

文章编号: 1004—5589 (2024) 04—0551—07

# CSA-PointNet: 一种面向针阔混交林的树种分类模型

霍燕平, 冷亮, 王民水, 纪雪, 王明常

吉林大学 地球探测科学与技术学院, 长春 130026

**摘要:** LiDAR 技术能够快速获取树木的三维结构信息, 结合深度学习算法可以实现单株级别的树种分类。为了解决将点云转换为二维图像或三维体素时损失树木的垂直结构、树冠形状和空间分布等信息的问题, 笔者在 PointNet 的基础上提出了 CSA-PointNet, 该模型可以直接将树木的单株点云作为输入, 通过引入通道注意力机制和空间注意力机制, 增强对单体植株的细节特征和空间分布特征的提取能力, 从而提高树种分类精度。应用制作的净月林场数据集分别对 CSA-PointNet 与主流模型 (VoxNet 和 PointNet) 进行训练和测试, 结果表明 CSA-PointNet 的整体分类精度为 74.69%, kappa 系数为 0.51, 均高于 VoxNet 和 PointNet。

**关键词:** LiDAR; 单木分割; 深度学习; 注意力机制; 树种分类

中图分类号: TP75 文献标识码: A doi: 10.3969/j.issn.1004-5589.2024.04.008

## CSA-PointNet: a tree species classification model for coniferous and broad-leaved mixed forests

HUO Yanping, LENG Liang, WANG Minshui, JI Xue, WANG Mingchang

College of Geo-exploration Science and Technology, Jilin University, Changchun 130026, China

**Abstract:** LiDAR technology is able to quickly acquire 3D structural information of trees, and when combined with deep learning algorithms, it can achieve tree species classification at the single plant level. In order to solve the problem of losing the vertical structure, canopy shape and spatial distribution information of trees when converting point clouds into 2D images or 3D voxels, the authors propose CSA-PointNet based on PointNet, which can directly take the point cloud of an individual tree as input. By introducing both the channel-attention mechanism and the spatial-attention mechanism, it enhances the extraction of detailed features and spatial distribution characteristics, thereby improving the accuracy of tree classification. The Jingyue forest dataset is used to train and test CSA-PointNet and mainstream models (VoxNet and PointNet), respectively. The results show that the overall classification accuracy of CSA-PointNet is 74.69%, and the kappa coefficient is 0.51, both of which are higher than those of VoxNet and PointNet.

**Keywords:** LiDAR; individual tree segmentation; deep learning; attention mechanism; tree species classification

收稿日期: 2024-01-05; 修订日期: 2024-08-30

基金项目: 国家自然科学基金面上项目 (42171407); 吉林省教育厅科学研究项目 (JJKH20241288KJ)

第一作者: 霍燕平 (1995—), 男, 主要从事遥感数据处理与应用研究。E-mail: huoy22@mails.jlu.edu.cn

通信作者: 王民水 (1989—), 男, 硕士, 工程师, 主要从事遥感图像变化检测研究。E-mail: 1543383519@qq.com

## 0 引言

树种分类是森林资源调查中的关键环节,可为森林资源的保护和经营管理提供重要依据<sup>[1-2]</sup>。传统的树种分类主要依靠人工地面调查,这种手段虽然准确率较高,但调查效率低,作业风险大且调查成本高<sup>[3]</sup>。应用传统光学遥感技术可大大提升其分类效率,但无法直接获取树木的三维结构信息,且“同谱异物”和“同物异谱”的现象也会对分类的准确性产生影响,导致树种分类的精度较低<sup>[4]</sup>。LiDAR (Light Detection And Ranging, LiDAR) 作为一种主动式遥感技术,可以快速获取树木的点云数据,日益发展为树种分类工作的主要技术手段<sup>[5]</sup>。

目前点云数据的处理方式可以概括为两类:①间接方式:将点云先转换为二维图像或三维体素,再利用图像处理的方法进行特征提取,主要模型有VoxNet、MVCNN等<sup>[6-7]</sup>;②直接方式:无需上述转换,直接将点云作为输入以实现学习和分类,代表模型有PointNet、PointNet++、PointCNN<sup>[8-10]</sup>等。近年来,越来越多的学者将上述两类方式应用于树种分类工作中。一方面,Hamraz等<sup>[11]</sup>采用间接方式将点云数据转换为数字表面模型(Digital Surface Model, DSM)和二维视图,并应用深度卷积神经网络(Convolutional Neural Networks, CNN)对针叶树和阔叶树进行了区分。陈向宇等<sup>[12]</sup>将点云数据转化为三维体素以提取树木特征参数,并应用机器学习算法对5类树种进行了分类。另一方面,刘茂华等<sup>[13]</sup>采用直接方式利用LayerNet模型,将无序点云直接作为输入,实现了对白桦和落叶松两类树种的分类。陈健昌等<sup>[14]</sup>以落叶松和白桦两类树种为研究对象,应用VoxNet和PointNet等9种模型进行分类,结果表明,采用直接处理方式的模型在分类精度上均高于采用间接处理方式的模型。综上所述,将点云数据转换成二维图像或三维体素会导致部分局部信息遗失,也提高了计算的复杂度。PointNet等模型可以直接从点云数据中提取特征并专注于全局信息的获取,但是忽略了对于树种分类至关重要的局部细节信息,导致树种分类精度难以提高。

针对上述问题,笔者基于PointNet提出了一种引入通道注意力机制和空间注意力机制(Channel

and Spatial Attention, CSA)的面向针阔混交林的树种分类模型—CSA-PointNet,其可以直接将树木的单株点云作为输入,在对整体特征提取的同时又能兼顾对局部关键特征的捕捉,进而提高树种分类的精度。

## 1 研究区概况与数据获取

### 1.1 研究区概况

研究区位于吉林省长春市净月潭实验林场(125°20'13"~125°34'08"E, 43°41'56"~43°51'99"N)内部(图1)。面积约为0.72 km<sup>2</sup>,林场位于温带大陆性季风气候区域,独特的气候条件使该林区形成了典型的针阔混交林,其优势树种主要包括落叶松、赤松、蒙古栎、榆树等树种。



图1 研究区位置图

Fig. 1 Location map of study area

### 1.2 数据获取

实验中的点云数据是2023年9月26日使用大疆M300无人机搭载的禅思L1激光雷达获取的,设备的参数设置详见表1。地面测量小组于2023年10月1日至3日期间,在林场内采集了蒙古栎、落叶松、赤松和榆树4种优势树种的位置信息,并记录其对应的树种类别。

表1 设备参数设置

Table 1 Device parameter settings

参数名称	参数指标
航带宽度	40 m
飞行高度	80 m
飞行速度	10 m/s
LiDAR 扫描线速度	100 m/s
LiDAR 扫描角	90°~270°

## 2 CSA-PointNet

笔者提出的 CSA-PointNet 以 PointNet 为基础, 通过引入通道注意力机制和空间注意力机制来加强

对局部特征提取。与 PointNet 相比, 该模型对特征进行了权值分配, 更加关注局部特征的重要性, 进而提高树种分类精度。其结构包括特征映射、注意力机制、对称函数和分类器 4 个模块 (图 2)。

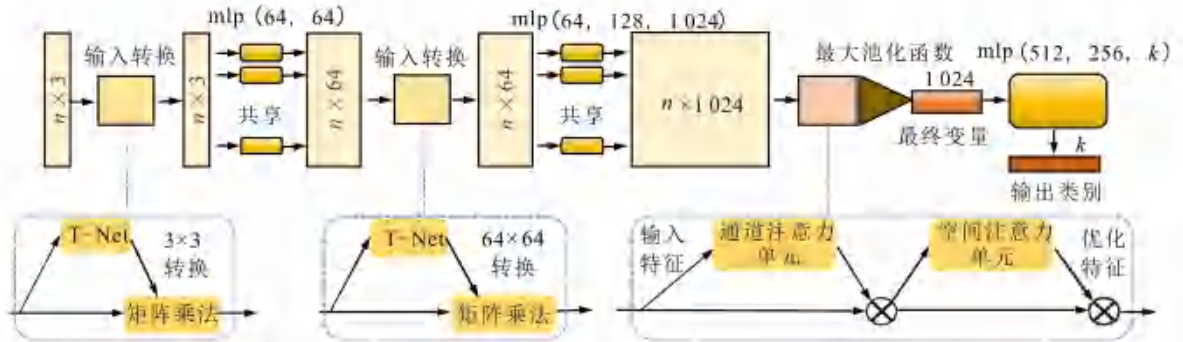


图 2 CSA-PointNet 结构  
Fig. 2 CSA-PointNet structure

(1) 特征映射模块。输入  $n$  个点, 利用其三维坐标进行特征提取。使用一个基于点云坐标的 T-Net 模块完成输入对齐, 通过一个输入通道为 64 的多层感知机 (MLP) 将三维点映射至高维空间, 使用一个 T-Net 模块完成特征对齐, 以确保不同输入点云的特征维度一致, 通过一个输入通道为 64 的 MLP 将特征映射至 1024 维。

查询向量  $q$  和键向量  $k$  之间的点积, 得到注意力分数以反映点云数据中每个点之间的相似度或关联程度。对注意力分数进行 Softmax 操作, 将其转换为概率分布, 得到每个点的注意力权重, 用于指示每个点在空间上的重要程度。最后, 输入特征乘以相应的注意力权重得到加权特征。

(2) 注意力机制模块。特征映射模块对每个点独立地进行特征提取, 此时提取到的是全局特征, 并不包含点与点之间的局部关系。Transformer 模型<sup>[15]</sup>中的自注意力机制 (Self-Attention) 能够动态地分配注意力权重, 关注不同位置的特征。笔者参考该自注意力机制的思想, 在空间注意力单元中设置  $q$ 、 $k$ 、 $v$  层并加入通道注意力机制, 来实现对整体和局部特征的提取。




图 3 通道注意力单元结构  
Fig. 3 Structure of channel attention unit

通道注意力单元用于计算通道注意力权重, 其结构如图 3 所示。首先, 输入特征进行平均池化 (average pooling) 和最大池化 (max pooling) 获得通道信息。通过多层感知机 (MLP) 提取关键信息, 并用 Sigmoid 激活函数进行非线性变换, 获得注意力权重。对每个通道上的特征乘以相应的注意力权重来调整通道特征的重要性。




图 4 空间注意力单元结构  
Fig. 4 Structure of spatial attention unit

空间注意力单元结构如图 4 所示, 该单元定义了 3 个全连接层分别用于计算查询 (query)、键 (key)、值 (value)。输入特征经过 3 个全连接层, 分别得到查询  $q$ 、键  $k$  和值  $v$ 。使用矩阵乘法计算

(3) 对称函数模块。将整体特征和局部特征进行对称操作。为了保证置换不变性, 利用一个简

单的对称函数（即最大池化层函数）以聚合每个点的信息。最大池化函数可以有效解决点云数据无序性的问题，不论点云数据如何排列，总能选取出其中最大的特征值，得到大小一致的特征向量。

(4) 分类器模块。笔者采用 Softmax 函数进行分类。Softmax 函数能够将特征向量从任意维度映射到与类别数量一致，并计算样本属于每个类别的概率值，最终通过级联的全连接层来输出 k 种类别。

### 3 实验过程

笔者将获取的点云数据进行预处理和单木分割，并结合实地调查数据制作数据集，应用数据集对 CSA-PointNet 进行训练和测试，并与 VoxNet 和 PointNet 的结果对比，通过精度评估得出结论。实验流程如图 5 所示。

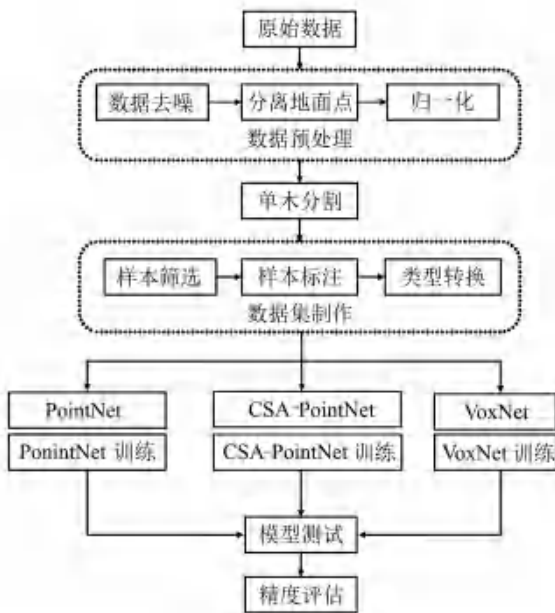


图 5 实验流程图

Fig. 5 Experimental flowchart

#### 3.1 点云数据预处理

在进行点云数据采集时，由于森林环境的复杂性，经常出现许多噪声点，并且地形因素会影响单个树木的分割。因此，需对原始点云数据进行预处理，以提高数据的质量，并确保后续分析的准确性。

笔者采用统计滤波法，将临近点个数设置为 10，标准差设置为 5，对点云数据中的噪声点进行去除；为了去除与研究无关的地面点，采用渐进式

致密化方法<sup>[16]</sup>通过逐步增加地面点密度，将地面点与非地面点分离开来；最后对点云数据做归一化处理。

#### 3.2 单木分割与数据集的制作

由于研究区内树木密度较高且 LiDAR 的穿透能力有限，导致获得的树干信息不完整。因此，需要应用自顶向下的算法对树冠进行分割，以便进一步确定树干的位置和形态。分离地面点后，生成数字表面模型 (Digital Surface Model, DSM) 和数字高程模型 (Digital Elevation Model, DEM)，DSM 减去 DEM 得到冠层高度模型 (Canopy Height Model, CHM)。应用冠层高度模型和改进的分水岭分割算法<sup>[17]</sup>，使每棵树的顶部形成一个封闭的树冠轮廓，以此实现对单个树木点云的分割。

由于每个单株点云中包含点的数量不一，过多的点会增加深度学习运算的负担，而数量过少则可能无法提供足够的特征信息。因此，对每棵树的点云进行均匀采样至 2 048 个点，以平衡计算负荷和保证特征信息的有效性。对经过分割的单株点云进行筛选，去除过度黏连和分割过度的植株。结合实地调查获得的位置信息和树种类别，选出质量较高的 2 460 棵单株，并进行人工标注，其中包含蒙古栎、榆树、赤松和落叶松 4 种优势树种，具体信息如表 2 所示。最后，以 8 : 2 的比例随机划分数据集，其中 80% 作为训练集，20% 作为测试集。

表 2 树种信息

Table 2 Information of tree species

树种种类	数量/棵
蒙古栎	735
榆树	487
落叶松	656
赤松	572

#### 3.3 模型训练

在训练过程中，超参数的不同取值会对模型的收敛性、泛化能力和训练效率等性能产生不同影响，因此需要进行合理设置。初始学习率设置为 0.1，每次输入的样本个数为 20，如果每 5 epochs 损失量不下降，则将学习率减半。通过观察模型分类的准确率变化，选择出适合该树种分类任务的超参数组合 (表 3)。

表 3 超参数设置

Table 3 Hyperparameter settings

参数	数值	说明
Batch-Size	20	每批输入样本的大小
Max-epochs	200	最大训练次数
Learning - Rate	0.001	学习率
Decay-Rate	0.5	学习率的衰减速率

### 3.4 实验结果与分析

对 3 种模型进行 200 epoch 的训练和测试, 其精度曲线如图 6 所示, 随着训练周期的增加, CSA-PointNet 模型的训练精度快速提升, 并在 0.76 左右稳定; PointNet 模型的训练精度不断增长, 最终稳定在 0.70 左右; 而 VoxNet 模型的训练精度最低, 最终稳定在 0.65 左右。总体趋势显示, 3 种模型的训练精度和测试精度不断提高, 且训练精度和测试精度的变化趋势基本一致, 最后均逐渐趋于稳定。CSA-PointNet 模型在训练和测试阶段均表现出更高的准确性, 这表明相对于 VoxNet 和 PointNet 其具有更好的性能。CSA-PointNet、VoxNet 和 PointNet 3 种模型的分类结果如图 7 中的混淆矩阵所示。

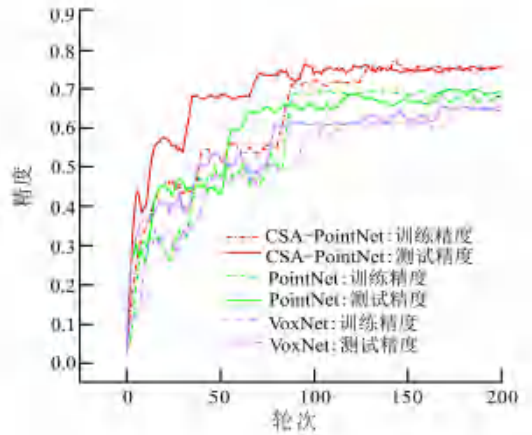


图 6 3 种模型训练结果精度曲线

Fig. 6 Accuracy curves of training results for three models

笔者采用总体准确率 (Overall Accuracy, OA)、kappa 系数、生产者精度 (Producer's Accuracy, PA) 和用户精度 (User Accuracy, UA) 来评估不同模型的分类结果 (表 4)。CSA-PointNet 模型的整体分类精度达到了 74.69%, kappa 系数为 0.51; PointNet 模型的整体分类精度为 68.31%, kappa 系数为 0.45; VoxNet 模型的整体分类精度为 67.00%, kappa 系数为 0.43。




图 7 3 种模型分类结果混淆矩阵

Fig. 7 Confusion matrices of classification results for three models

表 4 3 种模型分类精度比较

Table 4 Comparison of classification accuracy for three models

模型	OA/%	Kappa 系数	UA/%				PA/%			
			蒙古栎	赤松	落叶松	榆树	蒙古栎	赤松	落叶松	榆树
CSA - PointNet	74.69	0.51	79.41	79.46	66.67	73.04	81.20	72.95	75.23	68.85
PointNet	68.31	0.45	73.94	65.83	64.15	67.80	76.09	71.82	59.13	65.04
VoxNet	67.00	0.43	71.74	65.08	63.16	65.74	70.71	66.67	63.16	65.14

从精度评估的指标来看, CSA-PointNet 模型在整体精度和 kappa 系数上均高于其他两种模型。VoxNet 模型通过将点云转换为三维体素网格, 这一转换会使空间特征的细节部分丢失, 同时, 其侧重于体素内的局部特征分析, 未能充分捕捉到更广泛的空间上下文, 导致分类效果不佳。PointNet 模型通过直接从点云中提取特征, 专注于全局信息的获取, 却忽略了对树种识别至关重要的局部细节信息, 这限制了其在区分相似树种方面的表现。CSA-PointNet 模型在 PointNet 的基础上引入了通道注意力和空间注意力机制, 有效地保留了点云的空间信息, 并在局部与全局特征提取之间实现了平衡, 从而提高了树种分类精度。

对于赤松和落叶松, 较低的分类精度和较高的错分率反映了这两类树种形态上的高度相似性。虽然这 3 种模型在这两类树种的分类精度上都有待提高, 但 CSA-PointNet 模型的表现最佳。

## 4 结论

(1) 在 PointNet 的基础上提出 CSA-PointNet 直接将树木的单株点云作为输入, 引入通道注意力机制和空间注意力机制来对整体和局部特征进行提取, 提高了树种分类精度。

(2) CSA-PointNet 模型在分类任务中取得了较好的分类效果, 整体精度和 kappa 系数为 74.69% 和 0.51。与 PointNet 和 VoxNet 模型相比, 整体精度提高了 6.38% 和 7.69%, kappa 系数提高了 0.06 和 0.08。

(3) 点云数据虽然能提供精确的三维结构信息, 但对于树冠形状相似度较高的树种(如赤松与落叶松)仍难以区分。因此, 后续研究需结合其他类型的遥感数据, 如高空间分辨率影像或高光谱遥感数据, 以补充树种分类中所需的纹理和光谱信息, 以此来提高特定树种的分类精度。

## 参考文献:

[1] ORINA I, DIDIER B, MATTHIEU C. Detection, characterization, and modeling vegetation in urban areas from high-resolution aerial imagery [J]. IEEE Journal of Selected Topics in Applied Earth Observations and

Remote Sensing, 2008, 1 (3): 206-213.

- [2] 张晓羽, 李凤日, 甄贞, 等. 基于随机森林模型的陆地卫星-8 遥感影像森林植被分类 [J]. 东北林业大学学报, 2016, 44 (6): 53-57, 74.  
ZHANG X Y, LI F R, ZHEN Z, et al. Forest vegetation classification of landsat-8 remote sensing images based on random forest model [J]. Journal of Northeast Forestry University, 2016, 44 (6): 53-57, 74.
- [3] 蒲涛, 王妮, 汤连盟, 等. 自适应集成的高分辨率树种遥感分类 [J]. 遥感信息, 2023, 38 (6): 139-147.  
PU T, WANG N, TANG L M, et al. Adaptive ensemble high-resolution remote sensing classification of tree species [J]. Remote Sensing Information, 2023, 38 (6): 139-147.
- [4] 王克奇, 彭熙雯, 张怡卓, 等. 基于改进 U-Net 的高光谱农林植被分类方法 [J]. 森林工程, 2022, 38 (1): 58-66.  
WANG K Q, PENG X W, ZHANG Y Z, et al. Hyperspectral agroforestry vegetation classification method based on improved U-Net [J]. Forest Engineering, 2022, 38 (1): 58-66.
- [5] YU L G, XUE J L, HUA Q D, et al. Tree species classifications of urban forests using UAV-LiDAR intensity frequency data [J]. Remote Sensing, 2022, 15(1): 110.
- [6] WEN H Y, FAN Y. LiDAR image classification based on convolutional neural networks [J]. International Journal of Advanced Network (Monitoring and Controls), 2018, 2 (3): 158-162.
- [7] SU Y Y, HYUN S K, BOK W L, et al. Ensemble-based deep learning approach for performance improvement of BIM element classification [J]. KSCE Journal of Civil Engineering, 2023, 27 (5): 1898-1915.
- [8] JAEHEE L, SANGMI P, LEENSEOK K. Methodology for activity unit segmentation of design 3D models using PointNet deep learning technique [J]. KSCE Journal of Civil Engineering, 2023, 28 (1): 29-44.
- [9] ZEYNEP A, FEVZI K, MUSTAFA D. A new approach for ground filtering of airborne laser scanning data using PointNet++ [J]. Journal of the Indian Society of Remote Sensing, 2023, 52 (1): 1-15.