

基于多尺度维度准则对复杂自然场景的三维地面激光雷达数据分类:地貌应用

N. Brodu¹ , D. Lague^{1,2} , 刘坤³ (译)

1.Geosciences Rennes, Université Rennes 1, CNRS, Rennes, France

2.Department of Geological Sciences, University of Canterbury, Christchurch, New Zealand

3.中国地质大学(北京)

摘要

与地貌(河流、海岸环境、悬崖等)的问题有关自然环境的三维点云, 通常需要将数据分为相关的基础类。典型的例子是河流环境中的河岸植被与地面的分离, 悬崖环境下的新表面与岩崩的区别, 或更一般地根据它们的形态对表面进行分类(例如, 基岩的形态或颗粒大小)。自然表面是不均一的, 其独特的性质很难在同一个尺度下定义, 这就促使使用多尺度标准来实现高精度分类。因此我们在每个点周围定义了点云维度的多尺度度量。维数表征了在以测点为中心的局部三维点云的组织情况, 即从 1D(沿直线排列的点), 2D(点形成平面)到完整的 3D 体积。通过改变球体的直径, 我们可以观察到局部点云在不同尺度上的形态。我们提出了该技术, 证明了它将河岸植被与地面分离的能力, 并将山间溪流分类为植被、岩石、砾石和水面。在这两种情况下, 将植物与地面或其它类分离, 达到了 98% 以上的精度。通过与单尺度方法的比较, 证明了多尺度分析在提高分类的分类能力和空间分辨率方面的优越性。10 到 1 亿点的场景可以在一个普通的笔记本电脑上在合理的时间内分类。该技术对于存在丢失数据、阴影区域和场景中点密度的变化的情况是非常可靠的。分类速度快、准确, 可以在一定程度上解释不同植被类型的内部形态的差异程度。在每个点上都给出了分类结果的概率置信值, 允许用户删除类别不确定的点。这个过程可以是完全自动化的(用户可以最少只输入一次, 所有的场景都是在大的计算批次中完成的), 但是也可以由用户完全定制, 包括分类器的图形定义。工作分类器可以在用户之间进行独立的交换, 以获取样本数据, 从而避免了再次对分类器进行充分训练。该方法虽然为全三维数据开发, 但也可应用于 2.5D 机载激光雷达数据。

©2012 年国际摄影测量与遥感学会(ISPRS), 由 Elsevier B.V.出版, 版权所有。

一、前言

地面激光扫描(TLS)现在经常被用于地球科学研究, 来获得比几年前在自然环境测量中使用的技术的更高的精度和完整性。由于可以得到一个几乎完整和精确自然表面文件, TLS 已经被应用在了几个新的领域。这包括对自然

本文 2012 年 2 月刊登于: ISPRS Journal of Photogrammetry and Remote Sensing

相关链接: <http://nicolas.brodu.net/recherche/canupo/>

联系方式: nicolas.brodu@inria.fr (N. Brodu) ; dimitri.lague@univ-rennes1.fr (D. Lague) ;

liukunrs@163.com (刘坤)

表面的几何性质的详细分析(从厘米级到公里级), 例如三维地层重建和产量分析(Labourdette and Jones, 2007; Renard et al., 2006), 河流的粒径大小 (Hodge et al., 2009a, b; Heritage and Milan, 2009), 沙丘分布 (Nield et al., 2011; Nagihara et al., 2004), 植被水力粗糙度(Antonarakis et al., 2009, 2010), 河床形态(Milan et al., 2007), 以及对悬崖侵蚀和崩塌特性的现场监测 (Abellán et al., 2006; Lim and Suter, 2009; Rabatel et al., 2008; Rosser et al., 2005; Teza et al., 2008)。所有这些应用中, 迫切需要解决如何精确的自动分类——能够在各种自然环境中预先处理复杂的三维点云。典型的应用实例是植被与地面或悬崖露头的分离, 新岩石表面与岩崩的区别, 平坦和有波纹河床的分类, 概括来说就是根据它们的形态进行分类。然而, 在地质学中应用仍然困难, 原因有四: (1) 与传统的二维数字高程模型(DEM)相比, 数据具有三维的性质; (2) 由于不可避免的遮蔽效应, 数据的分辨率和完整性具有不确定性; (3) 自然表面的自然异质性和复杂性; (4) 现代 TLS 会产生大量数据。在接下来的文章中, 我们分析了这些困难, 以及在自然环境中提高我们对 TLS 数据的使用的必要性。

1. 地面激光雷达数据大多是 3D 的, 而不是 DEM 或机载激光雷达数据的那种 2.5D。这意味着传统的基于栅格格式的数据分析方法 (特别是从地面上的植被分离 e.g. Sithole and Vosselman, 2004) 和二维矢量数据处理方法不能应用于地面激光雷达数据。在某些情况下, 三维点云中的研究区域在感兴趣尺度下是二维的。(也就是, 河床 (Hodge et al., 2009b), 悬崖 (Rosser et al., 2005; Abellán et al., 2010), 河口 (Guarnieri et al., 2009)), 并且可以使用现有的快速栅格的方法进行投影和栅格化。然而, 在许多情况下, 自然表面是三维的, 没有简单的方法可以将其转化为二维表面(例如图 1)。在其他情况下, 当子像素的属性(如植物、碎石、裂缝等) 显著表现为三维时, 栅格化大规模二维表面变得非常重要。例如, 在河床上, 依据河床和覆盖层特征(通常是植被)对局部数据进行分类就需要采用 3D 分类方法。

2. 地面激光雷达数据集对于阴影效应和缺失的数据(例如水表面)都具有不确定性, 这是由传感器的地面位置和自然表面的粗糙度决定的固有特性(例如图 1)。虽然多个扫描位置可以显著地减少这个问题, 但由于扫描空间和时间的限制, 使得在有些地区不可行。虽然插值可以用来弥补缺失的信息(例如, 曲面的建网), 但在三维中是相当复杂的, 而且由于自然表面的几何形状复杂, 会导致错误的结果。可以论证的是, 插值应该作为最后的手段, 特别是在 3D 场景被正确分类后, 例如, 植被。因此, 任何对三维点云进行分类的方法都应该考虑到阴影效果, 要么是对它不敏感, 要么是在局部丢失数据的情况下。

3. 如图所示扫描陡峭的山涧, 自然表面表现出了复杂的几何形态(图 1)。这种复杂性起源于个体的非一致性(可变粒度, 植被类型和年龄, 多种岩性和裂缝密度, ...), 特征空间尺度的大范围 (从沙滩到巨石, 从杂草到树木) 或其缺失(例如断裂)。这就使得原始三维点云数据的分类比诸如道路或建筑物等具有简单几何特征的人工结构(如平面或棱角)更复杂。

4. 随着技术的发展, 数据集越来越密集, 这意味着在未来十年中有数十亿点的项目可能会变得很普遍。因此, 迫切需要能够在最小化用户输入的情况下快速精确的自动化处理方法, 来对大量三维点云进行快速分类。

据我们所知,还没有哪种技术可以将类似图 1 中的自然三维场景分类成子要素,如植被、岩石表面、砂砾和水等。在地面机器人导航系统的研究中,实现了仅仅采用几何方法对简单场景中平面和植被的分类(Vandapel et al., 2004;Lalonde et al., 2006),但在需要分析地物的几何特征时无法选择一个特定的空间尺度使用这种方法。基于反射激光强度的分类最近被提出(Franceschi et al., 2009),但由于对入射距离和入射率难以进行精确校正(例如 Kaasa-lainen et al., 2011;Lichti, 2005),它还不能应用于 3D 表面。基于 RGB 图像的分类可以用在简单的环境中,将植被从地面分离出来(Lichti, 2005)。但对于大型复杂的三维环境,其分类效果受强阴影投影(图 1)、图像曝光的不确定性、表面湿度的影响以及 RGB 光谱特征的有限可分性的限制(Lichti, 2005)。此外,当对具有相似 RGB 特征但几何特征不相同的对象进行分类时(即平坦的床与涟漪,新基岩与岩崩),只有几何特征可以用来分离点云。

本文针对复杂的自然环境,提出了一种新的三维点云分类方法。它解决了上面讨论的大部分难题:在真 3D 环境下,直接在点云上工作,对阴影效果或点密度的变化基本上不敏感,最重要的是它允许某种程度的可变性和在类特性上的异质性。为这个项目设计的软件集(CA-NUPO 套件)用来处理大体量的点云数据集。该工具可以由机器学习领域的非专业人员使用自动化的方式进行处理,也可以允许对分类过程的简单控制。因为几何测量效果独立于使用的测量仪器(不是利用反射强度或 RGB 的情况下(Kaasalainen et al.,2011)),根据具体环境定义分类器(即高山河流,盐沼泽环境,砾石床河,悬崖露头)可以被其他用户直接重用,不用强制性的每个阶段都对分类器进行重建。

我们的方法的优点是提出了一种基于不同尺度的三维几何特性对场景进行分类可靠方法。这允许在复杂场景(例如图 1)中以非常高的精确度识别植被。下面我们首先介绍了研究地点和数据采集过程。然后,我们引入了新的多尺度维度特征,用于描述场景中某个点的局部几何形状,以及它如何描述简单的基本环境特征(地面和植被)。在第 4 节中,我们描述了构建一个分类器的训练方法:它的目的是自动地找到最能区分两个或两个以上特征地物的尺度组合。使用两个数据集对分类方法进行质量测试:(1)一个简单的河岸沙子上的植被,(2)一个更复杂的,包括具有非常明显的异质性和三维特征的多个类的山区河流(图 1)。最后,我们将讨论该方法相对于其他分类方法的应用范围和不足。

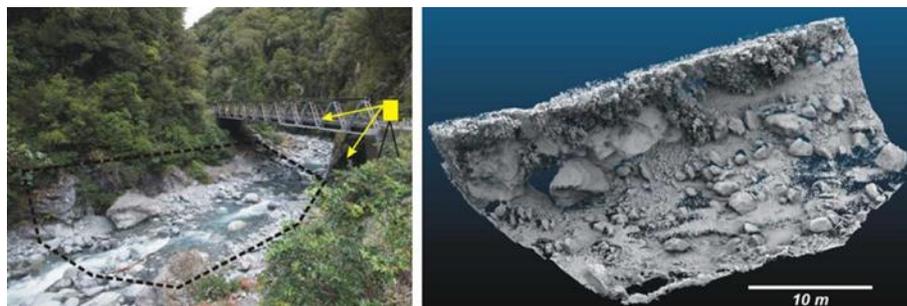


图 1. 左:位于奥提拉峡谷(新西兰)的陡峭的山河河床,以及陆地激光扫描仪的位置。右图:在 CloudCompare (Girardeau-Montaut, 2011)中使用 PCV 技术绘制的点云的一部分(Girardeau-Montaut, 2011)展示了场景的完整 3D 特性(300 万点,最小点间距= 1 厘米)。确定关键的基础类,如植被、岩石表面、砂砾或水面,可以研究植被的垂直分布、水面剖面、分割大块岩石,或测量砾石覆盖层和测量厚度的变化。

二、研究地点和数据采集

该方法在两种不同的环境下进行了测试:一种是在 Saint-Michel (法国)山湾的盐沼泽环境,在低海潮中进行扫描,由 10-30 厘米高的河岸植被覆盖在沙地上,或者是平坦的或有几厘米高的波纹(图 4 和图 6);另一种位于新西兰南岛的奥提拉河峡(Otira River 峡谷)陡峭的部分,包括部分由植被覆盖的基岩河岸,以及由砾石和石块组成的冲积层(图 1)。这两个场景都是利用 Leica Scanstation 2,其中盐沼泽地的安装在距地面 2 米高的测量三脚架上,另一处位于图 1 所示的 Otira 河岸上。Leica Scanstation 2 是一种使用绿色激光(532 纳米)的单回波脉冲式激光雷达,它的实际扫描范围根据表面反射率从 100 到 200 米不等。当激光入射到静止的水面时,激光可以穿透 30 厘米的清水,并从河床上传回回声。在奥提拉峡谷(Otira)的某些地方就是这样。然而,在湍流的白水里,激光直接从表面反射或穿透水柱(米兰等,2010)。因此,水的表面变成了明显的高度不一的噪声表面(图 1)。建筑方面的标准,所给出的标准差为每 50 米 4 毫米,角精度为 $60 \mu rad$ 。该扫描仪对 50 米的重复测量具有 1.4 毫米标准差(给出一个标准差)。经证实,在 1 到 50 米之间激光间距是 4 毫米。这种狭窄的间距使激光能在相对稀疏的植被中击中地面或悬崖。但这也会在物体的边缘(砂砾,茎,叶,...)产生一小部分被称为混合点的伪点(如 Hodge 等,2009b;Lichti,2007)。这些伪点对分类过程的影响在第 6 节中讨论。

用于测试的点云是从单个扫描位置获得的,因为它对应于最坏的情况,具有阴影效果和点密度变化的特点。在 Otira 河中,在距离扫描仪 15 - 45 米的位置,水平和垂直角度分辨率分别为(0.031L,0.019L)。这对应点间距从 5 到 24 毫米。在分类测试过程中,为了加快计算速度,这些数据以 10 毫米的最小点距离采样,这样整个场景中留下了 117 万个点。在河滨植被环境下的采集参数为:角分辨率(0.05°,0.014°),扫描距离为距离扫描仪 10-15 m。在用于分类测试的数据集中,大概有 640,000 个点,对应的点间距从 2.4 到 13 毫米不等。数据没有进一步的处理。

三、多尺度局部维度特征

这个特征的主要思想是在每个点和不同尺度上描绘出场景的局部维度属性。通过“局部维度”,我们的意思是,在给定的位置和给定的尺度上,点云的几何形状是怎样的:它是否更像一条直线(1D),一个平面(2D),或者在考虑的位置周围的整个立体空间中(3D)分布着点。例如,考虑一个由岩石表面、碎石和植被组成的场景(例如图 1):在几厘米的尺度上,基岩看起来像一个二维的表面,砾石看起来是三维的,而植被是像茎(1D)和叶(2D)这样的元素的混合物。在更大的尺度上(例如 30 厘米)的基岩看起来仍然主要是 2 d,碎石现在看起来更像 2 d 而非 3 d,植被已成为 3 d 的矮树丛(见图 7)。结合不同尺度信息我们可以建立解译标志,来识别场景中一些物体的类别。在这种分类方法的内容中,解译标志是在训练阶段自动定义的,以优化类别的可分性。第 4 节描述了这种训练过程。

在不同的尺度上,存在着各种不同的方法来表征维度,代表着多尺度关系。例如分形维数(Burrough,1981)和多重分形分析(Wendt et al.,2007)。然而,这些并不能满足我们的需要。分形维数是一个单一的值,它综合了点云在多个尺度上的局部空间填充特性。它与上面提出的直观想法不匹配,我们的目标是在多个尺度上对点云维度的变化

建立解译标志。多重分形分析在一个光谱中进行综合，如何用指数拟合的方式在每个尺度上定义一个相互关联的显著地统计矩（想要得到更精确的定义，请参见 Wendt 等(2007)，我们只给出了主要的思想，因为这不是本文的主要主题）。不幸的是，根据定义，多重分形谱几乎在任何给定的尺度上都没有区别能力（也就是说，它通常适用于多个尺度）。我们的目标是在每个尺度上定义特征，然后使用一个训练样本来定义哪个尺度的组合允许最好地分离两个或更多的类别(例如地面或植被)。使用上述分形分析工具可能有一定程度的分类，但我们的新技术更直观，更适合我们所考虑的自然场景。在下面我们使用简单的例子描述多尺度维度特性，在盐沼泽环境中只存在两类地物：河岸植被(分散的斑块)和地面(细沙)(图 4)。更复杂的三维多类案例(如图 1 所示)在第 5.2 节中讨论。

3.1.给定尺度下的局部维度特征

设 $C = \{P_i = (x_i, y_i, z_i)\} i = 1 \dots N$ 是一个 3 d 点云，标度 s 在这里定义为以一个点为中心的球的直径，如图 2 所示。对于场景中的每一个点，邻域的球体都是在每个感兴趣的尺度下计算的，而主成分分析(PCA) (Shaw, 2003) 则是基于该点在球体中重新计算的笛卡尔坐标上进行的。

设 $\lambda_i, i=1 \dots 3$ 是 PCA 产生的特征值,按大小逐级递减: $\lambda_1 \geq \lambda_2 \geq \lambda_3$ 。方差比例定义为每个特征值的 $p_i = \frac{\lambda_i}{\lambda_1 + \lambda_2 + \lambda_3}$ 。

图 3 显示了所有可能比例的域。

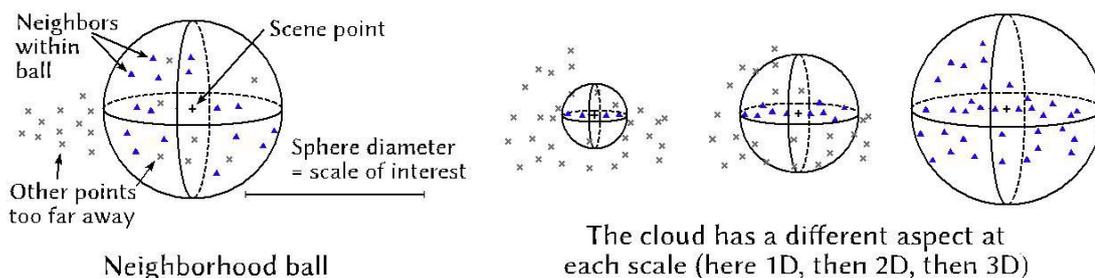


图 2 所示。不同尺度的邻域球。在这个描述中，外部点(灰色的星星)可以在旁边，也可以在邻居的球后面。

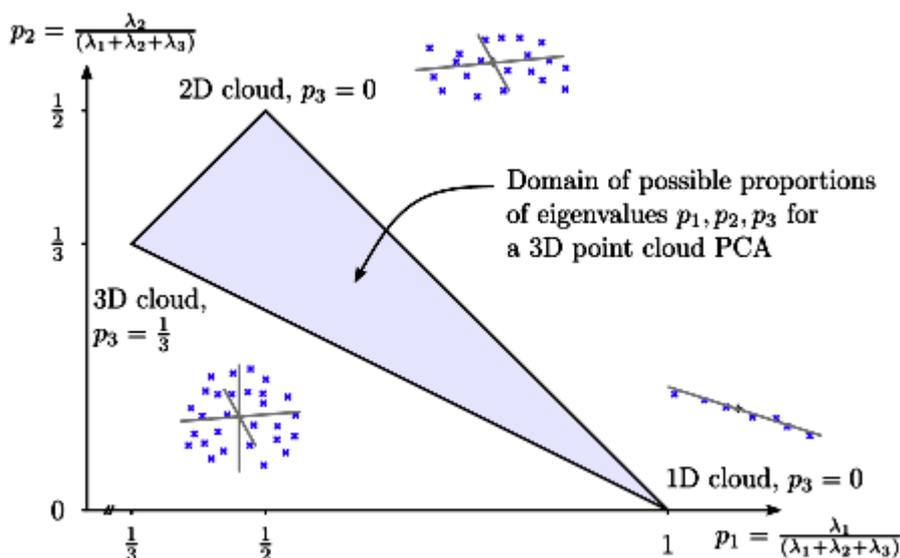


图 3 所示。表示一个三角形中局部邻域 PCA 的特征值重新划分。

当只有一个特征值 λ_1 解释邻域球的总方差时，点只在场景内参考点周围的一个维度上分布。当需要两个特征值来解释方差时，第三个特征没有贡献，这时点云主要是二维的。同样，一个完全三维的点云是一个所有三个特征值

都具有相同量级大小的云。因此，特征值的比例可以用来衡量在给定的尺度下，点云在局部出现的 1D、2D 或 3D 的程度(见图 2 和图 3)。在图 3 中，指定这些比例等价于在三角形域中放置一个点 X ，这可以用独立于三角形形状的重心坐标来完成。考虑到约束条件 $p_1 + p_2 + p_3 = 1$ ，度量点云 1D/2D/3D 维表现形式的双参数可以在任一给定点和尺度下进行定义。

在地面机器人导航(Vandapel et al., 2004;Lalonde et al., 2006)和城市激光雷达分类(Carlberg et al., 2009)的背景下，先前引入了一项有关自然地形分析的相关方法。在这些应用中，为了定义特征空间，PCA 的特征值仅被用作与三个阈值相比较的比值。在本研究中，我们不仅考虑了所有可能的特征值比例的全三角形，如图 3 所示，而且还考虑了多个尺度上的特征。尽管采用了不同的算法，计算机视觉重新搜索“张量投票”技术在我们的工作中使用特征值来量化激光雷达数据云的维度(Schuster, 2004;Kim 和 Medioni, 2011)。我们的工作是我们已知的最优的方法，尽快将局部维度特征与多个尺度相结合。因为 PCA 是一个简单而标准的工具，所以我们选用 PCA 在邻域球中找到相关的方向(Shaw, 2003)。其他投影技术(如非线性)当然可以用来定义邻域球几何的不同描述，但我们的结果表明，PCA 已经足够好了。

3.2.多尺度特征

在每一个感兴趣尺度内重复前一节中介绍的处理方法(见图 2)。给定一个尺度 N_s ，我们可以得到场景中每个点的 $2 \cdot N_s$ 值的特征向量。这个向量描述了特征点周围点云在多个尺度上的局部维度特征。在地基雷达数据中，因为阴影或边界附近点密度的降低，可能导致尺度缺失，尤其是最小的尺度。在这种情况下，最接近的更大尺度的几何性质被传播到缺失的一个尺度，以完成这个尺度下的 $2 \cdot N_s$ 值计算。图 4 展示了一个如何使用此方法进行四个尺度展示的示例场景。

注意到某一小块植被(图 4 中的蓝色)虽然在不同的尺度下定义了具有不同表现形式，但仍然可以与地面分开(红色)，这暗示了这两种可以进行分类的可能性。然而，其余的场景(未标记的灰点)在每一个尺度上都分布在整个三角形中：这些场景在任何给定的尺度下，植被和地面之间没有明显的分割界线。这个问题的解决方法是通过将多尺度向量在整个场景中作为一个高维的描述，而不是作为一个连续的二维空间来实现的。下一章将对此进行描述。

四、分类

分类过程背后的总体思路是，定义可量测维度的最佳组合，从而允许两个或多个类的最大可分性。实际上，用户可以直观地感觉到不同类别的地物在不同尺度范围上的几何特征是很不同的，但在很多情况下，由于形状和物体大小的自然变化，这不是一个简单的训练。因此我们依靠自动化建立一个可以找到最佳尺度组合的分类器(即使得所有尺度对最终的分类都有或多或少的影响)，使得用户自定义的两个类别的地物(即从点云中分割出来的植被样本和地面样本)具有最大可分性。在接下来的描述中，我们介绍了分类器的构造，然后在第 5 节中给出了典型分类结果并逐步应用到自然数据集。

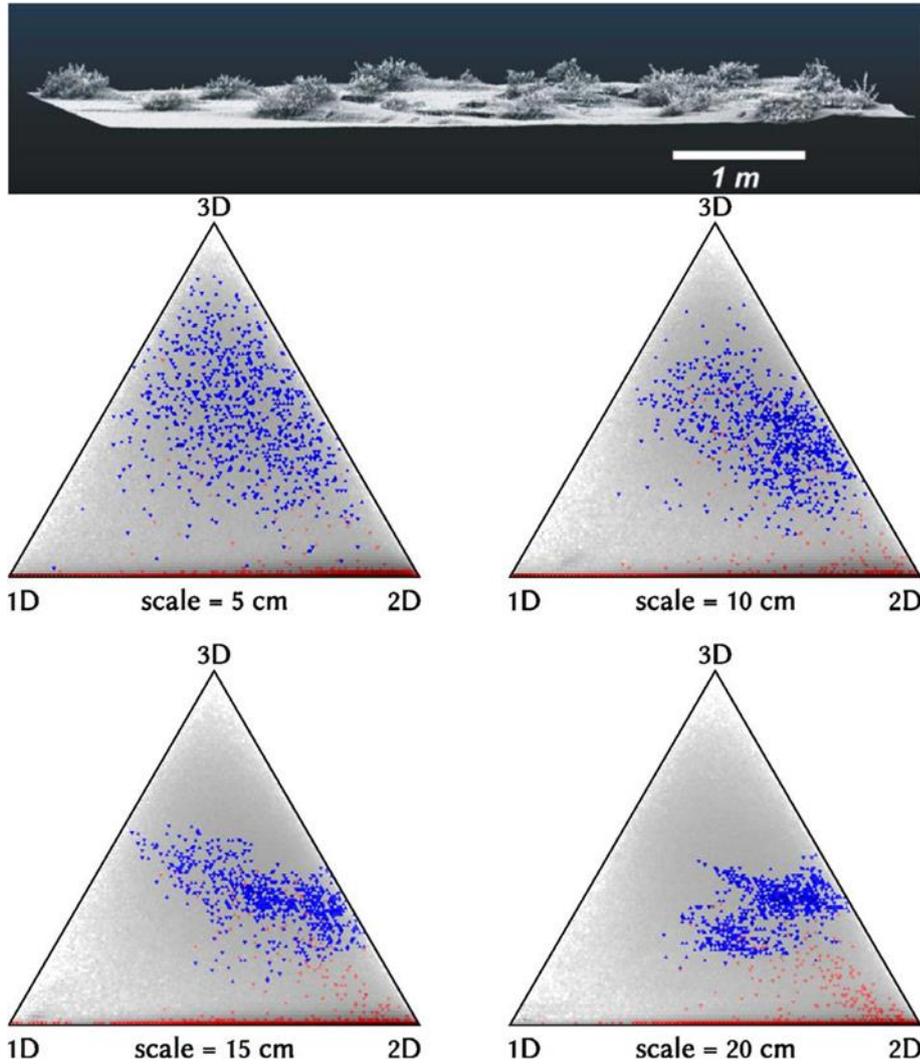


图 4 所示。在不同尺度的拟议特征空间中描绘的场景的密度图。顶部:摘自圣米歇尔湾盐沼泽(Fr)的一种点云,在先锋河岸植被和沙的区域(点距从 2.3 到 14 毫米)。底部:一个植被斑块的维度密度图(蓝色,以灰色显示为深灰色),一小块地(红色,在三角形右下方的二维区域显示为深灰色),以及场景的所有其他点(浅灰色)。每个三角形都是图 3 中的空间的线性变换的空间。

4.1.在最大可分性平面上的概率分类器

2. N_s 维度上的整个特征空间是为了定义一个分类器,可以在多个尺度上对不同的数据表现形式同时进行工作。这个分类器的定义有两个步骤:(1)通过将数据投影到最大可分性的平面上,(2)将该平面上的类分离出来。这么处理的主要优点是便于对分类过程进行监督。在最大可分性平面上的分类器的目视检查是非常直观的,这也使得分类器在需要时容易改进(例如,改变图 5 中的分离线,使其成为非线性分类器)。²

备注 2: 在这一点上,人工干预允许一个强大的模式识别,超出了在这里展示的简单分类器的能力。此外,一些实际应用可能要求每个类都有不平衡的精度。例如,一个人为了只留下一些地面点而可能更愿意把所有的植物都清除掉。在具有最大可分性的二维平面内,通过图形可调的分类器,方便的用户干预很好地提供了这两个优点:改进的模式识别和适应性。当然,自动配对处理也是可能的,事实上,它会形成默认的分类器,用户可以在这种情况

下进行干预。

最大类可分离性的平面就像一个 PCA，只有两个主要的部分被保留，只可惜它只是优化了一个类可分离性的标准，而不是像 PCA 那样最大限度地增加类间方差。原则上，任何允许在子空间上投影的分类器都可以在迭代过程中使用(包括带有内核映射的非线性分类器，参见 Maszczyk 和 Duch, 2008)。本工作使用了两个线性分类器:判别分析(Theodoridis and Koutrou, 2008)和支持向量机(Boser et al., 1992)。合理的方法是断言我们的新特性对区分自然对象类的有用性。通过这两种广泛使用的线性分类器的结果进行比较，验证了新引入的特性并不依赖于复杂的统计机制。我们强调最后一点:使用一个或另一个分类器在实践中几乎没有影响(见第 5.1 节的结果)，但是我们必须证明这是实际情况，使用简单的线性分类器就足够了。

设 $F = \{X = (x_0, y_0, x_1, y_1, \dots, x_{N_s}, y_{N_s})\}$ 是 $2 \cdot N_s$ 维度的多尺度特征空间，其中 (x_i, y_i) 是图 4 各个三角形中的坐标点。考虑点集 F^+ 和 F^- 分别由 +1 或 -1 对两类(例如: 植被和地面)进行标记。线性分类器提出了用一个超平面 F 使得 F^+ 和 F^- 完美分离。超平面是由 $w^T X - b = 0$ 与权重向量 w 和偏差 b 共同决定的:

- 线性判别分析提出设置 $w = (\Sigma_1 + \Sigma_2)^{-1} (\mu_2 - \mu_1)$ ，其中 Σ_c 和 μ_c 分别为 c 类样本的的协方差矩阵和样本的均值向量。
- 为使每个类中最近的样本到分离超平面的距离最大化，支持向量机设置了参数 w 。Shalev-Shwartz et al.(2007)和 King(2009)中描述的 Pegasos 方法用于计算 w ，因为它不仅适用于大量样本的情况，同时还保持了较高的精度。

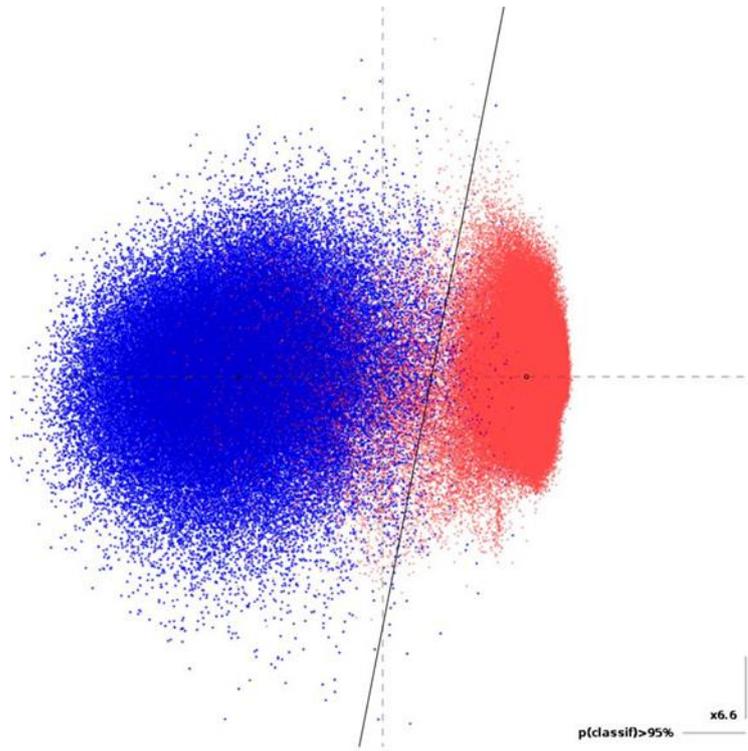


图 5 所示。在最大可分性平面上的分类器定义。蓝色(深灰色):植被样本。红色(浅灰色):土壤。分类器是通过使用第 4.1 节中描述的过程自动获得的一个线性支持向量机，以便对第 5.1 节中描述的基准进行分类。水平轴的置信

水平已经给出。Y 轴的缩放对自动分类性能没有影响，但是提供了一个更好的可视化，这在用户希望通过图形方式修改这个文件时特别有用。(为了解释这个图例中对颜色的引用，读者可以参考这篇文章的 web 版本。)

在每种情况下，用 Platt(1999)中描述的方法定义了偏差 b ，该方法给出了分类的概率解释:一个样本到超平面的距离 d 对应于一个分类置信值，内部估计是通过拟合逻辑函数:

$$p(d) = \frac{1}{1 + \exp(-ad)}。$$

特征空间 F 通过使用 w 和 b 投影到超平面，并且计算每个点到超平面的距离: $d_1 = w_1^T X - b_1$ 。将这个过程重复，以得到与第一个方向正交的最优方向以及与第二方向之间的距离 d_2 。然后把这对距离(d_1, d_2)作为坐标来定义最大可分性二维平面。在选择 w 和 b 时因为有 $w^T X - b = 0$ 的限制而仅有一定的自由度，两个坐标轴也可以进行调整，只需保证 $\alpha = 1$ 即可。因此，在可分离性平面中，坐标(d_1, d_2)与分类精度一致³。这种一致性允许在平面上进行一些后处理。在当前的定义中，大多数分类器会将数据压缩到 $X=Y$ 对角线上⁴。后处理包括旋转平面，使类中心对齐到 X 上，然后缩放 Y 轴，使类在两个方向上的平均方差相同。最后一步对在平面上绘制直线的自动配对分类器是完全中立的(无论最后怎样旋转和缩放，最优的分类线都可以被找到)。然而，现在可以更容易地在新旋转的和被调整的空间中可视化地识别每个类，如图 5 所示。该数据展示了使用第 5.1 节中给出的数据自动获得的分类器示例。在 X 轴上，得到了 95% 的分类可信度，并给出了 Y 轴的对应值。

备注 3: 根据我们的认识，这样定义一个平面上的最大可分性的二维可视化，同时保留对该平面尺度使用置信区间的做法，是这项工作的基础。

备注 4: 为了了解原因，假设以第一类为负坐标，第二类为正坐标，将数据投影在 X 轴上。同样也以类 1/2 分别为负/正坐标的形式投影到 Y 轴(第二个投影方向)。这样数据将主要集中在对角线上。

4.2.半监督学习

开发这种分类方法的一个目标是，在最大化分类器的普适能力的同时，将用户输入(即在场景中手动提取和标记数据)最小化。这是通过半监督学习实现的:使用无标记点的信息。最大可分性的平面只能用标记的例子来计算。我们在这个平面上寻找一个方向，使所有点的密度最小化(标记和未标记)，同时仍然分离标记的样本。假设类在投影空间中的形成集群，于是为了最小化未标记点的密度，就需要找到这些集群的边界。当没有额外的未标记数据时，类被一条具有相同概率的分割线简单地分开。

对于多类场景(参见第 5.2 节)，最终分类器是基本二进制分类器的组合。在这种情况下，没有标记的数据中的某些集群对应的是另一个类，而不是两个被分类的类，这将会与上述的密度最小化的相反。一个变通方法是只使用标记的示例，或者依靠人工视觉识别来手动地对集群进行分离。

更普遍的是，可视化和控制进程的能力(这不是一个“黑盒”工具)允许利用人工识别来更好地分离类。但是，

完全自动化操作得以保留，这对于大批量的处理是特别有用的。如果需要，用户在需要时可以随时查看分类器。

我们开发了一个非专业人员可用的工具:分类器是以一个简单的图形文件的形式提供的，用户可以使用任何通用的、通用的 SVG 编辑器进行编辑⁵。决策边界可以被图形化修改，从而快速定义一个非常强大的分类器，用户输入最少。这个步骤是完全可选的，默认的分类器当然可以不经修改就可以得到。

备注 5: 例如 Inkscape, 可在 <http://www.inkscape.org/> (as of 2012/01/19)查看

4.4.最优化

本算法最耗时的部分是计算点云在不同尺度计算点云的局部邻域，来应用 PCA 变换(见 4.1 节),以及 SVM 训练过程(即使是利用 SVM, 线性判别分析仍然十分快捷, 每种地物只需要对分类器训练一次)。我们通过计算一个核心点场景的子采样的多尺度特征来解决这些问题。整个场景的数据仍被考虑为邻域的几何特征, 但计算只在给定的核心点进行。

这是对激光雷达数据进行处理的一种自然方式:考虑到非均匀密度, 在密度最大的区域中, 计算每个点的多尺度特征的意义不大。一般来说, 核心点的空间均匀密度是足够的, 并且允许简单的场景操作和可视化⁶。然而, 在密度最大的区域中可用的额外数据仍然参与了 PCA 的操作, 这使得与远离数据点的遥远区域相比提高了精度。我们还保留了局部的密度信息, 以及每个核心点周围的分类置信概率, 以此来度量这种精确度。当对整个场景进行分类时, 每个场景都给出了最近的核心点的归属类。

由于用户提出了一个计算时间和空间分辨率之间的权衡:可以调用算法对整个场景(每个点是一个核心点) 或者在用户选择的子抽样上调用算法(例如, 核心点的均匀空间密度)。

备注 6: 使用像 CloudCompare (Girardeau-Montaut, 2011)这样的免费软件, 空间均匀的次采样和场景操作都很容易。

五、结果

5.1.地面和河岸植被分类的定量比较

为了定量地评价分类器的性能, 从先锋盐沼场景中选取出了一些例子(见图 4, 这种场景的一部分), 其中可以定义两个类:河滨植被和地面。这些例子包括各种植被斑块大小和形状, 阴影区域, 平坦地面, 小波纹, 数据密度变化和扫描仪定位。该数据集大约包含 64 万点, 人工划分为 20 万的植被和 44 万的地面。该数据集与软件(本文末尾给出的链接)一起在线提供, 因此可以用于比较基准测试。

分类器是经过训练的，在第一组例子中，使用上述数据的一半，从地面识别植被。然后，使用未被用于培训的另一半数据来评价它的性能。这不仅是机器学习领域的标准程序(当算法学习到某个特定数据集的细节，而不是与其他数据集(即过度拟合的问题)进行转换时)，这也适用于我们的新方法。我们的目标是一种优秀的泛化能力:算法必须能够识别未知场景中的植被，而不仅仅是在现在的样本上。

为了解释每个类中不同的点的数量，我们使用平衡精度度量来量化分类器的性能。设 t_v, t_g, f_v, f_g 分别表示植被(v)和地面(g)分类后正确(t)和错误(f)的点的数量，每类的分类精度为 $a_v = \frac{t_v}{t_v+f_v}$ 和 $a_g = \frac{t_g}{t_g+f_g}$ ，那么本次分类的平衡精度可以表示为 $ba = \frac{1}{2}(a_v + a_g)$ 。我们使用 Fisher 判别的比值 fdr (Theodoridis 和 Koutroum - bas,2008 年)来评估类可分性。每个样本的分类器都显示为一个点到分隔线的有正负的距离 d ，正负值各表示一类。当 μ_c 和 v_c 分别表示类 c 的正负距离的均值和方差时，类的可分性度量可以表示为 $fdr = (\mu_2 - \mu_1)^2 / (v_1 + v_2)$ 。注意到类的可分性仍然可能很高，尽管它的准确率一般(例如，在两个类的单面上放置分隔线)。这仅仅表明这是一种很差的训练方法，但可能会有更好的分离方法。因此， ba 和 fdr 都分别是评估分类器的作用和新引入的特性在最终分类结果中的有效评价。 ba 的值越大表明在给定的数据集上越具有良好的识别率($ba=50\%$ 表示随机的类赋值)，而 fdr 越大，表示类的分离效果越好(这表明 ba 的值是有鲁棒性的)。

表 1 显示了基准测试的结果。分类器使用完全自动化,不需要人工干预的决策边界,并以 2 至 20 厘米间隔 1 厘米分成 19 尺度(分类时较大尺度对不敏感,参见图 5 的典型植被大小 ≈ 40 厘米)。为了充分评估我们的算法在一般情况下的结果，我们使用了软件的默认质量/计算时间来权衡支持向量机分类器的训练。该算法被迫对每一个点进行分，而在实际操作中，用户可能无法决定哪些点不参加运算(参见 5.2 节)。然而，在训练集和测试集上的平衡精度都很好。这不仅表明该算法能够恢复人工选择的植被/土壤(训练集精度)，而且能够对以前未见过的地形数据进行归纳。这对于大型数据非常重要:我们可以在给定的数据类型上对算法进行一次训练，然后在不需要重新训练算法的情况下将分类器应用于大量点云的进一步测量。

表 1
将植被与地面分离的定量基准

		Accuracy (%)	ba (%)	fdr
LDA				
classifier				
Training set	Vegetation	98.3	97.9	12.3
	Ground	97.6		
Testing set	Vegetation	99.3	97.6	11.0

	Ground	95.9		
SVM				
classifier				
Training set	Vegetation	98.7	98.0	11.1
	Ground	97.3		
Testing set	Vegetation	99.6	97.5	11.0
	Ground	95.4		

每个分类器的性能都是用平衡精度(ba)和 Fisher 判别比(fdr)来衡量的。两者都在正文中有所描述。

表 2 只显示了使用单尺度的分类结果。使用多尺度分类器的优点是显而易见的:它的精度比单独的任何单一尺度都要高。区别更明显的是区分能力,多尺度分类器的类可分性几乎是单尺度的两倍。虽然这是预期的行为,但一些分类器对噪声敏感,并且如果只是增加尺度而不增加信息,会降低多尺度的性能。表 2 中未显示的 2 到 20 厘米的尺度具有相似的性质和分类的水平,在 5 到 10 厘米之间的单尺度效果稍好。即使有了这种观测到的性能峰值,在这个系统中也没有任何典型尺度,因为在所有尺度上都存在有区别的信息:多尺度分类器的点是预先确定地利用这些信息。

在这个例子中,两个分类器(LDA 和 SVM)在每个尺度上都给出相同的结果,并且同样适用于多尺度特性(表 1)。在其他场景中,情况可能会有所不同,但总的来说,这个例子证实了我们的方法不需要复杂的统计机制(比如 SVM),使用简单的线性分类器(如 LDA)就足够了。在任何情况下,我们至少可以达到 97.5%的分类准确率。

图 6 直观地展示了使用全自动化程序获得的多尺度 SVM 分类器对测试数据子集的分类结果。带有低分类置信率的点用蓝色突出显示。它们主要与地面和植被的边界相对应。图 6 表明,该算法能很好地处理具有不规则密度的点、阴影区和波纹。实际定义的分类器如图 5 所示。

表 2

在选定范围内的单尺度测试结果

LDA and SVM	5 cm		10 cm		15 cm		20 cm	
	ba (%)	fdr						
Training	97.0	5.2	97.1	6.5	96.6	5.6	95.7	4.6
Testing	97.3	6.4	96.9	6.5	95.7	4.8	94.1	3.7

两个分类器的结果仅在平衡精度 (ba) 的第四位和 Fisher 判别的第三位有所不同,因此合并了表。

5.2.多个类的 3D 多尺度分类器

5.2.1.多个类的处理

在机器学习(Shiraishi 和 Fukumizu, 2011 年)中,将多个二进制分类器组合成一个单独分类器来分离多个类是一个长期存在的问题。通常,该问题是通过训练“一对一”(或“一对多”)的基本二进制分类器来解决,然后由少数

服从多数规则进行分类器组合。上文提及的正是自动化工具套件 CANUPO 的特点，而且遵循领域中的惯例。

在将来的工作中，很可能会有额外的扩展。高级统计技术(Shiraishi 和 Fukumizu, 2011)最近的发展解决了样本训练的问题，并做到了与分类器相结合。然而，在当前的文本中，我们希望保留使用图形化编辑器对分类器的干预能力。此外，与上下文相关的选择也需允许，比如支持一个类，而不是另一个类。因此，将各个类单独分开并把重新生成的内容组合在一起会更有效，就像在下一节中解释的那样。

5.2.2.应用于复杂的自然环境

在接下来的文章中，我们介绍了将复杂的 3D 自然场景分类的方法。选择了 Otira 河场景的一个子集(图 1)，定义了四个主要的类:植被,基岩表面(位于河岸并且呈大块状区域),砾石表面和水。图 7 给出了不同类的维度密度图,尺度范围从 5 到 50 厘米不等。正如我们所预料的,植被在小尺度(叶子、茎)上大多是一维和二维的,并且在大于 15 厘米的尺度上成为显性的 3D。然而,点的聚类只在大于 20 厘米的尺度上表示。基岩的表面大多是二维的,在小尺度上和有断裂的情况下有些会呈现一维二维特征。由于颗粒大小的不均一性,砾石表面在所有尺度上呈现出较大的不确定性。在中等尺度(10-20 厘米)中,3D 组成比在非常小或非常大的尺度上更重要。这说明了分析尺度的变化比砾石直径小(即砾石看起来是显性的二维曲面),但是比砾石的组合(即砾石的粗糙度消失)大。在第 2 部分中,激流表面可以被激光反射,而一般情况下,清澈的水中不会反射(米兰等人, 2010)。然而,即使在很小的尺度上,水的表面也不完全是二维的,因为水的表面是凹凸不平的,而且激光穿透了泡泡水表面的不同深度。实际上,当尺度达到 20 厘米后,这个标志是多维的,而且只有大约在 20 厘米,水表面才会看起来明显地聚集在 2D-3D 的维度上。在更大的尺度上,水会变成更明显的二维。

各个类的多尺度属性表明,通过它们的维度特征没有一个单一的尺度可以区分类。植被和基岩在大尺度上是截然不同的,但是基岩、砾石和水在这个尺度上太相似,不能被很准确的标示开。只有在较小的尺度(10-20 厘米)才能区分出基岩和水。这种形象化也显示出,在所有的尺度上,砾石和水都很难区分,因为所有尺度上它们的维度特征都非常相似。

在接下来,我们每类大约选择了 5000 个核心点来进行训练。他们用整个场景的点云来估计他们的多尺度的特征,而不是只使用某一类的一部分。在原始场景中,点的最小间距为 1 厘米,对应于 117 万点。实际的分类操作在 33 万核心点的子集,最小间距为 2 厘米。多类标签使用了一系列的三个二进制分类器(图 8),它们都使用相同的 22 个尺度(从 2 厘米到 1 米)。一个自动的分类化(即唯一的用户交互是定义类和训练初始集),以及可能的用户变更的例子。这些改变有三种类型:改变初始训练集,修改分类器,定义分类置信区间。考虑到用户的改善取决于具体的项目(例如,对植物进行记录,描述谷物的大小或测量表面的变化),这些无法完全在这里一一讨论。在此基础上,对基岩表面的分类进行了初步的优化。LDA 方法用于所有分类器定义,因为结果与 SVM 相比相同或略好。图 9 给出了原始数据的结果,自动的以及用户改进的分类结果。

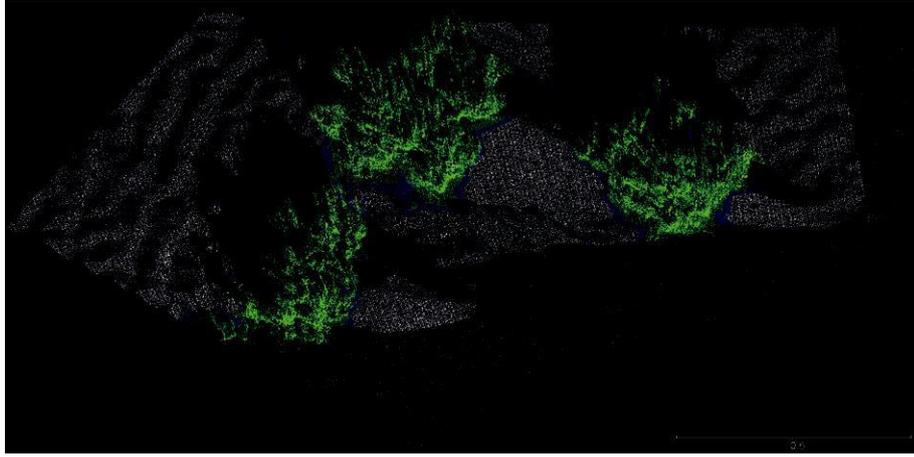


图 6 所示。这是定量基准测试集分类的一部分。白色:被认为是地面的点。绿色(浅灰色):被认为是植物的点。蓝色(深灰色):分类置信度不足 80%的点。比例尺为米(为了解释这个图图例中对颜色的引用,读者可以参考这篇文章的 web 版本)。

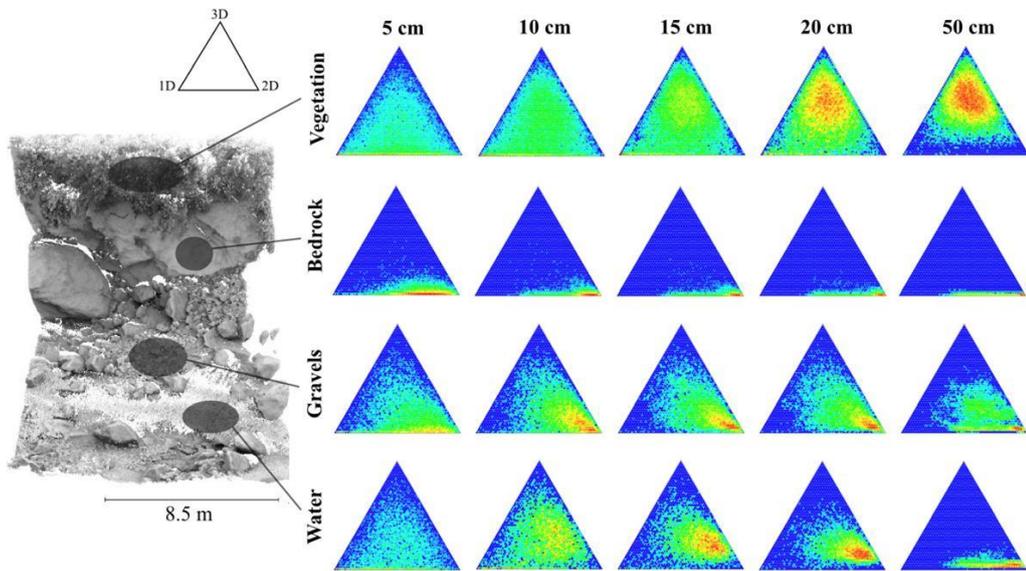


图 7 所示。多尺度、多层次的场景。左:摘自图 1 的点云。右:山河环境的四类主要类别的维度图,尺度范围从 5 到 50 厘米不等。从蓝色到红色的颜色对应于训练数据集的点密度,并描述了给定尺度的聚类程度。

第一个分类器将植被与其他三个类分开。在训练集上自动训练的分类结果是一 ba 约等于 99.66% 的值对植被进行了几乎完美识别。极高的可分离性反映在了一个大的 fdr 值(11.67)和一个很小的分类不确定性(图 8)中。如图 9 所示,植被的自动分类非常准确,在大块状区域的悬垂部分,由于几何形状在不同尺度上表现出了与植被相似的维度,使得这部分分类结果出现了非常少量的误判。标记的精度也很好,因为植被之间或底部的小部分基岩被正确识别,小灌木在基岩表面也被正确地分开。然而,如果在训练过程中使用未被正确分类的悬垂块(增加 5000 个核心点),仍有可能改进这个分类器。这 5 个最小值操作导致更好的处理错误植被指数,并且保留了原始训练集的优秀特征($ba = 98.2\%, fdr = 9.89$)。在 CloudCompare 软件(girardeo - montaut, 2011)中,通过显示每个核心点的不确定度,并定义一个具有最佳质量和覆盖率的分类,可以将 90% 的分类置信区间可视化。这就剩下了 5.7% 的原始场景没有标记。

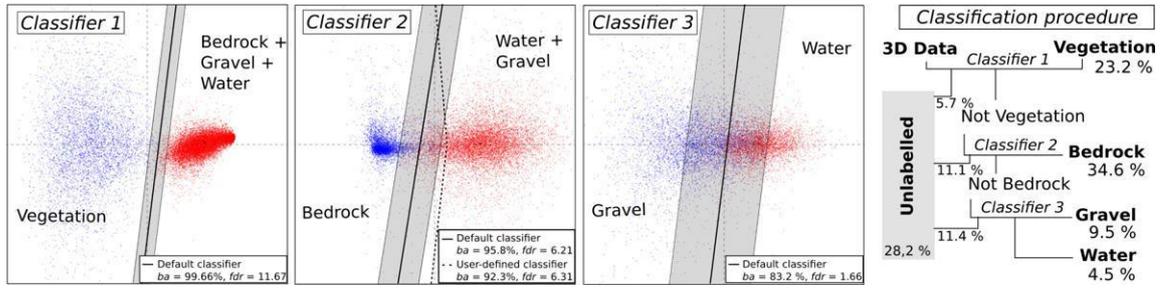


图 8 所示。多尺度案例的分类过程和分类器。用于 Otira 河数据集半监督分类器和分类过程图。对于每个分类器，灰色区域表示分类置信值低于 0.95 的部分空间。对于分类器 2，手动修改的监督分类器的目标是以牺牲非基岩表面的代价保护更系统的基岩表面。在分类过程图中，百分比表示在监督分类中每个类的比例，该分类使用 0.9 的置信区间为分类器 1，0.8 用于分类器 2 和分类器 3。

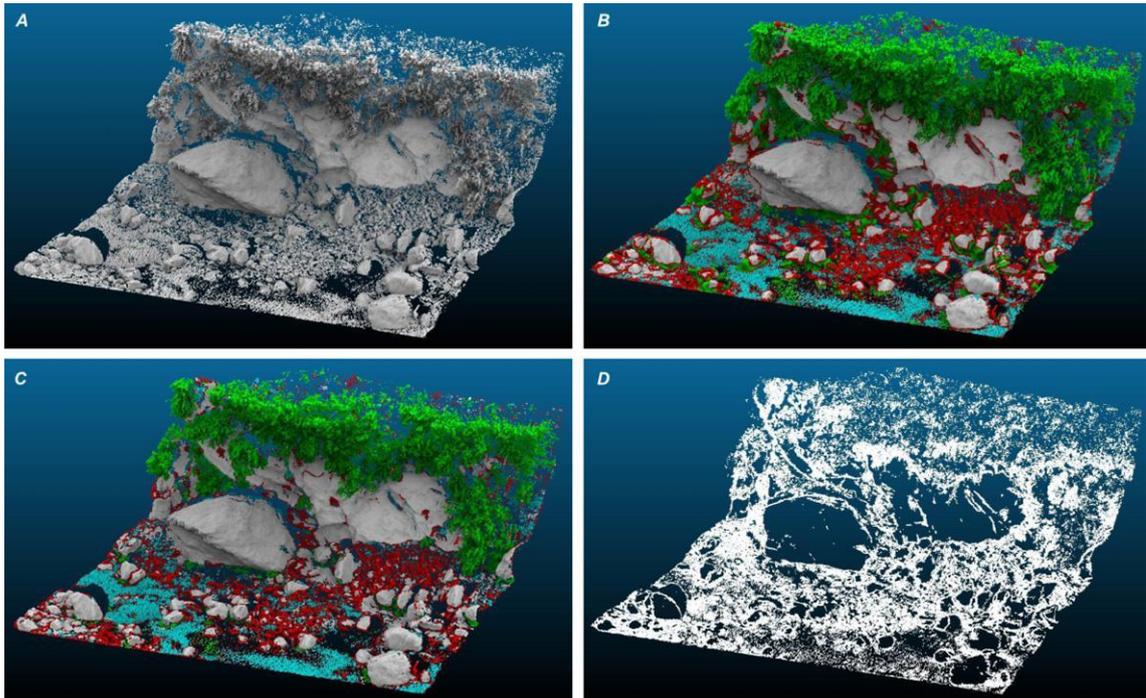


图 9 所示。山河数据集分类过程的结果。(A)原始的 Otira 河景(最小点间距= 1 厘米)。(B) 根据图 8 所描述过程的默认分类(绿色:植被，灰色:基岩，红色:砾石，蓝色:水)。(C)用户自己改善后的分类。(D)未标记点(占总点数的 28.2%)。

分类器 2 将基岩表面与水和砂砾表面分开(图 8)。对原有的训练集进行自动化训练分类得到了 $ba=95.7$ 和 $fdr=6.21$ 结果。由于砾石的尺度范围很大，从小圆石到大卵石，不可能完全把基岩和砾石类分开，因为最大的砾石往往被定义为岩石表面。块体的断裂和锐边往往被划分为非基岩，因为它们在小尺度上表现为三维特征，而在大尺度上表现为二维特征(如砾石)。然而，与前一种情况一样，置信水平为 0.95 的分类结果与在投影空间中两个集群的大小相比仍然很小。虽然原始分类器已经相当令人满意，但它主要通过手动改变超平面投影中的分类器位置来调整岩石表面($ba=92.3\%$ ， $fdr=6.31$ ，图 8)。当分类置信区间为 80% 时，剩下了 17% 未标记(图 9)。

分类器 3 将水与砂砾表面分开(分类器 3，图 8)。自动训练程序结果为 $ba=83.2\%$ 。根据维度密度图的相似性(图 7)，这两个类比前两个分类更难分离，而 0.95 的置信水平是在两个类上的显著重叠。然而，图 9 显示分类器成功

地将非训练数据集中的激流和砾石表面做了正确标记。在颇为有效的情况下，默认的分类器没有被改变。在 80% 的置信区间下，标记了 78% 的剩余点。

这个分类过程的最终结果是一个 3D 场景(图 9)。如图 9 所示，默认参数已经给出了一个优秀的一级分类。先前所描述的微调并不代表最佳的分类，而是一个如何快速调整自动化方法以提供改进的示例。实践表明，在本例中，改进默认分类器的最简单方法是在训练过程中添加第一次训练的假阳性和假阴性结果，而不是手工修改分类器。在分类过程中定义一个置信水平是非常有用的，因为数据量如此之大，以至于只标注 70% 的分数并不会对结果的解释造成不利影响。通过多尺度分析中计算出的数据量密度移除孤立点，可以进一步净化这些类

表 3
单尺度和多尺度分类器的平衡精度比较.

Scale (cm)	Classifier 1 vegetation		Classifier 2		Classifier 3 water, gravel	
	ba (%)	fdr	ba (%)	fdr	ba (%)	fdr
2-100	99.66	11.67	95.7	6.21	83.2	1.66
5	67.51	0.18	78.75	1.04	70.28	0.32
10	58.6	0.03	88.47	1.89	69.36	0.46
20	82.23	1.76	92.15	2.84	62.03	0.14
50	95.59	5.73	85.24	1.56	68.28	0.41
75	98.24	7.55	79.85	1.03	69.85	0.43
100	98.98	8.2	78.74	0.77	70.9	0.50

利用 Otira 河分类器的原始训练集，对单级和多尺度的半监督 LDA 分类结果(图 8)。结果与 SVM 方法相似。

5.3. 单尺度 vs 多尺度分类

表 3 展示了在 Otira 河场景中使用的三种分类器(图 8)的平衡精度，使用相同的子集但单一的空间尺度(5、10、20、50、75 或 100 厘米) 进行训练。对于每一个分类器，多尺度分类的平衡精度比单尺度分类更系统。对分类器 3(单个类的 83.2% vs 70.9%)的改进非常有意义。最重要的是，类的可分性(由 fdr 测量)在分类器 2 和 3 中总是至少提高 2 到 3 倍(而对于分类器 1 来说，则增加了 40%)。提高可分离性是多尺度方法的关键优势。在给定的类中，它允许较大的几何不均匀性，并且比单一尺度的方法更能概括结果。

相比于 1 m 的单尺度分类，多尺度分类器 1(植被与非植被)的改善显得更小。然而，通过对 Otira 河数据的分类

结果进行比较, 多尺度分类器比单尺度分类器更精确:在基岩内的小灌木, 在单尺度分类器中没有被正确分类, 但用多尺度方法可以正确归类。类似地, 两个分类器在石块下的错误分类区域都可以用单一分类器进行扩展。因此, 多尺度分类是定性地改进的, 并不只是由定量的 ba 度量所反映出来的。

我们得出的结论是, 多尺度分析与单一尺度分析相比, 在一个或多个方面都有显著的改进:辨别能力、分类的可分性和空间分辨率。

六、开放性讨论

虽然许多研究都集中在地面和植被的分类上, 和 2.5D 机载激光雷达数据中, 并且常用的分类方法为纯几何方法(例如, Sithole 和 Vosselman, 2004 年; Anton-arakis et al., 2008; Carlberg et al., 2009), 但这些研究没有一个能够真正应用于从地面(固定或移动的)激光雷达数据中获得的高密度的三维点云, 在这种数据处理中需要一个真三维的方法。这种 3D 方法是在给定的尺度下采用维度测量方法(Vandapel et al., 2004; Lalonde et al., 2006)探测 1D(如树干或电缆), 2D(地面)和 3D(植被)地物。然而, 由于自然表面具有大量的特征尺度, 在一个给定的类中, 自然物体具有很大程度的几何异质性(即植被或沉积物), 单个尺度很少能对整个场景进行分类。因此, 我们引入了点云局部的多尺度几何分析来处理上述问题, 利用这种方法即使是简单的线性分类器, 也表现出良好的性能。通过这样做, 不需要选择一个特定的特征的尺度。我们已经证明, 与单一尺度分析相比, 不同尺度的组合系统地提高了类的可分性(表 3, 表 1 对表 2), 并且有时是非常显著的。相比单一尺度的分析方法, 多尺度分析允许保留一个精细的空间分辨率。为了进一步应对自然环境的几何复杂性, 用户可以自由地在分类过程中设置一定程度的置信区间, 从而控制对分类的准确度和覆盖率之间的平衡。考虑到 TLS 中可用的大量数据, 为了保证 70% 的数据可以被正确的分类, 通常会保留 30% 的数据不进行分类。

因为所有尺度都会对分类过程产生不同程度的影响, 该方法对阴影效果, 缺失数据和不规则的点密度(例如如图 9b 和 6)具有较强的鲁棒性: 即使某一维数特征不能超过相应范围的尺度(如小的尺度下的点密度影响和大尺度下的阴影影响), 即使置信度较低, 其它尺度仍用于分类其他点。有趣的是, 对分类结果的定性检验表明, 在物体边缘产生的明显的杂散点往往被分类为低置信度(前提是场景的点密度相对较高, 小尺度的维度特征对分类有显著的贡献)。这可以由混合点附近的低密度(因为没有真正的物体存在于它们的位置)和由此产生的在小尺度缺乏一个良好的维度特征来解释。虽然已经系统的量化了这项工作是否超出了范围, 但这一观察结果表明, 在分类过程中使用相对较高置信度, 有助于净化生成的类的错误混合点。

我们选择了点云的维度作为局部场景几何的连续度量。这是一种直观的表面感知, 可以捕捉到自然几何的许多方面(Vandapel et al., 2004; Lalonde et al., 2006), 特别是三维植被与二维表面的二分法。然而, 根据分类的最终目标, 多尺度分类也可以使用其他的几何测量方法。表面定向, 曲率, 局部表面的数学导数(Barnea 等, 2007)或给定几何的相似度(球面, 圆柱, ...Vosselman et al., 2004)也可以用于分类器的构造。表面垂直角已经在分类器中实现, 但在这里没有使用。例如, 它可以用来将河流的河岸与河床分开, 或者作为一种附加的约束来区分水面和碎石

(相对于水来说，它很少是完全水平的)。我们注意到，对于三维点云的植被分类，维度测量是特别有效的方法，也很容易定义。事实上，即使是在一个精心选择的单尺度上，维数标准也能很好地检测植被(例如图 10)(Vandapel 等人，2004;Lalonde et al .,2006)

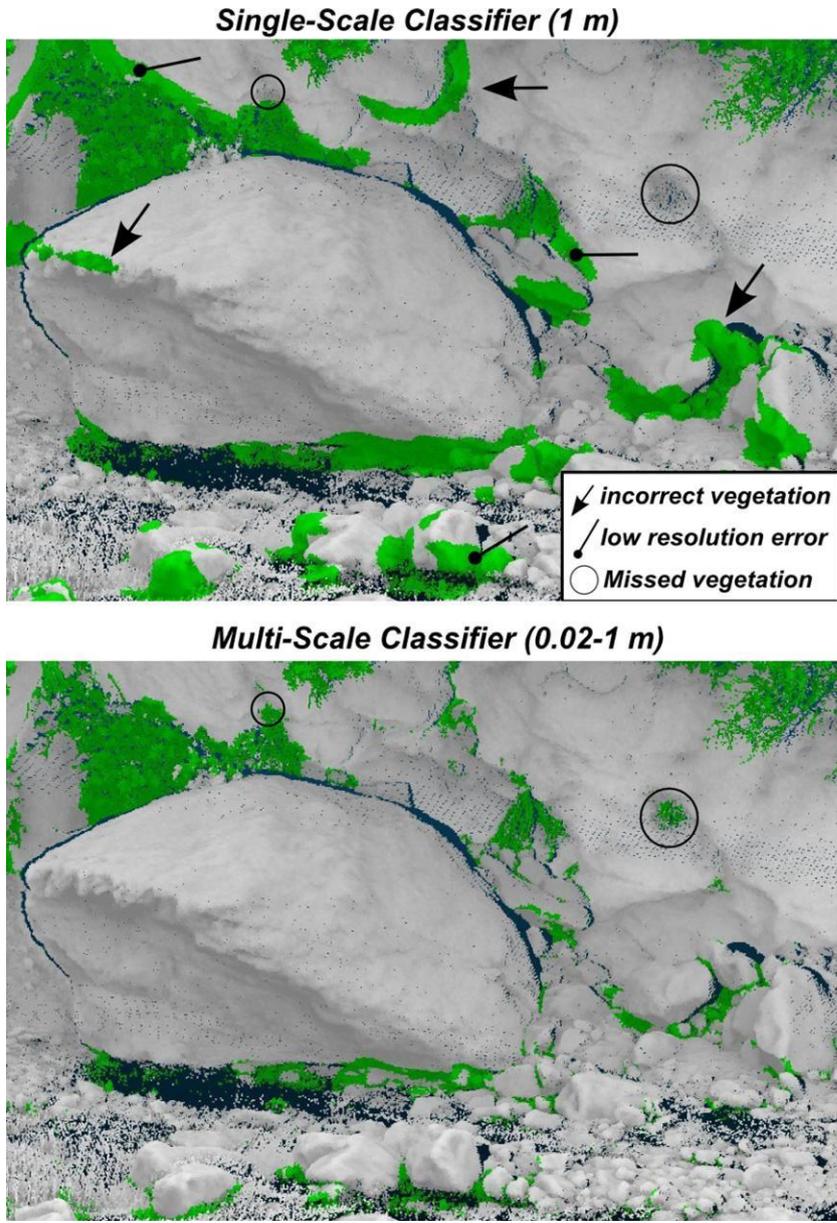


图 10 所示。最佳单尺度植被分类器与多尺度分类器的比较。利用多或单尺度(1 m)分类器进行植被检测的分类结果。虽然在训练集上的平衡精度是相似的，但多尺度分类更精确，在推广到整个场景时更不易出错。单尺度分类器忽略了基岩上的小灌木，错误地将大块边界划分为植被。

激光雷达(机载或地面)捕获的每一个点都有对激光反射强度的测量，在某些情况下，可以使用光学图像信息(RGB)来进行分类。机载(例如 Hasegawa, 2006;Hofle and Pfeifer, 2007)和陆基激光雷达(Franceschi et al., 2009;Pesci Teza,2008;Lichti,2005;Guarnieri et al .,2009;Kaasalainen et al .,2011)已经分别尝试了利用反射的激光强度进行分类。在后一种情况下，有很多困难，例如反射强度是距离扫描器、入射角和表面反射率(Kaasalainen et al., 2011;Lichti, 2005)(除了材料本身的物理化学特性外，还取决于表面湿度和微粗糙度 (Franceschi et al., 2009;Nield et

al., 2011; Pesci Teza, 2008)。在简单的情况下，距离和入射角并没有发生很大的变化(例如，悬崖调查)，激光强度可以用来比较有效地区分材料(Franceschi et al., 2009)。在简单的自然环境如在滩上的河岸植被中，它还可以提高基于简单几何参数的分类器的鲁棒性(Guarnieri et al., 2009)。然而，对于像 Otira 河这样的复杂场景，由于距离、入射角和表面状态(湿表面 vs 干表面)的巨大变化，激光雷达强度更难以使用。此外，扫描仪制造商之间不存在标准，这样即使表面反射率不受其他因素影响，它也不一定比得上不同扫描测量，而不是可用于任何来源的几何描述(即分类器可以独立于用户获取数据所用的扫描仪)。由于在复杂的三维场景中，激光反射强度并不是全局的，也不是始终一支的，因此我们得出结论，它还不能作为复合三维自然场景的主要分类器。随着反射强度的精确几何校正因子(如 Kaasalainen et al., 2011)的发展，为了提高几何分类的分辨率和准确性，未来其可能会包含分类器训练和后续分类的过程。这方面的准备已经包含在软件中。

在机载激光雷达的情况下，几何信息和图像的结合可以显著提高分类质量(如 Dalponte et al., 2008)。然而，RGB 图像很少在三维地面激光雷达分类中使用(Lichti, 2005)。最主要的原因是，从地面上获得具有空间一致性的三维复杂场景 RGB 图像要比从空中要困难得多。事实上，越具有 3D 特征的越复杂的场景，从地面和不同的角度得到一致曝光就越难。例如，在 Otira 河的情况下，由于狭窄的峡谷结构和植被的存在，阴影在一天内的变化程度是很明显的。在河流环境中常见的湿表面相对于干表面也有不同的光谱特征。此外，在新一代全波型多回声扫描器中 RGB 图像不能区分第一次或最后一次激光反射。然而，在河滨植被案例中(图 6)，由于植被和沙床的光谱特征差异很大，可以预测，使用 RGB 分类(Lichti, 2005)能够得到良好的分类效果。但是，这需要在没有强阴影的情况下拍摄图像，而在莱卡 Scanstation 2 的情况下，机载相机的分辨率较低，而且在点云上缺少精确的配准(通常是 50 米的几厘米差)。对平坦和波纹区域进行分类仍然需要几何分析。

因为它是三维的，我们的方法可以用在 2.5D 的空中激光雷达或大部分 2D 点云(Guarnieri et al., 2009; 霍奇 et al., 2009; 米兰 et al., 2010; Sithole Vosselman, 2004)。如河滨植被示例所示，它允许直接提取原始数据上的植被，而不需要构造一个栅格 DEM。由于点的密度较低，且在全波形空中激光雷达中所能描述的树木的尺度范围比地面激光雷达的范围小，因此不确定该方法是否比现有的航空数据更好地定义地面。然而，作为表面的一般几何分类器，它的效果应该比较好。虽然在本研究中没有使用，但多尺度计算也记录了最大尺度下局部表面的垂直角度。这可以作为一个额外的约束来检测道路上的建筑物。

七、结论

我们介绍了一种新的三维点云分类方法，根据其几何特征对特征进行分类，称为多维度分析。我们在两种情况下证明了这种方法的适用范围:(1)在圣米歇尔湾，将河岸植被与地面分离开来，(2)在陡峭的山河河床中识别岩石、植被、水和砾石。在每种情况下，分类都是非常准确的。该方法对地面激光雷达数据中常见的数据丢失和分辨率变化具有很强的鲁棒性。该方法结合各种尺度，系统地表现出比单尺度分析更好的方法，提高了分类的空间分辨率。

多尺度维数分析在将植被与其他数据分离的过程中，证明了它的有效性。在自然环境研究中，去除(或研究)植被是一个常见的问题，这种方法在这种情况下是有用的，因为它可以直接处理原始数据。典型的应用包括在河流环

境中研究地面的沉积/侵蚀模式(Wheaton et al., 2009), 岩石表面分析, 而其上的植被会称为噪声(Labourdette and Jones, 2007; Rosser et al., 2007)或分析植被类型及其与水文沉积过程的关系。

我们特别对机器学习领域的非专业人士提供了可用的工具, 同时也保留了自动处理大批量数据的能力。第一作者主页上的有这个工具集的免费、开放软件⁷。因为它只依赖于几何属性, 所以可以在用户之间进行分类器参数文件的交换, 并在不经过训练分类器的过程中应用于任何几何数据。

备注 7: 参见 <http://nicolas.brodu.numerimoire.net/en/recherche/canupo/> (as of 2012/01/19).

致谢

Daniel Girardeau-Montaut 因其正在开发的免费的点云分析和可视化软件 CloudCompare (Girardeau-Montaut, 2011)而得到了极大的承认, 该软件用于可视化和点云的分类。这些一直进行的研究得到了 European Research Executive Agency in the framework of the Marie Curie International Outgoing Fellowship €ROSNZ for D. Lague 的支持, 和 RISC-E(跨学科研究网络在复杂系统环境)给 N. Brodu 的项目的支持。

参考文献:

Abellán, A., Calvet, J., Vilaplana, J.M., Blanchard, J., 2010. Detection and spatial prediction of rockfalls by means of terrestrial laser scanner monitoring. *Geomorphology* 119 (3–4), 162–171.

Abellán, A., Vilaplana, J.M., Martínez, J., 2006. Application of a long-range terrestrial laser scanner to a detailed rockfall study at vall de núria (eastern pyrenees, spain). *Engineering Geology* 88 (3–4), 136–148.

Antonarakis, A.S., Richards, K.S., Brasington, J., 2008. Object-based land cover classification using airborne lidar. *Remote Sensing of Environment* 112 (6), 2988–2998.

Antonarakis, A.S., Richards, K.S., Brasington, J., Bithell, M., 2009. Leafless roughness of complex tree morphology using terrestrial lidar. *Water Resources Research* 45, W10401.

Antonarakis, A.S., Richards, K.S., Brasington, J., Muller, E., 2010. Determining leaf area index and leafy tree roughness using terrestrial laser scanning. *Water Resources Research* 46, 1–12.

Barnea, S., Filin, S., Alchanatis, V., 2007. A supervised approach for object extraction from terrestrial laser point clouds demonstrated on trees. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 36 (Pt. 3), 135–140.一种从地面激光点云上进行物体提取的监督方法。

Boser, B., Guyon, I., Vapnik, V., 1992. A training algorithm for optimal margin classifiers. In: *Fifth Annual Workshop*

on Computational Learning Theory. COLT'92. ACM, New York, NY, USA, pp. 144–152. <http://doi.acm.org/10.1145/130385.130401> (accessed 25.01.12).一种优化边缘分类器的训练算法。

Burrough, P.A., 1981. Fractal dimensions of landscapes and other environmental data. *Nature* 294, 240–242.景观和其他环境数据的分形维数。

Carlberg, M., Gao, P., Chen, G., Zakhor, A., 2009. Classifying urban landscape in aerial lidar using 3D shape analysis. In: 16th IEEE International Conference on Image Processing, pp. 1701–1704.

Dalponte, M., Bruzzone, L., Gianelle, D., 2008. Fusion of hyperspectral and lidar remote sensing data for classification of complex forest areas. *IEEE Transactions on Geoscience and Remote Sensing* 46 (5), 1416–1427.

Franceschi, M., Teza, G., Preto, N., Pesci, A., Galgaro, A., Girardi, S., 2009. Discrimination between marls and limestones using intensity data from terrestrial laser scanner. *ISPRS Journal of Photogrammetry and Remote Sensing* 64 (6), 522–528.

Girardeau-Montaut, D., 2011. Cloudcompare, a 3D point cloud and mesh processing free software. Technical Report, EDF Research and Development, Telecom ParisTech. <http://www.danielgm.net/cc/> (accessed 19.01.12).其中Cloudcompare一个三维点云和网格处理的免费软件。

Guarnieri, A., Vettore, A., Pirotti, F., Menenti, M., Marani, M., 2009. Retrieval of small-relief marsh morphology from terrestrial laser scanner, optimal spatial filtering, and laser return intensity. *Geomorphology* 113 (1–2), 12–20.

Hasegawa, H., 2006. Evaluations of lidar reflectance amplitude sensitivity towards land cover conditions. *Bulletin of the Geographical Survey Institute (Japan)* 53 (6), 43–50.

Heritage, G., Milan, D., 2009. Terrestrial laser scanning of grain roughness in a gravel-bed river. *Geomorphology* 113 (1–2), 4–11.

Hodge, R., Brasington, J., Richards, K., 2009a. Analysing laser-scanned digital terrain models of gravel bed surfaces: linking morphology to sediment transport processes and hydraulics. *Sedimentology* 56 (7), 2024–2043.

Hodge, R., Brasington, J., Richards, K., 2009b. In-situ characterisation of grain-scale fluvial morphology using terrestrial laser scanning. *Earth Surface Processes and Landforms* 34 (7), 954–968.

Hofle, B., Pfeifer, N., 2007. Correction of laser scanning intensity data: data and model-driven approaches. *ISPRS Journal of Photogrammetry and Remote Sensing* 62 (6), 415–433.

Kaasalainen, S., Jaakkola, A., Kaasalainen, M., Krooks, A., Kukko, A., 2011. Analysis of incidence angle and distance effects on terrestrial laser scanner intensity: search for correction methods. *Remote Sensing* 3 (10), 2207–2221.

Kim, E., Medioni, G., 2011. Urban scene understanding from aerial and ground lidar data. *Journal of Machine Vision and Applications (IJMVA)* 22 (4), 691–703.

- King, D.E., 2009. Dlib-ml: a machine learning toolkit. *Journal of Machine Learning Research* 10, 1755–1758.
- Labourdette, R., Jones, R.R., 2007. Characterization of fluvial architectural elements using a three-dimensional outcrop data set: Escanilla braided system, south-central pyrenees, spain. *Geosphere* 3 (6), 422–434.
- Lalonde, J.-F., Vandapel, N., Huber, D.F., Hebert, M., 2006. Natural terrain classification using three-dimensional Ladar data for ground robot mobility. *Journal of Field Robotics* 23 (10), 839–861.
- Lichti, D.D., 2005. Spectral filtering and classification of terrestrial laser scanner point clouds. *The Photogrammetric Record* 20 (111), 218–240.
- Lichti, D.D., 2007. Error modelling, calibration and analysis of an AM-CW terrestrial laser scanner system. *ISPRS Journal of Photogrammetry and Remote Sensing* 61 (5), 307–324. AM-CW 地面激光扫描系统的误差建模、校准和分析。
- Lim, E.H., Suter, D., 2009. 3D terrestrial lidar classifications with super-voxels and multi-scale conditional random fields. *Computer-Aided Design* 41 (10), 701–710. 三维地面激光雷达分类，具有超 voxels 和多尺度条件随机字段。
- Maszczyk, T., Duch, W., 2008. Support vector machines for visualization and dimensionality reduction. In: *Proceeding of the International Conference on Artificial Neural Networks, LNCS*, vol. 1, pp. 346–356. 支持向量机可视化和降维
- Milan, D.J., Heritage, G.L., Hetherington, D., 2007. Application of a 3D laser scanner in the assessment of erosion and deposition volumes and channel change in a proglacial river. *Earth Surface Processes and Landforms* 32 (11), 1657–1674.
- Milan, D.J., Heritage, G.L., Large, A., Entwistle, N., 2010. Mapping hydraulic biotopes using terrestrial laser scan data of water surface properties. *Earth Surface Processes and Landforms* 35 (8), 918–931.
- Nagihara, S., Mulligan, K.R., Xiong, W., 2004. Use of a three-dimensional laser scanner to digitally capture the topography of sand dunes in high spatial resolution. *Earth Surface Processes and Landforms* 29 (3), 391–398.
- Nield, J.M., Wiggs, G.F.S., Squirrell, R.S., 2011. Aeolian sand strip mobility and protodune development on a drying beach: examining surface moisture and surface roughness patterns measured by terrestrial laser scanning. *Earth Surface Processes and Landforms* 36 (4), 513–522.
- Pesci, A., Teza, G., 2008. Effects of surface irregularities on intensity data from laser scanning: an experimental approach. *Annals of Geophysics* 51 (5–6), 839–848.
- Platt, J.C., 1999. Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods. MIT Press, pp. 61–74.
- Rabatel, A., Deline, P., Jaillet, S., Ravel, L., 2008. Rock falls in high-alpine rock walls quantified by terrestrial lidar measurements: a case study in the mont blanc area. *Geophysical Research Letters* 35 (L10502).
- Renard, F., Voisin, C., Marsan, D., Schmittbuhl, J., 2006. High resolution 3D laser scanner measurements of a strike-slip fault quantify its morphological anisotropy at all scales. *Geophysical Research Letters* 33 (L04305).

- Rosser, N., Lim, M., Petley, D., Dunning, S., Allison, R., 2007. Patterns of precursory rockfall prior to slope failure. *Journal of Geophysical Research* 112, F04014.
- Rosser, N.J., Petley, D.N., Lim, M., Dunning, S.A., Allison, R.J., 2005. Terrestrial laser scanning for monitoring the process of hard rock coastal cliff erosion. *Quarterly Journal of Engineering Geology and Hydrogeology* 38 (4), 363–375.
- Schuster, H.-F., 2004. Segmentation of lidar data using the tensor voting framework. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 35 (Pt. B3), 1073–1078.
- Shalev-Shwartz, S., Singer, Y., Srebro, N., 2007. Pegasos: primal estimated sub-gradient solver for SVM. In: *Proceedings of the 24th International Conference on Machine Learning*, pp. 807–814.
- Shaw, P.J.A., 2003. *Multivariate Statistics for the Environmental Sciences*. Arnold, London.
- Shiraishi, Y., Fukumizu, K., 2011. Statistical approaches to combining binary classifiers for multi-class classification. *Neurocomputing* 74 (5), 680–688. 统计方法相结合的二元分类器对多层次分类。
- Sithole, G., Vosselman, G., 2004. Experimental comparison of filter algorithms for bare-earth extraction from airborne laser scanning point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing* 59 (1–2), 85–101.
- Teza, G., Pesci, A., Genevois, R., Galgaro, A., 2008. Characterization of landslide ground surface kinematics from terrestrial laser scanning and strain field computation. *Geomorphology* 97 (3–4), 424–437.
- Theodoridis, S., Koutroumbas, K., 2008. *Pattern Recognition*, fourth ed. Academic Press. 模式识别（第四版）
- Vandapel, N., Huber, D.F., Kapuria, A., Hebert, M., 2004. Natural terrain classification using 3-D Ladar data. In: *IEEE International Conference on Robotics and Automation*, vol. 5, pp. 5117–5122. 利用三维雷达数据进行自然地形分类。
- Vosselman, G., Gorte, B., Sithole, G., Rabbani, T., 2004. Recognizing structure in laser scanner point clouds. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 46 (Pt. 8/W2), 33–38.
- Wendt, H., Abry, P., Jaffard, S., 2007. Bootstrap for empirical multifractal analysis. *IEEE Signal Processing Magazine* 24 (4), 38–48.
- Wheaton, J.M., Brasington, J., Darby, S.E., Sear, D.A., 2009. Accounting for uncertainty in DEMs from repeat topographic surveys: improved sediment budgets. *Earth Surface Processes and Landforms* 35 (2), 136–156.