

論文93-30B-4-5

적응 뉴럴-퍼지 제어시스템의 설계에 관한 연구

(On Designing an Adaptive Neural-Fuzzy Control System)

金成炫**, 金容虎**, 崔永吉*, 沈貴寶**, 全洪兌***

(Seong Hyun Kim, Yong Ho Kim, Young Keel Choi, Kwee Bo Sim and Hong Tae Jeon)

要 約

지능 제어를 구현하기 위한 한 방법으로 본 논문은 퍼지 논리와 신경망 제어기법을 합성 결합한 새로운 형태의 FNC(Fuzzy-Neural Controller)와 적응 뉴럴-퍼지 제어 방식을 제안한다. 제안되는 FNC와 MNN(Model Neural Network)으로 구성된 뉴럴-퍼지 시스템은 적응성과 학습능력의 두가지 주요한 기능을 갖는다. 적응 제어시스템은 학습 알고리즘으로 역전파 학습 알고리즘이 사용된다.

Abstract

As an approach to develop the intelligent control scheme, this paper will propose an adaptive neural-fuzzy control scheme. The proposed neural-fuzzy control system, which consists of the Fuzzy-Neural Controller(FNC) and Model Neural Network(MNN), has two important characteristics of adaptation and learning. The error back propagation algorithm has been adopted as a learning technique.

1. 서 론

일반적으로 제어를 포함한 제어 시스템의 설계에 있어서 최근까지 연구되어온 제어 알고리즘의 대부분은 프로세스의 수학적 모델링에 근거하여 이루어져 있다. 그러므로 복잡한 동특성을 갖는 시스템이나 부하 외란이 존재하는 동적인 환경에서는 기존의 제어 이론으로는 강건한 제어기 구성이 용이하지 못하다.

이러한 어려움을 해결하기 위해서 최근에는 인간의 사고 능력과 적응 능력을 갖는 지능형 제어가 제안되고 있다. 이러한 방향으로 퍼지 이론을 이용한 퍼지 논리 제어기와 신경망 기법을 이용한 신경망 제어기를 들 수 있다.

퍼지 제어는 기존의 제어기에 비해 강건하고, 병렬형, 논리형, 그리고 언어적 제어의 특징을 가지고 있다.^{[1], [2]} 그러나 퍼지 논리 제어기는 전문가에 의한 퍼지 규칙 베이스 구성시 주관적이고 경험에 의존하므로 많은 시간 소비와 제어 규칙의 최적화 문제가 제시된다.

한편 신경망 제어는 자동적으로 지식 습득이 가능하고 정보의 분산 처리에 의한 오차 보간 능력과 외란에 대한 강건성 및 적응 능력등의 장점을 갖는다.^[3]

^[4] 그러나 신경망에서는 최적의 뉴런 및 층의 수를

*正會員, **準會員, 中央大學校 電子工學科
(Dept. of Elec. Eng., Chungang Univ.)

***正會員中央大學校 制御計測工學科
(Dept. of Control & Inst. Eng., ChungAng Univ.)

接受日字: 1992年 9月 29日

결정하기가 힘들고 학습시 지역적 최소치에 빠질 수 있다는 문제점을 갖는다.

따라서 각각의 단점을 보완하고 장점을 강화하기 위해 논리 및 추론의 특성을 갖는 퍼지 이론과 학습 및 적응능력을 갖는 신경망 이론과의 합성(Hybrid) 및 융합(Fusion) 기법에 관한 연구가 최근에 시도되고 있다.^{[5] [6]}

본 논문에서는 퍼지 이론과 신경망을 합성 결합한 새로운 퍼지 신경제어기(Fuzzy-Neural Controller :FNC)와 적응 뉴럴-퍼지 제어 방식을 제안하고 이를 응용하여 비선형 동특성을 갖는 플랜트의 제어기를 구성한다. 제안된 방법은 2 d.o.f. 로봇 매니퓰레이터와 Cart-pole의 위치제어에 적용된다.

II. 퍼지 신경제어기 (Fuzzy-Neural Controller : FNC)

본 절에서는 제안된 FNC 설계 과정에 대해서 설명된다. 다입력-단일출력(MISO) 구조의 일반적인 퍼지 시스템을 고려할때 언어 규칙은 다음과 같이 전건부와 후건부로 구성된다.

$$R_i: \text{IF}(x_1 \text{ is } A_{i1}) \text{ and } \dots \text{ and } (x_n \text{ is } A_{in}) \text{ THEN } (u \text{ is } B_i)$$

┌──────────────────────────┐
└──────────────────────────┘

전건부
후건부

for $i=1, \dots, m$ (1)

여기서, $x_i(i=1, \dots, n)$ 와 u 는 입력변수 및 제어변수이다: A_{ij} and B_i 는 퍼지변수이다.

한편, 상기의 퍼지 제어 규칙을 이용해서 원하는 제어 출력을 추론하기 위한 본 논문에서의 퍼지 추론 방법은 단순화된 추론방법을 사용한다.^[7] 추론과정은 다음과 같다.

$$u^* = \frac{\bigoplus_{i=0}^m \alpha_i \cdot B_i}{\bigoplus_{i=0}^m \alpha_i} \quad (2)$$

$$\alpha_i = \bigoplus_{j=0}^n \mu_{A_{ij}}(x_j^0) \quad (3)$$

여기서, 기호 ‘ \bigoplus ’와 ‘ \bigotimes ’는 각각 대수합 및 대수곱 연산자이다. 또한 α_i 는 i -번째 제어규칙의 전건부의 진리값(truth values)이고, B_i 는 실제 값들이다.

이때, 상기의 추론과정은 신경망 구조로 구현되고 퍼지 규칙의 전건부와 후건부는 비선형성과 학습능력을 갖는 다층 신경망으로 구성된다. 그림 1은 제안된

는 FNC의 구성을 보여준다.




그림 1. 퍼지-신경제어기
Fig. 1. Fuzzy-Neural Controller(FNC).

1. 다층 신경망에 의한 전건부 구성

그림 1에서 퍼지 규칙의 전건부는 $A_1 \sim A_3$ 층에서 구현되며 2개 이상의 뉴런층으로 구성된다. 이때 전건부의 소속함수를 효율적으로 구성하기 위해서 클러스터링 기법이 사용된다. 2개의 입력변수(x_1, x_2)와 단일 출력변수(u)를 갖는 제어 규칙을 설정하고 각 입력변수가 5개의 소속함수를 갖으며 출력 u 는 7개의 소속함수를 갖는다고 가정하면 입력공간은 25개의 퍼지공간으로 나누어 진다. 이때, 같은 제어동작을 갖는 규칙이 같은 입력공간으로 클러스터링될 수 있다면 입력공간은 7개의 클러스터로 줄어들 수 있다. 따라서 퍼지 제어 규칙의 수를 줄일 수 있으며, 뉴런의 시그모이드(sigmoid) 특성에 의해서 비선형 소속함수를 구성할 수 있고, 입력공간을 퍼지하게 분할할 수 있다.^[5, 8]

한편, A_3 층의 뉴런수는 각 부공간(subspace: R^r ($r=1, \dots, 7$))의 수 r 에 해당하며 A_3 층의 출력은 퍼지 규칙의 소속정도이며 식(3)에서의 i -번째 규칙의 전건부의 진리값 α_i 에 해당된다.

다음은 FNC를 학습시키는 과정이다. 학습 목적은 FNC에서 줄어든 7개의 제어규칙이 25개의 제어규칙과 같은 효과를 얻도록 하기 위함이다. 학습후 A_3 층의 출력값은 A_1 층의 입력값에 대해 각 그룹의 소속정도를 나타내므로 퍼지 추론 형태를 갖는다. 오차역전파 학습 알고리즘^[9]을 바탕으로 한 학습과정은 다음과 같다.

먼저, 전체 오차 함수는 식(4)와 같이 정의되며,

이것은 FNC이 각 입력에 대해 원하는 입력분할의 성취여부를 결정한다.

$$E^0 = \frac{1}{2} \sum_{i=1}^r (T_i - O_i)^2 \quad (4)$$

여기서, $T_i = \begin{cases} 1, & (x_1, x_2) \in R^i \\ 0, & \text{otherwise} \end{cases}$

O_i 는 A_3 층의 i -번째 뉴런이며, $r(=1, \dots, 7)$ 는 뉴런 수 (또는, 클러스터 수)이다. 이때 'T'는 입력데이터가 원하는 클러스터에 속하는지의 여부에 따라 결정된다.

오차함수를 최소화하기 위해 역전파 학습 알고리즘을 이용해서 $A_1 \sim A_3$ 층의 가중치를 조정한다. A_2 층과 A_3 층 사이의 가중치 변화량 ΔW_{ij} 및 중간층 $A_1 \sim A_2$ 층에서의 가중치 변화량 ΔW_{jk} 는 다음과 같이 구해진다.

$$\Delta W_{ij} = -\eta \frac{\partial E^0}{\partial W_{ij}} = -\eta \delta_i O_j \quad (5a)$$

$$\Delta W_{jk} = -\eta \frac{\partial E^0}{\partial W_{jk}} = -\eta \delta_j X_k \quad (5b)$$

여기서, 각층의 오차신호는

$$\delta_i = (T_i - O_i) f'(U_i) \quad (6a)$$

$$\delta_j = f'(U_j) \sum_i \delta_i W_{ij} \quad (6b)$$

η 는 학습율(learning rate), O_i 는 A_2 층의 i 번째 뉴런의 출력이고 X_k 는 제어기의 입력이며 $f(\cdot)$ 는 시그모이드 활성화 함수의 도함수, 그리고 U_i 와 U_j 는 A_2 과 A_3 층의 각 뉴런에 대한 입력의 총합이다.

최종적으로 오차함수를 최소화하기 위해서 가중치들은 다음과 같이 갱신된다.

$$W_{ij}(t+1) = W_{ij}(t) + \Delta W_{ij} + \alpha [W_{ij}(t) - W_{ij}(t-1)] \quad (7a)$$

$$W_{jk}(t+1) = W_{jk}(t) + \Delta W_{jk} + \alpha [W_{jk}(t) - W_{jk}(t-1)] \quad (7b)$$

2. 다층 신경망에 의한 후진부 구성

그림 1과 같이 후진부는 신경망의 $A_3 \sim A_4$ 층으로 구현된다. 가중치 W_{ai} 는 식(2)의 B_i 에 대응하며 상수값이다. 학습과정에서 소속함수($B_i, i=1, \dots, 7$)는 식(8)와 같은 오차함수를 최소화하는 역전파 알고리즘으로 조정된다.

$$E^* = \frac{1}{2} (X_d - X_p) A (X_d - X_p) \quad (8)$$

여기서, $X_d = [X_{d1}, \dots, X_{dn}]^T$ 와 $X_p = [X_{p1}, \dots, X_{pn}]^T$ 는 플랜트의 원하는 출력과 실제 출력이고 A 는 $n \times n$ symmetric positive definite weighting matrix이다. 그리고, 가중치 W_{ai} 의 변화량(ΔW_{ai})은 다음과 같다.

$$\Delta W_{ai} = -\eta \frac{\partial E^0}{\partial W_{ai}} = -\eta \delta_c O_i \quad (9)$$

여기서, δ_c 는 FNC의 출력단에서의 오차 신호이며 플랜트를 통해서 역전파되어 진다. 이때, 적당한 초기 가중치 W_{ai} 는 FNC의 학습속도를 향상시키고 플랜트의 초기 안정성을 보장한다.

3. 환산계수의 학습

한편, 환산계수 GE와 GC는 다음 식(10)과 같이 제어기의 실제 입력공간 $X'_1 \times X'_2$ 을 퍼지 입력공간 $X_1 \times X_2$ 으로 변환시키고 입력공간의 크기를 조정하기 때문에 제어기 성능에 중요한 영향을 미친다.

$$\begin{aligned} X_1 &= X'_1 \cdot GE \\ X_2 &= X'_2 \cdot GC \end{aligned} \quad (10)$$

그러므로 FNC의 성능을 향상시키기 위해서 FNC의 후진부의 소속함수와 환산계수는 역전파 알고리즘으로 동시에 조정되어야 한다. 환산계수의 변화량은 다음과 같다.

$$\Delta GE = -\eta \frac{\partial E^*}{\partial GE} = -\eta \delta_k X'_1 \quad (11a)$$

$$\Delta GC = -\eta \frac{\partial E^*}{\partial GC} = -\eta \delta_k X'_2 \quad (11b)$$

여기서, $\delta_k = \delta'_i W_{ik}, \delta'_i = f'(U_i) \sum_j \delta'_j W_{ij}, \delta'_i = f'(U_i) \sum_j \delta'_j W_{ji}$

III. 적응 뉴럴-퍼지 제어 시스템 (Adaptive Neural-Fuzzy Control System)

상기의 제안된 제어기를 플랜트의 제어기 설계에 적용했을때 식(9)에서의 오차신호 c 를 얻기는 쉽지만, 그것은 학습알고리즘으로 오차 역전파 알고리즘을 사용시 실제 플랜트의 출력값에서 얻어지는 학습 정보를 제어기의 학습정보로 직접적으로 이용하기 어

럽다.

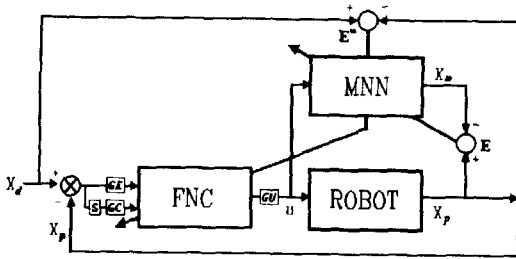


그림 2. 적응 뉴럴-퍼지 제어 시스템

Fig. 2. Adaptive neural-fuzzy control system.

해결방안으로 본 논문은 제어기에 적응성을 부여하고 학습시킬 수 있도록하는 방법으로 모델 신경망(MNN)과 FNC이 결합한 적응 뉴럴-퍼지 제어 시스템을 제안한다. 제안되는 제어 시스템은 MNN을 이용해서 플랜트의 동특성을 동정하고, 관찰 가능한 플랜트의 출력과 원하는 출력과의 오차를 MNN의 구조로부터 역전파하여 FNC의 최적의 제어량을 발생시키기 위한 제어 규칙을 자기동조한다. 그림 2은 2개의 입력과 단일 출력을 갖는 FNC와 MNN으로 구성된 제어 시스템을 보여준다.

또한, MNN은 플랜트 동특성을 동정하기 위해서 일반적인 신경망으로 구성하였다. 이때, MNN의 입력은 플랜트의 현재 상태($X_i(t)$, $i=1, \dots, n$)와 FNC의 제어입력 u 이고 MNN의 출력은 플랜트의 다음 상태 $X_i(t+1)$ 이다. MNN은 기존의 역전파 학습알고리즘으로 플랜트의 다음 상태를 추정하도록 학습되어진다. 학습시의 오차함수는 다음과 같이 정의된다.

$$E = \frac{1}{2} \sum_{i=1}^n (X_{pi} - X_{mi})^2 \quad (12)$$

상기의 오차함수를 최소화하기 위해서, 가중치의 변화량 ΔW_{mij} 과 ΔW_{mjk} 및 오차신호들은 일반화된 델타규칙에의해서 다음과 같이 구해진다.

$$\Delta W_{mij} = -\eta \frac{\partial E}{\partial W_{mij}} = -\eta \delta_{mi} O_{mi} \quad (13a)$$

$$\Delta W_{mjk} = -\eta \frac{\partial E}{\partial W_{mjk}} = -\eta \delta_{mj} X_k \quad (13b)$$

$$\delta_{mi} = X_{pi} - X_{mi} \quad (14a)$$

$$\delta'_{mi} = f'(U_{mj}) \sum_j \delta_{mj} W_{mij} \quad (14b)$$

MNN이 플랜트를 정확하게 동정하도록 학습되어지면, 식(8)의 플랜트의 출력 X_p 는 MNN의 출력 X_m 로 대체할 수 있다. FNC의 가중치 W_{ci} 를 학습하기 위해서 오차신호 δ_c 는 식(8)로부터 계산된다. 그리고, MNN의 출력층의 i 번째 뉴런에서 오차신호 δ'_{mi} 는 다음과 같다.

$$\begin{aligned} \delta'_{mi} &= \frac{\partial E^*}{\partial U_{mij}} = -\frac{\partial E^*}{\partial X_{mi}} \cdot \frac{\partial X_{mi}}{\partial U_{mij}} \\ &= a_i (X_{di} - X_{mi}) \end{aligned} \quad (15)$$

여기서, $\partial X_{mi} / \partial U_{mij} = 1$ 이고 a_i 는 가중 계수이다. 또한, 중간층의 j 번째 뉴런에서의 오차신호는

$$\delta'_{mj} = f'(U_{mj}) \sum_i \delta'_{mi} W_{mij} \quad (16)$$

그러므로 FNC의 출력단에서의 오차신호는 다음과 같이 구해진다.

$$\delta'_c = \sum_j \delta'_{mj} W_{mij} \quad (17)$$

최종적으로 식(8)의 오차함수를 최소화하기 위해서 가중치들은 다음과 같이 갱신된다.

$$W_{ci}(t+1) = W_{ci}(t) + \Delta W_{ci} \quad (18)$$

IV. 모의 실험 및 결과

1. Cart-pole 규형 제어

Cart-pole은 1차원의 수평방향으로 이동할 수 있고 pole은 축으로부터 좌(-), 우(+)로 자유 변화한다. 제어목적은 cart를 오른쪽(+), 왼쪽(-)으로 힘(F)를 인가함으로써 pole의 균형을 유지하며 원하는 위치로 cart를 이동시키는데 있다. Cart-pole의 상태변수는 θ , $\omega (= d\theta/dt)$, x , 그리고 $v (= dx/dt)$ 이고 초기 상태를 $\theta = 0.2(\text{rad})$, $x = 1.0(\text{m})$ 로 선정하였다. 그리고 Cart-pole을 위한 FNC는 5층 구조를 갖는 28(4-10-10-3-1)개의 뉴런수로 구성하였으며 입력변수는 $e_1(-\theta)$, $e_2(\omega)$, $e_3(x-X)$, 그리고 $e_4(v)$ 이다. FNC의 환산계수 및 후건부 소속함수를 표 1과 같이 초기화 시켰다.

Cart-pole 초기상태로 모의 실험한 결과는 FNC의 첫번째 수행결과는 그림 3처럼 pole이 균형을 이루지 못하였다. 그러나 그림 4에서 보는 바와 같이 10번째 FNC를 학습한 후, pole의 각도는 안정된 상

태로 도립함을 보인다. 생성된 FNC의 후진부 소속 함수와 환산계수는 표1과 같다.

표 1. Cart-pole을 위한 FNC의 초기치 및 수정치

Table 1. Initial and refined values of FNC for the cart-pole

기 호	초기치	수정치
Wc1	-0.300	-0.853
Wc2	0.000	0.000
Wc3	0.300	0.757
GE1	6.25	6.719
GE2	1.00	1.408
GC1	3.00	2.981
GC2	2.00	1.687
GU	70.000	70.000




그림 3. FNC의 첫번째 수행결과 및 MNN의 추정 결과

Fig. 3. The first result of FNC and the estimation result of MNN.




그림 4. 10번째 학습 이후의 FNC 수행 결과

Fig. 4. Performance result of FNC after 10 iterations.

2 로봇 매니플레이터의 위치 제어

로봇 위치제어는 명령된 경로를 정확하게 수행하도록 하는데 그 목표가 있다. 로봇 매니플레이터 시스템의 상태는 θ, ω 의 2가지 상태변수로 추정가능하다고 가정하였다. 주행경로는 카르테시안 공간에서 타원 궤적을 선정하였다.

FNC의 전진부에 해당하는 신경망은 4층 구조를 이루고 있으며 27(2-10-10-5)개의 뉴런으로 구성된다. 그리고 모델 신경망의 각 뉴런수는 26(4-10-10-2)개 이다. 후진부의 초기 소속함수와 환산계수는 표 2과 같다.

표 2. 로봇을 위한 FNC의 초기치 및 수정치
Table 2. Initial and refined values of FNC for the robot

기 호	첫번째 링크		두번째 링크	
	초기치	수정치	초기치	수정치
Wc1	-0.470	-0.485	-0.310	-0.402
Wc2	-0.100	-0.131	-0.100	-0.265
Wc3	0.000	0.000	0.000	0.000
Wc4	0.100	0.134	0.100	0.100
Wc5	0.500	0.540	0.410	0.410
GE	13.120	79.669	30.160	183.376
GC	1.540	2.024	0.920	0.594
GU	70.000	70.000	70.000	70.000




그림 5. FNC의 첫번째 수행결과 및 MNN의 추정 결과

Fig. 5. The first result of FNC and the estimation result of MNN.

상기의 과정에서 그림 5과 6의 결과를 얻었다. 그림 5에서 초기화된 FNC로 수행된 결과를 보이고 있

다. MNN은 1500번째 학습후에 효과적으로 플랜트의 동특성을 추정하였다. 그러나 초기 대략적으로 설정한 퍼지 제어 규칙으로 수행되었기 때문에 그 응답은 매우 만족스럽지 못하다. FNC 제어기의 20번째 학습한 후에는 그림 6에서 보는 바와 같이 원하는 경로와 로봇의 실제 경로와의 오차가 거의 없음을 보인다. 표 2은 20번째 학습후에 갱신된 소속함수와 환산계수(GE, GC)를 보여준다.




그림 6. 20번째 학습이후의 FNC 수행 결과
 Fig. 6. Performance result of FNC after 20 iterations.


V. 결론

본 논문은 지능 제어를 위한 한 방향으로서 논리 및 추론의 장점을 갖는 퍼지 이론과 학습능력을 갖는 신경망 기법의 합성 결합하여 새로운 퍼지 신경제어기(FNC)와 적응 뉴럴-퍼지 제어 방식을 제안하였다. FNC의 전건부를 효율적으로 구성하기 위해서 다층 신경망과 클러스터링 기법을 사용하였다. 신경망과 클러스터링 기법에 의해서 퍼지 제어 규칙의 수를 줄일 수 있었으며, 효율적으로 전건부를 구성할 수 있었다 또한, 제안된 FNC와 모델 신경망으로 구성된 제어 시스템은 불확실한 플랜트의 동특성을 동정하고 FNC에 적응성을 부여하도록 모델 신경망의 구조로부터 오차신호를 역전파하고 후건부의 소속함수를 자동적으로 동조하였다. 그러므로 제어규칙을 생성하는데 시간소비를 줄일수 있었다. 이러한 제안된 제어 시스템의 효율성은 cart-pole과 로봇 매니플레이터의 모의실험에 의해 입증되었다

參考文獻

- [1] M. Sugeno, M. Nishida, "Fuzzy control of model car," *Fuzzy Sets Syst.*, vol. 16, pp.103-113, 1985.
- [2] B. P. Graham, R. B. Newell, "Fuzzy identification and control of a liquid level rig," *Fuzzy Sets Syst.*, vol. 26, pp.255-273, 1988.
- [3] Teruo Fujii, Tamaki Ura, "SONCS:Self - Organizing Neural - Net-Controller System for Autonomous Under Water Robots," *IJCNN '91*, vol.3, pp.1973-1982, 1991.
- [4] A. Guez, J. Eilbert, and M. Kam, "Neuromorphic Architecture for Fast Adaptive Robot Control," *IEEE International Conference on Neural Networks*, vol.4, pp.567-571, 1987.
- [5] H. Takagi, "Fusion Technology of Fuzzy Theory and Neural Network-Survey and Future directions," *Int. Conf. on Fuzzy Theory & Neural Network(IIZUKA-90)*, vol.1, pp.13-26, 1990.
- [6] Y. Dote, "Fuzzy and Neural Network Controller," *Proc. of IECON'90*, vol. 2, pp.1315-1343, 1990.
- [7] H. Mizumoto, "Realization of PID controls by Fuzzy control methods," *IEEE Int. Conf. on Fuzzy Systems*, pp. 709-715, 1992.
- [8] H. Takagi, "Neural Network Designed on Approximate Reasoning Architecture and its the Pattern Recognition," *Int. Conf. on Fuzzy Theory & Neural Network(IIZUKA-90)*, vol.2, pp.671-674, 1990.
- [9] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning internal representations by error propagation," *Parallel Distributed Processing*, the MIT press, pp.318-362, 1986.

著 者 紹 介



金 成 炫 (準會員)

1964年 3月 30日生. 1990年 중앙대학교 전자공학과(공학사). 1993년 중앙대학교 대학원 전자공학과(공학석사). 1993년 ~현재 중앙대학교 대학원 전자공학과 박사과정 재학중. 주관심분야는 Robotics,

Neural Network, Fuzzy logic control, Fuzzy-Neural fusion 등임.



崔 永 吉 (正會員)

1950年 4月 7日生. 1974년 중앙대학교 전자공학과(공학사). 1981년 고려대학교 대학원 전자공학과(공학석사). 현재 중앙대학교 대학원 전자공학과 박사과정 재학중. 1981년 ~현재 부천전문대학 전자계산

기과 부교수. 주관심분야는 Robotics, Neural Network, Fuzzy logic control 등임.



金 容 虎 (準會員)

1962年 3月 4日生. 1986년 광운대학교 전자공학과(공학사). 1988년 중앙대학교 대학원 전자공학과(공학석사). 1992년 ~현재 중앙대학교 대학원 전자공학과 박사과정 재학중. 주관심분야는 Robotics,

Neural Network, Fuzzy optimal theory, Genetic Algorithms 등임.



沈 貴 寶 (正會員)

1956年 9月 20日生. 1984년 중앙대학교 전자공학과(공학사). 1986년 중앙대학교 대학원 전자공학과(공학석사). 1990년 일본 동경대학 전기 및 전자공학과(공학박사). 1991년 ~현재 중앙대학교 제어계

측공학과 조교수. 주관심분야는 Robotics, Neural Network, Fuzzy Control, Micro-Robot, Intelligent Sensor 등임.

全 洪 兌 (正會員) 第29卷 B編 第1號 參照

현재 중앙대학교 전자공학과 부교수