

DOI: 10.20098/j.cnki.1001-5132.2023.1115

基于三维与二维联合的彩色点云无参考质量评价方法

刘佳语¹, 蒋志迪², 郁梅^{1*}

(1. 宁波大学 信息科学与工程学院, 浙江 宁波 315211; 2. 宁波大学科学技术学院, 浙江 宁波 315300)

摘要: 点云作为一种三维视觉信息的载体, 在其采集、传输和重建时会不可避免地引入失真, 降低点云的视觉质量, 因此需要有效方法对失真点云进行质量评价. 本文提出一种基于三维与二维联合的彩色点云无参考质量评价方法, 在三维、二维空间中分别提取点云的几何信息和彩色纹理信息; 在点云几何与彩色纹理的联合失真方面, 新方法对几何和彩色纹理投影图进行联合张量分解; 考虑到人眼多方向、多尺度的感知特征, 利用曲波变换在彩色纹理投影图上提取特征; 最后通过随机森林池化来预测彩色点云的质量. 在3个数据库上的实验结果表明, 本文方法优于现有一些点云质量评价方法, 其预测结果与主观质量具有良好的相关性.

关键词: 彩色点云; 质量评价; 三维与二维联合; 感知特征

中图分类号: TP37

文献标志码: A

文章编号: 1001-5132 (2024) 04-0084-11

随着现代多媒体技术的迅速发展, 作为一种三维(Three Dimensional, 3D)场景的描述形式, 彩色点云(Color Point Cloud, CPC)孕育而生, 它是由空间中一系列点组成的数据集, 每个点都包括了位置信息和其他的属性信息(如颜色、法向量等), 已被广泛应用于自动驾驶^[1]、姿态估计^[2]、虚拟现实^[3]等领域. 然而在点云数据的采集、处理、压缩、传输、解码、显示等各个处理过程中都不可避免地会引入失真, 影响点云的感知质量, 因此对彩色点云进行质量评价十分必要. 彩色点云质量评价的目的是反映点云的人类视觉系统(Human Visual System, HVS)感知质量. 虽然主观质量评价方法最直接有效, 但对实验条件要求高, 且耗时、耗力、效率不高, 还无法嵌入系统. 因此, 通常实际应用中需采用模拟人眼感知的客观质量评价方法.

依据评价方法是否需要参考点云, 现有的点云质量评价方法(Point Cloud Quality Assessment, PCQA)主要分为全参考和无参考评价方法. 点到点(Po2point)^[4]和点到平面(Po2plane)^[5]方法是早期点云质量全参考的评价方法, 该类方法计算失真

点云与参考点云在几何层面的欧几里得距离差异, 再用所有点的均方误差(Mean Square Error, MSE)或者 Hausdorff 距离来衡量整体点云的误差. 此外, 平面到平面方法^[6]提出了角相似度度量(Angular Similarity, AS), 通过计算局部表面近似相似度来评估几何形变. 但是这些计算方法都只考虑了纯几何距离. 考虑到点云结构, Meynet 等^[7]提出了一种基于局部曲率统计的质量评价方法(Point Cloud Mesh Structural Distortion Measure, PC-MSDM), 其可以被视为适用于 3D 网格 MSDM 度量的点云扩展. 但以上方法只对几何失真进行描述, 对彩色点云的失真描述有限.

考虑到彩色纹理对点云质量的影响不可或缺, Meynet 等^[8]提出 PCQM (Point Cloud Quality Metric) 方法, 将几何特征与亮度、色度和色调相关的 5 种颜色特征相结合. 参考二维(Two Dimensional, 2D)图像结构相似性(Structural Similarity, SSIM)的评价方法, Alexiou 等^[9]在 PointSSIM 方法中, 从几何、法向量、曲率和颜色四方面描述局部分布, 通过每个区域获得的质量分数来预测质量. 考虑到有局

收稿日期: 2023-11-08.

宁波大学学报(理工版)网址: <http://journalg.nbu.edu.cn/>

基金项目: 浙江省自然科学基金(LY21F010003).

第一作者: 刘佳语, 硕士研究生, 主要研究方向: 点云质量评价. E-mail: liujiayu971089837@163.com

*通信作者: 郁梅, 博士/教授, 主要研究方向: 三维视频处理与编码、图像与视频质量评价. E-mail: yumei@nbu.edu.cn

部显著相似性问题, Yang 等^[10]在提出的 GraphSIM (Graph Similarity)方法中构建以关键点为中心的局部图聚合颜色梯度特征. 然而, GraphSIM 缺乏人类感知的多尺度特性. 受到 2D 图像质量评价的启发, 研究人员将点云投影到 2D 域进行质量评价. Torlig 等^[11]将经典 2D 图像质量评价指标, 如 PSNR(Peak Signal-To-Noise Ratio)、SSIM、MS-SSIM^[12](Multi-scale Structural Similarity)和 VIFP^[13](Visual Information Fidelity)等用于点云投影图, 但是该方法没有考虑到点云 3D 特性. Yang 等^[14]将 3D 点云投影到 6 个图像垂直平面上, 获取点云的几何和彩色纹理投影图后, 提取全局和局部特征予以评价; 并通过引入 2D 空间的显著图, 利用人眼显著性来加权融合点云的 3D 特征. 上述方法均属全参考方法, 但在实际应用中可能面临参考点云无法获取的问题. 而无参考质量评价无需参考点云, 应用范围更广. Zhang 等^[15]提出基于自然统计特征的 NR-3DQA 评价方法. Hua 等^[16]提出了一种基于联合点投影的度量 BQE-CVP, 它基于 3D 空间提取几何、颜色特征以及投影提取颜色特征, 并采用几何颜色共生矩阵来融合几何和颜色特征. Cheng 等^[17]提出了一种具有局部区域相关分析能力的无参考点云质量评价方法.

由于无参考评价方法的应用场景更为广泛, 使其成为点云质量评价方法的研究热点之一, 但

某些方法同样与全参考质量评价性能存在差距. 全参考质量评价方法可总结为在 3D 空间中提取结构信息并映射到 2D 空间上提取投影图特征, 这类方法被证明是有效的, 但面对单一特征评价时仍具有局限性. 为了更好地对点云进行全面的质量评价, 本文提出基于三维与二维联合的彩色点云无参考质量评价方法. 针对点云特征提取不全面的问题, 分别在 3D 和 2D 域提取特征. 其中, 3D 特征提取方法在空间中提取几何和颜色信息, 2D 特征提取方法涉及多域, 描述了几何、彩色纹理和联合信息. 在 2D 域中, 空间域特征直接从图像的像素值中提取信息, 主要关注像素之间的空间关系, 如纹理、对比度和结构; 变换域特征有助于捕捉图像的频域信息, 并可在变换域中采用多尺度、多方向分解来描述特征; 感知域特征关注图像的感知属性, 这些特征可以模拟人类视觉系统对图像的处理方式; 同时, 将几何投影和彩色纹理投影信息合并为四阶张量, 再对其进行张量分解, 以期在张量域中获取联合投影信息.

1 基于三维与二维联合的彩色点云无参考质量评价方法

考虑点云空间信息和投影到图像域的平面信息, 以及几何失真、彩色纹理失真、几何与彩色纹理联合失真, 本文提出一种基于三维与二维联合




图1 基于三维与二维联合的彩色点云无参考质量评价方法框图

的彩色点云质量无参考评价方法, 将点云的 3D 空间信息与 2D 投影平面信息相结合. 其框图如图 1 所示, 主要包含 3D 特征提取模块和 2D 特征提取模块. 在 3D 特征提取模块中, 考虑到对所有点计算几何特征会带来巨大计算量, 因此先利用最远点采样(Farthest Point Sampling, FPS)对点云提取关键点, 再计算每个关键点的 ESF(Eigenvalue-based Shape Functions)特征以描述点云的几何形状. 对于颜色信息, 转化到更符合视觉的 LMN 颜色空间^[18]进行提取. 在 2D 特征提取模块中, 针对几何和彩色纹理失真相互作用的问题, 采用张量分解在张量域中提取联合信息; 对于点云的几何失真, 可在空间域和感知域提取几何特征; 至于点云的彩色纹理失真, 可提取相关空间域特征, 并在变换域中结合人眼特征利用曲波多尺度、多方向分解来提取纹理特征以及提取感知特征. 最后通过随机森林回归模型训练得到质量预测模型, 并对失真彩色点云进行质量预测. 表 1 为本文涉及的主要特征变量说明.

表 1 本文方法涉及的主要特征变量

特征提取域	特征类型	特征
2D	几何	空间域 F_{gm}
		感知域 F_{gp}
	彩色纹理	空间域 $F_{tm}+F_{tg}$
		变换域 $F_{tc1}+F_{tc2}$
		感知域 F_{tp}
3D	联合特征	张量域 F_{gt}
	几何	F_{3g}
	彩色纹理	$F_{3l}+F_{3c}$

1.1 3D 特征提取模块

点云数据在 3D 域中包含点的位置和颜色等信息, 其中在空间中点的消失或位置偏移会导致几何失真, 点颜色的改变会导致颜色失真. 为有效描述这些失真形式, 将点云的 3D 特征提取分为 3D 几何信息提取和 3D 颜色信息提取.

1.1.1 几何信息提取

首先使用 FPS 算法随机采样降低点的数据密度. FPS 采样点是点云中距离分布均匀的点, 它们能够代表整个点云的几何特征. 为使 ESF 特征数量更好地反映分布情况, 对采样后的点云使用均值聚类生成 64 簇, 对每个簇的集合点提取 ESF 特

征, 形成簇 ESF 特征. 对每个簇集合的 ESF 特征取平均值, 最后形成 64 个簇的 ESF 特征平均值. ESF 特征提取方法^[19]是一种全局形状描述算子方法, 本文取 3 个纯几何形状函数作为描述函数, 分别计算点云表面上 2 个点之间的距离, 以及随机 3 个点形成的三角形(若不能构成三角形, 则重新随机选取 3 个点)面积的平方根和 3 个点之间的角度, 用来描述所涉及点云表面上的距离、面积和角度的几何特征分布, 并且使用点云的几何形状特征表示点云在几何形状函数中的采样概率分布. 最后, 总共 192 维的向量作为彩色点云的 3D 几何特征 F_{3g} (3g 代表 3D geometry).

1.1.2 颜色信息提取

为了逼真模拟人类的感知过程, 可借助 LMN 颜色空间将 HVS 的显著性信息融合到图像的结构中, 以提高图像的质量和视觉感知效果, 使其更接近人眼的感知过程. RGB 颜色空间转换到 LMN 空间的转换公式如下:

$$\begin{cases} L = 0.06R + 0.63G + 0.27B, \\ M = 0.30R + 0.04G - 0.35B, \\ N = 0.34R - 0.60G + 0.17B. \end{cases} \quad (1)$$

为更好地体现 3D 点云的颜色失真, 将点云中每个点的颜色值转换到 LMN 颜色空间, L 表示图像亮度通道, M 和 N 分别为两个色差通道. 通过对颜色分布进行建模, 可以帮助区分不同的颜色和纹理, 从而进行失真描述. 对点云的 L 分量, 提取亮度分布特征 F_{3l} (3l 代表 3D luminance):

$$F_{3l} = \left[\frac{1}{N_p} \sum_{i=1}^{N_p} \left(L_i - \frac{1}{N_p} \sum_{i=1}^{N_p} L_i \right)^3 \right]^{\frac{1}{3}}, \quad (2)$$

式中: N_p 表示点云的点数; L_i 表示点云中第 i 个点 P_i 的亮度分量. 将亮度值进行三次方运算, 可以突出非线性特性, 即亮度值的高次方差异. F_{3l} 越大表示该区域内像素亮度值的差异越大, 对应表示一些亮度明显变化的纹理区域可能存在的噪声点. 在 LMN 颜色空间中计算点云颜色差异度特征, 并且在 3 个通道中计算颜色距离:

$$D_i = \sqrt{(C_p(i) - C_p(i_1))^2 + (C_p(i) - C_p(i_2))^2}, \quad (3)$$

式中: $C_p(i) = \{L, M, N\}$ 为点云中第 i 个点 P_i 的 LMN 中某个通道的颜色分量; i_1 和 i_2 是用 K 近邻算法搜索出的 P_i 的 2 个相邻点. 根据式(3), 计算 3 个通道

的颜色差异度的标准差与均值, 得到6维颜色差异度特征. 另外在 LMN 颜色空间, 分别计算点云中所有点3个颜色通道分量的均值、标准差、偏度和峰度, 用这些统计特征来描述颜色分量分布和形态的重要信息. 上述颜色差异度特征和每个通道的颜色特征表示为 F_{3c} (3c 代表 3D color). 最后, F_{3l} 和 F_{3c} 共同组成 19 维的 3D 颜色特征.

1.2 2D 特征提取模块

1.2.1 几何纹理联合特征提取

采用正交投影将点云体素化后的彩色纹理信息和几何信息投影到立方体6个面上, 得到6个面的彩色纹理投影图和几何投影图, 分别定义为 P_{tq} 和 P_{gq} (t 代表 texture, g 代表 geometry, $q = 1, 2, \dots, 6$). 当体素数为 $L \times L \times L$ 时, 每个投影面大小为 $L \times L$. 当6个面合并后, P_t 和 P_g 的大小为 $(6L) \times L$. 图2为 CPD 2.0 数据库中 redandblack 模型的投影图示例.




图2 彩色点云 redandblack 的彩色纹理投影和几何投影图

考虑到几何投影图和彩色纹理投影图之间的相互作用, 需对两者联合进行张量分解, 以提取高维数据中的主要结构来描述两者的联合失真. 每个点云中 P_t 的 RGB 三通道和 P_g 的 D 通道堆叠合并为一个四阶张量, 表示为 ψ . 对于每个失真 3D 点云,

$$\psi = \kappa \times_n U^{(n)}, \quad (4)$$

式中: $\psi \in \mathbb{R}^{W \times H \times C \times N}$, W 和 H 为 ψ 的宽度和高度, C 表示其通道维度 (单通道的几何投影图扩展为 3 通道, 因此此处取值为 3), N 表示 P_t 和 P_g (此处取值为 2); κ 为核心张量, 保留了原张量的主要信息, 用于度量特征因子矩阵之间的关联程度; n 表示分解为 n 个特征因子矩阵; U 表示分解后的矩阵. 这里对 ψ 进行 $n=4$ 的 Tucker 分解, 分别表示张量 ψ 在每个模式 (维度) 上的投影. 再将核心张量与特征因


子矩阵 $U^{(3)}$ 和 $U^{(4)}$ 相乘, 得到包含 P_t 与 P_g 所组成的四阶张量主要信息的张量子空间 S , 其包含的 2 个成分 I_1 和 I_2 可表示为:

$$S = \kappa \times_3 (U^{(3)})^T \times_4 (U^{(4)})^T, \quad (5)$$


$$S = \{I_1, I_2\}. \quad (6)$$

为了涵盖更多的亮度和颜色信息, 并考虑算法简易性, 这里取 S 的第一成分 I_1 表示为联合信息. 第一成分是张量核心, 包含了张量的主要联合信息.

图3为 redandblack 模型不同失真状态下正视图张量分解联合的结果, 分别为彩色纹理投影图、几何投影图和张量分解联合投影图. 图3(a)为不同失真下的全局投影图, 图3(b)为局部放大图, 从左到右失真依次是 Original、GPCC (Geometry-based Point Cloud Compression) octree、GPCC trisoup、VPCC (Video-based Point Cloud Compression) 和高



(a) 全局投影图



(b) 局部放大图

图3 不同失真的彩色点云 redandblack 模型张量分解的全局投影和局部放大图

斯噪声(Gaussian Noise, GN)失真模型. GPCC 的两种失真是基于几何点云压缩标准产生的压缩失真, 其中, GPCC octree 失真表现为规则的网格状失真, GPCC trisoup 失真表现为随机三角形空洞. VPCC 失真是基于视频点云压缩标准而产生的压缩失真, 表现为随机的裂纹与边缘锯齿状. GN 是加入高斯噪声后的结果, 具体表现为噪声点. 此外, 还可从图 3 看到联合投影融入和呈现了纹理颜色和深度的主要信息.

对得到的联合投影图采用 DoG(Difference of Gaussian)算子在联合投影平面求取梯度信息, 再用局部二值模式(Local Binary Pattern, LBP)对梯度信息进行编码, 并根据梯度信息对每个 LBP 模式进行加权. 加权目的是根据梯度信息调整 LBP 编码权重以便实现自适应编码, 强调更重要的 LBP 模式是为了更精确地捕获到图像的局部纹理特征. 最后将编码后的 10 维向量作为联合特征 F_{gt} (gt 代表 geometry texture).

图 4 中比较了不同失真程度下的 redandblack

模型联合投影图的加权梯度直方图 H_O 与原始点云对应的加权梯度直方图 H_D . 图中 Low、Medium、High 对应不同的模型质量, 即每列从上至下失真程度依次减小, 直方图中横坐标为 $-180^\circ \sim 180^\circ$ 之间等间距划分的 10 个区间. 这里采用卡方距离 d 衡量两个直方图之间的差异, 算式如下:

$$d = \sum_i \frac{(H_O(i) - H_D(i))^2}{H_O(i) + H_D(i)}. \quad (7)$$

通过计算不同失真情况下的点云联合彩色纹理投影图的直方图与原始点云直方图的卡方距离, 发现随着图像质量的提高, 差异距离 d 变小, 说明该描述方法与失真情况有很好的一致性.

1.2.2 几何特征提取

针对几何投影图, 提取 4 个方向的均值减去对比标准化(Mean Subtracted Contrast Normalization, MSCN)系数进行非对称广义高斯分布(Asymmetric Generalized Gaussian Distribution, AGGD)的拟合, 拟合参数即为几何投影图的空间特征 F_{gm} (gm 代表 geometry MSCN). 根据相关研究发现人类识




图 4 不同失真类型点云 redandblack 模型的 P_t 和 P_g 联合信息 I_1 的加权梯度直方图分布(从上到下点云失真程度依次递减)

别或区分图像中物体的能力一定程度上依赖于对比度, 这里采用全局对比度^[20](Global Contrast Factor, GCF)提取对比度特征. 熵特征能描述图像的信息量, 而高质量图像携带了更多信息, 因此可以提取几何投影图的熵特征作为感知特征. 以上对比度特征和熵特征作为点云几何投影图的感知特征, 用 F_{gp} 表示(gp 代表 geometry perception).

1.2.3 彩色纹理特征提取

对彩色纹理投影图进行灰度化后, 提取其4个方向的 MSCN 系数进行 AGGD 拟合, 拟合后的参数作为彩色纹理投影图的空域特征 F_{tm} (tm 代表 texture MSCN). 研究表明^[21], 大脑处理图像结构规律的过程可以用 Weibull 分布来近似拟合图像的对比度分布参数 γ 和 λ , 其中, γ 是比例参数, λ 是形状参数. 图像除在空间位置上具有一定规律性分布外, 在对比度上也呈现出分布特征^[22]. 而梯度可以反映图像对比度的信息, 其直方图遵循双参数 Weibull 分布. 受此启发, 本文用彩色纹理投影图的梯度拟合参数 γ 和 λ 来描述投影图像对比度信息. 这里采用Prewitt算子提取梯度幅值, 其直方图用双参数 Weibull 分布来拟合. 根据定义, 双参数 Weibull 分布概率密度函数表示为:

$$\xi = (g; \gamma, \lambda) = \frac{\lambda}{\gamma} \left(\frac{g}{\gamma} \right)^{\lambda-1} e^{-\left(\frac{g}{\gamma} \right)^{\lambda}}, \quad (8)$$

式中: g 为图像梯度值. $F_{tg} = \{\gamma, \lambda\}$ 表示彩色纹理投影图的空域梯度特征(tg 代表 texture gradient).

图5为采用 Weibull 分布函数对不同失真程度点云 redandblack 模型正视彩色纹理投影图梯度分布进行拟合的分布曲线. 图中 H、M、L 分别表示高、中、低的点云质量. 从图5可见, 不同失真会导致概率分布—梯度曲线具有一定差异, 相当于人眼观察全局图像时可对不同失真类型的图像予以区分. 同时, 梯度值在[0,1]范围内概率分布差异性较大, 表明不同点云质量的差别主要体现在梯度值较低区域, 这与人眼对于局部细节的分辨能力相符. 由此可见, Weibull 分布函数对描述点云彩色纹理投影图梯度统计分布具有良好的拟合性.

人类视觉系统具有多通道特性和图像的各向异性, 而曲波 curvelet 变换可通过模拟人眼多尺度、多方向的感知方式来提取信号和图像特征. 因此, 通过 curvelet 变换在变换域上进行五尺度分解,




图5 不同失真类型点云 redandblack 模型彩色纹理投影图梯度拟合 Weibull 分布

来提取彩色纹理投影图比例、位置和方向特征. 以 $n \times n$ ($n = 2^m$, $m \geq 8$, 且为正整数) 的图像块 $I(x_1, x_2)$ 作为输入, $I(x_1, x_2)$ 的离散 curvelet 变换定义如下:

$$C(j, l, p) = \sum_{0 \leq x_1, x_2 \leq N} I(x_1, x_2) \overline{\phi_{j, l, p}(x_1, x_2)}, \quad (9)$$

式中: $C(j, l, p)$ 表示 curvelet 系数; j 、 l 和 p 分别代表尺度、方向和空间的位置参数; ϕ 表示 curvelet 母函数; 上划线表示共轭; $I(x_1, x_2)$ 定义为空间坐标. 将彩色纹理投影图划分为不重叠的 256×256 图像块作为输入, 并分解为 5 个不同的尺度. 其中, $C(j, l, p)|_{j=4}$ 包含彩色纹理投影图的大部分细节信息; $C(j, l, p)|_{j=5}$ 为精细层, 包含图像纹理细节、噪声纹理等高频信息. 由于失真会导致图像的结构变化, 尤其是高频部分更为敏感, 因此为量化这种结构变化, 可研究第五尺度 curvelet 系数分布. 对每个方向的 curvelet 系数取以 10 为底的对数值:

$$A_5 = \log_{10} |C(5, l, p)|. \quad (10)$$

为描述彩色纹理投影图的失真, 用 AGGD 来拟合 A_5 系数分布, 表示如下:

$$f(A_5; \alpha, \mu, \sigma_l, \sigma_r) = \begin{cases} \frac{\alpha}{2(\beta_l + \beta_r)\Gamma(1/\alpha)} \exp\left(-\left(\frac{A_5 - \mu}{\beta_l}\right)^\alpha\right), & A_5 < 0, \\ \frac{\alpha}{2(\beta_l + \beta_r)\Gamma(1/\alpha)} \exp\left(-\left(\frac{A_5 - \mu}{\beta_r}\right)^\alpha\right), & A_5 \geq 0, \end{cases} \quad (11)$$

$$\begin{cases} \beta_l = \sigma_l \sqrt{\frac{\Gamma(1/\alpha)}{\Gamma(3/\alpha)}}, \\ \beta_r = \sigma_r \sqrt{\frac{\Gamma(1/\alpha)}{\Gamma(3/\alpha)}}, \end{cases} \quad (12)$$

式中: α 为振幅; μ 为平均值; σ_l 和 σ_r 分别为左、右标准差. 提取 4 个系数作为 NSS (Natural Scene Statistics) 拟合的特征 $\mathbf{F}_{\text{tc1}} = \{\alpha, \mu, \sigma_l, \sigma_r\}$ (tc 代表 texture curvelet). 因为失真通常会破坏各个尺度和方向上的能量分布, 因而须计算不同尺度和方向上的能量值. 对每个方向不同尺度 curvelet 系数取绝对值, 作为能量值大小. 对于五尺度的 curvelet 变换, 其第四尺度的方向最全面且分布对称, 因此选择第四尺度 64 个方向上的前 32 个方向, 并以每个方向上系数矩阵的平均值作为方向能量:

$$E_4 = \frac{1}{B_4} \sum_x |C(j, l, p)|_{j=4}, \quad (13)$$

式中: B_4 是在第四尺度上不同方向的 curvelet 系数个数的总和.

图 6 为 redandblack 模型正视彩色纹理投影图经 curvelet 变换分解后第四尺度下不同方向子带的能量分布图. 如图 6 所示, 相较于原始点云, GPCC 和 VPCC 编码失真会引起不同方向子带的能量值变化, 而高斯失真导致子带能量分布趋于均匀和平坦. 由此可见, 不同失真类型可改变点云彩色纹理投影图 curvelet 变换域不同方向子带上的能量分布, 因而这些能量分布特征能有效描述不同失真对 curvelet 变换域能量分布的影响, 从而可以用来区分不同点云失真类型. 分别提取 1~16 方向子带和 17~32 方向子带的能量峰度特征 ω_l 和 ω_r , 32 个方向子带能量峰度平均值 ω_m 以及 32 个方向子带能量分布各向异性的特征值 τ , $\tau = \sigma_4 / \mu_4$, σ_4 和 μ_4 分别表示第四尺度方向上能量的标准偏差和平均值. 以上能量特征用 $\mathbf{F}_{\text{tc2}} = \{\omega_l, \omega_r, \omega_m, \tau\}$ 表示.




图 6 不同失真类型点云 redandblack 模型正视彩色纹理投影图第四尺度下不同方向的能量分布

点云色彩同样会影响其感知质量, 因此可采用彩色纹理投影图的颜色度^[23](Colorfulness, CF)来衡量色彩的丰富程度. 对彩色纹理投影图利用暗通道特征^[24](Dark Channel Feature, DCF)分析其对

比度,用以评估其质量.以上颜色度特征和暗通道特征作为点云彩色纹理投影图的感知特征,这里用 F_{tp} 表示(tp 代表 texture perception).

1.3 特征池化

以上从彩色三维点云中提取的特征涵盖了 3D 域和 2D 域的彩色纹理和几何方面的信息,3D 域特征 $F_{3D} = (F_{3g}, F_{3l}, F_{3c})$ 与 2D 域特征 $F_{2D} = (F_{gm}, F_{gp}, F_{tm}, F_{tg}, F_{tc}, F_{tp}, F_{gt})$ 共构成 267 维的特征 $F_{CPC} = (F_{3D}, F_{2D})$. 由于随机森林(Random Forest, RF)在执行回归和分类任务时通常不容易出现过拟合现象,因此选择 RF 将特征向量池化为彩色三维点云的整体质量预测分数 Q .

2 实验结果及分析

2.1 测试数据库及性能指标

本文实验选取 CPCD 2.0^[25]、SJTU-PCQA^[14]和 IRPC^[26] 3 个彩色点云数据库进行点云质量评价方法性能的评估. CPCD 2.0 数据库包含 10 个参考点云和 360 个失真点云,涵盖了 GPCC octree、GPCC trisoup、VPCC 的 3 种编码失真和高斯失真下的几何或纹理单独失真以及双重失真. SJTU-PCQA 数据库由 9 个参考点云和 378 个失真点云组成,失真类型包含几何高斯噪声、颜色噪声、降尺度、八叉树压缩和混合失真. IRPC 数据库包括 6 个参考点云和 54 个失真点云,失真类型包括 PCL(Point Cloud Library)、MPEG GPCC 和 VPCC 的 3 种编码失真.

使用 Pearson 线性相关系数(PLCC)、Spearman 秩序相关系数(SROCC)、Kendall 等级相关系数(KROCC)和均方根误差(RMSE)来量化点云质量评价方法的性能. PLCC 衡量客观质量分数和主观质

量分数的相关性, SROCC 和 KROCC 反映单调一致性, RMSE 用于衡量分数之间绝对误差. 当 PLCC、SROCC 和 KROCC 越接近 1 并且 RMSE 越小时,客观质量分数与主观质量分数一致性越高,相应的质量评价方法性能越好. 实验采用 K-Fold 交叉验证,根据每个数据库的参考点云数设置 K 值,即 CPCD 2.0、SJTU-PCQA 和 IRPC 数据库 K 值分别为 10、9 和 6,以保证训练集和测试集没有重复. 采用 8:2 比例划分训练集和测试集,记录输出的平均评价指标结果用于表示点云质量评价方法的性能.

2.2 实验结果及分析

表 2 给出了本文方法关于 CPCD 2.0 数据库的消融实验的结果. 可以看出,从特征数量来说,多种特征的联合评价效果要优于单特征评价,说明 3D 与 2D 特征的结合、几何与彩色纹理特征的结合可以更加全面地对失真点云进行描述. 在特征属性方面,对比 3D 特征与 2D 特征指标可以发现 F_{2D} 要优于 F_{3D} ,说明一些 2D 特征通常能够更直观地反映点云的视觉质量问题. 处理后的 3D 点云数据比 2D 图像数据更稀疏,也就意味着在 3D 点云中的特征点数量相对较少,而 2D 图像通常具有更丰富的像素信息. 此结果导致在 3D 特征中信息不足,难以捕捉到足够多的细节和结构,从而影响特征的质量和性能. 因此本文将 3D 数据作为辅助增强特征. 在特征种类方面,在 3D、2D 特征类型各自对应的彩色纹理特征和几何特征中,彩色纹理特征性能明显更高,例如 $F_{tm} + F_{tg} + F_{tc} + F_{tp}$ 特征明显优于 $F_{gm} + F_{gp}$ 特征,这主要得益于彩色纹理特征可以提供更多的表面细节和纹理信息. 例如在点云中存在表面瑕疵、颜色错位或纹理断裂等问

表 2 CPCD 2.0 数据库下,本文方法单特征及特征组合的性能测试

特征提取域	特征类型	特征	PLCC	SROCC	KROCC	RMSE
3D	几何	F_{3g}	0.574 7	0.406 8	0.422 4	0.801 6
	彩色纹理	$F_{3l}+F_{3c}$	0.770 9	0.630 9	0.516 9	0.680 4
	3D 总体	F_{3D}	0.814 2	0.720 4	0.708 0	0.437 2
2D	几何	$F_{gm}+F_{gp}$	0.680 3	0.639 2	0.527 8	0.829 1
	彩色纹理	$F_{tm}+F_{tg}+F_{tc}+F_{tp}$	0.863 8	0.800 0	0.677 3	0.516 5
	联合	F_{gt}	0.820 5	0.783 0	0.652 1	0.558 6
	2D 总体	F_{2D}	0.878 1	0.827 9	0.708 1	0.500 0
本文算法(3D 特征+2D 特征)		F_{CPC}	0.896 2	0.830 3	0.737 0	0.462 0

注:表中加粗数字表示最优指标结果,下表同.

题时,彩色纹理特征比几何特征可以更容易地捕捉到这些问题.

为进一步验证本文方法的性能,将本文方法与其他方法在 CPCD 2.0、SJTU-PCQA、IRPC 数据库中进行对比,相关实验结果见表 3. CPCD 2.0 数据库采用最新的点云编解码器和高斯噪声进行失真模拟,考虑了几何与彩色纹理的单一或双重失真的影响,所提方法涉及点云的几何和彩色纹理以及两者的联合失真;SJTU-PCQA 数据库包含八叉树压缩、降尺度以及颜色与几何噪声,这些失真能较好地在二维投影中识别提取,所提方法中的感知特征也有利于失真的识别;而 IRPC 数据库只涉及点云的几何编码失真,只有在几何失真时才可以检测出失真信息,同时也证明了本文所提出的通用性.表中, Hausdorff、MSE、Mean 和 RMS 为不同的距离度量方法.由表可见,纯几何的质量评价方法指标不高,包括 Po2point^[4]、Po2plane^[5]、AS^[6]、PC-MSDM^[7]和 PointSSIM-G^[9]模型,原因是没有考虑点云的颜色信息,导致它们评价能力有限.与 PointSSIM-G 相比, PointSSIM-C^[9]模型评价更优,由于彩色纹理信息可以提供更多关于点云

质量的视觉信息,说明只利用彩色纹理特征进行评价比只利用几何特征进行评价更加有效.在投影方法中, VIFP^[13]相比于 MS-SSIM^[12]效果更好,同样体现出彩色纹理信息的重要性.在 CPCD 2.0 和 IRPC 数据库中, GraphSIM^[10]模型显示出较好的性能,但由于它是全参考方法,需要原始点云信息的支撑,而本文方法为无参考质量评价方法,能从不同特征提取角度出发,同时结合了点云三维与二维的几何和彩色纹理失真,具有更广阔的应用范围.

3 结论

本文提出了一种基于三维与二维联合的彩色点云无参考质量评价方法.在 3D 空间中,以点云的几何属性和颜色属性来描述点云失真.在 2D 投影图上描述联合失真、几何失真和彩色纹理失真:在联合失真方面,将几何信息和彩色纹理信息合并为四阶张量,利用张量分解提取联合特征;在几何失真方面,提取空间域和感知域的特征;在彩色纹理失真方面,从空间域提取相关特征,在变换域进行 curvelet 变换,以模拟人眼多尺度、多方向的

表 3 不同算法在 3 个数据库中的性能对比

类型	算法	CPCD 2.0 数据库				SJTU-PCQA 数据库				IRPC 数据库			
		PLCC	SROCC	KROCC	RMSE	PLCC	SROCC	KROCC	RMSE	PLCC	SROCC	KROCC	RMSE
全参考	Po2point_Hausdorff ^[4]	0.348 2	0.314 5	0.217 9	1.099 5	0.166 8	0.430 1	0.309 7	2.392 8	0.238 8	0.215 1	0.145 5	0.960 1
	Po2point_MSE ^[4]	0.678 4	0.549 1	0.414 2	0.861 7	0.472 1	0.409 6	0.285 7	2.139 4	0.335 7	0.328 1	0.214 6	0.931 3
	Po2plane_Hausdorff ^[5]	0.406 1	0.378 6	0.266 3	1.071 8	0.375 2	0.460 9	0.335 4	2.446 7	0.392 5	0.254 1	0.197 5	0.908 9
	Po2plane_MSE ^[5]	0.691 4	0.569 2	0.438 5	0.847 4	0.565 1	0.495 6	0.351 7	2.002 2	0.429 6	0.256 4	0.195 7	0.892 8
	AS_Mean ^[6]	0.437 6	0.404 4	0.275 2	1.054 6	0.657 1	0.518 7	0.362 4	1.829 3	0.156 9	0.112 3	0.066 9	0.976 4
	AS_RMS ^[6]	0.446 4	0.417 3	0.289 5	1.049 6	0.657 9	0.529 6	0.371 6	1.827 6	0.145 2	0.118 8	0.085 2	0.978 2
	AS_MSE ^[6]	0.447 2	0.417 3	0.289 5	1.049 1	0.658 1	0.529 6	0.371 6	1.827 2	0.153 6	0.118 8	0.085 2	0.990 2
	PC-MSDM ^[7]	0.625 4	0.532 1	0.384 2	0.915 2	0.412 3	0.324 1	0.218 9	2.211 0	0.272 9	0.151 9	0.106 3	0.951 5
	PointSSIM-G ^[9]	0.534 3	0.553 3	0.423 8	0.991 5	0.386 0	0.364 9	0.279 2	2.241 0	0.618 3	0.595 1	0.469 3	0.776 0
	PointSSIM-C ^[9]	0.745 7	0.689 1	0.486 3	0.781 4	0.456 1	0.418 5	0.317 2	2.159 8	0.664 8	0.563 8	0.421 1	0.737 6
	PCQM ^[8]	0.481 3	0.340 8	0.261 5	1.028 1	0.777 1	0.742 0	0.562 4	1.527 4	0.561 1	0.381 9	0.303 3	0.818 4
	GraphSIM ^[10]	0.855 3	0.829 6	0.623 4	0.607 7	0.890 0	0.880 0		1.130 0	0.940 0	0.760 0		0.210 0
	MS-SSIM ^[12]	0.621 2	0.568 6	0.414 0	0.919 2	0.743 3	0.720 1	0.525 0	1.623 4	0.328 0	0.116 4	0.069 7	0.934 0
	VIFP ^[13]	0.698 5	0.674 4	0.495 7	0.839 4	0.786 4	0.742 7	0.549 6	1.499 2	0.094 9	0.171 6	0.121 7	0.984 2
无参考	NR-3DQA ^[15]	0.672 4	0.647 3	0.471 6	0.861 5	0.729 4	0.688 7		1.805 9	0.879 1	0.816 7	0.707 1	0.381 0
	BQE-CVP ^[16]	0.795 0	0.789 0	0.598 3	0.721 8	0.919 2	0.897 2	0.734 3	0.971 7	0.726 5	0.729 8	0.542 7	0.658 6
	本文算法	0.896 2	0.830 3	0.737 0	0.462 0	0.916 8	0.871 6	0.763 2	0.691 5	0.864 0	0.689 2	0.781 4	0.287 2

感知方式, 并从感知域提取相关特征. 最后, 利用随机森林融合上述所有特征来进行点云质量预测. 在 CPCD 2.0、SJTU-PCQA 和 IRPC 数据库中进行了验证, 实验结果表明本文方法达到了较好的效果. 在今后工作中, 期待对点云不同类型失真进行识别, 以便更好地理解数据, 提取更适合的特征进行有针对性的质量评价, 从而更好地提高模型性能.

参考文献:

- [1] ABBASI R, BASHIR A K, ALYAMANI H J, et al. Lidar point cloud compression, processing and learning for autonomous driving[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(1):962-979.
- [2] GOU J J, ZHAO M M, WANG H Y, et al. DNN-based prediction of standard driving posture for vehicle takeover[J]. *IEEE Access*, 2023, 11:72874-72883.
- [3] ZHU L F, XIANG Y C, SONG A G. Visible patches for haptic rendering of point clouds[J]. *IEEE Transactions on Haptics*, 2022, 15(3):497-507.
- [4] MEKURIA R, LI Z, TULVAN C, et al. Evaluation criteria for point cloud compression[S/OL]. [2020-03-01]. ISO/IEC JTC1/SC29/WG11 MPEG, N16332, Geneva, Switzerland, 2016.
- [5] TIAN D, OCHIMIZU H, FENG C, et al. Geometric distortion metrics for point cloud compression[C]//2017 IEEE International Conference on Image Processing (ICIP). Beijing, China. IEEE, 2017:3460-3464.
- [6] ALEXIOU E, EBRAHIMI T. Point cloud quality assessment metric based on angular similarity[C]//2018 IEEE International Conference on Multimedia and Expo (ICME). San Diego, CA, USA. IEEE, 2018:1-6.
- [7] MEYNET G, DIGNE J, LAVOUÉ G. PC-MSDM: a quality metric for 3D point clouds[C]//2019 Eleventh International Conference on Quality of Multimedia Experience (QoMEX). Berlin, Germany. IEEE, 2019:1-3.
- [8] MEYNET G, NEHME Y, DIGNE J, et al. PCQM: a full-reference quality metric for colored 3D point clouds[C]//2020 Twelfth International Conference on Quality of Multimedia Experience (QoMEX). Athlone, Ireland. IEEE, 2020:1-6.
- [9] ALEXIOU E, EBRAHIMI T. Towards a point cloud structural similarity metric[C]//2020 IEEE International Conference on Multimedia & Expo Workshops (ICMEW). London, UK. IEEE, 2020:1-6.
- [10] YANG Q, MA Z, XU Y L, et al. Inferring point cloud quality via graph similarity[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(6): 3015-3029.
- [11] TORLIG E M, ALEXIOU E, FONSECA T A, et al. A novel methodology for quality assessment of voxelized point clouds[C]//Applications of Digital Image Processing XLI. San Diego, USA. SPIE, 2018, 10752: 174-190.
- [12] WANG Z, SIMONCELLI E P, BOVIK A C. Multiscale structural similarity for image quality assessment[C]//Asilomar Conference on Signals, Systems & Computers. Pacific Grove, CA, USA. IEEE, 2003:1398-1402.
- [13] SHEIKH H, BOVIK A C. Image information and visual quality[J]. *IEEE Transactions on Image Processing*, 2006, 15(2):430-444.
- [14] YANG Q, CHEN H, MA Z, et al. Predicting the perceptual quality of point cloud: a 3D-to-2D projection-based exploration[J]. *IEEE Transactions on Multimedia*, 2020, 23:3877-3891.
- [15] ZHANG Z C, SUN W, MIN X K, et al. No-reference quality assessment for 3D colored point cloud and mesh models[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2022, 32(11):7618-7631.
- [16] HUA L, JIANG G Y, YU M, et al. BQE-CVP: blind quality evaluator for colored point cloud based on visual perception[C]//2021 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting (BMSB). Chengdu, China. IEEE, 2021:1-6.
- [17] CHENG J, SU H, KORHONEN J. No-reference point cloud quality assessment via weighted patch quality prediction[EB/OL]. [2023-04-12]. arXiv: 2305.07829. <https://arxiv.org/pdf/2305.07829.pdf>.
- [18] GEUSEBROEK J M, VAN DEN BOOMGAARD R, SMEULDERS A W M, et al. Color invariance[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, 23(12):1338-1350.
- [19] DING J F, CHEN H, ZHOU J, et al. Point cloud objective recognition method combining SHOT features and ESF features[C]//2022 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery (CyberC). Suzhou, China. IEEE, 2022:267-274.
- [20] MATKOVIĆ K, NEUMANN L, NEUMANN A, et al. Global contrast factor: a new approach to image contrast [C]//Proceedings of the First Eurographics conference on Computational Aesthetics in Graphics, Visualization and Imaging. Girona, Spain. ACM, 2005:159-167.

- [21] SCHOLTE H S, GHEBREAB S, WALDORP L J, et al. Brain responses strongly correlate with Weibull image statistics when processing natural images[J]. *Journal of Vision*, 2009, 9(4):2910-2915.
- [22] FIELD D J. Relations between the statistics of natural images and the response properties of cortical cells[J]. *Journal of the Optical Society of America A, Optics and Image Science*, 1987, 4(12):2379-2394.
- [23] LUO W, WANG X G, TANG X O. Content-based photo quality assessment[C]//2011 International Conference on Computer Cision. Barcelona, Spain. IEEE, 2011:2206-2213.
- [24] HE K M, SUN J, TANG X O. Single image haze removal using dark channel prior[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(12):2341-2353.
- [25] HE Z Y, JIANG G Y, YU M, et al. TGP-PCQA: texture and geometry projection based quality assessment for colored point clouds[J]. *Journal of Visual Communication and Image Representation*, 2022, 83:103449.
- [26] JAVAHERI A, BRITES C, PEREIRA F, et al. Point cloud rendering after coding: impacts on subjective and objective quality[J]. *IEEE Transactions on Multimedia*, 2020, 23:4049-4064.

No-reference quality assessment method of color point cloud based on the combination of 3D and 2D information

LIU Jiayu¹, JIANG Zhidi², YU Mei¹

(1.Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo 315211, China;

2.College of Science and Technology Ningbo University, Ningbo 315300, China)

Abstract: As a carrier of 3D visual information, point clouds inevitably exhibit distortions that are introduced during their acquisition, transmission, and reconstruction, leading to a reduction in their visual quality. Therefore, it is necessary to effectively measure the quality of distorted point clouds. This paper proposes a no-reference quality assessment method of color point cloud based on the combination of 3D and 2D information, with which the geometric information and color texture information of point clouds in 3D and 2D spaces are extracted, respectively. To account for the combined distortion of geometry and color texture in point clouds, a tensor decomposition-based approach is applied to jointly analyze and extract features from the combination of these two projection maps. Considering the multi-directional and multi-scale perceptual characteristics of the human eye, a curvelet transform is used to extract features from the color texture projection map. Finally, a random forest pooling method is employed to predict the quality of color point clouds. Experimental results on three databases demonstrate that the proposed method outperforms some of the existing point cloud quality assessment methods, in that it shows better correlation between the predicted results and subjective quality assessment.

Key words: color point cloud; quality assessment; combination of 3D and 2D; perceptual feature

(责任编辑 章践立)