

인공신경회로망을 이용한 소형 모터의 조립 불량 판별 시스템 개발

이상민*, 조중선**

Development of A Fault Diagnosis System
for Assembled Small Motors Using ANN

Sang-Min Lee*, Joongseon Joh**

ABSTRACT

Fault diagnosis of an assembled small motor relies usually on human expert's hearing ability. The quality of diagnosis depends, however, heavily on physical conditions of the human experts. A fault diagnosis system for assembled small motors is developed using artificial neural network (ANN) in this paper. It is consisted of sound sampling device and fault diagnosis software package. Six parameters are defined to characterize the sampled sound waves. The Levenberg-Marquardt Backpropagation (LMBP) Algorithm is used to diagnose the fault of assembled small motors. Experimental results for more than two hundred small motors verify the performance of the developed system.

Key Words : Fault Diagnosis for Assembled Small Motors(소형 모터의 조립 불량 판별), FFT(Fast Fourier Transform), Artificial Neural Network (인공신경회로망), Backpropagation Algorithm(역전파 알고리즘)

1. 서론

모터와 기어는 현대 산업사회에 있어 매우 중요한 부분을 차지하고 있다. 특히 모터를 구동원으로 사용하고, 동력전달을 위해 기어를 사용하는 경우가 많은데, 이때 한 부분의 결함은 다른 부분에 심각한 영향을 줄뿐만 아니라 전체 시스템에도 영향을 미치게 된다. 이러한 모터와 기어의 결합관계는 각각의 시스템 제작과정뿐만 아니라 조립과정도 매우 중요시된다. 따라서 본 연구는 일상 생활에서 항상 접하고 있는 가전제품 등에 필수적으로 사용되고 있는 기어 감속기 붙이 소형 모터(이하 조립

모터라 함)의 조립 후 불량여부 판별을 목적으로 한다.

감속기가 붙지 않은 모터 또는 회전체에 대한 결합진단은 많은 연구가 이루어지고 있다. 이와 더불어 기어나 베어링이 결합된 경우, 이러한 장치들의 결합을 진단하기 위한 연구 또한 많이 이루어지고 있다. 이때는 대부분 결합된 시스템에서 발생하는 음이나 진동 등의 신호를 이용^[1-2]하여 진단하게 된다. 특히 산업현장에서 이루어지는, 조립이 완료된 모터의 최종 검사는 조립된 모터의 구동시 발생하는 구동음을 숙련된 검사자의 청각을 이용하여 이루어지고 있다. 이는 조립모터에서 발생하는

2000년 12월 6일 접수
* 창원대학교 제어계측공학과 대학원
** 창원대학교 제어계측공학과

구동음이 현재 조립모터의 불량여부를 적절히 나타내어 주지만, 그 차이가 미세할 뿐만 아니라 조립과정의 여러 가지 요인으로 인해 불량음이 다양한 형태로 발생하여, 숙련된 검사자가 아닐 경우 판별에 많은 어려움이 따르기 때문이다. 따라서 조립모터의 불량여부를 구동음을 이용하여 판단하기 위해서는 신호처리 기법이 필요하게 되는데, 이때 일반적으로 가장 많이 사용되는 방법은 Fast Fourier Transform (FFT)을 이용한 주파수분석 기법이다^[2,4]. 이 기법을 이용하여 시간영역의 구동음을 주파수영역으로 변환시킴으로써 조립모터의 상태를 판별할 수 있는 특징을 찾아낼 수 있다.

본 논문에서는 주파수분석을 통해 얻어진 데이터들을 이용하여 인공신경회로망을 학습시킴으로써 조립모터의 불량여부를 판별하는데 이용하였다. 이는 인공신경회로망이 입증된 비선형 패턴의 분류능력을 가지기 때문이다^[1-3,5,7]. 학습된 인공신경회로망은 전문가의 지식을 포함하고 있으며, 이를 통하여 서로 다른 형태의 신호를 적절히 판별해 낸다. 즉 인간이 가지고 있는 비선형 데이터들을 구분할 수 있는 전문적인 기술을 이상적으로 학습이 가능한 것이다.

따라서 본 논문에서는 조립모터의 정상, 불량음향 판별이 다양한 불량 요인으로 인해 정량적인 한두 가지의 파라메터로는 그 구분이 모호할 뿐만 아니라 검사의 신뢰성을 가질 수 없음으로, 음향분석을 통해 여섯 가지의 파라메터를 도출하고, 이를 이용해 학습된 인공신경회로망을 조립모터의 불량여부 판별에 이용함으로써 검사의 정확성과 신뢰성을 향상시켰다. 이로써 검사자의 청각 판단에만 의존함으로 인해 검사자의 주변 작업환경뿐만 아니

라, 검사자의 개인적인 정신적, 육체적 상황에 따른 많은 변수를 가지고, 더구나 1인의 검사자가 아닌 다수의 검사자가 이러한 검사작업을 행할 시 그 판별기준이 검사자에 따라 다를 수 있음으로 인한 판별의 신뢰성 하락과 작업의 효율면에서도 발생할 수 있는 문제의 소지를, 인간의 청각이 아닌 컴퓨터를 이용한 실용화된 조립모터 불량 판별 소프트웨어 패키지를 이용함으로써 객관적이고 신뢰할 수 있는 조립모터 불량 판별 시스템을 구축하였다.

2. 실험대상 및 장치

본 연구에서 사용된 조립모터는 모터와 감속기가 결합된 형태로서 내부의 형상은 Fig. 1과 같이 중앙의 모터 및 구동축과 5개의 감속기어가 결합된 형태로써, 전원 입력시 중앙의 모터가 구동되고 최종적으로 다섯 번째의 감속기어를 통해 회전운동이 외부로 전달되게 되어있다. 회전운동을 전달하는 다섯 개의 감속기어는 플라스틱 재질로 되어있어 구동음이 적고 감속비가 큰 것이 특징이다. 이러한 조립모터를 조립시 발생할 수 있는 조립 불량은 기어의 손상, Grease의 부족, Washer의 불량 등 다양한 형태가 존재하는데, 생산현장의 검사자는 이러한 조립모터들의 구동음을 청취함으로써 불량여부를 판별한다.

실험을 위한 음채집에 사용된 조립모터의 샘플은, 상기 조립모터의 실제 조립생산업체에서 기존의 생산라인에 종사하는 숙련된 검사자가 조립모터

Table 1 Sample Motors for Experiment

구 분	수 량	총수량
정상 조립모터	정 상 음	98
불량 조립모터	금 속 음	51
	이 상 음	38
	딱 음	11
	기 동 음	1
	코일단자 불량음	1
	Washer 불량음	1
		103

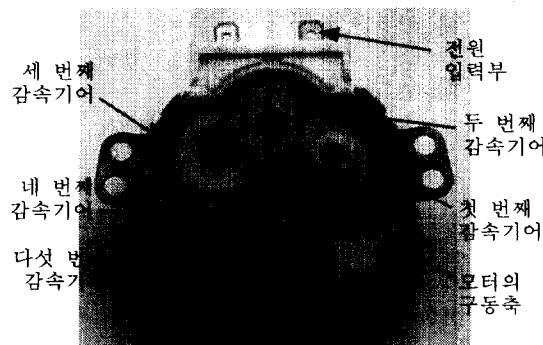


Fig. 1 Inner shape of sample motor

의 구동음을 직접 귀로 청취하여 불량여부를 명확히 판별한 조립모터를 실험을 위하여 제공한 것으로, Table 1과 같이 정상모터 98개, 불량모터 103개가 제공되었다. 제공된 조립모터들 중 불량 조립모터는 6가지로 분류되었다. 이는 인공신경회로망을 이용한 조립모터의 불량판별시 실제 인간이 검사하는 것과 동일한 정도의 불량판별을 위하여 실제 조립에서 발생할 수 있는 최대한 다양한 형태의 조립불량모터들이 제공된 것으로, Table 1과 같이 다양한 조립불량 항목의 분류는 숙련자의 구동음 청취로써만이 가능하였다.

제공된 조립모터들로부터 구동음을 채집하기 위하여 Fig. 2와 같은 간이 음채집 장치를 구현하였다. 이 음채집 장치는 주변의 소음을 최대한 차단하기 위하여 석면과 스펜지, 고무로 외부와 바닥을 마감하였으며, 구동음 채집은 마이크로폰을 이용하여 컴퓨터로 채집하였다. 이는 모터의 구동음 채집 및 채집된 구동음을 실시간으로 컴퓨터에서 분석 후 불량여부를 판별하기 위한 구성으로, 실제 검사 현장에서의 적용이 가능하도록 구현한 것이다. 실제 구현된 실험장치의 모습은 Fig. 3과 같다.

3. 데이터 분석 및 파라메터 도출

정상 조립모터와 불량 조립모터를 판별하기 위해서는 조립모터로부터 발생하는 음향을 분석하기 위한 알고리즘과 이 알고리즘에 사용되는 파라메터의 도출이 필요하다. 따라서 마이크를 통하여 채집된 음향을 FFT를 이용하여 주파수영역으로 변환^[2-4] 시킨 뒤, 적절한 가공을 통하여 파라메터들을 도출하고, 이 파라메터들을 이용하여 정상 조립모터와 불량 조립모터를 판별하기로 하였다. 그러나 Fig. 4 와 Fig. 5에서 살펴볼 수 있듯이 정상 조립모터의

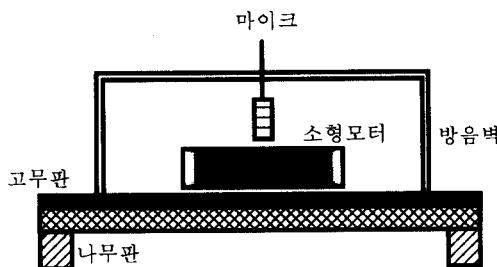


Fig. 2 A cross section of simple sound collection device

구동음과 불량 조립모터의 구동음을 명확히 구분할 수 있는 뚜렷한 특징들은 시간영역의 신호와 주파수 영역의 신호에서 나타나지 않았으며, 특히 Table 1에서 보듯이 불량 조립모터의 경우 다양한 형태의 조립 불량이 존재하고 있다. 즉 단순한 물리적인 한두 가지의 파라메터로는 정상 조립모터와 불량 조립모터를 구분할 수 없는 경우가 대부분이다.

그러므로 조립모터의 구동시 발생하는 구동음의 특성을 최대한 반영하기 위해서는 다양한 종류와 형태의 파라메터 도출이 필요하다. 이는 정상 조립모터와 불량 조립모터에서 발생하는 음향이 각각을 구분할 수 있는 특징이나 패턴을 가지고 있을 것으로 예측되나, 이러한 특징이나 패턴이 단순히 특정한 몇 가지의 파라메터에 의해서 정량적으로나 선형적으로 나타나기를 기대하기는 어렵기 때문이다^[2]. 따라서 본 논문에서는 정상 조립모터와 불량 조립모터를 판별할 수 있는 적절한 파라메터를 선정하기 위하여, 구동음을 16bit, 22KHz로 1초동안 샘플링한 후의 이산치 데이터와 FFT분석한 후의 가공데이터들로 다음의 6가지 파라메터를 선정하였으며 그 종류는 다음과 같다.

- ① FFT 데이터들의 표준편차.
- ② FFT 데이터들의 변동계수.

조립모터 음향판별 소프트웨어



Fig. 3 Experimental set-up on the simple sound collection equipment

- ③ FFT 데이터들의 합.
- ④ FFT 데이터들의 평균.
- ⑤ FFT 데이터들 중의 최고값.
- ⑥ 샘플링된 음향 데이터의 절대범위.

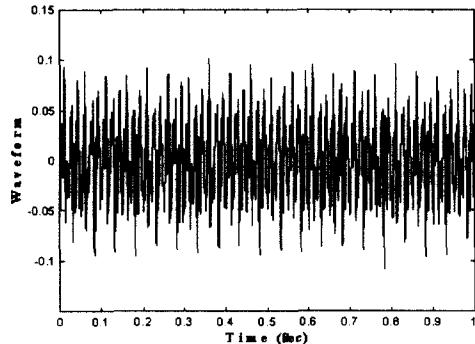
이들 파라메터들 중 ①-⑤는 FFT 후의 각 주파수별 크기의 합과 평균, 최고값을 나타내고 있으며, 특히 FFT 데이터들의 표준편차와 변동계수의 경우 조립모터의 구동음이 가지는 주파수의 절대적 변이 성과 상대적 변이성을 나타내 주고 있으며, 파라메터 ⑥의 경우는 이산화된 음향의 절대크기를 나타내고 있다.

4. 모터 불량 판별 알고리즘

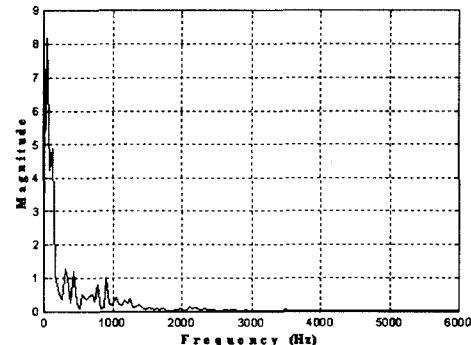
조립모터의 불량판별 알고리즘은 앞 절에서 도

출된 파라메터들을 충분히 활용하기 위하여 인공신경회로망을 이용하였다. 이는 앞 절에서도 언급하였듯이 정상 조립모터와 불량 조립모터를 구분하기 위해서는 적절한 파라메터의 선정이 이루어지더라도 이를 이용한 선형적인 구분이 불가능하므로, 다중 신경회로망에서 다양한 패턴들을 이용한 학습이 가능한 역전파(Backpropagation) 학습 알고리즘을 이용하여 정상 조립모터와 불량 조립모터를 판별하기 위함이다. 즉 정상 조립모터에 대한 파라메터 집합과 불량 조립모터에 대한 파라메터 집합들을 인공신경회로망의 학습데이터로 이용하는 것이다.

역전파 학습 알고리즘은 입력층의 각 유닛에 입력패턴을 주면, 이 신호는 각 유닛에서 변환되어 중간층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값과 기댓값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위층에 역전파하고 하위층에서는 이를 근거로 다시 자

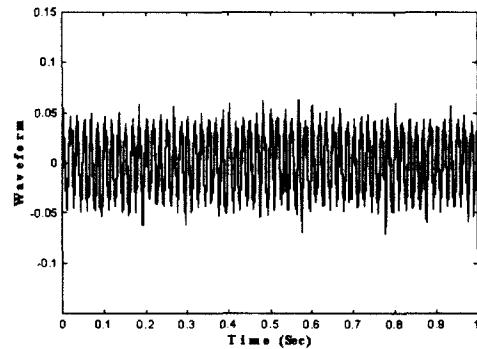


(a) Wave form

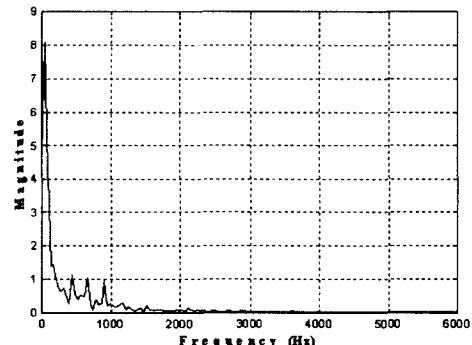


(b) FFT analysis

Fig. 4 Characteristic of normal motor's sound



(a) Wave form



(b) FFT analysis

Fig. 5 Characteristic of abnormal motor's sound

기층의 연결강도를 조절해 나간다. 이때 입력 및 원하는 출력 패턴이 신경회로망에 제시되면 신경회로망은 입력층에 주어진 입력패턴이 출력층에 전파되면서 변한 출력패턴을 목표패턴과 비교한다. 신경회로망에서 출력된 패턴이 목표패턴과 일치하는 경우에는 학습이 일어나지 않는다. 그렇지 않은 경우에는 얻어진 출력패턴과 목표패턴의 차이를 감소시키는 방향으로 신경회로망의 연결강도를 조절하여 학습을 한다^[7]. 따라서 정상 조립모터들의 파라메터 집합과 불량 조립모터들의 파라메터 집합들을 이용하여 신경회로망을 학습시킨다면 모터의 불량여부 판별이 가능하다.

그러나 다층의 구조를 가지는 일반적인 SDBP (Steepest Descent Backpropagation) 학습 알고리즘은 다음과 같은 몇 가지 문제점을 가지고 있다. 첫 번째로 역전파 학습 알고리즘이 지역 최소점에 빠질 가능성이 있다는 것이다. 두 번째로 학습이 완료되기까지 많은 횟수의 반복학습이 필요하며, 세 번째로 추가학습시 학습 파라메터의 조절과 전체적이 재학습이 필요하고, 네 번째로 신경망의 연결강도(weight)와 바이어스(bias)를 찾는데 많은 시간이 많이 걸린다는 것 등이다. 따라서 SDBP를 이용하여 조립모터의 파라메터들을 학습시, 다양한 데이터 학습과 다양한 불량음의 인식 등의 한계에 의하여 정상 조립모터와 불량 조립모터의 판별이 불가능하였다.

따라서 본 논문에서는 이러한 문제들을 최소화하기 위하여 Newton's method의 빠른 수렴성과 최대 하강법(Steepest descent method)의 수렴시 안정성을 보장받을 수 있는 LMBP (Levenberg-Marquardt Backpropagation)를 역전파 학습 알고리즘으로 이용한다^[6-7]. LMBP의 학습절차를 간단히 살펴보면 아래와 같다.

Step 1. 신경회로망의 모든 입력패턴으로부터 얻어지는 출력과 목표출력과의 오차의 제곱의 총합(sum of square error)을 계산한다.

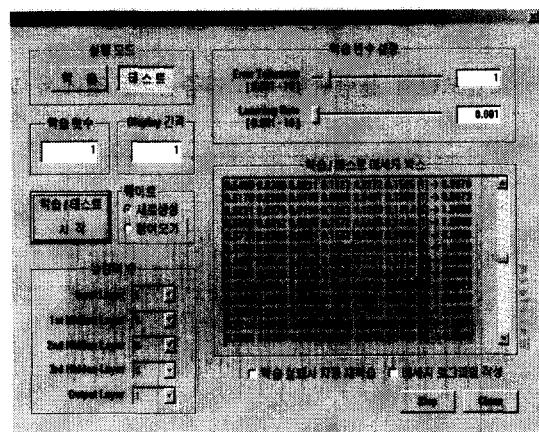
Step 2. 각 층(Layer)의 민감도(Sensitivity)를 구한다. 이때 각각의 민감도는 marquardt sensitivity로 나타낸다. 그리고 자코비안 행렬(Jacobian matrix)을 계산한다.

Step 3. 생성할 파라메터 ΔX 를 다음과 같이 계산한다.

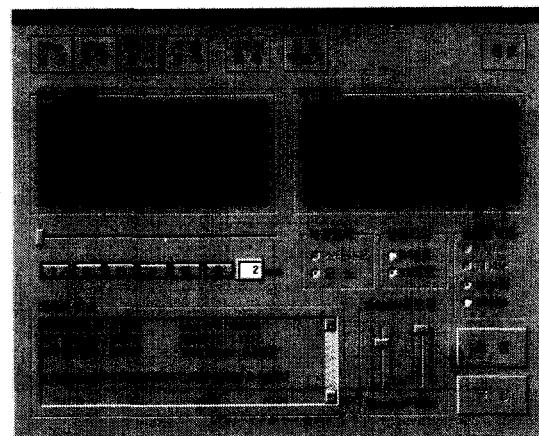
$$\Delta X_k = -[J^T(X_k)J(X_k) + \mu_k I]^{-1} J^T(X_k) V(X)$$

이때 k 는 학습횟수, X 는 매개변수 벡터, J 는 자코비안 행렬, V 는 오차 벡터, μ 는 어떤한 작은 값이다.

Step 4. step 3에 의해 생성된 파라메터를 이용하여 다시 오차를 계산한다. 만약 새로운 오차가 이전의 오차보다 작을 경우는 μ 를 0로 나누어준 뒤 step 1으로 돌아간다. 만약 오차가 줄지 않았다면 μ 를 0로 곱해준 뒤 step 3으로 돌아간다. 이때 0은 1보다 큰 정의된 계수로써, μ 를 0로 나누는 것은 Gauss-Newton 알고리즘과 같으며, μ 를 0로



(a) Neural network train and test



(b) Motor wave test

Fig. 6 Program external appearance

꼽하는 것은 최대 하강법 알고리즘에서 학습율(learning rate)을 작게 만드는 것과 같은 효과를 가진다.

또한 인공신경회로망의 각 층의 연결강도와 바이어스를 초기화시 Nguyen-Widrow method[8]를 이용하여, 각 층의 뉴런들이 가지는 동작영역을 입력 공간에 고르게 분산시킴으로써, 잘못된 동작영역을 가지는 뉴런으로 인한 계산손실을 막고 빠른 학습이 가능하도록 하였다.

5. 실험 및 분석

3절에서 제시된 조립모터의 구동음 분석을 통한 파라메터 도출기능과 4절에서 살펴본 인공신경회로망의 학습기능을 통합하여, 학습된 인공신경회로망을 이용하여 정상 조립모터와 불량 조립모터를 판별할 수 있도록 프로그램을 개발하였다. 이 프로그램은 모터의 구동음을 16bit, 22KHz로 샘플링하여 3절에서 제시된 6가지의 파라메터를 추출한 뒤, 정상 파라메터 집합과 불량 파라메터 집합을 생성하여 인공신경회로망 학습이 가능하도록 저장한다. 이 저장된 데이터들을 이용하여 프로그램 자체에서 인공신경회로망 학습이 가능하며, 따라서 실제 현장에서 테스트하고자 하는 조립모터의 모델이 바뀌더라도 현장에서 바로 재학습 및 판별이 가능하다. Fig. 6(a)는 인공신경회로망을 구성하고, 구성된 인공신경회로망과 저장된 입력패턴을 사용하여 인공신경회로망을 학습시킨 후 학습된 인공신경회로망의 평가가 가능하도록 구성된 화면이다. 또한 Fig. 6(b)는 조립모터의 구동음을 입력받아 구동음에서 6가지의 파라메터를 추출한 후, 학습된 인공신경회로망에 파라메터를 입력시켜 그 입력패턴이 정상인지 불량인지를 판별하는 화면이다.

이 프로그램을 이용하여 Table 1에서 제시되었던 98개의 정상 조립모터들과 103개의 불량 조립모터들에서 각각의 조립모터의 파라메터들로 학습데이터들을 구성하였다. 그리고 신경회로망은 Fig. 7과 같이 6가지의 파라메터들을 입력받기 위한 입력층 6 노드(node)와 첫 번째 은닉층 6 노드, 두 번째 은닉층 6 노드, 세 번째 은닉층 6 노드, 그리고 출력층 1 노드로 구성하였으며, 출력함수는 시그모이드(sigmoid) 함수를 사용하였다. 학습시의 신경회로망의 성능평가는 SSE(Sum of squared error)를 이용

하고 정상 조립모터의 경우 목표값을 1로, 불량 조립모터의 경우 목표값을 0으로 설정하여 학습하였다. 이렇게 해서 학습된 인공신경회로망의 SSE값은 1.00012를 가졌으며 학습 표본으로 사용된 조립모터의 경우 Table 1에서 제시되었던 98개의 정상 조립모터 중 1개를 불량으로 판별하였으며, 103개의 불량 조립모터는 모두 불량으로 판별하였다.

이상에서 학습된 인공신경회로망의 연결강도와 바이어스를 이용하여 검사자에 의해 검사되어 불량 여부는 알고 있으나 학습데이터로 이용되지 않은 20개의 조립모터에 대해서, 제작된 실험장비와 프로그램을 이용하여 테스트한 결과가 Table 2에 제시되어 있다. 이는 숙련된 검사자의 검사에 의한 결과와 테스트에 의해 나온 결과가 일치함을 보여주고 있다. 이로써 기존의 데이터를 이용하여 학습된 인공신경회로망은 단순한 한두 가지의 파라메터를 이용하여 그 패턴의 구분이 불가능하였던 조립모터의 불량 판별을 훌륭히 수행해낼 수 있다.

6. 결과 및 기대효과

본 논문에서는 기어 감속기 불이 소형모터의 구동음을 FFT분석을 통하여 적절한 파라메터를 선정한 후 이를 이용하여 인공신경회로망을 학습시킨 뒤, 불량여부를 알 수 없는 미지의 모터를 판별하여 보았다. 먼저 학습된 인공신경회로망은 학습에 사용된 98개의 정상데이터에 대해서는 97개를 판별함으로써 99%의 학습률을, 103개의 불량데이터에 대해서는 100%의 학습률을 보임으로써 전체적

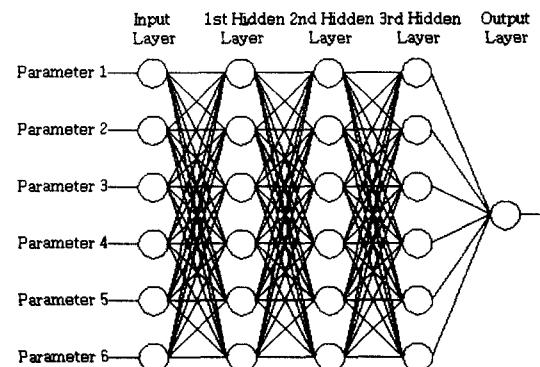


Fig. 7 The configuration of neural network

Table 2 The result of neural network test

불량 조립모터			정상 조립모터		
순번	목표값	출력값	순번	목표값	출력값
1	0	0.0090	11	1	1.0000
2	0	0.0062	12	1	1.0000
3	0	0.0048	13	1	0.9999
4	0	0.0000	14	1	0.9946
5	0	0.0000	15	1	1.0000
6	0	0.0000	16	1	0.9794
7	0	0.0060	17	1	0.9987
8	0	0.0000	18	1	0.9927
9	0	0.0000	19	1	0.9920
10	0	0.0001	20	1	1.0000

으로는 99.5%의 학습률을 보였다. 또한 이렇게 학습된 인공신경회로망을 이용하여 미지의 조립모터를 판별시 10개의 정상 조립모터와 10개의 불량 조립모터를 모두 판별해냄으로써 100%의 판별률을 보였다.

이는 다양한 패턴의 인식이 가능한 인공신경회로망을 불량 조립모터의 판별에 적용함으로써 가능했으며, 이러한 개발내용은 음향 또는 진동을 이용한 각종 검사 등에 널리 적용될 수 있을 것으로 사료된다. 아울러 이를 실제 현장에서 활용이 가능한 소프트웨어로 제작함으로써 현재까지 사람에 의한 조립모터의 불량 판별 작업의 자동화를 통해 검사의 신뢰성 향상 및 검사 작업의 능률 향상 등의 효과가 기대된다.

참고문헌

- M. Y. Chow and S. O. Yee, "An adaptive backpropagation through time training algorithm for a neural controller," Proc. IEEE Int. Symp. Intelligent Control, pp. 170-175, 1991.
- B. Li, M. Y. Chow, Y. Tipsuwan and J. C. Hung, "Neural-network-based motor rolling bearing fault diagnosis," IEEE Trans. Industrial Electronics, Vol. 47, No. 5, pp. 1060-1069, 2000.
- S. Nandi and H. A. Toliyat, "Condition Monitoring and Fault Diagnosis of Electrical Machines - A Review," Proc. 1999 IEEE Industry Applications Meeting, Vol. 1, pp. 197-204, 1999.
- D. D. Gobbo and M. R. Napolitano, "Issues in Fault Detectability for Dynamic Systems," Proc. 2000 American Control Conf., Vol. 5, pp. 3203-3207, 2000.
- S. Altug, M. Y. Chow and H. J. Trussell, "Fuzzy inference systems implemented on neural architectures for motor fault detection and diagnosis," IEEE Trans. Industrial Electronics, Vol. 46, No. 6, pp. 1069-1079, 1999.
- M. T. Hagan and M. Menhaj, "Training feedforward networks with the Marquardt algorithm," IEEE Trans. Neural Networks, Vol. 5, No. 6, pp. 1580-1585, 1994.
- M. T. Hagan, H. B. Demuth and M. Beale, Neural Network Design, PWS Publishing Company, 1996.
- D. Nguyen and B. Windrow, "Improving the learning speed of 2-layer neural networks by

choosing initial values of the adaptive weights,"
IEEE Proc. Int. Joint Conf. Neural Networks, Vol.
3, pp. 21-26, 1990.