

초음파 검사 기반의 용접결함 분류성능 개선에 관한 연구

김재열*, 윤성운+, 김창현**, 송경석**, 양동조**

Performance Comparison of Neural Network Algorithm for Shape Recognition of Welding Flaws

Jae-Yeol Kim*, Jae-Ki Sim, Dong-Gi Lee, Chang-Hyun Kim, Kyung-Seok Song, Dong-Jo Yang

Abstract

In this study, we made a comparative study of backpropagation neural network and probabilistic neural network and bayesian classifier and perceptron as shape recognition algorithm of welding flaws. For this purpose, variables are applied the same to four algorithms. Here, feature variable is composed of time domain signal itself and frequency domain signal itself. Through this process, we confirmed advantages/disadvantages of four algorithms and identified application methods of four algorithms.

Key Words : Welding Flaw (용접결함), Shape Recognition Algorithm (형상인식 알고리즘), performance comparison (성능비교)

1. 서론

비파괴검사의 분야 중에서 초음파 탐상검사는 결함의 위치에 대한 정량적인 값을 판정할 수 있는 장점을 가지고 있으나, 결함의 종류, 형상, 크기 판정에 있어서는 검사자의 경험 및 주판에 의존하여 신뢰성 및 재현성이 적은 단점이 있는 관계로 방사선 투과검사가 주로 이용되고 있다. 그러나, 방사선 투과검사는 탐상면에 평행하게 위치하는 슬래그 혼입(slag inclusion), 기공(porosity) 등의 체적결함에 대해서는 우수한 검출능력을 가지는 반면에, 탐상면에 수직한 융합불량(lack of fusion), 균열(crack) 등의 선형결함에 대해서는 탐상이 어려운 단점이 있다⁽¹⁾.

그러므로, 초음파 탐상검사는 현장적용의 용이성과 정량적인 값의 취득이 가능하고, 방사선 투과로서는 기하학적인 형상 및 방향성 때문에 발견하기 어려운 체적결함과 선형결함을 동시에 탐상할 수 있다는 관점에서 결함의 종류, 형상, 크기를 판정하기 위한 연구가 현재까지 진행되고 있다. 용접결함의 종류 판별은 각 결함의 종류에 있어서도 형상과 크기 등이 상이하게 다르므로 실제의 결함을 분류하기 위해서는 먼저 가장 큰 특징이 될 수 있는 용접결함의 특징변수로부터 다시 세부적인 특징을 분류하는 단계를 거쳐야 하며, 사실상 가장 중요한 단계는 용접결함의 가장 큰 특징을 선택하는 특징변수의 추출로서 결함분석의 정확도에 가장 큰 영향을 미치게 된다^{(2),(3),(4)}.

* 발표자, 조선대학교 기계공학과 (jykim@chosun.ac.kr)

주소: 501-759 광주광역시 동구 서석동 375

+ 조선대학교 기계공학과

++ 조선대학교 대학원

2. 신호형상 분류

초음파 탐상기를 사용하여 얻은 각 결함에 대한 반사신호의 아날로그 데이터를 얻어서 이를 PC-based Oscilloscope을 이용하여 디지털 데이터 값을 취득함으로써, 결함의 종류 판별을 위한 초음파 신호처리를 수행하여 특징의 정보군을 형성한다. 데이터의 처리과정은 원데이터를 수학적 변환식을 사용하여 다른 영역으로 만들고 이들로부터 형상을 구별 할 수 있는 특징값(feature)을 얻어내는 과정이다. 이 과정에서 특징들 사이의 상호 비교를 동일한 차원에서 처리하기 위해 적절한 방법^{(2),(3),(4)}을 사용하여 정규화 하고 서로 다른 분류군에 대하여 오차를 계산한다. 이 오차가 허용할 수 없을 정도로 크게 되면 다음과정은 무의미해지며 다른 측정법 또는 특징값 추출법을 사용하여 데이터를 얻게 된다. 이렇게 얻은 특징값 모음을 사용하여 각 분류군(class) 사이를 적절한 결정함수(decision function)로 나누는 분류기(classifier)를 설계하는 과정을 통하여 용접부 결함을 분류하기 위한 초음파 신호의 형상 분류에 대한 최종적인 결과를 얻게된다.

3. Bayesian 및 Perceptron 분류기 적용

3.1 Bayesian 분류기

특징변수의 수가 세분화되어 있는 관계로 평균값과 표준편차를 이용한 단순화된 거리함수를 사용한 경험적 Bayesian 분류기로서 분류를 수행하며, 설계한 경험적 Bayesian 분류기의 이론적 배경은 다음과 같다.

미지의 형상변수 X가 r = s 인 경우를 제외하고, 다음식을 만족할 경우에 X는 s에 속한다고 할 수 있다.

$$P(s|X) > P(r|X) \quad (1)$$

식(1)을 Bayesian 법칙에 따라 쓰면 다음과 같다.

$$P(s)P(X|s)/P(X) > P(r)P(X|r)/P(X) \quad (2)$$

이 식에서 P(X)는 형상의 분류 및 인식에 무관하게 되며, 이러한 이유로 인하여 다음의 식과 같이 쓸 수 있다.

$$P(s)P(X|s) > P(r)P(X|r) \quad (3)$$

N개의 특징변수에 대해서 P(X|s)을 계산하는 방법은 다음의 식을 이용한다.

$$P(X|s) = \prod_{i=1}^N P(x_i|s) \quad (4)$$

식(4)를 식(3)에 대입하면 다음과 같다.

$$P(s) \prod_{i=1}^N P(x_i|s) > P(r) \prod_{i=1}^N P(x_i|r) \quad (5)$$

모든 분류군에 대해서 우선확률(priori probability)이 모두 같다고 가정하면 다음의 식(6)과 같이 쓸 수 있다.

$$\prod_{i=1}^N P(x_i|s) > \prod_{i=1}^N P(x_i|r) \quad (6)$$

(여기서, r = s 인 경우는 제외된다.)

3.2 Perceptron 분류기

퍼셉트론 분류기는 A층 퍼셉트론 i로부터의 출력을 A_i로, 퍼셉트론과 R층의 퍼셉트론의 결합강도를 W_i로, R층 퍼셉트론의 임계치를 θ로, 퍼셉트론의 함수를 f로 나타내면 다음과 같은 식으로 나타낼 수 있다.

$$R = f(\sum W_i \cdot A_i - \theta) \quad (7)$$




Fig. 1. perceptron classifier

이 출력 R과 교사신호 T를 써서 결합강도 W_i(t)를 바꾸는 과정이 퍼셉트론 학습이며, 다음의 식으로 나타낸다.

$$W_i(t+1) = W_i(t) + C \cdot (T - R) \cdot A \quad (8)$$

여기서 C 는 상수이고, 식(8)의 $W_i(t)$ 는 시간 t 때의 무게이며, $W_i(t+1)$ 은 학습 후의 결합강도를 나타낸다. 또한, 교사신호 T 가 두가지의 패턴(즉, X 및 Y 일 경우)을 갖는 경우라면, 패턴 X 일 경우는 $T=1$ 이 되고, 패턴 Y 일 경우에는 $T=0$ 이 된다.

그러나, 퍼셉트론은 이동이나 확대 또는 회전된 패턴의 유사성에 대하여 식별이 곤란하며, S 층이 2차원 평면이 될 경우 학습한 패턴과 같은 패턴을 다른 위치에 입력했을 때 도 같은 패턴으로 식별이 곤란하다는 단점을 갖는다.

3. 역전파 및 확률 신경회로망의 적용

3.1 역전파 신경회로망

다층 퍼셉트론의 일종인 BPNN은 입력층과 출력층 사이에 은둔층이 존재하며, 다음의 Fig. 2.에 역전파 신경망의 계층구조를 나타내었다.




Fig. 2. backpropagation neural network

그리고 은둔층을 증가하고 비선형 활성화함수를 사용함에 따라서 결정구역이 고급화 되는 장점을 확보할 수 있으므로 본 연구에서 은둔층과 출력층의 비선형 활성화함수로서 시그모이드 함수를 적용하여 결정영역이 통상의 직선이 아닌 완만한 곡선으로 경계가 형성되도록 하여 은둔층을 학습하는 역전파 학습 알고리즘을 수행하도록 하였다.

Fig. 2.의 모델을 대상으로 하여 입력층 (I)와 은둔층 (H) 및 출력층 (O)은 다음의 식으로 정의된다.

$$\begin{aligned}
 H_j &= f\left(\sum_i W_{ji} \cdot I_i + \theta_j\right) \\
 O_k &= f\left(\sum_j W_{kj} \cdot H_j + \theta_k\right)
 \end{aligned}
 \quad (9)$$

입력층 (I)과 은둔층 (H)의 2승오차 (E_p)를 줄이기 위한 가중치 (W_{ji})는 다음의 식으로 재조정된다.

$$W_{ji} = -\eta_3 \cdot \frac{\delta E_p}{\delta W_{ji}} = \eta_3 \cdot \delta_j \cdot I_i \quad (10)$$

또한, 은둔층 (H)과 출력층 (O)의 2승오차 (E_p)를 줄이기 위한 가중치 (W_{kj})는 다음의 식으로 재조정된다.

$$W_{kj} = -\alpha_2 \cdot \frac{\delta E_p}{\delta W_{kj}} = \eta_2 \cdot \delta_k \cdot H_k \quad (11)$$

모든 패턴 (P)에 대한 2승오차 (E_t)는 다음의 식으로 나타낼 수 있다. 여기서, (T_{pk})는 목표벡터이며, (O_{pk})는 출력벡터이다.

$$E_t = \sum_p \sum_k (T_{pk} - O_{pk})^2 / 2 = \sum_p E_p \quad (12)$$

이러한 과정을 통하여 각 패턴 P 의 학습으로 2승오차 (E_p)를 점차 줄임으로서 전체적으로 오차함수 (E_t)를 극소화 한다.

3.2 확률 신경회로망

RBF(radial basis function : RBF) 신경회로망의 일종인 PNN은 시험에 의하여 취득한 데이터로부터 특징값의 분포 특성을 확률밀도함수(probabilistic density function : PDF)의 형태를 추론하는 특징을 가지고 있다. PNN의 구조를 살펴보면 입력층과 출력층 사이에 패턴층과 합산층이 존재하며 Fig. 3.과 같은 계층구조를 갖는다.

PNN은 4개의 층으로 구성되어 있다. 첫 번째 층은 입력층으로서 각 표본의 특징벡터 (X_i)가 PNN에 공급된다. 두 번째 층은 패턴층으로서 입력층에 공급된 표본의 특징값 (X_i)에 가중치 (W_{ij})를 곱한 결과들의 합을 받아들여서 그 값에 지수함수를 적용한 값을 출력한다. 세 번째 층은 합산층으로서 합산층의 각 노드(node)들은 패턴층의 노드들 중 자신과 같은 범주에 속한 노드들에만 연결되어 있는데 연결된 패턴층에 노드들의 출력의 합을 입력으로 받아들인 후 그 결과를 출력한다. 마지막으로 네 번째 층은 출력층으로서 최종적인 출력이 결함의 분류과정에 사용된다⁽⁶⁾. 다른 종류의 신경회로망과는 달리 PNN의 구조는 주어진 문제에서 가지고 있는 결함의 종류의 수와 학습과정에서 사용된

학습표본의 수에 의하여 결정된다. PNN은 적절한 연산을 위하여 큰 대표적인 훈련집합을 필요로 하고 σ 로 일컬어지는 너비 파라미터의 적절한 선택을 요구한다. 너비 파라미터는 각 모집단 또는 클래스에 관해 다르지만 여기서는 하나의 파라미터만을 사용하였다. 확률밀도함수의 추정량은 가우스 가중합수를 사용한다.

$$g(x) = \frac{1}{n} \sum_{i=1}^n \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (13)$$

n 은 클래스 내에 있는 사례들의 개수이고, (X_i) 는 클래스 내에 있는 특정한 사례를 나타내며, X 는 입력이고, σ 는 너비 파라미터를 나타낸다.




Fig. 3. probabilistic neural network

4. 실험장치

4.1 용접 시험편

용접결합의 탐상을 위한 용접시험편을 제작하기 위해서 사용한 재료는 일반 구조용 압연강재(SB41)로 평판에 아크 용접을 사용하여 용접시험편을 제작하고, 내재된 결함들은 자연 결함들이다. 제작상의 난점으로 인하여 Sonaspection Co, England 에 제작을 의뢰하여 용접결합 시험편을 제작하였으며 결함의 내용은 기공, 슬래그혼입, 용입불량, 용합 불량, 크랙으로 구성되었으며, 결함의 위치에 따라서 동일한 결함이 몇가지 더 제작되었다.

제작된 시험편의 용접결합을 대상으로 하여 분류를 수행하였다. 분류에 사용된 데이터의 전체 수량은 각각의 결함에 대하여 10회의 반복검사를 통하여 190개를 적용하였으며, 결함패턴의 학습에 사용된 학습데이터의 수량은 8개로서 역전파 신경회로망과 확률 신경회로망에 동일하게 적용하였다. 또한, 분류하려는 결함의 종류는 체적결합은 6종류이고, 선형결합은 13종류이다.

4.2 장치 구성

본 실험에서 사용된 초음파 측정 분석장비의 시스템은 Fig. 4와 같다. 초음파 탐촉자(5Z 10×10 A70)는 공진주파수 5MHz의 고감도형 경사각 탐촉자를 사용하였으며, 초음파 탐상기는 TOKIMEC사의 SM-300를 사용하였다. 결합으로부터 반사된 초음파 신호를 PC 기반의 oscilloscope를 사용하여 취득하였고 취득한 신호를 시간영역과 주파수영역에서 분석하였으며, 분석을 통한 특징을 적용함에 있어서 각각의 영역에서 결합패턴으로 대표되는 형태의 신호를 특징변수로 사용하였다.

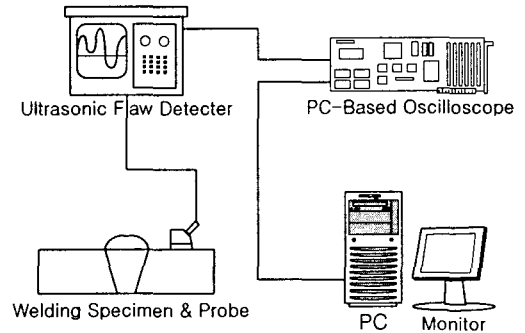


Fig. 4. Experimental apparatus

5. 실험결과 및 해석

Fig. 5와 Fig. 6.은 각각 선형결합과 체적결합의 대표적인 신호의 형상이며, 신호의 peak 부분을 관찰하면, 대표적인 차이점이 나타남을 알 수 있다.





Fig. 5. typical signal of planar flaw




Fig. 6. typical signal of volumetric flaw

Fig. 7.와 Fig. 8.은 체적결합에서의 시간영역과 주파수영역의 신호이고, Fig. 9.은 선형결합에서의 시간영역과 주파수영역의 신호를 통합하여 특징변수로 사용하였다.




a) Time domain b) Frequency domain

Fig. 7. Volumetric flaws signal (Type A)



a) Time domain b) Frequency domain

Fig. 8. Volumetric flaws signal (Type B)



a) Time domain b) Frequency domain

Fig. 9. Planar flaws signal




Fig. 10. Classification rates of each algorithm

위에 표시한 Fig.10.에 각 알고리즘을 적용하였을 경우의 결합의 분류율을 나타내었으며, 많은 차이를 나타내지는 않

지만, PNN과 BPNN이 Bayesian(BC) 분류기 및 Perceptron(PE)에 비하여 우수함을 확인 할 수 있다.

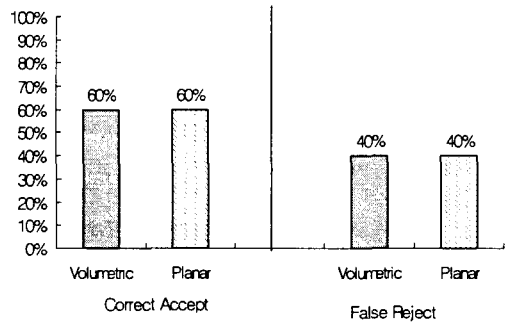


Fig. 11. Classification results of BPNN

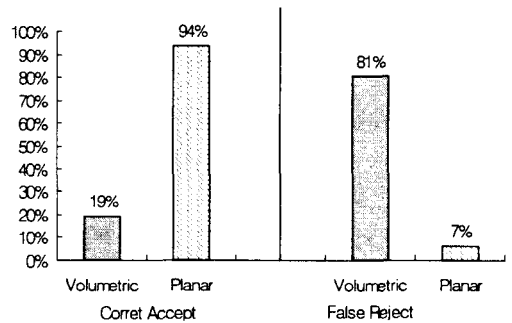


Fig. 12. Classification results of PNN

전체적인 분류율은 Fig. 10.에 나타난 것처럼 BPNN과 PNN은 동일하게 확인되었지만 각각의 분류결과를 확인하면, BPNN은 Fig. 11.처럼 작은 학습률 즉, 적은 수량의 데이터에 대하여도 안정적인 결과를 도출하였으나, PNN은 각각의 데이터 간의 거리에 의한 확률밀도함수에 기반을 두는 관계로 Fig. 12.에서처럼 충분한 확률밀도가 구성되는 선형결합에 대하여서는 높은 분류율을 보인 반면에 확률밀도가 낮은 분류율을 도출하였다. 또한 학습속에 있어서는 PNN이 BPNN에 비하여 빠름을 확인할 수 있었다.

4. 결론

용접결함으로부터 반사된 초음파 신호의 형상인식을 위한 신경회로망 알고리즘의 성능 비교를 수행한결과와는 다음과 같다.

(1) Bayesian 분류기 및 Perceptron은 이론적인 특성상 BPNN 및 PNN에 비하여 분류율이 낮음을 확인하였다.

(2) BPNN은 PNN에 비하여 학습속도가 늦은 단점이 있으나, 작은 학습률에 대하여 안정적인 분류결과를 도출함을 확인할 수 있었다.

(3) PNN은 작은 학습률에 대하여서는 불안정한 결과를 도출하였으나, 확률밀도가 형성되는 경우에 있어서는 BPNN에 비하여 높은 분류율을 도출함을 확인하였으며, 추정치에 대하여 이론적인 근거를 제공함을 확인하였다.

참 고 문 헌

- (1) Gordon, S. K., 1987, *Acoustic Waves*, Prentice-Hole, New York, pp. 92~110.
- (2) Rose, J. L., Nestleoroth, J. B. and Banlasu-bramanian, K., 1988, "Utility of Feature Mapping in Ultrasonics Non-Destructive Evaluation", *Ultrasonics*, Vol. 26, pp. 124~131.
- (3) Rose, J. L., Jeong, T. H., Alloway, E. and Copper, C. T., 1984, "A Methodology for Reflector Classification Analysis in Complex Geometric Welded Structures", *Materials Evaluation*, Vol. 42, No. 1, pp. 98~106.
- (4) Rose, J. L., 1984, "Element of Feature Based Ultrasonic Inspection System", *Materials Evaluation*, Vol. 42, No. 2, pp. 210~218.
- (5) Kim, J. Y., Roh, B. O., You, S., Kim, C. H., and Ko, M. S., 2002, "A Study on the Extraction of Feature Variables for the Pattern Recognition of Welding Flaws", *KSPE*, Vol. 19, No. 11, pp. 103~111.
- (6) Song, S. J., 1999, "Nondestructive Flaw Classification by Pattern Recognition Approach", *KSNT*, Vol. 19, No. 5, pp. 378~391.
- (7) Lee, H. Y. and Moon, K. I., 1999, *Neuro-Fuzzy using Matlab*, A-Jin, Seoul, pp. 209~325.
- (8) Vinay, K. I. and John, G. P., 1998, *Digital Signal Processing*, Sigma-press, Boston, pp. 353~428.