

# 一种基于LGB的色彩量化方法

张鑫, 王晖, 曹源

(国防科技大学多媒体研发中心, 长沙 410073)

**摘要:** 提出了一种基于LGB的二阶色彩量化方法: 第1阶段根据量化级别的大小确定初始调色板选择方案并遴选出初始调色板; 第2阶段利用LGB算法对调色板进行迭代优化。实验结果表明, 该方案能明显地减少LGB收敛所需的迭代次数以及最终的量化失真。相对于当前其它量化方法, 该方法具有更小的量化失真。

**关键词:** 色彩量化; 均方误差; Popularity 准则; 合并准则; LGB 算法

## LGB-based Method for Color Quantization

ZHANG Xin, WANG Hui, CAO Yuan

(Multimedia Research & Development Center, National Univ. of Defense Tech., Changsha 410073)

**【Abstract】** This paper proposes a two-stage color quantization method. At the first stage, a palette selection scheme suitable to the quantization level requirement is chosen and an initial palette is selected. At the second stage, LGB algorithm is adopted to iteratively refine the palette. Experimental results show that the scheme is effective for reducing both iterations needed and the final MSE. The results also prove the approach is superior to most of the prevalent methods in terms of quantization distortion measured by the MSE metric.

**【Key words】** Color quantization; Mean squared error; Popularity scheme; Merging scheme; LGB algorithm

通常将色彩量化定义为把彩色图像, 特别是真彩色图像中的像素色彩替换为视觉上“最相近”的调色板色彩, 从而减少图像中总色彩数目的过程<sup>[1,2]</sup>。作为一个有损过程, 色彩量化必然导致失真。如何使量化失真最小是这一问题的挑战性所在。设 24 位真彩色图像  $I$  包含  $N$  种色彩, 色彩量化就是从  $I$  到仅包含  $K$  种色彩的量化图像  $I_Q^K$  一个映射。

$$Q: I \rightarrow I_Q^K$$

其中,  $K$  为量化级别,  $K \ll N$ , 通常  $K \leq 255$ ; 以  $D_Q$  表示  $Q$  所导致的失真, 研究色彩量化就是要找到如下的最优映射:

$$Q_{opt} = \arg \min_{I \rightarrow I_Q^K} \{D_Q\} \quad (1)$$

### 1 量化失真的定义

在求解式(1)的过程中, 首先需要确定其中量化失真  $D_Q$  的度量方式。均方误差(MSE)和峰值信噪比(PSNR)是最常用的量化失真客观描述指标, 尽管它们经常与人眼感知的图像质量并不吻合<sup>[3]</sup>。对此, 研究人员提出了一些扩展和改进, 例如文献[3,4]。这些改进的失真度量通常都是带权形式的MSE, 再加上MSE通用性使得用它作失真度量可以方便地与别的量化方法进行比较, 所以本文也采用了MSE。设选定调色板  $P = \{c_1^p, c_2^p, \dots, c_K^p\}$ , 并记量化过程中被映射为第  $i$  种调色板色彩  $c_i^p$  的色彩集合为  $C_i$ , 则集合  $C_i$  上的MSE为

$$D_Q^i = \sum_{c \in C_i} f(c) \|c - c_i^p\|^2 \quad (2)$$

其中,  $f(c)$  是色彩  $c$  的出现频率, 定义为具有色彩  $c$  的像素数占图像总像素数的百分比;  $\|\cdot\|$  是色彩差异度量。

根据视觉心理学的研究成果, 感知一致色彩空间中的欧氏距离是色彩视觉差异的最佳度量<sup>[5]</sup>, 常用感知一致空间包括 CIE L\*a\*b 和 CIE L\*u\*v。由此整幅图像上的量化失真为

$$D_Q = \sum_{i=1}^K D_Q^i \quad (3)$$

这种MSE定义是从聚类观点给出的, 通常也称为  $K$ -均值量化误差<sup>[6]</sup>。量化级别  $K$  给定时(通常  $K \geq 2$ )。

式(1)求解的是一个NP完全问题<sup>[6]</sup>。研究人员把工作重点集中在如何通过一些启发式规则以便在可接受的时间内找到一个尽可能好的次优解。已有的方法可以分成分裂和聚类 2 大类。分裂方法采用自顶向下的工作模式, 而聚类方法则采用自底向上的工作模式。通常, 分裂方法的量化失真较大, 而聚类方法更可能取得较优的量化效果, 但聚类结果的好坏经常受到初始调色板选取和聚类过程的扫描顺序的影响。LGB算法<sup>[7]</sup>是一种原理简单而且十分有效的聚类方法, 本文用它来实现色彩量化。考虑到初始调色板的选取对LGB的迭代次数和最终量化结果影响巨大, 本文提出了 2 种互补的初始调色板选择方案: Popularity 准则和合并准则。

### 2 利用LGB算法实现色彩量化的基本思路

对于给定的图像  $I$ , 其 MSE 与平方和误差(SSE)成正比, 接下来的推导均使用 SSE。设色彩集合  $C_i$  的势为  $|C_i| = M$ , 其质心为  $\overline{c_M}$ , 并记具有色彩  $c_j \in C_i$  的像素点个数为  $n_j$ 。另设  $c_0 \in R^3$  是任意的色彩向量, 则将  $C_i$  中的所有色彩均映射为  $c_0$ , 所产生的 SSE 为

$$\begin{aligned} D(C_i, c_0) &= \sum_{j=1}^M n_j \|c_j - c_0\|^2 \\ &= \sum_{j=1}^M n_j \|c_j - \overline{c_M}\|^2 + \|c_0 - \overline{c_M}\|^2 \cdot M \end{aligned} \quad (4)$$

**作者简介:** 张鑫(1978-), 男, 博士生, 主研方向: 图像分析与处理; 王晖, 教授; 曹源, 学士

**收稿日期:** 2006-06-08 **E-mail:** ijunzhang@hotmail.com

其中，质心  $\overline{c_M}$  的定义为

$$\overline{c_M} = \frac{\sum_{j=1}^M n_j c_j}{\sum_{j=1}^M n_j} \quad (5)$$

由式(4)可知， $C_0$ 与 $\overline{c_M}$ 之间距离越小， $D(C_i, c_0)$ 也越小，当 $c_0 = \overline{c_M}$ 时， $D(C_i, c_0)$ 达到最小值。将色彩簇的代表色选为该簇的质心总是有助于减小量化误差的。按照LBG算法<sup>[7]</sup>，在选定初始调色板 $P_0 = \{c_1^0, \dots, c_K^0\}$ 后重复执行下面2个步骤即可实现色彩量化：

(1)对当前调色板 $P_i = \{c_1^i, \dots, c_K^i\}$ ，顺序扫描图像，将各像素色彩逐一映射为 $P_i$ 中与其距离最近的一个，这样可以产生 $K$ 个聚簇 $\{C_1^i, \dots, C_K^i\}$ ；

(2)计算上面各聚簇的质心，并以它们作为代表色，构成下次迭代所需的新调色板 $P_{i+1} = \{c_1^{i+1}, \dots, c_K^{i+1}\}$ 。

迭代过程的终止条件是前后2次迭代中色彩映射所产生的MSE之差为零。迭代终止时，算法将收敛到一个局部最优解。

### 3 初始调色板色彩的选取

由于LBG算法的迭代次数和最终量化结果对初始调色板依赖严重，因此好的初始调色板选择方案尤为重要。直观上，所选初始调色板与最优调色板的距离越近，则调色板优化所需的迭代次数会越少，而最终的量化失真也越有可能接近最小。基于这种考虑，本文构造了两种具有互补性的初始调色板选取方案，一种受启发于Heckbert的Popularity算法<sup>[8]</sup>，称之为Popularity准则；另一种则通过合并色彩簇来产生初始调色板，称为合并准则。

#### 3.1 Popularity 准则

从式(2)、式(3)可见，调色板色彩 $c_i^p (i=1, \dots, K)$ 越接近在图像 $I$ 中的出现频率高的那些色彩，将越有助于减少整个量化带来的MSE。所以可以根据色彩的出现频率高低来遴选初始调色板。

为了统计各种色彩在图像中的出现频率，需要计算图像的色彩直方图。但三通道彩色图像直方图的精确计算非常耗资时空资源，本文采用了一种下采样色彩直方图。为方便计算，下采样因子取为2的整数幂，即 $2^k$ 。 $k$ 过小将不利于节省时空资源，而过大又会给统计结果带来无法接受的误差。通过对大量测试图像的对比实验，选择 $2^4=16$ 作为因子对24位图像的3个色彩通道进行下采样。这样，色彩空间即被划分为 $(2^4)^3=4096$ 个互不相交的、体积为 $16^3$ 的小立方体区域。统计每个小立方体内的色彩在图像中的出现频率之和，便可得到一个4096饼(bins)的下采样色彩直方图。然后从中挑出频率最大的 $K$ 个饼，并计算图像色彩在这些饼所对应的小立方体内的质心，这 $K$ 个质心即可构成一个尽量照顾到频率最大的那些色彩的初始调色板。

#### 3.2 合并准则

Popularity 准则简单直观，但它片面地照顾了那些出现频率高的色彩，而几乎没有顾及出现频率较低的部分，很多时候其效果并不好，特别是当量化级别 $K$ 较小时。为此，我们设计了合并方案，试图兼顾到图像中出现频率低的色彩。

如上面3.1节所述，仍通过下采样将色彩空间划分为4096个体积为 $16^3$ 的小立方体区域。事实上，这些小立方体通常并没有被输入图像完全占用，即常常存在一些小立方体，其内部的色彩在输入图像中并没有出现。为图像挑选调色板

时只应考虑那些被占用的小立方体。把在图像 $I$ 中出现的、位于某个小立方区域内的那些色彩视为一个色彩簇。设色彩空间划分后图像 $I$ 中共有 $H$ 个簇，通常 $H > K$ ，要产生 $K$ 个初始调色板色彩，就需要进行适当的簇合并。

以上述各簇的质心作为该簇的代表色，一种常用的合并准则是：合并当前质心距离最近的2个簇。这种方式直观，但并不合理，因为合并质心距离最近的两簇所带来的失真并不一定最小。设任意2个色彩簇 $C_i$ 与 $C_j$ 的质心分别为 $\overline{c_i}$ 和 $\overline{c_j}$ ，合并后的簇记为 $C_{merge}$ ，其质心为 $\overline{c_{merge}}$ ，则可以得到将 $C_i$ 和 $C_j$ 中的色彩量化为 $\overline{c_{merge}}$ 带来的SSE为

$$\begin{aligned} SSE_{merge} &= \sum_{c_k \in C_{merge}} n_k \|c_k - \overline{c_{merge}}\|^2 \\ &= \sum_{c_m \in C_i} n_m \|c_m - \overline{c_{merge}}\|^2 + \sum_{c_n \in C_j} n_n \|c_n - \overline{c_{merge}}\|^2 \\ &= D(C_i, \overline{c_{merge}}) + D(C_j, \overline{c_{merge}}) \end{aligned} \quad (6)$$

根据式(4)、式(6)，则合并 $C_i$ 和 $C_j$ 所带来的SSE增量为

$$\begin{aligned} \Delta SSE &= SSE_{merge} - SSE_i - SSE_j \\ &= D(C_i, \overline{c_{merge}}) + D(C_j, \overline{c_{merge}}) - SSE_i - SSE_j \end{aligned} \quad (7)$$

$$= |C_i| \cdot \|\overline{c_i} - \overline{c_{merge}}\|^2 + |C_j| \cdot \|\overline{c_j} - \overline{c_{merge}}\|^2$$

其中，质心 $\overline{c_{merge}}$ 可以通过式(8)得到

$$\overline{c_{merge}} = \frac{|C_i| \cdot \overline{c_i} + |C_j| \cdot \overline{c_j}}{|C_i| + |C_j|} \quad (8)$$

显然，当前簇中使式(7)的 $\Delta SSE$ 最小的2个簇应被首先合并。用合并方案挑选初始调色板的流程是：

(1)通过色彩下采样将色彩空间划分成4096个体积为 $16^3$ 的小立方体区域。这个步骤的必要性在于，真彩色图像中的色彩常常数以万计，直接以单个色彩向量为初始簇进行合并将非常耗时。

(2)找出输入图像在各小立方体内的色彩簇，并计算各簇的质心。

(3)重复合并当前簇中使 $\Delta SSE$ 最小的两个簇，直至仅有 $K$ 个色彩簇。

(4)以这 $K$ 个簇的质心构成初始调色板。

## 4 实验与结果分析

为了验证本文提出的色彩量化方法，我们用Visual C++进行了算法实现，并对大量24位真彩色图像进行了实验。为了便于与其它方法比较，下面主要给出了对文献[9]中用到的6幅图像的实验数据，分别是Baboon、Lena、Peppers、Airplane、House和Sailboat。

表1 2种初始调色板选择方案的有效性对比(MSE/迭代次数)

K 方案	Baboon	Lena	Peppers	Airplane	House	Sailboat	
16	合并	532/9	238/11	412/11	237/34	455/18	309/20
	Popularity	587/12	274/11	400/11	197/12	451/11	318/17
	随机选取	547.1/15.1	259/14.8	410.3/19.1	210.6/12.7	453.1/21.5	319.3/20.2
32	合并	311/11	135/9	242/12	167/33	245/11	202/20
	Popularity	324/16	132/8	248/10	111/13	246/9	199/10
	随机选取	315.9/14.8	138.9/11.4	243.5/15.9	130.7/12.1	246.2/15.2	201.5/16
64	合并	186/13	82/7	149/12	111/17	153/7	131/9
	Popularity	186/10	83/7	148/8	73/7	145/9	128/7
	随机选取	190.8/14.5	85.6/10.4	149.9/16	81.9/9.5	144.9/14.3	130.8/13.5
128	合并	121/12	54/5	99/10	51/8	91/11	88/10
	Popularity	120/8	53/6	100/8	52/8	89/10	84/10
	随机选取	122.1/12.8	65/10.9	96.8/13	53.3/9.5	90.9/11.6	87.7/12.8

表1中给出了分别按Popularity准则和合并准则选取初始调色板进行量化，最终的量化失真MSE以及需要的迭代次数。为了验证这2种方案的有效性，表1中还给出了随机选

择初始调色板进行 LBG 迭代的结果，其中的数据是 10 次随机实验的平均值。从这些结果可见：上述 2 种方案都能有效减少迭代次数和最终的 MSE。当量化级别为  $k < 32$  时，合并方案更具优势；而  $k \geq 32$  时，Popularity 方案更优。在色彩量化过程中应当根据量化级别选择适当的初始调色板选取方案。对 24 位真彩色图像 garden 的量化结果如图 1 所示，从上到下，从左到右依次为原始图像和量化为 16、32、64、128、256 时的量化后图像，对应的 MSE 为 457、263、151、94 和 63。



图 1 真彩色图像 garden 的量化结果

文献[9]提出了一种基于色彩在主轴上的投影距离的分裂式量化算法，本文将其简称为 SAU 方法，SAU 是 3 位作者名的首字母联合。本文将 SAU 方法与当前主要的量化方法进行了比较，这些方法包括 Popularity 算法、中心切割方法、中值切割方法、基于偏差的方法，八叉树分裂法以及 Dekker 的基于 SOM 的量化方法。实验结果表明，SAU 和 SOM 方法的量化质量最好。本文直接引用文献[9]中 SAU 和 SOM 方法，把 24 位真彩色图像的实验数据和本文的实验结果放在表 2 中，以便比较。

表 2 本文方法与量化算法的实验结果对比(MSE)

K 算法	Baboon	Lena	Peppers	Airplane	House	Sailboat	
16	本文算法	532	238	412	237	455	309
	SAU	731	273	482	192	481	354
	SOM	667	272	479	214	511	365
32	本文算法	324	132	248	111	246	199
	SAU	424	140	298	127	288	235
	SOM	414	136	261	109	241	245
64	本文算法	186	83	148	73	145	128
	SAU	265	82	199	72	171	166
	SOM	256	83	154	54	146	157
128	本文算法	120	53	100	52	89	84
	SAU	169	53	129	34	105	112
	SOM	156	47	86	26	78	88

结果表明，相对于 SAU 和 SOM，本文方法多数时候具有更好的量化效果。图 1 给出了对 24 位真彩色图像“Garden”的量化结果。由图 1 可见，当  $K \geq 32$  时，人眼能感知的量化失真已经很小了；而  $K \geq 128$  时，人眼几乎感觉不到有量化失真存在。

## 5 结束语

本文提出了一种基于 LBG 的二阶色彩量化方法，在第 1 阶段中，当  $K < 32$  时，选用合并准则，当  $K \geq 32$  时，选用 Popularity 准则；在第 2 阶段中，利用迭代式优化得出量化结果。实验结果显示，与当前主要量化方法相比，本文的初始调色板方案在减小 MSE 和迭代次数方面，显示了其优越性。

## 参考文献

- Larabi M C, Richard N, Fernandez C. A Fast Color Quantization Using a Matrix of Local Pallets[C]. Proc. of Applied Imagery Pattern Recognition Workshop, 2000: 136-140.
- Uysal M, Yarman-vural F T. A Fast Color Quantization Algorithm Using a Set of One Dimensional Color Intervals[C]. Proc. of International Conference on Image, 1998: 191-195.
- Tremeau A, Calonnier M. Color Quantization Error in Terms of Perceived Image Quality[C]. Proc. of IEEE Int. Conf. on Acoustics, Speech and Signal Processing, 1994: 93-96.
- Puzicha J, Held M, Ketterer J, et al. Spatial Quantization of Color Images[J]. IEEE Trans. on Image Processing, 2000, 9(4): 666-682.
- Sharma G, Trussell H J. Digital Color Imaging[J]. IEEE Trans. on Image Processing, 1997, 6(7): 901-932.
- Braquelair J P, Brun L. Comparison and Optimization of Methods of Color Image Quantization[J]. IEEE Trans. on Image Processing, 1997, 6(7): 1048-1052.
- Linde Y, Buzo A, Gray R. An Algorithm for Vector Quantizer Design[J]. IEEE Trans. on Comm, 1980, 28(1): 84-95.
- Heckbert P. Color Image Quantization for Frame Buffer Display [J]. ACM Trans. on Computer Graphics, 1982, 16(3): 297-307.
- Sirisathitkul Y, Auwatanamongkol S, Uyyanonvara B. Color Image Quantization Using Distances Between Adjacent Colors Along the Color Axis with Highest Color Variance[J]. Pattern Recognition Letters, 2004, 25(9): 1025-1043.

(上接第 179 页)

## 参考文献

- Vapnik V N. Statistical Learning Theory[M]. New York: Springer-Verlag, 1998.
- Joachims T. Making Large-scale SVM Learning Practical, Advances in Kernel Methods-support Vector Learning[M]. Cambridge Massachusetts: MIT Press, 2000: 169-184.
- Syed N A, Liu H, Sung K K. Handling Concept Drifts in Incremental Learning with Support Vector Machines[C]. Proc. of International Conference on Knowledge Discovery and Data Mining, 1999: 317-321.
- Lu B L, Ito M. Task Decomposition and Module Combination Based on Class Relations: A Modular Neural Network for Pattern Classification[J]. IEEE Transactions on Neural Networks, 1999, 10(5): 1244-1256.
- Tresp V. Scaling Kernel-based Systems to Large Data Sets[C]. Proc. of the 9<sup>th</sup> Pacificasia Conference on Knowledge Discovery and Data Mining, Hanoi, Vietnam, 2001: 197-211.
- Wen Y M, Lu B L. A Cascade Method for Reducing Training Time and the Number of Support Vectors[C]. Proc. of Advances in Neural Networks, Dalian, China, 2004: 480-485.
- Blake C L, Merz C J. UCI Repository of Machine Learning Database[EB/OL]. <ftp://ftp.ics.uci.edu/pub/machines-learning-database>, 1998.
- Ke H X, Zhang X G. Editing Support Vector Machines[C]. Proc. of the International Joint Conference on Neural Networks, Washington D.C., 2001: 1464-1467.