

용접결함의 패턴인식을 위한 분류기 알고리즘의 성능 비교

윤성운*, 김창현⁺, 김재열⁺⁺
(논문접수일 2005. 12. 12, 심사완료일 2006. 4. 6)

The Performance Comparison of Classifier Algorithm for Pattern Recognition of Welding Flaws

Sung-Un Yoon*, Chang-Hyun Kim⁺, Jae-Yeol Kim⁺⁺

Abstract

In this study, we nondestructive test based on ultrasonic test as inspection method and compared backpropagation neural network(BPNN) with probabilistic neural network(PNN) as pattern recognition algorithm of welding flaw. For this purpose, variables are applied the same to two algorithms. Where, feature variables are zooming flaw signals of reflected whole signals from welding flaws in time domain. Through this process, we confirmed advantages/disadvantages of two algorithms and identified application methods of two algorithms.

Key Words : Welding Flaw(용접결함), Classifier Algorithm(분류기 알고리즘), Backpropagation Neural Network(역전파 신경망), Probabilistic Neural Network(확률신경망), Pattern Recognition(패턴인식), Ultrasonic Test(초음파 검사)

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 주관에 의존하여 신뢰성 및 재현성이 적은 단점이 있는 관계로 방사선 투과검사가 주로 이용되고 있다. 그러나, 방사선 투과검사는 탐상면에 평행하게 위치하는 슬래그 혼

입(slag inclusion), 기공(porosity) 등의 체적결함에 대해서는 우수한 검출능력을 가지는 반면에, 탐상면에 수직한 용합 불량(lack of fusion), 균열(crack) 등의 선형결함에 대해서는 탐상이 어려운 단점이 있다⁽¹⁾.

그러므로, 초음파 탐상검사는 현장적용의 용이성과 정량적인 값의 취득이 가능하고, 방사선 투과검사는 기하학적인 형상 및 방향성 때문에 발견하기 어려운 체적결함과 선형결함을 동시에 탐상할 수 있다는 관점에서 결함의 종류, 형상,

* 조선대학교 기계공학과 (suyoon@chosun.ac.kr)

주소: 501-759 광주광역시 동구 서석동 375

+ 광주과학기술원 기전공학과

++ 조선대학교 기전공학과

크기를 판정하기 위한 연구가 현재까지 진행되고 있다. 용접 결함의 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⁽²⁻⁴⁾.

이러한 과정들을 통하여 용접결함의 종류판별이 가능하게 된다면, 현재 용접부의 강도에 치명적인 손상을 야기하는 균열은 물론이고, 용접부에 발생하는 각종 결함의 종류를 판별함으로써 잔류수명의 예측과 안전성 문제의 해결을 위한 안전진단 분야에서 그 파급효과를 기대할 수 있으리라고 판단된다.

2. 신호형상 분류 및 특징변수 추출

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 구별할 수 있는 특징값(feature)을 얻어내는 과정이다. 이 과정에서 특징들 사이의 상호 비교를 동일한 차원에서 처리하기 위해 적절한 방법⁽²⁻⁴⁾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 취득한다.

결함의 위치와 파형의 크기 정보는 매우 중요하지만, 본 연구에서는 두 가지 부류의 신호파형을 동일한 진폭상에서 형태상의 차이만을 가지고 분리를 수행하기 위해 초음파 탐상기의 감도레벨을 동일진폭으로 정규화하여 원신호 파형을 취득 하였으며, 전체적인 초음파 신호 중에서 결함으로부터 반사된 순수한 결함신호만을 윈도우 함수를 사용하여 zooming 하고, 각각의 형태상의 특징을 갖는 대표신호를 특징변수로 선정하였다^(5,6).

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 방법로서는 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. 1에 역전파 신경망의 계층구조를 나타내었다. 계층의 구성은 입력층, 은둔층, 출력층으로 구성되며, 각 층간은 가중치에 의하여 연결되며, 이 가중치의 설정에 의하여 안정된 출력을 형성하게 된다.

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




Fig. 1 Backpropagation neural network

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

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

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.

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

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 극소화한다.

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. 2와 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⁽⁸⁾. 다른 종류




Fig. 2 Probabilistic neural network

의 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 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.

4. 실험장치

4.1 용접 시험편

용접결함의 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, England에 제작을 의뢰하여 용접결함 시험편을 제작하였다. 본 실험에서 사용된 용접결함 시험편에 내재된 결함의 종류에 관한 사항들은 Table 1에 나타내었다.

Table 1의 용접결함을 대상으로 하여 분류를 수행하였다. 분류에 사용된 데이터의 전체 수량은 각각의 결함에 대하여 5회의 반복검사를 통하여 110개를 적용하였으며, 결함패턴의 학습에 사용된 학습데이터의 수량은 40개로서 역전파신경회로망과 확률신경회로망에 동일하게 적용하였다. 또한,

분류하려는 결함은 spiral weld pipe에 내재하는 결함으로서 선형결함의 종류는 crack과 lack of fusion이고, 체적결함의 종류는 lack of penetration, slag 혼입, porosity로서 체적결함은 3종류이고, 선형결함은 2종류이다.

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, 초음파 탐상기는 TOKIMEC사의 SM-300를 사용하였다. 결함으로부터 반사된 초음파 신호를 PC 기반의 oscilloscope를 사용하여 취득하였고 각각의 신호로부터 결함패턴으로 대표되는 형태의 순수한 결함신호만을 특징변수로 사용하였다.

5. 실험결과 및 해석

Fig. 4는 본 연구에서 적용된 분류기인 PNN 분류기와 BPNN 분류기에 동일하게 적용된 학습데이터로서 선형결함의 대표신호로서는 crack을 사용하였으며, 체적결함의 대표신호로서는 slag 혼입과 porosity를 사용하였다.

Fig. 5는 본 연구에서 적용된 BPNN 분류기의 학습결과를 나타내었다. 여기서 사용된 은닉층 뉴런의 개수는 125개이며, 출력오차의 한계는 0.2로 설정하고, 초기학습률은 0.02로 설정하여 학습한 결과는 22,947 사이클 후에 학습이 완료되었다.

Fig. 6은 본 연구에서 적용된 PNN 분류기의 성능에 영향을 미치는 확률밀도함수의 너비 파라미터의 선정을 나타내었다. 0.03을 기준으로 그 이상의 너비 파라미터에서는 각 class의 구분에 있어서 확률의 분포를 정분류 및 오분류 모

Table 1 Configuration of Train welding flaws

Joint Method	Groove Type	Flaw Name(Spec. NO)
Butt Joint (Pipe)	V Groove	Root Crack(87)
		Porosity(88)
		Slag(85)
T Joint (T-Type)	K Groove	Root Crack(85)
		Toe Crack(86)
		Slag(89)
Butt Joint (Plane)	V Groove	Fine Porosity(90)
		Sidewall Crack(91)




Fig. 3 Train signals in each classifier




Fig. 4 Train signals in each classifier

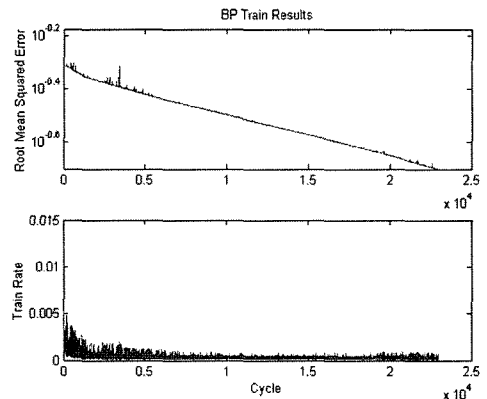


Fig. 5 Train Result of BPNN

두 높은 확률을 나타냄으로서 적절치 않은 분류율을 보요주고 있으며, 0.03 이하에 있어서도 정분류 및 오분류에 있어서 전체적으로 낮은 확률을 나타냄으로서 적절하지 않는 결과를 도출함을 확인할 수 있으며, 0.03의 경우에 분류를 위한 확률을 가장 적절하게 나타냄을 확인할 수 있다.

전체적인 분류율은 Fig. 7에 나타난 것처럼 BPNN 분류기가 다소 높게 보이지만 거의 유사한 분류율을 보임을 확인할 수 있다.




Fig. 6 Select width parameter of PNN




Fig. 7 Classification of each classifier




Fig. 8 Classification of each flaw type

할 수 있다. 각각의 분류결과를 확인하면, BPNN은 Fig. 8처럼 작은 학습률 즉, 적은 수량의 데이터에 대하여도 안정적인 결과를 도출하였다. 이는 선형결합과 체적결합의 분류율이 유사하게 나타남을 확인함으로써 유추할 수 있다. 그러나 PNN은 각각의 데이터 간의 거리에 의한 확률밀도함수에 기반을 두는 관계로 Fig. 8에서처럼 충분한 확률밀도가 구성되는 선형결합(즉, crack과 lack of fusion의 2종류의 결함만이 존재하는 경우)에 대하여서는 높은 분류율을 보인 반면에 확률밀도가 낮은(즉, lack of penetration, slag 혼입, porosity의 3종류의 결함이 존재할 경우는 확률밀도 함수가 분산되므로) 분류율을 도출함을 확인하였다. 또한 학습속도에 있어서는 PNN이 BPNN에 비하여 월등히 우수함을 확인할 수 있었다.

6. 결론

용접결함으로부터 반사된 초음파 신호의 패턴인식을 위한 분류기 알고리즘의 성능 비교를 수행한 결과는 다음과 같다.

- (1) BPNN은 PNN에 비하여 학습속도가 낮은 단점이 있으나, 작은 학습률에 대하여 안정적인 분류결과를 도출함을 확인할 수 있었다.
- (2) PNN은 작은 학습률에 대하여서는 불안정한 결과를 도출하였으나, 확률밀도가 충분히 형성되는 경우에 있어서는 BPNN에 비하여 안정된 분류율을 도출함을 확인하였으며, 학습속도에 있어서 우수성을 나타내었다.
- (3) 데이터의 구축량이 적은 초기에는 BPNN 분류기의 적용이 타당하다고 판단되며, BPNN 분류기에 의한 데이터가 충분히 구축되었다면 PNN 분류기를 적용하는 것이 타당하다고 판단된다.

후기

본 연구는 2004년도 조선대학교 교내 연구비 지원에 의하여 연구되었음.

참고 문헌

- (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) Vinay, K. I. and John, G. P., 1998, *Digital Signal Processing*, Sigma-press, Boston, pp. 353~428.
- (7) Lee, H. Y. and Moon, K. I., 1999, *Neuro-Fuzzy using Matlab*, A-Jin, Seoul, pp. 209~325.
- (8) Song, S. J., 1999, "Nondestructive Flaw Classification by Pattern Recognition Approach," *KSNT*, Vol. 19, No. 5, pp. 378~391.