

신경망 AE 신호 형상인식을 위한 특징값 선택법의 개발과 용접부 및 회전체 결함 분류에의 적용 연구

Development of Feature Selection Method for Neural Network AE Signal Pattern Recognition and Its Application to Classification of Defects of Weld and Rotating Components

이강용*, 황인범**

Kang-Yong Lee* and In-Bom Hwang*

초 록 음향방출 신호를 이용하여 분류기를 설계하는 과정에서의 특징값 선택법에 관해 연구하였다. 분류기는 역전파법을 이용한 신경망 분류기를 사용하였다. Fisher's criterion, class mean scatter criterion, eigenvector analysis와 함께 본 논문에서 새로 제안하는 특징값 공간에서의 특징값 좌표사이의 차이를 이용하는 2-D criterion, 3-D criterion을 이용해서 특징값을 선택하고 각각에 대해 분류기를 설계하여, 인식률과 수렴속도를 비교하였다. 분류를 위한 자료를 얻기 위하여 용접부 결함시편과 로터리 압축기 금속 접촉부 결함시편을 사용하였다. 인식률 면에서 2-D criterion과 3-D criterion이 우수한 결과를 나타내었다.

주요용어: 음향방출, 신경망 분류기, 특징값 선택법, 신호 형상인식

Abstract The purpose of this paper is to develop a new feature selection method for AE signal classification. The neural network of back propagation algorithm is used. The proposed feature selection method uses the difference between feature coordinates in feature space. This method is compared with the existing methods such as Fisher's criterion, class mean scatter criterion and eigenvector analysis in terms of the recognition rate and the convergence speed, using the signals from the defects in welding zone of austenitic stainless steel and in the metal contact of the rotary compressor. The proposed feature selection methods such as 2-D and 3-D criteria showed better results in the recognition rate than the existing ones.

Keywords: acoustic emission, neural network classifier, feature selection, signal pattern recognition

1. 서론

분류기(Classifier) 설계를 하는데 있어서는 특징값(Feature)들의 추출과, 분류기의 설계에 필요한 특징값의 선정이 분류기의 설계작업 자체와 더불어 중요한 역할을 차지한다. 기 개발되어 있는 특징값 선택방법 중 일반적인 것으로는 Fisher's criterion[1], class mean scatter

criterion[1], eigenvector analysis[2], feature-feature plot 을 이용하여 분리도가 좋은 특징값을 선택하는 방법 등이 있다. 이외에 특징값 선택법에 관련된 연구로는 Kudo와 Shimbo[3]은 데이터의 분포를 특징지어주는 색인(index)을 정의하고 이를 이용하여 특징값을 선정하는 방법을 제안하였고, Gupta 등[4]은 형상 분류군들이 겹치는 경우에 있어 신경회로망을 학습시킬 때 학습원형을

(접수: 2000. 2. 18) * 연세대학교 기계공학과(Dept. of Mechanical Engineering, Yonsei University, Seoul 120-749),

** LG 생산기술원

선정하는 방법을 제안하였다. 또한 Mucciardi와 Gosef[5]는 기존에 만들어진 여러 특징값 선택법을 검토하고 이중 오차확률법과 평균 공분산 계수법을 가중치를 이용해서 결합한 새로운 특징값 선택법을 제안하였고, Siddiqui 등[6]은 평균거리와 공분산 행렬을 이용한 최적화 방법을 사용해서 특징값을 선택하는 방법을 제안하였다. Battiti[7]는 통계적인 방법인 mutual information을 이용해서 특징값을 선정하는 방법을 제안하였다. 그러나 Fisher's criterion[1]과 class mean scatter criterion[1]의 경우 feature-feature plot 방법보다 부정확하다. eigenvector analysis[2]방법의 경우 추출된 특징값들의 공분산 행렬을 구하고 이를 eigenvector analysis해야 하기 때문에 계산량이 많아서 효율적이지 못하다. 또한 이를 이용해 선택된 특징값은 기존의 AE 특징값들이 각각의 물리적 의미를 가지고 있는 것과 비교해 물리적 의미를 가지지 못한다. Feature-feature plot을 이용해 좋은 분리도를 보이는 특징값을 선택하는 방법에 있어서는 사람이 직접 눈으로 해야하기 때문에 주관적인 관점이 들어갈 소지가 많다. 또한 이 방법은 용접부 결함 분류나 회전체의 결함 분류의 경우에는 너무도 많은 특징값이 있기 때문에 이들 각각에 대해 눈으로 확인한다는 것은 너무도 어려운 작업이다. 또한 Kudo와 Shimbo[3]가 제안한 색인을 정의하고 이에 따라 특징값을 선택하는 방법은 이진(binary) 데이터에 대한 방법으로 일반적인 데이터에는 적용할 수 없다. Gupta 등[4]이 제안한 방법은 특징값을 선택하는 것보다는 신경 회로망(Neural Network)을 교육시킬 때 잡음들을 제외한 데이터를 선택하는 방법이다. Mucciardi와 Gosef[5]와 Battiti[7]가 제안한 방법은 데이터의 분포를 정규분포로 가정해야만 하는 제약이 따르는 방법이었다. Siddiqui 등[6]이 제안한 방법은 특징값 선택 과정에서 복잡한 최적화 알고리즘을 사용하는 불편함이 있었다. 따라서 이러한 특징값 추출방법의 단점을 보완하여 새로운 특징값 선택방법을 개발할 필요가 있다.

이에 본 논문에서는 음향 방출 신호(Acoustic Emission)를 분류하기 위해 기존의 알려진 특징값 선정 방법인 Fisher's criterion과 class mean scatter criterion, 그리고 eigenvector analysis(Karhunen-Loeve method)를 이용해 분류기를 설계해 보고, 이 분류결과를 본 논문에서 새롭게 제안하는 특징값 선택법(특징값 공간에서의 특징값 좌표사이의 거리를 기준으로 선택)을 사용해 특징값을 선택하고 이를 이용해 분류기를 설계한 경우와 비교해 보았다. 이를 위해 스테인레스강의 용접부 결함과 로터리 압축기 금속 접촉부 이상결함으로부터의 AE 신호

를 자체 개발한 신경망 신호 형상인식 프로그램[8]에 이용하였다.

2. 특징값 선택법 개발

2.1. 2-D Criterion

2개의 분류군 사이에서 적용되는 공식이다. 분류군이 3개 이상일 때는 여러 개의 분류군들 중 임의의 2개씩의 분류군의 조합을 뽑았을 때 그 2개씩의 분류군의 조합 각각이 잘 분류되는 것이 중요하다. 분류군이 3개 이상일 때는 먼저 특징값의 조합에 대해 임의의 2개씩의 분류군의 조합을 만들고 각 분류군의 조합에 criterion을 적용한다. 그 2개씩의 분류군의 조합에서의 criterion의 값 중 가장 작은 값을 그 특징값의 조합에서의 값으로 정하고 그 값의 크기순으로 특징값의 조합을 정렬하고 값이 큰 조합을 분류기 설계에 사용한다.

2차원 특징값 공간에서, 분류군이 2개(A와 B), 특징값 x , 특징값 y , 각 분류군에서의 데이터 개수 n , $\overline{x_A} = \sum_{i=1}^n x_{A,i}$, $\overline{x_B} = \sum_{i=1}^n x_{B,i}$, $\overline{y_A} = \sum_{i=1}^n y_{A,i}$, $\overline{y_B} = \sum_{i=1}^n y_{B,i}$ 에 대해 2-D criterion의 값 $f(A, B, x, y)$ 은 다음과 같다.

$$f(A, B, x, y) = \frac{\sqrt{(\overline{x_A} - \overline{x_B})^2 + (\overline{y_A} - \overline{y_B})^2}}{\sum_{i=1}^n \sqrt{(x_A - x_{A,i})^2 + (y_A - y_{A,i})^2} + \sum_{i=1}^n \sqrt{(x_B - x_{B,i})^2 + (y_B - y_{B,i})^2}} \quad (1)$$

2.2. N-D Criterion

식(1)을 일반화하여 N 차원 특징값 공간에서 분류군이 2개(A와 B), 특징값 ($x^k, k=1,2,3,\dots,N$), 각 분류군에서의 데이터 개수 n , $\overline{x^k_A} = \sum_{i=1}^n x^k_{A,i}$, $\overline{x^k_B} = \sum_{i=1}^n x^k_{B,i}$ 에 대해 N-D criterion의 값 $f(A, B, x^1, x^2, \dots, x^N)$ 은 다음과 같다.

$$f(A, B, x^1, x^2, \dots, x^N) = \frac{\sqrt{\sum_{k=1}^N (\overline{x^k_A} - \overline{x^k_B})^2}}{\sum_{i=1}^n \sqrt{\sum_{k=1}^N (x^k_A - x^k_{A,i})^2} + \sum_{i=1}^n \sqrt{\sum_{k=1}^N (x^k_B - x^k_{B,i})^2}} \quad (2)$$

3. 신호 형상인식 프로그램

신호 형상 인식 프로그램이 갖춘 전체적인 구성[8]은 데이터 수집 과정, 특징값 추출 과정, 특징값 선택과정, 분류기 설계 과정, 분류기 검증 과정으로 나뉘어 진다. 본 연구에서 사용한 특징값은 시간 영역에서의 25개이고 이를 Table 1[8]에 제시하고 있다. 특징값 선택 과정은 각 특징값에 순위를 정하여 순차적으로 필요한 개수를 선택하여 사용하며 본 연구에서는 Fisher's criterion, class mean scatter criterion, eigen vector analysis와 2-D criterion, 3-D criterion을 이용하여 순위를 정한다. 분류기 설계 과정에서는 역전파법을 이용한 신경 회로망 분류기를 사용한다. 분류기 검증 과정에서는 설계된 분류기를 가지고 미지 신호에 적용하여 이를 검증하게 된다. p번째의 학습원형에 대해 Total Error (E_p)는 j 가 출력층 단위를 지칭하고, t_{pj} 는 출력층단위의 목적값, o_{pj} 는 출력층 단위의 현재 값일 때 다음 식으로 정의된다.

$$E_p = \frac{1}{2} \sum_j (t_{pj} - o_{pj})^2 \quad (3)$$

Table 1 Feature parameters in time domain[8]

No	feature parameter
0	total power in total original time domain
1	total mean level in total original time domain
2	total variance in total original time domain
3	total skewness in total original time domain
4	total kurtosis in total original time domain
5	a number of peaks exceeding a present threshold
6	ratio of the powers above 90% and 10% threshold
7	ratio of the powers above 50% and 10% threshold
8	ratio of the powers above 90% and 50% threshold
9	pulse duration of largest pulse in original time domain
10	rise time of largest pulse
11	decay time of largest pulse
12	peak duration
13	largest pulse area
14	energy of largest pulse
15	first amplitude moment of largest pulse
16	first energy moment of largest pulse
17	second amplitude moment of largest pulse
18	second energy moment of largest pulse
19	rise slope of largest pulse
20	decay slope of largest pulse
21	mean of largest pulse
22	variance of largest pulse
23	skewness of largest pulse
24	kurtosis of largest pulse




Fig. 1 Welding specimen with an artificial defect (a) no defect, (b) hole with crack, (c) notch and (d) crack

4. 실험

각 시편으로부터 40개의 신호를 검출하였고 30개의 신호는 분류기 설계에, 나머지 10개 신호는 검증용으로 사용하였다.

4.1. 용접부 인공 결함

서로 다른 인공 결함으로부터 발생하는 AE 신호를 구분하기 위한 시편에 사용한 재료는 오스테나이트 계열의 SUS304이다. 이 재료에 아크 용접법을 사용하여 용접 시편을 제작하였는데, 용접이 이루어진 후 연삭기를 이용하여 양쪽 면을 약 2mm씩 잘라 내어 균일한 용접면을 이루도록 하였다. 또한 중앙 결함 부분에 집중 하중이 가해질 수 있도록 양쪽을 반지름 7.5mm로 모따기 하였다. 그 후 방전 가공을 이용하여 인공 결함의 종류에 따라 무결함 시편 1개, 균열을 가진 구멍이 있는 용접 시편 2

개, 노치가 있는 용접 시편 2개, 균열이 있는 용접 시편 2개씩 모두 7개의 시편을 제작하였다. 이런 작업 후에 얻은 최종 인공 결함 시편의 형상은 Fig.1 (a)~(d)에 나타나 있다. 제작된 시편은 만능 재료 시험기(INSTRON, Model 1350, 10ton)의 변위 제어방식으로 3점 굽힘 실험을 하였다. 3점 굽힘 실험시 스펠의 길이는 130mm로 하였고 인공 결함이 존재하는 부분이 아래의 중앙에 위치하도록 주의하였다. 센서는 용접부 결함의 위치에서 40mm 떨어진 부분에 센서의 중앙 부분이 위치하게 하였다. 최대변위의 2% 정도(1mm)로 변위를 제어하였다. 센서는 광대역 센서(broadband sensor, AET사의 FC 500, 200kHz-2MHz)를 사용하였다. 센서를 부착시킬 때에는 센서 부착 부위를 사포로 다듬고 커플런트(couplant)를 칠한 다음 센서 고정용 스프링을 사용해 센서를 시편에 고정시켰다. 센서를 통해 나온 신호는 30kHz~2MHz 의 밴드 패스 필터(band pass filter)가 내장된 전치 증폭기(pre-amplifier)에서 40dB 증폭된 후 주 증폭기(main amplifier)가 내장된 AET5500에서 다시 10%증폭된 후 디지털 오실로스코우프로 들어가게 된다. 샘플링 주파수(sampling frequency) 500kHz로 신호당 4096개의 데이터를 받았으며, trigger level은 1.30V로 하고 5%의 pre-triggering을 취하였다.

4.2. 로터리 압축기 실린더 펌프부의 인공 결함

이 실험에서 사용한 시편은 룸 에어컨에 사용되고 있는 로터리 압축기의 실린더 펌프부이다. 시편의 형상은 Fig. 2에 나타나 있다. 실험에 사용한 시편은 무결함, 로울러의 찍힘, 베인의 찍힘, 축의 마모, 축의 마멸 시편으로 모두 5개이다. 본 실험에서는 디지털 오실로스코우프(tektronix TDS 420)를 사용하여 AE 센서((broadband sensor, AET사의 FC 500, 200kHz-2MHz)로부터 직접 신호를 받아 GPIB 인터페이스를 통해 컴퓨터에 저장하였다. 본 실험에서 압축기의 회전속도는 1460rpm이고 신호당 데이터는 4096개로 하고 샘플링 주파수는 100 kHz로 하여 40.96ms동안 1주기의 신호를 받았다. 압축기가 회전하고 있을 동안 지속적으로 Sunoco사의 JS-2368U 윤활유를 공급해 주었고, 무부하 상태로 실험하였다. Trigger level을 20mV로 하여 10% pretriggering을 취하여 신호를 얻었다.

5. 특징값 선택법 적용 및 고찰

용접부 결함과 로터리 압축기 실린더 펌프부 결함의




Fig. 2 Configuration of rotary compressor specimen[9]

신호를 분류할 때 사용된 신경회로망 분류기의 구조는 숨은층 1개, 숨은층의 단위수 7개로 통일하였다.

5.1. 용접부 인공결함 분류를 위한 적용

용접부 인공결함 시편 3가지와 무결함 시편의 신호를 분류할 수 있는 분류기를 설계해 보았다. Fisher's criterion, class mean scatter criterion, eigenvector analysis, 2-D criterion 그리고 3-D criterion에 의한 특징값의 순위를 상위 5개까지 Table 2에 나타내었고 각 특징값 선택법에 대한 feature-feature plot 을 Fig. 3에 나타내었다. 2-D criterion에 의한 feature-feature plot과

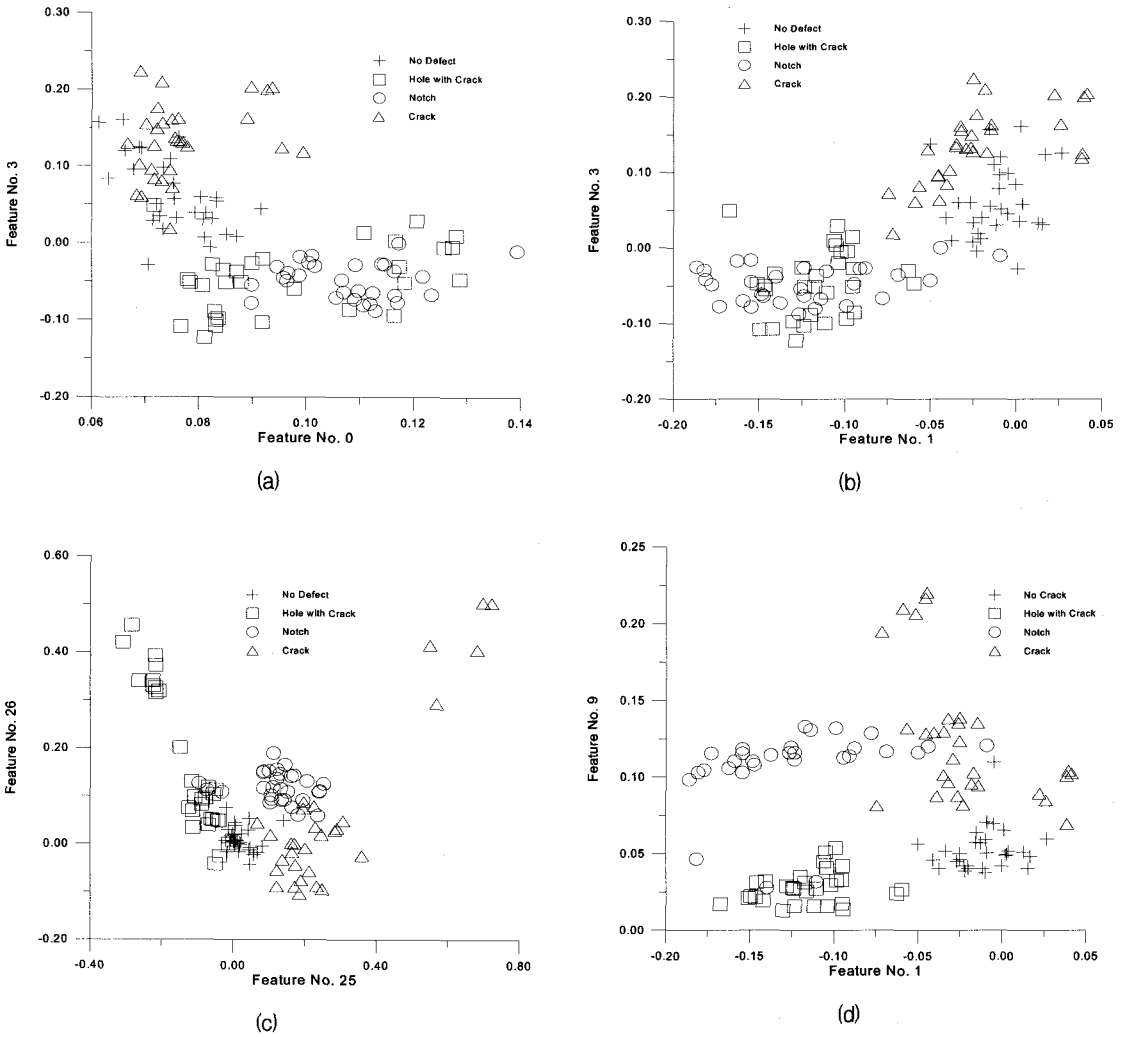


Fig. 3 Feature-feature plot for (a) Fisher's criterion, (b) class mean scatter criterion, (c) eigenvector analysis and (d) 2-D criterion.

Table 2 Feature ranking by Fisher' criterion, class mean scatter criterion, eigenvector analysis, 2-D criterion and 3-D criterion

Rank.	Feature Number				
	Fisher	Class Mean	Eigen-vector	2-D	3-D
1	3	3	25	1 9	3 9 16
2	0	1	26	3 16	3 15 16
3	1	9	27	3 9	0 1 9
4	2	10	28	3 15	3 9 15
5	23	19	29	1 10	3 10 16

eigen vector analysis 에 의한 feature-feature plot이 Fisher's criterion과 class mean scatter criterion에 의한 feature-feature plot보다 분류군을 잘 분리함을 알 수 있다. Eigenvector analysis의 경우에는 기존의 특징값의 조합으로 새로운 특징값을 만들어 내는 방법이기에 때문에 가장 좋은 특징값부터 25번부터의 번호를 매겼다. Table 3에 각각의 criterion에서 상위 2개씩 특징값을 뽑아서 분류기를 설계한 결과를 나타내었다. 이 경우 2-D criterion이 가장 좋은 인식률을 줄을 알 수 있다.

각각의 criterion에서 3개씩의 특징값을 뽑아서 분류기를 설계한 결과는 본문에 실지는 않았지만, 2개일 때와

Table 3 Classification result by 2 features selected by Fisher's criterion, class mean scatter criterion, eigenvector analysis and 2-D Criterion (NO: No Defect, H: Hole with Crack, N: Notch, C: Crack, R.R.: Recognition Rate, I.N.: Iteration Number)

Method	Feature No.	Classification Result					I.N.	
			NO	H	N	C		R.R.(%)
Fisher	0,3	NO			29	1	0	32767
		H			30		0	
		N			30		100	
		C			29	1	3.3	
Class Mean Scatter	1,3	NO		H	N	C	R.R.(%)	32767
		NO	28			2	93.3	
		H		9	21		30	
		N	2	1	27		90	
Eigen-vector Analysis	25,26	NO		H	N	C	R.R.(%)	32767
		NO	28	1		1	93.3	
		H	3	27			90	
		N		3	23	4	76.7	
2-D	1,9	NO		H	N	C	R.R.(%)	32767
		NO	29			1	96.7	
		H		30			100	
		N		2	25	3	83.3	
		C			1	29	96.7	

Table 4 Classification result by 4 features selected by Fisher's criterion, class mean scatter criterion, eigenvector analysis, 2-D criterion and 3-D criterion (NO: No Defect, H: Hole with Crack, N: Notch, C: Crack, R.R.: Recognition Rate, I.N.: Iteration Number)

Method	Feature No.	Classification Result					I.N.	
			NO	H	N	C		R.R.(%)
Fisher	0, 1, 2, 3	NO	29			1	96.7	32767
		H		26	3	1	86.7	
		N		2	28		93.3	
		C				30	100	
Class Mean Scatter	1, 3, 9,10	NO	30				100	32767
		H		27	3		90	
		N	1		29		96.7	
		C				30	100	
Eigen-vector Analysis	25, 26, 27, 28	NO	30				100	2069
		H		30			100	
		N		2	28		93.3	
		C				30	100	
2-D	1, 3, 9,16	NO		H	N	C	R.R.(%)	32767
		N	30				100	
		H		30			100	
		N		2	28		93.3	
		C				30	100	
3-D	3, 9, 15, 16	NO	29			1	96.7	32767
		H		30			100	
		N		3	27		90	
		C				30	100	

Table 5 Evaluation result by 4 Features selected by Fisher's criterion, class mean scatter criterion, eigenvector analysis, 2-D criterion and 3-D criterion (NO: No Defect, H: Hole with Crack, N: Notch, C: Crack, R.R.: Recognition Rate)

Method	Feature No.	Evaluation Result					I.N.	
			NO	H	N	C		R.R.(%)
Fisher	0, 1, 2, 3	NO	7		2	1	70	32767
		H		7	3		70	
		N		3	7		70	
		C		1	1	8	80	
Class Mean	1, 3, 9,10	NO		H	N	C	R.R.(%)	32767
		NO	9	1			90	
		H		8	2		80	
		N	1		9		90	
		C				10	100	
Eigen-vector Analysis	25, 26, 27, 28	NO		H	N	C	R.R.(%)	32767
		NO	9	1			90	
		H		10			100	
		N	1		9		90	
		C				10	100	
2-D	1, 3, 9,16	NO		H	N	C	R.R.(%)	32767
		N	9	1			90	
		H		10			100	
		N		1	9		90	
		C				10	100	
3-D	3, 9, 15, 16	NO	8	2			80	32767
		H		10			100	
		N		1	9		90	
		C				10	100	




Fig. 4 The convergence of total error for 4 features selected by Fisher's criterion, class mean scatter criterion, eigenvector analysis, 2-D criterion and 3-D criterion

비교하였을 때 비슷한 결과를 주었다. Table 4에 각각의 criterion에서 상위 4개씩의 특징값을 뽑아 분류기를 설계한 결과를 나타내었다. 이 경우에 2-D criterion과 eigenvector analysis가 가장 좋은 결과를 줄 수 있다. 검증은 4개씩의 특징값을 뽑아서 설계한 분류기를 가지고 하였다. 검증 결과는 Table 5에 나타내었다. 또한 각

4개씩의 특징값을 사용한 분류기에 대해 각각의 특징값 선택법에 대한 신경 회로망 분류기의 수렴과정을 Fig. 4에 나타내었다. 수렴속도는 eigenvector analysis가 가장 빠름을 알 수 있다.

5.2. 로터리 압축기 실린더 펌프부의 인공결합 분류를 위한 적용[9]

로터리 압축기의 결합 시편 4가지와 무결합 시편의 신호를 분류할 수 있는 분류기를 설계해 보았다. 특징값 선택에 관해서는 Fisher's criterion, class mean scatter criterion, eigenvector analysis, 2-D criterion 그리고 3-D criterion에 의한 각 특징값의 순위를 Table 6에 상위 5개씩 나타내었다. 분류결과는 Table 7에 나타내었다. 분류기 설계결과를 고찰해 보면 2-D criterion과 3-D criterion으로 선택한 특징값으로 설계한 분류기의 결과가

Table 6 Feature ranking by Fisher' criterion, class mean scatter criterion, eigenvector analysis, 2-D criterion and 3-D criterion

Rank	Feature Number				
	Fisher	Class Mean	Eigen-vector	2-D	3-D
1	0	0	25	0 19	2 15 19
2	3	2	26	2 19	2 9 19
3	2	9	27	0 9	2 16 19
4	11	16	28	2 9	0 9 19
5	4	15	29	0 11	0 15 19

Table 7 Classification result by 4 features selected by Fisher's criterion, class mean scatter criterion, eigenvector analysis, 2-D criterion and 3-D criterion (NOD: No Defect, DOR: Defect on Roller, DOV: Defect on Vane, DOW: Defect of Wear, DOA: Defect of Abrasion, R.R.: Recognition Rate, I.N.: Iteration Number)

Method	Feature No.	Classification Result						I.N.	
		NOD	DOR	DOV	DOW	DOA	R.R.(%)		
Fisher	0, 3, 2, 11	NOD	30					100	32767
		DOR		27	3			90	
		DOV		1	29			96.7	
		DOW				30		100	
		DOA					30	100	
Class Mean	0, 2, 9, 16	NOD	30					100	32767
		DOR		28	1		1	93.3	
		DOV		2	28			93.3	
		DOW				30		100	
		DOA					30	100	
Eigen-vector	25, 26, 27, 28	NOD	27	3				90	3366
		DOR		30				100	
		DOV			30			100	
		DOW				30		100	
		DOA					30	100	
2-D	0, 2, 9, 19	NOD	30					100	11203
		DOR		1	29			96.7	
		DOV			30			100	
		DOW				30		100	
		DOA					30	100	
3-D	2, 9, 15, 19	NOD	30					100	14993
		DOR		1	29			96.7	
		DOV			30			100	
		DOW				30		100	
		DOA					30	100	

Table 8 Evaluation by 4 features selected by Fisher's criterion, class mean scatter criterion, eigenvector analysis, 2-D criterion and 3-D criterion (NOD: No Defect, DOR: Defect on Roller, DOV: Defect on Vane, DOW: Defect of Wear, DOA: Defect of Abrasion, R.R.: Recognition Rate)

Method	Feature No.	Evaluation Result						R.R.(%)
		NOD	DOR	DOV	DOW	DOA		
Fisher	0, 3, 2, 11	NOD	9	1				90
		DOR		8	2			80
		DOV		1	9			90
		DOW				10		100
		DOA					10	100
Class Mean	0, 2, 9, 16	NOD	10					100
		DOR		7	2		1	70
		DOV		1	9			90
		DOW				10		100
		DOA					10	100
Eigen-vector	25, 26, 27, 28	NOD	8	2				80
		DOR		10				100
		DOV			10			100
		DOW				10		100
		DOA					10	100
2-D	0, 2, 9, 19	NOD	10					100
		DOR		10				100
		DOV			10			100
		DOW				10		100
		DOA					10	100
3-D	2, 9, 15, 19	NOD	10					100
		DOR		10				100
		DOV			10			100
		DOW				10		100
		DOA					10	100

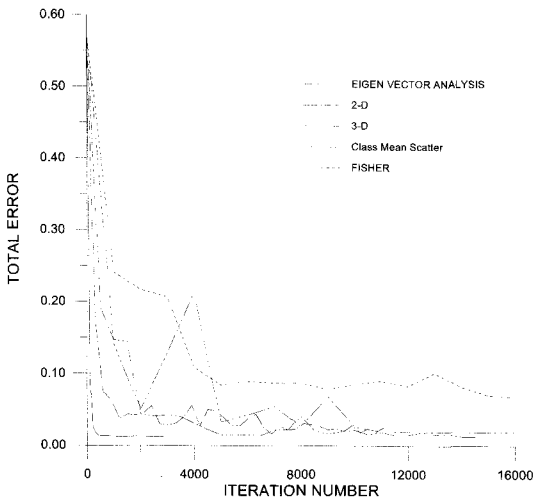


Fig. 5 The convergence of total error for 4 features selected by Fisher's criterion, class mean scatter criterion, eigenvector analysis, 2-D criterion and 3-D criterion

다른 criterion으로 선택한 특징값을 사용한 분류기보다 좋을 수 있다. 그리고 설계된 분류기를 검증한 결과를 Table 8에 나타내었다. 결과는 분류기 설계결과와 비슷함을 알 수 있다. 또한 각 특징값 선택 방법에 대한 신경 회로망 분류기의 수렴과정을 Fig. 5에 나타내었다. 2-D criterion과 3-D criterion으로 선택한 특징값을 사용한 분류기의 수렴속도가 다른 criterion (Fisher's criterion, class mean scatter criterion)을 사용한 특징값보다 빠름을 알 수 있다. 다만 eigenvector analysis에 의한 특징값에 의한 수렴속도는 2-D criterion과 3-D criterion으로 선택한 특징값을 사용한 분류기의 수렴속도보다 빠르다.

6. 결 론

본 연구에서 새로운 특징값 선정법(2-D criterion과 3-D criterion)을 개발하고 기존의 방법(Fisher's criterion, class mean scatter criterion, eigenvector analysis)과 비교 검토하기 위해 용접부 결함과 로터리 압축기 실린더 펌프 부 결함으로부터 AE신호를 받아 분류기를 설계하고 검증한 결과는 다음과 같다.

- 1) 본 연구에서 개발한 특징값 선정법이 기존방법보다 좋은 인식을 준다.
- 2) 신경회로망의 역전파 알고리즘의 수렴속도면에서

eigenvector analysis법이 기존 방법과 본 연구에서 개발한 특징값 선정법보다 우수하다.

- 3) 임의의 개수의 특징값을 선정할 때 차원을 증가시킨다고 해서 반드시 더욱 좋은 결과가 얻어지는 것은 아니다.

참고문헌

- [1] J. T. Tou and R.C. Gonzalez, *Pattern Recognition Principles*, Addison-Wesley Pub. Co., pp. 243-269, (1974)
- [2] Christopher Chatfield and Alexander J. Collins, *Introduction to Multivariate Analysis*, Chapman and Hall, pp. 56-79, (1980)
- [3] Mineichi Kudo and Masaru Shimbo, "Feature Selection Based On The Structural Indices of Categories," *Pattern Recognition*, Vol. 26, No.6, pp. 891-901, (1993)
- [4] Lalit Gupta, Jiesheng Wang, Alain Charles and Paul Kisatsky, "Prototype Selection Rules For Neural Network Training," *Pattern Recognition*, Vol. 25, No. 11, pp. 1401-1408, (1992)
- [5] Anthony N. Mucciardi and Earl E. Gose, "A Comparison of Seven Techniques for Choosing Subsets of Pattern Recognition Properties," *IEEE Transactions on Computers*, Vol. c-20, No.9, pp. 1023-1031, (1971)
- [6] K.J. Siddiqui, Y.H. Liu, D.R. Hay and C.Y. Suen, "Feature Selection using a proximity-index optimization model," *Pattern Recognition Letters*, Vol. 15, pp. 1137-1141, (1994)
- [7] Roberto Battiti, "Using Mutual Information for selecting Features in Supervised Neural Net Learning," *IEEE Transactions on Neural Networks*, Vol. 5, No. 4, pp. 537-550, (1994)
- [8] 이 강 용, 김 준 섭, "UT 신호 영상 인식을 위한 Intelligence Package 개발과 Austenitic Stainless Steel Welding 부 결함 분류에 관한 적용 연구", 비파괴검사학회지, 제 15권, 제 4호, pp. 531-538, (1995)
- [9] 이 강 용, 이 중 명, 김 준 섭, "적용형 AE 신호 영상 인식 프로그램 개발과 회전체 금속 접촉부 이상 분류에 관한 적용연구", 비파괴검사학회지, 제 15권, 제 4호, pp. 520-530, (1995)