

용접 결함 종류 판별을 위한 지능형 초음파 신호 분류 소프트웨어의 개발

김학준*, 송성진**, 정희돈***

* 조선대학교 대학원 기계설계공학과

** 조선대학교 기계설계공학과

*** 포항산업과학연구원 설비기술연구팀

요 약 용접 결함에 대한 초음파탐상시험으로부터 결함의 종류를 결정하는 것은 초음파형상인식기법에 의해 가장 잘 해결할 수 있기 때문에 지금까지 이 기법에 대한 연구가 많이 수행되어 왔다. 그러나 이 기법은 지금까지의 많은 연구에도 불구하고, 실제 산업 현장에서는 아직까지 널리 사용되지 못하고 있는 실정이다. 이러한 문제를 해결하기 위해 본 연구에서는, 용접 결함으로부터 초음파 신호를 채취하여 입력하면 적절한 신호처리를 통해 신호의 특징을 추출하고 신경회로망 등 다양한 인공지능기법을 적용하여 용접 결함의 종류를 자동적으로 판별하는 지능형 초음파 신호 분류 소프트웨어를 개발하였다. 그리고 개발된 분류기를 이용하여 용접부내에 존재하는 용접 결함을 균열(crack)과 비균열(non-crack)으로 분류하는 문제에 적용함으로써, 산업 현장에서 쉽게 이용할 수 있는 실제적인 분류기로서의 가능성을 검증하였다.

1. 서 론

철강 플랜트 및 원자력발전 플랜트 등 첨단 플랜트와 기계적 구조물은 용접이나 기타 조립 방법에 의해 결합된 복합구조물이다. 최근 최적설계기법의 발달은 이들 구조물의 경량화, 고기능화를 지향하고 있는데, 이에 따라 구조물의 내구성, 안전성 문제의 중요성이 부각되고 있다. 특히 용접부는 여러 가지 결함의 발생 가능성이 매우 높고, 또한 미세조직의 불균일성 때문에 반복하중이나 충격하중에 매우 취약하다. 특히 용접부에 존재하는 결함중 피로균열을 포함한 균열성 결함은 용접부의 기계적 강도에 치명적 영향을 미치기 때문에 용접부에 존재하는 결함(특히 균열)을 검출해내고 그 영향을 정량적으로 평가하는 것이 용접부 성

능 보장을 위해 필수적인 과제이다. 잘 알려진 바대로 용접 결함의 영향 평가는 파괴역학적 접근이 주로 사용되고 있는데, 이를 위해 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.

초음파시험은 결함의 위치 검출에는 대단히 효율적인 방법이지만, 결함의 종류·형상·크기 등 정량적 정보를 결정하는데는 아직도 신뢰도가 낮기 때문에, 초음파시험에 의한 용접 결함의 종류 판별 및 크기 산정이 비파괴시험 분야의 중요한 연구 과제의 하나가 되어 왔으며, 특히 결함의 종류 판별은 정량적 결함 평가의 첫번째 단계로서 그 중요성이 깊이 인식되어 이

에 대한 많은 연구가 진행중이다.

현재 산업 현장에서 사용되는 재래식 초음파시험에서 결함의 종류 판별은 작업자가 초음파 탐촉자를 결합 주위로 움직일 때 나타나는 에코동패턴(echo-dynamic pattern)^{1, 2)}의 변화를 이용하여 실시한다. 그러나 이 작업은 작업자의 경험과 지식에 크게 좌우될 뿐 아니라, 많은 경우 실제적인 문제를 해결하는데 미흡한 점이 대단히 많다. 이러한 문제를 해결하기 위해 초음파시험에서 얻은 결합 신호의 진폭을 이론적 예측치와 비교함으로써 정량적인 결합 분류를 실시하는 기법들과 결합 신호의 주파수 영역상의 특징들을 사용하여 결합을 분류하는 기법들이 개발된 바 있다^{3~6)}.

이러한 연구들은 초음파 결합 신호에서 결함의 종류를 판별하는데 핵심적인 역할을 하는 “강한 특징(strong features)”을 추출해 내고 이를 활용하는 것을 전제로 하고 있다. 그러나 불행히도 대부분의 실제적인 문제들은 이렇게 단순한 기법으로 해결할 수 없는 경우가 대부분이기 때문에, 이러한 복잡한 문제의 해결을 위해 “초음파형상인식(ultrasonic pattern recognition)”에 대한 연구가 수행되었다. 초음파형상인식 기법은 1) 결합 신호를 채취하고 2) 결합 신호로부터 신호의 특징을 추출하여, 3) 이를 기초로 적절한 의사결정 알고리즘에 의해 결합을 분류하는 세 가지 단계로 구성되어 있는데, 이에 관한 초기 연구에서는 통계적 분류기가 많이 사용되었으며^{7, 8)}, 그 이후 인공지능 기법을 활용한 연구가 활발히 수행된 바 있다^{9~11)}.

최근에 들어 신경회로망(neural networks)을 이용하려는 연구도 또한 수행되고 있다. 신경회로망은 인간 두뇌의 구조와 작동 원리를 모형화할 수 있다는 독특한 장점때문에 최근 이를 활용하는 연구가 급증하고 있다. 신경회로망은 단순한 처리 요소(processing elements)들이 서로 대단히 밀접하게 연결되어 있는 구조를 지니고 있는데, 이 단순 처리 요소들이 외란에 대해 동시에 반응하면서 매우 빠른 속도로 데이터를 처리한다. 또한 신경회로망은 입력층에 제시된 학습 표본을 통해 입력과 출력사이의 연관관계를 추론할 수 있을 뿐 아니라, 한번 학습이 완료되면 새로운 표본이 제시될 때 그 표본에 대한 결과를 매우 신속히 구할 수 있다¹²⁾. 특히 역전파 알고리즘(back-propagation algorithm)이 제안된 후¹³⁾, 여러 분야에서 그 응용이 더욱 널리 확산되고 있는데, 비파괴평가분야에서도 신경회로망의 활용이 지속적으로 확대되고 있다. 특히 비파괴평가분야에서 역전파 신경회로망(back-propagation neural networks;

BPNN)은 여러가지 결합 분류와 크기 산정 문제에 적용된 바 있다¹⁴⁾. 그러나 이 BPNN은 몇가지 중대한 단점을 가지고 있기 때문에 아직까지 적용상에 많은 문제를 내포하고 있다.

다행히도 신경회로망이 가지고 있는 여러가지 장점을 모두 갖추고 있으면서도 BPNN이 가지고 있는 대표적인 단점을 가지지 않는 새로운 신경회로망이 Specht에 의해 제안된 바 있는데, 이 신경회로망이 곧 확률신경회로망(probabilistic neural network; PNN)이다^{15, 16)}. 비파괴평가분야에서는 Song과 Scherrer가 PNN을 결합분류기로 활용한 바 있으며¹⁷⁾, 최근에 Song이 PNN을 적용하는데 수반되는 특징추출, 특징 선택, 결합 분류의 세부 과정을 자세히 논의한 바 있다¹⁸⁾.

그러나 이러한 결합분류기법들의 개발에도 불구하고, 실제 산업 현장에의 폭넓은 적용이 아직 이루어지지 않고 있는데, 그 이유는 초음파형상인식기법이 결합 신호의 채취에서부터, 신호 처리, 인공지능기법 등 다양한 분야의 지식을 복합적으로 요구하기 때문이다.

이러한 문제를 해결하기 위한 효율적인 방안중의 하나가 산업 현장에서 손쉽게 사용할 수 있는 지능형 프로그램의 개발이다. 이러한 관점에서 이강용과 김준섭¹⁹⁾은 초음파 신호형상 인식을 위한 intelligence package를 개발하였다.

이 프로그램은 초음파 결합 신호에 대한 디지털 신호처리, 특징 변수 추출, 특징 변수의 선택, 분류기에 의한 결합 분류 등의 과정을 일괄적으로 처리하는 프로그램인데, 이들은 이 프로그램을 이용하여 용접부내에 가공한 인공 결함(노치와 구멍)의 분류를 수행함으로써 그 적용성을 검증한 바 있다.

그러나, 이러한 지능형 결합 분류 프로그램을 실제 현장에 적용하기 위해서는 용접부에 실재하는 용접 결함(균열, 기공, 슬래그 혼입 등)을 분류할 수 있어야 한다. 따라서, 본 연구에서는 초음파형상인식기법의 현장 적용을 위해, 실제 산업 현장에서 채취한 용접 결함으로부터 초음파 신호를 입력하면, 적절한 신호 처리를 통해 신호의 특징을 추출하고 신경회로망 등 다양한 인공지능기법을 적용하여 용접 결함의 종류를 자동적으로 판별하는 지능형 초음파 신호 분류 소프트웨어를 종전의 연구 성과¹⁸⁾를 바탕으로 개발하였다. 그리고 개발된 분류기를 이용하여 용접부내에 실재하는 용접 결함인 균열(crack)과 비균열(non-crack)으로 분류하는 문제에 적용함으로써, 산업 현장에서 쉽게 이용할 수 있는 실제적인 분류기로서의 가능성을 검증하였다.

2. 초음파형상인식

여기에서는 본 연구에서 개발한 융접 결합의 종류 판별을 위한 지능형 신호 분류 소프트웨어에 적용한 초음파형상인식기법에 대해 간략히 논의하였다.

2.1. 형상인식

인간은 어떤 물체에 대해 그것의 특징을 파악하고 그를 기초로하여 그 물체가 어떠한 종류인지 인식하는 것을 매우 자연스럽게 행한다. 이러한 과정을 기계에 적용하여 어떤 물체의 특징을 추출하고 그것의 종류·특징을 파악하는 작업을 형상인식(pattern recognition)이라 한다²⁰⁾. 이러한 형상인식은 문자, 음성, 전기적 파형 또는 신호의 인식 등과 같은 분야 뿐만 아니라, 생산현장의 품질 검사나 자동제어 등에서도 널리 활용되고 있다.

형상인식은 감독형 형상인식(supervised pattern recognition)과 무감독형 형상인식 (unsupervised pattern recognition)으로 나눌 수 있는데, 만약 분류하고자 하는 패턴이 어느 범주에 속하는지 이미 알고 있다면 이는 감독형 형상인식의 문제이고, 분류하고자 하는 모든 패턴이 어느 범주에 속하는지 알지 못한다면 이러한 문제는 무감독형 형상인식의 문제이다. 감독형 형상인식기법은 추출된 패턴을 학습 표본(training samples)과 시험 표본(test samples)으로 분류하여, 학습 표본은 분류 알고리즘을 만드는데 이용하고, 나머지 시험 표본은 만들어낸 분류 알고리즘에 적용하여 그 분류기의 성능을 평가하는데 사용한다. 이에 반해 무감독형 형상인식은 패턴들의 범주가 어떤 종류의 것인지 알 수 없지만 유사한 특징을 갖는 패턴의 범주를 설정하고자 할 때 사용한다. 본 연구에서는 지금까지 실제적인 문제 해결을 위해 널리 사용되고 있는 감독형 형상인식기법을 사용하였는데, 이 기법의 기본적인 적용 절차를 Fig. 1에 나타내었다.




Fig. 1. The procedure in supervised pattern recognition

형상인식기법을 초음파 결합 분류에 적용하기 위해서는 초음파 탐촉자로부터 얻은 결합 신호로부터 특징을 추출하고, 추출된 특징으로부터 결합 분류에 적합한 특징을 선택하고, 이렇게 선택된 특징을 이용하여 결합 분류를 실시하는 알고리즘을 개발하는 과정으로 거쳐야 한다. 이 기법에 대해서는 참고문헌18)에 자세히 논의한 바 있으나, 여기에서는 논의의 연속성을 위해 각 과정을 간략히 서술코자 한다.

1) 특징 추출

형상인식기법에서 특징(feature)이란 일반적으로 같은 범주에 속하는 표본들이 지니고 있는 특성으로서 다른 범주와 구별할 수 있는 측정 함수를 의미한다. 특징 추출 단계는 초음파 탐촉자로부터 얻은 결합 신호로부터 유용한 형태의 특징을 도출해내는 과정으로서 분석 대상이 되는 패턴의 복잡성을 줄여서, 분류 알고리즘을 간단히 하고 동시에 분류 정확도를 향상 시키는데 그 목적이 있다. 이 과정에서 가장 중요한 문제는 과연 어떤 특징이 결합 분류에 유용한 특징이며, 그것을 어떻게 추출하느냐 하는 것인데, 사실상 이 문제가 결합 분석 정확도에 가장 큰 영향을 미치는 핵심 과제이다. 이러한 특징들은 이론적 모형이나 경험적인 결과를 바탕으로 보통 디지털 신호처리기법을 이용하여 도출한다.

2) 특징 선택

앞절에서 언급한 바와 같이 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 1) 결합 분석을 위해 충분한 정보를 가지고 있으며, 2) 물리적 시스템이 지니고 있는 종류간 이질성을 특징 공간에서도 일관성있게 유지해야 하고, 3) 사용자 하는 특징이 모든 표본에 대해서 일관성 있게 도출 가능해야 한다는 것 등이다. 그러나 이러한 정성적인 기준들은 실제 특징 선택 과정에서의 적용 기준으로는 분명하지 않기 때문에 보다 정량적인 특징 평가 기준이 필요하게 된다. 정량적인 평가기준을 설정할 때 보통 고려되는 조건으로는 결합 종류 구분 능력과 특징간의 독립성의 두 가지이다¹⁸⁾. 결합 종류 분류 능력은 특징의 결합 분류에의 효용성을 의미하며, 결합 분류시 발생하게 되는 오류확률로 정량화시키며, 특징간의 독립성은 특징의 중복성을 피하면서 특징의

숫자를 줄이는 것과 관계가 있는데, 보통 상관계수로 정량화 시킨다. 따라서 민감한 특징이란 오류확률이 낮 으면서 동시에 다른 특징과의 중복성이 낮은(상관계수 의 절대값이 작은) 특징을 의미하기 때문에, 특징 선택 이란 오류확률과 상관계수를 바탕으로 가장 적절한 특 징들을 선별해 나가는 과정을 말한다.

3) 분류

특징 추출과 특징 선택 과정을 통하여 민감한 특징 이 결정되면 이 특징을 이용하여 각 표본을 가장 적합 하다고 판단되는 범주로 분류하게 되는데 이러한 과정 을 수행하는 것을 분류기라 한다. 분류기는 적절한 분 류 알고리즘을 사용한다.

지금까지 개발된 분류기들은 크게 통계적 분류기 (statistical classifier), 법칙근거 분류기(rule-based classifier), 학습근거 분류기(learning-based classifier) 등이 있다. 통계적 분류기는 각 범주별 특징값들의 통계적인 접근을 통하여 분류하는 기법으로서, Fisher 의 선형판별함수(linear discriminant function), 최근거리 분류기(minimum distance classifier), K-nearest neighbor 분류기, Bayesian 분류기 등이 있다²¹⁾. 법칙근 거 분류기는 학습 표본에 대한 특징값의 분포를 살펴 보고 어떤 특정 범주에 속한 특징값의 분포를 가장 적 절히 표현하는 “분포 범위의 상·하한값(descriptor entries; 이하 분포 범위값)”을 설정하고, 이를 IF~ THEN 법칙에 적용하여 분류하는 방법으로서, 분류표 분류기(classification table classifier), 퍼지 분류기 (fuzzy classifier) 등이 있다. 학습근거 분류기는 대표 적으로 신경회로망 분류기를 생각할 수 있다. 20여가 지의 신경회로망 분류기중에서 가장 널리 사용되는 것 은 BPNN이다.

그러나 BPNN은 입력과 출력 사이의 관계가 사용자 에게 불투명하고, 어떤 경우에는 학습 시간이 너무 길 기 때문에, 모든 문제에 대해 보편성 있는 분류기로 사 용되기에는 아직도 문제점이 많은 상태이다. 이에 반 해 PNN은 신경회로망이 가지고 있는 병렬 처리 등 여 러 가지 장점을 가지고 있으면서도, 결합 분류시 Bayesian 방법을 적용시킬 수 있는 독특한 장점때문에 특히 형상분류분야에서 널리 사용되고 있다.

위와 같은 분류기중 본 연구에서는 지능형 결합 분 류 소프트웨어의 개발을 위해 “분류표 분류기 (classification table classifier; 이하 CT),” “강화 분류 표 분류기(enhanced classification table classifier;

이하 ECT),” 그리고 “확률신경회로망 분류기 (probabilistic neural network classifier; 이하 PNN)” 을 사용하였다. 다음에 각 분류기에 대해 간략히 소개 한다.

2.2. 분류표 분류기 (classification table classifier)

분류표란 모든 종류의 결합에 대한 특징값의 분포 범위를 각 결합 종류별로 미리 설정해 놓은 표를 가리 킨다. 분류표에 의한 분류란 어떤 결합(X)이 검출되면, 그 결합의 신호로부터 추출한 모든 특징값들($X_i, i=1, n$)이 분류표상의 어떤 종류의 분포 범위값(descriptor entries; $\alpha_i, \beta_i, i=0, \dots, n$)내에 속하는지를 판단하고 이를 IF~THEN 법칙으로 연결하여, 모든 특징값들이 포함되는 분포 범위를 갖는 결합 종류(Class A)로 검 출 결합(X)을 분류함을 말한다. 예를 들어 범주 A에 대해 특징 F_i 의 분포범위값이 α_i, β_i 라 주어져 있을때 검출 결합 X에 대해 다음과 같은 법칙을 이용하여 결 합 분류를 실시한다.

$$\begin{aligned} & \text{IF}((\alpha_1 \leq X_1 \leq \beta_1) \text{ AND } (\alpha_2 \leq X_2 \leq \beta_2) \text{ AND} \\ & \quad \vdots \\ & \quad \vdots \\ & \text{AND}(\alpha_n \leq X_n \leq \beta_n)) \text{ THEN} \\ & \text{Classify X to Class A} \end{aligned}$$

이 방법을 적용하기 위해서는 결합 종류별 특징별 분포범위값 α_i 와 β_i 을 미리 설정해야 한다. 이러한 값 을 적절히 설정하기 위해서는 학습 표본으로부터 모든 결합 종류별 특징값의 분포에 대한 통계적 분석이 필 요하다. 만약 이 과정이 수작업으로 이루어진다면 매 우 많은 인력과 시간이 소요될 뿐만 아니라 분포범위 값을 힘들어 설정한 후에도 실제적인 결합 분류의 정 확도가 매우 낮게 된다. 따라서 분류표 분류기의 효율 적인 사용을 위해서는 이 값의 설정 작업을 자동적으 로 수행할 수 있는 기법을 채택하는 것이 바람직하다.

2.3. 강화 분류표 분류기 (Enhanced Classification Table Classifier)

앞에서 언급한 분류표 분류기는 검출한 결합(X)으 로부터 추출한 특징 X_i 에 대해 IF~THEN 법칙의 논 리곱(AND 결합)으로 되어 있어, 결합 특징의 분포가

분산되어 있는 경우에는 그 성능이 급격히 저하될 우려가 있다. 이러한 단점을 보완하기 위해 “강화 분류표 분류기(Enhanced Classification Table: ECT)”를 제안하였다^{22, 23)}. 이 분류기는 시험 표본(X)로부터 추출한 n개의 특징값 $X_i(i=1, n)$ 를 추출하고 이 특징값들이 모든 결합 종류(m개)의 분포 범위 내에 속하는지를 확인한다. 그리고 분포 범위 내에 속한 특징의 수를 계수하여 m개의 결합 종류에 대한 m개의 $W_j(j=1, m)$ 값을 결정하고, 이 중에서 최대의 W_j 를 갖는 결합 종류로 검출 결합을 분류하는 기법이다. 즉 이 기법은 검출된 결합과 각 결합 종류와의 유사성을 점수(W_j)로 평가하여 최대 점수 (최대 W_j)를 획득한 결합 종류로 검출결합을 분류하는 방법으로, 분류 알고리즘은 다음과 같다.

```

For J = 1 To m
  Wj = 0
  IF (α1 ≤ X1 ≤ β1) THEN Wj = Wj + 1
  IF (α2 ≤ X2 ≤ β2) THEN Wj = Wj + 1
  .
  .
  IF (αn ≤ Xn ≤ βn) THEN Wj = Wj + 1

If Wk is the Maximum of Wj(j = 1, m) Then
  Classify X to Class K
    
```

이 강화 분류표 분류기도 역시 결합 종류별 특징별 분포범위값 α_i, β_i 가 필요한데, 이 값들은 분류표 분류기에서와 동일한 방법으로 결정한다.

2.4 확률신경회로망 (probabilistic neural networks)

PNN은 병렬처리 능력 등 신경회로망이 가지고 있는 여러 가지 장점과 함께, 패턴 분류시 Bayesian 기법을 적용시킨다는 독특한 장점때문에 형상 분류 문제에 광범위하게 적용되고 있다. PNN에 대해서는 참고문헌 18)과 22)에 자세히 소개되어 있으나, 여기에서는 논의의 연속성을 위해 간략히 서술한다.

Fig. 2에 PNN의 기본적인 구조를 나타내었다. Fig. 2에 나타난 바와 같이 PNN은 4개의 층(layer)으로 구성되어 있다. 첫째 층은 입력층으로서 여기들 통해 각 표본의 특징 벡터(X_i)가 PNN에 공급된다. 두번째 층은 패턴층으로서 입력층에 공급된 표본의 특징값 X_i 에 가

중치 W_{ij} 를 곱한 결과들의 합을 받아들여, 그 값에 지수함수를 적용한 값을 출력시킨다. 세번째 층은 합산층으로서, 합산층의 각 노드(node)들은 패턴층의 노드들 중 자신과 같은 범주에 속한 노드들에만 연결되어 있는데, 연결된 패턴층 노드들의 출력의 합을 입력으로 받아들인 후 여기에 사용자가 정의한 파라미터인 C_k 를 곱하여 그 결과를 출력시킨다. 마지막으로 네번째 층은 출력층으로서 최종적인 출력이 결합 분류 과정에 사용된다. 다른 종류의 신경회로망과는 달리, PNN의 구조는 주어진 문제가 가지고 있는 결합 종류의 수와 학습 과정에서 사용된 학습 표본의 수에 의해 결정된다. 즉 출력층과 합산층의 노드의 수는 결합 종류(즉 범주)의 수와 같고, 패턴층의 노드수는 학습 표본의 수와 일치하며, 입력층의 노드수는 특징벡터의 특징수와 동일하다.

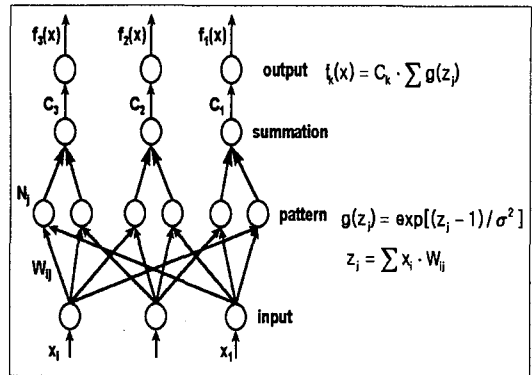


Fig. 2. Probabilistic neural network architecture

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

학습 과정에서 특징적인 것은 가중치 W_{ij} 가 반복 과정이 없이 단번에 결정된다는 것이며, 따라서 학습도 “순간적”으로 완료된다는 점이다. 또한 이 학습과정에서 PNN은 학습 표본으로부터 Parzen window 방법²¹⁾을 통해 각 범주별 확률밀도함수를 계산한다는 점이다.

일단 회로망의 훈련이 끝나면 사용자 정의 파라메터인 C_i ($i=1, 2, 3$)와 평활화계수 σ 를 선택해야 한다. C_i 는

$$C_i = \frac{h_i l_i}{n_i} \dots\dots\dots (1)$$

로 정의된다. 여기에서 h_i 는 i 번째 범주의 사전확률, l_i 는 손실계수, n_i 는 i 번째 범주내의 학습 표본의 수이다. 따라서 사용자가 균열과 같은 어떤 특정 범주에 더 큰 비중을 두고 싶을 때에는 손실계수 l_i 에 큰 값을 지정할 수 있다. 평활화계수 σ 는 패턴층내에 있는 각 패턴들의 개별적인 중요도를 조절하는 계수로서 σ 값을 작게 하면 개개의 패턴에 대한 중요성을 강조하게 되고, σ 값을 크게하면 많은 패턴들의 평균적인 거동을 강조하게 된다. 그리고 이 값은 어떤 이론적 근거로부터 결정된 다기보다는 다분히 실용적 관점에서 비교적 "양호한" 결합 분류 성능을 얻을 수 있는 σ 값을 찾아 사용하고 있다.

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

3. 지능형 초음파 신호 분류 소프트웨어

여기에서는 본 연구에서 개발한 지능형 초음파 신호 분류 소프트웨어(이하 지능형 분류 소프트웨어)에 대해 서술코자 한다. 이 소프트웨어는 Turbo-C 2.0을 이용하여 개발되었으며, DOS 환경하에서 작동하는데, 가능한 모든 작업 과정을 풀다운 메뉴 방식과 그래픽 처리를 함으로써 사용자의 편의를 도모코자 하였다.

본 연구에서 개발한 소프트웨어는 크게 3가지 메뉴로 이루어져 있는데, 첫번째 메뉴는, oscilloscope에서 저장한 결합신호를 PC용으로 전환하는 "file conversion"이다. 이 부분은 초음파탐상기를 통해 채취한 결합 data를 Lecroy oscilloscope를 통해 PC로 전송할 때 사용하기 위한 Lecroy사에서 제공하는 '93tran'이라는 프로그램을 접목시켜 작성하였다. 두번째 메뉴는, 채취한 결합 신호로부터 table 1에 나타낸 특징값을 추출하기 위한 "feature selection"이다. 이 부분은 저장한 결합 신호를 읽고, 이를 화면에 나타내는 "file

open", 읽어들이는 결합 신호의 잡음을 제거하여 결합 신호에 해당하는 부분만을 구하는 "noise elimination", time domain에서의 특징값을 추출하는 "T-feature", frequency domain에서의 특징값을 추출하는 "F-feature"로 구성되어 있다. 세번째 메뉴는, 두번째 메뉴에서 구한 특징값을 바탕으로 읽어들이는 결합 신호를 분류하는 부분으로서, CT, ECT, PNN의 세가지 분류기가 병렬적으로 결합 분류를 수행하고, 그 결과를 "최종 전문가 (final expert; FE) 분류기" 전달하면 FE가 최종적으로 분류 결과를 사용자에게 알려준다. Fig 3에 지능형 결합 분류 소프트웨어의 구성을 개괄적으로 나타내었는데, 각 구성 요소의 기능은 다음과 같다.

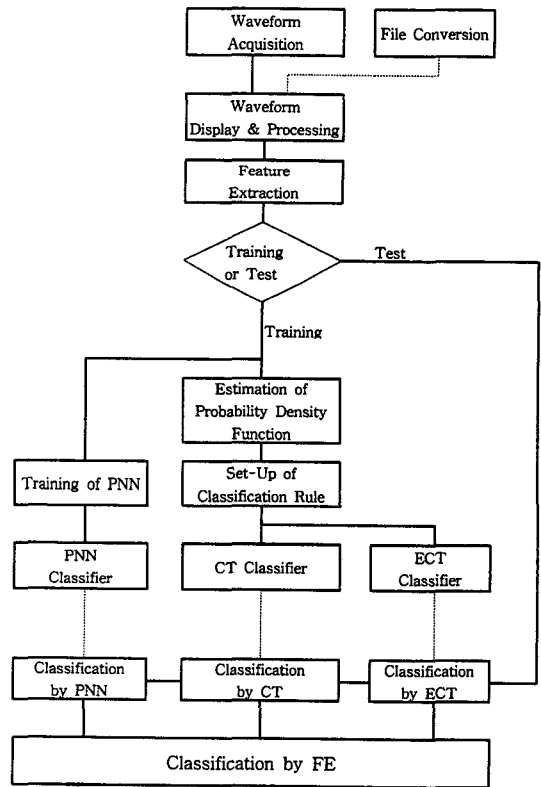


Fig. 3. Intelligent ultrasonic signature classification software

1) 파형 수집

결합에 대한 초음파 신호를 획득하고 이를 디지털 데이터로 변환시켜, 이를 PC에 전송하여 저장한다. 초음파탐상기에서 채취한 결합 신호를 A/D Board나 GPIB Port를 통해 PC에 전송할 경우에는 결합 데이터

를 ASCII 코드로 변환시킬 필요가 없으나, oscilloscope의 데이터 저장 장치를 사용할 경우에는 ASCII 코드로 저장되지 않는 경우가 많다. 따라서 이러한 경우의 파형 수집을 위하여는 oscilloscope를 통해 채취한 결합 신호를 '93tran(Lecroy사 제공)'을 이용하여 ASCII 코드로 변환시킬 수 있다. 본 연구에서 개발한 소프트웨어의 "file conversion" 부분은 이러한 작업을 자동적으로 수행하는 루틴이다.

2) 파형 표시 및 처리

저장된 초음파 신호를 CRT 모니터 상에 표시(display)하기 위해서는 pop-up pull down menu에서 결합 신호 데이터를 가지고 있는 화일명을 선택한다. 이렇게 하면 CRT에 초음파 결합 신호의 A-scan 파형이 나타난다. 보통 이 파형에는 잡음 성분이 많이 존재하기 때문에 이를 제거하기 위해 5점 이동 평균(5-pointing moving average)을 취한다. 잡음 성분이 제거된 파형이 다시 화면에 표시된다. 이 파형에 대해 적절한 문턱값을 설정하여 실제 결합 신호만을 분리하여 이를 화면에 표시한다.

3) 특징 추출

노이즈 성분이 제거된 실제 결합 신호로부터 시간 영역(time-domain)상에서 Table 1에 나타낸 10개의 특징을 추출하고, 추출한 특징값을 화면상의 파형 하단에 표시한다. 그리고, 시간 영역 신호에 대해 fast fourier transform을 적용하여 주파수 스펙트럼(frequency spectrum)을 구하고 화면에 표시한다. 여기에서 추가로 4개의 특징(Table 1 참조)을 추출하고 그 결과를 시간 영역의 경우와 마찬가지로 주파수 스펙트럼 하단에 표시한다.

Table 1. Features extracted from ultrasonic signatures

Time Domain Features
1) Number of signal groups
2) Pulse duration of the 1st group signal
3) Pulse duration of the 2nd group signal
4) Pulse duration of the 3rd group signal
5) energy of the 1st group signal
6) energy of the 2nd group signal
7) energy of the 3rd group signal
8) interval between the 1st and the 2nd groups
9) interval between the 2nd and the 3rd groups
10) antisymmetry of signal
Frequency Domain Features
11) number of maxima of the magnitude spectrum
12) number of minima of the magnitude spectrum
13) number of deep minima of the magnitude spectrum
14) number of shallow minima of the magnitude spectrum

4) 확률밀도함수 추정

CT와 ECT를 이용하여 신호를 분류하기 위해서는 결합 종류별 특징별 분포 범위값을 설정해야 하는데, 이 값은 확률밀도함수(probability density function; PDF)로부터 가장 합리적으로 설정할 수 있다. 학습 표본으로부터 결합 종류별 특징값의 확률밀도함수를 구하는 기법은 Parzen window 방법이다²¹⁾. 본 연구에서 개발한 지능형 소프트웨어는 3)에서 추출한 특징값에 대해 Parzen window 방법을 적용하여 확률밀도함수를 추정하고 그 결과를 화면상에 표시한다. 이 과정에서 확률밀도함수 추정에 필요한 평활화계수를 사용자가 임의로 선택할 수 있는데, 본 프로그램에서는 up/down 키를 이용하여 평활화계수를 변화시킬 수 있다. 전술한 바와 같이 평활화계수는 학습 표본들의 개별적인 중요도를 조절하는 계수로서 이 값을 작게 하면 개개의 학습 표본의 중요성을 강조하게 되고, 이 값을 크게 하면 많은 학습 표본들의 평균적인 거동을 강조하게 된다.

5) 분류표 분류기와 강화 분류표 분류기의 설정

4)에서 구한 결합 종류별 특징별 확률밀도함수의 분포도에서 최대값을 찾은 후, 이 최대값의 25%에 해당되는 값을 문턱선(threshold line)으로 취한다. 그리고 확률밀도함수의 최대점을 중심으로 PDF곡선과 이 문턱선이 교차하는 두 점에 해당하는 값을 분포 범위값 α_1 , β_1 로 설정한다. 이 분포범위값이 설정되면 이를 이용하여 CT와 ECT의 분류 범칙을 2.2와 2.3절의 방법대로 설정할 수 있다.

6) 확률신경회로망의 구축과 학습

주어진 신호 분류 문제를 해결하기 위한 PNN은 다음과 같이 구축하고 학습시킨다. 즉, 특징수와 동일한 수의 노드를 입력층에, 학습 표본의 수와 동일한 수의 노드를 패턴층에, 그리고 분류하고자 하는 범주수와 동일한 수의 노드를 합산층과 출력층에 설치함으로써 원하는 PNN을 구축한다. 이렇게 구성한 PNN에 학습 표본을 이용하여 회로망내의 가중치(weights)를 결정하여 PNN를 학습시킨다.

7) 신호 분류

주어진 시험 표본에 대해 CT, ECT, PNN을 이용하여 결합 분류를 각각 독립적으로 실시한다. 만약, 이 세 분류기의 분류 결과가 서로 다를 경우에는 사용자에게 혼란을 가져올 우려가 있으므로, 이 세 분류기의

분류 결과를 종합하여 최종적인 결과를 도출할 수 있도록 “최종 전문가 (final expert; FE) 분류기”을 구축하였다. FE는 지능형 결함 분류 소프트웨어에서 사용한 분류기준 가장 성능이 우수한 PNN의 분류 결과를 기준으로, CT와 ECT의 분류 결과를 고려하여 Fig. 4에 예시한 법칙에 따라 최종적인 분류 결과를 도출한다.

예를 들어 1) PNN은 균열이라고 분류하였을 때 CT와 ECT가 비균열이라고 분류하면, FE는 “maybe crack”이라 결정하고, 2) PNN은 균열이라 분류하였는데, CT 또는 ECT 중 하나는 균열이라 분류하고 다른 하나는 비균열이라 분류하면, FE는 “mostly crack”이라 결정하고, 3) CT, ECT, PNN 모두 균열이라고 분류하면, FE는 “definitely crack”이라 결정한다.

Classification Result			⇒	Classification Result
PNN	CT	ECT		by FE
C	C	C	⇒	Definitely Crack
C	C	N	⇒	Mostly Crack
C	N	C	⇒	
C	N	N	⇒	Maybe Crack

※ C : CRACK, N : NON-CRACK

Fig. 4. Classification rule for the final expert classifier

4. 지능형 분류기의 성능


본 연구에서 개발한 지능형 분류 소프트웨어의 성능을 평가하기 위해서 미국 Westinghouse사가 제작한 용접 시편내의 용접 결함으로부터 채취한 초음파 신호에 대한 결함 분류를 수행하였다.

4.1 초음파 신호의 수집

본 연구에서 사용한 용접 결함 시험편은 미국 Westinghouse사가 연구를 위해 특별히 제작한 것으로서 종류, 위치 그리고 대략적인 크기가 알려진 균열(피로균열)과 비균열(기공, 슬래그 혼입)의 용접 결함을 내포하고 있다(Fig. 5 참조).

균열은 피로시험을 통해 피로균열을 생성시킨 후 이를 시험편에 삽입하여 제작하였으며, 비균열은 용접 도중 부적절한 용접 조건을 사용하여 용접부에 기공, 슬래그 혼입의 용접 결함을 일부러 생성시켰다. 이 시험편 내에 있는 용접 결함으로부터 1.5MHz, 45° 사각 탐촉자를 사용하여 채취한 A-scan 협대역 초음파 결

함 신호를 25MHz A/D 보드(SONIX STR 825)를 통하여 디지털 데이터로 변환시켜 PC에 전송하였다. 이 시험편은 일반 강재로 된 시편 상부를 스테인레스강으로 약 0.6mm정도 클래딩(cladding)하였기 때문에, 이 시편에서 채취한 초음파 결함 신호는 매우 많은 노이즈 성분을 포함하고 있다.



Side view of the specimen

(unit : mm)					
Specimen #	Specimen size(L×M)	Flaw type	Distance from side (S)	distance from surface (d)	flaw size
I	875×274	Crack	34.544	9.662	19.05
		Crack	113.538	67.066	38.1
		Crack	192.532	134.112	19.05
		Crack	293.878	20.32	88.9
		Crack	406.654	33.528	38.1
		Crack	519.938	134.112	88.9
		Crack	728.472	134.112	88.9
II	870×234	Crack	82.55	33.528	38.1
		Crack	208.534	21.59	88.9
		Crack	311.912	136.906	19.05
		Crack	378.46	136.652	19.05
		Crack	456.692	68.351	38.1
		Crack	619.252	135.178	88.9
		Crack	757.482	66.294	38.1
III	1500×100	Porosity	150	125	22
		Porosity	350	125	11
		Porosity	550	125	5.5
		Porosity	150	30	22
		Porosity	350	30	11
		Porosity	550	30	5.5
		Slag Inclusion	150	125	22
		Slag Inclusion	350	125	11
		Slag Inclusion	550	125	5.5
		Slag Inclusion	150	30	22
		Slag Inclusion	350	30	11
		Slag Inclusion	550	30	5.5

Fig. 5. The specimen including welding defects


본 연구에서는 균열에서 104개, 비균열에서 135개, 총 239개의 결함 신호를 수집하여 이중 120개의 신호를 임의로 선택하여 학습 표본으로 하고, 나머지 119개를 시험 표본으로 사용하였다. 학습 표본은 이용하여 결함 신호 특징 추출, 확률밀도함수 추정, 분류표 분류기와 강화분류표 분류기의 설정, 신경회로망의 구축과 학습등에 사용하였으며, 시험 표본은 개발된 프로그램의 분류 성능 평가를 위해 사용하였다.

4.2. 파형 표시 및 처리


시험편내의 용접 결함으로부터 채취한 초음파 결함

신호중 균열, 기공, 슬래그 혼입에 대한 대표적인 파형을 본 연구에서 개발한 지능형 S/W를 이용하여 CRT 화면에 표시한 예를 Fig. 6에 나타내었다. 그리고, Fig. 7에는 Fig. 6(a)의 균열파형에 대해 신호 처리를 실시한 결과를 나타내었는데, Fig. 6에서 나타낸 균열 신호에


대해 5점 이동 평균을 취하여 잡음을 제거하였으며 (Fig. 7(a)), 적당한 문턱값을 취하여 결함 신호와 잡음 신호를 구분하고, 결함 신호만을 화면에 표시하였다 (Fig. 7(b)). 그리고 결함 신호에 대한 FFT를 수행하여 주파수 스펙트럼을 구하였다(Fig. 7(c)).




(a) Signal from a crack




(a) Signal from a crack after 5-point moving average




(b) Signal from a porosity



(b) Signal from a crack after thresholding



(c) Signal from a slag inclusion




(c) Frequency spectrum of a signal from a crack

Fig. 6. Display of ultrasonic signal from flaws in the specimen

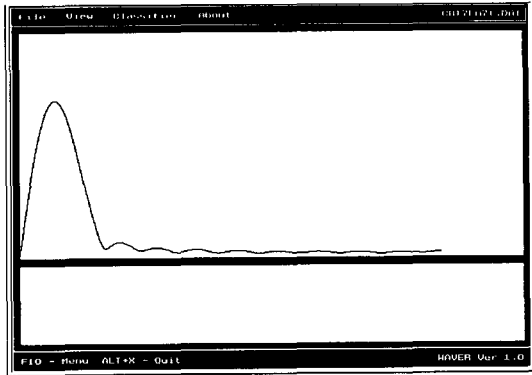
Fig. 7. Processing of an ultrasonic signal from a crack

4.3. 특징 추출

앞절에서 문턱값 처리를 수행한 시간 영역 초음파 신호와 이에 대한 주파수 스펙트럼으로부터 Table. 1에 언급한 초음파 특징들을 추출하였다. Fig. 6(a)에 나타난 균열 신호에 대한 특징 추출 결과를 Fig. 8에 나타내었다.




(a) Features extracted from time domain




(b) Features extracted from frequency domain
Fig. 8. Feature extraction from a crack signal

4.4. 확률밀도함수 추정


4.3절에서 언급한 방법대로 120개의 학습 표본에 대한 14개의 특징값을 모두 추출하고, 이를 바탕으로 결합 종류별 특징별 확률밀도함수를 Parzen window 기법을 적용하여 추정하였다. 이때 평활화계수는 0.02부터 0.3까지 0.02 간격으로 증가시키면서 사용자가 임의로 선택할 수 있다. Fig. 9에 이렇게 평활화계수 변화에 따른 확률밀도함수 추정 결과의 예(결합종류: 균열, 특징: 5번)를 나타내었다. Fig. 9에서 볼 수 있는 것과



a) Smoothing parameter : 0.02



b) Smoothing parameter : 0.05



c) Smoothing parameter : 0.1

Fig 9. Estimated probability density functions of "feature 5" for the crack

같이, 평활화계수값을 작게 취하면 개개의 학습 표본의 중요성을 부각시켜 폭이 좁고 굴곡이 심한 PDF가 구해지고 (Fig. 9(a)), 평활화계수값을 크게 할수록 학

습 표본의 전체적 거동을 중요시 한 폭이 넓고 부드러운 PDF가 구해짐을 알 수 있다(Fig. 9(c)). 이 중에서 어느 것이 과연 현실을 가장 잘 반영하는 PDF인가 하는 것은 전적으로 사용자의 전문적 지식과 경험에 달린 문제이지만, 실용적 관점에서 볼 때, 결함 분류의 성능을 높일 수 있는 PDF(즉 평활화계수)가 “좋은” PDF라 할 수 있을 것이다.

4.5. 분류표 분류기와 강화 분류표 분류기의 설정

특정 특징에 대한 결함 종류별 확률밀도함수가 구해지면 이로부터 특징의 분포 범위값을 결정할 수 있다. Fig. 9에 보인 바와 같이, PDF 최대값의 25%에 해당하는 문턱선을 설정하고, PDF 곡선이 이 문턱선과 교차하는 점을 분포 범위값으로 취한다. 이렇게 함으로써, 결함 종류별(균열과 비균열에 대한) 그리고 특징별(14 개의 모든 특징에 대한) 분포 범위값을 모두 결정하였다. 여기에서 유의해야 할 사항은 분포 범위값을 PDF 추정을 위한 평활화계수에 따라 달라진다는 점이다.

이상과 같이 결함 종류별 특징별 분포 범위값을 모두 결정하고, 이 값들을 2.2와 2.3절에 언급한 분류법칙에 대입하여 분류표 분류기와 강화분류표 분류기를 설정하였다.

4.6. PNN의 구축과 학습

본 연구에서는 용접 결함의 종류를 균열과 비균열의 2 가지로 구분하고, 이를 위해 120개의 학습 표본을 수집하여 각 학습 표본에서 14개의 특징들을 추출하였다. 따라서 이러한 문제를 해결하기 위해, 입력층에 14 개의 노드, 패턴층에 120개의 노드, 그리고 합산층과 출력층에 각각 2개의 노드를 갖는 PNN을 구축하였다. 그리고 120개의 학습 표본을 이용하여 PNN내의 가중치를 결정하여 학습을 완료하였다.

4.7. 분류기의 성능

본 연구에서 개발한 지능형 분류 소프트웨어의 성능을 평가하기 위해, 119개의 시험 표본를 이용하여 PNN, CT, ECT의 세가지 분류기를 통해 결함 분류를 실시했다.

전술한 바와 같이 CT와 ECT의 경우는 평활화계수의 선택에 따라 분류 법칙이 변화하고, PNN의 경우도 회로망 파라미터(범주별 손실계수와 평활화계수)를

사용자가 정의하기 때문에, 각 분류기의 성능이 평활화계수의 선택에 따라 달라진다. Fig. 10에 평활화계수의 변화(0.02부터 0.3까지 0.02 간격으로 증가시킴)에 따른 각 분류기별 분류 정확도의 변화를 나타내었다. Fig. 10에서 볼 수 있는 바와 같이, CT는 시험 표본의 특징값이 분류표상의 특징의 분포 범위안에 속하는 경우에만 결함 분류를 수행하기 때문에, 이 문제처럼 특징값의 분포에 산란이 심한 경우에는 그 성능이 급격히 저하함을 볼 수 있다. 또한 ECT는 CT보다는 향상된 결함 분류 성능을 보여 주고 있으나 PNN보다는 여전히 낮은 분류 성능을 보여주고 있다.




Fig. 10. Correct classification rates of classifiers

그리고 CT와 ECT는 평활화계수의 변화에 따라 분류 성능이 크게 변화하는 것을 볼 수 있다. 이에 반해, PNN은 (균열과 비균열에 대한 범주별 손실계수를 같게 취했을 때) 평활화계수의 변화에 관계없이 거의 일정하며, CT나 ECT에 비해 높은 분류 정확도를 나타내고 있다. 이것은 PNN이 평활화계수의 영향을 거의 받지 않는 매우 객관적인 분류기이며, 또한 유사한 형태

의 PDF를 갖는 아주 구별하기 힘든 결함도 구별해 내는 능력을 갖춘 우수한 분류기임을 말해주는 것이다.

사실 평활화계수는 모집단의 특징값들의 분포를 반영하는 인자이지만, 대부분의 경우 모집단의 특성을 알 수 없기 때문에, 평활화계수는 사용자가 임의로 정의하여 사용할 수 밖에 없는 실정이다. 어떤 분류기를 다양한 경우에 적용할 수 있기 위해서는, 분류기의 성능이 사용자가 임의로 선택한 변수에 대하여 될수록 "견실한(robust)" 성능을 가져야 할 것이다. 이러한 관점에서 볼 때, PNN이 CT나 ECT에 비해 매우 객관적이며 견실한 분류기임을 알 수 있다.

전술한 바대로, 본 연구에서 개발한 지능형 결함 분류 소프트웨어는 CT, ECT 그리고 PNN의 결함 분류 결과를 종합하여 최종적인 결론을 도출하는 최종 전문가(FE) 분류기가 내장되어 있다. Fig. 11은 평활화계수를 0.1로 취했을 때, CT, ECT, PNN 그리고 FE의 성능을 나타내었다. 이 결과를 보면, PNN의 성능은 FE의 성능과 거의 유사한 수준이지만 CT와 ECT는 상대적으로 낮은 분류 정확도를 나타내고 있다. FE는 crack의 경우 약 89%, non-crack은 약 68%의 분류 정확도를 보였고, PNN은 crack의 경우 약 86%, non-crack의 경우 약 63%의 분류정확도를 보였으며, ECT는 Crack 약 61%, non-crack 약 57%, CT는 crack 약 20%, non-crack 약 35%의 분류 정확도를 보이고 있다.




Fig. 11. Summary of correct classification rates of classifiers

5. 결론

본 연구에서는 산업 현장에서 초음파 형상인식기

법을 활용하여 용접 결함의 종류 판별 작업을 손쉽게 수행할 수 있도록 하기 위하여, 용접 결함으로부터 초음파 신호를 채취하여 입력하면 적절한 신호 처리를 통해 신호의 특징을 추출하고, 이를 바탕으로 결함 분류를 자동적으로 수행하는 지능형 초음파 신호 분류 소프트웨어를 개발하였다. 이 지능형 분류 소프트웨어는 범칙근거 분류기의 하나인 분류표 분류기(CT)와 이를 보완한 강화분류표 분류기(ECT), 그리고 신경회로망 분류기중에서 확률신경회로망 분류기(PNN)을 이용하여 결함을 분류하고, 그 결과를 종합하여 최종적인 결론을 도출하는 최종 전문가 분류기(FE)에 의해 결함을 분류한다.

본 연구에서 개발한 지능형 분류 소프트웨어를 용접 결함을 균열과 비균열로 구분하는 실제적인 용접 결함 분류 문제에 적용하였다.

이 문제에서 CT는 의한 시험 표본의 특징값이 분류 표상의 특징 분포 범위안에 속하는 경우에만 결함 분류를 수행하기 때문에 특징값의 분포에 산란이 심한 경우에는 그 성능이 급격히 저하함을 확인할 수 있었다. 이러한 단점을 보완하기 위해 개발한 ECT는 CT보다는 향상된 결함 분류 성능을 보여 주고 있으나 여전히 결함 종류별 특징의 확률밀도함수가 서로 겹치는 경우에는 분류 성능이 역시 저하하였다. 그리고 CT와 ECT는 평활화계수의 변화에 따라 분류 성능이 크게 변화하는 것을 볼 수 있었다.

이에 반해, PNN은 유사한 형태의 PDF를 갖는 아주 구별하기 힘든 결함도 구별해내는 능력이 있기 때문에, CT나 ECT에 비해 결함 분류 성능이 우수할 뿐만 아니라, 평활화계수의 영향도 거의 받지 않는 매우 객관적이고 견실한 분류기임을 확인할 수 있었다. 이 세 가지 분류기의 분류 결과를 종합한 FE의 경우, PNN과 매우 유사한 성능을 보여 주고 있다.

이러한 결과로부터 본 연구에서 개발한 지능형 분류 소프트웨어는 산업 현장에서 실제적인 용접 결함 분류 문제에 손쉽게 적용할 수 있는 매우 편리하고 우수한 결함 분류 도구를 확인할 수 있었다.

후 기

이 논문은 한국과학재단 지정 지역협력연구센터인 조선대학교 수송기계부품 공장자동화 연구센터의 연구비 지원에 의해 연구되었음.

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. Shcherbinski and V. E. Belyi, "New Information 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, New York, Plenum Press, (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) 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
- 10) L. S. Koo, Ultrasonic Flaw Classification, An Approach using Modelling, Signal Processing, and Adaptive Learning, Ph.D. Dissertation, Iowa State University, (1987)
- 11) 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 Non-destructive Evaluation, Vol. 8A, eds. D. O. Thompson and D. E. Chimenti, Plenum Press New York, (1989) pp. 657-664
- 12) D. E. Lippmann, "An Introduction to Computing with Neural Nets", IEEE ASSP Magazine(1987), pp. 4-22
- 13) 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, MIT Press, Cambridge, (1986) pp. 318-362
- 14) 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, Plenum Press, New York(1990), pp. 705-712
- 15) 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
- 16) D. F. Specht, "Enhancements to Probabilistic Neural Networks", Proceedings of the IEEE International Joint Conference on Neural Networks, Vol. 1(1992), pp. 761-768
- 17) 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
- 18) 송성진, "용접 결합 분류를 위한 초음파 형상인식 기법", 비파괴검사학회지, Vol. 15, No. 2(1995), pp. 395-405
- 19) 이강용, 김준섭, "UT 신호형상 인식을 위한 Intelligence Package 개발과 Austenitic Stain-

- less Steel Welding부 결함 분류에 관한 적용 연구”, 비파괴검사학회지, Vol. 15, No. 4(1995), pp. 531-539
- 20) C. W. Therrien, Decision Estimation and Classification, John Wiley, New York, (1989)
- 21) R. O. Duda and P. E. Hart, Pattern Classification and Scene Analysis, New York, John Wiley & Sons, (1973)
- 22) 김학준, “형상인식기법을 이용한 지능형 결함 분류기에 관한 연구”, 석사학위 논문, 조선대학교, (1997)
- 23) 송성진, 김학준, 최세호, 이종학, “확률신경회로망에 의한 냉연 강판 표면 결함의 분류”, 비파괴 검사학회 춘계학술발표회 논문초록집

Development of an Intelligent Ultrasonic Signature Classification Software for Discrimination of Flaws in Weldments

H. J. Kim,* S. J. Song** and H. D. Jeong***

* Dept. of Mechanical Design Eng. Graduate School, Chosun Univ. Kwangju, 501-759

** Dept. of Mechanical Design Eng. Chosun Univ. Kwangju, 501-759

*** Maintenance Technology Research Team, Research Institute of Industrial Science and Technology, Pohang, 790-330

Abstract Ultrasonic pattern recognition is the most effective approach to the problem of discriminating types of flaws in weldments based on ultrasonic flaw signals. In spite of significant progress in the research on this methodology, it has not been widely used in many practical ultrasonic inspections of weldments in industry. Hence, for the convenient application of this approach in many practical situations, we develop an intelligent ultrasonic signature classification software which can discriminate types of flaws in weldments based on their ultrasonic signals using various tools in artificial intelligence such as neural networks. This software shows the excellent performance in an experimental problem where flaws in weldments are classified into two categories of cracks and non-cracks. This performance demonstrates the high possibility of this software as a practical tool for ultrasonic flaw classification in weldments.