

# 웨이브렛 변환을 바탕으로 한 신경회로망을 이용한 전력용 변압기 보호 계전기법

論文

51A-3-4

## The Protective Relaying Scheme of Power Transformer Using Wavelet Based Neural Networks

權 奇 柏 \* · 徐 澈 錫 \*\* · 尹 錫 武 \*\*\* · 申 明 澈 \*\*\*\*  
(Gi-Back Kwon · Hee-Seok Suh · Seok-Moo Yoon · Myong-Chul Shin)

**Abstract** - This paper presents a new method for the protective relaying scheme in power transformer using wavelet based neural networks. This approach is as follows. After approximation and detail information is extracted by daub wavelet transform from differential current of power transformer, the former is used for obtaining the rate of differential currents and restrain currents, the latter used as the input of artificial neural networks to avoid the miss-operation in over-exciting state and magnetizing inrush state of power transformer. The simulation of EMTP with respect to different faults, inrush conditions and over-exciting conditions in power transformer have been conducted, and the results proved that the proposed method is able to discriminate magnetizing inrush states, over-exciting states and internal faults.

**Key Words** : Approximation information, Detail information, Differential current, Restrain currents, EMTP

### 1. 서 론

일반적으로 전력용 변압기를 보호하기 위한 주보호용 계전기법으로는 여자들입전류에 의한 계전기의 오동작 방지를 고려한 제2고조파 억제 기능을 갖는 비율차동계전기법이 널리 이용되고 있다.[1,2,3]

그러나 변압기 제작기술의 발달과 더불어 근래에 제작되는 변압기는 효율이 더욱 개선되어 변압기의 여자들입시 차전류에 제2고조파 성분의 함유율이 낮아지는 경향이 있는 반면 고압화 및 저중화로 인해 정전용량의 증가와 중저조파인 3~8조파 성분도 많이 포함되는 경향이 있다. 따라서 현재 널리 이용되고 있는 제2고조파 억제기능을 갖는 비율차동계전기법으로는 변압기의 고장상태와 여자들입 및 과여자 상태를 구별하기 어려운 경우가 발생한다.[2]

이와 같은 문제점을 보완하기 위해 근래에는 전력용 변압기의 보호계전기법으로 변압기 자속의 변화를 이용하는 방법[3], 신경회로망이나 퍼지 의사결정에 의한 방법[4,5], 전력을 이용하는 방법[2] 등이 제시되기도 하였다. 또한 최근에는 디지털 보호계전기법에 필수적인 신호처리 방법으로서 푸리에(Fourier) 변환과는 달리 크기 팽창(dilates)과 변이(translates)를 가변하면서 신호를 분석함으로써 과도파형 분석에 적합한 웨이브렛 변환을 이용한 신호처리 방법 등이 제시되었다.

웨이브렛 변환은 변환된 신호를 어떻게 이용하는가에 따라 그 효율성이 고려되는데 일반적으로 변압기 보호계전기법에서는 변환된 정보를 확률적으로 해석하는 방법이 이용되었다.[6,7,8]

본 논문에서는 웨이브렛 변환을 통해 얻은 정보를 이용하여 신경회로망에서 논리적 판단을 하게 함으로서 보다 정확하게 변압기의 내부고장 상태를 파악하는 새로운 고장검출 알고리즘을 제시한다.

본 논문에서 제시한 변압기 보호계전 알고리즘은 우선, 도비시(Daubechies) 웨이브렛 변환을 이용하여 근사정보(Approximation)와 상세정보(Detail)를 추출하고, 그 중에서 근사정보는 비율차동요소를 구하는데 이용하여 변압기의 정상상태와 이상상태를 판단하는데 이용되며, 나머지 상세정보는 신경회로망의 입력패턴으로 활용하여 과여자 상태나 여자들입상태인 경우 계전기의 오동작을 방지하는데 이용되며 내부고장인 경우에는 보호계전기의 트립정보로 이용된다.

그리고 제시한 변압기 보호계전 알고리즘은 전자과도해석 프로그램(EMTP)를 이용하여 시뮬레이션한 전력용 변압기의 다양한 고장, 여자들입상태, 과여자상태 등의 데이터를 이용하여 그 신뢰성을 입증하였다.

### 2. 웨이브렛 변환

웨이브렛 변환(Wavelet Transform)은 Fourier 변환의 변형인 이산 코사인 변환(Discrete Cosine Transform)이론을 근간으로 개발되어져 왔으며, 이 이론은  $\sin$  과  $\cos$ 이 Hilbert space에서 basis를 이룬다는 수학적 이론에 기반을 둔다. 즉 비 주기성 신호를 분석하는데 있어서 푸리에 변환에 가지고 있는 단점을 극복하기 위해 단축시간 푸리에 변

\*正會員：大德大學 電氣電子系列 專任講師

\*\*正會員：斗源工大 自動化시스템과 副教授·工博

\*\*\*正會員：大德大學 電氣電子系列 副教授·工博

\*\*\*\* 終身會員：成均館大 電氣電子 및 컴퓨터 工學部 教授·工博

接受日字：2001年 12月 8日

最終完了：2001年 12月 15日

H(Short Time Fourier Transform : STFT)가 제시되었으나 TFT는 신호를 일정한 해석 원도우의 크기만큼 주기적으로 가정하는 고정 원도우를 사용하기 때문에 빠른 과도파형과 정현파형이 동시에 존재하는 신호에 대해서는 적합한 분석법이 되지 못하였다. 반면, 웨이브렛 변환은 고주파수에는 짧은 원도우, 저주파수에서는 긴 원도우를 사용함으로써 기본파와 저차 고조파와 과도파형을 모두 갖는 신호의 분석에 적합하다.

## 2.1 웨이브렛 변환

연속적인 신호  $x(t)$ 의 웨이브렛 변환(Wavelet Transform WT)은 다음 식(1)과 같이 정의된다. [9]

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

여기서, 신호  $x(t)$ 는 분석함수  $g\left(\frac{t-b}{a}\right)$ 에 의해 변환된다. 분석함수  $g(t)$ 는 복소지수에 제한되지 않으며,  $g(t)$ 에 대해 유일한 제한은 짧고 진동적이어야 한다는 것이다. 그리고  $g(t)$ 는 모 웨이브렛(mother wavelet)이라 하며 웨이브렛은 단순히 팽창(dilates)과 변이(translates)시킨 것이다. 그럼 모 웨이브렛의 예를 나타낸 것이다.

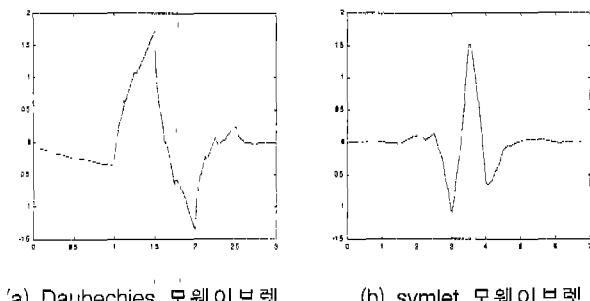


그림 1. 모 웨이브렛의 예

Fig. 1. Example mother wavelets.

그림 1의 (a)는 비대칭적이면서 진동적이고 비정현적인 특성을 보여주는 Daubechies 모 웨이브렛으로 전력계통분야 많이 이용되고 있으며, 그림(b)는 Daubechies 모 웨이브렛과 유사하지만 거의 대칭적인 특성을 가지고 있는 symlet 모 웨이브렛을 나타낸 것이다.

웨이브렛에는 STFT와는 달리 시간 스케일 파라메타가 존재한다. 즉 웨이브렛  $g\left(\frac{t-b}{a}\right)$ 은  $a > 1$  혹은  $a < 1$ 에 따라서 시간적으로 확장되거나 축축되는데,  $a > 1$ 인 경우는 간적으로  $g(t)$ 를 확장시키고  $g\left(\frac{t-b}{a}\right)$ 는 진동 주파수를 소시키며,  $a < 1$ 인 경우는 시간적으로  $g(t)$ 를 축소시키고  $g\left(\frac{t-b}{a}\right)$ 는 진동 주파수를 증가시킨다. 따라서 일반적으로 1로 시작해서 증가하며, 시간적으로 점점 확장하는 팽창함수에 의해 입력을 분석하게 된다.

이와 같은 웨이브렛 변환을 디지털적으로 표현하면 식(2)와 같은 이산 웨이브렛 변환(Digital Wavelet Transform : DWT)으로 정의된다.

$$DWT(m, k) = \frac{1}{\sqrt{a_0^m}} \sum_n x[n] \cdot g\left(k - \frac{na_0^{-m}}{a_0^m}\right) \quad (2)$$

여기서,  $g[n]$ 은 모 웨이브렛이며, 스케일과 변이 파라메터  $a, b$ 는 정수 파라메터  $m$ 의 함수이다.[9]

## 2.2 패턴 생성 웨이브렛 변환의 디지털적 구현

웨이브렛 변환을 이용하여 필터뱅크를 구현하기 위해 식(2)를  $n$ 에 대해서  $k$ 의 변수를 치환하면 식(3)과 같이 변형된다.

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

여기서 식(3)은 일반적인 FIR(Finite Impulse Response) 디지털 필터에 대한 방정식과 같은 형태로 식(4)와 같이 표현될 수 있다.

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

따라서 식(4)는  $g(a_0^{-m}n - k)$ 이 전달함수  $G(w)$ 을 갖는 로파스 필터(Low Pass Filter)의 임펄스 응답을 나타낸다. 그리고  $a_0=2$  또는  $a_0^{-m}=1, \frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \dots$ , 을 선택함으로써  $g[n]$ 의 팽창은 효과적으로  $G(W)$ 의 밴드폭(bandwidth)의 절반이 된다.

그림 2는 로파스 모웨이브렛  $g[n]$ 과 하이파스  $h[n]$ 을 이용하여 DWT를 구현한 다중 단계 필터뱅크(multi-stage filter bank)를 나타낸 것이다.

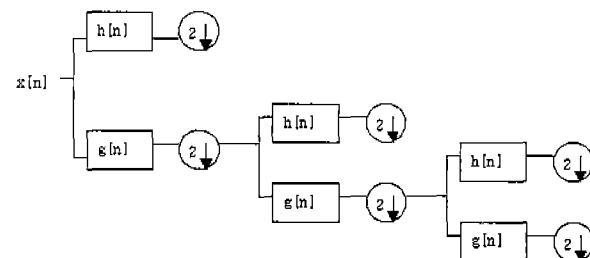


그림 2. 다단계 필터 뱅크 DWT 구현

Fig. 2. Mult-stage filter bank DWT implementation.

그림 2에서 다운샘플링 ( $2\downarrow$ )은 다음 관계를 위해 웨이브렛을 스케일링하는 것이다. 그리고  $g[n]$ 과  $h[n]$ 이 직교(orthogonal) 기저를 형성하도록 억제 조건을 준 모 웨이브렛이라면 그림 2와 같은 다단계 필터뱅크의 출력은 유일한(unique) 특성을 나타낸다.

### 3. 웨이브렛 변환을 바탕으로 한 신경회로망을 이용한 전력용 변압기 보호 계전기법

본 논문에서는 Daubechies 웨이브렛 변환을 이용하여 근사정보와 상세정보를 추출하고, 근사정보는 비율차동요소를 구하는데 이용하며, 상세정보는 신경회로망의 입력패턴으로 활용하여 과여자 상태나 여자돌입상태에 따른 계전기의 오동작을 방지하는데 이용된다. 이와 같은 과정을 블록도로 나타내면 그림 3과 같다.

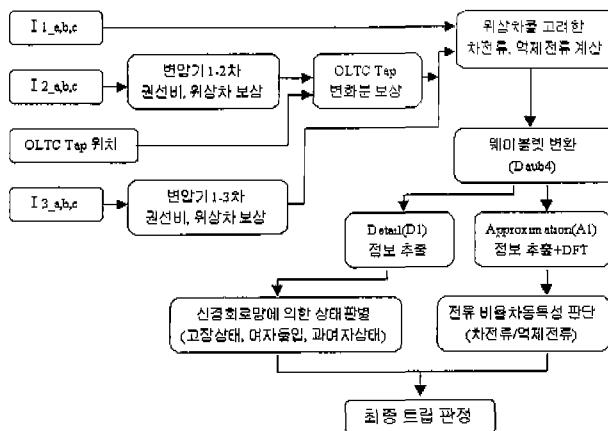


그림 3. 제안된 변압기 보호계전기법의 전체적인 구성도

Fig. 3. The entire construction diagram of the proposed protective relaying scheme for transformer.

알고리즘의 수행과정은 그림3에서 알 수 있듯이 먼저 각 단자 CT를 통해 입력된 2차측 전류로부터 변압기 1-2차, 1-3차간의 권선비 및 위상차를 보정하고 아울러 OLTC(On Load Tap Changer)의 탭(Tap) 변화분을 보상한다. 그리고 1-2차, 1-3차 각 상간의 차전류와 역전류를 구하여 웨이브렛 변환을 통해 상세정보와 근사정보를 분석한다. 마지막으로 근사정보는 비율차동 계전요소의 차전류와 역전류의 비율을 구하는데 이용하고, 상세정보는 신경회로망의 입력패턴으로 입력하여 변압기의 과여자 상태 및 여자돌입 상태를 판단하게 된다.

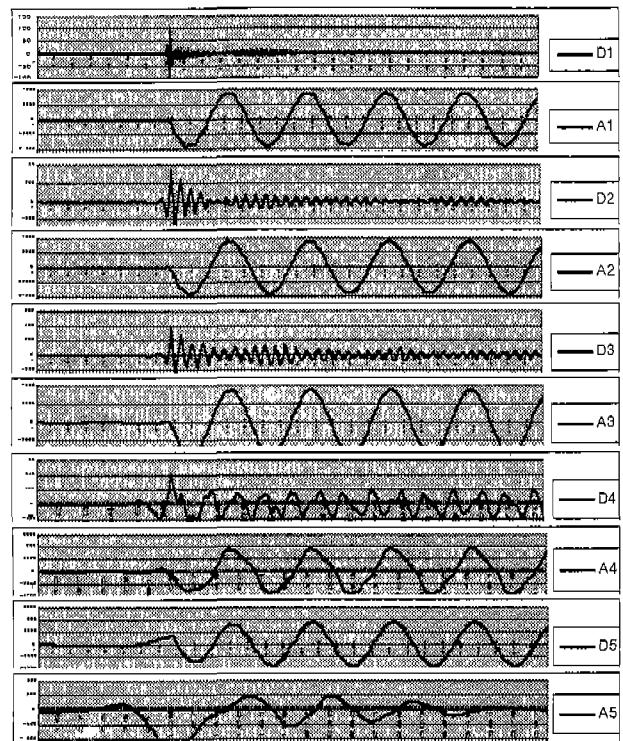
#### 3.1 웨이브렛 변환을 이용한 변압기의 상태 분석

모 웨이브렛의 종류에는 Haar, Daubechies, Coiflets, Biothogonal, Mexican Hat, Meyer, symlets 웨이브렛 등 여러 종류가 있으며 각 웨이브렛은 길이와 특성에 따라 여러 종류로 분류된다. 본 연구에서는 과도파형의 특징을 정확히 추출하기 위하여 Daubechies(db1~db6), Coiflets(coiflet1~coiflet5), Biothogonal( bior3.1 ), symlets( sym5 )를 적용한 결과, Daubechies(db4)의 상세(Detail) 성분이 가장 현저한 변화를 보였다. 즉 Daubechies 웨이브렛의 상세 성분 값들이 가장 급격한 변화를 보였으며 국부적으로 집중화되어 나타났다.[8]

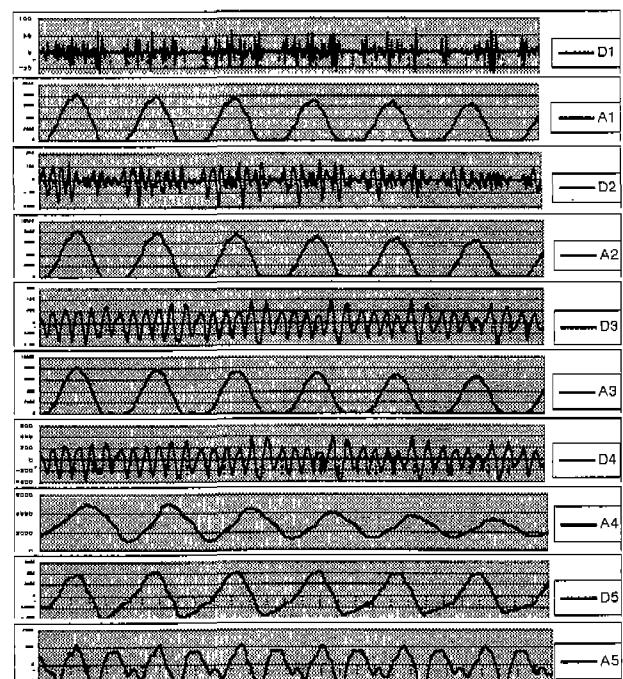
이에 본 논문에서는 Daubechies(db4) 모 웨이브렛을 이용하여 변압기의 이상상태에 대한 전류파형을 분석하였으며

그림 4는 각 상태에 따른 분석결과를 나타낸 것이다. 여기서, 사용된 필터계수는 다음과 같다.[9]

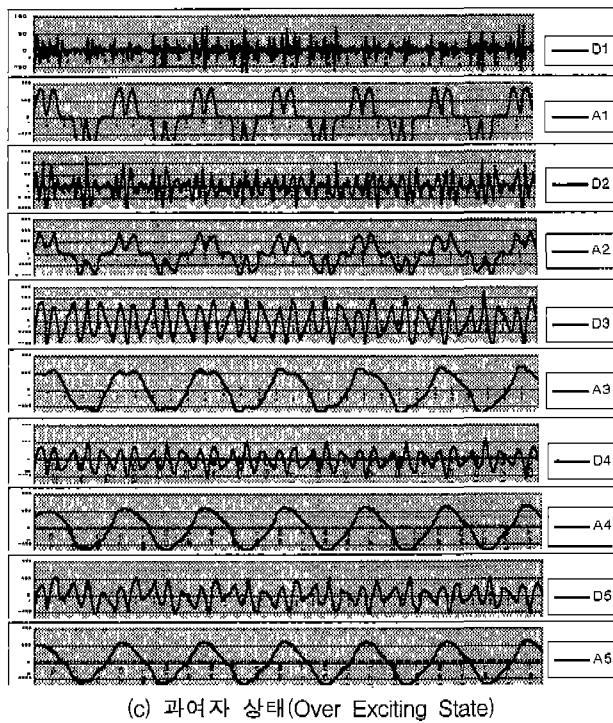
$$\begin{aligned} \{ h_0 &= 0.230377813309, h_1 = 0.714846570553, \\ h_2 &= 0.630880767930, h_3 = -0.02798376941, \\ h_4 &= -0.18703481171, h_5 = 0.030841381836, \\ h_6 &= 0.032883011667, h_7 = -0.01059740178 \} \end{aligned}$$



(a) 내부고장 상태 (Internal Fault State)



(b) 여자돌입 상태 (Magnetizing Inrush State)



(c) 과여자 상태(Over Exciting State)

그림 4. 변압기의 상태에 따른 웨이브렛 변환 결과

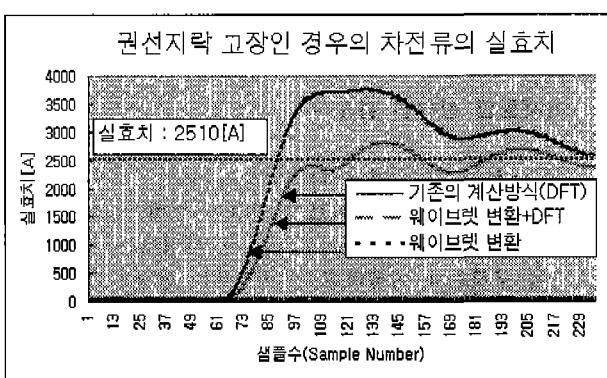
Fig. 4. Results of DWT according to state of transformer.

그림 4의 (a), (b), (c)에서 알 수 있듯이 변압기의 고장, 여자돌입 및 과여자 상태에서의 차전류를 바탕으로 daub4 (db4)의 모 웨이브렛 변환을 통해 레벨5까지의 상세정보와 근사정보를 분석한 결과 변압기의 상태에 따라 상세정보1에서 웨이브렛 변환계수들의 분포가 다름을 나타내고 있다.

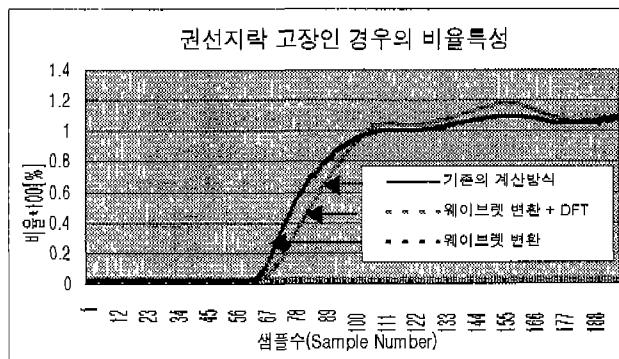
### 3.2 웨이브렛 변환을 이용한 비율차동특성

변압기 1차측과 2차측의 차전류와 역제전류의 웨이브렛 변환을 통해 얻은 상세정보와 근사정보 중에서 근사정보만을 이용하여 비율차동특성을 계산한다.

그림 5의 (a)는 변압기가 내부 고장상태인 경우 차전류의 웨이브렛 변환결과를 나타낸 것이고, (b)에서는 비율차동특성을 나타낸 것이다.



(a) 차전류의 웨이브렛 변환



(b) 웨이브렛 변환된 비율차동특성

그림 5. 내부 고장인 경우의 비율 차동특성

Fig. 5. The ratio of wavelet transformed differential current.

그림 5에서 기존의 방식은 DFT만을 이용하여 차전류와 비율차동 특성을 계산한 것이다. 그림5의 (a)에서 알 수 있듯이 웨이브렛 변환과 DFT를 혼합한 방법과 기존의 방식인 DFT를 이용해 차전류의 실효치를 구한 결과는 동일함을 알 수 있다. 그리고 웨이브렛 변환을 이용해 얻어진 실효치는 기존의 방법에 비해 고장직후의 과도현상에 조금 더 큰 영향을 받고 있음을 알 수 있다. 반면 비율차동 특성에 있어서는 기존의 방법과 웨이블렛변환을 이용한 방법이 유사한 결과를 나타내었다.

### 3.3 비율차동 계전기의 오동작 방지를 위한 신경회로망의 설계

앞 절에서는 웨이브렛 변환을 이용해서 얻은 근사정보에 의해 변압기의 비율차동특성을 추출하였다. 그러나 비율차동특성 요소만으로는 변압기의 과여자 및 여자돌입 상태에 따른 보호계전기의 오동작을 방지할 수 없다.

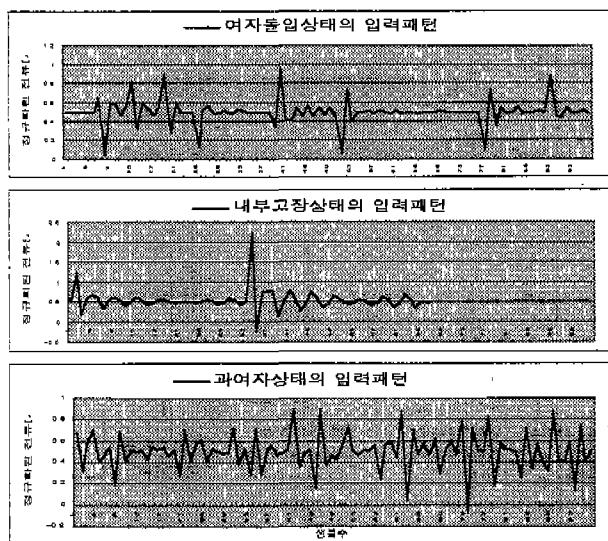


그림 6. 변압기의 상태에 따른 신경회로망의 입력패턴

Fig. 6. Input pattern of Neural Networks according to the state of transformer.

이를 위해 본 논문에서는 상세정보를 이용하고, 신경회로망의 패턴인식을 통해 보호계전기의 오동작을 방지하도록 하였다.

여기서 이용한 신경회로망은 입력층(96), 중간층(50), 출력층(3)으로 이루어진 3층 퍼셉트론(96-50-3)으로 구성되어져 있으며, 활성함수는 시그모이드 함수를 이용하였다. 가 사용되었다. 그리고 학습 알고리즘은 역전파 알고리즘을 사용하였으며, 시뮬레이션을 통해 가장 적절한 학습률  $\eta=0.5$ 와, 관성항  $\alpha=0.4$ 을 결정하였다.

그림 6은 샘플수에 대한 차전류의 웨이브렛 변환을 통해 얻은 상세정보의 정규화(normalization)된 데이터를 나타낸 것이다. 그리고 그러한 데이터가 완전히 학습되었음을 확인하기 위해서 테스트한 결과를 그림 7에서 나타내었다.

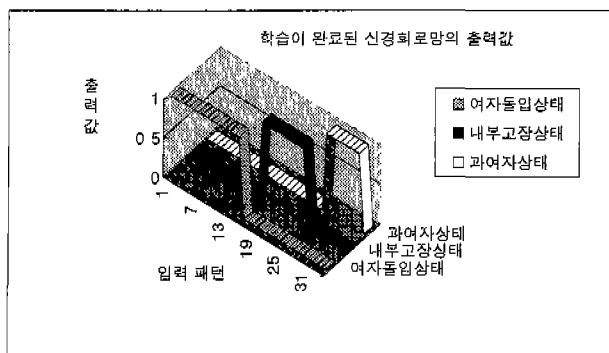


그림 7. 학습된 신경회로망의 출력

Fig. 7. The output of trained Neural Networks.

그림 7에서 알 수 있듯이 신경회로망의 출력은 여자돌입상태패턴(1-0-0), 내부 고장상태패턴(0-1-0), 과여자 상태패턴(0-0-1)으로 완전히 학습되었음을 알 수 있다.

한편 주기당 샘플수는 64로 샘플링 주파수는 3840Hz이다.

#### 4. 사례적용 및 결과 고찰

본 논문에서는 그림 8과 같은 모델전력계통을 구성하고, EMTP를 이용하여 변압기의 이상상태를 모의하였다.

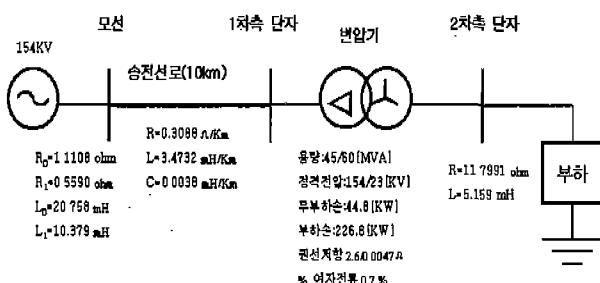


그림 8. 모델 전력계통도

Fig. 8. Power System Model.

그리고 여자돌입 상태 및 내부고장 등을 모의하여 얻은 데이터를 이용하여 제안된 변압기 보호계전 알고리즘의 효용성을 입증하였다.

여기서 변압기는 3상 2권선(45/60MVA, 154kV/22.9kV,  $\Delta$ -Y 결선) 전력용 변압기의 데이터, 송전선로는 ACSR 데이터를 이용하였다. 그리고 변압기의 내부고장을 모의하기 위해서는 EMTP의 보조 프로그램인 BCTRAN에서 출력되는 임피던스 행렬을 이용하였고,[10] 여자돌입 및 과여자 상태를 모의하기 위해서는 히스테리시스 곡선에 의한 가포화변압기 모델을 이용하였다.[11]

표 1은 EMTP를 이용하여 변압기를 시뮬레이션한 조건을 나타낸 것이다.

표 1. EMTP 시뮬레이션 조건

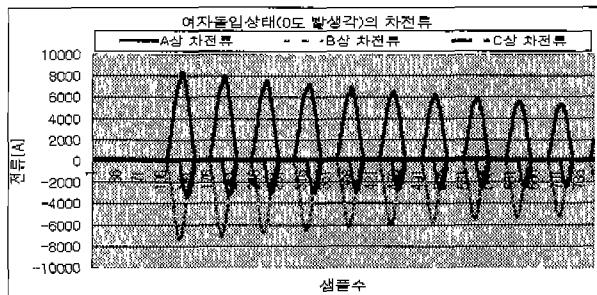
Table 1. Conditions of EMTP simulation.

모의 상태	학습 조건	시험 조건
과전압	125% 전압	135% 전압
여자돌입	0 도에서 발생 90도에서 발생	30도에서 발생
내부 고장	A상: 권선지락(70:30, 0도) 권선지락(70:30, 90도)	권선지락(70:30, 30도) 권선지락(80:20, 30도)
	B상: 권선지락(70:30, 0도) 권선지락(70:30, 90도)	권선지락(70:30, 30도) 권선지락(80:20, 30도)
	C상: 권선지락(70:30, 0도) 권선지락(70:30, 90도)	권선지락(70:30, 30도) 권선지락(80:20, 30도)
	ABC: 3상 지락고장	캐패시턴스를 통한 1선지락
	AB상: 권선단락(10:15:75)	권선단락(10:15:75)
	BC상: 권선단락(10:15:75)	권선단락(10:15:75)
CA상	CA상: 권선단락(10:15:75)	

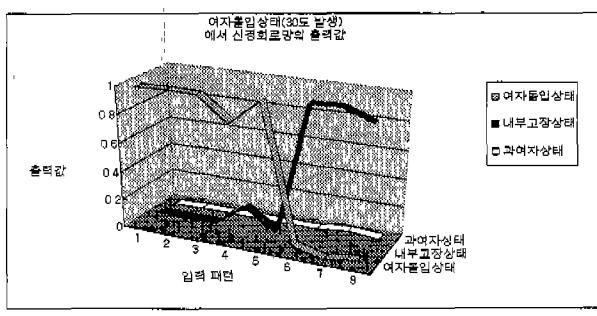
모델 전력계통의 학습조건은 과전압(125%)상태, 여자돌입(전원 투입 위상각: 0도, 90도)상태, 그리고 내부권선 지락고장(상: A, B, C, 고장 발생 위상각: 0도, 90도), 고장 발생위치(권선비: 70:30)로 나누었다. 그리고 시험조건은 과전압(135%)상태, 여자돌입상태, 내부권선 지락고장(상:A,B,C, 고장 발생 위상각: 30도, 발생위치:(권선비: 70:30, 20:80), 그리고 내부권선 단락고장(선간:AB, BC, CA 고장 발생 위상각: 30도, 발생위치:(권선비: 10:15:75) 등으로 나누어 시뮬레이션하였다.

#### 4.1 여자돌입 상태인 경우

본 연구에서는 그림3에 나타내었듯이 우선, 각상의 차전류와 억제전류를 구하여 웨이브렛 변환을 통해 상세 정보와 근사정보로 분석한다. 그리고 각각의 근사정보는 비율차동계전요소를 구하는데 이용하고, 상세정보는 신경회로망의 입력패턴으로 입력하여 변압기의 여자돌입 상태에서 비율차동계전기의 오동작 방지를 위해 이용된다. 그림9의 (a)는 변압기가 여자돌입상태인 경우의 차전류를 나타낸 것이고, 그림9의 (b)는 신경회로망의 출력패턴을 나타낸 것이다.



(a) 차전류



(b) 신경회로망의 출력값

그림 9. 변압기의 여자돌입상태인 경우

Fig. 9. Differential Currents and Neural Network Output Pattern in magnetizing inrush state of transformer

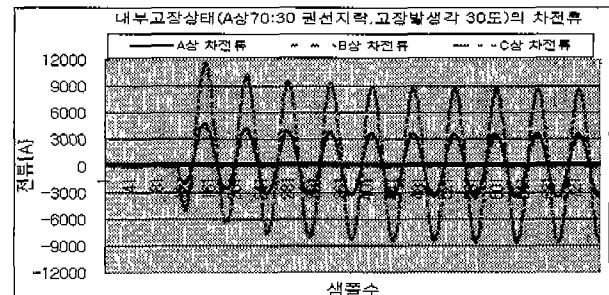
그림9의 (b)에서 알 수 있듯이 여자돌입 상태인 경우 최초 5주기까지는 신경회로망의 출력이 여자돌입 상태(1-0-0) 패턴으로 정확하게 패턴을 인식하다가 6주기부터 내부 고장 상태(0-1-0) 패턴으로 출력하여 패턴 분류가 잘못됨을 알 수 있다. 그 이유는 가장 효율적으로 신경회로망을 학습시키기 위해서 여자돌입 상태패턴이 명확하게 구별되는 5주기까지만 학습을 시켰기 때문이며, 이런 현상은 비율차동 특성을 확인하여 트립 조건이면 고장 발생 후 5주기 내에 고장을 제거하면 그 이후에 나타나는 신경회로망의 출력값은 무의미한 조건이 된다. 따라서 고장 후 1~5주기 내에 명확히 고장을 판단할 수 있음을 알 수 있다.

#### 4.2 변압기의 내부권선(A상 70:30)에서 권선지락 고장이 발생한 경우

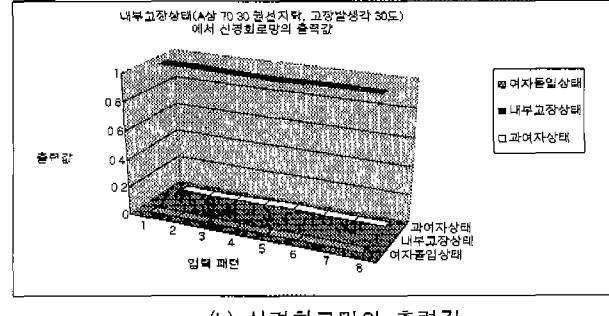
여자돌입 상태와 마찬가지로 그림10의 (a)는 변압기의 내부 권선(A상 70:30) 고장으로 인해 발생하는 차전류를 나타낸 것이다며, 그림10의 (b)는 신경회로망의 출력패턴을 나타낸 것이다.

그림10의 (b)에서 알 수 있듯이 권선지락 고장상태에서 신경회로망의 출력이 고장상태(0-1-0) 패턴이므로 정확하게 패턴이 인식됨을 알 수 있다.

그리고 구성된 신경회로망이 변압기의 내부 권선의 고장 위치를 달리함으로써 전혀 학습이 이루어지지 않은 사고의 형태에 어떤 출력패턴을 생성하는지를 알아보기 위해 내부 권선에서 발생한 지락사고(A상 20:80)에 대해 살펴보았다.



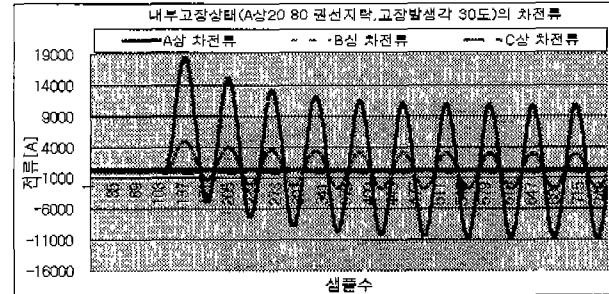
(a) 차전류



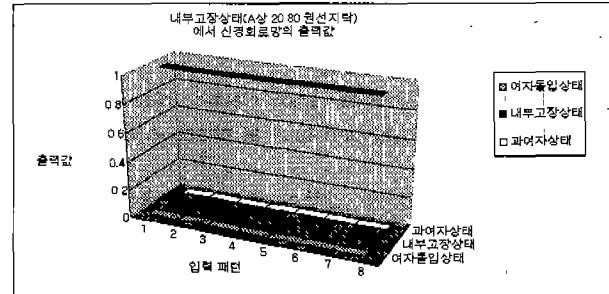
(b) 신경회로망의 출력값

그림 10. 권선지락(A상70:30) 고장의 경우 차전류와 신경회로망 출력 패턴

Fig. 10. Differential Currents and Neural Network Output Pattern in turn to earth fault at phase A(70:30).



(a) 차전류



(b) 신경회로망의 출력값

그림 11. 권선지락(A상20:80) 고장의 경우 차전류와 신경회로망 출력 패턴

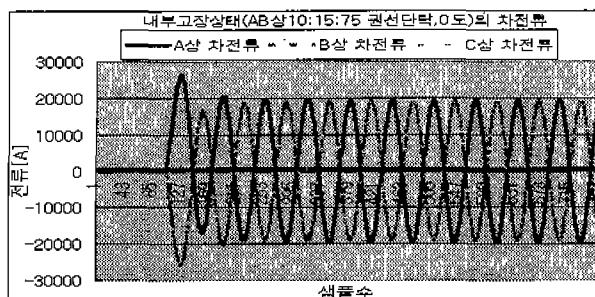
Fig. 11. Differential Currents and Neural Network Output Pattern in turn to earth fault at phase A(20:80)

그림11의 (a)는 변압기의 차전류를 나타내고 있으며, 그림11의 (b)는 구성된 신경회로망의 출력패턴을 나타낸 것이다.

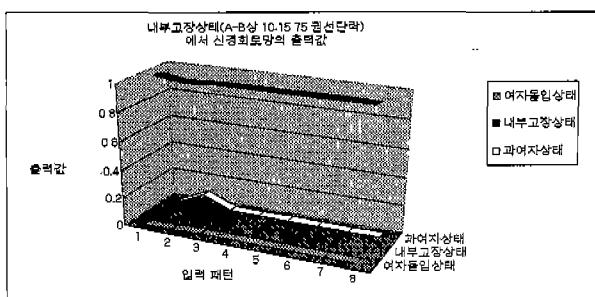
그림11의 (b)에서 알 수 있듯이 변압기의 내부권선(A상 20:80) 지락사고인 경우에도 신경회로망의 출력이 고장상태(0-1-0) 패턴이므로 구성된 신경회로망은 내부 권선의 고장 위치에 영향을 받지 않고 내부고장임을 정확하게 판별함을 알 수 있다.

#### 4.3 변압기의 내부권선(AB상 10:15:75)에서 권선단락 고장이 발생한 경우

학습된 패턴이 권선지락 고장과는 다른 권선단락 고장(AB상 10:15:75)이 발생한 경우에는 신경회로망이 어떤 출력패턴을 생성하는지를 알아보았다. 마찬가지로 그림12의 (a)는 차전류를, (b)는 신경회로망의 출력패턴을 나타내고 있다.



(a) 차전류



(b) 신경회로망의 출력값

그림12. 권선단락(AB상 10:15:75) 고장인 경우의 차전류와 신경회로망 출력 패턴

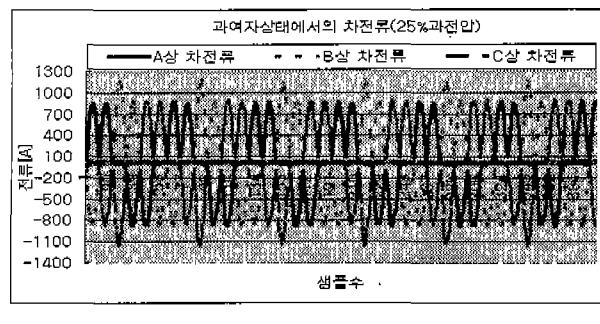
Fig. 12. Differential Currents and Neural Network Output Pattern in turn to turn fault at phase A-B(10:15:75).

그림12의 (b)에서 알 수 있듯이 변압기의 내부권선(AB상 10:15:75) 단락사고인 경우에도 신경회로망의 출력이 고장상태(0-1-0) 패턴을 나타내고 있음을 알 수 있으며, 구성된 신경회로망은 내부 권선의 지락사고나 단락사고에 관계없이 내부고장임을 정확하게 판별하고 있음을 알 수 있다.

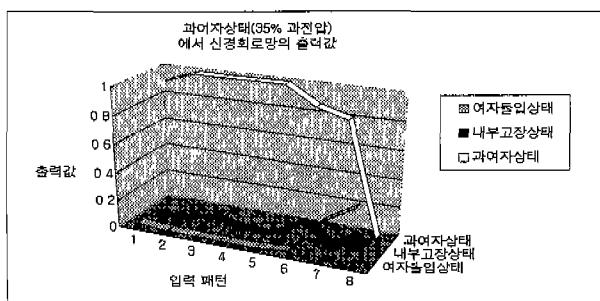
#### 4.4 변압기가 과여자상태인 경우

마지막으로 공급전압을 135%로 상승했을 때의 과전압상

태에서 신경회로망이 어떤 출력패턴을 생성하는지를 알아보았다. 그림13의 (a)는 변압기의 과여자상태에서의 차전류를 나타낸 것이며, (b)는 신경회로망의 출력패턴을 나타내고 있다.



(a) 차전류



(b) 신경회로망의 출력값

그림 13. 과여자상태인 경우 차전류와 신경회로망 출력 패턴

Fig. 13. Differential Currents and Neural Network Output Pattern in Over-excitation state.

그림13의 (b)에서 알 수 있듯이 변압기의 과여자상태인 경우에는 최초 6주기까지 신경회로망의 출력이 과여자 상태(0-0-1) 패턴이므로 정확하게 패턴을 인식하다가 7주기부터 패턴 분류가 불명확함을 알 수 있다. 이것은 여자돌입상태와 마찬가지로 가장 효율적으로 신경회로망을 학습시키기 위해서 초기 5주기 패턴만 학습을 시켰기 때문이며, 또한 이런 현상은 비율차동 특성을 계산한 후 트립 조건이면 5주기 내에 고장을 제거하기 위한 트립신호가 발생되기 때문에 그 이후부터의 신호에 대해서는 고장판단과는 무관함을 알 수 있다.

#### 4.5 차전류에 제2고조파 성분이 다량 함유된 고장이 발생한 경우

그림14의 (a)는 변압기의 외부단자 A상에서 캐패시턴스를 통한 고장이 발생하도록 함으로써 고장발생 후 변압기의 차전류에 고조파성분이 많이 포함되도록 한 경우 변압기의 차전류 과형이다. 그림14의 (b)는 그림14의 (a)와 같은 전류 과형을 나타내는 고장이 발생한 경우 변압기의 차전류에 포

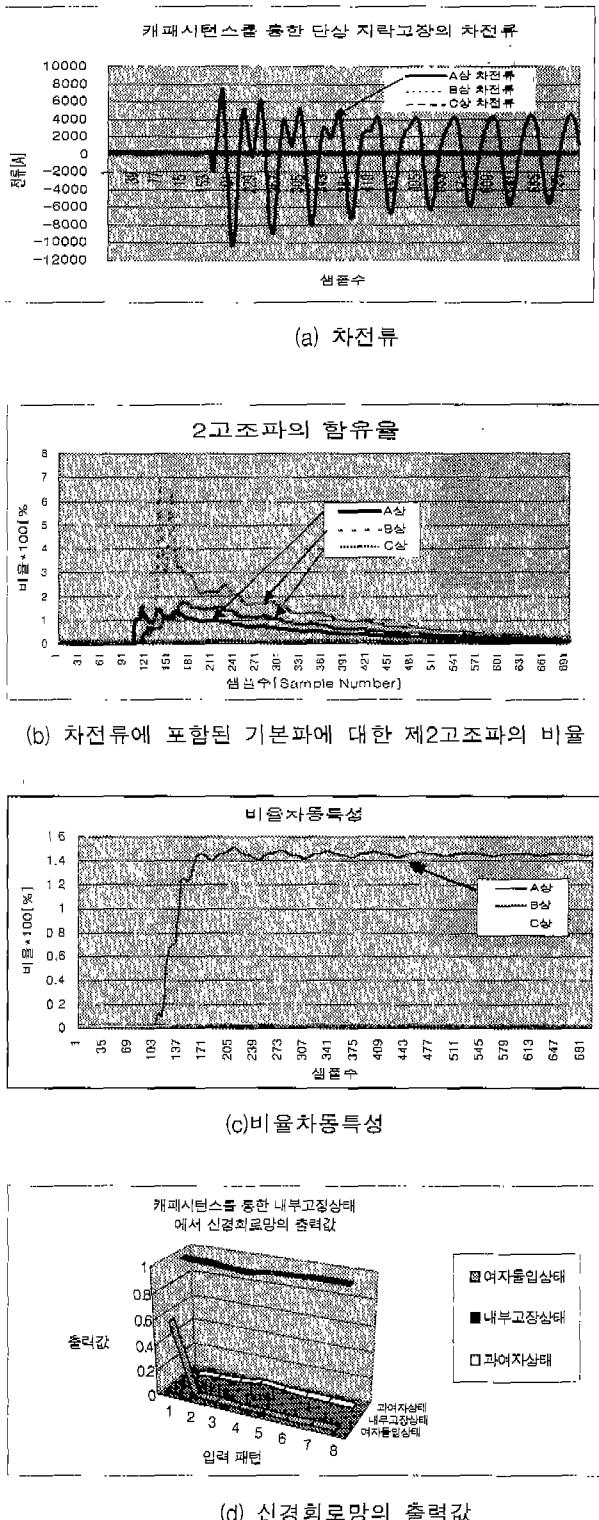


그림 14. 캐패시턴스를 통한 단상 지락고장이 발생한 경우의 차전류, 제2고조파의 비율, 비율차동특성 및 신경회로망 출력 패턴

Fig. 14. Differential Currents, Ratio of fundamental and 2nd harmonic, Percentage differential characteristic and Neural Network Output Pattern during single phase fault through capacitance.

합된 기본파 및 제2고조파 성분을 추출하여 기본파 성분에 대한 제2고조파 성분의 비율을 나타낸 것으로 고장발생 직후 A, B, C상의 차전류에는 제2고조파 성분의 비율이 매우 높게 나타내고 있음을 알 수 있다.

한편, 기존의 비율차동 계전기법은 그림14 (b)의 비율차동 특성에 의해 변압기를 차단할 조건임을 판단하고, 그림14 (c)에 의해 제2고조파의 함유량을 통해 보통 40%이상이면 여자돌입상태임을 판단하여 비율차동계전기의 동작제요소로 이용한다. 반면에 40%이하이면 변압기의 내부고장임을 판단하여 동작요소로 이용한다. 이와 같이 캐패시턴스를 통해 변압기의 내부고장이 발생함으로써 고장발생 후 약 5주기 경과할 때까지 기존의 비율차동기법으로는 동작할 수 없음을 알 수 있다. 따라서 그림14의 (d)에서 나타내었듯이 본 논문에서 제시하고 있는 방법을 통해 시험해 본 결과 고장 후 최소 1주기에서 2주기면 명확히 변압기의 내부고장상태임을 판단할 수 있음을 알 수 있다.

## 5. 결론

본 논문에서는 시간 영역과 주파수 영역에서 과도파형의 분석에 적합한 웨이브렛 변환을 통해 얻은 시작적인 정보를 신경회로망으로 판단하게 함으로서 고장 후 1~5주기 내에 보다 정확하게 변압기의 고장상태를 파악하는 새로운 고장 판별 알고리즘을 제시하였다.

변압기의 정상상태와 이상상태를 판단하기 위해 우선, Daubechies 웨이브렛 변환에 의한 근사정보를 추출하여 차전류와 억제전류의 비율을 계산하였으며, 다음은 웨이브렛 변환을 통해 얻은 상세정보를 신경회로망의 입력패턴으로 활용하여 과여자 상태나 여자돌입 상태를 판별하였다. 따라서 변압기에서 고장이 발생한 경우에는 트립신호를 발생하고, 여자돌입이나 과여자 상태인 경우에는 계전기의 동작을 억제한다. 아울러 제시된 알고리즘은 고조파 성분이 다량 함유된 고장상태에서도 정확히 고장을 판별함을 알 수 있었다.

제안된 변압기 보호계전 알고리즘은 전자파도해석프로그램을 이용하여 시뮬레이션된 전력용 변압기의 여자돌입 상태, 내부고장 상태 및 과여자 상태에 따른 데이터를 이용하여 그 신뢰성을 확인한 결과 모두 정확하게 패턴이 인식됨을 알 수 있었다.

앞으로 좀더 다양한 변압기의 이상상태에 따른 시뮬레이션을 통해 그 신뢰성과 적용가능성에 대해서 계속적인 연구가 필요할 것으로 사료된다.

## 참고 문헌

- [1] Arun G.Phadke, James S. Thorp, "Computer relaying for power systems", Research Studies Press LTD., pp.43-47, pp.166-176, 1988.
- [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] L.G.Perez, A.J.Flechsig, J.L.Meador, Z.Obradovic, "Training an artificial neural network to discriminate between magnetizing inrush and internal faults", IEEE trans. on Power Delivery, Vol.9, No.1, pp.434-441, 1994.
- [4] A. Wiszniewski, B.Kasztenny, "A multi-criteria differential transformer relay based on fuzzy logic", IEEE trans. on Power Delivery, Vol.10, No.4, pp. 1786-1792, 1995.
- [5] Moises Gomez-Morante, Denise W.Nicolette "A wavelet-based differential transformer protection", IEEE trans. on Power Delivery, Vol.14, No.4, pp. 1351-1355, 1999.
- [6] Surya Santoso, "Power quality disturbance waveform recognition using wavelet-based neural classifier-part 1: theoretical foundation", IEEE trans. on Power Delivery, Vol.15, No.1, pp.222-228, 2000.
- [7] 권기백, 윤석무, 신명철, "웨이브렛 변환을 바탕으로 한 신경회로망을 이용한 전력용 변압기보호계 전기법", 대한전기학회 2001년 하계학술대회 논문집, pp.292~232, 2001년 7월.
- [8] Ingrid Daubechies, "Ten Lectures On Wavelets", Rutgers University and AT&T Bell Lab., pp.194-196, 1992.
- [9] Patrick Bastard, Pierre Bertrand, Michel Meunier, "A transformer model for winding fault studies", IEEE trans. on Power Delivery, Vol. 9, No. 2, pp.690-699, April 1994.
- [10] ATP Rule Book, LEUVEN EMTP CENTER, July 1987.



서희식 (徐熙錫)

1961년 6월 2일생. 1987년 성균관대 전기공학과 졸업. 1997년 동 대학원 전기공학과 졸업(공박). 1989~1990년 금성산전연구소 연구원. 1995년~현재 두원공과대학 자동화시스템과 부교수.

Tel : 031-670-7265,

Fax : 031-670-7269

E-mail : shs7165@doowon.ac.kr



윤석무 (尹錫武)

1954년 8월 6일생. 1981년 성균관대 전기공학과 졸업. 1993년 동 대학원 전기공학과 졸업(공박). 1983~1990년 해군사관학교 전기공학과 조교수. 1990~현재 대덕대학 부교수.

Tel : 042-866-0371,

Fax : 042-866-0368

E-mail : smyoon@mail.ddc.ac.kr



신명철 (申明澈)

1947년 4월 3일생. 1970년 성균관대 전기공학과 졸업. 1978년 연세대 대학원 전기공학과 졸업(공박). 1975~1978년 충북대 전기공학과 조교수. 1982~1983년 미국 코넬대 전기공학과 교환교수. 2000 ~2001년 미국 펜실바니아 주립대 전기공학과 교환교수. 1978~현재 성균관대 전기전자 및 컴퓨터 공학부 교수.

Tel : 031-2907103, Fax : 031-290-7103

E-mail : mcshin@yurim.skku.ac.kr

## 저자 소개



권기백 (權奇柏)

1967년 6월 6일생. 1991년 성균관대 전기공학과 졸업. 1997년 동 대학원 전기공학과 박사수료. 1992~1999년 엘지산전연구소 주임연구원. 1999~2001년 (주) 피엔씨 테크 선임연구원. 2001~현재 대전 대덕대학 전기전자계열 전임강사.

Tel : 042-866-0327, Fax : 042-866-0368

E-mail : gbkweon@mail.ddc.ac.kr