

中医罐斑图像颜色特征提取分析方法的研究

刘慧琳¹, 陈超乾², 张必萌³, 钱 鹏¹, 赵 浩⁴, 郝乐亦^{4*}, 李福凤^{1*}

(1. 上海中医药大学中医学院, 上海 201203; 2. 宁夏回族自治区中医医院暨中医研究院, 宁夏 银川 750021;

3. 上海交通大学医学院附属第一人民医院, 上海 200080; 4. 上海市浦东新区公利医院中医部, 上海 200135)

【摘要】目的 探索罐斑图像特征信息提取识别及分析方法, 构建罐斑图像特征的分类识别模型并提高其分类识别准确性, 为后期罐斑作为中医四诊信息的补充和延伸, 辅助中医健康状态辨识及疗效评价等提供客观、有效的参考依据, 促进中医诊疗规范化、智能化发展。**方法** 首先利用阈值分割法去除皮肤基底颜色, 然后对罐斑进行颜色特征提取, 接着采用传统机器学习方法如决策树、支持向量机、最近邻结点和极值梯度提升算法, 构建罐斑图像颜色分类识别模型, 最后利用混淆矩阵进行模型评价, 分别得到四种模型的准确率、查准率、查全率和 F1 分数, 加以比较判断。**结果** 最终选出预测效果最为良好的模型, 即 XG Boost 模型, 其准确率为 96%, 每一类罐斑识别准确率分别为: 93% (淡紫)、100% (紫黑)、97% (紫暗) 和 86% (红)。**结论** 为中医罐斑的客观识别研究提供了一种新的思路和方法, 为辅助中医健康状态辨识和疗效评价提供了客观依据。

【关键词】 罐斑图像; 颜色特征提取; 机器学习; 分类识别模型; 客观化研究

DOI:10.70976/j.1008-0805.SZCYGY-2025-0932

CSTR:32392.14.j.1008-0805.SZCYGY-2025-0932

【中图分类号】R244.3; R245-3 **【文献标识码】**A **【文章编号】**1008-0805(2025)09-1785-07

拔罐是中医临床最常用的外治方法之一, 常配合针刺、艾灸等传统中医外治疗法, 在我国乃至世界多个国家和地区被广泛运用, 接受度极高, 已成为一项中医临床不可或缺的基本技术。其以不同型号大小的罐为工具, 利用燃烧、蒸汽及抽吸等方法使罐内形成负压^[1,2], 并吸附于体表腧穴或患处某一特定部位^[3], 使局部皮肤充血, 进而对施罐部位产生良性的温热刺激和机械刺激, 可显著改善机体血液循环^[4], 促进新陈代谢, 达到温经通络、祛风散寒除湿及行气活血等功效并在一定程度上改善症状、缓解疼痛、防治疾病^[5,6]。施罐部位在启罐后因局部毛细血管破裂造成瘀血, 则会表现为颜色不同、形状大小不一的瘀点、瘀斑, 或水泡、毛孔张大、皮肤凹陷或凸起等, 以及罐体内壁出现的水汽、肤温及皮肤感觉变化等, 即称罐斑^[7], 或罐印。

人工智能、图像处理、模式识别等现代信息技术^[8-11]的快速发展为中医罐斑客观化、信息化研究带

来了契机, 若能使中医罐斑理论逐渐由凭借医师主观经验判断向罐斑图像特征的客观定性、定量分析判断转变^[12,13], 则可以有效克服传统诊断方法中主观因素的影响和判断结果可重复性差^[14,15]等缺点。本研究通过探索罐斑图像特征信息提取识别及分析方法, 使用传统机器学习方法对罐斑样本数据集进行研究, 以此构建罐斑图像特征的分类识别模型并提高其分类识别准确性, 以期提升罐斑在临床应用中的科学性与实用性, 为后期运用罐斑辅助临床疾病的辨证分型诊断及疗效评价等提供客观、有效的参考依据。

1 资料

1.1 研究对象

于 2021 年 10 月至 2022 年 10 月期间, 在上海市浦东新区公利医院针灸科与上海市第一人民医院松江南院针灸科采集符合纳入标准的就诊患者样本数据 145 例, 罐斑图像数据 253 例。每例样本数据均包括

收稿日期: 2024-09-23; 修订日期: 2025-02-10

基金项目: 上海市卫生健康委员会面上项目(202140283); 上海市浦东新区科技发展基金项目(PKJ2021-Y64)

作者简介: 刘慧琳(1997-), 女(汉族), 广东江门人, 上海中医药大学在读博士研究生, 硕士学位, 主要从事计算机视觉和多模态融合研究工作。

*通讯作者简介: 李福凤(1972-), 女(汉族), 河南信阳人, 上海中医药大学教授, 博士研究生导师, 博士学位, 主要从事中医四诊规范化、信息化研究及临床应用研究工作。

*通讯作者简介: 郝乐亦(1972-), 男(汉族), 上海人, 上海市浦东新区公利医院主任医师, 硕士研究生导师, 硕士学位, 主要从事中医针灸临床研究。

研究对象的个人基本信息、罐斑图像信息、皮肤底色图像信息、爱色丽 24 色标准色卡图像信息、问诊信息、罐斑临床判读量表信息及临床辨证诊断结果等。研究通过上海市浦东新区公利医院医学伦理委员会批准(【2021】研预审第(10)号)。

1.2 纳入标准

①年龄 18~75 周岁,性别不限;②自愿进行健康状况检测,自愿签署知情同意书,接受本研究观察;③具有良好的依从性,思维正常,能够理解且清楚回答问卷问题,能够进行量表评测。

1.3 排除标准

参照中国针灸学会所发布团体标准 T/CAAM 0001-0004-2019《针灸养生保健服务规范·拔罐》禁忌症制订。

①不符合纳入标准;②接触性传染病、急性严重疾病、严重心脏病、心力衰竭等疾病的患者;③血小板减少性紫癜、血友病及血液系统肿瘤等出血性疾病的患者;④皮肤高度过敏、皮肤肿瘤(肿块)部、皮肤溃烂部及传染性皮肤病患者;⑤淋巴结结核、活动性肺结核、静脉曲张处及疝气处;⑥精神分裂症、抽搐、高度神经质及不合作者。

1.4 罐斑图像采集与特征判定

告知患者本研究的目的及罐斑图像采集的注意事项,指导患者阅读知情同意书并签名。患者就诊后取自然坐位或俯卧位,充分暴露需施罐部位。保持室内温度适宜,使患者充分放松,进行拔罐治疗 5min。本研究采集治疗前皮肤原始颜色图像及治疗后的罐斑图像,均使用爱色丽 24 色标准色卡在旁进行比对。完成罐斑图像采集后,由 2 名临床医师共同对患者进行辨证诊断并对其罐斑图像特征进行分类判读,完成罐斑临床判读量表的填写,对罐斑进行分类整理。

2 方法与结果

2.1 罐斑图像特征的提取识别与分析

2.1.1 罐斑图像数据分布

分类整理数据后得到皮肤基底图像 145 例以及罐斑图像 253 例,其中罐斑图像包括淡紫 39 例,紫黑 31 例,紫暗 141 例,红 42 例。见图 1。

2.1.2 罐斑颜色特征提取

Lab 色彩模式是国际照明委员会定义的一个理论上包括了人眼可看见的所有色彩的色彩模式,它致力于感知均匀性,其 L 分量与人眼的亮度知觉高度一致。因此可以通过修改 a 和 b 分量的输出色阶来进行精准的色彩均衡,亦可通过调整 L 分量来调整亮度对比。首先将罐斑 RGB 原图转换成 Lab 图像,将其三通道分离显示。从图 2 中可看出,不同种类罐斑的 L 通道示意图有不同的亮度程度。




图 1 四种不同颜色的罐斑图像视觉对比




图 2 原始罐斑图像的 Lab 三通示意图

本研究利用了灰度阈值分割法^[6]来实现去除皮肤基底颜色的任务,首先对同一个人的罐斑图像和皮肤基底图像进行颜色空间转换,接着将两者的 L 通道进行平均值计算,然后用阈值分割法,分别将罐斑图像和肤色图像的 L 通道平均值作为灰度阈值,罐斑的 L 通道图像作为图像输入。阈值分割后的图像是黑白二值图像,将其作为掩膜与罐斑原图进行“与”操作,获得罐斑图像的感兴趣区域。见图 3。




图 3 去除皮肤基底颜色的罐斑图像视觉对比

图像的颜色矩用于对图像内的颜色分布进行表征,是比较重要的一种全局图像特征表示。在对图像的颜色矩特征进行提取时,重点指向图像颜色矩中的一阶矩、二阶矩和三阶矩,对于图像而言,这 3 种统计特征可表达数字图像的颜色分布。相较于颜色直方图特征提取,颜色矩特征提取的优点是无需预先对颜色特征进行量化。针对罐斑图像,本章利用 RGB 和 Lab 颜色空间的 6 个通道的颜色矩一共有 18 个分量,每个颜色通道均有 3 个低阶矩。

2.1.3 罐斑图像分类识别方法研究

近年来随着科学技术的发展,机器学习和人工智能在医疗领域发挥着诸多重要作用;通过机器学习或深度学习建模可以实现许多中医理论及方法,以实现理论和方法的标准化、规范化,并提高临床诊疗效率及准确性。在中医罐诊理论中,医生根据罐斑的颜色形状来辅助临床疾病辨证诊断。罐斑图像诊断客观化可以有效地降低医生在人为诊断过程中的主观因素干预,提高智能诊断方法的可信度及可重复性,对于进一步提升中医学的科学质量和临床应用具有十分重大的意义。因此在小样本数据集的情况下,本研究采用传统机器学习方法对罐斑数据集进行学习,分别是决策树^[15](decision tree, DT)、支持向量机^[18](support vector machine, SVM)、最邻近结点算法^[19](K-Nearest Neighbor, KNN)和极值梯度提升算法^[20](eXtreme Gradient Boosting, XG Boost)。

2.1.3.1 DT

DT 是通过图示罗列解题的有关步骤以及各步骤发生的条件与结果。其采用一种树形结构,在该结构中每个内部节点分别表示一个属性上的检验,每个分枝点代表一个检验输出结果,每个叶节点代表一种类别。

2.1.3.2 SVM

SVM 是对数据进行二元分类的广义线性分类器,其决策边界是对学习样本求解的最大边距超平面。由于其采用了基于支撑向量集的核函数,使得其计算的复杂度取决于支撑向量集的数目,而不是样本空间的维数,从而在某种意义上有效避免维数灾难。

2.1.3.3 KNN

KNN 是使用一个样本在特征空间当中最近的 K 个样本的最多的类别来表示该样本的类别。在对测试样例进行类别预测的时候,找到与其距离最接近的 K 个样本,以其中数目最多的类别作为该测试样例的类别预测结果。

2.1.3.4 XG Boost

XG Boost 是在由梯度提升决策树进行改良的前提下,加入目标函数的二次泰勒展开项以及模型复杂度的正则项,从而使得目标函数与实际数据相差更小,达到降低数据资料偏差,提高预测精确性。

2.1.4 基于统计学方法的罐斑图像颜色分类参数范围

探讨罐斑图像的四色颜色特征参数范围^[21],运用 Graphpad Prism 9.5.1 医学生物数据处理绘图软件^[22]进行数据统计分析与绘图,对于符合正态分布的计量资料,使用 $\bar{x} \pm s$ 柱状图进行描述,采用方差分析,统一设定 95% 的置信区间,以 $P < 0.05$ 为差异具有统计学意义,其中显著性差异表示 $^*P < 0.05$, $^{**}P < 0.01$, $^{***}P < 0.001$, $^{****}P < 0.0001$ 。

2.2 评估指标与分类

2.2.1 评估指标

为评价模型的性能,采用准确率(Accuracy, A)、查准率(Precision, P)、查全率(Recall, R)和 F1 分数(F1-score)来衡量分类模型的准确性,它们分别定义如公式(1)~(4)所示:

$$\text{Accuracy} = \frac{1}{n} \sum_{i=1}^n I(f(x_i) = y_i) \quad \text{式(1)}$$

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

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

$$\text{F1-Score} = \frac{2 \times P \times R}{P + R} \quad \text{式(4)}$$

其中 TP 代表真阳性的数量,FP 为假阳性数量,FN 为假阴性数量。

本研究的分类任务属于多分类任务,同时本数据集的各类别数据量分布是不均衡的,且所有类别都是同样重要,属于不平衡数据集,因此利用宏平均(Macro Average)可从所有的类别的分类情况上整体评估分类模型的性能,较为关注样本量较少的类别。其具体计算公式如公式(5)~(7)所示,是根据每个类别的准确率、召回率和 F1 分数所求得算术平均数。

$$P_{\text{macro}} = \frac{1}{k} \sum_{i=1}^k P_i \quad \text{式(5)}$$

$$R_{\text{macro}} = \frac{1}{k} \sum_{i=1}^k R_i \quad \text{式(6)}$$

$$F1_{\text{macro}} = \frac{1}{k} \sum_{i=1}^k F1_i \quad \text{式(7)}$$

其中 i 和 k 分别为第 i 个类别和总类别数量 $k = 4$ 。

将所有训练数据集的图像及其标签作为前述所有分类方法的输入图像。由于交叉验证法可用来评估网络的性能,并能从小数据集中获得尽可能多的有效信息,因此本数据集使用了五折交叉验证法,使用了 80% 的数据集进行训练,而其余的 20% 用于验证和测试。

2.2.2 模型分类结果

如图 4a 所示,由四种算法构建的分类模型对于原始罐斑图像的分类准确率(Accuracy)由高到低依次

为:79% (KNN), 77% (XG Boost), 76% (SVM), 70% (DT)。直接利用原始罐斑图像进行分类分析的模型精确度都低于 80%, 因此可猜测是因为原始罐斑图像含有皮肤基底的颜色, 这会对罐斑颜色分类造成干扰。因此, 利用阈值分割法, 将罐斑颜色特征提取, 再进行

分类分析, 其结果如图 4b 所示。在去除皮肤基底颜色后再进行颜色分类图预测, 每一类模型的性能都有大幅度地提升, 其中 XG Boost 模型的准确率最高达到 96%, 提升了 19%。同时 F1 分数的结果达到了 94%, 相较于其他三种算法, 有明显的提升。




图 4 去除皮肤基底前后的颜色分类对比结果

通过混淆矩阵可评估所建立的预测模型分类效果, 准确度可以反映正确的预测在总样本里的占比。如图 5 所示, 由 DT 构建的分类模型对于四类罐斑原始图像颜色分类识别的准确性从高到低依次为: 紫暗(80%), 淡紫(72%), 紫黑(57%), 红(40%); SVM 算法构建的模

型分类准确性高低依次为: 紫暗(99%), 淡紫(85%), 红(34%), 紫黑(19%); KNN 算法构建的模型分类准确性高低依次为: 紫暗(90%), 淡紫(88%), 紫黑(77%), 红(36%); XG Boost 算法构建的模型分类准确性高低依次为: 紫暗(87%), 淡紫(77%), 紫黑(67%), 红(55%)。




图 5 原始罐斑图像的分类混淆矩阵结果

在原始罐斑图像数据的基础上去除皮肤基底颜色后,再次评价各分类器性能。由图 6 可见,由 DT 算法构建的分类模型对于去除皮肤颜色后的四类罐斑颜色分类识别的准确性从高到低依次为:紫黑(97%),紫暗(97%),淡紫(88%),红(76%);SVM 算法构建的模型分类准确性

从高到低依次为:紫暗(100%),淡紫(85%),紫黑(75%),红(57%);KNN 算法构建的模型分类准确性高低依次为:紫暗(99%),紫黑(97%),淡紫(93%),红(64%);XG Boost 算法构建的模型分类准确性高低依次为:紫黑(100%),紫暗(97%),淡紫(93%),红(86%)。




图6 去除皮肤基底后的分类混淆矩阵结果


由图 6 和图 7 可以看出,分别验证使用这四种分类模型对于罐斑原始图像以及去除皮肤基底颜色后的罐斑图像颜色分类识别的准确性,其中均以 XG Boost 算法构建的分类模型对于罐斑颜色的整体分类准确性最高,且可以观察到在去除皮肤底色后,每种罐斑颜色的分类识别准确性均得到了显著提高,尤其大幅提升了对“红”类的正确分类。

2.2.3 罐斑图像颜色分类参数范围结果

如图 7 和表 1 所示,淡紫、紫黑、紫暗与红色组之间的 R、G、B 通道有明显显著性差异。在 RGB 三通道的均值大小范围均为淡紫>红色>紫暗>紫黑。在 R 通道中,四组颜色之间存在显著性差异,但其中淡紫和红色的差异为 $P < 0.05$,考虑到因为淡紫色和红色组别的红色视觉比较较为相近,有别于紫黑和紫暗的暗色视觉比较。而各组别的 G 通道和 B 通道的数值均低于 G 通道,因各分量重数值越小,亮度越低,所以罐斑的视觉感受通常都是偏向于紫色、红色以及暗黑色。

从表 1 中可以看出,四组组别的 R 值区间为[100, 200],而 G 值和 B 值的区间为[50,150]。

同时分析罐斑的 Lab 三通道数值,见图 8,可以明显看出每个组别的 L 通道亮度存在较大的差异。四个组别的两两比较存在明显的显著性差异($P < 0.0001$)。在 L 通道的均值大小范围均为淡紫>红色>紫暗>紫黑。L 值越大,颜色越亮,反之 L 值越小,颜色越偏黑,这是符合视觉比较的主观感受。a 通道中,淡紫色组与紫暗和红色组存在显著性差异($P < 0.0001$),紫黑组和紫暗组的显著性差异($P < 0.05$),而紫黑和红色组之间的显著性差异($P < 0.01$)。b 通道中,红色组与其余三组都存在显著性差异($P < 0.0001$),而淡紫与紫黑的显著性差异($P < 0.05$),紫黑与紫暗的显著性差异($P < 0.01$)。从表 2 中可以看出,四组组别的 a 值和 b 值都在区间[100,150],而 L 值的区间为[50,200]。




四类雀斑的 R、G、B 值比较, * $P < 0.05$, * $P < 0.001$, * $P < 0.0001$

图 7 四类雀斑的 RGB 三通道的柱状图($\bar{x} \pm s$)

表 1 RGB 空间雀斑图像颜色参数范围

颜色	例数	95% CI		
		R	G	B
淡紫	39	173.27 ~ 185.01	133.01 ~ 145.20	124.51 ~ 139.17
紫黑	31	120.74 ~ 132.96	80.00 ~ 89.45	80.20 ~ 90.55
紫暗	141	152.59 ~ 159.92	102.20 ~ 108.48	97.75 ~ 103.84
红色	42	167.27 ~ 190.21	109.57 ~ 132.13	101.27 ~ 122.66



四类雀斑的 L、A、B 值比较, * $P < 0.05$, * $P < 0.01$, * $P < 0.0001$

图 8 四类雀斑的 Lab 三通道的柱状图($\bar{x} \pm s$)

表 2 Lab 空间雀斑图像颜色参数范围

颜色	例数	95% CI		
		L	a	b
淡紫	39	150.78 ~ 162.19	141.05 ~ 143.83	136.35 ~ 139.67
紫黑	31	97.13 ~ 107.72	144.84 ~ 147.18	134.15 ~ 136.31
紫暗	141	123.05 ~ 129.52	147.52 ~ 148.80	138.67 ~ 139.88
红色	42	132.74 ~ 154.50	147.64 ~ 152.00	141.23 ~ 143.92

3 结论

本部分研究采用多种传统机器学习方法对雀斑数据集进行图像分类识别方法研究,研究结果表明建立雀斑图像分类识别模型需要对原始雀斑图像进行皮肤基底颜色的去除,这样显著有利于雀斑颜色分类识别结果,并证实在去除肤色后,运用 XG Boost 算法建立的雀斑图像分类识别模型分类识别准确性明显优于运用 DT、SVM 及 KNN 算法,证明了 XG Boost 算法能有效地提高分类识别模型的效率及准确性,为建立雀斑图

像分类识别模型的最优算法,具有极大的价值与优势,也进一步支持了传统机器学习分类模型适用于雀斑颜色分类任务。同时探讨雀斑图像的四色颜色特征参数范围,为雀斑图像的颜色分类的判别标准提供依据。本研究增强诊疗技术创新,提高医学诊疗设备的技术创新能力和核心竞争力,充分运用现代科技,为中医智能化雀斑研究提供标准化的数据支持,有利于推进中医智能雀斑客观化识别研究与临床应用,提高中医健康服务能力。

参考文献:

- [1] 李国瑞, 苏映军, 郭树忠. 负压疗法的科学原理和运用[J]. 现代生物医学进展, 2014, 14(13): 2573.
- [2] 崔帅, 崔瑾. 拔罐疗法的负压效应机制研究进展[J]. 针刺研究, 2012, 37(6): 506.
- [3] 吴国民, 陈胤珍, 刘堂义. 罐疗法物理参数量化研究及其意义[J]. 上海针灸杂志, 2021, 40(7): 890.
- [4] LI T, LI Y, LIN Y, et al. Significant and sustaining elevation of blood oxygen induced by Chinese cupping therapy as assessed by near-infrared spectroscopy [J]. Biomed Opt Express, 2017, 8(1): 223.
- [5] 陆寿康. 刺灸灸法[M]. 北京: 中国中医药出版社, 2003: 8.
- [6] 崔瑞, 李迎红, 郭义. 对“罐斑诊断疾病法”的认识[J]. 河南中医, 2015, 35(2): 229.
- [7] 汪振宇, 李琳, 张畅. 罐斑显色临床意义的研究思路[C]// 中国针灸学会刺络与拔罐专业委员会, 中国·天津武清中医院. 中国·天津第六届国际中医药学术研讨会刺络与拔罐分会暨中国针灸学会刺络与拔罐专业委员会成立大会暨学术交流论文集, 2008: 3.
- [8] 吴菲霞, 裴金霞, 朱菲莉. 基于 CiteSpace 中医拔罐疗法研究热点的可视化分析[J]. 护理与康复, 2023, 22(4): 31.
- [9] 陈超乾, 郭元成, 关茜, 等. 贵州苗族气虚、阴虚体质人群的舌、面诊图像特征分析[J]. 中华中医药杂志, 2023, 38(8): 3849.
- [10] 陈超乾, 郭元成, 徐莹, 等. 慢性肾功能衰竭脾肾阳虚证的舌面诊图像特征研究[J]. 时珍国医国药, 2023, 34(5): 1144.
- [11] 朱蓉蓉, 钱祺, 陈超乾, 等. 慢性胃炎患者中医面型特征研究[J]. 中华中医药杂志, 2024, 39(1): 114.
- [12] 王永杰. 基于深度学习的罐斑图像自动分割与分类技术研究[D]. 桂林理工大学硕士学位论文, 2023.
- [13] KIM S B, LEE Y H. Numerical analysis of the change in skin color due to ecchymosis and petechiae generated by cupping: a pilot study [J]. Journal of Acupuncture and Meridian Studies, 2014, 7(6): 306.
- [14] 杨超博. 不同舌象、脉象、面色及体质的五脏背俞穴罐斑显色规律研究[D]. 天津中医药大学硕士学位论文, 2023.
- [15] 王艺颖, 刘建平, 曹开娟. 针灸从业人员对罐斑颜色临床意义认知的调查[J]. 现代中医临床, 2023, 30(3): 6.
- [16] 许高建, 沈杰, 徐浩宇. 基于 Lab 颜色空间下的小麦赤霉病图像分割[J]. 中国农业大学学报, 2021, 26(10): 149.
- [17] 叶丽珠, 郑冬花, 刘月红, 等. 基于鲸群优化随机森林算法的非平衡数据分类[J]. 南京邮电大学学报(自然科学版), 2022, 42(6): 99.
- [18] 肖敬达, 黄玉麟, 刘博闻, 等. 基于特征选择下机器学习的活动性结核病辅助诊断[J]. 厦门大学学报(自然科学版), 2024, 63(1): 134.
- [19] 李道全, 李静, 李玉秀. 基于自适应特征选择与 KNN 的网络流量分类研究[J]. 计算机工程与应用, 2023, 59(12): 270.
- [20] 凡如, 许碧云, 熊志刚, 等. 基于极端梯度提升算法的高血压识别模型建立[J]. 中国卫生统计, 2023, 40(1): 74.
- [21] 袁善敏, 李福凤. 中医常见面诊图像颜色参数范围探讨[J]. 中华中医药杂志, 2022, 37(3): 1682.
- [22] 翟润粉, 罗志丹, 石晓, 等. 不同统计软件在医药生物学教学实验数据处理中的应用比较[J]. 中国医药科学, 2024, 14(2): 74.

Study on the extraction and analysis methods for color features of cupping plaque images in traditional Chinese medicine

LIU Huilin¹, CHEN Chaoqian², ZHANG Bimeng³, QIAN Peng¹, ZHAO Jie⁴, DU Leyi^{4*}, Li Fufeng^{1*}

(1. School of Traditional Chinese Medicine, Shanghai University of Traditional Chinese Medicine, Shanghai 201203, China; 2. Ningxia Hui Autonomous Region Chinese Medicine Hospital and Research Institute, Yinchuan 750021, China; 3. Shanghai General Hospital Affiliated to Shanghai Jiao Tong University School of Medicine, Shanghai 200080; 4. Department of Traditional Chinese Medicine, Gongli Hospital of Pudong New Area, Shanghai 200135, China)

Abstract: **Objective** To explore the extraction, recognition, and analysis of feature information from cupping plaque images, construct a classification and recognition model for cupping plaque image features, and improve its classification accuracy. The study aims to provide an objective and effective reference for supplementing and extending cupping plaques as part of the four diagnostic methods in traditional Chinese Medicine (TCM), assisting TCM health status identification and efficacy evaluation, and promoting the standardized and intelligent development of TCM diagnosis and treatment. **Methods** First, threshold segmentation method was used to remove the skin's base color. Next, color feature extraction was performed on the cupping plaques. Traditional machine learning methods, including Decision Tree, Support Vector Machine (SVM), K-Nearest Neighbors (KNN), and Extreme Gradient Boosting (XGBoost), were employed to construct a color classification and recognition model for cupping plaque images. Finally, confusion matrices were applied to evaluate the models, yielding accuracy, precision, recall, and F1 scores for each model, enabling a comparative analysis. **Results** The model with the best performance was selected, namely the XGBoost model, with an accuracy rate of 96%. The accuracy rate of each class were 93% (light purple), 100% (purple-black), 97% (dark purple), and 86% (red). **Conclusion** The study provides a novel perspective for the objective recognition research of cupping plaques in TCM, offering an objective basis to assist TCM health status identification and efficacy evaluation.

Key words: Cupping plaque images; Color feature extraction; Machine learning; Classification and recognition model; Objective research

(责任编辑:程文锋)