

웨이브렛 변환을 바탕으로 한 신경회로망을 이용한 전력용 변압기 보호 개전기법

*권기백

*윤석무

신명철

*대덕대학 전기전자계열 컴퓨터 응용제어과

성균관대학교 전기전자 공학부

The protective relaying scheme of power transformer using wavelet based neural networks

*G. B. Kweon *S. M. Yoon M. C. Shin

*DaeDuk Collage

Sung Kyun Kwan Univ.

Abstract - This paper presents the protective relaying scheme as a method for discriminating of power transform's transient state associated with magnetizing inrush state, over-exciting state and internal fault using wavelet based neural networks. The simulation of EMTP with respect to different fault, inrush condition and over-exciting condition in transformer have been conducted, and the result prove that the proposed method is able to discriminate between inrush magnetizing current and internal fault.

1. 서 론

전력용 변압기는 전력계통에서 가장 중요한 설비중 하나이므로, 사고가 발생할 경우 그 파급효과는 상당히 크다. 뿐만 아니라 수리와 대체는 많은 비용과 상당한 시간을 필요로 한다. 따라서 변압기 보호는 필수적이며, 그러한 변압기 주보호용 계전기로는 비율차동계전기가 주류를 이루고 있다. 이것은 변압기의 유입전류와 유출전류의 차인 차전류와 합인 통과전류(역제전류)의 비율 관계를 이용한 방식으로써 통과전류가 적을 때에는 적은 차전류로 동작하고 통과전류가 큰 경우에는 큰 차전류에 동작하도록 하였다. 그리고 계통 가압시 발생하는 여자돌입전류에 의한 차전류 발생으로 인한 오동작 방지책으로 제2고조파 억제방식이 사용되고 있다. 이는 여자돌입시 발생하는 여자돌입전류의 기본파에 대한 제2조파 함유율을 계산함으로써 차전류와 통과전류의 비율이 일정 이상이더라도 계전기의 동작을 억제하는 역할을 한다.

한편 변압기 제작기술의 발달과 더불어 근래에 제작되는 변압기는 효율이 더욱 개선되어 변압기의 여자돌입시 차전류의 제2고조파 함유율이 낮아지는 경향이 있는 반면, 고압화 및 지중화에 따른 정전용량의 증가, 중저조파인 3~8조파 성분도 많이 포함되는 경향이 있다. 따라서 현재 널리 이용되고 있는 고조파 억제특성을 갖는 비율차동 계전기로는 변압기의 고장상태와 여자돌입 및 여자 상태를 구별하기 어려운 경우가 발생한다. 이와 같은 문제점을 보완하기 위해 변압기의 자속의 결합방정식, 신경회로망이나 퍼지 의사결정, 전력을 이용하는 방법 등이 많이 제시되고 있다.[1~4]

본 논문에서는 대부분 신호 분석하는 데 사용해 왔던 푸리어 변환과는 다르게 크기 팽창(dilates)과 변이(translates)를 가변하면서 신호를 분석하는, 다양한 고조파를 함유한 과도파형의 분석에 적합한 웨이브렛 변환을 이용하였다. 즉 Daubechies 웨이브렛 변환을 이용하여 Approximation 정보와 Detail 정보를 추출하여, Approximation 정보는 차전류와 통과전류의 비율을 구하는데 이용하였으며, Detail 정보는 신경회로망의 입력패턴으로 활용하여 과여자 상태나 여자돌입시 계전기의 동작을 억제하는 데 이용하였다. 따라서 Daube

-chies 웨이브렛 변환의 정보를 이용해서 계전기의 동작요소와 신경회로망을 통해 계전기의 동작을 억제하

는 역제요소로써 변압기의 내부 상태를 파악하는 고장판별기법을 제안하였다. 또한 전력용 변압기의 다양한 내부상태를 모의하여 EMTP를 이용하여 제시된 판별기법의 신뢰성을 입증하였다.

2. 본 론

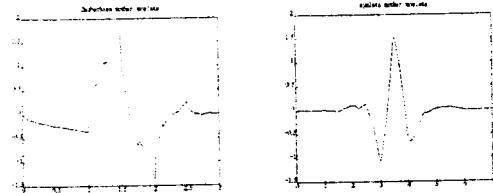
2.1 웨이브렛 변환

2.1.1 웨이브렛 변환

연속적인 신호 $x(t)$ 의 웨이브렛 변환(WT)는 다음 식(1)과 같이 정의한다.

$$WT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \cdot g\left(\frac{t-b}{a}\right) dt \quad (1)$$

여기서, 신호 $x(t)$ 는 분석함수 $g\left(\frac{t-b}{a}\right)$ 에 의해 변환된다. 분석함수 $g(t)$ 는 복소수에 제한되어 있지 않다. 사실, $g(t)$ 에 대한 유일한 제한은 짧고 진동적이어야 된다. 즉 평균 0이고 양 끝에서 빠르게 감소해야 된다. 이러한 제한은 식(1)에서 적분이 유한해야 된다는 것이다. $g(t)$ 는 모 웨이브렛으로 언급하고 웨이브렛을 단순히 팽창(dilates)과 변이(translates)시킨 것이다. 그림1에서 진동적이고 비정현적인 특성을 보여주는 2개의 모 웨이브렛의 예이다.



(a) Daubechies 모웨이브렛 (b)symlet 모웨이브렛
그림 1. 모 웨이브렛의 예

두번째 차이점은 STFT(Short Time Fourier Transform)에서 존재하지 않는 시간 스케일 파라메타이다. 웨이브렛 $g\left(\frac{t-b}{a}\right)$ 의 시간의 확장은 $a > 1$ 혹은 $a < 1$ 인지에 따라서 시간적으로 확장되거나 수축된다. $a > 1$ 인 경우는 시간적으로 $g(t)$ 를 확장시키고 $g\left(\frac{t-b}{a}\right)$ 는 진동의 주파수를 감소시킨다. 반면에 $a < 1$ 인 경우는 시간적으로 $g(t)$ 를 축소시키고 $g\left(\frac{t-b}{a}\right)$ 는 진동의 주파수를 증가시킨다. 그래서 a 가 어떤 범위에 존재할 경우 일반적으로 1로 시작해서 증가하며, 시간적으로 점점 초점을 잃어 가는 팽창함수에 의해 입력을 분석하게 된다.

디지털적으로 구현할 수 있는 것이 이산 웨이브렛 변환이다. DWT(Digital Wavelet Transform)는 다음 식(2)로 정의한다.

$$DWT(m, k) = \frac{1}{\sqrt{a_0^m}} \sum_n x[n] \cdot g\left(k - \frac{n a_0^m}{a_0}\right) \quad (2)$$

여기서, $g(n)$ 은 모 웨이브렛이다. 식 (2)의 스케일과 변이 파라메타 a, b 는 정수 파라메타 m 의 합수이다. 즉 $a = a_0^m, b = n \cdot a_0^m$ 이다. 결과는 기하학적인 스케일 $1, \frac{1}{a}, \frac{1}{a^2}, \dots$, 와 $0, n, 2n, \dots$,에 의한 변이가 발생한다.

2.1.2 웨이브렛의 구현

식 (3)의 구조를 살펴보면, 그림에서 보여주듯이 웨이브렛 변환의 효율적인 필터뱅크 구현을 암시한다. n 에 대해서 k 의 변수를 치환하면 식(2)는 다음과 같이 작성된다.

$$DWT(m, n) = \frac{1}{\sqrt{a_0^m}} \sum_k x[k] \cdot g(a_0^{-m}n - k) \quad (3)$$

식(3)의 유사성은 FIR 디지털 필터에 대한 일반적으로 보여주며, 식(4)와 같이 표현할 수 있다.

$$y(n) = \frac{1}{c} \sum_k x[k] \cdot h(n-k) \quad (4)$$

이러한 사실은 $g(a_0^{-m}n - k)$ 이 전달함수 $G(w)$ 을 갖는 로파스 필터(Low Pass Filter)의 임펄스 반응을 암시한다. 그리고 $a_0=2$ 혹은 $a_0^{-m}=1, \frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \dots$ 을 선택함으로써 $g(n)$ 의 팽창은 효과적으로 $G(W)$ 의 밴드위드(bandwidth)의 절반이 된다. 그림2에서 보여준 다중 단계 필터뱅크(multi-stage filter bank)는 로파스 모 웨이브렛 $g[n]$ 과 하이파스 $h[n]$ 을 이용하면서 DWT를 구현한다. 로파스 필터 $g[n]$ 의 출력에서 다운샘플링 (2↓)은 다음 관계를 위해 2에 의해 웨이브렛을 스케일하는 것이다. $g[n]$ 과 $h[n]$ 이 orthonormal 기저를 형성하도록 억제 조건을 준 모 웨이브렛이라면 이러한 구현은 그것이 출력이 유일한(unique) 특성을 가진다. 필터뱅크를 이용하면서 DWT의 디지털적인 구현을 효율적으로 한다.

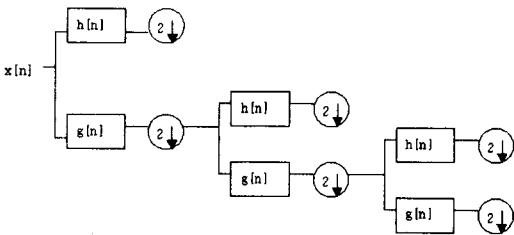


그림 2. 다단계 필터 뱅크 DWT 구현

2.2 웨이브렛 변환을 바탕으로 한 신경회로망을 이용한 전력용 변압기 보호 계전기법

Daubechies 웨이브렛 변환과 신경회로망을 이용하여 변압기의 여자돌입 상태, 과여자 상태 그리고 권선 내부 고장을 판별하기 위해 전체적인 구성도는 그림3에서 잘 나타내고 있다. 일단 각 단자 CT를 통해 입력된 2차측 전류로부터 변압기 1-2차, 1-3차의 권선비 보상 및 위상차 보상을 거쳐서 OLTC Tap 변화분을 보상한다. 그리고 1-2차, 1-3차 각 상의 차전류와 통과전류를 구하여 웨이브렛 변환을 통해 Detail 정보와 Approximation 정보로 분석한다. 마지막으로 Approximation 정보는 비율차동 계전요소의 차전류와 통과전류의 비율을 구하는데 이용하고 Details 정보는 신경회로망의 입력패턴으로 입력하여 변압기의 과여자 상태 및 여자돌입 상태에서 비율차동 계전요소의 오동작을 방지하기 위해 이용된다.

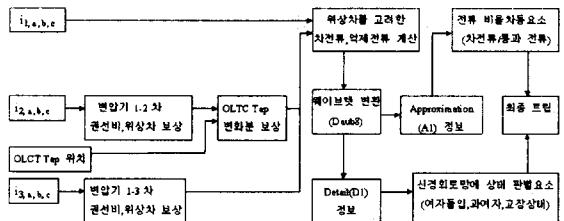
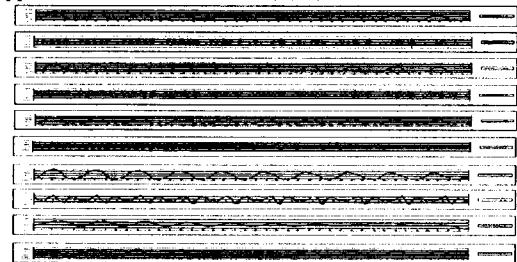


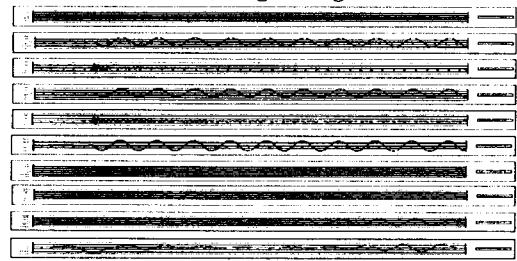
그림3. 제안된 변압기 보호 계전기법의 전체적인 구성도

2.2.1 웨이브렛 변환을 이용한 변압기의 내부상태 분석

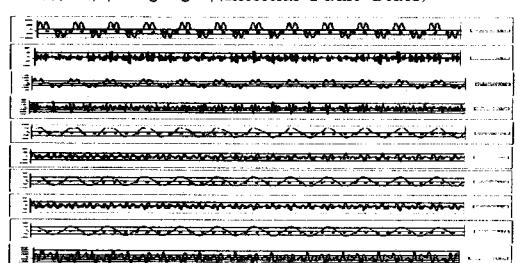
그림4에서 (a),(b),(c)는 웨이브렛 변환을 이용하여 변압기의 여자돌입 상태, 내부고장 상태, 과여자 상태에 대하여 분석하였다. 즉 변압기의 여자돌입 상태, 내부고장 상태, 과여자 상태에서의 차전류를 바탕으로 Daub8의 모 웨이브렛 변환을 통해 레벨5까지 Detail 정보와 Approximation 정보를 분석하였다.



(a) 여자돌입 상태(Magnetizing Inrush State)



(b) 내부고장 상태(Internal Fault State)



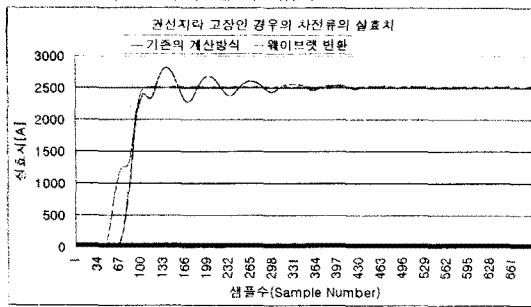
(c) 과여자 상태(Over Exciting State)

그림4. 변압기의 내부상태에 따른 웨이브렛 변환 결과

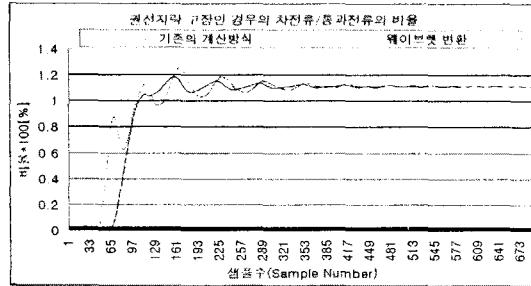
2.2.2 웨이브렛 변환을 이용한 비율차동전류

차전류와 통과전류의 웨이브렛 변환을 통해 얻은 Detail 정보와 Approximation 정보중에서 Approximation 정보만을 이용하여 차전류와 통과전류의 비율을 계산한다. 그럼5에서는 변압기의 내부 고장상태인 경우의 차전류의 웨이브렛 변환결과를 그림5의 (a)에서 나타내고 있고, 그림5의 (b)는 차전류와 통과전류의 비율을 나타내고 있다. 여기서 나타난 차전류와 통과전류의 비율을 살펴보면, 웨이브렛 변환하기 이전의 신호를 이용하여 차전류와 통과전류의 비율을 구하는 방법과 거의 유사함을

알 수 있다. 하지만 차전류를 구하는데 있어서 웨이브렛 변환을 함으로써 차전류에 포함되어 있는 노이즈가 제거됨을 그림5의 (a)에서 알 수 있다.



(a) 차전류의 웨이브렛 변환



(b) 웨이브렛 변환된 차전류와 통과전류의 비율
그림 5. 내부 고장인 경우의 비율 차동전류

2.2.2 비율차동 계전기의 오동작 방지를 위한 신경회로망의 설계

웨이브렛 변환을 이용해서 얻은 Approximation 정보에 의해 비율차동 계전요소의 차전류와 통과전류의 비율을 계산하였다. 하지만 변압기의 과여자 상태 및 여자돌입 상태에서 비율차동 계전요소의 오동작방지하기 때문에 이를 방지하기 위해서 Details 정보를 이용하여 신경회로망을 통해 이런 오동작을 방지하였다. 이 신경회로망은 입력층, 중간층, 출력층으로 이루어진 3층 퍼셉트론으로 구성하였으며, 활성함수는 시그모이드 함수가 사용되었다. 그리고 학습 알고리즘은 역전파 알고리즘을 사용하였으며, 시뮬레이션을 통해 가장 적절한 학습률 $\eta = 0.9$ 와 관성항 $\alpha = 0.7$ 를 결정하였다. 입력패턴은 그림 6에서 나타내듯이 3상의 차전류의 웨이브렛의 변환을 통해 얻은 Detail 정보이다. 그러한 데이터를 학습함으로서 얻은 최종의 학습 데이터는 그림 7에서 완전히 학습되었음을 보이고 있다.

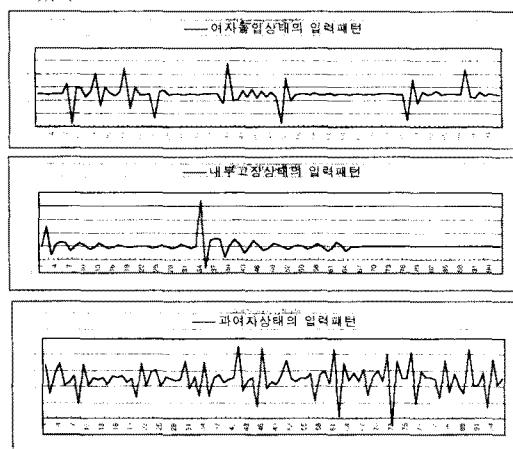


그림 6. 변압기의 상태에 따른 신경회로망의 입력패턴

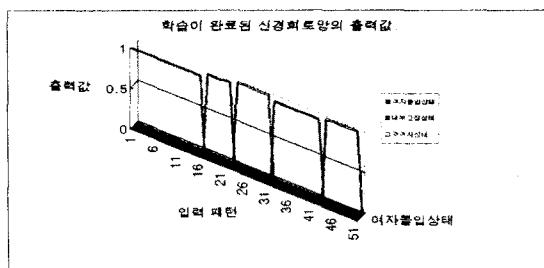


그림 7. 학습된 신경회로망의 출력결과

2.3 사례 적용 및 결과 교찰

제안된 기법의 효용성을 입증하기 위하여 그림8과 같은 모델 계통이 고려되었다. 여기서, 전력용 변압기는 3상 2권선 45/60MVA, 154KV/22.9KV, A-Y 결선으로 EMTP 소프트웨어를 이용하였으며 제시된 기법의 성능평가를 위하여 여자돌입상태, 내부 고장발생, 과여자 상태 등을 모의하였다.

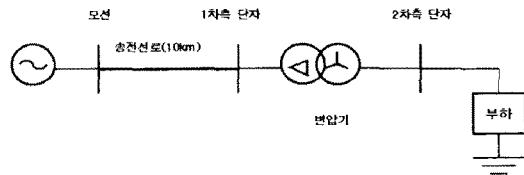
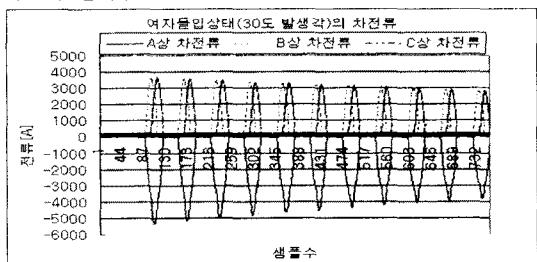


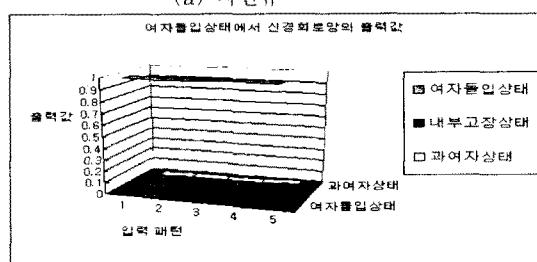
그림 8. 모델 전력계통도

2.3.1 여자돌입 상태인 경우

그림3에서도 나타내었듯이 우선, 차전류와 통과전류를 구하여 웨이브렛 변환을 통해 각각 Detail 정보와 Approximation 정보로 분석한다. 그리고 각각의 Approximation 정보는 비율차동 계전요소의 차전류와 통과전류의 비율을 구하는데 이용하고 Details 정보는 신경회로망의 입력패턴으로 입력하여 변압기의 여자돌입 상태에서 비율차동 계전요소의 오동작을 방지하기 위해 이용된다. 그림9의 (a)에서는 변압기의 여자돌입상태에서 1차측 전류와 2차측 전류를 통하여 차전류를 나타낸 것이고 그림9의 (c)에서는 신경회로망의 출력패턴을 나타내고 있다. 결국, 여자돌입 상태에서 정확하게 패턴이 인식됨을 알 수 있다.



(a) 차전류

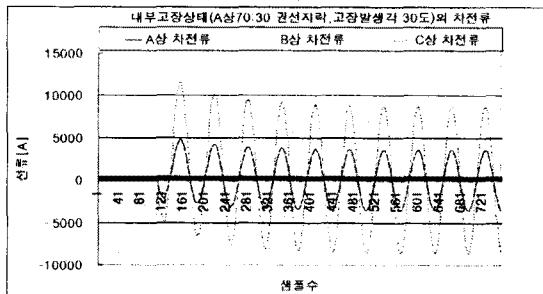


(b) 신경회로망의 출력값

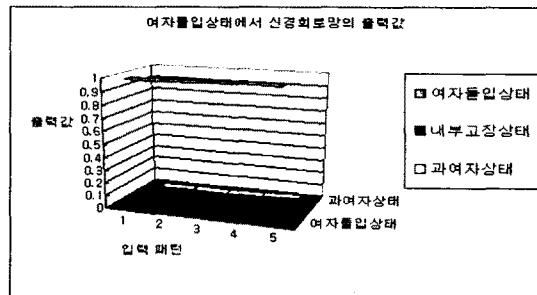
그림 10. 변압기의 여자돌입상태인 경우

2.3.2 변압기의 내부권선(A상 70:30)에서 고장이 발생한 경우

여자들입 상태와 마찬가지로 그림11의 (a)에서는 변압기의 내부 권선에서의 고장으로 인해 발생하는 차전류를 나타내고 있고 그림11의 (b)에서는 4주기까지 정확하게 패턴을 인식하다가 5주기부터 패턴 분류가 잘못됨을 알 수 있다. 그 이유는 가장 효율적으로 신경회로망을 학습시키기 위해서 고장패턴이 명확하게 구별을 할 수 있는 4주기까지만 학습을 시켰기 때문이다.



(a) 차전류

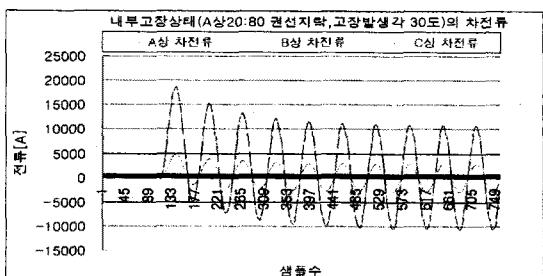


(b) 신경회로망의 출력값

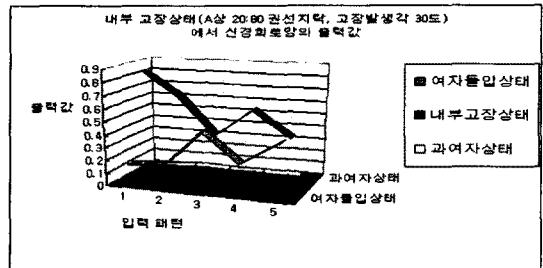
그림11.변압기의 내부권선(A상70:30)에서 고장인 경우

2.3.3 변압기의 내부권선(A상 20:80)에서 고장이 발생한 경우

그림12에서는 변압기의 내부권선(A상 20:80)의 지락사고로써 학습된 패턴의 내부권선사고와는 다르게 내부 권선의 고장 위치를 달리함으로써 전혀 학습이 이루어지지 않은 사고의 형태임에 어떤 출력패턴을 생성하는지를 알아보기 위해 살펴보았다. 마찬가지로 그림12의 (a)에서는 차전류를 나타내고 있으며, 그림12의 (b)의 신경회로망의 출력패턴을 살펴볼 때 2주기 사이에 명확하게 패턴을 인식함을 알 수 있다.



(a) 차전류



(b) 신경회로망의 출력값

그림12.변압기의 내부권선(A상20:80)에서 고장인 경우

3. 결 론

본 논문에서는 대부분 신호 분석하는 데 사용해 왔던 퓨리어 변환과는 다르게 크기 팽창(dilates)과 변이(translates)를 가변하면서 다양한 고조파를 함유한 과도파형을 분석하는 웨이브렛 변환을 이용하였다. 이런 웨이브렛을 변환을 이용하여 변압기의 여자들입상태, 내부고장상태, 과여자상태를 판별하는 새로운 고장판별 기법을 제안하였다. 제안된 고장판별 기법은 다음과 같다.

(1) 비율차동요소를 계산하기 위해서 Daubechies 웨이브렛 변환을 이용하여 Approximation 정보를 추출하여 차전류와 통과전류의 비율을 이용하였다.

(2) Detail 정보는 신경회로망의 입력패턴으로 활용하여 과여자 상태나 여자들입시 계전기의 동작을 억제하는데 이용하였다.

(3) 전력용 변압기의 내부상태를 모의하여 EMTP를 이용하여 제시된 판별기법의 신뢰성을 입증하였다.

이상과 같이 본 논문에서는 웨이브렛 변환을 이용하여 변압기의 내부상태의 특성을 추출하여 신경회로망을 통해 판별하도록 하는 계전기법을 제안하였다. 앞으로 좀 더 다양한 변압기의 내부상태를 모의하여 그 신뢰성과 적용 가능성에 대해서 계속적인 연구가 필요할 것이다.

[참 고 문 헌]

- [1] L.G.Perez, A.J.Flechsig, J.L.Meador, Z.Obradovic "Training An Artificial Neural Network to Discriminate between Magnetizing Inrush and Internal Faults", PWRD, Vol.9, No.1, pp.434-441, 1994
- [2] Kuniaki Yabe, "Power Differential Method for Discrimination between Fault and Magnetizing Inrush Current in Transformers", T. IEE Japan, Vol.116-B, No.3, pp.293-298, 1996
- [3] Moises Gomez-Morante, Denise W.Nicolette "A Wavelet-Based Differential Transformer Protection", PWRD, Vol.14, No.4, pp.1351-1355, 1999
- [4] Surya Santoso, "Power Quality Disturbance Waveform Recognition Using Wavelet-Based Neural Classifier-Part 1: Theoretical Foundation", PWRD, Vol.15, No.1, pp.222-228, 2000