

# 基于 3D-CNN 结合 PointSIFT 的断裂带提取方法

王浩\*, 宋冬梅, 王斌, 戴嵩

中国石油大学(华东)海洋与空间信息学院, 山东 青岛 266580

**摘要** 为解决面向复杂地形区域的断裂带提取问题,提出了一种基于三维卷积神经网络(3D-CNN)结合 PointSIFT 的断裂带提取方法。该方法首先通过 PointSIFT 模块对原始点云数据的空间方位信息进行编码,以实现点云特征的聚合,从而得到带有不同尺度特征的重构点云数据。其次,以构建的三维卷积模块为核心搭建 3D-CNN 模型,以此对重构的点云数据进行深层次特征提取。然后,将所提取的点云特征输入到全连接层以完成点云类别的判断,从而解决断裂带提取问题。最后,将所提方法与张量分解方法、深度神经网络方法在两套数据集上进行对比实验,结果表明:所提方法能够获得更低的分类误差,从而证实了该方法在点云断裂带提取方面的优越性。

**关键词** 激光雷达; 断裂带提取; 深度学习; PointSIFT; 三维卷积

中图分类号 TP79

文献标志码 A

DOI: 10.3788/LOP230737

## Fracture Zone Extraction Method Based on Three-Dimensional Convolutional Neural Network Combined with PointSIFT

Wang Hao\*, Song Dongmei, Wang Bin, Dai Song

College of Ocean and Space Information, China University of Petroleum (East China),  
Qingdao 266580, Shandong, China

**Abstract** This paper presents a fracture zone extraction method for complex terrain areas using a combination of a three-dimensional convolutional neural network (3D-CNN) and PointSIFT. The PointSIFT module encodes spatial orientation information of the original point cloud data to aggregate point cloud features, resulting in reconstructed point cloud data with different scale features. Subsequently, a 3D-CNN model is developed, with a 3D convolutional module serving as the primary component, to extract deep-level features from the reconstructed point cloud data. The extracted point cloud features are then fed into a fully connected layer for the categorization of the point clouds, addressing the challenge associated with fracture zone extraction. Comparative evaluations with the tensor decomposition method and deep neural network method are performed on two datasets. The results demonstrate that the proposed fracture zone extraction method achieves a lower classification error, thus confirming the superiority of the method in effectively extracting fracture zones from point cloud data.

**Key words** light detection and ranging; fracture zone extraction; deep learning; pointSIFT; three-dimensional convolution

## 1 引言

断层是地壳受力导致岩层发生断裂而形成的地质构造,多以断裂带的形式存在<sup>[1-2]</sup>,地震、滑坡等自然灾害的发生皆与其密切相关,因此准确地提取断裂带对地震断层的量化研究具有重要意义。地震造成的地壳形变差别不一,离地震中心越远形变量越小,形成的断裂带越不明显。因此,为了准确地对地表的物进

行提取,需要采集高空间分辨率的地形数据,以识别细小的形变特征<sup>[3]</sup>。在过去十几年里,遥感技术已日趋成熟,利用不同遥感技术手段进行地面观测并获取精细化地面模型的工作越来越深入<sup>[4]</sup>。激光雷达系统(LiDAR)作为一种新型遥感对地观测技术,凭借其能够获得地物的高精度三维信息且具有速度快、成本低等优点<sup>[5]</sup>,被广泛应用于数字地形模型(DTM)<sup>[6-10]</sup>、建筑物三维建模<sup>[11-15]</sup>、滑坡检测<sup>[16-17]</sup>等应用领域。基于不

收稿日期: 2023-02-27; 修回日期: 2023-04-05; 录用日期: 2023-05-15; 网络首发日期: 2023-05-25

基金项目: 国家自然科学基金(41772350, 41701513)、山东省自然科学基金(ZR2022MD015)

通信作者: \*z20160115@s.upc.edu.cn

同搭载平台的激光雷达各有优点,其中,机载激光雷达凭借灵活机动、容易观测等优势,可深入复杂地质环境中快速获取断裂带的地貌形态信息。

近年来,越来越多的国内外专家学者利用点云数据对断裂带的识别与提取进行大量研究,并取得一系列的研究成果。Hudnut 等<sup>[18]</sup>利用机载激光雷达对 Hector Mine 断裂带进行地形数据采集,并得到震后同震位移。Arrowsmith 等<sup>[19]</sup>利用高密度点云数据对断裂带的滑动位移开展研究,对断裂带的演变过程进行定量描述。张良等<sup>[20]</sup>利用地形开度算子获取地表的主体结构变化,并结合边缘提取算法确定断裂带位置。但该算法无法自适应调整开度半径,导致算法的复杂度高且精度无法令人满意。徐景中等<sup>[21]</sup>基于点云构建三角网模型,并计算出三角网之间法向量的数量关系,再通过方向优先搜索策略提取出断裂带。但该算法在精度方面却受点云密度影响较大,随着点云密度的降低,提取精度也将大幅度降低。彭检贵等<sup>[22]</sup>提出了双阈值断裂带提取方法,首先将点云转换为数字高程图像,并利用高程信息对图像进行区域分割,通过调整高程阈值进行约束,提取出断裂带。然而,适合不同地形的高程阈值需要人工设定,这也导致该算法自动化水平较低。

在过去的几十年里,深度学习被广泛应用于图像分类<sup>[23]</sup>。卷积神经网络作为典型代表,可以直接从图像中获取空间上下文信息,从而提取出深层次图像特征。近年来,随着点云在自动驾驶、测绘遥感等领域的优异表现,越来越多的学者开始研究基于卷积神经网络的点云处理方法。根据对点云数据的不同处理方式,可将这些方法归纳为 3 类:基于多视图的方法<sup>[24-25]</sup>、基于体素的方法<sup>[26-27]</sup>和基于点的方法<sup>[28-29]</sup>。具体来说,基于多视图方法主要是将三维点云投影到多个二维平面上,再使用卷积神经网络对投影后的图像提取特征,完成图像分类。然而,在将点云投影到二维平面上时,会造成三维数据几何结构信息的丢失,从而导致点云分类结果不理想。为了解决该问题,Maturana 等<sup>[26]</sup>将点云映射到 3D 体素格网中,再使用三维卷积神经网络(3D-CNN)对体素数据进行特征提取,从而实现对三维对象的识别。这类方法能够完成点云分类任务,但也造成了大量的数据冗余,增加了计算成本。为了提高数据处理速度,Qi 等<sup>[28]</sup>提出了基于点的网络模型,该模型利用多层感知器(MLP)对每个点进行独立建模,实现从不同角度和尺度捕捉物体表面的特征,成功解决了点云数据无法直接进行卷积处理等问题,并在点云分类与分割方面获得较高精度。目前已涌现出大量基于 LiDAR 点云的深度学习网络模型,但将其应用于断裂带提取领域的研究仍较为少见。

在基于点的网络模型中,利用神经网络充分提取出各个点所包含的特征信息十分关键。PointSIFT 作为一种描述局部特征的卷积运算模块,其能聚合邻域

点之间不同尺度的几何结构特征,对局部点集的三维形状进行有效描述。该模块能够完成点云数据的特征重构,丰富点云数据信息,为原始点云中的每个点重新分配包含局部几何结构的特征信息,确保神经网络能够充分挖掘出点云的深层次特征,有助于实现对点云的精确分类。

因此,针对现有的 LiDAR 点云断裂带提取不完整、连续性差以及错误率高等问题,本文提出了一种基于 3D-CNN 结合 PointSIFT 的断裂带提取方法。该方法首先利用 PointSIFT 模块对点云的空间尺度特征进行编码,完成点云局部特征的聚合,然后通过 3D-CNN 充分提取出点云的深层次特征,从而实现对断裂带的准确提取。与传统方法相比,所提方法能挖掘出点云的深层次几何结构特征,准确识别出断裂带点所具有的高程异常和坡度异常等特征,可以更好地实现对断裂带点与非断裂带点的精准分类。

## 2 方 法

提出了一种基于 3D-CNN 结合 PointSIFT 的断裂带提取方法(PS-CNN)。该方法包括两个阶段:1)利用 PointSIFT 模块对点云进行特征重构;2)构建 3D-CNN 模型,实现点云类别判断。第一阶段,通过 PointSIFT 模块对所输入原始点云的空间方位信息进行编码,以此获取点云的多尺度几何结构特征,实现对点云数据的特征重构。第二阶段,构建了基于点云数据的 3D-CNN 模型,对所输入的三维数据直接进行卷积处理,从而实现对 LiDAR 点云的二分类,即提取出断裂带点与非断裂带点。该方法整体流程如图 1 所示。

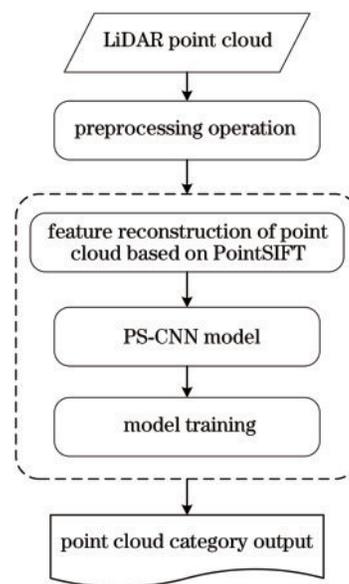


图 1 LiDAR 点云断裂带提取方法的流程图  
Fig.1 Flow chart of LiDAR point cloud fracture zone extraction method

## 2.1 PointSIFT 模块

PointSIFT 是一种描述局部特征的卷积运算模块,其核心在于聚集邻域点之间的几何结构特征<sup>[30]</sup>。PointSIFT 模块可以对点云不同方向上的信息进行有效编码,且具有尺度感知能力,从而可以很好地对局部点集的三维形状进行有效描述。具体来说,将给定的一个  $n \times d$  矩阵作为输入,其描述了一个数量为  $n$  的点集,每个点都有  $d$  维特征,经过 PointSIFT 模块处理后仍会输出一个  $n \times d$  矩阵,但此时模块已经为每个点分配了一个包含局部信息的  $d$  维新特征。

### 2.1.1 方向编码卷积

为了捕获三维点云的形状模型,对不同点云方向

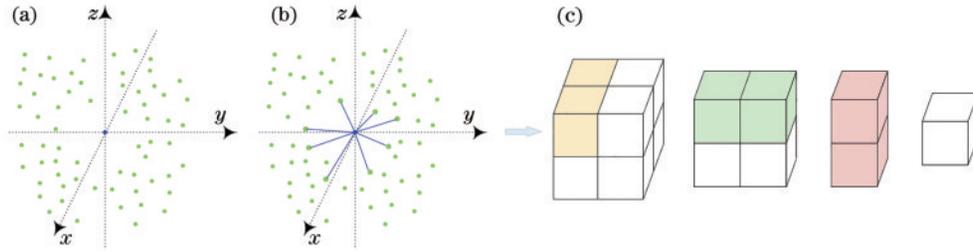


图2 OE卷积单元示意图。(a)三维空间点云(原点为输入点);(b)在8个分区进行最近邻搜索;(c)沿X、Y、Z轴的卷积  
Fig. 2 Schematic diagram of OE convolution unit. (a) Point cloud in 3D space (the input point is at origin); (b) nearest neighbour search in eight octants; (c) convolution along X, Y, Z axis

将获取的8个最近邻域点的特征整合到一个  $2 \times 2 \times 2$  的立方体中,以  $p_0$  为中心进行局部模式描述,如图2(c)所示。以往的很多工作都忽略了数据的结构,对特征向量沿  $d$  维进行最大池化来获得新的特征。而像卷积等有序算子可以更好地利用数据的结构。为此,提出了一种OE卷积,其是一个三级算子,依次沿X、Y和Z轴对  $2 \times 2 \times 2$  立方体进行卷积,将8个空间的特征整合到  $1 \times 1 \times 1$  的立方体中。具体来说,首先沿  $2 \times 2 \times 2$  立方体的X轴方向进行一次卷积,得到  $1 \times 2 \times 2$  的长方体特征,然后沿该  $1 \times 2 \times 2$  长方体的Y轴方向进行卷积,得到  $1 \times 1 \times 2$  的长方体特征,最后沿  $1 \times 1 \times 2$  长方体的Z轴方向进行卷积,得到  $1 \times 1 \times 1$  的立方体,即完成8个空间方向的特征整合。形式上,邻域点的特征是形状为  $1 \times 1 \times 1 \times d$  的向量  $\mathbf{V}$ ,其中前3个维度对应于3个轴。该三阶段卷积具体可表示为

$$\begin{cases} \mathbf{V}_x = g[\text{Conv}(\mathbf{W}_x, \mathbf{V})] \in \mathbf{R}^{1 \times 2 \times 2 \times d} \\ \mathbf{V}_{xy} = g[\text{Conv}(\mathbf{W}_y, \mathbf{V}_x)] \in \mathbf{R}^{1 \times 1 \times 2 \times d} \\ \mathbf{V}_{xyz} = g[\text{Conv}(\mathbf{W}_z, \mathbf{V}_{xy})] \in \mathbf{R}^{1 \times 1 \times 1 \times d} \end{cases}, \quad (1)$$

式中:  $\mathbf{W}_x \in \mathbf{R}^{2 \times 1 \times 1 \times d}$ 、 $\mathbf{W}_y \in \mathbf{R}^{1 \times 2 \times 1 \times d}$ 、 $\mathbf{W}_z \in \mathbf{R}^{1 \times 1 \times 2 \times d}$  为卷积算子的权值。设定  $g(\cdot) = \text{ReLU}(\cdot)$ 。最后,OE卷积单元通过重塑  $\mathbf{V}_{xyz} \in \mathbf{R}^{1 \times 1 \times 1 \times d}$ , 输出一个  $d$  维特征。OE卷积整合来自8个空间方向的信息,得到一个对方向信息进行编码的表示。

的形状信息进行明确编码。因此,针对所有的点提出一种方向编码(OE)卷积单元,这是一个逐点的局部特征描述符,对每个点的8个空间方位信息进行编码。

OE卷积单元的输入是点  $p_0$  的  $d$  维特征向量  $f_0 \in \mathbf{R}^d$ 。通过一个两阶段的方案,将来自8个方位的信息进行集成,生成一个方位感知特征  $f'_0$ ,如图2所示。OE卷积单元的第一阶段是堆叠八邻域搜索。以  $p_0$  点为中心,以  $r$  为搜索半径将其周围邻域划分为8个空间方位,在每个空间方位中找到一个距离  $p_0$  最近的邻域点,如图2(b)所示。远处的点对局部特征的描述提供的信息很少,若某个空间方位内不存在点时,则复制  $p_0$  作为其最近邻域点。

### 2.1.2 尺度感知

一个OE卷积单元只能够查看周围的8个点,若堆叠多个OE卷积单元,则视野会逐渐扩大。因此,为了使PointSIFT模块能够感知尺度信息,在PointSIFT模块中叠加多个OE卷积单元来实现多尺度特征获取。高等级的OE卷积单元比低等级的OE卷积单元有更大的感受野,如图3中矩形块2是在矩形块1基础

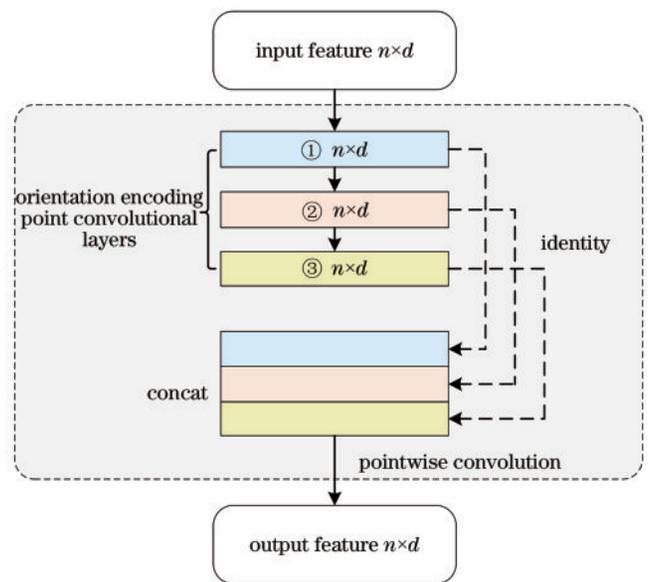


图3 PointSIFT模块  
Fig. 3 PointSIFT module

上进行 OE 卷积的,因此矩形块 2 为高级别的 OE 卷积单元,其能获取更大的感受野。通过构造 OE 卷积单元的层次结构,就可以获取点云局部区域的不同尺度的特征。然后,将不同尺度的特征进行堆叠,得到一个  $n \times 3d$  的多尺度特征,并通过 pointwise 进行逐点卷积处理,从而输出一个  $n \times d$  的多尺度特征。对 pointwise 而言,使用  $d$  个  $1 \times 1 \times 3d$  的卷积核进行逐点卷积操作,即可在不改变点的数量的前提下,只改变点的维度,实现将  $n \times 3d$  的多尺度特征维度转化为  $n \times d$ 。在融合多尺度特征的点卷积过程中,神经网络能够自适应匹配合适的尺度,这也使网络具有尺度感知能力。

## 2.2 3D-CNN 断裂带提取模型

### 2.2.1 三维卷积模块

卷积神经网络已成功解决图像的分类、分割、识别和分析等不同层次的问题。而三维点云数据通常是不规则的、无序的,这也导致无法直接利用卷积核在不规则的点云进行处理,使得对点云数据使用卷积神经网络变得十分困难。因此,利用一种转换函数与聚合函数代替二维 CNN 中的卷积核,构建一种 3D-CNN 模型,以达到直接提取三维点云深层次特征的目的,从而完成点云的分类任务。

三维卷积模块的构建过程如下:以采样点  $x_i$  为中心,进行邻域搜索,从而获取局部点集  $P \in \mathbf{R}^3$ ,并将该局部点集建模为一个半径为  $r$  的球形邻域  $N(x_i)$ ,目的是学习这个邻域  $P$  特征表示  $f_p$ ,以区分出采样点的归属类别。因此,将通用的卷积运算表述为

$$f_p = \sigma \left\{ A \left\{ \left[ T(f_{x_j}), \forall x_j \right] \right\} \right\}, d_{ij} < r \forall x_j \in N(x_i), (2)$$

式中:  $x_j$  为邻域  $N(x_i)$  中的一点;  $f_{x_j}$  为  $x_j$  的特征;  $T$  为转换函数,用于转化单点特征;  $A$  为聚合函数,可以使所有的特征聚集;  $\sigma$  为激活函数;  $d_{ij}$  为  $x_i$  和  $x_j$  的欧氏距

离;  $r$  为邻域半径。该卷积运算中转换函数  $T$  相当于二维 CNN 中卷积核的值与图像的对应位置的值相乘,聚合函数  $A$  相当于相加求和。

实现该卷积运算的关键,是对转换函数  $T$  的合理构建,该转换函数的本质就是对采样点与其邻域点特征的聚合,从而达到了类似于二维卷积核与图像值对应相乘产生特征图的过程。因此,对点云之间简单的低维特征使用 MLP 映射成为复杂的高维特征,并使得该高维特征作为卷积核的值对邻域点进行卷积操作,以进一步捕获点云的局部空间关系,该过程可描述为

$$T(f_{x_j}) = w_{ij} \cdot f_{x_j} = M(h_{ij}) \cdot f_{x_j}, (3)$$

式中:  $T$  为转换函数;  $M$  为由 MLP 组成的映射函数;  $h_{ij}$  为  $x_i$  和  $x_j$  的低维特征,即底层关系;  $w_{ij}$  为经过 MLP 映射的高维特征,这里起到卷积核的作用。则式(2)可改写为

$$f_p = \sigma \left\{ A \left\{ \left[ M(h_{ij}) \cdot f_{x_j}, \forall x_j \right] \right\} \right\}, (4)$$

式(4)为三维卷积模块的表达式,将其  $x_i$  和  $N(x_i)$  之间的所有关系聚合,实现对点的空间布局的显式推理,从而能够对形状进行判别。

图 4 为三维卷积模块的具体框架。输入的是以采样点  $x_i$  为中心、 $r$  为邻域半径所构建的球形邻域,然后计算出邻域点集  $N(x_i)$  中  $x_j$  与中心点  $x_i$  之间的低维特征  $h_{ij}$ 。此处,低维特征  $h_{ij}$  表示为邻域点  $x_j$  与中心点  $x_i$  之间的特征距离和欧氏距离。其次,将所计算出的低维特征  $h_{ij}$  通过共享 MLP 映射为高维特征  $w_{ij}$ ; 而映射后的高维特征  $w_{ij}$  与邻域点特征  $f_{x_j}$  的维度相同,因此能够直接相乘作为转换函数  $T$ 。最后,再通过聚合函数  $A$  将邻域点  $x_j$  的特征聚合至中心点  $x_i$  上,即将每一个邻域点与中心点的空间关系表征成一个值。

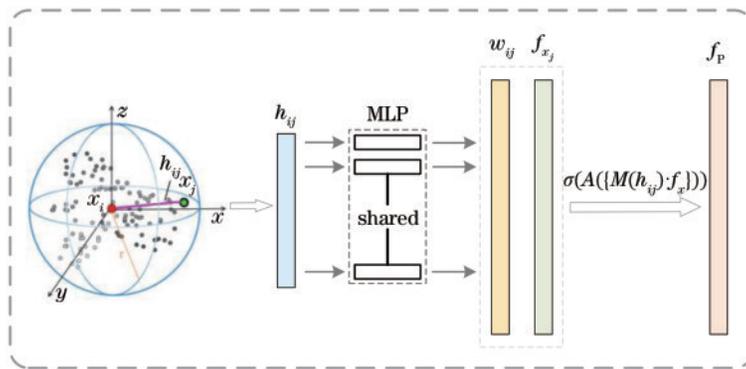


图 4 三维卷积模块框架示意图

Fig. 4 Schematic diagram of three-dimensional convolution module framework

### 2.2.2 PS-CNN 模型框架

PS-CNN 模型主要由 5 个模块组成:输入层、PointSIFT 模块、三维卷积模块、全连接层(FC)和输出层,如图 5 所示。输入层将接收到的经滤波和抽稀等

预处理后的点云数据( $n \times 3$ )输入到 PointSIFT 模块中,对点云数据的特征完成重构,从而获得带有不同尺度局部特征信息的新的点云数据( $n \times 3$ )。三维卷积模块为框架的核心构建模块,该模块对输入的重构点云

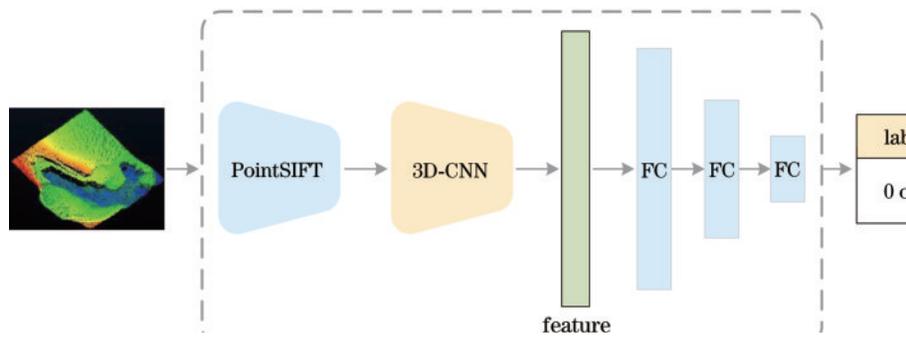


图5 PS-CNN点云断裂带提取框架示意图

Fig. 5 Schematic diagram of PS-CNN point cloud fracture zone extraction framework

数据进行卷积处理,从而得到深层次的点云局部特征。然后将所得到的点云局部特征输入到全连接层中以完成中心点的类别判断。其中,全连接层模块共有3层,全连接层模块中当前层的每个神经元与前一层所有神经元都相连。其最后一层作为输出层输出的是经softmax函数处理后的类别标签(0或1)。其中,网络模型对类别标签的判别主要是依据所捕获断裂带的线性特征、断层陡坎所呈现出的高程异常和坡度异常等特征。断裂带是岩层在不同方向上发生错位、断裂形成的,因此断裂带在空间上会呈现出显著的不连续性,坡度较大,高程变化明显。与断裂陡坎相比,非断裂带区域地面坡度较小,坡度变化较为平缓,且高程变化不显著。断裂带与非断裂带交界位置的点云通常密度较高。因此,可通过对点云局部特征的深入挖掘,实现对断裂带点与非断裂带点的区分。而所提的PS-CNN深度学习模型能够实现点云特征的聚合,以此利用三维卷积操

作更好地提取出点的局部几何结构特征,从而实现断裂带点与非断裂带点的准确分类,完成断裂带的提取。

### 3 实验与讨论

#### 3.1 实验数据集

##### 3.1.1 ISPRS点云数据集

ISPRS点云数据集由国际摄影测量和遥感学会(ISPRS)第III/3工作组提供。该数据集通过Optech ALTM激光扫描仪获取,共包含15个不同地形的样本数据,点空间分辨率为1~1.5 m。使用该数据集中包含断裂带地形的两个样本数据,Samp51和Samp53。其中Samp51样本由9636个点组成,包含了1894个断裂带点,7742个非断裂带点;Samp53样本由34373个点组成,包含了3208个断裂带点,31165个非断裂带点。图6为上述两个样本的三维空间分布图。图6中:蓝色为断裂带点,绿色为非断裂带点

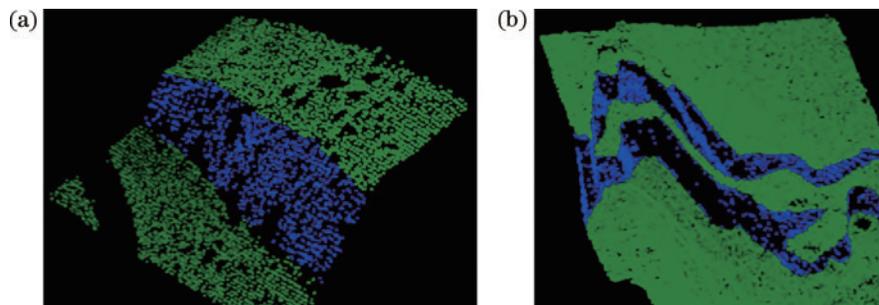


图6 ISPRS点云数据集样本展示图。(a); Samp51; (b) Samp53

Fig. 6 Sample display diagrams of ISPRS point cloud datasets. (a); Samp51; (b) Samp53

##### 3.1.2 川滇点云数据集

川滇点云数据集由北京地震局提供,该数据采源于四川与云南地区,该区域地形错综复杂,高低起伏较大,并包含部分断裂带地形。川滇点云数据集含有两个点云样本数据,分别为CD\_1和CD\_2。其中,CD\_1样本由75363个点组成,包含了40048个断裂带点,35315个非断裂带点;CD\_2样本由83059个点组成,包含了39212个断裂带点,43847个非断裂带点。图7为上述两个样本的三维空间分布图。

为完成所建模型的训练并验证其性能,从每个样本

中取出30%的数据作为训练集,用于模型参数的学习训练;70%的数据作为测试集,用于最终模型性能的评估。此外,在模型训练过程中从训练集取出10%作为验证集,用于检查训练过程中模型是否出现过拟合现象。

#### 3.2 精度评价指标

分别采用I类误差(T. I),II类误差(T. II)和总误差(T. E.)等3个指标对断裂带提取的精度进行评定。其中,I类误差表示非断裂带点被错误分类为断裂带点的数量占非断裂带点总数的百分比,II类误差表示断裂带点被错误分类为非断裂带点的数量占断裂带点总

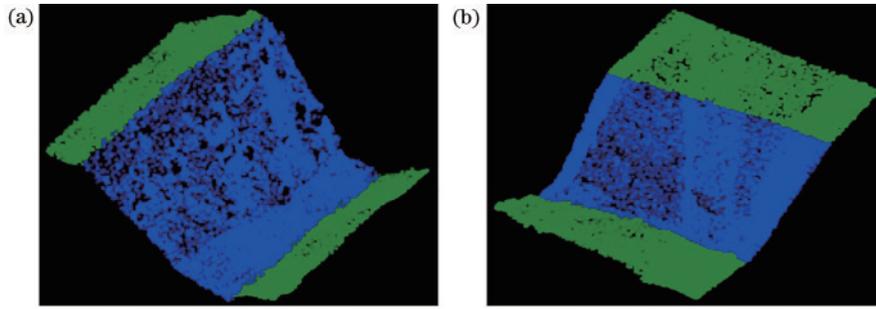


图 7 川滇点云数据集样本展示图。(a) CD\_1; (b) CD\_2

Fig. 7 Sample display diagrams of Chuandian point cloud datasets. (a) CD\_1; (b) CD\_2

数的百分比,总误差表示被错分的点个数占点云总数量的百分比,如表 1 所示。表 1 中: $a$  为断裂带点被正确分类为断裂带点的样本数量; $b$  为断裂带点被错误分类为非断裂带点的样本数量; $c$  为非断裂带点被错误分类为断裂带点的样本数量; $d$  为非断裂带点被正确分类为非断裂带点的样本数量。

表 1 分类结果的混淆矩阵及误差计算方法

Table 1 Confusion matrix of classification results and evaluation errors calculation method

Error	Calculation method
T. I	$c/(c+d)$
T. II	$b/(a+b)$
T. E.	$(b+c)/(a+b+c+d)$

### 3.3 结果与分析

为了证实所提方法的有效性,将所提方法与张量分解(TD)提取方法<sup>[31]</sup>、深度神经网络(DNN)提取方法<sup>[32]</sup>在上述 2 套数据集的 4 个样本上开展断裂带提取对比实验。具体来说,DNN 模型中包含 4 个隐藏层,每个隐藏层的神经元数目分别设置为 16、32、32、16。这 4 个隐藏层由全连接层(FC)、批归一化层(BN)和激活函数层(ReLU)组成。此外,所提方法在进行邻域搜索时,将邻域点 $x_j$ 的数量设为 64。

#### 3.3.1 ISPRS 点云数据集实验结果

所提方法与另外两种断裂带提取方法在 ISPRS 点云数据集上的对比结果如表 2 所示。由表 2 可知,所提方法在 Samp51 和 Samp53 两个样本上的 I 类误差、II 类误差和总误差均取得最低值。如在 Samp53 样本上,相对于 TD 与 DNN 两种方法,所提方法总误差分别降低了 2.72% 和 0.92%;I 类误差分别降低了 2.25% 和 0.89%;II 类误差降低了 7.21% 和 1.23%。所提方法获得了较好的提取效果,主要归因于深度学习强大的特征提取能力。首先,所采用的 PointSIFT 模块能够充分丰富点云的数据特征,将不同尺度的点云特征进行聚合,从而获得多尺度特征信息。其次,构建的 3D-CNN 能够直接对点云数据提取深层次特征,避免了数据转化带来的信息损失,使其更加容易区分断裂带点与非断裂带

表 2 3 种断裂带提取方法在 ISPRS 数据集上的性能比较  
Table 2 Performance comparison of three fracture zone extraction methods on ISPRS dataset

Dataset	Method	T. I / %	T. II / %	T. E. / %	Accuracy / %	Time / s
Samp51	TD	1.22	9.31	2.82	97.18	<b>16</b>
	DNN	0.46	4.95	1.35	98.65	32
	PS-CNN	<b>0.40</b>	<b>2.43</b>	<b>0.79</b>	<b>99.21</b>	51
Samp53	TD	2.43	17.37	3.83	96.17	<b>99</b>
	DNN	1.07	11.39	2.03	97.97	136
	PS-CNN	<b>0.18</b>	<b>10.16</b>	<b>1.11</b>	<b>98.89</b>	193

点。此外,所提方法需完成对点云深层次特征的提取,该过程会产生很大的计算量,导致模型运行时间相较于另外两种方法更长。而传统的 TD 方法只提取出点云的浅层特征,因此计算量小,所花费时间最少。

为了进一步体现所提方法的优势,对上述的实验结果进行可视化展示,如图 8、图 9 所示。图 8、图 9 中:蓝色为正确分类的断裂带点,绿色为正确分类的非断裂带点,黄色为错误分类的非断裂带点,红色为错误分类的断裂带点。

Samp51 是一个简单的陡坡地形,且点云较为稀疏。在 TD 的处理方法中,样本的断裂带区域出现了大量的 II 类误差,如图 8(b) 中红色点所示,同时非断裂带区域也出现了较多的错误分类现象,这可能是传统方法提取特征不充分造成的。相比于 TD 方法,DNN 方法提取的效果更好,被错误分类的点大多出现在断裂带与非断裂带的交界区域,且非断裂带区域出现的错分类情况较少,如图 8(c) 中的红色点所示。所提方法在该样本上表现最优,只存在极少的 I 类误差,且少量的 II 类误差基本只出现在两个区域的交界处。

Samp53 样本的地形结构十分复杂,该样本包含了两条曲折的断裂区域,增加了算法的挑战性。在 TD 方法中,断裂带区域仍出现大量的断裂带点被错分为非断裂带点的现象,这也导致该方法的 II 类误差大大增加,断裂带的提取效果不够理想。而由图 9(c)、

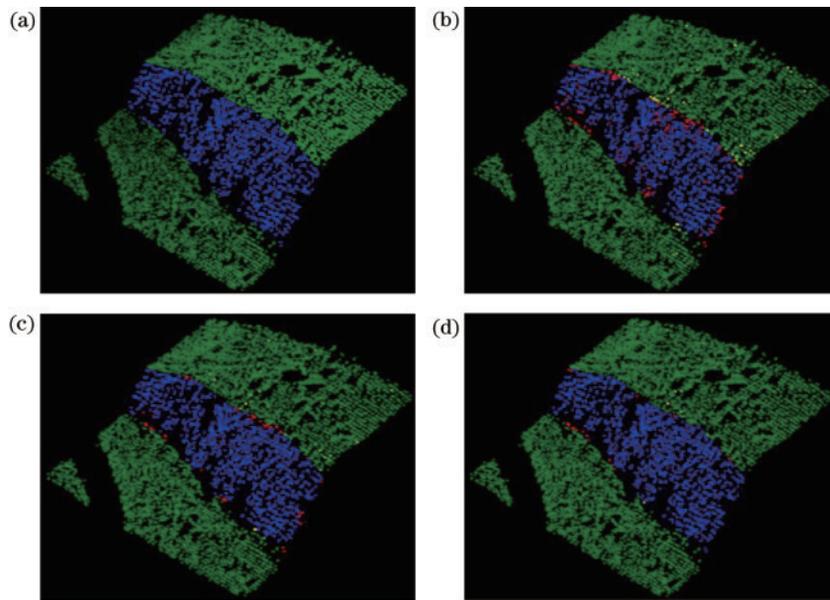


图 8 3 种断裂带提取方法在 Samp51 上的实验结果。(a) Label; (b) TD; (c) DNN; (d) PS-CNN

Fig. 8 Results of three fracture zone extraction methods on Samp51. (a) Label; (b) TD; (c) DNN; (d) PS-CNN

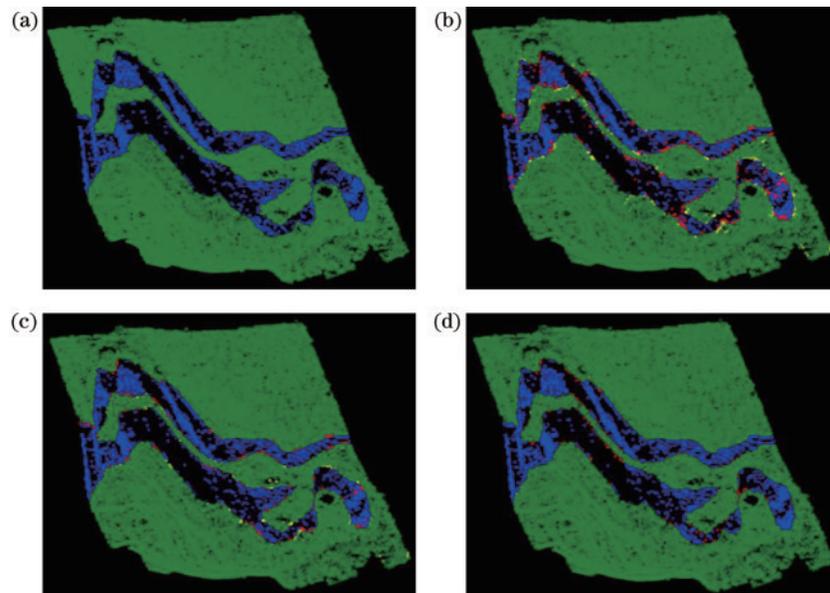


图 9 3 种断裂带提取方法在 Samp53 上的实验结果。(a) Label; (b) TD; (c) DNN; (d) PS-CNN

Fig. 9 Results of three fracture zone extraction methods on Samp53. (a) Label; (b) TD; (c) DNN; (d) PS-CNN

图 9(d) 可知, DNN 与 PS-CNN 方法产生的 II 类误差较少, 且主要分布在断裂带与非断裂带的交界区域。与 DNN 方法相比, 所提方法的非断裂带点错误分类的现象更少, 整体分类性能更优。

### 3.2.2 川滇点云数据集实验结果

为了验证所提方法的泛化能力, 将所提方法应用于川滇点云数据集进行实验, 所提方法与另外两种断裂带提取方法在该数据集上的实验结果, 如表 3 所示。由表 3 可知, 所提方法在 CD\_1 和 CD\_2 两个样本上均获得最低的分类误差, 断裂带提取效果最好。同时, 与 ISPRS 点云数据集的实验结果相同, 所提方法花费时间最长, TD 方法花费时间最少。

表 3 3 种断裂带提取方法在川滇数据集上的性能比较  
Table 3 Performance comparison of three fracture zone extraction methods on Chuandian dataset

Dataset	Method	T. I / %	T. II / %	T. E. / %	Accuracy / %	Time / s
CD_1	TD	1.15	1.47	1.32	98.68	<b>238</b>
	DNN	0.77	0.97	0.88	99.12	342
	PS-CNN	<b>0.29</b>	<b>0.49</b>	<b>0.40</b>	<b>99.60</b>	424
CD_2	TD	1.39	1.31	1.36	98.64	<b>273</b>
	DNN	0.63	2.01	1.28	98.72	364
	PS-CNN	<b>0.21</b>	<b>0.50</b>	<b>0.35</b>	<b>99.65</b>	473

由图 10(a) 可知, 在 CD\_1 样本中, 断裂带下半部分的坡度明显变小, 与非断裂带区域的交界变得十分模

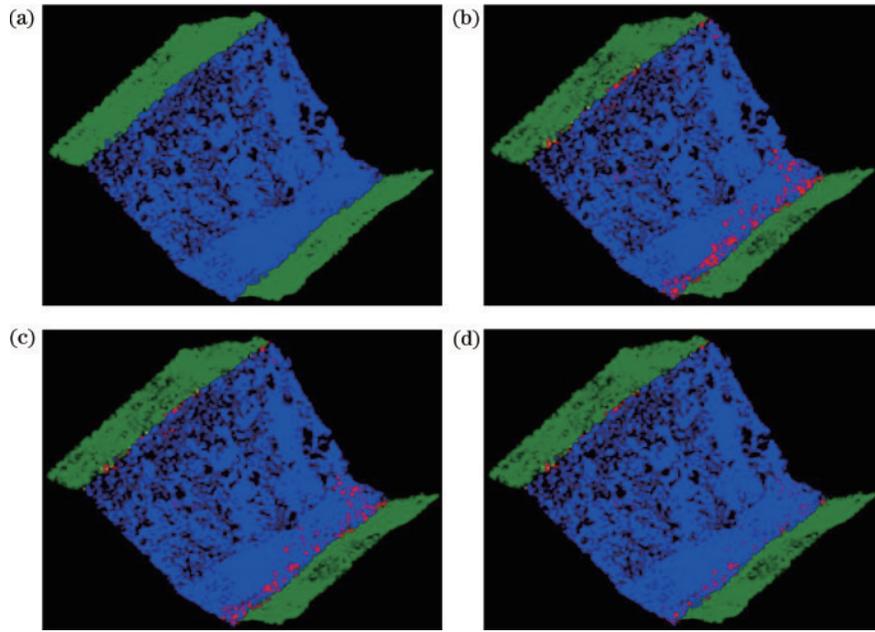


图 10 3 种断裂带提取方法在 CD\_1 上的实验结果。(a) Label; (b) TD; (c) DNN; (d) PS-CNN  
Fig. 10 Results of three fracture zone extraction methods on CD\_1. (a) Label; (b) TD; (c) DNN; (d) PS-CNN

糊,这可能会给断裂带点的提取带来一定困难。而实验结果也证实这一猜测,在断裂带的下半部分,3种提取方法均出现部分断裂带点被错分为非断裂带的情况。由图 10(d)可知,与 TD 与 DNN 方法相比,PS-CNN 方法也存在部分 II 类误差,但被错误分类的点最少,整体的分类效果最好。如图 10(b)所示,TD 方法的分类效果最不理想,在断裂带下半部分出现大量断裂带点被错分为非断裂带的情况,这也使得该方法

的总误差增大。

对 CD\_2 样本而言,在 TD 提取方法与 DNN 提取方法中均出现了部分非断裂带点被错误分类的情况,如图 11(b)、图 11(c)的黄色点所示。这可能是在非断裂带与断裂带的交界处,非断裂带点与断裂带点的几何结构特征十分相似,从而造成了传统方法与机器学习方法特征提取不充分,导致错误分类情况。相比较而言,所提的 PS-CNN 方法分类效果最好,这主要归

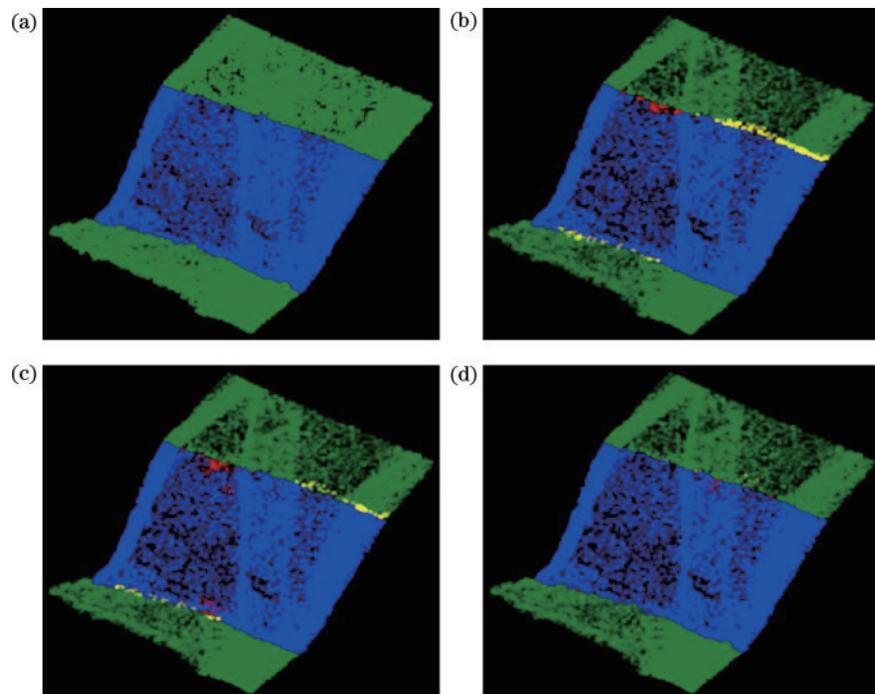


图 11 3 种断裂带提取方法在 CD\_2 上的实验结果。(a) Label; (b) TD; (c) DNN; (d) PS-CNN  
Fig. 11 Results of three fracture zone extraction methods on CD\_2. (a) Label; (b) TD; (c) DNN; (d) PS-CNN

由于深度学习方法能够挖掘出点云的深层次特征,从而使得在几何结构特征相似的情况下也能够获得较为理想的提取效果。

## 4 讨 论

为了验证所提方法中引入的 PointSIFT 模块的有效性,设计了两种不同的网络模型,分别是包含 PointSIFT 模块的 3D-CNN 模型和未包含 PointSIFT 模块的 3D-CNN 模型,在 ISPRS 数据集上开展消融实验。

在开展两种不同网络模型的实验过程中,点云的预处理操作和网络模型的参数均保持一致。其中,第 1 种网络模型包含了 PointSIFT 模块,以此实现对点云特征的聚合,然后利用三维卷积运算对聚合后的点云数据进行特征提取,并以此完成断裂带点与非断裂带点的分类。第 2 种网络模型中未包含 PointSIFT 模块,而是直接利用三维卷积运算对点云数据进行特征提取,从而完成断裂带点与非断裂带点的分类。消融实验的结果如表 4 所示,该结果表明:相比于未包含 PointSIFT 模块的 3D-CNN,包含 PointSIFT 模块的 3D-CNN 能够获得更低的分类误差,断裂带点提取效果更好。这也进一步证实所引入的 PointSIFT 模块对断裂带提取模型的性能提升具有积极作用。

表 4 3 种断裂带提取方法在 ISPRS 数据集上的性能比较  
Table 4 Performance comparison of three fracture zone extraction methods on ISPRS dataset

Dataset	PointSIFT	T. I / %	T. II / %	T. E. / %	Aaccuracy / %
Samp51		0.44	2.48	0.83	99.17
	✓	<b>0.40</b>	<b>2.43</b>	<b>0.79</b>	<b>99.21</b>
Samp53		0.23	10.27	1.17	98.83
	✓	<b>0.18</b>	<b>10.16</b>	<b>1.11</b>	<b>98.89</b>

此外,为了进一步验证不同点云抽稀参数对模型分类精度以及运行速度的影响,通过设置 3 种不同的点云抽稀率(0.3、0.2、0.1)利用川滇点云数据对模型进行测试,实验结果如表 5 所示。由表 5 可知,抽稀率为 0.1 时模型能获得最高的分类精度,但所花

表 5 所提方法应用于不同抽稀度点云样本上的性能对比  
Table 5 Performance comparison of the proposed method on point cloud samples with different dilution rate

Dataset	Method	Dilution rate	Point	Aaccuracy / %	Time / s
CD_1	PS-CNN	0.3	65817	99.58	<b>370</b>
		0.2	75363	99.60	424
		0.1	84670	<b>99.63</b>	476
CD_2	PS-CNN	0.3	72357	99.64	<b>412</b>
		0.2	83059	99.65	473
		0.1	93434	<b>99.67</b>	532

费的时间最多;抽稀率为 0.3 时模型所花费的时间最少,但获得的分类精度也最低。但总体来看,采用 3 种不同点云抽稀参数获得的分类精度及运行速度相差不大。

## 5 结 论

提出了一种基于 3D-CNN 结合 PointSIFT 的断裂带提取方法,以解决复杂地形区域的断裂带提取问题。该方法通过 PointSIFT 模块对原始点云的空间方位信息进行编码,实现对点云数据的特征重构,从而获得带有不同尺度特征信息的重构点云数据。所提模型的核心思想是将 PointSIFT 模块与 3D-CNN 相结合,通过三维卷积操作对输入的重构点云数据进行卷积处理,网络模型能够充分学习到不同空间尺度的点云几何特征,从而更加精准地实现点云的二分类,所提取出的断裂带具有更高精度。通过开展在 ISPRS 点云数据集和川滇点云数据集上的对比实验,相较于 TD 与 DNN 两种对比方法,所提方法能够获得更低的分类误差,断裂带提取精度更高。尤其是在地形结构复杂时,所提方法的断裂带提取优势更为明显。考虑到目前已有的三维点云卷积会产生海量的数据运算,降低算法运行效率,因此在未来工作中有必要探索出一种更加高效的三维点云卷积运算方式。

## 参 考 文 献

- [1] Neuendorf K K E. Glossary of geology[M]. New York: Springer Science & Business Media, 2005.
- [2] Curzi M, Giuntoli F, Vignaroli G, et al. Constraints on upper crustal fluid circulation and seismogenesis from *in situ* outcrop quantification of complex fault zone permeability[J]. Scientific Reports, 2023, 13: 5548.
- [3] 梁子哈, 魏占玉, 庄其天, 等. 基于高分辨率地形数据的富蕴 M8.0 地震地表破裂带精细特征[J]. 地震地质, 2021, 43(6): 1507-1523.
- [4] Liang Z H, Wei Z Y, Zhuang Q T, et al. Segmentation of surface rupture and offsets characteristics of the Fuyun M8.0 earthquake based on high-resolution topographic data[J]. Seismology and Geology, 2021, 43(6): 1507-1523.
- [5] Zhou Y, Parsons B, Elliott J R, et al. Assessing the ability of Pleiades stereo imagery to determine height changes in earthquakes: a case study for the El Mayor-Cucapah epicentral area[J]. Journal of Geophysical Research: Solid Earth, 2015, 120(12): 8793-8808.
- [6] 叶光豪, 邓懋懋, 徐文兵, 等. 机载激光雷达技术应用于沙丘变形监测的研究[J]. 激光与光电子学进展, 2018, 55(5): 052802.
- [7] Ye G H, Deng S S, Xu W B, et al. Application of airborne LiDAR technology in dune deformation monitoring[J]. Laser & Optoelectronics Progress, 2018, 55(5): 052802.
- [8] 惠振阳, 胡友健. 基于 LiDAR 数字高程模型构建的数学形态学滤波方法综述[J]. 激光与光电子学进展,

- 2016, 53(8): 080001.
- Hui Z Y, Hu Y J. Review on morphological filtering algorithms based on LiDAR digital elevation model construction[J]. *Laser & Optoelectronics Progress*, 2016, 53(8): 080001.
- [7] Akumu C E, Dennis S. Exploring the addition of airborne lidar-DEM and derived TPI for urban land cover and land use classification and mapping[J]. *Photogrammetric Engineering & Remote Sensing*, 2023, 89(1): 19-26.
- [8] Meng X L, Currit N, Zhao K G. Ground filtering algorithms for airborne LiDAR data: a review of critical issues[J]. *Remote Sensing*, 2010, 2(3): 833-860.
- [9] 曲辉, 蒋汪洋. 机载激光点云的精度分析及优化[J]. *测绘与空间地理信息*, 2022, 45(增刊1): 193-196, 199, 203.
- Qu H, Jiang W Y. Accuracy analysis and optimization of airborne laser point cloud[J]. *Geomatics & Spatial Information Technology*, 2022, 45(S1): 193-196, 199, 203.
- [10] Chen Z Y, Gao B B, Devereux B. State-of-the-art: DTM generation using airborne LIDAR data[J]. *Sensors*, 2017, 17(12): 150.
- [11] Wang R S. 3D building modeling using images and LiDAR: a review[J]. *International Journal of Image and Data Fusion*, 2013, 4(4): 273-292.
- [12] 周益, 檀丁, 谢亮, 等. 融合无人机影像点云与三维激光点云的建筑物三维建模研究[J]. *现代测绘*, 2022, 45(4): 16-19.
- Zhou Y, Tan D, Xie L, et al. Research on 3D building modeling by fusion of UAV image point cloud and 3D laser point cloud[J]. *Modern Surveying and Mapping*, 2022, 45(4): 16-19.
- [13] Rottensteiner F, Sohn G, Gerke M, et al. Results of the ISPRS benchmark on urban object detection and 3D building reconstruction[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, 93: 256-271.
- [14] 冯瑞, 姜阳, 刘安琪. 基于多源点云的建筑物三维建模研究[J]. *测绘与空间地理信息*, 2022, 45(S1): 296-299.
- Feng R, Jiang Y, Liu A Q. Research on 3D building modeling based on multi-source point clouds[J]. *Geomatics & Spatial Information Technology*, 2022, 45(S1): 296-299.
- [15] Wang R S, Peethambaran J, Chen D. LiDAR point clouds to 3-D urban models: a review[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(2): 606-627.
- [16] Chu H J, Wang C K, Huang M L, et al. Effect of point density and interpolation of LiDAR-derived high-resolution DEMs on landscape scarp identification[J]. *GIScience & Remote Sensing*, 2014, 51(6): 731-747.
- [17] Jin D J, Li J, Gong J H, et al. Shipborne mobile photogrammetry for 3D mapping and landslide detection of the water-level fluctuation zone in the Three Gorges Reservoir area, China[J]. *Remote Sensing*, 2021, 13(5): 1007.
- [18] Hudnut K W, Borsa A, Glennie C, et al. High-resolution topography along surface rupture of the 16 October 1999 Hector mine, California, earthquake (MW 7.1) from airborne laser swath mapping[J]. *Bulletin of the Seismological Society of America*, 2002, 92(4): 1570-1576.
- [19] Arrowsmith J R, Zielke O. Tectonic geomorphology of the San Andreas Fault zone from high resolution topography: an example from the Cholame segment[J]. *Geomorphology*, 2009, 113(1/2): 70-81.
- [20] 张良, 张帆, 姜晓琦, 等. 利用地形开度算子自动提取激光雷达点云断裂线[J]. *测绘通报*, 2018(4): 68-72.
- Zhang L, Zhang F, Jiang X Q, et al. Automatic break line extraction from airborne LiDAR point cloud using topographic openness[J]. *Bulletin of Surveying and Mapping*, 2018(4): 68-72.
- [21] 徐景中, 万幼川, 张圣望. 基于机载激光雷达点云的断裂线自动提取方法[J]. *计算机应用*, 2008, 28(5): 1214-1216.
- Xu J Z, Wan Y C, Zhang S W. Automatic breakline extraction from LIDAR point clouds[J]. *Journal of Computer Applications*, 2008, 28(5): 1214-1216.
- [22] 彭检贵, 马洪超, 王宗跃, 等. 机载 LiDAR 点云的双阈值自动提取断裂线方法[J]. *测绘科学技术学报*, 2010, 27(4): 275-279.
- Peng J G, Ma H C, Wang Z Y, et al. Dual-threshold extracting breaklines from airborne LiDAR point clouds [J]. *Journal of Geomatics Science and Technology*, 2010, 27(4): 275-279.
- [23] Chen C F, Guo J J, Wu H M, et al. Performance comparison of filtering algorithms for high-density airborne LiDAR point clouds over complex LandScapes [J]. *Remote Sensing*, 2021, 13(14): 2663.
- [24] Su H, Maji S, Kalogerakis E, et al. Multi-view convolutional neural networks for 3D shape recognition [C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2016: 945-953.
- [25] Qi C R, Su H, Nießner M, et al. Volumetric and multi-view CNNs for object classification on 3D data[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 5648-5656.
- [26] Maturana D, Scherer S. VoxNet: a 3D Convolutional Neural Network for real-time object recognition[C]//2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), September 28-October 2, 2015, Hamburg, Germany. New York: IEEE Press, 2015: 922-928.
- [27] Zhou Y, Tuzel O. VoxelNet: end-to-end learning for point cloud based 3D object detection[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4490-4499.
- [28] Charles R Q, Hao S, Mo K C, et al. PointNet: deep learning on point sets for 3D classification and segmentation[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press,

- 2017: 77-85.
- [29] Qi C R, Yi L, Su H, et al. PointNet++ : deep hierarchical feature learning on point sets in a metric space [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems, December 4-9, 2017, Long Beach, California, USA. New York: ACM Press, 2017: 5105-5114.
- [30] Jiang M Y, Wu Y R, Zhao T Q, et al. PointSIFT: a SIFT-like network module for 3D point cloud semantic segmentation[EB/OL]. (2018-07-02)[2023-02-03]. <https://arxiv.org/abs/1807.00652>.
- [31] 林洪彬, 刘彬, 张玉存. 基于多尺度张量分解的点云结构特征提取[J]. 中国机械工程, 2012, 23(15): 1833-1839.  
Lin H B, Liu B, Zhang Y C. Structural feature extraction from point clouds based on multi-scale tensor decomposition[J]. China Mechanical Engineering, 2012, 23(15): 1833-1839.
- [32] Martins V S, Kaleita A L, Gelder B K, et al. Deep neural network for complex open-water wetland mapping using high-resolution WorldView-3 and airborne LiDAR data[J]. International Journal of Applied Earth Observation and Geoinformation, 2020, 93: 102215.