Genetic Algorithm을 이용한 부분방전 패턴인식 최적화 연구

김성일, 정승용, 구자윤, 장용무
한양대학교

A Study on Optimization of Partial Discharge Pattern Recognition using Genetic Algorithm

Seong-il Kim, Seung-yong Jung, Ja-yoon Koo, Yong-mu Jang
Hanyang University

Abstract - 본 논문은 부분방전(PD: Partial Discharge)의 패턴인식 확률 극대화를 목적으로 신경망(NN: Neural Network) 파라미터 중에서 은닉층 뉴런의 수, 모멘텀(momentum)의 Step size와 Decay rate 를 최적화하기 위하여 유전 알고리즘(GA: Genetic Algorithm)을 적용하였다. 실험적 연구의 대상으로서, GIS(Gas Insulated Switchgear)사고의 주요 원인으로 보고되어있는 결함들을 인위적으로 모의한 16개 Test cell을 이용하여 부분방전을 발생시켰다. 부분방전 신호는 본 연구팀이 개발한 센서를 이용하여 검출되어 데이터베이스가 구축되어 그로부터 추출된 학습 데이터들의 학습에 다음과 같은 5가지 신경망 모델이 적용되었다: Multilayer Perceptron (MLP), Jordan-Elman Network (JEN), Recurrent Network (RN), Self-Organizing Feature Map (SOFM), Time-Lag Recurrent Network (TLRN).

유전 알고리즘 적용 효율성을 분석하기 위하여 동일한 데이터를 이용하여 다음과 같은 두 가지 방법을 적용한 결과를 상호 비교하였다. 우선 상기 선택된 모델만 적용하였고 다른 하나는 상기 모델과 Genetic Algorithm이 동시에 적용되었다. 모든 모델에 대하여 학습오차와 패턴 분류 확률을 비교한 결과, 유전 알고리즘 적용 시 부분방전 패턴인식 확률이 향상되었음이 확인되어 향후 신뢰성 있는 GIS 부분방전 진단기술에 활용될 수 있을 것으로 사료된다.

1. 서 론

1980년대 중반에 들어와 초고압 전력설비의 절연 진단 목적으로 부분방전 검출을 위하여 다양한 방법들이 제안되어 일부 상업적으로 적용되었다. 특히 검출된 부분방전 신호의 패턴인식을 위하여 신경망 기법이 적용되고 있으나 복잡하고 많은 양의 계산이 요구되어 산업 활용에 많은 의문이 제기되어왔다. 그러나 90년대 중반부터 CPU 처리속도가 향상되고 새로운 알고리즘들이 제안되어 이를 이용한 연구가 활발하게 수행되었다. 그 중 하나의 방법으로서, 최근 5년 전부터 유전 알고리즘이 부분방전 패턴인식의 최적화에 적용 되었지만 연구결과가 보고된 사례는 매우 적다[1-2]. 또한, 패턴인식 확률에 중요한 파라미터인 은닉층 뉴런의 수, 모멘텀의 Step size와 Decay rate 값의 최적화에 관한 국내 연구보고도 미비한 실정이다.

따라서, 본 연구에서는 GIS(Gas Insulated Switchgear)사고의 주요 원인으로 보고되어있는 결함들을 인위적으로 모의한 16개 Test cell을 이용하여 부분방전을 발생시켰다. 부분방전 신호는 본 연구팀이 개발한 센서를 이용하여 검출되어 데이터베이스가 구축되어 그로부터 추출된 학습 데이터들의 학습에 다음과 같은 5가지 신경망 모델이 적용되었다: Multilayer Perceptron (MLP), Jordan-Elman Network (JEN), Recurrent Network (RN), Self-Organizing Feature Map (SOFM), Time-Lag Recurrent Network (TLRN).

유전 알고리즘 적용 효율성을 분석하기 위하여 동일한 데이터를 이용하여 다음과 같은 두가지 방법을 적용한 결과를 상호 비교하였다. 우선 상기 선택된 모델만 적용하였고 다른 하나는 상기 모델과 Genetic Algorithm이 동시에 적용되었다.

2. 본 론

2.1 유전 알고리즘 이론

전형적인 유전 알고리즘은 임의의 값으로 초기화된 개체들의 집합으로 시작되며 각각의 개체는 상대적인 문제해결 능력에 따라 그 적합도(fitness)가 평가되고 적합도에 따라 다음세대(generation)에 부모의 유전자가 복제(reproduction)되는 정도를 달리 함으로써 우성 형질을 지닌 개체들은 열성 형질을 지닌 개체들에 비하여 더욱 많은 자식을 생성할 수 있도록 유도된다. 이러한 선택(selection) 메카니즘은 다윈의 진화론에서의 적자 생존의 원리에 연유하는 것으로 선택 복제된 개체들은 여러 가지 유전 연산자들에 의해 재결합(recombination)되어 다음 세대의 개체군을 형성한다. 이와 같은 세대 교체는 원하는 수준의 해가 개체군 내에 존재하거나 또는 다른 종료 조건이 만족될 때까지 반복된다[3-4].

<표 1> 기본적인 유전 알고리즘

```
procedure SimpleGeneticAlgorithm()
    initialize(Population);
    evaluate(Population);
    while not(termination condition satisfied) do
        MatingPool = reproduce(Population);
        Population = recombine(MatingPool);
        evaluate(Population);
    end while
end procedure
```

2.2 실험장치 및 방법

GIS 내부에서 발생하는 부분방전을 검출하기 위한 실험장치 구성도는 그림 1과 같다[5].

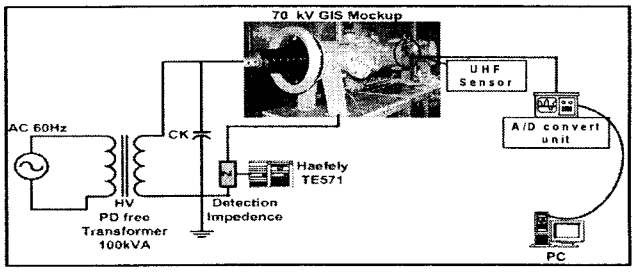

<그림 1> 실험장치 구성도

자체 제작된 내장형 UHF Sensor (Ultra High Frequency: 300MHz - 3GHz)를 감시창에 부착하여 부분방전을 검출하였으며, RG400 (50Ω) 이중차폐 동축 케이블로 전송된 신호는 A/D Convert Unit을 통해 디지털 신호로 컴퓨터에 저장되었다.

2.3 절연결함

신경망 학습에 사용될 데이터베이스를 구축하기 위하여 그림 2와 같은 결함들을 통하여 GIS 절연사고의 주요 원인으로 알려져 있는 16개의 결함을 제작하고 결함의 종류에 따라 4개의 그룹으로 분류하였다[6].

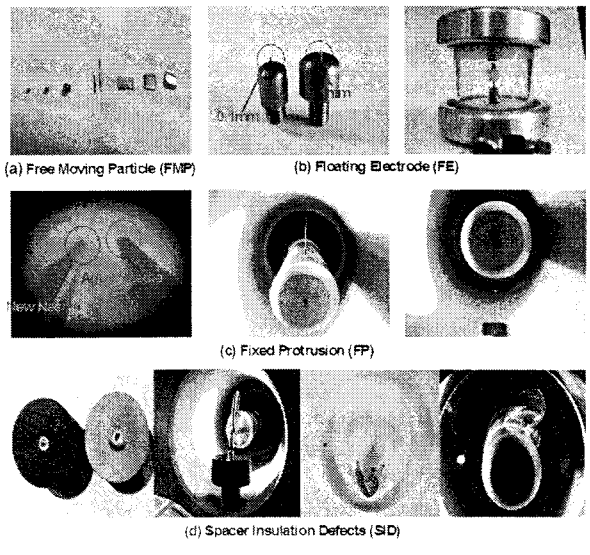

<그림 2> 모의 절연결함

2.4 신경망의 적용

2.4.1 신경망의 입력벡터와 출력벡터

발생된 부분방전 신호는 A/D Convert Unit을 거쳐 컴퓨터에 저장되고, 자체 구축한 소프트웨어를 이용하여 저장된 데이터를 PRPD 패턴으로 나타낸 후 각각의 Digitized phase에서 주요 요소인 Average amplitude와 Pulse count를 산출하였다. 산출된 2개의 요소는 하나의 조를 이루어 1개의 입력벡터로 사용되었다. 각각 결함 판별을 위하여 사용된 입력벡터의 수와 과훈련 방지를 위해 사용된 Cross validation 벡터의 수는 표 2와 같다.

<표 2> 입력벡터와 Cross validation 벡터의 수

Defects	The number of vectors	
	Input vector	Cross validation vector
FMP	50	25
FE	50	25
PF	50	25
SID	50	25
N	50	25

본 연구에서는 4개의 결함그룹 외에 레이더, 이동통신 및 써지 등의 Noise 그룹을 포함한 총 5개의 출력벡터를 선정하였으며 이에 따른 희망 출력벡터는 표 3과 같다.

<표 3> 희망 출력벡터

Input \ Desired	FMP	FE	PF	SID	N
FMP	1	0	0	0	0
FE	0	1	0	0	0
PF	0	0	1	0	0
SID	0	0	0	1	0
N	0	0	0	0	1

2.4.2 신경망 모델과 구성

패턴 인식 확률을 비교하기 위하여 본 연구에 선택된 신경망 모델은 다음과 같다[7-9]: Mulilayer Perceptron (MLP), Jordan-Elman Network (JEN), Recurrent Network (RN), Self-Organizing Feature Map (SOFM) 및 Time-Lag Recurrent Network (TLRN).

신경망의 여러 파라미터 중 유전 알고리즘의 적용에 따른 인식률 비교를 위해 각각의 모델에 대해 경험에 의해 얻은 파라미터 값과 유전 알고리즘을 통해 얻은 파라미터 값은 표 4와 같다.

<표 4> 신경망의 파라미터 값

Parameters \ Neural Models			MLP	JEN	RN	SOFM	TLRN
Without GA	The number of hidden layer		1	1	1	1	1
	The number of neuron of hidden layers		7	5	13	5	15
	Momentum	Step size	0.75	0.5	0.05	1	0.35
		Decay rate	0.03	0.06	0.01	0.01	0.03
With GA	The number of hidden layer		1	1	1	1	1
	The number of neuron of hidden layers		24	5	7	9	13
	Momentum	Step size	0.825977	0.420328	0.1546	0.054915	0.160921
		Decay rate	0.030952	0.087594	0.033441	0.010727	0.034822

2.4.3 절연결함 판별 결과 비교

각 신경망 모델간의 출력벡터와 희망 출력벡터의 평균제곱오차(MSE: Mean Square Error) 값은 표 5와 같다. 여기서 "Training"은 훈련데이터를 입력으로 하였을 때, "Testing"은 Cross validation을 입력으로 하였을 때 각각의 출력벡터와 희망출력벡터 간의 MSE이다.

<표 5> 신경망 모델의 MSE

Neural Model	Mean square error			
	Without GA		With GA	
	Training	Testing	Training	Testing
MLP	0.246588	0.250661	0031950	0.034026
JEN	0.146098	0.157952	0.002405	0.002632
RN	0.305236	0.324207	0.201375	0.195338
SOFM	0.230366	0.261962	0.161381	0.198583
TLRN	0.219706	0.301409	0.039268	0.036913

상기 결과를 바탕으로 유전 알고리즘의 적용 효과를 분석해보면, 적용한 경우 패턴인식 확률이 높을 뿐만 아니라 패턴인식의 최적화가 이루어 질 수 있음을 보여준다. 유전 알고리즘의 적용 결과 나타난 낮은 MSE가 실제 절연결함을 정확하게 분류하는지 검증하기 위하여 표 6과 같이 "Testing" 데이터를 입력으로 하였을 때, 신경망 모델들의 결함 분류확률을 비교하였다.

<표 6> 신경망 모델의 결함 분류 확률

Neural Model	Probability									
	Without GA					With GA				
	FMP	PE	FP	SID	N	FMP	PE	FP	SID	N
MLP	100	84	100	100	16	100	88	100	100	100
JEN	100	86	100	100	64	100	100	100	100	100
RN	100	64	100	60	0	100	96	100	92	0
SOFM	76	48	100	28	84	88	56	100	36	96
TLRN	76	88	84	10	100	100	96	96	92	100

3. 결 론

구축된 부분방전 측정 시스템과 유전 알고리즘 적용 연구를 통하여 얻은 결과의 요약은 다음과 같다.

(i) 유전 알고리즘을 적용한 경우, 패턴인식 확률이 높게 나타날 뿐만 아니라 패턴인식의 최적화가 이루어 질 수 있음.

(ii) 유전 알고리즘이 적용된 모델들의 결함판별 확률을 높은 순서는 다음과 같다.
MSE : JEN, MLP, TLRN, SOFM, RN
패턴분류 : JEN, MLP, TLRN, SOFM, RN

경험에 근거해 파라미터 값을 찾을 때, 모든 경우의 파라미터 값에 대하여 훈련을 수행할 수 없으며 또한 표 4의 결과와 같이 소수점 6자리까지의 최적화 값을 찾기 어렵다는 단점이 있다. 반면에 유전 알고리즘의 적용을 통해 우수한 인식률은 물론 파라미터 값을 찾기 위한 시간을 줄일 수 있는 이점이 있다. 이러한 결과를 근거로, 유전 알고리즘을 적용을 통한 패턴인식 기술은 신뢰성 있는 GIS 부분방전 진단기술에 활용될 수 있을 것으로 사료된다. 추가적으로, 부분방전 패턴인식에 가장 널리 사용되는 MLP 모델보다 JEN 모델에서 더 높은 인식률이 관찰되었다.

본 연구는 실험실과 같은 우수한 환경에서 수행된 결과이므로 현장 적용을 통한 검증이 필요할 것으로 사료된다.

감사의 글

본 연구는 산업자원부 전력산업 연구개발사업(R-2002-0-307), 한양대학교 전자재료 및 부품연구센터, 퓨전전기기술 응용 연구센터의 지원에 의해 수행된 연구 결과의 일부로 이에 감사드립니다.

[참 고 문 헌]

[1] E. Gulski, A. Rivda, "Neural Network as a Tool for Recognition of P artial Discharges", IEEE Transactions on Electrical Insulation, Vol. 28 No. 6, pp. 984-1001, 1993

[2] Guangning Wu, Xiongwei Jiang, Hengkun Xie, "A Neural Network U sed for PD Pattern Recogntion with Genetic Algorithm", Proceedings of t he 6th International Conference on Properties and Application of Dielectri c Materials, pp. 451-454, 2000.

[3] S. Han, "Neural Network Structure and Parameter Optimization via G enetic Algorithms", KFIS, Vol. 11, No. 3, pp. 215-222, 2001.

[4] H. Kim, J. Kim, M. Kim, S. Hwang, "A Study on Optimal Neural Ne twork Structure of Nonlinear System using Genetic Algorithm", JKNPR, Vol. 28, No. 3, pp. 221-225, 2004.

[5] Y. Lim, J. Koo, Y. Chang, C. Kang, J. Youn, "A Novel Approach for the Pattern Classification of Partial Discharges in Gas-Insulated Switchg ear using a Chaotic Theory Combined with Spectral Analysis", Cigre, D1 -305, 2004.

[6] S. Kim, S.Jung, J. Koo, Y. Lim, S. Koo, "A Study on the Reliability Improvement of Partial Discharge Pattern Recognition using Neural Netw ork Combination Method", KAS, pp 23-25, 2005.

[7] Jose C. Principe, Neil R. Euliano, W. Curt Lefebvre, "Neural and Ada ptive Systems", Wiley, pp. 100-529, 2000.

[8] Y. Han, "Introduction of Pattern Recognition", Hanbit, pp. 517-547, 2005.

[9] Simon Haykin, "Neural Networks", Macmillan College, pp. 12-14, 1994.