

논문 20-1-12

영상신호처리 기법을 이용한 고압전동기 고정자권선 절연결함신호 분류

Classification of Insulation Fault Signals for High Voltage Motors Stator Winding using Image Signal Process Technique

박재준¹, 김희동²
(Jae-Jun Park¹ and Hee-Dong Kim²)

Abstract

Pattern classification of single and multiple discharge sources was applied using a wavelet image signal method in which a feature extraction was applied using a hidden sub-image. A feature extracting method that used vertical and horizontal images using an MSD method was applied to an averaging process for the scale of pulses for the phase. A feature extracting process for the preprocessing of the input of a neural network was performed using an inverse transformation of the horizontal, vertical, and diagonal sub-images. A back propagation algorithm in a neural network was used to classify defective signals. An algorithm for wavelet image processing was developed. In addition, the defective signal was classified using the extracted value that was quantified for the input of a neural network.

Key Words : MSD, Wavelet transform, Stator winding, Partial discharge, Wavelet-neural network

1. 서 론

부분방전(Partial Discharge)측정은 오래전에 발전기에서 이루어져왔다[1], 그러나 오늘날에도 여전히 고압전동기 및 발전기의 PD를 어떻게 진단을 실행하여야 하는지 표준화된 규칙이나 방법은 없다. 그렇지만, 구체화된 조건에서 고압전동기 고정자권선으로부터 계측된 PD펄스들의 상호관계에 대하여 오랜시간에 걸쳐 노력하여 왔다. PD 계측을 위하여 여러 가지 기법을 이용하여 진행하여 오늘에 이른 것이다. 그들 기법 중 고정자 슬롯 바로 앞에서 안테나를 이용한 전자기신호[2]와 단순한 AM라디오를 이용하여 탐지하여 왔고[3], 고정자권선의 중성점주변에 고주파전류센서 (High Frequency

Current Transformer; HF-CT)에 연결하여 계측하여 왔다. 계측기법 중 가장 광범위하게 사용하고 있는 기법은 기기의 단말이나 기기와 개별적으로 병렬회로를 구성하여 직접적으로 용량성 커플러에 연결하여 측정하는 온라인 커플링(on-line coupling) 기법 등이 있다[4,5]. 여러 연구자들이 연구에 있어서 문제로 생각하는 것은 PD발생원의 Identification에 대한 PD데이터를 획득하여 처리하는 것이다. 이와 같은 연구는 지난 수십 년 동안 다양한 방법으로 특징들을 추출하여 왔고 또한 각기 다른 패턴인식방법을 이용하여 실행하여 왔다. 그렇지만, 대부분의 접근방식은 개개의 방전원만이 활성화 된 것으로 가정하여 계측하여 추측한 것이다. 고압전동기의 진단을 얻기 위하여, PD측정만 아니라 육안검사(Visual Inspection), 절연저항, 코아손실(Core Loss) 와 Wedge 견고성 측정 등 다양한 다른 기법과 혼합하여 사용하곤 한다. 더욱이 고압전동기 어려운 PD측정중 하나가 다중방전원(Multiple PD Sources)이 존재하면 그들 특성의 징후(Signature)가 전체위상 및 특정위상 패턴에

1. 중부대학교 전기전자공학과
(충남 금산군 추부면 대학로 101)

2. 한전전력연구원

a. Corresponding Author : jjpark@joongbu.ac.kr
접수일자 : 2006. 11. 28

1차 심사 : 2006. 12. 7
심사완료 : 2006. 12. 21

겹쳐 복잡한 패턴을 가져오게 될 것이다. 비전문가들의 경우는 하나의 방전원에서 발생된 징후를 보고 식별하기도 어려울 것이다. 수많은 연구결과를 분석 검토하여 얻어진 결과로는 다중방전원 PD패턴 인식은 아직 해결되지 못하는 문제로 드러났다. 이러한 문제가 본 연구의 필요성을 갖게 된 배경이 된다.

본 연구에서는 실제모델코일의 단일 및 다중부분 방전원을 설계 제작하여 PRPD(Phased Resolved Partial Discharge)의 부분방전 신호패턴을 계측 연구하였다. 그리고 디지털화된 각각의 단일방전원 PD패턴을 웨이블렛 영상신호처리를 이용하여 패턴 분류를 실시하였고, 각각의 결합영상을 중첩하여 PD패턴을 구하였다. 중첩된 다중방전원 PD패턴을 분리할 수 있는 기법을 연구하였다. 또한 새롭게 제안된 특징추출기법인 MSD(Multi-Resolution Signal Decomposition)의 알고리즘으로 PD영상상을 구하여 결합신호를 분류할 수 있는 특징추출 기법을 구하였다. 정량화된 특징추출 계수를 신경망의 전처리 입력으로 이용하여 완벽한 결합신호를 분류할 수 있었다.

2. 실험 및 측정시스템

2.1 모의 결합권선의 제작

고압전동기 고정자권선의 예상된 결합을 모의 수행하기 위하여 전문가들과 상의한 결과 고정자권선의 모델코일을 제작하였다. 6.6 kV급 고압전동기 고정자권선을 모의한 절연결함을 실시하였다. 절연결합의 종류는 가장 흔히 작업공장상 내포할 수밖에 없는 결합으로서 내부방전(Internal Discharge), 인공적으로 큰 보이드를 모의한 방전(Void Discharge: 두께0.8 mm, 지름16 mm, 길이 27 mm), 운전상에서 나타나는 방전의 일환으로서 슬롯방전(Slot Discharge), 표면방전(Surface Discharge) 등 4개의 단일방전원을 모의하였고, 실제현장에서는 열화진행되는 작업환경 및 열화의 여러조건에 의하여 대체적으로 1개 이상의 방전원이 발생이 이루어진다. 이점에 착안하여 연면방전+보이드방전을 중첩시켜 이중 방전을 할 수 있는 실제 모의 권선을 제작하였다. 실험은 실험실상에서 실시하였으며, 교류 6.6 kVrms을 인가하여 부분방전 측정장치를 이용하여 부분방전 패턴을 계측하였다. 권선은 하나의 모의결합방전을 위하여 4개를 제작하였으며, 측정 계측신호의 패턴은 최소 2개 이상의 권선에서 발생된 부분방전 결합신호패턴을 취하였다. 인공적으로 제작된 모의권선으로서 측정신호의 결합에 대한 신뢰를 높이기 위해서이다.

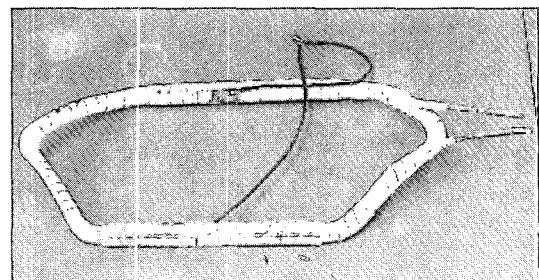


사진 1. 모델권선의 제작.

Photo 1. Production of model coil.

2.2 부분방전 취득 시스템

부분방전신호들은 고전압발생장치 (Hafely TE571, IEC6027방식)을 이용하여 교류 6.6 kVrms을 모의 결합코일에 인가하였다. 부분방전검출은 고주파전

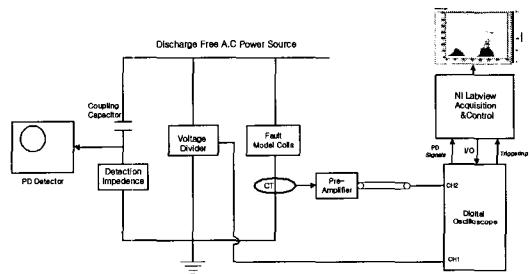


그림 1. 부분방전 측정시스템.

Fig. 1. Measurement system of partial discharge.

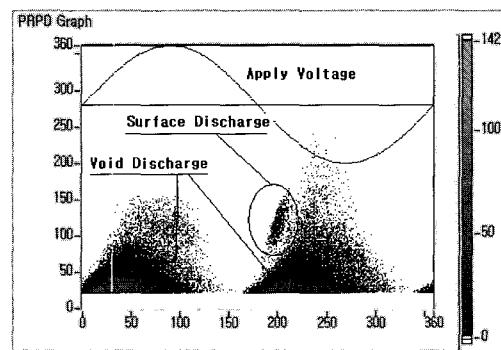


그림 2. 실측된 다중 방전원을 갖는 부분펄스패턴.

Fig. 2. PRPD Graph showing PD pulse pattern having multi-PD sources.

류센서 (High Frequency Current Transformer: HF-CT: -3 dB기준으로 2~25 MHz) 을 통한 출력된 신호와 분압기를 통하여 발생된 인가전압 위상각의 신호를 PRPD패턴으로 결합신호를 매 1분마다 누적된 PRPD부분방전 패턴결합신호가 계측되어 컴퓨터에 저장하게 된다. Labview 프로그램을 통하여 제어 및 자료처리를 실시하였다. 실험시스템 구성 및 블럭도는 그림 1에서 나타내었고, 그림2의 경우는 실측된 단일방전원 및 디지털적으로 중첩된다중 방전원을 갖는 부분방전패턴을 나타내고 있다.

3. 결과 및 고찰

3.1 Partial discharge pattern의 웨이블렛 변환

3.1.1 개개의 방전원과 다중방전의 PD패턴 [5,6,10]

다중방전원 PD패턴으로부터 개개의 PD원으로 분리하는 것은 어려움에 봉착할 수 있다. 4개의 개별 부분방전원 즉 내부방전, 보이드 방전, 슬롯방전, 연면방전을 그림 3(a)~(d)에 나타내었고, 그림 3(e)은 그림 3(b)와 (d)는 디지털적으로 두 개의 단일 방전원을 겹쳐놓아 (Superimposing) 얻어진 두 개의 방전원의 PD패턴이다. 두 개의 방전원의 PD 군집부분을 같은 위상으로 두 개의 방전원 중첩시킨 경우이다. 만일 위상의 차이를 통하여 중첩된다면 현실성이 없는 그러한 결과를 가져오게 될 것이다. 본 연구에서는 이런 점에 착안하여 진폭 및 위상차이 없이 완전 중첩된 결과의 다중 방전원으로서, 만일 두 개의 단일 방전원을 중첩하였을 때, 두개의 동일한 위상영역에서 펄스패턴이 완전중첩된다면, 어느 전문가도 식별하기 어려울 것이다. 그러나 방전마다 위상의 영역이 약간의 차이를 가져오고 그리고 진폭값의 차이를 가져오기 때문에 분명 식별은 가능할 것이다. 보통, 실제적인 PD측정에서 개개의 방전원은 부분적이든 전적이든 중첩될 수가 있다. 그러한 조건하에서 완전한 중첩이 아니면 육안으로는 식별이 가능하게 될 것이다. 예를들면 그림3의 경우는 모의원선의 다중방전원을 모의한 경과 표면방전과 보이드방전 두가지 방전원을 모의하여 측정된 결과로서 전체적인 위상영역에서는 보이드방전의 패턴을 발생하였고, 200°위상에서 150~200 mV정도의 진폭크기를 갖는 PD패턴이 표면방전으로서 나타난 결과를 볼 수가 있다. 이러한 경우 영상의 신호처리로서는 식별하기 어렵고, 단지 PRPD의 방식을 통하여 육안으로 식별이 가능한 경우로 본다. 완전히 위상과 진폭의 흐트러짐이 크게 되면 완전히 중첩되어 식별이 또한 불가능하게 될 것이다.

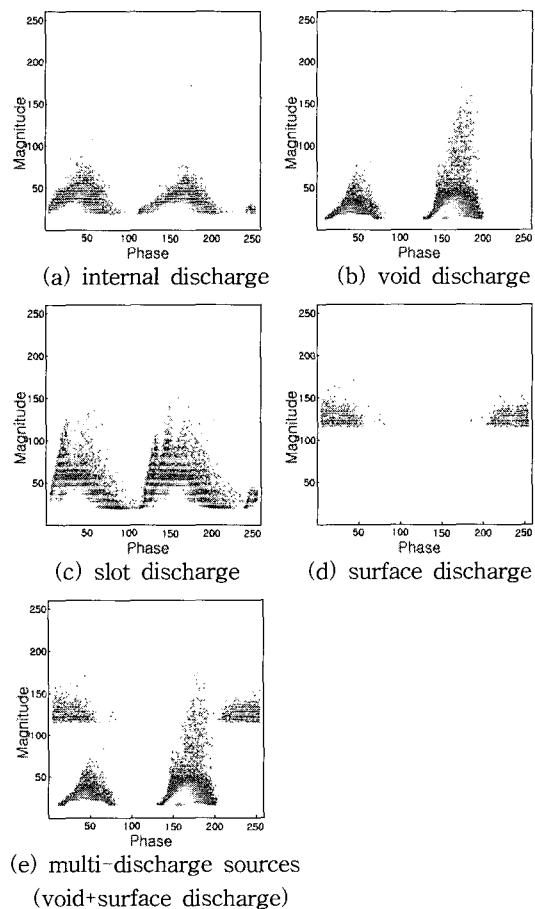


그림 3. 개개의 방전원과 다중방전원의 PD패턴.
Fig. 3. PD patterns of individual and multi-discharge sources.

3.2 기초가 되는 영상 웨이블렛의 원칙[7-9]

입력신호 또는 영상을 분석하는데 있어서 웨이블렛의 이용은 참으로 흥미롭고, 분석 및 분리하는데 도움이 된다. 그림 4의 경우는 보이드 방전의 영상을 64 gray-scale로서 나타낸 PD패턴을 보여주고 있다. 56개의 계수를 가지는 Daubechies 웨이블렛을 이용하여 MSD의 레벨-3로 적용한 결과를 의미한다. 레벨-3로 분해한 4개의 Sub-image는 다음과 같다. 즉, Approximate(A), Horizontal(H), Vertical(V), Diagonal(D)를 그림 4에 나타내었다. 그것의 원형 및 Sub-image를 각각 그림 5(a)에서는 원형의 영상을, 그림(b)의 경우는 Approximate를 그림(c)의 경우 Horizontal, 그림(d)의 경우 Vertical를 그림(e)에는 Diagonal의 영상을 나타내었다.

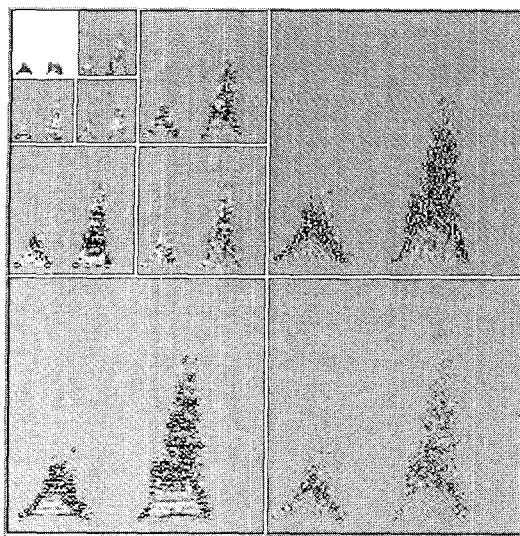


그림 4. 보이드 방전의 웨이블렛 변환과 MSD.

Fig. 4. Wavelet transform and MSD of void discharge.

그리면 각각의 Sub-image 영상 중 Approximate는 원형영상에 매끄러운 버전(smooth version)을 말하고, Horizontal과 Vertical 그리고 Diagonal의 sub-image는 원형영상에 숨어있는것을 나타내는 경우이다. 4개의 서브영상을 중에서 Horizontal과 Vertical 그리고 Diagonal의 선택은 향후 결합신호 분류에 필요한 특징추출 및 신경망의 입력으로 사용하기 위하여 필요한 것이다. 또한 MSD의 분해레벨 및 Mother Wavelet의 설정은 각각의 서로 다른 레벨에서 모든 영상의 합성(Inverse Wavelet Transform)에 의하여 철저한 조사가 필요한 것이다.

그림 6(a)와 그림 7(a)는 연면방전원과 보이드 방전원 각각에 대한 원형신호를 나타내고 있다. 그리고 그림 8(a)는 이를 개개의 방전원의 중첩에 기인된 PD패턴이다. 그림 6(b), 7(b), 8(b)는 그림 6~8(a)의 방전원에 대한 레벨-3의 Horizontal image을 분해와 합성된 것이다. 원형의 PD패턴은 인가전압위상각 정극성과 부극성으로 구성된 sine-wave에서 동기되어 PRPD의 패턴으로 구성된 영상이다. 전체 영상의 구성을 Horizontal의 경우 픽셀수를 256개로 정규화한 영상으로 제 편집하였고, 정극성의 경우 128픽셀, 부극성은 128픽셀로 구성하였다. 패턴은 특정부분의 위상에서 일정한 진폭의 크기를 갖는 펄스의 발생만을 기록하였고, 정극성과 부극성이 유사한 패턴을 나타내고 있

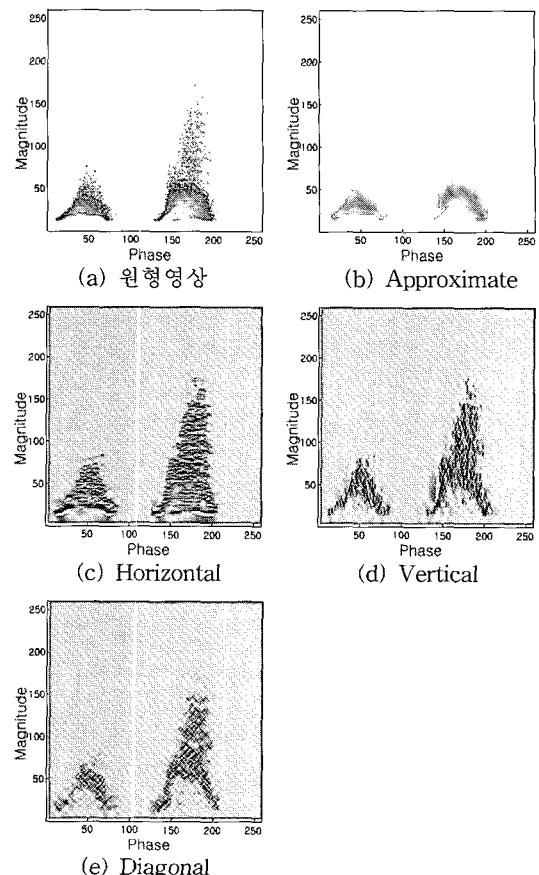


그림 5. 보이드방전의 MSD.

Fig. 5. MSD of void discharge.

다. 일반적으로 다른방전의 경우는 방전펄스가 영에 가까운 펄스크기로부터 다양한 펄스가 발생되었지만, 그러한 방전과는 다른방전의 패턴을 나타내고 있다. 다음에는 개개의 방전원과 중첩된 방전원에 대한 수직성분의 영상에 대하여 설명하기로 한다. 그림 6(c)~8(c)은 연면방전, 보이드방전, 중첩된방전의 Vertical image를 나타내고 있다. 펄스가 군집된 수직방향 성분의 뚜렷한 영상의 구분이 존재한다. 결국은 다중방전원 영상 그림 8(c)는 H의 영상과 V의 영상을 시각적으로 보아서도 쉽게 개개의 방전원과 뚜렷한 특징이 존재하고 있음을 알 수 있었다. 중요한 것은 그들 안에 존재하는 각각의 영상을 분리할 수 있는 형으로 이용할 수 있다는 점이다. 그런 분리는 본 연구에서 개발한 근본적인 영상의 처리과정을 준수하여 실시하면 가능하게 될 것이다. 원형영상의 패턴을 위상축이나 진폭크기의 축에 전혀 자리이동 없이 실시하였기 때

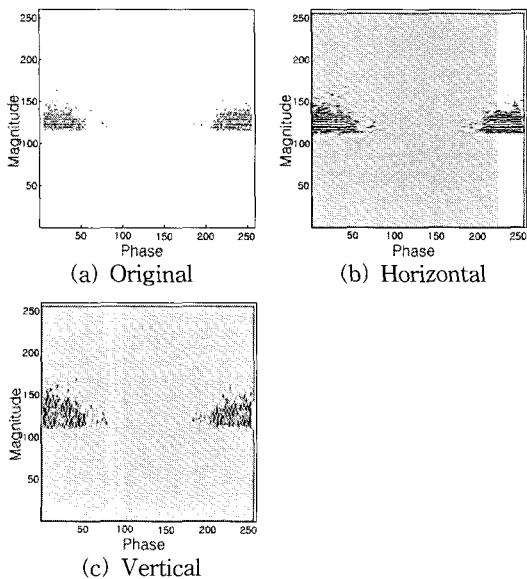


그림 6. 연면방전패턴의 Horizontal과 Vertical 영상.
Fig. 6. Horizontal and vertical image of surface discharge patterns.

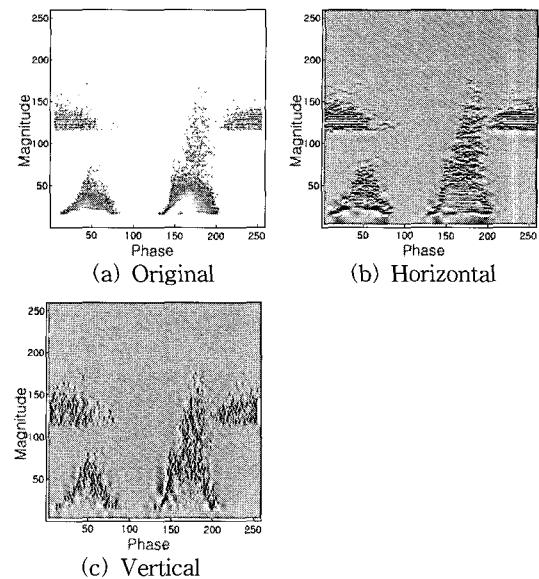


그림 8. 중첩된 이중방전패턴의 Horizontal과 Vertical 영상.

Fig. 8. Horizontal and vertical image of superimposed multi-discharge patterns

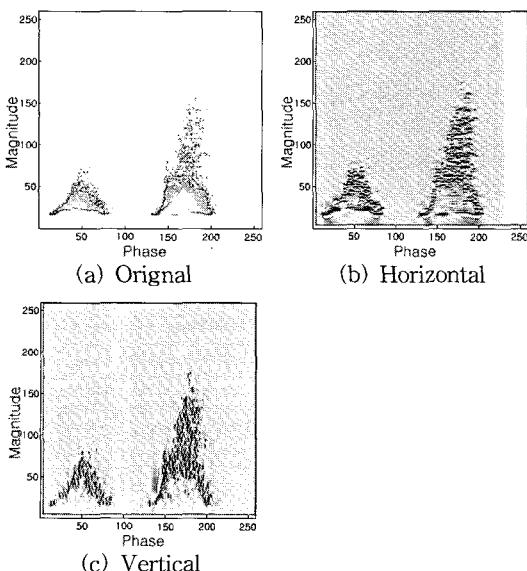


그림 7. 보이드방전 패턴의 Horizontal과 Vertical 영상.

Fig. 7. Horizontal and vertical image of void discharge patterns.

문에 실제의 중첩된 방전원을 모의하여 발생된 다중방전원 패턴분류 및 식별에 적용하면 다중방전원의 패턴을 쉽게 구할 수 있을 것이다.

3.3 2차원 웨이블렛 변환과 MSD [7-9]

(2-Dimension Wavelet Transform and MSD)

웨이블렛을 이용한 디지털데이터의 분해(Decomposition)와 합성(Reconstruction)은 데이터 압축, 영상 및 음성신호처리, 원격점침, 의료영상 등에 있어서 최근에 가장 강력하고, 보편화된 도구로서 드러나게 된 것이다[7-9]. 푸리에변환처럼 웨이블렛 변환은 주어진 신호들을 주파수성분으로 분해하지만 그러나 주파수영역의 불균질 구분(non-uniform division)의 제공과는 다르다. 푸리에 변환과는 다르게 웨이블렛 변환은 시간과 주파수들 모두를 동시에 국부적으로 나타낼 수가 있다. 이것은 분해 또는 푸리에변환(사인 또는 코사인)의 경우 기본함수(basic function)는 무한대에 걸쳐 뻗어지는 결과를 갖지만 그것에 반하여 웨이블렛변환의 경우 시간의 함수에 컴팩트한 함수이다. 수학적으로, 함수 마더웨이블렛 함수(mother wavelet function) $g(t)$ 과 관계된 함수 $f(t)$ 의 연속웨이블렛 변환(Continuous Wavelet; CWT)은 다음 식으로

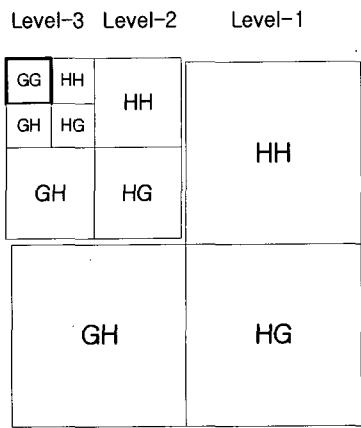


그림 9. 영상신호의 웨이블렛변환 과 MSD.

Fig. 9. 'Wavelet transform and MSD of image signals.

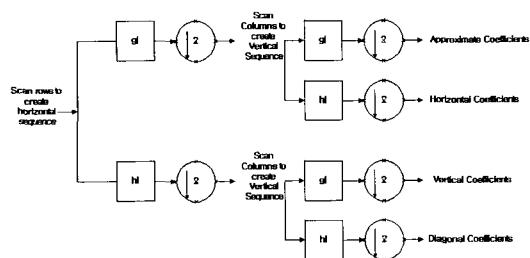


그림 10. 영상의 단일 분해단계.

Fig. 10. Single decomposition step of image signals.

정의된다.

$$W_g[f(t)](a,b) = W_g f(a,b) \\ = |a|^{-0.5} \int f(t) g^*(\frac{t-b}{a}) \cdot \quad (1)$$

여기서 a 는 scale factor (real, $a \neq 0$), b 는 translation parameter, $*$ 는 공액 연산자이다. $g(t)$ 선택의 수학적인 제한, 허용조건, 이 존재한다. 보편적으로 사용된 마더웨이블렛, Morlet, Daubechies, Haar, Coifman 이 있다. 마더웨이블렛의 선택은 응용에 의존하고 그리고 선택에 대한 일반적인 규칙은 없다. 함수 $W_g f(a,b)$ 는 스케일 a 와 시간 b 즉, 각기 다른 분해능에서 신호정보에 기여함을 나타낸 것이다. 그렇지만, CWT는 계산

적으로 비싸고 그리고 많은 Redundant 자료를 생성 한다. 이들의 결점을 회피하기 위하여 이산신호에 적용할 효과적인 구현은 적절한 필터를 사용하여 형성된 어떤 강제성을 만족하는 이산웨이블렛 변환(Discrete Wavelet Transform ; DWT)이다. 다중분해능 신호분해(Multi-resolution Signal Decomposition ; MSD)기법은 이 방법을 통하여 구현되어졌다. 이것은 웨이블렛 사용의 광범위한 이유이다. DWT신호에서 Low-Pass Filter G_A 을 통과시키고 그리고 Scaling function로 불리워지고, High-Pass Filter H_A 는 마더 웨이블렛으로 불리워 진다. 그리고 그때 각각의 출력은 2로 나뉘어져 다운샘플링 되어 진다. G_A 의 출력(Approximate Coefficients)은 High-Scale(Low-Frequency) 성분이고, H_A 의 출력(Detailed Coefficients)은 Low-Scale (High-frequency) 성분이다. Detailed Coefficient는 신호의 특성 와 더욱 높은 주파수의 에너지 나타내고 반면에 Approximate Coefficients는 원형신호의 Blurred Version을 나타낸다.

분해과정(Decomposition Process; Analysis Stage)은 순차적으로 분해되고 있는 연속적인 Approximate신호성분과 함께 반복될 것이다. 그래서 신호는 더욱 낮는 분해능의 많은 레벨로 나뉘어지게 된다. 그래서 그것은 각기 다른 분해능에서 신호의 정보를 주어지게 되고 그리고 MSD는 웨이블렛 분해의 개념이 보편화가 된 것이다. 아날로그적인 것에서 분해, 신호계수는 각기 다른 스케일에서 존재하는 신호의 정도를 주어지는 또 다른 필터집합 (G_S, H_S)을 이용하여 합성할 수가 있다. 분해와 합성필터 쌍은 상호관계가 있고 그리고 Quadrature Mirror Filter로서 참조된다. 그들 필터집합에 어떤 강제성의 부과는 완벽한 합성을 보장하게 된다. 다른말로서, 원형신호에서 만들어진 신호성분을 모두 재구성하여 합하는 것이다.

2차원 신호에 대해서, 즉 영상이라고 말하는, 행과 열은 분해하는 동안 분리하여진다는 것이다. 그림 10은 영상의 분해에 대한 단일단계를 나타내고 있다. 수평 과 수직성분의 영상은 분리적으로 걸려지고 그리고 서브샘플 되어 진다. 그런 과정이 그림 10에서 보여준바 대로 처리되어질 때 모든 레벨에서 분해의 출력결과는 4개의 서브영상을 만든다. 즉, 하나는 approximate 그리고 3개의 detailed 계수를 만든다. 합성과정에서 그들 계수는 다시 업샘플(upsample)되고 그리고 결러지게 된다. 재구성된 (합성)영상은 approximate(A)와 detailed Horizontal (H), Vertical(V), 그리고 diagonal (D)영상이다. 입

력영상의 blurred version은 A로 나타낸다. 반면에 H,V,D는 각각의 원형영상 수평, 수직, 대각선의 변화로 표현된다. 역시 여기서 모든 합성된 영상의 합은 원형영상을 낳는다.

3.4 신경망을 이용한 결합신호 분류

3.4.1 특징추출 및 신경망 전처리 입력

본 연구에서 더욱 정확한 결합신호 분류를 위하여 신경망 입력 전처리 과정시 추출된 특징을 가지고서는 입력 자료가 방대하고 많은 시뮬레이션 시간 때문에 다음과 같은 방법을 통하여 입력자료를 정량화 하였다.

원형의 결합영상을 레벨-3으로 웨이블렛변환을 실시하게 되면, 4개의 sub-image를 얻게 된다. 즉, Approximate, Horizontal, Vertical, Diagonal를 얻게 된다. 레벨-1을 적용하게 되면 3개의 sub-image와 1개의 Approximate를 얻게 되고, 레벨-2를 적용하게 되면, 첫번째 Approximate를 가지고 적용하게 되므로, 두 번째도 3개의 sub-image와 1개의 Approximate를 얻게 된다. 레벨-3을 적용하게 되면 두 번째 Approximate를 가지고 적용하게 되므로, 3개의 sub-image와 1개의 Approximate를 얻게 된다. 정량화된 신경망 전처리입력 값에는 Approximate의 성분을 제외한 3개의 sub-image를 가지고 실시하였다. 역변환(Inverse Wavelet Transform)의 원리를 이용하였다.

Horizontal 성분의 정량화된 값은 레벨-1, 레벨-2, 레벨-3과정을 걸치면서 발생된 3개의 Horizontal 영상성분을 역변환 할 때, Vertical 및 Diagonal 성분 각각에 대해서는 '0'의 값으로 입력하여 역변환시켜 발생된 파형의 면적을 구하였다. 정규화된 영상은 256×256 이므로, 면적의 평균화된 값을 구하기 위하여 65536의 값으로 나뉘어 결과를 얻게 된다.

Vertical 성분의 정량화된 값은 Horizontal 성분의 경우처럼 레벨-1, 레벨-2, 레벨-3의 과정을 걸치면서 발생된 3개의 영상을 역변환시켜 평균하여 얻은 결과를 이용하였다.

Diagonal 성분의 정량화된 위에서 열거한 방법대로 실시하여 최종 Diagonal의 평균값을 얻게 된다. 결국 하나의 결합영상에 대해서 3개의 평균화하여 정량화시킨 값을 신경망의 전처리에 적용하였다.

그림 11은 3가지의 결합영상 즉, 연면(표면)방전시 발생된 신호의 정량화된 특징추출 값을 간단히 나타낸 것이다. X축 경우는 각각의 결합영상에 대한 Horizontal, 평균값, Vertical 평균값, Diagonal

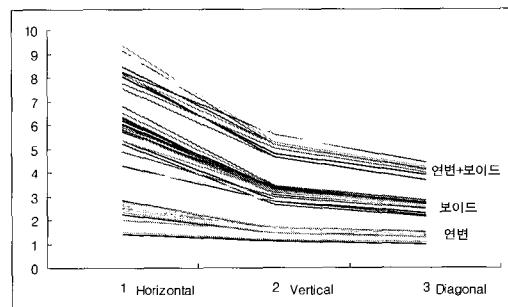


그림 11. 특징추출 결과 (신경망 입력자료).

Fig. 11. Feature extraction result.

평균값을 나타낸 것이다. 또한 Y축은 영상의 평균진폭을 나타낸 것이다. 아래의 그림에서 볼 수 있듯이, 3개의 서로 다른 방전들이 각각 명확히 구분됨을 알 수 있다.

3.4.2 절연 결합 분류를 위한 신경 회로망 학습 과정

본 논문에서 사용한 신경 회로망은 다층구조로 한 개의 히든층과 입력, 출력층으로 구성하였다. 입력층은 9개의 뉴런으로 구성하였고, 히든층과 출력층은 각각 3개와 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. 그림 12에 3층 역전파 신경망 구조를 나타내었고, 그림 13에 역전파 신경망의 활성화 함수를 나타내었다.

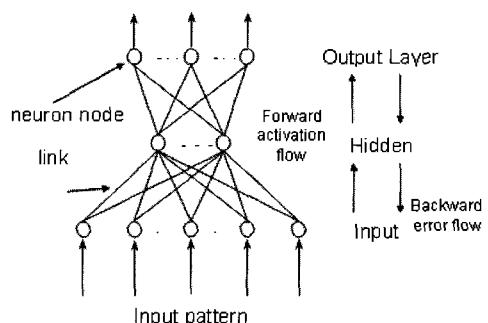


그림 12. 3층 역전파 신경망 구조.

Fig. 12. Neural network architecture of 3-layer back propagation.

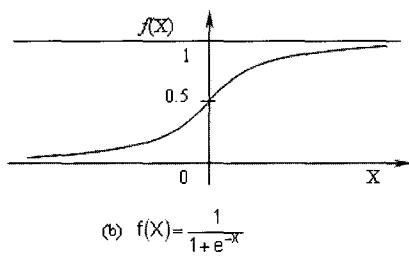


그림 13. 역전파 신경망의 활성화 함수.

Fig. 13. Activation function of back propagation wave.

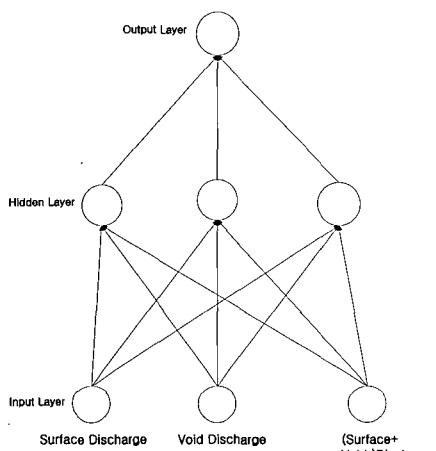


그림 14. 신경망의 다층구조.

Fig. 14. Multi-layer architecture of neural network.

본 논문에서는 세 종류의 부분방전 결합신호패턴을 특징추출한 결과를 학습시켰으며, 각각의 부분방전 결합신호의 패턴에 대한 학습패턴은 각각 50개씩으로 하였다. 교사 학습을 위한 출력 값은 연면방전의 패턴은 0으로 설정하였으며, 연면+보이드방전의 이중방전의 경우는 0.5로 그리고 보이드방전의 경우는 1로 설정하였다. 그리고 그림 14는 본 연구의 결합신호 분류를 위해 사용된 신경망 다층구조를 나타내고 있다.

3.4.3 신경 회로망의 성능 평가

신경 회로망의 성능은 초기 연결강도, 전처리과정에서의 명확한 특성 추출, 학습과정의 오차 허용 범위, 히든층의 뉴런수 등 여러 가지 요인에 의

표 1. 신경망의 테스트 결과.

Table 1. Test result of neural network.

시험 테이 터들	Target Values			Test Results		
	연변	연변+ 보이드	보이드	연변	연변+ 보이드	보이드
1	0.00000	0.50000	1.00000	0.00079	0.50145	0.99879
2	0.00000	0.50000	1.00000	0.00079	0.50033	0.99336
3	0.00000	0.50000	1.00000	0.00165	0.50336	0.99941
4	0.00000	0.50000	1.00000	0.00023	0.50063	0.99939
5	0.00000	0.50000	1.00000	0.00007	0.50033	0.99941
6	0.00000	0.50000	1.00000	0.00009	0.50033	0.99224
7	0.00000	0.50000	1.00000	0.00009	0.50140	0.99941
8	0.00000	0.50000	1.00000	0.00009	0.50211	0.99911
9	0.00000	0.50000	1.00000	0.00009	0.50311	0.99817
10	0.00000	0.50000	1.00000	0.00079	0.50051	0.99942
RSSE(Root Sum Square Error=0.01170)						

하여 영향을 받는다. 본 논문에서 신경 회로망은 9개의 입력 뉴런, 3개의 히든 뉴런, 1개의 출력 뉴런으로 구성하였고 또한 학습과정에서 Learing rate: 0.9, Offset: 0.2, Momentum constant: 0.1로 하였다.

4. 결 론

부분방전은 지금까지 단일방전원에서 만이 국한되어 연구가 진행되어왔다. 다중방전원 PD의 인식은 해결하여야 할 과제로서 인식되어왔다.

본 연구에서는 이와 같은 문제를 해결하기 위하여 이산웨이블렛 변환기법인 Multi-Resolution signal Decomposition and Reconstruction을 이용하여 단일방전 및 다중방전원의 결합신호에 디지털기법을 적절히 적용하여 overlapping된 PD패턴을 영상화하였다. 적용된 Daubechies Wavelet의 level-3를 적용한 결과 embedded된 4개의 sub-images를 approximate, horizontal, vertical, diagonal 이 포함되었다. 이중 분리할 수 있는 두 개의 sub-image인 horizontal과 vertical을 단일 및

다중방전원 결합신호에서 적용하여 특징추출 계수를 얻었다. 평균화 작업을 통하여 결함마다 단일화된 1차원적인 형태의 특징추출된 결과를 결합신호의 분류에 적용하기 위하여 신경망의 전처리로 이용하였다. 그렇지만 향후 실제적인 각기 다른 다중결함의 연구를 통하여 위에서 제안된 기법의 실현 가능성을 한층 높이게 될 것이다

감사의 글

본 연구는 2005년도 산업자원부 전력산업연구개발사업 전력선행기술에 의하여 이루어진 연구로서, 관계부처에 감사 드립니다.

참고 문헌

- [1] J. S. Johnson, "Slot discharge detection between coils surfaces and core of high-voltage stator winding", Trans. Amer. Inst. Electr. Eng, Vol. 70, p. 1993, 1951.
- [2] J. E. Timperley, "Incipient fault identification through neural rf monitoring of large rotating machine", IEEE Trans. Power. App. and Syst., Vol. 102, p. 693, 1983.
- [3] A. Contin, A. Cavallini, G. C. Montanari, G. Pasini, and F. Puletti, "Digital detection and fuzzy classification of partial discharge signals", IEEE Transaction on Dielectrics and Electrical Insulation, Vol. 9, No. 3, p. 335, 2001.
- [4] G. C. Stone, "Advancements during the past quarter century in on-line monitoring of motor and generator winding insulation", IEEE Trans. Dielectric. Insul., Vol. 9, p. 746, 2002.
- [5] Claude Hudon and Mario Belec, "Partial discharge signal interpretation for generator diagnostics", IEEE Transaction on Dielectrics and Electrical Insulation, Vol. 12, No. 2, p. 297, 2005.
- [6] E. M. Lalitha and L. Satish, "Wavelet analysis for classification of multi-source PD patterns", IEEE Transaction on Dielectrics and Electrical Insulation, Vol. 7, No. 1, p. 40, 2000.
- [7] Randy K. Young, "Wavelet Theory and Applications", Kluwer Academic Publications, 1993.
- [8] A Primer, "Introduction to wavelet and wavelet transforms", Prentice Hall, 1998.
- [9] Gilbert Strang and Truong Nguyen, "Wavelet and Filter Banks", Prentice Hall, 1997.
- [10] 박재준, 이성용, 문대철, "고압전동기 고정자 권선의 PRPD 부분방전 결합신호 해석", 전기전자재료학회 논문지, 19권, 10호, p. 942, 2006.