

Self-Organizing Neural Network를 이용한 임펄스 노이즈 검출과 선택적 미디언 필터 적용

論 文

54D-3~5

Impulse Noise Detection Using Self-Organizing Neural Network and Its Application to Selective Median Filtering

宋 昇珉[†] · 李鍾浩^{*} · 董聖秀^{**} · 魏載环^{***}

(Seung Min Song · Chong Ho Lee · Sung Soo Dong · Jae Woo Wee)

Abstract – Preserving image features, edges and details in the process of impulsive noise filtering is an important problem. To avoid image blurring, only corrupted pixels must be filtered. In this paper, we propose an effective impulse noise detection method using Self-Organizing Neural Network(SONN) which applies median filter selectively for removing random-valued impulse noises while preserving image features, edges and details. Using a 3×3 window, we obtain useful local features with which impulse noise patterns are classified. SONN is trained with sample image patterns and each pixel pattern is classified by its local information in the image. The results of the experiments with various images which are the noise range of 5~15% show that our method performs better than other methods which use multiple threshold values for impulse noise detection.

Key Words : Median Filter, Impulse Noise Detection, Pattern Classification, Self-Organizing Neural Network(SONN)

1. 서 론

현재는 디지털 정보 사회이고 영상은 중요한 정보의 매체이다. 인간은 기본적으로 감각 기관을 통하여 정보를 받아들이고 이를 처리하는데 그 중에서도 시각은 가장 고도의 감각으로서 시각정보의 비중은 대단히 높다.

사람이 직접 영상을 얻지 않고 기계로부터 획득한 영상을 눈으로 보거나 또는 기계가 영상을 획득하고 처리할 때 주변 환경, 기계의 전기적인 센서의 결합 또는 획득한 영상의 전송과 저장 과정에서 예기치 못한 영상에서의 원하지 않는 방해물 즉 노이즈가 존재하게 된다. 영상 복원(image restoration)은 이상과 같은 상황에서 원본 영상에 더욱 가깝게 복원하는 객관적인 과정이고 영상 향상(image enhancement)은 영상 정보를 더 효과적으로 이해하기 위한 주관적인 과정으로 이 두 가지를 영상 전처리라고 한다.

디지털 영상에서 노이즈의 형태는 여러 가지로 나타날 수 있으며 임펄스 노이즈(impulse noise)의 경우는 대표적인 비선형 공간(spatial) 필터 알고리즘인 미디언 필터[1]를 사용하여 제거할 수 있다. 미디언 필터는 평균값(mean) 필터보다 영상을 덜 흐려지게 하면서도 좋은 임펄스 노이즈 감소 능력을 제공하지만 역시 임펄스 노이즈의 제거 과정에서 영상의 흐려짐(blur)을 피할 수는 없다. 영상 분석의 방해물인 임펄스 노이즈는 감소시키지만 영상에서의 중요한 특징(feature) 정보인 윤곽선과 섬세함이 흐려지는 것은 정확한 영상 분석

을 어렵게 할 수 있다.

임펄스 노이즈 제거 효과는 유지하면서 영상의 흐려지는 단점을 보완하기 위해 처리 원도우의 중앙 픽셀에 가중치를 두는 중심부 가중 미디언 필터(center-weighted median filter, CWM)[2]는 기존 알고리즘 보다 향상된 영상 복원 성능을 보여주었다. 최근에는 모든 픽셀에 대하여 처리하지 않고 임펄스 노이즈를 검출하여 선택적으로 적용하는 보다 효과적인 방법들이 발표되고 있다. 임펄스 노이즈 검출에는 여러 방법들이 제안 되고 있으며 특징적 형태인 고정치(fixed-value) 임펄스 노이즈만을 대상으로 하는 경우[3][4]와 보다 일반적 형태인 임의치(random-value) 임펄스 노이즈를 대상으로 처리하는 경우[5][6]가 있다. 앞에서 언급한 방법들은 하나 또는 그 이상의 다중 문턱값에 기초하여 임펄스 노이즈를 검출하고 선택적으로 미디언 필터를 적용하거나 미디언 필터 알고리즘에서 파생된 필터들을 적용한다. 사람의 시각을 통해서 임펄스 노이즈 픽셀을 보면 주변 픽셀과의 관계가 정상 픽셀과는 다르게 보이듯이 픽셀과 주변과의 관계로부터 특징 정보를 추출하면 임펄스 노이즈 검출은 패턴 분류의 문제가 된다.

본 논문에서는 임의치 임펄스 노이즈 검출을 위하여 Self-Organizing Neural Network(SONN)[7]를 이용하는 방법을 제안한다. SONN은 영상의 지역적 정보로부터 정상 픽셀 패턴들과 임펄스 노이즈 픽셀 패턴들을 분류해 주며 검출된 임펄스 노이즈는 미디언 필터를 적용해서 제거하였다.

2. 본 론

2.1 임펄스 노이즈 모델

디지털 영상에서 노이즈의 주요한 인자는 영상 획득 또는

[†] 교신저자, 學生會員 : 仁荷大 工大 情報通信工學科 碩士
E-mail : dukefirst@hanmail.net

^{*} 正 會 員 : 仁荷大 工大 情報通信工學部 教授 · 工博

^{**} 正 會 員 : 龍仁松潭大 디지털電子情報科 教授 · 工碩

^{***} 正 會 員 : 仁荷大 工大 電氣工學科 工碩

接受日字 : 2004年 11月 26日

最終完了 : 2005年 2月 17日

전송과정에서 발생한다. 영상 센서의 성능은 영상 획득과정에서 환경조건과 같은 다양한 원인, 또는 CCD(charge-coupled device)같은 센싱 소자 자체의 품질에 의해 영향을 받고 전송 과정에서는 전송을 위해 사용된 채널에서의 간섭으로 인하여 발생하기도 한다. 임펄스 노이즈는 8비트 그레이 스케일 영상에서 0(검은색-pepper) 또는 255(흰색-salt)의 두 가지 극값 형태로 발생하는 고정치 임펄스 노이즈(salt and pepper noise)가 있고 임펄스 노이즈의 값이 무작위적인 임의치 임펄스 노이즈가 있다. 본 논문에서는 더 일반적인 형태인 임의치 임펄스 노이즈 모델에 대해서 다루도록 한다.

$v(n)$ 은 원본 영상의 픽셀 값이고, 영상의 픽셀들이 확률 p_e 만큼 0부터 255사이의 임의의 값($\eta(n)$)으로 임펄스 노이즈가 존재할 때 임펄스 노이즈가 있는 영상의 픽셀 값 $x(n)$ 은 식(1)과 같이 표현된다.

$$x(n) = \begin{cases} v(n), & \text{with probability } 1-p_e \\ \eta(n), & \text{with probability } p_e \end{cases} \quad (1)$$

2.2 미디언 필터

미디언 필터는 공간영역에서의 영상 복원 방법으로 어떤 픽셀 주변에 있는 제한된 공간영역의 모든 픽셀들을 명암도 값으로 정렬하고 중간값(median)으로 대치하는 것으로 차수 통계(order-statistics) 필터의 한 종류이며 비선형적인 처리 특성을 보인다. 출력을 y 로 표현할 때 식(2)로 표현되며 x_i 는 공간영역내의 픽셀들이다.

$$y = \text{median}(x_1, x_2, x_3, \dots, x_n) \quad (2)$$

그림 1은 영상에서 슬라이딩 윈도우를 통하여 미디언 필터를 처리하는 과정이다. 중앙에 있는 픽셀을 중심으로 주변 3×3 윈도우를 적용하면 중간값은 35이다. 현재 중앙 픽셀(60)을 지역적 중간값인 35로 대치시킨다.

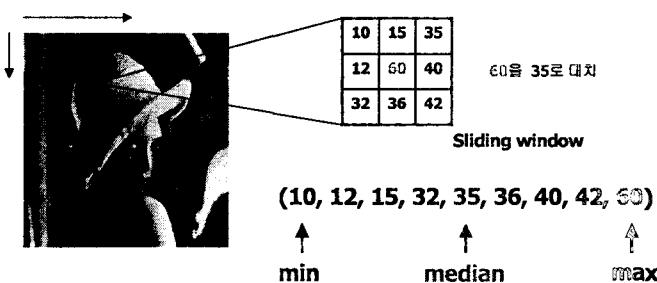


그림 1 3×3 윈도우를 이용한 미디언 필터

Fig. 1 Median filtering using 3×3 window

2.3 SONN

태어난 지 얼마 되지 않은 아기가 눈의 초점 맞추기를 배우는 과정을 생각해 보면, 이 기능은 타고나지 않았지만 아기

가 눈에 보이는 자극과 물체 및 모양들을 서로 연관시키는 방법들을 자연스럽게 배워서 그러한 능력을 갖게 된다. 1981년 편란드의 헬싱키 공과대학의 튜보 코호넨(Teuvo Kohonen)에 의해 제안된 SONN은 카펜터(G. A. Carpenter)와 그로스버그(S. Grossberg)의 ART(Adaptive Resonance Theory)[8]와 함께 비교사 신경망(unsupervised neural network)의 대표적인 모델이다. 자기 조직화(self-organizing) 학습 과정에서 입력 패턴에 대하여 원하는 출력이 나오도록 네트워크를 구성하는 것이 아니라 자기 스스로 학습하여 네트워크를 구성할 수 있는 능력을 말하며 이것은 신경 생리학적인 시스템을 본 따서 모델링한 것이다.

2.3.1 SONN의 경쟁 학습(competitive learning)

코호넨의 SONN은 입력층과 출력층 또는 코호넨층으로 불리는 2개의 층으로 그림 2와 같이 입력층의 뉴런들이 코호넨 층의 모든 뉴런들에 완전 연결(fully connected)되어 있다.

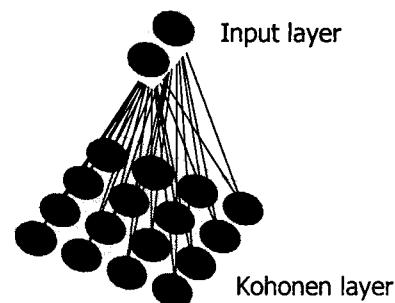


그림 2 SONN의 구조

Fig. 2 Structure of SONN

여기서 주목할 사항은 다른 신경망과 달리 출력층 즉 코호넨층이 뉴런들의 2차원 형식으로 구성되어 학습 과정에서 입력 패턴에 대하여 코호넨층의 각 뉴런들이 서로 경쟁을 해서 입력 패턴에 가장 가까운 뉴런이 승리하고 승리한 뉴런(winner neuron)과 인접한 뉴런들만이 제시된 입력에 대하여 학습이 허용된다. 그리고 실제 네트워크가 동작할 때에는 승자 독점(winner take all)으로 승자 뉴런만이 출력 신호를 보낼 수 있다.

2.3.2 SONN의 학습 규칙

SONN의 기본 학습 알고리즘은 자율 학습과 경쟁 학습이다. 그림 3은 SONN의 학습 알고리즘 흐름도이며 본 논문의 실험에 사용된 세부적인 규칙들에 대하여 기술할 것이다.

연결강도의 초기화(Weight initialize) : 입력 층의 각 뉴런들은 코호넨층의 뉴런들과 완전 연결되어 있으며 연결강도 (w)는 학습이전에 0과 1사이의 임의의 값으로 초기화 된다.

$$w_{i, n \rightarrow k, (x, y)}(0) = \text{Random}(0, 1) \quad (3)$$

식(3)에서 연결강도의 $i, n \rightarrow k, (x, y)$ 는 입력층 (i) 뉴런 n 에서 코호넨층 (k) 2차원 뉴런 (x, y) 으로의 연결 관계를 나타낸다.

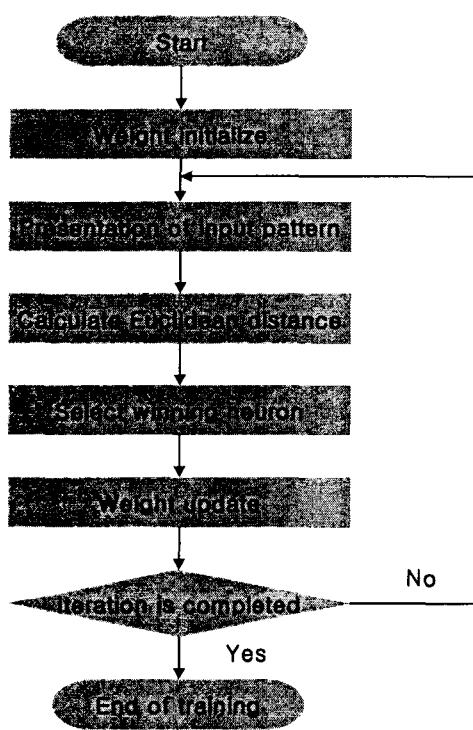


그림 3 SONN 학습 알고리즘 흐름도
Fig. 3 SONN training algorithm flow

새로운 입력 패턴 제시(Presentation of input pattern) : 자을 학습에 필요한 학습 패턴을 제시한다.

제시된 입력 패턴에 대한 모든 뉴런들의 유사도 계산(Calculate Euclidean distance) : 입력 패턴에 대한 코호넨층 각 뉴런들의 유사도를 계산하기 위해서 유클리디안 거리를 구한다.

$$Dist_{(x, y)}(t) = \sqrt{\sum_{n=1}^m (p_{i, n}(t) - w_{i, n \rightarrow k, (x, y)}(t))^2} \quad (4)$$

식(4)에서 m 은 입력층의 크기이고, p 는 입력층에 제시되는 패턴집합이다.

승자 뉴런의 선택(Select winner neuron) : 제시된 입력 패턴에 대하여 가장 유사한 뉴런 즉 유클리디안 거리가 가장 작은 뉴런을 선택한다. 학습 과정에서는 승자 뉴런과 인접한 뉴런들만 입력 패턴에 대해서 학습 기회를 부여하고 실제 네트워크가 동작할 때에는 출력 뉴런을 결정하는 과정이다.

$$\text{Winning Kohonen neuron } (t) = \min(Dist_{x, y}(t)) \quad (5)$$

승자 뉴런과 인접 뉴런의 연결강도 재조정(Weight update) : 코호넨층 2차원 뉴런들 중에서 승자 뉴런과 인접 뉴런들에 대하여 연결강도를 재조정한다.

$$w_{i, n \rightarrow k, (x, y)}(t+1) = w_{i, n \rightarrow k, (x, y)}(t) + \beta(t)(p_{i, n}(t) - w_{i, n \rightarrow k, (x, y)}(t)) \quad (6)$$

식(6)에서 β 는 학습률로 현재 (t)의 학습률은 총 반복 학습 횟수 (Q)와 초기 학습률 ($\beta_{initial}$), 최종 학습률 (β_{final})의 식(7)로 표현할 수 있다.

$$\beta(t) = \beta_{initial} - \frac{t}{Q}(\beta_{initial} - \beta_{final}) \quad (7)$$

그리고 학습할 승자 뉴런의 반경 (R)은 초기 인접 반경 ($H_{initial}$)에서 전체 학습 패턴을 특정 횟수만큼 반복 학습하면서 1씩 감소시켜 최종적으로 승자 뉴런에 대해서만 학습하도록 설정한다[9].

2.4 SONN의 구성과 학습

사람의 눈으로 영상을 볼 때 임펄스 노이즈는 주변 픽셀과의 어울림 여부로 판단할 수 있다. 따라서 그림 4와 같이 현재 관심을 가지는 픽셀(C) 주변의 2차원 영역을 설정하고 중앙 픽셀을 포함하는 4개의 직선 즉 수직, 수평, 그리고 양사선의 평균값과 중앙 픽셀의 차이 값을 입력으로 하여 정상 픽셀과 임펄스 노이즈 픽셀로 패턴 분류를 시도하였다.

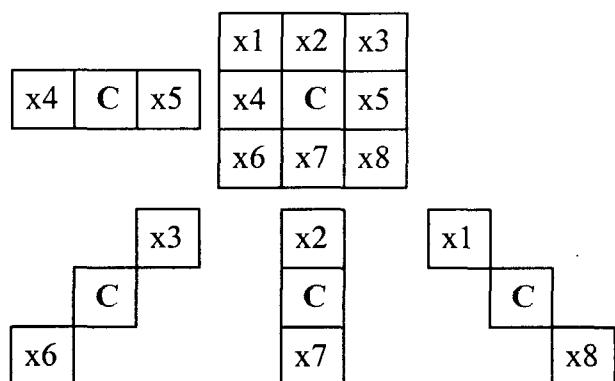


그림 4 2차원 영역에서 지역적 정보 추출

Fig. 4 Local information extraction from 2-dimension region

2.3.2절에서 제시된 학습 규칙을 적용하기 위한 여러 파라미터 값은 표 1과 같다. 표 1의 여러 파라미터 값들은 그림 4에서와 같은 지역적 정보를 추출하여 SONN의 입력값으로 사용하기 위해 먼저 입력층 크기를 결정한 상태에서 기타 파라미터 값들을 가변시키면서 얻은 실험적인 결과 값이다.

표 1 SONN의 학습 파라미터

Table 1 Parameters for training of SONN

파라미터 종류	파라미터 값
입력 층 크기	$m=4$
코호넨층 크기	$k, (x=5, y=5)$
초기 학습률	$\beta_{initial}=0.5$
최종 학습률	$\beta_{final}=0.02$
초기 인접 반경	$H_{initial}=3$
인접 반경 감소 횟수	$Q=1000$
총 학습 횟수	$Q=3000$

학습 패턴은 256×256 크기의 8비트 그레이 스케일 Lena 영상에서 지역적 정보를 추출할 수 없는 상하좌우의 좌외픽셀을 제외한 254×254 영역에 전체적으로 균일한 10%의 확률로 0에서 255까지의 임의의 값을 가지는 임펄스 노이즈를 발생시켜서 총 64516개의 학습 패턴을 얻었다. 원본 영상과 비교하여 이중에서 중앙 픽셀이 임펄스 노이즈인 패턴은 6432개이고 중앙 픽셀이 정상인 패턴은 58084개이다.

2.5 SONN의 학습 결과

그림 5는 학습을 마치고 전체 패턴에 대한 2차원 코호넨층 각 뉴런의 승리횟수 분포를 나타낸 그림이다.

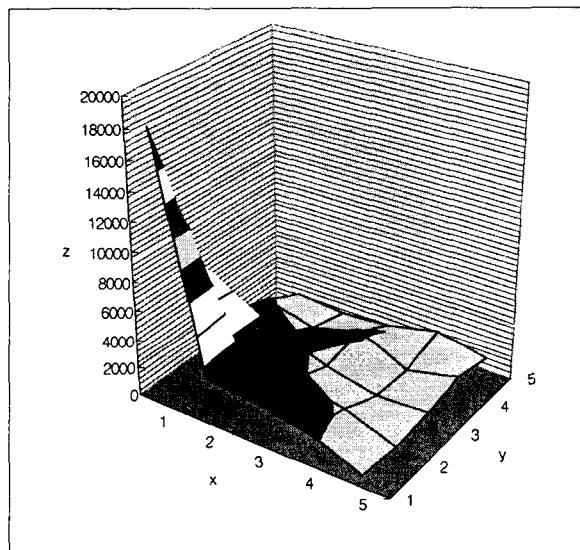


그림 5 전체 학습 패턴(64516개)에 대한 코호넨층 각 뉴런의 승리횟수 분포도

Fig. 5 Distribution chart of each neuron's winning number in Kohonen layer for the whole training patterns(64516)

바닥의 x-y평면에서 각 격자는 코호넨층 하나의 뉴런에 해당하며 z축은 각 뉴런의 승리횟수이다. 그림에서 x-y평면의 좌측영역 즉 (1, 1) 근방에 많은 패턴들이 분류된 것을 알

수 있다. 우리가 알고 싶은 것은 정상 패턴, 그리고 임펄스 노이즈 패턴이 SONN을 통하여 어떻게 분류 되는가이다. 따라서 전체 패턴 중 정상 패턴 58084개에 대한 코호넨층 각 뉴런의 승리횟수 분포도 그림 6과 반대로 임펄스 노이즈 패턴 6432개에 대한 코호넨층 각 뉴런의 승리횟수 분포도 그림 7을 얻을 수 있었다.

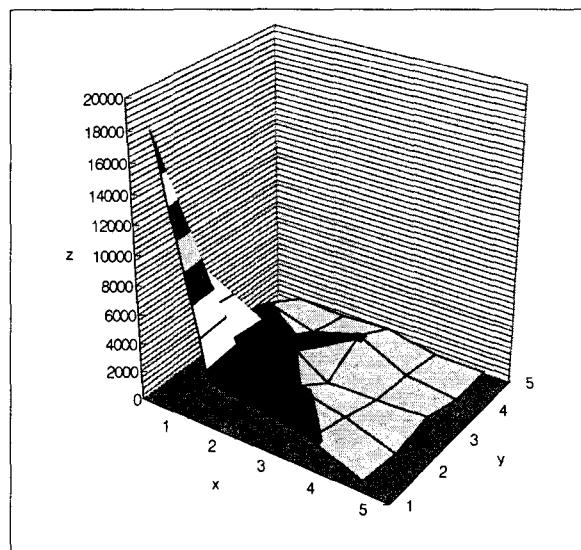


그림 6 정상 패턴(58084개)에 대한 코호넨층 각 뉴런의 승리 횟수 분포도

Fig. 6 Distribution chart of each neuron's winning number in Kohonen layer for the normal patterns(58084)

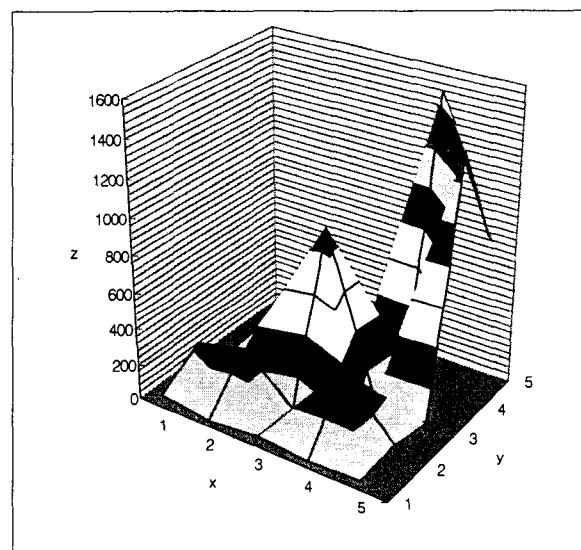


그림 7 임펄스 노이즈 패턴(6432개)에 대한 코호넨 층 각 뉴런의 승리횟수 분포도

Fig. 7 Distribution chart of each neuron's winning number in Kohonen layer for impulse noise patterns(6432)

그림 6의 정상 패턴의 경우 코호넨층 각 뉴런의 승리횟수 분포가 그림 5와 유사하다. 이것은 전체 패턴 중에서 정상

패턴이 차지하는 비율이 높기 때문이며, 그림 7에서처럼 임펄스 노이즈 패턴에 대한 코호넨층 각 뉴런의 승리횟수 분포를 보면 정상 패턴과 상이한 분류 결과를 보여준다. 코호넨층 x-y평면에서 각 뉴런에 대해 정상 패턴의 결과가 좌측영역에 치우쳐 있다면 임펄스 노이즈 패턴은 코호넨층 x-y평면의 우측과 중앙 뉴런에서 많은 승리횟수를 보이며 이것은 전체 임펄스 노이즈 패턴의 70% 이상이다.

그림 8은 코호넨층 각 뉴런의 전체 학습 패턴으로 인해 승리한 횟수 중에서 임펄스 노이즈 패턴으로 인해 승리를 차지한 비율(z')이다. 코호넨층 x-y평면의 (4, 5), (5, 4) 그리고 (5, 5) 뉴런은 100%에 가까운 비율을 보이고 (3, 3) 뉴런은 약 60% 정도의 비율을 보여준다.

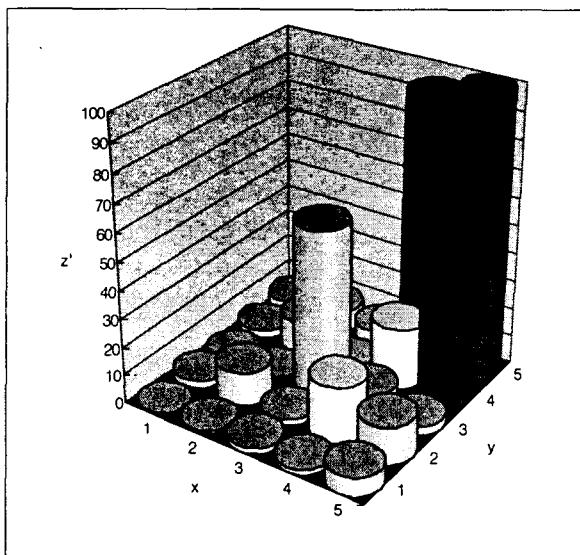


그림 8 각 뉴런에서 전체 학습 패턴(64516개)에 대한 임펄스 노이즈 패턴(6432개)이 차지하는 비율

Fig. 8 Each neuron's percentage of the impulse noise patterns(6432) in the whole train patterns(64516)

2.6 학습된 SONN을 이용한 임펄스 노이즈 검출과 미디언 필터의 선택적 적용

우리는 10%의 임펄스 노이즈가 있는 Lena 영상으로부터 얻은 학습 패턴들을 이용하여 SONN을 학습시켰다.

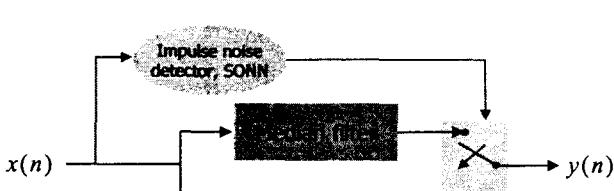


그림 9 선택적 미디언 필터의 구조

Fig. 9 Structure of selective median filter

그림 9는 현재 고려 대상인 픽셀 $x(n)$ 에 대하여 3×3 주변영역 정보를 바탕으로 SONN에서 분류된 결과에 따라 선택적으로 미디언 필터를 적용하는 구조도이다.

서론에서도 언급한 것처럼 기존의 임펄스 노이즈 검출은 실험적으로 얻은 다중 문턱값을 이용하여 임펄스 노이즈를 검출하고 미디언 필터를 적용한다. 전체 학습 패턴에 대한 코호넨층 각 뉴런의 승리횟수 중 임펄스 노이즈 픽셀 패턴의 비율이 50% 이상인 뉴런 4가지 경우에 대해서만 미디언 필터를 수행할 것이며 식(8)처럼 표현할 수 있다. 여기서 $y(n)$ 는 결과 픽셀이고, $\text{median}(u(n))$ 은 $x(n)$ 을 중심으로 하는 3×3 윈도우 영역 $u(n)$ 내의 중간값이다.

$$y(n) = \begin{cases} \text{median}(u(n)), & \text{When } (3, 3), (4, 5), (5, 4) \text{ or } (5, 5) \\ & \text{of SONN Output} \\ x(n), & \text{Otherwise} \end{cases} \quad (8)$$

2.7 실험 및 결과

본 논문에서 제안한 방법과 성능 비교를 위해서, 미디언 필터(Median, 3×3 window)[1], 중심부 가중 미디언 필터(CWM, $w=3$)[2] 그리고 다중 문턱값을 적용하여 임펄스 노이즈를 검출하고 선택적으로 필터링을 하는 기존 방법들(DCWM[5], SD-ROM[6])로도 영상 복원 실험을 하였다. DCWM은 중심부 가중 미디언 값에 다중 문턱값 ($[\delta_0, \delta_1, \delta_2, \delta_3] = [40, 25, 10, 5], 0 \leq \delta \leq 0.6$)을 적용하여 임펄스 노이즈를 검출하는 방법으로 검출된 임펄스 노이즈는 미디언 필터를 사용하여 제거한다. SD-ROM은 순위 평균(rank ordered mean : ROM)값에 다중 문턱값 ($T_1 \in \{4, 8, 12\}$, $T_2 \in \{15, 25\}$, $T_3 = 40$, $T_4 = 50$)을 적용하고 임펄스 노이즈를 검출하며 임펄스 노이즈 제거에는 미디언 알고리즘에서 파생된 ROM 필터를 사용한다. 각 영상 복원 방법들은 반복 수행과 주어진 다중 문턱값을 가변하면서 가장 좋은 영상 복원 성능을 얻은 결과이며 제안한 방법의 적용은 2.4절에서 Lena 영상으로 학습된 SONN을 이용하여 임펄스 노이즈를 검출하고 2.6절과 같은 선택적 미디언 필터를 수행한 결과이다.

영상 복원의 정량적 성능측정을 위해서는 mean square error(MSE)와 peak signal-to-noise ratio(PSNR)를 사용하였다. MSE는 식(9)와 같이 정의되며 N M 는 2차원 영상 크기로서 각각 256이고 x_{ij} , y_{ij} 는 원본 영상과 결과 영상의 2차원 ij 좌표에 해당하는 픽셀 값이다.

$$MSE = \frac{1}{NM} \sum_{i=1}^N \sum_{j=1}^M (y_{ij} - x_{ij})^2 \quad (9)$$

PSNR은 식(10)과 같이 정의된다.

$$PSNR = 10 \log_{10} \left(\frac{\sum_{i=1}^N \sum_{j=1}^M 255^2}{\sum_{i=1}^N \sum_{j=1}^M (y_{ij} - x_{ij})^2} \right) \quad (10)$$

그림 10은 256×256 사이즈의 Lena영상에 대하여 임의치 임펄스 노이즈를 5%부터 40%까지 증가시켜 가면서 각 필터 알고리즘들을 이용하여 영상 복원을 수행한 결과 성능비교 그래프이다.

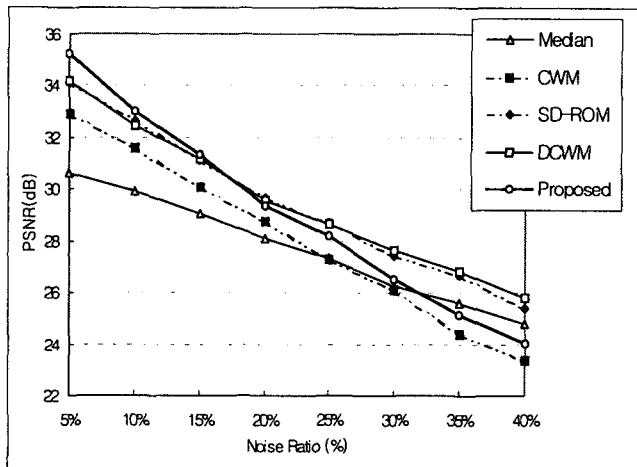


그림 10. 다양한 임의치 임펄스 Lena 영상에 대한 여러 방법들의 성능 비교

Fig. 10. Performance comparison of different methods for filtering the Lena image of various ratio's random-valued impulses

본 논문에서 제안한 방법이 임펄스 노이즈 비율이 비교적 낮은 5%에서 15%까지의 영역에서 좋은 영상 복원 성능을 보여주었다. 그러나 20%이상의 노이즈 비율에서는 영상 복원 성능이 떨어진다. 이것은 제안한 방법이 임펄스 노이즈 검출에 현재 고려중인 픽셀의 주변 정보를 이용하는데 노이즈의 비율이 높을수록 주변 정보가 많이 훼손되어 임펄스 노이즈를 정확히 검출하지 못해 나타나는 것으로 판단된다.

표 2는 그림 11에서 제시된 여러 영상들에 대하여 임펄스 노이즈가 없는 상태에서 각 영상 복원 방법들을 수행한 결과이다. 이 실험은 각 영상 복원 방법이 얼마나 원본 영상을 적게 왜곡하고 충실하게 보존하는가를 파악하기 위한 것이다.



(a) Lena



(b) Baboon

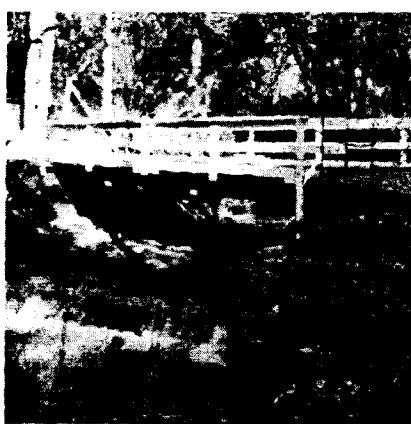


(c) Baboon

표 2 원본 영상에 대한 MSE와 PSNR(dB)

Table 2 MSE and PSNR(dB) for each original image

	Lena		Baboon		Boats		Bridge	
	MSE	PSNR	MSE	PSNR	MSE	PSNR	MSE	PSNR
Median	47.90	31.33	313.39	23.17	127.56	27.07	150.70	26.35
CWM	22.35	34.64	167.03	25.90	66.12	29.93	73.98	29.44
SD-ROM	15.22	36.31	162.36	26.03	57.78	30.51	58.39	30.47
DCWM	14.56	36.50	159.53	26.10	52.18	30.96	54.42	30.77
Proposed	5.30	40.89	129.24	27.02	28.02	33.66	37.80	32.36



(d) Bridge

그림 11 실험에 사용된 원본 영상 : (a) Lena (b) Baboon
(c) Boats (d) BridgeFig. 11 The original images for experiment : (a) Lena (b)
Baboon (c) Boats (d) Bridge

표 3은 그림 11의 여러 실험 영상에 대해서 각각 5%, 10% 그리고 15% 확률로 임의치(0~255) 임펄스 노이즈를 발생시켜 기존 영상 복원 방법과 본 논문에서 제안한 방법으로 수행한 결과이다.

표 3 각 노이즈 영상에 대한 MSE와 PSNR(dB)

Table 3 MSE and PSNR(dB) for each noise image

Noise Ratio	Filters	Lena		Baboon		Boats		Bridge	
		MSE	PSNR	MSE	PSNR	MSE	PSNR	MSE	PSNR
5 %	Median	56.51	30.61	321.26	23.06	138.12	26.73	160.61	26.07
	CWM	33.96	32.90	220.74	24.69	80.44	29.08	92.54	28.47
	SD-ROM	25.24	34.11	201.19	25.09	78.08	29.21	72.15	29.55
	DCWM	24.93	34.16	195.02	25.23	73.50	29.47	69.78	29.69
	Proposed	19.51	35.23	156.12	26.20	52.01	30.97	59.32	30.40
10 %	Median	66.61	29.90	331.41	22.93	148.69	26.41	176.56	25.66
	CWM	45.33	31.57	239.30	24.34	97.12	28.26	113.87	27.57
	SD-ROM	35.14	32.67	221.58	24.68	91.24	28.53	93.38	28.43
	DCWM	35.08	32.44	216.21	24.78	88.87	28.64	94.02	28.40
	Proposed	32.35	33.03	197.27	25.18	76.87	29.27	88.90	28.64
15 %	Median	81.10	29.04	343.27	22.77	166.46	25.92	195.85	25.21
	CWM	64.41	30.04	248.08	24.18	124.94	27.16	141.25	26.63
	SD-ROM	50.02	31.14	245.55	24.23	118.24	27.40	122.41	27.25
	DCWM	49.83	31.16	243.25	24.27	113.14	27.59	123.55	27.21
	Proposed	47.89	31.32	231.04	24.49	100.67	28.10	120.05	27.34

3. 결 론

임펄스 노이즈에 의해 손상된 영상에서 정상 픽셀들은 유지하고 임펄스 노이즈가 발생한 픽셀들에 대해서만 영상 복원 과정을 수행하는 것은 최선의 선택일 것이다. 본 논문에서는 SONN을 이용한 효과적인 임펄스 노이즈 검출 방법을 제안하였다. 제안된 방법은 영상의 지역적 정보로부터 정상 패턴들과 임펄스 노이즈 패턴들을 분류하였으며 임펄스 노이즈 패턴들에 대해서만 선택적으로 미디언 필터를 적용해 손상된 영상을 복원하였다. 여러 영상에 대하여 수행한 실험은 임펄스 노이즈 비율이 비교적 낮은 5%에서 15%까지의 영역에서 기존 다른 방법들에 비하여 우수한 영상 복원 성능을 보여주었다. 그러나 영상의 무한한 다양성과 실제 응용목적 등을 고려한다면 각각의 방법은 나름대로의 장점이 있다고 할 수 있다.

앞으로 SONN을 이용한 임펄스 노이즈 검출의 정확도를 높이기 위해서 효과적인 특징 정보의 추출과 네트워크의 최적화 등이 수행되어야 하며 특히 임펄스 노이즈의 강도가 높은 경우에도 효과적으로 검출할 수 있는 연구가 수행되어야 할 것이다. 또한 실시간 응용을 목적으로 하기 위해서는 본 논문에서 제안된 방법의 하드웨어의 구현에 대한 연구도 되어야 한다.

참 고 문 현

- [1] J. W. Tukey, "Nonlinear (nonsuperposable) methods for smoothing data," In Congr. Rec. EASCON, p. 673, 1974.
- [2] S.-J. Ko and Y. H. Lee, "Center weighted median filters and their applications to image enhancement," IEEE Trans. Circuits and Systems, vol. 38, pp. 984-993, Sept. 1991.
- [3] H.-L. Eng and K.-K. Ma, "Noise adaptive soft-switching median filter," IEEE Trans. Image Processing, vol. 10, pp. 242-251, Feb. 2001.
- [4] I. Aizenberg and C. Butakoff, "Effective impulse detector based on rank-order criteria," IEEE Signal Processing Letters, vol. 11, pp. 363-366, Mar. 2004.
- [5] T. Chen and H. R. Wu, "Adaptive impulse detection using center-weighted median filters," IEEE Signal Processing Letters, vol. 8, pp. 1-3, Jan. 2001.
- [6] E. Abreu and S. K. Mitra, "A signal-dependent rank ordered mean (SD-ROM) filter - A new approach for removal of impulses from highly corrupted image," in Proc. Int. Conf. Acoust. Speech Signal Processing, Detroit, MI, vol. 4, pp. 2371-2374, May 1995.
- [7] T. Kohonen, Self-Organizing Maps, Springer, 2nd Edition, 1997.
- [8] S. Grossberg and G. A. Carpenter, "The ART of adaptive pattern recognition by a self-organizing neural network," IEEE Computer, vol. 21, Mar. 1988.
- [9] J. Rogers, Object-oriented neural networks in C++, Academic Press, pp. 133-171, 1997.

저 자 소 개



송승민 (宋昇珉)

1975년 3월 8일생.
2002년 인하대 전기공학과 졸업.
2005년 동 대학원 정보통신대학원 졸업(공석).
Tel : 032-860-7396, Fax : 032-863-5822
E-mail : dukefirst@hanmail.net



이종호 (李鍾浩)

1953년 4월 14일생.
1976년 서울대 전기공학과 졸업.
1978년 동 대학원 전기공학과 졸업(공석).
1986년 미국 아이오와 주립대 전기 및 컴퓨터 공학과 졸업(공박).
1997년-1982년 해군사관학교 전임강사.
1980년-1982년 국방과학연구소 위촉연구원.
1986년-1989년 미국 노틀담대학교 조교수.
1991년-1993년 대한전기학회 컴퓨터 및 인공지능연구회 간사장.
1994년-1995년 미국 브라운대학교 방문교수.
1997년-1999년 인하대 집적회로설계센터 소장.
1989년-현재 인하대학교 정보통신공학부 교수.
2000년-현재 수퍼지능기술 연구소 소장
Tel : 032-860-7396, Fax : 032-863-5822
E-mail : chlee@inha.ac.kr



동성수 (董聖秀)

1967년 5월 11일생.
1990년 인하대 전기공학과 졸업.
1999년 동 대학원 전기공학과 졸업(공석).
1992년-1995년 나우정밀 연구소 전임연구원.
1996년-2000년 삼성전자 정보통신 선임연구원.
2001년-현재 용인송담대학 디지털정보과 조교수.
Tel : 031-330-9292, Fax : 032-330-9290
E-mail : sdong@ysc.ac.kr



위재우 (魏載玗)

1974년 5월 21일생.
1997년 인하대 전기공학과 졸업.
1999년 동 대학원 전기공학과 졸업(공석).
2005년 동 대학원 전기공학과 졸업(공박).
Tel : 032-860-7396, Fax : 863-5822
E-mail : wizet2000@empal.com