

## 전력계통 사고구간 판정에의 모듈형 신경 회로망의 구현

김광호\*      박종근\*  
\* 서울대학교 전기공학부

### Implementation of Modular Neural Net for Fault Diagnosis in Power System

\*Kwang-Ho Kim\*      Jong-Keun Park\*

\* Dept. of Electrical Eng. Seoul National University

#### ABSTRACT

In this paper, The implementation of modular neural net for fault diagnosis in power system is presented. Until now, there have been many researches on expert system for fault diagnosis. On expert system, a lot of time for searching goal is needed.

But, neural net processes with high speed, as it has parallel distributed processing structure. So neural net has good performance in on-line fault diagnosis. For fault diagnosis in large power system, the constitution of modular neural net with partition of large power system is presented.

#### 1. 서론

최근들어 관심이 고조되고 있는 Neural Network은 인간의 신경체계의 기본구조인 neuron을 modeling 한것으로서 기존의 Von Neumann 방식의 컴퓨터에서는 적용의 한계가 있는 decision-making, recognition 등의 분야에서 큰 성과를 거두고 있고 이에 대한 연구가 크게 확대되고 있다. 본 논문에서는 전력계통 사고구간판정에 있어서의 Neural Network의 적용을 고찰해 보았다. 이 적용에 있어서는 일정 계통 내의 모든 사고 유형을 pattern화 하여 이를 learning 시킨후 안정화된 Neural Net를 통해 사고구간을 판정하는 방법이 사용되었다. 기존에는 전력계통 사고구간 판정에 대해 List processing 언어인 Prolog, Lisp 등을 이용한 Expert System의 구현이 상당수 연구되어왔고 성과를 거두었다. 그러나 사고구간판정을 On-line으로 처리할 경우에 있어서는 goal에 도달하기 위한 search시간의 과다가 불리한점으로 대두되었다. 그러나 병렬분산처리 체계를 갖는 Neural Network은 고속으로 결과를 내기때문에 사고구간판단에 Neural Network를 적용할 경우 Expert System상의 난점이 해결되리라고 예상된다. 최근들어 외국에서는 일정 범위내의 사고구간 판정을 위한 Neural Net의 적용에 대한 시도가 있었다[3]. 그러나, 계통이 확대될 경우 Neural Net의 input, output unit의 증가 및 이에 따른 hidden unit의 증가에 의해 Network의 규모가 커짐으로써 learning시의

수렴시간 및 Network의 용량 과다의 문제가 발생하는 난점이 있다. 따라서 본 논문에서는 전력계통이 거대화 되었을 때 계통을 적절한 크기로 나누어, 나뉘어진 지역 각각에 대해 Neural net 를 구성하고 지역간의 연결 부분은 별도의 Neural net를 구성하여 사고판정을 수행하도록 함으로써 계통확대시에 나타나는 수렴시간 및 network 용량 과다 등의 문제를 해결할수있도록 하였다.

#### 2. Expert System과 Neural Network의 비교[1]

	Expert System	Neural Network
지식	사고구간판정에 대한 지식을 Rule화  Rule화 되지 않은 지식에 대한 입력이 들어왔을 경우 판정을 할 수가 없다.	사고구간판정에 대한 사고유형을 그대로 Neural Net에 Learning  Learning시키지 않은 지식에 대한 입력이 들어왔을 경우 기존의 Learning한 상태를 이용 적절한 판정을 한다.
판정 시간	판정을 행할 경우 사고구간에 대한 Goal에 도달하기 위한 Search 시간이 길어질 수 있다.	어떤 유형의 사고에 대해서도 Learning이 끝난상태에서는 동일 하게 고속의 판정을 수행한다.

#### 3. 계통모델 및 적용 Neural Net

##### 1) 계통모델

본 논문에서는 전체 대상계통을 A, B, C지역으로 분할하고 각 지역간에 연결 된 부분에 대해서는 별도의 중간지역으로 구분하여 Neural Net를 구성하였다. 따라서 A, B, C지역의 경우는 각각에 대응되는 Neural Net에서 사고구간을 판정하고 연결부분에 대해서는 중간지역에 대응하는 Neural Net에서

판정을 수행한다. 모델이 된 계통은 다음과 같다. 편의상 relay를 생략한 전체적인 계통도만을 나타내었다.

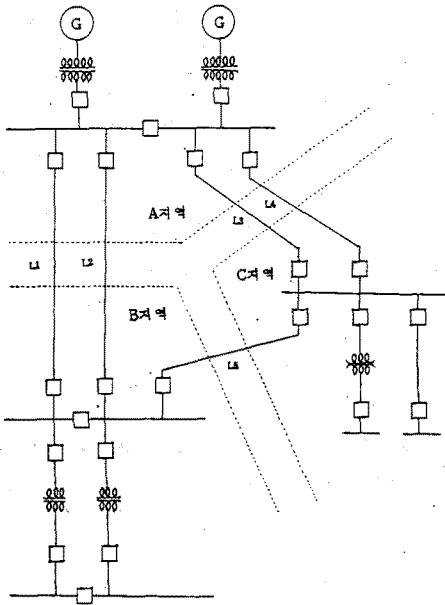


그림 1. 전체 계통

2) Neural Net[4,5]

i) Activation Function

한 unit의 현재 상태에서 다음 상태로의 전이가 이루어졌을 때 unit의 상태를 결정하는 함수가 Activation function이다. Activation function로서는 sigmoid 함수가 사용되었다. 각 unit의 출력은 Activation function의 출력과 동일하도록 하였다. (단, input unit의 출력은 입력과 동일하다.)

$$f_i = \frac{1}{1 + e^{-y_i}} = o_i$$

$w_{ij}$  = j에서 i로의 weight값  
 $o_j$  = j unit의 출력값  
 $b_i$  = i unit의 bias값

$$y_i = \sum_j w_{ij} o_j + b_i$$

ii) Learning Algorithm

Learning algorithm으로는 Back propagation algorithm이 사용되었다. 이때 weight의 변경을 위한 식은 다음과 같다.

$$\Delta w_{ji}(n+1) = \eta(\delta_j o_i) + \alpha \Delta w_{ji}(n)$$

$w_{ij}$  = i에서 j로의 weight값  
 $\delta_j$  = j unit의 Back propagation한 error값  
 $\eta$  = learning rate  
 $\alpha$  = momentum rate

본 논문에서는  $\alpha=0.9, \mu=0.7$ 로 사용하였다.

iii) Network Model

각 지역별로 사용한 model은 다음과 같다.


o A,B,C 지역

- input unit : 관할지역의 CB 및 주보호, 후비보호 Relay
- output unit : 관할지역의 사고구간

o 중간 지역

- input unit : 중간지역의 사고시 각지역의 neural net가 관할지역의 정보만으로 판정한 지역별 사고구간
- output unit : 중간지역의 사고구간

중간지역의 neural net가 A,B,C지역의 neural net와 다른점은 input을 CB, relay정보를 사용하는것이 아니고 중간지역 사고구간에 대해 A,B,C지역의 neural net가 관할지역의 정보를 통해 부분적으로 판정한 결과를 input으로 하여 판정을 수행한다는 점이다. input unit에는 중간지역의 Line에 대한 판정결과 뿐 아니라 Bus사고 판정결과도 포함시켜서 중간지역과 연결된 CB가 오부동작한 Bus사고에 대해서 중간지역의 Line사고로 오판하지 않도록 하였다.



(L1 : 중간지역의 L1에 대해 A지역 N.N가 판정한 결과  
Lb1 : 중간지역의 L1에 대해 B지역 N.N가 판정한 결과)

	A 지역	B 지역	C 지역	중간 지역
input unit의 갯수	21	25	23	15
hidden unit의 갯수	5	5	5	4
output unit의 갯수	8	9	8	5
pattern수	18	19	22	15

3) 사고 유형 Pattern[2]

본 논문에서는 CB와 주보호 및 후비보호 relay 정보를 이용하여 사고구간을 판단하도록 하였다. Input pattern은 CB와 Relay의 on-off값 으로 결정되고 output pattern은 이에 대응하는 사고구간을 나타내도록 하여 learning을 수행하였다.

4) 계통의 분할시 장점

이상의 모델계통을 하나의 Neural Net로 구성하는 것까 본 논문에서 제시한 중간지역에 대한 Neural Net를 두고 각 지역을 분할하여, 구성하는 것을 비교해 보았다. 본 논문에서는 Network의 상태를 나타내는 bias, weight 등의 저장을 위한 Network Memory와 learning시에 weight 변화를 위한 unit 상호간의 곱셈의 양을 비교하였다.

i) Network memory

Network 상태를 저장하기 위한 memory는 각 unit별로 할당된 bias값과 hidden unit와 input unit간의 weight값, output unit와 hidden unit 및 input unit간의 weight값이 저장된다.

( $_n$  : 각 unit 의 갯수 )

- o bias :  $[out\_n + hid\_n + in\_n]$
- o hid\_weight :  $[in\_n] \times [hid\_n]$
- o out\_weight :  $[in\_n + hid\_n] \times [out\_n]$

사용모델을 대상으로 하였을 때 전 계통을 하나로 통합하여 Network을 구성하는 것에 비해 계통을 분할하여 Network을 구성하는 것이 거의 1/2의 Network memory의 절감을 가져왔다.

ii) 곱셈의 양

Learning시 unit간의 곱셈은 크게 error-back propagation 과정과 weight change 과정의 2가지로 구분하여 볼 수 있다.

o Error-Back Propagation

$$\delta_{pl} = (t_{pl} - a_{pl}) a_{pl} (1 - a_{pl})$$

(output unit)

$$\delta_{pl} = a_{pl} (1 - a_{pl}) \sum_k \delta_{pk} w_{lk}$$

(hidden 및 input unit)

- output unit error back propagation :

$$[in\_n + hid\_n] \times [out\_n]$$

- hidden unit error back propagation :

$$[in\_n] \times [hid\_n]$$

o Weight Change

$$\Delta w_{jl}(n+1) = \eta (\delta_{pl} O_{pj}) + \alpha \Delta w_{jl}(n)$$

- output unit와 연결된 unit의 weight change :

$$[out\_n] \times [input\_n + hid\_n]$$

- hidden unit와 연결된 unit의 weight change :

$$[hid\_n] \times [input\_n]$$

곱셈의 양에서도 전 계통을 하나로 통합한 Network에 비해 계통을 분할한 것이 1/2의 계산량의 감소를 나타냈다. 또한 계통의 새로운 설비를 추가했을 때, 즉 input unit의 추가시 전계통을 하나로 통합한 Network에서는 전체 Network이 새로이 구성되어야 하는 단점이 있는 반면 계통분할시는 관련된 지역의 Network은 그대로 두고 해당 지역의 Network만 재구성하면 되기 때문에 Network Memory면에서나 재 learning시 계산량의 감소 등이 장점이 될 수 있다.

4. 결 과

1) Learning

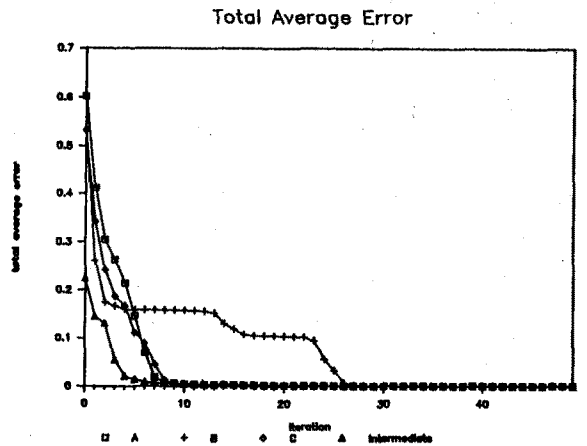
각 지역에 대한 Neural Net의 learning은 IBM PC AT에서 수행하였다. Back propagation에서 정의한대로 각 pattern에 대한 the square of error는 다음과 같다.

$$E_p = \frac{1}{2} \sum_k (t_{pk} - O_{pk})^2 \quad (p : \text{pattern}, k : \text{output unit})$$

따라서 총 pattern에 대한 total average error는 다음과 같다.

$$E = \frac{1}{2p} \sum_p \sum_k (t_{pk} - O_{pk})^2$$

각각의 Neural Net를 learning할 때 수렴판정의 기준은  $E \leq 2 \times 10^{-4}$ 으로 하였다. 각 지역의 Network에 대한 수렴결과를 도식화하면 다음과 같다. 모든 pattern에 대한 연산이 끝나는 것을 1회의 iteration으로 하였다.



각 지역별로 수렴 기준대로 들어오는 iteration수는 다소 다르나 거의 150 - 190번 정도의 iteration후에 수렴을 끝냈다.

2) 판정 결과

Learning이 끝난 상태에서 다양한 사고유형을 입력시켜 보았다. 정상적인 사고유형, CB 오부동작에 대한 사고유형, 2중사고에 대한 사고유형 등에 대해 올바른 사고구간 판정이 이루어지는 것을 보였다. 다음에 각각에 대한 판정결과를 보였다. (예를 들어 Bm1은 A지역의 Bus인 B<sub>1</sub>에 대한 주보호 relay를 나타내고, Ba1은 A지역의 Bus인 B<sub>1</sub>를 나타낸다)

o CB, Relay 정상 동작시

```
--- operated CB & Relay <A>
CBa1 CBa3 CBa4 CBa5 Bm1

=== result ===
Ba1 is faulted
```

```
-----
Ga1 : 0.000262773
Ga2 : 0.000005103
Ba1 : 0.997720877
Ba2 : 0.002367728
La1 : 0.002275223
La2 : 0.001731483
La3 : 0.000032761
La4 : 0.000122041
```

o CBa1의 오부동작시

```
--- operated CB & Relay <A>
CBa3 CBa4 CBa5 Bm1

=== result ===
Ba1 is faulted
```

```
-----
Ga1 : 0.000004178
Ga2 : 0.000046429
Ba1 : 0.987885849
Ba2 : 0.019878747
La1 : 0.029593436
La2 : 0.039013304
La3 : 0.000225462
La4 : 0.000651883
```

o 다중 사고시

```
--- operated CB & Relay <A>
CBa1 CBa2 CBa3 CBa4 CBa5 CBa6 CBa7
Bm1 Bm2

=== result ===
Ba1 is faulted
Ba2 is faulted
```

```
-----
Ga1 : 0.000000277
Ga2 : 0.000000729
Ba1 : 0.879095085
Ba2 : 0.927508277
La1 : 0.000042399
La2 : 0.000025658
La3 : 0.000010109
La4 : 0.000046438
```

다음은 중간지역에 대한 사고판정 결과를 나타냈다.

o 중간 지역사고시

```
--- operated CB & Relay <A>
CBa4
Bm1

=== result ===
Ba1 is faulted
```

```
--- operated CB & Relay <B>
CBb1
Lbml

=== result ===
Lb1 is faulted
```

```
!!! Intermediate Region !!!
L1 is faulted
```

```
-----
L1 : 0.977245018
L2 : 0.006137596
L3 : 0.002271008
L4 : 0.003163367
L5 : 0.004790854
```

5. 결 론

본 논문에서는 전력계통이 거대화되었을 때 이에 대한 효율적인 사고구간판정을 수행하기 위해 계통을 적절한 크기로 나누어 각각에 대한 Neural Net를 구성하는 방법을 제시하였다. 시뮬레이션 결과 정상적인 사고시 뿐 아니라 CB의 오부동작시, 다중사고시에도 올바른 판정결과가 얻어짐을 보였다. 고속의 병렬 분산 처리를 수행하는 Neural Net를 전력계통 사고구간판정에 적용한다면 기존의 Expert System상에서 문제가 되는 Search 시간의 과다를 해결할 수가 있고 on-line fault diagnosis의 경우는 Expert System보다 더 나은 performance를 얻을 수 있다고 보여진다.

본 논문에서는 Learning Pattern으로 개별적인 설비에 대한 사고유형을 사용하였으나, 일반적인 사고판정 rule을 사용하여 개별적인 사고에 대해서 판정할 수 있는 Neural Net Model의 연구가 시도되어야 할 것이다.

참고문헌

- [1] 최재균, 박중근, "전력계통의 고장구간 판단 Expert System에 관한 연구", 대한전기학회 전력계통 연구회 추계학술연구 발표회 논문집, 1986
- [2] 岡本 浩 横山 明彦 他 병렬형 지식처리에 기초한 전력계통의 진단제어, 일본전기학회 연구회 자료, PE-89-28, 1989
- [3] 田中, 松田 他 Neural Network의 전력계통 사고구간 판정문제에의 적용, 일본전기학회 시스템 제어연구회 자료, SC-88-21, 1988
- [4] J.L. McClelland & D.E. Rumelhart, Parallel distributed processing, Vol. 1, 1986, MIT Press
- [5] J.L. McClelland & D.E. Rumelhart, Explorations In P.D.P., 1988, MIT Press