

부분방전 펄스파형의 시간-주파수분포를 이용한 기중부분방전원의 식별

論 文

54C-7-7

Discrimination of Air PD Sources Using Time-Frequency Distributions of PD Pulse Waveform

李 剛 遠[†] · 姜 聲 華^{*} · 林 基 祚^{**}

(Kang-Won Lee · Seong-Hwa Kang · Ki-Joe Lim)

Abstract – PD(Partial Discharge) signal emitted from PD sources has their intrinsic features in the region of time and frequency. STFT(Short Time Fourier Transform) shows time-frequency distribution at the same time. 2-Dimensional matrices(33×77) from STFT for PD pulse signals are a good feature vectors and can be decreased in dimension by wavelet 2D data compression technique. Decreased feature vectors(13×24) were used as inputs of Back-propagation ANN(Artificial Neural Network) for discrimination of Multi-PD sources(air discharge sources(3), surface discharge(1)). They are a good feature vectors for discriminating Multi-PD sources in the air.

Key Words : PD, STFT, Wavelet 2D, ANN

1. 서 론

방전현상은 초기전자의 방출에 의한 전자사태에 의해 유발되며, 발생된 전자는 주변 기체원자들과 충돌하여 이온들을 형성시킨다. 전자와 이온들의 발생과 재결합 및 음극 및 양극에서의 2차 전자방출등에 의해 방전전하의 분포가 변하게 되며, 또한 분포는 방전이 발생되는 전극구조에 따른 전계분포, 주위기체의 종류, 그리고 전달매질의 상태등에 의해 변화하게 되며, 변화된 방전전하분포 즉 방전전하의 발생과 소멸들의 차이는 전류신호의 변화, 방전광의 변화, 방전음의 변화, 방사전자기파의 변화등을 유발하며, 이러한 물리적 양들을 측정하는 센서의 출력에 변화를 준다. 일반적인 실험실에서의 방전측정방법으로서는 전류의 변화를 측정하는 방법이 주로 사용되며, IEC에 의해 측정방법등이 규격화되어졌다.[1,2] 그러나 실제 전력기기등이 사용되는 현장에서는 측정자의 안전등을 고려하여 방전광, 방전음, 방전전자기파등으로 측정하는 방법이 주로 사용되고 있다.[3,4] 그러나 방전광 및 방전음의 측정은 실제 현장에서 방전광 및 음이 센서에 전달되는 경우, 전파되는 경로 및 매질들에 의하여 크게 영향을 받으며, 또한 실제 방전전하량과의 연관성을 밝히는데 어려움이 있다. 현재 이러한 방전광 및 방전음에 대한 측정은 발생 그 자체에 대한 부수적인 측정방법으로서 주로 사용되고 있는 실정이다. 이와는 달리 방전시 방사되는 전

자기파에 대한 측정은 외부 노이즈에 의한 영향이 적고, 또한 피측정체와 거리를 두고 측정할 수 있어 안전적이며, 전파매질 및 경로에 의한 영향이 앞의 두경우보다 적다는 이점이 있어, 현재 사용되는 대전력기기에서의 사고예방을 위한 측정방법으로 많이 사용되고 있다. 대전력기기의 결함들에 의한 방전원의 종류는 매우 다양하므로 이를 정확히 분류하는 일은 방전의 발생원인을 알기위해 매우 중요한 과정으로서 이러한 분류를 위한 방법으로는 현재 신경회로망등의 인공지능적인 방법들이 많이 사용되고 있다.[5] 그러므로 본 논문에서는 광대역 안테나를 이용하여 방전원들로부터 발생된 전자기파를 측정하고, 측정된 시간상의 1차원적인 신호에 대해 STFT를 적용하여 시간-주파수분포의 2차행렬구조의 데이터로 변환하여 각 방전원들에 대한 구별정도를 살펴보고, 구해진 2차행렬에 대해 wavelet2D 데이터압축기술을 이용하여 특징벡터의 차원을 감소시켰고, 차원이 감소된 특징벡터를 역전파학습에 의한 신경회로망의 입력으로 사용하여 4가지 방전원들에 대한 분류가능성을 확인하였다.

2. 본 론

2.1 STFT(short time fourier transform)과 wavelet 압축

2.1.1 STFT(short time fourier transform)

일반적으로 음성의 분석에 사용되어 왔던 STFT(Short-Time Fourier Transform)은 식 (1)과 같이 정의된다.

$$STFT(\tau, f) = \int x(t)\omega^*(t-\tau)e^{-2\pi ft} dt \quad (1)$$

[†] 교신저자 正 會 員 : 한국철도기술연구원 연구원

E-mail : wklee@krri.re.kr

* 正 會 員 : 충청대 소방안전과 부교수

** 正 會 員 : 충북대 공대 전기공학부 교수

接受日字 : 2005年 5月 11日

最終完了 : 2005年 6月 20日

STFT는 음성신호가 비정상적(non-stationary)인 성격이 강하므로 STFT를 사용하여 locally stationary하다고 생각되는 20~30[msec] 단위 구간으로 window를 취하고 데이터의 손실을 막기 위하여 window들 사이에 오버랩(overlap)을 취하여 분석하는 방법이다. 이러한 STFT는 single window analysis를 이용하여 분석하여 고정된 해상도(fixed resolution)을 갖게 되므로 시간 해상도와 주파수 해상도가 일정하게 결정되어 두 요소를 동시에 좋게 할 수 없다.

STFT의 기저함수는 $e^{j2\pi ft}$ 로서 음성신호의 경우에는 주파수 성분이 급격히 변하는 성질 때문에 그 주파수의 변화는 전체 스펙트럼에 걸쳐 널리 퍼진다. 광대역 안테나로 측정된 부분방전신호 또한 주파수성분이 변화하므로 시간에 따른 주파수변화로서 나타낼 수 있다. 시간-주파수분포에 대한 이차원적 계수를 특징벡터로 이용한다는 것은 부분방전신호의 시간의 흐름에 따른 동시적인 주파수변화특성을 이용하는 것과 마찬가지이므로 파형의 차이를 잘 나타낼 것으로 보인다.

2) 웨이블렛 압축

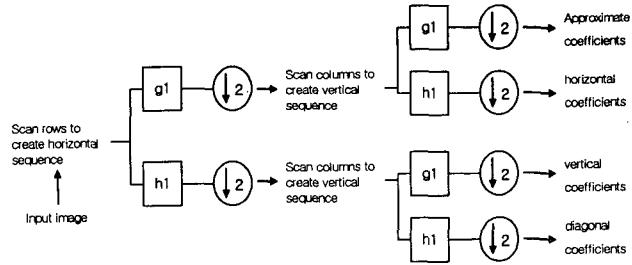
웨이블렛 변환(Wavelet Transform)은 식 (1)에서 보는 바와 같이 비주기적인 신호분리가 가능한 Daubechies, Coiflet, Haar, Symmlet 등과 같은 기저함수라 부르는 원형(prototype) 웨이블렛 $\psi(t)$ 을 정의하고, 이 원형 웨이블렛을 시간축으로 b만큼 이동(translation)시키고, a만큼 스케일링(scaling)하여 다양한 웨이블렛을 구성하여 신호를 분해한다.

$$\text{CWT}_x(b, a) = \frac{1}{\sqrt{a}} \int x(t) \psi\left(\frac{t-b}{a}\right) dt \quad (2)$$

웨이블렛 변환에서는 주파수라는 용어 대신 스케일이라는 용어를 쓰며 하나의 웨이블렛을 통과한 신호를 하나의 스케일의 상세신호(detail signal)라 한다. Scale factor a가 2보다 작아지면 기저함수는 시간축에서 좁아지며, 반면에 2보다 커지면 넓어진다. 따라서, 기저함수의 시간축 해상도를 조절할 수 있고, 시간축과 주파수축의 trade-off 성질에 따라 주파수 해상도 역시 조절할 수 있게 된다. 이것은 웨이블렛이 시간적으로 그 주파수 특성이 변하는 음성신호의 해석을 충분히 가능하게 하는 성질이다.

$$\text{WT} = \frac{1}{\sqrt{a}} \phi\left(\frac{t-b}{a}\right) \quad (3)$$

이산 웨이블렛 변환은 고역 통과 부분을 한 단계의 필터뱅크로 구성하고, 저역 통과 부분을 계속적인 필터뱅크로 확장하는 옥타브 밴드(octave-band) 구조와 고역 통과 부분도 필터뱅크로 확장하는 구조를 가지는 웨이블렛 패킷(wavelet packet)구조로 구현될 수 있다. 그림 1은 웨이블렛 2D의 기본 블록도를 보여주고 있으며, 압축원리는 웨이블렛 패킷구조와 동일하나, 영상 및 이차원분포의 데이터형태에 차이를 가지고 있다.



[MHz]이하에서 존재하는 부분방전신호의 주파수성분에 대한 측정이 가능한 광대역 안테나이다. 광대역 안테나의 주파수 대역은 30[kHz] - 2[GHz]으로서 부분방전측정에 적합하며, 다이폴 안테나의 일종인 모노폴 안테나의 형태를 가진다. 광대역 안테나를 이용하여 방전원으로부터 설정된 거리 만큼 떨어진 위치에서 전자파를 수신하며, 수신된 파형은 수[ns] ~ 수[μs]의 짧은 주기의 펄스신호이므로 이를 충분히 효과적으로 재생하기 위해서는 Nyquist의 조건을 따라 측정 주파수대역의 두배이상의 샘플링주파수가 필요하게 되어, 이에 적합한 디지털 오실로스코프(2[Gs/s], 5[GHz], Tektronix)를 사용하였다. 오실로스코프로 관찰 및 저장된 파형은 GPIB 및 플로피 디스크를 통하여 개인용 컴퓨터에 저장되었고, 저장된 파형데이터에 대해 STFT 및 웨이블릿 2D압축기술을 적용하여 특징을 추출하였고 추출된 특징을 신경회로망의 입력으로 사용하여 역전파학습을 이용한 신경회로망에 의한 분류를 행하였다.

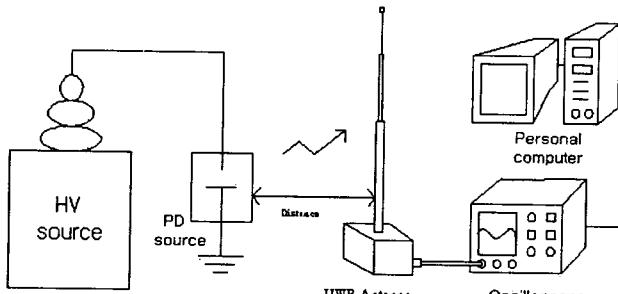
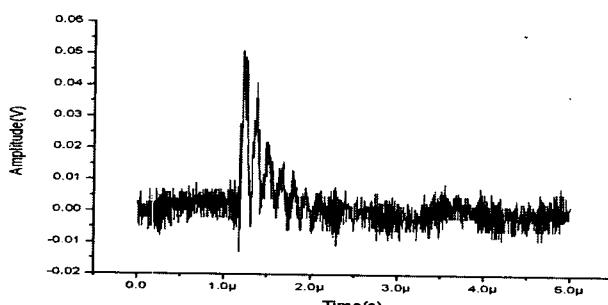


그림 2. 실험구성

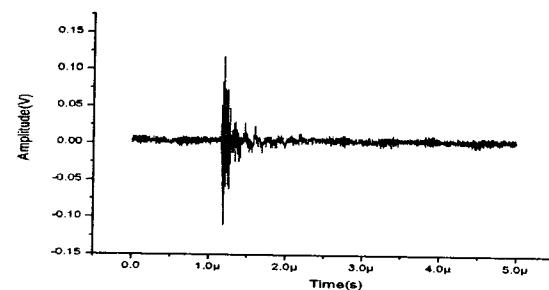
Fig. 2 Experimental configuration

2.3 실험결과 및 고찰

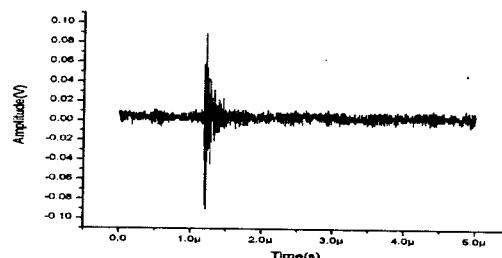
방전원으로부터 발생된 방전신호를 전계분포의 변화에 기인된 정전결합의 형태로서 안테나에 유기된 전압신호로서 측정하였다. 측정된 방전신호는 그림 3과 같이 시간에 따른 펄스신호의 형태를 가진 1차원적인 분포를 보여주며 이는 Fourier 급수전개에 의해 주파수분포로서 나타내어질수 있다. 측정된 신호파형은 주위 노이즈등의 영향으로 침대평판의 경우를 제외하고 금준 진동파형의 형태를 가지고 있어 그 구별이 육안으로는 모호하다는 것을 알수 있다.



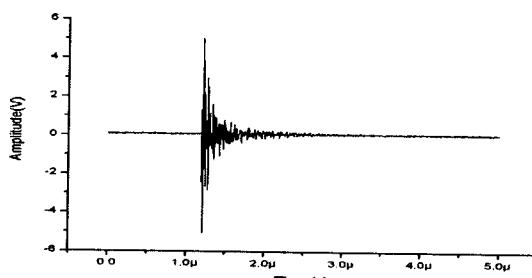
(a) needle - plane



(b) needle to sphere



(c) needle to needle



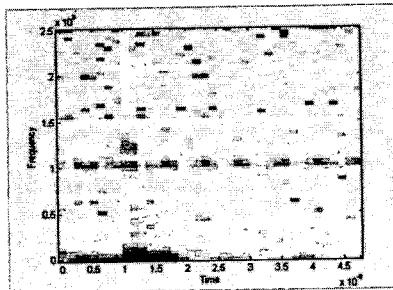
(d) surface discharge

그림 3. 부분방전원에 따른 UWB 안테나 신호의 파형과 FFT 결과

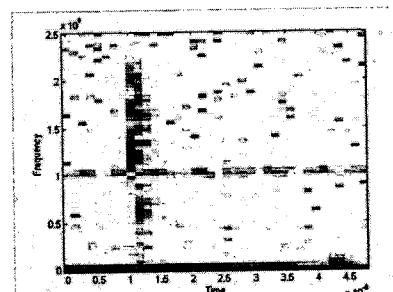
Fig. 3 waveforms and FFT results of UWB antenna signals according to PD sources.

그러나 이러한 1차원적인 분포를 통하여 얻어지는 정보는 방전신호가 보여주는 정보의 일부분으로 보여진다. 이러한 1차원적인 분포를 2차원분포로서 살펴본다면 방전신호가 가진 보다 많은 정보를 확인할수 있을 것으로 판단된다. 시간상 펄스신호에 대한 2차분포형태는 STFT(Short Time Fourier Transform), Wigner ville 분포, CWT(Continuous Wavelet Transfrom)등의 변환과정을 통하여 시간-주파수분포로서 보여질수 있다. 본 논문에서 방전원으로서 모의된 침대 평판, 침대침, 침대 구등의 기증방전 및 구대 평판전극 구조에서의 폴리에틸렌판상에서의 표면방전시 발생되어 측정된 방전펄스신호에 대해 현재 일반적으로 많이 사용되고 있는 STFT를 이용하여 시간-주파수분포로 나타내었다. 주파수부분은 0~2.5MHz를 75.7kHz씩 33개의 영역으로 구분하고 시간축에 대해 2500개의 데이터를 데이터수 64개씩 hanning window를 적용하여 77개의 데이터로 구성하여 시

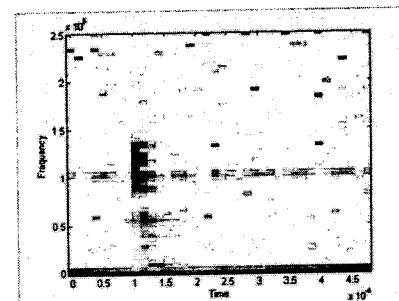
간-주파수분포를 33×77 의 행렬분포로서 구성하였다. 이렇게 구성된 분포를 각 방전원에 따라 나타낸 것이 그림 4로서 각 분포는 방전원에 따라서 다른 모습을 나타낸다는 것을 확인할 수 있었다. 분포에서 뚜렷이 나타나는 부분은 방전펄스신호가 발생한 부분으로서 각 부분에서의 모습은 각 방전원의 특징들을 보여주는 것으로 판단된다. 실제 측정된 부분방전신호는 주위 노이즈원에 의한 영향으로 본래의 방전파형에서 벗어난 단순한 진동감쇠파형으로서 보여졌으나 시간-주파수분포를 통하여 그 특징적인 모습이 구별되었다. 침대평판인 경우(그림4(a))는 주어진 주파수 분포에서 0.5MHz 이하 및 $1\text{MHz} \sim 1.5\text{MHz}$ 에서 주로 분포되어 있고, 침대구인경우(그림4(b))는 1.5MHz 이하의 전영역에서 주파수성분이 분포되어 있다는 것을 알 수 있으며, 침대침인 경우(그림4(c))는 저주파수 영역보다는 중간주파수부터 고주파수영역 까지 즉 $0.5\text{M} \sim 2.5\text{MHz}$ 까지 고르게 분포한다. 또한 표면방전(그림 4(d))의 분포는 기중방전보다 주파수성분크기가 크며 보다 넓은 펄스주기를 가지며, 1.5MHz 이하에서 주로 분포되어 있다는 것을 살펴볼수 있다. 그리고 각 분포에서 펄스신호가 나타난 부분이외에 어느 특정한 예를 들어 1MHz 의 주파수성분이 전시간영역에 걸쳐나타나는 것을 살펴볼수 있는데 이것은 방전원으로부터의 방전신호가 없는 경우, 주변노이즈에 의한 것으로 그림 5에서 노이즈신호에 대한 시간-주파수 분포로부터 확인할 수 있었다. 노이즈신호의 주파수분포는 어느 특정한 주파수들에서 주로 존재한다는 것을 알 수 있으며, 이러한 노이즈의 특성을 알고 노이즈를 제거한다면, 보다 정확한 부분방전신호의 측정이 가능할 것이다. 그림에서도 알수 있듯이 노이즈영역에서도 부분방전신호의 주파수 성분이 존재하므로 잘못된 노이즈필터를 이용하게 된다면 원 방전신호 또한 감쇄할 것이다.



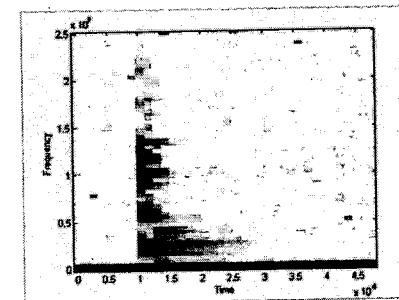
(a) Needle-Plane



(b) Needle-Needle



(c) Needle-Sphere



(d) Surface discharge

그림 4. 부분방전원에 따른 시간(sec)-주파수(Hz) 분포

Fig. 4 Time(sec)-Frequency(Hz) distribution according to PD sources

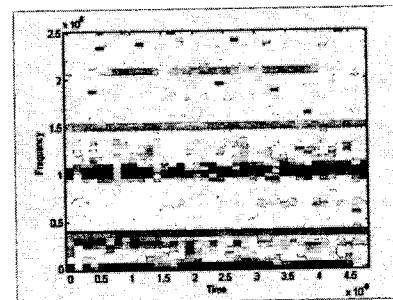


그림 5. 잡음의 시간(sec)-주파수(Hz) 분포

Fig. 5 Time(sec)-Frequency(Hz) distribution of noise

이러한 방전원들에 대한 시간-주파수분포가 방전원들의 구별을 가능하게 한다는 것을 확인하였다. 그러나 이러한 시간-주파수분포는 33×77 의 행렬로서 총 2,541개의 1차원데이터로 변환할 수 있고, 이러한 데이터를 특징값으로서 분류를 위한 신경회로망의 입력으로 사용할 수 있으나 학습시간의 지연 및 데이터저장용량이 커지게 되는 단점이 고려되므로 구해진 방전원들의 시간-주파수분포의 특징을 그대로 유지하며 데이터의 크기를 감소시키는 방법이 요구된다. 데이터를 압축시키는 방법으로서 본 논문에서는 wavelet2D 데이터 압축기술을 이용하였다. wavelet2D 데이터 압축기술은 현재 영상신호에 대한 데이터압축기술로서 널리 이용되고 있으며, 압축시 불필요한 노이즈성분도 효과적으로 제거할수 있는 특징을 가지고 있다. wavelet2D 데이터 압축기술에서

사용된 wavelet은 Daubechies wavelet 4이며, 33×77 의 원래의 시간-주파수분포는 wavelet 2D 압축에 의해 시간-주파수분포중 고주파성분들이 제거된 저주파성분들만의 행렬로 감소되어져 13×24 의 행렬 즉 312개의 데이터로 효과적으로 압축되었고 압축된 행렬을 신경회로망의 입력으로 이용하기 위하여 13×24 행렬에서 열의 마지막과 다음열의 첫 번째 행을 연속적으로 연결하여 1×312 의 1차원행렬로 변환하였다. 이들에 대한 그래프가 그림 6과 같이 보여진다.

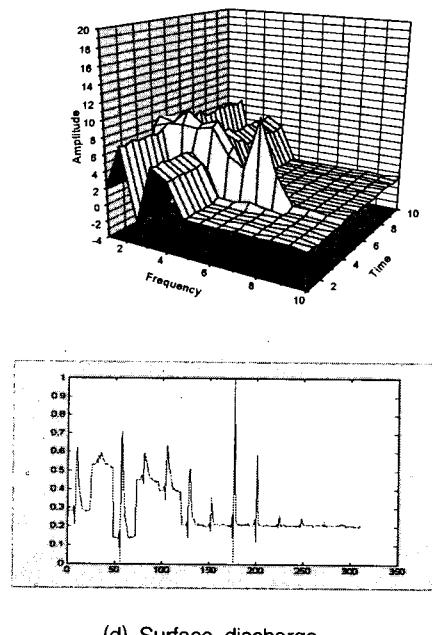
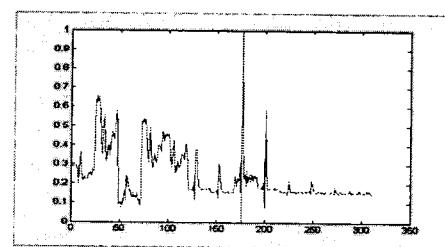
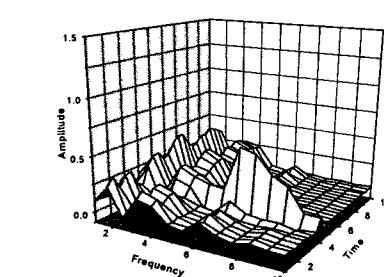
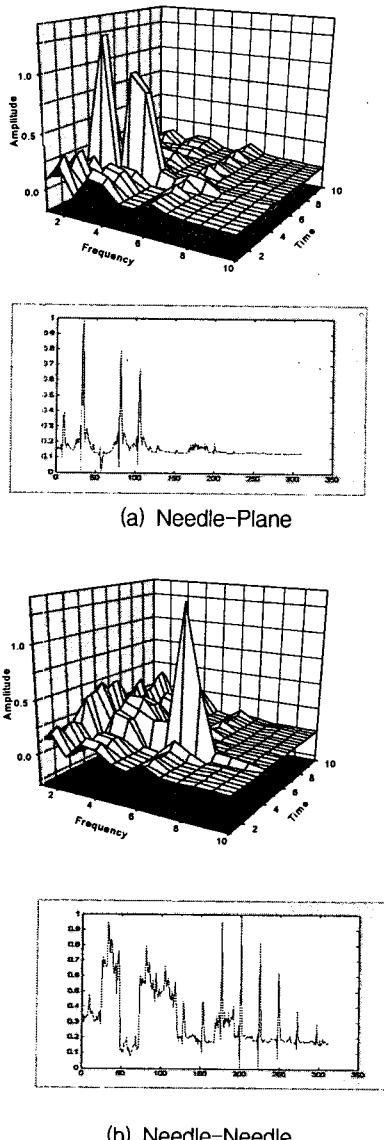


그림 6. 부분방전원에 따른 wavelet 2D의 압축결과

Fig. 6 Compression results of wavelet2D according to PD sources

그림 6의 맨위부터 침대평판, 침대침, 침대구, 표면방전순으로 압축된 3차원과 1차원데이터의 정규화된 그래프를 나타내고 있다. 구해진 정규화된 312개의 압축데이터는 방전원의 분류를 위하여 역전파학습을 이용한 신경회로망의 입력으로서 사용되었다. 역전파학습을 이용한 신경회로망은 일반적으로 패턴인식등과 같은 인공지능분야에서 가장 기초적이며 효과적인 방법으로서 널리 알려져 있다. 학습을 위한 훈련데이터는 각 방전원별로 50개씩 선택하였으며, 신경회로망의 학습에 대한 검증데이터로서 마찬가지로 각 방전원별로 50개씩 선택하였다. 신경회로망의 구조는 입력층(312), 은닉층(10), 출력층(2)으로 구성하였으며, 학습률은 0.01, 모멘텀은 0.1을 할당하였다. 그리고 일괄학습(batch 학습)을 이용하였으며, 학습반복횟수(epoch)는 가능한 많이 반복하면 할수록 RMSE(Root Mean Square Error)은 작아지나 실험결과로서 1000번정도가 적당하다는 것을 확인하였고, 1000번의 학습후 RMSE의 값은 0.13이었다. 사용된 전달함수는 쌍곡선 탄젠트전달함수(tanh)를 사용하였다. 그림 7은 1000회 학습동안 RMSE의 변화를 나타낸 것이다.

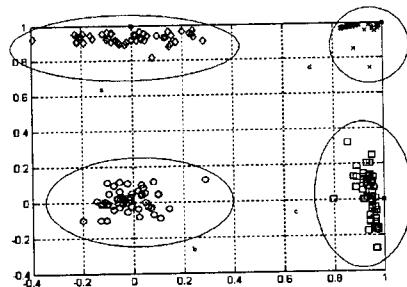
4. 결 론

노이즈환경 하에서 부분방전신호는 노이즈에 의한 영향을 받아 본래 신호파형과는 다른 왜곡된 파형을 보여주며, 이때 영향을 주는 노이즈를 제거하는 것은 또한 방전신호파형에 다른 왜곡을 줄 수 있다. 본 논문에서는 노이즈환경에 노출된 침대평판, 침대침, 침대평판등의 기중방전에 의한, 그리고 표면방전에 의한 방전현상에 대해 광대역으로 측정된 방전신호를 1차원적인 시간에 따른 파형이 아닌 시간과 주파수를 동시에 보여주는 2차원적인 시간-주파수분포를 STFT를 이용하여 구성하여 부분방전원 각각에 대한 서로 다른 모습을 보여준다는 것을 확인하였고, 33×77 의 행렬데이터를 wavelet2D 압축기술을 이용하여 13×24 의 행렬데이터로 압축한 후 이를 역전파학습에 의한 신경회로망의 입력으로서 부분방전원의 분류를 위해 사용하였다. 총 400개의 데이터를 이용한 신경회로망에 의한 부분방전원의 분류결과는 4개의 부분방전원을 거의 완전하게 분류할 수 있다는 것을 보여주었으므로 보다 많은 부분방전원들의 분류에도 효과적일 것으로 기대된다.

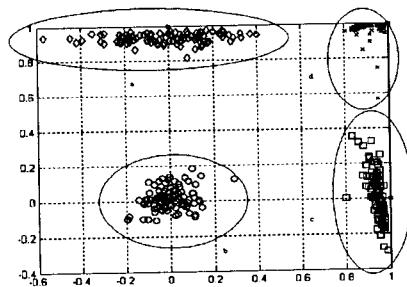
그림 7. RMSE 결과(1000 epoch, 0.13)

Fig. 7 RMSE results(1000 epoch, 0.13)

그림 8(a)와 (b)는 방전원분류결과를 보여주고 있다. 그림 8(a)는 훈련데이터의 학습결과이며, 그림 8(b)는 검증데이터에 대한 분류결과이다. 그림에서도 알 수 있듯이 방전원들의 분류는 약간의 흩어진 분포를 가지나 100% 정확하게 4가지로 분류되었다는 것을 알 수 있다.



(a) Result using Training data set



(b) Result using checking data set

그림 8. ANN에 의한 식별 결과

(a : 침대침, b : 침대평판, c : 침대구, d : 표면)

Fig. 8 Classification results by ANN

(a : Needle-Needle, b : Needle-Plane, c : Needle-Sphere, d : Surface)

참 고 문 헌

- [1] IEC Standard 60270, Partial Discharge Measurements, pp. 1-57, 1980
- [2] F. H. Kreuger, E. Gulski and A. Krivda, "Classification of Partial Discharge", IEEE Trans. Electrical Insulation, Vol. 28, No. 6, pp. 917-931, 1993.
- [3] L. E. Lundgaard, et al "Acoustic Diagnosis of Gas Insulated Substation; A Theoretical and Experimental Basis" IEEE Transactions on Power Delivery, Vol. 5, No. 4, November 1990.
- [4] Brian Hampton "UHF Diagnostics For Gas Insulated Substations"; High Voltage Engineering Symposium, IEE No. 467, 22-27 August 1999
- [5] E. Gulski, and A. Krivda, "Neural Networks as a Tool for Recognition of Partial Discharges", IEEE Trans. On Electrical Insulation. Vol. 28 No. 6, pp. 984-1001 Dec. 1993

저자 소개



이 강 원 (李剛遠)

1970년 2월 22일생. 1995년 충북대 전기공학과 졸업. 2005년 동 대학원 전기공학과졸업(공박). 2003년~현재 한국철도기술연구원 연구원

E-mail : wklee@krri.re.kr



임 기 조 (林基祚)

1973년 한양대 공과대학 전기공학 학사.
1986년 한양대 대학원 전기재료 박사.
1971~1981 국방과학연구소 연구원,
1983~현재 충북대학교 전기전자공학부 교수,
2005~현재 대한전기학회 C부문회 회장

E-mail : kjlim@chungbuk.ac.kr



강 성 화 (姜聲華)

1987년 충북대 전기공학과 졸업. 1997년 동 대학원 전기공학과 졸업(공박). 1991~1993 생산기술연구원, 연구원, 1998~1999 미국 MIT 고전압연구실 Visiting scientist, 1993~현재 충청대학 소방안전과 부교수
E-mail : shkang@ok.ac.kr