



融合无人机 LiDAR 和高分辨率光学影像的点云分类方法

摘要

点云分类是激光点云数据处理的重要环节,探索自动、高效、高精度的点云分类方法具有重要意义。通过分析无人机获取的 LiDAR 点云与高分辨率光学影像的特点,提出了融合无人机 LiDAR 与高分辨率光学影像的点云分类方法。首先将 LiDAR 点云投影到二维平面并构建不规则三角网模型,然后寻找同名点对完成与光学影像的配准与融合,进而将光学影像的光谱信息赋予无人机 LiDAR 点云,接着从光学影像上提取光谱特征,从 LiDAR 点云上提取多尺度几何特征构建分类特征集,进一步通过 CFS 特征选择算法实现特征集的降维,最后运用随机森林分类算法实现点云分类。实验结果表明,本文分类方法的总体精度可达 89.5%, Kappa 系数为 0.844,与未经特征选择的分类结果相比精度提高了 1.1 个百分点,与单纯依靠 LiDAR 或者光学影像的分类相比,精度分别提高了 5.4 和 14.9 个百分点。本文方法不仅有效避免了基于点云属性内插构建新的图像融合方式带来的计算误差,同时解决了单尺度下构建几何特征时难以确定最优空间分析尺度的问题,并且对特征集进行优化选择从而有效提高了数据处理的效率。

关键词

高分辨率影像;LiDAR;配准融合;特征选择;点云分类

中图分类号 P237

文献标志码 A

收稿日期 2017-11-04

资助项目 国家自然科学基金(41571331);新疆兵团空间信息创新团队项目(2016AB001)

作者简介

高仁强,男,硕士,研究方向为 3S 综合应用.rqgao@pku.edu.cn

张显峰(通信作者),男,博士,教授,研究方向为生态与环境遥感.xfzhang@pku.edu.cn

1 北京大学 遥感与地理信息系统研究所,北京,100871

2 新疆兵团空间信息工程技术研究中心,石河子,832002

0 引言

机载 LiDAR 是一种主动式对地观测系统,能快速获取大范围高密度、高精度的地表三维空间信息,可提供地物的激光反射强度信息,已在城市三维建模、数字高程模型构建、林业调查、电力选线巡线等方面得到了广泛应用^[1-2],而点云分类则是这些应用的首要任务。点云分类方法可归纳为三种:一是针对特定的目标定义一套规则,然后基于规则进行目标点云的提取,如道路^[3-4]、建筑物^[5]、电力线^[6-7]等;二是通过机器学习方法进行监督分类,如土地覆盖^[8]、城市场景分类^[9]等;第三就是对前两种方法进行组合。首先基于目标识别与提取的方法减少分类目标数量,然后再进行监督分类,例如先对点云进行地形滤波再进行地物分类^[10-11]。LiDAR 数据虽然在描述地物的空间几何形态方面有着明显的优势,但由于点集离散,导致特征不明显,地物边界识别困难。因此,仅仅利用 LiDAR 数据实现自动精确的地物分类具有难度^[12];另一方面,光学影像数据虽然缺少高程信息,但可提供丰富的地物纹理和光谱信息。因此针对这两种数据源的优缺点,将两种数据源融合以弥补各自的缺陷从而实现高精度分类是点云分类的重要研究方向之一^[13]。

在融合影像与激光雷达点云进行点云分类中,不少学者采取先将点云数据内插生成 DSM,然后提取点或线特征与影像数据进行配准融合,再采用基于像元的图像处理方法进行分类^[14-17]。该方法无法克服点云内插所带来的误差影响,而且将点云的三维空间信息转为二维平面图像后提取的几何特征参数会有信息损失。此外,对于从遥感图像上提取的分类特征如果不进行优化,会造成特征的冗余甚至减弱特征集的分类能力。有学者在特征融合过程中,考虑了在三维空间上下文环境中构建几何特征参数,但仅限于单个空间分析尺度,而且对于空间分析尺度的选择主要依靠多次尝试的经验方法来确定^[18-19],缺乏通用性且自适应性较弱。有学者采用面向对象的分类思想将 LiDAR 点云和影像数据配准融合后进行多尺度分割,然后根据对象提取分类特征变量,这样可减少空间分析尺度的依赖,但图像分割的参数设置具有主观性,从而影响分类算法的性能和效果^[10,20-23]。

针对上述现有研究的不足,本文提出一种融合机载 LiDAR 点云与高分辨率光学影像数据的点云分类方法.该方法通过将影像的光谱信息融合到点云属性内,然后基于三维空间上下文提取多尺度的几何特征,基于影像光谱提取光谱特征,共同构建分类特征集,然后使用机器学习领域的 CFS (Correlation based Feature Selector) 特征选择算法对特征集进行优化,最后采用随机森林分类算法进行点云分类.本文方法可有效避免基于点云内插进行融合所带来的误差影响,并通过构建多尺度几何特征减少了对最佳空间分析尺度的依赖,最后通过特征选择进一步提高分类特征集的预测能力,实现提高计算效率的同时有效提高点云分类精度.

1 数据与方法

研究区域位于新疆石河子市与沙湾县的交界处大榆树村附近(85°53'47"E,44°24'47" N),如图 1 所示.实验区内地势总体上南高北低,地形坡度小于

20°,主要以农作物为主.数据获取时间为 2016 年 6 月 23 日.由于实验时间正好处于农作物生长茂盛时期,因此农作物的叶面积指数较高,在影像上非常容易识别.

1.1 数据获取与处理

1.1.1 LiDAR 数据

LiDAR 数据是利用瑞士生产的 Scout-B100 无人直升机搭载的激光扫描系统 Rigel VUX-1LR 获得的.该扫描系统在获取地物三维坐标信息的同时可获得激光反射强度、扫描角、回波次数等信息.为使激光点云数据具有较高的密度满足制图需要,实验中设置无人机飞行的高度为 30 m,飞行速度为 5 m/s,扫描频率为 550 kHz,扫描视场角为 110°.由于飞行姿态有偏差导致边缘点稀疏不齐,经扫描角过滤后得到有效范围大约为 10 000 m² 的 3 889 384 个激光点数据(图 2),点云密度为 300~600 pts/m²,数据获取当天晴朗无(少)云.激光扫描仪系统经校准后的测绘精度为 15 mm,满足本研究的需求.




图 1 实验区地理位置

Fig. 1 The geographic location of the study area




图 2 实验区获取的 LiDAR 点云数据

Fig. 2 The LiDAR point cloud data acquired in the study area

1.1.2 光学影像数据

光学影像数据是由与激光扫描系统同机搭载的 Sony A6000 数码相机获得,包含红、绿、蓝 3 个波段的灰度信息,单张影像大小为 4 000×6 000 像元,空间分辨率约为 7 mm.运用瑞士 Pix4D 公司生产的 Pix4D Mapper 软件对获得的所有影像数据进行拼接和正射校正得到实验区的正射影像数据.为提高数据处理效率,对研究区外的影像进行了裁剪(图略).根据地物的空间形态差异以及影像上所能清楚辨别的地物类型,本文将研究区内的地物类型分为道路、汽车、土壤、电力线、低矮植被(包括路边灌木和农作物)、高大植被 6 种.本文的技术路线如图 3 所示.

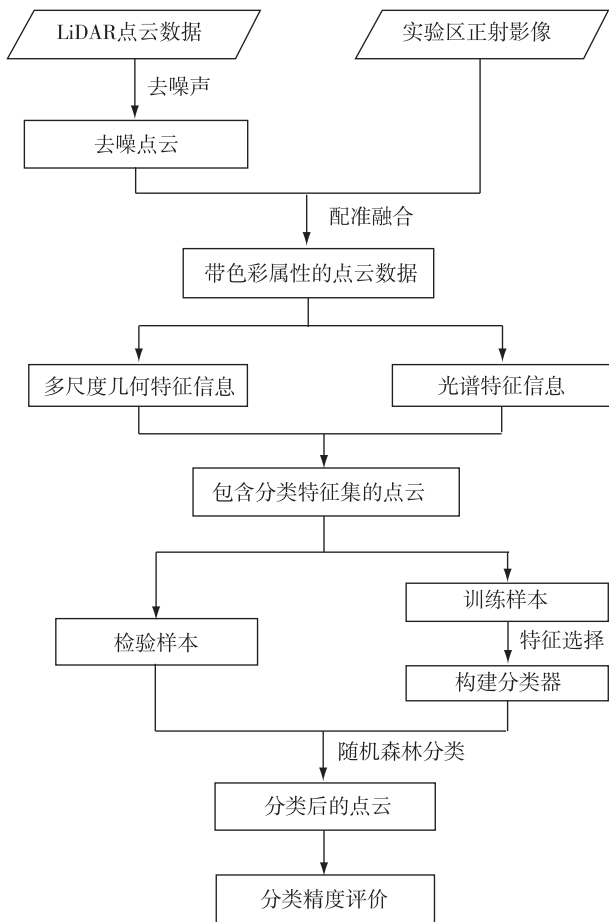


图3 本文的技术路线

Fig. 3 Flow chart of the proposed method

1.2 数据预处理与融合分析

1.2.1 LiDAR 点云预处理

LiDAR 点云数据存在许多由于激光脉冲的折射或者多路径效应所引起的噪声点数据,可直接交互式删除;另外,点云中也存在少量的高程粗差点,通过设置合适的搜索半径阈值 R ,逐个计算当前搜索

点的高程与该点所在半径 R 内的邻域点的高程平均值的差值,然后按照差值不超过 3σ 原则将粗差点进行识别并予以删除.

1.2.2 影像与点云数据的配准融合

由于 LiDAR 和光学影像数据是同机获取的,因此两数据源的外方位元素相同,并且两者的地理坐标系也一致,配准的实现相对容易.先将点云数据和影像投影到同一平面坐标系下,接着对点云数据插值生成不规则三角网(TIN),并依据同名点在点云数据和影像数据之间建立仿射变换关系,从而实现点云与影像数据的配准.点云和影像上提取的同名点对配准过程中涉及到的仿射变换模型^[23]为

$$\begin{bmatrix} X_c^i \\ Y_c^i \\ 1 \end{bmatrix} = \begin{bmatrix} a_1 & b_1 & c_1 \\ a_2 & b_2 & c_2 \\ 0 & 0 & 1 \end{bmatrix} \times \begin{bmatrix} X_1^i \\ Y_1^i \\ 1 \end{bmatrix}, \quad (1)$$

式中, (X_c^i, Y_c^i) 和 (X_1^i, Y_1^i) 分别代表点云和影像上的第 i 对同名点的 x, y 坐标, $a_1, b_1, c_1, a_2, b_2, c_2$ 分别是仿射变换系数,可通过选取 6 对以上的同名点对进行最小二乘求解得到.

经配准后,点云与影像的仿射变换关系就确定了,进而可将影像与点云进行融合.假设点云中的某一点 p 在投影平面上的坐标为 (x, y) ,则 p 点在影像上的像素坐标为

$$\begin{cases} p_{\text{row}} = \text{int}[(x - I_{x, \text{min}})/x_{\text{size}}], \\ p_{\text{col}} = \text{int}[(y - I_{y, \text{min}})/y_{\text{size}}], \end{cases} \quad (2)$$

式中 p_{row} 和 p_{col} 分别代表点 p 对应于影像像素坐标系下的行列号, $I_{x, \text{min}}$ 和 $I_{y, \text{min}}$ 分别表示影像的左下角所对应的投影坐标值, x_{size} 和 y_{size} 分别代表影像在横向和纵向的分辨率.得到该点在影像上的位置后,将影像上对应位置处的像素的 RGB 值赋给点 p ,由于点云的密度小于像素密度,因而不会出现多个像素的值赋给同一个点的现象.经过融合后,点云数据的属性由四维 (x, y, z, i) 增加到七维 (x, y, z, i, R, G, B) ,其中 i 是点云的激光反射强度信息.

1.3 分类特征集的构建

1.3.1 光谱特征提取

光学影像具有丰富的地物光谱信息,不同地物的特征光谱会有较大差异,因此原始的波段光谱反射信息可作为光谱特征.激光扫描仪发射的激光脉冲具有特定的波长信息,因此 LiDAR 数据中的激光反射强度也是一种光谱特征.除了光谱特征外,波段之间的组合与运算产生的新的特征变量也可作为反映地物差异的特征参数.

从可见光波段之间的标准差运算得到的图像可以看出(图4),道路的可见光光谱标准差值很小,土壤次之,而植被则较大.因此,本文将红绿蓝波段的标准差作为光谱类特征.NDVI(Normalized Difference Vegetation Index)是一种识别植被与非植被类型的光谱特征参数^[25].对于可见光波段,也有类似的波段指数,如红绿植被指数 GRVI(Green-Red Vegetation Index, I_{GRV})^[14]、归一化绿蓝植被指数 NGBDI(Normalized Green-Blue Difference Index, I_{NGBD})^[26],本文选取以下3种归一化差值类的光谱特征参数:

$$I_{GRV} = \frac{G - R}{G + R}, \quad I_{NGBD} = \frac{G - B}{G + B}, \quad I_{NRBD} = \frac{R - B}{R + B}, \quad (3)$$

式中 R, G, B 分别表示可见光影像的红绿蓝波段的灰度值.

1.3.2 几何特征提取

激光雷达点云数据包含了地物的三维几何信息,而地理空间中的点与邻域(或上下文)之间的空间相对位置关系能反映地物的几何特征差异.本文对搜索点的邻域定义如下:除搜索点外落在以搜索点为中心、半径为 R 的球体内部及边界的点.具体的几何特征参数包括三类:表面相关特征、高程相关特征、空间分布相关特征.

1) 表面相关特征

该类特征包括粗糙度(N),指搜索点到由邻域点所拟合的平面的距离,不同地物类型(如道路和土壤)的表面粗糙度存在较大差异.

2) 高程相关特征

该类特征包括高程差(Δh)以及高程标准差(δ).为了避免地形坡度带来的影响,在计算高程差的时候,本文采用的高程是用邻域内的点所拟合出的平面作为基准,然后取邻域内的点到该平面的最大距离与最小距离之差作为高程差.

3) 空间分布特征

主要包括各向异性指数(A_λ)、线性指数(L_λ)、平面性指数(P_λ)、球度性指数(S_λ)^[19].对包括搜索点在内的邻域点集的三维坐标进行主成分变换,得到对应的3个主成分系数 μ_1, μ_2, μ_3 ($\mu_1 \geq \mu_2 \geq \mu_3$),再对这3个主成分系数进行归一化:

$$\lambda_i = \mu_i / \sum_{i=1}^3 \mu_i, \quad (4)$$

式中, $\lambda_1, \lambda_2, \lambda_3$ 描述了搜索点所在的邻域点集服从一维、二维、三维空间分布的度量^[27].如果 $\lambda_1 \rightarrow 1$,则说明搜索点所在的邻域点在空间上呈现出线状分布特征(图5a);如果 λ_1 与 λ_2 的值可比拟且 $\lambda_1 + \lambda_2 \rightarrow$




图4 多光谱影像上提取的光谱特征图像

Fig. 4 Spectral features extracted from multispectral images




图5 三维空间中邻域点的空间分布特征

Fig. 5 Spatial distribution features extracted from the neighborhood points in 3D space,
(a) line distribution, (b) surface distribution, and (c) volume distribution

1, 则说明搜索点所在的邻域点在空间上呈现出面状分布特征(图 5b);如果 λ_1 与 λ_2, λ_3 的值均可比拟, 则说明搜索点所在的邻域点在空间上呈现体状分布特征(图 5c). 由此得到:

$$\begin{cases} A_\lambda = (\lambda_1 - \lambda_3) / \lambda_1, \\ P_\lambda = (\lambda_2 - \lambda_3) / \lambda_1, \\ S_\lambda = \lambda_3 / \lambda_1, \\ L_\lambda = (\lambda_1 - \lambda_2) / \lambda_1. \end{cases} \quad (5)$$

1.3.3 多尺度特征的表达

搜索半径 R 对应一个邻域空间, 该邻域空间决定了几何特征的分析范围, 因此搜索半径 R 也称为空间分析尺度. 通过不断调整空间分析尺度的大小, 分别计算对应分析尺度下的几何特征参数值, 可得到一个特征向量, 该向量就是描述当前搜索点与邻域点空间几何关系的一个多尺度几何特征向量. 本文根据地物对象的几何特征, 设定 9 个空间分析尺度, 搜索范围为 0.2~1.0 m, 步长为 0.1 m.

通过将提取的光谱特征与几何特征进行配准融合, 最终本研究使用的分类特征集包含 17 个特征, 表示为: $f_v = [R, G, B, I, d_{RGB}, I_{GRV}, I_{NCBD}, I_{NRBD}; N, \Delta h, \delta, \lambda_1, \lambda_2, A_\lambda, L_\lambda, P_\lambda, S_\lambda]^T$.

1.4 特征选择

特征选择的目的是从特征集中选择一个能够有效识别目标的最小特征子集^[28], 以降低特征空间的维数, 包括特征子集搜索和特征子集评价 2 个过程. 本文采用贪心搜索策略, 即初始的候选特征子集均为空, 然后逐步添加能使得当前候选特征子集的分类预测能力达到最大的特征变量, 逐步扩充候选特征

子集, 最后再从中选择类预测能力最大的候选特征子集作为最优特征子集. 特征子集评价则是采用 Hall^[29] 的 CFS 特征子集评价准则, 该特征评价准则的定义为

$$M_{\text{erit}} = \frac{k \bar{r}_{cf}}{\sqrt{k + k(k-1) \bar{r}_{ff}}}, \quad (6)$$

式中 M_{erit} 度量了包含 k 个特征变量的特征子集的分类预测能力, \bar{r}_{cf} 表示特征子集与类别属性之间的相关系数均值, \bar{r}_{ff} 则表示特征子集之间的相关系数均值. 该式的分子代表了特征子集的分类预测能力, 而分母则代表了特征子集的冗余程度. M_{erit} 的值越大, 则当前特征子集对分类的贡献程度也越大. 特征变量之间的相关性则是由 Pearson 相关系数来确定:

$$c_{\text{orr}}(X, Y) = \frac{\left| \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \right|}{\sqrt{\sum_{i=1}^m (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^m (Y_i - \bar{Y})^2}}, \quad (7)$$

式中 X 和 Y 是待分析变量, 可以同为特征变量, 也可分别为特征变量和类别变量, \bar{X} 和 \bar{Y} 表示所有样本在 X 和 Y 变量上的均值, n 是样本数.

1.5 随机森林分类

1.5.1 分类原理

随机森林是一种组合分类算法, 具有很好的抗噪声、泛化能力^[30-31], 其基本组成是分类回归树 (Classification And Regression Tree, CART). 具体的分类步骤为: 首先基于 Bagging 抽样技术从训练样本中有放回的随机选择 N 个样本数据、有放回的随机选择 M 个特征变量构建 bag, 并为每个 bag 构建一棵 CART, 由此产生 T 棵 CART 组成的森林. 一棵完整的

CART 树包括节点、分支和叶子结点三部分, 节点包括根节点和内节点. 分类回归树仅有一个根节点, 根节点存储的是抽样得到的训练样本数据, 从根节点开始按照最小不纯度原则选择特征变量进行分裂, 生成内节点. 本文使用的不纯度指标为基尼系数 G . 如果当前节点 p 的样本数据包含 m 个类别, 第 i 个类别的样本数比例为 p_i , 则该节点 p 的基尼系数值为

$$G(p) = 1 - \sum_{i=1}^m p_i^2. \quad (8)$$

选择能使分裂前后节点的基尼系数下降量达到最大的特征变量进行分裂. 假设当前选择的特征变量为 f , 分裂点为 k , 则该节点分裂前后的基尼系数下降量为

$$\Delta G(k) = G(p) - (1 - q) \times G(f < k) - q \times G(f > k), \quad (9)$$

式中, $G(f < k)$ 表示节点 p 的特征变量 f 小于 k 的样本数据的基尼系数, q 表示节点 p 的特征变量 f 小于 k 的样本个数所占比例, 而 $G(f > k)$ 则表示节点 p 的特征变量 f 大于 k 的样本数据的基尼系数. 选择使得 ΔG 取最大且大于 0 的 k 值作为分裂点, 从而实现子节点的生成, 如此递归的执行特征变量的选择和节点的分裂, 最终达到树的最大分解深度, 从而得到一系列具有相同类别属性的叶子结点. 在分类阶段, 每棵 CART 都对待分类样本进行一次投票, 最后将得票数最多的类别属性赋给待分样本, 从而实现随机森林分类. 随机森林的分类效果取决于两个因素: CART 之间的相关性和每棵 CART 自身的分类能力. CART 之间的相关性越高, 分类误差率就越大; CART 自身的分类能力越强, 分类误差就越小^[30].

1.5.2 特征变量的贡献度

随机森林算法除了可用来分类外, 也可对特征变量的重要性进行评价. 基于 Bagging 抽样技术选择一部分作为训练样本的同时, 剩下的样本就作为测试数据用于计算当前训练样本下的随机森林模型分类精度, 通过比较某个特征变量剔除前后随机森林分类精度的下降量, 就可以对特征的分类贡献度进行评价. 如果失去某个特征变量后, 分类精度的下降量越大, 则说明该特征变量越重要.

1.6 计算优化策略

LiDAR 数据的点数量一般达到百万量级, 这种数据量对于计算机的计算性能提出了较高要求. 为提高计算机的处理效率, 本文对训练样本和待分类样本均进行了抽稀处理, 但为确保在较小分析尺度

下不因采样导致空间点间距过大使得邻域点数量过低, 在确定样本点(包括训练样本点和待分类样本点)的邻域点时是以整个去噪后的点云为背景进行搜索得到的. 抽稀点云分类完成后, 基于空间最近邻插值的原理对去噪后点云中的每个未知类别点搜寻与之距离最近的抽稀点云样本点, 并将类别属性赋予该未知点, 从而完成点云分类.

1.7 精度评价方法

结合高分辨率光学影像信息对待分类点云样本进行人工分类并作为参考数据, 然后运用本文的 4 种分类策略逐一进行自动分类. 采用类似于遥感影像的分类评价方法评价点云的分类效果, 即评用总体精度(Overall Accuracy, OA)和 Kappa 系数 2 个指标对不同分类策略的分类结果进行比较:

$$A_0 = \frac{\sum_{i=1}^n n_{ii}}{N} \times 100\%, \quad (10)$$

$$K_{\text{appa}} = \frac{N \sum_{i=1}^n n_{ii} - \sum_{i=1}^n n_i \cdot n_i}{N \times N - \sum_{i=1}^n n_i \cdot n_i}, \quad (11)$$

式(10)、式(11)中 N 是样本总数, n_{ii} 代表模型的预测结果与参考分类结果均为第 i 类的样本数量, n_i 表示参考分类结果为第 i 类的样本总数, n_i 则代表模型预测结果为第 i 类的样本总数. OA 的值越高, 表明正确分类的样本数所占的比例越大, 整体分类效果也就越好; Kappa 系数则是表征实际分类结果与预测分类结果的一致性大小, 其值越高, 分类的一致性越好.

2 实验结果与分析

2.1 CFS 特征选择结果

图 6 表达的是特征子集大小与 CFS 评价指标 M_{ent} 之间的变化关系. 结果表明, 随着特征子集大小的增加, M_{ent} 值会呈现出先增加后减小的趋势. 这是因为, 最初的特征子集添加的是具有较强类别预测能力的特征, 从而使得特征子集的预测能力逐渐增加, 当最具分类预测能力的特征添加完全后, 特征子集的预测能力也就达到最大化, 此时再继续增加特征变量则会由于特征子集内部的冗余度增大而导致特征子集的预测能力降低.

表 1 是经过特征选择以后所保留的特征变量, 包含 7 个光谱特征和 33 个几何特征. 在优化的特征




图 6 特征子集大小与分类预测能力关系

Fig. 6 Relationship between predictive ability and feature set size

集中,红绿蓝波段的标准差被剔除;几何特征中的 λ_2 被剔除,可能是该特征与其他特征之间的相关性较高,因为 λ_2 表征当前点与邻域内的点服从空间二维分布的程度,而 P_λ 本身也具有该含义.经过特征变量选择后,分类特征减小了近一半,有效减少了后续分类所需要处理的数据量.

表 1 分类特征集的构成

Table 1 Component of the classification feature set

特征类型	特征参数	分析尺度/m
光谱特征	Intensity	
	Red	
	Green	
	Blue	
	GRVI	
	NGBDI	
	NRBDI	
几何特征	N	0.4, 1.0
	λ_1	0.9
	Δh	0.3, 0.7, 0.8, 0.9, 1.0
	δ	0.2, 0.3, 0.9, 1.0
	A_λ	0.2, 0.4, 0.9, 1.0
	S_λ	0.2, 0.4, 0.5, 0.7, 0.8, 0.9, 1.0
	P_λ	0.8, 1.0
	L_λ	0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0

2.2 点云分类结果

经过特征选择处理后,采用 Hall 等^[32]提出的随机森林算法软件对训练样本构建随机森林分类器.实验中设置 N 值为训练样本总数的80%, M 值为特征总数的平方根,分类回归树的棵数为200.图7是结合不同的分类策略对待分样本分类的结果,其中

图7a是本文方法的分类结果,图7e是参考分类结果.总体上看本文的分类效果较为满意.与其他分类策略相比,本文的分类方法产生的噪声点非常少(图7a、图7d),路上的汽车错分现象相对较轻(图7a、图7c),对道路、电力线、土壤和低矮植被的辨识力也很高,不足之处在于地物类型混合区域(尤其是低矮植被和高大植被之间)容易产生混淆,一方面激光点打在高大植被的冠层表面时,有部分点会穿过空隙或者从叶子边缘打到地面或土壤上,增加分类的不确定性,二是低矮植被和高大植被之间的几何形态存在相似性,比如叶子的平面性,会给分类带来挑战.另外地物类型的混合会导致几何特征的差异降低,影响分类结果.

2.3 精度评价与对比

表2是上述4种不同策略的分类结果所对应的分类混淆矩阵.从表2中可以得知,融合LiDAR和光学影像数据并经过特征选择后的分类精度比未经过特征选择直接得到的分类精度提高1.1个百分点,比单独使用LiDAR数据的分类精度提高5.4个百分点,比单独使用光学影像数据的分类精度提高14.9个百分点,而对应的Kappa系数则分别提高0.01、0.078和0.214.相比于未经过特征选择而言,特征选择后能有效提高汽车、电力线、土壤、低矮植被三类的用户精度,以及电力线、土壤和高大植被三类的产品精度;相比于只使用LiDAR数据而言,除电力线的产品精度和高大植被的用户精度稍不如外,其他方面都得到了极大的提高;相比于只使用光学影像而言,除道路的产品精度和汽车的用户精度稍不如外,其他方面都有大幅度的提高.

3 问题与讨论

3.1 空间分析尺度对分类结果的影响

为了定量比较空间分析尺度对分类结果的影响程度,考虑到特征选择后分析尺度的不连续性问题,本研究以融合光学影像和LiDAR数据并将所有特征变量均参与分类的分类策略为基础,分别在单尺度和多尺度下构建几何特征参数.实验过程中保持特征变量除了尺度其他条件均不变,并分别对训练样本和待分样本进行实验,对训练样本的精度评价则是通过将训练样本按照70%的分割比例将其的70%作为训练集,余下的部分作为检验样本以此评估训练样本的分类精度,最后的实验结果如表3所示.




图7 不同分类策略下的分类结果对比

Fig.7 Classification maps derived from different classification strategies,(a) fusing LiDAR and optical image with feature selection;(b) fusing LiDAR and optical image without feature selection;(c) only LiDAR used with feature selection;(d) only optical image used with feature selection;(e) reference classification

表2 不同组合策略下的分类精度评价对比

Table 2 Classification accuracy of different classification strategies

%

	LiDAR+image+fs		LiDAR+image+all		LiDAR+fs		image+fs	
	生产者精度	用户精度	生产者精度	用户精度	生产者精度	用户精度	生产者精度	用户精度
道路	84.4	97.6	86.2	97.8	82.4	98.1	85.4	88.8
汽车	97.8	73.6	98.2	46.0	95.7	25.5	96.1	86.9
电力线	98.2	73.9	97.8	71.8	98.7	71.9	60.8	29.8
土壤	91.3	88.7	87.0	88.6	80.9	88.2	63.6	78.1
低矮植被	93.4	91.9	94.2	90.8	93.4	90.5	82.6	80.9
高大植被	63.2	73.3	50.9	80.4	38.3	79.1	48.4	31.2
OA/%	89.5		88.4		84.1		74.6	
Kappa	0.844		0.834		0.766		0.630	

注:LiDAR+image+fs:融合LiDAR和光学影像并经过特征选择后的分类策略;LiDAR+image+all:融合LiDAR和光学影像并使用全部特征的分类策略;LiDAR+fs:仅使用LiDAR数据并经过特征选择后的分类策略;image+fs:仅使用光学影像数据并经过特征选择后的分类策略。

表3的结果表明,随着空间分析尺度的增大,训练样本和测试样本的分类总体精度都在提高,但如果将多个尺度进行组合,点云分类的总体精度就可得到进一步提高,其中训练样本的总体精度提高了0.8~4.8个百分点,待分样本的总体精度提高了0.4~5.4个百分点.这就说明多尺度特征相比于单

尺度而言,具有更好地表达地物空间形态差异的能力,这不仅是因为特征数量的增加而使得分类特征集的代表性提高,更重要的是多尺度特征能克服地物的空间异质性在单尺度下表现不明显的缺陷^[26],比如低矮植被和高大植被。

表 3 单尺度与多尺度特征下的分类精度比较

Table 3 Comparison of classification accuracy
between one-scale and multi-scale features

尺度/m	训练样本		测试样本	
	OA/%	Kappa	OA/%	Kappa
0.2	94.8	0.938	83.0	0.760
0.3	94.5	0.935	83.1	0.757
0.4	95.0	0.941	83.5	0.764
0.5	96.1	0.953	83.9	0.768
0.6	97.1	0.965	84.7	0.779
0.7	97.4	0.969	86.3	0.803
0.8	97.8	0.974	87.5	0.819
0.9	98.0	0.975	87.7	0.824
1.0	98.5	0.982	88.0	0.816
0.2~1.0	99.3	0.987	88.4	0.834

3.2 特征变量的贡献度比较

为定量分析在本文的分类方法下各个特征变量对点云分类结果的贡献程度,实验中只考虑经过特征选择后所留下的那部分特征变量,因此波段标准差和 λ_1 将被排除在外,并且为了减少不同类别之间因样本数的差异(如汽车和土壤)而带来的精度评价不合理问题,本研究采取了类别均衡处理措施,即对训练样本中的各类样本赋予不同的权重,使得各个类别的样本计数相当(每个类别的权重=实际样本数/总样本数).然后在构建随机森林模型时,选择其中 70% 的样本作为训练集,其余的 30% 作为测试集用于计算分类总体精度.通过不断地调整特征变量的组合方式并依次计算各个特征变量剔除前后总体分类精度的下降量,最后以总体精度下降量为纵坐标,处理的特征变量为横坐标(GR、GB、RB 分别表示 GRVI、NGBDI 和 NRBDI),得到图 8 所示的贡献度分布.

图 8 结果表明,高程标准差(δ)、平面高程差(Δh)及绿红植被指数(GRVI)对于点云分类的贡献程度最大,其他特征的贡献程度相对比较小,但这并不意味着其他特征就完全没意义,因为这些特征的缺少都会造成最后的分类总体精度下降.同时也说明实验区内的地物类型的几何特征差异主要集中在高程标准差和平面高程差上,而光谱特征差异则主要体现在 GRVI 指数上.

4 结论

本文提出了一种新的点云分类方法,通过从光学影像提取的光谱特征与点云数据中提取的多尺度




图 8 不同特征变量对分类的贡献度比较

Fig. 8 Contribution of different features to classification

几何特征进行配准融合,基于 CFS 特征选择算法对融合后的特征集进行优化选择从而构建激光点云的分类特征集,最后采用随机森林分类算法对点云进行分类.精度评价的结果表明,本文提出的方法的总体精度可达 89.5%,相比于其他的分类而言,提高了 1.1~14.9 个百分点,说明本研究中融合 LiDAR 和光学影像数据的点云分类精度比单纯基于激光点云数据的分类精度有较大提高.

此外,由于地物的空间异质性的存在,依靠单个尺度对地物的几何形态加以描述往往不全面,且也很难将地物的几何特征差异完全突显出来,其分类的鲁棒性也会较差,本文通过构建多尺度的几何特征减少了分类的误判.在实际应用中,最佳的空间分析尺度确定会因研究区域、数据源的空间分辨率以及地物类型的不同而不同,因此凭借经验知识和反复尝试的策略对于自动化分类而言并不可取,而构建多尺度的几何特征则能很好地解决此问题.

CFS 特征选择算法不仅将原始特征集由 89 下降为 40,减少模型的训练时间,最终使分类精度提高,说明特征集的预测能力取决于两个因素:特征本身的预测能力和特征之间的相关性.寻找预测能力强的特征并且使得特征子集之间的相关性最低,则特征集的预测能力也会得到提高.本研究表明:高程标准差和平面高程差是区分地物类型差异比较关键的几何特征,而 GRVI 指数则是区分地物类型差异比较关键的光谱特征.

本文的分类场景不是非常复杂,涉及的地物类型只有 6 类,且实验区内的道路数量较少,没有建筑物等人工地物,为了扩大方法的实用性,后续将针对

更为复杂的城市场景进行分类研究.此外,在数据源配准融合的过程中,本文主要采用交互式的方法选择同名点对,虽然能取得很好的效果,但是不够智能化,后续将会探索相关的自动寻找同名点对的方法,进一步提高分类方法的智能化水平.

参考文献

References

- [1] 郭波,黄先锋,张帆,等.顾及空间上下文关系的 Joint-Boost 点云分类及特征降维[J].测绘学报,2013(5):715-721
GUO Bo, HUANG Xianfeng, ZHANG Fan, et al. Points cloud classification using joint boost combined with contextual information for feature reduction [J]. Acta Geodaetica et Cartographica Sinica, 2013, 42(5):715-721
- [2] 徐宏根,王建超,郑雄伟,等.面向对象的植被与建筑物重叠区域的点云分类方法[J].国土资源遥感,2012,24(2):23-27
XU Honggen, WANG Jianchao, ZHENG Xiongwei, et al. Object-based point clouds classification of the vegetation and building overlapped area [J]. Remote Sensing for Land & Resources, 2012, 24(2):23-27
- [3] Díaz-Vilariño L, González-Jorge H, Bueno M, et al. Automatic classification of urban pavements using mobile LiDAR data and roughness descriptors [J]. Construction and Building Materials, 2016, 102:208-215
- [4] Karila K, Matikainen L, Puttonen E, et al. Feasibility of multispectral airborne laser scanning data for road mapping[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(3):294-298
- [5] Pahlavani P, Amirkolaee H A, Bigdeli B. 3D reconstruction of buildings from LiDAR data considering various types of roof structures [J]. International Journal of Remote Sensing, 2017, 38(5):1451-1482
- [6] 陈驰,麦晓明,宋爽,等.机载激光点云数据中电力线自动提取方法[J].武汉大学学报(信息科学版),2015,40(12):1600-1605
CHEN Chi, MAI Xiaoming, SONG Shuang, et al. Automatic power lines extraction method from airborne LiDAR point cloud [J]. Geomatics and Information Science of Wuhan University, 2015, 40(12):1600-1605
- [7] 余洁,穆超,冯延明,等.机载 LiDAR 点云数据中电力线的提取方法研究[J].武汉大学学报(信息科学版),2011,36(11):1275-1279
YU Jie, MU Chao, FENG Yanming, et al. Powerlines extraction techniques from airborne LiDAR data [J]. Geomatics and Information Science of Wuhan University, 2011, 36(11):1275-1279
- [8] Antonarakis A S, Richards K S, Brasington J. Object-based land cover classification using airborne LiDAR [J]. Remote Sensing of Environment, 2008, 112(6):2988-2998
- [9] Niemeyer J, Wegner J D, Mallet C, et al. Conditional random fields for urban scene classification with full waveform LiDAR data [C] // ISPRS Conference on Photogrammetric Image Analysis 2011:233-244
- [10] Wu M F, Sun Z C, Yang B, et al. A hierarchical object-oriented urban land cover classification using WorldView-2 imagery and airborne LiDAR data [J]. IOP Conference Series: Earth and Environmental Science, 2016, 46(1):012016
- [11] 程晓光,黄先锋,张帆.机载 LiDAR 数据的城区树木点提取方法[J].测绘科学,2014,39(3):52-56
CHENG Xiaoguang, HUANG Xianfeng, ZHANG Fan. A spatial distribution pattern-based urban tree points extraction method in airborne LiDAR [J]. Science of Surveying and Mapping, 2014, 39(3):52-56
- [12] 程效军,程小龙,胡敏捷,等.融合航空影像和 LiDAR 点云的建筑物探测及轮廓提取[J].中国激光,2016,43(5):247-255
CHENG Xiaojun, CHENG Xiaolong, HU Minjie, et al. Buildings detection and contour extraction by the fusion of aerial images and LiDAR point cloud [J]. Chinese Journal of Lasers, 2016, 43(5):247-255
- [13] Zhang J X, Lin X G. Advances in fusion of optical imagery and LiDAR point cloud applied to photogrammetry and remote sensing [J]. International Journal of Image and Data Fusion, 2017, 8(1):1-31
- [14] Rastiveis H. Decision level fusion of LiDAR data and aerial color imagery based on Bayesian theory for urban area classification [J]. International Archives of the Photogrammetry Remote Sensing & Spatial Information Sciences, 2015, XL-1/W5:589-594
- [15] Guo L, Chehata N, Mallet C, et al. Relevance of airborne LiDAR and multispectral image data for urban scene classification using random forests [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2011, 66(1):56-66
- [16] Mumtaz S A, Mooney K. Fusion of high resolution LiDAR and aerial images for object extraction [C] // International Conference on Advances in Space Technologies, 2008:137-142
- [17] Salah M, Trinder J, Shaker A. Evaluation of the self-organizing map classifier for building detection from Lidar data and multispectral aerial images [J]. Journal of Spatial Science, 2009, 54(2):15-34
- [18] Dechesne C, Mallet C, Bris A L, et al. Forest stand segmentation using airborne lidar data and very high resolution multispectral imagery [J]. International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences, 2016, XLI-B3:207-214
- [19] Vo A V, Truong-Hong L, Lafer D F. Aerial laser scanning and imagery data fusion for road detection in city scale [C] // IEEE International Symposium on Geoscience and Remote Sensing, 2015:4177-4180
- [20] Kang Z Z, Yang J T, Zhong R F. A Bayesian-network-based classification method integrating airborne LiDAR data with optical images [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(4):1651-1661
- [21] Chen Y H, Su W, Li J, et al. Hierarchical object oriented classification using very high resolution imagery and LiDAR data over urban areas [J]. Advances in Space Re-

- search, 2009, 43(7):1101-1110
- [22] Ke Y, Quackenbush L J, Im J. Synergistic use of quick bird multispectral imagery and LIDAR data for object-based forest species classification [J]. *Remote Sensing of Environment*, 2010, 114(6):1141-1154
- [23] Li S H, Li Z Y, Wang H S, et al. Urban land cover classification using aerial LiDAR and CCD images [C] // *IEEE Geoscience and Remote Sensing Symposium*, 2014: 1967-1970
- [24] 杨晓峰. 基于仿射变换模型的图像目标定位跟踪方法 [D]. 武汉: 华中科技大学, 2005
YANG Xiaofeng. Image target location and tracking based on affine transform model [D]. Wuhan: Huazhong University of Science and Technology, 2005
- [25] Verbesselt J, Hyndman R, Newnham G, et al. Detecting trend and seasonal changes in satellite image time series [J]. *Remote Sensing of Environment*, 2010, 114(1):106-115
- [26] 汪小钦, 王苗苗, 王绍强, 等. 基于可见光波段无人机遥感的植被信息提取 [J]. *农业工程学报*, 2015, 31(5):152-159
WANG Xiaoqin, WANG Miaomiao, WANG Shaoqiang, et al. Extraction of vegetation information from visible unmanned aerial vehicle images [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2015, 31(5):152-159
- [27] Brodu N, Lague D. 3D terrestrial LiDAR data classification of complex natural scenes using a multi-scale dimensionality criterion: Applications in geomorphology [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2012, 68:121-134
- [28] 姚旭, 王晓丹, 张玉玺, 等. 特征选择方法综述 [J]. *控制与决策*, 2012, 27(2):161-166
YAO Xu, WANG Xiaodan, ZHANG Yuxi, et al. Summary of feature selection algorithms [J]. *Control and Decision*, 2012, 27(2):161-166
- [29] Hall M A. Correlation-based feature subset selection for machine learning [D]. Hamilton, New Zealand: University of Waikato, 1998
- [30] Breiman L. Random forests [J]. *Machine Learning*, 2001, 45(1):5-32
- [31] Guo L, Chehata N, Mallet C, et al. Relevance of airborne lidar and multispectral image data for urban scene classification using random forests [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2011, 66(1):56-66
- [32] Hall M, Frank E, Holmes G, et al. The WEKA data mining software: An update [J]. *ACM SIGKDD Explorations Newsletter*, 2009, 11(1):10-18

Fusion of high-resolution optical image and unmanned aerial vehicle LiDAR for 3D point cloud classification

GAO Renqiang¹ ZHANG Xianfeng^{1,2} SUN Min^{1,2} ZHAO Qingzhan²

¹ Institute of Remote Sensing and Geographic Information System, Peking University, Beijing 100871

² Geospatial Information Engineering & Technology Research Center, Xinjiang Construction and Production Corps, Shihezi 832002

Abstract Point cloud classification is a critical step in the processing of LiDAR data, and exploring new automatic, efficient, high accuracy classification method is of great importance. This paper proposed a new method for point cloud classification by analyzing the feature of optical image and LiDAR data from the same aircraft. First, a TIN model was made by interpolating the LiDAR data which was projection transformed, then the registration fusion of LiDAR and optical image was achieved according to the correspondence vertexes of the two data, and the RGB attribution information from optical image was combined into LiDAR data later. Second, classification feature set was built by extracting the spectral features from optical image and multi-scale geometric features from LiDAR data. Third, a CFS feature selection method was used to reduce dimension of the classification set. Finally, a supervised classification was conducted using a random forest algorithm to classify the point cloud. Results indicate that, the overall accuracy and Kappa coefficient of the proposed method is 89.5% and 0.844, respectively. And the proposed method get an improvement in the overall accuracy by 1.1, 5.4 and 14.9 percentage point when compared with no feature selection strategy, only using LiDAR data and only using optical image, respectively. The proposed method not only efficiently reduce the interpolation error when fusion based on point cloud interpolation, but also solve the problem for choosing the optimal scale to extract geometry feature in a certain analytical scale, and the data are able to be processed more efficiently when feature selection is adopted.

Key words high resolution image; LiDAR; registration fusion; feature selection; point cloud classification