

可见光谱图与深度神经网络的垩白大米检测方法

林 萍¹, 张华哲¹, 何坚强¹, 邹志勇², 陈永明^{1*}

1. 盐城工学院电气工程学院, 江苏 盐城 224051

2. 四川农业大学电机学院, 四川 雅安 625014

摘 要 针对传统垩白大米检测主观随意性大、可重复性低、检测过程耗时费力、准确率低等问题, 提出一种基于可见光谱图结合深度学习算法的垩白大米检测手段。用 CCD 彩色摄像机获取垩白大米和正常大米可见光谱图, 对图像进行旋转、翻转以及调整对比度等随机图像变换方式提升网络训练数据集, 防止深度检测模型在学习过程中出现过拟合现象。构建了7层深层次卷积神经网络模型, 包括卷积层、池化层、全连接层和输入输出层, 通过网络模型对采样的大米可见光谱图集进行卷积与池化操作, 采用迭代学习训练方法获取大米可见光谱图在卷积层输出的特征参数, 采用连接非线性 ReLU 激活函数来降低训练时间, 以加速大米可见光谱图有效抽象特征提取的收敛速度; 然后将深度神经网络嵌入池化层, 对大米特征降维以获取能够表达正常大米和垩白大米可鉴别显著意义特征; 最后在全连接层输出进行分类, 从而实现对垩白大米的精确识别。基于可见光谱图的大米垩白深度检测方法比传统基于可见光谱图的垩白大米鉴别特征提取方法免去了复杂的特征提取步骤, 由于卷积网络提取的特征对特定目标具有更鲁棒的表达, 算法精度较高且复杂度比较小, 泛化效果更好, 获得识别精度达到 90%, 比基于传统特征提取的垩白大米鉴别方法识别精度高, SIFT+SVM, PHOG+SVM 和 GIST+SVM 模型识别精度分别为 70.83%, 77.08% 和 79.16%。提出的方法为当前我国现代农业生产中实现大米品质自动化快速精准检测提供了理论依据和有效的技术手段, 对于现阶段实现大米品质人工智能检测产生实际意义。

关键词 可见光谱图; 大米; 垩白; 深度神经网络; 人工智能

中图分类号: S24 **文献标识码:** A **DOI:** 10.3964/j.issn.1000-0593(2020)01-0233-06

引 言

大米是世界上最重要的粮食作物, 大米品质的好坏直接影响到人们的生活健康状况, 如何快速准确地对大米品质进行判别成为目前国际学术领域重要的研究课题。垩白参数是影响大米市场销售价格的主要因素之一。大米垩白是在大米籽粒胚乳中心白色不透明部分, 它是由于稻米胚乳中蛋白和淀粉颗粒填充疏松和充气引起的, 按其在大米颗粒中出现的部位可分为腹白、心白和背白等类型, 是大米籽粒在结构上的一种缺陷^[1]。传统的大米垩白的检测方法是基于人工目测抽样检测, 主观性较大, 不同人员的检测结果往往不一致, 这就严重影响了大米品质判别准确度。因此, 国内外采用机器视觉结合模式识别处理技术开展了针对大米中的垩白的自动化检测研究。房国志^[2]提出了一种基于形态学分水岭的图

像垩白区域检测方法。刘璿瑛^[3]提出了采用切比雪夫逼近方法的大米垩白自动分割。王卫星^[4]提出了基于直方图修正和小波自适应定位多阈值算法对大米垩白区域进行有效分割。黄星奕^[5]等采用遗传神经网络对大米垩白度进行计算, 结果显示基于机器视觉的检测方法由于图片的获取过程需要外加光源照射, 正常米粒中有一部分区域会造成强反射现象, 容易引发误判。目前提出的基于机器视觉的垩白大米图像检测方法都是采用由人工来选定目标特征的方式, 人工提取到的特征对于大米的垩白特性表达性能不一致, 因此最终获得的检测精度并不理想。

为了解决现有垩白大米检测算法效率低, 精度不高的问题, 提出了一种基于可见光谱图的垩白大米深度检测方法, 通过构建深层次卷积神经网络模型对大米垩白区域进行特征提取, 通过深层次隐含模型训练来确定网络结构并获取深度检测模型的最佳特征权重参数, 进而有效提升垩白大米的检

收稿日期: 2019-09-24, 修订日期: 2019-11-29

基金项目: 国家自然科学基金项目(31601227, 31501221, 61803325), 江苏省自然科学基金项目(BK20161310, BK20181049)资助

作者简介: 林 萍, 女, 1982年生, 盐城工学院电气工程学院副教授 e-mail: binglvcha007@126.com

* 通讯联系人 e-mail: billrange@126.com

测精度。

1 实验部分

1.1 仪器

基于机器视觉的垩白大米检测分析实验平台系统原理图如图 1 所示。该系统主要部件由暗箱、CCD 像机、图像采集卡、计算机、光源和载物台构成。样品放在暗箱内；暗箱下面是载物台，暗箱顶部安装有 CCD 像机，可以同时采集 700, 550 和 440 nm 附近 3 个波段的大米可见光谱图像信息。暗箱部安装有光源；为了避免样品在检测时形成镜面反射，暗箱内表面均粘贴有背景纸，使得光在箱体内部形成均匀的漫反射。为了进一步消除光源照射时在背景上产生的阴影，最终选用环形荧光灯管作为照射光源。图像采集采用松下 WV-CW370 型 CCD 彩色像机和嘉恒公司的 OK_C30A-E 型彩色图像采集卡，其中像机镜头采用精工 SE1614 型 F1.4 的 16.0 mm 24 位真彩色高清摄像镜头，其分辨率为 $1\ 024 \times 768$ ，并结合环形光源，确保能采集到准确清晰的大米图像信息。一台 Alienware 17 R3 笔记本电脑(美国戴尔)配置有 Nvidia Geforce GTX 980M, 8 GB 图形卡和 Intel Core(tm)i7-6820hk CPU, 16G 内存卡, 1T 数据存储容量卡。

1.2 样本

实验样本采用三种不同粒型的大米，糯米、泰国香米和长粒香。白样本信息如表 1 所示。通过深度学习网络对大米垩白区域进行检测需要大量样本数据对网络进行学习训练，

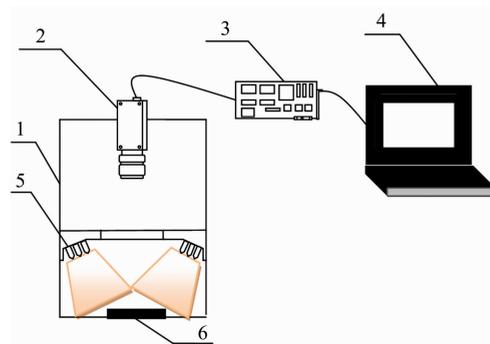


图 1 基于机器视觉的垩白大米检测分析实验平台系统原理图

1: 暗箱; 2: CCD 像机; 3: 图像采集卡;
4: 计算机; 5: 光源; 6: 载物台

Fig. 1 Schematic diagram of chalky rice detection and analysis platform based on machine vision

1: Black box; 2: CCD camera; 3: Image acquisition card;
4: Computer machine; 5: Light source; 6: Loading platform

若全部采用实验获取的垩白大米图像会增大采集工作量，并且原始图像数据集不够充分，不能满足网络学习和训练的要求。因此，对采集到的大米图像数据通过旋转、翻转以及调整对比度等随机变换处理对图像数据进行增强，提升网络训练数据集，从而提升网络的整体的学习性能。通过数据增强方法将大米样本集扩充至 3300 张，用于防止深度检测模型在学习过程中出现过拟合现象。

表 1 大米样本数据集

Table 1 Dataset for rice samples

Category	Training set			Validation set		
	Changlixiang rice	Glutinous rice	Thailand rice	Changlixiang rice	Glutinous rice	Thailand rice
Chalkness rice	400	400	400	150	150	150
Non-chalkness rice	400	400	400	150	150	150

2 理论和方法

2.1 SIFT 算子

尺度不变特征变换(scale-invariant feature transform, SIFT)^[6]算子通过在多尺度空间中寻找尺度域和图像域上的极值点的方法使得特征点对图像缩放、旋转和平移具有不变性。SIFT 算子通过特征点附近邻域像素的梯度直方图给每个特征点匹配一个主方向，进而保证特征点对旋转具有不变性，最后利用特征点周围邻域内像素的梯度为提取到的每一个特征点建立一个 128 维的描述子，由此提取的每一个特征点都可以用一个 128 维的特征向量进行表示。图 2(b)是提取的含有垩白大米图片的 SIFT 特征点，从图中可以看出，提取的特征点主要集中分布在非垩白区域。

2.2 GIST 算子

空间包络算子(GIST)^[7]是一种生物启发式算法，该算

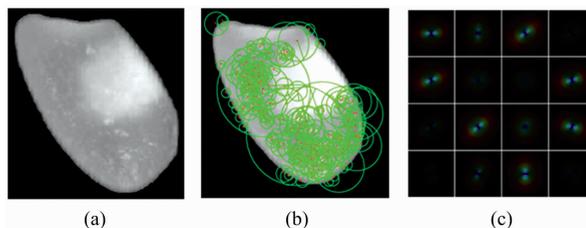


图 2 (a)原始垩白大米图片; (b) SIFT 关键特征分布图; (c) GIST 网格图像的全局特征信息

Fig. 2 (a) Original chalky rice image; (b) SIFT key characteristic distribution map of chalky rice; (c) GIST global feature information of chalky rice

法通过对人体视觉活动的模拟，获得图像中的上下文信息，从而形成对外部世界的一种空间表示。GIST 算子核心主要是将 Gabor 函数扩展到多尺度空间，并将 Gabor 滤波器进行

多尺度旋转后对垩白大米图像在频率域进行特征获取，并将滤波后的图像进行均匀划分如图 2(c)所示，接着采用窗口傅里叶变换和离散傅里叶变换将每个网格图像的全局特征信息提取出来，最终获得可鉴别的垩白大米 GIST 网格图像的全局特征信息。

2.3 PHOG 算子

金字塔梯度方向直方图(pyramid of histograms of orientation gradients, PHOG)^[8]算子是对形状的一种空间描述，它首先利用 Canny 算子提取出图像的边缘信息，其次对图像进行层次化表征，然后提取每层次各子区域的梯度直方图特征，最后将各子区域的梯度直方图特征进行级联，由此构造

出原始垩白大米图像的 PHOG 特征。图 3(a)为原始的垩白大米图像；图 3(b1)为垩白大米图像第一金字塔层表征层，即原始图像采用 Canny 算子提取的轮廓图像，图 3(b2)为垩白大米图像第一金字塔层特征分布图；图 3(c1)为垩白大米图像第二金字塔层表征层，图 3(c2)为垩白大米图像第二金字塔层均匀 4 等分特征分布图；图 3(d1)为垩白大米图像第三金字塔层表征层，图 3(d2)为垩白大米图像第三金字塔层均匀 16 等分特征分布图；从图 3(b2)，(c2)和(d2)中可以看出，随着分割层数的增加，统计梯度直方图对图像的刻画也越来越具鲁棒性和精细化。

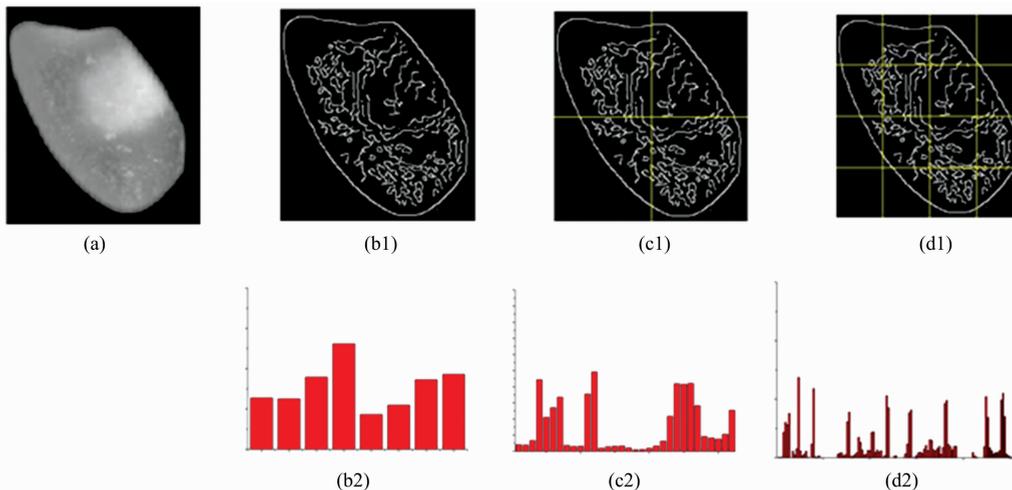


图 3 垩白大米 PHOG 特征分区检测及相应的统计梯度直方图

Fig. 3 PHOG characteristic detection and statistical gradient histogram of chalky rice

2.4 深层次卷积神经网络构架

样本图像采集时由于光照、背景等扰动因素影响，通过人工方式设计一个鲁棒性强、能有效表达垩白大米样本特征算子在实际应用中十分困难。因此，提出构建深层次卷积神经网络(convolutional neural networks, CNN)模型来提高垩白大米样本的识别精度，从而避免了繁琐的特征算法选择和特征设计的过程。

2.4.1 卷积网络层结构

传统的神经网络构架每个输出都与每个输入完全相连，而卷积神经网络构架采用局部感受野策略，使得每个输出单元只与输入图片的部分区域相连，因此只能感知获取的图片局部区域，而不能涉及图像的全局信息^[9-10]，需要利用空间局部相邻单元之间的相关性进行运算。利用 CNN 实现全局图像特征参数共享，在局部连接中确保每个神经元的参数一致，减少了整个网络的参数数量，有效利用空间局部相邻单元之间的相关性进行卷积运算，改进提高了网络计算精度。如图 4 所示，垩白大米深层次卷积神经网络模型特征提取模型由输入模块(Input)、卷积运算模块(C1、C2)、池化采样操作模块(S1、S2)、全连接运算(F1)和输出模块(Output)系统构成。卷积层参数可以看作是一种能够通过网络训练和学习得到优化的滤波器，在前向计算过程中，滤波器和上层网络局部区域的数据进行卷积运算后得到新特征参数作为卷积层

的神经元，该滤波器在原始图片上按照设定的步长进行滑动，再与各局部区域的数据进行卷积运算，计算出所有的新神经元，由此组成所需要的卷积层。然后将得到卷积层数据输入池化层进行降维处理，网络进行一系列的卷积与池化操作之后接入全连接层，全连接层将提取到的特征向量通过 Softmax 分类器进行分类，分类结果和数据集标签进行比对并计算损失函数，随后通过梯度下降算法对参数进行反向传播对网络进行优化，从而调整网络参数，网络在不断训练学习的过程中降低损失值(Loss)直到设定的阈值后收敛。

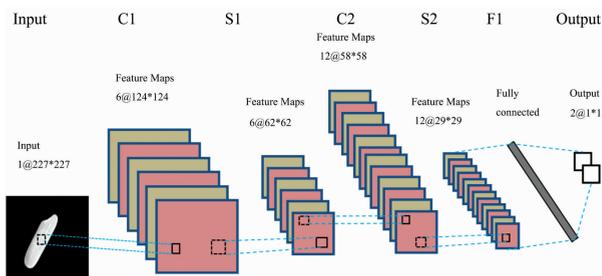


图 4 垩白大米深层次卷积神经网络模型特征提取原理图

Fig. 4 Diagram of deep convolution neural network model for chalky rice

2.4.2 卷积模块

在卷积模块中使用可训练的卷积核与上一层输出的图像进行卷积运算,卷积核以固定的观察域大小通过在前层输出图像上以设定的步长均匀滑动来实现特征提取操作,通过不同核大小的卷积特征模块来获取不同尺度图像的语义特征信息。其中,不同的卷积核映射出不同特征,即可以提取出图像中某类特定表达特征,因此用 n 个卷积核经过卷积运算后就可以提取 n 种特征,最终输出 n 个不同语义信息的特征图,具体的均匀滑动卷积运算公式如式(1)所示

$$x_j^{(l)} = f\left(\sum_{i \in M_j} x_i^{(l-1)} \otimes k_{ij}^{(l)} + b_j^{(l)}\right) \quad (1)$$

其中, \otimes 表示卷积运算符; $f(\cdot)$ 表示非线性映射; $x_j^{(l)}$ 表示第 l 层卷积运算后第 j 个神经元的输出; $x_i^{(l-1)}$ 表示第 $l-1$ 层的第 i 个神经元的输出; $k_{ij}^{(l)}$ 表示第 l 层卷积核; $b_j^{(l)}$ 表示第 l 层的偏置; M_j 表示输入层的局部感受野。

2.4.3 池化操作

在每个卷积层之后都有一个池化层,池化层的功能是降低上一层卷积计算输出的维数,有效减少训练参数的数量,防止过拟合,从而压缩图像的空间大小。经典 CNN 模型通常采用最大值池化层策略和平均值池化层策略^[11-12]。即将提取到的特征图像区域的一部分求最大值或者平均值,由求得的矩形邻域内的最大值或平均值来代表该部分区域,其中最大值池化策略最常用。池化层的计算公式如式(2)所示。

$$x_j^{(l)} = f(\beta_j^{(l)} \text{down}(x_j^{(l-1)}) + b_j^{(l)}) \quad (2)$$

其中, β 为特征图系数, $\text{down}(\cdot)$ 为采样函数。在卷积神经网络中,卷积层与池化层通常交替进行,并且每个卷积层都包含多个特征图,每个卷积核对应一种特定特征,因此每个卷积层都能提取出多个特征图,这些特征图经过线性组合形成更抽象的卷积特征图,由此形成对输入图片的语义特征描述。

2.4.4 全连接层

输入图像经过多层的卷积和池化操作处理后,最终提取的特征图按行展开成向量输入全连接网络。在全连接层中,每个神经元都要与前一层网络中的所有神经元相连,最后全连接层与输出层相连,输出属于各个类别的得分值。输出层通常为分类器,常用的分类器有 Softmax 函数作为特征分类器,函数计算公式如式(3)

$$h(x^{(i)}) = \frac{e^{\theta_k^T x^{(i)}}}{\sum_{j=1}^K e^{\theta_j^T x^{(i)}}} \quad (3)$$

式中, $h(x^{(i)})$ 表示样本 i 属于第 k 类的概率,总类别数为 K 。

3 结果与讨论

采用的 CNN 网络结构主要包含 3 层,分别由输入层、隐含层和输出层构成。隐含层包括 5 个层,即 C1, S1, C2, S2 和 F1。第一层的输入为网络训练提供数据,由于深度学习的框架要求输入图片大小统一为 227×227 大小的彩色图像,因此将数据库中所有输入图片调整为像素尺寸为 227×227 的标准。C1 层为第一层卷积层,该卷积层通过大小为

9×9 的卷积核按照设置步长为 2 滑动,随后提取出 6 幅 124×124 大小的特征图, S1 层为第一层池化层,该层将上层提取的特征图按 1:2 的比例采用最大值池化策略进行下采样处理得到 6 幅 62×62 大小的特征图;第二层卷积层为 C2 层,该卷积层通过大小为 5×5 的卷积核按照滑动步长为 1,提取出 12 幅 58×58 大小的特征图, S2 层为第二层池化层,下采样比例设定为 1:2,由此获得的特征图尺寸为 29×29 ,最后将提取的 12 幅特征图与全连接层相连;全连接层 F1 分别与上一层的对应单元相连接,共有 10 092 个单元,最后输出层包括两个分类单元,给出预测的分类结果。其中一类对应包含垩白的大米样本,另一类为正常大米样本。

3.1 整定网络训练参数

深度卷积网络的训练批处理参数设为 64,迭代次数设为 250,学习率设为 0.1。测试了三种不同激活函数的收敛情况,如图 5 所示。当增加 CNN 神经网络训练迭代次数时, Loss 值总体呈现下降趋势。当迭代次数达到 100 次后,下降趋势得到缓和,曲线趋于平缓。当迭代次数达到 200 后,损失值小于 0.1,虽然仍然有所降低,但下降程度不明显。Sigmoid 函数的损失值在迭代次数为 100 到 200 区间有所上升,在迭代次数达到 200 后损失值继续下降并趋于收敛。因为 Sigmoid 函数是连续非线性的软饱和函数,且其导函数在整个定义域内连续; Tanh 函数的收敛程度与 Sigmoid 函数接近;当迭代次数为 150 时收敛,但损失值较大。ReLU 函数收敛速度较慢,主要原因时 ReLU 函数是分段的非线性函数,导致不同区域的部分特征线性没有得到有效处理,但当在迭代次数为

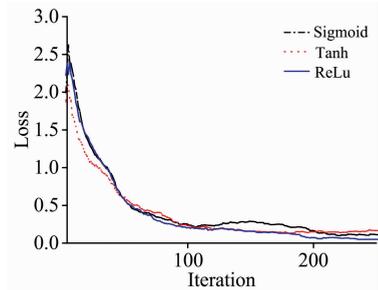


图 5 不同激活函数迭代次数与损失值之间的关系

Fig. 5 The relationship between the number of iterations and the loss value for different activation functions

200 时,收敛性能得到了有效的改善,即输出的 Loss 值最小,因此本研究选用 ReLU 函数作为激活函数来训练网络。

3.2 算法性能比较

图 6 为四种不同预测模型的查全率查准率曲线图 (precision recall curve),图中纵坐标为查全率 (recall),横坐标为查准率 (precision)。通常评判检测模型好坏时,查全率查准率值越高模型检测效果越好,也就是查全率查准率曲线上的点越接近右上角坐标 (1, 1) 说明模型检测效果越好。因此,查全率查准率曲线覆盖面积 (Area under Curve, AUC) 是综合评定检测模型性能的指标之一,其值越接近 1 说明模型预测效果越好。从查全率查准率曲线可以看出,对于验证集样本 CNN 模型的查全率查准率曲线覆盖面积最大,预测准确率

最高,其次依次为 GIST+SVM, PHOG+SVM 和 SIFT+SVM 模型。

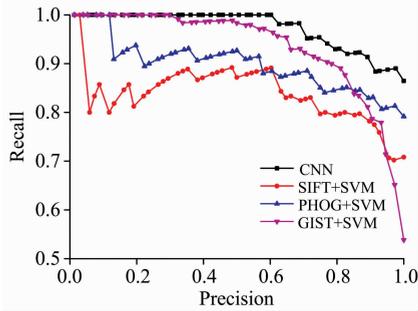


图 6 四种不同模型验证集样本查全率查准率曲线图

Fig. 6 Precision recall curves of four different models

表 2 为训练集样本和验证集样本分别采用 SIFT+SVM, PHOG+SVM, GIST+SVM 和 CN 四种不同方法建立的检测模型效果。对于训练集样本 SIFT+SVM, PHOG+SVM, GIST+SVM 和 CNN 四种建模方法的检测精度分别为 81.47%, 83.84%, 78.76% 和 94.79%, 其中 CNN 模型的精度最高。还计算了 mAP (mean average precision) 值, 在训练集样本中 CNN 的 mAP 值最高为 0.93, PHOG+SVM, SIFT+SVM 和 GIST+SVM 模型分别为 0.86, 0.89 和 0.88。在训练集样本中 CNN 表现出了最优的检测性能。对于验证集样本, CNN 的预测精度最高为 90%, mAP 值为 0.91, 预测效果明显好于其他三个模型。SIFT+SVM, PHOG+SVM, GIST+SVM 的三个模型检测精度分别为 70.83%, 77.08% 和 79.16%, 因此 CNN 模型的检测方法要优于基于传统特征提取的垩白大米鉴别方法。说明构建的深层次卷积神经网络模型提取到的特征对大米垩白特征具有更

鲁棒的表达,泛化效果更好,从而使垩白大米检测效果得到显著的提升。

表 2 四种不同模型检测性能参数

Table 2 Detection performance of four different models

Model	Training		Validation	
	mAP	Accuracy/%	mAP	Accuracy/%
SIFT+SVM	0.89	81.84	0.82	70.83
PHOG+SVM	0.86	83.84	0.84	77.08
GIST+SVM	0.88	78.76	0.88	79.16
CNN	0.93	94.79	0.91	90.00

4 结 论

构建了深度卷积神经网络模型应用于垩白大米可见光谱图的检测,与传统的图像识别方法相比,深度卷积神经网络不需要人为地对输入图片进行特征提取,采集到的图像能够直接输入到神经网络中,特征提取的工作由卷积神经网络通过学习和训练自动完成,免去了复杂的特征提取步骤,大大减少了数据预处理的难度。同时权值共享策略与局部感受野减少了参数空间,大大降低了算法的复杂度,提高了算法效率,增强了网络的鲁棒性和泛化性。当卷积神经网络的学习率为 0.1,迭代次数为 200 时,模型的识别精度最高为 90.00%。传统基于可见光谱图的垩白大米鉴别方法 SIFT+SVM, PHOG+SVM 和 GIST+SVM 分别为 70.83%, 77.08% 和 79.16%。本方法为当前我国现代农业生产大米品质自动化快速精准检测提供了理论依据和有效的技术支撑,具有一定的理论价值和实际意义。

References

- [1] DING Hua, WANG Jing, YAN Wei, et al(丁 华, 王 婧, 严 伟, 等). Hubei Agricultural Sciences(湖北农业科学), 2015, 54(23): 6012.
- [2] FANF Guo-zhi, XU Jiang-dong, WANG Quan, et al(房国志, 徐建东, 王 全, 等). Journal of Optoelectronics Laser(光电子激光), 2010, 21(4): 569.
- [3] LIU Ying-ying, DING Wei-min, LI Yi-nian(刘璎璎, 丁为民, 李毅念). Journal of Agricultural Engineering(农业工程学报), 2013(18): 262.
- [4] WANG Wei-xing, LIU Yong-qiang(王卫星, 刘永强). Journal of Chongqing University of Posts and Telecommunications(重庆邮电大学学报·自然科学版), 2010, 22(2): 218.
- [5] HUANG Xing-yi, WU Shou-yi, FANG Ru-ming, et al(黄星奕, 吴守一, 方如明, 等). Journal of Agricultural Engineering(农业工程学报), 2003, 19(3): 137.
- [6] TAN Xiang, MAO Hai-ying, ZHI Xiao-dong, et al(谭 翔, 毛海颖, 支晓栋, 等). Spectroscopy and Spectral Analysis(光谱学与光谱分析), 2018, 38(2): 413.
- [7] Li Haojie, Sun Fuming, Liu Lijuan, et al. Neurocomputing, 2015, 169: 77.
- [8] Acharya U R, Fujita H, Bhat S, et al. Information Fusion, 2015, (29): 32.
- [9] Rawat W, Wang Z H. Neural Computation, 2019, 29(9): 1.
- [10] Du C B, Gao S S. IEEE Access, 2017, 5(1): 99.
- [11] Liu Z, Blasch E, Xue Z Y, et al. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34 (1): 94.
- [12] Shelhamer E, Long J, Darrell T. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 39(4): 640.

Research on Chalky Rice Detection Based on Visible Spectrogram and Deep Neural Network Technology

LIN Ping¹, ZHANG Hua-zhe¹, HE Jian-qiang¹, ZOU Zhi-yong², CHEN Yong-ming^{1*}

1. College of Electrical Engineering, Yancheng Institute of Technology, Yancheng 224051, China

2. College of Mechanical and Electrical Engineering, Sichuan Agricultural University, Ya'an 625014, China

Abstract Aiming at the problems of subjective randomness, low repeatability, being time-consuming and low accuracy of traditional chalky rice detection, a new method based on visible spectrogram combined with deep learning algorithm is proposed to meet the requirement of rapid and accurate rice quality parameters in modern agricultural production. In the experiment, CCD color camera was used to obtain the visible spectra of chalky rice and normal rice. Random image transformation methods such as rotation, flipping and contrast adjustment were used to enhance the network training data set to prevent the fitting phenomenon of the depth detection model in the learning process. In this paper, seven deep-level convolution neural network models, including convolution layer, pooling layer, full-connection layer and input-output layer is constructed. The visible spectral image of rice is convoluted and pooled by network model. The characteristic parameters of visible spectral image of rice in convolution layer are obtained by iterative learning training method. The non-linear ReLU activation function is used to accelerate the convergence rate of the effective abstract feature extraction of rice; then the pool layer is employed to obtain the distinguishable semantic features that can express normal rice and chalky rice; finally, the data are transported into the full connection layer. The chalky rice can be identified accurately by classification. The method of rice chalkiness detection based on convolution neural network eliminates the complicated steps of feature extraction compared with the traditional method. Because the features extracted by convolution network have more robust expression for specific targets, the algorithm has higher accuracy and less complexity, and the generalization effect is better than the traditional method based on visible spectrogram. The recognition accuracy is up to 90%. The recognition accuracy of SIFT+SVM, PHOG+SVM and GIST+SVM are 70.83%, 77.08% and 79.16% respectively. The proposed method provides a theoretical basis and effective technical means for the realization of automatic and accurate detection of rice quality in modern agricultural production. Therefore, this study has certain theoretical value and practical significance for the realization of artificial intelligence detection of rice quality.

Keywords Visible spectrogram; Rice; Chalkiness; Deep learning; Artificial intelligence

(Received Sep. 24, 2019; accepted Nov. 29, 2019)

* Corresponding author