

Improved k-means Color Quantization based on Octree

Hyun Jun Park *, Kwang Baek Kim **

Abstract

In this paper, we present an color quantization method by complementing the disadvantage of K-means color quantization that is one of the well-known color quantization. We named the proposed method "octree-means" color quantization. K-means color quantization does not use all of the clusters because it initializes the centroid of clusters with random value. The proposed method complements this disadvantage by using the octree color quantization which is fast and uses the distribution of colors in image. We compare the proposed method to six well-known color quantization methods on ten test images to evaluate the performance. The experimental results show 68.29 percent of mean square error(MSE) and processing time increased by 14.34 percent compared with K-means color quantization. Therefore, the proposed method improved the K-means color quantization and perform an effective color quantization.

▶ Keyword : Color quantization, Octree, K-means, Image processing, Segmentation

I. Introduction

24비트를 이용하는 컬러 영상은 최대 16,777,216 가지 색을 사용할 수 있다. 다양한 색상을 표현 가능하다는 것은 미적인 부분이나 표현력을 올려줄 수 있다는 점에서 장점을 가진다. 하지만 문자 검출, 압축, 세그멘테이션, 내용기반검색, 워터마크, 색상 텍스처 분석 등의 많은 영상 분야에서 다양한 색상은 심각한 문제가 될 수 있다. 따라서 영상 내의 다양한 색상을 제한된 색상으로 표현하는 것에 대한 연구가 진행되어 왔고, 이를 색상 양자화라 한다[1, 2].

색상 양자화의 목적은 원본과의 왜곡을 최소화 하되, 이미지에 존재하는 많은 색상을 8bit 또는 그 이하 비트만을 사용하는 제한된 크기의 팔레트로 표현하는 것으로 원본 영상과의 차이가 적은 것이 보다 좋은 양자화 기법이라고 할 수 있다.

색상 양자화는 크게 영상 기반 기법과 영상 무관 기법으로 나뉜다. 영상 무관 기법(image-independent methods)은 이미지 내의 픽셀의 분포와 관계없는 팔레트를 생성한다. 그러므로 속도는 빠르지만 좋지 않은 결과를 나타낸다. 반대로 영상 기반 기법(image-dependent methods)은 이미지 내의 픽셀

분포를 이용하여 팔레트를 생성한다. 따라서 영상 무관 기법에 비해 느리지만 훌륭한 결과를 보여준다[3, 4].

영상 기반 기법에서 팔레트를 생성하는 것은 픽셀 색에 대한 클러스터링 과정이라고 할 수 있다. 그 중 K-means 클러스터링을 활용한 색상 양자화 기법은 비교적 빠른 속도로 색상 양자화가 가능하고 자연스러운 결과를 얻을 수 있다. 하지만 k개의 클러스터의 초기 값을 임의의 값으로 사용하기 때문에 한계가 발생한다. 따라서 본 논문에서는 K-means 알고리즘의 단점을 보완하여 보다 효율적인 색상 양자화 기법을 제안한다.

본 논문에서는 색상 양자화 기법들의 성능을 객관적으로 평가하기 위해 평균 절대 오차 (MAE: mean absolute error)와 평균 제곱 오차 (MSE : mean square error)를 측정하였다. 이는 수식 (1)과 (2)를 이용하여 계산하였다.

$$MAE(X, \hat{X}) = \frac{1}{HW} \sum_h \sum_w \| X(h, w) - \hat{X}(h, w) \|_1 \quad (1)$$

$$MSE(X, \hat{X}) = \frac{1}{HW} \sum_h \sum_w \| X(h, w) - \hat{X}(h, w) \|_2^2 \quad (2)$$

• First Author: Hyun Jun Park, Corresponding Author: Kwang Baek Kim

*Hyun Jun Park(hyunjun@pusan.ac.kr), Dept. of Computer Engineering, Pusan National University

**Kwang Baek Kim (gbkim@silla.ac.kr), Dept. of Computer Engineering, Silla University

• Received: 2015. 12. 02, Revised: 2015. 12. 08, Accepted: 2015. 12. 22.

II. K-means Color Quantization

K-means는 잘 알려진 클러스터링 기법이다. 이는 임의의 값을 가지는 K 개의 클러스터를 가지고 시작한다. 클러스터링은 매 반복에서 모든 입력 데이터와 각 클러스터의 거리를 계산해 최소 거리를 가지는 클러스터에 포함된다. 그리고 각 클러스터에 포함된 데이터의 평균값을 클러스터의 중심으로 다시 계산하고, 클러스터의 중심이 변경되지 않을 때 까지 반복된다. 클러스터가 수렴하면 클러스터의 중심 값을 이용하여 팔레트를 구성하고 양자화를 수행한다[5, 6].



(a) Quantized Image (b) Used Palette
Fig. 1. Results of K-means Color Quantization

그림 1은 K-means 알고리즘을 이용한 양자화 결과 예시를 보여준다. 색의 수 K가 커질수록 MAE, MSE 수치가 줄어들어 원본과의 오차가 줄어드는 것을 확인할 수 있다. 하지만 그림 1(b)에서 나타난 사용된 팔레트의 색상을 보면 영상과 무관한 색상들이 상당 수 포함되어 있는 것을 확인할 수 있다.

이는 K-means 알고리즘의 클러스터 중심값 초기화 방법에 의해 발생하는 결과이다. 즉, K 개의 클러스터를 생성하고 임의의 값으로 초기화하기 때문에 그림 1과 같이 전체적인 색상이 비슷한 영상의 경우 K 개 중 소수의 클러스터만이 입력 데이터와의 최소 거리를 가지게 되고 지속적으로 갱신, 수렴하는 결과를 가져오게 된다. 따라서 최대 K 개의 클러스터를 사용할 수 있음에도 소수의 클러스터만을 사용하여 팔레트를 생성하게 된다. 일반적으로 최대치인 K 개의 색상을 이용하여 영상을 양자

화했을 때 보다 좋은 결과를 가져올 수 있다는 것은 자명한 것이므로 이는 K-means 색상 양자화 기법의 큰 단점이 된다. 따라서 본 논문에서는 이러한 K-means 색상 양자화 기법의 단점을 보완하여 사용하는 클러스터의 수를 최대치에 가깝게 유도하는 방법을 제안한다.

III. Octree Color Quantization

Octree는 최대 8개의 자식 노드를 가질 수 있는 노드로 구성된 트리이다. 영상에서 색은 8 비트로 저장되어 있으므로 최대 8 레벨 깊이의 octree로 모든 색상을 표현 할 수 있다.

Octree 양자화 기법은 먼저 이미지 내의 색깔의 분포를 옥트리를 이용하여 표현한다. 영상 내의 모든 색상을 octree에 추가한 뒤, K개의 노드가 남을 때까지 노드를 합쳐 팔레트를 구성한다[7]. 따라서 octree 양자화 기법은 팔레트를 생성할 때 색상 분포를 활용함에도 팔레트 생성 속도가 매우 빠르다는 장점이 있다.

반면에 Octree 양자화 기법은 색상의 빈도수는 고려하지 않는다. 전체적으로 비슷한 색상으로 이루어져 있지만 곳곳에 다른 적은 수의 다양한 색상 또는 잡음이 많이 존재하는 영상의 경우에는 팔레트에 빈도수가 적은 색상이 많이 포함되어 성능이 매우 떨어질 수 있다. 이는 그림 2 (b)의 사용된 팔레트를 보면 알 수 있다. 영상에서 배경색과 붉은색이 많은 비중을 차지하고 있지만 사용된 팔레트를 보면 K가 8, 16일 때는 각각 1개의 색상, K가 32일 때 붉은색 1개, 배경색 3개 밖에 없다. 하지만 그로인해 영상내의 다양한 색상을 포함할 수 있다는 점은 장점으로 작용할 수 있다.



(a) Quantized Image (b) Used Palette
Fig. 2. Results of Octree Color Quantization

본 논문에서는 아래와 같은 octree 양자화 기법의 특징을 활용하여 K-means 색상 양자화 기법의 단점을 보완한다.

- 1) 팔레트를 생성하는 시간이 짧다.
- 2) 영상 내의 색상을 이용하여 팔레트를 생성한다.
- 3) 최대한 다양한 색상을 이용해 팔레트를 구성한다.

IV. Octree-means Color Quantization

본 논문에서는 위에서 언급된 K-means 색상 양자화 기법의 단점인 소수의 클러스터만 이용되는 단점을 보완하는 기법을 제안한다.

제안하는 기법은 octree를 활용한 K-means 색상 양자화 기법이므로 octree-means라고 명명한다. Octree-means의 전체적인 수행과정은 그림 3에서 나타낸다.

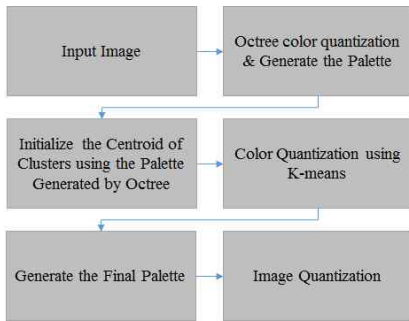


Fig. 3. Overall Process of Octree-means quantization

K-means 색상 양자화의 단점의 원인이 클러스터 중심값을 임의의 값으로 초기화 하는 것이므로 제안하는 기법에서는 원본 영상의 색상을 이용하여 초기화한다.

따라서 초기 클러스터 중심 값을 결정하기 위해 원본 영상의 색상을 분석해야 한다. 이 과정은 원본 영상의 색상 분포가 고려되어야 하고 원본 영상의 색상을 최대한 많이 포함해야 하며, 그 속도가 빨라야 한다는 조건을 만족해야한다. 이러한 조건을 모두 만족하는 방법이 바로 octree 양자화 기법을 이용한 팔레트 생성이다. 따라서 제안하는 알고리즘은 octree 양자화 기법을 이용해 팔레트를 생성하고, 생성된 팔레트의 색상을 이용하여 K-means의 초기 클러스터의 중심 값을 초기화한다.

이는 K 개의 초기 클러스터의 중심 값이 원본 영상과 비슷한 색상으로 구성되기 때문에 K 개의 클러스터 모두 고르게 사용될 수 있도록 하여 기존의 K-means보다 뛰어난 결과를 얻을 수 있도록 한다. 또한 octree 양자화 기법의 장점인 다양한 색상 표현이 가능해지므로 보다 원본과 비슷한 결과물을 얻을 수 있도록 한다.

V. Experiment and Analysis

Octree-means 색상 양자화 기법의 성능을 평가하기 위해 Intel i5-4460 3.2 GHz CPU, 8.0 GB RAM 사양의 PC를 사용하였고 각 색상 양자화 기법은 Visual Studio 2013에서 C++ 언어로 개발하였다. 총 10장의 24비트 영상을 이용하였으며 그림 4에서 볼 수 있다. 또 각 실험 영상들의 색상 수, 해상도는 표 1에서 확인할 수 있다.




Fig. 4. Test Images

Table 1. Test Image Informations

Image	Resolution	Colors
Lenna	512×512	148,279
Airplane	512×512	77,041
Mandrill	512×512	230,427
Motocross	768×512	63,558
Peppers	512×512	183,525
Parrots	768×512	72,079
Girl	768×512	44,576
Mona Lisa	1280×1920	125,240
House	1280×1024	363,724
Venus	1848×1173	396,799

실험 영상은 많은 영상 처리 관련 논문에서 사용되는 영상들과 보다 다양한 영상에 대한 적응력을 실험하기 위해 모나리자와 같은 그림들도 포함하였다.

우리는 잘 알려진 색상 양자화 기법들인 Popularity (POP) [1], Median-Cut (MC) [1], Octree (OCT) [1], K-means (KM) [5], Adaptive Resonance Theory 2 (ART2) [8], Self-Organizing Maps (SOM) [1]과의 비교를 통해 제안된 기법 (PM)의 성능을 평가하였다.

그림 5는 실험 영상 10장 중 5장에 대한 결과 예시이다. 왼쪽의 그림은 K=8일 때 K-means로 생성된 결과 영상이다. 가장 오른쪽 그림은 K=8일 때 octree-means로 생성된 결과이다. 결과 영상을 보았을 때 K-means 색상 양자화 보다 다양하고 선명한 색상으로 결과 영상이 표현되어 있어 원본과 보다 비슷한 결과를 얻을 수 있음을 확인할 수 있다.

또한 그림 5의 팔레트들은 순서대로 K-means, octree, octree-means 기법으로 생성된 팔레트이다. 2장에서 보았듯이 K-means의 팔레트는 소수의 클러스터만이 사용되어 있음을 확인할 수 있다. Octree의 팔레트는 원본과 비슷한 색상으로 구성되어 있지만 빈도수가 고려되어 있지 않아 MAE, MSE

수치가 높은 결과물이 생성된다. 반면 제안하는 기법으로 생성된 팔레트는 octree의 장점을 이용하여 다양한 색상을 가지고 있으며 다수의 클러스터를 사용하기 때문에 기존의 방법 보다 MAE, MSE 수치가 낮은 결과물을 생성할 수 있었다.




Fig. 5. Comparison of Color Quantization Methods

표 2, 3은 각 색상 양자화 기법을 이용하여 생성한 결과 영상과 원본 영상의 MAE, MSE를 측정된 결과이다. 표에서 상위 2개의 기법은 진하게 표시하였다. 대부분의 영상에서 제안하는 기법은 SOM과 함께 상위 2개의 기법으로 평가되었다. SOM 색상 양자화 기법이 대체적으로 더 낮은 MAE, MSE 수치를 보이지만 표 4에서 측정된 실행 속도를 보면 제안하는 기법의 속도가 SOM 기법보다 빠르므로 빠른 속도가 요구되는 응용 분야에서는 보다 사용하기에 적합할 것이다.

또한 기존의 K-means 기법에 비해 수행시간은 평균 14.34% 증가하였으나 결과물은 평균 68.29% MSE를 기록하였다. 수행시간이 다소 증가하였으나 결과물의 성능향상의 폭이 보다 큰 것을 알 수 있다.

Table 2. MAE Comparison

<i>Lenna</i>						
	8	16	32	64	128	256
POP	41.52	36.60	21.97	16.11	12.67	11.89
MC	31.00	25.12	19.36	15.11	11.51	8.61
OCT	35.88	32.80	23.34	15.47	12.86	9.59
KM	39.40	26.45	21.86	20.88	14.79	12.24
ART2	31.11	22.07	18.45	12.42	10.27	8.51
SOM	27.35	19.49	14.07	10.93	8.59	6.88
PM	27.82	22.02	15.56	11.22	9.21	7.42
<i>Airplane</i>						
	8	16	32	64	128	256
POP	59.37	23.38	19.22	14.86	12.59	12.06
MC	23.23	16.51	14.25	10.61	8.86	7.40
OCT	33.28	32.87	19.26	14.14	11.34	7.73
KM	27.97	15.53	13.92	12.86	9.92	8.82
ART2	29.66	23.42	16.09	10.48	7.54	6.15
SOM	21.22	13.24	9.41	7.27	5.81	4.65
PM	23.89	18.67	11.42	8.37	6.96	5.81
<i>Mandrill</i>						
	8	16	32	64	128	256
POP	78.59	56.88	40.88	30.96	21.08	15.73
MC	69.26	64.60	58.96	46.17	33.81	21.57
OCT	55.25	51.28	38.98	27.16	21.96	17.91
KM	48.12	38.59	28.17	24.61	19.78	16.70
ART2	50.70	37.32	29.17	24.82	20.00	16.30
SOM	45.32	34.22	25.91	20.40	16.43	13.16
PM	45.13	35.47	27.25	20.93	17.63	13.94
<i>Motocross</i>						
	8	16	32	64	128	256
POP	56.45	53.23	33.18	19.30	15.92	13.20
MC	37.77	30.89	26.34	20.23	16.50	12.43
OCT	62.49	35.97	31.80	23.41	16.84	13.52
KM	35.27	29.87	24.23	18.22	16.00	13.12
ART2	47.04	31.64	23.66	19.23	14.35	11.71
SOM	33.40	25.50	18.11	13.31	10.23	7.89
PM	35.67	24.95	20.59	15.66	12.18	10.17
<i>Peppers</i>						
	8	16	32	64	128	256
POP	64.67	42.81	35.32	21.36	15.99	13.27
MC	42.38	32.59	26.07	21.05	17.41	13.57
OCT	48.87	38.11	32.55	22.80	17.65	15.12
KM	57.98	27.97	27.76	20.26	16.67	13.45
ART2	44.36	30.44	23.07	18.94	14.46	12.16
SOM	35.49	26.40	19.85	15.01	11.62	9.23
PM	40.54	29.46	22.58	17.44	13.38	11.09
<i>Parrots</i>						
	8	16	32	64	128	256
POP	101.62	73.54	58.84	22.54	16.48	13.59
MC	64.83	52.10	36.86	25.12	17.78	12.80
OCT	53.85	38.23	28.58	20.25	16.30	12.59
KM	44.82	34.88	26.99	19.12	17.39	13.77
ART2	43.76	35.32	25.88	18.32	14.18	11.34
SOM	42.44	28.33	20.78	15.03	11.49	8.74
PM	42.26	27.90	21.57	15.78	12.27	9.45
<i>Girl</i>						
	8	16	32	64	128	256
POP	45.86	40.24	23.37	19.10	15.73	14.47
MC	40.80	28.59	21.08	15.63	12.61	9.76
OCT	52.96	36.49	29.01	25.26	14.07	12.38
KM	43.25	26.91	21.69	18.13	14.36	10.95
ART2	37.60	30.32	20.93	14.54	11.52	8.47
SOM	30.13	20.03	14.56	11.04	8.27	6.06
PM	33.21	23.24	19.33	14.96	9.89	8.61
<i>Mona Lisa</i>						
	8	16	32	64	128	256
POP	40.43	28.05	20.41	14.21	12.88	12.46
MC	25.15	20.32	16.09	12.47	9.35	7.44
OCT	29.72	24.76	16.30	13.37	10.35	8.87
KM	39.05	27.14	16.71	16.40	14.77	10.98
ART2	29.16	21.79	16.26	12.31	9.45	7.57
SOM	25.85	17.55	13.47	9.68	7.30	5.57
PM	21.70	17.19	11.75	10.07	7.64	6.62
<i>House</i>						
	8	16	32	64	128	256
POP	62.60	52.16	39.11	29.68	21.54	15.75
MC	63.62	54.86	39.59	27.52	20.19	15.88
OCT	51.44	43.25	40.95	25.90	24.76	17.60
KM	40.56	31.99	26.57	23.21	18.40	16.30
ART2	44.08	33.44	29.29	23.60	18.80	15.30
SOM	47.25	33.53	23.57	18.63	14.75	11.81
PM	41.82	31.26	24.67	19.36	17.38	13.21
<i>Venus</i>						
	8	16	32	64	128	256
POP	109.61	46.52	32.95	23.75	17.32	13.84
MC	41.84	35.70	33.33	27.45	20.26	15.12
OCT	68.62	56.30	34.88	31.97	22.93	17.78
KM	43.86	31.92	26.49	20.91	17.73	14.78
ART2	44.56	37.42	31.17	22.28	17.94	13.66
SOM	42.50	30.23	21.85	16.87	13.43	10.70
PM	41.12	32.33	21.76	19.34	15.10	12.07

Table 3. MSE Comparison

<i>Lenna</i>						
	8	16	32	64	128	256
POP	1296.19	1144.61	336.14	175.10	79.80	64.79
MC	577.78	412.40	264.53	163.62	94.84	46.98
OCT	692.64	580.59	273.48	126.13	85.35	47.47
KM	828.71	362.88	249.16	221.79	117.76	82.06
ART2	516.97	257.92	182.95	82.89	55.98	37.84
SOM	400.56	210.82	110.18	67.62	42.44	27.86
PM	413.14	253.54	131.90	69.13	46.64	31.01
<i>Airplane</i>						
	8	16	32	64	128	256
POP	4237.79	593.56	382.18	174.13	85.90	67.51
MC	576.46	366.40	314.49	164.68	125.32	52.01
OCT	605.99	592.13	228.21	120.79	66.67	36.30
KM	441.76	155.96	118.45	91.97	61.03	47.23
ART2	482.78	281.87	140.89	64.44	35.09	23.16
SOM	285.62	138.83	69.77	43.53	28.00	19.45
PM	331.28	191.21	95.46	50.68	32.39	23.01
<i>Mandrill</i>						
	8	16	32	64	128	256
POP	3878.91	2233.48	1200.56	739.96	305.65	151.73
MC	3308.92	3054.12	2614.88	1619.92	801.49	347.21
OCT	1544.71	1358.61	841.17	379.07	245.60	153.71
KM	1216.97	819.05	418.58	325.25	206.02	145.18
ART2	1339.07	733.36	436.95	319.55	206.31	135.44
SOM	1092.94	626.21	356.61	222.21	144.68	92.96
PM	1079.15	657.72	391.97	230.24	163.23	100.77
<i>Motocross</i>						
	8	16	32	64	128	256
POP	3339.25	3225.45	1278.74	334.35	213.68	97.04
MC	1084.26	753.17	598.26	442.91	332.50	206.62
OCT	1993.32	811.87	614.18	305.38	159.43	96.06
KM	723.85	524.25	311.68	183.85	138.62	92.69
ART2	1117.24	523.50	294.68	197.34	109.13	73.04
SOM	698.04	377.23	194.82	113.73	69.29	41.63
PM	739.63	362.73	232.87	137.28	81.78	57.00
<i>Peppers</i>						
	8	16	32	64	128	256
POP	2987.70	1649.58	1313.85	354.38	214.13	127.15
MC	1086.20	681.43	471.13	346.79	259.67	179.34
OCT	1300.75	835.20	595.93	281.11	166.32	116.63
KM	2217.36	438.89	439.08	227.10	151.93	98.55
ART2	1099.53	523.09	291.81	197.90	113.17	77.37
SOM	734.20	410.99	225.10	128.16	77.81	50.55
PM	943.72	512.68	289.89	165.92	97.82	66.52
<i>Parrots</i>						
	8	16	32	64	128	256
POP	8796.12	5976.08	4102.21	362.58	179.50	104.06
MC	2733.22	1716.26	999.73	508.56	274.37	142.87
OCT	1479.23	915.61	469.85	244.62	144.71	85.41
KM	1103.53	738.43	396.79	203.05	166.87	103.99
ART2	1085.78	657.27	353.44	179.73	105.81	68.03
SOM	1027.18	452.62	249.65	135.90	78.04	47.46
PM	990.29	470.65	255.15	144.78	84.65	50.51
<i>Girl</i>						
	8	16	32	64	128	256
POP	1660.82	1415.03	428.17	284.47	148.45	109.36
MC	1261.27	665.46	398.57	233.94	164.81	86.25
OCT	1431.67	721.27	450.41	362.15	112.03	85.28
KM	1026.00	388.33	264.22	182.73	115.32	70.71
ART2	728.70	487.37	238.97	116.28	74.21	40.32
SOM	575.30	250.76	139.33	79.68	47.27	26.17
PM	599.41	331.93	223.35	126.77	58.22	43.46
<i>Mona Lisa</i>						
	8	16	32	64	128	256
POP	1330.14	658.69	320.20	103.38	76.45	69.04
MC	496.45	330.87	211.67	131.15	60.33	33.20
OCT	536.28	340.30	155.47	97.35	61.00	43.26
KM	953.49	442.66	167.86	151.11	120.42	68.90
ART2	523.11	275.68	147.80	83.95	48.88	30.16
SOM	482.99	204.07	123.51	59.71	34.00	20.33
PM	291.84	167.50	84.26	57.98	34.27	24.98
<i>House</i>						
	8	16	32	64	128	256
POP	2758.12	2044.43	1305.08	844.53	399.13	175.60
MC	2406.95	2003.09	1307.81	674.61	338.84	211.01
OCT	1451.21	1058.83	958.51	370.73	339.29	151.88
KM	971.78	577.57	396.73	301.62	188.99	144.72
ART2	1137.80	619.95	480.99	306.32	189.67	121.59
SOM	1162.79	604.82	324.07	203.35	127.86	81.74
PM	962.11	552.72	350.32	221.95	177.84	95.53
<i>Venus</i>						
	8	16	32	64	128	256
POP	7759.77	1591.56	899.69	450.81	208.93	110.43
MC	1107.58	884.40	805.73	577.91	303.01	179.18
OCT	2290.20	1609.28	600.30	497.89	286.17	150.57
KM	967.32	536.75	374.34	240.09	170.13	120.53
ART2	987.40	691.02	499.02	261.68	165.98	99.83
SOM	1067.00	575.79	286.36	172.62	107.30	68.17
PM	874.61	533.46	275.02	201.40	132.80	79.03

Table 4. Processing Time Comparison

<i>Lenna</i>						
	8	16	32	64	128	256
POP	2	2	2	2	3	3
MC	2	2	2	2	4	3
OCT	6	7	7	8	9	9
KM	40	52	81	129	186	366
ART2	41	39	44	81	290	599
SOM	81	101	126	296	308	488
PM	45	58	86	138	244	447
<i>Airplane</i>						
	8	16	32	64	128	256
POP	2	2	2	2	3	3
MC	2	2	2	2	2	2
OCT	6	6	8	9	8	9
KM	40	54	85	123	248	221
ART2	30	36	47	78	292	559
SOM	84	92	137	176	354	474
PM	46	59	89	142	286	475
<i>Mandrill</i>						
	8	16	32	64	128	256
POP	2	3	4	3	3	6
MC	2	2	2	2	3	3
OCT	5	6	6	7	7	9
KM	45	57	85	138	229	428
ART2	52	87	163	302	701	1386
SOM	90	120	144	218	471	619
PM	56	63	92	139	265	498
<i>Motocross</i>						
	8	16	32	64	128	256
POP	3	3	3	4	4	13
MC	3	4	3	4	3	4
OCT	8	9	52	11	11	12
KM	68	86	125	202	472	636
ART2	81	120	217	476	798	1642
SOM	133	157	207	393	460	772
PM	70	97	139	232	366	688
<i>Peppers</i>						
	8	16	32	64	128	256
POP	2	3	2	2	3	10
MC	2	2	2	2	3	2
OCT	5	9	9	7	8	7
KM	39	53	84	127	200	373
ART2	48	74	125	243	497	1015
SOM	85	102	136	208	490	539
PM	48	62	92	154	260	437
<i>Parrots</i>						
	8	16	32	64	128	256
POP	3	3	5	9	5	5
MC	3	5	3	4	4	8
OCT	9	10	9	10	11	13
KM	62	82	194	219	334	608
ART2	63	91	157	294	481	957
SOM	140	156	204	365	473	803
PM	72	90	142	237	362	646
<i>Girl</i>						
	8	16	32	64	128	256
POP	3	3	6	3	4	6
MC	3	4	3	3	4	4
OCT	8	12	9	12	10	12
KM	61	77	118	190	430	610
ART2	47	114	197	400	505	975
SOM	129	207	190	271	427	721
PM	69	86	128	204	345	667
<i>Mona Lisa</i>						
	8	16	32	64	128	256
POP	19	19	22	20	22	20
MC	20	19	19	20	19	21
OCT	56	57	71	64	71	75
KM	352	644	720	1311	1142	2005
ART2	264	303	448	688	1383	5992
SOM	729	854	1158	1714	2712	4462
PM	446	552	806	1255	2236	4211
<i>House</i>						
	8	16	32	64	128	256
POP	10	11	11	12	12	13
MC	11	11	11	13	11	12
OCT	29	33	31	34	33	40
KM	215	284	411	643	1161	2100
ART2	390	598	861	1930	3713	7657
SOM	424	786	745	1248	1764	2852
PM	225	314	440	705	1258	2346
<i>Venus</i>						
	8	16	32	64	128	256
POP	18	17	34	20	18	19
MC	18	17	22	17	18	18
OCT	43	46	61	52	56	57
KM	345	586	658	1173	1826	3357
ART2	606	701	1385	3023	6325	13604
SOM	702	845	1158	1662	2598	4393
PM	382	619	724	1141	1997	3559

VI. Conclusions

본 논문에서는 octree-means 라고 명명한 효율적인 양자화 기법을 제안하였다. 잘 알려진 색상 양자화 기법 중 하나인 K-means 색상 양자화 기법의 단점을 보완하여 보다 효율적인 색상 양자화 알고리즘을 제안한다. 기존의 K-means 색상 양자화 기법은 K 개의 클러스터의 초기 중심값을 임의의 값으로 설정하기 때문에 K 개의 클러스터를 모두 활용하지 못하고 소수의 클러스터만으로 영상을 양자화 하는 문제가 있다. 따라서 K 개의 모든 클러스터를 양자화에 활용할 수 있도록 하면 보다 좋은 결과를 얻을 수 있을 것이다.

본 논문에서는 K-means 색상 양자화 기법의 단점을 보완하기 위하여 octree 색상 양자화 기법을 활용한다. octree 색상 양자화 기법은 빠르고 영상의 색상 분포를 활용하지만 빈도수는 고려되지 않은 팔레트를 생성한다. 그로 인해 팔레트에는 원본 영상의 다양한 색상이 존재하게 된다. 따라서 K-means의 초기 클러스터 중심값으로 octree 팔레트의 색상 값을 이용하게 되면 K개의 클러스터를 모두 활용할 수 있도록 유도하는 결과를 얻을 수 있다.

제안하는 기법의 성능을 평가하기 위해 총 10장의 영상에 대해 잘 알려진 6개의 색상 양자화 기법과 비교를 하였다. 비교는 MAE, MSE, 수행 시간을 측정하는 방법을 사용하였다. 실험 결과 기존의 K-means 기법에 비해 평균 68.29%의 평균 제곱 오차를 보였다.

실험 결과 제안된 기법은 SOM 색상 양자화 기법과 함께 효과적인 양자화 결과를 보여주었다. 제안하는 기법은 SOM 색상 양자화 기법보다 최종 결과물은 약간 떨어질 수 있지만 더 빠른 속도를 보여주므로 빠른 속도를 요구하는 응용에 있어서 SOM 색상 양자화 기법보다 활용 가능성이 높다고 할 수 있다.

REFERENCES

- [1] H. J. Park, E. Y. Cha, and K. B. Kim, "An Effective Color Quantization Method Using Color Importance-Based Self-Organizing Maps," *Neural Network World*, Vol. 25, No. 2, pp. 121-137, Mar. 2015.
- [2] M. E. Celebi, "An Effective Color Quantization Method Based on the Competitive Learning Paradigm," In *The 2009 International Conference on Image Processing, Computer Vision, and Pattern Recognition (ICCV'09)*, pp. 876-880, Jul. 2009.
- [3] L. Brun, A. Tre'meau, "Color quantization," In *Digital Color Imaging Handbook*, CRC Press, Boca Raton, Florida, USA, pp. 589-638, Dec. 2002.
- [4] M. E. Celebi, Q. Wen, and S. Hwang, "An effective real-time color quantization method based on divisive hierarchical clustering," *Journal of Real-Time Image Processing*, Vol. 10, No. 2, pp. 329-344, Nov. 2012.
- [5] Y. C. Hu, and M. G. Lee, "K-means based color palette design scheme with the use of stable flags," *Journal of Electronic Imaging*, Vol. 16, No. 3, pp. 033003-033003, Jul. 2007.
- [6] Y. C. Hu, and B. H. Su, "Accelerated k-means clustering algorithm for colour image quantization," *The Imaging Science Journal*, Vol. 56, No. 1, pp. 29-40, Feb. 2008.
- [7] M. Gervautz, and W. Purgathofer, "A simple method for color quantization: Octree quantization," In *New trends in computer graphics*, Springer Berlin Heidelberg, pp. 219-231, 1988.
- [8] K. B. Kim, M. Kim, and Y. W. Woo, "Recognition of shipping container identifiers using art2-based quantization and a refined rbf network," In *Adaptive and Natural Computing Algorithms*, Springer Berlin Heidelberg, pp. 572-581, Apr. 2007.

Authors



Hyun Jun Park received his M.S. degrees from the Department of Computer Science, Pusan National University, Busan, Korea, in 2009. From 2009 to the present, he is a Ph.D. course student at the Department of Computer Engineering, Pusan National University, Korea. His research interests include computer vision, image processing, neural network and applications.



Kwang Baek Kim received his M.S. and Ph.D. degrees from the Department of Computer Science, Pusan National University, Busan, Korea, in 1993 and 1999, respectively. From 1997 to the present, he is a professor at the Department of Computer Engineering, Silla University, Korea. He is currently an associate editor for *Journal of Intelligence and Information Systems* and *The Open Computer Science Journal (USA)*. His research interests include fuzzy neural network and applications, bioinformatics, and image processing.