

형상인식기법을 이용한 비파괴적 결함 종류 판별

Nondestructive Flaw Classification by Pattern Recognition Approach

송 성 진*
 Sung-Jin Song*

1. 서 론

과학기술의 급속한 발달에 따라 각종 소재, 부품, 기계, 설비 그리고 시설의 고성능 다기능화가 가속화되고 있는데, 이러한 추세는 자원 이용 효율 극대화라는 이점과 함께 예기치 않은 파손 발생 가능성 증대라고 하는 새로운 위험을 동시에 가져왔다. 각종 설비나 시설에 발생한 예기치 않은 손상이 얼마나 엄청난 경제적 손실과 함께 사회적 충격을 주는가에 대해 우리는 지난 10여년 사이에 발생한 여러 가지 사고를 통해 익히 경험한 바 있다. 이러한 재난을 사전에 예방하고, 또한 날로 격화되고 있는 전 세계적 경제 전쟁에서 승리하기 위해 필요한 제품의 고품질화를 이루기 위한 핵심 수단으로서 비파괴평가(nondestructive evaluation)의 중요성이 날로 증대되고 있다.

잘 알고 있는 바와 같이, 비파괴평가는 결함의 검출과 함께 결함의 영향을 분석하고 이를 바탕으로 적절한 조치를 취하기 위해 반드시 필요한 정보인 위치, 종류, 크기 등을 정확히 결정하는, 이른바 정량적 결함평가(quantitative flaw characterization) 과정으로 이루어진다. 이 중에서 결함의 종류 판별(flaw classification)은 정량적 결함 평가의 첫 과정으로서, 결함 평가의 성패를 좌우할 뿐 아니라, 더 나아가서는 이를 바탕으로 취해지는 각종 조치의 적절성을 결정짓는 결정적 과정이다. 그러나, 이러한 중요성에도 불구하고 지금까지 산업 현장에서는 결함 종류 판별이 전적으로 검사자의 주관적 판단에 의존하였기 때문에 비파괴검사의 객관적 신뢰성을 저해하는 한 요인이 되었다.

이에 따라 이러한 문제를 해결하기 위해 부단한 연구

가 지금까지 수행되어 왔는데, 그 결과 가장 효율적인 방법으로 자리 매김 되어 가는 기술이 바로 "형상인식(pattern recognition)" 기법이다. 따라서, 본 고에서는 형상인식 기법의 정의, 적용 절차, 그리고 형상인식 기법 과정에서 중요한 역할을 하는 확률신경회로망에 대해 간략히 소개하고, 이러한 기법을 적용하여 비파괴적으로 결함 종류를 판별한 사례 3가지(냉연강판 표면결함 분류, 용접결함 분류, 증기발생기 세관결함 분류)를 필자의 연구 결과를 중심으로 소개코자 한다.

2. 형상인식기법

인간은 어떤 물체에 대해 그것의 특징을 파악하고 이를 기초로 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 한다[1-3]. 이러한 형상인식은 문자, 음성, 전기적 파형 또는 신호의 인식 등과 같은 분야뿐만 아니라, 생산현장의 품질검사나 자동제어 등에서도 널리 활용되고 있다.

형상인식은 supervised pattern recognition과 unsupervised pattern recognition으로 나눌 수 있는데, 만약 분류하고자 하는 패턴이 어느 범주에 속하는지 이미 알고 있다면 이는 supervised pattern recognition이고, 분류하고자 하는 모든 패턴이 어느 범주에 속하는지 알지 못하다면 이러한 문제는 unsupervised pattern recognition에 속한다. supervised pattern recognition 기법은 추출된 패턴

을 훈련표본(training set)과 시험표본(test set)으로 분류하여, 훈련표본은 분류(Classification) 알고리즘을 만드는데 이용하고, 나머지 시험표본은 만들어진 분류 알고리즘에 적용하여 그 분류기의 성능을 평가하는데 사용된다. 이에 반해 unsupervised pattern recognition은 pattern들의 범주가 어떤 종류의 것이지 알 수 없지만 유사한 특징을 같은 패턴의 범주를 분류하고자 할 때 사용할 수 있다. 예를 들어, 혼합물 또는 세포들의 분류를 실시 할 때 혼합물 중 어떤 종류의 혼합물인지 그 종류는 정확히 알 수 없으나 유사한 특징을 같은 형태의 물질만을 따로 분리할 수는 있다. 이러한 형상인식 기법 중 초음파 결합 종류 판별 문제해결을 위해 널리 사용되고 있는 supervised pattern recognition 기법의 기본적인 구조는 Fig. 1과 같다.

형상인식 기법을 결합분류에 적용하기 위해서는 센서에서 출력되는 결합 신호로부터 특징을 추출하고, 추출된 특징으로부터 결합 분류에 적합한 특징을 선택하고, 이렇게 선택된 특징을 이용하여 결합분류를 실시하는 알고리즘을 개발하는 과정으로 나누어 생각할 수 있는데, 여기에서는 각 과정에 대해 보다 자세히 논의코자 한다.

2. 1. 특징 추출 (Feature Extraction)

형상인식 기법에서 특징(feature)이란 일반적으로 같은 범주에 속하는 표본들이 지니고 있는 특성으로서 다른 범주와 구별 할 수 있는 측정 함수를 의미한다. 특징추출 단계는 센서로부터 얻어지는 결합신호로부터 유용한 형태의 특징을 도출해내는 과정으로서 분석대상이 되는 패턴의 복잡성을 줄여서, 분류 알고리즘을 간단히

하고 동시에 분류 정확도를 향상시키는데 그 목적이 있다. 만약 패턴 분류에 전혀 소용이 없는 특징만이 추출된다면 아무리 훌륭한 분류기를 사용해도 좋은 분류성능을 얻기 어렵다. 따라서 특징들 중에서 패턴 분류에 유용한 특징만을 추출하는 것이 매우 중요한 문제이면서도, 이러한 특징을 도출할 방법에 대한 일반적인 원칙은 없다. 왜냐하면 유용한 특징이란 application dependent한 것이기 때문에, 어떤 문제를 풀려고 하느냐에 따라 달라지기 때문이다. 유용한 특징을 찾기 위한 노력으로 지금까지 다양한 종류의 특징들이 정의되어 사용되었다. 초음파 결합 신호에서 결합 분류에 유용한 것으로 여겨지는 특징들은 Rose, Burch(4)와 Bealing(5), Durocher(2) 등이 제안한 바 있으며, 국내에서도 심철무(6) 등의 연구에서 정리된 바 있다. 이러한 특징들은 이론적 모형이나, 경험적인 결과들로부터 정의된 것들로서, 보통 디지털 신호처리 기법을 이용하여 도출하였다.

2. 2. 특징 선택 (Feature Selection)

특징추출 단계에서 도출된 특징이 모두 결합분류에 유용한 것이 아니므로, 그 중에서 결합분류에 유용한 특징인 "민감한 특징"만을 선택하는 과정을 특징선택 단계라 한다. 보통 민감한 특징이 지녀야 할 특성으로는 첫째, 결합분석을 위해 충분한 정보를 가지고 있으며, 둘째는 물리적 시스템이 지니고 있는 종류간 이질성을 특징 공간에서도 일관성 있게 유지해야하고, 셋째로는 사용자자하는 특징이 모든 표본(sample)에 대해서 일관성 있게 도출 가능해야 한다는 것 등이다(3). 그러나 이러한 정성적인 기준들은 실제 특징선택 과정에서의 적용기준으로는 분명하지 않기 때문에 보다 정

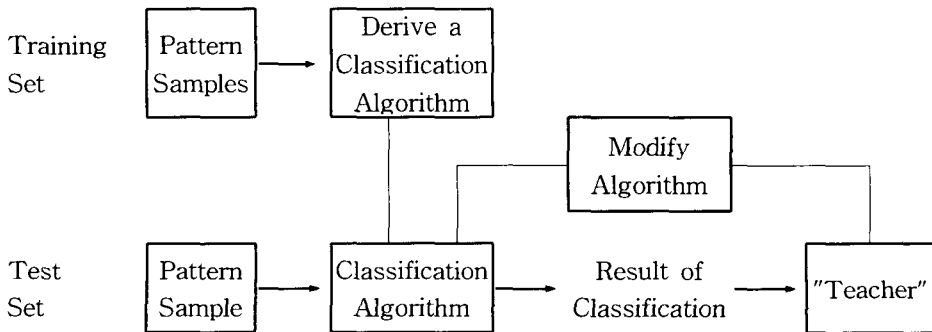


Fig. 1 The design procedure in supervised pattern recognition

량적인 특징평가기준이 필요하게 된다. 정량적인 평가 기준을 설정할 때 보통 고려되는 조건으로는 결합종류 구분능력과 특징간의 독립성의 두 가지이다. 결합종류 구분능력은 특징의 결합분류에의 효용성을 의미하며, 결합분류 시 발생하게 되는 오류확률로 정량화 시킬 수 있으며, 특징간의 독립성은 특징의 중복을 피하면서 특징의 숫자를 줄이는 것과 관계가 있는데, 상관계수로 정량화 시킬 수 있다[7].

만약 d-차원을 갖는 특징집합 $x = \{\zeta_1, \zeta_2, \dots, \zeta_d\}$ 을 생각할 때, 오류확률 e는 식 (1)로 표시된다.

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

여기에서 ξ 는 d개의 ζ_i 특징에 의해 구성되는 특징벡터이고, 즉

$$\xi = [\zeta_1, \zeta_2, \dots, \zeta_d]^T \dots\dots\dots (2)$$

$P(w_i | \xi)$ 는 i번째 범주에 대한 사후확률이며, $p(\xi)$ 는 식 (3)으로 정의되는 혼합밀도함수이다.

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

여기에서 $P(w_i)$ 는 i번째 범주의 사전확률이다. $P(w_i | \xi)$ 는 i번째 범주의 조건부확률밀도함수 $p(\xi | w_i)$ 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 식 (1)로 정의된 오류확률 e를 작게 하는 특징으로서 e값이 낮을수록 결합구분 능력이 우수하다.

두 변수간의 상호 의존성을 측정하는 통계량 중에서 가장 대표적인 척도가 Pearson의 상관계수인데[7], 이는 식 (5)에 의해 정의된다.

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

여기에서, n은 표본 수를 X_i, Y_i 는 두 가지 서로 다른 특징 X, Y의 i번째 값을, \bar{X}, \bar{Y} 는 각각 두 특징 X, Y의 평균값을 나타낸다. 이 상관계수 r은 두 변수간의 관계가 선형관계인지를 측정하는 척도로서 r의 절대값이 1에 가까우면 두 변수사이의 상호의존성이 매우 높음을 의미한다.

따라서 민감한 특징이란 전술한 오류확률 e값이 낮으면서 동시에 다른 특징과의 r의 절대값이 작은 특징을 의미하기 때문에, 특징선택이란 e값과 r값을 바탕으로 가장 적절한 특징들을 선별해 나가는 과정이라 할 수 있다.

2.3. 분류 (Classification)

특징 추출과 특징 선택과정을 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 분류기 중 대표적인 분류 기법에 대해 간략히 정리하면 다음과 같다.

2.3.1. K-Nearest Neighbor (KNN) 분류기

KNN 분류기의 분류 알고리즘은 “특징 공간상에 어떤 분류 대상 표본(X) 주위에 가장 가까이 있는 K개의 학습 표본 중 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)을 가질 수 있어 광범위하게 이용되고 있다[8].

2.3.2. Bayesian 분류기

Bayesian 분류기는 패턴 분류 시 통계적 접근 방법인 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 추정 가능할 때 주로 적용되고 있다. 실제 패턴 분류과정에서 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 ξ 를 갖는 실험 표본에 대해 $R(\alpha_i | \xi)$ 를 최소로 하는 범주 w_j 로 ξ 를 분류한다.” 즉 여기에서 $R(\alpha_i | \xi)$ 는 조건부 위험이라고 부르는데, 이는 다음과 같이 계산된다.

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

여기에서 α_i ($i=1, 2, 3, \dots, a$)는 a 개의 행동(action)을 나타내며, $\lambda(\alpha_i | \xi)$ 는 범주 w_j 인 실험표본에 대해 α_i 의 행동을 취했을 때 입게되는 손실이다. Bayesian 분류 알고리즘은 여러 가지 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 $P(w_j | \xi)$ 을 사용해야 하는데, 이를 위해서 필요한 범주별 조건부 확률 밀도 함수 $p(\xi | w_j)$ 를 알아야 한다. 학습표본으로부터 $p(\xi | w_j)$ 를 추정하는 방법에는 여러 가지가 있으나 그 중에서 가장 널리 사용되는 것이 Parzen window 기법(9,10)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 확률밀도 함수를 추론하는 방법이다. 즉 j 번째 범주 w_j 에 속하는 n 개의 학습표본에 대한 n 개의 특징 벡터 ξ_i ($i = 1, 2, \dots, n$)가 있다고 할 때 d -차원 공간상의 임의의 점 ξ 에서 Parzen window 기법에 의해 추정할 수 있는 조건부 확률 밀도 함수 $p(\xi | w_j)$ 는 다음과 같이 주어진다.

$$p(\xi | w_j) = \frac{1}{n} \sum_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp \left[-\frac{1}{2} \frac{(\xi - \xi_i)' (\xi - \xi_i)}{\sigma^2} \right] \quad (7)$$

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

2.3.3. 신경회로망 분류기

신경회로망은 인간의 뇌의 구조와 작동원리를 모형화

할 수 있다는 점과 함께, 학습표본을 통해 필요한 지식을 배울 수 있으며, 또한 학습 표본에서 경험하지 못하였을지라도 배운 지식을 일반화하여 필요한 결론을 자동적으로 내려준다는 독특한 장점 때문에 1980년대 후반부터 그 활용이 급속히 증가하고 있다. 20여 가지의 신경 회로망 구조 중 가장 널리 사용되는 것은 back propagation neural networks(BPNN)(9)이다. BPNN은 상기의 신경 회로망의 특성을 잘 나타내고 있어 패턴 분류, 자동제어, 회귀분석 등에 널리 사용되고 있다. 그러나, BPNN은 입력과 출력 사이의 관계가 사용자에게 대하여 불투명하고, 학습시간이 어떤 경우에는 너무 길어서, 모든 문제에 대해 보편성 있는 분류기로 사용하기에는 아직도 해결해야 할 문제점이 많은 상태이다. 이에 반해 probabilistic neural networks(PNN)(11)은 병렬 처리 능력 등 신경회로망이 가지고 있는 여러 가지 장점과 함께, 패턴 분류 시 통계적 Bayesian 기법을 적용시킬 수 있어 특히 패턴 분류 분야에서 널리 활용되고 있다.

3. 확률신경회로망

PNN은 BPNN과 외형적으로 매우 비슷해 보이지만, 실제로는 구조와 이용방법에서 매우 독특한 특성을 가지고 있다. 이 절에서는 PNN의 구조, 학습과정, 결합 분류 등의 중요한 특성에 대해 간략히 언급하고자 한다.

3.1. 구조

Fig. 2에 PNN의 기본적인 구조를 나타내었다. PNN은 4개의 층(layer)으로 구성되어 있다. 첫째 층은 입력층으로서 여기를 통해 각 표본의 특징 벡터




Fig. 2 Probabilistic neural network architecture

(X_i) 가 PNN에 공급된다. 두 번째 층은 패턴층으로서 입력층에 공급된 표본의 특징값 X_i 에 가중치 W_{ij} 를 곱한 결과들의 합을 받아들이며, 그 값에 지수함수를 적용한 값을 출력시킨다. 세 번째 층은 합산층으로서, 합산층의 각 노드(node)들은 패턴층의 노드들 중 자신과 같은 범주에 속한 노드들에만 연결되어있는데, 연결된 패턴층 노드들의 출력의 합을 입력으로 받아들이는 후 여기에 사용자가 정의한 파라메터인 C_i 를 곱하여 그 결과를 출력시킨다. 마지막으로 네 번째 층은 출력층으로서 최종적인 출력이 결함 분류 과정에 사용된다. 다른 종류의 신경회로망과는 달리, PNN의 구조는 주어진 문제가 가지고 있는 결함 종류의 수와 학습과정에서 사용된 학습표본의 수에 의해 결정된다. 즉 출력층과 합산층의 노드의 수는 결함종류(즉 범주)의 수와 같고, 패턴층의 노드 수는 학습표본의 수와 일치하며, 입력층의 노드 수는 특징 벡터의 특징 수와 동일하다. 그리고, PNN에는 세 가지 종류의 가중치가 존재한다. Fig. 2의 W_{ij} 는 학습 표본의 특징 벡터들의 특징값을 그대로 사용하기 때문에 학습 표본으로부터 직접 결정된다. 실제로 PNN내에서 조절 가능한 파라메터는 사용자가 정의하는 파라메터인 C_i 와 전달함수내의 평활화 계수 σ 가 있는데 이들에 대해서는 다음에 논의코자 한다.

3.2. PNN의 학습

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 학습표본의 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.

학습과정에서 특징적인 것은 가중치 W_{ij} 가 반복과정이 없이 단번에 결정된다는 것이며, 따라서 학습도 "순간적"으로 완료된다는 점이다. 또한 이 학습과정에서 PNN은 학습 표본으로부터 Parzen window 방법을 통해 각 범주별 확률밀도함수를 계산한다는 점이다.

3.3. 회로망 파라미터의 선택

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

C_i 는

$$C_i = \frac{h_i l_i}{n_i} \dots\dots\dots (7)$$

로 정의된다. 여기에서 h_i 는 i번째 범주의 사전확률, l_i 는 손실계수, n_i 는 i번째 범주내의 학습표본의 수이다. 따라서 사용자가 균열과 같은 어떤 특정 범주에 더 큰 비중을 두고 싶을 때에는 손실계수 l_i 에 큰 값을 지정할 수 있다. 평활화 계수 σ 는 패턴층 내에 있는 각 패턴들의 개별적인 중요도를 조절하는 계수로서 σ 값을 작게 하면 개개의 패턴에 대한 중요성을 강조하게되고, σ 값을 크게 하면 많은 패턴들의 평균적인 거동을 강조하게 된다. 그리고 이 값은 어떤 이론적 근거로부터 결정된다기보다는 다분히 실용적 관점에서 비교적 "양호한" 결함 분류 성능을 얻을 수 있는 σ 값을 찾아 사용하고 있다.

3.4. 결함 분류

PNN의 학습과 회로망 파라메터에 대한 선택이 끝나면, 이 PNN을 이용하여 시험표본에 대한 결함분류를 수행할 수 있다. PNN의 결함분석 알고리즘은 "주어진 시험표본에 대한 출력층의 노드 중 최대값(이 값은 곧 최대 예상손실을 의미함)을 갖는 범주를 그 시험표본의 범주로 결정한다"라고 할 수 있다. 이것은 곧 PNN이 Bayes법칙에 따라 결함분류를 수행함을 말한다.

4. 냉연강판 표면결함 분류

국내 철강 생산 업체에서는 표면 결함 검출기(surface defect detector: SDD)를 사용하여 냉연강판 표면 위에 발생하는 실제적인 결함들 중 딱지 흠(scab), 구멍(hole), line scab, 부푼 흠(blow hole)과 긁힌 흠(scratch)의 5종류 결함을 종류 판별을 수행하고 있었다. SDD가 채택하고 있는 분류기는 분류표 분류기(classification table classifier: CT)인데, 결함 분류 정확도가 그다지 좋지 않기 때문에 이러한 문제를 해결하기 위해 CT, ECT(enhanced classification table classifier),

힘들어 설정한 후에도 실제적인 결함 분류의 정확도가 매우 낮게 된다. 따라서 분류표 분류기의 효율적인 사용을 위해서는 이 값의 설정 작업을 자동적으로 수행할 수 있는 기법을 채택하는 것이 바람직하다.

4.3.2. 강화 분류표 분류기(Enhanced Classification Table Classifier: ECT)

앞에서 언급한 분류표 분류기는 검출한 결함(X)으로부터 추출한 특징 X_i 에 대해 IF~THEN 법칙의 논리곱(AND 결합)으로 되어 있어, 결함 특징의 분포가 분산되어 있는 경우에는 그 성능이 급격히 저하될 우려가 있다. 이러한 단점을 보완하기 위해 “강화 분류표 분류기(enhanced classification table: ECT)”를 제안하였다[12]. 이 분류기는 시험 표본(X)로부터 추출한 n개의 특징값 $X_i (i = 1, n)$ 를 추출하고 이 특징값들이 모든 결함 종류(m개)의 분포 범위 내에 속하는지를 확인한다. 그리고 분포 범위 내에 속한 특징의 수를 계수하여 m개의 결함 종류에 대한 m개의 $W_j (j = 1, m)$ 값을 결정하고, 이 중에서 최대의 W_j 를 갖는 결함 종류로 검출 결함을 분류하는 기법이다. 즉 이 기법은 검출된 결함과 각 결함 종류와의 유사성을 점수(W_j)로 평가하여 최대 점수 (최대 W_j)를 획득한 결함 종류로 검출결함을 분류하는 방법으로, 분류 알고리즘은 다음과 같다.

For J = 1 To m

$W_j = 0$

IF($\alpha_1 \leq X_1 \leq \beta_1$) THEN $W_j = W_j + 1$

IF($\alpha_2 \leq X_2 \leq \beta_2$) THEN $W_j = W_j + 1$

⋮

IF($\alpha_n \leq X_n \leq \beta_n$) THEN $W_j = W_j + 1$

If W_k is the Maximum of $W_j (j = 1, m)$

Then Classify X Class K

이 강화 분류표 분류기도 역시 결함 종류별 특징별 분포범위 값 α_i, β_i 가 필요한데, 이 값들은 분류표 분류기에서와 동일한 방법으로 결정한다.

4.3.3. 확률신경회로망의 학습

주어진 결함 신호에 대한 5개의 특징 값을 입력으로

제공하면 5종류의 결함 중 가장 적합한 종류의 결함으로 분류할 수 있는 확률신경회로망을 구성하였다. 이 PNN은 5개의 입력층 노드, 115개의 패턴층 노드, 5개의 합산층 노드, 그리고 5개의 출력층 노드를 가지고 있으며, 앞에서 언급한 115개의 학습표본을 이용하여 학습시켰다. 그리고 확률신경회로망 변수 중 사용자가 임의로 선택할 수 있는 파라미터인 평활화 계수는 분류표 분류기와 같이 0.01과 0.1 두값을 취하였다. 또한 결함의 오분류에 따른 기대 손실은 결함 종류별로 차이가 없는 것으로 간주하여 손실계수는 모두 같은 값을 사용하였다.

4.4. 분류 성능 평가

Fig. 3에 세 가지 분류기를 사용하여 얻은 결함분류 성능을 비교하였다. CT, ECT를 이용하여 결함을 분류하기 위해서는 각 특징별 descriptor entry 값을 결정해야 하는데, 실제로 이 값은 사용자에게 의해 다양한 방법으로 정의 될 수 있다. 본 연구에서는 확률 밀도 함수의 최대값의 25%에 해당하는 값을 취하였다. Fig. 3은 평활화 계수를 0.1로 취한 경우에 대한 결과인데, 이 결과에서 알 수 있는 바와 같이 CT는 약 55% 정도의 정확도를 나타내고 있으나, ECT와 PNN은 각각 86%, 77%의 높은 정확도를 나타내고 있어 매우 효율적인 분류기임을 알 수 있다. 그러나, CT와 ECT의 경우 Type E 결함을 Type D의 결함과 구분하지 못하는 반면, PNN은 Type E와 Type D를 어느 정도 구별해 내고있어, PNN이 가장 효율적인 분류기임을 알 수 있다. 그리고 평활화 계수가 0.02, 0.05인 경우에 대해서도 대개 같은 결과를 얻을 수 있어, 평활화 계수 (σ)는 분류성능에 그다지 큰 영향을 미치지 않은 것으로 나타났다.

5. 용접 결함 분류

용접부에 존재하는 결함을 초음파 탐상 시험 통해 검출하고, 획득한 결함 신호로부터 검출 결함의 종류를 판별에 초음파 형상 인식기법을 적용한 연구사례이다. 이 연구에서는 용접부에 존재하는 결함의 종류를 크게 균열(crack), 슬래그 혼입(slag inclusions), 기공(porosity)으로 분류하는 연구를 수행하였다[13].

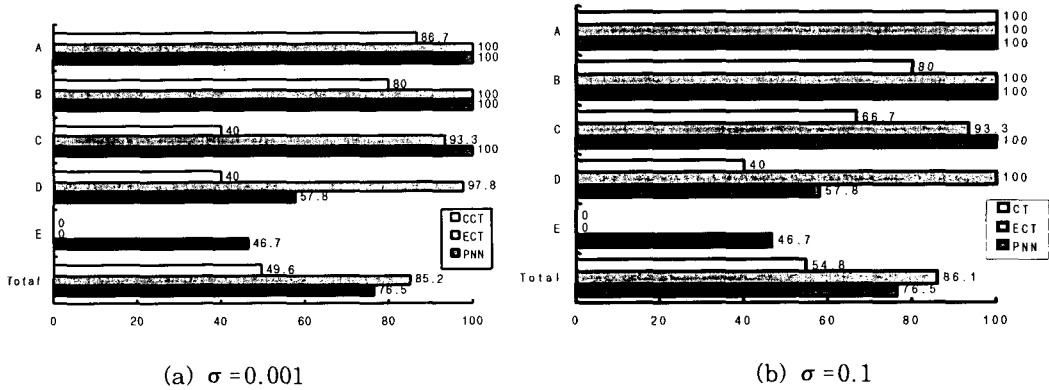


Fig. 3 Correct classification rates of classifiers

5. 1. 초음파 결합 신호 수집

용접결합 시험편은 미국 Westinghouse사가 연구를 위해 특별히 제작한 것으로서 종류, 위치 그리고 대략적인 크기가 알려진 균열(피로균열)과 비균열(기공, 슬래그 혼입)의 용접결합을 내포하고 있다(Fig. 4 참조). 균열은 피로시험을 통해 피로균열을 생성시킨 후 이를 시험편에 삽입하여 제작하였으며, 비균열은 용접 도중 부적절한 용접조건을 사용하여 용접부에 기공, 슬래그 혼입의 용접결합을 일부러 생성시켰다. 이 시험편 내에 있는 용접결합으로부터 1.5MHz, 45° 사각탐촉자를 사용하여 채취한 A-scan 협대역 초음파 결합 신호를 25MHz A/D 보드(SONIX STR 825)를 통하여 디지털 데이터로 변환시켜 PC에 전송하였다. 이 시험편은 일반 강재로 된 시편 상부를 스테인레스 강으로 약 0.6mm정도 클래딩(cladding)하였기 때문에, 이 시편에서 채취한 초음파 결합 신호는 매우 많은 노이즈 성분을 포함하고 있다.

균열에서 104개, 비균열에서 135개, 총 239개의 결합 신호를 수집하여 이 중 120개의 신호를 임의로 선택하여 학습표본으로 하고, 나머지 119개를 시험표본으로 사용하였다. 학습표본은 이용하여 결합신호특징 추출, 확률밀도함수 추정, 분류표 분류기와 강화분류표 분류기의 설정, 신경회로망의 구축과 학습등에 사용하였으며, 시험표본은 개발된 프로그램의 분류성능 평가를 위해 사용하였다.

5. 2. 특징 추출 및 선택

초음파 결합신호의 A-scan 파형으로부터 신호처리 기법을 이용하여 Table 3과 같이 time-domain에서 10개, frequency-domain에서 4개의 특징을 추출하였다.

5. 3. 분류기

표면결합 분류시와 동일하게 CT, ECT, PNN을 분류기로 사용하였다.


5.3.1. CT와 ECT의 설정

특정 특징에 대한 결합 종류별 확률밀도함수가 구해지면 이로부터 특징의 분포범위 값을 결정할 수 있다. 확률밀도함수 최대값의 25%에 해당하는 문턱선을 설정하고, 확률밀도함수 곡선이 이 문턱선과 교차하는 점을 분포범위 값으로 취한다. 이렇게 함으로써, 결합 종류별(균열과 비균열에 대한) 그리고 특징별(14개의 모든 특징에 대한) 분포범위 값을 모두 결정하였다. 여기에서 유의해야 할 사항은 분포범위 값이 확률밀도함수 추정을 위한 평활화 계수에 따라 달라진다는 점이다.

이상과 같이 결합 종류별 특징별 분포범위 값이 모두 결정하고, 이 값들을 4.3.1와 4.3.2 절에 언급한 분류 법칙에 대입하여 분류표 분류기와 강화 분류표 분류기를 설정하였다.

5.3.2. PNN의 학습

용접 결함의 종류를 균열과 비균열 2가지로 구분하



Side view of the specimen

고, 이를 위해 개의 학습표본을 수집하여 각 학습표본에서 14개의 특징들을 추출하였다. 따라서 이러한 문제를 해결하기 위해, 입력층에 14개의 노드, 패턴층에 120개의 노드, 그리고 합산층과 출력층에 각각 2개의 노드를 갖는 PNN을 구축하였다. 그리고 120개의 학습표본을 이용하여 PNN내의 가중치를 결정하여 학습을 완료하였다.

5.4. 분류 성능 평가

결함 분류 성능을 평가하기 위해, 119개의 시험표본을 이용하여 PNN, CT, ECT의 세 가지 분류기를 통해 결함 분류를 실시했다.

Specimen #	Specimen size(L×M)	Flaw type	Distance from side (S)	Distance from surface (d)	Flaw size
I	875×274	Crack	34.544	9.652	19.05
		Crack	113.538	67.056	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. 4 The specimen including welding defects

Table 2 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 2st group signal	
	F9	energy of the 3st 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 magnigude spectrum	

전술한 바와 같이 CT와 ECT의 경우는 평활화 계수의 선택에 따라 분류 법칙이 변화하고, PNN의 경우도 회로망 파라미터(범주별 손실계수와 평활화 계수)를 사용자가 정의하기 때문에, 각 분류기의 성능이 평활화 계수의 선택에 따라 달라진다. Fig. 5에 평활화 계수의 변화(0.02부터 0.3까지 0.02 간격으로 증가시킴)에 따른 각 분류기별 분류 정확도의 변화를 나타내었다. Fig. 5에서 볼 수 있는 바와 같이, CT는 시험표본의 특징값이 분류표 상의 특징의 분포범위 안에 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. 그리고 CT와 ECT는 평활화 계수의 변화에 따라 분류 성능이 크게 변화하는 것을 볼 수 있다. 이에 반해, PNN은 (균열과 비균열에 대한 범주별 손실계수를 같게 취했을 때) 평활화 계수의 변화에 관계없이 거의 일정하며, CT나 ECT에 비해 높은 분류 정확도를 나타내고 있다. 이것은 PNN이 평활화 계수의 영향을 거의 받지 않는 매우 객관적인 분류기이며, 또한 유사한 형태의 PDF를 갖는 아주 구별하기 힘든 결함도 구별해내는 능력을 갖춘 우수한 분류기임을 말해주는 것이다.

사실 평활화 계수는 모집단의 특징값들의 분포를 반

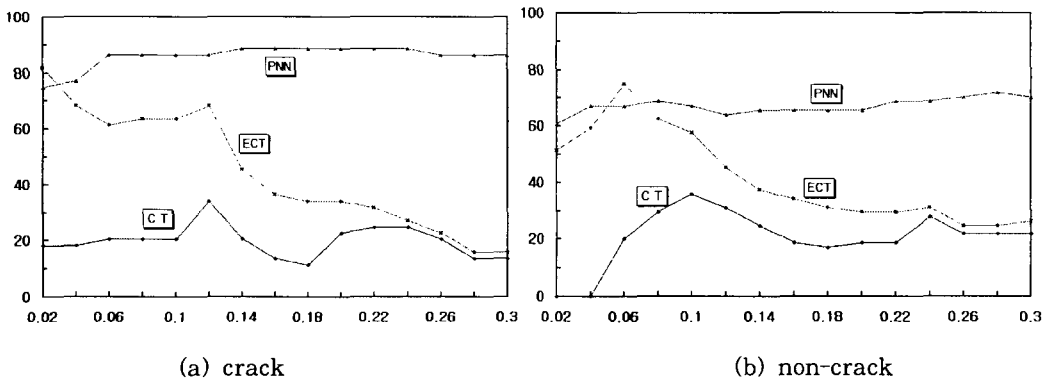


Fig. 5 Correct classification rates of classifiers

영하는 인자이지만, 대부분의 경우 모집단의 특성은 알 수 없기 때문에, 평활화 계수는 사용자가 임의로 정의 하여 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.

Fig. 6은 평활화 계수를 0.1로 취했을 때, CT, ECT, PNN 그리고 이 세 분류기의 분류결과를 종합하여 최종적인 결과를 도출하는 최종전문가 (final expert: FE)의 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.

6. 증기발생기관 결함 분류

와전류 탐상 기법을 통해 원자력 발전소의 증기발생 기관에 존재하는 결함을 검출하고, 검출 결함의 종류를 판별하기 위해 적용된 와전류 형상인식기법에 관한 연구를 수행한 결과이다[14].

6. 1. 와전류 결함 신호 수집

와전류 형상인식을 위해서는 형상인식 알고리즘 개발




Fig. 6 Summary of correct classification rates of classifiers




Fig. 7 Parameters in the simulation of eddy current testing for a defect at the outer diameter of the tube

의 기반이 되는 충분한 량의 와전류 결함신호 표본들이 필요하다. 축대칭 수치해석 프로그램으로부터 이론적 표본들을 수집하였다. 이때 수치해석 모델에서 사용한 Inconel 600 판의 크기와 탐상조건에 대한 자료를 정리하면 Fig. 7과 같다.

Table 3에 나타난 것처럼, 결함의 종류를 형상에 따라 2가지(I자형/V자형), 위치에 따라 2가지(관내벽/관외벽) 총 4가지로 구분하고, 각 범주에 속한 결함의 크기(폭과 깊이)를 다양하게 변화시킨 후, 각 결함에 대해 와전류탐상 주파수를 2가지(100kHz / 400kHz)로 변화시켜 가면서 I형 결함에 대해서는 총 200개, V형 결함에 대해서는 총 16개의 결함신호를 생성하였다.

Table 3 The number of simulated eddy current flaw signals and their conditions in simulation

Flaw Type	The number of levels			The number of signals
	w	d	f	
I-Out	5	10	2	100
I-In	5	10	2	100
V-Out	5	10	2	100
V-In	5	10	2	100
Total	-	-	-	400

*f=frequency (100kHz, 400kHz) *d=flaw depth (0.1, 0.2, 0.3, ...,1.0mm (for I type), 0.5, 1.0mm) *w=flaw width (0.2, 0.4, ...1.0mm)

Table 4 Features extracted from axisymmetric flaws

Feature
F 1. Maximum resistance in the upper half plane
F 2. Phase angle at the point of maximum resistance in the upper half plane
F 3. Maximum reactance in the upper half plane
F 4. Phase angle at the point of maximum reactance in the upper half plane
F 5. Maximum impedance in the upper half plane
F 6. Phase angle at the point of maximum impedance in the upper half plane
F 7. Phase angle at the starting point of the signal
F 8. Phase angle at the ending point of the signal
F 9. Turning phase angle at the point of maximum impedance of the signal
F10. The length up to the maximum reactance point of the signal / The length from the maximum reactance point of the signal
F11. Total length of the signal / Magnitude of the impedance at the maximum reactance point

6.2. 와전류 결함 신호 특징 추출

임피던스 평면상에 그려진 와전류 결함신호 궤적으로 부터 Table 4에 나타난 11개의 특징들을 추출하였는데, 각 특징에 대한 정의를 Fig. 8에 나타내었다. 이들 특징중에서 와전류 결함 종류 판별에는 F5, F7, F9, F10, F11 특징 5개를 사용하였다.

6.3. 분류기

와전류 형상인식 기법에서는 앞 절의 연구에서 결함 분류 성능이 입증된 확률신경회로망만을 사용하였다.

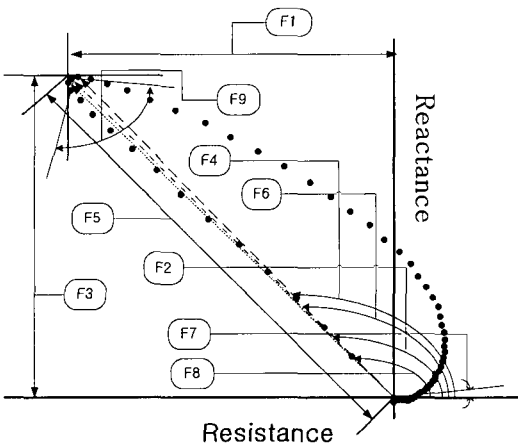


Fig. 8 Definition of features extracted from an eddy current flow signal in the impedance plane

6.3.1. PNN 학습

와전류 결함신호로부터 추출·선택된 5개의 특징값을 이용하여 결함의 위치와 형상을 결정할 수 있는 신경회로망 분류기를 구성하였다. 이 분류기는 하나의 확률신경회로망을 이용하여 종류(여기에서는 위치와 형상에 따라 구분됨)가 알려져 있지 않은 결함을 위치와 형상에 따라 4가지 결함(관 내벽 I형, 관 외벽 I형, 관 내벽 V형, 관 외벽 V형) 중 하나로 결정한다. 확률신경회로망의 구조는 최종 선택된 특징의 수와 분류하려는 범주 수에 따라 입력층 노드 수는 5개, 100개의 패턴층 노드, 4개의 합산층 노드, 출력층 노드 수는 4개로 구성하였다.

6.4. 결함 분류 성능 평가

200개의 결함으로부터 생성한 총 400개의 샘플신호 (100kHz 신호 200개, 400kHz 신호 200개) 중 200개

Table 5 Result of classification by PNN

Actual defect type	Classified defect type by PNN				
	I-Out	I-In	V-Out	V-In	Total
I-Out	24	0	1	0	25
I-In	0	17	0	8	25
V-Out	0	0	25	0	25
V-In	0	0	0	25	25
Total	24	17	26	33	25

는 학습표본으로 선택하고, 나머지 200개를 시험표본으로 선정한 후, 평활화 인자의 값을 0.10으로 하는 확률 신경회로망을 구성하였다. 이 신경회로망은 Table 5에 나타낸 바와 같이 91%의 분류정확도를 보였다.

7. 결 론

본 고에서는 각종 소재, 기계, 설비, 설비에 존재하는 결함을 비파괴적으로 검출하고, 검출한 결함의 종류 판별을 위한 형상인식기법의 적용에 대해서 지금까지 수행한 연구 중 표면결함, 용접결함, 증기발생관의 결함 분류에 적용한 예를 통해 설명하였다. 형상인식기법은 앞에서 살펴본 바와 같이 특징 추출, 특징 선택, 분류의 3단계로 구성되어 있는데, 이 과정 중에서 결함 분류를 위해 사용되는 분류기에는 앞서 언급하였듯이 여러 종류의 분류기가 있으나, 이러한 분류기들 중에서 확률신경회로망(PNN)의 결함 분류 성능이 가장 우수함을 알 수 있었다. 따라서, 결함 검출 기법에 따른 결함신호에서 결함 분류에 적합한 특징을 추출, 선택하는 과정만을 해당 문제에 맞게 조정하면 다양한 형태의 결함 분류에 적용할 수 있다. 따라서, 형상인식 기법을 비파괴 검사 기법에 적용하여 결함의 종류를 판별하기 위해서는 무엇보다도 현재 분류하고자 하는 결함의 종류를 명확히 구분해야 하며, 분류기를 학습시키기에 충분한 결함신호 data base를 구축하여야 한다. 특히, 현장 적용이 우수한 결함 분류 시스템을 개발하고자 할 경우에는 결함 신호 data base를 구축 시 시험편에서 채취한 결함 신호뿐만 아니라 현장에서 수집한 결함 신호를 충분히 확보하는 것이 가장 중요한 일이라고 볼 수 있다. 즉, 결함 분류시 풍부한 현장 결함 신호 data base와 결함 분류를 위한 유용한 특징을 추출한다면 현장 적용성 및 결함 분류 신뢰성이 우수한 결함 분류 시스템을 개발 할 수 있을 것으로 사료된다.

후 기

본 고는 지금까지 필자와 필자의 동료들에 의해 수행된 연구 내용을 요약한 것임을 밝힙니다. 이에, 본 고에

서 인용한 연구를 지금까지 필자와 함께 수행해 주신 김학준씨(성균관대학교 대학원), 최세호, 이종학 연구원(포항제철주식회사), 신영길 교수(군산대학교), 이항범 교수(송실대학교)께 감사를 드립니다.

참고문헌

- [1] C. W. Therrien, Decision Estimation and Classification, John Wiley, New York, (1989)
- [2] J. M. Dorochoer, D. R. Hay, R. W. Y. Chan and J. R. Matthews, "Application 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)
- [3] J. T. Tou and R. C. Gonzalez, Pattern Recognition Principles, Addison-Wesley, Reading, MA, (1974)
- [4] J. L. Rose, "Elements of a feature-based ultrasonic inspection system", Materials Evaluation, Vol. 42, pp. 210-218, (1984)
- [5] 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, pp. 145-152, (1986)
- [6] 심철무, 주영상, 홍순신, 장기욱, "형상인식을 이용한 압력용기 용접부 결함 특성 분류", 비파괴검사학회지, 제 13권 제 2호, pp. 11-18, (1993)
- [7] Lincoln L. Chao, Statistics: Methods and Analyses, 2nd Ed, McGraw-Hill Kogakusa, Tokyo, (1974)
- [8] S. J. Song and L. W. Schmerr, "Ultrasonic flaw classification in weldments using probabilistic neural networks", Journal of Non-destructive Evaluation, Vol. 11, pp. 69-7, (1992)

- [9] 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)
- [10] R. O. Duda and P. E. Hart, Pattern Classification and Scene Analysis, New York, John Wiley & Sons, (1973)
- [11] D. F. Specht, "Probabilistic neural networks for classification, mapping, or associative memory", Proceeding of the IEEE International Conference on Neural Networks, Vol. 1, pp. 525-532, (1988)
- [12] 송성진, 김학준, 최세호, 이종학, "확률신경회로망에 의한 냉연강판 표면결함의 분류", 비파괴검사학회지, 제 17권 제 3호, pp.162-173, (1997)
- [13] 김학준, 송성진, 정희돈, "용접 결함 종류 판별을 위한 지능형 초음파 신호 분류 소프트웨어의 개발", 비파괴검사학회지, 제 17권 제 4호, pp. 248-261, (1997)
- [14] S. J. Song and Y. K. Shin, "Eddy current flaw characterization in tubes by neural networks and finite element modeling", NDT & E international, (1999), In Press