

다층구조 퍼셉트론과 SOFM부호화로 된 복합 구조를 이용한 영상압축

正會員 趙 廣 輔*, 朴 哲 薰, 李 壽 永

Image Compression using Hybrid Structure with Multi-Layer Perception and SOFM Coding

Kwang Bo Cho*, Cheol Hoon Park, Soo-Young Lee Regular Members

要 約

본 논문에서는 블럭 분류, VQ(vector quantization), SOFM(self organizing feature map)과 함께 신경 회로망을 이용한 새로운 영상압축 복원과정을 보인다. 오차 역전파 알고리즘으로 학습되는 다층 퍼셉트론은 정규화된 영상데이터를 감소된 공간 중복성을 가지는 은닉층의 값으로 변환하는데 사용된다. 여기에 영상블럭의 복잡성에 따라 적응적으로 압축되도록 블럭을 분류한다. 또한 은닉뉴런의 양자화된 값은 효과적인 전송을 위해 VQ나 SOFM으로 코딩된다. SOFM의 경우 VQ보다 좀더 좋은 성능을 보인다. 또한 높은 압축률 영역에서 좋은 성능을 나타내는 MLP와 SOFM을 결합한 하이브리드 모델을 제안한다. 컴퓨터 모의실험에서 복원 영상의 큰 화질저하 없이 VQ나 SOFM을 이용한 경우 약 40-45:1의 압축률을 얻었다.

ABSTRACT

In this paper, a new method of image compression and reconstruction based on neural networks is presented with block classification, VQ(vector quantization), and SOFM(self organizing feature map). Multilayer perception(MLP) with error back-propagation learning algorithm is used to transform the normalized image into the compressed hidden values. Additionally, the image blocks can be grouped for adaptive compression rates depending on the characteristics of the complexity of the blocks. The quantized output of the hidden neuron can be vector quantized or SOFM coded for an efficient transmission. Self organizing feature map shows better performance than vector quantization. Hybrid model with MLP and SOFM shows good performance especially in high compression ratio region. In computer simulation, about 40-45:1 compression rate can be achieved using VQ or SOFM without much degradation of the reconstructed images.

* 한국과학기술원 전기 및 전자공학과

Department of Electrical Engineering Korea Advance
Institute of Science and Technology

論文番號 : 94223

接受日字 : 1994年 8月 26日

I. 서 론

신경회로망은 대규모 병렬처리, 많은 자유도, 비선형 특성, 적응학습, 일반화 특성 등의 장점을 가지므로 신호처리, 패턴인식, 음성인식, 비선형 시스템의 적응제어 등 여러 분야에서 응용되고 있다. 또한 기존의 방법으로 구현하기 힘든 문제들에 대해 엄밀한 수학적 해석에 의한 모델링이나 시스템에 대한 구체적인 정보 없이도 주어진 문제들을 해결할 수 있다. 특히 입력과 출력의 관계는 알고 있으나 적합한 알고리즘이 알려져 있지 않을 때 사용할 수 있다⁽¹⁾.

따라서 많은 양의 데이터를 다루어야 하는 영상분야에서는 신경회로망이 매우 유용하다 전체적인 경향을 살펴보면, 크게 세가지로 나누어 볼 수 있다. 첫째, 기존의 신경회로망인 다층구조 퍼셉트론(multilayer perception:MLP)이나 SOFM(self organizing feature map)이나 Hopfield Networks 등을 이용하여 영상압축에 이용하는 것, 둘째, 새로운 신경회로망을 만들어 좀더 효과적으로 압축하는 것, 셋째, 신경회로망을 영상압축의 주부분으로 사용하기보다는 전처리(영상분리기 등)나 후처리(필터 등)에 이용하는 것이다. 첫번째 예로, MLP는 영상데이터를 압축된 데이터인 은닉층의 출력으로 변환시킴으로 영상이 갖고 있는 공간적 중복성(spatial redundancy)을 제거하는 영상압축 분야에 사용되고 있다. 즉 Sonehara 등⁽²⁾은 하이퍼큐브 병력 컴퓨터로 DCT(Discrete Cosine Transform)를 이용하여 신경회로망의 초기 연결강도(weight)를 DCT계수로 하여 영상압축을 하였고, Marsi 등⁽³⁾은 DCT를 이용하여 블러를 나누고, 이들 각각의 부호를 만들어 영상압축을 하였으며, Arduini 등⁽⁴⁾은 입력영상블러를 종류로 나누고 블러크기를 $16 \times 16, 8 \times 8$ 로 나누어 적응적 압축을 하였다. 또한 Park 등⁽⁵⁾은 영상을 부표본화(Subsampling)하여 압축율을 높이려고 하였고, Cho 등^(6,7)은 인간의 시각특성에 따라 영상블러를 나누고 은닉층의 부호화 방법을 제안하였다. 그러나 전체적으로 아직까지 성능에 있어 만족스런 결과를 얻지 못했다.

영상은 크게 정지영상과 동영상으로 나눌 수 있는데, 현재 사용되고 있는 정지 영상압축의 국제 표준으로 되어 있는 JPEG(Joint Photographic

Expert Group)⁽⁸⁾은 기본적으로 Discrete Cosine Transform(DCT)을 이용하여 영상압축하는 것으로, 압축률이 약 20~30:1까지 좋은 성능을 나타내고 있으나 그 이상의 높은 압축률은 알고리즘에 한계가 있다. 또 다른 대표적인 것으로 Vector Quantization (VQ)⁽⁹⁾이 있다. 이는 영상블러를 하나의 벡터로 보고 이를 코드화하여 영상압축하고자 하는 것으로 일반적으로 높은 압축률을 얻을 수 있다. 그러나 성능에서는 JPEG이 좋은 성능을 보이는 영역에서는 JPEG보다 떨어지며, 높은 압축률을 요구할 경우 화질의 저하가 심하다. 따라서 높은 압축률을 얻으며 화질 저하가 기존 방법보다 심하지 않은 방법을 연구하는 것이 필요하다.

[6,7]에서 영상 블러를 분류 알고리즘을 사용하여 클래스로 나누어 적응적 압축을 하는 방법을 제안하였는데, 여기서는 압축 데이터의 효과적인 전송과 압축률을 높이기 위해 entropy coding을 사용하였다. 그러나 이것은 압축률에 한계가 있어 높은 압축률을 얻지 못한다. 따라서 본 논문에서는 entropy coding 대신에 VQ, 혹은 신경회로망의 하나인 SOFM(self organizing feature map)을 사용한 하이브리드 모델을 이용하여 높은 압축률을 얻도록 한다. 이를 기준 방법과 비교하여 효율성을 보인다.

논문의 전체 구성은 2장에서는 영상압축에 이용하는 MLP와 SOFM을 이용한 하이브리드 모델을 보이며, 3장에서는 제안한 영상압축 및 복원과정을 보이며, 4장에서는 시뮬레이션 결과 및 비교 분석을, 끝으로 5장에서 결론을 맺도록 한다.

II. MLP와 SOFM을 이용한 하이브리드 모델

영상압축에서 다층구조 퍼셉트론은 영상의 중복성을 줄이기 위해 사용되며, 학습은 일반적으로 많이 쓰이는 오류 역전파(error back-propagation) 알고리즘을 사용한다.⁽¹⁰⁾ 데이터 압축과 구현의 용이성을 위해 단순한 2층 신경회로망을 사용하며, 은닉층에 있는 뉴런수는 입력층의 뉴런수보다 적어야 한다.

코호넨(kohonen)의 SOFM은 다른 신경회로망과 달리 계층적인 시스템이 아니며, 그림 1에서 보는 바와 같이 2개의 층으로 이루어져 있다⁽¹⁰⁾. 이 네트워크의 첫번째 층은 입력층이고 두번째 층은 출력으로 경

쟁층(competitive layer)인데 2차원의 격자(grid)로 이루어 진다. 모든 연결들은 첫번째 층에서 두번째 층의 방향으로 되어 있는 완전 연결이다. 코호넨의 학습에서 각 뉴런은 연결강도(weight) 벡터와 입력 벡터가 얼마나 가까운지를 계산한다. 그리고 각 출력 뉴런들은 서로 경쟁하는데 거리가 가장 가까운 뉴런이 승리하게 된다. 이 승자 뉴런이 출력 신호를 보낼 수 있는 유일한 뉴런이다. 또한 이 뉴런과 인접한 이

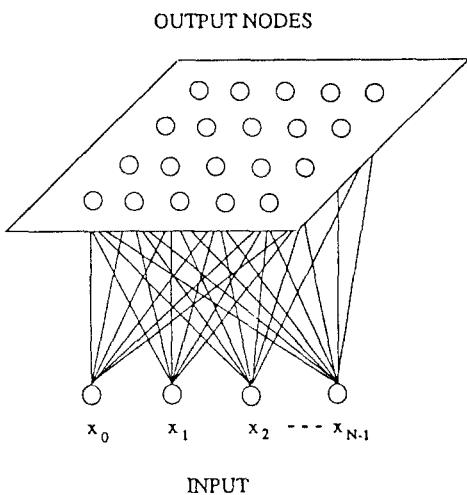


그림1. 영상압축에 이용되는 Self Organizing Feature Map(SOFM)
 Figure1. Self Organizing Feature Maps(SOFM) for image compression.

웃 뉴런들만이 제시된 입력벡터에 대하여 학습된다. 즉 코호넨 네트워크의 학습 방법은 ‘승자 독점(winner take all)’이다. 승자만이 출력을 낼 수 있으며, 승자와 그의 이웃들만이 그들의 연결강도를 조정할 수 있다.

제안한 하이브리드 모델⁽¹¹⁾은 그림 2와 같이 MLP의 은닉층에 SOFM을 결합한 형태이다. 따라서 MLP로 영상압축을 하고 압축된 은닉층의 값을 다시 SOFM으로 코딩하여 압축률을 높이는 것이다. 학습 알고리즘은 계층학습방법으로 먼저 오차 역전파 알고리즘으로 MLP을 학습하고, 이를 이용하여 은닉층의 값을 입력으로 하는 SOFM을 학습한다.

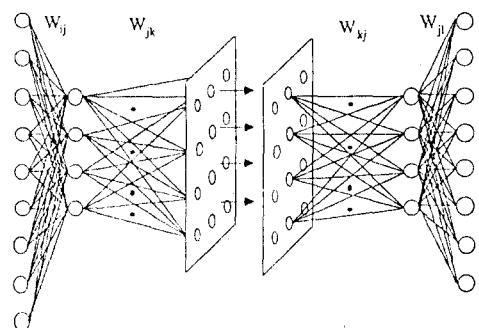


그림2. MLP와 SOFM을 같이 쓰는 복합구조
Figure2. Hybrid structure using MLP and SOFM.

III. 영상압축 및 복원과정

제안한 영상압축 및 복원 과정은 그림 3과 같다. 전체적으로 살펴보면, 압축과정은 먼저 영상을 8×8 픽셀 크기의 블럭으로 나누어서 전처리 과정으로 블럭을 분류한다. 다음 MLP의 입력으로 정규화하고 은닉층의 값으로 양자화되어 압축된다. 압축률을 더 높이기 위해 은닉층의 값을 VQ이나 SOFM을 사용하여 코딩한다. 이는 [6, 7]에서 제안한 방법에서 코딩 부분이 다르고 나머지는 유사하다.

복원과정은 압축과정의 역순으로 코딩된 신호를 디코딩(decoding)하여 그 값을 신경회로망의 후단을 통과하여 최종적으로 복원된 영상을 얻는다.

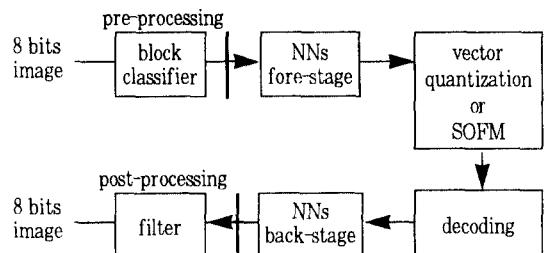


그림3. 영상 압축 및 복원과정
Figure3. Image compression/reconstruction process.

1. 전처리

인간시각의 민감도에 따라 영상의 복잡도 (complexity)를 고려하여 블럭을 분류하고, 이에 따라 2층 구조 신경회로망의 은닉층의 수를 다르게 하여 적응적으로 영상압축을 할 수 있게 하는 단계다.⁽⁷⁾

분류 알고리즘을 간단히 설명하면, 수평, 수직 방향의 경사도(gradient)로 인접한 화소간의 명암도 차이를 이용하여 블럭내의 모서리(edge)성분이 얼마나 있는가에 따라 블럭을 종류로 나누는 것으로, 먼저 영상을 8×8 블럭으로 나누고 수평, 수직 방향의 경사도로 인접한 화소간의 명암도 차이를 정규화한 값을 평탄(shade)과 모서리 성분으로 구분하는 임계값(threshold) T_e , T_s 을 정하고 그 블럭내 각 화소간에 이 값이 얼마나 있는지를 나타내는 카운터가 있어 이 카운터 값을 이용하여 실험에 의해 정해진 임계값 J_s (평탄 성분 갯수), J_e (모서리 성분 갯수)에 의해 네 클래스로 구분된다.^(6,7)

이 알고리즘을 사용하여 영상블럭은 4개의 클래스(Shade, Complicated, Edged, Midrange)로 구분된다. 이를 이용하여 Lena 영상에서 블럭을 분류한 예를 그림 4에 보였다. 여기서 Shade 블럭은 블럭전체가 눈으로는 gray레벨이 블럭 평균값으로 보이는 것으로 압축시 평균값만 보내면 된다. 이는 어느 한 픽셀이 주위 픽셀과 차이가 심하지 않을 때 인간이 감지하지 못한다는 웨버의 법칙(Weber's law)⁽¹²⁾을 이용한 것이다. Complicated 블럭은 영상 특성이 가장 복잡한 것으로 수평, 수직, 대각선 edge들이 섞여있는 블럭이고, Edged 블럭은 수평, 수직, 대각선 edge 중 한 형태만 존재하는 것이다. 나머지 Midrange 블럭은 edge가 없고 Shade 블럭이 아닌 것으로, Shade 와 Midrange 블럭의 구분은 주위 배경에 비해 밝기 차이가 Weber fraction(약 0.02~0.025)보다 작고 큼에 따라 분류된다.^(6,7)

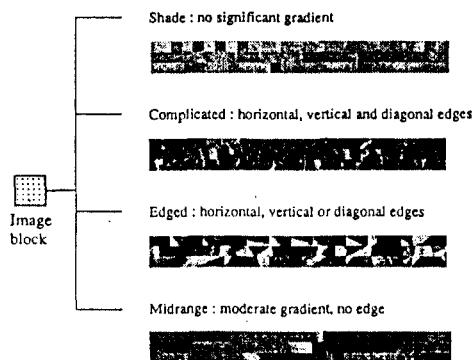


그림4. 분류된 블럭 예

Figure4. Examples of the classified blocks.

2. 매핑(mapping)

MLP을 학습시키기 위해 입력값의 동적범위를 정규화한다. 실험에서는 픽셀당 0~255 레벨을 -1~1로 정규화하였다.

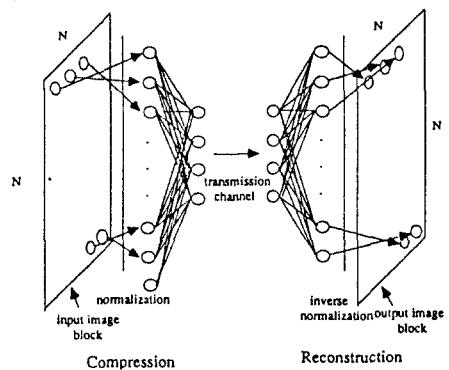


그림5. 분류된 블럭 예

Figure5. Structure for the mapping stage.

그림 5는 매핑 구조를 나타내는 것으로, 정규화된 영상블럭은 신경회로망의 입력층의 입력으로 되고, 출력층에서 복원된 영상블럭을 얻을 수 있다. 여기서 Shade 클래스는 앞에서 언급했듯이 신경회로망이 필요없고 Complicated 클래스는 8개의 은닉 뉴런, Edged 클래스는 6개의 은닉 뉴런, Midrange 클래스는 4개의 은닉 뉴런을 각각 사용했다. 물론 이 값들은 압축률을 고려하여 조정할 수 있다.

3. 부호화

부호화는 VQ 또는 SOFM을 사용하였다. VQ의 경우 은닉층 출력은 -1에서 1이므로 이를 6비트로 양자화된 값을 사용하고, SOFM의 경우는 MLP의 은닉층의 값을 양자화하지 않고 그대로 사용한다. 물론 SOFM에 양자화된 값을 사용해도 문제는 없으나 신경회로망의 특성상 양자화하지 않은 데이터를 사용하면 좀더 나은 효과를 얻을 수 있다. 또한 양자화기를 이용하지 않으면, 이것이 VQ를 사용하는 것보다 장점이 될 수 있다.

1) 벡터 양자화(VQ)

VQ는 신경회로망의 은닉층의 출력을 하나의 코드

로 보고 이를 LBG 알고리즘^[13]을 이용하여 부호책을 만들어 사용했다. 전체적인 블럭 다이어그램은 다음 그림 6과 같다.

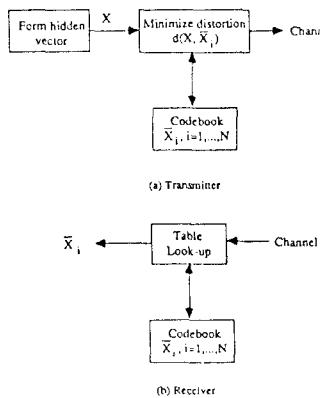


그림6. VQ블럭 다이아그램
Figure6. VQ block diagram.

2) Self Organizing Feature Map(SOFM)

신경회로망 중에서 VQ에 대응하는 모델이 앞에서 설명한 SOFM으로, VQ 대신에 사용할 수 있다. SOFM은 신경회로망 모델 중 하나로 자율 학습(unsupervised learning)을 하는 것이다. 이의 학습율과 이웃반경은 다음 식 (1)와 식 (2)과 같은 linear scale로 줄어드는 것을 사용했다.

$$\text{학습율 } \alpha = (\text{initial}\alpha - \text{initial}\alpha \times \frac{\text{itr}}{\text{ibnd}})$$

$$\text{neighborhood} = (\text{initialbound} - \text{initialbound} \times \frac{\text{itr}}{\text{ibnd}})$$

여기서 itr은 학습 반복수이고, ibnd는 학습 반복 제한수이다.

IV. 시뮬레이션 결과 및 비교 분석

1. 총실도(성능 비교 기준) 와 압축률

영상에서 각 화소는 m개의 비트로 된 2^m 의 명암도를 가진다. 영상의 객관적인 비교를 위해서 오차측정은 식(3)의 $N \times N$ 입력영상과 $N \times N$ 출력영상 사이의 MSE(mean-square-error)와 식(4)의 peak 신호대 잡음비(peak signal to noise ratio:PSNR)로

나타낸다.

$$MSE = \frac{1}{N^2} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} e^2(x, y) \quad (3)$$

$$PSNR = 10 \log \left(\frac{\sum 255^2}{\sum e^2} \right) \quad (4)$$

압축률은 영상의 전체 비트수를 압축된 비트수로 나누면 되는데, 일단 블럭 분류기를 사용한 경우, 각 블럭 당 $\log_2 \text{class \#}$ 의 비트가 추가되므로 블럭 당 2비트씩 더 소요된다.

VQ를 사용한 경우는 식 (5)와 같고, SOFM을 이용한 경우는 식 (6)과 같다. 다음 식에서 N^2 은 블럭 크기이며 N_i 는 입력영상의 픽셀 비트수이다. V_{class} 는 각 클래스 별로 VQ의 codebook의 크기를 나타내는 비트수이고 클래스 1인 Shade인 경우는 8bits이고, 마찬가지로 S_{class} 는 SOFM의 출력뉴런수를 비트로 나타낸 것이다.

$$CR_{\text{vq}} = \frac{\sum_{\text{block}} (N^2 \times N_i)}{\sum_{\text{block}} (V_{\text{class}} + \log_2 \text{class \#})} \quad (5)$$

$$CR_{\text{sofm}} = \frac{\sum_{\text{block}} (N^2 \times N_i)}{\sum_{\text{block}} (S_{\text{class}} + \log_2 \text{class \#})} \quad (6)$$

2. 시뮬레이션 결과

사용된 영상으로는 그림 7에 보인 256 gray 레벨을 갖고 크기가 512×512인 Lena, Bridge, Boat, Train 영상을 사용하였다. 전체 시뮬레이션은 학습 할 영상을 8×8 블럭으로 나누어 학습하고 그것을 학습된 영상과 다른 영상에 적용하였다.

먼저 블럭 분류기를 사용하여 학습영상으로 Lena 영상블럭을 분류하여 MLP로 학습한 후에, [6, 7]에서는 은닉층의 출력값을 entropy coding을 이용하여 압축률을 높였는데, 이제는 VQ를 이용하여 codebook을 만들어 코딩을 한다. VQ의 학습 데이터는 Lena, Bridge의 각 영상블럭의 MLP 은닉 뉴런 값을 이용했다. 그 이유는 Lena만을 사용할 경우 각 클래스의 데이터가 부족하여 효과적인 VQ가 되지 못하기 때문에 학습 데이터로 두 영상을 선택했다. 알고리즘은 앞에서 언급한 LBG 알고리즘을 사용했다. 각 클래스의 codebook 크기는 1024 words, 즉 $V=10$ bits이다.



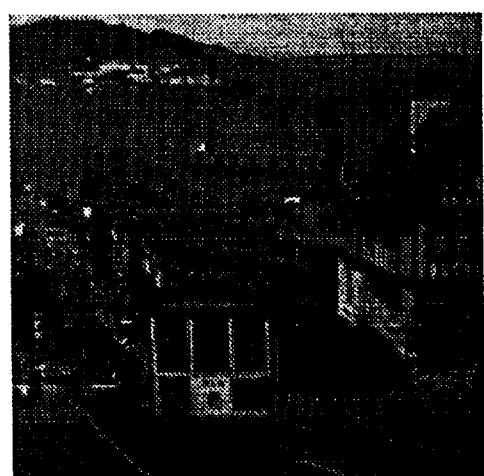
(a)



(b)



(c)

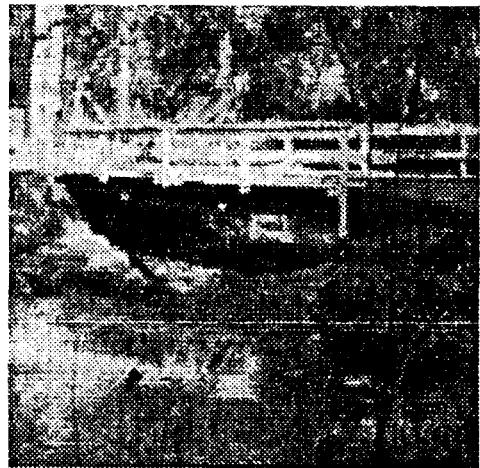


(d)

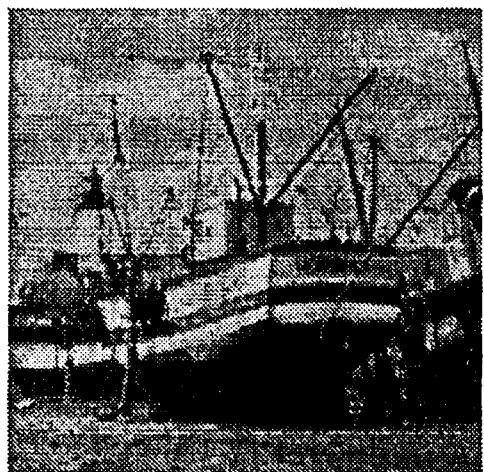
그림7. 시뮬레이션에서 사용한 영상
Figure7. Original images in simulation
(a)Lena (b)Bridge (c)Boat (d)Train



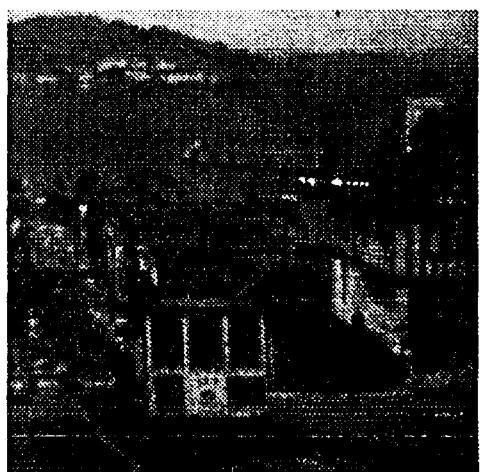
(a)



(b)



(c)



(d)

그림8. 블럭 분류기와 VQ을 이용하여 복원된 영상
Figure8. Reconstructed image using block classifier and VQ
(a)Lena(PSNR:28.583, CR:39.04:1)
(b)Bridge(PSNR:22.937, CR:28.90:1)
(c)Boat(PSNR:26.448, CR:38.42:1)
(d)Train(PSNR:28.772, CR:40.70:1)

표1. 블럭 분류기와 VQ를 동시에 이용하여 영상압축한 결과
Table1. Results for reconstructed images with block classifier and VQ.

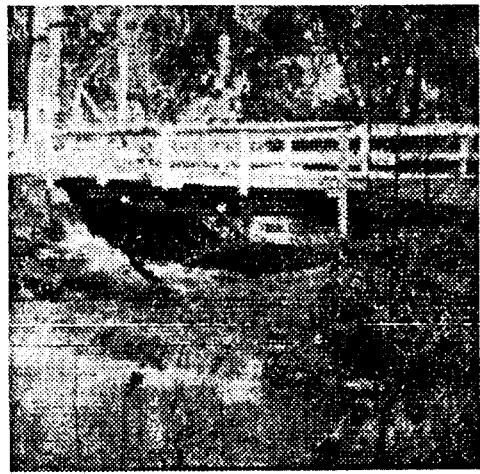
Image	MSE		PSNR: (dB)		Compression Ratio (CR _{VQ})	
	class2 4×1	class2 8×1	class2 4×1	class2 8×1	(class2:4×1)	(class2:8×1)
Trained Lena	84.67	105.29	28.853	27.907	39.04:1(0.20bpp)	43.82:1(0.18bpp)
Trained Bridge	330.68	396.19	22.937	22.151	28.90:1(0.28bpp)	42.87:1(0.19bpp)
Boat	147.34	187.84	26.448	25.392	38.42:1(0.21bpp)	45.15:1(0.18bpp)
Train	86.28	97.98	28.772	28.219	40.70:1(0.20bpp)	43.57:1(0.18bpp)

표2 블럭 분류기와 SOFM를 이용하여 영상압축한 결과
Table2. Results for reconstructed images with block classifier and SOFM.

Image	MSE		PSNR: (dB)		Compression Ratio (CR _{SOFM})	
	class2 4×1	class2 8×1	class2 4×1	class2 8×1	(class2:4×1)	(class2:8×1)
Trained Lena	79.77	89.89	29.112	28.594	39.04:1(0.20bpp)	43.82:1(0.18bpp)
Trained Bridge	299.99	325.06	23.306	23.011	28.90:1(0.28bpp)	42.87:1(0.19bpp)
Boat	141.39	162.64	26.627	26.016	38.42:1(0.21bpp)	45.15:1(0.18bpp)
Train	75.34	89.78	29.361	29.004	40.70:1(0.20bpp)	43.57:1(0.18bpp)



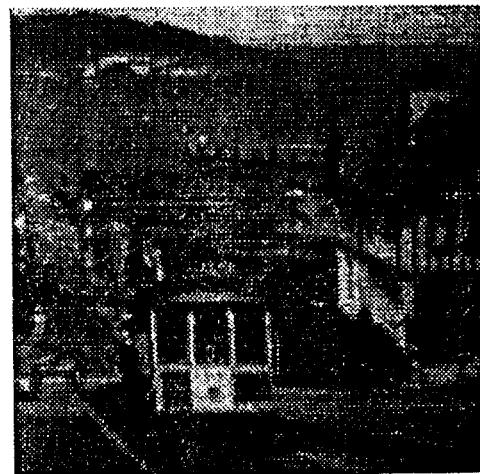
(a)



(b)



(c)



(d)

그림9. 블럭 분류기와 SOFM을 이용하여 복원된 영상

Figure9. Reconstructed image using block classifier and SOFM

(a)Lena(PSNR:29.112, CR:39.04:1)

(b)Bridge(PSNR:23.360, CR:28.90:1)

(c)Boat(PSNR:26.627, CR:38.42:1)

(d)Train(PSNR:28.361, CR:40.70:1)

표 1은 블럭 분류기와 VQ를 사용하여 나온 결과로, 클래스 2인 Complicated는 2개의 4×1 이나 한 개의 8×1 , 클래스 3인 Edged는 6×1 , 클래스 4인 Midrange는 4×1 을 codebook의 입력벡터로 각각 사용했다. 그럼 8은 블럭 분류기와 VQ를 이용하여 압축, 복원된 영상 예를 보인 것이다.

다음은 VQ 대신에 SOFM을 사용한 결과이다. SOFM은 신경회로망 모델 중 하나로 자율 학습을 하는 것으로 VQ에 대응되는 모델이다. 초기 학습율은 0.5이고 초기 이웃반경(neighborhood bound)은 일차원 상에서 ± 20 이다. 입력뉴런은 VQ의 입력벡터 크기와 같고, 출력뉴런의 수도 1024이다. 즉 $S=10$ bits이다.

표 2은 블럭 분류기와 SOFM를 동시에 이용하여 영상압축한 결과이다. 그림 9는 블럭 분류기와 SOFM을 이용하여 압축, 복원된 영상 예이다. 표1과 2에서 class2는 종류 2의 경우 부호체의 입력벡터로 2개의 4×1 과 한 개의 8×1 의 벡터를 각각 쓴 경우를 비교한 것이다.

3. 비교 분석

그림 10은 기존의 영상압축 알고리즘과 비교하기 위하여 Lena영상을 사용한 결과이다. 기존의 영상압축 알고리즘으로는 정지영상의 국제 표준인 JPEG⁽⁶⁾, VQ로는 비교적 좋은 성능을 보이는 Interpolative /Residual VQ(I/RVQ)⁽¹⁴⁾을 사용하였다. 간단히 I/RVQ에 대해 설명하면, 영상블럭을 subsampling하여 복원하고 원래 영상에서 복원된 영상을 뱃나머지(residue) 영상을 VQ를 이용해 코딩하는 것으로 blocking effect가 적게 생기고 압축률과 성능이 비교적 좋게 나오는 방법이다.

그림 10에서 N은 neural networks, E는 entropy coding, B는 block classifier, V는 vector quantization, SOFM은 self organization feature map을 각각 나타낸다. 한 예로 BNV는 블럭 분류기와 신경회로망, 그리고 은닉층의 값을 양자화한 것이다. 그림에서 N.Ns, NNE, BN, BNE는 비교를 위하여 같이 보였다^(6,7).

그림 10에서 보듯이 신경회로망(N.Ns)을 이용한 경우 JPEG과 VQ에 비해 성능이 많이 저하되

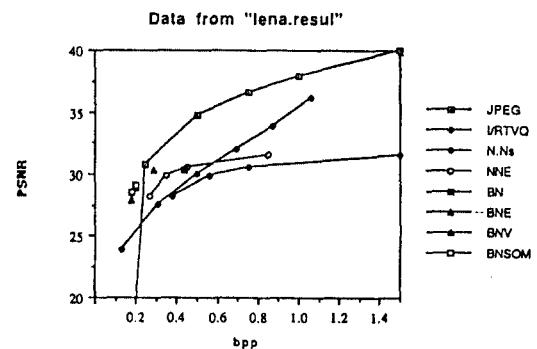


그림10. Lena영상을 이용한 결과
Figure10. Results for Lena image.

며, 여기에 entropy coding을 이용한 NNE는 약 0.6 bpp(bit per pixel)이하에서는 I/RVQ보다 성능이 좋아짐을 볼 수 있다. 블럭을 나누는 방법(BN)은 NNE와 비슷한 성능을 나타내나 지금까지의 성능은 대표적인 VQ보다 성능이 좋게 나타났으나 아직 JPEG보다는 성능이 떨어진다. 즉 같은 압축률에서 PSNR이 VQ보다는 높고 JPEG보다는 낮다. 블럭 분류와 entropy coding을 같이 쓴 BNE는 거의 JPEG과 비슷한 성능을 보였으나 아직 압축률이 25:1 정도로 한계를 보인다.

VQ을 쓴 BNV는 JPEG이 동작하지 않는 영역에서 좋은 성능을 보임을 알 수 있고 VQ에 대응하는 SOFM을 쓴 경우(BNSOFM) 좀 더 좋은 효과를 나타낼 수 있다. 그 이유를 생각하면 첫째, SOFM을 이용한 경우 은닉층의 출력을 양자화하지 않고 바로 이용함으로 양자화에 따른 오차를 줄일 수 있고 둘째, SOFM이 VQ와는 다른 local operation으로 은닉층 출력의 통계적 특성을 더 잘 표현하기 때문으로 생각된다.

전체적으로 살펴보면, 제안된 영상압축구조가 VQ 보다 좋은 성능을 보이고 JPEG가 동작하지 않는 영역에서도 좋은 성능을 보임을 알 수 있다. 즉 신경회로망을 이용한 영상압축이 40:1 이상의 높은 압축률을 요구하는 영역에서 유용하게 나타나므로 이 영역에서의 성능 향상과 용용을 고려할 수 있다. 특히 신경회로망을 이용한 MLP와 SOFM을 같이 쓰는 hybrid구조가 높은 압축률을 요구하는 영역에서 좋은 성능을 나타냄을 보였다. 이 구조에서 MLP를 기

존의 방법으로 학습하고 은닉층의 출력을 다시 SOFM으로 학습한 후 이를 hybrid로 연결하여 재학습을 하면 더 좋은 효과를 낼 수 있을 것이다.

V. 결 론

본 논문에서 전처리로 블럭 분류기, 코딩으로 VQ, SOFM을 이용하여, MLP를 이용한 새로운 영상압축 및 복원 방법을 제안하여 영상데이터 압축 성능과 일반화 특성을 시뮬레이션을 통해 보였다. 특히 학습에는 시간이 오래 걸리나, 간단한 구조를 갖고 있어 실제 사용에 있어서는 실시간 처리가 가능하며, 하드웨어 구현도 용이하다.

시뮬레이션에서 VQ나 SOFM을 이용하여 약 40:45:1의 높은 압축률을 얻었고 이를 기존의 방법과 비교하여 높은 압축률에서 VQ보다 성능이 좋고, JPEG이 동작하지 않는 영역에서 좋은 성능을 나타낸다. 또한 MLP와 SOFM을 같이 쓰는 hybrid 구조를 제안하여 높은 압축률을 요구하는 영상압축에서의 유용성을 보였다.

앞으로 할 일은 제안된 구조를 바탕으로 압축 효율을 높히고 칼라영상압축, 비디오 코딩에 적용해 보는 것이다.

참 고 문 헌

1. C.H. Park, "Neuro-fuzzy information processing," Proc. of 91' Korean Scientist and Engineer Summer Symposium, pp. 90-94, Seoul, Korea, 1991.
2. N. Sonehara, M. Kawato, S. Miyake, and K. Nakane, "Image Data Compression Using a Neural network Model," IJCNN, vol.2, pp. 35-40, Washington, 1989.
3. S. Marsi, G. Ramponi and G.L. Sicuranza, "Improved Neural structures for Image Compression," ICASSP, vol.4, pp. 2821-2824, Toronto, 1991.
4. F. Arduini, S. Fioravanti and D. Giusto, "Adaptive Image Coding using Multilayer neural Networks," ICASSP, vol.2, pp. 381-384, San Francisco, 1992.
5. C. H. Park and K. B. Cho, "Image Compression using Neural Networks and Sub-sampling," Proc. of JNNS, pp. 195-196, Iizuka, Japan, 1993.
6. K. B. Cho, C. H. Park, and S. Y. Lee, "Classified Image Compression and Coding using Neural Networks," Proc. of APCC, pp. 414-417, Taejon, Korea, 1993.
7. K.B. Cho, C.H. Park, and S.Y. Lee, "Classified Image Compression and Coding using Multi-Layer Perception," submitted to KICS.
8. "JPEG technical specification: Revision (DRAFT), joint photographic experts group, ISO/IEC JTC1/SC2/WG8, CCITT SGVII," August 1986.
9. A. Gersho and R.M. Gray, Vector Quantization and Signal Compression, Kluwer, Norwell, MA, 1992.
10. K. B. Cho, C. H. Park, and S. Y. Lee, "Image Compression using Multi-Layer Perception with Block Classification and SOFM Coding," Proc. of WCNN., San Diego, USA, 1994.
11. R.P. Lippmann, "An Introduction to Computing with Neural Nets," IEEE ASSP magazine, pp. 4-22, April 1987.
12. J. S. Lim, Two-Dimensional Signal and Image Processing, Prentice-Hall, USA, 1990.
13. Y. Linde, A. Buzo, and R. Gray, "An Algorithm for Vector Quantizer Design," IEEE Trans. Commun., vol. COM-28, no. 1, pp. 84-95, Jan. 1980.
14. M. Rabbani and P. W. Jones, Digital Compression Techniques, SPIE, Washington, 1991.



趙廣輔(Kwang Bo Cho) 정희원
1966년 12월 4일생
1992년 2월 : 서강대학교 전자공학과
졸업(공학사)
1994년 2월 : 한국과학기술원 전기
및 전자공학과 졸업(석
사)
현재 : LG전자기술원 근무중



朴哲薰(Cheol Hoon Park) 정희원
1961년 4월 14일생
1984년 2월 : 서울대학교 전자공학과
(학사)
1985년 6월 : California Institute
of Technology(석사)
1990년 6월 : California Institute
of Technology(박사)
1991년 3월~1992년 4월 : KIST대우교수 겸 연구연수원
1983년 5월~현재 : 한국과학기술원 전기 및 전자공학과 조교수



李壽永(Soo Young Lee) 정희원
1952년 10월 15일생
1975년 : 서울대학교 전자공학과 졸
업(학사)
1977년 : 한국과학원 전기 및 전자공
학과 졸업(석사)
1984년 : Polytechnic Institute
of New York 졸업(박사)
1977년~1980년 : 대한엔지니어링(주) 과장대리
1982년~1985년 : General Physical Corp. Staff/senior
Scientist
1986년~현재 : 한국과학기술원 전기 및 전자공학과 교수

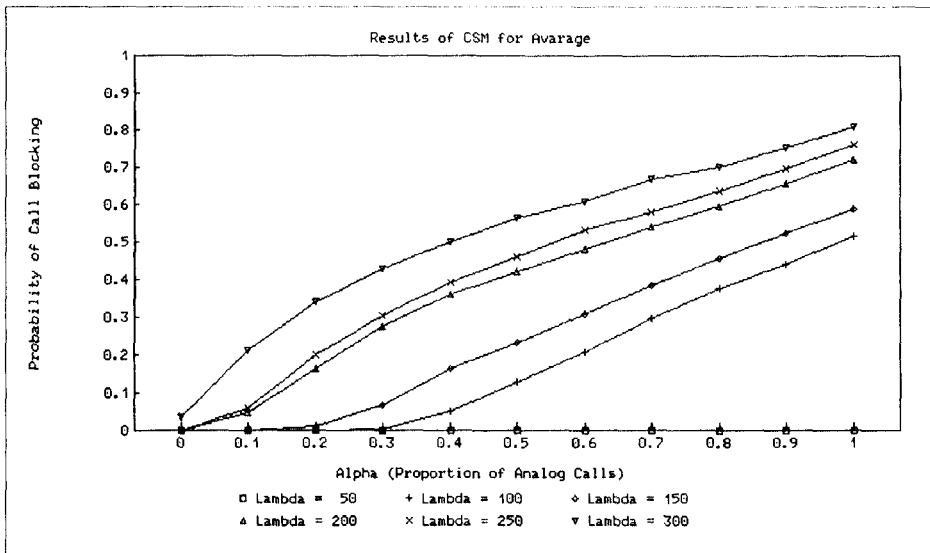


그림 15. 통화량에 따른 채널 공유 방법의 총 호손률

Fig. 15. Probability of average call blocking for channel sharing method with the traffic

있게 된다.

V. 결 론

이동 통신망의 사용량 급증에 따라 필요로 되는 채널 부족 문제를 해결하기 위한 노력이 많이 진행되어 왔다. 같은 주파수 채널을 재사용할 수 있는 셀룰라 시스템이 구성되었고, 보다 많은 호를 처리하기 위한 디지털 시스템으로의 전환이 추진되고 있다. 디지털 시스템으로의 완전한 전환 이전에 필요한 것이 A/D 이동 통신망이다.

본 연구에서는 A/D 이동 통신망에서 효율적인 채널 할당 기법으로서 채널 공유 방법을 제안하였다. 이 방법의 목적은 전체적인 호손률의 향상보다는 무엇보다 기존의 아날로그 단말기 사용자를 위한 아날로그 호의 손률을 향상시키기 위한 것이다. 제안한 방법의 기본이 되는 셀룰라 시스템에서의 채널 할당 기법을 제시하였다. 기존의 A/D 이동 통신망의 채널 할당을 위한 기법에 대한 제시와 성능 분석을 하였다.

채널 공유 방법에서는 기존의 기법에서와는 달리 아날로그 호와 디지털 호가 셀 내에서 사용 가능한 모든 채널을 공유하여 사용할 수 있도록 함으로써, 기존의 기법과는 다른 결과를 보여주었다. 아날로그 호에

대한 보다 좋은 결과를 나타내었다. 각 유형의 호에 대한 보다 유연한 채널 할당이 가능하게 되어 시스템의 적용성을 가져왔다. 따라서 채널 공유 방법은 디지털 시스템으로의 완전한 전환 이전에 기존의 아날로그 서비스 사용자에게 편의를 제공할 수 있도록 사용할 수 있는 채널 할당 방법이라고 할 수 있다.

참고문헌

1. Apostolos K. Kakaoes, "Channel Allocation Strategies in Dual Mode Digital Cellular Networks," Proceedings of the IEEE Globecom '90, pp. 1553-1558, 1990.
2. David Everitt and David Manfield, "Performance Analysis of Cellular Mobile Communication Systems with Dynamic Channel Assignment," IEEE Journal on Selected Areas in Communications, Vol. 7, No. 8, pp. 1172-1180, OCT. 1989.
3. Jun Tajima and Kenji Imamura, "A Strategy for Flexible Channel Assignment in Mobile Communication Systems," IEEE Transactions on Vehicular Technology, Vol. 37, No. 2,

- pp.92-103, MAY 1988.
4. Ming Zhang and Tak-Shing P. Yum, "The Nonuniform Compact Pattern Allocation Algorithm for Cellular Mobile Systems," *IEEE Transactions on Vehicular Technology*, Vol.40, No.2, pp.387-391, MAY 1991.
5. Ming Zhang and Tak-Shing P. Yum, "Comparisons of Channel-Assignment Strategies in Cellular Mobile Telephone Systems," *IEEE Transactions on Vehicular Technology*, Vol.38, No.4, pp.211-215, NOV. 1989.
6. Said M. Elnoubi, Rajendra Singh, Someshwar C. Gupta, "A New Frequency Channel Assignment Algorithm in High Capacity Mobile Communication Systems," *IEEE Transactions on Vehicular Technology*, Vol.31, No.3, pp.125-131, AUG. 1982.
7. William C. Y. Lee, "Spectrum Efficiency in Cellular," *IEEE Transactions on Vehicular Technology*, Vol.38, No.2, pp.69-75, MAY 1989.
8. William C. Y. Lee, "New Cellular Schemes for Spectral Efficiency," *IEEE Transactions on Vehicular Technology*, Vol.36, No.4, pp.188-192, NOV. 1987.
9. William C. Y. Lee, *Mobile Cellular Telecommunications Systems*, McGraw-Hill, 1989.
10. 김재주, 조신섭, 김병천, 컴퓨터를 이용한 통계학, 경문사, 1992.
11. 조광문, 김태윤, "아날로그/디지털 시스템의 효율적인 채널 할당 기법," 정보과학회 학술발표논문집, 제21권, 제1호, pp.451-454, 1994.4.



趙 光 門 (Kwang Moon Cho)

1988년 : 고려대학교 전산과학과(학사)
1991년 : 고려대학교 전산과학과(석사)
1993년 : 고려대학교 전산과학과 박사
과정 수료



金 泰 潤 (Tai Yun Kim)

1981년 : 고려대학교 산업공학과(학사)
1983년 : 미국 Wayne State Univ. 전
산과학과(석사)
1987년 : 미국 Auburn University 전
산과학과(박사)
1988년~현재 : 고려대학교 전산과학과
교수