



XXXX

基于多尺度球坐标变换与自适应层次聚类的三维点云可逆信息隐藏算法

任帅, 丛天煜

(长安大学信息工程学院, 陕西 西安 710064)

摘要: 三维点云模型在数字版权保护、内容认证等领域具有重要应用价值。然而, 其可逆信息隐藏研究仍存在嵌入容量与几何保真度难以兼顾的问题。提出了一种融合多尺度球坐标变换与自适应层次聚类的三维点云可逆信息隐藏算法, 基于聚类局部点密度与尺度特征对点云进行三层分级处理, 在各聚类的局部球坐标系下建立高斯加权径向距离预测器, 并基于预测误差扩展 (Prediction Error Expansion, PEE) 技术实现水印的可逆嵌入与精确提取。实验结果表明, 该算法在嵌入容量有效提升的同时, 在阈值 $T \leq 2$ 时信噪比均保持在 65dB 以上, 且在参数 $T \leq 3$ 的条件下误码率为零 (恢复率 100%), 嵌入密度相较现有同类点云方法提升显著; 消融实验进一步验证了球坐标变换、自适应分层策略及高斯加权预测器各模块的有效性。

关键词: 三维点云模型; 可逆信息隐藏; 自适应层次聚类; 球坐标变换; 预测误差扩展

中图分类号: TP309.2

文献标志码: A

doi: 10.11959/j.issn.1000-0801.

Reversible data hiding for 3D point clouds via multi-scale spherical coordinate and adaptive hierarchical clustering

Ren Shuai, Cong Tianyu

School of Information Engineering, Chang'an University, Xi'an 710064, China

Abstract: Three-dimensional point cloud models hold significant application value in fields such as digital copyright protection and content authentication. However, reversible data hiding for 3D point clouds still faces the challenge of balancing embedding capacity with geometric fidelity. A reversible data hiding algorithm for 3D point clouds was proposed by integrating multi-scale spherical coordinate transformation with adaptive hierarchical clustering. The point cloud was processed through a three-level hierarchical scheme based on local cluster point density and scale features. A Gaussian-weighted radial distance predictor was constructed within the local spherical coordinate system of each cluster, and reversible watermark embedding and accurate extraction were achieved based on Prediction Error Expansion (PEE) technique. Experimental results showed that the proposed algorithm achieved a significant improvement in

收稿日期: 2026-04-01; 修回日期: XXXX-XX-XX

通信作者: 丛天煜, 2024124131@chd.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62372062)

Foundation Items: The National Natural Science Foundation of China (No.62372062)



embedding capacity, while the signal-to-noise ratio was maintained above 65 dB under the condition of threshold $T \leq 2$, and the bit error rate was zero (recovery rate 100%) when parameter $T \leq 3$; ablation experiments further validated the effectiveness of each module, including the spherical coordinate transformation, the adaptive hierarchical strategy, and the Gaussian-weighted predictor. The embedding density of the proposed method demonstrates a marked improvement over existing plaintext-domain point cloud methods.

Key words: 3D point cloud, reversible data hiding, adaptive hierarchical clustering, multi-scale spherical coordinate transformation, prediction error expansion

0 引言

随着多媒体技术以及数字信息技术等领域的迅速发展,作为继图像、音视频后的新一代数字媒介,三维模型具有数据量大及信息种类丰富等特点,近年来呈现几何级增长趋势,在数字版权保护、内容认证以及篡改检测等应用中受到广泛关注^[1]。三维模型主要划分为网格模型、点云模型、体素模型等多种形式,其中网格模型和点云模型在数据隐写研究中占据主导地位。与网格模型相比,点云模型结构更加简单,且灵活性高,缺乏连接信息,个别点的增删不会影响整体结构,因此,点云模型在存储和传输方面具有较高的效率优势^[2]。

信息隐藏技术是一种重要的信息安全保护手段,将秘密信息嵌入数字媒体,不仅可用于版权保护,还可用于隐蔽传输敏感信息^[3]。然而,传统的信息隐藏方法会对载体数据造成永久性改变,这在医学影像、军事国防、司法取证等对数据完整性要求严格的领域是不可接受的。可逆信息隐藏(Reversible Data Hiding, RDH)技术采取了更为严格的标准:提取隐藏信息后,原始载体数据可以完全无损地恢复,不留任何痕迹^[4]。该特性使可逆信息隐藏在对数据完整性要求严格的应用场景中具有不可替代性。例如,在医学影像领域,医生需要在患者CT或MRI扫描数据中嵌入诊断信息、患者身份等敏感数据,同时必须确保在需要时能够完全恢复原始医学影像,以便进行精确的诊断和治疗决策^{[5][6]}。在军事国防领域,

三维地形模型、目标识别数据等敏感信息需要加密传输,但在解密后必须保证数据的完整性和准确性。在司法取证领域,三维犯罪现场重建、证物扫描等数据具有法律效力,任何修改都必须是可逆的,以确保证据链的完整性^[7]。

目前,图像可逆信息隐藏方法已趋于成熟^[8],但三维点云可逆信息隐藏仍处于发展阶段。与二维图像和三维网格模型相比,点云模型具有局部密度不均匀、种类多样以及几何复杂度差异显著等特点,这些特性使得传统图像或网格模型中的可逆信息隐藏方法难以直接迁移到点云场景中。一方面,点云缺乏网格模型中的边、面等连接关系,导致基于拓扑邻域或网格面片的预测方法难以直接应用;另一方面,点云在不同区域通常呈现出明显的密度和尺度差异,若对整体点云采用统一预测模型和统一嵌入参数,容易造成平滑区域容量利用不足、复杂区域几何失真增大等问题^[9]。

现有点云信息隐藏研究主要包括变换域方法、直方图修改方法、预测误差扩展方法以及加密域可逆隐藏方法等。其中,变换域方法通常利用点云局部相关性进行系数修改,但其嵌入容量受限;直方图类方法能够在一定程度上降低失真,但对误差分布集中程度依赖较强;预测误差扩展方法具有较好的可逆性,但预测模型对点云局部几何结构的适应能力直接决定容量与失真的平衡效果^[10]。因此,如何在明文域点云模型中充分利用局部几何结构,在保证严格可逆性的同时提高嵌入容量并降低几何失真,仍是当前点云可

逆信息隐藏研究中的关键问题。

在上述应用场景中,部分研究转向加密域可逆信息隐藏,以期同时实现数据保密与完整性保护。然而,加密域方法在以下场景中存在不可忽视的局限:其一,在自动驾驶实时点云传输等对时延敏感的场景中,加密与解密的额外计算开销难以接受;其二,在面向内容认证的版权水印应用中,水印信息通常需要在明文状态下直接嵌入并由终端验证,而加密域方法要求接收方持有密钥方能提取水印,削弱了其作为公开版权凭证的实用性;其三,加密操作本身引入的数值变换会干扰几何保真度的客观评估,使明文域与加密域的容量-失真性能不具可比性。因此,针对明文域三维点云的可逆信息隐藏研究具有独立的应用价值与理论意义,不能被加密域方法所取代。

本文选择融合多尺度球坐标变换与自适应层次聚类,主要出于以下考虑:首先,自适应层次聚类能够根据点云局部密度和尺度特征将点云划分为不同几何复杂度的局部区域,从而避免对全局点云采用统一参数造成的容量浪费或失真集中;其次,球坐标变换能够将局部点云的空间关系转化为径向距离与角度方向的组合表示,使预测模型能够重点利用径向距离的局部相关性;最后,预测误差扩展技术能够在误差域中实现秘密信息嵌入与原始点云恢复,为算法的严格可逆性提供基础。由此,本文试图建立“局部几何特征—球坐标离散尺度—预测误差嵌入容量”之间的自适应联系,以提升明文域三维点云可逆信息隐藏的容量—失真综合性能。

1 相关工作

早期信息隐藏的载体类型主要为二维图像,随着多媒体技术的发展,三维模型数量与种类日渐庞大,以三维模型为载体的信息隐藏技术得到了国内外专家学者的广泛关注。1997年,Ohbuchi等人首次提出三维模型信息隐藏算法^[1]。

2002年,Kalker等人开始进行可逆信息隐藏算法的研究,最先给出了关于可逆信息隐藏的无噪信息理论模型^[12],然而该工作仅停留于理论框架层面。2003年,Tian^[13]提出了经典的差分扩展(Difference Expansion, DE)算法,为可逆信息隐藏领域奠定了理论基础。2005年,Wu等人提出了一种基于三维网格模型的可逆信息隐藏方法,通过调节三维网格面到网格质心的距离来嵌入水印,并确保提取后可恢复原始网格模型,然而该方法依赖网格的显式拓扑结构,无法应用于缺乏连接信息的点云模型^[14]。2006年,Luo等人介绍了一种用于三维点云模型的可逆数据隐藏方法,利用邻近顶点之间的高度相关性进行整数离散余弦变换并修改频率系数实现嵌入,以确保数据隐藏过程可逆,但该方法对所有区域采用统一处理参数,存在嵌入容量低的问题^[15]。2010年,Zhu等人提出了一种基于预测误差扩展的三维网格模型可逆信息隐藏技术,该方法通过修改网格顶点的预测误差来嵌入水印信息,确保水印嵌入后可以无损恢复原始三维网格模型^[16]。2018年Jiang等人介绍了一种针对加密三维网格模型的可逆数据隐藏方法,利用空间相关性在解密后实现数据提取与内容恢复,但该方法引入了额外的加密开销,且仅适用于加密域场景^[17]。Zhang等人介绍了通过结合预测误差扩展(PEE)和排序技术,提升三维网格模型可逆数据隐藏的容量与精度^[18]。同时,针对三维点云模型,还介绍了一种基于差值直方图的多级可逆数据隐藏方法,在一定程度上提升了几何保真度,然而嵌入容量依然有限,容量与失真的权衡问题未得到根本改善^[19]。2022年,Tang等人提出了一种基于拓扑结构的高容量可逆数据隐藏方法,专门用于加密三维网格模型,具有较高的数据嵌入容量^[20]。2024年,欧跃发等人提出了一种基于预测误差扩展的加密域点云模型可逆信息隐藏方法,拓展了点云载体在加密域中的应用,然而该方法以加密



操作为前提,明文域下的嵌入容量与几何保真度问题仍未得到有效解决^[21]。

近年来,生成式信息隐藏方法通过构造或生成含密载体实现信息嵌入,在图像隐写领域取得了一定进展^{[22][23]}。与此类方法不同,本文属于可逆信息隐藏范畴,以原始点云的精确恢复为核心约束,二者在应用场景与技术路线上存在本质差异。

通过对现有研究的分析,明文域三维点云可逆信息隐藏的研究相对匮乏,现有代表性工作(如Luo等^[15],Zhang等^[19])存在嵌入容量偏低或对几何复杂度适应性不足的问题。尽管部分研究在加密域取得了一定进展,但加密域方法与明文域方法解决的是本质上不同的问题:前者侧重数据传输保密性与水印的联合设计,后者则面向无需加密开销的直接内容认证与版权保护场景。在明文域基线方法相对稀少的背景下,容量与失真的权衡更加苛刻,如何有效平衡嵌入容量与几何保真度这一问题为本文研究提供了重要的改进方向。

2 算法设计

2.1 算法框架

本文提出了一种结合层次聚类与球坐标变换的三维点云可逆信息隐藏方法,核心创新在于围绕三维点云局部几何差异建立一种自适应嵌入框架。具体而言,本文利用局部点密度和聚类尺度划分处理层级,在各聚类局部球坐标系下选择不同的离散精度和嵌入强度,并在径向预测误差域中完成可逆嵌入,使嵌入策略能够随局部几何特征自适应调整。

相较Luo等统一参数处理方法、Zhang等差值直方图或预测误差扩展方法以及欧跃发等加密域方法,本文的主要区别在于面向明文域点云,构建了局部几何感知的层级尺度协同嵌入框架,以改善嵌入容量与几何保真度之间的平衡。

整个算法分为以下处理阶段。首先,采用改进的层次聚类方法对点云进行分组,综合考虑空间密度和径向距离特征,选择适合的嵌入区域。对每个聚类,本文方法在其局部坐标系中进行球坐标变换,即多尺度的球坐标网格划分。不同于Luo等人^[15]的方法对所有聚类使用统一参数,本文方法根据聚类的几何特性(点密度、尺度大小)自适应地选择球坐标空间的离散化精度。表面细节丰富的小尺度聚类通常需要精细的球坐标网格以充分捕获局部结构特征,而几何较为平滑的大尺度聚类则可采用粗粒度网格以降低计算开销。多尺度策略在充分利用局部几何结构的同时,有效控制了计算复杂度

随后构建预测模型。在球坐标系下,本文为每个点构建基于邻域点的径向距离预测器。受Zhang等人^[18]在三维网格预测误差扩展中工作的启发,本文采用高斯加权平均预测器构建径向距离预测模型。

嵌入阶段应用标准的PEE扩展规则——对峰值附近的误差进行倍增并加入水印位,对远离峰值的误差进行平移以避免提取时的混淆,从而保证了可逆性。

最后,通过逆球坐标变换将修改后的径向距离映射回笛卡尔坐标,完成整个嵌入流程,嵌入信息的流程图如图1所示。提取过程为嵌入过程的逆操作——首先通过相同密钥重建聚类,球坐标变换后获得解码信息,应用相同的预测模型,从修改后的预测误差中提取水印并恢复原始数据。

球坐标变换为预测模型提供了几何一致的特征空间,多尺度划分适配了不同区域的容量-失真权衡,PEE技术则从根本上保证了算法的可逆性。

2.2 自适应层次聚类

给定原始点云




图1 嵌入信息流程图

$$P = \{p_i \mid p_i = (x_i, y_i, z_i) \in \mathbb{R}^3\}_{i=1}^N \quad \#(1)$$

其中 N 表示点云中点的总数。原始点云质心定义为

$$\bar{p} = \frac{1}{N} \sum_{i=1}^N p_i \quad \#(2)$$

对点云模型进行质心归一化可得：

$$P' = \{p'_i \mid p'_i = p_i - \bar{p}\}_{i=1}^N \quad \#(3)$$

其中， p'_i 表示归一化后的第 i 个点。质心归一化确保了算法对平移攻击的天然鲁棒性——无论攻击者如何移动整个模型，使后续聚类 and 预测主要依赖点云内部相对结构。

尽管整体点云的几何结构较为复杂，但局部区域内的点通常具有相似的几何属性与空间密度分布。因此，本文采用了一种改进的层次聚类方法。与传统的 K-means 或谱聚类不同，本文基于空间密度和距离质心的径向距离来构建聚类。本文首先计算每个点到质心的径向距离 $d_i = \|p'_i\|_2$ ，然后按 d_i 递增顺序处理这些点。对于每个未被分

配的点 p_i ，本文以其为种子点，在半径 δ_{min} 范围内收集邻近点形成一个聚类，直到聚类大小达到预设的阈值 K (通常设为 16-20 个点)，仅当聚类规模不小于阈值 K 时，才视为有效嵌入单元，最终获得聚类 $C = \{C_j\}_{j=1}^M$ 。其中动态最小聚类距离 $\delta_{min} = 0.05 \times \max_{j=1}^N d_j$ ，它根据点云的整体尺度自适应调整，有助于保持聚类的几何一致性，从而避免固定阈值带来的局限性。

由于靠近表面的小型聚类通常包含丰富的几何细节，而内部的大型聚类往往几何较为平滑，前者需要精细的空间划分来利用局部结构，后者则可以用粗糙划分降低计算开销。本文根据聚类的几何特性分配不同的处理层级。

本文定义两个特征量来刻画聚类的几何性质。首先计算聚类 C_j 的局部质心：

$$\bar{c}_j = \frac{1}{|C_j|} \sum_{p_i \in C_j} p'_i \quad \#(4)$$

局部点密度 ρ_j 定义为单位体积内的点数，但实际计算中本文用平均最近邻距离的倒数来近似：



$$\rho_j = \frac{|C_j|}{\sum_{p_i \in C_j} \text{dist}(p_i, \text{NN}(p_i))} \#(5)$$

其中 $|C_j|$ 表示聚类 C_j 中点的数量， $\text{NN}(p_i)$ 是点 p_i 在聚类 C_j 内的最近邻点， $\text{dist}(\bullet, \bullet)$ 是欧氏距离。该式采用平均最近邻距离的倒数形式近似描述局部点密度：当聚类内点间距离较小时，分母较小， ρ_j 较大，说明该区域点分布更紧凑。

聚类尺度 s_j 用聚类内点到局部质心的平均距离表示：

$$s_j = \frac{1}{|C_j|} \sum_{p_i \in C_j} \|p_i - \bar{C}_j\|_2 \#(6)$$

基于这两个特征，本文将聚类分为三个处理层级。令 $\{\rho_j\}_{j=1}^M$ 和 $\{s_j\}_{j=1}^M$ 的均值和标准差分别为 μ_ρ, σ_ρ 和 μ_s, σ_s ，层级划分规则为：

$$\text{Level}(C_j) = \begin{cases} 1, \rho_j > \mu_\rho \text{ and } s_j < \mu_s + 0.5\sigma_s \\ 3, \rho_j < \mu_\rho \text{ and } s_j > \mu_s + 0.5\sigma_s \\ 2, \text{otherwise} \end{cases} \#(7)$$

Level 1表示高密度、小尺度区域，通常对应几何细节丰富的区域；Level 3表示低密度、大尺度区域，通常对应几何变化相对平缓或稀疏区域；Level 2表示介于二者之间的过渡区域。

2.3 多尺度球坐标变换

对每个聚类 C_j ，本文在其局部坐标系中进行球坐标变换。首先将聚类内所有点平移到以 $\bar{C}_j$ 为原点的局部坐标系：

$$p_i^{\text{local}} = p_i' - \bar{C}_j, \forall p_i \in C_j \#(8)$$

对每个局部坐标 $p_i^{\text{local}} = (x_i^{\text{local}}, y_i^{\text{local}}, z_i^{\text{local}})$ 应用球坐标变换^[26]：

$$\begin{cases} r_i = \sqrt{(x_i^{\text{local}})^2 + (y_i^{\text{local}})^2 + (z_i^{\text{local}})^2} \\ \theta_i = \arctan2(y_i^{\text{local}}, x_i^{\text{local}}) \\ \phi_i = \arccos\left(\frac{z_i^{\text{local}}}{r_i}\right) \end{cases} \#(9)$$

r_i 是径向距离， $\theta_i \in [0, 2\pi)$ 是方位角， $\phi_i \in [0, \pi)$

是极角。使用 $\arctan2$ 函数是为了避免象限歧义问题。

不同层级的聚类采用不同精度的球坐标网格。对于层级 $l \in \{1, 2, 3\}$ 本文定义三个离散化参数：

径向分层数 $L_r^{(l)}$ 将径向范围 $[0, r_{\max}^{(l)}]$ 分为多少层；方位角分区数 $L_\theta^{(l)}$ 将 $[0, 2\pi)$ 分为多少个扇区；极角分区数 $L_\phi^{(l)}$ 将 $[0, \pi)$ 分为多少个环带。三个层级的参数配置如下：

层级	L_r	L_θ	L_ϕ	嵌入强度 α
Level-1	16	16	16	0.001
Level-2	8	8	8	0.002
Level-3	4	4	4	0.005

嵌入强度 α 控制预测误差修改后映射回径向距离时的幅度比例，不同层级采用不同 α 值，在几何细节丰富区域（Level-1， $\alpha=0.001$ ）采用较小修改幅度保护几何保真度，在几何平滑区域（Level-3， $\alpha=0.005$ ）适当放大修改幅度以提升嵌入容量。

点 $p_i \in C_j$ 被映射到网格单元 Ω_{ijk} ，映射关系为：

$$\text{mapping}(p_i) = \left\lfloor \left[\frac{r_i}{r_{\max}/L_r} \right], \left\lfloor \left[\frac{\theta_i + \pi}{2\pi/L_\theta} \right], \left\lfloor \left[\frac{\phi_i}{\pi/L_\phi} \right] \right\rfloor \right\rfloor \#(10)$$

其中 $r_{\max}$ 是聚类 C_j 内的最大径向距离。

网格划分将球坐标空间划分为具有几何意义的离散单元，其功能体现在两个方面：一是为不同层级聚类提供分辨率参照——Level-1、Level-2、Level-3分别对应 16^3 、 8^3 、 4^3 的网格精度，网格分辨率直接决定了球坐标离散化的精细程度与对应嵌入强度 α 的选取；二是为式(8)的点-格映射提供索引结构，记录每个点所处的角度方向区域。实际预测仍基于笛卡尔空间 k 近邻（见2.4节），不要求每个网格单元均有点填充。

2.4 径向预测模型与误差直方图

预测误差扩展的前提是建立有效的预测模型。在球坐标系中，本文的基本假设是：同一聚类内的邻近点，其径向距离具有空间相关性。

对点 $p_i \in C_j$ ，本文需要根据笛卡尔空间的欧氏距离找到它的邻域点来建立预测。在聚类 C_j 内寻找点 p_i 的 k 个最近邻，记为：

$$N_k(p_i) = \{p_{i_1}, p_{i_2}, \dots, p_{i_k}\} \#(11)$$

参数 k 的选择依赖于聚类大小。对于 $|C_j| = 16$ 的小聚类，取 $k=5$ ；对于 $|C_j| \geq 24$ 的大聚类，取 $k=8$ 。当 k 值过小时，会降低预测的鲁棒性， k 值过大则可能引入远距离点的干扰，导致预测精度下降。受 Zhang 等人^[18]在 3D 网格预测误差扩展中的工作启发，本文方法采用高斯加权平均预测器：

$$\hat{r}_i = \frac{\sum_{p_j \in N_k(p_i)} W_{ij} \cdot r_j}{\sum_{p_j \in N_k(p_i)} W_{ij}} \#(12)$$

权重函数基于高斯核：

$$W_{ij} = \exp \left(- \frac{\|p_i - p_j\|^2}{2h^2} \right) \#(13)$$

其中 h 是带宽参数。该高斯核函数赋予较近邻域点更大的预测权重，权重随距离增大呈指数递减，从而有效利用点云的局部空间相关性。

带宽参数 h 的选取需要在预测精度与计算稳定性之间取得平衡。基于高斯核函数的性质， h 应与聚类内点间典型距离处于同一量级，才能有效区分近邻与远邻的权重贡献。聚类特征尺度 s_j 天然反映了聚类的空间伸展程度，因此将 h 设为 s_j 的固定比例具有几何上的合理性，可取得较好的预测效果：

$$h = 0.1 \times s_j \#(14)$$

因此，对于紧凑的小聚类， h 较小，预测依赖于非常近的邻居；对于疏松的大聚类， h 较大，预测器的感受更广。为避免极端紧凑聚类

($s_j \rightarrow 0$) 时 h 趋近零导致预测器退化为单点最近邻，引入下界约束： $h = \max(0.1 \times s_j, h_{\min})$ ，其中 $h_{\min} = 10^{-4}$ （与点云坐标归一化后量级匹配）。

接下来计算预测误差：

$$e_i = r_i - \hat{r}_i, \forall p_i \in C_j \#(15)$$

该误差反映预测模型的精度。如果局部几何非常规则（如平面或球面），预测误差会很小且集中；如果几何复杂（如尖锐边缘或高曲率区域），误差会较大且分散^[27]。

对聚类 C_j 中所有点的预测误差 e_i ，本文构建直方图 $H(e)$ 。直方图的横轴是离散化后的误差值，纵轴是对应的点数。

从直方图中提取两个关键参数：

(1) **峰值误差 e_p** ：出现频率最高的误差值，即 $H(e)$ 的峰值位置。该峰值点是本文嵌入的“锚点”。对于几何规则的聚类， e_p 通常接近 0；对于几何复杂的聚类， e_p 可能偏离 0，但仍是误差分布的中心。

(2) **阈值 T** ：定义可嵌入区间的半径。满足 $|e_i - e_p| \leq T$ 的点被视为可嵌入点。这个参数直接控制容量与失真的权衡：

$T=1$ ：只有峰值附近可嵌入，容量小但失真低；

$T=2$ ：可嵌入点增加，容量提升但失真也增加；

$T \geq 3$ ：容量继续增长，失真可能超过接受范围。

基于在 Bunny 模型上的实验，如图 2 所示， $T=2$ 在大多数情况下提供了较好的平衡。当然，对于特别敏感的应用（如医学模型），可以降低到 $T=1$ ；对于容量优先的场景，可以尝试 $T \geq 3$ 。

基于峰值 e_p 和阈值 T ，可判定各点是否满足嵌入条件。定义可嵌入标志：

$$\text{Embeddable}(p_i) = \begin{cases} 1, & |e_i - e_p| \leq T \\ 0, & \text{otherwise} \end{cases} \#(16)$$



统计聚类 C_j 中可嵌入点的数量:

$$N_{emb}^{(j)} = \sum_{p_i \in C_j} \text{Embeddable}(p_i) \# (17)$$

2.5 预测误差扩展嵌入

预测误差扩展(PEE)技术的基本思想源于 Tian^[13]提出的差分扩展(DE)。DE方法针对像素对 (x, y) , 计算均值 $m = \lfloor (x+y)/2 \rfloor$ 和差值 $d = x - y$, 通过扩展差值嵌入水印: $d = 2d + b$ (其中 $b \in \{0, 1\}$ 是水印位)。提取时, $b = d \bmod 2$ 且 $d = \lfloor d/2 \rfloor$, 可以完全恢复原始值。

后续研究将DE推广到预测误差场景^[28]。由于局部几何的连续性提供了良好的可预测性, 利用数据内在相关性替代固定成对关系构建预测模型, 将水印嵌入预测误差中, 从而显著提高嵌入效率并降低几何失真^[29]。

2.5.1 因果顺序处理机制

为确保嵌入与提取阶段预测环境的严格一致, 本文采用确定性因果顺序处理机制: 在每个聚类 C_j 内部, 所有点按其在原始点云文件中的全局索引升序排列, 而非按浮点径向距离 r_i 排序——当聚类内相邻两点原始 r 差异极小时, 嵌入后 r'_i 的微小变动可能改变相对顺序, 导致提取阶段无法重建与嵌入阶段一致的邻域; 固定索引仅依赖静态整数, 与浮点坐标值无关, 从根本上消除了排序翻转风险。嵌入点 p_i 时, 邻域内索引较

小的已处理点处于修改后坐标, 索引较大的未处理点处于原始坐标; 提取阶段采用相同处理顺序, 每成功恢复一个点的原始坐标, 立即用于后续点的预测, 保证了嵌入与提取中每个点预测环境的精确重建。聚类间按嵌入时的逆序进行处理。

2.5.2 PEE嵌入规则

对于聚类 C_j 中的点 p_i , 已知其预测误差 e_i , 峰值误差 e_p , 阈值 T , 层级对应嵌入强度 α , 本文要嵌入水印位 $b_i \in \{0, 1\}$ 。

(1) 若为可嵌入点, 应用误差扩展:

$$e'_i = 2(e_i - e_p) + b_i + e_p \# (18)$$

经过扩展, 原始误差 $e_i \in [e_p - T, e_p + T]$ 被映射到 $e'_i \in [2(e_p - T), 2(e_p + T) + 1]$ 。该映射是单向映射, 即对于每个 e_i 和 b_i 的组合, 都有唯一的 e'_i 。

(2) 若为不可嵌入点, 不能直接扩展, 否则会与可嵌入点的扩展结果重叠, 导致提取时无法区分。所以要对不可嵌入点的误差进行平移:

$$e'_i = \begin{cases} e_i + T + 1, & e_i - e_p > T \\ e_i - (T + 1), & e_i - e_p < -T \end{cases} \# (19)$$

基于式(17), 对聚类 C_j 中的所有点修改径向距离:

$$r'_i = \hat{r}_i + \alpha \bullet e'_i \# (20)$$

完成修改后, 将修改后的球坐标转换回笛卡




图2 嵌入容量与SNR随T的变化

尔坐标, 逆变换公式为:

$$\begin{cases} x_i^{\text{local}} = r_i' \sin \phi_i \cos \theta_i \\ y_i^{\text{local}} = r_i' \sin \phi_i \sin \theta_i \\ z_i^{\text{local}} = r_i' \cos \phi_i \end{cases} \#(21)$$

将聚类 C_j 恢复到全局坐标系:

$$p_i^{\text{embed}} = (x_i^{\text{local}}, y_i^{\text{local}}, z_i^{\text{local}}) + \bar{C}_j + \bar{p} \#(22)$$

最终生成含水印的点云为:

$$P^{\text{embed}} = \bigcup_{j=1}^M \{p_i^{\text{embed}} : i \in C_j\} \#(23)$$

2.6 提取与恢复过程

提取过程实际上是嵌入的逆操作, 提取流程如图3所示。给定含水印点云模型 P^{embed} 和辅助信息, 可以完整提取嵌入的水印信息并无损恢复原始点云。辅助信息包括: 原始质心坐标 $\bar{p}$ (192 bits)、聚类划分结果 $\{C_j\}_{j=1}^M$ (利用各聚类点数序列经 3bits/聚类定长编码, 共 $M \times 3\text{bits}$)、各聚类的峰值误差 e_p (差分变长编码, 均值约 $M \times 2.5\text{bits}$)、阈值 T (8bits)。各测试模型上的辅助信息精确开销统计见表1。本文所报告的嵌入容量 (EC) 定义为算法实际可嵌入的水印比特数, 辅助信息作为系统传输开销单独统计, 不计入 EC。

对于当前处理的聚类 C_j 内每个含水印点 p_i^{embed} , 执行以下三步:

(1) 预测阶段: 重建与嵌入时相同的球坐标系, 在点 p_i 的 k 近邻邻域内计算径向坐标预测值 $\hat{r}_i'$ 进而得到预测误差:

$$e_i' = \frac{(r_i' - \hat{r}_i')}{\alpha} \#(24)$$

由于 α 为浮点数且各坐标经过三角函数运算

存在浮点误差, 实际计算中对所得 e_i' 进行四舍五入取整, 以确保误差序列为整数, 保证无误提取。为验证四舍五入取整的可靠性, 需对浮点误差传播进行定量分析。含水印点的球坐标逆变换 (式(19)) 及后续质心还原 (式(20)) 中, 坐标计算依赖 $\sin$ 、 $\cos$ 等超越函数的浮点运算。

(2) 提取阶段: 根据峰值误差 e_p 和阈值 T 判断点的类型并提取水印。若 $e_i' \in [2(e_p - T), 2(e_p + T) + 1]$, 则为可嵌入点, 提取水印位并恢复误差:

$$\omega_i = (e_i' - e_p) \bmod 2 \#(25)$$

$$e_i = \left\lfloor \frac{e_i' - e_p}{2} \right\rfloor + e_p \#(26)$$

否则为不可嵌入点, 执行逆平移恢复:

$$e_i = \begin{cases} e_i' - (T + 1), e_i' - e_p > 2T + 1 \\ e_i' + (T + 1), e_i' - e_p < -2T \end{cases} \#(27)$$

(3) 恢复阶段: 利用恢复的原始误差计算径向坐标 $r_i = \hat{r}_i' + e_i$, 结合角度坐标 (θ_i, ϕ_i) 进行逆球坐标变换, 并恢复到全局坐标系得到 p_i^{recover} 。当所有聚类按逆序完成处理后, 即可获得完整的水印信息序列 $W = \{\omega_1, \omega_2, \dots, \omega_m\}$ 和完全恢复的原始点云 P^{recover} 。

综上, 本文嵌入与提取过程的完整流程分别如算法1和算法2所示。

算法1: 嵌入流程

算法2: 提取与恢复流程

3 实验结果及性能分析

实验主要从以下几个方面对算法性能进行评

表1 各模型辅助信息开销统计

辅助信息项	编码方式	Bunny	Horse	Armadillo
质心坐标 $\bar{p}$	$3 \times \text{float64}$	192	192	192
聚类划分 $\{C_j\}_{j=1}^M$	聚类大小序列, $M \times 3\text{bits}$	5442	7341	26181
峰值误差 e_p	差分+变长编码, 均值 $M \times 2.5\text{bits}$	4535	6117	21817
阈值 T	整数, 8bits	8	8	8
辅助信息合计(bits)		10177	13658	48198




图3 提取信息流程

算法1：自适应层次聚类与多尺度球坐标PEE嵌入

输入：原始点云 P ，水印 W ，参数 $(K, \delta, k, T, \{L_r^{(l)}, L_\theta^{(l)}, L_\phi^{(l)}\})$
 输出：含密点云 P^{embed} ，辅助信息

- 1: $P' \leftarrow$ 质心归一化 (P)；按 $\|P'\|_2$ 升序排列
- 2: 按 $\delta_{\min} = \delta \cdot \max \|P'_i\|$ 顺序生长聚类，得 $\{C_j\}_{j=1}^M$
- 3: 按式(4)-(7)计算 $(\bar{C}_j, \rho_j, s_j)$ 并分配 $\text{Level}(C_j)$
- 4: for $j = 1$ to M do
- 5: 读取该层级参数 $(L_r, L_\theta, L_\phi, \alpha)$ ；按式(9)对 C_j 内各点作局部球坐标变换
- 6: for 每个 $p_i \in C_j$ (按全局索引升序) do
- 7: $\hat{r}_i \leftarrow$ 式(12)(13)高斯加权预测； $e_i \leftarrow \text{round}((r_i - \hat{r}_i) \times 10^4)$
- 8: if $|e'_i - e_{p_j}| \leq T$ 且 W 未耗尽:
- 9: 取 $b \leftarrow W.\text{pop}()$ ；按式(18)扩展 $e_i \rightarrow e'_i$
- 10: else: 按式(19)平移 $e_i \rightarrow e'_i$ (若不在平移区则保持)
- 11: 按式(20)-(22)由 e'_i 还原 p_i^{embed} ，写回 P^{embed}
- 12: end for
- 13: end for
- 14: 辅助信息 $\leftarrow (\bar{P}, \{C_j\}_{j=1}^M, e_p, T)$ ；return P^{embed} , 辅助信息

算法2：含密点云的水印提取与原始点云恢复

输入：含密点云 P^{embed} ，辅助信息，参数同算法1
 输出：水印 W ，恢复点云 P^{recover}

- 1: 用 $\bar{P}$ 归一化 P^{embed} ；按辅助信息中 $\{s_j\}$ 确定性重建 $\{C_j\}_{j=1}^M$ ；按式(7)重分配 Level
- 2: $W \leftarrow \emptyset$
- 3: for $j = 1$ to M do
- 4: for 每个 $p_i^{\text{embed}} \in C_j$ (按全局索引升序) do
- 5: 按式(9)取球坐标，按式(12)(13)预测 $\hat{r}'_i$ ； $e'_i \leftarrow \text{round}((r'_i - \hat{r}'_i)/\alpha)$
- 6: if $e_{p_j} - 2T \leq e'_i \leq e_{p_j} + 2T + 1$
- 7: $\omega \leftarrow (e'_i - e_{p_j}) \bmod 2$ ； $W.\text{append}(\omega)$ ；按式(26)恢复 e_i
- 8: else: 按式(27)逆平移恢复 e_i
- 9: 按式(21)(22)用 e_i 还原 p_i^{recover} ；立即用 p_i^{recover} 替换 p_i^{embed} 供后续预测使用
- 10: end for
- 11: end for
- 12: return W, P^{recover}

估：容量与失真性能分析、与现有算法的性能比较、可逆性验证以及视觉质量评价。实验环境为 Intel Core Ultra 7 155H 处理器，32GB 内存，Python 3.11，Meshlab 2023。

3.1 实验数据集与评价指标

实验选用了斯坦福三维扫描库中 Bunny、Ar-

madillo 和 Horse 三个具有代表性的点云模型作为测试数据集。上述模型在几何复杂度、点云密度等方面各具代表性，可全面地评估算法在不同几何特性下的性能。

为了定量评价算法性能，采用了以下评价指标：

(1) 嵌入容量(EC)与嵌入密度(ED)：

$$ED = \frac{EC}{N} \#(28)$$

其中 N 为点云模型总顶点数。实验所涉及的嵌入容量已扣除辅助信息所占比特数，为净可用容量。

(2) 误码率 (BER): 用于衡量水印提取的准确性，是验证算法严格可逆性的重要指标。

$$BER = \frac{N_{err}}{N_{total}} \#(29)$$

(3) 信噪比 (SNR): 度量嵌入水印后点云的几何保真度。

$$SNR = 10 \log \frac{\sum_{i=1}^N \|p_i - \bar{p}\|^2}{\sum_{i=1}^N \|p_i' - p_i\|^2} \#(30)$$

其中 p_i 为原始顶点坐标， p_i' 为含水印顶点坐标， $\bar{p}$ 为原始点云质心。

(4) 均方根误差 (RMSE): 从全局角度度量点云整体几何偏差。数值越小，表明几何保真度越高。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N \|p_i' - p_i\|^2} \#(31)$$

3.2 消融实验

为系统评估本文各核心设计对整体性能的贡献，在 Bunny 模型 ($N=35,947, T=2$) 上开展六组消融实验，分别验证球坐标变换、自适应分层策略、预测器设计、邻域大小 k 、聚类半径系数 δ 以及 PEE 阈值 T 的有效性。所有实验固定随机种子，水印序列相同，仅逐一改变目标变量，其余参数保持默认配置 ($K_{min}=16, K_{max}=20, \delta=0.05, k=8, T=2$)。

3.2.1 球坐标变换有效性验证

为验证球坐标变换在点云可逆信息隐藏中的必要性，设置对照组 (无球坐标): 保持聚类策略、分层策略和 PEE 框架完全一致，仅将球坐标变换 (Sph-PEE) 替换为笛卡尔坐标 (Cart-PEE) 直接预测，即对局部坐标系下各点的 x 、 y 、 z 三个分量分别构建高斯加权预测器并执行 PEE 嵌

入。实验结果如表 2 所示。

表 2 球坐标变换消融 (Bunny, $T=2$)

配置	EC(bits)	ED(bpv)	SNR(dB)
Cart-PEE	18026	0.501	63.0
Sph-PEE	27733	0.771	68.21

由表 2 可知，引入球坐标变换后 EC 提升 53.8%，SNR 提升 5.21dB。这一结果表明，点云局部结构中径向距离的空间相关性显著强于笛卡尔坐标分量，球坐标变换能够有效集中预测误差的直方图分布，使峰值更突出、可嵌入点更多，从而同时提升嵌入容量与几何保真度。

3.2.2 自适应分层策略有效性验证

为了验证本文提出的自适应层次聚类机制的有效性，本文设计了对比实验如表 3 所示，将算法在不同参数配置下的性能表现进行比较。具体而言，测试了三种配置方案：

方案 1 (无分层, Uni-SCT): 对所有聚类使用统一的球坐标网格参数 ($L_r=L_\theta=L_\phi=8$) 和嵌入强度 ($\alpha=0.002$);

方案 2 (两层分层, Bi-SCT): 将聚类分为高密度和低密度两类, 分别采用不同参数;

方案 3 (本文方法, MS-SCT): 采用本文提出的三层自适应分层策略。

从表 3 可以看出，三种方案的 BER 均为 0，验证了算法在不同分层配置下的严格可逆性。

在嵌入容量方面，MS-SCT 在三个模型上均取得最高的嵌入容量。在几何保真度方面，MS-SCT 的 SNR 和 RMSE 同样优于另外两种方案。值得注意的是，Bi-SCT 的嵌入容量在所有模型上均低于 Uni-SCT，这是因为缺乏 Level-2 过渡层，中间型聚类被强制归入 Level-3 粗粒度网格，导致误差直方图峰值不集中，可嵌入点反而减少。MS-SCT 通过 Level-2 缓冲层有效弥补了这一不足，在容量与几何保真度的综合权衡上表现最优。



表3 自适应分层策略消融实验结果(T=2)

模型	顶点数	方案	EC (bits)	ED (bits/v)	SNR (dB)	RMSE($\times 10^{-4}$)	BER
Bunny	35947	Uni-SCT	28827	0.802	65.25	3.079	0
		Bi-SCT	19893	0.553	67.44	2.825	0
		MS-SCT	27733	0.771	68.21	2.573	0
Horse	48485	Uni-SCT	30292	0.625	62.16	2.213	0
		Bi-SCT	19423	0.401	65.01	1.589	0
		MS-SCT	31842	0.657	69.92	0.902	0
Armadillo	172974	Uni-SCT	92367	0.534	69.66	1.636	0
		Bi-SCT	79279	0.458	70.13	1.560	0
		MS-SCT	120560	0.697	71.35	1.349	0

3.2.3 预测器类型对比

在保持其他参数不变的条件下, 对比三种预测器的性能: □ 聚类均值预测 (Cluster-Mean Predictor, CM-Pred): 以聚类内所有点径向距离的均值作为预测值; □ KNN 均值预测 (K-Nearest-Neighbor Mean Predictor, KNN-Pred): 取 k 个因果近邻的径向距离均值; □ 高斯加权预测 (Gaussian-Weighted Predictor, GW-Pred, 本文方法): 对 k 个因果近邻按空间距离施加高斯权重。实验结果如表4所示。

表4 预测器类型消融实验结果(Bunny, T=2)


预测器	EC(bits)	ED(bpv)	SNR(dB)	BER
CM-Pred	19967	0.555	64.4	0
KNN-Pred	25791	0.717	65.5	0
GW-Pred	27733	0.771	68.21	0

由表4可见, 高斯加权预测器相较聚类均值预测 EC 提升 39.9%、SNR 提升约 3.9dB; 相较 KNN 均值预测 EC 提升 10.8%、SNR 提升约 2.7dB。这一结果验证了近邻加权策略的有效性: 对空间距离较近的点赋予更高权重, 可使预测值更贴近当前点的真实径向距离, 有效压缩预测误差直方图, 提高可嵌入点比例。

3.2.4 邻域大小 k 的影响

固定预测器类型为高斯加权, 改变因果近邻数量 k , 测试 $k=3$ 、5、8、12 时的算法性能, 结果如图4所示。

由图4可知, 随 k 从3增至8, EC 和 SNR 均呈上升趋势, 这是因为更多的近邻点提供了更充分的局部几何信息, 预测精度随之提高。当 k 从8增至12时, 性能提升趋于平缓甚至略有下降, 原

图4 不同邻域大小 k 对结果的影响

因在于更远的近邻点引入了几何噪声，削弱了预测精度的提升效果。考虑计算复杂度与性能的综合权衡，本文选取 $k=8$ 作为默认配置。

3.2.5 聚类半径系数 δ 的影响

聚类半径系数 δ 控制自适应层次聚类中的动态搜索半径($\delta_{min}=\delta \times \max(d_i)$)，直接影响聚类数量 M 和聚类内点的几何均匀性。固定其他参数，测试 $\delta=0.03$ 、 0.05 、 0.07 、 0.10 时的算法性能，结果如表5所示。

表5 聚类半径系数 δ 的影响

系数 δ	聚类数 M	ED(bpv)	SNR(dB)	BER
$\delta=0.03$	2267	0.663	65.9	0
$\delta=0.05$	1814	0.771	68.21	0
$\delta=0.07$	1541	0.725	67.0	0
$\delta=0.10$	1233	0.671	65.3	0

由表5可见， δ 过小时聚类半径收窄，聚类数 M 增多但每个聚类内点数偏少，误差直方图的统计规律性减弱，峰值不突出，可嵌入点减少，EC降低； δ 过大时单个聚类内几何差异增大，局部预测精度下降，SNR降低。 $\delta=0.05$ 在聚类粒度与局部几何一致性之间取得最优平衡，综合性能最佳。

3.2.6 阈值 T 对性能的影响

阈值参数 T 直接控制可嵌入点的范围，是容量与几何保真度之间的核心权衡参数。图5、6给出了本文算法在Bunny模型上 T 从1增大至4时的EC和SNR变化曲线。随 T 从1增至3，嵌入容量

持续增长，增幅达11.6%，SNR从69.47 dB下降至60.54 dB。当 $T=4$ 时，嵌入容量反而略低于 $T=3$ ，原因在于聚类误差直方图峰值区间较窄， $T=3$ 时已接近饱和，继续扩大 T 导致平移点增多而净可嵌入点数不再增加。

综合来看， $T=2$ 是容量与保真度的较优平衡点：EC达到27,733bits，SNR保持在68.21dB。对于医学影像等高保真应用场景，建议采用 $T=1$ 以优先保证几何精度；对于容量需求较高的场景，可选用 $T=3$ 。当 $T \geq 4$ 时，虽算法仍满足可逆性，但实验表明嵌入容量不再随 T 增大而增长，因此实际应用中 T 取值不建议超过3。

3.3 可逆性分析

图7对原始点云、水印点云和提取点云进行了对比分析。含密模型(b、e、h)与原始模型(a、d、g)在整体轮廓和几何结构上保持高度一致，主观视觉上无明显可感知差异，表明水印嵌入对模型视觉质量的影响极小。在可逆性方面，恢复模型(c、f、i)与对应原始模型在视觉上完全一致，三个模型的BER均为0，验证了算法对秘密信息的无误码提取能力。

3.4 与现有方法的比较

为全面评价本文方法在同类研究中的竞争力，选取以下三种代表性方法进行比较：Zhang等人^[19]基于差值直方图的多级算法、申浩^[24]基于聚类的离散余弦域的算法以及Zhang等人^[25]基于双向直方图修改的三维网格可逆信息隐藏方法。




图5 嵌入容量随 T 变化




图6 信噪比随T变化




图7 原始点云、嵌入信息后点云以及恢复点云的视觉效果

各方法的特征对比见表6。

其中Zhang等^[25]面向具有显式拓扑结构的三维网格模型，与本文在载体结构上存在差异；但该方法同样属于明文域空间域PEE框架，使用相同的SNR定义，数据引自原文，具有一定的横向参考价值。三种方法的BER均为0，恢复率均为100%，验证了严格可逆性。表7给出了各方法在

表6 现有方法特征对比

方法	载体类型	处理域	预测方式	参数策略	可逆性
Zhang等 ^[19]	点云	明文域	差值直方图	全局统一	BER=0
申浩 ^[24]	点云	明文域	DCT变换域	全局统一	BER=0
Zhang等 ^[25]	网格	明文域	双向直方图修改	自适应动态	BER=0
本文	点云	明文域	高斯加权径向预测	自适应三层	BER=0

三个测试模型上的定量性能汇总。

由表7可以看出，各方法在嵌入密度（ED）与信噪比（SNR）两个指标上呈现出显著差异，需结合容量-失真权衡关系进行综合分析。

在嵌入密度方面，本文方法在三个测试模型上的ED均值约为0.708 bpv，嵌入密度优势显著。

在信噪比方面，申浩^[24]方法的SNR约为83dB，高于本文方法约13~15dB；Zhang^[19]方法SNR约为57~60 dB，低于本文方法约8~12 dB。需要指出的是，SNR指标与嵌入密度之间存在固有的容量-失真权衡关系：在可逆信息隐藏框架下，嵌入点数量越多、嵌入区间越宽，对载体几何坐标引入的累积扰动越大，SNR必然随之降低。申浩^[24]方法的高SNR，本质上是以极低的嵌

表7 各方法嵌入性能定量对比

方法	Bunny			Horse			Armadillo		
	ED(bpv)	SNR(dB)	BER	ED(bpv)	SNR(dB)	BER	ED(bpv)	SNR(dB)	BER
Zhang等 ^[19]	0.31	59.8	0	0.26	57.5	0	0.24	55.6	0
申浩 ^[24]	0.16	83.65	0	0.12	83.01	0	0.10	83.57	0
Zhang等 ^[25]	0.30	59.67	0	0.45	58.43	0	0.21	76.67	0
本文	0.771	68.21	0	0.657	69.92	0	0.697	71.35	0

入密度换取的,该方法在 Bunny 模型上的实际嵌入容量仅约 5749bits,远低于本文方法的 27733bits。在此嵌入密度条件下,几何扰动极小,高 SNR 是预期结果,而非方法在几何保真度设计上的优势。

综合嵌入密度与信噪比两个维度评价,本文方法表现最优:在嵌入密度约为申浩^[24]方法 5 倍以上的条件下,SNR 仍能稳定保持在 68dB 以上($T=2$),实现了高容量与高几何保真度的有效兼顾;相较 Zhang^[19],本文在嵌入密度提升约 2.6 倍的同时 SNR 也提升约 10dB,综合性能提升明显。对于 Zhang^[25]网格方法,由于载体结构存在差异,本文点云方法在 ED 和 SNR 两个维度上均优于该方法,进一步说明了本文自适应分层框架与高斯加权预测器设计的有效性。三种对比方法的 BER 均为 0,恢复率均为 100%,本文方法同样满足严格可逆性要求。

4 结束语

本文提出了一种融合多尺度球坐标变换与自适应层次聚类的三维点云可逆信息隐藏方法,依据聚类局部点密度与尺度特征将点云自适应划分为三个处理层级,并为各层级分配相应精度的球坐标离散化网格。在此基础上,于各聚类局部球坐标系下构建高斯加权径向距离预测器,结合预测误差扩展(PEE)技术完成水印的可逆嵌入与提取。实验结果表明,本文方法在 Bunny、Horse 和 Armadillo 三个测试模型上均取得了较高的嵌入容量,SNR 保持在 65dB 以上,嵌入密度约 0.65~0.77bpv,误码率为零(恢复率 100%),能够在保持严格可逆性与较低几何失真的前提下,显著提升嵌入容量,具有较高的实际应用价值。消融实验从球坐标变换、自适应分层、预测器类型、邻域大小 k 等六个维度系统验证了各模块设计的合理性, $k=8$ 与 $\delta=0.05$ 为当前测试规模下的最优参数配置。

目前算法对点云的均匀采样分布有一定依赖,对于采样极不均匀的点云,聚类质量可能下降;此外,加密域下的可逆信息隐藏尚未涉及。未来工作将重点探索算法在加密点云场景中的扩展,以及提升其对复杂采样条件的鲁棒性。

参考文献:

- [1] 张启龙. 三维模型可逆信息隐藏技术研究[D]. 辽宁: 东北大学, 2020.
ZHANG Q L. Research on reversible information hiding technology for 3D models[D]. Liaoning: Northeastern University, 2020.
- [2] GE J C, QIU Y Q, CHEN Z S, et al. Separable and high-capacity reversible data hiding for encrypted 3D mesh models based on dual multi-MSB predictions[J]. Signal Processing, 2025, 237: 110079.
- [3] 任帅, 龚浩, 郑苏雅. 基于复合算子特征增强的三维点云隐写分析算法[J]. 信息与电子工程前沿(英文版), 2025, 26(1): 62-79.
REN S, GONG H, ZHENG S Y. Algorithm for 3D point cloud steganalysis based on composite operator feature enhancement [J]. Frontiers of Information Technology & Electronic Engineering, 2025, 26(1): 62-79.
- [4] TSAI Y Y, JAO W T, LIN A, et al. Advanced octree-based reversible data hiding in encrypted point clouds[J]. Journal of Information Security and Applications, 2025, 89: 104006.
- [5] ZHONG C, DU J, LIN W, et al. Research on reversible information hiding technology for medical images based on histogram regionalization[C]// Proceedings of the 2025 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Wuhan: IEEE, 2025: 7364-7371.
- [6] Vidushi, Tripathi J K, Gupta P K, et al. Pioneering security in healthcare: reversible data hiding for ECG signals and patient information[C]// Proceedings of the 2026 IEEE 4th International Conference on Power Electronics & IoT Applications in Renewable Energy and Its Control (PARC). Piscataway: IEEE, 2026: 45-50.
- [7] YAMNI M, DAOUI A, PLAWIAK P, et al. A novel 3D reversible data hiding scheme based on integer-reversible Krawtchouk transform for IoMT[J]. Sensors, 2023, 23(18): 7914.
- [8] 欧博, 殷赵霞, 项世军. 明文图像可逆信息隐藏综述[J]. 中国图象图形学报, 2022, 27(1): 111-124.
OU Bo, YIN Zhaoxia, XIANG Shijun. A survey of reversible data hiding for plaintext images[J]. Journal of Image and



- Graphics, 2022, 27(1): 111-124.
- [9] Li Y H, Xia R B, Zhao J B, et al. Aggregate point cloud geometric features for processing[J]. *Computer Modeling in Engineering & Sciences*, 2023, 136(1): 555-571.
- [10] Ertugrul G, Tam G K L. Survey: 3D watermarking techniques [J]. *Journal of Visual Communication and Image Representation*, 2025, 112: 104572.
- [11] OHBUCHI R, MASUDA H, AONO M. Watermarking three-dimensional polygonal models through geometric and topological modifications[J]. *IEEE Journal on Selected Areas in Communications*, 1998, 16(4): 551-560.
- [12] KALKER T, WILLEMS F M J. Capacity bounds and constructions for reversible data-hiding[C]// *Proceedings of SPIE Security and Watermarking of Multimedia Contents V*. 2003. DOI: 10.1117/12.473164.
- [13] TIAN J. Reversible data embedding using a difference expansion[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2003, 13(8): 890-896.
- [14] WU H T, CHEUNG Y M. A reversible data hiding approach to mesh authentication[C]// *Proceedings of the 2005 IEEE/WIC/ACM International Conference on Web Intelligence*. Compiegne: IEEE, 2005: 774-777.
- [15] LUO H, LU Z M, PAN J S. A reversible data hiding scheme for 3D point cloud model[C]// *Proceedings of the 2006 IEEE International Symposium on Signal Processing and Information Technology*. Vancouver: IEEE, 2006: 863-867.
- [16] ZHU A, ZHANG C, YANG X, et al. Reversible watermarking of 3D mesh models using prediction-error expansion[C]// *Proceedings of the 3rd International Congress on Image and Signal Processing (CISP)*. Yantai: IEEE, 2010: 1171-1175.
- [17] JIANG R, ZHOU H, ZHANG W, et al. Reversible data hiding in encrypted three-dimensional mesh models[J]. *IEEE Transactions on Multimedia*, 2018, 20(1): 55-67.
- [18] ZHANG Q, SONG X, WEN T, et al. Reversibility improved data hiding in 3D mesh models using prediction-error expansion and sorting[J]. *Measurement*, 2019, 135: 738-746.
- [19] ZHANG Q, WEN T, SONG X. Multilevel Reversible Data Hiding Based on Difference Histogram for 3D Point Cloud Models [J]. *IEEE*, 2019.
- [20] TANG Y, CHENG L, LYU W, et al. High Capacity Reversible Data Hiding for Encrypted 3D Mesh Models Based on Topology[M]// PIVA A, TANG Z, ZHAO X, et al. *Digital Forensics and Watermarking*. Switzerland: Springer, 2023: 205-218.
- [21] 欧跃发, 邓维, 任帅, 等. 基于预测误差扩展的加密点云模型可逆信息隐藏算法[J]. *重庆邮电大学学报(自然科学版)*, 2024, 36(6): 1128-1139.
- OU Yuefa, DENG Wei, REN Shuai, et al. Reversible information hiding algorithm for encrypted point cloud models based on prediction-error expansion[J]. *Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition)*, 2024, 36(6): 1128-1139.
- [22] 周志立, 丁淳, 李进, 等. 生成式隐写研究[J]. *计算机学报*, 2023, 46(9): 1855-1887. DOI: 10.11897/SP.J.1016.2023.01855.
- ZHOU Z L, DING C, LI J, et al. Research on generative steganography[J]. *Chinese Journal of Computers*, 2023, 46(9): 1855-1887. DOI: 10.11897/SP.J.1016.2023.01855.
- [23] 周志立, 王美民, 杨高波, 等. 基于轮廓自动生成的构造式图像隐写方法[J]. *通信学报*, 2021, 42(9): 144-154. DOI: 10.11959/j.issn.1000-436x.2021174.
- ZHOU Z L, WANG M M, YANG G B, et al. Generative steganography method based on auto-generation of contours[J]. *Journal on Communications*, 2021, 42(9): 144-154.
- [24] 申浩. 基于聚类的离散余弦域三维点云水印算法[D]. 深圳: 深圳大学, 2019.
- SHEN Hao. 3D point cloud watermarking algorithm in discrete cosine domain based on clustering[D]. Shenzhen: Shenzhen University, 2019.
- [25] ZHANG Q, SONG X. Reversible data hiding based on bidirectional histogram modification for 3D mesh models[C]// *Proceedings of the 2023 8th International Conference on Image, Vision and Computing (ICIVC)*. Dalian: IEEE, 2023: 543-547.
- [26] LI W, XIE S, MIN W, et al. Spherical coordinate transformation-embedded deep network for primitive instance segmentation of point clouds[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2022, 113: 102983.
- [27] 周杨全, 冯柳平, 迟灵艺, 等. 基于预测误差直方图的密文域可逆信息隐藏算法[J]. *北京印刷学院学报*, 2024, 32(6): 1-8.
- Zhou Y Q, Feng L P, Chi L Y, et al. Reversible information hiding algorithm in ciphertext domain based on prediction error and histogram translation[J]. *Journal of Beijing Institute of Graphic Communication*, 2024, 32(6): 1-8.
- [28] Luo C E, Wu S J, Yan W, et al. An improved reversible data hiding algorithm based on prediction error expansion[C]// *Proceedings of the 2025 10th International Conference on Cyber Security and Information Engineering (ICCSIE)*. Piscataway: IEEE, 2025: 500-506.
- [29] Jindal A, Mahajan S, Rakheja P. A Comprehensive Review of Pixel Value Ordering in Reversible Data Hiding: Methodologies & Applications[C]// *Proceedings of 2025 2nd International Conference on Intelligent Systems for Cybersecurity (ISCS)*. Piscataway: IEEE Press, 2025: 1-6.

- [30] 秦宝堃, 郑洪英, 肖迪. 基于预测误差双重编码的大容量密文域可逆信息隐藏算法[J]. 计算机应用研究, 2022, 39(1): 245-248.

Qin B K, Zheng H Y, Xiao D. High-capacity reversible data hiding in encrypted images based on prediction error dual coding[J]. Application Research of Computers, 2022, 39(1): 245-248.

[作者简介]



任帅 (1982—), 男, 博士, 长安大学信息工程学院教授, 主要研究方向为信息隐藏技术。

丛天煜 (2001—), 女, 长安大学信息工程学院硕士研究生, 主要研究方向为信息隐藏技术。;

