

# 深度学习在LiDAR点云分类与特征提取中的应用探索

周 扬

中国能源建设集团黑龙江省电力设计院有限公司 黑龙江 哈尔滨 150078

**摘要：**本文深入探讨了深度学习在LiDAR点云分类与特征提取中的应用。通过分析基于体素、点云、图形和视觉的深度学习模型，揭示了各方法的优缺点。基于体素的方法利用CNN进行特征提取，但存在量化误差；基于点云的方法直接处理原始数据，计算效率高；基于图形的方法利用GCN处理图结构数据，但计算复杂度高；基于视觉的方法将点云投影为二维图像，但信息损失较大。本文还展望了未来的研究方向，包括高效数据表示、局部特征提取改进、多模态融合和自监督学习，旨在推动LiDAR点云处理技术的进一步发展。

**关键词：**深度学习；LiDAR；点云分类；特征提取

## 引言

LiDAR作为一种主动遥感技术，通过发射激光并接收反射信号来获取目标物体的三维空间信息，生成密集的点云数据。在自动驾驶、地形测绘、城市规划等领域，LiDAR点云数据的分类与特征提取对于环境感知、障碍物检测、地形重建等任务至关重要。深度学习作为一种强大的机器学习方法，在处理复杂、高维的数据方面具有显著优势，因此被广泛应用于LiDAR点云分类与特征提取中。

### 1 LiDAR 点云数据概述

LiDAR (Light Detection and Ranging) 点云数据是通过激光雷达系统扫描周围环境而获取的一种三维数据形式。它由一系列在三维空间中的离散点组成，每个点都包含其精确的位置坐标  $(x, y, z)$ ，这些信息对于重建物体的三维形状和场景的空间结构至关重要。此外，每个点还可能包含反射强度、颜色等其他属性，这些属性提供了关于物体材质和表面特性的额外信息。然而，LiDAR点云数据具有无序性、稀疏性和海量性等特点，这给数据的处理和分析带来了挑战。无序性意味着点云中的点没有固定的顺序或结构，稀疏性则体现在点云数据在空间中分布不均匀，而海量性则是指点云数据通常包含大量的点，需要高效的算法和强大的计算能力进行处理。

## 2 深度学习在 LiDAR 点云分类中的应用

### 2.1 基于体素的模型

基于体素的模型是深度学习在LiDAR点云分类中的一种重要方法。该方法的核心思想是将点云数据转换为三维网格，其中每个网格单元被称为一个体素。通过这种方式，点云数据的无序性和稀疏性问题得到了有效缓解，使得后续处理变得更加便捷。在体素化过程中，点

云数据被划分为一系列规则的体素网格。每个体素内可能包含多个点，这些点被编码为体素的特征。编码方式多种多样，可以是简单的统计特征（如点的数量、平均位置等），也可以是更复杂的几何和语义特征。编码后的体素网格可以被视为一种特殊的三维图像，从而可以利用成熟的卷积神经网络（CNN）进行特征提取和分类。基于体素的模型在点云分类中取得了显著的成果。由于体素网格具有规则的结构，CNN可以高效地提取体素内的特征，并实现全局的分类。然而，这种方法也存在一些缺点<sup>[1]</sup>。首先，体素化过程中会引入量化误差，因为点云数据中的点被近似地分配到体素网格中。这种误差可能会影响分类的准确性。其次，基于体素的模型通常需要处理大量的体素网格，计算量较大，对硬件资源的要求也较高。尽管如此，基于体素的模型仍然是深度学习在LiDAR点云分类中的一种有效方法。通过不断优化体素化策略和特征编码方式，可以进一步提高分类的准确性和效率。

### 2.2 基于点云的模型

基于点云的模型是另一种重要的深度学习在LiDAR点云分类中的应用方法。与基于体素的模型不同，这类方法直接对原始点云数据进行处理，无需进行体素化转换。PointNet及其改进版本PointNet++是基于点云的模型的代表。PointNet首次提出了直接处理点云数据的深度学习网络架构。它利用多层感知机（MLP）对每个点进行特征提取，并通过最大池化操作将点的特征聚合为全局特征，从而实现点云分类。PointNet++在PointNet的基础上进行了改进，引入了局部特征提取模块，通过构建点的邻域关系并对其进行特征提取，增强了模型对局部结构的感知能力。基于点云的模型具有显著的优势。首先，它们能够直接处理无序和稀疏的点云数据，无需进行预处理或转换，从而

保留了数据的原始信息。其次，由于直接对点进行操作，计算效率相对较高，适用于大规模点云数据的处理。然而，这类方法也存在一些挑战。尽管PointNet++等模型引入了局部特征提取模块，但对于复杂场景和精细结构的局部特征提取能力仍有待提升。此外，由于点云数据的特殊性，如何设计有效的网络架构和损失函数也是基于点云的模型需要解决的问题。

### 2.3 基于图形的模型

基于图形的模型是深度学习在LiDAR点云分类中的又一重要分支。这类方法将点云数据转换为图结构，其中每个点被视为图的一个节点，点之间的空间关系则被视为图的边。通过这种方式，点云数据的空间关系得到了显式表示，有利于后续的特征提取和分类。图卷积网络（GCN）是基于图形的模型中的核心组件。GCN通过设计特定的卷积操作，在图结构上进行特征提取和信息传播。对于每个节点，GCN会聚合其邻居节点的特征，并通过非线性变换更新该节点的特征表示。通过多层GCN的堆叠，模型可以逐步提取出点云数据中的高层次特征，并用于分类任务。基于图形的模型在点云分类中具有显著优势。首先，图结构能够显式表示点云数据的空间关系，有助于模型捕捉点之间的相互作用和依赖关系。其次，GCN作为一种强大的特征提取工具，能够高效地处理图结构数据，并提取出有用的特征用于分类。然而，这类方法也存在一些挑战。特别是当处理大规模点云数据时，图结构的复杂性和计算量会显著增加，对硬件资源的要求也较高。尽管如此，基于图形的模型在LiDAR点云分类中仍具有广阔的应用前景。通过优化图结构和GCN的设计，可以提高模型的计算效率和分类性能。此外，结合其他深度学习技术和算法，还可以进一步提升基于图形的模型在点云分类中的表现。

### 2.4 基于视觉的模型

基于视觉的模型是深度学习在LiDAR点云分类中的一种独特方法。这类方法将三维点云数据投影到二维平面上，生成多视图图像，从而可以利用传统的图像处理技术或卷积神经网络（CNN）进行分类。在投影过程中，点云数据通常被转换为多个二维图像，每个图像对应于一个特定的视角。这些图像可以保留点云数据中的部分空间信息和几何特征，同时降低了数据的维度和复杂性。随后，可以利用成熟的图像处理技术或CNN对这些图像进行特征提取和分类。由于CNN在图像处理领域取得了显著的成果，因此基于视觉的模型在点云分类中也具有一定的优势<sup>[2]</sup>。然而，这种方法也存在一些明显的缺点。首先，将三维点云数据投影到二维平面上会导致

信息损失，特别是深度信息和空间关系方面的损失。这可能会影响分类的准确性和鲁棒性。其次，基于视觉的模型难以处理复杂的三维形状和结构，因为二维图像无法完全表示三维空间的复杂性。尽管如此，基于视觉的模型在LiDAR点云分类中仍具有一定的应用价值。特别是在处理简单场景或对象时，这种方法可以取得较好的效果。此外，结合其他深度学习技术和算法，还可以进一步提升基于视觉的模型在点云分类中的表现。未来，随着深度学习技术的不断发展和点云数据处理需求的不断增长，基于视觉的模型有望在更多领域发挥重要作用，特别是在与图像处理相关的任务中。

## 3 深度学习在LiDAR点云特征提取中的应用

### 3.1 局部特征提取

局部特征提取是LiDAR点云处理中的关键环节，对于理解点云的几何结构和语义信息具有重要意义。基于深度学习的方法在局部特征提取方面展现出了强大的能力。卷积神经网络（CNN）是局部特征提取中常用的深度学习模型。在点云处理中，CNN可以通过对点云数据进行体素化或投影到二维平面上，然后利用卷积操作提取局部特征。体素化后的点云数据可以被视为一种特殊的三维图像，CNN可以在其上进行卷积操作，从而提取出体素内的局部特征。而对于投影到二维平面上的点云数据，CNN则可以直接在其生成的图像上进行卷积操作，提取出图像中的局部特征。除了CNN，图卷积网络（GCN）也在局部特征提取中得到了广泛应用。GCN通过构建点云数据的图结构，将每个点视为图的一个节点，并利用图卷积操作在节点之间进行信息传播和特征聚合。通过这种方式，GCN能够高效地提取出点云数据中的局部特征，并保留点之间的空间关系<sup>[3]</sup>。在局部特征提取过程中，多层感知机（MLP）也扮演着重要角色。MLP通常用于对每个点或点簇进行特征编码，将其转换为高维特征向量。这些特征向量包含了点或点簇的几何和语义信息，有助于后续的分类和识别任务。

### 3.2 全局特征提取

全局特征提取是LiDAR点云处理中的另一个重要环节，它的目标是提取整个点云的全局特征，用于点云分类、场景理解等高层任务。基于深度学习的方法在这一领域也展现出了强大的能力。在全局特征提取过程中，最大池化操作或全局平均池化操作是常用的手段。这些操作能够将局部特征聚合为全局特征，实现对点云的整体描述。具体来说，最大池化操作会选择局部特征中的最大值作为全局特征的一部分，而全局平均池化操作则会计算局部特征的平均值作为全局特征。除了池化操

作，一些深度学习模型还设计了特定的全局特征提取模块。例如，一些模型会利用全连接层（FC）对局部特征进行进一步的处理和整合，从而提取出更具代表性的全局特征。这些全局特征通常具有较高的抽象层次，能够捕捉点云中的整体结构和语义信息。在全局特征提取过程中，深度学习模型还会结合其他技术来提高特征提取的效果。例如，一些模型会利用注意力机制（Attention Mechanism）来关注点云中的关键区域和点，从而提取出更具判别性的全局特征。此外，多尺度特征融合（Multi-Scale Feature Fusion）也是常用的技术之一，它通过将不同尺度的局部特征进行融合，来丰富全局特征的代表性。

#### 4 未来研究方向

##### 4.1 高效的数据表示和编码

随着LiDAR技术的不断进步，点云数据的规模和复杂性也在不断增加。因此，研究更高效的数据表示和编码方法显得尤为重要。未来的研究可以探索如何利用稀疏表示、压缩感知等技术来减少点云数据的存储和计算需求，从而降低内存消耗和提高处理速度。此外，还可以研究如何设计更紧凑且富有表达力的特征描述符，以便在保持高精度的同时减少计算量。

##### 4.2 局部特征提取的改进

局部特征是点云分类和识别的重要依据。然而，当前的局部特征提取方法仍存在一些局限性，如对不同尺度、旋转和噪声的敏感性。因此，未来的研究可以致力于开发更鲁棒且准确的局部特征提取方法。例如，可以引入更先进的卷积神经网络或图卷积网络架构，以捕捉更丰富的局部几何和语义信息。同时，还可以研究如何利用点云的局部上下文信息来增强特征的判别性。

##### 4.3 多模态融合

LiDAR点云数据虽然具有丰富的几何信息，但缺乏颜色和纹理等细节。因此，结合其他传感器数据（如图像、GPS等）进行多模态融合是一个有前景的研究方向。

通过融合多种传感器的数据，可以充分利用各自的优势，提高点云处理的鲁棒性和准确性<sup>[4]</sup>。未来的研究可以探索如何设计有效的融合策略，以实现不同模态数据之间的互补和协同。

##### 4.4 自监督学习

标注点云数据是一项耗时且费力的任务，因此获取大量的标注数据对于深度学习模型的训练来说是一个挑战。为了解决这个问题，未来的研究可以探索自监督学习方法在点云分类与特征提取中的应用。通过利用未标注数据中的自然监督信号，可以训练出更具泛化能力的模型，从而在缺少标注数据的情况下提高点云处理的性能。

#### 结语

本文通过对深度学习在LiDAR点云分类与特征提取中的应用进行综述，展示了该领域取得的显著进展。深度学习模型在处理复杂、高维的点云数据时展现出了强大的能力，但仍面临一些挑战。未来的研究应聚焦于开发更高效的数据表示和编码方法，改进局部特征提取技术，探索多模态融合和自监督学习等新型方法。通过不断的研究和创新，相信深度学习将在LiDAR点云处理领域发挥更大的作用，为自动驾驶、智慧城市等领域的发展提供有力支持。

#### 参考文献

- [1]周振华.基于深度学习的LiDAR点云目标检测算法研究[D].西安理工大学,2024.
- [2]梁家安,陈科,季铮,等.三维点云深度学习分类模型学习策略分析——以机载多光谱LiDAR点云为例[J].测绘工程,2023,32(06):68-75.
- [3]王郑阳,俞昊,孟昊,等.POWERLINE-ALS:一种用于输电线路场景深度学习语义分割的机载LiDAR点云数据集[J].山东科技大学学报(自然科学版),2023,42(02):33-43.
- [4]胡振林.基于LiDAR点云的信号交叉口追尾冲突识别与深度学习预测[D].哈尔滨工业大学,2022.