

# 전자파의 측정과 패턴인식 기법에 의한 부분방전 신호 검출

論文

51A-6-4

## The Detection of Partial Discharge Signal by the Measurement of an Electromagnetic Wave and Pattern Recognition Technique

金泳魯\*·金載哲\*\*·徐寅喆\*\*\*·田永在<sup>§</sup>·金光和<sup>§§</sup>  
(Young-No Kim · Jae-Chul Kim · In-Chul Seo · Young-Jae Jeon · Kwang-Hwa Kim)

**Abstract** – This paper presents the method for detecting a partial discharge(PD) using an electromagnetic wave measured by an antenna. The various electromagnetic waves are measured in the laboratory and wavelet transform, which provides a direct quantitative measure of spectral content in the time-frequency domain, are applied for identifying the property of electromagnetic waves. Also, the statistical method and self-organizing feature map(SOFM) are applied for the pattern recognition of electromagnetic waves. The proposed method is shown to be useful for detecting electromagnetic waves emitted for PD in test data.

**Key Words** : Partial Discharge, Wavelet Transform, Electromagnetic Wave, Antenna, Self-Organizing Feature Map

### 1. 서 론

경제 개발을 시작한 이래 매년 경제성장을 옮도는 전력 소비 증가로 전력설비가 꾸준히 증설되어 왔으며, 이들 설비 중 일부가 점점 노후화됨에 따라 설비사고의 가능성성이 증대되고 있다. 최근에는 경제적인 문제와 용지확보 등의 문제로 인해 밀집형 전력설비가 늘어나는 추세이기 때문에 밀집된 전력설비를 경제적이면서 신뢰성 있게 진단할 수 있는 방법이 필요하게 되었다.

과거의 전력설비 보수유지는 외관 구조점검을 주체로 한 시간기준 진단에 의해 정기적인 부품교환이나 정비에 의한 예방정비가 대부분을 차지하고 있었다. 90년대 들어 이러한 시간기준 진단 대신에 온라인으로 전력설비의 상태를 진단하는 상태기준 진단의 필요성이 대두되었고, 이에 관한 많은 연구가 진행되었다. 다양한 상태기준 진단 방법 중에서 전력설비의 결연열화 상태를 부분방전의 유·무로 진단하는 방법이 많이 연구되고 있으며, 일부는 현장에 적용되고 있는 상태이다[1].

현재 전력설비에 관한 열화상태 진단방법의 경우 전력설비 개개에 대한 정밀진단을 위주로 하고 있어 많은 수의 센서가 필요하게 된다. 또한 전력설비 진단에 필요한 센서를 직접 전력설비에 부착해야 하지만 장소 때문에 원하는 위치에 부착하지 못해 정확성 있는 측정을 하지 못하는 경우가

많이 발생한다. 최근 이러한 문제점을 해결하기 위해 전력설비에서 발생하는 전자파를 안테나로 측정하여 진단하는 방법이 제시되었다[2-6]. 안테나를 이용한 진단은 전력설비에 센서를 직접 부착하지 않아도 되고 다수의 밀집된 전력설비에서 발생하는 전자파를 측정할 수 있기 때문에 측정 위치에 대한 문제가 없을 뿐만 아니라 경제성도 매우 높다.

안테나로 측정한 전자파는 안테나의 성능에 따라 다르겠지만 일반적으로 초음파 신호보다 주파수 대역이 넓은 편이며, 관련 지식과 경험이 부족하여 부분방전 유·무를 구분하기가 어렵다. 이러한 문제 때문에 안테나에서 측정한 전자파를 전력설비 진단에 적용할 때 시간과 주파수 영역에서 신호를 분석할 수 있는 웨이블렛 변환(wavelet transform)이 많이 적용되었다[2-9]. 이들 논문들은 주로 안테나로 측정한 전자파의 주파수 특성과 형태별로 구분할 수 있는 특성을 웨이블렛 변환을 이용하여 연구하였다. 그밖에 부분방전 유무나 진행 정도를 구분하기 위해 웨이블렛 변환을 통해서 얻은 데이터에 신경망을 적용한 연구도 진행되었다[10,11]. 지금까지는 전자파를 이용하여 부분방전 신호를 측정하거나 발생 유·무와 방전 형태에 따른 특성을 파악하는 등 부분적으로 연구가 진행되었다. 전자파를 이용한 현실적인 적용을 위해서는 부분방전 발생 유·무 및 발생 형태에 따른 구분이 가능한 일관적인 진단 알고리즘이 필요하다. 따라서, 본 논문에서는 안테나로 측정한 전자파의 특성 분석을 위해 웨이블렛 변환을 적용하였고, 발생 유·무 및 형태에 따른 구분을 위해 통계적인 기법과 신경망을 적용하여 전자파 측정에서부터 필요한 진단 결과를 도출할 수 있는 알고리즘을 제안하였다. 웨이블렛 변환 후 얻은 계수값과 통계적인 기법은 신경망에 필요한 입력값들의 수를 줄이면서 부분방전의 특성을 반영할 수 있도록 정규화 되었으며, 최종적인 패턴 분류를 위해서 코호넨이 제안한 대표적인 자율학습형 신경망 모델인 자기-조직화 형성 지도(self-organizing feature map)를 적용하였

\* 正會員 : (주)피에스디테크 研究員

\*\* 正會員 : 崇實大 工大 電氣工學科 教授 · 工博

\*\*\* 正會員 : 韓國東西發電(주) 발전부

§ 正會員 : 崇實大 T大 電氣T學科 時間講師 · T博

§§ 正會員 : 韓國電氣研究院 責任研究員 · T博

接受日字 : 2001年 11月 21日

最終完了 : 2002年 4月 12日

다. 실험실에서 이루어진 실험을 통해 필요한 데이터를 얻었으며, 이에 제안한 방법을 적용하여 부분방전 유·무 및 방전 형태를 확인할 수 있었다.

## 2. 안테나를 이용한 전자파 측정

실험장치는 부분방전 측정을 위해 실험 장치의 구성과 측정을 규정한 IEC-270을 기준으로 그림 1과 같이 구성하였다[12]. 전극과 1[m] 떨어진 위치에 있는 헬리컬 안테나를 사용하여 부분방전시 방사된 전자파를 측정하였으며, 로고스키 코일을 이용하여 부분방전 발생 유무를 확인하였다. 측정된 전자파는 IEEE-488 (GPIB-488) 인터페이스를 이용하여 오실로스코프에서 컴퓨터로 저장되었다.

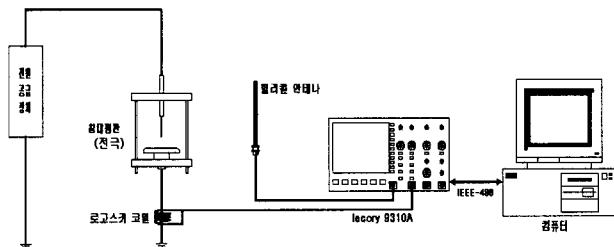


그림 1 부분방전 모의를 위한 실험 장치

Fig. 1 Experimental equipment for simulating partial discharge

본 논문에서는 부분방전의 대표적인 형태인 코로나 방전과 연면 방전을 모의하기 위해 그림 2에 보이는 침 대 평판과 평판 대 평판 전극을 이용하였다.

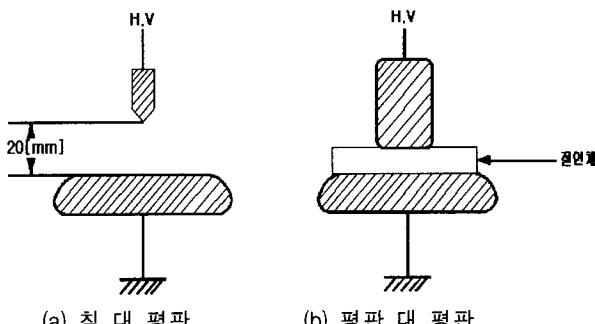


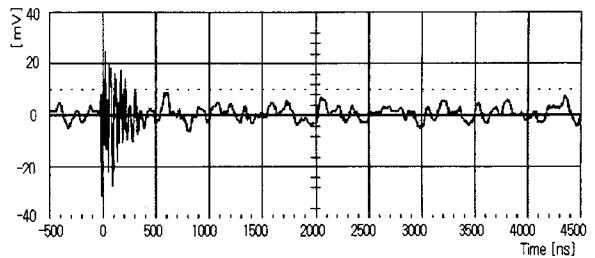
그림 2 전극의 형태

Fig. 2 Model of electrodes

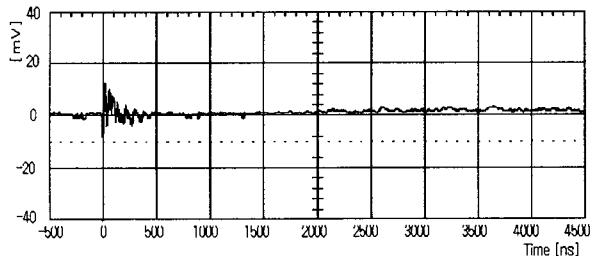
그림 2(a)처럼 침 대 평판 전극에서 간격은 20[mm]로 하였고, 지름이 90[mm]인 하부 전극을 사용하였다. 그림 2(b)의 평판 대 평판 전극에서는 IEC(b)전극의 형태를 따랐고, 지름이 30[mm]와 90[mm]인 평판 사이에 절연체를 두어 사용하였다[13]. 침 대 평판과 평판 대 평판 전극에서 발생한 부분방전을 확인하기 위하여 고압인가장치에 있는 부분방전 측정기를 우선적으로 이용하였고, 로고스키코일을 사용하여 재확인을 하였다.

100[MHz]의 주파수 대역의 로고스키 코일은 부분방전의 유무를 확인하기 위해 접지선에 연결하며, 부분방전 발생시 로고스키 코일에서 검출되는 전기신호는 안테나로 측정된

전자파 파형과 비교된다. 그림 3은 로고스키 코일과 안테나에 의해 측정된 파형들이다.



(a) 안테나로 측정한 파형



(b) 로고스키 코일로 측정한 파형

그림 3 안테나와 로고스키 코일에서 측정한 파형

Fig. 3 Waveforms measured by an antenna and rogoski coil

그림 3(a)는 안테나에서 측정된 부분방전 파형이고, 그림 3(b)는 로고스키 코일에서 측정된 부분방전 파형을 나타내었다. 안테나를 이용할 경우 공기중의 전자파 전파속도가 매우 빠르기 때문에 로고스키 코일에서의 전류 파형과 전자파의 파형이 동시에 측정된다. 그림 3의 경우 안테나에서 측정된 전자파 파형과 로고스키 코일에서 측정된 파형이 동시에 발생하여 부분방전의 발생 유무를 전자파로 판단할 수 있다는 것을 보였다.

본 논문에서는 안테나로 측정된 전자파를 이용하여 부분방전의 발생 유무와 방전 형태를 구분하기 위해 주변 노이즈, 침 대 평판 전극에 의한 코로나 방전, 평판 대 평판 전극에 의한 연면 방전에 관한 실험을 하여 데이터를 취득하였다. 주변 노이즈는 전극을 연결하지 않고 전압만 인가한 후 측정하였고, 코로나 방전과 연면 방전은 앞서 설명한 침 대 평판과 평판 대 평판 전극을 이용하여 측정하였다. 노이즈의 측정 파형은 그림 4에 나타내었고, 침 대 평판 방전과 평판 대 평판 방전의 파형은 각각 그림 5와 6에 나타내었다.

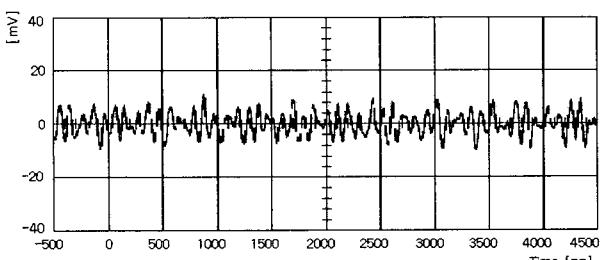


그림 4 노이즈 파형

Fig. 4 Noise waveform

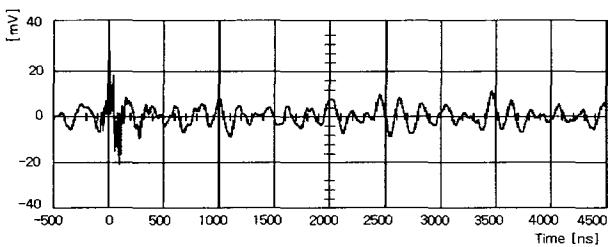


그림 5 침 대 평판의 방전 파형

Fig. 5 Corona discharge waveform

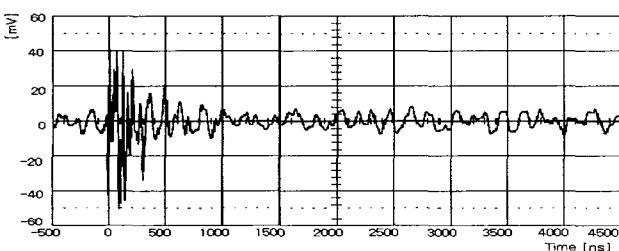


그림 6 평판 대 평판의 방전 파형

Fig. 6 Surface discharge waveform

그림 4에서 보이는 노이즈 파형의 경우 비교적 쉽게 부분방전 파형과 구분할 수 있지만 그림 5의 코로나 방전 파형과 그림 6의 연면 방전 파형은 비슷한 형태를 가지고 있기 때문에 구분하기가 쉽지 않다. 다만, 그림 6의 파형은 그림 5의 파형에 비해 방전이 지속되는 연면 방전의 특성을 보여주고 있어 부분방전의 형태에 따른 특성을 이용하면 분류할 수 있다는 가능성을 보여준다.

### 3. 부분방전신호 검출을 위한 알고리즘

본 논문에서는 부분방전의 유·무와 방전 형태에 따른 분류를 위해 전자파 파형을 분석하고 특성을 추출할 수 있는 기법들을 적용하였다. 시간-주파수 영역에서 파형의 특성을 알 수 있는 웨이블렛 변환을 적용하여 파형을 분석하였고, 특징에 따른 분류를 보다 정확히 하기 위해 통계적인 기법과 자기-조직화 특성 맵을 적용하였다.

#### 3.1 웨이블렛 변환

일반적으로 많은 분야에서 적용되는 푸리에 변환의 단점을 보완하기 위하여 기저함수가 지역적이고 다양하며 시간-주파수 표현이 가능한 웨이브렛 변환이 개발되어 적용되고 있다[14-16]. 웨이브렛 변환은 마더 웨이블렛(mother wavelet)의 스케일링(scaling)과 천이(translation)과정에 의해 다양한 기저함수를 생성하기 때문에 시간과 주파수의 정보를 동시에 적절하게 표현할 수 있다는 장점을 가지고 있다. 마더 웨이블렛은 식 (1)과 같이 표현된다.

$$\Psi_{\tau,s} = \frac{1}{\sqrt{s}} \Psi\left(\frac{t-\tau}{s}\right) \quad (1)$$

여기서,  $s$ 는 스케일의 매개변수이며,  $\tau$ 는 천이 매개변수이다.

천이(translation)는 시간 정보를 포함하고, 스케일(scale)은 주파수 정보를 포함한다. 마더 웨이블렛이란 다른 기저함수를 생성하는 기본형이라는 의미를 내포한다. 연속시간영역에서의 웨이블렛 변환(continuous wavelet transform : CWT)은 식 (2)과 같이 정의된다.

$$CWT_x(\tau, s) = \frac{1}{\sqrt{|s|}} \int f(t) \Psi^*\left(\frac{t-\tau}{s}\right) dt \quad (2)$$

여기서,  $f(t)$ 는 해석하고자 하는 신호이고,  $\Psi(t)$ 는 마더 웨이블렛이다.

CWT는  $s$ ,  $\tau$ 가 연속적이므로 중복(redundancy)과 구현상의 어려움을 지니고 있다. 이를 해결하기 위하여 식 (3)과 같이 각각의 매개 변수를  $s = s_0^j$ ,  $\tau = k\tau_0 s_0^j$ 로 불연속화시키며, 이산 웨이블렛 변환(discrete wavelet transform)은 다음과 같다.

$$DWT_x(j, k) = \frac{1}{\sqrt{|s_0^j|}} \int s(t) \Psi^*(s_0^{-j} t - k\tau_0) dt \quad (3)$$

일반적으로  $s_0$ 와  $\tau_0$ 의 값은 2와 1을 사용한다. 마더 웨이블렛의 형태는 Morlet, Haar, Shannon, Meyer, Daubechies 등 만들어 낸 사람들에 따라 다양하며, 각각의 마더 웨이블렛이 가지고 있는 신호 분해의 특성과 장점에 따라 응용되는 분야는 다르다[14,15].

#### 3.2 통계 기법

웨이블렛 변환을 이용하여 안테나에 의해 측정된 신호의 특성을 대략적으로 파악할 수 있지만 부분방전은 다양한 환경에서 발생하고 명확히 구분되지 않을 수도 있다. 이러한 부분방전을 판정하기 위해서는 많은 데이터를 취득한 후 적절한 패턴 분류 방법을 이용해야 한다. 패턴 분류의 정확도는 패턴 분류 방법 뿐만 아니라 패턴 분류기에 입력할 데이터의 특성에도 상당한 영향을 받는다.

본 논문에서는 웨이블렛 변환으로 측정된 파형을 시간과 주파수 영역으로 나누었지만 패턴 분류기에 입력할 데이터 양이 많고, 코로나 방전과 연면 방전의 특성이 명확하게 구분되지 않는다. 따라서, 입력 데이터 수도 줄이고 코로나 방전과 연면 방전의 구분을 용이하게 하기 위하여 통계적인 기법을 적용하였다.

웨이블렛 변환을 하면 원래의 파형이 주파수 영역별로 나누어지게 되는데 본 논문에서는 전체를 이용하기보다는 평균값, 표준편차, 총합, 왜도율, 첨도율을 이용하였다. 평균, 표준편차, 총합은 절대적인 크기에 있어 부분방전 유무를 위해 적용하였고, 왜도율과 첨도율은 코로나 방전과 연면 방전의 구분을 위해 적용하였다.

왜도율과 첨도율은 어떤 분포의 비대칭도를 나타낼 때 사용하는 방법이다. 왜도율은 자료분포의 기울어진 방향과 정도를 나타내는 값이다. 왜도 계수값이 클수록 비대칭도는 커져서 자료의 분포가 한쪽으로 치우치게 되는데 왜도 계수가 양의 값을 가질 경우는 오른쪽 꼬리분포가 되고, 음의 값을 가질 경우는 왼쪽 꼬리분포가 된다(정규분포의 왜도는 0이다). 왜도의 계수값이 큰 양의 값을 갖는다는 것은 정규분포

곡선이 왼쪽으로 치우쳐서 대다수의 값들이 평균 이하지만 몇몇 값들이 상당히 크다는 것을 의미한다. 이것은 또한 전자파 과형에서 부분방전의 발생과 특성을 알 수 있다는 것을 의미한다[17].

첨도율은 분포가 얼마나 중심에 집중되어 있는가를 볼 때 사용된다. 보통 첨도의 값이 3이면 정규분포이고, 3보다 큰 경우는 정규분포보다 높은 봉우리를 가지며, 3보다 작을 경우 정규분포보다 낮은 봉우리를 갖는다. 웨이블렛과 마찬가지로 첨도율도 분포의 형태에 따라 부분방전의 발생과 특성을 알 수 있다[17].

본 논문에서는 웨이블렛 변환을 이용하여 각 주파수 영역 별로 과형을 분리한 후 통계적 기법을 적용하여 각 과형들의 분포 특성을 추출하였다. 추출된 입력 데이터를 이용하여 부분방전의 유무와 형태를 분리하기 위하여 다음 절에 소개될 자율 신경망 모델인 자기-조직화 형상 지도를 이용한다.

### 3.3 자기-조직화 형상 지도

신경망은 크게 지도 학습형과 자율 학습형으로 나누어진다. SOFM은 입력 패턴에 대하여 정확한 해답을 미리 주지 않고 스스로 학습하는 자율 학습형 신경망이다. SOFM은 오차 역전파 알고리즘의 신경망과는 달리 계층적인 네트워크가 아니며 그림 7에서 보는 바와 같이 2개의 층으로 이루어져 있다. 코호넨 네트워크의 첫 번째 층은 입력층이고 두 번째 층은 경쟁층이다. 또한 네트워크의 모든 연결은 첫 번째 층에서 두 번째 층의 방향으로 되어 있으며, 두 번째 층은 서로 완전히 연결되어 있다[18].

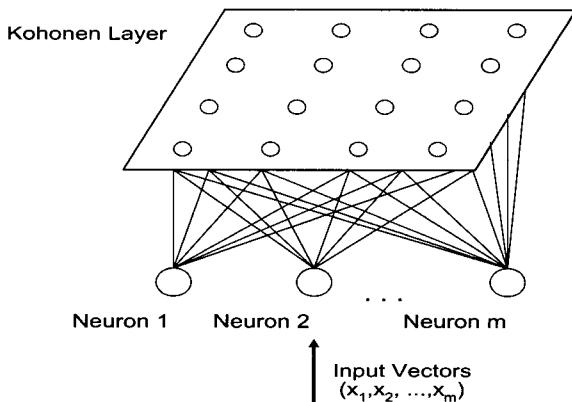


그림 7 SOFM의 구조  
Fig. 7 Structure of SOFM

SOFM의 학습 과정에서 각 뉴런은 연결 강도 벡터와 입력 벡터가 얼마나 가깝게 존재하는지를 계산한다. 그리고 각 뉴런들은 학습할 수 있는 특권을 부여받기 위해서 서로 경쟁하는데 입력 벡터와 가중치 벡터간의 거리가 가장 가까운 뉴런이 승리하게 된다. 이 승자 뉴런이 출력 신호를 보낼 수 있는 유일한 뉴런으로 존재한다. 또한 이 승자 뉴런과 이와 인접한 이웃 뉴런들만이 제시된 입력 벡터에 대해서 학습이 허용된다. SOFM의 학습 철학은 '승자 독점(winner take all)'으로써 승자 뉴런만이 출력력을 낼 수 있으며, 승자 뉴런과 그의 이웃 뉴런들만이 연결 강도를 조정할

수 있다.

승자 뉴런을 결정하고 난 후에는 SOFM의 학습 규칙에 따라 뉴런의 가중치를 조정해야 한다. 이 규칙은 다음 식으로 표현된다.

$$W_{\text{new}} = W_{\text{old}} + \alpha(X - W_{\text{old}}) \quad (4)$$

여기서,  $W_{\text{old}}$ 는 조정되기 이전의 가중치 벡터이며,  $W_{\text{new}}$ 는 조정된 후의 새로운 가중치 벡터이고,  $X$ 는 입력 패턴 벡터이며,  $\alpha$ 는 학습 상수이다.

SOFM은 가중치 벡터를  $n \times n$ 개의 형태로 놓고 승자 뉴런과 이웃 뉴런의 간섭 정도를 조정하여 같은 분류되는 패턴들이 2 차원 평면에서 군집을 이루게 하기 때문에 분류의 정확도를 높이면서 시각적으로도 결과를 쉽게 확인할 수 있다.

## 4. 부분방전 신호의 검출

### 4.1 웨이블렛 변환의 적용

웨이블렛 변환의 방법 중에서 이산 신호에 대해 적합한 Daubechies의 웨이브렛을 안테나로 측정한 전자파에 적용하였다. Daubechies의 웨이블렛은 다운 샘플링 방법으로 원신호를 적용하며 분석을 할 수가 있다. Daubechies의 마더 웨이블렛은 여러 개의 단위함수를 가지고 있으며, 신호의 분석에 따라서 적절한 적용이 필요하다. 본 논문에서 사용한 마더 웨이블렛은 db3을 사용하였다. db3의 특성으로는 3개의 탭(tap)과 6개의 이산 샘플링을 가지고 있고, 본 논문에서 사용한 6개의 웨이블렛 계수의 값은 (0.2352, 0.5706, 0.3252, -0.0955, -0.0604, 0.0249)이다. 또한 각 계수의 주파수 성분은 전체 샘플링 주파수가  $f_s$ [Hz]라고 하면,  $n$ 차 단계까지의 웨이블렛 변환을 수행하였을 때 주파수 분포는 다음과 같다.

$$D_n = \frac{f_s}{2^n} \sim \frac{f_s}{2^{n+1}} [\text{Hz}] \quad (7)$$

안테나로 측정된 부분방전의 신호는 오실로스코프에서 100[MHz] 샘플링 주파수로 샘플링을 하였다. 데이터의 개수는 502개를 취득하였으며, 이를 이용하여 컴퓨터 상에서 웨이블렛 분해를 하였다. 측정된 신호는 상세계수 8까지 분해하였다. 그림 4, 5, 6에 나온 과형들은 웨이블렛 변환을 이용하여 그림 8, 9, 10처럼 시간-주파수 영역 상에 나타내었다[16].

전압만 인가하여 노이즈를 측정한 그림 8에서는 계속 변화없는 모습을 보여주어 부분방전이 일어나지 않았음을 보여준다. 그림 9에서 침대 평판 전극으로 발생시킨 코로나 방전은 순간적으로 부분방전이 발생했다가 급격히 소멸하는 것이 보이며, 그림 10에서는 평판 대 평판 전극으로 발생시킨 연면 방전이 갑자기 소멸되지 않고 계속 이어지는 것을 볼 수 있다. 그림 8, 9, 10에서 시각적으로 각 그림의 차이점을 볼 수 있지만 모든 값을 패턴 분류를 위해 사용할 수 없기 때문에 다음의 통계적인 기법을 적용하여 패턴 분류를 위한 데이터 선처리 과정을 거친다.

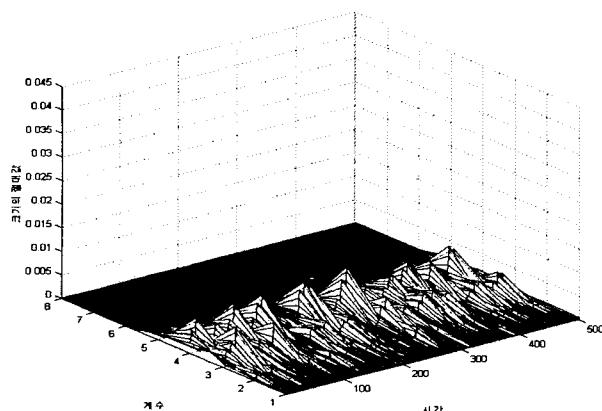


그림 8 노이즈 파형의 웨이블렛 변환

Fig. 8 Wavelet transform of a noise wave

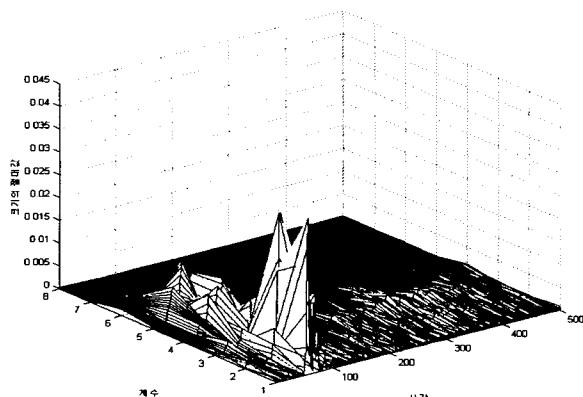


그림 9 코로나 방전 파형의 웨이블렛 변환

Fig. 9 Wavelet transform of a corona discharge wave

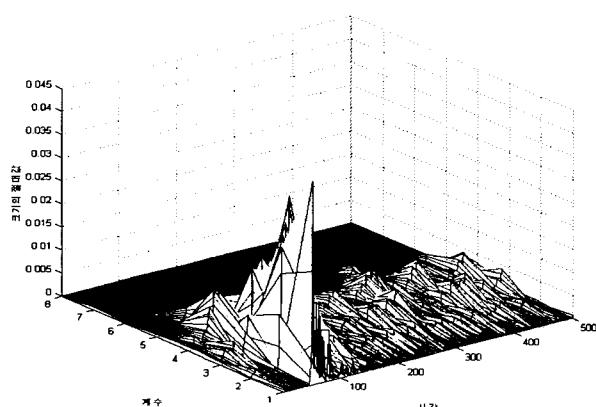


그림 10 연면 방전 파형의 웨이블렛 변환

Fig. 10 Wavelet transform of a surface discharge wave

#### 4.2 통계 기법의 적용

앞서 설명한 것처럼 원래의 파형은 8개의 주파수별 파형과 하나의 웨이블렛 기저 함수를 가진다. 그림 4, 5, 6의 파형에 웨이블렛 변환을 적용하여 그림 8, 9, 10를 얻었고, 여기에 평균, 표준편차, 합, 왜도율, 첨도율을 적용하여 그림 11에서 15까지 나타내었다.

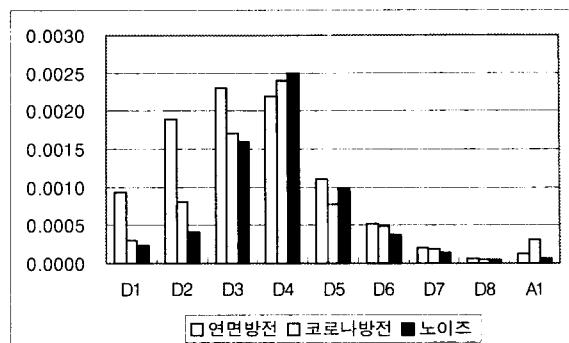


그림 11 웨이블렛 파형의 평균

Fig. 11 Mean of wavelet waves

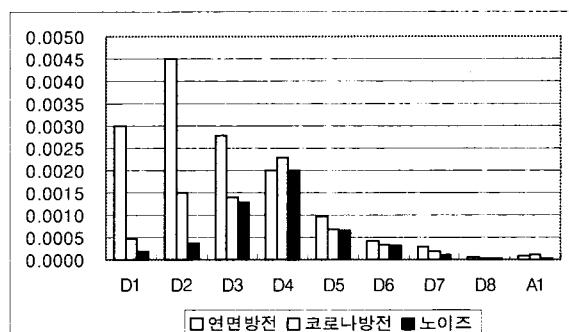


그림 12 웨이블렛 파형의 표준편차

Fig. 12 Standard deviation of wavelet waves

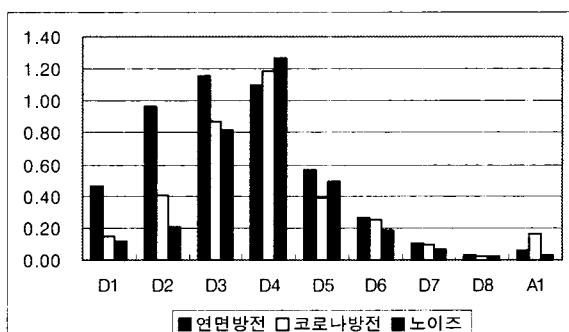


그림 13 웨이블렛 파형의 전체 합

Fig. 13 Sum of wavelet waves

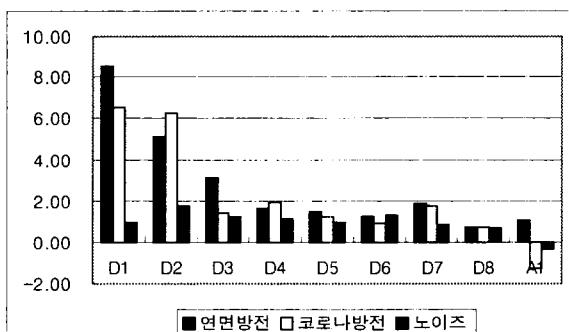


그림 14 웨이블렛 파형의 왜도율

Fig. 14 Skewness of wavelet waves

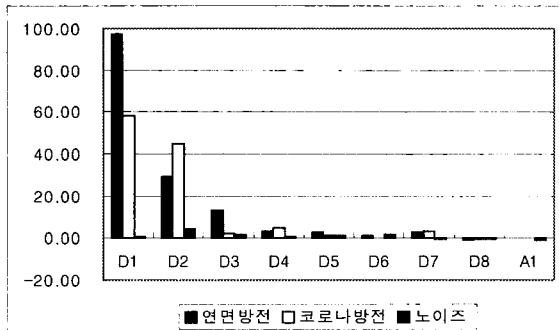


그림 15 웨이블렛 파형의 침도율

Fig. 15 Kurtosis of wavlet waves

그림 11부터 15까지에서 상세계수  $D_1$ 부터  $D_8$ 까지 8개의 주파수별 파형과 근사계수  $A_1$ 을 통해 부분방전 유무와 형태에 따른 차이를 알 수 있다. 노이즈는 비교적 구분이 쉽고, 코로나 방전과 연면 방전의 경우도 차이가 있음을 알 수 있다. 실험실의 조건과 방전량에 따라 각 통계값들이 변하지만 각 카테고리별로 가지고 있는 특성을 크게 변하지 않기 때문에 다음의 신경망을 통해 특징을 추출하여 패턴을 분류한다.

#### 4.3 SOFM의 적용

안테나를 통해 얻은 전자파를 시간-주파수 영역 상으로 표현하기 위해 웨이블렛 변환을 적용하였고, 변환된 값들의 특성을 뚜렷이 하기 위해 앞서 설명한 통계적인 기법을 도입하였다. 웨이블렛 변환을 통해 하나의 전자파 파형은 9개의 파형을 갖게 되고, 각각 평균값, 표준편차, 전체합, 왜도율, 침도율별로 5개의 값을 갖게 되어 모두 45개의 값을 갖게 된다. 45개의 값은 하나의 입력 패턴이 되며, 신경망의 입력 벡터로 사용된다.

본 논문에서는 전압만 인가한 노이즈, 침대 평판을 통해 발생시킨 코로나 방전, 평판 대 평판을 통해 발생시킨 연면 방전을 구분하기 위해 각각 50개씩의 데이터를 취득하여 150개의 입력 패턴을 SOFM 학습용으로 만들었다. 테스트를 위해 각각 20개씩 더 취득해 60개의 테스트용 데이터를 만들어 학습된 신경망의 결과를 점검하였다.

신경망의 학습은 3.3절에서 설명한 식 (4)을 적용하면 되고, 여기에 사용되는  $a$ 는 다음 식 (5)으로 정의한다.

$$\alpha = \frac{\alpha_0 \exp(-\frac{t}{\tau})}{1+d} \quad (5)$$

여기서,  $\alpha_0$ ,  $t$ ,  $\tau$ ,  $d$ 는 초기 가중치, 반복횟수, 가중치 감소 상수, 이웃의 크기를 나타낸다.  $\alpha_0=0.99$ ,  $t=1000$ ,  $\tau=300.0$ ,  $d=5$ 로 학습을 시켰으며, 반복횟수  $t$ 가 증가함에 따라 가중치가 계속 감소하여 학습이 진행될수록 생긴되는 값이 작아진다. 가중치 벡터를 생신할 수 있는 권리는 승자 뉴런과 이웃한 뉴런인데 이웃 뉴런은 승자 뉴런과 거리가 멀어질수록 식 (5)에 보는 것처럼 작은 값의 생신만 허용된다. 처음에 이웃 크기 5로 시작하여 200번의 반복 후에 1씩 감소하도록 하였다. 식 (5)에 따라 학습이 종료될 시점에는 승자 뉴런만 아

주 작은 값의 가중치 생신을 하게 되어 패턴 분류가 완성된다.

본 논문에서는 가로, 세로 6개의 가중치 벡터를 가져 총 36개의 가중치 벡터로 이루어진 경쟁층과 45개의 입력 벡터를 가진 입력층을 이용하여 학습을 하였다. 학습이 끝난 후 150개의 입력 패턴마다 유클리드 거리가 가장 가까운 가중치 벡터를 결정하였고, 각 가중치 벡터별로 많이 선택된 카테고리가 가중치 벡터의 특성을 가지게 된다. 본 논문에서는 신경망 학습 이전에 웨이블렛 변환과 통계적 기법을 이용하여 입력 벡터의 선처리를 했기 때문에 가중치 벡터를 결정할 때 겹치는 일이 없었으며, 가중치 벡터는 그림 16처럼 결정되었다.

(1,1)	C	(1,2)	C	(1,3)		(1,4)	N	(1,5)	N	(1,6)	N
6		9				11		10		9	
(2,1)	C	(2,2)	C	(2,3)	C	(2,4)	N	(2,5)	N	(2,6)	N
3		4		1		7		5		8	
(3,1)	C	(3,2)	C	(3,3)		(3,4)	T	(3,5)	T	(3,6)	
1		4				1		4			
(4,1)	C	(4,2)	C	(4,3)	T	(4,4)	T	(4,5)	T	(4,6)	T
5		3		1		5		4		3	
(5,1)	C	(5,2)	C	(5,3)	T	(5,4)	T	(5,5)	T	(5,6)	T
4		2		1		5		7		7	
(6,1)	C	(6,2)	C	(6,3)	T	(6,4)	T	(6,5)	T	(6,6)	T
6		2		1		2		2		7	

그림 16 SOFM의 결과

Fig. 16 Result of SOFM

그림 16에서 괄호 안의 숫자는 가중치 벡터의 가로, 세로 번호를 나타내고 괄호 옆의  $N$ ,  $C$ ,  $T$ 는 각각 노이즈, 코로나 방전, 연면 방전을 나타낸다. 밑의 숫자는 입력 벡터가 그 가중치 벡터를 승자 뉴런으로 선택한 개수이다. 즉 가중치 벡터 (1,1)는 침대 평판 전극으로 얻은 과정 6개와 유사한 특성을 갖는다는 것을 의미한다. 만약 새로운 입력 패턴이 생겨서 이 입력 패턴과 가장 가까운 가중치 벡터가 (1,1)이라면 이 입력 패턴은 코로나 방전이라고 간주하면 된다. SOFM은 승자 뉴런의 이웃 뉴런도 가중치를 생신할 수 있도록 하기 때문에 비슷한 특성을 가진 가중치 벡터가 그림 16에서처럼 군집을 이루게 되어 각 카테고리 별로 구별하기가 쉽다.

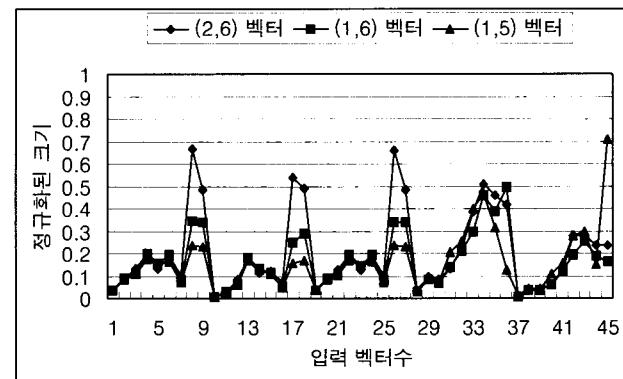


그림 17 노이즈 특성을 가진 가중치 벡터

Fig. 17 Weight vectors with the noise property

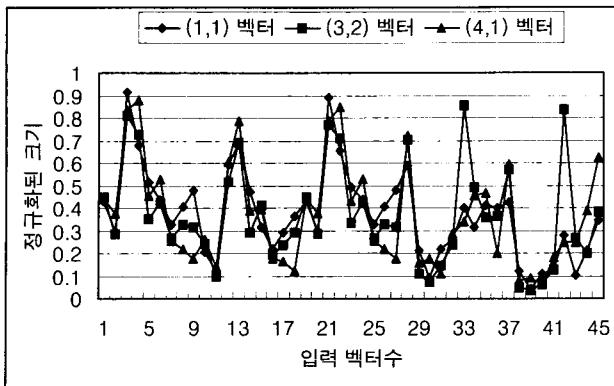


그림 18 코로나 방전 특성을 가진 가중치 벡터

Fig. 18 Weight vectors with the corona discharge property

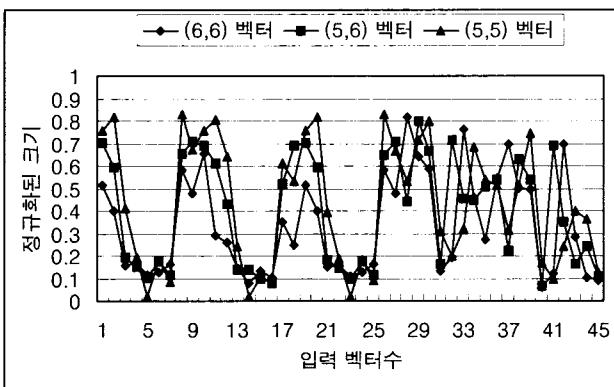


그림 19 연면 방전 특성을 가진 가중치 벡터

Fig. 19 Weight vectors with the surface discharge

패턴 분류의 결과와 함께 어떠한 특성을 바탕으로 각 카테고리별로 분류되었는지를 살펴보는 것도 중요한 사항이다. 그림 15에 보이는 각 가중치 벡터는 입력 패턴들의 군집의 중심에 해당하기 때문에 가중치 벡터의 값들을 보면 150개의 입력 패턴이 어떤 특성을 바탕으로 분류되었는지를 알 수 있다. 이를 보이기 위해 각 카테고리 별로 3개의 가중치 벡터를 임의로 선택하여 그림 17, 18, 19에 나타내었다.

그림 17, 18, 19에서 평균, 표준편차, 총합, 웨도율, 첨도율 순으로 웨이블렛 변환을 통해 얻은 9개씩의 값들이 나타난다. 노이즈의 경우 별다른 특징을 보이지 않아 쉽게 구분이 가능하다는 것을 알 수 있다. 코로나 방전과 연면 방전의 경우 평균, 표준편차, 총합 부분에서도 다르고, 웨도율, 첨도율에서 많은 차이를 보이는 것을 볼 수 있다. 코로나 방전의 웨도율과 첨도율은 방전이 순간적으로 일어난 후 사라지기 때문에 굴곡과 차이가 심한데 반해 연면 방전의 경우 완만한 상승과 하강을 하여 방전이 코로나 방전때보다 지속되는 것을 보여준다.

학습과 각 가중치 벡터의 특성 부여가 끝난 후 제대로 분류를 할 수 있는지를 알아보기 위해 각 카테고리 별로 20개 씩 총 60개의 테스트 데이터를 이용하여 분류한 결과 60개 데이터 모두 정확히 분류되었다. 모든 테스트 데이터가 정확히 분류된 것은 뛰어난 패턴 분류 능력을 보여주는 SOFM과 신경망 학습 이전의 선처리 과정이 전자파 파형의 특성에 적합하게 이루어진 결과로 볼 수 있다. 또한 노이즈가 적고 항

상 비슷한 조건을 유지하는 실험실에서 얻은 데이터이기 때문에 비교적 쉽게 분류할 수 있었던 것으로 생각된다.

본 논문에서 부분방전 유·무와 형태에 따른 패턴 분류를 하여 좋은 결과를 얻었고, 패턴 분류에 필요한 특성도 알아보았다. 실험실 수준과 한정된 조건에서 취득한 데이터를 바탕으로 패턴 분류를 했기 때문에 현장 적용에는 보다 많은 실험과 시뮬레이션이 필요하겠지만 비교적 가격이 싸고 장소의 구애를 받지 않는 안테나로 좋은 결과를 얻어 앞으로 많은 활용이 기대된다.

## 5. 결 론

본 논문에서는 안테나로 취득한 전자파를 이용하여 밀집형 전력설비에서 발생한 부분방전을 측정하고 절연열화를 감시할 수 있는 방법을 제시하였다. 실험실 내에서 코로나 방전, 연면 방전을 발생시켜 얻은 데이터를 웨이블렛 변환을 이용하여 시간-주파수 영역의 값으로 변환하였으며, 통계적인 기법을 적용하여 방전 형태에 따른 특성값을 추출하였다. 자율 학습형 신경망인 자기-조직화 특성 맵을 이용하여 부분방전 유무와 형태에 따른 분류를 하였으며, 실험실에서 취득한 학습용 데이터와 테스트 데이터를 이용하여 좋은 결과를 얻을 수 있었다. 실험실이 아닌 다양한 환경의 현장에서 데이터를 취득하고 노이즈에 대한 적절한 조치가 취해진다면 현장에서도 충분히 적용할 수 있을 것으로 기대된다.

### 감사의 글

본 연구는 전기연구원의 연구비 지원으로 수행되었음.

## 참 고 문 현

- [1] 곽희로, 정찬수, 전희종, 김재철, 한민구, 구자윤, 전력설비의 사고예방 및 진단기술(1차년도보고서), 기초전력공학연구소, 1992. 10.
- [2] M. Hu, X. Jiang, H. Xie, and Z. Wang, "A New Technique for Extracting Partial Discharge Signals in On-Line Monitoring with Wavelet Analysis", IEEE Electrical Insulating Materials, Proceedings of 1998 International Symposium, pp. 677-680, 1998.
- [3] M. Kawada, Z. Kawasaki, and M. Kenji, "Time-Frequency Analysis of E-M signals Emitted from a Partial Discharge Occurring in GIS using Wavelet Transform", IEEE Transaction on Power Delivery, Vol. 15, No. 2, pp. 57-60, April 2000.
- [4] M. Hikita and H. Okubo, "Electromagnetic Noise Spectrum Caused by Partial Discharge in Air at High Voltage Substation", IEEE Transaction on Power Delivery, Vol. 13, No. 2, pp. 434-439 April 1998.
- [5] K. Weck and F. Weinel, "Noise Reduction in On-Site Partial Discharge Measurement by the Use of the Transfer Function", European Transaction on Electrical Power, Vol. 8, No 4, pp. 229-304, July/August 1998.
- [6] Z. Li, Y. Feng J. Chen, and X. Zheng, "Wavelet

Analysis Used in UHF Partial Discharge Detection in GIS", IEEE Power System Technology, Proceedings. POWERCON '98. 1998 International Conference, Vol 1, pp. 163-166, 1998.

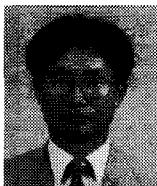
- [7] E. Lalitha and L. Satish, "Wavelet Analysis for Classification of Multi-source PD Patterns", IEEE Transaction on Dielectrics and Electrical Insulation, Vol. 7, No. 1, pp. 40-47, February 2000.
- [8] X. Ma, C. Zhou, and I.J.Kemp, "PD Pulse Propagation Studies using the Wavelet Transform". Electrical Insulation and Dielectric Phenomena, 2000, Annual Report Conference, Vol. 2, pp. 626-629, 2000.
- [9] 이현동, 이광식, 이동인, "이산 웨이블렛변환에 의한 부분 방전패턴 분석", 한국조명·전기설비학회 논문지, 제 15 권, 1호, pp. 84-89, 2001. 1.
- [10] E. Carminati, L. Cristaldi, M. Lazzaroni, A. Monti, "Partial Discharge Mechanism Detection by Neuro-Fuzzy algorithm", IEEE Instrumentation and Measurement Technology Conference, IMTC/98, pp. 744-748, May 18-21, 1998.
- [11] 박재준 "변압기 부분방전 발생패턴인식에 의한 열화진단" 기초전력공동연구소, 최종보고서, 9, 2000
- [12] IEC 270 "Partial discharge measurement"
- [13] T. Okamoto, N. Hozumi and T. Imajo, "Partial Discharge Pattern Recognition for Four Kind of Electrode Systems", IEEE International Symposium on Electrical Insulation, Baltimore, USA, pp. 375-378, June 1992.
- [14] A Primer, Introduction to Wavelets and Wavelet Transforms. Prentice-Hall International, Inc.
- [15] Y. Tang, L. Yang, J. Liu. and M. Ma, "Wavelet Theory and It's Application to Pattern Recognition" World scientific. 2000.
- [16] The Math Works Inc, Wavelet Toolbox For Use with MATLAB.
- [17] 박대철, 공학도를 위한 확률 통계, 인터비전, 2001.
- [18] S. Abhiit and B. Robert, Pattern Recognition with Neural Networks in C++, CRC Press. 1996.

## 저 자 소 개



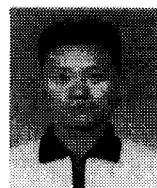
김 영 노 (金 泳 魯)

1974년 1월 14일생, 1999년 서남대 전기공학과 졸업, 2002년 송실대 대학원 전기공학과 졸업(석사), 현재 (주)피에스디테크 연구원  
E-mail : kyn134@psdtech.com



김 재 칠 (金 載 哲)

1955년 7월 22일생, 1979년 송실대 전기공학과 졸업, 1983년 서울대 대학원 전기공학과 졸업(석사), 1987년 서울대 대학원 전기공학과 졸업(공박), 1988년~현재 송실대 공대 전기공학과 교수.  
E-mail : jckim@ee.ssu.ac.kr



서 인 철(徐 實 喆)

1974년 5월 15일생 1997년 송실대학교 전기공학과 졸업(학사) 2002년 송실대학교 일반 대학원 전기공학과 졸업(석사) 2002년 5월 현재 한국동서발전(주) 발전부 근무



전 영 재 (田 永 在)

1972년 6월 30일생, 1995년 송실대 전기공학과 졸업, 1997년 송실대 대학원 전기공학과 졸업(석사), 2001년 동 대학원 전기공학과 졸업(공박), 현재 송실대 공대 시간강사.  
E-mail : anneal@dreamwiz.com



김 광 화(金 光 和)

1956년 5월 12일생. 1983년 부산대 대학원 전기공학과(석사). 1992년 부산대 대학원 전기공학과(공박). 1993년~현재 한국전기연구소 신전력기기 연구그룹 책임연구원  
Tel : 055-280-1570,  
Fax : 055-280-1589  
E-mail : khkim124@keri.re.kr