doi:10.6041/j.issn.1000-1298.2020.S1.052

基于卷积神经网络的蓖麻种子损伤分类研究

侯俊铭　姚恩超　朱红杰
(沈阳农业大学工程学院, 沈阳 100866)

摘要: 不同形式的机械损伤对蓖麻种子发芽生长和榨油后的蓖麻油质量影响不同,因此对产生机械损伤的蓖麻种子进行识别分类非常重要。提出了基于卷积神经网络的蓖麻种子损伤分类算法。以种壳缺失、裂纹和完整蓖麻种子(无损伤)的分类为例,构建了蓖麻种子训练集和测试集,搭建 2 个卷积层(每个卷积层 8 个卷积核)、2 个池化层和 1 个全连接层(128 个节点),实现分类。为提高分类的准确性和实时性,调整网络结构以及优化批量尺寸参数,得到较优的网络结构和批量尺寸;利用上下左右翻转扩充样本,改变优化器、学习率以及正则化系数对该网络进行组合试验,获得准确率及效率较优的组合。通过 Dropout 优化减小卷积神经网络模型的过拟合。试验结果表明:卷积层为 5 层、池化层为 5 层、批量尺寸为 32 时,该网络模型平均测试准确率为 92.52%。在组合试验中,Sgdm 优化器更新网络可以提高网络的分类性能;数据扩增可以增加样本的多样性,减小过拟合现象;通过 Dropout 优化卷积神经网络模型的过拟合;选择学习率为 0.01,正则化系数为 0.000 5 时,模型分类准确率达到 94.82%,其中种壳缺失蓖麻种子准确率为 95.60%,裂纹蓖麻种子准确率为 93.33%,完整蓖麻种子准确率为 95.51%,平均检测单粒蓖麻种子的时间为 0.143 5 s。最后,开发蓖麻种子损伤分类系统,验证结果为:种壳缺失蓖麻种子的准确率为 96.67%,裂纹蓖麻种子的准确率为 80.00%,完整蓖麻种子的准确率为 86.67%。该卷积神经网络模型在损伤蓖麻种子分类时具有较高的识别准确率,可在蓖麻种子在线实时分类的检测系统中应用。

关键词: 蓖麻种子; 损伤特征; 分类; 组合试验; 卷积神经网络
中图分类号: TP391.4　　**文献标识码**: A　　**文章编号**: 1000-1298(2020)S1-0440-10

Classification of Castor Seed Damage Based on Convolutional Neural Network

HOU Junming　YAO Enchao　ZHU Hongjie
(*College of Engineering*, *Shenyang Agricultural University*, *Shenyang* 100866, *China*)

Abstract: Different forms of mechanical damage affect the germination and growth of castor seeds and the quality of castor oil after oil extraction. Therefore, it is very important to identify and classify castor seeds with mechanical damage. The classification of castor seeds with seed shells missing and castor seeds with cracks and intact castor seeds (without damage) was taken as an example. The training set and test set of castor seeds were constructed, which included two convolutional layers (eight convolution nuclei per convolutional layer), two pooling layers and one full connecting layer (128 nodes). In order to improve the accuracy and real-time performance of the convolutional neural network, the network structure was adjusted and the batch_size parameters were optimized to obtain better network structure and batch_size. The sample was expanded by turning up and down, and the learning rate and regularization coefficient of the optimizer were changed to conduct a combination test on the network, so as to obtain a combination with better accuracy and efficiency. Finally, the over-fitting of the convolutional neural network model was reduced through Dropout optimization. The experimental results showed that the average test accuracy of the network model was 92.52% when the convolution layer was 5, pooling layers was 5 and the batch_size was 32. In combination test, the Sgdm optimizer can improve the classification performance of the network by updating the network. Data amplification can increase the diversity of samples and thus reduce the over-fitting phenomenon. After the over-fitting of the convolutional neural network model was reduced by Dropout optimization, the average test accuracy of the convolutional model was 93.45%, which was 0.93 percentage points higher than that before optimization. When the learning rate was 0.01

收稿日期: 2020-08-10　修回日期: 2020-08-30
基金项目: 国家自然科学基金项目(51475312)
作者简介: 侯俊铭(1978—),男,副教授,博士,主要从事农业机械设计与制造研究,E-mail: junming_hou@163.com

and the regularization coefficient was 0.000 5, the classification accuracy of the model could reach 94.82% after dropout optimization. The accuracy of missing seed shell castor seeds was 95.60%, the accuracy rate of cracked castor seeds was 93.33%, the accuracy rate of intact castor seeds was 95.51%, and the average detection time of a single castor seed image was 0.143 5 s. Finally, the system for castor seeds damage classification was developed. The results of verification of the algorithm showed that the accuracy of seed shell missing castor seeds was 96.67%, that of cracked castor seeds was 80.00%, and that of complete castor seeds was 86.67%. The combined test convolutional neural network model had a high recognition accuracy in the classification of damaged castor seeds, and the convolutional model can be applied to the detection system for the real-time classification of castor seeds.

Key words: castor seeds; damage feature; classification; composite test; convolutional neural network

0　引言

蓖麻是重要的生物质资源油料作物，脱壳后的蓖麻籽粒含油量高。蓖麻油可生产尼龙、润滑油、表面活性剂等产品，在航空、航海、运输、医药制造等高技术领域有广泛的应用[1-2]。蓖麻种子在脱壳过程产生的损伤将直接影响后期发芽及植株的生长。损伤还将影响作为榨油用蓖麻的出油率。因此，损伤蓖麻种子的检测极其重要。蓖麻种子表面的纹理特征、形态特征复杂，这些都影响缺陷特征的提取效果。不同缺陷特征需要不同的算法提取，线性判别模型、人工神经网络、支持向量机等常规分类算法已不能满足蓖麻种子的缺陷分类。研究合理的蓖麻种子损伤分类算法非常重要。

目前，卷积神经网络等深度学习模型越来越受到重视，在图像处理领域运用越来越广泛[3-4]，其被广泛应用于医学、航空、农业等领域。在农业领域，卷积神经网络常被用于农业作物的病害识别分类[5-9]、病虫识别定位[10-11]、植物识别与产量估算[12-18]等方面，相关研究表明，与传统机器视觉技术对比，卷积神经网络方法具有明显优势。文献[19]以完好花生、表皮破损花生和果仁破损花生的分类为例，构建花生图像库，搭造卷积神经网络，为提高分类准确率和实时性，从训练集构成、减小过拟合、加快训练收敛速度、简化网络结构等几方面对卷积神经网络进行优化。文献[20]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（LeNet－5、AlexNet、VGG－16 和 ResNet－34）与传统的 SVM 和 BP 神经网络进行比较试验，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，最高可达 99.29%。文献[21]通过对 AlexNet 网络进行优化得到适合油茶籽完整性识别的卷积神经网络模型，优化后的网络对油茶籽完整性识别准确率达到 98.05%，训练时间为 0.58 h，平均检测时间为 13.91 ms。文献[22]采用机器视觉与自适应卷积神经网络检测花生仁品质，试验结果表明，该方法对花生常见缺陷的平均识别率达 99.7%，与传统的深度网络相比实现了更高的收敛速度与识别精度。文献[23]利用卷积神经网络对大麦品种进行分类，结果表明，利用卷积神经网络对大麦品种分类准确率超过 93%，而基于颜色、纹理和形态属性的品种分类准确率不到 75%。文献[24]提出一种基于三通道卷积神经网络（Three-channel convolutional neural networks，TCCNN）的蔬菜病害识别方法，该方法不需要复杂的预处理、病变分割和手工提取特征，而是直接通过 TCCNN 从彩色病变叶片图像中自动提取出高水平的判别特征。结果表明，在训练样本与测试样本为 7∶3时，TCCNN 对蔬菜病害分类准确率为 94.27%，优于传统分类算法。本文采用卷积神经网络对蓖麻种子损伤进行分类，并优化卷积网络来提高其分类准确率。

本文以种壳缺失蓖麻种子、裂纹蓖麻种子和完整蓖麻种子的分类为例，建立卷积神经网络；通过分析卷积池化层及批量尺寸（batch_size），利用组合试验来对比分析优化器类型及学习率等参数，提高模型的训练效率及测试准确率。

1　数据采集及卷积神经网络构建

1.1　数据采集

以内蒙古自治区通辽市广泛种植的典型品种哲蓖 4 号作为试验材料。该物料在干燥后进行脱壳，并从中挑选种壳缺失、裂纹损伤、种壳完整的蓖麻种子作为试验样本。

在室内环境（自然光 + 节能灯）下，用像素为 1 600 万的索尼 IMX398 CMOS 相机拍摄放置于白色 A4 纸上的蓖麻种子样本，拍摄距离为 5 ~ 10 cm，获得 525 幅图像（150 幅种壳缺失种子图像、150 幅裂纹蓖麻种子图像、225 幅完整蓖麻种子图像），每幅蓖麻种子图像的分辨率为 9 216 像素 ×6 912 像素，并将这些图像裁剪为 256 像素 ×128 像素的完全包含蓖麻种子的样本。由于种壳缺失蓖麻种子图像、裂纹蓖麻种子图像与完整蓖麻种子图像相差较多，

利用左右翻转、上下翻转图像增广方法将种壳缺失、裂纹蓖麻种子图像增广 3 倍,之后将这些图像分为训练集和测试集,其中训练集占 80%,测试集占 20%。训练集中部分蓖麻种子如图 1 所示。

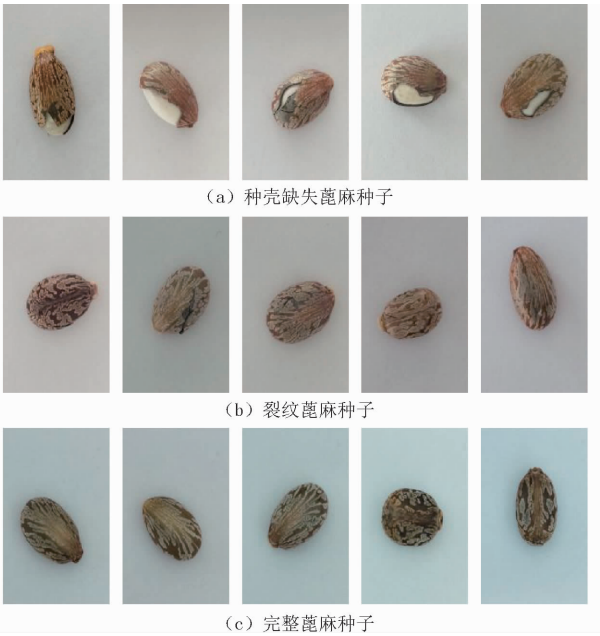

(a) 种壳缺失蓖麻种子

(b) 裂纹蓖麻种子

(c) 完整蓖麻种子

图 1 不同类型蓖麻种子图像

Fig. 1 Images of castor seeds of different types

1.2 卷积神经网络的构建

卷积神经网络(Convolutional neural network, CNN)是一种特殊的多层感知器或前馈神经网络。标准的卷积神经网络一般由输入层、交替的卷积层和池化层、全连接层和输出层构成。

1.2.1 输入层的设计

输入层可以直接输入原始数据,当输入为图像时,输入的数据为图像的像素值,本文输入层为经过处理后的 256 像素 ×128 像素的样本图像。

1.2.2 卷积层 1

卷积核的尺寸依据输入图像矩阵的大小和经验确定。若卷积核尺寸过小,会增加卷积核滑动过程的运算量,造成特征的过度提取,对于浅层的卷积神经网络无法很好识别;若卷积核尺寸偏大,则对图像边缘的检测效果欠佳。因此,根据经验将卷积层 1 中卷积核设置为 3 ×3,卷积核数目为 8 个,卷积核的移动步长为 1。卷积层特征图像尺寸计算公式为

$$w_{out1} = \frac{w_{in1} + 2p_a - F_1}{S_1} + 1 \tag{1}$$

式中 w_{out1}——卷积层输出特征图尺寸

w_{in1}——卷积层输入特征图尺寸

p_a——特征图填充圈数

F_1——卷积层卷积核尺寸

S_1——卷积步长

图像经过卷积层 1 卷积后得到的矩阵尺寸为 254 ×126,输出数据的维数为 8。

在卷积层后面加入非线性激励函数后,使神经网络的学习能力变强,能够更好地拟合目标函数。本研究采用 ReLu 函数作为激活函数,其表达式为

$$f(x) = \begin{cases} x & (x \geqslant 0) \\ 0 & (x < 0) \end{cases} \tag{2}$$

1.2.3 池化层 1

池化本质为采样,既可以看做是对上层数据进行压缩,也可以看成对特殊数据的选取。池化层的卷积核尺寸为 2 ×2,卷积核的移动步长为 2。池化后特征图像计算公式为

$$w_{out2} = \frac{w_{in2} - F_2}{S_2} + 1 \tag{3}$$

式中 w_{out2}——池化层输出特征图尺寸

w_{in2}——池化层输入特征图尺寸

F_2——池化层卷积核尺寸

S_2——池化步长

图像经过池化层处理后矩阵尺寸为 127 ×63,维度为 8 维,此输出为卷积层 2 的输入。

1.2.4 卷积层 2

卷积层 2 的卷积核尺寸为 3 ×3,卷积数目为 8 个,卷积核的移动步长为 1。图像经过卷积层 2 卷积后得到的矩阵尺寸为 125 ×61,输出数据的维数为 8。

1.2.5 池化层 2

使用 2 ×2 的池化窗口进行最大池化,池化层的卷积核尺寸为 2 ×2,卷积核的移动步长为 2。图像经过池化层处理后矩阵尺寸为 63 ×31,将输出的矩阵转化为向量,输入至全连接层。

1.2.6 全连接输出层

经过多个卷积层池化层交替连接之后为全连接层,在全连接层中进一步对特征降维,将特征通过 SoftMax 分类器进行分类,之后通过输出层输出结果,其计算公式为

$$y_{rn} = \frac{\exp(a_{rn})}{\sum_{j=1}^{q} \exp(a_{rj})} \tag{4}$$

式中 y_{rn}——第 r 个样本属于第 n 类的预测概率

q——分类类别数量

a_{rn}——向量中第 r 个样本输出与第 n 类乘积的分量

a_{rj}——向量中第 r 个样本输出与第 j 类乘积的分量

本研究中,对种壳缺失、裂纹损伤和完整蓖麻种子进行分类,q 取 3。

在分类任务中,采用损失函数来评估真实值与

预测值之间的差距，损失函数公式为

$$E = -\sum_{i=1}^{p}\sum_{j=1}^{k} t_{ij}\ln\hat{t}_{ij} \tag{5}$$

式中　E——损失函数

p——批尺寸

k——输入网络样本数

t_{ij}——第 i 个样本对应第 j 类的真实值

$\hat{t}_{ij}$——第 i 个样本对应第 j 类的预测值

构建后的卷积神经网络模型如图 2 所示，各层参数如表 1 所示。

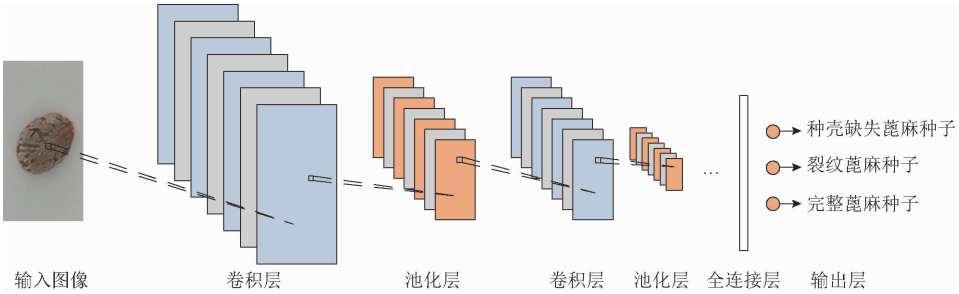

图 2　卷积神经网络模型图

Fig. 2　Convolutional neural network model diagram

表 1　卷积神经网络参数

Tab. 1　Convolutional neural network parameters

层序号	类型	参数大小	步长
1	输入层		
2	卷积层 1	8 个 3×3 核	1
3	池化层 1	2×2 核	2
4	卷积层 2	8 个 3×3 核	1
5	池化层 2	2×2 核	2
6	全连接层	128 个节点	1
7	输出层	3 个节点	

1.3　评价指标

采用准确率指标来评价分类算法的精度，定义为

$$a = \frac{N_C}{N_T}\times 100\% \tag{6}$$

式中　a——准确率，%

N_C——正确分类样本数量

N_T——训练总样本数量

1.4　运行平台

本文所有的训练和测试在同一台计算机上进行，处理器为 Inter(R) Xeon(R) CPU E5－2643 v3 3.4 GHz、32 GB 内存，8 GB 的 AMD FirePro W7100 Graphics Adapter 和 8 GB 的运行内存，在 Windows 10 系统下运行。

2　结果与分析

2.1　卷积和池化层对 CNN 模型的影响

选择合适数量的卷积层和池化层可以提高 CNN 模型分类精度，如果模型中含有的卷积层过少，模型无法获得蓖麻种子缺陷图像的本质特征；如果设计过多卷积层和池化层来提取图像特征，则会导致过度拟合。本文对动量随机梯度下降(Stochastic gradient descent with momentum，Sgdm)和自适应矩估计优化器(Adam)2 个优化器下的不同卷积层对分类模型准确率的影响进行比较，将卷积层从 2 层增加到 7 层，池化层从 2 层增加到 7 层，研究卷积、池化层数对准确率影响。由图 3 可知，在两个优化器下，卷积层和池化层为 5 层时，测试准确率最高。因此，本文选择卷积层和池化层为 5 层时，进行组合试验。

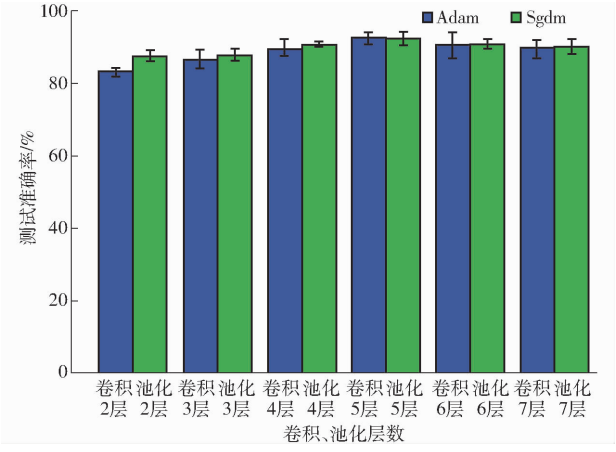

图 3　不同卷积层和池化层组合的分类精度

Fig. 3　Classification accuracy of combinations of different convolutional layers and pooling layers

2.2　批量尺寸对模型的影响

批量尺寸为每批数据量的大小，是深度学习中的一个重要参数。合适的批量尺寸能够加快模型的训练速度，也能够适当提高模型测试准确率。批量尺寸选择过小会难以达到收敛，选择过大会出现局部最优情况，习惯上选择批量尺寸(batch_size)为 2 的次幂可以加快二进制的计算[25]，本文选择不同批量尺寸(16、32、64、128)对模型性能影响进行对比试验，经过 5 次试验的平均测试准确率结果如图 4

所示。由图中可得,两个优化器下更新的模型在批量尺寸为 32 时准确率最高,因此,本文选择批量尺寸为 32 来进行组合试验。

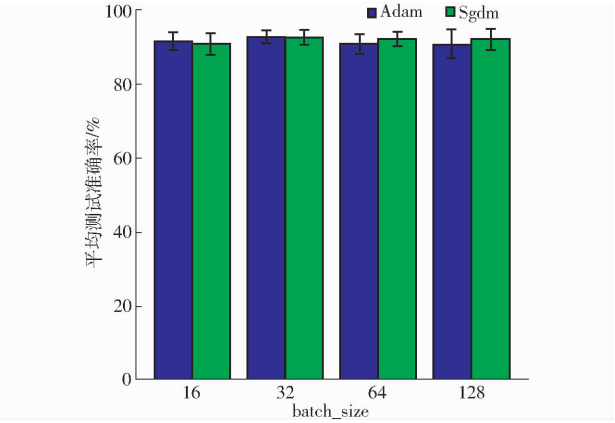

图 4 不同 batch_size 的测试准确率

Fig. 4 Test accuracy of different batch_size

2.3 模型训练及测试结果

结合硬件性能,测试和训练的批次样本数均设置为 32;训练间隔和显示间隔设置为 1 个 epoch(执行完 1 次全部训练样本,称之为 1 轮),最大训练轮数设为 32 个 epoch;梯度减裁设为 10。通过上文设计的卷积神经网络模型参数,综合试验的复杂度,以优化器类型(Sgdm、Adam),2 种数据扩充方法(无扩充、上下左右翻转),5 组初始学习率(0.1、0.01、0.001、0.005、0.000 1),3 组正则化系数(0、0.000 5、0.01),共进行了 60 组试验,各组试验的训练与测试结果如表 2 所示。

2.4 模型因素对模型性能的影响

2.4.1 优化器对模型的影响

优化器可以用来更新和计算影响模型训练和模型输出的网络参数,使其逼近或达到最优值,从而最小化(或最大化)损失函数。不同的优化器对网络的收敛速度及测试准确率有不同的影响。本文选择常用优化器 Sgdm、Adam 来对设计的卷积神经网络进行试验。由表 2 可知,用 Sgdm 优化器更新网络的测试准确率及训练效率基本上高于 Adam 优化器更新的网络(高出 0.37 ~ 9.52 个百分点)。Sgdm 优化器测试准确率及训练效率优于 Adam 优化器的各组之间差异性较小,因此,选择 4 组具有代表性的试验,编号 15 与 45,20 与 50,对迭代次数与训练准确率、测试准确率、训练损失值及测试损失值进行分析。由图 5 及表 2 得,在 Sgdm 优化器下的测试准确率高于 Adam,Adam 训练损失值与测试损失值差距比 Sgdm 下的差距稍大,过拟合化较 Sgdm 严重。因此,本模型选择 Sgdm 作为优化器更新模型。

2.4.2 扩充方式对模型的影响

在其他条件相同情况下,针对扩充方式(无扩充;上下左右翻转)进行训练集测试,准确率示例如图 6 所示。图 6 是相同优化器(Sgdm)、相同学习率(0.01)、相同正则化系数(0.001)以及不同扩充方式下的两组试验(6 和 21)的训练和测试准确率曲线。由表 2 及图 6 可得,扩充数据后的测试准确率基本比扩充前的测试准确率高,其原因是数据扩充增加了数据的多样性,对训练出现过拟合有促进作用。由图 6 可得,无扩充的准确率波动范围比较大,在稳定范围内,无扩充的波动率为 0.137 5,扩充后的波动率为 0.060 8。准确率的波动性可以衡量准确率曲线的平缓度,波动率越小表明曲线变化越稳定。其可以通过邻点准确率差值的均方根差值来衡量[5]。其波动率小的原因是数据量的增加,在学习过程中,学习到的损伤类型特征更加详细,致使准确率趋于稳定后波动平缓。因此,曲线波动趋于稳定,波动幅度逐渐减小,模型的鲁棒性逐渐提高。

2.4.3 学习率对模型的影响

学习率(Learning rate)作为监督学习以及深度学习中重要的超参数,其决定着目标函数能否收敛到局部最小值以及何时收敛到最小值。当学习率设置过小时,收敛过程将变得非常缓慢,而当学习率设置过大时,梯度会在最小值附近来回震荡,甚至可能无法收敛。合适的学习率能够使目标函数在合适的时间内收敛到局部最小值,使训练结果快速接近最优解,从而在相同的迭代次数下得到很好的训练准确率及测试准确率,结合文献[5]及试验经验,本研究选择学习率为 0.1、0.01、0.001、0.005、0.000 1 进行模型训练。在训练过程中,学习率按阶梯式指数衰减法衰减,学习率降低速度因子为 0.99,学习率速度降低的步长为 10 轮(训练过程中每 10 轮调整一次学习率)。

例如,第 20 组试验,初始学习率为 0.01,经过 32 轮的训练后,训练及测试准确率分别达到了 100% 及 94.44%。由表 2 中可得,在其它条件相同下,学习率为 0.01 时的测试准确率基本上高于其它学习率时的测试准确率(如试验编号 17、20、23、26、29 和试验编号 47、50、53、56、59)。图 7 为不同学习率下的测试准确率及损失值曲线。由图 7 可知,学习率大的测试准确率最低,其损失波动也最大,学习率为 0.01 时测试准确率最高,测试损失相对稳定。因此本研究模型选择学习率为 0.01 时进行训练。

2.4.4 正则化对模型的影响

本文采用 L2 正则化,它是通过添加正则化项的权重损失函数来减轻过拟合现象。L2 正则化的公

表 2　本文模型训练、测试的损失及准确率

Tab. 2　Loss and accuracy of training and testing of model

试验编号	优化器类型	数据是否扩充	学习率	正则化系数	训练时间/min	训练损失值	测试损失值	训练准确率/%	测试准确率/%
1	Sgdm	无扩充	0.1	0	3.77	0.289 7	0.397 8	87.50	86.67
2				0.000 5	3.73	0.132 1	0.521 6	96.88	84.76
3				0.001	3.73	0.111 7	0.407 6	96.88	88.57
4			0.01	0	3.72	0.001 0	0.480 1	100	90.48
5				0.000 5	3.77	0.002 6	0.275 0	100	93.33
6				0.001	3.75	0.015 2	0.382 7	100	89.52
7			0.001	0	3.73	0.012 5	0.238 8	100	91.43
8				0.000 5	3.78	0.011 9	0.298 7	100	90.48
9				0.001	3.80	0.006 5	0.328 1	100	89.52
10			0.005	0	3.72	0.001 1	0.216 2	100	94.29
11				0.000 5	3.75	0.006 9	0.375 7	100	89.52
12				0.001	3.52	0.005 0	0.306 4	100	93.33
13			0.000 1	0	3.28	0.086 7	0.287 6	100	90.48
14				0.000 5	3.77	0.080 6	0.355 3	100	82.86
15				0.001	3.75	0.100 4	0.368 5	100	88.57
16		扩充	0.1	0	11.40	0.391 8	0.367 5	84.38	86.67
17				0.000 5	11.25	0.150 3	0.308 5	96.88	91.85
18				0.001	9.27	0.225 3	0.373 0	90.63	89.26
19			0.01	0	10.35	0.043 3	0.393 4	100	91.11
20				0.000 5	10.33	0.037 2	0.300 4	100	94.44
21				0.001	10.27	0.014 2	0.321 5	100	91.85
22			0.001	0	10.47	0.018 8	0.287 6	100	92.96
23				0.000 5	10.27	0.030 9	0.286 3	100	91.85
24				0.001	10.27	0.010 6	0.216 0	100	94.07
25			0.005	0	10.47	0.019 1	0.314 5	100	92.22
26				0.000 5	10.22	0.142 8	0.363 1	96.88	91.85
27				0.001	10.27	0.142 3	0.244 0	96.88	91.11
28			0.000 1	0	11.40	0.069 9	0.246 1	100	90
29				0.00 05	11.55	0.068 9	0.286 3	100	91.48
30				0.001	11.43	0.048 6	0.255 1	100	92.22
31	Adam	无扩充	0.1	0	3.18	0.203 9	0.579 9	87.50	87.62
32				0.000 5	3.72	0.383 7	0.41.3	93.75	87.62
33				0.001	3.75	0.475 5	0.389 6	87.50	89.52
34			0.01	0	3.72	0.147 1	0.417 5	96.88	90.48
35				0.000 5	3.72	0.549 4	0.659 9	84.38	83.81
36				0.001	3.80	0.018 2	0.405 8	100	90.48
37			0.001	0	3.80	0.017 9	0.276 8	100	92.38
38				0.000 5	3.73	0.010 1	0.275 0	100	90.48
39				0.001	3.77	0.007 3	0.341 5	100	88.57
40			0.005	0	3.40	0.024 8	0.327 8	100	87.62
41				0.000 5	3.73	0.336 0	0.434 7	78.13	89.52
42				0.001	3.73	0.012 6	0.359 0	100	88.57
43			0.000 1	0	3.82	0.023 8	0.206 4	100	88.57
44				0.000 5	3.77	0.031 1	0.431 3	100	88.57
45				0.001	3.15	0.035 4	0.279 2	100	84.76
46		扩充	0.1	0	11.55	0.474 0	0.572 4	84.38	91.85
47				0.000 5	11.60	0.237 2	0.470 6	90.63	86.67
48				0.001	11.52	0.318 2	0.638 9	87.50	81.85
49			0.01	0	11.68	0.082 5	0.466 8	96.88	88.89
50				0.000 5	11.70	0.179 8	0.233 6	93.75	92.59
51				0.001	11.48	0.044 7	0.392 3	100	87.04
52			0.001	0	11.43	0.129 6	0.278 1	93.75	92.59
53				0.000 5	11.65	0.014 6	0.286 5	100	90.74
54				0.001	11.23	0.035 1	0.248 1	100	94.07
55			0.005	0	11.57	0.096 0	0.460 4	96.88	89.63
56				0.000 5	11.03	0.015 4	0.320 4	100	90.74
57				0.001	11.62	0.148 3	0.428 9	96.88	89.26
58			0.000 1	0	11.37	0.013 8	0.277 3	100	90.37
59				0.000 5	11.62	0.007 3	0.356 8	100	86.30
60				0.001	11.65	0.017 1	0.354 8	100	87.41

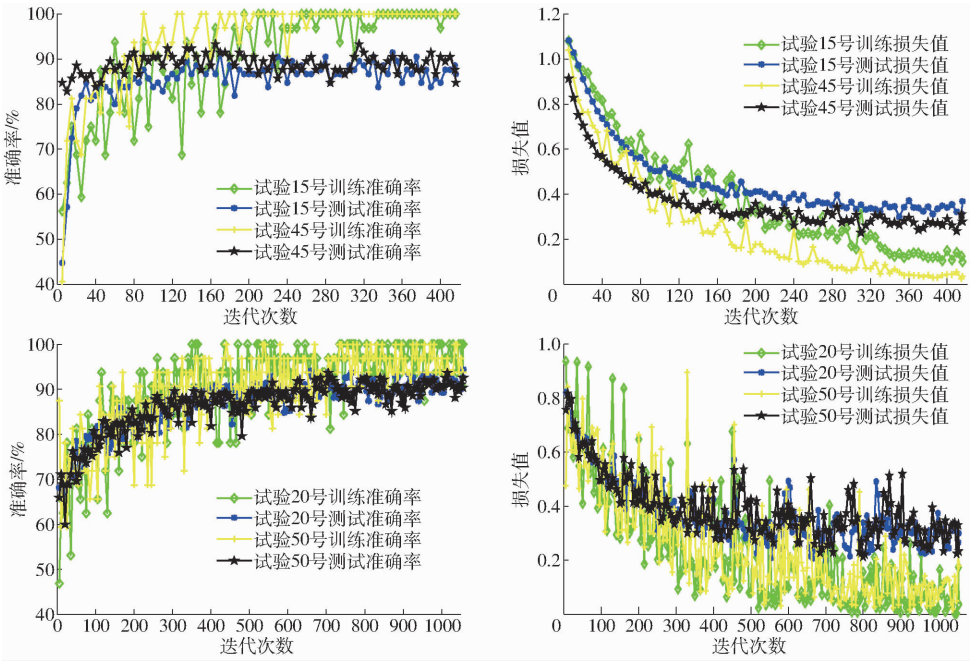

图 5 不同优化器下的训练、测试准确率和损失值

Fig. 5 Training, test accuracy and loss values under different optimizers

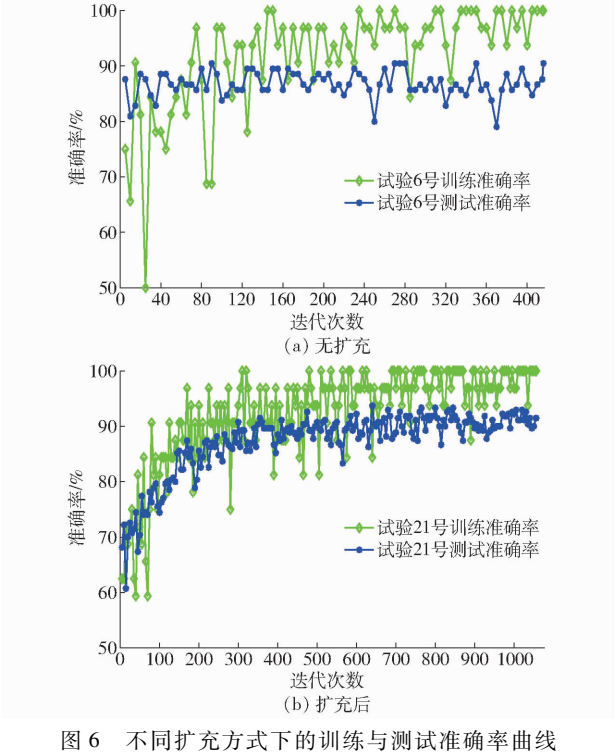

图 6 不同扩充方式下的训练与测试准确率曲线

Fig. 6 Accuracy curves of training and test under different expansion modes

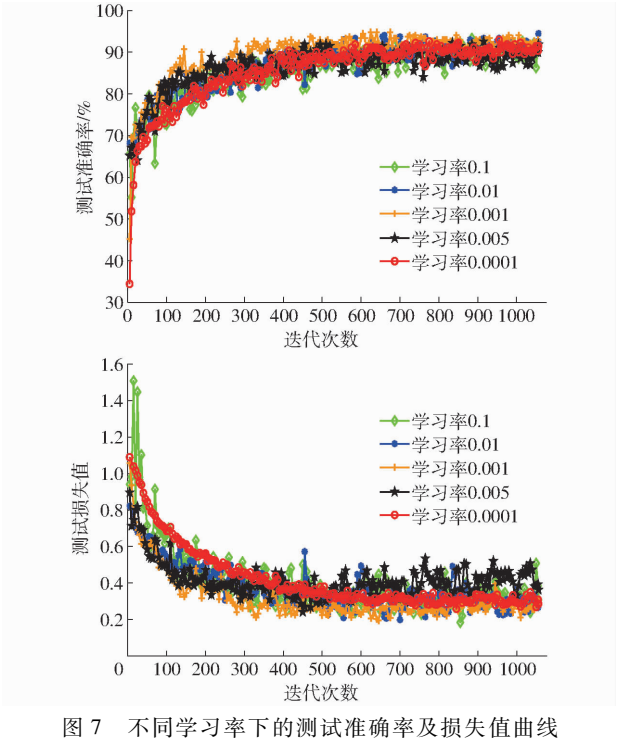

图 7 不同学习率下的测试准确率及损失值曲线

Fig. 7 Test accuracy and loss curves under different learning conditions

式为

$$\Omega(\boldsymbol{\omega}) = \frac{1}{2}\boldsymbol{\omega}^{\mathrm{T}}\boldsymbol{\omega} \tag{7}$$

式中 $\boldsymbol{\omega}$——权重向量

组合试验中，通过设置 3 组正则化系数（0、0.000 5、0.001）来强化对权重参数的惩罚。由表 2 可知，在 Sgdm 优化器下，当数据扩充和以较高学习率训练，正则化系数为 0.000 5 时，测试准确率存在比其它 2 个正则化系数的测试准确率稍高（如试验号为 16、17、18 和 19、20、21）的情况；而在其它情况下对准确率影响不稳定，原因是其它参数的影响大于 L2 正则化对模型性能的影响。

对性能较优的第 20 组试验（优化器为 Sgdm，初始学习率为 0.01，正则化系数为 0.000 5，通过上下左右翻转扩充数据）中经过 32 个 epoch 训练获得的模型进行训练。

2.4.5　Dropout 优化

为了解决过拟合问题，本研究采用 Dropout 策略，它是一种防止过拟合的正则化方式[26]。Dropout 层的输出等于它的输入，这个操作对应的是在训练过程中临时丢弃一个随机选择的单元及其所有来自网络的连接。因此，对于每个新的输入元素，trainNetwork 随机选择一个神经元子集，形成一个不同的层架构，这些结构使用普通的权重，学习不依赖于特定的神经元和连接，Dropout 层有助于防止过度拟合[27]。本文在全连接层采用了 Dropout 策略，根据文献[16]及试验经验，将 Dropout 参数设置为 0.25。经过 Dropout 后，测试准确率可以从较优的 94.44% 提升到 94.82%；经过 5 次的重复试验，平均测试准确率从 92.52% 提高到了 93.45%，增加了 0.93 个百分点。

3　模型检验

为检验设计模型的合理性及可行性，开发图形用户界面。在界面中选择训练好的模型，以及上文中的 3 种蓖麻种子损伤图像，载入待检测的图像即可进行检测。开发的系统界面如图 8 所示。选择优化器为 Sgdm，初始学习率为 0.01，正则化系数为 0.000 5，通过上下左右翻转扩充数据及添加 Dropout 层后的卷积神经网络模型进行训练，损伤蓖麻种子分类的卷积神经网络模型分类准确率可以达到 94.82%，其中种壳缺失蓖麻种子准确率为 95.60%，裂纹蓖麻种子准确率为 93.33%，完整蓖麻种子准确率为 95.51%，平均检测 1 幅单粒蓖麻种子图像的时间为 0.143 5 s。选择 1 幅完整蓖麻种子图像进行检测，结果显示图像为完整蓖麻种子，选择 1 幅裂纹蓖麻种子图像进行检测，结果显示图像为裂纹损伤蓖麻种子，选择 1 幅种壳缺失蓖麻种子图像进行检测，结果显示图像为种壳缺失蓖麻种子。

在可视化界面输入不同损伤类型的蓖麻种子图像（重新拍摄所得的损伤蓖麻种子图像）各 30 幅，其结果如表 3 所示。由表 3 可以看到，种壳缺失蓖麻种子的验证效果最理想，准确率高达 96.67%。部分裂纹蓖麻种子被分到完整蓖麻种子中，其分类错误原因是裂纹过于细微，在低分辨率图像下区分比较困难；裂纹蓖麻种子被分到种壳缺失蓖麻种子的原因为当蓖麻种子产生裂纹的过程中，裂纹周边有部分种皮缺失。部分分类不正确的原因为拍摄过程中蓖麻种子表面产生反光现象，影响结果。

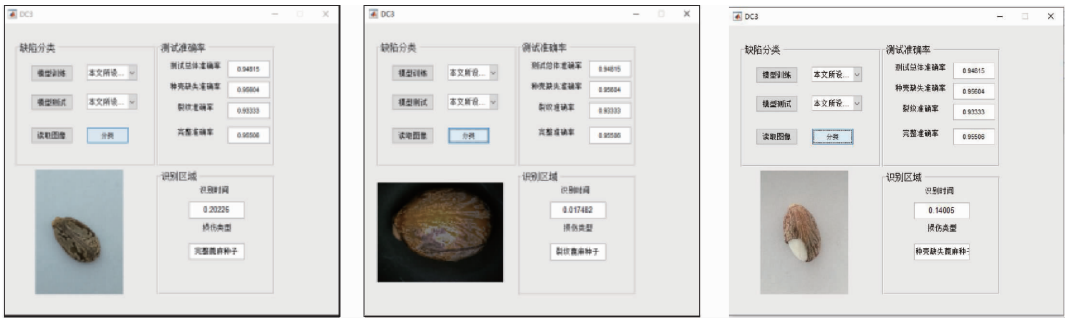

图 8　可视化界面检测结果

Fig. 8　Visual interface detection results

表 3　各损伤类型重复验证结果

Tab. 3　Repeated verification of each damage type

损伤类别	预测损伤类别			分类性能	
	种壳缺失	裂纹	完整（无损伤）	准确率/%	错误率/%
种壳缺失	29	1	0	96.67	3.33
裂纹	4	24	2	80.00	20.00
完整（无损伤）	3	1	26	86.67	13.33

4　结论

（1）在其它条件相同的情况下，采用 Sgdm 优化器的测试准确率可实现比 Adam 优化器下的测试准确率高出 0.37 ~ 9.52 个百分点。

（2）数据扩增可以增加模型的测试准确率，数据的扩增丰富了数据样本的多样性，可以减少模型的过拟合现象，当准确率趋于稳定时，数据扩增的波动率低于无数据扩增时，减轻了数据趋于稳定时的波动性。

（3）卷积层数为 5 层、批量尺寸为 32、优化器为 Sgdm、数据增广、学习率为 0.01、正则化系数为 0.000 5 时，模型性能较优，测试准确率可达到 94.44%，经过 Dropout 优化后，测试准确率可以达到 94.82%。

（4）开发蓖麻种子损伤分类的界面系统，对算法进行验证的结果为种壳缺失蓖麻种子准确率为 96.67%，裂纹蓖麻种子的准确率为 80.00%，完整蓖麻种子的准确率为 86.67%，该卷积模型可以较好识别不同损伤形式的蓖麻种子。

参 考 文 献

[1] 李敬忠，张宝贤，王伟男，等. 我国蓖麻育种与栽培技术研究进展[J]. 农业科技通讯，2018(10)：198－200，2.
LI Jingzhong，ZHANG Baoxian，WANG Weinan，et al. Research progress in breeding and cultivation of castor bean in China [J]. Bulletin of Agricultural Science and Technology，2018(10)：198－200，2. (in Chinese)

[2] 孙振钧，吕丽媛，伍玉鹏. 蓖麻产业发展：从种植到利用[J]. 中国农业大学学报，2012，17(6)：204－214.
SUN Zhenjun，LÜ Liyuan，WU Yupeng. Development of castor bean industry：from planting to utilization[J]. Journal of China Agricultural University，2012，17(6)：204－214. (in Chinese)

[3] 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 comprehension[J]. Acta Automatica Sinica，2016，42(9)：1300－1312. (in Chinese)

[4] KAMILARIS A，PRENAFETA-BOLDU F X. Deep learning in agriculture：a survey[J]. Computers and Electronics in Agriculture，2018，147(1)：70－90.

[5] 龙满生，欧阳春娟，刘欢，等. 基于卷积神经网络与迁移学习的油茶病害图像识别[J]. 农业工程学报，2018，34(18)：194－201.
LONG Mansheng，OUYANG Chunjuan，LIU Huan，et al. Image recognition of camellia oleifera diseases based on convolutional neural network & transfer learning[J]. Transactions of the CSAE，2018，34(18)：194－201 (in Chinese)

[6] 许景辉，邵明烨，王一琛，等. 基于迁移学习的卷积神经网络玉米病害图像识别[J/OL]. 农业机械学报，2020，51(2)：230－236，253.
XU Jinghui，SHAO Mingye，WANG Yichen，et al. Recognition of corn leaf spot and rust based on transfer learning with convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery，2020，51(2)：230－236，253. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=2002025&journal_id=jcsam. DOI：10.6041/j.issn.1000-1298.2020.02.025. (in Chinese)

[7] 马浚诚，杜克明，郑飞翔，等. 基于卷积神经网络的温室黄瓜病害识别系统[J]. 农业工程学报，2018，34(12)：186－192.
MA Juncheng，DU Keming，ZHENG Feixiang，et al. Disease recognition system for greenhouse cucumbers based on deep convolutional neural network[J]. Transactions of the CSAE，2018，34(12)：186－192. (in Chinese)

[8] 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.

[9] 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.

[10] THENMOZHI K，REDDY U S. Crop pest classification based on deep convolutional neural network and transfer learning[J]. Computers and Electronics in Agriculture，2019，164：104906.

[11] 杨国国，鲍一丹，刘子毅. 基于图像显著性分析与卷积神经网络的茶园害虫定位与识别[J]. 农业工程学报，2017，33(6)：156－162.
YANG Guoguo，BAO Yidan，LIU Ziyi. Localization and recognition of pests in tea plantation based on image saliency analysis and convolutional neural network[J]. Transactions of the CSAE，2017，33(6)：156－162. (in Chinese)

[12] 郑一力，张露. 基于迁移学习的卷积神经网络植物叶片图像识别方法[J/OL]. 农业机械学报，2018，49(增刊)：354－359.
ZHENG Yili，ZHANG Lu. Plant leaf image recognition method based on transfer learning with convolutional neural networks [J/OL]. Transactions of the Chinese Society for Agricultural Machinery，2018，49(Supp.)：354－359. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=2018s047&journal_id=jcsam. DOI：10.6041/j.issn.1000-1298.2020.02.025. (in Chinese)

[13] 吕石磊，卢思华，李震，等. 基于改进 YOLOv3－LITE 轻量级神经网络的柑橘识别方法[J]. 农业工程学报，2019，35(17)：205－214.
LÜ Shilei，LU Sihua，LI Zhen，et al. Orange recognition method using improved YOLOv3－LITE lightweight neural network [J]. Transactions of the CSAE，2019，35(17)：205－214. (in Chinese)

[14] 闫建伟，赵源，张乐伟，等. 改进 Faster－RCNN 自然环境下识别刺梨果实[J]. 农业工程学报，2019，35(18)：143－150.
YAN Jianwei，ZHAO Yuan，ZHAO Lewei，et al. Recognition of rosa roxbunghii in natural environment based on improved Faster－RCNN[J]. Transactions of the CSAE，2019，35(18)：143－150. (in Chinese)

[15] 薛金林，闫嘉，范博文. 多类农田障碍物卷积神经网络分类识别方法[J/OL]. 农业机械学报，2018，49(增刊)：42－48.
XUE Jinlin，YAN Jia，FAN Bowen. Classification and identification method of multiple kinds of farm obstacles based on convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery，2018，49(Supp.)：42－48. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=2018s006&journal_id=jcsam. DOI：10.6041/j.issn.1000-1298.2018.S0.006. (in Chinese)

[16] 袁培森，黎薇，任守纲，等. 基于卷积神经网络的菊花花型和品种识别[J]. 农业工程学报，2018，34(5)：152－158.
YUAN Peisen，LI Wei，REN Shougang，et al. Recognition for flower type and variety of chrysanthemum with convolutional neural network[J]. Transactions of the CSAE，2018，34(5)：152－158. (in Chinese)

[17] 周云成，许童羽，郑伟，等. 基于深度卷积神经网络的番茄主要器官分类识别方法[J]. 农业工程学报，2017，33(15)：219－226.
ZHOU Yuncheng，XU Tongyu，ZHEN Wei，et al. Classification and recognition approaches of tomato main organs based on DCNN[J]. Transactions of the CSAE，2017，33(15)：219－226. (in Chinese)

[18] 周亮，慕号伟，马海姣，等. 基于卷积神经网络的中国北方冬小麦遥感估产[J]. 农业工程学报,2019,35(15):119－128.
ZHOU Liang, MU Haowei, MA Haijiao, et al. Remote sensing estimation on yield of winter wheat in North China based on convolutional neural network[J]. Transactions of the CSAE, 2019,35(15):119－128. (in Chinese)
[19] 赵志衡，宋欢，朱江波，等. 基于卷积神经网络的花生籽粒完整性识别算法及应用[J]. 农业工程学报,2018,34(21):195－201.
ZHAO Zhiheng, SONG Huan, ZHU Jiangbo, et al. Identification algorithm and application of peanut kernel integrity based on convolution neural network[J]. Transactions of the CSAE,2018,34(21):195－201. (in Chinese)
[20] 祝诗平，卓佳鑫，黄华，等. 基于 CNN 的小麦籽粒完整性图像检测系统[J/OL]. 农业机械学报,2020,51(5)36－42.
ZHU Shiping, ZHUO Jiaxin, HUANG Hua, et al. Wheat grain integrity image detection system based on CNN[J/OL]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(5)36－42. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20200504&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2020.05.004. (in Chinese)
[21] 谢为俊，丁冶春，王凤贺，等. 基于卷积神经网络的油茶籽完整性识别研究[J/OL]. 农业机械学报:2020,51(7):13－21.
XIE Weijun, DING Yechun, WANG Fenghe, et al. Integrity recognition of camellia oleifera seeds based on convolutional neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(7):13－21. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag=1&file_no=20200702&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2020.07.002. (in Chinese)
[22] 张思雨，张秋菊，李可. 采用机器视觉与自适应卷积神经网络检测花生仁品质[J]. 农业工程学报,2020,36(4):269－277.
ZHANG Siyu, ZHANG Qiuju, LI Ke. Detection of peanut kernel quality based on machine vision and adaptive convolution neural network[J]. Transactions of the CSAE, 2020,36(4):269－277. (in Chinese)
[23] MICHA K, PRZEMYSAW G, PIOTR M S. Varietal classification of barley by convolutional neural networks[J]. Biosystems Engineering, 2019,184:155－165.
[24] SHANWEN Z, WENZHUN H, CHUANLEI Z. Three-channel convolutional neural networks for vegetable leaf disease recognition[J]. Cognitive Systems Research,2019,53:31－41.
[25] 赵立新，侯发东，吕正超，等. 基于迁移学习的棉花叶部病虫害图像识别[J]. 农业工程学报,2020,36(7):184－191.
ZHAO Lixin, HOU Fadong, LÜ Zhengchao, et al. Image recognition of cotton leaf diseases and pests based on transfer learning[J]. Transactions of the CSAE,2020,36(7):184－191. (in Chinese)
[26] HINTON G E, SRIVASTAVA N, KRIZHECVSKY A, et al. Improving neural networks by preventing co-adaptation of feature detectors[J]. Computer Science, 2012,3(4):212－223.
[27] SRIVASTAVA N, HINTON G, KRIZHECVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research,2014,15(1):1929－1958.

(上接第 428 页)

[21] ZHENG Y, YU C, CHENG Y, et al. Effects of ensilage on storage and enzymatic degradability of sugar beet pulp[J]. Bioresource Technology, 2011,102(2):1489－1495.
[22] DRIEHUIS F, ELFERINK S, SPOELSTRA S. Anaerobic lactic acid degradation during ensilage of whole crop maize inoculated with *Lactobacillus buchneri* inhibits yeast growth and improves aerobic stability[J]. Journal of Applied Microbiology, 1999, 87(4): 583－594.
[23] ELFERINK S, KROONEMAN J, GOTTSCHAL J C, et al. Anaerobic conversion of lactic acid to acetic acid and 1, 2-propanediol by *Lactobacillus buchneri*[J]. Applied and Environmental Microbiology, 2001, 67(1):125－132.
[24] WARNECKE T, GILL R T. Organic acid toxicity, tolerance, and production in *Escherichia coli* biorefining applications[J]. Microbial Cell Factories, 2005, 4(1): 25.
[25] HOFVENDAHL K, HAHN-HÄGERDAL B. Factors affecting the fermentative lactic acid production from renewable resources (1) [J]. Enzyme and Microbial Technology, 2000,26(2): 87－107.
[26] REN H, RICHARD T L, CHEN Z, et al. Ensiling corn stover: effect of feedstock preservation on particleboard performance [J]. Biotechnology Progress, 2006,22(1): 78－85.
[27] YAHAYA M S, KIMURA A, HARAI J, et al. Effect of length of ensiling on silo degradation and digestibility of structural carbohydrates of lucerne and orchardgrass[J]. Animal Feed Science and Technology, 2001, 92(3): 141－148.
[28] YANG L,LI Y. Anaerobic digestion of giant reed for methane production[J]. Bioresource Technology, 2014, 171: 233－239.
[29] BALDINI M, BORSO F D, FERFUIA C, et al. Ensilage suitability and bio-methane yield of *Arundo donax* and *Miscanthus* × *giganteus*[J]. Industrial Crops and Products, 2017, 95: 264－275.
[30] MILLEDGE J J, HARVEY P J. Ensilage and anaerobic digestion of *Sargassum muticum*[J]. Journal of Applied Phycology, 2016, 28(5): 3021－3030.
[31] CORNO L, PILU R, CANTALUPPI E, et al. Giant cane (*Arundo donax* L.) for biogas production: the effect of two ensilage methods on biomass characteristics and biogas potential[J]. Biomass and Bioenergy, 2016, 93: 131－136.