

칼라 이미지 디더링 알고리즘에 관한 연구

이 태 경, 최 두 일, 조 우 연
공주대학교 전기전자정보공학과
전화 : 041-850-8607

Algorithm for Dithering Color Images

Tae Kyoung Lee, Doo Il Choi, Woo Yeon Cho
Dept. of Electrical, Electronic, Information and Communcation Engineering,
Kongju University
E-mail : tklee@imusicsoft.com

Abstract

In this study, an algorithm for dithering true color image to 8-bit indexed color image using Artificial Neural Network was proposed.

An adaptive vector quantization algorithm based on Artificial neural network was proposed for dithering color images.

To evaluate the proposed algorithm, Mean Square Error(MSE) and quality between original image and dithered image was compared to those of other algorithm.

As a results, MSE of proposed algorithm was lower than that of other algorithm used in commercial application and quality of dithered image was also highly improved.

True-Color 칼라로 제작된 영상을 GIF로 바꾸는 과정에서 디더링을 하게 된다. 예를 들어 ACDSEE 혹은 PhotoShop에서 디더링을 하는 과정에서 어떠한 알고리즘을 선택하는가에 따라서 디더링된 영상의 질은 다소 차이가 있다. 이것은 그래픽 어플리케이션이 채택한 알고리즘의 성능의 결과라고 볼 수 있다.

24비트 True-Color 영상을 칼라 테이블을 이용한 8비트 영상으로 표현하기 위해서는 팔레트라고 불리는 최적화된 칼라 테이블을 생성해야 한다.

이러한 작업을 디더링이라 하며, 일종의 벡터 양자화(Vector Quantization)의 영역으로 해석할 수 있다. 벡터 양자화는 확률 분포에 따라서 최소의 MSE(평균 자승오차)를 내는 양자화가 필요하다. 이러한 벡터 양자화를 신경망 알고리즘의 경쟁 학습을 통해 구현하고 보고자 하며 이를 칼라 영상의 디더링에 적용했다.

I. 서론

디더링(Dithering)은 입력 영상이 가진 색상보다 출력 장치의 표현 색상이 적을 경우 출력 장치에 표현될 수 있는 색상으로 다시 렌더링을 하는 절차를 디더링(Dithering)이라고 한다.

인터넷 브라우저에서 가장 많이 쓰이는 그래픽 포맷인 GIF의 경우 256색상이 한계이다.

II. 칼라 이미지 디더링

1. 인덱스 칼라

자연계에서의 빛은 빨강, 초록, 파랑으로 이루어져 있다. 컴퓨터 시스템에서는 각각의 요소들을 최대 256 단계로 양자화(quantization)된다. 일반적으로 24비트 영상은 R, G, B 각각 8bit 씩 할당해서 총 24비트로 색상을 만들어 낸다. 8비트 영상으로 칼라를 표현할때

는 팔레트(Palette)라고 부르는 색상 테이블을 이용한다. 8비트로 색상 배분을 하기에는 R, G, B의 양자화 단계가 너무 낮아 표현할 수 있는 색상이 너무 적기 때문에 16만 칼라 중에서 256개를 골라 쓰는 방식으로 표현하게 된다. 8비트로 16만가지의 모든 색을 표현할 수 있지만 동시에 256칼라 밖에 쓸 수 없게 된다.[1]

팔레트는 사용자가 원하는 256가지의 칼라를 기술해 놓은 색상 테이블이다. 사용자가 원하는 색을 정확히 알려주기 위해 R,G,B순으로 저장되며 256개 반복된다. (팔레트 정보의 총 바이트 수 = 3바이트 x 256 = 768 bytes) 8비트 칼라는 256개의 팔레트 정보를 가지고 1바이트의 점을 표현한다. 이때 1바이트에 해당하는 것을 "인덱스 칼라"라고 하며 이것은 어떤 팔레트인지를 가리키는 지표일 뿐이지 색상 그 자체가 아니다.

이런 식으로 색상을 표시하는 방식을 인덱스 컬러라고 한다.[2]

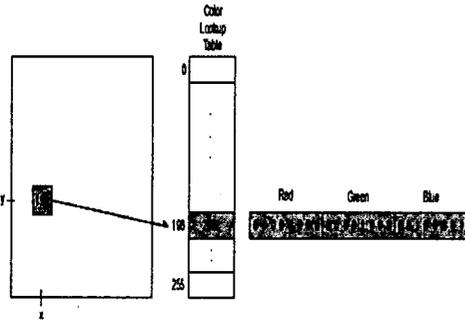


그림 1. 색상 테이블(Color Lookup Table)

2. 디더링(Dithering)

디더링을 하프톤, 혹은 칼라 축소라고 한다. 입력 영상이 가진 색상보다 출력 장치의 표현 색상이 적을 경우 출력 장치에 표현될 수 있는 색상으로 다시 렌더링을 하는 절차를 디더링이라고 한다.

[그림 3] 은 24비트 영상의 True Color 영상을 8비트 영상의 256칼라로 디더링 한 예이다.[2]



그림 2. 24비트 영상



그림 3. 디더링된 영상

3. 칼라 영상의 디더링

24비트 True-Color 영상을 8비트로 양자화 하면서

일반적으로 팔레트라고 하는 칼라 인덱스를 사용한다. 팔레트는 사용자가 원하는 256가지의 칼라를 기술해 놓은 것이 색상 테이블이다. 이러한 색상 테이블은 R, G, B 순으로 저장된 256개의 배열이다. 입력 영상이 24비트 True-Color 이미지라고 할지라도 실제로 16만가지의 색상을 다 쓰지 않기 때문에 이때 최적의 색상 256개로 양자화 과정이 필요하다.

16만가지의 색상에서 최적화된 256개의 색상을 선별하는 작업이 디더링의 단계에서 아주 중요한 요소를 차지 한다.

입력된 영상의 각 픽셀을 R,G,B 컴포넌트를 정육면체(cube)에 매핑(mapping)할 경우 R,G,B 3차원의 입력 벡터라고 생각 할 수 있으며 256단계로 양자화된 칼라 테이블을 생성을 벡터 양자화 알고리즘을 적용하여 취득할 수 있다.

III. 신경망을 이용한 디더링 알고리즘

1. 적응 벡터 양자화 기법의 기본 알고리즘

적응 벡터 양자화 기법의 기본 알고리즘은 다음과 같다.

(Step1) 코드북 벡터를 먼저 초기화 한다.

(Step2) 입력 벡터중 무작위로 하나 선택한다.

(Step3) 입력 벡터와 코드북 벡터중 가장 가까운 코드북 벡터를 찾는다.

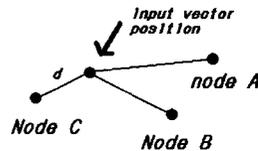


그림 4. 입력 벡터와 코드북 벡터와 거리

(Step4) Step3에서 찾은 코드북 벡터를 Step2에서 선택한 벡터쪽으로 a 만큼 조정한다.

$$\Delta w_i^* j = a(x_j - w_i^* j) \quad (1)$$

(Step5) Step2부터 반복한다.

a 는 학습률 또는 학습 강도라고 할 수 있으며 실험을 통해 적절하게 조정될 수 있다.

2. 2차원 벡터 적응

24비트 영상의 색상 컴포넌트 R,G,B 중 하나의 색상을 생각하지 않고 두가지 색 (예를 들어 R,G) 만을 고려할 때 입력 벡터를 2차원으로 생각 할 수 있다.

[그림 5]에서 굵은 점들이 코드북 벡터이며 무작위로 분포되어 있다. 학습후 [그림 6]과 같이 코드북 벡터들

이 입력 벡터 사이에 위치한다.

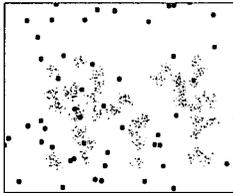


그림 5. 학습전



그림 6. 학습후

3. 3차원 벡터 적용

[그림 7]은 원본 이미지의 RGB 분포도를 나타낸 것이다. 검은 점은 초기의 코드북 벡터(팔레트)이며 학습 후 [그림 8]과 같이 입력 벡터 사이에 위치한다.



그림 7. 학습전



그림 8. 학습후

IV. 실험 및 결과 고찰

1. 학습 시간에 따른 비교 결과

적용 VQ에서는 학습이라는 일련의 반복된 프로세싱을 통해서 이상적인 코드 벡터를 형성하게 된다. 이러한 반복작업의 치명적인 단점은 단일 루프의 알고리즘과 비교해서 연산량이 증가하게 되며 실제 일정선에 도달하면 더 이상 학습이 진행되지 않는다.

[그림 9]는 30만번까지 학습을 진행했을때 MSE를 측정한 결과이다. 가로축은 학습 진행 시간축(1000단위)이며 세로축은 MSE 결과이다. [그림 9]에서처럼 일정선에 도달하게 되면 더 이상 학습은 진행되지 않

때문에 적당한 학습 횟수를 정할 필요가 있다.



그림 9. 30만번까지 학습을 진행 했을때 MSE 측정

3. 학습률(α)에 따른 비교 결과

[그림 10]은 실험을 위해서 5만번 정도의 학습을 한 MSE 결과이다. 가로 축은 MSE를 나타내며 세로축은 학습률(학습강도)를 나타낸다. [그림 10]에 따르면 학습률이 0.9이면 MSE가 60을 넘기 때문에 그래프상에 나타나지도 않는다. 0.1까지 MSE가 낮아지는 것을 볼 수 있다. 그리고 0.1 이하일 경우 오히려 MSE가 증가한다. 실험을 통해서 5만번 정도의 학습을 진행했을때 학습률(α)은 0.1이 최적이라고 할 수 있다.

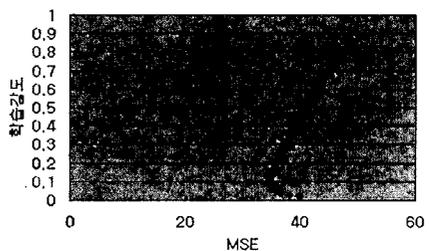


그림 10 학습강도에 따른 MSE 결과

4. 학습 향상을 위한 가변 학습률 실험

위 실험에서 최적의 VQ 적용을 위한 학습횟수는 5만번 학습률은 0.1이라고 실험의 결과로 판단할 수 있다. 학습률 5만번은 실제 알고리즘에 속도 개선의 최적화 이루어지면 현재의 컴퓨터 시스템에서는 무리가 없다. 하지만 학습횟수를 높이면 MSE 수치가 낮아지기 때문에 5만번 내에서 알고리즘 개선으로 학습률을 더 높힐 수 있는 방법을 생각할 수 있다.

입력 공간 상에 무작위로 분포된 코드벡터들이 초기에 근접한 자리에 재빨리 찾아가서 학습을 진행하면서 정밀한 위치에 정착하는 방법으로 학습률 0.1을 고정시키는 것이 아니라 가변적으로 조정해보았다.

(1) 선형 학습률

[식 2]는 학습 횟수를 5만번일때 학습률을 1에서 0.1 까지 하향되는 선형 함수이다.

$$a = -\frac{0.9}{50000}t + 1 \quad (2)$$

(2) 지수형 학습률

학습률을 초기에 급격히 감소 시키며 천천히 감소하는 지수형의 학습률을 생각할 수 있다.

[식 2]는 학습률 a 가 지수형으로 하향되도록 만든 것이다.

$$a = 0.99995^{2t} \quad (3)$$

[표 1]에 따르면 5만번까지 학습을 진행한 경우 지수형 학습률이 훨씬 낮은 MSE 수치를 가르키고 있음을 확인할 수 있다. 따라서 한정된 5만번의 루프에서 기본 적용 VQ 벡터 양자화 알고리즘이 가변 학습률을 적용하여 좀더 개선시킬 수 있다.

학습률	MSE
고정 0.1	35.223129
선형	35.280472
지수형	33.409454

표 1. 가변 학습률 실험 표

3. 렌더링 알고리즘 비교

제안한 신경망을 이용한 디더링 방법을 다른 디더링 알고리즘 및 상용 그래픽 어플리케이션에서 쓰이는 알고리즘과 MSE 측정을 통해서 비교하였다.

알고리즘	MSE
오차확산디더링	1007.129105
알씨	127.404572
ACDSEE	103.247177
Floyd Steinberg	83.752762
포토샵	53.898163
신경망디더링	33.409454

표 2. MSE 비교표

V. 결론

본 논문에서는 칼라 영상의 디더링의 한 방법으

로 신경망을 이용한 알고리즘을 제안했다. 신경망 이론의 가장 기본적인 경쟁학습 이론을 바탕으로 적용 VQ 양자화를 칼라 영상의 디더링에 적용하였다.

실험의 결과 최적의 학습 횟수가 5만번 정도였으며, 학습률은 지수형으로 하여 학습 초기에는 코드북 벡터의 조정을 많이 해서 최대한 빠르게 근접한 위치에 배치시키며, 학습이 진행될 수록 이상적인 위치에 배치 되도록 하였다. 학습률을 0.1로 고정시켰을 때보다 지수형으로 학습률을 조정했을 때 학습 횟수를 감소시키는 결과를 보여 주었다..

본 논문에서 제안한 알고리즘을 통해서 디더링된 MSE 측정결과가 기존의 알고리즘을 통해서 디더링된 MSE 측정결과보다 다소 우수하다는 결론이 나왔다. 물론 기존의 알고리즘을 100% 최적화되게 구현하지 못한 결과라고 할 수 있기 때문에 실제 상용 어플리케이션의 디더링 결과물의 MSE 측정을 통하여 비교하였다. 제안한 알고리즘의 결과물이 상용 어플리케이션의 디더링 결과물보다 MSE 측정에서 60% 더 낮은 수치를 보였다.

참고문헌(또는 Reference)

- [1] 이상길, 밑언어에 의한 디지털 영상 처리? 성안당, 2000.
- [2] 최형일,이근수,이양원 역, RANDY CRANE 저, "영상처리 이론과 실제? 홍릉과학출판사, 1997.
- [3] 정희경, 김병일,우영운 역, DONALD HEARN, M.PAULINE BAKER 저, ?컴퓨터 그래픽, 도서출판 아진, 2000.
- [4] D. Choi and S. Park, "Self-Creating and Organizing Neural Networks", IEEE Trans. on Neural Networks, Vol. 5, No. 4., pp. 561-575, July 1994.
- [5] 김대수, 신경망 이론과 응용(I), NEURAL NETWORKS Theory and Applications, 하이테크정보, 1998.
- [6] Gonzalez, Rafael C. e Wintz, Paul. 1987. Digital Image Processing. Addison-Wesley, Reading, MA. 1987.