

2차원 푸리에변환과 주성분분석을 기반한 초음파 용접검사의 신호분류기법

Classification Technique for Ultrasonic Weld Inspection Signals using a Neural Network based on 2-dimensional Fourier Transform and Principle Component Analysis

김재준

Jaejoon Kim

초 록 신경망 기반의 신호 분류 시스템은 비파괴 검사 시 추출되는 많은 양의 데이터를 처리하기 위한 방법으로 꾸준히 이용되고 있다. 비파괴검사 방법 중, 초음파 탐상법은 용접 지역에서 결함들을 찾기 위하여 비파괴 검사에서 일반적으로 사용되고 있는 추세다. 초음파 탐상법의 중요한 특징은 특정 신호에서 발생하는 불연속성을 판별해내는 능력이다. 지금까지의 보편화되어 있는 기술은 신호를 분류하기 위해 각각의 A-scan 신호를 처리하는 반면 본 논문에서는 이웃하는 A-scan 신호의 정보를 기반으로 하는 2차원 푸리에 변환(Fourier transform)과 주성분 분석(principal component analysis) 기법을 이용하여 특징 벡터를 추출, 분류하는 방법을 제시하고자 한다.

주요용어: 용접검사, 신경망, 2차원 푸리에 변환, 주성분 분석

Abstract Neural network-based signal classification systems are increasingly used in the analysis of large volumes of data obtained in NDE applications. Ultrasonic inspection methods on the other hand are commonly used in the nondestructive evaluation of welds to detect flaws. An important characteristic of ultrasonic inspection is the ability to identify the type of discontinuity that gives rise to a peculiar signal. Standard techniques rely on differences in individual A-scans to classify the signals. This paper proposes an ultrasonic signal classification technique based on the information lying in the neighboring signals. The approach is based on a 2-dimensional Fourier transform and the principal component analysis to generate a reduced dimensional feature vector for classification. Results of applying the technique to data obtained from the inspection of actual steel welds are presented.

Keywords: welding inspection, neural network, 2-D Fourier transform, principal component analysis

1. 서 론

자동화 신호 분류(automated signal classification, ASC) 시스템은 많은 양의 자료들을 정확하고 일률

적으로 해석을 할 수 있기 때문에 비파괴 검사에 점점 많이 사용되고 있다. 특히, 자동화된 신호 분류 시스템은 초음파, 와전류 및 누설자속탐상 신호들을 포함하여 다양한 소스로부터 발생하는 신호를 분류

하기 위해 성공적으로 사용되어 오고 있다[1,2]. 초음파 탐상 기법은 화학물질, 핵설비, 가스 전송관등과 같은 다양한 응용분야에서 용접부분의 특성을 규명하는데 널리 사용되고 있다[3]. 일반적으로, 초음파 비파괴 검사에서 트랜스듀서는 테스트 샘플에 초음파를 전송하고 불순물 등으로 인해 반사되는 에너지가 트랜스듀서에 의해 전기신호로 변환되고 그 결과 발생되는 1차원 시간 영역의 신호를 A-scan 이라 한다. 테스트 샘플의 2차원 영역을 래스터 스캔하면 샘플의 3차원 입체 데이터가 추출된다.

용접과정 및 재료 용력, 피로 그리고 환경 변화로 인해 용접 부분은 다양한 가공물들이 발생할 수 있다. 용접 재료와 모재 사이에 불완전한 접착은 "융합 불량" 또는 "용입부족"을 초래할 수 있다. 또한, 용접 재료에서 다양한 불순물들은 용접 시 계재물로 혼입될 수도 있다[4]. 용접부위에서 발생하는 결함은 구조물을 취약하게 만드는 원인이 된다. 이러한 계재물의 크기와 불순물의 종류에 따라 결함의 종류는 기공 또는 슬래그등으로 분리할 수 있다. 또한, 균열은 용접 영역 내 또는 용접 주변의 열영향부(heat affected zone, HAZ)에서 형성될 수 있다(Fig. 1). 용접과정에서 여러 가지 결함 형태를 살펴보면 일반적으로 크게 평면 결함과 체적 결함으로 분류할 수 있다. 슬래그와 기공은 체적 결함인 반면 융합불량과 균열은 평면 결함으로 발생한다. Table 1은 평면 결함과 체적결함의 일반적인 특성을 비교한 것이다. 입체적 결함은 강도 측면에서 볼 때 심각하게 고려되고 있지는 않지만 재료의 특성을 변형시키거나 치명적인 균열을 초래할 수 있는 특성을 지니고 있다. 이러한 각각의 결함들은 초음파 탐상 시 항상 탐상자 들에게 신호 분류의 어려움을 주고 있다.

지금까지 초음파 신호 분류 시스템은 개별적인 A-scan 신호를 처리하는데 주로 초점을 맞추고 있다[5]. 시간영역에서의 A-scan 신호는 신호의 크기와 형태를 이용하여 불연속점을 결정하는데 큰 역할을 담당하고 있다. 비록 단일 A-scan 신호를 처리함으로써 얻을 수 있는 장점은 구현하기가 쉽고 사용자에게 합리적인 결과를 제시해주지만 많은 양의 신호 중 하나의 신호가 시간, 공간, 또는 변환영역에서 대표적인 결함으로 판정을 내릴 수는 없다. 따라서 보다 나은 접근방법은 신호를 판별하기 이전에 결함신호의 이웃신호를 해석하는 방법이다. 종래의 신호 분류 접근방법은 A-scan 신호 그룹을 주성분분석(principal component analysis, PCA) 방

법을 적용한 사례를 참고문헌[6]에서 살펴볼 수 있다. 본 논문에서는 이러한 PCA 방법을 2차원으로 확장하고자 한다. 이러한 2차원 이미지로부터 추출된 푸리에변환 계수와 주성분분석의 하이브리드 알고리즘 구조를 통해 결함신호의 이웃신호 해석은 중요한 또 하나의 특징벡터로 형성될 수 있다. 우선 1단계 과정으로 B-scan 이미지에서 2차원 푸리에 계수를 구하는 방법을 설명하고 변환계수를 PCA 알고리즘에 적용된 후 식별력 있는 정보를 내포하고 있는 특징을 추출하여 신경망을 통해 신호를 분류한다.




Fig. 1 Weld inspection geometry and description of the flaws

Table 1 Comparison of planar flaw vs. volumetric flaw

Flaw type	Characteristics	
Planar flaws	<ul style="list-style-type: none"> • May initiate catastrophic brittle or fatigue failure • Often difficult to find • Cracks, incomplete fusion, inadequate penetration 	Critical flaws ↑↓ Non-critical flaws
Volumetric flaws	<ul style="list-style-type: none"> • Loss of cross section • Easier to find • Pores, blowholes, inclusions, many surface irregularities 	

2. 2차원 특징 추출

이미지의 특징은 이미지 자체의 고유 특성 및 속성을 구별해준다. 특징 추출에서 우선 2차원 푸리에 변환 계수의 크기와 위상정보를 이용하고 1차 과정에서 생산된 특징을 차수를 축소시키기 위하여 주성분 분석을 이용한 과정을 살펴보겠다.

2.1. 2차원 푸리에 변환계수

용접 부분의 2차원 스캔은 일반적으로 공간적인 위치에서 A-scan을 함으로써 데이터를 얻을 수 있다. 테스트 샘플은 3차원 입체 데이터로 형성되어 있기 때문에 (x,y) 좌표를 기준으로 시간정보 t 에

따라 $Z(x,y,t)$ 의 값으로 스캔해 나간다. 초음파 신호 처리에서 일반적으로 볼 수 있는 이미지의 형태인 C-scan은 2차원 좌표 (x,y) 위치에서 A-scan 신호의 최대값으로 형성된 이미지다. 한편, ROI(Region of Interest)는 C-scan 이미지에서 관심영역을 선택한 부분인데 본 논문에서는 이러한 ROI 영역 안에 있는 B-scan 과 B'-scan 신호들을 분석하였다.

ROI는 $Z(x',y',t)$ 로 나타낼 수 있으며 여기서 $(x',y') \in [x_1, x_2] \times [y_1, y_2]$ 이고 x_1, x_2, y_1, y_2 는 C-scan 이미지의 공간좌표 값을 나타낸다. $y'=y_0$ 에서 용접에 수직방향으로 스캔한 데이터를 B-scan 이라 하고 $Z(x',y_0,t)$ 로 표현할 수 있다. 반면에, $x'=x_0$ 에서 용접에 수평방향으로 스캔한 데이터는 B'-scan 이라 부른다. B-scan 및 B'-scan 의 예제는 Fig. 2에서 살펴볼 수 있다. 일반적으로, B-scan 및 B'-scan 이미지는 트랜스듀서가 결함의 한 라인을 따라 스캔할 때 A-scan에서의 신호 변화가 잘 나타나 있다. 따라서, B-scan 및 B'-scan 은 탐촉자의 표면에 수직인 면에 있는 물체의 횡단면을 보여준다. 이러한 이미지는 여러 종류의 결함을 구분할 수 있는 중요한 정보를 포함하고 있기 때문에 이웃하는 신호 정보를 이용하는 방법은 개별 A-scan 신호를 이용한 방법보다 효과적이다.

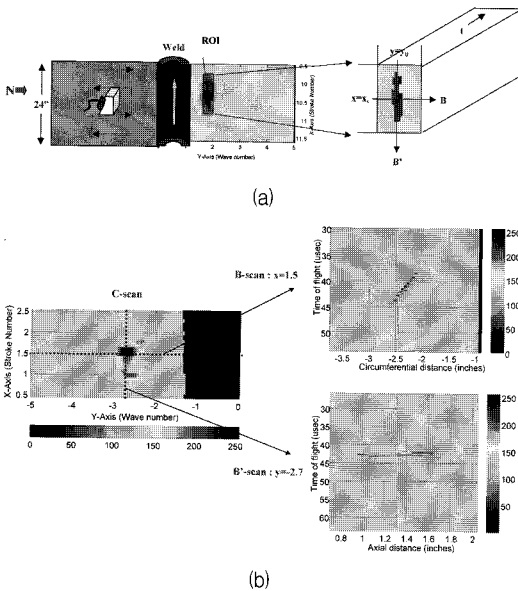


Fig. 2 Description of scanning method - (a) ROI, B- and B'-scan images, (b) examples

B-scan 과 B'-scan 이미지들은 결함의 클래스를 구별하기 위하여 자동화된 신호 분류 알고리즘에 적용된다. 이러한 자동화신호분류 시스템의 주요 절차를 살펴보면 (i) 전처리(pre-processing), (ii) 특징추출(feature extraction), 그리고 (iii) 분류(classification)로 이루어져 있다. 전처리 과정은 일반적으로 데이터의 잡음을 제거하고 주어진 표준 데이터 포맷에 맞추는 작업을 한다. 신호 분류 시스템에서, 특징 추출은 데이터 길이를 줄이고 여러 클래스로부터 신호를 구별할 수 있는 정보를 추출하는 과정이다. 가장 효과적인 특징의 선택을 통하여, 측정하고자 하는 데이터 벡터의 차수가 감소되고 또한 처리과정의 속도를 높여줄 수 있다. 지금까지 신호의 특징추출을 위해 시간, 주파수, 공간영역에서 적용된 연구를 참고문헌[7,8]에서 살펴볼 수 있다. 이러한 특징추출 중 주파수영역에서 적용되고 있는 푸리에 계수는 신호의 주파수 성분과 분포의 표현에 적합하여 보편적으로 신호 특징추출에 많이 사용되어 오고 있다. 푸리에 변환은 시간영역에서의 신호를 복소지수 기저함수를 이용하여 주파수 영역으로 전환한다. 마지막 단계인 분류과정은 신경망을 이용한 식별자나 클러스터링 접근방법으로 수행한다.

본 연구에서는 특징 추출을 위해 2차원 푸리에 변환(2-D DFT)[9]을 이용하였으며 다음 식으로 쓸 수 있다.

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \exp[-j2\pi ux/M] \exp[-j2\pi vy/N] \quad (1)$$

여기서 $f(x,y)$ 는 두개의 공간 변수 x 와 y 의 함수이며 B-scan 및 B'-scan 이미지를 나타낸다. 또한, u 와 v 는 주파수 변수, M, N 은 2차원 이미지의 픽셀수를 나타낸다. 일반적으로 푸리에 스펙트럼의 다이내믹 영역을 향상시키면서 데이터를 보기위해 $\log|F(u,v)|$ 를 이용한다. 또한 푸리에 계수의 대각대칭 성질에 이용하면 1사분면의 이미지만 필요로 하기 때문에 차수를 감소시킬 수 있다. 푸리에 변환은 크기와 위상정보를 다음과 같이 표현할 수 있다.

$$|F(u, v)| = [\text{Re}^2(F(u, v)) + \text{Im}^2(F(u, v))]^{1/2} \quad (2)$$

$$|\phi(u, v)| = \tan^{-1}[\text{Im}(F(u, v))/\text{Re}(F(u, v))] \quad (3)$$

여기서, Re 와 Im 은 각각 실수부와 허수부를 나타낸다. 이러한 2차원 스펙트럼 정보를 이용하여

하나의 특징벡터 즉, 크기와 위상정보의 결합된 특징을 구하기 위해 본 연구에서는 2차원 스펙트럼에 대한 1차 모멘트를 이용하였다. 즉, 크기와 위상 스펙트럼으로부터 주파수 변수 v 의 값에 따라 모든 행을 평균한 값이다.

$$M_v(i) = \frac{1}{M} \sum_{u=0}^{M-1} F(u, i), \quad \text{for } i = 0, 1, 2, \dots, (N/2) - 1. \quad (4)$$

$$\Phi_v(i) = \frac{1}{M} \sum_{u=0}^{M-1} \phi(u, i), \quad \text{for } i = 0, 1, 2, \dots, (N/2) - 1. \quad (5)$$

따라서 결합된 특징벡터(combined feature vector, CFV)는 다음과 같이 쓸 수 있다.

$$CFV_v(i) = \left[\frac{1}{M} \sum_{u=0}^{M-1} F(u, i), \quad \frac{1}{M} \sum_{u=0}^{M-1} \phi(u, i) \right], \quad (6)$$

$$i = 0, 1, 2, \dots, N/2 - 1.$$

Fig. 3은 위 과정에서 생성된 CFV_v 의 예를 보여 주고 있다. 이러한 CFV_v 가 주성분 분석에서 처리된 후 다층인식자 신경망[10]을 통해 각 결합의 클래스를 구별한다.




Fig. 3 Combined feature vector plots for the first moment of the magnitude and phase along frequency variable v of four classes (a) crack, (b) slag, (c) porosity, and (d) lack of fusion

2.2. 주성분 분석

푸리에 변환과정에서 구한 특징 벡터는 일반적으로 데이터양이 크기 때문에 압축이 필요하다. 물론, 압축 과정은 앞서 구한 특징 벡터들의 정보를 손실

하지 않는 범위에서 진행되어야 한다. 이러한 목적으로 본 논문은 PCA 방법을 제안하려고 한다. PCA는 1901년부터 여러 변수를 가진 데이터 분석에 잘 알려진 방법이다[11,12]. 주성분은 고유벡터와 공분산 행렬을 이용하여 구할 수 있으며 공분산 행렬의 대각화는 Hotelling 변환 또는 Karhunen-Loève 변환 (KLT) [13]이라 부르기도 한다.

x 를 하나의 랜덤벡터, $x = [x_1 \ x_2 \ \dots \ x_n]^T$, 라 하자. 여기서 랜덤벡터 x 의 평균과 공분산은 각각 다음과 같이 쓸 수 있다.

$$\mu_x = E\{x\} \quad (7)$$

$$C_x = E\{(x - \mu_x)(x - \mu_x)^T\} \quad (8)$$

C_x 의 원소들인 c_{ij} 는 랜덤벡터 x 의 각각의 원소 x_i 와 x_j 의 공분산을 나타낸다. 만일 두 성분 x_i 와 x_j 가 서로 상관관계가 없다면 두성분의 공분산은 영의 값을 갖는다. ($c_{ij} = c_{ji} = 0$) 또한 통계적으로 공분산은 항상 실수값을 가지며 대칭관계를 나타내는 특성을 지니고 있다. C_x 에 대한 고유벡터의 직교행렬은 공분산 행렬을 대각화 함으로써 유도할 수 있다. 한편, C_x 의 고유치와 고유벡터는 특성방정식 $|C_x - \lambda I| = 0$ 와 $C_x e_i = \lambda_i e_i, i = 1, 2, \dots, n.$ 로부터 구할 수 있다. 여기서 I 는 C_x 와 동일 차수를 갖는 단위행렬이며 $| \cdot |$ 는 행렬식을 나타낸다. 내림차순 고유치로부터 고유벡터를 정렬시킨 후 데이터의 가장 큰 분산방향을 가지는 고유벡터로 정렬화된 직교기저를 형성할 수 있다. 이러한 방법으로 본 논문은 실험 데이터를 가장 큰 에너지를 가지는 방향을 찾을 수 있다.

행렬 A 를 직교 기저집합이라 하고 K 개의 고유벡터를 A_K 라 쓰면 변환 및 복원 방정식은 다음과 같이 쓸 수 있다.

$$y_K = A_K(x - \mu_x) \quad (9)$$

$$x = A_K^T y_K + \mu_x \quad (10)$$

특징추출에서 일반적인 목적은 가능한 원 데이터의 정보를 유지하면서 차수를 낮추는데 있다. 이러한 개념을 이용한 PCA 차수 축소와 정보손실 간의 조율을 효과적으로 이용해야 한다.

한편, 균열, 슬래그, 기공, 용합불량의 공분산 행렬로부터 K개의 고유벡터를 V_{crk} , V_{slg} , V_{por} , V_{lof} 라 하고 하자. 그러면, 2.1절에서 설명한 결합된 특징 벡터 ($CFV_v = F$)의 PC 성분은 고유벡터에 대한 투영을 통해 다음과 같이 얻어질 수 있다.

$$PC_{crk} = E[F^T V_{crk}] \quad (11)$$

$$PC_{slg} = E[F^T V_{slg}] \quad (12)$$

$$PC_{por} = E[F^T V_{por}] \quad (13)$$

$$PC_{lof} = E[F^T V_{lof}] \quad (14)$$

최종적인 PCA기반의 특징 벡터는 $PC = [PC_{crk} \ PC_{slg} \ PC_{por} \ PC_{lof}]$ 로 쓸 수 있다.

주성분 분석에서 중요한 요소는 고유치 선택이다. 그러나, 적절한 고유치를 선택하는 일반적인 기준은 없어 본 논문에서는 각 클래스에서 11개의 가장 큰 고유치를 선택했다(Fig. 4). 각각의 클래스로부터 11개의 고유벡터를 트레이닝 데이터로부터 유도할 수 있다. 각 트레이닝 벡터는 44개의 고유벡터로 투영되어 44 차수의 특징벡터를 만들 수 있다. 각각의 PC 성분은 다층인식자 신경망(Fig. 5)을 통해 입력이미지의 클래스를 결정한다. 신경망의 각 층에서 사용된 노드수는 44-20-8-4 를 이용하였다. 2 차원 푸리에 변환계수 및 PCA 특징추출, 각 결합의 클래스를 구별하는 전반적인 과정을 다음과 같이 정리할 수 있다.




Fig. 4 Eigenvalues of the covariance matrix: (a) B-scan data (b) B'-scan data






Fig. 5 The multi-layer perceptron architecture with two hidden layers

- Step 1: Select a region of interest (ROI) on C-scan image.
- Step 2: Obtain B- and B'-scans from a ROI.
- Step 3: Create a fixed size image.
- Step 4: Compute two-dimensional Fourier transform.
- Step 5: Compute the first moment of two-dimensional spectra.
- Step 6: Normalize the data.
- Step 7: Compute the covariance matrix, eigenvalues, and eigenvectors.
- Step 8: Compute the principal components (PC).
- Step 9: Train B- and B'-networks.
- Step 10: Classify test images.



(a)



(b)

(c)

Fig. 6 The description of test sample - (a) scanning procedure, (b) HY-80 steel sample plate, and (c) a cross-sectional view

3. 실험 및 결과 고찰

테스트 샘플은 불연속성을 띤 계재물을 포함하여 제조된 가로, 세로, 두께가 24×24×1.5 인치의 크기를 가진 HY-80 강철 샘플을 이용하였다. 이 실험 샘플은 GMAW(gas metal arc welding)과정을 통해 제조되었고 4개의 서로 다른, 균열, 용합불량, 기공 및 슬래그의 결함을 포함하고 있다. Fig. 5는 테스트 샘플의 일반적인 스캐닝 방법과 구조도를 보여주고 있다. 데이터를 추출하기 위해 트랜스듀서는 용접부분의 용접선 방향을 따라 용접부분을 중심으로 North, South 방향으로 스캐닝하여 데이터를 수집했다. 자동화 스캐닝 시스템을 이용한 데이터는 5 MHz 트랜스듀서, 60도 사각 빔 및 25 MHz의 샘플링 주파수를 이용하였다.

본 연구에서 실험데이터는 4개의 결함(균열, 기공, 슬래그, 융합불량)으로 구성된 총 28개의 샘플 플레이트를 사용하였다. 이 샘플 플레이트로부터 114개의 B-scan 과 225개의 B'-scan 이미지로 구성되어 있다. Table 2는 테스트 데이터의 분포를 보여주고 있다. 2, 3절에서 언급한 것처럼 테스트 이미지로부터 푸리에 변환 계수를 통해 크기와 위상정보로 구성된 특징벡터를 구하고 이로부터 주성분 분석을 통해 최종 특징벡터를 구하기 위해 차수를 감소시켰다. 여기서, 차수 감소의 중요 특성은 고유치 선택이 중요한 요소임을 알 수 있다. 본 연구에서는 11개의 고유치를 선택하였고 각 결함의 클래스는 대응하는 11개의 고유벡터로 표현되고 각 트레이닝 데이터는 총 44개의 고유벡터로 투영된 후 44-차원의 특징벡터가 생성된다. 마지막으로 트레이닝 데이터는 각각(20, 8)개의 뉴런으로 구성된 2개의 은닉층을 통해 다층성 인식자의 신경망에 적용된다. 이러한 과정을 거쳐 생성된 각 층에서의 가중치 값을 이용하여 테스트 데이터를 시험하였다. 최종 클래스 분류는 다수투표기술 (majority voting technique)에 의해 결정된다. Table 2와 3은 B-scan 과 B'-scan의 결과를 보여주고 있다.

Table 2 Summary of data distribution and classification results for training and testing data using PCA for B-scans

Data distribution

Number of images	Crack	Porosity	Slag	Lack of fusion
Train	22	17	13	28
Test	10	7	5	12

Training data

Defect Type	Crack	Slag	Porosity	Lack of fusion
Crack	22	0	0	0
Slag	0	17	0	0
Porosity	0	0	13	0
Lack of fusion	0	0	0	28

Testing data

Defect Type	Crack	Slag	Porosity	LOF	Classification rate (%)
Crack	8	0	0	2	80
Slag	0	5	1	1	71
Porosity	0	1	4	0	80
Lack of fusion	2	0	0	10	83

마지막으로 Table 4는 C-scan 이미지의 최종 분류 결과를 보여주고 있는데 Table 2 와 3에서 보는 것처럼 각각의 B-scan 과 B'-scan 이미지의 클래스 분류에 에러가 발생하였지만 Table 4에서 나타난 것처럼 4개의 클래스를 구별하는 정확도를 보여주고 있다. 다수투표기술은 B-scan 과 B'-scan 이미지의 클래스 분류결과를 결합한 뒤 C-scan 테스트 샘플의 결과를 나타낸 것이다. 또한 중요한 요소로 지적할 수 있는 점은 두가지 클래스, 즉, 평면결함(균열, 융합불량)과 체적결함(기공, 슬래그)으로 볼 때 Table 2와 3에서 서로 연관성을 보여주고 있다.

Table 3 Summary of data distribution and classification results for training and testing data using PCA for B'-scans

Data distribution

Number of images	Crack	Porosity	Slag	Lack of fusion
Train	44	44	39	51
Test	19	19	17	22

Training data

Defect Type	Crack	Slag	Porosity	Lack of fusion
Crack	44	0	0	0
Slag	0	44	0	0
Porosity	0	0	39	0
Lack of fusion	0	0	0	51

Testing data

Defect Type	Crack	Slag	Porosity	LOF	Classification rate (%)
Crack	13	3	1	2	68
Slag	5	10	2	2	53
Porosity	1	2	13	1	76
Lack of fusion	2	3	0	17	77

Table 4 Summary of classification results using PCA for individual C-scans

Defect Type	Crack	Slag	Porosity	Lack of Fusion	Total
Crack	7				7/7
Slag		7			7/7
porosity			7		7/7
Lack of Fusion				7	7/7

4. 결 론

본 논문은 이웃하는 신호정보를 이용하여 초음파 신호 분류를 자동화하는 시스템을 검토하였다. 시스템은 용접검사 시 추출된 B-scan 과 B'-scan 데이터를 이용하여 2차원 푸리에변환계수 와 주성분분석의 하이브리드 알고리즘 구조를 통해 각각의 클래스에 대한 특징 벡터를 적용하여 신경망을 통해 분류하였다. 마지막 단계에서 각 클래스를 분류하기 위해서는 이웃하는 신호정보에서도 마찬가지로 여러 개의 클래스로 분류되기 때문에 히스토그램을 이용하여 클래스를 구분하였다. 비록, 초음파 신호 분류 시스템은 개별적인 A-scan 신호를 이용하여 처리하지만 본 연구는 이웃하는 신호정보, 즉, 그룹 정보를 이용한 접근방법을 제시하였다. 용접부분 검사 시 적용된 제안된 알고리즘은 플래너 형태의 결함과 체적 형태의 결함 구별 및 각각의 결함 구분 4개의 결함을 구분하는데 효과적으로 이용할 수 있는 결과를 보여주고 있다.

감사의 글

본 논문은 2003년도 대구대학교 교내연구비 지원에 의해 수행되었음.

참고문헌

- [1] P. Ramuhalli, L. Udpa, and S. S. Udpa, "An Automatic Signal Classification System for Ultrasonic Weld Inspection Signals," *Materials Evaluation*, Vol. 58, No. 1, pp. 85-89, (2000)
- [2] S. J. Song and Y. K. Shin, "Eddy Current Flaw Characterization in Tubes by Neural Networks and Finite Element Modeling," *NDT International*. Vol. 33, No. 4, pp. 233-243, (2000)
- [3] J. H. Krautkramer, *Ultrasonic Testing of Materials*, 4th Edition, New York, Springer-Verlag, (1990)
- [4] 이철구, *용접공학*, 청문각, (2002)
- [5] R. Polikar, L. Udpa, S. S. Udpa, and T. Taylor, "Frequency Invariant Classification of Ultrasonic Weld Inspection Signals," *IEEE Trans. Ultrasonics, Ferroelectrics and Frequency Control*, Vol. 45, No. 3, pp. 614-625, (1998)
- [6] *Neural Networks and Semi-Automatic Scanners for NDE Applications*, EPRI TR-107119, EPRI Final Report, (1996)
- [7] J. L. Rose, M. J. Avioli, and M. E. Lapidés, "A Physically Modeled Feature Based Ultrasonic System for IGSCC Classification," *Material Evaluation*, Vol. 40. No. 13, pp. 1367-1383, (1982)
- [8] S. F. Burch, "A Physical Approach to the Automated Ultrasonic Characterization of Buried Weld Defects in Ferritic Steel," *NDT International*. Vol. 19, No. 3, pp. 145-153, (1986)
- [9] Rafael C. Gonzalez and Richard E. Woods, *Digital Image Processing*, Reading, MA: Addison-Wesley Publishing, (1992)
- [10] Haykin Simon, *Neural Networks*, Prentice Hall, (1994)
- [11] Looney, Carl G., *Pattern Recognition Using Neural Networks : Theory and Algorithms for Engineers and Scientists*, Oxford, (1991)
- [12] Erkki Oja. "Neural Networks, Principal Components, and Subspaces," *International Journal of Neural Systems*, Vol. 1, No. 1, pp. 61-68, (1989)
- [13] W. K. Pratt, *Digital Image Processing*, John Wiley & Sons, Inc., New York, (2001)