引文格式：亓航 ,任潇洒 ,李博 ,等. 基于特征优选和优化算法的遥感影像机器学习分类方法[J]. 地理空间信息, 2026, 24(7): 11-17. doi:10.3969/j.issn. 1672-4623.2026.07.003

基于特征优选和优化算法的遥感影像机器学习分类方法

亓　航[1]，任潇洒[2]，李　博[3]，刘法军[1*]，韩　林[1]，陆天启[4]

（1. 山东省地质矿产勘查开发局第五地质大队，山东 泰安 271000；2. 自然资源实物地质资料中心，河北 廊坊 065201；
3. 中国科学院 东北地理与农业生态研究所，吉林 长春 130012；4. 广州海洋地质调查局 三亚南海地质研究所，海南 三亚 572025）

摘　要：基于高分二号遥感影像，提取光谱纹理特征、植被指数、水体指数，利用竞争性自适应重加权算法（CARS）、连续投影算法（SPA）和变量空间迭代收缩法（VISSA）进行特征优选；再结合遗传算法、粒子群迭代法（PSO）、麻雀搜索算法寻找支持向量机（SVM）的最佳参数组合，识别泰山地物类型，并评价分类模型的精度。结果表明，特征优选可剔除冗余信息，有效提升模型性能，CARS的表现优于SPA、VISSA；在参数优化方面，结合CARS与PSO的SVM分类模型具有显著优势，最高总体精度为86.13%，比未加入参数优化的模型提升了1.95%，呈现出较强的稳定性和准确性。研究结果可为生态监测、资源管理和景观保护等提供重要参考。

关键词：高分二号；特征优选；参数优化；地物分类

中图分类号：P237　　**文献标志码：**B　　**文章编号：**1672-4623（2026）07-0011-07

Remote Sensing Image Machine Learning Classification Method Based on Feature Selection and Optimization Algorithm

QI Hang[1], REN Xiaosa[2], LI Bo[3], LIU Fajun[1], HAN Lin[1], LU Tianqi[4]

(1. No.5 Geological Team of Shandong Provincial Bureau of Geology and Mineral Resources, Tai'an 271000, China;
2. Cores and Samples Center of Natural Resources, Langfang 065201, China;
3. Northeast Institute of Geography and Agroecology, Chinese Academy of Sciences, Changchun 130012, China;
4. Sanya Institute of South China Sea Geology, Guangzhou Marine Geological Survey, Sanya 572025, China)

Abstract: Based on GF-2 remote sensing images, we extracted spectral and texture features, vegetation index and water body index, and used competitive adaptive reweighted sampling (CARS), successive projection algorithm (SPA), and variable iterative space shrinkage algorithm (VISSA) to conduct feature selection. Then, we utilized genetic algorithm, particle swarm optimization (PSO), and sparrow search algorithm to optimize the parameters combinations of support vector machine (SVM). Finally, we utilized this method to identify the types of terrain objects on Mount Tai, and evaluated the accuracy of classification model. The results demonstrate that feature selection effectively removes redundant information, significantly enhances model performance. Among the algorithms, CARS outperforms SPA and VISSA. In terms of parameter optimization, the SVM model integrated with CARS and PSO shows superior performance, attaining the highest overall accuracy (86.13%), which is 1.95% higher than models without parameter optimization, presenting strong stability and high accuracy. The research findings provide important references for ecological monitoring, resource management, and landscape protection.

Key words: GF-2, feature selection, parameter optimization, terrain object classification

利用有效的分类方法识别和提取遥感影像中的地物类别，能为地物特征提取、变化检测等应用提供基础支撑[1]。随着遥感技术的快速发展，影像空间分辨率显著提高，其高精度的空间细节和丰富的纹理信息，为影像分类与分析提供了强有力的支持[2-3]。基于光谱、纹理、空间结构等特征构建的分类模型在提升识别精度方面具有显著优势[4-6]；但在实际应用中，多源特征易导致模型运算复杂和处理速度慢的问题，冗余或无关特征则可能进一步导致分类精度的下降。为解决这些问题，关键特征的筛选成为遥感影像分类与识别的重要研究内容，李哲等[7]结合支持向量机（SVM）递归特征消除、C5.0决策树、特征空间优化等方法提取有效数据特征；吴剑飞[8]通过竞争性自适应重加权算法（CARS）、连续投影算法（SPA）和随机蛙跳算法优选高光谱数据的敏感波段，结果表明基于优选后特征数据构建的模型具有更高的精度。此

项目来源：山东省地质矿产勘查开发局科技创新资助项目（KY202104）。
第一作者简介：亓航（1996—），硕士，工程师，主要从事遥感应用工作，E-mail：qih102@nenu.edu.cn。
通信作者：刘法军（1982—），硕士，正高级工程师，主要从事高分应用与地理信息系统工作，E-mail：876557655@qq.com。

外，传统分类方法在处理复杂地物类型时仍面临精度不足和适用性有限的问题，主要从参数优化和模型改进两个方面进行改进。传统优化方法通常采用网格搜索进行参数寻优，原理简单且能确保理论上的全局最优解，但存在计算耗时较长、效率较低、适用范围小的问题[9]；启发式算法通过引入启发规则，以更高的效率向最优解靠近，提供了更加快捷、高效的参数优化方式。相关研究表明，遗传算法（GA）、粒子群算法（PSO）、麻雀搜索算法（SSA）在分类任务中表现较好，能显著提升模型性能[2,10-12]。为提高模型分类精度与计算效率，本文以泰山为研究区，基于高分二号（GF-2）卫星遥感影像，提取影像光谱纹理特征、植被指数、水体指数并进行特征优选；再采用GA、PSO、SSA优化算法搜寻SVM分类模型的最优参数，探索适宜泰山地物类型识别的最佳算法组合，可为区域土地利用现状调查、生态系统监测和城市规划提供科学依据。

1 研究区概况与数据来源

本文选取山东省泰安市和济南市境内的泰山区域作为研究区（图1），地理范围为36°05′~36°30′ N、116°50′~117°24′ E[13]；属暖温带半湿润大陆性季风气候，气温呈现出明显的垂直变化[14]；植被资源丰富，森林植被主要包括针叶林、落叶阔叶林、混交林等，其中松林、侧柏林、刺槐林、栎林4种森林类型所占面积最大，达到90%以上[15]。

GF-2号卫星是我国自主研制的空间分辨率优于1 m的民用光学遥感卫星，搭载0.8 m全色和3.2 m多光谱高分辨率相机[16]。本文以2023年5月7日和2023年11月30日植被处于不同生长期的GF-2号影像为主要数据源，对影像进行辐射校正、正射校正、按掩膜提取、数据归一化等预处理，获得两期蓝光、绿光、红光、近红外4个波段的0.8 m正射产品影像。森林资源管理“一张图”数据包括坡度、坡向、坡位、优势树种、林种、郁闭度等字段，能作为植被解译的参考依据[17]。由于泰山区域范围较大且地形复杂，地物类型在复杂地形条件下具有较高的光谱异质性，非监督分类难以有效区分不同地物类别，而单纯依赖人工调查的工作量大、耗时长[18]。本文以森林资源管理“一张图”数据为基础，结合不同季节GF-2号影像数据，根据地物类型季节变化特性、空间分布特征和光谱差异性，在研究区内选取1 371个样本点，地物类型分为栎林、刺槐、侧柏、松林、其他植被、水体、道路、建筑和裸地9个类别；按照7∶3的比例划分为训练集和验证集，用于构建分类模型与验证精度（表1）。

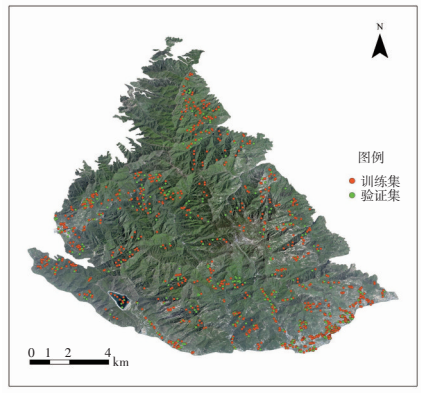


图1 研究区位置与样本点分布图

表1 各类样本数量/个

地物类型	训练集样本数	验证集样本数	样本总数
栎林	130	57	187
刺槐	81	29	110
侧柏	104	57	161
松林	219	82	301
其他植被	82	21	103
水体	25	14	39
道路	85	45	130
建筑	168	81	249
裸地	66	25	91

2 研究方法

本文以预处理后的GF-2号影像和森林资源管理“一张图”为数据基础，选取样本点并提取特征；再采用多种特征优选算法筛选样本特征，基于不同的参数优化算法搜寻SVM模型的最优参数组合；最后对比分析不同分类结果的精度，确定最合适的分类方案，输出结果影像。

2.1 特征提取与优选

1）特征提取。各类地物在不同时相、不同波段上的特性存在差异，可利用光谱特征判断地物属性[4]。纹理特征能通过空间结构差异增强类别可分性，灰度共生矩阵[19]具有稳定性好、鲁棒性强的特点，是一种应用广泛的纹理特征提取方法。植被指数能量化植被覆盖程度和密度，有效识别植被与非植被区域、落叶林和常绿林等。通过提取水体指数，可准确区分山体阴影与水体。本文选取的光谱特征包括蓝光（Blue）、绿光（Green）、红光（Red）、近红外（NIR）波段，纹理特征包括均值（Mean）、方差（Variance）、同质性（Homogeneity）、对比度（Contrast）、差异性

（Dissimilarity）、熵（Entroy）、角二阶矩（Angular Second Moment）、相关性（Correlation），植被指数特征包括归一化植被指数（NDVI）、增强型植被指数（EVI），水体指数特征为归一化水体指数（NDWI）。

2）特征优选。为降低数据维度，剔除相关性较低的变量，提高模型的运算速度，本文采用SPA、CARS和变量空间迭代收缩法（VISSA）对预处理后的样本集进行特征优选。SPA基于向量空间基变换原理，通过逐步选择具有最大投影值的特征变量，有效去除冗余信息并缓解多重共线性问题[20]。CARS采用蒙特卡洛采样与自适应加权算法进行多次随机采样和模型构建。交叉验证以使均方根误差最小的特征集为最优特征子集[8]。VISSA借助模型集群分析思想，在迭代过程中优化变量子空间，提取最具代表性的特征变量[21]。

2.2　建模方法

SVM是基于统计学理论的机器学习方法，通过引入核函数将非线性问题映射到高维线性空间，根据结构风险最小化原则达到全局最优解，能有效解决小样本、非线性、高维模式识别问题[22]。然而，相关研究表明SVM对惩罚因子 C 和核函数参数 g 选取的敏感度较高，选取不当将影响模型精度[10]。GA是基于自然选择和生物进化机制的全局优化算法，通过模拟生物的繁殖、变异和竞争过程，逐步进化出适应环境最优或近优的个体解[2]。PSO是一种启发式全局优化算法，模拟粒子在解空间中的飞行运动，动态调整粒子的速度和位置，从而逐步逼近最优解[23]。SSA是基于对麻雀捕食行为的群体智能优化算法，模拟麻雀群中的发现者、跟随者以及它们在食物搜寻过程中的协作与竞争机制，进行全局最优解的探索[24]。本文利用GA、PSO、SSA寻找SVM的最优 C、g 参数组合。

2.3　精度评价

本文利用混淆矩阵计算总体精度（*OA*）、生产者精度（*PA*）、用户精度（*UA*），从而评价模型分类结果的精度。*PA* 是被正确识别的样本与被识别为该类别的所有样本的比值，*UA* 是被正确识别样本数与真实样本数的比值[25]，*OA* 是所有分类结果的总体评价指标。

3　研究结果与分析

3.1　特征优选

基于两期GF-2号影像提取8个光谱特征、64个纹理特征、4个植被指数和2个水体指数特征，经SPA、VISSA、CARS特征优选，分别筛选出23、13、15个特征。SPA筛选的特征为202305-Green、202305-Red、202305-NIR、202311-Green、202311-Red、202311-NIR、202305-EVI、202305-NDVI、202305-NDWI、202311-EVI、202311-NDVI、202311-NDWI、202305-Blue-Homogeneity、202305-Blue-Contrast、202305-Blue-Dissimilarity、202305-Green-Homogeneity、202305-Green-Contrast、202305-Green-Dissimilarity、202305-Red-Mean、202305-NIR-Homogeneity、202305-NIR-Contrast、202305-NIR-Dissimilarity、202311-Red-Mean；VISSA筛选的特征为202305-Green、202305-Red、202305-EVI、202305-NDVI、202305-NDWI、202311-NDVI、202311-NDWI、202305-Blue-Mean、202305-Red-Mean、202305-NIR-Mean、202305-NIR-Entropy、202305-NIR-Angular Second Moment、202311-Red-Mean；CARS筛选的特征为202305-Green、202311-Green、202305-EVI、202305-NDVI、202305-NDWI、202311-NDVI、202311-NDWI、202305-Blue-Mean、202305-Blue-Homogeneity、202305-Red-Mean、202305-NIR-Mean、202311-Blue-Mean、202311-Red-Mean、202311-Blue-Dissimilarity、202311-Red-Variance。3种优选算法均筛选出5月Green、EVI、NDVI、NDWI以及11月NDVI和NDWI特征，说明这些特征对地物分类具有重要区分作用。在提取的64个纹理特征中，SPA、VISSA、CARS仅分别筛选出11、6、8个纹理特征，表明纹理特征存在较高的冗余度。3种算法的特征筛选结果均包括Green、EVI、NDVI、NDWI以及Red-Mean，表明它们在遥感影像多目标地物分类中具有重要作用。植被的叶绿素在绿光波段表现出显著的反射特性，不同森林类型（栎林、松林、刺槐、侧柏等）因其叶片结构和叶绿素含量的不同，在绿光波段的反射率存在差异。EVI和NDVI结合了蓝光、红光、近红外波段的信息，能量化植被覆盖程度和密度，有效划分植被与非植被区域。落叶阔叶林与常绿针叶林在5月（夏季）与11月（冬季）的植被指数特征差异较大，夏季落叶阔叶林植被指数值较高、冬季常绿针叶林植被指数较高。NDWI通过对比近红外和绿光波段的反射率变化，不仅可以识别水体和非水体区域，而且能有效区分山体阴影与水体。均值纹理特征能捕获影像中地物的空间结构信息，各地物类型因其粗糙度、斑块大小和形状等表面特性的不同，在纹理上表现出显著差异，为分类提供了重要特征。

SPA筛选的特征数量最多，在5月和11月选择了较多的光谱特征，表明SPA较注重时间序列的光谱变化信息；此外对5月蓝光、绿光、近红外波段的异质

性、对比度、差异性和11月红光波段均值等纹理特征也较敏感。VISSA的选择结果最少，倾向于保留与光谱信息相关的特征，纹理特征主要选择了均值纹理特征，表明VISSA更注重区分性强、冗余度较低的特征。CARS与VISSA保留的特征相似，但更考虑时序变化信息，CARS在平衡特征的多样性和独立性方面具有一定优势。

3.2 模型总体精度分析

不同特征优选算法的分类器*OA*见表2，可以看出，通过SPA、VISSA、CARS筛选后的特征比ALL-SVM验证集*OA*分别提高了3.89、2.67、5.10个百分点。此外，ALL-SVM的训练集与验证集*OA*差值最大，说明特征优选算法不仅能有效提取关键特征，还能增强模型的稳定性和泛化能力。CARS-SVM的分类效果最好，训练集与测试集*OA*最高且差值最小。与SPA、VISSA相比，CARS更能增强特征与地物类别的相关性，消除冗余信息，提高模型的运行效率。需要注意的是，SPA-SVM的验证集*OA*高于训练集*OA*，应进一步调整模型参数，优化分类效果。

表2 基于特征优选的SVM分类模型精度对比/%

算法组合	训练集*OA*	验证集*OA*	*OA*差值
SPA-SVM	81.67	82.97	1.30
VISSA-SVM	83.33	81.75	1.58
CARS-SVM	84.27	84.18	0.09
ALL-SVM	83.33	79.08	4.25

采用GA、PSO、SSA对基于不同特征优选算法的SVM分类模型进行参数寻优，各分类算法组合的*OA*见表3，与未加入优化算法的分类模型（表2）相比，结合优化算法后SPA-SVM、VISSA-SVM、CARS-SVM的精度均有所提高，验证集*OA*平均提高了1.46、2.37、1.06个百分点，说明优化算法通过全局搜索和迭代优化，能找到更合适的SVM超参数组合，提升分类器性能。GA、PSO、SSA优化VISSA-SVM后的训练集*OA*最高，但对应验证集*OA*在所有算法组合中最低，说明模型的过拟合风险较高，稳定性较弱。与其他算法组合相比，CARS-PSO-SVM模型精度最高，训练集与验证集精度差值最小（2.31%），说明基于CARS特征优选与PSO参数优化算法的SVM模型具有最佳的分类性能、较强的泛化能力和稳定性。

表3 基于特征优选和参数优化算法的SVM分类模型精度对比/%

特征优选算法	GA			PSO			SSA		
	训练集*OA*	验证集*OA*	*OA*差值	训练集*OA*	验证集*OA*	*OA*差值	训练集*OA*	验证集*OA*	*OA*差值
SPA-SVM	91.77	83.94	7.83	88.44	84.67	3.77	89.06	84.67	4.39
VISSA-SVM	93.85	83.70	10.15	93.65	84.18	9.47	92.92	84.48	8.44
CARS-SVM	93.02	84.67	8.35	88.44	86.13	2.31	90.73	84.91	5.82

3.3 分类结果分析

为进一步分析模型分类效果，通过*PA*、*UA*分析不同地物类型的分类精度。基于不同特征优选算法的SVM分类模型*PA*、*UA*见表4，可以看出，特征优选后的地物类型分类结果精度均有所提升；其中SPA-SVM在栎林、刺槐、松林、水体的分类效果较好，*PA*为87.72%、55.17%、93.90%、100%，*UA*为87.72%、76.19%、81.91%、100%；CARS-SVM对道路、建筑和裸地的识别效果较好，*PA*、*UA*分别为84.44%、86.42%、80.00%和80.85%、88.61%、86.96%。

表4 基于特征优选的SVM分类模型各地物精度对比/%

地物类型	ALL-SVM		SPA-SVM		VISSA-SVM		CARS-SVM	
	PA	*UA*	*PA*	*UA*	*PA*	*UA*	*PA*	*UA*
栎林	84.21	82.76	87.72	87.72	87.72	81.97	87.72	81.97
刺槐	41.38	63.16	55.17	76.19	44.83	65.00	55.17	64.00
侧柏	87.72	89.29	87.72	90.91	85.96	92.45	87.72	94.34
松林	90.24	78.72	93.90	81.91	92.68	80.85	89.02	82.95
其他植被	57.14	57.14	71.43	75.00	71.43	75.00	71.43	75.00
水体	78.57	91.67	100.00	100.00	92.86	100.00	100.00	93.33
道路	66.67	69.77	68.89	75.61	71.11	76.19	84.44	80.85
建筑	85.19	78.41	85.19	80.23	85.19	78.41	86.42	88.61
裸地	76.00	95.00	76.00	82.61	76.00	95.00	80.00	86.96

基于特征优化数据，加入优化算法后的SVM分类模型*PA*与*UA*见表5，结果表明，优化算法通过调整模型参数，使得SVM能更好地适应不同类别的特征，从而提升了分类精度。其中，CARS-GA-SVM对刺

槐、侧柏、松林的识别效果最好，*PA*、*UA*分别为65.52%、89.47%、96.34%和73.08%、91.07%、84.04%；CARS–PSO–SVM对栎林、道路、建筑的识别精度最高，*PA*、*UA*值分别为87.72%、86.67%、87.65%和86.21%、79.59%、92.21%；VISSA–PSO–SVM在裸地识别方面具有优势，*PA*、*UA*为92.00%和85.19%；SPA–GA–SVM对其他植被的识别精度较高，*PA*、*UA*分别为85.71%和75.00%。

表5　基于特征优选、参数优化和SVM的*PA*和*UA*对比/%

特征优选	地物类型	GA		PSO		SSA	
		PA	*UA*	*PA*	*UA*	*PA*	*UA*
SPA–SVM	栎林	84.21	88.89	87.72	90.91	87.72	90.91
	刺槐	62.07	75.00	62.07	78.26	62.07	78.26
	侧柏	85.96	92.45	85.96	92.45	85.96	92.45
	松林	91.46	81.52	92.68	82.61	92.68	82.61
	其他植被	85.71	75.00	85.71	72.00	85.71	72.00
	水体	100.00	100.00	100.00	100.00	100.00	100.00
	道路	82.22	77.08	77.78	79.55	77.78	79.55
	建筑	82.72	83.75	86.42	82.35	86.42	82.35
	裸地	76.00	86.36	72.00	90.00	72.00	90.00
VISSA–SVM	栎林	85.96	85.96	85.96	85.96	85.96	89.09
	刺槐	65.52	65.52	65.52	63.33	65.52	65.52
	侧柏	85.96	94.23	85.96	94.23	85.96	94.23
	松林	89.02	81.11	89.02	81.11	90.24	81.32
	其他植被	76.19	80.00	76.19	84.21	76.19	72.73
	水体	100.00	100.00	100.00	100.00	100.00	100.00
	道路	75.56	77.27	77.78	77.78	73.33	73.33
	建筑	82.72	87.01	83.95	88.31	80.25	85.53
	裸地	92.00	82.14	92.00	85.19	80.00	74.07
CARS–SVM	栎林	80.70	90.20	87.72	86.21	85.96	87.50
	刺槐	65.52	73.08	62.07	75.00	62.07	72.00
	侧柏	89.47	91.07	87.72	94.34	87.72	94.34
	松林	96.34	84.04	92.68	83.52	93.90	83.70
	其他植被	80.95	80.95	80.95	73.91	80.95	80.95
	水体	100.00	100.00	100.00	100.00	100.00	100.00
	道路	82.22	80.43	86.67	79.59	82.22	77.08
	建筑	80.25	87.84	87.65	92.21	82.72	88.16
	裸地	80.00	68.97	76.00	86.36	80.00	76.92

在使用特征优选和参数优化算法的SVM分类模型中，水体的*PA*、*UA*均为100%，而通过对分类结果进行更细致的局部分析发现（图2），只有CARS–PSO–SVM和CARS–SSA–SVM两种算法能更完整地提取出水体区域，其他算法组合则存在不同程度的水体与道路混淆现象。在林地区域的识别中，CARS–PSO–SVM分类结果在地物类别内部具有较高的同质性，混杂其他类别的现象较少，具有更完整的目标提取效果。

相关研究表明[6,26]，与仅使用光谱特征相比，加入纹理特征能提高地物类型的识别精度。由于研究区覆盖大范围森林类型，本文利用两期高分辨率影像提取光谱、纹理、植被和水体指数特征，经SPA、VISSA、CARS优选后，保留了大部分的光谱、植被和水体指数信息，而64个原始纹理特征中仅有少数几种被保留。结合特征优选算法的SVM分类结果显示，采用CARS筛选后数据构建的模型精度最高，说明影像的空间结构信息存在较强的相关性，但加入过多的纹理特征并不能显著提高模型识别能力[7]。本文基于特征优选后的数据集，利用GA、PSO、SSA寻找SVM的最优参数组合。结果表明，优化算法能有效提高模型分类精度，CARS–GA–SVM在森林类型识别中表现较好，CARS–PSO–SVM对不透水地表（道路、建筑）的识别精度最高，VISSA–PSO–SVM更适用于裸地的提取。综

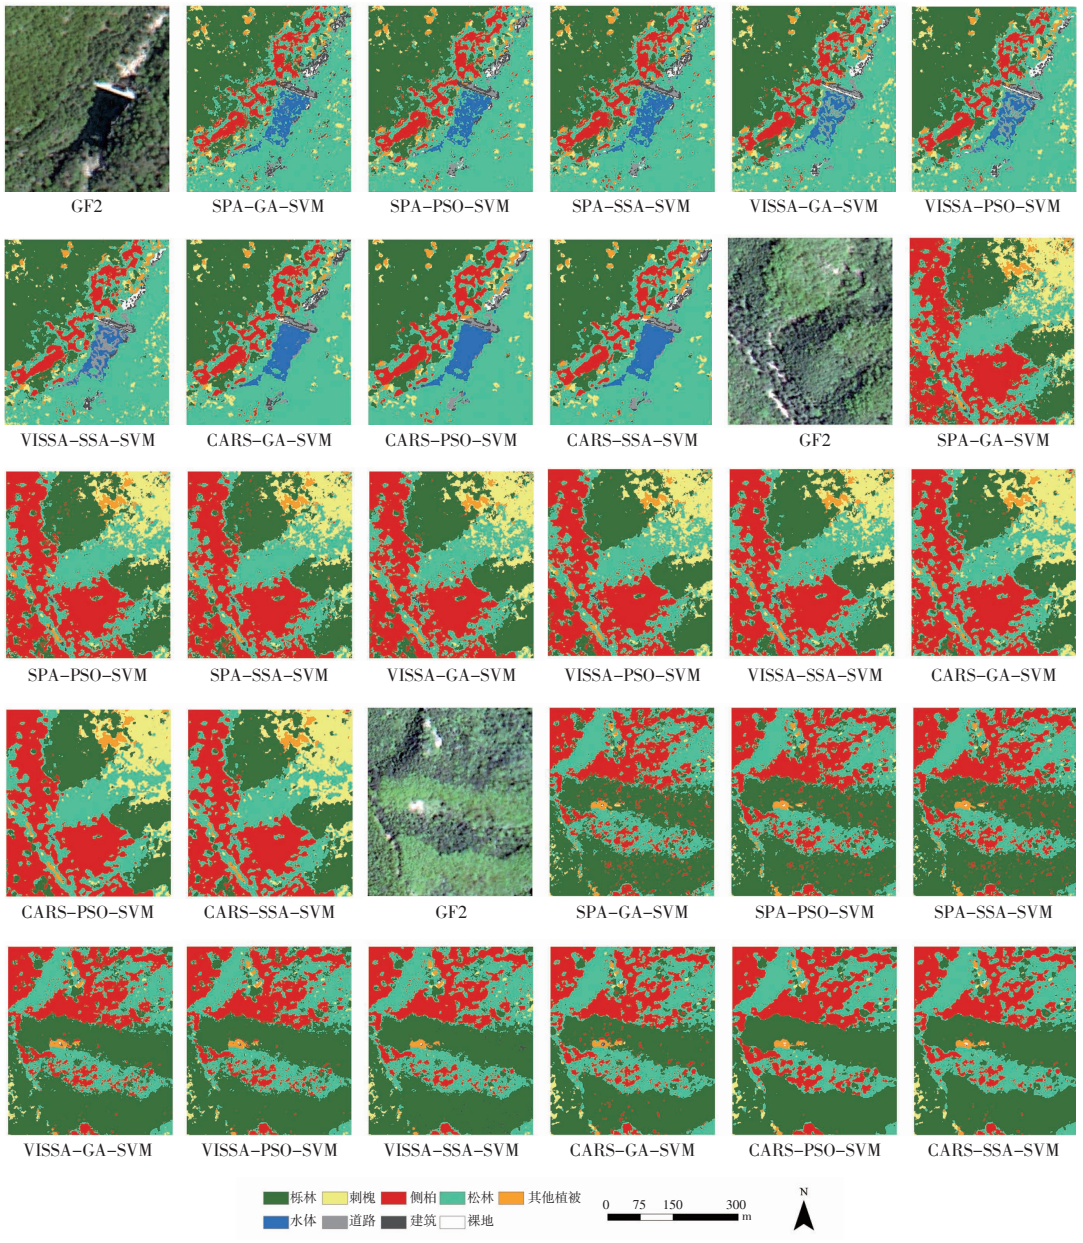


图2　分类结果局部放大图

合来看，CARS-PSO-SVM更适合泰山区域的地物类型分类，精度最高，训练集与验证集的精度差异最小，分类结果混杂现象较少，具有较好的分类效果和泛化能力。

为验证特征优选与参数优化算法对其他分类方法的适用性，本文进一步测试了结合特征选择和参数优化的随机森林（RF）分类模型。结果表明（表6），在未经优化的情况下RF模型训练集、验证集*OA*分别为100.00%和82.24%，模型存在明显的过拟合现象；采用特征优选与参数优化后，RF模型各算法组合的训练集和验证集精度差值显著减小，过拟合程度降低，且验证集*OA*普遍提高，说明模型的稳健性和准确性均有所增强，其中VISSA-SSA-RF的验证集*OA*最高。然而，相较于SVM模型，RF模型在验证集上的分类精度略显不足；在算法运行时间方面，优化后的RF模型平均耗时约为3 h，SVM模型约为1 h。综合比较运行效率、模型泛化能力和分类结果质量，SVM算法组合在泰山区域的地物类型分类中更具优势。

此外，在所有分类结果中，刺槐的分类精度较低。李哲等[7]在利用多时相GF-2号影像进行树种分类研究时发现，由于GF-2号影像空间分辨率较高、光谱分辨率较低，存在异物同谱的情况，刺槐等阔叶树种的分类效果普遍低于针叶树种。在后续的研究中，可以考虑融合多源遥感影像，获取高光谱长时间序列的数据，采用深度学习方法进行特征提取和分类任务，以提高地物分类的精细度和识别效果。

表6　RF算法组合OA对比/%

算法组合	训练集 *OA*	验证集 *OA*	*OA* 差值
RF	100.00	82.24	17.76
SPA-GA-RF	90.00	82.97	7.03
SPA-PSO-RF	88.54	84.18	4.36
SPA-SSA-RF	88.85	83.70	5.15
VISSA-GA-RF	89.48	83.94	5.54
VISSA-PSO-RF	87.50	83.70	3.80
VISSA-SSA-RF	90.83	84.43	6.40
CARS-GA-RF	89.17	82.97	6.20
CARS-PSO-RF	90.52	83.21	7.31
CARS-SSA-RF	89.79	83.46	6.33

4　结　论

本文基于两期GF-2号卫星遥感影像，结合特征优选、参数优化算法和SVM分类模型，识别了泰山区域的地物类型。结果表明，特征优选可有效筛选出关键地物信息，在降低数据维度的同时显著提高模型的分类性能，CARS表现最佳，*OA* 最高（84.18%），比未进行特征优选的模型提升了5.2%；参数优化算法能自动寻找SVM模型 *C*、*g* 参数的最优组合，进一步提高分类精度，CARS-PSO-SVM的 *OA* 最高（86.13%），且训练集和训练集差值最小（2.31%），比CARS-SVM提高了1.95%，具有较高的稳健性和准确性；CARS-PSO-SVM分类结果影像中的混杂现象较少，能实现地物的完整识别。本文构建的基于特征优选和参数优化的分类模型，不仅为泰山区域高分辨率遥感影像的地物信息提取提供了科学依据，还为其他类似生态敏感区的遥感监测和管理提供了重要参考。

参考文献

[1] 尚明,马杰,李悦,等. Landsat和GF数据面向对象土地覆盖分类研究[J]. 自然资源遥感,2024,36(3):240-247

[2] 乔慧娇,杜芳静,许镇藩,等. 基于GA-SA特征优选算法的Sentinel-2影像分类[J/OL]. (2025-01-07) [2025-04-11]. 太原理工大学学报 http://kns.cnki.net/kcms/detail/14.1220.N.20250107.1412.002.html

[3] 潘玥,金利娇,陈竹安,等. 协同GF-2号和OLI影像的土地利用模糊分类方法[J]. 地理空间信息,2020,18(11):26-30

[4] 王晓洋,姜友谊,黎晓,等. 基于GF-1影像的多时相多特征落叶松人工林提取研究[J]. 林业资源管理,2022(4):109-118

[5] 江济强,郑华健,刘洪顺. 多源时序数据特征优选的南方丘陵山区农作物分类研究[J]. 地理空间信息,2024,22(11):24-31

[6] 钟滨,廖永皓,蔡海生. 基于光谱与纹理特征的高分二号竹林信息提取:以庐山自然保护区为例[J]. 测绘与空间地理信息,2020,43(12):8-13

[7] 李哲,张沁雨,彭道黎. 基于高分二号遥感影像的树种分类方法[J]. 遥感技术与应用,2019,34(5):970-982

[8] 吴剑飞. 高光谱技术识别煤岩的特征波段筛选方法研究[J]. 黑龙江工程学院学报,2022,36(2):13-19

[9] 李楠,朱秀芳,潘耀忠,等. 人工蜂群算法优化的SVM遥感影像分类[J]. 遥感学报,2018,22(4):559-569

[10] 刘美辰,薛河儒,刘江平,等. 牛奶蛋白质含量的SSA-SVM高光谱预测模型[J]. 光谱学与光谱分析,2022,42(5):1601-1606

[11] 郑浩,贾展飞,周丽婷,等. 基于PSO-XGBoost的风电叶片缺陷分类算法[J]. 太阳能学报,2024,45(4):127-133

[12] 薛琳. 运用边缘保持滤波和改进核模糊聚类的遥感影像分类[J]. 地理空间信息,2024,22(12):42-45

[13] 韦秋雨. 基于RS的泰山主要建群树种空间分布的环境解释及应用[D]. 泰安:山东农业大学,2019

[14] 余世孝,郭泺. 山东泰山地区景观结构变化及其分形分析[J]. 生态学报,2005,25(1):129-134

[15] 郭泺,余世孝. 泰山风景区景观格局时空变化的研究[J]. 应用生态学报,2005,16(4):641-646

[16] 张智华,余锦佩,李军伟,等. 高分二号遥感影像融合方法比较分析[J]. 江西测绘,2022(4):31-34

[17] 宋歌,韩芳,许景伟,等. 基于LandUSEM模型的山东沿海防护林树种分布适宜性分析[J]. 南京林业大学学报(自然科学版),2023,47(4):42-50

[18] 韩芳,李传荣,申卫星,等. 泰山风景区油松的空间分布地形分异特征研究[J]. 山东理工大学学报(自然科学版),2019,33(3):1-7

[19] Haralick R M, Shanmugam K, Dinstein I. Textural Features for Image Classification[J]. lEEE Transactions on Systems, Man and Cybemeties, 1973, 3(6):610-621

[20] 李廉洁,樊书祥,王学文,等. 高光谱成像的煤与矸石分类[J]. 光谱学与光谱分析,2022,42(4):1250-1256

[21] Deng B C, Yun Y H, Liang Y Z, et al. A Novel Variable Selection Approach that Iteratively Optimizes Variable Space Using Weighted Binary Matrix Sampling[J]. Analyst, 2014,139(19):4836-4845

[22] 张妮娜,张珂,李运平,等. 中国南方典型湿润山区植被类型的无人机多光谱遥感机器学习分类研究[J]. 遥感技术与应用,2023,38(1):163-172

[23] 刘涛,刘望,杨奉源,等. 基于无人机高光谱影像和机器学习算法的花生生物量估算方法研究[J]. 中国农业大学学报,2025,30(3):206-217

[24] 吕鑫,慕晓冬,张钧. 基于改进麻雀搜索算法的多阈值图像分割[J]. 系统工程与电子技术,2021,43(2):318-327

[25] 陈珠琳,李添雨,张耀方,等. 基于高光谱数据的密云水库水生态空间地物精细分类[J]. 空间科学学报,2024,44(1):103-113

[26] 王美月,万红,刘法军,等. 基于哨兵二号红边波段特征的作物分类[J]. 山东农业大学学报(自然科学版),2025,56(1):11-20