

基于 CNN 的小麦籽粒完整性图像检测系统

祝诗平¹ 卓佳鑫¹ 黄华^{1,2} 李光林¹

(1. 西南大学工程技术学院, 重庆 400716; 2. 堪萨斯州立大学工程学院, 曼哈顿 KS 66502)

摘要: 为了快速、准确识别小麦籽粒的完整粒和破损粒, 设计了基于卷积神经网络(CNN)的小麦籽粒完整性图像检测系统, 并成功应用于实际检测中。采集完整粒和破损粒两类小麦籽粒图像, 对图像进行分割、滤波等处理后, 建立单粒小麦的图像数据库和形态特征数据库。采用 LeNet-5、AlexNet、VGG-16 和 ResNet-34 等 4 种典型卷积神经网络建立小麦籽粒完整性识别模型, 并与 SVM 和 BP 神经网络所建模型进行对比。结果表明, SVM 和 BP 神经网络所建模型的验证集识别准确率最高为 92.25%; 4 种卷积神经网络模型明显优于两种传统模型, 其中, 识别性能最佳的 AlexNet 的测试集识别准确率为 98.02%, 识别速率为 0.827 ms/粒。基于 AlexNet 模型设计了小麦籽粒完整性图像检测系统, 检测结果显示, 100 粒小麦的检测时间为 26.3 s, 其中, 图像采集过程平均用时 21.2 s, 图像处理与识别过程平均用时为 5.1 s, 平均识别准确率为 96.67%。

关键词: 小麦籽粒; 完整性; 图像识别; 卷积神经网络; 检测系统

中图分类号: TP391.41 文献标识码: A 文章编号: 1000-1298(2020)05-0036-07

OSID:



Wheat Grain Integrity Image Detection System Based on CNN

ZHU Shiping¹ ZHUO Jiaxin¹ HUANG Hua^{1,2} LI Guanglin¹

(1. College of Engineering and Technology, Southwest University, Chongqing 400716, China

2. College of Engineering, Kansas State University, Manhattan KS 66502, USA)

Abstract: In order to recognize the sound and broken grains of wheat quickly and accurately, an image detection system of wheat grain integrity based on convolution neural network (CNN) was designed and implemented, and successfully applied to actual detection. The images of sound and broken kernels were captured and the image database and morphological characteristics database of single wheat grain were established after some image processing (segmentation and filtering). Both databases were divided into a training set and validation set according to the ratio of 7:3. Four typical convolutional neural networks (LeNet-5, AlexNet, VGG-16 and ResNet-34) were used to build wheat grain integrity recognition model and compared with the other two traditional algorithms of machine learning (SVM and BP neural network). The results showed that the training speed of the two traditional models was faster, and SVM gave the highest accuracy of 92.25%. By contrast, all four kinds of convolutional neural networks had an accuracy rate of about 98%. Among them, the accuracy of test set of AlexNet, which had the best recognition performance, was 98.02%, and the recognition speed of it was at a rate of 0.827 ms per grain. Therefore, a wheat grain integrity image detection system was developed based on this model, and used for actual detection. The detection results showed that the detecting time of 100 wheat grains was 26.3 s, among which, the average image acquisition time was 21.2 s, and the average image processing and recognition time was 5.1 s, and the average recognition accuracy was 96.67%. The system was easy to operate, which had stable performance, and provided a reference for the design of wheat grain image detection system.

Key words: wheat grain; integrity; image recognition; convolutional neural network; detection system

0 引言

小麦是最重要的粮食作物之一^[1], 广泛种植于

世界各地, 其产量和贸易量在近几年不断攀升。在流通过程中, 外观品质是影响小麦价格的重要因素之一。目前, 针对小麦外观品质的检测主要分为高

光谱检测^[2-3]和图像检测^[4],两种方法各具优势。高光谱检测时间长、消耗大,无法满足实际检测需求。在图像检测方面,研究人员通过线性判别模型、人工神经网络、支持向量机等技术在小麦品种识别^[5-9]、品质分级^[10-11]、不完善粒识别^[12]、病害识别^[13]等方面进行了研究,识别准确率均在90%以上。但这些模型的实现环境较为严苛,首先,图像数据的采集必须在统一固定的环境下进行;其次,以小麦的形态特征、颜色特征、纹理特征等作为模型的输入数据,不同的特征数据需要不同的算法提取,计算过程较为繁杂。此类方法已不能满足实际生产中小麦图像检测的需求。

近年来,以卷积神经网络为代表的深度学习技术发展迅速,已在图像识别领域得到广泛应用^[14]。相较于传统的机器学习技术,卷积神经网络增加了特征学习部分,可以通过组合低层特征形成更加抽象的高层特征,以发现数据的分布式特征表示,从而不再需要其他算法进行特征提取。在农业领域,研究者将卷积神经网络用于诸多方面^[15-21],研究表明,卷积神经网络能够提供更好的性能,优于传统的机器学习技术^[22]。

不少研究者将卷积神经网络应用于小麦研究之中,张领先等^[23]研发了基于卷积神经网络的冬小麦麦穗检测计数系统,系统对麦穗的识别准确率高达99%;HASAN等^[24]训练了4种R-CNN模型,对田间小麦进行识别并估算其产量,准确率为88%~94%。在针对小麦籽粒的不完善粒识别中,结合高光谱检测和卷积神经网络的研究^[25-27]较多,而仅基于图像检测的研究较少。因此,本文采用LeNet-5、AlexNet、VGG-16和ResNet-34这4种较为成熟的卷积神经网络对小麦籽粒的完整性进行识别,并与支持向量机(Support vector machine, SVM)和反向传播(Back propagation, BP)神经网络进行对比,分析比较不同模型的性能,最后,基于检测效果最优的模型设计小麦籽粒完整性图像检测系统。

1 试验材料与预处理

1.1 图像采集

选用由天津粮油批发交易市场提供的白硬麦作为试验材料,其收获时间为2014年8月,产地为山东,含水率为11.5%。按照国家标准^[28]将这批小麦人工分为完整粒和破损粒两类。

在自然光照条件下,以黑色绒布作为背景,将每批100粒小麦按照10×10的分布进行随机摆放,采用华为手机(RNE-AL00型,摄像头1600万像素)从20~25cm的高度垂直拍摄小麦样本,完整粒和破损粒小麦分别采集3500粒,图1是部分完整粒和破损粒小麦样本。

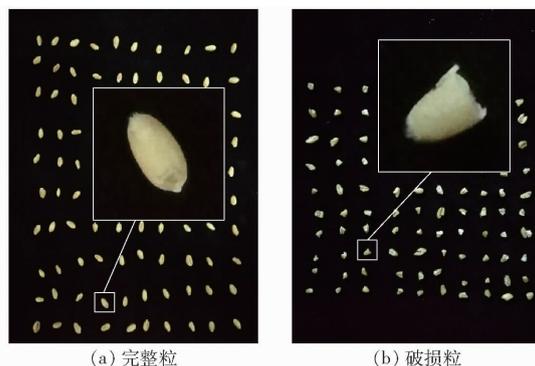


图1 小麦籽粒样本

Fig. 1 Samples of wheat grain

1.2 图像预处理

以Python 3.6为脚本语言对小麦图像进行预处理,共包含3部分,如图2所示。首先将RGB图像转换为灰度图像,再通过阈值分割方法将灰度图像转换为二值图像,小麦区域为白色,背景区域为黑色。计算每一个小麦区域的最小外接矩形的顶点坐标,根据该坐标在原始图像中分割出每一粒小麦,从而得到单粒小麦RGB图像。

由于卷积神经网络的输入图像一般为正方形,因此将单粒小麦图像扩展为正方形,扩展像素点的R、G、B值为(0,0,0),然后对其做旋转处理,旋转角

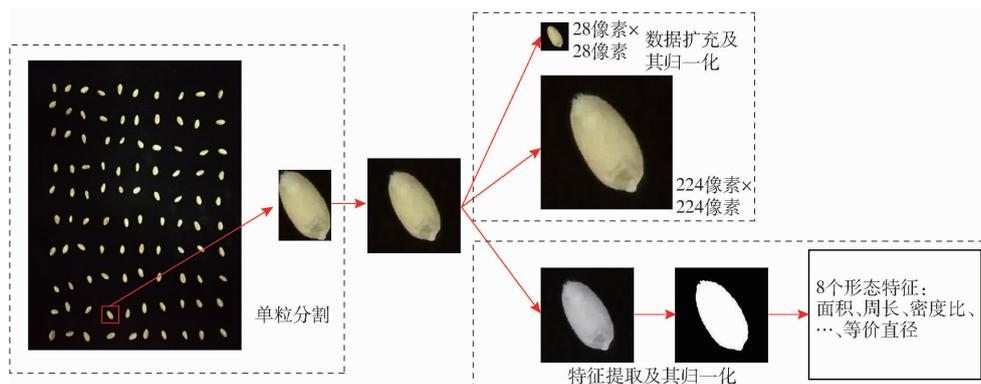


图2 图像预处理

Fig. 2 Image preprocessing

度随机,7000幅小麦图像扩充为14000幅,建立小麦图像数据库,接着按照7:3的比例,将9800幅小麦图像作为训练集,其余4200幅作为验证集。为满足卷积神经网络的输入图像尺寸需求,将小麦图像缩放为224像素×224像素或28像素×28像素,数据格式转换为float 32,归一化处理为

$$P_{ij} = \frac{p_{ij}}{255} \quad (1)$$

式中 p_{ij} ——图像数据中第 i 行第 j 列像素点的 R 、 G 、 B 值

P_{ij} —— p_{ij} 归一化值

采用巴特沃斯高通滤波器对灰度图像做图像增强处理,然后转换为二值图像,计算小麦的8个形态特征,分别为面积、周长、密度比、最小外接矩形的长轴长度和短轴长度、长宽比、椭圆离心率及等价直径,建立小麦的特征数据库,作为SVM和BP神经网络的输入数据,对8个特征数据进行归一化处理

$$X_i^j = \frac{x_i^j - \mu^j}{x_{\max}^j - x_{\min}^j} \quad (2)$$

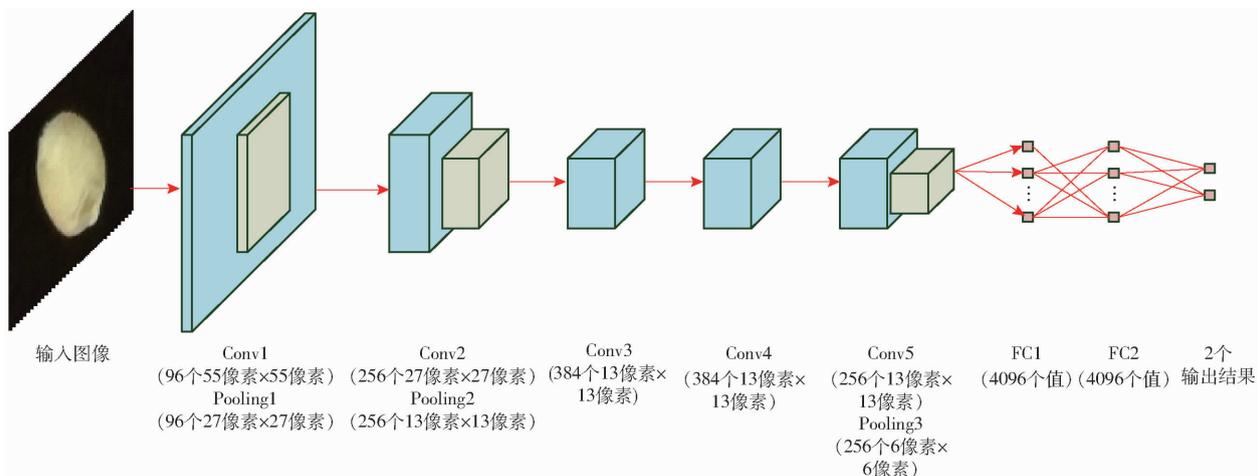


图3 AlexNet网络架构

Fig.3 Architecture of AlexNet

采用4种典型卷积神经网络,分别为LeNet-5、AlexNet、VGG-16以及ResNet-34,4种网络的输出层神经元个数均修改为2个。针对LeNet-5、AlexNet和VGG-16,在全连接层之后加入Dropout层,每次迭代过程中,Dropout层按一定比率将全连接层中的神经元随机设置为0,即这部分神经元不参与训练,有效防止训练过拟合,从而提升网络的拟合效果。

这4种网络均采用softmax函数计算类别概率,以实现分类,计算式为

$$y_{im} = \frac{e^{z_{im}}}{\sum_{k=1}^K e^{z_{ik}}} \quad (3)$$

式中 y_{im} ——第 i 个样本属于第 m 类的预测概率

式中 x_i^j ——第 j 个特征的第 i 个数据

μ^j ——第 j 个特征所有数据的平均值

x_{\max}^j ——第 j 个特征所有数据中的最大值

x_{\min}^j ——第 j 个特征所有数据中的最小值

X_i^j —— x_i^j 归一化值

2 试验方法

2.1 卷积神经网络

卷积神经网络是深度学习中应用最广泛的网络模型之一。在图像分类领域,由于图像的数据量非常大,如果使用传统的神经网络,会造成网络参数量过多,降低网络的拟合能力,而卷积神经网络具有参数降维的功能,即通过卷积和池化操作减少网络训练时需要计算的参数数量,进而提高网络的训练速度。典型的卷积神经网络主要包含卷积层、池化层和全连接层,如图3所示,该网络是经过修改后适用于本试验的AlexNet网络,网络输出层的神经元个数修改为2,分别为小麦籽粒完整和破损类别的概率。

K ——类别数

z_{im} ——第 i 个样本的输出向量与第 m 类参数向量的乘积

z_{ik} ——第 i 个样本的输出向量与第 k 类参数向量的乘积

以分类交叉熵(Categorical cross entropy)作为损失函数,计算式为

$$L = - \sum_{i=1}^n \hat{y}_{im} \lg y_{im} \quad (4)$$

式中 n ——批尺寸 L ——损失函数

\hat{y}_{im} ——第 i 个样本属于第 m 类的期望概率

采用SVM和结构为8-15-2(输入层8个神经元,隐含层15个神经元,输出层2个神经元)的BP

神经网络作为对比试验模型,其输入数据为小麦特征数据库中的 8 个形态特征数据。

使用准确率 R 评价模型效果,计算式为

$$R = \frac{n_{\text{right}}}{n_{\text{all}}} \times 100\% \quad (5)$$

式中 n_{all} ——所有样本数量

n_{right} ——正确识别的样本数量

2.2 模型参数

针对 SVM,选择高斯核函数作为核函数;针对 BP 神经网络和 4 种卷积神经网络,采用动量为 0.5、学习率衰减值为 1×10^{-6} 的随机梯度下降法 (SGD) 作为优化算法,并设置 3 组初始学习率 (0.01、0.005、0.001);针对 LeNet-5、AlexNet 和 VGG-16 设置 3 组 Dropout 值 (0.4、0.5、0.6),共进行 34 组试验。训练和验证的批尺寸 (batchsize) 设为 32,卷积神经网络的迭代 (epoch) 次数设为 100, BP 神经网络的迭代次数设为 200。

2.3 试验环境

采用 Tensorflow 为后端运行的 Keras 深度学习框架,以 Python 3.6 作为编程语言,在 PyCharm 平台搭建模型。Keras 是一个高级神经网络 API,提供多种神经网络层、损失函数、优化器、激活函数和初始化方法等,支持快速构建任意的神经网络架构,操作简便,易于调试和扩展。

卷积神经网络的参数量和训练集庞大,仅通过 CPU 执行训练会耗费大量时间,因此需要 GPU 加速训练过程,然而性能优异的 GPU 价格昂贵,增加了研发成本,为解决这一问题,本文选用提供免费 GPU 的 Google Colab 作为开发环境。Google Colab 是 Google 公司开发的一个免费的 Jupyter 笔记本环境,该环境绑定了一个 Ubuntu 虚拟机,提供双核处理器 Intel Xeon CPU,主频 2.20 GHz,运行内存 12.72 GB, GPU 为 NVIDIA Tesla K80。

将程序 (.py 文件) 和图像数据 (.npy 文件) 上传至谷歌云盘 (Google Drive),在 Google Colab 执行该程序,训练网络模型,输出训练结果并保存模型,以便后期测试。

3 试验结果与分析

各组训练和验证的结果如表 1 所示,其中迭代次数指验证集准确率达到稳定时的迭代次数,训练时间指一次迭代所花费的时间,试验 1~4 的训练时间包含图像预处理步骤中计算形态特征的时间。试验结果显示,SVM 和 BP 神经网络的训练速度普遍优于卷积神经网络,但其准确率不高于 93.61%,卷积神经网络的准确率大多高于 96%,优于 SVM 和

BP 神经网络。

在 4 种卷积神经网络中,LeNet-5 的训练速度最快,仅 0.5 次/s,但其识别准确率较低,验证集准确率最高为 97.90%,因为其输入图像尺寸为 28 像素 \times 28 像素,导致图像的部分特征丢失。AlexNet、VGG-16 和 ResNet-34 的输入图像为 224 像素 \times 224 像素,其训练集准确率都不低于 99.81%,其中 AlexNet 的训练速度最快,一次迭代用时为 30 s, VGG-16 最慢,为 162 s。ResNet-34 的验证集准确率最高,为 99.29%,但其训练时间比 AlexNet 长,为 141 s。综合观察 34 组试验结果,试验 19 和试验 32 训练得到的 AlexNet 和 ResNet-34 具有更好的识别效果,这两个模型在训练集和验证集上的准确率及损失值 (loss) 随迭代次数变化的曲线如图 4 和图 5 所示。从图中可以看出,两个模型的训练集曲线都较为平滑,波动小,但 AlexNet 的验证集曲线的波动性比 ResNet-34 大,尤其是在前 15 次迭代中。两者分别在迭代 37 次和 20 次后趋于稳定。

从试验材料中另外采集 2 574 个完整粒小麦和 1 036 个破损粒小麦图像作为测试集,分别计算两个模型的混淆矩阵及识别性能。从表 2 可见,两种网络模型对完整粒的识别准确率高于破损粒,均达到 99% 以上,ResNet-34 的平均识别准确率较高,为 98.57%,但其对单粒小麦的识别时间为 5 ms,约为 AlexNet 识别速率的 1/6。综合考虑两个模型的平均识别准确率及识别速率,选择试验 19 的 AlexNet 作为识别小麦籽粒完整性的实际应用模型。

4 系统性能测试

由本实验室自主设计的小麦籽粒完整性图像检测系统包含检测装置和识别软件两部分,其中,检测装置如图 6 所示。小麦籽粒从入料口进入检测装置,经进料装置落到传送带上,再经过分离板到达 USB 工业摄像头的拍摄范围,最后落入物料盒。LED 灯带提供背景光源,使图像清晰。播种机使小麦籽粒小批量地进入传送带,避免全部籽粒一次性落入传送带。

分离板如图 7 所示,可使紧挨的两粒或多粒小麦分隔开,增大小麦籽粒之间的间隙,避免籽粒紧挨导致后期图像分割错误而降低识别准确率。

触控计算机控制 USB 工业摄像头以 2 s 的周期垂直拍摄传送带上的小麦籽粒,得到 1 920 像素 \times 1 080 像素的图像并存储,如图 8 所示,红色方框内为目标图像区域。

小麦籽粒完整性识别软件对采集到的多幅目标图像进行拼接,然后对拼接后的图像进行边缘检测、

表1 模型训练与验证的准确率

Tab.1 Accuracy of model in training and validating

试验编号	模型	初始学习率	Dropout 值	迭代次数	一次迭代用时/s	训练集准确率/%	验证集准确率/%	
1	SVM			30	11.32	93.61	92.25	
2	BP 神经网络(8-15-2)	0.010		144		92.48	92.19	
3		0.005		156	0.55	92.43	92.13	
4		0.001		182		92.52	92.24	
5				0.4	76		99.90	96.67
6	LeNet-5	0.010	0.5	90	2	99.85	96.71	
7			0.6	100		96.38	94.64	
8			0.4	63		99.83	95.98	
9		0.005	0.5	95	2	99.04	96.00	
10	AlexNet		0.6	94		99.95	97.90	
11			0.4	100		96.38	94.69	
12		0.001	0.5	100	2	96.49	94.60	
13			0.6	94		98.99	96.19	
14	VGG-16		0.4	76		100	98.50	
15		0.010	0.5	43	30	100	98.74	
16			0.6	52		100	98.67	
17			0.4	43		100	98.48	
18	ResNet-34	0.005	0.5	88	30	99.82	98.24	
19			0.6	37		100	98.79	
20			0.4	57		99.85	98.57	
21		0.001	0.5	57	30	99.98	98.50	
22	ResNet-34		0.6	54		99.98	97.86	
23			0.4	42		100	97.81	
24		0.010	0.5	25	162	99.81	98.05	
25			0.6	31		99.95	98.19	
26	ResNet-34		0.4	62		99.99	97.76	
27		0.005	0.5	49	162	99.91	97.81	
28			0.6	51		99.99	98.24	
29			0.4	60		100	97.83	
30	ResNet-34	0.001	0.5	48	162	99.85	97.88	
31			0.6	53		100	97.90	
32			0.010		20		100	99.29
33		ResNet-34	0.005		25	141	100	99.12
34		0.001		21		99.96	98.76	

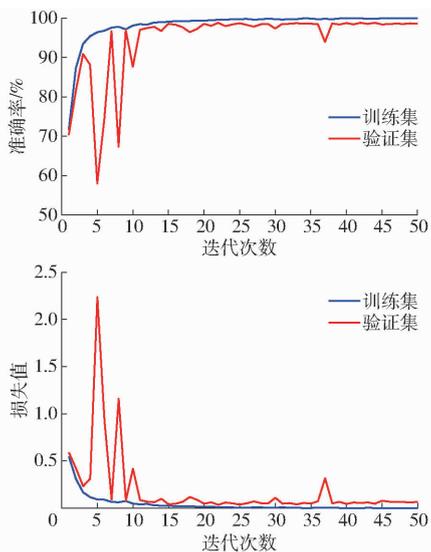


图4 AlexNet(试验19)的准确率与损失值曲线

Fig.4 Accuracy and loss curves of AlexNet(No.19)

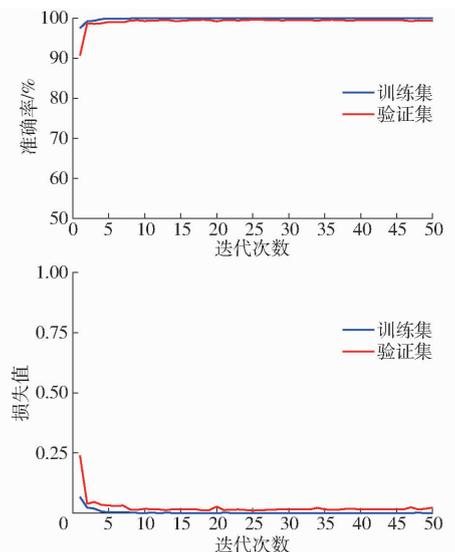


图5 ResNet-34(试验32)的准确率与损失值曲线

Fig.5 Accuracy and loss curves of ResNet-34(No.32)

表 2 AlexNet 和 ResNet-34 在测试集的识别性能比较

Tab. 2 Recognition performance comparison of AlexNet and ResNet-34 on test datasets

模型	小麦籽粒类别	预测类别		识别性能		
		完整粒/粒	破损粒/粒	准确率/%	平均准确率/%	单粒小麦识别时间/ms
AlexNet	完整粒	2 549	25	99.03	98.02	0.827
	破损粒	31	1 005	97.01		
ResNet-34	完整粒	2 560	14	99.46	98.57	5
	破损粒	24	1 012	97.68		

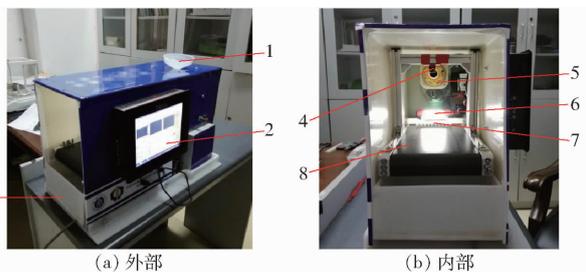


图 6 小麦籽粒完整性图像检测装置

Fig. 6 Wheat grain integrity detection device

1. 入料口 2. 触控计算机 3. 物料盒 4. USB 工业摄像头 5. 进料装置 6. LED 灯带 7. 分离板 8. 传送带

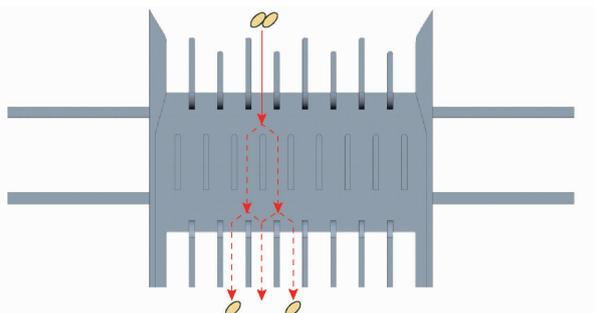


图 7 分离板

Fig. 7 Separating plate



图 8 USB 工业摄像头拍摄的小麦图像

Fig. 8 Wheat image by USB industrial camera

图像分割以及尺寸调整,得到尺寸为 224 像素 × 224 像素的单粒小麦籽粒图像,最后使用表 1 中试验 19 训练得到的 AlexNet 网络模型进行识别,并统计完整粒和破损粒的数量及所占比例。

利用上述系统对 3 批小麦(100 粒完整粒、100 粒破损粒、70 粒完整粒 + 30 粒破损粒)进行 3 组测试。测试结果显示,3 批小麦的识别准确率分别为 97%、96%、97%,平均识别准确率为 96.67%,低于表 2 中测试集的识别准确率,因为传送带的反光会导致分割出的部分单粒小麦图像具有较亮的背景,对识别过程产生一定的干扰,除此之外,极少部分图像中存在紧挨的两粒小麦,模型对此类图像无法做出正确识别。该系统操作简单,识别效果较稳定,具有较好的鲁棒性,采集 100 粒小麦籽粒图像的平均时间为 21.2 s,图像处理与识别的平均时间为 5.1 s,总共用时为 26.3 s,能够满足实际检测需求。

5 结论

(1) 针对小麦籽粒完整性图像识别的问题,将 4 种典型卷积神经网络与传统的 SVM 和 BP 神经网络进行比较,结果表明,卷积神经网络的识别准确率明显优于后两种传统模型,验证集准确率最高可达 99.29%。根据网络的结构复杂度,网络的训练时间具有显著差异,其中 AlexNet 网络训练一次时间为 30 s,验证集准确率最高为 98.79%。尽管卷积神经网络的训练时间远大于传统的机器学习技术,但显著提高了小麦籽粒完整性的识别准确度。

(2) 选择识别准确率最高的试验 19 的 AlexNet 和试验 32 的 ResNet-34,进行识别性能比较,结果表明,试验 19 的 AlexNet 识别速度更快,单粒小麦识别时间 0.827 ms,识别准确率与 ResNet-34 相近,前者为 98.02%,后者为 98.57%,因此选择 AlexNet 作为小麦籽粒完整性检测系统的识别模型。

(3) 基于 AlexNet 模型设计了小麦籽粒完整性图像检测系统,对 3 组 100 粒小麦籽粒进行检测,图像采集、处理及识别共用时 26.3 s,平均识别准确率为 96.67%。

参 考 文 献

[1] 王一杰,辛岭,胡志全,等. 我国小麦生产、消费和贸易的现状分析[J]. 中国农业资源与区划, 2018, 39(5):36-45. WANG Yijie, XIN Ling, HU Zhiqian, et al. Current situation of production, consumption and trade of wheat in China[J]. Chinese Journal of Agricultural Resources and Regional Planning, 2018, 39(5):36-45. (in Chinese)

[2] 刘欢,王雅倩,王晓明,等. 基于近红外高光谱成像技术的小麦不完善粒检测方法研究[J]. 光谱学与光谱分析, 2019, 39(1):223-229. LIU Huan, WANG Yaqian, WANG Xiaoming, et al. Study on detection method of wheat unsound kernel based on near-infrared hyperspectral imaging technology[J]. Spectroscopy and Spectral Analysis, 2019, 39(1):223-229. (in Chinese)

[3] 张航,姚传安,蒋梦梦,等. 基于高光谱图像技术的小麦种子分类识别研究[J]. 麦类作物学报, 2019, 39(1):96-104.

- ZHANG Hang, YAO Chuanan, JIANG Mengmeng, et al. Research on wheat seed classification and recognition based on hyperspectral imaging[J]. *Journal of Triticeae Crops*, 2019, 39(1): 96 – 104. (in Chinese)
- [4] 张玉荣, 陈赛赛, 周显青. 小麦图像检测技术研究进展[J]. *中国粮油学报*, 2014, 29(4): 118 – 123.
- ZHANG Yurong, CHEN Saisai, ZHOU Xianqing. A review of image detection technology for wheat[J]. *Journal of the Chinese Cereals and Oils Association*, 2014, 29(4): 118 – 123. (in Chinese)
- [5] PALIWAL J, VISEN N S, JAYAS D S. Evaluation of neural network architectures for cereal grain classification using morphological features[J]. *Journal of Agricultural Engineering Research*, 2001, 79(4): 361 – 370.
- [6] MANICKAVASAGAN A, SATHYA G, JAYAS D S, et al. Wheat class identification using monochrome images[J]. *Journal of Cereal Science*, 2008, 47(3): 518 – 527.
- [7] UTKU H. Application of the feature selection method to discriminate digitized wheat varieties[J]. *Journal of Food Engineering*, 2000, 46(3): 211 – 216.
- [8] 孟惜, 王克俭, 韩宪忠. 基于改进 BP 网络的小麦品种识别[J]. *贵州农业科学*, 2017, 45(10): 156 – 160.
- MENG Xi, WANG Kejian, HAN Xianzhong. Classification of wheat varieties by improved BP neural network[J]. *Guizhou Agricultural Sciences*, 2017, 45(10): 156 – 160. (in Chinese)
- [9] 何胜美, 李仲来, 何中虎. 基于图像识别的小麦品种分类研究[J]. *中国农业科学*, 2005, 38(9): 1869 – 1875.
- HE Shengmei, LI Zhonglai, HE Zhonghu. Classification of wheat cultivar by digital image analysis[J]. *Scientia Agricultura Sinica*, 2005, 38(9): 1869 – 1875. (in Chinese)
- [10] 王志军, 丛培盛, 周佳璐, 等. 基于图像处理与神经网络的小麦颗粒外观品质评价方法[J]. *农业工程学报*, 2007, 23(1): 158 – 161.
- WANG Zhijun, CONG Peisheng, ZHOU Jialu, et al. Method for identification of external quality of wheat grain based on image processing and artificial neural network[J]. *Transactions of the CSAE*, 2007, 23(1): 158 – 161. (in Chinese)
- [11] 贾佳, 王建华, 谢宗铭, 等. 计算机图像识别技术在小麦种子精选中的应用[J]. *中国农业大学学报*, 2014, 19(5): 180 – 186.
- JIA Jia, WANG Jianhua, XIE Zongming, et al. Wheat seeds selection based on computer image recognition technique[J]. *Journal of China Agricultural University*, 2014, 19(5): 180 – 186. (in Chinese)
- [12] 张玉荣, 陈赛赛, 周显青, 等. 基于图像处理和神经网络的小麦不完善粒识别方法研究[J]. *粮油食品科技*, 2014, 22(3): 59 – 63.
- ZHANG Yurong, CHEN Saisai, ZHOU Xianqing, et al. Identification of unsound kernels in wheat based on image processing and neural network[J]. *Science and Technology of Cereals, Oils and Foods*, 2014, 22(3): 59 – 63. (in Chinese)
- [13] 林中琦, 牟少敏, 时爱菊, 等. 基于 Spark 的支持向量机在小麦病害图像识别中的应用[J]. *河南农业科学*, 2017, 46(7): 148 – 153.
- LIN Zhongqi, MU Shaomin, SHI Aiju, et al. Classification of wheat disease images using parallelized support vector machine based on Spark[J]. *Journal of Henan Agricultural Sciences*, 2017, 46(7): 148 – 153. (in Chinese)
- [14] 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): 1300 – 1312.
- CHANG Liang, DENG Xiaoming, ZHOU Mingquan, et al. Convolutional neural networks in image understanding[J]. *Acta Automatica Sinica*, 2016, 42(9): 1300 – 1312. (in Chinese)
- [15] FERENTINOS K P. Deep learning models for plant disease detection and diagnosis[J]. *Computers and Electronics in Agriculture*, 2018, 145: 311 – 318.
- [16] ZHANG S, HUANG W, ZHANG C. Three-channel convolutional neural networks for vegetable leaf disease recognition[J]. *Cognitive Systems Research*, 2019, 53: 31 – 41.
- [17] BARBEDO J G A. Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification[J]. *Computers and Electronics in Agriculture*, 2018, 153: 46 – 53.
- [18] FUENTE A, YOON S, KIM S C, et al. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition[J]. *Sensors*, 2017, 17(9): 2022 – 2042.
- [19] PICON A, ALVAREZ-GILA A, SEITZ M, et al. Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild[J]. *Computers and Electronics in Agriculture*, 2019, 161: 280 – 290.
- [20] LU Y, YI S, ZENG N, et al. Identification of rice diseases using deep convolutional neural networks[J]. *Neurocomputing*, 2017, 267: 378 – 384.
- [21] RANGARAJAN A K, PURUSHOTHAMAN R, RAMESH A. Tomato crop disease classification using pre-trained deep learning algorithm[J]. *Procedia Computer Science*, 2018, 133: 1040 – 1047.
- [22] KAMILARIS A, PRENAFETA-BOLDÚ F X. Deep learning in agriculture: a survey[J]. *Computers and Electronics in Agriculture*, 2018, 147(1): 70 – 90.
- [23] 张领先, 陈运强, 李云霞, 等. 基于卷积神经网络的冬小麦麦穗检测计数系统[J/OL]. *农业机械学报*, 2019, 50(3): 144 – 150.
- ZHANG Lingxian, CHEN Yunqiang, LI Yunxia, et al. Detection and counting system for winter wheat ears based on convolutional neural network[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(3): 144 – 150. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190315&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2019.03.015. (in Chinese)
- [24] HASAN M M, CHOPIN J P, LAGA H, et al. Detection and analysis of wheat spikes using convolutional neural networks[J]. *Plant Methods*, 2018, 14(1): 100 – 113.
- [25] 于重重, 周兰, 王鑫, 等. 基于 CNN 神经网络的小麦不完善粒高光谱检测[J]. *食品科学*, 2017, 38(24): 283 – 287.
- YU Chongchong, ZHOU Lan, WANG Xin, et al. Hyperspectral detection of unsound kernels of wheat based on convolutional neural network[J]. *Food Science*, 2017, 38(24): 283 – 287. (in Chinese)
- [26] 金秀, 卢杰, 傅运之, 等. 基于深度卷积神经网络的小麦赤霉病高光谱病症点分类方法[J]. *浙江农业学报*, 2019, 31(2): 315 – 325.
- JIN Xiu, LU Jie, FU Yunzhi, et al. A classification method for hyperspectral imaging of fusarium head blight disease symptom based on deep convolutional neural network[J]. *Acta Agriculturae Zhejiangensis*, 2019, 31(2): 315 – 325. (in Chinese)
- [27] 余乐, 吴超, 吴静珠, 等. 结合高光谱与 CNN 的小麦不完善粒识别方法[J]. *电子测量与仪器学报*, 2017, 31(8): 1297 – 1303.
- YU Le, WU Chao, WU Jingzhu, et al. Identification method of unsound kernel wheat based on hyperspectral and convolution neural network[J]. *Journal of Electronic Measurement and Instrumentation*, 2017, 31(8): 1297 – 1303. (in Chinese)
- [28] 国家标准化管理委员会. GB 1351—2008 小麦[S]. 北京: 中国标准出版社, 2001.