

基于小波纹理和随机森林的猕猴桃果园遥感提取

宋荣杰<sup>1,2</sup> 宁纪锋<sup>2</sup> 常庆瑞<sup>1</sup> 班松涛<sup>1</sup> 刘秀英<sup>3</sup> 张宏鸣<sup>2</sup>

(1. 西北农林科技大学资源环境学院, 陕西杨凌 712100; 2. 西北农林科技大学信息工程学院, 陕西杨凌 712100; 3. 河南科技大学农学院, 洛阳 471003)

**摘要:** 为快速、准确地从高分影像中获取猕猴桃种植分布信息,提出了一种结合小波变换纹理分析和随机森林分类的 QuickBird 影像猕猴桃果园自动提取方法。首先,采用 *coif5* 小波对 QuickBird 全色影像进行多尺度小波分解,计算各子频带小波系数的能量特征作为纹理特征;然后,将小波纹理与光谱特征组合构建分类特征;最后,利用随机森林分类实现土地利用分类和猕猴桃果园空间分布提取。结果表明,小波纹理识别猕猴桃果园的效果明显优于光谱特征和其他 2 种纹理特征;光谱 + 小波纹理特征的分类精度最高,猕猴桃果园提取精度 ( $F_k$ ) 和总体分类精度 (OA) 分别为 95.30% 和 94.46%,比光谱 + 灰度共生矩阵纹理分类分别提高 6.70% 和 2.88%,比光谱 + 分形纹理分类显著提高 13.43% 和 6.98%;随机森林分类结果优于相同特征下的支持向量机、最大似然分类。本文提取的猕猴桃果园面积与目视解译结果的相对误差小于 7%。此外,利用本文方法对同期 QuickBird 影像另一研究区的苹果园分布进行提取,结果表明,该方法对苹果园提取有较好的适用性。

**关键词:** 猕猴桃果园; 遥感提取; 小波纹理; 随机森林; QuickBird

**中图分类号:** TP79; S127      **文献标识码:** A      **文章编号:** 1000-1298(2018)04-0222-10

Kiwifruit Orchard Mapping Based on Wavelet Textures and Random Forest

SONG Rongjie<sup>1,2</sup> NING Jifeng<sup>2</sup> CHANG Qingrui<sup>1</sup> BAN Songtao<sup>1</sup> LIU Xiuying<sup>3</sup> ZHANG Hongming<sup>2</sup>

(1. College of Natural Resources and Environment, Northwest A&F University, Yangling, Shaanxi 712100, China  
2. College of Information Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China  
3. College of Agronomy, Henan University of Science and Technology, Luoyang 471003, China)

**Abstract:** In order to obtain the distribution information of the kiwifruit orchards in high spatial resolution remote imagery fast and accurately, a hybrid method for automatic detection of kiwifruit orchard based on wavelet transform and random forest classification algorithm was proposed. Firstly, a wavelet transform based texture extracting process was carried out on the QuickBird panchromatic band by means of a two level decomposition with *coif5* biorthogonal wavelet function, and the multi-scale wavelet textures were further derived from the energy characteristics of the wavelet coefficients in each sub-band. Secondly, the wavelet textures and spectral features were combined to construct the classification feature vectors. Finally, the kiwifruit orchard distributions were automatically delineated through land cover classification by using the random forest ensemble technique. The wavelet textures were found to be more effective in identifying kiwifruit orchard compared with the multi spectral features, gray level co-occurrence matrix (GLCM) textural features and fractal textural features. There was an obvious increase in kiwifruit orchard extracting accuracy ( $F_k$ ) and overall classification accuracy (OA) when spectral features were combined with textural features compared with spectral-only and texture-only features. The highest classification accuracies were achieved by the integration of spectral features and the multi-scale wavelet texture features (spectral + wavelet TF) with  $F_k$  of 95.30% and OA of 94.46%, which was 6.70% and 2.88% higher respectively than those of the results of spectral + GLCM features and 13.43% and

收稿日期: 2017-10-16 修回日期: 2018-02-11  
基金项目: 国家高技术研究发展计划(863 计划)项目(2013AA102401-2)、国家重点研发计划项目(2017YFC0403203)、国家自然科学基金项目(41771315)和陕西省水利科技项目(2017slkj-7)  
作者简介: 宋荣杰(1981—),女,博士生,讲师,主要从事土地资源与空间信息技术研究,E-mail: srj@nwsuaf.edu.cn  
通信作者: 常庆瑞(1959—),男,教授,博士生导师,主要从事土地资源与空间信息技术研究,E-mail: changqr@nwsuaf.edu.cn

6.98% higher respectively than those of spectral + fractal features. Among the three classifiers used, the random forest classifier demonstrated the best performance in terms of OA and  $F_k$ , followed by support vector machine classifier and the maximum likelihood classifier under the same features. The extracted area of kiwifruit orchard was also assessed by the visual interpretation results and the relative error was less than 7%. An apple orchard extracting experiment in another test region was carried out by using the same method, and the results indicated that the method had good applicability.

**Key words:** kiwifruit orchard; remote sensing extraction; wavelet textures; random forest; QuickBird

0 引言

我国是世界上猕猴桃栽植面积和产量最大的国家<sup>[1]</sup>。陕西秦岭北麓是我国优质猕猴桃最佳优生区和集中种植区,猕猴桃栽植面积和产量均居全国前列<sup>[2]</sup>,猕猴桃产业已成为推动当地农村发展和农民致富的优势特色产业。因此,利用遥感技术准确快速掌握猕猴桃果园的空间分布及其种植面积,对于优化猕猴桃区域布局和促进产业结构调整具有重大意义,同时也为长势分析、产量估测和灾害预防提供基础数据。

高空间分辨率遥感影像(高分影像)已成为农作物遥感精细识别的重要数据支撑<sup>[3]</sup>,但高分影像受其低光谱分辨率制约,“异物同谱”现象严重;尤其在作物类型识别应用中,多种作物同时并存、目标作物与周围植被的反射光谱差异不明显。因此,单纯依靠光谱特征区分作物类型存在明显不足,提取精度难以满足应用需求。为此,结合不同作物的种植模式特点挖掘影像的空间纹理信息,并采用高效的机器学习算法构建分类决策机制,已成为提高农作物识别精度的有效途径<sup>[4-5]</sup>。

在纹理信息获取方面,常见的纹理提取方法有统计方法、模型方法和小波变换方法等<sup>[6]</sup>,其中小波变换具有良好的时频局部化特性,能够将图像特征变异从空间域转换到频率域,从而获取不同尺度和多个方向的特征信息,已成为多尺度纹理分析的有效工具。与传统单一尺度的纹理提取方法相比,小波变换有利于更全面表达高分影像的局部细节特征<sup>[7]</sup>。目前小波纹理在高分影像土地利用分类和变化检测方面的研究相对较多<sup>[6,8-9]</sup>,但在作物类型提取方面的研究成果整体偏少<sup>[10-11]</sup>,其适用性有待进一步研究。

在分类算法方面,随机森林(Random forest, RF)是一种树型集成分类器,近年来在遥感土地利用分类<sup>[12-13]</sup>、作物类型识别<sup>[14-16]</sup>和森林树种分类<sup>[17]</sup>等研究中应用广泛,研究表明,RF具有分类精度高、运算速度快和对噪声数据不敏感等优势,能取得比支持向量机(Support vector machine, SVM)、最大似然分类(Maximum likelihood classification, MLC)

更好的分类结果<sup>[18-19]</sup>。目前,RF分类已成功应用于水稻、小麦和玉米等主要粮食作物遥感提取中,但在果园提取方面的研究尚不多见,特别有关猕猴桃果园提取的研究未见系统报道。

本文提出基于小波纹理和随机森林算法的猕猴桃果园自动提取方法,以QuickBird高分影像作为遥感数据源,综合利用影像光谱信息和纹理信息构建分类模型,并通过对比小波纹理、灰度共生矩阵(Gray level co-occurrence matrix, GLCM)纹理和分形纹理3种纹理特征以及RF、SVM和MLC3种分类方法的效果,探索能够有效识别猕猴桃果园的纹理特征与分类模型,以期为基于遥感技术快速、准确获取猕猴桃种植分布信息提供依据。

1 数据来源与研究方法

1.1 研究区概况

杨凌国家农业高新技术产业示范区(简称杨凌区,107°59'~108°08'E,34°14'~34°20'N)位于陕西省关中地区西部,全区地势北高南低,海拔435~563 m,属暖温带半湿润半干旱季风气候,年平均气温12.9℃,年降水量635 mm,属猕猴桃种植适宜区<sup>[20]</sup>。

研究区位于杨凌区五泉镇,这里是杨凌区猕猴桃集中种植区和标准化生产示范基地,有利于开展猕猴桃果园提取研究。研究区农用地以果园为主,包括猕猴桃果园、苹果园和樱桃园。结合野外实地调查和室内目视判读结果,将研究区土地利用划分为猕猴桃园、苹果园、樱桃园、苗木、林地、建筑用地、道路和裸地共8种类型。研究区内猕猴桃园多为已进入结果期的成龄果园,猕猴桃树每年从3—4月开始萌芽生长,到9—10月果实成熟,其中夏季7月是猕猴桃树生长旺盛期,果园内枝叶繁茂、植被覆盖度大。此时区内猕猴桃果园与苹果园、樱桃园之间的光谱特征较为相似,增加了区分难度。

1.2 遥感数据与预处理

研究选用QuickBird高分影像数据,包括一个4波段的多光谱影像和一个单波段的全色影像(表1)。根据研究需要,首先在ENVI软件中对遥感影像进行正射校正,并将全色波段重采样为2.4 m<sup>[21]</sup>,

与多光谱影像分辨率保持一致同时减少纹理提取的计算量,最终裁剪得到研究区影像大小为 768 行、1 249 列(图 1),覆盖面积约为 5.53 km<sup>2</sup>。

根据目视解译结果,研究区猕猴桃果园分布面积最大,约占总面积的 28.59%,其他类别的面积比例分别为苹果园 5.17%、樱桃园 2.59%、苗木 7.76%、林地 10.79%、建筑用地 27.54%、道路 4.51%、裸地 13.05%。




图 1 研究区 QuickBird 数据和地面参考数据

Fig. 1 QuickBird data of study site and corresponding ground truth data

1.3 样本数据选取

为训练监督分类模型并进行分类精度定量评价,根据 2015 年同期实地调查数据,结合 Google Earth 历史高分影像数据,利用 ENVI 5.1 软件的感兴趣区(Region of intrest, ROI)工具以不规则多边形块为单元随机选取样本。为进行可靠分类,许多研究建议训练样本数量应达到 10*d*~30*d*(*d* 为波段数)<sup>[22]</sup>,本研究中各类别训练样本数量均超过 10*d*,其中猕猴桃果园、建筑用地、裸地等面积较大的地类样本数量超过 30*d*。研究还利用 J-M 距离计算不同样本之间的可分离度来优化样本集<sup>[23]</sup>,最终选取训练样本 2 327 个(像素:猕猴桃园 566,苹果园 258,樱桃园 138,苗木 205,建筑用地 343,道路 153,裸地 450,林地 214),另随机选取验证样本 4 659 个(像素:猕猴桃园 1 133,苹果园 517,樱桃园 276,苗木 410,建筑用地 687,道路 307,裸地 900,林地 429)。

虽然实地调查数据和遥感影像时间相差 1 a,考虑到同一季节的相同时间段,同一区域中农林作物的生长状况具有相似性,且研究区果园多为成龄果园,种植时间较长,面积相对稳定。因此,可认为由此获得的样本数据具有代表性和正确性<sup>[24-25]</sup>。

1.4 纹理特征提取方法

通过对影像进行小波变换提取纹理特征。首先采用金字塔分解算法将图像进行二维离散小波变换<sup>[26]</sup>,每级分解产生 1 个低频子带和水平、垂直、对角 3 个方向的高频子带;将低频子带再次分解,得到

表 1 QuickBird 影像波段参数(2014 年 7 月 25 日)

Tab. 1 Parameters of QuickBird data

| 参数                      | 波段  | 波长/μm     | 空间分辨率/m |
|-------------------------|-----|-----------|---------|
| <i>B</i> <sub>1</sub>   | 蓝   | 0.45~0.52 | 2.4     |
| <i>B</i> <sub>2</sub>   | 绿   | 0.52~0.60 | 2.4     |
| <i>B</i> <sub>3</sub>   | 红   | 0.63~0.69 | 2.4     |
| <i>B</i> <sub>4</sub>   | 近红外 | 0.76~0.90 | 2.4     |
| <i>B</i> <sub>pan</sub> | 全色  | 0.45~0.90 | 0.61    |

第 2 级分解的 4 个小波子带,重复这个过程实现多尺度小波分解。图像 *f*(*x*, *y*) 第 *j* 级小波分解的小波系数计算公式为<sup>[9]</sup>

$$\left\{\begin{aligned}c_{m,n}^{(j)} &= \sum_{l,k} \phi_{k-2m} \phi_{l-2n} f_{k,l}^{j-1} \\w_{m,n}^{(j,h)} &= \sum_{l,k} \phi_{k-2m} \psi_{l-2n} f_{k,l}^{j-1} \\w_{m,n}^{(j,v)} &= \sum_{l,k} \psi_{k-2m} \phi_{l-2n} f_{k,l}^{j-1} \\w_{m,n}^{(j,d)} &= \sum_{l,k} \psi_{k-2m} \psi_{l-2n} f_{k,l}^{j-1}\end{aligned}\right. \tag{1}$$

式中  $c_{m,n}^{(j)}$ ——低频近似系数  
 $w_{m,n}^{(j,h)}$ ——水平高频细节系数  
 $w_{m,n}^{(j,v)}$ ——垂直高频细节系数  
 $w_{m,n}^{(j,d)}$ ——对角高频细节系数  
 $\phi$ ——1 维尺度函数  
 $\psi$ ——1 维小波函数

试验选用 coi5f5 双正交小波基。研究表明,增加小波分解级数有利于获得图像在多尺度上的细节特征,但小波分解级数越高,特征图像的边界效应就越明显,从而影响分类精度;此外,小波变换的计算量随分解级数增加而增大<sup>[26-28]</sup>。为有效表达纹理信息并降低计算复杂度,本文对全色波段进行 3 级小波分解,并通过对比不同分解层次特征的分类识别效果来确定最佳分解级数 *b*。

通常采用小波变换系数的统计值来描述图像纹理特征<sup>[8]</sup>,常用统计量有均值、标准差、能量和熵等特征<sup>[26-27]</sup>,研究分别计算上述 4 种特征并进行比

较,最终选用效果最好的能量特征,其计算方法为

$$E = \sum_{r=1}^R \sum_{s=1}^S p^2(r,s) \tag{2}$$

式中  $p(r,s)$ ——像元 $(r,s)$ 的小波系数  
 $R、S$ ——小波子带影像的行、列数

通过 Matlab 编程实现小波纹理特征提取:首先以原始影像中每个像元为中心,选取一定大小的邻域窗口实施小波变换;并根据式(2)计算各小波子带的能量值赋给中心像元,获得该像元在不同频率子带的能量值;然后移动邻域窗口计算得到整个影像的能量特征;最后通过特征组合构建一个 4b 维小波特征向量。为分析不同邻域窗口对分类精度的影响,试验选取 6 个不同的窗口(7 像素×7 像素、11 像素×11 像素、15 像素×15 像素、19 像素×19 像素、23 像素×23 像素、27 像素×27 像素)提取纹理特征。

为明确小波纹理特征识别猕猴桃果园的效果,本文还分别提取全色波段的 GLCM 和分形纹理特征<sup>[29]</sup>。为简化计算并考虑分类识别效果,试验选用 64 级灰度级、1 个像元距离计算常用的 8 个 GLCM 统计量<sup>[30]</sup>:均值(MEA)、方差(VAR)、同质性(HOM)、对比度(CON)、不相似性(DIS)、熵(ENT)、角二阶矩(ASM)和相关性(COR);通过试验对比 0°、45°、90°和 135°方向的纹理分类效果,选用分类精度较高的 135°方向计算 GLCM。分形纹理提取方法详见文献[29]。

1.5 遥感图像监督分类

1.5.1 RF 算法

随机森林是一种由多棵分类与回归树(Classification and regression tree, CART)构成的集成分类器,主要包括训练和分类 2 个阶段。在训练阶段,首先采用随机可重复的自助取样策略(bootstrap)选取训练样本,然后针对每个训练样本集利用 CART 算法构建分类树,对树中每个节点,先从所有特征中为其随机选取  $M_{try}$  个特征,并依据基尼系数进行分裂测试并选取最优特征。重复上述取样、建树过程  $N_{tree}$  次,最终建立由  $N_{tree}$  棵决策树构成的随机森林。在分类阶段,每棵决策树都对新样本的类别进行独立判断,最后汇总所有决策树的分类结果,采用多数投票原则输出最终结果。

在 bootstrap 取样过程中,约有 1/3 的样本未被选中,这些样本称为袋外(Out of bag, OOB)数据<sup>[31-32]</sup>,使用 OOB 数据对 RF 模型进行评估可得到 OOB 精度或 OOB 误差。本研究通过 OOB 误差分析对 RF 模型构建所需的 2 个关键参数( $N_{tree}$  和  $M_{try}$ )进行参数寻优<sup>[17,31]</sup>,并评估分类特征变量的重要

性。

1.5.2 图像 RF 分类

首先利用 ENVI 5.1 软件将小波纹理特征与光谱特征叠加,获得光谱+小波纹理复合分类特征;其次以复合分类特征和训练样本为输入,利用 EnMap Box 软件训练并构建 RF 分类模型<sup>[33]</sup>;最后利用构建好的 RF 模型对整个遥感图像分类,获得研究区土地利用分类图。

1.5.3 分类精度评价

为定量评价各分类方案的分类精度,分别从猕猴桃果园提取精度和总体分类效果两个层面构建评价指标。首先利用表 1 中的验证样本和计算分类结果混淆矩阵,得到用户精度(User accuracy, UA)、生产者精度(Production accuracy, PA)、总体分类精度(Overall accuracy, OA)和 Kappa 系数;其次,根据猕猴桃果园的 UA 和 PA 计算猕猴桃果园提取精度  $F_k$ <sup>[5,34]</sup>。本文用 OA 和 Kappa 系数评价总体分类效果,用  $F_k$  评价猕猴桃果园提取精度,并结合目视解译结果对猕猴桃果园提取面积进行检验。

2 结果与分析

2.1 不同地物样本的光谱特征分析

对本研究选取的 8 种典型地物样本的光谱均值进行统计,结果如图 2 所示。由图 2 可以看出,猕猴桃果园与非植被类别(建筑用地、道路和裸地)在各波段上的光谱差异较明显,但与林地、樱桃园和苹果园等类别的光谱特征较为相似,除  $B_4$  波段外光谱区分性不大。因此,仅依靠光谱特征提取猕猴桃果园将面临一定难度,有必要引入纹理信息提升其识别精度。




图 2 典型地物在不同波段上光谱均值

Fig.2 Mean spectral values of each class across four multi-spectral bands

2.2 纹理窗口优选及小波纹理提取结果

为明确最佳纹理窗口,分别选取 6 个不同的邻域窗口提取小波纹理、GLCM 纹理和分形纹理,并将不同窗口提取的纹理特征分别与光谱特征组合进行 RF 分类,分类结果如图 3 所示。




图 3 分类精度随纹理窗口变化情况

Fig. 3 Classification accuracy with different texture window sizes

由图 3 可知,随着纹理窗口增大,3 种纹理特征对应的分类精度均呈现先增大后减少的趋势,其中小波纹理的猕猴桃果园提取精度和总体分类精度均在窗口大小为 19 像素×19 像素时取最大值,故确定此窗口为最佳小波纹理窗口。同理,GLCM 纹理和分形纹理最佳提取窗口分别为 19 像素×19 像素、15 像素×15 像素。

表 2 是不同分解水平的小波纹理特征分类精度,其中  $L_1$  表示第 1 级小波纹理与光谱特征叠加,  $L_1 \sim L_2$  表示第 1 级和第 2 级小波纹理与光谱特征叠加。

表 2 不同分解水平的小波纹理特征分类精度

Tab. 2 Classification accuracy with different wavelet decomposition levels

| 特征             | $F_k / \%$ | OA / % | Kappa 系数 |
|----------------|------------|--------|----------|
| $L_1$          | 93. 91     | 93. 05 | 0. 92    |
| $L_2$          | 86. 08     | 89. 38 | 0. 87    |
| $L_3$          | 83. 81     | 87. 42 | 0. 85    |
| $L_1 \sim L_2$ | 95. 30     | 94. 46 | 0. 93    |
| $L_1 \sim L_3$ | 95. 01     | 93. 71 | 0. 93    |

分析表 2 可知,小波分解各级特征对分类精度的影响不同。单一级别的小波纹理特征叠加光谱特征分类时,  $L_1$  的分类精度 (OA 和  $F_k$ ) 最高,随着分解级数增加,  $L_2$ 、 $L_3$  的 OA 和  $F_k$  依次降低。多级小波纹理特征叠加光谱特征的分类效果优于单一级别,其中  $L_1 \sim L_2$  的分类精度最高 ( $F_k$  和 OA 均高于 94%) 且优于  $L_1 \sim L_3$  的分类精度。由于 2 级小波分解既有较好的分类效果又能减少计算量,因此,本文选用 2 级小波分解提取纹理特征。

图 4 是采用最佳窗口、2 级小波分解提取的小波纹理特征,其中  $E_1$ 、 $E_2$ 、 $E_3$  和  $E_4$  分别是 1 级小波分解水平、垂直、对角高频子带和低频子带的能量特征,  $E_5 \sim E_8$  为第 2 级分解的 4 个纹理特征。图像中地物亮度越大,表明其能量值越大,反映其空间变异性大。可看出,建筑用地的亮度在各个特征图像中

普遍较大,而裸地则普遍较暗。猕猴桃果园在图 4d 中的亮度相对较大;图 4c 中苹果园和樱桃园亮度较大,与猕猴桃果园差异相对明显。从整体来看,与 1 级分解纹理图像相比,第 2 级分解对应的纹理图像整体偏暗。

2.3 RF 参数选取及分类模型构建

为评估 RF 模型的参数敏感性,以多光谱和小波纹理组合作为分类特征 (特征维数  $q = 12$ ),选取不同的  $N_{\text{tree}}$  和  $M_{\text{try}}$  构建 RF 分类模型,分析不同参数组合对 OOB 总体分类精度 (OOB OA) 的影响。图 5 是  $M_{\text{try}}$  分别取 12、6 和 3 (分别对应  $q$ 、 $q/2$  和  $\sqrt{q}$ )、 $N_{\text{tree}}$  取 1 000 时分类精度变化情况。

从总体上来看,OOB OA 随  $N_{\text{tree}}$  增大波动式上升并最终趋于稳定。 $N_{\text{tree}}$  由 1 增加到 30,图中 3 个 RF 模型的分类精度均有明显提升,随后增幅相对变缓,当  $N_{\text{tree}}$  增加至 100 时,分类精度趋于平稳 (约为 99.5%)。图 5 同时表明,当  $N_{\text{tree}} > 100$  时,  $M_{\text{try}} = 3$  时分类精度最高,当  $M_{\text{try}} = 6$  或  $M_{\text{try}} = 12$  时 OOB OA 并未有明显提升反而有小幅下降趋势。由于增大  $N_{\text{tree}}$  和  $M_{\text{try}}$  均会增加 RF 模型训练时间<sup>[31]</sup>,综合考虑分类精度和计算效率,本文  $N_{\text{tree}}$  统一取值为 100、 $M_{\text{try}}$  取值为  $\sqrt{q}$ 。

2.4 不同分类特征的分类精度对比

为比较不同特征识别猕猴桃果园的效果,构建以下 7 种分类特征:单纯光谱特征 (SF)、小波纹理特征 (wavelet TF)、GLCM 纹理特征 (GLCM TF)、分形纹理特征 (fractal TF)、光谱结合小波纹理 (SF + wavelet TF)、光谱结合 GLCM 纹理 (SF + GLCM TF)、光谱结合分形纹理 (SF + fractal TF)。表 3 为 7 种特征的 RF 分类结果,其中  $P_{Ak}$ 、 $U_{Ak}$  分别为猕猴桃果园的生产者精度和用户精度。

由表 3 可知,单一纹理特征分类时, wavelet TF 分类的  $F_k$  最高 (87.61%),其次是 GLCM TF ( $F_k = 84.03\%$ ), fractal TF 的  $F_k$  仅为 54.68%,说明小波纹理或 GLCM 纹理均能有效表达猕猴桃果园的空间




图 4 小波纹理特征提取结果

Fig. 4 Texture features derived from wavelet transform




图 5 决策树数量和特征数量对总体分类精度的影响

Fig. 5 Influence of different  $N_{tree}$  and  $M_{try}$  values on OOB OA

特征,但分形纹理识别效果较差。采用 SF 分类时  $F_k$ 和 OA 分别为 82.85%和 86.71%,其 OA 比单一纹理分类高出 4.87%以上,但  $F_k$ 却比 wavelet TF、GLCM TF 分别降低 5.74%和 1.42%,这表明虽然光谱特征总体分类效果优于各纹理特征,但其识别

猕猴桃果园的能力不如小波纹理和 GLCM 纹理。

将光谱与纹理特征结合得到的复合特征 (SF + wavelet TF、SF + GLCM TF、SF + fractal TF) 的分类效果优于单一光谱或单一纹理分类,其中, SF + wavelet TF 分类的  $F_k$ 和 OA 较 SF 分类分别大幅提高 15.03%和 8.94%,较 wavelet TF 分类分别提高 8.78%和 14.25%。在 3 种复合特征中, SF + wavelet TF 特征的分类精度最高,  $F_k$ 和 OA 均超过 94%,比 SF + GLCM TF 分类分别提高 6.70%和 2.88%,比 SF + fractal TF 分类显著提高 13.43%和 6.98%。上述分析表明光谱和纹理特征结合能充分发挥多源信息优势互补作用,有利于增加不同地类之间的可区分性,从而提升总体分类效果和猕猴桃果园提取精度,其中 SF + wavelet TF 特征效果最佳。

表 3 不同分类特征的 RF 分类结果

Tab. 3 Classification accuracy with different input features based on RF

| 分类特征            | 特征维数 | $P_{Ak}/\%$ | $U_{Ak}/\%$ | $F_k/\%$ | OA/%  | Kappa 系数 | $N_{tree}$ | $M_{try}$ |
|-----------------|------|-------------|-------------|----------|-------|----------|------------|-----------|
| SF              | 4    | 90.64       | 76.30       | 82.85    | 86.71 | 0.84     | 100        | 2         |
| wavelet TF      | 8    | 83.94       | 91.62       | 87.61    | 82.68 | 0.80     | 100        | 2         |
| GLCM TF         | 8    | 85.00       | 83.09       | 84.03    | 81.03 | 0.77     | 100        | 2         |
| fractal TF      | 1    | 71.84       | 44.14       | 54.68    | 52.50 | 0.42     | 100        | 1         |
| SF + wavelet TF | 12   | 95.76       | 94.84       | 95.30    | 94.46 | 0.93     | 100        | 3         |
| SF + GLCM TF    | 12   | 94.53       | 84.66       | 89.32    | 91.82 | 0.90     | 100        | 3         |
| SF + fractal TF | 5    | 91.70       | 77.54       | 84.02    | 88.30 | 0.86     | 100        | 2         |

为进一步明确 SF + wavelet TF 复合特征中各特征变量对分类精度的影响,利用 RF 算法的 OOB 误差分析计算特征变量重要性 (Normalized variable importance, NVI), NVI 越大表明该变量的重要性和贡献度越大<sup>[35]</sup>。图 6 是该复合特征 12 个特征分量的 NVI 计算结果排序。可以看出,不同变量的 NVI 差异较大,其中小波纹理  $E_2$  的 NVI 最大,其次是多光谱  $B_4$  波段,说明这 2 个特征分量对分类精度提升最为重要;  $E_1$ 、 $E_8$ 、 $B_3$  的 NVI 较为接近,表明这些分量对分类精度贡献相似;而  $B_2$ 、 $E_5$  和  $E_6$  的 NVI 排序靠后,表明这些特征分量对分类精度的贡献度相对较小。




图 6 光谱叠加小波纹理特征变量重要性  
Fig. 6 Variable importance of spectral features combined with wavelet texture features

保留图 6 中 NVI 最大的 6 个特征分量进行 RF 分类,  $F_k$  和 OA 分别为 93.78% 和 92.51%, 即特征维数减少 50% 时  $F_k$  和 OA 分别降低 1.62% 和 2.11%, 但结果仍优于表 3 中其他分类结果, 表明 NVI 分析能够自动标识最优特征子集, 在有效降维的同时保证较高的分类精度。

2.5 不同分类方法结果对比

为评估 RF 算法的分类性能, 基于相同样本集进行 SVM 和 MLC 分类。表 4 为采用复合分类特征时 3 种算法的分类结果。

由表 4 可知, RF 分类的  $F_k$  和 OA 高于相同特征下的 SVM 和 MLC 分类结果, 与 SVM 分类相比 OA 和  $F_k$  最高分别提升 3.38% 和 2.34%, 与 MLC 分类相比 OA 和  $F_k$  最高分别提升 4.89% 和 6.07%, 表明 RF 提取猕猴桃果园效果和稳定性好。此外, 除 SF + GLCM TF 特征外, SVM 结合其他 2 种特征的分类精度均高于 MLC 分类, 其中  $F_k$  较 MLC 提高 3% 以上, 表明 SVM 与这 2 种特征结合识别猕猴桃果园的效果优于 MLC。

此外, SF + wavelet TF 特征的分类精度 (OA 和  $F_k$ ) 在 3 种分类算法中均高于其他 2 种特征分类, 表明小波纹理对不同分类算法的普适性好。综合表 3 和表 4, 结合光谱与小波纹理特征和 RF 分类算法提取猕猴桃果园的效果最佳。

表 4 不同分类算法的分类精度  
Tab. 4 Classification accuracy using different classifiers

| 分类算法 | 分类特征            | $P_{Ak}/\%$ | $U_{Ak}/\%$ | $F_k/\%$ | OA/ $\%$ | Kappa 系数 |
|------|-----------------|-------------|-------------|----------|----------|----------|
| MLC  | SF + wavelet TF | 87.47       | 92.36       | 89.85    | 90.71    | 0.89     |
|      | SF + GLCM TF    | 92.50       | 85.34       | 88.77    | 90.64    | 0.89     |
|      | SF + fractal TF | 78.02       | 81.85       | 79.89    | 84.18    | 0.81     |
| SVM  | SF + wavelet TF | 93.29       | 94.21       | 93.75    | 91.37    | 0.90     |
|      | SF + GLCM TF    | 92.06       | 82.98       | 87.28    | 90.66    | 0.89     |
|      | SF + fractal TF | 89.14       | 76.52       | 82.35    | 85.81    | 0.83     |
| RF   | SF + wavelet TF | 95.76       | 94.84       | 95.30    | 94.46    | 0.93     |
|      | SF + GLCM TF    | 94.53       | 84.66       | 89.32    | 91.82    | 0.90     |
|      | SF + fractal TF | 91.70       | 77.54       | 84.02    | 88.30    | 0.86     |

2.6 猕猴桃果园提取结果评价

图 7 为不同分类方案得到的研究区土地利用分类图。可以直观看出, 光谱分类结果 (图 7a) 中存在明显的椒盐现象, 猕猴桃果园和其他植被之间的错分现象较为严重, 建筑用地显得非常破碎。wavelet TF 分类结果中道路等带状地物的边缘明显被扩大, 窗口效应较明显 (图 7b)。SF + wavelet TF 分类结果 (图 7c) 中椒盐噪声整体减少, 提取的猕猴桃果园分布完整性较好, 与其他果园的混分状况有较大改善。由图 7d 可以看出, SVM 分类与 RF 分类结果较为相

似, 但猕猴桃果园和苹果园混分现象增多。上述结果表明, 综合采用 SF + wavelet TF 特征和 RF 分类算法提取的猕猴桃果园完整性较好, 影像整体分类效果比其他分类方案有明显改善, 这与表 3 和表 4 的定量分析一致。

利用 ENVI 5.1 软件的 majority 分析功能对分类结果进行 3 像素  $\times$  3 像素的平滑滤波以减少椒盐噪声<sup>[36]</sup>; 并将结果整理为猕猴桃果园和非猕猴桃果园 2 类, 得到研究区猕猴桃果园的空间分布如图 8a 所示, 目视解译提取的猕猴桃果园分布如图 8b 所




图 7 不同方法的分类结果

Fig. 7 Classified maps using different methods




图 8 猕猴桃果园提取结果

Fig. 8 Spatial distributions of kiwifruit orchard produced with different methods

示。经统计,本文方法、基于光谱特征提取的猕猴桃果园面积分别为 1 688 486 m<sup>2</sup>和 1 754 669 m<sup>2</sup>,目视解译方法提取的猕猴桃果园面积为 1 579 628 m<sup>2</sup>。与目视解译结果相比,本文提取的猕猴桃果园面积相对误差为 6.89%,基于光谱特征的面积提取误差为 11.08%。可见,本文方法能够有效降低猕猴桃果园的面积提取误差。

2.7 对其他果园提取的适用性分析

为进一步验证本文方法对其他果园遥感提取的适用性,选取另一研究区的苹果园为提取对象进行试验。该试验选取的研究区土地利用类型包含苹果

园、夏玉米、苗木、居民地、道路、裸地和水渠共 7 种典型地物,遥感数据选用与上述猕猴桃果园提取试验同一景 QuickBird 影像,影像大小为 835 行、1 225 列(研究区及试验数据见文献[5])。分别采用本文 1.4 节和 1.5 节所述方法进行小波纹理特征提取和 RF 分类,得到苹果园提取精度( $F_a$ )和总体分类精度(OA)如表 5 所示。其中, $P_{Aa}$ 、 $U_{Aa}$ 分别为苹果园的生产者精度和用户精度;wavelet TF 纹理窗口尺寸为 13 像素×13 像素。

由表 5 可以看出,单独采用 wavelet TF 特征进行 RF 分类(wavelet TF,RF),虽然 OA 只有 82.01%,

表 5 苹果园提取试验分类精度

Tab. 5 Classification accuracy of apple orchard extraction experiment

| 方法                  | $P_{Aa}/\%$ | $U_{Aa}/\%$ | $F_a/\%$ | OA/%  | Kappa 系数 |
|---------------------|-------------|-------------|----------|-------|----------|
| wavelet TF, RF      | 99.27       | 92.05       | 95.52    | 82.01 | 0.77     |
| SF + wavelet TF, RF | 100         | 95.64       | 97.77    | 96.43 | 0.96     |
| SF + GLCM TF, SVM   | 99.91       | 94.23       | 96.99    | 96.16 | 0.95     |

但  $F_k$  达到 95.52%, 表明利用本文方法提取的小波纹理特征能有效识别苹果园; 将小波纹理与光谱特征组合后进行 RF 分类 (SF + wavelet TF, RF),  $F_a$  和 OA 均提升到 96% 以上, 说明本文方法用于苹果园提取是可行的且具有较高提取精度。SF + wavelet TF 分类结果比单独利用 wavelet TF 分类在精度上有明显提高, 这与上述猕猴桃果园提取试验结果一致。与文献[5]的研究方法 (SF + GLCM TF, SVM) 相比, 本文方法能获得更高的提取精度 ( $F_a$  和 OA 分别提升 0.80% 和 0.28%)。上述分析表明, 本文方法对基于 QuickBird 影像的苹果园提取具有较好的适用性。

### 3 结论

(1) 构建了一种结合高分影像光谱信息和纹理信息以及随机森林算法的集成分类模型, 利用该模型对 QuickBird 高分影像中猕猴桃果园进行有效识

别和自动提取, 猕猴桃果园提取精度 ( $F_k$ ) 为 95.30%、总体分类精度 (OA) 为 94.46%。

(2) 通过对比不同分类特征的分类精度, 发现采用 coif5 小波函数、2 级小波分解、窗口大小为 19 像素 × 19 像素提取的小波纹理特征能够有效识别猕猴桃果园, 其  $F_k$  明显优于光谱特征和其他纹理特征; 光谱与纹理信息结合能有效提升  $F_k$  和 OA, 其中光谱 + 小波纹理分类精度最高,  $F_k$  和 OA 比光谱 + GLCM 纹理分类分别提高 6.70% 和 2.88%, 比光谱 + 分形纹理分类显著提高 13.43% 和 6.98%。

(3) 通过对比 RF、SVM 和 MLC 分类器性能, 结果表明, RF 算法在相同分类特征中  $F_k$  和 OA 最高, 与 SVM 分类相比分类精度提升幅度超过 2%, 与 MLC 分类相比分类精度提升超过 4%。对猕猴桃果园提取结果进行面积统计, 本文提取的猕猴桃种植面积与目视解译结果的相对误差小于 7%。

### 参 考 文 献

- 屈振江, 周广胜. 中国主栽猕猴桃品种的气候适宜性区划[J]. 中国农业气象, 2017, 38(4): 257-266.  
QU Zhenjiang, ZHOU Guangsheng. Regionalization of climatic suitability for major kiwifruit cultivars in China[J]. Chinese Journal of Agrometeorology, 2017, 38(4): 257-266. (in Chinese)
- 胡凡, 石磊, 李茹, 等. 陕西关中地区猕猴桃施肥现状评价[J]. 中国土壤与肥料, 2017(3): 44-49.  
HU Fan, SHI Lei, LI Ru, et al. Fertilization evaluation of kiwifruit in Guanzhong region of Shaanxi province[J]. Soil and Fertilizer Sciences in China, 2017(3): 44-49. (in Chinese)
- 陈仲新, 任建强, 唐华俊, 等. 农业遥感研究应用进展与展望[J]. 遥感学报, 2016, 20(5): 748-767.  
CHEN Zhongxin, REN Jianqiang, TANG Huajun, et al. Progress and perspectives on agricultural remote sensing research and applications in China[J]. Journal of Remote Sensing, 2016, 20(5): 748-767. (in Chinese)
- AKAR Ö, GÜNGÖR O. Integrating multiple texture methods and NDVI to the random forest classification algorithm to detect tea and hazelnut plantation areas in northeast Turkey[J]. International Journal of Remote Sensing, 2015, 36(2): 442-464.
- 宋荣杰, 宁纪锋, 刘秀英, 等. 基于纹理特征和 SVM 的 QuickBird 影像苹果园提取[J/OL]. 农业机械学报, 2017, 48(3): 188-197. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20170324&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170324&journal_id=jcsam). DOI:10.6041/j.issn.1000-1298.2017.03.024.  
SONG Rongjie, NING Jifeng, LIU Xiuying, et al. Apple orchard extraction with QuickBird imagery based on texture features and support vector machine[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(3): 188-197. (in Chinese)
- LI Qingyu, HUANG Xin, WEN Dawei, et al. Integrating multiple textural features for remote sensing image change detection[J]. Photogrammetric Engineering and Remote Sensing, 2017, 83(2): 109-121.
- MYINT S W, MESEV V. A comparative analysis of spatial indices and wavelet-based classification[J]. Remote Sensing Letters, 2012, 3(2): 141-150.
- MYINT S W, ZHU Tong, ZHENG Baojuan. A novel image classification algorithm using overcomplete wavelet transforms[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(6): 1232-1236.
- 黄昕, 张良培, 李平湘. 基于小波的高分辨率遥感影像纹理分类方法研究[J]. 武汉大学学报: 信息科学版, 2006, 31(1): 66-69.  
HUANG Xin, ZHANG Liangpei, LI Pingxiang. Methods for classification of the high spatial resolution remotely sensed images based on wavelet transform[J]. Geomatics and Information Science of Wuhan University, 2006, 31(1): 66-69. (in Chinese)
- REGNIERS O, BOMBRUN L, LAFON V, et al. Supervised classification of very high resolution optical images using wavelet-based textural features[J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(6): 3722-3735.
- CIRIZA R, SOLA I, ALBIZUA L, et al. Automatic detection of uprooted orchards based on orthophoto texture analysis[J]. Remote Sensing, 2017, 9(5): 492-513.
- DEBATS S R., LUO D, ESTES L D, et al. A generalized computer vision approach to mapping crop fields in heterogeneous agricultural landscapes[J]. Remote Sensing of Environment, 2016, 179: 210-221.
- 马玥, 姜琦刚, 孟治国, 等. 基于随机森林算法的农耕地土地利用分类研究[J/OL]. 农业机械学报, 2016, 47(1): 297-303. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20160140&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20160140&journal_id=jcsam). DOI:10.6041/j.issn.1000-1298.2016.01.040.  
MA Yue, JIANG Qigang, MENG Zhiguo, et al. Classification of land use in farming area based on random forest algorithm[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(1): 297-303. (in Chinese)

- 14 SON N T, CHEN C F, CHEN Chengru, et al. Assessment of Sentinel-1A data for rice crop classification using random forests and support vector machines[J]. *Geocarto International*, 2017, 32(10): 1-32.
- 15 LIU Jiantao, FENG Quanlong, GONG Jianhua, et al. Winter wheat mapping using a random forest classifier combined with multi-temporal and multi-sensor data[J]. *International Journal of Digital Earth*, 2017, 10(11): 1-20.
- 16 黄健熙,侯裔焯,苏伟,等. 基于 GF-1 WFV 数据的玉米与大豆种植面积提取方法[J]. *农业工程学报*, 2017, 33(7): 164-170. HUANG Jianxi, HOU Yuzhuo, SU Wei, et al. Mapping corn and soybean cropped area with GF-1 WFV data[J]. *Transactions of the CSAE*, 2017, 33(7): 164-170. (in Chinese)
- 17 GAO Tian, ZHU Jiaojun, ZHENG Xiao, et al. Mapping spatial distribution of larch plantations from multi-seasonal Landsat-8 OLI imagery and multi-scale textures using random forests[J]. *Remote Sensing*, 2015, 7(2): 1702-1720.
- 18 OTHMAN A A, GLOAGUEN R. Integration of spectral, spatial and morphometric data into lithological mapping: a comparison of different machine learning algorithms in the Kurdistan region, NE Iraq[J]. *Journal of Asian Earth Sciences*, 2017, 146: 90-102.
- 19 陈元鹏,郑文聚,周旭,等. 基于 MESMA 和 RF 的山丘区土地利用信息分类提取[J/OL]. *农业机械学报*, 2017, 48(7): 136-144. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20170717&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170717&journal_id=jcsam). DOI:10.6041/j.issn.1000-1298.2017.07.017.
- CHEN Yuanpeng, YUN Wenju, ZHOU Xu, et al. Classification and extraction of land use information in hilly area based on MESMA and RF classifier[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2017, 48(7): 136-144. (in Chinese)
- 20 贺文丽,李星敏,朱琳,等. 基于 GIS 的关中猕猴桃气候生态适宜性区划[J]. *中国农学通报*, 2011, 27(22): 202-207. HE Wenli, LI Xingmin, ZHU Lin, et al. Climate ecological applicability regionalization for kiwifruit based on GIS in Guanzhong of Shaanxi province[J]. *Chinese Agricultural Science Bulletin*, 2011, 27(22): 202-207. (in Chinese)
- 21 AGÜERA F, AGUILAR F J, AGUILAR M A. Using texture analysis to improve per-pixel classification of very high resolution images for mapping plastic greenhouses[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2008, 63(6): 635-646.
- 22 MASOUMI F, ESLAMKISH T, ABKAR A A, et al. Integration of spectral, thermal, and textural features of ASTER data using random forests classification for lithological mapping[J]. *Journal of African Earth Sciences*, 2017, 129: 445-457.
- 23 KESHTKAR H, VOIGT W, ALIZADEH E. Land-cover classification and analysis of change using machine-learning classifiers and multi-temporal remote sensing imagery[J]. *Arabian Journal of Geosciences*, 2017, 10(6): 154-168.
- 24 杨红卫,童小华. 高分辨率影像的橡胶林分布信息提取[J]. *武汉大学学报:信息科学版*, 2014, 39(4): 411-416. YANG Hongwei, TONG Xiaohua. Distribution information extraction of rubber woods using remote sensing images with high resolution[J]. *Geomatics and Information Science of Wuhan University*, 2014, 39(4): 411-416. (in Chinese)
- 25 REGNIERS O, BOMBRUN L, GUYON D, et al. Wavelet-based texture features for the classification of age classes in a maritime pine forest[J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12(3): 621-625.
- 26 OUMA Y O, NGIGI T G, TATEISHI R. On the optimization and selection of wavelet texture for feature extraction from high-resolution satellite imagery with application towards urban-tree delineation[J]. *International Journal of Remote Sensing*, 2006, 27(1): 73-104.
- 27 韦春桃,王宁,张利恒,等. 基于纹理特征的高分辨率遥感影像分类方法[J]. *桂林理工大学学报*, 2013, 33(1): 80-85. WEI Chuntao, WANG Ning, ZHANG Liheng, et al. Remote sensing image classification based on texture features[J]. *Journal of Guilin University of Technology*, 2013, 33(1): 80-85. (in Chinese)
- 28 倪玲,张剑清,姚巍. 基于小波的 SAR 影像纹理分析[J]. *武汉大学学报:信息科学版*, 2004, 29(4): 367-370. NI Ling, ZHANG Jianqing, YAO Wei. SAR image's texture analysis based on wavelet[J]. *Geomatics and Information Science of Wuhan University*, 2004, 29(4): 367-370. (in Chinese)
- 29 郑淑丹,郑江华,石明辉,等. 基于分形和灰度共生矩阵纹理特征的种植型药用植物遥感分类[J]. *遥感学报*, 2014, 18(4): 868-886. ZHENG Shudan, ZHENG Jianghua, SHI Minghui, et al. Classification of cultivated Chinese medicinal plants based on fractal theory and gray level co-occurrence matrix textures[J]. *Journal of Remote Sensing*, 2014, 18(4): 868-886. (in Chinese)
- 30 CHUANG Yungchung, SHIU Yishiang. A comparative analysis of machine learning with WorldView-2 pan-sharpened imagery for tea crop mapping[J]. *Sensors*, 2016, 16(5): 594.
- 31 BELGIU M, DRĂGUT L. Random forest in remote sensing: a review of applications and future directions[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 114: 24-31.
- 32 FENG Quanlong, LIU Jiantao, GONG Jianhua. UAV remote sensing for urban vegetation mapping using random forest and texture analysis[J]. *Remote Sensing*, 2015, 7(1): 1074-1094.
- 33 DU Peijun, SAMAT A, WASKE B, et al. Random forest and rotation forest for fully polarized SAR image classification using polarimetric and spatial features[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, 105: 38-53.
- 34 JOHNSON B A, SCHEYVENS H, SHIVAKOTI B R. An ensemble pansharpening approach for finer-scale mapping of sugarcane with Landsat 8 imagery[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2014, 33(12): 218-225.
- 35 刘舒,姜琦刚,马玥,等. 基于多目标遗传随机森林特征选择的面向对象湿地分类[J/OL]. *农业机械学报*, 2017, 48(1): 119-127. [http://www.j-csam.org/jcsam/ch/reader/view\\_abstract.aspx?flag=1&file\\_no=20170116&journal\\_id=jcsam](http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170116&journal_id=jcsam). DOI: 10.6041/j.issn.1000-1298.2017.01.016.
- LIU Shu, JIANG Qigang, MA Yue, et al. Object-oriented wetland classification based on hybrid feature selection method combining with Relief F, multi-objective genetic algorithm and random forest[J/OL]. *Transactions of the Chinese Society for Agricultural Machinery*, 2017, 48(1): 119-127. (in Chinese)
- 36 ALGANCI U, SERTEL E, OZDOGAN M, et al. Parcel-level identification of crop types using different classification algorithms and multi-resolution imagery in southeastern Turkey[J]. *Photogrammetric Engineering & Remote Sensing*, 2013, 79(11): 1053-1065.