

陈舒迪, 柴琴琴, 张 勋, 等. 基于多特征融合和 LightGBM 的金线莲品系识别[J]. 江苏农业学报, 2021, 37(1): 155-162.
doi: 10.3969/j.issn.1000-4440.2021.01.020

基于多特征融合和 LightGBM 的金线莲品系识别

陈舒迪^{1,2}, 柴琴琴^{1,2}, 张 勋³, 黄泽豪³, 林 羽³, 徐 伟³

(1. 福州大学电气工程与自动化学院, 福建 福州 350108; 2. 福建省医疗器械和医药技术重点实验室, 福建 福州 350108; 3. 福建中医药大学药学院, 福建 福州 350122)

摘要: 金线莲是中国珍稀中草药, 不同品系的金线莲具有细微的形态差异和显著的药效差异。针对金线莲的单一特征贡献能力不足以及传统分类器泛化能力不佳的问题, 提出使用形状、颜色和纹理特征对金线莲叶片图像进行特征提取与融合, 再使用表现性能更优的 LightGBM(轻量级梯度提升机)构建分类器, 以提高金线莲识别正确率。LightGBM 具有精确高效等优点, 将提取得到的高层次特征导入 LightGBM 进行训练预测, 可以有效提高分类准确性。对金线莲数据集中的 6 个品系共 368 幅叶片图像进行试验, 结果表明, 相比于传统的分类方法, 基于多特征融合和 LightGBM 的模型识别效果最好, 10 次随机试验的平均识别率比传统方法 KNN、SVM 和 GBDT 高, 并且在分类评价指标精确率、召回率、综合评价指标上有较优表现, 该研究结果可为中药材品系识别提供参考。

关键词: 金线莲; 多特征融合; LightGBM; 叶片识别

中图分类号: TP391 **文献标识码:** A **文章编号:** 1000-4440(2021)01-0155-08

Identification of *Anoectochilus roxburghii* strains based on multi feature fusion and LightGBM

CHEN Shu-di^{1,2}, CHAI Qin-qin^{1,2}, ZHANG Xun³, HUANG Ze-hao³, LIN Yu³, XU Wei³

(1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China; 2. Ministry of Education Key Laboratory of Medical Instrument and Pharmaceutical Technology, Fuzhou University, Fuzhou 350108, China; 3. College of Pharmacy, Fujian University of Traditional Chinese Medicine, Fuzhou 350122, China)

Abstract: *Anoectochilus roxburghii* is a rare Chinese herbal medicine, different strains of *A. roxburghii* have slight morphological difference and significant variance in medicinal effects. To solve the problems of insufficient contribution ability of single-feature in *A. roxburghii* and poor generalization ability of traditional classifiers, it was proposed to use shape, color and texture features to extract and fuse features of *A. roxburghii* leaf images. Then LightGBM (light weight class elevator) with a better performance was used in building classifier, so as to improve the recognition accuracy of *A. roxburghii*. LightGBM had the advantages of accurate and efficient, and the prediction accuracy could be improved effectively by importing the extracted high-level features into LightGBM to forecast the training. A total of 368 leaf images from six strains of *A. roxburghii* dataset were trained and tested. The results showed that model based on multi-feature fusion and LightGBM had

the best recognition effect compared with traditional classification methods. The average recognition rate of ten random experiments was higher than traditional methods such as KNN, SVM and GBDT, and it showed good performance in classification evaluation indices like precision, recall rate and comprehensive evaluation index. The result can provide reference for the identification of different strains of traditional Chinese medicine.

收稿日期: 2020-06-02

基金项目: 福建省科技厅重大产学研项目(2019Y4009); 晋江市福大科教园区发展中心科研项目(2019-JJFDKY-48)

作者简介: 陈舒迪(1997-), 女, 福建南平人, 硕士研究生, 主要从事机器学习与图像处理研究。(E-mail) chshud@163.com

通讯作者: 柴琴琴, (E-mail) qq.chai@fzu.edu.cn; 林 羽, (E-mail) ly-fjtem@163.com

Key words: *Anoectochilus roxburghii*; multi feature fusion; LightGBM; leaf recognition

金线莲属于兰科开唇兰属植物^[1-2],含糖类、多种氨基酸及无机元素等,常用于糖尿病、肺热咳嗽、急慢性肝炎等疾病的治疗^[3-4]。由于金线莲药用价值高、市场需求量大,而野生金线莲的繁殖率低、生存条件受限等原因,导致目前市场上销售的金线莲基本是人工栽培的。不同品系的金线莲虽外观相似但生物产量积累和药用化合物组成有着很大的差异,市面上以低药用价值的金线莲冒充优质品系的金线莲的现象尤为常见。因此,金线莲品系识别是选择优质品系的重要依据,如何精确高效地对金线莲品系进行识别有着重要的意义。

常用的金线莲品系鉴别方法有中药鉴定法、解剖学法和近红外光谱检测法等^[5-8],这些传统方法存在主观性强、效率低、正确率低和操作复杂等缺陷,而基于机器视觉^[9]的植物品系识别技术具有速度快、准确率高和操作方便等优点,因此使用计算机进行植物品系识别受到了越来越多的关注。机器视觉可获得不同品系金线莲植株的颜色^[10]、形状^[11]和纹理^[12]等遗传信息,其中叶片数据最易采集且具有较长存活期,故以金线莲叶片作为研究对象,提取其颜色、形状和纹理特征,并将 3 种特征加以融合以进行识别。然而,不同品系的金线莲叶片图像十分相似,识别难度大,因此如何基于获得的图像特征,构建合适的分类器对采集的叶片图像进行进一步品系识别仍是具有挑战性的问题。

在分类器的选择上,传统的机器算法,如支持向量机(SVM)^[13]、最近邻分类器(KNN)^[14]、决策树(DT)^[15]及逻辑回归(LR)^[16]等在植物图像识别上应用广泛,但上述分类器的应用仍具有局限性,由于金线莲脉纹复杂、种类繁多,这些传统的分类方法在金线莲数据集上的表现也差强人意。深度学习^[17]算法具有覆盖范围广、学习能力强和特征提取方便等特点,Dyrmann 等^[18]基于 Keras 学习框架使用卷积神经网络对 10 413 幅旱田杂草图像进行识别,取得了较好的识别效果;邓向武等^[19]将深度置信网络应用于稻田杂草图像的检测和分类,识别正确率为 91.13%。然而直接通过原图像构建深度学习模型通常需要大量的标记样本,且训练时间太长;在处理小样本数据集时深度学习算法往往需要对数据集进行扩充,易出现精度低、过拟合等问题。考虑到本研

究样本数量、分类品系不多和普通计算机硬件资源有限等问题,本研究提出用轻量级梯度提升机(Light gradient boosting machine, LightGBM)^[20]作为分类模型。LightGBM 是一种基于梯度提升树(Gradient boosting decision tree, GBDT)的提升算法,比起传统的 GBDT 算法,LightGBM 通过直方图优化对连续特征值进行分段处理,可以节省内存并加快运行速度,决策树通过 Leaf-wise 的叶子生长策略进行生长,限制树的深度防止过拟合,能够有效提高模型预测的准确率。Wang 等^[21]将 LightGBM 用于乳腺肿瘤的分类和诊断,并使用模型 RF、XGBoost 和 LightGBM 分别对样本进行分类识别,试验结果表明,LightGBM 模型的分类精度最高。Zhang 等^[22]将 LightGBM 用于化学毒性预测,在所有 Tox21 (21 世纪毒理学测试)和致突变性数据集上,与其他分类算法相比,LightGBM 提供了最佳的预测性能。目前,LightGBM 分类算法鲜被用于植物图像识别中。

综上所述,针对不同品系金线莲叶片差异不明显、复杂生长环境下不同品系金线莲叶片形态多变等因素引起的品系鉴别困难,本研究提出了基于多特征融合和 LightGBM 的金线莲品系识别。对提取得到的特征进行融合,解决了金线莲叶片单一特征贡献能力不足的缺点,通过 LightGBM 分类器进行预测,解决了传统机器学习算法识别效果不佳的问题。

1 样本预处理及特征提取

1.1 图像预处理

在试验研究阶段,所用金线莲样品均采自福建葛园生物科技有限公司,为金线莲成熟期叶片,采集 6 个品系的金线莲叶片,共 368 个样本,在实验室环境下用尼康单反数码相机(型号为 NIKON D7100)获取金线莲叶片图像。其中台湾金线莲图像 69 幅、红霞图像 70 幅、小圆叶图像 50 幅、尖叶图像 58 幅、一株圆叶图像 66 幅、大圆叶图像 55 幅,采集的金线莲各品系代表图像如图 1 所示。

针对获取的金线莲叶片图像,在进行特征提取和识别之前先对其进行预处理,突出叶片图像中的有效特征,削弱噪声和虫洞的影响。将金线莲叶片图像转换成灰度图像,接着使用中值滤波对灰度图像进行去噪处理,增强叶片的目标信息,之后使用形态学膨胀

和腐蚀方法对叶片虫洞进行填充,并将叶柄与叶面分割,最后选取自适应阈值确定的大津法获取叶片二值

图像,将二值图像和金线莲叶片原始图像通过掩膜操作,获得金线莲叶片前景图像(图 2)。




图 1 金线莲各品系叶片代表图像

Fig.1 Representative images of leaves from all strains of *Anoectochilus roxburghii*

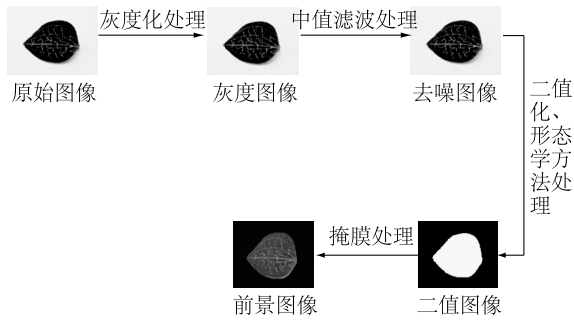


图 2 金线莲叶片图像预处理过程

Fig.2 Image preprocessing of *Anoectochilus roxburghii* leaves

1.2 金线莲叶片特征提取

在人工智能时代,特征数据决定了机器学习的上限,特征数据是否有效是识别模型作用能否发挥到极致的重要前提^[23]。如果从金线莲叶片图像中提取到的特征数据含有大量品系差异信息,那么识别模型的识别性能将会大大提高。本研究从金线莲叶片图像中提取 23 维形状特征、18 维颜色特征和 75 维纹理特征,共 116 维特征,作为表征金线莲品系差异的主要特征。

1.2.1 形状特征 形状特征是图像识别中广泛应用的重要特征,由图 1 可以看出,不同品系的金线莲叶片存在一定的形态差异。本研究选择 16 维傅里叶特征以及 7 维 HU 不变矩特征共 23 维特征作为金线莲叶片的形状特征。

1.2.1.1 傅里叶描述子 傅里叶描述子只需通过少量的描述子即可大致代表整个金线莲叶片的轮廓^[24]。将傅里叶描述子归一化后,提取到的形状特征可以不受轮廓在图像中的位置、大小和角度的影响,具有良好的鲁棒性。傅里叶描述子用 1 个总长度为 N 的离散的坐标序列 $\{x(n), y(n) | n=0, 1, \dots,$

$N-1\}$ 来表示金线莲的闭合轮廓,坐标序列使用复数形式表示,如公式(1)所示:

$$z(n) = x(n) + jy(n), n=0, 1, \dots, N-1 \quad (1)$$

通过傅里叶变换可得 $a(u)$:

$$a(u) = \frac{1}{K} \sum_{k=0}^{K-1} S(K) e^{-j2\pi uk/K} \quad (2)$$

对 $a(u)$ 进行傅立叶反变换可获得金线莲叶片的边缘系数,本研究通过选取 16 个边缘系数来描述金线莲叶片轮廓。

1.2.1.2 HU 不变矩 HU 不变矩通过统计矩计算得到,常被用来表示图像的形状特征^[25]。对于灰度分布为 $f(x, y)$ 的图像,该图像的 HU 不变矩 $(p+q)$ 阶统计量的定义为:

$$m_{pq} = \iint x^p y^q f(x, y) dx dy \quad (3)$$

其中 $p, q=0, 1, 2, \dots, (p+q)$ 阶中心矩定义为:

$$\mu_{pq} = \iint (x-x_0)^p (y-y_0)^q f(x, y) dx dy \quad (4)$$

其中矩心为: $x_0 = \frac{m_{10}}{m_{00}}, y_0 = \frac{m_{01}}{m_{00}}$, 通过公式(5)计

算可得归一化中心矩:

$$\gamma_{pq} = \frac{\mu_{pq}}{\mu_{00}^r} \quad (5)$$

式中: $r = \frac{p+q+2}{2}, p, q=0, 1, 2, \dots$, 本研究通过二

阶和三阶归一化中心矩共构造 7 个 HU 不变矩。

1.2.2 颜色特征 颜色特征是彩色图像中最显著的特征,常用于描述颜色特征的方法有颜色矩、颜色聚合向量和颜色集等^[26]。本研究通过颜色矩来提取颜色特征,共提取了 18 维特征,分别是 RGB (红-绿-蓝)、HSV (色调-饱和度-明度) 颜色空间的 R、G、B、H、S 和 V 6 个分量的均值、方差和斜度,均值 (M_{11})、方差 (M_{12}) 和斜度 (M_{13}) 的计算方法如公式(6)~公式(8)所示:

$$M_{i1} = \frac{1}{N} \sum_{j=1}^N P_{ij} \quad (6)$$

$$M_{i2} = \left[\frac{1}{N} \sum_{j=1}^N (P_{ij} - M_{i1})^2 \right]^{1/2} \quad (7)$$

$$M_{i3} = \left[\frac{1}{N} \sum_{j=1}^N (P_{ij} - M_{i1})^3 \right]^{1/3} \quad (8)$$

式中, P_{ij} 为图像中灰度为 j 的像素在第 i 个颜色通道分量中出现的概率, N 为图像中所有像素的个数。

1.2.3 纹理特征 纹理特征描述了物体局部特征的周期性变化及排列规则, 本研究根据金线莲叶片纹理特征分别使用灰度共生矩阵 (GLCM) [27] 和圆形 LBP (CLBP) 方法 [28] 对叶片图像进行纹理特征提取, 共得到 75 维纹理特征。

1.2.3.1 灰度共生矩阵 灰度共生矩阵通过计算像素之间不同灰度值组合出现的次数来反映纹理信息。本研究通过计算金线莲叶片图像 4 个方向 (0° , 45° , 90° , 135°) 的 4 个 GLCM 关键特征 [对比度 (Con)、能量 (Ent)、熵 (Asm) 和相关性 (Idm)], 共可提取得到 16 个特征值。4 个关键特征的计算方法如公式 (9) ~ 公式 (12) 所示:

$$Con = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i-j)^2 P(i, j) \quad (9)$$

$$Ent = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P(i, j) \log_2 [P(i, j)] \quad (10)$$

$$Asm = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P(i, j)^2 \quad (11)$$

$$Idm = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{P(i, j)}{1 + (i-j)^2} \quad (12)$$

式中 $P(i, j)$ 为归一化后的灰度共生矩阵, N 为灰度级数。

1.2.3.2 圆形 LBP LBP 是一种常用的纹理描述方法, 具有计算简单、速度快和旋转不变性等特点。然而传统 LBP 算子提取的是固定领域内的灰度值, 当图像的比例发生改变时, 传统 LBP 特征将无法正确地反映纹理信息。故本研究使用圆形 LBP 算子来描述纹理特征, 圆形 LBP 可适应图像不同尺度的变换, 使用灵活的圆形邻域代替固定的 3×3 正方形邻域, 可设置得到采样点为 P 、半径为 R 的圆形 LBP 算子。对于 1 个点 (X_c, Y_c) , 它邻近的 (X_a, Y_a) $a \in P$ 的计算公式如公式 (13)、公式 (14) 所示:

$$X_a = X_c + R \cos\left(\frac{2\pi a}{P}\right) \quad (13)$$

$$Y_a = Y_c - R \sin\left(\frac{2\pi a}{P}\right) \quad (14)$$

式中, R 为所设置的圆形领域的半径, P 为采样点的个数。中心为 (X_c, Y_c) 的 LBP 值计算方法如公式 (15)、公式 (16) 所示:

$$S(g_a - g_c) = \begin{cases} 1 & g_a \geq g_c \\ 0 & g_a < g_c \end{cases} \quad (15)$$

$$LBP(X_c, Y_c) = \sum_{a=0}^{P-1} 2^a S(g_a - g_c) \quad (16)$$

本研究共设置 8 个采样点, 共产生二进制形式的 LBP 值 $2^8 = 256$ 种, 由于太大的特征维度会影响特征融合后其他特征的描述效果, 故使用 Uniform 降维方法 [29] 对采样得到的特征进行降维处理, 特征由 256 维降至 59 维。

2 金线莲品类识别模型

2.1 梯度提升树 (GBDT) 原理

梯度提升 (Gradient boosting) 是一种常用的机器学习算法, 常被用于回归和分类任务。梯度提升通过目前模型的残差来对新的弱分类器进行训练, 之后将训练好的弱分类器不断累加到现有模型中, 保证损失函数不断减小。假设 $f_i(x)$ 为弱分类器, 得到最终强分类器为:

$$F_m(X) = a_0 f_0(x) + a_1 f_1(x) + \dots + a_i f_i(x) + \dots + a_m f_m(x) \quad (17)$$

决策树 (Decision tree) 为树形结构的分类方法。从决策树的根节点开始进行决策, 其中的每个内部节点代表 1 个划分标准, 每个分支代表 1 个划分结果。

GBDT 将梯度提升思想和决策树思想相融合, 以决策树为弱分类器, 通过多轮迭代, 不断减小损失。在迭代过程中, 逐步增加弱分类器, 最后将训练好的各个弱分类器的结果进行集成, 从而得出最终的预测结果, GBDT 训练过程如图 3 所示。

2.2 LightGBM

2.2.1 直方图优化 LightGBM 是 GBDT 算法的一种改进, LightGBM 没有使用传统的预排序思想, 而是对特征值进行直方图优化。直方图优化首先对特征数据进行“装箱处理”, 得到 n 个“桶”。之后对数据进行遍历, 将离散化后的值作为索引在直方图中的每个“桶”中进行累计, 遍历完成后, 就可以得到每个“桶”的统计量, 直方图统计过程如图 4 所示。比起传统的预排序思想, 直方图优化只需保存特征离散化后的值, 明显降低了内存的损耗, 加快了训练速度。

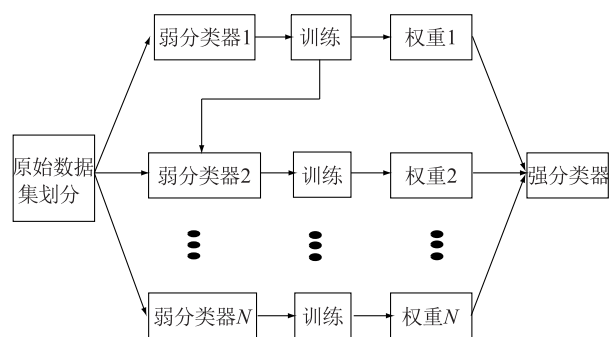


图3 GBDT 训练过程

Fig.3 GBDT training process

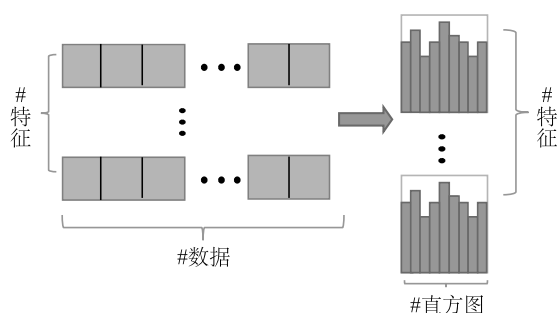


图4 直方图优化

Fig.4 Optimization of histogram

2.2.2 叶子生长策略 为了提高模型训练的效率, LightGBM 选择 Leaf-wise 作为叶子生长策略,传统的 GBDT 算法通常使用 Level-wise 叶子生长策略,Leaf-wise 和 Level-wise 的对比如图 5 所示。由图 5 可见, Level-wise 叶子生长策略每次分裂需要对同一层的所有叶子同时进行分裂,因此在很多叶子上进行了不必要的分裂和搜索,而 Leaf-wise 每次分裂只对分裂增益最大的 1 个叶子进行分裂,避免不必要的分裂和搜索,可以达到提升分类精度的目的。但 Leaf-wise 可能会产生 1 棵过深的决策树,使结果过拟合,因此 LightGBM 在 Leaf-wise 叶子分裂策略的基础上增加了决策树最大深度的限制,最大程度避免了过拟合。

2.3 识别模型

为训练 LightGBM 识别模型,本研究选取 70% 的金线莲叶片特征数据用作训练样本,30% 的特征数据用作测试样本,识别模型如图 6 所示。

识别流程如下:

(1) 特征提取及融合:对 6 个品系共 368 幅金线莲叶片图像分别提取形状、颜色和纹理特征,通过融合,共提取得到 116 维特征。




图5 Leaf-wise 和 Level-wise 对比

Fig.5 Comparison of leaf growth strategies between Leaf-wise and Level-wise

(2) 数据集划分:本研究从 368 个数据样本中选择 258 个数据样本作为训练样本,将剩下的 110 个数据作为测试样本。

(3) 训练过程:

(a) 初始化决策树棵数为 m , 训练样例权重为 $1/m$; 初始化迭代次数 $i_{\text{ter}} = 1$, 设置最大迭代次数 i_{max} ;

(b) 根据样例特征直方图计算各个切分点,并寻找最优分割点;再采用带有深度限制的 Leaf-wise 叶子生长策略训练每棵决策树 $f_i(x)$;

(c) 根据误差确定当前弱分类器的话语权 a_i ;

(d) 按公式(17)合并基分类器为强分类器;

(e) 若训练误差或者最大迭代次数满足要求则停止训练,转步骤(4); 否则 $i_{\text{ter}} = i_{\text{ter}} + 1$, 转步骤(b);

(4) 预测过程:使用训练后的 LightGBM 识别模型对测试集进行预测,并获得识别结果。

2.4 试验结果及分析

本试验均在 pycharm 环境下进行,试验所用电脑为 Windows 10 系统,配备 4 GB 内存,处理器为英特尔第七代酷睿 i5-7200U@2.50 GHz。为了研究基于多特征融合和 LightGBM 的识别模型的识别性能,本研究基于融合特征分别构建 KNN、SVM、GBDT 和 LightGBM 识别模型,统计金线莲品系识别正确率。并且为了避免识别结果的不确定性,数据集划分的随机数种子是由系统随机给出的,重复测试 10 次,4 种分类器的 10 次试验分类结果如图 7 所示。

考虑到寻优算法在寻优过程中所需要的时间和模型的自适应等原因,本研究所用的 4 种识别模型 KNN、SVM、GBDT 和 LightGBM 在试验过程中均未对参数进行优化,4 种识别模型均选择合理参数。从图 7 可知:将 3 种特征进行融合后,LightGBM 分类器 10 次试验的平均正确率高于其他分类器,由于

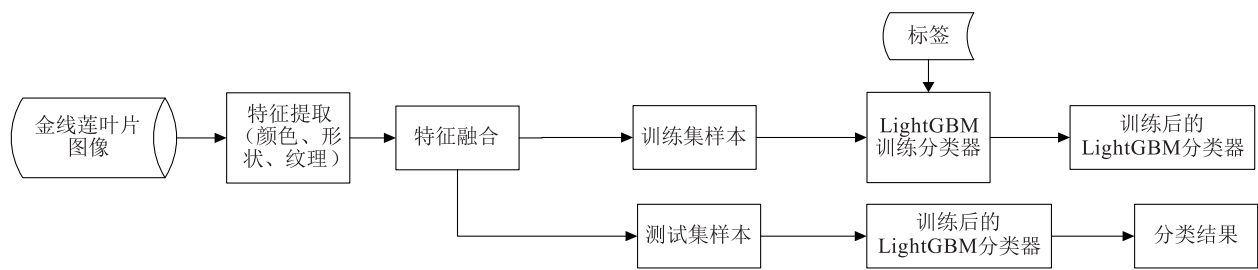


图 6 金线莲品系识别模型
Fig.6 Identification model of *Anoectochilus roxburghii* strains




图 7 4 种分类器的 10 次试验分类结果比较
Fig.7 Comparison of classification results of ten experiments based on four kinds of classifiers

SVM 分类模型对于小样本数据的识别效果比较好,故通过网格寻优算法对 SVM 模型进行参数寻优,10 次随机试验平均正确率为 88.20%,正确率仍然低于未寻优的 LightGBM 模型,体现了 LightGBM 识别模型良好的性能。为验证特征融合的有效性,基于颜色、形状和纹理单一特征分别构建 KNN、SVM、GBDT 和 LightGBM 识别模型,统计不同分类器和不同特征的金线莲品系识别率,随机进行 10 次试验,取平均值,结果如表 1 所示。

表 1 不同特征和不同分类器下的分类识别率
Table 1 Recognition rate of different classifiers under different features

特征类型	特征数量 (个)	识别率 (%)			
		GBDT	KNN	SVM	LightGBM
颜色特征	18	78.83	74.14	75.85	77.75
形状特征	23	58.11	55.41	59.82	60.00
纹理特征	75	67.84	67.03	55.86	68.47
融合特征	116	87.57	77.21	85.41	91.08

由表 1 可以看出,在金线莲品系识别中,叶片颜

色特征对识别率贡献最大,将所有特征进行融合后识别率有很大的提升,识别率高于任意单一特征向量,证明了对特征进行融合的有效性。除基于单一颜色特征的 LightGBM 识别模型的识别率略低于 GBDT 识别模型外,基于单一形状特征、单一纹理特征和融合特征的 LightGBM 识别模型的识别率均高于 GBDT、KNN 和 SVM 识别模型,充分体现了 LightGBM 识别模型性能的优越性。

此外,本研究使用常见识别性能度量指标精确率、召回率和综合评价指标来评价识别模型,LightGBM 对各个金线莲品系的识别性能度量指标如表 2 所示。

表 2 LightGBM 识别模型评价结果
Table 2 Performance evaluation results of the LightGBM model

品系	样本数 (幅)	精确率 (%)	召回率 (%)	综合评价指标 (%)
台湾金线莲	69	95.00	90.48	92.68
红霞	70	80.77	100.00	89.36
小圆叶	50	100.00	86.67	92.86
尖叶	58	93.75	88.24	90.91
一株圆叶	66	94.74	90.00	92.31
大圆叶	55	94.12	94.12	94.12

从表 2 数据可得,除红霞由于与尖叶的叶片特征相似度太高,精确率只有 80.77% 以外,其他各个品系的精确率、召回率、综合评价指标均在 85.00% 以上,可见基于多特征融合和 LightGBM 的模型在分类评价指标方面有较优表现。

综上所述,本研究提出的方法对金线莲叶片特征的表述更加准确,对金线莲数据集的识别率达 91.08%,取得了较好的识别效果。

3 结 论

本研究从金线莲叶片图像的单一特征贡献能力不足以及传统分类器泛化能力不佳引起的金线莲品系识别问题出发,研究基于机器视觉的金线莲品系识别问题,提出了基于多特征融合和 LightGBM 的金线莲品系识别方法。对金线莲叶片图像进行预处理后,分别从叶片颜色、形状和纹理 3 个方面共提取 116 维特征,并对特征进行融合,构建了基于 LightGBM 的分类模型,对金线莲进行品系识别,并与传统分类算法 GBDT、KNN 和 SVM 进行比较。结果表明,基于多特征融合和 LightGBM 的金线莲品系识别方法能够有效提取金线莲叶片特征,具有良好的鲁棒性,能够快速识别不同品系的金线莲。但本研究依然具有局限性,研究所用金线莲叶片图像数据集均为实验室环境下采集得来,叶片特征提取相对简单,如何处理复杂背景下的叶片图像,在复杂环境下对植物叶片进行识别,将是下一步研究的重点。

参考文献:

- [1] 王 勇,陈 硕,卢端萍,等.金线莲化学成分的研究[J]. 中草药, 2017(13):36-41.
- [2] 何春年,王春兰,郭顺星,等. 福建金线莲的化学成分研究 II [J]. 中国中药杂志, 2005, 39(10): 581-582.
- [3] 马玉芳,郑小香,衣伟萌,等. 金线莲多糖对免疫抑制小鼠脾淋巴细胞体外增殖、分泌 NO 及细胞因子的影响[J]. 天然产物研究与开发, 2018,30(1):21-26.
- [4] 李 芹,周 文,刘 路,等. 金线莲喷雾剂治疗手足口病口腔溃疡临床观察[J]. 福建中医药, 2012, 43(3):9-10.
- [5] 肖雪洋. 植物叶片图像识别特征的研究和在线识别系统实现 [D]. 合肥:中国科学技术大学,2011.
- [6] 蔡 超. 金线莲的鉴别与应用[J]. 中国中医药现代远程教育, 2016, 14(21):123-124, 127.
- [7] 蔡文燕,肖华山,范秀珍. 金线莲研究进展(综述)[J]. 亚热带植物科学, 2003(3):69-73.
- [8] 王海阁,许 文,张 勋,等. 林下栽培金线莲的生药鉴别[J]. 中药材, 2020, 43(2):303-308.
- [9] TAO O, LIN Z, ZHANG X B, et al. Research on identification model of chinese herbal medicine by texture feature parameter of transverse section image[J]. World Science and Technology-Modernization of Traditional Chinese Medicine, 2014(12):2558-2562.
- [10] 沈宝国,陈树人,尹建军,等. 基于颜色特征的棉田绿色杂草图像识别方法[J]. 农业工程学报, 2009, 25(6):163-167.
- [11] HERRERA P J, DORADO J, RIBEIRO Á. A novel approach for weed type classification based on shape descriptors and a fuzzy decision-making method[J]. Sensors, 2014(14):15304-15324.
- [12] TURKOGLU M, HANBAY D. Leaf-based plant species recognition based on improved local binary pattern and extreme learning machine[J]. Physica A: Statistical Mechanics and its Applications, 2019, 527: 121297.
- [13] PAL M, FOODY G M. Feature selection for classification of hyperspectral data by SVM[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(5): 2297-2307.
- [14] ZHANG S C, LI X L, ZONG M, et al. Learning k for kNN classification[J]. ACM Transactions on Intelligent Systems and Technology, 2017, 8(8):1-19.
- [15] KIM S Y, UPNEJA A. Predicting restaurant financial distress using decision tree and AdaBoosted decision tree models[J]. Economic Modelling, 2014, 36(1): 354-362.
- [16] FAGERLAND M W, HOSMER D W, BOFIN A M. Multinomial goodness-of-fit tests for logistic regression models[J]. Statistics in Medicine, 2008, 27(21): 4238-4253.
- [17] HAN J, ZHANG D, CHENG G, et al. Advanced deep-learning techniques for salient and category-specific object detection: a survey[J]. IEEE Signal Processing Magazine, 2018, 35(1):84-100.
- [18] DYRMANN M, KARSTOFT H, MIDTIBY H S, et al. Plant species classification using deep convolutional neural network[J]. Biosystems Engineering, 2016, 151:72-80.
- [19] 邓向武,齐 龙,马 旭,等. 基于多特征融合和深度置信网络的稻田苗期杂草识别[J]. 农业工程学报, 2018, 34(14):173-180.
- [20] KE G, MENG Q, FINLEY T, et al. Lightgbm: a highly efficient gradient boosting decision tree[C]//Ulrike von Luxburg, Isabelle Guyon. Proceedings of the 31st International Conference on Neural Information Processing SystemsDecember. San Diego, CA: Neural Information Processing Systems Foundation, 2017: 3146-3154.
- [21] WANG D H, ZHANG Y, ZHAO Y. LightGBM: an effective miRNA classification method in breast cancer patients [C]// Association for Computing Machinery.Proceedings of the 2017 International Conference on Computational Biology and Bioinformatics. New York: Association for Computing Machinery, 2017: 7-11.
- [22] ZHANG J, MUCS D, NORINDER U, et al. LightGBM: an effective and scalable algorithm for prediction of chemical toxicity-application to the Tox21 and mutagenicity data sets [J]. Journal of Chemical Information & Modeling, 2019, 59(10):4150-4158.
- [23] POST F H, VROLJK B, HAUSER H, et al. The state of the art in flow visualisation: feature extraction and tracking[J]. Computer Graphics Forum, 2010, 22(4):775-792.
- [24] 胡维炜,张 武,刘连忠,等. 利用图像处理技术计算大豆叶片相对病斑面积[J]. 江苏农业学报, 2016, 32(4):774-779.
- [25] WANG X F, HUANG D S, DU J X, et al. Classification of plant leaf images with complicated background[J]. Applied Mathematics and Computation, 2008, 205(2): 916-926.

-
- [26] HWANG W, WANG H T, KIM H, et al. Face recognition system using multiple face model of hybrid fourier feature under uncontrolled illumination variation[J]. IEEE Transactions on Image Processing, 2011, 20(4): 1152-1165.
- [27] HARALICK R M, SHANMUGAM K, DINSTEN I H. Textural features for image classification[J]. Studies in Media and Communication, 1973, 3(6): 610-621.
- [28] LIU L, FIEGUTH P, GUO Y, et al. Local binary features for texture classification: taxonomy and experimental study[J]. Pattern Recognition, 2017(62): 135-160.
- [29] OJALA T, PIETIKÄINEN M, MÄENPÄÄ T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(7): 971-987.

(责任编辑:陈海霞)