

doi:10.6041/j.issn.1000-1298.2023.S2.028

# 基于 ECA – FV – CNN 的水稻单籽粒质量分级方法

陈孟燕<sup>1</sup> 王敏娟<sup>1</sup> 宋青峰<sup>2</sup> 朱新广<sup>2</sup> 李民赞<sup>1</sup> 郑立华<sup>1</sup>

(1. 中国农业大学智慧农业系统集成研究教育部重点实验室, 北京 100083;

2. 中国科学院植物分子遗传国家重点实验室, 上海 200032)

**摘要:**为解决传统水稻质量分级依靠人工分拣,工作量大、错误率高、分级标准不严格等问题,本文提出一种基于ECA改进的双流卷积神经网络模型对水稻单粒质量分级进行研究。首先,获取每组水稻单籽粒(本文以7颗水稻单籽粒为1组)正视和俯视图像,对于5种简单的监督模型(朴素贝叶斯、决策树、随机森林、最邻近结点算法、支持向量机)、基于遗传算法和投票机制优化的模型(GA – SVM)、集成模型(RF + GA – SVM),通过图像预处理轮廓检测分离出单籽粒图像,利用颜色矩、LBP(Local binary pattern)和Canny算子提取籽粒颜色、纹理和边缘特征,并采用PCA(Principal component analysis)降维后进行训练;而对于单流卷积神经网络模型、双流卷积神经网络模型(FV – CNN)以及本文提出并构建的基于ECA改进的双流卷积神经网络模型(EA – FV – CNN),则使用预处理后的图像进行训练。将上述多种模型进行对比分析,发现基于ECA改进的双流卷积神经网络模型性能最好,其在单粒质量三分级、四分级和五分级准确率分别达94.0%、92.3%和71.0%。实验结果表明,使用基于ECA改进的双流卷积神经网络模型能够提高水稻单粒质量的分级精度,弥补传统方法的不足,规范籽粒筛选分级标准。

**关键词:**水稻; 质量分级; 机器学习; ECA; 双流卷积神经网络

中图分类号: TP183 文献标识码: A 文章编号: 1000-1298(2023)S2-0235-09

## Method for Single Rice Grain Weight Grading Based on ECA – FV – CNN

CHEN Mengyan<sup>1</sup> WANG Minjuan<sup>1</sup> SONG Qingfeng<sup>2</sup> ZHU Xinguang<sup>2</sup> LI Minzan<sup>1</sup> ZHENG Lihua<sup>1</sup>

(1. Key Laboratory of Smart Agriculture Systems Integration, Ministry of Education, China Agricultural University, Beijing 100083, China

2. National Key Laboratory of Plant Molecular Genetics, Chinese Academy of Sciences, Shanghai 200032, China)

**Abstract:** Aiming to solve the problems that traditional grain weight classification depends on manual sorting, such as heavy workload, high error rate and lax classification standard, an improved two-stream convolutional neural network model was proposed based on ECA to classify rice by single grain weight. Firstly, images of each group of rice (a group consists seven single rice grains) were taken from two different perspectives: front view and top view. For five traditional supervised models (naive Bayes, decision tree, random forest, K-nearest neighbor, support vector machine), voting mechanism optimization based on genetic algorithm (GA) (GA – SVM) and integrated model (RF + GA – SVM), single grain images were separated through image preprocessing and contour detection. Color moment, local binary pattern (LBP) and Canny operator were used to extract grain color, texture and edge features. And then through principal component analysis (PCA), the principal features were extracted to train each model. For the constructed single-stream convolutional neural network model, two-stream convolutional neural network model (FV – CNN) and the improved two-stream convolutional neural network model were proposed based on ECA (ECA – FV – CNN), the pre-processed images were divided into training set, verification set and test set according to the ratio of 6:2:2, and data enhancement were carried out for each data set, and then the models were trained. By comparing and analyzing the above models, the traditional machine learning model, RF + GA – SVM, had the best effect, but its highest accuracy was only 72% when the single grain weight was set for three-graded. Experimental verification showed that the ECA – FV – CNN model proposed had the best performance, and its accuracy for the

收稿日期: 2023–07–28 修回日期: 2023–08–29

基金项目: 国家重点研发计划项目(2022YFD1900701)和国家自然科学基金项目(32201654)

作者简介: 陈孟燕(1999—),女,硕士生,主要从事计算机应用技术研究,E-mail: chenmy\_123@163.com

通信作者: 郑立华(1969—),女,教授,主要从事农业信息化研究,E-mail: zhenglh@cau.edu.cn

single grain weight classification of three-graded, four-graded and five-graded reached 94.0%, 92.3% and 71.0%, respectively. However, the accuracies of single-stream convolutional neural network model and FV - CNN model for single grain weight grading were 92.7%, 91.1%, 61.1% and 93.0%, 91.6%, 65.6%, respectively. The grading effect of FV - CNN model was better than that of single-stream convolutional neural network model in three experiments, which showed that the two-branch network training was better than that of single-branch rice single grain weight grading. The accuracy of ECA - FV - CNN model in three grading experiments was 16.2% higher than that of single-stream convolutional neural network model and 8.2% higher than that of FV - CNN model. The results showed that the introduction of ECA module was effective for rice single grain classification, and the improved two-stream convolutional neural network model based on ECA can improve the classification accuracy of rice single grain weight, and the classification of rice single grain weight can be achieved by using computer vision technology, making up for the shortcomings of traditional methods, and improving the classification standard of grain screening.

**Key words:** rice; grain weight classification; machine learning; ECA; two-stream convolution neural network

## 0 引言

粒质量作为水稻的重要性状之一,一定程度上影响着水稻单株产量、总产量以及稻米的品质<sup>[1]</sup>。国际水稻研究所(IRRI)研究认为,水稻单粒质量提高后水稻总产量可提高30%以上<sup>[2]</sup>,同时粒质量又是影响稻米品质的重要因素。因此,通过粒质量的分级筛选出品质较好的水稻单籽粒进行育种对水稻种植发展至关重要<sup>[3]</sup>。传统水稻粒质量分级依靠人工分拣,存在工作量大、错误率高、分级标准不严格等问题,急需更加自动化的分级方法。

机器视觉(Machine vision, MV)具有强大的信息捕获能力,机器学习(Machine learning, ML)则为数据挖掘提供了多种实用建模方法<sup>[4]</sup>。将两者结合应用到水稻单籽粒质量分级的研究中,可弥补传统分级依靠人工分拣的缺点。目前,基于机器视觉和机器学习的技术在农业领域应用日趋广泛<sup>[5-6]</sup>。陈进等<sup>[7]</sup>应用机器视觉技术在平均3.24 s内识别水稻破损籽粒F1值达84.74%,茎秆和细小枝梗杂质识别F1值分别达86.92%和85.07%;张思雨等<sup>[8]</sup>采用机器视觉和自适应神经网络对花生的品质进行检测;朱俊松<sup>[9]</sup>利用机器视觉和BP神经网络及SVM模型检测小麦外观品质;张洋<sup>[10]</sup>利用多种深度学习模型对水稻缺陷及千粒质量进行测量;安娟华<sup>[11]</sup>将GWO-SVM模型和线性回归模型用于小麦籽粒分级及千粒质量估算,对于航麦8805、金禾727和河农8613个小麦品种,分级模型的精度达到95.08%、93.44%和93.44%,估重模型的精度达到98.261%、98.232%和98.134%。以上研究为本文提供了方法上的参考,但由于上述模型研究对象非单籽粒,不能实现本文目标。

利用机器视觉的目识别和分类技术对于研究

单籽粒质量分级研究具有较好借鉴意义。PENG等<sup>[12]</sup>提出了一种基于机器视觉的油菜籽计数算法,FERNANDEZ-LOZANO等<sup>[13]</sup>提出了一种信号和非信号蛋白的分类算法,它们都较好地实现了研究目标,但由于特征差别明显,模型无需对原始图像进行特征提取。LI等<sup>[14]</sup>利用局部特征提取流和全局特征提取流对高光谱图像进行特征提取实现分类,LIU等<sup>[15]</sup>构建了一种双流卷积神经网络模型对人体动作进行判别,分为VMHI(VGG和MHI)和FMHI(Faster R-CNN和RGB帧)2个分支,该模型在KTH数据集、Weizmann数据集和UT-interaction数据集上获得的平均精度分别为98.83%、99.1%和99%。以上研究虽实现了较高精度的分类,但由于它们分类的图像类间差异较大,而水稻单籽粒图像类间差异小,将这些模型迁移到本研究后发现模型的精度大幅降低。

针对以上问题,本文提出一种基于ECA改进的双流卷积神经网络模型(ECA-FV-CNN),不再采用局部和全局特征分别提取策略<sup>[14]</sup>,舍弃空间流和时间流2个分支网络的概念<sup>[15]</sup>,而将获得的2个不同角度的图像作为2个分支网络的输入。ECA机制将2个分支网络的二维卷积经过1次一维卷积变换,增强有效特征信息,以最低的计算和参数开销获取最高的网络性能。对比其他模型分析本文模型的性能,并开发构建“一键式”水稻单籽粒质量分级系统进行单籽粒质量的自动分级。

## 1 材料与方法

### 1.1 数据采集

水稻单籽粒小,需采集的图像数据较多,进行单粒拍摄耗时长导致环境变量(如光照等)难以较好地控制,因此设计如图1所示水稻籽粒图像采集装

置。将采集籽粒正面图像的相机固定在放置籽粒台面的正前方, 距离台面 10 cm 处, 采集籽粒俯视图的相机固定在放置籽粒台面的正上方, 距离台面 30 cm 处, 仅对籽粒放置台面进行光照射。保持室内无其他光源及环境因素相对稳定的情况下, 将 7 颗水稻籽粒为 1 组以“一”字形排开分别拍摄其正视图和俯视图, 拍摄角度如图 2 所示。7 颗水稻籽粒为 1 组进行拍摄既可以保证采集图像的速度和图像品质, 对后续图像处理准确率的影响也较小, 若具有更加可控的图像采集环境和图像采集设备则可单次对任意多颗籽粒图像进行采集。

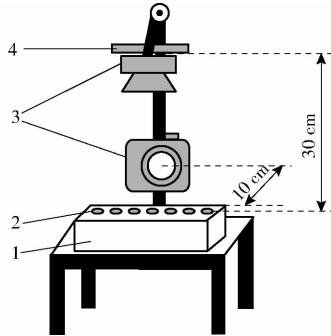


图 1 图像采集装置示意图

Fig. 1 Schematic of image acquisition device

1. 台面 2. 水稻籽粒 3. 相机 4. 光源

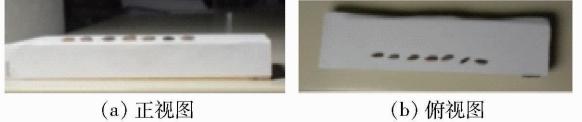


图 2 拍摄角度示意图

Fig. 2 Schematics of shooting angle

本文采集籽粒总数为 5 586 颗, 正视图和俯视图各拍摄 798 幅, 共 1 596 幅图像。图像采集后进行预处理, 按照采集顺序对每颗单籽粒称量, 对预处理分割出的每颗籽粒按质量区间划分不同的标签, 在保持类间平衡的基础上三分级质量区间为: [0, 0.019 0)、[0.019 0, 0.025 0)、(0.025 0, 0.050 1], 对应标签为 0、1、2; 四分级质量区间为: [0, 0.015 5)、[0.015 5, 0.022 0)、[0.022 0, 0.027 0)、[0.027 0, 0.050 1], 对应标签为 0、1、2、3; 五分级质量区间为: [0, 0.011 0)、[0.011 0, 0.021 0)、[0.021 0, 0.031 0)、[0.031 0, 0.041 0)、[0.041 0, 0.050 1], 对应标签为 0、1、2、3、4。

## 1.2 图像预处理

噪声对图像的分析处理有干扰<sup>[16]</sup>, 针对多种随机噪声, 本文依次选择均值、二维中值、高斯和双边滤波 4 次滤波有效滤除原始图像(图 3a)上的各类噪声(图 3b)。为解决图像对光照变化敏感性强、抗噪声能力弱等问题将彩色纹理图像映射到 HSV 颜

色空间(图 3c)。目标对象与背景的视觉分离使图像对比更加鲜明<sup>[17]</sup>, 本文选择大津法(Otsu)对图像进行背景分割(图 3d)。在拍摄时部分水稻籽粒间存在重叠, 导致分割受阻, 且上述操作后产生了其他干扰因素, 如图像孔洞、图像边缘缺失等, 针对这类现象本文对图像进行了腐蚀(Erosion)和膨胀(Dilation)的形态学处理<sup>[18]</sup>(图 3e)。上述预处理后通过轮廓检测分割单籽粒图像, 如图 3f 所示。得到的图像通过 Padding 边缘填充实现图像统一化, 如图 4 所示。

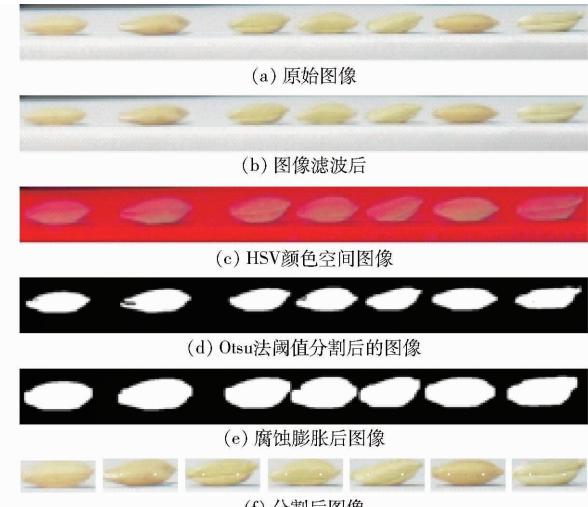


图 3 预处理图像

Fig. 3 Preprocessed images



图 4 图像 Padding 填充效果

Fig. 4 Image Padding filling effect diagram

经上述操作后获得由最小外接矩形切割出的单个籽粒图像, 将分割不完整的图像剔除, 最终筛选出单籽粒正视图和俯视图各 5 458 幅可用于模型训练并构成本研究的数据集, 正视图和俯视图一一对应, 共 5 458 组。

## 1.3 数据集构建

### 1.3.1 监督学习和集成学习模型数据集

筛选出的 5 458 组水稻单籽粒图像数据用于特征提取训练监督学习和集成学习模型, 将此 5 458 组图像数据按照比例 3:1 划分成训练集和测试集, 划分后正视图和俯视图仍保持一一对应, 划分后得到训练集图像 4 093 组, 测试集图像 1 365 组。

监督学习和集成学习模型的训练首先需要对特征进行提取, 颜色是人眼极易捕捉到的特征<sup>[19]</sup>, 采用颜色矩的前三阶矩从颜色的亮度、分布范围和对称度来描述图像的颜色特征。图像中每个像素点都具有 R、G、B 通道, 因此前三阶矩用 9 个分量来描

述,即最终水稻籽粒图像的颜色表现为一个9维颜色特征矩阵  $F_{color}$

$$F_{color} = [M_R \quad M_G \quad M_B \quad V_R \quad V_G \quad V_B \quad S_R \quad S_G \quad S_B] \quad (1)$$

式中  $M_i$ ——一阶矩  $V_i$ ——二阶矩  
 $S_i$ ——三阶矩

局部二值模式(Local binary patterns, LBP)是一种较强大的纹理特征提取方法,可灵活地作用在图像特定部位<sup>[20]</sup>。使用LBP算子对水稻籽粒图像的纹理特征进行处理,具体处理过程为

$$S(v) = \begin{cases} 0 & (a_i < c_j) \\ 1 & (a_i \geq c_j) \end{cases} \quad (i=1,2,\dots,8; j=1,2,\dots,N) \quad (2)$$

$$LBP(x_j, y_j) = \sum_{i=0}^{N-1} 2^i S(a_i - c_j) \quad (3)$$

式中  $N$ ——图像中像素点数

$S(v)$ ——符号函数

$(x_j, y_j)$ —— $3 \times 3$ 邻域的中心元素

$LBP(\cdot)$ ——中心像素点的LBP值

LBP获取纹理特征结果如图5所示。

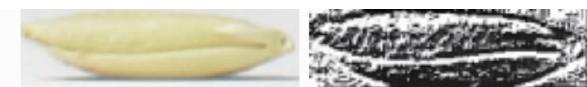


图5 纹理特征图

Fig. 5 Texture feature map

边缘特征的提取能够很好地将目标物体从背景中描绘识别出来<sup>[21]</sup>。在水稻籽粒图像处理中,通过提取边缘特征实现前景与背景分离,得到更加可信的数据集。采用Canny算子进行边缘检测,算法操作流程如图6所示。该方法易受噪声影响,需先进行高斯滤波,计算图像的x和y方向的偏导数  $G_x$  和  $G_y$ ,由此计算图像边缘的梯度(Edge\_Gradient( $g$ ))和角(Angle( $\theta$ )),具体计算为

$$\text{Edge\_Gradient}(g) = (G_x^2 + G_y^2)^{\frac{1}{2}} \quad (4)$$

$$\text{Angle}(\theta) = \arctan \frac{G_y}{G_x} \quad (5)$$

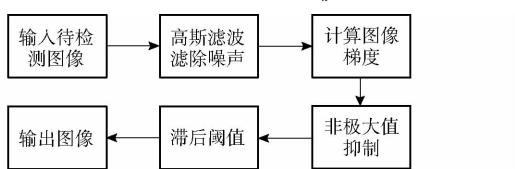


图6 Canny算子边缘检测流程图

Fig. 6 Canny operator edge detection flowchart

经过上述两步骤处理后扫描图像,在各个点的梯度方向上判断该点的剔留,若不存在比该点梯度大的点则保留该点,否则剔除,滞后阈值确定真正的边界点。边缘特征图如图7所示。



图7 边缘特征图

Fig. 7 Edge feature map

简单将上述颜色、边缘和纹理3种特征拼接得到的特征维度为1038,其中颜色特征维度为9,边缘和纹理特征的维度均为255,2个视角的3类特征进行拼接后得到1038种高维特征。计算的时空开销大且高维向量存在冗余分量,为精简数据,将特征降维。本文采用主成分分析(Principal component analysis,PCA)<sup>[22]</sup>进行降维,PCA通过线性变换将原始特征空间数据的主要成分映射到新的特征空间,找到原始特征空间数据中方差最大的方向,以原始数据中最主要的方面作为新的特征来代表原始数据。本文使用Python的机器学习库Sklearn来处理PCA,经过PCA处理后的降维数据保留167个重要特征,其他维度的信息被忽略,提取到的特征信息制作成二进制格式的NPY文件用于训练。

### 1.3.2 深度学习模型数据集

将筛选后的5458组图像按比例6:2:2划分为训练集、验证集和测试集,划分后正视图和俯视图保持一一对应,其中训练集图像共3275组。深度学习模型通常需要大量的数据作为支撑<sup>[23]</sup>,因此,将划分后的数据集通过添加椒盐噪声等进行数据增强以提高模型的泛化能力和精度,数据增强后的训练集图像为11962组。为高效加载模型训练需要的数据,将上述图像文件制作成NPY格式数据集用于单流卷积神经网络、双流卷积神经网络和基于ECA改进的双流卷积神经网络等模型的训练。

## 1.4 模型构建

### 1.4.1 监督学习和集成学习模型的构建

基于监督学习方法建立K最近邻(K-nearest neighbors,KNN)、随机数森林(Random forest,RF)、支持向量机(Support vector machine,SVM)、朴素贝叶斯(Naive Bayes,NB)和决策树(Decision tree,DT)模型,对于SVM模型训练后通过网格搜索算法和遗传算法(Genetic algorithm,GA)对模型中存在的超参数寻优构建优化的GA-SVM模型。

针对水稻单籽粒分类时类内方差大,类间方差小的特点,本文结合监督学习模型训练结果进行集成学习模型构建,将多个弱分类器组合起来进行分类决策,模型结构如图8所示。2个随机数不同的RF模型和GA-SVM模型作为基分类器进行集成,通过投票机制分别进行硬投票和软投票,本文称该模型为RF+GA-SVM模型。

### 1.4.2 深度学习模型的构建

ECA(Efficient channel attention)是一种高效的

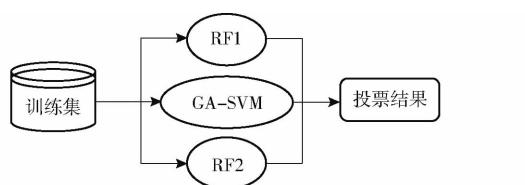


图 8 RF + GA - SVM 模型示意图

Fig. 8 Schematic of RF + GA - SVM model

通道注意力机制,其结构如图 9 所示。ECA 具有较低的计算和参数开销,却能达到较好的性能,其在每个通道上都通过一个自适应的加权平均操作来增强通道间的交互,调整不同通道的重要性使模型能够更有效地利用通道间的信息。ECA 舍弃了 SENet 中的全连接层,避免了降维带来的不利影响,直接在 GAP 之后的特征图上进行一维卷积,卷积核大小为  $K$ , $K$  是自适应的<sup>[24]</sup>,与输入通道维数  $C$  满足关系式

$$K = \Phi(C) = \left| \frac{\ln C}{\gamma} + \frac{b}{\gamma} \right|_{\text{odd}} \quad (6)$$

式中,参数  $b=1$ , $\gamma=2$ 。卷积后权重  $\omega$  满足

$$\omega = \sigma(C_{1D}(y)) \quad (7)$$

式中  $\sigma$ —Sigmoid 激活函数

$C_{1D}$ —一维卷积  $y$ —通道

该权重与原始特征图对应元素相乘得到不同权重下的特征图,强化重要特征,抑制无用特征。

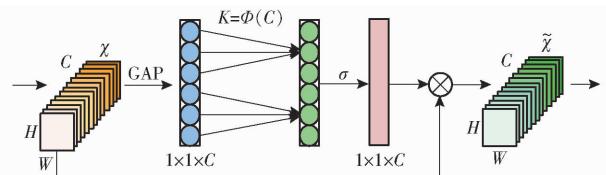


图 9 ECA 结构图

Fig. 9 ECA structure diagram

卷积神经网络 (Convolutional neural networks, CNN) 利用滤波器来提取输入图像的重要特征<sup>[25]</sup>。不断学习优化卷积层参数实现精准识别和预测<sup>[26]</sup>。

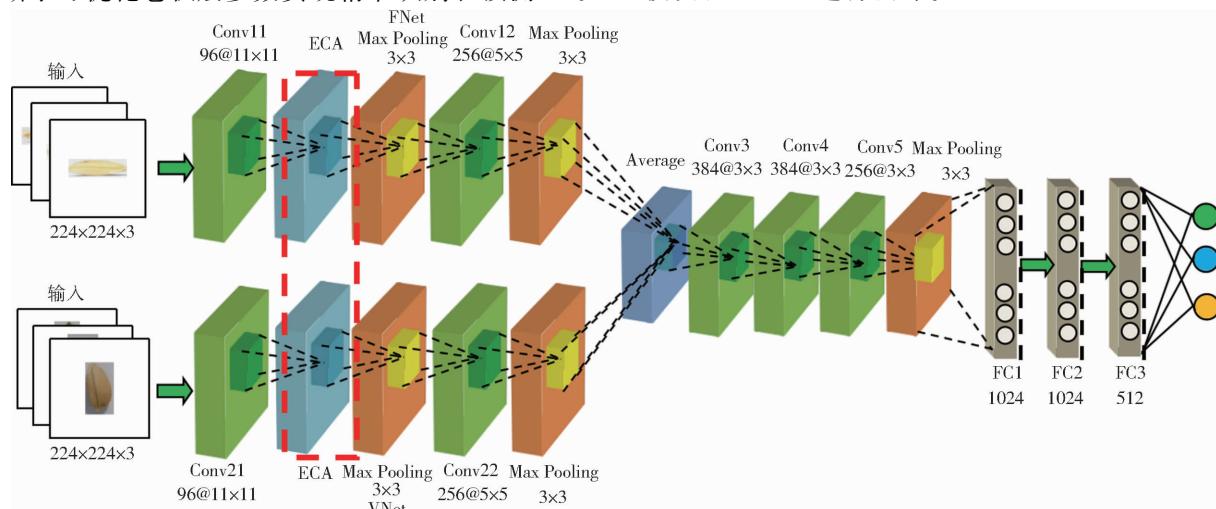


图 10 双流卷积神经网络模型结构图

Fig. 10 Structure diagram of two-stream convolutional neural network model

其一般包含卷积层 (Convolutional layer)、池化层 (Pooling layer) 和全连接层 (Fully connected layer)<sup>[27]</sup>。本文构建基于 ECA 改进的双流卷积神经网络模型 (ECA - front view vertical view - CNN, ECA - FV - CNN) 进行水稻单粒质量的三分级、四分级和五分级训练,将同一颗籽粒不同视角的图像以  $224 \times 224$  分别输入 2 个分支网络,网络总体结构如图 10 所示。2 个分支网络 FNet 和 VNet 对输入图像提取相同粒度的特征,因此将 2 个分支网络设置数量相同的卷积层且第 1 层卷积核都设为  $11 \times 11$  提取图像粗略的特征,其余层卷积核设置为  $5 \times 5$  来提取更加抽象的特征。采用 ReLU 激活函数增加模型的非线性,为保证模型的泛化能力和训练速度,在 2 分支网络融合之前的每次卷积后都进行归一化处理,在 2 个分支网络第 1 次卷积归一化后添加 ECA 模块,使模型更加关注重要特征信息。为防止模型过拟合,将 Dropout 与模型结合,在每个 epoch 中随机舍弃一定比例的神经元。2 分支网络汇成 1 个网络后继续进行卷积和池化,最后通过 Softmax 层输出预测概率。

为验证基于 ECA 改进后的双流卷积神经网络的性能,本文构建了除监督模型和集成模型外的单流卷积神经网络模型、双流卷积神经网络模型 (FV - CNN) 以及添加不同注意力机制的双流卷积神经网络模型,并保持这些模型与 ECA 改进的双流卷积神经网络模型的卷积层、池化层等网络结构的层数及顺序均一致。单流卷积神经网络结构如图 11 所示,双流卷积神经网络结构是图 10 中 ECA 改进的双流卷积神经网络去除红色虚线框后的部分。添加不同注意力机制的双流卷积神经网络模型是将图 10 中红色框内的 ECA 模块分别替换为 SE 模块和 CBAM 进行训练。

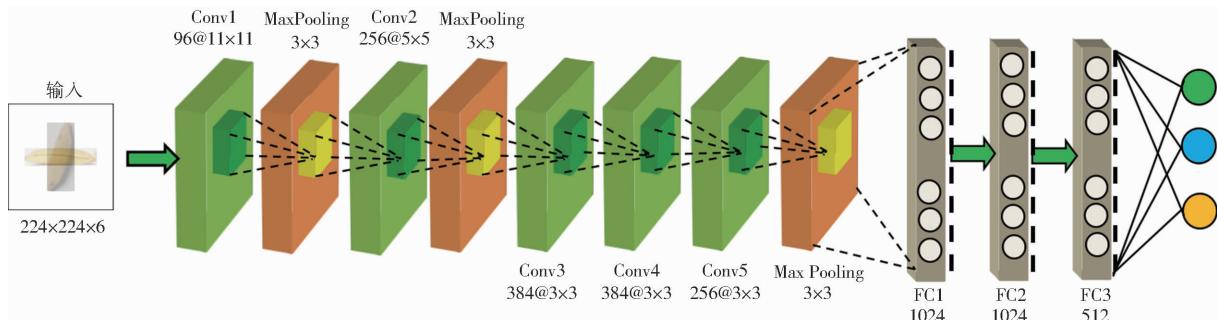


图 11 单流卷积神经网络模型结构图

Fig. 11 Structure diagram of single stream convolutional neural network model

## 1.5 系统设计搭建

为进一步应用本文方法,构建自动的“一键式”质量分级系统,结合训练好的模型和2个相机传感器,点击按钮触发后,系统自动通过2个相机传感器分别拍摄水稻籽粒的正视图和俯视图,将2个角度的图像传入计算机系统同时进行图像预处

理,预处理的图像输入到经过训练并且效果最好的模型中进行质量的分级并且输出分级结果,系统搭建示意图如图12所示。该系统只需要将水稻籽粒放置于拍摄台上并进行点击后即可得到水稻籽粒质量分级结果,可实现水稻籽粒的简单快速分级。

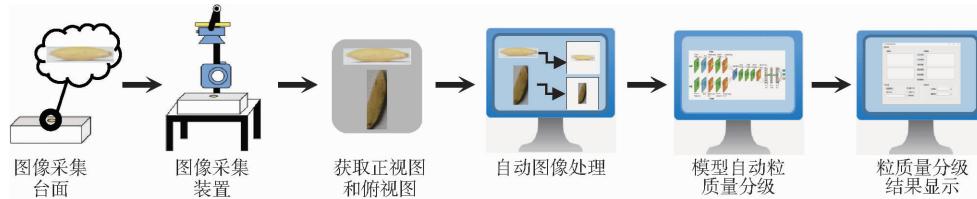


图 12 质量分级系统搭建示意图

Fig. 12 Schematic of grain weight classification system

## 2 结果与分析

### 2.1 监督学习和集成学习模型训练与结果

对构建的NB、DT、KNN、RF、SVM模型进行训练。在对SVM模型优化时将其预测值与实际值之间的均方误差作为遗传算法的适应度,经生存选择参数C和 $\sigma$ 得以优化,构建GA-SVM模型。模型的训练结果如表1所示,由结果可知RF模型对粒质量三分级的效果最好,但测试集准确率也仅达67%,GA-SVM模型与未优化的SVM模型相比,其测试集准确率达67%,提升6.3%,其他评估指标也有较大提升。

表 1 基于监督学习的模型训练结果

Tab. 1 Training results of model based on supervised learning

模型	supervised learning			% %	
	TeA	TrA	精确率	召回率	F1值
NB	49.0	53.0	50.0	51.0	49.0
DT	55.0	58.0	55.0	55.0	55.0
KNN	60.0	66.0	60.0	61.0	60.0
RF	67.0	66.0	68.0	67.0	67.0
SVM	63.0	66.0	64.0	63.0	63.0
GA-SVM	67.0	66.0	68.0	68.0	68.0

注:TeA为测试集准确率,TrA为验证集准确率,下同。

示。软投票时RF+GA-SVM模型测试集准确率达72%,较GA-SVM模型准确率提升7.46%,硬投票时测试集准确率达70%,较GA-SVM模型准确率提升4.47%。

表 2 基于集成学习的模型训练结果

Tab. 2 Training results of model based on ensemble learning

类型	TeA	TrA	精确率	召回率	F1值	%
软投票	72.0	98.0	71.0	72.0	72.0	
硬投票	70.0	98.0	69.0	70.0	70.0	

### 2.2 深度学习模型训练及结果

单流卷积神经网络、双流卷积神经网络、添加不同注意力机制的双流卷积神经网络以及基于ECA改进的双流卷积神经网络模型(ECA-FV-CNN)均基于Tensorflow框架进行训练,学习率和训练轮数等均设置相同的数值。未改进的和改进后的双流卷积神经网络模型训练时均分别选用3种融合位置不同的双流网络(卷积层融合、全连接层融合、Softmax层之后融合)对籽粒图像的两类视图进行训练,结果表明卷积层融合分级效果最好。单流网络、双流网络、添加不同注意力机制的双流网络以及改进的双流卷积神经网络模型的训练结果如表3所示。

集成模型(RF+GA-SVM)训练结果如表2所示

表 3 深度学习模型的训练结果

模型	分级	TeA	准确率	召回率	F1 值	损失率
单流卷积神经 网络	三分级	92.7	92.6	92.9	92.7	47.5
	四分级	91.1	91.3	90.8	91.0	64.2
	五分级	61.1	43.0	74.8	63.6	84.6
FV - CNN	三分级	93.0	93.2	93.2	93.0	45.7
	四分级	91.6	91.9	91.5	91.6	54.2
	五分级	65.6	45.9	78.0	67.8	76.6
FV - CNN + CBAM	三分级	91.4	91.8	91.4	91.4	44.2
	四分级	90.0	90.0	89.5	89.5	46.9
	五分级	62.5	43.4	77.3	62.5	85.1
FV - CNN + SE	三分级	92.9	93.2	93.0	92.9	44.2
	四分级	91.7	92.2	91.4	91.7	51.9
	五分级	62.2	51.0	79.0	64.9	84.0
ECA - FV - CNN	三分级	94.0	93.8	93.9	93.8	41.0
	四分级	92.3	92.6	92.1	92.2	48.1
	五分级	71.0	51.0	82.1	72.0	72.5

对比单流卷积神经网络模型和双流卷积神经网络模型的结果, 双流卷积神经网络模型在质量三分级、四分级及五分级上的准确率较单流卷积神经网络模型最大提高 7.3%, 召回率最大提高 4.3%, ECA 改进的双流卷积神经网络模型较未改进的双

流卷积神经网络模型在粒质量三分级、四分级和五分级的准确率最大提升 8.2%, 召回率最大提高 5.3%, 较单流卷积神经网络准确率最大提高 16.2%, 召回率最大提高 9.8%。使用 SE 和 CBAM 分别替换 ECA 进行网络训练, 只有在质量四分级时, 添加 SE 模块的网络较未改进的网络有极微提升, 仅为 0.1%, 其他结果相比于添加 ECA 模块的网络结果并没有明显提升。分析原因, SE 模块和 CBAM 模块的引入会增加模型的计算量和复杂度, 因而增加模型的训练难度, 同时, SE 模块和 CBAM 模块需要设置部分超参数, 如缩小比例等, 超参数的设置不同可能会导致模型的性能升高或者降低, 而 ECA 模块根据模型的通道维度来自定义卷积核进行更有效特征的学习, 避免调参的同时引入极少的参数量。实验表明, 将双流卷积神经网络模型的 2 个分支网络进行第 1 次卷积后的特征图输入 ECA 模块, 经过 ECA 不降维的 GAP 后, 聚合卷积特征进行一维卷积跨通道交互学习对单籽粒分级是有效的。

ECA - FV - CNN 模型在水稻单粒质量三分级、四分级、五分级混淆矩阵如图 13 所示。

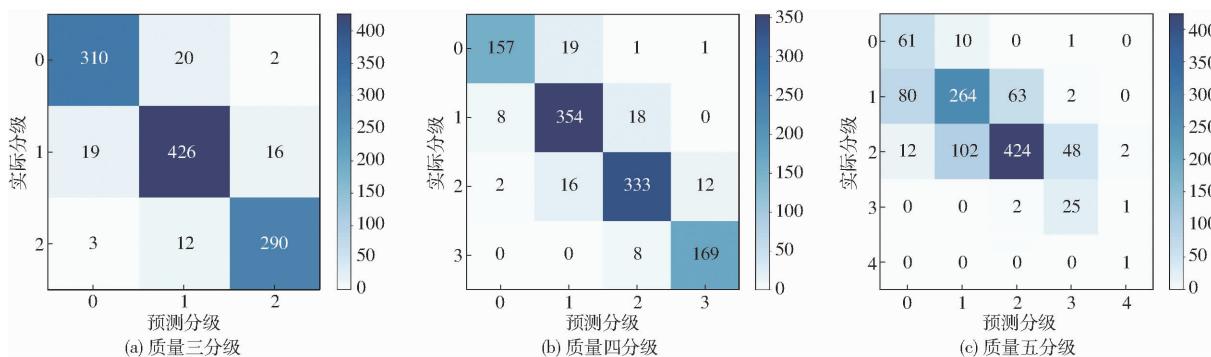


图 13 单粒质量不同分级时的混淆矩阵

Fig. 13 Confusion matrix for different classification of grain weights

图 13 中混淆矩阵对角线的值表示正确划分的籽粒数, 非对角线的值表示错误划分的籽粒数, 能够明显看出三分级和四分级时有少量籽粒分类不正确, 落在非对角线上, 但错误划分的籽粒数较小, 仅为 6% 和 7.7%。五分级时效果较差, 颜色分布较为分散, 落在第 5 个区间的籽粒数较少。

对模型进行 3 种分级策略时的精度和损失进行分析, 准确率和损失值随着迭代次数增长的变化如图 14、15 所示。

图 14 和图 15 中, 模型进行不同分级训练时均迭代 150 次。在模型训练的前 30 个轮次设置学习率为 0.005, 使模型以较快速度收敛, 各项指标在前 30 个轮次内变化较快, 在 30~50 个轮次和 50~80 个轮次内学习率分别设为 0.001 和 0.0005, 80~

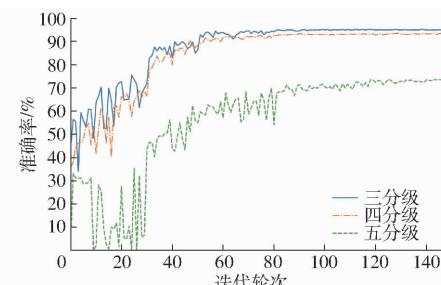


图 14 准确率变化曲线

Fig. 14 Accuracy index change chart

150 个轮次内学习率设为 0.0001, 使学习率逐渐减小, 提高模型准确性和泛化性能。在对单籽粒质量进行三分级和四分级时, 模型在迭代 100 个轮次后各项指标均不再有明显变化, 准确率稳定在 94% 和 92% 上下, 损失值为 0.41 和 0.48。对于单籽粒粒

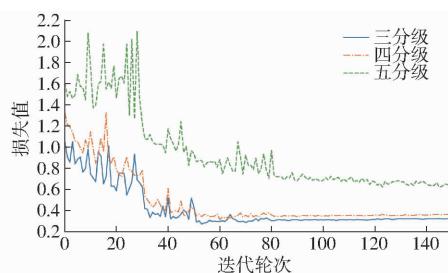


图 15 损失值变化曲线

Fig. 15 Loss index change chart

质量的五分级实验,在进行了 120 个轮次之后,模型各项指标趋于稳定,最终准确率稳定在 71% 上下。

分析五分级模型训练精度低的原因,主要在于数据分布不均匀,采集的质量数据大致呈现正态分布,中等质量籽粒较集中,质量较大的籽粒较少,及时进行数据增强后也存在不均匀现象。其次,在数据采集方面,由于实验条件限制未能使用性能较好的图像采集设备,图像噪声较多,造成图像质量降低,后续构建的模型的精度难以提升。最后,模型还待优化,需尝试更多的优化算法。

### 3 结论

(1) 对监督模型进行集成可在一定程度上提高

### 参 考 文 献

- [1] 杜成兴. 水稻粒形粒重的 QTL 定位 [D]. 北京:中国农业科学院, 2021.  
DU Chengxing. Mapping of QTL for grain shape and grain weight in rice [D]. Beijing: Chinese Academy of Agricultural Sciences, 2021. (in Chinese)
- [2] 彭丁文. 水稻粒重遗传与育种研究进展 [J]. 南方农业学报, 2011, 42(3): 250–252.  
PENG Dingwen. Research progress on the utilization of rice grain weight traits in molecular breeding [J]. Journal of South China Agriculture, 2011, 42(3): 250–252. (in Chinese)
- [3] 武威. 基于机器视觉技术的稻麦籽粒外观品质评测研究 [D]. 扬州:扬州大学, 2021.  
WU Wei. Research on appearance quality evaluation of rice and wheat grains based on machine vision technology [D]. Yangzhou: Yangzhou University, 2021. (in Chinese)
- [4] 杨晓静, 张福东, 胡长斌. 机器学习综述 [J]. 科技经济市场, 2021(10): 40–42.
- [5] 周宝仓, 吕金龙, 肖铁忠, 等. 机器视觉技术研究现状及发展趋势 [J]. 河南科技, 2021, 40(31): 18–20.  
ZHOU Baocang, LÜ Jinlong, XIAO Tiezhong, et al. Research status and development trend of machine vision technology [J]. Henan Science and Technology, 2021, 40(31): 18–20. (in Chinese)
- [6] 杨涛, 李晓晓. 机器视觉技术在现代农业生产中的研究进展 [J]. 中国农机化学报, 2021, 42(3): 171–181.  
YANG Tao, LI Xiaoxiao. Research progress of machine vision technology in modern agricultural production [J]. China Journal of Agricultural Chemistry, 2021, 42(3): 171–181. (in Chinese)
- [7] 陈进, 顾琰, 练毅, 等. 基于机器视觉的水稻杂质及破碎籽粒在线识别方法 [J]. 农业工程学报, 2018, 34(13): 187–194.  
CHEN Jin, GU Yan, LIAN Yi, et al. Online recognition method of impurities and broken paddy grains based on machine vision [J]. Transactions of the CSAE, 2018, 34(13): 187–194. (in Chinese)
- [8] 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)
- [9] 朱俊松. 基于机器视觉的小麦外观品质检测技术研究 [D]. 镇江:江苏大学, 2021.  
ZHU Junsong. Study on wheat appearance quality inspection based on machine vision [D]. Zhenjiang: Jiangsu University, 2021. (in Chinese)
- [10] 张洋. 基于深度学习的水稻种粒缺陷识别及重叠分布千粒重测量研究 [D]. 扬州:扬州大学, 2021.  
ZHANG Yang. Research on rice seeds defect recognition and thousand kernel weight measurement of overlapping distribution

模型的准确率。基于提取的籽粒的颜色、边缘和纹理特征构建多种模型,其中 RF + GA – SVM 集成模型的水稻单籽粒质量三分级的准确率可达到 72%。

(2) 双流卷积神经网络模型 (FV – CNN) 较单流卷积神经网络模型性能更好。FV – CNN 学习能力更强,对水稻单粒重分级更加准确,在水稻单粒质量三分级、四分级和五分级准确率较单流卷积神经网络模型最大提高 7.3%,召回率最大提高 4.3%。

(3) 基于 ECA 改进的双流卷积神经网络模型 (ECA – FV – CNN) 关注更加有效的特征信息,ECA 模块在不增加模型复杂度的同时有效提升模型的准确性,其质量三分级和四分级准确率最高达 94.0% 和 92.3%,在五分级上较未改进的双流卷积神经网络准确率和召回率分别提升 8.2% 和 5.3%,该模型较好地实现了端到端的水稻单籽粒质量分级。

(4) 基于 ECA – FV – CNN 模型开发水稻单籽粒质量分级系统,系统将模型与相机传感器结合,相机自动拍照并传入计算机系统进行相应图像处理后实现质量分级,可实现水稻单籽粒质量的简单快速分级。

- based on deep learning[D]. Yangzhou: Yangzhou University, 2021. (in Chinese)
- [11] 安娟华. 基于图像处理的小麦籽粒分级及千粒重估算研究[D]. 保定:河北农业大学, 2021.  
AN Juanhua. Research on grading of wheat grain quality and thousand grain weight based on image processing[D]. Baoding: Hebei Agricultural University, 2021. (in Chinese)
- [12] PENG Shunzheng, ZHAO Zeying, WU Xiaobo, et al. Research on rapeseed counting based on machine vision[J]. Journal of Physics: Conference Series, 2021, 1757(1):012028.
- [13] FERNANDEZ-LOZANO C, CUINAS R F, SEOANE J A, et al. Classification of signaling proteins based on molecular star graph descriptors using machine learning models[J]. Journal of Theoretical Biology, 2015, 384: 50–58.
- [14] LI X, DING M, PIURICA A. Deep feature fusion via two-stream convolutional neural network for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(4):2615–2629.
- [15] LIU C, YING J, YANG H, et al. Improved human action recognition approach based on two-stream convolutional neural network model[J]. The Visual Computer, 2021, 37(6):1327–1341.
- [16] WAN Y, YU Z, WANG Y, et al. Action recognition based on two-stream convolutional networks with long-short-term spatiotemporal features[J]. IEEE Access, 2020, 8: 85284–85293.
- [17] SHI J, MALIK J. Normalized cuts and image segmentation[J]. IEEE Trans. Pattern Anal. Mach. Intell., 2000, 22(8): 888–905.
- [18] 汤红忠, 黄辉先, 郭雪峰, 等. 新型彩色图像形态学处理方法[J]. 计算机应用, 2010, 30(8): 2101–2104.  
TANG Hongzhong, HUANG Huixian, GUO Xuefeng, et al. New method of morphological color image processing[J]. Computer Applications, 2010, 30(8): 2101–2104. (in Chinese)
- [19] TIGISTU T, ABEBE G. Classification of rose flowers based on Fourier descriptors and color moments[J]. Multimedia Tools and Applications, 2021, 80(30): 36143–36157.
- [20] ALPASLAN N. Neutrosophic set based local binary pattern for texture classification[J]. Expert Systems With Applications, 2022, 209: 118350.
- [21] LIU Y, REN L, CAO X, et al. Breast tumors recognition based on edge feature extraction using support vector machine[J]. Biomedical Signal Processing and Control, 2020, 58: 101825.
- [22] MAĆKIEWICZ A, RATAJCZAK W. Principal components analysis (PCA)[J]. Computers & Geosciences, 1993, 19(3): 303–342.
- [23] 席欢欢. 基于卷积神经网络的医学图像分割方法研究[D]. 贵阳:贵州大学, 2021.
- [24] WANG Q, WU B, ZHU P, et al. ECA - Net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020;11534–11542.
- [25] 潘熙文. 基于卷积神经网络的肿瘤医学图像分割和检测方法研究[D]. 北京:北京邮电大学, 2021.  
PAN Xiwen. Study on segmentation and detection method of tumor medical images based on CNN [D]. Beijing: Beijing University of Posts and Telecommunications, 2021. (in Chinese)
- [26] HAO Zhenbang, LIN Lili, POST C J, et al. Automated tree-crown and height detection in a young forest plantation using mask region-based convolutional neural network (Mask R - CNN)[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 178: 112–123.
- [27] 杨波, 梁伟. 深度神经网络模型构建及优化策略[J]. 计算机时代, 2022(1): 8–13, 18.  
YANG Bo, LIANG Wei. Model construction and optimization strategies of deep neural networks[J]. Computer Age, 2022(1): 8–13, 18. (in Chinese)