

論文2003-40CI-2-2

# 가상 로봇 팔 제어를 위한 퍼지-SOFM 방식의 근전도 패턴인식

## (A Virtual Robot Arm Control by EMG Pattern Recognition of Fuzzy-SOFM Method)

李政勳\*, 鄭慶權\*, 李賢寬\*\*, 嚴基煥\*

(Jeong Hun Lee, Kyung Kwon Jung, Hyun Kwan Lee, and Ki Hwan Eom)

### 요 약

본 논문에서는 개선된 SOFM(Self Organizing Feature Map)방식을 이용한 근전도 패턴인식으로 가상 로봇 팔을 제어하는 방식을 제안한다. 개선된 SOFM 방식은 근전도 신호의 전처리기를 사용하는 대신에 근전도 신호 자체를 SOFM에 입력으로 사용하고, 퍼지논리시스템을 이용하여 SOFM의 이웃반경과 학습율을 자동 조절하는 간단한 방식으로 입력 패턴을 더욱 빠르고 신뢰성있게 분류한다. 개선된 방식의 성능을 확인하기 위하여 어깨, 손목, 팔꿈치의 여섯 가지 동작의 근전도 패턴인식을 실험한 결과 기존의 일반적인 SOFM방식보다 제안한 SOFM방식의 인식율이 21.7% 향상되고, 평균학습 수도 절반이하로 감소되었으며, 인식한 근전도 신호를 이용하여 컴퓨터 상의 가상 로봇 팔을 정확하게 제어하였다.

### Abstract

We proposed a method of a virtual robot arm controlled by the EMG pattern recognition using an improved SOFM method. The proposed method is simple in that the EMG signals are used as SOFM's input directly without preprocessing but nevertheless input patterns are reliably classified and then used for fuzzy logic systems to automatically tune the neighborhood and the learning rate. In order to verify the effectiveness of the proposed method, we experimented on EMG pattern recognition of 6 movements from the shoulder, wrist, and elbow. Experimental results show that the proposed SOFM method has 21.7% higher recognition rate than the general SOFM method, the average number of learning iterations has been decreased, and then the virtual robot arm is controlled by EMG pattern recognition.

**Keywords** : fuzzy, SOFM, pattern recognition, EMG signal, virtual robot arm

### 1. 서 론

인간이 근육을 수축시킬 때 발생하는 근전도 신호를

추출하여 처리하는 근전도 신호처리 분야는 크게 근육 질환의 진단이나 근육의 피로도를 측정하여 임상의학 및 스포츠 과학에 응용하는 분야와, 수족의 기능을 인간 기계 시스템에 적용하는 보철제어(prosthetic control)를 위한 응용분야로 나눌 수 있다<sup>1, 2, 6)</sup>.

\* 正會員, 東國大學校 電子工學科  
(Dept. of Electronic Engineering, Dongguk Univ.)

\*\* 正會員, 湖南大學校 인터넷프로그래밍學科  
(Dept. of Internet Programming, Honam Univ.)

接受日字:2002年8月21日, 수정완료일:2003年3月3日

일반적으로 팔의 보철제어는 근전도 신호를 이용하여 팔의 동작을 정확하게 인식하고 이를 바탕으로 보

철용 팔을 제어한다. 팔의 동작인식을 위한 근전도 신호의 패턴인식은 실지의 근전도 신호를 가지고 각 해당 동작의 특성을 잘 반영하는 특징 파라미터를 추출하여 이러한 특징 파라미터들을 바탕으로 여러 가지 동작을 분류해 내는 것이다. 이러한 보철제어를 위한 근전도 신호처리에 대한 연구는 지금까지 많이 진행되고 있다<sup>[1,6]</sup>.

Hansan 등은 근전도 신호의 지속시간, 진폭, 주파수 등의 특징을 추출하여 인체 움직임의 해석을 시도하였고, Yasuharu와 Mitsuo는 근전도 신호에서 근력강도를 계산하여, 팔 움직임패적의 추정을 위한 연구를 하였다<sup>[2-3]</sup>.

이러한 연구들은 근전도 신호의 분석과 특정한 전처리 과정을 통한 근전도 신호의 지속시간, 진폭, 주파수를 추출하거나 근력강도를 계산하는 단계를 필요로 하므로 시스템의 계산량 증가와 시간적 지연은 불가피하다고 할 수 있다.

최근에는 Christodoulou, Lee 등이 신경회로망을 이용하여 근육의 동작을 분류하는 연구들이 진행되고 있으며, 신경회로망을 이용하는 경우에는 주로 경쟁네트 워크인 Hamming Network, Self Organizing Feature Map(SOFM) 및 Learning Vector Quantization(LVQ) 등을 사용하고 있다<sup>[4-6]</sup>.

그러나 이들의 공통적인 문제점은 최적의 학습을 선택, 초기 연결강도의 값이나 배열, 이웃반경 및 클러스터가 서로 밀접하게 가까이 있을 때의 안정도 등에 있다.

본 논문에서는 팔의 보철제어를 위해 개선된 SOFM을 이용하여 근전도 신호의 패턴을 인식하고, 가상 로봇 팔을 제어하는 방식을 제안한다.

제안하는 방식은 어깨, 팔꿈치, 손목관절 등의 근전도를 개선된 SOFM을 이용하여 근전도 신호의 특징추출을 위한 전처리 과정 없이 신호자체를 직접 입력으로 패턴을 분류한다. 개선된 SOFM은 신뢰성과 처리시간 단축을 위하여 퍼지 논리 시스템을 이용하여 훈련하는 동안 이웃반경과 학습율을 자동 조절한다. 퍼지 논리 시스템은 입력으로 입력벡터와 각 출력노드에 대한 연결강도 벡터와의 거리 및 거리의 변화율을 사용하고, 출력으로 이웃반경과 학습율을 사용하여 구성한다.

제안한 방식의 유용성을 확인하기 위하여 팔의 부위별로 가능한 동작인 어깨의 굴곡과 신전, 팔꿈치의 굴

곡과 신전 및 손목의 장굴과 배굴 등의 근전도 패턴인식에 대하여 학습율과 이웃반경을 고정한 일반적인 SOFM과 제안한 SOFM에 대하여 성능을 비교 검토하고, 분류한 정보를 이용하여 컴퓨터상에 가상으로 제작된 로봇 팔을 제어한다.

II. 근전도 신호 및 측정

근전도 신호는 근육의 수축 및 이완 시에 발생하는 전기적 신호로서 10 2,000[Hz]의 주파수와 10[μV] -15[mV]의 전압특성을 갖는다. 근전도 신호의 측정에는 보통 침 전극(needle electrode)과 표면 전극(surface electrode)이 사용되는데 일반적으로 피검자에게 고통도 없고 성능도 뒤지지 않는 전극용 전도젤이 발려져 있는 1회용 Ag/AgCl 표면 전극이 사용되고 있다.

근전도 신호를 정확하게 인식하여 그 신호를 보철용 팔이나 로봇 팔에 제어하기 위한 근전도 신호 측정 시스템은 <그림 1>과 같다.

본 논문에서 측정된 근전도 신호는 팔의 부위별로 가능한 동작은 여러 가지가 있으나 일반적으로 다음과 같은 6가지 동작이다. <그림 2>는 어깨의 굴곡(flexion of a shoulder: FS)과 신전(extension of a shoulder: ES), <그림 3>은 팔꿈치의 굴곡(flexion of an elbow: FE)과 신전(extension of an elbow: EE), <그림 4>는 손목의 굴곡( 손목의 굴곡(flexion of a wrist: FW)과 신전(extension of a wrist: EW)을 각각 나타낸다.




그림 1. 근전도 신호 측정 시스템  
Fig. 1. The measuring system of EMG signal.




그림 2. 어깨의 굴곡과 신전  
Fig. 2. Flexion and extension of a shoulder.



그림 3. 팔꿈치의 굴곡과 신전  
Fig. 3. Flexion and extension of an elbow.




그림 4. 손목의 굴곡과 신전  
Fig. 4. Flexion and extension of a wrist.

### III. 제안한 근전도 신호 분류 방식

#### 1. 퍼지 논리 시스템을 이용한 제안한 SOFM 방식

SOFM의 학습은 경쟁 학습의 일종으로 입력 패턴이 입력 층에 주어지면 경쟁 층의 뉴런들은 학습 할 수 있는 특권이 제한적으로 주어지는데 입력 패턴과 가장 거리가 가까운 승리 뉴런과 이웃 뉴런들이 학습에 기여하게 된다. 경쟁 층에서 승리 뉴런을 중심으로 이웃 뉴런의 학습영역 범위는 학습이 진행됨에 따라서 축소된다. 즉 승리 뉴런의 연결강도와 이웃뉴런의 연결강도는 갱신되며, 출력이 수렴상태로 갈 때까지 학습이 반복되며, 이때 학습율에 직접적인 영향을 받는다<sup>[5]</sup>. 본 논문에서는 SOFM의 신뢰성과 처리시간 단축을 위하여 간단한 퍼지 논리 시스템을 이용하여 훈련하는 동안 이웃반경과 학습율을 자동 조절하는 방식을 제안한다. SOFM의 이웃반경과 학습율을 자동 조절하는 시스템의 블록선도는 <그림 5>와 같다.

<그림 5>에서 퍼지 논리 시스템의 입력은 입력벡터와 각 출력 뉴런에 대한 연결강도 사이의 거리  $d$ , 거리  $d$ 의 변화량  $dd$ 이고 출력은 학습율  $\alpha$ 와 이웃반경  $NH$ 이다. 일반적인 퍼지 논리 시스템은 그 시스템에 전문가나 숙련자들의 지식을 근거로 퍼지 제어규칙과 소속함수를 만드나 본 논문에서는 시물레이션을 통한 데이터를 이용하여 만든다.

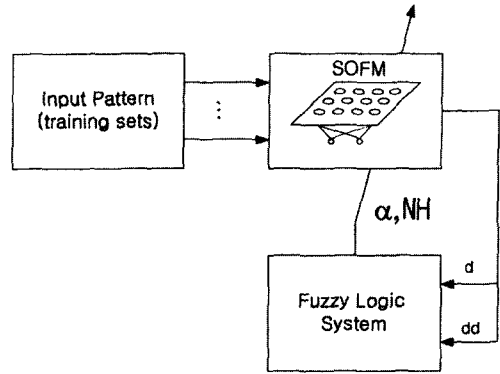


그림 5. SOFM의 이웃반경과 학습율 자동 조절 시스템 블록선도

Fig. 5. The block diagram of autotuning system for neighborhood and learning rate of SOFM.




그림 6. 거리와 학습율에 대한 그래프  
Fig. 6. The graph of distance and learning rate.




그림 7. 거리  $d$ 의 소속함수  
Fig. 7. The membership function of distance  $d$ .

시물레이션은 다음 장에서의 근전도 신호 패턴인식에 대하여 시물레이션 한다. 시물레이션 조건은 SOFM




그림 8. 거리의 변화  $dd$  에 대한 소속함수  
 Fig. 8. The membership function of changed distance  $dd$ .




그림 9. 학습율의 소속함수  
 Fig. 9. The membership function of learning rate.




그림 10. 이웃반경의 소속함수  
 Fig. 10. The membership function of neighborhood.

의 구성을 100개(10x10)의 뉴런, 이웃반경은 1, 학습율은 0.1로 하고, 훈련 데이터는 2,400개로 하였다.

거리와 학습율의 변화에 대한 시뮬레이션 결과는 <그림 6>과 같다. <그림 6>에서 거리가 커지면 학습율도 커지는 경향을 알 수 있다.

이웃반경은 초기에 거리가 큰 경우에는 크게하고 학습이 되어 거리가 작아지는 경우에 작게한다.

이러한 경향을 이용하여 다음과 같은 퍼지논리 시스템을 구성한다.

이웃반경과 학습율에 대한 퍼지논리시스템의 입력의 구성은 동일하게 한다.

퍼지 논리 시스템의 거리  $d$ 의 소속함수는 <그림 7>과 같이 삼각형 함수로 구성하였고, 입력들은 이 소속함수에 의하여 퍼지화된다. <그림 8>는 거리  $d$ 의 변화량  $dd$  이다.

퍼지 논리 시스템의 출력은 이웃반경과 학습율이며 <그림 9>와 <그림 10>과 같이 구성하였다.

퍼지 제어 규칙도 앞 장의 시뮬레이션을 바탕으로 거리  $d$ 와 거리의 변화  $dd$ 에 따른 이웃반경과 학습율에 대한 관계를 <표 1>과 <표 2>와 같이 정한다.

여기서 사용한 언어적인 변수들의 의미는 N: Negative, Z: Zero, P: Positive, S: Small, M: Medium, B: Big이며, 가운데 변수들은 출력 변수들이다.

<표 1>과 <표 2>의 퍼지 제어 규칙을 이용하여 퍼지 추론을 하는 방법으로 본 논문에서는 최소 최대 연산을 사용하고, 퍼지 추론의 결과인 퍼지 값을 단일 실수 값으로 변환 시키는 비퍼지화는 무게중심법을 사용한다<sup>[7]</sup>.

표 1. 이웃반경의 퍼지 규칙  
 Table 1. Fuzzy rule of neighborhood.

$d \backslash dd$	N	Z	P
S	S	S	M
M	M	M	B
B	B	B	B

표 2. 학습율의 퍼지 규칙  
 Table 2. Fuzzy rule of learning rate.

$d \backslash dd$	N	Z	P
S	S	S	M
M	S	M	B
B	M	B	B

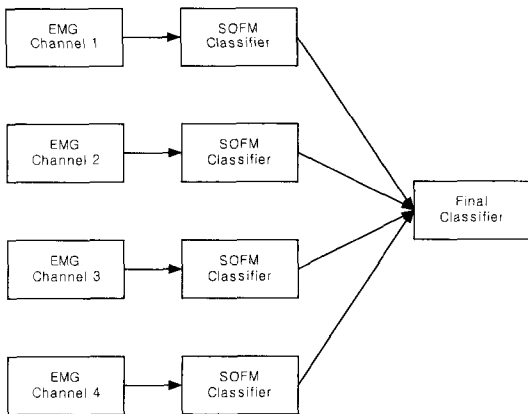


그림 11. 제안한 근전도 신호 분류 방식의 블록선도  
Fig. 11. The block diagram of proposed EMG signal classification.

2. 근전도 신호분류 방식

인체의 움직임 추정을 위한 기존의 근전도 신호처리 방식은 전처리 과정을 통해 동작과 관련된 근육의 근전도 신호로부터 주파수, 전력 스펙트럼 및 근력강도 등의 특징을 추출한 후, 이를 입력으로 사용하여 근전도 신호와 움직임의 상관관계를 밝힌다. 제안하는 방식은 근전도 신호의 전처리 과정을 통한 특징 추출 없이 신호자체를 SOFM의 입력으로 직접 사용하여 패턴을 분류한다. 어깨, 팔꿈치 및 손목 근처에 고정된 4개의 채널의 위치에서 각 동작에 대한 근전도 신호를 측정하기 위한 제안한 근전도 패턴분류 방식의 블록선도는 <그림 11>과 같다.

IV. 실험 및 검토

실험은 고정된 4개 채널의 위치에서 다음과 같은 6가지 동작에 대한 근전도 신호를 측정한다.

1. 어깨의 굴곡(FS: Flexion of a shoulder)
2. 어깨의 신전(ES: Extension of a shoulder)
3. 팔꿈치의 굴곡(FE: Flexion of an elbow)
4. 팔꿈치의 신전(EE: Extension of an elbow)
5. 손목의 장굴(FW: Flexion of a wrist)
6. 손목의 배굴(EW: Extension of a wrist)

제안한 SOFM의 학습을 위한 훈련 세트(training set)로 각 동작에 대한 4개 채널의 근전도 신호를 SOFM의 입력으로 사용한다.

근전도 신호의 측정과 분류를 위한 전체적인 실험 시스템 구성도는 <그림 12>와 같다.




그림 12. 실험 시스템 구성도  
Fig. 12. The block diagram of an experimental system.

각 채널의 근전도 신호 측정은 각 채널의 차동 증폭기를 위한 4쌍의 전극과 하나의 공통접지 전극을 사용한 총 9개의 전극으로 4개 채널을 구성하여 신호를 측정하였다. 측정은 오른팔에 대하여 실행하였으며, 측정시 손목과 팔꿈치, 어깨를 움직이도록 팔의 비틀림에 대한 움직임을 최대한 억제하였으며, 반복되는 측정에서도 같은 자세를 유지하였다.

A/D 변환기는 8비트 4채널 방식인 Analog Device사의 AD7824를 사용하였으며 변환된 데이터는 인터페이스 카드를 이용하여 저장하였다.

신호의 측정을 위하여 19~58dB까지의 이득을 갖는 증폭기와 5~1,200[Hz]의 신호를 통과시키는 필터를 OP Amp INA101HP와 OP Amp LF412CN을 사용하여 구성하였다. 또한 최종 출력이 A/D 변환기의 입력 범위(5V~+5V)를 초과하지 않도록 주 증폭기의 이득을 조정하였다. 초기 형상 맵 구성은 제안한 SOFM 방식(PSOFM: Proposed SOFM)과 이웃반경을 1, 학습율을 0.1로 고정한 일반적인 SOFM 방식(GSOFM: General SOFM)을 동일하게 100 (10x10)의 2차원 뉴런을 각 채널에 대하여 구성 하였다. 2,400(4channels 6개 신호100번 횟수)개의 훈련 세트를 이용하여 시뮬레이션 한 각 채널 SOFM1, SOFM2, SOFM3, SOFM4의 각 동작에 관한 출력 뉴런 즉 승리 뉴런은 <표 3>과 같다.

<표 3>에서 번호는 구성된 뉴런의 상단에서부터 오른쪽으로 1, 2로 붙인 번호를 의미한다.

학습을 하는 과정에서 학습율이 점차 감소하여 5000번 이후에는 학습에 의한 연결강도의 변화가 적어서 학습 횟수를 5000번으로 하였다.

실험에서 사용한 비교 방식은 GSOFM이 5000번의 학습에서 분류되어 <표 3>의 출력 뉴런이 나오기까지의 각 동작의 평균 학습수(Average iteration number)에 대하여 GSOFM 방식과 제안한 PSOFM 방식을 비교한 것은 <표 4>와 같다.

표 3. SOFM의 출력 뉴런

Table 3. The output neurons of SOFM.

채널 동작	CH 1	CH 2	CH 3	CH 4
FS	95	48	22	76
ES	85	46	19	76
FE	41	7	21	43
EE	95	6	95	43
FW	95	46	12	16
EW	95	57	22	34

표 4. 평균 학습 수 비교

Table 4. The comparison of average iteration numbers.

동작	방식	GSOFM	PSOFM
FS		5000	2135
ES		5000	2500
FE		5000	1685
EE		5000	2065
FW		5000	2392
EW		5000	2137

표 5. GSOFM의 신호 인식 결과

Table 5. The results of GSOFM's recognition.

신호 동작	측정횟수	분류	인식성공률(%)
FS	50	36	72
ES	50	30	60
FE	50	42	84
EE	50	38	76
FW	50	42	84
EW	50	37	74

<표 4>에서 PSOFM의 평균 학습 수는 약 2150회이며 GSOFM보다 약 57%로 감소됨을 알 수 있다. <표 5>와 <표 6>은 시험세트(test set)로 50회 측정된 각 동작에 대한 GSOFM과 PSOFM의 근전도 신호의 인식결과를 나타낸다.

<표 5>와 <표 6>의 실험 결과 GSOFM 방식은 인식 성공률이 평균 75%이나 PSOFM 방식은 평균

표 6. 제안한 PSOFM 신호 인식결과

Table 6. The results of PSOFM's recognition.

신호 동작	측정횟수	분류	인식성공률(%)
FS	50	44	88
ES	50	42	84
FE	50	47	94
EE	50	46	92
FW	50	47	94
EW	50	48	96




그림 13. 모델링 된 3차원 가상 로봇 팔  
Fig. 13. The modeling of the 3 D virtual robot arm.

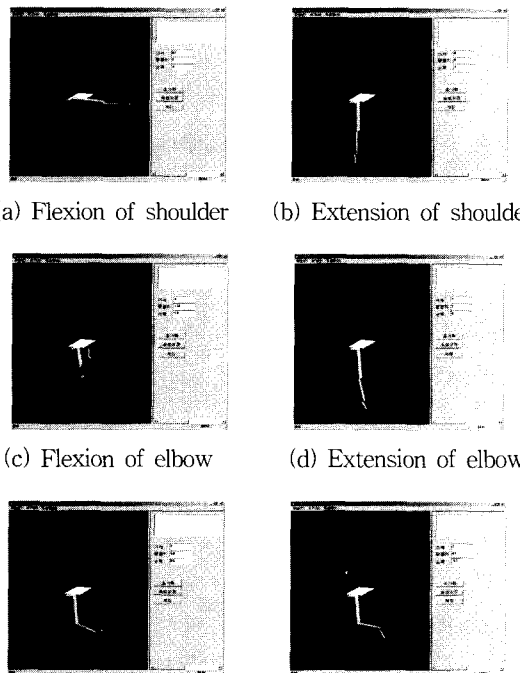


그림 14. 근전도 신호 분류에 의한 가상 로봇 팔의 제어

Fig. 14. The virtual robot arm controlled by EMG pattern classifier.

91.3%로 성능이 크게 개선됨을 알 수 있다. 즉 팔의 움직임에 대한 근전도 신호는 학습에 의해 보다 정확하게 분류할 수 있음을 알 수 있다. 분류한 정보를 이용하여 컴퓨터상에 가상으로 제작된 로봇 팔을 제어하기 위하여 3차원 그래픽 프로그래밍을 위해서 OpenGL이라는 라이브러리를 사용하였다. <그림 13>과 같이 가상 로봇 팔의 구성을 어깨, 팔꿈치, 손목의 3개의 관절로 구성하였고, <그림 14>와 같이 조작이 가능한 GUI 형태의 프로그램을 이용하여 로봇 팔을 제어한다.

이상과 같이 어깨, 팔꿈치, 손목 관절 등의 6가지 동작에 대한 근전도를 제안한 SOFM 방식으로 90%이상 인식하고, 인식한 정보를 이용하여 컴퓨터상에 가상된 로봇 팔을 정확하게 동작시킴을 확인할 수 있다.

## V. 결 론

본 논문에서는 팔의 보철제어를 위해 어깨, 팔꿈치, 손목 관절 등으로부터 생성되는 근전도 신호를 제안한 SOFM 방식으로 패턴 인식한 후 인식한 근전도 신호를 이용하여 컴퓨터상에 가상으로 제작된 로봇 팔을 제어하였다.

제안한 방식은 기존의 근전도 패턴인식에 있어서 전처리 과정을 통하여 특징을 추출한 후 신호처리의 입력으로 사용하는 기존의 방식과는 달리 근전도 신호 자체를 입력으로 사용하는 간단한 방식이며 또한, SOFM의 성능을 개선하기 위하여 승리 뉴런 및 이웃반경 내의 뉴런들의 연결강도를 갱신(update)하는데 영향을 미치는 이웃반경과 학습율을 퍼지 논리 시스템을 이용하여 자동으로 조정하여 신뢰성을 높임과 동시에 처리시간을 단축하였다.


제안한 SOFM 방식의 유용성을 확인하기 위하여 팔의 부위별로 가능한 동작인 어깨의 굴곡과 신전, 팔꿈치의 굴곡과 신전 및 손목의 배굴과 장굴 등의 6개 동작에 대해 어깨, 팔꿈치, 손목관절의 고정된 위치의 4개 채널로부터 근전도 신호를 측정하여, 학습율을 고정된 일반적인 SOFM 방식과 패턴인식 성능을 비교하였으며, 그 결과는 다음과 같다.

- 일반적인 SOFM 방식의 인식율이 75% 인 것에 비해 제안한 SOFM 방식은 91.3%로 향상되었다.
- 평균학습수가 57% 감소되었다.

## 참 고 문 헌

- [1] Carlo J. De Wiener, Surface EMG Detection and Recording. Neuro Muscular Research Center. 1997.
- [2] Karst G M, Hasan Z, "Timing and magnitude of electromyographic activity for two joint arm movements in different directions" J Neurophysiol 66:1594-1604. 1991.
- [3] Yasuharu Koike, Mitsuo Kawato, Estimation of dynamic joint torque and trajectory formation from surface electromyography signals using a neural network model, Biological Cybernetics, Springer Verlag. 1995.
- [4] Christodoulou C. I. and C. S. Pattichis, "Unsupervised pattern recognition for the classification of EMG Signals", IEEE Trans. On Biomedical Eng, VOL. 46, NO. 2, pp.169-178, FEB. 1999.
- [5] T. Kohonen, "The self organizing map" proc. IEEE, vol. 78, pp. 1464-1480, 1990.
- [6] Sukhan Lee, and George N. Saridis, "The control of a prosthetic arm by EMG pattern recognition." IEEE trans, 1997.
- [7] Li Xin Wang, A Course in Fuzzy Systems and Control, Prentice Hall, Inc., 1997.

## 저 자 소 개



李 政 勳(正會員)

1997년 2월 : 동국대학교 전자공학과(학사). 1999년 2월 : 동국대학교 전자공학과(석사). 2001년 2월 : 동국대학교 전자공학과 박사과정 수료. 동국대학교, 서울산업대학교, 인천시립대학교, 서일대학, 대림대

학 강사. <주관심분야 : 인공지능, 자동제어, 마이크로프로세서, 생체인식>



李賢寬(正會員)

미국 인디애나주립대학 전자공학과(학사). 미국 인디애나주립대학 전자공학과(석사). 2002년 2월 : 동국대학교 전자공학과 박사. 삼성전자 자동화연구소 근무. 현재 : 호남대학교 인터넷학부 교수.

鄭 慶 權(正會員) 第39卷 CI編 第4號 參照

嚴 基 煥(正會員) 第38卷 SC編 第4號 參照