

논문 2004-41SP-4-4

웨이블릿 영역에서 훈련 없는 은닉 마코프 트리 모델을 이용한 영상 보간

(Image Interpolation Using Hidden Markov Tree Model Without Training in Wavelet Domain)

우 동 현*, 엄 일 규**, 김 유 신***

(Dong Hun Woo, Il Kyu Eom, and Yoo Shin Kim)

요 약

웨이블릿 변환은 영상을 분석하고 처리하는데 유용한 도구로써 영상 압축, 영상 잡음 제거 등의 분야에서 우수한 성능을 보여주었다. 웨이블릿 계수들은 은닉 마코프 트리(Hidden Markov Tree: HMT) 모델^[1]에 의해 효과적으로 모델링될 수 있다. 그러나 영상 보간에서 은닉 마코프 트리 모델을 적용하기 위해서는 훈련 과정이 필요하며 훈련 과정에서 획득된 파라미터들이 입력 영상과 잘 맞지 않는 단점이 있다. 본 논문에서는 웨이블릿 영역에서 영상 보간을 위해 은닉 마코프 트리의 구조를 사용하되, 그 파라미터들은 훈련 과정 없이 부대역간의 통계적 특성을 이용하여 직접 추정한다. 제안 방법에서 웨이블릿 계수는 가우스 혼합 모델(Gauss Mixture Model: GMM)로 모델링된다. 가우스 혼합 모델의 상태 천이 확률은 부대역간의 웨이블릿 계수의 통계적 천이 특성을 이용하여 결정하며, 각 상태의 분산은 웨이블릿 계수의 지수적 감소(exponential decay) 특성에 의해 추정된다. 모의실험에서 제안 방법은 전통적인 bicubic 방법이나 훈련 과정을 필요로 하는 은닉 마코프 모델을 사용한 방법^[2]보다 여러 테스트 영상들에 대해서 개선된 성능을 보여주었다.

Abstract

Wavelet transform is a useful tool for analysis and process of image. This showed good performance in image compression and noise reduction. Wavelet coefficients can be effectively modeled by hidden Markov tree(HMT) model^[1]. However, in application of HMT model to image interpolation, training procedure is needed. Moreover, the parameters obtained from training procedure do not match input image well. In this paper, the structure of HMT is used for image interpolation, and the parameters of HMT are obtained from statistical characteristics across wavelet subbands without training procedure. In the proposed method, wavelet coefficient is modeled as Gaussian mixture model(GMM). In GMM, state transition probabilities are determined from statistical transition characteristic of coefficient across subbands, and the variance of each state is estimated using the property of exponential decay of wavelet coefficient. In simulation, the proposed method shows improvement of performance compared with conventional bicubic method and the method using HMT model with training^[2].

Keywords : 영상 보간, 은닉 마코프 트리 모델, 훈련, 웨이블릿

* 정회원, 부산대학교 전자공학과
(Dept. of Electronic Engineering, Pusan National University)

** 정회원, 밀양대학교 정보통신공학과
(Dept. of Information and Communication, Miryang National University)

*** 정회원, 부산대학교 컴퓨터 및 정보통신 연구소
(Research Institute of Computer and Information and Communication, Pusan National University)

※ 본 연구는 부산대학교 교내학술연구비(4년과제)에 의한 연구임.

접수일자: 2004년3월15일, 수정완료일: 2004년6월3일

I. 서 론

영상 보간은 영상을 확대하기 위해 기존의 화소들 사이에 적절한 값을 삽입하는 기술이다. 오늘날 영상 보간은 디지털 카메라, 캠코더 같은 디지털 영상 획득 매체와 인터넷을 통한 디지털 영상의 전송 방법의 발달로 그 중요성이 커지고 있다. 또한 영상 보간은 비월 주사 영상을 순차 주사 영상으로 변환하는 deinterlacing이나 여러 장의 저해상도 영상으로부터 한 장의 고해상도 영

상을 만들어 내는 superresolution등과도 밀접한 관련을 맺고 있다.

일반적으로 저해상도 디지털 영상은 고해상도 영상이 저대역 통과 필터를 통과한 후 다운 샘플링된 것으로 볼 수 있다^[3]. 이 과정에서 고해상도 영상의 고주파 성분은 aliasing에 의해 손실된다. 이 고주파 성분의 손실로 인해 다시 확대된 영상은 원 고해상도 영상보다 흐린 영상이 된다. 특히 이러한 현상은 영상의 에지영역에서 두드러진다.

이렇게 손실된 고주파 성분을 복구하는 것은 영상 보간 분야에서의 중요한 연구 주제이다. EDI (edge-directed interpolation) 방법^[4]은 에지 영역에서 흐림 현상을 해결하기 위한 비선형적 방법이다. 이 방법은 에지를 더 선명하게 하지만, 다른 여러 artifact들도 같이 만들어 내는 단점이 있으며 객관적인 성능도 별로 좋지 않다. NEDI(new edge-directed interpolation)^[5] 방법은 입력 저해상도 영상의 국부 영역의 상관도를 최소자승법으로 추정하여 이 상관도를 고해상도 영상의 화소를 복원하기 위한 가중치로 사용한다. 이 방법은 저해상도 영상과 고해상도 영상의 상관도가 높은 길고 강한 에지에서는 우수한 주관적, 객관적 성능을 보여주지만 상관도가 낮은 텍스처 부분이나 복잡한 에지에서는 여러 artifact들을 발생시키며 계산량 부담이 크다.

최근에는 웨이블릿 영역에서 영상을 보간하는 방법들이 제안되었다^{[2][6]}. 웨이블릿 영역에서 영상 보간은 웨이블릿 영역의 고주파 부대역의 계수의 크기와 부호를 추정하는 것으로 볼 수 있다^[2]. Carey에 의해 제안된 방법^[6]에서는 웨이블릿 계수가 저주파 부대역에서 고주파 부대역으로 감에 따라 지수적으로 감소하는 특성을 이용하여 계수를 추정하였다. 이 방법은 에지를 더욱 선명하게 한다. 그러나 지수적 감소 특성은 강한 고립 에지에서는 잘 맞지만 텍스처같은 복잡한 에지 영역에서는 잘 맞지 않은 단점이 있다. Kinebuchi는 은닉 마코프 트리 모델을 사용한 방법^[2]을 제안하였다. 이 방법도 역시 bicubic 방법 같은 기존의 보간 방법들에 비해 선명한 영상을 보여준다. 그러나 은닉 마코프 트리 모델의 파라미터들을 획득하기 위해서는 훈련 영상에 의한 훈련 과정이 필요하다. 또한 구해진 파라미터들이 입력 영상과 잘 맞지 않은 경우들이 종종 생긴다.

제안 방법에서는 앞에서 언급한 은닉 마코프 트리 구조를 사용하여 영상을 보간하되, 그 파라미터들은 훈련 과정 없이 입력 영상으로부터 부대역간의 통계적 특성을 이용하여 직접 구해진다. 제안 방법에서 각 계수에

대한 가우스 혼합 모델의 부모 계수의 상태는 각 계수의 크기에 따라 결정되며 상태 천이 확률은 웨이블릿 계수의 부대역간의 통계적 특성^[7]에 의해 미리 정해진다. 각 계수의 가우스 혼합 모델의 분산들은 웨이블릿 계수의 지수적 감소 특성을 이용하여 입력 영상으로부터 추정된다. 이렇게 구해진 파라미터들로부터 성립된 은닉 마코프 트리 모델은 학습 과정이 불필요할 뿐 아니라, 입력 영상의 특성을 더 잘 반영하는 장점이 있다. 제안 방법은 모의실험에서 기존의 bicubic 방법뿐만 아니라 훈련 과정을 필요로 하는 은닉 마코프 모델을 사용한 Kinebuchi의 방법보다 개선된 PSNR성능을 나타내었다. 또한 주관적인 면에서도 기존 방법들에 비해 좋은 화질을 보여주었다.

본 논문은 다음과 같이 구성되어 있다. 먼저, II장에서 웨이블릿 영역에서 은닉 마코프 트리 모델이 소개된다. 이어서 III장에서는 제안 방법이 설명된다. IV장에서는 모의실험 결과를 보이고 V장에서 결론을 맺는다.

II. 웨이블릿 영역에서 은닉 마코프 트리 모델

웨이블릿 변환된 영상은 여러 개의 부대역으로 나누어지며, 각 부대역들은 영상의 특정한 주파수 대역의 특성을 나타낸다. 그림 1에서 볼 수 있는 바와 같이 각 부대역의 계수들은 다른 부대역의 해당 위치에 있는 계수들과 통계적인 측면에서 밀접한 관계를 보여준다. 이러한 관계는 영상 압축이나 잡음 제거 분야에서 널리 이용되어 왔다. 그림 1에서 하나의 계수에 대해 그 계수의 바로 위의 저주파 부대역에서 해당 위치에 있는 계수를 그 계수의 부모계수(parent coefficient)라고 하고, 그 계수의 바로 밑의 고주파 부대역에 있는 해당 계수를 그 계수의 자식 계수(child coefficient)라고 한다.

웨이블릿 영역에서 해당 계수의 부모 계수와 자식 계수 사이의 통계적 상관성은 그림 2와 같이 웨이블릿 영역에서의 은닉 마코프 트리 모델에 의해 효과적으로 모델링될 수 있다^[1]. 그림 2에서 가로축은 공간 영역을 나타내며 세로축은 주파수 영역을 나타낸다. 검은 부분은 웨이블릿 계수를 의미하고, 흰 부분은 각 계수의 상태(state)를 뜻한다. 본 논문에서 각 계수는 2개의 상태 중 하나를 가지며 상태 0과 상태 1로 표시한다. 상태 0은 계수의 크기가 큰 중요계수(significant coefficient)를 뜻하고 상태 1은 계수의 크기가 작은 비중요계수(non-significant coefficient)를 나타낸다. 이 상태들은

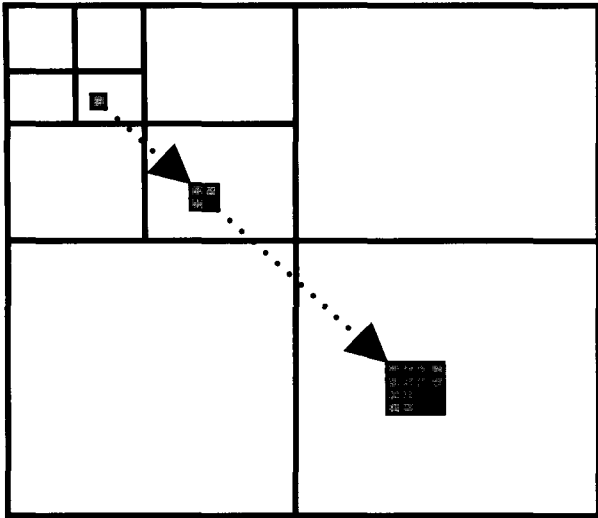


그림 1. 웨이블릿 영역에서 다른 부대역들의 계수들 사이의 상관성
 Fig. 1. The correlation between coefficients of different subbands in wavelet.

상태 확률(state probability)로 표현된다. 또한 계수들의 상태들 사이의 실선은 계수들 간의 상관성을 나타내며 상태 천이 확률(state transition probability)의 형태로 모델링된다.

웨이블릿 계수는 라플라스 확률모델, 가우스 혼합모델, 또는 일반화된 가우스 모델 등으로 모델링될 수 있다. 일반적으로 활용의 용이성과 모델의 정확성 때문에 가우스 혼합 모델이 많이 이용된다. 본 논문에서는 계수의 각 상태에 하나의 가우스 확률모델을 할당하고 각 가우스 확률모델들을 선형 조합한 가우스 혼합모델로써 웨이블릿 계수를 모델링한다.

그림 2와 같은 구조를 가진 은닉 마코프 트리 모델은 상태 확률, 상태 천이 확률, 각 상태의 가우스 확률모델의 평균과 분산을 구함으로써 완성된다.

$$\theta = [P(S_i(m)), \epsilon_{i,\rho(i)}^{m}, \mu_{m,i}, \sigma_{m,i}^2] \quad (1)$$

식 (1)에서 $P(S_i(m))$ 는 i 번째 계수 w_i 가 m 상태가 될 확률이며, $\epsilon_{i,\rho(i)}^{m}$ 는 i 번째 계수의 부모계수 $w_{\rho(i)}$ 가 n 상태일 때, i 번째 계수 w_i 가 m 상태로 천이할 확률이다. 또한 $\mu_{m,i}, \sigma_{m,i}^2$ 은 각각 w_i 가 m 상태일 때의 평균과 분산이다. 웨이블릿 계수의 부대역간의 통계적 상관성은 상태천이 확률로써 모델링될 수 있다. 즉, 부모계수가 '1'의 상태를 가질 때, 자식 계수의 상태가 '1' 또는 '0'이 될 확률을 구함으로써 웨이블릿 계수의 부대역간 통계적 특성을 간단히 표현할 수 있다.




그림 2. 웨이블릿 영역에서의 은닉 마코프 트리 모델
 Fig. 2. The hidden Markov tree model in wavelet domain.




그림 3. 상태천이확률의 개념
 Fig. 3. The interpretation of state transition probability.

웨이블릿 영역에서 영상 보간은 고주파 부대역의 계수 추정문제로 볼 수 있다. 따라서 상태천이 확률로 표현되는 부대역간의 통계적 상관성을 이용하여 웨이블릿 영역에서 영상 보간을 수행할 수 있다. 그림 3은 각 계수 당 2개의 상태가 존재할 때, 상태천이확률의 개념을 보여준다.

식 (1)의 파라미터들은 훈련 영상들에 대해 EM(expectation-maximization) 알고리즘을 사용하여 추정될 수 있다. 그러나 식 (1)에서 보는 바와 같이 파라미터들은 각 계수들에 대해 존재하므로 훈련해야 할 파라미터의 수가 너무 많다. 또한 이렇게 훈련된 파라미터들은 훈련 영상에 대해 편향되어 실제 입력 영상에 대해서는 잘 반응하지 않는 문제점이 있다. 이런 문제점들 때문에 실제 적용에서는 일반적으로 각 부대역 안에서는 모

든 계수에 대해 동일한 파라미터들을 사용하는 묶음 (tying) 방법이 사용된다.

III. 제안 방법

웨이블릿 영역에서의 영상 확대는 저주파 부대역들의 계수들로부터 고주파 부대역의 계수의 크기와 부호를 추정하는 과정으로 볼 수 있다. 영상 잡음 제거의 경우와는 달리 웨이블릿 영역에서 영상 확대에서는 입력 영상으로부터 고주파 부대역에 대한 어떤 정보도 직접적으로 주어지지 않는다. 따라서 보간 방법으로 은닉 마코프 트리 모델을 사용할 때 필요한 파라미터들은 훈련 영상으로부터 구해지게 된다. 그러나 이는 훈련 과정을 필요로 할 뿐 아니라 훈련 영상에서 획득한 고주파 부대역에 대한 파라미터들은 훈련 영상에 대한 파라미터들이므로 입력 영상에 대해 바로 적용하기에는 무리가 있다. 이러한 문제를 해결하기 위해 제안 방법에서는 은닉 마코프 모델의 구조를 사용하되 그 파라미터들을 훈련 과정 없이 웨이블릿 변환된 영상의 부대역 간의 통계적 특성을 이용하여 추출한다.

본 논문에서는 웨이블릿 계수를 가우스 혼합모델에 의한 랜덤 변수로서 가정한다. 따라서 웨이블릿 계수에 대한 확률밀도 함수는 각 상태에 대해 다른 평균과 분산을 가지는 가우스 확률밀도 함수들의 선형조합으로 표현할 수 있다.

$$\begin{aligned} P(w_i) &= P(w_i | S_i(0))P(S_i(0)) + P(w_i | S_i(1))P(S_i(1)) \\ &= g(w_i; 0, \sigma_{i,0}^2)P(S_i(0)) + g(w_i; 0, \sigma_{i,1}^2)P(S_i(1)) \end{aligned} \quad (2)$$

식 (2)에서 $g(w_i; \mu, \sigma^2)$ 은 평균 μ 와 분산 σ^2 을 가진 가우스 확률밀도 함수를 나타내며 그 수식은 다음과 같다.

$$g(w_i; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(w_i - \mu)^2}{2\sigma^2}\right] \quad (3)$$

일반적으로 웨이블릿 영역에서 최저주파 부대역이 아닌 부대역의 웨이블릿 계수의 평균은 0으로 설정된다. 그림 3의 구조에 대해, 식 (2)의 가우스 혼합 모델은 다음과 같이 표현될 수 있다.

$$\begin{aligned} P(w_i) &= g(w_i; 0, \sigma_{i,0}^2)(\epsilon_{i,\rho(i)}^{00}P(S_{\rho(i)}(0)) + \epsilon_{i,\rho(i)}^{01}P(S_{\rho(i)}(1))) \\ &\quad + g(w_i; 0, \sigma_{i,1}^2)(\epsilon_{i,\rho(i)}^{10}P(S_{\rho(i)}(0)) + \epsilon_{i,\rho(i)}^{11}P(S_{\rho(i)}(1))) \end{aligned} \quad (4)$$

식 (4)를 통해 고주파 부대역의 웨이블릿 계수의 확률 밀도 함수는 부모 계수의 정보와 연결된다. 제안 방법에서는 부모계수의 부대역의 표준편차를 이용해서 부모 계수의 상태를 결정한다.

$$S(w_{\rho(i)}) = \begin{cases} 0 & \text{if } |w_{\rho(i)}| < \alpha\sqrt{\sigma_{k(\rho(i))}^2} \\ 1 & \text{otherwise} \end{cases} \quad (5)$$

여기서 α 는 경험적으로 정해진 가중치 상수이며 상태 0에 해당하는 비중요계수와 상태 1에 해당하는 중요계수를 적절하게 구분하도록 정해진다. $\sigma_{k(\rho(i))}$ 는 부모 계수 $w_{\rho(i)}$ 가 속한 부대역 $k(\rho(i))$ 의 표준편차이다. 식 (5)에서 만약 부모계수의 상태가 상태 1로 결정되면, $P(S_{\rho(i)}(0))$ 는 0이 되고 $P(S_{\rho(i)}(1))$ 은 1이 되므로 식 (4)는 다음과 같이 표현된다.

$$P(w_i) = g(w_i; 0, \sigma_{i,0}^2)\epsilon_{i,\rho(i)}^{01} + g(w_i; 0, \sigma_{i,1}^2)\epsilon_{i,\rho(i)}^{11} \quad (6)$$

반대로 부모계수의 상태가 상태 0가 되면, 식 (4)는 다음과 같이 표현된다.

$$P(w_i) = g(w_i; 0, \sigma_{i,0}^2)\epsilon_{i,\rho(i)}^{00} + g(w_i; 0, \sigma_{i,1}^2)\epsilon_{i,\rho(i)}^{10} \quad (7)$$

일반적으로 웨이블릿 영역에서 부모 계수와 자식 계수 사이의 확률 천이 함수에 대해 다음과 같은 경향이 발견된다. 첫째로, 부모 계수가 크기가 큰 중요계수 (significant coefficient)일 때 자식 계수가 중요계수가 될 확률은 절반에 가깝다. 둘째로 부모 계수가 비중요 계수(non-significant coefficient)일 때 자식이 비중요 계수가 될 확률은 거의 1에 가깝다^[7]. 그리고 이 특성들은 고주파 부대역으로 갈수록 뚜렷해진다. 그러므로 식 (6)와 식 (7)의 상태 천이 확률은 다음과 같이 결정될 수 있다.

$$A = \begin{pmatrix} \epsilon_{i,\rho(i)}^{00} & \epsilon_{i,\rho(i)}^{01} \\ \epsilon_{i,\rho(i)}^{10} & \epsilon_{i,\rho(i)}^{11} \end{pmatrix} = \begin{pmatrix} 1 & 1/2 \\ 0 & 1/2 \end{pmatrix} \quad (8)$$

한편, 웨이블릿 계수의 분산은 저주파 부대역에서 고주파 부대역으로 갈수록 지수적으로 감소한다^[7]. 제안 방법에서는 이 특성을 이용하여 가우스 혼합모델의 각 상태의 분산을 구한다. 이를 위해 그림 4에서 보는 바와 같은 두 개의 저주파 부대역의 계수들을 식(9)에 따라 두 개의 집합으로 나눈다.

$$w_j \in \begin{cases} W_1^{k(j)} & \text{if } |w_j| > \beta\sigma^{k(j)} \\ W_0^{k(j)} & \text{otherwise} \end{cases} \quad (9)$$

식에서 두 개의 집합은 각각 상태 0과 상태 1을 나타

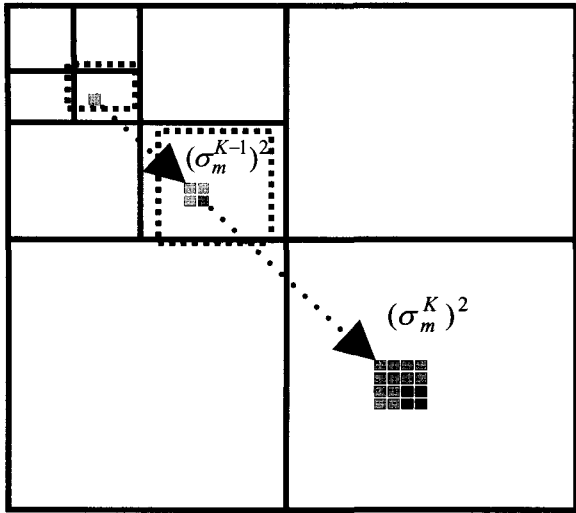


그림 4. HH 고주파 부대역의 분산을 추정하기 위해 사용되는 두 개의 저주파 부대역
 Fig. 4. The two subband used to estimate variances of high frequency subband.

낸다. 따라서 가중치 상수 β는 이를 적절하게 나누도록 정해진다. 식(9)와 같이 구해진 각 집합들의 원소들에 대해 식(10과 같이 분산들을 구한다.

$$(\sigma_m^{k(j)})^2 = \frac{1}{N_m^{k(j)}} \sum_{w_j^{k(j)} \in W_m^{k(j)}} (w_j^{k(j)})^2 \quad (10)$$

여기서 $N_m^{k(j)}$ 은 집합 $w_m^{k(j)}$ 의 원소의 개수이다. 이렇게 구한 분산 $(\sigma_m^{k(j)})^2$ 은 m 상태의 분산을 나타낸다. 따라서 웨이블릿 영역의 분산들의 지수적 감소 특성을 이용해서 고주파 부대역의 각 상태의 분산은 다음과 같이 추정될 수 있다.

$$(\sigma_m^K)^2 = \frac{(\sigma_m^{K-1})^2}{(\sigma_m^{K-2})^2} (\sigma_m^{K-1})^2 \quad (11)$$

IV. 모의 실험 결과

본 논문에서는 객관적인 성능 평가를 위해 512×512 lena, woman, boat, peppers, barbara 영상에 대해 PSNR을 구했다. 제안 알고리즘의 성능 비교를 위해 bicubic 방법, Kinebuchi의 은닉 마코프 트리 모델을 이용한 방법의 PSNR도 같이 구해졌다. Kinebuchi의 방법에서 은닉 마코프 트리 모델의 훈련은 입력 영상의 고해상도 원 영상으로 행해졌다. 실험에서 저해상도 입력 영상으로는 원 영상을 한 단계 웨이블릿 변환을 한 후 얻은 저주파 부대역 영상을 사용하였다. 실험을 위한

표 1. 제안 방법과 다른 방법들과의 PSNR 비교
 Table 1. The PSNR comparison between the proposed method and other methods.

	Bicubic	Kinebuchi's method	Proposed method
Lena	30.29	32.20	34.37
Woman	36.02	36.69	39.25
Boat	27.40	29.54	31.32
Peppers	30.82	31.73	33.75
Barbara	23.92	24.07	25.41




그림 5. 제안 방법에 의한 고주파 부대역 추정 결과
 Fig. 5. The estimation result for high frequency subband using the proposed method.

웨이블릿 필터로서는 여러 웨이블릿 필터 중 가장 좋은 성능을 보인 daubechies 쌍직교 9/7 필터가 사용되었다.

표 1은 이들 테스트 영상들에 대한 PSNR 결과이다. 표 1에서 보는 바와 같이 제안방법은 전통적인 bicubic 방법보다 우수한 성능을 보여줄 뿐 아니라, 계수 모델링을 위해 단일 가우스 분포를 사용하고 복잡한 부호추정 방식을 사용하는 Kinebuchi의 방법^[2]에 대해서도 개선된 성능을 보였다. 또한 Kinebuchi의 방법은 훈련 과정을 필요로 하고 훈련 영상으로서 입력 영상과 유사한 특징의 영상을 사용해야하는 반면, 제안 방법에서는 그런 과정들이 필요하지 않다.

그림 5는 lena 영상에 대해 웨이블릿 영역에서 고주파 부대역을 추정한 결과이다. 그림 5에서 보는 바와 같이 제안 알고리즘은 lena의 에지 부분과 평탄 부분을 효과적으로 추정한 것을 볼 수 있다.

그림 6과 그림 7은 제안 방법과 다른 방법들과의 주관



(a) (b)

그림 6. Lena 영상에 대한 bicubic 방법과 제안 방법과의 주관적 화질 비교

Fig. 6. The subjective quality comparison between the bicubic method and the proposed method for lena image (a) bicubic 방법 (b) 제안 방법.



(a) (b)

그림 7. Lena 영상에 대한 kinebuchi 방법과 제안 방법과의 주관적 화질 비교

Fig. 7. The subjective quality comparison between the kinebuchi method and the proposed method for lena image (a) kinebuchi 방법 (b) 제안 방법.

적인 비교이다. 그림 6은 제안 방법과 bicubic 방법과의 비교이며, 그림 7은 제안 방법과 Kinebuchi의 방법과의 비교이다. 그림 6에서 제안 방법은 bicubic 방법에 비해 선명한 영상을 보여주며 그림 7에서는 Kinebuchi의 방법보다 깨끗한 영상을 보여준다.

V. 결 론

본 논문에서는 웨이블릿 영역에서 영상을 보간하는 방법을 제안한다. 제안 방법에서는 은닉 마코프 트리 모델의 구조를 사용하여 입력 영상으로부터 주어지는 저주파 부대역들의 계수들로부터 고주파 부대역의 계수를 추정한다. 은닉 마코프 트리 모델의 파라미터들은 부대역간의 통계적 특성을 이용하여 추정한다. 이러한 추정 방법은 훈련 과정을 필요로 하지 않으며 입력 영상에 더 잘 맞는 파라미터들을 구할 수 있다. 모의실험에서

제안 방법은 전통적인 bicubic 방법이나 훈련 과정이 있는 Kinebuchi의 방법보다 개선된 성능을 보여주었다.

참 고 문 헌

- [1] M. S. Crouse, R. D. Norwak, R. G. Baraniuk, "Wavelet-based statistical signal processing using hidden Markov models," *IEEE Trans. Signal Processing*, Vol. 46, No. 4, pp. 886-902, April, 1998.
- [2] K. Kinebuchi, D. D. Muresan, and T. W. Parks, "Image interpolation using wavelet-based hidden Markov model," *ICASSP01*, pp. 7-11, Salt Lake City, USA May 2001.
- [3] A. V. Oppenheim, and R.W. Schaffer, *Discrete-time Signal Processing*, Prentice Hall, pp. 102-111, 1989.
- [4] J. Allebach and P. W. Wong, "Edge directed interpolation," *ICIP96*, pp. 707-710, Lausanne, Switzerland, Sep. 1996.
- [5] X. Li and M. T. Orchard, "New edge-directed interpolation," *IEEE Trans. Image Processing*, Vol. 10, No. 10, pp. 1521-1527, Oct., 2001.
- [6] W. K. Carey, D.B. Chung, and S. S. Hemami, "Regularity-preserving image interpolation," *IEEE Trans. Image Processing*, Vol. 8, No. 9, Sep., 1999.
- [7] J. R. Romberg, H. C. Choi, R.G. Baraniuk, "Bayesian tree-structure image modeling using wavelet-domain hidden Markov models," *IEEE Trans. Image Processing*, Vol. 10, No. 7, July, 2001.

저 자 소 개



우 등 현(정회원)
 1998년 부산대학교 전자공학과
 학사.
 2000년 부산대학교 전자공학과
 석사.
 2000년~현재 부산대학교
 전자공학과 박사 과정.

<주관심분야: 영상처리, 패턴인식, 웨이블릿 변환
 신호처리, 신경회로망>



김 유 신(정회원)
 1974년 서울대학교 전자공학과
 학사.
 1980년 U.C. Berkeley 전자공학과
 석사.
 1983년 Standford University
 전자재료 박사과정 수학.

1995년 Cornell University Ph.D
 1983년~현재 부산대학교 전자공학과 교수
 현재 한국 과학철학회 회장
 <주관심분야: 영상처리, 신경회로망, 공학윤리, 과
 학기술철학>



엄 일 규(정회원)
 1990년 부산대학교 전자공학과
 학사.
 1992년 부산대학교 전자공학과
 석사.
 1998 부산대학교 전자공학과
 박사.

1997년~현재 밀양대학교 정보통신학과 부교수
 <주관심분야: 통계신호처리, 영상처리, 웨이블릿
 변환 신호처리, 신경회로망>

