

文章编号 1004-924X(2016)01-0210-10

基于信息向量机的机载激光雷达点云数据分类

刘志青*, 李鹏程, 陈小卫, 张保明, 郭海涛
(信息工程大学, 河南 郑州 450052)

摘要:针对支持向量机应用于机载激光雷达(LiDAR)点云数据分类时存在的模型稀疏性弱、预测结果缺乏概率意义、训练时间长等缺点,提出一种基于信息向量机的 LiDAR 点云数据分类算法。该算法采取假定密度滤波算法进行近似逼近,将分类问题转化为回归问题;以最大后验微分熵为依据,选择 LiDAR 点云数据活动子集信息向量实现模型稀疏化;最后,通过边缘似然最大化进行核函数自适应获取,选择一对余分类方法实现了点云数据多类分类。利用 Niagara 地区和非洲某地区点云数据进行了对比实验。结果表明:与支持向量机方法相比,基于信息向量机分类方法的分类精度分别提高到 94.20%和 90.78%,基向量数量分别减少到 50 个和 90 个,训练时间分别降低到 5.86 s 和 8.03 s。实验结果验证了基于信息向量机的点云数据分类算法具有训练速度快、模型稀疏性强、分类精度高等优点。

关键词:激光雷达测距(LiDAR);点云;数据分类;高斯过程;信息向量机

中图分类号:TP751.1;TN958.98 **文献标识码:**A **doi:**10.3788/OPE.20162401.0210

Classification of airborne LiDAR point cloud data based on information vector machine

LIU Zhi-qing*, LI Peng-cheng, CHEN Xiao-wei, ZHANG Bao-ming, GUO Hai-tao

(Information Engineering University, Zhengzhou 450052, China)

* Corresponding author, E-mail: lqc1987212@163.com

Abstract: When Support Vector Machines (SVMs) are applied in airborne LiDAR point data classification, their performance is limited by weak model sparseness, the prediction lack of probabilistic sense, and long training time. Therefore, a novel LiDAR point cloud data classification method was proposed based on an Informative Vector Machine (IVM). Firstly, the assumed density filtering was utilized to produce an approximation for probit classification noise model, and the classification problem was transformed into the regression problem. Then, the informative vectors of the active set in LiDAR point cloud data were chosen to achieve the model sparseness according to the largest posteriori differential entropy. Finally, in the training process, the kernel parameter was obtained by Marginal Likelihood Maximisation (MLM) and an One Against Rest (OAR) classifier was selected to realize multi-class classification. The LiDAR point cloud data from Niagara and Africa were selected for experiments in comparison with the SVM, and experimental results show that the classification accuracy of the method based on IVM increases to 94.20% and 90.78% respectively, the number of basis vectors reduce to 50 and 90 separately, and the training time decreases to 5.86 s and

收稿日期:2015-09-25;修订日期:2015-11-30.

基金项目:国家自然科学基金资助项目(No.41371436)

8.03 s respectively. In conclusion, the classification method based on IVM has advantages in fast training speeds, strong model sparseness and high classification accuracy.

Key words: Light Detection and Ranging(LiDAR); point cloud; data classification; Gaussian process; Informative Vector Machine (IVM)

1 引言

激光雷达测量(Light Detection and Ranging, LiDAR)是一种将激光测距、动态 GPS 差分以及惯性导航姿态测定高度集成的技术^[1]。与传统的摄影测量方式不同, LiDAR 的数据采集方式为主动测量, 其对天气、季节以及时段的要求较小, 另外, 激光脉冲穿透能力强, 可以快速获取地物三维结构信息^[2]。机载 LiDAR 点云数据信息提取与三维建模的关键步骤是机载 LiDAR 点云数据分类。分类后的地面点集将为后续滤波处理提供先验信息, 并生成数字高程模型(Digital Elevation Model, DEM), 可应用于地貌分析、工程设计、环境规划等相关研究中; 分类为建筑物的点集可作为城市三维建模、城市规划设计的基础; 分类为植被的点集将为城市绿地分析、森林火警预警等研究提供良好的工作思路。因此, 设计快速、准确、稳健的机载 LiDAR 点云分类算法具有重要的理论意义和经济价值。

由于地形复杂、地物多样性等原因, 机载 LiDAR 点云数据分类方法的精度、效率仍面临着较大的挑战。近 10 年来, 以点云数据分类精细程度为依据可将相关分类研究概略分为三个阶段: 第一阶段以两元分类研究为主, 即点云数据滤波处理^[3-4]; 第二阶段是针对特定目标地物提取的分类研究, 例如对建筑物或植被区域的提取^[5-6]; 第三阶段是将点云数据分为裸地、建筑物、植被等多个种类, 即多元分类研究^[7-8]。其中多元分类在未来一段时期仍为点云数据分类的研究热点和难点。

目前, 以支持向量机(Support Vector Machine, SVM)为代表的核方法在 LiDAR 点云分类研究中应用广泛, 取得了较好效果^[7-8]。SVM 具有良好的泛化能力, 能够避免过学习现象, 但它自身却存在着许多不足, 主要表现在: ①解的稀疏性有限, 随着训练样本规模的增大, 支持向量数量呈线性增长; ②预测结果缺乏必要的概率信息, 不具有统计意义; ③需要对核函数参数和

规则化系数(折中系数 C)进行估计, 采用交叉验证方法确定参数过程复杂, 计算量大, 训练时间长。高斯过程与 SVM 相似, 也是应用较为广泛的核方法^[9]。但与 SVM 相比, 高斯过程具有自动相关决策功能, 其核函数可以通过自适应学习获取, 并且可以得到具有统计意义的预测结果, 但当样本数据较大时, 利用高斯过程进行处理时会出现计算复杂、占用内存多及稀疏性弱等问题。信息向量机(Informative Vector Machine, IVM)是 Lawrence 在贝叶斯统计学习理论的基础上提出的一种稀疏高斯过程的机器学习技术^[10]。IVM 以信息原理中的贪婪选择准则为依据选择训练样本, 使得计算效率大幅度提高, 并释放了部分内存空间, 从而实现了模型稀疏化目的。目前, IVM 已逐步应用于数字识别^[10]、神经活动分类^[11]、人脸识别^[12]和高光谱图像分类^[13]等领域。

本文提出一种基于信息向量机的机载 LiDAR 点云数据分类算法。该算法以假定密度滤波算法(Assume Density Filtering, ADF)为依据将概率噪声模型逼近为高斯模型; 以信息原理中的贪婪选择为准则, 利用最大化后验微分熵选择点云数据训练样本活动子集数据, 从而实现模型稀疏化; 通过边缘似然最大化(Marginal Likelihood Maximisation, MLM)方法进行核函数参数自适应学习, 选择两类 IVM 分类器组合实现点云数据多类分类研究。通过 Niagara 地区及非洲某地区的 LiDAR 点云数据进行实验, 验证了基于 IVM 的点云分类方法的优势。

2 高斯过程

2.1 高斯过程模型

高斯过程又称为正态随机过程, 可以将其定义为—组随机变量的集合, 此集合中的任意有限个随机变量均服从联合高斯分布, 即高斯过程是把多元高斯分布推广到无限多个随机变量的形式, 高斯过程任意时刻的随机变量概率分布均满足高斯分布。同样, 高斯过程由两个参数确定, 即

均值函数和协方差函数。

设输入集合为 $\mathbf{x}=(x_1, x_2, \dots, x_N)$, 此随机变量对应的随机过程按照函数形式可表示为 $f(\mathbf{x})$, 若 \mathbf{x} 中任意有限个随机变量的联合分布满足高斯分布, 则高斯过程可以通过随机过程 $f(\mathbf{x})$ 的均值函数 $m(\mathbf{x})$ 和协方差函数 $k(\mathbf{x}, \mathbf{x}')$ 确定, 如下所示:

$$f(\mathbf{x}) \sim gp(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}')), \quad (1)$$

其中: $m(\mathbf{x}) = E(f(\mathbf{x}))$, 核函数 $k(\mathbf{x}, \mathbf{x}') = \text{cov}[f(\mathbf{x}), f(\mathbf{x}')]]$ 。

对于独立同分布的点云数据样本集 $D = \{\mathbf{x}_n, \mathbf{y}_n\}_{n=1}^N$, $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T$ 为输入数据, 即激光脚点样本数据的特征向量, $\mathbf{y} = [y_1, y_2, \dots, y_N]^T$ 代表输出观察值即激光脚点的类别标记, $\mathbf{f} = [f_1(\mathbf{x}_1), f_2(\mathbf{x}_2), \dots, f_N(\mathbf{x}_N)]^T$ 为隐变量函数集。按照高斯过程定义, 通常取均值函数 $m(\mathbf{x}) = 0$, 隐变量集 \mathbf{f} 的先验分布如下所示:

$$p(\mathbf{f} | \mathbf{X}, \boldsymbol{\theta}) = N(\mathbf{f} | 0, \mathbf{K}), \quad (2)$$

式中: \mathbf{K} 为协方差函数或核函数, $\boldsymbol{\theta}$ 为 \mathbf{K} 的参数。

高斯过程模型主要包括 4 个步骤: 定义边缘似然函数 $p(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta})$; 计算后验分布 $p(\mathbf{f} | \mathbf{y}, \mathbf{X}, \boldsymbol{\theta})$; 进行核参数 $\boldsymbol{\theta}$ 学习; 预测 $f(\mathbf{x})$ 在 \mathbf{x} 处的函数值。

2.1.1 定义边缘似然函数

以贝叶斯公式为根据, 隐变量集 \mathbf{f} 和输出观测值 \mathbf{y} 的联合分布如式(3)所示:

$$p(\mathbf{y}, \mathbf{f} | \mathbf{X}, \boldsymbol{\theta}) = p(\mathbf{f} | \mathbf{X}, \boldsymbol{\theta}) p(\mathbf{y} | \mathbf{f}) = p(\mathbf{f} | \mathbf{X}, \boldsymbol{\theta}) \prod_{n=1}^N p(y_n | f_n), \quad (3)$$

式中: $p(y_n | f_n)$ 被称为噪声模型, 它表明了隐变量 \mathbf{f} 和输出观测值 \mathbf{y} 之间的联系。在高斯回归模型中, 噪声模型服从高斯分布。

对式(3)中 \mathbf{f} 进行积分可得边缘似然函数的计算公式:

$$p(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta}) = \int N(\mathbf{f} | \mathbf{0}, \mathbf{K}) \prod_{n=1}^N N(y_n | f_n, \sigma_n^2) d\mathbf{f} = N(\mathbf{y} | \mathbf{0}, \mathbf{K} + \mathbf{B}^{-1}), \quad (4)$$

式中: \mathbf{B} 为对角矩阵, 它的第 n 个对角元素为 β_n , β_n 的值为 $1/\sigma_n^2$ 。

2.1.2 计算后验分布

以贝叶斯公式和多元高斯分布为依据, 联合式(3)和式(4)可得 \mathbf{f} 的后验分布 $p(\mathbf{f} | \mathbf{y}, \mathbf{X}, \boldsymbol{\theta})$:

$$p(\mathbf{f} | \mathbf{y}, \mathbf{X}, \boldsymbol{\theta}) = \frac{p(\mathbf{y}, \mathbf{f} | \mathbf{X}, \boldsymbol{\theta})}{p(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta})} = N(\mathbf{f} | \boldsymbol{\mu}, \boldsymbol{\Sigma}), \quad (5)$$

其中: $\boldsymbol{\mu} = \boldsymbol{\Sigma} \mathbf{B} \mathbf{y}$, $\boldsymbol{\Sigma} = (\mathbf{B} + \mathbf{K}^{-1})^{-1}$ 。

高斯过程模型中的一个重要假设条件是噪声模型必须服从高斯分布, 否则无法通过积分获取边缘似然和后验分布。学者们提出了一系列近似逼近策略, 包括: 变分法^[14]、期望传播逼近方法^[15]及假定密度滤波^[16]等。IVM 通过 ADF 构造近似函数代替非高斯后验分布以保持模型的适用性, 并选择点云数据训练样本以实现模型稀疏。

2.1.3 核参数 $\boldsymbol{\theta}$ 学习

高斯过程优于支持向量机的一个特性是可以直接利用点云数据训练样本来进行核参数选择, 即为训练过程。通过对式(4)的边缘似然函数最大化进行核参数 $\boldsymbol{\theta}$ 估计, 包含 $\boldsymbol{\theta}$ 的目标函数如式(6)所示:

$$\boldsymbol{\theta}_{\text{ML}} = \underset{\boldsymbol{\theta}}{\text{argmax}} p(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta}). \quad (6)$$

实际应用中, 比较常用的方法是将最大化边缘似然函数转化为负对数边缘似然函数, 即 $L(\boldsymbol{\theta}) = -\log p(\mathbf{y} | \mathbf{X}, \boldsymbol{\theta})$, 关于核参数 $\boldsymbol{\theta}$ 做最小化处理。

2.1.4 数据预测

计算得到最优核参数 $\boldsymbol{\theta}_{\text{ML}}$ 后, 利用后验概率对点云测试数据 \mathbf{x} 进行预测, 确定隐函数 $f(\mathbf{x})$ 的分布, 即预测 $f(\mathbf{x})$ 在 \mathbf{x} 处的函数值, 即为测试过程。

根据式(2)及多元高斯分布的性质可得到 $[f \ f(\mathbf{x})]$ 的联合分布, 隐变量 $f(\mathbf{x})$ 在测试数据 \mathbf{x} 处的分布可通过 $[f \ f(\mathbf{x})]$ 的联合分布与后验分布对 \mathbf{f} 的积分获取, 如下所示:

$$p(f(\mathbf{x}) | \mathbf{X}, \mathbf{y}, \mathbf{x}, \boldsymbol{\theta}) = \int p(f(\mathbf{x}) | \mathbf{f}, \mathbf{X}, \mathbf{x}, \boldsymbol{\theta}) p(\mathbf{f} | \mathbf{y}, \mathbf{X}, \boldsymbol{\theta}) d\mathbf{f} = N(f(\mathbf{x}) | \boldsymbol{\mu}(\mathbf{x}), \boldsymbol{\sigma}^2(\mathbf{x})),$$

其中 $\boldsymbol{\mu}(\mathbf{x}) = \mathbf{k}^T \mathbf{K}^{-1} \boldsymbol{\Sigma} \mathbf{B} \mathbf{y}$ 代表后验均值函数, $\boldsymbol{\sigma}^2(\mathbf{x}) = k(\mathbf{x}, \mathbf{x}) + \mathbf{k}^T \mathbf{K}^{-1} (\boldsymbol{\Sigma} - \mathbf{K}) \mathbf{K}^{-1} \mathbf{k}$ 为后验协方差函数。

2.2 假设密度滤波逼近

ADF 逼近策略的基本原理为: 每次挑选一个激光脚点以后, 构造一个服从高斯分布的近似函数来代替改变后的后验概率密度, 以保持模型的适用性和可靠性。具体是通过建立真实后验分布概率密度 $p(\mathbf{f} | \mathbf{y}, \mathbf{X}, \boldsymbol{\theta})$ 的近似高斯分布 $q(\mathbf{f})$ 进行

有序逼近,初始近似逼近为 $q_0(\mathbf{f}) = t_0(\mathbf{f}) = N(\mathbf{f} | 0, \mathbf{K})$ 。

ADF 算法将点云数据训练样本分为活动子集 \mathbf{I} 和非活动子集 \mathbf{J} 两部分, \mathbf{I} 代表已经选择用于计算近似高斯分布的训练数据, \mathbf{J} 为未被选择的训练数据。初始化时, \mathbf{I} 为空集, $\mathbf{J} = \{1, \dots, N\}$ 即包含所有训练样本数据。因此在挑选了 i 个训练样本后近似逼近可以表示为以下形式: $q_i(\mathbf{f}) \propto N(\mathbf{f} | \mathbf{0}, \mathbf{K}) N(\mathbf{m}_i | \mathbf{f}_i, \mathbf{B}_{i-1}^{-1}) \approx p(\mathbf{f} | \mathbf{y}_i, \mathbf{X}_{i-1}, \boldsymbol{\theta})$, 其中 \mathbf{I} 中训练样本数据的近似噪声模型为 $N(\mathbf{m}_i | \mathbf{f}_i, \mathbf{B}_{i-1}^{-1})$, 包含参数 m_{i-1} 和 β_{i-1} , 可以通过顺序序列选择获得。

在 ADF 算法中, 真实后验分布逼近过程是将 \mathbf{J} 中的训练数据 n_i 加入到 \mathbf{I} 中, 则后验分布 $\hat{p}_i(\mathbf{f})$ 可更新为:

$$\hat{p}_i(\mathbf{f}) = \frac{q_{i-1}(\mathbf{f}) t_{n_i}(\mathbf{f})}{Z_i}, \quad (7)$$

式中 Z_i 为归一化常数, 计算公式如下:

$$Z_i = Z_i(\boldsymbol{\mu}_{i-1}, \boldsymbol{\Sigma}_{i-1}) = \int t_{n_i}(\mathbf{f}) q_{i-1}(\mathbf{f}) d\mathbf{f}. \quad (8)$$

利用矩匹配实现 KL 散度的最小化, 新的近似 $q_i(\mathbf{f}) = N(\mathbf{f} | \boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i)$ 其中, $\boldsymbol{\mu}_i$ 为 $q_i(\mathbf{f})$ 的均值向量, $\boldsymbol{\Sigma}_i$ 为 $q_i(\mathbf{f})$ 的协方差矩阵, 它们的更新公式如下所示:

$$\begin{aligned} \boldsymbol{\mu}_i &= \boldsymbol{\mu}_{i-1} + \boldsymbol{\Sigma}_{i-1} \mathbf{g}_i, \\ \boldsymbol{\Sigma}_i &= \boldsymbol{\Sigma}_{i-1} - \boldsymbol{\Sigma}_{i-1} (\mathbf{g}_i \mathbf{g}_i^T - 2\boldsymbol{\Gamma}_i) \boldsymbol{\Sigma}_{i-1}, \end{aligned} \quad (9)$$

其中: $\mathbf{g}_i = \frac{\partial \log Z_i(\boldsymbol{\mu}_{i-1}, \boldsymbol{\Sigma}_{i-1})}{\partial \boldsymbol{\mu}_{i-1}}$,

$$\boldsymbol{\Gamma}_i = \frac{\partial \log Z_i(\boldsymbol{\mu}_{i-1}, \boldsymbol{\Sigma}_{i-1})}{\partial \boldsymbol{\Sigma}_{i-1}}.$$

综上所述, 利用 ADF 算法可以利用高斯噪声模型对任何噪声模型进行近似逼近。

3 信息向量机

3.1 概率噪声模型

概率噪声模型主要用于分类问题, 噪声模型中的真实后验分布是非高斯形式, 可以通过选择逼近策略使其近似符合某一高斯分布, 将高斯过程分类转化为回归问题进行处理。对于高斯过程的二元分类问题, 由于分类结果为概率值, 因此可选用 S 型函数中的累积高斯函数进行转换, 得到高斯过程分类的概率噪声模型:

$$\begin{aligned} p(y_n | f_n) &= \varphi(\lambda y_n (f_n + b)) = \\ &= \int_{-\infty}^{\lambda y_n (f_n + b)} N(t | 0, 1) dt = \\ &= \int_{-\infty}^0 N(t | -\lambda y_n (f_n + b), 1) dt, \end{aligned} \quad (10)$$

其中曲线倾斜度由参数 λ 进行控制。

将式(10)代入式(8)中, 并将积分顺序进行交换, 可得归一化常数 Z_i :

$$\begin{aligned} Z_i &= \int \varphi(\lambda y_n (f_n + b)) N(f_n | \mu_{i-1, n}, \zeta_{i-1, n}) df = \\ &= \int_{-\infty}^0 N(t | -\lambda y_n (f_n + b), 1 + \lambda^2 \zeta_{i-1, n}) dt = \\ &= \varphi(u_{i-1, n}), \end{aligned} \quad (11)$$

其中: $u_{i-1, n} = c_{i-1, n}(\mu_{i-1, n} + b)$, $c_{i-1, n} = \frac{y_n}{\sqrt{\lambda^{-2} + \zeta_{i-1, n}}}$ 。

因此, 近似逼近 $q_i(\mathbf{f})$ 均值向量和协方差矩阵更新公式中的参数 g_m 与 γ_m 可分别表示为:

$$\begin{aligned} g_m &= c_{i-1, n} N(u_{i-1, n}) [\varphi(u_{i-1, n})]^{-1}, \\ \gamma_m &= -\frac{1}{2} g_m u_{i-1, n} c_{i-1, n}, \end{aligned} \quad (12)$$

其中 g_m 表示 \mathbf{g}_i 的第 n 个元素, γ_m 则代表 $\boldsymbol{\Gamma}_i$ 的第 n 个对角线元素。

那么 $(\mathbf{g}_i \mathbf{g}_i^T - 2\boldsymbol{\Gamma}_i)$ 的第 n 个对角线元素 v_m 的计算公式如下:

$$v_m = g_m (g_m + u_{i-1, n} c_{i-1, n}), \quad (13)$$

则噪声模型的近似高斯分布 $N(m_n | f_n, \beta_n^{-1})$ 中 m_n 及 β_n 的计算公式如下:

$$m_n = \frac{g_m}{v_m} + \mu_{i-1, n}, \quad (14)$$

$$\beta_n = \frac{v_m}{1 - v_m \zeta_{i-1, n}}. \quad (15)$$

综上所述, 可以用式(16)中的近似公式表示分类问题中的边缘似然函数:

$$p(\mathbf{y}) \approx N(\mathbf{m} | \mathbf{0}, \mathbf{K} + \mathbf{B}^{-1}). \quad (16)$$

3.2 信息向量机原理

在基于 ADF 近似算法的高斯过程分类问题中, 核参数 $\boldsymbol{\theta}$ 的自动优化选择是利用点云数据训练样本数据通过边缘似然函数最大化实现的。设训练样本包含 N 个激光脚点, 在对核矩阵及其逆矩阵 \mathbf{K} 进行计算时, 会产生大小为 $O(N^3)$ 的算法复杂度; 同时, 在 $\boldsymbol{\theta}$ 学习过程中, 解算边缘似然函数对 $\boldsymbol{\theta}$ 的梯度时, 计算复杂度为 $O(N^3)$, 并占用 $O(N^2)$ 的内存。当 N 数值较大时, 计算效率会受到很大影响, 也会限制模型的广泛应用。为了解决上述问题, 采用文献[10]方法进行活动子集

中信息向量选择,若活动子集中激光脚点数量为 d ,则计算复杂度可以降低为 $O(d^2 N)$,内存需求也降低到 $O(dN)$,由于 $d \ll N$,故 IVM 方法可使计算效率得到大幅度提高,并释放了部分内存空间,从而实现了模型稀疏化。

3.2.1 活动子集选择

在信息向量机中,计算 \mathbf{J} 中每个激光脚点的后验微分熵,选择具有最大后验微分熵的激光脚点加入 \mathbf{I} 。当为 \mathbf{I} 选择第 i 个信息向量时,针对 \mathbf{J} 中的第 n 个激光数据点,其后验微分熵如下:

$$\begin{aligned} \Delta H_m = & -\frac{1}{2} \log |\boldsymbol{\Sigma}_i| + \frac{1}{2} \log |\boldsymbol{\Sigma}_{i-1}| = \\ & -\frac{1}{2} \log |\mathbf{I} - \boldsymbol{\Sigma}_{i-1} \text{diag}(v_i)| = \\ & -\frac{1}{2} \log (1 - v_m \zeta_{i-1,n}). \end{aligned} \quad (17)$$

对 \mathbf{J} 中每一个数据点进行如式(17)所示的计算,选择具有最大后验微分熵的数据点加入 \mathbf{I} ;重复以上过程直至 \mathbf{I} 中包含 d 个信息向量为止。

从式(17)中可以看出,为了对 \mathbf{J} 中每个激光脚点进行评价,需要记录后验协方差矩阵 $\boldsymbol{\Sigma}_{i-1}$ 的对角线元素及 v_m 的值。保存整个后验协方差矩阵 $\boldsymbol{\Sigma}_{i-1}$ 需要占用大小为 $O(N^2)$ 的内存空间,因此需要对 $\boldsymbol{\Sigma}_{i-1}$ 进行稀疏表达以降低占用内存量。鉴于后验协方差矩阵 $\boldsymbol{\Sigma}_i$ 结构特殊性,即利用原始先验协方差矩阵 $\boldsymbol{\Sigma}_0 = \mathbf{K}$ 的连续矢量积可解算获得 $\boldsymbol{\Sigma}_i$ 。 $\boldsymbol{\Sigma}_i$ 可以改写为如下形式:

$$\boldsymbol{\Sigma}_i = \mathbf{K} - \mathbf{M}_i^T \mathbf{M}_i, \quad (18)$$

其中: \mathbf{M}_i 为 $i \times n$ 阶矩阵,第 k 行为 $\sqrt{v_{k,n_k}} \mathbf{s}_{k-1,n_k}^T$, n_k 代表 \mathbf{I} 包含的第 k 个信息向量; $\zeta_{i-1,n}$ 为协方差矩阵 $\boldsymbol{\Sigma}_{i-1}$ 中第 n 个对角元素,在不保存 $\boldsymbol{\Sigma}_{i-1}$ 的情况下无法对 $\zeta_{i-1,n}$ 进行直接表达。利用 \mathbf{M}_{i-1} 和 \mathbf{K} 可以对 $\zeta_{i-1,n}$ 进行重新计算:

$$\mathbf{s}_{i-1,n_i} = \mathbf{k}_{n_i} - \mathbf{a}_{i-1,n_i}^T \mathbf{M}_{i-1}. \quad (19)$$

上式中, $\mathbf{K} = \boldsymbol{\Sigma}_0$ 的第 n_i 列向量由 $\mathbf{k}_{n_i} = \mathbf{s}_{0,n_i}$ 表示,矩阵 \mathbf{M}_{i-1} 的第 n_i 列向量则由 \mathbf{a}_{i-1,n_i} 表示。这样,将行、列向量代替矩阵存储于内存中,可使内存需求降低为 $O((i-1)N)$,大大节约了内存空间。

由于 ζ_i 为后验协方差矩阵 $\boldsymbol{\Sigma}_i$ 的对角线元素,即 $\zeta_i = \text{diag}(\boldsymbol{\Sigma}_i)$,则后验协方差向量的更新公式如式(20)所示,以对角形式表示,从而简化了

计算;后验均值输出向量也需要保存,其更新公式如式(21)所示。

$$\zeta_i = \zeta_{i-1} - v_{i,n_i} \text{diag}(\mathbf{s}_{i-1,n_i} \mathbf{s}_{i-1,n_i}^T), \quad (20)$$

$$\boldsymbol{\mu}_i = \boldsymbol{\mu}_{i-1} + g_{n_i} \mathbf{s}_{i-1,n_i}. \quad (21)$$

式(20)、(21)的计算复杂度均为 $O(N)$ 。综上所述,为了大幅度降低计算复杂度和内存需要,可以通过以下两种策略实现:①选择活动子集;②对角化表示后验协方差矩阵。基于 IVM 的 LiDAR 点云数据分类问题中活动子集选择的算法伪代码如下:

算法 1:IVM 活动子集选择算法

要求:设活动子集点云数据训练样本个数为 d 。对于分类问题,从 $\mathbf{m} = \mathbf{0}$ 、 $\boldsymbol{\beta} = \mathbf{0}$ 开始。设 $\zeta_0 = \text{diag}(\mathbf{K})$, $\boldsymbol{\mu} = \mathbf{0}$;非活动子集 $\mathbf{J} = \{1, 2, \dots, N\}$,包含所有训练数据;活动子集 $\mathbf{I} = \emptyset$ 为空集, \mathbf{S}_0 为空矩阵

for $i = 1, \dots, d$ do

for $n \in \mathbf{J}$ do

根据式(12)及(13)分别计算 g_m 、 γ_m 及 v_m

根据式(17)计算 ΔH_m

根据式(12)计算 g_m

end for

$n_i = \arg \max_{n \in \mathbf{J}} \Delta H_m$

根据式(14)、(15)更新 m_{n_i} 和 β_{n_i}

根据式(19)、(20)及(21)计算 ζ_i 和 $\boldsymbol{\mu}_i$

扩展 $\sqrt{v_{i,n_i}} \mathbf{s}_{i-1,n_i}^T$ 到 \mathbf{M}_{i-1} , 根据式(19)计算 \mathbf{M}_i

将第 n_i 个激光脚点添加到 \mathbf{I} 中,同时在 \mathbf{J} 中
去掉第 n_i 个激光脚点

end for

3.2.2 参数优化

对于 IVM 而言,为了优化核参数 θ 需要依据向量的稀疏形式对似然函数进行最大化处理,也称为第 II 类型边缘似然最大化方法。IVM 算法仅利用活动子集中的信息向量训练样本进行高斯近似,边缘似然函数计算方法如下所示:

$$p(\mathbf{y}_i) \approx N(\mathbf{m}_i | \mathbf{0}, \mathbf{K}_i + \mathbf{B}_i^{-1}), \quad (22)$$

其中: \mathbf{y}_i 是只包含活动子集中 \mathbf{y} 元素的向量,核函数参数 $\boldsymbol{\theta}$ 包含于 \mathbf{K}_i 中。选择尺度共轭梯度法^[17]最大化式(22)获取最优核参数 $\boldsymbol{\theta}$ 。点云数据分类研究中参数 $\boldsymbol{\theta}$ 的优化过程伪代码描述如下:

算法 2:IVM 参数优化

要求:设活动子集中信息向量个数为 d ,迭代次数为 T

for $i=1, \dots, T$ do

根据算法 1 选择激光脚点作为活动子集的信息向量

根据式(22)计算边缘似然函数,通过尺度共轭梯度算法进行核函数参数 θ 优化求解;

end for

4 LiDAR 点云数据分类实验

4.1 特征提取与 IVM 多类分类步骤

基于 SVM 的点云分类方法应用较为广泛,分类精度较高。本文采用了 IVM 和 SVM 分类器进行点云分类实验,并对分类结果进行比较分析。

以单个离散激光脚点为对象,提取的 LiDAR 点云脚点特征包括:①归一化高程,即地物的绝对高度信息,其可通过计算 DSM 与 DEM 之间的差值获得,其中,DEM 由渐进加密三角网滤波方法获得;②高程标准差,可作为反应激光脚点局部邻域内高程变化情况的微观特征,计算公式如式(23)所示;③高程差为局部邻域内激光脚点高程最高值与最低值之间的差值;④曲率特征用于定量描述局部曲面某处的剧烈变化程度,利用激光脚点的邻近元素建立协方差矩阵,分析协方差矩阵的特征向量与特征值,根据特征值进行曲率特征解算;⑤强度,即由机载 LiDAR 系统获取的激光脉冲返回幅度。

$$\begin{cases} \text{HSTD} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (H_i - \bar{H})^2} \\ \bar{H} = \frac{1}{n} \sum_{i=1}^n H_i \end{cases} \quad (23)$$

上式中,局部邻域内的脚点个数由 n 表示, H_i 代表了邻域中第 i 个脚点的高程值, \bar{H} 是邻域内所有脚点的高程平均值。

为了便于比较分析,IVM 和 SVM 分类器均采用高斯径向基核函数(Radial Basis Function, RBF),其表达式为 $k(x, x') = \exp(-\|x - x'\|^2 / \sigma^2)$, σ 为核函数参数。在 SVM 分类中,需要通过交叉验证网格搜索法确定核函数参数 σ 及惩罚系数 C 以

达到最佳的分类性能,选择序列最小优化算法^[18]进行模型学习。IVM 和 SVM 均选择“一对余”(OAR)法解决多类分类问题。

基于 IVM 的 LiDAR 点云数据多类分类流程如下:

步骤 1:选取 LiDAR 点云数据的 5 类特征作为 IVM 分类器的输入向量,选取 5% 的特征向量作为训练样本;

步骤 2:选择 RBF 和 OAR 分类方法构造多类分类器 OAR-RBF-IVM;

步骤 3:利用训练样本对 OAR-RBF-IVM 分类器进行训练,首先按照算法 1 从训练样本中选择活动子集中的信息向量,然后根据算法 2 进行核函数优化学习;

步骤 4:将待识别的激光脚点特征输入训练完毕的 IVM 分类器,得到分类标记结果。

4.2 实验数据

本文选择两组数据进行实验,第一组数据来源于 TerraSolid 提供的 Niagara 地区点云数据,点云密度为 2.46 pts/m²,总点数为 45 099 个,样本信息情况如表 1 所示;第二组为非洲某地区点云数据,点云密度为 3.12 pts/m²,总点数为 57 557 个,样本信息情况如表 2 所示。实验过程中,随机选取每组数据各类地物数量的 5% 作为训练样本,其余作为测试样本。

表 1 Niagara 测区点云数据样本信息

Tab. 1 Sample information of points cloud data in Niagara area

类别	1	2	3	4	5
名称	地面点	建筑物	植被	车辆	建筑物墙面
数量	25 820	15 020	2 955	958	346

表 2 非洲某地区点云数据样本信息

Tab. 2 Sample information of points cloud data in African area

类别	1	2	3
名称	地面点	建筑物	植被
数量	38 873	8 103	10 581

4.3 信息向量数量选择

实验过程中,需要设置活动子集信息向量的数量。设信息向量数量最大为 500 个,选择具有不同数量信息向量的两组点云数据来分析模型训练耗时和分类精度,结果如图 1、图 2 所示。

通过对不同数量信息向量时两组点云数据的

模型训练时间和分类精度的实验结果进行综合分析可得到如下结论:随着信息向量数量的不断变大,模型训练时间显著增大;初始阶段,在信息向量数量少许增加后,IVM 分类精度显著提高并且逐渐趋于稳定。




图 1 Niagara 数据不同信息向量数量 IVM 分类结果

Fig. 1 IVM classification results of Niagara data with different number of informative vectors




图 2 非洲某地区数据不同信息向量数量 IVM 分类结果

Fig. 2 IVM classification results of African area data with different number of informative vectors

4.4 分类性能比较

选择 IVM 进行点云数据分类时,通过边缘似然函数最大化获取最优 RBF 核函数 σ_{IVM} ; 利用 SVM 进行分类时,将 RBF 核函数参数 σ_{SVM} 和惩罚系数 C 的取值范围设置为 $0.2 \times i, i =$

$\{1, 2, \dots, 10\}$, 利用 2-折交叉验证选择最优参数。

Niagara 测区和非洲某地区点云数据的 IVM 与 SVM 分类结果分别如表 3、表 4 所示。其中,基向量数量分别表示信息向量和支撑向量数量。

表 3 Niagara 测区点云数据 IVM 与 SVM 分类比较

Tab. 3 Classification comparison between IVM and SVM of point cloud data in Niagara area

	参数 σ	参数 C	交叉验证时间/s	基向量数量	训练时间/s	测试时间/s	精度/%
SVM	0.2	1.4	2 032.70	323	115.61	1.31	88.04
IVM	0.73	—	—	50	5.86	6.28	94.20

表 4 非洲某地区点云数据样本信息点云数据 IVM 与 SVM 分类比较

Tab. 4 Classification comparison between IVM and SVM of point cloud data in African area

	参数 σ	参数 C	交叉验证时间/s	基向量数量	训练时间/s	测试时间/s	精度/%
SVM	0.4	2.0	4 891.83	224	108.20	1.76	87.57
IVM	0.24	—	—	90	8.03	5.83	90.78

对表 3、表 4 实验结果进行分析,可得出如下结论:

(1)与 SVM 相比,IVM 对于点云数据的分类精度更高,可靠性更强。

(2)IVM 分类器使用的基向量数据少于 SVM,模型更加稀疏。

(3)进行核函数参数获取时,SVM 进行交叉

验证耗时较长;而 IVM 可自适应获取核函数参数,故训练速度更快,耗时更短,效率更高。

Niagara 测区点云数据及非洲某地区点云数据的分类结果分别如图 3、图 4 所示,其中(a)为按照高程渲染的原始点云数据,(b)为本文算法获得的分类结果,(c)为参考分类结果。

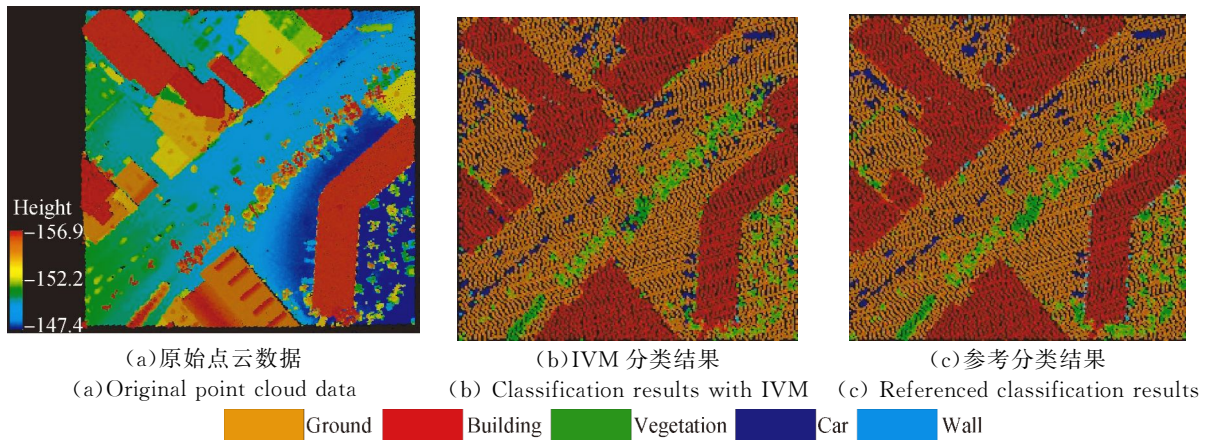


图 3 Niagara 点云数据分类结果比较
Fig. 3 Comparison of classification results of point cloud data in Niagara area

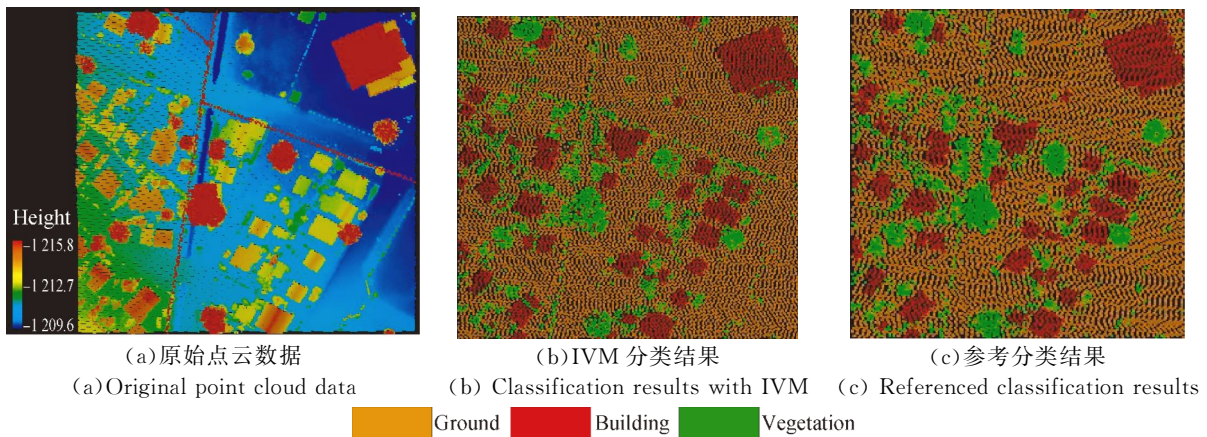


图 4 非洲某地区点云数据分类结果比较
Fig. 4 Comparison of classification results of point cloud data in African area

通过与人工分类生成的分类结果进行对比可知,基于 IVM 的机载 LiDAR 点云数据分类结果较好,每类地物基本都得到了有效识别,与真实地表覆盖非常接近。

5 结 论

本文提出一种基于 IVM 的点云数据分类算法。该算法利用 ADF 将概率噪声模型近似逼近为高斯噪声模型,对边缘似然函数进行最大化处理,以自适应获取核函数参数,通过选择活动子集

中信息向量数量来降低内存耗费,从而实现模型稀疏,选择一对余法进行多类分类。通过对 Niagara 地区和非洲某地区点云数据进行实验,结果证明:基于 IVM 分类方法的分类精度分别提高到 94.20% 和 90.78%,基向量数量分别减少到 50 个和 90 个,训练时间分别降低到 5.86 s 和 8.03 s。实验结果验证了基于 IVM 的点云数据分类算法在精度、效率方面的优势。


本文只选取了 LiDAR 脚点特征进行分类,下一步的研究重点是融合多源数据辅助点云数据分类。

参考文献:

- [1] 赖旭东. 机载 LiDAR 基础原理与方法[M]. 北京: 电子工业出版社, 2010.
LAI X D. *Principle and Application of Airborne LiDAR* [M]. Beijing: Publishing House of Electronics Industry, 2010. (in Chinese)
- [2] 张小红. 机载 LiDAR 测量技术理论与方法[M]. 武汉: 武汉大学出版社, 2007.
ZHANG X H. *Theory and Method of Airborne LiDAR Measuring Technology* [M]. Wuhan: Wuhan University Press, 2007. (in Chinese)
- [3] 孙美玲, 李永树, 陈强, 等. 基于迭代多尺度形态学开重建的城区 LiDAR 滤波方法[J]. 红外与激光工程, 2015, 44(1): 363-369.
SUN M L, LI Y SH, CHEN Q, *et al.*. Iterative multi-scale filter based on morphological opening by reconstruction for LiDAR urban data [J]. *Infrared and Laser Engineering*, 2015, 44(1): 363-369. (in Chinese)
- [4] VOSSSELMAN G. Slope based filtering of laser altimetry data [J]. *International Archives of Photogrammetry and Remote Sensing*, 2000, 33(B3/2): 935-942.
- [5] 李乐林, 江万寿, 郭程方. 基于区域多次回波点密度分析的城区 LiDAR 建筑物提取[J]. 国土资源遥感, 2015, 27(2): 29-35.
LI L L, JIANG W SH, GUO CH F. Classification of LiDAR point clouds in urban areas based on the analysis of regional multi-return density [J]. *Remote Sensing for Land&Resources*, 2015, 27(2): 29-35. (in Chinese)
- [6] 张齐勇, 岑敏仪, 周国清, 等. 城区 LiDAR 点云数据的树木提取[J]. 测绘学报, 2009, 38(4): 330-335.
ZHANG Q Y, CEN M Y, ZHOU G Q, *et al.*. Extracting trees from LiDAR data in urban region [J]. *Acta Geodaetica et Cartographica Sinica*, 2009, 38(4): 330-335. (in Chinese)
- [7] SAMADZADEGAN F, BIGDELI B, RAMZI R. A multiple classifier system for classification of LiDAR remote sensing data using multi-class SVM [C]. *Multiple Classifier Systems: 9th International Workshop, Cairo, Egypt: MCS*, 2010: 254-264.
- [8] 吴军, 刘荣, 郭宁, 等. SVM 加权学习下的机载 LiDAR 数据多元分类研究[J]. 武汉大学学报: 信息科学版, 2013, 38(1): 1-6.
WU J, LIU R, GUO N, *et al.*. Aerial LiDAR data classification using weighted support vector machines [J]. *Geomatics and Information Science of Wuhan University*, 2013, 38(1): 1-6. (in Chinese)
- [9] 姚伏天, 钱运涛. 高斯过程及其在高光谱图像分类中的应用[J]. 智能系统学报, 2011, 5(6): 396-404.
YAO F T, QIAN Y T. Gaussian process and its applications in hyperspectral image classification [J]. *Caa Transactions on Intelligent Systems*, 2011, 5(6): 396-404. (in Chinese)
- [10] LAWRENCE N D, SEEGER M, HERBRICH R. The informative vector machine: a practical probabilistic alternative to the support vector machine [R]. *Technical report, Department of Computer Science, Sheffield, UK*, 2005.
- [11] 徐翔, 刘建伟, 罗伟麟. 基于信息向量机的神经活动分类和译码研究[J]. 计算机工程, 2010, 36(7): 198-199, 202.
XU X, LIU J W, LUO W L. Research on neural activity classification and decoding based on informative vector machine [J]. *Computer Engineering*, 2010, 36(7): 198-199, 202. (in Chinese)

- [12] 刘建伟,徐翔,罗伟麟. 基于OLPP和信息向量机的人脸识别[J]. 计算机工程, 2010, 36(7): 200-202.
LIU J W, XU X, LUO W L. Face recognition based on orthogonal locality preserving projection and informative vector machine [J]. *Computer Engineering*, 2010, 36(7): 200-202. (in Chinese)
- [13] 谭熊. 联合光谱和空间特征的高光谱影像分类技术研究[D]. 郑州:信息工程大学, 2014.
TAN X. *Research on Classification Techniques for Hyperspectral Imagery Based on Combined Spectral and Spatial Features* [D]. Zhengzhou: PLA Information Engineering University, 2014. (in Chinese)
- [14] GIBBS M N, MACKAY D J C. Variational Gaussian process classifiers [J]. *IEEE Transactions on Neural Networks*, 2002, 11(6): 1458-1464.
- [15] MINKA T P. *A Family of Algorithms for Approximate Bayesian Inference* [D]. Cambridge: Massachusetts Institute of Technology, 2014.
- [16] CSATO L. *Gaussian Processes-iterative Sparse Approximations* [D]. Birmingham: Aston University, 2002.
- [17] MARTIN F M. A scaled conjugate gradient algorithm for fast supervised learn [J]. *Neural Networks*, 1993, 6: 525-533.
- [18] 李航. 统计学习方法[M]. 北京:清华大学出版社, 2012.
LI H. *Statistical Learning Method* [M]. Beijing: Tsinghua University Press, 2012. (in Chinese)

作者简介:



刘志青(1986—),女,河南郑州人,博士研究生,2009年、2012年于解放军信息工程大学分别获得学士、硕士学位,主要从事数字摄影测量与激光雷达方面的研究。E-mail: lpc1987212@163.com



李鹏程(1987—),男,湖北武汉人,博士,2009年、2012年、2015年于解放军信息工程大学分别获得学士、硕士、博士学位,主要从事机载激光雷达数据后处理方面的研究。E-mail: lpclqq@163.com

导师简介:



张保明(1961—),男,河北安国人,教授,博士生导师,1982年、1995年于解放军信息工程大学分别获得学士、硕士学位,主要从事数字摄影测量、遥感影像处理研究。E-mail: chenxw_2007@aliyun.com