

논문 2005-42SP-6-3

스케일간 웨이블릿 계수 절대치의 선형 모델링을 이용한 영상 보간

(Image Interpolation Using Linear Modeling for the Absolute Values of Wavelet Coefficients Across Scale)

김 상 수*, 엄 일 규**, 김 유 신***

(Sang-Soo Kim, Il-Kyu Eom, and Yoo-Shin Kim)

요 약

웨이블릿 영역에서의 영상 보간은 웨이블릿 계수들의 통계적 특성과 스케일간 의존성을 표현하는 확률모델을 이용한다. 본 논문에서는 보간할 영상에 대해 스케일간 웨이블릿 계수의 절대치를 선형 모델링하여 분산을 추정하고 이를 바탕으로 고주파 부대역의 확률모델을 실현하여 영상을 보간하는 방법을 제안한다. 본 논문의 방법은 확률 모델에 대한 추정된 파라미터에 의해 웨이블릿 계수를 난수 형태로 발생시키는 방법을 사용한다. 확률모델을 따라 난수를 발생할 경우 추정 부대역에 난수에 의해 한 잡음이 발생하게 된다. 본 논문에서는 후처리 과정으로 Wiener filter를 사용하여 부대역의 잡음을 제거하였다. 제안 방법으로 외삽한 부대역에 대한 확률을 밀도함수를 비교적 정확하게 추정한 것을 볼 수 있다. 실험을 통해 제안방법이 bicubic과 같은 전통적인 방법뿐 아니라 웨이블릿 영역에서의 다른 영상보간법보다 나은 주관적, 객관적 성능을 가지고 있음을 보였다.

Abstract

Image interpolation in the wavelet domain usually takes advantage of the probabilistic models for the intrascale statistics and the interscale dependency. In this paper, we adopt the linear model for the absolute values of wavelet coefficients of interpolated image across scale to estimate the variances of extrapolated bands. The proposed algorithm uses randomly generated wavelet coefficients based on the estimated parameters for probabilistic model. Random number generation according to the estimated probabilistic model may induce the 'salt and pepper' noise in subbands. We reduce the noise power by Wiener filtering. We observe that the proposed method generates the histogram of the subband coefficients similar to the that of original image. Experimental results show that our method outperforms the previous wavelet-domain interpolation method as well as the conventional bicubic method.

Keywords : 영상보간, 웨이블릿 변환, 스케일간 의존성, 가우스 혼합모델

I. 서 론

영상 보간은 디지털 영상 획득 장치로부터 얻은 저해

상도 영상을 고해상도 영상으로 전환하는 방법이다. 최근 HDTV와 같은 고화질 디스플레이 장치와 캠코더, 디지털 카메라 같은 디지털 영상 획득 매체의 급속한 보급으로 영상 보간의 중요성은 더욱 커지고 있다. 디지털 영상 획득 장치를 통해 얻은 영상은 고해상도의 자연영상을 저대역 통과 필터를 거쳐 다운 샘플링 한 것으로 볼 수 있다. 이렇게 획득한 영상은 고주파성분을 잃고 aliasing 현상이 생기게 된다. 고주파 성분의 손실은 영상 확대시 흐림 현상이 나타나는 주요 원인이 된다. 따라서 영상 보간의 주된 목적은 이런 손실된 고주파성분을 효과적으로 복원하는 것이다.

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

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

*** 정희원, 부산대학교 컴퓨터 및 정보통신 연구소
(Research Institute of Computer and Information and Communication)

접수일자: 2005년 4월 6일, 수정완료일: 2005년 9월 22일

공간영역에서의 보간은 기존 화소의 정보에 적당한 필터링을 가하여 빈 화소들을 채워 나가는 방법으로 고주파 성분에 해당하는 에지정보를 제대로 복원할 수 있는 필터계수를 찾는 것이 중요하다. 대표적으로 bilinear 보간법과 bicubic 보간법 같은 선형 필터링 방법이 있다. 이 방법들은 적은 계산량으로 인해 실시간 처리가 요구되는 분야 등에 널리 쓰이고 있다. 그러나 저해상도 영상이 단순히 고해상도 영상의 샘플들로 구성되어 있다는 잘못된 가정에 기반하고 또한 영상 전체에 연속성에 대한 조건을 부여하여 에지에 해당하는 고주파 정보를 효과적으로 복구할 수 없다. 일반적으로 선형 보간 필터는 과도한 흐림 현상이나 계단형 에지(jagged edge)의 발생과 같은 문제점들을 가진다. 이를 개선하기 위해 많은 방법들이 제안되었다. 보간 위치의 실제 거리 대신 주변 화소의 에지 특성에 따른 변형된 거리를 이용하거나^[16-18], 저해상도 에지의 기하학적 정보를 고해상도 에지에 대한 지도로 전환하는 모델을 세우고 이 모델과 일치하도록 보간을 반복적으로 수정해 나가는 방법^[2, 4], 저해상도 영상의 국부적인 공분산 행렬을 사용하여 화소를 보간하는 방법^[3], 영상의 국부적 특성에 따라 다른 필터계수를 적용하는 방법^[19, 20], 신경망과 같은 비선형필터를 이용하는 방법^[15, 21]등이 있다.

웨이블릿 영역에서의 보간은 영상에 연속성에 대한 조건을 부여하지 않기 때문에 에지를 복구하기가 좀 더 효율적이다. 또한 유무선 통신환경에서 영상들은 DCT나 웨이블릿 변환에 기반한 압축기법에 의해 표현되므로 공간 영역에서의 보간보다는 변환 영역에서의 보간이 실용적인 면에서 더 적합하다. 웨이블릿 영역에서의 영상보간은 마지막 고주파 부대역 계수의 추정문제로 볼 수 있다. [5]에서는 Hölder regularity를 사용하여 cubic spline 근사로 고주파 부대역 계수를 추정하였다. 은닉 마코프 트리(HMT) 모델을 이용한 방법^[1]은 스케일간의 통계적 특성을 좀 더 잘 모델링할 수 있으나 파라미터 추정을 위한 훈련과정이 필요하다. 훈련이 필요 없는 은닉 마코프 모델^[7]도 있지만 보간할 영상에 대한 스케일간 지수적 감소 특성을 제대로 반영하지 못하는 단점이 있다.

본 논문에서는 웨이블릿 영역에서 스케일간의 계수의 절대치를 선형모델링 하여 고주파 부대역의 분산을 추정하고 이것을 고주파 부대역 계수에 대한 확률 모델에 이용하는 영상보간법을 제안한다. 본 논문의 방법은 확률 모델에 근거하여 추정할 웨이블릿 계수를 난수 형태로 발생시키는 방법을 사용한다. 웨이블릿 계수를 확

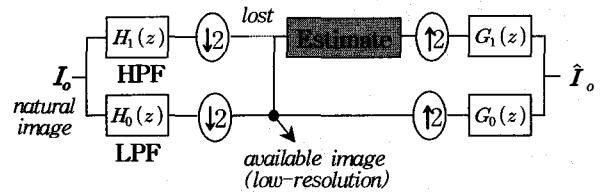


그림 1. 웨이블릿 영역에서의 영상보간

Fig. 1. Image Interpolation in the wavelet domain

률 모델에 따라 난수를 발생할 경우 추정 부대역에 확률은 작지만 의외의 큰 값이 발생할 수 있다. 이러한 잡음을 제거하기 위해 Wiener filter를 후처리로 사용한다. 모의실험에서 제안 방법은 bicubic과 같은 전통적인 방법뿐 아니라 HMT에 기반한 다른 방법들 보다 나은 성능을 보였다.

이 논문은 다음과 같은 순서로 구성된다. 먼저 II장에서 웨이블릿 영역에서의 영상 확대 개념과 기준 방법들을 소개하며 III장에서 제안한 영상보간법을 기술한다. IV장에서는 모의실험결과를 보여주며 V장에서 결론을 맺는다.

II. 웨이블릿 영역에서의 영상보간

1. 문제 설정

웨이블릿 영역에서 영상 보간은 마지막 고주파 부대역의 계수추정 문제이다. 그림 1은 이러한 개념을 보여준다. 그림 1에서 저대역 통과 필터(LPF)는 영상 획득 장치의 특성을 반영한다. 입력 영상은 고해상도 영상에서 고주파 부대역의 정보가 손실된 영상으로 간주한다. 웨이블릿 영역에서는 공간 영역에서 추출할 수 없는 신호의 다중 해상도 특성과 통계적 특성을 활용할 수 있다. 또한 공간 영역에서의 영상보간이 일반적으로 지니는 연속 제약조건을 가지지 않기 때문에 에지복구에 좀 더 효율적이다. JPEG2000이 웨이블릿 변환을 기반으로 하고 있기 때문에 유무선 통신 환경 하에서 영상을 공간영역에서 다루는 것 보다는 웨이블릿 영역에서 다루는 것이 더 적합하다.

2. 관련 연구

웨이블릿 계수들은 스케일내 확률 모델과 스케일간의 존성을 가지고 있다. 같은 스케일 내에서 계수들은 비슷한 위치에서 비슷한 크기를 가지는 군집화 특성이 있다. 그리고 0 근처에서 끝이 뾰족하고 양쪽 꼬리가 긴(peaky at zero and heavy-tailed) 형태의 확률밀도

함수를 지닌다. 한 스케일내 균집화된 형태는 다른 스케일에서도 비슷한 형태로 유지된다. 즉 큰 값을 갖는 위치는 다음 스케일에서도 해당 위치에서 큰 값을 가지고 작은 값에 대해서도 마찬가지이다. 그리고 스케일이 커짐에 따라 계수 크기가 지수적으로 감소하는 특성을 보인다^[6, 7, 9, 12].

이러한 계수들의 특성을 이용한 웨이블릿 영역에서의 영상보간법들이 몇 가지 제안되었다. [5, 11]에서는 Lipschitz 특성을 이용하여 영상을 보간하였다. 두 방법은 비슷하지만 [11]에서는 Lipschitz 특성이 잘 맞지 않는 텍스처 영역에서도 외삽을 시도하였다. 반면 [5]에서는 Lipschitz 특성이 잘 맞을 경우에는 웨이블릿 계수들의 외삽을 시도하고 그렇지 않을 경우는 추정치를 영으로 하였다. [5]의 방법이 [11]의 방법보다 계산량 측면에서 효율적이다. [10]에서는 웨이블릿 계수의 극대점뿐 아니라 국부 에너지가 응집된 주변 영역들까지 고려하여 Liptschitz 특성을 반영하였다.

위의 방법들은 강하고 고립된 에지에서는 설명하지만 스케일간 지수적 감소 특성이 잘 맞지 않는 부분에서는 화질의 열화를 가져온다. [6]에서는 웨이블릿 계수의 스케일간 의존성을 고정된 지수 감소 모델이 아니라 은닉 마코프 트리를 기반으로 한 확률모델로 표현하였다. [1]의 저자는 이 은닉 마코프 트리 모델을 영상보간에 적용하여 비교적 선명한 영상을 얻었다. 이런 접근 방법의 특징은 웨이블릿 계수가 추정된 가우스 혼합모델에 따른 난수 발생으로 주어진다는 것이다. 따라서 실행할 때마다 약간씩 다른 결과를 얻게 된다. 이 모델의 단점은 주로 가우스 혼합모델의 파라미터들을 결정하는 것에 있다.

웨이블릿 영역에서 제시된 다른 영상 보간법으로는 저해상도 영상으로부터 에지 프로파일에 대한 모델을 추정하여 고주파 부대역의 계수를 찾는 방법이 있다^[13, 14]. 이 방법은 아직은 에지 모델의 한계 때문에 복잡한 에지를 가진 영상에서 좋은 성능을 보이지 못한다. 웨이블릿 영역에서 가우스 혼합 모델에 기반한 방법들은 파라미터 추정에 어려움을 지닌다. 특별히 분산 추정이 다른 영상들에 대한 훈련을 통해 이루어지기 때문에 확대하려는 영상의 특징을 잘 반영하지 못한다.

본 논문은 확률 모델에 필요한 파라미터 추정을 간략화하고 보간하려는 영상에 대해 스케일간 계수의 절대치를 선형 모델링하는 방법으로 개별 영상의 특성에 맞게 분산을 추정한다. 파라미터 결정을 위한 훈련 과정이 필요 없고 고주파 부대역에서의 확률밀도 함수를 비

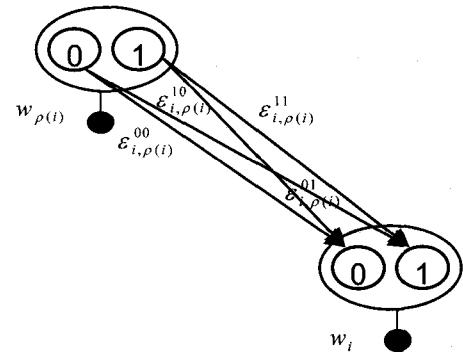


그림 2. 상태천이확률의 개념
Fig. 2. State transition Probabilities.

교적 잘 추정할 수 있었다.

III. 제안 방법

1. 모델의 설정

신호를 웨이블릿 변환하면 고주파 부대역에서 많은 개수의 작은 계수들과 적은 개수의 큰 계수가 생긴다. 이것은 0 근처에서 끝이 뾰족하고 양쪽 꼬리가 긴 (peaky at zero and heavy-tailed) 형태의 확률밀도 함수를 만들게 된다. 웨이블릿 계수의 이런 특성은 일반적으로 라플라스 확률 모델, 가우스 혼합 모델, 또는 일반화된 가우스 모델 등으로 표현할 수 있다. 본 논문에서는 계수의 상태에 따른 가우스 확률 모델을 할당하고 이 가우스 확률모델들을 선형 조합한 가우스 혼합 모델로서 계수를 모델링한다.

웨이블릿 계수에 대한 가우스 혼합 모델은 다음과 같은 파라미터의 집합으로 특정 지울 수 있다.

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

여기서 $S_i(m)$ 은 i 번째 계수가 상태 m 에 있음을 나타낸다. 상태 확률 $P(S_i(m))$ 는 i 번째 계수 ω_i 가 상태 m 에 있을 확률이다. 상태천이확률 $\epsilon_{i,p(i)}^{mn}$ 은 이전 스케일에서 ω_i 에 해당하는 위치의 계수(부모계수) $\omega_{p(i)}$ 가 상태 n 일 때, i 번째 계수 ω_i 가 상태 m 에 있을 확률이다. 그림 2는 2개의 상태가 존재할 경우에 대한 상태천이확률의 개념을 보여준다. $\mu_{m,i}$, $\sigma_{m,i}^2$ 은 각각 i 번째 계수 ω_i 가 상태 m 일 때의 평균과 분산이다. 은닉 마코프 트리 모델에서는 EM(Expectation-Maximization) 알고리즘을 이용한 별도의 훈련과정을 거쳐 이러한 파라미터들을 결정한다. 식 (1)의 파라미터들은 각 계수들에 대해 존재하므로 훈련해야 할 파라미터의 수가 너무 많다. 그

래서 실제 적용에서는 같은 부대역 안의 모든 계수에 대해 동일한 파라미터들을 사용하는 묶음(tying) 방법을 사용한다^[6].

가우스 혼합 모델에서 계수의 상태는 크기가 작은 비중요(non-significant)계수에 해당하는 상태 0과 크기가 큰 중요(significant) 계수에 해당하는 상태 1로 나눌 수 있다. 웨이블릿 계수의 확률 밀도 함수를 다음과 같은 가우스 혼합 모델로 표현한다.

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

여기서 $g(w_i; \mu, \sigma^2)$ 은 평균 μ 와 분산 σ^2 을 가진 가우스 확률 밀도 함수이다. 일반적으로 웨이블릿 영역의 확률 모델에서 LL 부대역이 아닌 부대역의 웨이블릿 계수의 평균은 0으로 본다. 그림 2로부터

$$P(S_i(m)) = \epsilon_{i,\rho(i)}^{m0}P(S_{\rho(i)}(0)) + \epsilon_{i,\rho(i)}^{m1}P(S_{\rho(i)}(1)) \quad (3)$$

이다. 그러면 식 (2)와 식 (3)에서

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

만약 부모 계수의 상태가 0으로 결정된다면 $P(S_{\rho}(0)) = 1$ 이고 $P(S_{\rho}(1)) = 0$ 이다. 이 때 식 (4)는 다음과 같이 된다.

$$p(w_i) = g(w_i; 0, \sigma_{i,0}^2)\epsilon_{i,\rho(i)}^{00} + g(w_i; 0, \sigma_{i,1}^2)\epsilon_{i,\rho(i)}^{10} \quad (5)$$

반대로, 부모 계수의 상태가 1이라면 식 (4)는 다음과 같이 된다.

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

이 모델을 사용하여 영상 보간을 하기 위해서는 계수의 상태 결정과 상태천이 확률의 추정 그리고 분산의 추정이 이루어져야 한다.

2. 파라미터 추정

(1) 계수의 상태

본 논문에서는 웨이블릿 계수를 상태 0에 해당하는 클래스와 상태 1에 해당하는 클래스로 나누기 위해 [8]에서 제시한 방법을 사용하였다. [8]에서는 그레이 영상의 히스토그램에서 클래스내 분산을 최소화하면서 클래스간 분산은 최대화하도록 화소값의 클래스들을 구분하

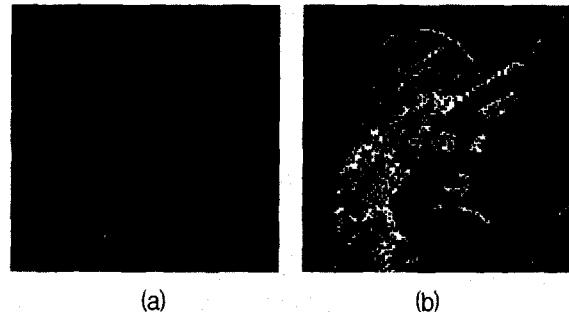


그림 3. 계수의 상태 결정 예 ('Lena' image, LH-band)
(a) 원 영상의 계수 크기에 대한 그레이스케일 영상 (b) 이진영상으로 나타낸 상태결정 맵

Fig. 3. Example of state decision(Lena, LH-band) (a) Gray-scale representation of absolute coefficients in original image (b) Binary map of decided states

는 방법을 제시하였다. 웨이블릿 계수는 그레이 영상의 화소값과는 달리 큰 동적 범위를 가진다. 그래서 웨이블릿 계수에 대해 양자화된 히스토그램이 거의 대칭형태를 가진다는 점에 착안하여 계수의 동적 범위를 1/2로 줄여서 적용하였다. 이에 따라 계수의 상태 m 은 다음과 같이 결정된다.

$$m = \begin{cases} 0 & \text{if } |w_i| < T \\ 1 & \text{otherwise} \end{cases} \quad (7)$$

웨이블릿 계수의 절대치 w 의 동적범위를 L 개의 구간으로 나누었을 때, l 번째 구간에 속한 w 의 개수를 ψ_l 라 하면 T 를 다음과 같이 결정한다.

$$T = \underset{w_k \in W_c}{\operatorname{argmax}} \frac{[\mu(w_L)p(w_k) - \mu(w_k)]^2}{p(w_k)[1 - p(w_k)]} \quad (8)$$

여기서

$$p(w_k) = \sum_{l=1}^k \frac{\psi_l}{\Omega}, \quad \mu(w_k) = \sum_{l=1}^k \frac{w_l \psi_l}{\Omega} \quad (9)$$

이다. $\Omega = \psi_1 + \psi_2 + \dots + \psi_L$ 이고 W_c 는 각 구간의 대표값의 집합이다. 그림 3은 이 방법으로 상태를 결정한 예이다.

(2) 상태천이확률

상태 천이 확률은 [7]에서 보인 웨이블릿 계수의 부대역간 상태천이 특성을 이용하여 결정한다. 웨이블릿 계수의 크기가 작을 경우 다음 스케일에서 웨이블릿 계수가 커질 확률은 없다. 즉,

$$\begin{aligned} P(S_i(1) | S_{\rho(i)}(0)) &= 0 \\ P(S_i(0) | S_{\rho(i)}(0)) &= 1 \end{aligned} \quad (10)$$

반면에 웨이블릿 계수의 크기가 클 경우에는 고주파 부대역으로 갈수록 다음 스케일에서 웨이블릿 계수가 클 확률은 0.5가 된다. 즉,

$$\begin{aligned} P(S_i(1) | S_{\rho(i)}(1)) &= 1/2 \\ P(S_i(0) | S_{\rho(i)}(1)) &= 1/2 \end{aligned} \quad (11)$$

제안방법에서 외삽할 부대역은 가장 스케일이 큰 부대역이므로 위의 사실을 이용하면 상태천이 확률은 다음과 같이 근사화할 수 있다.

$$\begin{pmatrix} \epsilon_{i,\rho(i)}^{00} & \epsilon_{i,\rho(i)}^{01} \\ \epsilon_{i,\rho(i)}^{10} & \epsilon_{i,\rho(i)}^{11} \end{pmatrix} \approx \begin{pmatrix} 1 & 1/2 \\ 0 & 1/2 \end{pmatrix} \quad (12)$$

(3) 분산의 추정

분산 추정의 정확도는 추정된 가우스 혼합 모델의 정확도를 의미한다. 가우스 혼합 모델에 기반한 방법들은 분산 추정치를 비슷한 영상에 대한 훈련과정을 통해 얻는다^[1, 7]. 이러한 추정 방법은 보간하려는 영상의 스케일간 특성을 잘 반영하지 못하는 단점이 있다. 보간할 영상의 스케일간 특성을 반영하려면 각 스케일간의 지수적인 감소율을 유연하게 표현할 수 있는 적절한 모델이 있어야 한다. 본 논문에서는 보간할 영상의 스케일간 감소 비율을 반영할 수 있도록 웨이블릿 계수의 절대치에 대한 스케일간 크기를 다음과 같이 선형 모델링하였다.

$$|w_m^{j-1}| = \lambda_m^j |w_m^j|, \quad j = 1, 2, \dots \quad (13)$$

여기서 w_m^j 는 j 번째 스케일에서 상태 m (0 or 1)에 해당하는 계수를 나타낸다. $j = 0$ 은 LL-밴드를 제외한 가장 저주파 부대역을 가리킨다. j 가 클수록 고주파 부대역이다. λ_m^j 는 상태 m 에 있는 $j-1$ 번째 스케일과 j 번째 스케일간의 계수 크기가 감소하는 비율을 나타낸다. [22]에서 보인 조건부 히스토그램은 연속된 두 스케일의 계수크기가 감소하는 평균적인 비율을 선형 모델링을 통해 근사화할 수 있음을 보여준다.

λ_m^j 는 최소자승법을 이용하면 각 스케일별로 다음과 같이 구할 수 있다.

$$\lambda_m^j = \frac{N_m^j \sum_k w_m^{j,k} \|w_m^{\rho(j,k)}\| - \sum_k w_m^{j,k} |\sum_k w_m^{\rho(j,k)}|}{N_m^j \sum_k w_m^{j,k}^2 - (\sum_k w_m^{j,k})^2} \quad (14)$$

여기서 N_m^j 는 j 번째 스케일에서 m 상태에 있는 계수의 총 개수이고, $w_m^{j,k}$ 는 j 번째 스케일에서 m 상태에 있는 k 번째 계수이며 $w_m^{\rho(j,k)}$ 는 $w_m^{j,k}$ 에 해당하는 부모계수이다.

저상도 영상의 마지막 고주파 밴드를 $j = J$ 라 할 때, 영상 보간을 위한 계수 추정을 위해 최소자승법으로 구한 λ 값들로부터 λ_m^{J+1} 을 외삽해야 한다. 일반적으로 웨이블릿 계수는 다음과 같은 성질을 만족한다.^[23]

$$\frac{1}{J} \sum_{j=1}^J \frac{|w_m^{j-1}|}{|w_m^j|} = 2^\alpha \quad (15)$$

이 때 α 는 J 값에 의존하게 된다. 식(13)으로부터

$$\frac{1}{J} \sum_{j=1}^J \lambda_m^j = 2^\alpha \quad (16)$$

이다. 외삽을 위해서 다음과 같은 가정을 한다.

$$2^{\alpha(J)} \ln 2 = \frac{2^{\alpha(J-1)} \ln 2 + 2^{\alpha(J+1)} \ln 2}{2} \quad (17)$$

그러면,

$$\lambda_m^{J+1} = \frac{J+2}{J} S_m^J - \frac{J+1}{J-1} S_m^{J-1} \quad (18)$$

이고, 여기서 $S_m^J = \sum_{i=1}^J \lambda_m^i$ 이다.

외삽할 부대역의 분산 σ_m^{J+1} 은 λ_m^{J+1} 를 이용해 다음과 같이 추정할 수 있다.

$$(\sigma_m^{J+1})^2 = \frac{1}{(\lambda_m^{J+1})^2} (\sigma_m^J)^2 \quad (19)$$

3. 후처리

앞에서 추정한 확률 모델의 실현으로 부대역 계수를 추정할 경우 비록 작은 확률이긴 하지만 난수발생으로 인해 예기치 않은 큰 값이 발생할 수 있다. 이것은 해당 부대역에서 잡음으로 작용하게 된다. Wiener filter는 영상의 잡음 제거에 성공적으로 사용되었다. 본 논문에서는 가우스 혼합 모델에 따른 난수 발생으로 인한 잡음을 제거하기 위해서 후처리과정으로 추정된 부대역에 Wiener filter를 적용하였다. 추정된 각 부대역에 대한 잡음의 분산 $\hat{\sigma}_N$ 은 다음과 같이 추정할 수 있다^[24].

$$\hat{\sigma}_N = \frac{\text{med}(|w_{HH}^{J+1} - \text{med}(|w_{HH}^{J+1}|)|)}{0.6745} \quad (20)$$

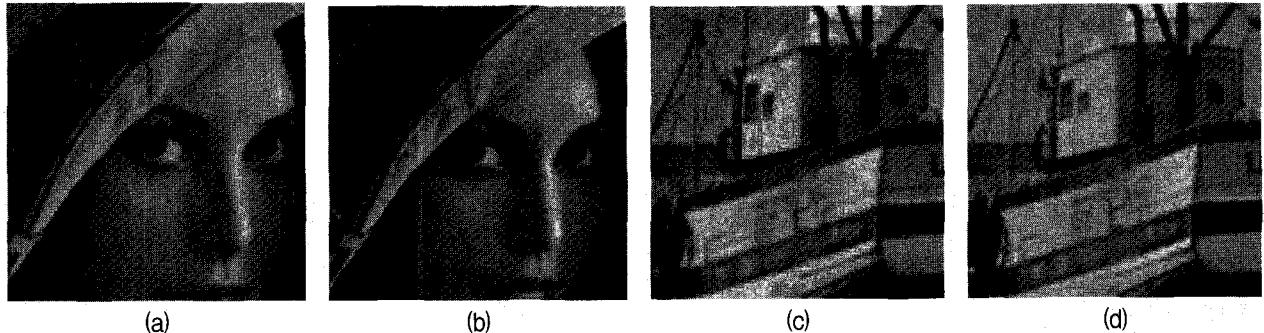


그림 4. [1]의 방법과 제안방법의 주관적인 화질 비교

(a) [1]의 방법(32.20dB) (b) 제안방법(33.97dB) (c) [1]의 방법(29.54dB) (d) 제안방법(31.21dB)

Fig. 4. The subjective quality comparison between method in [1] and proposed method.

(a) method in [1](32.20dB) (b) proposed(33.97dB) (c) method in [1](29.54dB) (d) proposed(31.21dB)

여기서 w_{HH}^{j+1} 는 추정된 웨이블릿의 대각 에지 성분 부대역에 해당하는 계수 벡터이고 $med(w_{HH}^{j+1})$ 는 w_{HH}^{j+1} 의 중간값을 의미한다.

IV. 모의 실험

본 논문에서는 제안 방법의 객관적인 성능 평가를 위해 lena, woman, boat, peppers 영상에 대한 PSNR을 비교했다. 저해상도 입력 영상으로는 고해상도 영상을 한 단계 웨이블릿 변환을 한 후 얻은 LL영상을 사용하였다. 실험에서 사용된 웨이블릿 필터는 여러 웨이블릿 필터들 중 가장 좋은 성능을 보여준 Daubechies 쌍직교 9/7 필터이다. Wiener filter는 7×7 사이즈를 사용하였다. 부호는 부모계수의 것을 그대로 상속하였다.

그림 5는 고해상도 영상의 히스토그램과 제안방법에 의해 추정된 계수값들의 히스토그램에 대한 비교이다. 제안방법이 후처리 이후 비교적 정확하게 히스토그램을 추정함을 보여준다. 표 1은 테스트 영상에 대한 PSNR 결과이다. 제안 방법의 성능 비교를 위해 전통적인 bicubic 방법과 은닉 마코프 트리 모델을 사용한 영상 확대 방법^[1]의 PSNR도 같이 표기하였다. [1]에 제시된 방법의 훈련은 입력 영상의 고해상도 영상으로 행하였다.

표 1에서 보는 바와 같이 제안 방법은 전통적인 bicubic 방법보다 우수한 성능을 보여줄 뿐 아니라, 훈련 과정을 가진 은닉 마코프 트리 모델을 사용하는 [1]의 방법에 비해서도 개선된 성능을 보여 주었다. 그림 6와 그림 4은 제안 방법과 다른 알고리즘들의 lena 영상에 대한 주관적인 화질 평가이다. 그림 6에서 bicubic 방법은 전반적으로 흐린(blurred) 영상을 만들어 내는

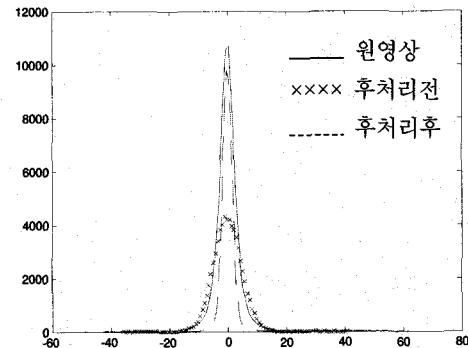


그림 5. 히스토그램 비교

("Lena" image, horizontal band)

Fig. 5. Comparison of histograms.

표 1. PSNR 비교

Table 1. Comparisons of PSNR's (dB).

	Bicubic	[1]	제안방법
Lena	30.29	32.20	33.97
Woman	36.02	36.69	39.09
Boat	27.40	29.54	31.21
Peppers	30.82	31.73	33.59

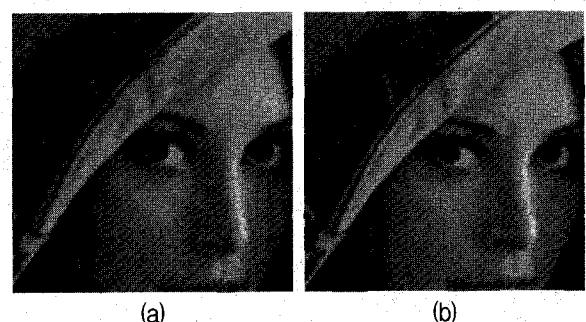
그림 6. bicubic 방법과 제안방법의 주관적인 화질 비교
(a) bicubic 방법(30.29dB) (b)제안 방법(33.97dB)

Fig. 6. The subjective quality comparison between bicubic method and proposed method.

(a) bicubic method(30.29dB)

(b) proposed method(33.97dB).

데 비하여, 제안 방법은 상대적으로 선명한 영상을 복원하는 것을 볼 수 있다. 또한 그림 5에서 제안 방법은 [1]의 방법보다 깨끗한 영상을 복원하는 것을 관찰할 수 있다.

V. 결 론

본 논문에서 제안한 방법은 기존의 웨이블릿 기반의 영상 보간법이 가지는 파라미터 추정에 따르는 어려움을 해결하였다. 분산 추정시 훈련에 의존하지 않고 보간할 영상의 스케일간 계수에 대해 모델링하여 직접 추정함으로써 입력 영상의 특성에 보다 적합한 추정을 시도하였다. 훈련이 필요 없고 개별 영상에 맞는 분산 추정이 이루어진다는 장점이 있다. 실험 결과는 제안 방법의 타당성을 보여준다. 앞으로 입력 영상에 대한 상태천이 확률을 훈련 없이 보다 정확하게 추정하는 방법과 스케일간 웨이블릿 계수에 대한 부호의 통계적인 상관관계를 이용하여 부호를 좀 더 정확히 추정하는 연구가 필요하다.

참 고 문 헌

- [1] K. Kinebuchi, D. D.Muresan, and T. W. Parks, "Image interpolation using wavelet-based hidden Markov trees," ICASSP01, Vol. 3, pp. 7-11, May 2001.
- [2] J. Allebach and P. W. Wong, "Edge directed interpolation," ICIP96, Vol. 3, pp. 707 - 710, 1996.
- [3] X. Li and M. T. Orchard, "New edge-directed interpolation," IEEE Trans. Image Processing, Vol. 10, No. 10, pp. 1521-1527, Oct. 2001.
- [4] K. Jensen and D. Anastassiou, "Subpixel edge localization and the interpolation of still images," IEEE Trans. on Image Processing, Vol. 4, pp. 285-295, Mar. 1995.
- [5] W. K. Carey, D. B. Chuang, and S. S. Hemami, "Regularity-preserving interpolation," IEEE Trans. Image Processing, Vol. 8, No. 9, Sept. 1999.
- [6] M. S. Crouse, R. D. Norwak, and, 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.
- [7] J. R. Romberg, H. C. Choi, and R. G. Baraniuk, "Bayesian tree-structure image modeling using wavelet-domain hidden Markov models," IEEE Trans. Image Processing, Vol. 10, No. 7, July, 2001.
- [8] Nobuyuki Otsu, "A threshold selection method form gray-level histogram," IEEE Trans. Systems, Man, And Cybernetics Vol. SMC-9, No. 1 Jan. 1979.
- [9] S. Mallat and S. Zhong, "Characterization of signals from multiscale edges," IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 14, pp. 710-732, July 1992.
- [10] D. D. Muresan and T. W. Parks "Prediction of image detail," IEEE International Conference on Image Processing, Sept. 2000.
- [11] S. G. Chang, Z. Cvetković, and M. Vetterli, "Resolution enhancement of images using wavelet transform extrema extrapolation," IEEE ICASSP'95, pp. 2379-2382.
- [12] Z. Cvetković and M. Vetterli, "Discrete-time wavelet extrema representation: design and consistent reconstruction," IEEE Trans. on Signal Processing, Vol. 43, No. 3, pp. 681-693, Mar. 1995.
- [13] Y. Zhu, S. C. Schwartz, M. T. Orchard, "Wavelet domain image interpolation via statistical estimation," IEEE ICIP'01, Vol. 3 pp. 7-10
- [14] H. F. Ates, M. T. Orchard, "Image interpolation using wavelet-based contour estimation," IEEE ICASSP'03, Vol. 3, pp. III-109-112
- [15] N. Plaziac, "Image interpolation using neural networks," IEEE Trans. Image Processing, Vol. 8, No. 11, pp. 1647-1651, Nov. 1999.
- [16] T. Blu, P. Thévenaz, and M. Unser, "Linear interpolation Revitalized," IEEE Trans. Image Processing, Vol. 13, No. 5, pp. 710-719, May 2004.
- [17] G. Ramponi, "Warped Distance For Space Variant Linear Image Interpolation," IEEE Trans. Image Processing, Vol. 8, pp. 629-639, 1999.
- [18] S. E. Khamy, M. M. Hadhoud, M. I. Dessouky, B. M. Salam, and F. E. Abd El-Samie, "A New Edge Preserving Pixel-by-Pixel Cubic Image Interpolation Approach," NRSC Mar. 16-18, 2004.
- [19] V. R. Algazi, G. E. Ford, and R. Potharlanka, "Directional interpolation of images based on visual properties and rank order filtering," IEEE ICASSP, Vol. 4, 1991, pp. 3005-3008
- [20] S. Carrato, G. Ramponi, and S. Marsi, "Simple edge-sensitive image interpolation filter," IEEE ICIP, Vol. 3, 1996, pp. 711-714
- [21] S. K. Mitra, H. Li, I. Lin, and T. Yu, "A new class of nonlinear filters for image

- enhancement," IEEE ICASSP'91 pp. 2525-2528
- [22] E. P. Simoncelli, "Bayesian denoising of visual images in the wavelet domain," Bayesian inference in wavelet based models eds. P Müller and B Vidakovic, Chap.18, pp. 291-308, Lecture notes in statistics, Vol. 141, Springer-Verlag, 1999.
- [23] M. Malfait and D. Roose, "Wavelet-based image denoising using a Markov random field a priori model," IEEE Transaction on Image Processing, vo.6, no.4, pp.549-565, 1997.
- [24] D. L. Donoho and I. M. Johnstone, "Adapting to unknown smoothness via wavelet shrinkage," J. Amer. Statist. Assoc., vol. 90, no. 432, pp. 1200-1224, 1995.

저자 소개



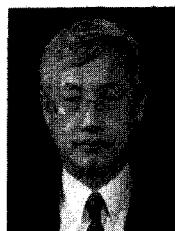
김 상 수(정회원)
 1997년 부산대학교 전자공학과
 학사.
 1999년 부산대학교 전자공학과
 석사.
 2005년 ~ 현재 부산대학교
 전자공학과 박사 과정.

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



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>



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 컴퓨터 및 정보통신
 연구소

<주관심분야 : 영상처리, 신경회로망, 공학윤리,
 과학기술철학>