

論文2001-38CI-5-3

# Stochastic Relaxation 방법을 이용한 온라인 벡터 양자화기 설계

## (On-line Vector Quantizer Design Using Stochastic Relaxation)

宋 權 培 \* , 李 幸 世 \*\*

(Geun-Bae Song and haing-Sei Lee)

### 요 약

본 논문은 온라인 벡터 양자화기 설계에 stochastic relaxation (SR) 개념을 응용함으로써 SR 방법에 기초한 새로운 온라인 학습 알고리즘을 제안한다. 이는 전통적인 Kohonen 학습법 (KLA)이 안고 있는 극소점(local minimum)으로의 수렴 문제를 개선시켜준다. SR 방법의 응용은 simulated annealing (SA) 개념을 사용하느냐 안 하느냐에 따라 둘로 나눌 수 있는데, 이를 구분하기 위해 SA 개념을 이용하는 SR 알고리즘을 OLVQ-SA로, SA 개념을 이용하지 않는 알고리즘을 OLVQ-SR로 부르기로 한다. 제안된 방법들은 KLA와 결합되어 있으며 KLA의 특성을 보존하도록 설계되었다. 이는 제안된 방법들의 수렴의 속도 및 안정성을 향상시켜준다. 제안된 방법의 우수성을 입증하기 위하여 Gauss-Markov 신호원과 음성 및 영상 자료에 대한 벡터양자화 실험을 하였으며 실험결과를 통하여 제안된 방법이 KLA 보다 일관되게 우수한 코드북을 생성함을 보인다.

### Abstract

This paper proposes new design algorithms based on stochastic relaxation (SR) for an on-line vector quantizer (VQ) design. These proposed SR methods solve the local entrapment problems of the conventional Kohonen learning algorithm (KLA). These SR methods cover two different types depending upon the use of simulated annealing (SA) : the one that uses SA is called the OLVQ-SA and the other the OLVQ-SR. These methods are combined with the KLA and therefore preserve the its convergence properties. Experimental results for Gauss-Markov sources, real speech and image demonstrate that the proposed algorithms can consistently provide better codebooks than the KLA.

### I. 서 론

\* 正會員, 亞洲大學校 認知工學實驗室

(Department of Electronics Engineering, Graduate School, Ajou University)

\*\* 正會員, 亞洲大學校 電子工學部

(Department of Electronics Engineering, Ajou University)

接受日字:2000年10月2日, 수정완료일:2001年6月13日

Kohonen 학습법(Kohonen learning algorithm : KLA)[1]은 신경망 학습을 위해 Kohonen에 의해서 제안된 일종의 자율학습 클러스터링 알고리즘이다. KLA는 신호처리의 관점에서 보면, 비 볼록(nonconvex) 형태의 목적함수에 적용된 최소 평균 자승(least mean square : LMS) 알고리즘<sup>[2]</sup>으로 볼 수 있다<sup>[1], [3]</sup>. 따라서

KLA는 강하법(descend algorithm) 계열의 알고리즘들이 본질적으로 안고 있는 극소점(local minimum)으로 수렴하는 문제를 가지고 있다.

KLA는 벡터 양자화기 설계를 위해서도 사용되었다<sup>[4]-[6]</sup>. KLA는 학습벡터가 하나씩 인가될 때마다 코드북을 수정해나가는 온라인 양자화기 설계 알고리즘이다. 여기서 처리된 학습자료는 원칙적으로 저장되지 않고 버려지며 계속해서 새로운 자료를 받아들여 학습을 진행해 나간다. 이와 같은 온라인 알고리즘은 기준으로 하는 목적함수를 계산하기 어렵거나 목적함수가 잡음에 의해 왜곡되어 있는 환경에서 사용된다. 또한 일괄처리(batch) 알고리즘에 비해 자료의 통계가 변해갈 경우 이를 실시간으로 코드북 설계에 반영할 수 있다는 장점이 있다. 일괄처리 방식의 대표적인 알고리즘으로 일반화된 Lloyd 방법(GLA)<sup>[7]</sup>이 있다. 수렴 특성에 있어서는 GLA 보다 KLA 혹은 KLA 형태의 알고리즘이 약간 더 우수한 코드북을 생성하는 것으로 알려져 있다<sup>[4],[8]</sup>. 그러나 이는 약간의 개선이며 GLA와 KLA 모두 강하법의 범주에 속하는 알고리즘으로 복잡한 양자화 문제에 대해 최소점(global minimum)이 아닌 극소점으로 수렴하는 문제를 안고 있다.

극소점 수렴 문제는 모의 담금질(simulated annealing : SA)<sup>[9]-[11]</sup>방법 혹은 보다 일반적인 개념으로서 통계적 이완법(stochastic relaxation : SR)<sup>[12]-[14]</sup>방법에 의해 해결될 수 있다. 특히 SA는 현재까지 극소점에 빠지지 않고 최소점(global minimum)으로 수렴하면서, 해의 수렴이 (통계적으로) 보장되는 유일한 방법이라 할 수 있다<sup>[9], [12]</sup>. 이러한 방법들의 공통점은 시스템 파라미터에 잡음을 추가하여 잡음의 강도(즉 분산)를 학습의 초기에는 큰 값에서 학습이 진행됨에 따라 서서히 줄여나간다. 이렇게 함으로써 학습은 랜덤탐색(random search)에서 점차로 직접탐색(direct search)으로 바뀌어 가며 따라서 학습의 초기에 극소점에 갇히게 되는 현상을 줄일 수 있다.

본 논문은 온라인 벡터 양자화기 설계에 있어서 KLA의 극소점 수렴문제를 극복하기 위해 SR 개념을 도입한다. SR 방법의 응용은 SA 개념을 사용하느냐 안 하느냐에 따라 다시 둘로 나뉜다. 이를 구분하기 위하여 본 논문은 SA개념을 사용하는 알고리즘은 “모의 담금질법을 이용한 온라인 벡터 양자화기 설계 알고리즘”(on-line vector quantizer design algorithm with simulated annealing : OLVQ-SA)로, 사용하지 않는 알




그림 1. 단층 신경망

Fig. 1.D Single-layered neural network.

고리즘은 “통계적 이완법을 이용한 온라인 벡터 양자화기 설계 알고리즘”(on-line vector quantizer design algorithm with stochastic relaxation : OLVQ-SR)로 부르기로 한다. 제안된 방법들은 KLA와 결합되어 있으며 따라서 KLA의 특성을 보존하도록 설계되었다. 이는 제안된 방법들의 수렴 속도 및 안정성을 개선시켜준다. 제안된 방법의 성능을 평가하기 위해 Gauss-Markov 신호원과 음성 및 영상신호에 대한 벡터 양자화 실험을 하였으며 기존의 KLA와 비교평가를 통하여 제안된 방법의 우수성을 보인다.

## II. Kohonen 학습법, 모의 담금질, 통계적 이완법의 기본 개념

### 1. KLA의 기본개념

KLA는 신경망의 자기 조직화 학습을 위해 제안되었다<sup>[1]</sup>. 보통 자기조직화사상(self-organizing map : SOM) 알고리즘이라 하면 복수 승자 방식의 KLA를 일컫는다. 즉 SOM은 승자 출력 뉴런 뿐 아니라 그 뉴런으로부터 공간적으로 일정 거리 안에 드는 이웃뉴런에게까지 학습의 기회를 준다. 이렇게 함으로써 학습과정을 통해 인접한 뉴런들이 서로 닮게 되는 결과를 가져온다. 이는 고차원 입력벡터의 복잡하고 비선형적인 관계를 저차원의 단순하고 기하학적인 관계로 보존하여 표현하여 줄으로써 고차원 자료를 시각화(visu-alization)하고 정보를 함축(abstract)하는 효과를 가져올 수 있다<sup>[1]</sup>.

SOM은 또한 벡터 양자화기 설계를 위해서도 사용되었다<sup>[4]-[6]</sup>. 그림 1은 벡터 양자화기로 이용될 수 있는 단층 신경망 구조를 나타낸 것이다. 그림에서 가중치벡터  $W_i = [w_{i1}, \dots, w_{iN}]'$ 는  $M$  개의 코드벡터 중  $i$  번째 코드벡터에, 뉴런 출력  $y_1, \dots, y_M$ 은 코드벡터

인덱스에 대응된다. 벡터 양자화의 관점에서 보면 복수 승자 방식은 하나의 휴리스틱이 될 수 있다. 즉, 일반적으로 입력벡터는 벡터 공간에서 특정 지역에 편중되어 분포되어 있다. 따라서 균일 분포의 랜덤 값으로 코드 벡터들을 초기화시키는 것은 그리 좋은 방법이 아니다. 학습 초기에 승자뿐만 아니라 넓은 범위의 이웃 뉴런들에게까지 학습기회를 주는 것은 초기 코드 벡터들을 입력 벡터의 분포 지역으로 이동시켜줄 것이다. 그 뒤 학습이 진행됨에 따라 이웃뉴런의 범위를 줄여나가면 각 뉴런에 의해 보다 세밀한 클러스터링을 할 수 있을 것이다. 그러나 이러한 전략의 효과는 불분명하며 일관되지 않은 결과를 가져오는 것으로 알려져 있다<sup>[9], [15]</sup>. 이 문제와 관련한 다른 휴리스틱들은<sup>[16], [17]</sup> 등을 참조할 수 있다. 본 논문에서는 문제를 간단히 하기 위해 단일 승자 방식의 SOM 알고리즘에 대해서만 논의하기로 하며 이를 간단히 'KLA'라 부르기로 한다.

본 논문에서 KLA는 벡터 양자화 문제에 사용된다. Euclid 거리측도  $d$ 의 관점에서,  $t$  시점에서 랜덤벡터  $x(t)$ 에 가장 가까운 가중치벡터(즉, 코드벡터)를  $W_c(t)$ 라 하자. 여기서  $c$ 는 승자뉴런을 가리키며 (1)에 의해 결정된다.

$$c = \arg \min_i d(x(t), W_i(t)) \quad (1)$$

양자화기 설계의 궁극 목적은 (2)로 정의되는 평균양자화오차를 최소로 하는 코드북  $W = \{W_i\}_{i=1}^M$ 을 탐색하는 것이다.

$$D(t) \equiv E[d(x(t), W_c(t))^2] \quad (2)$$

여기서  $E[\cdot]$ 는 평균연산을 나타낸다. 만약 랜덤벡터  $x(t)$ 가 정상신호(stationary)라 하면 시간변수  $t$ 는 생략될 수 있다. (2)의  $E[\cdot]$ 를 계산하기 위해서는  $x(t)$ 의 확률밀도함수  $p(x(t))$ 를 알아야 한다. 일반적으로 이는 사전에 알려져 있지 않다. 그리고 설령 알려져 있다하더라도 복잡한 경우가 대부분 임으로 (2)에 직접 gradient descent 방법을 적용하기는 어렵고, (2)의 최적 해를 닫힌 형태로 풀어내기에는 더욱 어렵다. 따라서 현실적으로 반복적 근사법으로 준최적의 해를 탐색하게 된다. KLA는 통계적 경도강하법(stochastic gradient descent : SGD)<sup>[2]</sup>라 불리는 반복적 근사법이다. 이 경우에 기준이 되는 오차함수는 (2)의 형태가 아닌 (3)의 형태의 순간 오차함수이다.

$$\hat{D}(t) \equiv d(x(t), W_c(t))^2 = \|x(t) - W_c(t)\|^2 \quad (3)$$

여기서  $\hat{D}(t)$ 는  $t$  시점에서의 순간 오차를 나타낸다. (3)을 최소화하기 위한 근사적 최적화 알고리즘은 다음과 같다.

$$W_c(t+1) = W_c(t) - (1/2)\alpha(t) \frac{\partial \hat{D}(t)}{\partial W_c(t)} \quad (4)$$

여기서  $\alpha(t)$ 는 학습률을 나타내는 0과 1 사이의 작은 스칼라 함수이다. (4)의 오른쪽의 편미분을 풀면 (5), (6)과 같은 잘 알려진 KLA를 얻게된다.

$$\begin{aligned} W_c(t+1) &= W_c(t) + \Delta W_c(t) \\ &= W_c(t) + \alpha(t)[x(t) - W_c(t)], \quad (5) \\ (0 < \alpha(t) < 1) \end{aligned}$$

$$W_i(t+1) = W_i(t), \quad \text{그 밖의 } i \neq c. \quad (6)$$

(5)와 (6)의 학습법을 관찰하여 보면, 승자뉴런의 가중치벡터는 입력벡터 쪽으로 가까이 다가가게 하여 입력 벡터와 더욱 가까워지게 하고 패자뉴런의 가중치벡터는 제자리에 두어 변동 없게 하는 식의 학습임을 알 수 있다. 최적의 학습률 함수  $\alpha(t)$ 에 관해서는 알려진 바가 없으며 실험적으로 결정하게 된다. 보통 선형이나 지수 함수적으로 감소하는 형태면 무난하다. 이 문제와 관련하여 Yair 등<sup>[18]</sup>은 몇 가지 스칼라 함수를 조사하였는데 (7) 형태의 쌍곡선 함수가 가장 좋은 학습률 함수가 될 수 있음을 (부분적으로) 증명하였다.

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

따라서 본 논문에서도 이 함수를 사용하였다.

## 2. 모의 담금질

SA<sup>[9]-[11]</sup>는 최적화 문제를 금속의 담금질 공정과 관련지는 기술이다. 최적화 문제에 적용된 SA방법의 본질은 평형특성에 있다. 먼저, 최적화 하고자 하는 시스템의 상태(보통 큰 차원의 벡터)를  $W$ 라하고 그 상태에 대해 에너지 함수(혹은 목적함수)  $D(W)$ 가 정의되어 있다고 하자. 또한 정상상태분포가 Gibbs 분포가 되도록 하는 연산자(가령 Metropolis 알고리즘)가 정의되어 있어 이를 사용하여 시스템의 상태천이를 해 나간

다고 하자. 여기서 Gibbs 분포는 (8)과 같다.

$$P(W) = \frac{1}{Z} e^{-\frac{D(W)}{T}} \quad (8)$$

여기서  $Z$ 는  $\sum_w P(W)=1$ 이 되도록 정한 정규화 상수이다. 그리고  $T(>0)$ 는 열역학적 비유에 의해 온도라 불리지는 변수이다. 이러한 동작을 하는 시스템은 연산자 의해 결정되는 상태전이 확률을 가지는 일차 Markov chain 모델이라 할 수 있다<sup>[12]</sup>. 이제  $T$ 를 고정시킨 상태에서 (8)을 관찰하여 보면 이 함수는  $D(W)$ 에 따라 지수 함수적으로 감소하는 함수이다. 즉 어떤 시스템이 (8)과 같은 정상상태분포를 나타낸다고 할 때 그 시스템이 어느 특정 상태  $W$ 에 있을 확률은 그 상태의 에너지  $D(W)$ 와 관련되며 낮은 에너지 상태로 존재할 확률이 높은 에너지 상태 보다 높다는 것을 알 수 있다. 온도를 변화시켜 보면, 높은 온도, 즉  $T \rightarrow \infty$  일 때에는  $\frac{1}{T} D(W) \rightarrow 0$  임으로 (8)은 균일 분포의 형태를 띠어간다. 반대로  $T \rightarrow 0$ 일 때 (8)은 낮은 에너지 쪽에 크기가 집중된 임펄스 함수의 형태를 띠게 된다. 따라서 (8)과 같은 정상상태 시스템은 높은 온도에서 평형상태에 도달할 경우 에너지에 무관하게 모든 상태의 존재 확률이 균등해 지며 반면, 낮은 온도에서는 시스템이 낮은 에너지 상태에 존재할 확률이 급격히 증가하게 된다.

모든 최적화 문제는 상태  $W$ 와 상태의 에너지 함수  $D(\cdot)$ 에 의해 정형화될 수 있다. 그리고 이때  $D(W)$ 를 최소로 하는  $W$ 를 찾는 것이 탐색의 목적이 된다. 문제의 정형화가 이루어졌을 경우 Gibbs 분포로의 수렴을 보장하는 연산자에 의해 상태전이를 해나간다면 시스템은 열 평형상태에 도달하게 될 것이고 이때 일반적으로 시스템이 낮은 에너지 상태에 있을 확률이 높은 에너지 상태에 있을 확률보다 크게 된다.

Metropolis 알고리즘<sup>[13]</sup>은 열 평형상태의 분포가 (8)과 같이 되는 것을 보장하는 상태전이 연산자이다. 이 알고리즘을 간단히 설명하면 다음과 같다. 시스템의 현재상태  $W(t)$ 가 주어졌을 경우 새로운 상태  $\eta$ 를  $\eta = \pi(W(t))$ 의 규칙에 따라 결정한다. 여기서  $\pi$ 는  $W(t)$ 으로부터 어떤 통계적 규칙에 따라 새로운 상태  $\eta$ 를 생성하는 함수로 '교란(perturbation) 함수'라 부른다. 다음으로 에너지 변화  $\Delta D = D(\eta) - D(W(t))$ 와

(9)의 양을 계산한다.

$$q = \frac{P(\eta)}{P(W(t))} = e^{-\frac{\Delta D}{T}} \quad (9)$$

여기서  $P(\cdot)$ 는 (8)에 정의된 바, Gibbs 분포를 나타낸다. 만약  $q > 1$  이면, 새로운 상태  $\eta$ 로 천이 한다. 즉  $W(t+1) = \eta$ . 반대로 만약  $q \leq 1$  이면, 상태천이는  $q$ 의 확률로 일어난다. 0과 1 사이에서 균일 분포의 난수  $\gamma$ 를 발생시켜 만약  $\gamma \leq q$  이면  $W(t+1) = \eta$ 로  $\gamma > q$  이면  $W(t+1) = W(t)$ 로 설정한다.

최저 에너지 상태의 시스템을 얻기 위한 직접적인 방법은 0에 가까운 낮은 온도에서 시스템이 열 평형에 도달하도록 시도하는 하는 것이다. 그러나 주어진 초기 상태에서 열 평형 상태에 도달하기 위해 필요한 상태천이의 수는 낮은 온도일수록 기하급수적으로 증가한다<sup>[9]</sup>. 따라서 낮은 온도에서 열 평형 상태에 도달하기 위한 가장 빠른 방법은 열 평형에 빨리 도달할 수 있는 높은 온도에서 시작하여 서서히 온도를 낮추어 나가는 것이다. 각 온도에서는 충분한 상태천이 연산으로 열 평형에 도달된 뒤에 다음 온도로 온도를 낮추어야 한다. 그리고 각 온도에서 열 평형에 도달하기 위해 시도하는 상태천이의 수는 온도 강하 폭에 의해 좌우된다. 만약 너무 빨리 온도를 낮춘다면 평형을 회복하기 위해 그만큼 더 많은 시간이 필요하다. 온도를 낮추어 가는 계획을 온도(혹은 냉각) 스케줄이라 한다. Geman<sup>[12]</sup>은 최적 점으로의 수렴을 보장하기 위해 온도  $T$ 를 시간  $t$ (상태천이 시간)에 따라 (10)와 같이 내리면 되는 것을 제시하였다.

$$T(t) = \frac{T_0}{\log t} \quad (10)$$

여기서  $T_0$ 는 초기온도를 나타내며 문제에 따라 결정된다. 현실적으로 이러한 스케줄은 매우 느리다. 그래서 Kirkpatrick<sup>[11]</sup>은 (11)와 같은 준최적의 스케줄을 추천하였다.

$$T(t) = T_0 K^t \quad (11)$$

여기서  $K$ 는 0과 1 사이의 상수(가령 0.9)이다. 일반적으로 지수 함수적으로 감소하는 온도 스케줄을 사용한다. 그러나 구체적인 모양은 응용에 따라 실험적으로 결정한다.

3. 통계적 이완법

SR은 SA를 포함하는 보다 포괄적인 개념이다 [2]-[4]. 그리고 그 내용은 상당히 일반적이다. SR 방법의 핵심은 다음의 두 가지에 있다.

1) 교란 : 어떤 상태  $W(t)$  에서 다음 상태  $W(t+1)$  로 랜덤하게 천이 한다.

2) 담금질 : 학습의 초기에는 교란의 강도가 크게 하고 학습이 진행됨에 따라 서서히 줄여 0으로 수렴하게 한다.

위 1)항에서 천이 하는 방법은 랜덤한 성분을 포함하기 만 한다면 설계자의 자유에 따라 다양하게 정의할 수 있다. 만약 천이 방법으로 3.1절에서 언급한 Metropolis 알고리즘을 사용한다면 이러한 SR 방법은 SA 방법으로 귀결된다. 2)항에서 교란의 강도를 줄인다는 것은 천이과정에서 랜덤한 성분의 비중이 점점 줄어들게 하고 결정적인 성분의 비중이 커지게 한다는 것을 뜻한다. 이와 같이 교란의 강도를 줄여나가는 문제는 2.2절에서 언급한 온도 스케줄링 문제에 대응된다.




그림 2. OLVQ 학습법에 의한 온라인 벡터 양자화기 설계 블록도

Fig. 2. A block diagram of on-line vector quantizer design by OLVQ learning.

III. 모의 담금질, 통계적 이완법을 이용한 온라인 벡터 양자화

SA 혹은 SR 방법을 온라인 양자화기 설계에 응용함에 있어 KLA와의 결합은 필요조건이 아니다. 그러나 KLA와 결합된 학습법은 수렴속도( $O(10^1)$ ) 이상나 수렴의 안정도 면에서 상당한 개선을 가져다준다. 따라서 기본적 선택사항으로 볼 수 있다.

1. SA 방법을 이용한 온라인 벡터 양자화

본 절에서는 'SA를 이용한 온라인 벡터 양자화기 설

계 방법'을 제안하고자한다(그림 2 참조). 이 방법을 단순한 SR 방법과 구분하여 OLVQ-SA로 부르기로 한다. SA를 학습에 응용하기 위해서는 먼저 최적화 하고자하는 시스템(즉 양자화기)의 상태와 상태의 에너지함수를 정의해야 한다. OLVQ-SA는 전체 코드벡터들의 집합, 즉 '코드북  $W$ '를 시스템 상태로 정의하기로 한다. 다음으로 에너지함수로는, KLA와 마찬가지로 순간오차함수 (3)을 에너지함수로 정의하기로 한다. 이와 같이 하면  $t$  시점에서의 에너지함수  $D(t)$ 은  $t$  시점의 상태  $W(t)$ 와 더불어 (12)와 같이 나타내질 수 있다.

$$D(W(t)) = \{d(x(t), W_c(t))\}^2 \quad (12)$$

(12)의 오른쪽의 승자뉴런을 가리키는 인덱스  $c$ 는 (1)에서 정의된 바와 같이,  $t$  시점에서의 입력벡터  $x(t)$  과 그 시점에서의 모든 코드벡터, 즉 코드북  $W(t)$ 의 함수이다. 따라서 순간오차함수를 (3)의  $D(t)$  대신 (12)처럼  $D(W(t))$ 으로 표기할 수 있다.

이상과 같이 상태와 에너지함수의 정의가 일단락 되면 양자화 문제는 최소에너지 상태를 탐색하는 문제로 정형화되고 SA방법의 적용은 직접적이고 간단하다. 이에 대한 간단한 절차는 그림 3과 같다.

1) 초기화 :

$$t = 1, \quad T = T_0, \quad W_1, \dots, W_M$$

2) 가장 가까운 이웃(nearest neighbor) 탐색 :

$$c = \arg \min_i d(x(t), W_i(t))$$

$$D_1 = d(x(t), W_c(t))$$

3) 중심(centroid) 교란 :

$$W_{c \text{ new}} = W_c(t) + \alpha Koh + \xi(T(n))$$

$$D_2 = d(x(t), W_{c \text{ new}})$$

4) 에너지 증분  $\Delta D$  계산 :

$$\Delta D = D_2 - D_1$$

5) 채택 결정 :

$$\text{If } q = \exp\left[-\frac{\Delta D}{T}\right] > 1$$

$$W_c(t+1) = W_{c \text{ new}}.$$

Else

Generate uniform RN  $\gamma \in (0, 1)$ .

If  $\gamma \leq q$   
 $W_c(t+1) = W_{c, new}$   
 Else  
 $W_c(t+1) = W_c(t).$

6) 열 평형 :

If Thermal Equilibrium, Goto 7).  
 Else  
 $t = t + 1,$   
 Goto 2).

7) 온도 냉각 :

If  $T(n) < \text{End Temperature}, \text{ Stop}$   
 Else  
 $T = T(n+1),$   
 Goto 2).

그림 3. 온라인 코드북 설계를 위한 OLVQ-SA 방법  
 Fig. 3. The OLVQ-SA algorithm for on-line code-book design.

그림 3의 단계 3)에서 Koh는 (5)에 정의되어 있는 Kohonen 학습량을 뜻한다.  $\alpha$ 는 학습률을 뜻한다. 온도  $T(n)$ 은 그림 3에서 단계 3)의 가우시안 잡음  $\xi(\cdot)$ 의 분산을 결정하는 역할과 단계 5)에서 제안된 교란의 채택 여부를 결정하는 변수로 작용한다. 높은 온도는 잡음의 영향을 크게 하고 목적함수를 나빠지게 하는 상태천이가 채택될 확률을 높인다. 온도가 낮아짐에 따라 잡음의 영향은 줄어들며 목적함수를 개선시키는 천이만 받아들이는 경향을 띄게 된다. 이러한 과정으로 SA 방법은 점차로 KLA에 근사해 간다. 온도는 각각의 온도에서 시스템이 열 평형에 도달할 때마다 서서히 감소하는데 이때의 스케줄에 따라 수렴속도나 성능이 영향을 받게된다. 사용되는 온도스케줄  $T(n)$ 은 실험적으로 결정된다. 본 연구에서 사용한 곡선은 (11)과 같다.

시스템이 열 평형에 도달하였는가 하는 것을 판단하는 것은 어려운 문제다. Kirkpatrick [9]은 주어진 온도에서 상태천이가(시도된 회수가 아닌)받아들여진 회수로 이를 추정하였다. 대략 이 지침에 따라,  $M \times 200$  정도의 상태 천이가 일어난 시점을 그 온도에서 열 평형에 도달한 시점으로 보고 온도를 낮추었다.

## 2. SR 방법을 이용한 온라인 벡터 양자화

본 절에서는 'SR을 이용한 온라인 벡터 양자화기 설계 방법'을 제안하고자한다. 이 방법을 SA 방법과 구분하여 OLVQ-SR로 부르기로 한다. SR의 응용에 있어서 두 가지 방식의 교란을 고려할 수 있다. 즉,

1) 중심(centroid) 교란 : 이는 3.1절의 SA 방법과 마찬가지로 중심을 교란하는 것이다. 즉 Kohonen 학습량에 잡음을 섞어 생성되는 코드북에 랜덤성을 부여한다.

2) 가장 가까운 이웃(nearest neighbor : NN) 교란 : 이 방법은 입력벡터에 잡음을 섞음으로써 간단히 구현될 수 있다. 이는 (1)에 의한 가장 가까운 코드벡터의 선정을 혼란스럽게 하는 것이다.

실험결과, 1)의 교란 방법은 KLA에 비해서는 우수하였으나 2)에 비해 혹은 SA 방법에 비해서는 좋은 결과를 가져오지 못하였다. 따라서 1)의 방법은 구현하지 않았다. 2)의 방법과 같이 입력자료에 잡음을 섞어 학습 성능을 높이는 방법은 인공 신경망 학습의 분야에서는 상당히 잘 알려진 방법이다. 이와 관련한 논의는 [20], [21] 등을 참조할 수 있다.

SR 방법에서는 제안된 교란이 목적함수의 증감에 상관없이 무조건 받아들여진다. 따라서 SA의 경우처럼, Metropolis 알고리즘을 구현하기 위해 필요한 목적함수의 증분계산, 채택 여부의 결정 등을 하지 않아도 되므로 계산상으로 효율적이다. 그러나 SA와는 달리 최소점으로서의 수렴에 관한 이론적 정리가 정립되어 있지 않다는 단점을 가진다. 이 방법의 정당성은 어디까지나 실험적 성공으로 뒷받침된다. 제안된 OLVQ-SR은 그림 4와 같다.

1) 초기화 :

$$t = 1, \quad T = T_0, \quad W_1, \dots, W_M$$

2) 가장 가까운 이웃 교란 :

$$x(t) = x(t) + \xi(T(n)).$$

3) 중심 계산 :

$$W_c(t+1) = W_c(t) + \alpha \text{ Koh}$$

4) 열 평형 :

If Thermal Equilibrium, Goto 5).

Else

$$t = t + 1,$$

Goto 2).

5) 온도 냉각 :

```
If  $T(n) < \text{End Temperature}$ , Stop
Else
 $T = T(n+1)$ ,
Goto 2).
```

그림 4. 온라인 코드북 설계를 위한 OLVQ-SR 방법  
Fig. 4. The OLVQ-SR algorithm for on-line code-book design.

그림 4에서 단계 3)의 Koh는 그림 3의 단계 3)과 마찬가지로 Kohonen 학습량을 뜻하는데 여기서 주의해야 할 점은, 학습에 사용하는 입력벡터는 잡음에 오염된 벡터가 아닌 오염되기 전의 순수한 입력벡터  $x(t)$ 을 사용한다.  $\alpha$ 는 학습률을 뜻한다.

이러한 학습에서 온도가 줄어들수록 따라 잡음 벡터  $\xi$ 의 영향은 점점 줄어들게 되고 입력벡터는 NN 규칙에 따라 본래의 승자뉴런(NN 영역)에 할당되게 될 것이다. 따라서 학습은 점차로 순수한 Kohonen 학습법으로 근사해가며 최적해에 수렴해가게 된다.

#### IV. 실험 및 결과 분석

제안된 방법들 즉, OLVQ-SA, OLVQ-SR와 KLA의 성능을 비교하기 위해 두 가지 실험을 하였다. 첫째는 Gauss-Markov 신호원에 대한 양자화 실험이다. 이는 벡터 양자화기 성능실험에 흔히 사용되는 신호원으로 실제 자료(음성이나 화상)에 대한 간단한 확률적 모델로서 사용될 수 있다. 둘째로는 실제 음성 및 영상 자료에 대한 양자화실험이다.

##### 1. Gauss-Markov 신호원에 대한 양자화 실험

본 실험은 상관계수  $\rho$ 가 각각 0, 0.5, 0.9인 세 가지 경우의 1차 Gauss-Markov 신호원에 대해 조사하였다. 이들 신호원은 (13)에 의해 생성된다.

$$x_{i+1} = \rho x_i + w_i \tag{13}$$

여기서  $w_i$ 는 평균 0, 분산 1인 i.i.d 가우시안 잡음이다. 이렇게 생성된  $x_i$ 는 평균과 분산이 각각 0과  $1/(1-\rho^2)$ 인 Gauss 신호가 된다. 각 상관계수에 대해 총 16384( $2^{14}$ ) 샘플을 채집하여 벡터를 구성한 뒤(2차

원일 경우 9182개 4차원일 경우 4096개) 순차적으로 인가하며 학습에 사용하였다. KLA의 최대 세대(epoch) 수는 실험 결과를 토대로 200회로 설정하였다. 그리고 제안된 방법과 형평을 기하기 위해 KLA의 점수는 초기조건을 바꿔가며 30 재시행을 실시하여 최고점으로 기록하였다. 이는 OLVA-SR의 계산량이 대략 KLA의 23배, OLVQ-SA의 계산량이 대략 30배정도 드는데 따라 설정한 회수다.

각 신호원에 대해 벡터의 차원과 코드북의 크기를 변화시켜가며 제안된 방법들과 KLA 성능을 비교한 것이 표 1에 주어져 있다. 표 1에서 보면, 대체로 상관계수, 벡터 차원, 코드북의 크기가 증가함에 따라 제안된 방법들과 KLA 간의 차이가 커짐을 알 수 있다. 전체적으로 OLVQ-SA가 OLVQ-SR보다 약간 더 좋은 성능을 나타내고 있다. 그러나 계산량은 OLVQ-SR이 OLVQ-SA보다 약간 더 효율적이다. OLVQ-SA는 KLA에 대해 최대 3.12(dB)의 성능우위를 나타내고 있다. 이는 코드북 성능이 SNR의 관점에서 약 2배정도 개선되었음을 뜻한다. 그러나 코드북 크기가 64인 경우

표 1. 일차 Gauss-Markov 신호원에 대한 KLA와 OLVQ-SA, OLVQ-SR의 SNR 성능 비교 단위는 dB 이다.

Table 1. Performance comparison between KLA, OLVQ-SA and OLVQ-SR for first-order Gauss-Markov source. The used unit is decibel.

$\rho$	벡터 차원	코드북 크기	KLA	OLVQ-SA	OLVQ-SR
0	2	64	16.46	15.67	15.66
		128	18.96	19.04	19.02
		256	21.78	22.65	22.14
	4	64	7.95	8.06	8.00
		128	9.77	9.97	9.92
		256	12.03	12.27	12.22
0.5	2	64	16.96	16.40	16.33
		128	19.47	19.63	19.60
		256	21.93	23.27	23.20
	4	64	8.88	8.93	8.94
		128	10.63	10.82	10.81
		256	12.88	13.15	13.10
0.9	2	64	19.68	19.45	19.43
		128	22.11	22.62	22.58
		256	23.11	26.14	25.94
	4	64	13.32	13.35	13.36
		128	14.98	15.11	15.10
		256	16.02	17.46	17.32

에는 상관계수나 벡터차원에 상관없이 제안된 방법들과 KLA의 성능에 별 차이가 없었다. 이는 간단한 양자화 문제일 경우 KLA도 좋은 성능을 보이며 적절한 해법이 될 수 있음을 시사하는 것이다.

### 2. 음성 자료에 대한 양자화 실험

음성은 SB-64 사운드카드로 모노채널, 11kHz 샘플링 주파수, 16bit 양자화 레벨로 총 16384 샘플을 채집하였다. 이렇게 채집된 샘플들을 다시 평균 0, 표준편차 1로 표준화한 뒤에 양자화기 설계를 위한 학습자료로 사용하였다. 참고로 이 음성의 1차 상관계수는 0.96이다.

표 2. 음성 자료에 대한 KLA와 OLVQ-SA, OLVQ-SR의 SNR 성능비교. 단위는 dB이다.

Table 2. Performance comparison between KLA, OLVQ-SA and OLVQ-SR for speech data. The used unit is decibel.

벡터 차원	코드북 크기	KLA	OLVQ-SA	OLVQ-SR
2	64	22.46	22.72	22.51
	128	24.10	26.24	25.96
	256	24.89	30.23	27.65
4	64	17.21	18.15	18.12
	128	18.39	20.46	20.65
	256	18.96	23.35	23.97

표 2에서 보면, 음성 자료의 경우에 KLA에 대한 제안된 방법의 우수성이 보다 분명히 드러남을 알 수 있다. 이는 패턴의 분포가 복잡해짐에 따라 통계적 학습이 보다 효과를 발휘하는 것으로 볼 수 있다. 대체적으로 여기서도 벡터 차원, 코드북의 크기가 증가함에 따라 제안된 방법들과 KLA 간의 차이가 커지고 있다. 표 2에서도 표 1에서처럼 전체적으로 OLVQ-SA가 가장 우수한 성능을 나타내었다. OLVQ-SA는 KLA에 비해 최대 5.52dB에서 최저 0.81dB까지의 성능 우위를 나타내고 있다. 이를 코드북의 크기와 관련지어 생각해 볼 때, KLA에 비해 코드북의 크기를 절반으로 줄여도 제안된 방법이 보다 우수한 코드북을 생성할 수 있음을 보여주는 것이다. 또한 이는 1 bit 이상의 전송률 이득이 가능하다는 것을 뜻한다. KLA는 코드북의 크기가 128에서 256으로 증가할 때 SNR의 증가율이 급격히 둔화되고 있다. 이는 문제가 복잡해짐에 따라 KLA에

의한 극소점 근방으로의 접근이 더욱 어려워지고 있다는 것을 시사한다. 반면 제안된 방법들은 코드북 크기에 대해 거의 등 간격의 SNR 개선을 보이고 있다. 이는 복잡해지는 문제에 대해서 잘 대응하고 있음을 시사한다. OLVQ-SR은 대부분의 경우에 있어서 OLVQ-SA에 준하는 성능을 나타내고 있다. 이는 계산량이나 구현의 측면에서 보다 효율적인 OLVQ-SR이 경우에 따라서는 OLVQ-SA의 대안이 될 수 있음을 시사하는 것이다.



그림 5. 128×128, 8bit 흑백사진 “Lena”  
Fig. 5. 128×128, 8bit monochrome “Lena” image.

표 3. 영상 자료에 대한 KLA와 OLVQ-SA, OLVQ-SR의 SNR 성능비교. 단위는 dB이다.

Table 3. Performance comparison between KLA, OLVQ-SA and OLVQ-SR for image data. The used unit is decibel.

벡터 차원	코드북 크기	KLA	OLVQ-SA	OLVQ-SR
2	64	20.79	20.86	20.76
	128	23.74	23.90	23.73
	256	25.92	27.21	27.21
4	64	14.85	14.92	14.88
	128	16.59	16.92	16.76
	256	17.99	19.19	19.17

### 3. 영상 자료에 대한 양자화 실험

영상 자료로는 그림 5에서 보는 바와 같이 “Lena”로 불리는 128×128의 8bit 레벨의 흑백사진을 사용하였다. 이 영상의 평균은 123.10이고 표준편차 43.71이다. 이 샘플들 역시 양자화 되기 전에 평균 0, 표준편차 1로 표준화되었다. 학습벡터는 행 단위로 영상을 스캔하여



중첩이 되지 않게 총 9182개의 2차원 벡터와 4096개의 4차원 벡터를 구성하여 사용하였다. 표 3에서도 표 1, 표 2의 경우와 마찬가지로 OLVQ-SA가 가장 우수한 성능을 나타내었다. 또한 그 차이는 코드북의 크기와 차원의 크기에 비례하여 커지고 있다. OLVQ-SA는 KLA에 비해 최대 1.2dB에서 최저 0.07dB까지의 성능 향상을 나타내고 있다.

## V. 결 론

본 논문은 온라인 방식의 벡터 양자기 설계에 있어서 극소점 문제를 해결하기 위해 SR 방법을 응용하였다. SR 방법은 SA 개념을 사용하느냐 안 하느냐에 따라 달라 나눌 수 있다. 우리는 이를 구분하여 SA 개념을 이용한 SR 방법은 OLVQ-SA로, SA 개념을 이용하지 않는 SR 방법은 OLVQ-SR로 명명하였다. OLVQ-SR 방법은 교란방법에 따라 보다 세분화될 수 있으나 중심교란 방법에 의한 OLVQ-SR 방법은 가장 가까운 이웃 교란 방법에 비해 상대적으로 약간 성능이 떨어지므로 지면을 절약하기 위해 생략하였다. Gauss-Markov 신호원과 음성 및 영상 자료에 대한 벡터 양자화 실험 결과 제안된 방법들은 KLA에 비해 일관되게 우수한 성능의 코드북을 생성하였다. 결론적으로, 온라인 벡터 양자기 설계에 있어서 통계적 방법이 성공적으로 응용될 수 있으며 이는 KLA의 극소점 수렴문제를 개선할 수 있음을 보였다.

## 참 고 문 헌

- [1] T. Kohonen, *Self-Organizing Maps*, Springer-Verlag, 1995.
- [2] B. Widrow and S. D. Stearns, *Adaptive Signal Processing*, Englewood Cliffs, NJ : Prentice-Hall, 1985.
- [3] E. Erwin, K. Obermayer and K. Schulten, "Self-organizing maps: ordering, convergence properties and energy functions," *Biol. Cybern.*, vol. 67, pp. 47~55, 1992.
- [4] N. M. Nasrabadi and Y. Feng, "Vector quantization of images based upon the Kohonen self-organization feature maps," in *Proc. 2nd ICNN Conf.*, vol. I, pp. 101~105, 1988.
- [5] Jun Wang, Ce Zhu, Chenwu Wu and Zhenya He, "Neural network approaches to fast and low rate vector quantization," in *Proc. IEEE ISCAS'95* vol. 1, USA, 1995.
- [6] SriGouri Kamarsu and H. C. Card, "Vector quantization of speech using artificial neural learning," in *Proc. IEEE Pacific RIM Conf. Communications, Computers & Signal Processing*, Canada, 1995.
- [7] Y. Linde, A. Buzo, and R. M. Gray, "An algorithm for vector quantizer design," *IEEE Trans. Commun.*, vol. COM-28, pp. 84~95, Jan. 1980.
- [8] P. -C. Chang and R. M. Gray, "Gradient algorithms for designing predictive vector quantizers," *IEEE Trans. Acoust., Speech, Signal Processing*, vol. ASSP-34, pp.679~690, Aug. 1986.
- [9] P. J. M. van Laarhoven and E. H. L. Aarts, *Simulated Annealing : Theory and Applications*, Boston : D. Reidel Publishing, 1987.
- [10] V. Cerny, "A thermodynamical approach to the traveling salesman problem : an efficient simulation algorithm," preprint, *Inst. Phys. & Biophys.*, Comenius Univ., Bratislava, 1982.
- [11] S. Kirkpatrick, C. D. Gelatt, Jr., and M. P. Vecchi, "Optimization by simulated annealing," *Science*, vol. 220, pp. 671~680, May 1983.
- [12] S. Geman and D. Geman, "Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images," *IEEE Trans. Patt. Anal. Machine Intell.*, vol. PAMI-6, pp.721~741, Nov. 1984.
- [13] K. Zeger and A. Gersho, "A stochastic relaxation algorithm for improved vector quantizer design," *Electron. Lett.*, vol. 25, no. 14, pp. 896~898, July. 1989.
- [14] K. Zeger, J. Vaisey and A. Gersho, "Globally optimal vector quantizer design by stochastic relaxation," *IEEE Trans. Signal Proc.*, vol. 40, no. 2, Feb. 1992.
- [15] P. D. Wasserman, *Neural Computing*, NY : Van Nostrand Reinhold, 1989.

- [16] D. DeSieno, "Adding a conscience to competitive learning," in Proc 2nd ICNN Conf., vol. I, pp. 117~124, 1988.
- [17] H. Ritter and K. Shulten, "Kohonen's self organizing maps: Exploring their computational capabilities," in Proc 2nd ICNN Conf., vol. I, pp. 109~116, 1988.
- [18] E. Yair, K. Zeger and A. Gersho, "Competitive Learning and soft competition for vector quantizer design," IEEE Trans. Signal Proc., vol. 40, no. 2, Feb. 1992.
- [19] N. Metropolis, A. W. Rosenbluth, M. N. Rosenbluth, A. H. Teller, and E. Teller, "Equations of state calculations by fast computing machines," J. Chem. Phys., vol.21, pp. 1087~1091, 1953.
- [20] L. Holmstrom and P. Koistinen, "Using additive in backpropagation training," IEEE Trans. Neural Networks, vol. 3, 1992.
- [21] Y. Grandvalet and S. Canu, "A comment on noise injection into inputs in backpropagation learning," IEEE Trans, Syst., Man, Cybern., vol. 25, 1995.

---

 저 자 소 개
 

---

## 宋 權 培(正會員)

1992년 : 아주대학교 전자공학과(학사). 1995년 : 아주대학교 전자공학과(공학석사). 2001년 : 아주대학교 전자공학과(공학박사). 1995년~1996년 : 현대전자 소프트웨어 연구소 <관심분야> 음성신호처리, 적응신호처리, 인공지능 및 신경망

## 李 幸 世(正會員)

1966년 : 전북대학교 전기공학과(학사). 1972년 : 서울대학교 전자공학과(공학석사). 1984년 : 고려대학교 전자공학과(공학박사). 1968년~1970년 : 해군 사관학교 교관. 1982년~1983년 : Columbia Univ.n.y. 객원교수. 1987년~1988년 : INRIA PARIS 객원교수. 1992년~1994년 : 거제전문대학장. 1973년~현재 : 아주대학교 교수. <관심분야> 음성신호처리, 음성인식, 인공지능 및 신경망