

文章编号 1004-924X(2019)07-1601-12

利用迁移学习的机载激光雷达点云分类

赵 传*, 张保明, 余东行, 郭海涛, 卢 俊

(战略支援部队信息工程大学 地理空间信息学院, 河南 郑州 450001)

摘要:为解决现有机载激光雷达点云分类方法存在难以在获得较高精度的点云分类结果的同时降低分类过程所需时间等问题,提出了一种利用迁移学习的机载激光雷达点云分类方法。首先,计算点云的归一化高程、强度和法向量三个特征,通过设置不同邻域大小,利用所提出的点云特征图生成策略生成多尺度点云特征图;然后,利用预训练的深度残差网络从每个点的多尺度点云特征图提取其多尺度深度特征;最后,为了实现快速地训练,构建仅包含两层全连接神经网络模型,再利用训练好的模型对点云进行分类。两组 ISPRS 提供的标准点云数据集的试验结果表明:提出的方法所需训练时间少,分类结果的整体精度为 89.6%,较 ISPRS 官网上所报道的最佳点云方法分类精度高 4.4%。分类结果可为机载激光雷达点云的后续处理与应用提供可靠的信息。

关键词:迁移学习;特征图;分类;机载激光雷达点云

中图分类号:P237 文献标识码:A doi:10.3788/OPE.20192707.1601

Airborne LiDAR point cloud classification using transfer learning

ZHAO Chuan*, ZHANG Bao-ming, YU Dong-hang, GUO Hai-tao, LU Jun

(*Institute of Surveying and Mapping, Strategic Support Force Information Engineering University, Zhengzhou 450001, China*)

* *Corresponding author, E-mail: zc-mail163@163.com*

Abstract: In order to overcome the problem that existing airborne methods for LiDAR point cloud classification have difficulties in obtaining high classification accuracy and reducing processing time simultaneously, a method using transfer learning for classifying airborne LiDAR point clouds was proposed. First, normalized height, intensity, and normal vector were calculated for each LiDAR point, by setting different sizes of neighborhood, and multi-scale point cloud feature images were generated by utilizing the proposed feature image generation strategy. Subsequently, a pre-trained deep residual network was employed to extract multi-scale deep features from the generated multi-scale feature images. Finally, a neural network model containing only two fully connected layers was constructed to achieve efficient training, and each point cloud was classified by the trained neural network model. Experimental results of two ISPRS benchmark airborne LiDAR point cloud sets demonstrate that the proposed method requires less training time, and the overall classification accuracy obtained by the method is 89.6%, which is 4.4% higher than the best classification result reported on the ISPRS official website. The classification result can provide reliable information for further processing and applica-

收稿日期:2018-10-16;修订日期:2018-12-14.

基金项目:国家自然科学基金资助项目(No. 41601507);地理信息工程国家重点实验室开放基金资助项目(No. SKLGIE2017-M-3-2)

tion of point cloud.

Key words: transfer learning; feature image; classification; airborne LiDAR point cloud

1 引言

随着机载激光雷达 (Light Detection and Ranging, LiDAR) 传感器的发展, 机载 LiDAR 点云数据的可获得性在不断提高, 其自动处理与分类也已成为摄影测量与遥感、计算机视觉等诸多领域的研究重点与热点^[1]。尽管机载 LiDAR 点云数据在如建筑物检测与重建^[2]、电力线的识别与建模^[3-4]、植被分类与提取^[5]、道路、路边石以及道路标志的提取^[6]等方面都有着广泛的应用, 但由于点云密度不均、分布离散以及场景复杂等多方面因素的影响, 使得机载 LiDAR 点云的自动高精度分类仍存在较大挑战。

目前, 机载 LiDAR 点云分类的方法, 依据不同的分类标准可以分为不同的类别, 按是否需要训练样本, 可分为非监督学习和监督学习的点云分类。基于非监督学习的点云分类通常需要计算多种具有较高区分度的点云特征, 如归一化高程、法向量、拟合残差以及基于协方差分析的特征, 然后采用区域生长^[7-8]、分割^[9]、最优化^[10]等策略得到结果, 这类方法最大的特点在于无需训练样本, 且分类过程较为简单, 但由于受到机载 LiDAR 点云涉及的范围广、场景复杂以及现有的点云特征不足以区分多种地物等诸多因素的影响, 使得该类方法通常只能将点云分为少数几种地物^[11], 如建筑物、地面、植被等。此外, 该类方法通常需要设置较多阈值, 且分类结果容易受噪声、点云分布、场景复杂度等多方面的影响, 适应性相对较差。相对地, 基于监督学习的点云分类充分利用训练样本中包含的点云先验信息进行点云分类, 其适应性相对更广, 因此是现阶段研究相对较多的一类算法。传统的点云监督分类算法通常首先计算多种人工设计的点云特征, 通过特征工程对特征进行处理, 再利用如支持向量机 (Support Vector Machine, SVM)^[12]、信息向量机 (Information Vector Machine, IVM)^[13]、自适应提升树 (Adaptive Boost, AdaBoost)^[14]、随机森林 (Random Forest, RF)^[3]、条件随机场 (Conditional Random Fields, CRF)^[15]、JointBoost^[16]等

单一浅层机器学习算法, 或组合多种浅层机器学习算法^[17]进行训练, 得到模型后再对点云进行分类。尽管基于浅层机器学习算法的点云分类可以得到精度更高的分类结果, 且其适应性也有一定提高, 但其分类结果的精度很大程度上取决于人工设计的点云特征, 而现有的人工设计的点云特征难以进一步提高点云分类精度。近年来, 随着深度学习的不断发展及其在图像上目标检测、场景识别等诸多领域的成功应用, 已有部分学者研究基于深度学习的机载 LiDAR 点云分类^[18-20], 虽然这种方法无需人工设计点云特征, 且能进一步提高点云分类精度, 但是神经网络模型通常参数较多、训练过程复杂, 且需要大量的训练时间。

迁移学习将从源任务中学习到的知识迁移到目标任务, 可有效地降低网络模型的复杂度、参数数量以及训练模型所需的时间^[21], 因此本文借鉴已有的利用深度学习分类机载 LiDAR 点云的方法, 首次将迁移学习引入机载 LiDAR 点云分类中, 提出一种利用迁移学习的机载 LiDAR 点云分类方法, 以在降低模型复杂度和训练时间的同时提高点云分类精度。

2 方法原理

本文提出的点云分类方法主要包括以下 3 个步骤: 预处理, 包括点云特征的计算和逐点特征图的生成; 点云深度特征提取, 利用现有的在 ImageNet 数据集^[22]上预训练的深度残差网络模型提取每个点的深度特征; 模型构建与分类, 构建两层全连接神经网络, 将提取的深度特征作为输入训练该网络, 然后利用训练好的网络预测得到最终的点云分类结果。

2.1 预处理

2.1.1 点云特征计算

目前, 机载 LiDAR 点云分类中用到的点云特征有多种, 主要可以分为^[16-17]: 高程相关特征, 包括归一化高程值、局部邻域范围的高程差等; 基于协方差分析的特征, 如平面性、球性、线性、各向异性等; 波形特征, 如回波强度、回波次数等及光谱特征等。文献^[17]分析了不同特征在点云分类

中的重要程度,并得出了归一化高程是最重要的一种机载 LiDAR 点云分类特征的结论,同时,其试验结果也表明法向量和强度在分类中也发挥着重要的作用。因此,本文选择点云法向量的 z 分量、强度和归一化高程(分别记为 f_{zv} , f_{in} 和 f_{ht})作为点云特征图的红、绿、蓝 3 个通道。

为了得到点云的归一化高程值,采用文献[23]提出的布料滤波算法对原始点云进行滤波,然后将滤波得到的地面点进行内插得到 DTM,再逐点计算得到其归一化高程值。考虑到通过主成分分析(Principal Component Analysis, PCA)计算点云法向量的方式受邻域大小影响较大,且通过这种方式计算的点云法向量在不同地物的边界、屋顶面交界处等过渡区域不准确,因此采用文献[24]提出的稳健法向量估计算法计算点云法向量,该算法具有效率高、受邻域大小影响小等优点,并能克服基于 PCA 计算的法向量在过渡区计算不准确的不足,图 1 为其法向量计算结果与基于 PCA 计算结果的对比(彩图见期刊电子版)。从图中红色圆框中所示点云可以看出,稳健法向量估计算法在不同屋顶面的交界处仍能获得准确的法向量。

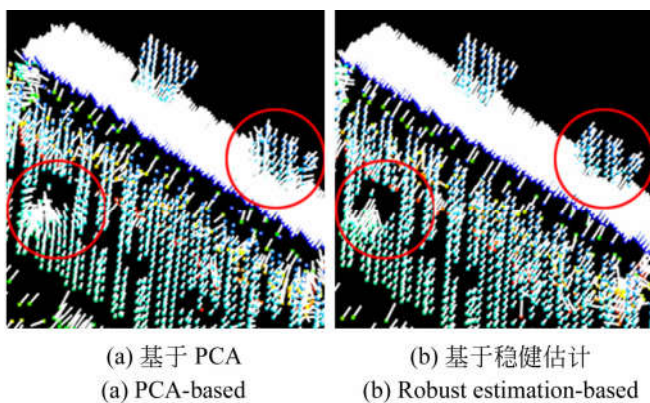


图 1 不同方法计算的法向量对比

Fig. 1 Comparison of normal vectors calculated by different methods

由于 f_{zv} , f_{in} 和 f_{ht} 的数量级不同,为了利用其生成点云特征图,需进行标准化。本文采用式(1)所示的最大最小值归一化原则分别将归一化高程、强度和法向量的 z 分量归一化至 0 到 1 之间,为便于叙述,归一化后的值仍分别记为 f_{zv} , f_{in} 和 f_{ht} 。

$$f' = \frac{f - f_{\min}}{f_{\max} - f_{\min}}, \quad (1)$$

式中: f 代表单个点的特征值, $f \in \{f_{zv}, f_{in}, f_{ht}\}$, f' 为归一化后的特征值, f_{\max} , f_{\min} 分别代表整个点云中对应特征值的最大最小值。

2.1.2 点云特征图生成

点云特征图包含了单个点及其局部邻域范围内其他点的特征,但由于点云实质上是空间中离散的三维点集,因此需要采取一定的方式将其投影到二维平面。文献[18]将点云直接投影到二维平面,将待生成特征图的点的邻域范围划分为 128×128 的网格,再以该点的平面坐标计算每个格网点的平面坐标,并将所有格网点的高程均设置为该点的高程,然后将邻域范围内距离各格网点最近的点的特征值作为各格网点的特征值,从而得到点云特征图。文献[19]则直接以二维投影的点云为基础,利用自然邻域内插法直接得到各格网点的特征值。通过上述方式得到的点云特征图虽能通过深度学习得到较好的分类结果,但由于未能对各点的邻域空间分布较好地建模,因此精度难以进一步提高,同时也存在难以正确分类地物边界点的问题。此外,由于机载 LiDAR 具有一定的穿透能力,能获得部分树木下的地面点,通过上面所述方法生成的点云特征图,会导致生成的树木下地面点与树木点的特征图相似性较大(如图 2(a)中的点 P 和 P_1),从而增加分类的难度。为了解决上述问题,本文提出一种新的点云特征图生成策略。

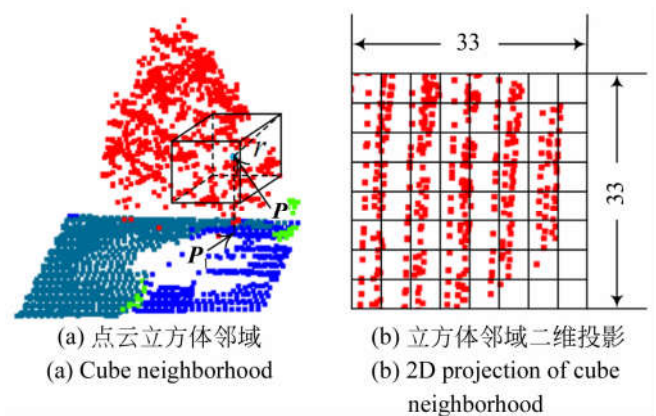


图 2 点云特征图生成过程

Fig. 2 Process of point cloud feature image generation

如图 2 所示,对于任一点 P ,本文选取其立方体邻域内的点(立方体对角线长为 $2r$)投影到平面,设置格网大小 ω ,生成 $M \times M$ ($M=33$) 的点云特征图。由于点云分布不均匀,使得特征图的像

素格网中包含的 LiDAR 点个数不同,如图 2(b)所示,因此需要采取一定策略确定各像素格网的特征值。

本文首先利用式(2)计算各像素的平面坐标,并以整个区域中的点云构建二维 kd 树,搜索各像素点的最邻近 n 个点($n=3$),采用式(3)所示的加权反距离算法内插各像素的高程值,然后以立方体邻域内的点构建局部 kd 树,仍搜索各格网点的最邻近 n 个点,采用加权反距离算法内插得到各格网点的 f_{zv} , f_{in} 和 f_{ht} ,最后采用式(4)将各特征值转换到 $0\sim 255$ 以形成点云特征图。

$$\begin{cases} X_{p_{ij}} = X_P + (j - 16) \times \omega \\ Y_{p_{ij}} = Y_P + (i - 16) \times \omega \end{cases}, \quad (2)$$

$$\begin{cases} z_{s^{ij}} = \sum_{k=1}^n w_k \times z_s^k \\ w_k = \frac{1/d_k}{\sum_{k=1}^n 1/d_k} \end{cases}, \quad (3)$$

$$\begin{cases} R = \lfloor 255 \times f_{zv} \rfloor \\ G = \lfloor 255 \times f_{in} \rfloor \\ B = \lfloor 255 \times f_{ht} \rfloor \end{cases}. \quad (4)$$

式中: X_P 和 Y_P , $X_{p_{ij}}$ 和 $Y_{p_{ij}}$ 分别代表点 P 和像素点 P_{ij} 的地理坐标; i, j 代表该点在特征图中的行号和列号; z_s 代表高程; P_k 为像素点 P_{ij} 的最邻近点; d_k 为点 P_k 到像素点 P_{ij} 的平面距离; 符号 $\lfloor \cdot \rfloor$ 代表向下取整。

2.2 多尺度深度特征提取

点云特征是决定点云分类精度高低的关键因素之一^[10],尽管研究者们针对机载 LiDAR 点云分类问题已设计了诸多点云特征,但这些点云特征依赖于专家知识,且层次较低,虽能针对某些任务,在特定场景中取得较高的分类精度,但为得到最优的点云特征和分类结果通常需要设置较多的经验阈值。近年来,深度学习在计算机视觉、目标检测与识别等领域取得了巨大成功^[21],使得利用卷积神经网络(Convolutional Neural Network, CNN)提取深度特征也受到了越来越多地关注。与人类实现目标识别与解译相似,深度学习通过层级抽象低层次特征以提取深度特征,因此相比人工设计的特征,深度特征更能反映目标的内在属性,适应性也相对更广。

尽管深度特征泛化性较强,但完整地训练一个 CNN 通常需要很长时间,尤其是在网络较深

的情况下,这种现象更为突出。此外,相比传统的机器学习算法,为了得到更好的结果,深度学习通常需要更多的训练样本。为解决上述问题,很多学者研究迁移学习,以期通过将已有任务的知识迁移到新任务中,降低 CNN 的模型复杂度、训练时间和对训练样本数量的要求。文献[25]对近些年的迁移学习方法进行了详细的总结与回顾,并指出基于网络的迁移学习复用在源任务中训练好的网络结构和参数,可大幅降低目标任务所需的训练时间。随着自然图片数据集 ImageNet^[22]的提出,利用在该数据集上训练的深度 CNN 提取的深度特征泛化性较强,且能较容易地扩展到诸如遥感影像的分类、识别、目标检测等多种任务中。同时,文献[26]指出,在 ImageNet 数据集上取得较好结果的网络结构具有较强的泛化性,且残差网络(Residual Networks, ResNet)^[27]的迁移能力始终优于其他在 ImageNet 上取得更高准确率的网络,因此本文采用在 ImageNet 上预训练的 50 层残差网络(ResNet50)提取深度特征。

不同尺度下往往能得到地物不同方面的信息,很多学者的研究表明,综合利用多种尺度下提取的点云特征更有利于点云分类,得到的分类结果往往优于单一尺度下的分类结果^[17,19],因此本文利用 1.1.2 节所述方法将格网大小设置为 3 个不同的值($\omega=0.1, 0.15, 0.2$ m)生成 3 种尺度的点云特征图,然后利用 ResNet50 提取不同尺度的深度特征,并将多尺度深度特征连接得到最终用于分类的深度特征,多尺度深度特征提取流程如图 3 所示。




图 3 深度特征提取流程

Fig. 3 Flowchart of deep feature extraction

2.3 模型构建与分类

利用 ResNet50 从点云特征图中提取的深度

特征虽具有较好的泛化性,但其基于自然图像数据集训练的权重提取,直接用于点云分类难以保证其有效性。此外,考虑到神经网络越深,模型越复杂,训练所需的时间也越长,因此本文构建仅包含两层全连接层的神经网络模型,其结构如图 4 所示,图中每层全连接层下方的数字代表神经元个数, C 代表最终分类的类别数(本文中 $C=9$)。




图 4 点云分类全连接神经网络模型

Fig. 4 Fully connected neural network model for point cloud classification

构建好神经网络模型后,为了训练该模型以进行点云分类,需要定义训练过程中的损失函数。本文采用常用的交叉熵损失函数,其计算公式如式(5)所示。定义损失函数后,设置学习率为 $5e-6$,批大小(Batch size)为 128,epoch 为 100 训

练所构建的神经网络模型,并利用训练好的模型分类点云,得到最终结果。

$$loss = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_k^{(i)} \log(p_k^{(i)}), \quad (5)$$

式中: N, K 分别代表训练样本总数和待分类类别数; $y_k^{(i)} \in \{0, 1\}$,当训练样本 i 为类别 k 时, $y_k^{(i)} = 1$,否则为 0; $\hat{p}_k^{(i)} \in [0, 1]$,表示分类模型预测训练样本 i 为类别 k 的概率。

3 试验结果及比较

3.1 数据与试验方法

为了验证本文方法的效率和有效性,利用 ISPRS 三维点云语义标记竞赛的两组机载 LiDAR 点云数据(Training 和 Eval)进行试验,图 5 为两个区域点云数据按高程显示的结果。两组数据均为 Leica ALS50 系统于 2008 年 8 月采集,采集高度约为 500 m,其平均点密度约为每平方米 8 个,每组数据中都包含建筑物屋顶、树木、低矮植被、电力线、灌木、篱笆、地面、建筑物立面、车辆等 9 类不同地物,各类地物的详细信息如表 1 所示。所有试验均基于 Python3. 6, TensorFlow 和 Keras 实现,硬件环境为 CPU Intel Core i7-7700HK, 64 G RAM, GPU NVIDIA GTX1080Ti 11 G 的工作站。

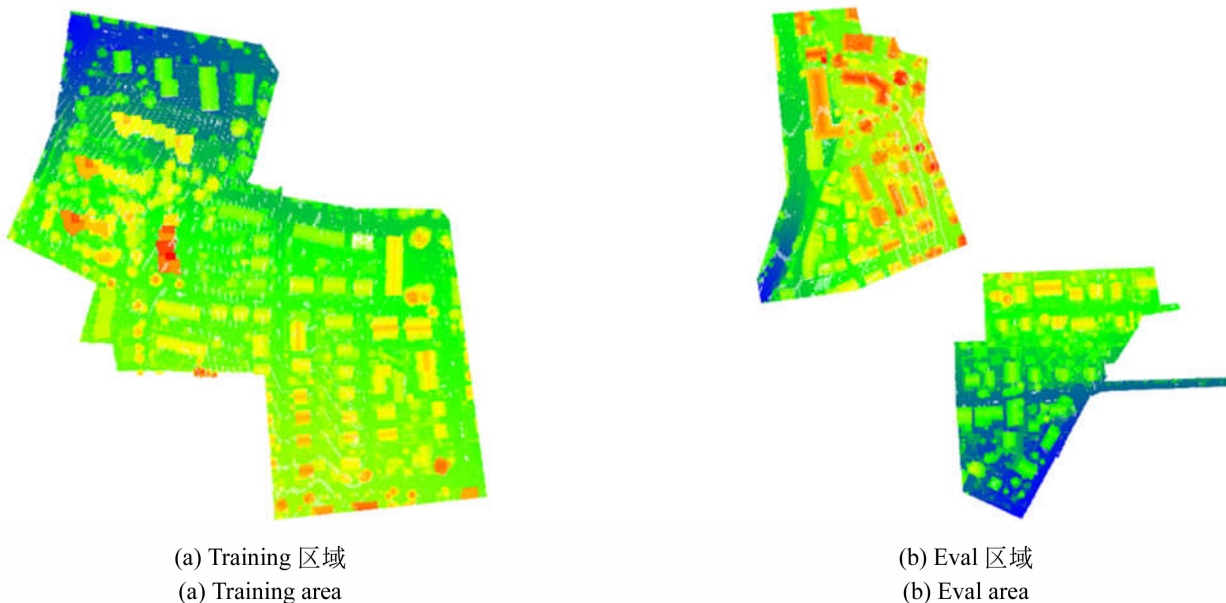


图 5 试验数据(按高程着色)

Fig. 5 Experimental datasets(colored by height)

本文先将 Training 区域点云划分为训练集 T_1 、验证集和测试集 3 部分,但由于电力线、车辆和篱笆点云较少,为了评价模型在 Training 区域的性能,将此 3 类点云的验证集也作为其测试集。为了与现有基于深度学习的机载 LiDAR 点云分类方法进行比较,再从 T_1 训练集中选取两组不同数量的训练集(分别记为 T_2, T_3 ,且满足 $T_3 \subset T_2, T_2 \subset T_1$)进行训练,并将训练的模型用于 Eval 区域的点云分类。选取的 T_2, T_3 数据集的数据量分别与文献[18],[19]的训练数据量相同,各组训练集的地物点数量统计如表 2 所示。

表 1 两组数据集的详细信息
Tab.1 Details of two datasets

类别	Training	Eval
电力线	546	600
低矮植被	180 850	98 690
地面	193 723	101 986
车辆	4 614	3 708
篱笆	12 070	7 422
屋顶	152 045	109 048
立面	27 250	11 224
灌木	47 605	24 818
树木	135 173	54 226
总和	753 876	411 722

表 2 不同训练数据集详细信息

Tab.2 Details of different training datasets

类别	T_1	T_2	T_3
电力线	546	546	446
低矮植被	22 005	18 005	4 000
地面	23 576	19 516	4 000
车辆	4 614	4 614	3 614
篱笆	12 070	12 070	4 000
屋顶	22 235	15 235	4 000
立面	17 731	13 731	4 000
灌木	20 850	11 850	4 000
树木	17 492	13 492	4 000
总和	141 119	109 059	32 060

试验的参数设置如前文所述,试验结果采用 ISPRS 竞赛中的分类结果统计所用指标,即精度(Precision)、召回率(Recall)和 F1 得分(F1 score),其计算方式参见文献[19]。

3.2 结果与分析

3.2.1 试验 1

为了对比不同训练数据得到的模型性能,统计模型在 Training 区域的各项分类指标。

在分析表 3 可知,随着训练数据的增加,精度有明显地提高,这与实际情况一致。对比不同地物的分类指标可知,本文方法对低矮植被、地面、

表 3 不同训练数据集分类指标统计结果

Tab.3 Statistical results of classification indices of different training data sets

(%)

类别	精度			召回率			F1 得分		
	T_1	T_2	T_3	T_1	T_2	T_3	T_1	T_2	T_3
电力线	61.5	27.8	10.1	40.0	60.5	66.0	48.5	38.1	17.6
低矮植被	97.1	97.0	96.9	93.7	92.5	88.5	95.4	94.7	92.5
地面	98.8	99.0	98.6	98.7	98.1	96.8	98.8	98.5	97.7
车辆	77.1	52.7	30.6	93.7	97.0	97.7	84.6	68.3	46.6
篱笆	34.0	39.1	19.7	95.8	91.7	87.7	50.2	54.8	32.2
屋顶	99.8	99.8	99.8	99.0	98.5	96.8	99.4	99.1	98.3
立面	81.1	81.6	74.0	98.6	98.2	97.2	89.0	89.1	84.0
灌木	74.7	68.8	59.5	80.0	83.2	77.7	77.2	75.3	67.4
树木	99.4	99.4	99.4	98.4	98.1	97.0	98.9	98.7	98.2
平均值	80.4	73.9	65.4	88.6	90.9	89.5	82.4	79.6	70.5

建筑物屋顶和树木这 4 类地物的分类效果相较于其他几类地物更好,这 4 类地物分类精度均在 97% 以上,其中建筑物屋顶分类精度达 99.8%,主要原因有:(1) f_{zv} , f_{in} 和 f_{ht} 3 种特征对这 4 类地物本身就具有较高的辨别力,利用 ResNet50 提取的深度特征进一步增强了其区分这 4 种地物的能力;(2)这 4 类地物数量相对较多,因此在错分相同数量点云的情况下,对这 4 类地物精度的影响相对较小;(3)这 4 类地物的训练数据量相对于其他地物更多,因此通过构建的神经网络更能学习到区分此 4 类地物的参数,从而能更好地区分此 4 类地物。本文方法对电力线的分类效果较差,主要是由于电力线的训练样本过少,因此无法很好地学习到区分电力线与其他地物的深层次特征。然而,尽管篱笆和灌木的训练样本较多,本文方法对这两类地物的分类效果较差,主要原因在于这两类地物的 f_{zv} , f_{in} 和 f_{ht} 3 种特征与地面点具有很高的相似度,导致较多地面点误分为此两类地物,同时,这两类地物的 f_{zv} , f_{in} 和 f_{ht} 也很相似,进一步降低了其分类精度。

为了验证本文方法的效率,本文统计利用不同数据集训练过程所需要的时间(包括提取深度特征和训练神经网络两部分),如图 6 所示。

从图 6 可以看出,即使在训练数据较多的情况下(T_1 训练数据集),整个训练过程也能在 40 min 左右完成,其中大部分时间耗费在深度特

征的提取,而对于数据量较小的训练数据集 T_3 ,本文方法能在 10 min 内完成训练过程。值得注意的是,本文所选用的 T_2 训练数据集数量与文献[18]相同,而文献[18]提出的方法需要 6 h 以上的训练时间,尽管本文试验的软硬件环境与其有一定差别,但对比时间统计结果,仍能得出本文方法具有较高效率的结论。

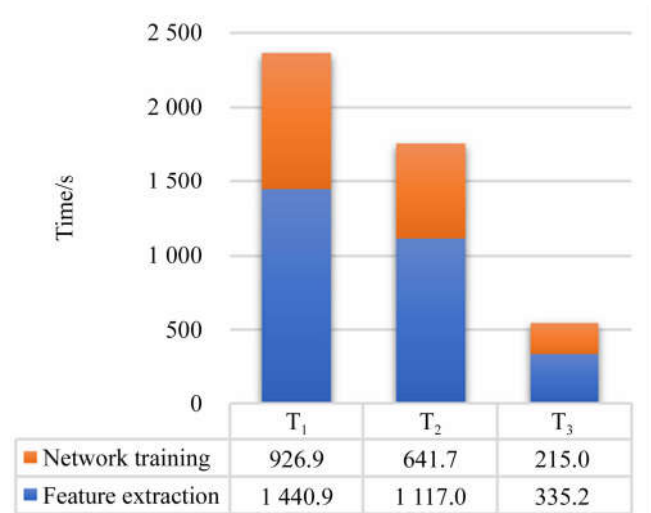


图 6 不同训练数据集训练过程所需时间统计

Fig. 6 Time of training process using different training datasets

3.3.2 试验 2

为了验证本文方法的泛化性,利用在 Training 区域的 T_1 , T_2 和 T_3 训练数据集上得到的分类

表 4 TL- T_1 分类结果混淆矩阵

Tab. 4 Confusion matrix of TL- T_1 classification results

(%)

类别	电力线	低矮植被	地面	车辆	篱笆	屋顶	立面	灌木	树木
电力线	36.7	3.8	0.2	0.2	0.0	27.3	11.7	8.0	12.2
低矮植被	0.0	94.7	0.6	0.0	0.4	0.0	0.0	4.2	0.0
地面	0.0	4.1	95.9	0.0	0.0	0.0	0.0	0.0	0.0
车辆	0.0	8.8	27.1	60.7	2.0	0.0	0.1	1.2	0.0
篱笆	0.0	36.4	0.6	0.0	21.8	0.0	0.5	40.7	0.0
屋顶	0.3	0.9	0.2	0.0	0.1	96.1	1.2	0.4	0.8
立面	0.1	8.3	0.2	0.0	0.7	1.7	76.9	9.3	2.8
灌木	0.0	28.6	0.1	0.0	2.4	0.0	0.1	67.8	0.9
树木	0.0	0.7	0.0	0.0	0.5	0.1	0.7	18.0	80.0
精度	42.1	84.9	98.1	97.5	50.9	99.6	82.7	47.6	96.5
召回率	36.7	94.7	95.9	60.7	21.8	96.1	76.9	67.8	80.0
F1 得分	39.2	89.6	97.0	74.8	30.5	97.8	79.7	55.9	87.5

模型对 Eval 区域的点云进行分类,分类结果分别记为 TL-T1, TL-T2 和 TL-T3。由于篇幅限制,

此处仅给出 TL-T1 分类结果的详细统计结果及效果图,分别如表 4 和图 7 所示。

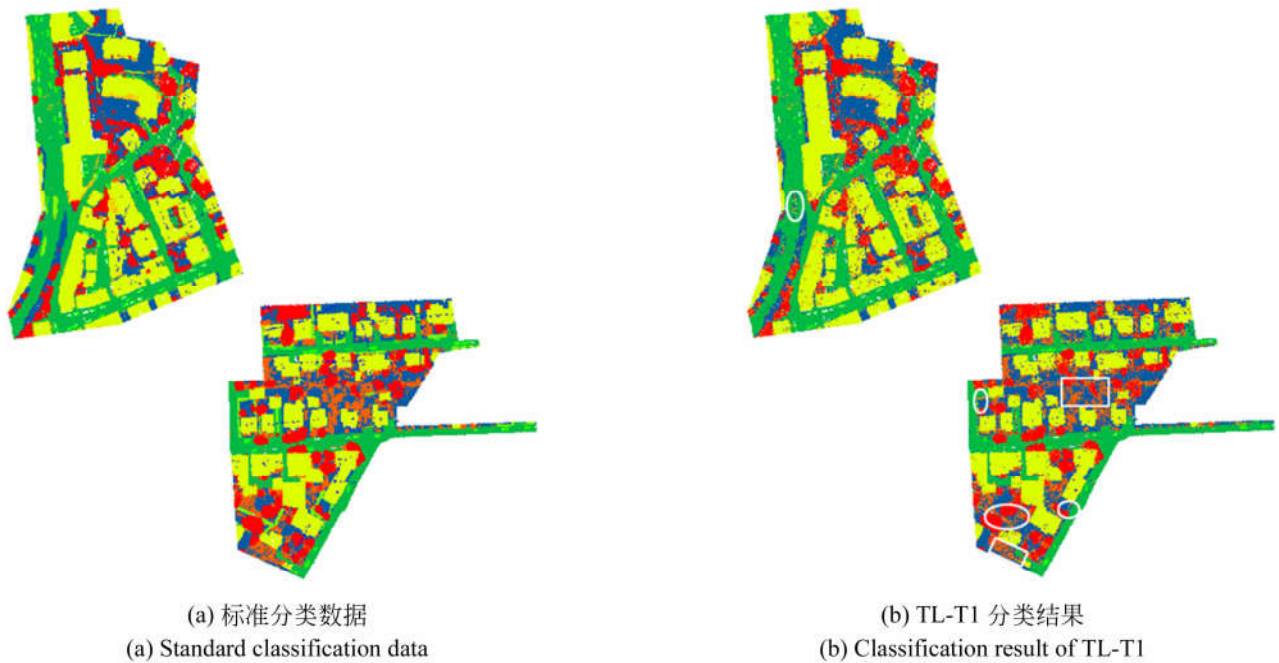


图 7 TL-T1 分类结果与标准分类数据对比

Fig. 7 Comparison of TL-T1 classification result and standard classification data

从表 4 中可以看出,本文方法对植被、地面、建筑物屋顶和树木分类较好(其中建筑物屋顶的 F1 得分为 97.8%),这与 3.2.1 节中的结论一致。同时,本文方法也能较好地 对车辆及建筑物立面进行分类,但电力线很大一部分被误分为建筑物屋顶,主要因为 T_1 训练集中包含如烟囱等屋顶附属物,而这些附属物点云被标记为建筑物屋顶,且由于试验所采用的点云数据密度较低,这些附属物点数较少,使得其邻域点的分布与真实的

电力线点云很相似,同时这些屋顶附属物点云的 f_{zv} , f_{in} 和 f_{ht} 特征值也与电力线很相似,从而导致了较多的电力线误分为建筑物屋顶。尽管低矮植被的召回率较高,但由于其 f_{zv} , f_{in} 和 f_{ht} 特征与灌木、篱笆相似,使得这两类地物存在较多的误分为低矮植被的情况(如图 7(b)中的白色矩形和椭圆所示),降低了低矮植被的分类精度,也导致这两类地物分类效果较差。

为了与现有的点云分类方法进行对比,除统

表 5 不同方法 F1 得分和 OA 对比

Tab. 5 Comparison of F1 scores and overall accuracy of different methods

方法	电力线	低矮植被	地面	车辆	篱笆	屋顶	立面	灌木	树木	OA
LUH	59.6	77.5	91.1	73.1	34.0	94.2	56.3	46.6	83.1	81.6
RIT_1	37.5	77.9	91.5	73.4	18.0	94.0	49.3	45.9	82.5	81.6
WhuY3	37.1	81.4	90.1	63.4	23.9	93.4	47.5	39.9	78.0	82.3
WhuY4	42.5	82.7	91.4	74.7	53.7	94.3	53.1	47.9	82.8	84.9
NANJ2	—	88.8	91.2	66.7	40.7	93.6	42.6	55.9	82.6	85.2
TL-T1	39.2	89.6	97.0	74.8	30.5	97.8	79.7	55.9	87.5	89.6
TL-T2	19.8	89.7	96.8	76.0	24.3	96.0	77.4	55.9	85.9	88.5
TL-T3	9.2	88.1	96.3	80.3	26.6	93.5	74.3	53.5	85.1	85.9

计 3.1 节中所述指标外,还统计了本文方法分类的整体精度 (Overall Accuracy, OA)。表 5 为 ISPRS 官网上公布的 F1 得分排名前 5 的论文结果与本文方法的分类结果对比。

表 5 中 LUH^[17] 利用两层层级条件随机场 (CRF) 结合点云上下文信息进行点云分类; NANJ2^[19], WhuY3^[18] 和 WhuY4 均为基于点云特征图的深度学习点云分类,其中 WhuY3 基于单一尺度的点云特征图,NANJ2 和 WhuY4 基于多尺度点云特征图,3 种方法的不同点主要在于生成点云特征图所采用的低层次特征以及采用的神经网络模型;RIT_1^[20] 为基于 PointNet^[28] 框架构建的全连接神经网络的点云分类,该方法利用了点云的归一化坐标值以及光谱特征,并能直接处理三维点云,各方法的简要介绍参见文献[20],此处不再赘述。需要注意的是,尽管 NANJ2 是目前整体精度最高的方法,但由于电力线样本数过少,NANJ2 并未对电力线进行分类,即仅对其余 8 类地物进行分类。

对比表 5 中不同点云分类方法的 F1 得分可知,基于深度学习的点云分类方法优于传统方法,在基于深度学习的点云分类方法中,本文方法具有最高的整体分类精度,且各类地物的 F1 得分

也较高,仅有电力线和篱笆两类地物的 F1 得分低于其他方法。同时,由于本文方法生成的点云特征图较好地保留了点云之间的空间关系,因此相对于其他方法,建筑物立面的分类精度得到了较大的提高。需要注意的是,TL-T2 和 TL-T3 的训练数据量分别与 WhuY3 和 NANJ2 训练样本数相同,对比其分类结果可知,在相同训练数据量的情况下,本文方法可以得到更好的分类结果,主要原因在于本文所提出的生成点云特征图的策略更好。对比 TL-T3 和 WhuY3 可知,本文方法即使在少量训练数据的情况下也能取得较好的分类结果,主要在于本文生成点云特征图策略的有效性以及利用 ResNet50 提取的深度特征较强的分辨力。此外,从表 5 可知,本文方法具有较强的泛化能力,对比 TL-T1,TL-T2 和 TL-T3 3 组试验结果可知,随着训练样本的增多,分类整体精度在不断上升,即泛化能力呈增长趋势,这与实际情况相符。

为了从直观上对比本文方法和其他方法的分类结果,此处给出 NANJ2, WhuY4, RIT_1 及本文方法 TL-T1 的正确分类点云和误分点云对比图,如图 8 所示(彩图见期刊电子版),图中红色、绿色分别代表错误分类、正确分类的点云。




图 8 不同方法正确分类与误分类结果对比

Fig. 8 Comparison of correct classification and misclassification results of different methods

从图 8 可知,本文方法误分类的点云较少,除篱笆误分类较为集中外(图 8(d)中白色矩形框所示),其余误分类点分布较为离散,且对比图 8(a)~图 8(d)可知,本文分类方法误分类点云明显少于其他方法,尤其在图 8(d)中蓝色矩形框所示区域。然而,尽管在点云特征图的生成时考虑了点

云邻域信息,但本文方法实质上仍然是基于单点的分类,因此存在较多不合理分类的情况,如建筑物屋顶中包含立面点和低矮植被点等。为了进一步提高点云分类精度并消除不合理的分类情况,需要结合如 CRF 等考虑点云上下文信息的方法,这也是今后研究的方向。

4 结 论

现有的传统点云分类方法精度普遍较低,而基于深度学习的点云分类方法训练耗时长。针对这些问题,本文提出一种利用迁移学习的机载激光雷达点云分类方法,将迁移学习引入点云分类中,在有效地提高分类精度的同时,较大程度上降低了训练所需时间。利用两组 ISPRS 标准点云

数据进行试验,结果表明,本文方法可以得到效果较好的点云分类结果,整体分类精度为 89.6%,比现有 ISPRS 官网报道的最佳分类方法的整体分类精度高 4.4%。然而,尽管本文方法能得到精度较高的分类结果,但分类时没有考虑点云上下文信息,导致存在一些不合理分类的情况,因此结合点云上下文信息实现更好地分类点云是进一步研究的方向。

参考文献:

- [1] WEINMANN M, JUTZI B, HINZ S, *et al.*. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, 105: 286-304.
- [2] DU S J, ZHANG Y S, ZOU Z R, *et al.*. Automatic building extraction from LiDAR data fusion of point and grid-based features[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 130: 294-307.
- [3] 杨俊涛, 康志忠. 多尺度特征和马尔可夫随机场模型的电力线场景点云分类法[J]. 测绘学报, 2018, 47(2): 188-197.
- YANG J T, KANG ZH ZH. Multi-scale features and Markov random field model for powerline scene classification[J]. *Acta Geodaetica Et Cartographica Sinica*, 2018, 47(2): 188-197. (in Chinese)
- [4] 张继贤, 段敏燕, 林祥国, 等. 激光雷达点云电力线三维重建模型的对比与分析[J]. 武汉大学学报(信息科学版), 2017, 42(11): 1565-1572.
- ZHANG J X, DUAN M Y, LIN X G, *et al.*. Comparison and analysis of models for 3D power line reconstruction using LiDAR point cloud[J]. *Geomatics and Information Science of Wuhan University*, 2017, 42(11): 1565-1572. (in Chinese)
- [5] 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)
- [6] BOYKO A, FUNKHOUSER T. Extracting roads from dense point clouds in large scale urban environment[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2011, 66(6): S2-S12.
- [7] VO A V, TRUONG-HONG L, LAEFER D F, *et al.*. Octree-based region growing for point cloud segmentation[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, 104: 88-100.
- [8] 李明磊, 李广云, 王力, 等. 采用八叉树体素生长的点云平面提取[J]. 光学精密工程, 2018, 26(1): 172-183.
- LI M L, LI G Y, WANG L, *et al.*. Planar feature extraction from unorganized point clouds using octree voxel-based region growing[J]. *Opt. Precision Eng.*, 2018, 26(1): 172-183. (in Chinese)
- [9] 王晓辉, 吴禄慎, 陈华伟, 等. 应用改进的粒子群优化模糊聚类实现点云数据的区域分割[J]. 光学精密工程, 2017, 25(4): 563-573.
- WANG X H, WU L SH, CHEN H W, *et al.*. Region segmentation of point cloud data based on improved particle swarm optimization fuzzy clustering[J]. *Opt. Precision Eng.*, 2017, 25(4): 563-573. (in Chinese)
- [10] ZHU Q, LI Y, HU H, *et al.*. Robust point cloud classification based on multi-level semantic relationships for urban scenes[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 129: 86-102.
- [11] 高仁强, 张显峰, 孙敏, 等. 融合无人机 LiDAR 和高分辨率光学影像的点云分类方法[J]. 南京信

- 息工程大学学报(自然科学版), 2018, 10(1): 102-112.
- GAO R Q, ZHANG X F, SUN M, *et al.*. Fusion of high-resolution optical image and unmanned aerial vehicle LiDAR for 3D point cloud classification [J]. *Journal of Nanjing University of Information Science & Technology (Natural Science Edition)*, 2018, 10(1): 102-112. (in Chinese)
- [12] 潘锁艳, 管海燕. 机载多光谱 LiDAR 数据的地物分类方法[J]. 测绘学报, 2018, 47(2): 198-207.
- PAN S Y, GUAN H Y. Object classification using airborne multispectral LiDAR data[J]. *Acta Geodaetica Et Cartographica Sinica*, 2018, 47(2): 198-207. (in Chinese)
- [13] 刘志青, 李鹏程, 陈小卫, 等. 基于信息向量机的机载激光雷达点云数据分类[J]. 光学精密工程, 2016, 24(1): 210-219.
- LIU ZH Q, LI P CH, CHEN X W, *et al.*. Classification of airborne LiDAR point cloud data based on information vector machine[J]. *Opt. Precision Eng.*, 2016, 24(1): 210-219. (in Chinese)
- [14] 朱江涛, 黄睿. 基于 AdaBoost 的高光谱与 LiDAR 数据特征选择与分类[J]. 遥感信息, 2014, 29(6):68-72.
- ZHU J T, HUANG R. Feature selection and classification of hyperspectral data and LiDAR data based on AdaBoost[J]. *Remote Sensing Information*, 2014, 29(6):68-72. (in Chinese)
- [15] NIEMEYER J, WEGNER J D, MALLETT C, *et al.*. Conditional random fields for urban scene classification with full waveform LiDAR data[C]. *ISPRS Conference on Photogrammetric Image Analysis*. Springer-Verlag, 2011:233-244.
- [16] GUO B, HUANG X, ZHANG F, *et al.*. Classification of airborne laser scanning data using Joint-Boost[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2015, 100: 71-83.
- [17] NIEMEYER J, ROTTENSTEINER F, SOER- GEL U. Contextual classification of LiDAR data and building object detection in urban areas[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, 87(1):152-165.
- [18] YANG Z S, JIANG W S, XU B, *et al.*. A convolutional neural network-based 3D semantic labeling method for ALS point clouds[J]. *Remote Sensing*, 2017, 9(9): 936.
- [19] ZHAO R, PANG M, WANG J. Classifying airborne LiDAR point clouds via deep features learned by a multi-scale convolutional neural network [J]. *International Journal of Geographical Information Science*, 2018(3):1-20.
- [20] YOUSEFHUSSIEN M, KELBE D J, IENTILUC- CI E J, *et al.*. A multi-scale fully convolutional network for semantic labeling of 3D point clouds [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2018, 143: 191-204.
- [21] WANG J, LUO C, HUANG H Q, *et al.*. Transferring pre-trained deep CNNs for remote scene classification with general features learned from linear PCA network[J]. *Remote Sensing*, 2017, 9(3): 225.
- [22] RUSSAKOVSKY O, DENG J, SU H, *et al.*. ImageNet large scale visual recognition challenge[J]. *International Journal of Computer Vision*, 2015, 115(3): 211-252.
- [23] ZHANG W M, QI J B, WAN P, *et al.*. An easy-to-use airborne LiDAR data filtering method based on cloth simulation[J]. *Remote Sensing*, 2016, 8(6): 501.
- [24] BOULCH A, MARLET R. Fast and robust normal estimation for point clouds with sharp features [C]. *Computer graphics forum*. Blackwell Publishing Ltd, 2012, 31(5): 1765-1774.
- [25] TAN C Q, SUN F C, KONG T, *et al.*. *A Survey on Deep Transfer Learning* [M] Artificial Neural Networks and Machine Learning-ICANN 2018. Cham: Springer International Publishing, 2018: 270-279.
- [26] KORNBLITH S, SHLENS J, LE Q V. Do better ImageNet models transfer better? [J]. *arXiv preprint arXiv: 1805. 08974*, 2018.
- [27] HE K M, ZHANG X Y, REN S Q, *et al.*. Deep residual learning for image recognition [C] 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 27-30, 2016. Las Vegas, NV, USA. New York, USA: IEEE, 2016.

- [28] CHARLES R Q, HAO S, MO K C, *et al.*.
PointNet: deep learning on point sets for 3D clas-
sification and segmentation[C] 2017 *IEEE Con-*

*ference on Computer Vision and Pattern Recogni-
tion (CVPR)*, July 21-26, 2017. *Honolulu,
HI. New York, USA: IEEE*, 2017, 1(2): 4.

作者简介:



赵 传(1991—),男,湖南湘潭人,博士
研究生,2014年、2017年于解放军信息
工程大学分别获得学士、硕士学位,主
要从事机载 LiDAR 点云数据处理与建
筑物三维模型重建,数字摄影测量的研
究。E-mail: zc_mail163@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: zbm1961@163.
com