

웨이브렛 변환 기반 뉴로-퍼지를 이용한 변압기 보호계전 알고리즘

論 文
54A-5-6

Protective Relaying Algorithm for Transformer Using Neuro-Fuzzy based on Wavelet Transform

李 銘 倫[†] · 李 鍾 範^{*}
(Myoung-Rhun Lee · Jong-Beom Lee)

Abstract - This paper proposes a new protective relaying algorithm using Neuro-Fuzzy and wavelet transform. To organize advanced neuro-fuzzy algorithm, it is important to select target data reflecting various transformer transient states. These data are made of changing-rates of D1 coefficient and RSM value within half cycle after fault occurrence. Subsequently, advanced neuro-fuzzy algorithm is obtained by converging the target data. As a result of applying the advanced neuro-fuzzy algorithm, discrimination between internal fault and inrush is correctly distinguished within 1/2 after fault occurrence. Accordingly, it is evaluated that the proposed algorithm can effectively protect a transformer by correcting discrimination between winding fault and inrushing state.

Key Words : Current differential Relay, Internal fault, Inrush, Overexcitation, Wavelet Transform, Neuro-fuzzy algorithm

1. 서 론

전력용 변압기를 보호하기 위해 일반적으로 비율차동계전 방식이 사용된다. 이 방식은 제 2고조파 성분을 이용하여 여자돌입현상을 판단하고 이를 억제요소로, 제 5고조파 성분을 이용하여 과여자 상태를 판단하고 이를 억제요소로 이용하는 방식이다. 하지만 계통 변화에 따른 저해요소인 변압기 여자돌입 현상을 내부 고장 상태로, 내부고장상태를 여자돌입 상태로 잘못 판단하는 경우가 발생할 수 있다[1-7]. 이와 같은 문제점을 보완하고 보다 신뢰성 있는 보호계전 방식을 찾기 위한 수많은 기술적 노력으로, 변압기 보호 방식에 신경회로망[8-9], 퍼지이론[9] 그리고 새로운 신호처리 방법인 웨이브렛 변환[10]등이 제안되었다. 이중 웨이브렛 변환 방법은 기존 푸리에 변환의 신호처리가 갖는 시간정보의 손실의 결점을 보완한 것으로 비주기성 과도파형을 분석하는데 유연한 접근이 가능한 신호처리방법이다[11-12]. 신경회로망은 학습을 통해 비선형적인 입·출력관계를 가지고 있는 변압기 과도 상태를 선형화 할 수 있는 장점을 가지고 있다. 그리고 퍼지이론은 비선형적인 입·출력 관계를 언어적으로 표현이 가능하며 다중 입력을 하나의 입·출력의 관계식으로 구현 할 수 있는 강점을 가지고 있다[13-14].

따라서 본 논문에서는 보다 효과적인 변압기 보호를 위해 웨이브렛 변환을 기반으로 한 뉴로-퍼지 알고리즘을 적용하였다. 여기서 뉴로-퍼지 알고리즘은 신경회로망과 퍼지이론

의 장점을 결합시킨 구조로 효과적인 인공지능방법으로 평가되고 있다[15-16]. 먼저 EMTP를 이용하여 총 63여가지의 변압기 내부고장과 여자돌입을 모델링 하여 과도상태에 따른 1차측 전압과 차동전류를 얻는다. 그런 다음 1차측 전압에 대한 RMS변화분과 차동전류에 대한 D1의 상대적 변화분을 추출한다. 추출된 전압과 전류는 뉴로-퍼지 알고리즘의 입력 X와 Y로 사용되어진다. 사례연구 결과 과도입력에 따른 정확한 보호계전 동작이 이루어졌으며 1/2주기 내에 고장 유무를 판단함으로써 양호한 계전특성을 가짐을 확인하였다.

2. 웨이브렛 변환

2.1 웨이브렛 변환 이론




그림 1. 푸리에 변환과 STFT의 신호분석

Fig. 1. Signal analysis of fourier transform and STFT

그림 1(a)의 푸리에 분석은 신호를 다양한 주파수의 정현파로 분해하여 시간영역의 관점에서 주파수 영역으로 변환시키는 방법이다. 하지만 주파수 영역으로 변환 할 때 시간영역에 대한 정보가 손실된다는 단점을 가지고 있다. 그림 1(b)의 STFT(Short-Time Fourier Transform)방법은 신호가 발생하는 주파수 뿐만 아니라 시간에 대한 정보를 제공

[†] 교신저자, 學生會員 : 圓光大 電氣工學科 碩士課程
Email : queen0476@hanmail.net

^{*} 正 會 員 : 圓光大 電氣電子 및 電氣工學部 教授 · 工博
接受日字 : 2004年 12月 20日
最終完了 : 2005年 3月 12日

한다. 하지만 이 또한 일정한 크기 윈도우를 사용함으로써 시간에 따라 변화하는 과도신호분석에 적합하지 않다.

한편 그림 2와 같은 웨이블릿 변환은 웨이블릿 함수를 시간에 따른 크기 변형(Scaling)과 이동(Translation)을 통하여 분석영역이 가변되는 윈도우를 사용함으로써 푸리에 변환과 STFT의 단점을 극복하였다. 이와 같은 웨이블릿 변환은 비정적인 전력계통의 과도특성을 분석하는데 적절하며, 현재 선로 및 기기의 보호계전분야에서 응용되고 있다[10-11].




그림 2. 웨이블릿 변환의 시간-스케일의 관계
Fig. 2. Relation of time-scale of wavelet transform

2.2 연속 웨이블릿 변환 이론

연속 웨이블릿 변환(CWT-Continuous Wavelet Transform)은 신호의 정확한 분석을 위해 결정된 최대 스케일까지 모든 스케일에서 연속적으로 이동하면서 계산하는 방식이다. 연속웨이블릿 변환은 주어진 신호 F(t)에 식 (1)의 적용을 의미한다.

$$CWT(f, a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} F(t) \psi\left(\frac{t-b}{a}\right) dt \quad (1)$$

여기서, a와 b는 Scale과 Time shift에 대한 상수이다. 어떤 신호에 대한 정확한 웨이블릿 분석을 수행하려면 모든 스케일에서 웨이블릿 계수를 계산하는 것이 바람직하나, 연속 웨이블릿 변환을 이용해 여러 단계의 웨이블릿 분석을 수행하면 무한히 많은 웨이블릿 계수의 데이터가 산출되고 이로 인해 분석시간이 길어진다는 단점을 가지고 있다.

2.3 이산 웨이블릿 변환 이론

이산 웨이블릿 변환(DWT-Discrete Wavelet Transform)은 Scale 요소와 Shift 요소를 이산화시켜 더욱 효율적으로 신호를 분석할 수 있는 방식이다. 웨이블릿 함수(Ψ)와 원신호 S(t)에 대한 이산 웨이블릿 변환의 계산식은 식(2)와 같다.

$$DWT(s, m, n) = \frac{1}{\sqrt{a_0^m}} \sum_n S(t) \cdot \psi\left(\frac{t - na_0^m}{a_0^m}\right) \quad (2)$$

여기서, a₀^m은 Scale의 변수를 나타내고 na₀^m은 Shift 변수를 나타낸다. 이처럼 이산 웨이블릿 변환은 스케일과 Shift 요소를 이산화시켜 효율적으로 웨이블릿 분석을 수행할 수 있다.

실질적인 이산 웨이블릿 변환의 수행은 각 스케일 범위에서 Approximation(A)와 Detail(D)의 연속적인 쌍을 포함한다. 일반적으로 Approximation은 신호에 대한 저주파 성분으로 신호의 고유한 특성을 나타내고, Detail은 신호에 대한

고주파성분으로 신호의 미세한 특성을 나타낸다. 즉 웨이블릿 변환에서 Approximation은 고차 스케일을 통해 얻어지며 신호의 고주파 성분을 나타낸다. 그림 3에서는 웨이블릿 변환의 필터뱅크의 구성을 나타내었다. 원신호 S는 저역필터와 고역필터를 통해 분해되고 저역필터를 통과한 신호는 다시 고역필터와 저역필터를 통해 분해되며 이러한 과정은 원하는 신호를 얻을 때까지 반복하게 된다. 여기서 여러 단계의 고역필터와 저역필터를 통해 분석한 이산 웨이블릿 변환의 원신호는 식 (3)과 같이 나타낼 수 있다.




그림 3. 웨이블릿 필터 뱅크
Fig. 3. Wavelet filter bank

$$S = D1 + D2 + D3 + \dots + Dn + An \quad (3)$$

또한 이산 웨이블릿 변환은 Downsampling 기법을 사용하여 필터를 통해 얻어지는 데이터양을 줄여서 계산을 신속하게 할 수 있다는 장점을 가지고 있다. Downsampling 기법은 고역필터(Highpass Filter)와 저역 필터(Lowpass Filter)에 입력되는 데이터를 매 2번째 샘플점마다 통과시키는 원리이며, 웨이블릿 필터뱅크를 사용하는 이산 웨이블릿 변환의 특성은 이처럼 Downsampling를 통해 얻어지는 낮은 연산량이다. 그림 4는 Downsampling에 의한 분해과정을 나타내었다.




그림 4. Downsampling에 의한 분해 과정
Fig. 4. Analysis process of downsampling

본 논문에서 사용된 마더 웨이블릿은 Daubechies 중 하나인 db4이며 본 연구에 앞서 동일계통에서 변압기 과도상태에 따른 신호 분석시 db4가 가장 양호한 특성이 나타나는 것이 입증되었으므로 본 논문에서는 직접적인 증명은 생략한다[10].

3. 뉴로-퍼지 이론

3.1 뉴로-퍼지

뉴로-퍼지는 퍼지 이론과 신경회로망 이론을 결합한 이론이다. 이는 복잡성과 불확실성을 갖는 비선형 시스템을 표현하는데 있어 다른 지능형 이론 보다 우수하다. 이와 관련된 연구 중 Jang은 결론부를 입력에 대한 선형 방정식으로

표현한 ANFIS(Adaptive Network-Based Fuzzy Inference System)구조를 제안하였다[12-15]. 제안된 구조는 그림 5와 같다.




그림 5. ANFIS 구조
Fig. 5. The structure of ANFIS

여기서, x, y 는 입력, A_i, B_i 는 각 입력에 대한 소속함수, f_i 는 각 규칙에서의 출력, (p_i, q_i, r_i) 학습되어야 할 후건부 파라미터이다.

그림 5의 언어적 규칙은 식 (4)와 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 $f_2 = p_2x + q_2y + r_2$ (4)

그림 5에서 언급된 각 층의 동작에 대해서 살펴보면 아래와 같다.

Layer 1 : 입력 변수 x, y 가 소속함수에 소속되는 정도를 의미하며 입력 신호에 대한 멤버십 값을 식 (5)와 같이 계산한다.

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x) & i=1, 2 \\ O_{1,i} &= \mu_{B_{i-2}}(y) & i=3, 4 \end{aligned} \quad (5)$$

여기서, 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 (6)과 같다.

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} \quad (6)$$

여기서, a_i, b_i, c_i 는 전건부 파라미터로서 이들을 조정함으로써 소속함수의 모양을 변화시킬 수 있다.

Layer 2 : 식 (7)과 같이 각 규칙의 적합도를 계산한다.
 $O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_{i-2}}(y)$ (7)

Layer 3 : 각 규칙의 적합도가 구해지면 식 (8)과 같이 i 번째 적합도에 대한 모든 규칙의 적합도 합 의 비로 정규화된 값을 계산한다.

$$O_{3,i} = w'_i = \frac{w_i}{\sum w_i} \quad (8)$$

Layer 4 : 각 규칙에 대한 출력을 의미하며 식 (9)와 같

이 Layer 3에서 구해진 i 번째의 정규화된 값과 i 번째의 규칙에서의 출력값과의 곱을 수행한다.

$$O_{4,i} = w'_i (p_i x + q_i y + r_i) \quad (9)$$

여기서, p_i, q_i, r_i 는 학습되어야 할 후건부 파라미터 파라미터이고 이는 최소자승법에 의해 구해진다.

Layer 5 : Layer4에서의 출력 $O_{4,i}$ 를 모두 합한 최종 출력을 계산하며 이는 식 (10)과 같다.

$$f = \sum_i w'_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (10)$$

여기서, f_i 는 각 규칙의 출력이다.

추론 과정을 그림으로 보면 그림 2와 같다.




그림 6. 추론과정
Fig. 6. Inference process

뉴로-퍼지의 최종 출력은 식 (11)과 같이 후건부 파라미터의 조합으로 표현될 수 있으며 후건부 파라미터는 최소자승법에 의해 구해지게 된다.

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= w'_1 (p_1 x + q_1 y + r_1) + w'_2 (p_2 x + q_2 y + r_2) \\ &= w'_1 (p_1 + w'_2 p_2) x + (w'_1 q_1 + w'_2 q_2) y + (w'_1 r_1 + w'_2 r_2) \end{aligned} \quad (11)$$

뉴로-퍼지 알고리즘의 학습은 식 (12)와 같이 출력 오차 E_p 를 최소화하기 위해 오류 역전파 알고리즘이 사용되고 이는 연결 가중치 w_i 를 조정함으로써 이루어진다.

$$E_p = (y_p - y'_p)^2 \quad (12)$$

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


연결가중치 w_i 는 식 (13)과 같이 경사하강법(gradient decent method)에 의해 조정된다.

$$\begin{aligned} w_{i(new)} &= w_{i(old)} + \Delta w_i \\ \Delta w_i &= \eta \cdot \left(-\frac{E'_p}{w'_i} \right) \end{aligned} \quad (13)$$


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

4 변압기 과도상태 모의 결과 및 분석

본 논문에서 적용된 뉴로-퍼지 알고리즘의 성능을 검증하기 위해 선정된 모델은 154/22.9 [kV], 부하용량이 40 [MVA], Y-Y결선, 단상변압기 3대로 이루어진 3상 변압기로 1차측 송전선 거리가 50km이다. 변압기 고장은 EMTP를 이용하여 모델링 되었으며, 주기당 64샘플링으로 총 모의시간은 10주기이다. 모의된 변압기 내부고장은 층간단락(5%~80%), 권선지락(5%~80%)이며, 전압 투입위상각은 0°와 90°로 하였다. 그림 7은 A상 10%에 권선 지락 사고가 발생하였을 경우 1차측 전압과 차동전류의 파형이다.




(a) 전압 파형




(b) 차동전류 파형

그림 7. 10% 권선지락 사고시 전압 및 차동전류 파형(0°)

Fig. 7. Differential current and voltage wave during 10% turn to ground fault (0°)



(a) 전압 파형




(b) 차동전류 파형

그림 8. 60% 권선단락 사고시 전압 및 차동전류 파형 (90°)


Fig. 8. Differential current and voltage wave during 60% turn to turn fault (90°)

그림 8은 전압 투입 위상각이 90°이고 권선단락이 60%일 때의 1차측 전압과 차동전류의 파형이다.

여자 투입은 전압 위상각에 크게 의존한다는 사실에 입각하여 전압 투입 위상각을 0°에서 90°로 변화시켜가며 모의하였다. 그림 9는 전압 투입 위상각이 0°인 경우 1차측 전압과 차동전류 파형이다.



(a) 전압 파형




(b) 차동전류 파형


그림 9. 여자돌입시 전압 및 차동전류 파형 (0°)

Fig. 9. Differential current and voltage wave during Magnetizing inrush (0°)

변압기의 과여자는 1차측의 과전압에 의해 발생하며 그림 10은 130% 과전압일 때의 1차측 전압과 차동전류 파형이다.



(a) 전압 파형



(b) 차동전류 파형

그림 10. 과여자시 전압 및 차동전류 파형 (130%)

Fig. 10. Differential current and voltage wave during overexcitation (130%)

5. 뉴로-퍼지 알고리즘을 이용한 변압기 보호계전 알고리즘

5.1 변압기 보호계전 알고리즘 흐름도

본 논문에서 사용된 변압기 보호계전 알고리즘 흐름도는 그림 11과 같다.

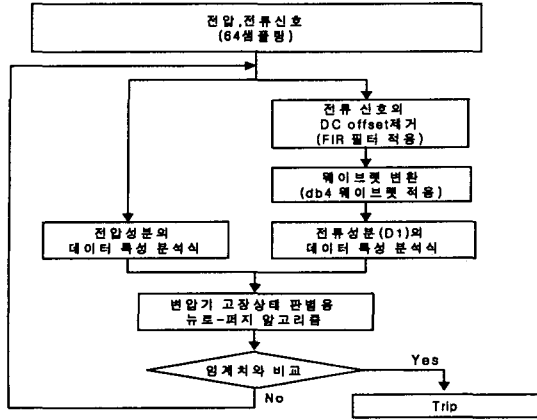


그림 11. 변압기 보호계전 알고리즘 흐름도
 Fig. 11. Flow chart of protective relaying Algorithm for transformer

뉴로-퍼지 알고리즘은 2입력 1출력 구조이며, 첫번째 입력은 1차측 전압에 대해 특성 분석식을 거친 RMS 변화분이다. 두번째 입력은 차동전류에 대해 특성 분석식을 거친 D1계수의 상대적 변화분이다. 여기서 사용된 학습된 뉴로-퍼지 알고리즘은 변압기 과도상태를 판단하는 기준이며 학습된 뉴로-퍼지 알고리즘을 구성하기 위해서는 변압기 과도상태의 특징에 부합되는 목표데이터 선정이 매우 중요하다. 이러한 목표 데이터는 변압기 과도 상태를 모의하여 얻어진 고장후 1/2주기 1차측 계전전압과 차전류를 토대로 얻어진다.

5.2 직류오프셋 제거

뉴로-퍼지 알고리즘의 입력으로 사용되는 전류신호는 직류 성분을 제거하는 FIR 필터를 거치게 되며 신호의 에리 요소로 작용하는 DC성분이 제거된다. 여기에서 사용된 DC offset 필터는 직류 성분을 상수로 가정한 것으로 일정 윈도우내의 입력과형은 식 14와 같이 표현될 수 있다. 한 샘플씩 옮겨감에 따라 오프셋의 크기 c는 변하게 된다. 이때 직류 성분은 식 15에 의해 제거된다.

$$x_k = \sum_{n=1}^{\infty} X_n \sin\left(\frac{2\pi nk}{N}\right) + c \quad (14)$$

여기서, c는 상수, N은 주기당 샘플링 수, n은 고조파 차수이다.

$$y_k = x_k - x_{k-m} \quad (15)$$

여기서, m은 필터 윈도우의 크기이다.

식 14의 과형을 식 15와 같은 필터에 통과시키면 그 출력은 식 16과 같다.

$$y_k = \sum_{n=1}^{\infty} X_n a_N \sin\left(\frac{2\pi nk}{N} + \Phi_n\right) \quad (16)$$


여기서,

$$a_N = \sqrt{E_N^2 + F_N^2} \quad \Phi_n = \tan^{-1}\left(\frac{F_N}{E_N}\right)$$


$$E_N = 1 - \cos\left(\frac{2n\pi}{N}\right) \quad F_N = \sin\left(\frac{2n\pi}{N}\right) \text{ 이다.}$$

5.3 웨이브렛 변환


DC성분이 제거된 전류신호는 특성분석식에 적용되기 위해 웨이브렛 변환을 거치게 된다. 여기서 사용된 웨이브렛 변환은 db4 변환이다. 그림 12~그림 15는 특성분석식에 사용될 차전류에 대한 D1계수이다.



(a) 10% 권선지락 사고시 A상의 D1 (0°)




(b) 10% 권선지락 사고시 B상의 D1 (0°)




(c) 10% 권선지락 사고시 C상의 D1 (0°)


그림 12. 10% 권선지락 사고시 3상의 D1 (0°)
 Fig. 12. Detail 1 of 3-phase during 10% turn to ground fault(voltage inception angle 0°)



(a) 60% 권선단락 사고시 A상의 D1 (90°)



(b) 60% 권선단락 사고시 B상의 D1 (90°)



(c) 60% 권선단락 사고시 C상의 D1 (90°)

그림 13. 60% 권선단락 사고시 3상의 D1 (90°)
 Fig. 13. Detail 1 of 3-phase during 60% turn to turn fault (voltage inception angle 90°)




그림 14. 여자 돌입시 3상의 D1 (0°)
 Fig. 14. Detail 1 of 3-phase during magnetizing inrush (voltage inception angle 0°)




그림 15. 과여자시 3상의 D1 (130%)
 Fig. 15. Detail 1 of 3-phase during overexcitation (130%)

5.4 입력 변수

뉴로-퍼지 알고리즘의 입력으로 사용된 값은 전압에 대한 RMS 변화분과 차전류를 웨이브렛 변환하여 얻은 D1계수의 상대적 변화분이다. 이는 전압에 대하여 식 17과 전류에 대하여 식 18을 거친 값이다.

$$V_{rms} = V_{rms}(a) + V_{rms}(b) + V_{rms}(c)$$

$$I_{rms} = I_{rms}(a) + I_{rms}(b) + I_{rms}(c)$$

$$X = \frac{V_{rms}}{V_{rms}} \tag{17}$$

$$I_a = \sum_1^{32} abs(d1(k)) \quad I_{aa} = abs\left(\frac{I_a - I_{average}}{I_{average}}\right)$$

$$I_b = \sum_1^{32} abs(d1(k)) \quad I_{bb} = abs\left(\frac{I_b - I_{average}}{I_{average}}\right)$$

$$I_c = \sum_1^{32} abs(d1(k)) \quad I_{cc} = abs\left(\frac{I_c - I_{average}}{I_{average}}\right)$$


$$I_{average} = \frac{(I_a + I_b + I_c)}{3} \quad Y = \frac{(I_{aa} + I_{bb} + I_{cc})}{3} \tag{18}$$

여기서, $V_{rms}(a)$ 는 1차측 A상 전압의 1/2주기 RMS값, $V_{rms}(b)$ 는 1차측 B상 전압의 1/2주기 RMS값, $V_{rms}(c)$ 는 1차측 C상 전압의 1/2주기 RMS값, $V_{rms}(a')$ 는 1샘플 이동 후 1차측 A상 전압의 1/2주기 RMS값, $V_{rms}(b')$ 는 1샘플 이동 후 1차측 B상 전압의 1/2주기 RMS값, $V_{rms}(c')$ 는 1샘플 이동 후 1차측 C상 전압의 1/2주기 RMS값, I_a 는 반주기 A상 웨이브렛 분석결과인 d1계수의 절대값의 합, I_b 는 반주기 B상 웨이브렛 분석결과인 d1계수의 절대값의 합, I_c 는 반주기 C상 웨이브렛 분석결과인 d1계수의 절대값의 합이다.

5.5 변압기 고장상태 판별용 뉴로-퍼지 알고리즘

5.5.1 목표값 설정

목표값을 선정하기 위해서는 변압기 과도상태의 특징을 반영하는 소속함수의 선정이 매우 중요하다. 입력 X에 상응하는 소속함수는 전압에 대한 특성 분석식인 식 17을 통하여 얻어지게 된다. 특성분석식을 거친 입력 X값은 고장인 경우 0.8~0.95, 여자돌입인 경우 0.93~0.99, 정상인 경우 0.98~0.12, 과여자 상태인 경우 1.3~0.4의 값을 갖는다. 입력 Y에 상응하는 소속함수는 전류에 대한 특성분석식인 식 18을 통하여 얻어진다. 특성 분석식을 거친 입력 Y는 정상인 경우 0~0.05, 과여자 상태인 경우 0.03~0.5, 여자돌입인 경우 0.1~0.3, 고장상태인 경우 0.45~0.6이상의 값을 갖는다. 이러한 특징을 반영하도록 소속함수를 구성하면 그림 16과 같다.



(a) X의 소속함수 (b) Y의 소속함수

그림 16. X, Y의 소속함수

Fig. 16. Membership function of X, Y

두 가지 소속함수를 이용하여 변압기 과도상태를 반영하

는 목표값 선정에 있어 퍼지 이론이 도입된다. 식 19는 목표데이터를 만들기 위해 입력 X, 입력 Y에 따른 언어적 룰 베이스이다.

- Rule 1 : IF X is 고장 and Y is 정상 , $f_1=5$
- Rule 2 : IF X is 고장 and Y is 과여자 , $f_2=7$
- Rule 3 : IF X is 고장 and Y is 여자돌입 , $f_3=7$
- Rule 4 : IF X is 고장 and Y is 고장 , $f_4=10$
- Rule 5 : IF X is 여자돌입 and Y is 정상 , $f_5=1$
- Rule 6 : IF X is 여자돌입 and Y is 과여자 , $f_6=2$
- Rule 7 : IF X is 여자돌입 and Y is 여자돌입 , $f_7=2$
- Rule 8 : IF X is 여자돌입 and Y is 고장 , $f_8=7$
- Rule 9 : IF X is 정상 and Y is 정상 , $f_9=0$
- Rule 10 : IF X is 정상 and Y is 과여자 , $f_{10}=1$
- Rule 11 : IF X is 정상 and Y is 여자돌입 , $f_{11}=1$
- Rule 12 : IF X is 정상 and Y is 고장 , $f_{12}=5$
- Rule 13 : IF X is 과여자 and Y is 정상 , $f_{13}=1$
- Rule 15 : IF X is 과여자 and Y is 여자돌입 , $f_{15}=2$
- Rule 14 : IF X is 과여자 and Y is 과여자 , $f_{14}=2$
- Rule 16 : IF X is 과여자 and Y is 고장 , $f_{16}=7$ (19)

그림 17은 룰 베이스를 바탕으로 만들어진 목표데이터를 좌표평면상에 도시한 것이다.




그림 17. 목표치 데이터
Fig. 17. Target data

5.5.2 뉴로-퍼지 알고리즘의 학습

뉴로-퍼지 알고리즘의 학습은 뉴로-퍼지 알고리즘이 갖는 값과 목표데이터 값과의 오차를 줄여나가는 방향으로 학습되어진다. 식 20은 뉴로-퍼지 알고리즘의 최종 출력 오차 식이다.

$$E = \frac{1}{N} \sum_{p=1}^N (y_p - \hat{y}_p)^2 \tag{20}$$

여기서, N은 입출력 데이터 쌍이다




그림 18. 에러 곡선
Fig. 18. error curve

10000번의 학습을 통하여 그림 18과 같이 에러를 0.03이하로 수렴하였다.

학습을 통해 얻어진 최종적인 뉴로-퍼지 알고리즘의 출력값은 그림 19와 같다.





그림 19. 최종 뉴로-퍼지 출력
Fig. 19. Final Neuro-fuzzy output

이러한 학습을 통하여 최적화된 전진부 파라미터와 후진부 파라미터값을 얻을 수 있다. 그런 다음 파라미터값들은 변압기 상태 판별용 뉴로-퍼지 알고리즘 값으로 세팅되어진다.


6. 사례 연구

학습된 뉴로-퍼지 알고리즘의 성능을 확인하기 위해 전압에 대한 RMS변화분과 전류에 대한 D1계수의 상대적 변화분을 입력으로 하여 그 출력을 확인하였다. 학습된 뉴로-퍼지 알고리즘의 출력은 고장일 경우 10에 가까운 값을 갖게 설정되어있다. 따라서 미리 정해진 임계치 7과 비교하여 그 이상일 경우 고장임을 판단하고 최종 계전기가 동작하게 된다.

6.1 내부 고장 상태



(a) 10% 권선지락 사고시 뉴로-퍼지 출력(0°)



(b) 10% 권선지락 사고시 트립 신호(0°)

그림 20. 10% 권선지락 사고시 뉴로-퍼지 알고리즘의 출력 및 트립 신호(0°)

Fig. 20. Output of neuro-fuzzy algorithm and trip signal during 10% turn to ground fault (voltage inception angle 0°)

학습된 뉴로-퍼지 알고리즘의 출력은 32샘플링의 정보를 받아서 순차적인 출력을 갖는다. 따라서 뉴로-퍼지 알고리즘의 1번째 출력은 실제 32샘플링이 지난 후부터의 출력이다

다. 모의계통에서 고장발생 시점은 2주기 지점인 128번째 샘플점이다. 그림 20은 a상 10% 권선지락 고장시 뉴로-퍼지 알고리즘의 출력이다. 출력값이 148번째 샘플점에서 임계치 7을 넘어 고장임을 판단하고 148번째 샘플점에서 계전기가 트립함을 보여준다. 이것은 고장 후 20샘플점으로 시간상 고장 후 5.2[ms]이다.

그림 21은 a상 60% 권선단락 고장 상태를 입력으로 하였을 때 뉴로-퍼지 알고리즘의 출력이다. 계전 알고리즘은 145번째 샘플점에서 임계치 7을 넘어 고장임을 판단하고 계전기가 동작된다. 이것은 고장 후 17샘플점, 즉 시간상으로




그림 21. 60% 권선 지락 사고시 뉴로-퍼지 알고리즘의 출력 및 트립 신호(90°)

Fig. 21. Output of neuro-fuzzy algorithm and trip signal during 60% turn to turn fault (voltage inception angle 90°)

6.2 여자돌입 상태

전압투입 위상각이 0°인 여자돌입 상태의 경우 그림 22와 같이 뉴로-퍼지 알고리즘의 출력은 최대 5보다 작다. 따라서 계전기가 동작되지 않는다.




그림 22. 여자 돌입시 뉴로-퍼지 알고리즘의 출력 및 트립 신호(0°)

Fig. 22. Output of neuro-fuzzy algorithm and trip signal during magnetizing inrush (voltage inception angle 0°)

고장 후 4.4[ms]이다.

6.3 과여자 상태

그림 23은 130% 과여자 상태에서 뉴로-퍼지 알고리즘의 출력과 계전기 동작이다. 과여자 상태의 경우 뉴로-퍼지 알고리즘의 출력이 1.5~5미만을 값으로 임계치 7을 넘지 않아 계전기가 동작되지 않는다.

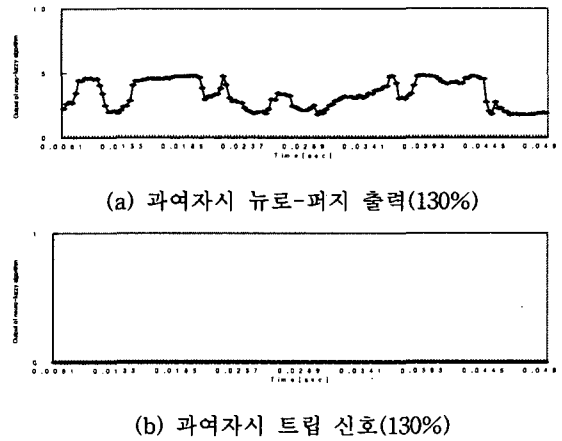


그림 23. 과여자시 뉴로-퍼지 알고리즘의 출력 및 트립 신호 (130%)

Fig. 23. Output of neuro-fuzzy algorithm and trip signal during overexcitation (130%)

7. 결 론

본 논문에서는 웨이브렛 변환과 ACI기법을 전력용 변압기 보호계전 알고리즘에 적용하였다. 이는 전력계통 보호에 계산 지능을 적용시킨 것으로서 연구를 통해 얻은 내용과 결과를 정리하면 아래와 같다.

- (1) 기존 변압기 보호계전 방법은 계통 변화에 따른 저해요인으로 인해 기존 수학적 알고리즘만으로 대처하기 곤란한 경우가 생긴다.
- (2) 따라서 저해요인으로 인한 대처방안으로 지능형 신기술이 필요하다.
- (3) 과도신호의 고주파 성분을 검출하기 위해 DC 필터를 적용하여 직류성분을 제거하고 웨이브렛 변환을 적용하였다.
- (4) 웨이브렛 변환을 적용하여 얻은 고주파 성분에 상응하는 성분인 D1계수를 통하여 특징을 분석하고 이를 토대로 뉴로-퍼지 알고리즘을 구현하였다.
- (5) 변압기의 내부고장과 여자돌입상태는 실제 뉴로-퍼지 알고리즘에 적용된 결과 정확히 판별되었다.
- (6) 고장후 반주기 데이터만을 이용하였으며 1/2주기 이내에 고장 여부를 정확히 판별되었다.
- (7) 학습에 사용된 데이터 이외의 훈련되지 않은 변압기 고장 데이터를 입력으로 하여 제안된 알고리즘을 테스트해 본 결과 동일하게 좋은 판별 결과를 확인하였다.
- (8) 모의된 변압기 모델 이외 다른 계통에서의 적용 및 신뢰성 여부의 연구가 필요할 것으로 사료된다.

감사의 글

본 연구는 2003년도 산업자원부 전력산업연구개발 사업 전력기술기초연구에 의하여 이루어진 연구로서, 관계부처에 감사 드립니다.

참 고 문 헌

- [1] "The-Multi-Differential Relaying for Transformer Protection" IEEE Transmission and Distribution Conference and Exhibition 2002, Volume: 3 , 6-10 Oct. 2002
- [2] kuniaki Yabi, "Power differential method for discrimination between fault and magnetizing inrush current in transformers", IEEE Transactions on Power Delivery, Vol. 12, NO.3, July 1997
- [3] 김상태 외 2명, "전압, 전류 변화 추이를 이용한 전력용 변압기 보호계전 알고리즘", 대한전기학회 논문지 50A 권 4호, pp157~165, 2001
- [4] "전력계통 보호계전 시스템 기술의 현황과 전망", 대한전기학회 기술조사보고, 1999
- [5] "지능형 보호계전기 연구개발", 전력연구원 최종보고서, 1998
- [6] LUIS G. PEREZ, "Training An Artificial Neural Network To Discriminate Between Magnetizing Inrush and Internal Faults", IEEE Transactions on Power Delivery, Vol. 9, No. 1, January 1994
- [7] M. Nagpal, "Using A Neural Network For Transformer Protection", IEEE Energy Management and Power Delivery, 1995. Proceedings of EMPD '95., 1995 International Conference on , Volume: 2, 21-23 Nov. 1995
- [8] B. Kasztenny, "Self-Organizing Fuzzy Logic Based Protective Relay An Application to Power transformer Protection", IEEE Transactions on Power Delivery, Vol. 12, NO. 3, July 1997
- [9] 이명윤 외2명 "뉴로-퍼지를 이용한 변압기 보호계전 알고리즘", 대한전기학회 논문지 52권 22호, 2003. 12.
- [10] 홍동석 외1명 "웨이브렛 변환을 이용한 변압기 보호계전 알고리즘", 대한전기학회 논문지 52권 2호, 2003. 2.
- [11] Wavelet Toolbox For Use with MATLAB, 2000
- [12] J.-S. P. Jang. "ANFIS: Adaptive-Network-Based Fuzzy Inference System", IEEE Trans. on SYSTEM. Vol. 23, No.3 May/June, 1994
- [13] Lofi Zadeh, "Neuro-Fuzzy and Soft Computing".
- [14] 오성권, "프로그래밍에 의한 컴퓨터지능" 내하출판사, 2002.
- [15] 이현엽 외 1명, "Matlab을 이용한 퍼지-뉴로" 아진출판사, 1999.

저 자 소 개



이 명 윤 (李 銘 倫)

1978년 1월 8일생. 2003년 원광대 공대 전기전자 공학부 졸업. 2004년~현재 동 대학원 전기공학과 석사과정
Tel : (063)850-6735
E-mail : queen0476@hanmail.net



이 종 범 (李 鍾 範)

1955년 7월 12일생. 1981년 한양대 공대 전기공학과 졸업, 1983년 동 대학원 전기공학과 졸업(석사), 1986년 동 대학원 전기공학과 졸업(공학박), 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