

퍼지 클러스터 필터와 가중화 된 벡터 α -trimmed 평균 필터를 이용한 칼라 영상처리

정희원 엄경배*, 이준환**

Color Image Processing using Fuzzy Cluster Filters and Weighted Vector α -trimmed Mean Filter

Kyoung-Bae Eum*, Joonwhoan Lee** *Regular Members*

요약

칼라 영상은 센서 잡음이나 채널 전송 에러에 의해 생기는 잡음에 의해 자주 오염되어진다. 이러한 칼라 잡음을 제거하기 위해 벡터 미디안, 벡터 α -trimmed 평균 필터등 여러 형태의 필터들이 개발되어져 왔다. 본 논문에서 제안된 퍼지 클러스터 필터는 잡음에 오염된 환경 하에서 강건한 소속함수 값을 얻을 수 있는 가능성 c-mean 클러스터링 방법을 이용하였다. 또한, 본 논문에서는 혼합된 잡음에서 우수한 벡터 α -trimmed 평균 필터를 개선하여, 원도우내의 화소중 중심에 위치한 화소에는 더 가중치를 부여하여 가중화 된 평균 필터링을 수행하는 가중화 된 벡터 α -trimmed 평균 필터를 제안하였다. 본 논문에서는 칼라 잡음이 발생한 영상에서 제안된 필터들의 성능을 평가하기 위해 칼라 잡음 발생기를 구현하였으며, 실험 결과는 NCD 척도 및 관측자의 시각에 의해 평가되었다. 실험 결과 제안된 퍼지 클러스터 필터는 NCD 관점에서 기존의 필터들에 비해 혼합된 잡음에서 우수한 성능을 보였고, 제안된 가중화된 벡터 α -trimmed 평균 필터는 벡터 α -trimmed 평균 필터에 비해 어떠한 잡음 하에서도 양호한 결과를 보였다.

ABSTRACT

Color images are often corrupted by the noise due to noisy sensors or channel transmission errors. Some filters such as vector median and vector α -trimmed mean filter have been used for color noise removal. In this paper, We propose the fuzzy cluster filters based on the probabilistic c-means clustering, because the probabilistic c-means clustering can get robust memberships in noisy environments. Also, we propose weighted vector α -trimmed mean filter to improve the conventional vector α -trimmed mean filter. In this filter, the central data are more weighted than the outlying data. In this paper, we implemented the color noise generator to evaluate the performance of the proposed filters in the color noise environments. The NCD measure and visual measure by human observer are used for evaluating the performance of the proposed filters. In the experiment, proposed fuzzy cluster filters in the sense of NCD measure gave the best performance over conventional filters in the mixed noise. Simulation results showed that proposed weighted vector α -trimmed mean filter is better than the conventional vector α -trimmed mean filter in any kinds of noises.

* 군산대학교 컴퓨터과학과 정희원,

** 전북대학교 전자공학과 정희원

논문번호 : 98308-0720, 접수일자 : 1998년 7월 20일

※ 이 논문은 1997년도 한국과학재단 핵심전문연구 연구비 지원에 의한 결과임 (과제번호 : 971-0916-098-1)

I. 서 론

영상은 센서의 잡음이나 채널 전송 에러에 의한 잡음에 의해 자주 오염되어진다. 이와 같은 잡음 제거를 위한 비선형 필터링 기술로는 미디안(median) 필터, 순서 통계(order statistics) 필터, 스택(stack) 필터, 형상학(morphological) 필터 등이 있다. 이를 비선형 필터중 미디안 필터는 윤곽선(edge) 보존 능력과 잡음 제거 능력이 우수하며 화질 개선, 윤곽선 검출, 부호화(coding), 비디오 영상의 필드율 변환등 많은 분야에서 응용되어 왔다.[1] 그러나, 이러한 연구들은 모두 단색조 영상을 대상으로 한 것이다. 따라서, 단색조 영상에 비해 인간의 시각을 크게 향상시켜 보다 많은 정보를 제공할 수 있는 칼라 영상을 위한 새로운 필터링 방법의 개발의 필요성이 요구되고 있다.

칼라 영상들 역시 입력 센서나 채널 전송시 오류가 발생하여 잡음에 오염되는 경우가 많다. 따라서, 이러한 칼라 잡음을 제거하기 위하여 벡터 미디안 필터(Vector Median Filter : VMF), 벡터 α -trimmed 평균 필터(Vector α -trimmed Mean Filter : V α TM), GVDF(Generalized Vector Directional Filter)등 여러 형태의 필터들이 개발되어져 왔다.[2,3,4] 본 논문에서는 임펄스(impulse) 잡음과 가우시안(gaussian) 잡음이 혼합된 잡음 환경에서 우수한 성능을 보이는 퍼지 클러스터 필터(Fuzzy Cluster Filters : FCF)를 제안하였다. 혼합된 잡음에서 우수한 성능을 보이는 벡터 α -trimmed 평균 필터를 개선하여 가중화된 벡터 α -trimmed 평균 필터(Weighted Vector α -trimmed Mean Filter : WV α TM)를 제안하였다. 제안된 필터들은 기존의 벡터 미디안 필터, GVDF, 산술 평균 필터(Arithmetic Mean Filter : AMF)등과 비교 검토되었다. GVDF는 원도우내의 칼라 화소를 각도 정보를 기반으로 정렬한 뒤 유사한 방향을 갖는 칼라 화소 k개의 평균을 출력으로 취하는 필터링 방법이고, 산술 평균 필터는 원도우내의 화소들의 평균을 필터링 출력으로 하는 방법이다.[5,6]

신호의 잡음에 강인한 추정기(robust estimator)로써 고전적인 LS(Least Square) 방법은 오차들의 합을 최소화하는 방법으로 계산의 효율성에 의해 널리 이용되어져 왔다. 그러나, LS방법은 단일 외곽 화소에 의해 추정값에 심각한 문제를 발생하게 된다. 이러한 점을 보완한 것이 M-추정기(M-estimator)이다. 칼라 영상 필터링은 영상 신호의 추정이라 볼 수 있고, 가능적 c-means 클러스터링(Possibilistic C-means

clustering : PCM) 방법[7]은 M-추정기의 일종이다. 따라서, 본 논문에서는 칼라 영상 신호의 비선형 필터링을 위해 가능적 c-means 클러스터링 방법을 사용하였다. 본 논문에서 제안된 퍼지 클러스터 필터에서 이용된 가능적 c-means 클러스터링 방법은 소속함수 값이 다른 클러스터와 무관하며, 속성과 해당 클러스터 중심간의 거리에만 의존하기 때문에 퍼지 c-means(fuzzy c-means) 클러스터링 방법[8]에 비해 잡음에 오염된 환경 하에서 강인한 소속함수 (membership) 값을 얻을 수 있는 장점을 가지고 있다.

벡터 α -trimmed 평균 필터는 임펄스 잡음의 제거에 우수한 성능을 보이는 미디안 필터의 장점과 가우시안 잡음의 제거에 뛰어난 평균 필터의 장점을 결합한 형태의 필터이다. 그러나, 벡터 α -trimmed 평균 필터는 균일한 가중치로 평균 필터링을 하기 때문에 윤곽선 이동이 일어나고 잡음의 가능성성이 높은 외곽 화소나 중심에 위치한 화소 모두 균일하게 필터링하는 문제점이 있다. 따라서, 본 논문에서는 벡터 α -trimmed 평균 필터를 개선하여, 원도우내의 화소들을 벡터 정렬 방법[9]을 이용하여 정렬한 뒤 중심에 있는 화소에는 좀 더 가중치를 부여하고 외곽 화소는 가중치를 적게 부여하여 윤곽선 이동을 줄이고 잡음에 강인한 추정을 수행하는 가중화된 벡터 α -trimmed 평균필터를 제안하였다. 그리고, 제안된 필터들을 기존의 필터들과 성능을 비교 평가하여 보았다.

본 논문에서는 칼라 잡음이 발생한 영상에서 제안한 필터들의 성능을 평가하기 위해 칼라 잡음 발생기를 구현하였으며, 이러한 환경하에서 제안된 필터들의 성능을 기존의 필터들과 비교 검토하였다. 실험 결과를 모니터에 기반한 RGB 공간에서 비교하는것보다 인간의 시지각 특성에 기반한 균등색 공간(Uniform Color Space)에서 칼라 오차를 비교하는 것이 타당하다. 따라서, CIE LUV 균등색 공간에서 NCD (Normalized Color Difference)값을 이용하여 칼라 오차를 비교하였다. NCD 관점에서 칼라 임펄스 잡음에서는 벡터 미디안이 가장 우수하였고, 가우시안 잡음에서는 산술 평균 필터의 결과가 전반적으로 우수하였으며 혼합된 잡음에서는 제안된 퍼지 클러스터 필터의 결과가 가장 우수하였다. 또한, 제안된 가중화된 벡터 α -trimmed 평균 필터는 임펄스, 가우시안 잡음, 혼합된 잡음이 있는 모든 실험 영상에서 NCD관점에서 벡터 α -trimmed 평균 필터의 결과보

다 양호하였다.

본 논문의 구성은 II장에서 칼라 잡음 발생기 구성에 대해 설명하고, 제안된 가중화된 벡터 α -trimmed 평균 필터 및 제안된 퍼지 클러스터 필터에 대해 설명하였으며, III장에서는 제안된 필터들에 대한 실험 결과를 제시하고, 마지막으로 IV장에서는 결론을 맺는다.

II. 본론

1. 칼라 잡음 발생기 구성

잡음이 발생한 영상에서 제안된 필터들의 성능을 평가하기 위하여 칼라 잡음을 모델링하는 것이 필요하다. 본 논문에서는 가산 잡음(additive noise)만을 고려하였고, 잡음을 생성하기 위한 과정은 아래 그림 1과 같다.

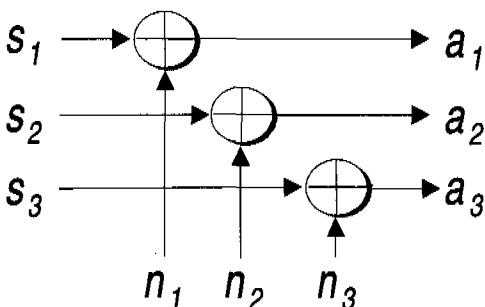


그림 1. 잡음 생성 과정의 블록 다이어 그램

$$\mathbf{a} = \mathbf{s} + \mathbf{n}$$

$\mathbf{s}=[s_1, s_2, s_3]$ 은 원 영상이고, $\mathbf{n}=[n_1, n_2, n_3]$ 은 잡음이며, $\mathbf{a}=[a_1, a_2, a_3]$ 은 잡음이 부가된 영상이다.

칼라 잡음 발생기를 구성하기 위해서는 3차원 랜덤 프로세스 \mathbf{n} 을 생성시켜야 한다. 본 논문에서는 제안한 필터들의 성능을 평가하기 위하여, 임펄스 잡음과 가우시안 잡음을 고려하였다. 8비트 그레이 스케일 시스템을 위하여 신호의 최소치 s_{min} 은 0, 최대치 s_{max} 는 255를 이용하였다. 임펄스 잡음은 그레이 영상에서 임펄스 잡음을 생성시키는 것과 유사한 방법으로, 동일한 확률을 가진 음과 양의 임펄스 잡음을 생성하였다. 또한, 실제 칼라 영상에서 잡음을 채널 사이에 상관관계(correlation)를 갖고 있으므로, 상관관계를 가진 잡음 모델을 고려하였다.

임의의 벡터 \mathbf{X} 의 다변수 가우시안 분포는 다음 식과 같다.

$$f(\mathbf{X}) = \frac{1}{(2\pi)^{p/2} |\Sigma|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (\mathbf{X} - \boldsymbol{\eta})^T \Sigma^{-1} (\mathbf{X} - \boldsymbol{\eta}) \right] \quad (I)$$

여기서, p 는 채널들의 수나 벡터의 차원이고, $\boldsymbol{\eta}$ 는 평균값 벡터이다. $\boldsymbol{\eta}_i = E[x_i]$ 이며, $\Sigma = E[\mathbf{XX}^T]$ 는 공분산(covariance) 행렬이고, $\Sigma_{ij} = E[x_i x_j]$ 이다. 공분산 행렬 Σ 는 $p \times p$ 차원 symmetric positive definite 행렬이다.

$\mathbf{n} = [n_1, n_2, n_3]^T$ 가 상관관계가 없는 임의의 랜덤 벡터라고 하고, 선형 변환 \mathbf{A} 를 이용하여 새로운 랜덤 벡터 $\mathbf{s}' = [s'_1, s'_2, s'_3]^T$ 가 만들어 진다고 하자.

$$\mathbf{s}' = \mathbf{A} \cdot \mathbf{n} \quad (2)$$

변환 행렬 \mathbf{A} 는 다음과 같이 쓰여질 수 있다.

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} = \begin{bmatrix} \mathbf{a}_1^T \\ \mathbf{a}_2^T \\ \mathbf{a}_3^T \end{bmatrix} \quad (3)$$

여기서, $\mathbf{a}_i = [a_{1i}, a_{2i}, a_{3i}]^T$ 이다. 그러므로, $\mathbf{s}' = [\mathbf{a}_1^T \cdot \mathbf{n}, \mathbf{a}_2^T \cdot \mathbf{n}, \mathbf{a}_3^T \cdot \mathbf{n}]^T$ 이다. 변환되어진 벡터의 평균 벡터 $\boldsymbol{\eta}_{s'}$ 와 공분산 행렬 $\Sigma_{s'}$ 는 원래의 $\boldsymbol{\eta}_n$ 값과 Σ_n 으로부터 계산되어 질 수 있다.

$$\boldsymbol{\eta}_{s'_i} = E[s'_i] = \mathbf{a}_i^T \cdot \boldsymbol{\eta}_n \quad (4)$$

$$\Sigma_{s'_i s'_j} = E[s'_i s'_j] = \mathbf{a}_i^T \Sigma_n \mathbf{a}_j \quad (5)$$

따라서, 적절한 변환 행렬 \mathbf{A} 를 선택함으로써 임의의 평균 벡터와, 임의의 공분산 행렬을 가진 분포를 생성시킬 수 있다. 본 논문에서는 세 채널(빨강, 녹색, 파랑)이 대칭이라는 가정을 이용하여 다음과 같은 행렬 \mathbf{A} 를 선택하였다.

$$\mathbf{A} = \begin{bmatrix} a & b & b \\ b & a & b \\ b & b & a \end{bmatrix}$$

대칭 행렬은 채널 상호간에 상관관계가 모두 같다 는 것을 의미하고, 세 채널의 분산 역시 동일하다는 것을 의미한다. 그러므로, 상관관계가 있는 가우시안 잡음을 생성하기 위하여, 식(1)에서 정의되어진 바와 같이 상관관계가 없는 세 채널 가우시안 분포와 0의 평균값을 갖는 분포를 고려하여 보면,

$$\boldsymbol{\eta}_n = [0, 0, 0]^T \text{와 } \Sigma_n = \sigma^2 \mathbf{I} = \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix}$$

이다. 이때, 이 분포를 식 (3)에서 정의되어진 \mathbf{A} 행렬을 가지고 변환을 해보면, 그때

$\boldsymbol{\eta}_{s_i} = \mathbf{a}_i^T \cdot \boldsymbol{\eta}_n = 0, \quad i=1,2,3$ 이다. 그러므로, 새로운 분포는 역시 $\boldsymbol{\eta}_{s_i} = [0, 0, 0]^T$ 의 평균값을 갖는다. 또한, 공분산은

$$\begin{aligned} \Sigma_{s_i} &= \mathbf{a}_i^T \Sigma_n \mathbf{a}_i = \sigma^2 (\mathbf{a}_i^T \mathbf{a}_i) \\ &= \begin{cases} \sigma^2(a^2 + 2b^2), & i=j \\ \sigma^2(b^2 + 2ab), & i \neq j \end{cases} \end{aligned} \quad (6)$$

과 같다. 본 논문에서 구현한 칼라 잡음 발생기에서는 각 채널의 분산을 σ^2 으로 같은 유지하였다. 따라서 위 식 (6)에 다음과 같은 제약을 두었다.

$$a^2 + 2b^2 = 1 \text{ 그때, } \Sigma_s = \sigma^2 \begin{bmatrix} 1 & \rho & \rho \\ \rho & 1 & \rho \\ \rho & \rho & 1 \end{bmatrix}$$

여기서, $\rho = b^2 + 2b\sqrt{1-2b^2}$ 은 상관관계 계수 (correlation coefficient)이다. 따라서, b 를 적절히 선택하므로써 행렬 \mathbf{A} 를 구성하고 임의의 상관관계 계수 ρ 의 가우시안 잡음 분포를 구성할 수 있다.

2. 벡터 정렬 방법 및 벡터 미디안 필터(VMF)

칼라 데이터는 3차원 벡터로 생각할 수 있다. 이러한 벡터 데이터를 정렬하는 방법에는 칼라 데이터의 각 채널별로 독립적으로 정렬하는 marginal 정렬, 다변수(multivariate) 관측이 거리 행렬(distance matrix)에 의해 얻어진 스칼라 값에 의해 정렬되는 aggregate

정렬, 표본 데이터들의 최소 콘벡스 헬(convex hull)을 구하여 표본 데이터를 각 그룹으로 나누는 partial 정렬, 표본 데이터들의 한 채널에 대해서만 조건적으로 정렬하는 conditional 정렬등 여러가지 정렬 방법들이 있다.^[9] 그러나, marginal 정렬은 정렬한 후의 데이터가 원래의 데이터와 일대일로 일치하지 않는 문제점이 있고, partial 정렬은 각 그룹들 안에서는 정렬이 이루어지지 않고, 콘벡스 헬을 결정하는 것도 다 차원 데이터의 경우에는 쉽게 구할 수 없는 문제점을 가지고 있다. 또한, conditional 정렬에서는 정렬 방법이 간결한 반면에 정렬하는데 있어서 한 채널의 정보만을 이용하기 때문에 많은 유용한 정보를 손실하는 문제점을 가지고 있다. 이에 반하여, aggregate 정렬 방법은 거리 행렬에 의해 가장 작은 스칼라 값을 갖는 경우인 표본 데이터들의 가장 중심에 있는 데이터로부터 외곽에 있는 데이터까지 효율적으로 정렬할 수 있다.

aggregate 정렬 방법에서는 각각의 다변수 관측 (\mathbf{x}_i)은 \mathbf{x}_i 의 어떤 함수 또는 거리 행렬에 의해서 스칼라 값 (d_i)으로 표현된다. aggregate 정렬 방법은 절대적인 최소와 최대 벡터가 없기 때문에 스칼라 정렬 방법과 똑같은 방법으로 해석되어 질 수 없다. 이 정렬 방법은 정렬이 거리 척도에 기반을 두고 있고, 거리 행렬로써 다음 식과 같은 aggregate 거리를 사용할 수 있다.

$$d_i = \sum_{k=1}^n \|\mathbf{x}_i - \mathbf{x}_k\| \quad (7)$$

윗 식에서 d_i 는 데이터 \mathbf{x}_i 와 모든 데이터 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$ 들과의 거리의 합이고, $\|\cdot\|$ 은 적절한 벡터 norm이다. 위와 같은 거리를 사용할 경우는 정렬된 데이터중 d_i 값이 가장 작은 데이터가 벡터 미디안이 될것이고, 정렬된 데이터중 d_i 값이 가장 큰 데이터가 가장 외곽 데이터(outlier)가 될 것이다.

Neuvo 등에 의해 개발된 벡터 미디안 필터는 두 개의 다차원 확률 밀도함수로부터 maximum likelihood 추정방법을 이용하여 유도될 수 있다.[4] 확률 밀도를 지수함수인 식 (8)과 같은 형태를 갖는다고 가정하자.

$$f(\mathbf{x}) = \gamma e^{-\alpha \|\mathbf{x} - \beta\|_2} \quad (8)$$

여기서, γ 와 α 는 스케일링 변수들이고, $\|\cdot\|_2$ 는

L_2 norm)이며 β 는 분포함수의 위치 변수이다. 식 (8)의 분포 함수로부터 임의의 표본 집합에 근거한 β 의 maximum likelihood 추정값인 $\hat{\beta}$ 은 likelihood 함수를 최대화하는 β 값이다.

$$L(\beta) = \prod_{i=1}^N \gamma e^{-\alpha \|x_i - \beta\|_2} \quad (9)$$

$L(\beta)$ 를 최대화하는 문제는 다음의 식 (10)을 최소화시키는 것과 동일하다.

$$\sum_{i=1}^N \|x_i - \beta\| \quad (10)$$

그러나, 이 경우 스칼라 미디안에 반하여, 일반적으로 β 은 입력값 중의 하나가 아니다. 따라서, β 가 입력 벡터중의 하나가 되도록 하는 부가적인 요건을 추가할 때, 부 최적인(suboptimal) 추정값을 얻을 수 있다. 이것으로부터 L_2 norm을 이용한 벡터 미디안의 정의를 다음 식과 같이 유도할 수 있다. 이것은 앞에서 언급된 aggregate 정렬에서 이용된 aggregate 거리와 동일함을 알 수 있다.

$$x_{vm} \in \{x_i \mid i=1, \dots, N\}$$

$$\sum_{i=1}^N \|x_{vm} - x_i\|_2 \leq \sum_{i=1}^N \|x_i - x_v\|_2 \quad (11)$$

$$\forall j = 1, 2, \dots, N$$

3. 제안된 가중화된 벡터 α -trimmed 평균 필터

3.1 벡터 α -trimmed 평균 필터(V ATM)

미디안은 윤곽선을 보존하거나, 임펄스 잡음을 제거하는데는 우수하지만, 영상처리에서 자주 접하게 되는 부가적인 백색 가우시안 잡음을 제거하는데는 평균 필터나 다른 선형 필터들 보다 우수하지 못하다. 따라서, 미디안 필터와 평균 필터의 좋은 절충 형태가 α -trimmed 평균 필터이다. α -trimmed 평균 필터는 정규 분포에 대해 최적의 강건한 추정기이다.[1] 강건한 추정기로서 breakdown point는 $\varepsilon^*=\alpha$ 로 알려져 있다. 그레이 영상에서 α -trimmed 평균 필터는 원도우내의 화소들을 정렬한 뒤, 상부 $\alpha\%$ 와 하부 $\alpha\%$ 를 배제한 후 남아 있는 화소들의 평균값을 필터의 출력으로 하여 미디안 필터와 평균 필터의 절충형태를 얻을 수 있다.

벡터 데이터의 경우, 전술한 벡터 정렬 방법을 이용하여 원도우내의 화소들을 정렬한 뒤, 다차원 벡터

영상의 α -trimmed 평균 필터를 다음 식과 같이 정의 할 수 있다.

$$\mathbf{y} = \sum_{k=1}^{n(1-2\alpha)} \mathbf{a}_k^T \mathbf{x}_{(k)} \quad (12)$$

여기서, n 은 원도우내의 화소의 개수이다.

$$\mathbf{a}_k^T = \left[\frac{1}{n(1-2\alpha)}, \frac{1}{n(1-2\alpha)}, \dots, \frac{1}{n(1-2\alpha)} \right]^T$$

위 식에서 정의되어진 바와 같이 외곽 화소의 $2\alpha\%$ 를 배제한 뒤, 원도우내의 화소 중 $(1-2\alpha)\%$ 의 평균을 취한다. 이 필터에서 trimming연산은 임펄스 잡음과 같은 long tailed 잡음에 대해 좋은 성능을 유지하게 하며, 윤곽선을 보존하게 하고, 평균 연산은 가우시안 잡음과 같은 short tailed 잡음을 제거하는데 좋은 성능을 유지하게 한다.

3.2 제안된 가중화된 벡터 α -trimmed 평균 필터 (WV ATM)

앞절에서 언급한 바와 같이 벡터 α -trimmed 평균 필터는 벡터 정렬 방법을 이용하여 원도우내의 화소들을 정렬한 뒤 외곽 화소들 중 $2\alpha\%$ 를 배제하고 나머지 화소들에 대해 평균 필터링을 한다. 그러나, 벡터 α -trimmed 평균 필터는 원도우내의 화소들중에서 중심에 있는 화소나 잡음일 가능성성이 높은 외곽에 있는 화소 모두 균일한 가중치로 평균 필터링을 하고, 균일한 가중치로 평균 필터링을 하기 때문에 윤곽선 부분에서 윤곽선 이동이 일어나 blurring 현상이 발생 할 수 있다. 따라서, 본 논문에서는 중심에 있는 화소에는 좀 더 가중치를 부여하고 잡음일 가능성이 많은 외곽 화소에는 가중치를 적게 부여함으로써 잡음에 강인한 필터 특성을 얻을 수 있고, 윤곽선 보존 능력이 우수한 벡터 미디안 값 즉 중심에 위치한 화소에 더 가중치를 부여하고 외곽 화소들은 가중치의 값을 작게 부여함으로써 윤곽선 이동이 적게 발생할 것이다.

제안된 가중화된 벡터 α -trimmed 평균 필터에서 데이터 x_i 의 가중치 W_i 는 식 (13)과 같다.

$$W_i = \frac{\text{sum} - s_i}{(n(1-2\alpha)-1)(s_1 + s_2 + \dots + s_{n(1-2\alpha)})} \quad (13)$$

위 식에서 n 은 원도우내의 화소의 개수이며, s_i 는 i 번째 화소와 원도우내의 모든 화소와의 거리의 합을

나타내는 aggregate 거리이고, s_1 은 가장 작은 aggregate 거리값을 갖게 되고 이에 해당하는 화소는 원도우내의 화소들 중 중심에 위치한 벡터 미디안값이 된다. 식(13)에서 분모는 가중치의 합이 1이 되게끔하는 정규화를 위한 값이고, 분자값은 중심에 위치한 화소에 가중치를 크게 부여하게 된다. 윗식에서 sum은 $\sum_{i=1}^n s_i$ 이다. 가중치의 범위는 임펄스 잡음의 %가 클 경우는 임펄스 잡음에 강인한 추정을 위하여 외곽 화소들을 많이 배제하기 위해서 a 를 크게 하고, 임펄스 잡음의 %가 작을 경우는 a 를 작게 잡는 것 이 타당하다.

따라서, 가중화된 벡터 a -trimmed 평균 필터는 다음 식과 같이 정의할 수 있다.

$$y = \sum_{k=1}^{n(1-2\alpha)} W_k x_{(k)} \quad (14)$$

속성 공간상에 분포하는 화소들을 정렬을 하기 위해서는 aggregate 거리를 이용하는데 이를 구하는데 많은 시간이 걸린다. 그러나, 벡터 미디안에서는 단지 최소 aggregate 거리를 갖는 화소로 추정하는데 그치고, 또한 벡터 a -trimmed 평균 필터는 정렬된 화소 중 $2\alpha\%$ 의 외곽 화소들을 배제하고 나머지 화소들에 대해 균일한 가중치로 평균 필터링을 한다. 그러나, 제안된 가중화된 벡터 a -trimmed 평균 필터는 가중화된 평균을 구하는데 정렬을 하기 위해 이미 구해진 aggregate 거리를 이용함으로써 계산량의 추가적인 증가 없이 필터링을 수행할 수 있다.

4. 퍼지 클러스터 필터

4.1 기능적(possibilistic) c-means 클러스터링

퍼지 클러스터링 알고리즘은 객체들 집합의 요소들 사이의 유사성을 찾아내는 수학적 도구이다. 퍼지 c-means은 Bezdek에 의하여 제안되어진 퍼지 클러스터링 알고리즘중의 하나이다.[8] 퍼지 c-means 알고리즘의 목적(objective) 함수와 소속함수 개신식은 다음 식과 같이 주어진다.

$$J_m(L, U) = \sum_{i=1}^c \sum_{j=1}^N (\mu_{ij})^m d_{ij}^2 \quad (15)$$

$$\text{where } \sum_{i=1}^c \mu_{ij} = 1 \quad \text{for all } j$$

$$\mu_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ik}}{d_{kj}} \right)^{\frac{2}{(m-1)}}} \quad (16)$$

윗식에서 $L = (\beta_1, \dots, \beta_c)$ 는 prototype의 c-tuple이고 d_{ij}^2 은 미지의 데이터 x_j 와 각 클러스터 중심 β_i 사이의 거리이다. N 은 속성 데이터의 총 갯수이고, c 는 클러스터의 갯수이다. $U = [u_{ij}]$ 는 퍼지 c-partition 행렬이고, u_{ij} 는 클러스터 β_i 에서 속성 데이터 x_j 의 소속함수 값이며, m 은 퍼지화라고 불리는 가중치 지수이다. 퍼지 c-means 알고리즘은 한 데이터가 각 클러스터에 속하는 소속함수 값이 합하여 1이 된다는 확률론적인 접근법을 이용하고 있기 때문에 한 데이터가 어떤 클러스터들에서 클러스터들로부터 멀리 떨어진 데이터나 가까운 데이터나 동일한 비율로 멀리 떨어져 있을 경우는 동일한 크기의 소속함수 값을 가질 수 있다. 퍼지 c-means의 이러한 성질은 “equal evidence”와 “ignorance”를 구분할 수 없기 때문에 잡음에 강건한 소속함수를 생성할 수 없다.

그러나, 가능한 c-means 알고리즘에서는 소속함수의 값이 다른 클러스터와 관계가 없고, 속성 데이터와 해당 클러스터 중심간의 거리에만 의존하기 때문에 퍼지 c-means이 갖는 문제점을 해결할 수 있어 잡음에 강건한 소속함수 값을 생성할 수 있다. 이와 같은 목적을 달성하기 위해 윗식 (15)에서 확률적 제약 조건을 완화시킴으로써, 식 (17)과 같은 가능한 c-means의 목적함수를 얻을 수 있고, 이는 최근에 다음과 같이 제안되어졌다.[7]

$$J_m(L, U) = \sum_{i=1}^c \sum_{j=1}^N (\mu_{ij})^m d_{ij}^2 + \sum_{i=1}^c \eta_i \sum_{j=1}^N (1 - u_{ij})^m \quad (17)$$

위 식은 식 (15)에서 확률적 제약조건을 완화시킬 때, 목적 함수가 모든 소속 함수 값을 0으로 최소화하여, 쓸모 없는 해를 얻는 것을 피하기 위해 우측항을 삽입하였다. 식 (17)에서 η_i 는 적절한 양수 값이다. 식 (17)로부터 소속함수 값 개신식을 유도하기 위해, 먼저 U 의 행과 열이 서로 독립이라는 것을 주목해 보자. 그러므로, U 에 관해 $J_m(L, U)$ 를 최소화하는 것은 u_{ij} 각각의 값에 관해 목적함수를 최소화 시키는 것과 동일하다. 따라서, 식 (17)을 u_{ij} 에 관해

미분하고, 미분값을 0으로 놓을 때 다음 식을 얻을 수 있다.

$$u_{ij} = \frac{1}{1 + \left(\frac{d_{ij}^2}{\eta_i} \right)^{\frac{1}{m-1}}} \quad (18)$$

식 (18)로부터, u_{ij} 의 값이 [0,1]사이에 놓여있다는 것을 알 수 있고, 소속함수 u_{ij} 값은 클러스터 중심 \mathbf{a}_j 와 속성 데이터 \mathbf{x}_i 사이의 거리에만 의존하는 것을 알 수 있다.

4.2 제안된 퍼지 클러스터 필터(FCF)

비선형 필터링의 목적은 잡음을 제거하거나, 윤곽 선과 같은 비선형 특성을 보존하기 위한 것이다. 전술한 바와 같이 신호의 잡음에 강인한 추정기로써 고전적인 LS(Least Square) 방법은 오차들의 합을 최소화하는 방법으로 계산의 효율성에 의해 널리 이용되어져 왔다. 그러나, LS방법은 단일 외곽 화소에 의해 서도 추정값에 심각한 문제를 발생하게 된다. 이러한 점을 보완한 것이 M-추정기이다. 칼라 영상 필터링은 영상 신호의 추정이라 볼 수 있고, 가능적 c-means 클러스터링 방법은 M-추정기의 일종이다. 따라서, 본 논문에서는 칼라 영상 신호의 비선형 필터링을 위해 가능적 c-means 클러스터링 방법을 사용하였는데 전술한 바와 같이 퍼지 c-means 방법에 비해 잡음이 있는 환경에서 강건한 소속함수 값을 얻을 수 있기 때문이다. 가능적 c-means 방법에서 클러스터 중심의 계산은 분산을 최소화하는 클러스터링 방법에 의해 얻어진다. 따라서, 퍼지 클러스터 필터에서 원도우내의 각 화소를 위한 소속함수 값을 클러스터 중심으로부터 각 화소간의 거리에 의해 얻어진다. 필터의 출력은 소속함수에 의해 가중화된 원도우내의 화소들의 가중화된 평균값에 의해 추정되어진다.

퍼지 클러스터 필터를 위한 클러스터링에서 초기 중심 값은 외곽화소(spike noise와 같은)에 대한 강건함에서 기인한 원도우내의 화소들의 벡터 미디안 값이다. 식 (20)에서 $d^2(\mathbf{x}_k, \mathbf{a})$ 는 원도우 내의 화소 \mathbf{x}_k 와 클러스터 중심 \mathbf{a} 사이의 유clidean 거리이고, η 는 클러스터의 분산을 나타내는 정규화 요소이다.

퍼지 클러스터 필터링의 알고리즘은 다음과 같다.

1st step) 초기화 : $\mathbf{a}(0)=vector median(\mathbf{x}_k), k=1,2,$

…; k 로 표현되는 클러스터 초기 중심값을 원도우내의 벡터 미디안 값으로 설정한다. 클러스터 초기 중심값 $\mathbf{a}(0)$ 의 팔호 안의 0은 0번째 반복을 나타낸다. 여기서, 초기 η 값은 식 (19)를 이용하여 구한다.

2nd step) 반복수가 증가함에 따라 j 값도 1씩 증가시킨다 ; $j \leftarrow j+1$

3rd step) 식 (20)을 이용하여 원도우내의 모든 화소들의 소속함수 값을 계산한다. 클러스터 중심값으로부터의 거리에 의해 얻어진 $\mu_{x_k}(j)$ 는 전 단계 반복 때의 $\mathbf{a}(j-1)$ 로부터 얻을 수 있다.

4th step) 식 (22)를 이용하여 클러스터 중심 \mathbf{a} 를 포함하는 모든 클러스터 변수들을 갱신하고 식 (21)을 이용하여 정규화 요소 η 를 계산한다.

5th step) 원하는 모든 변수 값들이 수렴하면 끝내고, 아니면 2nd step으로 돌아가 다시 반복한다.

6th step) 필터의 출력값을 클러스터 중심값으로 대체한다.

초기의 η 값의 계산은 식 (19)를 이용하여 구했고, 소속함수의 계산은 식 (20)으로부터 얻어진다. 식 (21)은 잡음에 의한 η 값의 계산 오류를 방지하기 위해 잡음일 가능성성이 있는 화소들은 배제하고 η 의 계산을 한 것이며, 식 (22)는 클러스터 중심을 계산하기 위한 식이다. 여기서, η 는 평균 클러스터 내부거리(average intraclass distance)로 클러스터의 형태와 크기에 밀접한 관계가 있다. 식 (20)으로부터 알 수 있는 바와 같이 η 는 정규화 요소이며, 원도우내의 화소가 클러스터 중심으로부터 평균 클러스터 내부거리 η 보다 외곽에 있는 경우는 잡음일 가능성이 많으므로 소속함수 값을 크게 부여하고, 그 반대인 경우는 소속함수 값을 크게 부여하는 것을 알 수 있다.

$$\eta = K \frac{\sum_{k=1}^n (\mu_k)^m \cdot d^2(\mathbf{x}_k, \mathbf{a})}{\sum_{k=1}^n (\mu_k)^m} \quad (19)$$

단, K는 상수이고, $K = 10$ 이다.

$$\mu(\mathbf{x}_k) = \frac{1}{1 + \left(\frac{d^2(\mathbf{x}_k, \mathbf{a})}{\eta} \right)^{\frac{1}{m-1}}} \quad (20)$$

$$\eta = \frac{\sum_{\mathbf{x}_k \in \Pi_a} d^2(\mathbf{x}_k, \mathbf{a})}{|\Pi_a|} \quad (21)$$

단, $(II)_\alpha$ 는 Π 의 적절한 α -cut이다.

$$\alpha = \frac{\sum_{k=1}^n (\mu_k)^m \cdot x_k}{\sum_{k=1}^n (\mu_k)^m} \quad (22)$$

여기서, $m \in [1, \infty)$ 은 퍼지화(fuzziness)의 정도를 나타낸다.

III. 실험 및 결과

본 논문에서는 제안한 필터들의 성능을 평가하기 위해 칼라 잡음 발생기를 구성하였고, 256×240 크기의 칼라 영상 Lenna와 Mandrill, Peppers 등을 가지고 실험을 행하였다. 칼라 잡음 생성을 위한 상관관계 계수는 $\rho = 0.5$ 이다. 실험 결과에 대한 정량적인 평가는 인간의 시지각 특성에 기반한 균등색 공간인 CIE LUV 좌표계에서 계산된 NCD 관점에서 행해졌다. 또한, 주관적인 평가로 사람의 시각에 의한 평가도 해 보았다. 식(23)은 NCD에 관한 식이다.

$$NCD = \frac{\sum_{i=0}^{255} \sum_{j=0}^{240} \|\Delta E_{Luv}\|}{\sum_{i=0}^{255} \sum_{j=0}^{240} \|\Delta E_{Luv}\|}, \quad (23)$$

where $\|\Delta E_{Luv}\| = [(L - L^*)^2 + (u - u^*)^2 + (v - v^*)^2]^{1/2}$

윗 식(23)에서 L, u, v 는 원 영상 신호이고, L^*, u^*, v^* 는 필터링 된 결과 신호이다. 표1, 표2, 표3은 Lenna 영상, Mandrill 영상, Peppers 영상의 NCD값 들이다. 그림2는 칼라 임펄스 잡음하에서, 그림3은 가우시안 잡음하에서, 그림4는 혼합된 잡음하에서 Lenna 영상의 실험 결과들이다. 지면 관계상 Lenna 영상의 실험 결과만 도시하였고 출력의 편의상 칼라영상을 그레이 영상으로 출력하였다.

칼라 임펄스 잡음이 4%인 경우 칼라 임펄스 잡음에서 뛰어난 성능을 갖는 베틀 미디안 필터와 NCD 관점에서 비교하여 볼 때, 본 논문에서 제안된 퍼지 클러스터 필터의 결과나 가중화된 베틀 α -trimmed 평균 필터의 결과보다 베틀 미디안의 결과가 가장 우수하였고, 모든 실험 영상에서 제안된 가중화된 베틀 α -trimmed 평균 필터는 베틀 α -trimmed 평균 필터의 결과보다 NCD 관점에서 양호한 결과를 얻었다. 시각적으로 관찰한 결과 Lenna 영상과 Mandrill 영상, Peppers 영상에서 제안된 필터들이 대부분 양호한 결과를 보였다.

가우시안 잡음($\sigma = 15$)인 경우 가우시안 잡음에서

우수한 성능을 발휘하는 산술 평균 필터와 NCD 관점에서 비교하여 볼 때 Lenna 영상과 Mandrill 영상에서는 본 논문에서 제안된 퍼지 클러스터 필터나 가중화된 베틀 α -trimmed 평균 필터의 결과보다 평균 필터의 결과가 전반적으로 우수하였고, Peppers 영상에서는 제안된 가중화된 베틀 α -trimmed 평균 필터의 결과가 AMF의 결과보다 다소 양호하였다. 또한, 모든 실험 영상에서 가중화된 베틀 α -trimmed 평균 필터의 성능은 베틀 α -trimmed 평균 필터의 성능보다 NCD 관점에서 양호하였다. 시각적으로 관찰해 보면 Lenna 영상의 경우 AMF의 결과보다 제안된 퍼지 클러스터 필터와 가중화된 베틀 α -trimmed 평균 필터의 결과가 눈, 코, 머리카락 등과 같은 윤곽선 부분이 다소 선명하여 보였다. 즉, AMF의 결과는 윤곽선 흐림 현상이 심하였다. Mandrill 영상의 경우 영상의 특성상 통과 필터에 따른 결과의 상태를 판단하기 힘들었으나, AMF의 결과가 윤곽선 흐림 현상으로 인하여 입 주변의 털과 눈 주위부분에 흐림 현상이 나타났으나 제안된 퍼지 클러스터 필터와 가중화된 베틀 α -trimmed 평균 필터의 결과는 이러한 부분들이 다소 선명하게 보였다. Peppers 영상에서도 마찬가지로 이와 같은 현상이 나타났다.

표 1. Lenna 영상에서의 각 필터들의 NCD값 ($\times 10^{-2}$)

Noise Model	VMF	GVDF ($\alpha=0.0$, $m=1.7$)	FCF ($\alpha=0.0$, $m=1.7$)	AMF
impulsive 4% ($\rho=0.5$)	3.540	4.335	4.811	12.311
Gaussian $\sigma=15$ ($\rho=0.5$)	10.461	8.621	8.256	7.084
impulsive 4% + Gaussian $\sigma=15$ ($\rho=0.5$)	12.564	10.490	9.340	13.674
Noise Model	$V\alpha TM$ $\alpha=0.1$	$V\alpha TM$ $\alpha=0.2$	$WV\alpha TM$ $\alpha=0.1$	$WV\alpha TM$ $\alpha=0.2$
impulsive 4% ($\rho=0.5$)	6.620	4.337	6.350	4.284
Gaussian $\sigma=15$ ($\rho=0.5$)	7.852	8.541	7.835	8.518
impulsive 4% + Gaussian $\sigma=15$ ($\rho=0.5$)	10.012	9.935	9.906	9.902

가우시안 잡음($\sigma=15$)과 임펄스 잡음(4%)이 혼합된 잡음하에서는 혼합된 잡음에서 우수한 베틀 α -trimmed 평균 필터와 비교하여 볼 때 NCD 관점에서 Lenna와 Mandrill, Peppers 등 모든 영상에서 제안

된 퍼지 클러스터 필터($\alpha=0.0, m=1.7$)의 성능이 가장 우수하였고, 모든 실험 영상에서 제안된 가중화된 벡터 α -trimmed 평균 필터의 결과도 NCD 관점에서 벡터 α -trimmed 평균 필터의 결과보다 양호하였다. 시각적으로 평가해 보면, 제안된 퍼지 클러스터 필터와 가중화된 벡터 α -trimmed 평균 필터의 결과가 다른 필터들의 결과에 비해 양호하였다. 표 1, 2, 3에서 음영진 부분은 모든 필터링의 결과 중 가장 우수한 결과이다.

표 2. Mandrill 영상에서의 각 필터들의 NCD값($\times 10^{-2}$)

Noise Model	VMF	GVDF	FCF ($\alpha=0.0, m=1.7$)	AMF
impulsive 4% ($\rho=0.5$)	8.859	9.047	9.260	14.861
Gaussian $\sigma=15$ ($\rho=0.5$)	13.799	11.693	11.198	10.373
impulsive 4% + Gaussian $\sigma=15$ ($\rho=0.5$)	15.998	13.534	12.587	15.994
Noise Model	V α TM $\alpha=0.1$	V α TM $\alpha=0.2$	WV α TM $\alpha=0.1$	WV α TM $\alpha=0.2$
impulsive 4% ($\rho=0.5$)	10.735	9.262	10.561	9.209
Gaussian $\sigma=15$ ($\rho=0.5$)	10.904	11.597	10.888	11.575
impulsive 4% + Gaussian $\sigma=15$ ($\rho=0.5$)	13.234	13.178	13.138	13.139

표 3. Peppers 영상에서의 각 필터들의 NCD값($\times 10^{-2}$)

Noise Model	VMF	GVDF	FCF ($\alpha=0.0, m=1.7$)	AMF
impulsive 4% ($\rho=0.5$)	6.345	7.610	7.205	14.886
Gaussian $\sigma=15$ ($\rho=0.5$)	11.881	10.016	9.933	9.924
impulsive 4% + Gaussian $\sigma=15$ ($\rho=0.5$)	13.938	12.246	11.225	16.171
Noise Model	V α TM $\alpha=0.1$	V α TM $\alpha=0.2$	WV α TM $\alpha=0.1$	WV α TM $\alpha=0.2$
impulsive 4% ($\rho=0.5$)	8.788	6.806	8.572	6.756
Gaussian $\sigma=15$ ($\rho=0.5$)	9.836	10.102	9.793	10.066
impulsive 4% + Gaussian $\sigma=15$ ($\rho=0.5$)	11.947	11.577	11.837	11.535



(a) Lenna 원 영상 (b) 임펄스 4% 잡음의 Lenna 영상



(c) VMF 결과 (d) GVDF 결과

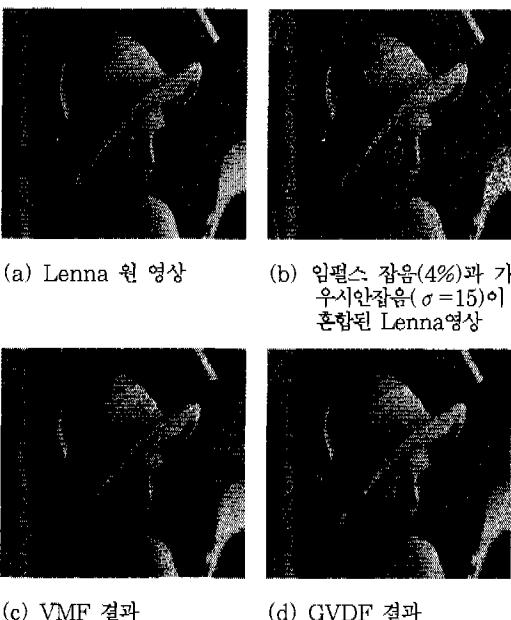


(e) FCF 결과 (f) AMF 결과

(g) $\alpha=0.2$ V α TM 결과 (h) $\alpha=0.2$ WV α TM 결과

그림 2. 임펄스 잡음 4%의 Lenna 영상 필터링 결과

(a) Lenna 원 영상 (b) $\sigma=15$ 인 가우시안 잡음의 Lenna 영상

그림 3. $\sigma=15$ 인 가우시안 잡음의 Lenna영상 필터링 결과

(c) VMF 결과

(d) GVDF 결과

그림 4. 임펄스 잡음(4%)+가우시안 잡음($\sigma=15$)의 Lenna영상 필터링 결과

IV. 결 론

칼라 영상은 전술한바와 같이 인간의 시각을 크게 향상시키고 여러 장점을 가지고 있음에도 불구하고, 칼라의 복잡한 속성과 칼라 영상을 처리하는데 많은 시간과 비용을 요구하였기 때문에 다른 분야에 비해 많은 연구가 이루어지지 못하였다. 근래에는 향상된 환경과 필요로 인하여 기존의 그레이 영상처리 방법을 단색조 영상에서 칼라 영상으로 단순히 확장하기도 해왔다. 그러나, 기존의 그레이 영상 처리 방법은 단색조 영상을 대상으로 한 방법이기 때문에 여러 가지 문제점을 가지고 있다. 따라서, 칼라 영상처리를 위한 새로운 영상처리 기법의 개발의 필요성이 요구됨에 따라, 본 논문에서는 칼라 잡음 제거를 위한 방법으로 퍼지 클러스터 필터와 가중화된 벡터 α -trimmed 평균 필터를 제안하였다. 그리고, 이를 기존에 개발된 필터들과 성능을 비교 평가하여 보았으며, 이들의 성능을 평가하기 위해 칼라 잡음 발생기를 구현하였다.

실험 결과 NCD 관점에서 칼라 임펄스 잡음 영상에서는 벡터 미디안이 가장 우수하였고, 가우시안 잡음에서는 산술 평균 필터의 결과가 전반적으로 우수하였으며 혼합된 잡음하에서는 제안된 퍼지 클러스터 필터의 결과가 가장 우수하였다. 시각적으로도 판

찰한 결과 제안된 퍼지 클러스터 필터는 칼라 임펄스 잡음과 가우시안 잡음하에서 양호한 결과를 보였으며, 특히, 혼합된 잡음하에서 기존의 필터들에 비해 양호한 결과를 보였다. 또한, 벡터 α -trimmed 평균 필터를 개선하기 위해 제안된 가중화된 벡터 α -trimmed 평균 필터는 임펄스, 가우시안 잡음, 혼합된 잡음이 있는 모든 실험 영상에서 NCD관점에서 벡터 α -trimmed 평균 필터의 결과보다 양호하였다. 이는 벡터 α -trimmed 평균 필터는 균일한 가중치로 평균 필터링을 하기 때문에 윤곽선 부분에서 윤곽선 이동이 일어나 blurring 현상이 발생할 수 있는 반면에, 본 논문에서 제안된 가중화된 벡터 α -trimmed 평균 필터는 중심에 있는 화소에는 좀 더 가중치를 부여하고 잡음일 가능성이 많은 외곽 화소에는 가중치를 적게 부여함으로써 잡음에 강인한 필터 특성을 얻을 수 있고, 윤곽선 이동을 줄일 수 있었다.

그러나, 전술한 바와 같이 NCD 척도는 칼라의 복잡한 속성으로 인하여 칼라 오차를 측정하는데 있어서 절대적인 척도가 아니기 때문에 필터링된 결과를 정확히 평가하기 위해 칼라 오차를 정확히 계산할 수 있는 척도에 관한 연구가 계속되어야 한다. 그리고, 영상의 칼라 잡음 발생기에 있어서도 실제 존재하는 칼라 잡음의 모델링이 필요하다.

본 논문에서 제안된 필터들은 멀티미디어, 통신 분야에서의 화질 개선, 의료 영상에서의 화질 개선 뿐만 아니라, 벡터 형태의 데이터를 갖는 움직임 벡터, 윤곽선의 잡음 제거 및 평활화 등 여러 분야에 이용될 수 있으리라 생각한다. 그리고, 제안된 필터들을 확장 적용하여 다차원 데이터인 위성사진 영상의 잡음제거에도 적용시킬 수 있을 것이라 기대된다.

참 고 문 헌

- [1] I. Pitas and A. N. Venetsanopoulos, "Nonlinear Digital Filters: Principles and Applications," MA:Kluwer, Boston, pp.216~257, 1990.
- [2] S. Sanwalka and A. N. Venetsanopoulos, "Vector order statistics filtering of color images," in 13th GRETSI Symp. on Signal and Image Processing, pp. 785~788, 1991.
- [3] P. E. Trahanias and A. N. Venetsanopoulos, "Multichannel image processing using vector angle ranking," SPIE Nonlinear Image Processing IV, vol. 1902, pp.116~127, 1993.
- [4] J. Astola, P. Haaristo and Y. Neuvo, "Vector

Median Filters," Proc. of IEEE, vol. 78, no.4, pp.678~689, 1990.

- [5] P. E. Trahanias and A. N. Venetsanopoulos, "Vector Directional Filters," IEEE Trans. Image Processing, vol. 2, no 4, pp.528~534, 1993.
- [6] P. E. Trahanias and A.N. Venetsanopoulos, "Color edge detection using vector order statistics," IEEE Trans. Image Processing, vol.2, pp.259~264, 1993.
- [7] R. Krishnapuram and J. M. Keller, "A possibilistic approach to clustering," IEEE Trans. on Fuzzy systems, vol. 1, no. 2, pp.98~110, 1993.
- [8] J. C. Bezdek, "Pattern Recognition with Fuzzy Objective Function Algorithms," Plenum, New York, 1981.
- [9] V. Barnett, "The Ordering of Multivariate Data," J. R. Statistical Society A, vol. 139, Part 3, pp.318~343, 1976.
- [10] A. K. Jain, "Fundamentals of Digital Image Processing," Prentice Hall, pp. 49~79, 1989.

엄 경 배(Kyoung-Bae Eum)

정회원

1990년 : 전북대학교 대학원 전자공학과(공학박사)

1995년 : 캐나다 토론토대학교 전기 및 컴퓨터공학과

Post Doc.

1999년 : 일본 동경대학 생산기술 연구소 객원연구원

1989년 ~ 현재 : 군산대학교 컴퓨터과학과 부교수

<주관심 분야> 칼라 영상처리 및 인식, 병렬처리, 퍼지 이론 및 신경망

이 준 환(Joonwhoan Lee)

정회원

1980년 : 한양대학교 전자공학과(공학사)

1982년 : 한국과학기술원 전기 및 전자공학과(공학석사)

1990년 : 미국 Univ. of Missouri, Columbia 전기 및 컴퓨터공학과(공학박사)

1985년 ~ 현재 : 전북대학교 전자공학과 부교수

<주관심 분야> 인공지능, 컴퓨터 비전, 퍼지이론 및 신경망