

論文95-32B-5-9

최소 거리 분류 벡터 양자기와 시스토크 어레이 구조

(Minimum-Distance Classified Vector
Quantizer and Its Systolic Array
Architecture)

金 東 植 *

(Dong Sik Kim)

요 약

본 논문에서는 일반적으로 전 탐색(full-search) 벡터 양자화에서 요구되는 계산량을 줄이기 위한 목적으로 최소 거리 분류기(minimum-distance classifier)를 이용한 일종의 분류 벡터 양자화(classified vector quantization: CVQ)를 제안하였다. CVQ 설계에 있어서 각 부류의 부 부호책(subcodebook)의 크기를 결정하는 것은 최적 CVQ 설계를 위해서 매우 중요하면서 또한 힘든 작업이다. 따라서 제안된 CVQ에서는 각 부 부호책의 크기는 모두 같은 값으로 놓고 분류기가 최적 CVQ 조건을 근사적으로 만족하도록 하였다. 제안된 CVQ는 부분 탐색(partial-search)에 근거한 양자화이므로 전 탐색에 비하여 계산량이 줄어드는데 부 부호책들의 크기가 모두 같으므로 최소의 계산량이 요구되며, 분류기의 동작은 VQ와 동일하므로 전체 계산량을 $O(N^{1/2})$ 로 줄일 수가 있어서 효율적인 VLSI 구현이 가능하다. 그 성능에 있어서도 실 영상(image)들에 대한 모의 실험을 통해서 전 탐색 VQ와 거의 비슷함을 보였다. 아울러 제안된 CVQ의 VLSI 구현을 위한, through-put 이 벡터의 차수와 같은 systolic array를 제안하여 제안된 CVQ의 유용성을 보였다.

Abstract

In this paper in order to reduce the encoding complexity required in the full search vector quantization(VQ), a new classified vector quantization(CVQ) technique is described employing the minimum-distance classifier. The determination of the optimal subcodebook sizes for each class is an important task in CVQ designs and is not an easy work. Therefore letting the subcodebook sizes be equal, a CVQ technique, which satisfies the optimal CVQ condition approximately, is proposed. The proposed CVQ is a kind of the partial search VQ because it requires a search process within each subcodebook only, and the minimum encoding complexity since the subcodebook sizes are the same in each class. But, simulation results reveal that the performance of the proposed CVQ is almost comparable to that of the full search VQ, while the encoding complexity is only $O(N^{1/2})$ comparing with $O(N)$ of the full-search VQ. A simple systolic array, which has the through-put of k, is also proposed for the implementation of the VQ. Since the operation of the classifier is identical with that of the VQ, the proposed array is applied to both the classifier and the VQ in the proposed CVQ, which shows the usefulness of the proposed CVQ.

*正會員, 서울大學校 制御計測工學科
(Dept. of Control and Instrumentation Seoul

National Univ.)
接受日字: 1994年12月5日, 수정완료일: 1995年4月27日

I. 서론

벡터 양자화(vector quantization: VQ)는 입력되는 벡터 열을 index들의 열로 사상(mapping)하는 것으로 최근에 영상 및 음성 데이터 부호화에 사용되기 위해 많은 연구가 수행되고 있다. 그러나 VQ를 실시간 시스템에 적용하는 데 있어서 가장 큰 문제점은 부호화(encoding)시에 계산 복잡도(complexity)가 높다는 것인데, 이는 벡터의 차수 또는 부호책(codebook)의 크기가 증가하면서 기하 급수적으로 증가하게 된다. 따라서 이러한 계산 복잡도로 인하여 VQ의 실현 가능한 벡터의 차수는 약 16에서 20 정도로 제한된다. 이러한 복잡도를 줄이기 위해 여러 알고리즘들이 제안되었다. 그중에서 나무 구조(tree-structured) VQ, 다단(multi-stage) VQ, 이득 형태 분리(gain-shape) VQ 등이 잘 알려진 알고리즘들이다^{1, 6, 13}. 또한 최근에는 분류 벡터 양자화(classified VQ: CVQ) 기법이 제안되어, 부호화 복잡도를 낮추면서 VQ에서 일반적으로 MSE(mean square error) 측정치를 사용함으로 야기되는 가장자리(edge) 성분의 왜곡을 줄였다^{15, 17}.

영상 신호를 양자화하는 CVQ의 동작을 설명하면 다음과 같다. 먼저 하나의 영상 데이터는 연속되는 여러 부블럭(subblock)들로 나뉘어지고 하나의 벡터는 한 부블럭의 화소들을 그 원소로 하여 구성된다. 그 다음 이러한 벡터들은 분류기(classifier)에 의해서 미리 정해진 부류로 분류가 된다. 이렇게 분류된 벡터들은 각 부류에서 부 부호책(subcodebook)에 의해 부호화가 된다. 이렇게 각 부류에서 서로 독립적으로 부호화를 행하는 것을 부분 탐색(partial-search) 기법이라 하여 부호화 복잡도를 상당히 줄일 수 있다. 또한 분류기의 설계에 따라서 CVQ의 성능이 좌우됨을 알 수 있다. 부호화된 영상에서 가장자리 성분의 충실한 복원(reconstruction)을 위해서는 가장자리 성분의 위치와 성분에 근거한 분류기 설계가 필요하다^{15, 17, 19}.

본 논문에서는 최소 거리 분류기(minimum-distance classifier)^{11, 2, 31}를 이용한 새로운 CVQ를 제안하였다. 제안된 CVQ의 주된 목적은 부호화 복잡도를 줄이는 데 있다. P_i 를 입력 벡터가 i 번째 부류에 속할 확률이라 하고 P_i 를 i 번째 부류의 평균 양자화 왜곡치(average quantization distortion), N_i 를 i 번째 부 부호책의 크기라 할 때 최적 CVQ는 $P_i \rho_i / N_i$ 가 모든 부류에 대해 서로 같아야 한다. 그러나 이러한 조건을 만족시키는 부 부호책 크기 집합인 $\{N_i\}$ 의 계산은 매우 어려우며, 더욱이 입력 신호의 분포를 모르는

경우에는 더욱 그러하다. 그러므로 CVQ 설계에서 가장 어려운 부분은 부 부호책의 크기를 결정하는 것임을 알 수 있다. 본 논문에서 제안하는 CVQ는 단지 부호화 복잡도를 낮추기 위하여 분류화 기법을 적용하는 것으로 어떠한 특징(feature)에 의해서 분류기를 설계하고 그에 따라 최적의 부 부호책 크기 집합 $\{N_i\}$ 를 구하는 방법 대신에, 제안된 CVQ 설계의 기본 개념은 각 부 부호책의 크기를 모두 같은 값으로 고정시키고 분류기가 최적의 CVQ 조건을 만족시키도록 설계하는 것이다. 본 논문에서는 이러한 기본 개념의 구현을 위해서 분류화(classification) 분야에서 흔히 사용되는 최소 거리 분류기^{11, 2, 3, 18}를 CVQ의 분류기로 사용하여 언급된 최적 CVQ 조건을 근사적으로 만족하도록 하였다. 이 분류기의 기본적인 동작은 VQ와 동일하므로 제안된 CVQ의 VLSI 구현을 보다 용이하게 한다. 최소 거리 분류기의 설계는 군집화 알고리즘(clustering algorithm)을 사용해서 설계하는데, 이러한 알고리즘이 각 군집의 대표 벡터를 찾는 데에도 국부 최소치 등으로 빠져 버리는 문제가 존재하므로 이를 위해 군집화 알고리즘을 보완하는 기법이 도입되었다¹⁸. 서론 이후의 본 논문의 구성은 다음과 같다. 먼저 제 II장에서는 일반적인 CVQ가 최적화되기 위한 조건에 대해 정리하였으며, 제 III장에서는 제안된 CVQ 기법에서 최소 거리 분류기를 적용하여 어떻게 CVQ의 최적 조건을 근사적으로 만족시키는가를 묘사하였으며 제안된 CVQ의 부호화 복잡도를 분석하였다. 제 IV장에서는 이 CVQ의 VLSI 구현을 위한 systolic array 구조를 제안하였다. 그리고 제안된 CVQ의 성능을 실 영상에 대해 모의 실험하여 그 성능에 대한 비교를 제 V장에 정리하였다. 마지막 장에서 본 논문의 결론을 내렸다.

II. 부분 탐색에 근거한 분류 벡터 양자기

VQ에서 벡터 간의 거리 측정으로 MSE 거리를 사용한다고 하면 거리 측정 함수는 $d(x, y) = k^{-1} \sum_{j=1}^k (x_j - y_j)^2$ 로 표기된다. 여기서 x_j 와 y_j 는 각각 k 차원의 벡터 x 와 y 의 원소이며 $x, y \in R^k$ 이다. $S = \{S_1, \dots, S_m\}$ 을 양자화하려는 random 벡터 X 가 분포되어 있는 R^k 공간을 m 개로 나누는 중첩되지 않은(non-overlapped) 구획(partition)이라 하자. 그러면 분류기는 어떤 벡터 x 가 입력될 때 다음과 같은 index로의 사상인 함수로 정의된다.

$$\eta(x) \stackrel{\Delta}{=} \sum_{i=1}^m i I_{S_i}(x) \quad (1)$$

이 식에서 $I_S(x)$ 는 $x \in S_i$ 일 때 1이 되며 그렇지 않으면 0이다. 그리고 i 번째 영역 S_i 의 부호책 C_i 로 구해지는 조건부 VQ 평균 왜곡치(conditional VQ average distortion)를 $\rho_i(C_i) = E\{d(X, Q_{C_i}(X)) | X \in S_i\}$ 로 표기하자. 여기서 $Q_C(\cdot)$ 는 벡터 양자기(vector quantizer)로 $Q_C(x) = \min_{y \in C} d(x, y)$ 로 정의된다. 그러면 CVQ의 총 평균 왜곡치는 다음과 같다.

$$D = \sum_{i=1}^m P_i \rho_i(C_i) \quad (2)$$

이 식에서 m 은 CVQ에서의 부류의 갯수가 되며 $P_i = \Pr\{X \in S_i\}$ 이다. N 개의 부호 단어를 가지는 부호책들의 family를 C_N 이라 할 때 $C_{S_i} \in C_N$ 를 S_i 에 최적의 부호책이라 하자. 여기서 $\sum_{i=1}^m N_i = N$ 이다. 그러면 각 부류에 충분히 할당되는 N_i 에 대해 각 부류의 조건부 평균 왜곡치는 다음과 같이 점근적으로(asymptotically) 나타낼 수 있다^[6.8.11.12].

$$\rho_i(C_{S_i}) \cong B_i(\beta) N_i^{-\beta} (\det P_i)^{1/k}, \quad i=1, \dots, m \quad (3)$$

이 식에서 $\beta = 2/k$ 이며 $B_i(\cdot)$ 는 벡터 차수 k 와 random 벡터 X 의 pdf(probability density function)가 i 번째 부류 S_i 에 해당되는 조건부 pdf의 형태(shape)에 관계되는 함수이다. 여기서 pdf의 형태라 함은 covariance 행렬로 P 를 갖는 random 벡터를 선형 변환에 의해 covariance 행렬이 단위 행렬 I 가 되도록 하였을 때, 이때 선형 변환된 random 벡터의 pdf를 의미한다. 그리고 P_i 는 i 번째 부류에 속하는 입력 벡터의 조건부 covariance 행렬이다^[17]. [15]에서는 식(2)의 총 평균 CVQ 왜곡치를 최소화시키는 최적 부 부호책(subcodebook) 크기 집합 $\{N_i^*\}$ 를 나타내는 식을 유도하였는데 점근식 (3)을 사용해서 다시 유도하면 다음과 같다.

$$N_i^* = \frac{N_i P_i B_i(\beta) (\det P_i)^{1/k}}{\sum_{j=1}^m [P_j B_j(\beta) (\det P_j)^{1/k}]^{1/(\beta+1)}}, \quad j=1, \dots, m \quad (4)$$

식 (4)로부터 집합 $\{N_i^*\}$ 를 구하기 위해서는 식에서 보는 바와 같이 $B_i(\cdot)$ 를 구해야 한다. 그러나 불행히도 임의의 벡터 차수에 대해서 구체적으로 제시된 유도식^[11,12]이 아직 없고, 이의 하한 경계치^[18]를 사용하여 근사화한다고 해도 입력의 분포를 알지 못한다고 하면 결국 $B_i(\cdot)$ 는 구할 수가 없다. 그래서 [15]에서는 이 집합을 다음과 같은 최적 CVQ 조건이 만족되도록

실험적으로 구했다.

$$\frac{P_i \rho_i(C_{S_i})}{N_i} = \text{constant}, \quad i=1, \dots, m \quad (5)$$

이산 여현 변환(discrete cosine transform) 영역에서 VQ를 수행하는 경우 이때의 변환된 입력 벡터를 일반적으로 i.i.d.(independent and identically distributed) Laplacian 분포로 가정한다^[19]. 그러면 $B_i(\cdot)$ 의 하한 경계치를 이론적으로 구할 수가 있으며 이 경계치를 $B_i(\cdot)$ 의 근사치라 가정하여 식 (4)로부터 최적 집합 $\{N_i^*\}$ 를 구할 수 있다. 그러나 입력의 분포를 모른다고 하면 식 (4)로부터 부 부호책의 최적 크기 집합을 구하는 것은 매우 힘들어진다. 그래서 본 논문에서는 이렇게 구하기 힘든 최적 집합을 구하는 대신, 부 부호책의 크기는 모두 같은 값으로 고정시키고 식 (5)의 CVQ 최적 조건을 근사적으로 만족시키도록 분류기(classifier)를 설계하여 근사적으로 최적인 CVQ 설계를 시도하였다.

III. 최소 거리 분류기를 이용한 CVQ

최소 거리 분류기는 pattern 인식(recognition) 및 분류화(classification) 영역에서 흔히 사용되는 기법으로^[1,2,3], 그 기본적인 동작은 VQ 과정과 동일하다. 그러므로 제 IV장에서 소개될 systolic 구조에서도 분류기의 구조는 VQ를 위한 구조와 동일하다. 각 부류의 대표 벡터를 ω_i 라 하고 이로 인해 만들어지는 Voronoi 구획을 $V = \{V_1, \dots, V_m\}$ 이라 하면 최소 거리 분류기의 동작은 다음과 같은 함수로 정의된다.

$$\eta_{md}(x) = \sum_{i=1}^m i I_{V_i}(x) \quad (6)$$

이때 입력 벡터의 분포는 연속하다고 가정한다. 식 (6)과 같은 것을 1-NN(nearest neighbor)에 근거한 분류화 법칙이라 흔히 말한다^[2]. 이러한 분류기를 CVQ에 적용하게 되면 앞 장에서 family S 를 Voronoi 구획 V 로 대체하여 CVQ에 대한 식을 전개하면 된다.

최소 거리 분류기, 즉 $\{\omega_i\}$ 를 설계하기 위한 군집화 알고리즘은 다음과 같은 군집화 criterion^[2,7]을 최소화시키는 대표 벡터 $\{\omega_i\}$ 를 찾아 주어야 한다.

$$J = \sum_{i=1}^m P_i \sigma_A^2(i) \quad (7)$$

이 식에서 $\sigma_A^2(i)$ 는 i 번째 부류의 조건부 왜곡치

(distortion)로 이 부류의 평균이 ω_i 가 되므로 $\sigma_A^2(i) \triangleq E\{d(X, \omega_i) | X \in V_i\}$ 로 정의된다. 즉 이 값은 정의로부터 행렬 P_i 의 대각선에 있는 k 개 분산들의 산술 평균(arithmetic mean)으로 다음과 같이 쓸 수 있다¹⁵⁾.

$$\sigma_A^2(i) = \frac{1}{k} \text{trace}(P_i) = \frac{1}{k} \sum_{j=1}^k \lambda_{j,i} \quad (8)$$

이 식에서 $\lambda_{j,i}$ 는 행렬 P_i 의 singular 값들이다.

식 (7)을 최소화시키는 대표 벡터 집합인 $\{\omega_i\}$ 는 Gersho의 추측에 의하면 다음과 같은 조건을 만족해야 한다.

$$J_i \triangleq P_i \sigma_A^2(i) = \text{constant}, \quad i=1, \dots, m \quad (9)$$

즉 모든 대표 벡터 ω_i 로 구해지는 왜곡치가 모두 같아야 한다 (equal contribution property)¹⁸⁾. 이러한 최적 조건은 제안하는 CVQ가 최적 조건인 식 (5)를 만족시키기 위한 전제 조건이 된다.

그러면 식 (9)의 전제 조건으로부터 어떻게 해서 식 (5)의 CVQ의 최적화 조건이 제안된 CVQ에서 근사적으로 만족되는가를 설명하겠다. 제안된 CVQ의 기본 개념은 각 부 부호책의 크기를 상수로 하는 것이므로 식 (5)에 $N_i^* = \text{constant}, i=1, \dots, m$ 을 대입하면 다음과 같은 관계식이 얻어진다.

$$P_i \rho_i(C_{V_i}) = \text{constant}, \quad i=1, \dots, m \quad (10)$$

만일 각 부류에 할당된 부 부호책의 크기 N_i^* 가 크다고 하면 식 (3)의 점근식을 식 (10) 대입하여 다음과 같은 근사적 조건식을 얻을 수 있다.

$$P_i B_i(\beta) N_i^{*k} (\det P_i)^{1/k} = \text{constant}, \quad i=1, \dots, m \quad (11)$$

그런데 식 (11)의 조건을 만족하기 위한 충분 조건으로 다음과 같은 두가지 사항이 성립되어야 한다.

- (i) $B_i(\beta) = \text{constant}, i=1, \dots, m,$
- (ii) $P_i (\det P_i)^{1/k} = \text{constant}, i=1, \dots, m$

즉 (i)항은 모든 부류의 조건부 pdf가 같은 형태를 가져야 한다는 것을 의미한다. 또한 (ii)항은 식 (9)에 제시된 최소 거리 분류기의 조건을 사용한다고 하면

$$(\det P_i)^{1/k} = K \cdot \sigma_A^2(i), \quad i=1, \dots, m \quad (12)$$

이라는 관계식이 성립되면 된다. 이 식에서 K 는 비례 상수이다. 그런데 양자화하려는 random 벡터 X 의

pdf가 $E\{X\}^2 < \infty$ 라고 가정하면 m 개의 부류에 해당하는 Voronoi 영역인 V_i 들은 bound되어 있고 convex한 양자화 영역(quantizer region)들로 생각할 수 있으며, 최적으로 설계된 m 개의 양자화 영역은 m 값이 커짐에 따라 서로 같은 형태를 가지는 다각형이 된다고 추론할 수 있다¹⁸⁾. 즉 2차원에서는 정육각형(hexagon)이며 3차원에서는 truncated octahedron이 되며 차수가 증가하게 되면 hyper sphere로 접근하게 된다¹⁸⁾. 그리고 X 의 pdf가 smooth하다고 가정하면 각 양자화 영역은 uniform 분포를 가진다고 생각할 수 있다. 그러므로 (i)항이 근사적으로 만족된다.




그림 1. 산술 평균과 기하 평균의 비: δ_i
Fig. 1. The ratio of arithmetic and geometric mean: δ_i .

(ii)항에 대해 논하면 다음과 같다. $\sigma_A^2(i)$ 를 covariance 행렬 P_i 의 k 개 singular 값들의 기하 평균(geometric mean)이라 하자^{11),17)}. 그리고 산술 평균과 기하 평균의 비율 $\delta_i = \sigma_A^2(i) / \sigma_G^2(i)$ 라 쓰면, 식 (3)의 $(\det P_i)^{1/k}$ 는 $\sigma_G^2(i)$ 로 쓸 수 있으며, 식 (12)의 조건을 다음과 같이 다시 쓸 수 있다.

$$\delta_i = K^{-1}, \quad i=1, \dots, m \quad (13)$$

벡터의 차수가 $k=1$ 인 경우, 즉 scalar 양자기의 경우에는 $\delta_{i=1}, i=1, \dots, m$ 이 성립된다. $k=2$ 인 경우에는 최적 다각형은 정육각형인데 이 다각형의 방향에 따라 $\delta_i=1, i=1, \dots, m,$ 즉 벡터를 이루는 random 변수가 uncorrelated되어 있다. 그리고 다각형의 방향이 회전되어져 있는 경우에도 $\delta_i \approx 1, i=1, \dots, m$ 으로 근사적이 성립된다. $k \rightarrow \infty$ 함에 따라 최적 다각형은 hyper sphere로 접근한다고 추론되며¹⁸⁾ 그러므로 모든 벡

터 차수에 대해 다음과 같은 근사식을 얻을 수 있다.

$$\delta_i \approx 1, i = 1, \dots, m \quad (14)$$

이는 충분히 큰 부류의 갯수 m 에 대해 하나의 벡터를 구성하는 k 개 원소들의 분산들이 서로 같다는 것을 의미한다. 이러한 관계식의 실험적 확인을 위하여 다섯 장의 512×512 실 영상 데이터로 $\sigma_{\lambda}^2(i)$ 와 $\sigma_{\lambda}^2(i)$ 를 구하여 그림 1에 도시하였다. 그런데 $\sigma_{\lambda}^2(i)$ 는 사실상 구하기가 난해하므로 제 II장 뒷부분에서 언급한 바와 같이 영상 신호의 DCT 영역의 값은 uncorrelated 신호라는 가정하에서 변환된 데이터를 사용하여 근사적으로 구했다. 이 모의 실험에서 $m=16$ 이고 $k=16$ 이다. 그림에서 보는 바와 같이 모든 부류에서 1에 가까운 상수치를 보임을 알 수 있다. 즉 식 (14)에서 언급한 이야기가 실험적으로 확인되었다. 이렇게 δ_i 가 상수가 되면 (ii)항이 근사적으로 성립된다. 따라서 최소 거리 분류기를 사용하고 각 부류에 부 부호책의 크기를 $N_i = N_c$ 로 할당하므로 식 (5)의 최적 조건을 근사적으로 만족할 수 있다. 여기서 N_c 는 상수로 $N_c = N/m$ 이다. 그런데 언급된 바와 같이 이러한 최적 CVQ의 설계에서 기본이 되고 있는 조건은 식 (9)의 조건이 각 군집, 즉 각 부류에서 성립되어야 한다.

제안된 CVQ 기법을 정리하면 다음과 같다. 처음에 최소 거리 분류기의 설계를 위해 군집화 알고리즘으로 m 개 군집(부류)들의 대표 벡터 (ω_i)를 찾아야 한다. 이때 각 대표 벡터에 의해 계산되는 벡터 분산은 식 (2)의 조건을 만족해야 한다. 다음에 양자화하려는 random 벡터 X 의 구현된 값의 열이 분류기에 입력되어 최소 거리(minimum-distance)를 가지는 부류로 각각 분류된다. 각 부류에 속한 표본 벡터(sample vector)들을 훈련 벡터(training vector)로 하여 각 부류에서 독립적으로 부호책을 훈련시킨다. 이때도 군집화 알고리즘을 사용하여 부 부호책을 설계하는데, 각 부 부호책의 크기는 $N_c = N/m$ 이다. 부호화(encoding) 과정은 일단 입력된 하나의 벡터가 분류기에 의해 분류되어서 각 부류에서 독립으로 양자화된다. 즉 부호화 과정은 부분 탐색에 의해서 양자화가 수행되므로 부호화 복잡도가 전 탐색(full search) VQ에 비해서 상당히 낮아진다. 이러한 부분 탐색 VQ의 성능은 항상 전 탐색 VQ에 비해서 떨어짐에도 불구하고 본 논문에서 제안된 CVQ는 거의 비슷한 성능을 나타내었다.

언급된 바와 같이 분류기는 식 (9)의 조건을 만족해야 하는데 일반적으로 GLA나 Kohonen의 신경회로망^[6,8] 등의 군집화 알고리즘은 국부 최소치(local minimum)에 빠지기가 쉬워서 식 (9)의 조건이 잘

만족되지 못한다. 그러므로 본 논문에서는^[18]에서 제안된 간단한 군집 보정 알고리즘을 일반적인 군집 알고리즘에 부가하여 사용하였다.

여기서 제안된 CVQ의 부호화 복잡도에 대해 언급하면 다음과 같다. 먼저 부호화 복잡도를 나타내는 척도로 입력 벡터 하나당 요구되는 비교의 양(comparisons per a vector:CPV)을 사용한다고 하면 일반 전 탐색 VQ의 복잡도 N_{FVQ} 는 $N_{FVQ} = N$ 이 된다. 반면에 CVQ는 $N_{CVQ} = \sum_{i=1}^m P_i N_i$ 가 되는데 당연히 $N_{FVQ} \geq N_{CVQ}$ 이다. 그런데 부록에서 보인 것처럼 N_{CVQ} 를 최소화시키는 조건은 P_i 또는 N_i 가 모든 부류에 대해 상수가 되어야 한다. 그런데 제안된 CVQ가 이러한 경우를 만족하므로, 즉 $N_i = N/m$ 으로 모든 부류에서 같으므로 최소 복잡도인 $N_{CVQ} = N/m$ 를 가진다. 그러므로 총 부호화 복잡도는 분류화 과정에서의 비교 횟수를 포함하여 CPV로 $m + N/m$ 이 되고 $m^2 = N$ 일 때 이 값도 최소화된다. 정리하면 일반 전 탐색 VQ의 복잡도가 $O(N)$ 인데 반해서 제안된 CVQ는 $O(N^{1/2})$ 가 된다.

IV. 제안된 CVQ의 systolic array 구조

벡터의 차수가 k 라고 하면, VQ는 입력으로부터 k step 동안에 k 개의 데이터를 받아서 하나의 벡터를 구성한 후 양자화하여 하나의 index를 내보내게 되는데, 이러한 관점에서 실시간 구현을 위한 VQ의 VLSI 구조는 through-put이 최소한 k 가 되어야 하며, 방대한 양의 데이터와 계산량, PE(processing element) 간의 통신 때문에 데이터의 흐름은 wave-front 형태의, PE 간의 연결은 국부 연결(local connection), 그 구조는 regularity, modularity 등을 가지는 systolic array 형태가 요구된다^[10].

VQ의 동작은 하나의 벡터가 부호화되기 위하여 입력 되면 비교기에서 부호책의 N 개의 대표 벡터(부호단어)와 비교되어 그중에서 거리 측정치가 가장 작은 것을 선택하는 것이다. 그러므로 모든 부호단어와 벡터로 표기되는 데이터들의 거리를 계산해야 하므로 상당히 많은 양의 계산량이 요구된다. 부호화 과정은 VQ 부호화 과정에서 많은 계산량이 요구되는 것과는 달리 ROM(read only memory)과 같은 기억 소자에 의해 look up table 형태로 간단히 구현 가능하다^[13]. 그러므로 본 논문에서는 VQ의 부호화와 그의 VLSI 구조에 대해서만 논하였다.

[10]과 [14]에서 언급된 바와 같이 k 차수의 벡터를 하나의 대표 벡터와 MSE에 의한 거리를 계산하

기 위해서는, $d(x, y) = x^T x - 2(xy - y^T y/2)$ 를 계산해야 하는데, 일단 하나의 입력 데이터 x 에 대해 $x^T x$ 는 x 에 대한 값이므로 비교하려는 대표 벡터들과는 무관하다. 또한 $r_i - y^T y/2$ 는 어떤 대표 벡터 y 에 대해 주어지는 상수이므로, 입력 x 가 들어올 때마다 $x^T y$ 를 계산하고 미리 계산된 r 을 더해서 $x^T y + r$ 이 가장 크게 되는 부호단어의 index를 찾으면 된다. 즉 한번 거리 측정을 위해서 각 k 번의 곱셈과 덧셈을 행하면 된다. [16]에서 제안된 "linear array systolic VQ architecture"는 PE의 갯수가 $k+1$ 로 적은 반면에 through-put은 N 이므로 N 이 큰 경우에 실시간 비디오 영상의 VQ에는 적합하지 못하다. 그와 반면 [16]에서의 "two-dimensional systolic architecture"는 through-put이 1이지만 요구되는 PE의 갯수가 $N(k+1)$ 개로 상당한 구현 면적을 차지하게 된다.

본 장에서는 기본적인 특징에 있어서 앞에 언급된 [16]의 기본적인 두 구조를 절충하면서 비디오 영상의 실시간 VQ 부호화를 위해 through-put이 k 이고 PE의 갯수는 $2N$ 인 VQ systolic array 구조를 제시하였으며, 이를 앞장에서 제안한 CVQ에 적용하는 문제에 대해 논하였다.

(가) Through-put 이 k 인 VQ systolic array

제안된 systolic array의 블럭 선도를 그림 2에, 이를 구성하는 두 가지 종류의 PE들은 그림 3에 도시하였다. 그림 2는 $N=5, k=3$ 인 경우의 예로, 첫번 데이터가 입력되어서 그의 대표 벡터의 index가 나오는 시간인 latency는 $k+N$ step이며 이후로 through-put이 k 로, 즉 k step마다 k 차수의 벡터에 대한 VQ의 index들이 출력된다. PE A는 k step마다 Δ 를 계산하는 것으로 X_{IN}^1 로 양자화하고자 하는 벡터의 원소가 하나씩 입력되며 Y_{OUT}^1 로 Δ 값이 출력된다. Y_{IN}^1 로는 부호책중 하나의 대표 벡터가 매 step마다 벡터의 원소 단위로 입력된다. 이러한 PE A는 각 대표 벡터마다 하나씩 있어야 하며, 각 PE는 그에 해당되는 하나의 대표 벡터의 값만을 계속해서 다루게 된다. 또한 하나의 Δ 를 계산하기 시작하는 처음 step마다 덧셈기로 입력되는 데이터를 Y_{OUT}^1 의 값 대신에 Y_{IN}^2 의 r 을 선택하기 위해 선택 작업(muxing)을 해야 한다. PE B는 각 PE A의 하단에 위치하여 전단에서 X_{IN}^1 로 넘어온 Δ 값과 Y_{IN}^1 으로 입력되는 현재 step의 Δ 값을 서로 비교하여 큰 값을 X_{OUT}^1 을 통해서 또한 그의 index를 X_{OUT}^2 를 통해서 다음 단으로 넘겨 주게 된다. 그림 3(b)의 PE B 구조에서 "code index"는 PE B 상단의 PE A에 해당하는 대표 벡터의 index 값이다.

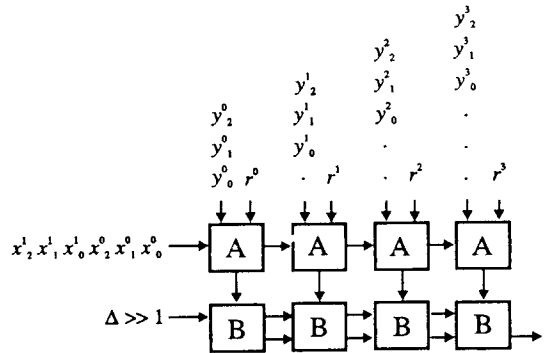


그림 2. Through-put이 k 인 선형 systolic 구조
Fig. 2. Linear systolic architecture for the VQ with the through-put of k .





그림 3. PE A와 PE B.
(a) PE a, (b) PE B.

Fig. 3. Processing elements, A and B.
(a) PE a, (b) PE B.

실시간 VLSI 구조를 위한 VQ는 through-put이 k 이면 되고 PE의 갯수도 $2N$, 즉 $O(N)$ 이므로 VLSI 구현을 위한 chip 면적도 절약된다. 또한 제안된 구조는 벡터의 차수 k 와는 무관하고 부호책의 크기 N 에만 관계되므로 k 를 임의로 변경해서 사용할 수 있다. 이는 DCT(discrete cosine transform)에 기초한 VQ에서 사용되는 여러 가지 차수를 가지는 VQ의 구현에 용이하다¹⁹⁾. 또한 PE의 배열이 선형으로 되어 있으므로 일정 수의 PE를 가지는 하나의 IC 소자를 임의로 여러 개 연결해서 원하는 크기의 부호책을 가지는 VQ의 구현도 가능하다. 그러나 $N=1024$ 와 같이 N 이 큰 경우에는 역시 상당히 많은 양의 PE가 요구됨을 알 수 있다.

(나) 제안된 CVQ의 systolic array

제안된 CVQ에서의 최소 거리 분류기는 그 구조가 VQ 과정과 동일하므로 먼저 VQ를 한 후 그 결과에 따라 입력 벡터가 해당되는 부류의 부 부호책으로 VQ를 다시 행한다. 이러한 과정을 그림 4에 도시하였는데, 앞서 제안된 VQ systolic array를 사용해서 분류기와 VQ를 구현한 것이다. 이 그림에서 z^k 는 line buffer로 k 개의 임시 기억 장소로 구성되어 있다. 같은 크기를 가지는 부 부호책들의 크기를 N_c 라 하면 전체 부호책의 크기는 $N=m \cdot N_c$ 가 된다. 또한 latency는 $2(k+N)$ 이며 두번째 단의 VQ구조로 입력되는 부호책은 첫번째 단의 분류기에서 계산된 부류 index에 의해 선택된다. PE의 갯수는 $O(m+N_c)$ 로 $m=N_c=N^{1/2}$ 일 때 $O(N^{1/2})$ 로 가장 적어진다. 그림 4에서 보는 바와 같이 제안된 CVQ의 구조는 동일한 형태의 VQ 구조를 분류기와 VQ에 모두 적용할 수 있으므로 regularity와 modularity의 성질을 가지고 있으며 이로 인해 VLSI로의 구현성이 우수함을 알 수 있다.




그림 4. 제안된 CVQ의 systolic 구조
 $m=3, N_c=3$

Fig. 4. Systolic array for the proposed CVQ.
 $m=3, N_c=3$

V. 모의 실험 및 토론

첫번째 모의 실험은 제안된 CVQ가 최적 조건에 열

마나 부합되는지를 보이기 위하여 수행되었다. 이 실험에서 각 입력 벡터는 영상을 연속되는 4×4 화소의 부블럭들로 나누어 구성하였으며, 부류의 갯수는 $m=16$ 이다. 실험 영상은 512×512 의 LENA를 사용하였다. 첫번째로 그림 5에는 각 부류의 왜곡치 J_i 를 도시하였다. 이때 최소 거리 분류기를 위한 군집화를 위해 LBG 알고리즘¹⁹⁾을 사용하였다. 언급된 바와 같이 J_i 들은 제안된 CVQ의 최적 조건을 만족하기 위한 전제 조건으로 상수가 되어야 한다. 그러나 LBG와 같은 군집화 알고리즘은 국부 최소치 문제로 그림 5에서 보는 바와 같이 식 (9)의 조건을 잘 만족시키지는 못한다. 따라서 [18]에서 제안된 군집 보정 알고리즘을 부가하였다.

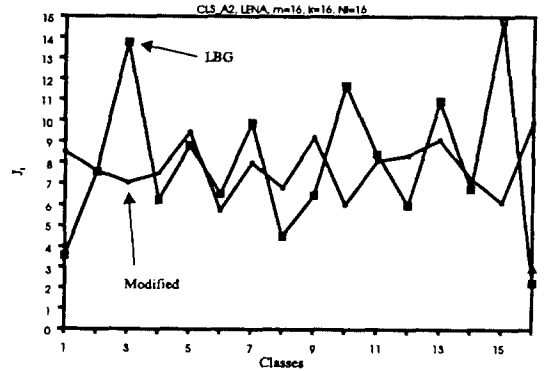


그림 5. 군집화 알고리즘에서 J_i
 Fig. 5. J_i 's in the clustering algorithm.




그림 6. 제안된 CVQ에서의 D_i
 Fig. 6. D_i 's in the proposed CVQ.

적용한 결과를 그림 5의 "MODIFIED"라 표기된 선으로 도시하였는데, 적용하기 전보다 많이 개선되었음을 알 수 있다. 예를 들어 1번, 3번 그리고 15번,

16번 부류는 고립된 군집들이지만 군집 보정 알고리즘에 의해서 J_i 값이 아주 크거나 작은 값이 없이 평균화 되었음을 알 수 있다. 이렇게 만들어진 각 부류에 상수의 같은 부호책 크기를 할당하여 부 부호책들을 설계 하였을 때의 각 부류에 의해 야기되는 왜곡치 D_i 를 그림 6에 도시하였다. 보는 바와 같이 최적 CVQ 조건인 식 (5)의 조건이 완벽하게 만족되지는 못하지만 각 군집을 분류기 설계시 보정해 줌으로 어느 정도 개선하였다. 그림 5와 6의 실험을 DCT 영역의 영상 데이터에 대해서도 행하여 그림 7과 8에 각각 도시하였다. 그림 5와 6의 공간 영역에서의 결과와 마찬가지로 결과를 보이고 있다. 결론적으로 제 III장에서 (i)항과 (ii)항의 조건에 대해 언급된 추론이 실 영상 데이터에 대해 잘 부합됨을 알 수 있다.

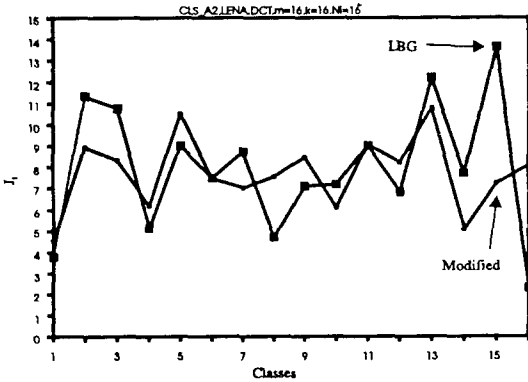


그림 7. 군집화 알고리즘에서 J_i (DCT 영역)
Fig. 7. J_i 's in the clustering algorithm(DCT domain).




그림 8. 제안된 CVQ에서의 D_i (DCT 영역)
Fig. 8. D_i 's in the proposed CVQ(DCT domain)

표 1. 훈련 집합의 내부 벡터에 대한 실험
Table 1. PROPOSED CVQ INSIDE TRAINING SET (PSNR)

b/pixel	algorithm	LENA	BRIDGE	PEPPER	BOATS
0.5	FVQ	31.51	25.50	31.29	30.78
0.5	16	31.47	25.37	31.26	30.79
0.625	FVQ	33.64	27.02	33.34	33.01
0.625	32	33.85	26.92	33.62	33.23

이제 제안된 CVQ를 영상 신호의 부호화에 사용하여 그 성능을 평가해 보았다. 분류기는 $m=16$ 과 $m=32$ 를 가지는 두 가지를 사용하였다. 벡터의 구성은 앞의 실험과 마찬가지로 벡터의 차수도 4×4 이다. 여기서 실험을 두 가지 방식으로 나누어서 행하였다. 첫번째 방법은 훈련 벡터의 내부 집합(inside training set)에 대한 CVQ설계 및 부호화로, 각 실험마다 512×512 영상 하나를 사용하였으며 그 결과를 표 I에 정리하였다. 이 실험들에서 PSNR은 다음과 같이 정의된다.

$$PSNR = 10 \log_{10} \frac{255^2}{M^{-1} \sum_{i=1}^M d(x_i, y_i)} \quad (15)$$

이 식에서 x_i 와 y_i 는 각각 원 영상과 복호화된 영상의 벡터이고, M 은 복호화된 벡터의 총 갯수이다. 표 I에서 "FVQ"로 표기된 실험은 LBG 알고리즘을 [18]에서 제안된 군집 보완 알고리즘 없이 사용해서 얻은 결과이며 "16"은 $m=16$, "32"는 $m=32$ 의 부류를 가지는 제안된 CVQ들의 결과이다. 표 I에서 보는 바와 같이 일반 전 탐색 VQ와 비교해서 성능이 거의 비슷함을 알 수 있다. 또한 오히려 더 좋은 결과를 보이는 경우도 있는데, 만일 제안된 CVQ 부호책으로, 즉 부호책 $\sum_{i=1}^m c_i$ 전 탐색 VQ를 수행한다면 이때의 결과는 당연히 각 CVQ의 결과보다는 더 좋아진다. 이러한 결과는 분류기 설계를 하면서 고립된 군집에 해당되는 대표 벡터들을 보정해 주었기 때문에 얻어지는 결과라고 사료된다. 이러한 고립된 군집을 보정해 주는 것을 부호책의 모든 대표 벡터에 대해 수행하면 표 I의 "FVQ"에 열거한 결과보다 상당히 좋은 결과를 얻을 수가 있다^[18]. 그러나 부호책의 크기가 커지면 보정 알고리즘으로 인하여 부호책 설계를 위한 계산량이 늘어나게 되므로 이때 제안된 CVQ의 설계와 같은 방법으로 군집화를 계층적으로(hierarchically) 행함으로써 부호책 설계에 소요되는 계산량을 줄임과 동시에 고립된 군집을 효율적으로 보정할 수 있다.

두번째 방법은 훈련 벡터의 외부 집합(outside

training set)을 복호화하는 것으로 다섯 장의 영상 데이터를 훈련 벡터 집합으로 사용하였으며 복호화는 훈련 집합에 속하지 않는 다른 영상들을 사용하였다. 실험 결과를 표 II에 정리하였는데 표 I에서의 실험과 마찬가지로 제안된 CVQ가 일반 전 탐색 VQ에 비해서 그 성능이 비슷하거나 오히려 더 좋은 결과를 보이고 있다.

표 2. 훈련 집합의 외부 벡터에 대한 실험
Table 2. PROPOSED CVQ OUTSIDE TRAINING SET (PSNR).

b/pixel	algorithm	LENA	BRIDGE	PEPPER	BOATS
0.5	FVQ	30.32	24.72	30.45	29.55
0.5	16	30.34	24.65	30.48	29.58
0.625	FVQ	31.77	25.69	31.73	30.84
0.625	32	31.77	25.67	31.78	30.90

VI. 결론

본 논문에서는 VQ의 양자화 복잡도를 줄이기 위한 일종의 CVQ 기법을 제안하였다. 부호화 복잡도를 최소화하기 위해서 각 부류의 부 부호책의 크기는 상수로 놓았고 제안된 CVQ가 최적화되기 위하여 최소 거리 분류기를 사용하였다. 모의 실험을 통해서 일반 전 탐색 VQ와 PSNR 면에서 성능이 비슷함을 보였다. 그러나 부호화 복잡도에서도 전 탐색 VQ가 $O(N)$ 인데 반해서 제안된 CVQ는 $O(N^{1/2})$ 이다. 예를 들면 $m=16, k=16$ 이고 $N_c=16$ 일때 부호화 복잡도는 전 탐색에 비하여 약 6.5 % 정도에 불과하다. 그러므로 부호화 복잡도를 줄여야 하는 VQ에 제안된 방법을 사용하여 복잡도를 줄일 수 있을 것으로 기대되며, 제 IV장에서 제안된 through-put이 k 인 단순하면서도 반복되는 systolic array 구조를 사용하여 제안된 CVQ를 구현하므로 실시간 VQ 부호기 설계가 가능하리라 기대된다.

부 록

계산의 용이성을 위하여 식 (5)의 상수 항을 ξ 라고 표기하면 식 (5)는 다음과 같이 다시 쓸 수 있다.

$$P_i^{ast} = [B_i(\beta) (\det P_i^{\beta+2} x_i)^{1/(\beta+1)}] \quad (A1)$$

그러면 Lagrange multiplier 방법^[4]으로 $\sum_{i=1}^m P_i = 1$ 이라는 제약(constraint)하에서 N_{cvq} 를 최소화시키자. 먼저 이를 위한 cost 함수는 다음과 같다.

$$\sum_{i=1}^m P_i N_i^* + \lambda (1 - \sum_{i=1}^m P_i) \quad (A2)$$

식 (A2)를 각 i 에 대해서 P_i 로 미분하고 그 미분치를 0으로 놓으면, 식 (A2)의 cost 함수를 최소화시키는 집합 $\{P_i^*\}$ 는 다음과 같다.

$$P_i^* = \xi [\frac{\lambda(\beta+1)}{\beta+2}]^{\beta+1} \frac{1}{B_i(\beta)(\det P_i)^{1/k}}, \quad i=1, \dots, m \quad (A3)$$

$P_i \geq 0, i=1, \dots, m$ 에 대해 식 (A1)의 2차 미분치는 항상 양수이므로 $\{P_i^*\}$ 는 strict minimum point^[4]가 된다. 따라서 식 (5)로부터 다음과 같은 관계가 유도된다.

$$N_i = constant, \quad i=1, \dots, m \quad (A4)$$

같은 방법으로 식 (A2)의 cost 함수를 $\sum_{i=1}^m N_i = N$ 이라는 제약에서 최소화시키는 집합 $\{N_i^*\}$ 를 구해 보면 다음과 같다.

$$N_i^* = \frac{\lambda}{\xi} \cdot \frac{\rho_i(C_i)}{\beta+2}, \quad i=1, \dots, m \quad (A5)$$

그러므로 식 (5)로부터 P_i 들이 모든 $i=1, \dots, m$ 에 대해 상수가 된다는 결과가 나온다.

참 고 문 헌

- [1] M.R. Anderberg, Clustering Analysis for Applications New York: Academic Press, 1993.
- [2] J.T. Tou and R.C. Gonzalez, Pattern Recognition Principle New York: Addison-Wesley, 1974.
- [3] J.A. Hartigan, Clustering Algorithms New York: John Wiley Sons, 1975.
- [4] D.G. Luenburger, Linear and Nonlinear Programming New York: Addison-Wesley, 1984, 2nd ed.
- [5] G.H. Golub and C.F. Van Loan, Matrix Computations. The Johns Hopkins Univ. Press, 1989, 2nd ed.
- [6] A. Gersho and R.M. Gray, Vector Quantization and Signal Compression. Boston: Kluwer Academic Publishers, 1992.
- [7] K. Fukunaga and W.L.G. Koontz, "A criterion and an algorithm for grouping data," IEEE Trans. Comput., vol. C-19.

- no.8, pp. 917-923, Oct. 1970.
- [8] A. Gersho, "Asymptotically optimal block quantization," IEEE Trans. Inform. Theory vol. IT-25, no.4, pp. 373-380, July 1979.
- [9] Y. Linde, A. Buzo, and R.M. Gray, "An algorithm for vector quantizer design," IEEE Trans. Commun. vol. COM-28, no.1, pp. 84-95, Jan, 1980.
- [10] H.T. Kung, "Why systolic architecture?" IEEE Computer Mag. vol.15, pp. 37-46, Jan. 1982.
- [11] P. Zador, "Asymptotic quantization error of continuous signals and the quantization dimension," IEEE Trans. Inform. Theory vol. IT-28, no.2, pp. 139-149, March 1982.
- [12] J.A. Bucklew and G.L. Wise, "Multi-dimensional asymptotic quantization theory with ϵ th power distortion measure," IEEE Trans. Inform. Theory vol. IT-28, no.2, pp. 239-247, March 1982.
- [13] R.M. Gray, "Vector quantization," IEEE ASSP Mag vol.1, no.4, pp. 4-29, Apr. 1984.
- [14] L.M. Ni and A.K. Jain, "A VLSI systolic architecture for pattern clustering," IEEE Trans. Pattern Anal. Machine Intell. vol. PAMI-7, pp. 80-89, Jan. 1985.
- [15] B. Ramamurthi and A. Gersho, "Classified vector quantization of images," IEEE Trans. Commun. vol. COM-34, no.11, pp. 1105-1115, Nov, 1986.
- [16] G.A. Davison, P.R. Cappello, and A. Gersho, "Systolic architectures for vector quantization," IEEE Trans. Acoust., Speech, Signal Processing vol. ASSP-36, no.10, pp. 1651-1664, Oct, 1988.
- [17] D.S. Kim and S.U. Lee, "Image vector quantizer based on a classification in the DCT domain," IEEE Trans. Commun., vol. COM-39, no.4, pp. 549-556, Apr, 1991.
- [18] D.S. Kim and S.U. Lee, "Classified vector quantizer based on the minimum-distance partitioning, in Proc. Visual Communications and Image Processing SPIE-1360, Boston, Nov. 1991, pp. 190-201.
- [19] J.W. Kim and S.U. Lee, "Discrete cosine transform-classified VQ technique for image coding," IEEE Trans. Circuits, Systems for Video Technology vol. VT-2, no.1, pp. 3-14, March 1992.

 저 자 소 개



金東植(正會員)

1963年 10月 16日生. 1986年 2月 서울대학교 공과대학 제어계측공학과 졸업. 1988년 2월, 1994년 2월 서울대학교 대학원 제어계측공학과에서 각각 석사 학위와 박사 학위 받음. 주관심

분야는 벡터 양자화, 영상 데이터 감축, VLSI 신호 처리, 패턴 인식 등임.