

任亚举,王瑞敏,薛冬,等. 基于深度学习结合高光谱技术的大豆种子活力检测方法[J]. 江苏农业学报, 2025, 41(5): 927-936.
doi:10.3969/j.issn.1000-4440.2025.05.011

基于深度学习结合高光谱技术的大豆种子活力检测方法

任亚举^{1,2}, 王瑞敏², 薛冬², 周琰琰², 陈新², 袁星星², 闫强², 罗楚平¹
(1.淮阴工学院生命科学与食品工程学院,江苏 淮安 223003; 2.江苏省农业科学院经济作物研究所,江苏 南京 210014)

摘要: 为实现大豆种子活力的高效精准无损识别,本研究以大豆品种 Williams82 种子为试验材料,通过不同程度的人工老化处理构建不同活力的大豆种子库,然后采集其成像高光谱图像和 RGB 图像,生成 3 个图像集(RGB 数据集、SIQ 数据集、ENVI 数据集),利用 4 个深度学习模型(Vgg16Net、GoogLeNet、MobileV3Net、ResNet-34)对种子活力进行检测,筛选出较优模型和数据集。并进一步在较优模型中添加坐标注意力机制(Coordinate attention, CA)和标签平滑损失函数提高模型的检测性能及鲁棒性。结果表明,基于 SIQ 数据集,ResNet-34 模型的训练集和验证集识别准确率分别达到 97.6%和 96.8%,检测性能优于其他模型和数据集组合。在 ResNet-34 模型中添加坐标注意力机制和标签平滑损失函数构建的 CA-ResNet-34 模型,基于 SIQ 数据集对大豆种子活力检测的准确率可达到 98.5%,比原始模型 ResNet-34 提升 1.7 个百分点。本研究结果为大豆种子活力准确、无损、高效检测提供新的方法。

关键字: 大豆; 种子活力; 检测; 高光谱; 深度学习; 注意力机制

中图分类号: S127 **文献标识码:** A **文章编号:** 1000-4440(2025)05-0927-10

Soybean seed vigor detection based on deep learning combined with hyperspectral technology

REN Yaju^{1,2}, WANG Ruimin², XUE Dong², ZHOU Yanyan², CHEN Xin², YUAN Xingxing²,
YAN Qiang², LUO Chuping¹

(1.School of Life Science and Food Engineering, Huaiyin Institute of Technology, Huai'an 223003, China; 2.Institute of Industrial Crops, Jiangsu Academy of Agricultural Sciences, Nanjing 210014, China)

Abstract: To achieve efficient, accurate, and non-destructive identification of soybean seed vigor, this study used seeds of the soybean variety Williams 82 as experimental materials. A library of soybean seeds with different levels of vigor was constructed through artificial aging treatments. Hyperspectral images and RGB images of the seeds were then collected to generate three image datasets (RGB dataset, SIQ dataset, and ENVI dataset). Four deep learning models (Vgg16Net, GoogLeNet, MobileV3Net, and ResNet-34) were employed to detect seed vigor, and the optimal models and datasets were selected. Furthermore, the coordinate attention (CA) mechanism and label smoothing loss function were incorporated into the optimal models to enhance their detection performance and robustness. The results demonstrated that using the SIQ data-

set and ResNet-34 model, the recognition accuracy reached 97.6% and 96.8% on the training set and validation set, respectively. The detection performance was superior to other combinations of models and datasets. The CA-ResNet-34 model, which incorporated the CA mechanism and label smoothing loss function into the ResNet-34 model, achieved a detection accuracy of 98.5% for soy-

收稿日期:2024-08-06

基金项目:生物育种钟山实验室项目(ZSBBL-KY2023-03);种质资源精准鉴定评价项目(005012691230229)

作者简介:任亚举(1997-),男,河南新乡人,硕士研究生,主要从事农作物图像识别。(E-mail)13419891193@163.com

通讯作者:闫强, yanqiang@jaas.ac.cn; 罗楚平, (E-mail) luochuping@163.com

bean seed vigor based on the SIQ dataset. This represented an improvement of 1.7 percentage points in accuracy compared to the original ResNet-34 model. The results of this study can provide a new method for the accurate, non-destructive, and efficient detection of soybean seed vigor.

Key words: soybean; seed vigor; detection; hyperspectral; deep learning; attention mechanism

大豆是中国重要的油料作物和经济作物,2023 年中国大豆种植面积达 $1.047 \times 10^7 \text{ hm}^2$, 产量约 $2.084 \times 10^7 \text{ t}$ 。由于大豆种子的种皮较薄,内部组织结构较为松散,使得大豆种子在储存时对环境条件比较敏感,极易在储存时发生老化。而种子老化常导致其活力下降、出苗延迟、成苗率低以及幼苗生长势和抗逆能力下降,进而降低大豆的产量和经济价值^[1-2]。老化种子和非老化种子在外表上并没有明显的差异,非专业人员很难区分。生产中常通过测定种子的酶活性、浸泡液电导率和发芽率等来评估种子的质量和活力,但这些方法耗时长、成本高且易对种子造成损害,因此生产中亟需建立一种高效、精准、无损的大豆种子活力检测度检测方法。

近年来,基于高光谱技术和机器学习方法(包括深度学习方法的)作物长势监测、作物营养状况监测、病虫害监测已取得较多成果^[3-8]。在基于高光谱技术和深度学习方法的种子活力检测方面亦得到初步开展。张伏等^[9]利用 963~1 698 nm 的玉米种子光谱数据,实现了热损伤玉米种子的检测,识别精确率达 98.33%。Liu 等^[10]基于光谱-空间特征提取高光谱图像,实现了糯玉米种子机械损伤检测。Zhang 等^[11]利用高光谱成像技术结合深度森林模型进行冻害水稻种子的识别。彭彦昆等^[12]利用近红外光谱和 PCA-SVM 模型实现热损伤番茄种子的识别;Peng 等^[13]利用高光谱成像和深度学习方法进行缺陷松子的检测。Al-Amery 等^[14]利用近红外光谱数据,构建了大豆种子活力的偏最小二乘回归(PLSR)分类模型,该模型在区分高活力与低活力种子方面表现出较高的准确性,准确率超过 85%。然而在进行更精细化的种子活力检测时效果并不理想。Zhang 等^[15]结合高光谱成像技术、非靶向代谢组学方法和机器学习方法等成功实现自然老化和加速老化甜玉米种子的活力监测。Ambrose 等^[16]利用高光谱成像技术和 PLSDA 模型实现玉米种子活力的快速测定;Xu 等^[17]利用高光谱成像结合多元数据分析成功实现玉米种子活力分类;丁子予等^[18]利用玉米种子全光谱信息提取特征光谱,并结合深度

学习方法实现玉米种子活力检测分类。Qi 等^[19]利用一种改进的 DCGAN(深度卷积生成对抗网络)和近红外高光谱成像技术实现水稻种子活力检测。此外,高光谱技术在西瓜、辣椒、甜菜等作物种子的活力检测中亦有开展^[20-22]。

目前利用种子表型进行识别的相关研究很多,但由于大多豆类种子老化后表型并无明显变化,针对大豆种子活力检测的研究还比较少,所得结果难以应用到实际生产中,且基于高光谱成像技术和深度学习方法的的大豆种子活力检测更少。此外,研究人员提出了较多的高光谱图像处理方法,但不同处理方法所得数据对种子活力检测差异比较的研究较少。因此,本研究以不同活力大豆种子的高光谱图像为研究对象,结合深度学习方法,通过多个数据集和多个模型相互交叉训练筛选出最优数据集和较优模型,并对较优模型结构以及训练方式加以优化实现对不同活力度大豆种子高效、精准、无损识别,从而为大豆种子筛选和大豆种子活力检测仪器的开发提供参考。

1 材料与方 法

1.1 种子处理

本研究试验所用种子为大豆品种 Williams82 种子,由江苏省农业科学院经济作物研究所提供。2023 年 8 月,挑选大小均匀、颗粒饱满且无损的大豆种子 3 900 粒,利用 3 个小网袋平均分装后,用 1% 次氯酸钠溶液浸泡 5 min 后冲洗干净,1 袋为不作处理对照,另外 2 袋放入提前预热好的温度 $(58 \pm 1) \text{ }^\circ\text{C}$ 的恒温水浴锅中进行人工老化处理^[23-24],分别水浴 12 min 和 24 min,取出后平铺放在通风处自然干燥 3~5 d 直至种子含水量降至原状态,得到未老化种子、老化 12 min 种子及老化 24 min 种子,如图 1 所示。从各处理种子中取出 100 粒,先采集各粒种子的高光谱数据及影像数据,再在恒温 $28 \text{ }^\circ\text{C}$ 智能温室中进行发芽试验,3 d 后观察种子的萌发情况,以种子萌发的芽长超过自身长度为正常萌发统计萌发率。根据芽长将种子活力分为高活力、中活力和低活力,对应芽长分别为 $> 12.1 \text{ cm}$ 、 $5.1 \sim 12.0 \text{ cm}$ 和 $\leq 5.0 \text{ cm}$ 。




图1 不同人工老化处理后的大豆种子

Fig.1 Soybean seeds after different artificial aging treatments

1.2 图像采集

利用 Specim IQ 手持式高光谱成像仪(芬兰 SPECIM 公司产品)采集各处理大豆种子的高光谱图像和 RGB 图像。采集时利用三脚架固定成像仪后将大豆种子每4粒一组摆放至镜头下方垂直

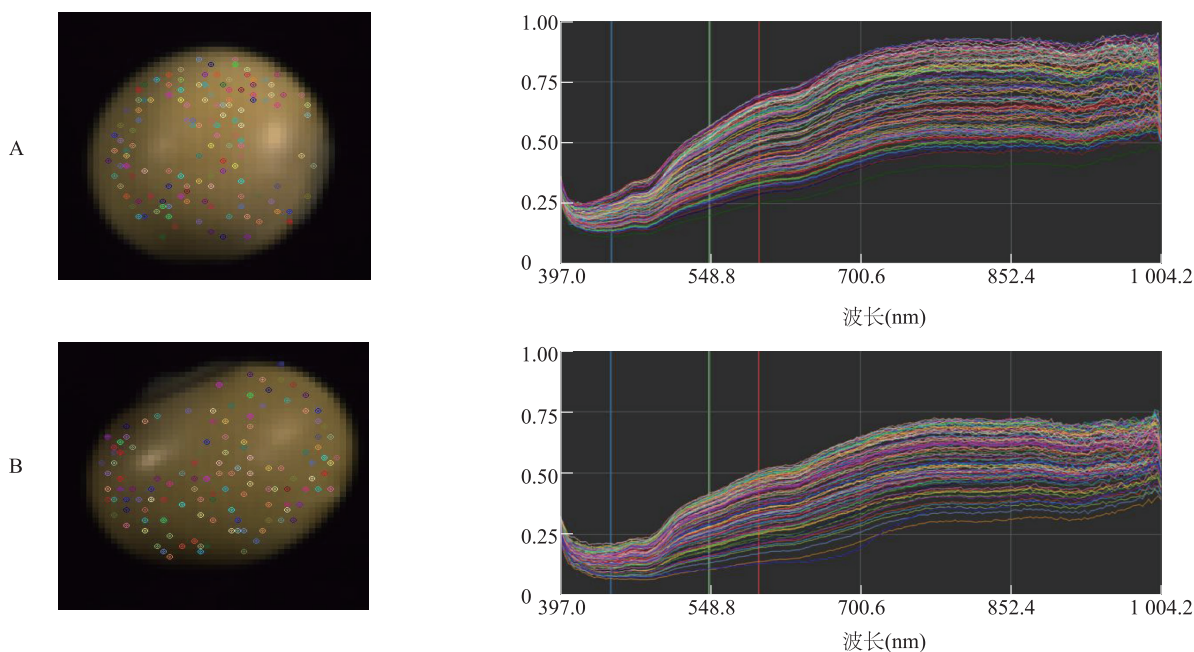
30 cm 处,采用 Simultaneous 参照白板进行数据采集,最终采集到各粒种子397~1 004 nm 波段的高光谱数据和 RGB 图像。

1.3 数据集制作

直接将采集到的 RGB 图像导出并裁剪得到 RGB 初始数据集,初始数据集经过水平翻转、垂直翻转、色彩增强、添加噪声、饱和度调整等数据增强后,每个处理可得 600 张 RGB 图像数据,3 个处理共得1 800 张 RGB 数据。其中 70% 用作训练集,30%用作测试集。

采集得到的高光谱数据集采用两种方式进行处理,一是利用 Specim IQ 手持式高光谱成像仪配套的 IQ Studio 高光谱数据可视化程序进行处理,二是利用 ENVI5.3 软件进行处理。

IQ Studio 导入采集的高光谱数据后在不同处理的种子表面光线均匀的地方分别选取 300 个不同的像素点,根据不同活力种子的高光谱曲线特征(图 2),提取光谱反射率>75%的斑块进行标记(图 3),并导出和裁剪得到 SIQ 数据集。



A:高活力种子不同像素点的光谱曲线;B:低活力种子不同像素点的光谱曲线。

图2 不同活力种子表面像素点的高光谱特征

Fig.2 Hyperspectral characteristics of pixels on the surface of seeds with different levels of vigor

将高光谱数据导入 ENVI5.3 软件后,以不同活力种子整个表面为感兴趣区域,计算不同活力种子整个表面的平均光谱曲线(图 4),构建不同活力种子的平

均高光谱特征数据库。再根据种子表面各像素点的高光谱曲线特征,利用光谱角映射分类器进行种子表面光谱特征分布分析(图 5),构建 ENVI 数据集。




图3 SIQ 数据集示例

Fig.3 Example of SIQ dataset





图4 不同活力种子的平均光谱特征

Fig.4 Average spectral characteristics of soybean seeds with different levels of vigor



A: 高活力种子; B: 中等活力种子; C: 低活力种子。

图5 不同活力种子表面光谱特征分布

Fig.5 Distribution of spectral characteristics on the surface of seeds with different levels of vigor

1.4 模型构建与评估

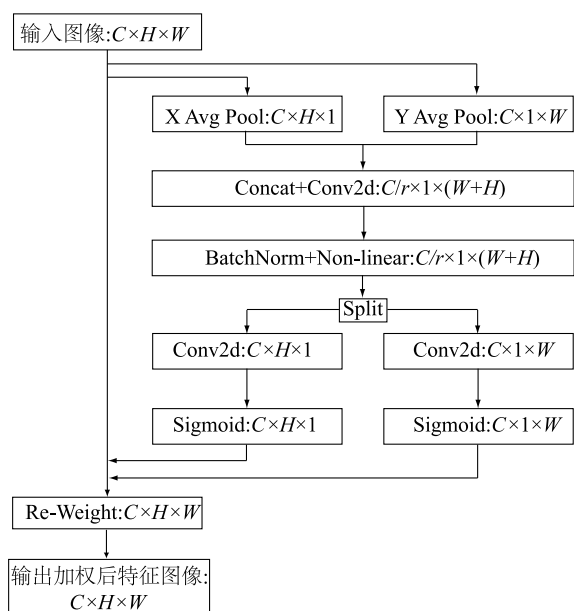
1.4.1 模型构建、选择与优化 使用 PyTorch 3.8 平台构建 Vgg16Net^[25]、GoogLeNet^[26]、MobileV3Net^[27]、ResNet-34^[28] 4 个深度卷积神经网络模型。然后利用不同模型和数据集进行大豆种子活力检测性能分析,筛选出最优模型和数据集,再进一步在最优模型中添加坐标注意力(Coordinate attention, CA)机制,模型训练过程中选用标签平滑用作损失函数的计算,进一步优化模型,提升模型检测性能。

1.4.1.1 标签平滑 标签平滑(Label smoothing)是一种正则化技术,用于深度学习模型的训练过程中^[29]。该技术能避免模型对训练数据中的某些标签过于自信导致过拟合,有助于模型学习到更为平滑的决策边界。标签平滑通常与交叉熵损失函数结合使用,是模型训练过程中损失函数的重要组成部分^[30]。

1.4.1.2 坐标注意力机制 坐标注意力(CA)机制是一个即插即用的轻量级注意力模块,是将位置信息嵌入到通道注意力中^[31]。与传统的通道注意力不同,本研究采用的 CA 机制通过一维全局池化将输入特征分解为两个特征编码,分别沿着不同空间方向聚合特征,以保留精确位置信息^[32]。CA 机制结构如图 6 所示。维度为 $C \times H \times W$ 的输入特征图首先沿宽度(W)和高度(H)分别进行全局平均池化,得到维度为 $C \times H \times 1$ 和 $C \times 1 \times W$ 的特征图,然后经过特征融合与转换层(Concat + Conv2d)将两个池化后的特征图像在通道维度上进行拼接,得到一个 $C/r \times 1 \times (W+H)$ 的特征图像(r 为调节注意力机制的缩减系数),进一步经过批量归一化与非线性激活层(BatchNorm+Non-linear)对卷积后的特征图进行批量归一化(BatchNorm)处理和非线性激活处理,以提高模型的表达能力,再经过分裂(Split)与二维卷积模块(Conv2d)将批量归一化和激活后的特征图分裂为两个维度分别为 $C \times 1 \times W$ 和 $C \times H \times 1$ 的特征图,再经过 Sigmoid 激活与重标定层对两个卷积后的特征图生成两个注意力图,这两个图将分别在宽度和高度上对输入特征图进行重标定;再经过特征权重重新分配层(Re-weight)将 Sigmoid 激活后的注意力图输出为加权后的维度为 $C \times H \times W$ 特征图,此时特征图就完成了某些特征的强化或弱化,同时结合了原始输入特征的通道信息和空间位置信息。

CA 机制能够非常准确地捕获到不同通道之间的关系,而且还考虑到相关的位置信息,提高了特征表达的准确性^[33]。凭借其灵活性和轻量化设计,CA 机制能够无缝集成到不同的网络架构中,满足多样化的任务需求。

1.4.1.3 CA-ResNet-34 模型结构 CA-ResNet-34 模型网络结构如图 7 所示。在 CA-ResNet-34 模型中,每个残差块包含多个卷积层和注意力模块,以及 1 个捷径连接。对于一个残差块,如果输入和输出的形状相同,则捷径分支中无需添加 1×1 卷积。如果



C :通道数量, H :图像的高度, W :图像的宽度, r :调节注意力机制的缩减系数,Avg Pool:空间池化层,Conv2d:2维卷积,Concat+Conv2d:特征融合与转换层,BatchNorm+Non-linear:批量归一化与非线性激活层,Sigmoid:激活函数,Re-Weight:特征权重重新分配层,Split:分裂与二维卷积模块。

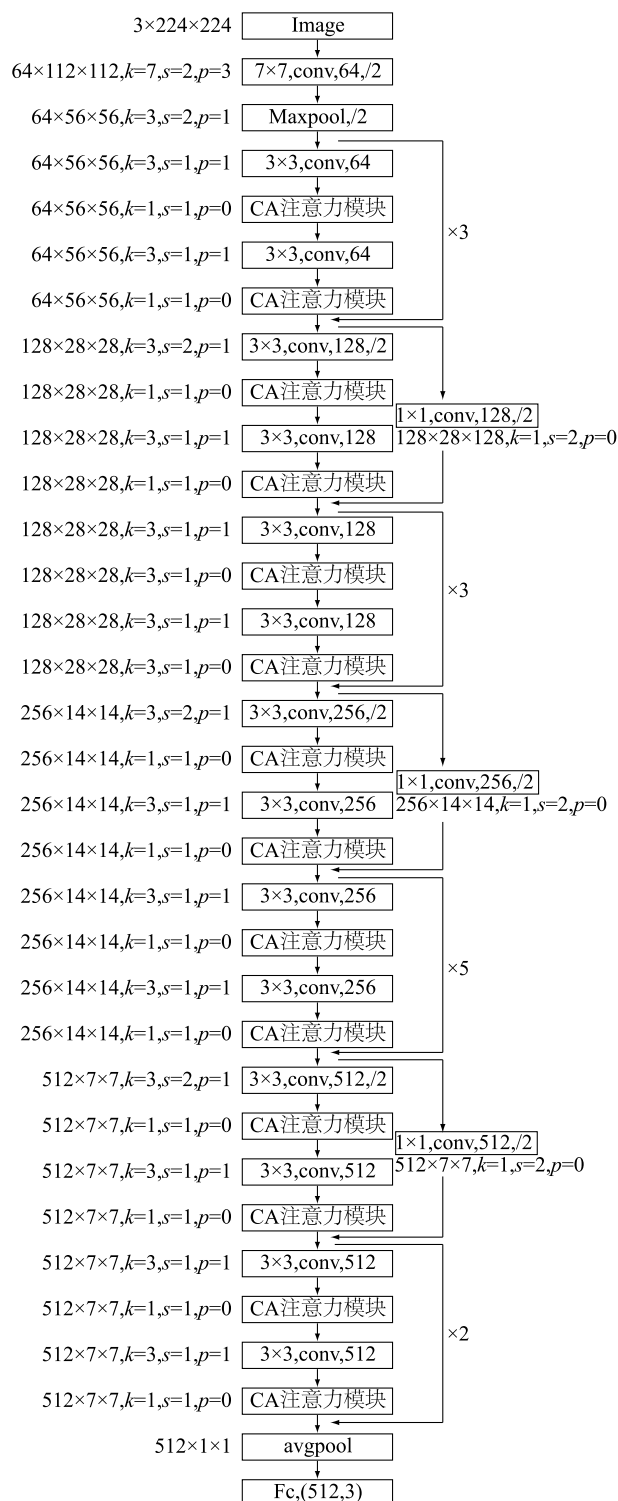
图6 坐标注意力模块结构

Fig.6 The structure of coordinate attention module

输入和输出的形状不同,比如在降采样或者升维的情况下,则捷径分支中需要添加 1×1 卷积层,用于匹配输入和输出的形状。

经规范化处理成维度为 $3 \times 224 \times 224$ 的图片输入模型,模型由8个模块组成,数据输入后首先经过卷积核大小为 7×7 的卷积层,再通过1个最大池化下采样层,然后经过4个残差模块处理,最后经过平均池化下采样层到全连接层实现特征提取并分类。每个残差模块都有2个卷积核大小为 3×3 的卷积层和2个CA机制模块组成,相同维度的残差模块直接相连,不同维度的残差模块通过1个核大小为 1×1 的卷积层相连,从而实现升维或降维操作。

1.4.2 模型评估 本研究采用混淆矩阵和准确率(Accuracy)、精确度(Precision)、召回率(Recall)、特异度(Specificity)等指标来评估模型的检测性能。混淆矩阵能揭示模型的总体性能,详细展示模型在各个类别上的预测准确性,是衡量模型检测性能的重要标准之一^[34]。准确率、精确度、召回率、特异度等指标的计算方法如下:



k :卷积核大小; s :步长,决定卷积核在输入特征图上滑动的间隔; p :填充值,在输入特征图边缘添加的行列数,用以保持输出特征图与输入特征图的尺寸一致;/2:高和宽降为原来一半;Image:规范化处理后维度为 $3 \times 224 \times 224$ 的输入图片;conv:卷积层;Maxpool:最大池化下采样层;avgpool:平均池化下采样层;Fc:全连接层。

图7 CA-ResNet-34模型的网络结构

Fig.7 Network structure of CA-ResNet-34 model

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

$$Specificity = \frac{TN}{TN+FP} \quad (4)$$

式中, TP 为实际值为正、预测结果为正的样本数; FP 为实际值为负、预测结果为正的样本数; TN 为实际值为负、预测结果为负的样本数; FN 为实际值为正、预测结果为负的样本数。

2 结果与分析

2.1 大豆种子的萌发

避光萌发 3 d 后, 各处理大豆种子的萌发情况如图 8 所示。从图中可以看出, 未老化处理的 CK 种子萌发率达 99%, 芽长基本在 12 cm 以上; 老化 12 min 处理的大豆种子萌发率为 54%, 且萌发种子的芽长大多低于 12 cm; 老化 24 min 处理的大豆种子萌发率仅为 7%, 基本均为低活力种子。




图 8 不同处理大豆种子的发芽情况

Fig.8 Germination of soybean seeds under different treatments

2.2 适宜模型和数据集的筛选

不同数据集下, 4 个模型对大豆种子活力检测结果的准确率如表 1 所示。从表中可以看出, 基于 RGB、SIQ、ENVI 数据集, ResNet-34 模型验证集准确率分别达到 91.9%、96.8%、97.4%, 表现最好。基于 SIQ 数据集, ResNet-34 模型的训练集和验证集识别准确率分别达到 97.6% 和 96.8%, 效果较好。基

于 RGB 数据集、ENVI 数据集, ResNet-34 模型的识别准确率亦均在 90.0% 以上, 但两者在训练集和验证集上的检测准确率差异均在 5 个百分点以上, 说明基于 RGB 数据集和 ENVI 数据集, ResNet-34 模型的大豆种子活力检测存在一定的欠拟合现象。

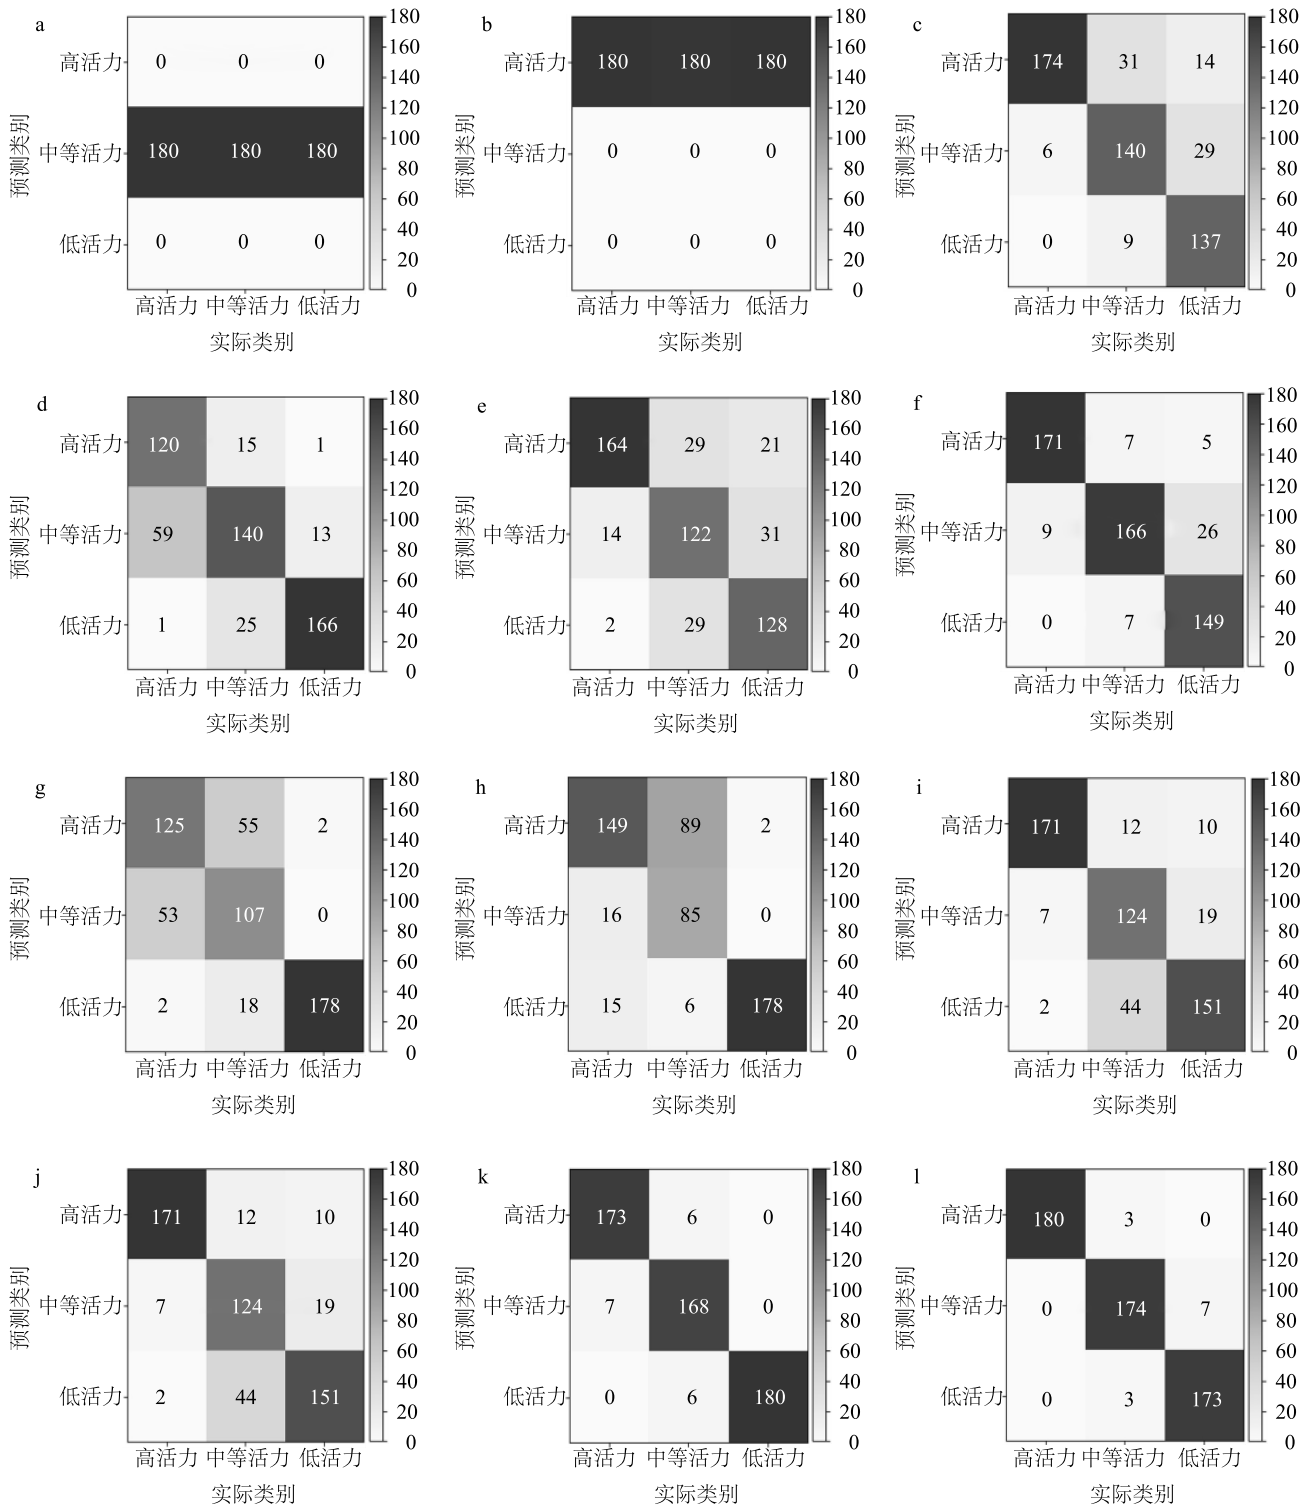
表 1 基于不同模型及数据集的种子活力检测结果

Table 1 Soybean seed vigor detection results based on different models and data sets

模型	训练集准确率(%)			验证集准确率(%)		
	RGB数据集	SIQ数据集	ENVI数据集	RGB数据集	SIQ数据集	ENVI数据集
Vgg16Net	35.6	34.7	85.9	33.3	33.5	93.1
MobileV3Net	74.2	81.7	70.1	73.1	78.8	82.2
GoogLeNet	79.8	86.4	86.6	79.6	76.6	89.3
ResNet-34	97.0	97.6	90.1	91.9	96.8	97.4

基于不同模型和数据集的大豆种子活力检测结果的混淆矩阵如图 9 所示。从图中可以看出, 基于 RGB 和 SIQ 数据集, Vgg16Net 模型无法正确区分不同活力的种子, 基于 ENVI 数据集, Vgg16Net 模型分类效果有所改善, 但错判情况仍较为严重。基于 3 个数据集, MobileV3Net 模型、GoogLeNet 模型能较好地进行不同活力大豆种子的分类, 其中, 基于 ENVI 数据集的分类效果更好。基于 RGB、SIQ、ENVI 3 个数据集, ResNet-34 模型的大豆种子活力分类效果优于其他 3 个模型; 基于 SIQ 数据集、ENVI 数据集, ResNet-34 模型的误判比基于 RGB 数据集更少。但由于基于 ENVI 数据集, ResNet-34 模型的种子活力检测准确率在训练集和验证集上存在较大差异, 即模型存在过拟合现象, 因此, 本研究认为, 基于 SIQ 数据集的 ResNet-34 模型大豆种子活力检测效果最好。

基于 RGB 数据集、SIQ 数据集和 ENVI 数据集, ResNet-34 模型对大豆种子活力检测的精确度、召回率、特异度如表 2 所示。从表中可以看出, 基于 SIQ 和 ENVI 数据集的 ResNet-34 模型大豆种子活力的检测精确度、召回率、特异度均表现较好, 而基于 RGB 数据集, ResNet-34 模型的精确度和召回率相对较低。考虑到基于 ENVI 数据集进行检测出现的过拟合现象, 本研究认为本试验条件下, 利用 ResNet-34 模型和 SIQ 数据集进行大豆种子活力检测效果较好。



a~c 分别为基于 RGB 数据集、SIQ 数据集和 ENVI 数据集的 Vgg16Net 模型大豆种子活力检测混淆矩阵；d~f 分别为基于 RGB 数据集、SIQ 数据集和 ENVI 数据集的 GoogleNet 模型大豆种子活力检测混淆矩阵；g~i 分别为基于 RGB 数据集、SIQ 数据集和 ENVI 数据集的 MobileV3Net 模型大豆种子活力检测混淆矩阵；j~l 分别为基于 RGB 数据集、SIQ 数据集和 ENVI 数据集的 ResNet-34 模型大豆种子活力检测混淆矩阵。

图 9 基于不同模型和数据集的大豆种子活力检测的混淆矩阵

Fig.9 Confusion matrices for soybean seed vigor detection based on different models and data sets

表 2 不同数据集下,ResNet-34 模型对大豆种子活力的检测性能
Table 2 The detection performance of ResNet-34 model for soybean seed vigor under different data sets

数据集	精确度 (%)	召回率 (%)	特异度 (%)
RGB	91.4	90.7	95.4
SIQ	96.8	96.8	98.4
ENVI	97.6	98.0	94.2

2.3 CA-ResNet-34 训练结果

基于 SIQ 数据集,CA-ResNet-34 模型训练集和




图 10 基于 SIQ 数据集,CA-ResNet-34 模型训练集和验证集的准确率和损失率随迭代次数的变化特征

Fig.10 Variation characteristics of the accuracy and loss rate for the training set and the validation set of CA ResNet-34 model based on the SIQ data set across iterations

2.4 ResNet-34 模型和 CA-ResNet-34 模型检测性能差异

利用 SIQ 数据集,CA-ResNet-34 模型对验证集大豆种子活力检测结果的混淆矩阵如图 11 所示。从图中可以看出,高活力种子中仍有 5 个样本被误

验证集的准确率和损失率随训练迭代次数的变化如图 10 所示。从图中可以看出,迭代次数低于 100 次时,训练集与验证集的准确率快速增加,而损失率迅速下降,当迭代次数达到 300 次时,训练集与验证集的准确率和损失率达到稳定,经过 500 次的迭代后,训练集和验证集的准确率分别高达 99.0% 和 98.5%,分别比 ResNet-34 模型提升 1.4 个百分点和 1.7 个百分点。此外,训练集和验证集的准确率和损失率保持相同趋势,说明 CA-ResNet-34 模型的检测性能较好。

判为中活力种子,中活力种子中亦有 5 个样本被错误分类,低活力种子全部正确分类,而原始模型 ResNet-34 中高活力种子有 7 个样本、中活力种子有 12 个样本被错误分类,说明改进后的模型对大豆种子活力检测效果更好。

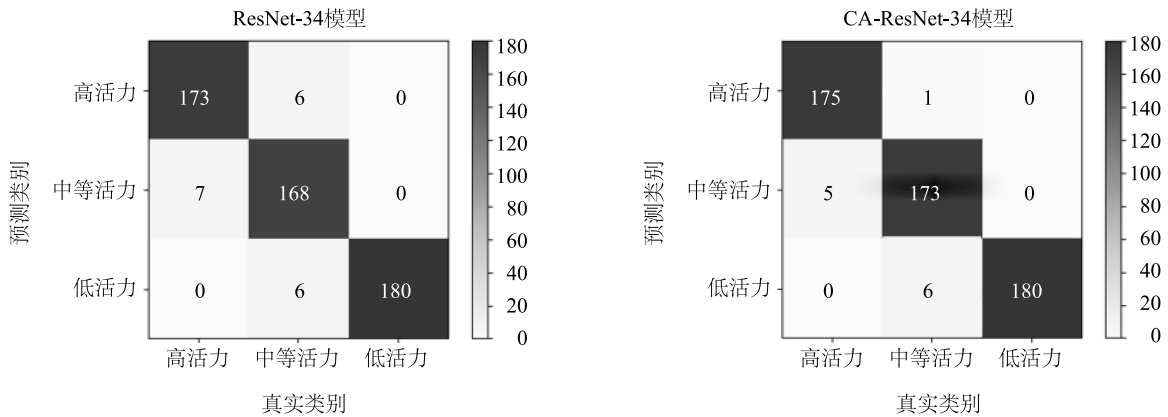


图 11 ResNet-34 模型和 CA-ResNet-34 模型对大豆种子活力检测的混淆矩阵

Fig.11 Confusion matrices for soybean seed vigor detection based on ResNet-34 model and CA-ResNet-34 model

基于 SIQ 数据集,ResNet-34 模型和 CA-ResNet-34 模型对大豆种子活力进行检测得到的精确度、召

回率、特异度如表 3 所示。从表中可以看出,CA-ResNet-34 模型的检测精确度、召回率、特异度分别

为 98.1%、98.1%、99.1%,比原始模型 ResNet-34 提升 1.3 个百分点、1.3 个百分点、0.7 个百分点。

表 3 基于 SIQ 数据集, ResNet-34 模型和 CA-ResNet-34 模型对大豆种子活力检测性能

Table 3 Detection performance of ResNet-34 model and CA-ResNet-34 model on soybean seed vigor based on SIQ dataset

模型	精确度 (%)	召回率 (%)	特异度 (%)
ResNet-34	96.8	96.8	98.4
CA-ResNet-34	98.1	98.1	99.1

3 讨论与结论

目前,基于高光谱数据与机器学习方法的大豆种子活力检测已有初步研究。Larios 等^[35]利用主成分分析(PCA)对原始光谱进行预处理,再结合传统机器学习模型(支持向量机、K 最近邻等)对大豆种子活力进行检测,研究结果发现模型能较好区分高活力种子和低活力种子。但当分类类别较多时,模型的识别效果较差。Al-Amery 等^[14]的研究结果表明,偏最小二乘分类模型无法区分高活力种子和中活力种子。此外,上述研究中一般多采用传统机器学习模型,在光谱数据的使用上一般先选择感兴趣区域,再利用主成分分析等算法进行光谱数据的分析,进而提取有效特征光谱,并进行检测,其步骤繁琐,方法复杂。本研究首先基于成像高光谱数据,分析了不同活力种子的高光谱特征,建立了基于成像高光谱的 SIQ 数据集、ENVI 数据集和 RGB 数据集,再利用 Vgg16Net、GoogleNet、MobileV3Net、ResNet-34 4 个深度学习模型进行大豆种子活力的检测,发现基于 SIQ 数据集, ResNet-34 模型验证集对大豆种子活力检测的准确率为 96.8%。在 ResNet-34 模型中进一步引入 CA 注意力机制及标签平滑技术后,优化后的模型(CA-ResNet-34)对大豆种子活力检测的准确率高达 98.5%。本研究还发现基于 RGB 数据集、SIQ 数据集和 ENVI 数据集, ResNet-34 模型在验证集均取得较好的检测效果,但在训练集与验证集间存在一定的差异,基于 SIQ 数据集, ResNet-34 模型验证集和训练集的检测准确率基本一致,而基于 RGB 数据集、和 ENVI 数据集, ResNet-34 模型在验证集和训练集间检测准确率差异较大,说明模型的泛化性不好,因此,实际应用中需要综合模型验证集和训练集的检测性能,选择适宜的

模型和数据集。

由于不同品种大豆种子及其老化后的表型差异较大,本研究建立的检测方法仅适用于表型如品种 Williams82 的黄色种皮大豆种子,进一步的研究中可增加不同表型大豆种子样本,进一步提高模型的识别精度和泛化能力。

参考文献:

- [1] 高琴梅,卢新雄,朱凌燕,等.大豆种子老化 MDA 和 4-HNE 的含量变化相关性研究[J].种子,2019,38(4):1-9.
- [2] 田桂霞.种子老化的生理化与分子机理研究进展[J].农业与技术,2018,38(10):42.
- [3] ZHANG G S, XU T Y, TIAN Y W. Hyperspectral imaging-based classification of rice leaf blast severity over multiple growth stages [J]. Plant Methods, 2022, 18(1): 123.
- [4] YANG M, KANG X Y, QIU X F, et al. Method for early diagnosis of *Verticillium* wilt in cotton based on chlorophyll fluorescence and hyperspectral technology [J]. Computers and Electronics in Agriculture, 2024, 216: 108497.
- [5] GUO A T, HUANG W J, DONG Y Y, et al. Wheat yellow rust detection using UAV-based hyperspectral technology [J]. Remote Sensing, 2021, 13(1): 123.
- [6] GUI J S, XU H R, FEI J Y. Non-destructive detection of soybean pest based on hyperspectral image and attention-ResNet meta-learning model [J]. Sensors, 2023, 23(2): 678.
- [7] WANG Z L, FAN S X, AN T, et al. Detection of insect-damaged maize seed using hyperspectral imaging and hybrid 1D-CNN-BiLSTM model [J]. Infrared Physics & Technology, 2024, 137: 105208.
- [8] NGUYEN H D, NANSEN C. Hyperspectral remote sensing to detect leafminer-induced stress in Bok choy and spinach according to fertilizer regime and timing [J]. Pest Management Science, 2020, 76(6): 2208-2216.
- [9] 张 伏,禹 煌,熊 瑛,等.热损伤玉米种子的高光谱无损检测[J].光谱学与光谱分析,2024,44(4):1165-1170.
- [10] LIU F S, FU J, ZHAO R Q. Pixel-wise mechanical damage detection of waxy maize using spectral-spatial feature extraction and hyperspectral image [J]. Computers and Electronics in Agriculture, 2023, 209: 107853.
- [11] ZHANG L, SUN H, RAO Z H, et al. Hyperspectral imaging technology combined with deep forest model to identify frost-damaged rice seeds [J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2020, 229: 117973.
- [12] 彭彦昆,赵 芳,李 龙,等.利用近红外光谱与 PCA-SVM 识别热损伤番茄种子 [J]. 农业工程学报, 2018, 34(5): 159-165.
- [13] PENG D D, JIN C, WANG J, et al. Defects recognition of pine nuts using hyperspectral imaging and deep learning approaches [J]. Microchemical Journal, 2024, 201: 110521.

- [14] AL-AMERY M, GENEVE R L, SANCHES M F, et al. Near-infrared spectroscopy used to predict soybean seed germination and vigour[J]. *Seed Science Research*, 2018, 28(3): 245-252.
- [15] ZHANG T T, LU L, YANG N, et al. Integration of hyperspectral imaging, non-targeted metabolomics and machine learning for vigour prediction of naturally and accelerated aged sweetcorn seeds[J]. *Food Control*, 2023, 153: 109930.
- [16] AMBROSE A, KANDPAL L M, KIM M S, et al. High speed measurement of corn seed viability using hyperspectral imaging[J]. *Infrared Physics & Technology*, 2016, 75: 173-179.
- [17] XU P, ZHANG Y P, TAN Q, et al. Vigor identification of maize seeds by using hyperspectral imaging combined with multivariate data analysis[J]. *Infrared Physics & Technology*, 2022, 126: 104361.
- [18] 丁子予, 岳学军, 曾凡国, 等. 基于机器学习和深度学习的玉米种子活力光谱检测[J]. *华中农业大学学报*, 2023, 42(3): 230-240.
- [19] QI H N, HUANG Z H, JIN B C, et al. SAM-GAN: an improved DCGAN for rice seed viability determination using near-infrared hyperspectral imaging[J]. *Computers and Electronics in Agriculture*, 2024, 216: 108473.
- [20] HONG S J, PARK S, LEE A, et al. Nondestructive prediction of pepper seed viability using single and fusion information of hyperspectral and X-ray images[J]. *Sensors and Actuators A: Physical*, 2023, 350: 114151.
- [21] 杨波, 段明磊, 杨童. 基于高光谱成像技术的西瓜种子活力等级分类方法研究[J]. *河南农业科学*, 2022, 51(9): 151-158.
- [22] 周翔, 兴旺, 杨军, 等. 甜菜种子活力的测定: 基于近红外高光谱技术[J]. *中国农学通报*, 2021, 37(29): 7-12.
- [23] 黄瑶, 乔爱民, 孙敏. 热水加速老化黄瓜种子的试验研究[J]. *种子*, 2004, 23(8): 11-12, 26.
- [24] 董永梅, 谢宗铭, 王志军, 等. 热水老化对棉花种子活力及遗传完整性的影响[J]. *种子*, 2018, 37(3): 19-22, 27.
- [25] HUANG Y Q, DONG C, LUO X S, et al. Facial expression recognition algorithm based on improved VGG16 network[C]//IEEE. 2021 6th international symposium on computer and information processing technology. Changsha, China: IEEE, 2021: 480-485.
- [26] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//IEEE. 2015 IEEE conference on computer vision and pattern recognition. Boston, MA, USA: IEEE, 2015: 1-9.
- [27] YI P Y, GU W X, ZHANG K, et al. Improvement and application of MobileNetV3-small model in the field of smart grid[C]//IEEE. 2022 2nd international conference on electrical engineering and control science. Nanjing, China: IEEE, 2022: 1144-1148.
- [28] PATIL O S, LE D M, GRIFFIS E J, et al. Deep residual neural network (ResNet)-based adaptive control: a Lyapunov-based approach[C/OL]//IEEE. 2022 IEEE 61st conference on decision and control (CDC). Cancun, Mexico: IEEE, 2022. <https://arxiv.org/pdf/2404.07385v2>.
- [29] WEI Y X, LIU Q X, ZHANG G X, et al. Label smoothing technique for ordinal classification in cloud assessment[C/OL]//IEEE. IGARSS 2020-2020 IEEE international geoscience and remote sensing symposium. Waikoloa, HI, USA: IEEE, 2020. <https://ieeexplore.ieee.org/document/9323714>.
- [30] ATKINSON G, LI X M, METSIS V. Conditional diffusion with label smoothing for data synthesis from examples with noisy labels[C]//IEEE. 2023 31st european signal processing conference (EUSIPCO). Helsinki, Finland: IEEE, 2023: 1300-1304.
- [31] LIU R J, CUI B G, FANG X, et al. Super-resolution of GF-1 multispectral wide field of view images via a very deep residual coordinate attention network[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 5513305.
- [32] WANG E Y, SU R Z, HUANG B Y, et al. Enhancing YOLOv7-based fatigue driving detection through the integration of coordinate attention mechanism[C]//IEEE. 2023 IEEE international conference on image processing and computer applications. Changchun, China: IEEE, 2023: 725-729.
- [33] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design[C]//IEEE. 2021 IEEE/CVF conference on computer vision and pattern recognition. Nashville, TN, USA: IEEE, 2021. <https://arxiv.org/abs/2103.02907>.
- [34] KRSTINIC D, SERIC L, SLAPNICAR I. Comments on 'MLCM: Multi-Label confusion matrix'[J]. *IEEE Access*, 2023, 11: 40692-40697.
- [35] LARIOS G, NICOLODELLI G, RIBEIRO M, et al. Soybean seed vigor discrimination by using infrared spectroscopy and machine learning algorithms[J]. *Analytical Methods*, 2020, 12(35): 4303-4309.

(责任编辑:石春林)