

基于深度学习的三维网格简化算法及GIS应用研究综述

刘 茜, 刘 刚, 陈根深, 范文遥, 张俊杰

(中国地质大学(武汉) 计算机学院, 湖北 武汉 430078)

摘要: 随着数字化时代的来临, 三维模型的广泛应用使得人们对高效三维网格简化技术展开了持续不断的追求。深度学习作为一种强大的模式学习工具, 近年来在三维网格简化领域崭露头角, 为三维网格简化带来了新的机遇与挑战。首先, 对现有基于深度学习的三维网格简化算法进行了全面综述, 系统梳理了当前采用深度学习技术进行三维网格简化的主要方法和框架, 其中涵盖了网格卷积神经网络、图卷积神经网络等深度学习结构。其次, 详细介绍了深度学习三维网格简化技术在地理信息系统、图形渲染和计算机辅助设计等领域的应用, 凸显了深度学习在提高渲染效率、降低网络传输开销, 以及空间分析与查询等方面的潜在价值。最后, 总结全文并对未来简化算法发展方向进行了展望。

关键词: 深度学习; 网格简化; 三维模型; 计算机视觉; 地学信息处理

DOI: 10.11907/rjdk.241274

开放科学(资源服务)标识码(OSID):

中图分类号: TP183

文献标识码: A

文章编号: 1672-7800(2025)007-0001-12



Research Overview on 3D Mesh Simplification Algorithms and GIS Application Based on Deep Learning

LIU Xi, LIU Gang, CHEN Genshen, FAN Wenyao, ZHANG Junjie

(School of Computer Science, China University of Geosciences, Wuhan 430078, China)

Abstract: With the advent of the digital age, the widespread application of 3D models has led to a continuous pursuit of efficient 3D mesh simplification technology. Deep learning, as a powerful pattern learning tool, has emerged in the field of 3D mesh simplification in recent years, bringing new opportunities and challenges to 3D mesh simplification. Firstly, a comprehensive review was conducted on existing 3D mesh simplification algorithms. The system has summarized the main methods and frameworks for 3D mesh simplification using deep learning techniques in current literature, including deep learning structures such as mesh convolutional neural networks and graph convolutional neural networks. Subsequently, the application of deep learning 3D mesh simplification technology in fields such as geographic information systems, graphic rendering, and computer-aided design was introduced in detail. Highlighting the potential value of deep learning in improving rendering efficiency, reducing network transmission overhead, and spatial analysis and querying. Finally, the full text is summarized and the future development direction of simplification algorithms is discussed.

Key Words: deep learning; mesh simplification; 3D model; computer vision; geoscience information processing

收稿日期: 2024-05-14

扫描二维码阅读全文:



基金项目: 国家自然科学基金项目(42372345, U1711267)

作者简介: 刘茜(2000-), 女, 中国地质大学(武汉)计算机学院硕士研究生, 研究方向为计算机图形学、智能地学信息处理等; 刘刚(1967-), 男, 博士, 中国地质大学(武汉)计算机学院教授、博士生导师, 研究方向为地学大数据、三维可视化与可视分析、地学信息工程; 陈根深(1993-), 男, 中国地质大学(武汉)计算机学院博士研究生, 研究方向为地学大数据、智能地学信息处理等; 范文遥(1996-), 男, 中国地质大学(武汉)计算机学院博士研究生, 研究方向为随机建模、深度学习与地质统计学等; 张俊杰(1998-), 男, 中国地质大学(武汉)计算机学院硕士研究生, 研究方向为计算机图形学、智能地学信息处理等。本文通讯作者: 刘刚。

0 引言

高分辨率可视化和三维建模在计算机视觉领域具有重要作用。它们有助于在视频监控和安防领域进行准确的人脸识别和物体检测,为增强现实和虚拟现实提供沉浸式体验;支持医学图像分析和诊断,为智能交通和自动驾驶提供关键功能;同时有助于在游戏和娱乐产业中创造出真实感和沉浸式体验。这些技术应用推动着科技的进步,对安全、教育、医疗和娱乐等领域产生了积极影响。

然而,随着海量数据的增长,高分辨率可视化和三维建模面临计算性能、存储需求、网络带宽限制、设备和硬件要求以及交互体验等困难。对于复杂场景和详细模型,数据集的大小可以快速增长,将大规模数据从存储设备加载到计算机内存中成为一项挑战。因此,如何高效地存储和处理大规模数据成为一个重要课题。它需要更多的计算资源、存储空间和网络带宽,对处理器、存储设备和显示设备提出了更高要求。

为解决该问题,同时保持拓扑结构不变,实现多尺度可视化,并且增强模型泛化能力,可以采取数据压缩、数据分布与异地计算以及硬件升级、网格简化等方法。其中,数据压缩技术能够减少存储空间占用,通过优化数据结构,可以降低计算资源使用率,从而提高性能和效率。分布式计算将任务分解为多个子任务,并在多台计算机上并行处理以加快计算速度。而使用云计算平台可以将大部分计算任务转移到云端,充分利用云服务提供商的高性能硬件资源,并根据需要进行弹性扩展。云计算还可以提供更大的存储空间和网络带宽,以满足三维建模需求。升级处理器和存储设备也可以提供更好的性能和处理速度。高性能计算机或服务器通常具有更高的计算能力和存储容量,从而能够更快地处理复杂的三维建模任务。

尽管以上方法可以帮助解决三维建模所需的计算资源、存储空间和网络带宽等问题,但相较于网格简化算法,它们仍旧存在一些缺陷。数据压缩可以减少存储空间占用,但有时会牺牲数据的精确性和质量。特别是在需要高保真度的三维建模任务中,过度压缩可能导致失真。分布式计算将任务分发到多台计算机上进行并行处理增加了通信开销。管理和同步分布式计算系统也需要一定的复杂性和额外开销。相比于以上方法,网格简化算法通过减少模型的顶点数量和面片数量以降低模型复杂度,从而节省存储空间,加快渲染速度,并减少渲染所需计算资源。同时,网格简化可减少模型文件大小,因此可以更快地传输和加载模型,对于通过网络传输模型或者在资源受限的环境中加载模型非常有帮助。网格简化算法会尽量保持模型的基本形状和外观,权衡保留足够的细节以满足特定需求,并确保最终结果满足预期质量标准,因而受到了国内外学者们的广泛关注。

传统网格简化算法在处理三维模型时受限于手工设计的规则和特征,难以捕捉复杂模型的高级结构和语义信息,同时在处理大规模和高复杂度模型时效率较低,对模型细节的保留也存在挑战。相比之下,基于深度学习的算法通过自动学习特征表示,具备更强的泛化能力和更好的复杂度处理能力,能够在简化模型的同时有效保留重要细节,展现了更强的适应性和通用性。

基于深度学习的网格简化算法在灵活性、准确性、适应性和处理大规模数据等方面展示出了显著的优越性。然而,以往研究主要集中在传统方法上,对于基于深度学习的网格简化算法尚未进行全面概括。本文旨在通过综合分析近期发表的研究论文和方法,为深度学习在网格简化方面的研究提供新的视角和解决方案。

本文阐述了简化算法的相关概念,如流形网格、卷积网络、八叉树表示法等,并综述了现有基于深度学习的简化算法。基于深度学习的简化方法具有广泛的适用性,能够处理多种三维数据格式,包括多边形网格、点云数据^[1]、体素数据^[2]和混合数据格式等。非网格模型可以通过数据格式转换得到网格模型或直接表示为网格模型以作进一步处理。因此,在讨论基于网格模型进行简化算法的同时,也介绍了针对其他数据格式的简化算法。首先,对这些算法的性能和简化效果进行了简要分析,以展现不同目的场景下各类简化技术的优点和局限性;其次,介绍了网格简化算法在不同领域的具体应用,突显了基于深度学习的网格简化算法在各领域提高效率、优化性能的潜力;最后,总结了现有基于深度学习的简化算法的局限性,并提出了未来可能的研究方向。

1 相关工作

1.1 文献检索与筛选

本文在主要数据库上使用结构化关键字进行相关文献检索,组合使用了 Deep Learning Mesh Simplification Algorithms、Model Simplification Techniques、3D Mesh Model Optimization、Grid Compression、Deep Learning、Deep Neural Networks、Artificial Intelligence 等关键词。通过以上关键词,本文在 Web of Science、Scopus、Google Scholar、中国知网、百度学术等平台进行检索,通过不同平台检索的文献相互补充。本文检索了1996年至今279篇相关文献,其出版年份分布情况如图1所示。1996—2008年,发文量整体呈快速上升趋势,相关领域的研究人员越来越多,研究成果也不断涌现。而2009—2014年发文量总体呈下降趋势。但2014—2016年,新的研究热点与技术出现,再次激发了研究人员的兴趣。

为确保内容具有时效性,本文从初步筛选的文献中优先选取涉及最新技术的文献,并在此基础上选择对该研究主题具有重要贡献、创新性高、影响力大的文献进行深入




Fig. 1 Article year distribution

图1 文章年份分布

阅读, 充分理解其研究方法和技术特点, 进而根据研究内容将文献分类整理成不同主题加以介绍。

1.2 主要贡献

本文主要贡献如下: ①对基于深度学习的网格简化算法进行分类介绍; ②介绍了网格简化算法在地理信息系统中的应用; ③总结了现有算法的局限性并提出未来研究方向。

2 相关概念

2.1 流形网格

流形网格是指具有连续、可微和可逆的局部性质的网格模型, 它可以通过局部调整和扭曲表面以保持其整体连通性和可逆性, 主要包括简单的三角形网格以及复杂的曲面和多面体网格。流形网格易于处理, 对应复杂的几何特性, 例如曲率、变形等, 可以方便地进行提取和描述, 如图2所示。非流形网格是指存在断裂、奇点、无界面或多包含曲面的网格模型, 它没有连续的拓扑结构和单一的几何表示。此类网格模型通常不能有效地应用于计算机图形学和计算机辅助设计相关任务, 但通常适用于流体力学、非线性仿生学等某些特定领域。非流形网格主要包括T形拼接^[3](T-joining)、欧拉融合^[4](Euler Merging)等。流形网格相较于非流形网格更常用和更容易处理, 因此在进行模型处理和分析时, 通常需要将非流形网格进行划分后相互连接, 从而生成流形网格。针对一些具体的应用场景, 会有特定的算法和技术以处理非流形网格, 如表面剖分^[5]、曲面重构^[6]、线性细分^[7]等。

2.2 卷积网络

在欧几里德空间中, 卷积神经网络(Convolutional Neural Network, CNN)具有卷积层、激活层、池化层和全连接层等结构用于有效地学习和提取模型特征^[8]。卷积操作利用卷积核 K 与输入信号 f 滑动窗口相乘并求和, 形成输出特征图 G 。卷积核 K 与信号 f 之间的传统图卷积定义为:

$$(K * f)_p = K_s f_p + \sum_{q \in N_p} K_n f_q \quad (1)$$

其中, N_p 为顶点 p 在 G 中的邻域集合, K_s 与 K_n 分别表




Fig. 2 Manifold and non-manifold mesh

图2 流形网格与非流形网格

示自相互作用和邻域贡献的两个线性映射矩阵, f_p 为输入特征向量。

激活层通过引入非线性变换解决了梯度消失问题, 使网络能够学习和捕捉更为复杂的数据特征。池化层对卷积层输出的特征图进行下采样, 在降低空间维度的同时保留关键特征。这有助于网络将注意力集中于重要特征, 提高模型鲁棒性和泛化能力。通过结合卷积层和池化层, 卷积网络可以提取模型不同尺度下的特征, 并利用全连接层将特征映射到输出空间。

2.3 八叉树表示

八叉树是一种用于在三维空间中表示立方体区域的数据结构, 树的根节点代表整个空间, 而每个内部节点都可以被递归地细分为8个子节点, 每个子节点表示父节点区域的1/8。叶子节点通常关联着具体的对象或场景信息, 而内部节点用于加速空间查询和渲染。

在八叉树中, 空间集合由按层次定位结构排列的节点表示, 如图3所示。其中, 与空间集合相交的立方体区域用混合节点表示, 空间内部的区域用黑色节点表示, 外部区域用白色节点表示。混合节点对应的立方体区域 C 被细分为8个大小相同的立方体子区域 C_i , 并用混合节点的8个子节点表示, 此细分过程递归地进行直到达到八叉树的最佳分辨率 γ 。在最佳分辨率下, 所有混合节点都被转换成黑色节点, 表示达到了八叉树的最终细分状态。

八叉树具有高效分割三维空间、提供层次结构和快速查询的优势。这种结构允许以逐层方式处理模型, 利用局部性原理对相似区域进行操作, 并动态调整空间分辨率,




Fig. 3 Octree structure

图3 八叉树结构

从而实现对三维模型更灵活、高效的简化处理。

3 相关算法

3.1 深度神经网络

随着三维网格简化技术的迅速发展,深度学习在网格简化领域的应用日益显著。与传统方法相比,深度学习技术不仅无需手动调节模型参数,而且能够很好地保持网格模型的拓扑结构与模型特征,尤其在处理复杂网格数据时表现突出。深度神经网络能够有效地捕获模型的局部与全局特征,已成为网格简化的主流方法之一。目前,常见且效果显著的深度学习模型包括自适应神经气体模型、图神经网络、网格卷积神经网络、顶点一面卷积神经网络和自编码器等。

3.1.1 自适应神经气体模型

Fritzke等^[9]提出的自适应神经气体模型(Growing Neural Gas, GNG)是一种用于无监督学习和聚类的神经网络模型。GNG能够根据输入数据的分布动态地增长和调整神经元(节点)的拓扑结构,以更好地适应不同形状和密度的数据集。GNG模型在数据降维和聚类任务上表现出色,但也存在着一些不足。首先,GNG仅提供顶点和连接边的信息。因此,将GNG模型应用于三维网格简化问题时还额外需要面信息以进行模型重建^[10]。其次,GNG模型存在非活动节点,这些节点往往导致算法收敛到局部最小值。GNG网络能自适应地学习和增长,而无需手动设置网络结构。对于简化具有复杂拓扑结构的网格效果较好,由于其网络的增长和学习受到输入数据规模的限制,GNG网络对于大规模网格简化任务的性能有限。Rodrigues等^[11]提出一种基于GNG的自适应网格简化算法,其在GNG网络的基础上,通过适应性地调整神经元和连接的数量,实现了网格的自适应简化。该算法能够根据网格数据的特性自动调整简化程度,提高了简化效率和准确性。但由于受到GNG算法自身的局限性影响,该算法对于复杂数据的处理能力有限。Hurtado等^[12]对GNG算法进行了优化,提高了算法性能和稳定性,使其更适用于实际应用场景。然而,该算法具有较高的计算复杂度,对于初始参数的选择比较敏感,不恰当的初始参数选择可能导致算法收敛速度慢或者陷入局部最优解。在此基础上,Álvarez等^[13]开发了GNG3D网格简化算法,该方法能够生成多边形模型的高质量近似值。该方法由两个不同的阶段组成:

(1)优化阶段。GNG3D通过引用局部计数器变量移除了未被引用的点以及相应边,避免了局部最小值问题。此阶段的主要目标是获得一组表示原始模型最佳近似值的简化顶点。输入信号与输入空间 R^n 之间局部误差定义为:

$$\Delta \text{error}(s_i) = \|w_{s_i} - \gamma\|^2 \quad (2)$$

其中, s_i 为 R^n 中的最近节点, w_{s_i} 为 s_i 在 R^n 中的位置, γ 为生成的输入信号。

(2)重建阶段。在重建阶段,GNG3D利用优化阶段提供的优化节点集 $A = \{n_1, n_2, \dots, n_M\}$ 以及原始模型顶点集合 $K = \{k_1, k_2, \dots, k_N\}$ 对模型进行重构,从而得到优化后的网格。

GNG3D延续了GNG的优点,包括动态拓扑结构和无监督学习能力,这使得GNG3D能够根据输入数据的分布动态地增长和调整神经元的拓扑结构,以适应不同形状和密度的数据集。与此同时,GNG3D能够在复杂环境中工作,并快速生成能够准确表示原始三维模型的简化多边形模型。

然而,GNG3D的性能高度依赖于其参数设置,包括神经元增长规则、连接权重更新方式等,选择合适的参数对于获得高质量的简化模型至关重要。与此同时,GNG3D在处理具有复杂几何形状的三维模型时仍然可能会遇到性能和计算资源方面的挑战。

3.1.2 图神经网络

传统的神经网络主要处理向量化的数据,而图神经网络(Graph Neural Network, GNN)扩展了这一范围,能够有效地处理非常复杂的关系和连接^[14-15]。三维模型通常由大量的三角形构成,导致模型复杂性高、存储和计算成本大。通过将三维模型表示为图,GNN可以实现对模型的自动简化。一些研究者使用GNN对3D网格进行分割和重建,以实现网格简化和形状重构^[16]。通过设计特定的网络架构如MeshCNN^[17]和TopoNet^[18],用于处理和操作3D网格数据以实现网格简化。部分研究则关注于结合图神经网络和拓扑感知技术,以实现3D网格的拓扑结构分析,从而更好地理解 and 处理网格数据。这些研究为使用图神经网络解决网格简化和相关任务提供了新的方法和技术,推动了该领域的进展。

其中,Potamias等^[19]开发了一种通过对显著点进行采样的快速点云简化方法。该架构综合了多层感知机^[20](Multilayer Perceptron, MLP)、批量归一化^[21]、ReLU激活函数^[22]和GNN层。其中,GNN层的更新规则如下:

$$f'_i = W_c f_i + \frac{1}{N_i} \sum_{j \in N_i} W_n f_j \quad (3)$$

其中, f_i 为输入点 P_i 后共享逐点MLP的输出, W_c 、 W_n 为投影矩阵^[23], N_i 为点 P_i 的邻域。

通过这些组件相互作用,实现了对模型特征的有效学习与快速简化。由于该方法会产生遵循输入噪声模式的

噪声输出, 因此简化结果不会受到异常噪声的干扰。同时, 为了加速大规模网格数据的实时处理过程, Potamias等^[24]提出第一个可微网格简化模型。该模型由点采样器、边缘预测器和面分类器3个模块组成, 并且以端到端的方式进行训练, 其框架结构如图4所示^[24]。与以贪婪迭代方式折叠边缘的传统简化方法^[25]相比, 该方法可以一次性简化给定网格。该方法分3个步骤展开: ①使用随机采样的复杂扩展对输入顶点的子集进行采样; ②训练稀疏注意力网络以根据采样顶点的边缘连通性^[26]得到候选三角形; ③利用分类网络估计候选三角形包含在网格中的概率。

该模型通过训练点采样器模块选择提供输入空间的最佳覆盖点, 并将点与其邻域的偏差近似为:

$$f_i = \sigma(\mathbf{W}_{\varnothing} \max_{j \in N(X_i)} \mathbf{W}_{\theta}(X_i - X_j)) \quad (4)$$

其中, $N(X_i)$ 为点 X_i 的邻域, $\mathbf{W}_{\varnothing}$ 、 $\mathbf{W}_{\theta}$ 为可学习的参数, $\sigma(\cdot)$ 为非线性函数。在点采样器对模型进行采样后, 稀疏的自注意力层负责预测采样点之间的连通性。点 X_i 与点 X_j 相连的概率 $S[i, j]$ 为:

$$S[i, j] = \frac{\exp((\mathbf{W}_q \mathbf{f}_j)^T (\mathbf{W}_k \mathbf{f}_i))}{\sum_{k \in N(X_i)} \exp((\mathbf{W}_q \mathbf{f}_j)^T (\mathbf{W}_k \mathbf{f}_k))} \quad (5)$$

为了估计候选三角面的包含概率 p_i , 面分类器堆叠了3个GNN层, 并使用先验概率 $\{p_i^{init}\}$ 作为每个三角形的初始特征输入, 通过 Softmax 激活函数得到三角形的最终包含概率。该模型运行时效率和轻量级结构使其能够直接用于广泛的微分应用, 但该方法可能会破坏原始网格的拓扑结构及其流形性。




Fig. 4 Model framework

图4 模型架构

Groueix 等^[27]提出一种利用拓扑修改网络结构的方法。该方法能够捕捉并保持重建网格的拓扑结构, 有助于在重建过程保持形状的整体连通性和准确性。该方法使用端到端的训练方式简化了整个模型简化流程。但其网络结构相对复杂, 需要更多的计算资源和训练时间。Zhou 等^[28]创新性地提出了一种基于图卷积神经网络的多任务学习框架, 该框架将模型简化问题表述为节点移除分类与节点移动回归的联合优化任务, 能够高效地同时学习节点移除和移动的复杂关系, 为模型简化领域提供了新的解决方案。然而, 该算法的性能在很大程度上依赖于训练数据的质量和多样性, 训练数据会在很大程度上影响模型泛化能力。

3.1.3 网格卷积神经网络

多边形网格利用非均匀性表示大的平坦区域以及尖锐、复杂的特征。传统卷积和池化操作无法很好地适应不规则的网格结构, 因此难以直接应用于这类数据。网格卷积神经网络 (Mesh Convolutional Neural Network, MeshCNN) 的出现为处理不规则的三维网格数据提供了一种有效方法, MeshCNN 采用了特殊设计的卷积层, 这些卷积层能够在不规则的网格结构上进行局部和全局特征的捕捉^[29]。该网络为边缘定义的卷积算子, 其空间支持使用4个入射邻边定义, 边缘特征 e 及其4个相邻边的卷积定义如下:

$$e \cdot k_0 + \sum_{j=1}^4 k_j \cdot e^j \quad (6)$$

其中, e^j 为 e 的第 j 个卷积邻居的特征, k_0 、 k_j 分别为 e 与

e^j 对应的卷积核。

同时, 为了保证输入数据排序的卷积不变性, 该方法对模糊对应用一组简单的对称函数^[30]。边 e 的感受野如下^[31]:

$$(e^1, e^2, e^3, e^4) = (|a - c|, a + c, |b - d|, b + d) \quad (7)$$

因此, 卷积运算无需考虑网格元素的初始顺序即可得到相同输出。

MeshCNN 可以适应不均匀的节点和边分布, 提高了对不规则数据的处理能力。在此基础上, 研究者们提出了一些改进和扩展的方法。一部分研究者通过在 MeshCNN 框架中整合图神经网络, 能够更好地理解和处理网格数据, 从而实现高效的网格简化。而另一些研究者通过对原始网格进行细分操作, 将其转换为更加密集的网格结构, 提高了特征提取精度, 适用于处理复杂的网格数据。此外, 研究者们还尝试在网格卷积神经网络中引入注意力机制, 允许网络在进行卷积操作时更加关注重要的网格节点或特征。引入注意力机制能够帮助模型更好地捕捉网格数据的重要特征, 从而提高了模型的简化性能。

(1) 原始对偶网格卷积神经网络。传统的神经网络方法在简化三维几何模型时, 通常有以下两种方法: ①将输入网格转化为图处理, 忽略了网格的特定几何属性; ②依赖于不准确捕捉网格局部拓扑的卷积定义实现对网格的直接应用。为了克服上述限制, Milano 等^[32]将图神经网络框架与 MeshCNN 相结合, 提出了能直接应用于三角网格的原对偶图卷积框架 (Primal-Dual Mesh Convolutional Neu-

ral Networks, PD-MeshNet)。对于给定网格, PD-MeshNet 将构建相应的原图和对偶图(见图 5), 将三维网格的边和面的特征作为输入, 并且利用注意力机制对特征进行动态聚合^[32,33]。此外, PD-MeshNet 的独特之处在于其具有精确几何解释的池化操作, 即两个相邻原始节点之间的注意力系数编码着网格的两个相应面之间的信息流, 原始图 $P(M)$ 中基于注意力驱动的边缘收缩对应于网格 M 的面合并。PD-MeshNet 通过堆叠多个池化层, 允许通过以任务驱动的方式对网格面进行聚类以处理网格连接性的变化。




Fig. 5 Original dual graph

图 5 原对偶图

在 PD-MeshNet 网络架构的基础上, Yang 等^[34]提出利用对偶网格和金字塔式扩张卷积以学习 3D 网格的有效表示。这种表示学习方法能够捕获复杂的几何形状特征, 从而为网格简化任务提供更好的支持和性能。但对于一些复杂的形状或者特定的数据分布, 生成的结果并不稳定, 需作进一步改进和优化。Hu 等^[35]基于 PD-MeshNet 提出 PDMeshNet++ 这一神经网络架构, PDMeshNet++ 利用金字塔扩张卷积等技术以增强网络的特征学习能力, 该方法在处理不同形状具有较强鲁棒性的同时, 还提高了网格简化的性能和效率。Xing 等^[36]提出一种结合层次神经网络进行网格简化的方法, 层次神经网络的设计有助于对不同层次的特征进行学习和集成, 能够有效地去除噪声并保持网格形状的细节和结构, 提高了网格简化的准确性。此外, Li 等^[37]提出了网格处理网络 DGNet。DGNet 基于双图金字塔指导层次级别之间的特征传播, 在所提出的层次图上聚合局部特征, 确保特征在不同层次之间的有效传递, 从而实现任意网格的高效处理。

(2) 基于细分的网格卷积神经网络。细分曲面能够提供分层多分辨率结构, 其封闭三角形网格中的每个面都与 3 个面相邻^[38-39]。基于以上两点, Hu 等^[40]提出了一种新颖的多功能 CNN 框架 SubdivNet, 其用于具有循环细分序列连接性的三维网格^[41]。由于具有任意连接性的网格均可以通过自参数化重新网格化以具有循环细分序列连接性, 从而使得 SubdivNet 成为一种通用方法。SubdivNet 使用网格金字塔结构进行有效的特征聚合, 并利用池化层将 4 个面统一合并为 1 个面^[42]。该方法在准确性和效率方面都表现良好, 但也存在着以下局限性: ①该框架必须确保卷积是有序不变的, 因此必须首先变换邻域特征而无法直

接应用原始信号; ②SubdivNet 仅支持具有循环细分序列连接性的三维网格, 因此应用于其他类型网格时必须重新划分网格。

Genova 等^[43]从三维网格中提取等值面进行可微分的细分和合并操作, 使得对等值面的提取过程可以直接纳入到深度学习框架中。MeshSDF 可以在保持网格拓扑的同时, 对三维网格进行动态调整。这种方法在生成等值面的同时, 还可以计算等值面的法向量和曲率, 从而提高了对几何细节的表达能力。然而, MeshSDF 存储的是网格表面上的距离场值, 其在表面以外的区域精度会受到限制, 因而不适用于需要高精度表示的应用场景。Huang 等^[44]通过使用可微分的网格表示实现了对三维网格的端到端优化, 整个网格优化过程通过梯度下降进行训练, 从而在保持网格整体形状不变的情况下, 能够实现对网格的高效简化。由于端到端优化的特性, 该方法可以适应不同类型的输入网格和优化目标, 使得在不同的应用场景中都能够取得良好效果。但其优化过程是针对静态网格, 对于动态变化的网格, 该方法需要频繁地更新优化过程, 从而导致计算和存储成本增加。

(3) 基于注意力机制的网格卷积神经网络。相较于其他数据表达形式, 三角网格适用于表示各种形状和表面类型, 并且具有灵活性, 通过控制三角形数量可在不同场景中平衡模型细节和性能需求, 因而在计算机图形学领域被广泛采用。然而, 图形处理器等硬件的发展速度逐渐无法保持与三角网格日益增加的复杂度相匹配。为了解决这一问题, 谭超^[45]提出了一种基于注意力模块的网格简化方法。该方法通过引入注意力模块对网格特征进行有效提取, 加强模型的重要特征而忽略非重要特征。其通道注意力权重向量 $F_\alpha(V)$ 由下式计算得出:

$$F_\alpha(V) = \sigma(\text{MLP}(\text{AvgPool}(V)) + \text{MLP}(\text{MaxPool}(V))) \\ = \sigma(W_1 * \rho(W_0(F_{\text{avg}})) + W_1 * \rho(W_0(F_{\text{max}}))) \quad (8)$$

其中, σ 表示激活函数, W_0 与 W_1 为多层感知机 MLP 的权重, ρ 表示 ReLU 函数, F_{avg} 与 F_{max} 分别为平均池化算子和最大池化算子生成的特征向量。

该方法能够利用神经网络直接优化原始模型与简化模型之间的损失函数以得到顶点的最佳合并位置, 而无需额外数据对模型进行训练。该算法能够在对网格模型进行简化的同时很好地保持模型特征, 但该算法并不能够保证简化误差在任何时候均可以小于给定阈值, 进而不适用于简化程度很高的简化任务。此外, Xu 等^[46]介绍了一种基于网格注意力机制的网络结构, 通过注意力机制, 网络可以自动学习并聚焦于网格中的重要区域, 从而更好地保留关键的几何特征并提高简化精度。但注意力机制会导致网络计算复杂度的增加, 因而需要更多的计算资源和时间。Potamias 等^[28]提出了基于注意力机制的快速且可扩展的简化方法, 其运行性能相较于传统方法提高了近 10 倍。Milano 等^[37]提出了基于对偶图的网格简化算法, 其同

样引入了注意力机制动态聚合 3D 网格的边和面, 使得网络在专注于模型局部特征的同时在全局范围内协调节点之间的关系, 以确保简化后的网格更好地保持原始网格的整体形状和拓扑结构。

3.1.4 顶点—面卷积神经网络

Zhang 等^[47]提出了一种新颖的顶点连接卷积方法(Vertex Connection Convolution, VCC)用于处理三角网格数据, VCC 充分利用了网格中顶点之间的连接性质, 能够更好地考虑网格的局部连接性, 但其基于顶点卷积导致训练和推理的时间复杂度较高。Huang 等^[48]提出了一种用于三角网格的卷积神经网络结构, 该方法利用了面—顶点—面(Face-Vertex-Face, FVF)结构, 其在卷积操作中考虑了三角网格的局部连接性, 通过在每个面上执行卷积操作以提取特征, 提高了模型简化效率。同时, 该方法引入了内在滤波以解决不同尺度上的卷积问题, 提高了模型鲁棒性和性能。

但是, 上述方法依赖于 CPU 以获取多分辨率网格, 因而不足以满足实时性或大规模数据的处理需求。为了实现网络的快速抽取, Lei 等^[49]设计了基于 GPU 加速的网格简化库 Picasso。与将网格视为具有边的空间图的简化方法不同, Picasso 将网格视为包含顶点和面的几何结构。Picasso 中内含 4 种类型的新颖卷积模块, 分别是 facet2vertex、vertex2facet、vertex2vertex 和 facet2facet。这些卷积模块交替学习网格上的逐点特征和逐面特征, 以提高特征提取的执行效率。facet2vertex 卷积根据相邻面的特征计算顶点特征, 通过将每个面的法线关联到球体上的不同位置以定义内核的滤波器权重, 并利用不同高斯分量的混合^[50]以划分球体表面和隐式聚类法线。Picasso 根据面 f_i 对应的法向量 n_i 计算其模糊系数 π_{ii} , 令卷积核中的滤波器权重为 w_i , 顶点 v 的相邻面为 $N(v)$, 面特征为 J_i , 得到顶点特征 I_v 为:

$$I_v = \frac{1}{N(v)} \sum_{f_i \in N(v)} \left(\sum_{i=1}^r \pi_{ii} w_i \right) J_i \quad (9)$$

vertex2facet 卷积模块定义了一个与面顶点相关联的 3 个滤波器组成的内核, 进而对面进行重心插值, 用于将模糊方案合并到卷积中。Picasso 确定插值点总数为 K , 通过计算每个插值点的特征 I_k 与滤波器权重 w_k , 得到对应面的特征 J 为:

$$J = \frac{1}{K} \sum_k w_k * I_k \quad (10)$$

vertex2vertex 卷积和 facet2facet 卷积由 vertex2facet 卷积和 facet2vertex 卷积组成, 并且将批量归一化应用于顶点和面特征。同时, Picasso 不再执行迭代收缩, 相反, 它将顶点组分为多个独立的簇。由于孤立簇之间相互独立, Picasso 利用 GPU 对每个顶点簇并行执行顶点抽取, 极大提高了网格简化的执行效率。

Lei 等^[51]在 Picasso 的模块化操作功能的基础上进一步提出了一种新颖的分层神经网络 PicassoNet ++。PicassoNet ++ 包含一系列有效保持几何特征的模块化操作, 其

网格卷积利用球谐函数作为正交基以创建连续卷积滤波, 并使用 GPU 加速对网格的即时批量处理, 因而能够高效学习模型特征并进行模型处理。然而, PicassoNet ++ 中 facet2vertex 卷积和扩展点云卷积由于依赖于法线和点之间的相对位置, 而无法保持旋转不变性, 从而可能导致模型在不同旋转姿态下的泛化能力下降。

3.1.5 自编码器

自编码器(Autoencoder)由编码器(Encoder)网络和解码器(Decoder)网络组成, 输入数据通过编码器被压缩为低维表示, 再通过解码器进行重构, 同时最小化重构与原始输入数据之间的误差^[52-53]。对于复杂的网格数据, 自编码器通过识别和捕获模型的重要特征, 有助于减少模型复杂度并保留最重要特征信息。

为实现在部分解码的同时能够理解整个模型的形状及其细节, Kimata^[54]提出了一种混合点云编码方法。该方法由分层结构和高效的分块编码方法组成, 通过结合自编码器以呈现模型的主要特征。该混合编码器方案结合了 Spatial 和基于自编码器的深度神经网络(Deep Neural Network, DNN)两种表示模式^[55]。在 Spatial 模式下, 该方法对每个重要要素 3D 坐标值进行均匀量化, 并采用 Lempel-Ziv-Markov 链算法编码^[56]。在 DNN 模式下, 使用自动编码器的编码器将高维度的输入数据映射到低维度的表示空间, 对其进行量化和算术编码。编码过程如图 6 所示^[54]。其中, DNN 模式在较高编码层上比 Spatial 模式具有更高的压缩效率。而在较低层, DNN 模式和 Spatial 模式的效率优势发生逆转。通过在 DNN 模式和 Spatial 模式之间进行切换, 该方法提高了简化效率, 在解码时能够很好地呈现模型整体形状和细节。




Fig. 6 Hybrid point-cloud encoding process

图6 混合点云编码过程

对于高分辨率或大规模的三维数据, 三维体素的显式表示会占用大量存储空间, 这将导致存储成本增加, 并且在处理和传输数据时也面临着挑战。针对这一问题, Mills 等^[57]提出了一种基于八叉树表示和变分自编码器(Variational Autoencoders, VAEs)压缩三维体素网格的方法。八叉树递归地将整个空间分解成八元组进行编码, 有效节省了存储空间。该方法定义了 3 种不同类型的八元组, 分别

为混合叶子、空叶子和内部节点。该方法将分解后的叶子节点作为训练数据输入到编码器中,并将输出隐向量送入解码器进行重构以得到简化结果。通过对混合叶子进行高效编码得到其紧凑的隐式表示,该算法进一步降低了存储需求。VAEs网络结构如表1所示,其中编码器最后一层激活函数为Sigmoid,解码器对应激活函数为ReLU。

Table 1 Network structure for VAEs encoder

表1 VAEs编码器网络结构

层	卷积类型	激活函数	特征维度	卷积核大小	步长
1	Conv3d+bn	ELU	64 x 32 x 32 x 32	4	2
2	Conv3d+bn	ELU	128 x 16 x 16 x 16	4	2
3	Conv3d+bn	ELU	256 x 8 x 8 x 8	4	2
4	Conv3d+bn	Sigmoid/ReLU	512 x 4 x 4 x 4	4	1

目前,大多数简化算法均基于几何且依赖于特定规则。Yan等^[58]提出基于图自动编码器(Graph Autoencoder, GAE)的深度学习方法来简化建筑物。该模型接收顶点坐标并将其作为输入,使用基于图傅里叶变换的图卷积用于逐层特征计算,并通过池化用更少的顶点重构原始输入以获得简化表示。通过调整损失函数,该模型可以在统一的学习框架下灵活配置面积和形状保留以及角度特征增强等约束。与其他基于深度学习的网格简化算法一样,Yan等^[59]提出的方法需要大量的训练数据,在训练数据量有限的情况下会导致模型泛化能力下降。Schönhof等^[60]提出基于EfficientNet架构的深度残差3D自动编码器,旨

在使用自动编码器在没有标记数据的情况下以无监督的方式对模型进行特征学习,很大程度上解决了训练数据不足这一挑战。

现有基于深度学习的网格简化算法之间的联系如图7所示。其中,GNG通过动态调整神经元数量以适应不同形状和密度的数据集,尤其适用于处理具有复杂拓扑结构的网格。然而,GNG对大规模网格的简化性能有限且高度依赖于参数设置。GNN利用图结构处理网格数据,适用于分割和重建网格。通过结合拓扑感知技术,GNN能够更好地理解和处理网格数据,为网格简化提供了新方法。MeshCNN则通过特殊的卷积层直接应用于三维网格模型,为捕获不规则的三维网格数据的局部与全局特征提供了有效方法。基于细分的卷积神经网络通过细分网格提高特征提取精度,但仅适用于具有循环细分连接性的网格。基于注意力机制的卷积神经网络使网络聚焦于重要区域从而提高简化精度,但计算复杂度增加。基于顶点与面的卷积神经网络考虑了网格的局部连接性,提高了简化效率。但其卷积操作依赖于法线信息,法线方向的变化可能导致简化效果在不同旋转姿态下的模型上产生变化。基于自编码器的网格简化算法利用编码器压缩顶点以及解码器重构网格,可以识别和保留网格的关键特征。但在训练过程中,自编码器可能会陷入局部最优解,导致简化效果不佳。




Fig. 7 Algorithm relationship

图7 算法关系

4 网格简化技术在GIS中的应用

在地理信息系统(Geographic Information System, GIS)中,网格简化技术在多个方面得到应用,以提高矢量数据处理、可视化和用户交互效率。网格简化技术在GIS中的常见应用主要体现在如下方面。

4.1 地质体模型处理

地质体模型是基于地质学、地球物理学及地球化学数据建立的三维模型,用于理解地球内部结构、地质过程、矿产资源勘探开采、地下水管理及工程规划。地质体模型整合了多种数据源,包括地质勘探、地球物理勘测、地球化学分析、钻孔数据等。地质体模型通常包含大量的三维地质

数据,这对计算机性能和存储要求提出了挑战。

在处理三维地质体模型时,网格简化技术是一项关键方法,用于优化模型以提高处理效率、降低存储需求并方便可视化。网格简化技术在地质勘探、建模与仿真、可视化等领域发挥着重要作用,基于网格的三维地质体模型如图8所示。在地质勘探中,网格简化能够有效地减小地质体模型复杂性,提高计算效率,加速地质过程模拟和分析速度。而在地质建模和仿真领域,网格简化有助于降低计算复杂度,提升仿真速度。此外,网格简化还提高了地质体模型的交互性,用户可以在不同细节级别之间进行切换,动态加载和卸载数据,以便更好地了解地下结构,进行模型导航和分析。

总体而言,网格简化技术在处理大规模的三维地质体




Fig. 8 Mesh-based 3D geological model

图8 基于网格的三维地质体模型

模型时发挥着关键作用。它通过在保留关键地质信息的同时减少数据量,使得地学研究、资源勘探和其他地球科学领域能够更有效地处理和应用地质体模型。

4.2 地图绘制与渲染

大规模的地理数据集通常包含大量细节,但并非所有细节对于特定应用或特定缩放级别都是必要的,复杂的数据可能会导致绘制和渲染速度缓慢。简化后的数据具有更少的顶点,使得地图绘制和渲染过程更加高效。这对于需要实时交互和动态更新的GIS应用尤为重要,例如导航应用需要在实时导航过程中快速渲染更新的地图。

网格简化技术还可用于控制绘制质量,在不同的缩放级别下,选择不同程度的细节层次以绘制地图。在高缩放级别下,可使用完整的高精度数据进行渲染,而在低缩放级别下,可使用简化后的数据对地图进行渲染。通过调整简化的程度,能够使绘制的地图更加平滑或保留更多细节,从而确保地图在不同的缩放级别下都能保持合适的绘制质量。图9展示了不同分辨率下绘制的折线向量。其中,图9(a)为全分辨率面片(LOD-0)上绘制的折线向量,而图9(b)为较低分辨率面片(LOD-1)上绘制的相同折线向量。此外,使用简化后的数据进行渲染时,能够根据当前视口和分辨率,选择合适级别的网格数据对地图进行显示,进而实现在用户导航或变焦时动态更新渲染的网格级别。




Fig. 9 Multi resolution line

图9 多分辨率折线

4.3 网络传输与存储优化

GIS数据通常包含大量的地理空间信息,如地图图层、卫星影像、地形数据等。网格简化技术可以通过减少数据量、多分辨率传输和空间优化等方式,显著降低数据传输和存储成本。在网络传输中,大量的数据会占用带宽和增加传输时间。网格简化技术通过去除冗余信息和减少数据复杂性,能够显著减小模型或图形数据的体积。通过减

小数据量,可以降低网络传输延迟,提高传输效率。同时,网格简化技术允许创建多个分辨率级别的数据,低分辨率的数据适用于远程浏览或快速预览,而高分辨率的数据则可用于需要更多细节的场合。在传输过程中,可以根据需要选择合适的分辨率进行传输,以平衡传输效率和保留足够细节的需求。此外,网格简化通常能够与压缩技术结合使用^[61-62]。这种组合可以进一步减少数据量,提高传输效率,并在接收端解压还原成原始的高分辨率数据。

网格简化技术通过降低模型复杂性,能够大幅度减小存储所需空间。对于需要频繁存储和访问的大规模三维模型,网格简化技术节省存储空间的优势尤为显著。同时,网格简化技术还支持动态加载,即根据需要在运行时动态加载数据^[63]。这在网络传输和存储中意味着可以按需获取数据,而不是一次性加载全部数据,有助于减少内存占用和提高运行效率。

4.4 空间分析和查询

网格简化在空间分析与查询中扮演着至关重要的角色,其主要通过降低空间数据的复杂性,在提高查询性能、减小存储需求、加速分析过程等方面发挥作用。

网格简化技术通过构建空间索引,将地理空间划分为规则的网格单元,能够实现对空间数据的快速查询,例如范围查询和最近邻查询^[64-66]。网格简化动态调整数据精度和分辨率,以适应不同的查询和分析需求,进而提高实时地理数据流处理效率。

网格简化还有助于进行空间聚类 and 簇分析^[67]。网格简化技术能够将相似地理对象分配到相邻网格单元,识别出空间上的簇和群集,揭示出空间中的关联性和模式。在移动物体轨迹数据分析方面,网格简化可以降低轨迹数据的复杂性,支持关键路径和趋势识别。总而言之,网格简化技术在空间分析与查询中发挥着关键作用,为处理大规模、高复杂性的空间数据提供了有效的解决方案。

4.5 地形建模

高程数据是地形建模的基础,数字高程模型^[68](Digital Elevation Map, DEM)和数字地面模型^[69](Digital Terrain Model, DTM)是常用的高程数据形式,记录了地表上各点的高程信息。DEM与DTM通常以复杂的栅格形式存在,虽然复杂密集的网格可以表现出地质体的真实感和层次感,但大量的数据给存储、传输、计算和绘制带来了不便,特别是在硬件条件相对受限的移动设备上。此外,在可视化过程中,由于人类感知细节的有限性,过多的网格并不一定会带来更好的体验效果,反而可能增加硬件负担并降低加载速度。因此,在某些情景下需要对网格进行简化以提高传输与显示效率。

为了增强地形模型的视觉效果,地质建模通常使用纹理映射将地表纹理贴图应用于模型表面^[70]。纹理映射使得地形模型更加真实,并呈现出地表的自然特征,如土地类型、植被覆盖等。但高分辨率的地质纹理可能导致数据

过于庞大和复杂,需要消耗大量的计算和存储资源。通过对地质模型进行网格简化,可以减小模型的体积,从而降低纹理映射的计算复杂度,确保在有限的计算环境中更高效地进行纹理映射。图 10 展示了 MeshCNN 和 Picasso 模型简化效果。




Fig. 10 Simplification effects of mountain ranges

图 10 山脉简化效果

地球上的地质结构通常呈现出多层次的特征,包括从大地质单元(如大陆和洋壳)到小尺度的地质细节(如岩石层和断层)^[71]。为了更准确、全面地模拟自然地质现象,提供更具真实感和可视化效果的模型,地质建模通常需要使用网格简化支持的多层次细节技术,根据观察者的距离调整模型的细节级别,以在远处呈现整体地形,在近处呈现更为精细的细节。地形网格简化与调整效果如图 11 所示^[72]。




Fig. 11 Simplification and adjustment of terrain meshes

图 11 地形网格简化与调整

此外,网格简化技术还能够提高地形绘制技术的同时,尽可能地保留地形特征^[73]。通过对地形特征重要度进行学习,可以对特征重要度较高的山地地区放大处理,对特征重要度较低的平原地区缩小处理,以突显地形丰富区域。依据地形重要度调整平原特征与山区特征的比例,可以保留特征明显区域的原貌。

总而言之,网格简化技术在 GIS 中的应用旨在平衡地理数据的精度和处理性能,为有效地管理和利用地理信息提供了重要工具。

5 总结与展望

本文对基于深度学习的网格简化算法进行了全面的梳理和总结,深入探讨了不同深度学习模型在网格简化领域的应用,以及它们在提高网格简化效率和质量方面的优势。通过回顾多个相关研究,本文强调了深度学习在网格

简化中取得的显著进展,包括对复杂模型和大规模数据集的高效处理能力。

尽管深度学习算法在网格简化任务中表现出色,但当前算法仍然存在着一定的局限性。首先,深度学习模型通常被认为是黑盒模型,其决策过程往往依赖于大量的非线性变换,缺乏明确的解释规则;其次,深度学习算法通常需要大量标注数据以训练模型,以便在不同网格结构上取得良好的泛化性能。然而,在某些领域,获取大规模的标注数据可能非常昂贵或困难,这使得算法在小样本数据上的表现受到限制。此外,深度学习模型的训练和推理通常对计算资源有着较高需求,使得在资源受限的环境中应用这些算法变得具有挑战性。未来,该领域的研究可能集中于以下几个方面:

(1)模型可解释性。提高深度学习模型的可解释性将成为一个重要研究方向。解释模型对网格简化的决策过程有助于提高算法的可信度和可控性,对于一些对解释性要求较高的应用场景尤为重要。未来研究工作将致力于开发更清晰的网络结构和训练方法,以提高模型解释性。

(2)小样本学习方法。针对需要大量训练数据的问题,研究人员可以探索迁移学习和元学习等小样本学习方法。优化模型在小样本数据上的表现,以减少对大规模标注数据的依赖。

(3)降低计算资源需求。降低深度学习模型对计算资源的需求也将是未来研究的重点。这包括通过不断改进模型压缩技术、设计轻量级网络结构,以及进行硬件优化以减小模型的参数量和计算复杂度。此外,将深度学习模型部署到边缘设备,通过边缘计算减少对中央服务器的依赖,有望在降低通信开销和提高计算效率方面取得进展。

参考文献:

- [1] WANG Q, KIM M K. Applications of 3D point cloud data in the construction industry: a fifteen-year review from 2004 to 2018[J]. *Advanced Engineering Informatics*, 2019, 39: 306-319.
- [2] GORTE B. Analysis of very large voxel datasets[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2023, 119: 103316.
- [3] ZHANG C, NING T, LI J, et al. Refractive index and strain sensor based on twin-core fiber with a novel T-shaped taper[J]. *Optics & Laser Technology*, 2018, 102: 12-16.
- [4] DENISOV S A. The sharp corner formation in 2D Euler dynamics of patches: infinite double exponential rate of merging[J]. *Archive for Rational Mechanics and Analysis*, 2015, 215: 675-705.
- [5] LI K, WU X, CHEN D Z, et al. Optimal surface segmentation in volumetric images—a graph-theoretic approach[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 28(1): 119-134.
- [6] LIM S P, HARON H. Surface reconstruction techniques: a review[J]. *Artificial Intelligence Review*, 2014, 42: 59-78.
- [7] STAM J. Exact evaluation of Catmull-Clark subdivision surfaces at arbitrary parameter values[C]//*Proceedings of International Conference on Computer Graphics and Interactive Techniques*, 1998: 161-172.

- [8] DARMOCHWAL A. The euclidean space [J]. *Formalized Mathematics*, 1991, 2(4): 599–603.
 - [9] FRITZKE B. A growing neural gas network learns topologies [J]. *Advances in Neural Information Processing Systems*, 1994, 7: 625–632.
 - [10] HARAZONO Y, ISHII H, SHIMODA H, et al. Development of AR-based scanning support system for 3D model reconstruction of work sites [J]. *Journal of Nuclear Science and Technology*, 2022, 59(7): 934–948.
 - [11] RODRIGUES F, CARDOSO J S. An adaptive grid simplification technique based on growing neural gas [C]//Coimbra: The 18th Portuguese Conference on Pattern Recognition, 2011.
 - [12] HURTADO J E, FERNÁNDEZ C, ÁLVAREZ M A. An optimized implementation of growing neural gas for the automatic construction of topological maps [J]. *Neurocomputing*, 2017, 229: 168–180.
 - [13] ÁLVAREZ R, NOGUERA J V, TORTOSA L, et al. A mesh optimization algorithm based on neural networks [J]. *Information Sciences*, 2007, 177(23): 5347–5364.
 - [14] WANG J, YI X, GUO R, et al. Milvus: a purpose-built vector data management system [C]//Proceedings of the 2021 International Conference on Management of Data, 2021: 2614–2627.
 - [15] WU S, SUN F, ZHANG W, et al. Graph neural networks in recommender systems: a survey [J]. *ACM Computing Surveys*, 2022, 55(5): 1–37.
 - [16] WANG Y, SUN Y, LIU Z, et al. Dynamic graph CNN for learning on point clouds [J]. *ACM Transactions on Graphics (TOG)*, 2018, 38(5): 1–12.
 - [17] HANOCKA R, HERTZ O, FISH N, et al. MeshCNN: a network with an edge [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 9242–9251.
 - [18] MAO Y, HUANG Z, LU H. TopoNet: topology-aware convolutional neural networks for 3D shape analysis [J]. *ACM Transactions on Graphics (TOG)*, 2019, 38(6): 165.
 - [19] POTAMIAS R A, BOURITSAS G, ZAFEIRIOUS S. Revisiting point cloud simplification: a learnable feature preserving approach [C]//Proceedings of the European Conference on Computer Vision, 2022: 586–603.
 - [20] TOLSTIKHIN I O, HOULSBY N, KOLESNIKOV A, et al. MLP-mixer: an all-MLP architecture for vision [J]. *Advances in Neural Information Processing Systems*, 2021, 34: 24261–24272.
 - [21] YAO Z, CAO Y, ZHENG S, et al. Cross-iteration batch normalization [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 12331–12340.
 - [22] CHEN Y, DAI X, LIU M, et al. Dynamic relu [C]//Proceedings of the European Conference on Computer Vision, 2020: 351–367.
 - [23] CUI X C, FU Y, SU Y, et al. Space target attitude estimation based on projection matrix and linear structure [J]. *IEEE Signal Processing Letters*, 2023, 30: 918–922.
 - [24] POTAMIAS R A, PLOUMPIS S, ZAFEIRIOU S. Neural mesh simplification [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 18583–18592.
 - [25] LI M, NAN L. Feature-preserving 3D mesh simplification for urban buildings [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 173: 135–150.
 - [26] MITTAL M, VENNA A, KAUR I, et al. An efficient edge detection approach to provide better edge connectivity for image analysis [J]. *IEEE Access*, 2019, 7: 33240–33255.
 - [27] GROUEIX T, FISHER M, KIM V G, et al. A papier-mâché approach to learning 3D surface generation [C]//Proceedings of the European Conference on Computer Vision, 2018: 217–234.
 - [28] ZHOU Z, ZHI Y, CHENG F, et al. Move and remove: multi-task learning for building simplification in vector maps with a graph convolutional neural network [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 202: 205–218.
 - [29] HANOCKA R, HERTZ A, FISH N, et al. MeshCNN: a network with an edge [J]. *ACM Transactions on Graphics (ToG)*, 2019, 38(4): 1–12.
 - [30] KAYHAN O S, GEMERT J C. On translation invariance in CNNs: convolutional layers can exploit absolute spatial location [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 14274–14285.
 - [31] ARAUJO A, NORRIS W, SIM J. Computing receptive fields of convolutional neural networks [J]. *Distill*, 2019, 4(11): e21.
 - [32] MILANO F, LOQUERCIO A, ROSINOL A, et al. Primal-dual mesh convolutional neural networks [J]. *Advances in Neural Information Processing Systems*, 2020, 33: 952–963.
 - [33] QIAO W, LIU Q, WU X, et al. Automatic pixel-level pavement crack recognition using a deep feature aggregation segmentation network with a self-attention mechanism module [J]. *Sensors*, 2021, 21(9): 2902.
 - [34] YANG H T. Learning mesh representation for 3D shape representation and generation [C]//New York: the AAAI Conference on Artificial Intelligence, 2020.
 - [35] HU Q Y. PDMeshNet++: pyramid dilated mesh convolutional neural networks for 3D shape classification [J]. *IEEE Access*, 2021, 9: 16476–16485.
 - [36] XING Y, TAN J, HONG P, et al. Mesh denoising based on recurrent neural networks [J]. *Symmetry*, 2022, 14(6): 1233–1246.
 - [37] LI X L, LIU Z N, CHEN T, et al. Mesh neural networks based on dual graph pyramids [J]. *IEEE Transactions on Visualization and Computer Graphics*, 2024, 30(7): 4211–4224.
 - [38] CHEN L, LU C, ZHAO W, et al. Subdivision surfaces—boundary element accelerated by fast multipole for the structural acoustic problem [J]. *Journal of Theoretical and Computational Acoustics*, 2020, 28(2): 2050011.
 - [39] KARAMI M, LUO J H. Hierarchical multi-resolution graph generative networks [DB/OL]. <https://arxiv.org/abs/2305.19337>, 2023.
 - [40] HU S M, LIU Z N, GUO M H, et al. Subdivision-based mesh convolution networks [J]. *ACM Transactions on Graphics (TOG)*, 2022, 41(3): 1–16.
 - [41] LIU H T D, KIM V G, CHAUDHURI S, et al. Neural subdivision [DB/OL]. <https://arxiv.org/abs/2005.01819>, 2020.
 - [42] CHEN K, CAO Y, LOY C C, et al. Feature pyramid grids [DB/OL]. <https://arxiv.org/abs/2004.03580>, 2020.
 - [43] GENOVA K. MeshSDF: differentiable Iso-surface extraction [C]//Online: The European Conference on Computer Vision, 2020.
 - [44] HUANG H. DeepMesh: differentiable mesh optimization [J]. *Computer Graphics Forum (CGF)*, 2021, 40(2): 499–510.
 - [45] TAN C. Triangle mesh simplification algorithm based on neural network [D]. Hefei: University of Science and Technology of China, 2022.
- 谭超. 基于神经网络的三角网格简化算法 [D]. 合肥: 中国科学技术大学, 2022.

- [46] XU K. Mesh attention networks[C]//Seattle: the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10825–10833.
- [47] YANG Z S. Simplify 3D mesh by neural network[C]//Seattle: the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020.
- [48] HUANG S Y. Mesh convolutional operators with intrinsic filtering[C]//Long Beach: The IEEE Conference on Computer Vision and Pattern Recognition, 2019.
- [49] LEI H, AKHTAR N, MIAN A. Picasso: a cuda-based library for deep learning over 3d meshes[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13854–13864.
- [50] SUN S, TONG Y, ZHANG B, et al. An adaptive optimization method for estimating the number of components in a Gaussian mixture model[J]. Journal of Computational Science, 2022, 64: 101874.
- [51] LEI H, AKHTAR N, SHAH M, et al. Mesh convolution with continuous filters for 3-d surface parsing[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 35(10): 14863–14877.
- [52] ZHANG G, LIU Y, JIN X. A survey of autoencoder-based recommender systems[J]. Frontiers of Computer Science, 2020, 14: 430–450.
- [53] JI Y, ZHANG H, ZHANG Z, et al. CNN-based encoder-decoder networks for salient object detection: a comprehensive review and recent advances[J]. Information Sciences, 2021, 546: 835–857.
- [54] KIMATA H. Hybrid spatial and deep learning-based point cloud compression with layered representation on 3D shape[J]. ITE Transactions on Media Technology and Applications, 2023, 11(4): 138–145.
- [55] GUARDA A F R, RODRIGUES N M M, PEREIRA F. Adaptive deep learning-based point cloud geometry coding[J]. IEEE Journal of Selected Topics in Signal Processing, 2020, 15(2): 415–430.
- [56] SOWMYALAKAHMI R, WALY M I, SIKKANDARM Y, et al. An optimal Lempel Ziv Markov based microarray image compression algorithm[J]. Computers, Materials & Continua, 2021, 69(2): 018636.
- [57] LIU J, MILLS S, MCCANE B. Variational autoencoder for 3D voxel compression[C]//2020 35th International Conference on Image and Vision Computing New Zealand (IVCNZ), 2020: 1–6.
- [58] YAN X, YANG M. A deep learning approach for polyline and building simplification based on graph autoencoder with flexible constraints[J]. Cartography and Geographic Information Science, 2024, 51(1): 79–96.
- [59] YAN X, YANG M. A deep learning approach for polyline and building simplification based on graph autoencoder with flexible constraints[J]. Cartography and Geographic Information Science, 2024, 51(1): 79–96.
- [60] SCHÖNHOF R, ELSTNER J, MANEA R, et al. Simplified learning of CAD features leveraging a deep residual autoencoder[J]. Procedia CIRP, 2022, 109: 84–88.
- [61] GARLAND M, HECKBERT P S. Surface simplification using quadric error metrics[C]//Proceedings of the 24th Annual Conference on Computer Graphics and Interactive Techniques, 1997: 209–216.
- [62] DENG L, LI G, HAN S, et al. Model compression and hardware acceleration for neural networks: a comprehensive survey[J]. Proceedings of the IEEE, 2020, 108(4): 485–532.
- [63] DONG Y, PENG C. Multi-GPU multi-display rendering of extremely large 3D environments[J]. The Visual Computer, 2023, 39(12): 6473–6489.
- [64] JI C, LI Y, FAN J, et al. A novel simplification method for 3D geometric point cloud based on the importance of point[J]. IEEE Access, 2019, 7: 129029–129042.
- [65] DAVITKOVA A, MILCHEVSKI E, MICHEL S. The ML-index: a multi-dimensional, learned index for point, range, and nearest-neighbor queries[C]//Proceedings of the 23rd International Conference on Extending Database Technology, 2020: 407–410.
- [66] CHEN Y, ZHOU L, TANG Y, et al. Fast neighbor search by using revised KD tree[J]. Information Sciences, 2019, 472: 145–162.
- [67] FELLEGERA R, FLORIANI L D, MAGILLO P, et al. Tetrahedral trees: a family of hierarchical spatial indexes for tetrahedral meshes[J]. ACM Transactions on Spatial Algorithms and Systems (TSAS), 2020, 6(4): 1–34.
- [68] GUTH P L, VAN NIEKERK A, GROHMANN C H, et al. Digital elevation models: terminology and definitions[J]. Remote Sensing, 2021, 13(18): 3581.
- [69] GALIN E, GUERIN E, PEYTAVIE A, et al. A review of digital terrain modeling[J]. Computer Graphics Forum, 2019, 38(2): 553–577.
- [70] YANG J, LU L, PENG G, et al. Texture-mapping error removal based on the BRIEF operator in image-based three-dimensional reconstruction[J]. Remote Sensing, 2023, 15(2): 536.
- [71] THIELE S T, LORENZ S, KIRSCH M, et al. Multi-scale, multi-sensor data integration for automated 3-D geological mapping[J]. Ore Geology Reviews, 2021, 136: 104252.
- [72] XIAO M J, LU Q, LU Y Y, et al. Simplification and adjustment of terrain meshes based on the importance of terrain features[J]. Journal of Hefei University of Technology (Natural Science Edition), 2019, 42(5): 651–654, 701.
- 肖铭杰, 路强, 陆亦扬, 等. 基于地形特征重要度的地形网格简化与调整[J]. 合肥工业大学学报(自然科学版), 2019, 42(5): 651–654, 701.
- [73] FAN W, LIU G, CHEN Q, et al. Geological model automatic reconstruction based on conditioning Wasserstein generative adversarial network with gradient penalty[J]. Earth Science Informatics, 2023, 16: 2825–2843.

(责任编辑: 孙娟)