

신경망이 벡터양자화와 프랙탈 혼합시스템에 미치는 영향

A Study on the Hybrid Fractal clustering Algorithm with SOFM vector Quantizer

김 영 정, *박 원 우, *김 상 희, *임 재 권
금오공과대학교 전자공학과, *금오공과대학교 전자공학과
전화 : 054-467-4381 / 핸드폰 : 017-426-2053

Yung-Jung Kim, Won-Woo Park, Sang-Hee Kim, Jae-Kwon Lim
Dept. of Eelectronics Engineering, Kumoh National University of Technology
E-mail : yjkim1@knut.kumoh.ac.kr

Abstract

Fractal image compression can reduce the size of image data by contractive mapping of original image. The mapping is affine transformation to find the block(called range block) which is the most similar to the original image. Fractal is very efficient way to reduce the data size. However, it has high distortion rate and requires long encoding time. In this paper, we present the simulation result of fractal and VQ hybrid systems which use different clustering algorithms, normal and improved competitive learning SOFM. 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.

I. 서론

프랙탈 영상압축은 영상내 자기유사성을 이용하는 것으로서 우선 원영상을 축소하여 원영상과 비교될 영상으로 만들고, 축소된 영상에 대한 원영상의 축소변환의 고정점을 얻어서 영상 데이터를 반복축소변환만으로 표현하는 방법으로 Barnsley[1]가 처음으로 제안한 프랙탈이론을 Fisher, Jacquin이 영상압축에 적용하였다. 그러나 웨이블릿과 같이 최근에 발전하는 영상압축 방법과 비교해 보면 상대적으로 떨어지는 영상의 왜곡률과 느린 부호화 시간이 단점으로 평가되어 다른 부호화 방법과의 결합 또는 변환부호화방법으로의 접목으로 극복해보려는 노력이 계속되어왔다.

벡터양자화와 프랙탈은 부호화 할 때 원영상의 블록과 가장 비슷한 영상을 벡터 코드북에서 찾아 그 코드북의 인덱스를 부호로 하여 압축을 한뒤, 복호화 할 때는 인덱스를 이용하여 임의의 영상을 원영상에 근사화 시킨다. 본 논문에서는 벡터양자화와 프랙탈의 이와 같은 공통점을 기초로 벡터양자화기를 프랙탈에 접합시켰다. 벡터양자화기 코드북의 코드벡터가 입력영상과 비교하여 만족할 만한 근사값을 제공하지 못했을 경우에만 프랙탈 영상압축 알고리즘으로 학습영상 스스로를

검색하여 가장 비슷한 영상을 찾아내는 방법을 사용하였다.

벡터 양자화기의 코드북을 생성시키는 클러스터링 알고리즘으로는 기존의 SOFM(Self Organize Feature Map)신경망과 개선된 경쟁학습알고리즘을 적용시킨 SOFM 신경망 이 두 가지 방법을 사용하였으며, 벡터양자화기와 프랙탈 알고리즘의 결합에서 벡터양자화기의 클러스터링 알고리즘이 전체 왜곡률의 변화에 미치는 영향을 평가하기 위하여 모의실험을 수행하였다.

II. 프랙탈과 벡터양자화

2.1 프랙탈의 기본이론

Mandelbrot이 처음으로 제안한 프랙탈 이론은 지구상에 존재하는 불규칙한 자연형상들이 단순한 법칙의 반복으로 표현되어질 수 있다는 개념에 기반을 두었다. 뒤에 Jacquin, Bansley, Monro 등에 의해서 영상 압축 방식에 적용이 되어 현재에 있어서는 효율적인 영상 압축 부호화 기법으로 자리잡고 있다. 프랙탈 영상압축의 기본원리는 원영상의 한 부분(치역블럭)과 가장 유사한 원영상내의 특정부분(정의역블럭)을 찾는 것이다.

2.2 프랙탈 영상압축방법

2.2.1 부호화

- ①. 치역블럭구성: 입력영상을 BxB블럭으로 서로 중첩되지 않게 분할한다
- ②. 정의역블럭구성: 입력영상을 그림 1과 같이 치역 블록의 두배 크기인 2Bx2B로 50%중첩 분할한다.
- ③. Isometry 적용: 정의역 블록을 치역블럭의 크기만큼으로 축소하고 정해진 8가지(원영상, y축접힘, x축접힘, 180도회전, 원점접힘, 90도회전, 270도회전, 역원점접힘)의 isometry를 적용하여 치역 블록과의 오차를 줄인다.
- ④. 축소된 정의역블럭과 치역 블록간의 오차가 최소가 되도록하는 밝기 조절 변수 O_i 를 구한다.
- ⑤.이상의 과정을 반복하여 매 치역블록마다 정의역블럭 전체를 탐색하여 가장 오차가 정의역블럭 번호와 isometry 번호를 구하여 부호화 한다.

2.2.2 복호화

- ①. 임의의 영상의 매 치역블럭에 대하여 해당하는 정의역 블록을 잘라냄.
- ②. 잘라낸 블록을 공간 축소함.
- ③. 밝기 조절량 O_i 를 더함.
- ④. 모든 치역블럭에 대하여 반복.

2.3 벡터양자화

벡터양자화방법은 미리 설계된 코드북에서 주어진 왜곡 측도를 이용하여 입력 벡터와 가장 유사한 코드 벡터로 맵핑하는 방법으로 주로 고압축을 요구하는 영상부호화 방법으로 사용되어 왔다.

2.4 SOFM(Self Organize Feature Map)

Kohonen은 입력 벡터 패턴을 표현할 수 있는 특성지도(Feature Map)을 만들기 위해서 자기 조직하는 신경 분류회로인 SOFM을 제안하였다.

SOFM 알고리즘.

- ①. N개의 입력 뉴런과 M개의 출력 뉴런 사이의 연결강도를 임의의 작은 값으로 초기화한다.
- ②. 새로운 입력벡터를 입력한다.
- ③. 입력벡터와 각 출력 뉴런의 거리를 구한다.

$$d_j = \sum_{i=0}^{N-1} (X_i(t) - w_{ij}(t))^2 .$$

$X_i(t)$: 시각 t 에서의 입력.

$w_{ij}(t)$ 시각 t 에서의 입력출력사이의 연결강도.

- ④. 최소거리를 갖는 출력 뉴런을 선택.
- ⑤. Weight를 재조정.
- ⑥. $w_{ij}(t+1) = w_{ij}(t) + a(t)m(t)(x_i(t) - w_{ij}(t))$.
 $m(t)$: 이웃, $a(t)$: 학습률.
- ⑦. ②.에서부터 반복.

2.5 개선된 경쟁학습 알고리즘

이 논문에서는 적응 VQ[6]의 개선된 경쟁학습 원리를 적용하였다. 이 방법은 학습영상세트를 학습시키고 난 뒤에도 한번도 입력영상에 의해서 학습이 되지 않은 출력뉴런이 있으면 그 뉴런을 삭제한다. 그리고 학습된 횟수가 가장 많은 출력뉴런을 아주 작은 랜덤한 값으로 조정해서 2개로 분리시킴으로서 영상에 많이 포함되어있는 특성을 가진 뉴런을 보다 많이 만들어 보다 정확한 분류가 되게 하는 방법이다.[4]

III 실험 및 결과.

실험에 쓰인 컴퓨터는 PentiumII 333, Ram 96M이며, 운영체제는 Win98을 사용하였다. 특성이 다른 256x256크기의 8[bpp]인 Airfield, Ave, Baboon, Couple, Goldhill, House, Moon, Oleh, Pyramid, Reagan, Vegas영상을 SOFM의 학습영상으로 사용하였으며 Aero, Lena를 비 학습영상으로 부호화 시켜보았다. 프랙탈은 256x256의 입력영상을 받아 치역블록은 4x4로 중첩이 되지 않게 나누고 정의역블록은 8X8로 서로 1/2씩 중첩이 되도록 설정하였다. 신경망 입력영상은 256x256크기의 256 단계의 밝기값을 가지는 8[bpp]영상12개를 4x4로 중첩되지 않게 분할을 하여 입력으로 주었다. 학습률은 0.14에서 지수 함수적으로 0.1까지 감소 시켰고 처음에는 총 학습뉴런의 2/3를 입력과 가장 유사한 승자뉴런을 중심으로 같이 학습을 시켜주었으며, 지수적으로 감소하여 마지막 학습을 할 때에는 주위에 1개 또는 2개의 뉴런만 승자뉴런과 함께 학습이 되도록 하였다. 또한 양쪽 가장자리에 위치한 뉴런이 선택이 되었을 경우 반대편 뉴런은 학습이 되지 않을 수가 있기 때문에 전체를 끌고루 학습시키기 위해서 양쪽 뉴런의 끝이 연결되어있는 링형 구조의 뉴런을 도입하였다.

표.1은 개선된 경쟁학습원리를 적용하지 않은 SOFM 벡터양자화기의 입력영상과 복원영상의 PSNR을 나타내고, 표.2는 개선된 경쟁학습원리를 적용한 SOFM 벡터양자화기의 입력영상과 복원영상의 PSNR을 나타내고 있다. 이 결과를 비교해 볼 때 개선된 경쟁학습원리를 적용한 SOFM의 경우가 약 0.5dB정도 좋은 성능을 나타내었다.

표.1 SOFM으로 학습한 경우의 PSNR(단위 dB). 표.2 개선된 경쟁학습원리를 적용한 SOFM을 사용한 경우의 PSNR(dB).

SOFM	96 코드벡터	128 코드벡터	256 코드벡터	경쟁 학습	96 코드벡터	128 코드벡터	256 코드벡터
House	28.89	29.56	30.10	House	29.27	30.06	30.54
Lena	27.58	27.95	28.57	Lena	27.92	28.45	29.10
Aero	27.10	27.54	27.10	Aero	27.10	27.86	28.40

표.3 프랙탈과 혼합되었을 때 복호화영상의 화질(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
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
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

표.3은 위의 두가지 종류의 클러스터링 알고리즘의 벡터 양자화기를 프랙탈에 적용하여 각 입력영상 블록에 대해 벡터양자화기의 코드북이 문턱치만큼의 적합한 유클리디안 거리를 제공해주지 못한 경우, 프랙탈을 적용하여 입력영상을 처리하는 방법으로 구성되어진 벡터양자화기와 프랙탈 혼합시스템의 성능표이다.

문턱치는 입력블록의 유클리디안 거리의 평균치를 고려해서 임의적으로 선택했으며 표.3의 결과에서 보듯이 개선된 경쟁학습이론을 적용한 혼합시스템의 PSNR이 개선된 경쟁학습이론을 적용하지 않은 혼합시스템의 PSNR보다 약0.3dB에서 0.4dB정도 개선되는 것을 볼 수가 있다.

IV. 결론

본 논문에서는 Fractal 영상압축의 왜곡률 향상을 위해 벡터양자화기와 혼합하여 성능의 개선을 확인하였으며, 개선된 경쟁학습알고리즘을 적용한 SOFM의 성능이 개선된 경쟁학습알고리즘을 적용하지 않은 SOFM의 성능보다 좋다는 것을 검증하였다. 또한 프랙탈의 복호화 반복횟수도 감소하여 일반 프랙탈의 복호화보다 빠른 복호화가 가능함을 제시하였다.

이후에 공간 영역 벡터양자화기가 아닌 변환영역 벡터양자화기에 개선된 경쟁학습알고리즘을 사용한 SOFM을 사용하여 시스템을 설계하여 성능향상 정도를 확인이 필요하다.

V. 참고문헌

- [1] M. Barnsley, "Fractals Everywhere." Sandiego, CA: Academic, 1988.
- [2] R. Hamzaoui, "Codebook clustering by self-organizing maps for fractal image compression," in NATO ASI Fractal Image Encoding and Analysis, Trondheim, Norway, July 1995. Also in Fractals, vol.5, pp. 27-38, Apr. 1997.
- [3] 김영근, "다중 하이퍼큐브 구조를 갖는 자기조직형 신경회로망 모델을 이용한 새로운 벡터양자화 알고리즘에 관한 연구". 한국과학기술원, 1994.
- [4] W. C. Chu, N. K. Bose, "Vector Quantization of Neural Networks", IEEE Transactions on neural networks, vol 9, No 6, November 1998.
- [5] 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.
- [6] N. K. Bose and P. Liang, "Neural Network Fundamentals with Graphs, Algorithms, and Applications.", McGraw Hill, 1996.