

적응형 AE신호 형상 인식 프로그램 개발과 회전체 금속 접촉부 이상 분류에 관한 적용 연구

이강용*, 이종명*, 김준섭**

* 연세대학교 기계공학과

** 생산기술연구원

요약 본 연구에서는 음향방출법을 이용하여 로터리 압축기의 인공 결함을 분류하기 위한 연구를 수행하였다. 이를 위해 프로그램을 개발하였고 선형 분류기, 경험적 Bayesian 분류기, 신경 회로망 분류기를 함께 사용하여 비교하였다. 그 결과 신경 회로망 분류기가 인식을 면에서 유리하였으며 신경 회로망 분류기의 경우 99%이상의 인식률을 얻을 수 있었다.

1. 서론

지금까지 로터리 압축기의 조립 상태에 대한 평가는 뚜렷한 방법이 없었다. 이를 개선하여 로터리 압축기 출하시 line에서 이상이 있는 제품을 비파괴적으로 검출할 수 있다면 로터리 압축기의 신뢰성과 생산성을 높일 수 있다. 제품을 비파괴적으로 검사할 수 있는 방법으로는 음향 방출(Acoustic Emission : 이하 AE)법이 있다. 물체에 변형이 생기거나 물체 내에 균열이 발생, 성장할 때 원자의 재배열이 일어나며, 이때 물체는 탄성과(elastic wave)를 방출하게 되는데 이 탄성과 방출을 음향 방출이라 하며 이 탄성과는 물체 표면에 부착시킨 AE 트랜스듀서(transducer)에 의해 감지된다.¹⁾

로터리 압축기의 운동은 주로 마모와 마찰인데 여기에 AE법을 이용하는 연구가 진행되고 있다. Lingard와 Ng²⁾는 disk-disk 마모 실험에서 디스크의 재질, 하중, 속도를 변화시켜 가면서 마찰에 의한 일과 누적 AE수와의 관계를 제시했고 Carpenter등³⁾은

block-on-ring 마찰 실험에서 하중과 속도를 변화시켜 가면서 AE 실효값과 마찰력과의 관계를 제시하였다. McBride와 Boness⁴⁾는 ball-on-cylinder 마모 실험에서 AE 실효값, 마모 시간, 마모량간의 관계를 측정하였고 Yoon과 Kwon⁵⁾은 저널 베어링의 비정상적인 조작 상태와 AE 실효값과의 관계를 제시하였으며 Sato와 Yoneyama⁶⁾는 로터리 압축기 저널 베어링의 마멸, 핀과 베인의 마모에 AE를 적용하여 회전속도, AE 발생 수, 신호의 최대값과 평균값의 비에 근거한 진단 구조를 고안하였고 Sato등⁷⁾은 스크롤 압축기의 이상 마찰에 대해 효과적인 AE 파라미터를 찾았으며 Jouaneh등⁸⁾은 여러 가지 접촉 형태의 마찰과 AE 파라미터와의 관계를 제시하였다. 위에서 보는 바와 같이 기존의 연구에서는 단순한 형상이나 실제 모델의 마찰과 마모 과정에 AE를 적용함으로써 마찰과 마모의 진행과 AE와의 관계를 제시하고 있을 뿐 마찰과 마모를 분류하기 위하여 신경 회로망 분류기를 신호 형상 인식법에 적용한 연구는 거의 없다.

신경 회로망을 이용하는 연구로는 Dornfeld⁹⁾가 공

구 이상 검출에 신경 회로망을 이용하였고 Yuki와 Homma¹⁰⁾는 여러 가지 형상의 pencil lead break로부터 얻은 신호를 신경 회로망을 이용하여 분류하였다. 송성진¹¹⁾은 용접 결함인 균열, 기공, 슬래그 개재에 초음파법으로 얻은 신호를 확률 신경 회로망을 적용하여 분류하였고 Oishi등¹²⁾은 신경 회로망과 계산 역학을 이용한 역분석법과 초음파법을 사용하여 결함의 위치와 크기를 파악하였고, Jiefu등¹³⁾은 용접부 인공 결함에 신경 회로망을 사용하여 98%이상의 분류를 하였다.

그러나 회전체에 신경 회로망을 적용하여 결함을 분류한 연구는 거의 없다. 이러한 이유로 본 연구에서는 신호 형상 인식법과 신경 회로망을 이용하여 신호를 분류하는 프로그램을 개발하고 로터리 압축기의 정상적인 제품, 조립상 있을 수 있는 찍힘 결함이 있는 제품, 장시간 사용 후 생기는 마모나 마멸이 있는 제품의 신호들을 분류하여 로터리 압축기의 신뢰성을 높이고자 한다. 본 연구에서 개발된 신경 회로망 프로그램은 AE법을 이용한 신호의 분류는 물론 초음파법이나 진동을 이용한 신호의 분류에도 적용할 수 있다.

2. 신호 형상 인식 프로그램의 구성

Fig. 1은 개발된 신호 형상 인식 프로그램의 기본적인 과정을 나타내고 있다.




Fig. 1. Basic pattern recognition system.

Data acquisition에서는 digital storage oscilloscope에 저장된 데이터를 GPIB 인터페이스를 통하여 컴퓨터에 저장하고 이 데이터를 신호 형상 인식에 사용하기 위한 형태의 파일로 바꾸어 준다. Data transformation에서는 앞에서 얻은 시간축 상의 데이터를 디지털 신호 처리 기술을 사용하여 여러 영역으로 변환시킴으로써 시간축에서 얻을 수 없는 정보를 얻을 수 있도록 하였다. 즉 Fourier 변환을 함으로써 주파수축 상에서 각 주파수에 대한 진폭을 얻을 수 있고 자기 상관 함수를 통하여 신호 간

격에 따른 유사성을 볼 수 있으며 그 외에 포락성 파형, 진폭 분포와 밀도 함수, 변형된 자기 상관 함수 등도 얻을 수 있도록 하였다. Feature extraction에서는 시간축의 경우 파형의 형태를 나타내는 최대 진폭 파형의 상승 시간, 하강 시간, 지속 시간, 최대 진폭 기울기 등의 특징 매개 변수와 데이터의 통계적 분포를 나타내는 평균값, 척도, 왜도, 분산등의 매개변수 그리고 주파수 영역에서는 주파수 밴드 별 에너지량 등을 자동으로 얻은 후 이 특징값들을 정규화(normalized)하는 프로그램을 구성하였다. Table 1은 그 일례로 시간축 상의 특징 변수를 나타낸다. 또한 이들 값을 얻어내기 위해 문턱값과

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

number	feature parameter
1	total power in total original time domain
2	total mean level in total original time domain
3	total variance in total original time domain
4	total skewness in total original time domain
5	total kurtosis in total original time domain
6	a number of peaks exceeding a present threshold
7	ratio of the powers above 90% and 10% threshold
8	ratio of the powers above 50% and 10% threshold
9	ratio of the powers above 90% and 50% threshold
10	pulse duration of largest pulse in original time domain
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

신호 처리 과정을 사용자가 정의할 수 있도록 하였다. Feature select에서는 추출한 특징값이 신호를 분류하는 과정에서 모두 필요하지 않고 신호를 잘 구별할

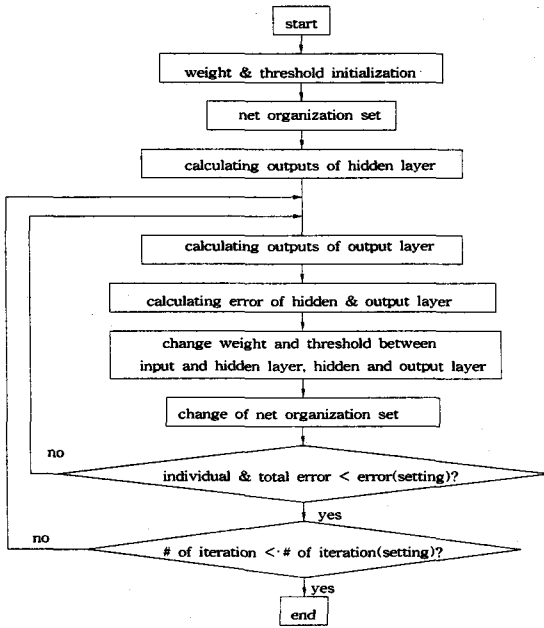


Fig. 2. Flow chart of neural network by back propagation method

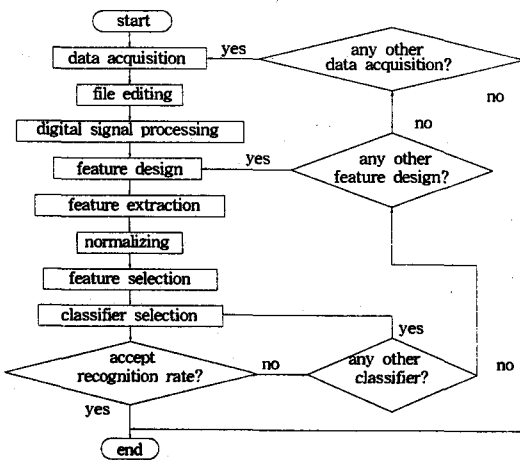


Fig. 3. Flow chart of pattern recognition program.

수 있는 몇 개의 특징값만이 필요하므로 class-mean scatter criterion을 이용하여 신호를 잘 분류할 수 있는 특징값의 순위를 정하고 필요한 개수만큼 선택하도록 하였다. Classifier design에서는 선택한 특징값을 가지고 신호를 분류하는 분류기를 설계하는데 선형 분류기(linear discriminant function classifier), 경험적 Bayesian 분류기(empirical Bayesian classifier), 신경 회로망 분류기(neural network classifier)^{11),14)}를 사용하여 신호를 분류할 수 있도록 하였다. 신경 회로망에서는 역전파법을 이용하였다. Fig. 2는 역전파법을 사용한 신경 회로망의 순서도를 보여주며 Fig. 3은 형상 인식 프로그램의 흐름도 이다.

3. 실험

3.1. 시험편

본 연구에서 사용한 시험편은 림 에어콘에 사용되고 있는 로터리 압축기이며 그 구조는 Fig. 4와 같다. Fig. 5는 실제 발생하는 결함을 참고하여 만든 인공 결함에 대한 정량적인 수치를 보여준다. 로울러(roller)와 베인(vane)의 적힘 결함은 드라이버(driver)로 찍어서, 축 상의 마모 결함은 사포로 문질러서, 축 상의 마멸 결함은 톱으로 끊어서 만들었다. 실험에 사용한 시험편은 무결함, 로울러의 적힘, 베인의 적힘, 축의 마모, 축의 마멸 시험편으로 모두 5개이다.




Fig. 4. Configuration of specimen.

	location of defect	description of defect (unit mm)
defect on roller		
defect on vane		
defect of wear		
defect of abrasion		

Fig. 5. Configuration of artificial defects

3.2. 실험 장치

본 실험에서는 디지털 오실로스코프(Tektronix TDS 420)를 사용하여 AE 센서로부터 직접 신호를 받아 GPIB 인터페이스를 통해 컴퓨터에 저장하였다. 실험 장치의 구성은 Fig. 6과 같다.

AE 센서를 부착하는 곳이 곡면이기 때문에 웨이브 가이드(wave guide)를 사용하여 AE 센서를 부착하였다. AE 센서는 주파수 범위 50 kHz ~ 1MHz 인 광대역 센서(broadband sensor) (AET IQI501)을 사용하

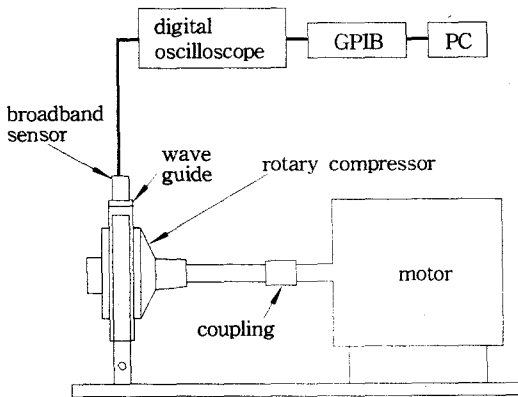


Fig. 6. Schematic diagram of testing system.

였고 로터리 압축기, 웨이브 가이드, AE센서 사이를 모두 접촉제로 고정시켰다.

로터리 압축기의 구동은 직류 모터를 사용하였고 모터의 구동력을 잘 전달하기 위하여 플렉시블 커플링(flexible coupling)을 사용하였다.

3.3. 실험 방법

본 실험에서 압축기의 회전속도는 1460 rpm으로 회전시켰고 디지털 오실로스코프의 성능상 신호당 데이터는 4096개로 하고 샘플링 주파수는 100kHz로 하여 40.96ms동안 1주기의 신호를 받았다. 압축기가 회전하고 있을 동안 지속적으로 Sunoco회사의 JS-2368U 윤활유를 공급해 주었고 무부하 상태로 실험하였다.

신호를 얻기 위하여 압축기가 계속 회전하고 있는 동안 trigger level 을 20mV로 하여 10% pre-triggering을 하여 각 결함 시험편당 40개의 신호를 얻었다. 그중 10개는 분류기를 설계하는데 사용하였고 30개로는 설계한 분류기를 검증하는데 사용하였다.


4. 실험 결과 및 고찰

4.1. 조립상 생긴 결함의 분류


Fig. 5의 결함 시험 4가지 중 조립상 있을 수 있는 결함인 로울러의 찍힘 시험, 베인의 찍힘 시험과 무결함 시험등 3가지 결함을 구분하고자 한다.

Fig. 7에서는 일례로 각 시험에 대해 시간 영역에서의 신호를 나타내고 있다. Table 2에서는 세 가지 영역의 특징값 중 class mean scatter 값이 가장 좋은 특징값 2개와 feature-feature plot 상에서 각 특징값의 분포를 확인하여 구분되는 2개의 특징값을 나타내었고 feature-feature plot으로 Fig. 8과 Fig. 9에서 시간영역을 예로 비교하여 보았다. Fig. 8의 특징값이 Fig. 9의 특징값의 class mean scatter 값보다 더 좋지만 결함을 구분하기에는 Fig. 9의 특징값이 더 좋을 수 있다. 이러한 결과는 본 실험의 경우 Fig. 8에서 보는 바와 같이 class mean scatter 값에 의해 선택한 특징값들이 1개 시험의 신호는 잘 분류하고 나머지 2개 시험의 신호는 잘 분류하지 못하는 반면에 feature-feature plot 상에서 찾은 특징값들은 class mean scatter 값은 낮지만 Fig. 9에서 보는 바와 같이


3개 시편의 신호를 잘 분류하기 때문이다. Table 3은 Table 2에서 보이는 feature-feature plot상으로부터 얻은 각 영역별 특징값으로 분류기를 설계하였을 경우의 결합 인식률을 주고 있다. 분류기 설계에서 사용된 신경 회로망 분류기의 구조는 숨은층 1개, 숨은층의 단위 수는 5개이며 이 구조는 본 연구 전 과정에서 동일하게 적용된다. 선형 분류기, 경험적 Bayesian 분류기, 신경 회로망 분류기의 결과를 각 영역별로 비교하면 신경 회로망 분류기가 가장 높은 인식률을 보인다. 따라서 신경 회로망 분류기에 의해 각 결합당 30



(a) no defect



(b) defect on roller



(c) defect on vane

Fig. 7. Signals in cases of no defect, defect on roller and defect on vane in time domain

Table 2. Feature numbers selected in each domain in cases of no defect, defect on roller and defect on vane.

	class mean scatter value	feature - feature plot
time domain	20, 21	4, 20
envelop domain	18, 19	1, 4
autocorrelation domain	8, 25	13, 21

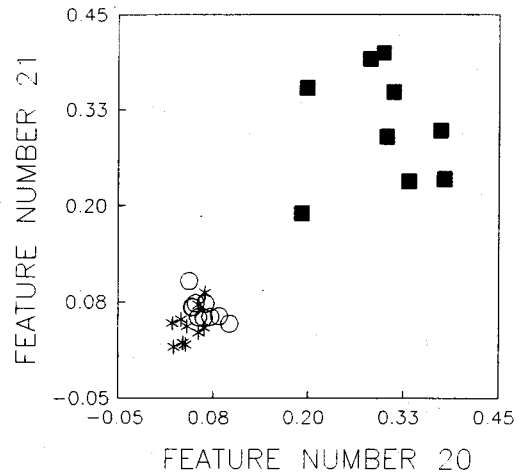


Fig. 8. Feature-feature plot by class mean scatter value in time domain as an example

(○ : no defect ■ : defect on roller * : defect on vane)




Fig. 9. The best feature-feature plot in time domain as an example (○ : no defect ■ : defect on roller * : defect on vane)

Table 3. Recognition rate by two features selected by the best feature-feature plot

domain	feature #	classifier														
		LDF				EMB				NN						
			NOD	DOR	DOV	R.R.		NOD	DOR	DOV	R.R.		NOD	DOR	DOV	R.R.
time	4, 20	NOD	9		1	90.0	NOD	9	1		90.0	NOD	10			100.0
		DOR		9	1	90.0	DOR		9	1	90.0	DOR		10		100.0
		DOV	1		9	90.0	DOV	1		9	90.0	DOV	1		9	90.0
		total R.R.(%)				90.0	total R.R.(%)				90.0	total R.R.(%)				96.7
envelop	1, 4	NOD	10			100.0	NOD	6	4		60.0	NOD	9	1		90.0
		DOR	4	4	2	40.0	DOR		10		100.0	DOR		10		100.0
		DOV			10	100.0	DOV		1	9	90.0	DOV			10	100.0
		total R.R.(%)				80.0	total R.R.(%)				83.3	total R.R.(%)				96.7
auto-correlation	13, 21	NOD	9	1		90.0	NOD		4	6	0.0	NOD	10			100.0
		DOR		9	1	90.0	DOR		8	2	80.0	DOR		10		100.0
		DOV		3	7	70.0	DOV		4	6	60.0	DOV			10	100.0
		total R.R.(%)				83.3	total R.R.(%)				46.7	total R.R.(%)				100.0

Table 4. Evaluation of neural network classifier in cases of no defect, defect on roller and defect on vane.

domain	feature-feature plot				
	feature #4,20				
		NOD	DOR	DOV	R.R.
time	NOD	29		1	96.7
	DOR	1	29		96.7
	DOV	11		19	63.3
	total R.R.(%)				85.6
envelop	feature #1,4				
		NOD	DOR	DOV	R.R.
	NOD	27		3	90.0
	DOR		29	1	96.7
	DOV			30	100.0
total R.R.(%)				95.6	
auto-correlation	feature #13,21				
		NOD	DOR	DOV	R.R.
	NOD	22		8	73.3
	DOR	1	24	5	80.0
	DOV	1		29	96.7
total R.R.(%)				83.3	

개의 미지 신호를 분류하였으며 그 결과를 Table 4에 보였다. 이 결과도 마찬가지로 임의로 찾은 특징값인 경우에 더 높은 인식률을 보였다.

4.2. 장시간 사용 후 생긴 결함의 분류

장시간 사용 후 나타날 수 있는 마모성 결함과 마멸성 결함을 무결함과 분류하여 보고자 한다.

앞에서와 동일한 방법으로 feature-feature plot 상에서 찾은 2개의 특징값에 대하여 분류기를 설계한 결과를 Table 5에 나타내었다. 여기에서도 앞에서와 마찬가지로 신경 회로망 분류기가 더 좋은 인식률을 주는 것으로 나타났다. 이러한 신경 회로망 분류기로 각 결함당 30개의 미지 신호를 분류한 결과는 Table 6과 같다.

4.3. 다섯 가지 신호의 분류

여기에서는 앞서 취급된 결함 즉 로울러의 찍힘, 베인의 찍힘, 마모성 결함, 마멸성 결함 모두를 함께 무결함과 분류하여 보았다. 특징값의 선택은 class mean scatter 값에 의해 정하지 않고 두개의 결함을 구분할 수 있는 특징값을 feature-feature plot 상에서 찾고 이 특징값을 모두 사용하여 5개의 신호를 구분하

Table 5. Recognition rate by two features selected by the best feature-feature plot.

domain	feature #	classifier															
		LDF				EMB				NN							
			NOD	DOW	DOA	R.R.		NOD	DOW	DOA	R.R.		NOD	DOW	DOA	R.R.	
time	4, 20	NOD	10			100.0	NOD	10			100.0	NOD	10			100.0	
		DOW		10		100.0	DOW		10		100.0	DOW		10		100.0	
		DOA			1	9	90.0	DOA			10	100.0	DOA			10	100.0
		total R.R.(%)				96.7	total R.R.(%)				100.0	total R.R.(%)				100.0	
envelop	4, 20	NOD	9		1	90.0	NOD	8		2	80.0	NOD	9		1	90.0	
		DOW		10		100.0	DOW		10		100.0	DOW		10		100.0	
		DOA	4			6	60.0	DOA	2		8	80.0	DOA	1	1	8	80.0
		total R.R.(%)				83.3	total R.R.(%)				86.7	total R.R.(%)				90.0	
auto-correlation	1, 2	NOD	10			100.0	NOD	10			100.0	NOD	10			100.0	
		DOW		10		100.0	DOW		10		100.0	DOW		10		100.0	
		DOA	1			9	90.0	DOA		1	9	90.0	DOA			10	100.0
		total R.R.(%)				96.7	total R.R.(%)				96.7	total R.R.(%)				100.0	

Table 6. Evaluation of neural network classifier in cases of no defect, defect of wear and defect of abrasion.

		feature-feature plot			
		feature #4,20			
		NOD	DOW	DOA	R.R.
time domain	NOD	26		4	86.7
	DOW		29	1	96.7
	DOA			30	100.0
	total R.R.(%)				94.4
envelop domain	feature #4,20				
		NOD	DOW	DOA	R.R.
	NOD	24		6	80.0
	DOW		30		100.0
	DOA	3		27	90.0
total R.R.(%)				90.0	

		feature #1,2			
		NOD	DOW	DOA	R.R.
auto-correlation domain	NOD	30			100.0
	DOW		30		100.0
	DOA			30	100.0
	total R.R.(%)				100.0

였다. Table 7은 각 영역에서 찾은 특징값을 사용하여 세 가지의 분류기를 설계해 본 결과이다. 그 결과 신경 회로망 분류기가 가장 높은 인식률을 나타내었다. 설계한 신경 회로망 분류기를 각 결함당 30개의 미지 신호로 검증한 결과는 Table 8과 같다. 선택한 특징값의 숫자와 인식률을 고려하였을 때 시간 영역에서의 신경 회로망 분류기가 가장 좋음을 알 수 있다.

Table 9에는 영역에 관계없이 특징값을 증가시켜 가면서 각각 3가지의 분류기를 설계하여 보았다. 여기에서 feature-feature plot을 고려하여 특징값을 적절

Table 7. Recognition rate of each classifier in each domain.

domain	feature #	classifier																					
		LDF						EMB						NN									
		NOD	DOR	DOV	DOW	DOA	RR.	NOD	DOR	DOV	DOW	DOA	RR.	NOD	DOR	DOV	DOW	DOA	RR.				
time	1,2,4,7,8,11,20	NOD	10				100.0	NOD	5		5		50.0	NOD	9		1		90.0				
		DOR		10			100.0	DOR		10			100.0	DOR		10			100.0				
		DOV	1		8	1	80.0	DOV			10		100.0	DOV			10		100.0				
		DOW			2	8	80.0	DOW			2	8	80.0	DOA				10	100.0				
		DOA	1			1	8	80.0	DOA				10	100.0	DOW					10	100.0		
		total RR.(%)						88.0	total RR.(%)						86.0	total RR.(%)						98.0	
envelop	1,2,3,4,13	NOD	10				100.0	NOD	4		3		3	40.0	NOD	10				100.0			
		DOR		8			2	80.0	DOR		6			4	60.0	DOR		10			100.0		
		DOV		2	8			80.0	DOV		2	8			80.0	DOV			10		100.0		
		DOW				10		100.0	DOW			9	1		10.0	DOW				10	100.0		
		DOA	2	3	1			4	40.0	DOA			3		7	70.0	DOA					10	100.0
		total RR.(%)						80.0	total RR.(%)						52.0	total RR.(%)						100.0	
auto-correlation	1,2,3,4,8,10,12,13,16,21	NOD	7		3			70.0	NOD	6	4				60.0	NOD	10				100.0		
		DOR		9	1			90.0	DOR		9	1			90.0	DOR		9		1	90.0		
		DOV		1	9			90.0	DOV		9	1			100.0	DOV			10		100.0		
		DOW				10		100.0	DOW				9	1	90.0	DOW				10	100.0		
		DOA					10	100.0	DOA					10	100.0	DOA					10	100.0	
		total RR.(%)						90.0	total RR.(%)						70.0	total RR.(%)						98.0	

히 선택하면 인식률을 높일 수 있음을 알 수 있다. Table 10에는 Table 9와 같은 영역과 특징값으로 신경 회로망 분류기를 검증한 결과 특징값의 수가 많아질 수록 더 높은 인식률을 얻었다.

Table 8. Evaluation of neural network classifier in each domain.

domain	feature #	evaluation result							
		NOD	DOR	DOV	DOW	DOA	RR.		
time	1,2,4,7,8,11,20	NOD	28		2			93.33	
		DOR	1	29				96.67	
		DOV			22	8		73.33	
		DOW					30	100.0	
		DOA						30	100.0
		total R.R. (%)						92.67	

envelop	1,2,3,4,13	NOD	30					100.0	
		DOR		26	1		3	86.67	
		DOV			30			100.0	
		DOW					18	12	60.00
		DOA	3	1				26	86.67
		total R.R. (%)						86.67	
auto-correlation	1,2,3,4,8,10,12,13,16,21	NOD	23		7			76.67	
		DOR	1	23	2		4	76.67	
		DOV	7	2	19	1	1	63.33	
		DOW					30		100.0
		DOA						30	100.0
		total R.R. (%)						83.33	

Table 9. Recognition rate of classifier by features selected by the best feature-feature plot in multi-domain.

domain (feature #)	classifier																			
	LDF						EMB						NN							
	NOD	DOR	DOV	DOW	DOA	R.R.	NOD	DOR	DOV	DOW	DOA	R.R.	NOD	DOR	DOV	DOW	DOA	R.R.		
time (1,2,4,10,20) envelop (1,2)	NOD	9		1		90.0	NOD	8		2		80.0	NOD	10				100.0		
	DOR		10			100.0	DOR		9	1		90.0	DOR		10			100.0		
	DOV	1		9		90.0	DOV			9	1	90.0	DOV			10		100.0		
	DOW			2	8	80.0	DOW			5	5	50.0	DOW				10	100.0		
	DOA	1			1	8	80.0	DOA				10	100.0	DOA				10	100.0	
	total R.R.(%)						88.0	total R.R.(%)						82.0	total R.R.(%)					
time (1,2,4,10,20) demodulated autocorrelation (10)	NOD	9		1		90.0	NOD	9		1		90.0	NOD	10				100.0		
	DOR		10			100.0	DOR		10			100.0	DOR		10			100.0		
	DOV	1		9		90.0	DOV			10		100.0	DOV			10		100.0		
	DOW				10	100.0	DOW			1	9	90.0	DOW				10	100.0		
	DOA	1			1	8	80.0	DOA				10	100.0	DOA				10	100.0	
	total R.R.(%)						92.0	total R.R.(%)						96.0	total R.R.(%)					
time(1,2,10,20) envelop (4) demodulated autocorrelation (1,10)	NOD	10				100.0	NOD	9		1		90.0	NOD	10				100.0		
	DOR		10			100.0	DOR		10			100.0	DOR		10			100.0		
	DOV			10		100.0	DOV			10		100.0	DOV			10		100.0		
	DOW				10	100.0	DOW				10	100.0	DOW				10	100.0		
	DOA					10	100.0	DOA				10	100.0	DOA				10	100.0	
	total R.R.(%)						100.0	total R.R.(%)						98.0	total R.R.(%)					
time(1,2,10,20) envelop (4) autocorrelation (2) demodulated autocorrelation (1,2,10)	NOD	10				100.0	NOD	10				100.0	NOD	10				100.0		
	DOR		10			100.0	DOR		10			100.0	DOR		10			100.0		
	DOV	1		9		90.0	DOV			10		100.0	DOV			10		100.0		
	DOW				10	100.0	DOW				10	100.0	DOW				10	100.0		
	DOA					10	100.0	DOA				10	100.0	DOA				10	100.0	
	total R.R.(%)						98.0	total R.R.(%)						100	total R.R.(%)					
time(1,2,10,20) envelop (4) autocorrelation (2) demodulated autocorrelation (1,2,10,12)	NOD	10				100.0	NOD	10				100.0	NOD	10				100.0		
	NOR		10			100.0	DOR		10			100.0	DOR		10			100.0		
	DOV	1		9		90.0	DOV			10		100.0	DOV			10		100.0		
	DOW				10	100.0	DOW				10	100.0	DOW				10	100.0		
	DOA					10	100.0	DOA				10	100.0	DOA				10	100.0	
	total R.R.(%)						98.0	total R.R.(%)						100.0	total R.R.(%)					

Table 10. Evaluation of neural network classifier by features selected by the best feature-feature plot in multi-domain.

domain (feature #)	evaluation result						
		NOD	DOR	DOV	DOW	DOA	R.R.
time (1,2,4,10,20) envelop (1,2)	NOD	30					100.0
	DOR		30				100.0
	DOV			20	10		66.7
	DOW				30		100.0
	DOA					30	100.0
	total R.R.(%)						
time (1,2,4,10,20) demodulated autocorrelation (10)	NOD	28		2			93.3
	DOR	1	29				96.7
	DOV			29	1		96.7
	DOW				24	6	80.0
	DOA					30	100
	total R.R.(%)						
time(1,2,10,20) envelop (4) demodulated autocorrelation (1,10)	NOD	29		1			96.7
	DOR		30				100.0
	DOV			30			100.0
	DOW				29	1	96.7
	DOA	1				29	96.7
	total R.R.(%)						
time(1,2,10,20) envelop (4) autocorrelation (2) demodulated autocorrelation (1,2,10)	NOD	28		2			93.3
	DOR		30				100.0
	DOV			30			100.0
	DOW				29	1	96.7
	DOA					30	100.0
	total R.R.(%)						
time(1,2,10,20) envelop (4) autocorrelation (2) demodulated autocorrelation (1,2,10,12)	NOD	30					100.0
	DOR		30				100.0
	DOV			30			100.0
	DOW				30		100.0
	DOA	1				29	96.7
	total R.R.(%)						

5. 결론

신호 형상 인식법에 의한 결함 분류 프로그램을 개발하고 이를 로터리 압축기의 조립상 결함과 장시간 사용 후 생기는 결함을 묘사한 인공 결함으로부터 검출된 음향 방출 신호에 적용한 결과는 다음과 같다.

1. 선형 분류기, 경험적 Bayesian 분류기, 신경 회로망

분류기 중 신경회로망 분류기를 적절히 학습시켰을 때 신경 회로망 분류기가 가장 높은 결함 인식률을 보인다.

2. 본 연구 대상인 로터리 압축기의 인공 결함 분류에는 class mean scatter 값에 따른 특징값 선택은 높은 결함 인식률을 주지 못한다.

3. 취급한 5개 인공결함 분류를 위하여 신경회로망 분류기를 사용할 경우 시간 영역에서 설계한 분류기로는 92%이상의 결함 인식률을 보이며 시간 영역, 포락성 파형 영역, 자기 상관 함수 영역, 변형된 자기 상관함수 영역에서 선택한 특징값으로 설계한 분류기로는 99%이상의 결함 인식률을 보인다.

후기

본 논문은 교육부 학술 연구 조성비(기계공학 분야)에 의한 연구(과제 번호 ME 94-C-08)이며 이에 감사 드립니다.

참고 문헌

1. 이강용, 선형 파괴 역학 개론, (1990), pp.109-114
2. S. Lingard and K. K. Ng, "An Investigation of Acoustic Emission in Sliding Friction and Wear of Metals", Wear, Vol.130(1989), pp.367-379
3. S. H. Carpenter, C. R. Heiple, D. L. Armentrout, F. M. Kustas and J. S. Schwartzberg, "Acoustic Emission Produced by Sliding Friction and its Relationship to AE from Maching", Journal of Acoustic Emission. Vol.10(1992), Number 3/4, pp.97-101
4. S. L. McBride and R. J. Boness, "Acoustic Emission Monitoring of a Wear Occurring in a Lubricated Ball-on-Cylinder Test", Progress in Acoustic Emission V(1990), pp.181-187
5. D. J. Yoon and O. Y. Kwon, "Acoustic Emission Monitoring of Incipient Failure in Journal Bearings", Progress in Acoustic Emission VI(1992), pp.93-100
6. I. Sato and T. Yoneyama, "Diagnosis of Rotating Slides in Rotary Compressors Using Acoustic Emission Technique", Progress in Acoustic

- Emission IV(1988), pp.405-412
7. I. Sato, T. Yaneyama and Y. Sato, "An Acoustic Emission Diagnosis Technique for Rotating Slides in Scroll Compressors", Progress in Acoustic Emission VII(1994), pp.607-612
 8. M. K. Jouaneh, R. Lemaster and F. C. Beall, "Study of Acoustic Emission Generation Sliding Motion", Journal of Acoustic Emission, Vol.10(1992), Number 3/4, pp.83-90
 9. D. A. Dornfeld, "Monitoring the Machine Process by Means of Acoustic Emission Sensors", Acoustic Emission : Current Practice and Future Directions, ASTM STP 1077(1991), pp.328-344
 10. H. Yuki and K. Homma, "AE Source Waveform Analysis by Using a Neural Network", Progress in Acoustic Emission VI(1992), pp.235-242
 11. 송성진, "확률 신경 회로망을 이용한 용접 결함 분류 기법", 초음파와 재료 강도에 관한 학술 토론회 (1994), 자료 번호:KSNT/UT9407
 12. A. Oishi, K. Yamada, S. Yoshimura and G. Yagawa, "Inverse Analysis by Mean of Neural Network and Computational Mechanics : Its Application to UT-Based Nondestructive Evaluation", The Joint JSME/KSME Conference on Recent Progress in Fracture Mechanics (1993), pp.89-94
 13. T. Jiefu, T. Wenxin and D. Xiaodai, "Application of Artificial Neural Network in Intelligent Ultrasonic Flaw Detector", Proceeding of International Symposium on Nondestructive Testing & Stress-Strain Measurement(1992), pp.325-330
 14. J. T. Tou and R.C.Gonzales, Pattern Recognition Principle(1974), pp.40-48, pp.111-114

Development of Adaptive AE Signal Pattern Recognition Program and Application to Classification of Defects in Metal Contact Regions of Rotating Component

K. Y. Lee*, C. M. Lee* and J. S. Kim**

* Department of mechanical engineering, Yonsei University

** KAITECH

Abstract In this study, the artificial defects in rotary compressor are classified using pattern recognition of acoustic emission signal. For this purpose the computer program is developed. The neural network classifier is compared with the statistical classifier such as the linear discriminant function classifier and empirical Bayesian classifier. It is concluded that the former is better. It is possible to acquire the recognition rate of above 99% by neural network classifier.

(Received : May 29, 1995)