

신경회로망을 이용한 오스테나이트계 스테인리스강 304 용접부의 결함 분류 및 평가에 관한 연구

이 원*, 윤인식**

A Study on the Defect Classification and Evaluation in Weld Zone of Austenitic Stainless Steel 304 Using Neural Network

Won Yi*, In-Sik Yun**

ABSTRACT

The importance of soundness and safety evaluation in weld zone using by the ultrasonic wave has been recently increased rapidly because of the collapses of huge structures and safety accidents.

Especially, the ultrasonic method that has been often used for a major non-destructive testing(NDT) technique in many engineering fields plays an important role as a volume test method. Hence, the defecting any defects of weld zone in austenitic stainless steel type 304 using by ultrasonic wave and neural network is explored in this paper.

In order to detect defects, a distance amplitude curve on standard scan sensitivity and preliminary scan sensitivity represented of the relation between ultrasonic probe, instrument, and materials was drawn based on a quantitative standard. Also, a total of 93% of defect types by testing 30 defect patterns after organizing neural network system, which is learned with an accuracy of 99%, based on ultrasonic evaluation is distinguished in order to classify defects such as holes or notches in experimental results.

Thus, the proposed ultrasonic wave and neural network is useful for defect detection and Ultrasonic Non-Destructive Evaluation(UNDE) of weld zone in austenitic stainless steel 304.

Key Words : Neural Network(신경회로망), Ultrasonic Waves(초음파), Shear Wave(횡파), Fractal Dimension(프랙탈 차원), Weld Defect(용접 결함), Artificial Defect(인공결함), Reference Block(대비시험편), Beam Distance(빔거리), Refraction Angle(굴절각)

* 숭실대학교 기계공학과
** 숭실대학교 대학원/대한검사기술(주)

1. 서론

오스테나이트계 스테인리스강은 내식성뿐만 아니라 고온 및 극저온에서도 성능이 우수하여 적용 범위 및 사용이 점점 확대되어 가고 있다. 현재 원자력 발전소 1차 배관 계통의 60% 이상을 차지하고 있는 오스테나이트계 스테인리스강은 많은 용접부로 이루어져 있으며, 이러한 용접부는 초기 용접시 공정중의 여러가지 변수와 가동중의 열화(degradation)로 인하여 결함의 발생 가능성이 매우 높다. 특히 용접부의 결함중에서도 동적 응력을 받는 언더컷이나 크랙 등은 역학적으로 현저한 응력 집중의 원인이 되어 구조물의 강도 저하를 초래하기도 한다. 따라서 용접부에 존재하는 각종 결함을 검출하고 검출 결함의 종류를 판별하는 것은 구조물 전체 시스템의 안전성 향상 및 보수·유지 최적화에 필수적이라 할 수 있다.

현재 여러 산업 현장에서 용접부 내부 결함의 검출 및 평가를 위하여 사용되고 있는 방법으로는 크게 파괴적인 방법과 비파괴적인 방법을 들 수 있다.

파괴적인 방법은 내부 결함에 대하여 크기, 위치, 종류 등의 모든 정보를 가장 확실하게 알 수 있지만, 가동중의 구조물이나 배관 라인 등에 대해서는 경제성 측면에서 적용이 불가능한 실정이다. 그러나 비파괴적인 방법은 파괴적인 방법의 적용시 가장 문제가 되는 재질의 손상 및 파손 없이 대상 재질의 상태를 파악할 수 있는 유력한 방법으로 위력을 발휘하고 있으며, 이에는 방사선 투과법⁽¹⁾과 초음파법⁽²⁾을 대표적으로 들 수 있다.

방사선에 의한 방법은 실시간 결과 처리가 어렵고, 대상재의 두께 증가에 따른 분해능의 저하, 결함의 방향에 따른 민감성 등의 많은 문제점을 내포하고 있다.

초음파에 의한 방법은 화학·화력·원자력 플랜트의 가동전·중에 실시하는 비파괴 검사 방법중에서 체적 검사 방법⁽³⁾으로 상당히 중요한 역할을 하고 있으며, 특히 용접부의 결함 종류 판별은 정량적 강도 평가를 가능하게 함으로서 피로파괴와 같은 대형 사고를 미연에 방지할 수 있어 그 중요성이 더욱 높아 가고 있다. 최근에는 형상인식 분야에서 우수성이 입증된 신경회로망(Neural Network)을 이용함으로써 결함의 위치 및 크기 뿐만 아니라 형상까지도 분류할 수 있는 장점을 가지고 있으며 Schmerr⁽⁴⁾, 이⁽⁵⁾ 등에 의한 연구가 있다.

Schmerr⁽⁴⁾는 확률 신경회로망(Probabilistic Neural Network)을 이용한 초음파 형상 인식 기법으로 기공, 슬래그 혼입, 크랙과 같은 선형 및 체적 용접 결함 분류를

하였으며, 이⁽⁵⁾는 오스테나이트계 스테인리스강 304 용접부의 용접 결함에 대하여 정량적 결함 평가 기준인 거리진 폭특성곡선의 설정으로 인한 현장성 및 실용성이 높은 초음파법의 제안과 역전파 학습 알고리즘에 의한 신경회로망으로 열영향부의 인공 결함을 분류하고 평가하였다.

기존의 연구들은 오스테나이트계 스테인리스강 304 용접부의 용착금속 및 열영향부에 대하여 단편적이고도 실험실적인 것이 대부분이며, 실용성이 높은 결함의 정량적 평가 기준에 의한 용접부의 결함 검출과 종류 판별에 관한 것은 거의 없다.

따라서 이러한 용접부의 결함 검출 및 종류 판별에 있어서는 결함으로부터의 초음파 신호에 대한 정량적 특징 추출(feature extraction)과 추출한 특징으로부터 초음파와의 관계를 해석하는 것이 첫번째의 선결 과제이다.

이에 대한 기존의 연구에 있어서는 결함 형상 인식을 위한 용접부 결함 신호 특징 추출 과정에서 주로 시간 영역(time domain)상의 가장 첫 번째 파형이나 에너지가 큰 파형을 대상으로 하고 있으나, 결함의 종류에 따라 파형의 특성이 달라서 피크 대 피크에 의한 추출 특징은 결함의 신호에 따라 일관성을 고려하기 어려우며, 또한 일반적으로 결함으로부터의 초음파 신호중 해석이 가능한 부분 파형만을 적용하는 단점으로 인하여 정밀도가 낮아지는 등의 문제점을 갖고 있다. 이와 같이 일반적인 신호 분석법으로 전체 파형을 고려한 정량적 특징을 추출하기 어려운 경우에 대하여 프랙탈 해석에 의한 방법의 시도가 모색되고 있다.

프랙탈⁽⁶⁾을 이용한 해석은 대상 신호가 갖는 고유의 성질을 시계열 데이터로 하여 계의 상태 공간내에 내재한 특성을 평가하게 되며, 이러한 특성을 파악하고, 해석하는 프랙탈 특징 추출로부터 정밀도 높은 해석이 가능하다.

특히 이⁽⁷⁾ 등에 의한 인간 심박 변화율의 연구와 김⁽⁸⁾ 등에 의한 엔드밀 가공시 공구 마멸에 대한 프랙탈 해석은 생체역학 분야와 공구 마멸의 분야에서 그 유효성이 입증되었다. 이러한 프랙탈 해석은 전체 파형의 평가에 있어서 강점을 갖고 있지만 생체 분야 및 특정 공학 분야 외에는 적용이 미미한 실정이다.

따라서 본 연구에서는 오스테나이트계 스테인리스강 304의 용접부 인공결함(형공, 수직공, 노치)에 대하여 CRT상의 초음파에 의한 결함 신호로부터 그 특성을 파악하고, 시계열 데이터에 의한 전체 파형으로부터 프랙탈 특징 1개를 추출하여 역전파 학습 알고리즘 신경회로망

에 의한 인식률의 결과로부터 프랙탈 해석에 의한 초음파 형상 인식의 유효성을 제시하고자 하였다.

2. 신경회로망 기법

2.1 신경회로망의 구조

신경회로망은 인간의 뇌에 존재하는 생물학적 신경세포와 이들의 연결 관계를 단순화시켜 수학적으로 모델링하므로써 병렬 시스템인 인간의 두뇌와 같은 지능적 형태를 구현하는 것이다.

다층 계층형 신경회로망은 Fig. 1과 같이 입력층, 은닉층, 출력층으로 구성되며, 패턴 분류를 위하여 사용된다.

중간층과 출력층은 처리 소자와 연결 강도를 지니고 있으며, 노드마다의 처리 소자는 강도를 곱한 각각의 입력값에 바이어스값을 더해서 식(1)과 같은 시그모이드 함수 $f(x)$ 에 의해 출력을 만들어 낸다.

$$f(x) = \frac{1}{1 + e^{(-x/\theta_0)}} \quad (1)$$

여기서 θ_0 는 활성화함수인 시그모이드 곡선의 형태를 결정하는 형태상수이다. 입력층을 제외한 각 노드에 대한 총입력은 그 전층의 모든 노드의 출력값에 강도를 곱한 값들이다. 즉, k 층의 j 노드에 대한 총 입력은 식(2)와 같이 된다.

$$net_j^k = \sum_{i=1}^m w_{ji}^k o_i^{k-1} \quad (2)$$

여기서 m 은 $(k-1)$ 번째층의 노드수, w_{ji}^k 은 $(k-1)$ 번째층의 i 번째 노드와 k 번째층의 j 번째 노드간의 연결강도, o_i^{k-1} 은 $(k-1)$ 번째층의 j 번째 노드의 출력이다. 따라

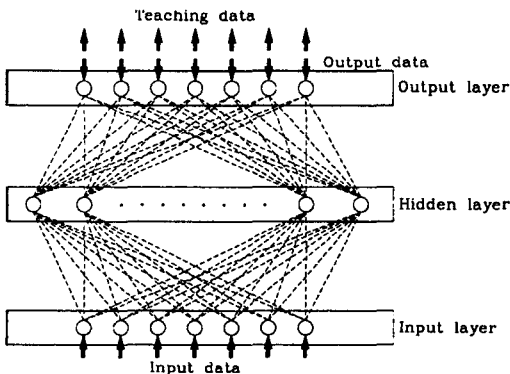


Fig. 1 Architecture of multilayer neural networks

서 k 층의 j 노드에서의 출력은 식(3)과 같다.

$$o_i^k = \frac{1}{1 + e^{-(net_j^k + \theta_j^k)/\theta_0}} \quad (3)$$

식(3)에서 계수 θ_j 는 바이어스값이다. 은닉층에서의 노드의 출력을 식(3)으로 계산하고 출력단에서의 출력을 계산한 후, 식(4)와 같이 주어지는 출력단에서의 각 입력 패턴에 따라서 발생하는 추정치의 자승오차항을 평균으로 하는 오차 E 를 최소화하는 방향으로 입력과 출력단사이의 연결강도를 수정하는 과정을 반복한다. 일반적으로 출력값은 목표값과 같지 않고, 따라서 평균시스템 오차를 다음과 같이 구할 수 있다.

$$E = \frac{1}{2m} \sum_{i=1}^m (y_i - o_i)^2 \quad (4)$$

여기서 m 은 입력으로 선정된 데이터 패턴수, y_i 는 목표치, o_i 는 출력치이다.

식(4)를 연결강도 w_j 에 대해서 최소화시키는 것은 최급강하(steepest-descent)방법으로 가능하며, 역전파 학습알고리즘을 이용하였다.

$$w_{ji}^k(n+1) = w_{ji}^k(n) + \Delta w_{ji}^k(n) \quad (5)$$

$$\Delta w_{ji}^k(n) = -\eta \frac{\partial E}{\partial w_{ji}^k} \quad (6)$$

식(5)와 (6)은 단순히 현재의 강도를 최급강하 방향으로 가도록 새로운 강도를 형성하는 것으로 그 정도는 학습을 η 에 의해서 조절된다. η 가 크면 빠른 학습을 가져오나 E 가 net_j^k 에 대하여 복잡한 함수인 경우 발산할 수 있으므로 식(7)과 같은 모멘텀항을 갖는 수정된 학습식이 도입되었다.

$$\Delta w_{ji}^k(n+1) = -\eta \frac{\partial E}{\partial w_{ji}^k} + \alpha \Delta w_{ji}^k(n) \quad (7)$$

여기서 α 는 모멘텀으로 $(n+1)$ 단계에서의 학습 강도 w_{ji} 가 n 번째 단계의 값과 심한 차이를 갖지 못하도록 이전 단계에서 추정된 w_{ji} 를 현단계에서 이용하는 비율을 나타낸다.

2.2 다층 계층 신경회로망의 특징

계층형 신경회로망의 특징으로는 아래와 같이 크게 3가지로 나타낼 수 있다.

(1) 유한개의 이산적인 입·출력 관계를 학습하는 것으로 임의의 연속 사상을 시뮬레이션하는 네트워크를 구축할 수 있다.

(2) 미학습의 입력 데이터에 대해서도 네트워크내에서 적절히 내삽하여 타당한 출력을 얻을 수 있다.

(3) 학습 종료후에는 주어진 입력 데이터에 대해 처리 소자에 의한 덧셈과 곱셈으로 단시간에 출력을 얻을 수 있다.

이중에서 3번째의 성질은 고속 처리가 요구되는 해석 대상에 대하여 신경회로망 적용의 강점을 가장 위력적이면서 정밀도 높게 평가할 수 있다.

3. 프랙탈 해석

프랙탈 차원은 시계열 신호에 대하여 재구성된 어트랙터의 기하학적 특징을 표현한다. 따라서 어트랙터를 재구성하는 것이 필요하며 이러한 어트랙터의 재구성은 Takens의 지연 방법⁹⁾을 사용하였다.

i 개의 데이터가 주어졌을 때, 식(8)과 같이 주어지는 m 차원 벡터 $\bar{X}(i)$ 를 위상 공간에서 순서대로 연결시킴으로써 어트랙터가 재구성된다.

$$\begin{aligned} \bar{X}(1) &= (x(1), x(1+\tau), x(1+2\tau), \dots, x(1+(m-1)\tau)) \\ \bar{X}(2) &= (x(2), x(2+\tau), x(2+2\tau), \dots, x(2+(m-1)\tau)) \\ &\vdots \\ \bar{X}(i) &= (x(i), x(i+\tau), x(i+2\tau), \dots, x(i+(m-1)\tau)) \end{aligned} \quad (8)$$

여기서 $x(i)$ 는 주어진 시계열 데이터이며, m 은 임베딩 차원(embedding dimension)을, τ 는 시간 지연(time delay)을 나타낸다.

프랙탈 차원은 정수 값이 아닌 실수로 표현되며 신호의 특성에 따라 그 값이 달라진다. 따라서, 어트랙터의 고유한 특성으로 프랙탈 차원을 사용할 수 있다.

본 연구에서는 재구성된 어트랙터로부터 프랙탈 차원을 구하기 위하여 Grassberger와 Procaccia가 제안한 식(9)를 이용한 상관 적분 방법을 사용하였다.

$$C(r) = \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N \Theta(r - |\bar{X}(i) - \bar{X}(j)|) \quad (9)$$

여기서, Θ 는 step function이며, $\bar{X}(i)$ 와 $\bar{X}(j)$ 는 i 와 j 번째 어트랙터를 구성하는 점이다. 또한, N 은 데이터의 수, r 은 반지름, 그리고 $|\bar{X}(i) - \bar{X}(j)|$ 는 두점 사이의 유클리디안 거리를 나타낸다.

어트랙터상의 각 점에서 상관 적분을 계산함으로써 프랙탈 차원을 결정하게 되는데, 어트랙터상의 한 점을 중심으로 반지름이 r 인 구를 그리고 구 내부점의 수를 구하는 과정을 어트랙터 상의 각 점에서 반복하여 구한 값들에 대하여 평균을 한다.

어트랙터상의 특성이 결정되는 것으로부터 식(10)과 같은 $\log_2 r$ 대 $\log_2 C(r)$ 을 변수로 하는 직선 회귀선을 구하여 프랙탈 차원으로 나타낸다.

$$\nu = \frac{\log_2 C(r)}{\log_2 r} \quad (10)$$

4. 초음파 이론

고체 내부를 전파하는 음파에는 입자의 진동이 파의 진행 방향과 같은 종파와 파의 진행 방향이 수직인 횡파가 있으며, 전파하는 재질의 종류 및 특성에 따라 음속이 결정된다.

종파의 음속 C_l 과 횡파의 음속 C_s 는 식 (11)과 식 (12)로 나타낼 수 있다.

$$C_l = \sqrt{\frac{E}{\rho} \times \frac{(1-\nu)}{(1+\nu)(1-2\nu)}} = \sqrt{\frac{K+(4/3)G}{\rho}} \quad (11)$$

$$C_s = \sqrt{\frac{E}{\rho} \times \frac{1}{2(1+\nu)}} = \sqrt{\frac{G}{\rho}} \quad (12)$$

여기서 E 는 종탄성 계수, K 는 체적 탄성 계수, G 는 횡탄성 계수 또는 전단 탄성 계수, ρ 는 밀도, ν 는 포와송비(Poisson's ratio)이다.

결합 검출을 목적으로 사용되는 초음파는 재질내를 일정한 음속을 갖고 진행하여 결합으로부터의 반사 에코를 얻게 된다. 용접부 결합을 대상으로 하는 경우, 탐촉자의 굴절각에 의한 횡파 사각법을 적용할 수 있다. 0.5 스킵(Skip) 빔거리내를 기준으로 하는 직사법에 대해서는 삼각 함수의 원리에 의해 다음과 같은 식들을 얻을 수 있으며, 아에 대한 원리는 Fig. 2와 같다.

$$W_{0.5s} = \frac{t}{\cos\theta} \quad (13)$$

$$y = W \sin\theta \quad (14)$$

$$d = W \cos\theta \quad (15)$$

$$d' = 2t - W \cos\theta \quad (16)$$




Fig. 2 Principle of angle beam method

여기서 스킵(Skip)점이라는 것은 사각 탐상에서 빔중 심축이 저면에서 반사하여 탐상면에 도달하는 점을 말하며, 빔거리(W)는 초음파빔이 이동한 거리, 1 스킵 빔거리는 탐촉자의 입사점으로부터 1 스킵점까지의 거리, 0.5 스킵 거리는 0.5 스킵 점까지의 거리를 말한다. 식 (16)의 1회 반사법에 의한 결함 깊이는 $d' = 2t - W \cos \theta$ 로 나타내는데 이는 판두께를 2배로 가상하여 구한 거리이다.

5. 실험

5.1 실험조건

본 연구에 사용된 주요 기기는 초음파 탐상기(Epoch II), 횡파 사각 탐촉자(주파수 : 2MHz, 굴절각 : 70°, 진동자 크기 : 8×9mm), 종파 사각 탐촉자(주파수 : 2MHz, 굴절각 : 70°, 진동자 크기 : 20×35mm), 수직 탐촉자(주파수 : 2MHz, 진동자 크기 : 10mm), 펄서 리시버(Bandwidth 35MHz Pulsar-Receiver), 디지털 오실로스코프(Bandwidth 2GHz DSO), 집축매질⁽¹⁰⁾(기계유) 등이며, 프래탈 특징 추출을 위한 신호 취득에 있어서는 한 결함당 23 point에 대하여 10ns와 100MHz로 샘플링하여 5000샘플을 총 데이터의 크기로 하였다.

실험에 있어서는 수직 및 사각 탐촉자의 굴절각, 주파수, 시험편의 두께와 성질 등의 상관관계에 의하여 초음파 탐상기의 CRT상에 나타나는 에코 특성을 파악하고자 하였다. 이를 위하여 Fig. 3, Fig. 4와 같은 대비시험편(reference block)을 제작하였으며, 여기서 Fig. 3은 입사점 및 시간축의 조정에, Fig. 4는 굴절각의 측정 및 초음파 탐상기의 교정을 하기 위한 용도로 사용하였다.

초음파를 이용하여 오스테나이트계 스테인리스강 304 용접부의 정량적 결함 검출을 위해서는 관심 대상재와 같




Fig. 3 Configuration of reference block(ITRB)




Fig. 4 Configuration of reference block(RDRB)




Fig. 5 Configuration of standard test block

은 재질, 두께의 선정과 동일 용접 조건에 의한 가공 등을 들 수 있으며, 이를 위하여 Fig. 5, Fig. 6과 같은 시험편의 열영향부 및 용착금속에 횡공, 수직공, 노치등 3가지 종류의 인공 결함을 가공하였다.

5.2 거리진폭특성곡선(Distance Amplitude Curve : DAC)의 설정

재료 내부의 결함을 검출하기 위해서는 정량적 결함 검출 기준의 설정이 필요하며, 이러한 기준으로는 DAC가




Fig. 6 Configuration of test block

적용되고 있다. 따라서 DAC가 설정되는 레벨은 결합의 검출성에 가장 큰 영향을 주며, 초음파 탐상기의 CRT상에 나타나는 동에코 패턴을 인자로 하여 작성하게 된다.

이를 위하여 펄스-에코식에 의한 RDRB의 횡공으로부터 반사되어 돌아오는 에코를 기준으로 하여 초음파 탐상기의 CRT상에 직접 작성하였다.

작성시에 고려한 주요 사항 및 작성 방법은 다음과 같다.

- 대상재의 조건을 고려한 탐촉자의 주파수와 굴절각의 선정
- 탐촉자의 실제 굴절각과 입사점의 측정
- RDRB 각각의 횡공에 대한 최대 에코 위치의 측정
- 최대 에코에 의한 기준 에코 높이의 설정

6. 결과 및 고찰

6.1 용접 결합의 검출 및 평가

오스테나이트계 스테인리스강 304 용접부는 결정립이 조대한 주상정 조직으로 초음파가 용접부내를 진행할 경우 산란에 의한 감쇠가 크고, 주상정이 현저한 이방성을 나타내어 신호대 잡음비(SNR)가 낮고, 의사에코가 나타나게 되는 등의 페라이트계 탄소강과는 현저하게 다른 특성⁽¹¹⁾을 나타낸다.

따라서 정량적 결합의 검출을 위해서는 초음파 탐상기 및 탐촉자의 정확한 교정이 필요하며, 이를 위하여 ITRB와 RDRB를 이용하여 초음파 탐상기 및 탐촉자를 특성에 맞게 교정한 후, Fig. 5는 결합에 대한 감도를 확인하기 위하여 용착금속에 수직공 ($\phi 3\text{mm}$), 열영향부위에 수직공 및 횡공 ($\phi 3\text{mm}$), 표면에 노치(깊이 3mm, 개선각




Fig. 7 The measured result of defect echo in deposited metal

30°)를 각각 가공하였다. Fig. 6의 테스트 시험편에서는 용접부 중앙에 있는 횡공 ($\phi 3\text{mm}$), 결합에 대하여 횡파 사각법에 의한 검출 가능성을 알아 보고자 하였으며, Fig. 7은 이러한 결과를 나타내고 있다.

에코 높이가 100%가 넘는 가장 좌측의 신호는 송신 에코이며, 3개의 실선은 6dB 간격의 DAC를 나타낸다. DAC 작성시의 기준감도는 50.7dB, 예비탐상감도는 기준감도에 18dB를 높인 68.7dB로 설정하였다. CRT상의 게이트설정 부위에서 55%로 나타난 용착 금속내의 결합에코의 위치는 진행한 빔거리, 탐촉자로부터 결합까지의 표면거리, 깊이를 지시하고 있다. 그러나 실제로 측정된 빔거리와 깊이는 각각 38.82mm와 14.54mm로 CRT상의 지시값과는 다른 값들을 나타내고 있으며, 이는 횡공 주위에 결합에코로 나타날 만한 결합이 없는 것을 고려할 경우, 초음파가 주상정 조직인 용착금속내를 진행할 시에 도파관의 역할을 하여 결합을 향하여 진행하지 못하고 도파되어 표면을 맞고 되돌아 온 의사에코라고 생각된다.

용착 금속의 결합 검출에 있어서는 횡파 사각법의 경우와는 달리 종파 사각탐촉자를 사용하여 직사법에 의한 초음파 에코의 변화를 파악하는 것이 중요하며, Fig. 8, Fig. 9는 횡공 및 수직공에 대한 초음파의 에코 거동을 나타내고 있다. 횡공, 수직공에 대한 CRT상의 초음파 에코는 실측 거리와 상당히 잘 일치하였으며, 기준 감도 (40.4dB) 및 예비탐상감도 (58.4dB), 시간축 (100mm), DAC 등이 횡파 사각법의 경우와 상당히 다르게 설정되어 있음을 알 수 있다.

초음파는 결합의 크기와 형태, 진행한 빔거리에 따라 에코의 거동이 달라지게 되며, 이는 결합에 대한 검출성에 가장 큰 영향을 준다.




Fig. 8 The measured result of ϕ 3.0mm vertical hole in deposited metal




Fig. 9 The measured result of ϕ 3.0mm vertical hole in deposited metal




Fig. 10 The measured result of ϕ 3.0mm vertical hole

Fig. 10과 Fig. 11은 이런 현상을 나타내는 것으로 특히 Fig. 10에서는 1 스킵 빔거리인 수직공의 표면가까이에서 반사되어 돌아오는 에코가 대단히 작게 나타나고 있다.

Fig. 11에서는 약 1 스킵 빔거리인 표면 노치에 대한




Fig. 11 The measured result of notch

결과를 나타내는 것으로 빔이 진행한 거리는 Fig. 10의 경우와 비슷하지만 에코의 크기는 24% 정도로 거의 2배 이상 높게 나타나고 있으며, 이는 초음파가 같은 빔거리를 진행하더라도 결함의 종류 및 반사 형태, 면적과 강한 상관 관계를 나타내는 결과라고 생각된다.

6.2 프랙탈 특징 추출

획득한 초음파 결합 신호에 대하여 한 결합당 10개씩을 대상으로 프랙탈 차원을 추출하였다. 최대 에코 강도를 기준으로 하여 결합으로부터 가까운 경우가 가장 기하학적으로 복잡한 프랙탈성을 나타내었고, 거의 1.0 스킵 거리 근처에서는 비교적 낮은 값을 나타내었다. 또한 같은 결합에 있어서 서로 다른 위치와 에코의 유사 형태 파형의 정량적 프랙탈 특징값은 다르게 나타났으며, 서로 다른 결합에 대해서 위치가 다른 경우라도 거의 기하학적 형태가 유사한 프랙탈성을 나타내었으며 이에 대한 구체적인 사항은 Table 1과 같다.

결합 신호가 획득되는 전 부분을 scan하여 황공의 경우에 최대 3.85, 최소 3.47, 평균 3.63으로, 수직공의 경우에 최대 3.82, 최소 3.43, 평균 3.58로, 노치의 경우에 최대 3.80, 최소 3.41, 평균 3.55로 나타났다. scan 위치에 따른 프랙탈 차원의 변화에 있어서 0.5 스킵 거리 및 스킵점에서 높고, 1.0 스킵거리 근처에서 낮은 특성을 나타내었다. 또한 황공의 경우가 수직공이나 노치의 경우보다 더 복잡한 프랙탈성을 나타내었으며, 이상의 결과로부터 결합의 형상에 따른 각각의 초음파 신호를 프랙탈 차원으로 정량화할 수 있다.

이는 기존의 파형 특징 추출에서 일부 파형만을 대상으로 하는 정성적인 경우와는 달리 전체 파형에 대한 어트랙터 재구성으로 위상 공간상에서 신호의 고유 특성을 정량

Table 1 Fractal dimensions of all signals in welding defects

Condition of signals		Fractal dimensions(learn data)	
kind of welding defects	Position	value per point	mean value (Σall point/number)
Side hole	within 0.5 skip	0.83	0.892
	within 0.5 skip	0.88	
	nearby 0.5 skip	0.92	
	within 1.0 skip	0.92	
	within 1.0 skip	0.87	
Vertical hole	within 0.5 skip	0.86	0.879
	within 0.5 skip	0.89	
	nearby 0.5 skip	0.91	
	within 0.5 skip	0.88	
	within 0.5 skip	0.86	
Notch	within 0.5 skip	0.89	0.885
	within 0.5 skip	0.88	
	nearby 0.5 skip	0.90	
	within 0.5 skip	0.92	
	within 0.5 skip	0.85	

화합으로서 초음파 형상 인식의 성능을 향상시킬 수 있다.

6.3 용접 결함 분류를 위한 신경회로망 시스템의 구성

본 연구에서는 비선형성이 강한 초음파 신호를 해석하는데 있어서 최근 비선형 해석에서 그 유효성이 입증된 역전파 학습 알고리즘에 의한 계층형 신경회로망을 적용하였다.

전체 시스템의 구성은 Fig. 12와 같이 크게 2단계로 이루어지게 되며, 첫 번째 단계에서 해석을 위한 주요 사항들이 대부분 결정된다.

첫 번째 단계에서 이루어지는 사항으로는 1) 오스테나이트계 스테인리스강 304 용접부의 결함에 대하여 0.5 ~ 1.0 스킵 거리 내 각각의 측정점들에 대한 초음파의 동요코 패턴 정보를 획득하고, 2) 획득한 정보에 대하여 최적의 특징 선택 및 추출을 하며, 3) 이렇게 결정된 특징들에 대하여 최대 실제값을 기준으로 무차원화하여 데이터를 전처리하고, 4) 입력층, 은닉층, 출력층에 관계되는 사항들을 결정하게 되며, 5) 학습에 의하여 각층간의 결함 계수값이 결정되므로써 시스템이 완성되어진다.

두 번째 단계에서는 첫 번째 단계에서 구축한 시스템을 이용하여 1) 초음파 및 거리와 위치가 다른 결함의 정보로부터 특징 선택 또는 특징 추출을 하며, 2) 결정된 특징들에 대하여 학습시에 적용한 기준을 함께 고려하여 최대 실제값에 대하여 무차원화한 데이터를 전처리하고, 4) 학습된 처리 소자로 덧셈과 곱셈에 의한 테스트를 한후,

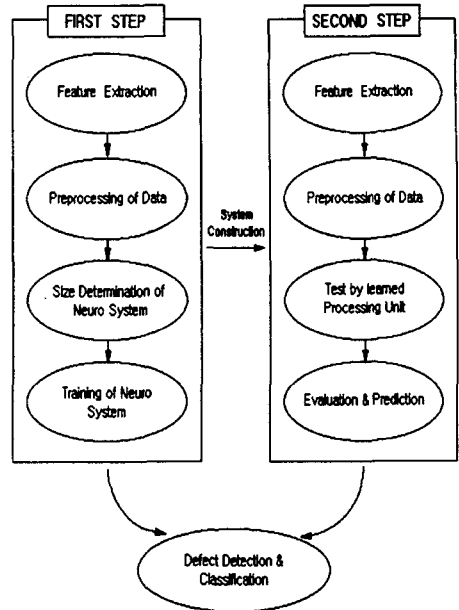


Fig. 12 Constitution of total system for defect analysis

5) 최종적으로 패턴에 대한 성공 인식율(목표값의 90%)을 기준으로 에러율을 계산하여 결함에 대한 판별 및 예측을 한다.

이상과 같은 프로세스는 병렬 컴퓨터나 전용의 뉴로컴퓨터를 사용하면 고속 처리가 가능하며, 해석 대상에 따라 시스템의 규모도 각각 다르게 되므로 간단한 해석을 할 경우에는 계산양이 작기 때문에 소형 컴퓨터정도라도 거의 실시간처리 결과를 얻을 수 있다.

6.4 신경회로망에 의한 결함의 분류 및 평가

신경회로망은 몇개의 샘플 데이터를 학습하여 미학습의 데이터에 대한 입력 정보로부터 출력 정보를 추측하는 시스템으로 본 연구에서는 초음파 신호를 데이터로 하여 결함 분류 시스템을 구성하였다.

적용한 신경회로망의 구조와 입력 조건은 Table 2, Table 3과 같으며, 여기서 학습율과 모멘텀항은 신경회로망 시스템이 최적의 조건을 실행할 수 있도록 실행 시간과 해의 수렴성을 기본으로 많은 반복 시뮬레이션을 하여 결정하였다.

또한 결함의 종류를 인식시키는 방법으로는 두 개의 패턴에 대하여 부울 대수를 이용하여 각각의 결함에 대한 목표값을 갖도록 하였다.

Table 2. Structure of neural network for training

Parameters	Structure
Number of input units	4
Number of hidden units	12
Number of output units	3
Number of hidden layers	1
Learning rate(η)	0.7
Momentum rate(γ)	0.9
Shape factor(θ_0)	1.0

Table 3. Relation of defect and defect type

Defect	Defect type
∅3mm side hole	1
∅3mm vertical hole	2
Notch	3

계층형 신경회로망의 네트워크 규모는 구성된 시스템의 특징을 해석하는 연산량에 직결되는 양으로 출력층과 은닉층간의 결합층수, 은닉층과 입력층간의 결합층수, 출력층 유닛 총수, 중간층 유닛 총수를 고려하여 최종적으로 104로 설정하였으며, 이에 대한 시스템의 최적화에는 128초가 소요되었다.

신경회로망은 탐촉자로부터 결합까지의 빔거리, 횡파 및 종파 사각탐촉자의 주파수 특성, 실측 굴절각 관계, 프랙탈 차원, 에코 강도에 따른 결합의 종류를 표본으로 역전파 학습알고리즘을 이용하여 학습시켰다.

학습은 30개의 패턴을 표본데이터로 하여 전체 에러값을 0.0001, 학습회수 30,000번으로 학습시킨 결과, 한 개의 노치에 대한 패턴(98%)을 제외하고는 목표값에 거의 일치되는 99%정도의 정확성으로 학습되었으며, 입력 패턴에 따른 결합 인식의 학습결과는 Table 4와 같다.

또한 학습된 처리소자들에 의해 새로운 실험조건(위치와 거리가 다른 용접결합)을 테스트하여, 목표값의 90% 이하를 에러 처리 기준으로 평가하였다.

신경회로망에 의한 평가 시스템은 두가지로 설정하였으며, 첫 번째 시스템은 실측 굴절각을 기준으로 하였을 경우이고, 두 번째 시스템은 프랙탈 차원을 고려하였을 경우이다.

Table 5는 횡공에 대한 테스트 결과로 10개의 데이터 중 두개의 데이터가 0.41, 0.89로 나타나므로서 에러로 처리되어 80%의 성공율을 나타내었으며, Table 6의 수직공의 결과에서도 횡공의 경우와 같이 두개의 데이터가 0.79, 0.89로 나타남으로서 80%의 성공률을 나타내었

Table 4 Learning condition and results

Experimental conditions			Actual defect types			Defect type of learning results		
Beam dis&Fractal dim	Echo strength	Miscellaneuss	1	2	3	1	2	3
0.107	1.00	• Real refraction angle	1	0	0	0.99	0	0
0.119	1.00		1	0	0	0.99	0	0
0.137	1.00		1	0	0	0.99	0	0
0.197	0.75		1	0	0	0.99	0	0
0.225	0.72		1	0	0	0.99	0	0
0.269	0.56		1	0	0	0.99	0	0
0.309	0.41		1	0	0	0.99	0	0
0.340	0.40		1	0	0	0.99	0	0
0.781	0.35		1	0	0	0.99	0	0
0.829	0.25		1	0	0	0.99	0	0
0.221	0.35	• Frequency	0	1	0	0	0.99	0
0.263	0.30		0	1	0	0	0.99	0
0.376	0.43		0	1	0	0	0.99	0
0.423	0.70		0	1	0	0	0.99	0
0.489	0.57		0	1	0	0	0.99	0
0.538	0.35		0	1	0	0	0.99	0
0.585	0.35		0	1	0	0	0.99	0
0.621	0.30		0	1	0	0	0.99	0
0.769	0.17		0	1	0	0	0.99	0
0.950	0.10		0	1	0	0	0.99	0
0.383	0.43	0	0	1	0	0	0.99	
0.400	0.45	0	0	1	0	0	0.99	
0.413	0.60	0	0	1	0	0	0.99	
0.436	0.20	0	0	1	0	0	0.99	
0.483	0.15	0	0	1	0	0	0.99	
0.507	0.15	0	0	1	0	0	0.99	
0.542	0.75	0	0	1	0	0	0.99	
0.890	0.30	0	0	1	0	0	0.99	
0.937	0.28	0	0	1	0	0	0.99	
0.990	0.17	0	0	1	0	0	0.99	

Table 5 Test result of horizontal hole

Experimental conditions			Defect type of learning results			Actual defect types
Real refraction angle	Echo height	Miscellaneuss	1	2	3	
1.00	0.70	• Beam distance	0.99	0	0	1
1.00	0.70		0.41	0.58	0	1
0.99	0.75		0.99	0	0	1
0.99	0.69		0.99	0	0	1
0.99	0.65		0.99	0	0	1
0.99	0.62		0.99	0	0	1
0.99	0.60		0.99	0	0	1
0.99	0.53		0.99	0	0	1
0.99	0.48		0.89	0.11	0	1
0.99	0.45		0.92	0.07	0	1

다. Table 7 노치의 경우에서는 한 데이터가 0.88로 나타남으로서 에러로 처리되었으나, 횡공, 수직공의 경우보다는 높은 인식율(90%)을 나타내었다.

Table 6 Test result of vertical hole

Experimental conditions			Defect type of learning results			Actual defect types	
Real refraction angle	Echo height	Miscellaneity	1	2	3		
0.99	0.40	• Beam distance	0	0.92	0.07	2	
1.00	0.35		0	0.99	0	2	
1.00	0.35		0	0.79	0.21	2	
1.00	0.35		0	0.99	0	2	
0.99	0.30		0	0.99	0	2	
0.99	0.25		• Frequency	0	0.99	0	2
0.99	0.75			0	0.99	0	2
0.99	0.70			0	0.99	0	2
0.99	0.65			0	0.99	0	2
0.99	0.50			0	0.89	0.11	2

Table 7 Test result of notch

Experimental conditions			Defect type of learning results			Actual defect types
Real refraction angle	Echo height	Miscellaneity	1	2	3	
1.00	0.28	• Beam distance	0	0	0.98	3
1.00	0.28		0	0.04	0.95	3
1.00	0.25		0	0	0.99	3
1.00	0.22		0	0	0.99	3
1.00	0.20		0	0	0.99	3
0.99	0.99	• Frequency	0	0	0.99	3
0.99	0.99		0	0	0.99	3
0.99	0.99		0	0	0.99	3
0.99	0.99		0	0.11	0.88	3
0.99	0.99		0	0.08	0.91	3

프랙탈 차원을 고려한 평가 시스템에 있어서 Table 8 은 횡공에 대한 테스트 결과로 10개의 데이터중 한개의 데이터가 0.88 나타나므로서 에러로 처리되어 90%의 성공율을 나타내었으며, Table 9의 수직공의 결과에서도 횡공의 경우와 같이 한개의 데이터가 0.87로 나타남으로서 90%의 성공율을 나타내었다. Table 10 노치의 경우에는 전체 10개의 데이터가 0.90이상으로 나타남으로서 100%의 높은 인식율을 나타내었다. 두 개의 시스템에서 에러로 나타난 부분에 있어서도 프랙탈 차원을 적용한 경우 거의 0.90에 근접한 미소한 인식율의 차이를 나타내었으며, 이는 내·외삽을 나타내는 신경회로망의 특성상 학습의 범위를 벗어나게 됨으로서 일반화 능력으로 는 평가가 힘든 경우에 해당된다고 생각된다.

프랙탈을 고려한 평가의 결과 전체 30개의 데이터중 2개만을 에러로 처리함으로써 93.3%의 적중율을 나타내었으며, 이는 실측 굴절각을 고려한 경우의 83.3%보다

Table 8 Test result of horizontal hole

Experimental conditions			Defect type of learning results			Actual defect types	
Fractal dimension	Echo height	Miscellaneity	1	2	3		
0.83	0.70	• Beam distance	0.99	0	0	1	
0.86	0.70		0.98	0.12	0	1	
0.88	0.75		0.99	0	0	1	
0.93	0.69		0.99	0	0	1	
0.89	0.65		0.99	0	0	1	
0.92	0.62		• Frequency	0.99	0	0	1
0.91	0.60			0.99	0	0	1
0.94	0.53			0.94	0.05	0	1
0.92	0.48			0.99	0	0	1
0.88	0.45			0.99	0	0	1

Table 9 Test result of vertical hole(case of fractal dimension)

Experimental conditions			Defect type of learning results			Actual defect types	
Fractal dimension	Echo height	Miscellaneity	1	2	3		
0.88	0.40	• Beam distance	0	0.95	0.04	2	
0.86	0.35		0	0.99	0	2	
0.87	0.35		0	0.99	0	2	
0.91	0.35		0	0.99	0	2	
0.89	0.30		0	0.99	0	2	
0.92	0.25		• Frequency	0	0.87	0.12	2
0.91	0.75			0	0.99	0	2
0.85	0.70			0	0.99	0	2
0.86	0.65			0	0.99	0	2
0.85	0.50			0	0.94	0.05	2

Table 10 Test result of notch(case of fractal dimension)

Experimental conditions			Defect type of learning results			Actual defect types	
Fractal dimension	Echo height	Miscellaneity	1	2	3		
0.90	0.28	• Beam distance	0	0.03	0.96	3	
0.86	0.28		0	0	0.99	3	
0.84	0.25		0	0	0.99	3	
0.89	0.22		0	0	0.99	3	
0.92	0.20		0	0	0.99	3	
0.87	0.99		• Frequency	0	0	0.99	3
0.91	0.99			0	0.08	0.92	3
0.93	0.99			0	0	0.99	3
0.89	0.99			0	0	0.99	3
0.86	0.99			0	0	0.99	3

10% 높게 용접 결함 판별을 할 수 있음을 의미하며, 따라서 본 연구에서 제시한 프랙탈 차원을 신경회로망 시스템의 특징으로 적용할 경우, 용접 결함 판별의 정밀도를 향상시킬 수 있다고 생각된다.

7. 결 론

오스테나이트계 스테인리스강 304 용접부는 결정립이 조대한 주상정 조직으로 초음파를 이용하여 결함을 검출할 경우, 페라이트계 탄소강과는 달리 결함의 검출 및 평가가 대단히 어렵다고 하는 것이 세계적으로 공통된 견해이다. 특히 우리나라의 오스테나이트계 스테인리스강 용접부의 결함 검출에 대한 초음파적 연구는 단편적이고도 세부적인 몇몇 결과에 머물러 있는 실정이다.

따라서 본 연구에서는 이러한 점을 고려하여 오스테나이트계 스테인리스강 304 용접 시험편에 인공 결함(횡공, 수직공, 노치)을 가공하여 초음파에 의한 용접부 결함의 정량적 검출에 대한 고찰과, 검출된 결함에 대하여 역전파 학습 알고리즘에 의한 계층형 신경회로망으로 학습시킨 후 프랙탈 차원을 고려한 테스트로부터 결함의 종류를 분류하므로써 다음과 같은 결론을 얻었다.

(1) 오스테나이트계 스테인리스강 304의 용접부 결함 검출을 위한 초음파 탐상에 있어서 횡파 및 종파 사각 탐촉자의 조합으로 용착 금속부와 열영향부의 결함 검출 가능성을 확인할 수 있었다.

(2) 용착 금속과 열영향부에 대한 DAC의 기준 탐상 감도(50.7, 58.4dB)와 예비 탐상 감도(68.7, 76.4dB)에 의한 결함의 검출로 실용성을 띤 정량적 초음파 기준을 제시하였다.

(3) 프랙탈 차원을 고려한 신경회로망 평가 시스템으로부터 횡공에서 90%, 수직공에서 90%, 노치에서 100%의 성공율을 나타내었으며, 전체 30개의 패턴에 대하여 93.3%의 높은 적응율로 결함의 종류를 판정하였다.

(4) 시스템 규모 104로 구성된 신경회로망으로 결함의 종류를 결정함으로써 향후 용접 결함 분류 자동화를 위한 실용적인 평가 방법을 제시하였다.

참 고 문 헌

1. Thomas F. Perrone, "Principles of Radiographic Film Interpretation of Pipeline Welds, Journal of the American Society for Nondestructive Testing," Vol. 50, 11, pp.

1268~1273, 1992.
 2. 이 원, 윤인식, 유영철, 정의섭, "초음파에 의한 SM45C/STS410재의 접촉압력 측정에 관한 연구," 한국정밀공학회지, 제13권 제11호, pp.92~99, 1996.
 3. ASME Boiler & Pressure Vessel Code Sec. XI, "Rules for Inservice Inspection of Nuclear Power Plant Components," pp. 287~319, 1995.
 4. S. J. Song and L. W. Schmerr, "Ultrasonic Flaw Classification in Weldments using Probabilistic Neural Networks," Journal of Nondestructive Evaluation, Vol. 11, pp. 395~406, 1995.
 5. 이 원, 윤인식, 황영택, 유영철, 정의섭, "초음파법을 이용한 용접부의 결함 검출과 평가," 대한기계학회 추계학술대회 논문집(I), pp. 41~46, 1996.
 6. 이 원, 윤인식, 이병채, 김영환, "카오스 특징 추출에 의한 시계열 신호의 초음파 형상 인식," 대한기계학회 추계학술대회 논문집(I), pp. 41~45, 1997.
 7. 이병채, "시계열 데이터의 혼돈도 분석 알고리즘에 관한 연구," 대한의용생체공학회 추계학술대회 논문집, pp. 281~284, 1995.
 8. 김정석, 강명창, 이기용, 구세진, "엔드밀가공시 복합계측 신호를 이용한 공 구 마멸의 카오스적 해석," 한국정밀공학회지, 제14권 11호, pp. 93~101, 1997.
 9. F. Takens, "Lecture Notes in Mathematics," D. A. Rand and L. S. Young(eds.), Springer, Vol. 898, P. 266, 1981.
 10. 윤인식, 이성식, 김영환, 이정기, 김호철, "접촉식 초음파 시험에서 접촉매질의 영향에 관한 고찰," 한국비파괴검사학회 추계학술발표회 논문집, pp. 206~211, 1996.
 11. 岸上守孝, "オーステナイト系ステンレス鋼溶接部の超音波探傷試験方法に關する指針," 非破壊検査, 第34卷 2號, pp. 60~76, 1985.