

다층 신경회로망 학습에 의한 정지 영상의 벡터

이 상 찬[†] · 최 태 원^{††} · 김 진 흥^{†††}

요 약

본 논문에서는 다층 신경회로망의 일반화 특성을 이용한 새로운 영상 압축 알고리듬을 제안한다. 제안 알고리듬은 벡터 양자화방식을 이용하여 영상을 몇 개의 클래스로 분류하고 이들을 다층 신경회로망으로 학습한다. 이렇게 학습된 다층 신경회로망은 일반화 특성에 의하여 무 학습의 영상에 대해서도 압축과 복원을 수행한다. 아울러 벡터 양자화방식에 있어서 벡터 양자화 오차와 수신측에서의 메모리를 감소시킨다.

본 논문에서는 Lena 영상을 학습 영상으로 하여 이를 16개의 클래스로 나누고 각 클래스를 1개의 다층 신경회로망으로 학습하였다. 그리고 학습에 사용된 Lena 영상 및 무 학습 영상들에 대하여 압축과 복원을 수행하여 우수한 화질의 영상이 복원 되어짐을 보인다.

Vector Quantization Compression of the Still Image by Multilayer Perceptron

Sang-Chan Lee[†] · Tae-Whan Choi^{††} · Jin-Hong Kim^{†††}

ABSTRACT

In this paper, a new image compression algorithm using the generality of the multilayer perceptron is proposed. Proposed algorithm classifies image into some classes, and trains them through the multilayer perceptron. Multilayer perceptron which trained by the above method can do compression and reconstruction of the nontrained image by the generality. Also, it reduces memory size of the side of receiver and quantization error.

For the experiment, we divide Lena image into 16 classes and train them through one multilayer perceptron. The experimental results show that we can get excellent reconstruction images by doing compression and reconstruction for Lena image, Dollar image and Statue image.

1. 서 론

최근 몇 년간 신경회로망은 많은 연구 분야에서 매우 커다란 관심의 대상이 되어 왔다. 이 같은 관심은 신경회로망이 지닌 병렬처리 능력, 적응학습 능력,

Error-Tolerance능력, 그리고 Fault-Tolerance능력 등과 같은 장점 때문이다[1]. 이 가운데서도 Rumelhart [2]가 제안한 오차 역전파 학습 알고리듬의 다층 신경회로망은 분류, 인식, 그리고 제어등의 비선형 문제를 해결하는데 우수한 성능을 보여왔다.

특히 역전파 학습 알고리듬이 지닌 근사능력에 관한 이론적 연구 및 이를 이용한 영상 압축에 관한 연구가 활발히 이루어지고 있다. 1957년에 Kolmogorov

† 정 회 원:부산전문대학 전산정보처리과 시간강사

†† 정 회 원:부산대학교 전자공학과 시간강사

††† 정 회 원:부산전문대학 전산정보처리과 조교수

논문 접수:1995년 7월 20일, 심사완료:1996년 2월 9일

[3]는 $[0, 1]^n$ 에서 \mathbb{R}^m 으로 사상하는 어떠한 다변수 연속함수도 일변수 연속함수의 선형조합에 의해 근사될 수 있다는 것을 증명하였다. 1987년에 Nielsen[4]은 이 증명을 신경회로망에 적용하여 연속 함수를 정확히 근사할 수 있는 다중 신경회로망이 존재함을 이론적으로 보였다. Chiang과 Fu[5]는 2차 시그모이드함수를 활성화 함수로 하는 다중 신경회로망을 이용하여 함수 근사를 시도하였다.

이와 같은 다중 신경회로망의 근사능력 즉 일반화 특성은 영상 압축을 위한 신경회로망의 적용을 가능케 하였다. 일반적으로 영상 압축에 대한 다중 신경회로망의 이용은 영상 데이터를 축소된 공간으로 매핑하는 압축 특성과 무 학습의 영상 데이터를 처리할 수 있는 일반화 특성을 지닌 것으로 알려져 있다. 이를 바탕으로 1989년에 Sonehara[6]는 2차원의 입, 출력층과 작은 수의 뉴런으로 구성된 은닉층을 이용하여 영상 압축을 시도하였다. 영상의 밝기를 입력 및 교사신호(신경회로망의 학습을 위하여 외부에서 부여하는 출력 신호 즉, 신경회로망에 의하여 출력되기를 원하는 값)로 영상 전체를 학습하여 압축하였다. 그리고 일반화 특성에 의하여 다른 무 학습 영상에 대하여 압축, 복원을 시도하였다. 그러나 이 방식은 계산량이 많아 학습시간이 너무 긴 단점을 지니고 있고 일반화 특성도 우수하지 않았다. 1990년에 Sicuranza[7]는 이 문제를 해결하기 위하여 전체 영상을 부분 영상들로 나누어 학습하는 방식을 제안하였다. 그러나 이 방식은 계산량을 감소시키기 위한 불러의 선정과 통계적 분포를 결정해야 하는 문제점을 지니고 있다.

본 논문은 이 같은 문제점을 해결하기 위하여 기존의 영상 압축 방식 중 하나인 벡터 양자화방식[8]에 다중 신경회로망을 적용한 영상 압축 방식을 제안한다. 일반적으로 벡터 양자화방식은 상관도가 높은 영상 불러들을 클래스별로 분류하여 각 클래스에 대한 대표 불러를 구한다. 그리고 각 영상 불러들을 전송하는 대신 그 불러이 속한 클래스의 대표 불러를 전송하여 영상을 압축한다. 이에 반하여 본 논문의 제안 방식은 벡터 양자화방식에 의하여 분류된 클래스내의 불러들을 다중 신경회로망으로 학습하여 영상을 압축하는 것이다. 제안 방식에 의하여 학습된 다중 신경회로망은 일반화 특성에 의하여 벡터 양자화방식의 양자화 오차를 감소시키며 무학습의 영상에 대

하여 압축을 수행한다. 따라서 제안 방식은 Sonehara 방식보다 다중 신경회로망의 학습 시간을 감소시킨다. 그리고 일반화 특성으로 인하여 벡터 양자화에서의 양자화 오차를 감소시키며 큰 규모의 코드북에 따른 수신측의 메모리를 감소시킨다. 본 논문의 구성은 2장에서는 제안 방식에서 사용된 신경회로망의 구조 및 학습 알고리듬을 설명하고 3장에서는 벡터 양자화 방식과 다중 신경회로망을 결합한 영상 압축 방식을 제안한다. 그리고 4장에서는 시뮬레이션을 수행하고 그 결과를 검토하며, 5장에서는 결론과 앞으로의 연구방향에 대해서 언급한다.

2. 다중 신경회로망의 구조 및 학습 알고리듬

일반적으로 다중 신경회로망은 기본적으로 다수의 뉴런들과 이들 간의 연결강도를 나타내는 가중치에 의한 계층적 구조로서 입력층, 은닉층, 그리고 출력층으로 구성된다. 가장 바닥층인 입력층은 외부로부터 오는 신호를 가중치를 거쳐 다음 은닉층으로 전달하며 은닉층은 입력층과 출력층 사이의 일련의 층으로 입력층으로부터 입력된 신호를 출력층으로 보낸다. 그리고 출력층은 은닉층으로부터 받은 신호를 최종 출력한다. 이와 같은 구조의 다중 신경회로망에서 학습은 반복적인 계산과정을 통하여 원하는 값이 출력되도록 가중치를 변화시켜가는 일련의 과정을 뜻한다. 전통적인 다중 신경회로망 구조에 대한 학습 알고리듬으로서 Rumelhart의 오차 역전파 학습 알고리듬이 알려져 있다. 이 알고리듬은 가중치에 대한 오차함수의 경사하강법을 사용하여 반복적 계산으로 오차를 최소화한다.

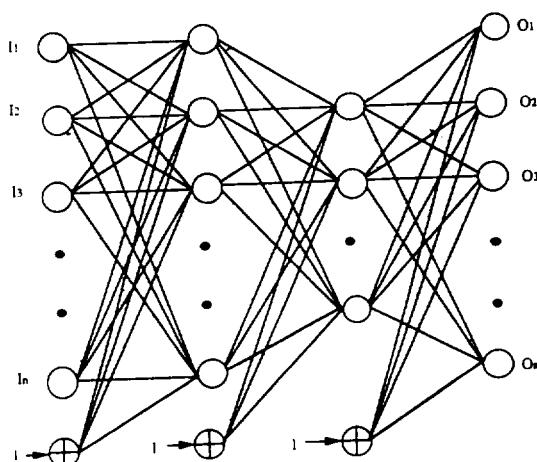
그러나 이와 같은 전통적인 다중 신경회로망의 구조와 학습 알고리듬에는 몇 가지 문제점들이 있다. 본 장에서는 다중 신경회로망을 이용한 영상 압축 및 복원을 수행하기 위하여 개선된 형태의 구조 및 학습 알고리듬을 이용하였다.

2.1 다중 신경회로망의 구조

지금까지 이용되어 온 다중 신경회로망은 1개의 은닉층을 지닌 3-layer 구조이다. 이 구조에서 은닉층은 매우 중요한 역할을 수행한다고 알려져 있다. 그러나 그 역할에 관한 정확한 이론적 연구 결과는 보고되어

있지 않고 단지 실험적 연구 결과만이 발표되어 오고 있다. 일반적으로 1개의 은닉층을 지닌 다층 신경회로망은 convex 형태로 분포된 패턴들을 분류할 수 있으며 2개의 은닉층으로 구성된 다층 신경회로망은 non-convex 형태의 분포 패턴들을 분류할 수 있다고 알려져 있다[10]. 이러한 배경에서 본 논문은 학습 능력의 향상을 위하여 2개의 은닉층을 지니는 다층 신경회로망을 영상 학습에 적용한다.

2개의 은닉층을 지닌 다층 신경회로망을 영상 압축에 적용하기 위하여 본 논문에서는 Sonehara의 구조와 같이 입력층과 출력층의 뉴런 수를 동일하게 하였다. 그리고 압축하려는 영상 블럭의 밝기를 학습 알고리듬에서의 입력 및 교사신호로 하였다. 또한 출력층에 가까운 은닉층의 수를 입력층과 출력층에서의 뉴런 수보다 작게 제한하여 압축을 시도하였다. 따라서 입력층에 입력되는 입력신호는 축소된 공간 즉, 작은 갯수의 뉴런으로 구성된 은닉층으로 매핑되어 압축되어지고 은닉층의 출력신호는 출력층을 거쳐 역으로 복원되어 진다. 그러므로 송신단인 학습된 다층 신경회로망의 입력층과 은닉층에서 영상 압축을 수행하여 은닉층의 출력을 수신단으로 전송한다. 그리고 수신단에서는 전송된 은닉층의 출력을 다층 신경회로망의 출력층에 입력시켜 간단한 계산에 의하여 복원한다. 그림 1은 본 논문에서 도입한 다층 신경회로망의 구조이다.



(그림 1) 영상 압축/복원을 위한 다층 신경회로망의 구조
(Fig. 1) The structure of multilayer perceptron for image compression/reconstruction.

2.2 학습 알고리듬

Rumelhart에 의하여 제안된 오차 역전파 학습 알고리듬은 입력 신호에 대한 출력층의 출력값을 원하는 출력값(교사신호)과 비교하고 그 오차를 각 층의 가중치로 전파하는 방식이다. 이러한 일련의 과정들은 순방향 과정과 역방향 과정으로 나누어 진다.

순 방향 과정에서 각 층의 뉴런에 대한 출력값은 동일한 방식으로 계산되어 진다. 한 예로 은닉층과 출력층에 있어서 k번째 뉴런의 출력값은 다음과 같이 계산된다.

$$O_{pk} = f(\text{net}_{pk}) = \frac{1}{1 + e^{-\frac{\text{net}}{\lambda}}} \quad (1)$$

여기서 net_{pk} 는 다음과 같다.

$$\text{net}_{pk} = \sum_j w_{pj} O_j + \theta_p \quad (2)$$

여기서 w_{pj} 는 p번째 뉴런과 (k-1)번째 층의 j번째 뉴런을 연결하는 시냅스의 가중치이고 O_j 는 (k-1)번째 층의 j번째 뉴런의 출력값이다. θ_p 는 p번째 뉴런의 바이어스를 나타낸다. 이처럼 순방향 과정은 층간의 계산이 동일하여 다층 신경회로망의 층 수에 관계없이 쉽게 적용되어 질 수 있다.

역방향 과정은 실제 출력과 교사신호와의 차이를 감소시키기 위하여 가중치를 수정하는 과정이다. 전체 오차함수 E는 다음과 같이 정의 한다.

$$E = \sum_p E_p = \frac{1}{2} \sum_p \sum_k (T_{pk} - O_{pk})^2 \quad (3)$$

여기서 E_p 는 p번째 패턴의 오차이고 T_{pk} 는 p번째 패턴에 대한 k번째 출력신호이고 O_{pk} 는 출력층의 실제 출력이다. 이 오차에 의한 급하강법으로 계산되는 가중치의 증가분은 다음과 같은 chain rule에 의하여 이루어진다.

$$\begin{aligned} \Delta_p w_{ki} &= -\eta \frac{\partial E}{\partial w_{ki}} \\ &= \eta \delta_{pk} O_{pj} \end{aligned} \quad (4)$$

여기서 η 는 학습상수(learning rate)이며 η 는 0 ($\eta < 1$)의 범위를 지닌다. 한편 δ_{pk} 의 값을 계산하면

$$\begin{aligned}\delta_{pk} &= -\frac{\partial E}{\partial \neq t_{pk}} \\ &= (T_{pk} - O_{pk}) f'(\neq t_{pk}) \\ &= 0_{pj}(1 - 0_{pj}) \sum_k \delta_{pk} w_{kj}\end{aligned}\quad (5)$$

로 나타낼 수 있다.

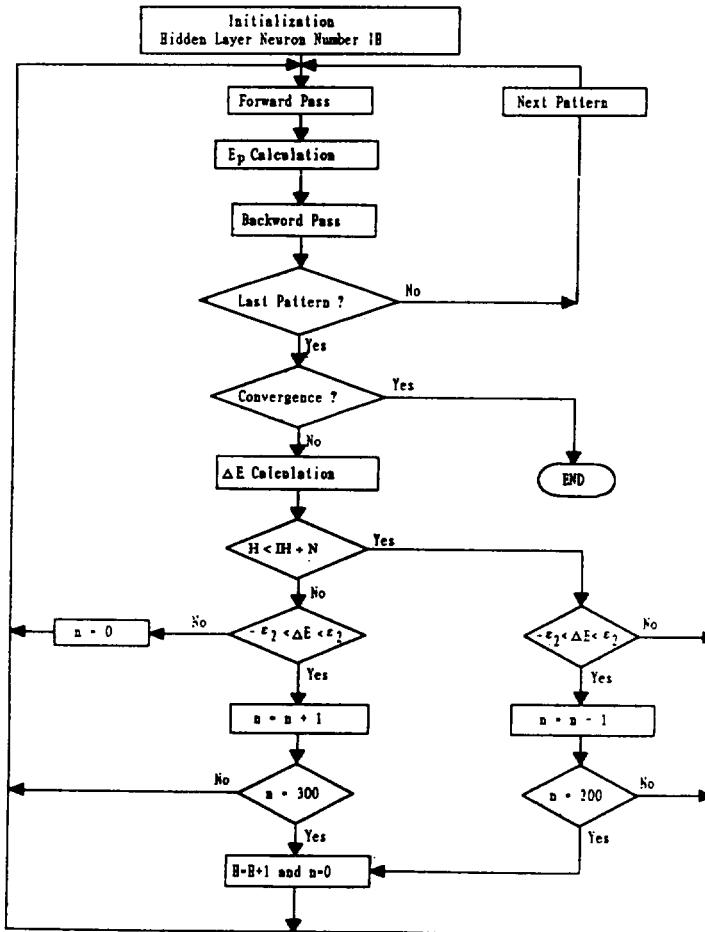
그리고 은닉층에 대한 결과는 위와 같은 방법에 의하여

$$\Delta_p w_{ji} = -\eta \delta_{pj} 0_{pi} \quad (6)$$

$$\delta_{pj} = f'(\neq t_{pj}) \sum_k \delta_{pk} w_{kj} \quad (7)$$

가 된다. 기존의 방식에서 볼 때 알 수 있듯이 오차 급강하법은 출력층의 오차에 대한 각층의 가중치 변화가 chain rule에 의하여 계산된다. 그러므로 다수의 은닉층으로 구성된 다층 신경회로망의 역변환 과정은 단순히 chain rule의 확장에 의하여 일반화되어 진다.

이와 같은 오차 역전파 알고리듬은 학습 속도가 느리고 최적의 은닉층 뉴런 수를 결정할 수 없다는 문제점들을 지닌다. 은닉층의 뉴런 수가 불필요하게 많으면 계산량이 증가하여 학습 속도가 느리게 된다. 한편 뉴런 수가 적다면 학습이 정체되거나 국부극소



(그림 2) 학습 알고리듬의 순서도
(Fig. 2) Flow chart of learning algorithm.

점(local minimum)에 빠져 학습이 잘 이루어 질 수 없다. 본 논문에서는 이러한 문제들을 극복하기 위하여 은닉층 뉴런 추가 학습 알고리듬[11]을 적용하였다. 기존의 역전파 알고리듬에서 은닉층 뉴런의 갯수는 학습 초기에 미리 설정되고 학습이 끝날 때까지 고정된다. 그리고 적당한 뉴런의 갯수는 여러번의 실험에 의하여 결정된다. 이에 반하여 은닉층 뉴런 추가 학습 알고리듬은 작은 수의 은닉층 뉴런으로 학습을 시작하여 학습 중에 뉴런을 증가시켜 나가는 알고리듬이다. 일반적으로 작은 수의 뉴런으로 구성된 다층 신경회로망은 학습시 학습을 멈추기에 충분한 오차 수준에 이르지 못한다. 따라서 학습중에 오차의 변화율($E = E(i) - E(i-1)$)이 미리 정한 기준값보다 작지만 오차가 큰 경우, 즉 학습은 되어있지 않지만 더 이상 학습이 이루어지지 않을 경우, 이를 극복하기 위하여 기준치보다 작은 오차 변화율이 연속적으로 일정한 횟수 이상 나타나면 은닉층의 뉴런을 하나 첨가시킨다. 본 논문에서는 2층의 은닉층에 대하여 각각 1개의 뉴런을 첨가한다. 그리고 첨가된 은닉층의 뉴런과 연결되는 모든 가중치는 작은 값으로 초기화한다. 이는 첨가된 은닉층 뉴런이 첨가시까지 해온 학습에 미칠 영향을 줄이기 위한 것이다. 이와 같은 방법으로 학습을 시켜 나가면 은닉층의 뉴런 수는 점차 증가하게 되고 전체 오차가 기준값보다 작아 학습이 완료될 때 은닉층 뉴런 수는 어떤 값에 이른다. 따라서 은닉층 뉴런 첨가 학습 알고리듬은 학습의 속도를 높이고 아울러 학습에 필요한 적절한 은닉층 뉴런 수를 결정하게 한다. 다음 그림 2는 은닉층 뉴런 추가 학습 알고리듬의 순서도를 나타낸다.

3. 영상 압축 알고리듬

기존의 영상 처리 분야에는 다양한 영상 압축 알고리듬들이 있다. 이 중에서도 벡터 양자화방식은 대표적인 영상 압축 알고리듬으로 이용되고 있다. 이 알고리듬은 상관도가 높은 영상블럭들을 하나의 클래스로 분류하여 대표블럭으로 각각의 영상블럭을 대치하는 방식이다. 따라서 이 알고리듬은 각 클래스의 대표블럭을 구하는 과정과 구해진 대표블럭을 이용하여 영상블럭을 압축하는 과정으로 구성된다. 대표블럭들을 구하기 위하여 먼저 원 영상을 적당한 크기

의 블럭들로 나누고 블럭의 밝기를 좌표값으로 하여 영상블럭을 패턴 공간의 한 점에 대응시킨다. 그리고 미리 주어진 수의 클래스로 패턴 공간을 분할하여 각 클래스의 중심을 구한다. 이때 각 클래스의 중심을 대표블럭이라 하며 전체 대표블럭과 그 인덱스의 집합을 코드북이라 한다. 이렇게 구해진 코드북을 이용하는 벡터 양자화방식의 영상 압축은 각 영상 블럭이 속하는 클래스를 구하고 코드북에서 그 클래스에 해당하는 부호의 인덱스를 전송함으로써 이루어진다. 그리고 수신측에서의 영상 복구는 송신측과 동일한 코드북에 대하여 전송된 인덱스에 해당하는 대표블럭을 코드북에서 구하여 지정된 블럭의 밝기값으로 할당함으로써 이루어 진다. 이 압축 방식의 구성도는 다음의 그림 3과 같다.



(그림 3) 벡터 양자화방식에 의한 영상 압축/복원 구성도
(Fig. 3) Block Diagram for Image Compression/Reconstruction using Vector Quantization.

이같은 과정속에서 벡터 양자화는 블럭의 밝기를 대표블럭 값으로 대치함으로써 발생되는 양자화 오차를 지닌다. 이 오차를 줄이기 위해서는 블럭의 크기를 작게 하고 클래스의 수를 증가시켜야 한다. 그러나 이와 같이 할 경우 압축율이 감소한다. 또한 여러가지 영상들을 압축하기 위해서는 규모가 큰 코드북이 필요하며, 이는 수신측에 많은 메모리를 요구하는 문제점이 있다.

본 논문은 다층 신경회로망을 이용한 영상 압축에 있어서 벡터 양자화의 분류방식을 도입한 새로운 영상 압축방식을 제안한다. 먼저 벡터 양자화 알고리듬에서와 같이 영상블럭들을 패턴 공간에 대응시키고 난 후 작은 수의 클래스로 패턴 공간을 분할한다. 이때 분할방식은 기존의 LBG 알고리듬을 적용한다[9]. 분류된 각각의 클래스에 대하여 1개씩의 나층 신경회로망을 할당하고 은닉층 추가 학습 알고리듬을 이용하여 다층 신경회로망을 학습한다. 하나의 클래스에

부여된 다중 신경회로망에 있어서 입출력층의 뉴런 수는 영상의 블럭크기와 동일하게 설정하고 입력과 교사신호는 0과 1사이로 정규화된 블럭의 밝기 값으로 한다. 이같은 방식에서의 학습은 벡터 양자화방식에 의해 분류된 클래스만을 학습하므로 학습 데이터 수가 감소되어 기존의 다중 신경망에 의한 영상 압축에서 보다 학습시간이 줄어들고 또한, 정밀한 근사가 이루어진다. 학습이 끝난 후 다중 신경회로망들은 일반화 특성에 의하여 각각의 클래스에 대하여 Identify Mapper역할을 한다. 즉, 일반화 특성에 의하여 입력된 값과 동일한 값이 출력되어진다. 따라서 학습된 블럭뿐만 아니라 무 학습된 블럭에 대해서도 그 입력신호는 출력층에 연결된 은닉층 뉴런들의 출력으로 압축되어 전송되고 전송된 값들은 출력층에 연결된 가중치를 거치면서 다시 확장, 복원되어 입력값과 동일한 값이 출력된다. 즉 수신측에서는 은닉층과 출력층간의 가중치에 이 전송값을 곱하여 복구된 영상 출력을 얻는다. 이와 같이 제안 방식에 의한 복원은 다중 신경회로망의 일반화 특성에 의하여 무 학습의 다른 영상들을 압축, 전송, 복원하는 데 쓰일 수 있다. 다음 그림 4는 제안 방식에 의한 영상 압축과 복원 구성을이다.

이와같은 제안방식은 벡터 양자화방식에 비하여 수신측에 큰 메모리를 요구하지 않는다. 다만 다중 신경회로망의 일반화 특성에 의하여 한 번 학습된 다중 신경회로망은 무학습의 영상에도 적용되어질 수 있으므로 수신측은 은닉층과 출력층간의 가중치만을 저장하기 위한 메모리만 필요로 할 뿐이다. 또한, 일반화 특성은 벡터 양자화방식에 존재하는 양자화 오차를 감소시킨다.

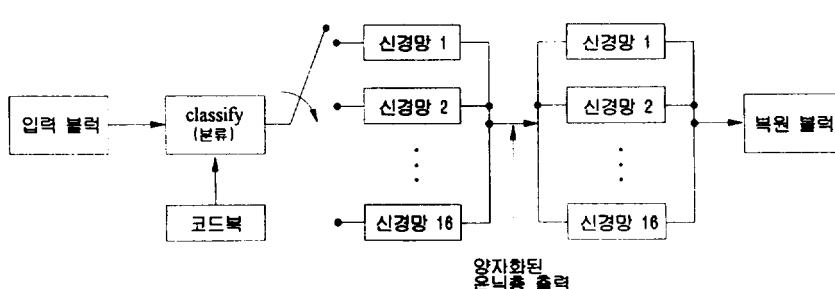
4. 시뮬레이션 및 검토

본 장에서는 제안한 방식에 의한 영상 압축, 복원 성능을 알아 보기 위하여 256x256크기의 Lena 흑백 영상을 벡터 양자화로 분류하고 이를 다중 신경회로망으로 학습하였다. 그리고 학습에 사용된 Lena 영상과 무 학습의 Dollar 영상, Statue 영상에 대하여 압축

<표 1> TEST영상의 학습 데이터 및 결과

<Table 1> The result and learning data of test image

클래스	영상 블럭수	학습 블럭수	내삽전 PSNR	학습오차 E	은닉층의 뉴런수	내삽후 PSNR
c1	969	120	28.54	0.60	67.4	31.27
c2	209	93	22.70	1.21	55.4	25.57
c3	333	151	24.27	1.48	66.4	27.27
c4	524	214	24.39	2.69	30.4	27.17
c5	152	77	19.28	2.13	53.4	22.61
c6	944	250	26.58	1.99	52.4	30.97
c7	159	52	21.17	0.90	62.4	23.84
c8	246	141	21.29	1.01	50.4	28.41
c9	1051	262	27.40	1.05	39.4	33.71
c10	80	30	18.90	0.28	74.4	26.86
c11	963	239	28.84	0.62	39.4	36.08
c12	1117	245	28.69	1.40	45.4	32.87
c13	79	39	20.55	0.40	50.4	23.82
c14	570	160	27.17	0.75	43.4	32.24
c15	383	97	28.35	0.48	63.4	31.97
c16	413	48	30.46	0.10	58.4	30.33



(그림 4) 제안 방식에 의한 영상 압축/복원 구성도

(Fig. 4) Block diagram for iamge compression/reconstruction by the proposed method.

과 복원을 수행하였다. 본 논문은 벡터 양자화에 의한 영상 블럭의 분류에서 한 블럭의 크기를 2×4 로 하고 총 클래스 수는 16개로 하였다. 따라서 입, 출력 층의 뉴런 수가 8개인 총 16개의 다층 신경회로망을 학습에 이용하였다. 그리고 은닉층의 출력 값은 6bits로 양자화하여 전송하였다. 학습에 관련된 데이터 및 결과는 표 1에 나타내었다.

표 1은 16개의 클래스 각각에 있어서 전체 영상을 블럭의 갯수, 학습에 이용된 학습블럭수, 그리고 학습이 완료되었을 때의 학습오차를 보여준다. 표에서 볼 때 출력층에 연결된 은닉층의 뉴런수가 4개로 입, 출력 층의 뉴런수보다 작아 압축이 이루어짐을 알 수 있다. 학습에 의한 효과를 살펴보기 위하여 학습전과 학습후의 PSNR을 표 1에 포함시켰다. 일반적으로 PSNR은 NxM 크기의 영상에 대하여 다음과 같이 정의된다.

$$PSNR = 10 \log \frac{255^2}{\frac{1}{N \cdot M} \sum_{i=1}^N \sum_{j=1}^M (e_{ij})^2} \quad (8)$$

여기서 e_{ij} 는 (i, j) 화소에서의 오차이다.

표에서 내삽전 PSNR은 영상블럭들과 대표블럭들간의 오차를 계산한 것이고, 내삽후 PSNR은 영상블럭과 다층 신경망의 출력블럭간의 오차를 계산한 것이다. 또한, 표에서 알 수 있듯이 모든 클래스에 대하여 내삽후 PSNR이 증가한 것을 알 수 있다. 이것은 학습 다층 신경회로망의 일반화 특성에 의하여 벡터 양자화방식에서의 양자화 오차가 감소한 것을 보여준다.

그림 5는 Lena영상에 대하여 수신측에서 복구한 복원 영상을 나타내고 있다.

학습 영상인 Lena영상에 대하여 복원된 영상의 PSNR은 29.94dB로 화질이 우수함을 알 수 있다. 학습된 다층 신경회로망의 일반화 특성에 의한 영상 압축을 살펴 보기 위하여 무학습 영상에 대하여 압축을 시도하였다. 그림 6, 7은 무학습의 Dollar 영상, Statue 영상에 대한 복원 영상을 나타내고 있다.

그림 6, 7에서 볼 때 무학습의 영상에 대해서도 우수한 화질의 복원 영상이 얻어짐을 알 수 있다. 이는 다층 신경회로망의 일반화 특성이 양자화 오차를 줄인 결과이다. 이 같은 결과에서 볼 때 이 방식은 수신 측에 은닉층과 출력층간의 가중치만을 가지고 모든



(a) 원 영상



(b) 복원 영상 (PSNR : 29.94)

(그림 5) 원 영상과 복원 영상

(Fig. 5) Original and Reconstructed Lena Images.

(a) 원 영상

(b) 내삽된 영상 (PSNR : 28.88)

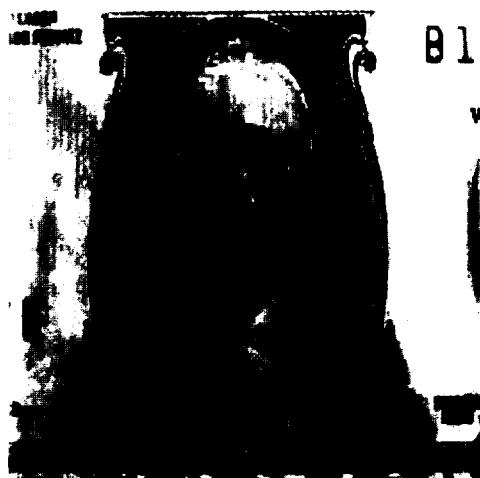
영상을 복원할 수 있으므로 큰 규모의 코드북을 요구하지 않는 잇점을 지니고 있다. 그러나 제안 방식에서 압축률은 3bpp로 낮았다. 이것은 블럭의 크기가 2×4 로 작아서 생긴 현상이다.



(a) 원 영상

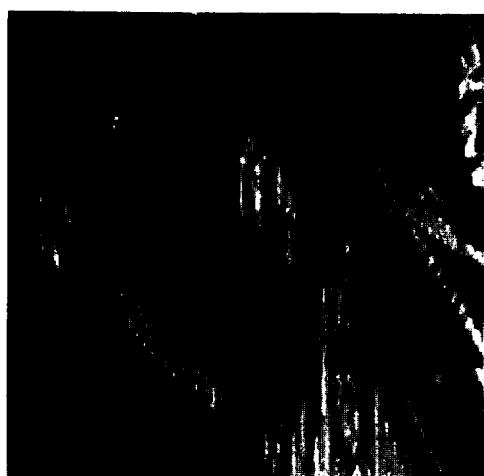


(a) 원 영상



(b) 복원 영상 (PSNR : 28.88)

(그림6) 원 영상과 복원 영상
(Fig. 6) Original and Reconstructed Dollar Images.



(b) 내삽된 영상 (PSNR : 25.5)

(그림7) 원 영상과 복원 영상
(Fig. 7) Original and Reconstructed Statue Images.

5. 결 론

본 논문에서는 벡터 양자화방식에 다층 신경회로망을 적용한 새로운 영상 압축 알고리듬을 제안하고 실험을 통하여 이를 검증하였다. 실험을 통하여 다층 신경회로망이 지닌 일반화 특성은 벡터 양자화의 양

자화 오차를 감소시켰다. 그리고 무 학습 영상에서 새로운 학습을 수행하지 않고도 우수한 화질의 영상을 복원하였다. 또한, 제안방식은 수신측의 메모리를 절약하는 잇점도 지닌다. 그러나 이 방식은 영상의 우수한 복원능력에 반하여 압축률이 낮은 단점을 지닌다. 이 같은 문제점을 해결하기 위하여 규모가 큰

영상볼륨을 학습하고 은닉층 출력값에 대하여 새로운 부호화 기법을 적용하는 등의 연구가 향후 연구과제로 남아 있다. 더나아가 다중 신경회로망으로 보다 우수한 범용의 영상 압축 구현에 관한 연구도 필요할 것이다.

참 고 문 헌

- [1] V. Milutinovic and P. Antognetti, "NEURAL NETWORKS:Concepts, Application and Implementation", Vol. 1, pp. 110-148, Prentice-Hall, 1992.
- [2] D. E. Rumelhart, G. E. Hinton, and R.J. Williams, "Learning Internal Representations by Error Propagation," in D. E. Rumelhart and J. L. McClelland(Eds), Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Vol. 1: Foundations, pp. 318-362, MIT Press, 1986.
- [3] R. H. Nielsen, "Kolmogorov's Mapping Neural Network Existence Theorem," IJCNN'87, Vol. 3, pp. 11-13, 1987.
- [4] R. H. Nielsen, "Theory of the Backpropagation Neural Networks," IJCNN'89, Vol. 1, pp. 593-605, 1989.
- [5] C. C. Chiang and H. C. Fu, "A Variant of Second-Order Multilayer Perceptron and Its Application to Function Approximation," IJCNN'92, Vol. 3, pp. 887-892, 1992.
- [6] N. Sonehara, M. Kawato, S. Miyake, and K. Nakane, "Image Data Compression using a Neural Network Model," IJCNN'89, Vol. 2, pp. 35-41, 1989.
- [7] G. L. Sicuranza, "Artificial Neural Network for Image Compression," Eletronics Letters, Vol. 26, No. 7, March, 1990.
- [8] R. M. Gray, "Vector Quantization," IEEE ASSP MAGAZINE, pp. 4-29, 1984.
- [9] Y. Linde, A. Buzo, and R. M. Gray, "An Algorithm for Vector Quantizer Design," IEEE Transactions on communications, Vol. Com-28, No. 1, 1980.
- [10] P. D. Wasserman, "NEURAL COMPUTING- Theory and Practice," VAN NOSTRAND REINHOLD, 1989.
- [11] Y. Hirose, k. Yamashita, and S. Hijiya, "Back Propagation Algorithm which Varies The Number of Hidden Units," Neural Networks, Vol. 4, pp. 61-66, 1991.



이 상 찬

- 1985年 2月 부산대학교 전자공학과 졸업(공학사)
 1994年 2月 부산대학교 전자공학과 졸업(공학석사)
 1995年 現在 부산대학교 전자공학과 대학원 박사과정 중
 1985年~1991年 6月 효성그룹 컴퓨터사업부 근무
 現在 부산전문대학 전산정보처리과 시간강사
 주관심 분야: 패턴인식, 영상처리 등임.



최 태 완

- 1983年 2月 동아대학교 전자공학과(공학사)
 1985年 2月 부산대학교 전자공학과(공학석사)
 1996年 3月 부산대학교 전자공학과(공학박사)
 1884年 12月~1991年 5月 (주) LG전자연구소 주임연구원
 1991年 5月~1992年 3月 부산대학교 전자공학과 조교
 1993年 3月~現在 부산대학교 전자공학과 시간강사
 주관심 분야: 초기시각 및 컴퓨터 비전, 영상처리, 신경회로망 등임.



김 진 흥

- 1983年 동아대학교 전자공학과(공학사)
 1986年 동아대학교 대학원 전자공학과(공학석사)
 1994年 동아대학교 대학원 전자공학과(공학박사)
 1986年 3月~현재 부산전문대학 전산정보처리과 조교수
 주관심 분야: 디지털 신호처리, 멀티미디어.