

doi:10.6041/j.issn.1000-1298.2023.03.025

# 基于特征优选的多时相 SAR 数据水稻信息提取方法

于飞<sup>1</sup> 吕争<sup>2</sup> 隋正伟<sup>1</sup> 李俊杰<sup>2</sup> 盖彦锋<sup>1</sup>

(1. 中国四维测绘技术有限公司, 北京 100094; 2. 中国资源卫星应用中心, 北京 100094)

**摘要:** 多时相合成孔径雷达(Synthetic aperture radar, SAR)数据可为水稻提取提供丰富信息,在多云多雨地区对水稻识别和监测具有独特优势。但过多特征变量的加入,一定程度上造成“维数灾难”及信息冗余,因此,本文提出一种基于多时相后向散射特性及干涉相干性优选特征的水稻提取方法。基于研究区水稻生长周期的多时相 Sentinel-1 SAR 数据,构建后向散射系数和干涉相干系数特征集,利用 ReliefF 算法对特征重要性进行排序,同时采用 JM 距离确定最优特征数目完成最优特征选择,结合随机森林分类算法对研究区水稻进行提取及精度评价。结果表明:基于优选特征提取水稻面积相对误差为 4.96%,总体精度达到 92.48%,Kappa 系数为 0.90;从优选特征剔除干涉相干特征提取的水稻面积相对误差增加 2.39 个百分点,总体分类精度和 Kappa 系数分别降低 4.03 个百分点、0.06,说明干涉相干性有利于水稻信息提取。基于多时相后向散射特性及干涉相干性的特征优选减少了数据冗余,提高了运算效率,可实现大范围高精度水稻提取。

**关键词:** 水稻提取; 合成孔径雷达; 多时相; 特征优选; 干涉相干系数

中图分类号: TP79

文献标识码: A

文章编号: 1000-1298(2023)03-0259-07

OSID:



## Extraction of Rice Information Using Multi-temporal SAR Data Based on Feature Optimization

YU Fei<sup>1</sup> LÜ Zheng<sup>2</sup> SUI Zhengwei<sup>1</sup> LI Junjie<sup>2</sup> GAI Yanfeng<sup>1</sup>

(1. China Siwei Surveying and Mapping Technology Co., Ltd., Beijing 100094, China

2. China Centre for Resources Satellite Data and Application, Beijing 100094, China)

**Abstract:** Synthetic aperture radar (SAR) data has unique advantages for rice identification and monitoring in cloudy and rainy weather. Multi-temporal SAR and multi-features can provide rich information for rice extraction, but too many feature variables will cause dimension disaster and information redundancy to some extent. Therefore, a rice extraction method based on multi-temporal backscattering characteristics and coherent coefficient optimization features was proposed. Based on the multi-temporal Sentinel-1 SAR data during the rice growth cycle in the study area, the feature sets of backscattering coefficient and coherence coefficient were constructed, and the importance of the features was sorted by ReliefF algorithm. At the same time, JM distance was used to determine the optimal number of features to complete the optimal features selection. According to the optimal features, the rice planting area in the study area was extracted by the random forest classification algorithm. The results showed that the error of rice area extraction based on the optimal features was 4.96%, the overall accuracy planting was 92.48%, and the Kappa coefficient was 0.90. Excluding coherence coefficient features from the optimal features to extract rice, the area error was increased by 2.39 percentage points, and the overall classification accuracy and Kappa coefficient were decreased by 4.03 percentage points and 0.06, respectively, which showed that coherence coefficient was beneficial to rice information extraction. Based on the characteristics of multi-temporal backscattering and coherence coefficient, data redundancy was reduced, operation efficiency was improved, and large-scale and high-precision rice extraction can be realized.

**Key words:** rice extraction; synthetic aperture radar; multi-phase; feature optimization; coherence coefficient

收稿日期: 2022-12-01 修回日期: 2023-01-19

基金项目: 国家重点研发计划项目(2018YFB0505001)

作者简介: 于飞(1989—),女,工程师,主要从事微波遥感技术应用研究,E-mail: fei\_aza@163.com

## 0 引言

水稻是我国重要的粮食作物之一,准确、及时掌握其种植面积是国家制定粮食政策和经济计划的重要依据。传统农业统计报表和采样调查法难以快速、准确地获取水稻种植分布信息。遥感技术为水稻信息提取提供了有力支撑。近年来,众多学者利用水稻生长关键时期的光学遥感影像,基于波段反射率或植被指数与其他地类在时空域上的变化特征,区分水稻与其他地类<sup>[1-4]</sup>。但目前我国水稻主产区绝大多数仍分布在南方,这些地区阴雨天气频繁,限制了光学遥感在这些地区的应用<sup>[5-6]</sup>。SAR具有全天时、全天候观测能力,并且具有一定的穿透力,可一定程度上穿透植被冠层,在植被冠层和地面/水面之间形成双向散射,对于识别水稻具有很大的潜力。越来越多的学者基于SAR数据开展水稻提取研究,主要方法包括:①利用阈值法分析不同时相和极化方式下的合理阈值提取水稻信息,常用的方法有比值法和插值法<sup>[7]</sup>。②与水稻生长模型相结合的水稻识别方法,尤其是利用单极化数据识别水稻,通过选择多时相可以提高识别精度<sup>[8-9]</sup>。③与光学影像融合应用,发挥光学与微波遥感在水稻提取方面的各自优势<sup>[10-11]</sup>。已有研究多基于SAR数据的强度信息、极化信息,结合水稻识别机理,却较少考虑SAR特有的相位信息可获得的干涉相干性特征。此外,多种特征变量均可以参与到影像分类中,不同的特征组合会得到不同的水稻提取效果,引入过多特征变量,一定程度上会造成“维数灾难”以及信息冗余,甚至降低分类精度<sup>[12]</sup>。通过合适的特征选择算法确定最优特征是提高水稻提取精度的重要环节。

本文结合研究区水稻物候特征,选取多时相Sentinel-1 SAR影像为数据源,构建多极化时间序列后向散射系数和干涉相干系数特征集,利用ReliefF算法对特征重要性进行排序,同时结合Jeffries-Matusita(JM)距离确定最优特征,最后,采用随机森林分类器进行分类提取研究区水稻信息,并进行精度评价。

## 1 研究区及实验数据

### 1.1 研究区概况

研究区域位于江苏省盐城市阜宁县,介于北纬 $33^{\circ}26' \sim 33^{\circ}59'$ 、东经 $119^{\circ}27' \sim 119^{\circ}58'$ 之间,面积为 $1\,439\text{ km}^2$ 。研究区属北亚热带向暖温带过渡的气候带,季风显著,四季分明,雨水充沛,日光充足,气候温和。阜宁县地处苏北里下河地区,主要种植

制度为中稻-冬小麦一年轮番耕作,依据盐城市统计局资料,当地水稻主要种植期间为5—10月,其中5月中旬至9月上旬分别为秧田期、移栽-分蘖期、孕穗-抽穗期,9月中旬至10月下旬为灌浆结实期。2021年统计年鉴资料<sup>[13]</sup>显示,2020年阜宁县水稻种植面积为 $604.2\text{ km}^2$ 。

### 1.2 实验数据

结合研究区水稻物候期,选取2020年5月11日—10月14日共14期多时相Sentinel-1A数据(表1)进行水稻提取。Sentinel-1星座是欧洲哥白尼计划的首个任务,由A、B星两颗卫星组成。单颗卫星的重访周期为12d,双星重访周期缩短为6d。Sentinel-1搭载C波段SAR传感器,具有条带模式(Stripmap, SM)、干涉宽幅(Interferometric wide swath, IW)模式、超宽幅(Extra-wide swath, EW)模式和波模式(Wave, WV)4种成像模式。研究中采用Sentinel-1A单视复数产品(Single look complex, SLC),IW成像模式,极化方式为VH、VV。数据预处理过程中采用30m的航天飞机雷达地形测绘任务(Shuttle radar topography mission, SRTM)获取的数字高程模型(Digital elevation model, DEM)数据进行几何校正。

表1 Sentinel-1A数据信息

Tab.1 Sentinel-1A data information

成像日期	对应物候期	成像日期	对应物候期
2020-05-11	秧田期	2020-08-03	孕穗-抽穗期
2020-05-23	秧田期	2020-08-15	孕穗-抽穗期
2020-06-04	秧田期	2020-08-27	孕穗-抽穗期
2020-06-16	秧田期	2020-09-08	孕穗-抽穗期
2020-06-28	移栽-分蘖期	2020-09-20	灌浆结实期
2020-07-10	移栽-分蘖期	2020-10-02	灌浆结实期
2020-07-22	移栽-分蘖期	2020-10-14	灌浆结实期

样本数据通过对比Google Earth高分辨率影像和SAR图像进行选取,地物类型包括水稻、建设用地、水体、其他作物及植被4类,共计500个样本,其中2/3作为训练样本,1/3作为验证样本。

## 2 研究方法

本研究技术流程如图1所示,主要包括3部分:①对多时相SAR数据进行预处理,包括多时相处理和干涉(Interferometric synthetic aperture radar, InSAR)处理,得到时间序列后向散射系数及干涉相干系数。②构建原始特征集,基于ReliefF算法计算每个特征的重要性权值,然后按照重要性权值由高到低的顺序依次增加一个特征,计算地类的JM可分离性距离,随着特征个数增加,水稻与其他地类的

可分离性增加,当使用的特征达到一定量后,可分离性增加逐渐缓慢,趋于平衡,据此获得优选特征。

③基于最终优选特征子集,采用随机森林分类器对研究区水稻进行提取,并对结果进行精度评价。

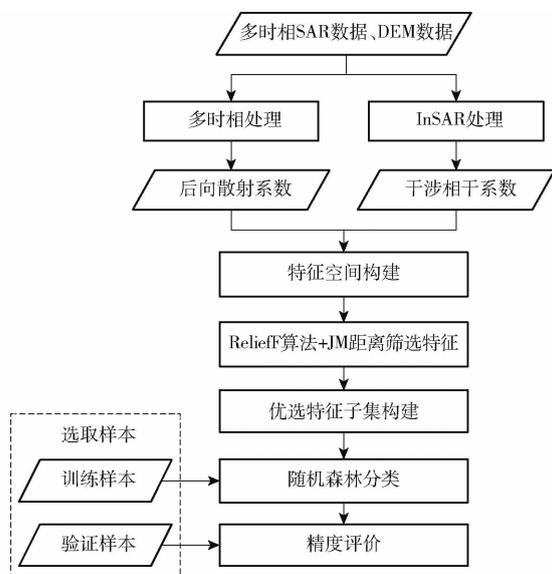


图1 技术流程图

Fig.1 Technique flow chart

## 2.1 数据预处理

对14个时相、VH和VV极化的Sentinel-1数据分别进行多时相处理和InSAR处理。其中,多时相处理包括影像配准、多时相斑点滤波、辐射定标、基于SRTM DEM数据进行地理编码,将各个时相SAR数据从斜距投影转换为地理坐标投影,得到以dB为单位的后向散射系数;InSAR处理以成像时间最早的SAR数据作为主影像,其余时相的SAR数据作为从影像,分别与主影像做干涉处理,包括干涉图生成、自适应滤波、相干性计算、地理编码,得到地理坐标系下的干涉相干系数。相干性(Coherence)是雷达回波中蕴含的相位信息和强度信息的相似程度,能提供目标散射体的相关信息,反映目标散射体的相似性。为衡量目标散射体的相似程度,引入相干系数作为衡量参数,其计算式为<sup>[14]</sup>

$$\gamma = \frac{|\langle S_1 \cdot S_2^* \rangle|}{\sqrt{\langle S_1 \cdot S_1^* \rangle \langle S_2 \cdot S_2^* \rangle}} \quad (1)$$

式中  $\gamma$ ——相干系数

$S_1, S_2$ ——复数干涉像对

$*$ ——复数共轭

$\langle \rangle$ ——期望值

相干系数数值域为 $[0, 1]$ ,0表示不存在相干性,1表示完全相干。

## 2.2 水稻后向散射特性及干涉相干性分析

### 2.2.1 水稻后向散射特性

SAR通过主动发射微波脉冲,接收目标地物对

微波的后向散射信号,根据其强度的不同进行成像,不同的地物类型具有不同的后向散射信号强度。后向散射系数反映的是后向散射截面散射回来的回波强度。农作物在SAR影像中的后向散射强度与其冠层结构和底层表面土壤有密切关系,这种关系在冠层结构为竖直狭长型的农作物中尤其明显<sup>[15]</sup>。根据雷达波反射路径的不同来划分,水稻后向散射可分为水稻冠层的直接散射、水稻冠层-水面复合散射、水面-水稻冠层的复合散射、水面-水稻冠层-水面复合散射,在大多数情况下,上述第2、3项占主导地位<sup>[16]</sup>。水稻在SAR影像中的后向散射系数不仅受水稻物候期、植株高度、生物量、含水量等的影响,也受SAR入射角、波段、极化方式等的影响。

利用选取的样本,绘制研究区2种极化数据的地物后向散射系数曲线,结果见图2。水稻在VH、VV极化上的后向散射系数分别在 $-20 \sim -15$  dB、 $-16 \sim -9$  dB范围内波动,整体上呈现“低-高-低”的趋势。5月中旬—6月,水稻处于播种和移栽阶段,水田中灌满水,植株个体很小,密度很低,雷达回波信号主要以水体的面散射为主,后向散射系数较低;7—8月水稻处于主要发育期,随着水稻冠层的逐渐增大,雷达回波信号主要是冠层-水面的复合散射,这期间后向散射系数逐渐增大,在7月22日达到最大;9—10月水稻处于成熟期,稻田中水量减少,茎叶密度也逐渐下降,后向散射系数逐渐降低。建设用地以二次散射为主,大部分能量能返回传感器,总体上后向散射系数较大并且随时间变化不大。水体主要是面散射,后向散射系数较低,随时间变化不大。其他作物及植被由于种类复杂,后向散射系数变化趋势不明显,但是在部分时相上与水稻的后向散射系数差异较大。由此可以根据水稻的这种时相变化特征来区分其与其他地物。

### 2.2.2 水稻干涉相干性

干涉相干性一方面可以衡量用于相干处理SAR图像的相关程度及干涉条纹图质量,另一方面也提供了地物散射体的散射信息,如果在2幅SAR图像获取周期内覆盖地物有变化,则相干程度就会减弱,表现出较低的相干性,反之,若无明显变化,则表现出较高的相干性。在基于干涉相干系数得到的相干图中,地表的变化程度不同,从而引起各类地物相干性也不同,因此可以借助相干性对不同地物进行分类<sup>[17-18]</sup>。

以成像最早的5月11日影像作为主影像,其他影像作为从影像,每种极化组成13对干涉对进行干涉处理,计算其相干系数,根据选取的样本,绘制研究区2种极化方式的地物相干系数曲线。如图3所

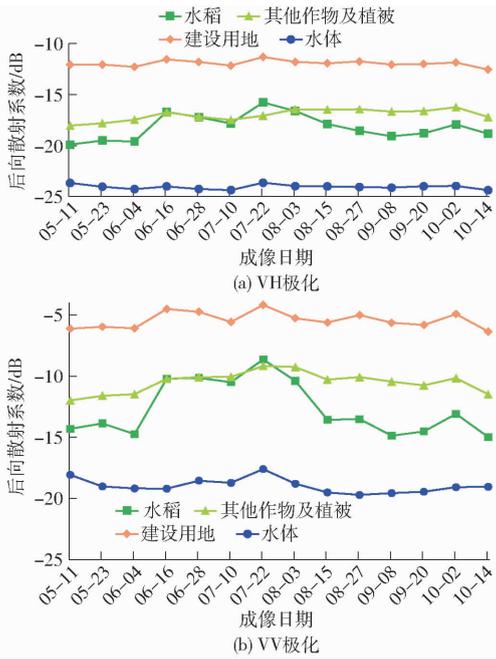


图2 地物后向散射系数曲线

Fig. 2 Backscattering coefficient curves of ground objects

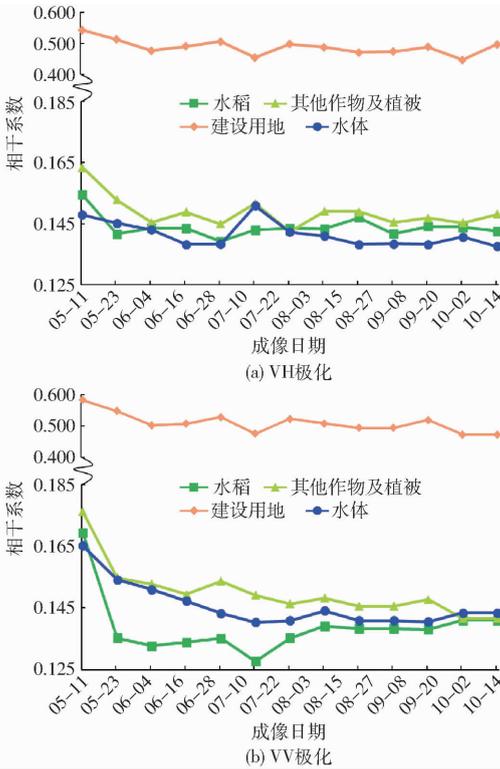


图3 地物相干系数曲线

Fig. 3 Coherence coefficient curves of ground objects

示,水稻相干系数在VH极化下呈现波浪趋势,规律性不强,在VV极化呈现先下降后上升趋势,最小值出现在7月底,此时水稻后向散射主要是冠层的后向散射,而5月的后向散射主要是水体的后向散射,故相干系数较小,变化较大,水稻的相干性与地表的覆盖状况和水稻的生长阶段密切相关。建设用地的相干系数在2种极化方式下均大于0.45,远高于其他3种地物,建设用地大多为建筑、道路等,表面形

态稳定,随时间变化较小,因此表现出较高的相干性。水体表面在内陆河、湖面相对光滑,雷达入射波能量大部分被前向反射,后向散射较小,回波信号较弱,从而导致水体的相干性较低。其他作物及植被种植区域的形态随时间变化,使得雷达回波在不同的时间存在差异,因此,总体上表现出较低的相干性。通过分析两种极化方式下的相干系数曲线,可以看出相干系数能够很好地区分建设用地与其他地物,而水稻与水、其他作物及植被的相干系数差异不大,但水稻在不同时间下垫面及形态上的差异,其相干性具有本身的特性,可为水稻识别提供辅助信息。

### 2.3 特征空间构建

选取后向散射特征及干涉相干特征构建特征集,后向散射特征包括14个时相的后向散射系数,VH极化和VV极化后向散射系数各14个,干涉相干特征包括VH极化和VV极化干涉相干系数各13个,特征集总共包含54个特征,各个特征的详细说明见表2。

表2 特征说明

Tab. 2 Description of features

特征变量	编号	简称	特征说明
后向散射特征	1 ~ 14	VH_b1 ~ VH_b14	14个VH极化后向散射系数
	15 ~ 28	VV_b1 ~ VV_b14	14个VV极化后向散射系数
干涉相干特征	29 ~ 41	VH_c1 ~ VH_c13	13个VH极化相干系数
	42 ~ 54	VV_c1 ~ VV_c13	13个VV极化相干系数

### 2.4 特征优选

对于构建的SAR特征空间,无法直接确定每个特征的地物目标分类性能,以及哪些特征的组合可以获得到更好的地物目标分类性能,因此需要利用特征选择的方法选择出最优的特征用于水稻提取。特征筛选算法按照搜索策略不同分为完全搜索、启发式搜索和随机搜索;按评价标准不同,特征选择算法可分为过滤式、封装式和嵌入式<sup>[19-20]</sup>。综合考虑计算效率、对分类算法的依赖,本研究选择Relieff算法和JM距离相结合进行特征筛选。

#### 2.4.1 Relieff算法

Relieff算法是由Relief算法改进而来,相比于Relief算法只能处理二分类问题,Relieff算法可以解决多分类特征问题<sup>[21-22]</sup>。该算法的基本思想为:从训练集 $D$ 中随机抽取一个样本 $R$ ,从该样本的同类样本中寻找出 $k$ 个最近邻样本 $H_j(C)$  ( $j=1,2,\dots,k$ ),从样本的每个不同类样本中找出 $k$ 个最近邻

样本  $M_j(C)$  ( $j=1,2,\dots,k$ )。分别计算  $R$  与所有同类样本和异类样本的距离和,并根据距离更新特征的权重  $W_A^i$ ,计算公式为

$$W_A^i = W_A^{i-1} - \frac{\sum_{j=1}^k d_A(R, H_j(C))}{mk} + \frac{\sum_{C \neq \text{class}(R)} \frac{p(C)}{1-p(\text{class}(R))} \sum_{j=1}^k d_A(R, M_j(C))}{mk} \quad (2)$$

式中  $A$ ——某个分类特征

$C$ ——样本类别

$\text{class}()$ ——与样本  $R$  不同的样本类别

$d_A()$ ——2 个样本在特征  $A$  上的距离

$H_j(C)$ ——样本  $R$  最邻近的同一类样本

$M_j(C)$ ——样本  $R$  最邻近的不同类样本

$p()$ ——某类样本在训练集  $D$  中所占比例

$m$ ——迭代次数

$i$ ——权重更新时当前迭代次数,  $i=1,2,\dots,m$

$k$ ——最邻近样本数量

## 2.4.2 JM 距离可分离性

类别可分性度量是一种常用的特征选择评价准则,相较于其他类别可分性准则, JM 距离更适用于表达类间可分性<sup>[23]</sup>。JM 距离考虑各类的概率分布,可以有效地表达各类别在特征空间中不同区域的交叠程度,交叠程度越小,类别可分性越好;同时它又考虑各类别之间的影响,可以合理处理类别间距离差异较大的情况<sup>[24]</sup>。本研究采用 JM 距离计算地类之间的可分性,计算公式为

$$J_{ij} = \left[ \int_x (\sqrt{p(x/\omega_i)} - \sqrt{p(x/\omega_j)})^2 dx \right]^{\frac{1}{2}} \quad (3)$$

式中  $J_{ij}$ ——样本间的可分离性距离

$p(x/\omega_i)$ 、 $p(x/\omega_j)$ ——条件概率密度,即第  $i$ 、 $j$  个像元属于  $\omega_i$ 、 $\omega_j$  类别的概率

$J_{ij}$  值为 0~2,其值越大代表样本间可分离程度越高。

## 2.5 随机森林分类

采用随机森林(Random forest, RF)算法用于研究区水稻分类。RF 是一种基于分类与回归树(Classification and regression tree, CART)的集成分类学习方法<sup>[25]</sup>。与其他的机器学习算法如决策树(Decision trees, DT)和支持向量机(Support vector machine, SVM)相比,它更加稳健并且易于使用<sup>[26]</sup>。该方法通过建立大量决策树,通过投票机制决定最终的分类,克服单棵决策树分类结果可能不是最优

的缺点。并且 RF 是通过随机选择训练样本和随机选择分裂节点使用特征进行建立决策树,有效结合了 Bagging 集成思想和随机特征选择,所以决策树之间独立性较好,分类器分类性能强,对异常值和噪声忍耐力高,不容易出现过拟合问题。

随机森林算法实现流程如图 4 所示:①从原始训练数据集  $D$  中利用 Bootstrap 抽样技术,有放回地随机抽样,生成  $n$  个训练数据子集。②基于抽取的训练数据子集建立  $n$  棵 CART 决策树组成随机森林,在树的生长过程中,从全部  $F$  个特征变量中随机选择  $f$  ( $f \leq F$ ) 个特征作为非叶子节点的分裂特征空间,并从中根据基尼系数(Gini)最小原则筛选出最具有分类能力的特征进行内部节点分裂。基尼系数代表了模型的不纯度,该系数越小,则不纯度越低,特征越好。每棵 CART 决策树都可以自由生长,不需要进行剪枝。③将训练好的 CART 决策树基分类器组合在一起形成随机森林分类器,对测试集样本的类别进行预测,森林中每棵 CART 决策树都会产生一个预测类别结果。④对预测结果进行统计,采用投票的方式,将获得票数最多的类别作为样本的最终类别。

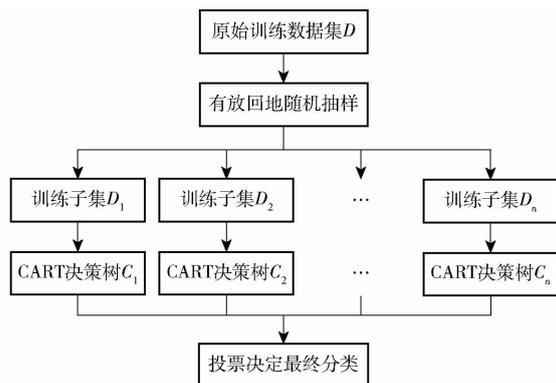


图 4 随机森林算法示意图

Fig. 4 Schematic of random forest algorithm

随机森林算法构建过程中涉及 2 个重要参数,即决策树数量  $n$  和节点分裂过程中选取的特征个数  $f$ ,选取决策树数量  $n$  为 100,将节点特征数  $f$  设置为特征总数的平方根。

## 3 结果与分析

### 3.1 优选特征

利用 ReliefF 算法计算 54 个特征的权重,其中最邻近样本数  $k=127$ ,将特征按照权重从大到小排序,结果如图 5 所示。排在前 10 位的特征变量均是后向散射系数特征,并且 VH 极化后向散射系数占多数,相干系数特征的权重相差不大。

通过 ReliefF 算法得到当前特征集的各个特征

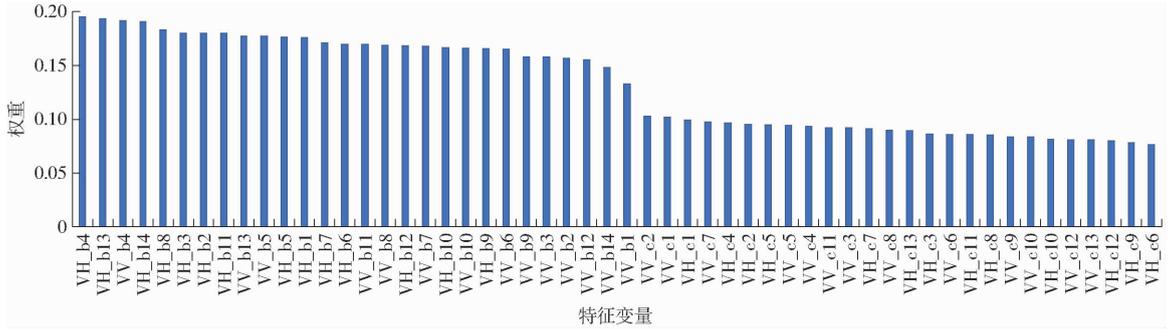


图5 ReliefF 算法结果

Fig. 5 Result of ReliefF algorithm

重要性排序,但还无法确定参与分类的最优特征变量个数。按照特征变量重要性权重由大到小的顺序依次增加一个特征,计算地类的 JM 可分离性距离,统计水稻与其他地类的 JM 距离和,由图 6 可知,特征数由 1 增加到 30 时,水稻与其他地类的 JM 距离和由 3.43 增加到 5.97,此时,水稻与其他 3 类地物的 JM 距离均大于 1.9,表明该特征子集下,水稻与其他地物有较好的可分性。而随着特征数由 30 增加到 54,水稻与其他地类的 JM 距离和涨幅微弱。因此,按照重要性权重由大到小的顺序,选取排名前 30 的特征作为研究区的最后优选特征。

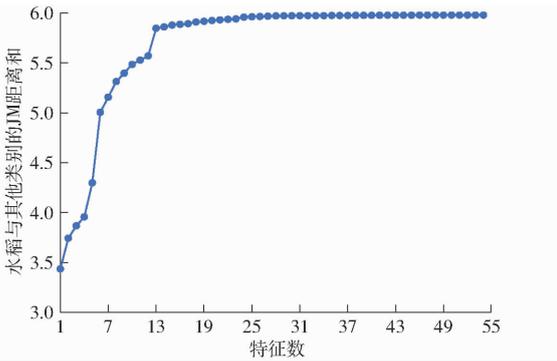


图6 不同特征数下的水稻与其他地类的 JM 距离和

Fig. 6 JM distance sum between rice and other land types under different characteristic numbers

### 3.2 分类结果与精度评价

为了验证基于优选特征的分类精度,以及干涉相干性特征对于水稻提取的影响,利用 RF 分类器,分别基于上述优选的 30 个特征(简称“优选 30 特征”)、全部的 54 个特征(简称“54 特征”),以及从 30 个优选特征中去除 2 个相干性特征(VV\_c2、VV\_c1)得到的 28 个特征(简称“28 特征”)进行分类,分类结果及细节对比如图 7 所示。从水稻提取面积及混淆矩阵两方面评价分类精度,结果见表 3。基于优选 30 特征、54 特征、28 特征进行分类得到的水稻面积分别为 574.2、588.7、559.8 km<sup>2</sup>,与盐城市 2021 年统计年鉴中发布的水稻种植面积 604.2 km<sup>2</sup> 相比,相对误差分别为 4.96%、2.57% 和 7.35%。

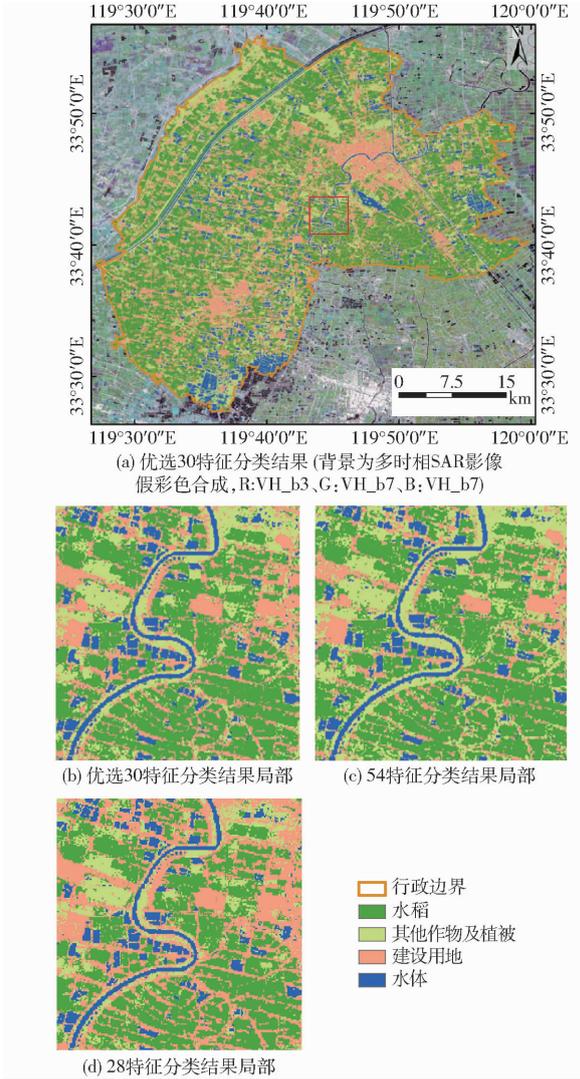


图7 研究区分类结果

Fig. 7 Classification results of study area

表3 分类结果精度评价

Tab.3 Accuracy assessment of classification results

特征集	总体分类精度/%	Kappa 系数	制图精度/%	用户精度/%	面积相对误差/%
优选 30 特征	92.48	0.90	95.48	98.11	4.96
54 特征	93.81	0.91	96.38	97.81	2.57
28 特征	88.45	0.84	94.91	98.15	7.35

利用混淆矩阵统计分类结果的总体精度、用户精度、

制图精度和 Kappa 系数,基于优选 30 特征、54 特征、28 特征的总体精度分别为 92.48%、93.81% 和 88.45%,Kappa 系数分别为 0.90、0.91、0.84,制图精度和用户精度均高于 90%。

通过对比发现,基于优选 30 特征的分类精度略低于 54 特征的分类精度。优选 30 特征中包含全部的后向散射特征及少量的相干性特征,并且相干特征主要为 VV 极化方式的,虽然相干性特征的重要性权重比较小,但是仍然对分类结果有一定的影响,导致优选 30 特征分类精度略低于 54 特征。总体而言,优选 30 特征和 54 特征提取研究区内 4 地类的表现相差较小,且水稻都取得了较好的提取结果,说明优选 30 特征已经具备研究区水稻提取能力。此外,28 特征分类精度相较于优选 30 特征,面积相对误差增加 2.39 个百分点,总体分类精度和 Kappa 系数分别降低 4.03 个百分点、0.06,说明 2 个干涉相干性特征对于研究区的水

稻提取起到了一定的积极影响,通过 InSAR 技术引入的相干系数能为识别水稻提供辅助作用。

## 4 结论

(1)基于多时相 SAR 后向散射特性及干涉相干性特征,利用 ReliefF 算法和 JM 距离方法得到的优选特征进行水稻提取,总体分类精度为 92.48%,Kappa 系数为 0.90,制图精度和用户精度分别为 95.48%、98.11%,水稻面积相对误差 4.96%。优选特征不仅减少了数据冗余,提供了运算效率,还能保持与全部特征相近的分类精度。

(2)对比优选 30 特征与 28 特征分类精度,干涉相干特征的引入使总体分类精度和 Kappa 系数分别提高 4.03 个百分点、0.06,水稻面积相对误差减少 2.39 个百分点,说明 SAR 的干涉相干性特征能为识别水稻提供辅助作用。

## 参 考 文 献

- [1] 田苗,单捷,卢必慧,等. 基于 MODIS - EVI 时间序列与物候特征的水稻面积提取[J]. 农业机械学报,2022,53(8):196 - 202. TIAN Miao, SHAN Jie, LU Bihui, et al. Extraction of rice planting area based on MODIS - EVI time series and phenological characteristics[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(8): 196 - 202. (in Chinese)
- [2] 牛海鹏,王占奇,尚东洋. 基于时空数据融合的县域水稻种植面积提取[J]. 农业机械学报,2020,51(4):156 - 163. NIU Haipeng, WANG Zhanqi, SHANG Dongyang. Paddy rice planting area extraction in county-level based on spatiotemporal data fusion[J]. Transactions of the Chinese Society for Agricultural Machinery,2020, 51(4): 156 - 163. (in Chinese)
- [3] DONG J W, XIAO X M, MENARGUEZ M A, et al. Mapping paddy rice planting area in northeastern Asia with Landsat 8 images, phenology based algorithm and Google Earth Engine[J]. Remote Sensing of Environment, 2016, 185: 142 - 154.
- [4] 魏永霞,杨军明,吴昱,等. 基于多源数据融合模型的水稻面积提取[J]. 农业机械学报,2018,49(10):300 - 306. WEI Yongxia, YANG Junming, WU Yu, et al. Rice planting area extraction based on multi-source data fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(10): 300 - 306. (in Chinese)
- [5] 张卫星,马晨怡,袁玉伟,等. 我国水稻三大优势产区稻米品质现状及区域差异[J]. 中国稻米,2021,27(5):12 - 18. ZHANG Weixing, MA Chenyi, YUAN Yuwei, et al. Current situation and regional difference of rice grain quality in three rice-production superiority areas of China[J]. China Rice, 2021, 27(5): 12 - 18. (in Chinese)
- [6] 杨靖雅,胡琼,魏浩东,等. 基于 Sentinel - 1/2 数据的中国南方单双季稻识别结果一致性分析[J]. 中国农业科学,2022,55(16):3093 - 3109. YANG Jingya, HU Qiong, WEI Haodong, et al. Consistency analysis of classification results for single and double cropping rice in southern China based on Sentinel - 1/2 imagery[J]. Scientia Agricultura Sinica, 2022, 55(16): 3093 - 3109. (in Chinese)
- [7] 刘警鉴,李洪忠,华璠,等. 基于 Sentinel - 1A 数据的临高县早稻面积提取[J]. 国土资源遥感,2020,32(1):191 - 199. LIU Jingjian, LI Hongzhong, HUA Cui, et al. Extraction of early paddy rice area in Lingao County based on Sentinel - 1A data[J]. Remote Sensing for Natural Resources, 2020, 32(1): 191 - 199. (in Chinese)
- [8] 黄翀,许照鑫,张晨晨,等. 基于 Sentinel - 1 数据时序特征的热带地区水稻种植结构提取方法[J]. 农业工程学报,2020,36(9):177 - 184. HUANG Chong, XU Zhaoxin, ZHANG Chenchen, et al. Extraction of rice planting structure in tropical region based on Sentinel - 1 temporal features integration[J]. Transactions of the CSAE, 2020, 36(9): 177 - 184. (in Chinese)
- [9] CHANG L, CHEN Y T, WANG J H, et al. Rice-field mapping with Sentinel - 1A SAR time-series data[J]. Remote Sensing, 2021, 13(1):103.
- [10] 谭深,吴炳方,张鑫. 基于 Google Earth Engine 与多源遥感数据的海南水稻分类研究[J]. 地球信息科学学报,2019,21(6):937 - 947. TAN Shen, WU Bingfang, ZHANG Xin. Mapping paddy rice in the Hainan Province using both Google Earth Engine and remote sensing images[J]. Journal of Geo-information Science, 2019, 21(6): 937 - 947. (in Chinese)
- [11] TALEMA T, HAILU B T. Mapping rice crop using Sentinels (1 SAR and 2 MSI) images in tropical area: a case study in Fogera wereda, Ethiopia[J]. Remote Sensing Applications: Society and Environment, 2020, 18:100290.

- [J]. *International Journal of Computer Vision*, 2021, 129(11): 3051–3068.
- [17] LIU H, JIANG B, XIAO Y, et al. Coherent semantic attention for image inpainting[C] // *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019: 4170–4179.
- [18] WANG Q, WU B, ZHU P, et al. ECA – Net: efficient channel attention for deep convolutional neural networks[C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2020:11531–11539.
- [19] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C] // *Proceedings of the IEEE International Conference on Computer Vision*, 2017: 2242–2251.
- [20] ZHOU D, HOU Q, CHEN Y, et al. Rethinking bottleneck structure for efficient mobile network design[C] // *European Conference on Computer Vision*. Springer, Cham, 2020: 680–697.
- [21] TAN M, LE Q V. Mixconv: mixed depthwise convolutional kernels[C] // *Proceedings of the British Machine Vision Conference (BMVC)*, 2019:1–13.
- [22] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception – v4, inception-resnet and the impact of residual connections on learning[C] // *Proceedings of the Thirty-first AAAI Conference on Artificial Intelligence*, 2017:4278–4284.
- [23] DAVID E, SEROUART M, SMITH D, et al. Global wheat head detection 2021: an improved dataset for benchmarking wheat head detection methods[J]. *Plant Phenomics*, 2021, 2021: 277–285
- [24] ZENG Y, FU J, CHAO H, et al. Learning pyramid-context encoder network for high-quality image inpainting[C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019: 1486–1494.
- [25] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600–612.

(上接第 265 页)

- [12] 王李娟,孔钰如,杨小冬,等. 基于特征优选随机森林算法的农耕地土地利用分类[J]. *农业工程学报*,2020,36(4): 244–250.  
WANG Lijuan, KONG Yuru, YANG Xiaodong, et al. Classification of land use in farming areas based on feature optimization random forest algorithm[J]. *Transactions of the CSAE*, 2020, 36(4): 244–250. (in Chinese)
- [13] 阜宁县地方志办公室. 阜宁年鉴[J]. 南京:江苏人民出版社,2021.
- [14] 陈子琪,陈亮,李建松. 基于 InSAR 相干系数的河湖岸线水事活动监测[J]. *人民黄河*,2020,42(7):160–163.  
CHEN Ziqi, CHEN Liang, LI Jiansong. Monitoring water matter activity of river and lake shoreline based on coherent coefficient[J]. *Yellow River*, 2020, 42(7): 160–163. (in Chinese)
- [15] BOUMAN B A M. Crop modelling and remote sensing for yield prediction[J]. *Egyptian Journal of Biology*, 1995, 43(2): 143–161.
- [16] TOAN L T, RIBBES F, WANG L F, et al. Rice crop mapping and monitoring using ERS – 1 data based on experiment and modeling results[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1997, 35(1): 41–56.
- [17] BOUARABA A, BELHADJ-AISSA A, BORGHYS D, et al. InSAR phase filtering via joint subspace projection method: application in change detection[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(10): 1817–1820.
- [18] SUN Y, JIANG L, LIU L, et al. Mapping glacier elevations and their changes in the western Qilian Mountains, northern Tibetan Plateau, by bistatic InSAR[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, 11(1): 68–78.
- [19] DASH M, LIU H. Feature selection for classification[J]. *Intelligent Data Analysis*,1997, 1(1–4): 131–156.
- [20] HUANG J, LI G, HUANG Q, et al. Joint feature selection and classification for multilabel learning[J]. *IEEE Transactions on Cybernetics*, 2018, 48(3): 876–889.
- [21] KONONENKO I, ŠIMEC E, ROBNIK-ŠIKONJA M. Overcoming the myopia of inductive learning algorithms with RELIEFF [J]. *Applied Intelligence*, 1997, 7(1): 39–55.
- [22] ZHOU Y, ZHANG R, WANG S, et al. Feature selection method based on high-resolution remote sensing images and the effect of sensitive features on classification accuracy[J]. *Sensors(Basel)*, 2018, 18(7): 2013.
- [23] 朱梦豪,李国清,彭壮壮. 特征优选下的农作物遥感分类研究[J]. *测绘科学*,2022,47(3):122–128.  
ZHU Menghao, LI Guoqing, PENG Zhuangzhuang. Remote sensing crop classification method based on feature selection[J]. *Science of Surveying and Mapping*, 2022, 47(3): 122–128. (in Chinese)
- [24] 王长耀,刘正军,颜春燕. 成像光谱数据特征选择及小麦品种识别实验研究[J]. *遥感学报*,2006,10(2):249–255.  
WANG Changyao, LIU Zhengjun, YAN Chunyan. A experimental study on imaging spectrometer data feature selection and wheat type identification[J]. *Journal of Remote Sensing*, 2006, 10(2): 249–255. (in Chinese)
- [25] BREIMAN L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5–32.
- [26] RODRIGUEZ-GALIANO V F, GHIMIRE B, ROGAN J, et al. An assessment of the effectiveness of a random forest classifier for land-cover classification[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2012, 67: 93–104.