

SOFM 벡터 양자화와 프랙탈 혼합 시스템의 영상 왜곡특성 향상에 관한 연구

A Study on the Enhancement of Image Distortion for the Hybrid Fractal System with SOFM Vector Quantizer

김 영 정, 김 상 희, 박 원 우
Yung-Jung Kim, Sang-Hee Kim, Won-Woo Park

요 약

프랙탈 영상압축은 원영상블록과 가장 유사한 영역을 원영상 내에서 찾는 자기유사성에 기반한 축소변환을 이용하여 영상데이터를 압축시키는 방법이다. 프랙탈은 영상데이터를 압축하는 효율적인 방법으로 인정을 받고 있으나 상대적으로 높은 영상 왜곡률과 부호화 시간이 오래 걸리는 단점을 가지고 있다. 본 논문은 프랙탈의 영상 왜곡률 특성을 개선하기 위하여 프랙탈과 벡터양자화를 혼합하였으며, 벡터양자화의 클러스터링 알고리즘으로는 개선한 Self Organizing Feature Map(SOFM)을 사용하였다. 제안된 시스템의 성능평가를 위하여 일반적인 SOFM을 사용한 시스템 그리고 프랙탈을 단독으로 사용한 시스템과 비교하여 전체적인 성능 향상 정도를 확인하였다. 그 결과 개선한 경쟁학습 SOFM을 사용한 벡터양자화와 프랙탈 혼합시스템이 일반적인 SOFM을 사용한 벡터양자화와 프랙탈 혼합시스템보다 영상 왜곡특성이 향상된 것을 확인하였다.

ABSTRACT

Fractal image compression can reduce the size of image data by the contractive mapping that is affine transformation to find the block(called as range block) which is the most similar to the original image. Even though fractal image compression is regarded as an efficient way to reduce the data size, it has high distortion rate and requires long encoding time. In this paper, we presented a hybrid fractal image compression system with the modified SOFM Vector Quantizer which uses improved competitive learning method. The simulation results showed that the VQ hybrid fractal using improved competitive learning SOFM has better distortion rate than the VQ hybrid fractal using normal SOFM.

Key words: Fractal, Vector Quantization, Image compression, Clustering, SOFM

I. 서론

급속도로 발전이 이루어지고 있는 현재의 네트워크 환경에서는 많은 양의 영상데이터를 저장하고 전송하기 위하여 영상압축을 기본으로 하고 있다. 이러한 영상데이터를 압축하기 위한 방법은 크게 무손실 부호화 방법과 손실 부호화 방법으로 나눌 수 있다. 무손실 부호화기법은 Huffmann 부호화, run-length 부호화 등이 있으며 원영상을 왜곡하지 않고 압축하여 복원된 영상이 원영상과 동일하나 압축률은 매우 낮은 특징이 있다. 반면에 손실

부호화 기법으로는 변환기법, 예측기법, 양자화기법 등이 있으며 인간이 정보를 얻는데 영향을 주지 않는 범위에서 데이터를 제거 혹은 대체하여 복원된 영상이 일정수준의 왜곡을 가지나 높은 압축특성을 가지는 방법이다[1].

손실압축방법인 프랙탈을 이용한 영상압축은 영상내의 자기유사성을 이용하는 것으로서 원영상을 축소한 영상과 원영상사이의 축소변환에 대한 고정점을 얻어서 영상데이터를 반복축소 변환만으로 표현하는 방법이다. 프랙탈은 프랑스의 수학자 Mandelbrot가 제안한 이론으로 복잡한 자연현상들의 전체와 일부분 사이에 강한 자기상관

성이 있다는 이론이다. Barnsley는 프랙탈이론을 영상압축에 적용시킬 수 있음을 처음으로 제시하였고 Fisher, Jacquin, Monro들에 의해서 구현 및 발전되었다[2, 3]. 프랙탈은 높은 압축률에도 복원 영상의 화질을 일정 수준 이상으로 유지하는 부호화 알고리즘으로 평가되고 있으며 기존의 다른 방법에 비해 복호화 시간이 매우 빠르고 간단한 장점을 가지고 있다. 그러나 해이블릿과 같은 최근의 발전된 영상압축 방법과 비교해 보면 상대적으로 떨어지는 영상 왜곡률과 느린 부호화 시간이 단점으로 평가되어 다른 부호화 방법과의 결합 또는 변환부호화 방법으로서의 주목 등으로 이러한 단점들을 극복해보려는 노력이 계속되어왔다[4, 5].

프랙탈의 성능개선을 위한 여러 가지 시도들 가운데 Raouf Hamzaoui는 원영상의 블록과 가장 비슷한 영상을 벡터코드북에서 찾아서 원영상에 근사화 시킨다는 벡터양자화와 프랙탈의 공통점을 기초로 프랙탈을 벡터양자화와 혼합시켰으며, 프랙탈과 벡터양자화기 혼합 시스템이 향상된 영상 왜곡률 특성을 나타내는 것을 보여 주었다[4, 6].

본 논문에서는 프랙탈과 벡터양자화기 혼합시스템의 영상 왜곡률 특성을 향상시키기 위하여 벡터양자화기의 코드북 생성에서 중심적인 역할을 하는 클러스터링 알고리즘으로 기존의 SOFM(Self Organizing Feature Map) 신경망을 대신하여 개선한 경쟁학습알고리즘을 적용시킨 SOFM 신경망을 사용하였다. 제안된 시스템의 성능을 비교하기 위하여 프랙탈 시스템과 벡터양자화기 시스템 그리고 프랙탈과 벡터양자화기 혼합시스템들이 가지고 있는 영상 왜곡률 특성과 제안된 시스템의 영상 왜곡률 특성을 비교하기 위한 실험을 수행하였다.

II. 프랙탈 영상압축

Mandelbrot가 처음으로 제안한 프랙탈 이론은 지구상에 존재하는 불규칙한 자연형상들이 단순한 법칙의 반복으로 표현되어질 수 있다는 개념에 기반을 두었다. 뒤에 Bansley, Jacquin, Monro들에 의해서 영상압축에 적용되었고 현재에 있어서는 효율적인 영상압축 부호화 기법으로 자리잡고 있다. 그러나 부호화 시간이 오래 걸린다는 것과 최근의 발전된 다른 영상압축방법(zero-tree based wavelet)과 비교했을 때 상대적으로 떨어지는 영상 왜곡률 특성을 보인다는 단점들이 프랙탈이 해결해야 할 과제로 남아있다[4, 7]. 이러한 프랙탈 영상압축은 원영상의 한 부분(지역블록)과 가장 유사한 원영상 내의 특정부분(정의역블록)을 찾는 것을 기본으로 하고 있다.

그림 2.1은 프랙탈 영상압축에서 압축하고자하는 지역블록과 가장 유사한 자기영상 내의 일부(정의역블록) 사이의 축소변환을 나타낸다. 부호화와 복호화 알고리즘은 표 2.1과 표 2.2에 설명하였다.

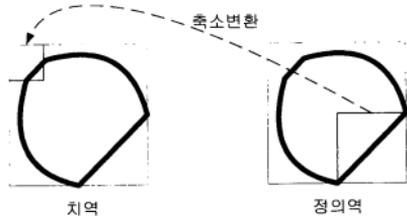


그림 2.2 프랙탈 개념도

표 2.1 부호화 알고리즘

- A. 지역블록구성: 입력영상을 $B \times B$ 블록으로 서로 중첩되지 않게 분할한다. (B : 블록의 크기)
- B. 정의역블록구성: 입력영상을 그림 2.1과 같이 지역블록의 두 배 크기인 $2B \times 2B$ 로 50%중첩 분할한다.
- C. Isometry 적용: 정의역 블록을 지역블록의 크기만큼으로 축소하고 정해진 8가지(원영상, y 축절편, x 축절편, 180도회전, 원점절편, 90도회전, 270도회전, 역원점절편)의 isometry를 적용하여 지역블록과의 오차를 줄인다.
- D. 축소된 정의역블록과 지역블록간의 오차가 최소가 되도록 하는 밝기 조절 변수 O_i 를 구한다. (i : 지역블록 번호)
- E. 이상의 과정을 반복하여 매 지역블록마다 정의역블록 전체를 탐색하여 가장 오차가 작은 정의역블록 번호와 isometry 번호를 구하여 부호화한다.

표 2.2 복호화 알고리즘

- A. 임의의 영상의 각 지역블록에 대하여 해당하는 정의역블록을 잘라낸다.
- B. 잘라낸 블록을 공간 축소한다.
- C. 밝기 조절량 O_i 를 더한다.
- D. 모든 지역블록에 대하여 반복한다.

III. SOFM을 이용한 벡터양자화

3.1 벡터양자화

벡터양자화 방법은 미리 만들어진 벡터코드북에서 주어진 왜곡 측도를 이용하여 입력 벡터와 가장 유사한 코드 벡터를 찾아내는 방법으로 입력 벡터의 특성들을 잘 표현할 수 있는 벡터코드북을 만드는 것이 핵심이다. 벡터양자화기 설계과정에서 코드북을 생성시키는 과정에는 많은 연산이 필요하지만 생성된 벡터코드북을 가지고 양자화를 시키는 부호화 시간은 상당히 빠르다는 장점이

있다. 이러한 벡터양자화는 주로 높은 압축률을 요구하는 영상부호화 방법으로 사용되고 있다[1].

그림 3.1은 벡터양자화기를 사용하여 원영상을 인덱스로 부호화하는 과정과 생성된 인덱스를 가지고 복원영상으로 복호화하는 과정을 나타낸다.

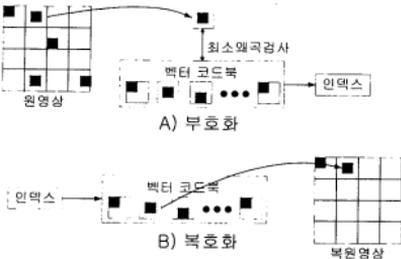


그림 3.1 벡터양자화기 블록다이아그램

3.2 SOFM(Self Organizing Feature Map)

신경망의 학습 방법에는 크게 입력패턴과 함께 목표패턴을 주는 교사학습(Supervised Learning)과 입력패턴만 주고 이에 따른 목표패턴이 주어지지 않는 비교사학습(Unsupervised Learning)이 있다. 교사학습법은 출력결과가 의도하는 목적패턴과 일치하는지를 지속적으로 검사하며 학습하기 때문에 학습시간이 매우 길어지는 단점이 있다.

벡터양자화기의 클러스터링 알고리즘으로 사용되는 SOFM은 비교사학습을 하는 신경망으로서 입력 벡터 패턴을 표현할 수 있는 특징지도(Feature Map)를 만들기 위하여 자기 조직하는 신경 분류회로이며 Kohonen에 의해서 제안된 SOFM을 일반적으로 사용하고 있다[8, 9, 10]. 그림 3.2는 SOFM의 학습 또는 부호화 부분에서 입력뉴런과 가장 유사한 코드벡터(승리뉴런)를 찾는 과정을 나타내며 SOFM의 학습알고리즘은 표 3.1에 설명하였다

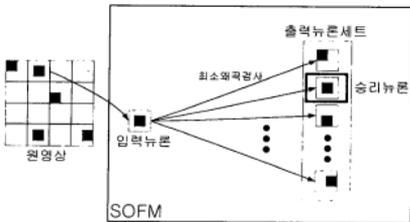


그림 4.2 SOFM의 개념도

표 3.1 SOFM 알고리즘.

ㄷ.	N개의 입력 뉴런과 M개의 출력뉴런 사이의 연결강도를 임의의 작은 값으로 초기화한다.
ㄹ.	새로운 입력벡터를 입력한다.
ㄴ.	입력벡터와 각 출력 뉴런의 거리를 구한다.
$d_j = \sum_{i=0}^{N-1} (X_i(t) - w_{ij}(t))^2$	
$w_{ij}(t) : \text{시각 } t \text{ 에서의 입력출력사이 연결강도}$	
ㄷ.	최소거리를 갖는 출력뉴런(승리뉴런)을 선택한다.
ㄹ.	Weight를 재조정한다.
$w_{ij}(t+1) = w_{ij}(t) + a(t)m(t)(x_i(t) - w_{ij}(t))$	
$X_i(t) : \text{시각 } t \text{ 에서의 입력}$	
$m(t) : \text{이웃}$	
$a(t) : \text{학습률}$	
ㄹ.	ㄷ에서부터 반복한다.

3.3 개선한 경쟁학습 알고리즘

본 논문에서는 기존의 SOFM을 개선하여 프랙탈과 SOFM 벡터양자화기 혼합시스템의 영상 왜곡률 특성을 향상시키고자 적용 벡터양자화기에서 제시된 개선한 경쟁학습 원리를 적용하였다[11]. 개선한 경쟁학습의 개념은 학습패턴 세트에 의해서 학습되지 않는 SOFM의 코드벡터는 삭제하고, 학습패턴 세트에 의해서 많이 학습된 SOFM의 코드벡터 개수는 늘려주어 SOFM을 보다 자생하게 학습시키는 것이다.

적용된 알고리즘은 기존의 Kohonen SOFM과 함께 입력패턴의 특성을 표현하는 정도에 따라서 코드벡터(출력 뉴런)를 생성 또는 삭제를 담당하는 부분이 추가되었다. 코드벡터가 생성 및 삭제되는 부분은 다음과 같다. 학습 영상세트 전체를 1회 학습시킨 뒤에 한번도 입력영상에 의해서 학습되지 않은 출력뉴런이 있으면 그 뉴런을 삭제한다. 그리고 학습된 횟수가 가장 많은 출력뉴런을 아주 작은 랜덤값으로 조정하여 2개로 분리시킴으로서 영상에 많이 포함되어있는 특성을 가진 뉴런을 증가시켜 보다 정확한 분류가 되게 한다[9].

그림 3.3은 개선한 SOFM의 학습 과정을 나타낸다.

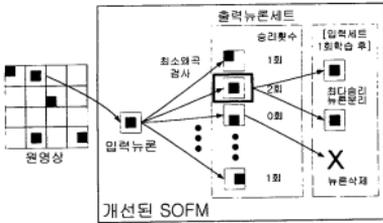


그림 3.3 개선한 SOFM의 개념도

IV. 실험 및 결과

프랙탈은 Fisher의 PIFS방법을 적용하였으며 8[bppl]의 256x256 크기인 입력영상을 받아 지역블록은 4x4로 중첩되지 않게 나누고 정의역블록은 8x8로 서로 1/2씩 중첩되도록 설정하였다.

신경망 학습영상은 특성이 다른 8[bppl]의 256x256 크기인 Airfield, Ave 등과 같은 12개의 영상을 SOFM의 학습영상 세트로 사용하였으며 입력영상을 4x4로 서로 중첩되지 않게 분할하여 신경망의 입력으로 주었다. 또한 학습영상과 비학습영상의 왜곡률 특성비교를 위해 Aero, Lena 영상을 부호화시켰다. 학습물은 초기치를 0.14로 하였고, 식 4.1을 사용하여 지수 함수적으로 0.1까지 감소시켰다. 출력뉴런의 학습이 편중되는 것과 사용되지 않는 뉴런이 생기는 문제를 보완하기 위하여 설정해주는 이웃 뉴런(승리뉴런과 함께 학습되는)의 개수는 초기치로 총 학습뉴런 개수의 2/3개를 주었으며 식 4.2를 사용하여 지수 함수적으로 감소하여 마지막 학습을 할 때에는 주위에 1개 또는 2개의 뉴런만 승리뉴런과 함께 학습이 되도록 하였다. 양쪽 가장자리에 위치한 뉴런이 승리뉴런으로 선택되었을 경우 반대편 뉴런은 학습되지 않을 수가 있기 때문에 전체를 끌고루 학습시키기 위하여 양쪽 뉴런의 끝을 연결한 링형 구조로 뉴런을 연결하였다.

$$\eta(t) = \eta_0 \exp(-t/T_1) \quad (식 4.1)$$

- η_0 : 초기 학습이득
- $\eta(t)$: t 회수의 학습이득
- t : 학습 반복 회수
- T_1 : 학습률의 시상수

$$E(t) = E_0 \exp(-t/T_2) \quad (식 4.2)$$

- E_0 : 초기 이웃범위
- $E(t)$: t 회수의 이웃범위
- t : 학습 반복 회수

T_2 : 이웃 뉴런학습의 시상수

복원영상의 화질은 식 4.3과 같이 정의되는 PSNR로 나타내었다.

$$PSNR = 10 \log_{10} [255^2 / (\frac{1}{P} \sum_{i=1}^P (p_i - q_i)^2)] \text{dB} \quad (식 4.3)$$

p_i, q_i : 원영상과 복원영상 화소의 그레이 레벨 값
 P : 부호화하는 영상의 총 화소의 수

벡터양자화기의 성능을 좌우하는 코드북의 크기는 코드북내의 코드벡터 개수를 96개, 128개, 256개로 다르게 하여 실험을 했으며 각각의 영상 왜곡률 특성을 실험하였다. 클러스터링 알고리즘으로서 일반적인 Kohonen의 SOFM과 개선한 경쟁학습원리를 적용한 SOFM을 각각 사용하여 벡터양자화기를 설계한 다음 각 시스템의 영상 왜곡률을 비교하는 실험을 하였다.

표 4.1 SOFM으로 학습한 경우의 PSNR (단위 dB)

SOFM	96 코드벡터	128 코드벡터	256 코드벡터
House	28.89	29.56	30.10
Lena	27.58	27.95	28.57
Aero	27.10	27.54	27.10

표 4.1은 개선한 경쟁학습 원리를 적용하지 않은 SOFM 벡터양자화기의 입력영상과 복원영상의 PSNR을 나타낸다. 표 4.1에서 SOFM의 학습에 포함되었던 House 영상을 SOFM 벡터양자화기의 입력으로 주었을 때 코드벡터의 개수, 즉 벡터양자화기 코드북의 크기를 96개, 128개, 256개로 변화시켜 주었을 때 코드북의 크기가 커짐에 따라 영상 왜곡률이 약 0.6dB에서 0.9dB 정도 향상됨을 볼 수가 있다. 그리고 SOFM의 학습에 포함되지 않았던 Lena와 Aero 영상을 SOFM 벡터양자화기의 입력으로 주었을 경우는 코드벡터 개수의 변화에 따라 약 0.4dB~0.6dB 정도의 영상 왜곡률이 개선됨을 보았다.

표 4.2 개선한 경쟁학습원리를 적용한 SOFM의 경우의 PSNR(dB)

경쟁학습	96 코드벡터	128 코드벡터	256 코드벡터
House	29.27	30.06	30.54
Lena	27.92	28.45	29.10
Aero	27.10	27.86	28.40

표 4.2는 개선한 경쟁학습원리를 적용한 SOFM 벡터양자화기에서의 입력영상에 따른 복원영상의 PSNR을 나타내고 있다. 이를 표 4.1에 나와있는 Kohonen의 SOFM으로 학습한 결과와 비교해 보면 SOFM의 학습영상에 포함된 House 영상의 경우는 약 0.3dB에서 0.45dB 정도의 성능개선을 보였다. 학습영상에 포함되지 않은 Lena와 Aero 영상을 개선한 경쟁학습원리를 적용한 SOFM 벡터양자화기의 입력영상으로 주었을 경우에서 Lena는 약 0.3dB에서 0.55dB 정도의 영상 왜곡률 개선을 보였다. Aero 영상은 96 코드벡터일 때는 성능개선이 보이지 않았으나 128 코드벡터와 256 코드벡터의 코드북 크기를 가졌을 경우는 각각 0.42dB와 0.30dB 정도의 성능개선을 보였다.

표 4.3 복원영상의 PSNR(dB)

	Factal		Hybrid		경쟁학습 hybrid	
	횟수	PSNR	횟수	PSNR	횟수	PSNR
House	1	15.58	1	15.81	1	15.81
	7	28.81	7	29.80	7	30.21
	13	35.18	12	34.49	12	35.12
	26	35.75	19	36.01	19	36.40
	횟수	PSNR	횟수	PSNR	횟수	PSNR
Lena	1	13.11	1	13.10	1	13.23
	7	24.57	7	25.73	7	25.93
	15	30.01	12	29.64	12	30.32
	22	30.57	16	30.72	16	30.92
	횟수	PSNR	횟수	PSNR	횟수	PSNR
Aero	1	12.55	1	12.61	1	12.59
	7	15.67	7	16.55	7	16.86
	16	20.46	15	23.57	15	24.17
	36	28.93	22	29.30	22	29.63

이 있었으며, 본 논문에서 제안한 방법을 사용했을 경우와 프랙탈을 비교했을 경우에는 약 0.65dB의 성능개선이 있었다.

벡터양자화기의 학습영상에 포함되지 않은 Lena와 Aero 영상을 각각의 시스템 입력으로 주었을 경우에는 Lena 영상은 28%의 복호화 회수가 감소되었고, Aero의 경우에는 39%의 복호화 회수가 감소됨을 보였다. Kohonen의 SOFM을 사용한 혼합시스템과 프랙탈의 영상 왜곡률을 비교했을 경우에는 Lena 영상의 경우는 0.15dB이고 Aero 영상은 0.37dB의 영상 왜곡률 향상을 보였다. 제안된 방식의 혼합시스템과 프랙탈의 영상 왜곡률을 비교했을 경우에는 Lena 영상은 0.35dB, Aero 영상은 0.70dB의 영상 왜곡률 향상을 보였다.

표 4.3의 결과에서 보듯이 개선한 경쟁학습이론을 적용한 혼합시스템의 영상 왜곡률이 개선한 경쟁학습이론을 적용하지 않은 혼합시스템의 PSNR보다 약 0.2dB~0.4dB 정도 개선되는 것을 볼 수가 있다.

개선한 경쟁학습알고리즘 SOFM과 일반적인 SOFM의 연산량을 학습시간 기준으로 비교해보았을 때, 256x256 크기의 12개 학습영상 세트들 1회 학습시킬 경우 학습 시간(초 단위)은 두 가지 방법 모두가 146초의 동일한 수치를 나타내었으며 실제적으로 두 학습 알고리즘 사이의 연산시간 차이는 1초 미만으로 거의 차이가 나지 않았다.

표 4.3은 기존의 SOFM 벡터양자화기와 프랙탈 혼합시스템, 본 논문에서 제안한 방법인 경쟁학습 이론을 적용한 SOFM 벡터양자화기와 프랙탈 혼합시스템, 그리고 Fisher의 PIFS 방법을 사용한 fractal의 영상왜곡 특성들을 비교한 것이다. 입력영상을 벡터양자화기 코드북을 사용하여 부호화시킨 것인지 또는 프랙탈의 벡터코드북을 사용하여 부호화시킨 것인지를 결정해주는 문턱치 값은 유클리디안 거리 50을 사용하였다. 이 문턱치는 입력블록의 유클리디안 거리의 평균치를 고려해서 임의적으로 선택했다.

벡터양자화기의 학습영상에 포함된 House 영상은 각각의 시스템 입력으로 주었을 때는 혼합시스템과 프랙탈의 영상 왜곡률이 수렴하는 복호화 반복횟수는 약 27% 정도 감소하였다. 또한 Kohonen의 SOFM을 사용한 벡터양자화기와 프랙탈 혼합시스템과 프랙탈의 영상 왜곡률을 비교해 보았을 때 약 0.26dB의 성능 개선



(a)



(b)



(c)

그림 4. (a) 원영상, (b) 프랙탈과 벡터양자화 혼합시스템의 복원영상, (c) 프랙탈과 개선한 벡터양자화 혼합시스템의 복원영상

그림 4(a), 그림 4(b), 그림 4(c) 영상들은 순서대로 Lena 영상을 입력으로 했을 때 원영상, 프랙탈과 벡터양자화 혼합시스템의 복원영상 그리고 개선한 경쟁학습 이론을 적용한 프랙탈과 벡터양자화 혼합시스템의 복원영상을 나타낸 것이다.

V. 결론

프랙탈은 복호화 시간이 적게 걸리는 장점과 압축률이 높아질 경우에도 일정 수준이상의 복원영상의 화질을 보장받는다는 장점을 가지고 있다. 그러나 느린 부호화 시간과 최근의 발전된 다른 영상압축 방식들보다 뒤떨어지는 영상 왜곡률 특성은 보완해야할 단점으로 남아있다. 본 논문에서는 프랙탈의 영상 왜곡률 향상을 위하여 프랙탈과 벡터양자화기를 혼합시켰다. 그 결과 평균 0.3dB 정도 향상된 복원화질을 얻을 수 있었으며 부호화 시간도 단축됨을 확인하였다. 또한 프랙탈과 SOFM 벡터양자화기 혼합시스템의 영상 왜곡률 특성을 보다 향상시키기 위하여 개선한 경쟁학습 알고리즘을 적용한 SOFM을 사용한 프랙탈과 벡터양자화기 혼합시스템을 구성하였다. 그 결과 개선한 경쟁학습 알고리즘을 적용한 SOFM의 경우가 일반적인 Kohonen의 SOFM의 경우보다 평균 0.3~0.4dB 정도 향상된 영상 왜곡률 특성을 나타냈으며 Kohonen의 SOFM과의 계산량 차이는 학습패턴 세트 1회 학습시간을 기준으로 했을 때 1초 미만으로 거의 동일했다.

향후에는 개선한 SOFM 벡터양자화기를 최근의 발전된 여러 프랙탈기법들과 혼합시켰을 때의 성능을 확인하고자 한다.

접수일자 : 2001. 12. 19 수정완료 : 2002. 1. 23

본 연구는 한국과학재단 지정 금오공과대학교 전자 부품고품질화 및 공정자동화 연구센터의 지원에 의한 것입니다.

참고문헌

- [1] Randy Crane, "A simplified approach to Image Processing", Prentice Hall, pp. 245~285, 1997.
- [2] M. Barnsley, "Fractals Everywhere." Sandiego CA: Academic, 1988.
- [3] A. E. Jacquin, "Image Coding Based on a Fractal Theory of Iterated Contractive Image Transformations", IEEE Trans. Image Process., vol. 1, no. 1 pp. 18~30, 1992.
- [4] Raouf Hamzaoui, and Dietmar Saupe, "Combining Fractal Image Compression and Vector Quantization", IEEE Trans. Image Process., vol. 9, no. 2, 2000.
- [5] D. M. Monro and F. Dudbridge, "Fractal Approximation of Image blocks", Proc. ICASSP-92, vol. 3, pp. 485~488, 1993.
- [6] R. Hamzaoui, "Codebook clustering by self organizing maps for fractal image compression", in NATO ASI Fractal Image Encoding and Analysis, Trondheim, Norway, Jul. 1995. Also in Fractals, vol. 5, pp. 27~38, Apr. 1997.
- [7] K. Shen and E. J. Delp, "Wavelet Based Rate Scalable Video Compression," IEEE Trans. Circuits and Systems for Video Technology, 1998.
- [8] 김영근, "다중 하이퍼큐브 구조를 갖는 자기조직형 신경회로망 모델을 이용한 새로운 벡터양자화 알고리즘에 관한 연구", 한국과학기술원, 1994.
- [9] W. C. Chu, N. K. Bose, "Vector Quantization of Neural Networks", IEEE Transactions on Neural Networks, vol. 9, no. 6, Nov. 1998.
- [10] T. Kohonen, "The self-organizing map", Proc. of the IEEE, vol. 78, pp. 1467~1480, 1990.
- [11] N. K. Bose and P. Liang, "Neural Network Fundamentals with Graphs, Algorithms and Applications", McGraw Hill, 1996.



김영정(Yung-Jung Kim)

正會員

1999년 금오공과대학교 전자공학과
(공학사)

2001년 금오공과대학교 전자공학과
(공학석사)

2001-현재 금오공과대학교 전자공학과
박사과정

관심분야 : 영상 신호처리, 패턴인식, 컴퓨터 구조, 컴퓨터 그래픽스



박원우(Won-Woo Park)

正會員

1981년 서강대학교 전자공학과
(공학사)

1986년 The Univ. of Texas at Austin
(공학석사)

1991년 The Univ. of Texas at Austin
(공학박사)

1991년-1993년 삼성전자 컴퓨터부문 수석연구원

1993년 - 현재 금오공과대학교 전자공학과 부교수

관심분야 : 컴퓨터 구조, 컴퓨터 그래픽스, 인공지능



김상희(Sang-Hee Kim)

正會員

1983년 홍익대학교 전기공학과
(공학사)

1985년 연세대학교 전기공학과
(공학석사)

1992년 TEXAS A&M
(공학박사)

1993 - 현재 금오공과대학교 전자공학부 부교수

관심분야 : 신경회로망, 계측 제어, 생체전자