

뉴로-퍼지를 이용한 변압기 보호계전 알고리즘

論文

52A-12-7

Protective Relaying Algorithm for Transformer Using Neuro-Fuzzy

李銘倫* · 李鍾範** · 徐在鎬**
(Myoung-Rhun Lee · Jong-Beom Lee · Je-Ho Seo)

Abstract – Current differential relay is commonly used to protect power transformer. However, current differential relay will be tripped by judging like internal fault during inrush occurring in transformer. To resolve such problem, this paper proposes a new protective relaying algorithm using Neuro-Fuzzy Inference. A variety of transformer transition states are simulated by BCTRAN and HYSDT of EMTP. Primary phase voltage and differential current are obtained from simulation. The target data which are used in Neuro-Fuzzy algorithm are obtained from transformed primary voltage and current. Then, these are trained by Neuro-Fuzzy algorithm. The trained Neuro-Fuzzy algorithm correctly distinguishes whether internal fault occurs or not, within 1/2 cycle after fault. Accordingly, it is evaluated that the proposed algorithm has good relaying characteristics.

Key Words : Current differential relay, Internal fault, Inrush, Overexcitation, Neuro-Fuzzy algorithm

1. 서 론

전력용 변압기를 보호하기 위해서는 일반적으로 비율차동 계전방식이 사용된다. 이 방식은 제2고조파 성분을 이용하여 여자돌입 현상을 판단하고 이를 억제요소로, 5고조파 성분을 이용하여 과여자 상태를 판단하고 이를 억제요소로 이용하는 방식이다. 그러나 최근에 제작되는 변압기는 여자돌입시 변압기 차전류에 제2고조파 함유율이 줄어드는 경향이 있어, 변압기 여자돌입현상을 판단하기 어려운 경우가 생긴다. 또 송전 전압이 높아지고 지중선로가 많아짐에 따라 제2고조파 함유율이 많아져 내부고장을 여자돌입 상태로 잘못 판단하는 경우가 발생할 수 있다[1-3]. 이러한 문제점을 보완하기 위해 변압기 보호 알고리즘에 신호처리 방법을 이용한 웨이브렛변환(Wavelet Transform)[3-4]이 적용되었다. 또 신경회로망(Neural Network)[4-5], 퍼지 논리(Fuzzy Logic)[6]등의 인공지능기법을 이용한 알고리즘 방식들도 제시되었다. 이러한 변압기 보호 알고리즘의 적용 방법에 있어 본 논문에서는 효과적인 인공지능기법으로 평가되고 있는 뉴로-퍼지(Neuro-Fuzzy)를 적용하였다. 이는 언어적으로 표현이 가능한 퍼지이론과 입출력 관계를 학습시킬 수 있는 신경회로망이 결합된 구조로서 기존의 인공지능 방법이 가지는 단점이 보완된 구조이다[7-9]. EMTP(Electromagnetic

Transient Program)를 이용하여 총 82가지의 변압기 내부고장, 여자돌입, 과여자, 정상 상태를 모의하였으며, 모의하여 얻은 전압과 전류 데이터를 가공하여 입력 변수로 사용하였다. 본 논문에 사용된 입력 변수는 1차측 각 상 전압의 RMS변화분 X와 변압기 1차 전류와 차전류에 포함되어 있는 기본파 함유율을 가공하여 만든 Y이다. 전력용 변압기 보호에 적용될 목표 데이터는 고장 후 반주기의 입력변수 X와 Y를 토대로 만들어진다. 그런 다음 뉴로-퍼지 알고리즘을 적용하여 학습시킨다. 이렇게 학습된 뉴로-퍼지 알고리즘은 변압기 고장 상태를 정확히 판단하였고 1/2주기 이내에 계전기 트립 여부 결정함으로써 아주 양호한 계전특성을 가짐을 확인하였다.

2. 뉴로-퍼지

2.1 뉴로-퍼지 이론

뉴로-퍼지는 퍼지 이론의 언어적 논리를 규칙의 형태로 표현 할 수 있는 능력과 신경회로망의 오류 역전과 알고리즘을 사용한 학습기능이 서로 결합한 형태로 양 이론의 장점을 이용하여 서로의 단점을 보완한 구조이다. 이는 퍼지 논리와 신경회로망이 갖는 독특한 특성들을 가진 것으로 복잡성과 불확실성을 갖는 비선형 시스템에서 다른 지능형 모델 보다 우수한 성능을 가지고 있다[7]. 이와 관련된 연구 중 Jang은 결론부를 입력에 대한 선형 방정식으로 표현한 ANFIS(Adaptive Network-Based Fuzzy Inference System) 구조를 제안하였다[8-9]. 이는 1차 슈게노시스템 파라미터들을 최적화시키기 위해 혼합된 학습 규칙을 사용하는 구조로 그림 1과 같다.

* 準會員：圓光大 電氣工學科 碩士課程

** 正會員：圓光大 電氣電子 및 電氣工學部 教授 · 工博

接受日字：2003年 3月 17日

最終完了：2003年 10月 30日

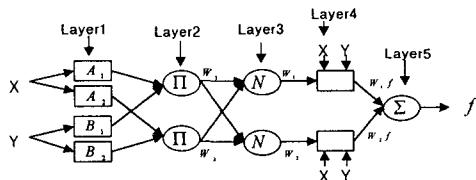


그림 1 ANFIS 구조

Fig. 1 The structure of ANFIS

여기에서 x, y 는 입력, A_i, B_i 는 각 입력에 대한 소속 함수, f_i 는 각 규칙에서의 출력, (p_i, q_i, r_i) 학습되어질 후 전부 파라미터이다.

그림 1의 언어적 규칙은 다음과 같다.

Rule 1: IF x is A_1 and y is B_1 , then $f_1 = p_1x + q_1y + r_1$

Rule 2: IF x is A_2 and y is B_2 , then $f_2 = p_2x + q_2y + r_2$

각 층의 동작에 대해서 살펴보면 다음과 같다.

Layer 1 : 입력 변수 x, y 가 소속함수에 소속되는 정도를 의미하며 입력 신호에 대한 멤버쉽 값을 식 (1)과 같이 계산한다.

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x) & i=1, 2 \\ O_{1,i} &= \mu_{B_{i-2}}(y) & i=3, 4 \end{aligned} \quad (1)$$

식(1)에서 x, y 는 입력, A_i, B_{i-2} 는 소속함수, $O_{1,i}$ 는 입력 x, y 가 소속함수에 소속되는 정도, 소속함수는 가우시안 함수로 표현될 수 있으며 이는 식 (2)와 같다.

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} \quad (2)$$

여기에서 a_i, b_i, c_i 는 전전부 파라미터로서 이들을 조정함으로써 소속함수의 모양을 변화시킬 수 있다.

Layer 2 : 식 (3)과 같이 각 규칙의 적합도를 계산한다.

$$O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_{i-2}}(y) \quad (3)$$

Layer 3 : 각 규칙의 적합도가 구해지면 식 (4)와 같이 i 번째 적합도에 대한 모든 규칙의 적합도 합의 비로 정규화된 값을 계산한다.

$$O_{3,i} = w'_i = \frac{w_i}{\sum w_i} \quad (4)$$

Layer 4 : 각 규칙에 대한 출력을 의미하며 식 (5)와 같이 Layer 3에서 구해진 i 번째의 정규화된 값과 i 번째의 규칙에서의 출력값과의 곱을 수행한다.

$$O_{4,i} = w'_i (p_i x + q_i y + r_i) \quad (5)$$

여기에서, p_i, q_i, r_i 는 학습되어야 할 후전부 파라미터 파라미터이고 이는 최소자승법에 의해 구해진다.

Layer 5 : Layer 4에서의 출력 $O_{4,i}$ 를 모두 합한 최종 출력을 계산하며 이는 식 (6)과 같다.

$$f = \sum_i w'_i f_i = \frac{\sum_i w'_i f_i}{\sum_i w_i} \quad (6)$$

여기에서, f_i 는 각 규칙의 출력이다.

추론 과정을 그림으로 보면 그림 2와 같다.

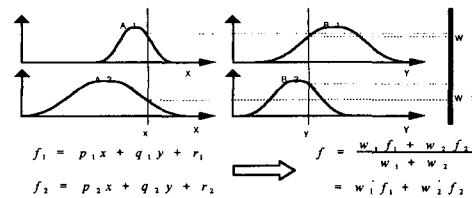


그림 2 추론과정

Fig. 2 Inference process

뉴로-퍼지의 최종 출력은 식 (7)과 같이 후전부 파라미터의 조합으로 표현될 수 있으며 후전부 파라미터는 최소장승법에 의해 구해지게 된다.

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= w'_1 (p_1 x + q_1 y + r_1) + w'_2 (p_2 x + q_2 y + r_2) \\ &= w'_1 (p_1 + w'_2 p_2) x + (w'_1 p_1 + w'_2 p_2) y + (w'_1 r_1 + w'_2 r_2) \end{aligned} \quad (7)$$

뉴로-퍼지 알고리즘의 학습은 식 (8)과 같이 출력 오차 E_p 를 최소화하기 위해 오류 역전파 알고리즘이 사용되고 이는 연결 가중치 w_i 를 조정함으로써 이루어진다.

$$E_p = (y_p - y'_p)^2 \quad (8)$$

여기서, E_p 는 출력 오차, y_p 는 목표 데이터, y'_p 는 모델의 출력이다.

연결 가중치 w_i 는 식 (9)와 같이 경사하강법(gradiant decent method)에 의해 조정된다.

$$w_i(\text{new}) = w_i(\text{old}) + \Delta w_i$$

$$\Delta w_i = \eta \cdot \left(-\frac{E'_p}{w'_p} \right) \quad (9)$$

여기서, η 는 학습률, E'_p 는 출력 오차의 편미분, w'_p 는 가중치의 편미분이다.

2.2 제안된 뉴로-퍼지 구조

본 논문에서 제안한 뉴로-퍼지 구조는 슈게노가 제안한 구조로 2입력 1출력, 각 입력에 대하여 소속함수 3개, 규칙이 9개인 구조이다. 이는 입력 x, y 에 대하여 총 9개의 퍼지 분할 공간을 의미한다. 또 추론 방법은 각 규칙에 대한 결론부 파라미터가 상수인 간략 추론 방법을 사용하였다. 이러한 구조는 입력 변수들의 상호 상관 관계를 고려하여 퍼지 공간을 분할하고 퍼지 규칙을 생성하는 적용 능력을 가진 구조로 그림 3과 같다.

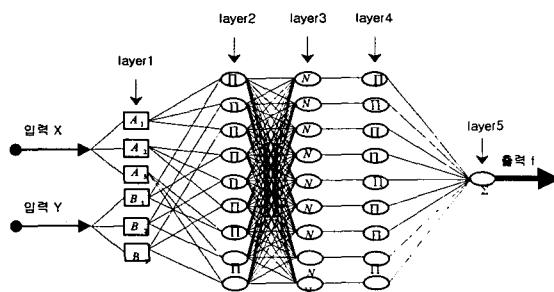


그림 3 제안된 뉴로-퍼지 구조

Fig. 3 Proposed structure of Neuro-Fuzzy

그림 3의 언어적 규칙은 다음과 같다.

- Rule 1 : if x is A_1 and y is B_1 , then $f_1 = r_1$
- Rule 2 : if x is A_1 and y is B_2 , then $f_2 = r_2$
- Rule 3 : if x is A_1 and y is B_3 , then $f_3 = r_3$
- Rule 4 : if x is A_2 and y is B_1 , then $f_4 = r_4$
- Rule 5 : if x is A_2 and y is B_2 , then $f_5 = r_5$
- Rule 6 : if x is A_2 and y is B_3 , then $f_6 = r_6$
- Rule 7 : if x is A_3 and y is B_1 , then $f_7 = r_7$
- Rule 8 : if x is A_3 and y is B_2 , then $f_8 = r_8$
- Rule 9 : if x is A_3 and y is B_3 , then $f_9 = r_9$

여기에서 x, y 는 입력, A_i, B_i 는 각 입력에 대한 소속 함수, f_i 는 각 규칙에서의 출력, r_i 는 학습되어질 후진부 파라미터이다.

3 입력 변수 선정

뉴로-퍼지를 변압기 보호계전 알고리즘에 적용하기 위해서는 변압기의 고장 상태를 판단할 수 있는 목표데이터 선정이 매우 중요하다. 이러한 목표 데이터는 퍼지 논리의 언어적인 규칙을 토대로 만들어지며, 이러한 언어적 규칙을 토

대로 만들어 질 목표 데이터의 입력 변수는 1차측 단자 전압의 RMS의 변화분 X 와 과도 상태시 반주기에 포함되어 있는 각 상 차전류의 기본파 성분의 합유율을 이용하여 만든 Y 이다.

3.1 입력 변수 X 의 선정

변압기 과도상태를 모의하여 얻은 1차측 각 상 전압을 이용하여 입력 변수 X 를 만들었으며 이는 식 (10)과 같이 반주기 데이터의 RMS값과 고장후 반주기 RMS의 변화분이다.

$$X = \frac{V_{(r.m.s)}}{V_{(R.M.S)}} \quad (10)$$

여기서, $V_{(r.m.s)}$ 는 고장후 각 상의 반주기 데이터의 RMS의 합, $V_{(R.M.S)}$ 는 고장전 각 상의 반주기 데이터의 RMS의 합이다.

3.2 입력 변수 Y 의 선정

변압기 과도 상태를 모의하여 얻은 변압기의 차전류 데이터로부터 변압기 상태에 따라 차전류가 각기 다르게 변화하는 것을 확인하였으며 이 차 전류를 DFT(Discrete Fourier Transform)분석하여 차전류에 포함되어 있는 기본파 성분을 분석하였다. 분석결과 각 상의 차전류에 포함되어 있는 기본파 합유율이 다른 것을 확인하였으며 이를 식 (11)과 같이 가공하여 또 다른 입력 변수 Y 를 선정하였다.

$$\begin{aligned} I &= \frac{(I_A + I_B + I_C)}{3} \\ I_b &= \left| \frac{I_B - I}{I} \right| \\ I_a &= \left| \frac{I_A - I}{I} \right| \\ I_c &= \left| \frac{I_C - I}{I} \right| \\ Y &= \frac{(I_a + I_b + I_c)}{3} \end{aligned} \quad (11)$$

여기서, I_A 는 고장후 반주기 안에 포함되어 있는 A상 기본파 성분의 합, I_B 는 고장후 반주기 안에 포함되어 있는 B상 기본파 성분의 합, I_C 는 고장후 반주기 안에 포함되어 있는 C상 기본파 성분의 합이다.

4 변압기 과도상태 모의 결과 및 분석

4.1 모델과 보호알고리즘

본 논문에서 변압기의 과도 상태를 모의하기 위해 선정된 모델은 154/22.9 [kV], 부하용량이 40 [MVA], Y-Y 결선이며 단상변압기 3대로 이루어진 3상 변압기로 1차측 송전선 거리가 50km이다. 변압기의 내부고장을 모의하기 위해 EMTP의 보조프로그램인 BCTRAN를 이용하였다. 또 변압기의 포화특성을 감안해 여자돌입 및 과여자를 모의하기 위해 EMTP의 HYSDAT를 사용하였으며 이는 자화곡선의 모

텔링이 가능한 Type-96소자를 이용하였다. 본 논문에서 학습될 뉴로-퍼지 알고리즘의 목표데이타는 고장후 반주기의 입력 변수 X와 Y를 퍼지 논리의 언어적 측면에서 고장일 때는 10, 정상일 때는 0의 값을 갖도록 언어적 규칙을 만들었으므로써 만들어진다. 이렇게 선정된 목표데이타는 뉴로-퍼지 알고리즘의 구배 감소 알고리즘을 통하여 출력 오차를 최소화하는 방향으로 학습되어지고 학습된 뉴로-퍼지 알고리즘은 변압기 상태에 따른 출력 값을 갖게 된다. 본 논문에서 제안한 알고리즘은 그림 4와 같이 미리 정해진 임계치와 비교하여 변압기가 고장인지 아닌지를 판별하는 알고리즘으로 임계치는 7을 기준으로 이상일 때는 고장으로 판단하고 이하 일 때는 고장이 아닌 것으로 판단하게 설정하였다.

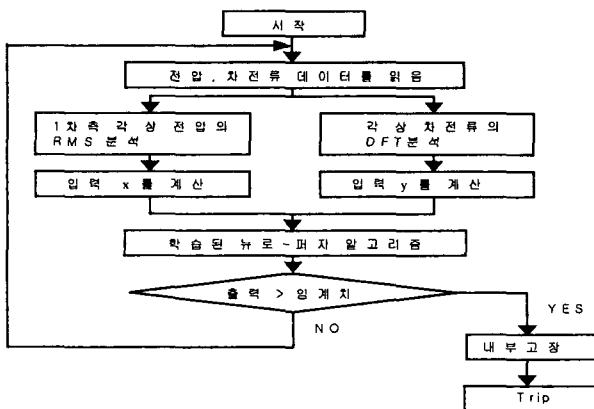


그림 4 알고리즘 흐름도

Fig. 4 Flow chart of algorithm

4.2 모의결과 분석

변압기 내부고장은 선형 모델링 기법인 BCTRAN 보조 프로그램에 의해 모의되었고, 모의된 내부고장은 충간단락(5%~80%) 22가지, 권선지락(5%~90%) 24가지로 전압 투입 위상각은 0°, 90°로 하였다. 여자 돌입 및 과여자 상태는 EMTP내에 자화곡선 모델이 가능한 Type-96소자를 이용하여 모의되었고 여자 돌입의 경우 모의시 전압 투입 위상각에 크게 의존한다는 사실에 입각하여 0°~90°로 변화시켜가며 총 18가지가 모의되었고 과여자의 경우 전압을 102%~135%로 변화시켜가며 총 17가지를 모의하였다. 또 선로 정전용량이 변수로 고려되었다. 그림 5는 변압기 1차측 A상

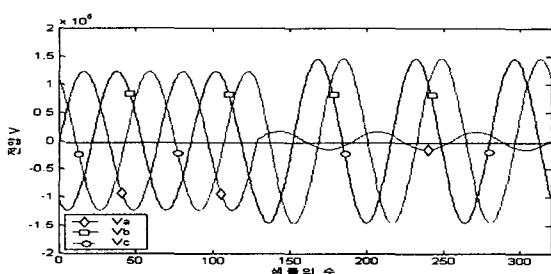


그림 5 a상 20% 충간단락 고장시 상전압 (0°)

Fig. 5 Phase voltage on a phase 20% turn to ground fault (0°)

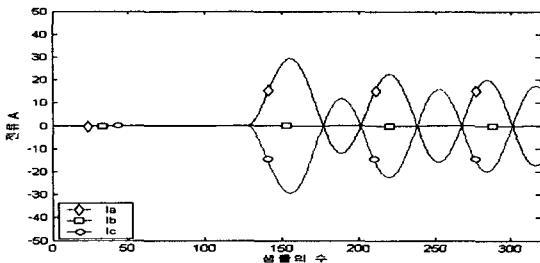


그림 6 a상 50% 충간단락 고장시 차전류 (0°)

Fig. 6 Differential current on A phase 50% turn to turn fault (0°)

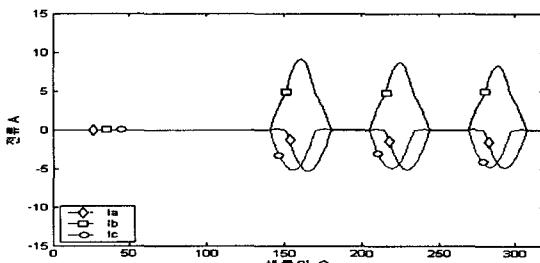


그림 7 여자돌입시 차전류(90°)

Fig. 7 Differential current on magnetizing inrush (90°)

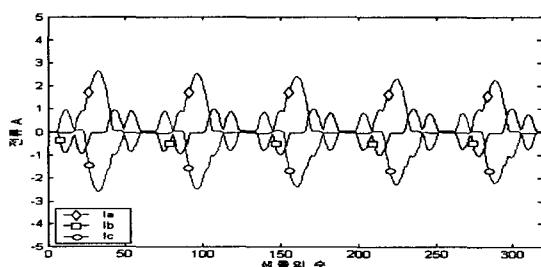


그림 8 과여자시 차전류(115%)

Fig. 8 Differential current on overexcitation(115%)

20%에 권선지락 고장시 1차측 각 상전압을 나타내며, 그림 6은 a상 20:50:30으로 분리되는 부분에서 권선단락이 일어나는 것으로 50% 권선 단락시 각 상에 대한 차전류를 나타낸 것이다. 그림 7은 전압 투입각이 90인 여자돌입의 경우이며 그림 8은 과여자 115%인 경우이다. 샘플링은 주기당 64 샘플을 하였다.

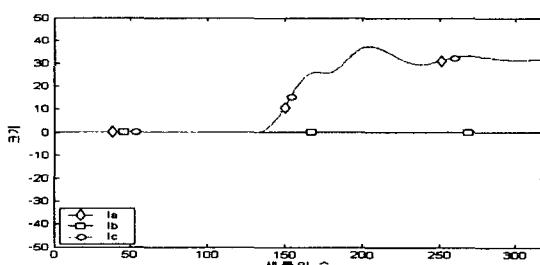


그림 9 권선지락 고장시 차전류의 기본파 분석

Fig. 9 Harmonic First Analysis on turn on ground fault

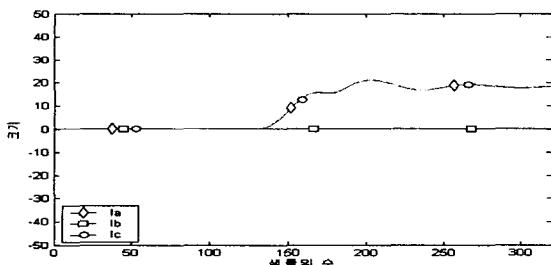


그림 10 권선단락 고장시 차전류의 기본파 분석
Fig. 10 Harmonic First Analysis on turn on turn fault

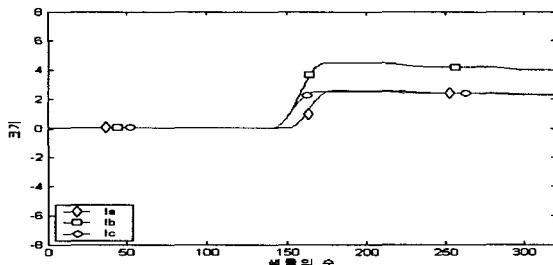


그림 11 여자돌입시 차전류의 기본파 분석
Fig. 11 Harmonic First Analysis on magnetizing inrush

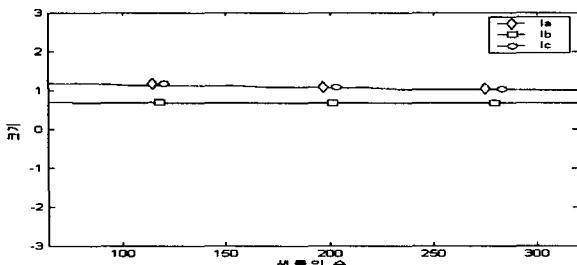


그림 12 과여자시 차전류의 기본파 분석
Fig. 12 Harmonic First Analysis on overexcitation

변압기의 여러 과도 상태를 모의한 결과 고장상황이 아닌 내부고장 이외의 여자돌입 또는 과여자시에 차전류가 발생함을 확인하였다. 이러한 차전류의 기본파 성분을 분석하기 위해 DFT를 사용하였으며 차전류 각 상에 기본파 성분은 그림 9~12와 같다.

5 뉴로-퍼지 시스템의 학습

변압기의 여러 과도 상태를 모의한 출력으로부터 뉴로-퍼지 알고리즘에 사용될 목표 데이터를 만들기 위해 입력변수 X, Y에 대한 소속함수를 언어적 변수로 정의하였다. 즉, 입력 변수 X에 대하여 변압기 고장 상태은 9.2 값을 중심으로 그 입력을 가지므로 9.2 값을 중심으로 갖는 소속함수, 여자돌입이나 과여자는 9.7이상 값을 가지는 소속함수, 정상일 때는 거의 10 값이므로 10 값을 중심으로 갖는 소속함수를 결정하였으며 이는 그림 13과 같다. 입력 변수 Y에 대해서는 변압기 정상상태시 1 값을 중심으로 갖는 소속함수, 여자돌입의 경우 넓게 나타나는 특징이 있어 소속함수를 3.5 값을 중심으로 1.5~5.5를 갖는 소속함수, 고장일 때 6.5이상을 가지므로 그 소속함수를 6.5이상을 중심으로 소속함수를 정의하였으며 그림 14와 같다.

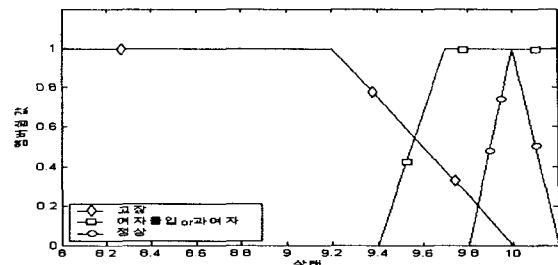


그림 13 입력 X의 멤버십 함수
Fig. 13 Membership funtion of input X

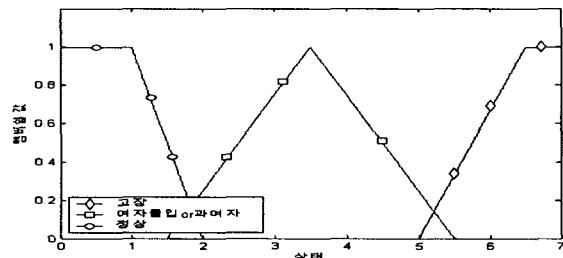


그림 14 입력 Y의 멤버십 함수
Fig. 14 Membership funtion of input Y

이러한 소속함수를 바탕으로 뉴로-퍼지 알고리즘의 목표데이터를 만들기 위해 언어적 규칙을 9개 사용하였으며 각 규칙에 대한 출력 값을 0~10 범위로 정의하였다. 즉 입력 X,Y가 고장상태에 상응하는 입력일 경우 10의 값, 여자돌입상태인 경우 3의 값, 정상 상태인 경우 0의 값을 갖도록 부여하였다. 이를 언어적인 규칙으로 표현하면 다음과 같다.

Rule 1 : X is 고장 and Y 고장 , then Z is 10

Rule 2 : X is 고장 and Y 여자돌입 or 과여자, then Z is 7

Rule 3 : X is 고장 and Y 정상, then Z is 5

Rule 4 : X is 여자돌입 or 과여자 and Y 고장, then Z is 7

Rule 5 : X is 여자돌입 or 과여자 and Y 여자돌입 or 과여자, then Z is 3

Rule 6 : X is 여자돌입 or 과여자 and Y 정상, then Z is 2

Rule 7 : X is 정상and Y 고장, then Z is 5

Rule 8 : X is 정상 and Y 여자돌입 or 과여자, then Z is 2

Rule 9 : X is 정상 and Y 정상, then Z is 0

이러한 규칙을 토대로 목표출력을 좌표축상으로 도시하면 그림 15와 같다.

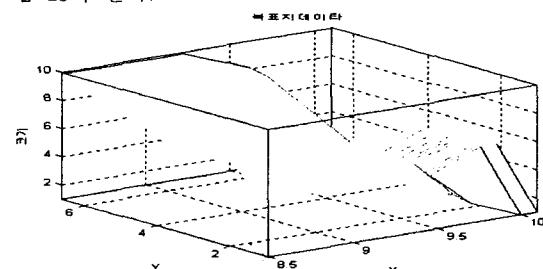


그림 15 목표데이터

Fig. 15 Traget data

이렇게 구한 목표출력을 출력으로 갖는 뉴로-퍼지 알고리즘을 구현하기 위해 변압기 과도 상태를 모의하여 얻은 출력 데이터로 입력 X, Y를 구한다. 그런 다음 이 값들은 훈련되지 않은 뉴로-퍼지 알고리즘의 입력으로 사용되고 그 출력들은 목표출력과 오차를 최소화하기 위해 오류역전 알고리즘에 의해 학습되어진다. 이렇게 학습되어진 뉴로-퍼지 알고리즘은 목표출력과의 오차를 최소화하는 방향으로 전반부 파라미터와 후반부 파라미터를 학습시킨다.

뉴로-퍼지 알고리즘은 기존의 전문가적 개념에서 결정되어지는 소속함수를 이루는 전반부 변수들을 출력에 맞게끔 최적의 변수들로 조정하는 기능을 가지고 있다. 이는 그림 16~그림 17에서 보이는 것처럼 초기 입력 X, Y에 대한 초기 소속함수가 10000번의 훈련을 통하여 그림 18~19와 같은 소속함수로 최적화되었다.

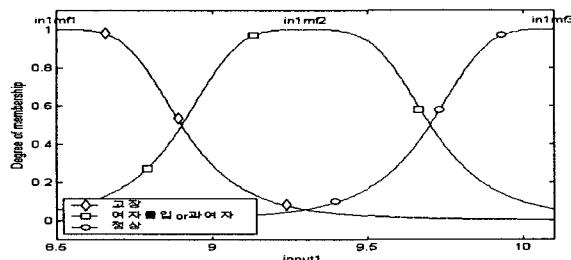


그림 16 초기 입력 X의 멤버십 함수

Fig. 16 Initial membership funtion of input X

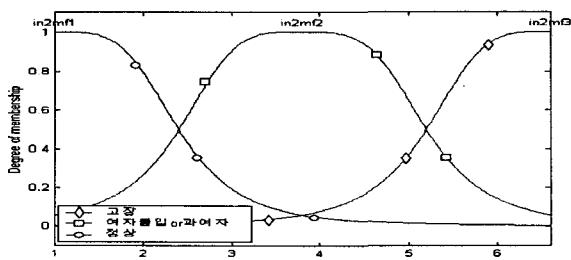


그림 17 초기 입력 Y의 멤버십 함수

Fig. 17 Initial membership funtion of input Y

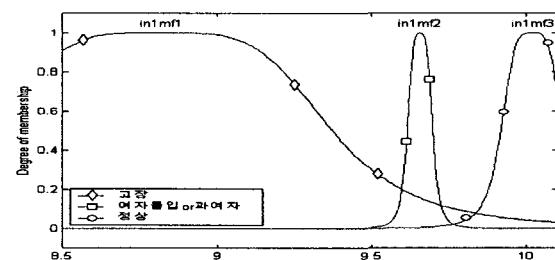


그림 18 최종 입력 X의 멤버십 함수

Fig. 18 Final membership funtion of input X

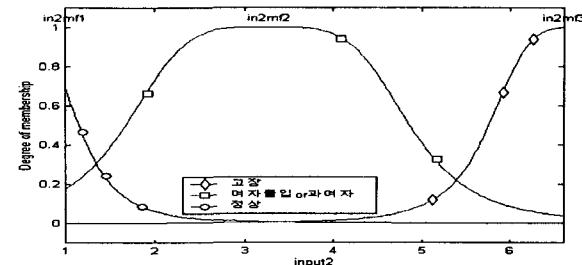


그림 19 최종 입력 Y의 멤버십 함수

Fig. 19 Final membership funtion of input Y

10000번의 학습을 통하여 목표출력에 대한 퍼지 시스템의 출력의 오차에 대한 에러률은 0.005이하로 수렴하였으며 이는 그림 20과 같고, 최종학습 되어 얻은 뉴로-퍼지 시스템의 출력은 목표치 출력과 거의 유사한 출력신호를 내도록 학습되였으며 이는 그림 21과 같다.

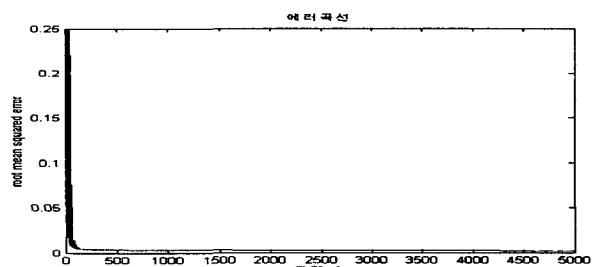


그림 20 에러곡선

Fig. 20 Error curve

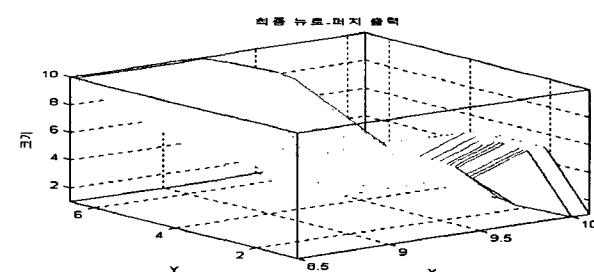


그림 21 뉴로-퍼지시스템의 최종 출력

Fig. 21 Final output of neuro-fuzzy

6. 사례 연구

학습된 뉴로-퍼지 알고리즘의 타당성을 확인하기 위해 변압기 과도상태를 입력으로 하여 그 출력을 확인하였다. 여기서 뉴로-퍼지 알고리즘의 출력은 미리 정해진 임계치 7 이상과 비교하여 고장 판단에만 이용되었으며 뉴로-퍼지 알고리즘의 출력은 언어적인 표현으로 고장일 때는 7이상이 되게 설정하였으며 고장이 아닐 경우에는 7이하의 값을 갖도록 설정하였다. 따라서 7이상 출력을 가지면 변압기 내부

고장으로 판단하여 트립 신호 1을 갖게 되어 계전기가 동작한다.

6.1 내부 고장

아래 그림 22는 a상 20% 권선 지락 고장 상태를 입력으로 하였을 때 뉴로-퍼지 알고리즘의 수행 결과를 나타낸 것이다. 여기서 고장 발생 시점은 0.03333초로 샘플링 수 128 번째이다. 그림 23에서 보는 바와 같이 고장 발생 시점인 128샘플 이후 뉴로-퍼지 알고리즘의 출력이 증가하여 148번째 샘플에서 임계치 7을 넘어 고장임을 판단하고 계전기가 트립함을 보여준다. 이는 고장 후 5.4ms인 시점이다.

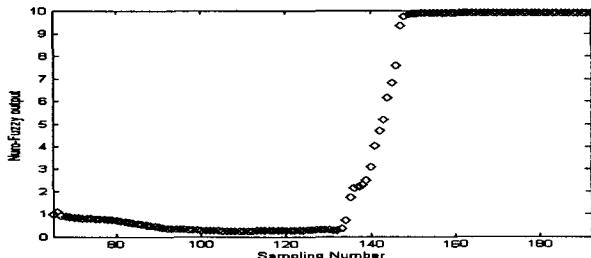


그림 22 a상 20% 권선 지락 고장시 뉴로-퍼지 알고리즘의 출력 값 (0°)

Fig. 22 Output value of trained Neuro-Fuzzy Algrorithm on a phase 20% turn to ground fault (0°)

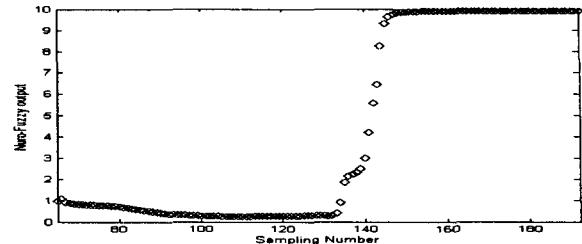


그림 24 a상 50% 층간 단락 고장시 뉴로-퍼지 알고리즘의 출력 값 (0°)

Fig. 24 Output value of trained Neuro-Fuzzy Algrorithm on a phase 50% turn to turn fault (0°)

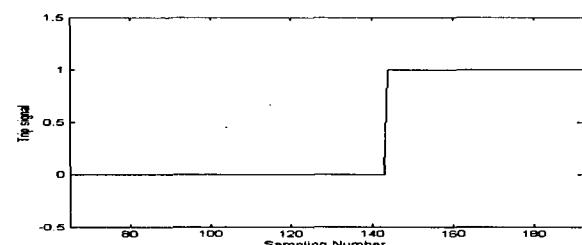


그림 25 a상 50% 권선 단락 고장시 트립신호(0°)

Fig. 25 Trip Signal on 50% turn to turn fault (0°)

6.2 여자돌입

여자 돌입의 경우 뉴로-퍼지 값이 언어적인 측면에서 3 정도의 값을 갖도록 훈련시켰으며 그림 26은 전압 투입 위상각이 90°인 여자 돌입 상태를 입력하였을 때 뉴로-퍼지 알고리즘의 수행결과이다. 그림 27은 여자 돌입 상태의 경우 내부고장파는 달리 뉴로-퍼지 알고리즘의 출력 값이 4정도를 중심으로 임계치 7을 넘지 않음으로써 고장이 일어나지 않은 것으로 판단하고 계전기가 동작되지 않았다.

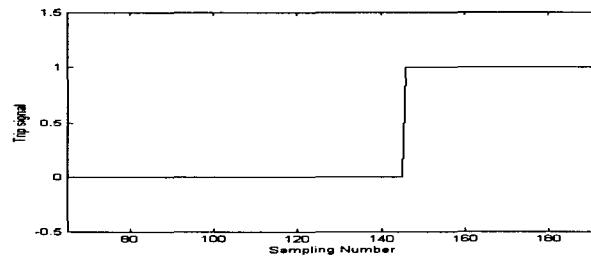


그림 23 a상 20% 권선 지락 고장시 트립신호(0°)

Fig. 23 Trip Signal on 20% turn to ground fault(0°)

아래 그림 24와 25는 a상 50% 권선 단락 고장 상태를 입력으로 하였을 때 뉴로-퍼지 알고리즘의 수행 결과와 계전기 수행을 나타낸 것이다. 이 그림 또한 고장 발생 128샘플 점 이후 값이 증가하여 146샘플점에서 임계치를 넘어 고장임을 판단하고 계전기가 트립하였다. 이는 고장 후 4.9ms인 시점이다.

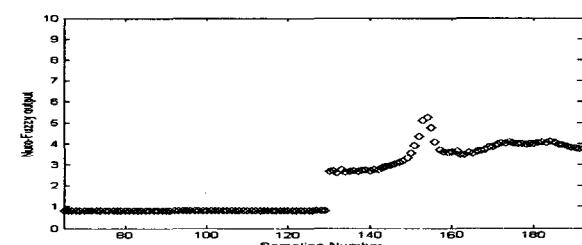


그림 26 여자돌입시 뉴로-퍼지 알고리즘의 출력 값 (90°)

Fig. 26 Output value of trained Neuro-Fuzzy Algrorithm on magnetizing inrush (90°)

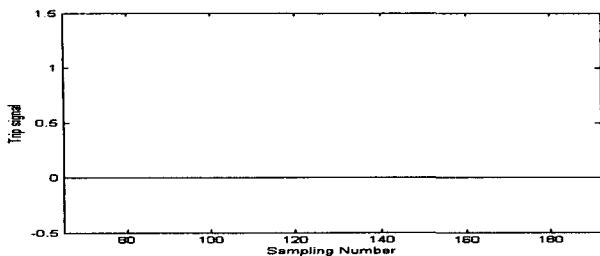


그림 27 여자 돌입 상태시 트립신호 (90°)

Fig. 27 Trip Signal on magnetizing inrush (90°)

그림 28와 29는 전압 투입 위상각이 0°인 여자 돌입 상태를 입력하였을 때 뉴로-퍼지 알고리즘의 수행 결과와 계전 신호를 나타낸 것이다. 이 그림 또한 임계치 7를 넘지 않음으로써 계전기가 동작되지 않았다.

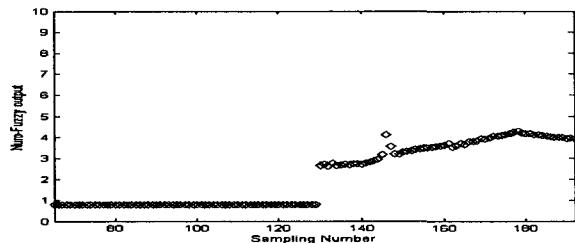


그림 28 여자돌입시 뉴로-퍼지 알고리즘의 출력 값(0°)

Fig. 28 Output value of trained Neuro-Fuzzy Algrorithm on magnetizing inrush (0°)

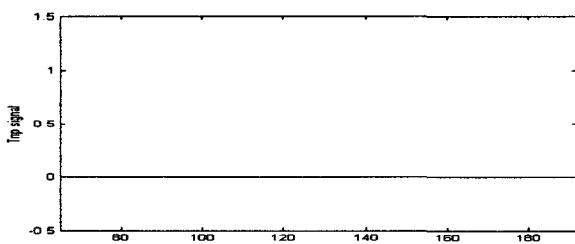


그림 29 여자 돌입 상태시 트립신호 (0°)

Fig. 29 Trip Signal on magnetizing inrush (0°)

6.3 과여자

그림 30은 115% 과여자 상태시 뉴로-퍼지 알고리즘의 출력과 계전기 동작을 나타낸 그림이다. 그림 29와 같이 과여자 상태시 뉴로-퍼지 알고리즘의 출력이 2를 중심으로 출력 값을 가짐으로써 임계치 7을 넘지 않아 계전기가 동작하지 않았다.

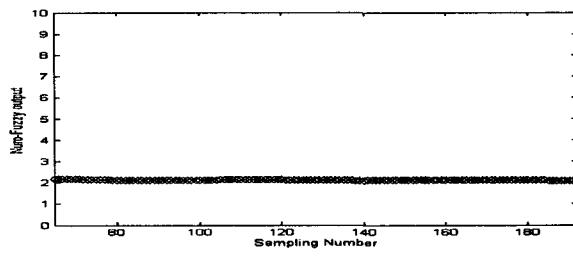


그림 30 과여자 상태시 뉴로-퍼지 알고리즘의 출력 값 (115%)

Fig. 30 Output value of trained Neuro-Fuzzy Algrorithm on overexcitation (115%)

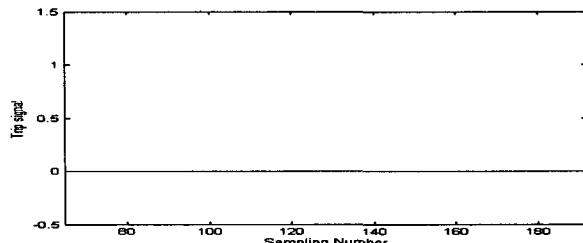


그림 31 과여자 상태시 트립신호 (115%)

Fig. 31 Trip Signal on overexcitation (115%)

사례 연구로부터 변압기 고장 상태 여부를 정확히 판별하였으며 고장 후 1/2주기 이내에 판별함으로써 아주 양호한 계전 특성을 지니고 있음을 확인하였다.

7. 결 론

본 논문에서는 CI(Computational Intelligence)중 퍼지이론과 신경회로망을 결합시킨 뉴로-퍼지를 전력용 변압기 보호 알고리즘을 적용하였다. 사례 연구를 통해 얻은 내용과 결과를 정리하면 다음과 같다.

- (1) 학습된 뉴로-퍼지 알고리즘을 통하여 변압기 고장상태는 정확히 판별되었다.
- (2) 고장후 1/2주기 내에 변압기 고장 상태를 판별함으로써 아주 양호한 계전 특성을 가지고 있음을 확인하였다.
- (3) 사례 연구 이외 훈련되지 않은 변압기 고장 데이터를 입력으로 하여 제안된 알고리즘에 적용하여 본 결과도 마찬가지 좋은 판별 결과를 냄을 확인하였다

감사의 글

이 논문은 2002년도 원광대학교의 교비지원에 의하여 연구됨

참 고 문 헌

- [1] Kuniaki Yabi, "Power differential method for discrimination between fault and magnetizing inrush current in transformers", IEEE Trans. On Power Delivery, Vol.12, NO. 3 July 1997.
- [2] 김상태외 2명, "전압, 전류 변화 추이를 이용한 전력용 변압기 보호계전 알고리즘", 대한전기학회 논문지 50A권 4호, pp157~165, 2001.
- [3] 홍동석외 1명, "웨이블렛 변환을 이용한 변압기 보호계 전 알고리즘", 대한전기학회 논문지 52권 2호, 2003.2.
- [4] 권기백외 3명, "웨이브렛 변환을 바탕으로 한 신경회로 망을 이용한 전력용 변압기 보호 계전기법", 대한 전기 학회 논문지 51권 3호, 2002.3.
- [5] Luis G. Perez, Alfred, J. Flechsig, Jack L. Meador, Zoran oberadovic, "Training an Artificial Neural Network to Discriminate between Magnetizing Inrush and Internal Faults", IEEE Trans. PWRP, Vol. 9, No. 1, pp. 434-441, Jan. 1994.
- [6] 서희석외 3명, "퍼지시스템에 의한 변압기 보호용 디지털 보호계전 알고리즘", 대한전기학회 논문지 46권 3호 1997.
- [7] J.-S. P. Jang. "ANFIS: Adaptive-Network-Based Fuzzy Inference System", IEEE Trans. on SYSTEM. Vo 1.23, No.3. May/June, 1994.
- [8] Lofi Zadeh, "Neuro-Fuzzy and Soft Computing".
- [9] 오성권, "프로그래밍에 의한 컴퓨터지능", 내하출판사, 2002.
- [10] 이현엽, 문경일, "MATLAB을 이용한 퍼지-뉴로", 도서 출판 아진.
- [11] Neural network Toolbox for use with MATLAB.
- [12] Fuzzy Logic Toolbox for use MATLAB.

저 자 소 개



이 명 윤 (李 銘 倫)

1978년 1월 8일생. 2003년 원광대 공과 대학 제어계측과 졸업. 2003년 ~ 현재 동 대학원 전기공학과 석사과정
Tel : (063)850-6735
E-mail : queen0476@hanmail.net



이 종 범 (李 鐘 範)

1955년 7월 12일생. 1981년 한양대 공대 전기공학과 졸업, 1983년 동 대학원 전기공학과 졸업(석사), 1986년 동 대학원 전기공학과 졸업(공박), 1987~1990년 한국 전기연구원 지중송전연구실 실장. 1997~1998년 미국 Texas A&M University 객원교수, 현재, 원광대 공대 전기전자 및 정보 공학부 교수
Tel : (063)850-6735
E-mail : ipower@wonkwang.ac.kr



서 재 호 (徐 在 鋒)

1948년 8월 6일생. 1973년 명지대 공대 전기공학과 졸업, 1977년 동 대학원 전기공학과 졸업(석사), 1989년 동 대학원 전기공학과 졸업(공박), 1977년 ~ 1979년 대전공업전문대학 조교수, 1980 ~ 현재 원광대 공대 전기전자 및 정보 공학부 교수
Tel : (063)850-6733
E-mail : jehoso@wonkwang.ac.kr