

論文99-36C-11-10

## 양자화 삼각 퍼지 함수를 이용한 FDNN 구현 및 성능 분석

(Implementation and Performance Analysis of FDNN  
Using Quantization Triangularity Fuzzy Function)

卞 吾 星 \*, 李 喆 熙 \*, 文 成 龍 \*

(Oh-Sung Byun, Cheul-Hee Lee, and Sung-Ryong Moon)

## 요 약

본 논문에서는 삼각함수와 양자화 된 삼각 퍼지함수를 가중퍼지평균(WFM: Weighted Fuzzy Mean)에 적용하여 비교하였다. 또한 잡음의 특성에 따라서 영상에 포함된 잡음을 완전히 제거할 수 없는 단점을 개선하기 위하여, 계층적 구조의 결정기반 신경회로망(DBNN: Decision Based Neural Network)에 퍼지알고리즘을 적용하여, 영상에 포함된 잡음을 제거하고 동시에 정보의 손실을 최소화하고 최적의 정보를 얻을 수 있는 고속 가중 퍼지결정 신경회로망(FDNN: Fuzzy Decision Neural Network)을 구현하였다. 그리고 모의실험을 통하여 WFM과 FDNN의 성능을 비교하였으며, 보트(boats)의 영상에 대한 평균자승오차(MSE:Mean Square Error)를 비교한 결과 제안된 FDNN이 우수함을 확인하였다.

## Abstract

In this paper, we could analyze the comparison with applied WFM to the quantization triangularity fuzzy function and triangularity Fuzzy function. In order to improve on a fault which not remove completely noise included image according to a peculiarity of noise, we got to realize FDNN of the high speed weight eliminating noise included image, minimizing the lost of information, obtaining information of suitability owing to applied Fuzzy Algorithm to DBNN of a hierarchical structure. We could analyze the comparison with a power of WFM and FDNN using simulation. We could find to superiority the proposed FDNN in a result which was the comparison of MSE for the boats image.

## I. 서 론

모든 정보 전달이 컴퓨터 네트워크에 의해 이루어지는 정보화 사회에서 영상처리를 위한 시스템의 필요성이 증가되고 있어, 신경망과 퍼지 알고리즘을 이용한 화상 인식, 보안시스템 등의 응용분야에 적용할 수 있는 영상 처리 시스템의 개발에 관한 연구가 진행되고 있다<sup>[1-2]</sup>.

신경망에 대한 연구의 주 관심 분야인 지도학습 모델은 홉필드(hopfield)망, 역전파 신경망(backpropagation neural network), 퍼셉트론(perceptron), DBNN 등이 있으며, 지도학습(supervised learning)에서 지도자(teacher)는 결정이 올바르게 되었는지, 그리고 적절하게 조정이 이루어졌는지를 판별하게 되므로 지도학습은 영상들을 정확하게 분류하기 위한 가중치들을 학습시키고 최상의 판별함수(discriminant function)에 의해서 결정 경계치(decision boundary)를 결정한다. 이와 같이 지도학습을 이용하여 패턴 분류에 적용되고 있는 DBNN 모델은 선형 퍼셉트론 이론을 기초로 결정 경계치에 의해 선형적으로 이진 분류하여 경계치를 결정하는 것이

\* 正會員, 圓光大學校 電子工學科

(Dept. of Electronic Engineering Wonkwang University)

接受日字:1998年4月20日, 수정완료일:1999年10月20日

다<sup>[4, 5, 7]</sup>.

본 논문에서는 삼각 퍼지함수와 양자화된 삼각 퍼지함수를 WFM<sup>[2]</sup>에 적용하여 비교하고, 또한 잡음의 특성에 따라서 영상에 포함된 잡음을 완전히 제거할 수 없는 단점을 개선하기 위하여, 계층적 구조의 DBNN에 퍼지알고리즘을 적용한 FDNN을 구현하여 영상에 포함된 잡음을 제거함과 동시에 정보의 손실을 최소화하고, 최적의 정보를 얻을 수 있는 고속 가중 FDNN을 구현한 후, 모의실험을 통하여 그 성능을 비교하고자 한다.

## II. DBNN의 알고리즘

DBNN 알고리즘의 지도학습 네트워크는 검색단계와 학습단계로 나누어지는데, 학습단계에서는 영상들을 정확하게 분류하기 위한 가중치들을 훈련시키고 최상의 판별함수에 의해서 결정 경계치를 결정한다. 선형 판별함수를 갖는 선형 퍼셉트론의 기본 구조는 다음 (1)식과 같다.

$$y = \phi(X, W) = \sum_j w_j x_j + \theta \quad (1)$$

여기에 가중치 파라미터를 첨가한 임계치  $\theta = w_{p+1}$ 을 대입하면,

$$W = [w_1, w_2, \dots, w_p, \theta]^T \quad (2)$$

이다.

Z는 증가된 영상 X로서 (3)식과 같다.

$$Z = [x_1, x_2, \dots, x_p, 1]^T \quad (3)$$

(1)식과 (2)식을 이용하여 선형판별함수를 표현하면  $y = \phi(X, W) = W^T Z$ 이 되고, m번째 훈련영상  $Z^{(m)}$ 은 가중치 벡터  $W^{(m)}$ 로 나타낼 수 있으며 (4)식과 같다.

$$W^{(m+1)} = W^{(m)} + \eta(t^{(m)} - d^{(m)})Z^{(m)} \quad (4)$$

여기서,  $\eta$ 는 양의 학습률이고,  $t^{(m)}$ 은 m 번째 임계치,  $d^{(m)}$ 은 결정 경계치로  $y > 0$ 이면 1을,  $y \leq 0$ 이면 0의 값을 갖는다.

결정 경계치는 판별함수  $\phi(X, W)$ 에 의존하기 때문에 가중치 벡터 W가 선형 판별함수의 기울기방향이면 긍정학습이고, 반대방향 이면 부정학습으로 수정되며, 이 때의 가중치 벡터 변화값  $\Delta W$ 는 (5)식과 같다.

$$\Delta W = \pm \eta \nabla \phi(X, W) \quad (5)$$

가중치 벡터 W에 대한 함수  $\phi$ 의 기울기 벡터는 (6)식과 같다.

$$\begin{aligned} \nabla \phi(X, W) &= \frac{\partial \phi(X, W)}{\partial W} \\ &= \left[ \frac{\partial \phi}{\partial W_1}, \frac{\partial \phi}{\partial W_2}, \dots, \frac{\partial \phi}{\partial W_N} \right]^T \end{aligned} \quad (6)$$

신경망 내 L개의 클래스(Class)( $\Omega_i, i=1, \dots, L$ )중에서 일치하는  $s = (X^{(1)}, X^{(2)}, \dots, X^{(M)})$ 를 주어진 입력영상의 집합이라고 가정하면, 각 클래스는 식별함수  $\phi(X, W_i)$ 을 갖는 하부 망(subnet)으로 모델화 된다. m 번째 입력영상  $X^{(m)}$ 이 클래스  $\Omega_i$ 에 속한다고 가정하면 다음 (7)식과 같이 표현할 수 있다.

$$\phi(X^{(m)}, W_i^{(m)}) > \phi(X^{(m)}, W_j^{(m)}), \quad \forall i \neq j \quad (7)$$

따라서, 입력영상에 대한 승리 클래스는 j 번째 클래스의 하부망이 되며 다음 조건에 따라 입력 영상에 대한 수정이 이루어진다.

- (1)  $j=i$  이면 입력 영상  $X^{(m)}$ 은 이미 정확하게 분류되었기 때문에 수정할 필요가 없다.
- (2)  $j \neq i$  이면 입력 영상  $X^{(m)}$ 은 아직 분류되지 않았기 때문에 식(8)의 학습조건에 의해서 수정되어야 한다.

$$\begin{aligned} W_i^{(m+1)} &= W_i^{(m)} + \eta \nabla \phi(X, W_i) : \text{긍정학습} \\ W_j^{(m+1)} &= W_j^{(m)} - \eta \nabla \phi(X, W_j) : \text{부정학습} \end{aligned} \quad (8)$$

전체 승리자는, 각 클래스의 하부 클래스 사이의 국부 승리자 결정에 따른 이들 국부승리자에 의해서 결정되며, l번째 클래스의 국부 승리자를 선택하는 함수는 (9)식과 같이 표현할 수 있다.

$$s_l = \underset{s_l}{\text{Max}} \phi_l(X, W_{s_l}) \quad (9)$$

여기서,  $s_l$ 은 클래스의 국부승리자.

(8)식의 DBNN 학습규칙에 퍼지이론을 적용하기 위하여 이 식을 변형하면 (10)식과 같다.

$$\begin{aligned} W_{s_l, q}^{(m+1)} &= W_{s_l, q}^{(m)} + \eta_m \nu_i \pi_i \\ W_{s_l, q}^{(m+1)} &= W_{s_l, q}^{(m)} - \eta_m \nu_j \pi_j \end{aligned} \quad (10)$$

여기서  $\pi_i = \nabla \phi(x, W_i)$ 이고  $\nu_i$ 는 L-R 형태 멤버십

함수의 파라미터이다.

### III. FDNN의 알고리즘

#### 1. 삼각 퍼지함수의 양자화

(10)식에서 멤버십 함수는 L-R 퍼지집합  $[m, \alpha, \beta]_{LR}$ 이고, (11)식의 마지막 I는 잡음 필터링을 위한 퍼지 평가자를 생산하기 위해 사용된 L-R 퍼지 구간임을 뜻한다<sup>[2]</sup>.

퍼지 구간 I는 L-R 형태 퍼지 숫자이며, 멤버십 함수는 아래의 (11)식과 같다.

$$\nu_{LR-I}(x) = \begin{cases} L\left(\frac{m_l - x}{\alpha}\right) & \text{for } x \leq m_l \\ 1 & \text{for } m_l \leq x \leq m_r \\ R\left(\frac{x - m_r}{\beta}\right) & \text{for } x \geq m_r \end{cases} \quad (11)$$

여기에서 L과 R은 형태 함수이고,  $\alpha, \beta, \nu$ 는 퍼지 구간에 대한 파라미터이다. L과 R을 가우시안 모양을 갖는다고 가정한다면 식(12)과 같다.

$$\nu_{LR-I}(x) = LR\left[\frac{m_l \nabla x}{\alpha} + \frac{x \nabla m_r}{\beta}\right] \quad (12)$$

여기에서 경계가 다른 연산은  $a \nabla b = \max(a - b, 0)$ 이고, 퍼지 구간  $I = [m, m_r, \alpha, \beta]_{LR}$ 로 나타낸다.

본 논문에서는 L-R 퍼지 삼각함수의 이론을 FDNN에 적용하기 위한 삼각 퍼지함수로서, 0~255사이의 임의의 픽셀값을 [0, 1]로 퍼지화 하는데 DARK, MIDDLE, BRIGHT의 퍼지함수를 사용하여 그 레벨을 퍼지화 하였다. 퍼지화에 사용한 함수는 DARK(45, 44, 44), MIDDLE(125, 44, 44), BRIGHT(205, 44, 44)로 설정하였으며, 그림 1과 같이 그레이 스케일(Gray scale)값(1~89)을 4비트(bit)로 양자화 하는 방법을 제안하였으며, 이 1~89의 레벨을 낮게 양자화 하여 설계가 용이하도록 하였다. 각 퍼지함수가 적용되는 구간을 16등분하여 그레이 스케일의 픽셀 값을 0~8사이의 디지털 값으로 표현함으로써 디지털처리가 가능하도록 하였다.

#### 2. 가중 FDNN의 구조

일반적인 L-R 삼각함수에 퍼지라는 개념을 도입하여 전체 0~255를 0과 1사이의 값으로 나타내어, 만약 I가

저장된 퍼지 구간이라면,  $y_E(\cdot)$ 에 의해서 표현되는 퍼지 평가자 E는 다음 (13)식에 의해서 산출된다.




그림 1. 삼각퍼지 함수의 양자화

Fig. 1. Quantization of Triangular Fuzzy Function.

$$y_E(X(i, j)) = \frac{X(i, j) * x(i, j)}{N_{LR-I}} \\ = \frac{\sum_{k=-\frac{n_1-1}{2}}^{\frac{n_1-1}{2}} \sum_{l=-\frac{n_2-1}{2}}^{\frac{n_2-1}{2}} \nu_{LR-I}(x(i+k, j+l)) * x(i+k, j+l)}{\sum_{k=-\frac{n_1-1}{2}}^{\frac{n_1-1}{2}} \sum_{l=-\frac{n_2-1}{2}}^{\frac{n_2-1}{2}} \nu_{LR-I}(x(i+k, j+l))} \quad (13)$$

여기  $X(i, j)$ 는  $(i, j)$ 에서  $n_1, n_2$  샘플행렬 중심이고,  $(i+k, j+l)$ 는 퍼지 구간  $LR-I$ 의 입력  $(i+k, j+l)$ 에 대한 멤버십 그래이드이며,  $F_{n_1 \times n_2} = \{f | f \in X, f \text{는 퍼지숫자이다}\}$ ,  $n = |F_{n_1 \times n_2}|$ 이다. WFM의 필터함수는 입력  $x(i, j)$ 의  $n$ 번째 WFM에 의해 나타낸다. 여기서 WFM의  $h(i, j)$ 는  $n_1 \times n_2$  샘플행렬에 의한 임펄스 응답형식인 컨벌루션  $h(i, j) * x(i, j)$ 를 나타낸다<sup>[2]</sup>. 다음의 (14)식은 Sugeno-type 퍼지규칙에서 퍼지평균을 나타낸 것이다.

IF  $x(i - n_1, j - n_2)$ 은  $f, x(i - n_1, j - n_2 + l)$ 은  $f, \dots, x(i - n_1, j + n_2)$ 은  $f, x(i - n_1 + l, j - n_2)$ 은  $f, \dots, x(i - n_1 + l, j + n_2)$ 은  $f, \dots, x(i + n_1, j - n_2)$ 은  $f, \dots, x(i + n_1, j + n_2)$ 은  $f,$

THEN

$$\bar{y}(i, j) = \frac{h(i, j) * x(i, j)}{N_i} \\ = \frac{\sum_{k=-n_1}^{n_1} \sum_{l=-n_2}^{n_2} \mu_f(x(i+k, j+l)) * x(i+k, j+l)}{\sum_{k=-n_1}^{n_1} \sum_{l=-n_2}^{n_2} \mu_f(x(i+k, j+l))} \quad (14)$$

그림 1과 같이 퍼지화된 픽셀 값은 비퍼지화 과정을 통하여 퍼지화된 데이터에서 원래 값을 찾기 위하여, 5x5 행렬의 25개의 픽셀 값을 퍼지화하고, (14)식은 퍼지평균을 나타낸 것이며, 퍼지평균으로부터 L-R 퍼지 집합인 비퍼지화에 대한 규칙의 추론 결과를 계산한다<sup>[2]</sup>. 퍼지평균에 의해서 얻어진 값은 (13)식을 이용하여 오차가 가장 적은 출력 값을 얻기 위한 퍼지평가자 값을 구한다.

그림 2는 FDNN의 하드웨어 구조로서, 퍼지함수의 양자화를 거쳐 퍼지화 된 데이터는 퍼지 평균 연산을 통하여 비퍼지화 되는데, 실시간 처리를 위하여 병렬 연산을 수행하고 그런 결과의 데이터들은 클럭에 동기되어 결정(Decision) 블록으로 전송되며, 비퍼지화 과정 동안 계산된 퍼지평가자 역시 Decision 블록으로 비퍼지 결과와 같이 전송된다. Decision 블록에서 비퍼지화 된 데이터들은 퍼지평가자와 절대값 연산 최소값을 찾게 되는데, 이 과정에서 평가자와 가장 유사한 비퍼지값을 찾게 된다.

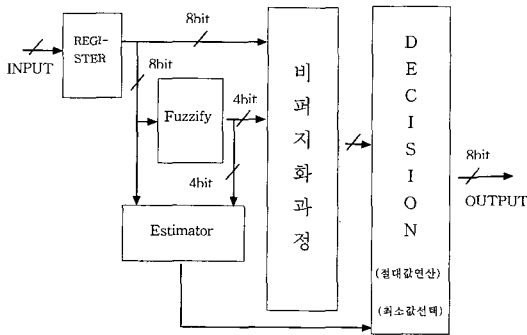


그림 2. FDNN의 하드웨어 블록도  
Fig. 2. Hardware Block of FDNN.

IV. 모의실험 및 결과 분석

입력영상 보트에 WFM을 적용하여 모의 실험을 행한 결과를 나타내면 그림 3과 같으며, 이 그림을 통하여 양자화 삼각 퍼지함수를 적용했을 때의 오차는 삼각 퍼지함수를 적용했을 때 보다 0.001~0.002정도의 오차가 더 많이 발생함을 알 수 있었고, 양자화 삼각 퍼지함수를 적용한 FDNN이 WFM보다 오차가 더 감소하였음을 확인 할 수 있었으며, 이들에 대한 오차는 다음 (15)식의 평균자승오차를 이용하였다.

$$MSE = \frac{\sum(X_{ij} - \bar{X}_{ij})^2}{\sum(X_{ij})^2} \quad (X: \text{원영상}, \bar{X}: \text{결과영상})(15)$$

또한 FDNN의 모의실험은  $|Y_E - Y_f|$ 가 최소가 될 때의 오차값이 허용오차 범위 안에 들어가도록 가중치를 변화시키는 과정을 통해서 이루어 졌으며, 최적의 허용오차 가중치 조절범위는 평균자승오차를 계산해서 결정하였다. 그림 4는 보트 입력 영상이고 그림 5, 6, 7은 보트 영상에 대해 30, 50, 70% 임펄스 잡음을 첨가한 후 Median, WFM, FDNN의 필터링을 행한 모의 실험 결과의 영상을 나타낸 것이다.

그림 8은 보트 영상에 대하여 Median, OC(Open-closing), CO (Close -Opening), WFM, FDNN의 필터링을 행한 모의 실험 결과 평균자승오차를 나타낸 곡선으로, FDNN을 적용한 영상이 매우 우수한 결과를 얻고 있음을 나타내고 있다.




그림 3. 삼각퍼지함수와 양자화 삼각 퍼지함수를 적용한 WFM과 FDNN의 평균자승오차  
Fig. 3. MSE of FDNN and WFM applied triangularity fuzzy function and quantization triangularity fuzzy function.





그림 4. 보트 원영상  
Fig. 4. The original image Boats.



(A) 30% 잡음영상




(D) FDNN


그림 5. 30% 잡음영상에 대한 필터링 결과  
Fig. 5. Results of Filtering for 30% Noise Image.




(B) MEDIAN



(A) 50% 잡음




(C) WFM



(B) MEDIAN




(C) WFM



(B) MEDIAN




(D) FDNN



(C) WFM

그림 6. 50% 잡음영상에 대한 필터링 결과  
Fig. 6. Results of Filtering for 50% Noise Image.



(A) 70% 잡음



(D) FDNN

그림 7. 70% 잡음영상에 대한 필터링 결과  
Fig. 7. Results of Filtering for 70% Noise Image

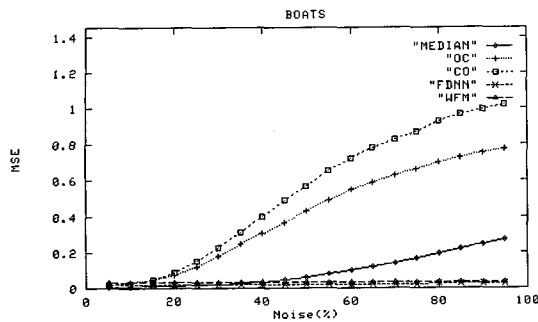


그림 8. 필터 종류에 대한 보트 영상의 평균자승오차  
Fig. 8. MSE of Boats Image for Filter sort.

## V. 결론

영상처리를 위한 시스템의 효율성의 증가와 영상 인식 알고리즘을 이용한 화상처리 및 패턴인식, 개별인식, 보안 시스템 등의 응용 분야에 적용할 수 있는 인식 시스템의 개발이 요구되고 있다. 영상인식에 있어서 신 경망을 이용한 많은 알고리즘이 제안되고 있으나 연산의 가중치와 지도학습 방식에 의해서 처리되기 때문에 영상 실시간 처리를 위해 병렬 연산회로의 집적화가 필요하다.

본 연구에서는 영상처리를 위하여 DBNN에 삼각 퍼지함수를 적용하여 FDNN을 구현하였으며, 임의의 입력 데이터가 입력되면 기준영상 중에서 유사도가 가장 큰 기준 영상을 찾아 국부 승리자로 선택하고, 국부 승리자 중에서 전체 승리자를 선택하여 최종 출력값을 얻을 수 있도록 계층적 구조의 FDNN을 구현하였다. 그리고 삼각함수와 양자화 된 삼각 퍼지함수를 WFM에 적용하여 모의실험을 통하여 비교하였고, 또한 잡음의 특성에 따라서 영상에 포함된 잡음을 완전히 제거할 수 없는 단점을 개선하기 위하여, 계층적 구조의 DBNN에 퍼지알고리즘을 적용한 FDNN을 구현하여 영상에 포함된 잡음을 제거함과 동시에 정보의 손실을 최소화하고 최적의 정보를 얻을 수 있는 고속 가중 FDNN을 구현하였으며, 모의실험을 통하여 그 성능을 비교하였다. 그림 3에서는 잡음에 따른 전체적인 오차는 상승하는데 항상 일정하게 양자화 삼각 퍼지함수를 적용한 WFM보다 FDNN이 약 0.001~0.002 정도의 오차가 적음을 알 수 있었으며, 구현된 FDNN이 잡음의 비에 따라서 최고 0.004~0.005정도의 오차가 있음을 알 수 있었다.

그림 5, 6, 7과 같이 30%, 50%, 70%의 잡음이 실린 영상에 대하여 Median과 WFM, FDNN의 필터링을 행한 결과 FDNN이 우수함을 나타냈으며, 보트의 영상에서 각각의 Median과 OC, CO, WFM, FDNN의 MSE를 비교 분석한 결과, 그림 8과 같이 제안된 FDNN이 우수함을 알 수 있었다. 앞으로 영상의 에지 정보를 보다 선명하게 향상시킴으로써 화상처리 및 인식 시스템 등에 응용할 수 있을 것으로 사료된다.

## 참고 문헌

- [1] K. Fukushima, "A Neural Networks for Visual Pattern Recognition", IEEE Computer Magazine, pp.65-75, March, 1988.
- [2] Chao-Lieh Chen, Chang-Shing Lee and Yau-Hwang Kuo. "Design of high speed weighted fuzzy mean filters with generic LR fuzzy cells", IEEE, 1996.
- [3] C-S Lee, Y-H Kuo and P-T Yu. "Weighted fuzzy mean filters for heavy-tailed noise removal", Proceedings of ISUMA-NAFIPS'95, IEEE CS Press, pp. 601-606.
- [4] C-S Lee, Y-H Kuo. "Three dimensional weighted Fuzzy mean filters for color image filtering", Proceeding of international Joint conference of CFSA/IFIS/SOFT'95 ON Fuzzy Theory and Applications, world scientific Process, pp.423-428.
- [5] Chao-Lieh Chen and Yau-Hwang Kuo, "Fuzzy inference processor design with generic LR fuzzy cells", proceedings of the international Joint Conference of CFSA/IFIS/SOFT'95 on Fuzzy Theory and Applications.
- [6] S. Y. Kung, J. N. Hwang, "Parallel architecture for artificial neural nets", In Proceeding IEEE, International Conference on Neural Networks, vol. 2, pp. 165-172, July 1988.
- [7] S. Y. Kung, J. S. Taur. Decision based neural networks with signal/image classification application. In Proceeding, IEEE Transactions on neural, networks for signal Processing, 1993.

- [8] 송창영, 문성룡, 김환용, 패턴인식을 위한 디지털 DBNN의 설계, VOL.21/NO.11, 한국통신학회논문지, Nov, 1996

---

저자 소개

卞 吾 星(正會員) 第 35 卷 C 編 第 7號 參照  
원광대학교 전자공학과 대학원생

文 成 龍(正會員) 第 35 卷 S 編 第 4號 參照  
원광대학교 전자공학과 조교수

李 喆 熙(正會員) 第 35 卷 C 編 第 7號 參照  
원광대학교 전자공학과 대학원생