

## 영상 잡음 제거 필터를 위한 퍼지 순환 신경망 연구

변오성\*

### A study on the Fuzzy Recurrent Neural Networks for the image noise elimination filter

Oh-Sung Byun \*

#### 요 약

본 논문은 퍼지를 적용한 순환 신경망을 이용하여 잡음 제거용 필터를 구현하였다. 제안된 퍼지 순환 신경망 구조는 기본적으로 순환 신경망 구조를 이용하여 가중치 및 반복횟수가 일정한 값에 수렴하도록 하였으며, 하이브리드 퍼지 소속 함수 연산자를 적용하여 수학적 계산량 및 복잡성을 단순화하였다.

본 논문은 제안된 퍼지 순환 신경망 구조 필터가 일반적인 순환 신경망 구조 필터보다 평균 0.38dB 정도 영상 복원이 개선됨을 PSNR을 이용하여 증명하였다. 또한 결과 영상 비교에서 제안된 방법을 적용하여 얻은 영상이 기존 방법을 적용하여 얻은 영상보다 원영상과 더 유사함을 확인하였다.

▶ Keyword : 퍼지 소속 함수, 필터, 퍼지 순환 신경망, 시그모이드 함수, 잡음 제거

#### Abstract

In this paper, it is realized an image filter for a noise elimination using a recurrent neural networks with fuzzy. The proposed fuzzy neural networks structure is to converge weights and the number of iteration for a certain value by using basically recurrent neural networks structure and is simplified computation and complexity of mathematics by applying the hybrid fuzzy membership function operator.

In this paper, the proposed method, the recurrent neural networks applying fuzzy which is collected a certain value, has been proved improving average 0.38dB than the conventional method, the generalised recurrent neural networks, by using PSNR. Also, a result image of the proposed method was similar to the original image than a result image of the conventional method by comparing to visual images.

---

• 제1저자 : 변오성  
• 투고일 : 2011. 03. 28, 심사일 : 2011. 04. 11, 게재확정일 : 2011. 05. 16  
\* 현대모비스 기술연구소 (R&D Center, HYUNDAI MOBIS)

▶ Keyword : Fuzzy Membership Function, Filter, Fuzzy Recurrent Neural Networks, Sigmoid Function, Noise Elimination

## I. 서 론

현대 사회는 디지털통신 기술을 기반으로 멀티미디어, 즉 디지털 카메라, 휴대폰, 군장비 등 다양한 영상 시스템이 발전되고 있다. 여기서 사용되는 영상 기술은 데이터의 압축, 전송, 처리, 저장, 인식 그리고 복원등이 기본적으로 포함하고 있다. 이러한 영상 시스템은 특성에 따라서 영상 데이터를 다양하게 처리하는데 있어서 주변의 환경 및 장치의 특성에 따라 영상의 왜곡, 잡음이 발생하게 된다. 발생하는 왜곡 및 잡음은 영상 정보를 압축, 전송, 저장을 수행하는데 방해 요인으로 작용하며, 또한 원 영상 정보를 훼손하게 된다. 따라서 획득 영상에 대한 잡음의 제거, 왜곡의 보정 등이 전처리 과정으로 필수적으로 수행하게 된다. 영상 처리 분야에서 획득된 영상에 대한 전처리 과정은 효과적인 영상 처리를 위해 반드시 필요한 분야이다. 현재는 영상 정보의 대량화, 디지털 멀티미디어 발전, 고화질 영상의 압축, 전송, 획득 및 처리가 일반화 되면서 잡음 제거를 위해 영상 전처리 분야가 새롭게 발전되고 있다[1-11].

영상 처리에 있어서 발생하는 잡음은 크게 임펄스 잡음(Impulse Noise)와 적응 흰색 가우시안 잡음(Adaptive White Gaussian Noise)이 대표적이다. 임펄스 잡음을 제거하기 위한 방법들이 다양하게 제시되고 있으며, 대표적으로 일정한 크기를 갖는 윈도우 내의 최소 값에 대한 평균 및 중간값을 이용한 평균값 필터, 중간값 필터 [1,2]가 있다. 또한 가중치를 이용한 중간값 필터[3], 스위칭 중간값 필터[4,5], 중심 가중치 기반의 중간값 필터[6], SVM (Support Vector Machine)의 입력데이터인 특징벡터를 구성하는데 있어서 몇 개의 변수만을 사용하여 국소적인 정보 측도로 사용하였고, 평균값 필터와 중간값 필터의 장점을 이용하여 매개변수를 적응적으로 조절하는 ATM (Adaptive Two-pass Median) 필터[7]가 제안되었다. 이와 같은 기존의 방식들은 영상 전체에 대하여 균일하게 적용되어 노이즈와 노이즈가 섞이지 않은 최소 전체에 적용하고, 그 결과 윤곽선과 시각적으로 중요한 정보를 동시에 열화시키는 단점을 가지고 있다. 그리고 간단한 계산으로 잡음을 제거하나 가우시안 잡음 등에는 효과적이지 못하며, 고주파 영역에서는 오히려 영상을 왜곡하는 경우가 발생한다.

그리고 적응 흰색 가우시안 잡음은 가우시안 분포를 가지

고 있다는 가정을 기반으로 한다. 그리고 일반적으로 영상의 특성이 국부의 특성에 의해서 결정되므로 국부 통계적 특성을 추출하여 해상도 개선을 위한 매개변수로 활용하는 것이 성능 향상에 기여할 수 있다. 그래서 기존의 잡음 검출과 잡음 제거에 관한 방법은 LMS (Least Mean Square) 필터, 정규화 잡음 제거 필터, 칼만 필터의 잡음 제거 방식은 잡음 분포에 대한 가정으로 인해 필터링 된 영상의 윤곽선 정보의 열화 현상을 동반하고, 인간 시각 시스템을 반영하지 않은 관계로 시각적인 왜곡 현상을 일으켜 심각한 화질 저하를 발생시키게 된다[8].

기존 필터에서 발생하는 화질 저하 및 영상 왜곡 등의 문제를 해결하기 위해 선형 구조나 결정 순환 구조에 비해 영상 복원에 탁월한 비선형 특성을 가진 신경망 구조를 가진 필터에 여러 학자들에 의해 관심을 보이기 시작했다. 이 신경망 구조를 가진 필터는 단순한 피드포워드(Feedforward) 구조로 가중치 및 반복요소를 요구함으로써 많은 계산량과 시간이 필요하며, 구조가 너무 복잡하여 시스템에 적용하기가 어렵다는 단점을 가지고 있다. 이것은 시스템 구조가 크며, 속도가 느리다는 것으로 계산의 복잡도가 증가된다는 것을 의미한다 [9-13].

본 논문에서는 신경망 구조에서 가지고 있는 기본적인 문제점을 해결하기 위해 신경망 전체 구조를 폐회로로 구성하여 신경망의 출력이 신경망의 입력으로 사용함으로써 계산량과 구조의 복잡도를 단순화하였다. 그리고 수학적 계산량 및 복잡성, 계산량 축소를 위해 역전파 알고리즘의 한 응용 분야인 일반적인 순환 신경망 알고리즘에 퍼지를 적용한다. 이것은 시간 동적 모델에서 반응 지연을 줄이는 것을 목적으로 퍼지 적용 순환 신경망을 구현했다. 또한 신경망의 기울기 계산은 기본적으로 역전파 규칙을 포함하여 복잡하나, 순환 신경망의 은닉층 노드는 각각 자기 자신의 출력을 자신의 입력으로 받아서 신경망 구조를 단순화함으로써 기울기 계산을 쉽게 할 수 있다.

본 논문은 신경망 구조를 단순화하기 위해 자기 자신의 출력을 자신의 입력으로 받는 구조인 입력층과 출력층을 갖는 2층 구조의 퍼지 순환 방식 신경망 필터를 제안한다. 그리고 제안된 알고리즘인 퍼지 신경망 필터를 잡음이 포함된 영상을 복원하여 기존 필터와 성능을 비교하여 우수함을 분석한다.

본 논문은 II장에서 기존 순환 신경망 알고리즘의 구조를 간략히 설명하고, III장에서는 제안한 퍼지 순환 신경망 필터

구조에 대해 설명한다. IV장에서는 모의실험을 통해 기존 필터보다 제안한 필터가 우수하다는 것을 MSE와 PSNR을 이용하여 비교 분석하고, V장에서 결론을 맺는다.

## II. 기존 순환 신경망 구조

그림 1은 일반적인 순환 신경망 회로의 구조를 나타낸 것으로 신경망 회로의 입력  $X(k)$ 과 신경망 회로의 출력  $y(k)$ , 그리고 각 노드에서 계산되어지는 은닉층의 합  $S(k)$ 은 식 (2.1)과 같다[11-13].

$$y(k+1) = f(S(k))$$

$$S(k) = W_I^T U(k) + \sum W_{D_p}^T X(k-p) \quad (2.1)$$

여기서,  $f(x)$ 는 시그모이드(sigmoid) 함수이며,  $y(k)$ 는 신경망 회로의 출력이다.  $X(k)$ 는 신경망 회로 은닉층의 출력을 나타내고,  $S(k)$ 는 은닉층으로 들어오는 가중치의 합을 의미하는 것으로, 외부 입력의 가중치 합과 내부 입력 즉 피드백된 자체 입력의 가중치 합으로 구해진다. 그리고  $W_I \in R^{N_H \times N_I}$ 는 입력층의 가중치를 나타내며,  $W_D \in R^{N_H \times N_H}$ 는 은닉층이 가지고 있는 피드백된 입력들이 가지는 가중치 행렬이고, 이 가중치의 크기는 정해진 값 이하로 제한된다. 여기서  $N_I$ 는 입력층 노드들의 개수이고,  $N_H$ 는 은닉층 노드들의 개수,  $N_D$ 는 은닉층의 피드백된 출력의 개수이다.

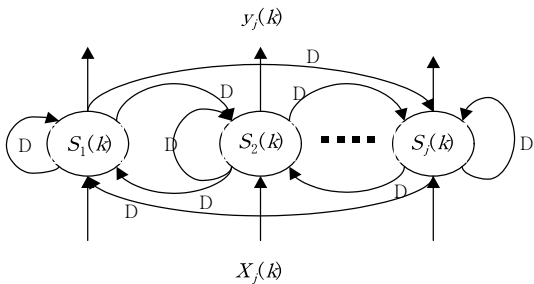


그림 1. 일반적인 순환 신경망 회로의 구조  
 Fig. 1. The structure of the generalized recurrent neural networks  
 그리고 일반적인 실시간 학습 알고리즘인 RTRL(Real-Time Recurrent Learning)을 사용하여 신경망을 학습한다.

## III. 제안된 퍼지 순환 신경망 구조

제안된 퍼지 순환 신경망 구조는 기본적으로 순환 신경망 구조를 이용한 것으로, 수학적 계산량 및 복잡성, 계산량 축소를 위해 하이브리드 퍼지 소속 함수 연산자를 적용하였다. 또한 입력 연산자를 퍼지 연산자로 구성하여 영상의 출력 값이 일정하게 수렴하도록 하였다. 일반적으로 퍼지 소속함수는 사다리꼴 소속함수, 삼각형 소속함수와 하이브리드 소속함수 등 있으며, 본 논문에서는 하이브리드 소속 함수를 적용하였으며, 퍼지 소속함수 규칙은  $(X_1 \text{은 } A_1^k)$  그리고  $(X_2 \text{는 } A_2^k)$  그리고  $(X_n \text{은 } A_n^k)$ 이라면,  $(Y^k \text{는 } B^k)$ 이다. 여기서  $k = 1, 2, \dots, r$  이다[14-17]. 입력 변수  $X_i$ 는 모든 규칙에 적용되고  $k$ 에 독립적이다.  $A_1^k, \dots, A_n^k$ 와  $B^k$ 는 퍼지집합에 의해 나타나며,  $k$ 는 규칙의 수이고, 퍼지 전체의 기본적 형식은 'p : X는 A이다'로 정의된다. 여기서 X는 보통집합 U로 정의된 삼각 퍼지 변수이고, A는 같은 일반적인 사다리꼴 퍼지이다. 만약 Max-product가 적용되면  $v_{M_m}$ 은 식 (3.1)에 의해서 얻게 되며, X가 삼각 퍼지 변수 ( $b_x = c_x$ )일 때 보다 X가 사다리꼴 변수 ( $b_x \neq c_x$ )일 때 더욱 일반적인 경우로 확정되어진다.

그림 2는 하이브리드 퍼지 소속 함수 연산자가 순환 신경망 구조에서 신경망 회로의 입력 연산자로 사용된다. 여기서  $X' = X'(u) = \wedge_c(u; 0, b_x, 0)$ 은 비퍼지 단일 변수이고,  $A' = A'(u) = \Pi_c(u; a'_A, b_A, c_A, \beta'_A)$ 는 하이브리드 방식이다. 퍼지 결합 계산은 하이브리드 방식의 레벨 A'에 대한  $\Pi_s$ 를 이용하여 식 (3.1)과 식 (3.2)를 이용하여 간단하게 결합하여 구할 수 있다.

$$A' = A'(u) = \Pi_s(u; a'_A, a'_A, \beta'_A, d'_A)$$

$$a'_A = b_A - \alpha'_A$$

$$d'_A = c_A + \beta'_A \quad (3.1)$$

결합  $v_{M_m}$ 은 식 (3.2)를 이용하여 얻을 수 있다.

$$v_{M_m} = \{ b_x \leq a'_A \text{ 혹 } b_x \geq d'_A, 0, \\ a'_A + \alpha'_A \leq b_x \leq d'_A - \beta'_A \rightarrow 1, \\ b_x < a'_A + \alpha'_A \rightarrow (b_x - a'_A) / \alpha'_A, \\ b_x > d'_A - \beta'_A \rightarrow (d'_A - b_x) / \beta'_A \}$$

$$(3.2)$$

결합  $v_{M_m}$ 에서 얻은 퍼지 연산자를 신경망의 여기 함수로 사용한다. 일반적인 함수인 시그모이드 함수를 대신하여 정리하면 식 (3.3)과 같이 구할 수 있다. 제안된 구조는 식 (3.3)에서와 같이  $O(k)$ 라는 신경망 회로의 출력층의 퍼지 적용 여기 함수로 들어오는 은닉층의 가중치 합을 이용하여 출력값이 일정하게 수렴하도록 구성하였다.

$$y(k) = v_{M_m}(O(k)), \quad O(k) = W_O^T X(k),$$

$$X(k) = v_M(S(k))$$

$$S(k) = W_I^T U(k) + \sum W_{D_p}^T X(k-p) \quad (3.3)$$

여기서,  $v_{M_m}$ 는 퍼지 적용 여기 함수이며,  $y(k)$ 는 신경망 회로의 출력이다.  $X(k)$ 는 퍼지 연산자를 사용한 여기 함수에 적용된 신경망 회로 은닉층의 출력을 나타낸다.  $S(k)$ 는 일반 구조와 같이 은닉층으로 들어오는 가중치의 합을 의미하는 것으로, 외부 입력의 가중치 합과 내부 입력 즉 피드백된 자체 입력의 가중치 합으로 구해진다. 그리고  $W_O \in R^{N_o \times N_h}$ 는 퍼지 연산자를 사용한 여기 함수를 적용한 신경망 회로 은닉층 출력의 가중치이며,  $W_I \in R^{N_h \times N_i}$ 는 입력층의 가중치를 나타낸다.  $W_{D_p} \in R^{N_h \times N_h}$ 는 은닉층이 가지고 있는 피드백된 입력들이 가지는 가중치 행렬이고, 이 가중치의 크기는 정해진 값 이하로 제한된다. 기존 구조와 같이  $N_i$ 는 입력층 노드들의 개수이고,  $N_h$ 는 은닉층 노드들의 개수,  $N_o$ 는 은닉층의 피드백된 출력의 개수이다. 또한  $N_o$ 는 출력층 노드들의 개수이다. 이때 퍼지 연산자를 사용한 여기 함수를 포함한  $j$  번째 은닉층의 구조는 아래의 그림 3과 같다.

그림 3은 제안된 퍼지 적용한 순환 신경망 구조를 나타낸 것이다. 퍼지 소속함수 연산자를 적용한 순환 되는 구조를 포함하고 있다.

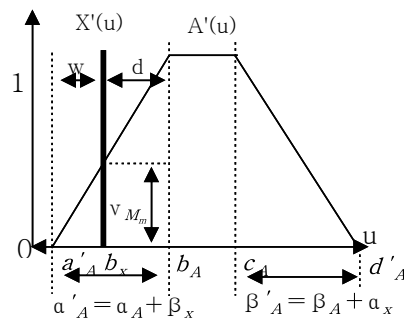


그림 2 하이브리드 퍼지 소속 함수  
Fig. 2. The hybrid fuzzy membership function

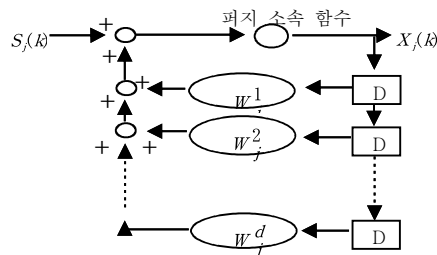


그림 3. 퍼지 순환 신경망 회로의 j 번째 은닉층의 구조  
Fig. 3. The jth hidden layer structure of the fuzzy 순환 neural networks

일반적인 신경망 회로는 동적 매핑(Mapping) 성질을 가지고 있으며, 일반적인 신경망 회로가 가지고 있는 되먹임 회로에 기인하는 것으로 식 (3.4)와 같이 나타낼 수 있다.

$$y(k) = f \left[ \sum_{j=1}^n W_j^p \left[ \sum_{i=1}^m W_{ij} U_i(k) + \sum_{p=1}^{N_i} W_j^p X_j(k-p) \right] \right] \quad (3.4)$$

여기서 입력을  $U(k) = \{r(k), u(k)\}$ 라고 가정하고,  $r(k)$ 와  $u(k)$ 는 각각 주어진 시스템의 출력과 입력을 의미한다. 여기서 신경망 회로는 입력이 2개이고, 출력이 1개라고 가정하여 식 (3.4)를 다시 정리하면, 식 (3.5)와 같다.

$$y(k) = f(r(l), u(l); l \leq k) \quad (3.5)$$

식 (3.5)에서와 같이 일반적인 신경망 회로는 현재의 입력 값이 과거 출력 값에 대한 함수라 할 수 있으며, 동적 시스템을 근사화할 수 있다. 여기서 퍼지 소속함수 연산자를 함수를 적용한 신경망 회로의 출력층 가중치  $W_O$ 를 학습하는 방법은 식 (3.6)과 같다.

$$\begin{aligned} \text{최소 : } & \frac{1}{2} \| W_O(k+1) - W_O(k) \|^2 \\ & v_M^{-1}(\tilde{d}(k+1)) - \mathcal{O}(k+1) = 0 \end{aligned} \quad (3.6)$$

여기서,  $\tilde{d}(k+1) = d(k)$ 는 원하는 신경망 회로 출력인 후 출력이고,  $\mathcal{O}(k+1) = W_O^T(k+1)\mathcal{X}(k)$ 는 퍼지 함수 연산자 적용 신경망 회로의 후 출력을 말한다. 여기서 라그레인지언(Lagrangian)  $\lambda_o$ 를 도입하여  $H_o$ 를 구하면 다음 식 (3.7)과 같다.

$$\begin{aligned} H_o = & \frac{1}{2} \| W_O(k+1) - W_O(k) \|^2 \\ & + \lambda_o(v_M^{-1}(\tilde{d}(k+1)) - \mathcal{O}(k+1)) \end{aligned} \quad (3.7)$$

이때 퍼지 연산자 적용 신경망 회로의 출력층 가중치  $W_O(k+1)$ 와  $\lambda_o$ 에 대해 식 (3.7)  $H_o$ 를 최소화하기 위한 필요조건은  $\frac{\partial H_o}{\partial W_O(k+1)} = 0$ 와  $\frac{\partial H_o}{\partial \lambda_o} = 0$ 이 된다. 위의 필요조건과  $\frac{\partial \mathcal{O}(k+1)}{\partial W_O(k+1)} = \mathcal{X}(k)$ 라는 관계를 이용하면, 퍼지 연산자 적용 신경망 회로 가중치  $W_O$ 의 학습 방법은 식 (3.8)과 같다.

$$\begin{aligned} W_O(k+1) &= W_O(k) + \lambda_o \frac{\partial \mathcal{O}(k+1)}{\partial W_O(k+1)} \\ &= W_O(k) + \lambda_o \mathcal{X}(k) \end{aligned} \quad (3.8)$$

이때 주어진  $\lambda_o$ 에 대한 필요조건에서  $\frac{\partial H_o}{\partial \lambda_o} = v_M^{-1}(\tilde{d}(k+1)) - \mathcal{O}(k+1)$ 이므로 식 (3.9)가 된다.

$$\lambda_o = \frac{v_M^{-1}(\tilde{d}(k+1)) - W_O^T(k)\mathcal{X}(k)}{\widehat{\mathcal{X}}^T(k)\mathcal{X}(k)} \quad (3.9)$$

따라서 퍼지 연산자 적용 신경망 회로 가중치  $W_O$ 를 학습시키는 방법은 식 (3.10)과 같다.

$$W_O(k+1) = W_O(k)$$

$$+ \frac{v_M^{-1}(\tilde{d}(k+1)) - W_O^T(k)\mathcal{X}(k)}{\widehat{\mathcal{X}}^T(k)\mathcal{X}(k)} \mathcal{X}(k) \quad (3.10)$$

$H_o$ 를 구하는 방법으로 가중치  $W_O$ 를 구할 수 있다. 여기서  $j$ 번째 은닉층의 가중치  $W_j^P$ 에 대해  $H_{jP}$ 를 구하면 식 (3.11)와 같이 나타낼 수 있다.

$$\begin{aligned} H_{jP} = & \frac{1}{2} \| W_j^P(k+1) - W_j^P(k) \|^2 \\ & + \lambda_D(v_M^{-1}(\tilde{d}_{hj}(k+1)) - \mathfrak{S}_j(k+1)) \end{aligned} \quad (3.11)$$

여기서,  $\tilde{d}_{hj}(k+1) = d_{hj}(k)$ 는 원하는 내부 출력값  $d_h(k)$ 의  $j$ 번째 후 출력값을 의미하고,  $\mathfrak{S}_j(k+1)$ 은  $S_j(k)$ 의 후 출력값을 나타낸다. 여기서 원하는 내부 출력값  $d_h(k)$ 는  $d(k) = v_M(W_O^T d_h(k))$ 라는 가정에서 얻을 수 있다. 따라서 Pseudo-inverse에 의해서  $d_h(k) = W_O^+ A(d(k))$ 와 같이 구할 수 있고, 여기서 +는 주어진 행렬의 Pseudo-inverse를 의미한다. 퍼지 연산자 적용 신경망 회로의 가중치  $W_O$ 를 구하는 방법과 같은 방법에 의해  $\lambda_o$ 를 구하면, 가중치  $W_j^P$ 를 구하는 학습 방법은 식 (3.12)와 같다.

$$\begin{aligned} W_j^P(k+1) &= W_j^P(k) + \frac{\varepsilon(k)}{P_j^P(k)\mathcal{X}_j(k-p)} P_j^P(k) \end{aligned} \quad (3.12)$$

여기서,  $P_j^P(k) = \frac{\partial \mathfrak{S}_j(k+1)}{\partial W_j^P}$ 로 정의되고, 후 오차인  $\varepsilon(k)$ 는 식 (3.13)과 같다.

$$\begin{aligned} \varepsilon(k) &= v_M^{-1}(\tilde{d}_{hj}(k+1)) \\ &- \sum_d W_j^d(k)\mathcal{X}_j(k-d) - (W_j^I)^T(k)U(k) \end{aligned} \quad (3.13)$$

그리고 전체적인 계산 방법과 순환 학습 방법을 이용하여 식 (3.14)를 구할 수 있다.

$$P_j^P(k) = f'(S_j(k))(\mathcal{X}_j(k-p) + \sum_d W_j^P(k) P_j^P(k-d)) \quad (3.14)$$

식 (3.14)와 같은 방법으로 신경망 회로 가중치  $W_j$ 를 구하면 식 (3.15)와 같다.

$$W_j^I(k+1) = W_j^I(k) + \frac{\epsilon(k)}{Q_j^T(k) U(k)} \cdot Q_j(k) \quad (3.15)$$

여기서  $Q_j(k) = \frac{\partial S_j(k+1)}{\partial W_j^I}$ 이며, 식 (3.16)과 같이 구할 수 있다.

$$Q_j(k) = f'(S_j(k)) (U(k) + \sum_d W_j^d(k) Q_j(k-d)) \quad (3.16)$$

위에서 설명된 식 (3.3)에서 식 (3.16)까지를 반복적으로 수행함으로써 퍼지 순환 신경망 구조는 식 (3.8), (3.12), (3.15)에서 얻은 각각의 가중치를 안정화하여 일정한 값에 수렴하도록 학습함으로써 계산량 및 복잡성, 계산량 축소를 가능하도록 하였다. 그리고 식 (3.17)은  $j$ 번째 은닉층 구조에 대한 간략한 의사코드를 나타낸 것이다.

```

begin initialize  $S, \mathcal{X}, W$ 
do k k+1
     $W_0$ 은 식 3.8로 업데이트
     $W_r^P$ 는 식 3.12로 업데이트
     $W_j^I$ 는 식 3.15로 업데이트
do  $U(k) \leftarrow U(k+1), \mathcal{X}(k) \leftarrow \mathcal{X}(K-p)$ 
     $S_j(k) \leftarrow W_r^T, W_p^T$ 
     $O(k) \leftarrow W_O^T$ 
     $v_M \leftarrow (S(k))$ 
until  $\|\epsilon(k)\| < \Theta$ 
    
```

```

until  $\|\epsilon(k)\| < \Theta$ 
return  $W$ 
end \quad (3.17)
    
```

### IV. 시뮬레이션

본 논문에서는 영상에 잡음을 임의적으로 포함시켜서 영상 복원을 위한 필터링 실험을 하였다. 그리고 제안된 알고리즘의 객관적인 성능 평가를 위하여 MSE와 PSNR을 사용하였다. PSNR은 식 (4.1)과 같이 정의 된다.

$$PSNR = 10 \log \frac{255^2}{MSE} \quad (4.1)$$

식 (4.1)에서 가로X세로가 255X255인 영상을 사용하였다. 영상 필터링을 하기 위해 본 논문에서 제안한 퍼지 소속 함수를 연산자로 적용한 순환 신경망 구조 알고리즘은 잡음이 많이 포함된 영상에서 더욱 우수하였으며, 기존 알고리즘인 순환 신경망 필터보다 제안된 알고리즘인 퍼지 순환 신경망 필터가 더 우수한 복원 능력을 보였음을 그림 5'8에서 통하여 확인하였다. 모의실험은 원 영상에 10%, 20%, 30%, 40%의 잡음을 넣고 기존 필터와 제안된 필터를 이용하여 잡음을 제거한 후 영상을 MSE와 PSNR을 이용하여 비교하였다. 그림 4은 lena의 원 영상이고, 그림 5(a), 그림 6(a), 그림 7(a), 그림 8(a)는 10%, 20%, 30%, 40% 잡음을 포함한 영상에서 기존 알고리즘인 순환 신경망 필터를 적용하여 잡음을 제거하여 복원한 영상이고, 그림 5(b), 그림 6(b), 그림 7(b), 그림 8(b)는 10%, 20%, 30%, 40% 잡음을 포함한 영상에서 제안한 알고리즘인 퍼지 순환 신경망 필터를 적용하여 잡음을 제거하여 복원한 영상이다. 여기 시뮬레이션 결과 영상에서 알 수 있듯이 기존 필터를 적용한 복원 결과 영상은 제안된 필터에 비해 복원된 영상의 질이 떨어지며, 일부 복원된 영상은 잡음이 제거되지 않고 일부 포함하고 있으며, 또한 복원 영상에서 에지 정보가 손실되었음을 결과 영상을 통하여 확인할 수 있었다.



그림 4. Lena의 원 영상

Fig. 4. The original image of Lena



(a) 기존 필터 (b) 제안된 필터  
(a) The conventional Filter (b) The proposal Filter

그림 5. 10% 잡음을 포함한 영상에서 복원 영상  
Fig. 5. Restoration image at image included 10% noise



(a) 기존 필터 (b) 제안된 필터  
(a) The conventional Filter (b) The proposal Filter

그림 6. 20% 잡음을 포함한 영상에서 복원 영상  
Fig. 6. Restoration image at image included 20% noise



(a) 기존 필터 (b) 제안된 필터  
(a) The conventional Filter (b) The proposal Filter

그림 7. 30% 잡음을 포함한 영상에서 복원 영상  
Fig. 7. Restoration image at image included 30% noise



(a) 기존 필터 (b) 제안된 필터  
(a) The conventional Filter (b) The proposal Filter

그림 8. 40% 잡음을 포함한 영상에서 복원 영상  
Fig. 8. Restoration image at image included 40% noise

그림 9는 Camera의 원 영상이고, 그림 9(a), 그림 10(a), 그림 11(a), 그림 12(a)는 10%, 20%, 30%, 40% 잡음을 포함한 영상에서 기존 필터를 적용하여 잡음을 제거한 복원 영상이고, 그림 9(b), 그림 10(b), 그림 11(b), 그림 12(b)는 10%, 20%, 30%, 40% 잡음을 포함한 영상에서 제안된 필터를 적용하여 잡음을 제거한 복원 영상이다. 여기 Camera 영상에서는 30%와 40%의 잡음이 포함된 영상에

기존 필터를 적용하여 복원된 영상이 제안된 필터를 적용하여 복원된 영상보다 잡음을 더 많이 포함되어 잡음이 완전히 제거되지 않은 것을 복원 영상에서 확인 할 수 있다. 그리고 그림 14에서는 기존 필터를 적용하여 복원된 영상보다 제안된 필터를 적용하여 복원된 영상이 예지나 잡음 제거 면에서 우수함을 확인 할 수 있다.



그림 9. Camera의 원 영상

Fig. 9. The original image of Camera



(a) 기존 필터 (b) 제안된 필터  
(a) The conventional Filter (b) The proposal Filter

그림 10. 10% 잡음을 포함한 영상에서 복원 영상  
Fig. 10. Restoration image at image included 10% noise



(a) 기존 필터 (b) 제안된 필터  
(a) The conventional Filter (b) The proposal Filter

그림 11. 20% 잡음을 포함한 영상에서 복원 영상  
Fig. 11. Restoration image at image included 20% noise

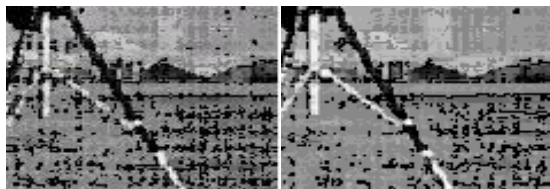



(a) 기존 필터 (b) 제안된 필터  
(a) The conventional Filter (b) The proposal Filter

그림 12. 30% 잡음을 포함한 영상에서 복원 영상  
Fig. 12. Restoration image at image included 30% noise



(a) 기존 필터 (b) 제안된 필터  
 (a) The conventional Filter (b) The proposal Filter  
 그림 13. 40% 잡음을 포함한 영상에서 복원 영상  
 Fig. 13. Restoration image at image included 40% noise



(a) 기존 필터 (b) 제안된 필터  
 (a) The conventional Filter (b) The proposal Filter  
 그림 14. 40% 잡음을 포함한 영상에서 복원 영상  
 Fig. 14. Restoration image at image included 40% noise

표 1. Lena 영상의 MSE 데이터  
 Table 1. MSE Data of Lena image

Noise	기존 필터	제안된 필터
10%	903	823
20%	924	869
30%	950	879
40%	997	886

표 2. Lena 영상의 PSNR 데이터  
 Table 2. PSNR Data of Lena image

Noise	기존 필터	제안된 필터
10%	18.58	18.97
20%	18.47	18.74
30%	18.35	18.69
40%	18.14	18.66

표 1과 표 2는 기존 알고리즘인 순환 신경망 필터와 제안된 알고리즘인 퍼지 순환 신경망 필터를 적용한 후 복원 영상과 원영상을 비교한 MSE와 PSNR을 각각 표로 나타낸 것이다. 여기서 기존 필터를 적용하여 얻은 MSE의 결과보다 제안된 필터를 적용하여 얻은 MSE가 대략 79.25정도 우수함을 알 수 있다. 그리고 PSNR은 0.38dB 정도 우수함을 알 수 있었다. 그림 15와 16은 각 영상에 대한 잡음별 MSE와 PSNR을 그래프로 나타낸 것이다. 여기서 본 논문에서 제안한 알고리즘인 퍼지 순환 신경망 필터는 임펄스 잡음의 포함 정도에 관계없이 유사하게 복원하여 잡음이 포함되기 전 영상에 수렴하는 현상을 보였으며, 기존 필터에 비해 잡음 제거에 우수함을 보였다.

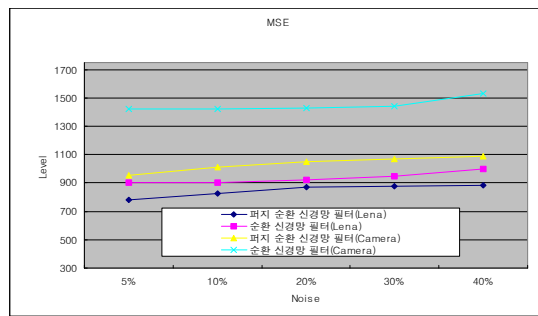


그림 15. 각 잡음별의 MSE  
 Fig. 15. MSE of each noise

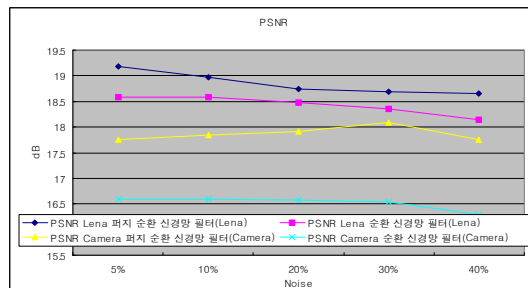


그림 16. 각 잡음별의 PSNR  
 Fig. 16. PSNR of each noise

## V. 결론

본 논문은 기본적으로 순환 신경망 구조를 이용한 것으로, 수학적 계산량 및 복잡성, 계산량 축소를 위해 하이브리드 퍼지 소속 함수 연산자를 적용하였다. 또한 입력 연산자를 퍼지 연산자로 구성하여 영상의 출력값이 일정하게 수렴하도록

함으로써 제안된 알고리즘인 퍼지 순환 신경망 필터는 신경망 모델의 복잡한 구조를 간단하게 하였다. 그리고 모의실험을 통하여 제안된 퍼지 소속함수를 적용한 순환 신경망 필터가 이미지의 복잡한 연산처리에 효과적임을 알 수 있었으며, 제안된 필터는 잡음이 많이 포함 될수록 일정하게 원영상에 가깝도록 수렴하는 현상을 볼 수가 있었다. 또한 기존 필터보다 제안된 필터가 영상에서 잡음을 제거하는 성능이 MSE에서 평균 79.25 우수하며, PSNR에서 0.38dB정도 개선되었음을 확인하였다.

향후, 제안된 알고리즘은 실시간 동화상, 복잡한 영상 등의 전처리 과정에서 잡음 제거 필터로 사용하여 성능향상을 기대할 수 있으며, 또한 객체 검출 및 인식기, 보안기등에 사용하기 위해 전용 하드웨어에 대한 최적화 연구가 필요하다고 사료된다.

## 참고문헌

- [1] D. K. Lee, M. J. Park, J. W. Kim, D. Y. Kim, D. W. Kim and D. H. Lim, "Support Vector Machine and Improved Adaptive Median Filtering for Impulse Noise Removal from Images," *Journal of KSS*, Vol. 23(1), pp. 151-165, 2010.
- [2] J. R. Mohammed, "An improved median filter based on efficient noise detection for high quality image restoration," *AICMS, Modeling & Simulation*, pp 217-331, 2008.
- [3] T. W. Baek and S. I. Lee, "An Iterative Bilateral Weighted Median Filter for the Removal of High-Density Impulse Noise," *KIIT Review*, Vol. 8, No. 2, pp. 59-65, Feb. 2010.
- [4] P. Ng and K. Ma, "Switching Median Filter with Boundary Discriminative noise detection," *IEEE Trans., Image Process.* Vol. 15, No. 6, pp. 1506-1516, Jun. 2006.
- [5] R. K. Kulkarni, C. B. Lahoti and S. Meher, "Impulse denoising using improved progressive switching median filter," *Proceedings of the International Conference and Workshop on Emerging Trends in Technology*, Feb. 2010.
- [6] T. Chen and Hong Ren Wu, "Adaptive Impulse Detection using Center-Weighted Median Filters," *IEEE Trans. Signal Processing Letters*, vol. 8, pp. 1-3, 2001.
- [7] T. C. Lin and P. Y. Yu, "Adaptive two-pass median filter based on support vector machines for image restoration," *Neural Computation*, Vol. 16, pp. 333-354, 2004
- [8] Ezequiel Lopez-Rubio, "Restoration of images corrupted by Gaussian and uniform impulsive noise," *Pattern Recognition*, Vol. 43 No. 5, pp.1835-1846, May, 2010
- [9] H. Kong and L. Guan, "A Neural Network Adaptive Filter for the Removal of Impulse Noise in Digital Images," *Neural Networks*, Vol. 9, pp. 373-378, Apr. 1996.
- [10] C. C. Ku and K. Y. Lee, "Diagonal Recurrent neural networks for dynamic system control," *IEEE Trans. on Neural Networks*, Vol. 6, No. 1, pp. 144-156, 1995.
- [11] S. Ong, C. You, S. Choi and D. Hong, "A decision feedback Recurrent neural equalizer as an infinite impulse response filter," *IEEE Trans. on Signal Processing*, Vol. 45, No. 11, pp. 2851-2858, 1997.
- [12] J. A. Nossek, G. Seiler, T. Roska and L. O. Chua, "Cellular neural networks: theory and circuit design," *Int j. circuits. theory.* no. 20, pp. 523-543, Apr. 1992.
- [13] S. Y. Kung, "Digital Neural Networks" Prentice Hall, International, Inc., pp. 203-236, 1993.
- [14] T. Yang and L. B. Yang, "The global stability of fuzzy cellular neural network," *IEEE Trans. circuit system I*, Vol. 43, pp. 880-883, Oct. 1996.
- [15] Abraham Kandel, Gideon Langholz, "Fuzzy Hardware," Kluwer Academic Publishers, 1998.
- [16] O. S. Byun, "An efficient Color Edge Fuzzy interpolation Method for improving a Chromatic Aberration," *Journal of KSCI*, Vol. 15, No. 10, pp. 59-70, Oct. 2010.

- [17] H. J. Jung and C. Y. Jung, "Development of Information Systems Model Applying Fuzzysset Theory," Journal of KSCE, Vol. 9, No. 4, pp. 203-214, Dec. 2004.

## 저 자 소 개



### 변 오 성

2000 : 원광대학교 전자공학과 공학석사.

2003 : 원광대학교 전자공학과 공학박사.

2003~2010 : 삼성전기 ISM 개발팀 책임  
연구원

현 재 : 현대모비스 기술연구소 책임연  
구원

관심분야 : 영상처리, 패턴인식, 임베디드  
시스템, 지능형 전장시스템 등

Email : byunoh@naver.com