

論文95-32B-11-17

다중쉘 하이퍼큐브 구조를 갖는 코드북을 이용한 벡터 양자화 기법

(Image Coding Using the Self-Organizing Map of Multiple Shell Hypercube Structure)

金 永 根 * , 羅 鍾 範 **

(Young-Keun Kim and Jong-Beom Ra)

要 著

벡터 양자화 기법이 낮은 비트율에서 영상의 압축에 사용될 때 신호대 잡음비를 올리기 위해서는 양자화를 위한 블럭의 크기가 클수록 바람직하다. 그러나 블럭 크기 증가로 인해 계산량 및 저장 용량은 기하급수적으로 증가하게 되므로 이 문제를 해결하기 위하여 새로운 모델의 신경 회로망 구조를 제안하였다. 이 구조는 다차원의 하이퍼 큐브로 이루어진 자기 조직형 신경 회로망을 다중쉘로 구성하므로써 정의된다. 이러한 구조를 이용하면 성능 저하를 최소화하면서 시간적으로 효과적인 검색이 가능하다. 한편 이구조에서는 각 단위쉘에 따라서 서로 다른 시각 특성의 벡터들이 자연적으로 분산되게 학습되므로 기존의 분류 양자화 기법에 비해서 별도의 분류기를 갖지 않고도 분류 벡터 양자화가 이루어지는 특성을 갖는다. 컴퓨터 모의 실험을 통하여 제안된 방법이 큰 블럭의 벡터 양자화에 유용함을 확인하였다.

Abstract

When vector quantization is used in low rate image coding (e.g., $R < 0.5$), the primary problem is the tremendous computational complexity which is required to search the whole codebook to find the closest codevector to an input vector. Since the number of code vectors in a vector quantizer is given by an exponential function of the dimension, i.e., $L = 2^{nR}$ where R is the rate in bits/pixel, its computational complexity increases abruptly with the dimension n . To alleviate this problem, a multiple shell structure of hypercube feature maps (MSSHFM) is proposed. A binary HFM of k -dimension is composed of nodes at hypercube vertices and a multiple shell architecture is constructed by surrounding the k -dimensional HFM with a $(k+1)$ -dimensional HFM. Such a multiple shell construction of nodes inherently has a complete tree structure in it and an efficient partial search scheme can be applied with drastically reduced computational complexity. Computer simulations of still image coding were conducted and the validity of the proposed method has been verified.

I. 서 론

** 正會員, 三星電子 通信 開發室

(Communication Systems R/D Center, Samsung Electronics Co., Ltd.)

* 正會員, 韓國 科學 技術院 電氣 및 電子工學科

(Dept. of Electrical Engineering, KAIST)

※ 본 연구는 국방과학연구소 기초연구비 지원에 의하여 수행되었음

接受日字: 1995年2月21日, 수정완료일: 1995年10月26日

좁은 대역폭이 요구되는 신호 압축에서 벡터 양자화 (vector quantization)방식은 매우 효율적인 방법으로 알려져 있다 [1][2]. 이때 블럭의 크기(혹은 벡터의 차원)는 크면 클수록 더 나은 성능을 기대할 수 있으나 압축 단계에서 입력 벡터에 가까운 대표 벡터를 찾는데 걸리는 시간이 기하급수적으로 증가하는 문제 점 때문에 여러가지 근사화된 방식들이 연구되어 왔다

[3] [4] 이중 트리 구조 벡터 양자화 기법은 부분 검색 방법에 비해 적은 계산량으로 이상적인 벡터 검색(Full Search VQ)에 가까운 성능을 얻을수 있는 대신 많은 메모리 요구량이 그 단점으로 지적된다. 계산량 다음으로 중요한 문제는 벡터 양자화 방식으로 재구성된 영상에서 흔히 나타나는 edge 열화 현상이다. 이를 개선하기 위하여 최근 여러가지 형태의 분류 벡터 양자화 방식(Classified VQ)들이 제안되었다^[5].

[5] 그러나 종래의 방식들은 선분류(pre-classification)를 이용하므로 이 분류 방식의 정확도가 성능을 크게 좌우하게 되며 블럭의 크기가 크면 분류 자체도 어려울 뿐만 아니라 입력 신호의 통계적인 특성이 변화할 경우 이미 고정되어 있는 codebook 때문에 성능이 떨어지게 되는 문제점이 있다. 이를 개선하기 위해서 최근에는 적응 학습을 통하여 codebook을 계속 고쳐나갈 수 있도록 신경회로망을 이용한 방식이 제안되었으나 구현의 복잡성 때문에 실용 적이지 못한 단점이 있다^[6].

본 논문에서는 새로운 형태의 다중쉘 신경 회로망 모델을 제안하여 계산 복잡도를 줄이고, 영상을 구성하는 block들의 분포에 따라서 효율적으로 전송 bit수를 줄일 수 있는 벡터 양자화 방식을 제안한다. 제안된 방법은 Neighbor 개념을 도입하여 트리 구조의 벡터 양자화 기법에 비해 구조상 발전된 형태로 신경 회로망을 근간으로 하므로 입력 신호에 적응성이 있으며 외곽쉘에서의 노드(code vector)의 수가 기하급수적으로 증가하여 외곽쉘에 edge 성분의 벡터가 분포하게 되는 모델의 특성상 벡터 양자화의 단점으로 되어 있는 edge의 열화를 방지할 수 있다는 장점이 있다. 2절에서는 제안된 신경 회로망 모델의 구조와 학습 알고리즘에 관해서 기술한다. 3절에서는 정지 영상의 압축에 제안한 알고리즘을 적용한 결과를 설명하고 4절에서 결론을 맺는다.

II. 자기 조직형 신경 회로망 모델

자기 조직형 신경 회로망 모델인 SOFM(self-organizing feature map)은 Kohonen에 의해서 제안되었고 계층적 관계를 갖는 정보들을 잘 나타낼 수 있다^[7]. SOFM은 node와 연결강도 벡터(weight vector)의 집합으로 이루어져 있다. 그림 1(a)에서처럼 하나의 node는 외부에서 가해지는 입력 신호들과

각각 연결강도를 갖고 있는 꾀으로 연결되어 있다. 노드가 하는 일은 입력 벡터 $x = [x_1, x_2, \dots, x_n]^T$ 와 연결강도 벡터 $w = [w_1, w_2, \dots, w_n]^T$ 사이의 거리를 계산하는 것이다. 각 node들은 열구조(array structure)로 조직될 수 있으며 그림 1(b)는 2차원 열구조의 경우를 나타낸 것이다. 입력 벡터는 모든 node들에 동시에 가해지며 모든 node들은 주어진 입력 벡터와 자신들의 연결강도 벡터들과 거리를 계산한다. 그중에서 거리가 가장 적은 node를 winner라고 정의한다. SOFM은 1차원은 물론 3차원 이상의 열구조를 가질 수도 있다.

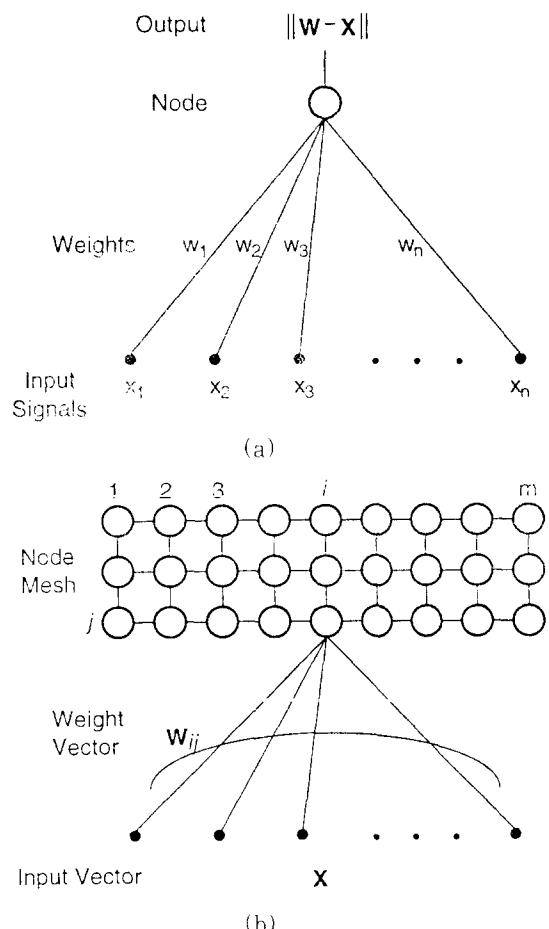


그림 1. SOFM의 topology

Fig. 1. Examples of SOFM topology.

SOFM은 고유의 학습 알고리즘을 가지고 있다. 학습을 통하여 SOFM은 연결강도 벡터들을 외부의 입력 벡터들의 통계 특성에 적응시킨다. 이 때 사용되는 입력 벡터들을 학습 벡터(training vector)라고 부른다.

학습이 적용되는 node들의 집합을 neighborhood라고 하며 winner를 중심으로 항상 정의 된다. 하나의 학습 벡터를 주고 SOFM의 winner를 찾은 다음 그림 2에서처럼 정의되는 neighborhood N_a 를 찾는다. N_a 에 속하는 node들의 연결강도 벡터는 식 1에서처럼 주어진다.

$$w_i(t+1) = w_i(t) + \eta [x(t) - w(t)], i \in N_a \quad (1)$$

여기에서 η 는 학습률(learning rate)을 결정하는 변수이며 0과 1사이의 값을 갖고 학습 초기에는 1에 가까운 값을 갖고 학습이 진행되면서 값이 작아진다.

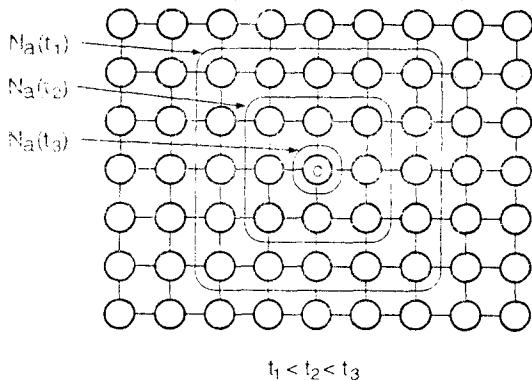


그림 2. 학습이 진행됨에 따라 winner를 중심으로 neighborhood가 변천해 가는 과정

Fig. 2. An example of the topological neighborhood N_a of cell c . The radius of neighborhood decreases with time ($t_1 < t_2 < t_3$).

그림 3은 2차원 입력 벡터의 확률에 대해서 1차원과 2차원 SOFM이 어떻게 학습될 수 있는가를 예로 보여주고 있다. 2차원 평면상에 삼각형의 내부에서 만 균일한 빈 도로입력 벡터가 발생하고 외부에서 발생하는 확률은 zero라고 가정한다. (a)는 SOFM의 연결강도 벡터들을 난수로 초기화시켰을 때를 나타낸다. Node의 개수를 모두 16개라고 할 때 그들이 1차원 열구조와 4×4 의 2차원 그물구조를 가질 때 학습이 끝난 후 결과는 각각 (b)와 (c)로 주어질수 있다. 학습 벡터들은 삼각형의 내부에서 임의로 발생시켜 사용한다. 학습이 완료된 후 그림 3의 (b)와 (c)에서처럼 입력 벡터 x 가 가해졌다고 가정한다. 이 입력벡터에 대해서 결정되는 winner는 1차원과 2차원 SOFM에 대해서 각각 7번째 node와 node(3,3)이 될 것이다. 1차원 SOFM에서는 7번째 node가 winner가 된다는 것을 알기 위하여 모든 node에 대해서 거리를 계

산해야 한다.

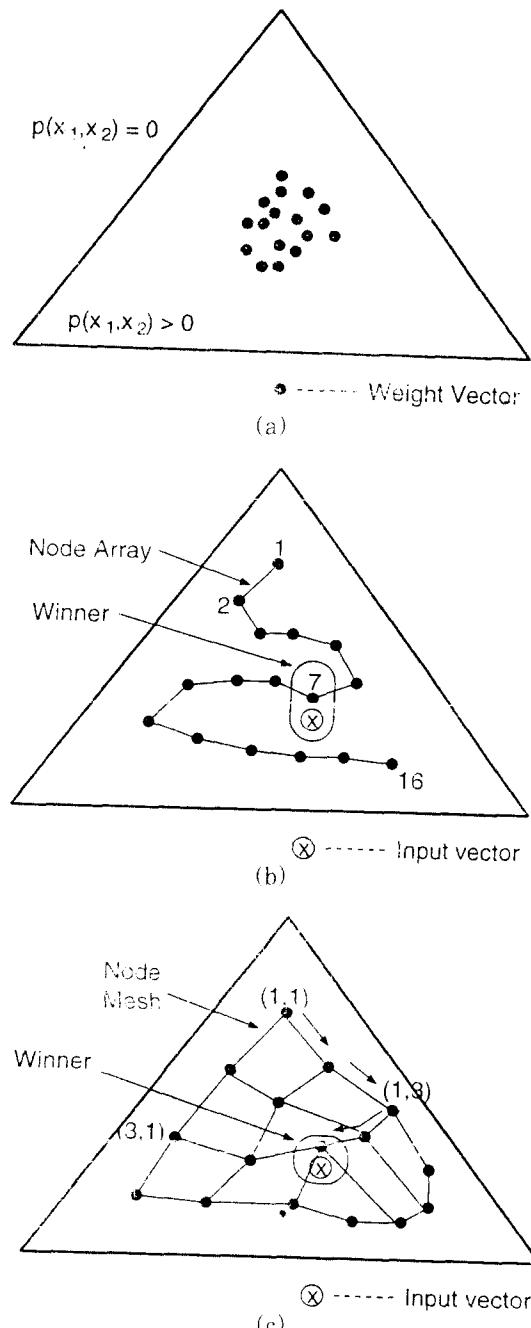


그림 3. (a) 삼각형의 내부에서만 벡터가 발생한다고 가정할때, 16개의 연결 강도 벡터들이 (b) 1차원과 (c) 2차원 SOFM으로 학습이 일어나는 예

Fig. 3. A graphical comparison of the search paths of (a) 1-dimensional and (b) 2-dimensional SOFM, respectively.

그러나 2차원 SOFM의 경우에는 먼저 node (1,1) (1,2) (1,3) (1,4)에 대해서만 최소거리를 찾고 다음 (2,3) (3,3) (4,3)에 대해서 최소거리를 구함으로써 보다 적은 계산량으로 winner인 node(3,3)을 찾아낼 수 있다. 이러한 차이 점은 사용할 SOFM의 차원 및 그 구조를 결정하는데 중요한 열쇠가 된다. 벡터 양자화를 위한 codebook을 설계하는데 널리 쓰이는 LBG 알고리즘은 codebook 생성을 위해서 모든 학습벡터들을 여러번 적용해야만 한다. 그러나 벡터의 차원이 16일 때(4x4 경우)와 64일 때(8x8 경우) 필요한 학습 벡터들의 수는 기하급수적으로 차이가 난다^[10]. 반면에 SOFM은 하나의 학습벡터마다 가중벡터들을 생성하여 주기 때문에 계산량에 대한 부담이 훨씬 적고, 입력 벡터들의 전체 통계 특성을 빠른 시간안에 찾아갈 수 있다는 장점으로 인하여 높은 차원의 벡터 공간에서도 용이하게 적용될 수 있으며 따라서 낮은 대역폭의 영상부호화에 사용될 수 있다.

1. 다중쉘 구조 자기 조직형 모델

본 논문에서는 새로운 다중쉘 구조의 자기 조직형 모델인 MSSHFM (multiple shell structure of hypercube feature map)을 제안하여 낮은 대역폭의 벡터 양자화 방식에 적용하고자 한다. MSSHFM은 0 차 원에서부터 K차원까지 분포하는 HFM(hypercube feature map)들을 서로 concentric한 단일 구조체로 결합한 형태를 갖는다. 그림 4는 각기 서로 다른 차원의 HFM들을 나타내고 있다.

그림 5는 이러한 HFM들을 결합하여 구성한 MSSHFM의 예를 보여준다. MSSHFM의 차원은 그것을 구성하는 가장 높은 차원의 HFM에 의해서 대표된다. 그림 5은 3차원 MSSHFM에 해당한다.

또한 MSSHFM은 그림 6에서처럼 계층적 나무구조의 형태로 나타낼 수도 있다. 이것은 2진 나무 구조(binary tree structure)를 그 안에 포함하고 있으며 같은 층(layer 혹은 HFM)내에서 서로 떨어져 있는 node사이에 neighbor 관계가 정의되어 있다. 하나의 h 차원 HFM의 node는 h 개만큼의 neighbor를 갖는다. 또한 각자의 node는 h -bit 2진수에 의해서 모두 지정될 수 있다. 그림 4의 3차원 HFM의 경우 3-bit 2진수를 사용하면 8개의 모든 node를 지정할 수 있으며 서로 neighbor 관계에 있는 node 쌍은 3-bit 중에 하나의 bit를 역전시킴으로써 서로 표현될 수 있다. 그

림 5에서는 서로 다른 차원의 HFM node간의 neighbor 관계를 표현하고 있다.

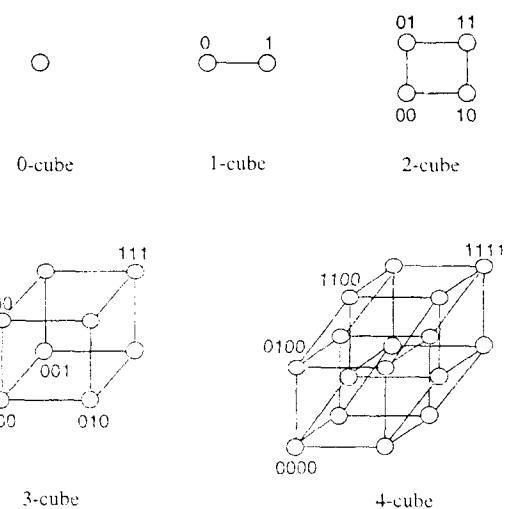


그림 4. 여러 차원의 HFM들

Fig. 4. The hypercube topology: 0, 1, 2, 3, and 4-cube are illustrated.

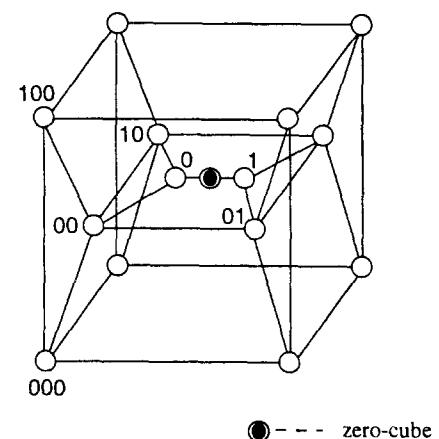


그림 5. 3차원 MSSHFM

Fig. 5. 3-cube MSSHFM.

차원이 하나 높은 HFM내의 neighbor는 bit수가 하나 증가함으로써 지정될 수 있다. 예를 들어 2차원 HFM의 node '00'의 neighbor는 3차원 HFM내의 두개의 node '000'과 '100'이 되며 한차원 낮은 1차원 HFM내의 neighbor는 '0'이 된다. 그리고 2차원 HFM내의 neighbor는 '10'과 '01'이 된다. 일반적으로 h 차원 HFM의 node는 같은 HFM내에 h 개, 바깥쪽 차원 HFM내에 2개, 그리고 안쪽 차원의 HFM에 1개의 neighbor를 가지며 모두 $(h+3)$ 개의 neigh-

bor를 가질수 있고 그 지정 address 혹은 index 는 위에서 설명한 2진수 관계를 만족시킨다. (단 $h=0$ 인 경우와 $h=K$ 인 경우는 제외.) K차원 MSSHFM의 임의의 node로부터 다른 곳에 위치한 임의의 node로 이동할 때는 연속적인 bit 역전에 의해서 이루어진다.

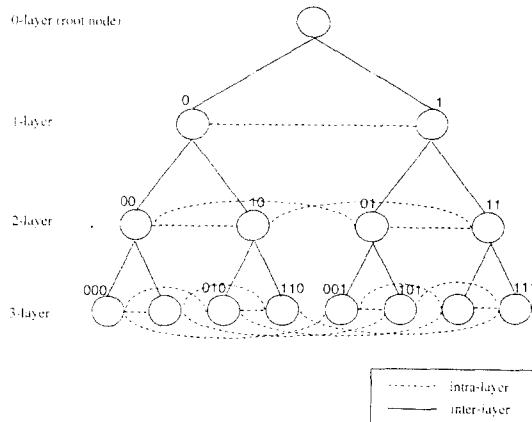


그림 6. 3차원 MSSHFM의 나무구조 그림
Fig. 6. A tree structure representation of K -cube MSSHFM where $k=3$.

자기 조직형 신경 회로망 모델에서는 neighborhood의 정의가 필수적이다. K차원 MSSHFM에서는 그 특수한 구조상 그림 7과 같은 neighborhood N_c 를 정의한다. N_c 의 범위는 중심에 위치하는 node c 에서 바깥쪽에 위치하는 p 개의 HFM과 안쪽 1개의 HFM을 포함한다. 학습이 진행되는 동안 N_c 에 포함되는 node들의 연결강도 벡터들은 식 1에 의해서 생성된다. N_c 는 생성되는 node들의 범위를 정의할 뿐만 아니라 winner를 찾는 과정에 서도 동일하게 사용된다.

자기 조직형 신경 회로망 모델을 사용할 경우 그 구조에 따라서 부분 검색 알고리즘(partial search algorithm)이 적용될 수 있음을 앞에서 언급하였다. MSSHFM의 부분 검색 알고리즘은 그 검색범위를 N_c 로 정의하고 N_c 내에서의 최소 거리 node가 중심에 위치하는 중심 노드 c 가 되는 것을 종료 조건으로 정합으로써 이루어진다. 검색의 시작은 항상 0차원 HFM node(혹은 root node)로부터 출발한다. 검색의 진행 방향은 보통 root node로부터 높은 차원의 HFM 쪽으로 흘러 가게 된다.

이와 같은 부분 검색 알고리즘은 필요한 계산량을 크게 감소시킬 수 있는 장점이 있지만 반대로 성능이 떨어지는 결과를 낳게 된다. 그러나 K차원 MSSHFM

은 그 구조가 root node의 연결강도 벡터를 전체 학습 벡터의 중심(평균벡터)으로 고정시킴으로써 성능의 열화를 개선할 수 있다. 학습 벡터의 확률 분포가 그 평균점에 대해서 Gaussian 분포와 같이 중심에 대부분이 집중되어 있고 멀어질수록 희박해지는 경우를 가정하자. 이 때 root node의 연결강도 벡터를 평균 입력 벡터라고 생각한다. root node 이외의 K차원 MSSHFM의 연결강도 벡터들을 난수로 초기화시킨 다음 학습을 진행시키게 되면 부분 검색 알고리즘의 특성상 낮은 차원의 HFM들이 먼저 학습이 잘 이루어지게 된다. 이것은 평균점에서 가까운 곳의 확률분포를 균사화시키는 형태로 연결강도 벡터들이 형성된다는 것을 의미한다. 이와같이 낮은 차원의 HFM이 포화 단계에 먼저 도달하게 되면 학습의 진도가 바깥쪽 즉 높은 차원의 HFM 쪽으로 옮겨가게 되어 중심점으로부터 멀리 떨어진 영역의 확률분포를 닮아가도록 학습이 진행된다. 이것은 마치 다차원의 구형 그물이 공간의 중심에서 멀어지는 방향으로 부풀어 오르는 것처럼 연결강도 벡터들의 분포가 퍼져나가는 것과 같다.

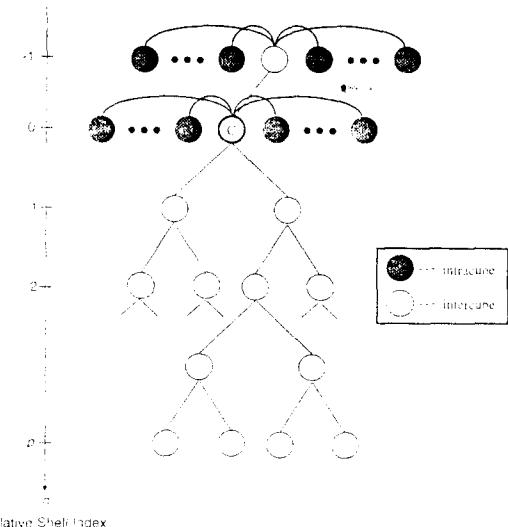


그림 7. K차원 MSSHFM에서의 neighborhood
Fig. 7. The graphical representation of topological neighborhood of cell c .

이러한 모델의 학습 특성으로부터 두 가지 장점을 얻을 수 있다. 첫째, 평균 검색 시간의 단축 혹은 평균 계산량의 감소효과이다. 확률이 평균점 근처에 집중되어 있고 부분 검색이 root node로부터 이루어지기 때문에 제일 바깥쪽 HFM까지 검색이 진행되는 경우는 확률적으로 적어진다. 따라서 전체 평균검색 시간이

절약될 수 있다. 물론 이것은 확률 분포가 중심에 집중되어 있을 경우에만 효력을 발생할 수 있다. 그러나 영상을 부호화할 경우 벡터의 mean을 분리하거나 혹은 예측 벡터 양자화에서처럼 redundancy를 먼저 제거한 후의 차ベ터를 다룰 경우에는 이와 같은 가정이 충분히 성립될 수 있다. 둘째, 부호화에 필요한 bit수를 효과적으로 절약할 수 있다. K차원 MSSHFM의 node는 그 node가 속한 HFM의 shell index와 그 HFM내에서의 member index에 의해서 지정될 수 있다. 이때 필요한 bit수 r_n 은 다음과 같이 주어진다.

$$\begin{aligned} r_n &= r_{\text{shell}} + r_{\text{member}} \\ &= \log_{2K} n, \quad n = 0, 1, \dots, K, \end{aligned} \quad (2)$$

여기에서 shell index를 위한 bit r_{shell} 에 대해서 entropy code를 부여한다. 고정된 bit수보다는 확률에 따라서 그 길이를 다르게 하면 많은 bit를 절약할 수 있다. 단 하나의 bit를 절약하더라도 낮은 대역폭에 서는 큰 효과를 나타낼 수 있다.

표 1. 16차원 MSSHFM의 shell index를

부호화하기 위한 Huffman code

Table 1. Huffman codes for hypercube indexes.

Hypocube Index	Probability	Huffman Code (Prefix)
15	0.127	111
14	0.063	1101
13	0.057	10111
12	0.043	10001
11	0.024	101101
10	0.025	101100
9	0.045	10011
8	0.021	100101
7	0.024	100100
6	0.012	1000001
5	0.020	100001
4	0.093	1010
3	0.057	1100
2	0.003	10000001
1	0.001	10000000
0	0.385	0

표 1은 블럭의 크기를 8x8로 하고 16개의 셀로 이

루어진 MSSHFM 코드북을 만들었을 때, 사용된 학습 영상들에 대해서 각 단위셀에서 양자화된 학습 벡터들의 분포로부터 구한 Huffman code를 각 셀에 대해서 나타낸 것이다. 만약 이와 같은 entropy 코드를 사용하게 되면 고정 길이 비트(4 bit)를 썼을 때에 비해서 Lena 영상에 대해서 약 0.853비트를 절약할 수 있게 된다.

2. 학습 알고리즘

K차원 MSSHFM을 위한 학습 알고리즘은 다음과 같이 요약될 수 있다.

단계 1. 연결강도 벡터의 초기화. 전체 연결강도 벡터들을 난수로 초기화시킨다. Root node를 위한 연결강도 벡터는 0으로 초기화시키며 학습이 진행되는 동안 이 값은 갱신되지 않는다. 각 차원의 HFM을 독립적으로 다루기 위해서 반복계수 m_k 를 0으로 초기화시킨다. 이 때 $k = 0, 1, \dots, K$.

단계 2. 학습 벡터의 적용 및 검색. 학습 벡터를 임의로 선택하여 부분 검색을 실행한다. 입력벡터와 가장 짧은 거리를 갖는 연결강도 벡터를 찾고 그 winner에 대해서 neighborhood N_i 를 찾는다.

단계 3. 연결강도 벡터의 갱신. m_k 가 미리 정해진 반복한계인 M'_k 보다 크면 단계 4로 간다. 아니면 N_i 에 속하는 모든 node들에 대해서 다음 식에 의해서 연결강도 벡터를 갱신한다.

$$w_i(m_{k+1}) = w_i(m_k) + \eta_i(m_k, \alpha) | x(m_k) - w_i(m_k) |$$

여기에서 $i \in N_i$ 이고 최종 학습률 $\eta(m_k, \alpha)$ 는 다음과 같이 주어진다.

$$\eta_i(m_k, \alpha) = \eta(m_k) \alpha(n) \quad (2)$$

그 winner가 속한 HFM의 반복계수 m_k 를 1만큼 증가시킨다.

단계 4. 종료 검사. 만약 모든 m_k 가 그 반복한계 M'_k 을 벗어나면 학습을 종료하고 그렇지 않으면 단계 2로 간다.

그림 8은 각 HFM에 대한 학습률의 변화를 나타낸 것이고 $\eta_{k, \max}$ 는 보통 0.7을 사용하고 $\eta_{k, \min}$ 은 0.003, 그리고 M_k 와 M'_k 은 k 차원 HFM에 대해서

알맞게 정한다. $a(n)$ 은 N_c 에 속해있는 node의 HFM이 winner가 속해있는 HFM과 떨어져있는 정도에 의해서 가해지는 가중치로서 거리에 반비례한다.

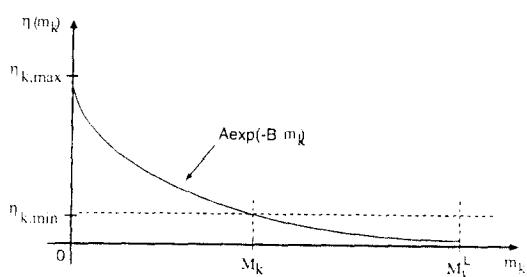


그림 8. K차원 MSSHFM을 위한 학습율의 변화
Fig. 8. The basic change of learning rate for a node.

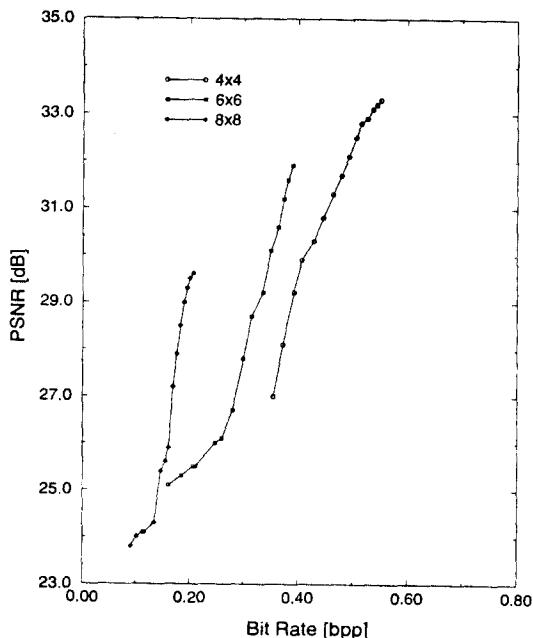


그림 9. 4x4, 6x6, 그리고 8x8 블록에 대해서 K-cube MSSHFM을 이용하여 lena 영상을 양자화했을 때 PSNR

Fig. 9. PSNR vs. rate curve. PSNRs of the test image "lena" are measured with the block sizes, 4×4, 6×6, and 8×8, using k-cube MSSHFM where $k=1, 2, \dots, 15$.

바깥쪽 HFM일 경우에는 n_i 가 양수이고 안쪽 HFM은 음수값을 갖는다. M'_k 은 각 HFM에 대해서 서로 다른 값을 부여하는데 보통 바깥쪽 HFM으로 갈수록

큰 값을 준다. 대략 4000에서 25000사이의 값을 사용한다. 이것은 모든 node들이 꼴고루 학습될 수 있는 기회를 조절하는 기능을 갖는다. 최종적인 학습률 $\eta_e(m_k, \alpha)$ 는 입력벡터의 통계 특성을 직접 반영하기 때문에 이외에도 입력 벡터의 특성에 따라 강조하고 싶은 것들에 대해서 또 다른 가중치를 정의하여 변화를 줄 수 있다.

III. 실험 결과

컴퓨터 모의실험은 블럭의 크기를 4x4, 6x6, 그리고 8x8로 변화시키면서 수행하였다. 학습 영상으로는 모두 24장의 정지화상을 사용하였으며, 성능 측정을 위한 실험 영상으로는 학습 영상에 포함되지 않은 lena, pepper, 그리고 baboon을 사용하였다. 비트율은 대략 0.1에서 0.5 bpp사이에 분포하였다. 학습 블록들은 학습 영상들로부터 구하고 블럭의 평균을 제거하고 남은 차블럭을 사용하였다. K-cube MSSHFM은 K 값을 1부터 15까지 변화시켜가면서 학습을 시켰으며 각 코드북의 크기는 $2^{K+1}-1$ 로 주어진다.

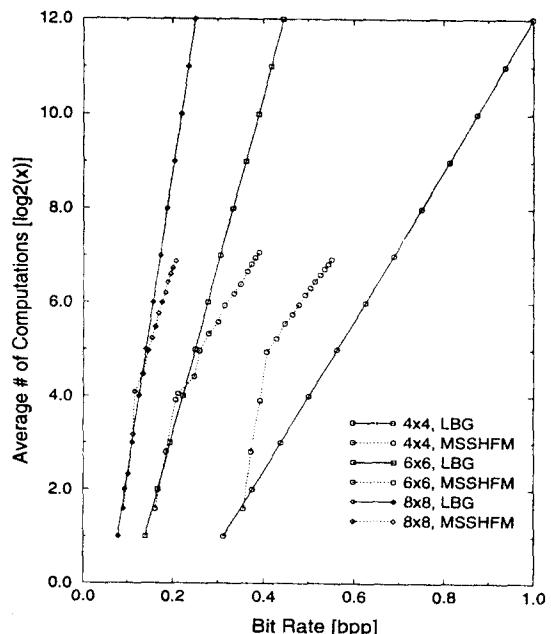


그림 10. 4x4, 6x6, 그리고 8x8 블록에 대해서 K-cube MSSHFM을 이용하여 lena 영상을 양자화했을 때 평균계산량

Fig. 10. Average number of distance computations measured with the test image "lena" using k-cube MSSHFM where $k=1, 2, \dots, 15$.



그림 11. 8x8 블록에 대해서 K-cube MSSHFM을 이용하여 lena영상을 양자화한 결과. (a) $K=1(0.09\text{bpp})$, (b) $K=9(0.16\text{bpp})$, (c) $K=12(0.19\text{bpp})$, (d) $K=15(0.2\text{bpp})$

Fig. 11. Reproduced images of the block size 8×8 . (a) $K=1(0.09\text{bpp})$, (b) $K=9(0.16\text{bpp})$, (c) $K=12(0.19\text{bpp})$, (d) $K=15(0.2\text{bpp})$.

그림 9는 lena 영상을 사용하여 압축한 PSNR 결과를 나타낸 것으로 Huffman 코드를 이용하여 entropy coding을 수행한 것이다. 블럭 크기가 4x4일 때, 0.515 bpp에서 약 32.8 dB를 얻었으며 이것은 공간 영역에서 CVQ를 하였을 때보다 약 2.5 dB 큰 값이다 [5]. 표 1은 학습 영상들에 대해서 그 학습 블럭들의 확률 분포를 MSSHFM의 각 셀에 대해서 나타낸 것으로서, 하나의 입력 블럭에 대해서 coding이 끝난 후에 각 셀 index의 대응하는 Huffman 코드가 사용된다.

블럭의 크기가 작을수록 발생할 수 있는 feature들의 종류가 edge보다는 shade, midrange에 집중 되며 블럭의 크기가 커지면 상대적으로 발생하는 feature의 종류가 급격히 증가하여 바깥쪽 셀의 점유가 증가한다.

그림 10은 각 비트율에 대해서 하나의 입력 벡터가 양자화될 때 필요한 평균 계산량을 LBG 알고리즘과 서로 비교한 것이다. MSSHFM을 사용하게 되면 하나의 셀이 증가하더라도 평균 계산량은 선형적으로만 증가하고 그 절대량도 크지않다. 그림 11(a)-(d)는

8x8 블럭에 대해서 제안된 방법으로 양자화한 결과 영상이다. $K=9$ 일때 어깨 부분에서 나타나는 edge degradation이 $K=15$ 가 되면서 개선되는 것을 볼 수 있다. 이것은 바깥쪽 HFM을 구성하는 코드벡터들이 edge 부분들을 보다 잘 양자화하기 때문이며 이것은 또한 안쪽에 위치한 HFM들을 midrange나 shade에 해당한다는 것을 의미한다.

IV. 결 론

본 논문에서 제안한 신경회로망 모델을 이용하여 low rate coding에 적용할 수 있는 가능성을 살펴볼 수 있었다. VQ는 이론적으로 가장 성능이 뛰어난 방법이며 벡터의 차원이 크면 클수록 최선의 결과를 얻을수 있다. 그러나 거기에 따라서 기하급수적으로 늘어나는 계산량의 복잡도와 edge의 열화때문에 그 사용이 제한되어 왔다. 다중쉘 형태의 자기 조직형 신경회로망 모델내에서 주어진 하나의 입력 벡터에 대한 최소오차 코드벡터를 검색할 때 이동하는 쉘의 거리와 같은 쉘내에서 찾아가는 거리(node의 갯수)가 블럭의 크기에는 민감하지 않고 입력 영상의 특성에 의해서만 변화하는 특징이 있는 것을 확인할 수 있었다. 즉 입력 영상이 head-and-shoulder 영상과 같이 변화가 약한 영상일 경우 거의 모든 블럭에 대해서 검색이 이루어지는 쉘이 제일 바깥쪽이 될 경우는 아주 적으며, 반대로 bridge와 같이 edge나 texture와 같은 특성이 아주 지배적인 영상일 경우에는 상당수의 검색이 바깥쪽 쉘까지 이루어지게 된다. 이러한 특성은 정지 영상의 압축보다는 동영상으로의 응용면에서 이점이 있다는 것을 의미한다고 할수 있다.

VQ를 이용한 영상 압축의 또 다른 장점은 변환 부호화를 사용하는 방식에 비해서 특히 low rate에서 재구성된 영상의 시각적인 특성이 우수하다는 것이다. VQ는 blocking artifact를 잘 만들지 않는다. 반대로 VQ 방법의 단점은 변화하는 외부입력 특성에 대해서 성능이 떨어지는 것이다. 그러나 본 논문에서 제안된 방법은 신경회로망 모델에 기초한 것이기 때문에 외부의 특성 변화에 적응할 수 있는 능력이 있다.

참 고 문 헌

- [1] E. E. Shannon *The mathematical Theory of Communication*. Illinois: The University of Illinois Press, 1949
- [2] P. Elias. In N. Abramson, *Information Theory and Coding* New York: McGraw-Hill Book Company (1963)
- [3] P. A. Chou, T. Lookabaugh, and R. M. Gray, "Optimal pruning with applications to tree-structured source coding and modeling," *IEEE Trans. Inform. Theory*, vol. 35, pp. 299-315, Mar. 1989.
- [4] F. Kossentini, M. Smith, and C. F. Barnes, "Large block RVQ with multi-path searching," *ISCAS*, pp. 2276-2279, 1992.
- [5] B. Ramamurthi and A. Gersho, "Classified vector quantization of images," *IEEE Trans. Commun.*, vol. 34, pp. 1105-1115, Nov. 1986.
- [6] J. W. Kim and S. U. Lee, "A transform domain classified vector quantizer for image coding," *IEEE Trans. Circuits and Systems for Video Technology*, vol. 2, pp. 3-14, Mar. 1992.
- [7] K. N. Ngan and H. C. Koh, "Predictive classified vector quantization," *IEEE Trans. Image Processing*, vol. 1, pp. 269-280, Jul. 1992.
- [8] H. Niemann and J. Wu, "Neural adaptive image coding," *IEEE Trans. Neural Networks*, pp. 615-627, Jul. 1993.
- [9] T. Kohonen, *Self-Organization and Associative Memory*, 3rd ed. Berlin, Heidelberg, Germany : Springer-Verlag, 1989.
- [10] D. Cohn, E. A. Riskin, and R. Ladner, "Theory and practice of vector quantizers trained on small training sets," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 16, pp. 54-65, Jan. 1994.
- [11] R. C. Kim and S. U. Lee, "Adaptive

entropy constrained predictive vector quantization of image with a classifier and a variable vector dimension scheme." SPIE, vol.1818, pp.466-475, 1992.

- [12] A. Gersho,"Optimal nonlinear interpolative vector quantization," *IEEE Trans. Comm.*, vol. 38, pp. 1285-1287, Sep. 1990.

저자 소개



金 永 根(正會員)

1981년 3월 ~ 1985년 2월 고려대학교 전기공학과 졸업(공학사). 1985년 3월 ~ 1988년 2월 한국과학기술원 전기 및 전자공학과(공학석사). 1988년 3월 ~ 1995년 2월 한국과학기술원 전기 및 전자공학과(공학박사). 1995년 3월 ~ 현재 삼성전자 통신개발실 연구원. 주관심분야는 영상처리, 멀티미디어 시스템 등



羅 鍾 範(正會員)

1971년 3월 ~ 1975년 2월 서울대학교 전자공학과 졸업(공학사). 1975년 3월 ~ 1977년 2월 한국과학기술원 전기 및 전자공학과(공학석사). 1979년 3월 ~ 1983년 2월 한국과학기술원 전기 및 전자공학과(공학박사). 1983년 7월 ~ 1987년 6월 미국 콜럼비아 대학교 방사선과 연구조교수. 1987년 7월 ~ 현재 한국과학기술원 전기 및 전자공학과 교수. 주관심분야는 영상처리, 영상시스템분야 등