

## 용접 결함 분류를 위한 초음파 형상 인식 기법

송 성진

조선대학교 기계설계공학과

요 약 초음파탐상시험을 통해 용접 결함의 종류를 정확히 구분하는 것은 정량적 비파괴시험을 위한 기본적인 단계로서 매우 중요한 문제인데, 이 문제는 최근 활발한 연구가 진행중인 초음파 형상 인식 기법의 적용에 의해 해결할 수 있다. 여기에서는 특징 추출, 특징 선택 그리고 결함 분류 등 초음파 형상 인식 기법의 세부 기술과 함께, 특히 최근 효율적인 분류기로 관심을 모으고 있는 확률 신경 회로망의 적용에 대해 논의하였다. 그리고 강 용접부 내부에 존재하는 결함을 균열, 기공, 슬래그 혼입의 3 종류로 분류하는 문제에 확률 신경 회로망을 적용한 예를 통하여, 초음파 형상 인식 기법의 효율성을 검증하였다. 또한 민감한 특징을 효율적으로 선별하는데 널리 사용되는 전방 특징 선택법과 그 적용에 대해서도 논의하였다.

### 1. 서론

용접부는 그 제조 공정의 특성상 균열, 기공, 슬래그 혼입 등 다양한 내부 결함이 존재할 가능성이 매우 높으며, 이 중 균열 등의 결함은 용접부의 기계적 강도에 치명적인 영향을 미치고 경우에 따라서는 예기치 않은 파괴를 일으키기도 한다. 따라서 용접부에 존재하는 결함을 검출해내고 그 영향을 정량적으로 평가하는 것이 용접부 성능 보장을 위해 필수적인 과제이다. 잘 알려진 바대로 용접 결함의 영향 평가는 파괴역학적 접근이 주로 사용되고 있는데, 그 과정에서 필요한 결함에 대한 위치, 종류, 방향 등의 정량적 정보는 비파괴시험을 통해 얻고 있다. 현재 산업 현장에서 용접부 내부 결함의 검출을 위해 널리 사용되고 있는 비파괴시험 방법중의 하나가 초음파시험이다.

일반적으로 초음파시험은 결함의 위치 검출에는 대단히 효율적인 방법이지만, 결함의 종류·형상·크기 등 정량적 정보를 정확히 결정하는 데는 아직도 신뢰도가 낮기 때문에, 초음파시험에 의한 용접 결함

의 종류 판별 및 크기 산정이 비파괴시험 분야의 중요한 연구과제의 하나가 되어 왔으며, 특히 결함 종류 판별은 정량적 결함 평가의 첫번째 단계로서 그 중요성이 깊이 인식되어 이에 대한 많은 연구가 진행중이다. 현재 산업 현장에서 초음파 결함 분류를 위한 수단으로 가장 보편적으로 사용되는 방법은 에코동 패턴(echodynamic pattern)의 특성을 이용하는 것이지만<sup>1,2)</sup>, 이 방법은 작업자의 경험과 주관적인 판단에 따라 달라지기 때문에 객관성이 결여되기 쉬워 실제적인 적용에 어려움이 많다.

이러한 결점을 보완하기 위해 정량적인 결함 분류에 대한 연구가 진행되었는데 초기에는 주로 용접 결함 분류에 결정적인 역할을 할 수 있는 "강한 특징(strong features)"를 초음파 결함 신호에서 찾아내는데 많은 관심이 집중되었다<sup>3-6)</sup>. 강한 특징이라 함은 초음파 결함 신호에 이 특징이 존재한다는 것은 곧 그 결함이 특정 종류의 용접 결함이라는 매우 확실한 증거가 되는 것으로서 보통 초음파 빔이 결함에 의해 산란되는 과정에 대한 이론적 모형을 기초로 정의하고 있다. 이러한 부류에 속하는 연

구들로는 Shcherbinskii와 Bely의 "형상 인자(form factor)"<sup>3)</sup>, Gruber의 "위성 펄스(satellite pulse)"<sup>4)</sup>, Chiou와 Schmerr의 "모우드 변환 신호(mode converted signals)"<sup>5)</sup>, 그리고 Fitting과 Adler에 의해 정리된 "스펙트럼 특징(spectral features)"<sup>6)</sup> 등이 있다.

그러나 실제적인 결함 분류 문제는 몇 개의 강한 특징만으로 해결할 수가 없는 경우가 대부분이기 때문에 "초음파 형상 인식(ultrasonic pattern recognition)"에 대한 연구가 시도되었다. 초음파 형상 인식 기법은 초음파 탐촉자로 얻은 결함 신호로부터 여러 가지 "특징(feature)"을 추출하고, 이 특징들을 기초로 "분류기(classifier)"를 이용하여 결함 종류를 판별하는 기술이다. 따라서 초음파 형상 인식 기법에는 첫째, 결함 신호로부터 여러 가지 특징들을 어떻게 효과적으로 추출해 낼 것인가하는 특징 추출(feature extraction), 둘째, 추출된 특징 중 결함 분류에 보다 유용한 특징들을 선별해 내는 특징 선택(feature selection), 그리고 특징들을 사용하여 결함의 종류를 판별하는 분류(classification)의 세 과정으로 세분할 수 있다. 초음파 형상 인식에 대한 연구의 초기에는 선형 판별 함수(linear discriminant function) 등 비교적 간단한 통계적 분류 기법을 적용한 연구가 Rose, Burch 그리고 Bealing 등에 의해 행해졌으며<sup>7,8)</sup> 국내에서도 심철무 등<sup>9)</sup>의 연구결과가 발표된 바 있다. 최근 인공 지능 분야의 발전과 함께 Mucciadi<sup>10)</sup>와 Koo<sup>11)</sup> 등이 적응 학습 회로(adaptive learning network)를, Schmerr에 의해 전문가시스템(expert system)<sup>12)</sup>이 적용되었다. 특히 최근에 신경 회로망(Neural Network; NN) 기법의 적용이 시도되었는데, 대부분 역전파 신경 회로망(Back Propagation Neural Network; BPNN)이 적용되었고<sup>13)</sup>, Song과 Schmerr<sup>14)</sup>에 의해 확률 신경 회로망(Probabilistic Neural Network; PNN)의 적용이 이루어졌다. 그러나 지금까지의 초음파 형상 인식 연구들은 새로운 분류 기법의 실험적 적용에 연구 중점을 두고 있어, 용접 결함 분류 기법의 각 과정을 포괄하는 체계적인 접근은 아직 시도되지 않고 있다.

따라서 본 연구에서는 초음파 형상 인식 기법의 특징 추출, 특징 선택 그리고 결함 분류의 각 과정

에 대해 간략히 고찰하고, 최근 결함 분류기로서 고성능이 입증된 PNN을 이용하여 실제적인 용접 결함 분류 문제를 해결한 적용 사례를 통해 용접 결함 분류 자동화를 위한 체계적인 접근 방법을 제시코자 한다.

## 2. 초음파 형상 인식

기계를 사용하여 어떤 물체의 특징을 파악하고 그것을 기초로 대상물의 종류·특성을 결정하는 작업을 형상 인식<sup>15-17)</sup>이라고 하는데, 현재 문자나 음성 인식 등 다양한 분야에서 활용되고 있다. 초음파 탐촉자에서 얻은 결함 신호로부터 그 신호의 특징을 파악하고 결함의 종류·특성을 결정하는 작업도 역시 형상 인식의 한 범주에 속하기 때문에 초음파 형상 인식이라고 부른다. 초음파 형상 인식 기법은 특징 검출, 특징 선택, 결함 분류의 3단계로 나누어 생각할 수 있는데 여기에서는 각 과정에 대해 간략히 논의코자 한다.

### 2.1. 특징 추출

특징 추출 단계는 초음파 탐촉자의 전기적 결함 신호로부터 결함 분류를 위해 유용한 형태의 특징을 도출해내는 과정으로서, A-스캔 형태의 초음파 결함 신호의 복잡성을 줄여서, 결함 분류 알고리즘을 간단히 하는 동시에 분류 정확도를 향상시키는데 그 목적이 있다. 이 과정에서 가장 중요한 문제는 과연 어떤 특징이 결함 분류에 유용한 특징이며, 그것을 어떻게 추출하느냐 하는 것인데, 사실상 이 문제가 결함 분석 정확도에 가장 큰 영향을 미치는 핵심과제로서 지금까지 수행된 "강한 특징"을 찾으려는 많은 연구들의 연구 목적이 이 문제의 해결에 있다고 할 수 있다. 초음파 결함 신호에서 결함 분류에 유용한 것으로 여겨지는 특징들은 Rose<sup>7)</sup>, Burch와 Bealing<sup>8)</sup>, Durocher<sup>16)</sup> 등이 제안한 바 있으며, 국내에서도 심철무 등<sup>9)</sup>의 연구에서 정리된 바 있다. 이러한 특징들은 이론적 모형이나, 경험적인 결과들로부터 정의된 것들로서, 보통 디지털 신호처리 기법을 이용하여 도출한다.

### 2.2. 특징 선택

특징 추출 단계에서 도출된 특징이 모두 결합 분류에 유용한 것이 아니므로, 그 중에서 결합 분류에 유용한 특징인 "민감한 특징"만을 선택하는 과정을 특징 선택 단계라 한다. 보통 민감한 특징이 지녀야 할 특성으로는 첫째, 결합 분석을 위해 충분한 정보를 가지고 있으며, 둘째는 물리적 시스템이 지니고 있는 종류간 이질성을 특징 공간에서도 일관성 있게 유지해야 하고, 셋째로는 사용코자 하는 특징이 모든 표본(sample)에 대해서 일관성있게 도출 가능해야 한다는 것 등이다<sup>17)</sup>. 이러한 정성적인 특성들은 실제 특징 선택 과정에서의 적용 기준으로는 분명하지 않기 때문에 보다 정량적인 특징 평가 기준이 필요하게 된다. 정량적인 평가 기준을 설정할 때 보통 고려되는 조건으로는 결합 종류 구분 능력과 특징간의 독립성의 두 가지이다. 결합 종류 분류 능력은 특징의 결합 분류에의 효용성을 의미하며, 결합 분류시 발생하게 되는 오류 확률로 정량화시킬 수 있으며<sup>18)</sup>, 특징간의 독립성은 특징의 중복성을 피하면서 특징의 숫자를 줄이는 것과 관계가 있는데, 상관 계수로 정량화시킬 수 있다<sup>19)</sup>.

만약 d-차원을 갖는 특징 집합  $x = \{ \xi_1, \xi_2, \dots, \xi_d \}$  를 생각할 때, 오류 확률 e는 식(1)로 표시된다.

$$e = \int [1 - \max P(w_i | \xi)] p(\xi) d\xi \dots\dots\dots(1)$$

여기에서  $\xi$ 는 d개의  $\xi_i$ 특징에 의해 구성되는 특징 벡터이고, 즉

$$\xi = [\xi_1, \xi_2, \dots, \xi_d]^T \dots\dots\dots(2)$$

$P(w_i | \xi)$ 는 i번째 범주에 대한 사후 확률이며  $p(\xi)$ 는 식(3)으로 정의되는 혼합 밀도 함수이다.

$$p(\xi) = \sum_{i=1}^m p(\xi | w_i) P(w_i) \dots\dots\dots(3)$$

여기에서  $P(w_i)$ 는 i번째 범주의 사전 확률이다.  $P(w_i | \xi)$ 는 i번째 범주의 조건부 확률 밀도 함수  $p(\xi | w_i)$ 와 식(4)의 관계를 가지고 있다.

$$P(w_i | \xi) = \frac{p(\xi | w_i) P(w_i)}{p(\xi)} \dots\dots\dots(4)$$

민감한 특징은 (1)식으로 정의된 오류 확률 e를

작게하는 특징으로서 e값이 낮을수록 결합 구분 능력이 우수하다.

두 변수간의 상호 의존성을 측정하는 통계량 중에서 가장 대표적인 척도가 Pearson의 상관계수<sup>19)</sup>인데, 이는 식 (5)에 의해 정의된다.

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{[\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2]^{1/2}} \dots\dots\dots(5)$$

여기에서, n은 표본 수를  $X_i, Y_i$ 는 두 가지 서로 다른 특징 X, Y의 i번째 값을,  $\bar{X}_i, \bar{Y}_i$ 는 각각 두 특징 X, Y의 평균값을 나타낸다. 이 상관 계수 r은 두 변수간의 관계가 선형 관계인지를 측정하는 척도로서 r의 절대값이 1에 가까우면 두 변수 사이의 상호 의존성이 매우 높음을 의미한다.

따라서 민감한 특징이란 전술한 오류 확률 e값이 낮으면서 동시에 다른 특징과의 r의 절대값이 작은 특징을 말한다고 할 수 있으며, 특징 선택이란 e값과 r값을 바탕으로 가장 적절한 특징들을 선별해 나가는 과정이라 할 수 있다.

### 2.3. 결합 분류

특징 추출과 특징 선택 과정을 통하여 민감한 특징이 결정되면 이 특징을 이용하여 각 표본을 가장 적합하다고 판단되는 범주로 분류하는 과정을 결합 분류라 하는데, 이때 분류기는 결합 분류에 분류 알고리즘을 사용한다. 지금까지 개발되어 현재 널리 사용되고 있는 분류 기준중 대표적인 분류 기법에 대해 간략히 정리한다.

#### 2.3.1. K-Nearest Neighbor (KNN) 분류기

KNN 분류기의 분류 알고리즘은 "특정 공간상에서 어떤 분류 대상 표본(X) 주위에 가장 가까이 있는 K개의 학습 표본중 가장 많은 수가 속해 있는 범주로 분류 대상 표본 X를 분류한다"라고 말할 수 있다. 이 분류 알고리즘은 비록 직관적이긴 하지만, 특징 공간상에서 가장 복잡한 형태의 의사 결정 표면(decision surface)를 가질 수 있어 광범위하게 이용되고 있다<sup>14)</sup>.

#### 2.3.2. Bayesian 분류기

Bayesian 분류기는 패턴 분류시 통계적 접근 방

법인 Bayes 결정 이론에 기초를 두고 있다. 이 방법은 모든 의사 결정 문제가 확률적인 개념들을 사용할 때 적절하게 풀릴 수 있다고 가정하며, 또한 의사 결정에 필요한 확률적 내용들이 알려져 있거나 혹은 학습 표본으로부터 추정이 가능할 때 주로 적용되고 있다. 실제 패턴 분류 과정에서 분류자가 궁극적으로 관심을 갖게 되는 것은 오분류 때문에 입게되는 손해 즉, 기대 손실이다. 따라서 이러한 점을 중시한 Bayes 결정 법칙의 분류 알고리즘은 다음과 같이 말할 수 있다. 즉 “특징 벡터  $\xi$ 를 갖는 실험 표본에 대해  $R(a_i | \xi)$ 를 최소로 하는 범주  $w_i$ 로  $\xi$ 를 분류하라.” 여기에서  $R(a_i | \xi)$ 는 조건부 위험이라고 부르는데, 이는 다음과 같이 계산된다.

$$R(a_i | \xi) = \sum_{j=1}^m \lambda(a_i | w_j) P(\xi | w_j) \dots \dots \dots (6)$$

여기에서  $a_i (i=1, 2, \dots, a)$ 는  $a$ 개의 행동(action)을 나타내며,  $\lambda(a_i | w_j)$ 는 범주  $w_j$ 인 시험 표본에 대해  $a_i$ 의 행동을 취했을 때 입게 되는 손실이다. Bayesian 분류 알고리즘은 여러가지 패턴 분류 문제를 다루는데 있어, 실제적 상황을 가장 잘 반영하는 분류기라 할 수 있다. 그러나, 이 Bayes 분류기를 적용하는데 있어서 가장 큰 문제점은 사후 확률  $P(w_j | \xi)$ 를 사용해야 하는데, 이를 위해서 필요한 범주별 조건부 확률 밀도 함수  $p(\xi | w_j)$ 를 알아야 한다. 학습 표본으로부터  $p(\xi | w_j)$ 를 추정하는 방법에는 여러가지가 있으나 그 중 가장 널리 사용되는 것이 Parzen window 기법<sup>20)</sup>으로서, 주어진 개개의 학습 표본에 대해 특정한 성질을 갖는 window (주로 Gaussian 분포 함수를 사용)를 이용하여 연속적인 분포를 갖는 확률 밀도 함수를 만들고, 각각의 학습 표본으로부터 구한 개별 밀도 함수를 합하여 최종적인 확률 밀도 함수를 추론하는 방법이다. 즉  $j$ 번째 범주  $w_j$ 에 속하는  $n$ 개의 학습 표본에 대한  $n$ 개의 특징 벡터  $\xi_i (i = 1, \dots, n)$ 가 있다고 할 때  $d$ -차원 공간상의 임의의 점  $\xi$ 에서 Parzen window 기법에 의해 추정할 수 있는 조건부 확률 밀도 함수  $p(\xi | w_j)$ 는 다음과 같이 주어진다.

$$p(\xi | w_j) = \frac{1}{n} \sum_{i=1}^n \frac{1}{\sqrt{2\pi} \sigma}$$

$$\exp \left[ -\frac{1}{2} \frac{(\xi - \xi_i)^t (\xi - \xi_i)^t}{\sigma^2} \right] \dots \dots \dots (7)$$

여기서  $\sigma$ 는 각 학습 표본으로부터  $p(\xi | w_j)$ 를 추정할 때 각 학습 표본의 개별적인 중요도를 조절하는 계수로써  $\sigma$ 값을 작게 하면 개개의 학습 표본의 중요성을 강조하게 되고,  $\sigma$ 값을 크게 하면 많은 학습 표본들의 평균적인 거동을 강조하게 된다.

2.3.3. 신경 회로망 분류기

신경 회로망은 인간 뇌의 구조와 작동 원리를 모형화할 수 있다는 점과 함께, 학습 표본을 통해 필요한 지식을 배울 수 있으며, 또한 학습 표본에서 경험하지 못하였을지라도 배운 지식을 일반화하여 필요한 결론을 자동적으로 내려준다는 독특한 장점 때문에 1980년 후반부터 그 활용이 급속히 증가하고 있다. 20여 가지의 신경 회로망 구조중 가장 널리 사용되는 것은 BPNN<sup>21)</sup>이다. BPNN은 상기의 신경 회로망의 특성을 잘 나타내고 있어 패턴 분류, 자동 제어, 회귀 분석 등에서 널리 사용되고 있다. 그러나 BPNN은 입력과 출력 사이의 관계가 사용자에게 대하여 불투명하고, 학습 시간이 어떤 경우에는 너무 길어서, 모든 문제에 대해 보편성 있는 분류기로 사용하기에는 아직도 해결해야 할 문제점이 많은 상태이다. 이에 반해 PNN<sup>22)</sup>은 병렬 처리 능력 등 신경 회로망이 가지고 있는 여러가지 장점과 함께, 패턴 분류시 통계적 Bayesian 기법을 적용시킬 수 있어 특히 패턴 분류 분야에서 널리 활용되고 있다.

3. 확률 신경 회로망

PNN은 BPNN과 외형적으로 매우 비슷해 보이지만, 실제로는 구조와 이용 방법에서 매우 독특한 특색을 가지고 있다. 이 절에서는 PNN의 구조, 학습 과정, 결함 분류 등의 중요한 특성에 대해 간단히 언급코자 한다.

3.1. 구조

Fig.1에 PNN의 기본적인 구조를 나타내었다.

PNN은 4개의 층(layer)으로 구성되어 있다. 첫째 층은 입력층으로서 여기들 통해 각 표본의 특징 벡




Fig. 1. Probabilistic neural network architecture

타( $X_i$ )가 PNN에 공급된다. 두번째 층은 패턴층으로서 입력층에 공급된 표본의 특징값  $X_i$ 에 가중치  $W_{ij}$ 를 곱한 결과들의 합을 받아들여, 그 값에 지수 함수를 적용한 값을 출력시킨다. 세번째 층은 합산층으로서, 합산층의 각 노드(node)들은 패턴층의 노드들 중 자신과 같은 범주에 속한 노드들에만 연결되어 있는데, 연결된 패턴층의 노드들의 출력의 합을 입력으로 받아들인 후 여기에 사용자가 정의한 파라미터인  $C_i$ 를 곱하여 그 결과를 출력시킨다. 마지막으로 네번째 층은 출력층으로써 최종적인 출력이 결함 분류 과정에 사용된다. 다른 종류의 신경 회로망과는 달리, PNN의 구조는 주어진 문제가 가지고 있는 결함 종류의 수와 학습 과정에서 사용된 학습 표본의 수에 의해 결정된다. 즉 출력층과 합산층의 노드의 수는 결함 종류(즉 범주)의 수와 같고, 패턴층의 노드수는 학습 표본의 수와 일치하며, 입력층의 노드수는 특징 벡터의 특징수와 동일하다. 그리고, PNN에는 세가지 종류의 가중치가 존재한다. Fig. 1의  $W_{ij}$ 는 학습 표본의 특징 벡터들의 특징값을 그대로 사용하기 때문에 학습 표본으로부터 직접 결정된다. 실제로 PNN내에서 조절 가능한 파라미터는 사용자가 정의하는 파라미터인  $C_i$ 와 전달 함수내의 평활화 계수  $\sigma$ 가 있는데 이들에 대해서는 다음에 간략히 설명코자 한다.

### 3.2. PNN의 학습

PNN의 학습 과정은 매우 간단한 다음의 3과정으로 이루어져 있다. (1) 학습 표본이 주어지면 패턴층에 이에 해당하는  $j$ 번째 노드  $N_j$ 를 설정한다. (2) 만약에  $X_{ij}(i=1,2,3 \dots M, j=1,2, \dots N)$ 를 주어진  $j$ 번째 학습 표본의  $i$ 번째 특징이라고 하면, 패턴층의  $j$ 번째 node와 입력층의  $i$ 번째 노드를 잇는 연결선의 가중치  $W_{ij}$ 를  $X_{ij}$ 와 같게 한다. (3) 그리고 마지막으로 패턴층의  $j$ 번째 노드를 주어진 학습 표본이 속해있는 범주에 상응하는 합산층과 연결한다.

학습 과정에서 특징적인 것은 가중치  $W_{ij}$ 가 반복 과정이 없이 "순간적"으로 결정된다는 것이며, 따라서 학습도 "순간적"으로 완료된다는 점이다. 또한 이 학습 과정에서 PNN은 학습 표본으로부터 Parzen window 방법을 통해 각 범주별 확률 밀도 함수를 계산한다는 점이다.

### 3.3. 회로망 파라미터의 선택

일단 회로망의 훈련이 끝나면 사용자 정의 파라미터인  $C_i$  ( $i=1,2,3$ )와 평활화 계수  $\sigma$ 를 선택해야한다.  $C_i$ 는

$$C_i = \frac{h_i l_i}{n_i} \dots \dots \dots (8)$$

로 정의된다. 여기에서  $h_i$ 는  $i$ 번째 범주의 사전 확률,  $l_i$ 는 손실 계수,  $n_i$ 는  $i$ 번째 범주내의 학습 표본의 수이다. 따라서 사용자가 균열과 같은 어떤 특정 범주에 더 큰 비중을 두고 싶을 때에는 손실 계수  $l_i$ 에 큰 값을 지정할 수 있다.

평활화 계수  $\sigma$ 는 패턴층내에 있는 각 패턴들의 개별적인 중요도를 조절하는 계수로서  $\sigma$  값을 작게 하면 개개의 패턴에 대한 중요성을 강조하게 되고,  $\sigma$  값을 크게 하면 많은 패턴들의 평균적인 거동을 강조하게 된다. 실제로 평활화 계수  $\sigma$ 는 2.3.2절에서 언급한 바와 같이 개개의 학습 표본으로부터 범주별 확률 밀도 함수를 추론할 때 사용되는 계수로서, 어떤 이론적 근거로부터 결정된다기보다는 다분히 실용적 관점에서 비교적 "양호한" 결함 분류 성능을 얻을 수 있는  $\sigma$  값을 찾아 사용하고 있다.

3.4. 결함 분류

PNN의 학습과 회로망 파라미터에 대한 선택이 끝나면, 이 PNN을 이용하여 시험 표본에 대한 결함 분류를 수행할 수 있다. PNN의 결함 분석 알고리즘은 “주어진 시험 표본에 대한 출력층의 노드중 최대값(이 값은 곧 최대 예상 손실을 의미함)을 갖는 범주를 그 시험 표본의 범주로 결정한다”라고 할 수 있다. 이것은 곧 PNN이 Bayes법칙에 따라 결함 분류를 수행함을 말한다.

4. 용접 결함 분석 적용 예

이 절에서는 지금까지 논의한 초음파 형상 인식 기법을 실제적인 용접 결함 분류 문제에 적용한 사례를 중심으로, 결함 분류를 위한 특징 추출, 특징 선택, 그리고 PNN을 이용한 결함 분류의 과정에 대한 체계적 접근 방법을 제시코자 한다.

4.1. 초음파 특징 추출과 PNN

본 연구에는 미국 Westinghouse사가 연구를 위해 특별히 제작한 결함의 종류, 위치 그리고 대략적인 크기를 알고 있는 균열, 기공, 슬래그 혼입 등 3가지 종류의 용접 결함을 내포하고 있는 강용접 시험편에서 1.5MHz, 45° 사각탐촉자 두개를 사용하여 pitch-catch법으로 채취한 A-스캔 협대역 초음파 결함 신호를 사용하였다. 이 시험편의 대략적인 크기는 길이 875mm × 폭 630mm × 두께 270mm 이며 일반 강재로된 시험 상부를 스테인리스강으로 약6.0mm 정도 클래딩(cladding)하였기 때문에, 이 시험편에서 채취한 초음파 결함 신호는 매우 많은 노이즈 성분을 포함하고 있다. 균열에서 104개, 기공에서 53개, 슬래그 혼입에서 82개, 총 239개의 결함 신호를 수집하여 이중 120개의 결함 신호를 학습 표본으로 하고 나머지를 시험 표본으로 사용하였다.

용접 결함 종류 판별을 위해 필요한 초음파 특징은 특징 추출을 위해 특별히 작성한 컴퓨터 프로그램을 통해 추출하였는데 이때 문제가 되는 것 중의 하나는 A-Scan 초음파 신호에 내재되어 있는 잡음 성분이다. 본 연구에서는 이러한 잡음 성분을 줄이기 위하여 A-Scan 초음파 신호에 대해 5점 이동평균(5-point moving averaging)을 통해 고주파 잡음 성분을 제거한 후, 적당한 threshold값을 취하여 결함 신호와 잡음 신호를 구분하였다. 그리고 이렇게 잡음 성분이 제거된 초음파 결함 신호를 특징 추출 프로그램에 입력하여 초음파 특징들을 결정하였다.

결함 분류의 성패는 초음파 결함 신호에서 어떤 특징을 추출하여 사용하느냐에 달려 있기 때문에 가능한 한 “강한 특징”을 많이 선택해야 한다. 이를 위해서는 협대역보다는 주파수 영역의 정보를 풍부히 가지고 있는 광대역 결함 신호를 이용하는 것이 바람직하다. 그러나 불행히도 Westinghouse사가 채취한 결함 신호는 이러한 특징 추출을 우선적으로 고려하지 않고 채취한 것이기 때문에 종래의 연구 결과에서 제안되었던 여러가지 특징들을 사용할 수가 없어, Table 1에 보인대로 총 14개의 특징(시간 영역에서 10개, 주파수 영역에서 4개)을 추출하였다.

결함 분류의 성패는 초음파 결함 신호에서 어떤 특징을 추출하여 사용하느냐에 달려 있기 때문에 가능한 한 “강한 특징”을 많이 선택해야 한다. 이를 위해서는 협대역보다는 주파수 영역의 정보를 풍부히 가지고 있는 광대역 결함 신호를 이용하는 것이 바람직하다. 그러나 불행히도 Westinghouse사가 채취한 결함 신호는 이러한 특징 추출을 우선적으로 고려하지 않고 채취한 것이기 때문에 종래의 연구 결과에서 제안되었던 여러가지 특징들을 사용할 수가 없어, Table 1에 보인대로 총 14개의 특징(시간 영역에서 10개, 주파수 영역에서 4개)을 추출하였다.

Table 1. Features extracted from ultrasonic flaw signals.

Domain	No	Feature	Remark
Time	F1	number of signal groups	# of groups
	F2	pulse duration of the 1st group signal	pulse duration or energy
	F3	interval between the 1st and the 2nd groups	
	F4	pulse duration of the 2nd group signal	
	F5	interval between the 2nd and the 3rd groups	
	F6	pulse duration of the 3rd group signal	
	F7	energy of the 1st group signal	
	F8	energy of the 2nd group signal	
	F9	energy of the 3rd group signal	
	F10	antisymmetry of signal	
Frequency	F11	number of maxima in the magnitude spectrum	spectral properties
	F12	number of minima in the magnitude spectrum	
	F13	number of deep minima in the magnitude spectrum	
	F14	number of shallow minima in the magnitude spectrum	

본 연구에서 사용한 특징들은 균열로부터 초음파 빔이 산란될 때 이론적으로 예견되는 특징인 F10 (역대칭성, antisymmetry)을 제외하고는 대개가 채취된 결함 신호의 특성을 고려하여 직관적으로 결

정한 특징들이다.

이상의 초음파 특징들을 이용하여 결함 분류를 수행할 수 있도록 PNN을 구성하였는데, 이 PNN은 14개의 입력층 노드와 120개의 패턴층 노드, 그리고 3개의 합산층 및 출력층 노드를 가지고 있으며, 패턴층 노드의 전달 함수로써 지수함수를 사용하였다.

4.2. 성능 평가 기준

결함 분류 성능을 평가하기 위하여 "정확한 채택률(correct accept rate)",  $(CA)_i$ 와 "오류 기각률(false reject rate)",  $(FR)_i$ 등 두가지 평가 기준을 선택하였다.  $(CA)_i$ 와  $(FR)_i$ 는 각각 다음과 같이 정의된다.

$$(CA)_i = \frac{m_i}{n_i} \quad (i=1,2,3) \dots\dots\dots(9)$$

$$(FR)_i = \frac{\sum_j m_{ji}}{\sum_j n_j} \quad (j \neq i) \dots\dots\dots(10)$$

여기에서  $m_i$ 는  $i$ 번째 범주에 속한 총  $n_i$ 개 시험표본중 정확히 분류된 시험 표본의 수이며,  $m_{ji}$ 는  $j$ 번째 범주에 속한  $n_j$ 개의 시험 표본중  $i$ 번째 범주로 잘못 분류된 시험 표본의 수를 나타낸다.

4.3. PNN의 성능

그림 2a와 b에 균열, 기공, 슬래그 혼입의 세가지 범주에 대하여 범주별 사전 확률  $h_i(i=1,2,3)$ 는 모든 범주에 대해 동일한 것으로 간주하고 손실 계수  $l_i(i=1,2,3)$ 도 역시 모든 범주에 대해 1로 택하였을때, 평활화 계수  $\sigma$  값의 변화에 따른 PNN 성능 변화를 나타내었다.




Fig. 2a. Correct accept rates of welding defects by the PNN for different choices of the smoothing parameter  $\sigma$  and with  $l_i = 1$  for all.




Fig. 2b. False reject rates of welding defects by the PNN for different choices of the smoothing parameter  $\sigma$  and with  $l_i = 1$  for all.

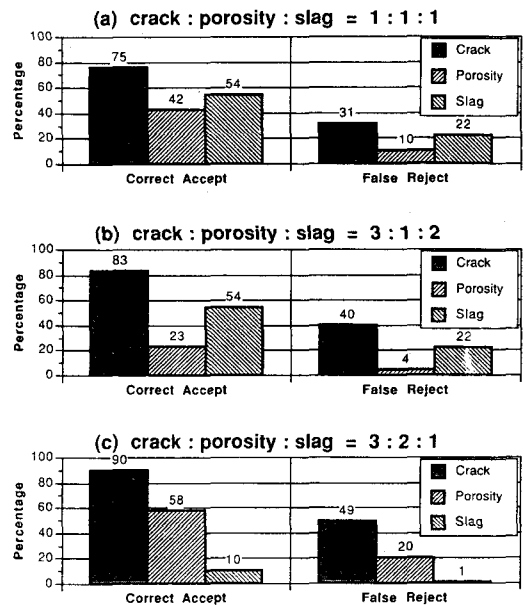


Fig. 3. Influence of the choice of the  $l_i$  parameter on PNN performance.

이들 그림은  $\sigma$  값이 0.03~0.3 사이의 값에서는 결함 분류 성능에 그다지 큰 변화가 없음을 보여주

고 있는데, 실제로  $\sigma$  값을 이 범위 이상으로 다양하게 변화시켰을 때도 비교적 비슷한 결과를 얻을 수 있었다. 따라서 평활화 계수  $\sigma$ 가 PNN 성능을 크게 좌우하지 않기 때문에 이후의 논의에서는  $\sigma=0.1$ 로 고정하고 여타 변수를 변화시켰다. 그림 3a에  $\sigma=0.1$ ,  $i_i=1(i=1,2,3)$ 인 경우의 PNN의 성능을 요약하였으며, 그림 3b,c는 각 결함 범주에 대한 손실 계수  $i_i$ 를 다르게 취했을 때의 PNN의 거동을 나타내었다.

잘 알려진 바대로 균열은 여타 다른 결함보다도 훨씬 중요하기 때문에 균열을 다른 결함으로 오분류했을 때 입게 되는 피해는 상대적으로 클 수밖에 없다. 그래서 균열에 대한 손실 계수를 높게 책정하면 (그림 3b,c) 균열에 대한 정확한 채택률이 향상되는데, 이때 유의해야 할 점은 균열에 대한 오류 기각률도 동시에 증가한다는 점이다.

Fig. 2와 3에서 보인 PNN의 성능은 불행히도 통상 희망하는 높은 정확도에 비해서 상당히 낮은 값이다. 그러나 우리가 본 연구에서 사용한 데이터를 KNN 분류기를 이용하여 결함 분류를 실시했을 때도 비슷한 수준의 결과를 얻을 수 있었다<sup>14)</sup>. 따라서 이렇게 결함 분류 정확도가 낮은 이유는 초음파 결함 신호 자체에 많은 양의 노이즈를 함유하고 있는 등 데이터 자체의 특성에 기인한다고 보여진다. 최근 많은 연구 결과에서 PNN이 KNN이나 BPNN으로 얻을 수 있는 것보다 더 우수한 성능을 보인다고 보고되고 있다<sup>14,23)</sup>.

4. 4. 특징의 선택

지금까지의 논의에서는 특징 추출 과정에서 선택된 14개의 특징들에 대한 결함 분류에의 유용성에 관하여는 아무런 검증없이 PNN의 성능에만 관심을 집중하였다. 그러나 실제 결함 분류 작업의 효율성 증대를 위해서는 특징들의 유용성 검증이 필수적이다. 앞에서 언급한 바와 같이 민감한 특징이란 결함 구분 능력이 뛰어나면서 동시에 다른 특징과의 상호 의존성이 낮은 특징을 말하는데, 결함 구분 능력은 식(1)의 오류 확률로, 상호 의존성은 식(5)의 상관 계수로 측정할 수 있다. Table 2에 14개 특성들에 대한 오류 확률과 상호 의존성을 나타내었다.

오류 확률  $e$  값은 Fig. 4에 보인 것과 같이 어떤 특정 특징에 대한 각 범주별 확률 밀도 함수를 그렸

Table 2. Result of error probability analysis and correlation analysis for features.

Feature	error probability		features with strong correlation	
	rank	e (%)	$ r  \geq 0.9$	$0.7 \leq  r  \leq 0.9$
F1	1	41.8		F11, F12, F14
F2	9	52.7	F7	F3, F4, F8
F3	6	49.9		F2, F7
F4	10	55.2	F8	F2, F7
F5	12	59.5		
F6	14	62.6	F9	
F7	7	50.1	F2	F3, F4, F8
F8	8	52.5	F4	F2, F7
F9	13	59.8	F6	
F10	5	49.4		
F11	3	46.1		F1, F11, F14
F12	2	43.9		F1, F12, F14
F13	11	56.9		
F14	4	47.5		F1, F11, F12




Fig. 4. Schematic representation of the probability of error estimated from class conditional probability density functions.

을 때 결함 종류별 확률 밀도 함수가 중첩되는 부분(그림4의 빗금친 부분)의 백분율을 의미한다. 이 값이 곧 어떤 특정 특징 하나만을 가지고 결함 분류를 시행했을 때 겪게 되는 전체적인 오분류 확률을 나타낸다. 오류 확률  $e$ 를 결정하기 위해서는 결



합 종류별 조건부 확률 밀도 함수  $p(\xi | w_j)$ 가 필요하는데, 이 확률 밀도 함수는 학습 표본으로부터 식 (7)을 사용하여 결정하였다. 그런데 이 경우에는 사용하는 특징수가 1개씩이기 때문에 식(7)의  $\xi$ 와  $\xi_i$ 가 1차원 변수가 되며, 모두 14개 초음파 특징에 대해 이에 해당하는 조건부 확률 밀도 함수를 계산하였다. 14개 특징중 F1이 가장 낮은 오분류 확률을 보여주고 있으며 F9와 F6이 가장 높은 오분류 확률을 보여주고 있다.

또한 Table 2에 14개 특징들간에 존재하는 상호 의존성 척도인 상관 계수  $r$ 값을 나타내었다. 상관 계수  $r$ 를 식(5)에 의하여 결정하기 위해서는 특징값  $X_i, Y_i$ 를 알아야 하는데, 이 값들은 각 학습 표본으로 사용한 초음파 결합 신호로부터 초음파 특징 추출 프로그램을 통해 결정하였다. F2와 F7, F4와 F8, F6과 F9 사이에  $|r|$  값이 0.9가 넘는 높은 상호 의존성이 있으며, F11과 F12를 비롯한 12개 쌍의  $|r|$  값이 0.7이 넘는 상호의존성을 가지고 있어 본 연구에서 정의한 특징들 사이에는 공선성이 존재함을 알 수 있다. 따라서, 이러한 상호 의존 관계와 결합 구분 능력을 동시에 고려하면서 가장 적합하다고 생각되는 특징들을 선정하여 결합 분류를 실시하는 것이 통상적인 방법이다.

그러나 다행히도 PNN은 학습의 신속성 때문에 그 자체적으로 특징들의 민감도를 평가할 수 있는 능력이 있다. 즉, 단일 특징에 의한 오류 확률  $e$ 를 최소화하는 특징 F1를 단일 특징중 최선의 특징으로 선택하고, 나머지 F2부터 F14까지 13개 특징을 하나씩 취하여 2개의 특징으로 구성된 13쌍(F1과  $F_j, j = 2, \dots, 14$ )의 특징군을 가지고 결합 분류를 시행한다. 그 결과 최대 결합 분류 성능을 보여주는 특징인 F7을 택하여, F1과 F7의 2개를 최적 특징으로 선택하였다. 그 다음에는 F1과 F7의 특징군에 첨가할 세번째 특징을 나머지 12개의 특징(F2 ~ F6, F8 ~ F14) 중에서 같은 방법으로 결합 분류 성능이 최대가 되도록 선택하였다. 이러한 전방 선택 방법<sup>19)</sup>을 14개의 특징에 대해서 모두 수행한 결과를 Fig. 5에 나타내었는데, 이때 전체적인 결합 분류 성능을 나타내는 지수로써 성능 지수(Performance Index; PI)를 식 (13)과 같이 정의하여 사용하였다.

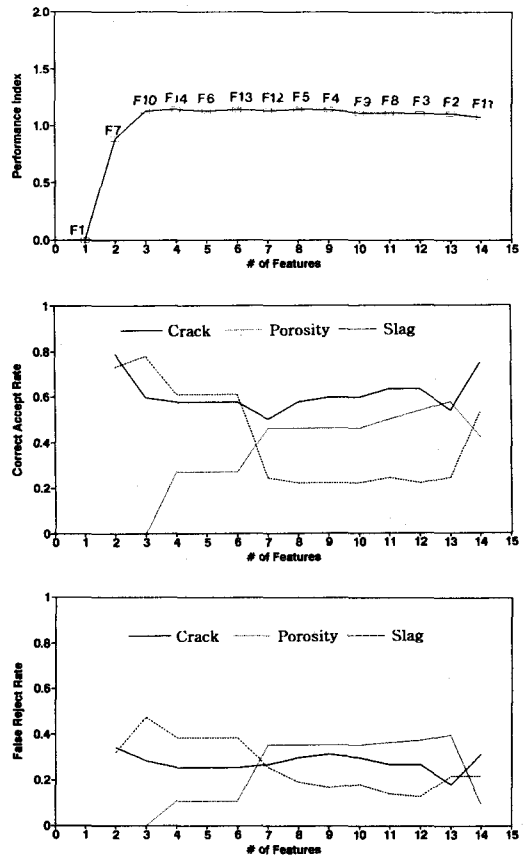


Fig. 5. (a) Performance index, (b) Correct accept rates, and (c) False reject rates by PNN for different choices of the number of features.t

$$PI = \sum_{i=1}^3 (CA)_i - \sum_{i=1}^3 (FR)_i \dots \dots \dots (11)$$

Fig. 5에 보인 바와 같이 전방 선택법을 통해 선택한 4개의 특징은 F1, F7, F10, F11인데, 이들은 Table 1에 보인 것과 같이 본 연구에서 사용한 14개의 특징들을 성격에 따라 4개의 세부 그룹으로 분류했을 때, 각 세부 그룹을 대표하는 특징들임을 알 수 있다.

특징 수가 5개보다 많아지면  $(CA)_i$ 와  $(FR)_i$ 는 다소간 변화가 있으나, 전체적인 성능지수 PI가 크게 변하지 않음을 알 수 있는데, 이것은 Table 2에 보인 것처럼 각 특징간에 존재하는 공선성 때문에 특징의 수를 증가시켜도 성능 향상에 크게 기여하지

않는 것으로 판단된다.

## 5. 결론

본 연구에서는 초음파 형상 인식 기법을 용접 결함의 종류 판별에 이용하는 체계적 접근 방법을 제시하였다. 초음파 형상 인식은 초음파 탐촉자에서 얻은 결함 신호로부터의 특징 추출, 결함 분류의 효율성 제고를 위한 특징 선택, 그리고 효율적인 결함 분류기의 선정 등이 중점 과제가 된다. 특히 본 연구에서는 결함 분류기로서 PNN의 적용에 대해 집중적으로 논의하였는데, PNN은 매우 쉽게 구성할 수 있을 뿐 아니라, 학습도 순간적으로 완료할 수 있으며, 또한 내부적으로 표본으로부터 확률 밀도 함수를 도출해내고 결함 분류에 Bayes 법칙을 적용하는 장점을 가지고 있다. 본 연구를 통해서 PNN은 매우 실용적인 분류기임이 입증되었다.

본 연구에서는 또한 결함 분류에 효율적인 특징들을 어떻게 선택할 것인가에 대한 체계적인 접근 방법을 제시하였다. 민감한 특징은 결함 구분 능력이 우수하면서 동시에 다른 특징들과의 상호 의존성이 없어야 하는데 결함 구분 능력은 오류 확률로, 상호 의존성은 상관 관계에 의해 정량적으로 평가될 수 있음을 보였다. 또한 PNN의 학습 기간이 매우 짧은 독특한 장점 때문에 PNN을 전방 선택법에 의한 특징 선택에 직접 활용할 수 있음을 보였다. 이상의 연구 결과에서 살펴본 바와 같이 PNN의 사용과 함께 특징선택 기법을 적절히 결합한다면 초음파 형상 인식 기법은 용접 결함 분류의 여러가지 실질적인 문제를 해결할 수 있는 좋은 방법이 될 수 있다고 판단된다.

## 참고 문헌

- 1) International Institute of Welding, The Evaluation of Ultrasonic Signals, Welding Institute for International Institute of Welding, Cambridge, England, (1987).
- 2) International Institute of Welding, Handbook on the Ultrasonic Examination of Welds, Welding Institute for International Institute of Welding, Cambridge, England, (1977).
- 3) V. G. Shcherbinskii and V. E. Belyi, "New informative index for the nature of flaws in ultrasonic inspection," Soviet Journal of Nondestructive Testing, Vol. 11 (1975), pp. 279-288.
- 4) G. J. Gruber, "Defect identification and sizing by the ultrasonic satellite-pulse technique," Journal of Nondestructive Evaluation, Vol. 1 (1980), pp. 263-273.
- 5) C. P. Chiou and L. W. Schmerr, "A quasi-pulse-echo technique for ultrasonic flaw classification," Ultrasonics, Vol. 29 (1991), pp. 471-481.
- 6) D. W. Fitting and L. Adler, Ultrasonic Spectral Analysis for Nondestructive Evaluation, Plenum Press, New York, (1981).
- 7) J. L. Rose, "Elements of a feature-based ultrasonic inspection system," Materials Evaluation, Vol. 42 (1984), pp. 210-218.
- 8) S. F. Burch and N. K. Bealing, "A physical approach to the automated ultrasonic characterization of buried weld defects in ferritic steel," NDT International, Vol. 19 (1986), pp. 145-152.
- 9) 심철무, 주영상, 홍순신, 장기옥, "형상 인식을 이용한 압력 용기 용접부 결함 특성 분류," 비파괴 검사학회지, 제13권 제2호, (1993), pp. 11-18.
- 10) M. F. Whalen and A. N. Mucciardi, "Inversion of physically recorded ultrasonic waveforms using adaptive learning network models trained on theoretical data," in Proc. ARPA/ AFML Review of Progress in Quantitative NDE, ed. D. O. Thompson, Air Force Materials Laboratory Technical Report AFML-TR-78-205 (1979), pp. 341-367.
- 11) L. S. Koo, Ultrasonic flaw classification: an approach using modelling, signal processing, and adaptive learning, Ph.D. Dissertation, Iowa State University, (1987).
- 12) L. W. Schmerr, K. E. Christensen, S. M. Nugen,

- L.-S. Koo and C.-P. Chiou, "Ultrasonic flaw classification - an expert system approach," in Review of Progress in Quantitative Nondestructive Evaluation, Vol. 8A, eds. D. O. Thompson and D. E. Chimenti, pp. 657-664, Plenum Press New York, (1989).
- 13) L. M. Brown and R. DeNale, "Classification of ultrasonic defect signatures using an artificial neural network," in Review of Progress in Quantitative Nondestructive Evaluation, Vol. 10A, eds. D. O. Thompson and D. E. Chimenti, pp. 705-712, Plenum Press, New York, (1990).
- 14) S. J. Song and L. W. Schmerr, "Ultrasonic flaw classification in weldments using probabilistic neural networks," Journal of Nondestructive Evaluation, Vol. 11 (1992), pp. 69-77.
- 15) C. W. Therrien, Decision, Estimation and Classification, John Wiley, New York, (1989).
- 16) J. -M. Durocher, D. R. Hay, R. W. Y. Chan, and J. R. Matthews, "Applications of Waveform and Image Pattern Recognition," in Pattern Recognition and Image Processing in Physics, ed. R.A. Vaughan, pp. 247-256, Adam-Hilger, Bristol, (1991).
- 17) J. T. Tou and R. C. Gonzalez, Pattern Recognition Principles, Addison-Wesley, Reading, MA, (1974).
- 18) J. Kittler, A. Etemadi and N. Choakjarearnwanit, "Feature Selection and Extraction in Pattern Recognition," in Pattern Recognition and Image Processing in Physics, ed. R.A. Vaughan, pp. 81-100, Adam-Hilger, Bristol, (1991).
- 19) Lincoln L. Chao, Statistics: Methods and Analyses, 2nd Ed, McGraw-Hill Kogakusa, Tokyo, (1974).
- 20) R. O. Duda and P. E. Hart, Pattern Classification and Scene Analysis, John Wiley & Sons, New York, (1973).
- 21) D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning internal representations by error propagation", in Parallel Distributed Processing, Vol. 1, eds. D. E. Rumelhart, J. L. McClelland, and the PDP Research Group, pp. 318-362, MIT Press, Cambridge, (1986).
- 22) D. F. Specht, "Probabilistic neural networks for classification, mapping, or associative memory," Proceedings of the IEEE International Conference on Neural Networks, Vol. 1 (1988), pp. 525-532.
- 23) D. F. Specht, "Enhancements to Probabilistic neural networks," Proceedings of the IEEE International Joint Conference on Neural Networks, Vol. 1 (1992), pp. 761-768.

## An Ultrasonic Pattern Recognition Approach to Welding Defect Classification

Sung-Jin Song

Department of Mechanical Design Engineering

Chosun University

**Abstract** Classification of flaws in weldments from their ultrasonic scattering signals is very important in quantitative nondestructive evaluation. This problem is ideally suited to a modern ultrasonic pattern recognition technique. Here brief discussion on systematic approach to this methodology is presented including ultrasonic feature extraction, feature selection and classification. A stronger emphasis is placed on probabilistic neural networks as efficient classifiers for many practical classification problems. In an example probabilistic neural networks are applied to classify flaws in weldments into 3 classes such as cracks, porosity and slag inclusions. Probabilistic nets are shown to be able to exhibit high performance of other classifiers without any training time overhead. In addition, forward selection scheme for sensitive features is addressed to enhance network performance.

---

*Received: March 15, 1995.*