

基于多尺度卷积神经网络的缺陷红枣检测方法

Defective jujube detection technology based on multi-scale convolutional neural network

方 双 赵凤霞 楚松峰 吴振华

FANG Shuang ZHAO Feng-xia CHU Song-feng WU Zhen-hua

(郑州大学机械与动力工程学院, 河南 郑州 450001)

(School of Mechanical and Power Engineering, Zhengzhou University, Zhengzhou, Henan 450001, China)

摘要:提出了一种基于多尺度卷积神经网络的缺陷红枣检测方法,在 AlexNet 卷积神经网络上增加并行的多尺度卷积模块,增加网络的深度和宽度,减少网络中的参数;在卷积层中加入批标准化处理,减少训练过程中数据分布的变化,提高网络的泛化能力。以新疆干制红枣中的黄皮枣、霉变枣、破头枣和正常枣为研究对象,对这些干制红枣进行训练和验证。结果表明:该模型对黄皮枣、霉变枣、破头枣和正常枣的识别率分别为 96.67%, 96.25%, 98.57%, 97.14%, 综合识别率可达 97.14%。与其他的算法相比,该算法具有较强的稳健性,对缺陷红枣的识别准确率更高。

关键词: 红枣; 缺陷检测; 多尺度卷积; 批量归一化; AlexNet 模型

Abstract: In this paper, a method based on a multi-scale convolutional neural network for detecting defects in jujube is proposed. Parallel multi-scale convolution modules were added to the AlexNet convolutional neural network to increase the depth and width of the network and reduce the parameters in the network; Added batch normalization processing to the convolutional layer to reduce changes in data distribution during training and improve the generalization ability of the network. Taking the yellow-skinned jujube, moldy jujube, broken-head jujube and normal jujube in Xinjiang dried jujube as the research objects, these dried jujubes were trained and verified. The results showed that the recognition rates of this model for yellow-skinned jujubes, moldy jujubes, broken-head jujubes and normal jujubes were 96.67%, 96.25%, 98.57%, and 97.14% respectively, and the comprehensive recognition rate could reach 97.14%. Compared with other algorithms, this algorithm was more robust and had higher accu-

racy in identifying defective red jujubes.

Keywords: red jujubes; defect detection; multi-scale convolution; batch normalization; AlexNet model

红枣在生长、成熟、收获和存放过程中,会产生黄皮、霉变、破头等缺陷^[1],这些缺陷降低了红枣的品质,因此深加工前需要进行缺陷枣的识别和筛选。目前主要依靠人工筛选红枣,劳动强度大、主观性强,而且费时、费力、效率低下^[2]。为此,学者们对缺陷红枣的检测进行了深入研究,并取得了较大的进展。海潮等^[3]根据红枣的表面缺陷特征提出基于 Blob 分析的红枣表面缺陷识别方法,该方法对缺陷枣的识别率达到 90% 以上,但是对黑斑枣的识别率较低且速度也较慢。詹映等^[4]对南疆红枣颜色分级进行研究,提取预处理图片的红体均值、绿体均值和蓝体均值及其均方差,再将图片从 RGB 转换到 HIS 颜色空间,提取色度均值、亮度均值和饱和度均值及其均方差,利用提取的 12 个特征变量结合 BP 神经网络对南疆骏枣和灰枣的外部品质进行了定量化分级研究。苏军等^[5]提出了基于 GA 优化 SVM 的干制红枣识别方法,但是该方法存在对霉变枣分类效果不明显的问题。以上基于传统机器学习的红枣缺陷识别方法主要依据经验,易受样本和人为主观性的影响,需要针对不同的分类情况精心设计特征,这需要耗费大量的时间和精力^[6],且设计的特征很难具有普适性,鲁棒性差。

卷积神经网络(convolutional neural network, CNN)可以有效地克服上述弊端,其对图像的空间不变形具有良好的适应性,其强大的自主学习能力可以自动提取并学习图像中的特征信息,无需额外的监督训练^[6-7]。近年来已被逐渐应用于人脸识别^[8]、目标检测^[9]和图像识别^[10-11]等领域。将卷积神经网络用于缺陷红枣识别的研究也陆续展开。曾宛俊等^[12]提出一种基于帧间最短路径搜索的目标定位方法和集成卷积神经网络模型对视频图像中的虫蚀枣、霉变枣、裂痕枣、黑头枣进行定位和检

基金项目:国家重点研发计划项目(编号:2017YFF0206501-01)

作者简介:方双,女,郑州大学在读硕士研究生。

通信作者:赵凤霞(1971—),女,郑州大学教授,博士。

E-mail: zfxmail@163.com

收稿日期:2020-09-17

测,分类准确率达到 98.45%。文怀兴等^[13]提出了一种基于深度残差网络对红枣表面缺陷以及纹理识别的分类算法,对正常枣、霉变枣和破皮枣进行分类,其分类准确率达到 96.11%。以上方法只针对常见的缺陷红枣进行了研究,但是对黄皮枣的研究较少。杨志锐等^[14]提出一种基于网中网的卷积神经网络对红枣进行检测,对图片进行背景分离、消除噪声、匀光处理等数据预处理操作,使其总体准确率达到 94.79%,对于黄皮枣的识别准确率为 95.56%,但操作复杂且模型性能还有一定的提升空间。

黄皮枣制干后呈黄色,肉质不坚实、口感差,但其外观特征和颜色特征与正常红枣相似,且颜色特征受光照的影响比较大,增大了识别的难度。为了提高缺陷红枣的识别率,拟提出一种基于 AlexNet^[15] 的多尺度卷积神经网络缺陷红枣识别方法,利用多尺度卷积模块提取多尺度的红枣特征信息;在卷积层中加入批标准化处理以减少训练过程中数据分布的变化,提高网络的泛化能力,避免过拟合。

1 研究对象

1.1 试验材料

试验研究对象是新疆干制红枣,图 1 为在生产环境下采集的红枣检测的部分图像,将图像进行分割、去背景操作之后,得到红枣数据集,数据集中包括 4 类红枣,分别为黄皮枣、霉变枣、破头枣和正常枣,如图 2 所示。对所采集到的图像进行特征分类和人工标记,并对所采集的红枣图像样本进行随机旋转、随机剪切、水平翻转和垂直翻转等数据增强处理共得到 2 800 张红枣图片,并将所有图片均匀混合,然后按照 7:2:1 的比例划分为训练集、验证集和测试集,即训练集图片 1 960 张,验证集图片 560 张、测试集 280 张。



图 1 生产环境下红枣检测的部分图像

Figure 1 Part of the image of jujube detection in a production environment




图 2 训练集红枣图像示例

Figure 2 Examples of jujube images in the training set

1.2 数据预处理

在进行训练之前,对图像进行必要的预处理可以增强样本数据,从而提高模型的性能。文中进行的预处理操作包括:

(1) 统一图片大小为 227×227 ,作为模型的输入。

(2) 样本数据归一化:将图片格式数据转换为 RGB 三通道的矩阵向量,并将图像像素值从 $[0, 255]$ 映射到 $[0, 1]$,以避免数据经激活函数处理时神经元进入“死区”,导致神经元失活,可以加速卷积神经网络的收敛速度。

(3) 样本数据标准化:对图像进行均值和方差的均衡处理,使得图片数据更加符合数据分布的规律,提高训练模型的泛化效果。

2 多尺度卷积神经网络模型

多尺度卷积神经网络模型是一种基于 AlexNet 改进的神经网络模型,将传统 AlexNet 模型中的部分卷积层替换为多尺度卷积模块,从而有效地提取红枣的多尺度特征;引入批量归一化层减少训练过程中数据分布的变化,提高网络的泛化能力。

2.1 传统的 AlexNet 模型结构

传统的 AlexNet 模型结构如图 3 所示,主要包括 5 个卷积层、2 个池化层和 2 个全连接层以及一个输出层。卷积层用于提取目标不同层次的特征;池化层对特征进行压缩,降低分辨率,进而减少冗余特征;全连接层对最后一层卷积层提取到的特征进行加权,通过线性变换将特征空间映射到样本标记空间;并在最后的输出层用 softmax 对目标进行分类。

2.2 基于 AlexNet 的多尺度卷积神经网络模型

AlexNet 模型采用传统的卷积滤波器,参数众多且卷积计算量很大,不利于模型充分学习数据的特征,采用多尺度卷积模块不仅可以大大减少模型中的参数,还可以在增加模型深度和宽度的同时充分学习和利用红枣的特征信息,从而提高模型的识别准确率;模型训练过程中参数一直不断地更新,会引起各网络层输出数据的分布随之发生变化,不利于提高模型的泛化性,从而影响模型对红枣的识别效果。针对上述问题,引入多尺度卷积模块和批量归一化层对 AlexNet 模型进行改进。

2.2.1 多尺度卷积模块 构建多尺度卷积模块如图 4 所示。该模块中有 4 个支路,每个支路对输入特征进行卷积操作提取特征之后,再进行特征融合操作,作为下一个




图 3 传统的 AlexNet 模型结构示意图

Figure 3 Schematic diagram of classical AlexNet model structure

模块的输入;每个支路中有不同大小的滤波器,这样可以增加网络对尺度的适应性,有利于提取多尺度的特征信息,在增加网络宽度的同时也增加了网络的深度;每条支路中都包括 1×1 卷积,主要用于压缩提取特征的维度,减少模型中的参数,同时添加非线性函数,有助于网络提取抽象的特征。

2.2.2 批量归一化层 在模型进行卷积操作时加入批量标准化(Batch Normalization, BN)层,该过程可以保证网络容量、加快网络的训练速度并提高网络泛化能力,减少训练过程中参数更新引起的各层数据分布发生变化对模型的影响。批量归一化^[16]过程如下,首先计算每个批次中 m 个样本 $x_1 \sim x_m$ 的均值和方差:

$$\mu = \frac{1}{m} \sum_{i=1}^m x_i, \quad (1)$$

$$\sigma = \frac{1}{m} \sum_{i=1}^m (x_i - \mu)^2, \quad (2)$$

式中:

μ ——批次的均值;

σ ——批次的方差。

将数据进行归一化:

$$\hat{x}_i = \frac{x_i - \mu}{\sqrt{\sigma^2 + \beta}}, \quad (3)$$

式中:

β ——防止方差 σ 为 0 时分式不成立而设置的常量。

归一化得到的数据 $\hat{x}_i$ 服从均值为 0、方差为 1 的正态分布。为避免数据归一化破坏数据的特征分布,需要通过缩放和平移等重构变换来使得返回的批量归一化结果的特性和原始输入数据的特性相同:

$$\gamma_i = \sqrt{V_{ar} [x_i]}, \quad (4)$$

$$\beta_i = E [x_i], \quad (5)$$

$$y_i = \gamma_i x_i + \beta_i, \quad (6)$$

式中:

γ_i, β_i ——通过训练得到的重构参数。

$V_{ar} [x_i], E [x_i], y_i$ ——样本 x_i 的方差、均值、标签。

2.2.3 多尺度卷积神经网络模型 引入多尺度卷积模块和批量归一化层后,基于 AlexNet 的多尺度卷积神经网络如图 5 所示。该网络在 AlexNet 模型中引入了 5 个 BN 层,将后面 4 个传统的卷积层替换为多尺度卷积模块,并在前 2 个多尺度卷积模块之后添加了池化层压缩图片的特征。4 个多尺度卷积模块的参数如表 1 所示。

2.2.4 传统卷积层和多尺度卷积模块的参数和计算量对比 为了便于将传统卷积层和多尺度卷积模块进行对比,设置传统 AlexNet 模型和多尺度卷积神经网络模型的具体参数如表 2 所示。

按式(7)、(8)分别计算出 AlexNet 模型中各卷积层参数量、计算量和多尺度卷积神经网络中各多尺度卷积模块的参数量、计算量,并将对应的卷积层和多尺度卷积模块的参数量和计算量进行对比,其计算结果如表 3 所示。

$$A = \sum_{l=1}^n k_l^2 c_{l-1} c_l, \quad (7)$$

$$B = \sum_{l=1}^n H_l W_l k_l^2 c_{l-1} c_l, \quad (8)$$

式中:

A ——参数量;

B ——计算量;

n ——卷积层数;

k_i ——尺寸为 $i \times i$ 的卷积核;




图 4 多尺度卷积模块

Figure 4 Multi-scale convolution module




图 5 多尺度卷积神经网络结构示意图

Figure 5 Schematic diagram of the multi-scale convolutional neural network structure

表 1 模型中 4 个多尺度卷积模块的参数[†]

Table 1 Parameters of the four multi-scale convolution modules in the model

模块	n1	n2	a	b1	b2	c1	c2	d
多尺度卷积模块 1	96	256	128	16	64	16	32	32
多尺度卷积模块 2	256	384	128	32	128	16	64	64
多尺度卷积模块 3	384	384	128	32	128	16	64	64
多尺度卷积模块 4	384	384	128	32	128	16	64	64

[†] n1 为输入通道;n2 为输出通道;a 为多尺度卷积模块中第 1 条支路中 1×1 卷积中的通道数;b1、b2 分别为第 2 条支路中 1×1 卷积、3×3 卷积的通道数;c1、c2 分别为第 3 条支路中 1×1 卷积、5×5 卷积的通道数;d 为第 4 条支路中 1×1 卷积的通道数。

表 2 传统的 AlexNet 模型和多尺度卷积神经网络模型的网络参数

Table 2 Network parameters of classical AlexNet model and multi-scale convolutional neural network model

AlexNet 模型网络的网络参数				多尺度卷积神经网络的网络参数			
层名称	卷积核个数、大小	步长	特征图大小	层名称	卷积核个数、大小	步长	特征图大小
输入层			227×227×3	输入层			227×227×3
卷积层 1	96×11×11	4	55×55×96	卷积层 1	96×11×11	4	55×55×96
池化层 1	3×3	2	27×27×96	池化层	3×3	2	27×27×96
卷积层 2	256×5×5	1	27×27×256	多尺度卷积模块 1	256	1	27×27×256
池化层 2	3×3	2	13×13×256	池化层 2	3×3	2	13×13×256
卷积层 3	384×3×3	1	13×13×384	多尺度卷积模块 2	256	1	13×13×384
卷积层 4	384×3×3	1	13×13×384	池化层	3×3	2	6×6×384
卷积层 5	384×3×3	2	13×13×384	多尺度卷积模块 3	384	1	6×6×384
全连接层 1	4 096			多尺度卷积模块 4	384	1	6×6×384
全连接层 2	1 024			全连接层 1	4 096		
输出层	4			全连接层 2	1 024		
				输出层	4		

表 3 传统卷积层和多尺度卷积模块的参数和计算量对比

Table 3 Comparison of parameters and calculation amount of traditional convolution layer and multi-scale convolution module

卷积层名称	参数量 A_1	计算量 B_1	卷积模块名称	参数量 A_2	参数量 B_2	A_1/A_2	B_1/B_2
卷积层 2	614 400	447 897 600	多尺度卷积模块 1	40 448	27 993 600	15.19	16.00
卷积层 3	884 736	149 520 384	多尺度卷积模块 2	123 904	20 939 776	7.14	7.14
卷积层 4	1 327 104	47 775 744	多尺度卷积模块 3	154 624	4 706 304	8.58	10.15
卷积层 5	1 327 104	47 775 744	多尺度卷积模块 4	154 624	4 706 304	8.58	10.15

c_{l-1} 、 c_l ——第 l 个卷积层的输入通道数和输出通道数;

H_{l-1} 、 W_l ——第 l 个卷积层输入特征的高度和宽度。

由计算结果可知,卷积层 2 的参数量和计算量分别是多尺度卷积模块 1 的 15.19 倍和 16.00 倍,卷积层 3 的参数量和计算量均是多尺度卷积模块 2 的 7.14 倍,卷积层 4、卷积层 5 的参数量和计算量分别是多尺度卷积模块 3、多尺度卷积模块 4 的 8.58 倍和 10.15 倍。鉴于卷积运算中加法运算与乘法运算的次数近似相等,因此在此处

仅计算出乘法运算的计算量,并进行对比,其比值与卷积运算中加法运算和乘法运算相加的比值近似相等。由表 3 可知,设计的多尺度卷积模块可以大大减少模型中的参数和计算量,加快模型的训练速度。

3 试验与分析

为了验证多尺度卷积神经网络在缺陷红枣分类上的有效性,将提出的算法与浅层网络 LeNet^[17]、深层网络 VGG16^[18]和经典 AlexNet 网络进行对比。模型的训练和测试环境是 Anaconda 4.8.5 平台、运行内存为 64 GB、

NVIDIA GeForce RTX 2080 Ti 显卡 GPU、并行 CUDA^[19] 编程平台, keras 深度学习框架和 python3.7.7 编程语言。在模型训练过程中将训练集和验证集分为多个批次, 综合考虑计算机的硬件环境, 在试验过程中利用 keras 框架中的生成器函数^[20], 设置 batch_size 为 64, 通过数据流的形式, 从训练样本中每次提取 64 个样本参与训练, 采用 Adam 优化器, 并设置初始学习率为 0.001, 训练总轮数为 500 次。

3.1 模型训练与测试

为了验证不同网络架构对缺陷红枣分类的影响和文中提出算法的有效性, 将红枣数据集分别统一大小为 32×32 , 227×227 , 224×224 的尺寸, 并分别将 LeNet 模型、AlexNet 模型和 VGG16 模型在数据集上进行训练。4 个模型在训练集和测试集上的准确率和损失函数如图 6、7 所示。

由图 6 可知, 浅层网络 LeNet 模型的学习较缓慢, 将近 500 轮迭代才达到收敛, 且在学习过程中波动较大。而深层网络 VGG16 模型、AlexNet 模型和多尺度卷积神经网络模型的训练过程都能够快速地收敛, 在训练集上表现良好, 其中 AlexNet 模型和多尺度卷积神经网络模

型的训练过程相对平稳。

由图 7 可知, 浅层网络 LeNet 模型在验证集上的表现随着迭代次数的增加逐渐变好, 但整体表现不如其他 3 个模型, 而且其波动较大。VGG16 模型的验证准确率和验证损失函数在前 80 轮迭代中分别迅速上升和下降, 但是随着迭代的进行, 验证准确率有降低的趋势并收敛到 91.8%, 验证损失也有逐渐上升的趋势, 这是因为 VGG16 出现了在验证集上出现过的过拟合现象。AlexNet 模型和多尺度卷积神经网络在验证集上均表现良好, 在前 100 轮迭代中, AlexNet 模型的验证准确率高于多尺度卷积神经网络模型, 但是在后面的迭代中, 多尺度卷积神经网络模型的验证准确率收敛到 97.4%, AlexNet 模型的验证准确率收敛到 95.4%, 且多尺度卷积神经网络模型的验证损失函数远小于 AlexNet 模型的验证损失。

综上所述, LeNet 模型学习缓慢且波动大主要是因为其结构过于简单, 学习效率低, 需要更多的迭代来充分学习图像中的特征; VGG16 模型虽然学习很快, 但是出现了过拟合, 这主要是因为 VGG16 模型参数众多, 比较复




图 6 模型的训练准确率和训练损失函数对比图

Figure 6 Comparison of models' training accuracy and training loss function




图 7 模型的验证准确率和验证损失函数对比图

Figure 7 Comparison of models' verification accuracy and verification loss function

杂,图片数据集有限,模型得不到充分地训练,使得其泛化性能较差;AlexNet 模型和多尺度卷积神经网络模型在训练集和验证集上都可以快速收敛,并且未出现过拟合现象,后者的收敛速度虽然稍慢,但其验证集收敛准确率与前者相比提高了 2%,且验证损失远小于前者。完成 500 轮训练,AlexNet 模型和多尺度卷积神经网络分别耗时 0.924 h 和 0.483 h,多尺度卷积神经网络训练时间相对减少了 40.13%,与 2.2.4 部分传统卷积层和多尺度卷积模块的对比结果相一致。说明所构建的多尺度卷积神经网络模型减少了大量的参数,可以缩短模型的训练时间,且与 AlexNet 模型相比,其性能得到了明显的提升。

3.2 模型验证

为了验证多尺度卷积神经网络模型的泛化性,用其对测试集中的 280 张图片分别进行识别,结果如表 5 所示。

表 5 多尺度卷积神经网络模型在测试集的识别结果
Table 5 Recognition results of the multi-scale convolutional neural network model in the test set

红枣类型	待识别图片数	正确识别数	识别率/%
黄皮枣	60	58	96.67
霉变枣	80	77	96.25
破头枣	70	69	98.57
正常枣	70	68	97.14
总计	280	272	97.14

由表 5 可知,多尺度卷积神经网络模型在测试集上的平均识别准确率为 97.14%。与文献[12]中提出的基于深度残差网络对红枣表面缺陷分类的准确率(96.11%)相比,识别精度更高。

4 结束语

提出了一种基于多尺度卷积神经网络的缺陷红枣识别方法,并对黄皮枣、霉变枣、破头枣和正常枣进行了检验。与 LeNet 模型、VGG16 模型相比,提出的方法可以充分学习红枣图片中的特征信息,且未出现过拟合现象;与 AlexNet 模型进行对比,训练时间减少了 40.13%,验证准确率提高 2%,说明多尺度卷积模块能够大大减少卷积运算中的参数,加速模型的训练,并提高了模型的准确率,其平均识别率达到了 97.14%,而且对黄皮枣也有较高的识别率。

试验提出的多尺度卷积神经网络还存在优化的空间,后续可考虑制作包含更多缺陷红枣的较大数据集,结合更先进、高效的网络模块对其作进一步改进。

参考文献

[1] 中国国家标准化管理委员会. 干制红枣: GB/T 5835—2009[S]. 北京: 中国标准出版社, 2009: 2.

[2] 钟小华, 曹玉华, 张永清, 等. 基于机器视觉技术的红枣全表面信息无损分拣系统研究与实现[J]. 食品与机械, 2017, 33(5): 114-118.

[3] 海潮, 赵凤霞, 孙烁. 基于 Blob 分析的红枣表面缺陷在线检测技术[J]. 食品与机械, 2018, 34(1): 126-129.

[4] 詹映, 罗华平, 彭云发, 等. BP 神经网络南疆红枣颜色分级方法的研究[J]. 食品工业, 2015, 36(1): 165-167.

[5] 苏军, 饶元, 张敬尧, 等. 基于 GA 优化 SVM 的干制红枣品种分类方法[J]. 洛阳理工学院学报(自然科学版), 2018, 28(4): 68-72, 96.

[6] KAMILARIS A, PRENAFETA-BOLDU F. Deep learning in agriculture: A survey[J]. Computers and Electronics in Agriculture, 2018, 147: 70-90.

[7] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.

[8] LI Ya, WANG Guang-run, NIE Lin, et al. Distance metric optimization driven convolutional neural network for age invariant face recognition[J]. Pattern Recognition, 2018, 75: 51-62.

[9] SINGH R, OM H. Newborn face recognition using deep convolutional neural network[J]. Multimedia Tools & Applications, 2017, 76(18): 1-11.

[10] YANG Wei-xin, JIN Lian-wen, TAO De-cheng, et al. DropSample: A new training method to enhance deep convolutional neural networks for large-scale unconstrained handwritten chinese character recognition[J]. Pattern Recognition, 2016, 58: 190-203.

[11] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1 300-1 312.

[12] 曾宛俊, 吴俊航, 马本学, 等. 基于帧间路径搜索和 E-CNN 的红枣定位与缺陷检测[J]. 农业机械学报, 2019, 50(2): 307-314.

[13] 文怀兴, 王俊杰, 韩昉. 基于改进残差网络的红枣缺陷检测分类方法研究[J]. 食品与机械, 2020, 36(1): 161-165.

[14] 杨志锐, 郑宏, 郭中原, 等. 基于网中网卷积神经网络的红枣缺陷检测[J]. 食品与机械, 2020, 36(2): 140-145, 181.

[15] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.

[16] LOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]// International Conference on Machine Learning(ICML). New York: [s.n.], 2015: 448-456.

[17] 程鸿芳, 张春友. 自然场景下基于改进 LeNet 卷积神经网络的苹果图像识别技术[J]. 食品与机械, 2019, 35(3): 155-158.

(下转第 168 页)

成功率由 87% 提高至 97%，能够满足传送带分拣要求。

微小误差可能来源：传送带传输过程中不稳定，出现左右摆动问题；花生传输过程中与传送带发生相对滑动；编码器脉冲读数不准确，导致传输方向误差；通讯模式有延迟等问题。

5 结论

根据花生生产现场操作条件，改进了传统手眼标定方法，利用专门定制的“9+2”标定块进行平面标定，并对花生处理提取轮廓信息，进行重心高度补偿。结果表明，该标定方法便于在生产现场实际操作，降低了传统手眼标定矩阵求解难度，可满足基于传送带作业的机器人分拣精度要求。但对于相机、传送带平整度及安装精度要求较高的，需后期对此方面问题继续探索，使之得到广泛应用。

参考文献

- [1] 杨少荣. 机器视觉算法与应用[M]. 北京：清华大学出版社，2008：378-443.
- [2] LEE K M. Machine vision[M]. Taylor and Francis; CRC Press, 2015：15-33.
- [3] XIA Ke, WENG Zheng-xin. Workpieces sorting system based on industrial robot of machine vision [C]// International Conference on Systems & Informatics. [S.l.]：IEEE, 2016：422-426.
- [4] 尹双双，姜海勇，李娜，等. 花生负压分级试验[J]. 食品与机械，2018，34(7)：86-89.
- [5] TSAI R Y, LENZ R K. A new technique for fully auto-

mous and efficient 3D robotics hand-eye calibration[J]. IEEE Transactions on Robotics and Automation, 1989, 5(3)：345-358.

- [6] 胡寒. 基于机器视觉的 Delta 机器人动态抓取系统关键技术研究[D]. 广州：广东工业大学，2019：34-38.
- [7] 李楠，平雪良，王晨学，等. 一种机器人的平面约束自标定技术研究[J]. 机械科学与技术，2019，38(8)：1 214-1 222.
- [8] 许国树，言勇华. 一种基于场景特征的工业机器人手眼自动标定方法[J]. 机械设计与研究，2019，35(6)：17-21.
- [9] 郭新年，白瑞林，王秀平. 基于主动视觉的手眼矩阵和光平面标定方法[J]. 计算机工程与应用，2015，51(19)：56-60.
- [10] LIU Kun, LIU Wei-dong. Detection algorithm for infrared dim small targets based on weighted fusion feature and ostu segmentation[J]. Computer Engineering, 2017, 43(7)：253-260.
- [11] 张凯. 花生米品质分选系统的关键技术研究[D]. 济南：山东大学，2019：26-32.
- [12] 张墨逸，张秋余，段宏湘，等. 基于运动轨迹的单目相机位姿自标定方法[J]. 华中科技大学学报(自然科学版)，2019，47(2)：64-69.
- [13] ZHANG Zheng-you. A flexible new technique for camera calibration[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2000, 22(11)：1 330-1 334.
- [14] FITZGIBBON A W, PILU M, FISHER R B. Direct least squares fitting of ellipses[J]. IEEE Trans on Pami, 1996, 21(5)：253-257
- [15] 杨麒，李天伟，黄谦，等. 基于直线投影特征的镜头畸变校正方法[J]. 计算机测量与控制，2018，26(9)：264-268.

(上接第 157 页)

地坪立柱散冷量。立柱保温更能削弱散冷量、改善地坪温度状况。但环境因素往往是多变的，各种环境因素作用下的散冷量和地坪冻胀问题还有待进一步研究。

参考文献

- [1] 冷库建筑保温系统设计技术与发展探讨[J]. 物流工程与管理，2017，39(10)：76-79.
- [2] 刘金平. 5 000 吨组装式冷库地坪保温及防冻性能测试研究[J]. 制冷，1994，48(3)：7-12.
- [3] 高祖锟. 冷库地坪防冻机械通风的传热计算[J]. 暖通空调，1996(4)：68-71.
- [4] 贾景福，郝满晋，赵建华. 通风流速对冷库地坪通风防冻系统传热性能影响的研究[J]. 制冷空调与电力机械，2009，

128(30)：57-60.

- [5] 陈曦，王军，毕文峰. 设计参数对冷库地坪通风防冻系统性能的影响研究[J]. 低温与超导，2016，44(10)：58-61.
- [6] 孙小红，满林香. 冷库地坪通风散冷管道的数值模拟与优化[J]. 低温与超导，2020，48(2)：75-79，106.
- [7] 羊烨，鲍莉. 运用有限元法计算热桥对围护结构热工性能的影响[J]. 建筑结构，2016，43(3)：59-60，62.
- [8] 沈张. 基于 COMSOL 仿真技术在热桥中三维传热研究及节能利用[M]. 武汉：武汉轻工大学，2017：1-57.
- [9] 中华人民共和国住房和城乡建设部，中华人民共和国国家质量监督检验检疫总局. 冷库设计规范：GB 50072—2010[S]. 北京：中国计划出版社，2010：6，16，124.
- [10] 蒋小强，张黎辉，谢尚桢. 冷库柱体冷桥的形成机理及其保温方案的优化[C]//福建省制冷学会学术年会论文集. 成都：工程科技，2018：104-114.

(上接第 163 页)

- [18] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2015(7)：1 409-1 556.
- [19] BAKHODAA, YUAN G L, FUNG W W L, et al. Analyzing CUDA workloads using a detailed GPU simulator[C]//

2009 IEEE International Symposium on Performance Analysis of Systems and Software. [S. l.]：IEEE, 2009：163-174.

- [20] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston：IEEE, 2015：1-9.