

웨이브렛 변환기반 ACI 기법을 이용한 변압기 보호계전 알고리즘

이명윤·이종범
원광대*

Protective Relaying Algorithm for Transformer Using ACI based on Wavelet Transform

Myoung-Rhun Lee·Jong-Beom Lee
Wonkwang University*

Abstract - This paper proposes a new protective relaying algorithm using ACI(Advanced Computational Intelligence) and wavelet transform. To organize the advanced neuro-fuzzy algorithm, it is important to select target data reflecting various transformer transient states. These data are made of changing-rates of DI coefficient and RSM value within half cycle after fault occurrence. Subsequently, the 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 half cycle 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.

1. 서 론

변압기 보호에 있어 중요한 판단 기준은 변압기 내부사고와 내부사고가 아닌 외란 즉, 여자돌입, 과여자의 명확한 구분이 다. 하지만 계통 변화에 따른 저해요인으로 내부고장 상태와 여자 돌입 상태를 정확히 판단할 수 없는 경우가 발생할 수 있다. 이러한 문제점을 보완하고 보다 신뢰성 있는 보호계전 방식을 찾기 위한 수많은 기술적 노력으로, 변압기 보호 방식에 신경회로망, 퍼지이론 그리고 새로운 신호처리 방법인 웨이브렛 변환 등이 제시되고 있다[1-8].

이에 본 논문에서는 비주기성 과도파형을 분석하는데 유연한 접근이 가능한 신호처리방법인 웨이브렛 변환과 비선형적인 입·출력 관계를 가진 변압기 과도상태를 선형화 시킬 수 있는 ACI(Advanced Computational Intelligence)기법을 적용하였다. 여기서 ACI기법은 단일 기준이 아닌 다 입력에 기준에 입각하여 변압기 상태를 판단한다. 따라서 계통 변화에 대하여 보다 유연하게 대처 할수 있다. 실제 사례 연구를 통하여 변압기 고장상태 유무를 고장 후 1/2 주기 이내에 정확히 판별함을 확인함으로써 알고리즘 성능을 검증하였다.

2. 본 론

2.1 웨이브렛 변환 이론

웨이브렛 변환 방법은 그림 1과 같이 급격히 변화는 고주파 성분을 분석하기 위해 짧은 시간 간격의 윈도우를 사용하고, 상대적으로 변화분이 적은 저주파 성분을 분석하기 위해 긴 시간 간격의 윈도우를 사용하는 방법으로 보다 정확한 과도신호를 분석할 수 있는 유용한 방법이다[9-10].




그림 1. 웨이브렛 분석
Fig. 1. Wavelet Analysis

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

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

여기서, scale을 나타내는 변수는 a_0^n , shift를 나타내는 변수는 na_0^n , 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

$$S = D_1 + D_2 + D_3 + \dots + D_n + A_n \quad (2)$$

여기서, D_n 은 Detail성분이고 A_n 은 Approximation성분이다.

2.2 뉴로-퍼지 이론

ACI(Advanced Computational Intelligence)기법 중 본 논문에서 사용된 기법은 뉴로-퍼지 이론이다. 이 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 Inferency System) 구조를 제안하였다[11-14]. 이는 1차 슈게노시스템 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 $f_1 = p_1x + q_1y + r_1$

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

여기서, x, y 는 입력, A_n, B_n 는 각 입력에 대한 소속함수, f_i 는 각 규칙에서의 출력, (p_i, q_i, r_i) 는 각 규칙에서 입력에 대한 선형 파라미터이다.

그림 3에서, Layer 1에서는 동정될 전진부 파라미터를 가지고 있으며 Layer 4에서는 후건부 파라미터를 가지고 있다. 전진부 파라미터는 입력에 대한 각 소속함수의 멤버십 함수의 파라미터 값인데 이는 forward pass시 조정되며, 후건부 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.

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

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 함에 대한 i 번째 노드의 적합도의 비를 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.

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

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

Layer 5 : Layer 4에서의 출력 $O_{4,i}$ 가 모두 합쳐져 최종적인 출력을 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 후건부 파라미터의 조합으로 표현될 수 있다.

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= w'_1 (p_1 x + q_1 y + r_1) + w'_2 (p_2 x + q_2 y + r_2) \\ &= (w'_1 p_1 + w'_2 p_2) x + (w'_1 q_2 + w'_2 q_2) y + (w'_1 r_1 + w'_2 r_2) \end{aligned} \quad (9)$$

뉴로-퍼지 알고리즘의 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 연결가중치 변화량 Δw_i 를 경사하강법(gradient decent method)를 이용하여 구하며 식 (11)과 같다.

$$\begin{aligned} w_i(\text{new}) &= w_i(\text{old}) + \Delta w_i \\ \Delta w_i &= \eta \cdot \left(-\frac{\partial E_p}{\partial w_i} \right) \end{aligned} \quad (11)$$

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 변압기 모델과 보호 계전 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 10주기이고 주기당 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 7이상으로 정하였다.

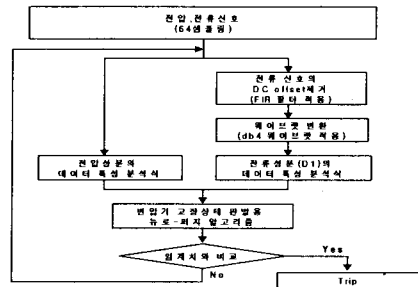


그림5. 알고리즘 흐름도
Fig. 5. Flow chart

2.4 변압기 고장 판별용 뉴로-퍼지 알고리즘 구성

변압기 고장 판별용 뉴로-퍼지 알고리즘을 구성하기 위해서는 목표데이터 선정이 매우 중요하다. 목표데이터는 변압기 과도상태를 모의하여 얻은 고장후 1/2 cycle 내의 정보로부터 얻어진다. 그런 다음 뉴로-퍼지 알고리즘은 목표데이터를 수렴하도록 학습되어진다. 최종 수렴을 통하여 전진부 파라미터와 후건부 파라미터값을 얻을 수 있다.

2.4.1 목표데이터 선정

목표 데이터는 변압기 과도 상태에 따른 변압기 특성을 표현하는 값이며 두가지 정보를 토대로 만들어진다. 첫 번째는 고장후 1/2주기 동안 변화된 1차측 전압의 RMS값이다. 두 번째,

는 차전류를 웨이브렛 변환해서 얻은 D1계수의 상대적 변화분이다. 목표데이터를 얻기 위해 사용된 룰 베이스는 식 (12)와 같다.

- 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 14 : IF X is 과여자 and Y is 과여자 , $f_{14}=2$
- Rule 15 : IF X is 과여자 and Y is 여자돌입 , $f_{15}=2$
- Rule 16 : IF X is 과여자 and Y is 고장 , $f_{16}=7$

식 (12)와 같은 룰베이스를 통해 얻어진 목표데이터는 그림 6과 같다.




그림 6. 목표치 데이터
Fig. 6. Target data

2.4.2 뉴로-퍼지 알고리즘의 학습

뉴로-퍼지 알고리즘의 학습은 뉴로-퍼지 알고리즘이 갖는 값과 목표데이터 값과의 오차를 줄여나가는 방향으로 학습되어진다. 식 (17)은 뉴로-퍼지 알고리즘의 최종 출력 오차식이다.

$$E = \frac{1}{N} \sum_{p=1}^N (y_p - \hat{y}_p)^2 \quad (17)$$

여기서, N 은 입력력 데이터 쌍이다.

최종 학습을 통하여 그림 7과 같이 에러를 0.03이하로 수렴하였다.




그림 7. 에러 곡선
Fig. 7. Error curve

학습을 통해 얻어진 최종적인 뉴로-퍼지 알고리즘의 출력값은 그림 8과 같다.




그림 8. 최종 뉴로-퍼지 출력
Fig. 8. Final Neuro-fuzzy output

2.5 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 설정되어 있다. 따라서 미리 정해진 임계치 7과 비교하여 그 이상일 경우 고장임을 판단하고 최종 계전기가 동작하게 된다.

2.5.1 내부고장

학습된 뉴로-퍼지 알고리즘의 출력은 32샘플링의 정보를 받아서 순차적인 출력을 갖는다. 따라서 뉴로-퍼지 알고리즘의 1번째 출력은 실제 32샘플링이 지난 후부터의 출력이다. 모의계통에서 고장발생 시점은 2주기 지점인 128번째 샘플링이다. 그림 9는 a상 10% 권선지락 고장시 뉴로-퍼지 알고리즘의 출력이다. 출력값이 148번째 샘플링에서 임계치 7을 넘어 고장임을 판단하고 148번째 샘플링에서 계전기가 트립함을 보여준다. 이것은 고장 후 20샘플링으로 시간상 고장 후 5.2[ms]이다.



(a) 10% 권선지락 사고시 뉴로-퍼지 출력(0°)




(b) 10% 권선지락 사고시 트립 신호(0°)


그림 9. 10% 권선지락 사고시 뉴로-퍼지 알고리즘의 출력 및 트립 신호(0°)

Fig. 9. Output of neuro-fuzzy algorithm and trip signal during 10% turn to ground fault (voltage inception angle 0°)

그림 10은 a상 60% 권선단락 고장 상태를 입력으로 하였을 때 뉴로-퍼지 알고리즘의 출력이다. 계전 알고리즘은 145번째 샘플링에서 임계치 7을 넘어 고장임을 판단하고 계전기가 동작된다. 이것은 고장 후 17샘플링, 즉 시간상으로 고장 후 4.4[ms]이다.



(a) 60% 권선단락 사고시 뉴로-퍼지 출력(90°)




(b) 60% 권선단락 사고시 트립 신호(90°)

그림 10. 60% 권선 단락 사고시 뉴로-퍼지 알고리즘의 출력 및 트립 신호(90°)


Fig. 10. Output of neuro-fuzzy algorithm and trip signal during 60% turn to turn fault (voltage inception angle 90°)

2.5.2 여자돌입

전압투입 위상각이 0°인 여자돌입 상태의 경우 그림 11과 같이 뉴로-퍼지 알고리즘의 출력은 최대 5보다 작다. 따라서 계전기가 동작되지 않는다.



(a) 여자 돌입시 뉴로-퍼지 출력(0°)




(b) 여자 돌입시 트립 신호(0°)

그림 11. 여자 돌입시 뉴로-퍼지 알고리즘의 출력 및 트립 신호(0°)


Fig. 11. Output of neuro-fuzzy algorithm and trip signal during magnetizing inrush (voltage inception angle 0°)

2.5.3 과여자 상태

그림 12는 130% 과여자 상태시 뉴로-퍼지 알고리즘의 출력과 계전기 동작이다. 과여자 상태의 경우 뉴로-퍼지 알고리즘의 출력이 1.5~5 범위를 값으로 임계치 7을 넘지 않아 계전기가 동작되지 않는다.



(a) 과여자시 뉴로-퍼지 출력(130%)



(b) 과여자시 트립 신호(130%)

그림 12. 과여자시 뉴로-퍼지 알고리즘의 출력 및 트립 신호 (130%)

Fig. 12. Output of neuro-fuzzy algorithm and trip signal during overexcitation (130%)

3. 결 론

본 논문에서는 웨이블릿 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 웨이블릿 변환을 적용하였다.
- (4) 웨이블릿 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 전력산업연구개발사업 전력기술기초연구(R-2003-B-105)에 의하여 이루어진 연구로서, 관계부처에 감사 드립니다.

[참 고 문 헌]

- [1] 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
- [2] 김상태 외 2명, "전압, 전류 변화 추이를 이용한 전력용 변압기 보호계전 알고리즘", 대한전기학회 논문지 50A 권 4호, pp157~165, 2001
- [3] "전력계통 보호계전 시스템 기술의 현황과 전망", 대한전기학회 기술조사보고, 1999
- [4] "지능형 보호계전기 연구개발", 전력연구원 최종보고서, 1998
- [5] 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
- [6] 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
- [7] 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
- [8] 이명운 외 2명 "뉴로-퍼지를 이용한 변압기 보호계전 알고리즘", 대한전기학회 논문지 52권 12호, 2003. 12.
- [9] 홍동석 외1명 "웨이블릿 변환을 이용한 변압기 보호계전 알고리즘", 대한전기학회 논문지 52권 2호, 2003. 2.
- [10] Wavelet Toolbox For Use with MATLAB, 2000
- [11] J.-S. P. Jang, "ANFIS: Adaptive-Network-Based Fuzzy Inference System", IEEE Trans. on SYSTEM. Vol. 23, No.3 May/June, 1994
- [12] Lofi Zadeh, "Neuro-Fuzzy and Soft Computing".
- [13] 오성권, "프로그래밍에 의한 컴퓨터지능" 내하출판사, 2002.
- [14] 이현업 외 1명, "Matlab을 이용한 퍼지-뉴로" 아진출판사, 1999.