

이산웨이블렛 변환과 신경망을 이용한 변압기 열화상태 진단에 관한 연구

A Study on Diagnosis of Transformers Aging State Using Wavelet Transform and Neural Network

박재준^{*}, 송영철^{*}, 전병훈^{*}

(Jae-Jun Park^{*}, Young-Chul Song^{*}, Byung-Hoon Jeon^{*})

Abstract

In this papers, we proposed the new method in order to diagnosis aging state of transformers. For wavelet transform, Daubechies filter is used, we can obtain wavelet coefficients which is used to extract feature of statistical parameters (maximum value, average value, dispersion, skewness, kurtosis) about each acoustic emission signal . Also, these coefficients are used to identify normal and fault signal of internal partial discharge in transformer. As Improved method for classification use neural network. Extracted statistical parameters are input into an back-propagation neural network .The number of neurons of hidden layer are obtained through Result of Cross-Validation.

The network, after training, can decide whether the test signal is early aging state, last aging state or normal state. In quantity analysis, capability of proposed method is superior to compared that of classical method.

Key Words : Acoustic Emission Signals, Discrete Wavelet Transform, Wavelet coefficient , Feature Extraction, Multi-Decomposition, Neural-Network

1. 서론

전력설비에 대한 열화상태의 계측과 진단은 전체 시스템의 신뢰성을 높일 수 있는 하나의 방법이 될 것이다. 전력분배 시스템에서 가장 중요한 전력기기 중 하나로서 변압기가 치명적인 고장, 사고를 초래하면 그에 대한 엄청난 피해와 보상이 뒷 따르게 될 것이다.

이런 사고를 미연에 방지하여 엄청난 정전사고를 예방하기 위해서는 변압기의 결함탐지 및 변압기 열

화의 원인이 될 수 있는 부분에서 발생 된 신호를 계측하여 중요한 특징을 추출 함으로서 변압기 열화상태를 진단할 수 있는 [1,2] 많은 연구가 절실히 필요한 것이다. 이런 변압기의 열화상태를 진단하기 위해서 종래에는 신호 해석 및 분석을 통한 진단 방법으로서 부분방전 시 발생된 방전 전하량 과 음향 방출 펄스에 대한 새로운 정보로서 인가전압 위상각의 정보를 도입하였다. 절연열화과정 및 절연파괴와의 관계, 즉 전극형상에 의한 사이클 평균 ϕ -q분포를 도입하여 보이드 결합 추정 및 위상각 특성을 고려한 절연재료의 수명예측 등 인가전압 위상각에 따른 $\phi - q - n$ 분포 패턴을 이용하여 수 많은 연구가 진행되었고 현재 실용화를 하고 있는 실정이다. [3~6]

또한, 신호해석을 위한 디지털신호처리 기법으로서는 주파수-크기 분석법인 FFT(Fast Fourier Transform) 스펙트럼 해석을 주로 이용하였지만, 이

* : 충부대학교 정보공학부
(충남 금산군 추부면 마전리 산 2-25)
Phone:041-750-6751
H.P:011-207-2381
E-mail:jjpark@joongbu.ac.kr
** : 광운대학교 전기공학과
2000년 9월14일 접수 2000년12월18일 심사완료

기법으로서는 주파수-크기만 알기 위해 계측된 신호가 몇 KHz 인지 또는 몇 MHz 인지 알고자 할 때는 편리하지만 시간의 흐름에 따른 분석으로서 적합하지 못한 것이다.

최근에서는 음향방출신호(Acoustic Emission Signals) 가지고 시간의 흐름에 따른 주파수 분석기법으로 탁월한 성능을 가진 웨이블렛 변환기법(wavelet Transform)을 적용하여 연구되어지고 있다. [1,2,7,8,9] 결합신호를 통한 진단분석기법으로서는 웨이블렛-신경망 [2,9,10,11] 그리고 웨이블렛-퍼지뉴로 [12], 웨이블렛-뉴로퍼지 [13] 등과 같은 기법을 이용한 연구가 진행 중에 있다.

본 논문에서는 변압기의 치명적인 사고 및 정전사태를 예방하는 차원에서 변압기의 열화상태를 진단하기 위해서 불평등 전계를 유발 시킬 수 있는 침대 평판의 전극을 구성한 후 15[KV_{RMS}]을 일정하게 파괴 시까지 인가 하였다.

음향방출신호를 열화초기로부터 열화말기인 파괴 직전까지 신호를 계측하여 임의로 열화상태를 구분(정상상태, 열화초기상태, 열화말기상태)하여 Daubechies' 웨이블렛을 구현하여 3-레벨분해를 통하여 특징을 추출하고 그리고 특징 추출된 자료가 신경 회로망을 이용하여 전력변압기의 현재열화상태를 진단하기 위해서 신경망(Neural Network)입력의 전처리(Preprocessing)과정으로 이용하게 된다. 특징 추출을 위해 3-레벨으로 웨이블렛 변환을 결과를 이용하여 특징을 추출하기 위한 통계적 파라메터인 웨이블렛 계수의 최대값(WCM), 평균값(AVR), 분산(DIS), 왜도(Skewness=SKE), 침쇄도(Kurtosis=KUR)의 정보를 얻을 수가 있다. 교차확인은 신경망의 적절한 구조를 선택하기 위해서 사용하였으며 즉, 하든 총의 최적개수를 얻을 수가 있었고 그리고 출력결과는 열화상태의 판정결과로서 정상신호: 0, 열화초기상태 일 때: 0.5, 열화말기상태 일 때: 1 을 얻게 된다.

2. 실험장치 및 디지털 신호처리 과정

2.1 실험장치

(1) Sensor

센서는 독일 Vallen System 제품으로서 20[KHZ] ~500[KHZ] 밴드 폭을 갖는 40[dB] 전치 증폭기(Pre-amplifier)가 내장된 150[KHZ] 공진주파수를 갖는 Acoustic Emission Sensor를 사용하였다. 센서의 출력 단에서 증폭되어 나온 신호가 후치 증폭기 20[dB]의 걸쳐 A/D 컨버터로 입력되었다. 이 센서는

Magnetic hold를 사용하여 침대 평판 전극이 변압기 오일에 잠기도록 제작된 통의 측면외벽에 부착 하였다.

(2) 전극구성 및 실험방법

전극의 구성은 그림 1에서 보여준 바대로 침대 평판 전극으로 구성하였다. 침 전극은 일본 제품인 10[mm] 광률반경을 갖는 침 전극을 사용하였고, 평판전극은 로고스키전극으로 구성하였으며 1[KV/s]의 일정한 승압속도로 15[KV_{RMS}]까지 승압 후 파괴 시 까지 일정하게 인가하였다. 부분방전이 발생하게 되면 부분방전 시 발생된 전기적인 신호로서 방전 전하량 및 방전전류 등이 발생되고 음과 빛이 발생하게 되는데 전기적인 신호와 음향신호를 동시에 계측하여 Yoshimura씨 등이 보고한 바에 의하면 [14] NAE=1.82Q_{max}인 선형관계가 이루어진다고 보고하였고, 또한 음향방출신호는 그 외도 몇 가지 장점을 가지고 있다.

1. 불투명한 재료와 복잡한 전극배열에 적합하다.
2. 음향방출신호를 검출하기 때문에 전기. 자기적인 간섭을 받지 않는다.

이처럼 한 가지 종류의 신호만을 계측하여 전력설비를 진단한다고 하는 것은 어려움이 많이 있다. 그러나 본 실험방법에서는 방전 전하량과 음향방출 필스진폭과의 비례성이 있기 때문에 음향방출센서를 이용하여 센서에서 계측된 신호를 이용하여 열화상태 진단에 적용하기로 한다.

(3) Data acquisition System

Data Acquisition System은 Digital Oscilloscope을 이용하게 되면 실시간으로 데이터를 컴퓨터로 전송받기 어려운 점이 많기 때문에 본 연구에 적합한 A/D Converter를 선정 하였습니다. Ultraview에서 생산된 12bit A/D board로서 80MHZ/Dual 40MHZ를 처리할 수 있으며, 최대 80MS/S 샘플링을 가지고 있으며 2-Channel로 구성되었으며, 차폐된 동축케이블(Shield coaxial cable)을 통하여 음향센서로부터 신호가 A/D보드로 입력되도록 구성하였습니다. 본 연구에서는 위상각을 고려하지 않은 단일AE 채널만을 이용하여 4Mbyte A/D보드의 버퍼 메모리를 갖는 PCI버스방식을 가지고 있다.

Sampling Rate는 A/D 컨버터의 계측기 면에서 체적의 상태라고 생각되는 8Ms/s을 유지하였으며, 4M byte를 실시간 data를 획득하는데 걸리는 시간은 125[ms]= 0.125[s]이었다. 9분 동안 데이터를 획득하고 1분 동안의 휴지시간을 두고서 절연파괴시 까지 연속적으로 계측을 실시하였다. 4M byte의 정보는 2진 정보로 되어 있으므로 Visual C++ 6.0으로

Interface 프로그램을 작성하여 10진 형식으로 코드 변환을 실시하였다. 동시에 4 M byte의 데이터를 나타낼 수 없으므로 EXCEL창에서 쉽게 나타낼 수 있도록 하기 위해서 64등분하는 프로그램을 작성하여 파일로 분류 선별하였다. 한 file내의 신호 point 수는 16384개의 Point를 가지게 되므로 한 file동안 데이터를 획득하는데 소요되는 시간은 1.95[ms]이었다. 음향방출신호의 한 point 동안의 시간은 0.12[μ s]가 된다.

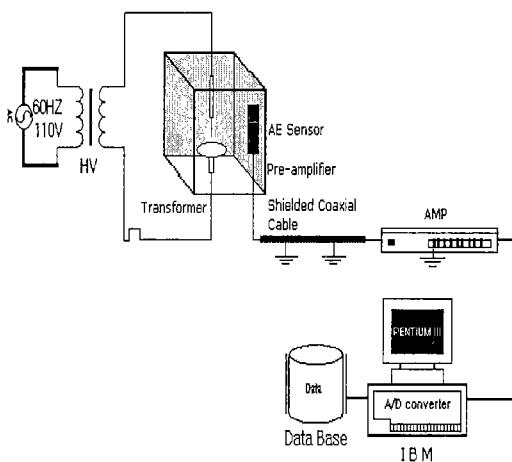


그림1 실험장치 구성

Fig. 1 Data Acquisition system set up

2.2 신경망 입력을 위한 전처리 과정

(Pre-Processing procedure)

(1) 디지털 필터계수 [15,16,17]

이산웨이블렛 변환으로 표1의 Daubechies'필터를 사용하였다.

표 1 Daubechies마더 웨이블렛의 필터계수

Table 1 DaubechiesMother Wavelet Filter Coefficients

DaubechiesMother Wavelet Filter Coefficients	
저주파	.026749f, -.016864f, -.078233f, .266864f, .602949f, .266864f, -.078233f, -.016864f, .026749f
고주파	0.000f, -.045636f, .028772f, .295636f, -.557543f, .295636f, .028772f, -.045636f, 0.00f

(2) 다중해상도 웨이블렛 변환

(multi-resolution Wavelet Transform)

[1,11,15,16,17]

이산 웨이블렛의 확장으로 직교벡터공간에서 웨이블렛 함수를 변화 시킴에 따라서 다양한 크기의 해상도로 신호 $x(t)$ 에 포함되어 있는 성분들을 분석할 수 있게 된다. 이를 위해 다중 해상도 신호 분할 알고리즘이 소개되었으며, 이는 신호성분을 단계별로 더욱 세밀하게 표현하는 이산웨이블렛을 만들어서 적용하는 과정을 거치게 된다. 다시 말해 2ⁿ만큼 확장된식 (1)에서

$$W_\psi f(a,b) = \frac{1}{\sqrt{|a|}} \int f(t) \Psi^*(\frac{t-b}{a}) dt \quad \dots\dots(1)$$

이산 웨이블렛 함수 $\Psi_2^j(t)$ 를 시간 축에 대해 $2^{-j}n$

천이 시키고, 로 정규화

함으로써, 함수를 $\Psi_2^j(t)$ 를 시간 축에 대해 $2^{-j}n$ 천이 시키고, $\sqrt{2^{-j}}$ 로 정규화 함으로써,

$$\sqrt{2^{-j}} \Psi_2^j(t - 2^{-j}n) \quad \dots\dots(2)$$

이산웨이블렛이 구성된다. 다중 해상도 웨이블렛 변환(Multi Resolution Wavelet Transform)은 웨이블렛 함수를 정규 직교기저에 적용함으로써 주어진 함수 특성을 분해하여 나타내는 알고리즘이라 할 수 있다. 웨이블렛은 고주파와 저주파를 단계별로 분리 적용하여 level-1, level-2……level-n로 분해하여간다. 그 역의 과정을 합성 즉, 역 이산웨이블렛(IDWT)이라고 한다. 이산웨이블렛의 과정 및 그 역의 과정을 그림 2에서 나타내고 있다.

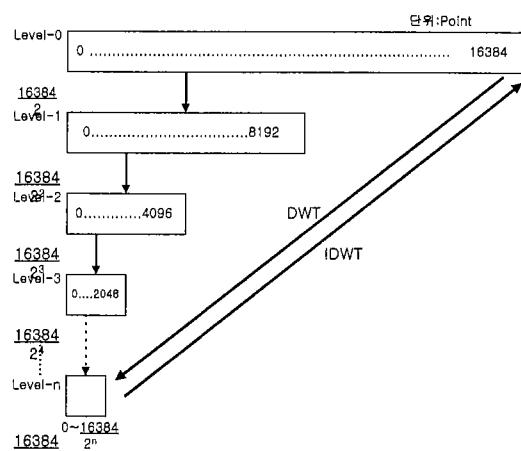


그림 2 본 연구에 적용된 신호의 이산웨이블렛의 분해 및 합성 과정

Fig. 2 Discrete Wavelet Decomposition and Composition Procedure

그림2에서 볼 수 있듯이 고주파성분과 저주파성분이 적절히 분해되고 있음을 볼 수 있으며, 분리된 에너지는 웨이블렛 변환레벨을 증가시킴에 따라 저주파 쪽으로 에너지가 집중 되어가는 과정을 볼 수가 있다. 일반적으로 웨이블렛 변환을 적용했을 때 90[%] 이상의 에너지성분이 저주파 쪽으로 집중된다.

(3) 데이터 처리의 흐름도

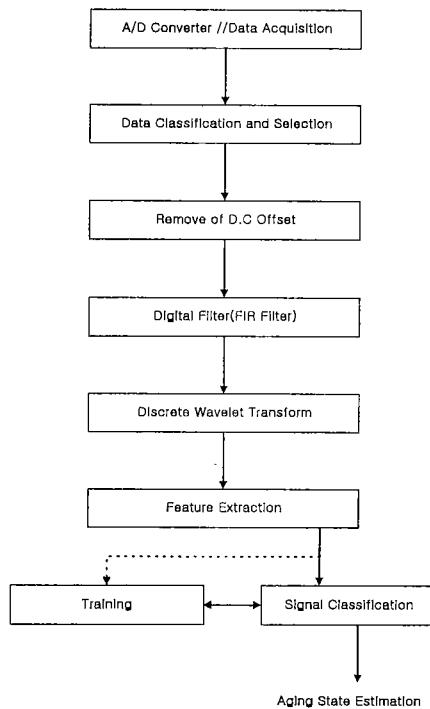


그림 3 자료처리의 흐름도

Fig. 3 Flowchart of Data Treatment

(4) 변압기 열화상태 분류를 위한 신경 회로망 학습과정 [9,11,18,19]

본 논문에서 사용한 신경 회로망은 다층구조로서 하나의 입력층과 하나의 히든층 그리고 또 하나의 출력층으로 구성하였다.

입력층은 5개의 뉴런으로 구성하였고, 히든층과 출력층은 각각 5개와 1개로 구성하였다. 제안된 시스템의 학습방법은 역전파 알고리즘(back-propagation algorithm)을 이용한 교사 학습법(supervised learning)을 사용하였으며, 초기 연결강도는 0과 1사이의 난수를 발생시키는 난수 발생기를 사용하여 지정하였다. 그림4에 3층 역전파 신경망 구조를 나타내었고, 그림5에는 역전파 신경망의 활성화 함수를 나타내었다.

본 논문에서는 변압기내 부분방전 시 발생된 음향 방출신호를 계측하여 정상신호, 열화초기상태신호, 열화말기상태신호를 이산웨이블렛 변환을 이용한 전처리 과정에서 특징을 추출한 5가지 통계적 파라미터를 입력패턴으로 하여 학습시켰다. 교사 학습을 위한 출력 값은 정상신호인 경우 "0", 열화초기상태인 경우 "0.5", 그리고 열화말기상태인 경우 "1"로 설정하였다. 학습에 사용된 데이터는 2가지로 구분하였다. 첫번째 학습에 사용된 데이터는 각각의 열화 상태에 따라 "Good 데이터로 선별된 데이터"를 신경망 학습에 적용하였고, 오차허용범위가 ±0.048175 이하의 값으로 되면 신경망 학습을 종료하였다. 두번째 학습에 사용된 데이터는 "Random하게 선별된 데이터"를 신경망학습에 적용하였고, 오차가 ±0.2 이하의 값으로 되면 신경망 학습을 종료하였다.

패턴인식과 같이 일반적으로 원형(prototype)이 정해져 있는 경우에 오차는 가능한 0에 가깝게 수렴시키는 것이 바람직하다. 그러나, 절연 열화 과정 중의 음향방출 팬스는 변화가 다양하고 일정하게 나오는 것이 아니기 때문에 본 논문의 학습 과정에서는 대소 오차를 허용함으로써 특이한 패턴에 의하여 연결강도가 크게 영향을 받지 않도록 하였으며 오차에 대한 의존성을 줄이면서 전체적인 성능 향상을 모색하였다.

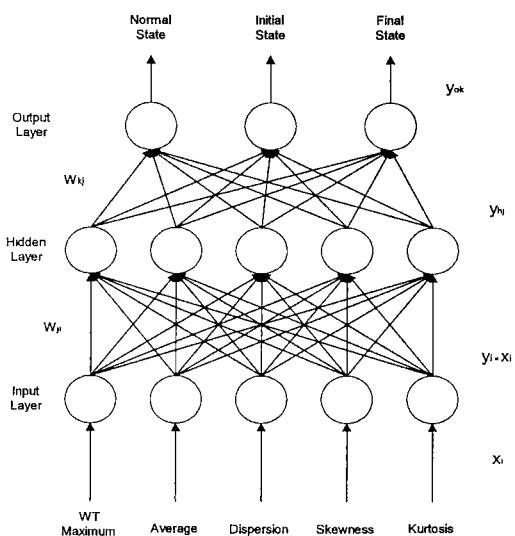


그림 4 3층 역전파 신경망의 구조

Fig. 4 Structure of a three-layer back-propagation neural network

3. 결과 및 검토 고찰

3.1 디지털 필터 [8,9]

디지털 신호처리기법으로 연속적인 노이즈는 입력 신호로부터 예보자 연속 신호를 마이너스 한만큼 노이즈를 줄일 수 있다. 시간 영역에서 작용한 이런 예보 알고리즘이 노이즈의 통계적 특성으로 이용하고 있다. 이 음향방출신호에 FIR(Finite Impulse Response) 디지털 필터를 이용한 결과를 나타내고 있다. 그림5의 경우는 음향방출신호와 함께 시스템 내에서 발생된 신호인 노이즈가 합성된 경우의 신호를 보여주고 있다. 이런 시스템내에서 발생된 노이즈를 렌덤노이즈로 가정하고 FIR 필터 알고리즘을 적용한 결과 그림6과 같이 상당한 정도의 노이즈가 제거된 상태를 볼 수가 있다

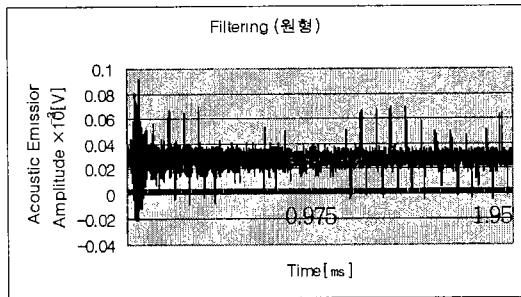


그림 5 음향신호와 시스템 내에서 발생된 노이즈 신호의 합성신호

Fig. 5 Composite signals include Noise signal generate in system

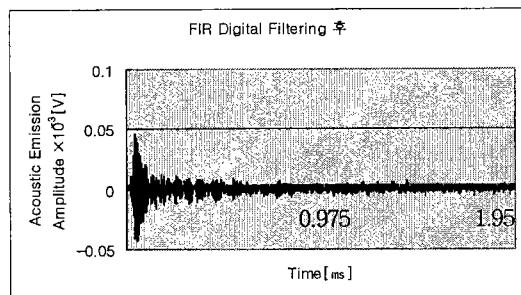


그림 6 FIR 디지털 필터링 적용 후의 노이즈가 제거된 음향신호

Fig. 6 Noise remove signal after FIR digital filter application

3.2 음향방출신호

부분방전 시 발생된 음향방출신호의 전형적인 신호파형을 그림7에서 나타내었다. 신호의 포인터 수는 24576포인트로서 2.825[ms]의 시간동안 측정한

신호이다. 측정된 모든 음향방출 신호의 전반적인 특징은 신호 전반부에서는 급상승하여 급강하 되는 형태를 나타내고 있으며, 부분방전신호 원이 모의 변압기의 중앙에 위치하여 부분방전이 발생하면 음향의 전파에 의하여 다른 벽면에 부딪쳐 일부 반사되어오게 되므로 이는 echo에 의하여 음향펄스의 파가 길어지고 있다고 사료된다.

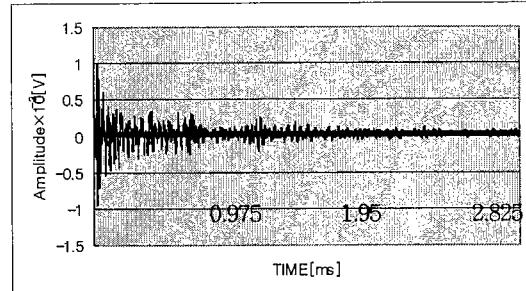


그림 7 실제 계측 된 전형적인 음향방출 신호

Fig. 7 Typical acoustic signal

3.3 변압기 부분방전 시 열화정도에 따른 음향방출신호의 패턴

(1) 열화 초기신호

열화초기 음향방출신호의 대표적인 신호 패턴으로서 그림 8에서 나타내고 있다. 음향방출 열화 초기 신호는 중기 및 말기신호에 비하여 발생 펄스진폭이 크고, 발생신호의 duration time이 상대적으로 길기 때문에 excel상에서 나타내기 쉬운 정도인 16384포인트 만으로 나타내고 있다.

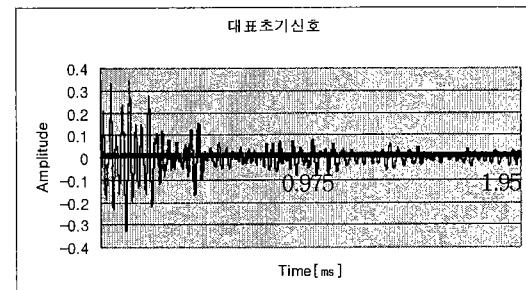


그림 8 변압기 부분방전시 열화초기의 음향방출신호

Fig. 8 Initial aging state signal pattern

음향방출 파형은 지수함수적인 형태이지만, 말기의 음향방출신호보다 좀 더 완만한 지수함수 형태의 신호가 다수의 신호형태로 표현되고 있다. 여기서 열화 초기 대표적인 신호라고 하는 것은 전압인가와 동시에 초기단계에 해당된 전체시간의 10[%]로 정하였

고 그리고 말기상태도 초기상태의 경우처럼 절연파괴 된 상태로부터 이전시간의 10[%]로 정하였다. 대표적인신호의 경우는 하나의 파일에서 추출된 특징이 5가지 통계적인 파라메터(이산웨이블렛의 최대값, 평균값, 분산값, 왜도값, 첨예도값)를 가지므로, 초기상태에 계측된 신호의 파일수가 수천에서 수만 개의 파일이 발생됨으로 각 신호에서 발생된 특정 추출된 값을 전체산술평균한 값이 5가지 파라메터에 가장 근사한 신호를 선택하여 초기상태 및 말기상태 대표신호로 나타내었다.

(2) 열화말기신호

열화말기 음향방출신호패턴으로서 그림9에서 나타내고 있다. 열화의 말기신호는 초기에 비하여 진폭이 낮고, 펄스의 duration time도 극히 짧은 시간동안의 신호로서 단발성의 펄스가 다수의 신호 특징으로 나타나고 있다. 역시 지수함수 적인 펄스의 형태를 이루고 있지만 초기에 비하여 기울기가 더욱 큰 지수함수의 형태를 가진 신호로서 나타나고 있다.

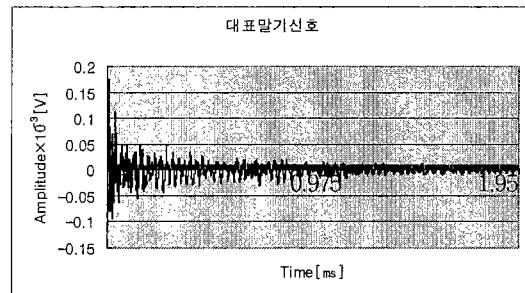


그림 9 변압기 부분방전시 열화말기의 대표적인 음향방출신호

Fig. 9 Final aging state signal pattern

(3) 정상신호

펄스와 펄스 발생된 사이의 시간동안에 계측된 신호로서 정상신호라고 부른다. 그림10에서 나타내었다.

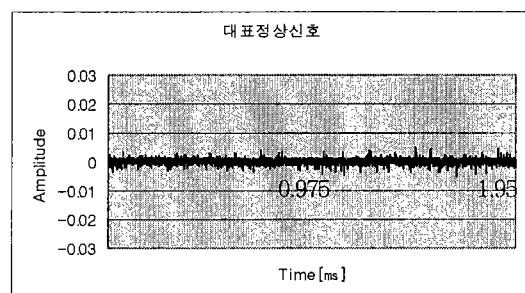


그림 10 정상신호

Fig. 10 Normal state signal pattern

3.4 음향방출신호를 Daubechies' Discrete

Wavelet Transform에의 적용

이산웨이블렛 변환을 그림11~14까지 즉, 레벨 1~ 4까지의 경우를 나타내었다. 신경망의 전처리과정 시 이산웨이블렛을 취한 경우는 레벨-3(스케일4)으로 하였다.

그 이상의 웨이블렛 레벨을 높이게 되면 원형신호의 패턴을 잃게 되므로, 즉 에너지가 새어버리므로서 최적의 이산 웨이블렛 레벨-3으로 하는 것이 바람직하였다. 특정추출 시 하나의 파일에서 나타낸 신호패턴이 16384포인트인데 구성되어있지만, 이산 웨이블렛 변환의 Level-3으로 취하게 되면 2048 포인트의 웨이블렛 계수로서 16384포인트와 유사한 신호패턴을 그대로 유지하게 된다. 2048포인트를

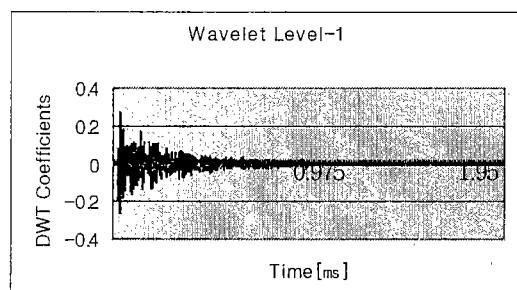


그림 11 DWT의 레벨-1

Fig. 11 DWT of Level-1

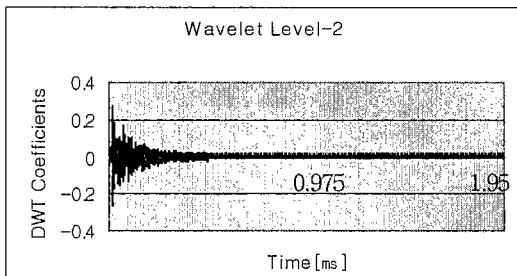


그림 12 DWT의 레벨-2

Fig. 12 DWT of Level-2

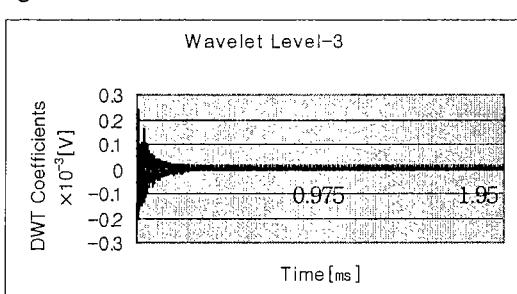


그림 13 DWT의 레벨-3

Fig. 13 DWT of Level-3

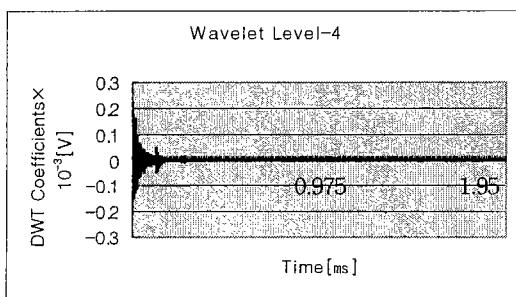


그림 14 DWT의 레벨-4

Fig. 14 DWT of Level-4

Zero Cross의 Positive값을 재배열하여 5가지의 통계파라메터에 적용하였다.

3.5 신경 회로망의 성능 평가 [9,11,18,19]

전처리과정 시 이산웨이블렛 변환 레벨-3으로 적용하여 특징추출을 행하였다. 여기서 레벨-3으로 적용하게 된 이유는, 원 신호들의 에너지 집중도가 그 경우에 제일 높다고 판단했기 때문입니다. 일반적으로 변환레벨을 너무 작거나 또는 크게 하면 에너지 집중도가 떨어지는 결과를 초래하기 때문입니다. 특징추출된 5개의 특징을 신경망의 입력으로 이용되었다. 신경회로망의 구조를 효율 높게 하기위해서 중간층 뉴런인 Hidden Layer의 수를 선택하기 위해서 교차확인기법을 적용한 결과를 표2에서 나타내었다. 표2에서의 Number은 중간층에서 뉴런의 개수를 의미한다.

중간층뉴런의 개수를 5,7,9,18,19,22등으로 변화한 결과, 본 연구에서는 평균에러 값이 뉴런개수가 "5"일 때 최소라는 사실을 확인할 수가 있었다.

(1) Good데이터로 선별된 데이터를 신경망에 적용

신경망의 학습에 참여한 데이터는 정상신호 100개, 초기신호 100개, 말기신호 100개를 선별하여 훈련벡터로 사용하였다.

열화상태 진단을 위해 원하는 출력은 정상상태의 신호인 경우 "0"으로 하였고, 초기상태신호인 경우 "0.5" 그리고 말기상태신호인 경우 "1"로 설정하였으며, 최소허용오차는 0.048175로 하였다.

(2) Random하게 선별된 데이터를 신경망에 적용

신경망의 학습에 참여한 데이터는 정상신호 100개,

표 2 교차확인의 결과

Table 2 The Result of Cross Validation

Number	Neural Network
5	0.051822
7	0.100943
9	0.095288
18	0.057987
19	0.099118
22	0.101507

Learning rate(인식률)는 0.28로, Offset는 0.22로, 그리고 Momentum constant는 0.28로 하여 학습을 시켰다. 테스트에 사용된 데이터는 각 열화상태에 따라 각각 20개씩(총 60개) 테스트에 사용하였다. 그 결과는 표3에서 나타내었다.

표 3 신경망의 테스트 결과

(Good데이터로 선별된 데이터를 신경망에 적용)

Table 3 Test Result of Neural Network

(Data selected good data)

The Number of Test Data	Desired Value			Output of Neural Networks of Testing Data		
	The Normal State	The Initial State	The Final State	The Normal State	The Initial State	The Final State
1	0.00000	0.50000	1.00000	0.00234	0.50020	1.00000
2	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
3	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
4	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
5	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
6	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
7	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
8	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
9	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
10	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
11	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
12	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
13	0.00000	0.50000	1.00000	0.00000	0.50120	1.00000
14	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
15	0.00000	0.50000	1.00000	0.00000	0.50042	0.99989
16	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
17	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
18	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
19	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000
20	0.00000	0.50000	1.00000	0.00000	0.50020	1.00000

RSSE(Root Sum Square Error)= 0.002797

초기신호 170개, 말기신호 170개(총440개 파일)를 훈련벡터로 사용하였다.

열화상태 진단을 위해 원하는 출력은 정상상태의 신호인 경우 "0"이고, 초기상태인 경우 "0.5" 그리고 말기상태인 경우 "1"로 설정하였으며, 최소허용오차는 0.2으로 하였다.

Learning rate(학습률)는 0.22이고, **Offset**는 0.26, **Momentum constant**는 0.24으로 하여 학습을 시켰다. 테스트에 사용된 데이터는 각 열화상태에 따라 각각 훈련에 참여하지 않은 데이터로서 무작위로 각각 20개(총 60개) 선택하여 Test한 결과 다음과 같다. 그 결과는 표4에서 나타내었다.

표 4 신경망의 테스트 결과

(Random하게 선별된 데이터를 신경망에 적용)

Table 4 Test Result of Neural Network

(Data selected random data)

The Number of Test Data	Desired Value			Output of Neural Networks of Testing Data		
	The Normal State	The Initial State	The Final State	The Normal State	The Initial State	The Final State
1	0.00000	0.50000	1.00000	0.00517	0.50001	0.99988
2	0.00000	0.50000	1.00000	0.00000	0.50001	1.00000
3	0.00000	0.50000	1.00000	0.00000	0.50001	0.99988
4	0.00000	0.50000	1.00000	0.00000	0.50001	0.99969
5	0.00000	0.50000	1.00000	0.00000	0.50001	1.00000
6	0.00000	0.50000	1.00000	0.00000	0.50001	1.00000
7	0.00000	0.50000	1.00000	0.00000	0.50001	0.99939
8	0.00000	0.50000	1.00000	0.00005	0.49877	1.00000
9	0.00000	0.50000	1.00000	0.00009	0.49957	0.99473
10	0.00000	0.50000	1.00000	0.00000	0.50001	0.99934
11	0.00000	0.50000	1.00000	0.00000	0.50001	1.00000
12	0.00000	0.50000	1.00000	0.00000	0.50001	0.99953
13	0.00000	0.50000	1.00000	0.00000	0.50001	1.00000
14	0.00000	0.50000	1.00000	0.00000	0.50001	1.00000
15	0.00000	0.50000	1.00000	0.00000	0.50001	1.00000
16	0.00000	0.50000	1.00000	0.00000	0.50001	1.00000
17	0.00000	0.50000	1.00000	0.00000	0.50001	0.99992
18	0.00000	0.50000	1.00000	0.00000	0.50001	1.00000
19	0.00000	0.50000	1.00000	0.00000	0.50001	1.00000
20	0.00000	0.50000	1.00000	0.00000	0.50001	0.99970
RSSE(Root Sum Square Error)= 0.007580						

4. 결 론

본 연구에서 다음 같은 결론을 얻을 수가 있었다.

1. 시스템 노이즈의 제거기법으로서 FIR Digital Filter의 알고리즘을 적용한 결과 상당히 노이즈를 제거할 수가 있었다.
2. 이산웨이블렛 변환의 경우, Multi-Decomposition

시 Level-3가 특정추출을 위해서 최적이라고 사료됩니다.

3. 신경망을 이용한 변압기 열화상태의 진단에서 웨이블렛 변형이 신경망 전처리 과정으로 이용되었고, 입력된 자료는 웨이블렛 계수를 통한 통계적인 파라메터로 이용하였다. 교차확인은 신경망의 적절한 구조를 선택하기 위해서 사용하였으며, 신경망의 전처리로서 이산웨이블렛을 사용하게되면 신경망의 구조를 단순화 할 수가 있으며, Good 데이터로 선별한 데이터를 신경망에 적용한 경우 RSSE=0.002797는, Random 하게 선별된 데이터를 신경망에 적용한 경우 RSSE=0.007580로서 테스트한 결과의 값은 대단히 원하는 값에 거의 근사한 정도로 인식을 할 수가 있었다.

이로서 변압기의 열화상태를 알아내는데 유익한 정보를 제공할 수가 있다고 사료됩니다.

감사의 글

이 연구는 한국전력공사 지원에 의하여 기초전력 공동연구소 주관(관리번호 99-자-02호)으로 수행되었으며 이에 감사 드립니다.

참고 문헌

- [1] Santosh Kumar Pandey and L. Satish , "Multiresolution Signal Decomposition : A New Tool For Fault Detection in Power Transformers During Impulse Tests", IEEE Transaction on Power Delivery ,Vol.13, No.4 , pp1194-1200, 1998
- [2] Hang Wang ,Karen L.Butler, "Detection of Transformer Winding Faults Using Wavelet Analysis and Neural Network", Intelligent System Application to Power Systems(ISAP'99)April 4 ~8,pp 231~235, 1999
- [3] T. Okamoto, T. Tanaka Change in Pulse-Mean $\phi - q$ Distribution Patterns of Partial Discharge due to Treeing Propagation", Trans. Inst. Elect. Eng. Japan, vol. 102.A, No. 12, pp. 665-672, 1982
- [4] T. Okamoto and T. Tanaka, " Cycle-mean $\phi - q$ characteristic of partial discharges in six electrode system", JIEE Vol. 102, No. 7, pp. 7-14, 1982
- [5] 박재준, 김성홍, 김재환,"The Diagnosis of Treeing Breakdown using Simultaneous