

인공 신경망을 이용한 분권 전동기의 고장 진단

이기상, 최낙원^o, 임재형, 이정동

단국대학교 전기공학과

Fault Diagnosis of Shunt Motor
using Artificial Neural NetworkKee-sang Lee, Nak-Won Choi^o, Jea-Hyung Lim, Jeong-Dong Lee

Dept. of Electrical Eng., Dankook Univ.

Abstract

A Fault Detection, Isolation scheme based on ANN(Artificial Neural Network) is proposed for the supervision of a DC shunt motor. The Proposed FDIU scheme can promptly detect the occurrence of fault and classify all the faults that may occur during the operation. Also, it covers the full operating range in spite that the mathematical model of the motor contain strong nonlinearities. The simulation results show that the FDIU has good diagnostic ability even in the noisy environment.

1. 서론

산업 플랜트의 대형화, 자동화가 급속히 이루어짐에 따라 이를 가능케 해 주는 구동 장치로서, 각종 전동기의 활용 범위와 그 역할이 더욱 확대되고 있다.

일반적으로 대부분의 전동기는 견고하게 제작되므로 돌발적인 고장은 매우 적지만 기계적, 또는 전기적 결함이 점진적으로 증가되고, 그 결과 계통 성능의 감퇴 및 운전 정지를 초래할 수 있다. 특히, 대부분의 직류전동기는 유도기와는 달리 브러시 등과 같이 오른 기능성이 큰 부품을 포함하므로 고장에 대한 지속적인 점검이 요구된다. 그러나, 운전중인 전동기의 점검에는 숙련된 전문가와 장시간의 관찰이 요구된다. 따라서, 다수의 전동기를 포함한 대형 플랜트의 경우에는 지속적인 감시와 점검을 위하여 자동화된 고장 검출 진단 시스템의 도입이 필수적이다. 전동기 고장 검출 진단 기법은 80년대부터 연구되어 있으며, vibration monitoring, particle analysis 등의 고전적인 기법과, 상태 추정, 파라미터 추정 등에 근거한 해석적 기법이 개발되었으며, 최근에는 ANN, 퍼지 추론 기법 등에 의한 실시간 검출 진단 기법에 대한 연구가 활발히 진행되고 있다. [1][2][3][4]

본 논문에서는 이미 언급한 직류전동기 중 비선형성을 포함하므로써, 기존의 해석적 기법에 의한 FDIU의 설계가 매우 곤란한 직류 분권전동기를 대상으로 이 전동기에서 발생할 수 있는 모든 고장을 신속히 검출하고, 고장 원인을 진단(분류)하는 기능을 가진 신경망을 이용한 FDIU를 설계하고, 그 유용성을 입증함에 그 목적을 둔다.

2. 직류 분권전동기의 모델 및 고장

2.1 구조 및 수학적 모델

고장 검출 진단 대상인 직류 분권전동기의 구조는 그림 1과 같고, 식(1)의 비선형 상미방으로 표현된다.

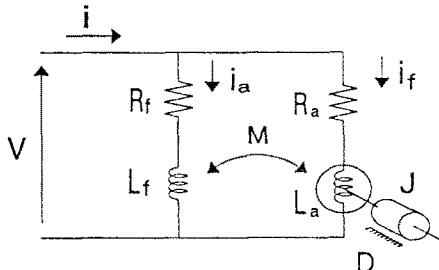


그림 1 직류 분권전동기

$$\begin{aligned} i_f &= -\frac{R_f}{L_f} i_f + \frac{1}{L_f} V \\ \dot{i}_a &= -\frac{R_a}{L_a} i_a - \frac{M}{L_a} i_f u + \frac{1}{L_a} V \\ \dot{u} &= \frac{M}{J} i_f i_a - \frac{D}{J} u \end{aligned} \quad (1)$$

여기서 i_f , i_a , u 는 상태 변수로서 계자 전류, 전기자 전류 및 회전속도이며, R_f , L_f 는 계자 저항과 인덕턴스, R_a , L_a 는 전기자 저항과 인덕턴스, M 은 L_f 와 L_a 간의 상호 인덕턴스, D , J 는 각각 부하 점성저항 및 관성모멘트이고, V 는 입력전압이다.

2.2 검출 진단 대상의 고장

직류전동기의 고장 요소와 파라미터 변화 간의 관계는 표1과 같다. [2]

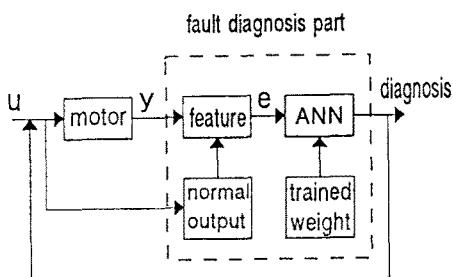
표1 전동기의 고장 '요소와 파라미터 변화 간의 관계'

고장 요소	R_a	L_a	M	D	J
브러시 결합	증가	—	—	—	—
전기자 코일 결합	감소	감소	감소	—	—
전기자 코어 결합	—	감소	감소	—	—
부하(급변)	—	—	—	증가	증가
축수(베어링)	—	—	—	증가	—

단, 표1은 계자 회로의 고장은 발생하지 않고, 또한 전동기의 고장 요소 중 한번에 하나의 고장이 발생한다는 가정을 전제로 한다.

3. FDIU의 설계

제안된 FDIU의 구조는 그림 2와 같다. 이 FDIU의 설계 과정은 운전(실험) 데이터를 분석하여 각 고장을 차별화 해주는 특징량을 설정, 추출하는 단계와 각 특징량과 고장 원인간의 인과관계를 ANN에 학습시키는 단계로 이루어 지며, 이 과정에서 FDIU의 고장 검출 진단 성능을 좌우하는 핵심 요소인 학습 데이터 선정 및 처리, 진단을 위한 지식 기반, ANN 구조 및 학습 알고리즘은 다음과 같다.



[그림2] 고장 검출 진단 시스템

3.1 학습 데이터의 선정

고장 진단은 패턴 분류 문제라고 할 수 있으며, 따라서 제작된 ANN base FDIU의 성능은 학습 데이터의 질에 의해 매우 큰 영향을 받는다. 전동기의 고장 검출과 진단을 위한 학습 데이터는 일정 전압에 대응되는 정상 운전시의 정상상태값, 즉 기준량과 고장 발생시의 정상상태 출력값, 즉 특징량에 근거하여 주출한다.

3.1.1 특징량의 추출

특징량은 진단 대상 고장의 식별에 농통한 전문가에 의해 또는 각 고장 데이터를 분석하므로써 선정될 수 있다. 본 연구에서는 일정한 입력전압하의 각 고장에 대한 결과를 분석 검토하므로써 상태변수와 입력전압의 조합으로 다음의 네 가지 특징량을 선정하였다.

$$\begin{aligned} f_r^1 &= \frac{i_a}{V} \\ f_r^2 &= \frac{\omega}{V} \\ f_r^3 &= \frac{i_a \cdot \omega}{V} \\ f_r^4 &= \frac{\omega}{(i_a \cdot i_p)} \end{aligned} \quad (2)$$

여기서, i_p , i_a , ω 는 고장 발생시의 전류값, 속도값이다.

3.1.2 기준량의 추출

고장 검출과 진단의 기준이 되는 모든 상태변수의 정상상태값은 오직 입력전압에 의해서만 결정되며, 다음과 같이 표현된다.

$$\begin{aligned} i_{\infty} &= \frac{R_f^2 DV}{R_a R_f^2 D + M^2 V^2} \\ \omega_0 &= \frac{R_f M V^2}{R_a R_f^2 D + M^2 V^2} \end{aligned} \quad (3)$$

이때, i_p , i_{∞} , ω_0 는 정상 운전시의 기준 전류값, 속도값이고, 기준량은 이들과 입력전압의 조합으로 구성되며 식(3)과 같다.

$$\begin{aligned} f_d^1 &= \frac{i_{\infty}}{V} \\ f_d^2 &= \frac{\omega_0}{V} \\ f_d^3 &= \frac{i_{\infty} \cdot \omega_0}{V} \\ f_d^4 &= \frac{\omega_0}{(i_{\infty} \cdot i_p)} \end{aligned} \quad (4)$$

3.1.3 학습 데이터의 가공

앞에서 추출된 특징량은 단순히 응답패턴만을 나타내는 수치들이다. 따라서 이를 정보를 이용하여, FDIU를 위한 ANN을 학습시키기 위해서는 먼저, 각 기준량과 특징량과의 편차를 구해야 하며, 다음으로는 이를 특징량이 같은 비중으로 적용될 수 있도록 정규화 하여야 하며, 다음과 같다.

$$f_N^i = \frac{f_d^i - f_d^1}{f_d^4}, \quad i = 1, 2, 3, 4 \quad (5)$$

3.2 진단 규칙기반의 구축

표2는 일정 입력전압하에서 정규화된 특징량과 고장 요소와의 관계를 분석하여 도표화한 것이다.

표2 특징량과 고장간의 관계

정규화된 특징량	고장의 종류				
	브러쉬 코일	전기자 코일	전기자 케이스	과부하	축 수
f_N^1	감소	증가	증가	증가/불변	증가/불변
f_N^2	감소	감소	증가/불변	감소	감소
f_N^3	감소	증가	증가	불변/감소	불변/감소
f_N^4	불변	감소	감소	감소	감소

표2로부터 다음과 같은 진단규칙을 추출할 수 있다.

Rule 1:

If($f_N^1, f_N^2, f_N^3, f_N^4$) = (감소, 감소, 감소, 불변)
THEN 브러쉬의 고장

Rule 2:

If($f_N^1, f_N^2, f_N^3, f_N^4$) = (증가, 감소, 증가, 감소)
THEN 전기자 코일의 고장

Rule 3:

If($f_N^1, f_N^2, f_N^3, f_N^4$) = (증가/불변, 감소, 불변/감소, 감소)
THEN 전기자 케이스의 고장

Rule 4:

If($f_N^1, f_N^2, f_N^3, f_N^4$) = (증가/불변, 감소, 불변/감소, 감소)
THEN 과부하 / 부하의 고장

위의 진단 규칙들은 설계된 ANN base FDIU의 진단 과정에 대한 정성적 표현이라는 측면에서 중요한 의미를 가지며, 편지 전문가 진단 시스템등의 구축에 매우 유용하게 사용될 수 있다.

3.3 진단을 위한 ANN 구조 및 학습 알고리즘

채택된 ANN은 3층구조의 perceptron network으로서, 정규화된 특징량을 입력으로 하고, 식별 대상 고장을 출력으로 한다. 따라서, 입력층과 출력층의 뉴런수는 각각 4개로 구성되며, 은닉층의 뉴런수는 10개로 설정하였다.

또한, ANN의 학습은 역전파 알고리즘을 사용하였고, 각 뉴런의 활성 함수로는 가장 일반적인 식(6)의 시그모이드 함수를 사용하였으며,

$$f(NET) = \frac{1}{1 + e^{-NET}} \quad (6)$$

패턴 p에 대한 에너지 함수 E_p 는 각 출력 유니트의 2차 형식으로 식(7)과 같다.

$$E_p = \frac{1}{2} \sum_k (TARGET_{pk} - OUT_{pk})^2 \quad (7)$$

이때, Delta 함수는 식(8)과 같고,

$$\delta_{qk} = OUT_{qk}(1 - OUT_{qk})(TARGET_{qk} - OUT_{qk}) \quad (8)$$

Momentum항을 포함한 연결강도의 변화량은 식(9)와 같다.

$$\Delta W_{pq,k}(n+1) = \alpha \Delta W_{pq,k}(n) + (1 - \alpha) \delta_{qk} OUT_{pj} \quad (9)$$

그리고, 오차에 의해 조정된 연결강도는 식(10)과 같다.

$$W_{pq,k}(n+1) = W_{pq,k}(n) + \eta \Delta W_{pq,k}(n+1) \quad (10)$$

위에서, δ_{qk} 는 출력층, k에서 q번째 뉴런의 편차, OUT_{qk} 는 출력층, k에서 q번째 뉴런의 출력, $TARGET_{qk}$ 는 출력층, k에서 q번째 뉴런의 원하는 출력값, η 는 학습률, α 는 평활화 계수, 그리고 OUT_{pj} 는 은닉층, j에서 p번째 뉴런의 출력이다.

4. 시뮬레이션 결과 검토

제작된 ANN base FDIU의 성능을 검토하기 위하여 표3의 파라미터를 갖는 본관전동기에 대하여 표4와 같이 파라미터를 변화시켜, 전동기의 정상상태 출력값을 학습 데이터로 사용하였고, 이때 입력전압들은 고장 대상 전동기의 운전 영역에 따라 임의로 설정될 수 있으며, 본 논문에서는 70 V, 80 V, 90 V, 100 V로 선정하였다.

표3 전동기의 파라미터 값[2]

R_a	3.8 [Ω]	M	0.221 [H]
L_a	0.5 [H]	D	0.042 [Nmms/rad]
R_f	50 [Ω]	J	0.4 [kgm ²]
L_f	20 [H]		

표4 고장 요소에 따른 파라미터의 변화
(주어진 입력전압 : 70 V, 80 V, 90 V, 100 V)

고장요소	파라미터	파라미터 변화의 크기(%)
브러쉬	R_a	+5, +10, +20
전기자 회로	L_a	-5, -10, -20
	M	-5, -10, -20
	R_a	-5, -10, -20
전기자 코어	L_a	-5, -10, -20
	M	-5, -10, -20
	D	+5, +10, +20
과부하	J	+5, +10, +20

그림 3은 입력전압이 95 V일때 5%의 파라미터 변화에 대한 고장의 결과이며, 그림 a)는 브러쉬의 결합, 그림 b)는 전기자 회로의 결합, 그림 c)는 전기자 회로의 절연이 변화된 경우, 그리고 그림 d)는 축수 결합 또는 과부하를 나타낸다. 그림 3의 결과는 신경망의 연결강도를 학습시킨 입력전압과는 다른 동작점에서의 고장 진단이 가능함을 보여준다.

표5는 학습에 사용된 고장량 보다 큰 고장 뿐 아니라, 작은 고장이 발생하는 경우에도 고장 진단이 가능함을 나타내고 있으며, 이 결과는 설계된 FDIU가 초기 고장의 신속한 검출, 분류에 사용될 수 있음을 의미한다.

표6은 제안된 FDIU의 잡음에 대한 강인성을 검토한 결과이다. 잡음은 측정되는 변수, 즉 i_a , i_f , θ , V 에 투입되었으며, 모든 경우 zero-mean인 백색잡음을 가정하였다. 각 측정 잡음의 분산은 대응되는 변수값의 0.2, 0.4, 1%의 세가지 경우를 고려하였다. 표6의 결과는 고장의 크기가 매우 작고(5%이내) 잡음의 분산이 변수값의 1%(표준 편차 10%)를 초과하는 경우를 제외한 모든 경우에 거의 완벽한 진단이 가능함을 보여준다.

표5 고장량에 따른 고장 진단
(입력전압 95 V, 단위 [%])

고장요소	파라미터 변화의 크기					
	1 %	2 %	3 %	4 %	7 %	15 %
브러쉬	0	0	100	100	100	100
전기자코일	0	0	100	100	100	100
전기자코어	0	0	100	100	100	100
과부하	0	0	0	100	100	100

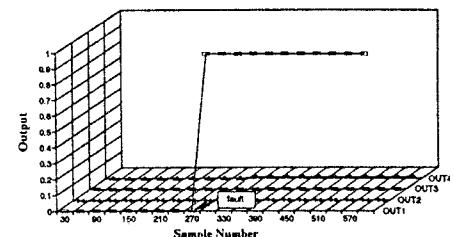
표6 파라미터 변화에 잡음을 첨가시 고장 진단
(입력전압 95 V, 단위 [%])

고장요소	잡음의 크기	파라미터 변화 크기		
		5 %	10 %	20 %
브러쉬	0.2	100	100	100
	0.4	97.5	100	100
	1.0	75	96	100
전기자코일	0.2	100	100	100
	0.4	99.5	100	100
	1.0	81	100	100
전기자코어	0.2	100	100	100
	0.4	99.5	98.5	100
	1.0	73	80.5	97
과부하	0.2	100	100	100
	0.4	93.5	99	100
	1.0	61	80.5	99

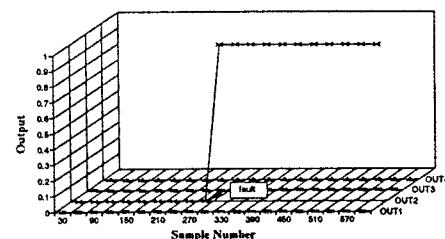
6. 결론

본 논문에서는 직류 분권전동기의 성능 시험 및 운전중의 고장 검출 진단에 효과적으로 사용될 수 있는 FDIU를 설계하고, 그 성능을 검토했다.

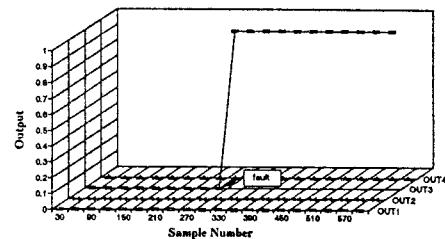
제안된 FDIU는 페턴 분류 및 비선형성의 처리에 매우 유용한 인공신경회로망에 근거하여 설계되었다. 시뮬레이션에 의한 성능 검토 결과는 이 FDIU가 분권전동기 운전중 발생할 수 있는 네 가지의 고장을 신속히 분류하며, 특히 비교적 큰 축정 잡음이 투입된 경우에도 좋은 진단 성능을 유지함을 보여주고 있다.



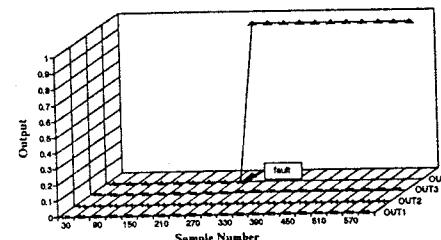
a) 브러쉬의 결합이 발생한 경우 출력 패턴



b) 전기자 회로의 결합이 발생한 경우 출력 패턴



c) 전기자 회로의 절연이 변화한 경우 출력 패턴



d) 축수 결합 / 과부하가 발생한 경우 출력 패턴

[그림 3] 고장 (입력전압 95 V)

참고 문헌

- [1] ALAN S.Willsky, "A Survey of Design Methods for Failure Detection in Dynamic System", *Automatica*, Vol. 12, pp. 601-611, 1976.
- [2] K.Watanabe, M.Sasaki and D.M.Himmelblau, "Determination of Optimal Measuring Sites for Fault Detect of Non-Linear System", *INT. J. SYSTEMS SCI.*, Vol. 16, No.11, pp. 1345-1363, 1985.
- [3] 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.
- [4] Kee-Sang Lee and Sang-Wook Bae, "A Process Fault Detection Filter Design by Fault Vector Model Approach and Application", *TKIEE*, Vol. 36, No. 6, June, 1987