

신경회로망을 이용한 전동기의 고장 부분 탐지

正會員 李 權 鉉* 正會員 姜 熙 熙*

Failure Detection of Motors using Artificial Neural Networks

Kwon Hyun LEE*, Heau Jo KANG* *Regular Members*

要 約

전동기 회전시 발생하는 소음이 전동기 구조상의 소손부분 및 정도에 따라 서로 다른 소음의 특징을 갖는다는 점을 고려하여 신경회로망을 이용한 시그널(소음)인식 시스템으로써 전동기의 고장부분 탐지에 적용하였다. 적용된 신경회로망은 역전파(Back-propagation) 알고리즘을 써서 학습하였고 2개의 은닉층을 갖는 4단신경회로망으로 구성 되었다. 실험결과 전동기의 구조와 출력이 거의 일치하는 경우에는 고장 부분에 대한 항상 바른 관정을 내릴 수 있었으나 출력이 유사하다라도 전동기의 구조가 상이한 경우나 전동기 제작회사가 다른 경우에는 부정확한 관정으로 나타났었다.

ABSTRACT

Subject of this work is the application of neural networks for the signal(motor noise) recognition systems which detects motor failures and employs different signal(noise) characteristics that result from damaged part and measure of motor construction during working. The four layers neural networks is applied to this examination, and consists of one input layer, two hidden layers, and one output layer, and learns by the back propagation algorithm.

The results of this examination show that if the construction and the output power of the testmotor and learning motor are compatible, the damaged part of the testmotor are detected correctly in the system, on the other hand, if the motors have different construction but similar output power each other, misleading results are obtained in this system.

1. 서 론

전동기는 전기적 에너지를 기계적 에너지로 변환하는 기기로써 우리 일상생활에서 흔히 사용되고 있는 가전제품에서부터 항공산업등 첨단산업에 이르기 까지 광범위하게 응용되고 있다. 그러나 많은 응용분

야 중에서도 정밀을 요하는 특정 응용분야에 있어서 전동기의 부분적 소손 즉, 베어링(bearing)이나 브리쉬(brush) 또는 조립불량 등으로 인하여 그 고유 목적달성에 차질을 빚을수 있는데 이의 예방으로는 조기에 고장부분을 탐지하여 수리 또는 교체하는데 있을 것이다. 이와같은 고장부분을 탐지하는 방법으로는 수년간 이 직종에 근무한 경력의 소유자라면 전동기의 회전상태(소음이나 진동)로 부터 직감적으로 말하 낼수도 있겠고 진기직(진압 및 진류) 측정과 기

*東新大學 電子工學科
Dept. of Electronic Eng. Dong Shin Univ.
論文番號 : 92-6 (接受1991. 9. 13)

계직(모멘트 및 회전상태)측정, 열적(온도) 측정방법을 통해서 찾아 낼수도 있었으나 원형의 조립상태를 보존한채 소음부분을 관찰하기에는 부정확성이 따르고 진동기를 분해하여 분석 하려하는 많은 공정이나 번거로움을 갖게된다.

본 논문에서는 그림 1에서와 같이 진동기의 에너지 변환 과정에서 발생하는 출력단의 기계적 일직 에너지 외에도 회전시 발생하는 회전소음(본 논문에서는 소음 신호라 칭함)을 검출과 함께 인식이 가능하다는 점을 착안 하여 현재까지 주로 연구되어 오고 있는 진경회로방을 이용한 음성인식 시스템을 진동기의 고장부분 탐지에 적용하고자 한다.




그림 1. 진동기의 변환 시스템
Fig. 1. Transmission system of motor.

이 시스템은 진동기 회전시 발생하는 소음을 진경회로방을 이용한 학습과정을 통해서 정상 및 고장상태에 대한 소음의 특징추출을 하고 이를 데이터로 파일(file)하여 컴퓨터에 저장시켜 놓은 후 지원진동기의 운전시 발생하는 입력신호로 받아서 각 저장된 파일의 데이터와 비교하여 진동기의 상태를 관찰하게 된다.

본 연구에서는 역전파(back propagation) 알고리즘을 써서 학습하였으며 2개의 은의층을 갖는 1단진경회로방을 적용하였다. 다만 은의층의 진경회로방을 이용한 인식시스템은 입력단에 대량의 뉴런수를 적용하더라도 은의층의 뉴런수 및 은의층 수를 적절히 조정하므로써 빠르고 최적의 학습을 완료할수 있는 장점을 갖게된다.

따라서 이 측정방법은 특명한 측정기의 준비가 필요없고 진동기를 분해하거나 모든 소음 측정을 위한 별도의 진공실을 갖지않더라도 측정이 가능하여 간편하고 경제적 잇점도 갖을수 있다.

II. 시그널 인식 시스템

1. 시스템 구성

진동기의 고장상태에 따라서 상이하게 발생하는 소음에 의해 고장관찰을 위한 시스템은 그림 2와 같다.

이 시스템을 크게 세 부분으로 분류할수 있는데 첫째 진동기로부터 발생하는 소음신호의 디지털화과 둘째로 디지털화된 신호 데이터의 분석 및 특징 추출 마지막 단계의 진경회로방의 학습과정을 통한 분류과정을 나눌수 있다. 진동기의 소음을 마이크로폰(microphone)을 통해서 전기적 시그널로 변환화한 후 증폭기를 거쳐 표본화한 다음 A/D변환기를 통해서 digital신호로 바꾼후 컴퓨터에 저장하게 된다. 저장된 데이터는 12.6ms 마다 25.6ms의 Hamming window를 사용해서 FFT(Fast Fourier Transform)을 한 다음 컴퓨터의 진경회로방으로 전달되고 그곳에서 학습을 통한 분류과정을 갖게 되는데 이때의 학습과정에서는 연결강도(weight)의 조절에 의해 분류가 가능토록 중요 정보를 저장해 놓았다가 테스트 시 그날의 진경회로방을 통과할때 연결 강도가 얻어지고 이것을 통해서 학습시 회정지위전 등장에 덧붙여 가므로서 인식의 어부가 걸린다. 이와같은 과정에서 신호분석 및 특징추출은 컴퓨터와 직결된 워크스테이션(DSP)을 통해서 이뤄지고 분류과정을 workstation sun/unix 시스템 내에서 진경회로방의 학습을 통해서 이뤄지게 된다.

2. BP알고리즘 및 학습

본 연구의 학습에 이용한 진경회로방은 그림 3과 같이 입력단, 은의 1단(hidden layer 1), 은의 2단(hidden layer 2)과 출력단으로 구성되어있으며 은의층에는 은의로 뉴런수를 설정할 수 있도록 설계되었다.

따라서 입력단의 각 뉴런들은 256개의 특징과라매대로 주어지게 되며 하나의 진동기에 해당되는 시그널은 10개의 spectrum으로 세분화되어 결국 한개의 진동기에 해당되는 입력뉴런은 10개의 뉴런으로 구성되어있다. 학습방법으로는 BP(back-propagation) 알고리즘을 적용하였는데 이것은 어떤 pattern 이 입력단으로 부터 출력단으로 진행됨에 따라 각 단의 뉴런은 작질보다 낮은 바로 앞단 뉴런의 weight가 곱해져서 출력단 방향으로 보내어 준다. 이때 통산

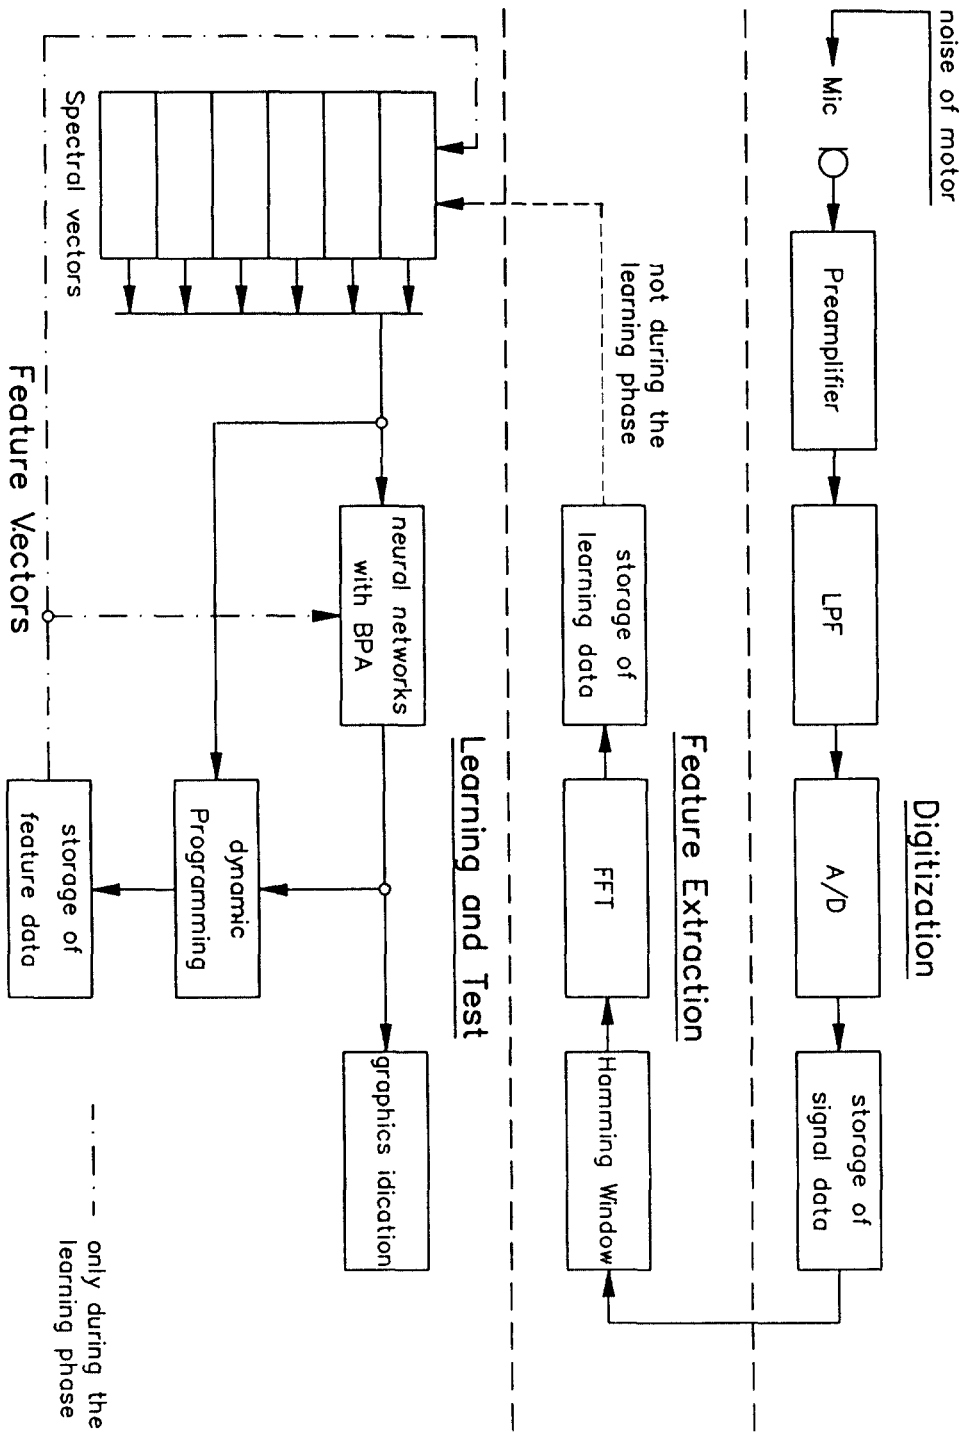


그림 2. 신경회로망을 적용한 신호인식 시스템
 Fig. 2. Structure of signal recognition system at neural networks.




그림 3. 4단 신경 회로망
Fig. 3. 4Layer neural networks.

gradient search 기법을 이용하여 최종 출력단에 실제 나타난 출력값(actual output) O_{ik} 와 기대하는 출력값(target output) O_{it} 와의 차는 식(1)과 같이 최소화 오차함수(last-mean square-error function)로 표시할 수 있다. [6, 7, 8], 9, 10]

$$E = \frac{1}{2} \sum_{i=1}^n (O_{it} - O_{ik})^2 \quad (1)$$

여기서 X_i 는 임의 layer의 출력 neuron이다. 이를 오차값은 회로를 역 방향으로 진행시킴으로써 하위 각층의 weight를 수정해 가며 전체 오차가 기대치에 미칠때까지 계속적으로 학습한다. 이때 neuron들의 활성함수는 sigmoid 함수

$$f(x) = \frac{1}{1 + e^{-x}}$$

를 가지게 되며 x 의 값은 학습횟수를 통해서 점진적으로 새 형성된다. 반복되는 학습과정을 통해서 각 layer에 형성되는 neuron들의 weight는 다음과 같다. 신경회로망을 통한 전향(forward) 단계의 각 layer에 대한 actual output O_{ik} 는 weight w_{im} 과 threshold θ 에 의해 확정 되어 지는데 반복되는 학습 횟수를 시간함수로 표현하여 neuron들의 weight를 time index(t)를 사용한 시간 종속 함수로 표현할 수 있다. 즉 m neuron의 weight w_{im} 은 $w_{im}(t)$ 로, θ 는 $\theta(t)$ 및 O_{ik} 는 $O_{ik}(t)$ 로 쓸수 있었다. time index(t)를 사용한 실제 출력 $O_{ik}(t)$ 는 식(2)와 같이 나타낼 수 있는데

$$O_{ik}(t) = f\left(\sum_{m=1}^j w_{im}(t) \cdot I_{im}(t)\right) = f(Z_{ik}) \quad (2)$$

여기서 f : neuron m의 active function,
 w_{im} : t-시간함수의 neuron m에 대한 weight,
 I_{im} : neuron i에의 입력값.

$\theta_{(t)}$: t-시간함수의 threshold 값이다.

또한 입력벡터(input vector) I 와 이로부터 요구되는 출력벡터(output vector) O_n 는 식(3)과 (4)로 나타낼 수 있다.

$$I = \{I_{0(t)}, I_1, \dots, I_n\} \quad (3)$$

$$O_n = \{O_{a0(t)}, O_{a1(t)}, \dots, O_{an(t)}\} \quad (4)$$

후향(backward)단계는 t 회수의 전향 단계에서 기대했던 출력과 실제 나타난 출력과의 오차를 역전파시키면서 오차를 최소화 하도록 각 단계 간의 wright를 조절하고 이로부터 학습의 계속 여부를 결정하게 된다. (t+1) 회수에 대한 m 뉴런의 weight는

$$W_{m(t+1)} = W_{m(t)} - \eta \frac{\partial}{\partial W_{m(t)}} \left(\frac{1}{2} [O_{ex} - O_{ax}(t)]^2 \right) \quad (5)$$

$$\theta_{(t+1)} = \theta_{(t)} - \eta \frac{\partial}{\partial \theta_{(t)}} \left(\frac{1}{2} [O_t - O_{a(t)}]^2 \right)$$

여기서 η =학습배턴(learning factor)

식(5)과 (6)를 sigmoid 함수를 적용하면 식 (7)과 식 (8)와 같이 고쳐 쓸 수 있다.

$$W_{m(t+1)} = W_{m(t)} + \eta O_n(t) \cdot (1 - O_{a(t)}) \cdot$$

$$(O_t - O_{a(t)}) \cdot I_{m(t)} \quad (7)$$

$$\theta_{(t+1)} = \theta_{(t)} + \eta O_n(t) \cdot (1 - O_{a(t)}) \cdot (O_t - O_{a(t)}) \quad (8)$$

식 (5)와 (6)는 weight 및 threshold의 조정에 대한 관계치를 나타내는 함수로서 본 연구의 알고리즘에 적용하였다. (마치 2.2.1.1.1.)

III. 실험결과 및 고찰

1. 실험자료 및 실험방법

실험자료 : 학습 및 테스트를 위한 전동기로서는 MEXON(T.216080) 및 BOSCH(Type 30861)와 VALVO(VD 1230)의 3개의 회사에서 제작하고 있는 18개의 전동기를 이용했으며 이들 모터는 영구자석 어차형 DC모터로써 슬롯(slot)형 회전자로 되어 있고 Sleeve Bearing과 26개의 정류자 Segment, 그리고 2쌍의 흑연 Brush로 구성되어 있다. 실험에 이용된 전동기의 중요 규격 및 특징은 표 1과 같다.

또한 실험에 적용된 전동기의 상태 및 실험용도(학습용 또는 테스트용)에 대한 분류는 표 2와 같다.

실험 방법 : 본 실험은 보통 감속 상태의 일반 컴퓨터 작업실에서 전동기의 회전소음을 마이크로폰을 통해 입력한 후 10KHz로 표본화 한 다음 16bit A/D변환기를 통해서 Digital신호로 바꾼 후 Digital Signal

표 1. 전동기의 중요 특징 및 규격

Table 1. Important Data and Construction Features of Test Motor

Motor type	MAXON	BOSCH	VALVO
Data	216080	130861	VD1230
construction features			
Nominal Voltage	12 V	12 V	12 V
Max. power output	1300 mW	12600 mW	11000 mW
Torque at max.	72 mNm	69 mNm	62 mNm
Stall torque	241 mNm	237 mNm	196 mNm
No load current	45 mA	43 mA	38 mA
No load speed	2100 rpm	1980 rpm	2650 rpm
Number of commutator bars	26	26	24
Brushes	Lever Graphite Brushes for 4 pole motor	Lever Graphite Brushes for 4 pole motor	Change able graphite brushes for 1 pole motor
Bearing	Sleeve bearing	Sleeve bearing	Sleeve Bearing

표 2. 실험에 적용된 전동기의 상태

실험 용도명	A grup MOXON		B grup BOSCH		C grup VALVO		비 고
	전동기 상태	갯수	전동기 상태	갯수	전동기 상태	갯수	
학 습 용	M 1	2	M 1	2			M1 : 정상상태
	M 2	2	M 2	2			M2 : Bearing 소손
	M2+M3	2					M3 : Brush 소손
	M 3	2	M 3	2			M4 : gear 소손
테 슷 트 용	M 4	2	M 4	2			
			M 3	1	M 3	1	

Processor(DSP)와 직결된 workstation Sun 386i 컴퓨터의 신경회로망에 저장되도록 하였고 Program은 C언어로 쓰였다. 전동기의 운전상태는 무부하(no load) 운전이며 학습용 전동기의 다양한 시그널의 표본을 구하고자 운전전압 및 소음부위와 마이크로프로세서의 거리간격을 변형해 가면서 측정 하였다.

2. 결과 및 분석

동일한 실험에 사용된 각 전동기의 소음 pattern은 제작회사에 따라 기동시와 정상운전시 공히 약간씩 상이한 amplitude의 Pattern을 나타내고 있었는데 그림 4의 a와 b는 제작회사 A와 B의 정상상태인 전동기의 정상운전시 소음을 나타낸 것이다.

그림 4의 b 경우 그림 4의 a에 비하여 최고 amplitude에서는 약간 낮은 값이나 일반적으로 높은 소음을 발생하고 있었다. 이는 표 1에서와 같이 A회사의 제품이 B 회사 제품에 비하여 Torque 및 회전수, 무부하 전류치가 약간 높으므로서 최고 amplitude에서






그림 4. 각 전동기의 소음 패턴
Fig. 4. Signal(Noise) Pattern of each motor.

의 차이를 나타내고 있으나 이보다 큰 원인은 조립사의 차이가 있다고 본다. 그러나 최고 amplitude가 동일 주파수대에서 발생하므로서 소음의 유사성을 발견할수 있다. 이밖에도 두 회사의 전동기는 브러쉬 또는 베어링등이 소손 되었을때도 대체적으로 일치

하는 파형을 이루고 있었다. 그림 4의 c에서는 A회사의 전동기를 베어링의 표면과 bearing house의 표면에 흠을 만든후 그 소음을 측정함 것으로 정상 상태의 전동기에 비하여 진 주파수에 걸쳐 2배 이상의 높은 소음을 나타내고 있으므로 쉬게 전동기의 정상 여부를 판별 할수 있겠다. 그림 5의 a는 회사 A의 각종상태의 전동기를 오차 0.013까지 학습시킨후 학습

에 사용되었던 전동기의 소음을 가지고 test한 결과로서 모든 전동기에 대하여 완벽에 가깝게 인식한 결과이다. 여기에서

X축 : 기대하는 출력 뉴런

Y축 : 입력 뉴런(테스트 전동기)

Z축 : 각 뉴론에 대한 인식의 정도를 나타낸다.




그림 5.a 학습용 데이터를 이용한 인식 결과
Fig. 5.a Recognition result by learning data.




그림 5.b 동일한 제품의 테스트용 전동기의 인식 결과
Fig. 5.b Recognition result by test motor of the same kind.

그러나 그림 5의 b는 회사 A와 회사 B의 진동기를 함께 오차 0.039가 되도록 학습시킨후 학습에 사용된 회사 A의 진동기를 가지고 다시 소음을 측정할 후 이것을 테스트 진동기로서 시험한 결과로써 역시 100%의 바른 인식율을 나타내고 있으나 그림 5의 a에 비하여 상당한 변화를 나타내고 있다. 즉, 예로서 그림 5의 a 뉴런 M₁에서는 뉴런 M₂이외의 다른 뉴런에는 전혀 인식의 크기가 나타나지 않았지만 그림 b의 경우에는 뉴런 M₁ 이외에도 전 뉴런에 걸쳐 약간의 약한 인식된 크기가 출현됨을 볼수 있다. 이와같은 실험은 학습시킨 진동기를 가지고 테스트에 적용했다는 의미에서 광범위한 실험의 의미가 부여인수는 없겠으나 적어도 진동기 생산회사에서 제품의 품질검사시험에 응용이 가능하다고 판단된다. 그림 6은 그림 5의 b중에서 베이링과 브러쉬가 함께 고장상태인 진동기를 제외하고 실시한 학습한 데이터를 가지고 학습에 전혀 적용하지 않았던 회사 B의 Brush가 손상된 진동기 M₃를 테스트 진동기로 이용한 결과인데 정상적인 진동기(뉴런 M₁)와 가이의 고장(뉴런 M₂)에 대한 인식된 값은 전혀 나타나지 않았다. 여기서 한개 진동기의 소음시그널은 10개의 spectrum으로 세분화해서 특징을 분류 했으므로 각 뉴런에 해당되는 테스트 진동기는 10개로 분류된 인식의 크기를 갖는다. 그러나 그림 6의 결과는 Spectrum에 대하여는

는 옳은 인식으로, 3 Spectrum에 대하여는 베이링고장의 진동기로 인식되었고 1 Spectrum에 대해선 동일한 인식의 크기로 나타났다. 이와같은 결과에서 인식 스펙트럼 6:3비율로 바르게 인식되었다.

그러나 측정 조건의 가변에도 항상 옳게 인식되어진 확실성(O_{acc})은 다음 식(9)에 의해

$$O_{acc} = \frac{O_{acc} - O_{err}}{O_{acc}} \quad (9)$$

여기서 O_{acc}: Test pattern과 동일한 뉴런의 실제 출력값

O_{err}: Test pattern 이외의 뉴런들이 갖는 실제 출력값

식 (9)로 부터 그림 6의 실험은 바른 인식의 확실성(O_{acc})이 0.5의 값을 나타내므로써 테스트 조건이 약간 변경된다 하더라도 안정성에 가까운 인식의 결과가 일어날 것으로 환경된다. 반면 그림 7에서는 그림 6에서 적용했던 학습데이터를 가지고 진동기의 굵기가 학습데이터용 진동기와 어느정도 상이한 회사 C의 Brush가 손상된 진동기를 테스트한 결과이다 (참1 참조).

실제로 바르게 인식되어져야할 뉴런 M₃ 부분에서




그림 6. 시험 진동기의 인식 결과
Fig. 6. Recognition result by test motor 1.




그림 7. 시험 진동기의 인식 결과
Fig. 7. Recognition result by test motor 2.

는 2개의 Spectrum만이 절대적으로 우세하게 인식된 반면 오히려 베어링과손으로 인식되어진 스펙트럼이 4개로 나타나 전체적으로 잘못 인식되어졌고 특히 뉴론 M1(정상적인 전동기)로 판정된 인식값도 나타났으며 기업부분 과손인 뉴론 M1에서도 2개의 스펙트럼에서 최고 인식값을 나타내는데는 전체적인 인식은 베어링 과손으로 잘못 판정을 내릴수 있게 되었으나 스펙트럼 6,7,9 부분에서 분수 있듯이 어느 뉴론의 우세로 판정을 내리기 어려운 부분에 대해서는 실험조건외의 작은 변경에도 이들의 인식의 크기가 쉽게 바뀌질수 있는 상황으로 분수 있다. 결국 그림 7의 결과에서 동일회사의 전동기구조와 출력이 거의 유사한 경우는 상대적으로 우세한 인식의 결과로써 쉽게 옳은 인식의 판정을 내릴수 있었으나 그림 7의 결과에서 분수 있듯이 출력은 유사하더라도 전동기의 구조가 상이한 경우는 본 실험을 통해 옳은 판정을 얻을수가 없었다. 이는 동일회사의 제품에 대해서는 본 연구의 방법을 사용하면 간단하고 정확한 결과를 얻을수 있었으나 서로다른 회사의 제품에 대해서는 다음 그림 8에서 보는바와 같이 시크널(소음)의 바뀐 인식의 결과가 나타나기에는 방해요소(interference quantities) 및 제한조건(restrictions)들로 되어이 이들 요소에 대한 구체적인 대책이 요구된다. 예를 들자면 방해요소의 전동기소음 이외의 외부잡음을 제

기하기 위해선 간단한 방법으로 Microphone과의 감속 조절을 해보거나 또는 고정밀 필터기의 사용으로 불필요한 잡음을 제거할수 있겠고 또한 제한조건에 대한 개선방법으로는 학습을 통한 최적 인식율의 도달이나 알고리즘의 변형을 통한 방법을 들수 있겠다.

IV. 비판 및 결론

전동기의 회전소음을 별도의 측정실험실(전공실험실)이라든가 측정기구의 도움없이 DSP와 컴퓨터만으로 측정하여 전동기구조상 회전부위의 소손부분을 판정하는 실험의 시도는 아직 만족할만한 결과에는 도달할수 없었지만 우선 판정 가능성을 나타냈다는 점에서 그 의미를 강조하고자 한다. 그러나 본 실험에서는 실험에 요구되는 다양한 전동기의 sample입수가 어려워져 각 부분에 걸쳐 많은 소음의 pattern을 입수할수 없었고 이로인해 좀더 신뢰할수 있는 data의 확보가 부족했다는 점과 본 시험은 오직 무부하 상태에서 시험을 했다는 점에 비판을 가하고자 한다. 아울러 향후 무부하상태에서의 바뀐인식을 위해서는 기계적, 전기적, 열적 관계를 함께 관련된 연구가 진행 되었으면 한다. 그러나 전동기를 생산하는 회사에서 또는 부하가 거의 일정한 가전제품(세탁기)이나 사무기기(프린터나 복사기)등에 사용되는

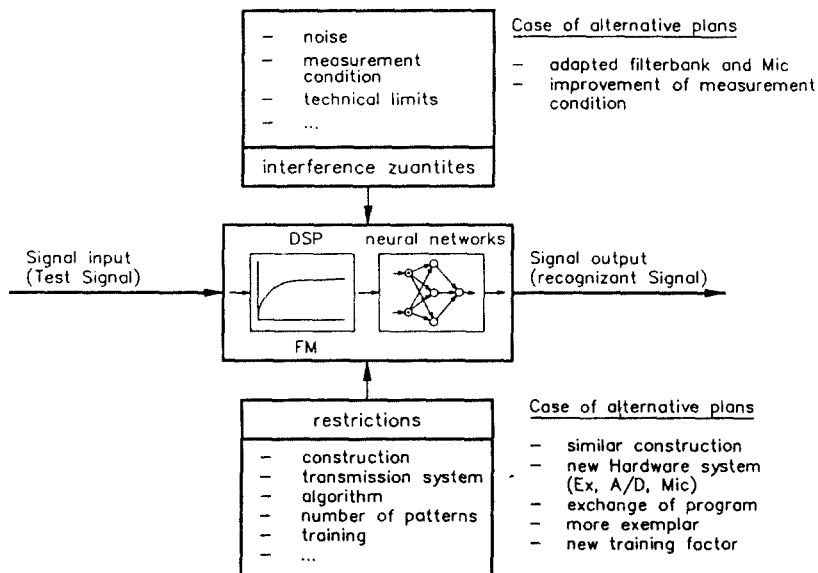


그림 8. 신호변환 시스템의 블록 다이어그램
Fig. 8. Block diagram of signal transmission system

신동기 테스트를 위해 본 실험의 적용을 시도해 볼수 있었다. 그러기 위해선 각종 타입에 대한 많은 실험기의 확보와 다양한 실험조건(진공실험실을 이용한 경우와 일반 삼층상태에서의 실험, 부분하 및 부하상태)등을 통해서 그림 8의 제한 및 방해요소로 제기되는 매개체에 대한 정칙이고 동적인 특성해석의 보완이 요구되고 풍부한 실험자료를 찾을수 있는 실험기의 생산회사에서 직접 이 방법에 의한 실험을 시도해 보았을 한다.

참 고 문 헌

1. U.schramm, Automatische Inspektion von Zylinderbohrungen proc. IDENT / VISION '89, pp.201-206.
2. E.Gerhard, K-H. LEE, Mechanische Verluste an Gleichstrom kleinstmotoren, Feinwerktechnik & Messtechnik 93 H.2 pp.64-66, 1985.
3. K.Sickert, Automatische Spracheingabe und Sprachausgabe, Mark & Technik Verlag, 1983.
4. H.G. Hirsh, t. Pieper, C. Cydow and H. Finster, Automatische Spracherkennung mit einer gehoerbezogenen Sprachanalyse und neuronalen Netzstrukturen, ASST '90 7, Aachener Symposium fur Signaltheorie, Sept. 1990.
5. B.Hosticka and P.Richert, Spreacherunabhagige Spracherkennung mit neuronalen Netzen, Mustererkennung 1989, Oktober 1989.
6. D.E. Rummelhart, G.E. Hinton and R.J. Williams, Learning internal representations by error propagations by error propagation in parallel distributed processing, vol.1, The MIT press, 1986.
7. G. Cybenco, Complexitx theory of neural networks and classification problems, neural networks EURASIP workshop 1990, Feb. 1990.
8. R.P. Lippmann, pattern Classification using neural networks, IEEE communications magazine, vol.77, 1989.
9. C.Politt, Verfahren zur Bestimmung von Gewichtsmatrizen beineuronalen netzen, Mustererkennung, Springer Verlag 1990.
10. U.KreBei, J.Franke, J.schürmann, polynomklassifikator versus Multilayer Perzeptron, Mustererkennung, Springer vglag 1990.
11. J.shynk, S.Roy, Aanalysis of Perceptron learning algorithm with momentum updating, IEEE Int. conf. Acoust. speach signal processing, pp.1377-1380, April 1990.
12. E. Monte and E. Lleida The Back Propagation using the conjugate gradient method, signal processing '90, pp.1615-1617.
13. H.Reiminger and D.Wolf Nonlinear prediction of stochastic processes using neural networks, signal processing '90, pp.1623-1626.
14. T.Kohonen, self organisation and associative memory, springer verlag, 1984.
15. E.Gghard, Einflussfaktoren auf den Entscheidungsprozeß beim wissenschaftlichen Konstruieren in der Feinwerktechnik, Habilitationsschrift universitaet stuttgart, 1976.



李權 鉉(Kwon Hyun LEE) 正會員
1950年 4月24日生
1972年 2月：朝鮮大學校電氣工學
科(工學士)
1976年 9月：延世大學院 電氣·電
子專攻(工學碩士)
1985年 5月：西獨Duisburg 大學院
器具設計學(工學博
士)

1985年 9月：現代重電機(株)技術研究所 責任研究員
1986年 5月：三星電子部品(株)技術研究所 責任研究員
1987年 3月：東新大學 電子工學科 副教授
1990年 6月～1990年 8月：西獨 KAAD 裝學財團招請 研
修(Duisburg 大學校 精密機械器具研究所)
1990年 9月～1991年 現在：韓國科學財團支援 Post-Doc
研修中(西獨 Aachen 工科大學 情報通信機
器研究所)



姜熙 照(Heu Jo KANG) 正會員
1961年 1月26日生
1979年～1986年：圓光大學校電子
工學科卒業(工學士)
1986年～1988年：崇實大學校半導
體工學科卒業(工學
碩士)
1989年 9月～現在：韓國航空大學
航空電子工學科 博
士課程

1990年 3月～現在：東新大學校 電子工學科 專任講師，
韓國通信學會 職場幹事