

용접결함의 형상인식을 위한 신경회로망 알고리즘의 성능 비교

김재열*, 심재기†, 이동기†, 김창현**, 송경석**, 양동조**

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

J. Y. Kim*, J. K. Sim†, D. G. Lee†, C. H. Kim**, K. S. Song**, D. J. Yang**

Abstract

In this study, we compared backpropagation neural network(BPNN) with probabilistic neural network(PNN) as shape recognition algorithm of welding flaws. For this purpose, variables are applied the same to two algorithm. Here, feature variable is composed of time domain signal itself and frequency domain signal itself. Through this process, we confirmed advantages/disadvantages of two algorithms and identified application methods of two algorithms.

Key Words : Welding Flaw(용접결함), Shape Recognition Algorithm(형상인식 알고리즘), Neural Network(신경회로망)

1. 서 론

비파괴검사의 분야 중에서 초음파 탐상검사는 결합의 위치에 대한 정량적인 값을 판정할 수 있는 장점을 가지고 있으나, 결합의 종류, 형상, 크기 판정에 있어서는 검사자의 경험 및 주관에 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 현장 적용의 용이성과 정량적인 값의 취득이 가능하고, 방사선 투과로서는 기하학적인 형상 및 방향성 때문에 발견하기 어려운 체적결함과 선형결함을 동시에 탐상할 수 있다는 관점에서 결합의 종류, 형상, 크기를 판정하기 위한 연구가 현재까지 진행되고 있다. 용접결합의 종류 판별은 각 결합의 종류에 있어서도 형상과 크기 등이 상이하게 다르므로 실제의 결합을 분류하기 위해서는 먼저 가장 큰 특징이 될 수 있는 용접결합의 특징변수로부터 다시 세부적인 특징을 분류하는 단계를 거쳐야 하며, 사실상 가장 중요한 단계는 용접결합의 가장 큰 특징을 선택하는 특징변수의 추출로서 결합분석의 정확도에 가장 큰 영향을 미치게 된다^{(2),(3),(4)}.

* 주저자, 조선대학교 기전공학과 (jykim@chosun.ac.kr)
주소: 501-759 광주광역시 동구 서석동 375

+ 조선대학교 기전공학과
++ 조선대학교 대학원

이러한 과정들을 통하여 융접결합의 종류판별이 가능하게 된다면, 현재 융접부의 강도에 치명적인 손상을 야기하는 균열은 물론이고, 융접부에 발생하는 각종 결합의 종류를 판별함으로서 잔류수명의 예측과 안전성 문제의 해결을 위한 안전진단 분야에서 그 파급효과를 기대할 수 있으리라고 본다.

2. 신호형상 분류 및 특징변수 추출

2.1 신호형상 분류

초음파 탐상기를 사용하여 얻은 각 결합에 대한 반사신호의 아날로그 데이터를 얻어서 이를 PC-based Oscilloscope을 이용하여 디지털 데이터 값을 취득함으로서, 결합의 종류 판별을 위한 초음파 신호처리를 수행하여 특정의 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 융접부 결합을 분류하기 위한 초음파 신호의 형상 분류에 대한 최종적인 결과를 얻게된다.

2.2 특징변수 추출

결합으로부터 반사된 초음파의 형상적인 변수를 이용하여 결합을 분류하는 경우, 초기단계에서는 시간축의 원파형을 이용하였다. 그러나 결합의 많은 정보를 얻어 내기 위해선은 시간축상의 데이터만으로는 한계가 있다. 따라서 초음파 신호와 결합사이에 상관 관계를 통하여 결합의 종류를 판별하기 위하여, 본 연구에서는 최근에 주목받고 있는 디지털 신호처리 기술을 응용하여 초음파 신호를 처리하고, 신호의 형상 분류에 적용하여 다음의 과정으로 연구를 수행하였다.

시간영역에서는 결합의 신호에서 원파형을 신호처리 과정인 low pass 필터링 과정을 통하여 평활화 하였다. 이는 신호의 잡음영역을 필터링하기 위하여 행하였다⁽⁸⁾.

또한 주파수영역에서의 특징변수 추출은 결합의 종류에 따라서 주파수 영역상에서 다른 특징을 가진 신호를 얻을 수 있다는 근거에서 Fourier 변환을 통하여 특징변수를 추출하였다⁽⁹⁾.

이러한 과정들을 통하여 추출된 특징변수는 시간영역과 주파수 영역에서의 각각의 신호파형의 데이터를 통합하여 사용하였다.

3. 역전파 및 확률 신경회로망의 적용

역전파 신경회로망(backpropagation neural network ; BPNN)은 다층 퍼셉트론에 관련된 가중치 및 임계값에 관한 해를 반복적으로 구하는 일반적인 방법으로서 작은 학습률이 사용되는 경우에 안정적인 최속 강하법에 속하지만, 수렴이 느린 단점을 가지고 있으므로 BPNN의 성능을 높이기 위한 방법으로서는 가변적인 학습률을 적용하는 방법등이 있다.

반면에 확률 신경회로망(probabilistic neural network : PNN)은 가중치들이 반복적인 과정을 통하여 학습과정 중에 기억됨으로서 빠른 학습속도를 갖게 되고, 신뢰성 있는 추정치를 위한 이론적인 근거를 제공하지만, 모든 패턴을 기억해야 하기 때문에 많은 데이터를 필요로 하게 된다⁽⁷⁾.

3.1 역전파 신경회로망

다층 퍼셉트론의 일종인 BPNN은 입력층과 출력층 사이에 은둔층이 존재하며, 다음의 Fig. 1.에 역전파 신경망의 계층구조를 나타내었다.

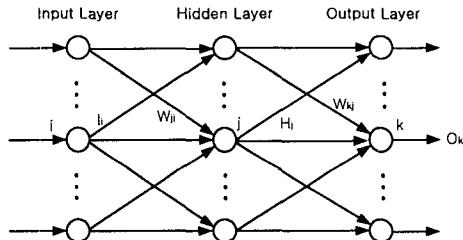


Fig. 1. backpropagation neural network

그리고 은둔층을 증가하고 비선형 활성함수를 사용함에 따라서 결정구역이 고급화 되는 장점을 확보할 수 있으므로 본 연구에서 은둔층과 출력층의 비선형 활성함수로서 시그모이드 함수를 적용하여 결정영역이 통상의 직선이 아닌 완만한 곡선으로 경계가 형성되도록 하여 은둔층을 학습하는

역전파 학습 알고리즘을 수행하도록 하였다.

Fig. 1.의 모델을 대상으로 하여 입력층 (I)과 은둔층 (H) 및 출력층 (O)은 다음의 식으로 정의된다.

$$H_j = f(\sum_i W_{ji} \cdot I_i + \theta_j)$$

$$O_k = f(\sum_j W_{kj} \cdot H_j + \theta_k) \quad (1)$$

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

$$W_{ji} = -\eta_3 \cdot \frac{\delta E_p}{\delta W_{ji}} = \eta_3 \cdot \delta_j \cdot I_i \quad (2)$$

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

$$W_{kj} = -\alpha_2 \cdot \frac{\delta E_p}{\delta W_{kj}} = \eta_2 \cdot \delta_k \cdot H_k \quad (3)$$

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

$$E_t = \sum_p \sum_k (T_{pk} - O_{pk})^2 / 2 = \sum_p E_p \quad (4)$$

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. 2.와 같은 계층구조를 갖는다.

PNN은 4개의 층으로 구성되어 있다. 첫 번째 층은 입력

층으로서 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 결합의 분류과정에 사용된다⁽⁶⁾. 다른 종류의 신경회로망과는 달리 PNN의 구조는 주어진 문제에서 가지고 있는 결합의 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 가중함수를 사용한다.

$$g(x) = \frac{1}{n} \sum_{i=1}^n \exp \left(-\frac{\|x - x_i\|^2}{2\sigma^2} \right) \quad (5)$$

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

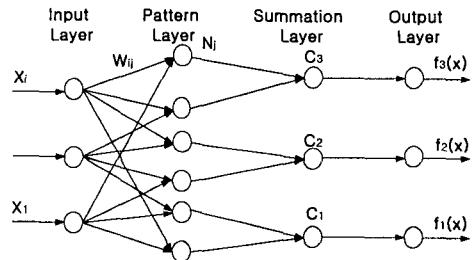


Fig. 2. probabilistic neural network

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 결합들은

자연 결합들이다. 제작상의 난점으로 인하여 Sonaspection Co, England에 제작을 의뢰하여 용접결합 시험편을 제작하였다. 본 실험에서 사용된 용접결합 시험편에 내재된 결합의 종류에 관한 사항들은 Table 1에 나타내었다.

Table 1. Configuration of welding flaws

Joint Method	Groove Type	Flaw Name (Spec. NO)
Butt Joint (Pipe)	V Groove	Root Crack (87)
		Lack of sidewall Fusion (87)
		Porosity (88)
		Lack of Root Fusion (88)
T Joint (T-Type)	K Groove	Slag (85)
		Root Crack (85)
		Lack of Penetration (86)
		Toe Crack (86)
Butt Joint (Plane)	V Groove	Slag (89)
		Lack of Penetration (89)
		Fine Porosity (90)
		Lack of sidewall Fusion (91)
		Sidewall Crack (91)
		Root Crack (92)
		Root Crack (92)
		Toe Crack (93)
		Trans Crack (92)
		Centerline Crack (94)
		Sidewall Crack (94)

Table 1.의 용접결합을 대상으로 하여 분류를 수행하였다. 분류에 사용된 데이터의 전체 수량은 각각의 결합에 대하여 10회의 반복검사를 통하여 190개를 적용하였으며, 결합패턴의 학습에 사용된 학습데이터의 수량은 8개로서 역전파 신경회로망과 확률 신경회로망에 동일하게 적용하였다. 또한, 분류하려는 결합의 종류는 체적결합은 6종류이고, 선형결합은 13종류이다.

4.2 장치 구성

본 실험에서 사용된 초음파 측정 분석장비의 시스템은 Fig. 3과 같다. 초음파 탐촉자(5Z 10×10 A70)는 공진주파수 5MHz의 고감도형 경사각 탐촉자를 사용하였으며, 초

음파 탐상기는 TOKIMEC사의 SM-300를 사용하였다. 결합으로부터 반사된 초음파 신호를 PC 기반의 oscilloscope를 사용하여 취득하였고 취득한 신호를 시간영역과 주파수 영역에서 분석하였으며, 분석을 통한 특징을 적용함에 있어서 각각의 영역에서 결합패턴으로 대표되는 형태의 신호를 특징변수로 사용하였다.

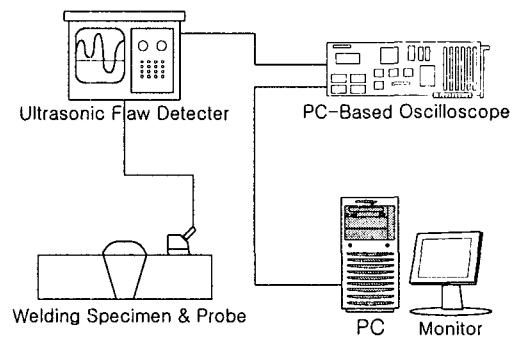
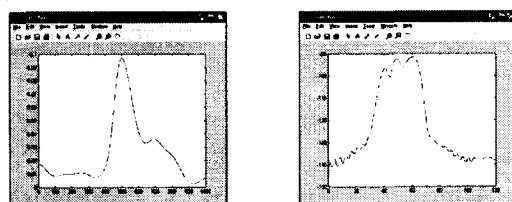


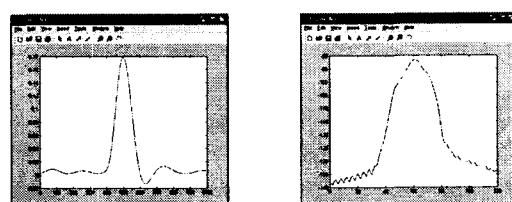
Fig. 3. Experimental apparatus

5. 실험결과 및 해석

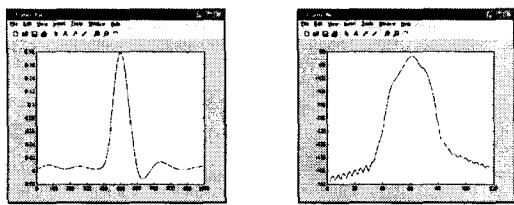
Fig. 4와 Fig. 5는 체적결합에서의 시간영역과 주파수 영역의 신호이고, Fig. 6은 선형결합에서의 시간영역과 주파수영역의 신호를 통합한 데이터를 특징변수로 사용하였다.



a) Time domain b) Frequency domain



a) Time domain b) Frequency domain
Fig. 5. Volumetric flaws signal (Type B)



a) Time domain b) Frequency domain
Fig. 6. Planar flaws signal

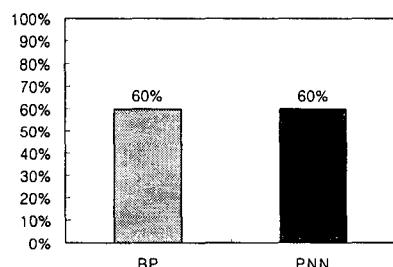


Fig. 7. Classification rates

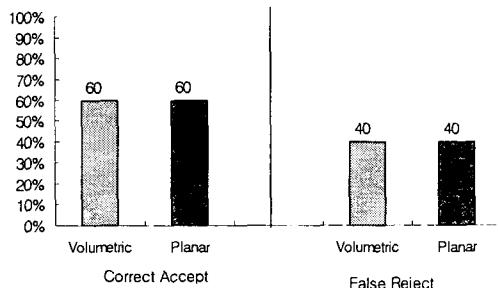


Fig. 8. Classification results of BPNN

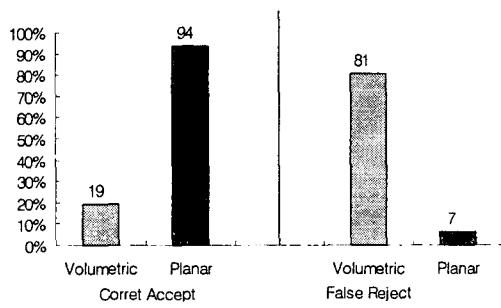


Fig. 9. Classification results of PNN

전체적인 분류율은 Fig. 7.에 나타낸 것처럼 동일하게 확인되었지만 각각의 분류결과를 확인하면, BPNN은 Fig. 8.처럼 작은 학습률 즉, 적은 수량의 데이터에 대하여도 안정적인 결과를 도출하였으나, PNN은 각각의 데이터 간의 거리에 의한 확률밀도함수에 기반을 두는 관계로 Fig. 9.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. 결 론

용접결합으로부터 반사된 초음파 신호의 형상인식을 위한 신경회로망 알고리즘의 성능 비교를 수행한 결과는 다음과 같다.

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

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

후 기

본 연구는 과학기술부·한국과학재단지정 지역협력연구센터인 레이저응용 신기술개발 연구센터의 2002년도 연구비 지원에 의해 연구되었음.

참 고 문 헌

- (1) Gordon, S. K., 1987, *Acoustic Waves*, Prentice-Hall, 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.