

# 웨이블릿 계수의 통계적 활동성을 이용한 공간 적응 잡음 제거

정희원 엄 일 규\*, 김 유 신\*\*

## Spatially Adaptive Denoising Using Statistical Activity of Wavelet Coefficients

Il-Kyu Eom\*, Yoo-Shin Kim\*\* *Regular Members*

요 약

영상 잡음의 제거를 위해서는 영상에 대한 통계적 모델을 설정하고, 잡음이 섞인 영상에서 원 영상의 분산을 정확하게 추정하는 것이 매우 중요하다. 분산을 추정하기 위해서는 일반적으로 유한한 크기의 주변 영역 정보를 이용한다. 주변 영역의 크기는 평탄 영역 및 에지 영역과 같이 영상의 영역에 따라 달라진다. 즉, 에지 영역인 경우는 주변 영역의 크기를 작게 설정할수록 추정 분산이 보다 정확하며, 평탄 영역의 경우는 주변 영역의 크기가 크면 분산의 추정이 정확해진다. 이와 같이 추정된 원 영상의 분산을 이용하여 잡음 영상에 Wiener 필터를 적용함으로써 영상의 잡음을 제거하는 것이 일반적이다. 본 논문에서는 영상의 잡음을 제거하기 위해 웨이블릿 영역의 부모-자식 관계를 이용하여 중요도(重要圖)를 작성하고, 이를 이용하여 분산을 구하기 위한 이웃 영역의 범위를 결정하는 방법을 제안한다. 먼저 웨이블릿 계수의 중요한 특성을 획득할 수 있는 중요도를 작성하기 위해 간단한 분류 방법을 사용한다. 중요한 웨이블릿 계수의 수에 근거하여 웨이블릿 계수의 범위를 결정한 뒤 ML(maximum likelihood) 방법을 이용하여 원 신호의 분산을 추정한다. 실험 결과를 통하여 제안 방법이 기존의 방법보다 나은 결과를 보여줄 수 있다.

Keyword : denoising, wavelet transform, significance map, spatially adaptive, statistical activity

### ABSTRACT

It is very important to construct statistical model in order to exactly estimate the signal variance from a noisy image. In order to estimate variance, information of neighboring region is used generally. The size of neighbor region is varied according to the regional characteristics of image. More accurate estimation of edge variance is due to smaller region of neighbor, on the other hands, larger region of neighbor is used to estimate the variance of flat region. By using estimated variance of original image, in general, Wiener filter is constructed, and it is applied to the noisy image. In this paper, we propose a new method for determining the range of neighbors to estimate the variance in wavelet domain. Firstly, a significance map is constructed using the parent-child relationship of wavelet domain. Based on the number of the significant wavelet coefficients, the range of neighbors is determined and then the variance of the original signal is estimated using ML(maximum likelihood) method. Experimental results show that the proposed method yields better results than conventional methods for image denoising.

\* 밀양대학교 정보통신공학과(ikeom@mnu.ac.kr), \*\*부산대학교 전자공학과 (kimys@pusan.ac.kr)  
논문번호 : 020529-1209, 접수일자 : 2002년 12월 9일

## I. 서론

웨이블릿 변환은 실제계의 신호를 포함하는 많은 응용 분야에 강력한 정보를 제공하고 있기 때문에 통계 신호처리 및 영상 처리를 위해 일반적으로 사용하고 있다. 특히, 웨이블릿 변환은 영상의 잡음 제거에 우수한 성능을 나타내고 있다. 웨이블릿 변환을 이용하여 잡음을 제거하기 영상에 대한 통계적 모델을 설정하고, 잡음이 섞인 영상에서 원 영상의 분산을 정확하게 추정하는 것이 중요하다. 웨이블릿 영역 영상의 통계적 모델은 가우스 확률 모델(Gaussian model)[1,3], 일반화된 가우스 확률 모델(generalized Gaussian model)[2], 가우스 혼합 모델(Gaussian mixture model)[5-8] 및 단순 혼합 모델[4] 등을 주로 사용하고 있다. 원 영상 신호의 분산을 추정하기 위한 방법으로는 ML 방법[1-4], MAP(maximum a posteriori) 방법[1-2], HMM(hidden Markov model)을 이용한 방법[5-8] 등이 있다.

웨이블릿 계수에 대한 통계적 특성을 가우스 확률 모델로 설정하고 ML 및 MAP 방법을 이용하여 분산을 추정하여 잡음 제거를 하는 방법[1]은 적은 계산량을 가지는 장점이 있지만 복잡한 추정 기법을 사용한 방법 보다 잡음 제거 성능이 떨어진다. 이웃 영역의 웨이블릿 계수에 대하여 최소자승법을 사용하여 적절한 가중치를 부여함으로써 이웃 영역 계수의 기여도를 달리하여 신호의 분산을 추정하는 방법[2]은 일반적인 ML 방법보다 성능이 높은 반면 계산량이 많은 단점을 가지고 있다. 웨이블릿 계수의 통계적 특성을 가우스 혼합 모델로 설정하고 분산을 추정하기 위하여 HMM을 사용한 방법은 보다 정확한 분산을 추정할 수 있지만 EM(Expectation Maximization) 알고리즘을 사용하기 때문에 계산량이 많은 단점을 가지고 있다. 다른 HMM을 이용한 방법은 웨이블릿 계수의 부모-자식의 상관관계를 이용한 HMT[Hidden Markov tree] 모델[5-6, 8], 복소수 웨이블릿 변환과 HMM을 결합한 방법[7] 등이 알려져 있다.

웨이블릿 영역에서 한 계수의 분산을 추정하기 위해서 그 계수 이웃 계수 정보를 이용하는 방법이 일반적으로 사용된다. 즉, 이웃 계수들을 이용하여 ML, MAP, HMM 등의 통계 모델로 계수의 분산을 추정한다. 신호의 분산을 보다 정확히 추정하기 위해 이용되는 이웃 계수들의 수는 그 신호의 성질에 따라 달라진다. 평탄한 영역에서는 많은 수의 이

웃이 유리하고 변화가 심한 에지 영역에서는 적은 수의 이웃이 유리하다. 따라서 웨이블릿 영역의 특성에 따라 이웃 계수 영역을 공간적으로 가변 시키는 방법이 분산의 추정이 보다 정확하기 때문에 잡음 제거의 성능을 높일 수 있다. 이웃 영역의 크기를 영상의 특성에 따라 가변적으로 적용하는 방법[2,3]은 아직 많은 연구가 진행되고 있지 않다.

본 논문에서는 웨이블릿 영역에서 웨이블릿 계수의 확률적 특성을 이용하여 공간적으로 이웃 계수를 가변 시키는 방법을 제안한다. 먼저 통계적 정보를 이용한 문턱값[2]을 이용하여 중요한 정보를 가지는 웨이블릿 계수와 중요하지 않은 웨이블릿 계수를 분류하여 중요도(Significance map)를 생성한다. 중요도의 생성은 웨이블릿 계수의 부모-자식 관계를 이용한다. 다음으로 중요도를 이용하여 이웃 영역의 범위를 결정하고, 결정된 이웃 영역의 계수를 이용하여 원 신호의 분산을 추정하는 방법을 제안한다. 제안된 방법은 간단하면서도 ML, MAP 및 HMM을 이용한 잡음 제거 방법들과 비교하여 우수한 잡음 제거 성능을 나타낸다.

본 논문의 구성은 다음과 같다. II장에서는 신호의 분산을 추정하기 위한 모델들에 대한 간단한 이론을 살펴보고, III장에서는 제안 방법을 설명한다. 제안된 방법을 영상 잡음 제거에 적용한 것을 IV장에 나타내며, V장에서는 결론을 기술한다.

## II. 웨이블릿 변환을 이용한 잡음 제거 방법

잡음 영상은 다음과 같이 모델링될 수 있다. 즉,

$$x[i, j] = s[i, j] + \epsilon[i, j], \quad i, j = 1, \dots, P, \quad (1)$$

여기서  $s[i, j]$ 는 원 영상이고,  $\epsilon[i, j]$ 은 평균이 영이고 분산이  $\sigma_n^2$ 인 백색 가우스 잡음이다. 잡음이 첨가된 영상  $x[i, j]$ 로부터  $s[i, j]$ 를 복구하는 것이 영상 잡음 제거의 목적이다. 웨이블릿 영역에서 잡음을 제거하기 위해서는 먼저 관찰된 영상  $x[i, j]$ 에 대하여 다음과 같이 웨이블릿 변환을 수행한다.

$$X^{(s, o)}[i, j] = S^{(s, o)}[i, j] + E^{(s, o)}[i, j], \quad (2)$$

여기서  $i, j = 1, 2, \dots, P/2^s$ 이고,  $s = (1, 2, \dots, J)$ 는

웨이블릿 변환 스케일을 나타낸다. 또한 방향성은  $\alpha \in \{LL, HL, LH, HH\}$  로 나타낸다. 앞으로 혼동의 여지가 없는 한  $(s, \alpha)$  는 생략한다.

웨이블릿 계수가 독립적이고 동일하게 분포된 가우스 확률 모델을 가지고 있다고 가정하면, 웨이블릿 계수의 분산은 주변 영역의 웨이블릿 계수를 사용하여 구할 수 있다. 가우스 랜덤 변수를  $X$  라 하면 독립적으로 분포하는 웨이블릿 계수의 확률 밀도함수  $f(X|0, \sigma)$  는 다음과 같다.

$$f(X|0, \sigma) = \prod_{k, l \in M[i, j]} \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{X[k, l]^2}{2\sigma^2}\right] \quad (3)$$

여기서  $M[i, j]$  는  $X[i, j]$  의 이웃 영역에 포함된 웨이블릿 계수들을 나타낸다. ML 방법은 식 (3)의 확률 밀도함수를 최대화 시키는 분산을 추정하는 방법이다. 즉 추정된 분산  $\hat{\sigma}^2[i, j]$  은 다음과 같이 나타낼 수 있다.

$$\hat{\sigma}^2[i, j] = \arg \max_{\sigma^2 \geq 0} \prod_{k, l \in M[i, j]} f(X[k, l] | \sigma^2) \quad (4)$$

최대값을 구하기 위해서 먼저 식 (3)에 로그를 취한다. 즉, 로그를 취한 확률 밀도함수  $\Lambda(0, \sigma, X)$  는 다음과 같다.

$$\Lambda(0, \sigma, X) = -|M[i, j]| \log \sqrt{2\pi} - |M[i, j]| \log \sigma - \frac{1}{2\sigma^2} \sum_{k, l \in M[i, j]} X[k, l]^2 \quad (5)$$

식 (5)에서  $|M[i, j]|$  는 분산을 추정하기 위한 웨이블릿 계수  $X[i, j]$  의 주변 영역으로 설정된 웨이블릿 계수의 개수이다. 식 (5)을 분산으로 미분하여 0으로 두고 최대가 되는 분산을 구하면 다음과 같다. 즉,

$$\frac{\partial \Lambda}{\partial \sigma} = -\frac{|M[i, j]|}{\sigma} + \sigma^{-3} \sum_{k, l \in M[i, j]} X[k, l]^2 = 0 \quad (6)$$

$$\hat{\sigma}^2[i, j] = \frac{1}{|M[i, j]|} \sum_{k, l \in M[i, j]} X[k, l]^2 \quad (7)$$

MAP에 의한 추정 방법은 통계 파라미터에 대한 정보를 가지고 있을 경우 사용한다. 즉, 분산에 대한 분포를 알고 있다고 가정하면 다음 식에 의하여 분산을 추정할 수 있다.

$$\hat{\sigma}^2[i, j] = \arg \max_{\sigma^2 \geq 0} \prod_{k, l \in M[i, j]} f(X[k, l] | \sigma^2) f_\alpha(\sigma^2) \quad (8)$$

여기서  $f_\alpha(\sigma^2)$  는 분산에 대한 분포를 나타내는 a priori 밀도 함수이다. 추정 방법은 ML 방법과 동일하다. 이 때 a priori 밀도 함수를 결정하는 것이 또 하나의 문제가 될 수 있다. 식(7-8)에서 이웃 영역의 웨이블릿 계수의 집합  $M[i, j]$  을 고정적으로 둘 수도 있고, 추정방법에 따라 가변적으로 둘 수 있다. ML 및 MAP 방법에 대한 Wiener 필터,  $H[i, j]$  는 잡음의 분산이  $\sigma_n^2$  일 때 다음과 같이 구할 수 있다.

$$H[i, j] = \frac{\hat{\sigma}^2[i, j]}{\hat{\sigma}^2[i, j] + \sigma_n^2} \quad (9)$$

일반적으로 웨이블릿 계수의 통계적 특성은 가우스 확률 분포보다 복잡한 특성을 가지고 있다. 가우스 확률 분포를 사용하는 이유는 복잡도를 줄이기 위해서이다. 따라서 웨이블릿 계수의 특성을 가우스 모델로 보지 않고 가우스 혼합 모델로 간주하는 경우 보다 정확도를 높일 수 있다. 이산 히든 상태  $S = \{0, 1, \dots, M-1\}$  및  $S$  에 대한 확률밀도 함수  $p_S(m)$  을 가지는 가우스 혼합 모델은  $\pi = \{p_S(m), 0, \sigma_m^2 | m = 0, 1, \dots, M-1\}$  에 의해서 모델링되며, 전체 확률밀도 함수는 다음과 같다.

$$f_X(X) = \sum_{m=0}^{M-1} p_S(m) f_{X|S}(X | S=m) \quad (10)$$

가우스 혼합 모델에 의하여 추정된 분산을 이용한 Wiener 필터는 다음과 같이 구할 수 있다.

$$H[i, j] = \sum_{m=0}^{M-1} p(S=m) \cdot \frac{\sigma_m^2[i, j]}{\sigma_m^2[i, j] + \sigma_n^2} \quad (11)$$

식 (11)에서  $p(S=m)$  및  $\sigma_m^2$  은 EM 알고리즘으로 구할 수 있지만, 계산량이 많은 단점을 가지고 있다.

### III. 제안 방법

#### 3.1 부모-자식 관계를 이용한 중요도의 작성

웨이블릿 계수는 작은 값을 가지는 아주 많은 계수와 큰 값을 가지는 적은 수의 계수를 가지고 있다. 큰 값을 가지는 적은 수의 웨이블릿 계수는 원 신호의 고주파 성분 즉, 에지 정보를 나타내고 있다. 이러한 에지 정보를 이용하여 분산을 구하는 이웃 영역의 범위를 달리함으로써 잡음 제거의 효과를 높일 수 있다. 잡음이 없는 신호에 대해서는 웨이블릿 영역의 에너지를 이용하여 에지 영역을 판단하기 쉽지만, 잡음이 첨가된 신호는 잡음의 영향 때문에 에너지를 사용하는 것에 문제가 발생한다. 즉, 잡음의 에너지 때문에 배경 부분이 에지 부분으로 나타날 수 있다.

본 논문에서는 통계적 특성을 이용한 문턱값을 이용하여 중요한 정보를 가지는 웨이블릿 계수의 중요하지 않은 웨이블릿 계수를 분류하는 방법을 사용한다. 문턱값  $T[i, j]$ 는 가우스 백색 잡음의 분산  $\sigma_n^2$ 과 신호의 분산  $\sigma_s[i, j]$ 을 이용하여 다음과 같이 구할 수 있다.[2]

$$T[i, j] = \frac{\sigma_n^2}{\sigma_s[i, j]} \quad (12)$$

식 (12)에 의해 일차적으로 웨이블릿 계수에 대한 중요도,  $M_1[i, j]$ 는 다음과 같이 구할 수 있다.

$$M_1[i, j] = \begin{cases} 1 & \text{if } |X[i, j]| \geq T[i, j] \\ 0 & \text{otherwise} \end{cases} \quad (13)$$

그림 1은 웨이블릿 영역에서 잡음의 표준편차가  $\sigma_n = 10$ 인 Lena 영상에 대한 중요도를 나타낸다. 흰색은  $M_1[i, j] = 1$ 인 웨이블릿 계수를 나타내고, 검은색은  $M_1[i, j] = 0$ 인 웨이블릿 계수를 나타낸다. 그림 1에서 볼 수 있듯이 중요도는 영상의 중요한 정보를 포함하고 있다. 그러나 배경 부분에서 중요하다고 판단된 웨이블릿 계수를 볼 수 있는데 이것은 잡음의 효과로 인해 발생된 오류로 볼 수 있다.



그림 1. Lena 영상에 대한 웨이블릿 계수의 중요도 ( $M_1[i, j]$ )

웨이블릿 영역에서 신호 성분은 진 스케일(주파수 대역)에 걸쳐 분포되어 있고, 잡음 성분은 웨이블릿 변환의 저주파 통과 특성 때문에 스케일이 높아질수록 감소하게 된다. 따라서 부모 계수가 중요하면 자식 또한 중요한 확률이 높고, 부모 계수가 중요하지 않으면 자식 계수 또한 중요하지 않을 확률이 높다. 그림 2는 웨이블릿 영역의 부모-자식 관계를 나타낸다. 이러한 관계는 EZW[10]와 같은 영상 압축 방법 등 다양한 분야에서 사용되고 있다. 잡음 제거 방법에서는 Holder 지수를 사용한 방법[11-12] 등이 일반적으로 사용되고 있지만, 계산량이 많고 다운 샘플링을 하지 않은 웨이블릿 계수에 적용할 수 있다. 그러나 Holder 지수는 입력 영상의 공간적 변이에 아주 민감하기 때문에 입력 영상의 변이에 독립적이지 못한 다운 샘플링된 웨이블릿 변환에 적용할 수 없다. 본 논문에서는 다운 샘플링된 웨이블릿 계수를 사용하기 때문에 Holder 지수를 사용하기 힘들다.

따라서 본 논문에서는 EZW에서 사용한 방법과 같이 부모 계수가 중요하면 자식 계수도 중요하다고 판단하고, 부모-관계를 이용한 중요도  $M_2[i, j]$ 를 다음과 같이 간단히 정의한다.

$$M_2^{(j,0)}[i, j] = M_1^{(j,0)}[i, j] \quad (14)$$

$$M_2[i, j] = M_1[i, j] \times M_1[|i/2|, |j/2|] \quad (15)$$




그림 2 웨이블릿 영역의 부모-자식 관계.

현재의 중요도  $M_1[i, j]$  과 그 부모의 중요도  $M_1[|i/2|, |j/2|]$  이 동시에 중요한 신호를 포함하고 있다면, 중요하다고 판단한다. 스케일이 가장 높은 경우 즉,  $s=J$  인 경우는 부모가 없기 때문에  $M_1[i, j]$  을 그대로 사용한다. 흔히 잡음을 제거하기 위하여 뭉통화 필터를 사용하듯이 본 논문의 방법은 뭉통화 효과를 가진다. 그림 3는 Lena 영상에 대하여  $M_2[i, j]$  를 나타낸 것이다. 그림에서 볼 수 있듯이  $M_1[i, j]$  보다 잡음 성분이 상당히 제거된 것을 알 수 있다.

### 3.2 중요한 웨이블릿 계수이한 이웃 영역 크기의 결정

분산을 추정하기 위한 이웃 영역을 정방형의 형태로 다음과 같이 정의한다.

$$L_k[i, j] \equiv (k \times k), \quad k = 2l + 3, \quad l = 0, 1, \dots \quad (16)$$

이에 따른 이웃 영역을 다음과 같이 결정된다.

$$N_k[i, j] = \{X[m, n] \mid m, n = -|k/2| + i, j, \dots, |k/2| + i, j\} \quad (17)$$

또한 이웃 영역에 포함되는 웨이블릿 계수의 수는  $|N_k[i, j]| = k^2$  이다.



그림 3 부모-자식관계를 이용한 Lena 영상에 대한 중요도( $M_2[i, j]$ ).

$M_2[i, j]$  의 분포에 의해 웨이블릿 계수가 에지일 확률,  $P_e[i, j]$  을 다음과 같이 구할 수 있다.

$$P_{sig}[i, j] = \frac{1}{|N_k[i, j]|} \sum_{m, n} M_2[m, n] \quad (18)$$

본 논문에서는  $P_e[i, j]$  를 구하기 위해 식 (18)에서  $k=5$ 로 하였다. 그림 4는  $P_{sig}[i, j]$  를 보여준다. 각 확률값은 0에서 255로 선형적으로 확장되었다. 그림 4에서 볼 수 있듯이 영상의 에지 영역에서 확률값이 높고, 잡음 영역에서는 확률값이 낮음을 알 수 있다.

$P_e[i, j]$  를 이용하여 본 논문에서는 이웃 영역의 범위를 다음과 같이 설정한다. 즉,

$$k = \begin{cases} 3 & \text{if } P_e[i, j] \geq 1/2 \\ 5 & \text{if } 1/4 \leq P_e[i, j] < 1/2 \\ 7 & \text{if } 1/8 \leq P_e[i, j] < 1/4 \\ 9 & \text{if } P_e[i, j] < 1/8 \end{cases} \quad (19)$$

식 (19)에서 결정된 이웃 영역은 확률값의 범위에 따라서  $3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9$  등으로 결정될 수 있다. 앞서 결정된 결과들을 이용하여 신호의 분산  $\hat{\sigma}^2[i, j]$  를 ML 방법을 이용하여 다음과 같이 추정할 수 있다.




그림 4 Lena 영상에 대한  $P_{sig}$  값(0에서 255로 선형적으로 확장).

$$\hat{\sigma}_n^2[i, j] = \max \left( \frac{1}{|N_{k,l}[i, j]|} \sum_{m, n \in N_{k,l}[i, j]} |X[m, n]|^2 - \sigma_n^2, 0 \right) \quad (20)$$

식 (20)에서 추정된 분산에서 잡음의 분산을 빼 값을 원 신호의 분산으로 추정할 수 있다. 따라서 추정된 분산을 이용하여 식 (9)의 Wiener 필터를 적용하여 잡음을 제거할 수 있다. 본 논문에서 제안한 필터는 잡음 환경의 웨이블릿 영역에서 적응적으로 이웃 영역의 범위를 결정할 수 있는 장점이 있다.

#### IV. 실험 및 결과

제안된 영상 잡음 제거 방법을 이용하여 표준 영상(Lena 및 Barbara, 512×512, 8bpp)에 대하여 Adelson 9-탭 웨이블릿 필터[9]로 5번의 웨이블릿 변환을 하여 모의실험을 하였다. 가우스 백색 잡음은 MATLAB의 randn 함수를 사용하여  $\sigma_n = 10, 15, 20, 25$  만큼 생성하였다.

표 1은 Lena 영상에 대하여 신호의 분산을 추정하기 위하여 제안 방법과 다양한 잡음 제거 방법을 비교한 결과를 나타낸다. 표 1에서 SAWT는 이웃 웨이블릿 계수의 가중치를 최소 자승법으로 구하여 ML을 적용한 경우이고, MAP는 5×5 마스크에 대하여 MAP를 적용한 경우이다. AML은 부트스트랩 알고리즘을 이용하여 각 웨이블릿 계수에 대하여 적응적 마스크 크기를 적용한 경우이고, HMT는

HMT 모델을 이용한 경우이다. CHMT는 복소수 웨이블릿 변환과 HMT를 접목한 방법이고, SSM은 웨이블릿 계수에 대하여 ML 및 MAP를 혼합적으로 적용한 방법이다. 표 1에서 볼 수 있듯이, 제안한 방법의 성능이 다른 방법에 비하여 우수함을 알 수 있다.  $\sigma_n = 10$  인 경우에는 복소수 웨이블릿과 HMT 방법을 이용한 것보다 성능이 0.3dB 정도 떨어지지만 다운 샘플링한 웨이블릿 계수를 사용한 경우와 다운 샘플링을 하지 않은 웨이블릿 계수를 사용한 경우의 비교이기 때문에 복잡도에 비하여 잡음 제거 성능이 떨어지는 것은 trade-off 관계에 있다고 볼 수 있다. 그러나 표 1의 결과에서 알 수 있듯이 잡음의 분산이 큰 경우에는 이웃 영역의 크기를 가변시킨 제안 방법의 결과가 0.1dB 우수함을 알 수 있다.

표 1. 다양한 잡음 제거 방법에 대한 PSNR 결과(Lena 영상).

PSNR/ $\sigma_n$	10	15	20	25
SAWT[2]	-	31.83	30.49	29.50
MAP[1]	34.31	32.36	31.01	29.98
AML[3]	34.39	32.38	30.96	29.84
HMT[8]	33.9	31.8	30.4	29.5
CHMT[7]	34.9	-	-	29.9
SSM[4]	34.8	32.5	-	-
제안방법	34.60	32.65	31.20	30.09

표 2는 Barbara 영상에 대하여 신호의 분산을 추정하기 위하여 제안 방법과 다양한 잡음 제거 방법을 비교한 결과를 나타낸다. Lena 영상과 마찬가지로 기존의 방법에 비하여 우수한 결과를 나타내고 있다. Barbara 영상의 경우는 에지 영역 및 복잡한 텍스처 영역이 많이 존재하기 때문에 Lena 영상과 비교하여 전체적인 성능 개선을 볼 수 있다. 이는 에지 영역에 대하여 적은 이웃 웨이블릿 계수를 사용하여 보다 정확한 분산을 추정할 수 있기 때문이다.

그림 5는 Lena 영상에 대하여  $\sigma_n = 20$  일 때 제안방법의 결과이다. 그림 5(c)는 이웃 영역의 범위를 표현하고 있다. 즉, 하얀색은 가장 작은 영역 즉,  $k=3$ 인 경우이고, 어두워질 수록  $k$ 의 값이 5, 7, 9 등으로 증가한다. 그림 5에서 볼 수 있듯이 에지 영역에서는 높은 확률값을 가지기 때문에 적은 이웃 계수(하얀색)를 가지고 평탄 영역에서는 낮

은 확률값을 가지기 때문에 많은 이웃 계수(검은색)를 가지고 있음을 보이고 있다.

표 2 다양한 잡음 제거 방법에 대한 PSNR 결과(Barbara 영상).

PSNR/ $\sigma_n$	10	15	20	25
SAWT[2]	-	29.19	27.65	25.19
MAP[1]	32.57	30.19	28.59	27.42
AML[3]	32.67	30.26	28.65	27.43
HMT[8]	31.9	29.4	27.8	27.1
CHMT[7]	-	-	-	-
SSM[4]	32.4	30.0	-	-
제안방법	32.83	30.44	28.83	27.64




그림 5. (a) 원 영상, (b) 잡음 영상(21.11dB), (c) 이웃 영역의 범위, (d) 잡음 제거된 영상

### V. 결론

본 논문에서는 웨이블릿 영역에서 웨이블릿 계수의 통계적 특성을 이용하여 공간적으로 이웃 계수를 가변 시키는 방법을 제안하였다. 먼저 문턱값을 이용하여 중요한 정보를 가지는 웨이블릿 계수와 중요하지 않은 웨이블릿 계수를 분류하여 일차적으로 중요도를 생성하고, 웨이블릿 영역의 부모-자식 관계를 이용하여 이차적으로 중요도를 생성하였다. 다음으로 중요도를 이용하여 이웃 영역의 범위를 결정하고, 결정된 이웃 영역의 계수를 이용하여 원 신호의 분산을 추정하는 방법을 제안하였다. 제안된

방법은 간단하면서도 ML, MAP 및 HMM을 이용한 잡음 제거 방법들과 비교하여 우수한 잡음 제거 성능을 나타내고 있음을 알 수 있다.

### 참고문헌

- [1] M. K. Mihcak, I. Kozintsev, K. Ramchandran, and P. Moulin, "Low-complexity image denoising based on statistical modeling of wavelet coefficients," *IEEE Signal Processing Letters*, vol. 6, pp. 300-303, 1999.
- [2] S. G. Chang, B. Yu, and M. Vetterli, "Spatially adaptive wavelet thresholding with context modeling for image denoising," *IEEE Trans. Image Processing*, vol. 9, no.9, pp.1522-1531, 2000.
- [3] M. K. Mihcak, I. Kozintsev, K. Ramchandran, "Spatially Adaptive statistical Modeling of Wavelet Image Coefficients and Its Application to Denosing," *Proc. IEEE Int. Conf. Acous., Speech and Signal Processing*, vol.6, pp. 3253-3256, 1999.
- [4] J. Liu and P. Moulin, "Image denoising based on scale-space mixture modeling of wavelet coefficients," *Proc. IEEE Int. Conf. on Image Processing, Kobe, Japan, 1999*.
- [5] M. S. Crouse, R. D. Nowak, and R.G. Baraniuk, "Wavelet-based statistical signal processing using hidden Markov models," *IEEE. Trans. Image Processing*, vol.46, pp. 886-902, 1998.
- [6] J. K. Romberg, H. Choi, and R. G. Baraniuk, "Bayesian tree-structured image modeling using wavelet-domain hidden Markov models," *IEEE. Trans. Image Processing*, vol.10, no.7, pp. 1056-1068, 2001.
- [7] H. Choi, J. Romberg, R. Baraniuk, and N. Kingsbury, "Hidden Markov Tree Modeling of Complex Wavelet Transforms," *Proc. IEEE Int. Conf. Acous., Speech and Signal Processing, Istanbul, Turkey, June, 2000*.
- [8] J. K. Romberg, H. Choi, and R. Baraniuk, "Bayesian tree structured image modeling using wavelet domain hidden Markov model," *Proc. SPIE*, vol.3816, pp.31-44, 1999.

- [9] E. H. Adelson, E. Simoncelli, and R. Hingorani, "Orthogonal pyramid transforms for image coding, " Proc. SPIE, vol.845, pp.50-58, 1987.
- [10] J. M. Shapiro, "Embbded image coding using zerotrees of wavelet coefficients," IEEE Trans. Signal Processing, vol. 41, pp. 3445-3462, 1993.
- [11] M. Malfiat 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.
- [12] A. Pizurica, W. Ohulips, I. Lemahieu, and M. Achcroy, "A joint inter- and intra scale statistical model for Bayesian wavelet based image denoising," , IEEE. Transaction onImage

임 일 규(Im-Kyu Eom)

정회원



1990년 2월 : 부산대학교 전자  
공학과 졸업  
1992년 0월 : 부산대학교 전자  
공학과 석사  
1998년 2월 : 부산대학교 전자  
공학과 박사  
1997년 3월~현재 : 밀양대학

교 정보통신공학과 부교수

<수관심분야> 통계신호처리, 영상처리, 웨이블릿  
변환 신호처리, 신경회로망

김 유 신(Yoo-Shin Kim)

정회원

한국통신학회 논문지 제27권 6A호 참조  
현재 : 부산대학교 전자공학과 교수