

http://bhxb.buaa.edu.cn jbuua@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2021.0509

基于彩色三要素的无参考对比度失真图像质量评价方法

丁盈秋¹, 杨杨^{1,2,*}, 成茗¹, 张卫明³

(1. 安徽大学电子信息工程学院, 合肥 230601; 2. 合肥综合性国家科学中心人工智能研究院, 合肥 230088;

3. 中国科学技术大学网络空间安全学院, 合肥 230027)

摘要: 图像质量评价是图像处理领域中基本且具有挑战性的问题。对比度失真对图像质量的感知影响较大, 目前针对对比度失真图像的无参考图像质量评价研究相对较少。基于此, 提出了基于彩色三要素的无参考对比度失真图像质量评价方法, 利用彩色三要素的亮度、色调和饱和度 3 个参数实现了对比度失真图像的质量评价方法。在亮度方面, 提取矩特征及图像直方图与均匀分布之间的 Kullback-Leibler 散度特征。在色调和饱和度方面, 分别在 HSV 空间的 H 和 S 通道中提取颜色加权局部二值模式 (LBP) 直方图特征。利用 AdaBoosting-BP 神经网络训练预测模型。在 5 个标准图像数据库中进行广泛的实验分析和交叉验证, 结果表明, 所提方法与现有的对比度失真图像质量评价方法相比, 性能有明显的提升。

关键词: 图像质量评价; 对比度失真; HSV 颜色空间; 无参考; 彩色三要素; BP 神经网络

中图分类号: TP391

文献标志码: A

文章编号: 1001-5965(2022)08-1418-10

近年来, 随着网络与通信技术的发展, 生活中图像信息大幅度增长。但是, 图像在采集、压缩、处理及传播等过程中, 由于各种原因经常会出现不同程度和种类的失真, 从而影响人们对信息的获取。因此, 对图像质量评价的研究也越来越受到关注^[1]。图像的评估是通过人类视觉系统 (human visual system, HVS) 进行的, 但是主观评价在时间和经济成本上有局限性, 为了克服主观评价的不足, 科研人员提出了大量的客观图像质量评价 (image quality assessment, IQA) 方法。根据参考图像的可用性, 将现有的 IQA 方法划分为全参考 (full reference, FR)^[2-5]、半参考 (reduced ref-

erence, RR)^[4-6] 及无参考 (no reference, NR)^[7-13] 方法。FR 方法需要依赖全部原始信息, RR 方法只需要部分原始信息, 而 NR 方法完全不依赖于原始信息。

目前的 IQA 方法主要针对模糊、JPEG 压缩及噪声等失真图像^[12], 鲜有针对对比度失真图像的质量评价研究。另外, 在实际应用场合中, 由于较难获得原始图像信息, 建立符合人类视觉系统的、稳定且针对对比度失真图像的 NR-IQA 方法就显得尤为重要。目前, 针对对比度失真的 NR 质量评价方法有: 文献[7]从图像中提取矩特征和熵特征, 并利用图像数据库对其进行自然场景

收稿日期: 2021-09-02; 录用日期: 2021-09-17; 网络出版时间: 2021-11-02 16:04

网络出版地址: kns.cnki.net/kcms/detail/11.2625.V.20211101.1707.014.html

基金项目: 安徽省高等学校自然科学基金 (KJ2021A0016); 国家自然科学基金 (61502007, 61871411)

* 通信作者. E-mail: sky_yang@ahu.edu.cn

引用格式: 丁盈秋, 杨杨, 成茗, 等. 基于彩色三要素的无参考对比度失真图像质量评价方法 [J]. 北京航空航天大学学报, 2022, 48 (8): 1418-1427. DING Y Q, YANG Y, CHENG M, et al. No reference quality assessment method for contrast-distorted images based on three elements of color [J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 48 (8): 1418-1427 (in Chinese).

统计建模,在自然场景统计模型的基础上,根据图像的自然程度来衡量每幅对比度失真图像的失真程度(CDIQA)方法。文献[8]在CDIQA的基础上做了改进,提出了基于改进学习方法的无参考对比度失真图像质量评价(ICDIQA)。文献[9]通过结合局部和全局特征提出了一个NR图像质量度量(NIQMC),根据视觉显著性检测技术寻找具有最大信息的最优区域,将最优区域的熵作为局部质量度量,通过计算对比度失真图像和原始图像的均匀分布的直方图之间的Jensen-Shannon(JS)散度来测量全局对比度失真。文献[10]利用相位一致性的熵、边缘强度和3个基于对比度能量的特征进行对比失真评估,虽然其是一种NR-IQA模型的通用度量,但是对于对比度失真的图像表现出很高的性能。文献[11]寻求对比度失真与相关图像直方图特征之间的关系,定义了特征直方图,其是图像块直方图集的特征向量,利用图像特征直方图的随机性和相应特征值的幅值反映图像对比度的变化。文献[12]提出了一种基于结构的多面统计表示的对比失真图像的无参考质量度量,从S-CIELAB颜色空间三通道中提取空间强度、分布和方向3个质量度量,文献[13]提出一种基于梯度域和HSV空间的无参考对比度失真图像质量度量,通过将梯度域上的局部二值模式(local binary pattern,LBP)算子与HSV颜色空间上的颜色矩相结合得到综合质量度量。

尽管上述针对对比度失真图像的NR-IQA方法已取得了一定的进展,但仍存在一些不足。一方面,文献[7-10]只计算了亮度信息的失真,忽略了对比度失真对色度的影响。另一方面,文献[11-13]虽然考虑了色度失真,但是并没有考虑全面。本文提出了基于彩色三要素的无参考对比度失真图像质量评价方法,从亮度、色调和饱和度3个方面计算对比度失真。首先,对于亮度失真,在灰度上提取2组特征:①矩特征,包括均值、方差、偏度和峰度;②图像直方图与均匀分布之间的KL(Kullback-Leibler)散度和逆KL散度。然后,对于图像的饱和度和色调方面,分别在HSV空间的H和S通道中计算颜色加权LBP直方图特征。最后,利用AdaBoosting BP神经网络^[12]对质量模型进行训练。通过在5个标准图像数据库中进行广泛的实验分析和交叉验证,结果表明,本文方法与现有方法相比较性能具有明显提升。

1 基于彩色三要素的对比度失真图像质量评价

色度学早已表明,通常用亮度、色调和饱和度三要素来表征彩色图像特征。亮度即颜色的亮度,色调描述的是一种纯色(纯黄色、纯红色或纯蓝色)的属性,而饱和度是指一种纯色被白光稀释程度的度量^[14]。如图1所示,图1(a)为来自CID2013数据库^[15]的原图,图1(b)、(c)为对应的具有不同对比度变化的图像,图1(d)~(f)为图1(a)~(c)图像对应的亮度图,图1(g)~(i)为对应的色调图,图1(j)~(l)为对应的饱和度图,MOS为测试图像的主观得分(mean opinion score), \bar{Y} 为亮度均值参数, \bar{H} 为色调均值参数, \bar{S} 为饱和度均值参数,MOS值的范围为1~5,值越小代表图像质量越差,对比度失真程度越大。从图1中可以主观看出,随着对比度失真程度增加,亮度越来越低,色调变化范围不大,饱和度越来越大(因为白光越来越少),对应的客观参数表示亮度均值越来越小,色调均值在小范围内越来越小,饱和度均值越来越大。这表明主观视觉与客观参数可以对应,三要素参数是表征彩色对比度失真的有效因素。据此,本文提出了基于彩色三要素的无参考对比度失真图像质量评价方法。

本节详细介绍本文方法的实现步骤,分别从亮度、色调及饱和度3个方面来提取对应的表征特征,方法流程如图2所示。

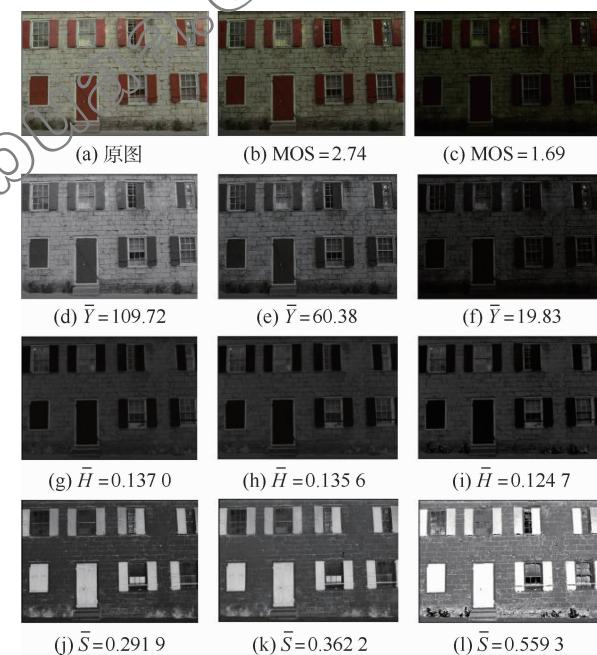


图1 原图及其对比度失真版本图像的相关参数

Fig. 1 Related parameters of original image and its contrast-distorted version

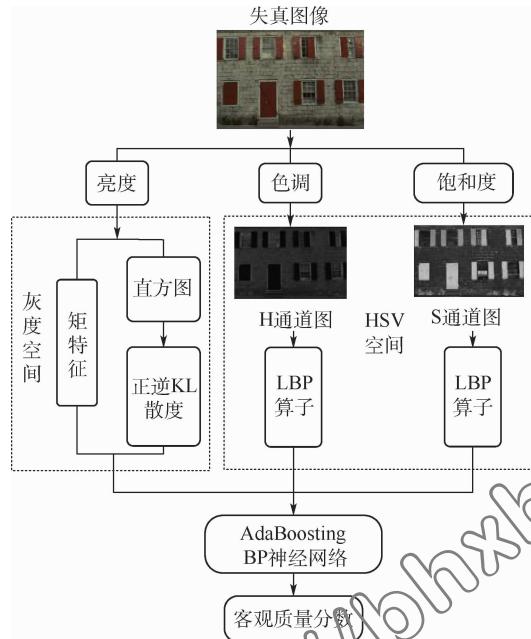


图 2 本文方法流程

Fig. 2 Flow chart of the proposed method

1.1 基于亮度的特征提取

1.1.1 矩特征

图像的矩特征包括均值、方差、偏度和峰度，在众多针对对比度失真图像质量评价的研究中得到了广泛的应用^[7]。图像的均值表示图像的整体亮度，方差可以用来计算图像对比度，偏度反映了图像像素值的对称性，峰度用来测量图像的正态分布。

设 I_{gray} 表示图像 I 的灰度版本。图像 I 的均值 $Me(I)$ 、方差 $Va(I)$ 、偏度 $Sk(I)$ 和峰度 $Ku(I)$ 可表示为

$$Me(I) = M(I_{gray}) \quad (1)$$

$$Va(I) = \sqrt{M(I_{gray} - M(I_{gray}))^2} \quad (2)$$

$$Sk(I) = \sqrt[3]{M(I_{gray} - M(I_{gray}))^3} \quad (3)$$

$$Ku(I) = \sqrt[4]{M(I_{gray} - M(I_{gray}))^4} \quad (4)$$

式中： $M(\cdot)$ 表示均值算子。

图 3 描述了图 1(a) ~ (c) 所示图像的矩特征。可见，均值和方差随着对比度失真程度的增大而减小，相反，偏度和峰度随之增大。这表明矩特征能够有效地表示不同对比度失真的图。

1.1.2 KL 散度特征

对于一幅图像来说，直方图集中在左边时，图像较暗，集中在右边时，则较亮，当直方图分布较均匀时，图像的对比度也会比较明显。图 4 绘制了均匀分布及图 1(a) ~ (c) 所示图像直方图的概率分布。可以看出，随着对比度失真程度的增加，概率密度曲线越来越偏离均匀分布。

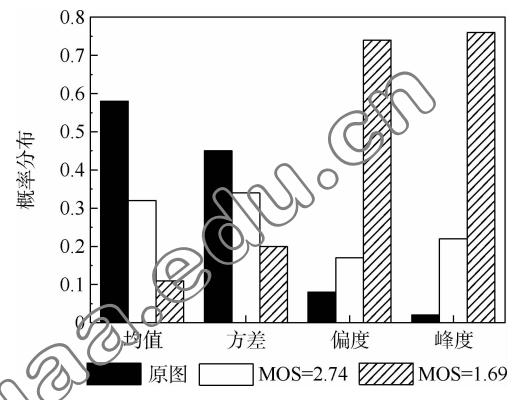


图 3 图 1(a) ~ (c) 所示图像的矩特征

Fig. 3 Moment features of images

shown in Fig. 1(a) ~ Fig. 1(c)

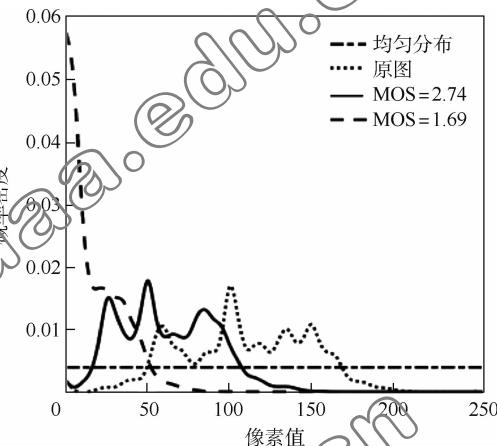


图 4 均匀分布、原图及不同程度对比度失真图像的概率密度

Fig. 4 Probability density of uniform distribution, original image and different degree of contrast distortion image

因此，图像直方图与均匀分布的偏离度为对比度失真的图像质量提供了一个很好的度量。假设 h_1 和 h_2 分别为对比度失真的图像直方图和均匀分布直方图，用 KL 散度来测量 h_1 和 h_2 之间的距离，KL 散度通常被用来评估 2 个分布之间的距离，定义为

$$D_{KL}(h_1 \| h_2) = - \int h_1(t) \ln h_2(t) dt + \int h_1(t) \ln h_1(t) dt \quad (5)$$

然而 KL 散度是不对称的，可能会引起一些不稳定性。因此，本文同时使用 KL 散度和逆 KL 散度作为特征。逆 KL 散度描述为 $D_{KL}(h_2 \| h_1)$ 。在 2.2 节中，用实验验证了使用 KL 散度和逆 KL 散度的结合使方法性能大大提升。

1.2 基于色调与饱和度的特征提取

为了计算测试图像在色调和饱和度方面的失真，引入与人类视觉系统特点一致的 HSV 颜色空

间。HSV模型的3个组成部分分别为:①色调,用角度度量,取值范围为 $0^\circ \sim 360^\circ$;②饱和度,取值范围为 $0\% \sim 100\%$;③明度,即亮度,取值范围为 $0\% \sim 100\%$ 。HSV颜色空间是RGB颜色空间的一种非线性变换,转化过程为

$$H = \begin{cases} 0^\circ & \max = \min \\ 60^\circ \left(\frac{G-B}{\max - \min} + 0 \right) & \max = R \\ 60^\circ \left(\frac{B-R}{\max - \min} + 2 \right) & \max = G \\ 60^\circ \left(\frac{R-G}{\max - \min} + 4 \right) & \max = B \end{cases} \quad (6)$$

$$S = \begin{cases} \frac{\max - \min}{\max} & \max \neq 0 \\ 0 & \text{其他} \end{cases} \quad (7)$$

$$V = \max \quad (8)$$

式中: H 、 S 、 V 分别为色调值、饱和度值和亮度值; R 、 G 、 B 分别为图像每个像素RGB3通道的值; \min 和 \max 分别为(R, G, B)中的最小值和最大值。

因为1.1节已经提取出合适的亮度特征,所以本节从HSV颜色空间的H和S通道中计算图像的颜色失真。LBP算子常用来描述局部区域中心和相邻像素之间的关系,因此本节计算H和S通道图中每个像素的LBP值,计算公式为

$$\text{LBP}_{n,r} = \begin{cases} \sum_{t=0}^{n-1} F(U_t - U_c) & \text{Ti(LBP}_{n,r}) \leq 2 \\ n+1 & \text{其他} \end{cases} \quad (9)$$

式中: n 为像素邻域,设置为8; r 为邻域的半径,设置为1; U_t 和 U_c 分别为H或S通道图像中的邻域像素和中心像素;函数 $F(\cdot)$ 的定义为

$$F(U_t - U_c) = \begin{cases} 1 & U_t - U_c \geq 0 \\ 0 & \text{其他} \end{cases} \quad (10)$$

Ti 为用于计算按位转换次数的度量,其定义为

$$\text{Ti(LBP}_{n,r}) = \|F(U_{n-1} - U_c) - F(U_0 - U_c)\| + \sum_{t=0}^{n-1} \|F(U_t - U_c) - F(U_{t-1} - U_c)\| \quad (11)$$

研究发现,当均匀LBP算子的位转换次数不超过2时,可以增强LBP算子的区分能力^[12]。因此,旋转不变的均匀LBP算子具有 $n+2$ 个模式。基于色调和饱和度的LBP映射可描述为

$$\text{CW}^U = \text{LBP}_{n,r}(U) \quad (12)$$

因此,可以得到2个LBP图,即 CW^H 和 CW^S 。

然而,LBP算子只编码相邻像素之间的差异,不能捕获准确的幅度信息。为了解决这一问

题,通过累积 CW^U 中具有相同LBP模式的像素来计算加权LBP直方图,则颜色加权LBP直方图定义为

$$L^U(k) = \sum_{Y=1}^M \sum_{X=1}^N U(X, Y) f(\text{CW}^U(X, Y), k) \quad (13)$$

$$f(x, y) = \begin{cases} 1 & x = y \\ 0 & \text{其他} \end{cases} \quad (14)$$

式中: M 和 N 分别为输入图像的行数和列数; k 为可能的LBP模式, $k \in [0, 9]$; $U(X, Y)$ 为分配给LBP值的权重。本文使用H和S通道图作为每个像素的LBP权重。对于测试图像,可以产生20个色调和饱和度特征。

为了验证提取特征的有效性,图5(a)、(b)分别展示了图1(a)~(c)中在H和S通道的颜色加权LBP直方图。图中,横坐标表示对应LBP图中的不同模式,纵坐标表示具有相同模式的所有像素的总和。通过观察图5(a)、(b)可以看出,H和S通道中每个LBP模式的累积值均随着对比度的变化而变化,即不同对比度的图像具有不同的统计特征,这表明本节所提出的组合特征可以有效地表示对比度的变化。

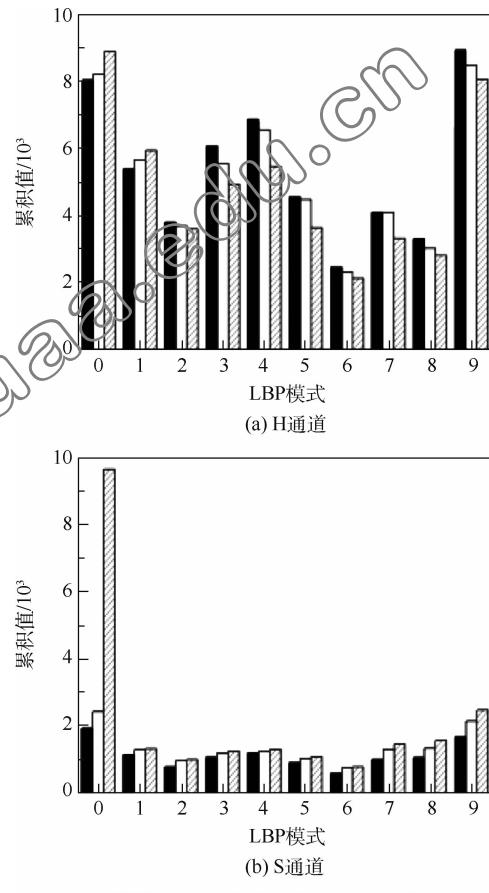


图5 H和S通道下LBP各模式的累积值

Fig. 5 Accumulated amplitude of each mode of LBP under H and S channels

1.3 AdaBoosting BP 神经网络评价模型

提取到所有特征之后,本文通过 AdaBoosting BP 神经网络建立了一个从图像特征到图像质量的映射。AdaBoosting 算法是学习弱学习算法的强回归算法^[12],本文利用 BP 神经网络作为弱学习算法。AdaBoosting BP 神经网络结构的原理如图 6 所示。图上方的虚线框描述了 BP 神经网络的结构,在 BP 神经网络中,输入层的神经元个数与图像特征的维数相同。输出层只有一个神经元节点,输出结果即被预测的图像质量结果。2 个隐藏层的节点数和输入层的节点数目相同。第 1 层隐藏层使用 tangent sigmoid 函数作为激活函数。第 2 层隐藏层使用径向基函数(radial basis function, RBF)作为激活函数。

AdaBoosting BP 神经网络算法步骤如下:

- 1) 确定 BP 神经网络的个数 T ,将 T 设置为 10^[12],并将训练集 X_{tr} 的主观分数 Y_{tr} 映射到 $[0, 1]$ 。
- 2) 对于第 i 个 BP 神经网络,使用 X_{tr} 和 Y_{tr} 进行训练,并计算 X_{tr} 和测试集 X_{te} 的预测结果,分别为 \hat{Y}_{tr}^i 和 \hat{Y}_{te}^i 。
- 3) 使用第 i 个 BP 神经网络的训练集分布 D_i 代表每个训练集对计算训练误差的权重,计算公

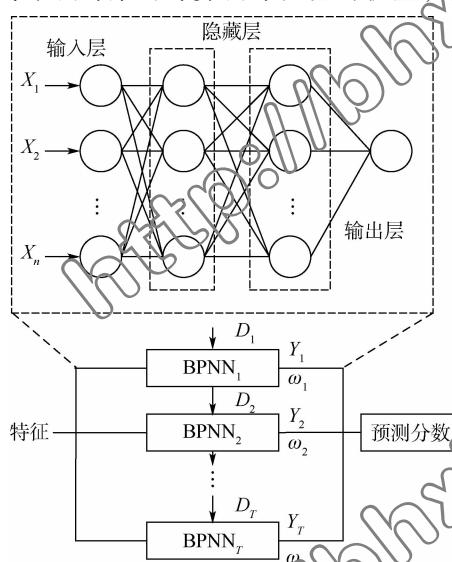


图 6 AdaBoosting BP 神经网络模型

Fig. 6 AdaBoosting BP neural network model

式为

$$D_{i,j} = \begin{cases} \frac{1}{Z} & i=1 \\ D_{i-1,j}(1 + \sigma \cdot \partial(Y_{\text{tr}}^j - \hat{Y}_{\text{tr}}^{j-1})) & i=2,3,\dots,T \end{cases} \quad (15)$$

式中: $D_{i,j}$ 为 D_i 的第 j 个元素; σ 设置为 0.1^[12]; Z 为训练集中图像的数量; 函数 ∂ 的定义为

$$\partial(x) = \begin{cases} 1 & x > \text{threshold} \\ 0 & \text{其他} \end{cases} \quad (16)$$

4) 每个 BP 神经网络的权重定义为

$$\omega_i = \frac{1}{e^{-b(|\text{Error}_i| - c)}} \quad (17)$$

式中:由于本文计算的是预测器权重,设置 $b = -1$, $c = -\ln 2$ ^[12]; Error_i 为第 i 个 BP 神经网络的误差,计算公式为

$$\text{Error}_i = \sum_{j=1}^M D_{i,j} \cdot \partial(Y_{\text{tr}}^j - \hat{Y}_{\text{tr}}^{i,j}) \quad (18)$$

5) 将 i 个 BP 神经网络预测结果线性组合,可得最终预测结果为

$$\hat{Y} = \sum_{i=1}^T \omega_i \hat{Y}_{\text{te}}^i \quad (19)$$

2 实验结果与分析

2.1 实验设置

为了验证本文方法的性能,引入了 5 个用于图像对比度失真评价的公共图像数据库,分别为 CID2013^[15]、CCID2014^[4]、CSIQ^[16]、TID2008^[17] 和 TID2013^[18] 数据库。其中,CSIQ 数据库的主观评分由差分平均意见得分(differential mean opinion score, DMOS)表示,DMOS 值越小代表图像质量越好,而其他数据库用 MOS 表示,MOS 值越大表示图像质量越好。表 1 描述了这 5 个图像数据库的主要特征。

在实验中,本文采用 Pearson 秩相关系数(PLCC)、Spearman 秩相关系数(SRCC)和 Kendalls 秩相关系数(KRCC)3 个准则对方法的性能进行

表 1 五个图像质量数据库的特征

Table 1 Features of five image quality databases

数据库	原始图像数量	对比度失真图像数量	失真类型	图像尺寸	分数类型	主观分数范围
CID2013 ^[15]	15	400	1	768 × 512	MOS	[1 ~ 5]
CCID2014 ^[4]	15	655	1	768 × 512	MOS	[1 ~ 5]
CSIQ ^[16]	30	116	6	512 × 512	DMOS	[0 ~ 1]
TID2008 ^[17]	25	200	17	512 × 384	MOS	[0 ~ 9]
TID2013 ^[18]	25	250	24	512 × 384	MOS	[0 ~ 9]

了测试。其中,预测精度采用 PLCC,而预测单调性使用 SRCC 和 KRCC。PLCC、SRCC 和 KRCC 的值越接近 1,表示方法性能越好。在计算 PLCC 之前,需要在主观和客观得分之间提供一个非线性的逻辑映射函数^[10]:

$$A(x) = \alpha_1 \left[\frac{1}{2} - \frac{1}{1 + e^{\alpha_2(x-\alpha_3)}} \right] + \alpha_4 x + \alpha_5 \quad (20)$$

式中: x 为原始 IQA 得分; $A(x)$ 为映射的 IQA 得分; $\alpha_1, \alpha_2, \alpha_3, \alpha_4, \alpha_5$ 为回归参数。

2.2 定量分析

为了验证亮度方面本文所使用的 KL 散度特征和逆 KL 散度特征结合后对性能的影响,在本文步骤中将散度特征分别用常用的 KL 散度、JS

散度替换并比较 3 种特征的性能。在 3 个数据库中的结果如表 2 所示。可以看出,使用 KL 散度或 JS 散度时性能相差不大,但同时使用 KL 散度和逆 KL 散度时,性能提升较大,因此本文选用 KL 散度和逆 KL 散度结合的方法。

另外,为了验证 AdaBoosting BP 神经网络的有效性,本节将回归模型替换成常用的支持向量回归(support vector regression, SVR)^[19]和随机森林(random forest, RF)^[20]进行了比较。实验结果如表 3 所示。可以看出,AdaBoosting BP 神经网络作为回归模型的方法与使用 SVR 或 RF 的方法相比,在 3 个数据库中性能明显提升。因此,本文使用 AdaBoosting BP 神经网络训练质量模型。

表 2 使用不同散度的性能比较

Table 2 Performance comparison using different divergence

散度类型	CID2013 ^[15]			CSIQ ^[16]			TID2008 ^[17]		
	PLCC	SRCC	KRCC	PLCC	SRCC	KRCC	PLCC	SRCC	KRCC
KL 散度	0.930	0.926	0.768	0.949	0.915	0.767	0.897	0.860	0.686
JS 散度	0.935	0.931	0.777	0.947	0.931	0.777	0.896	0.862	0.683
正逆 KL 散度	0.969	0.966	0.848	0.966	0.945	0.818	0.927	0.911	0.749

注:黑体数据表示最好结果。

表 3 使用不同回归模型的性能比较

Table 3 Performance comparison using different regression models

回归模型	CID2013 ^[15]			CSIQ ^[16]			TID2008 ^[17]		
	PLCC	SRCC	KRCC	PLCC	SRCC	KRCC	PLCC	SRCC	KRCC
SVR	0.906	0.895	0.718	0.905	0.851	0.708	0.912	0.867	0.693
RF	0.921	0.905	0.739	0.920	0.871	0.712	0.922	0.881	0.703
AdaBoosting BP 神经网络	0.969	0.966	0.848	0.966	0.945	0.818	0.927	0.911	0.749

注:黑体数据表示最好结果。

2.3 不同数据库方法性能比较

为了验证本文方法的性能,表 4 展示了在 CID2013、CCID2014、TID2013、TID2008 和 CSIQ 数据库上本文方法的性能评价结果,以及与 13 种针对对比度失真图像评价方法的比较结果。为了更好的比较,本文将 IQA 方法分为 3 组,FR、RR 和 NR 度量。FR-IQA 指标有 QMC^[1]、PCQI^[2]、QCCI^[3];RR-IQA 指标涉及 RIQMC^[4]、RCIQM^[5]、CIQM^[6];NR-IQA 方法由 CDIQA^[7]、ICDIQA^[8]、NIQMC^[9]、BIQME^[10]、HEFCS^[11]、文献[12]和文献[13]组成。此外,表中还列出了性能标准的数据库数量加权平均值。对于每个数据库,随机选择 80% 的图像进行模型训练,20% 的图像用于性能测试。为避免数据精度误差带来的影响,训练-测试过程重复 1 000 次,并在表 4 中显示中值。

从表 4 中可以看出,本文方法明显优于其他

NR-IQA 方法,甚至比 FR 和 RR 方法更具竞争力。在 NR 方法中,本文方法结果明显优于 5 个数据库中的所有 NR 模型。仅仅在 CSIQ 数据库中略低于 RIQMC 和 RCIQM 方法,但是 RIQMC 和 RCIQM 均属于半参考质量度量方法,需要原始图像的部分信息。从表 4 中的平均值结果来看,本文方法的结果明显优于其他方法。

2.4 泛化性能实验

为了证明本文方法的泛化能力,本节进行了跨数据库验证实验。通过对每个数据库的所有对比度失真图像进行训练来获得训练模型,使用这些训练模型测试其他 4 个数据库的失真图像。性能结果如表 5 所示,其中行代表训练集,列代表测试集。对于相同的训练和测试集,表中表示为 0。从表 5 中可以看出,用 CSIQ 数据库测试而在其他数据库上训练时,取得了最好的性能结果。在 CID2013 和 CCID2014 数据库上测试而在其他数

表 4 五个对比度失真图像数据库上本文方法和其他方法的性能比较

Table 4 Performance comparison of the proposed method and other methods on five contrast-distorted image databases

数据库	秩相关系数	FR			RR		
		QMC ^[1]	PCQI ^[2]	QCCI ^[3]	RIQMC ^[4]	RCIQM ^[5]	CIQM ^[6]
CID2013 ^[15]	PLCC	0.806	0.924 6	0.934 5	0.899 5	0.918 7	0.913 9
	SRCC	0.767 4	0.923 2	0.929 3	0.900 5	0.920 3	0.920 6
	KRCC	0.578 5	0.758 0	0.762 0	0.716 2	0.754 3	0.724 0
CCID2014 ^[4]	PLCC	0.895 2	0.872 1	0.888 0	0.877 6	0.884 5	0.885 3
	SRCC	0.870 5	0.886 9	0.895 7	0.846 5	0.856 5	0.869 7
	KRCC	0.684 6	0.682 0	0.702 1	0.650 7	0.669 5	0.685 4
CSIQ ^[16]	PLCC	0.960 5	0.948 2	0.946 6	0.965 2	0.964 5	0.946 2
	SRCC	0.953 2	0.948 8	0.951 2	0.957 9	0.956 9	0.949 6
	KRCC	0.816 5	0.814 4	0.798 2	0.827 9	0.819 8	0.810 5
TID2008 ^[17]	PLCC	0.803 6	0.882 1	0.881 4	0.858 5	0.880 7	0.892 2
	SRCC	0.752 9	0.900 2	0.898 9	0.809 5	0.857 8	0.868 1
	KRCC	0.571 9	0.722 6	0.711 9	0.622 4	0.670 5	0.689 0
TID2013 ^[18]	PLCC	0.797 2	0.873 8	0.873 3	0.865 1	0.886 6	0.897 0
	SRCC	0.733 6	0.917 5	0.912 6	0.804 4	0.854 1	0.862 1
	KRCC	0.551 3	0.709 3	0.685 4	0.617 3	0.667 5	0.687 3
加权平均值	PLCC	0.851 4	0.892 0	0.900 6	0.883 0	0.898 5	0.899 4
	SRCC	0.815 3	0.906 6	0.911 0	0.856 7	0.879 2	0.886 6
	KRCC	0.633 4	0.719 4	0.721 4	0.671 0	0.701 0	0.704 6

数据库	秩相关系数	NR							
		CDIQA ^[7]	ICDIQA ^[8]	NIQMC ^[9]	BIQME ^[10]	HEFCS ^[11]	文献[12]	文献[13]	本文方法
CID2013 ^[15]	PLCC	0.866 8	0.912 9	0.869 4	0.900 4	0.897 3	0.943 5	0.964 6	0.968 9
	SRCC	0.850 0	0.908 1	0.866 8	0.902 3	0.877 7	0.933 8	0.960 3	0.966 2
	KRCC	0.658 8	0.703 5	0.669 0	0.722 3	0.690 6	0.781 4	0.835 4	0.848 0
CCID2014 ^[4]	PLCC	0.837 1	0.877 9	0.843 8	0.858 8	0.865 0	0.923 5	0.910 9	0.925 4
	SRCC	0.802 6	0.851 2	0.811 3	0.830 9	0.842 6	0.911 8	0.902 3	0.914 5
	KRCC	0.603 6	0.659 8	0.605 2	0.630 5	0.639 5	0.728 6	0.728 5	0.748 3
CSIQ ^[16]	PLCC	0.666 3	0.881 7	0.874 7	0.810 6	0.941 7	0.936 8	0.926 9	0.965 5
	SRCC	0.585 6	0.814 5	0.853 3	0.784 8	0.903 9	0.887 6	0.895 3	0.944 7
	KRCC	0.439 0	0.690 3	0.668 9	0.598 3	0.752 4	0.729 0	0.731 2	0.818 2
TID2008 ^[17]	PLCC	0.632 0	0.756 8	0.776 7	0.899 3	0.865 0	0.865 4	0.876 3	0.926 5
	SRCC	0.572 3	0.703 6	0.732 4	0.848 8	0.804 2	0.800 3	0.817 6	0.911 3
	KRCC	0.425 3	0.498 9	0.541 9	0.647 0	0.630 2	0.609 8	0.638 9	0.748 7
TID2013 ^[18]	PLCC	0.579 8	0.696 3	0.722 5	0.852 4	0.844 3	0.895 7	0.911 1	0.951 0
	SRCC	0.508 2	0.642 9	0.645 8	0.814 9	0.749 9	0.840 1	0.853 0	0.924 0
	KRCC	0.362 8	0.453 6	0.468 7	0.610 9	0.568 7	0.659 5	0.688 7	0.768 0
加权平均值	PLCC	0.767 2	0.843 9	0.825 3	0.869 6	0.875 3	0.917 9	0.921 1	0.943 1
	SRCC	0.724 9	0.812 8	0.792 7	0.845 0	0.836 6	0.890 7	0.898 1	0.930 5
	KRCC	0.546 3	0.621 1	0.596 6	0.649 7	0.648 1	0.714 3	0.737 9	0.781 0

注: 黑体数据表示最好结果。

据库上训练时, 性能较差。在 CSIQ 和 TID2008 及 TID2013 互相作为训练集和测试集时, 性能结果都较好。这是因为 CSIQ 数据库包含的对比度失真方面最少, 其次是 TID2008 和 TID2013, 而 CID2013 和 CCID2014 数据库中涉及的对比度失真方面最多。另外, 本文方法的特征共有 27 个, 属于低维特征, 这就可能导致在追求计算效率的同时鲁棒性较差。这也表明未来的研究应该考虑更多的属性。

2.5 一致性实验

为了分析在质量回归模型中训练集和测试集

的比例对性能的影响, 对本文模型的训练集和测试集在 3 个比例下进行实验, 分别为 80%、50% 和 20% 的失真图像用于训练, 剩余的 20%、50% 和 80% 用于测试。每个数据库在 3 个分割比例下的 SRCC、PLCC 和 KRCC 值如表 6 所示。通过表 6 中的结果得出, 本文方法的预测性能随着训练集在数据库上比例的减少而下降。然而, 在有大量失真图像的数据上, 如 CID2013 和 CCID2014, 分割比例对性能的影响相对较小。这表明训练数据不足会限制本文方法的泛化能力。

表5 跨数据库验证的性能

Table 5 Performance of cross-database verification

数据库	秩相关系数	CID2013 ^[15]	CCID2014 ^[4]	CSIQ ^[16]	TID2008 ^[17]	TID2013 ^[18]
CID2013 ^[15]	PLCC		0.922	0.663	0.580	0.540
	SRCC	0	0.902	0.653	0.556	0.503
	KRCC		0.733	0.485	0.398	0.361
CCID2014 ^[4]	PLCC ^[16]	0.966		0.649	0.541	0.503
	SRCC	0.965	0	0.626	0.500	0.458
	KRCC	0.839		0.434	0.350	0.317
CSIQ ^[16]	PLCC	0.588	0.540		0.771	0.769
	SRCC	0.586	0.443	0.6	0.701	0.670
	KRCC	0.401	0.302		0.520	0.490
TID2008 ^[17]	PLCC	0.475	0.468	0.858		0.955
	SRCC	0.387	0.364	0.853	0	0.932
	KRCC	0.277	0.260	0.641		0.787
TID2013 ^[18]	PLCC	0.503	0.502	0.806	0.956	
	SRCC	0.364	0.323	0.779	0.948	0
	KRCC	0.261	0.248	0.553	0.809	

表6 三个数据库上不同训练集和测试集比例性能比较

Table 6 Performance comparison of different training set and test set ratios on three databases

测试集 比例/%	CID2013 ^[15]			CSIQ ^[16]			TID2008 ^[17]		
	PLCC	SRCC	KRCC	PLCC	SRCC	KRCC	PLCC	SRCC	KRCC
20	0.903	0.904	0.727	0.766	0.755	0.553	0.828	0.789	0.601
50	0.951	0.952	0.808	0.905	0.893	0.712	0.897	0.872	0.694
80	0.969	0.966	0.848	0.966	0.945	0.818	0.927	0.911	0.749

注:黑体数据表示最好结果。

2.6 消融实验

本文采用了3种特征,分别从亮度、色调和饱和度方面提取统计特征来预测图像质量。为了验证各部分特征对性能的影响,本节在CID2013数据库上进行了消融实验。总体结果如图7所示。图中,V1表示从灰度图中提取的矩特征,V2表示正逆KL散度特征,H和S分别表示从HSV颜色空间提取的色调和饱和度特征。随着各部分特征的增加,在CID2013数据库上,PLCC、SRCC和KRCC的值不断提高,这表示性能也越来越高。

2.7 通用性评估实验

为了检验本文方法对于其他图像失真的效果,本节在CSIQ数据库中对于各种失真类型图像进行了评价实验。CSIQ数据库中包含JPEG压缩失真、JPEG2K压缩失真、高斯模糊失真(Gaussian blur, GB)、高斯白噪声失真(white Gaussian noise, WGN)、高斯粉红噪声失真(pink Gaussian noise, PGN)和全局对比度失真(global contrast decrements, GCD)。本文方法针对每种失真类型图像评估的SRCC、PLCC和KRCC值如表7所示。从结果中可以看出,本文方法针对每种失真类型图像的评价都具有一定效果,但是在针对对比度失真图像上具有最佳性能。究其原因,不同的失真类型图像具有不同的特性,而本文从彩色三要素方面提取的各种特征是针对对比度失真图像特性的。

表7 在CSIQ数据库上不同失真类型图像的性能比较

Table 7 Performance comparison of different distortion types in CSIQ database

秩相关系数	JPEG	JPEG2K	GB	WGN	PGN	GCD
PLCC	0.913	0.891	0.908	0.942	0.931	0.966
SRCC	0.862	0.852	0.867	0.934	0.907	0.945
KRCC	0.688	0.684	0.702	0.801	0.773	0.818

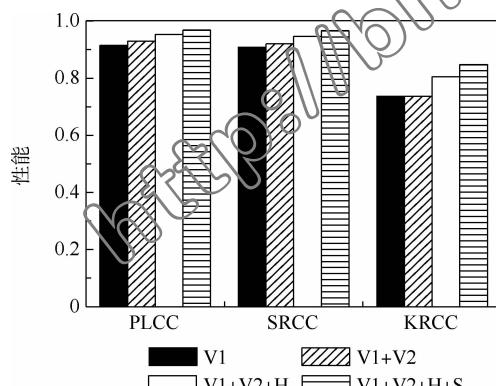


图7 CID2013数据库上的消融结果

Fig. 7 Ablation results on CID2013 database

注:黑体数据表示最好结果。

3 结 论

1) 本文提出了基于彩色三要素的无参考对比度失真图像质量评价方法。从彩色三要素的亮度、色调和饱和度出发,提取 3 方面的特征参数。在亮度方面,在灰度上提取了矩特征及对比度失真图像直方图与均匀分布之间的散度特征。在饱和度和色调方面,分别在 HSV 空间的 H 和 S 通道中计算颜色加权 LBP 直方图特征。基于这些特征,采用 AdaBoosting BP 神经网络对质量模型进行训练。

2) 在 5 个公开数据库上的实验结果可以看出,本文方法对对比度失真图像的评价性能优于其他相关的 IQA 方法。

在未来的工作中,可以考虑更多属性的特征,并探索更好的神经网络用于质量模型训练。

参 考 文 献 (References)

- [1] GU K, ZHAI G T, YANG X K, et al. Automatic contrast enhancement technology with saliency preservation [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2015, 25(9):1480-1494.
- [2] WANG S Q, MA K D, YEGANEH H, et al. A patch-structure representation method for quality assessment of contrast changed images [J]. IEEE Signal Processing Letters, 2015, 22(12): 2387-2390.
- [3] SUN W, YANG W M, ZHOU F, et al. Full-reference quality assessment of contrast changed images based on local linear model [C] // 2018 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE Press, 2018: 1228-1232.
- [4] GU K, ZHAI G T, LIN W S, et al. The analysis of image contrast: From quality assessment to automatic enhancement [J]. IEEE Transactions on Cybernetics, 2016, 46(1):284-297.
- [5] LIU M, GU K, ZHAI G T, et al. Perceptual reduced-reference visual quality assessment for contrast alteration [J]. IEEE Transactions on Broadcasting, 2017, 63(1):71-81.
- [6] KIM D, LEE S, KIM C. Contextual information-based quality assessment for contrast-changed images [J]. IEEE Signal Processing Letters, 2019, 26(1):109-113.
- [7] FANG Y M, MA K D, WANG Z, et al. No-reference quality assessment of contrast-distorted images based on natural scene statistics [J]. IEEE Signal Processing Letters, 2015, 22(7): 838-842.
- [8] WU Y J, ZHU Y H, YANG Y, et al. A no-reference quality assessment for contrast-distorted image based on improved learning method [J]. Multimedia Tools and Applications, 2019, 78(8):10057-10076.
- [9] GU K, LIN W S, ZHAI G T, et al. No reference quality metric of contrast-distorted images based on information maximization [J]. IEEE Transactions on Cybernetics, 2017, 47(12):4559-4565.
- [10] GU K, TAO D C, QIAO J F, et al. Learning a no-reference quality assessment model of enhanced images with big data [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(4):1301-1313.
- [11] KHOSRAVI M H, HASSANPOUR H. Blind quality metric for contrast-distorted images based on eigen decomposition of color histograms [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 30(1):48-58.
- [12] ZHOU Y, LI L D, ZHU H C, et al. No reference quality assessment for contrast-distorted images based on multifaceted statistical representation of structure [J]. Journal of Visual Communication and Image Representation, 2019, 60:158-169.
- [13] LYU W J, LU W, MA M. No-reference quality metric for contrast-distorted image based on gradient domain and HSV space [J]. Journal of Visual Communication and Image Representation, 2020, 69:102797.
- [14] GONZALEZ R C, WOODS R E. Digital image processing [M]. 3rd ed. Beijing: Publishing House of Electronics Industry, 2011.
- [15] GU K, ZHAI G T, YANG X K, et al. Subjective and objective quality assessment for images with contrast change [C] // 2013 IEEE International Conference on Image Processing. Piscataway: IEEE Press, 2013:383-387.
- [16] LARSON E C, CHANDLER B M. Most apparent distortion: Full-reference image quality assessment and the role of strategy [J]. Journal of Electronic Imaging, 2010, 19(1):011006.
- [17] PONOMARENKO N, LUKIN V, ZELENSKY A, et al. TID2008-A database for evaluation of full-reference visual quality assessment metrics [J]. Advances of Modern Radio electronics, 2009, 40:30-45.
- [18] PONOMARENKO N, IEREMIEIEV O, LUKIN V, et al. Color image database TID2013: Peculiarities and preliminary results [C] // European Workshop on Visual Information Processing (EUVIP). Piscataway: IEEE Press, 2013:106-111.
- [19] WILLIAMS C K I. Learning with kernels: Support vector machines, regularization, optimization, and beyond [J]. Journal of the American Statistical Association, 2003, 98(462):489-490.
- [20] ANTONIO C, ENDER K, JAMIE S. Decision forests: A unified framework for classification, regression, density estimation, manifold learning and semi-supervised learning [J]. Foundations and Trends in Computer Graphics and Vision, 2011, 7(2-3): 81-227.

No reference quality assessment method for contrast-distorted images based on three elements of color

DING Yingqiu¹, YANG Yang^{1,2,*}, CHENG Ming¹, ZHANG Weinong³

(1. School of Electronic and Information Engineering, Anhui University, Hefei 230601, China;

2. Institute of Artificial Intelligence, Hefei Comprehensive National Science Center, Hefei 230088, China;

3. School of Cyber Science and Technology, University of Science and Technology of China, Hefei 230027, China)

Abstract: Image quality assessment is a basic and challenging problem in the field of image processing, among which the contrast distortion has a greater impact on the perception of image quality. However, there is relatively little research on the no-reference image quality assessment of contrast-distorted images. This paper proposes a no-reference contrast-distorted image quality assessment method based on the three elements of color. The three parameters of brightness, hue and saturation of the three elements of color are used to realize the assessment of contrast-distorted images. First, in terms of brightness, the moment feature and the Kullback-Leibler divergence between the image histogram and the uniform distribution are extracted. Secondly, in terms of hue and saturation, the color-weighted local binary patterns (LBP) histogram features are extracted from the H and S channels of the HSV space, respectively. Finally, the AdaBoosting BP neural network is used to train the prediction model. Through extensive experimental analysis and cross-validation in five standard image databases, the experimental results show that the performance of this method is significantly improved compared with the existing contrast-distorted image quality assessment methods.

Keywords: image quality assessment; contrast distortion; HSV color space; no reference; three elements of color; BP neural network

Received: 2021-09-02; **Accepted:** 2021-09-17; **Published online:** 2021-11-02 16:04

URL: kns.cnki.net/kcms/detail/11.2625.V.20211101.1707.014.html

Foundation items: Natural Science Foundation of the Anhui Higher Education Institutions of China (KJ2021A0016); National Natural Science Foundation of China (61502007,61871411)

* **Corresponding author.** E-mail: sky_yang@ahu.edu.cn