

웨이블릿 계수의 혼합 모델링을 이용한 영상 잡음 제거

정희원 엄 일 규*, 우동현**, 김유신**

Image Denoising via Mixture Modeling of Wavelet Coefficients

Il-Kyu Eom*, Dong-Heon Woo**, Yoo-Shin Kim** *Regular Members*

요약

영상 잡음의 제거를 위해서는 영상에 대한 통계적 모델을 설정하고, 잡음이 섞인 영상에서 원 영상의 분산을 정확하게 추정하는 것이 매우 중요하다. 추정된 원 영상의 분산을 이용하여 잡음 영상에 Wiener 필터를 적용함으로써 영상의 잡음을 제거하는 것이 일반적이다. 본 논문에서는 영상의 잡음을 제거하기 위해 웨이블릿 계수의 새로운 통계적 혼합 모델링을 제안한다. 먼저 웨이블릿 계수의 중요한 특성을 획득할 수 있는 중요도(重要圖)를 작성하기 위해 간단한 분류 방법을 사용한다. 분류된 중요도에 혼합 모델의 상태 확률을 계산하고 이를 이용하여 신호의 분산을 추정한다. 실험 결과를 통하여 제안 방법이 기존의 방법보다 0.1-0.2dB 정도 높은 PSNR을 보여준다는 것을 알 수 있다.

Keyword : denoising, wavelet transform, significance map, Wiener filter, mixture model

ABSTRACT

It is very important to construct statistical model in order to exactly estimate the signal variance from the noisy image. 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 statistical mixture modeling of wavelet coefficients for image denoising. Firstly, a simple classification method is used to construct a significance map that captures significant property of wavelet coefficients. Based upon the significance map, the state probabilities of mixture model is computed, and signal variance is estimated by using them. Experimental results show that the proposed method yields 0.1-0.2dB higher PSNR than conventional methods for image denoising.

I. 서론

웨이블릿 변환은 실세계의 신호를 포함하는 많은 응용 분야에 강력한 정보를 제공하고 있기 때문에 통계 신호처리 및 영상 처리를 위해 웨이블릿 변환을 일반적으로 사용하고 있다. 웨이블릿 변환은 특히 영상의 잡음 제거를 위한 강력한 도구로 사용되고 있다. 영상 잡음의 제거를 위해서는 영상에 대한 통계적 모델을 설정하고, 잡음이 섞인 영상에서 원

영상의 분산을 정확하게 추정하는 것이 중요하다. 원 영상 신호의 분산을 추정하기 위한 방법으로는 ML(maximum likelihood)^[1-4], MAP(maximum a posteriori)^[1-2], HMM(hidden Markov model)^[5-8] 등이 있다. 추정된 원 영상의 분산을 이용하여 잡음 영상에 Wiener 필터를 적용함으로써 영상의 잡음을 제거하는 것이 일반적이다.

웨이블릿 계수에 대하여 단순히 ML 및 MAP 방법을 이용하여 잡음 제거를 한 방법 및 이웃 영역의 웨이블릿 계수에 대한 적절한 가중치를 부여함

* 밀양대학교 정보통신공학과(ikeom@mnu.ac.kr), ** 부산대학교 전자공학과(kimys@pusan.ac.kr)
논문번호 : 020482-1111, 접수일자 : 2002년 11월 12일

으로써 신호의 분산을 추정하는데 이웃 영역 계수의 기여도를 달리하는 방법^[2]도 보고 되고 있다. 원 신호의 분산을 구하기 위한 웨이블릿 계수의 이웃 영역을 적응적으로 계산하는 방법^[3]은 잡음 제거의 성능은 좋아지는 반면 계산량이 많은 단점이 있다. 웨이블릿 계수를 분류하고 분류된 웨이블릿 계수에 대하여 각각 MAP 및 ML을 적용하여 신호의 분산을 구하는 방법^[4]도 보고 되고 있다.

HMM을 이용한 잡음 제거 방법은 주로 가우스 혼합 모델을 사용하여 신호의 분산을 추정한다. 그러나 EM(Expectation Maximization) 알고리듬을 사용하여 신호의 분산을 추정하기 때문에 계산량이 많다. 웨이블릿 계수의 부모-자식의 상관관계를 이용한 HMT(Hidden Markov tree) 모델^[5-6, 8], 복소수 웨이블릿 변환과 HMM을 결합한 방법^[7] 등이 알려져 있다.

일반적으로 웨이블릿 계수의 확률밀도 함수는 영 근처에서 피크를 가지면 꼬리가 무거운 비-가우스 확률밀도 함수로 볼 수 있다. 또한 웨이블릿 계수는 작은 값을 가지는 아주 많은 계수와 큰 값을 가지는 적은 수의 계수를 가지고 있다. 즉, 큰 값을 가지는 적은 수의 웨이블릿 계수에 거의 대부분의 중요한 정보들이 포함되어 있다. 혼합 모델은 웨이블릿 계수의 이러한 특성을 나타낼 수 있다. 본 논문에서는 먼저 웨이블릿 계수의 확률적 특성을 추정하기 위하여 웨이블릿 계수가 혼합 모델을 가진다고 정의한다. 그리고 적절한 문턱값을 이용하여 중요한 정보를 가지는 웨이블릿 계수와 중요하지 않은 웨이블릿 계수를 분류하여 중요도(significance map)를 생성한다. 생성된 중요도를 이용하여 원 신호의 분산을 추정하는 방법을 제안한다. 제안된 방법은 간단하면서도 ML, MAP 및 HMM을 이용한 잡음 제거 방법들과 비교하여 경쟁적인 성능을 나타내고 있다.

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

II. 웨이블릿 변환을 이용한 잡음 제거 방법

잡음 영상은 다음과 같이 모델링될 수 있다. 즉,

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

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

$$X^{(s, o)}[i, j] = S^{(s, o)}[i, j] + E^{(s, o)}[i, j], \quad j = 1, \dots, N/2^s \quad (2)$$

여기서 $s = (1, 2, \dots)$ 는 웨이블릿 변환 스케일을 나타내고, $o \in \{LL, HL, LH, HH\}$ 는 방향을 나타낸다.

영상에 대한 웨이블릿 계수는 평균이 영이고, 독립적이고 동일하게 분포된 확률 모델에 의한 랜덤 변수라 볼 수 있다. 분산의 추정을 위해서는 일반적으로 웨이블릿 계수가 국부적으로 독립적이고 동일하게 분포한다고 본다. ML 방법에 의한 웨이블릿 계수의 분산, $\hat{\sigma}^2[i, j]$ 은 주어진 잡음에 대하여 다음과 같이 추정할 수 있다.

$$\hat{\sigma}^2[i, j] = \arg \max_{\sigma^2 \geq 0} \prod_{k, l \in M[i, j]} f(X[k, l] | \sigma^2) \quad (3)$$

여기서 $M[i, j]$ 는 $X[i, j]$ 의 이웃 영역에 포함된 웨이블릿 계수들을 나타내고, $f(\cdot | \sigma^2)$ 는 평균이 영이고, 분산이 σ^2 인 가우스 확률 밀도 함수이다. MAP에 의한 분산 추정 방법은 다음과 같다.

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

여기서 $f_d(\sigma^2)$ 는 *a priori* 밀도 함수이다. ML 및 MAP 방법에 대한 Wiener 필터, $H[i, j]$ 는 잡음의 분산이 σ_n^2 일 때 다음과 같이 구할 수 있다.

$$H[i, j] = \frac{\hat{\sigma}^2[i, j]}{\hat{\sigma}^2[i, j] + \sigma_n^2} \quad (5)$$

III. 제안 방법

3.1 웨이블릿 계수의 분류 - 중요도의 작성

웨이블릿 계수는 작은 값을 가지는 아주 많은 계수와 큰 값을 가지는 적은 수의 계수를 가지고 있다. 즉, 큰 값을 가지는 적은 수의 웨이블릿 계수에 거의 대부분의 중요한 정보들이 포함되어 있다. 그러므로 웨이블릿 계수를 두 개의 영역으로 나누어 통계적 특성을 이용하는 것이 효과적이라 볼 수 있다. 본 논문에서는 문턱값을 이용하여 중요한 정보를 가지는 웨이블릿 계수와 중요하지 않은 웨이블릿 계수를 분류한다. 문턱값 $T[i, j]$ 는 가우스 배색 잡음의 분산 σ_n^2 와 신호의 분산 $\sigma_s^2[i, j]$ 을 이용하여 다음과 같이 구한다^[2].

$$T[i, j] = \frac{\sigma_n^2}{\sigma_s^2[i, j]} \quad (6)$$

잡음 환경에서 신호의 분산을 정확하게 측정하기는 어렵기 때문에 실제적으로는 $X[i, j]$ 의 이웃 영역 $M[i, j]$ 에서 ML 방법을 사용하여 추정된 신호의 분산을 사용하는 것이 일반적인 방법이다. 추정된 신호의 분산 $\hat{\sigma}_s^2$ 는 다음과 같다.

$$\hat{\sigma}_s^2[i, j] = \max \left(\frac{1}{|M[i, j]|} \sum_{X[k, l] \in M[i, j]} X[k, l]^2 - \sigma_n^2, 0 \right) \quad (7)$$

여기서 $|M[i, j]|$ 는 이웃 영역에 포함되는 웨이블릿 계수의 수를 나타내며 웨이블릿 계수는 가우스 분포를 가진다고 가정한다. 식(7)에 의하여 추정된 문턱값을 다음과 같이 다시 정의할 수 있다.

$$T[i, j] = \frac{\sigma_n^2}{\hat{\sigma}_s^2[i, j]} \quad (8)$$

식 (8)에 의해 웨이블릿 계수에 대한 중요도 $M[i, j]$ 는 다음과 같이 구할 수 있다.

$$M[i, j] = \begin{cases} 1 & \text{if } X[i, j] \geq T[i, j] \\ 0 & \text{otherwise} \end{cases} \quad (9)$$

그림 1은 웨이블릿 영역에서 Lena 영상에 대한 중요도를 나타낸다. 흰색은 $M[i, j] = 1$ 인 웨이블릿 계수를 나타내고 검은색은 $M[i, j] = 0$ 인 웨이블릿 계수를 나타낸다. 그림에서 볼 수 있듯이 중요도는 영상의 중요한 정보를 포함하고 있다.

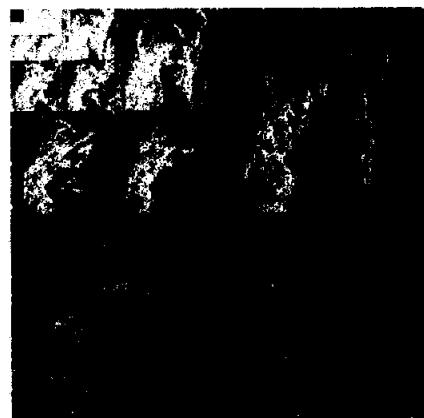


그림 1 Lena 영상에 대한 중요도

Figure 1. The significance map for Lena image.

3.2 웨이블릿 계수의 혼합 모델

생성된 중요도에 의해 웨이블릿 계수 $X[i, j]$ 는 다음과 같이 $X_{sig}[i, j]$ 와 $X_{insig}[i, j]$ 로 분류될 수 있다.

$$X[i, j] = \begin{cases} X_{sig}[i, j] & \text{if } M[i, j] = 1 \\ X_{insig}[i, j] & \text{if } M[i, j] = 0 \end{cases} \quad (10)$$

$X_{sig}[i, j]$ 및 $X_{insig}[i, j]$ 는 평균이 영이고 분산이 각각 σ_{sig}^2 , σ_{insig}^2 인 가우스 분포를 가진다고 가정한다. 본 논문에서는 웨이블릿 계수가 다음과 같은 혼합된 확률밀도 함수를 가진다고 보고 분류된 웨이블릿 계수를 이용하여 다음과 같이 정의한다.

$$f_X(X) = P_{sig} \cdot \frac{1}{\sqrt{2\pi\sigma_{sig}^2}} \exp \left(-\frac{X_{sig}^2}{2\sigma_{sig}^2} \right) + P_{insig} \cdot \frac{1}{\sqrt{2\pi\sigma_{insig}^2}} \exp \left(-\frac{X_{insig}^2}{2\pi\sigma_{insig}^2} \right) \quad (11)$$

여기서 $P_{sig}[i, j]$ 및 $P_{insig}[i, j]$ 는 주어진 영역에서 웨이블릿 계수 $X[i, j]$ 가 $X_{sig}[i, j]$ 또는 $X_{insig}[i, j]$ 일 확률을 나타낸다.

분류된 웨이블릿 계수에 대한 분산을 계산하기 위하여 먼저 $X[i, j]$ 에 대한 이웃 영역, $M[i, j]$ 를 정의한다. 이웃 영역은 정방형의 모양, 즉 $M \times M$ 마스크의 형태를 가지며 이웃 영역의 수는 $|M[i, j]| = M^2$ 이라고 가진다고 가정한다. 이웃 영역 또한 중요도 $M[i, j]$ 에 의하여 $N_{sig}[i, j]$, $N_{insig}[i, j]$ 로 나누어진다. 즉,

$$\begin{aligned} N_{sig}[i, j] &= \{X[k, l] \mid M[k, l] = 1\} \\ N_{insig}[i, j] &= \{X[k, l] \mid M[k, l] = 0\} \end{aligned} \quad (12)$$

식 (12)에서 $k = -|M/2| + i, \dots, |M/2| + i$, $l = -|M/2| + j, \dots, |M/2| + j$ 이다.

따라서 $\widehat{\sigma}_{sig}^2[i, j]$ 와 $\widehat{\sigma}_{insig}^2[i, j]$ 는 ML 방법을 이용하여 각각 다음과 같이 계산할 수 있다.

$$\begin{aligned} \widehat{\sigma}_{sig}^2[i, j] &= \\ \max \left(\frac{1}{|N_{sig}|} \sum_{X[k, l] \in N_{sig}[i, j]} X[k, l]^2 - \sigma_n^2, 0 \right) & \end{aligned} \quad (13a)$$

$$\begin{aligned} \widehat{\sigma}_{insig}^2[i, j] &= \\ \max \left(\frac{1}{|N_{insig}|} \sum_{X[k, l] \in N_{insig}[i, j]} X[k, l]^2 - \sigma_n^2, 0 \right) & \end{aligned} \quad (13b)$$

$M[i, j]$ 를 이용하여 웨이블릿 계수가 중요한 계수일 확률은 다음과 같이 간단하게 구할 수 있다.

$$\begin{aligned} P_{sig}[i, j] &= \frac{1}{|M[i, j]|} \sum_{k, l} M[k, l], \\ P_{insig}[i, j] &= 1 - P_{sig}[i, j] \end{aligned} \quad (14)$$

그림 2는 웨이블릿 영역에서 P_{sig} 의 값을 나타내고 있다. 각 확률값은 0에서 255로 선형적으로 확장되었다. 그림 2에서 볼 수 있듯이 P_{sig} 값은 신호 영역에서 크게 나타나며, 잡음이 생긴 부분에서는 작게 나타낼 수 있다.



그림 2. Lena 영상에 대한 P_{sig} 값(0에서 255로 선형적으로 확장).

Figure 2. P_{sig} value for Lena(linearly scaled from 0 to 255)

식 (13-14)에서 구한 분산과 확률에 의해서 다음과 같이 Wiener 필터를 정의할 수 있다.

$$\begin{aligned} H[i, j] &= P_{sig} \cdot \frac{\widehat{\sigma}_{sig}^2[i, j]}{(\widehat{\sigma}_{sig}^2[i, j] + \sigma_n^2)} \\ &+ P_{insig} \cdot \frac{\widehat{\sigma}_{insig}^2[i, j]}{(\widehat{\sigma}_{insig}^2[i, j] + \sigma_n^2)} \end{aligned} \quad (15)$$

본 논문에서 제안한 필터는 HMM 잡음 제거 방법에서 기우스 혼합 모델에 의한 필터와 동일한 형태를 가진다. 그리고 ML 및 MAP 방법보다 정교하면서 HMM 방법보다 계산량이 적고, 잡음 제거 결과 또한 우수하게 나타난다. 그럼 3은 제안한 잡음 제거 방법의 블록도이다.

IV. 실험 및 결과

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

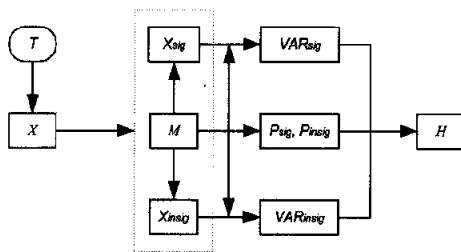


그림 3. 제안한 잡음 제거 방법의 블록도
Figure 3. The block diagram of the proposed denoising method.

표 1과 2는 각각 Lena 및 Barbara 영상에 대하여 신호의 분산을 추정하기 위하여 이웃 영역을 정방형으로 설정한 경우의 결과를 나타낸다. 표에서 SAWT는 이웃 웨이블릿 계수의 기중치를 최소 자승법으로 구하여 ML을 적용한 경우이고, MAP는 5×5 마스크에 대하여 MAP를 적용한 경우이다. AML은 부트스트랩 알고리듬을 이용하여 각 웨이블릿 계수에 대하여 적응적 마스크 크기를 적용한 경우이고, HMT는 HMT 모델을 이용한 경우이다. CHMT는 복소수 웨이블릿 변환과 HMT를 결합한 방법이고, SSM은 웨이블릿 계수에 대하여 ML 및 MAP를 혼합적으로 적용한 방법이다. 제안방법(1)은 고정된 마스크 크기(5×5)를 사용한 경우이고, 제안방법(2)은 웨이블릿 영역에서 부랜드별로 마스크의 크기를 달리한 경우이다. 표 1에서 볼 수 있듯이, 제안한 방법의 성능이 다른 방법에 비하여 우수함을 알 수 있다.

표 1. 다양한 잡음 제거 방법에 대한 Lena 영상의 PSNR 결과(정방형 마스크).
Table 1. PSNR results of several denoising methods for Lena image(square mask).

PSNR/ σ_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]	34.18	32.13	30.65	29.46
HMT[8]	33.9	31.8	30.4	29.5
CHMT[7]	34.9	-	-	29.9
SSM[4]	34.8	32.5	-	-
제안방법(1)	34.48	32.56	31.11	30.03
제안방법(2)	34.52	32.61	31.13	30.06

영상에 대하여 웨이블릿 변환을 수행하면 변환된

영상은 각각 수직, 수평 및 대각 영역으로 나누어진다. 각 변환 영역에서 중요한 웨이블릿 계수는 방향성을 띠고 있다고 볼 수 있다. 따라서 신호의 분산을 추정하기 위하여 이웃 영역을 웨이블릿 변환 영역의 방향성을 따르도록 하는 것이 효율적이다. 본 논문에서는 비정방형 마스크를 사용하여 신호의 분산을 추정하는 방법을 사용한다. 그림 4는 각 방향에 대한 비정방형 마스크를 나타낸다. 그림에서 볼 수 있듯이 수직 예지 및 수평 예지가 있는 영역에서는 각각 수직 및 수평 마스크를 사용하고, 대각 영역에서는 정방형 마스크를 사용한다.

표 2. 다양한 잡음 제거 방법에 대한 Barbara 영상의 PSNR 결과(정방형 마스크).
Table 1. PSNR results of several denoising methods for Barbara image(square mask).

PSNR/ σ_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(1)	32.72	30.35	28.75	27.58
제안방법(2)	32.78	30.42	28.81	27.61

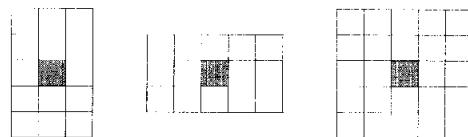


그림 4. 왼쪽 : 수직방향 예지 영역의 마스크, 중간 : 수평 방향 예지 영역의 마스크, 오른쪽 : 대각 방향 예지 영역의 마스크

Figure 4. Left : mask for the region of vertical edge, middle : mask for the region of horizontal edge, right : mask for the region of diagonal edge.

표 3 및 4는 각각 Lena 및 Barbara 영상에 대하여 신호의 분산을 추정하기 위하여 이웃 영역을 비정방형으로 설정한 경우의 결과를 나타낸다. 제안방법(3)은 수직, 수평 및 대각 방향으로 각각 고정된 마스크 크기 3×5 , 5×3 및 5×5 를 사용한 경우이고, 제안방법(4)은 웨이블릿 영역에서 부랜드별로 마스크의 크기를 달리한 경우이다. 표 1, 3의 결과와 마찬가지로 표 3, 4의 결과도 제안한 방법의 성능이 다른 방법에 비하여 우수함을 알 수 있다.

표 3. 다양한 잡음 제거 방법에 대한 Lena 영상의 PSNR 결과(비-정방형 마스크).

Table 1. PSNR results of several denoising methods for Lena image(non-square mask).

PSNR/ σ_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]	34.18	32.13	30.65	29.46
HMT[8]	33.9	31.8	30.4	29.5
CHMT[7]	34.9	-	-	29.9
SSM[4]	34.8	32.5	-	-
제안방법(3)	34.51	32.55	31.07	29.95
제안방법(4)	34.54	32.67	31.25	30.21

표 4. 다양한 잡음 제거 방법에 대한 Barbara 영상의 PSNR 결과(비-정방형 마스크).

Table 1. PSNR results of several denoising methods for Barbara image(non-square mask).

PSNR/ σ_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(3)	32.75	30.36	28.74	27.55
제안방법(4)	32.73	30.39	28.82	27.64

고주파 성분이 비교적 적은 Lena 영상의 경우에는 비정방형 마스크를 사용한 방법이 더 우수한 결과를 나타내고 있고, 고주파 성분이 많은 Barbara 영상의 경우에는 거의 비슷한 결과를 보여 주고 있다. 가우스 백색 잡음이 무작위적으로 발생하므로 표의 PSNR 결과에서 소수점 둘째 자리는 의미가 없는 것으로 보고 반올림하여 처리할 수 있다. 그럼 5는 Lena 영상에 대하여 $\sigma_n = 20$ 일 때 제안방법 (4)의 결과이다.

V. 결 론

본 논문에서는 문턱값을 이용하여 중요한 정보를 가지는 웨이블릿 계수와 중요하지 않은 웨이블릿 계수를 분류하여 중요도(Significance map)를 생성하였다. 그리고 생성된 중요도를 이용하여 웨이블릿 계수에 대하여 통계적 혼합 모델을 적용하여 신호의 분산을 추정하는 방법을 제안하였다. 본 논문에

서 영상 잡음 성능을 측정하기 위해서 정방형 고정 마스크와 웨이블릿 계수의 방향성에 따라 비정방형 마스크를 사용하였다. 정방형 고정 마스크를 사용한 경우는 대부분 기존의 방법보다 0.1dB 정도의 PSNR 개선이 있었고, 고정 마스크를 부랜드별로 딜리한 경우 0.05dB 미만의 조금의 성능 개선이 있었다. 또한 고주파 성분이 적은 Lena 영상의 경우에는 비정방형 마스크를 사용한 방법이 조금 더 우수한 결과를 나타내고 있고, 고주파 성분이 많은 Barbara 영상의 경우에는 거의 비슷한 결과를 보여 주고 있다. 위의 결과를 볼 때 혼합 모델링을 사용한 제안 방법은 HMM 잡음 제거 방법에서 가우스 혼합 모델에 의한 필터와 동일한 형태를 가지며, ML 및 MAP 방법보다 정교하고, HMM 방법보다 계산량이 적으면서 비교적 우수한 결과를 나타내고 있다.

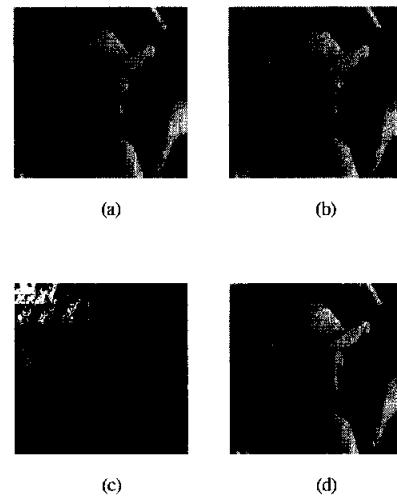


그림 5. (a) 원 영상, (b) 잡음 영상(21.11dB), (c) 중요도 영상, (d) 잡음 제거된 영상(31.24dB).

Figure 5. (a) Original image (c) noisy image(21.11dB), (c) significance map image, (d) denoised image(31.24dB).

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," Proc. IEEE Int. Conf. Image Processing, pp.535-539 1998.
- [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.

엄 일 규(Il-Kyu Eom)



정회원

1990년 2월 : 부산대학교 전자

공학과 졸업

1992년 0월 : 부산대학교 전자

공학과 석사

1998년 2월 : 부산대학교 전자

공학과 박사

1997년 3월~현재 : 밀양대학교

정보통신공학과 부교수

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

우 동 현(Dong-Heon Woo)

정회원

한국통신학회 논문지 제27권 6A호 참조

현재 : 부산대학교 전자공학과 박사과정

김 유 신(Yoo-Shin Kim)

정회원

한국통신학회 논문지 제27권 6A호 참조

현재 : 부산대학교 전자공학과 교수