

모사 와전류 탐상신호를 이용한 비대칭 단면을 갖는 축대칭 결함의 형상분류

Classification of Axis-symmetric Flaws with Non-Symmetric Cross-Sections using Simulated Eddy Current Testing Signals

송성진*, 김창환*, 신영길**, 이항범***, 박운원****, 임창재*****

S. J. Song*, C. H. Kim*, Y. K. Shin**, H. B. Lee***, Y. W. Park**** and C. J. Yim*****

초 록 본 연구는 와전류 형상인식 기법을 증기발생기 세관의 보다 실제적인 결함 평가 문제에 적용하기 위한 목적으로 시도되었다. 이를 위해 증기발생기 세관에 발생하는 실제적인 결함을 보다 사실적으로 모사하는 다섯 가지 형태의 외벽 결함을 선택하고, 이들 결함의 크기 인자와 시험주파수를 변화시켜 가면서, 유한요소 수치해석 프로그램을 이용하여 이론적인 결함신호를 생성하였다. 그리고, 이들 결함신호의 분석을 효율적으로 수행하기 위한 도구로서, '와전류 특징추출 프로그램', '와전류 특징분석 프로그램', 그리고 'PNN 결함분류 프로그램'을 자체적으로 개발하였다.

비대칭 단면을 갖는 결함의 신호는 교점이 원점으로부터 이격되는 현상이 관찰되었는데, 이러한 특성을 반영하는 특징을 추가하여 총 18개의 특징을 시험주파수 별로 정의하였다. 이 특징들을 이용하여 결함을 분류하는 확률신경회로망을 구성하고 결함 분류를 수행한 결과, 결함단면의 대칭성 여부를 결정하는 문제에서는 비교적 높은 정확도를 얻었으나, 결함선단의 침도를 판단하는 문제에서는 낮은 정확도를 얻었다.

주요용어: 와전류탐상 시험, 증기발생기 세관, 유한요소모델, 형상인식, 신경회로망

Abstract: This paper describes an initial study for the application of eddy current pattern recognition approaches to more realistic flaw characterization in steam generator tubes. For this purpose, finite-element model-based theoretical eddy current testing (ECT) signals are simulated from 5 types of OD flaws with the variation in flaw size parameters and testing frequency. In addition, three kinds of software are developed for the convenience in the application of steps in pattern recognition approaches such as feature extraction, feature selection and classification by probabilistic neural networks (PNNs). The cross point of the ECT signals simulated from flaws with non-symmetric cross-sections shows the deviation from the origin of the impedance plane. New features taking advantages of this phenomenon are added to complete the feature set with a total of 18 features. Then, classification with PNNs are performed based on this feature set. The PNN classifiers show high performance for the identification of symmetry in the cross-section of a flaw. However, they show very limited success in the interrogation of the sharpness of flaw tips.

Keywords: eddy current testing, steam generator tube, finite element model, pattern recognition, neural network

1. 서 론

원자력발전소의 증기발생기 세관은 1차 계통수와 2차 계통수에 직접 접촉하는 부품으로, 파손 시 방사성 물질의 누출 사고를 일으킨다. 따라서 증기발생기 세관의 건전성 확보가 원자력 발전소 전체의 안전성 확보에서 차지하는 비중이 매우 크기 때문에 비파괴검사가 주기적으로 수행되고 있다. 증기발생기 하나에는 수 천 개에 이르는 세관들이 있어 검사 시간의 단축을 위한 고속 검사가 필수적이다. 이러한 필요성 때문에, 비접촉의 고속 검사가 가능한 와전류탐상 시험을 실시하고 있으며, 그 결과를 토대로 세관의 건전성을 평가하고 있다.

와전류탐상 시험에 의한 세관의 건전성 평가에서 가장 큰 문제가 되는 것은 와전류탐상 신호해석이다. 와전류탐상 신호 해석이란 와전류탐상 신호로부터 그 신호 생성에 직접적인 영향을 미친 결함에 대한 정량적 정보(위치, 종류, 크기 등)를 결정하는 것을 말하는데, 확산 현상이 지배적인 와전류의 특성상 결함 인자와 신호 특성과의 상관관계를 설정하는 것이 간단하지 않아, 작업자에 의한 신호 해석의 객관적 신뢰성이 매우 낮은 상태이다. 또한, 고속으로 검사가 수행되기 때문에 작업자에 의한 신호 해석보다는 고속검사에 적합한 자동화 장치에 의한 신호 해석이 선호되고 있다. 이러한 필요를 충족시키기 위해 지금까지 비파괴평가 분야에서는 와전류탐상 신호해석의 자동화에 대한 많은 연구가 수행되어 여러 가지 새로운 기법들이 제안된 바 있는데, 이 중에서 가장 주목을 받고 있는 기법이 "와전류 형상인식" 기법이다[1,2].

와전류 형상인식은 와전류 신호를 해석하는데 형상인식 기법[3]을 도입한 것으로서, 다양한 결함으로부터 획득한 결함 신호를 수집하여 데이터베이스화하고, 데이터베이스 내의 결함신호들로부터 와전류 특징을 추출하고, 추출한 특징에 인공신경회로망[4-6] 등을 적용함으로써 결함의 위치, 종류, 크기를 자동적으로 결정하는 기법이다. 따라서, 와전류 형상인식 기법에서 가장 중요한 역할을 하는 것은 두 가지이다. 첫째는 결함 신호의 데이터베이스이다. 결함 신호의 데이터베이스에는 가능한 한 다양한 종류의 많은 결함으로부터 획득한 결함 신호가 포함되어야 하는데, 이러한 신호를 실험적으로 채취하는 것은 매우 많은 시간과 비용이 소요된다. 이러한 문제를 해결하기 위한 매우 효율적인 대안이 모델링을 이용하는 것이다. 와전류탐상 시험의 모델링은 와전류탐상 시험에서 획득하는 결함 신호를 이론적으로 예측하는 기술인데, 이를 위한 유한요소 수치

해석 프로그램을 개발하고[2,7], 이를 이용하여 이론적인 신호를 생성하여 데이터베이스를 구축한 바 있다[1,2]. 두 번째는 결함 신호로부터 결함의 정량적 특성을 결정하는 형상인식 알고리즘인데, 이를 위해서는 신경회로망이 가장 널리 쓰이고 있다[8,9]. 국내에서도 확률신경회로망으로 종류를 판별하고, 역전파신경회로망으로 결함의 크기를 결정하는 알고리즘이 제안된 바 있다[1,2]. 그러나, 이 연구에서 분석의 대상으로 삼은 결함은 증기발생기 세관에 발생한 2차원 축대칭 결함이었으며, 결함의 단면 형상 또한 좌우 대칭인 "I"자 형태나 "V"자 형태로 제한되어 있었다. 이렇듯, 지금까지 수행된 이전 연구를 통해 와전류 형상인식 기법 자체는 체계적으로 정립되었으나, 이 기법을 이용하여 증기발생기 세관에 발생하는 실제 결함을 분석하고자 하는 연구는 상대적으로 미흡하였다.

본 연구는 이전 연구[1,2]를 통해 정립된 와전류 형상인식 기법을 실제 결함 신호 분석에 적용하기 위한 노력의 일환으로서 수행되었다. 본 연구에서는 증기발생기 세관에 발생한 축대칭 결함 중 단면의 형상이 대칭이 아닌 결함에 대해 와전류탐상 검사를 수행했을 때 얻게되는 결함 신호를 이전 연구[2,7]에서 개발한 유한요소 수치해석 프로그램을 이용하여 생성하고, 이 신호를 해석하는데 적합한 와전류 특징들을 새롭게 정의하였다. 그런데, 결함의 단면이 비대칭인 경우에는 와전류탐상 신호도 비대칭이 되어 결함 신호 해석에 필요한 특징들의 정의와 추출이 매우 복잡하게 되기 때문에, 이 과정을 편리하게 할 수 있도록 특징 추출 프로그램을 자체적으로 개발하여 사용하였다. 그리고, 이 프로그램을 사용하여 특징을 추출하고, 이전 연구[1,2]에서 제안한 특징 선택 기법과 확률신경회로망 기법을 적용하여 결함 종류 판별을 수행하였다.

본 연구에서는 먼저 유한요소 수치해석을 이용하여 비대칭 단면을 갖는 축대칭 관 결함에 대해 결함 인자를 변화시켜 가면서 와전류 신호를 생성하였다. 모사된 와전류 탐상신호에 확률신경회로망 기법을 적용하여 결함의 종류를 판별하였다. 본 연구에서 사용한 유한요소 수치해석 모델과 와전류 형상인식 기법, 그리고 확률신경회로망에 대해서는 이전 연구[1,2]에서 자세히 보고한 바 있기 때문에, 여기에서는 논의의 진행 상 꼭 필요한 부분에 대해서만 간략히 서술하였다.

2. 와전류탐상 신호의 생성

결함신호로부터 결함의 특성을 파악하기 위해서는 충

분히 많은 양의 결함신호를 확보해야 하는데, 실험적으로 이러한 신호를 획득하는데는 시간과 비용 상의 많은 제약이 따른다. 이러한 제약을 극복하기 위해, 본 연구에서는 이전 연구[2,7]에서 개발된 유한요소 수치해석 프로그램을 사용하여 이론적인 신호를 생성하였다. 이 프로그램은 원자력발전소의 증기발생기 세관을 모델로 하여 축대칭 2차원 결함을 설정하고, 이에 대한 와전류 결함신호를 이론적으로 예측한다. 증기발생기 세관에 발생하는 실제 결함은 균열 뿐 만 아니라, 세관과 지지판 사이의 마찰에 의한 마모, 환경에 의한 부식 등이 있는데, 이들 결함의 단면 형상은 비대칭인 경우가 대부분이다.

본 연구에서는 이러한 비대칭 단면을 갖는 실제 결함을 모사하여, Fig. 1에 나타낸 바와 같이 5 종류의 인공 결함을 대상으로 하였고 이들은 모두 증기발생기 세관의 외벽에 발생한 것으로 가정하였다. 여기서 I와 V는 각각 결함의 단면이 I자와 V자 형태를 나타내고, K는 I와 V의 중간형태이다. Fig. 1에서 (a)와 (c)는 대칭 단면을 갖는 결함, (b)와 (d)는 결함 선단(tip)의 중심선이 축으로부터 45도 기울어진 비대칭 단면을 갖는 결함, 그리고, (e)는 K형 결함이다.

Fig. 1에 나타낸 5가지 범주의 결함에 대해, 형상인자




Fig. 1 Schematic representation of cross-sections of flaws. (a) I-symmetric, (b) I-inclined, (c) V-symmetric, (d) V-inclined and (e) K

Table 1 The number of simulated flaw signals and their conditions.

Flaw Type	The number of levels			The number of signals
	w	d	f	
I-Symmetric	3 (2)	3 (2)	2	18 (8)
I-Inclined	3 (2)	3 (2)	2	18 (8)
V-Symmetric	3 (2)	3 (2)	2	18 (8)
V-Inclined	3 (2)	3 (2)	2	18 (8)
K	3 (2)	3 (2)	2	18 (8)
Total	-	-	-	90 (40)

* The numbers out of and in () denote the number of levels for the training and test sets, respectively.


* f=frequency : 100 kHz, 400 kHz

* d=flaw depth : 0.4, 0.6, 0.8 mm for the training set, and 0.5, 0.7 mm for the test set


* w=flaw width : 0.4, 0.6, 0.8 mm for the training set, and 0.5, 0.7 mm for the test set

(깊이, 폭)를 변화시켜 가면서 65개의 결함을 설정하고, 하나의 결함에서 두 가지 시험 주파수(100kHz, 400kHz)를 사용하여, Table 1에 나타낸 것처럼 총 130개의 결함 신호를 생성하였다. 이 중 결함의 깊이와 폭을 0.4 mm, 0.6mm, 0.8mm로 취한 90개의 신호는 확률신경회로망의 학습용으로 사용하고, 결함의 깊이와 폭을 0.5mm와 0.7mm로 취한 40개의 신호는 학습이 끝난 확률신경회로망의 성능 평가를 위해 사용하였다.

Figs. 2와 3은 Fig. 1에 나타낸 5가지 종류의 결함으로부터 수치해석 프로그램[2,7]을 이용하여 이론적으로 생성한 결함 신호의 예를 보여 주고 있다. 이 신호의 생성을 위해 결함의 깊이와 폭을 모두 0.8mm로 설정하였으며, Fig. 2는 시험주파수가 100kHz인 경우의 신호이며, Fig. 3는 시험주파수가 400kHz인 경우의 신호이다. 그리고, 이들 그림에서 (a)는 단면이 I자 형태인 결함("I-Symmetric"과 "I-Inclined")에 대한 신호이며, (b)는 단면이 V자형("V-Symmetric"과 "V-Inclined")인 경우와 "K"자형인 경우("K")에 대한 신호이다.



(a)



(b)

Fig. 2 ECT signals simulated from 5 types of flaws with the test frequency of 100kHz (a) for flaws with I-shaped cross-sections, and (b) for flaws with V-shaped or K-shaped cross-sections

이들 그림을 보면, 단면이 대칭이면 결함 신호(임피던스 평면상의 궤적)의 교차점이 원점과 일치하는 대칭 형태로 나타나고 있으나, 비대칭 단면의 경우에는 결함 신호의 형태도 비대칭이 됨을 알 수 있다. 그런데, 교차점이 원점으로부터 이격되는 정도는 주파수에 의존적인 것으로 나타났는데, 표준침투깊이가 1.6mm인 100kHz 신호에서보다는 0.8mm인 400kHz 신호에서 보다 크게 나타났다. 그러나, 비대칭 단면 결함의 신호의 세기와 위상각은 대칭 단면의 경우와 큰 차이를 보이지 않고 있음을 알 수 있다.

3. 와전류탐상 신호의 특징 추출

앞 절에서 언급한 것처럼, 와전류탐상 신호는 결함 인자(위치, 크기, 형상)의 변화에 따라 변화하는데, 이때 이 신호의 변화를 효과적으로 표현하는 특징을 추출하는 것


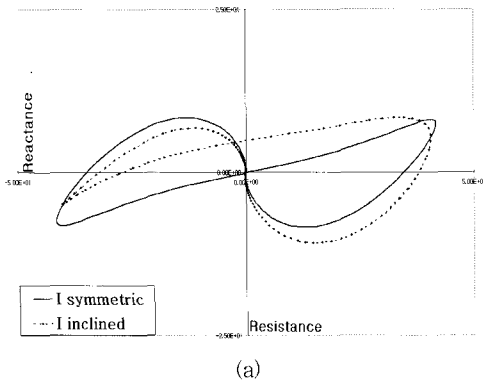


Fig. 3 ECT signals simulated from 5 types of flaws with the test frequency of 400 kHz (a) for flaws with I-shaped cross-sections, and (b) for flaws with V-shaped or K-shaped cross-sections

이 와전류 형상인식 기법의 신뢰도를 결정짓는 가장 중요한 요소이다. 그러나, 불행히도, 결함 인자의 변화에 민감하게 변화하는 특징(feature)을 찾아내기 위해 적용되는 일반적인 원칙이 아직까지 정립되지 않은 상태이기 때문에, 주어진 문제에 따라 적절히 대처해야 한다. 따라서, 이러한 특징추출의 문제를 해결하기 위해, 본 연구에서는 와전류 결함신호로부터 유용한 특징을 탐색하는 것을 도와주며, 정의된 특징을 자동으로 추출해 주는 “와전류 특징추출 프로그램”을 자체적으로 제작하였다.

Fig. 4에 나타난 대로, 이 프로그램은 같은 화면상에 결함 단면의 형상과 결함 신호(지향 성분, 리액턴스 성분, 임피던스 평면상의 궤적)를 동시에 표시하여, 사용자가 결함 형상 인자의 변화에 따른 결함 신호의 변화 양상을 쉽게 파악할 수 있는 환경을 제공한다. 이러한 환경 속에서 사용자는 결함 인자 변화에 따른 신호의 변화 양상을 가장 잘 기술하는 특징을 효과적으로 탐색할 수 있다. 또한, 이 프로그램은 사용자에게 의해 정의된 특징을 실시간으로 추출하여 그 값을 같은 화면에 표시함으로써, 결함 인자 변화에 따른 특징값의 변화를 쉽게 파악할 수 있도록 도와준다.

본 연구에서는 이 프로그램을 이용하여, 결함 단면의 변화에 따른 신호의 변화 양상을 면밀히 분석하였다. 그 결과, 앞에서 언급한 대로, 비대칭 단면의 결함의 경우에는 임피던스 평면상의 “교점(cross point)”이 원점에서 이격되는 현상이 나타나는데, 이를 정량적으로 기술할 수 있는 인자로서 교점의 크기와 위상각을 선택하였다. 그리고, 기존의 연구[1,2]에서 사용했던 특징 집합에 교점에 관한 특징을 추가하여 본 연구에서 사용한 총 18개의 특

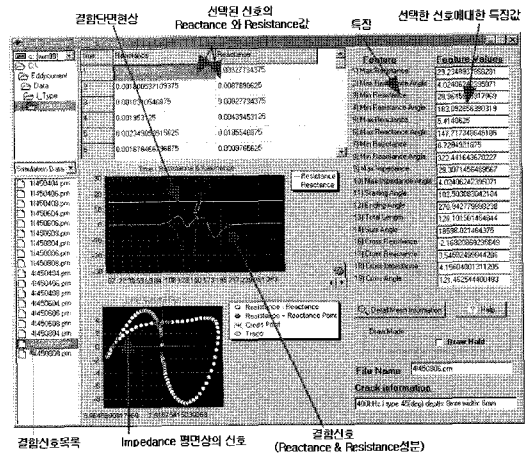


Fig. 4 The eddy feature extraction program

징을 Table 2와 같이 정의하였다. Fig. 5는 Table 2에 열거한 특징의 정의를 도식적으로 나타내었다.

4. 특징선택

일반적으로 결함 신호로부터 추출한 특징이 모두 결함 인자의 결정에 유용한 것이 아니기 때문에, 결함 인자의 결정에 유용한 특징을 선택하는 일이 필요하다. 본 연구에서는 Fig. 1에 나타난 5가지 종류의 결함을 분류하는 것이 목적이기 때문에, Table 2에 나타난 18개의 특징 중 결함 분류에 유용한 특징의 선택을 시도하였다. 추출한 특징의 결함 분류에의 유용성은 결함종류 판별 능력과 독립성이라는 두 개의 기준에 의해 정량적으로 평가 될 수 있다[1,2]. 결함 종류 판별 능력은 특징의 결함분류에의 효용성을 나타내는 척도로서 '단일특징분류성능(single feature classification performance)'으로 정량화 시킬 수 있다. 그리고 독립성은 주어진 특징 집합 내에서 특징이 제공하는 정보의 중복을 나타내는 척도로서 특징간의 '선형상관계수'로 정량화 시킬 수 있다. 따라서, 특징선택을 위해서는 분석 대상이

Table 2 Features extracted from ECT signals

Feature	
F1. Max Resistance	F10. Max Impedance Angle
F2. Max Resistance Angle	F11. Starting Angle
F3. IMax Resistance - Min Resistance	F12. Ending Angle
F4. Min Resistance Angle	F13. Total Length
F5. Max Reactance	F14. Sum Angle
F6. Max Reactance Angle	F15. Cross Resistance+10
F7. IMax Reactance - Min Reactance	F16. Cross Reactance+10
F8. Min Reactance Angle	F17. Cross Impedance
F9. Max Impedance	F18. Cross Impedance Angle

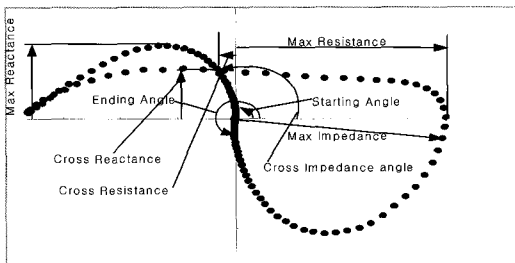


Fig. 5 Schematic representation of the definition of features

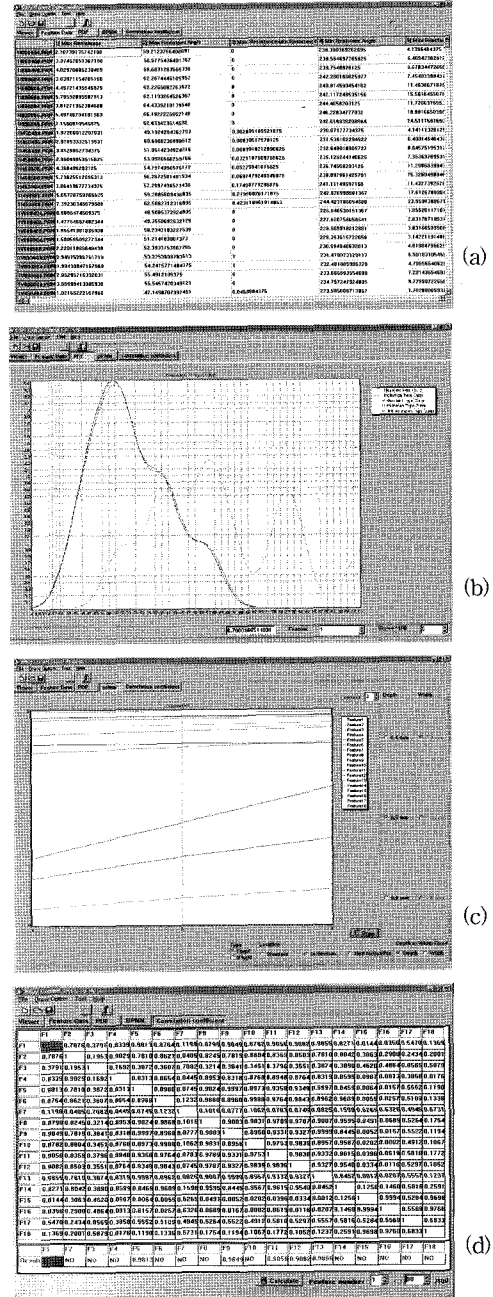


Fig. 6 The eddy current feature analysis program. (a) Table of extracted feature values, (b) Probability density functions and the single feature classification performance, (c) Sensitivity to flaw size parameters, and (d) Linear correlation coefficients among features

되는 데이터베이스 내의 모든 결합신호로부터 특징을 추출한 후, 각 특징에 대한 단일특징분류성능과 특징간의 선형상관계수를 계산해야 한다.

이러한 작업을 많은량의 결합신호를 대상으로 일괄적으로 처리하기 위하여, 본 연구에서는 ‘와전류 특징분석 프로그램’을 개발하였다. 이 프로그램은 분석 대상이 되는 데이터베이스를 사용자가 지정하면, 그 데이터베이스에 속한 모든 결합 신호로부터 Table 2에 정의된 18개의 특징을 자동으로 추출하여, Fig. 6 (a)에 나타난 것과 같이 표로 정리한다. 그리고, 추출한 특징값에 Parzen window 기법[3]을 적용하여 Fig. 6 (b)에 나타난 바와 같이 분석 대상 특징에 대한 결합 종류별 확률밀도함수(Fig. 6 (b)의 그래프)를 추정하고, 그로부터 그 특징에 대한 단일특징분류성능(Fig. 6 (b) 하단의 숫자)을 산출한다. 또한, 결합의 크기 인자 변화에 따른 각 특징값의 변화 추이를 Fig. 6 (c)에 나타난 바와 같이 자동적으로 출력한다. 물론, 이 특징 변화 추이는 결합의 분류를 위한 특징 선택에는 사용되지 않으나, 결합의 크기 산정을 위한 특징 선택에는 매우 유용하게 사용된다. 마지막으로, 모든 특징들 간의 선형상관계수를 계산하여 Fig. 6 (d)에 나타난 것처럼 표로 표시해 주기 때문에, 결합분류를 위한 특징 선택에 유용하게 이용할 수 있다.

Table 3은 Fig. 6에 나타난 ‘와전류 특징분석 프로그램’을 이용하여, 본 연구에서 생성한 90개의 결합신호를 분석하여 얻은 18개 특징의 단일특징분류성능을 시험주파수별로 요약하여 보여주고 있다. 이 표를 보면, 본 연구에서 생성한 비대칭 단면 결합신호에서 추출한 특징들에 대한 단일특징분류성능이 너무 낮음을 알 수 있다. 따라서, 본 연구에서는 분류성능이 탁월한 몇 개의 특징만을 선택하여 사용하는 대신에, Table 2에 나타난 18개 특징을 모두 사용하였다.

Table 3 Single feature classification performances

100kHz				400kHz			
Feature	SFCP (%)	Feature	SFCP (%)	Feature	SFCP (%)	Feature	SFCP (%)
F1	3.12	F10	6.09	F1	1.80	F10	34.46
F2	23.64	F11	1.20	F2	8.16	F11	3.46
F3	37.22	F12	1.21	F3	33.18	F12	0.85
F4	4.48	F13	1.22	F4	5.46	F13	1.74
F5	1.61	F14	4.28	F5	11.67	F14	5.84
F6	5.61	F15	5.17	F6	12.88	F15	18.37
F7	16.26	F16	4.94	F7	34.97	F16	11.45
F8	3.25	F17	35.44	F8	5.49	F17	31.32
F9	1.33	F18	30.12	F9	2.22	F18	26.70

* SFCP: single feature classification performance

5. 확률신경회로망을 이용한 결합분류

5.1. 확률신경회로망(Probabilistic Neural Network, PNN)의 학습

‘와전류 특징분석 프로그램’을 사용하여 선택한 특징(각 주파수별로 18개, 총 36개)들을 입력으로 하여 결합의 종류를 판별하는 지능형 분류기를 Fig. 7에 도식적으로 나타난 확률신경회로망을 사용하여 구성하였다. 본 연구에서는 모두 3가지 확률신경회로망을 구성하였는데, 1) 첫째는, 주어진 결합신호를 Fig. 1에 도시한 5가지 범주의 결합 중 하나로 분류(Case 1)하는 PNN을 구성하고, 2) 둘째는, Fig. 1에 나타난 5가지 범주를 단면의 대칭성의 관점에서 3개의 범주(“Symmetric”, “Inclined”와 “K”)로 재편하고 주어진 시험신호로부터 결합의 종류를 이 3가지 범주 중 하나로 결정(Case 2)하는 PNN, 그리고, 3) 마지막으로, Case 1의 5가지 결합 범주를 결합 선단(tip)의 침도(sharpness)를 고려하여 2가지 범주(“I-shape”과 “V-shape”)로 재편하고, 시험신호의 결합을 이 두 범주 중 하나로 결정(Case 3)하는 PNN을 각각 구성하였다. 이들 세 가지 PNN의 입력층의 노드는 모두 36개이며, 패턴층의 노드는 학습표본의 수인 90개, 그리고, 합산층과 출력층의 노드 수는 Case 별로 주어진 문제의 범주수인 5, 3, 2로 각각 설정하였다. 패턴층 노드 내의 전달함수인 지수함수의 평활화 계수는 0.1로 취하였다. 그리고, 이들 3개의 PNN은 Table 1에 나타난 90개의 학습표본을 이용하여 학습시켰다.

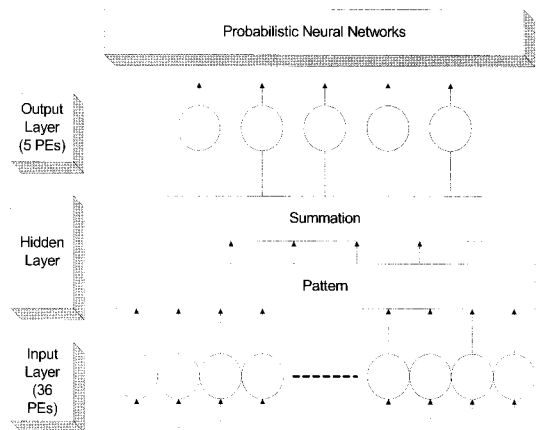


Fig. 7 Schematic representation of PNNs

5.2. 결함분류 성능

PNN의 학습이 완료되면, 주어진 시험신호에 대해 결함분류를 실시하고 그 결과를 얻을 수 있다. 본 연구에서는 결함분류 결과를 사용자에게 편리하게 제공하기 위하여 C++ 프로그래밍 언어로 Fig. 8에 나타낸 'PNN 결함분류 프로그램'을 개발하였다. 이 프로그램은 결함분류를 위한 결함신호가 입력되면, 입력 신호로부터 결함분류에 사용될 특징을 자동으로 추출하고, 추출한 특징값을 내장된 PNN에 입력하여, 출력으로서 각 범주별 사후확률을 계산하고 이를 막대그래프로 나타내 준다. 따라서, 이 프로그램을 이용하면, 사용자는 시험표본이 속할 것으로 추정되는 범주뿐만 아니라, 그 추정에 대한 신뢰도에 대한 정보도 사후확률로서 얻을 수 있다.

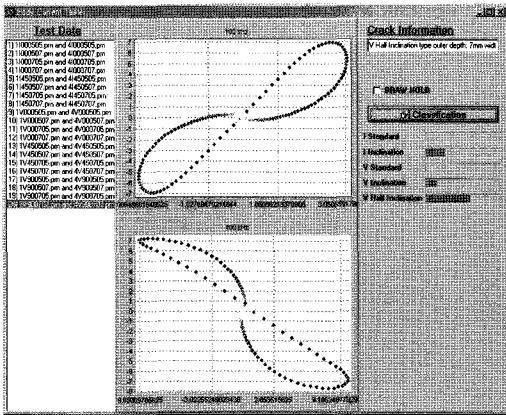


Fig. 8 The flaw classification program using PNNs

Table 4는 Fig. 8에 나타낸 결함분류 프로그램을 이용하여 Table 1에 나타낸 시험표본 40개에 대한 결함분류를 수행한 결과를 요약하여 나타내었다. 5.1에서 언급한 학습이 완료된 PNN은 Case1의 5 범주에서 55%의 정확도를, Case 2의 3 범주에서 90%의 정확도를, 그리고, Case 3의 2 범주 문제에서 65%의 정확도를 보여주었다.

이 결과는 PNN 분류기가 결함단면의 대칭성 여부를 결정하는 문제(Case 2)에서는 우수한 성능을 보여주고 있으나, 결함선단의 침도를 판단하는 문제(Case 3)에서는 성능이 급격히 저하됨을 보여 준다. 이러한 성능의 차이는 PNN 분류기에 사용된 특징에 기인한 것으로 판단된다. 본 연구에서 추출한 특징 중 “교점”에 대한 4개의 특징(Table 2의 F15부터 F18까지)들은 모두 결함 단면의

대칭성에 매우 민감하기 때문에, 이들을 이용하면 단면의 대칭 여부를 정확히 판단할 수 있다. 본 연구에서 사용한 특징 집합중 결함단면의 침도의 변화에 민감한 특징이 없기 때문에 PNN을 사용한 경우에는 Case 3의 정확성이 낮은 것으로 판단되며, 이를 위해서는 BPNN과 같은 다른 분류기를 사용하면 정확도가 향상될 것으로 기대된다.

Table 4 Performance of the PNN classifiers

	Classes	Performance
Case 1	5: I-Symmetric, I-Inclined, V-Symmetric, V-Inclined, K	55%
Case 2	3: Symmetric, Inclined, K	90%
Case 3	2: I, V	65%

- * Case 1: 5-class problem
- * Case 2: 3-class problem
- * Case 3: 2-class problem

6. 결 론

증기발생기 세관에 발생하는 실제적인 결함을 보다 사실적으로 모사하는 다섯 가지 형태의 외벽 결함을 선택하고, 이들 결함의 크기 인자와 시험주파수를 변화시켜 가면서, 총 130개의 결함신호를 이전 연구에서 사용한 유한요소 수치해석 프로그램을 이용하여 생성하였다. 자체적으로 개발한 ‘와전류 특징추출 프로그램’, ‘와전류 특징 분석 프로그램’, 그리고 ‘PNN 결함분류 프로그램’을 사용하여 결함신호를 분석하였다.

- 1) 비대칭 단면을 갖는 결함의 신호에서는 대칭형태의 단면을 갖는 결함신호에서는 보이지 않던 ‘교점의 이격’이라는 새로운 현상이 관찰되어 이러한 특성을 반영하는 특징 4개를 새로 정의하고, 이전 연구에서 사용했던 특징 집합에 추가하여 총 18개의 특징을 시험주파수 별로 정의하였다.
- 2) 그리고, 추출한 특징들의 단일특징분류성능과 특징간의 선형상관계수를 기준으로, 결함분류에 유용한 특징의 선택을 시도하였으나, 특징들의 단일성능분류성능이 너무 낮아, 본 연구에서는 정의한 18개의 특징을 모두 사용하였다.
- 3) PNN을 사용하여 그 성능을 검증한 결과, 5 가지 범주 문제에서는 55%의 정확도를, 결함단면의 대칭성 여부를 결정하는 3가지 범주 문제에서는 90%의 정확도를, 그리고, 결함선단의 침도를 판단하는 2가지 범주 문제

에서는 65%의 정확도를 얻었다. 이러한 성능의 차이는 PNN 분류기에 사용된 특징에 기인한 것으로 PNN을 사용하여 단면의 대칭 여부를 정확히 판단할 수 있었으나 결함단면의 침도변화를 판단하기에는 미흡하였다. 이를 해결하기 위해서는 BPNN과 같은 새로운 분류기를 사용할 필요가 있다.

참고문헌

- [1] 송성진, 박홍준, 신영길, "신경회로망을 이용한 와전류 결함 특성 평가", 비파괴검사학회지, Vol. 18, pp. 464-475, (1998)
- [2] S. J. Song and Y. K. Shin, "Eddy current Flaw characterization in tubes by neural networks and finite element modeling", NDT& E International, Vol. 33, pp. 233-243, (2000)
- [3] R. O. Duda and P. E. Hart, "Pattern Classification and Science Analysis", John Wiley & Sons, New York, (1973)
- [4] D. F. Specht, "Probabilistic neural networks for classification, mapping, or associative memory," Proceedings of the IEEE International Conference on Neural Networks, Vol. 1. pp. 525-532, (1998)
- [5] D. F. Specht, "Enhancements to probabilistic neural networks," Proceedings of the IEEE International Joint Conference on Neural Networks, Vol. 1, pp. 761-768, (1992)
- [6] D. E. Rumelhart, G. E. Hinton, and R.J. Williams, "Learning internal representations by error propagation", in Parallel Distributed Processing: Exploration in the Microstructure of Cognition, ed. D. E. Rumelhart, J.L. McClelland, and the PDP Research Group, ed. MIT Press, Cambridge, MA, pp. 318-362, (1986)
- [7] 신영길, "와전류 탐상신호 예측을 위한 3차원 수치해석 프로그램 확립", 기초전력공학공동연구소 최종보고서, (1999)
- [8] L. Udpa and S. S. Udpa, "Eddy current defect characterization using neural Networks," Materials Evaluation, Vol. 48, pp. 342-347,353, (1990)
- [9] M. T. Shyamsunder, C. Rajagopalan, B. Raj, S. K. Dewangan, B. P. C. Rao, and K. K. Ray, "Pattern Recognition Approaches for the Detection and Characterization of Discontinuities by Eddy Current Testing," Materials Evaluation, Vol. 58, pp. 93-101, (2000)