

DOI: 10.13718/j.cnki.xdzk.2025.01.018

冯川, 祝诗平, 黄华, 等. 基于深度学习的高效率烤烟等级识别模型研究 [J]. 西南大学学报(自然科学版), 2025, 47(1): 213-225.

基于深度学习的高效率烤烟等级识别模型研究

冯川¹, 祝诗平¹, 黄华¹, 严森垚¹, 于丽敏²

1. 西南大学 工程技术学院, 重庆 400715; 2. 山东农业工程学院 信息科学与工程学院, 济南 250110

摘要: 烤烟的等级识别是烟草产业的一个关键环节, 为了降低烟农烤烟分级劳动强度, 减少主观因素, 提高识别精度, 需要实现烤烟的自动分级。研究了深度学习中多种卷积神经网络的多层特征提取方法, 并基于 ShuffleNetV2 网络提出一种改进的网络模型(ShuffleNetV2_FTC)。ShuffleNetV2_FTC 网络是将 ShuffleNetV2 网络的主干单元进行更改, 并引入 CBAM(Convolutional Block Attention Module)注意力机制和 SiLU 激活函数。应用该模型对 27 种类别的烤烟图像进行识别分类。该模型的最佳测试准确率为 93.09%, 检测帧率达到每秒 15.3 张。相对原模型获得了 0.24%(0.5×)、6.06%(1×)和 4.73%(1.5×)的准确率提升, 每秒检测 12.3 张图片到 15.3 张图片的检测帧率提升。ShuffleNetV2_FTC 网络结合机器视觉技术可以很好地识别烤烟等级, 为优化烤烟的收购、烘干和加工等流程奠定基础。

关键词: 烤烟等级; 图像处理; 机器视觉; 深度学习;

ShuffleNetV2 网络

中图分类号: TP183

文献标志码: A

开放科学(资源服务)标识码(OSID):



文章编号: 1673-9868(2025)01-0213-13

Research on High Efficiency Flue-cured Tobacco Grade Identification Model Based on Deep Learning

FENG Chuan¹, ZHU Shiping¹, HUANG Hua¹,
YAN Senyao¹, YU Limin²

1. College of Engineering and Technology, Southwest University, Chongqing 400715, China;

2. School of Information Science and Engineering, Shandong Agriculture and Engineering University, Jinan 250110, China

Abstract: The grade identification of flue-cured tobacco is a crucial step in the tobacco industry. In order to reduce the labor intensity of tobacco farmers in grading flue-cured tobacco, minimize subjective factors,

收稿日期: 2024-01-17

基金项目: 教育部中国高校产学研创新基金—德州专项(2021DZ005); 中国烟草总公司云南省公司科技计划项目(2021530000241036)。

作者简介: 冯川, 硕士研究生, 主要从事机器视觉在农业中的应用研究。

通信作者: 祝诗平, 博士, 教授, 博士研究生导师。

and enhance identification accuracy, it is necessary to achieve the automatic grading of flue-cured tobacco. This article investigated multiple methods of multi-layer feature extraction using various convolutional neural networks in deep learning. Based on ShuffleNetV2, an improved model (ShuffleNetV2_FTC) was proposed. The ShuffleNetV2_FTC modified the backbone units of ShuffleNetV2 and incorporated the CBAM (Convolutional Block Attention Module) attention mechanism and SiLU activation function. This model was applied to the identification and classification of 27 categories of flue-cured tobacco images. The testing accuracy of this model reached 93.2%, and the detection frame rate achieved 15.3 frames per second. Compared to the original model, there was an improvement of 0.24% ($0.5\times$), 6.06% ($1\times$) and 4.73% ($1.5\times$) in accuracy, as well as an increase in the detection frame rate from 12.3 frames per second to 15.3 frames per second. The ShuffleNetV2_FTC, combined with machine vision technology, can effectively identify the grades of flue-cured tobacco, laying the foundation for optimizing the procurement, drying and processing processes of flue-cured tobacco.

Key words: flue-cured tobacco grade; image processing; machine vision; deep learning; ShuffleNetV2

烤烟等级识别在烤烟生产和贸易中具有重要意义。烤烟是用于制造烟草制品(如香烟、雪茄)的原材料,其质量和特性直接影响最终产品的口感、气味和吸引力。在现行的国家标准《烤烟》(GB 2635—1992)^[1]中,根据部位、颜色和级别将烤烟分为 3 等 42 级。烤烟等级识别是对烤烟质量的评估,通常基于烤烟的外观、颜色、大小、形状、叶片均匀性以及烟叶中的糖分、尼古丁和其他化学成分等因素^[2],而识别的准确性直接影响分拣与分类的精度和效率以及价格的确定。

烤烟等级识别作为烟草产业的关键环节,吸引了大量研究者的兴趣。在过去几十年里,研究者们通过 3 种不同的方法和技术^[3],探索了烤烟等级识别精度的影响因素。① 基于化学成分分析^[4-5]。研究者们通过色谱分析、质谱技术等手段,研究烟叶中的糖分、尼古丁、挥发性化合物等成分的含量和变化规律。这些研究揭示了不同等级烤烟之间的化学成分差异,为合理分级提供了科学依据。② 基于数据挖掘和模式识别^[6]等现代信息技术。研究者们利用大数据分析、机器学习和人工智能技术^[7],从大量的烤烟数据中挖掘出有关烤烟等级的隐藏规律。③ 基于外观特性分析^[8-9]。研究者们利用计算机视觉技术、图像分析和机器学习算法,检测叶片颜色、纹理、大小和完整性等特征,从而快速、准确地判断烤烟的等级。总之,这些方法不仅提高了烤烟等级识别的准确性,还为决策制定和质量控制提供了科学支持^[3,10-11]。

在近 10 年的研究中,李海杰^[12]构建了 5 层人工神经网络(ANN)对 7 种等级烤烟进行分类分级方法研究,验证准确率为 80%;曾祥云^[13]采用 AlexNet 卷积神经网络构建了烤烟质量分类模型,5 种等级验证准确率为 78%;随着可分离卷积理论的提出,王士鑫等^[14]采用 Inception V3 卷积神经网络并运用迁移学习方法构建分类模型,12 种等级下的验证准确率为 95.23%;陈鹏羽等^[15]使用特征融合方法改进 WSDAN 网络得到 5 种等级验证准确率为 91.261%;Swasono 等^[16]将 ResNet 模型进行剪枝然后添加额外降维层构建模型,4 类烟草病害的验证准确率为 99.3%。虽然以上研究使该领域得到工业应用成为可能,但仍然存在 2 个主要局限。① 识别分类的种类较少。烤烟总共有 42 个等级,而之前算法最高识别种类仅有 12 类。② 算法冗余度较高。烤烟等级识别应用是流水线作业,需要算法识别快、准确率高,高冗余度的算法意味着高延迟,因此难以应用。据研究,之前算法局限的原因在于它们对烤烟图像的深层特征提取不足^[17],因此为了实现烤烟自动分级的工业应用,增强算法深层特征提取能力是解决问题的关键。

近年来,ShuffleNet 系列网络因其具有高轻量化特点和较强的深层特征提取能力,受到研究者们广泛

关注^[18], 目前已在多项基于农产品分类的项目中得到应用^[19-20]。而对于烤烟识别领域所面临的问题, 运用 ShuffleNet 系列网络可以有效解决。本研究基于该领域所面临的问题, 结合深度学习技术, 采用分类算法中的 ShuffleNetV2 网络实现烤烟等级分类, 并结合实际图像特征进一步改进算法, 最终提升了该算法在该领域的检测性能, 为实现烤烟自动分级从而提高烤烟收购效率和卷烟生产质量提供了一种新方法。

1 材料与方方法

1.1 材料与仪器

试验使用 iPhone 11 手机相机(分辨率为 $3\ 024 \times 4\ 032$)采集山东、云南等烟草园区的烤烟图像样本。光源信息: 电压 AC 110~265 V, 功率 15 W, 色温正白, 长度 0.9 m。图像样本采集方法和设备如图 1 所示, 共采集 32 个等级 7 055 张图片。




图 1 烤烟图像样本采集方法

机器视觉识别系统主要由硬件和软件 2 部分组成^[21], 其中烤烟图像数据采集一般是由灯源、相机和桌面(模拟传送带)组成^[2,4,9,13,22,23]。苏明秋^[22]改进为桌面铺上吸光布, 目的是让烟叶叶身纹路充分展现; 鲁梦瑶等^[17]改进光源为面光源, 目的是让烟叶叶身均匀受光。如图 2 所示, 本研究试验的烤烟图像采集方法在之前研究的基础上增加了吸光布和反光纸, 使烤烟图像的色彩、纹理和轮廓更容易被捕捉; 仅在传送带上时, 烟叶叶身暗淡, 纹路模糊; 仅有吸光布时, 曝光过度失去颜色信息, 但纹理信息显示较好; 仅有白色背景时, 反光过度曝光不足, 导致叶身暗淡, 缺少光泽。




图 2 不同烤烟图像采集方法比较

1.2 数据划分及预处理

根据样本数量, 试验图像从目前收集的 32 个等级中选用 27 种类别构建数据集, 其他 5 种类别数据因数量太少故没有引入试验。为了数据的均衡性, 将数据删减或增强后按约 6 : 2 : 2 的比例划分为训练集样

本 2 430 张, 验证集样本 822 张, 测试集样本 822 张。具体分类情况如表 1 所示。

表 1 烤烟图像样本

烤烟类别	训练集	验证集	测试集	总计
B1F	90	30	30	150
B1K	90	32	32	154
B2F	90	30	30	150
B2K	90	30	30	150
B2L	90	30	30	150
B2V	90	30	30	150
B3F	90	30	30	150
B3L	90	30	30	150
B3V	90	30	30	150
B4F	90	30	30	150
B4L	90	32	32	154
BR	90	32	32	154
C1F	90	32	32	154
C2F	90	30	30	150
C2L	90	30	30	150
C3F	90	30	30	150
C3L	90	30	30	150
C3V	90	32	32	154
C4F	90	30	30	150
C4L	90	31	31	152
CX1K	90	30	30	150
GY	90	30	30	150
X2F	90	30	30	150
X2L	90	31	31	152
X3F	90	30	30	150
X3L	90	30	30	150
X4F	90	30	30	150
总计	2 430	822	822	4 074

1.3 烤烟识别模型构建

1.3.1 ShuffleNetV2 网络

ShuffleNetV2 整体的网络架构如图 3 所示, 主要由输入层、循环层和输出层组成^[24]。输入层对图像进行预处理, 得到 $224 \times 224 \times 3$ 大小的 RGB 图像, 然后经过 1 个 CBR3 模块 (3×3 Conv+BN+ReLU) 和 1 个 MP3 模块 (3×3 MaxPool) 后, 得到 $56 \times 56 \times 24$ 的特征矩阵, 输入到循环层中。循环层由阶段 2、阶段 3 和阶段 4 共 3 个循环结构组成, 其中包含了通道裁剪(Channel Split)、若干 CBR1 模块 (1×1 Conv+BN+ReLU)、DWB3 模块 (3×3 DWConv+BN)、通道直连(Concatenation)和通道洗牌(Channel Shuffle)等结构。“通道裁剪”和“通道直连”分别是将 2 个特征矩阵按通道维度直接剪切或

连接起来;“通道洗牌”是将特征矩阵按通道维度进行打乱。输出层由 1 个 CBR1 模块、1 个 GP7 模块 (7×7 GlobalPool) 和全连接层 (FC) 组成, 最后输出为一个 $k \times 1$ 大小的一维向量序列, 其中 k 表示分类数。图 3 中 R 表示循环次数, S 表示卷积操作步距。

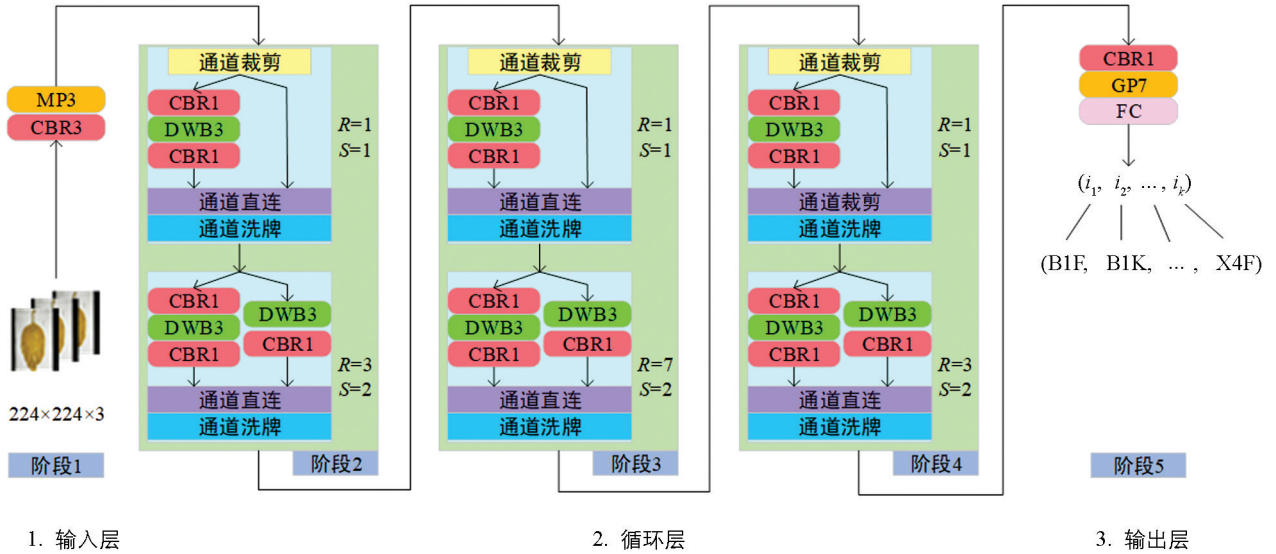


图 3 ShuffleNetV2 网络整体框架

1.3.2 改进 ShuffleNetV2 网络

为了提高网络性能, 本研究引入 CBAM 注意力机制^[25] 和 SiLU 激活函数^[26], 并基于 ShuffleNetV2 网络提出了 ShuffleNetV2_FTC(Flue-cured Tobacco Classification, FTC)网络模型。主要改进工作为: ① 在循环层中, 将卷积注意力机制(CBAM)嵌入阶段 3 和阶段 4 的循环结构中; ② 将网络所有激活函数由原来的 ReLU 改为 SiLU^[27]; ③ 在循环层中, 将阶段 3 和阶段 4 循环结构中的前 2 个模块(CBS1: 1×1 Conv+BN+SiLU 和 DWB3)合并为 1 个模块(CBS3: 3×3 Conv+BN+SiLU)。改进后的网络主干单元层结构如图 4 所示。

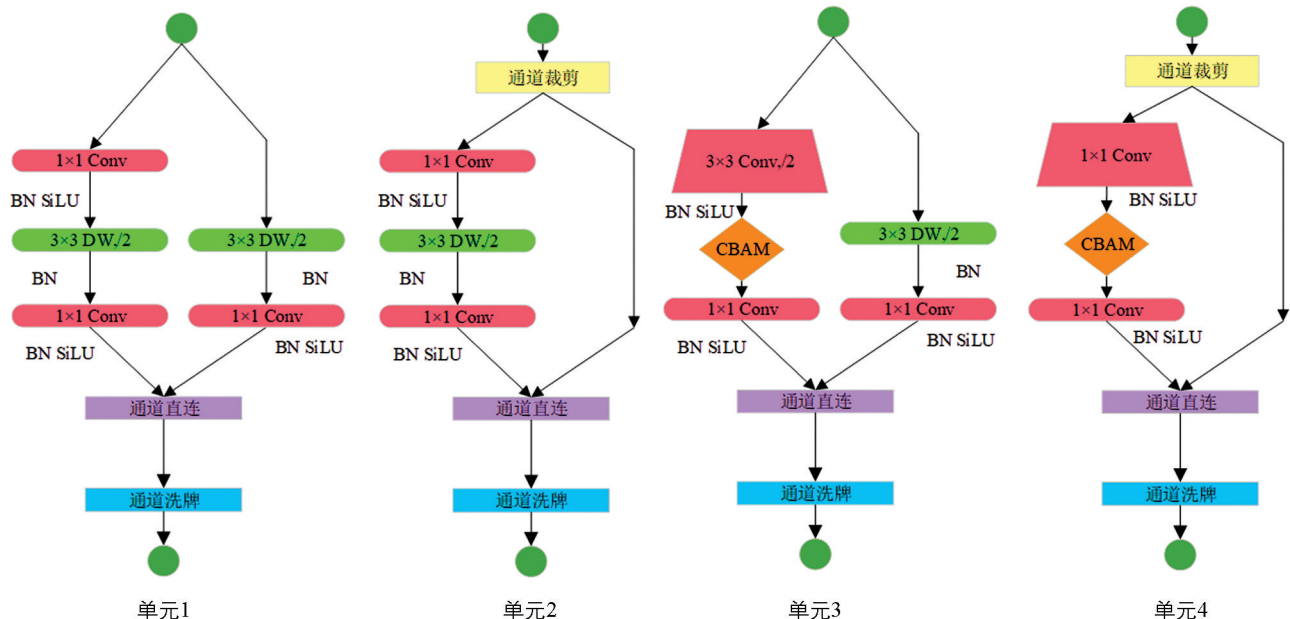


图 4 ShuffleNetV2_FTC 网络主干单元

这种修改方式的灵感来自于 Tan 等^[28] 的工作, 他们在 EfficientNet 系列网络中使用 SE 注意力机制, 并在每层卷积输入前扩充了中间特征图通道数, 而本研究使用的是 CBAM 注意力机制, 没有扩充通道数。

注意力机制嵌入位置的选择参考了 Howard 等^[29]的工作,他们提出了 MobileNet 系列网络。研究表明,在浅层尽量不要使用注意力机制,并且不同深度层使用不同的激活函数。例如 MobileNetV3_S 中,浅层更多使用的是 ReLU,深层更多使用的是 H-Swish,但在本研究提出的网络中应用时会导致准确率降低,故没有采用。

CBAM 是一种用于前馈卷积神经网络的通用轻量级注意力模块,它会沿着通道和空间 2 个维度独立地依次推断注意力特征,然后将注意力特征相乘以进行自适应特征优化^[25]。CBAM 结构如图 5 所示。




图 5 CBAM 结构

CBAM 注意力机制由 2 段组成,前一段是根据 3×3 卷积层输出结果的一个中间特征矩阵 $\mathbf{F} \in \mathbf{R}^{C \times H \times W}$ 作为通道注意力模块的输入,对输入按通道分别进行全局最大池化(MaxPool)和均值池化(AvgPool),池化后的 2 个一维向量经过全连接层运算相加,生成一维通道注意力 $M_c \in \mathbf{R}^{C \times 1 \times 1}$,再将通道注意力与输入元素相乘,得到通道注意力调整后的特征图 $M_c(\mathbf{F})$,见式(1);后一段将特征图 $M_c(\mathbf{F})$ 再按空间进行全局最大池化和均值池化,池化后的 2 个二维向量经过拼接后进行 7×7 卷积操作,得到二维空间注意力 $M_s \in \mathbf{R}^{1 \times H \times W}$,见式(2);最后再与特征图 $M_c(\mathbf{F})$ 相乘得到结果 $M_{c \otimes s}(\mathbf{F})$,继续输往下一层,见式(3)。注意力机制使用前后特征图大小和深度没有变。

通道注意力机制如下式所示:

$$M_c(\mathbf{F}) = \sigma(MLP(\text{AvgPool}(\mathbf{F})) + MLP(\text{MaxPool}(\mathbf{F}))) \quad (1)$$

空间注意力机制如下式所示:

$$M_s(\mathbf{F}) = \sigma(f^{7 \times 7}(\text{AvgPool}(M_c(\mathbf{F})); \text{MaxPool}(M_c(\mathbf{F})))) \quad (2)$$

CBAM 如下式所示:

$$M_{c \otimes s}(\mathbf{F}) = M_s(\mathbf{F}) \otimes M_c(\mathbf{F}) \quad (3)$$

其中: σ 为 Sigmoid 函数; MLP 为全连接层运算。

SiLU 激活函数是 Sigmoid 函数的加权线性组合,相对于 ReLU 激活函数,其能够保留负样本输入信息,这对烤烟图像数据来说很重要。同时,它在接近 0 时具有更平滑的曲线,并且由于其使用了 Sigmoid 函数,可以使网络的输出范围在 0 和 1 之间,因此使得 SiLU 在一些应用中比 ReLU 表现更好(图 6)。

$$\text{SiLU}(x) = x \times \sigma(x) = \frac{x}{1 + e^{-x}} \quad (4)$$

改进后的 ShuffleNetV2_FTC 网络具体配置如表 2 所示,依然有 $0.5 \times$ 、 $1 \times$ 和 $1.5 \times$ 3 种配置。 $0.5 \times$ 的输出通道为 [24, 48, 96, 192, 1 024, 27],模型体量为参数量 0.81 M,内存占用 8.86 M,浮点运算量 0.09 G。 $1 \times$ 的输出通道为 [24, 116, 232, 464, 1 024, 27],模型体量为参数量 3.90 M,内存占用 15.05 M,浮点运算量 0.44 G。 $1.5 \times$ 的输出通道为 [24, 176, 352, 704, 1 024, 27],模型体量为参数量 8.59 M,内存占用 20.51 M,浮点运算量 0.97 G。整体来讲,该模型提高了网络单层的非线性能力,但减少了卷积层层数(CBR1 和 DWB3 合并为 CBS3)。




图 6 SiLU 和 ReLU 激活函数图像

表 2 ShuffleNetV2_FTC 网络结构

层名称	输出尺寸	操作方法	步距	循环次数	CBAM	输出通道数		
						0.5×	1×	1.5×
图像输入	224×224					3	3	3
卷积 1	112×112	二维卷积, 3×3	2	1	—	24	24	24
最大池化	56×56	池化, 3×3	2					
阶段 2	28×28	单元 1	2	1	—	48	116	176
	28×28	单元 2	1	3				
阶段 3	14×14	单元 3	2	1	✓	96	232	352
	14×14	单元 4	1	7	✓			
阶段 4	7×7	单元 3	2	1	✓	192	464	704
	7×7	单元 4	1	3	✓			
卷积 5	7×7	二维卷积, 1×1	1	1	—	1 024	1 024	1 024
全局池化	1×1	池化, 7×7			—			
全连接						27	27	27
参数量/M						0.81	3.90	8.59
内存占用/M						8.86	15.05	20.51
浮点运算量/G						0.09	0.44	0.97

1.3.3 模型建立与训练

在整个训练过程中, 先用 CIFAR-100 数据集训练得到一个预训练权重, 然后在训练烤烟等级图像时导入分类网络初始化权重矩阵。优化器统一选用自适应动量的 Adam 随机优化方法, 训练 60 轮后学习率下降 1%, 并使用早停机制 (Early Stopping)^[30] 防止过拟合训练。训练停止后, 将得到的最优分类权重保存下来。

在测试过程中, 首先将最优分类权重加载到分类网络中, 然后导入烤烟测试集数据, 最后输出烤烟等级识别分类准确率。基本试验参数如表 3 所示。

表 3 基本试验参数

参数	值	参数	值
图像尺寸	224×224×3	初始学习率	0.001
批量大小	16	早停机制	7
优化器	Adam	数据通道	2

试验环境: AMD 锐龙 5 4600H 处理器搭配 Radeon Graphics 3.00 GHz (16 G 内存) + NVIDIA 3060 显卡(6 G 显存); 编程环境: Python 3.6 + Pytorch 1.10。

1.4 模型评价指标

对于烤烟等级识别模型使用准确率(Accuracy)、帧率(Frame Rate)、精确率(Precision)、召回率(Recall)、F1 分数(F1 Score)等评判标准^[17,20,31]。

假设: TP 为正确标签识别为真的数量; TN 为错误标签识别为假的数量; FN 为正确标签识别为假的数量; FP 为错误标签识别为真的数量^[34]。

准确率为所有预测正确的样本占总样本的比例, 即:

$$R_{\text{Accuracy}} = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

精确率为正确标签识别为真的样本占全部识别为真的比例, 即:

$$R_{\text{Precision}} = \frac{TP}{TP + FP} \quad (6)$$

召回率为正确标签识别为真的样本占全部实际为正确的比例, 即:

$$R_{\text{Recall}} = \frac{TP}{TP + FN} \quad (7)$$

F1 分数是精确率和召回率的调和平均, 兼顾了模型的精确率和召回率, 可以用来衡量模型的准确度, 其数值(范围为 0~1)越接近 1 表示模型性能越好。

$$S_{\text{F1}} = 2 \times \frac{R_{\text{Precision}} \times R_{\text{Recall}}}{R_{\text{Precision}} + R_{\text{Recall}}} \quad (8)$$

2 结果与分析

2.1 ShuffleNet 系列网络试验结果

为了验证 ShuffleNet 系列网络在 27 类烤烟图像数据集上的效果, 分别将 ShuffleNetV1^[32]、ShuffleNetV2(0.5×)、ShuffleNetV2(1×)和 ShuffleNetV2(1.5×)网络导入进行训练, 并在测试集上进行测试, 试验结果如表 4 所示。通过表 4 的对比结果可以看出, V2 系列在相同的浮点运算量下参数量要大于 V1, 但测试结果却得到提升, 每秒 12.3 张的帧率完全满足烤烟等级识别工业应用的要求。

同时可以看出 V2 系列准确率有点偏低, 如果能保证检测速度的情况下把准确率提高就更好了。因此本研究选用 ShuffleNetV2 网络, 并在此基础上进行改进, 以提升检测准确率。

表 4 ShuffleNet 系列网络测试结果

模型	参数量/M	内存占用/M	浮点运算量/G	准确率/%	帧率/fps
ShuffleNetV1	0.90	24.57	0.14	76.21	11.1
ShuffleNetV2(0.5×)	0.35	11.23	0.04	84.95	12.3
ShuffleNetV2(1×)	2.19	20.84	0.15	85.32	12.3
ShuffleNetV2(1.5×)	2.51	29.32	0.30	88.36	12.3

2.2 改进的 ShuffleNetV2 网络试验结果

ShuffleNetV2_FTC 网络训练过程如图 7 所示, 左边是验证准确率变化过程, 右边是验证损失变化过程。0.5×模型在整个训练过程中耗时 120 个轮次, 1×模型耗时 98 个轮次, 1.5×模型耗时 102 个轮次。前 60 轮的训练曲线经历了明显的震荡, 但在第 60 轮调整学习率后, 准确率和损失曲线发生了明显

变化,之后震荡趋于平稳,这表明学习率的调整对于稳定训练过程和提高性能是有效的。相比之下,在 $0.5\times$ 模型中,调整学习率后,准确率曲线和损失曲线却没有明显突变,这可能表明在初始学习率为 0.001 时,模型更早地接近拟合终点,不需要额外的轮次和学习率调整来稳定性能。最终, $1.5\times$ 模型取得了更高的验证准确率(93.88%)和更低的验证损失值(0.1318)。




图 7 ShuffleNetV2_FTC 网络训练过程

将训练好的最优权重载入 ShuffleNetV2_FTC 网络,然后导入测试集图像(822 张),得到如表 5 所示的测试结果。表中的精确率、召回率和 F1 分数为 27 类烤烟图像检测的均值。对比可知,改进网络在参数数量和计算量上有所牺牲,但降低了内存占用(这将有利于将算法移植到移动设备上),提升了准确率(提升了 0.24% ($0.5\times$)、 6.06% ($1\times$)和 4.73% ($1.5\times$))。帧率也得到了提高(减少模型层数是有必要的),由原来的每秒检测 12.3 张图片提升到了 15.3 张。

表 5 改进前后结果对比

模型	精确率/%	召回率/%	F1 分数/%	准确率/%	帧率/fps
ShuffleNetV2($0.5\times$)	86.13	85.04	85.03	84.95	12.3
ShuffleNetV2($1\times$)	86.58	85.36	85.24	85.32	12.3
ShuffleNetV2($1.5\times$)	89.61	88.46	87.99	88.36	12.3
ShuffleNetV2_FTC($0.5\times$)	87.14	85.18	84.87	85.19	15.3
ShuffleNetV2_FTC($1\times$)	91.77	91.39	91.25	91.38	15.3
ShuffleNetV2_FTC($1.5\times$)	93.60	93.11	93.08	93.09	15.3

热力图能对模型的分类结果提供很好的可视化依据^[33]。如图 8 所示,试验展示了测试集中一张烤烟图像(C3L)在改进前后网络识别差异的对比,颜色越深、范围越广表示提取效果越好。在图 8 中可以看出,改进网络对烤烟的颜色、形状和纹理信息特征提取能力更好,提取信息重心都在烟叶叶身。而 ShuffleNetV2 系列网络在烟叶本身提取到的特征无论从深度还是范围上都相对而言逊色于改进网络。

图 9 展示了 ShuffleNetV2_FTC($1\times$ 和 $1.5\times$)网络在烤烟测试集上的混淆矩阵图。横坐标表示真实标签,纵坐标表示预测标签,对角线数据占比越大表明分类的效果越好^[34]。

从 2 个矩阵整体来看,各部位叶外(上部叶 B、腰叶 C、下部叶 X)识别少有混淆,各部位叶内(CL 系列、CF 系列)识别多有混淆,表明相近等级间的识别效果较差,较远等级间的识别较好,和韩东伟等^[23]的研究一致。从 2 个矩阵细节上看,对上杂二(B2K)、中柠二(C2L)、中柠三(C3L)、中柠四(C4L)和下秸二

(X2F)类别的识别效果较差,其辨别难度较大,与童德文等^[35]的研究一致;对上秠一(B1F)、上杂三(B3K)、中下杂一(CX1K)、中下杂二(CX2K)、下柠二(X2L)、下柠三(X3L)类别的识别效果略好,辨别难度较小,和庄珍珍等^[2]的研究一致。

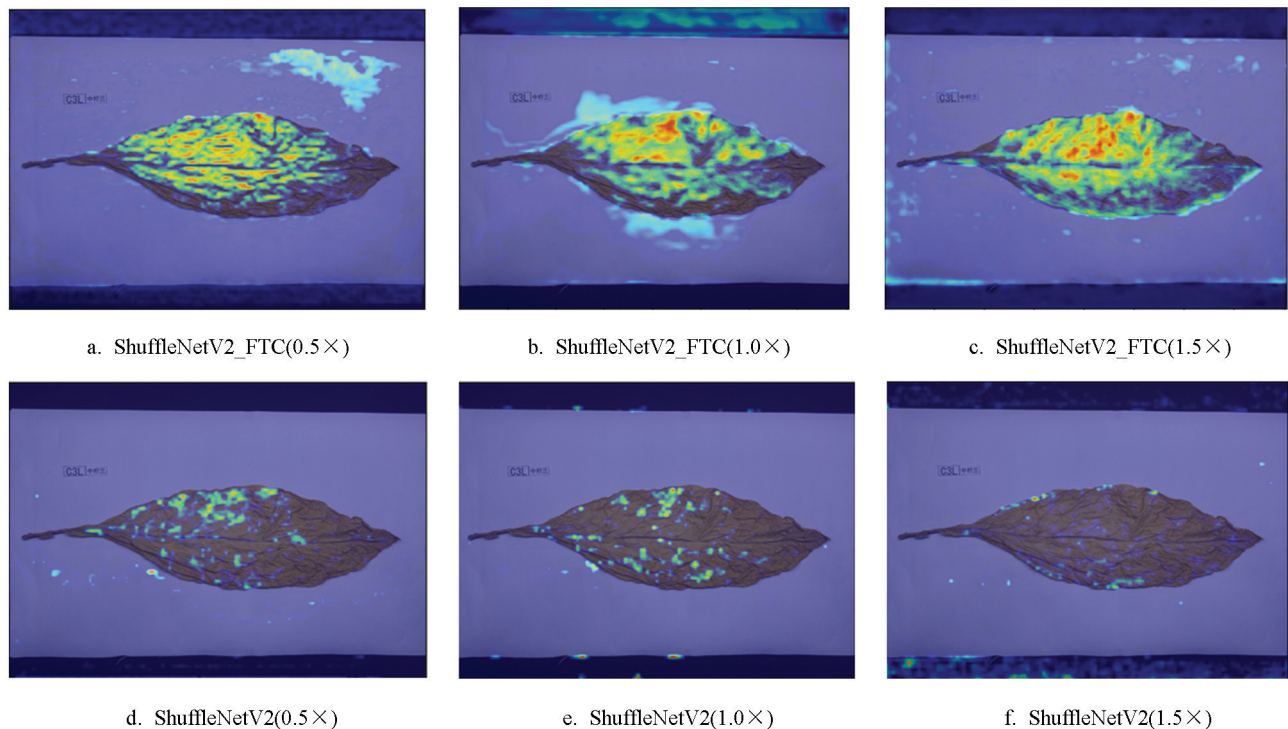


图 8 热力图分析

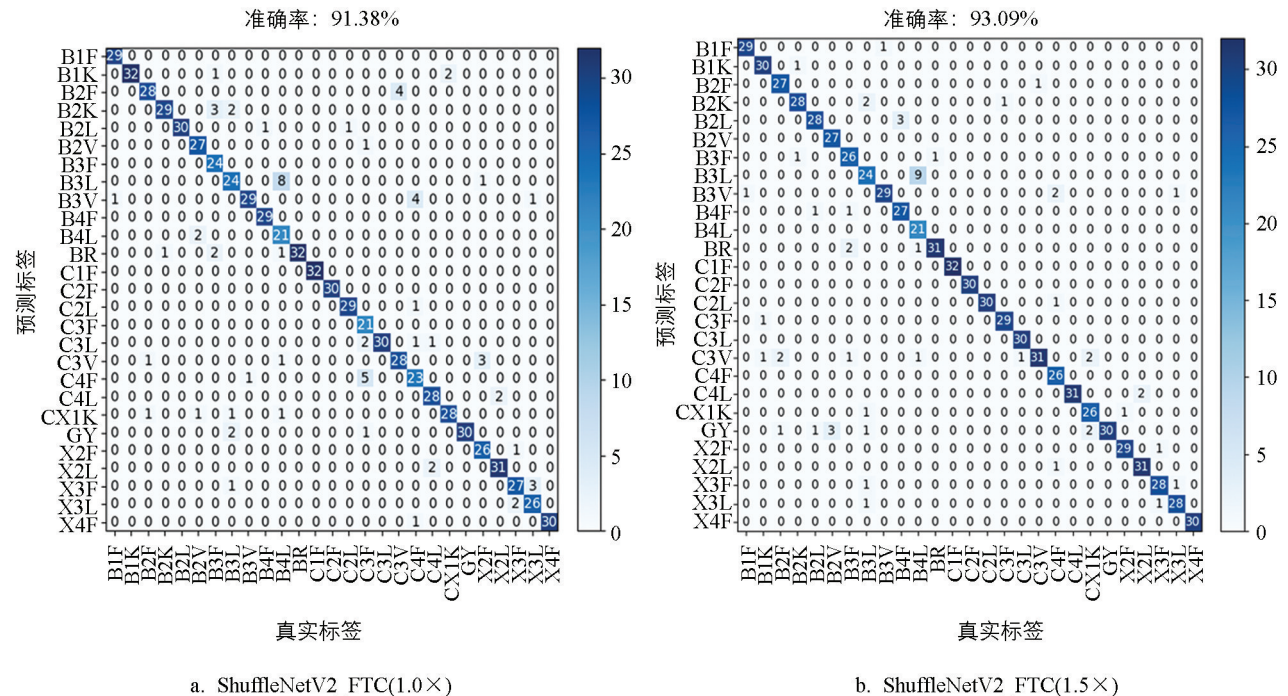


图 9 测试混淆矩阵

2.3 多方法评估对比

表 6 展示了不同模型在测试集上的对比。首先从模型评估测试结果来看, ShuffleNetV2_FTC(1.5x)

网络有着较好的应用性能。相对其他网络有最好的精确率、召回率、F1 分数和准确率, EfficientNetV2_S 次之, ResNeXt50^[33] 和 MobileNetV3_S 在本测试中表现不理想。

表 6 不同模型测试结果对比

模型	精确率/%	召回率/%	F1 分数/%	准确率/%
ResNeXt50 ^[37]	84.54	82.44	82.41	82.40
MobileNetV3_S ^[37]	83.70	79.43	78.24	84.71
MobileNetV3_L ^[37]	92.04	91.23	91.21	91.14
EfficientNetV2_S ^[37]	93.25	91.71	91.57	91.63
EfficientNetV2_M ^[37]	91.90	90.13	89.73	90.05
ShuffleNetV2_FTC(1×)	91.77	91.39	91.25	91.38
ShuffleNetV2_FTC(1.5×)	93.60	93.11	93.08	93.09

其次从模型体量来看, ShuffleNetV2_FTC(1.5×)网络有着较好的移动端部署性能。MobileNetV3_S 有着最低的参数量和最低的浮点运算量; ShuffleNetV2_FTC(1×)有着最低的内存占用量, MobileNetV3_S 次之; ShuffleNetV2_FTC 整体有着最高的帧率, MobileNetV3_S 次之。具体如表 7 所示。

表 7 不同模型的体量对比

模型	参数量/M	内存占用/M	浮点运算量/G	帧率/fps
ResNeXt50	21.94	134.76	4.26	13.7
MobileNetV3_S	1.46	16.19	0.06	14.7
MobileNetV3_L	4.02	50.39	0.22	14.4
EfficientNetV2_S	19.26	144.97	2.87	12.1
EfficientNetV2_M	50.42	233.59	5.40	12.2
ShuffleNetV2_FTC(1×)	3.90	15.05	0.44	15.3
ShuffleNetV2_FTC(1.5×)	8.59	20.51	0.97	15.3

最后综合评估 ShuffleNetV2_FTC 网络具有更好的性能。EfficientNetV2_S 虽然有较好的检测结果, 但是模型体量太大, 且帧率仅有 12 张图片, 相对不适合部署在移动端; MobileNetV3_S 虽然有最好的移动设备部署性能, 但模型检测结果准确率仅有 84.71%; ShuffleNetV2_FTC(1.5×)因较低的内存占用 ($20.51 < 50.39$) 和较高的检测帧率 ($15.3 > 14.4$) 使其综合性能优于 MobileNetV3_L。

3 结论

本研究针对烤烟等级识别技术目前所面临的识别种类少和算法冗余度高 2 大问题, 借助深度学习理论和计算机视觉技术, 改进 ShuffleNetV2 网络, 构建了 ShuffleNetV2_FTC 网络。提出的 ShuffleNetV2_FTC 网络相对于原模型获得了准确率和检测帧率的提升, 相对于其他网络有更好的效率。最终改进模型在 27 类样本下测试准确率为 93.09%, 检测帧率为每秒 15.3 张, 达到了理想检测效率。同时本研究还引入吸光布和反光纸结合的方式改进数据采集方法, 一定程度上避免了图像失真的情况发生。本研究解决烤烟等级识别技术迟迟无法工业应用问题的方法具有普适性, 可应用于其他分类识别任务, 为后续实现精度和帧率更高更快的农产品分类识别方法提供了参考。在下一步研究计划中, 将继续完善类别数据集, 建立完整 42 个等级的烤烟等级识别数据库。

参考文献:

- [1] 国家技术监督局. 烤烟: GB 2635—1992 [S]. 北京: 中国标准出版社, 1992.
- [2] 庄珍珍, 祝诗平, 孙雪剑, 等. 基于机器视觉的烟叶自动分组方法 [J]. 西南师范大学学报(自然科学版), 2016, 41(4): 122-129.
- [3] 张珂, 冯晓晗, 郭玉荣, 等. 图像分类的深度卷积神经网络模型综述 [J]. 中国图象图形学报, 2021, 26(10): 2305-2325.
- [4] 李士静, 潘羲, 陈熙卓, 等. 基于高光谱信息的烟叶分级方法比较 [J]. 烟草科技, 2021, 54(10): 82-91.
- [5] 胡善科, 秦玉华, 段如敏, 等. 联合矩阵局部保持投影的近红外光谱特征提取 [J]. 光谱学与光谱分析, 2020, 40(12): 3772-3777.
- [6] 向金海, 杨申, 樊恒, 等. 基于稀疏表示的烤烟烟叶品质分级研究 [J]. 农业机械学报, 2013, 44(11): 287-292.
- [7] 周志华. 机器学习 [M]. 北京: 清华大学出版社, 2016.
- [8] GU J X, WANG Z H, KUEN J, et al. Recent Advances in Convolutional Neural Networks [EB/OL]. (2017-10-19) [2023-11-27]. <https://arxiv.org/abs/1512.07108>.
- [9] 王戈, 丁冉, 徐玮杰, 等. 计算机视觉和智能识别技术在烤烟烟叶分级中的应用 [J]. 计算机与应用化学, 2019, 36(5): 548-553.
- [10] KETKAR N, MOOLAYIL J. Deep Learning with Python: Learn Best Practices of Deep Learning Models with PyTorch [M]. 2nd ed. Berkeley, CA: Apress, 2021.
- [11] MARZAN C S, RUIZ C R Jr. Automated Tobacco Grading Using Image Processing Techniques and a Convolutional Neural Network [J]. International Journal of Machine Learning and Computing, 2019, 9(6): 807-813.
- [12] 李海杰. 基于机器视觉的烟草异物检测和烟叶分类分级方法研究 [D]. 南京: 南京航空航天大学, 2016.
- [13] 曾祥云. 一个基于深度学习的烤烟分级系统的设计与实现 [D]. 南京: 东南大学, 2017.
- [14] 王士鑫, 云利军, 叶志霞, 等. 一种基于卷积神经网络的烟叶分级处理算法 [J]. 云南民族大学学报(自然科学版), 2020, 29(1): 65-69.
- [15] 陈鹏羽, 张洪艳, 贺威. 基于多尺度特征融合细粒度分类网络的扎把烟叶分级方法 [J]. 安徽农业大学学报, 2022, 49(6): 1013-1021.
- [16] SWASONO D I, TJANDRASA H, FATICHAH C. Classification of Air-Cured Tobacco Leaf Pests Using Pruning Convolutional Neural Networks and Transfer Learning [J]. International Journal on Advanced Science, Engineering and Information Technology, 2022, 12(3): 1229.
- [17] 鲁梦瑶, 周强, 姜舒文, 等. 基于深度学习与多尺度特征融合的烤烟烟叶分级方法 [J]. 中国农机化学报, 2022, 43(1): 158-166.
- [18] 宋怀波, 华志新, 马宝玲, 等. 基于 SimCC-ShuffleNetV2 的轻量化奶牛关键点检测方法 [J]. 农业机械学报, 2023, 54(10): 275-281.
- [19] XU X M, ZHANG Y Q, CAO H C, et al. Recognition of Edible Fungi Fruit Body Diseases Based on Improved ShuffleNetV2 [J]. Agronomy, 2023, 13(6): 1530.
- [20] 彭红星, 何慧君, 高宗梅, 等. 基于改进 ShuffleNetV2 模型的荔枝病虫害识别方法 [J]. 农业机械学报, 2022, 53(12): 290-300.
- [21] 何艳, 夏志林, 祝诗平, 等. 基于机器视觉的穴盘烟苗自动间苗算法研究 [J]. 云南农业大学学报(自然科学), 2019, 34(1): 50-57.
- [22] 苏明秋. 基于烟叶图像的参数精确提取和分级识别系统研究与实现 [D]. 成都: 电子科技大学, 2020.
- [23] 韩东伟, 王小明, 王新峰. 基于深度学习网络的烟叶质量识别 [J]. 安徽农业科学, 2018, 46(10): 185-188.
- [24] MA N N, ZHANG X Y, ZHENG H T, et al. ShuffleNet V2: Practical Guidelines for Efficient CNN Architecture Design [EB/OL]. (2018-07-30) [2023-11-27]. <https://arxiv.org/abs/1807.11164>.

- [25] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module [C] //Proceedings of the European Conference on Computer Vision (ECCV 2018). Lecture Notes in Computer Science. Cham: Springer International Publishing, 2018: 3-19.
- [26] ELFWING S, UCHIBE E, DOYA K. Sigmoid-Weighted Linear Units for Neural Network Function Approximation in Reinforcement Learning [J]. Neural Networks, 2018, 107: 3-11.
- [27] 蒋镛圻, 叶泽聪, 彭月平, 等. 针对弱小无人机目标的轻量级目标检测算法 [J]. 激光与光电子学进展, 2022, 59(8): 109-120.
- [28] TAN M X, LE Q V. EfficientNetV2: Smaller Models and Faster Training [EB/OL]. (2021-04-01) [2023-12-10]. <https://arxiv.org/pdf/2104.00298>.
- [29] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3 [C] //2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). IEEE, 2019: 1314-1324.
- [30] YUAN P S, QIAN S Y, ZHAI Z Y, et al. Study of Chrysanthemum Image Phenotype On-Line Classification Based on Transfer Learning and Bilinear Convolutional Neural Network [J]. Computers and Electronics in Agriculture, 2022, 194: 106679.
- [31] 孙月莹, 陈俊霖, 张胜茂, 等. 基于改进 YOLOv7 的毛虾捕捞渔船作业目标检测与计数方法 [J]. 农业工程学报, 2023, 39(10): 151-162.
- [32] ZHANG X Y, ZHOU X Y, LIN M X, et al. ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices [C] //2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. IEEE, 2018: 6848-6856.
- [33] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization [J]. International Journal of Computer Vision, 2020, 128(2): 336-359.
- [34] 王泽钧, 马凤英, 张瑜, 等. 基于注意力机制和多尺度轻量型网络的农作物病害识别 [J]. 农业工程学报, 2022, 38(S1): 176-183.
- [35] 童德文, 陈钰, 杜超凡, 等. 开放环境下烟叶等级 RGB 图像智能识别及判别模型的构建 [J]. 贵州农业科学, 2020, 48(3): 131-135.
- [36] XIE S N, GIRSHICK R, DOLLÁR P, et al. Aggregated Residual Transformations for Deep Neural Networks [EB/OL]. (2017-04-11) [2023-11-27]. <https://arxiv.org/abs/1611.05431>.
- [37] 冯川, 祝诗平, 赵虎, 等. 基于移动设备的烤烟等级识别模型优选 [J/OL]. 计算机仿真, (2023-12-21) [2024-01-17]. <https://link.cnki.net/urlid/11.3724.TP.20231220.1610.006>.

责任编辑 柳剑
崔玉洁