

인공신경망을 이용한 유도전동기 고장진단

김부일*, 우혁재*, 송명현*, 박중조**, 김경민***
순천대학교 전기제어공학과*, 경상대학교 제어계측공학과**, 여수대학교 전기공학과***

Faults Diagnosis of Induction Motors by Neural Network

Boo Y. Kim*, Hyuk J. Woo*, Myung H. Song*, Joong J. Park**, Kyung M. Kim***
ECE, Sunchon Nat'l Univ.*, CIE, Gyeongsang Nat'l Univ.**, EE, Yosu Nat'l Univ.***

Abstract - This paper presents a faults diagnosis technique of induction motors based on a neural network. Only stator current is measured, transformed by using FFT and normalized for the training. Healthy, bearing fault, stator fault and rotor end-ring fault motors are prepared to obtain the learning data and diagnose the several faults.

For more effective diagnosis, the load rate is changed by 100%, 60%, 30% of full load and the obtained are applied to the learning process. The experimental results show the proposed method is very detectable and applicable to the real diagnosis system.

1. 서 론

시스템이 점점 복잡하고 정교해짐에 따라 에너지 변환 장치로서 전동기의 사용이 확대되고 전동기의 고장 가능성은 점차 커지고 있으며 생산 공정에서의 전동기 고장은 생산성의 저하를 초래할 뿐 아니라 고장이 발생한 시스템 운전자의 안전을 심각하게 위협하며 시스템의 전제적인 신뢰도를 떨어뜨리고, 복구를 위한 추가 인력, 재정, 및 시간의 손실을 초래하게 되므로 전동기 고장의 초기 검출 및 진단은 매우 중요한 문제로 할 수 있다.

유도 전동기는 최근에 생산 현장에서 주된 동력원으로 자리잡아 가고 있어 유도 전동기의 고장 검출 및 진단에 대한 연구의 필요성이 커지고 있다. 지금까지 알려진 진단 방법으로는 모델링을 기반으로 하는 방법과 신호측정에 의한 방법이 있다. 그러나 모델링을 이용한 방법은 유도전동기의 비선형성으로 인하여 고장 검출 및 진단이 어려워, 전동기의 전동신호, 자장 및 고정자 전류 등의 특성신호를 이용하는 방법이 많이 사용되고 있다[1-2]. 그중 고정자 전류 이용 방법이 데이터 획득이 쉽고 고장 진단에 유리하여 점차 실용화되고 있으며, 최근에는 인공 신경망, 퍼지추론 기법 등에 의한 실시간 검출 진단 기법에 대한 연구가 증가되고 있다[3-4].

따라서 본 논문은 유도전동기의 고장 중 가장 발생빈도가 높은 베어링, 고정자 권선, 회전자 고장들에 대하여 고정자 전류를 이용한 신경회로망을 통한 고장 검출과 진단의 가능성을 제시하였다.

본 논문의 구성은 다음과 같다. 먼저 2절에서 전동기에서 발생 할 수 있는 고장을 대해 설명하고 3절에서 인공 신경망이론에 대하여 간략하게 설명하고, 인공신경망 학습 데이터의 획득방법과 진단방법을 설명하고, 4절에서는 학습에 의한 진단결과를, 5절에서는 결론을 기술하였다.

2. 유도전동기 고장

전기 기기에서 발생할 수 있는 고장을 살펴보면, 크게 전계적 고장, 기계적 고장, 또는 두 고장의 복합으로 볼

수 있다. 대부분의 고장은 기계적 압력이 가장 크게 작용하거나, 절연이 파괴되는 경우와 같은 천이 동작에서 발생 하는 것이 보통이다. 고장이 발생한 경우, 진동, 온도, 자장, 그리고 입력전류 등을 이용하여 감지할 수 있으며, 대부분의 전동기는 전류 센서를 부착하고 있어, 전동기 상태를 모니터링하기 위해 변류기를 사용하면 별도의 하드웨어 추가가 없이 간단하게 시스템을 구현할 수 있다. 전동기 입력전류를 통해 검출할 수 있는 고장들은 베어링고장, 고정자 권선고장 및 회전자 바 그리고 엔드링(End-ring) 고장등이다.

베어링 고장은 부적당하거나 불충분한 윤활, 반경(radii), 그리고 샤프트 편향, 부적절한 마운팅(mounting), 정렬로 인한 축 스트레스에 의해 발생할 수 있다. 발생하는 고장 주파수는 베어링의 기계적 구조와 전동기의 회전속도에 의해 결정된다. 고장시 발생되는 특성 주파수는 다음과 같다[5]

$$f_o = f_e \pm (0.6n f_r) \quad (1)$$

$$f_i = f_e \pm (0.4n f_r) \quad (2)$$

여기서 f_e 는 공급전원의 주파수, k 는 양의 정수, n 은 베어링 볼(bearing ball)의 수, f_r 은 전동기의 회전속도이다.

고정자 고장은 절연체 고장이 원인인 inter-turn권선 고장 때문에 발생할 것이다. 이 고장은 고조파 공극 자속과 전류-시간 고조파 변화에 의해 동반된 고정자의 불균형을 이끈다. 공급 전류의 상대적인 변화를 측정하는 방법으로 고장을 발견한다[6].

회전자 고장은 파동 부하나 직접적 온라인 시동의 결과인 바와 엔드 링 사이 결합의 문제이다. 결과는 전류가 보다 많은 파손의 위험의 증가와 함께 남아있는 바에서 증가한다는 것이다. 회전자 고장은 공급 전류와 축의 펠드에서의 토크 파동, 속도 불안정, 진동, 주파수 요소의 변화를 일으킨다.

회전자 권선 손상에 의해 발생하는 주파수 성분은 다음과 같다[2].

$$f_{bhb} = f_e [k(\frac{1-s}{p/s}) \pm s] \quad (3)$$

여기서 f_e 는 전원 주파수, $\frac{2k}{p} = 1, 5, 7, 13, \dots$ 이다.

3. 인공신경망 시스템에 의한 고장진단

3.1 인공 신경망

신경회로망은 일종의 병렬분산처리를 행하는 간단한 프로세서를 통하여 기존의 기술로 구현하기 어려운 많은 일들을 행한다. 인간의 수리, 계산 능력을 극대화시킨 종래의 컴퓨터는 선형적인 문제의 해결에는 대단히 효율

적이고 빠른 반면, 인간이 지닌 학습, 판단, 인식 등과 같은 것들을 필요로 하는 분야에서는 적용하기가 어려운 것이다. 신경회로망은 이러한 분야에 적극적으로 활용되며 실제 로봇제어, 신호 및 영상처리, 예측 및 진단 등의 분야에서 성공적인 결과를 나타내고 있다[7].

본 연구에서 신경회로망 모델수립에 적용된 알고리즘은 가장 많은 활용도를 보이며 상태진단 분야에서도 널리 이용되고 있는 오차역전파 알고리즘으로[8], 1986년 Rum-ellhart에 의하여 제안된 것으로 Widrow-Hoff (1959) 학습규칙을 다층네트워크와 비선형 미분 가능한 전이함수로 확장한 것이며 오늘날 신경회로망의 비약적인 발전을 뒷받침 한, 다층퍼셉트론(multi-perceptron)의 가장 효과적인 학습알고리즘 중의 하나이다.

오차역전파(error back-propagation) 알고리즘은 오차를 최소화하기 위한 규칙이기 때문에, 오류계도율으로 잘 알려진 Mean Square Error, E를 식 (4)과 같이 정의했을 경우, 가중치-오차 공간에서의 오류 E를 최소로 하는 가중치를 구하는 최소하강법 알고리즘이 된다.

$$E = \frac{1}{2} \sum_i (t_i - O_i)^2 \quad (4)$$

즉, 이것은 음의 오류에 대한 가중치의 미분값을 구하여 이 값에 비례해서 변화시킬 양을 산출하는 방법인데 변화량을 구하기 위해서는 먼저 모든 입력값과 활성화함수(activation function)를 선택하여야 한다. 전체 입력값은 식 (5)와 같으며, 활성화함수는 식 (6)의 미분 가능한 비선형활성화함수를 사용한다.

$$\text{net}_i = \sum W_{ji} O_j \quad (5)$$

$$O_j = \frac{1}{1 + \exp[-\sum W_{ji} O_i + \theta_j]} \quad (6)$$

또한, 전방향 연결선의 가중치를 학습하기 위해서는 위에서 설명한 알고리즘을 사용하여 입력값과 출력값을 쌍으로 주어 실제 출력의 차이가 어떤 한계값 이하로 될 때까지 반복하여 재귀적 연산이 이루어지게 한다. 결과적으로 가중치의 변화량은 식 (7)와 같이 된다.

$$\Delta W_{ji}(t+1) = \eta (\delta_j O_j) + \alpha \Delta W_{ji}(t) \quad (7)$$

여기서 t 는 Time Sequence이고 η 은 학습률(learning rate)로서 값이 클수록 가중치(weight)의 변화량이 큰 값을 가지게 되며, 변수 α 는 진동을 막으면서 학습률을 크게 해주기 위해 도입된 것으로 바로 이전의 가중치 변화량을 얼마만큼 적용시킬 것인가를 나타내는 모멘텀항이다[8].

3.2 고장 진단을 위한 신경망시스템의 구성 및 학습

그림 1은 주파수 스펙트럼을 획득하기 위해 적용된 고장진단시스템으로서, 전류센서에 의해 측정된 전류치는 0khz에서 100khz의 주파수대를 갖는 2채널 FFT 스펙트럼 분석기에서 주파수별로 분석되어 신망에 의한 학습 및 진단이 PC에서 수행된다. 인버터는 범용 인버터를 사용하였으며, 실험 모터는 삼상 유도 전동기로서 60Hz, 0.75kW, 380V, 2A, 36개의 고정자 슬롯과 45개 회전자 슬롯, 다이캐스트(die-cast) 회전자를 가진 4극 유도 전동기이다.

대상 시스템의 고장진단에 이용되는 데이터는 100Hz 대역에서 측정된 것으로 각각 400개의 샘플링 수를 가지고 있으므로 0.25Hz 간격의 분석치를 가지게 된다.

이 값들은 신경망 학습 및 실제 수행시, 각각 하나의 입력노드가 되어 결과적으로 총 400개의 측정값이 신경

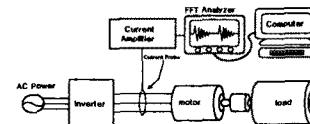


Fig. 1. Fault diagnosis system

망 모델의 입력노드로 구성되며, 이 값들은 신경망 학습 및 실제 수행시 일정한 입력범위를 가지기 위해 노멀라이징(normalizing) 단계를 거친 후 입력이 된다.

데이터 노멀라이징은 식 (8)과 같이 수행하였다. 최대값과 최소값은 시스템이 정상일때의 측정값을 기준으로 하였다.

$$\text{Normalized Data} = \frac{\text{Measured Data} - \text{Min. Value}}{\text{Max. Value} - \text{Min. Value}} \quad (8)$$

신경망 회로망의 출력층은 시스템의 상태진단 결과를 판단하는 부분으로, 여기서는 앞서 분석한 시스템 고장에 관한 정보를 바탕으로 그림2와 같이 모두 4개의 출력값을 선정하였다. 학습은 오차 역전파 학습 알고리즘을 이용하였다.

실제 회로의 모델 선정을 위하여 학습시 선정되어야 할 것들로는 은닉층(hidden layer)개수, 은닉층 노드수, 활성화 함수, 활성화 함수 계수, 모멘텀 계수 등이 있다. 오차 역전파 알고리즘의 경우 그 학습절차가 이미 수학적으로 알려져 있기 때문에[8], 본 논문에서는 이것을 범용 프로그래밍 언어인 C언어로 신경망 함수를 구성하여 해당 학습수행에 적용하였다. 학습에 이용된 개략적 환경은 다음과 같다.

[Algorithm: Back-propagation algorithm]	
• Tool(Program language)	: C
• Activation function	: log-sigmoid function
• Input/output node	: input node(400), output node(4)
• No. of hidden layer	: 1 ~ 2
• No. of node in hidden layer	: 200 ~ 805

4. 적용 결과 및 고찰

학습 수행결과 제시되는 가중치행렬을 토대로 실제 고장 발생시 측정된 데이터를 실행시켜 보았다.

각 패턴당 최소 200번에서 최대 2,000번까지 학습을 수행하였다. 학습횟수가 증가함에 따라 오차의 감소율은 점차 줄어들었으나, 성능과 횟수사이에는 큰 차이가 없어 학습횟수를 500번으로 설정하였다. 그리고 활성화함수계수(coefficient of log-sigmoid function)는 보편적으로 사용하는 1.0으로 설정하였다. 은닉층의 수는 1~2까지 변화시켜 보았으며 학습결과 은닉층이 1개일 경우는 학습이 제대로 수행되지 않았으나 2개의 은닉층에서는 학습이 수행되었으며 은닉층 노드수의 경우 200~805, 20~100로 변화시키면서 수행해 본 결과 가장 양호한 응답은 600, 50개일 경우였으며 경우에 따라서 노드수의 증감에 따라 출력에러가 변하였다.

학습률은 0.4~0.9까지 변화시키면서 살펴보았다. 값이 증가할수록 오차는 감소하였으나 값이 커질수록 학습결과가 불일치함을 보였다. 특히 full load에 대한 정보만으로 학습률 0.7에서 학습을 수행하였을 때 학습은 제대로 되었으나 적용에 있어 30% 베어링 고장을 제대로 진단해 내지 못하였다. 이에 따라 30% load와 60% load의 정보에 대한 학습을 수행하였으나 이 경우에는 회전자 고장과 베어링고장의 데이터가 제대로 학습되지 않아 학습률을 조정한 결과 학습률 0.5에서 만족할 만한 응답을 얻었다. 모멘텀 계수의 경우는 0.4~0.95까지 변화시켰으며 학습률과 마찬가지의 결과를 보여주었다.

표1과 그림2는 전동기의 3가지 고장과 정상조건의 전동기에 대한 부하별(100%, 60%, 30%) 전류 데이터를 FFT로 변환한 신호를 노멀라이징을 거쳐 진단 시스템에 시험입력으로 주어졌을 때 학습된 결과를 토대로 한 고장 진단의 결과를 보여주고 있다. 각 고장별 오차 범위는 최저 0.56%에서 최고 0.04%로서 높은 진단 정밀도를 가지고 있어 제시된 방법이 유용함을 보여주고 있다.

Table. 1. Result of diagnosis output

A kind of sample	Load	Target	Actual output
Sound motor	full		0.000599 0.001751 0.002570 0.999561
	60%	0 0 0 1	0.003166 0.001993 0.002629 0.998150
	30%		0.003761 0.002444 0.001459 0.994439
Winding fault	full		0.000787 0.001049 0.997623 0.000174
	60%	0 0 1 0	0.004944 0.000218 0.996976 0.000666
	30%		0.004940 0.000626 0.997357 0.000157
Broken rotor bar	full		0.000374 0.999693 0.000459 0.000085
	60%	0 1 0 0	0.000338 0.999477 0.000705 0.000092
	30%		0.000040 0.996652 0.003714 0.001577
Bearing fault	full		0.999050 0.000451 0.001613 0.001441
	60%	1 0 0 0	0.996142 0.000866 0.002839 0.002214
	30%		0.995068 0.001078 0.002863 0.002643

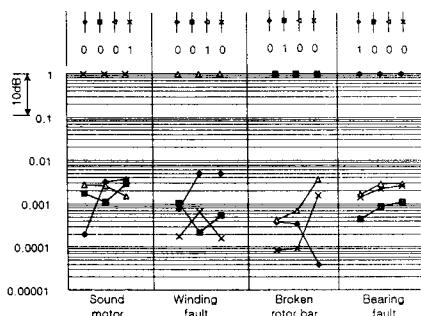


Fig. 2. Result of diagnosis output

5. 결 론

본 연구에서는 유도전동기 입력 전류 스펙트럼의 인공신경망 학습을 통한 고장 검출 및 진단방법을 제시하였다. 베어링 고장, 고정자 권선고장, 회전자 앤드링고장 및 정상의 유도전동기를 준비하여 고장 검출 및 진단 실험을 통하여 본 시스템의 유용성을 증명하였고 다음의 결론을 얻었다.

(1) 유도 전동기 고장 검출 및 진단을 위하여, 입력전류만을 이용함으로써 진동센서 같은 별도의 추가적인 하드웨어 없이 유도전동기 고장 검출 및 진단이 가능하다.

(2) 고장 검출을 위해 학습 클러스터링 기법을 적용함으로써, 유도 전동기 부하 변동에 영향을 받지 않는 고장 검출 기법을 제시하였다.

(3) 가장 고장 빈도가 많은 3가지 전동기 고장을 인공신경망을 이용하여 확실하게 고장을 진단할 수 있었다.

앞으로 인공신경망의 데이터 적용과 파라미터 설정의 유연성의 부재와, 고정된 지식을 스스로 보완해 나갈 수 있는 지능적 시스템의 연구개발이 이루어진다면 시스템의 고장 진단에 대한 신뢰도를 높일 수 있을 것으로 기대된다.

(참 고 문 헌)

- [1] P. Vas, Parameter Estimation, Condition Monitoring, and Diagnosis of Electrical Machines, Oxford Science Publications, 1993
- [2] R. R. Schoen, B. K. Lin, T. G. Habetler, J. H.

Schlag, S. Farag, "An Unsupervised On-Line System for Induction Motor Fault Detection Using Stator Current Monitoring", IEEE Trans. Industry Application, vol. 31, no. 6, pp. 1280-1286, 1995

[3] Alan S. Willsky, "A Survey of Design Methods Failure Detection in Dynamic System", Automatica, vol. 12, pp. 601-611, 1976

[4] Mo-yuen Chow, Robert N. Sharpe, and James C. Hung, "On the Application and Design of Artificial Neural Networks for Motor Fault Detection-Part I", IEEE Transactions on Industrial Electronics, vol. 40, No. 2, April, 1993

[5] Randy R. Schoen, Thomas G. Gabetler, Farrukh Kamran, and Robert G. Bartheld, "Motor Bearing Damage Detection Using Stator Current Monitoring", IEEE Trans. on Industry Applications, Vol. 31, No. 6, November/December, 1995

[6] J. Penman, H. G. Sedding, and W. T. Fink, "Detection and Location of Interturn Short Circuits in The Stator Winding of Operation Motors", IEEE Trans. on Energy Conversion, vol. 9, No. 4, December, 1994

[7] Chin-Teng Lin & C.S. George Lee, Neural Fuzzy systems, Prentice-Hall, 1996

[8] B.K.N. RAO, Handbook of Condition Monitoring, Elsevier Advanced Technology, 1996