

# 압축률 대비 화질 향상을 위한 소벨 연산 기반 엣지 보존 적응적 양방향 필터

전기현<sup>\*</sup>, 오의열<sup>\*</sup>, 최윤식<sup>◦</sup>

## An Edge-Preserving Adaptive Bilateral Filter Based on Sobel Operator for Improving Image Quality Over Compression Ratio

Gi-hyeon Jeon<sup>\*</sup>, Eui-yeol Oh<sup>\*</sup>, Yoon-sik Choe<sup>◦</sup>

### 요약

디지털 이미지를 외부에서 획득함에 있어 필연적으로 잡음이 발생하게 되며 이는 압축 효율을 떨어뜨리는 요소로 작용한다. 압축 효율을 높이기 위한 방법으로 잡음은 제거하면서 시각에 민감한 엣지는 보존하기 위한 필터 개발은 이미지 처리 분야에서 시대를 불문하고 중요한 이슈였다. C. Tomasi가 제안한 양방향 필터의 경우 연산의 간결함과 필터의 효용성으로 인하여 일반적으로 사용된 필터이나 픽셀 주변 문맥을 고려하지 않고 이미지 내의 모든 픽셀에 사용자가 입력한 변수들이 일괄적으로 적용되어 해당 픽셀에 적합한 변수를 적응적으로 적용하지는 못한다는 문제점이 발생한다. 본 논문은 각 픽셀을 중심으로 소벨 연산을 이용하여 주변의 복잡도를 정의하고 이미지의 화질을 극대화하는 양방향 필터의 변수와의 관계를 함수로 추정하고 이를 통해 변수를 적응적으로 선택하는 알고리즘을 제안한다. 실험에서는 기존의 양방향 필터뿐만 아니라 개선된 성능을 보이는 다른 알고리즘들보다 제안하는 방법이 같은 압축률 대비 PSNR도 뛰어날 뿐만 아니라 엣지 부분에서는 더욱 더 뛰어난 효과가 나타남을 결과를 통해 확인할 수 있다.

**Key Words :** Image processing, Edge preserving image filtering, Compression, Bilateral filter

### ABSTRACT

In obtaining the digital image from any device, noise is inevitably generated, which reduces the compression efficiency. In order to increase the compression efficiency, the development of a filter for preserving the edge sensitive to the vision while eliminating the noise in the image processing field has been an important issue regardless of the times. Bilateral filter proposed by C. Tomasi are generally used because of its simplicity and efficiency of computation. However, parameter of bilateral filter inputted by the user are applied to all the pixels in the image without considering context around the pixels. Therefore, there is a problem that it is not possible to adaptively apply a suitable parameter to the pixel. In this paper, we propose an algorithm to adaptively select a parameter by estimating the relationship between the complexity of the surroundings in using sobel operator and the parameter of the bilateral filter that maximizes the image quality. Experimental results show that the proposed method has better PSNR than the conventional bilater filter as well as other algorithms that show improved performance. Especially, proposed method has better performance at edge than others.

\* First Author : Yonsei University Dept. of Electrical & Electronic Engineering, ssjy90@yonsei.ac.kr, 학생회원

◦ Corresponding Author : Yonsei University Dept. of Electrical & Electronic Engineering, yschoe@yonsei.ac.kr, 종신회원

\* Yonsei University Dept. of Electrical & Electronic Engineering, eyoh@lgdisplay.com, 정회원

논문번호 : KICS2017-02-054, Received February 27, 2017; Revised August 28, 2017; Accepted September 4, 2017

## I. 서 론

일반적으로 이미지 데이터를 외부에서 획득함에 있어 장치내의 여러 요소 및 외부 환경 등 여러 가지 요인으로 인하여 펜던스적으로 잡음이 발생하게 된다. 이러한 잡음은 이미지의 화질을 떨어뜨릴 뿐만 아니라 이미지의 히스토그램 분포에 영향을 미치게 되어 압축 효율을 저하시키는 원인이 된다.

이러한 문제를 해결하기 위한 일반적인 방법으로 저역필터나 가우시안 필터를 이용할 경우 어느 정도 잡음을 제거하게 되어 압축률이 향상되는 효과를 볼 수 있으나 인간의 시각에 민감한 엣지 영역에 펜던스성이 발생하여 영상의 주관적인 화질을 떨어뜨리는 원인이 된다. 따라서 이와 같은 문제점을 해결하기 위하여 엣지를 보존함으로써 화질향상을 도모하고 잡음은 제거하여 압축률을 높이는 필터에 대한 다양한 연구가 진행되어 왔다.

1985년 L.P Yaroslavsky<sup>[1]</sup>는 중앙 픽셀을 중심으로 가까운 공간 안의 비슷한 grey level을 갖는 픽셀들의 평균값을 이용하는 필터를 제안하였다. 이후 1995년 Aurich 와 Weule<sup>[2]</sup>이 제안한 Non-linear Gaussian 필터가 기반이 되어 C.Tomasi가 1998년 양방향 (Bilateral) 필터를 제안하였다<sup>[3,4]</sup>. 양방향 필터의 경우 빈복연산을 하지 않으며 간단한 수식으로 표현이 가능하다는 장점으로 인하여 stereo-matching<sup>[5,6]</sup>, DIBR(Depth Image Based Rendering)<sup>[7]</sup>, demosaicing<sup>[8]</sup>, tone mapping<sup>[9]</sup>, optical-flow estimation<sup>[10]</sup> 등 다양한 분야에서 일반적으로 사용된다.

C. Tomasi이 제안한 양방향 필터의 경우 픽셀을 중심으로 두가지 커널 Spatial gaussian kernel과 Intensity gaussian kernel을 사용하는데 각 커널의 폭에 연관된 변수  $\sigma_s, \sigma_i$ 를 사용자가 선택하여 이미지의 모든 픽셀에 동일하게 적용하여 처리한다. 사용자가 임의로 변수를 선택하기 때문에 해당 이미지에 가장 최적인 변수를 적용하기 힘들다는 단점이 있으며, 일반적인 양방향 필터를 사용하여도 엣지 보존효과가 있는 것은 사실이나 이미지 내에서 평탄 영역과 엣지 영역에 동일한 변수를 적용하기 때문에 그 효과가 미미하다. 또, 픽셀을 중심으로 주변 문맥을 고려하지 않고 변수를 적용하게 되어 다음과 같은 문제가 추가적으로 발생한다. 평탄 영역에 적합한 변수를 적용할 경우 잡음이 제거 되면서 전체적인 질과 압축률이 향상되나 시각에 예민한 엣지 영역 또한 펜던스성이 두

드러지게 되어 이미지의 주관적인 질이 하락하게 된다. 반대로 엣지 영역에 적합한 변수를 적용할 경우 엣지 영역에서의 펜던스성이 적게 발생하나 평탄 영역에서 잡음 제거 효과가 감소하게 되어 압축률이 떨어지게 되고 이미지의 전체적인 질이 하락하게 된다.

기존 양방향 필터에서의 이와 같은 문제점을 해결하기 위하여 픽셀을 중심으로 주변의 문맥을 파악하고 문맥에 따라 적합한 필터를 변경하거나<sup>[11]</sup> 변수를 적응적으로 적용하는 방식이 제안되었다.

Ahn, B.Y은 분산영상에서의 캐니 엣지 검출기를 이용하여 엣지 이미지를 검출하고 중심픽셀을 기준으로 윈도우를 생성하였을 때 그 안에 엣지의 개수가 문턱치 이상 존재하면 엣지 영역으로 문턱치 이하 존재하면 평탄 영역으로 구분한다. 엣지에 가까울수록 필터링 효과를 적게 멀수록 필터링 효과를 크게 주어야 하므로 각 영역에 맞게  $\sigma_s, \sigma_i$ 를 각각 설정하고 필터링을 진행한다. 영역을 나누어 필터링을 진행하므로 기존의 양방향 필터보다 더 좋은 성과를 보여주나 캐니 엣지 검출기의 변수 및 엣지의 개수의 문턱치 그리고 각기 다른 영역이나 사진마다 최적의  $\sigma_s, \sigma_i$ 를 사용자가 직접 설정해야 하므로 변수가 기존 양방향 필터에 비해 크게 늘어나게 되며 이는 각 상황에서 최적의 변수를 찾기가 복잡해짐을 의미한다.<sup>[12]</sup>

Kim, D.H은 웨이블릿 변환을 통해 이미지를 고주파 영역과 저주파 영역으로 나누고 고주파 영역은 임계값 처리를 통하여 잡음을 제거하고 저주파 영역에서는 양방향 필터를 적용한다. 이때, 소벨 연산자를 이용하여 문턱치보다 높으면 엣지 영역으로 가정하고 낮으면 평탄 영역으로 가정한다. 각 영역에서  $\sigma_s, \sigma_i$ 를 각각 설정하여 이미지에 적용시킨다. 이 또한 소벨 연산자 결과값의 문턱치와 각기 다른 영역이나 사진마다 최적의  $\sigma_s, \sigma_i$ 를 사용자가 설정해야 하므로 변수가 기존 양방향 필터에 비해 크게 늘어나게 되며 이 또한 각 상황에서 최적의 변수를 찾기가 복잡해짐을 의미한다.<sup>[13]</sup>

본 논문에서는 주변의 문맥을 파악하기 위하여 픽셀을 중심으로 소벨 연산자를 이용하여 복잡도를 정의하고 해당 복잡도에서 이미지의 화질을 극대화시키는 양방향 필터의 변수  $\sigma_s, \sigma_i$ 를 사용자의 입력이 아닌 자동으로 적응적으로 선택하는 알고리즘을 제안하며 본 알고리즘의 성능을 타 다른 알고리즘과 비교하기 위한 실험을 진행하였다.

본 논문의 구성은 다음과 같다. II장에서는 기존의 양방향 필터에 대해서 설명하고 III장에서는 복잡도를

정의하는 방법과 해당 복잡도에 적합한  $\sigma_s, \sigma_i$ 를 적응적으로 선택하는 알고리즘을 제안하며 IV장에서는 제안한 알고리즘과 다른 알고리즘과 비교하여 실험한 결과를 나타내며 V장에서는 본 기술에 대한 결론과 추후 더 연구가 필요한 부분에 대해서 기술한다.

## II. 양방향 필터

이미지 데이터를 외부에서 얻을 경우 다양한 요인으로 인하여 잡음이 함께 이미지에 적용되어 나타난다. 이러한 잡음을 제거하기 위한 방법으로 평균값 필터(average filter), 중간값 필터(median filter), 가우시안 필터(gaussian filter) 등이 사용되어 왔다. 그러나 이러한 필터를 사용할 경우 Edge 부분에 있어서 퍼짐 현상이 뚜렷으로 생기게 되어 이미지의 주관적인 화질이 하락하게 된다. 이와 같은 문제점을 해결하기 위한 방법 중 하나로 양방향 필터가 제안되었다.

양방향 필터의 경우 크게 잡음을 제거하기 위한 목적의 spatial gaussian kernel부분과 엣지를 보존하기 위한 intensity gaussian kernel부분 두 부분으로 나누어진다. 중심 픽셀  $x$ 를 기준으로 윈도우를 구성하고 spatial gaussian kernel의 경우 중심 픽셀  $x$ 와 윈도우 내의 픽셀과의 거리 차이를 이용하고 intensity gaussian kernel의 경우 중심 픽셀  $x$ 와 윈도우 내의 픽셀과의 intensity 차이를 이용한다. 만들어진 각 kernel을 곱하여 그림 1과 같이 최종적인 kernel을 생성하고 이를 최종적으로 잡음이 첨가된 입력 이미지에 적용하여 엣지의 디테일은 보존하고 잡음은 제거한 결과 이미지를 추출해 낸다. 양방향 필터의 수식은 아래와 같다.

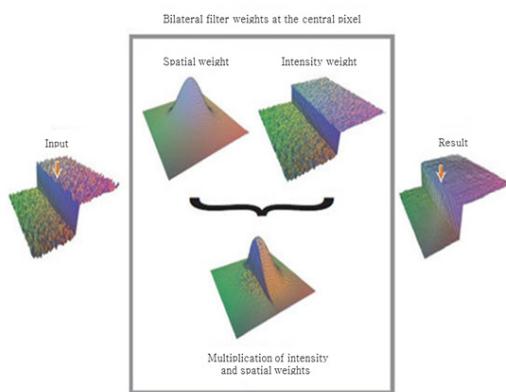


그림 1. 양방향 필터의 구동 방식  
Fig. 1. Operation process of bilateral filter

$$I(x) = \frac{\sum_{x_i \in \Omega} I(x_i) f_I(\|I(x_i) - I(x)\|) g_s(\|x_i - x\|)}{\sum_{x_i \in \Omega} f_I(\|I(x_i) - I(x)\|) g_s(\|x_i - x\|)} \quad (1)$$

수식(1)에서  $g_s$ 와  $f_I$ 는 각각 spatial gaussian kernel과 intensity gaussian kernel을 의미하며  $\Omega$ 는 윈도우 내부의 픽셀의 집합을 의미한다.

## III. 제안하는 방법

앞서 기존의 양방향 필터의 경우 spatial kernel의 폭  $\sigma_s$ 와 intensity kernel의 폭  $\sigma_i$ 를 사용자가 임의로 적용하여 모든 픽셀에 대하여 일괄적으로 처리하였다. 이는 사용자가 아무 정보도 없는 채로 변수를 선택해야 하므로 선택한 변수 자체의 적합성에 대한 문제가 제기될 뿐만 아니라 해당 픽셀에서 주변 문맥을 고려하지 않고 영역에 관계없이 일괄되게 처리함으로써 여러 가지 문제들이 발생한다.

위와 같은 문제점을 해결하기 위한 방법으로 픽셀 주변의 문맥을 파악하고 이를 토대로 최적에 가까운  $\sigma_s, \sigma_i$ 를 결정하기 위해서는 해당 문맥에서 이미지의 화질을 극대화 시키는 변수  $\sigma_s, \sigma_i$ 와의 관계를 파악할 필요가 있다.  $\sigma_s, \sigma_i$ 는 공간정보와 빛의 밝기 정보를 나타내므로 서로 독립적으로 작용한다고 가정하면 관계를 표현하기 위한 함수는 수식(2)과 같다. 여기서, 변수  $C$ 는 복잡도를 의미한다.

$$\sigma_s = f_1(C) \quad \sigma_i = f_2(C) \quad (2)$$

III-1에서는 각 픽셀 주변 문맥을 수치로 표현하기 위하여 소벨 연산자를 이용하여 복잡도  $C$ 를 정의하는 방법에 대해서 설명하고 III-2에서는 인간 시각에 예민한 엣지 영역과 잡음이 반드시 제거되어야 할 평탄 영역에서 각각의 화질 평가 방법을 제안하며 마지막 III-3에서는 해당 복잡도에서 화질을 극대화 시키는 변수  $\sigma_s, \sigma_i$ 와의 관계 함수  $f_1$ 과  $f_2$ 를 추정하기 위한 방법에 대하여 설명할 것이다.

### 3.1 복잡도(Complexity)

정의한 식(2)에 의하면 두 변수  $\sigma_s, \sigma_i$ 는 복잡도에 대한 함수로 표현된다. 평탄 영역에서는 잡음에 의한 왜곡을 최대한 많이 없애 압축률을 끌어 올리는 것이 목표이고 엣지 영역에서는 엣지 부분을 살려 주관적인 화질을 높이는 것이 목표이므로 각 영역에서의  $\sigma_s$ ,

$\sigma_i$ 는 차이를 보이게 된다. 따라서 복잡도를 정의하기 위해서는 평탄 영역과 엣지 영역을 잘 구분하게끔 설계하는 것이 중요하다.

복잡도  $C$ 를 정의하기 위하여 본 논문은 소벨 연산자를 이용하였다.  $3 \times 3$  크기의 소벨 연산자의 경우 그 크기가 너무 작아 픽셀 주변의 문맥을 파악하기엔 너무 좁아 한계가 있고 잡음에 민감하게 반응한다. 따라서 주변의 복잡도를 더 넓은 범위에서 파악하고 잡음에 의한 오차도 줄이기 위하여  $5 \times 5$  크기의 소벨 연산자를 이용하였다. 복잡도를 구하는 수식은 수식(3)과 같다.

$$C(x_i) = \sqrt{C_x^2(x_i) + C_y^2(x_i)} \quad (3)$$

$C_x(x_i), C_y(x_i)$ 는 각각  $x_i$  픽셀에서 수평 소벨 연산자, 수직 소벨 연산자를 거친 값을 의미한다.

### 3.2 영역 기반의 PSNR

잡음이 섞인 이미지 내에서는 시각에 민감하여 보존해야 할 엣지 영역과 반드시 잡음이 제거되어 할 평탄 영역으로 분류할 수 있다. 일반적으로 필터링한 영상의 질적 수준을 판단하기 위한 수치로써 PSNR이 많이 사용되나 이는 이미지 전체에 대한 수치이므로 각 영역에 대한 질적 수준을 판단하기에는 무리가 있다.

따라서 각 영역에 대한 화질을 평가를 위하여 그림 2와 같이 어떤 이미지에 대하여 ground truth격인 Edgemap을 구성하여 수식(4), (5)와 같이 엣지 영역에 대한 질적 지표인  $PSNR_{EDGE}$ 을 구한다.

$$MSE_{EDGE} = \frac{1}{N_{EDGE}} \sum_{x_i \in Edge map} [O(x_i) - F(x_i)]^2 \quad (4)$$

$$PSNR_{EDGE} = 10 \log \frac{255^2}{MSE_{EDGE}} \quad (5)$$

$N_{EDGE}$ 는 Edgemap에서 활성화된 픽셀의 개수를 의미하며,  $O$ 는 원본 이미지,  $F$ 는 필터링 후 이미지를 의미한다.

엣지 영역과 비슷하게 평탄 영역을 위한 지표  $PSNR_{FLAT}$ 는 수식(6), (7)와 같이 구한다.

$$MSE_{FLAT} = \frac{1}{N_{FLAT}} \sum_{x_i \in Edge map^c} [O(x_i) - F(x_i)]^2 \quad (6)$$

$$PSNR_{FLAT} = 10 \log \frac{255^2}{MSE_{FLAT}} \quad (7)$$

$N_{FLAT}$ 는 Edgemap에서 비활성화된 픽셀의 개수를 의미한다.

### 3.3 화질 극대화 함수 추정

픽셀 주변의 문맥에 대한 정보인 복잡도를 구하고 나면 수식(2)의 함수를 통하여 양방향 필터의 각 변수  $\sigma_s, \sigma_i$ 가 결정된다. 이때 선택된 각 변수는 해당 복잡도에서 가장 이미지의 화질을 높이는 즉 엣지 영역에서는  $PSNR_{EDGE}$ 가 가장 높고 평탄 영역에서는  $PSNR_{FLAT}$ 을 가장 높게 만들어야 한다.

화질을 극대화시키는  $\sigma_s, \sigma_i$ 를 복잡도의 함수로 표현하기 위한 전체적인 알고리즘의 흐름도는 그림 3과 같다. 함수를 추정함에 있어서 충분한 수의 학습 이미지 데이터와 이것들의 Edgemap들을 확보한다. 각각의 이미지에 대하여  $\sigma_s, \sigma_i$ 를 바꿔가며 기준의 양방향 필터를 적용하여 수식(8), (9)과 같이 엣지 영역

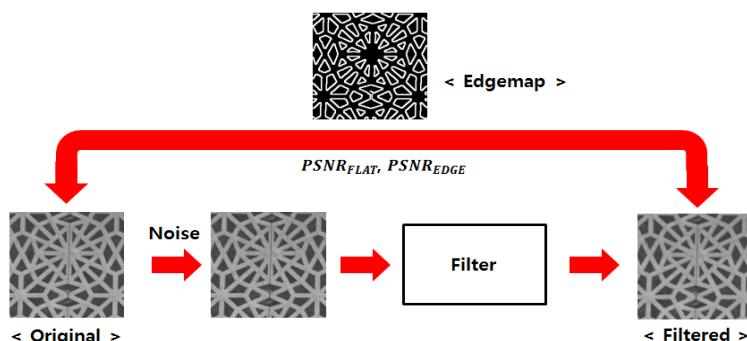


그림 2.  $PSNR_{EDGE}$ 와  $PSNR_{FLAT}$ 의 계산

Fig. 2. Calculation method of  $PSNR_{EDGE}$ ,  $PSNR_{FLAT}$

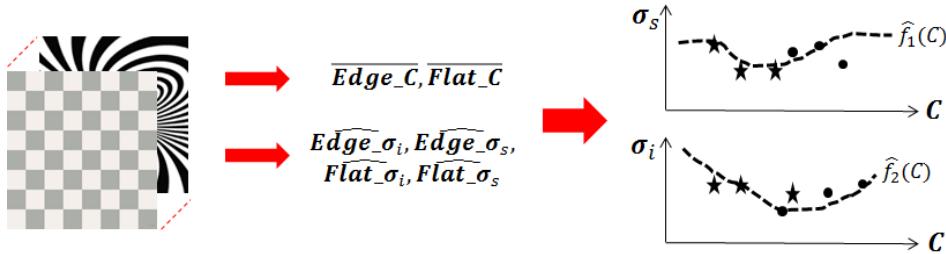


그림 3. 복잡도와  $\sigma_s, \sigma_i$  사이의 관계함수 학습 흐름도  
Fig. 3. Flow chart to train function between complexity and  $\sigma_s, \sigma_i$

에서의 화질과 평탄 영역에서의 화질이 최고가 되는 즉  $PSNR_{EDGE}$ 과  $PSNR_{FLAT}$ 을 최대로 만드는  $\widehat{EDGE}_{\sigma_s}, \widehat{EDGE}_{\sigma_i}, \widehat{FLAT}_{\sigma_s}, \widehat{FLAT}_{\sigma_i}$ 를 구한다.

$$[\widehat{EDGE}_{\sigma_s}, \widehat{EDGE}_{\sigma_i}] = \arg\max PSNR_{EDGE}(\sigma_s, \sigma_i) \quad (8)$$

$$[\widehat{FLAT}_{\sigma_s}, \widehat{FLAT}_{\sigma_i}] = \arg\max PSNR_{FLAT}(\sigma_s, \sigma_i) \quad (9)$$

어떠한 한 이미지에 대하여 엣지 영역과 평탄 영역에서  $PSNR_{EDGE}$ 와  $PSNR_{FLAT}$ 을 최대로 하는  $\sigma_s, \sigma_i$ 는 구하였으나 이는 이미지 한 장 전체를 두고 구한 것이다. 그러나 복잡도는 픽셀단위의 계산이므로 위에서 구한  $PSNR_{EDGE}$ 와  $PSNR_{FLAT}$ 을 최대로 하는  $\sigma_s, \sigma_i$ 와의 관계를 구하기는 것은 불가능하다. 이러한 문제점을 해결하기 위하여 식(10), (11)과 같이 이미지 내에서 엣지 영역과 평탄 영역의 복잡도의 평균을  $PSNR_{EDGE}$ 와  $PSNR_{FLAT}$ 을 최대로 만드는  $\sigma_s, \sigma_i$ 에 대한 복잡도의 대푯값으로 가정한다.

$$\overline{EDGE\_C} = \frac{1}{N_{EDGE}} \sum_{x_i \in Edgemap} C(x_i) \quad (10)$$

$$\overline{FLAT\_C} = \frac{1}{N_{FLAT}} \sum_{x_i \in Edgemap^c} C(x_i) \quad (11)$$

$\overline{EDGE\_C}, \overline{FLAT\_C}$ 가 각 이미지에서  $PSNR_{EDGE}$ 와  $PSNR_{FLAT}$ 을 최대로 만드는 복잡도의 대푯값으로 가정하기 위해서는 최대한 Edgemap에서 활성화된 영역과 비활성화된 영역에서 복잡도의 표준편차가 적은 이미지 데이터를 반드시 사용하여야 한다. 따라서 그림 3에서의 왼쪽 그림같이 반드시 단조로운 이미지의 데이터로 실험을 진행해야 보다 정확한 결과를 얻을 수 있다.

각 이미지에서 구한  $\overline{EDGE\_C}, \overline{FLAT\_C}$  그리고  $\widehat{EDGE}_{\sigma_s}, \widehat{EDGE}_{\sigma_i}, \widehat{FLAT}_{\sigma_s}, \widehat{FLAT}_{\sigma_i}$ 들을 복잡도와 각 변수  $\sigma_s, \sigma_i$ 에 대한 그래프 위에 표현하게 되면 그림 3의 오른쪽 그래프와 같이 나타난다. 그래프에서 동그라미 표시는 엣지 영역에서의 복잡도인  $\overline{EDGE\_C}$ 와 각 변수  $\widehat{EDGE}_{\sigma_s}, \widehat{EDGE}_{\sigma_i}$ 를 의미하고 별 표시는 평탄 영역에서의 복잡도  $\overline{FLAT\_C}$ 와 각 변수  $\widehat{FLAT}_{\sigma_s}, \widehat{FLAT}_{\sigma_i}$ 를 의미한다.

양방향 필터의 경우 화질을 보존하면서 압축률을 끌어올리기 위하여 복잡도가 높은 엣지 영역에서는 필터링의 강도를 줄이고 복잡도가 작은 평탄 영역에서는 필터링의 강도를 높이는 것이 좋다. 즉, 복잡도에 따라 각 영역에서 변수가 다르게 적용되어야 한다.  $\overline{EDGE\_C}, \overline{FLAT\_C}$ 의 경우 픽셀단위로 계산된 것이 아니고 이미지 한 장에서 구해낸 것이기 때문에 정확한 값은 아니라 단조로운 이미지의 경우 각 영역을 대표할 수 있다고 가정한다.  $\overline{EDGE\_C}, \overline{FLAT\_C}$ 와  $\widehat{EDGE}_{\sigma_s}, \widehat{EDGE}_{\sigma_i}, \widehat{FLAT}_{\sigma_s}, \widehat{FLAT}_{\sigma_i}$ 를 그래프 위에 띄우고 개략적인 추세가 파악될 경우 그래프 위에 생성된 점들을 이용, 여러 가지 회귀(Regression)방법을 통하여 복잡도와 변수  $\sigma_s, \sigma_i$  사이의 함수  $\widehat{f}_1$ 과  $\widehat{f}_2$ 를 그림 4와 같이 추정한다.

#### IV. 실험 결과 및 분석

제안하는 방법의 잡음 제거를 통한 압축률 대비 화질향상 성능의 검증을 위하여 화질 극대화 함수  $\widehat{f}_1$ 과  $\widehat{f}_2$ 를 구하기 위한 256 x 256 크기의 학습 이미지 45개와 그에 해당되는 Edgemap을 구성하였다. 주어진 학습이미지에 표준편차 5인 가우시안 분포를 가지는 잡음을 추가하고 Edgemap을 이용하여  $\overline{EDGE\_C}$ ,

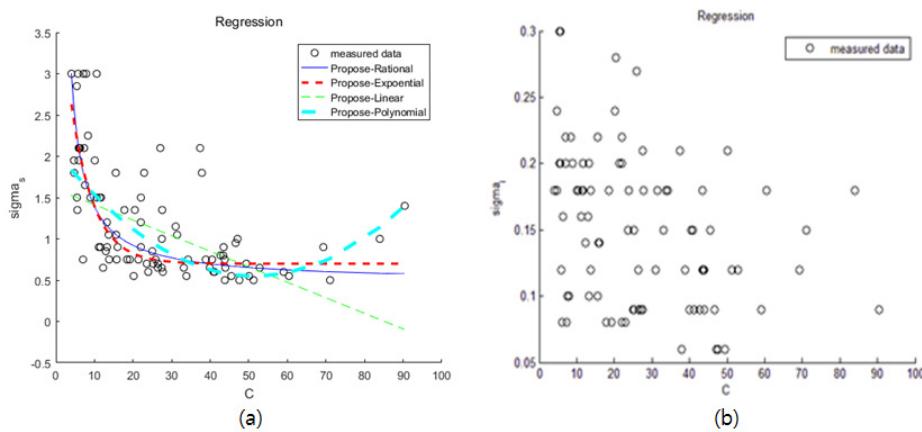
그림 4. 회귀분석을 통한 복잡도와  $\sigma_s, \sigma_i$  사이의 함수 추정 결과 (a) 복잡도와  $\sigma_s$  (b) 복잡도와  $\sigma_i$ 

Fig. 4. Estimation result of function between complexity and  $\sigma_s, \sigma_i$  using regression method (a) Complexity and  $\sigma_s$  (b) Complexity and  $\sigma_i$

$\overline{FLAT\_C}$ 를 구한다. 이미지에서  $\sigma_s, \sigma_i$ 를 변경시켜가며 이미지의 화질을 극대화 시키는 변수  $\overline{EDGE\_\sigma_s}, \overline{EDGE\_\sigma_i}, \overline{FLAT\_\sigma_s}, \overline{FLAT\_\sigma_i}$ 들을 구하고 이를 복잡도와  $\sigma_s, \sigma_i$  사이의 그래프에 그려 회귀방법을 통해  $\hat{f}_1$ 과  $\hat{f}_2$ 를 추정한다.

$\sigma_s$ 의 경우 제안하는 방법에서 주어진 조건대로 테스트를 해 본 결과 그 분포가 확연하게 눈으로 확인이 되어 분수함수, 지수함수, 선형함수, 다항함수로 MMSE(Minimum Mean Square Error)를 활용하여 회귀시켰다. 그림 4는 이에 대한 결과를 표현한 것이고 표 1은 각 회귀방법의 평균 오차를 나타낸 것이다. 회귀 분석의 평균오차가 굉장히 작고 각 방법이 편차가 크지 않아 실질적인 사용에 큰 무리가 없을 것으로 최종 판단하였다.  $\sigma_i$ 의 경우 제안하는 복잡도에서 그 분포가 무작위로 나오게 되어 함수 추정을 사용하지 않고 평균값을 이용하였다.

표 1. 회귀 분석의 평균 오차

Table 1. Average error of regression analysis

	Linear	Poly nomial	Expo nential	Rational
오차	0.1227	0.1062	0.1	0.1008

픽셀단위로 복잡도를 계산하면 앞서 회귀를 이용해 구한 추정함수를 이용하여 각 픽셀에서 이미지의 화질을 극대화 시키는  $\sigma_s$ 를 획득 할 수 있다.

타 알고리즘과 추정함수를 이용한 제안하는 알고리즘의 필터 성능을 비교하기 위하여 그림 5와 같이 512 x 512의 크기를 가진 총 5장의 테스트 이미지를 이용하였다. 테스트 이미지에 표준편차가 10인 가우시안 잡음을 추가하고 각 필터를 통과시킨 후 JPEG방식으로 압축하고 이를 원본 이미지와 비교하여 PSNR,  $PSNR_{EDGE}$ , 그리고  $PSNR_{FLAT}$ 을 구하였다.

그림 6은 Lena 이미지를 타 알고리즘과 제안하는 알고리즘을 거친 후 JPEG 압축방식에서 quality



그림 5. 성능 평가를 위한 테스트 이미지

Fig. 5. Test image for performance evaluation

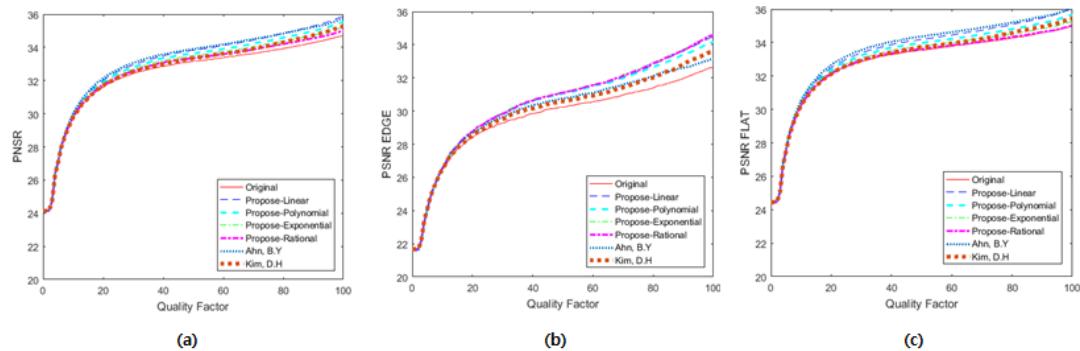


그림 6. Lena 영상의 시뮬레이션 정량적 결과 (a)JPEG quality factor와 PSNR 그래프 (b) JPEG quality factor와 PSNR<sub>EDGE</sub> 그래프 (c) JPEG quality factor와 PSNR<sub>FLAT</sub> 그래프

Fig. 6. Simulation qualitative result of lena image (a) Graph of JPEG quality factor and PSNR (b) Graph of JPEG quality factor and PSNR<sub>EDGE</sub> (c) Graph of JPEG quality factor and PSNR<sub>FLAT</sub>

factor를 바꿔가면서 얻은 PSNR, PSNR<sub>EDGE</sub>, 그리고 PSNR<sub>FLAT</sub> 그래프이다. IIG(Independent JPEG Group)에 의해 제공된 quality factor란 1-100사이의 숫자를 선택할 수 있으며 숫자가 높을수록 압축률은 낮아지고 영상의 질은 높아짐을 의미한다. 그림을 보면 JPEG의 같은 quality factor에서 제안하는 알고리즘들[1] PSNR과 PSNR<sub>EDGE</sub>, 그리고 PSNR<sub>FLAT</sub> 모두

에서 C. Tomasi가 제안한 기준의 양방향 필터를 모두 상회하는 결과를 얻을 수 있다. 특히 본 알고리즘이 시각에 예민한 엣지 부분을 보존하는것에 목적을 두고 있으므로 PSNR<sub>EDGE</sub>의 경우 PSNR에 비해 대폭 향상된 결과를 얻을 수 있으며 PSNR<sub>FLAT</sub>의 경우 PSNR<sub>EDGE</sub> 만큼의 성능 향상이 있던 것은 아니나 기존 알고리즘들에 비해서는 제안하는 알고리즘에서 소

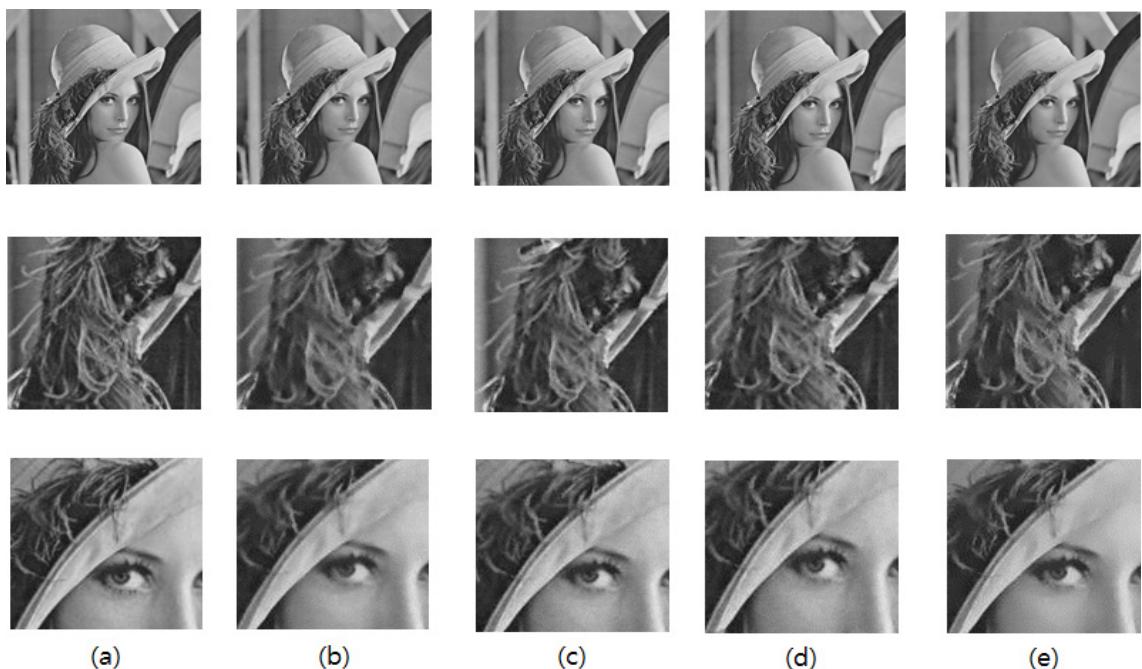


그림 7. Lena 영상의 시뮬레이션 정성적 결과 (a) 원 영상 (b) C.Tomasi (c) Ahn, B.Y (d) Kim, D.H (e) 제안하는 방법

폭 향상된 결과를 얻을 수 있다.

그림 7은 이를 정성적으로 확인하기 위하여 레나 이미지를 JPEG 방식, quality factor 70으로 하여 압축한 영상이다. 그림을 보면 C. Tomasi가 기존에 제안한 방법보다 Ahn, B.Y와 Kim, D.H가 제안한 방법이 모자의 털 부근에서 보다 더 디테일이 살아 있음을 확인할 수 있다. 본 논문의 제안하는 방법의 경우 앞선 타 알고리즘 보다 모자의 털 부근에서 퍼짐현상이 덜 발생하고 엣지가 보다 더 잘 살아있음을 눈으로 확인할 수 있다.

이를 여러 이미지로 비교하기 위하여 표 1,2,3은 총 5장의 테스트 이미지를 모두 JPEG, quality factor 70으로 하여 압축하고 이를 통해 구해지는  $PSNR$ ,  $PSNR_{EDGE}$ , 그리고  $PSNR_{FLAT}$ 을 각각 정리한 것이다.

Ahn, B.Y와 Kim, D.H이 제안한 알고리즘의 경우 각각 캐니 에지 검출기와 소벨 연산자를 이용하여 계

산된 값이 문턱치보다 높을 때와 낮을 때로 나누어  $\sigma_s, \sigma_i$ 를 적용한다. C. Tomasi가 제안했던 알고리즘의 경우 이미지 전체의 모든 픽셀에 대해서 같은  $\sigma_s, \sigma_i$ 를 적용했으므로 Ahn, B.Y와 Kim, D.H가 제안한 알고리즘이 전반적으로 더 뛰어난 성능을 가짐을 확인할 수 있다. 그러나, 계산된 값이 문턱치보다 높을 때와 낮을 때 단 두가지 경우로 나누어 불연속적으로  $\sigma_s, \sigma_i$ 를 적용하기 때문에 본 논문에서 제안하는 복잡도에 따라 연속적인 함수에 의해서 계산된  $\sigma_s, \sigma_i$ 를 적용하는 방식에 비해 성능이 전반적으로 떨어짐을 확인 할 수 있다.

제안한 방식에서 선형함수로 회귀시킨 경우 그림 4의 (a)에서 보이듯 복잡도가 적은 영역에서 계산된  $\sigma_s, \sigma_i$ 의 정확성이 높고 높은 영역에서 정확성이 떨어지며 심할 경우 마이너스로 전환되며 수치의 신뢰성

표 2. 테스트 이미지에 대한 여러 알고리즘과의  $PSNR$  비교  
Table 2. Comparison  $PSNR$  for various filtering algorithm

$PSNR$		C. Tomasi	Ahn, B.Y	Kim, D. H	Propose Linear	Propose Polynomial	Propose Exponential	Propose Rational
Lena	33.65	34.50	33.89	34.42	34.21	34.03	33.87	
Baboon	26.22	27.66	27.39	27.82	27.78	27.92	27.83	
Barbara	28.81	29.86	30.33	30.73	30.63	30.65	30.56	
Boat	31.25	31.76	31.72	32.24	32.04	31.94	31.81	
Goldhill	30.62	31.08	30.93	31.29	31.10	30.95	30.83	

표 3. 테스트 이미지에 대한 여러 알고리즘과의  $PSNR_{EDGE}$  비교  
Table 3. Comparison  $PSNR_{EDGE}$  for various filtering algorithm

$PSNR_{EDGE}$		C. Tomasi	Ahn, B.Y	Kim, D. H	Propose Linear	Propose Polynomial	Propose Exponential	Propose Rational
Lena	30.98	31.60	31.42	32.06	31.99	32.20	32.13	
Baboon	25.18	26.37	26.48	27.05	27.11	27.36	27.27	
Barbara	25.71	27.04	27.68	28.16	28.09	28.27	28.19	
Boat	26.96	27.07	28.17	29.18	29.21	29.54	29.42	
Goldhill	28.11	28.79	28.85	29.45	29.44	29.73	29.62	

표 4. 테스트 이미지에 대한 여러 알고리즘과의  $PSNR_{FLAT}$  비교  
Table 4. Comparison  $PSNR_{FLAT}$  for various filtering algorithm

$PSNR_{FLAT}$		C. Tomasi	Ahn, B.Y	Kim, D. H	Propose Linear	Propose Polynomial	Propose Exponential	Propose Rational
Lena	34.02	34.90	34.22	34.74	34.50	34.25	34.07	
Baboon	26.49	27.73	27.63	28.02	27.94	28.03	27.95	
Barbara	29.72	30.66	31.06	31.42	31.30	31.24	31.14	
Boat	31.82	32.43	32.15	32.56	32.32	32.14	32.00	
Goldhill	31.03	31.44	31.26	31.56	31.34	31.10	30.97	

까지 잃게 되어  $PSNR_{EDGE}$ 에 비해  $PSNR_{FLAT}$ 의 성능이 타 알고리즘보다 상대적으로 뛰어나게 나올 수 있음을 볼 수 있다. 지수함수로 회귀시킨 경우 복잡도가 극도로 낮은 경우에는  $\sigma_s, \sigma_i$ 의 정확성이 심각하게 훼손되며 복잡도가 높은 경우  $\sigma_s, \sigma_i$ 의 감쇠가 상대적으로 더뎌  $PSNR_{FLAT}$ 에 비해  $PSNR_{EDGE}$ 가 더 뛰어나게 나옴을 확인할 수 있다.

## V. 결론 및 추후 과제

제안하는 알고리즘의 경우 압축률에 방해가 되는 잡음을 제거함으로써 압축률을 향상시켜줄 뿐만 아니라 시각에 예민한 엣지 또한 타 알고리즘보다 더욱 더 잘 보존하기 때문에 같은 압축률에 대비하여 이미지의 정량적 향상 및 이미지의 주관적인 질적 향상도 도모할 수 있다. 특히 사용자가 직접 변수를 선택할 필요 없이 평탄영역에 특화된 성능을 원할 경우 선형함수로 엣지영역에 특화된 성능을 원할 경우 지수함수로 회귀시켜 학습할 경우 자동적으로 최적에 가까운 변수를 계산하기 때문에 편리성 또한 높아 실제 적용에 있어 유용할 것으로 보인다.

그러나 소벨 연산자를 이용한 복잡도 기반 기법의 경우 공간적인 시점에서 그 수치를 도출하기 때문에 복잡도와 픽셀의 intensity 분포와 연관이 있는  $\sigma_i$ 와는 상관관계가 적게 나타난 것으로 추측되며 추후 연구를 통해 이 문제에 대한 해결책이 필요할 것으로 보인다.

## References

- [1] L. P. Yaroslavsky, *Digital Picture Processing: An Introduction*, Springer, 1985.
- [2] P. Perona and J. Malik, "Scale-space and edge detection using anisotropic diffusion," *IEEE Trans. Pattern Anal. and Machine Intell.*, vol. 12, no. 7, pp. 629-639, 1990.
- [3] C. Tomasi and R. Manduchi, "Bilateral filtering for gray and color images," *Computer Vision Sixth Int. Conf. IEEE*, pp. 839-846, 1998.
- [4] Y. Hyun and T. Park, "Hardware design of bilateral filter based on window division," *J. KICS*, vol. 41, no. 12, pp. 1844-1850, Dec. 2016.
- [5] Q. Yang, L. Wang, R. Yang, H. Stewénius, and D. Nistér, "Stereo matching with color-weighted correlation, hierarchical belief propagation and occlusion handling," *PAMI*, vol. 31, no. 3, pp. 492-504, 2009.
- [6] K. J. Yoon and I. S. Kweon, "Adaptive support-weight approach for correspondence search," *PAMI*, vol. 28, no. 4, pp. 650-656, 2006.
- [7] D. Oh, B. T. Oh, and J. Shin, "Up-sampling method of depth map using weighted joint bilateral filter," *J. KICS*, vol. 40, no. 6, pp. 1175-1184, Jun. 2015.
- [8] R. Ramanath and W. E. Snyder, "Adaptive demosaicking," *J. Electronic Imaging*, vol. 12, no. 4, pp. 633-642, 2003.
- [9] G. Petschnigg, M. Agrawala, H. Hoppe, R. Szeliski, M. Cohen, and K. Toyama, "Digital photography with flash and no-flash image pairs," *ACM TOG*, vol. 23, no. 3, pp. 664-672, 2004.
- [10] P. Sand and S. Teller, "Particle video: Long-range motion estimation using point trajectories," *IJCV*, vol. 80, no. 1, pp. 72-91, 2006.
- [11] S. Kwon and N. Kim, "A study on modified switching filter using region segmentation," *J. KICS*, vol. 41, no. 10, pp. 1284-1289, Oct. 2016.
- [12] B. Ahn and N. Cho, "Edge-adaptive bilateral filter in noisy image," in *Proc. Korean Soc. Broadcast Engineers Conf.*, pp. 105-107, Nov. 2012.
- [13] D. Kim, U. Hwang, and J. Jeong, "Bilateral filtering for image enhancement using edge detection and emphasis," in *Proc. Korean Soc. Broadcast Engineers Conf.*, pp. 134-137, Nov. 2014.

전기현 (Gi-hyeon Jeon)



2013년 8월 : 연세대학교 전자  
공학과 졸업  
2013년 9월~현재 : 연세대학교  
전자공학과 석박사 통합과정  
<관심분야> 머신러닝, 신호처  
리

최윤식 (Yoon-sik Choe)



1979년 2월 : 연세대학교 전자  
공학과 학사  
1984년 5월 : Case Western  
Reserve 대학 시스템 공학  
과 석사  
1987년 5월 : Pennsylvania 주  
립 대학 전기공학과 석사  
1990년 12월 : Purdue 대학 전기공학과 박사  
1993년 3월~현재 : 연세대학교 전기전자공학 교수  
<관심분야> 비디오/영상 신호 처리 및 해석

오의열 (Eui-yeol Oh)



1987년 2월 : 연세대학교 전자  
공학과 졸업  
1989년 2월 : 연세대학교 전자  
공학과 석사 졸업  
2013년 3월~현재 : 연세대학교  
전자공학과 박사과정

<관심분야> LCD/OLED 디스플레이 영상 처리