

DOI: 10.13652/j.issn.1003-5788.2021.10.006

基于卷积神经网络的白酒酒花分类研究

Research on classification of liquor hops based on
convolution neural network

潘 斌^{1,2} 韩 强^{1,2} 姚娅川³

PAN Bin^{1,2} HAN Qiang^{1,2} YAO Ya-chuan³

(1. 四川轻化工大学自动化与信息工程学院, 四川 自贡 643000; 2. 人工智能四川省重点实验室,

四川 自贡 643000; 3. 四川轻化工大学物理与电子工程学院, 四川 自贡 643000)

(1. School of Automation and Information Engineering, Sichuan University of Science & Engineering,

Zigong, Sichuan 643000, China; 2. Sichuan Key Laboratory of Artificial Intelligence, Sichuan

University of Science & Engineering, Zigong, Sichuan 643000, China; 3. School of Physics and

Electrical Engineering, Sichuan University of Science & Engineering, Zigong, Sichuan 643000, China)

摘要:目的: 实现白酒酒花自动分类, 提高摘酒的实时性与稳定性。方法: 提出以机器视觉结合卷积神经网络代替人眼进行摘酒的方法, 并与多种图像分类方法进行比较, 验证改进分类算法的优越性。结果: 基于改进 Vgg16 卷积神经网络 + 迁移学习方法分类模型准确率高达 96.69%。结论: 该方法能够实时稳定地对白酒酒花进行分类。

关键词: 白酒; 酒花; 机器视觉; 图像分类; 卷积神经网络

Abstract: Objective: This study focuses on realizing the automatic classification of liquor flowers and then improving the real-time and stability of liquor picking. Methods: The machine vision combined with convolutional neural network was used to replace human eyes for liquor picking. Comparing with many image classification methods, the superiority of the improved algorithm was verified. Results: The results showed that the classification accuracy of the model based on the improved Vgg16 convolutional neural network plus transferring-learning method was up to 96.69%. Conclusion: This method can be used in the real-time classification of Baijiu hops stably.

Keywords: baijiu; hops; machine vision; image classification; convolution neural network

中国白酒生产工艺中摘酒是非常重要的环节, 目前

绝大多数酒厂摘酒多由工人凭借经验按酒花进行分类, 效率低下且分类不够客观、准确。为实现酒花自动分类, 进一步实现自动化摘酒, 国内外许多学者对代替人眼进行酒花分类开展了大量研究, 赵平^[1]设计了一种白酒量质摘酒过程中的图像采集和传输装置, 避免了摘酒工需要进入生产车间, 但仍然没有消除摘酒过程中的人工干预。何盛国等^[2]在白酒蒸馏的甑罐出口设置了酒精度、风味物质在线检测仪器, 完成分段摘酒。但该方法使用的在线检测仪器价格昂贵, 难以实现大规模的自动化摘酒。范明明^[3]利用近红外技术, 开发了基于近红外技术的白酒摘酒在线检测装置, 取得了较好的试验效果, 但需要在白酒生产线上进行实用化试验。余锴鑫^[4]提出了基于图像分类算法的自动化摘酒方法研究, 将深度学习引入到白酒摘酒环节, 但受到了计算量的限制, 分类速度缓慢。陈林等^[5]提出酒精度重建模型配合分段摘酒装置, 通过音叉密度计建立基酒与酒精度模型的关系, 来预测基酒酒精度。杨静娴等^[6]提出基于图像处理的白酒酒花轮廓检测, 采用模式识别的方式实现智能摘酒。

虽然目前已有酒企采用接触式设备进行智能摘酒, 脱离了人工摘酒, 但设备价格昂贵、维护成本高、不易实现大规模生产。而非接触式的机器视觉技术, 因为成本低, 方便快捷, 易于大规模实现。研究拟提出基于卷积神经网络的酒花分类方法, 以期实现智能摘酒。

1 酒花特征分析与数据集构建

1.1 酒花气泡特征分析

相同的温度和压强下, 不同成分的酒会具有不同的黏度和表面张力, 因此酒花会有所不同^[7-8]。不同酒精

基金项目: 四川省科技厅项目(编号: 2021YFS0339); 四川省重大科技专项项目(编号: 2018GZDZX0045)

作者简介: 潘斌, 男, 四川轻化工大学在读硕士研究生。

通信作者: 姚娅川(1968—), 女, 四川轻化工大学教授, 硕士生导师, 硕士。E-mail: 610851229@qq.com

收稿日期: 2021-02-05

度的基酒产生的酒花会不同即酒花与基酒酒精度有对应关系。酒花特征与酒精度的关系如表 1 所示。

表 1 酒花特征与酒精度

Table 1 Characteristics of hops and alcohol concentration

酒花名称	酒花特征	酒精度/% Vol
头段酒花(大清花)	酒花大,透亮,均匀	70~80
中段酒花(小青花)	酒花大小有变化,大小不均匀	60~70
末段酒花(云花)	酒花混乱,大小差异较大,小酒花发白	40~50
酒尾酒花(二花)	颜色暗淡无光、皮厚、泡沫粘连	约 30

1.2 酒花数据集构建

目前中国没有完整的酒花数据,需要人工采集,因此需要自行构建白酒酒花数据集。

1.2.1 工业相机选型 工业相机具有高的成像质量、更快的传输速度、更好的图像稳定性和更强的抗干扰能力,考虑到图像传感器类型、分辨率、帧率、接口类型等,选择中国海康威视公司生产的 MV-CA050-20GM/GC 型工业面阵相机。其性能参数如表 2 所示。

1.2.2 数据采集 为实现精确的酒花分类,采用控制变量法采集数据,利用蒸汽阀门控制流酒速度,盛酒器与流酒管高度固定。酒花数据来自中国某酒厂,采用 MV-CA050-20GM/GC 型工业面阵相机,由 2 名生产组组长协同采集(四段)酒花视频数据以保证样本的正确性。四段酒花数据包含不同角度、不同光照条件、不同摘酒现场的样本,基本考虑到了摘酒现场各种可能出现的因素。从四段酒花视频中分别逐帧提取头段酒花、中段酒花、末段酒花、酒尾酒花原始样本,分别获取 1 375,1 386,1 369,1 386 个样本,样本图像大小 544 × 960 × 3,图像类型为 JPG 格式。

2 图像预处理

为了提高系统后续输入图像的可信度与分类准确

表 2 MV-CA050-20 型工业相机性能参数

Table 2 Performance parameters of MV-CA050-20 industrial camera

性能	单位	参数
帧率	帧/s	22
解像度(分辨率)		2 592 × 2 048
传感器类型		CMOS
靶面尺寸	mm ³	1
曝光时间	μs	65~1 × 107
增益	dB	0~15
通讯接口		USB3.0
信噪比	dB	39.5

率,减少分类时间,对图像进行预处理,包括:输入图像、图像灰度化、Gamma 校正、图像滤波 4 步。

2.1 图像灰度化与 Gamma 校正

图像灰度化是指将彩色图像中多个通道各种对应的分量通过一种方法转化为一个通道的灰度图^[9]。文中选用加权平均法作为图像灰度化的方法,其数学表达式:

$$G_{\text{ray}} = R \times \omega_R + G \times \omega_G + B \times \omega_B, \quad (1)$$

式中:

R, G, B ——对应通道的像素值;

ω_R —— R 通道的权重,取 0.299;

ω_G —— G 通道的权重,取 0.114;

ω_B —— B 通道的权重,取 0.587。

Gamma 校正的压缩计算公式:

$$I(x, y) = I(x, y)^g, \quad (2)$$

式中:

$I(x, y)$ ——灰度图;

g ——校正值。

2.2 图像滤波

均值滤波是将滤波核内像素的平均值代替滤波核中心位置像素值^[10]。假设现在使用 3 × 3 的模板对 $m \times n$ 的图像进行滤波,图解如图 1 所示。

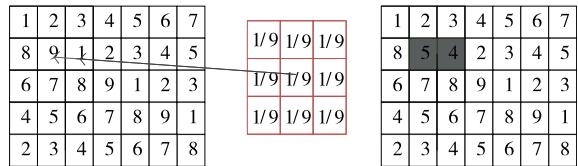


图 1 均值滤波

Figure 1 Mean filtering

由图 2 可知,均值滤波算法可表示为:

$$f_a(x, y) = \frac{1}{9} \left[\sum_{t=-1}^1 \sum_{s=-1}^1 f(x+t, y+s) \right], \quad (3)$$

式中:

$2 \leq x \leq m-1$;

$2 \leq y \leq n-1$;

$f_a(x, y)$ ——输出图像;

$f(x, y)$ ——原始图像;

m, n ——图片大小。

中值滤波属于非线性滤波方法,基本思想是将滤波核的中心像素,由邻域像素灰度值的中值代替^[11],中值滤波示意如图 2 所示。

在图 2 中,采用 3 × 3 滤波核,滤波核的大小可以自己确定,常用滤波核大小有 5 × 5, 9 × 9 形式,滤波核的大小通常为奇数。以 3 × 3 为例中值抑噪可由式(4)表示。

$$f_m(x, y) = \text{med} [f(x+k, y+l)], (k, l \in [-1, 1]), \quad (4)$$

式中:

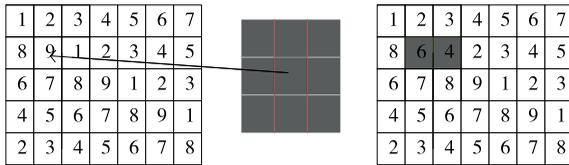


图 2 中值滤波示意图

Figure 2 Schematic diagram of median filter

$f(x, y)$ ——原始图像;

$f_m(x, y)$ ——中值滤波后的结果图。

高斯滤波是一种线性平滑滤波,能为邻域内每个像素赋予权值,滤波核的中心像素由不同权值的邻域像素加权平均值确定^[12],高斯滤波图解如图 3 所示。



图 3 高斯滤波

Figure 3 Gaussian filtering

图 3 中高斯卷积核由二维高斯函数进行离散化得到,二维高斯函数如式(5)所示。

$$p(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (5)$$

由式(5)离散化得到式(6):

$$p_{i,j} = \frac{1}{2\pi\sigma^2} e^{-\frac{(i-k-1)^2+(j-k-1)^2}{2\sigma^2}} \quad (6)$$

式中:

k ——核矩阵的维数;

σ ——方差;

i, j ——核矩阵中各点到中心点的距离。

以头段酒花为例各滤波示意图如图 4 所示。

通过研究表明,白酒酒花图像中存在的噪声多为高斯噪声,因此选用高斯滤波。

3 基于卷积神经网络酒花分类模型设计

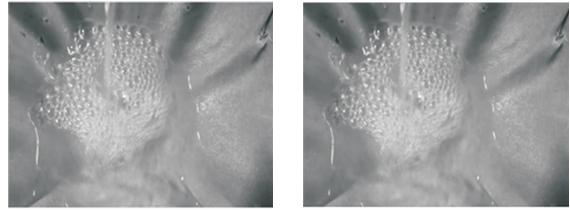
3.1 卷积神经网络

卷积神经网络是一种多层前馈神经网络,具备良好的自学习特征能力,强大的并行处理能力,以及优秀的鲁棒性,卷积网络的基本结构如图 5 所示。主要由输入层、卷积层、激活层和池化层、全连接层构成。

(1) 数据输入层:对待输入的样本图片进行一些预处理,例如将所有样本统一成相同的大小,方便后续的其他操作。

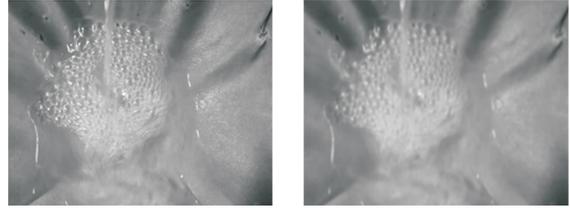
(2) 卷积层:卷积层也叫特征提取层,是卷积神经网络的核心部分。卷积过程如图 6 所示。

(3) 池化层:也被称为下采样层。池化就是对图像某个区域的特征进行统计分析,并将统计的结果用来表示整个区域的总体特征。运算过程如图 7 所示。



(a) 原图

(b) 均值滤波



(c) 中值滤波

(d) 高斯滤波

图 4 滤波示意图

Figure 4 Filtering diagram

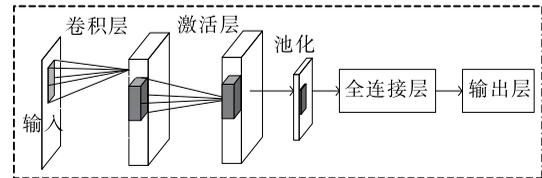


图 5 卷积神经网络基本结构

Figure 5 Basic structure of convolutional neural network

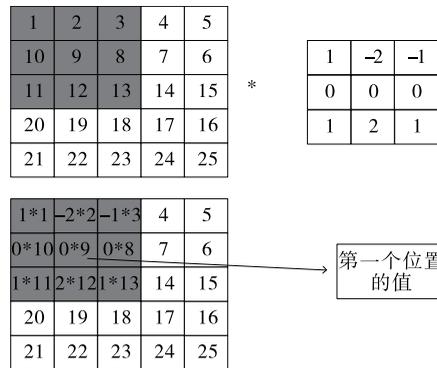


图 6 卷积过程

Figure 6 Convolution process

(4) 激活层:解决线性模型所不能解决的问题,常见的激活函数有 Sigmoid、Tanh、ReLU、PreLU、Maxout 等。

(5) 全连接层:将最后得到的图像特征,映射成一个固定长度的特征向量,传入分类器完成最终分类。

(6) 输出层:输出层一般为分类器层,最后输出的是一个将制定分类的种类数目作为维度的概率向量。

3.2 基于改进 Vgg16+迁移学习的模型设计

3.2.1 Vgg16 模型 传统 Vgg16 模型结构如表 3 所示, Vgg16 总网络深度为 16,其中包含 13 个卷积层和 3 个全连接层。输入图片大小为 $224 \times 224 \times 3$ 的彩色图片,其卷积核采用随机初始化,池化层采用最大池化,激活函数采用 ReLU 激活函数,分类器采用 Soft_max。

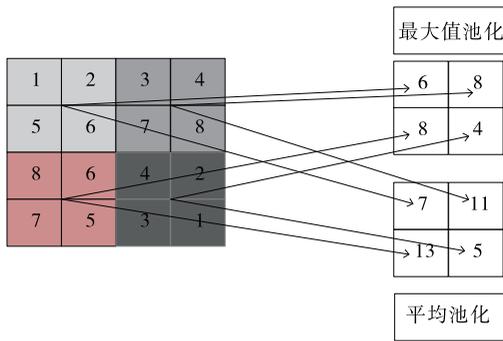


图 7 池化过程

Figure 7 Pooling process

3.2.2 迁移学习 传统的数据挖掘和机器学习算法使用带标签或不带标签的数据集,统计模型对未来数据进行预测。半监督分类使用大量未标注的数据集和少量标注数据集,解决标签数据集太少而无法训练良好的分类器的问题,大多数是基于假设标记样本和未标记样本具有相同的分布。然而在实际应用中,搜集样本费时费力,带标签的训练样本数量更是有限,所以服从统一分布的数据的假设很难满足。统计模型必须根据不同数据分布重

构模型,重构模型和重采集训练样本的代价太大。针对以上问题,迁移学习可以解决数据重采集和模型重构的问题,而且迁移学习还可以实现异类数据集之间的知识转移^[13]。迁移学习的动机是人们可以智能地应用以前学习到的知识来更快地解决新的问题,或者有更好的解决方案。

3.2.3 池化层设计 为在保留图像轮廓的完整性的同时,尽可能多地保留图像特征信息,文中结合最大池化与平均池化的优点提出最大—均值池化方式。通过式(7)和式(8)分别定义最大池化和平均池化的数学表达式:

$$f(x) = \max_{1 \leq m \leq n} (x_m), \tag{7}$$

$$f(x) = \frac{1}{n} \sum_{m=1}^n x_m, \tag{8}$$

式中:

x_m ——得到图像的滑动窗口 n 个像素点中的第 m 个像素点;

m ——在滑动窗口中的位置。

池化方式是将 x_m 映射到对应的统计值。

通过联合两者的优点,将最大池化方式和平均池化方式分别以权重相加得到新的池化方式——最大—均值

表 3 Vgg16 模型结构

Table 3 Vgg16 model structure

结构名称	卷积核	通道数	步长	填充	特征图大小	激活函数
输入层		3			224×224	
卷积层	3×3	64	1	1	224×224×64	ReLU
卷积层	3×3	64	1	1	224×224×64	ReLU
池化	2×2	64			112×112×64	
卷积层	3×3	128	1	1	112×112×128	ReLU
卷积层	3×3	128	1	1	112×112×128	ReLU
池化	2×2	128			56×56×128	
卷积层	3×3	256	1	1	56×56×256	ReLU
卷积层	3×3	256	1	1	56×56×256	ReLU
卷积层	3×3	256	1	1	56×56×256	ReLU
池化	2×2	256			28×28×256	
卷积层	3×3	512	1	1	28×28×512	ReLU
卷积层	3×3	512	1	1	28×28×512	ReLU
卷积层	3×3	512	1	1	28×28×512	ReLU
池化	2×2	512			14×14×512	
卷积层	3×3	512	1	1	14×14×512	ReLU
卷积层	3×3	512	1	1	14×14×512	ReLU
卷积层	3×3	512	1	1	14×14×512	ReLU
池化	2×2	512			7×7×512	
全连接					1×1×4 096	
全连接					1×1×4 096	
全连接					1×1×1 000	

池化。其数学表达式可表示为:

$$f(x) = \alpha \frac{1}{T} \sum_{i=1}^T x_i + \beta \max_{1 \leq i \leq T} x_i, \quad (9)$$

式中:

$$\alpha + \beta = 1.$$

3.2.4 激活函数设计 为了解决 ReLU 激活函数存在的“神经元死亡”和输出偏移问题,提高网络模型的性能,提出一种基于 ReLU 激活函数与 Tanh 激活函数改进的激活函数 TReLU。其数学表达式:

$$f(x) = \begin{cases} \alpha \left(\frac{e^x - e^{-x}}{e^x + e^{-x}} \right), & x < 0 \\ x, & x \geq 0 \end{cases}, \quad (10)$$

式中:

α ——可调参数。

3.2.5 参数优化方法 反向传播技术的使用使得深层神经网络的训练成为可能,基本原理是通过实际输出与期望输出计算出误差,并采用梯度下降法计算出误差函数相对于权值参数的梯度;然后在损失函数梯度的反方向上更新权值,假设有 m 个数据样本 $\{(x_1, y_1), \dots, (x_m, y_m)\}$,对于单个样本 (x, y) 的损失函数定义为:

$$J(\omega, b; x, y) = \frac{1}{2} \|h_{\omega, b}(x) - y\|^2, \quad (11)$$

式中:

ω ——连接权值;

b ——偏置;

$h_{\omega, b}(x)$ ——网络实际输出;

y ——网络的期望输出。

对于整个样本数据集 m 的整体损失函数可以表示为:

$$J(\omega, b) = \left[\frac{1}{m} \sum_{i=1}^m J(\omega, b; x_i, y_i) \right] + \frac{\lambda}{2} \sum_{l=1}^{n_l-1} \sum_{j=1}^{s_l} \sum_{i=1}^{s_{l+1}} (\omega_{ij}^l)^2, \quad (12)$$

式中:

ω ——权值矩阵;

n_l ——网络层数;

s_l ——对应网络层神经元数目;

ω_{ij}^l ——连接第 n_l 层第 i 个神经元和第 $n_l + 1$ 层第 j 个神经元的权值参数;

λ ——权值衰减参数。

梯度下降法在计算梯度时只进行了一次权值更新,所以处理大量数据时其收敛速度很慢。针对上述问题提出了几种优化梯度下降法的方法。

(1) 随机梯度下降法:随机梯度下降法(SGD)的基本原理是参数更新都是随机从训练集中选取^[14],更新迭代公式:

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta; x_i; y_i), \quad (13)$$

式中:

η ——学习率;

x_i, y_i ——训练样本;

θ ——训练参数。

随机梯度下降法的优点在于频繁的参数更新使得参数间具有高方差,这有助于网络收敛到最优解。但缺点是参数的更新都是随机从训练集中选取,每次的参数更新方向具有随机性,增加了网络的迭代次数,使网络收敛速度变得缓慢。

(2) 小批次随机梯度下降法:小批次随机梯度下降法的提出是为了缓解随机梯度下降法中网络迭代次数增加和网络收敛速度缓慢的问题,在参数更新速度和更新次数间取得一个平衡^[15],在参数每次的更新过程中会从训练集中随机选取 $m (m < n)$ 个样本进行参数更新。其优点降低了网络收敛的波动性,加快了网络收敛速度。迭代表达式:

$$\theta = \theta - \eta \cdot \nabla_{\theta} J(\theta; x_{i:i+m}; y_{i:i+m}), \quad (14)$$

式中:

η ——学习率;

$x_{i:i+m}, y_{i:i+m}$ ——训练样本;

θ ——训练参数动量因子方法。

由于梯度下降法在应用过程中伴随着高方差振荡,这使得网络很难稳定收敛,因此研究者^[16]提出了动量技术来缓解网络收敛不稳定的问题,数学表达:

$$v_t = \mu v_{t-1} + \eta \nabla_{\theta} J(\theta), \quad (15)$$

$$\theta = \theta - v_t, \quad (16)$$

式中:

μ ——0~1 的动量因子;

v_{t-1} ——上一次的更新值。

选用小批次随机梯度下降法,加入动量因子对小批次随机梯度下降法,减少计算量,加快网络收敛。

3.3 最终模型结构

文中改进模型是基于 Vgg16 大框架下进行改进,该模型结构框图如图 8 所示。

在图 8 中,卷积核初始化方式采用基于权重的迁移学习,池化方式采用改进后的最大—均值池化方式,激活函数采用改进后的 TReLU 激活函数。

4 试验结果分析

4.1 试验平台

试验基于操作系统 windows 1064,处理器 Intel(R)

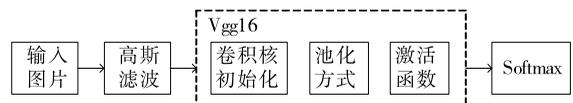


图 8 改进模型结构

Figure 8 Structure of improved model

core(TM) i5-8300H CPU @ 2.30GHZ,内存 8.00 GB,显卡 NVIDIA GeForce GTX 1050 的开发平台,采用 python + tensorflow + pycharm 作为开发环境。

4.2 试验结果及其分析

整个试验部分使用的数据集,如无特别说明都采用以下数据集,从构建的酒花数据集中选取头段酒花、中段酒花、末段酒花、酒尾酒花图片各 1 000 张。其中 70% 作为训练集,30% 作为测试集,图片大小为 544×960×3。

模型采用改进 Vgg16+迁移学习,图像输入要经过 5 次池化,由模型结构可以推出第 1,2,3,4,5 次池化的特征图个数分别为 64,128,256,512,512。由于篇幅有限文中展示第 1 次和第 5 次池化后的部分特征图,如图 9 所示。1:1 特征融合图,如图 10 所示。

由图 10 可知,最初卷积提取到的特征比较全面,图像纹理边缘信息比较清楚,随着卷积的深入,特征图越来越抽象。第 1 次池化后特征提取的信息比较全面,特征融合过后能够看见较清楚的花。第 5 次池化后图像变得模糊,高级特征肉眼不可见,特征融合后图像也比较抽象,肉眼基本无法看见酒花。

4.2.1 经典模型分类结果 为了验证现有经典模型对白酒酒花的分类效果,直接将预处理后的酒花图像输入到模型中,对其准确率和迭代步数进行比较。试验仿真结果如图 11 所示。

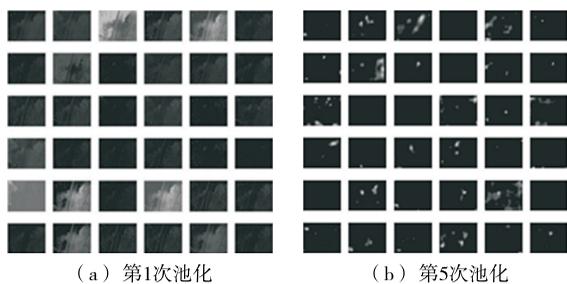
由图 11(a)可以看出,LeNet_5、AlexNet 网络深度浅,分别是 5 层和 8 层,在迭代次数较少的情况下就达到饱和,对于一些简单的分类任务能够达到很高的准确率。但酒花分类准确率远低于人工分类,达不到分类精度要求。由图 11(b)可以看出,随着卷积网络深度的加深,分类准确率逐渐提高,但仍然达不到酒花分类的精度要求,且相应的训练时间也变长。

4.2.2 基于改进池化方式的准确率对比 为验证改进池化方式的有效性,在传统 Vgg16 框架的基础上,改变不同的池化方式,验证其在白酒酒花分类的准确率。试验结果如图 12 所示。

单一的池化方式不能完全考虑图像特征信息,平均池化更多地保留了图像的背景信息,忽略了图像中的纹理信息,相反最大池化则更多地保留了纹理信息,因为酒花特征对纹理要求高,从图 12 可以看出最大池化的准确率略大于平均池化的。但两种方法对酒花分类准确率明显低于改进的池化方法,因为改进的方法综合考虑了背景与纹理信息。

4.2.3 基于改进激活函数的准确率对比 为验证改进激活函数的有效性,在传统 Vgg16 框架的基础上,使用不同的激活函数,验证其在白酒酒花分类的准确率。试验结果如图 13 所示。

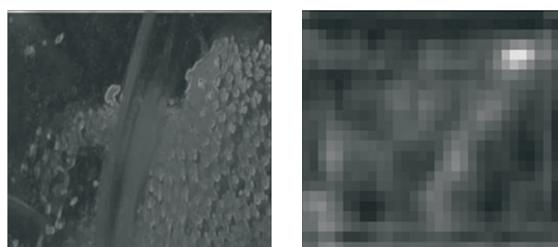
Sigmoid函数与Tanh函数容易产生梯度消失的情



(a) 第1次池化 (b) 第5次池化

图 9 池化后的特征图

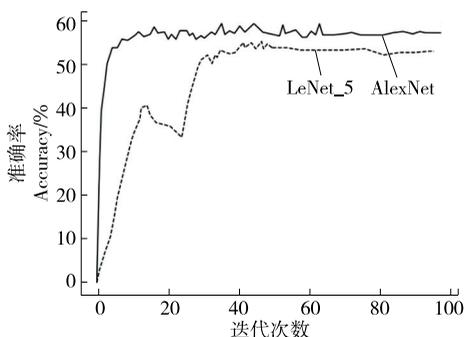
Figure 9 Pooled feature graph



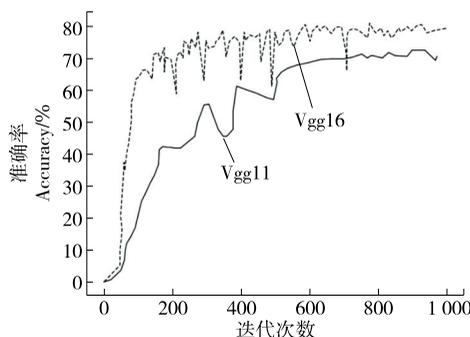
(a) 第1次池化 (b) 第5次池化

图 10 1:1 特征融合图

Figure 10 1:1 feature fusion graph



(a) LeNet_5与AlexNet准确率可视化



(b) Vgg11与Vgg16准确率可视化

图 11 经典模型分类结果

Figure 11 Classification results of classical model

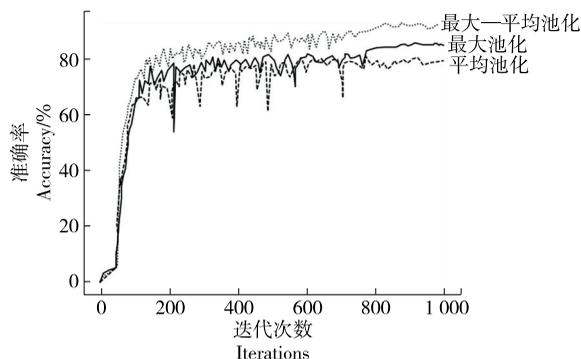


图 12 不同池化方式准确率对比

Figure 12 Comparison of accuracy of different pooling methods

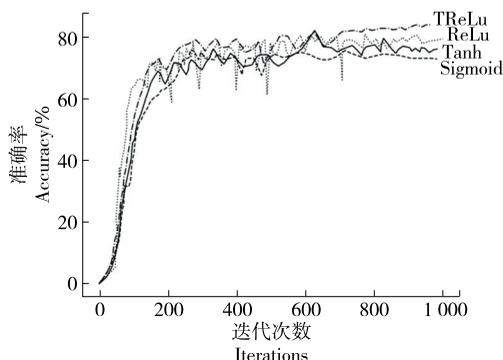


图 13 不同激活函数准确率对比

Figure 13 Comparison of accuracy of different activation functions

况,ReLU 函数在反向传播过程中会出现神经元死亡。从图 14 可以看出,改进的激活函数分类准确率高于其他几种激活函数。

4.2.4 最终模型与传统 Vgg16 模型准确率对比 最终模型结构包括 Vgg16 框架+迁移学习+改进池化方式+改进激活函数,为验证改进模型的有效性,将其与原始 Vgg16 模型进行对比。试验结果如图 14 所示。

从图 14 可以看出,基于 Vgg16 改进的卷积神经网络模型,对白酒酒花数据集分类准确率有明显的提升,未改进前分类准确率为 80.30%,改进后分类准确率为 96.69%,改进后的分类准确率能够达到白酒生产的实时性要求。改进模型与传统模型试验结果对比如表 4 所示。

从表 4 可以看出,LeNet_5、AlexNet 网络深度浅,训练时间短,分类准确率低,Vgg11 和 Vgg16 随着层数增加分类准确率明显提高,但训练时间较长,改进模型在分类准确率与训练时间取得了一个平衡,且分类准确率高于其他几种分类模型。

4.2.5 人工分类对比试验 从头段酒花、中段酒花、末段酒花、酒尾酒花分别选取 100 张组成人工分类和试验系

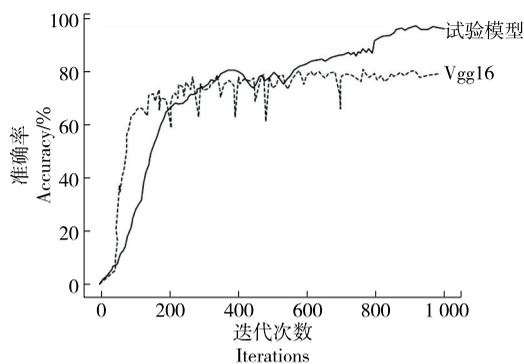


图 14 改进模型准确率

Figure 14 Accuracy of improved model

表 4 改进模型与传统模型试验结果对比

Table 4 Comparison of experimental results between improved model and traditional model

算法模型	网络层次	迭代次数	分类准确率/%	训练时间/min
LeNet_5	5	100	52.81	4.96
AlexNet	8	100	57.33	12.53
Vgg11	11	1 000	70.24	279.00
Vgg16	16	1 000	80.30	537.60
改进模型	16	1 000	96.69	394.80

统分类对比的数据集。将 400 张酒花图片的标签隐藏并且将图片随机排序,从生产线上请 2 位经验丰富的摘酒师傅 A 和 B,再请 2 位年轻的摘酒师傅 C 和 D 对此次试验数据集进行 2 次分类,第 1 次分类试验结果如表 5 所示。

第 2 次试验使用同样的数据集,告知 4 位摘酒师傅数据集已经改变,试验分类结果如表 6 所示。

从表 5 和表 6 可以看出,无论是人工分类还是试验系统分类在没有时间的要求下分类准确率基本都能达到 90% 以上;经验不同的员工分类准确率高低不同,同一工人在不同时间准确率也会有波动,人工分类具有不稳定性,而机器视觉的分类精度高且稳定,因此试验系统分类算法相比人工分类具有一定的优越性。

表 5 人工分类与系统分类准确率对比(第 1 次)

Table 5 Comparison of accuracy between manual classification and systematic classification (the first time)

酒花	人工分类				试验系统分类
	A	B	C	D	
头段酒花	92	94	87	89	99
中段酒花	93	91	86	86	98
末段酒花	95	96	95	92	98
酒尾酒花	97	99	98	94	99

表 6 人工分类与系统分类准确率对比(第 2 次)

Table 6 Comparison of accuracy between manual classification and systematic classification(the second time) %

酒花	人工分类				试验系统分类
	A	B	C	D	
头段酒花	92	92	86	89	99
中段酒花	93	92	86	86	98
末段酒花	94	98	93	92	98
酒尾酒花	97	99	97	94	99

使用上述数据集完成分类时间对比试验,结果如表 7 所示。

表 7 人工分类与系统分类(每张)耗时对比

Table 7 Comparison of classification time s

酒花	人工分类				试验系统分类
	A	B	C	D	
头段酒花	0.724	0.693	0.695	0.644	0.231
中段酒花	0.713	0.687	0.678	0.659	0.228
末段酒花	0.698	0.669	0.668	0.635	0.214
酒尾酒花	0.654	0.653	0.654	0.622	0.198

从表 7 可以看出,人工分类时间虽然有所不同但总体需要时间较多,分类一张图片大约需要 0.69 s,然而试验系统分类时间需要 0.22 s,因此试验分类系统能够达到白酒生产的实时性要求。

5 结论

试验提出的基于改进 Vgg16+迁移学习的分类模型,能够高效、精确地对不同类别的酒花进行分类。试验结果表明,该分类模型的准确率达 96.69%,比人工稳定性好且准确率高,具有较好的实用性。后续研究将继续提升白酒酒花分类的速度,进一步改进模型提高分类准确率,实现白酒生产摘酒智能。

参考文献

[1] 赵平. 一种自动化操作的白酒量质摘酒装置: CN206188782U[P]. 2017-05-04.
ZHAO Ping. An automatic baijiu quality liquor extraction device: CN206188782U[P]. 2017-05-04.

[2] 何盛国, 冯涛, 孙毅, 等. 温度、压力和酒精度控制量质摘酒装置: CN201210569678.2[P]. 2013-07-31.
HE Sheng-guo, FENG Tao, SUN Yi, et al. Temperature, pressure and alcohol control quality wine picking device: CN201210569678.2[P]. 2013-07-31.

[3] 范明明. 基于近红外技术的白酒摘酒在线检测装置开发[D]. 镇江: 江苏大学, 2019: 1-2.

FAN Ming-ming. Development of on-line detection device for Baijiu picking based on near infrared technology [D]. Zhenjiang: Jiangsu University, 2019: 1-2.

[4] 余锴鑫. 基于图像分类算法的自动化摘酒方法研究[D]. 杭州: 浙江大学, 2019: 15-20.
YU Kai-xin. Research on automatic wine picking method based on image classification algorithm[D]. Hangzhou: Zhejiang University, 2019: 15-20.

[5] 陈林, 庾兴国, 张贵宇, 等. 基于酒精度重建模型的摘酒技术研究[J]. 中国酿造, 2019, 38(3): 23-27.
CHEN Lin, TUO Xian-guo, ZHANG Gui-yu, et al. Study on wine picking technology based on wine precision reconstruction model[J]. China Brewing, 2019, 38(3): 23-27.

[6] 杨静娴, 任小洪. 基于图像处理的白酒酒花轮廓检测[J]. 食品与机械, 2019, 35(12): 52-55, 145.
YANG Jing-xian, REN Xiao-Hong. Image processing based Baijiu flower contour detection[J]. Food & Machinery, 2019, 35(12): 52-55, 145.

[7] 卢文龙. 浓香型白酒生产中感官检验方法的探讨[J]. 酿酒科技, 2007(3): 71-74.
LU Wen-long. Discussion on sensory examination methods in Luzhou flavor liquor production[J]. Liquor-making Science & Technology, 2007(3): 71-74.

[8] 李增胜. 汾酒看花接酒在今天的运用[J]. 酿酒科技, 1991(1): 28-29.
LI Zeng-sheng. The application of Fen Liquor in today's world[J]. Liquor-making Science & Technology, 1991(1): 28-29.

[9] 顾梅花, 王苗苗, 李立瑶, 等. 彩色图像多尺度融合灰度化算法[J]. 计算机工程与应用, 2021, 57(4): 209-215.
GU Mei-hua, WANG Miao-miao, LI Li-yao, et al. Multi scale grayscale fusion algorithm for color image [J]. Computer Engineering and Applications, 2021, 57(4): 209-215.

[10] 郭慧娟, 白文江, 岳云霄, 等. 去除图像椒盐噪声的自适应迭代均值滤波算法[J]. 太原学院学报(自然科学版), 2020, 38(3): 23-28.
GUO Hui-juan, BAI Wen-jiang, YUE Yun-xiao, et al. Adaptive iterative mean filtering algorithm for removing salt and pepper noise in images[J]. Journal of Taiyuan University (Natural Science Edition), 2020, 38(3): 23-28.

[11] 郭晓惠. 一种高效去除椒盐噪声机械零件图像算法[J]. 信息技术与信息化, 2020(10): 38-41.
GUO Xiao-hui. An efficient algorithm for removing salt and pepper noise from mechanical parts image[J]. Information Technology And Informatization, 2020(10): 38-41.

[12] 李俊峰. 改进高斯滤波算法的舰船尾迹图像无损去噪技术[J]. 舰船科学技术, 2020, 42(18): 37-39.
LI Jun-feng. Ship wake image lossless denoising technology based on Improved Gaussian filtering algorithm[J]. Ship Science and Technology, 2020, 42(18): 37-39.

(下转第 88 页)

优势,同时采用 PLC 与触摸屏设计的控制系统,工作稳定,效率高,在中小企业中具有较高的推广价值。

6 结论

文章设计的三轴机械手装箱工件站基于伺服控制器及数据变址的算法,能够有效地实现不同盒装食品的装箱,系统对不同盒子装箱的适应性强。在工作站投入使用前需对各个点位的数据进行示教,通过触摸屏在程序中进行预设置,并保存到 PLC 数据中。当工作站自动运行时,根据点位排序依次执行机械手的各个点位流程,能够快速有效地实现将盒装食品装入到相应的箱子中,从而实现盒装食品的装箱功能,系统操作简单,通用性较强。试验设计的装箱工作站作业需要传送带对产品进行导向,影响其动作效率的发挥,导向传送带的要求也较高,后续将引入视觉引导定位抓取,实现不同姿态下的抓取,以提高工作站装箱的智能化及更好的适用性。

参考文献

- [1] 郭会元. 精裱纸盒自动化生产线关键技术研究[D]. 合肥: 合肥工业大学, 2019: 5-8.
GUO Hui-yuan. Research on key technology of automatic production line of fine mounting carton[D]. Hefei: Hefei University of Technology, 2019: 5-8.
- [2] 王纯贤, 郭会元, 高世安, 等. 精裱纸盒自动装箱工作站设计与开发[J]. 现代制造工程, 2019(8): 114-119.
WANG Chun-xian, GUO Hui-yuan, GAO Shi-an, et al. Design and development of fine carton automatic packing workstation [J]. Modern Manufacturing Engineering, 2019(8): 114-119.
- [3] 句秋月, 贾志闻, 李小江. 基于 SIMOTION 的机器人装箱工艺包的开发[J]. 包装与食品机械, 2020, 38(5): 47-49, 54.
JU Qiu-yue, JIA Zhi-wen, LI Xiao-jiang. Development of robotic packing technology package based on SIMOTION [J]. Packaging and Food Machinery, 2020, 38(5): 47-49, 54.
- [4] 葛畅. 基于 PLC 的伺服装箱机控制系统的设计[J]. 包装与食品机械, 2019, 37(4): 40-42.
GE Chang. Design of servo boxing machine control system based on PLC[J]. Packaging and Food Machinery, 2019, 37(4): 40-42.

- [5] 张弘韬, 孙之尧. 智能化绿色快递包装设计研究[J]. 绿色包装, 2021(4): 59-62.
ZHANG Hong-tao, SUN Zhi-yao. Research on intelligent green express packaging design[J]. Green Packing, 2021(4): 59-62.
- [6] 陈落根, 贾志闻, 朱俏俏, 等. 袋装奶粉自动装箱机的设计与研究[J]. 包装与食品机械, 2019, 37(5): 34-37.
CHEN Luo-gen, JIA Zhi-wen, ZHU Qiao-qiao, et al. Design and research of automatic packing machine for bagged milk powder[J]. Packaging and Food Machinery, 2019, 37(5): 34-37.
- [7] 韩基伟, 孟钢钳. Delta 机构的装箱机器人的工作空间及轨迹规划[J]. 食品工业, 2021, 42(3): 216-219.
HAN Ji-wei, MENG Gang-qian. Workspace and trajectory planning of boxed robots based on delta mechanism[J]. Food Industry, 2021, 42(3): 216-219.
- [8] 陈锐鸿. 基于 PLC 控制的多工位码垛系统设计与实现[J]. 包装工程, 2018, 39(17): 159-164.
CHEN Rui-hong. Design and implementation of multi-station palletizing system based on PLC control[J]. Packaging Engineering, 2018, 39(17): 159-164.
- [9] 杜建, 冯渝, 朱学建, 等. 基于运动控制器的立式袋装箱机控制系统设计[J]. 食品与机械, 2017, 33(3): 93-95.
DU Jian, FENG Yu, ZHU Xue-jian, et al. Design of control system for vertical bag packing machine based on motion controller[J]. Food & Machinery, 2017, 33(3): 93-95.
- [10] 刘长生, 单葆虹, 邵思程. 小型袋装食品自动装箱机器人设计及运动仿真[J]. 信息记录材料, 2019, 20(12): 180-181.
LIU Chang-sheng, SHAN Bao-hong, SHAO Si-cheng. Design and motion simulation of small automatic packing robot for bagged food[J]. Information Recording Materials, 2019, 20(12): 180-181.
- [11] 管树龙. 数控车床自动上下料机械手结构设计[J]. 内燃机与配件, 2021(7): 75-77.
GUAN Shu-long. Structure design of automatic loading and unloading manipulator for CNC lathe[J]. Internal Combustion Engine & Parts, 2021(7): 75-77.
- [12] 陈锐鸿, 谭兆湛. 变速箱齿轮啮合测试机上下料机械手设计[J]. 机床与液压, 2020, 48(3): 41-46.
CHEN Rui-hong, TAN Zhao-zhan. Design of loading and unloading manipulator for gearbox gear meshing tester[J]. Machine Tool & Hydraulics, 2020, 48(3): 41-46.

(上接第 37 页)

- [13] 秦敏. 基于深度学习的花卉图像分类识别模型研究[D]. 桂林: 广西师范大学, 2020: 12-15.
QIN Min. A study on the classification and recognition model of flower images based on deep learning[D]. Guilin: Guangxi Normal University, 2020: 12-15.
- [14] 谭涛. 基于卷积神经网络的随机梯度下降优化算法研究[D]. 重庆: 西南大学, 2020: 13-19.
TAN Tao. Research on stochastic gradient descent optimization algorithm based on convolutional neural network[D]. Chongqing: Southwest University, 2020: 13-19.

- [15] 吕恩辉, 王雪松, 程玉虎. 基于反卷积特征提取的深度卷积神经网络学习[J]. 控制与决策, 2018, 33(3): 447-454.
LU En-hui, WANG Xue-song, CHENG Yu-hu. Deep convolution neural network learning based on deconvolution feature extraction[J]. Control and Decision, 2018, 33(3): 447-454.
- [16] 王锦, 赵德群, 邓钱华, 等. 基于自适应动量因子的 BP 神经网络优化方法研究[J]. 现代信息科技, 2019, 3(7): 11-13.
WANG Jin, ZHAO De-qun, DENG Qian-hua, et al. Optimization method of BP neural network based on adaptive momentum factor[J]. Modern Information Technology, 2019, 3(7): 11-13.