

RBFN 신경망을 이용한 동영상의 적응 양자화

Adaptive Quantization of Image Sequence using the RBFN

안 철 준 , 공 성 곤

승실대학교 전기공학과

Chul-Joon Ahn and Seong-Gon Kong

Department of Electrical Engineering

Soongsil University

e-mail : wille@elecpwr.soongsil.ac.kr

ABSTRACT

This paper presents an adaptive quantization of image sequences using the Radial Basis Function Network (RBFN) which classifies interframe image blocks. The classification algorithm consists of two steps. Blocks are classified into NA(No Activity), SA(Small Activity), VA(Vertical Activity), and HA(Horizontal Activity) classes according to edges, image activity and AC energy distribution. RBFN is trained using the classification results of the above algorithm, which are nonlinear classification features are acquired from the complexity and variability of difference blocks. Simulation result shows that the the adaptive quantization using the RBFN method produced better results than that of the sorting and MLP methods.

I. 서 론

멀티미디어의 발전으로 동영상 압축에 대한 관심이 고조되고 있다. 동영상의 적용 양자화 방법은 영상간 차이 영상의 각 블록들을 유사한 블록들로 분류하여 같은 클래스로 분류된 블록끼리 같은 비트맵을 통해 양자화하는 방법이다. 1970년대 후반 W.H.Chen [1]에 의해 기본적인 적용 양자화 방법이 제안되었지만, 이는 블록의 AC energy의 특징만으로 블록 분류를 수행했기 때문에 블록의 다양한 성질들에 대한 고려가 미흡했다. 따라서 본 논문에서는 영상과 영상 사이의 차이 영상에서의 블록들의 AC energy와 변환 계수 분포값을 블록의 특징값으로 사용하여 RBFN(Radial Basis Function Network)을 통한 분류를 제안한다. 그림 1은 RBFN을 이용한 동영상의 적용 양자화 압축과정에 대한 블록도이다.

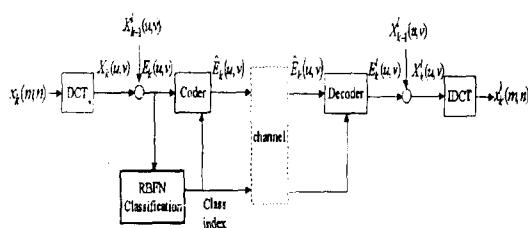


그림 1: RBFN을 이용한 동영상의 적용 양자화

II. 블록 분류 알고리즘

본 논문에서 제시한 분류 알고리즘은 크게 두 단계로 나눌 수 있는데, 간략한 블록도를 그림 2에 나타내었다. 활동도 분류 단계에서는 에지 추출을 통한 활동 블록과 비활동 블록의 분류가 이루어지고, 분포도 분류 단계에서는 활동 블록들에 대해서 AC energy와 변환계수분포특성을 이용하여 분류하게 된다. 클래스의 종류로는 NA (No Activity), SA (Small Activity), VA (Vertical Activity), 그리고 HA (Horizontal Activity) 가 있다.

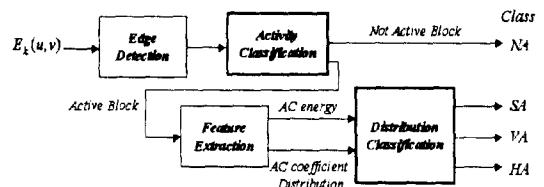


그림 2: 블록 분류 알고리즘의 블록도

2.1 활동도의 분류

활동도 분류(activity classification)단계에서는 활동 블록과 비활동 블록의 분류가 이루어진다. 차이 영상을 살펴 보면 일반적으로 대상의 외곽 부근, 즉 에지 부분에 대부분의 차이값이 나타난다. 따라서, 차이 영상에서 활동 영

역들을 분류해내는 방법으로 에지 추출법을 사용한다. 에지 추출법은 기본적으로 영상값 주변의 픽셀간의 변화량을 이용하는데, 각 에지 추출 방법의 고유한 장을 영상에 써움으로써 얻을 수 있고, 본 논문에서는 Sobel 방법[2]을 사용하였다. Sobel 에지 추출 방법에 의해 에지로 추출된 블록들은 활동 블록으로, 에지가 아닌 블록들은 비활동 블록으로 분류되고, 비활동 블록들은 NA로 분류한다.

2.2 분포도 분류

분포도의 분류(distribution classification) 단계에서는 활동 블록으로 분류된 블록들에 대해서 AC energy와 DCT 변환된 계수 분포에 대한 특성에 의해 SA, VA, HA의 분류가 이루어진다.

2.2.1 활동 블록의 특성값

AC energy는 블록의 활동 정도를 나타내는 지표이다. 즉, AC energy의 값이 상대적으로 크면 보다 움직임이 많은 영역이라고 볼 수 있다.

$$AC\ energy = -E_k^2(0,0) + \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} E_k^2(u,v) \quad (1)$$

같은 활동 정도를 가진 블록이라 하더라도 변환 계수들의 분포는 각기 다르다. 이러한 변환 계수의 분포 특성값은 먼저 그림 3과 같은 수직창과 수평창을 각 블록에 써움으로써 얻어진다.

0	1	1	1	0	0	0	0
0	0	1	1	0	0	0	0
0	0	0	1	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0

(a) $W_v(u, v)$

0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0
1	1	0	0	0	0	0	0
1	1	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0

(b) $W_h(u, v)$

그림 3: 변환 계수 분포 특정 추출을 위한 창

창의 우기를 기친 각 블록들은 식 (2)에 의해서 변환 계수의 각 분포 특징에 대한 d_v 를 얻게 된다. d_v 는 $W_v(u, v)$ 대신에 $W_h(u, v)$ 를 대입하면 구할 수 있다.

$$d_v = \left(\sum_{u=0}^{M-1} \sum_{v=0}^{N-1} |W_v(u, v) E_k(u, v)| \right) / 6 \quad (2)$$

수직값 d_v 와 수평값 d_h 이 구해지면, 식 (3)에서 같이 두 값의 차이를 변환 계수의 분포값으로 정한다.

$$d = d_v - d_h \quad (3)$$

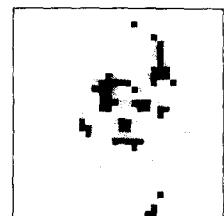
2.2.2 블록 분류

먼저 AC energy값의 크기순으로 반으로 나눠서, AC energy 가 작은 값으로 분류된 절반의 블록들에 대해서는 SA로 분류한다. AC energy가 큰 값으로 분류된 나머지 절반의 블록들에 대해서는 변환 계수의 분포 특성값을 비교함으로써 계수 분포값이 양수이면 VA로, 음수이면 HA로 분류하는 것이다.

그림 4는 지금까지 설명한 두 단계의 블록 분류 알고리즘에 의해 분류한 결과이다. 분류 결과는 표 1과 같다.



(a) 차이 영상



(b) 최종 분류 결과

그림 4: 분류 알고리즘에 의한 분류 결과

표 1: 분류 알고리즘에 의한 차이 영상 분류

블록 형태	예지 검출	AC energy	변환 계수 분포	블록 개수
NA	□	No	매우 작다	.
SA	□	Yes	작다	.
VA	■	Yes	크다	수직 분포
HA	■	Yes	크다	수평 분포
				32개

III. RBFN을 이용한 적응 양자화

2장에서 설명한 분류 알고리즘을 신경망을 통해 구현해 보고자 한다. 본 논문에서 사용하고자 하는 신경망은 RBFN[3]이다. RBFN을 통한 분류는 활동 블록들에 대한 클래스 SA, VA, HA의 분류 과정만을 포함한다.

3.1 RBFN의 구조

RBFN의 구조는 그림 5와 같다.

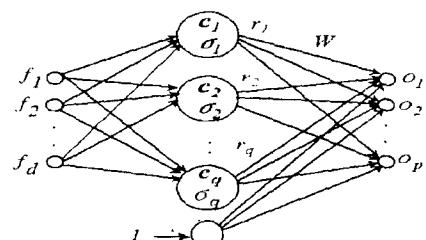


그림 5: RBFN의 구조

$\mathbf{c}_j = [c_{j1}, \dots, c_{jd}]$, $j=1, \dots, q$ 는 중간층 뉴런의 중심점 벡터이고, $\sigma_j = [\sigma_{j1}, \dots, \sigma_{jd}]$, $j=1, \dots, q$ 는 각 중심점에서의 가우시안 함수의 함수폭 벡터, r_1, \dots, r_q 는 중간층의 출력값이다. 연결강도 \mathbf{W} 는 중간층과 출력층 사이에서만 존재한다.

일단 중심점과 함수폭이 결정되면 식 (4)에 의해서 중간층의 출력값 r_j 를 구한다.

$$r_j = \exp\left(-\sum_{i=1}^d \frac{(f_i - c_{ji})^2}{2\sigma_{ji}^2}\right), j=1, \dots, q \quad (4)$$

중간층과 출력층의 연결강도 \mathbf{W} 는 의사 역행렬을 통하여 식 (5)에 의해서 구해진다.

$$\mathbf{W} = (\mathbf{R}^T \mathbf{R})^{-1} \mathbf{R}^T \mathbf{Z} \quad (5)$$

$\mathbf{R} = [\mathbf{r}_1, \dots, \mathbf{r}_K]$ 에서 K 는 학습 데이터의 개수이고, 각 데이터의 출력 벡터는 바이어스 항을 출력을 추가하여 $\mathbf{r}_j = [r_{j1}, \dots, r_{jq}, 1]^T$, $j=1, \dots, K$ 이다.

$\mathbf{Z} = [\mathbf{z}_1, \dots, \mathbf{z}_K]$ 는 원하는 출력행렬(desired output)이고, 각 벡터 \mathbf{z}_j 는 $[z_{j1}, \dots, z_{jq}, 1]^T$ 이다. 출력층의 활성함수는 hard limit을 사용하였다

3.2 RBFN의 학습

블록 분류를 위한 RBFN의 학습 데이터로는 Salesman, Football, Tennis 동영상의 6개 차이 영상 중 활동 블록으로 분류된 블록들의 특징값을 사용하였고 각 데이터는 -1에서 1사이로 정규화 시켰다. 학습 데이터로 사용된 총 데이터의 개수는 1532개이다.

3.2.1 중심점의 개수 및 위치 선택

중심점의 위치와 수를 결정하는 것은 RBFN의 학습 과정에서 매우 중요하다. 실제로 RBFN에서의 학습은 중심점의 수를 하나씩 늘려가면서 이루어지며, 중심점의 위치를 결정하는 몇 가지 방법이 제안되었지만, 본 논문에서는 강장 학습 알고리즘[4]을 사용하여 중심점의 위치를 선택하였다.

3.3.2 함수폭 σ_j 결정

RBFN의 학습 과정에서 또 하나의 중요한 변수는 각 중심점에서의 가우시안 함수폭이다. 함수폭 σ_j 를 구하는 몇 가지 제안된 방법이 있다. 본 논문에는 식 (6)의 방법[5]을 사용하였다.

$$\sigma_j = \frac{1}{2} \| \mathbf{c}_j - \hat{\mathbf{c}}_j \|, i=1, \dots, d \quad (6)$$

$\hat{\mathbf{c}}_j$ 는 \mathbf{c}_j 에서 가장 가까운 중심점이다. 식 (6)을 이용하면 구하려는 중심점에서 가장 가까운 다른 중심점과의 간섭을 줄일 수 있도록 적당한 함수폭 σ_j 를 결정할 수 있다. 또한 분류하고자 하는 패턴의 분포에 따라서 각 중심점에서의 함수폭의 각 차원에 대한 비율을 달리 하면 학습 성능을 보다 향상시킬 수 있다[6].

3.3 블록 분류 결과

3.2절에서 언급한 학습 데이터에 대해서 학습을 실시하여 그림 6과 같은 최종적인 분류 결과를 얻었다. 그림 6에서 진한 선은 분류 경계선이다.

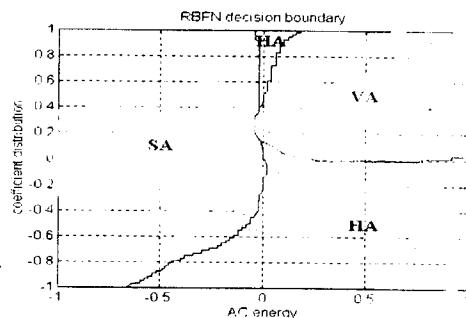


그림 6: RBFN 분류 결과

IV. 시뮬레이션

본 논문에서 제안한 방법의 성능을 시뮬레이션을 통해 비교하도록 한다. 테스트 데이터로는 Miss America와 Trevor 동영상 16개 프레임을 사용하였다. 시뮬레이션 환경은 Pentium150이고, 툴은 Matlab을 사용하였다.

RBFN 분류 방법에 대한 압축 성능 비교 대상으로 Sorting 방법과 MLP(Multi-Layer Perceptron) 방법을 사용하였는데, Sorting 방법은 AC energy에 의해서만 4개의 클래스로 분류하는 방법이고, MLP는 RBFN과 같은 학습조건 하에서 비교하였다. 시뮬레이션 결과 그림 7, 8, 9, 10에서 RBFN 방법과 MLP 방법이 Sorting 방법에 비해 더 나은 압축 성능을 확인할 수 있다.

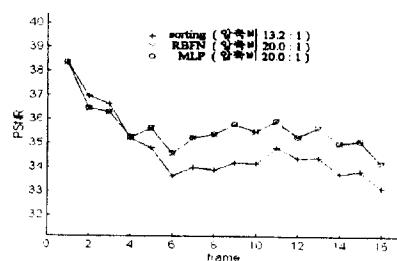


그림 7: Miss America의 압축 성능 비교

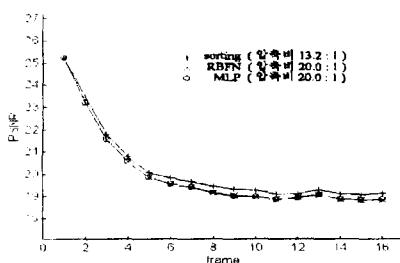


그림 8: Trevor의 압축 성능 비교

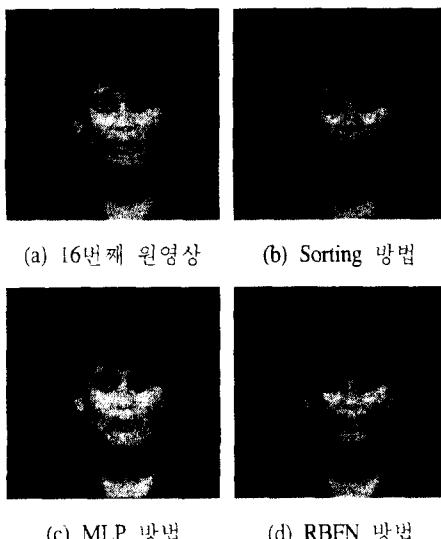


그림 9: Miss America 동영상의 복원 영상 비교

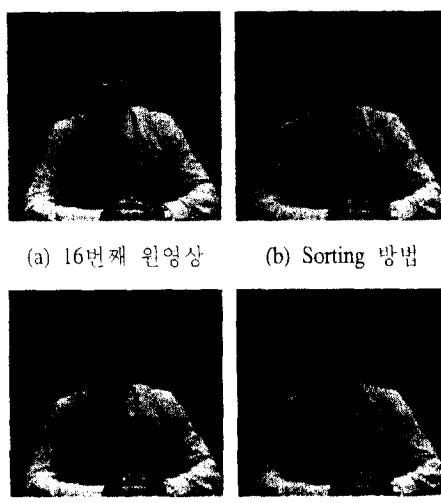


그림 10: Trevor 동영상의 복원 영상 비교

RBFN과 MLP는 표 2에서 학습 및 분류 성능으로 비교할 수 있다.

표 2: 학습 및 분류 성능 비교

	중간층 뉴런수	학습시간 [sec]	분류시간 [sec/frame]
MLP	20 개	84.8	2.9
RBFN	9 개	46.1	1.8

표 2에서 보는 것처럼, RBFN의 학습 성능과 분류 성능이 MLP에 비해 우수함을 알 수 있다.

V. 결 론

본 논문에서는 RBFN을 이용한 동영상의 적응 양자화 기법에 대해서 살펴 보았다. 제안한 알고리즘에 의해 NA, SA, VA, HA의 클래스로 분류한 결과를 사용해 RBFN을 이용한 분류기기를 구성하여 복잡하고 다양한 블록들의 분류에 있어서의 비선형성을 획득하였다.

시뮬레이션을 통해 압축비 대 PSNR 성능에서 Sorting 방법보다 RBFN과 MLP의 방법이 훨씬 개선되었음을 보았고, 학습 성능과 분류 속도면에서 MLP보다 RBFN의 방법이 뛰어남을 확인하였다.

VI. 참 고 문 헌

- [1] W. H. Chen and C. H. Smith, "Adaptive Coding of Monochrome and Color Images," *IEEE Trans. on Communications*, Vol. COM-25, No.11, pp. 1285-1292, 1977.
- [2] D. Marr and E. Hildreth, "Theory of Edge Detection," *Proceedings R. Soc. Lond.*, Vol. B207, pp. 187-217, 1980.
- [3] D. S. Broomhead and D. Lowe, "Multivariable functional interpolation and adaptive networks," *Complex Systems*, Vol. 2, pp. 321-355, 1988.
- [4] T. Kohonen, *Self-Organization and Associative Memory*, 2nd Edition, Berlin: Springer-Verlag, 1987.
- [5] 신요안, 윤병문, 임영선, "Complex radial basis function network을 이용한 비선형 디지털 위성 통신 채널의 등화," 한국통신학회논문지, 제21권, 제9호, pp. 2456-2469, 1996.
- [6] 안철준, 공성곤, "RBFN을 이용한 변환 영역에서의 동영상의 적응 양자화," 대한전기학회 하계학술대회 논문집, Vol. G, CAO-1, pp. 2282-2285, 1997.