

웨이브릿 이론을 이용한 퍼지-신경망 구조의 최적화 The FNN Optimization Using The Wavelet Theory

김용택 · 서재응 · 연정흠 · 김종수 · 전홍태

Yong-Taek Kim, Jae-Yong Seo, Jung-Hum Yeon, Jong-Su Kim and Hong-Tae Jeon

중앙대학교 전자전기공학부

요 약

본 논문에서는, 퍼지 신경망 시스템에 대한 최적의 규칙 베이스의 생성과 초기화를 이루기 위하여 웨이브릿 이론을 기반으로 한 퍼지 신경망 구조를 제안한다. 제안한 웨이브릿 기반의 퍼지 신경망 구조(WFNN)에서는 퍼지-신경망에 대하여 웨이브릿 함수의 성질과 다운스트레칭 메카니즘에 의하여 초기의 최적 퍼지 규칙 베이스를 구성하고 은닉층의 노드 갯수를 최적화시키며, 에러 역전파 알고리즘에 의하여 각 파라미터의 조절과 학습이 진행된다. 역진자 시스템에 대한 모의 실험을 통하여 제안한 웨이브릿 기반의 퍼지 신경망 제어 시스템의 우수성을 검증하였다.

ABSTRACT

In this paper, we propose the wavelet-based FNN structure for construction of optimal rule bases and initialization of FNN system. The proposed wavelet-based FNN structure constructs optimal initial fuzzy rule bases using characteristic of the wavelet function and down stretching mechanism, and optimizes the number of nodes in the hidden layer. Error back propagation algorithm is used to train this network system. And we will demonstrate the effectiveness of the proposed wavelet-based FNN system with computer simulation of the inverted pendulum system.

1. 서 론

기존의 퍼지 논리를 신경회로망의 영역 안으로 포 함시켜 비구조적인 수치 데이터뿐만 아니라, 구조적인 정보까지 신경회로망이 처리할 수 있는 퍼지-신경망 이 도입되었다[7]. 이는 퍼지 상관 방정식에 근거하여 만들어지며, 퍼지화 블록과 미지 시스템의 퍼지 규칙 을 찾기 위해 충분한 자유도를 갖는 신경회로망 블 록, 그리고 비퍼지화 블록으로 구성된다. 이러한 퍼지 -신경망은 퍼지 추론과 신경망의 학습을 융합했음에도 사용된 망구조의 잉여성(redundance)과 학습조건들에 대한 일반적인 원칙을 구하기가 어렵고 초기조건에 따 라서 전역 최소점(global minimum)에 도달하지 않을 수도 있다.

이러한 퍼지-신경망(FNN)의 단점을 보완하고자 본 논문에서는 웨이브릿 이론을 이용한 퍼지-신경망 (WFNN)을 제안한다[1-4]. WFNN은 웨이브릿 함수로 은닉층을 구성함으로써 최적 규칙 베이스를 구성할 수 있는 이론적 근거를 제시해주고, 다운 스트레칭 매커 니즘을 적용하여 불필요하게 사용되는 규칙을 하나로 대체함으로써 전체 규칙의 수를 줄일 수 있는 장점이 있다. 제안한 WFNN의 성능을 검증하기 위해 역진자 제어 문제에 적용하여 모의실험을 수행하였다.

2. 웨이브릿 함수 분석에 의한 퍼지 -신경망(WFNN)의 최적화

2.1 퍼지-신경망 제어 시스템

퍼지 논리 제어기는 전문가의 경험에 의존해서 퍼 지 규칙 베이스와 소속 함수를 구성해야 하기 때문에 주관적이고 규칙의 갯수가 증가함에 따라 구조와 계 산이 크게 복잡해지기 때문에, 최적의 규칙 갯수를 결 정하는 데에 많은 시간과 노력이 필요하다. 이러한 문 제에 대한 해결책으로, 다층 신경망 구조를 퍼지 논리 에 도입한 퍼지-신경망 제어기가 있다. 퍼지-신경망 제 어기는 퍼지 규칙과 추론과정을 신경망 구조로 구현 한 것이다. 이 제어기는 추론 과정에 따라 전건부 (Premise part)와 후건부(Consequence part)로 나누어 진다.

최종 추론값은 전건부의 진리값을 고려하여 다음과 같이 계산된다.

$$y^* = \frac{\sum_{j=1}^m \mu_j \cdot f_j(x_1, \dots, x_n)}{\sum_{j=1}^m \mu_j} = \sum_{j=1}^m \hat{\mu}_j \cdot f_j(x_1, \dots, x_n) \quad (1)$$

여기서 μ_j 는 j 번째 규칙 R_j 의 진리값, $\hat{\mu}_j$ 는 μ_j 의 정규

화된 출력값이다. 그리고 m 은 규칙의 개수이다.

퍼지신경망 시스템은 입력공간을 퍼지분할(fuzzy partition)하여 각각의 퍼지 부분공간(fuzzy subspace)에 대한 선형 입출력 관계를 할당함으로써 기존의 선형 근사화 방식(piecewise linear approximation)에 비해 적은 규칙으로도 비선형 특성을 갖는 입출력 관계를 보다 정확하게 표현할 수 있다[7]. 그러나 입력 차원이 증가할 때 망이 복잡해지는 문제점이 발생하며, 퍼지신경망에 도입된 다층 신경망 구조는 초기 가중치를 설정하는 문제와, 각 층의 신경세포의 갯수를 결정하는 데 많은 어려움이 따른다. 또한 언어적 제어가 아닌 높은 비선형성을 가진 수치적 제어에 의해 학습 시간이 오래 걸리고, 학습시 지역적 최소치(local minimum)에 빠질 수 있다는 문제점을 갖는다.

이러한 문제점을 해결하기 위하여 본 논문에서는 웨이브릿을 기반으로 한 퍼지신경망 제어 시스템을 제안한다.

2.2 웨이브릿 이론

임의의 함수 $f(x)$ 가 식 (2)와 같은 선형분해(linear decomposition)형태로 표현된다고 가정하자.

$$f(x) = \sum_l a_l \psi_l(x) \quad (2)$$

만약 이 기준함수의 집합이 서로 직교(orthogonal)한다면, 즉,

$$\langle \psi_k(x), \psi_l(x) \rangle = \int \psi_k(x) \psi_l(x) dx = 0 \quad k \neq l \quad (3)$$

을 만족하는 경우, 그 계수는 다음과 같이 함수와 기준함수 간의 내적으로 구할 수 있다.

$$a_k = \langle f(x), \psi_k(x) \rangle = \int f(x) \psi_k(x) dx \quad (4)$$

웨이브릿 급수 전개는 다음과 같은 2개의 변수를 갖는 시스템으로 표현된다.

$$f(x) = \sum_m \sum_n a_{m,n} \psi_{m,n}(x) \quad (5)$$

여기서, m 와 n 는 자연수 지표이고, $\psi_{m,n}(x)$ 는 일반적으로 직교 기준을 형성하는 웨이브릿 함수가 된다. 급수 전개식의 계수 $a_{m,n}$ 의 집합을 $f(x)$ 의 이산 웨이브릿 변환(Discrete Wavelet Transform)이라고 부르고, 식 (5)은 그 역변환(Inverse transform)이다.

2차원 스케일링 함수의 집합은 다음과 같은 기저 스케일링 함수의 자연수 신축(dilation)과 이동(translation)으로 정의한다.

$$\phi_{m,n}(x) = 2^{m/2} \phi(2^m x - n) \quad (6)$$

이 함수들의 선형 조합에 의해 표현되어지는 L^2 (제곱 적분가능 함수의 공간)의 부분공간을 다음과 같이 정의한다.

$$V_m = \overline{\text{Span}_n \{ \phi_{m,n}(x) \}} \quad (7)$$

이는 V_m 의 부분공간에 속하는 임의의 함수 $f(x)$ 를 다음 식과 같이 표현할 수 있다는 것을 의미한다.

$$f(x) = \sum_n a_n \phi(2^m x - n) \quad (8)$$

L^2 공간의 정규 직교 기저(orthonormal basis)를 형성하는 다음과 같은 형식의 원형(prototype or mother) 웨이브릿을 얻을 수 있다.

$$\psi_{m,n}(x) = 2^{m/2} \psi(2^m x - n) \quad (9)$$

이에 따라, $L^2(R)$ 에 존재하는 임의의 함수 $f(x)$ 를 분해(decomposition)하기 위하여 식 (10)과 방법을 생각할 수 있다.

$$f(x) = \sum_n \langle f, \phi_{m_0,n} \rangle \phi_{m_0,n}(x) + \sum_{m \geq m_0, n} \langle f, \psi_{m,n} \rangle \psi_{m,n}(x) \quad (10)$$

여기서 m_0 는 가장 낮은 분해능(resolution)을 표시하는 임의의 자연수이다.

2.3 계층구조와 다중분해 해석

퍼지이론의 추론과정은 고전 수학의 Modus-Ponens 기법으로서 규칙부분을 $\mu_{A \rightarrow B}(y)$ 와 같이 표현하면, 식 (11)과 같이 정의할 수 있다.

$$\begin{aligned} \mu_B(y) &= \text{proj}_u \{ \mu_A(u) \text{ and } \mu_{A \rightarrow B}(u, y) \} \\ &\triangleq \max_u \{ \mu_A(u) \text{ and } \mu_{A \rightarrow B}(u, y) \} \end{aligned} \quad (11)$$

이 때, 사실 부분이 “x is x”와 같은 크리스프(crisp) 값을 갖는 경우에 $u = x$ 인 경우에만 $\mu_A(u) = 1$ 의 값을 갖고 그 외에는 모두 0이다. 이에 따르면

식 (11)은 다음과 같이 쓸 수 있다.

$$\mu_B(y) = \mu_{A \rightarrow B}(x, y) = 1 - \mu_A(x)(1 - \mu_B(y)) \quad (12)$$

퍼지 집합이 같이 공간에 대한 퍼지 분할을 한다고 가정하고, 이 규칙 베이스를 표현하면 다음과 같다.

$$\prod_{j=1}^p \prod_{i=1}^d \mu_{A_{j,i}}(x_i) \equiv 1 \quad (13)$$

즉, 입력 데이터를 “1”로 정규화한 것을 의미한다.

또한 결론 부분을 프로덕트(product)로 표현하면 다음과 같다.

$$\mu_B(y) = \prod_{j=1}^p \mu_{B_j}(y) \quad (14)$$

식 (14)를 이용하여 다시 쓰면

$$\mu_B(y) = \prod_{j=1}^p \left\{ 1 - \prod_{i=1}^d \mu_{A_{j,i}}(x_i)(1 - \mu_{B_j}(y)) \right\} \quad (15)$$

여기서, μ_j 가 작고 p 는 클 때, 다음과 같이 근사된다.

$$\mu_B(y) \approx 1 - \sum_{j=1}^p (1 - \mu_{B_j}(y)) \prod_{i=1}^d \mu_{A_{j,i}}(x_i) \quad (16)$$

또한, 식 (14)의 퍼지 분할 형식에 대한 성질을 사용하면,

$$\mu_B(y) = \sum_{j=1}^p \mu_{B_j}(y) \prod_{i=1}^d \mu_{A_{j,i}}(x_i) \quad (17)$$

이고, 퍼지 분할 성질을 다시 이용하여 $\mu_B(y)$ 의 값에 그 값의 무게중심을 대입하면, 최종적으로 다음과 같은 비퍼지화된 함수를 얻는다.

$$y = \sum_{j=1}^p y_j \left\{ \prod_{i=1}^d \mu_{A_{j,i}}(x_i) \right\} \triangleq \sum_{j=1}^p y_j w_j(x) \quad (18)$$

여기서, 입력 $x = (x_1, \dots, x_d)$ 에 의하여 가중치 $w_j(x)$ 가 결정된다.

퍼지 모델은 퍼지 소속함수의 특성상 임의의 함수에 대한 일반적인 다중분해와 근사화에는 미치지 못한다. 따라서, 웨이브릿에 연관되어 퍼지 규칙 베이스를 설정하는 방법을 생각할 수 있다. 규칙에 대하여, 다중 분해 계층구조의 개념을 고려하여 다음과 같은 계층적 퍼지 모델(Hierarchical fuzzy model) 구조가 있다.

표준 퍼지 규칙은 계층적 퍼지 모델로써 다음과 같이 표현된다.

$$\text{if } (x_1 \text{ is } A_1) \text{ and } (x_2 \text{ is } A_2) \dots \text{ and } (x_d \text{ is } A_d) \text{ then } (y \text{ is } B) \quad (19)$$

퍼지 규칙 베이스에 대하여 다음과 같이 명명한다. RULE BASE는

$$\text{if } (x_1 \text{ is } A_{11}) \text{ and } (x_2 \text{ is } A_{12}) \dots \text{ and } (x_d \text{ is } A_{1d}) \text{ then } (y \text{ is } B_1)$$

$$\text{if } (x_1 \text{ is } A_{p1}) \text{ and } (x_2 \text{ is } A_{p2}) \dots \text{ and } (x_d \text{ is } A_{pd}) \text{ then } (y \text{ is } B_p) \quad (20)$$

이를 다음과 같은 계층적(hierarchical) 퍼지규칙으로 나타낼 수 있다.

$$\text{if } (x_1 \text{ is } C_1) \text{ and } (x_2 \text{ is } C_2) \dots \text{ and } (x_d \text{ is } C_d) \text{ then} \\ \text{RULE BASE applies} \quad (21)$$

여기서, 전건부는 표준 퍼지규칙의 문장과 동일하다. 그리고 다음 문장, 즉 then RULE BASE applies가 후건부로 주어진다.

다운 매커니즘을 이용하여 (A, C) 의 퍼지집합의 쌍에 의하여 다음과 같은 $(A | C)$ 의 전후관계(contextual) 퍼지집합을 정의한다.

$$(A | C) = (\mu_{(A|C)}, l_C, r_C) \\ \mu_{(A|C)}(x) = \mu_A \left(\frac{b-a}{r_C-l_C}(x-l_C) + a \right) \mu_C(x) \quad (22)$$

여기서 집합 $(A | C)$ 는 집합 C 와 동일한 구간에서 존재한다. $\mu_{(A|C)}(x)$ 의 소속함수는 구간 $[a, B]$ 를 $[l_C, r_C]$ 로 사상하는 관계와, $\mu_C(x)$ 의 곱으로 구해진다.

식 (14)의 전후관계 퍼지 집합의 정의를 사용하면, 다음과 같이 계층적 구조 베이스가 수식적으로 표현된 값을 얻는다.

$$y = y_0 \left[\prod_{i=1}^d \mu_{C_i}(x_i) \right] + \left[\sum_{j=1}^p y_j \left(\prod_{i=1}^d \mu_{(A_{j,i}|C_i)}(x_i) \right) \right] \quad (23)$$

식 (23)의 형태에 따르면 이를 웨이브릿 이론의 함수의 다중분해 급수(식 10)과 연관시킬 수 있다. 따라서, 식 (23)에서의 $\mu_{C_i}(x_i)$ 가 1차 근사화의 스케일링 함수, $\mu_{(A_{j,i}|C_i)}(x_i)$ 를 웨이브릿 함수로 구성한다면, 퍼지 관계식을 웨이브릿 이론에 따른 함수의 근사화로 적용할 수 있다.

2.4 웨이브릿 기반의 퍼지-신경망 (FNBW)

그림 1은 웨이브릿 이론을 기반으로 한 퍼지-신경망 모델로 각각의 층은 다음과 같이 구성된다.

[Layer 1] 이 층의 각 노드에서의 출력은 다음과 같다.

$$O_{ji} = \mu_{A_j}(x) \quad (x = x_j) \quad (24)$$

x 는 i 번째 노드에 대한 입력으로, 그림 2에서는 $j=1, 2$ 이므로, x_1 과 x_2 으로 주어지고, A_j 는 언어적 변수로, O_j 는 x 가 A_j 에 소속되는 정도를 출력하게 된다. 여기서, 웨이브릿 다중분해에 사용되는 스케일링 함수를 소속함수로 사용한다.

[Layer 2] 이 층으로 들어오는 입력은 각각 곱




그림 1. 웨이블릿 기반의 퍼지-신경망

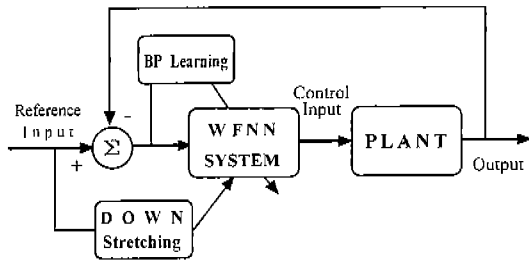


그림 2. WFNN 제어 시스템 구성도

(Product) 연산을 취하여 출력값을 얻는다. 따라서, 각 노드에서의 출력은 규칙의 발화(Firing) 강도를 나타낸다.

$$O_i^2 = w_i = \prod_{k=1}^i \mu_{A_jk}(x_k) \quad (25)$$

[Layer 3] 이 층에서의 j번째 노드는 모든 규칙의 가중치의 합에 대한 j번째 규칙의 가중치의 비로 계산된다.

$$O_j^3 = \bar{w}_j = \frac{w_j}{\sum_i w_i} \quad (26)$$

[Layer 4] 이 층에서의 i번째 노드의 출력은 다음과 같이 주어진다.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (a_1 x_1 + a_2 x_2 + a_3 x_3 \dots) \quad (27)$$

여기서, \bar{w}_i 는 층 3의 출력이고 파라미터 $\{a_1, B_i, c_i, \dots\}$ 는 후진부에서 선형계산식의 계수이다.

[Layer 5] 이 층에서의 단일 노드는 들어오는 신호들을 선형 결합한 연산으로 구한다.

$$f = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (28)$$

WFNN의 학습방법은 FNN의 학습방법으로 널리 사용되는 역전파 학습알고리즘을 사용하였다. 따라서 논문에서 제안되는 다운스트레칭에 의하여 소속함수, 규칙의 갯수를 줄일 수 있게 된다는 것은 역전파 학습 알고리즘에서의 계산량을 크게 감소시킬 수 있음을 의미한다.

3. WFNN 시스템 제어 모의 실험

기존의 방사형 기저 함수(Radial Basis Function)를 이용한 퍼지-신경망(FNN)과 본 논문에서 제시한 웨이블릿 함수를 이용한 퍼지-신경망(WFNN)간의 실제 시스템에 대한 적용시의 성능을 비교 분석한다. WFNN의 제어 시스템은 그림 2와 같다.

이는 퍼지-신경망(FNN)에 대하여 down-stretching 기법에 의하여 최적의 소속함수를 배치하며, 역전파 학습방법에 의하여 학습된다.

모의실험에 사용된 역진자(Inverted Pendulum) 시스템에 대한 동적 방정식은 다음과 같다[8].

$$\begin{aligned} \dot{x}_1 &= x_2 \\ \ddot{x}_2 &= \frac{g \sin x_1 - m l x_2^2 \cos x_1 \sin x_1}{m_c + m} + \frac{\cos x_1}{m_c + m} u \end{aligned} \quad (29)$$

여기서 x_1 과 x_2 는 각각 막대에 대한 각도 θ 와 각속도 $\dot{\theta}$ 를 의미하며, $g=9.8 \text{ m/s}^2$ 은 중력 가속도이다. m 은 막대의 질량이고, l 은 막대의 길이의 1/2을 의미하며, u 는 제어기 입력이다. 각 파라미터는 $m_c=1 \text{ kg}$, $m=0.1 \text{ kg}$, $l=0.5 \text{ m}$ 로 각각 설정하였다.

WFNN 제어시스템은 먼저, 시스템의 특성에 따라 주어지는 소속함수에 대하여 다운스트레칭에 의하여 소속함수에 대한 오프라인 최적화를 수행하고, 실제 시스템의 출력과 원하는 값 사이의 오차에 따라 오차 역전파 방식에 의하여 WFNN을 학습시킨다. 또한 FNN, WFNN에서 사용되는 오차 역전파 학습 알고리즘에서의 학습률 η 은 동일한 0.001로 설정하고 모의




그림 3. 3-RFNN VS 3-WFNN

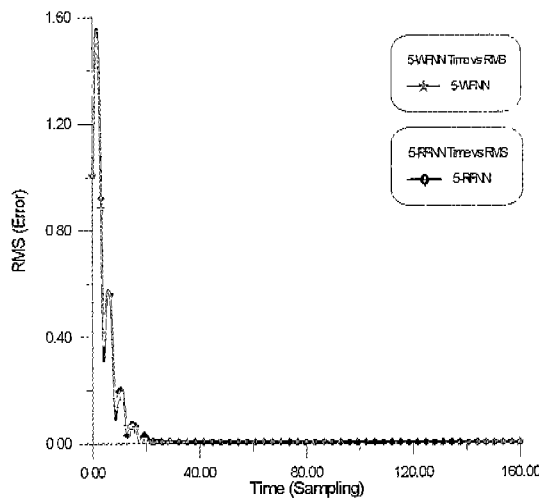


그림 4. 5-RFNN VS 5-WFNN

실험을 행하였다.

그림 3은 WFNN과 RBFN에서 동일한 3개의 소속함수를 사용하였을 경우에 대한 결과를 나타낸 것이다. 전체적인 에러 평균값은 기존의 RBFN 보다 빨리 감소함을 알 수 있다. 이는 동일한 복잡성과 구조하에서 WFNN이 RBFN보다 성능이 우수함을 의미한다.

그림 4는 5개의 소속함수를 사용한 WFNN과 5개의 소속함수를 사용한 RBFN에 대한 결과를 나타낸다. 이 때 전체적인 에러 평균값은 WFNN과 RBFN이 비슷한 값을 보이는데, 이는 WFNN에 의하면 RBFN에 비하여 적은 수의 소속함수, 즉 보다 간단한 구조와 계산으로도 동일한 성능을 얻을 수 있음

을 의미한다.

5. 결 론

본 논문에서는 퍼지-신경망에 웨이브릿 이론을 적용하였다. 웨이브릿 이론에 의하면 입력공간 분포영역을 피라미드 형태와 같이 구성할 수 있기 때문에 계층적 구조를 가진 퍼지 모델에 적용이 가능하며, 매개 변수로서 확장(dilation)과 천이(translation)를 이용하므로 입력력 데이터 분포 찾기에 매우 유용하여, 입력력 관계를 학습시키기 용이하다.

또한, 다운스트레칭 매커니즘에 의하여 기존의 FNN에 비하여 노드수를 감소시키며, 이러한 과정으로 보다 적은 수의 규칙으로도 유사한 성능을 구현하는 웨이브릿 함수를 이용한 퍼지-신경망 제어기를(WFNN)을 제안하였다.

비선형 시스템에 대한 모의 실험에 적용한 결과 WFNN에 의한 제어 방식은 보다 적은 수의 규칙 갯수를 가지고도 기존의 FNN과 유사한 성능을 보였으며, 동일한 규칙과 환경에서는 기존의 FNN보다 우수한 성능을 보임을 알 수 있었다. 본 논문에서 제안된 WFNN의 성능을 보다 향상시키기 위해서는 파라미터 조정과 초기 규칙 설정에 관한 연구가 더 필요할 것으로 보인다.

참고문헌

- [1] S. Horikawa, T. Furuhashi, and Y. Uchikawa, "On fuzzy modeling using fuzzy neural network with the Back-propagation algorithm," *IEEE Trans. Neural Networks*, Vol. 3, No. 5, pp. 801-806, Sep. 1992.
- [2] Y. C. Pati and P. S. Krishnaprasad, "Analysis and synthesis of feed-forward neural network using discrete affine wavelet transformations," *IEEE Trans Neural Network*, Vol. 4, pp. 73-85, Jan. 1993.
- [3] J. Zhang, G. G. Walter, Y. Miao and W. N. W. Lee, "Wavelet neural networks for function learning," *IEEE Trans Signal Processing*, Vol. 43, pp. 1485-1497, June. 1995.
- [4] Zhang, Qinghua, "Using Wavelet Network in Non-parametric Estimation," *IEEE Trans. on Neural Networks*, Vol. 8, No. 2, March 1997, pp. 227-236
- [5] Masami Ueda and Suresh Lodha, "Wavelets : An Elementary Introduction and Examples," UCSC-CRL 94-47 January 1995.
- [6] A. Juditsky, Q. Zhang, B. Delyon, P-y. Glorennec, and A. Benveniste, "Wavelets, Splines, Neurons, Fuzzics : How Good For Identification," Technical Report 849 SepteBer 1994.
- [7] Andreas Ikonomopoulos and Akira Endou, "Wavelet Decomposition and Radial Basis Function Networks

for System Monitoring," *IEEE Trans. Neural Networks*, Vol. 10, OctBer 1998.

- [8] J. -S. R. Jang, C. -T. Sun, E. Mizutani "Neuro-Fuzzy and soft Computing", Prentice-Hall International, Inc. pp. 335-346, 1997.
-

서재용 (Jae-Yong Seo) (정회원)

1996년 : 중앙대학교 전자공학과 졸업(학사)
1998년 : 중앙대학교 대학원 전자공학과 졸업(석사)
1998년~현재 : 중앙대학교 대학원 전자공학과 박사과정 재학중
주관심분야 : 퍼지, 유전알고리즘, 신경망, FNN 등임

김종수 (Jong-Su Kim)

1990년 : 중앙대학교 전자공학과 졸업(학사)
1992년 : 중앙대학교 대학원 전자공학과 졸업(석사)
1997년~현재 : 중앙대학교 대학원 전자공학과 박사과정 재학중
주관심분야 : 퍼지 논리, 신경회로망, FNN 등임

김용택 (Yong-Taek Kim) (정회원)

1992년 : 중앙대학교 전자공학과 졸업(학사)
1994년 : 중앙대학교 대학원 전자공학과 졸업(석사)
1996년~현재 : 중앙대학교 대학원 전자공학과 박사과정 재학중
주관심분야 : 신경망, 로보틱스, 퍼지 등임

연정흠 (Jeong-Hum Yeon) (정회원)

1994년 : 중앙대학교 전자공학과 졸업(학사)
1996년 : 중앙대학교 대학원 전자공학과 졸업(석사)
1996년~현재 : 중앙대학교 대학원 전자공학과 박사과정 재학중
주관심분야 : 퍼지, 유전알고리즘, 신경망 등임

전홍태 (Hong-Tae Jeon) (정회원)

현재 : 중앙대학교 전자공학과 교수
