

Cluster의 중심벡터를 이용하는 영상 압축

The Image Compression Using the Central Vectors of Clusters

趙 濟 煌*

(Che Hwang Cho*)

요 약

Training 벡터 집합이 Cluster를 이루는 경우, 벡터 양자화에서 영상과 음성의 압축에 사용되는 코드북의 코드벡터는 Cluster의 중심벡터로 간주된다. 본 연구에서는 Training 벡터 간의 Euclidean 거리가 최소가 되는 벡터를 찾는 과정에서 얻어지는 Euclidean 거리분포를 관찰하여 적절한 Cluster수와 그 중심벡터를 결정할 수 있는 방법을 제시하고, 제안된 방법이 기존의 LBG 알고리즘이나 Competitive 학습 알고리즘에 의한 영상 압축보다 약 4[dB] 이상 향상된 SNR을 얻을 수 있음을 보인다.

ABSTRACT

In the case where the set of training vectors constitute clusters, the codevectors of the codebook which is used to compression for speech and images in the vector quantization are regarded as the central vectors of the clusters constituted by given training vectors. In this work, we consider the distribution of Euclidean distance obtaining in the process of searching for the minimum distance between vectors, and propose the method searching for the proper number of and the central vectors of clusters. And then, the proposed method shows more than the about 4 [dB] SNR than the LBG algorithm and the competitive learning algorithm

I. 서 론

음성이나 영상 압축의 한 방법으로 주목받고 있는 벡터 양자화(vector quantization)는 음성이나 영상 데이터를 수개의 성분을 갖는 벡터로 재구성하고, 적절히 설계된 코드북(codebook)에서 가장 근사한 코드벡터(codevector)를 찾아 그 벡터에 부여된 첨자(index)를 전송하므로 이루어진다[1].

벡터 양자화에 의한 압축 성능은 코드북 설계에 의

해 좌우되며, 코드북 설계 방법으로는 LBG(Linde, Bu-zo, and Gray) 알고리즘이 보편적으로 사용된다[2]. LBG 알고리즘은 국소 최적 코드북(locally optimal codebook)만을 보장하며, 학습(learning)에 사용할 Training 벡터 집합에는 일반적으로 다수의 국소 최적점이 존재하기 때문에 초기(initial) 코드벡터 결정이 설계된 코드북 성능에 중요한 영향을 미친다[3]. 이미 알려진 초기 코드벡터 결정 방법으로는 Random codes, Splitting, PNN(pairwise nearest neighbor) clustering[4] 등이 있다. Training 벡터 집합이 Cluster를 이루는 경우, 설계된 코드북을 구성하는 코드벡터는 각 Cluster의 중심벡터가 될 때 최

* 東新大學校 電子工學科
Dept. of Electronic Eng., Dongshin Univ.
접수일자: 1994년 8월 6일

적의 코드북이 된다.

최근에는 신경망(neural networks) 적용의 한 방법으로 Competitive 학습 알고리즘에 의한 벡터양자화 방법이 제안되고 있으며, Competitive 학습 알고리즘에서 발생할 수 있는 Underutilization 문제를 고려한 FSC(frequency sensitive competitive) 학습 알고리즘이 발표된 바 있다[5].

LBG 알고리즘과 Competitive 학습 알고리즘은 주어진 Training 벡터 집합의 Cluster 분포에 무관하게 임의로 결정된 수의 코드벡터를 찾는 방법으로써, LBG 알고리즘은 초기 코드벡터를, Competitive 학습 알고리즘은 초기 가중치(weights) 벡터를 적절히 선택한 경우에 두 알고리즘에 의해 얻어지는 코드벡터는 Cluster의 중심벡터가 된다. 두 알고리즘을 사용하여 보다 우수한 코드북을 설계하기 위해서는 학습 전에 Training 벡터 집합이 이루는 Cluster의 수를 아는 것과, 각 Cluster 근처의 초기 코드벡터 혹은 초기 가중치 벡터를 선택해야 하는데, 이것은 두 알고리즘의 적용 시 어려운 문제이다.

본 연구에서는 Training 벡터 집합이 Cluster를 이루는 경우, 임의의 한 Cluster에 속하는 벡터들간의 Euclidean 거리는 작고, 각 Cluster 중심벡터 간 거리는 크다는 점에 기초하여 Training 벡터 간의 Euclidean 거리를 구한다. Training 벡터 간의 Euclidean 거리가 최소가 되는 벡터를 찾게 되면, Cluster 내에서의 Euclidean 거리는 작게 나타나고, Cluster 외에서의 Euclidean 거리는 크게 나타나기 때문에 이러한 Euclidean 거리분포를 관찰하므로써 적절한 Cluster 수와 그 중심벡터를 결정할 수 있다.

II. 이 론

1. LBG 알고리즘

스칼라 양자화를 위한 Lloyd-Max 알고리즘[6]을 일반화한 LBG 알고리즘은 초기 코드북의 선택에 크게 영향을 받고, 국소 최적 코드북 만을 보장함에도 불구하고 벡터 양자화의 코드북 설계에 가장 널리 사용되는 방법이며, 그 과정은 다음과 같다[2].

(a). Training 벡터 집합, N개의 초기 코드벡터 $x_1(0), x_2(0), x_3(0), \dots, x_N(0)$ 로 구성된 초기 코드북 $X(0)$, 가능한 큰 값으로 초기화된 모든 Training 벡터 집합에 대한 평균 왜곡(average dis-

tortion) $D(0)$, 가능한 작은 값을 갖는 임계값 ϵ , 최대 반복 학습 회수 $L=M$ 이 주어졌을 때,

(b). 식(1)과 같은 Euclidean 거리를 사용하여 임의의 한 Training 벡터 y 를 모든 코드벡터와 비교하여 최소 거리가 되는 코드벡터를 찾아 두벡터의 중심벡터를 구한다. 모든 Training 벡터에 대하여 동일한 방법으로 1회 반복으로 새로운 코드북 $X(1)$ 을 얻는다. 이러한 과정은 최대 반복 회수에 의하여 $X(M)$ 이 구해지거나, 식(2)가 만족될 때 종결된다.

$$d(x_i(L), y) = \sqrt{\frac{1}{n} \sum_{k=1}^n (x_k - y_k)^2} \quad (1)$$

$$\frac{D(L) - D(L+1)}{D(L)} \leq \epsilon \quad (2)$$

$$D(L) = \frac{1}{N} \sum_{i=1}^N d(x_i(L), y) \quad (3)$$

식(1)에서 x_k 와 y_k 는 각각 L 번째 반복 학습 시 i 번째 코드벡터 $x_i(L)$ 와 임의의 한 Training 벡터 y 의 k 번째 성분이다.

2. Competitive 학습 알고리즘

n개 성분을 갖는 Training 벡터 집합으로 부터 N 개의 코드벡터를 구하기 위해 n개의 노드(nodes)를 갖는 입력층(input layer)과 N 개의 노드를 갖는 출력층(output layer), 그리고 두 층을 연결하는 가중치로 구성된 신경망을 사용하여 Competitive 학습 알고리즘을 적용할 수 있다. L 번째 반복 학습 시 출력층의 i 번째 노드에 연결된 가중치 벡터를 $W_i(L)$ 라 하면, i 번째 노드의 출력값 Z_i 는 다음과 같이 계산된다.

$$d(X, W_i(L)) \leq d(X, W_j(L)) \quad \text{일 경우, } Z_i = 1$$

$$d(X, W_i(L)) > d(X, W_j(L)) \quad \text{일 경우, } Z_i = 0$$

(4)

여기서, $i \neq j, i, j = 1, 2, \dots, N$ 이고, $d(X, W_i(L))$ 는 식(1)과 같이 입력 벡터 X 와 가중치 벡터 $W_i(L)$ 간의 Euclidean 거리이며, 새롭게 변화된 가중치 벡터는 다음과 같이 계산된다[5].

$$W_i(L+1) = W_i(L) + \eta(X - W_i(L))Z_i \quad (5)$$

여기서, η 는 학습률(learning rate)로써 학습이 진행함에 따라 일반적으로 0으로 단조 감소(monotonical decrease)하는데, 본 논문에서는 0.01 값으로 고정하였다.

식(4)와 (5)로부터 반복 학습이 진행되는 동안 입력되는 Training 벡터와 가장 근사한 가중치 벡터만 입력 벡터 방향으로 변화하고 나머지 가중치 벡터는 변화하지 않는 것을 알 수 있다. 학습이 종결된 후 출력층의 각 노드에 연결된 가중치 벡터는 구하고자 하는 코드북의 코드벡터가 된다.

3. 제안된 방법

영상을 구성하는 벡터들의 중복성(redundancy)은 벡터 양자화에 의한 압축의 근거가 되고, 벡터 양자화에서의 코드벡터는 압축하고자 하는 영상의 구성 벡터들 중 서로 유사한 벡터를 대표한다. 따라서 코드북을 구성하는 코드벡터의 수는 일반적으로 압축하고자 하는 음성이나 영상의 구성 벡터수보다 적다. 코드벡터를 얻기 위해 사용되는 Training 벡터 집합은 서로 유사한 벡터로 구성된 여러개의 Cluster를 갖고, LBG 알고리즘이나 Competitive 학습 알고리즘 등으로 얻게 되는 최적인 코드벡터는 이러한 Cluster의 중심벡터가 된다.

그러나 두 알고리즘의 적용 시 Training 벡터 집합의 Cluster 수에는 무관한 코드벡터 수를 가정하며, 초기 코드벡터나 초기 가중치 벡터는 Cluster 분포에 무관하게 선택되기 때문에 주어진 Training 벡터 집합에 대하여 최적의 코드벡터를 기대하기 어렵다.

임의의 한 Cluster를 구성하는 벡터들은 그렇지 않은 벡터와 비교하여 서로 더 가까운 거리에 위치하기 때문에 식(1)에 주어진 Euclidean 거리로써 임의의 한 벡터가 어느 Cluster에 소속될 지를 결정할 수 있다. 다음은 본 연구에서 제안한 방법으로써 주어진 Training 벡터 집합의 Cluster 수와 중심벡터를 구하는 절차이다.

- (a). $\ell = m = q = r = k = s = 0$ 인 정수, $E_max' \ll 1$ 인 실수, $d(0, x) > d(0, y_i)$ 인 초기 벡터 x 를 가정, 여기서, $i = 1, 2, \dots, P$ 이고, y_i 는 i 번째 Training 벡터이다.
- (b). P 개의 Training 벡터에 y 에 대하여 $d(x, y_i) < d(x, y_j)$ (단, $i \neq j$)인 경우,
 $dist = d(x, y_i)$, $m = m + 1$,

- (c). $d(x, y_i) \leq E_max'$ 인 경우, $c_k = x + y_i$, $x = y_i$,
 $dist = dist + d(x, y_i)$, $\ell = \ell + 1$
- (d). $\ell \geq 1$ 인 경우, $c_k = c_k / \ell$, $k = k + 1$
- (e). $m < P$ 인 경우 (b)~(d) 과정을 반복, $m = P$ 일 때 벡터 c_1, c_2, \dots, c_B 로 구성된 B 개의 벡터 C 를 결정
- (f). 선택된 벡터 C 에 대한 거리 $dist$ 값의 분포에 따라 E_max' 를 E_max 로 재조정
- (g). $d(0, z) > d(0, c_k)$ 인 초기 벡터 z 를 가정, 여기서, $k = 1, 2, \dots, B$ 이다.
- (h). B 개의 벡터 C 에 대하여 $d(z, c_i) < d(z, c_j)$ (단, $i \neq j$)인 경우, $q = q + 1$,
- (i). $d(z, c_i) \leq E_max$ 인 경우, $e_s = z + c_i$, $z = c_i$, $r = r + 1$
- (j). $r \geq 1$ 인 경우, $e_s = e_s / r$, $s = s + 1$
- (k). $q < B$ 인 경우 (h)~(j) 과정을 반복, $q = B$ 일 때 벡터 e_1, e_2, \dots, e_N 으로 구성된 N 개의 벡터 E 를 결정

단계 (a)에서 부등식 $d(0, x) > d(0, y_i)$ 는 두 벡터 x 와 y_i 의 원점으로부터 거리를 비교하는 부등식으로써, 하나의 초기 벡터 x 의 크기가 모든 Training 벡터 y_i 의 크기보다 큰 초기 벡터 x 를 결정한다. 따라서, 단계 (a)에서 결정되는 하나의 초기 벡터 x 는 Training 벡터 공간에서 원점으로부터 가장 멀리 떨어진 벡터가 된다. 단계 (b)에서 부등식을 만족하는 벡터 y_i 는 반복되는 다음 조사에서 제외되고, 주어진 모든 Training 벡터에서 벡터 간 최소 거리를 갖는 벡터를 찾게되므로 E_max' 값은 Cluster의 중심 부근에서의 거리를 의미한다. 제안된 과정은 Cluster 중심에서의 구성 벡터 간 거리는 짧은 반면, Cluster간 거리는 크게 나타나는 특성을 이용한다.

III. 실험 및 결과 고찰

본 실험에서는 참고문헌[7]에서 제안한 방법에 의해 실험에 필요한 벡터를 구한다. 즉, 주어진 영상을 2×2 블럭(block)으로 나누고, 각 블럭의 평균치와 편차(deviation)를 사용하여 새로운 벡터를 얻는다.

$$X_i = (Y_i - m_i) / \sigma_i \quad (6)$$

$$m_k = \frac{1}{4} \sum_{k=1}^4 Y_k \quad (7)$$

$$\sigma_i^2 = \frac{1}{4} \sum_{k=1}^4 (Y_k - m_i)^2 \quad (8)$$

여기서 σ_i 는 i 번째 블록의 표준 편차이고, m_i 는 i 번째 블록의 평균치이며, Y_i 는 i 번째 블록의 벡터로써 4개의 성분을 갖는다. X_i 는 식(6)에 의해 새로 얻어진 벡터이다. Y_i 의 4개 성분은 0부터 255까지의 그레이 레벨(gray level)을 갖지만, 새로운 벡터 X_i 는 0에서 절대값 약 1~2 범위의 값을 갖게 된다. 따라서 벡터 공간에 위치하는 벡터들의 분포는 동일한 수의 경우, Y_i 보다는 X_i 가 보다 분명한 Cluster 분포를 갖게 된다. 본 연구에서 고려한 2×2 블록 대신 4×4 블록을 적용하는 경우, Training 벡터의 성분수가 4에서 16으로 증가되므로 보다 분명한 Cluster 분포를 얻기 위해서는 2×2 블록을 사용할 때 보다 큰(혹은 많은) Training 영상을 사용하여야 한다.

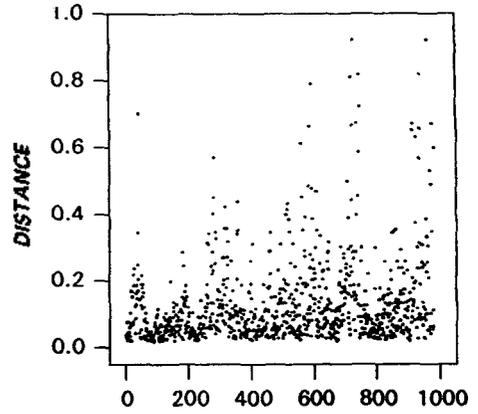
영상 1(a)는 Training 벡터 집합을 얻기 위해 사용한 512×512 화소(pixel) 256 그레이 레벨의 영상으로써 식(6)~식(8)에 의해 4개 성분으로 구성된 65536개의 Training 벡터를 얻을 수 있다. 각각 girl, LBT, Lena로 불러우는 영상 1(b), 1(c), 1(d)는 설계된 코드북의 성능을 실험하기 위해 사용한 128×128 화소 256 그레이 레벨 영상으로써 동일한 방법에 의해 4개 성분으로 구성된 4096개의 벡터로 각각 구성됨을 알 수 있다.

그림 1(a), 1(b), 1(c)는 E_{max}' 을 각각 0.01, 0.02, 0.03으로 정한 경우, 영상 1(a)에 적용한 식(6)~식(8)로부터 얻어지는 Training 벡터 간 Euclidean 거리 분포를 나타내고, 제안된 방법의 e 단계에서 벡터 C를 각각 981, 3578, 4041개 얻는다. 그림 2(a), 2(b), 2(c)는 각각 girl, LBT, Lena 영상에 대하여 Competitive 학습 알고리즘, LBG 알고리즘, 본 연구에서 제안한 방법 등에 의해 설계된 코드북의 성능을 비교하여 보여준다. 여기서 횡축과 종축의 RATIO와 SNR는 각각 다음과 같이 주어진다.

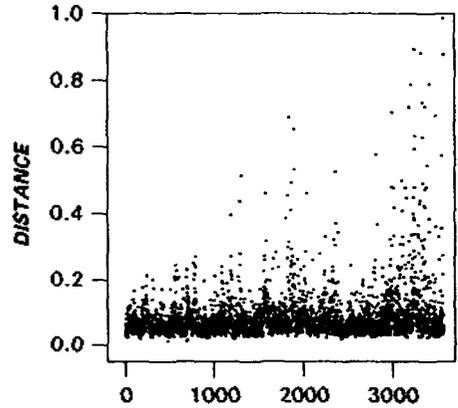
$$RATIO = \frac{\text{코드벡터의 수}}{\text{시험 영상의 벡터수(4096 개)}} \quad (9)$$

$$SNR = 20 \log_{10}(255/RMSE) \quad (10)$$

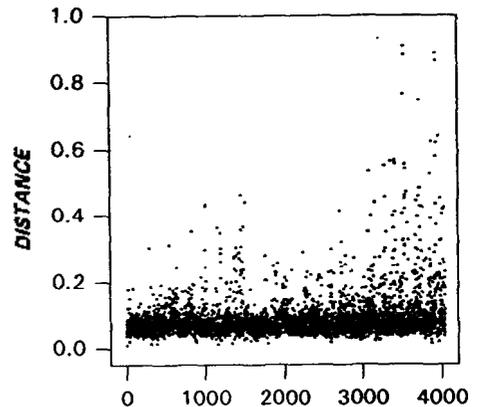
$$RMSE = \sqrt{\frac{1}{128^2} \sum_{j=1}^{128} \sum_{i=1}^{128} (f_{ij} - g_{ij})^2} \quad (11)$$



(a) $E_{max}' = 0.01$

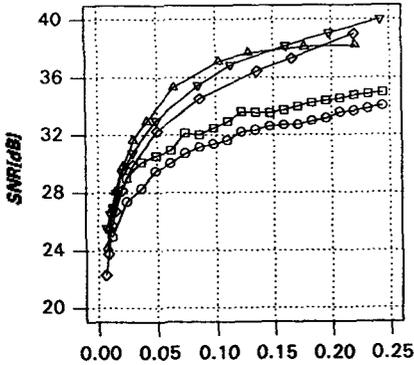


(b) $E_{max}' = 0.02$

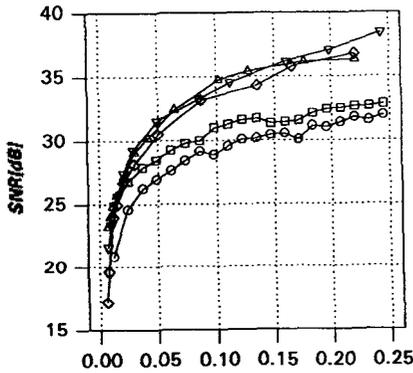


(c) $E_{max}' = 0.3$

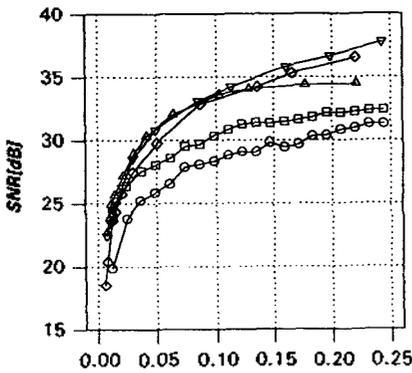
그림 1. Training 벡터에 대한 Euclidean 거리
Fig. 1. Euclidean distance vs. Training vector



(a) RATIO



(b) RATIO



(c) RATIO

그림 2. RATIO에 대한 SNR [dB] (a) girl, (b) LBT, (c) Lena

- : Competitive 학습 알고리즘,
- : LBG 알고리즘, -△- : E_max' = 0.01,
- ▽- : E_max' = 0.02, -◇- : E_max' = 0.03

Fig. 2. SNR [dB] vs. RATIO (a) girl, (b) LBT, (c) Lena

- : Competitive learning algorithm,
- : LBG algorithm, -△- : E_max' = 0.01,
- ▽- : E_max' = 0.02, -◇- : E_max' = 0.03

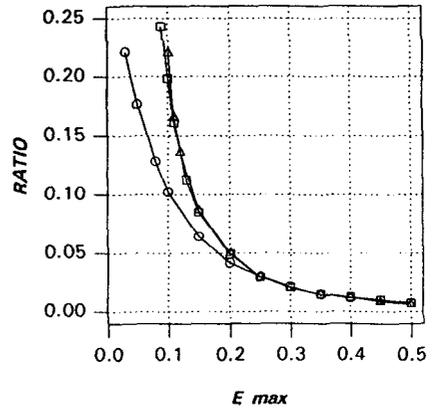


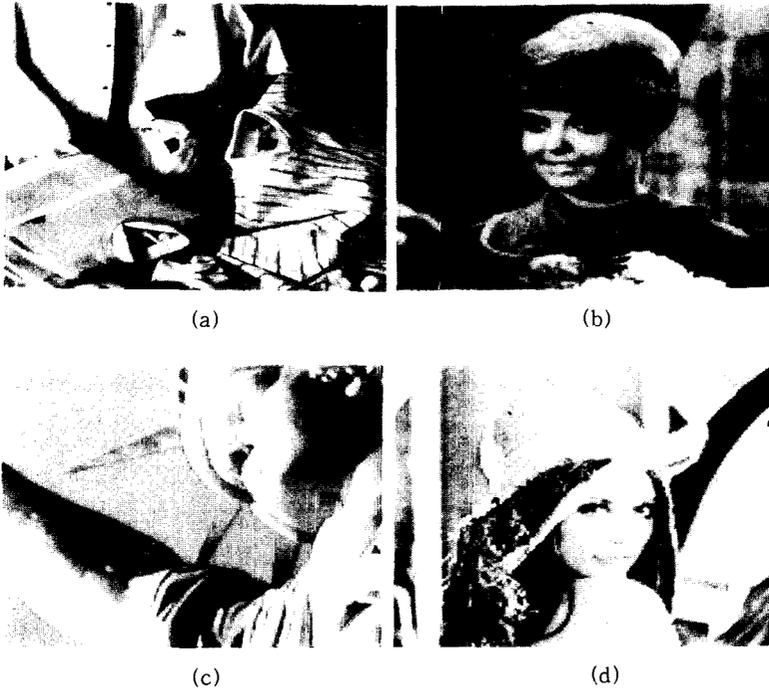
그림 3. E_max에 대한 RATIO

- : E_max' = 0.01, -□- : E_max' = 0.02,
- △- : E_max' = 0.03

Fig. 3. RATIO vs. E_max

- : E_max' = 0.01, -□- : E_max' = 0.02,
- △- : E_max' = 0.03

식(11)에서 f_{ij} 와 g_{ij} 는 각각 원영상과 설계된 코드북에 의해 압축 후 복원된 영상의 i 번째 행(row)과 j 번째 열(column)의 화소값이다. 식(9)에서 코드벡터의 수는 Competitive 학습 알고리즘과 LBG 알고리즘의 경우에는 50~1000까지 50 간격으로 가정하였고, 본 연구에서 제안한 방법의 경우는 그림 2(a)~2(c)에서 E_max 값을 0~0.5 까지 변화하면서 코드벡터를 얻었으며, 그 결과는 그림 3에 주어진다. E_max가 0.2 이하일 때 E_max' = 0.01 그래프는 E_max' = 0.02, 0.03 그래프와 차이를 보인다. 그림 2에서 알 수 있듯이 girl, LBT, Lena 영상 모두에 대하여 Competitive 학습 알고리즘과 LBG 알고리즘에 의해 설계된 코드북 성능보다 본 연구에서 제안한 방법에 의해 설계된 코드북 성능이 우수함을 보인다. RATIO가 증가할수록 E_max' = 0.02, 0.03인 경우 기존 두 방법보다 제안된 방법에 의한 복원력이 큰폭으로 향상됨을 보인다. RATIO가 약 0.15 이하에서 E_max' = 0.01인 경우가 E_max' = 0.02, 0.03인 경우보다 복원력이 우수함을 보이고, RATIO가 약 0.15 이상에서는 E_max' = 0.02, 0.03인 경우가 복원력이 우수함을 보인다. 영상 2는 Lena 원영상과 제안된 방법에 의해 RATIO가 약 0.24이고, E_max' = 0.01 일때의 복원된 영상의 확대된 영상을 보여준다.



영상 1. (a) Training 영상(512×512 화소 256 그레이 레벨)
 (b) girl 영상(128×128 화소 256 그레이 레벨)
 (c) LBT 영상(128×128 화소 256 그레이 레벨)
 (d) Lena 영상(128×128 화소 256 그레이 레벨)
 Image 1. (a) Training image(512×512 pixel 256 gray level)
 (b) girl image(128×128 pixel 256 gray level)
 (c) LBT image(128×128 pixel 256 gray level)
 (d) Lena image(128×128 pixel 256 gray level)



영상 2. Lena 영상의 확대된 영상
 (a) 원영상
 (b) $E_{max}'=0.01 : E_{max}=0.01$, RATIO=0.24, SNR[dB]=34.50
 image 2. The zoomed image for Lena image
 (a) The original image
 (b) $E_{max}'=0.01 : E_{max}=0.01$, RATIO=0.24, SNR[dB]=34.50

IV. 결 론

벡터 양자화에 있어서 적절히 설계된 코드북의 코드벡터는 코드북 발생을 위해 사용되는 Training 벡터 집합이 이루는 각 Cluster의 중심벡터가 된다. Cluster는 서로 유사한 특성의 벡터 모임으로서 Euclidean 거리를 사용하여 임의의 Training 벡터의 Cluster 소속 여부를 결정할 수 있다. 코드북 발생을 위해 일반적으로 사용되는 LBG 알고리즘이나, 신경망에서의 Competitive 학습 알고리즘은 Training 벡터 집합이 이루는 Cluster 분포에 무관하게 임의로 결정된 수의 코드벡터를 찾는 방법이다. 두 알고리즘 적용으로 얻어지는 코드북의 성능은 충분한 Training 벡터수와 학습 시간이 주어진다면 초기 코드북의 선택에 의해 좌우된다. Training 벡터 집합이 Cluster 분포를 이루는 경우, 두 알고리즘 적용으로 보다 우수한 코드북 발생을 위해서는 가정된 초기 코드벡터의 수가 Cluster의 수와 일치해야 하고, 초기 코드벡터가 될 수 있는 한 각 Cluster 주위에 위치해야 한다. 이러한 두가지 점은 두 알고리즘에서 실현하기 어렵다.

임의의 한 Cluster에 속하는 벡터들 간의 Euclidean 거리는 그렇지 않은 벡터와의 거리에 비하여 작기 때문에 이러한 거리를 관찰함으로써 Cluster의 수와 Cluster의 중심벡터를 구할 수 있다. 제안된 방법은 주어진 E_{max} ' 보다 작은 거리를 갖는 벡터를 찾고, 선택된 벡터의 거리를 구하여 Cluster 수를 구하는 방법으로서 크게 두 단계로 나눌 수 있다. 첫째, E_{max} '은 주어진 모든 Training 벡터 간 최소 거리에 근사한 값으로서 Cluster의 중심 부근에서의 거리를 의미하고, E_{max} ' 보다 작은 거리를 갖는 벡터들의 중심벡터와 거리를 구한다. 둘째, 첫 단계에서 선택된 벡터와 그 벡터의 거리분포에 따라 E_{max} '를 재조정하여 (E_{max}) 첫 단계와 동일한 과정을 거쳐 각 Cluster의 중심벡터를 구한다.

실험 결과 RATIO가 약 0.05 이상에서 기존의 두 알고리즘보다 제안된 방법에 의해 설계된 코드북 성능이 우수함을 보이고, $E_{max}'=0.02, 0.03$ 에서는 RATIO가 증가할수록 기존의 두 알고리즘보다 복원력이 크게 향상되는 코드북을 얻을 수 있음을 보인다. 본 연구에서는 1개의 512×512 화소 영상을 사용하여 2×2 블럭을 적용하고 각 블럭의 평균치와 편차를 이용해 새로운 벡터를 구함으로써 보다 분명한 Cluster 분포를 얻고, 코드북을 얻기 위한 학습 시간을 단축

하였다. Training 벡터 집합이 보다 분명한 Cluster를 이루기 위해 벡터수는 많아야하고, 벡터의 성분수와 각 성분의 범위는 적어야 한다. Cluster 분포를 보다 분명히하기 위해 벡터수를 증가시킬 때 코드북 설계를 위한 학습 시간이 증가되며, 벡터의 성분수를 줄이는 경우 압축을 행할 입력 영상의 블럭수가 증가하여 압축에 의한 영상 전송이나 복원 시간이 증가된다. 큰 영상에 대한 압축시간을 단축하기 위해 블럭을 크게 잡을 경우, 분명한 Cluster 분포를 얻기 위해서는 보다 많은(혹은 큰) Training 영상을 사용해야 하고, 따라서 코드북을 얻기 위한 학습시간을 증가한다. 그러므로 압축할 영상의 크기에 따라 압축에 의한 영상 전송이나 복원시간, 그리고 코드북을 얻기 위한 학습시간 등을 고려한 적절한 Training 영상의 개수(혹은 크기)와 블럭의 크기 선택이 요구된다.

참 고 문 헌

1. R.M. Gray, "Vector quantization," *IEEE ASSP Magazine*, vol.1, pp.4-29, 1984.
2. Y.Linde, A.Buzo, and R.M. Gray, "An algorithm for vector quantizer design," *IEEE Trans. Commun.* vol. COM-28, pp.84-95, 1980.
3. M. Rabbani and P.W. Jones, *Digital Image Compression Techniques*, SPIE Press, 1991.
4. W.H. Equitz, "A new vector quantization clustering algorithm," *IEEE Trans. Acous., Speech, Signal Proc.*, vol.37, pp.1568-1575, 1989.
5. S.C. Ahalt, A.K. Krishnamurthy, P.Chen, and D.E. Melton, "Competitive learning algorithms for vector quantization," *Neural Networks*, vol.3, pp.277-289, 1990.
6. S.P. Lloyd, "Least squares quantization in PCM," *IEEE Trans. Info. Theory*, vol.IT-28, pp.129-137, 1982.
7. T.Murakami, K.Asai, and E.Yamazaki, "Vector quantiser of video signals," *Electronics Letters*, vol.7, pp. 1005-1006, 1982.

▲趙 濟 燾(Che Hwang Cho)



1984년 2월 : 광운대학교 전자공
학과(학사)

1986년 2월 : 광운대학교 대학원
전자공학과(석사)

1990년 2월 : 광운대학교 대학원
전자공학과(박사)

1989년 3월 ~현재 : 동신대학교 전
기전자공학과 조교수

※주관심분야 : 신호처리, 영상처리, 뉴로-퍼지, 패턴
인식