

프레임간 차영상 블록의 적응분류에 의한 영상시퀀스 압축

Image Sequence Compression based on Adaptive Classification of Interframe Difference Image Blocks

안철준 · 공성곤

Chul-Joon Ahn and Seong-Gon Kong

숭실대학교 전기공학과

요 약

이 논문에서는 영상시퀀스의 프레임간 차영상 블록을 영상활동도의 크기 및 분포에 따라 적응적으로 분류함으로써 영상시퀀스를 압축하는 기법을 제안한다. 활동도의 크기에 의한 분류에서는 차영상 블록에 포함되어 있는 물체의 에지부분에 해당하는 활동블록과 비활동 블록으로 분류하고, 활동도의 분포에 의한 분류에서는 활동블록들을 이산 코사인변환계수의 분포정도를 특징으로 하여 수직, 수평, 저활동 블록으로 분류한다. 대표적인 분류결과를 이용하여 RBFN 신경망을 학습시켜 프레임간 차영상 블록들의 비선형적인 분류 특성을 얻었다. 시뮬레이션 결과 RBFN을 이용한 차영상 블록의 분류가 영상활동도의 정렬방법이나 다층퍼셉트론 신경망(MLP)에 비해 영상시퀀스의 압축성능이 향상되었다.

ABSTRACT

This paper presents compression of image sequences based on the classification of interframe difference image blocks. Classification process consists of image activity classification and energy distribution classification. In the activity classification, interframe difference image blocks are classified into activity blocks and non-activity blocks using the edge detection. In the distribution classification, activity blocks are further classified into vertical blocks, horizontal blocks, and small activity blocks using the AC energy distribution features. The RBFN, trained with numerical classification results, successfully classifies difference image blocks according to image details. Image sequence compression based on the classification of interframe difference image blocks using the RBFN shows better compression results and less training time than the classical sorting method and the MLP network.

1. 서 론

영상시퀀스의 적응양자화 방법의 기본개념은 프레임간 차영상 블록들을 유사한 특성을 지닌 것끼리 분류하고, 부류별로 다른 비트맵을 할당하여 차등적으로 양자화함으로써 영상압축의 성능을 향상시키는 것이다. 이제까지는 영상블록내에 포함되어 있는 복잡함의 정도를 나타내는 영상활동도(image activity)를 기준으로 영상블록을 분류하는 방법이 널리 사용되어 왔다[1]. 이것은 영상블록내에 포함된 복잡도에 비례하여 영상활동도가 증가한다는 사실을 이용하여, 영상활동도의 크기 순서대로 블록들을 정렬(sort)하고 동일한 개수의 블록들의 부류로 나누어 차등적으로 양자화하는 방법이다. 그러나 영상블록내에 포함된 영상블록들은 복잡함만으로는 표현할 수 없는 다양한 특성을 지니고 있기 때문에, 영상활동도 뿐만 아니

라 복잡함의 분포에 의하여 블록을 분류하는 방법[2]이 제안되었다.

이 논문에서는 RBFN(Radial Basis Function Network)[3][4] 신경망 분류기를 이용하여 차영상 블록들을 분포특성에 따라 효과적으로 분류하고 부호화함으로써 적응적으로 영상데이터를 압축시키는 과정을 제안한다. 여기서는 대표적인 분류과정을 통하여 구한 데이터를 이용하여 RBFN을 학습시키고, 학습된 신경망을 이용하여 영상시퀀스의 블록들을 그 분포 특성에 따라 분류하고 각 부류별로 다른 비트맵을 적용하여 양자화함으로써 영상시퀀스의 압축성능을 향상시킨다. RBFN 신경망은 다층퍼셉트론(MLP) 신경망에 비해 학습속도가 빠르고 패턴인식에 효과적이다[5]. 차영상블록의 분류를 위한 RBFN 신경망의 입력에 해당되는 특징값으로 차영상의 에지 추출을 통한 활동 정도, 영상의 복잡함을 나타내는 AC 에너지,

그리고 이산 코사인변환된 변환계수들의 분포 특성을 사용한다.

2. 차영상블록 분류 알고리즘

블록의 분포특성에 따른 최적의 차영상 블록 분류는 영상시퀀스의 적응압축에서 가장 중요한 문제에 해당한다. 이 논문에서는 영상활동도 분류(activity classification)과정과 분포 분류(distribution classification)과정의 두 단계를 통하여 차영상 블록을 분류하고, 이 결과를 이용하여 영상시퀀스를 압축한다. 그림 1은 이 논문에서 사용하고 있는 차영상 블록의 분류과정을 나타낸다.

2.1. 영상활동도 분류

영상프레임 내에서 어떤 물체가 움직이고 있을 때 그 물체의 움직임은 차영상의 에지부분에 큰 값으로 나타난다. 따라서 영상시퀀스의 프레임간 차영상 블록 $e_k(m,n)$ 의 에지에 해당하는 블록은 영상활동도가 매우 높으므로 활동 블록으로 분류하고, 그렇지 않은 블록들은 비활동(NA; No Activity) 블록으로 분류한

다. 활동 블록으로 분류된 블록들에 대해서는 2차원 이산 코사인변환을 행하고 변환영역에서의 차영상 블록 $E_k(u,v)$ 의 AC 에너지와 변환계수 분포특성에 해당하는 특징값을 추출하고 이 특징들을 기반으로 분포 분류를 하여, 수직(VA; Vertical Activity), 수평(HA; Horizontal Activity), 그리고 저활동(SA; Small Activity) 블록의 부류로 분류한다. 이 방법에 의해 배경에서의 약간의 밝기변화나 잡음으로 인한 차이값들은 에지로 나타나지 않고 실제로 움직이는 대상에서의 변화 부분만이 에지로 추출되므로 밝기의 변화가 큰 에지블록만 선택적으로 압축함으로써 압축률을 높일 수 있다.

공간영역에서의 차영상 $e_k(m,n)$ 과 이산 코사인변환 영역에서의 차영상 $E_k(u,v)$ 은 다음과 같이 정의된다.

$$e_k(m, n) = |x_k(m, n) - \hat{x}_{k-1}(m, n)| \quad (1)$$

$$E_k(u, v) = |X_k(u, v) - \hat{X}_{k-1}(u, v)| \quad (2)$$

에지 추출 방법은 어떤 픽셀의 주변 픽셀들의 변화량을 이용하며, 주변 픽셀간의 변화량은 각 에지 추출 방법의 고유한 창을 영상에 씌움으로써 얻어진다. 이

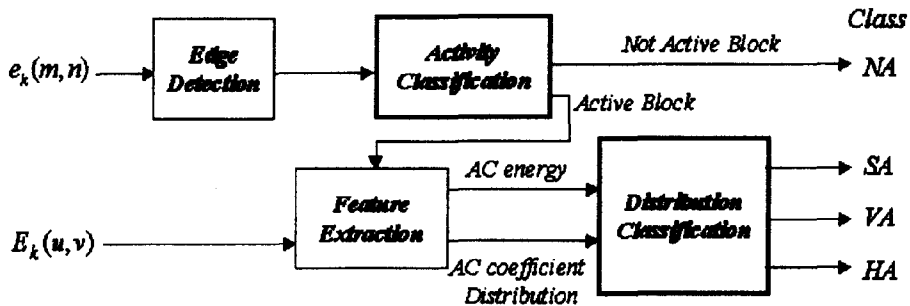



그림 1. 차영상 블록의 분류과정.

Fig. 1. Difference image block classification process.



(a) 차이 영상 $e_k(m, n)$

(b) 에지검출

(c) 활동블록 분류

그림 2. 활동블록의 분류결과.

Fig. 2. The activity block classification result.

논문에서는 대표적 에지 추출 방법인 Sobel 방법[6]을 사용한다. 추출한 에지값을 임계치에 의하여 이진화시키면 8×8의 차영상 블록에 속해 있는 1에 해당하는 픽셀수로 활동블록을 분류한다. 그림 2는 영상 시퀀스 Miss America의 차영상 $e_2(m,n)$ 에 대해서 에지를 추출하고 에지 정보에 의해 활동 블록과 비활동 블록으로 분류한 것이다. 그림 2(c)에서 흰 블록들은 차영상의 에지에 해당하지 않는 비활동(NA) 블록으로 분류된 블록들이고, 검은 블록들은 활동블록에 해당하며 분포에 따른 분류과정을 거쳐 세분된다.

2.2 분포 분류

2.2.1 활동 블록의 특성값

영상활동도 분류 단계에서 활동 블록으로 분류된 블록들에 대해서는 영상블록 내에 포함되어 있는 에너지의 분포특성에 따라 여러개의 부류로 분류한다. 그림 3은 분포분류 과정을 나타낸다.

AC에너지 E_{AC} 의 정규화된 크기를 비교하여 임계치 θ 보다 작은 경우는 SA로 분류하고, θ 보다 큰 블록에 대해서는 변환계수 분포 특성 E_d 를 비교하여 0보다 크면 VA로 분류하고, 0보다 작으면 HA로 분류한다. 이때 AC 에너지 E_{AC} 는 -1에서 1사이로 정규화하고 임계치는 $\theta=0$ 으로 하였다.

활동 블록의 특성값으로는 AC 에너지와 변환 계수 분포값이 있다. AC 에너지는 블록의 복잡함의 정도를 나타내는 지표이다. 즉, AC 에너지의 값이 상대적으로 크면 보다 복잡한 영역이라고 볼 수 있고, AC 에너지의 값이 상대적으로 작다면 덜 복잡한 영역이라고 볼 수 있다. 따라서 활동 블록으로 분류된 블록들에 대해서 보다 복잡한 블록과 덜 복잡한 블록으로 나누게 된다. $M \times N$ 크기의 블록에 대한 AC 에너지 E_{AC} 는 식 (3)으로 구한다.

$$E_{AC} = -E_k^2(0, 0) + \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} E_k^2(u, v) \tag{3}$$





그림 3. 분포 분류 과정
Fig. 3. The distribution classification process.



(a) $W_v(u, v)$ (b) $W_h(u, v)$

그림 4. 변환계수 분포특징 추출을 위한 창.

Fig. 4. Windows for AC coefficient distribution feature extraction.

변환계수 분포특성은 이산 코사인 변환된 차영상 블록의 계수 분포가 어떤 방향으로 분포하는지에 대한 수치이다. 영상블록의 에지특성이 변환계수의 분포에 반영되므로 이것을 블록분류에 적용하여 에지부분의 화질의 열화를 막을 수 있으며, 계수의 위치별로 발생할 확률이 높은 블록들끼리 분류함으로써 비슷한 분포특성을 가지는 블록들에 적당한 비트맵을 할당하기 위해서이다. 변환계수의 분포 특성값은 그림 4와 같은 수직창과 수평창을 각 블록에 씌움으로써 얻어진다.

창씩우기를 거친 각 블록들은 식 (4),(5)에 의해서 변환 계수의 각 분포 특징에 대한 d_v 와 d_h 를 얻는다[7].

$$d_v = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} |W_v(u, v) E_k(u, v)| \tag{4}$$

$$d_h = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} |W_h(u, v) E_k(u, v)| \tag{5}$$

차영상 $E_k(u, v)$ 에 각 분포 특징창 $W(u, v)$ 를 씌움으로써 수치, 수평의 방향의 분포값을 추출한다. 수치값과 수평값을 구하고, 두 값의 차이를 변환 계수의 분포값으로 정한다.

$$E_d = d_v - d_h \tag{6}$$

식 (6)에서 변환 계수의 분포값이 양수이면 그 블록은 수직의 분포 특성이 큰 블록으로 정하고, 음수이면 수평의 분포 특성이 큰 블록으로 결정한다.

2.2.2 블록 분류

차영상 활동 블록들의 AC 에너지와 변환 계수 분포값을 -1에서 1사이로 정규화하고 AC 에너지가 임계치 θ 보다 작은 값으로 분류된 블록들에 대해서는 SA로 분류한다. AC 에너지가 θ 보다 큰 값으로 분류된 블록들에 대해서는 변환 계수의 분포 특성값을 비교하는데, 변환 계수 분포값이 양수이면 VA로, 변환 계수 분포값이 음수이면 HA로 분류하는 것이다.




그림 5. 분류 알고리즘에 의한 분류 결과.
Fig. 5. Result of classification algorithm.

그림 5는 지금까지 설명한 두 단계의 블록 분류 알고리즘에 의해 차영상 $e_x(m, n)$ 을 분류한 결과이다. 프레임간 변화가 거의 없는 대부분의 영역이 NA로 분류되고, 변화가 심한 에지부분에 있어서는 세밀한 분류가 이루어져 있음을 알 수 있다. 그림 5에서 흰 블록들(□)은 차영상의 에지에 해당하지 않는 비활동(NA) 블록으로 분류된 블록들이고, 활동 블록들은 분포분류 과정을 거쳐 SA(▨), VA(▣), HA(▧) 부류로 세분된다.

3. RBFN을 이용한 차영상블록 분류

3.1 RBFN 신경망 분류기

RBFN 신경망은 가우시안 함수들의 지역적인 근사화 과정을 통해서 학습하므로 다양한 입력 패턴에 대해 다층 퍼셉트론 신경망보다 학습속도가 빠르고 패턴분류 성능이 우수한 장점이 있다. RBFN 신경망을 통한 분류는 활동 블록들에 대한 분포분류 과정만을 포함한다. 본 논문에서 사용한 RBFN 신경망 분류기의 구조는 그림 6과 같다.

그림 6에서 입력값 f_1, f_2 는 각각 특징값 E_{AC} 와 E_d 이




그림 6. RBFN 신경망 분류기의 구조.
Fig. 6. Structure of the RBFN classifier.

다. $c_j=[c_{j1}, c_{j2}]$, $j=1, \dots, 9$ 는 중간층의 중심점벡터이고, $\sigma_j=[\sigma_{j1}, \sigma_{j2}]$, $j=1, \dots, 9$ 는 중심점에서 가우시안 함수폭 벡터이다. σ_{j1}, σ_{j2} 는 출력층의 출력값으로 1 또는 0의 값을 가진다. 연결강도 W 는 중간층과 출력층 사이에서만 존재한다. 일단 중심점과 함수폭이 결정되면 식 (7)에 의해서 중간층의 가우시안 출력 r_j 를 구한다.

$$r_j = \exp \left(- \sum_{i=1}^2 \frac{(f_i - c_{ji})^2}{2\sigma_{ji}^2} \right), \quad j=1, \dots, 9 \quad (7)$$

중간층 각 뉴런은 가우시안 함수에 의하여 출력값을 생성한다. 즉 각 중심점에서 가까운 입력값은 큰 출력값을 내고, 중심점에서 멀어진 입력값이 들어올수록 0에 가까운 출력이 나온다. 가우시안 함수폭은 그 중심점에서의 가우시안 함수가 얼마나 넓게 퍼져 있는가에 대한 변수가 된다. 연결강도 W 는 원하는 출력 $Z=[z_1, z_2, \dots, z_K]$, $z_i=[z_{i1}, z_{i2}]^T$ 와 중간층 출력값 $R=[r_1, r_2, \dots, r_K]$, $r_i=[r_{i1}, r_{i2}, \dots, r_{i9}, 1]^T$ 으로 식 (8)과 같은 행렬식으로 표현할 수 있다. 여기서 K 는 입출력 데이터의 개수를 나타낸다.

$$RW = Z \quad (8)$$

그러나 중간층 출력 R 이 정방행렬이 아니기 때문에 제곱오차 $\|Z - RW\|^2$ 를 최소가 되도록 다음 식에 의해서 W 를 결정한다.

$$W = R^+ Z \quad (9)$$

여기서 $R^+ = (R^T R)^{-1} R^T$ 은 R 의 의사역행렬(pseudoinverse)이다. RBFN은 중심점과 함수폭만 결정되면 연결강도 W 를 식 (9)에 의해서 한 번에 계산할 수 있으므로 학습에 소요되는 시간을 줄일 수 있다.

3.2 RBFN 블록분류기의 학습

블록 분류를 위한 RBFN의 학습 데이터로는 세 종류의 영상시퀀스 'Salesman,' 'Football,' 그리고 'Tennis'의 6개 차영상 중 활동블록으로 분류된 블록들의 특징값을 사용하였다. 블록 특징값 중 1차원 특징은 AC 에너지에 대한 크기순으로 정렬된 값이고, 2차원 특징은 변환 계수 분포값이다. 낮은 AC 에너지에서의 변환계수 값은 거의 0 근처에 분포되어 있기 때문에 절대값의 제곱근을 취한 후, 원래의 부호를 붙였다.

3.2.1 중심점의 개수 및 위치 선택

중심점 c_j 의 위치와 개수를 결정하는 것은 RBFN의 학습 과정에서 매우 중요하다. 중심점의 개수를 하나씩 늘려가면서 RBFN을 학습하는데, 이 때 중심점 위치의 결정은 중요한 영향을 미친다. 중심점의 위치는




그림 7. 경쟁 학습에 의한 중심점 결정

Fig. 7. Decision of center using the competitive learning algorithm.

이론적으로 각 부류의 확률 분포를 알고 있다고 가정했을 때, 각 부류의 평균값의 위치가 중심점의 위치가 된다. 하지만 실제의 문제에 있어서는 각 부류의 확률 분포를 추정하기 어려우며, 따라서 분류하고자 하는 부류의 개수만의 중심점으로는 학습 인식률을 제대로 만족시킬 수 없다. 그러므로 중심점의 개수를 부류의 개수보다 더 증가시키면서 학습을 진행해야 되는데, 이 논문에서는 경쟁 학습 알고리즘[8]을 사용하여 중심점의 위치를 결정하였다.

그림 7은 학습 데이터의 분포 내에서의 중심점의 위치를 그린 것이다. 중심점의 개수 선정에서, 초기치는 부류의 수 3개로 시작했고, 중심점 개수를 증가시킬 때마다 각각 3번 반복 학습하였다. 중심점의 개수가 같다고 할지라도 그 위치에 따라서 분류 결과가 달라지므로 3번의 반복 학습을 통한 평균 오차값을 구해서 학습 인식률을 판단하였다. 평균 오차값이 목표치에 추종하지 못했을 경우에는 중심점의 수를 한 개씩 증가시켜서 위의 단계를 반복하였다.

3.2.2 함수폭의 결정

RBFN의 학습과정에서 또 하나의 중요한 변수는 각 중심점에서의 함수폭이다. σ_i 는 각 중심점 c_i 에서의 가우시안 함수폭을 의미한다. 즉 σ_i 는 각 중심점에서의 가우시안 함수가 얼마나 넓은 범위로 퍼져 있는가 하는 척도가 된다. 함수폭 σ_i 를 구하기 위해서는 여러가지 방법들[9][10]이 있으나 본 논문에서는 가장 인접한 중심점까지의 거리의 절반으로 결정하였다[11].

$$\sigma_i = \frac{1}{2} \|c_j - \hat{c}_j\|, \quad i=1,2 \tag{10}$$

\hat{c}_j 는 c_j 에서 가장 가까운 중심점을 나타낸다. SA는




그림 8. RBFN 분류 경계선.

Fig. 8. Decision boundary of RBFN.

변환계수 분포값에는 무관하게 AC 에너지에 의해서만 분류되고, VA와 HA는 변환계수 분포값에 의해서 부호에 따라 분류된다. 따라서 SA에 해당하는 중심점인 경우는 가우시안 분포의 형태가 가로축보다는 세로축으로 보다 길게 분포하고, VA와 HA에 해당하는 중심점의 경우는 가우시안 분포의 형태가 세로축보다는 가로축으로 길게 분포할 때 전체 학습데이터에 대한 학습 성능이 향상될 수 있다. 부류의 분포에 따라 각 축에 대한 비율의 차이를 1:2 혹은 2:1로 해서 총 100회의 학습을 수행한 결과, 전체 1,532개의 학습 데이터에 대해 잘못 분류된 데이터의 평균 개수가 27개가 나왔고, 비율을 고정한 학습에서의 잘못 분류된 평균 개수는 82개가 나왔다. 따라서 각 부류의 특성을 이용하여 각 축에 대한 함수폭의 비율을 달리 한 학습 방법이 그렇지 않은 학습에 비해 향상되었음을 알 수 있다.

3.3 블록 분류 결과

RBFN 패턴분류기의 학습을 수행하는 과정에서 전체 학습 데이터에 대해서 올바르게 분류한 데이터의 비율이 98% 이상이 되도록 충분히 학습하였다.

그림 8은 학습된 RBFN 신경망에 의하여 얻어진 분류 경계선으로서, 분류 알고리즘에 의해서 생성된 선형적인 경계선과는 달리 비선형인 것을 알 수 있다. 실제 데이터로 사용되는 영상시퀀스의 종류와 이로부터 추출되는 차영상 블록들은 매우 다양하므로 선형적인 분류는 적합하지 않다. RBFN에 의한 비선형 분류 경계선은 실제 데이터 분포에 가까운 분류결과이다.

4. 압축 성능 비교

4.1 시뮬레이션 조건

시뮬레이션에서는 두 가지 영상시퀀스 Miss America와 Flower의 16개 프레임을 사용하였다. 'Miss America'는 256×256의 크기로 앉아 있는 한 여성이 대화를 하면서 얼굴이나 어깨, 그리고 눈과 입 부분을 움직이는 영상시퀀스이고, 'Flower'는 240×352크기로 시간에 따라 영상이 점차 확대되면서 꽃잎들이 바람에 날리는 영상시퀀스이다.

동영상 압축의 성능을 평가하기 위하여 동일한 압축률에서 최대 신호대잡음비(PSNR)를 계산하였다. 영상시퀀스의 각 프레임의 압축률은 다음과 같이 계산된다.

$$R_k = \sum_{c=1}^4 N_c \left(2 + \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} B_c(u, v) \right) / PQb \quad (11)$$

여기서 분자부분은 $M \times N$ 크기의 블록으로 이루어지는 차영상 프레임을 표현하는데 사용된 총 비트 수를 나타낸다. $B_c(u, v)$ 는 부류 c 의 차영상블록을 부호화하기 위하여 할당된 비트맵이고, N_c 는 각 부류로 분류된 블록의 개수를 나타낸다. $P \times Q$ 는 전체 영상의 크기이고, 사용한 영상시퀀스의 각 픽셀의 밝기레벨은 256이므로 $b=8$ 이다. 전체 영상시퀀스의 압축률은 첫 번째 프레임을 제외한 모든 프레임의 압축률의 평균으로 계산하였다. 압축된 영상의 화질을 평가하는 기준으로 PSNR를 사용한다.

$$PSNR \text{ (dB)} = 10 \log_{10} \frac{(2^b - 1)^2}{MSE} \quad (12)$$

여기서 평균제곱오차(MSE)는 다음과 같이 정의된다.

$$MSE = \frac{1}{PQ} \sum_{m=0}^{P-1} \sum_{n=0}^{Q-1} (x_k(m, n) - \hat{x}_k(m, n))^2 \quad (13)$$

여기서 $x_k(m, n)$ 및 $\hat{x}_k(m, n)$ 은 각각 k 번째 원 영상 및

복원된 영상이다.

4.2 시뮬레이션

RBFN 분류 방법에 대한 압축성능 비교 대상으로 정렬 방법과 다층 퍼셉트론 신경망을 사용하였다. 정렬 방법은 AC 에너지의 크기 순서대로 정렬하여 같은 4개의 부류로 분류하는 방법이고, 신경망에 의한 방법에는 다층 퍼셉트론 신경망과 RBFN 신경망을 사용하여 분류하는 방법이다. 다층 퍼셉트론의 경우, 중간층 뉴런수는 20, 최대 epoch수는 10000회로 학습하였다.

시뮬레이션을 통하여 정렬 방법과 MLP, 그리고 RBFN의 압축성능을 압축비 대 PSNR에 의하여 비교하였다. 그림 9는 압축비가 30:1인 경우에 두 테스트 영상시퀀스에 대한 압축 성능을 비교한 것이다.

그림 10은 테스트 영상시퀀스의 정렬 방법과 다층 퍼셉트론 방법, 그리고 RBFN 방법에 대한 16번째 프레임의 복원 영상에 대한 그림이다. 복원 영상은 앞단의 프레임에 비해 오차가 누적되어 화질의 열화가 좀 더 많다.

그림 9와 그림 10의 결과를 통하여 RBFN 방법과 다층 퍼셉트론 방법이 압축 성능과 실제 영상의 화질에서 정렬 방법에 비해 더 우수함을 볼 수 있다. RBFN과 다층 퍼셉트론의 평가에서는 학습 성능과 분류 성능을 비교하였다. 차영상의 블록들처럼 다양하고 복잡한 특성을 지닌 비선형 분류에 있어서 지역적 근사화 신경망인 RBFN이 다층 퍼셉트론보다 쉽고 빠르게 학습되며, 분류성능에 있어서도 중간층의 개수가 다층 퍼셉트론에 비해서 절반에 불과하므로 빠른 분류성능을 지닌다. 시뮬레이션 결과 RBFN의 평균 학습속도와 프레임당 평균 분류 속도면에서 다층 퍼셉트론에 비해서 50% 이상 향상되었다.

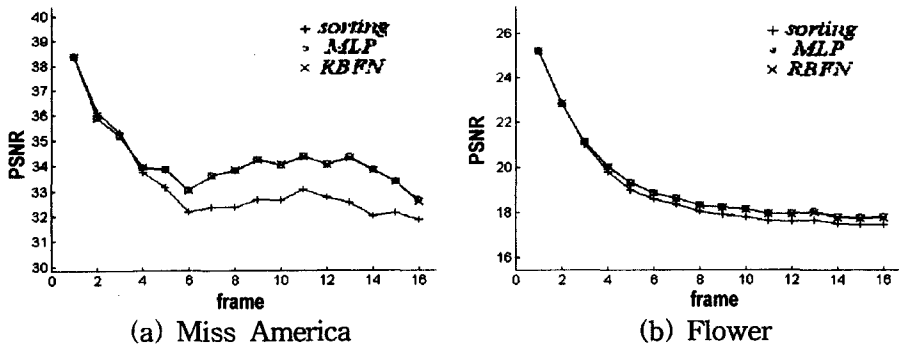


그림 9. 압축비 30:1일 경우 압축성능 비교.

Fig. 9. Compression performance for compression ratio 30:1.




그림 10. Miss America 영상시퀀스의 복원 영상.
Fig. 10. Reconstruction of the 'Miss America' sequence.


5. 결 론

본 논문에서는 RBFN을 이용한 영상시퀀스의 적응 양자화 기법에 대해서 살펴보았다. 제안한 분류 알고리즘은 크게 두 단계로 나누었는데, 첫 단계에서는 에지 추출 방법에 의한 활동 블록과 비활동 블록(NA)의 분류이고, 두 번째 단계에서는 블록의 AC 에너지와 변환 계수 분포값에 의해서 SA, VA, HA로 분류하는 과정이다. 두 단계의 분류과정은 움직임으로 파악되는 영역들을 보다 구체적으로 분류함으로써 변화가 심한 부분에 대한 복원 성능을 향상시켜 인간의 시각에 보다 민감한 영역의 화질의 열화를 최대한 막을 수 있었다. 시뮬레이션에서 정렬 방법과 다층 퍼셉트론 방법을 비교 대상으로 하여 RBFN의 압축 성능을 검증하였다. 압축 성능에서 정렬 방법보다 RBFN과 다층 퍼셉트론의 방법이 개선되었고, MLP보다

RBFN의 학습속도가 단축되었음을 확인하였다.


참고문헌

- [1] W. H. Chen and C. H. Smith, "Adaptive Coding of Monochrome and Color Images", *IEEE Trans. on Communications*, COM-25(11), 1285-1292, 1977.
- [2] S.-G. Kong and B. Kosko, "Fuzzy Subimage Classification in Image Sequence Coding", *Proceedings of International Conference on Acoustics, Speech, and Signal Processing (ICASSP-92)*, Vol. III, pp. 517-520, March 1992.
- [3] T. Poggio and F. Girosi, "Networks for approximation and learning", *Proceedings of the IEEE*, 78, 1481-1497, 1990.
- [4] M. J. D. Powell, J. C. Mason, and M. G. Cox, eds., "Radial basis functions for multivariable interpolation: A review", *Algorithms for the Approximation of Functions and Data*, Oxford, England: Clarendon Press, 143-167, 1987.
- [5] S. Haykin, *Neural Networks: A Comprehensive Foundation*, Macmillan College Pub., 1994.
- [6] D. Marr and E. Hildreth, "Theory of Edge Detection", *Proceedings R. Soc. Lond.*, B207, 187-217, 1980.
- [7] 안철준, 공성곤, "블록의 활동 레벨과 에지 특성의 분류를 이용한 동영상의 적응 양자화", *한국 퍼지 및 지능시스템 학회 춘계학술대회 논문집*, 7(1), 191-194, 1997.
- [8] T.Kohonen, *Self-Organization and Associative Memory*, 2nd ed., Berlin: Springer-Verlag, 1987.
- [9] D.Lowe and A.R.Webb, "Adaptive networks, dynamical systems, and the predictive analysis of time series", 1st IEEE International Conf. on Artificial Neural Networks, 95-99, 1989.
- [10] M.J.D.Powell, "Radial basis function approximations to polynomials", *Proc. of Numerical Analysis*, 223-241, 1988.
- [11] 신요안, 윤병문, 임영선, "Complex radial basis function network을 이용한 비선형 디지털 위성 통신 채널의 등화", *한국통신학회논문지*, 21(9), 2456-2469, 1996.



안철준(Chul-Joon Ahn)

1996년 : 숭실대학교 전기공학과(학사)
1998년 : 숭실대학교 대학원 전기공학과(석사)
1998년~현재 : 주식회사 흥창 기술연구소 앰프개발팀 연구원
주관심분야 : 영상인식, 영상압축, 지능 제어



공성곤(Seong-Gon Kong)

1982년 : 서울대학교 전기공학과(학사)
1987년 : 서울대학교 대학원 전기공학과(석사)
1991년 : 미국 University of Southern California 전기공학과(학사)
1992년~현재 : 숭실대학교 전기공학과 부교수

주관심분야 : 퍼지시스템, 신경회로망, 지능제어, 신호처리, 패턴분류