

## 적응형 신호 형상 인식 프로그램 개발과 AE법에 의한 용접부 결함 분류에 관한 적용 연구

이강용\*, 임장목\*, 김준섭\*\*

\* 연세대학교 기계공학과

\*\* 생산기술연구원

요 약 음향 방출 신호의 수집 및 처리, 특징값 추출 및 선택, 분류기 설계 및 검증 과정 등을 수행할 수 있는 신호 형상 인식 프로그램을 개발하고, 이를 오스테나이트계 STS304 용접부의 인공 결함 분류 연구에 적용하였다. 특히 분류기로는 선형 함수 분류기, 경험적 Bayesian 분류기, 신경 회로망 분류기를 사용하였고, 센서는 광대역 센서와 공진형 센서를 사용하여 분류기간의 비교와 센서간의 차이점을 검토하였다. 그 결과 신경 회로망 분류기가 다른 분류기에 비해 높은 인식률을 주었고, 공진형 센서보다는 광대역 센서를 통해 받은 신호가 더 높은 인식률을 주었다.

### 1. 서 론

신호 형상 인식법과 관련된 연구로는 Ono<sup>1)</sup>가 섬유 강화 복합재(fiber reinforced resin composites)에서 나타나는 미세 파단 기구 규명에 형상 인식 분석(pattern recognition analysis, PRA) 기법을 사용하였고, Maslouhi와 Roy<sup>2)</sup>는 CFRP 인장 시험에서 얻어진 AE 신호를 시간 영역과 주파수 영역에서 얻어진 17개의 특징값을 가지고 형상 인식 기법을 사용하여 발생원 분류를 시도하였다. 그리고 Majeed와 Murthy<sup>3)</sup>는 네 가지의 간단한 분류 모델에 대하여 형상 인식 기법의 새로운 방법론을 제시한 바 있고, Bentley와 Beesley<sup>4)</sup>는 자연 결함을 가진 PWR(pressurized water reactor) 용접부에 항복 하중을 가하여 받은 AE 신호를 통계적 분류기를 이용함으로써 외부 소음과 구별할 수 있고 결함끼리 분류할 수 있는 가능성을 제시하였다. 그리고

Buttle과 Scruby<sup>5,6)</sup>는 알루미늄 합금의 피로 실험에서 얻어진 AE 신호를 리벳 부분의 침식 등 다른 원인으로부터 기인한 신호와 구별했다.

이와 같이 그 유용성이 입증된 신호 형상 인식법에 음향 방출법을 적용함으로써 기존의 방법으로는 접근할 수 없던 분야에 대한 연구가 가능해질 수 있다. 특히 오스테나이트 스테인레스 강을 용접하여 구성된 구조물에 대한 결함 검출이 그 일례이다. 오스테나이트 스테인레스 강의 용접부는 용접을 행한 후 서서히 냉각되면서 큰 주상정 모양의 조직을 발생시키는데 이 조직은 이방성을 가지게 된다. 이에 따라 AE 신호의 감쇠, 흡수, 산란, 모드 변환 등을 유발시키므로 결함을 검출하는데 있어 심각한 장애 요인이 된다. 그러나 조사된 바에 의하면 AE 신호 형상 인식법에 의해 오스테나이트 스테인레스 강의 용접 부위에서 발생하는 균열이나 기공과 같은 결함을 분류하거나 결함의 정성적인 정도를 판

악한 연구는 진행된 바 없다. 이러한 이유로 본 연구에서는 오스테나이트 스테인레스 강의 용접부 인공 결함으로부터 발생한 AE 신호를 처리하기 위한 다양한 디지털 신호 처리 프로그램과 처리된 신호로부터 많은 신호 특징들을 뽑아 내고 이들을 통계적으로 처리하여 신호를 분류하는 신호 처리 프로그램을 개발하고 그 유용성을 입증하고자 한다. 특히 신호 분류를 위한 분류기로 선형 분류기, 경험적 Bayesian 분류기와 신경 회로망 분류기를 이용한다.

**2. 신호 형상 인식 프로그램**

본 연구에서 개발된 신호 형상 인식 프로그램은 borland C++로 작성하였으며 전체적인 구성은 데이터 수집, 데이터 변환, 특징값 추출, 특징값 선택, 분류기 선택 및 설계, 그리고 미지 신호에의 검증 과정으로 나눌 수 있다. 각각의 구성에 대해 살펴보면 다음과 같다.

데이터 수집(data acquisition) 과정은 검출하고자 하는 계(mechanism)를 가장 잘 표현할 수 있는 현상을 센서(sensor)를 통하여 얻고 이를 디지털화하여 PC에 저장한 후 이 신호를 본 연구에서 개발한 프로그램에 맞게 바꾸어 주도록 하였다, 이때 필요 없는 부분의 신호는 제거할 수 있도록 하였고 각각의 계에서 받은 신호를 구분하기 위하여 화일 이름에 번호를 추가시키도록 하였다.

데이터 변환(data transformation) 과정은 앞에서 얻은 시간축 상의 데이터로부터 얻을 수 없는 정보를 적절히 가공함으로써 얻을 수 있다는 것으로, 본 연구에서는 시간 영역 외에 포락선 영역, 주파수 영역, 자기 상관 함수 영역, 변형된 자기 상관 함수 영역 등 다섯 가지의 영역을 사용하여 주파수 영역을 제외한 나머지 4개의 영역에서는 각각 25개의 특징값을 추출할 수 있도록 하였고 주파수 영역에서는 31개의 특징값을 추출해서 모두 131개의 특징값을 사용할 수 있게 하였다. 이 중에서 일례로 시간 영역에서의 특징값을 Table 1에 제시하고 있다.

그리고 특징값 추출(feature extraction) 과정에서 특징값을 추출하기 위해서는 각 영역에서 여러 가지 파라미터가 필요한데 이를 사용자가 결정할 수 있게 만들었다. 앞에서 얻은 여러 가지 영역 상의

데이터로부터 신호 특징값들을 추출하여 정량화하고 정규화 하는 과정으로 분석을 위한 데이터 감소의 효과가 있다.

특징값 선택(feature selection) 과정에서는 앞의 과정에서 추출한 131개의 특징값을 모두 쓰지 않고 분류를 잘 해줄 수 있는 특징값만을 선택하여 분류기를 설계하므로 이 특징값들의 순위를 계산하여 상위 특징값중 사용자가 임의로 선택할 수 있게 하였다. 이는 분류에 필요한 데이터의 양을 더욱 줄이는 효과가 있다. 이러한 순위를 매기는 방법으로 본 연구에서는 Fisher의 가중치 원리<sup>7)</sup>와 함께 하

Table 1. Feature parameters in original time domain as an example.

Number	Feature parameter
1	total power
2	total mean level
3	total variance
4	total skewness
5	total kurtosis
6	number of peaks exceeding a present threshold
7	ratio of the power above 90% and 10% threshold
8	ratio of the power above 50% and 10% threshold
9	ratio of the power above 90% and 50% threshold
10	pulse duration of largest pulse
11	rise time of largest pulse
12	decay time of largest pulse
13	peak duration
14	largest pulse area
15	energy of largest pulse
16	first amplitude moment of largest pulse
17	first energy moment of largest pulse
18	second amplitude moment of largest pulse
19	second energy moment of largest pulse
20	rise slope of largest pulse
21	decay slope of largest pulse
22	mean of largest pulse
23	variance of largest pulse
24	skewness of largest pulse
25	kurtosis of largest pulse

면에 표시되는 특징값-특징값 선도에서 분류도가 좋은 특징값을 직접 선택할 수 있도록 하였다.

분류기 선택 및 설계(classifier design) 과정에서는 선형 함수 분류기(linear discriminant function classifier), 경험적 Bayesian 분류기(empirical Bayesian classifier), 신경 회로망 분류기(neural network classifier)를 사용하여 분류기를 설계할 수 있도록 하였다<sup>7),8)</sup>. 신경 회로망 분류기의 경우 분류기를 설계하기 위해서는 숨은 층의 개수와 각 숨은 층의 유닛 수가 필요한데 이를 사용자가 임의 조정하여 보다 좋은 분류기를 설계할 수 있도록 하였다. 이렇게 설계된 분류기를 가지고 마지막으로 미지 신호에 적용하여 설계된 분류기를 검증하여 분류기의 타당성을 시험해 볼 수 있게 하였다. Fig. 1은 역전파법을 이용한 신경 회로망 구조의 흐름도를 나타내며, Fig. 2에서는 본 프로그램에서 사용한 모듈들을 나타낸다.

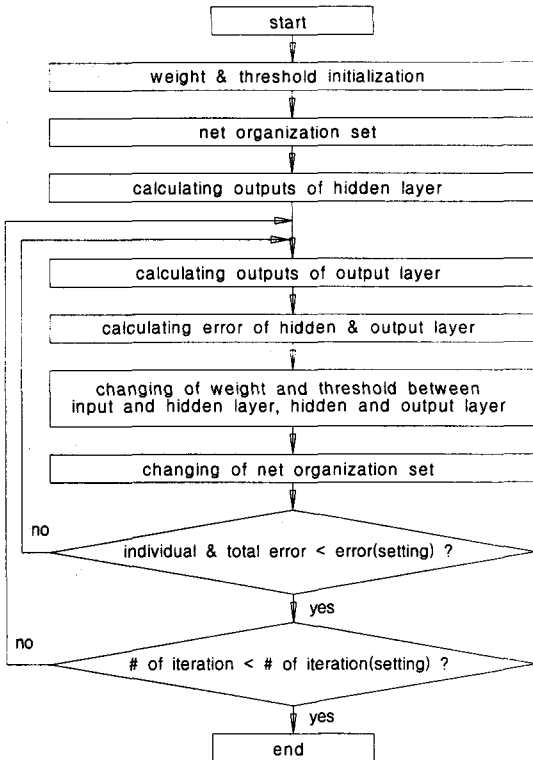


Fig. 1. Flow chart of neural network using back propagation method.

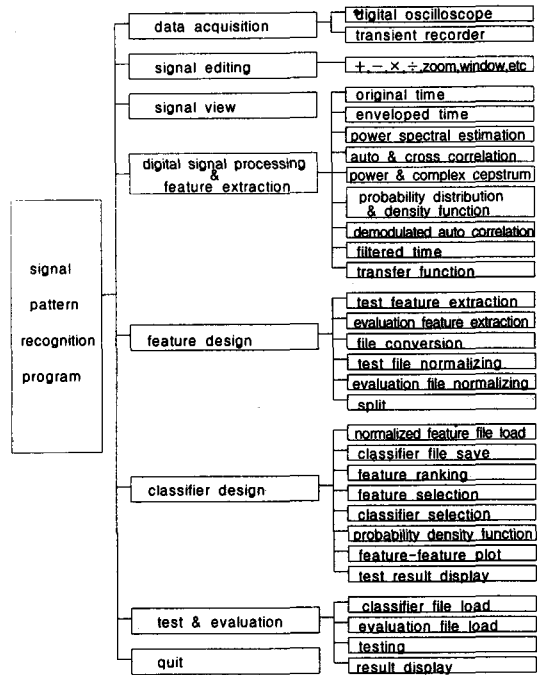


Fig. 2. Program modules of signal pattern recognition program.

### 3. 실험

#### 3.1. 시편 제작

시편 재료는 오스테나이트계 STS304로써 화학적 조성과 물리적 특성은 Table 2와 Table 3과 같다.<sup>9)</sup> 이 재료의 용접할 부분에 깊이 10mm, 60도 각도의 V 홈을 관 후 아아크 용접법에 의해 용접하였으며, 용접을 행한 후에 연삭기를 이용하여 양측 면을 약 2mm씩 깎아 내어 균일한 8mm 두께의 용접면을 이루도록 하였다. 또한 결함 부분에 집중 하중이 가해질 수 있도록 집중 하중이 작용하는 중앙부 양측면에 반지름 7.5mm로 노치 가공을 하였다. 그 후 방전 가공을 하여 인공 결함의 종류에 따라 무결함 시편 1개, 구멍이 있는 용접 시편 2개, 노치가 있는

Table 2. Chemical compositions of STS304 stainless steel.

Material	British or other standard	Composition(wt %)				
		C	Mn	Ni	Cr	N
18/9CrNiN Steel	UK(Hi-proof 304)	0.06 max	2.00 max	8.00 11.00	17.50 19.00	0.15 0.25

용접 시편 2개, 균열이 있는 용접 시편 2개씩 모두 7개의 시편을 제작하였다. 최종 인공 결함 시편의 형상은 Fig. 3(a)~(d)와 같다.

Table 3. Material properties of STS304 stainless steel.

Material	British or other standard	Condition	Properties(minima unless otherwise stated)		
			UTS MPa (tonfin <sup>2</sup> )	Yield stress MPa (tonfin <sup>2</sup> )	Elongation %
18/9CrNiN Steel	UK(Hi-pro of 304)	Softened	585(38)	295(19)	35




Fig. 3. Welding specimens with artificial defects  
 (a) no defect, (b) cracked hole.  
 (c) notch, (d) crack

### 3. 2. 실험 장치

실험 장치와 신호 처리의 전체적인 개략도는 Fig. 4와 같다. 3점 굽힘 실험시 스패의 길이는 130mm로 하였고 인공 결함이 존재하는 부분이 아래의 중앙에 위치하도록 주의하였다. 센서는 용접부 결함의 위치에서 40mm 떨어진 부분에 위치하게 하였다.

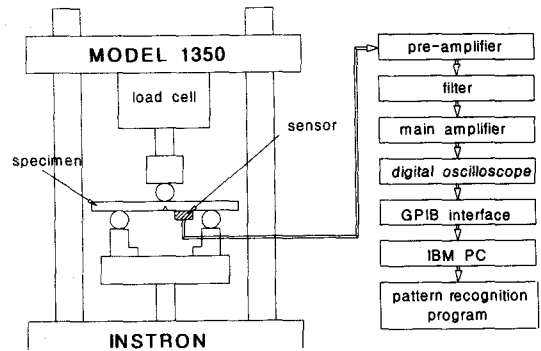


Fig. 4. Schematic diagram of experimental setup.

### 3. 3. 실험 방법

3점 굽힘 시험은 만능 재료 시험기(INSTRON, Model 1350)에 10ton의 load cell을 붙이고 변위를 제어하는 방식(stroke control)으로 진행하였다. 전체 변위가 100%일 경우 50mm를 이동하게 되므로 하중이 작용할 때의 최종 변위가 2% 정도(1mm) 되도록 변위를 제어하였다. 이때 계기판에 나타나는 하중은 약 25kgf정도가 되었다. 하중을 주는 속도는 전체 이동 변위 1mm를 움직이는데 1000초가 걸리게 하였고 센서는 주파수 범위 100~2000kHz인 광대역 센서(broadband sensor)와 175kHz 공진형 압전 센서(resonance type piezoelectric sensor) 두 가지를 사용하여 센서간의 차이를 살피는데 사용하였다. 특히 센서를 부착시킬 때에는 센서에 가해지는 표면 상태와 압력에 따라 신호가 크게 좌우되므로 센서와 시편간에 충분한 밀착이 이루어지게 하였고 일정한 압력이 센서에 가해지게 하였다. 센서를 통해 나온 신호는 30kHz ~ 2000kHz의 밴드 패스 필터(band pass filter)가 내장된 선 증폭기(pre-amplifier)에서 40dB 증폭된 후 주 증폭기(main amplifier)가 내장된 AET5500에서 다시 증폭된 후 디지털 오실로스코우

프로 들어가게 된다. 주 증폭기는 최대 40dB까지 증폭시킬 수 있지만 본 실험에서는 10% 증폭으로 고정시켰다. 디지털 오실로스코프(Tektronics사, TDS420)에 입력되는 신호는 샘플링 주파수 (sampling frequency) 500kHz로 신호당 4096개의 데이터를 받았으며, trigger level은 광대역 센서의 경우 1.30V로 공진형 센서의 경우 350mV로 하고 5%의 pre-triggering을 취하여 triggering이전의 신호를 사용할 수 있게 하였다. 이렇게 설치한 후 각 시편당 그리고 각 센서당 50개의 신호를 받아 전체 신호의 개수는 700개가 되었다.

**4. 실험 결과 및 고찰**

**4. 1. 광대역 센서를 이용한 분류기의 설계**

특징값의 우선 순위를 결정하는 방법으로 Fisher의 가중치 원리<sup>7)</sup>와 특징값-특징값 선도(feature-feature plot) 상에서 가장 좋은 분류 결과를 보이는 특징값을 선택하는 방법 등 두 가지를 병행하여 사용하였다. 그 결과 선택된 5개의 특징값을 Table 4에 그리고 각각의 특징값 중에서 일례로 두개의 특징값을 가지고 특징값-특징값 선도 상에 나타낸 그림을 Fig. 5에 나타내었다. 분류기 설계에 사용한 신경 회로망 분류기의 구조는 숨은 층 1개, 숨은 층

Table 4. Best features by Fisher's weight criterion and feature-feature plot in case of a broadband sensor.

Fisher's weight criterion		feature-feature plot	
feature number*	Fisher's weight	feature number*	Fisher's weight
3	1.115862	2	0.260519
100	0.735400	3	1.115862
27	0.653003	28	0.350179
26	0.653003	56	0.011945
1	0.628548	103	0.320270

\* feature numbers

- 1 : total power in original time domain
- 2 : total mean level in original time domain
- 3 : total variance in original time domain
- 26 : total power in enveloped time domain
- 27 : total mean level in enveloped time domain
- 28 : total variance in enveloped time domain
- 56 : ratio of the 3rd partial power and the largest partial power in frequency domain
- 100 : second energy moment of largest pulse in autocorrelation domain
- 103 : mean of largest pulse in autocorrelation domain




Fig. 5. Feature-feature plot in case of a broadband sensor as an example

(a) Features by Fisher's weight criterion, (b) Features by feature-feature plot.

Table 5. Recognition rate by Fisher's weight criterion in case of a broadband sensor.

(L.D.F.C : linear discriminant function classifier, E.B.C : empirical Bayesian classifier, N.N.C : neural network classifier) (NO : no defect, H : hole, N : notch, C : crack)

L.D.F.C						E.B.C						N.N.C								
Feature #	3					%	Feature #	3					%	Feature #	3					%
	NO	H	N	C	NO			H	N	C	NO	H			N	C				
NO	7		2	1	70		NO	7		2	1	70		NO	8		2		80	
H		10			100		H		10			100		H		10			100	
N			10		100		N			10		100		N			10		100	
C	1			9	90		C	1			9	90		C	1			9	90	
%						72.5	%						90.0	%						92.5

Feature #	3,100,27					%	Feature #	3,100,27					%	Feature #	3,100,27					%
	NO	H	N	C	NO			H	N	C	NO	H			N	C				
NO	4	1		5	40		NO	8		1	1	80		NO	10				100	
H		10			100		H		10			100		H		10			100	
N	2	1	7		70		N			10		100		N			10		100	
C	2			8	80		C	1			9	90		C	1			9	90	
%						72.5	%						92.5	%						97.5

Feature #	3,100,27,26,1					%	Feature #	3,100,27,26,1					%	Feature #	3,100,27,26,1					%
	NO	H	N	C	NO			H	N	C	NO	H			N	C				
NO	4	1		5	40		NO	8		1	1	80		NO	10				100	
H		10			100		H		10			100		H		10			100	
N	1	1	8		80		N	1		9		90		N			10		100	
C	2			8	80		C			1	9	90		C	1			9	90	
%						75.0	%						90.0	%						97.5

의 단위 수는 5개로 하였고, 각 결함당 10개씩 총 40개의 데이터를 사용하여 특징값의 개수를 1개, 3개, 5개로 증가시켜 가면서 Fisher의 원리로 설계한 분류기의 인식률을 Table 5에, 그리고 특징값-특정

값 선도에 의한 인식률 결과를 Table 6에 각각 분류기별로 제시하였다. Table 5과 Table 6에서 보는 바와 같이 특징값의 개수가 증가할수록 인식률은 대체적으로 증가함을 알 수 있고, 분류기 설계를

Table 6. Recognition rate by feature-feature plot in case of a broadband sensor.

(L.D.F.C : linear discriminant function classifier, E.B.C : empirical Bayesian classifier, N.N.C : neural network classifier) (NO : no defect, H : hole, N : notch, C : crack)

L.D.F.C						E.B.C						N.N.C					
Feature #	2					Feature #	2					Feature #	2				
	NO	H	N	C	%		NO	H	N	C	%		NO	H	N	C	%
NO	8			2	80	NO	7			3	70	NO	9			1	90
H		2	5	3	20	H		1	5	4	10	H			7	3	0
N		3	6	1	60	N		1	8	1	80	N			9	1	90
C	1		1	8	80	C	1		1	8	80	C	3		1	6	60
%					60.0	%					60.0	%					60.0

L.D.F.C						E.B.C						N.N.C					
Feature #	2,3,28					Feature #	2,3,28					Feature #	2,3,28				
	NO	H	N	C	%		NO	H	N	C	%		NO	H	N	C	%
NO	10				100	NO	9		1		90	NO	8		1	1	80
H		10			100	H		10			100	H		6	4		60
N			10		100	N			10		100	N			10		100
C				10	100	C	1			9	90	C				10	100
%					100	%					95.0	%					85.0

L.D.F.C						E.B.C						N.N.C					
Feature #	2,3,28,56,103					Feature #	2,3,28,56,103					Feature #	2,3,28,56,103				
	NO	H	N	C	%		NO	H	N	C	%		NO	H	N	C	%
NO	5	1		4	50	NO	10				100	NO	9		1		90
H		10			100	H		9	1		90	H		10			100
N		1	9		90	N			10		100	N			10		100
C	3			7	70	C	1			9	90	C				10	100
%					77.5	%					95.0	%					97.5

위한 특징값의 결정 방법 중에는 Fisher의 원리보다는 특징값-특징값 선도 상에서 찾은 특징값이 더 좋은 인식률을 보여준다는 것을 알 수 있다. 그리고 분류기간의 비교에서는 선형 분류 함수나 경험적

Bayesian 분류기보다는 신경 회로망 분류기가 더 높은 인식률을 보여주고 있다. 그리고 Table 7에서 설계된 분류기에 미지 신호 20개씩을 적용하여 검증한 결과 좋은 인식률을 보였음을 알 수 있다.

Table 7. Evaluation of neural network classifier in case of a broadband sensor

(NO : no defect, H : hole, N : notch, C : crack)

(a) Fisher's weight criterion,

(b) Feature-feature plot

Feature #	3,100,27,26,1				
	NO	H	N	C	%
NO	20				100
H		20			100
N		1	19		95
C	2			18	90
%					96.25

Feature #	2,3,28,56,103				
	NO	H	N	C	%
NO	19		1		95
H		20			100
N		1	19		95
C	1			19	95
%					96.25

(a)

(b)

4.2. 공진형 센서를 이용한 분류기의 설계

4.1절에서와 마찬가지로 Fisher의 원리와 특징값-특징값 선도를 사용해 선택한 5개의 특징값을 Table 8에, 그리고 일례로 선택된 2개의 특징값을 가지고 특징값-특징값 선도에 나타낸 그림을 Fig. 6에 나타내었다. 그리고 특징값의 개수를 1개, 3개, 5개로 증가시키면서 Fisher의 원리로 설계한 분류기의 인식률을 Table 9에, 그리고 특징값-특징값 선도에 의한 인식률 결과를 Table 10에 각각 분류기별로 제시하였다. 그리고 Table 11에는 설계된 분류기에 미지 신호 20개씩을 적용하여 검증한 결과 여기에서도 좋은 인식률을 나타냄을 알 수 있다.

여기에서도 마찬가지로 특징값의 개수가 증가할수록 인식률은 대체적으로 증가하고 특징값 결정 방법에서는 특징값-특징값 선도가 더 나은 결과를 주며 신경 회로망 분류기가 더 높은 인식률을 나타냄을 알 수 있다. 센서간의 비교에서는 광대역 센서가 더 나은 인식률을 나타내었다.

Table 8. Best features by Fisher's weight criterion and feature-feature plot in case of a resonance type sensor.

Fisher's weight criterion		feature-feature plot	
feature number*	Fisher's weight	feature number*	Fisher's weight
59	0.529660	3	0.004045
85	0.322787	52	0.196993
86	0.292697	54	0.089003
52	0.196993	85	0.322787
58	0.140067	74	0.000044

\* feature numbers

- 3 : total variance in original time domain
- 52 : 2nd partial power in frequency 0.25MHz band in frequency domain
- 54 : ratio of the largest partial power and the total power in frequency domain
- 58 : total mean level in frequency domain
- 59 : total variance in frequency domain
- 74 : second amplitude moment of largest pulse in frequency domain
- 85 : total skewness in autocorrelation domain
- 86 : total kurtosis in autocorrelation domain




Fig. 6. Feature-feature plot in case of a resonance type sensor as an example.

(a) Features by Fisher's weight criterion, (b) Features by feature-feature plot



Table 9. Recognition rate by Fisher's weight criterion in case of a resonance type sensor  
 (L.D.F.C : linear discriminant function classifier, E.B.C : empirical Bayesian classifier,  
 N.N.C : neural network classifier) (NO : no defect, H : hole, N : notch, C : crack)

L.D.F.C						E.B.C						N.N.C					
Feature #	59					Feature #	59					Feature #	59				
	NO	H	N	C	%		NO	H	N	C	%		NO	H	N	C	%
NO	3	3	2	2	30	NO	2	3	2	3	20	NO		3	7	0	
H		5	2	3	50	H	6	1	2	1	10	H		3	7	0	
N		1	9		90	N	1		9		90	N		9	1	90	
C	2	2		6	60	C	2	1		7	70	C			10	100	
%					57.5	%					47.5	%					47.5

Feature #	59,85,86					Feature #	59,85,86					Feature #	59,85,86				
	NO	H	N	C	%		NO	H	N	C	%		NO	H	N	C	%
NO	10				100	NO		6	4		0	NO	7	2	1	70	
H	4	5		1	50	H		5	3	2	50	H		6	3	60	
N	3		6	1	60	N		1	8	1	80	N	1		9	90	
C		2	1	7	70	C				10	100	C				10	100
%					70.0	%					57.5	%					80.0

Feature #	59,85,86,52,58					Feature #	59,85,86,52,58					Feature #	59,85,86,52,58				
	NO	H	N	C	%		NO	H	N	C	%		NO	H	N	C	%
NO	10				100	NO	7	2	1		70	NO	10			100	
H	4	5		1	50	H	1	5	4		50	H	1	5	4	50	
N	3		6	1	60	N		2	8		80	N			10	100	
C		1	2	7	70	C				10	100	C				10	100
%					70.0	%					75.0	%					87.5

Table 10. Recognition rate by feature-feature plot in case of a resonance type sensor

(L.D.F.C : linear discriminant function classifier, E.B.C : empirical Bayesian classifier,  
N.N.C : neural network classifier) (NO : no defect, H : hole, N : notch, C : crack)

L.D.F.C

E.B.C

N.N.C

Feature #	3				
	NO	H	N	C	%
NO	9	1			90
H		6	3	1	60
N		3	1	6	10
C		1	3	6	60
%					55.0

Feature #	3				
	NO	H	N	C	%
NO	10				100
H		8	1	1	80
N		4		6	0
C		2	5	3	30
%					52.5

Feature #	3				
	NO	H	N	C	%
NO	10				100
H		6		4	60
N		3		7	0
C		1		9	90
%					62.5

Feature #	3,52,54				
	NO	H	N	C	%
NO	10				100
H		8	2		80
N		4	5	1	50
C		1		9	90
%					80.0

Feature #	3,52,54				
	NO	H	N	C	%
NO	10				100
H		6	3	1	60
N		2	6	2	60
C			1	9	90
%					77.5

Feature #	3,52,54				
	NO	H	N	C	%
NO	10				100
H		5	5		50
N			9	1	90
C			1	9	90
%					82.5

Feature #	3,52,54,85,74				
	NO	H	N	C	%
NO	9		1		90
H		4	5	1	40
N		1	8	1	80
C			3	7	70
%					70.0

Feature #	3,52,54,85,74				
	NO	H	N	C	%
NO	10				100
H	1	7	2		70
N		3	6	1	60
C			1	9	90
%					80.0

Feature #	3,52,54,85,74				
	NO	H	N	C	%
NO	10				100
H		7	2	1	70
N			10		100
C				10	100
%					92.5

Table 11. Evaluation of neural network classifier in case of a resonance type sensor.

(NO : no defect, H : hole, N : notch, C : crack)

(a) Fisher's weight criterion,

(b) Feature-feature plot

Feature #	59,85,86,52,58				
	NO	H	N	C	%
NO	20				100
H	5	11		2	55
N	1	11	8		40
C				15	75
%					67.5

(a)

Feature #	3,52,54,85,74				
	NO	H	N	C	%
NO	19			1	95
H		8		12	40
N		4	16		80
C				20	100
%					78.75

(b)

5. 결론

AE 신호 형상 인식 프로그램을 개발하고 이를 오스테나이트계 STS304 용접부 인공 결함 분류에 적용한 결과 다음과 같은 결과를 얻었다.

- 1) 개발된 프로그램으로 오스테나이트계 STS304 용접부의 인공 결함을 효과적으로 분류한다.
- 2) 결함을 분류하기 위한 특징값의 우선 순위를 정하는데 있어서 Fisher의 가중치 원리보다는 특징값-특징값 선도에서 결정한 특징값에 의한 분류기가 더 높은 인식률을 보여 준다.
- 3) 공진형 센서를 통해 받은 신호보다 광대역 센서를 통해 받은 신호가 인식률이 더 높다.
- 4) 선형 분류기, 경험적 Bayesian 분류기보다 신경 회로망 분류기를 사용하였을 경우가 더 높은 인식률을 보여 준다.

후 기

본 연구는 '94년도 한국 과학 재단 연구비 지원 (과제 번호 941-1000-017-2)에 의한 결과임을 밝히며 이에 감사드립니다.

참고 문헌

- 1) Kanji Ono, "Pattern Recognition Analysis of Acoustic Emission Signals", Progress in Acoustic Emission VII, (1994), pp. 69-78.
- 2) A. Maslouhi and C. Roy, "Analysis of AE signals in Time and Frequency Domains Coupled to Pattern Recognition to Identify Fracture Mechanisms in CFRP", J. of Acoustic Emission, Vol. 9, No. 1, (1990), pp. 9-16.
- 3) M. A. Majeed and C. R. L. Murthy, "An Efficient Unsupervised Pattern Recognition Procedure for Acoustic Emission Signal Analysis", J. of Acoustic Emission, Vol. 8, No. 1/2, (1989), pp. S16-S19.
- 4) P. G. Bentley and M. J. Beesley, "Acoustic Emission Measurements on PWR Weld Material with Inserted Defects using Advanced Instrumentation", J. of Acoustic Emission, Vol. 7, No. 2, (1988), pp. 59-79.
- 5) D. J. Buttle and C. B. Scruby, "Characterization of Fatigue of Aluminum Alloys by Acoustic Emission, Part I - Identification of Source Mechanism", J. of Acoustic Emission, Vol. 9, No. 4, (1990), pp. 243-254.
- 6) D. J. Buttle and C. B. Scruby, "Characterization of Fatigue of Aluminum Alloys by Acoustic Emission, Part II - Discrimination between Primary and Other Emissions", J. of Acoustic Emission, Vol. 9, No. 4, (1990), pp. 243-254.
- 7) R. J. Schalkoff, Pattern Recognition : Statistical, Structural and Neural Approach, John Wiley & Sons, (1992).
- 8) T. Y. Young and King-Sun Fu, Handbook of Pattern Recognition and Image Processing, Academic Press, (1986).
- 9) Eric A. Brandes, Smithells Metals Reference Book, Butterworths, 6th Edition, (1983), pp. 22-112.

## Development of Adaptive Signal Pattern Recognition Program and Application to Classification of Defects in Weld Zone by AE Method

K. Y. Lee\*, J. M. Lim\* and J. S. Kim\*\*

\* Department of Mechanical Engineering, Yonsei University

\*\* KAITECH

**Abstract** The signal pattern recognition program which can perform signal acquisition and processing, the extraction and selection of features, the classifier design and the evaluation, is developed and applied to the classification of artificial defects in the weld zone of Austenitic STS304. The neural network classifier is compared with the linear discriminant function classifier and the empirical Bayesian classifier. The signal through a broadband sensor is compared with that through a resonance type sensor. In recognition rate, the neural network classifier is best, and the signal through a broadband sensor is better.

---

*(Received : November 23, 1995)*