

DOI:10.16136/j.joel.2023.07.0360

基于引导调制的彩色点云无参考质量评价方法

郭小敏, 郁梅*, 宋洋, 蒋志迪

(宁波大学 信息科学与工程学院, 浙江 宁波 315211)

摘要: 彩色点云(color point cloud, CPC)作为三维场景和对象的有效描述形式,在虚拟现实、增强现实等许多领域得到重要应用。CPC在其采集、压缩、传输、重建等过程中会引入相应的失真,需要设计有效的评价方法对失真CPC质量进行评测。本文提出一种基于引导调制的CPC无参考质量评价方法。考虑到几何信息与彩色纹理信息的联合失真,利用引导调制的方法联立两者,以综合考虑几何失真、彩色纹理失真、联合失真。结合人眼的多通道性,利用剪切波变换提取特征。最后,将所有特征构成的特征向量输入到支持向量回归模型(support vector regression, SVR)学习预测点云质量。实验结果表明,所提出的方法与人类主观感知具有很好的一致性。

关键词: 彩色点云(CPC); 无参考质量评价; 引导调制; 剪切波变换

中图分类号: TP391 **文献标识码:** A **文章编号:** 1005-0086(2023)07-0713-10

CPC-GM: No-reference quality assessment method of color point cloud based on guided modulation

GUO Xiaomin, YU Mei*, SONG Yang, JIANG Zhidi

(Faculty of Information Science and Engineering, Ningbo University, Ningbo, Zhejiang 315211, China)

Abstract: As an effective description of 3D scenes and objects, color point clouds (CPCs) are widely used in many fields such as virtual reality and augmented reality. However, distortions will be introduced to CPC in the process of its collection, compression, transmission and reconstruction, so it is necessary to design an effective assessment method to evaluate the quality of distorted CPC. In this paper, a no-reference quality assessment method is proposed for CPC based on guided modulation. Considering the joint distortion of geometric information and color texture information, the guided modulation is used to combine them to comprehensively consider geometric distortion, color texture distortion and the joint distortion. Combined with the multi-channel characteristic of human eyes, Shearlet transform is used to extract features. Finally, the feature vector composed of all extracted features is inputted into the support vector regression (SVR) model to learn and predict the quality of point cloud. Experimental results show that the proposed method is well consistent with human subjective perception.

Key words: color point cloud (CPC); no-reference quality assessment; guided modulation; Shearlet transformation

0 引言

随着成像、图像处理和网络技术的快速发展,彩色点云(color point cloud, CPC)处理及其应用受到广泛关注。CPC由三维空间中的点集合及其相应的几何位置和视觉属性信息组成,能为用户提

供更真实的视觉信息和更好的沉浸体验^[1,2]。CPC的采集、处理、压缩、传输、重建等过程^[3-5]中会不可避免地引入失真,因此,如何准确评价CPC的视觉质量是优化点云处理算法、提升用户视觉体验质量的关键。

CPC质量评价可通过主观评价和客观评价方

* E-mail: yumei2@126.com

收稿日期:2022-05-16 修订日期:2022-08-15

基金项目:国家自然科学基金项目(62071266)、浙江省自然科学基金项目(LY21F010003)资助项目

式来实现。主观评价方式准确性高,但对实验环境与设备等要求高,且耗时费力、难以应用于实时系统。客观质量评价方式通过模拟人类视觉系统(human visual system, HVS)对点云视觉质量进行建模,能够更好地适用于实际应用。根据特征属性,现有点云客观质量评价方法分为基于几何特征、基于几何与彩色纹理特征等。

基于几何特征点云客观质量评价方法主要考虑点云的几何失真,提取其几何信息的特征进行客观质量评价模型设计。从全参考质量评价的角度,人们设计了 point-to-point 模型^[6]、point-to-plane 模型^[7]和 plane-to-plane 模型^[7],并应用于点云压缩等。point-to-point 模型利用参考点云与失真点云间的点对点距离描述点云的失真程度,point-to-plane 模型利用参考点云与失真点云间的点对面距离来描述点云的失真程度,而 plane-to-plane 模型使用欧几里德距离计算最近邻关联点切面之间的角度相似性特征以实现失真点云的质量评价。考虑到曲率能够反映点云的几何失真,MEYNET 等^[8]将为三维网格设计的网格结构变形扩展到点云,提出了一种基于局部曲率统计的全参考点云质量评价方法,称为 PC-MSDM。这些方法都是基于几何误差的全参考质量评价方法,容易受到点云的平移或缩放变形影响。针对这一问题,JAVAHERI 等^[9]分别提出了基于改进的峰值信噪比、广义 Hausdorff 距离^[10]和 Mahalanobis 距离^[11]等点云几何质量评价方法。

为了进一步提高质量评价方法的准确性,许多研究团队将重点转移至基于几何与彩色纹理属性的点云客观质量评价方法上。MEYNET 等^[12]将几何和颜色特征进行最优线性加权组合提出了 PCQM。该方法将曲率和 5 种与亮度、色度、色调相关的颜色特征相结合对点云进行质量评价。HUA 等^[13]结合 CPC 的几何和纹理信息利用形心距离作为指标对点云进行质量评价。考虑到局部显著相似性,YANG 等^[14]对参考点云重新采样以提取关键点,构建以关键点为中心的局部图,并聚合颜色梯度特征提出了基于图相似的点云质量评价方法。HE 等^[15]在投影域结合几何特征与纹理特征来对点云进行质量评价。为了减少视图投影带来的遮挡,WU 等^[16]通过面片生成,提出了基于面片投影的点云质量评价方法。以上均为点云全参考质量评价方法,而点云无参考质量评价的研究还处于初步阶段。ZHANG 等^[17]把点云投影用于无参考质量评价,将三维模型从三维空间投影到质量相关的几何特征域和颜色特征域,但其

没有考虑到几何信息与彩色纹理信息间的相互作用。HUA 等^[18]结合视觉掩蔽效应对点云进行区域分割,提出了基于视觉感知的点云无参考质量评价方法。

几何属性与彩色纹理属性的结合能够提升点云质量评价方法的性能。从编码角度来说,点云的几何编码参数会影响到其纹理的视觉感知^[3];从人眼视觉特性^[19]角度,点云的几何失真与彩色纹理失真之间可能会相互作用并影响用户视觉感知,造成视觉掩蔽效应。因此,单一地考虑几何、彩色纹理失真或者简单地聚合两类失真可能会忽略联合失真。

在此背景下,本文提出采用引导调制的方法融合几何信息与彩色纹理信息,综合考虑几何失真、彩色纹理失真、联合失真来进行点云质量评价。在所提出的基于引导调制的 CPC 无参考质量评价方法中,针对点云失真程度大小极大地依赖于观看分辨率,提出使用多尺度分解的方法来模拟不同分辨率下的失真情况;考虑到分别从颜色 3 通道提取特征忽略了颜色通道的相关性,通过将颜色空间转换到矢量空间来进行纹理特征提取;针对联合失真,使用 1 个调制函数将 6 面正交投影后的几何投影图与纹理投影图调制成联合投影图,在联合投影图中结合人眼视觉感知特性进行联合特征提取。

1 本文方法

基于以上分析,从几何失真、彩色纹理失真、几何与纹理联合失真进行考虑,提出了基于引导调制的无参考 CPC 质量评价方法,简称 CPC-GM。所提方法如图 1 所示,主要包含联合特征提取模块、几何特征提取模块、彩色纹理特征提取模块。针对点云的几何失真与彩色失真相互作用对视觉质量的影响,联合特征提取模块利用引导函数构造联合投影图并结合人眼显著特性进行权重分配来提取联合特征。针对点云的几何失真,几何特征提取模块结合人眼特性利用剪切波多尺度多方向分解来提取几何特征。针对点云的彩色失真,彩色纹理特征提取模块通过构造颜色矢量空间来关联颜色通道,在矢量空间中描述彩色纹理失真。最后,将提取的联合特征、几何特征和颜色特征构成失真 CPC 的特征向量,通过支持向量回归模型(support vector regression, SVR)训练学习得到预测质量模型,以对失真 CPC 质量进行评价。

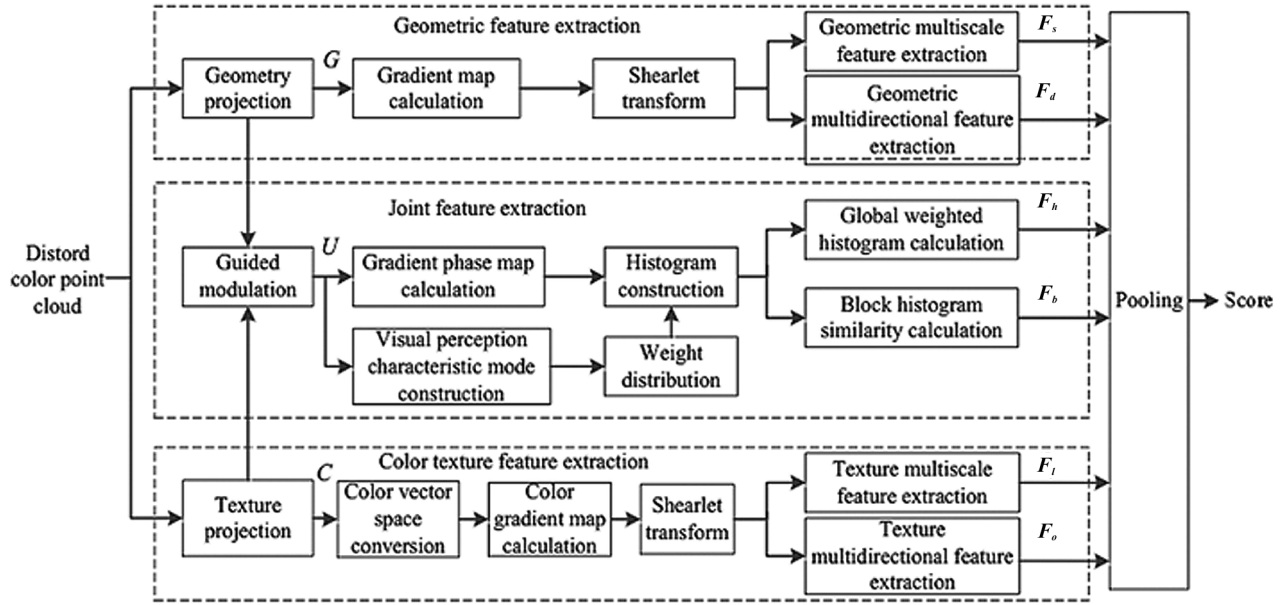


图 1 基于引导调制的彩色点云无参考质量评价方法框图

Fig. 1 Framework of no-reference quality assessment of color point cloud based on guided modulation

1.1 联合特征提取模块

给定一个失真 CPCP, 它由带有空间位置信息 (x, y, z) 和颜色信息 (R, G, B) 的点组成。使用 6 面正交投影^[20]的方法将体素化后的 CPC 投影到立方体 6 个子平面上, 得到带有颜色信息的彩色纹理投影图与带有深度信息的几何投影图。令 C_i 表示 6 个面的彩色纹理投影子图, G_i 表示 6 个面的几何投影子图, $i=1, 2, \dots, 6$ 。投影过程表示如下:

$$P_v(v_x, v_y, v_z, v_r, v_g, v_b) = H(P(x, y, z, R, G, B)), \quad (1)$$

$$C_i = \xi_{\alpha, \beta}(P_v(v_r, v_g, v_b)), \quad (2)$$

$$G_i = \psi_{\alpha, \beta}(P_v(v_x, v_y, v_z)), \quad (3)$$

式中, P_v 为体素转换函数 H 体素化后的点云, (v_x, v_y, v_z) 和 (v_r, v_g, v_b) 分别为体素的空间位置信息和颜色信息, $\xi_{\alpha, \beta}$ 与 $\psi_{\alpha, \beta}$ 分别表示彩色纹理与几何投影操作, 在正交方向上依次选择 6 个角度 (α, β) 投影得到投影子图。旋转角度 $(\alpha, \beta) = \{(0, 0), (0, \pi/2), (0, \pi), (0, -\pi/2), (\pi/2, 0), (-\pi/2, 0)\}$ 。图 2 给出了 CPCD2.0 数据库^[16]中 longdress 模型的投影图示例, 6 个子平面合并的投影图表示为 $C_i = \{C_1, \dots, C_6\}$ 和 $G_i = \{G_1, \dots, G_6\}$ 。

引导滤波器^[21]通过在引导图计算权重自适应地对目标图进行滤波, 可以很好地保留图像细节和边缘轮廓信息, 它广泛应用于图像增强与图像融合领域。考虑到几何投影图与彩色纹理图无法充分反映

联合失真信息, 利用引导滤波融合图像的思想将彩色纹理投影图作为引导对几何投影图进行滤波, 从而得到联合投影图。通过引导调制, 可得到 6 个子平面的联合投影图, 记为 $U_i = \{U_1, \dots, U_6\}$ 。 U_i 在以像素点 k 为中心的窗口 ω_k 处的计算如下:

$$U_{i,j} = a_k C_{i,j} + b_k, \quad \forall j \in \omega_k, \quad (4)$$

$$a_k = \frac{1}{|\omega|} \sum_{j \in \omega_k} C_{i,j} G_{i,j} - \mu_k^c \mu_k^g, \quad (5)$$

$$b_k = \mu_k^g - a_k \mu_k^c, \quad (6)$$

式中, μ_k^c 与 σ_k^2 分别为 C_i 在窗口 ω_k 中的均值与方差, $|\omega|$ 为 ω_k 中的像素个数, μ_k^g 为 G_i 在窗口 ω_k 中的均值, $\epsilon = 10^{-8}$, 防止分母为 0。

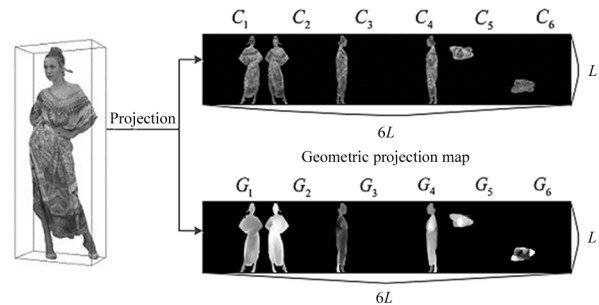


图 2 彩色点云的 6 面彩色纹理投影图和 6 面几何投影图

Fig. 2 Six color texture projection maps and six geometric projection maps of CPC

图3给出了CPCD2.0数据库^[16]中longdress模型正视图的引导调制结果,图中3行分别为彩色纹理投影图、几何投影图、联合投影图。图3(a)为不同失真类型点云投影以及引导调制的结果,图3(b)为对应结果的局部放大图,第1列为原始点云模型,其他列依次为GPCC1、GPCC2、VPCC编码失真模型和高斯噪声失真模型。其中,GPCC1与GPCC2是基于几何的点云压缩标准(geometry-based point cloud compression, G-PCC)^[4]分别利用八叉树形式编码与三态谐波Trisoup编码产生的失真。GPCC1失真表现为规则的网格状失真,GPCC2失真表现为三角形空洞。VPCC是基于视频的点云压缩标准(video-based point cloud compression, V-PCC)^[5]编码产生的失真,表现为裂纹与边缘锯齿状。GG是高斯噪声

引入的失真,表现为噪声点。从图3可以看到,联合投影的亮度有所变化,这主要是融入了几何投影图中的深度信息,亮度越大深度越小。

将得到的联合投影图求取梯度的幅值图与相位图后进行分块,构建每个块的直方图,然后结合视觉感知模型进行加权得到加权方向梯度直方图。首先,利用Prewitt算子在每个联合投影平面 $U_i = \{U_1, \dots, U_6\}$ 计算的梯度幅值与相位。在 $-180^\circ - 180^\circ$ 之间等间距划分9个区间,对不同相位对应的梯度幅度进行直方图统计构建基于块的直方图。再利用视觉显著模型^[22]所得到的显著权值 ω_q 对不同块中的直方图进行加权得到加权方向梯度直方图:

$$F_h = \sum \omega_q H_q, \quad (7)$$

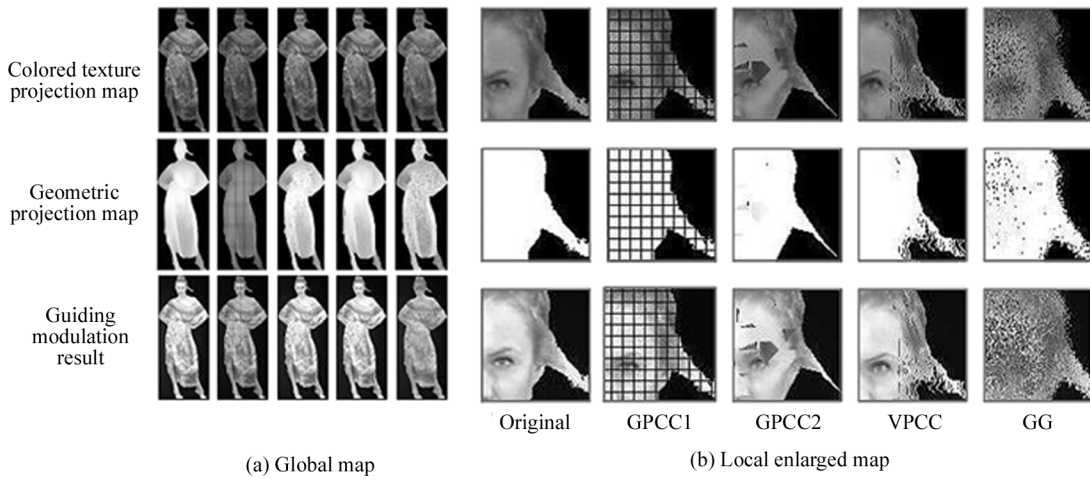


图3 彩色点云的投影图和引导调制结果

Fig. 3 Projection map and guided modulation result of CPC

$$\omega_q = Z_q/Z, \quad (8)$$

$$F_b(p, q) = \frac{2H_q H_p + \epsilon}{H_q^2 + H_p^2 + \epsilon}, \quad (9)$$

式中, p 与 q 为块索引且 $p \neq q$, $\epsilon = 10^{-8}$, H_p 和 H_q 分别为第 p 、 q 个块中的直方图, ω_q 为第 q 个块中显著图均值 Z_q 与整体显著图均值 Z 的比值, F_b 为任意两个块的相似性, F_h 为加权方向梯度直方图。为了去除大面积黑色背景的影响,当分块中的像素值均为0时,不计入统计。最后,利用加权方向梯度直方图 F_h 和块相似性的均值 μ 、标准差 σ 、斜度 ρ 、峰度 τ 作为联合特征,表示 $F_j = (F_h, \mu, \sigma, \rho, \tau)$ 。

以CPCD2.0数据库中longdress模型正视图为例,图4为不同失真模型的加权方向梯度直方图分布。图中Low、Medium、High表示对应的模型的质量,即每一列从上至下失真程度依次减小,横坐标为

$-180^\circ - 180^\circ$ 之间等间距划分的9个区间。从图4可以看出,编码失真模型的加权方向梯度直方图分布大致表现为第3、5、7个区间(对应于 $[-100^\circ, -60^\circ]$ 、 $[-20^\circ, 20^\circ]$ 、 $[60^\circ, 100^\circ]$)的梯度幅度相比较于原始点云增加而在其他角度的梯度幅度减少,并且失真程度越小,幅值的增减幅度越小。由于失真产生的原因不同,编码失真模型与噪声失真模型直方图分布差异较大。

1.2 几何特征提取模块

为了描述几何失真,利用Prewitt算子求取梯度的方法对几何投影图进行预处理。考虑到点云失真程度与观看的分辨率有关,并且人眼对于不同方向信息的感受具有差别,因此在变换域实施多尺度多方向分解进行几何特征提取。剪切波变换为多维数据和多尺度的各向异性信息提供了稀疏表示,可以

提供精确的信号奇异性检测^[23]。在此使用剪切波变换提取了几何尺度特征以及几何方向特征。在二维空间中,剪切波变换的定义表示为:

$$S(r, d, l) = \langle f, \Psi_{r,d,l} \rangle, \quad (10)$$

$$\Psi_{r,d,l} = |\det M_{r,d}|^{-1/2} \Psi(M_{r,d}^{-1}(x - l)), \quad (11)$$

式中, S 表示剪切波变换的系数, r, d 和 l 分别表示剪切波变换的尺度参数、方向参数和平移参数, f 表示需要进行剪切波变换的函数, $\Psi_{r,d,l}$ 表示剪切波, M 为膨胀矩阵与剪切矩阵的乘积。若方向向量为 $d = [d_1, d_2, \dots, d_r]$, 尺度 r 上水平锥和垂直锥各有 $2 \times 2^{dr} + 1$ 个方向。在此进行四尺度分解, 方向向量

对梯度图进行四尺度分解, 分析子带系数的分布, 设置为 $d = [1, 1, 1, 1]$, 则可得到总方向数为 40。针对剪切波变换所得的子带系数, 利用归一化子带系数振幅(normalized sum of subband coefficient amplitudes, SSCA)进行分析, SSCA 的计算方式如下:

$$M(r, d) = \frac{\sum_l |S(r, d, l)|}{\max(\sum_l |S(r, d, l)|)}. \quad (12)$$

以 CPCD2.0 数据库中 longdress 模型正视图为例, 图 5 为不同失真类型点云在精细层中不同方向的 SSCA 分布。图 5(a)、图 5(b)、图 5(c)和图 5(d)分别为 GPCC1、GPCC2、VPCC 和高斯噪声失真模型

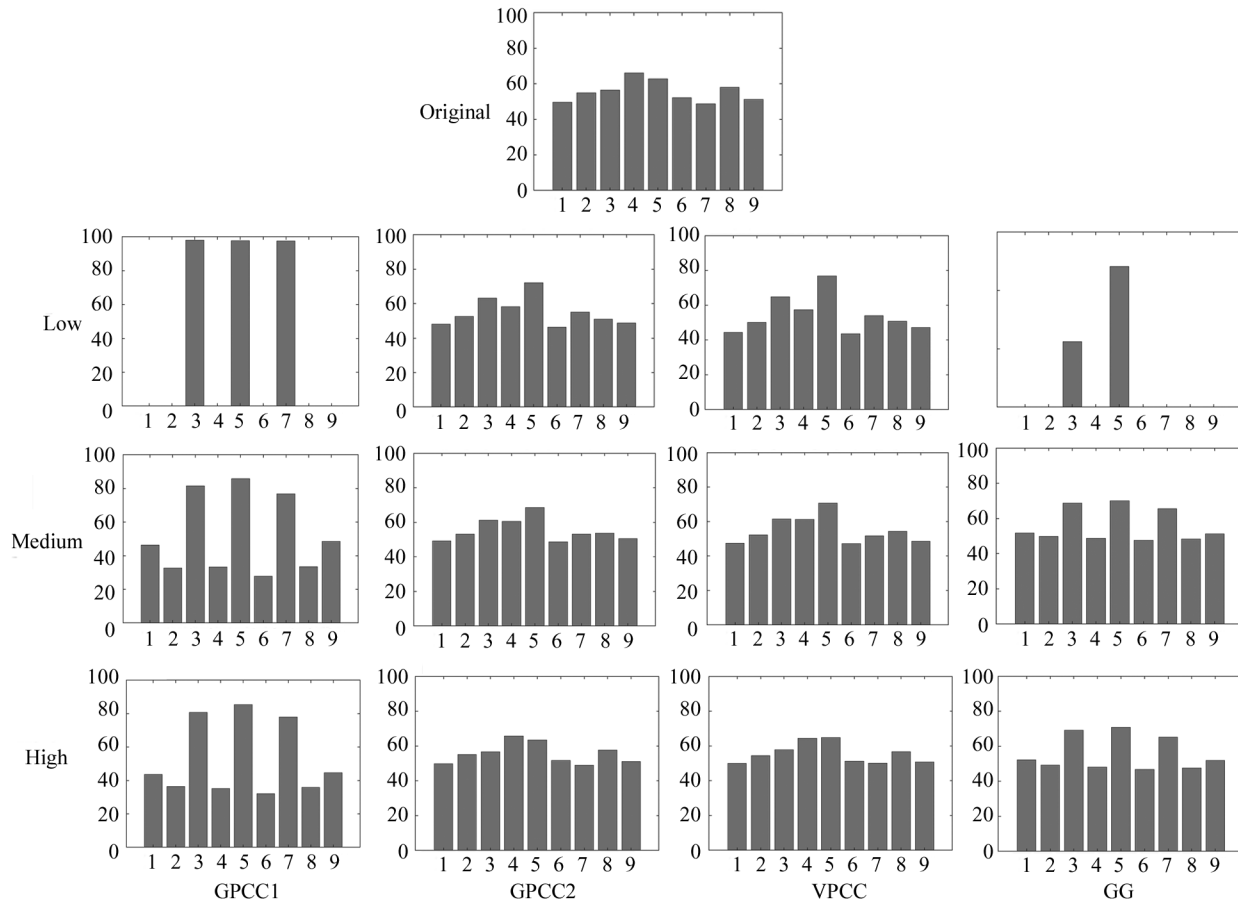


图 4 不同失真类型彩色点云的加权梯度直方图分布

Fig. 4 Histogram distribution of weighted directional gradient for different distorted color point cloud

SSCA 分布。横坐标为不同方向, 为了更清楚地观察子带系数的变化, 将纵坐标设置为归一化子带系数振幅取对数(log of SSCA, LSSCA)。图例中的 L、M、H 表示图像质量低、中、高。从图 5 可以看出, 不同类型的编码失真模型的 SSCA 分布大多会出现双峰, 且双峰的位置均在第 3 个方向(垂直方向)和第 8 个方向(水平方向), 而且失真越大峰值越小。这主要由于人眼视觉关注方向主要为水平、垂直方向, 故

失真与未失真点云投影图在水平、垂直方向上的 SSCA 系数变化最大。GPCC1 失真模型的失真表现为网格状失真, 像素缺失主要发生在水平、垂直方向上, 当失真程度较大时, SSCA 在水平和垂直方向上的峰值差异较大甚至出现峰谷。GPCC2、VPCC 失真不具有规则性, 故在特征各个方向上均有变化。而高斯噪声主要表现为噪声, 在深度信息上的变化较少, 故 SSCA 系数在不同方向上差异较小。根据

图5大致可以得出结论:这3种编码失真模型的SSCA分布大多会出现双峰且失真程度越大峰值越小。基于以上分析,使用不同尺度上的SSCA作为几何尺度特征,记为 F_s 。由于失真主要发生在剪切波的

精细层,故使用精细层上不同方向上的SSCA作为几何方向特征,记为 F_d 。最终,利用几何方向特征 F_d 的峰值 τ_1 与标准差 σ_1 和尺度特征 F_s 作为几何特征,几何投影图的几何特征表示为 $F_G = (\tau_1, \sigma_1, F_s)$ 。

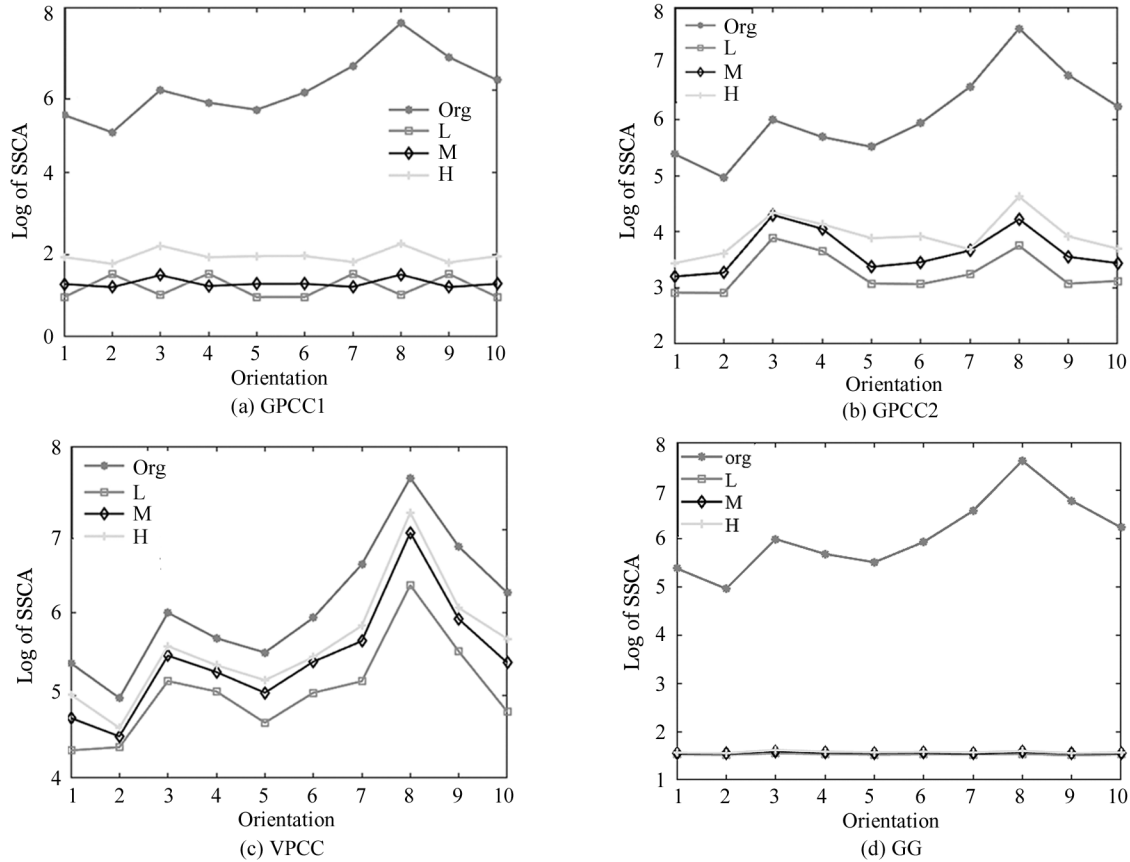


图5 不同失真类型彩色点云几何投影图的LSSCA系数分布

Fig. 5 The distribution of LSSCA coefficients of CPC geometric gradient map in different distortion types

1.3 纹理特征提取模块

考虑到分别从RGB颜色3通道进行特征提取忽略了颜色通道间的关联性,将6面投影得到的彩色纹理投影子图转换到了矢量空间。在矢量空间中,求取颜色梯度图后利用剪切波变换对其进行多尺度多方向分解。设 r, g, b 为RGB颜色空间 r, g, b 轴上的单位向量,定义向量构造颜色矢量空间:

$$u = \frac{\partial R}{\partial x} r + \frac{\partial G}{\partial x} g + \frac{\partial B}{\partial x} b, \quad (13)$$

$$v = \frac{\partial R}{\partial y} r + \frac{\partial G}{\partial y} g + \frac{\partial B}{\partial y} b. \quad (14)$$

彩色纹理投影图 $C_i (i=1, 2, \dots, 6)$ 在像素点 (m, n) 的颜色梯度幅值 $G_i(m, n)$ 与相位 $\beta_i(m, n)$ 为:

$$\beta_i(x, y) = \arctan\left(\frac{2v^T v}{u^T u - v^T v}\right), \quad (15)$$

$$G_i(x, y) = \{[(u^T u + v^T v) + (u^T u - v^T v) \times$$

$$\cos\beta(x, y) + 2u^T v \times \sin\beta(x, y)]/2\}^{1/2}. \quad (16)$$

在颜色梯度图上进行剪切波变换,得到40个子带。图6为点云彩色纹理投影图的颜色梯度图在精细层中不同方向的SSCA分布,从图6可以看出,不同失真类型模型的SSCA分布大多会出现双峰并且双峰的位置均在第3个方向(垂直方向)和第8个方向(水平方向)。而对于图6(b)、图6(c)对应的GPCC2、VPCC失真模型的SSCA均分布在原始点云模型的SSCA之上,这主要是因为针对这两种编码的几何量化参数和纹理量化参数设置之间存在影响,故在彩色纹理投影图中除了纹理失真外可能还含有部分几何失真。基于以上分析,使用不同尺度上的SSCA作为纹理尺度特征,用 F_l 表示。使用精细层上不同方向上的SSCA作为纹理方向特征,用 F_o 表示。最终,利用 F_o 的峰值 τ_2 与标准差 σ_2 和 F_l 作为彩色纹理特征,表示为 $F_C = (\tau_2, \sigma_2, F_l)$ 。

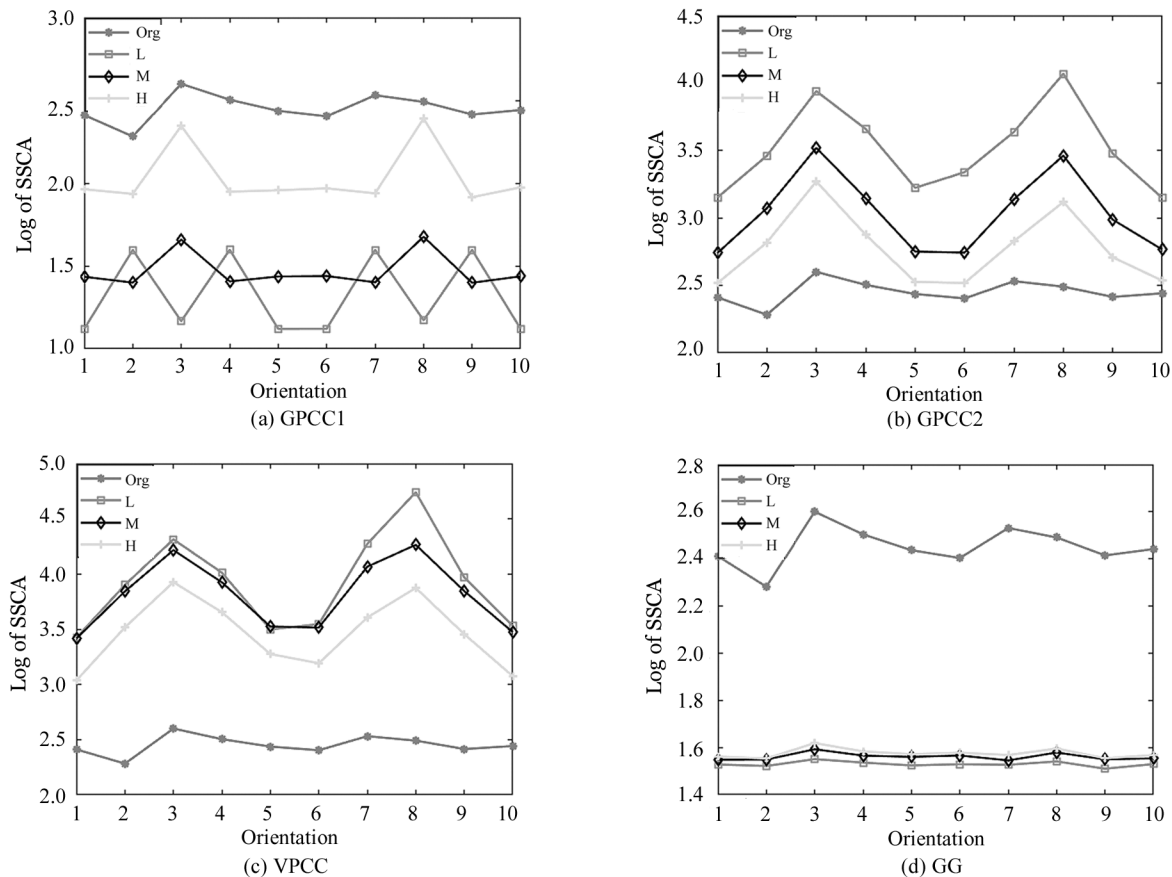


图 6 不同失真类型彩色点云彩色纹理投影图的 LSSCA 系数分布

Fig. 6 The distribution of LSSCA coefficients of CPC color gradient map in different distortion types

1.4 特征池化

以上所有的特征都是在 6 个投影子平面上提取的,得到的初始特征向量为 $F = (F_G, F_J, F_C)$ 。考虑到人眼对于不同投影面的关注度不同,文献[20]对“背面”、“正面”、“右侧面”、“左侧面”、“顶部”、“底部”分配权重为 $[0.2, 0.5, 0.1, 0.1, 0.05, 0.05]$ 。加权后,得到共计 25 维特征向量 F 。最后,使用 SVR 对提取的特征进行池化得到点云质量预测分数 Q 。

2 实验结果与分析

为了验证本文方法的有效性,在 CPCD2.0^[16]、SJTU-PCQA^[20]与 IRPC^[24] CPC 数据库上进行性能评估。CPCD2.0 数据库包括 10 个参考点云与 360 个失真点云,失真类型包含编码失真与高斯噪声下的几何失真、纹理失真以及双重失真。SJTU-PCQA 包含 9 个参考点云与 378 个失真点云,失真类型包括八叉树压缩、降尺度、高斯噪声以及降尺度与噪声的双重失真。IRPC 数据库包括 6 个参考点云与 54 个失真点云,失真类型包含 3 种不同的编码失真。

利用数据库中提供的主观分数与所得的客观分数进行相关性分析,用于评价模型的性能评估。在评价模型的训练与测试阶段,随机选取数据库中 80% 参考 CPC 所对应的失真 CPC 以及剩余的 20% 失真 CPC 分别用于训练与测试。该过程重复 1000 次以获得较稳定的性能结果,选取中值作为最终的性能指标。首先,在 CPCD2.0 数据库中验证了不同特征的性能,实验结果如表 1 所示。从表 1 可以看出:联合特征的性能最好、彩色纹理特征的性能次之、几何特征性能最差。单一的特征性能有限,在进行特征提取时应该考虑多方面信息。

表 2 显示了本文方法针对 CPCD2.0 数据库中不同失真类型的性能。由表 2 可以看出,本文方法对于 VPCC 失真的性能最好,而对 GPCC2 失真的性能最差。这与前面分析特征的结果一致,VPCC 失真等级变化与特征差异变化最为符合、GPCC2 稍有差异。而 GPCC1 与高斯噪声失真表现相对简单,故本文方法对于这两种失真也具有较好的衡量效果。

表1 不同特征在CPCD2.0数据库上的性能

Tab.1 Performance of different feature on CPCD2.0

Feature-types	Features	PLCC	SROCC	KROCC	RMSE
Geometry	F_s	0.6074	0.4996	0.3604	0.9250
	F_d	0.5769	0.4580	0.3283	0.9522
	F_G	0.6524	0.5845	0.4294	0.8860
Color	F_l	0.4586	0.2924	0.2054	1.0345
	F_o	0.6540	0.6041	0.4241	0.8804
	F_C	0.7059	0.6466	0.4680	0.8251
Joint	F_J	0.8013	0.7612	0.6373	0.6153
All	F	0.8564	0.8343	0.6427	0.5992

为了进一步验证本文方法CPC-GM的有效性,将本文方法和其他现有方法分别在CPCD2.0、SJTU-PCQA、IRPC数据库上进行了对比,实验结果如表3所示。其中,PC-MSDM^[8]、P2point^[6]、P2plane^[7]、plane-to-plane^[7]、PointSSIM-geometry^[25]都是在三维空间中描述几何失真的点云质量评价方法,这类算法很好地描述了失真带来的点偏移问题,但由于没有考虑颜色信息导致这类方法的性能有限。PointSSIM-color^[25]是在三维空间中描述彩色纹理失真的点云质量评价方法,对比PointSSIM-color与PointSSIM-geometry发现单一彩色纹理特征性能要优于单一几何特征性能。这也充分说明了人眼视觉

表2 关于CPCD2.0数据库中不同失真类型的性能

Tab.2 Performance of different distorted types in CPCD2.0

Distorted-types	PLCC	SROCC	KROCC	RMSE
GPCC1	0.8073	0.7405	0.5556	0.7919
GPCC2	0.6875	0.6043	0.4276	0.7123
VPCC	0.8800	0.8004	0.6164	0.5103
GG	0.8556	0.7687	0.5902	0.4650
All	0.8564	0.8343	0.6427	0.5992

对于彩色纹理信息的关注度。PCQM^[12]、GraphSIM^[14]、PCMRR^[26]都是在三维空间中描述几何失真与彩色纹理失真的点云质量评价方法,NR-3DQA^[17]是在投影域中描述几何失真与彩色纹理失真的无参考点云质量评价方法。对比表中数据发现,本文方法在3个数据库中都达到了较好的效果,结合人类视觉特性综合考虑多方面的失真信息能够大大提升质量评价方法的有效性。对比SJTU-PCQA数据库上的实验结果发现,BEQ-CVP^[18]的PLCC、SROCC、RMSE达到了0.9192、0.8972、0.9717,而本文方法的指标为0.8402、0.8093、1.2710。这主要是因为SJTU-PCQA的失真类型包括八叉树压缩、降尺度、高斯噪声以及降尺度与噪声的双重失真,不带有编码失真,而本文方法主要是面向编码失真和高斯噪

表3 不同算法在3个数据库上的性能对比

Tab.3 Performance comparison of different methods on three databases

Reference	Metric	CPCD2.0				SJTU-PCQA				IRPC			
		PLCC	SROCC	KROCC	RMSE	PLCC	SROCC	KROCC	RMSE	PLCC	SROCC	KROCC	RMSE
Full-reference	P2point_Hausdorff ^[6]	0.3482	0.3145	0.2179	1.0995	0.1668	0.4301	0.3097	2.3928	0.2388	0.2151	0.1455	0.9601
	P2point_MSE ^[6]	0.6784	0.5491	0.4142	0.8617	0.4721	0.4096	0.2857	2.1394	0.3357	0.3281	0.2146	0.9313
	P2plane_Hausdorff ^[7]	0.4061	0.3786	0.2663	1.0718	0.3752	0.4609	0.3354	2.4467	0.3925	0.2541	0.1975	0.9089
	P2plane_MSE ^[7]	0.6914	0.5692	0.4385	0.8474	0.5651	0.4956	0.3517	2.0022	0.4296	0.2564	0.1957	0.8928
	plane-to-plane_Mean ^[7]	0.4376	0.4044	0.2752	1.0546	0.6571	0.5187	0.3624	1.8293	0.1569	0.1123	0.0669	0.9764
	plane-to-plane_RMS ^[7]	0.4464	0.4173	0.2895	1.0496	0.6579	0.5296	0.3716	1.8276	0.1452	0.1188	0.0852	0.9782
	plane-to-plane_MSE ^[7]	0.4472	0.4173	0.2895	1.0491	0.6581	0.5296	0.3716	1.8272	0.1536	0.1188	0.0852	0.9902
	PC-MSDM ^[8]	0.6254	0.5321	0.3842	0.9152	0.4123	0.3241	0.2189	2.2110	0.2729	0.1519	0.1063	0.9515
	PointSSIM-geometry ^[25]	0.5343	0.5533	0.4238	0.9915	0.3860	0.3649	0.2792	2.2410	0.6183	0.5951	0.4693	0.7760
	PointSSIM-color ^[25]	0.7457	0.6891	0.4863	0.7814	0.4561	0.4185	0.3172	2.1598	0.6648	0.5638	0.4211	0.7376
Reduced-reference	PCQM ^[12]	0.4813	0.3408	0.2615	1.0281	0.7771	0.7420	0.5624	1.5274	0.5611	0.3819	0.3033	0.8184
	GraphSIM ^[14]	0.8553	0.8296	0.6234	0.6077	0.8900	0.8800	—	1.1300	0.9400	0.7600	—	0.2100
	PCMRR ^[26]	0.5372	0.7215	0.5357	1.1463	0.8200	0.8210	—	—	0.3020	0.4340	—	—
	NR-3DQA ^[17]	0.6724	0.6473	0.4716	0.8615	0.7294	0.6887	—	1.8059	0.8791	0.8167	0.7071	0.3810
	BEQ-CVP ^[18]	0.7950	0.7890	0.5983	0.7218	0.9192	0.8972	0.7343	0.9717	0.7265	0.7298	0.5427	0.6586
	CPC-GM	0.8564	0.8343	0.6427	0.5992	0.8402	0.8093	0.6237	1.2710	0.9678	0.8286	0.7333	0.1787

声。对比 CPCD2.0 和 IRPC 数据库中的实验结果发现,本文方法的指标相对更好,这在一定程度上说明了其有效性。为进一步说明本文方法预测的合理

性,给出了部分方法与所提方法在 CPCD2.0 数据库上的预测分数与 MOS 值的散点图,如图 7 所示。从图 7 中可以看出,所提算法的质量预测分数与 MOS

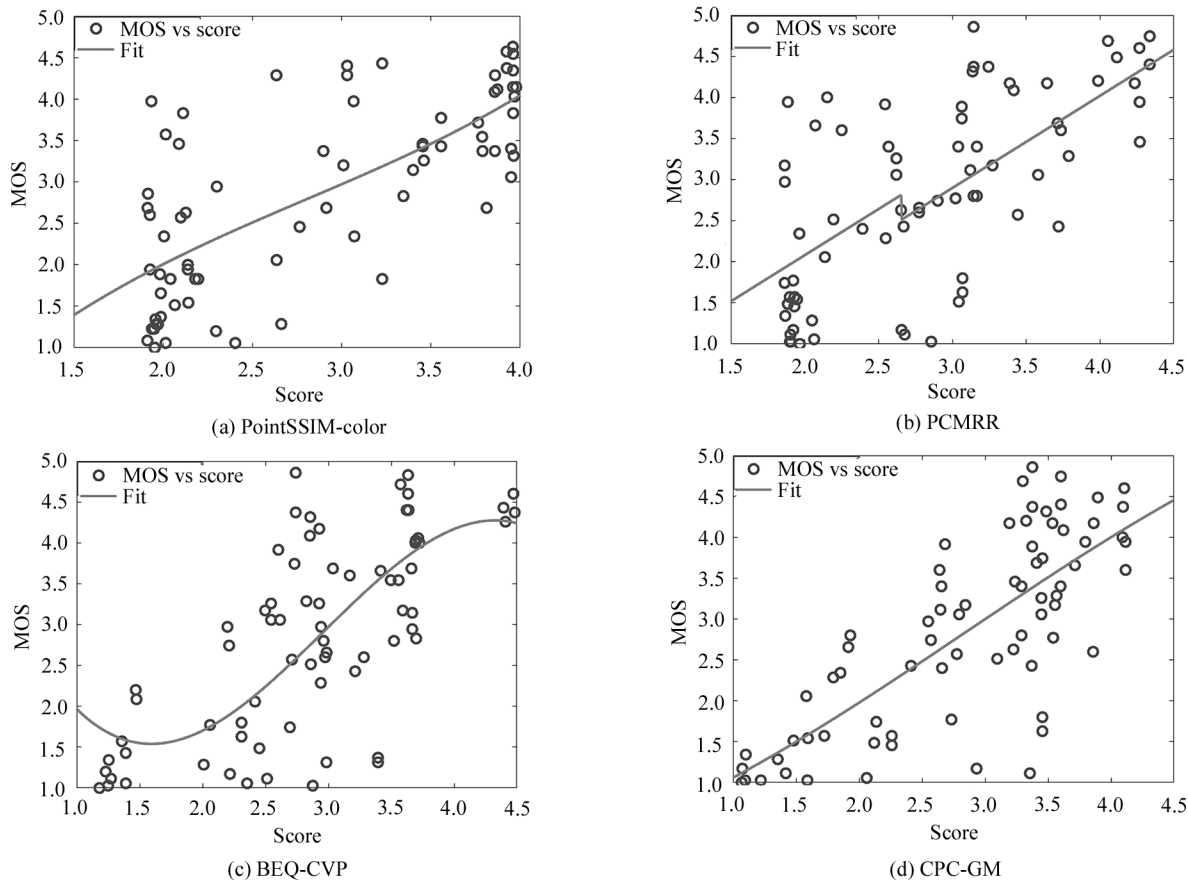


图 7 CPCD2.0 数据库上本文方法 CPC-GM 与对比算法的散点图

Fig. 7 Scatter diagram of the proposed CPC-GM and comparison methods on CPCD2.0

具有更好的线性性和相关性。

3 结论

本文提出了一种基于引导调制的无参考点云质量评价方法,称为 CPC-GM。提出使用引导调制的方法来融合点云的几何信息与彩色纹理信息,通过表征几何失真、彩色纹理失真、联合失真来对点云进行质量评价。在几何失真方面,采用多尺度多方向剪切波变换来模拟人眼的多通道特性进行特征提取。在彩色纹理失真方面,考虑到从 RGB 颜色 3 通道提取特征忽略了颜色通道的相关性,利用颜色矢量空间构造来联立颜色通道进行彩色纹理失真描述。在联合失真方面,结合视觉感知模型从局部与全局来描述失真。最后,利用 SVR 融合所提取的几何特征、彩色纹理特征、联合特征来预测点云质量。在 CPCD2.0、SJTU-PCQA、IRPC 数据库上进行了

验证,实验结果表明本文提出的 CPC-GM 方法达到了较好的效果。在今后的工作中,将重点关注点云的不同失真类型,深入探索针对特定失真类型点云的质量评价方法。

参考文献:

- [1] LIU B Y, BI X W, GU L J. 3D point cloud construction and display based on LiDAR[C]//2022 2nd International Conference on Computer, Control and Robotics, March 18-20, 2022, Shanghai, China. New York: IEEE, 2022: 268-272.
- [2] ZHANG D B, LU X Q, QIN H, et al. Pointfilter: point cloud filtering via encoder-decoder modeling[J]. IEEE Transactions on Visualization and Computer Graphics, 2021, 27(3): 2015-2027.
- [3] 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.
- [4] CUI L, MEKURIA R, PREDA M, et al. Point cloud compression: moving picture experts group's new standard[J]. IEEE Consumer Electronics Magazine, 2019, 8(4): 17-21.
- [5] JANG E, PREDA M, MAMMOU K, et al. Video based point-cloud-compression standard in MPEG: from evidence collection to committee draft [J]. IEEE Signal Processing Magazine, 2019, 36(3): 118-123.
- [6] TIAN D, OCHIMIZU H, FENG C, et al. Geometric distortion metrics for point cloud compression[C]//IEEE International Conference on Image Processing, September 17-20, 2017, Beijing, China. New York: IEEE, 2017: 3460-3464.
- [7] ALEXIOU E, EBRAHIMI T. Point cloud quality assessment metric based on angular similarity[C]//IEEE International Conference on Multimedia and Expo, July 23-27, 2018, San Diego, CA, USA. New York: IEEE, 2018: 1-6.
- [8] MEYNET G, DIGNE J, LAVOUE G. PC-MSDM: a quality metric for 3D point clouds[C]//Eleventh International Conference on Quality of Multimedia Experience, June 5-7, 2019, Berlin, Germany. New York: IEEE, 2019: 1-3.
- [9] JAVAHERI A, BRITES C, PEREIRA F, et al. Improving PSNR-based quality metrics performance for point cloud geometry[C]//IEEE International Conference on Image Processing, October 25-28, 2020, Abu Dhabi, United Arab Emirates. New York: IEEE, 2020: 3438-3442.
- [10] JAVAHERI A, BRITES C, PEREIRA F, et al. A generalized Hausdorff distance based quality metric for point cloud geometry[C]//International Conference on Quality of Multimedia Experience, May 26-28, 2020, Athlone, Ireland. New York: IEEE, 2020: 1-6.
- [11] JAVAHERI A, BRITES C, PEREIRA F, et al. Mahalanobis based point to distribution metric for point cloud geometry quality evaluation[J]. IEEE Signal Processing Letters, 2020, 27: 1350-1354.
- [12] MEYNET G, NEHME Y, DIGNE J, et al. PCQM: a full-reference quality metric for colored 3D point clouds[C]//International Conference on Quality of Multimedia Experience, May 26-28, 2020, Athlone, Ireland. New York: IEEE, 2020: 1-6.
- [13] HUA L, YU M, JIANG G Y, et al. VQA-CPC: a novel visual quality assessment metric of color point clouds[C]//Optoelectronic Imaging and Multimedia Technology VII, October 10, Online. Bellingham: SPIE, 2020, 11550: 1155012.
- [14] 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.
- [15] 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.
- [16] WU X J, ZHANG Y, FAN C L, et al. Subjective quality database and objective study of compressed point clouds with 6DoF head-mounted display[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2021, 31(12): 4630-4644.
- [17] ZHANG Z C, SUN W, MIN X K, et al. No-reference quality assessment for 3D colored point cloud and mesh models [J]. (2021-07-05)[2022-05-16]. <https://arxiv.org/abs/2107.02041>.
- [18] HUA L, JIANG G Y, YU M, et al. BQE-CVP: blind quality evaluator for colored point clouds based on visual perception[J]. IEEE International Symposium on Broadband Multimedia Systems and Broadcasting, 2021: 4-8.
- [19] CHEN Z, CAVE K R. When does visual attention select all features of a distractor? [J]. Journal of Experimental Psychology Human Perception & Performance, 2006, 32(6): 1452-1464.
- [20] 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, 2021, 23: 3877-3891.
- [21] HE K, SUN J, TANG X. Guided image filtering[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 35(6): 1397-1409.
- [22] HAREL J, KOCH C, PERONA P. Graph-based visual saliency[C]//Advances in Neural Information Processing Systems 19, December 4, 2006, Vancouver, Canada. Cambridge: MIT Press, 2007: 545-552.
- [23] LIM W. Nonseparable Shearlet transform[J]. IEEE Transactions on Image Processing, 2013, 22(5): 2056-2065.
- [24] JAVAHERI A, BRITES C, PEREIRA F, et al. Point cloud rendering after coding: impacts on subjective and objective quality[J]. IEEE Transactions on Multimedia, 2021, 23: 4049-4064.
- [25] ALEXIOU E, EBRAHIMI T. Towards a point cloud structural similarity metric[C]//IEEE International Conference on Multimedia & Expo Workshops, July 6-10, 2020, London, UK. New York: IEEE, 2020: 1-6.
- [26] VIOLA I, CESAR P. A reduced reference metric for visual quality evaluation of point cloud contents[J]. IEEE Signal Processing Letters, 2020, 27: 1660-1664.

作者简介:

郁梅 (1968—),女,博士,教授,博士生导师,主要从事多媒体信号处理、视频压缩与通信等方面的研究。