

机载激光雷达数据的三维深度学习树种分类*

刘茂华¹, 韩梓威¹, 陈一鸣², 刘正军², 韩颜顺²

(1. 沈阳建筑大学 交通工程学院, 辽宁 沈阳 110168; 2. 中国测绘科学研究院, 北京 100089)

摘要:针对传统基于激光雷达(Light Detection And Ranging, LiDAR)数据的树种分类方法难以直接且全面地利用点云的三维结构信息的问题,提出一种基于三维深度学习的机载LiDAR数据的树种分类方法。该方法直接从三维数据中抽象出高维特征,而无须将点云转化为体素或二维图像。以塞罕坝国家森林公园内白桦和落叶松两个树种的无人机LiDAR数据为研究对象,对其进行数据滤波,去除噪声和地面点;基于点云距离和改进的分水岭分割的方法提取单木并制作数据集;最终建立由权重共享的多层感知器、最大池、全连接层和softmax分类器组成的深层神经网络,其能自动提取树木的高维特征并实现树种分类。实验结果显示分类总体准确率为86.7%,kappa系数为0.73,最优特征维度为1 024,最优点密度为2 048。与将单木点云投影到二维视图的方法相比,该算法提供了更高的分类精度,且能有效减少计算成本、提高工作效率。

关键词:机载激光雷达;点云;三维深度学习;树种分类

中图分类号:O43 文献标志码:A 文章编号:1001-2486(2022)02-123-08

Tree species classification of airborne LiDAR data based on 3D deep learning

LIU Maohua¹, HAN Ziwai¹, CHEN Yiming², LIU Zhengjun², HAN Yanshun²

(1. School of Transportation Engineering, Shenyang Jianzhu University, Shenyang 110168, China;

2. Chinese Academy of Surveying and Mapping, Beijing 100089, China)

Abstract: Aimed at the problem that the traditional tree species classification method based on LiDAR (light detection and ranging) data is difficult to directly and comprehensively use the 3D structure information of the point cloud, a tree species classification method of airborne LiDAR data based on 3D deep learning was proposed. This method directly abstracts high-dimensional features from 3D data without converting point clouds into voxels or two-dimensional images. Taking the airborne LiDAR data of white birch and larch in Saihanba National Forest Park as the research object, data filtering was performed to remove noise and ground points; the point cloud distance and improved watershed segmentation method were used to extract the individual wood and make a data set. Finally, a deep neural network composed of a weight-sharing multi-layer perceptron, a max pooling, a fully connected layer and a softmax classifier was established, which can extract the high-dimensional features of trees automatically and realize tree species classification. The experimental results show that the overall classification accuracy rate is 86.7%, the kappa coefficient is 0.73, the optimal feature dimension is 1 024, and the most advantageous point density is 2 048. Compared with the method projecting individual tree point cloud to a two-dimensional view, this algorithm provides higher classification accuracy, and can reduce the calculation cost effectively and improve work efficiency.

Keywords: airborne LiDAR; point cloud; 3D deep learning; tree species classification

树种分类是生态环境、林业测量、遥感等众多行业和领域的重点研究课题,因为树种识别对生态系统评估、生物多样性监测和森林资源利用起着至关重要的作用^[1-2]。传统的树种分类方法通常是利用高光谱遥感技术,通过树木的光谱信息区分不同的树种。然而,高光谱数据冗余度大,且存在着“同谱异物”和“同物异谱”的现象,忽略了树木的三维结构信息^[3]。激光雷达(Light

Detection And Ranging, LiDAR)是一种先进的主动遥感技术,它能够高精度地快速获取地表目标的高度信息和三维结构信息,且具有抗干扰能力强、低空探测性能好等优点^[4-5]。随着无人机技术的快速发展,无人机LiDAR为快速、准确的植被精细分类提供了有力的技术支撑^[6]。

近年来,深度学习技术在三维数据上取得了很好的发展,根据输入网络的表达方式可以概括

* 收稿日期:2020-10-25

基金项目:国家自然科学基金资助项目(41730107,41671414);中国测绘科学研究院基本科研业务费资助项目(AR1920)

作者简介:刘茂华(1981—),男,辽宁铁岭人,副教授,博士,硕士生导师,E-mail:liumaohua1115@126.com;

陈一鸣(通信作者),男,助理研究员,博士,E-mail:sjzlmh@163.com

为以下三种:①基于体素的方法一般是将三维模型划分为三维网格后再进行 3D 卷积,代表模型有 VoxNet、3D ShapeNets、O-CNN 等^[7-9];②基于多视图的方法是先三维模型通过投影等方法得到二维图像,再利用图像领域的方法进行处理,代表模型有 MVCNN、FPNN、DeepPano 等^[10-12];③基于点的方法是网络能够适应三维数据的特点,直接对点云进行处理,代表模型有 PointNet、PointNet++、PointCNN 等^[13-15]。

由于深度学习在特征提取上的优势,近年来有学者将该技术运用到基于 LiDAR 数据的树种识别。Guan 等^[16]基于体素实现了滤波和单木分割,然后将树的点密度用波形表示,再利用深度玻尔兹曼机(Deep Boltzmann Machine, DBM)实现了对城市树种的分类;Zou 等^[17]利用栅格化的方法在样本空间中划分体素,将每个体素格网中的点云数累积,投影到包含树木轮廓的二维图像上,每 30°重复投影,并用一个深度信念网络(Deep Belief Network, DBN)来生成高级特征,从而进行树种分类;Hamraz 等^[18]将点云转化为数字表面模型(Digital Surface Model, DSM)和 2D 视图,再利用深度卷积神经网络(Convolutional Neural Networks, CNN)对针叶树和落叶树分类。

然而,这些研究都是先将点云进行规则化处理,例如转换成体素或二维图像,而没有直接利用三维数据进行特征提取或分类。体素划分不仅会呈指数级地增加计算成本,还会受到分辨率的限制,存在局部信息丢失的现象。多视图投影的方法不能充分利用点云的三维结构信息,在点分类和场景理解等 3D 任务上具有较大的局限性。因此,本文基于森林样区内获取的无人机 LiDAR 点云数据,提出了一种新的树种分类方法,该方法将无序的点云数据作为神经网络的输入,直接利用其三维信息进行特征提取,实现白桦树和落叶松两个树种的分类。

1 方法与实验

1.1 研究区概况与数据获取

研究区域为中国河北省承德市围场满族蒙古

族自治县内的塞罕坝国家森林公园(42°24'N, 117°19'E)的一部分,海拔高度为 1 500 ~ 2 067 m,植被覆盖度约为 80%。研究区内包括白桦和落叶松两类树种共计约 1 790 棵,两类树主要以一条较宽的土路为分隔,其中白桦树主要分布在路的西北部,约 870 棵;落叶松分布在路的东南部,约 920 棵。

实验数据由大疆无人机搭载的 Riegl 公司 miniVUX 1U 激光雷达扫描仪于 2019 年 8 月 24 日获取,航线间距 40 m,航高 50 m,飞行速度 5 m/s,激光雷达扫描角 90°~270°,扫描线速度 100 m/s。基于该无人机 LiDAR 系统获得的原始数据如图 1 所示,两类树种点云样例数据如图 2 所示,样区内各树种的结构特征见表 1。

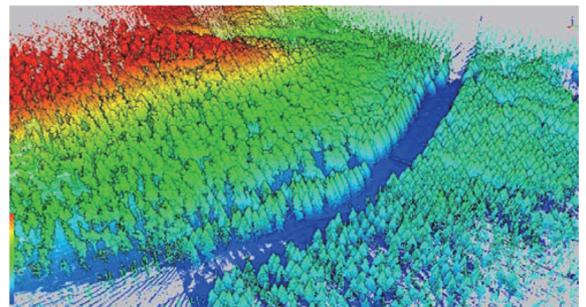


图 1 无人机 LiDAR 原始数据
Fig. 1 Airborne LiDAR raw data

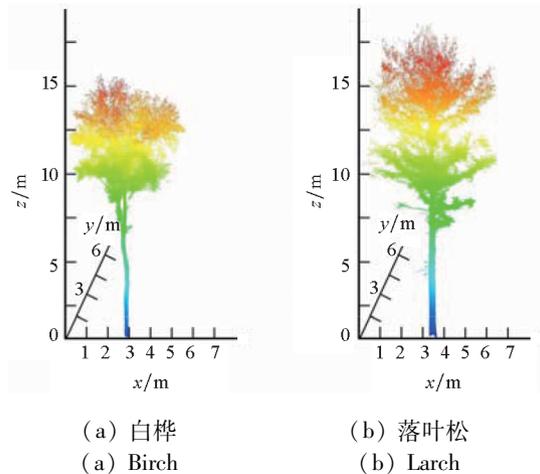


图 2 基于无人机 LiDAR 系统的点云样本示例
Fig. 2 Example of point cloud sample based on airborne LiDAR system

表 1 样本树木结构特征

Tab. 1 Sample tree structure characteristics

树种	平均树高 /m	平均冠幅 宽度 /m	平均胸径 长度 /cm	平均树干高 /m	单木平均 激光点数/个	数量/棵
白桦	15.89 ± 2.84	5.28 ± 2.23	72.98 ± 17.25	5.23 ± 4.04	37 984	873
落叶松	18.62 ± 1.68	6.94 ± 2.05	95.16 ± 19.41	5.75 ± 2.45	40 563	921

1.2 工作流程

对于获取的原始无人机 LiDAR 点云数据,首先进行预处理,包括去噪和地面滤波。其次,对预处理后的森林点云数据进行单木分割,获取单木点云。再次,对单木点云添加标签,制作数据集。训练集用于训练神经网络模型,测试集用于对得到的模型测试树种分类精度。最后,对可能的分类精度影响因素进行分析,并做对比实验。基于机载 LiDAR 数据的三维深度学习树种分类工作流程如图 3 所示。

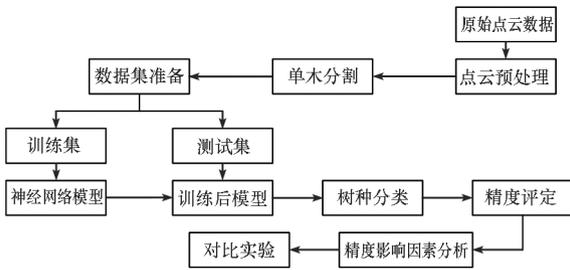


图 3 树种分类工作流程

Fig. 3 Work flow of tree species classification

1.3 数据预处理

1.3.1 去噪与地面滤波

由于森林环境的复杂性,获取机载 LiDAR 数据的过程中会产生粗差,因此必须先对原始点云数据去噪。对每一个点搜索相同个数的邻域点,经多次实验发现,当邻近点个数为 10 时,去噪效果最好。然后计算该点到邻域点的距离平均值 D_{mean} 及其中值 m 和标准差 σ 。计算最大距离 D_{max} :

$$D_{\text{max}} = m + K\sigma \quad (1)$$

其中, K 为标准差倍数,设置为 5。若 D_{mean} 大于 D_{max} ,则认为该点为噪点,将其去除。

为消除地形影响,需要先对去噪后的点云数据进行地面滤波,以获得更准确的单木分割结果。本文利用改进的渐进加密三角网滤波算法^[19]对地面点与非地面点进行分离。首先对 LiDAR 点云以 1 m 的尺寸划分网格,取每个网格的最低点进行光栅化,再利用形态学开操作选取潜在地面种子点 $G_{\text{potential}}$ 。然后,利用平移平面拟合法滤除 $G_{\text{potential}}$ 中的非地面点,进而获得准确的地面种子点 G_{seeds} 。最后,建立 TIN 模型,执行先向下再向上的迭代加密,得到地面点 G_{result} 。地面点和非地面点的分类结果如图 4 所示,其中蓝色点为地面点 G_{result} ,白色点是树木点,删除地面点即完成滤波。

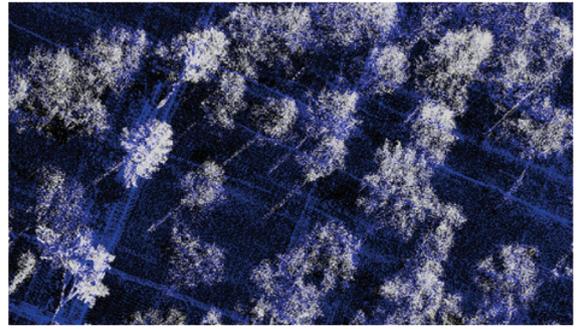


图 4 地面点与非地面点的分类结果

Fig. 4 Classification results of ground points and non-ground points

1.3.2 单木分割

为了制作深度学习的数据集,向每棵树添加代表树种的标签,需要对原始的森林数据进行单木分割。单木提取存在一定的错误率,例如欠分割、多树粘连等情况,所以使用单一方法分割得到的高质量单木数量较少。因不同分割方法得到的单木三维形状有所差异,可作为数据增强的一种方法,故本实验分别采取改进的分水岭分割算法^[20]和基于点云距离的分割方法^[21]对原始的森林点云数据进行分割,以筛选出数量足够多的高质量单木点云。改进的分水岭分割算法首先从原始的激光脉冲生成数字表面模型和数字高程模型,进而得到冠层高度模型;然后,通过在具有可变窗口大小的冠层最大值模型中搜索局部最大值来检测树梢,其窗口大小由冠部大小和树高度之间的回归曲线预测间隔的下限确定,该步骤可有效减少对树顶点的判别错误;最后,利用 Marker-controlled 分水岭算法完成单木分割,如图 5 所示。基于点云距离的分割将点按顺序从高到低进行分类,间距大于指定阈值的点排除在目标树之外,间距小于阈值的点根据最小间距规则进行分类,分割结果如图 6 所示。通过这两种算法,共分割出单木 3 598 棵,经人工筛选,删除过分割、欠分割以及粘连严重的树,保留 1 200 棵高质量树作为实验数据。

1.3.3 样本集准备

深度神经网络需要输入样本具有相同的点云数,故将所有单木均匀采样 2 048 个点,并将每棵树零均值归一化至单位球内,以解决点的平移不变性。向每棵树添加标签,其中白桦树记为 0,落叶松记为 1。为了避免因种植区域相同而导致分类器可能过于适合研究地点的情况,从不同的空间中划分数据。将整个数据集按照 8 : 2 的比例随机分成训练集和测试集,其中训练数据取自研



图 5 基于改进的分水岭分割的单木分割结果

Fig. 5 Results of individual tree segmentation based on improved watershed segmentation

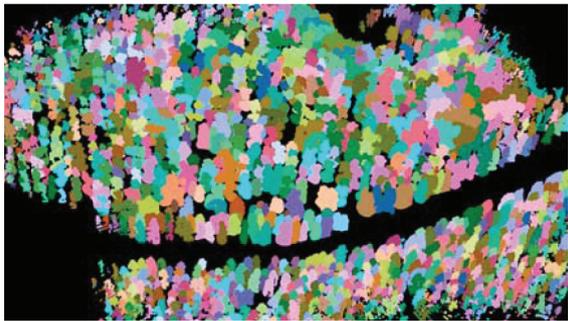


图 6 基于点云距离的单木分割结果

Fig. 6 Results of individual tree segmentation based on point cloud distance

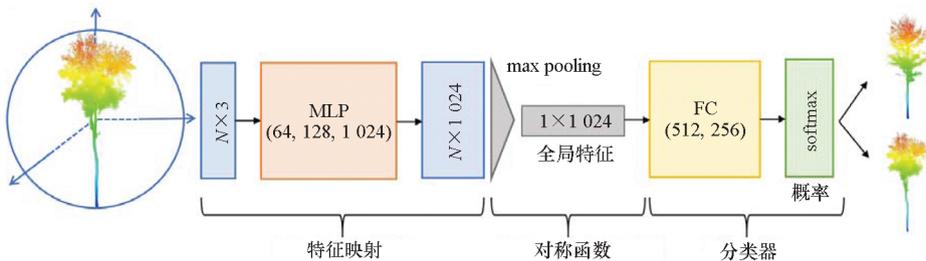


图 7 神经网络模型

Fig. 7 Neural network model

块,以全局特征作为输入,通过两个全连接层和一个 softmax 分类器得到两个树种的分类概率。

1) 特征映射模块:多层感知器是一种前向结构的人工神经网络,层与层之间全连接,在输入与输出的向量之间能够进行非线性映射。将输入层向量记为 X ,则隐藏层的输出为 $f(W_1 X + b_1)$,其中 W_1 为权重(也叫连接系数), b_1 为偏置, f 是激活函数。在该网络模型中,感知器的每一层都使用了 ReLU 激活函数和批处理归一化,输出大小依次为 64、128、1 024。

2) 对称函数模块:点云是一个无序点的集合,而点的顺序不会影响这个集合本身。如果把点云表示为一个 N 行 D 列的二维矩阵(其中 N 代

究区西侧,测试数据选取研究区的东侧树。最后,将包含 (x, y, z) 坐标的原始点云数据、标签值和归一化数据转换成 HDF5 格式。详见表 2。

表 2 训练集与测试集

Tab. 2 Training set and test set

数据集	数量/棵	树的种类	各树种的 数量/棵
训练集	960	白桦	480
		落叶松	480
测试集	240	白桦	120
		落叶松	120

1.4 网络模型构建

网络模型分为特征映射模块、对称函数模块和分类器模块,如图 7 所示。对每一个单木点云取固定值 N 个点,每个点有三个维度的特征 (x, y, z) ,即点的三维坐标。在特征映射模块中,输入的是 $N \times 3$ 的矩阵,经过三层权重共享的多层感知器(Multi-Layer Perceptron, MLP)将每个点映射到 1 024 维的高维空间,得到 $N \times 1\ 024$ 的特征矩阵。在对称函数模块,通过对称函数 max pooling 得到 $1 \times 1\ 024$ 维的全局特征。最后,在分类器模

表点的个数, D 代表点的维度),对该矩阵做行变换则一共有 $N!$ 种变换方式,而这 $N!$ 种置换代表的是同一点集,因此网络需要拥有对点云的置换不变性。对称函数能够很好地解决这个问题,例如对某一点的集合 $X(x_1, x_2, \dots, x_n)$,取该集合的最大值、最小值、平均值都与点的顺序无关。但是,直接对每个点做对称操作,例如取最大值,会得到整个点集的最远点值;取平均值,会得到点集的重心,这样会损失点集有意义几何信息。因此,在网络结构中,首先利用 MLP 对每个点做相同的高维映射,通过高维空间中信息的冗余性避免对称操作导致的信息丢失。该结构实质上是 h, g, Y 的函数组合:

$$f(x_1, x_2, \dots, x_n) = Yg(h(x_1), h(x_2), \dots, h(x_n)) \quad (2)$$

其中, h 代表高维映射, g 代表对称函数, Y 代表 MLP 整合信息。

3) 分类器模块: 对于得到的全局特征向量, 将其输入两个全连接层 (Fully Connected layers, FC) 中, 并在最后一个层 (输出维度为 256) 中使用 0.7 的 dropout 防止过拟合。在 softmax 分类损失中加入一个正则化损失 (权重为 0.001), 使矩阵接近正交。

1.5 实验过程

实验使用 NVIDIA Tesla V100 - PCIE - 16 GB 显卡, 在 Ubuntu 18.4 系统下搭配 cuda 10.0 框架和 cuDNN 7.4.1 加速库训练。编译语言使用 Python3.6, 深度学习框架为 Tensorflow - gpu - 1.13.1。模型使用 Adam 优化器, 初始学习率为 0.001, 最小学习率设定为 0.000 01, 通过指数衰减的方式实现学习率衰减, 衰减率为 0.7, 动量为 0.9, 共训练 200 个周期, 每 20 个周期学习率除以 2, 批处理归一化的衰减率从 0.5 开始, 逐渐增加到 0.99, 训练时长 18 min。为了更好地提高模型的泛化能力, 在训练过程中, 通过沿上轴随机旋转物体来动态地增强点云, 并通过均值为 0 和标准偏差为 0.02 的高斯噪声来抖动每个点的位置。

为了探究单木分割效果对分类结果的影响, 同时使本文方法和实验结果更具实际意义, 本文又对数据集的结构做了改变。保持原数据集单木个数不变, 随机抽取 10%、20%、30%、40%、50% 的树木样本, 并加入同等数量的非完整分割单木。如图 8 所示, 替换的样本有过分割和欠分割的单木, 非完整分割的程度及替换次序为随机抽取, 未经人工干预。

为了证明本实验方法的优越性, 与以下三种方法进行比较。

方法 1: 参考 Lin 等^[22] 提出的方法, 计算点云数据的 9 个点分布特征参数、13 个冠内结构参数、11 个树外结构参数, 共计 33 个特征参数输入一个三层的 MLP 分类器中进行树种分类。

方法 2: 参考 Guan 等^[16] 提出的方法, 如图 9 所示, 取预定义的波形维数 n 为 50, 对分割得到的单木进行 n 个剖面的垂直剖分, 将每个剖面的点统计值归一化至 0~1 内, 以生成波形图。将得到的波形图输入一个两层的 DBM 模型中生成高级特征, 进行树种分类。

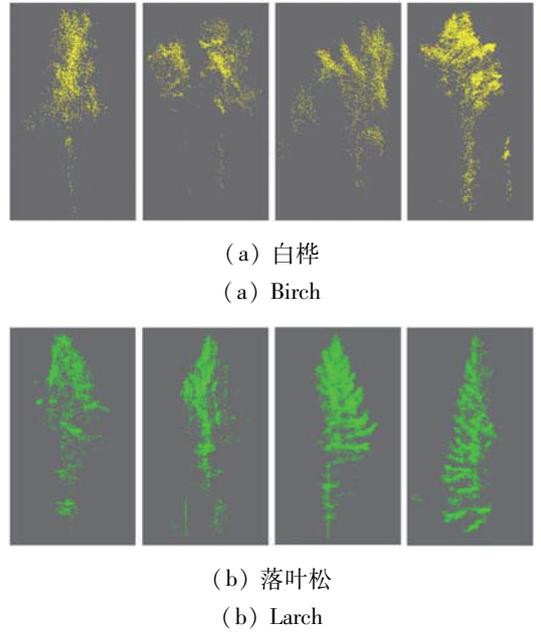
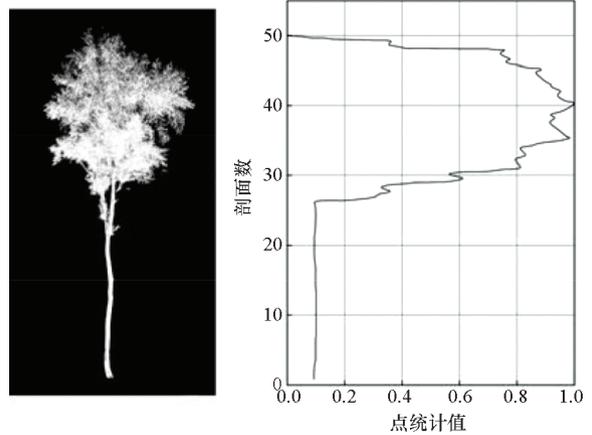


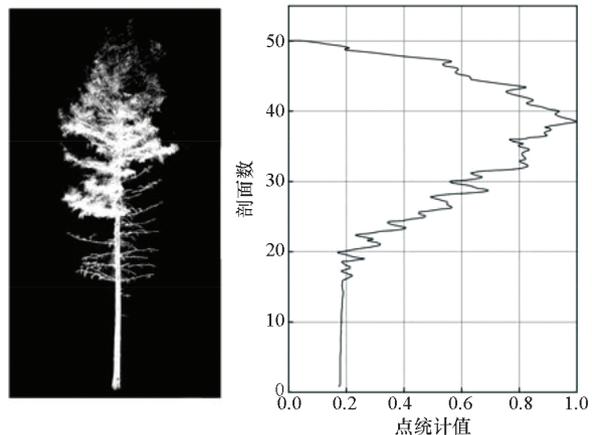
图 8 非完整分割单木示例

Fig. 8 Example of incomplete segmented individual tree



(a) 白桦树样本及其波形图

(a) Sample of white birch tree and its waveform



(b) 落叶松样本及其波形图

(b) Sample of larch and its waveform

图 9 树样本及其对应的波形图

Fig. 9 Tree samples and their corresponding waveforms

方法 3:参考 Zou 等^[17]提出的方法,在样本空间中对本木做栅格化划分,计数每个网格块中的点数,沿 y 轴在 xz 平面上积累网格,得到类似灰度图像的图片。对单木点云以相同的旋转度数重复投影,得到的二维图像作为树木的低级特征输入一个三层的 DBN,再使用 softmax 分类器对同一棵树的所有投影图像的分类结果进行投票。参与投票的每幅图像使用相同的权重,并通过赢得大部分选票的类别结果来判定树种。图 10 为每旋转 36° 后的栅格化示意,蓝色虚线框内为投影结果。实验中分类最优结果产生在旋转角度为 10° 时。

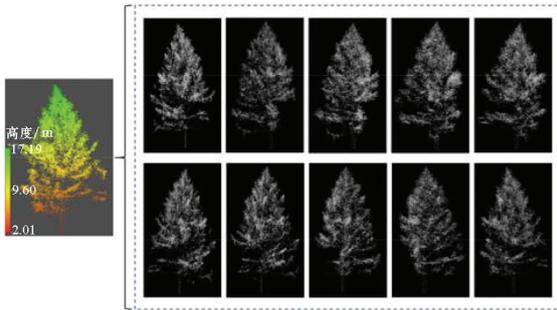


图 10 单木的栅格化与投影

Fig. 10 Rasterization and projection of individual tree

2 结果

2.1 分类精度

实验分类结果如表 3 所示,树种分类的总体准确率 (Overall Accuracy, OA) 为 86.7%, kappa 系数为 0.73;生产者精度 (Producer's Accuracy, PA) 高于 85.5%,用户精度 (User Accuracy, UA) 高于 85.0%。图 11 显示了数据集中非完整分割单木所占比例对分类结果的影响。由图可以看出,当少量样本质量变低时(如占比 10%),分类准确率并没有受到较大影响,说明该网络的鲁棒性较好。当低质量样本变多时(如占比 30% 以上),网络的分类精度会迅速下降,说明此时数据集的质量对网络的学习产生了较大的负面影响。当低质量样本占总样本的 50% 左右时,网络的分类准确率也降至 50% 附近,此时对于一个二分类问题来说,相当于网络能在样本中学到的东西是非常少的,近乎随机猜测。

由此可以得出,造成分类错误的原因主要有以下两点:一是白桦和落叶松两个树种在结构形态上具有较高的相似性;二是实验区内的树木比较密集,单木分割的效果会直接影响最后的分类结果。

表 3 树种分类结果的混淆矩阵

Tab. 3 Confusion matrix of tree species classification results

		预测值			准确率 UA/%
		白桦	落叶松	合计	
真实值	白桦	106	14	120	88.3
	落叶松	18	102	120	85.0
	合计	124	116	240	
准确率	PA/%	85.5	87.9		
	OA/%		86.7		
kappa 系数		0.73			

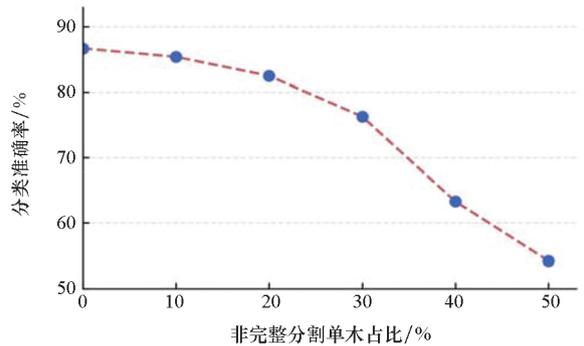


图 11 数据集质量对分类准确率的影响

Fig. 11 Influence of data set quality on classification accuracy

2.2 方法对比结果

本文方法与 1.5 节所述三种方法的分类结果如表 4 所示。其中方法 1 的分类精度最低,总体精度为 81.7%,kappa 系数为 0.63,该方法虽然统计了树木的 33 个不同的结构参数,但有限参数加浅层学习的分类方法仍限制了其分类精度。

方法 2 的总体准确度为 84.2%,kappa 系数为 0.68,优于方法 1,这是因为该方法通过波形数据更好地表示了不同树种独特的几何结构,且使用 DBM 模型生成了高级特征,减少了人工解译的错误。

方法 3 的总体精度为 85.6%,kappa 系数为 0.71,优于前两个方法。相较于方法 2 对每棵树生成唯一的波形表示,每 10° 重复投影对树木信息的保留更加全面,且大大增加了样本量,有利于深度学习模型的学习,因此得到了更高的分类精度。

实验表明,本文方法优于以上三种方法,其原因是:①与将三维数据转化成二维表达形式的方法相比,基于点的深层神经网络能够有效减少数据转化过程中的信息损失,很好地保留树木的三维结构信息;②本文提出的网络模型能够有效地提取 LiDAR 数据的高维特征,有利于提高树种分类精度。

表 4 四种方法的分类精度比较结果

Tab. 4 Comparison results of classification accuracy of the four methods

方法	OA/%	kappa 系数	UA/%		PA/%	
			白桦	落叶松	白桦	落叶松
方法 1	81.7	0.63	83.3	80.0	80.6	82.8
方法 2	84.2	0.68	85.0	83.3	83.6	84.7
方法 3	85.6	0.71	86.7	84.2	84.6	86.3
本文方法	86.7	0.73	88.3	85.0	85.5	87.9

2.3 特征维度对分类结果的影响

为了避免点云数据几何信息的损失,本文在对称操作之前,通过参数共享的 MLP 将每个点映射到一个高维空间。为了探究点的特征维度对分类结果的影响,对使用 128、256、512、1 024、2 048 维特征的分类准确度进行了比较(如图 12 所示)。结果表明,随着特征维度的增加,总体分类准确度提高,点云的几何信息得到了更好的保留。当特征维度达到约 1 000 时,分类性能达到最好。当特征维度超过 1 000 以后,分类性能无明显提升。

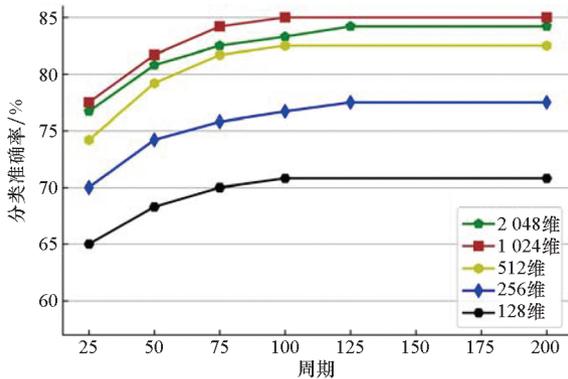


图 12 特征维度对分类准确率的影响
Fig. 12 Influence of feature dimensions on classification accuracy

2.4 点密度对分类结果的影响

本研究对分割得到的单木数据分别进行五次均匀下采样,如图 13 所示,采样点个数从 128 增加至 2 048 的过程中,分类准确度提升了 13.1%。当每棵树的采样点数量超过 2 000 时,网络的分类性能趋于饱和。点密度的增加促使分类效果大幅提升的原因主要是白桦和落叶松两个树种相似度较高,增加点密度能够保留更多的几何结构信息,使得深度神经网络能够更好地学习。而当点密度增加到一定数值时,网络能学到的信息趋于饱和,过大的点密度只会增加信息的冗余程度而

很难提升分类性能。

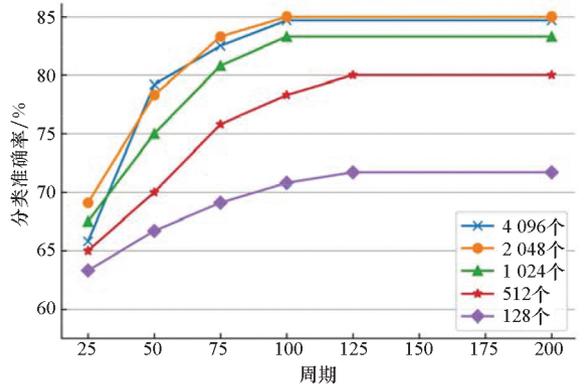


图 13 密度对分类准确率的影响

Fig. 13 Effect of dot density on classification accuracy

3 结论

本研究提出了一种新的基于三维深度学习的树种分类方法。该方法对预处理后的点云数据做单木分割,将得到的单木点云作为模型的输入,利用由特征映射模块、对称函数模块和分类器模块组成的深度神经网络自动提取树木的高维特征并实现树种分类。通过实验得到以下结论:

1) 本研究在树种分类任务上取得了较好的效果,在包含白桦树和落叶松两个树种的数据集上实现了 86.7% 的总体精度和 0.73 的 kappa 系数。

2) 实验结果表明,相比于特征参数法、波形图法和栅格化投影法,本文方法在特征提取上存在优势,有助于提高树种分类精度。

3) 随着点的特征维度和点密度的增加,分类准确率不断提高,但存在提高的临界值。在该数据集中,对每棵树取 2 048 个点,每个点取 1 024 维特征时,模型的分类效果最好。

参考文献 (References)

[1] JONES T G, COOPS N C, SHARMA T. Assessing the utility of airborne hyperspectral and LiDAR data for species

- distribution mapping in the coastal Pacific northwest, Canada[J]. *Remote Sensing of Environment*, 2010, 114: 2841–2852.
- [2] PLOURDE L C, OLLINGER S V, SMITH M L, et al. Estimating species abundance in a northern temperate forest using spectral mixture analysis [J]. *Photogrammetric Engineering & Remote Sensing*, 2007, 73(7): 829–840.
- [3] HEINZEL J, KOCH B. Investigating multiple data sources for tree species classification in temperate forest and use for single tree delineation [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2012, 18: 101–110.
- [4] CAO L, COOPS N C, INNES J L, et al. Tree species classification in subtropical forests using small-footprint full-waveform LiDAR data [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2016, 49: 39–51.
- [5] JAWAK S D, PANDITRAO S N, LUIS A J. Validation of high-density airborne LiDAR-based feature extraction using very high resolution optical remote sensing data [J]. *Advances in Remote Sensing*, 2013, 2: 297–311.
- [6] BRUGGISSER M, RONCAT A, SCHAEPMAN M E, et al. Retrieval of higher order statistical moments from full-waveform LiDAR data for tree species classification [J]. *Remote Sensing of Environment*, 2017, 196: 28–41.
- [7] MATURANA D, SCHERER S. VoxNet: a 3D convolutional neural network for real-time object recognition [C]// *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2015: 922–928.
- [8] WU Z R, SONG S R, KHOSLA A, et al. 3D ShapeNets; a deep representation for volumetric shapes [C]// *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 1912–1920.
- [9] WANG P S, LIU Y, GUO Y X, et al. O-CNN: octree-based convolutional neural networks for 3D shape analysis [J]. *ACM Transactions on Graphics*, 2017, 36(4): 72.
- [10] SU H, MAJI S, KALOGERAKIS E, et al. Multi-view convolutional neural networks for 3D shape recognition [C]// *Proceedings of IEEE International Conference on Computer Vision*, 2015: 945–953.
- [11] LI Y Y, PIRK S, SU H, et al. FPNN: field probing neural networks for 3D data [C]// *Proceedings of Conference on Neural Information Processing Systems*, 2016.
- [12] SHI B G, BAI S, ZHOU Z C, et al. DeepPano: deep panoramic representation for 3-D shape recognition [J]. *IEEE Signal Processing Letters*, 2015, 22(12): 2339–2343.
- [13] QI C R, SU H, MO K C, et al. PointNet: deep learning on point sets for 3D classification and segmentation [C]// *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 77–85.
- [14] QI C R, YI L, SU H, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space [DB/OL]. (2017–06–07) [2020–10–20]. <https://arxiv.org/abs/1706.02413>.
- [15] LI Y, BU R, SUN M, et al. PointCNN: convolution on χ -transformed points [DB/OL]. (2018–11–05) [2020–10–20]. <https://arxiv.org/abs/1801.07791v5>.
- [16] GUAN H Y, YU Y T, JI Z, et al. Deep learning-based tree classification using mobile LiDAR data [J]. *Remote Sensing Letters*, 2015, 6(11): 864–873.
- [17] ZOU X H, CHENG M, WANG C, et al. Tree classification in complex forest point clouds based on deep learning [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(12): 2360–2364.
- [18] HAMRAZ H, JACOBS N B, CONTRERAS M A, et al. Deep learning for conifer/deciduous classification of airborne LiDAR 3D point clouds representing individual trees [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 158: 219–230.
- [19] ZHAO X Q, GUO Q H, SU Y J, et al. Improved progressive TIN densification filtering algorithm for airborne LiDAR data in forested areas [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 117: 79–91.
- [20] CHEN Q, BALDOCCHI D, GONG P, et al. Isolating individual trees in a savanna woodland using small footprint lidar data [J]. *Photogrammetric Engineering & Remote Sensing*, 2006, 72(8): 923–932.
- [21] LI W K, GUO Q H, JAKUBOWSKI M K, et al. A new method for segmenting individual trees from the LiDAR point cloud [J]. *Photogrammetric Engineering & Remote Sensing*, 2012, 78(1): 75–84.
- [22] LIN Y, HYYPPÄ J. A comprehensive but efficient framework of proposing and validating feature parameters from airborne LiDAR data for tree species classification [J]. *International Journal of Applied Earth Observation and Geoinformation*, 2016, 46: 45–55.