

DOI:10.13718/j.cnki.xsxb.2023.07.012

基于多策略改进麻雀搜索算法优化 SVM 的古建筑彩画分割^①

鄢敏¹, 夏永华^{1,2}, 顾进立², 许曦², 王冲³

1. 昆明理工大学 国土资源工程学院, 昆明 650093; 2. 昆明理工大学城市学院, 昆明 650051;
3. 中国电建集团 昆明勘测设计研究院有限公司, 昆明 650200

摘要: 为精确地提取古建筑彩画的色彩、图案与轮廓信息, 本文利用网络搜索优化 SLIC 超像素分割, 通过多策略改进的麻雀搜索算法优化 SVM 的超参数选择过程, 获取古建筑彩画分割的精确分类结果, 最后利用 ArcGIS 软件进行分割结果的矢量化。实验表明: 本文算法较原 SSA-SVM 具有更高的精度和效率, 最终的彩画矢量化结果优异。

关键词: 别子彩画样式; 麻雀搜索算法; 支持向量机; 图像分割

中图分类号: TP751.1

文献标志码: A

文章编号: 1000-5471(2023)07-0080-09

Optimization of SVM for Segmentation of Ancient Architectural Paintings Based on Multi Strategy Improved Sparrow Search Algorithm

YAN Min¹, XIA Yonghua^{1,2}, GU Jinli², XU Xi², WANG Chong³

1. Faculty of Land Resources Engineering, Kunming University of Science and Technology, Kunming 650093, China;

2. City College, Kunming University of Science and Technology, Kunming 650051, China;

3. Kunming Survey and Design Institute Co., Ltd., China Power Construction Group, Kunming 650200, China

Abstract: In order to accurately extract the color, pattern, and contour information of ancient architectural paintings, this article uses network search to optimize SLIC super-pixel segmentation. The Multi-strategy Improved Sparrow Search Algorithm has been used to optimize the hyperparameter selection process of SVM classification, and the accurate classification results of ancient architecture painting were obtained in this study. Finally, the ArcGIS software has been used for vectorization of segmentation results. Experimental results show that the proposed algorithm has higher accuracy and efficiency than the original SSA-SVM, and the final color painting vectorization results are excellent.

Key words: the Biezi architectural painting style; sparrow search algorithm; support vector machine; image segmentation

① 收稿日期: 2022-05-15

基金项目: 国家自然科学基金项目(41861054, 42161067); 昆明理工大学横向科技服务项目(KKF0201956004)。

作者简介: 鄢敏, 硕士, 主要从事图像处理、数字摄影测量的研究。

通信作者: 夏永华, 副教授。

中国古建筑彩画历史悠久,形成了以官式彩画为主体的大量区域性彩画样式,是我国古代建筑装饰艺术的主要表现形式之一.但因建筑木制结构常年暴露于外部环境中,建筑彩画极易出现褪色、破甲、开裂等病害,现存的大量历史彩画保存现状堪忧.为保护古建筑彩画遗产,各地学者通过数字摄影方式,以大量像片为载体记录彩画的现状信息.但受限于图幅大小,像片难以兼顾彩画的清晰度与全局性,且对存储空间消耗极大,亟需一种准确且高效的彩画数据采集与数字化解决方案.

近年来,以数字摄影测量为基础并结合图像分割、矢量化等图像处理手段的贴近摄影测量方法,以其优异的模型完整度和建模精细度在文物保护领域成效斐然^[1].目前的图像分割方法种类繁多^[2-10],其中 SVM 算法在解决小样本、高维度问题上具有独特优势,是目前最受欢迎的分类算法之一,本文也将采用 SVM 作为分类算法,以供后续实验对比与分析.

高斯径向基函数(RBF)的 SVM 模型的性能主要受损失参数 c 与核函数参数 g 的影响.为寻找最优训练参数,大量学者通过群智能优化算法来搜索模型最佳训练参数,以实现更高的分类精度^[11-14].麻雀搜索算法(sparrow search algorithm, SSA)^[14]是一种新型的群智能优化算法.相比于传统群体优化算法,SSA 算法的控制参数少、局部开发能力较强.但类似其它群优化算法,SSA 算法同样存在早熟收敛、易陷入局部最优与边界计算等问题.针对 SSA 算法存在的部分局限性,本文提出了一种多策略改进麻雀搜索算法(multi-strategy improved sparrow search algorithm, MISSA),用于优化 SVM 的参数选择过程、提高分类精度.

1 多策略改进麻雀搜索算法优化 SVM 的分割方法

本文使用 SLIC 算法提取超像素,通过主成分分析(PCA)对融合多个色彩空间的颜色矩特征进行降维,利用 MISSA 算法优化 SVM 的初始训练参数,获取更加精确的分类结果.算法的主要步骤如下:

- 1) 输入彩画图像,通过形态学重构处理,在保留边界信息的同时,滤除图像明暗噪声.
- 2) 通过网络搜索确定最佳分割步长与紧凑度,对去噪图像使用 SLIC 算法获取超像素分割结果.
- 3) 融合超像素区域内多色彩空间的颜色矩特征,并采用 PCA 算法进行特征降维.
- 4) 通过 MISSA 算法寻找最优训练参数,使用 SVM 获取精确分类结果.
- 5) 利用 ArcGIS 软件对分类结果进行矢量化.

1.1 图像预处理

1.1.1 图像去噪

形态学重构^[4]通常用来突出图像中与掩膜图像相一致的部分,同时忽略图像中其它对象.因此,通过与腐蚀、求补运算相结合,可对图像进行双边滤波,去除图像明暗噪声,并保留重要的区域轮廓信息.其计算公式如下:

$$\mathbf{I}_1 = \text{reconstruct}(\mathbf{I}, \mathbf{I} \odot \mathbf{g}) \quad (1)$$

$$\mathbf{I}_2 = \text{reconstruct}(\mathbf{R}_1, \mathbf{R}_1 \odot \mathbf{g}) \quad (2)$$

其中: \mathbf{I} 为图像某一波段的灰度图像, \mathbf{g} 为结构元素, \mathbf{R}_1 为图 \mathbf{I}_1 的补像.式(1)实现了对图像亮部噪声的剔除,式(2)则通过补像实现了图像暗部噪声的剔除.最后,对 \mathbf{I}_2 进行求补,即可得到去噪图像.

1.1.2 超像素分割

超像素分割算法利用相邻像素间的特征相似性将像素组合成具有一定视觉意义的不规则像素块,用少量的超像素来代替像素表达图片特征,极大地降低了图像后处理的复杂度,是目前常用的图像分割预处理方法.常用的超像素分割方法主要有分水岭算法^[5]、均值漂移算法^[6](Mean Shift)与简单线性迭代聚类算法^[7](simple linear iterative clustering, SLIC)等,其中,SLIC 算法因结构简单、结果紧凑且贴合边缘,是目前最常用的超像素分割算法之一.本文通过网络搜索确定 SLIC 算法分割步长与紧凑度参数,以小块样本区域的边界重叠度作为适应度指标,采用过分割策略获取超像素结果,以保证分割的准确性.

1.2 特征提取与降维

1.2.1 多色彩空间的区域颜色矩

彩画图像超像素区域分类主要依靠色彩特征的差异. 不同漆料色彩的 RGB 值差异明显, 但光照变化等因素造成的漆面反光与边缘模糊问题会严重影响分类效果. 为降低光照等因素的影响, 本文引入了颜色属性与光照强度独立的 CIE-Lab 和 YCbCr 色彩空间, 共选取 R, G, B, L, a, b, Y, Cb, Cr, Gray(0.2989R + 0.587G + 0.114B) 共 10 个颜色分量用于后续的区域色彩统计.

由于图像颜色信息主要分布于低阶矩中, 所以一般采用一阶矩(均值, *Mean*)、二阶矩(方差, *Variance*)、三阶矩(偏斜度, *Skewness*)便足以表达图像的颜色分布^[15]. 因此, 本文选择以上 3 种颜色矩统计超像素区域的色彩特征. 计算公式如下:

$$Mean = \sum_{i=1}^N \frac{Color_i}{N} \quad (3)$$

$$Variance = \sqrt{\frac{\sum_{i=1}^N (Color_i - Mean)^2}{N}} \quad (4)$$

$$Skewnes = \sqrt[3]{\frac{\sum_{i=1}^N (Color_i - Mean)^3}{N}} \quad (5)$$

其中: N 为一超像素区域内像素总数, $Color_i$ 为超像素区域内第 i 个像素的某颜色分量值.

1.2.2 特征降维

当特征维数增加, 后续分类计算的复杂程度也会相应增加, 对 SVM 分类的效率与精度影响极大. 因此, 对特征进行适当的降维十分必要. 本文采用目前常用的主成分分析(PCA)方法, 通过线性投影将高维特征映射至低维空间, 并保证同一维度上特征的方差最大, 以使用较少的特征维度, 保留尽可能多的特征信息.

1.3 多策略改进麻雀搜索算法

本文针对麻雀搜索算法存在种群缺乏多样性、易陷入边界计算、早熟收敛与收敛速度慢等问题做出了改进.

1.3.1 Tent 混沌映射改进种群初始化

假设种群中存在 n 只麻雀, 变量搜索空间为 d 维, 则初始化种群与适应度可表示为:

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1d} \\ x_{21} & x_{22} & \cdots & x_{2d} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nd} \end{bmatrix} \quad \mathbf{f}_x = \begin{bmatrix} f([x_{11}, x_{12}, \cdots, x_{1d}]) \\ f([x_{21}, x_{22}, \cdots, x_{2d}]) \\ \vdots \\ f([x_{n1}, x_{n2}, \cdots, x_{nd}]) \end{bmatrix}$$

原 SSA 算法通过伪随机数生成器初始化种群位置, 但伪随机函数生成器的不确定性会严重降低种群的多样性. 混沌映射由于具有非线性、遍历性与长期不可预测性等特点, 常被用于替代伪随机数生成器来优化搜索. 本文采用了其中性能较好的 Tent 混沌映射模型, 通过建立映射关系将混沌序列转换至变量空间以替代原始种群. 其计算公式如下:

$$x_{i,j} = b_u - (b_u - b_l) * r_i \quad (6)$$

$$r_{i+1} = \begin{cases} \frac{r_i}{a}, & r_i < a \\ \frac{1-r_i}{1-a}, & r_i \geq a \end{cases} \quad (7)$$

其中: r_0 为 $[0, 1]$ 范围内的随机数, r_i 为第 i 个初始参数取值, a 为 $(0, 1)$ 范围内的常数, $x_{i,j}$ 为第 i 个个体在第 j 维的位置, b_u 为变量上界, b_l 为变量下界.

1.3.2 引入幂数级递减惯性权重的发现者位置更新公式

麻雀种群中, 发现者具有高适应度, 搜索范围更广, 负责引导种群的觅食行为. 为了平衡算法的全局搜索与局部开发能力, 本文在发现者位置更新公式中引入了幂数级递减的惯性权重. 改进后位置更新公式为:

$$x_{i,j}^{t+1} = \begin{cases} \omega * x_{i,j}^t * e^{\frac{-i}{iter_{max}}} \\ x_{i,j}^t + \omega * QL, R \geq S_T \end{cases} \quad (8)$$

$$\omega = \omega_{max} - \left(\frac{t}{iter_{max}} \right)^n * (\omega_{max} - \omega_{min}) \quad (9)$$

其中: t 为当前迭代次数; $x_{i,j}^t$ 表示在第 t 次迭代中第 i 只麻雀在第 j 维的位置; a 为 $(0, 1)$ 范围内的均匀分布随机数; $iter_{max}$ 是最大迭代次数; R 为均匀分布随机数; S_T 为安全阈值; Q 为符合标准正态分布的随机变量; L 为 $1 * d$ 的元素全为 1 的矩阵; ω_{max} 与 ω_{min} 为惯性权重取值范围; n 为幂数级递减参数, 当取 1 表现为线性递减, 且 n 越大迭代前后的下降速率差异越大. 当 $R < S_T$ 时表示未发现捕食者, 可以进行更广泛的搜索; 反之代表发现捕食者, 麻雀向安全区域转移.

1.3.3 加入者位置更新公式

加入者的适应度相对较低, 会跟随发现者与其竞争食物, 或飞往其它区域进行觅食. 其位置更新公式如下:

$$x_{i,j}^{t+1} = \begin{cases} Q * e^{(x_{worst}^t - x_{i,j}^t)}, i > \frac{n}{2} \\ x_{best}^t + |x_{i,j}^t - x_{best}^t| * A^+ * L, i \leq \frac{n}{2} \end{cases} \quad (10)$$

其中: x_{worst}^t 为第 t 次迭代适应度最差的麻雀位置, x_{best}^t 为第 t 次迭代最佳位置, A 表示 $1 * d$ 的元素随机为 1 或 -1 的矩阵, $A^+ = A^T(AA^T)^{-1}$, L 为 $1 * d$ 的元素全为 1 的矩阵. 当 $i > 0.5n$ 时表示该麻雀为适应度较低的半数加入者, 无法与发现者竞争, 需飞往其他区域觅食; 当 $i \leq 0.5n$ 时, 加入者将与发现者竞争食物, 前往最优个体附近觅食.

1.3.4 引入警戒解除机制的警戒者位置更新公式

警戒者负责扩散警戒信号, 一般选取种群中 10% ~ 20% 的个体负责预警, 其位置更新公式如下:

$$x_{i,j}^{t+1} = \begin{cases} x_{best}^t + \beta * |x_{i,j}^t - x_{best}^t|, f_i \neq f_b \\ x_{best}^t + k * \left(\frac{x_{i,j}^t - x_{best}^t}{|f_i - f_w| + \epsilon} \right), f_i = f_b \end{cases} \quad (11)$$

其中: β 为控制步长, 服从均值为 0, 方差为 1 的正态分布; k 为 $[-1, 1]$ 范围内的随机数; ϵ 设置为一极小常数, 以避免除零错误; f_i 为当前个体的适应值, f_b 与 f_w 则分别表示目前最优与最差适应值. 当 $f_i \neq f_b$ 时, 个体位于种群外围, 需飞往种群中心; 当 $f_i = f_b$ 时, 个体位于种群中心, 它将向临近个体靠近, 远离捕食者.

警戒者的存在是为了提升种群的全局搜索能力, 但原 SSA 算法中警戒者的数量固定, 会使算法后期的收敛速度变慢. 本文采用线性递减策略调节警戒者比例, 其计算公式如下:

$$S = \begin{cases} \text{int} \left(S_{max} * \left(1 - \frac{t}{iter_{max}} \right) \right), S > S_{max} \\ S_{min}, S \leq S_{min} \end{cases} \quad (12)$$

其中: S_{max} 与 S_{min} 为警戒者的数量范围.

1.3.5 线性递减的最优个体 T 分布变异

本研究引入以迭代次数 t 为自由度的 T 分布随机算子对最优麻雀个体的位置进行扰动, 以防止种群陷入局部最优解. 计算公式如下:

$$x_{i,j}^{t+1} = \begin{cases} x_{i,j}^t + x_{i,j}^t * T(r), r \leq p \\ x_{i,j}^t, r > p \end{cases} \quad (13)$$

$$p = p_{\max} - \frac{t}{\text{iter}_{\max}} * (p_{\max} - p_{\min}) \quad (14)$$

当 $f_i \geq f_b$ 时, 执行以上变异运算, 其中: r 为 $(0, 1)$ 范围内的随机数, $T_{(t)}$ 为以迭代次数 t 为自由度的 T 分布随机数, p_{\max} 与 p_{\min} 为变异概率的取值范围.

1.3.6 随机回归的越界处理

在 SSA 中, 由于麻雀运动的随机性, 常出现位置越界导致边界计算, 缺乏对边界邻域搜索. 本文使用一种随机回归的越界处理改善该问题, 公式如下:

$$x_{i,j} = \begin{cases} b_u - \min(x_{i,j} - b_u, b_u - b_l) * r, & x_{i,j} > b_u \\ b_l + \min(b_l - x_{i,j}, b_u - b_l) * r, & x_{i,j} < b_l \end{cases} \quad (15)$$

其中: b_u 与 b_l 分别为变量 x 在数值的上界与下界, r 为 $(0, 1)$ 范围内的均匀分布随机数. 这一处理方法会使越界回归具有一定的弹性, 而不是单一的赋值变量的上下界, 提高了种群的多样性.

1.3.7 MISSA 算法实现步骤

多策略改进麻雀搜索算法(MISSA)的运算步骤如下.

Step1: 根据公式(6)初始化种群与 MISSA 参数: 种群数量 popsize 、最大迭代次数 T_{Max} 、搜索参数的上下界 b_u 与 b_l 、惯性权重范围 w_{\max} 与 w_{\min} 、发现者比例 P_d 等参数.

Step2: 计算初始种群适应度并排序, 记录最优、最差适应度个体位置与适应度值: $X_{\text{best}}, f_{\text{best}}, X_{\text{worst}}, f_{\text{worst}}$.

Step3: 根据公式(9)与公式(12)计算惯性权重与警戒者数量: w, S .

Step4: 根据公式(8)更新发现者位置.

Step5: 根据公式(10)更新加入者位置.

Step6: 根据公式(11)更新警戒者位置.

Step7: 根据公式(14)计算变异概率, 根据公式(13)计算最优个体扰动后位置.

Step8: 根据公式(15)进行越界后的边界计算.

Step9: 更新适应度值并排序, 更新最优、最差适应度个体位置与适应度值: $X_{\text{best}}, f_{\text{best}}, X_{\text{worst}}, f_{\text{worst}}$.

Step10: 循环 Step3-Step4, 判断是否满足条件, 满足则跳出循环.

Step11: 算法结束, 返回最优参数与适应度.

2 实验与分析

2.1 实验数据

本研究使用的彩画图像属典型的昆明别子彩画样式^[16], 像片通过贴近摄影测量方式采集于昆明市龙泉观道教古建筑群. 实验采集设备为 DJI Mini, 其相机焦距 24 mm, 传感器尺寸 1/2.3 英寸, 拍摄中心距物面约 5 米, 采集了 6 个梁枋彩画对象共 522 张图像. 采用 Context Capture 软件对影像进行三维建模并生成正射影像, 再利用 Photoshop 软件裁剪彩画主体. 影像三维建模结果示例如图 1 所示.

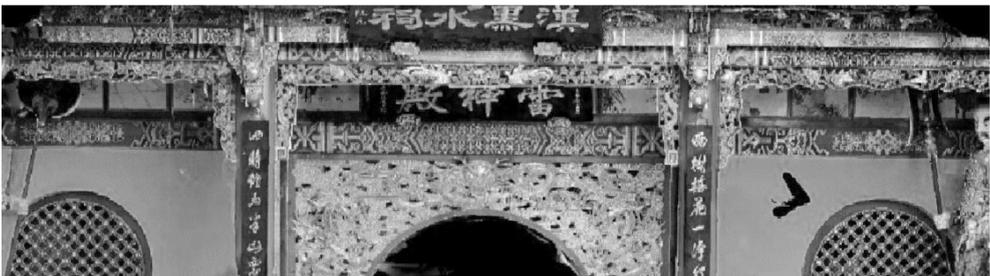


图 1 影像三维建模示例图

本文的实验环境为: AMD Ryzen-5 六核 CPU、16G 内存、Windows10 操作系统、MATLAB 2018b、

libsvm 3.25、Context Capture 10.17、ArcGIS 10.5.

2.2 颜色矩特征组合分类结果对比

为验证多色彩空间颜色矩特征不同组合方式对于分割精度的影响, 本文对各单一色彩空间的色彩及其组合方式、降维处理进行精度对比. 通过人工筛选得到损失参数 c 为 1, 高斯核函数参数 g 为 0.1, PCA 取贡献率大于 0.1% 的主成分特征向量进行降维. 单一方法与不同组合方法的分类性能对比如表 1 所示.

表 1 不同特征组合分类精度对比

方法	特征提取时间/s	分类时间/s	特征维度	精确率/%
Mean RGB	2.36	0.013	3	94.873 9
Mean Lab	2.36	0.013	3	93.409 3
Mean YCbCr	2.33	0.012	3	95.958 8
Mean Color	2.34	0.014	10	96.772 4
All	2.39	0.022	30	97.776 0
All+PCA	4.04	0.013	5	97.776 0

从表 1 中可以发现, 利用单一色彩空间的均值进行分类, 分类精度平均可达到 94.7%. 通过结合不同色彩空间特征, 分类精度较单一 RGB 提升约 1.9%. 而整合全部颜色矩特征后, 特征维数达到 30 维, 此时分类精度最高, 达 97.996%, 但分类效率明显下降. 通过主成分分析进行特征降维后, 特征维数下降至 5 维, 分类精度几无损失, 且分类用时明显降低. 实验表明, 通过融合多色彩空间特征, 改善了单一色彩空间因光照等因素造成的局限性, 并且在使用低阶颜色矩统计特征并进行 PCA 降维后, 分类精度与效率有明显提高.

2.3 改进麻雀优化 SVM 分析

本文通过多种改进策略来平衡与进一步挖掘 SSA 算法的全局搜索与局部开发能力, 丰富种群多样性, 提升算法收敛效率. 为验证改进算法的优化性能, 将本文改进算法与 PSO 算法、WOA 算法、SOA 算法及原 SSA 算法进行对比. 通过 3 折交叉验证的验证精度作为适应度值, 对一尺寸为 831×217 像素, 共 3687 个超像素的小尺寸彩画图像分别进行 10 次实验, 取最优与平均精度及平均用时进行对比. 为降低优化算法的时间成本, 引入了精度停滞退出机制, 当精度停滞增长 num 次后即跳出迭代. 实验图像共有 8 个色彩类别, 各类别均匀采样 15 个样本. 算法公共参数设置为 $num = 20$, $T_{Max} = 100$, $Popsiz = 20$, $c \in [0.1, 100]$, $g \in [0.01, 10]$; PSO 算法参数设置为 $c_1 = 2$, $c_2 = 2$; WOA 算法参数设置为 $b = 0.8$; SOA 算法参数设置为 $fc = 2$, $u = 1$, $v = 1$; SSA 算法参数设置为 $S_T = 0.6$, $P_d = 0.7$, $S = 0.2$; 本文算法参数设置为 $a = 0.7$, $n = 2$, $r_{1,0} = 0.8$, $r_{2,0} = 0.1$, $w \in [0.4, 0.9]$, $p \in [0.2, 0.5]$, $S_T = 0.6$, $P_d = 0.7$, $S \in [0.05, 0.2]$. 各算法优化性能对比如表 2 所示.

表 2 各优化算法性能对比

算法	最优精度/%	精度均值/%	方差/%	迭代轮数/轮	平均耗时/s
PSO	96.962 3	96.289 7	0.600 8	31	1.79
WOA	97.165 2	96.809 0	0.391 0	39	3.18
SOA	98.021 8	97.698 9	0.246 6	38	2.75
SSA	98.020 1	97.740 7	0.249 2	33	1.84
Ours	98.047 2	97.832 9	0.113 5	35	1.67

通过分析可得, SSA 算法在分类精度上明显优于 PSO 经典算法, 在平均耗时、精度均值与方差上优于 WOA 等新型最优化算法, 体现出 SSA 算法在运算速度与输出稳定性上的优势. 此外, 本文算法在精度上相较于原 SSA 算法提升约 0.03%, 精度方差提升约 0.14%, 且用时上节省 0.17 s. 实验表明本文算法较原 SSA 算法进一步改善了算法优化性能与稳定性, 加快了算法的迭代收敛速度, 相较于原算法在稳定性与收敛速度上表现出明显优势.

2.4 彩画图像分割结果对比

本文从数据集中选取了两幅不同规模的彩画图像进行实验, 图像信息如表 3 所示. 将本文算法与 PSO-SVM^[11]、GA-PSO-SVM^[17]、原 SSA-SVM^[14] 以及 PSO-RF 进行对比实验. 其中基于 SVM 的算法训练参数依旧采用 2.3 小节的设置, PSO-RF 算法的 PSO 参数与 PSO-SVM 一致, RF 的超参数取值为决策树棵数范围[5, 50], 属性特征集大小范围[5, 20]. 图像分类结果的精度评价采用总体分类精度与 Kappa 系数进行评价, 各算法分类结果对比如图 2 与表 4、表 5 所示.

表 3 实验图信息

图片名	像素值	超像素个数	色彩类别数	样本量(各类别平均)
1	1 215×545	20 947	15	50
2	1 217×291	9 695	11	50

表 4 图 1 各算法分类性能对比

算法	精度/%	Kappa	迭代轮数/轮	耗时/s
PSO-SVM	79.65	0.775 5	54	7.54
GA-PSO-SVM	82.37	0.806 5	51	8.10
PSO-RF	82.86	0.811 9	46	45.41
SSA-SVM	81.05	0.752 4	47	8.69
MISSA-SVM	84.18	0.826 2	44	6.61

表 5 图 2 各算法分类性能对比

算法	精度/%	Kappa	迭代轮数/轮	耗时/s
PSO-SVM	80.54	0.780 8	51	5.29
GA-PSO-SVM	83.86	0.818 0	59	7.02
PSO-RF	84.29	0.822 6	41	21.28
SSA-SVM	82.97	0.808 0	44	6.06
MISSA-SVM	86.41	0.846 6	46	4.65

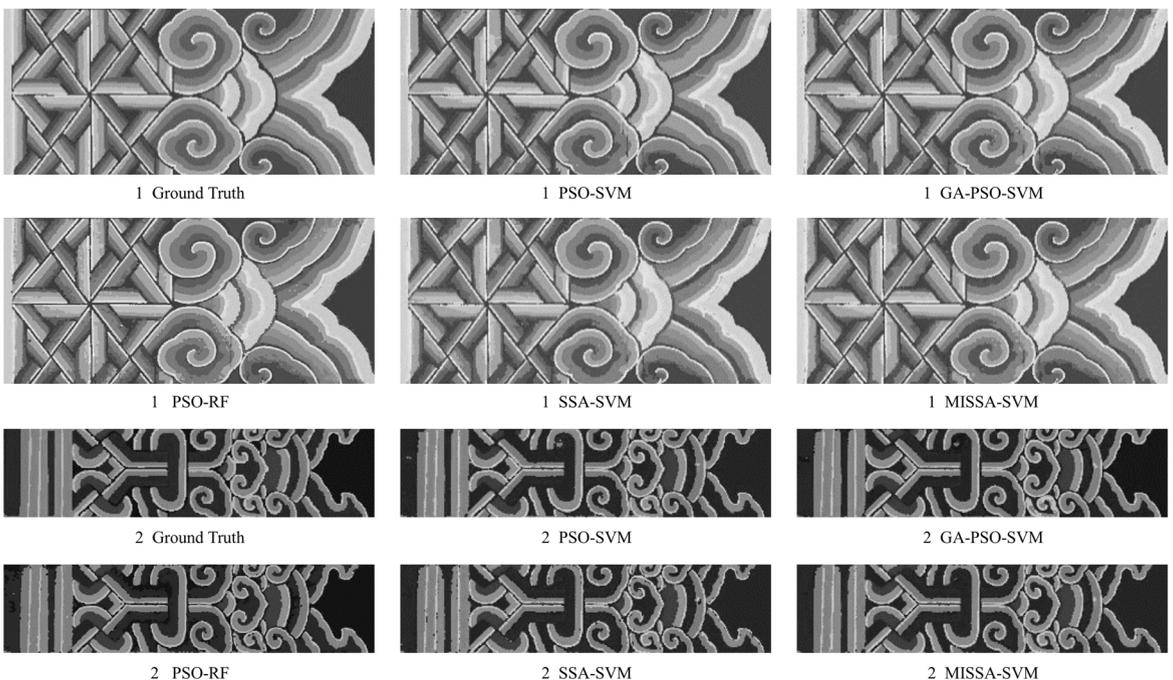


图 2 各算法分类结果

分析表中数据可发现, PSO-RF 实验精度仅次于本文算法, 但由于决策树规模对分类效率的影响, 导致其处理效率极其低下. 综合实验数据来看, 本文算法分割精度最高, 分类效率也优于其它对比算法, 总体分类精度分别高于原 SSA 算法 3.13% 与 5.87%, Kappa 系数优于原算法 0.073 8 与 0.065 8, 迭代次数与原算法相近的情况下, 分类用时节省了 2.08 s 与 1.41 s, 效率提升约 27%.

2.5 分割结果矢量化

将彩画分割结果进行矢量化后, 可对彩画的图案、轮廓与色彩信息更加便捷地保存与分析. 本文将修正后的分割结果输出为类别掩膜, 利用 ArcGIS 软件将其转换为矢量面要素, 并进行坐标校正与适当平滑, 可将分割后的栅格信息转换为以 *.shp 与 *.dwg 格式保存的矢量数据文件. 转换结果如图 3 所示.



图 3 图像矢量化结果

2.6 结果分析

通过分析上述实验结果, 大致可发现以下问题:

1) 本文基于边界重叠度网络搜索超像素分割最优参数的方法极为有效, 可直接做到以样本最小目标尺度进行图像过分割. 但由于未加入任何融合策略, 还无法实现多尺度分割, 须在今后的研究中加以改善.

2) 融合多个色彩空间低阶矩特征的分类结果有明显改善, 通过利用分离亮度与色相的 lab 与 YCbCr 色彩空间信息, 降低了过曝等图像噪声影响. 再通过适当的特征降维, 可有效提高分类的精度与效率.

3) 整体来看, 本文提出的算法在原 SSA 算法基础上, 通过改善种群多样性与平衡全局与局部搜索能力等措施, 在算法稳定性与效率上改进效果明显, 在彩画分类实验中表现优异. SSA 算法属新型智能优化算法, 在具体应用上存在大量改进空间, 本文部分改进思路同样适用于其它群体智能算法应用方向, 并值得深入探究.

4) 彩画图像分割结果锯齿化严重, 需利用合适的平滑方法, 才能得到轮廓平滑且准确的矢量化结果, 但本文通过软件人工设定平滑参数的方法较为繁琐, 难以平衡结果精度与线条精简间的目的冲突, 这是目前研究中需加以改进的地方.

3 结语

本文通过融合多色彩空间颜色矩统计特征, 改进图像分割与分类算法, 有效地提升了图像的分割效率与精度, 为古建筑彩画等古代艺术的传承与保护提供了一种新思路, 为建筑彩画艺术研究提供了新工具, 具有一定的研究与应用价值.

参考文献:

- [1] 谭金石, 陈颖彪, 祖为国. 利用无人机贴近摄影的临街建筑立面测绘方法 [J]. 遥感信息, 2021, 36(6): 80-85.
- [2] NAVED M, AHAMAD M. An Improved Method for Image Segmentation Using K-Means Clustering with Neutrosophic Logic [J]. Procedia Computer Science, 2018, 132: 534-540.
- [3] 曾台英, 杜菲. 基于层次聚类的图像超分辨率重建 [J]. 光学学报, 2018, 38(4): 130-137.
- [4] LEI T, JIA X H, ZHANG Y N, et al. Significantly Fast and Robust Fuzzy C-Means Clustering Algorithm Based on

- Morphological Reconstruction and Membership Filtering [J]. *IEEE Transactions on Fuzzy Systems*, 2018, 26(5): 3027-3041.
- [5] 黄亮, 姚丙秀, 陈朋弟, 等. 融合层次聚类的高分辨率遥感影像超像素分割方法 [J]. *红外与毫米波学报*, 2020, 39(2): 263-272.
- [6] ERIK C, JORGE G, OMAR A, et al. A Mean Shift Segmentation Scheme Using Several Pixel Characteristics [J]. *Computers and Electrical Engineering*, 2021, 90(1): 107022.
- [7] ACHANTA R, SHAJI A, SMITH K, et al. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(11): 2274-2282.
- [8] BALAJI V R. Skin Disease Detection and Segmentation Using Dynamic Graph Cut Algorithm and Classification through Naive Bayes Classifier [J]. *Measurement*, 2020, 163: 107922.
- [9] 杜妍开, 龚丽霞, 李强, 等. 基于多纹理特征融合的震后 SAR 图像倒塌建筑物信息提取 [J]. *遥感技术与应用*, 2021, 36(4): 865-872.
- [10] CORTES C, VAPNIK V. Support-Vector Networks [J]. *Machine Learning*, 1995, 20(3): 273-297.
- [11] FEI S H, WANG M J, MIAO Y B, et al. Particle Swarm Optimization-Based Support Vector Machine for Forecasting Dissolved Gases Content in Power Transformer Oil [J]. *Energy Conversion and Management*, 2009, 50(6): 1604-1609.
- [12] CHAKRABORTY S, SHARMA S, SAHA A, et al. SHADE-WOA: A Metaheuristic Algorithm for Global Optimization [J]. *Applied Soft Computing*, 2021, 113: 107866.
- [13] 盛四清, 关皓闻, 雷业涛, 等. 基于混沌海鸥优化算法的含光伏发电系统负荷模型参数辨识 [J]. *太阳能学报*, 2022, 43(7): 64-72.
- [14] XUE J K, SHEN B. A Novel Swarm Intelligence Optimization Approach: Sparrow Search Algorithm [J]. *Systems Science & Control Engineering*, 2020, 8(1): 22-34.
- [15] 王民, 王静, 张立材, 等. 基于混合色彩空间的分块颜色特征提取算法 [J]. *激光与光电子学进展*, 2018, 55(1): 258-264.
- [16] 兰永康, 顾进立, 许曦. 昆明古建筑别子彩画样式 [M]. 昆明: 云南教育出版社, 2020.
- [17] 薛明, 韦波, 杨禄, 等. GA-PSO 优化 BP 神经网络的遥感影像分类方法 [J]. *遥感信息*, 2020, 35(3): 110-116.

责任编辑 张宥