

수정 퍼지 경쟁 학습 네트워크를 이용한 이미지 코딩 응용

이 범 로[†] · 정 진 현[†]

요 약

분류 벡터 양자화(classified vector quantization: CVQ)[2]의 부코드북을 설계함에 있어서, 경쟁 학습 네트워크(5)-(7)는 소속도의 이분법적 표현으로 상당한 소속도를 가지는 코드 벡터들이 학습 과정에 무시되는 경향을 가진다. 이를 개선하기 위해 제안된 퍼지 경쟁 학습 네트워크(8)는 각 클러스터가 연속적인 소속도를 가진다는 개념을 도입하여 이와 같은 문제들을 해결했다. 그러나 퍼지 경쟁 학습 네트워크를 CVQ에 적용할 경우, 각 부코드북의 크기를 시행착오로 결정해야 하는 문제점을 여전히 가지고 있으며, 이러한 문제점들의 개선을 위하여 본 논문에서는 수정 퍼지 경쟁 학습 네트워크(modified fuzzy competitive learning network)를 제안한다. 수정 퍼지 경쟁 학습 네트워크는 퍼지 학습 네트워크와는 달리, 각 부코드북의 사이즈를 학습 과정 중에 적응적으로 결정하도록 하였으며, 또한 경쟁 학습 네트워크가 가지는 이분법적 소속도를 연속적인 소속도로 확장하여, 학습 과정중에 나타날 수 있는 지역 최소점 도달을 억제하였다.

Application to the Image Coding by the Modified Fuzzy Competitive Learning Network

Bumro Lee[†] · Chinhyun Chung[†]

ABSTRACT

In designing a subcode book of the Classified Vector Quantization (CVQ), the Competitive Learning Network has a weakness to ignore some code vectors with considerable membership, because of their binary representation. Fuzzy Competitive Learning Network corrects such weakness with an adoption of the concept that each cluster has its continuous membership. But the algorithm must determine the size of subcode book by applying a trial and error procedure. In this paper, modified fuzzy competitive learning network, which has continuous membership extending binary membership, is proposed, as an algorithm applying to CVQ. The proposed algorithm yields an adaptive determination of the size of each subcode book according to the given sample vector in learning process, and prevents the designed subcode book from coming to a local minimum point by applying fuzzy concept to the competitive learning algorithm.

1. 서 론

방대한 데이터를 가지는 이미지를 저장 및 전송하고

자 할 경우, 한정된 저장 용량의 저장 매체나 한정된 대역을 가지는 통신 채널의 한계로 인하여, 저장 또는 전송에 많은 시간과 비용이 소요된다. 이러한 이유로 저장 또는 전송되는 이미지 데이터의 대부분은 코드화되어, 데이터의 크기를 최소화하게 된다. 벡터 양자화(vector quantization: VQ)기법은 입력되는 샘플 벡

[†] 정 회 원 : 광운대학교 제어계측공학과
논문접수 : 1998년 3월 6일, 심사완료 : 1998년 6월 8일

터를 이용하여, 최적화 된 코드를 생성시킨다(1)(4). 대부분의 벡터 양자화 기법에서는 입력되는 샘플 벡터를 적당한 알고리즘에 의한 비감독 학습(unsupervised learning)을 통해 서로 어느 정도의 독립성을 가지는 클러스터(cluster)를 형성하게 하고, 이러한 클러스터의 중심값(centroid value)으로 벡터들을 코드화 한다. 이러한 벡터 양자화를 통한 이미지 코딩은 높은 압축률을 가지며, 상대적으로 적은 데이터 왜곡을 가져오기 때문에 이미지 코딩에 많이 이용되고 있다. 그러나 벡터 양자화를 통해서 압축된 이미지는 인간의 지각력(human perception)에 특히 민감하게 반응하게 되는 경계(edge)부분의 정보를 상당히 손상시키는 단점을 가지고 있다. 특히 대각선 경계 부분에서는 계단 효과(staircase effect)라고 불리는 왜곡들이 나타나게 된다. 이러한 단점들을 극복하기 위해서 제안된 알고리즘이 분류 벡터 양자화 기법(classified vector quantization: CVQ)이다(2). 이 알고리즘은 주어진 샘플 벡터를 경계의 방향에 따라 8종류로 분류하고, 이렇게 나뉘어진 벡터들을 다시 경계의 위치에 따라서 세분하게 되는데, 코드에 의한 이미지 디코딩을 할 경우에도 이와 같은 분류 알고리즘이 적용된다. 이렇게 분류된 벡터들에 VQ알고리즘을 적용하여, 각각의 부코드북(subcode book)을 디자인하게 된다. 이와 같이 분류 알고리즘을 적용하여 부코드북을 디자인함으로써, 계단 모양의 왜곡을 제거하고 벡터 양자화의 높은 압축률은 그대로 유지할 수 있게 된다. 본 논문에서는 CVQ알고리즘을 구현함에 있어서 수정 퍼지 경쟁 학습 네트워크(modified fuzzy competitive learning network)를 벡터 양자화 코드 생성 알고리즘으로 제안한다. 경쟁 학습(competitive learning)이란 입력되는 샘플 벡터와 가장 적은 왜곡값을 가지는 클러스터의 중심값을, 그 클러스터에 속해진 벡터의 개수에 역수만큼의 비중으로, 코드 벡터의 방향으로 변화시키는 알고리즘이다(5)(7). 그러나 이 알고리즘은 클러스터에 대한 벡터들의 소속도(membership)를 이분법적으로 처리하게 되어 있어서, 한 코드 벡터에 있어서 최고 왜곡값을 가지지는 않지만 상당한 소속도를 가지는 클러스터에 대한 학습이 이루어지지 않는다는 단점을 가지고 있다. 본 논문에서 제안하는 수정 퍼지 경쟁 학습 네트워크는 샘플 벡터에 대한 각 클러스터의 소속도를 학습 규칙의 매개변수로 하여 샘플 벡터에 대한 각 클러스터의 학습이 승리 클러스터(winning cluster)에


국한하지 않고 모든 클러스터에 대해, 소속도에 비례하는 학습을 하게 된다. 일반적인 VQ에 비해 CVQ에서 부가되는 두 가지 문제점은 벡터의 분류 알고리즘과 부코드북의 크기를 결정하는 것인데, 본 논문에서는 기존의 CVQ에서 제안된 분류 알고리즘을 사용하였으며, 부코드북의 크기를 결정함에 있어서는 기존에 시행착오를 통한 방법과 달리 적합한 임계값을 설정하여, 각 클러스터의 최대 왜곡값을 제한하고, 어떤 샘플 벡터가 존재하는 모든 클러스터에 대해서 임계값을 초과하는 왜곡값을 가질 경우에는 그 벡터를 중심값으로 가지는 새로운 클러스터를 만드는 과정을 통해서, 학습 과정에서 각 부코드북의 크기를 결정하도록 하였다.

2. 이미지 코딩 알고리즘(image coding algorithms)

2.1 벡터 양자화의 개요

벡터 양자화는 일정한 기준에 의해 하나의 클러스터로 묶여진 다양한 벡터들을 하나의 코드로 나타냄으로써 데이터를 압축하는 기법이다. 크게 공간 영역(spatial domain)에서의 벡터 양자화와 벡터의 변환을 통하여 얻어진 변환 계수(transform coefficient)를 양자화하는 방식이 있다. 본 논문에서는 공간 영역에서의 벡터 양자화를 다룬다. 벡터 양자화 기법은 주로 이미지 데이터나 음성 데이터를 코드화 하는 데에 사용되었는데, 1980년에 제안된 LBG(Linde-Buzo-Gray)알고리즘을 비롯하여, 많은 알고리즘들이 제안되어 왔다(1)(4)(11). 이러한 알고리즘들은 대체적으로 비감독 학습을 통해서 입력되는 샘플 벡터들은 적당한 클러스터로 묶어 주고, 이렇게 형성된 클러스터의 무게 중심점을 잡아 그 클러스터의 코드 벡터로 삼는 것이 일반적이다. LBG 알고리즘의 경우에 샘플 벡터들을 초기 코드 벡터와의 왜곡이 가장 작은 클러스터로 대응시키고, 각 클러스터에 대응된 샘플 벡터들의 평균 벡터를 그 클러스터의 코드 벡터로 놓는데, 이러한 과정을 평균 왜곡의 변화율이 일정한 임계값에 이를 때까지 반복한다. 이때 코드 벡터 Y와 샘플 벡터 X간의 평균 왜곡은 식 (2-1)과 같이 나타내어진다.

$$D = \frac{1}{T} \sum_{t=1}^T \min_{i=1, \dots, N} \|x_t - y_i\|^2 \quad (2.1)$$



(그림 1) 벡터 양자화.
(Fig. 1) vector quantization.

(그림 1)에 나타난 바와 같이 일단 코드북의 디자인이 완료된 상태에서, 이미지를 전송할 경우, 같은 코드북을 수신 측과 송신 측에서 공유하게 되고, 하나의 벡터가 인가되면 코드북에서 인가된 벡터와 가장 작은 왜곡을 가지는 코드 벡터를 찾아 그 코드 벡터의 색인(index)을 통신 채널을 통해 전송하게 되고 수신 측에서는 수신된 색인을 지표로 코드 벡터를 찾아내어 데이터 전송을 완료하게 된다.

2.2 분류 벡터 양자화

앞서 언급된 것처럼 벡터 양자화를 통한 데이터 압축은 높은 압축률을 가지며, 경계 부분에서 상대적으로 큰 왜곡을 가진다는 문제점을 각 벡터를 사전에 분류하고, 분류된 벡터로 부코드북을 디자인하는 분류 벡터 양자화 기법을 도입함으로써 해결한다[2][3]. 벡터의 분류는 경계 강화(edge enhancement) 과정과 결정 계통(decision tree) 과정으로 나뉘어지는데, 경계 강화 과정에서는 주어진 벡터가 p^2 의 크기를 가질 때, 식 (2-2)과 식 (2-3)를 이용하여 각 벡터의 수평 기울기(horizontal gradient)와 수직 기울기(vertical gradient)를 측정한다.

$$d_h = \frac{2(x_{i,j} - x_{i,j+1})}{x_{i,j} + x_{i,j+1}} \quad (2-2)$$

$$d_v = \frac{2(x_{i,j} - x_{i+1,j})}{x_{i,j} + x_{i+1,j}} \quad (2-3)$$

식 (2-2)와 식 (2-3)에서 측정된 기울기는 절대 기울기가 아닌 두 원소 평균값으로 정규화 된 기울기이며, 인간의 지각력에는 절대 기울기보다는 이와 같은

정규화 된 기울기에 더욱 민감하다. [Pratt, 1978] 이렇게 구해진 정규화 된 기울기는 주어진 벡터의 함수로 표현되는 임계값을 기준으로 아래와 같이 3가지 요소로 분리되어, 경계 강화를 하게 된다. 식 (2-4)은 수평 경계에 대한 강화를 수행하고, 식 (2-5)는 수직 성분에 대한 경계 강화를 수행하게 된다. 강화된 경계는 행렬 G_h, G_v 에 1, 0, -1로 아래와 같이 나타낸다.

$$G_h(i, j) = \begin{cases} 1 & \text{if } d_h > T_e \\ -1 & \text{if } d_h < -T_e \\ 0 & \text{otherwise} \end{cases} \quad (2-4)$$

(i = 1, 2, ..., p and j = 1, 2, ..., p-1)

$$G_v(i, j) = \begin{cases} 1 & \text{if } d_v > T_e \\ -1 & \text{if } d_v < -T_e \\ 0 & \text{otherwise} \end{cases} \quad (2-5)$$

(i = 1, 2, ..., p-1 and j = 1, 2, ..., p)

식 (2-4)와 식 (2-5)에서 사용된 임계값은 벡터의 평균값 d_{av} 를 매개변수로 하는 식 (2-6)에서 구해진다.

$$T_e = \begin{cases} \frac{8.0}{d_{av}} & \text{if } d_{av} < 30.0 \\ 0.2 & \text{otherwise} \end{cases} \quad (2-6)$$

식 (2-4)와 식 (2-5)에서 구해진 행렬 G_h, G_v 에 나타나는 +1, -1은 벡터가 대응되는 위치에서 양, 혹은 음의 방향으로 경계를 포함하고 있음을 나타내고 여기서 양의 방향은 수평 성분의 경우, 왼쪽에서 오른쪽 방

향으로 기울기를 가지는 경우이며, 수직 성분의 경우에는 위쪽에서 아래쪽으로 기울기를 가지는 경우를 말한다. 0은 대응되는 위치에 경계가 없음을 나타내며, 음의 방향은 위와 반대의 경우를 말한다. 경계 강화 과정에서는 경계가 아닌 평면(shade)을 나타내는 요소를 가리는 과정도 포함이 되는데, 식 (2-7)과 같이 벡터의 평균값을 매개변수로 하는 또 하나의 임계값을 기준으로, 앞에서 구해진 정규화 된 기울기와의 비교함으로써, 평면에 해당되지 않는 요소의 수를 합산한다. 식 (2-8)은 이 경우 적용되는 임계값을 정의한다.

$$S_h \leftarrow S_h + 1 \text{ if } |d_h| > T_s, \quad i = 1, 2, \dots, p$$

$$j = 1, 2, \dots, p-1$$

$$S_v \leftarrow S_v + 1 \text{ if } |d_v| > T_s, \quad i = 1, 2, \dots, p-1$$

$$j = 1, 2, \dots, p \quad (2-7)$$

$$T_s = \begin{cases} 0.1 & \text{if } d_{av} < 30.0 \text{ or } d_{av} > 225.0 \\ 0.025 & \text{otherwise} \end{cases} \quad (2-8)$$

식 (2-7)과 (2-8)의 변수들 이외에, G_h 행렬이 가지는 +1의 개수를 나타내는 H_p 변수, -1의 개수를 나타내는 H_n 변수, G_v 행렬이 가지는 +1의 개수를 나타내는 V_p 변수, -1의 개수를 나타내는 V_n 변수 등이 있어서 결정 계통 과정에서 이용된다. 식(2-6)과 (2-8)에서 정의된 수치들은 벡터 원소의 값들이 0부터 255라는 가정 하에, 실험적으로 산출된 값들이다. 일단 경계 강화 과정을 마치게 되면, 얻어진 데이터를 이용하여, 벡터를 분류하는 결정 계통 과정에 들어가게 되는데, 첫 단

계로서 또 하나의 임계값을 설정하여 식 (2-9)을 이용하여 경계를 포함하지 않는 벡터를 분류한다.

$$S_h < J_s \text{ and } S_v < J_s$$

$$J_s = p-1 \quad (2-9)$$

경계를 포함하는 벡터를 분류할 때는, 양의 방향의 수평 성분의 경우와 음의 방향 수평 성분의 경우, 또 다른 임계값을 설정하여 식 (2-10)과 같이 분류를 한다.

$$V_p \geq J_c \text{ (positive direction)} \quad (a)$$

$$V_n \geq J_c \text{ (negative direction)} \quad (b)$$


$$J_c = p/2 \quad (c) \quad (2-10)$$

수직 성분을 가지는 벡터는 식 (2-11)과 같이 분류한다.

$$H_p \geq J_c \text{ (positive direction)} \quad (a)$$

$$H_n \geq J_c \text{ (negative direction)} \quad (b) \quad (2-11)$$

대각선 성분에 대해서는 식 (2-10)와 식 (2-11)의 조합으로 분류한다. 식 (2-9)와 식 (2-11)에서의 (a), (b)식을 동시에 만족하는 경우, 이 벡터는 혼합(mixed) 벡터로 분류하고 (2-9), (2-10), (2-11)식들 중 어느 한 식도 만족시키지 않는 벡터를 중간 범위(midrange) 벡터로 분류한다. 각 분류된 각 벡터들 내부의 경계의 위치는 행렬 G_h, G_v 에서 주어지는 데이터로써 판별한



(그림 2) 분류 벡터 양자화.
(Fig. 2) classified vector quantization.

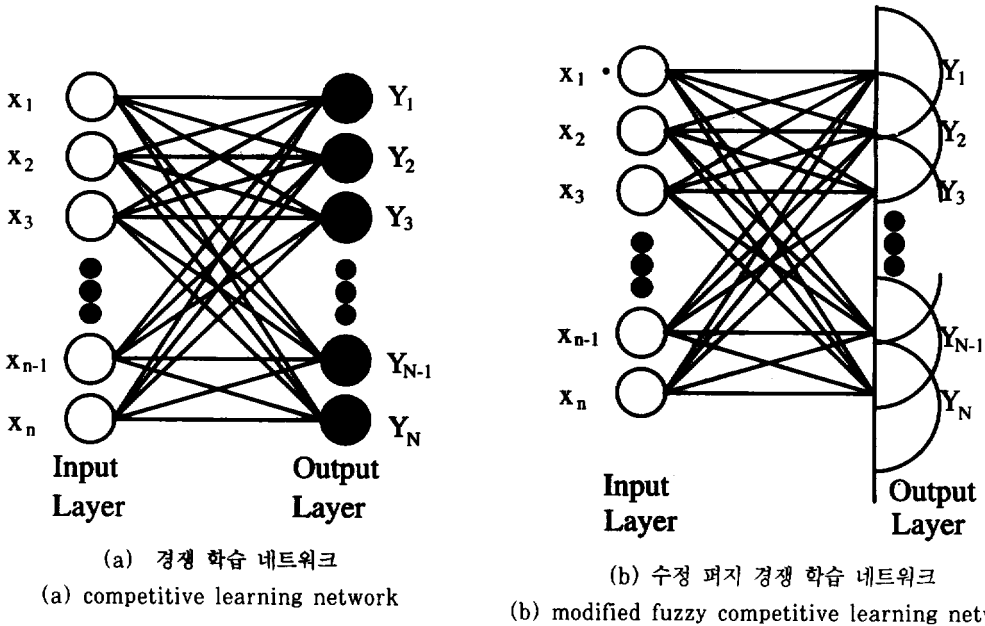
다. 이렇게 분류된 벡터들은 각각 다른 부코드북을 디자인하여, (그림 2)에서 보는 바와 같이 분류 벡터 양자화를 수행할 수 있게 된다.

2.3 퍼지 경쟁 학습 알고리즘

연속적으로 입력되는 벡터에 대한 비감독 학습 알고리즘에는 여러 가지가 있으며, 경쟁 학습 네트워크(competitive learning network)는 주어진 샘플 벡터와 가장 왜곡이 적은 클러스터의 중심값을, 그 클러스터에 속해진 벡터 개수의 역수만큼의 비중으로, 샘플 벡터의 방향으로 변화시키는 알고리즘이다(5)-(7). 경쟁 학습 네트워크는 클러스터에 대한 벡터들의 소속도를 단편적인 이분법적 논리로써 처리하게 되어 있어서, 한 샘플 벡터에 있어서 최고 왜곡값을 가지지는 않지만 상당한 소속도를 가지는 클러스터에 대한 학습이 이루어지지 않는다는 단점을 가지고 있다(8). 또한 극단적인 경우에 하나 이상의 클러스터가 하나의 입력 샘플에 대하여 같은 최대 소속도를 가지는 경우도 있을 수 있다. 이러한 문제점들을 해결하기 위해서 제안된 퍼지 경쟁 학습 네트워크(fuzzy competitive learning


network)는 학습과정 중, 코드 벡터들이 지역 최소점에 이르는 문제들을 해결하고 입력벡터에 대한 클러스터들의 소속도를 정확히 반영하게 하였다(8)-(10). 그러나 퍼지 경쟁 학습 네트워크 알고리즘을 CVQ에 응용할 경우 각 부코드북의 크기를 시행착오 방법으로 결정해야 하는 문제점이 여전히 남게 된다.

본 논문에서는 이러한 문제점을 개선하기 위해서 수정 퍼지 경쟁 학습 네트워크(modified fuzzy competitive learning network) 제안한다. (그림 3)에 나타난 바와 같이 제안된 알고리즘은 하나의 샘플 벡터의 소속도를 경쟁 학습 네트워크의 경우와 같이 이분법적으로 나누지 않고 모든 클러스터에 대한 소속도를 정규화된 형태로 표현하고, 이렇게 산출된 각 소속도 만큼의 비중으로 학습을 수행하기 때문에, 보다 최적화된 코드 벡터 생성이 가능하다. 또한 모든 클러스터에 대해서 최소 소속도 미만의 소속도를 가지는 샘플 벡터가 입력되었을 경우, 그 샘플 벡터를 코드 벡터로 하는 새로운 클러스터를 생성함으로써, 각 코드북의 크기를 학습과정 중에 적응적으로 결정하게 되어 별도로 코드북




(그림 3) 경쟁 학습 네트워크와 수정 퍼지 경쟁 학습 네트워크와의 비교.
(Fig. 3) Comparison between competitive learning network and modified fuzzy competitive learning network


의 크기를 고려해야 하는 과정이 불필요하게 된다. 이러한 경쟁 학습 네트워크와 수정 퍼지 경쟁 학습 네트워크 간의 학습 알고리즘의 비교를 (그림 4)와 (그림 5)에 각각 나타내었다.



(그림 4) 경쟁 학습
(Fig. 4) The competitive learning.



(a) 최소 소속도 이상의 소속도를 가진 클러스터가 존재할 경우
(a) When the clusters exist with membership over minimum membership



(b) 모든 클러스터가 최소 소속도 이하의 소속도를 가질 경우
(b) When all clusters have the membership below minimum membership

(그림 5) 수정 퍼지 경쟁 학습
(Fig. 5) The modified fuzzy competitive learning

다음은 수정 퍼지 경쟁 학습 알고리즘이다.

(a) 각 클러스터 내에 존재할 수 있는 최소 소속도 (T_{min})을 초기화하고, 코드 벡터 개수에 대한 카운터 *counter* 를 1로 한다.

(b) 첫 번째 샘플 벡터를 입력받아 첫 번째 클러스터의 코드 벡터로 초기화한다.

$$y_0 = x_0$$

(c) 무작위로 입력되는 샘플 벡터에 대해서 코드 벡터와 가장 큰 소속도를 가지는 코드 벡터를 찾아낸다. 이때 소속도는 왜곡값의 역수를 정규화하여 나타낸다.

$$m_i(t) = \|y_i(t) - x(t)\|^{-1} / \sum_{j=0}^N \|y_j(t) - x(t)\|^{-1}$$

$$m_k(t) = \max [m_i(t)]$$

(d) (c)에서 계산된 소속도가 T_{min} 보다 작은 경우에는 입력받은 샘플 벡터를 중심값으로 새로운 클러스터를 만들고, 클러스터의 수를 나타내는 *counter*를 1만큼 증가시킨다. T_{min} 보다 크거나 같을 경우에는 다음 규칙에 의해 코드 벡터를 갱신한다.

$$y_i(t+1) = y_i(t) + m_i(t)[x(t) - y_i(t)]/c_i(t)$$

$$i = 1, 2, \dots, N$$

$$c_i(t+1) = c_i(t) + m_i(t)$$

$$i = 1, 2, \dots, N$$

(e) $t = t + 1$ 로 놓고 (c)를 반복한다.

위의 알고리즘은 한 클러스터의 최소 소속도를 임계값으로 지정하고 입력된 샘플 벡터가 모든 코드 벡터에 대해서 임계값 미만의 소속도를 가지는 경우에는 새로운 클러스터를 만들어 넣으로써, 기존의 분류 벡터 양자화에서 시행착오를 통해서 정해지던 각 부코드북의 크기를 학습 단계에서 결정하도록 하였다. 실험 과정에서 T_{min} 은 모두 같은 값으로 설정하여, 학습 과정 중 입력되는 샘플 벡터들간의 Euclidean distance에 비례하여, 부코드북의 크기를 결정하도록 하였다. 실험 과정에서 사용된 T_{min} 을 결정하기 위해서는 어느 정도의 시행착오가 필요한 것은 사실이나 기존 알고리즘은 각 코드북의 크기를 모두 결정해야 하므로 N class로

코드북을 분류하였다면, N 개의 변수를 결정해야 하지만, 제안된 수정 퍼지 경쟁 학습 네트워크에서는 class의 수에 관계 없이 하나의 임계값만을 결정하면 된다는 점에서 기존 알고리즘이 개선되었다고 할 수 있다.

코드의 최적화 문제에 있어서, CVQ에서는 부코드북을 최적화 시킨다는 의미를 다음의 식을 만족한다는 의미로 해석한다.[2]


$$\frac{P_i D_i^*}{N_i^*} = \text{constant.} \quad (2-12)$$

위 식(2-12)에서 P_i 는 i class에 샘플 벡터가 속할 확률이고, D_i^* 는 optimize된 코드북의 평균 왜곡, N_i^* 는 optimize된 부코드북의 수이다. 본 논문에서는 평균 왜곡률이 큰 edge나 text부분에서는 가 함께 커짐으로 위 식을 근사적으로 만족하게 하였다. 코드 생성 과정에서의 각 코드들의 최적화 문제에 있어서 본 논문에서 채택한 퍼지 경쟁 학습 알고리즘에서는 각 코드들을 주어진 샘플 벡터의 소속도에 따르는 학습을 함으로써 단일 코드북 내에서의 최적화를 실현할 수 있도록 한다.[8]

3. 실험 결과


아래의 결과는 경쟁 학습 네트워크를 적용하여 코딩된 이미지와 수정 퍼지 경쟁 학습 네트워크를 통해 코딩된 이미지를 상호 비교한 것이다. 정확한 성능의 비교를 위해서 두 학습 네트워크에 인가되는 샘플 벡터는 동일한 개수의, 동일한 벡터를, 동일한 순서로 인가하였으며, 동일한 이미지 분류 루틴을 사용하였다. 샘플 벡터들은 다양한 이미지들 가운데 무작위로 추출된 31,460개의 벡터들로 구성되었으며, 학습 과정에서 설정된 코드북은 총 2843코드로 이루어진다. 따라서 코딩된 이미지들의 화소 당 비트 수(bit / pixel)는 0.717bpp로 정해진다.

이미지 코딩을 적용한 이미지는 (그림 6)에 나타낸의 크기를 가진 Lenna이미지이며, 외부이미지(sub-image)를 16차 벡터화 하여 사용하였다. (그림 7)은 경쟁 학습 알고리즘을 적용한 예로 전체적으로 보면 원래의 Lenna이미지와 거의 차이를 발견하기 힘들다.




(그림 6) Lenna의 원래 영상.
(Fig. 6) original Lenna image.

그러나 좀 더 주의 깊게 관찰하면, Lenna의 왼쪽 눈 언저리나, 모자 테두리의 끝부분 그리고 복잡한 구조를 가지는 머리카락 등에서 비교적 분명한 왜곡을 발견할 수 있다. 이러한 문제들은 앞서 지적한 바와 같이 학습 과정에서 이분법적인 소속도를 기준으로 샘플 벡터들을 처리하는 기존의 기법을 정규화된 연속적인 소속도의 개념으로 확장시킨 수정 퍼지 경쟁 학습 알고리즘의 도입으로 완화된다.



(그림 7) 경쟁 학습 네트워크를 통해 코딩된 Lenna 영상.
(Fig. 7) Lenna image coded by the competitive learning network.

(그림 8)은 수정 퍼지 경쟁 학습 네트워크를 적용한 예로서, (그림 7)에서 보여졌던 왜곡들이 감소했음을 알 수 있다. 이러한 지각적인 화질에서 뿐만 아니라, 실제로 각 화소의 MSE에 대한 평가에서 경쟁 학습 네트워크는 53.913의 MSE를 가지던 이미지가, 수정 퍼지 경쟁 학습 네트워크에서는 MSE가 42.172로 감소하였으며, 이미지의 화질 평가의 객관적인 지표로서 사용되는 PSNR수치를 비교하여 보면, 경쟁 학습 네트워크를 이용해 코딩된 이미지는 30.849dB의 수치를 보인 반면에, 수정 퍼지 경쟁 학습 네트워크를 이용해 코딩된 이미지는 31.915dB이라는 수치를 보였다. 따라서 경쟁 학습 네트워크에 대한 퍼지 개념의 적용은 벡터 양자화를 이용한 이미지 코딩에 있어서 더욱 향상된 성능을 보장해 준다고 추론할 수 있다.



(그림 8) 수정 퍼지 경쟁 학습 네트워크를 통해 코딩된 Lena 영상.
(Fig. 8) Lena image coded by the modified fuzzy competitive learning network.

(그림 9)와 (그림 10)은 두 학습 네트워크에 의해 코딩된 이미지와 원래의 Lena 이미지와의 MSE를 이미지에 나타내었다. (그림 9)와 (그림 10)은 원래 이미지와 코딩된 이미지의 MSE값을 0부터 255까지의 값에 대응한 결과이며, 따라서 이미지가 어두울수록 작은 에러값을 가짐을 나타낸다. (그림 9)와 (그림 10)에서 지역적으로 경쟁 학습 네트워크가 적은 에러를 가지는 부분도 일부 존재하기는 하지만, 전체적으로 보면 수정

퍼지 경쟁 학습 네트워크에 의해 코딩된 이미지가 상대적으로 작은 MSE값을 가짐을 알 수 있다. 보다 객관적인 성능 비교를 위해 두 이미지의 PSNR값과 MSE값을 <표 1>에 나타내었다. 이것은 연속적인 속속도의 채택을 통해 이분법의 속속도를 바탕으로 코드북을 생성하는 과정 중에 발생할 수 있는 지역 최소점 (Local Minimum Point) 도달 현상이 억제시켰고, 시행착오를 통해 만들어진 각 부코드북의 사이즈를 그 부코드북이 담당하는 코드의 주파수 범위에 기준하여 설정함으로써, 고주파성분이 상대적으로 큰 부코드북은 큰 사이즈가 할당되고 저주파 성분의 코드북은 상대적으로 작은 사이즈가 할당되게 되어 보다 최적화된 사이즈의 부코드북들이 생성된 결과이다.


<표 1> 경쟁 학습 네트워크와 수정 퍼지 경쟁 학습 네트워크와의 성능 비교

(Table 1) Performance comparison between the competitive learning network and the modified fuzzy competitive learning network


학습 네트워크	MSE 값	PSNR 값
경쟁학습 네트워크	53.913	30.849dB
수정 퍼지 경쟁 학습 네트워크	42.172	31.915dB



(그림 9) 경쟁 학습 네트워크에 의해 코딩된 Lena 영상의 에러 요소.
(Fig. 9) error component of Lena image coded by the competitive learning network



(그림 10) 수정 퍼지 경쟁 학습 네트워크에 의해 코딩된 Lenna 영상의 에러 요소.
 (Fig. 10) error component of Lenna image coded by the modified fuzzy competitive learning network.



(a) 얼굴 부분 확대
 (a) Magnification of face



(b) 머리털 부분 확대
 (b) Magnification of hair

(그림 11) 부분적으로 확대된 이미지의 비교.
 (Fig. 11) Comparison of magnified images.

(그림 11)은 원 이미지와 경쟁 학습 네트워크를 이용해 코딩된 이미지, 그리고 수정 퍼지 경쟁학습 네트워크로 코딩된 이미지를 부분 확대 비교한 그림이다. (a)는 얼굴의 입술 부분을 확대한 것이고, (b)는 머리털 부분을 확대한 그림으로, 첫 번째 그림이 원이미지,

두 번째, 세 번째 이미지가 각각 경쟁 학습 네트워크를 이용해 코딩된 이미지, 그리고 수정 퍼지 경쟁학습 네트워크로 코딩된 이미지로서 두 번째 이미지에 비해서 세 번째 이미지가 보다 원 이미지에 가깝다는 것을 알 수 있다.

4. 결 론

본 논문에서는 벡터 양자화 과정에서 퍼지 논리의 적용이 실제로 나타나는 시각적인 화질의 향상과 더불어 객관적인 평가에 있어서도 양자화 된 코드들이 더욱 최적화 된 형태임을 보였다. 이상의 결과로 인간의 추론이나 지각에 더욱 가까운 퍼지 논리는 이미지나 음성과 같이 인간의 지각과 직접적인 관련을 가지는 매체들을 처리하는데 유용하며, 이미지 처리를 비롯한 여러 신호 처리 분야에서의 기존의 알고리즘의 성능을 향상 시키는데 기여함을 알 수 있다. 추후 과제로는, 보다 우수한 화질을 유지하는 이미지 코딩을 위해서 벡터를 특정한 변환 계수로 만든 다음 벡터 양자화를 하고, 아울러 분류 벡터 양자화의 전처리(pre-processing)에 해당하는 벡터의 분류 알고리즘을 규칙 베이스(rule base)에 의한 퍼지 추론을 통해서 실현함으로써, 보다 향상된 이미지 코딩을 가능하리라 추정된다.

참 고 문 헌

- [1] Nasser M. Nasabadi, Robert A. King, "Image Coding Using Vector Quantization: A Review," *IEEE Trans. Commun.*, Vol. COM-36, No.8, pp.957-971, August 1988.
- [2] Bhaskar Ramamurthi, Allen Gersho, "Classified Vector Quantization of Images," *IEEE Trans. Commun.*, Vol.COM-34, No. 11, pp.1105-1115, November 1986.
- [3] Ferran Marques, C. C. Jay Kuo, "Classified Vector Quantization Using Fuzzy Theory," *Int. Conf. on Fuzzy Systems*, San Diego, pp.237-244, March 8-12 1992.
- [4] Yoseph Linde, Andres Buzo, Robert M. Gray, "Algorithm for Vector Quantizer Design," *IEEE Trans. Commun.*, Vol.COM-28, No.1, pp.84-95, January 1980.

[5] Stephen I. Gallant, "Neural Network Learning And Expert Systems," The MIT Press, 1993.

[6] Bart Kosko, "Neural Network For Signal Processing," Prentice-Hall, 1992.

[7] S. Y. Kung, "Digital Neural Networks," Prentice-Hall, 1993.

[8] C. C. Jou, "Fuzzy Clustering Using Fuzzy Competitive Learning Networks," *IEEE Int. Conf. on Neural Networks*, Vol.2, pp.II-714-II-719, 1992.

[9] 서영로, 정진현, "자기 학습 구조를 가진 퍼지 제어기의 응용," 한국통신학회 논문지 제19권 제6호, pp.1182-1189, 1994년.

[10] E. T. Seo and C. H. Chung, "Application of Self-Tuning Filter Based-on a Fuzzy Logic with MC68000," *ASCC*, Japan, 1994.

[11] Allen Gersho, Robert M. Gray, "Vector Quantization and Signal Compression," KAP, 1992.

[12] Rafal C. Gonzalez, Richard E. Woods, "Digital Image Processing," Addison Wesley, 1992.

이 범 로

1993년 광운대학교 제어계측공학과 졸업 (공학사)
 1995년 광운대학교 대학원 제어계측공학과 (공학석사)
 1995년~1996년 현대전자 S/W 연구소 연구원

1996년~1998년 현대정보기술 인터넷 사업본부 선임
 1998년~현재 LG 인터넷 시스템 개발팀 대리
 관심분야: 분산 멀티미디어, 영상 압축, 뉴로 퍼지 시스템, 인터넷 응용

정 진 현

1981년 연세대학교 전기공학과(공학사)
 1983년 연세대학교 대학원 전기공학과 (공학석사)
 1990년 Rensselaer Polytechnic Institute (Ph.D)

1991년~현재 광운대학교 제어계측공학과 부교수, 신기술연구소 연구원
 관심분야: fuzzy control, neural network, MPEG II, stochastic control, CIM