): 876 – 895.
- [18] WANG S D, DONG L Y, WANG X. Classification of pathological types of lung cancer from CT images by deep residual neural networks with transfer learning strategy [J]. *Open Medicine*, 2020, 15: 190 – 197.
- [19] TOGACAR M, COMERT Z, ERGEN B, et al. Classification of brain MRI using hyper column technique with convolutional neural network and feature selection method [J]. *Expert Systems with Applications*, 2020, 149:113274.
- [20] 徐俊波,周国祥,沈轶杰,等. NCEP 震前异常增温数据插值及可视化方法 [J]. *合肥工业大学学报(自然科学版)*, 2019, 42(9):1199–1204,1257.
- [21] 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: 47 – 61.
- [22] GU X Y, GUO J C, XIAO L J, et al. A feature selection algorithm based on equal interval division and minimal-redundancy-maximal-relevance [J]. *Neural Processing Letters*, 2020, 51: 1237 – 1263.

(上接第 341 页)

- [29] 郭文川,朱新华,郭康权. 采后苹果电特性与生理特性的关系及其应用 [J]. *农业工程学报*, 2005,21(7): 143 – 146. GUO Wenchuan, ZHU Xinhua, GUO Kangquan. Relationship between electrical properties and physiological properties of postharvest apples and its application [J]. *Transactions of the CSAE*, 2005,21(7): 143 – 146. (in Chinese)
- [30] 李明霞,韩建群,王琦,等. 低强度微波处理对猕猴桃细胞壁降解酶活性的影响 [J]. *食品与发酵工业*, 2015, 41(11): 52 – 58. LI Mingxia, HAN Jianqun, WANG Qi, et al. Effect of low intensity microwave on cell wall degradation enzymes activity of kiwifruit [J]. *Food and Fermentation Industries*, 2015, 41(11): 52 – 58. (in Chinese)
- [31] ZOLFAGHARI M, SAHARI M A, BARZEGARR M, et al. Physicochemical and enzymatic properties of five kiwifruit cultivars during cold storage [J]. *Food & Bioprocess Technology*, 2010, 3(2):239 – 246.
- [32] 秦海容,徐丹,刘琴. 壳聚糖复合涂膜的微观形貌变化及其对红桔的保鲜效果 [J]. *食品与发酵工业*, 2018, 44(2): 233 – 239. QIN Hairong, XU Dan, LIU Qin. Morphologies changes of chitosan composite coating and effects on preservation of tangerine [J]. *Food and Fermentation Industries*, 2018, 44(2): 233 – 239. (in Chinese)
- [33] DA Y, DONGLI L, WENCAI X, et al. Effects of packaging design with dual function films on quality of wax apples stored at ambient temperatures [J]. *Food & Bioprocess Technology*, 2018, 11(10): 1904 – 1910.
- [34] LIU Y, YANG X, ZHU S, et al. Postharvest application of MeJA and NO reduced chilling injury in cucumber (*Cucumis sativus*) through inhibition of H₂O₂ accumulation [J]. *Postharvest Biology and Technology*, 2016, 119: 77 – 83.
- [35] 盘柳依,赵显阳,陈明,等. 外源茉莉酸甲酯处理对采后猕猴桃果实品质和抗氧化酶活性的影响 [J]. *食品与发酵工业*, 2019, 45(9): 190 – 196. PAN Liuyi, ZHAO Xianyang, CHEN Ming, et al. Effects of exogenous methyl jasmonate on fruit qualities and antioxidants activities of postharvest kiwifruits [J]. *Food and Fermentation Industries*, 2019,45(9): 190 – 196. (in Chinese)
- [36] VIJAY R, SHARMA K S. Investigation of dielectric properties of some varieties of apple and their correlation with nutrients [J]. *Journal of Pure Applied and Industrial Physics*, 2017,7(10): 383 – 390.
- [37] 李芳,蔡骋,马惠玲,等. 基于生物阻抗特性分析的苹果霉心病无损检测 [J]. *食品科学*, 2013,34(18): 206 – 211. LI Fang, CAI Cheng, MA Huiling, et al. Nondestructive detection of apple mouldy core based on bioimpedance properties [J]. *Food Science*, 2013,34(18): 206 – 211. (in Chinese)