

전력계통 사고구간 판정을 위한 Connectionist Expert System

A Connectionist Expert System for Fault Diagnosis of Power System

金 光 鎬* · 朴 鍾 根**
 (Kwang-Ho Kim · Jong-Keun Park)

Abstract - The application of Connectionist expert system using neural network to fault diagnosis of power system is presented and compared with rule-based expert system. Also, the merits of Connectionist model using neural network is presented. In this paper, the neural network for fault diagnosis is hierarchically composed by 3 neural network classes. The whole power system is divided into subsystems, the neural networks (Class II) which take charge of each subsystem and the neural network (Class III) which connects subsystems are composed. Every section of power system is classified into one of the typical sections which can be applied with same diagnosis rules, as line-section, bus-section, transformer-section. For each typical section, only one neural network (Class I) is composed. As the proposed model has hierarchical structure, the great reduction of learning structure is achieved. With parallel distributed processing, we show the possibility of on-line fault diagnosis.

Key Words : · Fault Diagnosis of Power System · Connectionist Expert System
 (전력계통 사고구간판정) (Connectionist 전문가 시스템)
 · Hierarchical Neural Network
 (계층형 신경회로망)

1. 서 론

근래에 들어 사회가 고도정보화, 산업사회로 이행되어 감에 따라 전력수요 및 양질의 전력에 대

*正 會 員 : 서울大 大學院 電氣工學科 博士課程
 **正 會 員 : 서울大 工大 電氣工學科 副教授 · 工博
 接受日字 : 1991年 8月 9日
 1次修正 : 1992年 1月 16日

한 요구가 급증하고 있다. 따라서 전력계통은 더욱 복잡, 거대해지고 이에 대한 계통보호기능의 중요성이 증대됨과 아울러 이에 대한 효율적 처리는 더욱 어려워지고 있다.

최근 들어 계통보호기능중 계통사고구간판정 분야에 대해 Artificial Interlligence 를 이용한 Expert System[1, 2, 3]을 구현하고자 하는 시도가 상당수있어 왔고 성과를 거두고 있다. Expert System의 경우는 사고구간판정 전문가의 지식과 경험을 Knowledge Base화하여 현재 상황을 추론 판단하는 형태를 갖는다. 그러나 Rule이나 Data가 많을 경우 Goal에 도달하기 위한 Search Path의 증가에 따라 판정시간이 지나치게 길어지는 문제가 발생하고 있다.

본 논문에서는 이런 단점을 해결하기 위해 병렬 분산처리체계를 갖는 신경회로망의 적용을 통해 전력계통 사고구간 판정에 고속성을 도입하고자 했다. 본 논문에서는 사고구간 판정을 위한 신경회로망을 3가지의 종류로 구분하여 계층적으로 구성하였다.

- 1) 모든 구간을 Transformer, Bus, Line등의 종류별로 구분하여 각 종류별로 단일의 신경회로망을 구성하여 일반적인 사고구간판정 지식을 Learning한다.
- 2) 구간 상호간의 정보가 필요한 경우에 대해 1)에서 구성된 신경회로망 Output Unit을 입력으로 하는 신경회로망을 구성하고 각 구간의 사고상태를 조합하여 사고구간을 판정하는 사고 Pattern을 Learning한다.
- 3) 계통이 거대 해졌을 경우는 전체계통을 부분계통으로 나누어 각 부분계통간의 연결 구간에 대한 사고구간판정을 하는 별도 신경회로망을 구성한다.

2. Rule-based Expert System 과 Connectionist Expert System의 고찰[1, 2, 3]

Rule-based Expert System은 특정분야에서의 문제를 해결하는 전문가의 지식이나 경험을 통해 사고를 판정해가는 과정을 모방하는 컴퓨터 하드웨어 및 소프트웨어로 구성된 컴퓨터시스템으로서 특정분야에서 전문가의 역할을 모의할 수 있는 시스템을 지칭한다.

즉 Rule-based Expert System은 문제의 해결법을 이미 알고있는 분야에 사용되어지는 것이 아니라 문제의 해결법을 알지 못하는 분야에 사용될




그림 1 Rule-based Expert System의 구조
Fig. 1 Rule-based Expert System scheme

수 있는데 이 경우는 문제에 관련된 많은 양의 지식을 결합하여 추론과정을 통해 해를 구하게 되므로 기존의 알고리즘 중심의 프로그램과는 다르다. Rule-based Expert System의 구조를 간략히 나타내면 그림1과 같다.

전력계통의 사고구간판정문제에 적용되는 Expert System의 경우는 계통의 계전기과 차단기의 동작정보를 바탕으로하여 계통사고의 형태를 분석, pattern matching방식으로 backward tracking 또는 forward tracking등의 추론을 수행한다. 그러나 이런 방식의 문제점은 추론에 필요한 data나 rule이 많아지게 되면 결과적으로 search space가 증대되어 해결점(goal)에 도달하는데 많은 시간이 요하게 되므로 on-line fault diagnosis에는 문제점이 대두된다.

기본적으로 Connectionist Expert System은 Rule-based Expert System과 마찬가지로 문제의 해결법을 알지못하는 분야에 적용이 되고, pattern matching과 유사한 형태로 해결점을 찾는다는 점에서는 유사한 형태이나 문제 해결에 필요한 지식들이 pattern의 형태로서 신경회로망의 각 node간을 연결하는 connection으로서 저장된다는 점에서 근본적으로 다르다고 볼 수 있다. 따라서 정보가 한곳에 집중되는 것이 아니라 수 많은 connection의 형태로 분산 저장되기 때문에 입력의 결손이나 오차에 대해 강하게 되고 (error tolerance), 보간성능을 갖게된다. 또한 parallel distibuted processing으로 요약 될 수 있는 특성에 의해 rule-based expert system의 문제점을 극복하여 고속의 문제해결을 수행하므로 on-line fault diagnosis에 적용이 보다 수월하다고 볼 수 있다.

3. 계층형 구조의 신경회로망의 구성

본 논문에서는 전술한 바와 같이 3가지 종류의




그림 2 신경회로망의 계층형 구조
Fig. 2 The hierarchical neural network scheme

신경회로망을 모듈형으로 구성하였다.

- 구간 종류별 일반적인 신경회로망
- 구간별 신경회로망을 입력으로 하는 지역내 사고판정 신경회로망
- 분할 계통의 연결구간 사고판정 신경회로망 계층형 구조를 갖는 신경회로망에 있어서 한가지 고려할 점은 입력된 정보가 계층을 따라 상위의 계층으로 전파될 때 각 계층에서 발생하는 오차가 중첩이 되어 최종 출력이 되기 때문에 출력값에 다소의 오차가 포함되게 된다. 본 논문에서는 판정에 대한 문제를 다루기 때문에 pattern이 0과 1의 값으로 주어져 큰 문제는 발생하지 않지만 중첩된 오차를 최소화하기 위해 한 단계에서 판정이 끝나지 않는 사고에 대해서는 다음 Class의 신경회로망으로 넘어갈때 출력값을 그대로 입력시키는 것이 아니라 일정한 threshold를 지정하여 0과 1의 값으로 변환하여 다음 계층으로 입력한다. 이런 방식을 통해 중첩된 오차에 의한 판정의 혼란을 줄이게 된다. 본 논문에서는 threshold를 0.5로 지정했다.

신경회로망의 계층형 구조는 그림2와 같다.

3.1 구간 종류별 신경회로망(Class I)의 구성

전력계통은 수 많은 Line, Transformer, Bus등이 상호연결되어 구성되어 있다. 이들 보호구간들은 일반적으로 같은 형태를 갖는 동일한 종류로 구분할 수 있으므로 즉, Line, Transformer, Bus의 3가지로 묶을 수 있다. 전체계통을 단일의 신

경회로망으로 구성하는 경우는 같은 형태의 구간이라 할지라도 별개의 것으로 취급하여 각각에 대해 모든 pattern을 학습시켜야 한다. 이 경우 동일한 사고형태라 할지라도 각각의 구간에 대해 별개의 사고 pattern으로 취급하기 때문에 결과적으로 학습 pattern의 중복이 생기고 신경회로망의 size도 커지게 된다. 이런 난점을 해결하기 위해 계통내 모든 보호구간을 동일한 종류 즉, Line, Transformer Bus등으로 구분지어 3가지 종류별 구간을 대표하는 신경회로망을 각각 1개만 구성하도록하여 이에 대표되는 사고 Rule을 pattern화하여 학습함으로써 학습의 효율성과 신경회로망의 size를 감소시키게 된다. 학습이 끝난 3가지 대표 신경회로망은 실제 사용시 종류에 맞게 단순히 접속시킴으로써 사고구간 판정을 수행하게 된다.

- 동일한 Rule의 적용을 받을 수 있는 구간을 구분하여 단일의 신경회로망을 구성한다. (즉, Line용 신경회로망, Transformer용 신경회로망, Bus용 신경회로망등)
- 모든 차단기와 계전기는 신경회로망의 각 input unit에 대응된다.
- 있을 수 있는 사고유형들을 신경회로망의 각 output unit에 대응시킨다.
- 각 구간종류별 신경회로망을 해당하는 rule들로 learning시킨다.
- learning이 끝난 신경회로망을 해당구간에 접속한다.

Line용 신경회로망을 예로 들면 그림3와 같다. 이 경우 사고유형 pattern의 set는 다음과 같다.

①②③④ rule은 주보호, 후비보호 구분없이 양단의 계전기가 동작하고 양단의 차단기가 동작했으므로 구간내부사고임이 확실하여 L_{in} 으로 판정하도록 학습시키고 ⑤⑥rule은 한쪽의 주보호 계전기가 동작하여 구간내부의 사고일 가능성이 많으나 다른 쪽단의 계전기와 차단기가 동작하지 않아

	input pattern	target pattern
①	$R_{YML} R_{YMR} C_{BL} C_{BR}$	L_{in}
②	$R_{YBL} R_{YMR} C_{BL} C_{BR}$	L_{in}
③	$R_{YML} R_{YBR} C_{BL} C_{BR}$	L_{in}
④	$R_{YBL} R_{YBR} C_{BL} C_{BR}$	L_{in}
⑤	$R_{YML} C_{BL}$	L_{out}
⑥	$R_{YMR} C_{BR}$	L_{out}
⑦	$R_{YBL} C_{BL}$	L_R
⑧	$R_{YBR} C_{BR}$	L_L

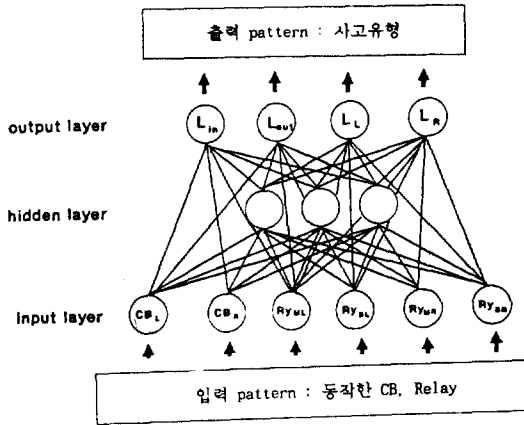



그림 3 Line 구간의 model
Fig. 3 Line section model

인접구간의 사고정보가 필요한 경우 L_{out} 으로 하고, ⑦⑧ rule은 한쪽의 후비보호계전기만 동작하여 구간내부사고일 가능성이 상대적으로 적어 각각 오른쪽, 왼쪽의 인접구간 사고정보가 필요한 경우는 L_R, L_L 으로 학습한다. 이 경우 L_{out}, L_L, L_R 은 사고판정을 Class I에서 하지않고 출력 값을 Class II로 전송하여 인접구간의 정보를 조합하여 Class II에서 판정하도록 한다.

3.2 지역내 사고 판정 신경회로망(Class II)의 구성

본 신경회로망은 일정한 지역내에 있는 모든 사고구간의 Class I 신경회로망의 내부 구간사고로 판정이 불가능한 출력 (즉 L_{out}, L_L, L_R)들을 입력으로 하여 구성된다. 이들의 조합으로 있을 수 있는 모든 사고유형을 pattern화하여 학습시키고 Class I과는 달리 지역내의 모든 구간이 각각 출력 unit에 할당된다.

- 1) 각 구간별의 일반화된 신경회로망 (Class I)의 출력을 통해 나오는 각 구간의 상태를

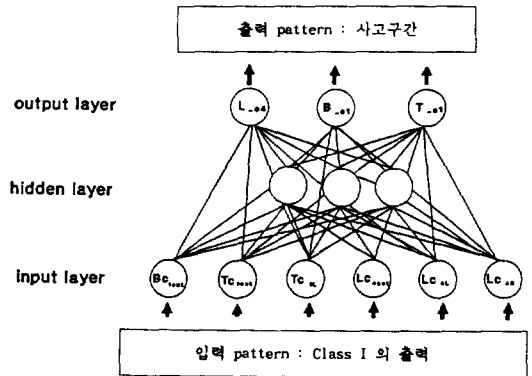


그림 4 C지역의 예 (Class II)
Fig. 4 The example of C region (Class II)

input unit로 하고 구간을 output unit로 하는 신경회로망을 구성한다. 이때 Class I을 통해 들어오는 입력값을 threshold를 통해 0과 1로 변환된 binary값이 입력된다.

- 2) 구간상태의 조합을 통해 특정구간의 사고를 판단할 수 있는 input-output Pair를 Learning한다.
구간 내부사고에 대해서는 입력하지 않으므로 불필요한 Learning이나 Memory를 감소시킬 수 있다.

그림4와 그림7에 C지역에 대한 Class II 신경회로망과 이에 대한 계통 모델을 보였다. 이때 첨자 c 는 C지역을 나타내고 예를 들어 B_{c1out} 은 C지역의 Bus 1의 Class I 신경회로망의 출력 중 out 에 해당하는 unit를 나타낸다. 또한 출력 unit는 C지역의 각 구간이 된다.

3.3 분할 계통간 연결 구간 판정 신경회로망 (Class III)의 구성

본 신경회로망은 거대하고 복잡한 실제계에 적용하기 위한 것으로서 임의로 지역을 나누어 각 지역별로 각각의 Class II 신경회로망을 구성했을 때 각 지역간의 연결이 되는 구간 즉, 그림5에서 $L1, L2, L3, L4, L5$ 와 같은 구간을 담당하도록 하는 신경회로망이다. Class III는 Class II와 비슷한 개념으로 구성되며 입력 unit는 연결구간에 해당되는 모든 Class II 신경회로망의 출력값을 받아들이게 되고 출력 unit는 연결구간이 각각 할당된다. 연결구간사고상태의 조합을 이용 사고판정을 하도록하는 pattern을 구성하여 학습한다.




그림 5 계통 모델
Fig. 5 Power System Model

4. Simulation결과

본장에서는 임의로 구성한 계통모델에 이상과 같은 신경회로망 모델을 적용하여 사고 판정을 수행한 결과를 보인다.

4.1 계통 모델

본 논문에서 사용된 모델 계통은 그림5와 같다. 각 지역 별로 다양한 종류의 구간을 포함시켰고 전체계통을 A지역, B지역, C지역으로 구분하였다. A, B, C지역의 연결 구간은 L1, L2, L3, L4, L5등 5개의 Line으로 구성되고 별도의 신경회로망에서 5개의 Line을 담당하게 된다.

4.2 신경회로망의 구조[6, 7]

모든 신경회로망은 input layer, hidden layer, output layer의 3가지 layer로 구성된다. 또한 3가지 layer의 모든 unit는 완전히 연결(connected)되어 있다.

4.3 Activation Function[6, 7]

각 unit의 Activation function은 Sigmoid함수가 사용되었다. 각 unit의 출력은 Activation function의 출력과 동일하다. 단, Input Unit의 출력은 입력과 동일하다.

$$F_i = \frac{1}{(1 + e^{-y_i})} = O_i$$

$$y_i = \sum_j \omega_{ij} O_j + b_i$$

F_i = i unit의 activation value

O_i = i unit의 출력값

b_i = i unit의 bias값

4.4 Learning Algorithm[6, 7]

Learning Algorithm으로 Back-Propagation Algorithm이 사용되었다.

$$\Delta \omega_{ij}(n+1) = \eta \delta_{pj} O_{pj} + \alpha \Delta \omega_{ij}(n)$$

$$\delta_{pj} = (t_{pj} - O_{pj}) O_{pj} (1 - O_{pj}) : \text{output unit}$$

$$= O_{pj} (1 - O_{pj}) \sum_k \delta_{pk} \omega_{jk} : \text{hidden unit}$$

p : index of pattern i, j : i 번째, j 번째 unit

t_{pj} : p 번째 학습 pattern의 j 번째 출력 unit의 target값

O_{pj} : p 번째 학습 pattern에 대한 학습중의 j 번째 출력 unit의 출력값

η : learning rate α : momentum rate

Learning은 IBM PC AT에서 수행되었다. Back Propagation Algorithm에서 정의한 대로 각 pattern에 대한 제곱 오차는 다음과 같다[8].

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

(p : index of pattern k : index of output unit)

따라서 총 Pattern에 대한 Total Average Error는 다음과 같아진다[8].

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

각각의 신경회로망을 learning할때 수렴판정 기준은 $E \leq 2 \times 10^{-4}$ 으로 하였다. 본 논문에서 제시한 방법의 경우 신경회로망의 구조가 단순해지므로




그림 6 구간 종류별 신경회로망의 수렴
Fig. 6 The convergence of Class 1 neural network




그림 7 C지역의 계통모델
Fig. 7 Power system model of region C

η, α 값이 학습에 큰 문제를 발생시키지 않는다. 본 논문에서는 $\eta=0.7, \alpha=0.9$ 을 사용하였다. 참고로 구간 종류별 신경회로망의 수렴 예를 그림6에 나타내었다.

모든 Pattern에 대한 연산이 끝나는 것을 1회 iteration으로 하였다. 종류에 따라 다르나 대략 1000 iteration이내에서 수렴하였다.

4.5 사고 구간 판정결과

본 항에서는 구성된 신경회로망을 통해 사고 구간 판정을 수행한 결과를 나타내었다. L_c4 사고는 Class I 이, Bus_c1 사고는 Class II 가 판정한 결과 이다. 그림에 각 신경회로망의 출력값을 나타내었다. 연결구간의 예에서 threshold를 주었을 때 와주지 않았을 때를 비교하였다.

- L_c4 사고시
...operated CB & Relay (C지역)
Lcm4, Lcp5, CBc5, CBc7

L_c4 fault




그림 8 L c4 사고
Fig. 8 L c4 fault

- Bus_c1 사고시
...operated CB & Relay (C지역)
Bcm1, CBc1, CBc2, CBc3, CBc4, Lcp5, CBc7

Bus_c1 fault




그림 9 Bus c1 사고
Fig. 9 Bus c1 fault

- 다중 사고시 (Bus_c1, Tr_c1)
...operated CB & Relay (C지역)
Bcm1, CBc1, CBc2, CBc3, CBc4, CBc5, Tcs1, Tct1, CBc6

Double fault




그림 10 다중사고시
Fig. 10 Multiple fault

- 지역간 연결 구간 사고시 (L1 사고시)
...operated CB & Relay (A지역)
Lam1, CBa4
...operated CB & Relay (B지역)
Lbm1, CBb1

connecting section fault (L1)
without threshold



connecting section fault (L1)
with threshold




그림 11 연결구간 사고시
Fig. 11 Connecting section fault

5. 결과의 고찰

본 논문에서 제시된 방법을 사용했을 경우 기존의 연구에 비해 개선된 점을 항목 별로 기술하면 다음과 같다. 이하에서는 on-line fault diagnosis의 가능성과 전력계통 전체에 대해 단일의 신경회로망을 구성하는 방법[5]에 비해 향상된 점을 기술했다.

5.1 On-line fault diagnosis

전술한 바와 같이 본 논문에서 제시한 방법으로 expert system을 구축하게 되면 parallel distributed processing으로 요약될 수 있는 특성에 의해 rule-based expert system의 문제점을 극복하여 고속의 사고구간 판정을 수행하므로 on-line fault diagnosis에의 적용이 수월하다고 볼 수 있다.

5.2 Network Memory의 용량 감소

신경회로망의 상태를 저장하기 위한 Memory는 각 Unit별로 할당된 Bias값과 Hidden unit와

Input unit간의 Weight값, Output unit와 Hidden unit 및 Input unit간의 Weight값이 저장된다.

- Bias : [out_n+hid_n+in_n]
- Weight : [in_n]×[hid_n]+[in_n+hid_n]×[out_n]
(_n : 각 unit의 갯수)

신경회로망은 구조상 모든 unit가 weight형태로 연결되어 있기 때문에 1개 unit의 추가는 특히 weight의 수를 급격히 증가시킨다. 본 논문에서 제시한 방법은 기본적으로 unit의 수를 절감시켜주는 구조이므로 사용 모델 계통을 대상으로 하였을 때 전체통을 하나로 통합하여 신경회로망을 구성하는 것에 비해 제시된 방법을 사용하면 weight와 bias등을 저장하기 위한 Memory가 1/2정도 절감이 된다.

5.3 Learning시 곱셈의 양의 감소

Learning시 Unit간의 곱셈은 크게 Error Back-Propagation 과정과 Weight Change과정의 2가지로 구분하여 볼 수 있다.

- Error Back-Propagation

$$\delta_{pj}(\text{output unit}) = (t_{pj} - O_{pj})O_{pj}(1 - O_{pj})$$

$$\delta_{pj}(\text{hidden unit}) = O_{pj}(1 - O_{pj}) \sum_k \delta_{pk} \omega_{jk}$$

error-back propagation시 곱셈의 양은 다음과 같다.

- Output unit : [in_n+hid_n]×[out_n]
- Hidden unit : [in_n]×[hid_n]

- Weight Change

$$\Delta \omega_{ji}(n+1) = \eta(\delta_{pj} O_{pi}) + \alpha \Delta \omega_{ji}(n)$$

weight change시 곱셈의 양은 다음과 같다.

- Output unit와 연결된 Unit : [out_n]×[in_n+hid_n]
- Hidden unit와 연결된 Unit : [hid_n]×[in_n]

이상을 통해 C지역의 경우를 예를 들면, 전 지역을 통합하며 Neural Net를 구성 했을 경우 약 2,540,000번의 곱셈이 필요했고 본 논문에서 제시한 방법을 사용했을 경우는 약 1,360,000번의 곱셈이 필요했다. 따라서 약 40%의 계산량 감소가 얻어지나 논문에서 제시한 방법으로 Learning할 때는 구간 종류별 신경회로망을 모두 포함하였기 때문에 이 신경회로망을 별도로 취급한다면 계산량의 감소는 더욱 커질것이다.

5.4 Learning Pattern수의 감소

동일한 rule의 적용을 받을 수 있는 사고에 대해서는 각 구간별로 별도의 사고유형으로 간주 하지 않고 구간 종류별 신경회로망에서 하나의 사고유형으로 Learning하므로 Learning pattern수가 감소한다.

6. 결 론

본 논문에서는 전체 계통을 지역적으로 분할하여 중간 지역은 별도의 신경회로망으로 구성하고 지역내 사고 구간 판정은 동일한 판정 Rule이 적용될 수 있는 구간 종류별의 일반적인 신경회로망을 구성하여 지역내 사고를 판정하는 방법이 제시되었다. 또한 계층구조를 갖는 신경회로망의 문제점인 오차의 증폭을 최소화 하기위해 한단계에서 판정이 끝나지 않는 사고에 대해 다음 Class의 신경회로망으로 넘어가는 값을 threshold를 통해 0과 1의 값으로 변환하는 방법을 사용했다.

제시된 방법으로 병렬처리를 이용한 고속의 판정, 입력결손에 대한 유효한 판정값의 취득결과를 얻어 기존의 rule-based expert system의 한계를 극복할 수 있음을 보였고, 전체 전력계통에 대해 단일의 신경회로망을 구성하는 방법에 비해 Learning Pattern의 수와 Network 저장 Memory용량 및 Learning시 곱셈의 양이 감소하고, 모듈로 구성되었기 때문에 구간추가등 설비의 추가가 용이하다. 따라서 판정을 위한 신경회로망은 3계층 구조가 되지만 전체적인 size는 감소한다.

참 고 문 헌

[1] 최재균, 박종근, "전력계통의 고장구간 판단

Expert System에 관한 연구", 대한전기학회 전력계통 연구회 추계학술연구 발표회 논문집, 1986

- [2] 최준영, 박종근, "전력계통의 사고복구시 expert system에 관한 연구" 대한전기학회 춘계 학술대회, 1986
- [3] Y.M. Park, H.J. Lee, "An Expert System for Fault Diagnosis in Power System", 대한전기학회, January, 1990
- [4] 岡本 浩, 横山 明彦, 他, "병렬형 지식처리에 기초한 전력계통의 진단제어", 일본전기학회 연구회자료, PE-89-28, 1989
- [5] 田中, 松田, 他, "Neural Network의 전력계통 사고구간판정문제어의 적용", 일본전기학회 시스템 제어연구회 자료, SC-88-21, 1988
- [6] J.L. McClelland & D.E. Rumelhart, "Rarallel distibuted processing", Vol. 1, 1986, MIT Press
- [7] J.L. McClelland & D.E. Rumelhart, "Explorations In P.D.P.", 1988, MIT Press
- [8] Yoh-Han Pao, "Adaptive Pattern Recognition & Neural Networks", Addison-Wesley, 1989
- [9] Waibel. A., Hampshire. J., "Building Block for Speech", 컴퓨터 매거진, Sept 1989
- [10] 김광호, 박종근, "전력계통 사고구간 판정에의 모듈형 신경 회로망의 구현", 대한전기학회 추계 종합 학술대회 논문집, p. 224, 1989, 11
- [11] K.H. Kim, J.K. Park, "Application of Hierarchical Neural Network to Fault Diagnosis of Power System", 3rd Symposium on Expert Systems Application to Power Systems, April 1-5, 1991, TOKYO-KOBE, JAPAN



김광호(金光鎬)

1966년 1월 17일생. 1988년 서울대 공대 전기공학과 졸업. 1991년 동 대학원 전기공학과 졸업(석사). 현재 서울대 대학원 전기공학과 박사과정.



박종근(朴鍾根)

1952년 10월 21일생. 1973년 서울대 공대 전기공학과 졸업. 1979년 일본 동경대 대학원 전기공학과 졸업(석사). 1982년 일본 동 대학원 전기공학과 졸업(공학). 현재 서울대 공대 전기공학과 부교수. 당학회 평의원.