

논문 2004-41SP-5-12

영상 잡음 제거를 위한 영역 확장 기반 가변 윈도우 크기 결정 알고리즘

(Region Growing Based Variable Window Size Decision Algorithm
for Image Denoising)

엄 일 규*, 김 유 신**

(Il Kyu Eom and Yoo Shin Kim)

요약

웨이블릿 영역에서 Bayesian 추정법을 이용한 잡음 제거를 위해서는 웨이블릿 계수의 prior 모델, 잡음의 확률분포, 웨이블릿 계수에 대한 분산 등의 정보가 필요하다. 잡음 제거의 일반적인 방법은 웨이블릿 계수에 대한 적절한 prior 모델을 설정하고 이에 대한 신호의 분산을 추정하는 것이다. 본 논문에서는 영역 확장 방법을 사용하여 영상의 영역에 따라 분산을 추정하기 위한 창의 크기를 결정하는 방법을 제안한다. 이웃 계수의 범위는 동질성 척도를 정의하여 가장 작은 영역부터 영역을 확장하는 방법을 사용한다. 결정된 가변 이웃 영역을 사용하여 원 신호의 분산을 결정하고 이를 이용하여 웨이블릿 영역에서 Bayesian 추정법을 사용하여 영상의 잡음을 제거한다. 실험 결과를 통하여 제안 방법이 기존의 방법보다 높은 PSNR을 나타낸다 보여 준다.

Abstract

It is essential to know the information about the prior model for wavelet coefficients, the probability distribution of noise, and the variance of wavelet coefficients for noise reduction using Bayesian estimation in wavelet domain. In general denoising methods, the signal variance is estimated from the proper prior model for wavelet coefficients. In this paper, we propose a variable window size decision algorithm to estimate signal variance according to image region. Simulation results shows the proposed method have better PSNRs than those of the state of art denoising methods.

Keywords: 잡음제거, 영역 확장, 가변 윈도우, 웨이블릿

I. 서 론

웨이블릿 변환은 실세계의 신호를 포함하는 영상 신호의 추정, 검출, 분류, 압축, 잡음 제거 등의 많은 응용 분야에서 강력한 정보를 제공하고 있으며 특히, 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 변환 기반 영상 잡음 제거 방법은 웨이블릿 변환의 종류, 잡음의 종류, 영상 신호에 대한 prior 모델의 설정, 통계 파라메타의 추정 방법, 신호의 추정 방법 등에 의해서 분류될 수 있다.

웨이블릿 계수에 대한 통계적 특성을 가우스 확률 모델로 설정하고 Bayesian 추정법을 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

* 정희원, 밀양대학교 정보통신공학과
(Dept. Information and Communication Eng,
Miryang National University)
** 정희원, 부산대학교 컴퓨터 및 정보통신연구소
(Research Institute of Computer, Information and
Communication, Pusan National University)
접수일자: 2003년11월13일, 수정완료일: 2004년8월24일

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) 알고리듬을 사용하기 때문에 계산량이 많은 단점을 가지고 있다. 다른 HMM을 이용한 방법은 웨이블릿 계수의 부모-자식의 상관관계를 이용한 HMT(Hidden Markov tree) 모델^[4-7], 복소수 웨이블릿 변환과 HMM을 결합한 방법^[6] 등이 알려져 있다.

웨이블릿 영역에서 한 계수의 분산을 추정하기 위해서 그 계수 이웃 계수 정보를 이용하는 방법이 일반적으로 사용된다. 즉, 이웃 계수들을 이용하여 웨이블릿 계수의 분산을 추정한다. 신호의 분산을 보다 정확히 추정하기 위해 이용되는 이웃 계수들의 수는 그 신호의 성질에 따라 달라진다. 평탄한 영역에서는 많은 수의 이웃이 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 영역 확장 방법을 이용하여 분산을 추정하기 위한 이웃 계수의 수를 가변 시키는 방법을 제안한다. 분산을 구하기 위한 웨이블릿 계수의 수는 분산의 동질성이 보장되는 한 계속 확장된다. 제안된 방법은 평탄 영역에서는 많은 수의 계수를 이용하여 분산을 추정하고, 에지 영역에서는 적은 수의 계수를 이용하여 분산을 추정함으로써 분산 추정의 정확도를 높인다. 제안 방법은 ML, MAP 및 HMM을 이용한 잡음 제거 방법들과 비교하여 우수한 잡음 제거 성능을 나타낸다.

본 논문은 다음과 같이 구성된다. II 장에서는 가우스 확률분포에 의한 웨이블릿 영역의 Bayesian 잡음 제거 방법을 기술하고, III 장에서는 영역 확장을 이용한 웨이블릿 영역에서의 잡음 제거 방법을 제안한다. IV 장에서는 잡음 영상에 대하여 제안 방법과 기존 방법들과의 성능 비교를 통하여 제안 방법의 우수성을 보이고 V 장에서 결론 및 앞으로의 연구 방향을 서술한다.

II. 웨이블릿 영역의 Bayesian 잡음제거

잡음 영상은 일반적으로 다음과 같이 표현될 수 있다.

$$\mathbf{o} = \mathbf{v} + \mathbf{n} \quad (1)$$

여기서 \mathbf{o} , \mathbf{v} 및 \mathbf{n} 는 관찰된 영상, 원 영상, 및 분산이 σ_n^2 이고 평균이 0인 백색 가우스 잡음을 나타낸다. 관찰된 영상 \mathbf{o} 를 웨이블릿 변환하면 잡음 영상은 다음과 같다.

$$\mathbf{y} = \mathbf{w} + \mathbf{n} \quad (2)$$

\mathbf{y} 및 \mathbf{w} 는 각각 웨이블릿 영역에서 관찰된 영상과 원 영상을 나타낸다. 관찰된 \mathbf{y} 에서 \mathbf{w} 를 추정하는 것이 잡음 제거의 목적이 된다. \mathbf{y} 및 \mathbf{w} 를 랜덤 변수로 보고 y_k^j , w_k^j 를 각각 랜덤 변수에 대한 현실화된 값으로 가정하면, 식 (2)에 대한 Bayesian 추정은 다음과 같다.

$$\hat{w}_k^j(y_k^j) = \arg \max p_{\mathbf{w}|\mathbf{y}}(w_k^j | y_k^j) \quad (3)$$

영상의 화소수가 N 이라면 식 (3)에서 $k = 1, 2, \dots, N/4^j$ 는 웨이블릿 계수의 위치를 나타내고, $j = 1, 2, \dots, J$ 는 웨이블릿 변환 스케일을 나타며, $j = 1$ 이 가장 높은 주파수 대역이다.

Bayes 법칙을 이용하면 식 (3)은 다음과 같이 표현될 수 있다.

$$\begin{aligned} \hat{w}_k^j(y_k^j) &= \arg \max [p_{\mathbf{y}|\mathbf{w}}(y_k^j | w_k^j) \cdot p_{\mathbf{w}}(w_k^j)] \\ &= \arg \max [p_{\mathbf{n}}(y_k^j - w_k^j) \cdot p_{\mathbf{w}}(w_k^j)] \end{aligned} \quad (4)$$

식 (4)에 의해서 웨이블릿 계수에 대한 확률분포 함수 $p_{\mathbf{w}}(w_k^j)$ 와 잡음에 대한 확률분포 함수 $p_{\mathbf{n}}(n)$ 을 알고 있어야 한다. 위의 식은 최대값을 구하는 것이기 때문에 각 확률분포 함수에 log를 취하여 최대값을 구하는 것과 동일하다. 따라서 식 (4)를 다음과 같이 표현할 수 있다.

$$\hat{w}_k^j(y_k^j) = \arg \max [\log(p_{\mathbf{n}}(y_k^j - w_k^j)) + \log(p_{\mathbf{w}}(w_k^j))] \quad (5)$$

각 웨이블릿 계수가 서로 독립적인 가우스 확률분포 함수를 가진다고 가정하면 식 (5)는 다음과 같다.

$$\hat{w}_k^j(y_k^j) = \arg \max [-\frac{(y_k^j - w_k^j)^2}{2\sigma_n^2} + \log(p_{\mathbf{w}}(w_k^j))] \quad (6)$$

식 (6)을 w_k^j 에 대하여 미분을 취하고 그 값을 0으로 두면 최대값을 구할 수가 있다. 즉,

$$\frac{y_k^j - \hat{w}_k^j}{\sigma_n^2} - \hat{w}_k^j / (\sigma_k^j)^2 = 0 \quad (7)$$

따라서 추정치는 다음과 같다.

$$\hat{w}_k^j(y_k^j) = \frac{(\sigma_k^j)^2}{(\sigma_k^j)^2 + \sigma_n^2} \cdot y_k^j \quad (8)$$

관찰된 웨이블릿 계수로부터 잡음이 제거된 계수를 구하기 위해서는 잡음이 섞이지 않은 웨이블릿 계수에 대한 분산 $(\sigma_k^j)^2$ 을 정확하게 추정하는 것이 필요하다. 이를 위해서 일반적으로 웨이블릿 계수가 서로 독립적인 가우스 분포를 가진다고 가정하고 그림 1과 같이 이웃 웨이블릿 계수를 이용하여 ML(Maximum likelihood) 추정법을 이용하여 구한다. 하나의 웨이블릿 계수 w_k^j 에 대한 분산을 추정하기 위하여 이웃 영역의 집합 $c(k)$ 를 설정한다. 이웃 영역의 개수를 $|c(k)|$ 라 하면 분산은 다음과 같이 구할 수 있다. 즉,

$$\sigma_k^2 = \left(\frac{1}{|c(k)|} \sum_{m \in c(k)} y_m^2 - \sigma_n^2 \right)_+ \quad (9)$$

식 (9)에서 $(h)_+$ 연산은 $h < 0$ 일 때 $h = 0$ 의 값을 가지고 $h \geq 0$ 일 때는 그대로 값을 할당하는 연산이다.

그림 1과 같이 분산을 구하기 위한 웨이블릿 계수의 이웃 영역은 정재적 특성을 고려하여 적절하게 선택하는 것이 바람직하다. 즉, 비슷한 분산을 가지는 영역에서는 많은 이웃을 설정하여 분산을 구하고, 예지 영역과 같이 분산의 동질성이 보장되지 않는 영역에서는 적은 수의 이웃 계수를 이용하여 분산을 추정하는 것이 유리하다.

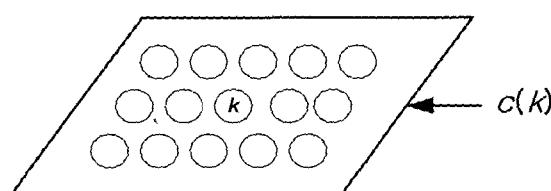


그림 1. 분산을 구하기 위한 웨이블릿 계수의 이웃 영역.

Fig. 1. The neighboring region of wavelet coefficient for obtaining variance.

III. 제안 방법

본 논문에서는 분산의 동질성 척도를 이용하여 분산을 추정하기 위한 이웃 계수의 수를 가변 시키는 방법을 제안한다. 분산을 구하기 위한 웨이블릿 계수의 수는 분산의 동질성이 보장되는 한 계속 확장된다. 웨이블릿 계수 w_k^j 를 포함하는 G 개의 영역 $R_{k,g}$ ($g = 1, 2, \dots, G$)가 있다고 가정하고, 각 영역은 다음과 같은 관계를 가지고 있다고 가정한다. 즉,

$$R_{k,1} \subset R_{k,2} \subset \dots \subset R_{k,G} \quad (10)$$

그림 2는 분산을 추정하기 위한 영역을 나타낸다. $c_0(k), c_1(k), \dots, c_{N-1}(k)$ 를 각 영역에 속하는 웨이블릿 계수의 집합이라고 하면, $R_{k,i}$ ($i = 0, 1, \dots, N-1$) 영역에서 각 영역에 대한 분산 $\sigma_{k,i}^2$ 를 ML 방법을 이용하여 다음과 같이 구한다.

$$\sigma_{k,i}^2 = \frac{1}{c_i(k)} \sum_{m \in c_i(k)} y_m^2 \quad (11)$$

식 (11)에서 계산한 분산에 대하여 영역 $R_{k,g}$ 와 $R_{k,g+1}$ 의 분산의 동질성 척도 $H_{k,g}^j$ 를 다음과 같이 정의한다. 즉,

$$H_{k,g}^j = \frac{(\sigma_{k,g+1}^j)^2 - (\sigma_{k,g}^j)^2}{(\sigma_{k,g}^j)^2} \quad (12)$$

만약 현재의 영역이 $R_{k,g}$ 이고, $H_{k,g}^j \leq T_k^j$ 이면 영역 $R_{k,g}$ 와 $R_{k,g+1}$ 은 서로 동질성을 가진다고 판단을 하고 분산을 구하기 위한 영역은 $R_{k,g+1}$ 로 확장된다. $H_{k,g}^j > T_k^j$ 인 경우는 $R_{k,g}$ 와 $R_{k,g+1}$ 은 정재적 특성을 보장하지 못하기 때문에 분산을 구하기 위한 영역은

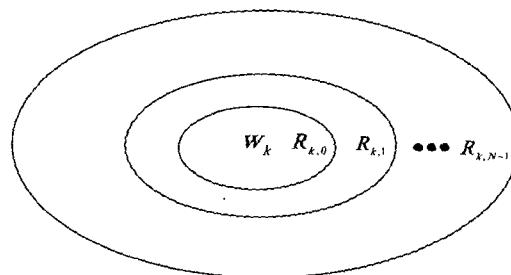


그림 2. 분산을 추정하기 위한 영역의 설정.

Fig. 2. The modeling of region for estimating variance.

$R_{k,g}$ 확정된다. 본 논문에서 제안하는 영역 확장을 이용한 분산을 결정 방법을 정리하면 다음과 같다.

Step 1 : $g = 1, (\sigma_k^j)^2 = (\sigma_{k,1}^j)^2 - \sigma_n^2$

Step 2 : $H_{k,g}^j$ 계산

Step 3 :

if $H_{k,g}^j \leq T_k^j, (\sigma_k^j)^2 = (\sigma_{k,g+1}^j)^2 - \sigma_n^2$

$g \leftarrow g + 1$, goto Step 2

else $(\sigma_k^j)^2 = (\sigma_{k,g}^j)^2 - \sigma_n^2$, goto Step 4

Step 4: end

동질성을 판단하기 위한 T_k^j 는 웨이블릿 변환의 스케일 j 를 고려하여 다음과 같이 두었다.

$$T_k^j = a \cdot 2^{j-1}, j = 1, 2, \dots, J \quad (13)$$

위의 방법에 의하여 $(\sigma_k^j)^2$ 를 결정하고, 식 (8)에 의해서 잡음을 제거할 수 있다.

IV. 모의실험 결과

제안된 영상 잡음 제거 방법을 이용하여 표준 영상 (Lena, Barbara:8bpp)에 대하여 Daubechies 8-탭 직교 웨이블릿 필터(D8)로 5번의 웨이블릿 변환 ($J = 5$)을 하여 모의실험을 하였다. 가우스 백색 잡음은 MATLAB의 randn 함수를 사용하여 $\sigma_n = 10, 15, 20, 25$ 만큼 생성하였다. 분산을 추정하기 위한 영역은 4개 ($G = 4$)로 설정하였으며, 분산의 동질성을 판단하기 위한 문턱값의 계수를 $a = 0.1$ 으로 설정하였다. 실질적인 잡음 제거를 위해서는 영역의 설정을 정방형으로 하는 것이 계산량의 측면에서 유리하다. 따라서 본 논문에서는 영역의 형태를 그림 3과 같이 $3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9$ 로 정방형으로 설정하였다. 영역의 크기는 $11 \times 11, 13 \times 13$ 등으로 계속 크게 설정할 수 있지만, 계산량을 고려하여 본 논문에서는 9×9 까지 설정하였다.

표 1은 Lena 영상에 대하여 제안 방법과 다양한 잡음 제거 방법을 비교한 결과를 나타낸다. 표 1에서 보면 제안 방법의 결과가 잡음의 강도가 적을 경우 다른 방법의 결과 보다 우수함을 알 수 있다. 그러나 잡음이 많이 첨가된 경우에는 Bivariate^[8] 방법보다 약 0.1dB 정도 PSNR이 떨어짐을 알 수 있다. Bivariate 방법은

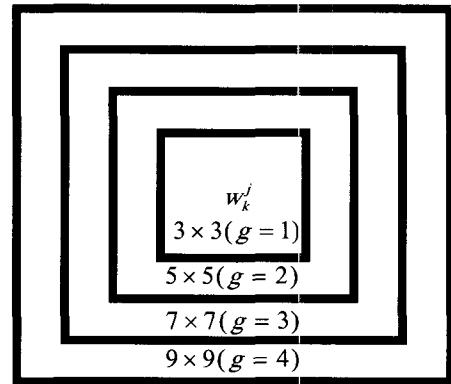


그림 3. 분산을 결정하기 위한 정방형 영역.

Fig. 3. The rectangular region for determining variance.

표 1. 다양한 잡음 제거 방법 및 잡음 강도에 대한 잡음 제거된 Lena 영상의 PSNR 값.

Table 1. PSNR values of denoised Lena image for different denoising methods and noise levels.

PSNR/ σ_n	10	.15	20	25
	28.13dB	24.61dB	22.11dB	20.17dB
LAWML[1]	34.18	32.11	30.65	29.50
LAWMAP[1]	34.32	32.33	30.90	29.80
Bivariate[12]	34.23	32.32	31.04	29.92
Cai[14]	34.22	32.23	30.85	29.79
제안방법	34.41	32.38	30.95	29.83

웨이블릿 계수에 대한 통계 모델을 두개의 랜덤 변수로 모델링한 것으로 웨이블릿 계수의 부모-자식 관계를 이용한 경우이다. 본 논문의 방법을 Bivariate 모델에 적용하면 보다 나은 결과를 얻을 수 있을 것으로 생각된다.

그림 4는 $\sigma_n = 10$ 때, Lena 영상의 분산을 추정하기 위한 영역을 보여준다. 그림 4에서 하얀색이 그 영역에서 분산을 구하기 위한 이웃의 크기를 결정한 것이다. 웨이블릿 변환은 대부분 계수가 작은 값을 갖고, 예지 또는 텍스쳐를 표현하는 적은 수의 계수만이 큰 값을 가진다. 그림 4에서 볼 수 있는 바와 같이 대부분의 영역이 9×9 에 속하는 것을 볼 수 있다.

표 2는 Barbara 영상에 대하여 제안 방법과 다양한 잡음 제거 방법을 비교한 결과를 나타낸다. Lean 영상과 마찬가지로 Barbara 영상에 대해서도 제안 방법의 결과가 다른 방법의 결과 보다 우수함을 알 수 있다.

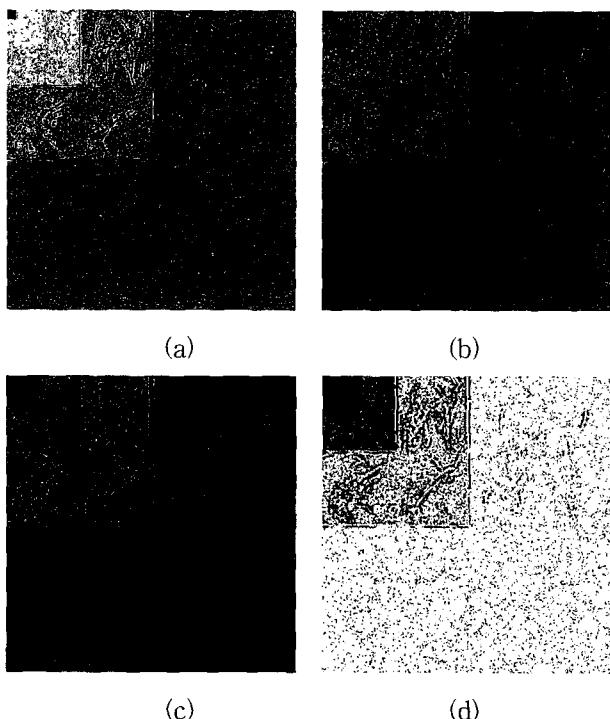


그림 4. $\sigma_n = 10$ 일 때 Lena 영상의 분산을 추정하기 위한 정방형 이웃 영역 (a) 3×3 , (b) 5×5 , (c) 7×7 , (d) 9×9 .

Fig. 4. The rectangular regions for estimating variances of Lena image when $\sigma_n = 10$ (a) 3×3 , (b) 5×5 , (c) 7×7 , (d) 9×9 .

표 2. 다양한 잡음 제거 방법 및 잡음 강도에 대한 잡음 제거된 Barbara 영상의 PSNR 값.

Table 2. PSNR values of denoised Barbara image for difference denoising methods and noise levels.

PSNR/ σ_n	10	15	20	25
	28.13dB	24.60dB	22.11dB	20.17dB
LAWML[1]	32.50	30.10	28.50	27.26
LAWMAP[1]	32.60	30.19	28.53	27.24
Bivariate[8]	32.36	29.94	28.30	27.07
Cai[9]	-	-	-	-
제안방법	32.64	30.25	28.64	27.41

Barbara 영상은 복잡한 에지 및 텍스쳐 성분을 많이 포함하고 있다. 그러므로 영상의 특성에 따라 가변적으로 이웃 계수의 개수를 적용한 경우 잡음의 크기에 관계없이 성능이 개선되었음을 알 수 있다.

그림 5는 $\sigma_n = 20$ 일 때 Barbara 영상에 대한 실험 결과이다. 그림에서 볼 수 있는 바와 같이 제안 방법의

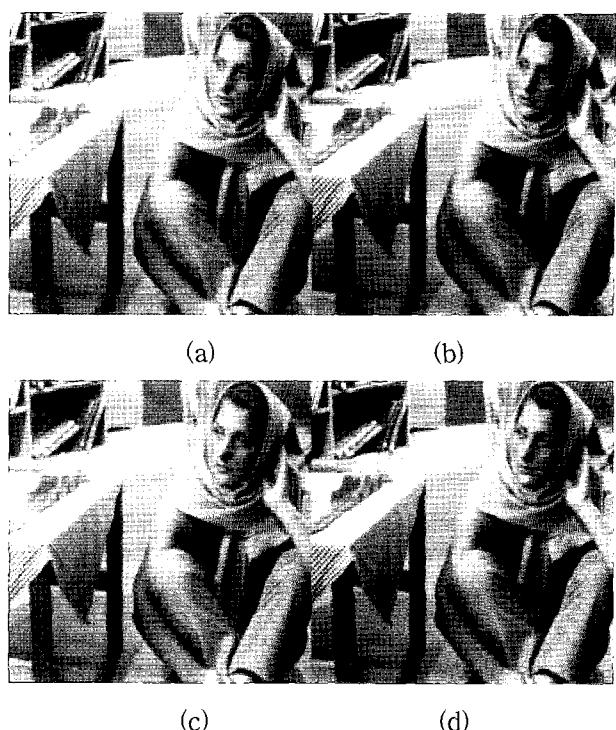


그림 5. $\sigma_n = 20$ 일 때의 기존 방법과 제안 방법의 잡음 제거 결과 (a) LAWML (28.50dB), (b) LAWMAP (28.53dB), (c) Bivariate (28.30dB), (d) 제안방법 (28.64dB).

Fig. 5. Denoising results of conventional methods and the proposed method when $\sigma_n = 20$ (a) LAWML (28.50dB), (b) LAWMAP (28.53dB), (c) Bivariate (28.30dB), (d) the proposed method (28.64dB).

결과가 영상의 영역에 따라 보다 정확을 분산을 추정하였기 때문에 특히 에지 부분에 대하여 우수한 결과를 보이고 있다.

V. 결 론

본 논문에서는 웨이블릿 영역에서 영역 확장 방법을 이용하여 분산을 추정하기 위한 이웃 계수의 수를 가변시키는 방법을 제안하였다. 분산 추정을 위한 이웃 영역은 정방형으로 설정하였으며, 분산의 동질성 척도를 정의하여 원 신호의 분산을 구하기 위한 웨이블릿 계수의 영역을 결정하였다. 잡은 제거는 일반적인 Byes 잡음 제거 방법을 사용하였다. 제안 방법은 영상의 영역적 특성에 따라 정재적 특성을 유지하도록 웨이블릿 계수의 영역을 결정하기 때문에 기존의 잡음 제거 방법들과 비교하여 우수한 잡음 제거 성능을 나타내었다.

참 고 문 헌

- [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, 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] 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.
- [5] 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.
- [6] 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.
- [7] 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.
- [8] L. Sendur and I. W. Selesnick, "Bivariate shrinkage with local variance estimation," IEEE Signal Processing Letters, vol.9, no.12, pp.438 -441, 2002.
- [9] Z. Cai, T. H. Cheng, C. Lu, and K. R. Subramanian, "Efficient wavelet based image denoising algorithm," Electron. Lett., vol. 37, no.11, pp.683-685, 2001.

저 자 소 개



엄 일 규(정회원)

1990년 부산대학교 전자공학과
학사 졸업.

1992년 부산대학교 전자공학과
석사 졸업.

1998년 부산대학교 전자공학과
박사 졸업.

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

김 유 신(정회원)

전자공학회논문지 제 41권 SP편 제4호 참조