

# 一种基于集成学习和特征融合的遥感影像分类新方法

刘培<sup>1</sup>, 杜培军<sup>2\*</sup>, 谭琨<sup>1</sup>

(1. 中国矿业大学 江苏省资源环境信息工程重点实验室, 江苏 徐州 221116;  
2. 南京大学 江苏省地理信息技术重点实验室, 江苏 南京 210046)

**摘要:** 针对多源遥感数据分类的需要, 提出了一种基于全极化 SAR 影像、极化相干矩阵特征、光学遥感影像光谱和纹理的多种特征融合和多分类器集成的遥感影像分类新方法。对全极化 PALSAR 数据进行预处理和极化相干矩阵特征提取, 利用灰度共生矩阵计算光学和 SAR 影像的对比度、逆差距、二阶距、差异性等纹理特征参数, 并与光谱特征结合, 形成 6 种组合策略。利用集成学习方法对随机森林分类器、子空间分类器、最小距离分类器、支持向量机分类器、反向传播神经网络分类器等分类器进行组合, 对不同组合策略的遥感影像特征集进行分类。结果表明提出的基于多种特征和多分类器集成的新方法很好地利用了主被动遥感数据在不同地表景观类型提取上的潜力, 综合了多种算法的优势, 能够有效地提高总体精度和各类别的分类精度。

**关 键 词:** 光谱特征; 纹理特征; 极化特征; 集成学习; 特征融合; 分类

中图分类号:P237 文献标识码:A

## A novel remotely sensed image classification based on ensemble learning and feature integration

LIU Pei<sup>1</sup>, DU Pei-Jun<sup>2\*</sup>, TAN Kun<sup>1</sup>

(1. Jiangsu Key laboratory of Resources and Environment Information Engineering, China University of Mining and Technology, Xuzhou 221116, China;  
2. Jiangsu Provincial Key Laboratory of Geographic Information Science and Technology, Nanjing University, Nanjing 210046, China)

**Abstract:** To make full use of the multi-source remotely sensed data for classification, a novel method was proposed based on the integration of full-polarization SAR (HH, HV, VH, VV) data, features of polarization coherence matrix, spectral features provided by optical data, texture features extracted from optical and SAR data and multi-classifier ensemble. Preprocessing for full-polarization data was performed and polarimetric features are extracted from polarization coherence matrix. Spatial textural features including contrast, dissimilarity, second moment, etc., are extracted from PALSAR full-polarization data and optical image using Grey-level Co-occurrence Matrix (GLCM) method. Features of polarization coherency matrix, full-polarization SAR channels, spectral and textures are integrated by 6 strategies. Some well-known classification techniques, including Support Vector Machine (SVM), Minimum Distance (MD), Back Propagation Neural Network (BPNN), Multi-Layer Perceptron (MLP), Random Subspace (RSS), Random Forest (RF) classifiers were selected to test different combination strategies. The parallel and sequential ensemble learning techniques were selected to integrate single classifier for land cover classification. The results indicate that the proposed approach integrating multi-source, multi-features and multi-classifier strategy can make full use of the potential of optical and SAR remotely sensed data for landscape types, and improve the overall accuracy and the accuracy of single land cover type effectively.

**Key words:** spectral features, textural features, polarimetric features, ensemble learning, feature integration, classification  
**PACS:** 43.28. We, 43.60. Rw, 07.07. Df

收稿日期:2013-03-02,修回日期:2013-09-25

Received date: 2013-03-02, revised date: 2013-09-25

基金项目:国家自然科学基金项目(NSFC-41171323);江苏省自然科学基金(201021539)项目;江苏省研究生培养创新工程基金项目(CX09B\_115Z)

**Foundation items:** Supported by the National Natural Science Foundation of China (NSFC-41171323); Natural Science Foundation of Jiangsu Province of China (201021539), Graduate Education Innovation Project of Jiangsu Province (CX09B\_115Z)

**作者简介(Biography):** 刘培(1985-),男,河南许昌人,博士研究生. E-mail: cumtlp@gmail.com.

\* 通讯作者(Corresponding author): E-mail: dupjrs@126.com.

## 引言

随着航空航天遥感技术的不断发展,遥感平台获取的遥感数据朝着多波段、多极化、多分辨的趋势发展,可获得的对地观测数据越来越多,为区域、全球监测等不同尺度应用都提供了支持<sup>[1]</sup>。光学图像具有丰富的光谱信息,能够有效区分不同地表覆盖类型,但是对“同物异谱、异物同谱”情况却不能很好处理。雷达数据由于其自身具有一定的穿透性,可以获取地表的粗糙度、结构、纹理等信息,从而有效区分地物,弥补光学图像的不足<sup>[2]</sup>。在过去十年中,遥感图像分类的研究主要集中在分别从光学和SAR数据提取信息,如Brunner等提出了快速从SAR数据中提取城市覆盖信息<sup>[3]</sup>;Zhong等发展了从光学数据中提取城市覆盖信息的技术方法<sup>[4]</sup>。

近年来,越来越多的研究者加强了光学与雷达数据集成处理的研究<sup>[5]</sup>。Sportouche等通过融合高分辨率光学和SAR图像实现了城区建筑物的提取<sup>[6]</sup>,Brunner等通过集成处理光学和SAR影像评价地震灾害情况<sup>[7]</sup>。但是目前的研究多数偏重于集成主被动特征对某一专题信息的提取,对集成多源特征的土地覆盖分类的研究并不多。自Gamba等在其综述性文献[8]中讨论了多源数据特别是主被动数据集成/融合在城市覆盖的应用问题以后,学术界不少学者尝试了通过数据融合的方法来提高遥感图像分类精度。如Dong等详细介绍了多传感器数据融合的算法和应用<sup>[9]</sup>,Zhang等利用随机森林算法融合SPOT和ASAR数据实现城市土地利用/覆盖制图<sup>[10]</sup>,Rusmini等分别通过基于像素和基于对象的融合方法对高空间分辨率光学GeoEye-1、COSMO-SkyMed雷达数据进行融合后提取米兰市部分土地利用/覆盖信息<sup>[11]</sup>,Gamba等利用GS、HSV、PCA、ATWT+HIS融合方法分别对ALOS光学和雷达数据、Landsat光学和ERS雷达数据进行融合后土地利用/覆盖信息提取,并进行评价分析<sup>[12]</sup>。以上研究表明由于光学和雷达数据的成像机理不同,现有的融合算法如基于光谱/彩色域变化的HIS、PCA融合算法,基于代数运算的BT、MT融合算法,基于空间域信号分解和重构的HPF、SFIM、WT融合算法都不能很好适用与光学和雷达数据的融合,即使能够提高融合后分类效果,提高的幅度也不是很明显。

针对主被动遥感数据分类的需要,本文提出的遥感影像分类新方法,不仅体现了不同集成策略的优、劣势,也评价验证了不同分类器在主被动数据集

成处理的能力。

## 1 技术方法

图1为所提出方法的技术流程,利用灰度共生矩阵方法对预处理过的光学影像和雷达数据提取反差、差异性、二阶距等空间纹理特征,并且在预处理PALSAR L1.0数据的同时提取极化相干矩阵特征,通过构建主被动多源特征集成策略,实现光谱、纹理与极化特征的融合。以所构建的多源特征集成组合为基础,利用多分类器集成技术对不同的特征组合策略进行土地利用/覆盖信息提取。根据多种分类器算法及其集成学习结果对景观信息的提取精度,比较分析和评价多源特征组合和多分类器集成在研究区域的适用性和各自的优缺点。

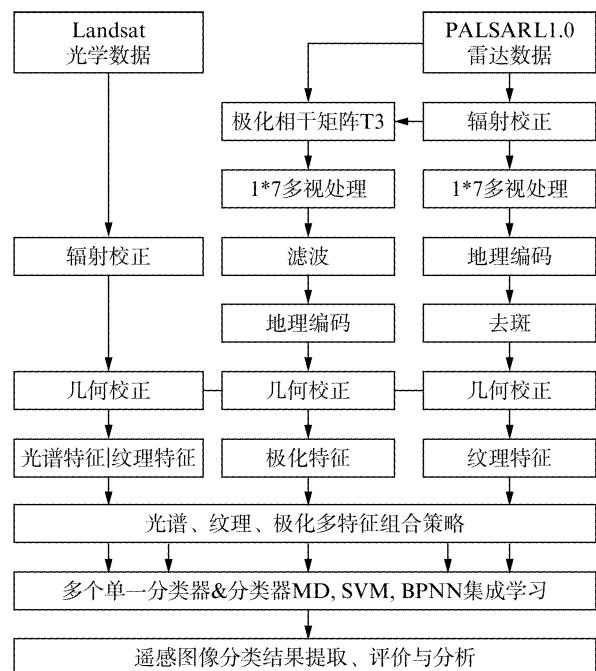


图1 集成分类方法的技术流程

Fig. 1 Flow chart of ensemble classification method

### 1.1 纹理和极化相干矩阵特征

空间测量指标从简单的统计方法到傅里叶变换提供了图像的视觉特征的定量描述<sup>[13]</sup>。图像空间中相隔某距离的两个像素之间会存在一定的灰度关系,而灰度共生矩阵就是一种通过研究灰度的空间相关特性来描述纹理的常用方法,通过计算两个未知像素的联合概率密度,不仅可以反映亮度的分布特征,也反映具有同样亮度或接近亮度的像素之间的位置分布特征。灰度共生矩阵的数学模型和其特征参数纹理中值、协方差、同质性、熵、反差、差异性、

二阶距、自相关的数学模型详细见参考文献[14].

极化在光学遥感中被称为偏振,根据介质物理性质不同,不同的偏振状态蕴含反射面介质的不同信息,与光学数据相比,雷达数据具有更长的波长,对地表的穿透效应更明显,因此能够获取与光学数据互补的地表信息<sup>[15]</sup>. 地表目标的极化行为可以被描述为 $2 \times 2$  辛克莱散射矩阵式(1),通过不同的散

$$T_3 = \langle k_p \cdot k_p^{* T} \rangle = \frac{1}{2} \begin{bmatrix} \langle |S_{HH} + S_{VV}|^2 \rangle & \\ \langle (S_{HH} - S_{VV})(S_{HH} + S_{VV})^* \rangle & \\ 2\langle S_{HV}(S_{HH} + S_{VV})^* \rangle & \end{bmatrix}$$

## 1.2 多源特征集成策略

光学和雷达数据能够提供地表光谱信息、纹理信息和散射信息,特别是全极化 SAR 数据及其极化参数包含了丰富的地表信息. 通过集成多种特征有利于提高地物识别精度. 分别从光学影像和雷达 PALSAR 极化通道提取光谱特征和纹理特征,从 PALSAR 数据中提取极化相干矩阵特征. 将提取的纹理特征、极化特征、波谱特征经过实验筛选提出 6 组不同集成策略. 由于实验中使用的多光谱影像和 SAR 数据信息冗余较小,因此研究中特征的选择主要考虑的是特征的信息量,将光谱特征、纹理特征和极化相干矩阵特征组合形成多种分类特征集进行分类处理,旨在探讨利用多特征数据融合进行遥感分类的有效性和分类过程中不同组合在集成学习中的优势. 所选组合分别为: 原始光学遥感影像; 光学遥感影像与雷达数据集成; 光谱特征与 Hermitian 矩阵特征集成; 光谱特征、雷达原始极化通道特征与 Hermitian 矩阵非对角线实部元素、虚部元素特征信息集成; 光谱特征、雷达原始极化通道特征与 Hermitian 矩阵特征集成; 光谱特征、雷达原始极化通道特征与 Hermitian 矩阵特征以及基于 GLCM 的空间纹理特征集成. 具体如表 1 所示.

表 1 空间、波谱、极化特征组合策略

Table 1 Combination strategy of spatial textures, spectral and polarimetric features

策略	数据源	变量	组合
1	OPT	6	光学 1-5,7
2	SAR + OPT	10	SAR 和光学
3	OPT + T3	15	OPT, T11, T22, T33, R12, R13, R23, I12, I13, I23
4	OPT + SAR + offT3	16	SAR, OPT, R12, R13, R23, I12, I13, I23
5	OPT + SAR + T3	19	SAR, OPT, T11, T22, T33, R12, R13, R23, I12, I13, I23
6	OPT + SAR + GLCM + T3	25	SAR, OPT, T11, T22, T33, R12, R13, R23, I12, I13, I23, GLCM

注: T11, T12, T13 为 T3 的实对角线元素; R12, R13, R23 为非对角线元素的实部; I12, I13, I23 为非对角线元素的虚部

射目标向量式(2)来区分不同的散射信息.

$$S = \begin{pmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{pmatrix}, \quad (1)$$

$$k_p = \frac{1}{\sqrt{2}} [S_{HH} + S_{VV} S_{HH}^* - S_{VV}^* 2S_{HV}]^T, \quad (2)$$

因此全极化雷达所产生的 Hermitian 矩阵可以用表达式公式(3)描述.

$$\begin{bmatrix} \langle (S_{HH} + S_{VV})(S_{HH} - S_{VV})^* \rangle & 2\langle (S_{HH} + S_{VV})S_{HV}^* \rangle \\ \langle |S_{HH} - S_{VV}|^2 \rangle & 2\langle (S_{HH} - S_{VV})S_{HV}^* \rangle \\ 2\langle S_{HV}(S_{HH} - S_{VV})^* \rangle & 4\langle |S_{HV}|^2 \rangle \end{bmatrix}. \quad (3)$$

## 1.3 集成学习策略

分类器在特征空间中不同区域的性能存在差异,单一分类器容易造成较多的错分漏分现象,对于某个分类器错分的区域,运用其他分类器有可能得到正确的分类结果,实现分类器之间的模式互补. 因此选择分类器集成至关重要的因素是分类器之间的差异性. 常见的多分类器集成方法有三种<sup>[16]</sup>: (1) 基于训练样本的选取进行分类,此类集成方式中最常见的是 Bagging 算法和 Boosting 算法;(2) 分类器串联集成,即把某一分类器分类的结果作为下一个分类器分类的输出;(3) 分类器并联集成,在分类器并联集成过程中,首先分别独立设计单个分类器,然后根据某种策略将单个分类器的输出结果进行融合,获取最终的分类结果. 并联集成学习算法认为成员分类器的输出结果是独立的. 最简单且运用最广泛的是投票法,该方法原理简单且无需任何参数. 投票法是将多数分类器一致的类别作为最终类别,串联集成学习算法在构造过程中存在前后依赖关系,即当前分类器的构造是在之前分类器的结果的基础上进行的,分类器呈现一种次序关系. 通过后一层分类器的训练,能够有效地消除前一层分类器输出概率不准确和对各个分类器性能不一致的影响<sup>[16]</sup>. 从原理来看,分类器集成方法具有较好的适用性,本文分别选择并联和串联的多分类器集成算法,并选择最常用的抽象级分类器集成方法,投票法进行决策. 权重投票算法是根据不同的结果,按照分类好坏设置不同的权重,进行加权投票,将最多分类器分类一致的类别作为待分类象元类别. 常见加权投票法有简单加权投票、重新调整的权重投票、最好-最差权重投票、二次方程最好-最坏加权投票和多数加权投票<sup>[17]</sup>. 本研究采用的多数加权投票法的权重计算模型为:

$$\omega_k = \log \frac{\alpha_k}{1 - \alpha_k}, \quad (4)$$

这里  $\alpha_k$  是单一分类器的分类精度.

## 2 试验与分析

选取江苏省射阳湿地区域的 Landsat TM 光学遥感数据(2009 年 5 月 23 日), ALOS PALSAR 全极化(HH, HV, VH, VV)倾斜角为 21.5°升轨道雷达数据(2009 年 4 月 9 日)为数据源(图 2), 分别提

取并集成极化相干矩阵特征、空间纹理特征, 结合多分类器集成技术从空间格局方面进行研究, 侧重湿地自然地理环境调查, 根据研究区域的实际情况将所实验区域的地表覆盖情况分为芦苇(墨绿色)、碱蓬(紫色)、河流(浅蓝色)、建筑(红色)、农用地(黄色)、米草(粉红色)、养殖场(青色)、海域(深蓝色) 8 种类别(图 3).

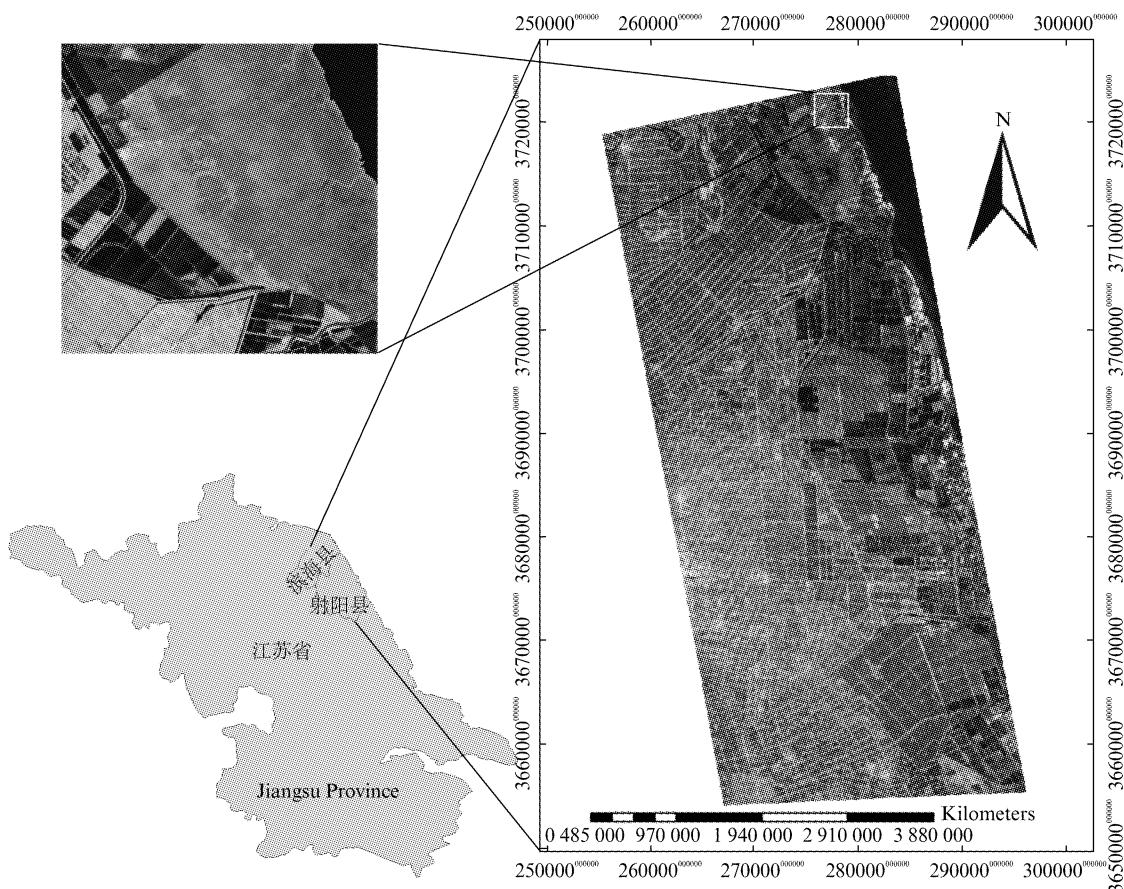


图 2 研究区域 2009 年 4 月 9 日全极化数据 lexicographic 合成( $R = HH, G = HV, B = VV$ ), 左上角为 Landsat 光学数据子区域( $R = B5, G = B4, B = B3$ )

Fig. 2 Full-polarization and optical data over research area

对光学数据的预处理主要包括辐射校正、几何校正、滤波和图像增强, 所有处理均在遥感影像处理软件 ENVI 下完成, 与 SAR 影像及极化相干矩阵特征的几何校正误差控制在 0.5 像元之内, 为了分类器串联计算的需要在串联计算过程中对所有预处理后的光学数据归一化到 0~1 之间.

对 ALOS PALSAR Level1.0 雷达数据的预处理包括利用 GAMMA 软件对 SLC 数据进行辐射校正; 提取包含真实的物理目标特征的极化相干矩阵 T3, 并通过分解获取非对角元素的实部和虚部; 对单视复数图像 ALOS PALSAR 雷达 1.0 级数据的 HH,

HV, VH, VV 极化通道和获取的 T3 相干矩阵数据分别进行多视处理, 即进行距离向和方位向压缩, 考虑到所使用光学数据的特性及空间分辨率和后续采用 DEM 进行地理编码的需求, 本研究采用 1\*7 多视处理; 采用中值滤波减弱斑点噪声的干扰影响的同时保留纹理特征; 使用 Shuttle Radar Topography Mission (SRTM-3) 90 m 空间分辨率的 DEM 数据 (<http://srtm.csi.cgiar.org>) 进行地形校正; 对地理编码后的雷达数据进行重采样使之拥有和光学数据一致的 30 m 空间分辨率; 同样将全极化通道数据和极化相干矩阵 T3 元素分别归一化为 0~1.

利用最小距离分类器 MD、反向传播人工神经网络 BPNN、支持向量机 SVM、随机子空间 RSS、多层次感知器 MLP、随机森林 RF 等多种分类器对极化、纹理和光谱特征的集成融合结果进行处理来获取分类图。多分类器集成成功的关键是分类器之间的差异性,在并联的多分类器集成方法中选择了分类精度高,分类器差异性大的分类结果进行集成;在串联型的分类器集成中,将决策能力好、鲁棒性强的 SVM 分类器作为决策级分类器,分别对遥感数据和 BPNN、MD 的类别输出概率进行决策,并对集成分类器分类结果与单个分类器分类结果进行比较<sup>[18-20]</sup>。本研究所使用多分类器集成的算法流程为:(1)BPNN 作为第一阶段的分类器,BPNN 输出的待识别的模式的类别概率作为第二阶段的输入,SVM 作为第二阶段的分类器;(2)将单个分类器的输出概率作为第二阶段的输入,第二阶段采用 SVM 分类器作为决策分类器;(3)将遥感数据和第一阶段 BPNN 分类器的输出类别概率一起输入到决策级的 SVM 分类器获取最终分类结果。

选取三龙镇以北、黄尖镇以南、盐东镇以东直至黄海的湿地地物覆盖类型最为复杂的区域(如图 2 光学图像所示)进行实验测试。将所提取的多源数据特征构建为 6 种组合策略,实现主被动特征的集成,然后分别利用 MD, SVM, NN, MLP, RSS, RF 等单一分类器和分类器集成提取湿地景观信息,生成分类图 48 幅,其中分类精度和多分类器集成分类结果如表 2 和图 3 所示。

表 2 分类精度

Table 2 Overall accuracy of classification results

	OA	G1	G2	G3	G4	G5	G6
MD	63.101	72.254	72.259	72.254	72.259	72.261	
BPNN	71.742	78.929	80.038	78.296	80.761	79.393	
SVM	76.45	84.029	86.809	84.242	84.064	84.125	
RSS	69.012	72.127	72.908	72.604	73.633	73.633	
MLP	72.120	75.005	65.756	71.58	69.399	69.288	
RF	67.151	75.239	74.499	74.074	72.098	72.405	
ESB 并	82.621	88.368	89.602	87.378	88.177	88.16	
ESB 串	75.632	89.229	86.772	89.069	88.975	87.679	

从表 2 可以看出 RSS 分类器的分类精度提高幅度稳定,均为 2~3 个百分点,对极化、纹理和光谱特征集成处理反应敏感,MLP 分类器并没有达到预期的实验目的,分类精度出现了逆变化趋势,而利用 MD 分类器分类得到的结果最低,而且该分类器对多源特征集成处理优势体现不明显,即随着多源特征的加入,并没能明显改善分类精度。

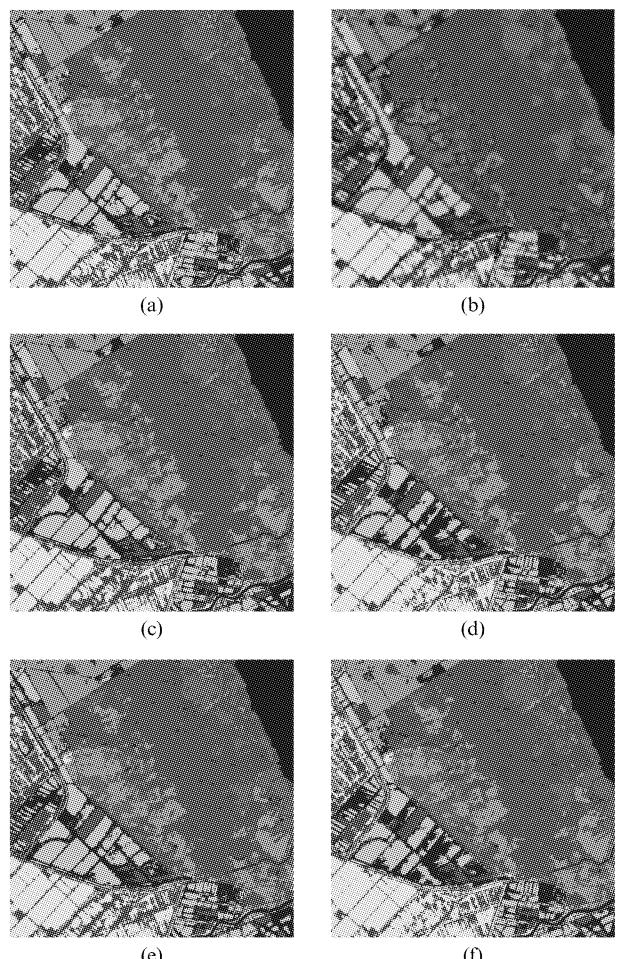


图 3 特征组合 G2、G3、G5 的并联和串联多分类器集成分类结果 (a) G2 特征组合 ESB 并联; (b) G3 特征组合 ESB 并联; (c) G5 特征组合 ESB 并联; (d) G2 特征组合 ESB 串联; (e) G3 特征组合 ESB 串联; (f) G5 特征组合 ESB 串联

Fig. 3 Classification results of features combination scheme in G2, G3, G5 using parallel and sequential ensemble learning techniques (a) Parallel ESB learning result of features combination scheme in G2; (b) Parallel ESB learning result of features combination scheme in G3; (c) Parallel ESB learning result of features combination scheme in G5; (d) Sequential ESB learning result of features combination scheme in G2; (e) Sequential ESB learning result of features combination scheme in G3; (f) Sequential ESB learning result of features combination scheme in G5

单个分类器中整体分类精度最好的是 SVM, SVM 对 G1 的分类精度达到 76.45%, 远高于 MD 和 BPNN 分类器, 而且 SVM 分类结果对极化和空间纹理特征的集成表现敏感, 体现在:(1)集成空间和极化特征后的光学图像分类结果明显提高;(2)当光谱特征与极化相干矩阵集成时达到最高为 86.809%;(3)由于 SAR 原始极化通道 HV 或 VH 通道与 T33 高度相关, HH, VH 通道分别与 T11, T22

高度相关,因此 G2 和 G4 的分类精度十分相似; (4) SVM 对极化相干矩阵、光谱和原始极化通道集成不明显,这个从 G4, G5, G6 的分类结果可以看出,通过这些特征的集成分类精度变化并不明显。

利用单一分类器和多分类器集成学习技术,分别对不同特征集成策略进行实验(如表 2 和图 3、图 4 所示),分析结果得出:1. 通过多分类器集成学习明显提高分类精度,实现了分类器之间的优势互补;2. 多源主被动特征集成的最好结果为光学数据与极化相干矩阵特征的集成处理;3. 多分类器集成学习对空间纹理及极化特征集成的敏感性要明显高于单一分类器的应用;4. 通过主被动多特征集成可以看出,集成雷达极化特征和空间纹理特征,分类精度明显优于单一光学数据分类结果;5. 单个分类器 BPNN 在 G5 特征组合时精度最高,SVM 在 G3 特征组合时体现明显优势;6. 分类器集成方法中,串联的分类器集成方法在 G2、G4 和 G5 组合时分类精度优于并联的分类器集成方法,体现了不同分类器集成方法对不同特征的敏感性和各自的优势。

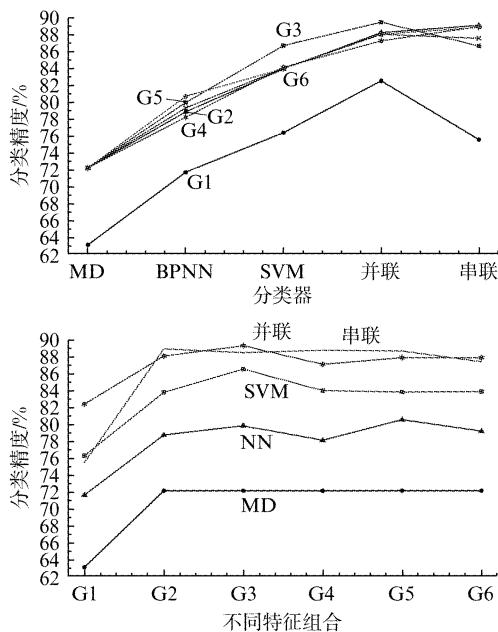


图 4 特征集成和分类器集成功能分析  
Fig. 4 Overall accuracy analysis of feature integration and classifier ensemble

进一步分析多分类器集成学习和多特征集成对各类别分类精度的改进(如图 5 所示),可以看出:1. 多分类器集成学习比单一分类器在提取土地覆盖各类别方面优势明显,特别是建筑物、碱蓬、芦苇等地表覆盖信息的提取,精度改进比原始多光谱数据

在 G3 和 G6 组合分别达到 27.23%, 32.35% 和 23.97%;2. 不同的分类器在处理各种地物类别时差异明显,对各种不同地物覆盖适应性表现混乱,但通过多分类器集成学习后分类,不但提高了分类精度也增强了分类器对不同地物类别的适应性和分类器的稳健性;3. 通过多特征的集成,各地物的分类精度也明显比使用单一特征分类获取的精度要高,特别是对下垫面复杂的建筑、米草、芦苇等土地覆盖类型,组合后分类精度较之组合前分类精度提高幅度分别为 26.49%、4.82% 和 10.79%.

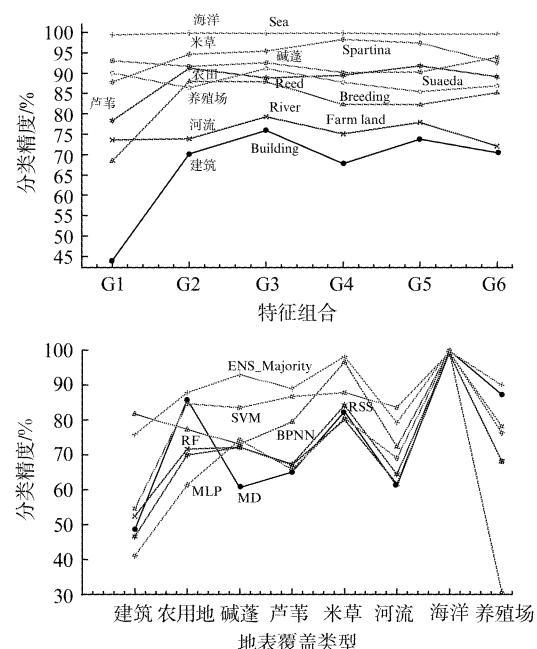


图 5 特征集成和分类器集成对各类别精度影响分析  
Fig. 5 Accuracy analysis of feature integration and classifier ensemble for single land cover type

### 3 结论与展望

本研究以主被动遥感数据的极化特征、光谱特征和空间纹理特征的融合集成处理为基础,构建主被动遥感数据集成处理的 6 组集成策略,并通过单一分类器分别处理与多分类器集成学习处理的研究方法对盐城滨海湿地的部分区域进行分类,研究结果表明:

(1) 多特征集成和多分类器集成的分类技术,对研究区域的各地表类型均有不同程度的改进,特别是对于下垫面复杂的地表类型改进明显。在多源遥感数据多特征集成处理方面优势明显,能够集成多种分类器之间的优势互补,获取更高的分类精度。

(2) 极化相干矩阵特征与光谱特征集成策略通

过并联的分类器处理能够得到最好分类结果;极化特征、光谱特征及纹理特征的集成策略更适宜与串联的分类器集成方法;

(3)以分类器类别识别能力差异为组合依据,串联集成策略中选择SVM为决策方法;并联集成策略中,选择MD、BPNN、SVM分类器,以权重投票法为决策方法。从本次实验的结果,及根据以往对该方法进行的多个试验,精度都优于传统方法,并且从方法原理来看,方法应具有较好的适用性。

在今后的研究中应从不同集成策略特征关联的比较,优化不同分类器对不同特征影响的集成策略;分析不同分类器对单一地表类型的优劣势,从而选择更合适的分类器集成策略等方面进行更加深入的研究。

## References

- [1]Du Peijun, Liu Pei, Gamba P. Urban spatial and temporal changes analysis based on spectral, polarimetric, temporal, spatial dimensions and decision level fusion [C]. 1st EAR-Sel Workshop on temporal analysis of satellite images, Mykonos, Greece, 22–25 May 2012, 58–64.
- [2]Yu Fan, Li Haitao, Wan Zi. Synthesis of multi-source remote sensing data for classification based on bayesian theory and Mrf[J]. *Journal of remote sensing*, (余凡, 李海涛, 万紫. 结合贝叶斯理论和MRF的主被动遥感数据协同分类. 遥感学报) 2012, **16**(4): 809–826.
- [3]Brunner D, Lemoine G, Bruzzone L, et al. Building Height Retrieval From VHR SAR Imagery Based on an Iterative Simulation and Matching Technique[J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2010, **48**(3): 1487–1504.
- [4]Zhong Ping, Wang Runsheng. A Multiple Conditional Random Fields Ensemble Model for Urban Area Detection in Remote Sensing Optical Images[J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2007, **45**(12): 3978–3988.
- [5]Lehmann A, Caccetta A, Zhou Z, et al. Joint Processing of Landsat and ALOS-PALSAR Data for Forest Mapping and Monitoring [J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2012, **50**(1): 55–67.
- [6]Sportouche H, Tupin F, Denise L. Building detection by fusion of optical and SAR features in metric resolution data [C], Geoscience and Remote Sensing Symposium, Cape Town, 12–17 July 2009, IV–769–IV–772.
- [7]Brunner D, Lemoine G, Bruzzone L. Earthquake Damage Assessment of Buildings Using VHR Optical and SAR Imagery[J]. *Geoscience and Remote Sensing, IEEE Transactions*, 2010, **48**(5): 2403–2420.
- [8]Gamba P, Dell'Acqua F, Dasarathy V. Urban remote sensing using multiple data sets: Past, present, and future[J]. *Information Fusion*, 2005, **6**(4): 319–326.
- [9]Dong Jiang, Zhuang Dafang, Huang Yaohuan et al. Advances in Multi-Sensor Data Fusion: Algorithms and Applications[J]. *Sensors*, 2009, **9**(10): 7771–7784.
- [10]Zhang Hongsheng, Zhang Yuanzhi, Lin Hui. Urban land cover mapping using random forest combined with optical and SAR data[C]. Geoscience and Remote Sensing Symposium (IGARSS), Munich, 22–27 July 2012, 6809–6812.
- [11]Rusmini M, Candiani G, Frassy F, et al. High-resolution SAR and high-resolution optical data integration for sub-urban land-cover classification[C]. Geoscience and Remote Sensing Symposium, Munich, 22–27, July, 2012, 4986–4989.
- [12]Gamba P, Liu P, Du P, et al. Evaluation and analysis of fusion algorithms for active and passive remote sensing image [C]. Geoscience and Remote Sensing Symposium, Munich, 22–27, July, 2012, 2272–2275.
- [13]Rodriguez-Galiano F, Chica-Olmo M, Abarca-Hernandez F, et al. Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture [J]. *Remote Sensing of Environment*, 2012, (121): 93–107.
- [14]Jiao Longhao, Zhou Zhongfa, Li Bo. Study of SAR Image Texture Feature Extraction Based on GLCM in Guizhou Karst Mountainous Region. in Remote Sensing[C], Environment and Transportation Engineering (RSETE), Nanjing, 1–3 June 2012, 1–4.
- [15]Chen Jiong, Jia Haifeng, Yang Jian, et al. Primary exploration on monitoring of river pollution based on polarimetric coherence matrix[J]. *Journal of remote sensing*, (陈炯, 贾海峰, 杨健, 等. 基于极化相干矩阵的河流水质污染初探. 遥感学报) 2011, **15**(5): 1064–1078.
- [16]Du Peijun, Xia Junshi, Zhang Wei, et al. Multiple Classifier System for Remote Sensing Image Classification: A Review[J]. *Sensors*, 2012, **12**(4): 4764–4792.
- [17]Yeung D, Kwok J, Fred A, et al. *Structural, Syntactic, and Statistical Pattern Recognition* [M]. Berlin Heidelberg, Springer 2006, 1–939.
- [18]Du Qian, Xia Junshi, Chanussot J, et al. Hyperspectral remote sensing image classification based on the integration of support vector machine and random forest[C]. Geoscience and Remote Sensing Symposium(IGARSS), Munich, 22–27 July 2012, 174–177.
- [19]Du Peijun, Chen Yu, Xia Junshi, et al. A novel remote sensing image classification scheme based on data fusion, multiple features and ensemble learning[J]. *J Indian Soc Remote sensing*, 2013, **41**(2): 213–222.
- [20]Zhang Caiyu, Xie Zhixiao. Data fusion and classifier ensemble techniques for vegetation mapping in the coastal everglades. *Geocarto International*, 2012(35): 1–6.