

웨이브렛 변환기반 뉴로-퍼지를 이용한 변압기 보호계전 알고리즘

이명윤* 이종범* 홍동석**
원광대 KEPRI

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

Myoung-Rhun Lee* Jong-Beom Lee* Dong-suk Hong**
Wonkwang University KEPRI

Abstract - A breakdown occurred in power transformer causes interruption of power transmission. Protective relay should be installed in transformer to detect such a fault. Protective relaying algorithm for transformer must be included a function to discriminate between winding fault and inrushing state. Recently, current differential relay is widely used to protect power transformer. However if inrush occurs in transformer, relay can be tripped by judging as internal fault. New algorithms are required in order to such problem. This study proposes a new protective relaying algorithm using Neuro-Fuzzy inference and wavelet. A variety of transformer transient states are simulated by BCTRAN and HYSDT in EMTP. D1 coefficients of differential current are obtained by wavelet transform. D1 coefficients and RMS of 3-phase primary voltage are used to make a target data and are trained by Neuro-Fuzzy algorithm which distinguishes correctly whether internal fault occurs or not within 1/2 after fault detection. It is evaluated that the results obtained by simulations can effectively protect a transformer by correct discriminating between winding fault and inrushing state.

1. 서 론

변압기 보호에 있어 중요한 판단 기준은 변압기 내부사고와 내부사고가 아닌 외란 즉, 여자돌입, 과여자의 명확한 구분이다. 이러한 수행을 위해 일반적으로 비유차동계전방식이 사용된다. 하지만 변압기 대규모화와 계통 커패시턴스 증가와 같은 보호계전 기능의 저해 요인으로 기존 수학적 알고리즘만으로 대처하기 곤란한 경우가 발생할 수 있다[1-2]. 이와 같은 문제점을 보완하고 보다 신뢰성 있는 보호계전 방식을 찾기 위한 수많은 기술적 노력으로, 변압기 보호 방식에 신경회로망[3-4], 퍼지이론[5] 그리고 새로운 신호처리 방법인 웨이브렛 변환[6-7]등이 제안되었다. 이중 웨이브렛 변환 방법은 기존 푸리에 변환의 신호처리가 갖는 시간정보의 손실의 결점을 보완한 것으로 비주기성 과도파형을 분석하는데 유연한 접근이 가능한 신호처리방법이다[7]. 신경회로망은 학습을 통해 비선형적인 입·출력관계를 가지고 있는 변압기 과도 상태를 선형화할 수 있는 장점을 가지고 있다. 그리고 퍼지이론은 비선형적인 입·출력 관계를 언어적으로 표현이 가능하며 다중 입력을 하나의 입·출력의 관계식으로 구현 할 수 있는 장점을 가지고 있다[8-9]. 따라서 본 연구에서는 보다 효과적인 변압기 보호를 위해 웨이브렛 변환을 기반으로 한 뉴로-퍼지 알고리즘을 적용하였다. 여기서 제안한 뉴로-퍼지 알고리즘은 신경회로망과 퍼지이론의 장점을 결합시킨 구조로 효과적인 인공지능방법으로 평가되고 있다[10]. 먼저 EMTP를 이용하여 총 63여가지의 변압기 내부고장과 여자돌입을 모델링 하여 과도상태에 따른 1차측 전압과 차동전류를 얻는다. 그런 다음 1차측 전압에 대한 RMS와 차동전류에 대하여 D1계수를 추출한다. 얻어진 RMS와 D1계수는 특성 분석식을 거친뒤 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. 한편 향후 변압기 보호계전 방식에 있어 기타 여러 가지 인공지능 방법이 도입되어 보다 더 정확하고 객관적인 지능형 이론이 도입되어야 할 것이다. 더불어 변압기 이외의 전력계통 보호분야에서의 지능형 이론의 도입과 활용이 기대된다.

2. 본 론

2.1 웨이브렛변환 이론

웨이브렛 변환 방법은 그림 1과 같이 급격히 변화는 고주파 성분을 분석하기 위해 짧은 시간 간격의 윈도우를 사용하고, 상대적으로 변화분이 적은 저주파 성분은 분석하기 위해 긴 시간 간격의 윈도우를 사용하는 방법으로 보다 정확한 과도신호를 분석할 수 있는 유용한 방법이다.



그림 1. 웨이브렛 분석
Fig. 1. Wavelet Analysis

일반적으로 사용되는 웨이브렛 변환 방법은 이산 웨이브렛 변환 방법으로 신호에 대하여 식(1)을 적용시킨다.

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

여기서, scale을 나타내는 변수는 a_0^m , shift를 나타내는 변수는 na_0^m , 그리고 $\frac{1}{\sqrt{a_0^n}}$ 은 마더 웨이브렛과 같은 크기의 에너지를 유지시키기 위한 에너지 정규화 성분이다.

웨이브렛 변환은 그림 2와 같이 고역필터와 저역 필터를 거치는 과정을 의미하며 원신호는 식 (2)와 같이 재구성될 수 있다.



그림 2. 웨이브렛 필터 뱅크의 구성
Fig. 2 Configuration of wavelet filter bank

$$S = D1 + D2 + D3 + \dots + Dn + An \quad (2)$$

여기서 D_n 은 Detail성분이고 A_n 은 Approximation성분이다.

2.2 뉴로-퍼지 이론

뉴로-퍼지 이론은 퍼지 이론과 신경회로망 이론을 결합시킨 것으로 양 이론의 단점을 보완한 이론이다. 이는 두 이론이 갖는 독특한 특성들을 살리면서 모델의 효율과 성능을 향상시키는 방향으로 융합된 형태이다. 따라서 복잡성과 불확실성을 나타내는 비선형 시스템에서 다른 지능형 모델에 비해 우수한 성능을 가지고 있다. 이와 관련된 연구 중 Jang은 결론부를 입력에 대한 선형 방정식으로 표현한 ANFIS(Adaptive network-based Fuzzy Inference System) 구조를 제안하였다[8-10]. 이는 1차 수계노시스템 파라미터들을 최적화시키기 위해 혼합된 학습 규칙을 사용하는 구조로 그림 3과 같다.




그림 3. 뉴로-퍼지 구조
Fig. 3 Neuro-Fuzzy structure

그림 3의 언어적 규칙은 아래와 같다.

- Rule 1: IF x is A_1 and y is B_1 , then $f_1 = p_1x + a_1y + r_1$
- Rule 2: IF x is A_2 and y is B_2 , then $f_2 = p_2x + a_2y + r_2$

여기서, x, y 는 입력, A_n, B_n 는 각 입력에 대한 소속함수, f_i 는 각 규칙에서의 출력, (p_i, a_i, r_i) 는 각 규칙에서 입력에 대한 선형 파라미터이다. 그림 3에서, Layer 1에서는 동정렬 전건부 파라미터를 가지고 있

며 Layer 4에서는 후진부 파라미터를 가지고 있다. 전진부 파라미터는 입력에 대한 각 소속함수의 멤버십 함수의 파라미터 값인데 이는 forward pass시 조정되며, 후진부 파라미터는 최소자승법을 사용하여 구해지며 backward pass시 조정된다. 한편 각 층의 동작은 다음과 같다.

Layer 1 : 입력 변수 x, y 가 소속함수에 소속되는 정도를 의미하여 입력 신호에 대한 멤버십 값을 식 (3)과 같이 계산한다. 소속함수로는 가우시안 함수를 사용하였다.

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

가우시안 함수는 식 (4)와 같다.

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b}} \quad (4)$$

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

Layer 2 : 식 (5)와 같이 각 뉴런은 입력되는 신호들을 곱하여 상호 결합된 퍼지 부분공간을 형성하며, 각 규칙의 적합도를 계산한다.

$$O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad i=1,2 \quad (5)$$

Layer 3 : 각 규칙의 적합도가 구해지면 식 (6)과 같이 모든 규칙의 합에 대한 i 번째 노드의 적합도의 비율 계산하는 것으로 이는 정규화 단계이다.

$$O_{2,i} = w'_i = \frac{w_i}{\sum w_i} \quad (6)$$

Layer 4 : 각 규칙에 대한 출력을 의미하며 Layer 3에서 구해진 적합도는 연결가중치와 곱해서 식 (7)과 같이 출력층의 입력이 된다.

$$O_{4,i} = w'_i (\rho_i x + q_i y + r_i) \quad (7)$$

여기서 ρ_i, q_i, r_i 는 학습되어야 할 파라미터이며 이를 후진부 파라미터라고 한다. 후진부 파라미터는 최소자승법에 의해 구해진다.

Layer 5 : Layer 4에서의 출력 $O_{4,i}$ 가 모두 합해져 최종적인 출력은 식 (8)에 의해 계산한다.

$$f = \sum w_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad (8)$$

추론 과정을 보면 그림 4와 같다.




그림4. 추론과정
Fig. 4 Inference process

뉴로-퍼지의 최종 출력은 식 (9)와 같이 후진부 파라미터의 조합으로 표현될 수 있다.

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= w'_1 (\rho_1 x + q_1 y + r_1) + w'_2 (\rho_2 x + q_2 y + r_2) \\ &= (w'_1 \rho_1 + w'_2 \rho_2) x + (w'_1 q_1 + w'_2 q_2) y + (w'_1 r_1 + w'_2 r_2) \end{aligned} \quad (9)$$

뉴로-퍼지시스템의 학습은 연결 가중치 w_i 를 최적으로 조정해 나감으로써 이루어진다. 학습 방법은 오류 역전파 알고리즘이 사용되며 연결 가중치를 학습하기 위해 출력 오차식은 식 (10)과 같다

$$E_p = (y_p - y'_p)^2 \quad (10)$$

여기서, E_p 는 각 데이터에 대한 오차, y_p 는 주어진 출력 데이터, y'_p 는 모델의 출력이다.

연결가중치의 조절은 오차 E_p 를 최소화하기 위한 연결 가중치 변화량 Δw_i 를 경사하강법(gradient decent method)를 이용하여 구하며 식 (11)과 같다.

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

$$\Delta w_i = \eta \cdot \left(-\frac{E_p}{w'_i} \right) \quad (11)$$

여기서, η 는 학습률, E_p 는 오차의 편미분, w'_i 는 가중치의 편미분이다.

최종 출력은 학습을 통하여 연결가중치 w_i 를 조절하고 원 출력과의 오차를 만족 하였을 때 얻어진다.

2.3 입력 변수 선정

뉴로-퍼지를 이용하여 변압기 보호알고리즘을 구성하기 위해서는 변압기의 과도 상태를 판단할 수 있는 입력변수의 선정이 매우 중요하다. 본 논문에서는 입력 변수로 1차측 단자 전압의 RMS의 변화분과 과도 상태시 반주기에 포함되어 있는 차동 전류에 대하여 웨이브렛 변환하여 얻은 D1계수의 상대적 변화분을 입력 변수로 선정하였다.

2.3.1 입력 X

모의하여 얻은 1차측 단자전압에 대하여 식 (12)를 적용하여 이를 입력 변수 X로 정하였다.

$$X = \frac{V_{(r,ms)}}{V_{(RMS)}} \quad (12)$$

여기서, $V_{(r,ms)}$ 는 고장후 각 상의 반주기 데이터의 RMS의 합, $V_{(RMS)}$ 는 고장전 각 상의 반주기 데이터의 RMS의 합이다.

2.3.2 입력 Y

차동 전류를 웨이브렛 변환하여 D1계수를 얻은뒤 식 (13)과 적용하여 이를 또 다른 입력 변수 Y로 정하였다.

$$\begin{aligned} I_a &= \sum_{k=1}^d abs((d1(k))) & I_{oa} &= abs\left(\frac{I_a - I_{average}}{I_{average}}\right) \\ I_b &= \sum_{k=1}^d abs((d1(k))) & I_{ob} &= abs\left(\frac{I_b - I_{average}}{I_{average}}\right) \\ I_c &= \sum_{k=1}^d abs((d1(k))) & I_{oc} &= abs\left(\frac{I_c - I_{average}}{I_{average}}\right) \\ I_{average} &= \frac{(I_a + I_b + I_c)}{3} & Y &= \frac{(I_{oa} + I_{ob} + I_{oc})}{3} \end{aligned} \quad (13)$$

여기서, I_a : 반주기 A상 웨이브렛 분석결과인 d1계수의 절대값의 합, I_b : 반주기 B상 웨이브렛 분석결과인 d1계수의 절대값의 합, I_c : 반주기 C상 웨이브렛 분석결과인 d1계수의 절대값의 합이다.

2.4 변압기 모델과 보호 알고리즘

본 논문에서 변압기의 과도상태를 모의하기 위해 선정된 모델은 154/22.9kV, 부하용량이 40MVA, Y-Y결선이며 단상변압기 3대로 이루어진 3상 변압기로 1차측 송전선거리가 50km이다. 변압기의 내부고장을 모의하기 위해 EMTP상의 보조프로그램인 BCTRAN를 이용하였다. 또 변압기의 포화특성을 감안해 여자돌입 및 과여자를 모의하기 위해 EMTP상의 HYSDAT를 사용하였으며 이는 자화곡선의 모델링이 가능한 Type-96소자를 이용하였다. 모의시간은 총 10주기로 1주기당 64샘플링을 하였다. 고장 발생 시점은 2주기지점인 0.03333초이다. 본 논문에서 제안된 변압기 보호계전 알고리즘은 그림 5와 같이 2입력 1출력 구조로 고장일 때는 10, 정상일 때는 0에 가까운 값을 갖는다. 여기서 임계치는 8이상으로 정하였다.




그림5. 알고리즘 흐름도
Fig. 5 Flow chart

2.5 뉴로-퍼지 알고리즘의 훈련

학습된 뉴로-퍼지 알고리즘을 구현하기 위해서는 변압기 과도 상태를 반영할 수 있는 목표 데이터 설정이 무엇보다 중요하다. 목표 데이터는 입력 X와 입력 Y를 토대로 얻어진다. 분석 결과 입력 X값은 과여자 상태인 경우 1.03~1.4, 여자돌입인 경우 0.93~0.98, 내부고장인 경우 0.8~0.96의 값을 갖는다. 그리고 입력 Y값은 과여자 상태인 경우 0~0.5, 여자돌입인 경우 0.08~0.3, 내부고장인 경우 0.49~1의 값을 갖는다. 입력 X와 Y에 따른 소속함수는 그림 6과 같이 표현될 수 있다.




그림 6. X, Y의 소속함수
Fig. 6. Membership function of X & Y

소속함수를 바탕으로 만들어진 목표데이터를 좌표평면상에 도시하면 그림 7과 같다.



그림 7. 목표값
Fig. 7. Target data

변압기 고장상태를 판별하기 위해 만든 목표데이터는 변압기 과도 입력에 따른 출력을 나타내주는 기준이다. 목표데이터는 뉴로-퍼지 알고리즘의 출력과의 오차를 줄여나가는 방향으로 학습되어진다. 오차 조건을 만족하면 학습을 멈추게 되며 최종적으로 변압기 과도 상태를 반영할 수 있는 하나의 선형과 식이 가능하게 되어진다. 1000번의 반복 학습을 통해 그림 8과 같이 에러율은 0.03이하로 수렴하였으며 최종적인 뉴로-퍼지 알고리즘의 출력값은 그림 9와 같다.




그림 8. 에러 곡선
Fig. 8. Error curve

최종적인 뉴로-퍼지 알고리즘의 출력값은 그림 9와 같다.




그림 9. 최종 뉴로-퍼지 출력
Fig. 9. Final output of Neruo-Fuzzy

2.6 사례연구

학습된 뉴로 퍼지 알고리즘을 성능을 확인하기 위해 변압기 과도상태에 따른 전압, 전류의 D1계수를 입력으로 하여 그 출력을 확인하였다. 학습된 뉴로 퍼지 알고리즘의 출력은 고장일 경우 10에 가까운 값을 갖는다. 따라서 뉴로 퍼지 알고리즘의 출력이 미리 정해진 임계치 8과 비교하여 고장 여부를 판단한다. 그 이후 최종 계전기가 동작하게 된다.

2.6.1 내부고장

학습된 뉴로 퍼지 알고리즘의 출력은 32샘플링의 정보를 받아서 순차적인 출력을 갖는다. 따라서 뉴로 퍼지 알고리즘의 1번째 출력은 실제 32샘플링이 지난 후부터의 출력이다. 모의계통에서 고장 발생 시점은 2주기 지점인 128번째 샘플점이다. 그림 10은 a상 5% 권선지락 고장시 1차측 전압의 RMS변화분과 차전류 D1계수의 변화분을 입력으로 하였을 경우 학습된 뉴로 퍼지 알고리즘의 출력이다. 출력값이 152번째 샘플에서 임계치 8을 넘어 고장임을 판단하고 152번째 샘플점에서 계전기가 트립함을 보여준다.



그림 10. 5% 권선지락시 계전 알고리즘의 출력값 & 트립 신호(0°)
Fig. 10. Trip signal & Output value of trained Neuro-Fuzzy Algorithm on a phase 5% turn to ground fault(0°)

그림 11은 a상 60% 권선단락 고장 상태를 입력으로 하여 학습된 뉴로-퍼지 알고리즘의 출력이다. 150번째 샘플점에서 임계치 8을 넘어 고장임을 판단하고 계전기가 트립하였다.



그림 11. 60% 권선지락시 계전 알고리즘의 출력값 & 트립 신호(90°)
Fig. 11. Trip signal & Output value of trained Neuro-Fuzzy Algorithm on a phase 60% turn to turn fault(90°)

2.6.2 여자돌입

전압 투입 위상각이 0°인 여자돌입 상태의 경우 그림 12와 같이 학습된 뉴로-퍼지 알고리즘의 출력은 최대 7이다. 따라서 계전기는 동작하지 않았다.



그림 12. 여자돌입시 계전 알고리즘의 출력값 & 트립 신호(0°)
Fig. 12. Trip value of trained Neuro-Fuzzy Algorithm on magnetizing inrush(0°)

2.6.3 과여자 상태

그림 13은 140% 과여자 상태시 학습된 뉴로 퍼지 알고리즘의 출력과 계전기 동작이다. 과여자 상태의 경우 여자돌입 상태와 마찬가지로 임계치 8을 넘지 않았으며 계전기가 동작하지 않았다.



그림 13. 과여자시 계전 알고리즘의 출력값 & 트립 신호 (140%)
Fig. 13. Trip signal & Output value of trained Neuro-Fuzzy Algorithm overexcitation(140%)

3. 결론

본 논문에서는 웨이브렛 변환과 뉴로-퍼지 이론을 전력용 변압기 보호 알고리즘을 적용하였다. 이는 전력계통 보호에 계산 지능을 적용시킨 것으로서 연구를 통해 얻은 내용과 결과를 정리하면 다음과 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) 1차측 전압의 RMS변화분과 웨이브렛 변환을 적용하여 얻은 D1계수의 변화분의 특징을 토대로 뉴로 퍼지 알고리즘을 구현하였다.
- (4) 변압기의 내부고장과 여자돌입상태는 실제 뉴로 퍼지 알고리즘에 적용된 결과 정확히 판별되었다.
- (5) 고장후 반주기 데이터만을 이용하였으며 1/2주기 이내에 고장 여부를 정확히 판별되었다.
- (6) 학습에 사용된 데이터 이외의 혼련되지 않은 변압기 고장 데이터를 입력으로 하여 제안된 알고리즘을 테스트해 본 결과 동일하게 좋은 판별 결과를 확인하였다.
- (7) 모의된 변압기 모델의 다른 계통에서의 적용 및 신뢰성 여부의 연구가 필요할 것으로 사료된다.

감사의 글

본 연구는 2003년도 산업자원부 전력산업연구개발사업 전력기술기초연구에 의하여 이루어진 연구로서, 관계 부처에 감사 드립니다.

[참고 문헌]

- [1] "전력계통 보호계전 시스템 기술의 현황과 전망", 대한전기학회 기술조사보고, 1999
- [2] "지능형 보호계전기 연구개발", 전력연구원 최종보고서, 1998
- [3] 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
- [4] 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
- [5] B. Kasztemny, "Self-Organizing Fuzzy Logic Based Protective Relay An Application to Power transformer Protection", IEEE Transactions on Power Delivery, Vol. 12, NO. 3, July 1997
- [6] 홍동석 외1명 "웨이브렛 변환을 이용한 변압기 보호계전 알고리즘", 대한전기학회 논문지 52권 2호, 2003, 2.
- [7] Wavelet Toolbox For Use with MATLAB, 2000
- [8] J.-S. P. Jang, "ANFIS: Adaptive-Network-Based Fuzzy Inference System", IEEE Trans. on SYSTEM, Vol. 23, No.3 May/June, 1994
- [9] Lotfi Zadeh, "Neuro-Fuzzy and Soft Computing",
- [10] 오성권, "프로그래밍에 의한 컴퓨터지능" 내하출판사, 2002.