

HCM기반 뉴로-퍼지 시스템을 이용한 변압기 보호 알고리즘

이명윤* 이종범
원광대

Protective Algorithm for Transformer Using Nuro-Fuzzy System based on HCM

Myoung-Rhun Lee* Jong-Beom Lee
Wonkwang University

Abstract – The second harmonic component is commonly used for blocking differential relay in power transformers. However, it is difficult to distinguish between inrush and internal winding fault with differential current protective relaying. This paper proposed a new method using Nuro-Fuzzy System based on HCM(Hard C-Means). The proposed system is more objective and systematic than existing model. The data used in input are 3-phase primary voltage and fundamental harmonic of differential current. Various states of transformer are simulated using BCTRAN and HYSDAT of EMTP. As a result of the application of algorithm in various cases, the exact discrimination between internal winding fault and inrush is performed.

1. 서 론

전력용 변압기의 주 보호용 계전기로 비율차동계전기 사용되고 있으나 변압기의 효율이 더욱 개선되어 여자돌입시 차전류의 제2고조파 함유율이 낮아지는 경향이 있다. 반면 고압화와 저증화에 따른 청전용량의 증가로 내부사고시에도 2고조파가 많이 포함되는 경향이 있다. 따라서 현재 사용되고 있는 비율차동계전법으로는 변압기의 고장상태와 여자돌입 및 과여자류 구분하여 판별하기 어려운 경우가 발생한다 [1-2]. 이러한 문제점으로 인하여 보호계전방식도 전력계통의 상황변화에 적응성을 갖는 새로운 방식이 요구되고 있다. 이에 웨이브렛[3], 신경회로망[4-5], 퍼지시스템[6]등의 방법이 제시되었다. 따라서, 본 논문에서는 언어적 표현이 가능하며 불확실한 정보에 강인성을 갖는 퍼지시스템과 입력력 관계를 학습할 수 있도록 하며 병렬처리 능력을 가진 신경회로망을 응용한 HCM(Hard C-Means) 기반의 뉴로-퍼지시스템을 변압기 보호알고리즘에 적용하였다. 제안된 시스템은 HCM 알고리즘에 의한 입력 데이터 분포의 특성에 따라 멤버쉽 함수 파라미터 중심을 찾아내고 이를 바탕으로 입출력 관계식을 만든다. 그런 다음 관계식을 뉴로-퍼지시스템에 적용시킨 것으로 이는 기존의 뉴로-퍼지시스템보다 체계적이고 객관적인 모델이다. 이 시스템에 사용된 입력변수는 변압기 과도상태를 모의하여 얻은 1차측 각 상전압의 RMS 변화분과 차전류에 포함되어 있는 기본파 성분이다. 본 논문에서 제시된 시스템은 학습되어지지 않은 입력데이터 이외의 데이터에 대해서도 정확한 결과를 출력하였다. 또 고장 후 반주기 데이터만을 이용함으로써 빠른 시간내에 고장을 검출하였다.

2. 본 론

2.1 뉴로-퍼지이론

뉴로-퍼지는 퍼지 시스템의 언어적 논리를 규칙의 형태로 표현 할 수 있는 능력과 신경회로망의 오류 역전파 알고리즘을 사용한 학습기능이 서로 결합한 형태로 양 이론의 장점을 이용하여 서로의 단점을 보완한 구조이다. 이는 퍼지논리와 신경회로망이 갖는 독특한 특성을 살리면서 모델의 효율과 성능을 향상시키는 방향으로 두 모델 구조를 하나의 모델 구조로 응합한 형태이기 때문에 복잡성과 불확실성을 나타내는 비 선형 시스템에서 다른 지능형 모델에 비해 우수한 성능을 가지고 있다[7-8]. 이와 관련된 연구 중 Jang은 결론부를 입력에 대한 선형 방정식으로 표현한 ANFIS 구조를 제안하였다[9-10]. 이는 1차 슈퍼노이즈모델 파라미터들을 최적화시키기 위해 혼합된 학습 규칙을 사용하는 구조로서 그림 1과 같이 나타낼 수 있다.

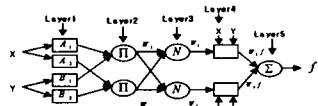


그림 1. ANFIS 구조

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 $f_2 = p_2x + q_2y + r_2$

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 1에서, Layer 1은 동정될 전건부 파라미터를 가지고 있으며 Layer 4는 후건부 파라미터를 가지고 있다.

Layer 1 : 입력에 대한 멤버쉽 값을 출력하며 소속함수로는 가우시안 함수 식(2)를 사용한다.

$$O_{1,i} = \mu_{A_i}(x) \quad i=1, 2 \quad (1)$$

$$O_{1,i} = \mu_{B_{n-2}}(y) \quad i=3, 4 \quad (1)$$

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

여기에서 a_i, b_i, c_i 는 전건부 파라미터이다.

Layer 2 : 각 규칙의 적합도를 계산한다.

$$O_{2,i} = w_i = \mu_{A_i}(x) \times \mu_{B_i}(y) \quad i=1, 2 \quad (3)$$

Layer 3 : 적합도에 대하여 정규화시킨다

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

Layer 4 : 각 규칙의 출력을 나타낸다.

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

여기에서 p_i, b_i, r_i 는 후건부 파라미터이다.

Layer 5 : 모든 규칙에 대한 출력의 합으로 최종 출력을 나타낸다.

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

추론 과정을 보면 그림 2와 같다.

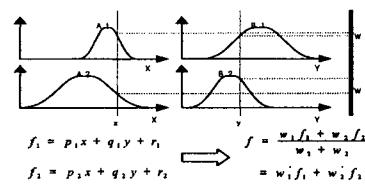


그림 2. 추론과정

뉴로-퍼지의 최종 출력은 식 (7)과 같이 후건부 파라미터의 조합으로 표현될 수 있다.

$$f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2$$

$$= w'_1(p_1x + q_1y + r_1) + w'_2(p_2x + q_2y + r_2) \\ = w'_1(p_1 + w'_2 p_2)x + (w'_1 p_1 + w'_2 p_2)y + (w'_1 r_1 + w'_2 r_2) \quad (7)$$

뉴로-퍼지시스템의 학습 방법으로는 오류 역전파 알고리즘이 사용되며 연결 가중치를 학습하기 위해 출력 오차식은 식 (8)과 같다.

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

여기에서, y_p 는 목표값, y'_p 는 ANFIS의 출력이다.

연결 가중치의 학습은 오차 E_p 를 최소화하기 위해 연결 가중치 변화량 Δw_i 를 경사하강법(gradient decent method)을 이용한다. 이는 식 (9)과 같다.

$$\begin{aligned} w_i(\text{new}) &= w_i(\text{old}) + \Delta w_i \\ \Delta w_i &= \eta \cdot \left(-\frac{E_p}{w_i} \right) \end{aligned} \quad (9)$$

여기에서, η 는 학습률, E_p 는 오차의 편미분, w_i 는 가중치의 편미분이다.

2.2 HCM 클러스터링 알고리즘

HCM(Hard C-Mean) 알고리즘은 데이터들간의 거리를 기준으로 하며 점집합 정도를 측정하고 이를 통해 데이터를 분류하는 알고리즘이다. 이를 통하여 데이터 특성에 맞게 멤버쉽 함수를 정의한다[7]. HCM 클러스터링 알고리즘은 0과 1, 즉 2진 논리에 의해서 분리된 데이터가 그룹에 속해 있는지 아닌지를 판별하며 다음과 같은 단계를 수행한다.

단계 1 : 클러스터의 개수($2 \leq c \leq n$)를 결정하고, 소속행렬 U 를 $U^{(0)} \in M_c$ 으로 초기화한다.

$$M_c = \{ U | U_{ij} \in \{0, 1\}, \sum_{j=1}^n U_{ij} = 1, 0 < \sum_{i=1}^m U_{ij} < m \} \quad (10)$$

여기에서, U_{ij} ($i=1, 2, \dots, c$; $j=1, 2, \dots, m$)는 소속행렬의 파라미터이다.

단계 2 : 각각의 클러스터의 중심벡터 V_i 를 구한다.

$$\begin{aligned} V_i &= \{ V_{i1}, V_{i2}, \dots, V_{i3}, \dots, V_{im} \} \\ V_{ij} &= \frac{\sum_{k=1}^m U_{ik} \cdot X_{kj}}{\sum_{k=1}^m U_{ik}} \end{aligned} \quad (11)$$

여기에서, i 는 i 번째 클러스터, j 는 j 번째 입력 변수($j=1, \dots, m$), n 은 data 수이다.

단계 3 : 각각의 클러스터 중심과 데이터와의 거리를 계산하여 새로운 소속행렬 $U^{(r)}$ 를 생성한다.

$$\begin{aligned} d_{ik} &= d(x_k - V_i) = \|x_k - V_i\| = [\sum_{j=1}^m (x_{kj} - v_{ij})^2]^{1/2} \\ u_{ij}^{(r+1)} &= \begin{cases} 1 & d_{ik}^{(r)} = \min d_{ik}^{(r)} \text{ for all } j \in c \\ 0 & \text{otherwise} \end{cases} \end{aligned} \quad (12)$$

여기에서, d_{ik} 는 k 번째 데이터 샘플 x_k 와 i 번째 클러스터 중심 V_i 의 기하학적 거리이다.

단계 4 : 단일 셜 13을 만족하지 않으면 단계 2로 가서 반복한다.

$$\|U^{(r+1)} - U^{(r)}\| \leq \epsilon \quad (\text{tolerance level}) \quad (13)$$

HCM 클러스터 알고리즘을 수행하여 각 입력데이터에 대한 분류 및 중심값은 그림 3과 같다.

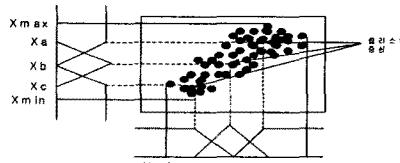


그림 3. HCM을 이용한 데이터분류 및 중심값

2.3 제안된 뉴로-퍼지 시스템의 구조

본 논문에서 제안된 뉴로-퍼지 시스템의 구조는 그림 4와 같이 2입력 1출력 구조로 되어 있고 각 입력에 대하여 소속함수를 3개씩 사용

하였으며 규칙은 9개를 사용하였다. 이는 입력 x, y 에 대한 총 9개의 퍼지 분할 공간을 의미한다. 또 각 규칙에 대한 결론부가 1차식인 선형추론법을 사용하였으며 이는 입력 변수들의 상호 상관 관계를 고려하여 퍼지 공간을 분할한다.

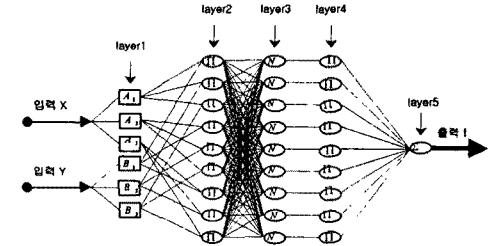


그림 4. 제안된 뉴로-퍼지 구조

제안된 뉴로-퍼지 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_1 and y is B_2 , then $f_2 = p_2x + q_2y + r_2$
- Rule 3: IF x is A_1 and y is B_3 , then $f_3 = p_3x + q_3y + r_3$
- Rule 4: IF x is A_2 and y is B_1 , then $f_4 = p_4x + q_4y + r_4$
- Rule 5: IF x is A_2 and y is B_2 , then $f_5 = p_5x + q_5y + r_5$
- Rule 6: IF x is A_2 and y is B_3 , then $f_6 = p_6x + q_6y + r_6$
- Rule 7: IF x is A_3 and y is B_1 , then $f_7 = p_7x + q_7y + r_7$
- Rule 8: IF x is A_3 and y is B_2 , then $f_8 = p_8x + q_8y + r_8$
- Rule 9: IF x is A_3 and y is B_3 , then $f_9 = p_9x + q_9y + r_9$

2.4 변압기 과도상태 및 모의

2.4.1 모델과 보호알고리즘

본 논문에서 변압기의 과도 상태를 모의하기 위해 선정된 모델은 154/22kV, 부하용량이 40MVA, Y-Y결선이며 단상변압기 3대로 이루 어진 3상 변압기로 1차측 송전선거리는 50km이다. 변압기의 내부 고장 을 모의하기 위해 EMTP상의 보조프로그램인 BCTRAN을 이용하였다. 또 변압기의 포화특성을 고려한 여자돌입 및 과여자를 모의하기 위해 EMTP상의 HYSDAT를 사용하였으며 자화곡선의 모델링이 가능한 Type-96소자를 이용하였다. 본 논문에서 제안된 변압기 보호 알고리즘의 입력 데이터는 변압기의 여러 과도상태를 모의하여 나온 전압과 전류 데이터를 가공한 것이다. 그 후 HCM 클러스터링 알고리즘을 이용하여 데이터 특성에 맞게 분류하고 이를 토대로 일출역 관제식을 정하였다. 이러한 일출역 관제식은 언어적 변수로 확실한 고장일 때는 10, 정상일 때는 0에 가까이 수렴하도록 설정하였다. 이렇게 정의된 관제식을 뉴로-퍼지 시스템에 적용하였으며 구체 감소 알고리즘과 최소 자승법에 의한 출력오차를 감소하는 방향으로 소속함수 파라미터값과 결론부 파라미터값들이 조정되었다. 변압기 보호 알고리즘은 그림 5와 같으므로 최적화된 뉴로-퍼지 시스템은 일제계 7을 넘을 경우 고장임을 판단하고 트립 신호를 내도록 설정하였다.

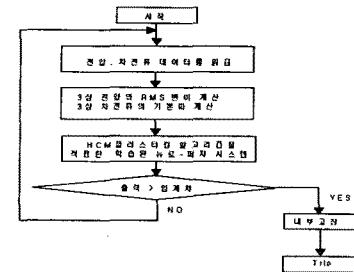


그림 5. 알고리즘 흐름도

2.4.2 모의결과 및 분석

그림 6은 변압기 1차측 A상 20% 권선지락 고장시 1차측 각상 전압을 나타내며 그림 7은 A상 50% 권선 단락시 차전류를 나타낸 것이다. 그림 8은 전압 투입각이 90도인 여자 돌입의 경우이며 그림 9는 과여자 115%인 경우의 차전류이다. 과도상태 모의는 주기당 64 생플을 하였으나 그램 8 상에서는 320생플, 5주기만 나타내었다.

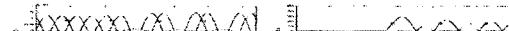


그림 6. A상 20% 충간단락 고장 시 차전류 (0도)

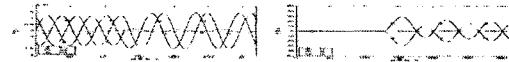


그림 7. A상 50% 충간단락 고장 시 차전류 (0도)

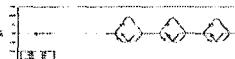


그림 8. 여자들입시 차전류 (90도)

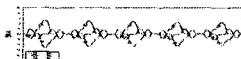


그림 9. 과여차시 차전류 (115%)

변압기의 여러 과도 상태를 모의한 결과 여자들입 또는 과여차시에 차전류가 발생함을 확인하였다. 또 이러한 차전류의 특성을 파악하기 위해 적교 변환기를 사용하여 각 상에 포함되어 있는 기본파 성분을 추출하였다. 그림 10~13은 분석한 결과를 나타낸다.



그림 10. 권선지락 고장시 고조파 분석



그림 11. 권선단락 고장시 고조파 분석

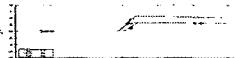


그림 12. 여자들입시 고조파 분석



그림 13. 과여차시 고조파 분석

2.5 뉴로-퍼지시스템의 학습 및 사례연구

2.5.1 뉴로-퍼지시스템의 학습

변압기의 여러 과도 상태를 모의한 출력으로부터 목표치데이터를 만들기 위해 입력변수를 2개 선정하였으며, 첫번째 입력변수는 1차측 단자 전압의 RMS의 변화분이고 두 번째 입력변수는 차전류의 기본파 함유율이다. 이러한 입력 데이터들에 대한 HCM클러스터링 알고리즘의 적용 결과는 그림 14~15와 같다.

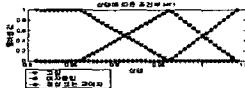


그림 14. 입력 1의 멤버십 함수

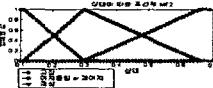


그림 15. 입력 2 멤버십 함수

이러한 소속함수를 바탕으로 한 목표값을 그림 16에 나타내었다.



그림 16. 목표데이터

이렇게 얻어진 입력력 관계식을 결론부가 1차 선형식이며 소속함수가 gbell함수인 뉴로-퍼지시스템에 적용하였다. 이 시스템은 300번의 학습을 통하여 출력 오차가 최소화 되는 방향으로 전반부 소속함수의 파라미터를 생성하고 후반부 파라미터를 최소자승법에 의해 구한다. 그림 19~20은 최종학습 결과 생성된 소속함수를 나타낸다.

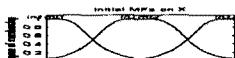


그림 17. 초기 소속함수(Input 1)

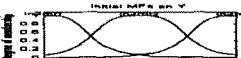


그림 18. 초기 소속함수 (Input 2)

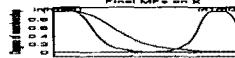


그림 19. 최종 소속함수(Input 1)

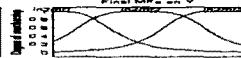


그림 20. 최종 소속함수 (Input 2)

최종 학습을 통한 출력 오차는 그림 21과 같고 학습된 최종 출력을 그림 22에 나타내었다.



그림 21. 출력 오차

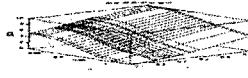


그림 22. 학습된 최종 출력

2.5.2 사례 연구

학습된 뉴로-퍼지시스템의 타당성을 확인하기 위해 과도상태를 모의하고 나온 출력을 재입력으로 하여 그 결과를 확인하였으며 이는 표

1과 같다. 여기에서 뉴로-퍼지시스템의 출력은 미리 정해진 임계치 7 이상과 비교하여 고장판단에만 이용되었으며 뉴로-퍼지 시스템의 출력은 언어적인 표현으로 고장일 때는 7과 비교하여 이상일 경우에만 트림 신호를 내보내도록 설정하였다.

표 1. 학습된 입력에 대한 뉴로-퍼지시스템의 출력

변압기 상태	뉴로-퍼지시스템의 출력	트림신호
A상 20%(0도) 권선지락사고	9.9989	1
A상 50%(0도) 권선단락사고	9.1074	1
여자들입(전압부일각 90도)	4.4361	0
과여차(107%)	1.8904	0
점상	0.4765	0

학습에 사용되지 않은 입력에 대한 뉴로-퍼지시스템의 신뢰도를 평가하기 위해 A상 22%(0도)권선지락사고, A상 47%(0도), 여자들입 전압부일각(86도), 과여차(107%)를 입력으로 뉴로-퍼지시스템에 적용시켜 본 결과는 표 2와 같다.

표 2. 학습되지 않은 입력에 대한 뉴로-퍼지시스템의 출력

변압기 상태	뉴로-퍼지시스템의 출력	트림신호
A상 22%(0도) 권선지락사고	9.9901	1
A상 47%(0도) 권선단락사고	8.9575	1
여자들입(전압부일각 86도)	4.0997	0
과여차(107%)	1.298	0

3. 결 론

본 논문에서는 퍼지시스템과 신경회로망 시스템을 융합시킨 뉴로-퍼지시스템에 HCM클러스터링 알고리즘을 도입함으로써 보다 객관적이고 체계적인 전력용 변압기 보호 알고리즘을 제안하였다. 이 연구를 통해 얻은 결과는 다음과 같다.

- (1) 변압기의 내부고장과 여자들입상태는 뉴로-퍼지 시스템을 통해 정확히 판별되었다.
- (2) 고장후 반주기 데이터만을 이용한 것으로 빠른 시간내에 정확히 판별되었다.
- (3) 학습에 사용되지 않은 입력에 대하여서도 정확한 판별하였다.

(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] 김상태의 2명, "전압, 전류 변화 추이를 이용한 전력용 변압기 보호제전 알고리즘", 대한전기학회 논문지 50A 권 4호, pp157~165, 2001.
- [3] 홍동석의 1명, "웨이브렛을 이용한 변압기 보호제전 알고리즘", 2001년도 대한전기학회 하계학술대회 논문집, pp. 485~487, 2001.
- [4] 권기백의 3명, "웨이브렛 변환을 바탕으로 한 신경 회로망을 이용한 전력용 변압기 보호 제전기법", 대한전기학회 논문지 51권 3호, 2002.2.
- [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] 서희석의 3명, "퍼지시스템에 의한 변압기 보호용 디지털 보호계 전 알고리즘", 대한전기학회 논문지 46권 3호, 1997.
- [7] 오성권, "프로그래밍에 의한 컴퓨터지능", 내화출판사, 2002.
- [8] 이현엽, 문경일, "MATLAB을 이용한 퍼지-뉴로", 도서출판 아진.
- [9] J.-S. P. Jang, "ANFIS: Adaptive-Network-Based Fuzzy Inference System", IEEE Trans. on SYSTEM. Vo 1.23, No.3, May/June, 1994.
- [10] Loft Zadeh, "Neuro-Fuzzy and Soft Computing".