

DBNN구조를 갖는 가중 FDNN의 구현

*이철희, 변오성, 홍석명, 최선근, 사춘화**, 문성봉
원광대학교 공과대학 전자공학과

**효정 여자 중학교

Implementation of Weighted FDNN with Structure of DBNN

*C.H. Lee, O.S. Byun, S.M. Hong, S.K.Choi, C.H. Seo**, S.R. Moon

Dept. Electronic Engineering Wonkwang University

** Hyo Jung girl Middle School

요약

본 논문에서는 고분해도에 적합한 WFM(Weighted Fuzzy Mean)필터를 이용하여 잡음 제거 능력 향상과 정보 손실을 최소화할 수 있도록 WFM의 성능을 개선하기 위하여 계층적 구조의 DBNN에 퍼지알고리즘을 적용하여 구현하였으며, 모의실험을 통하여 성능을 비교 분석하였다. 모의 실험 결과 Boats의 영상에 대해서 MSE를 비교 분석한 결과 가중FDNN이 우수함을 확인하였다.

I. 서론

멀티미디어 기기의 발달로 인하여 정보 전달 과정의 이미지화가 요구되어지는 고급 영상 정보에서의 잡음 제거와 데이터 복원, 전달과정에서의 보존이 중요한 역할을 형성하고 있고, 화상인식과 이를 이용한 보안시스템등의 응용 가능한 시스템의 개발에 대한 연구가 진행되고 있다.[1-5] 특히, 영상처리에 효과적인 신경망을 통한 잡음, 영상 인식과 잡음 제거에 효과적인 알고리즘을 제공하므로 활용 가치가 높다. 지도학습 모델에서 지도사(teacher)는 적절한 조결과, 결점이 온마를 지를 판별하게 된다. DBNN 모델의 경우, 선형 퍼셉트론 이론에 의한 결정 경계치에 의해 선형적으로 이진 분류하여 결정치를 결정한다.[7, 11]

본 논문에서는 WFM 필터[12, 15]를 70%잡음에 포함된 영상에 적용하여 모의실험을 통하여 비교 분석하고, 계층적 구조의 DBNN에 퍼지알고리즘을 적용한 가중FDNN을 구현한 후 성능을 비교, 분석하고자 한다.

II. DBNN의 알고리즘

먼저 DBNN(Decision based Neural Network) 알고리즘의 지도학습(supervised learning) 매트릭스는 검색단계(retrieving phase)와 학습단계(learning phase)로 나누어지는데 학습단계에서는 영상들을 정확하게 분류하기 위한 가중치들을 훈련시키고 최상의 판별함수(disclaiming function)에

의해서 결정 경계치(decision boundary)를 결정한다.[7, 11] 선형 판별함수를 갖는 선형 퍼셉트론의 기본 구조는 식(1)과 같으며,

$$y = \phi(X, W) = \sum_{j=1}^L W_j x_j + \theta \quad (1)$$

가중치 파라미터를 첨가한 임계치 θ w_{p+1} 을 대입하면 식(2)와 같고,

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

Z는 중기된 영상 X로써 식(3)과 같다.

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

식(1)과 (2)를 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 식(4)와 같다.

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

여기서, η 는 양의 학습률이고, $t^{(m)}$ 은 m 번째 임계치(threshold value), $d^{(m)}$ 은 결정값으로 $y > 0$ 이면 1을, $y < 0$ 이면 0의 값을 갖는다.

결정 경계치는 판별함수 $\phi(X, W)$ 에 의존되기 때문에 가중치 벡터 W가 선형 판별함수의 gradient 방향이면 긍정학습이고, 반대방향이면 부정학습(antireinforced learning)으로 수정되며, ΔW 의 가중치 벡터 변화값 ΔW 는 식(5)와 같고,

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

가중치 벡터 W에 대한 함수 ϕ 의 gradient 벡터는 식(6)와 같다.

$$\nabla \phi(X, W) = \frac{\partial \phi(X, W)}{\partial W} \quad (6)$$

선결정 클래스들 $\{ \Omega_1, \Omega_2, \dots, \Omega_L \}$ 중에서 임치되는 $s = (X^{(1)}, X^{(2)}, \dots, X^{(M)})$ 은 주어진 입력영상의 집합이라고 가정하면, 각 클래스는 선

면함수 $\Phi(X, W_i)$ 을 갖는 하부 망(subnet)으로 모델화 된다. m 번째 입력영상 $X^{(m)}$ 은 클래스 Ω 에 속한다고 가정하면 식(7)과 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 Winning 클래스는 j 번째 클래스(하부망)가 되며 영상에 대한 수정된 다음 조건을 따른다.

$$W_i^{(m+1)} = W_i^{(m)} + \eta \nabla \Phi(X, W_i) : \text{긍정학습} \quad (8)$$

$$W_i^{(m+1)} = W_i^{(m)} - \eta \nabla \Phi(X, W_i) : \text{부정학습}$$

전체승리자(global winner)는 부분승리자에 의해 결정되며, 1 번째 클래스의 부분승리자를 선택하는 함수는 식(9)과 같이 표현할 수 있다.

$$s_j = \text{Arg} \max_{s_j} \Phi_j(X, W_j) \quad (9)$$

여기서, s_j 은 클래스의 부분승리자 식(8)의 DBNN 학습 단계에 퍼지퍼텐은 적용하기 위하여 변형하면 식(10)과 같으며,

$$W_{s,u}^{(m+1)} = W_{s,u}^{(m)} + \eta_m \nu_j \pi_i \quad (10)$$

$$W_{s,u}^{(m+1)} = W_{s,u}^{(m)} - \eta_m \nu_j \pi_i$$

여기서 $\pi_i = \nabla \Phi(x, W_i)$ 이고 ν_j 는 L-R 형태 멤버쉽 함수의 파라미터이다.

III. 삼각 퍼지함수의 양자화

식(10)에서 L-R함수의 멤버쉽 함수로 사용된 L-R 퍼지집합 $[m, \alpha, \beta]_{LR}$ 이고, R: 도이스 원터림을 위한 퍼지 평가부값을 찾기 위해 사용된 L-R 퍼지 구간이다[2, 9]

퍼지 구간 R: L-R 형태 퍼지 숫자이며, 멤버쉽 함수는 아래와 같다.

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

여기에서 L과 R은 형태(shape)함수이고, ν 라고 α, β, ν 는 퍼지 구간에 대한 파라미터이다. L과 R을 가우시안 모양을 갖는다고 가정한다면 식(12)과 같다.

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

여기에서 경계값 다른 원천은 $a \nabla b = \max(a-b, 0)$ 이고, 퍼지 구간은 $L [m, m, \alpha, \beta]_{LR}$ 로 나타낸

다. 본 논문에서는 L-R 퍼지 삼각함수의 이분을 FDNN에 사용하기 위한 삼각 퍼지함수로서 퍼지 레벨은 0 ~ 255사이의 그레이 스케일의 레벨값을 [0, 1]로 퍼지화 하는 데에 사용된 퍼지함수로 DARK, MIDDLE, BRIGHT의 세 개의 퍼지 함수를 이용하여 퍼지화 하였다. 퍼지화에 사용한 함수는 DARK(45, 14, 44), MIDDLE(125, 44, 44), BRIGHT(205, 44, 44)로 설정을 하였으며, 그림 1과 같이 그레이 스케일(Gray scale)값을 삼각 퍼지함수에 이용함에 있어 비트(bit)로 양자화 하는 방법을 제안하고, 레벨링(leveling)을 낮게 양자화하여 설계기 용이하도록 하였다. 각 퍼지함수가 적용되는 구간을 16등분하여 그레이 스케일의 레벨 값을 0 ~ 8사이의 디지털 값으로 표현 가능하였다. 이렇게 퍼지화한 레벨 값을 0 ~ 8 사이의 값으로 표현하면 디지털 값이 가능하도록 하였다. WFM의 원리를 기초로 3부분(DARK, MIDDLE, BRIGHT)의 영역중 각 부분의 영역을 그림 1과 같이 디지털화하기 위해서 1 ~ 80를 5단위씩 세분화하였다. 양자화 오차는 레벨값이 정수이므로 무시할 수 있는 정도에 지나지 않는다. 이렇게 함으로써 퍼지화하는 부분의 디지털 처리가 가능해지고, 전체 구조에서도 디지털 처리가 가능해졌다.




Fig.1 Quantization of Triangularity Fuzzy Function

IV. 가중 FDNN의 구조

일반적인 L-R삼각함수에 퍼지라는 개념을 도입하여 전체 0~255를 0과 1사이의 값으로 나타내어, 만약 1기 사용된 퍼지 구간이라면, $y_R(\cdot)$ 에 의해서 나타나는 퍼지 평가자 E는 다음 식(13)에 의해서 산출된다.

$$y_R(X(i, j)) = \frac{X(i, j) * x(i, j)}{N_{LR-L}} \left(\sum_{k=1}^{m_1} \sum_{l=1}^{m_2} \nu_{LR-L}(x(i, k, l, j)) * x(i, k, l, j) \right) \quad (13)$$

여기 X(i, j)는 (i, j)에서 m_1, m_2 샘플 행렬 중심

이고, (i, k, j, D) 는 피지 구간 LR_j 의 입력 (i, k, j, D) 에 대한 멤버십 크레이브이며, F_{min2} ($|I|=X, |I|$: 피지숫자이다), $n = |F_{min2}|$ 이다. WFM 필터의 함수는 입력 $x(i, j)$ 의 n 번째 WFM에 의해 나타낸다. 여기서 WFM의 $h(i, j)$ 는 $m \times m$ 샘플링 면에 의한 임펄스 응답형식의 컨볼루션(convolution) $h(i, j) * x(i, j)$ 를 나타낸다.[12, 15] 다음의 식(14)은 Sugeno-type 피지 규칙은 피지 평균을 나타낸다.

$$IF \quad x(i - n_1, i - n_2) \in f, x(i - n_1, i - n_1 + D) \in f, \dots, x(i - n_1, i + n_2) \in f, x(i - n_1 + L, i - n_2) \in f, \dots, x(i - n_1 + L, i - n_2 + D) \in f, \dots, x(i - n_1 + L, i + n_2) \in f, \dots, x(i - n_1, j - n_2) \in f, x(i - n_1, j - n_1 + D) \in f, \dots, x(i - n_1, j + n_2) \in f \quad THEN \quad y(i, D) = \frac{h(i, D) * x(i, D)}{N_i} \quad (14)$$

$$= \frac{\sum_{i=n_1}^i \sum_{k=n_2}^k \mu(x(i, k, j, D)) * x(i, k, j, D)}{\sum_{i=n_1}^i \sum_{k=n_2}^k \mu(x(i, k, j, D))}$$

그림 1과 같이 피지화된 피셀 값을 비피지화 과정을 통하여 피지화된 데이터에서 원래 값을 찾기 위하여 5x5 행렬의 25개의 피셀 값을 피지화하고 피지평균은 식(14)와 같으며 피지평균에서 L-R 피지 집합인 비피지화에 대한 규칙의 추론 결과를 계산한다.[13-15] 피지평균에 의해서 얻어진 값은 식 (13)을 이용하여 오차가 가장 적은 출력 값을 얻기 위한 평가자 값을 구하게 된다.

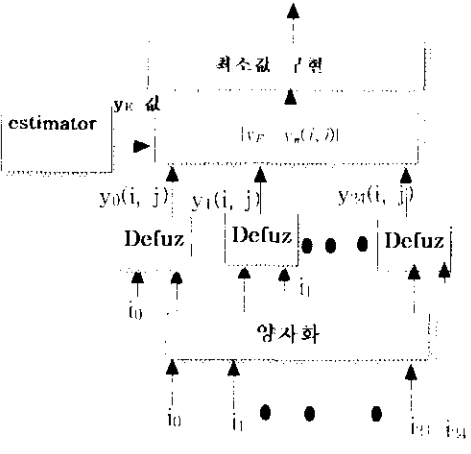


그림 2. 가중 FDNN의 하드웨어 구조
Fig. 2. Hardware Structure of WeightedFDNN

그림 2는 FDNN의 하드웨어 구조로써 피지함수의 양자화를 거쳐 피지화된 데이터의 피지 평균

연산을 통하여 비피지화 되는데, 실시간 처리를 위하여 병렬 연산을 수행하고 이런 결과의 데이터들은 입력에 동기 되어 decision 블록으로 전송되며, 비피지화 과정동안 계산된 평가자 역시 decision 블록으로 비피지 결과와 같이 전송된다. Decision 블록에서 비피지화된 데이터들은 평가자와 절대값 연산과 최소값을 찾게 되는데, 이 과정에서 평가자와 가장 유사한 비피지 값을 찾는 결과를 얻게된다. 이 과정에서 정보의 손실을 최소화하는 가중 FDNN의 출력을 얻을 수 있다.

V. 모의실험 및 결과 분석

위험영상 Boats에 WFM을 적용하여 모의 실험한 결과 양자화 삼각 피지 함수를 적용했을 때 오차는 삼각 피지함수를 적용했을 때 보다 그림 3과 같이 0.004 ~ 0.005 정도의 오차가 발생함을 알수 있었다. 양자화 삼각 피지함수를 적용한 가중 FDNN이 WFM보다 오차가 더 줄어들었음을 그림 3과 같이 확인 할 수 있었으며, 이들에 대한 오차는 식(15) MSE(Mean Square Error)를 이용하였다.

$$MSE = \frac{\sum (X_n - X_n)^2}{\sum (X_n)^2} \quad (15)$$

(X: 원영상, X: 결과영상)

$|Y_n - Y_n|$ 가 최소가 될 때의 오차값이 허용오차 범위 안에 들도록 기준치를 변화시키는 과정을 통해 가중 FDNN의 모의실험이 이루어졌으며, 최적의 허용오차 기준치 조절범위는 MSE를 계산해서 결정하였다. 그림 4는 Boats 입력 영상이고 그림 5 은 Boats 영상에 대해 70% 임펄스 잡음을 첨가한 후 MEDIAN, WFM, 가중 FDNN을 적용하여 모의 실험한 결과의 영상들을 나타낸 것이다. 그림 3은 Boats 영상에 대하여 Median, OC, CO, WFM, 가중 FDNN을 적용한 모의 실험 결과에 대하여 MSE를 나타낸 곡선으로써 가중 FDNN을 적용한 영상이 가장 우수한 결과를 얻을 수 있음을 확인하였다.




그림 3. 필터 종류에 대한 Boats영상의 MSE
Fig.3 MSE of Boats Image for Filter sort





그림 4. Boats 원영상
Fig.1 The original image Boats



(A)(B)
(C)(D)
(E)(F)
(A) 70% 잡음영상
(B) MEDIAN
(C) CO
(D) OC
(E) WFM
(F) 가중 FDNN

그림 5. 70% 잡음영상에 대한 필터링 결과
Fig.5 Results of Filtering for 70% Noise Image

V. 결 론

영상 처리에 있어서 신경망을 이용한 많은 알고리즘이 제안되고 있으나 영상의 가중치화 기호학습 방식에 의해서 처리되기 때문에 영상 실시간 처리를 위해 병렬연 방식과 화소의 집지화가 필요하다.

본 논문에서는 양자화된 삼각 퍼지함수를 WFM(Weighted Fuzzy Mean)에 적용하여 모의 실험을 통하여 비교 분석하고, 모한 잡음의 특징에 따라서 영상에 포함된 잡음을 완전히 제거하기 못하는 단점을 개선하기 위하여, 개층식 구조의 DBNN에 퍼지알고리즘을 적용한 FDNN을 구현하여 영상에 포함된 잡음을 제거함과 동시에 정보의 손실을 최소화하고 최적의 정보를 얻을 수 있는 가중 FDNN을 구현하였으며, 모의실험결과 그림 5와 같이 잡음 70%인 영상에 대하여

Median과 WFM, 가중 FDNN을 적용한 결과 가중 FDNN이 우수함을 확인하였으며, 앞으로 영상의 예각정보를 보다 선명하게 향상시켜으로써 화상처리 및 인식 시스템 등에 응용할 수 있을 것으로 사료된다.

참고문헌

1. Robert L. Harvey, Neural Network Principles, Prentice-all, Inc., 1994.
2. S. Y. Kung, Digital Neural Networks, PTR Prentice-Hall, Inc, 1993.
3. K. Fukushima, "A Neural Networks for Visual Patten Recognition", IEEE Computer Magazine, pp. 65-75, March, 1988.
4. K. Wojtek Przytul, Viktor K. Prasanna, Parallel Digital Implementations of Neural Networks, Prentice-Hall, Inc, 1993.
5. R. C. Gonzalez, R. E. Woods, Digital Image Processing, Addison-Wesley Publishing Company, 1992.
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, InProceeding, IEEE Transactions on neural, networks for signal Processing, 1993
8. C. H. Chen, Fuzzy Logic and Neural Network Handbook, McGraw-Hill Series on computer Engineering, 1997.
9. 이광형, 오길복, 박기이론 및 응용(I, II권), 흥남과학출판사, 1991.
10. 송장영, 문성용, 김학용, 폐탄인식을 위한 디지털 DBNN의 설계, VOL.21/NO.11, 한국통신학회논문지, Nov, 1996.
11. Bart Kosko, Fuzzy Engineering, Prentice Hall International, Inc, 1997.
12. 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.
13. Chi, Zhen, Fuzzy Algorithms, Singapore: River Edge, N.J. World Scientific, 1996.
14. Bernji, Hamid R. Fuzzy logic and neural networks, Piscataway, NJ: Institute of Electrical and Electronics Engineers, Inc, 1992.
15. Granino A. Korn, Neural networks and fuzzy-logic control on personal computers and workstation, Cambridge, Mass: MIT Press, 1995.