

## 분류된 학습률을 가진 고속 경쟁 학습

### (Fast Competitive Learning with Classified Learning Rates)

金昌旭\*, 趙成元\*\*, 李忠雄\*\*\*

(Chang Wook Kim, Seong Won Cho and Choong Woong Lee)

#### 要約

본 논문은 분류된 학습률을 이용한 고속 경쟁 학습에 대한 연구이다. 이 연구의 기본 개념은 각 출력 노우드의 연결강도 벡터에 분류된 학습률을 할당하는 것이다. 출력 노우드의 각 연결강도 벡터는 자기 자신의 학습률에 의하여 갱신된다. 각 학습률은 관련되는 출력 노우드가 경쟁에서 승리할 때에만 변화되며, 승리하지 못한 노우드들의 학습률은 변화되지 않는다. 영상 벡터 양자화에 대하여 실험한 결과는 제안한 방법이 기존 경쟁 학습 방법에 비하여 더 빠르게 학습되고 더 좋은 화질을 갖게 됨을 보였다.

#### Abstract

This paper deals with fast competitive learning using classified learning rates. The basic idea of the proposed method is to assign a classified learning rate to each weight vector. The weight vector associated with an output node is updated using its own learning rate. Each learning rate is changed only when its corresponding output node wins the competition, and the learning rates of the losing nodes are not changed. The experimental results obtained with image vector quantization show that the proposed method learns more rapidly and yields better quality than conventional competitive learning.

#### 1. 서론

\*正會員, 空軍士官學校 電子工學科

(Dept. of Elec. Eng., Air Force Academy)

\*\*正會員, 弘益大學校 電氣, 制御 工學科

(Dept. of Elec. and Control Eng., Hong Ik Univ.)

\*\*\*正會員, 서울大學校 電子工學科

(Dept. of Elec. Eng., Seoul Nat'l Univ.)

接受日字: 1993年 6月 4日

신경망(NN: Neural Networks)의 중요한 특성 중 하나는 학습능력이며, 신경망의 학습은 정보 처리 시스템의 목적에 맞게 노우드간의 연결강도(weight)를 조절하는 것이다.<sup>[1]</sup> 이러한 신경망의 학습 알고리즘은 크게 지도 학습(supervised learning)과 자율 학습(unsupervised learning)으로 구분된다. 지도

학습에서는 집단의 속성 및 패턴을 이미 알고 있는 훈련 데이터들로 학습한다. 자율 학습에서는 집단에 대한 사전 정보를 갖지 못한 훈련 데이터들로 학습한다. 지도 학습에서는 실제 출력을 이미 알고 있는 출력과 비교하여 연결강도를 조정하며, 자율 학습에서는 외부의 영향은 받지 않고 입력되는 훈련 데이터들에서 규칙성을 찾아 신경망 시스템 자체를 조직하여 나간다. 이러한 신경망의 자율 학습 방법 중에서 경쟁 학습 방법은 계산이 복잡하지 않기 때문에 빠른 학습이 가능하며 벡터 양자화 등에 이용되고 있다.<sup>[2,4]</sup> 그리고 경쟁 학습을 이용한 신경망의 학습 능력을 향상시키기 위한 여러 방법들이 제안되었다.<sup>[2,5-8]</sup> 학습에 있어서 학습률은 학습 속도 및 학습 결과에 매우 중요한 역할을 한다. 작은 학습률은 느리게 학습하며 큰 학습률은 안정된 학습 결과에 수렴 하지 못하고 좋지 않은 학습 결과 사이에서 발진을 하게 된다. 이와 같이 학습률에 의하여 학습 속도 및 학습 결과가 결정되며 학습 속도와 학습 결과는 서로 상반된 관계를 가지고 있다.<sup>[9,10]</sup> 일반 경쟁 학습에서는 현재 입력되는 데이터와 가장 근접한 연결강도 벡터를 가진 노우드가 경쟁에서 승리하며, 이 승리한 노우드의 연결강도 벡터가 비분류된 학습률(NCLR : Non-Classified Learning Rate)에 의해 갱신된다. 일반 경쟁 학습에서는 승리하는 노우드에 관계 없이 단지 시간에 따라 천천히 감소하는 비분류된 학습률이 사용되고 있다. 그러나 비분류된 학습률은 각 노우드의 연결강도 벡터가 학습에 의해 분리가 된 후에는 각 노우드의 특성에 따른 학습이 이루어지지 않아 빠른 학습 속도를 지속적으로 얻기 어려우며 따라서 좋은 학습결과도 얻기 어렵다.

본 논문에서는 이와같은 문제점을 해결하기 위하여 학습 속도 뿐만 아니라 학습 결과도 향상 시킬 수 있는 분류된 학습률(CLR : Classified Learning Rate)을 이용한 새로운 경쟁 학습 방법을 제안하였다. 제안한 방법은 각 노우드의 연결강도 벡터에 각각의 학습률을 지정하여 각 노우드가 경쟁에서 이길 경우 자기 고유의 분류된 학습률에 의해 연결강도 벡터가 갱신되도록 하는 것이다. 비분류된 학습률은 입력 벡터가 들어 올 때마다 변화되나 분류된 학습률들은 관련 노우드가 경쟁에서 이길 때에만 변화되고 이기지 못한 때에는 변화되지 않는다. 그러므로 제안한 분류된 학습률을 이용한 경쟁학습에서는 전체 입력 순서가 아닌 각 집단의 입력 순서에 의해 학습률이 결정되고 각 집단의 입력 샘플 크기에 따라 학습률이 변화되므로 비분류된 학습률을 이용한 경쟁 학습 보다 빨리 각 노우드의 연결강도 벡터를 각 노우드에

관련된 입력 벡터의 평균이 되도록 학습시킨다. 성능을 평가하기 위하여 기존 경쟁 학습 방법과 제안한 방법을 영상 벡터 양자화에 적용하여 실험한 결과 제안한 방법이 기존 경쟁 학습 방법에 비하여 학습 속도 및 학습 결과에 있어 매우 향상됨을 보였다.

본 논문의 구성은, II절에서 비분류된 학습률을 이용한 일반 경쟁 학습 및 코호넨의 자기조직화 형상지도(Kohonen's Self-Organizing Feature Maps) 학습에 대해 기술하였으며 III절에서 분류된 학습률을 가진 경쟁 학습의 방법을 제안 설명하였으며, IV절에서는 에너지 함수를 이용하여 이론적으로 해석하였다. 그리고 V절에서는 영상 데이터를 압축하는 벡터 양자화에 대하여 실험한 결과를 비교 분석하였으며 VI절에서는 결론을 기술하였다.

## II. 경쟁 학습

### 1. 일반 경쟁 학습

경쟁 학습 방법에는 여러가지가 있으나 대표적인 경쟁 학습 알고리즘은 다음과 같다.<sup>[11,12]</sup>

$$W_k(t+1) = W_k(t) + c(t)[X(t) - W_k(t)]$$

출력 노우드 k가 이길 경우 (1)

$$W_k(t+1) = W_k(t) \quad \text{출력 노우드 k가 질 경우 (2)}$$

여기서  $W_k(t+1)$ 는 갱신 조정한 후 출력 노우드 k의 연결강도 벡터를 나타내며,  $W_k(t)$ 는 갱신 조정 이전 출력 노우드 k의 연결강도 벡터를 나타낸다. 그리고  $X(t)$ 는 시각 t에서 입력되는 훈련 벡터를 나타내며,  $c(t)$ 는 시각 t에서 비분류된 학습률을 나타내며 보통 시간에 따라 천천히 감소하는 0과 1 사이의 스칼라 시간 함수이다. 각 훈련 벡터가 입력될 때마다 (3)식과 같이 각 출력 노우드의 연결강도 벡터와 입력되는 훈련 벡터 사이의 유클리디언 거리가 최소인 출력 노우드가 승리 노우드로 선택된다.

$$\sum_j (x_j(t) - w_{kj}(t))^2 = \min_k \left\{ \sum_j (x_j(t) - w_{kj}(t))^2 \right\} \quad (3)$$

$x_j(t)$ 와  $w_{kj}(t)$ 는  $X(t)$ 와  $W_k(t)$ 의 j번째 성분을 나타내며  $w_{kj}(t)$ 는 승리 노우드의 연결강도 벡터  $w_k(t)$ 의 j번째 성분을 나타낸다. 선택된 승리 노우드의 연결강도 벡터는 (1)식에 의해 갱신되며, 기타 연결강도 벡터는 (2)식과 같이 변화되지 않는다.

### 2. 코호넨의 자기조직화 형상지도 학습

코호넨의 자기조직화 형상지도 학습에서 입력벡터

와 가장 가까운 연결강도 벡터를 가진 출력 노우드가 출력 신호를 보낼 수 있는 유일한 승리 노우드가 되며, 이 노우드와 인접한 이웃 노우드들만이 제시된 입력 벡터에 대하여 학습이 허용된다.




그림 1.  $t_1 < t_2 < t_3$  일때 이웃 반경 의 크기  $N_c(t)$  의 예

Fig. 1. Example of topological neighborhood  $N_c(t)$ , where  $t_1 < t_2 < t_3$ .

승리 노우드의 이웃 반경( $N_c$ )은 그림 1과 같이 처음에는 매우 커 층내의 많은 노우드들이 포함되나, 훈련이 진행됨에 따라 이웃 반경은 점점 줄어들어 점점 적은 갯수의 노우드들이 학습을 하게되며, 최종적으로는 단지 승리 노우드만이 연결강도를 조정하는 학습을 하게된다. 승리 노우드를 결정하고 난 후에는 다음과 같은 코호넨의 학습 규칙에 따라 노우드의 연결강도를 조정한다.

$$W_k(t+1) = W_k(t) + c(t)\{X(t) - W_k(t)\} \quad k \in N_c(t) \text{ 경우 (4)}$$

$$W_k(t+1) = W_k(t) \quad k \notin N_c(t) \text{ 경우 (5)}$$

이와같은 학습은 모든 입력 벡터에 대하여 노우드들이 균등한 확률로 반응하도록 전역적 형상지도 구성을 가능하게 한다.<sup>[2,5,6,8]</sup>

### III. 분류된 학습률을 이용한 경쟁 학습

#### 1. 기본 개념

출력 노우드가 하나인 경쟁 학습 신경망에서 학습된 연결 강도 벡터는 (1)식을 이용하여 다음과 같이 표시될 수 있다.

$$W(t) = \{ c(1)[1 - c(2)][1 - c(3)...[1 - c(t-1)]\} X(1) \\ \vdots \\ + \{ c(t-2)[1 - c(t-1)]\} X(t-1) \\ + \{ c(t-1)\} X(t-1) \quad (6)$$

여기서  $X(t)$ 는 입력 벡터이고  $W(t)$ 는 연결강도 벡터이며  $c(t)$ 는 학습률이다. (6)식의  $c(t)$ 를 (7)식과 같이 하면 (6)식은 (8)식과 같이 된다.

$$c(t) = \frac{1}{t} \quad (7)$$

$$W(t) = [X(1) + X(2) + X(3) + \dots + X(t-1)] / (t-1) \quad (8)$$

(8)식의 의미는 출력 노우드가 하나인 경쟁 학습 신경망에서, (7)식과 같은 학습률을 사용하여 훈련 입력 데이터로 학습을 마치면 연결강도 벡터  $W(t)$ 는 항상 (8)식과 같은 입력 데이터의 평균값을 정확하게 학습하게 됨을 나타낸다. 출력 노우드가 하나인 경쟁 학습 신경망의 학습 방법은 지도 경쟁 학습에서는 그대로 적용될 수 있으며, 자율 경쟁 학습에서는 초기에 비분류된 학습률로 각 노우드의 연결강도 벡터를 1단계 분리한 후 분류된 학습률을 이용한 경쟁 학습으로 2단계 정밀 학습으로 확장될 수 있다.

#### 2. 학습 규칙

분류된 학습률을 이용한 경쟁 학습의 알고리즘은 다음과 같이 표현된다.<sup>[14]</sup>

$$W_k(t+1) = W_k(t) + C_k(t) [X(t) - W_k(t)]$$

출력 노우드 k가 이길 경우 (9)

$$W_k(t+1) = W_k(t) \quad \text{출력 노우드 k가 질 경우 (10)}$$

여기서  $C_k(t)$ 는 시각 t에서 출력 노우드 k의 연결강도 벡터 학습률이며 출력 노우드 k가 경쟁에서 이길 경우에만 변하게 된다. 각 노우드의 연결강도 벡터  $W_k$ 는 자신의 고유학습률  $C_k(t)$ 를 갖고 있으며, 훈련 벡터가 들어올 때마다 승리 노우드의 연결강도 벡터는 (3)식과 (9)식에 의하여 결정된다. 각 노우드의 연결강도 벡터는 다른 노우드의 연결강도 벡터 학습률과는 상관없이 자기 자신의 학습률로 갱신된다.

분류된 학습률을 가진 경쟁학습의 학습 규칙은 다음과 같다.

단계 1 : 크기가 (L, I)인 신경망을 구성한다. 여기서 L은 출력 노우드의 수로서 집단의 크기이며, I는 입력 노우드의 수로서 각 입력 벡터의 크기이다.

단계 2 : 입력 데이터 중에서 임의로 선택하여 각 노우드의 연결강도 벡터를 초기화한다.  $w_{kj}(0)$ 은 시각 0에서 초기화된 입력 노우드 j와 출력 노우드 k사이의 연결강도 값이다. 그리고 각 노우드의 승리 수를 0으로 초기화한다.

$$n_k(0)=0 \quad \text{모든 } k \text{에 대하여} \quad (11)$$

단계 3 : 새로운 훈련 입력 벡터  $X(t)$ 를 입력한다.  
 단계 4 : 입력 벡터와 각 노우드의 연결강도 벡터 사이의 거리를 (12)식과 같이 계산한다.

$$d_k = \sqrt{\sum_{j=0}^L (x_j(t) - w_{kj}(t))^2} \quad (12)$$

단계 5 : 최소 거리  $d_k$ 를 가진 출력 노우드를 선택하여 승리 노우드  $k^*$ 라고 한다.

$$d_{k^*} = \min \left\{ \sqrt{\sum_{j=0}^L (x_j(t) - w_{kj}(t))^2} \right\} \quad (13)$$

단계 6 : 최소 거리로 선택된 승리 노우드의 승리 수를 1 증가시킨다.

$$n_{k^*}(t+1) = n_{k^*}(t) + 1 \quad (14)$$

단계 7 : 승리 노우드의 연결강도를 다음식에 의해 갱신한다.

$$w_{kj}(t+1) = w_{kj}(t) + C_k(n_{k^*}(t+1))(x_j(t) - w_{kj}(t)) \quad (15)$$

패배 노우드의 연결강도는 변화시키지 않는다.

$$w_{kj}(t+1) = w_{kj}(t) \quad (16)$$

단계 8 : 단계 3으로 가서 반복한다.

#### IV. 에너지 함수 해석

학습 시각  $t$ 에서 경쟁 학습의 에너지 함수 값은 다음과 같다.<sup>[13]</sup>

$$E(t) = \frac{1}{2} \sum_k \sum_i |M_{ik}[X_i - W_k(t)]|^2 \quad (17)$$

여기서  $X_i$ 는 입력 벡터,  $N$ 은 입력 샘플의 수,  $W_k(t)$ 는 시각  $t$ 에서 출력노우드  $k$ 의 연결강도 벡터,  $L$ 은 출력 노우드의 수,  $M_{ik}$ 는 자격행렬 함수(membership matrix)로서 입력  $X_i$ 에 대하여 출력 노우드  $k$ 가 승리하였는지 혹은 패배하였는지를 나타낸다.

$$M_{ik} = \begin{cases} 1 & X_i \text{가 입력될때 출력 노우드 } k \text{가 이길 경우} \\ 0 & \text{기타} \end{cases} \quad (18)$$

(17)식을 미분하면 (19)식과 같으며 (20)식과 같은 조건에서 최소값이 된다.

$$\Delta E(t) = \sum_k \sum_i M_{ik}[X_i - W_k(t)]\Delta W_k(t) \quad (19)$$

$$\sum_i M_{ik}[X_i - W_k(t)] = 0 \quad (20)$$

(20)식의 좌측을 분리하여 (21)식과 (22)식으로 나타낼 수 있다.

$$\sum_i M_{ik}X_i = \sum_i X_{ik} \quad (21)$$

$$\sum_i M_{ik}W_k(t) = W_k(t) \sum_i M_{ik} = W_k(t)N_k \quad (22)$$

여기서  $X_{ik}$ 는 노우드  $k$ 가 승리하여 집단  $k$ 에 속하게 된 입력 샘플들이며  $N_k$ 는 집단  $k$ 에 속하게 된 입력 샘플들의 수이다. (21)식과 (22)식을 (20)식에 대입하여 정리하면 (23)식 처럼 나타낼 수 있다.

$$W_k(t) = \frac{\sum_i X_{ik}}{N_k} \quad (23)$$

(23)식은 (17)식의  $E(t)$ 가 최소가 되는 조건으로 노우드  $k$ 의 연결강도 벡터는 집단  $k$ 에 속하는 입력 샘플의 평균일 때 최소가 됨을 나타내고 있다.

비분류된 학습물을 이용한 출력 노우드  $k$ 의 연결강도 벡터는 (1)식을 이용하여 다음과 같이 표시될 수 있다.

$$W_{nk}(t) = C(n_k(t_k))X_k(t_k) + [1 - C(n_k(t_k))]C(n_k(t_k - 1))X_k(t_k - 1) + \dots + [1 - C(n_k(t_k))] [1 - C(n_k(t_k - 1))] \dots [1 - C(n_k(2))] C(n_k(1))X_k(1) \quad (24)$$

여기서  $t_k$ 는 전체 학습 시각  $t$ 까지 출력 노우드  $k$ 가 승리한 수로서  $k$  집단의 입력 순서이며,  $X_k(t_k)$ 는 출력 노우드  $k$ 의  $t_k$ 번째 승리한 입력 벡터이다.  $n_k(t_k)$ 는  $k$  집단의 입력 순서  $t_k$ 의 전체 입력 순서이며,  $C(n_k(t_k))$ 는 전체 입력 순서  $n_k(t_k)$ 에서의 비분류된 학습물로서 (25)식과 같은 형태로 나타낼 수 있으며 (24)식에 대입하면 (26)식과 같다.

$$C(n_k(t_k)) = \frac{b}{n_k(t_k) + a} \quad (25)$$

$$W_{nk}(t) = \frac{b}{n_k(t_k) + a} X_k(t_k) + \frac{n_k(t_k) + a - b}{n_k(t_k) + a} \frac{b}{n_k(t_k - 1) + a} X_k(t_k - 1) + \dots + \frac{n_k(t_k) + a - b}{n_k(t_k) + a} \frac{n_k(t_k - 1) + a - b}{n_k(t_k - 1) + a} \dots \frac{n_k(2) + a - b}{n_k(2) + a} \frac{b}{n_k(1) + a} X_k(1) \quad (26)$$

비분류된 학습물을 이용한 경쟁 학습으로 학습된 연결강도 벡터는 (26)식과 같이 각 집단에 입력되는 순서  $t_k$ 에 의해 결정되는 것이 아니고 전체 입력 순서

$n_k(t_k)$ 에 따라 결정된다.

분류된 학습률을 이용한 출력 노우드  $k$ 의 연결강도 벡터는 (9)식을 이용하여 다음과 같이 표시될 수 있다.

$$W_{ck}(t) = C_k(t_k)X_k(t_k) + [1 - C_k(t_k)]C_k(t_k - 1)X_k(t_k - 1) + \dots + [1 - C_k(t_k)][1 - C_k(t_k - 1)] \dots [1 - C_k(2)]C_k(1)X_k(1) \quad (27)$$

여기서  $C_k(t_k)$ 는  $k$  집단에서 집단 입력 순서  $t_k$ 일 때 분류된 학습률로서 (28)식과 같은 형태로 나타낼 수 있으며 (27)식에 대입하면 (29)식과 같다.

$$C_k[t_k] = \frac{d}{t_k + c} \quad (28)$$

$$W_{ck}(t) = \frac{d}{t_k + c} X_k(t_k) + \frac{t_k + c - d}{t_k + c} \frac{d}{t_k - 1 + c} X_k(t_k - 1) + \dots + \frac{t_k + c - d}{t_k + c} \frac{t_k - 1 + c - d}{t_k - 1 + c} \frac{t_k - 2 + c - d}{t_k - 2 + c} \dots \frac{2 + c - d}{2 + c} \frac{d}{1 + c} X_k(1) \quad (29)$$

각 집단이 분리되었을 경우 (28)식의 분류된 학습률은 (7)식과 같이  $c=0, d=1$ 로 할 수 있으며 (29)식에 대입하면 (30)식과 같이 된다.

$$W_{ck}(t) = \frac{X_k(t_k)}{t_k} + \frac{t_k - 1}{t_k} \frac{X_k(t_k - 1)}{t_k - 1} + \frac{t_k - 1}{t_k} \frac{t_k - 2}{t_k - 1} \frac{X_k(t_k - 2)}{t_k - 2} + \dots + \frac{t_k - 1}{t_k} \frac{t_k - 2}{t_k - 1} \frac{t_k - 3}{t_k - 2} \dots \frac{2}{3} \frac{1}{2} \frac{1}{1} X_k(1) = \frac{1}{t_k} (X_k(t_k) + X_k(t_k - 1) + X_k(t_k - 2) + \dots + X_k(2) + X_k(1)) \quad (30)$$

분류된 학습률을 이용한 경쟁 학습으로 학습된 연결강도 벡터는 (30)식과 같이 각 집단의 입력 벡터 합을 입력 샘플 크기  $t_k$ 로 나누어 입력 벡터의 평균값이 되므로 (23)식에 의하여 (17)식의 에너지 함수값은 최소가 된다. 그러나 비분류된 학습률을 이용한 경쟁 학습으로 학습된 연결강도 벡터는 (26)식과 같이 전체 입력 순서에 따라 결정되고 각 집단의 입력 샘플 크기가 고려되지 않으므로 각 집단의 평균 값에 도달하기 어려우며 지역 최소값에 도달하는데도 많은 학습 시간이 필요하게 된다. 연결강도 학습은 학습률과 입력 벡터가 상호 작용하므로 입력 벡터가 승리 노우드와 입력 순서의 어느 위치에서 작용하느냐에 따라 달라진다. 만일  $W_k$ 의 변화에 기여하는 입력 벡

터들이 전체 입력 순서의 뒷부분에 있다면 이 입력 벡터에 작용하는 비분류된 학습률들은 작을 것이며 이 입력 벡터에 대한 학습량이 작아 지역 최소값에 도달하는데 매우 많은 훈련이 필요하게 된다. 이와 같이 비분류된 학습률은 각 집단마다 고유 학습률이 없으므로 입력 벡터들의 학습률은 전체 입력 순서에 의해 영향 받는다. 그러나 분류된 학습률들은 각 집단마다 고유 학습률이 있으므로 각 집단에 속하는 입력 벡터들의 학습률은 전체 입력 순서의 영향을 받지 않게 되어 비분류된 학습률을 이용한 경쟁 학습 보다 빨리 각 노우드의 연결강도 벡터를 각 노우드에 소속된 입력 벡터들의 평균값에 도달하게 학습시킨다.

### V. 실험 결과 및 분석

본 논문에서 제안된 방법의 성능 평가를 위하여 영상을 압축하는 벡터 양자화에 대하여 실험하였으며, 그림 4(a) 및 그림 5(a)의 8-bit 밝기 값을 갖는  $256 \times 256$  크기의 Lena 영상 및 Cronkite 영상을 사용하였다. 입력 훈련벡터의 크기는 모두  $4 \times 4$ 로 하였으며, 코우드북의 크기는 256개로 하였다. 초기 코우드북 (초기 연결 강도) 값은 해당 영상에서 4 4 블록 영상을 불규칙적으로 256개를 선택하였다. 그리고 압축비를 나타내는 전송률(bits / pixel (bpp))은 다음과 같이 표시 된다.

$$\text{전송률} = \frac{\text{전송된 총 데이터의 수}}{\text{전송하는 영상의 총 화소수}} \quad (31)$$

본 실험에서, 단위 블록 영상에 대한 전송된 데이터의 수는 코우드북의 크기가 256개이므로 8이 되며, 전송하는 단위 블록 영상의 화소수는 블록의 크기가  $4 \times 4$  이므로 16이 되어 전송률은 0.5 bpp가 된다. 그리고 코우드북 크기에 해당되는 연결강도 벡터의 크기는  $w_{kj}$  에서  $j$ 의 크기는 16이며,  $k$ 의 크기는 256이다. 성능 평가를 위하여 MSE(Mean Square Error) 및 PSNR(Peak Signal to Noise Ratio)을 사용하였으며 다음과 같이 표시된다.

$$MSE = \frac{1}{(512)^2} \sum_{i=1}^{512} \sum_{j=1}^{512} (x_{ij} - \hat{x}_{ij})^2 \quad (32)$$

$$PSNR = 10 \log_{10} \frac{(255)^2}{MSE} \quad (\text{dB}) \quad (33)$$

여기서  $x_{ij}$ 는 원형 영상의 화소값이며,  $\hat{x}_{ij}$ 는 부호화한 영상의 화소값이다. 이 논문에서 사용한 비분류된 학습률 및 분류된 학습률은 다음과 같다.

$$C(t) = \frac{A}{t + A_2} \quad : \text{NCLR} \quad (34)$$

$$C_k(t) = \frac{A_1}{n_k(t) + A_2} \quad : \text{CLR} \quad (35)$$

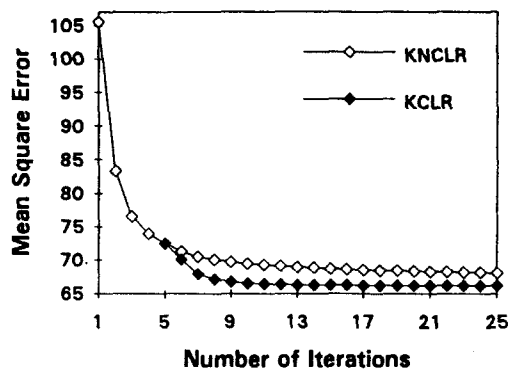

$A_1, A_2$ 는 상수이고,  $t$ 는 입력되는 시간이며,  $n_k(t)$ 는 출력 노우드  $k$ 의 승리 회수이다.  $C(t)$ 와  $C_k(t)$ 는 0과 1사이를 취하므로  $A_1$ 보다  $A_2$ 가 크다. 그리고  $C(t)$ 는  $C_k(t)$ 보다 더 많은 샘플을 입력하므로  $C(t)$ 는  $C_k(t)$ 보다 더 천천히 감소된다. 제안한 학습 방법은 비분류된 학습률로 1단계 학습하여 연결강도 벡터 값이 다른 노우드의 연결강도 벡터와 분리되게 학습한 후, 각 노우드의 연결강도 벡터들이 분류된 학습률을 이용한 학습으로 분리된 입력 벡터 집단들의

중심이 되게 정밀학습이 되도록 하였다. 그리고 비분류된 학습률에서 분류된 학습률로의 전환은 앞 회 (iteration) 연결 강도 벡터와의 변화량이 50% 미만

표 1. 사용 학습들의 계수

Table 1. Coefficients of used Learning Rates.

영 상	사 학 습 용 률	경쟁 학습		코호넨 자기조직화 형상지도 학습	
		$A_1$	$A_2$	$A_1$	$A_2$
Lena	미분류된 학습률	3410	5500	2550	7500
	분류된 학습률	3,448	3,586	3,030	5,454
Cronkite	미분류된 학습률	4020	6700	2824	8200
	분류된 학습률	3,571	3,500	3,571	5,714


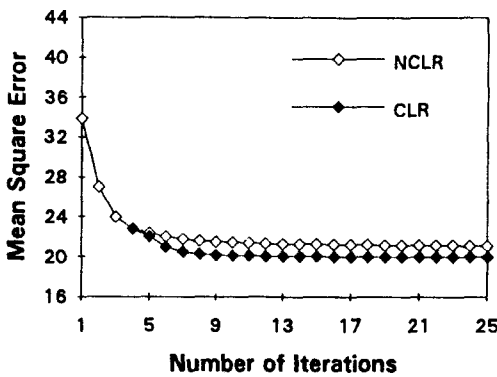


(a)The competitive learning network

(b)The Kohonen self-organizing feature map

그림 2. MSE 비교 (Lena 영상)

Fig. 2. MSE Comparison. (Lena Image)



(a)The competitive learning network

(b)The Kohonen self-organizing feature map

그림 3. MSE 비교 (Cronkite 영상)

Fig. 3. MSE Comparison. (Cronkite Image)

이 되어 집단 분리가 이루어지면 실시하였다. 실험에서 좋은 결과를 낸 학습률들의 계수는 영상 및 학습 방법에 따라 약간씩 달랐으며 표 1과 같다.

그림 2는 Lena 영상을 경쟁 학습 신경망에서 비분류된 학습률을 이용한 학습 방법(NCLR)과 분류된 학습률을 이용한 학습 방법(CLR) 그리고 코호넨 자기조직화 형상지도 신경망에서 비분류된 학습률을 이용한 학습 방법(KNCLR)과 분류된 학습률을 이용한 학습 방법(KCLR)으로 각각 얻은 부호화 된 영상의 MSE를 나타내고 있다. 그리고 그림 3은 Cronkite 영상을 그림 2와 같은 방법으로 각각 얻은 부호화 된 영상의 MSE를 나타내고 있다. 그림 2(a)에서 3회까지 비분류된 학습률로 학습한 후 8회까지 제한한 분류된 학습률을 이용

하여 학습하였을 경우 MSE는 69.0 이나 비분류된 학습률만으로 25회 학습하였을 경우에는 70.09이며 300회 학습을 하여도 69.52로 결국 이 값에 도달하지 못하였다. 결과적으로 그림 2와 3은 일반 경쟁 학습 및 코호넨 자기조직화 형상지도 학습에서 제한한 분류된 학습률을 이용한 방법이 비분류된 학습률을 이용한 방법에 비하여 학습 속도 및 학습 결과가 향상됨을 보이고 있다. 그림 4(a)는 256×256 크기의 8bit 원형 Lena 영상이며, 그림 4(b)는 256×256 크기의 8 bit 원형 Cronkite 영상이다. 그림 5(a), 그림 5(b), 그림 5(c) 및 그림 5(d)는 그림 4(a)를 NCLR, CLR, KNCLR 및 KCLR 학습 방법으로 각각 부호화한 영상(0.5 bpp)



(a)Lena Image (b)Cronkite Image

그림 4. 원형 영상  
Fig. 4. Original Image.



(a)NCLR (b)CLR



(c)KNCLR (d)KCLR

그림 5. 부호화된 Lena 영상  
Fig. 5. Encoded Lena Image.



(a)NCLR (b)CLR



(c)KNCLR (d)KCLR

그림 6. 부호화된 Cronkite 영상  
Fig. 6. Encoded Cronkite Image.

표 2. 전송률 0.5 bpp인 경우의 PSNR [dB] 비교

Table 2. PSNR[dB] Comparison at the bit rate of 0.5 bpp.

영 상	사 용 학 습 률	반 복 회 수					
		7 회	9 회	12 회	15 회	20 회	25 회
Lena	NCLR	29.489	29.569	29.612	29.644	29.664	29.674
	CLR	29.705	29.761	29.788	29.796	29.803	29.807
	KNCLR	29.650	29.695	29.736	29.759	29.784	29.797
	KCLR	29.812	29.884	29.910	29.917	29.921	29.923
Cronkite	NCLR	34.755	34.810	34.849	34.868	34.885	34.893
	CLR	35.022	35.091	35.119	35.127	35.131	35.133
	KNCLR	35.177	35.232	35.278	35.300	35.327	35.341
	KCLR	35.195	35.513	35.589	35.582	35.589	35.592

이고, 그림 6(a), 그림 6(b), 그림 6(c) 및 그림 6(d)는 그림 4(b)를 NCLR, CLR, KNCLR 및 KCLR 학습 방법으로 각각 부호화한 영상(0.5 bpp)이다.

표 2에는 일반 경쟁 학습 신경망과 코호넨 자기조직화 형상지도에 비분류된 학습률 및 제안된 분류된 학습률을 이용한 방법의 PSNR을 비교하여 나타내었다.

Ⅵ. 결 론

본 논문에서는 학습 속도 및 학습 결과를 향상시킬 수 있는 분류된 학습률을 가진 경쟁 학습 방법을 제안하였다. 제안한 방법은 각 출력 노우드의 연결강도 벡터에 각각의 분류된 학습률이 할당되어 출력 노우드가 경쟁에서 이길 경우 관련 출력 노우드의 연결강도 벡터는 자기 고유의 학습률에 의하여 갱신된다. 각 출력 노우드의 연결강도 벡터 학습률은 관련 출력 노우드가 이길 때에만 변화되고 이기지 못한 때에는 변화되지 않는다. 그러므로 제안한 분류된 학습률을 이용한 경쟁학습에서는 전체 입력 순서가 아닌 집단 입력 순서에 의해 학습률이 결정되므로 전체 입력 순서의 영향이 줄어들게 되고 각 집단의 입력 샘플 크기에 따라 학습률이 변화되므로 비분류된 학습률을 이용한 경쟁 학습 보다 빨리 각 노우드의 연결강도 벡터를 각 노우드에 관련된 입력 벡터의 평균이 되도록 학습시킨다. 제안한 방법을 일반 경쟁 학습 및 코호넨의 자기조직화 형상지도 학습에 이용하여 영상 압축하는 벡터 양자화에 대하여 실험한 결과, 제안한 방법이 비분류된 학습률을 이용한 방법에 비하여 학습속도가 빨라지고 학습 결과도 향상됨을 확인하였다.

參 考 文 獻

[1] Philip D. Wasserman, *Neural Computing*. Van Nostrand Reinhold, New York, 1989.

[2] S. C. Ahalt, A. K. Krishnamurthy, P. Chen, and D. E. Melton, "Competitive learning algorithms for vector quantization." *Neural Networks*, Vol. 3, pp. 277-290, 1990.

[3] Nasser M. Nasrabadi and Yushu Feng, "Vector quantization of images based upon the Kohonen self-organizing feature maps," *IEEE Inter. Conf. on Neural Networks*, pp. 101-108, July 1988.

[4] J. D. Mc Auliffe, L. E. Atlas and C.

Rivera, "A comparison of the LBG algorithm and Kohonen neural network paradigm for image vector quantization." *International conference on acoustics, speech, and signal processing*, vol. 4, pp. 2293-2296, April, 1990.

[5] T. Kohonen, *Self-Organization and Associative Memory*, 2nd ed., Springer-Verlag, New York, 1988.

[6] T. Kohonen, "The self-organizing map." *Proceedings of the IEEE*, vol. 78, No. 9, pp. 1464-1480, SEP, 1990.

[7] B. Kosko, *Neural Networks for Signal Processing*, Prentice-Hall, Inc., New Jersey, 1992.

[8] D. DeSieno, "Adding a conscience to competitive learning," *Proc. IEEE International Conference on Neural Networks(ICNN-88*, San Diego, California), pp. 1117-1124, 1988.

[9] S. M. Weiss and C. A. Kuikowski, *Computer Systems That Learn*, Morgan Kaufmann Publishers, Inc., California, 1991.

[10] Marilyn McCord Nelson and W.T. Illingworth, *A Practical Guide to Neural Nets*, Addison-Wesley, Massachusetts, 1991.

[11] J. Hertz, A. Krogh and R. G. Palmer, *Introduction to The Theory of Neural Computation*, Addison-Wesley Publishing Company, California, 1991.

[12] J. M. Zurada, *Introduction to Artificial Neural Systems*, West Publishing Company, MN, 1992.

[13] H. Ritter and K. Schulten, "Kohonen's self-organizing maps: Exploring their computational capabilities." *Proc. IEEE International Conference on Neural Networks (ICNN-88*, San Diego, California), pp. 1109-1116, 1988.

[14] Chang Wook Kim, O.K. Ersoy, Seongwon Cho and Choong Woong Lee, "Competitive Learning with Multiple Learning Rates," *Proceedings of Artificial Neural Networks in Engineering*, St. Louis, Missouri, Nov. 1992.



## 著者紹介



金昌旭(正會員)

1950年 12月 9日生. 1973年 3月 공군사관학교 졸업(이학사). 1976年 2月 서울대학교 전자공학과 졸업(공학사). 1981年 2月 서울대학교 대학원 전자공학과 졸업(공학석사). 1989年 2月 서울대학교 대학원 전자공학과 박사과정 수료. 1991年 ~ 1992年 미국 퍼듀대 전기과 방문교수. 현재 공군사관학교 전자공학과 조교수. 주관심 분야는 신경회로망, 영상처리 및 패턴인식 등임.

趙成元(正會員) 第 31卷 第 9號 參照

현재 홍익대학교 전기. 제어공학과 조교수

李忠雄(正會員) 第 29卷 第 8號 參照

현재 서울대학교 전자공학과 교수