

面向点云无损压缩的快速细节层次优化方法

魏磊¹, 万帅^{1,2}, 王哲诚¹, 丁晓斌¹, 张伟³

(1. 西北工业大学电子信息学院, 710129, 西安; 2. 皇家墨尔本理工大学工程学院, VIC3001, 澳大利亚墨尔本;
3. 西安电子科技大学通信工程学院, 710071, 西安)

摘要: 为解决点云压缩中基于距离的细节层次(LoD)划分未优化的问题,提出了基于预测残差的LoD优化模型以及相应的快速LoD划分方法。推导了LoD预测残差与码率的关系,建立了LoD预测残差和距离的数学模型;以预测残差的最小化为目标,通过对点云进行预编码或在线计算获取模型参数,根据所提模型获得编码性能最优的LoD层数;为了降低实现复杂度,分析模型各参数对编码性能的影响,得出细节层中的点数随着LoD层数的增加而呈现指数级减少,导致这部分点对编码性能的影响急剧降低这一结论;根据均匀采样及平滑点云的特性,对模型参数进行简化,通过求解细节层中的点数占点云中全部点数的比例得到编码性能最优的LoD层数;在此基础上,提出了一种基于阈值的LoD划分快速方法,提高了模型的实用性。实验结果表明:所提方法在不增加码率的情况下,有效降低了编解码复杂度,平均节省了约4%的编码时间和约6%的解码时间。

关键词: 点云压缩;细节层次;预测残差;无损压缩;编码性能

中图分类号: TP391.4 **文献标志码:** A

DOI: 10.7652/xjtuxb202109010 **文章编号:** 0253-987X(2021)09-0088-09



OSID 码

Optimization Method for Level of Detail of Lossless Point Cloud Compression

WEI Lei¹, WAN Shuai^{1,2}, WANG Zhecheng¹, DING Xiaobin¹, ZHANG Wei³

(1. School of Electronics and Information, Northwestern Polytechnical University, Xi'an 710129, China;

2. School of Engineering, Royal Melbourne Institute of Technology, Melbourne VIC3001, Australia;

3. School of Telecommunications Engineering, Xidian University, Xi'an 710071, China)

Abstract: To improve the distance-based level of detail (LoD) construction in point cloud compression, a prediction residual-based LoD optimization model and a fast LoD generation method are proposed. The relationship between LoD prediction residuals and coding bitrate is firstly deduced. A model of LoD prediction residual and distance is further constructed, and the model parameters can be obtained by pre-coding or online calculation of the point cloud. Relying on this model, the optimal number of LoD layers can be obtained by minimizing the prediction residuals. To lower the complexity of the proposed method, the influences of the model parameters on the coding performance are analyzed. It is found that the number of points in detail layer decreases exponentially with the increasing LoD layers, which makes the impact on coding performance weaken sharply. Following this analysis, the model parameter determination is simplified according to uniform sampling and smooth distribution features of point clouds. The optimal number of LoD layers can be obtained by the proportion of the points in the detail layer to

the total points in the point cloud, so as to achieve the optimal coding performance. Furthermore, a fast LoD generation method based on threshold control is proposed to heighten the model practicability. Experimental results show that the proposed method enables to shorten encoding time by 4% and decoding time by 6% without any performance loss.

Keywords: point cloud compression; level of detail; prediction residuals; lossless compression; coding performance

近年来,随着 3D 传感和捕获技术的飞速发展,点云在虚拟现实、自动驾驶、数字城市和 3D 打印等领域得到了广泛的应用^[1-2]。作为一种新型空间数据类型,点云非常适合用来表示 3D 模型和空间,并且可以非常高效地用于计算和处理,已经成为了一种用于显示和存储三维信息的流行方法。点云是由三维空间中一系列非均匀采样的点组成的,每个点除了空间坐标外,还附着有若干属性信息,比如颜色、反射率和法线等,因此点云具有数据量巨大的特点,为其处理和传输带来挑战。高效的点云压缩是点云相关应用实用化的关键,通常将几何信息和属性信息分别进行压缩。

针对点云的属性信息的压缩,目前已经提出了多种有效的方法。文献[3]提出了一种用于编码点云中属性块的图形变换方法,要求将点云捕捉或排列到规则网格上;文献[4]将点云采样到统一的网格中,然后将网格划分为块以便直接应用图变换,进而进行三维块内预测;文献[5]提出了一种基于图变换的属性压缩方法,利用 k 近邻扩展生成更有效的图;文献[6]提出了一种基于层次变换和算术编码的点云颜色信息的压缩方法,该变换是一种分层子带变换,类似于 Haar 小波的自适应变化,已被收于动态图像专家组(MPEG)的基于几何的点云压缩(G-PCC)标准^[7]中。另一种重要的基于层次变换的方法为细节层次(LoD),由 Clark 于 1976 年首次提出^[8],已广泛用于计算机图形的实时 3D 技术中。目前,关于 LoD 的工作大多集中在生成方案上:文献[9]提出了一种新的基于二叉树的 LoD 生成方案;文献[10]提出了一种基于聚类的 LoD 生成方法;文献[11]则是针对图形学中的几何模型的简化工作;文献[12-13]提出了一种基于距离的 LoD 生成方法。G-PCC 提出了利用 LoD 对点云属性信息进行压缩的方法,同时为可伸缩编码提供了可能性^[7]。文献[14]将 LoD 与图变换结合,利用图变换对预测残差进行变换编码,进一步去除冗余。现阶段 LoD 在点云压缩中的主要作用是属性信息的预测编码。

这些文献中的工作并没有解决如何实现最优 LoD 划分的问题。对于基于距离的 LoD,影响编码性能的因素主要有 3 个:初始采样距离、各层之间的采样距离比和 LoD 层数^[15]。其中,以 LoD 层数最为关键,除了影响压缩后码率外,还直接关系到编解码时间。本文在理论分析的基础上,建立了基于 LoD 的预测残差和距离的数学模型,通过该模型对编码性能进行优化;面向点云无损压缩,基于该模型提出了一种通过设置终止阈值优化编码性能的快速方法。

1 点云压缩中的 LoD

1.1 LoD 及预测

LoD 结构是将点云划分为一系列的增强层 $(A_i)_{i=1,2,\dots,N-1}$ 和顶端的细节层 L_N ,如图 1 所示。定义 L_i 为第 i 个细节层,对 L_i 层进行下采样可以得到更为稀疏的 L_{i+1} 层,剩余的点则组成 i 个增强层,即 A_i 。




图 1 LoD 金字塔结构
Fig. 1 LoD pyramid structure

类似于视频预测编码,点云通过预测来去除点之间的相关性,利用特定的预测方式来表征点之间的相互关系。预测编码是指利用已编码的一个或几个样本值,根据某种模型或方法,对当前的样本值进行预测,并将样本真实值和预测值之间的差值进行编码,从而有效提高压缩性能^[16]。

在点云压缩中,常用的预测方法是从已编码点中找到若干个距离当前点最近的点作为参考点,将

这些参考点的属性重建值进行基于距离的加权平均作为当前点的属性预测值。

与一般的方法相比,基于 LoD 的预测方法在每个 LoD 层都具有不同的参考点选择范围,可以分为以下两类:①在对图 1 中细节层 L_N 进行编码时,其参考点只能在本层中已编码的点中选择,记为细节层的预测;②对于增强层 $(A_i)_{i=1,2,\dots,N-1}$,不仅可以选 择本层中已编码的点,还可以选择此前已编码过的细节层中的点,记为增强层的预测。对于增强层的预测,划分 LoD 所带来的变化较大。以划分两层来进行说明,如图 2 所示。对于 P_3 点的参考点选择:在不划分 LoD 时,预测编码按照原始编码顺序进行,因此参考点都分布在受限 于该顺序的方向上,如图 2a 所示;在划分 LoD 后, P_3 位于增强层 A_1 中,其参考点除本层内已编码的点外,还包含已编码的 L_2 中的点,位于空间上的多个方向,如图 2b 所示。划分 LoD 的预测通常使得预测的效果更好,从而提升了编码性能。




图 2 未划分 LoD 及划分两层 LoD 的参考点范围对比

Fig. 2 Comparison of the reference points range between the unbuilt LoD and the 2-layer LoD

1.2 预测残差与码率的关系

为了优化 LoD 的生成,需要获取每一层的码率,而在当前基于 LoD 的点云压缩方案中,并未对每一层 LoD 进行独立编码,很难获得其相应的码率,因此本文使用预测残差来代替码率进行建模。

为了研究预测残差的分布情况以及与码率的关系,从 G-PCC 的静态对象与场景数据库 Cat1-A^[17] 中选择了 basketball_player_vox11 和 dancer_vox11 点云作为分析数据集,如图 3 所示。



图 3 分析数据集

Fig. 3 The analysis dataset

对分析数据集进行基于 LoD 的无损压缩,统计点云中每个点的预测残差情况,并将预测残差的分布拟合为拉普拉斯分布,拟合精度由相关系数的平方 (R^2) 来度量,结果如图 4 所示。图中, $p(e)$ 为概率, e 为预测残差。




图 4 预测残差的分布

Fig. 4 Distribution of prediction residuals

从图 4 可以看出,预测残差服从拉普拉斯分布 $p(e)=\frac{1}{2\lambda}\exp\left(-\frac{|e|}{\lambda}\right)$,其中 λ 是拉普拉斯分布的参数。预测残差的熵为

$$H(e) = \frac{M_e}{\lambda} + \ln(2\lambda) \tag{1}$$

式中 M_e 为预测残差 e 的平均绝对误差。

M_e 和熵是单调递增的关系。因此,将熵或码率的最小化问题转化为 M_e 的最小化问题是合理的。

对分析数据集分别设置不同的参数进行无损压缩,得到码率和预测残差的关系,如图 5 所示。可以看出,码率随着 M_e 的增大而增大。所以,本文利用 M_e 的最小化来等效码率的最小化是可行的,与理论推导一致。




图 5 预测残差与码率的关系

Fig. 5 Relationship between prediction residual and bitrate

在 LoD 划分中,每一个细节层相当于对原始点云不同程度的均匀采样,其预测残差也服从拉普拉斯分布。以点云 basketball_player_vox11 为例,细




图 6 basketball_player_vox11 细节层 L_3 的预测残差分布
Fig. 6 Distribution of prediction residuals in the detail layer L_3 of basketball_player_vox11

节层 L_3 的预测残差分布及拟合结果如图 6 所示。

对于增强层中的预测残差的分布,以点云 basketball_player_vox11 为例。增强层 A_6 和 A_8 的预测残差分布及拟合结果如图 7 所示。可以看出,对应的增强层的预测残差也服从拉普拉斯分布。因此,本文使用各 LoD 层的预测残差来代替码率进行建模。




图 7 basketball_player_vox11 增强层的预测残差分布
Fig. 7 Distribution of the prediction residuals in the refinement layers of basketball_player_vox11

2 预测残差模型及性能优化

2.1 预测残差模型及性能分析

LoD 对点云压缩性能的影响来自于不同的预测方式,因此本小节主要针对此问题进行分析。

以 LoD 第一次划分为例,在经过一次采样后,点云被划分为了细节层 L_2 和增强层 A_1 。按照 LoD 的顺序,首先对 L_2 中的点进行预测编码,其可用参考点仍然具有原始点云的特点,即位于受限于编码顺序的空间方向上。同时,又由于经过采样,相邻点之间的最小距离变大,使得它们之间的相关性减弱,导致预测的效果变差,从而造成编码性能的损失。对于其后进行编码的 A_1 中的点,参考点不仅可以选本层中已编码的点,还可以选择已编码的 L_2 中的点,因此参考点的可选范围更大,且位于空间中的多个方向,同时相邻点之间的最小距离与原始点云一致,由此提高了预测的准确度,提升了编码性能。对于整个点云,若 A_1 的性能增益大于 L_2 的性能损

失,则 LoD 划分可以提升预测编码性能。

为了准确分析 LoD 划分前后的性能变化情况,利用预测残差建立数学模型。设 A_1 中的点数占 L_1 (原始点云) 的比例为 r_1 , 那么 L_2 占 L_1 的比例则为 $1-r_1$ 。 L_1 在划分 LoD 后的预测残差平均绝对误差可以表示为

$$E_{L_1}^* = (1-r_1)E_{L_2} + r_1E_{A_1} \quad (2)$$

式中: E_{L_2} 为 L_2 的预测残差平均绝对误差; E_{A_1} 为 A_1 的预测残差平均绝对误差。

与不划分 LoD 时 L_1 的预测残差平均绝对误差 (记为 E_{L_1}) 相比, 预测残差的变化记为 Δ_1 , 有

$$\Delta_1 = E_{L_1}^* - E_{L_1} \quad (3)$$

当 $\Delta_1 > 0$ 时, 整个点云的预测残差平均绝对误差在划分 LoD 后变大, 编码性能降低; 当 $\Delta_1 < 0$ 时, 整个点云的预测残差平均绝对误差减小, 编码性能提升, 此时为了进一步提升整个点云的编码性能, 可以通过多次 LoD 划分来减少对应细节层中的性能损失。假设进行了 N 次采样, 此时细节层 L_N 被划分为 L_{N+1} 和 A_N , 其预测残差平均绝对误差为 $E_{L_N}^*$, 计算式为

$$E_{L_N}^* = (1-r_N)E_{L_{N+1}} + r_NE_{A_N} \quad (4)$$

式中: r_N 为 A_N 占 L_N 的比例; $E_{L_{N+1}}$ 为 L_{N+1} 的预测残差平均绝对误差; E_{A_N} 为 A_N 的预测残差平均绝对误差。

L_N 的预测残差变化 Δ_N 可表示为

$$\Delta_N = E_{L_N}^* - E_{L_N} = (1-r_N)(E_{L_{N+1}} - E_{L_N}) + r_N(E_{A_N} - E_{L_N}) \quad (5)$$

式中 E_{L_N} 为 L_N 未进一步划分 LoD 时的预测残差平均绝对误差。

令 $\delta_1 = E_{L_{N+1}} - E_{L_N}$, $\delta_2 = E_{A_N} - E_{L_N}$, 可得

$$\Delta_N = (1-r_N)\delta_1 + r_N\delta_2 \quad (6)$$

由于 L_{N+1} 是对 L_N 的采样, 因此 L_{N+1} 中相邻点之间的距离要大于 L_N , 其相关性更差, 有 $\delta_1 > 0$, 即随着 LoD 的划分, 新的细节层通常会有性能的损失。对于 δ_2 , 可以认为是 A_N 中的点使用何种预测方式最优的问题。根据 2.1 小节前半部分中的分析, 对于增强层的预测方式, 参考点的分布更加广泛并且具有全向性, 可以提高预测的准确度和编码性能, 因此 $E_{A_N} < E_{L_N}$, 此时 $\delta_2 < 0$ 。随着 LoD 的进一步划分, 点之间的距离越来越大, 距离对相关性的影响超过了方向性。此时的 A_N 可能会选择距离更远的 L_{N+1} 中的点作为参考点, 因此预测效果和编码性能降低, 使得 $E_{A_N} \geq E_{L_N}$, 从而 $\delta_2 \geq 0$ 。

综合分析 δ_1 和 δ_2 带来的性能变化可知, 式(6)

为 0 时的编码性能最优, 此后的划分都不会带来编码性能的增益, 反而会造成性能损失, 如图 8 所示。




图 8 Δ_N 与划分层数 N 的关系

Fig. 8 Curves of Δ_N vs. number of LoD layers N

考虑到在划分 LoD 的过程中, 最顶层 L_N 中的点数随着 LoD 的划分次数 N 的增大而减小, 对性能的影响也越来越小, 因此从整体性能出发, 定义 Δ_N^*

$$\Delta_N^* = p_N \Delta_N \quad (7)$$

式中 p_N 为 L_N 中的点占全部点的比例, 公式为

$$p_N = \begin{cases} 1, & N = 1 \\ \prod_{i=1}^{N-1} (1-r_i), & N > 1 \end{cases} \quad (8)$$

其中 r_i 为 A_i 占 L_i 的比例, 与初始采样距离和各层之间的采样距离比有关。

当式(7)为 0 时, 编码性能达到最优。为了求解最优值, 需对两种预测方式下的预测残差进行拟合。

由空间相关性可知, 预测残差与距离相关, 因此将它们表示为距离的函数。对于细节层 L_j , 设

$$E_{L_j} = f(d_{1,j})_{(j=1,2,\dots,N)} \quad (9)$$

式中 $d_{1,j}$ 是 L_j 中相邻点之间的距离。

对于增强层 A_i , 设

$$E_{A_i} = g(d_{2,i})_{(i=1,2,\dots,N)} \quad (10)$$

式中 $d_{2,i}$ 是 A_i 中相邻点之间的距离。

点云 dancer_vox11 两种预测方式的对比如图 9 所示。将 E_{L_j} 和 E_{A_i} 的拟合结果代入式(7), 可得




图 9 dancer_vox11 中两种预测方式的对比

Fig. 9 Comparison of prediction methods in dancer_vox11

$$\Delta_N^* = p_N((1-r_N)f(d_{1,N+1}) + r_N g(d_{2,N}) - f(d_{1,N})) \quad (11)$$

式中: $d_{1,N}$ 和 $d_{1,N+1}$ 分别为细节层 L_N 和 L_{N+1} 中相邻点的距离; $d_{2,N}$ 为增强层 A_N 中相邻点的距离。

式(11)为0时的编码性能最优,式中的参数可通过在编码端对点云进行预编码或在线计算获取,然后求解方程 $\Delta_N^* = 0$,即可得到编码性能最优的LoD层数。然而,在实际应用中,复杂的实现过程对模型的实用性造成了影响,因此有必要提出一种能够快速实现的方法。

将式(6)代入式(7),可得

$$\Delta_N^* = p_N((1-r_N)\delta_1 + r_N\delta_2) \quad (12)$$

观察到图9中两种预测方式的曲线较为相似,使得 δ_1 和 δ_2 的变化相对较小,而 p_N 则随着LoD划分的深入而呈现指数下降的趋势。因此, p_N 对 Δ_N^* 的影响要远大于 δ_1 和 δ_2 的。由此,本文提出一种利用 p_N 优化编码性能的快速方法:当 p_N 足够小时,使得 Δ_N^* 近似为0,认为剩余这部分点无论是否继续划分LoD对整体编码性能几乎没有影响,此时已经达到了最优的编码性能,可以提前终止LoD划分。

2.2 面向点云无损压缩的快速LoD划分方法

由于当前基于LoD的点云压缩方案适用于均匀采样或者平滑的点云,对于非均匀采样和噪声点云并不适用^[15],因此本文主要针对均匀采样或者平滑的点云,并由此简化2.1小节中所建立的模型式(11)。

在实际中,点云中的点都位于物体表面,因此在较小区域内点云可以被视为二维平面,如图10所示。




图10 点云表面小区域内点的分布示意

Fig. 10 Points in a small region of surface in point cloud

在G-PCC中,相邻两次采样距离比都固定为

$2^{[7]}$,因此除第一次采样比 r_1 以外,其余每次采样比 $r_i (i > 1)$ 都几乎相同,约为 $3/4$ 。式(11)可以简化为

$$\Delta_N^* = r_1 \left(\frac{1}{4}\right)^{N-1} \left(\frac{1}{4}f(d_{1,N+1}) + \frac{3}{4}g(d_{2,N}) - f(d_{1,N})\right) \quad (13)$$

统计数据集中点云的预测残差进行分析,可以计算得到 Δ_N^* ,如图11所示。




图11 Δ_N^* 与划分层数 N 的关系

Fig. 11 Graph of Δ_N^* and the number of LoD layers N

在LoD层数 N 为5时, Δ_N^* 趋于0,认为此时达到了性能最优,对应细节层 L_5 中的点的比例为 p_5 。由统计得到两个点云的 r_1 都约为0.8,那么根据式(8)可求得 p_5 约为0.0031。为了增强方法的适用性以及提高方法的速度,本文提出了一种基于阈值 θ (θ 设为0.003)的LoD划分快速方法,即当划分至当前细节层中的点所占比例小于 θ 时,结束LoD划分,具体流程如图12所示。本文方法避免了预编码或在线计算等过程。




图12 所提方法流程

Fig. 12 Flow chart of the proposed method

对点云进行LoD划分,在每一层的采样结束后,计算当前细节层 L_i 占原始点云的比例,并判断是否小于终止阈值 θ 。若小于 θ ,则结束LoD划分,进行预测编码;若不小于 θ ,那么判断当前LoD层数

i 是否小于编码端预设的 LoD 层数 N , 若小于, 则继续 LoD 划分, 否则结束划分, 进行预测编码。

3 实验与分析

3.1 数据集

在第 3 节中, 进行了大量的实验来评估所提方法。实验选取了 G-PCC 的静态对象与场景数据库 Cat1-A^[18] 作为测试集(分析数据集中的点云除外), 这些点云也被广泛应用于评估各类点云压缩方法性能的实验中^[6,18-20]。

3.2 评价指标

为了评估压缩的性能, 本文对比了码率比 R' 、编码时间比 T_E 、解码时间比 T_D 共 3 种指标。码率比 R' 的计算公式为

$$R' = \frac{R_p}{R_G} \tag{14}$$

式中: R_p 是点云按照所提方法进行无损压缩后的属性码率; R_G 为点云根据 G-PCC 的通用测试条件(CTC)进行无损压缩后的属性码率。

编码时间比 T_E 为所提方法的编码时间与 G-PCC(参数参照 CTC 设置)的编码时间的比值; 解码时间比 T_D 为所提方法的解码时间与 G-PCC(参数参照 CTC 设置)的解码时间的比值。

3.3 结果分析

将所提方法与 G-PCC(参数参照 CTC 设置)进行比较, 对测试集使用 G-PCC TMC13 v9 点云压缩平台^[7] 进行无损压缩, 结果如表 1 所示。可以看出, 当阈值 $\theta=0.003$ 时, 与设置为 CTC 时相比, 码率没有增加, 而编解码时间则显著减少, 平均节省了约 4% 的编码时间和 6% 的解码时间。

对于绝大多数点云, 在通过本文阈值终止 LoD 划分时, 其性能已经达到最优, 与 CTC 一致, 因此码率比 R' 为 100%。若进一步划分 LoD, 新的细节层中相邻点的距离呈指数增大, 使得其相关性急剧下降, 性能损失较大; 对于新的增强层, 虽然对改善预测的准确性有一定的效果, 但所带来的增益与细节层的损失相互抵消, 因此无法进一步减小码率。同时, 这部分点的比例又足够小, 两个因素综合起来使得压缩后的码率维持不变, 达到最小。

对个别的点云, 码率比 R' 略微大于 100%, 例如 loot_vox12 的 100.01%, 表明所提方法的码率大于 CTC 的码率。这是由于本文方法使用了统一的阈值, 可能造成一定的误差, 使得 LoD 较早结束了划分。此时, 最顶端的细节层中的点还存在一定的相

关性, 若再继续划分 LoD, 还会有一定的性能增益, 但是由于这部分点的数量已经非常少, 根据 2.1 小节中的分析, 其影响也非常有限。

表 1 所提方法与 CTC 的性能对比

Table 1 Coding performance and time complexity comparison between the proposed method and CTC

测试集	$R'/\%$	$T_E/\%$	$T_D/\%$
boxer_vox12	100.00	95.92	93.76
Egyptian_mask_vox12	100.00	96.51	95.26
Facade_vox12	100.00	95.76	94.62
Facade_vox14	100.00	94.53	92.42
Facade_vox11	100.00	96.13	94.82
Frog_vox12	100.00	96.19	94.28
Head_vox12	100.00	96.28	94.59
House_without_roof_vox12	100.00	96.21	93.76
longdress_vox12	100.00	94.85	93.37
longdress_vox10	100.00	95.85	94.39
loot_vox12	100.01	94.18	92.69
loot_vox10	100.00	96.36	94.36
queen	100.00	96.80	95.29
redandblack_vox12	100.00	94.87	92.38
redandblack_vox10	100.00	97.41	94.29
Shiva_vox12	100.00	97.05	95.37
soldier_vox12	100.00	94.82	92.94
soldier_vox10	100.00	96.52	94.39
Thaidancer_vox12	100.00	97.25	94.98
ULB_Unicorn_vox13	99.99	96.16	93.35
平均值	100.00	95.98	94.07

另外还有一种很少见的情况, 例如 ULB_Unicorn_vox13 的码率比 R' 小于 100%, 即此时本文方法的码率小于 CTC 的码率。这类点云的内容较为复杂, 相似点大多集中在较小的范围内, 如图 13



图 13 ULB_Unicorn_vox13 点云

Fig. 13 Point cloud ULB_Unicorn_vox13

所示。

在达到阈值后,若再进一步划分 LoD,由于新的细节层中相邻点的距离呈指数增大而使得其相关性急剧下降,性能损失较大。另一方面,新的增强层对提升预测准确性的效果甚微,甚至反而会降低预测准确性,因此本文方法性能会有一定的下降,码率比 R' 小于 100%。

表 2 对比了 CTC 中的 LoD 层数 N_G 和本文方法实际划分的 LoD 层数 N^* 。可以看出,对于测试集的每一个点云, N^* 都远远小于 N_G , 因此避免了不必要的 LoD 划分过程,节省了宝贵的编解码时间。

表 2 LoD 层数对比

Table 2 Number comparison of LoD layers between two methods

测试集	N_G	N^*
boxer_vox12	12	5
Egyptian_mask_vox12	11	6
Facade_vox12	12	6
Facade_vox14	13	5
Facade_vox11	13	6
Frog_vox12	13	6
Head_vox12	12	6
House_without_roof_vox12	13	6
longdress_vox12	13	5
longdress_vox10	12	6
loot_vox12	12	5
loot_1200	12	6
queen	12	6
redandblack_vox12	12	5
redandblack_vox10	12	6
Shiva_vox12	12	6
soldier_vox12	12	5
soldier_vox10	12	6
Thaidancer_vox12	12	6
ULB_Unicorn_vox13	12	6

本文提出了通过设置终止阈值优化 LoD 划分的方法,无需考虑各层 LoD 的采样距离。实验中使用的阈值仅是通过两个分析点云进行简单统计得到的,将其用于均匀采样或者平滑点云的测试集已经获得了较好的效果。当然,阈值的设置并不仅限于此,可以通过更多的训练得到更优的阈值。

4 结 论

本文针对基于 LoD 的点云无损压缩,通过分析

LoD 中增强层与细节层的预测方式对编码性能的影响,并结合空间相关性的原理,建立了基于预测残差的 LoD 优化模型。在实际应用中,特别是对编码端的实时性要求较高的场合,对每个未知点云都进行预编码或在线计算是不现实的,为了降低实现复杂度,本文提出了一种基于均匀采样及平滑点云特性的模型参数简化方法,并在此基础上实现了一种基于阈值的 LoD 划分快速方法。实验结果表明,在通用测试条件下,所提方法与 G-PCC 相比,在码率未增加的同时,节省了约 4% 的编码时间和 6% 的解码时间。

本文方法避免了对点云进行预编码或在线计算的复杂过程,提高了所建模型的实用性。仅通过阈值控制实现 LoD 的性能优化,在达到最小编解码率的同时避免了无效的 LoD 划分,节省了编解码时间,提高了点云压缩的实时性。

下一步将研究快速和高效的预编码和在线计算的方法,实现对任意未知点云编码性能的自适应优化。另外,本文所建立的模型并不仅限于点云的无损压缩,还可扩展至点云有损压缩的率失真优化。

参考文献:

[1] MEKURIA R, BLOM K, CESAR P. Design, implementation, and evaluation of a point cloud codec for tele-immersive video [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2017, 27 (4): 828-842.

[2] 李厚强, 李礼, 李竹. 点云编码综述 [J]. 中兴通讯技术, 2021, 27(1): 5-9.

LI Houqiang, LI Li, LI Zhu. A review of point cloud compression [J]. ZTE Technology Journal, 2021, 27 (1): 5-9.

[3] ZHANG Cha, FLORÊNCIO D, LOOP C. Point cloud attribute compression with graph transform [C]//Proceedings of the 2014 IEEE International Conference on Image Processing (ICIP). Piscataway, NJ, USA: IEEE, 2014: 2066-2070.

[4] COHEN R A, TIAN Dong, VETRO A. Point cloud attribute compression using 3-D intra prediction and shape-adaptive transforms [C] // Proceedings of the 2016 Data Compression Conference (DCC). Piscataway, NJ, USA: IEEE, 2016: 141-150.

[5] COHEN R A, TIAN Dong, VETRO A. Attribute compression for sparse point clouds using graph transforms [C]//Proceedings of the 2016 IEEE International Conference on Image Processing (ICIP). Piscat-

- away, NJ, USA: IEEE, 2016: 1374-1378.
- [6] DE QUEIROZ R L, CHOU P A. Compression of 3D point clouds using a region-adaptive hierarchical transform [J]. IEEE Transactions on Image Processing, 2016, 25(8): 3947-3956.
- [7] MPEG 3DG. G-PCC codec description v9 [EB/OL]. [2021-03-01]. https://dms.mpeg.expert/doc_end_user/current_document.php?id=76925&id_meeting=0.
- [8] CLARK J H. Hierarchical geometric models for visible-surface algorithms [J]. ACM SIGGRAPH Computer Graphics, 1976, 10(2): 267.
- [9] KATHARIYA B, ZAKHARCHENKO V, LI Zhu, et al. Level-of-detail generation using binary-tree for lifting scheme in LiDAR point cloud attributes coding [C] // Proceedings of the 2019 Data Compression Conference (DCC). Piscataway, NJ, USA: IEEE, 2019: 580.
- [10] FAN Yuxue, HUANG Yan, PENG Jingliang. Point cloud compression based on hierarchical point clustering [C] // Proceedings of the 2013 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference. Piscataway, NJ, USA: IEEE, 2013: 1-7.
- [11] LUEBKE D, REDDY M, COHEN J D, et al. Level of detail for 3D graphics [M]. San Francisco, CA, USA: Morgan Kaufmann Publisher, 2002: 19-45.
- [12] CHOU P A, KOROTEEV M, KRIVOKUCA M. A volumetric approach to point cloud compression; part I Attribute compression [J]. IEEE Transactions on Image Processing, 2020, 29: 2203-2216.
- [13] SCHWARZ S, PREDA M, BARONCINI V, et al. Emerging MPEG standards for point cloud compression [J]. IEEE Journal on Emerging and Selected Topics in Circuits and Systems, 2019, 9(1): 133-148.
- [14] 周凡. 点云属性压缩算法研究 [D]. 西安: 西安电子科技大学, 2019: 51-63.
- [15] MAMMOU K, KIM J, VALENTIN V, et al. Efficient implementation of the lifting scheme in TMC13 [EB/OL]. [2021-03-01]. https://dms.mpeg.expert/doc_end_user/current_document.php?id=63053&id_meeting=0.
- [16] 万帅, 杨付正. 新一代高效视频编码 H.265/HEVC: 原理、标准与实现 [M]. 北京: 电子工业出版社, 2014: 94-104.
- [17] VALENTIN V, MAMMOU K, TOURAPIS A, et al. Improved G-PCC lossless and near-lossless coding [EB/OL]. [2021-03-01]. https://dms.mpeg.expert/doc_end_user/current_document.php?id=64363&id_meeting=0.
- [18] MPEG 3DG. Common test conditions for G-PCC [EB/OL]. [2021-03-01]. https://dms.mpeg.expert/doc_end_user/current_document.php?id=76939&id_meeting=0.
- [19] DE QUEIROZ R L, CHOU P A. Transform coding for point clouds using a Gaussian process model [J]. IEEE Transactions on Image Processing, 2017, 26(7): 3507-3517.
- [20] SANDRI G, DE QUEIROZ R L, CHOU P A. Comments on “compression of 3D point clouds using a region-adaptive hierarchical transform” [EB/OL]. [2021-03-10]. <https://arxiv.org/abs/1805.09146>.

(编辑 陶晴)