

효과적인 영상처리를 위한 α -LTSHD 기반의 FCNN 구조 연구

A study on FCNN structure based on a α -LTSHD for an effective image processing

변오성 · 문성룡

Oh-Sung Byun and Sung-Ryong Moon

원광대학교 전기·전자 및 정보공학부

요약

본 논문에서, 영상에서 임펄스 잡음을 효과적으로 제거하고, 연산 속도를 개선하기 위해 Fuzzy Cellular Neural Network(FCNN)구조에 Hausdorff distance(HD)를 적용한 α -Least Trimmed Square HD(α -LTSHD) 기반 FCNN 구조를 제안한다. FCNN은 Cellular Neural Network(CNN) 구조에 퍼지 이론을 적용한 것이고, HD는 특징 대상의 대응 없이 이진 영상의 두 픽셀 집합 사이의 거리를 구하는 척도로 물체의 정합에 널리 사용한다. 성능 평가를 위해, 제안된 방법을 MSE와 SNR을 이용하여 기존 FCNN, Opening-Closing(OC) 그리고 LTSHD 연산자를 적용한 FCNN과 비교 분석하였다. 그 결과, 본 논문에서 제안된 망(network) 구조의 성능이 다른 필터보다 임펄스 잡음 제거에 우수함을 확인하였다.

ABSTRACT

In this paper, we propose a Fuzzy Cellular Neural Network(FCNN) that is based on α -Least Trimmed Square Hausdorff distance(α -LTSHD) which applies Hausdorff distance(HD) to the FCNN structure in order to remove the impulse noise of images effectively and also improve the speed of operation. FCNN incorporates Fuzzy set theory to Cellular Neural Network(CNN) structure and HD is used as a scale which computes the distance between set of two pixels in binary images without confrontation of the feature object. This method has been widely used with the adjustment of the object. For performance evaluation, our proposed method is analyzed in comparison with the conventional FCNN, with the Opening-Closing(OC) method, and the LTSHD based FCNN by using Mean Square Error(MSE) and Signal to Noise Ratio(SNR).

As a result, the performance of our proposed network structure is found to be superior to the other algorithms in the removal of impulse noise.

Key Words : FCNN, Hausdorff Distance, α -Least Trimmed Square, OC, MSE

1. 서론

Cellular Neural Network(CNN)의 주요 특성은 셀 (processing unit)이 이웃 셀(neighbor Cell)에 국부적으로 연결이 가능하고, 셀과 셀 사이의 상호 연결 요소의 구조가 매우 간단하다. CNN의 국부적 상호연결과 간단한 시냅스 연산자(synopsis operator)는 초고속, 실시간 처리를 실현 할 수 있도록 VLSI 구현이 가능하다. 또한 CNN은 잡음 제거, 윤곽선 검출, 그림자 검출과 연결 성분 검출 등 다양한 기능을 수행할 수 있다[1]. 이는 이미지 처리, 패턴 인식 등 여러 분야에서 응용되고 있는 새로운 회로 구조로 Leon. Chua[2]에 의해 소개되었으며, 이러한 CNN을 디지털 가중, 입력, 상

태, 출력을 얻기 위하여 퍼지 개념을 도입하여 Fuzzy Cellular Neural Network(FCNN)이란 새로운 구조로 소개 되었다[3]. FCNN에서 템플릿(templet)을 적용할 때에 국부적인 해(local minimum)에 빠질 경우가 발생하므로, 전체적인 해를 얻기 위하여 많은 시간이 필요하다. 그래서 기존 FCNN에서의 단점인 국부적인 해에 빠질 우려가 있는 단일 연산(single operation)과 템플릿을 사용할 때에 결과 영상의 전체적인 그레이 레벨 값이 낮아지는 단점을 해결하기 위하여 구조적인 연산(structural operation)과 정합 방법(Matching method)을 이용을 하고 있다. 그래서 서로 다른 두 개의 영상 집합사이에 비슷한 정도를 측정하는 영상 정합은 패턴 인식, 컴퓨터 비전, 영상 해석에 있어서 아주 중요한 문제로 대두되고, 그리고 여러 가지 영상 정합 방법이 제안되었는데, 이 연산들은 특징 검출, 거리 변환, 정합도를 측정하여 영상의 유사도를 측정하게 된다. 현재 많은 정합 알고리즘이 제안되었는데, Hierarchical Chamfer Matching Algorithm(HCMA)[4], Hausdorff Distance(HD)등이 대표적인 예라 할 수 있다[5-7]. HCMA는 물체의 픽셀로부터 특

접수일자 : 2001년 10월 19일

완료일자 : 2002년 8월 16일

본 논문은 2001년도 원광대학교의 교비지원에 의해서 연구됨.




그림 1. FCNN에서 셀 C_{ij} 회로. ($I_{xu}(i, j, k, l) = B(i, j, k, l)v_{ukl}$, $I_{xy}(i, j, k, l) = A(i, j, k, l)v_{ykl}$, $I_{fxu}(i, j, k, l) = B_f(i, j, k, l)v_{ukl}$, $I_{fxy}(i, j, k, l) = A_f(i, j, k, l)v_{ykl}$. $f(\cdot)$ 는 비선형함수이다. \widehat{F}_B 와 \widehat{F}_A 는 2개 퍼지논리연산이다.)

Fig. 1 Cell C_{ij} circuit in FCNN. ($I_{xu}(i, j, k, l) = B(i, j, k, l)v_{ukl}$, $I_{xy}(i, j, k, l) = A(i, j, k, l)v_{ykl}$, $I_{fxu}(i, j, k, l) = B_f(i, j, k, l)v_{ukl}$, $I_{fxy}(i, j, k, l) = A_f(i, j, k, l)v_{ykl}$. $f(\cdot)$ is nonlinear function. \widehat{F}_B and \widehat{F}_A are 2 fuzzy logic operation.)

정 점을 얻은 후 특징 점 사이의 유사도에 의해 물체 정합을 수행하는 방법이다. 이에 비하여 HD 정합 방법은 픽셀로부터 특징 점을 구하지 않고 전체 픽셀 점 집합들 사이의 HD 정합에 의해 물체의 유사도를 판단하는 방법으로, max-min 거리를 사용하고 실제 영상의 정합에 있어서 잡음에 대단히 민감한 결과를 보였다.

본 논문에서는 기존의 LTSHD 정합 방법을 기반으로 α -Least Trimmed Square(LTS) 연산자를 적용한 FCNN을 구현하고, 이 알고리즘을 통하여 영상의 잡음을 제거하고, 최적의 영상을 얻도록 한다. 또한 제한된 α -LTSHD를 기반으로 한 FCNN과 기존 FCNN, OC, LTSHD를 모의 실험을 통하여 성능을 분석하고자 한다.

2. FCNN 구조

퍼지연산과 퍼지 템플릿을 적용한 $M \times N$ FCNN의 회로는 그림 1과 같고, 구조는 식(1)과 같으며, u , x 그리고 y 는 각각 입력, 상태, 출력을 나타낸다. 전압 V_{uij} , V_{xij} , V_{yij} 는 셀 C_{ij} 의 입력, 상태, 출력 전압을 표현한 것으로 방정식은 다음과 같다[1,3].

C_{ij} 상태방정식(State equation):

$$C \frac{dv_{xij}(t)}{dt} = -\frac{1}{R_x} v_{xij}(t) + \sum_{C_k \in N_r(i,j)} A(i, j, k, l)v_{ykl}(t) + \sum_{C_k \in N_r(i,j)} B(i, j, k, l)v_{ukl} + I + \bigwedge_{C_{kl} \in N_r(i,j)} A_{fmin}(i, j, k, l)y_{kl} + \bigvee_{C_{kl} \in N_r(i,j)} A_{fmax}(i, j, k, l)y_{kl} + \bigwedge_{C_{kl} \in N_r(i,j)} B_{fmin}(i, j, k, l)u_{kl} + \bigvee_{C_{kl} \in N_r(i,j)} B_{fmax}(i, j, k, l)u_{kl} \quad (1)$$

$$1 \leq i \leq M; 1 \leq j \leq N$$

여기서 $A_{fmin}(i, j, k, l)$, $A_{fmax}(i, j, k, l)$, $B_{fmin}(i, j, k, l)$, $B_{fmax}(i, j, k, l)$ 는 각각 퍼지제한 MIN 템플릿(template), 퍼지제한 MAX 템플릿, 퍼지 feed-forward

MIN 템플릿, 퍼지 feed-forward MAX 템플릿의 원소이다. 그리고 $A(i, j, k, l)$, $B(i, j, k, l)$ 는 각각 제한 템플릿과 feed-forward의 원소이고, 그리고 \bigwedge 와 \bigvee 는 각각 퍼지 AND와 퍼지 OR을 나타낸다. C_{ij} 의 출력방정식은 식(2)와 같다[3].

$$v_{yij}(t) = f(x_{ij}(t)) = \frac{1}{2} (|v_{xij}(t) + 1| - |v_{xij}(t) - 1|) \quad (2)$$

$$1 \leq i \leq M; 1 \leq j \leq N$$

제한 조건(Constraint conditions):

$$|x_{ij}| \leq 1, |u_{ij}| \leq 1, 1 \leq i \leq M; 1 \leq j \leq N \quad (3)$$

파라미터 가정(Parameter assumption):

$$C > 0, R_x > 0$$

$$A(i, j, k, l) = A(k, l; i, j)$$

$$A_{fmin}(i, j, k, l) = A_{fmin}(k, l; i, j)$$

$$A_{fmax}(i, j, k, l) = A_{fmax}(k, l; i, j)$$

$$1 \leq i, k \leq M; 1 \leq j, l \leq N \quad (4)$$

3. 기존 Hausdorff Distance 알고리즘

영상처리기술에서 물체 인식은 중요한 부분을 차지하고 있으며, 많은 연구가 진행되어 왔다. 영상처리기술의 한 분야인 HD 정합은 2차원 물체 정합에 응용되고 있으며, 기준 영상과 비교 영상의 에지점 집합들 사이의 거리값을 계산하는 방법이다. HD 연산의 구성은 양방향성을 가지고 있고, 픽셀 갯수가 각각 N_A 와 N_B 인 점 집합 $A = \{a_1, \dots, a_{N_A}\}$ 와 $B = \{b_1, \dots, b_{N_B}\}$ 사이의 거리값을 계산하는 기존의 HD 척도는 식(5)로 정의된다[5].7

$$H(A, B) = \max(h(A, B), h(B, A)) \quad (5)$$

여기서 $h(A, B)$ 와 $h(B, A)$ 는 점 집합 A와 B 사이의 방향성 HD를 표현한다. 한 점 a로부터 집합 B의 점들에 대한

거리를 $d_B(a) = \min_{b \in B} \|a - b\|$ 로 나타내고, 한 점 b 로부터 집합 A 의 점들에 대한 거리를 $d_A(b) = \min_{a \in A} \|b - a\|$ 로 정의하면, 방향성 HD, $h(A, B)$ 와 $h(B, A)$ 는 각각 식(6)과 식(7)으로 정의된다[5].

$$h(A, B) = \max_{a \in A} d_B(a), \quad (6)$$

$$h(B, A) = \max_{b \in B} d_A(b) \quad (7)$$

$\|\cdot\|$ 는 유클리디안(Euclidean) norm 또는 L2를 나타낸다. 그러나 이 기존의 HD 척도는 잡음이나 겹침 등의 영상 훼손에 민감하므로, 물체 정합을 위한 개선된 HD 척도들이 제안되었다. 그래서 Huttenlocher 등[6]은 잡음에 의해 손상되었거나 겹쳐 있는 정합을 위한 유사도 측정을 위해서 partial HD 척도를 사용하여 물체 정합을 수행하였다. 이 척도는 손상된 물체의 나머지 부분의 유사도를 판단하도록 고려하였으며, Partial HD의 방향성 HD $h_K(A, B)$ 는 식(8)과 같이 정의된다[5].

$$h_K(A, B) = K \max_{a \in A} d_B(a) \quad (8)$$

여기서 $K \max_{a \in A}$ 는 순차적으로 정렬된 $d_B(a)$ 값의 집합들 중에 K 번째에 해당하는 순서의 값을 나타낸다. 이 척도에서 물체의 훼손된 정도에 따른 물체의 유사도 판단을 위하여 partial fraction f 를 정의했는데 f 는 0부터 1사이의 값을 갖고, $K = fN_A$ 로 주어진다. 이는 rank-min 거리를 사용하는 방법으로 부분적으로 훼손된 물체의 정합시 좋은 성능을 나타낸다. 그러나 이것은 파라미터에 의해 정합 성능이 크게 좌우되므로 적절한 파라미터를 결정하는 것이 중요한 문제가 된다. 그래서 Azencott 등[6]은 잡음 등으로 인한 영상의 훼손 문제를 해결하기 위하여 partial HD의 수정된 형태인 Censored HD(CHD)를 제안하였다. CHD의 방향성 HD $h_{CHD}(A, B)$ 는 식(9)로 정의된다[6].

$$h_{CHD}(A, B) = K \max_{a \in A} L \max_{b \in B} \|a - b\| \quad (9)$$

여기서 $K \max_{a \in A}$ 는 순차적으로 나열된 $L \max_{b \in B} \|a - b\|$ 값들 중에서 K 번째에 해당하는 값을 나타내고, $L \max_{b \in B}$ 는 순차적으로 나열된 유클리안 거리값 $\|a - b\|$ 의 L 번째의 값을 나타낸다. 여기서는 영상의 훼손 정도에 따른 유사도 판단을 위해 파라미터 β, γ 를 정의했는데, β 는 0부터 1사이의 값을 갖고 $K = \beta N_A$ 로 주어지며, γ 는 0부터 1사이의 값을 갖고 $L = \gamma N_B$ 로 주어진다. 그러나 이는 정합시 잡음에 덜 민감하지만 1개의 파라미터를 갖는 partial HD에 비해 2개의 파라미터를 사용하기 때문에 많은 계산량을 처리하기 위해 많은 시간을 필요로 한다. 그래서 Dubuisson과 Jain[8]은 $d_B(A, B)$ 의 거리값들을 평균낸 형태의 MHD(Modified HD)를 제안하여 4가지 형태의 잡음에 의해 손상된 합성 영상들에 대해 실험하였다[7]. MHD의 방향성 HD $h_{MHD}(A, B)$ 는 식(10)으로 정의된다[7].

$$h_{MHD}(A, B) = \frac{1}{N_A} \sum_{a \in A} d_B(a) \quad (10)$$

MHD는 Partial HD가 1개의 파라미터와 CHD가 2개의 파라미터를 갖는 것에 반해 파라미터가 없는 것이 장점이다.

그러나 이 방법은 실제 임펄스 잡음을 포함한 이진 영상에 대해서는 좋은 성능을 보이지 않았다. CHD를 제외한 partial HD와 MHD는 HD값을 구하기 위해서는 픽셀 연산자에 의해 얻어진 모델 영상과 비교 영상의 한 점으로부터 점 집합에 대한 최소 거리는 아래 식(11)과 같은 계산과정이 필요하다.

$$d_B(a) = \min_{b \in B} \|a - b\|, \quad d_A(b) = \min_{a \in A} \|b - a\| \quad (11)$$

이 과정은 매우 간단한 연산에 의해 가능하지만 양방향성 특성에 따라 많은 계산량을 필요로 한다. 그래서 본 논문에서는 잡음이나 훼손된 물체의 정합에 좋은 성능을 나타내는 robust HD 척도 중 잡음이나 훼손된 영상을 복원하기 위해, Breakdown point를 개선시키기 위한 least median square(LMedS)의 변형인 Least Trimmed Square(LTS)[9]에 α -Trimmed를 적용한 α -LTSHD를 제안한다.

4. 개선된 α -LTSHD 알고리즘

FCNN에서 국부(local)해에 빠질 우려가 있는 단일 연산을 구조적 원소로 확장하여 전체적인 구조로 해결을 할 수 있다. 그리고 영상처리에 있어서 구조적인 원소의 크기가 큰 원소를 가지는 연산은 회로 구현하기가 어렵고, 국부 해에 빠질 우려가 있다. 또한 템플릿을 사용할 때에는 결과 영상의 전체적인 그레이 레벨 값이 낮아지는 단점을 가지고 있다. 그래서 위와 같은 단점을 해결하기 위하여 FCNN의 연산 특징인 반복성과 정합 연산자인 HD 연산을 수행함으로 구조적 원소를 분해하여 원소의 크기를 변형함으로써 해결할 수 있다. HD는 물체 모델과 비교 영상의 픽셀 점 집합들 사이의 거리값을 계산하는 척도로서 FCNN의 연산 반복성 구조를 이용하여 연산을 수행하였다. 본 논문은 HD를 연산하는 과정에서 발생하는 Breakdown point를 개선하기 위해 Least median square(LMS)의 변형인 Least trimmed square(LTS)[8]에 α -trimmed를 적용한 α -Least trimmed square(LTS)를 제안한다. 여기서 LTS의 목적 함수는 식(12)와 같다.

$$O = \sum_{i=1}^n (r_i^2)_{i:n} \quad (12)$$

여기서 목적함수의 목적은 식(12)을 최소화시키는데 있는 데 O 함수는 대칭형인 유한 양수 함수로 $r_i = 0$ 일 때, 최소값을 가진다. O 함수가 좌우 대칭이므로 r^2 은 $|r|$ 과 같다고 할 수 있다. 그래서 O 함수에서 $|r| \leq \tau$ 와 같은 범위이면 $|r|$ 이고, $|r| > \tau$ 와 같은 조건이면 τ 가 된다. 여기서 τ 는 outlier를 제거 할 수 있는 문턱값이다. 이 함수를 최소화하는데 $(r_i^2)_{1:n} \leq (r_i^2)_{2:n} \leq \dots \leq (r_i^2)_{n:n}$ 는 순서적으로 배열되고, LTS는 순차적으로 나열된 오차값들 중에서 오차가 큰 부분을 제거시킨 후 나머지 오차를 최소화시키는 방법이다. 본 논문에서 제안된 α -LTS는 순차적으로 나열된 오차값이 큰 부분을 α 비율만큼 전체의 길이 N_A 에서 제거하고 나머지 오차를 최소화시키는 방법으로 이용하였다. 즉 원소의 크기를 변형하는 방법으로 오차를 최소화하는 것이다. 여기서 α -LTS의 목적 함수는 식(13)과 같다.

$$O = \sum_{i=1}^n (|r_i|)_{i:n} \quad (13)$$

여기서 이 함수를 최소화하는데 $(|r_i|)_{1:n} \leq (|r_i|)_{2:n} \leq \dots \leq (|r_i|)_{n:n}$ 는 순서적으로 배열된다. 먼저 α 만큼 일부를 제거하고 나머지에서 모든 계산을 전개한다. 그리고 α -LTSHD의 방향성 거리 $h_{\alpha-LTS}(A, B)$ 는 순차 상태의 선형 결합으로 식(14)와 같다.

$$h_{\alpha-LTS}(A, B) = \frac{1}{(1-f)(N_A-\alpha)} \sum_{i=1}^n d_B(a)_i \quad (14)$$

여기서 α 는 제거되는 오차의 비율로써, 0부터 N_A 사이의 값을 갖게 된다. 만약 α 와 f 가 0을 취하면 MHD와 같은 값을 얻게된다. n 은 $N_A-\alpha$ 의 크기를 나타내며, $d_B(a)_i$ 는 순차적으로 나열된 거리 값 $d_B(a)_1, d_B(a)_2, \dots, d_B(a)_n$ 중에서 i 번째의 거리 값을 나타낸다. 파라미터 f 는 partial fraction을 나타내는 변수로써 0부터 1사이의 값을 갖고, 훼손이나 잡음의 정도에 따라 결정되고, $(1-f)$ 는 입력 데이터에 포함된 outlier의 확률이 $1-f$ 일 때까지 빠른 추정을 할 수 있다는 것을 의미한다. 이것에 대한 이론적 해석은 기존의 robust statistics에서 증명되었다[8]. 그리고 HD 연산자를 FCNN에 적용하기 위하여 E는 $[0, 1]$ 로 정규화하고, α -LTSHD를 적용하기 위한 FCNN은 식(15), (16)과 같은 변수의 값을 갖는다.

$$\begin{aligned} A=0, B=0, I=0, \\ A_{fmin}=undefined, A_{fmax}=undefined, \\ B_{fmax}=undefined, B_{fmin}=-S_{\alpha-LTS} \end{aligned} \quad (15)$$

$$f_y(x) = f(v_{xij}(t)) = \frac{1}{2} (|v_{xij}(t)+1| - |v_{xij}(t)-1|), \quad t \in [0, 1] \quad (16)$$

여기서 $S_{\alpha-LTS} = \{-t : t \in S\}$ 이다.

5. 모의 실험 분석

그림 2에서 전체적인 그레이 레벨 값(gray level value)은 낮아지고, 국부적인 해에 빠질 우려가 있는 단점을 극복하기 위하여 α -LTSHD를 FCNN의 구조에 적용한 것이다. 또한 영상 잡음 제거를 위한 흐름도로써 $n(n+1)/2$ 개의 α -LTSHD와 $n-1$ 개의 min 필터로 구성되었으며, 선형적으로 구조적 원소가 증가되고 입력 영상의 크기에 상관없이 전체적인 구조는 병렬구조와 파이프라인 형식으로 구성하였다. 각각의 윈도우는 3×3 윈도우 영상을 사용하였다. 그림 3(a)는 모의 실험에서 사용한 256×256 영상인 Lena의 원 영상으로 가로, 세로, 대각선에 대한 에지를 알기 위해서 적용하였다. 그림 3(b)는 lenna 영상에 5% 임펄스 잡음을 인가한 영상이고, 그림 3(c)는 10% 임펄스 잡음을 인가한 영상이다. 그림 4는 기존 FCNN을 적용한 결과 영상이고, 그림 5는 본 논문에서 제안한 α -LTSHD를 적용한 FCNN의 모의 실험을 한 결과 영상이다. 또한 그림 6은 각 알고리즘을 잡음 별로 모의 실험을 한 결과를 그래프로 나타낸 것으로, MSE는 다른 알고리즘(기존 FCNN)에 비해 제안한 알고리즘이 약 30.3424 ~ 30.8276이 적음을 확인하였고, SNR은 약 3.3479 ~ 3.6558이 크다는 것을 확인 할 수 있었다. 여기서 제안한 α -LTSHD를 적용한 FCNN 알고리즘은 기존 FCNN보다 영상의 에지 부분의 블러링 제거효과 및 영상의 복원 능력이

우수함을 표 1, 표 2, 그림 4, 5, 6에서 확인 할 수 있다.




그림 2. α -LTSHD를 적용한 FCNN 구조
Fig. 2 The FCNN structure applying α -LTSHD




그림 3. 원 영상과 잡음을 포함한 영상 : (a) lenna의 원 영상, (b) 5%의 잡음 영상, (c) 10%의 잡음 영상

Fig. 3 The original image and images included noise : (a) Original image of lenna, (b) Noise image of 5%, (c) Noise image of 10%




그림 4. 형태학 연산자를 적용한 기존 FCNN의 결과 영상 : (a) 5% 잡음에 대한 결과 영상, (b) 10% 잡음, (c) 20% 잡음

Fig. 4 Results image of the conventional FCNN applying the morphological operator : (a) Result image for 5% noise, (b) 10% noise, (c) 20% noise




그림 5. 제안한 α -LTSHD 연산자를 적용한 FCNN의 결과 영상 : (a) 5% 잡음에 대한 결과 영상, (b) 10%

Fig. 5 Results image of FCNN applying the proposed α -LTSHD operator : (a) Result image for 5% noise, (b) 10% noise, (c) 20% noise

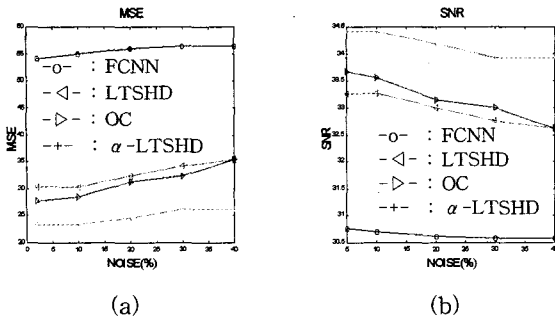


그림 6. Lenna 영상에서의 각 알고리즘에 대한 분석 : (a) MSE, (b) SNR

Fig. 6 Analysis for each algorithms in lenna image : (a) MSE, (b) SNR

표 1. Lenna 영상에서의 각 알고리즘과 임펄스 잡음별 MSE 와 SNR

Table. 1 MSE and SNR for between each algorithms and impulse noises in lenna image

알고리즘 \ 잡음비율		5%	10%	20%	30%
		MSE	SNR	MSE	SNR
FCNN	MSE	54.1732	54.9419	55.9569	56.4620
	SNR	30.7588	30.6976	30.6181	30.5791
LTSHD	MSE	30.4808	30.5568	32.3112	34.1448
	SNR	33.2564	33.2341	33.0031	32.7634
OC	MSE	27.7061	28.4302	31.2553	32.3228
	SNR	33.6709	33.5589	33.1474	33.0016
α -LTSHD를 적용한 FCNN	MSE	23.3456	23.3559	24.5420	26.1196
	SNR	34.4146	34.4127	34.1976	33.9270

표 2. Camera 영상에서의 각 알고리즘과 임펄스 잡음별 MSE

Table 2. MSE for between each algorithms and impulse noises in camera image

알고리즘 \ 잡음비율		5%	10%	20%	30%
		MSE	SNR	MSE	SNR
FCNN	MSE	49.0047	50.1389	50.4543	52.6621
	SNR	30.7588	30.6976	30.6181	30.5791
LTSHD	MSE	26.1513	26.1823	26.3221	27.0812
	SNR	33.2564	33.2341	33.0031	32.7634
OC	MSE	20.8453	21.2238	21.4442	22.7579
	SNR	33.6709	33.5589	33.1474	33.0016
α -LTSHD를 적용한 FCNN	MSE	18.5834	19.3275	19.8867	20.2937
	SNR	34.4146	34.4127	34.1976	33.9270

6. 결 론

본 논문은 α -LTSHD를 적용한 FCNN 구조를 제안하였고, 또한 이 제안된 알고리즘과 기존 FCNN과 OC, LTSHD를 비교하여 제안된 알고리즘이 영상 복원인 필터링에 대해 우수함을 확인하였다. 기존 FCNN은 전체적으로 그레이 레벨 값이 낮아지고, LTSHD는 복잡한 연산 수행을 하는 단점을 가지고 있다. 그래서 α -LTSHD 연산을 FCNN에 적용하

여 전체적인 그레이 레벨 값을 원 영상과 거의 같은 값을 얻었고, 복잡한 연산 수행을 FCNN 구조인 파이프라인을 이용하여 복잡도를 해결하였다. 그리고 MATLAB을 이용한 컴퓨터 모의 실험을 통하여 lena 영상에서는 기존 FCNN보다 본 논문에서 제안한 α -LTSHD 연산자를 적용한 FCNN이 그림 6과 표 1에서와 같이 MSE가 약 30.3424~30.8276 정도 그리고 camera 영상에서는 약 30.4215~32.3684 정도 임펄스 잡음 제거에 더 우수함을 확인하였다.

앞으로는 α -LTSHD를 적용한 FCNN 알고리즘은 영상의 복원 및 정합 필터링에 사용될 수 있을 것이라 사료된다.

참 고 문 헌

- [1] M. Brucoli, L. Carnimeo, and A. Dingankar, "Discrete-Time Cellular Neural Networks for Associative Memories with Learning and Forgetting Capabilities," *IEEE Trans on Circuits and Systems*, Vol. 42, No. 7, pp. 396-399, July, 1995.
- [2] L. O. Chua and L. Yang, "Cellular neural networks: Theory," *IEEE Trans. Circuits Syst.*, Vol. 35, pp. 1257-1272, Oct. 1988.
- [3] T. Yang and L.-B. Yang, "The Global Stability of Fuzzy Cellular Neural Network," *IEEE Trans on Circuits and Systems*, Vol. 43, No. 10, pp. 880-883, Oct. 1996.
- [4] G. Borgefors, "Hierarchical chamfer matching," *IEEE Trans. Pattern Anal, Machine Intell.*, Vol. PAMI-10, No. 6, pp. 849-865, Nov. 1988.
- [5] D. P. Huttenlocher, G. A. Klauerman, and W. J. Rucklidge, "Comparing images using the Hausdorff distance," *IEEE Trans, Pattern Anal. machine Intell.*, Vol. PAMI-15, No. 9, pp. 850-863, Sep. 1993.
- [6] R. Azencott, F. Durbin, and J. Paumard, "Multiscale identification of buildings in compressed large aerial scenes," in *Proc. 13th Int. Conf. Pattern Recognition*, Vol. 3, pp. 974-978, Vienna, Austria, Aug. 1996.
- [7] M. P. Dubuisson and A. K. Jain, "A modified Hausdorff distance for object Matching," in *Proc. 12th Int. Conf. Pattern Recognition*, pp. 566-568, Jerusalem, Israel, Oct. 1994.
- [8] P. J. Rousseeuw, "Least median of squares regression," *Journ. American Statistical Association*, Vol. 79, No. 388, pp. 871-880, Dec. 1984.

저 자 소 개



변오성

1997년 원광대학교 전자공학과 졸업.
1998년~2000년 동 대학원 전자공학과
석사졸업
2000년~현재 동 대학원 전자공학과
박사과정

관심분야 : 퍼지 이론, 신경회로망,
유전알고리즘, 영상처리, 컴퓨터 비전, 러프집합이론등

Phone : 063-850-6883
Fax : 063-855-1798
E-mail : boss@wonkwang.ac.kr

문성룡(Moon Sung Ryong)

2000, vol. 10, no. 6 참조
Phone : 063-850-6883
E-mail : srmoon@wonkwang.ac.kr