
SOM을 이용한 부호책의 고속 탐색 알고리즘

김진태*, 김동욱**

A Fast Search Algorithm of Codebook Using the SOM

Jin-Tae Kim, Dong-Wook Kim

본 연구는 한국과학재단 목적기초연구(2000-1-30300-003-2) 지원으로 수행되었음.

요 약

본 논문에서는 부호책의 계산 복잡도를 감소시키기 위하여 SOM의 처리 과정에서 발생하는 정보를 이용하는 고속 탐색 알고리즘을 제안한다. 부분 거리 탐색의 성능을 부호책의 재배열 영향을 입증하기 위해 3가지 경우의 배열에 의한 계산 시간 감축의 효과를 보인다.

ABSTRACT

In this paper, in order to reduce the computational complexity of codebook, we propose a fast search algorithm which takes advantage of the information generated in the process of the self-organizing map (SOM). In an attempt to demonstrate the influence of the ordering of codebook on the performance of the partial distance search (PDS), we present the results of computation savings for three cases of ordering of codebooks.

I. 서론

최근 인간의 뇌가 대량의 복잡한 데이터를 효율적으로 병렬 처리할 수 있을 뿐만 아니라 학습능력이 있다는 사실에 근거하여 새로운 계산방식으로서 신경회로망(neural network)이 제안되었으며 여러 분야에 성공적으로 응용되고 있다.[1] 특히 기존의 컴퓨터로는 비효율적인 패턴 인식(pattern recognition)을

효율적으로 해결하는 데 적합하다.[2]

디지털 통신 기술은 19세기부터 정보전송이라는 측면에서 꾸준히 발전되어 왔다. 음성 정보외에 디지털 영상정보의 전송은 1920년대부터 시도되었으며 1970년대 이후 다각화된 정보시대에 있어서 영상신호의 전송은 필수적이 되었다.[3] 디지털 영상정보의 전송이 아날로그 영상신호보다 주위의 잡음에 강하다는 등의 여러 가지 장점 때문에 디지털 영상정보를 저장하고 처리하여 전송할 필요성이 대두되었으며 종래에 사용하고 있던 전송로에 다량의 디지털 영상정보를 전송하기 위한 영상압축 기법이 폭넓게 연구

* 한서대학교 컴퓨터정보학과

** 전주대학교 정보기술컴퓨터공학부

접수일자: 2000. 4. 18

개발되어 왔다. 1930년대 이후에 정보이론을 기초로 한 데이터 압축방법들이 연구되고 있다. 그런데 기존의 양자화 과정에서는 스칼라 양자화기를 사용했는데 1970년대에 벡터 양자화(vector quantization: VQ)의 성능이 정보이론 측면에서 우수하다는 연구결과들이 발표됨에 따라 1980년대부터 영상신호와 음성신호의 부호화와 음성인식과 같은 수많은 분야에서 연구되고 있다.[4,5]

지금까지의 최적의 벡터 양자화기 알고리즘은 LBG 알고리즘[6]인데 이는 계산상의 복잡성 때문에 실시간 처리에 제한을 받아 왔다. 그래서 최근에 이런 한계를 극복하고자 신경 회로망을 이용하게 되었다. 벡터 양자화기에 신경 회로망을 적용하는데는 다음과 같은 장점이 있다. 첫째, 신경 회로망이 하드웨어로 구현될 때 회로망이 병렬로 처리되기 때문에 실시간 처리가 가능하다. 둘째, 연상(associative) 기억 기능으로써 일부 훼손된 시험 입력정보로부터 학습시에 교육된 전체 정보를 인출할 수 있는 능력이 있다. 셋째, 최근접(nearest neighbor) 자료인출 기능으로써 시험 입력 정보와 정확히 대응되는 학습자료가 없을 때 가장 비슷한 자료를 인출해 내는 능력이 있다. 넷째, 고장방지 능력(fault-tolerance) 성질로서 회로망의 일부가 훼손된 경우에도 전체 성능이 급격히 저하되기보다는 완만하게 저하된다.

최근의 신경회로망 벡터 양자화와 관련된 논문들로는 웨이브릿 변환을 하고 가장 저주파 성분의 입력 벡터에 대해 통계적 특성을 이용하여 주성분을 해석하여 부호책(codebook)의 생성시간을 단축하고자하는 연구[7]가 있고, Kohonen의 SOM(self-organizing map)을 부호책 작성시에 파라미터를 적절히 선택 혹은 제거함으로써 온라인상에서 이용할 수 있도록 하는 개선된 알고리즘[8]이 발표되었다.

본 논문에서는 벡터 양자화를 행하는데 여기에 정보의 병렬처리와 복잡한 기능의 학습이 가능한 자기조직(self-organizing)형 신경회로망인 SOM[9]을 이용한다. 즉, 부호책을 작성할 때 PONS(partial output node search) 과정에 PDS(partial distance search)를 적용하고, 이때 얻어진 입력 벡터 패턴의 확률 밀도 함수 정보를 가지고 부호책을 재배열하며, 여기에 PDS 알고리즘을 적용하여 전역 탐색(full search) VQ와 비교시 부호책이 커질수록 탐색 시간이 절약되는 벡터 양자화기의 고속탐색 알고리즘을 제안한다.

II. 신경 회로망

1. 신경 회로망의 개요

신경 세포는 중앙 신경계(central nervous system)의 구성 단위로서 신체 각 부위의 상호 정보 통신을 수행한다. 신경 세포는 체세포(cell body or soma)라고 불리는 중심부와 신경의 돌기부(dendrite)와 축삭(axon)으로 불리는 신경 섬유로 되어 있다. 서로 다른 신경 세포들간의 연결부위를 시냅스(synapse)라 한다. 시냅스를 통하여 전달되는 신호는 신경 전달물질(neurotransmitte)이라 불리는 물질을 통하여 신경 세포간의 통신이 이루어진다.

신경세포는 많은 입력과 하나의 출력을 갖는 정보 처리 요소이다. 신경 세포의 생물학적 특성을 기반으로 그림 1과 같이 신경 세포의 모델을 세울 수 있다. 시냅스는 가중치로 표현되며, 이 가중치를 통하여 들어온 입력을 모아 신경 세포의 출력을 정하는 방법에 따라 결정론적 모델과 확률론적인 모델로 나눌 수 있다. 여기서 신경 세포 x 에서 신경 세포 y 로 가는 가중치를 W_{yx} 로 나타내고 신경세포 y 의 출력 값을 $Output_y$, 신경 세포 y 가 받는 총 입력을 Net_y 라고 하면, $Net_y = \sum W_{yx} \times y_x$ 가 된다.




그림 1. 신경 세포의 일반적인 모델
Fig. 1 Common model of nerve cell

신경 세포의 모델은 다음과 같은 종류로 나눌 수 있다. 첫째로, 결정론적 모델은 다음과 같다.

- 선형 모델 : $Output_y = K \times Net_y$ (K 는 비례상수)

- 선형 임계치(linear threshold) 모델 :

$$Output_y = \begin{cases} 1 & \text{if } Net_y \geq threshold \\ 0 & \text{if } Net_y < threshold \end{cases}$$

- 비선형 모델 : 대표적으로 시그모이드(sigmoid) 함수를 들 수 있으며, 그 출력은

$$Output_y = \frac{1}{1 + E^{-Net_y}} \text{ 가 된다.}$$

둘째로, Net_y 가 직접 신경 세포의 출력 값을 결정하는 것이 아니라 출력 값의 확률만을 결정하는 확률적인 모델이 있다. 예를 들면, Boltzman형의 기계에서 어떤 신경 세포의 출력 값이 1이 될 확률은

$$P(Output_y = 1) = \frac{1}{1 + E^{-Net_y/T}} \text{ 가 된다.}$$

2. 신경 회로망을 이용한 패턴 인식

패턴 인식이란 말이 사회에 정착된 것은 비교적 최근의 일이다. 인간은 태어나면서부터 시각, 청각, 후각, 미각, 촉각 그리고 감각 등을 이용하여 사물을 식별하는 인식 능력이 있다. 패턴이란 패턴 인식에서의 취급 대상이다. 즉, 인간이 보는 것, 듣는 것을 기초로 한 인식 대상을 패턴이라 한다.

인간의 뇌 세포는 130억개 이상 있다고 한다. 그러나 감각기로부터 들어온 다량의 정보를 그대로 처리 정보로서 대뇌에 입력해서는 아무리 많은 기억 세포를 가지고 있다하더라도 처리할 수는 없을 것이다. 그래서 인간은 입력 정보량의 압축, 즉 그 정보가 갖고 있는 특징만을 추출하여 기술한 패턴화된 정보와 인간이 기억하고 있는 모델 정보간의 비교 판단에 바탕을 두고 인식을 행하는 것이 특징이다. 여기서 인식은 크게 두 경우로 나눌 수 있는데, 클래스를 알 수 없는 미지의 경우와 클래스를 알고 있는 경우이다. 전자는 미지의 대상 집합을 닮은 것끼리 같은 종류로 분류화(clustering)를 하는 과정이다. 클래스를 모르는 비지도형(unsupervised) 학습 또는 자기 학습이라 부른다. 클래스를 알고 있을 경우에는 좁은 의미의 패턴 인식이다.

신경 생리학적 연구 등에 의하면 고등 동물에 있어서의 시각 패턴 등에 관한 고도의 정보처리는 대뇌의 시각 영역에서 시작된다고 한다. 더욱이 고등 동물의 대뇌의 시각 영역에는 패턴의 특징 추출, 운동 방향의 검출 등을 수행하는 신경 세포가 존재한다고

알려져 있다. 이러한 사실로부터 고등 동물의 대뇌의 시각 영역에는 패턴의 특징 추출 기능, 패턴의 위치 변형, 굽기, 회전, 대소 등의 정규화 기능을 수행하는 신경 회로망이 존재한다고 추측할 수 있다. 그러나 구체적인 신경 회로에 관해서는 생리학적으로도 아직 명확히 밝혀지지 않았으므로 신경 회로 모델을 구성함으로써 이들의 기능을 실현하려는 노력이 시도되고 있다.

많은 양의 데이터를 취급하는 영상처리에서는 신경 회로망 모델의 국소 병렬성을 이용함으로써 대규모적인 최적화 문제를 고속으로 해결할 수가 있다. 또한 학습 능력은 여러 가지 영상처리 응용을 같은 형식의 병렬처리 회로를 사용하여 가중치를 적당히 변화시켜 실현함으로써 범용적인 패턴 정보처리 장치의 개발을 가능하게 한다.

현재까지 개발되고 알려진 대부분의 영상인식 신경 회로망은 정적 패턴(static pattern)을 그 입력으로 한다. 이들은 먼저 입력이 2진 값인가 연속 값인가의 여부와 다음에 학습이 지도형(supervised)인가 비지도형인가의 여부로 크게 나누어 질 수 있다. Kohonen의 SOM은 연속 값의 입력을 가지는 비지도형 학습 신경 회로망의 예이다.

III. SOM을 이용한 벡터 양자화기

1. SOM의 원리

신경 회로망의 동작은 학습에 의하여 점차로 개선을 해 나간다. 특히 어떻게 동작을 해야 좋을지 지시가 없는 경우에도 외부의 정보구조에 따라 그것에 적합하도록 결합을 바꾸어 외부의 모델을 내부에 형성할 수 있다. 이것을 자기 조직이라고 한다. Kohonen은 입력 벡터 패턴을 표현하는 최상의 특성 지도(feature map)를 만들기 위하여 국부적으로 상호 연결된 많은 노드들간의 가중 값을 적응적으로 자기 조직하는 분류화 신경 회로망(neural clustering network)을 제안하였다.[10,11] 이는 신경 회로망의 자기 학습 방법으로 가까이 위치하고 있는 신경 세포들은 물리적으로 유사한 외부 입력에 민감한 반응을 보이도록 입력으로부터 신경 세포로 연결된 가중 값들을 변화시키는 것이다. 이렇게 조정된 가중 값들은 입력 특성 지도를 형성한다.

특성 지도 형성을 위해 그림 2와 같은 출력 노드

(신경 세포)들의 이차원 배열이 사용된다. 모든 출력 노드들은 국부적으로 상호 연결된 많은 노드들을 가지고 있으며 모든 입력은 모든 출력 노드와 가중 값의 변화가 가능하게 연결되어 있다. 특성 지도를 작성하는 알고리즘은 그림 3과 같이 각 노드의 주변에 정의된 이웃영역이 필요하다. 그림 3에서 $NE_j(t)$ 는 시간 t 에서 $node_j$ 의 이웃영역을 나타낸다. 이는 시간에 따라 그 크기가 점차로 줄어든다. 그림 3에서 보는 것처럼 Kohonen의 알고리즘은 N 개의 입력 노드에서 M 개의 출력 노드들의 각각의 가중 값을 조정하여 분류화를 행한다.




그림 2. 특성 지도 형성을 위한 노드의 2차원 배열
Fig. 2-2-D array of node for making of feature map




그림 3. 특성 지도 형성시의 이웃 영역의 변화 상태
Fig. 3 Variation state of neighborhood as making of feature map

즉, N 차의 입력 벡터로부터 M 차의 출력 벡터로 사상하는 대표 벡터가 가중 값의 갱신에 의해서 이루

어진다. 이 알고리즘은 클래스의 개수가 고정되어 있고 가중 값의 변화가 $a(t)$ 의 값이 0으로 수렴함에 따라 가중 값이 더 이상 변하지 않는 데에 그 근거를 두고 있다. 그러므로 분류의 수가 미리 정해져 있고 훈련 데이터(training data)의 수가 분류에 비해 월등히 많다면 좋은 벡터 양자화가 된다.

2. Kohonen의 SOM 알고리즘[12] SOM 알고리즘은 아래의 5단계로 이루어진다.

단계 1 : 신경 회로망의 크기가 (J, I) 라 하자. J 는 출력 노드의 개수이며, I 는 입력 벡터 패턴의 크기이다. 입력 노드 i 와 출력 노드 j 사이의 가중 값 W_{ji} 는 작은 랜덤한 값으로 초기화 한다. 그리고 $x(t); t = 0, 1, \dots, n-1$ 는 훈련 벡터열(training vector sequence)을 나타낸다.

단계 2 : 새로운 벡터 $x(t)$ 를 입력시킨다.

단계 3 : 입력 벡터 패턴과 각각의 출력 노드사이의 거리 d_j 를 계산한다.

$$d_j = \sum_{i=0}^{I-1} (X_i(t) - W_{ij}(t))^2$$

단, $j = 0, 1, \dots, J$ 이다.

단계 4 : 최소 값 d_j 를 갖는 출력 노드 j^* 를 선택하고 노드 j^* 와 $NE_{j^*}(t)$ 로 정의된 이웃영역 내의 모든 노드에 대해서 다음과 같이 가중 값을 갱신한다.

$$W_{ij}(t+1) = W_{ij}(t) + a(t)(X_i(t) - W_{ij}(t))$$

단, $j \in NE_{j^*}(t)$ 이고 $0 \leq i \leq I-1$ 이다.

NE_{j^*} 는 시간에 따라 감소하는 선택된 출력 노드 주변의 유클리디안(Euclidean) 거리 이웃이다. 적응 이득함인 $a(t)(0 \leq a(t) \leq 1)$ 도 시간에 따라서 감소한다.

단계 5 : 단계 2로 간다.

모의 실험에서 $NE_{j^*}(t)$ 는 $NE_{j^*}(t) = A_1 + A_2 \times E^{-t/T_2}$ 로 주어진다. A_1, A_2 는 이웃영역의 범위를 결정해 주는 상수이며, T_2 는 감소율을 결정하는 상수이다.

본 논문에서는 SOM을 이용하여 벡터 양자화의 부호책을 작성할 때 PONS 과정에 PDS를 적용하는데 이 때의 알고리즘은 그림 4와 같다. 이때 얻어진 입력 벡터 패턴의 확률 밀도 함수 정보를 가지고 부호책을 재배열하며, 여기에 PDS 알고리즘을 적용한 벡터 양자화의 고속 탐색 알고리즘을 제안한다.

순차로 배열되지 않았다는 것을 실험한다. 여기서 제안한 입력 벡터의 확률 밀도 함수 분포에 따른 부호책의 재배열 순차화는 PDS 방법으로부터 더 많은 계산 시간을 절약할 수 있다.

P_i 는 주어진 입력 벡터 X 가 부호 벡터 c_i 에 대응하는 분류에 속하는 확률이라 하자. 그렇다면 P_i

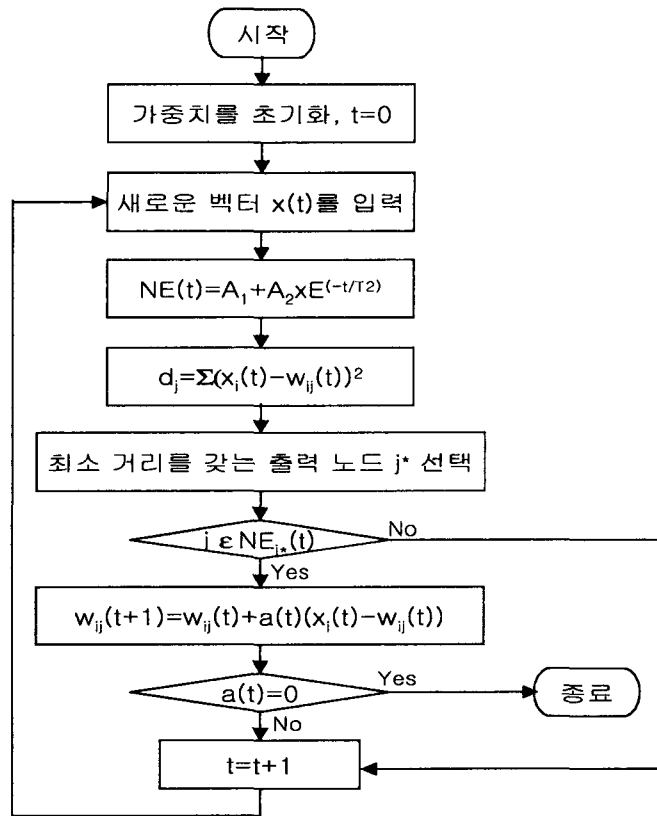


그림 4. 부호책을 작성할 때 적용한 알고리즘의 흐름도
Fig. 4 Flowchart of algorithm for construction of codebook

IV. 부호책의 재배열 및 고속 탐색 알고리즘

본 논문의 목적은 PDS에 의해 절약되는 부호책 순서화의 효과 등에 관한 것이다. 이 탐색시간 절약을 극대화하기 위하여 대응 분류의 크기에 따라 부호책의 순차화를 제안한다. 더욱이 LBG 알고리즘과 같은 분류화 알고리즘을 사용하여 훈련 과정의 끝에서 얻어진 부호책은 임의의 순차화를 가지며, 결코 좋은

는 부호 벡터 c_i 가 임의로 주어진 X 에 대하여 최소 왜곡 부호 벡터일 확률이다. 만약 부호 벡터가 부호책내에서 감소 확률 P_i , 즉 $P_1 > P_2 > \dots > P_N$ 의 순서대로 재배열될 경우에 탐색의 초기 단계에서 얻어지는 최소 d_{min} 의 확률은 증가되어 부분 탐색 알고리즘의 계산 시간의 절약을 더 개선한다.

확률 P_i , $i=1, 2, \dots, N$ 은 X 를 분류화하는 과

정에서 얻을 수 있다.

$S = \{X_p, p=1, 2, \dots, M\}$ 는 훈련 벡터열이다. 분류화의 완료 후에 이 세트는 N 개의 분류 $S_i, i=1, 2, \dots, N$ 로 분해된다.

이때 $S_i = \{X_p; c_j = q(X_p)\}$, 즉 c_j 는 모든 $X_p \in S_i$ 에 최근접점인 부호 벡터이다. 만일 n_i 가 분류 S_i 의 크기일 때, c_j 가 임의의 X_p 에 대해 최근접점 부호 벡터인 확률은 $p_i = n_i/n (n \rightarrow \infty)$ 으로 얻어질 수 있다. 입력 벡터의 P_i 는 부호책을 순차화 하는 데 필요한 확률의 적합한 측정으로 간주된다. 그래서 분류화 후에 얻어진 부호책은 감소 P_i 순으로 재배열되고, 나중에 PDS의 부호화 방법에 사용한다.

$C = \{c_i, i=1, 2, \dots, N\}$ 는 크기 N 의 부호책이다. 이때 $c_i = (c_{ij}, j=1, 2, \dots, K)$ 는 K 차 벡터이다. 훈련 벡터 $X = (x_j, j=1, 2, \dots, K)$ 가 주어질 때, PDS 알고리즘의 기본 구조는 다음과 같다.

```

d_min = ∞
Loop A: For I=1, ..., N
    d=0
    Loop B: For J=1, ..., K
        d = d + (x_j - c_ij)^2
        if d > d_min → next I
    Next J
    d_min = d
    min = I
Next I
    
```

PDS 알고리즘이 전체 탐색 알고리즘에 비해 계산 시간이 절약됨을 알 수 있다. 왜냐하면 거리 계산 $d(x, c_i)$ 의 완료전에 탈출 조건을 만족할 때 Loop B로부터 조기 탈출 조건이 있기 때문이다. 주어진 입력 벡터 X 에 대해 탈출 조건이 각각의 c_i 에 대해서 Loop B안에서 가능한 한 빨리 만족될 때 최대 절약이 이루어진다.

V. 컴퓨터 모의 실험 및 검토

신경 회로망 분류화 기법에 훈련 영상열로 여러 종류의 영상을 사용해서 실험을 했다. 크기가 64, 128, 256, 512, 1024개인 부호책을 사용했고, 블록의 크기는 4×4를 사용하였다. 비교 검토를 위해서 LBG 알고리즘을 사용한 것과 같은 크기의 부호책을 작성하였다. 모의 실험은 훈련에 사용한 집합(inside training set: ITS)으로 'Lenna', 'Woman', 'Girl' 영상을 사용하였고, 훈련에 사용하지 않은 집합(outside training set: OTS)으로 'Cronkite' 영상을 가지고 하였다.

Kohonen 기법에 있어서 파라미터는 아래와 같이 주어진다.

$$a(t) = 0.1 \times E^{-t/2000}$$

$$NE_r = 5 + 495 \times E^{-t/100}$$

Kohonen의 자기 조직 기법과 LBG 알고리즘과의 부호책을 작성하는데 있어서의 주된 차이점은 자기 조직은 부호책의 내용을 적응적으로 갱신시키지만 반복적은 아니라는 것이다. 그런 반면에 LBG 알고리즘은 반복적이며 훈련 집합은 부 공간(sub-space)으로 분할되고 모든 부 공간은 저장되어야만 한다. 두 가지 경우에 있어서 부호책의 크기는 미리 정해져 있다.

표 1은 'Woman' 영상의 부호책을 작성하는 경우에 SOM과 LBG 방법에 대한 비교이다. 훈련 벡터로는 'Woman' 영상만을 사용하였고 부호책의 크기는 64~1024의 각각을 구성하였다. 작성된 부호책을 가지고 'Woman' 영상을 VQ 했을 경우의 결과도 표 1에 보인다.

표 1. 'Woman' 영상(ITS)의 부호책 작성시간 및 SNR 비교

Table 1. Comparison of constructed time of codebook and SNR for 'Woman'

| 부호책의 크기 | 작성시간(sec) | | SNR(dB) | |
|---------|-----------|--------|---------|-------|
| | SOM | LBG | SOM | LBG |
| 64 | 432.4 | 234.0 | 26.19 | 27.26 |
| 128 | 602.3 | 438.1 | 27.40 | 28.39 |
| 256 | 1207.5 | 684.1 | 28.60 | 29.59 |
| 512 | 2388.0 | 1446.6 | 29.89 | 31.47 |
| 1024 | 5268.0 | 2778.0 | 32.32 | 33.86 |

표 1에서 보면, SOM 방법이 LBG 방법에 비해 부호책 작성시에 시간이 조금 더 걸리고 재구성 영상의 객관적인 화질도 조금 떨어지는 것으로 나타났다.

표 2는 'Cronkite' 영상의 부호책을 작성하는 경우에 SOM과 LBG 방법에 대한 비교이다. 훈련 벡터로는 'Woman', 'Lenna', 'Girl' 영상들을 사용하였고 부호책의 크기는 64~1024의 각각을 구성하였다. 작성된 부호책을 가지고 'Cronkite' 영상을 VQ 했을 경우의 결과도 표 2에 보인다. 표 2에서 보면, 표 1에서와는 달리 SOM 방법이 LBG 방법에 비해 부호책 작성시에 시간이 조금 적게 걸리고 재구성 영상의 객관적인 화질도 약간 개선된 것으로 나타났다. 이는 부호책 작성시 걸리는 시간은 훈련 벡터가 많을수록 LBG 방법에 많은 시간이 소요됨을 알 수 있다.

표 2. 'Cronkite' 영상(OTS)의 부호책 작성시간 및 SNR 비교

Table 2. Comparison of constructed time of codebook and SNR for 'Cronkite'

| 부호책의 크기 | 작성시간(sec) | | SNR(dB) | |
|---------|-----------|---------|---------|-------|
| | SOM | LBG | SOM | LBG |
| 64 | 640.2 | 702.0 | 27.75 | 27.05 |
| 128 | 798.9 | 1314.3 | 29.31 | 28.65 |
| 256 | 1456.3 | 2052.3 | 30.66 | 29.91 |
| 512 | 2745.0 | 4339.8 | 32.02 | 32.77 |
| 1024 | 7364.2 | 10800.2 | 33.34 | 33.49 |

표 3에서는 전역 탐색 VQ에 있어서 3가지 형태의 부호책 순차화 성능을 실험하기 위해 첫째로 훈련 후에 얻어진대로 남겨진 부호책(CASE1)과 둘째로, 확률의 감소 $P_i (P_1 > P_2 > \dots > P_N)$ 순서대로 가장 유리하게 순차화된 부호책(CASE2)과 셋째로, 확률의 증가 $P_i (P_1 < P_2 < \dots < P_N)$ 순서대로 가장 불리하게 순차화된 부호책(CASE3)에 PDS를 적용해 탐색 시간 절약의 결과를 나타내었다. 표 3에서 절약율은 $(FS - PDS) / FS \times 100$ 으로 하였다. 절약율은 부호책의 크기가 커질수록 더욱 크게 나타났다. 표 3의 결과는 'Woman' 영상의 부호책에 대한 결과이다.

표 3. 부호책에 PDS를 적용한 후의 탐색 시간 절약 효과

Table 3. Saving effect of search time after apply PDS to codebook

| 부호책의 크기 | 64 | 128 | 256 | 512 | 1024 | |
|-----------|-------|------|------|------|-------|------|
| PDS (sec) | CASE1 | 15.2 | 17.4 | 24.1 | 33.5 | 54.0 |
| | CASE2 | 14.2 | 15.5 | 22.5 | 31.0 | 50.9 |
| | CASE3 | 15.7 | 18.2 | 25.0 | 35.9 | 57.8 |
| FS(sec) | 21.1 | 29.7 | 29.9 | 89.3 | 175.8 | |
| 절약율 (%) | CASE1 | 27.9 | 41.4 | 51.7 | 62.5 | 69.3 |
| | CASE2 | 32.7 | 47.8 | 54.9 | 65.3 | 71.0 |
| | CASE3 | 25.6 | 38.7 | 49.8 | 59.8 | 67.1 |

VI. 결론

본 논문에서 Kohonen의 자기 조직 신경 회로망은 디지털 영상의 부호화를 위한 벡터 양자화를 설계하는 데 사용되었다. 자기 조직화 LBG를 이용하여 부호책을 작성한 후 이들을 비교하고 결과를 나타내었다. Kohonen의 SOM은 비선형 적응 방법으로 부호책내의 각각의 벡터 패턴과 이들의 이웃들은 입력 벡터 패턴에 의해서 갱신된다.

LBG 방법은 결정론적이며 반복적인 알고리즘인데 최종의 부호책 벡터 패턴은 초기 부호책에 의존할 수밖에 없다. 그래서 예측 왜곡을 최소로 하는 최적의 벡터를 찾을 수 없다. 물론 Kohonen의 SOM 방법이 최적의 벡터 패턴을 찾을 것이라는 것도 증명된 바가 없다. 그러나 부호책의 크기와 관련한 많은 양의 훈련 데이터 열이 주어졌을 때 적응과 이웃 영역 파라미터가 매우 천천히 감소된다면 최적의 최소 왜곡치를 찾을 수 있을 것이다. 그리고 PDS 방법에 의해 얻어진 계산 시간 절약에 대한 부호책의 순차화의 결과를 나타내었다. 계산 시간 절약의 관점에서 PDS 알고리즘의 효율이 부호책내의 대표 벡터를 확률 감소 순으로 배열함으로써 개선될 수 있음을 보여 주었다.

참고문헌

- [1] R. P. Lippmann, "An introduction to computing with neural nets," IEEE ASSP Mag., vol. 3, no. 5, pp. 4-22, Apr. 1987.

- [2] J. L. McClelland, D. E. R. Hart, Parallel Distributed Processing, The PDP Research Group, 1987.
- [3] R. C. Gonzalez and P. Wintz, Digital Image Processing, Addison-Wesley, 1977.
- [4] R. M. Gray, "Vector quantization," IEEE ASSP Mag., vol. 1, pp. 4-29, Apr. 1984.
- [5] J. Makhoul, S. Roucos, and H. Gish, "Vector quantization in speech coding," Proc. IEEE, vol. 73, pp. 1555-1558, 1985.
- [6] Y. Linde, A. Buzo, and R. W. Gray, "An algorithm for vector quantizer design," IEEE Trans. Commun., vol. 28, pp. 84-95, Jan. 1980.
- [7] 서석배, 김대진, 강대성, "멀티미디어 정보검색에 적합한 영상정보의 벡터 양자화 코드북 설계 및 특징추출", 대한전자공학회 논문지, 제36권 S편, 제8호, pp. 101-112, 1999. 8.
- [8] 진영근, 김태균, "개선된 Kohonen 신경망 SOM을 이용한 데이터 탐색에 대한 연구", 한국통신학회 논문지, 제24권, 제2B호, pp. 266-273, 1999. 2.
- [9] T. Kohonen, "The self-organizing map," Proc. IEEE, vol. 78, pp. 1464-1480, 1990.
- [10] T. Kohonen, Self-Organized and Associative Memory, Spring Verlag, 1988.
- [11] T. Kohonen, "An introduction to neural computing," Neural Networks, vol. 1, no. 1, pp. 3-16, 1988.
- [12] J. R. Jang, C. T. Sun, and E. Mizutani, Neuro-Fuzzy and Soft Computing, Prentice-Hall, pp. 423-432, 1997.



김동욱(Dong-Wook Kim)

1987년 2월 성균관대학교 전자공학과 졸업(공학사)

1992년 2월 중앙대학교 대학원 전자공학과 졸업(공학석사)

1996년 8월 중앙대학교 대학원 전자공학과 졸업(공학박사)

1997년 3월~1998년 2월 청운대학교 전자공학과 전임강사

1998년 3월~현재 전주대학교 정보기술컴퓨터공학부 조교수

※주관심분야 : 통신신호처리, 영상통신, 정보보호 등



김진태(Jin-Tae Kim)

1987년 2월 중앙대학교 전자공학과 졸업(공학사)

1989년 2월 중앙대학교 대학원 전자공학과 졸업(공학석사)

1993년 8월 중앙대학교 대학원 전자공학과 졸업(공학박사)

1995년 3월~현재 한서대학교 컴퓨터정보학과 조교수

※주관심분야 : 영상통신, 얼굴인식, 정보보호 등