

論文2000-37SC-4-3

동적 다차원 웨이브릿 신경망을 이용한 제어 시스템 설계 (On Designing a Control System Using Dynamic Multidimensional Wavelet Neural Network)

趙 一*, 徐 在 龍*, 延 貞 欽*, 全 洪 兑*

(Il Cho, Jae-Yong Seo, Jung-Heum Yon, Yong-Taek Kim, and Hong-Tae Jeon)

요 약

본 논문에서는 동적 다차원 웨이블릿 신경망을 제안한다. 웨이블릿 이론을 이용한 DMWNN은 균사화 대상함수를 유일하고 효과적으로 표현할 수 있으며, 추후에 사용할 수 있는 정보를 저장하는 능력을 가지고 있다. 따라서 DMWNN은 동적 매핑이 가능하고, 필요한 입력의 차원을 줄일 수 있는 장점이 있다. DMWNN은 대각 귀환신경망과 전방향 웨이블릿 신경망의 단점을 보완하여 설계하였다. 제안한 DMWNN의 우수성을 실험을 통해 검증하였다.

Abstract

In this paper, new neural network called dynamic multidimensional wavelet neural network (DMWNN) is proposed. The resulting network from wavelet theory provides a unique and efficient representation of the given function. Also the proposed DMWNN have ability to store information for later use. Therefore it can represent dynamic mapping and decreases the dimension of the inputs needed for network. This feature of DMWNN can compensate for the weakness of diagonal recurrent neural network(DRNN) and feedforward wavelet neural network(FWNN). The efficacy of this type of network is demonstrated through experimental results.

I. 서 론

신경회로망(neural network)은 함수 균사화 및 비선형 시스템의 제어와 동정에 성공적으로 적용되어 왔다^{[5][9][15]}. 그러나 이러한 전방향 신경망은 그 구조상 정적 사상(static mapping)이기 때문에 동적 사상(dynamic mapping)을 구현하기 위해서는 구조적 변형이나 필요 이상의 데이터가 사용되어야 한다. 따라서 이러한 문제를 해결하기 위해서 피드백(feedback)의 신

호 흐름을 가지는 귀환 신경망이 제안되었다^{[6][12][13][14]}. 이러한 귀환신경망은 전방향 신경망이 갖지 못한 attractor dynamics와 이전 정보를 저장할 수 있는 능력을 가지게 됨으로써 tapped delays 등을 연결해야 하는 구조적 변형이 불필요하고 입력 데이터의 수가 줄어들게 된다. 그러나 이러한 귀환 신경망 역시 전방향 신경망 구조에서 나타나는 은닉층(hidden layer) 노드(node) 개수의 최적화, 가중치(weight) 초기화, 학습 알고리즘의 선택, 안정성(stability) 등의 문제점들이 있다^{[9][15]}. 또한 신경망의 단점을 보완하기 위하여 웨이브릿 신경망(wavelet neural network ; WNN)이 제안되었다^{[2][3][4][18]}. 웨이블릿 신경망은 기존의 신경망과 웨이브릿 분해(wavelet decomposition) 사이의 구조적인 유사성과 뛰어난 함수 균사화 능력에 기인하여 웨이브릿 이론과 신경망을 결합하였다. 이러한 웨이브릿 신경망은 어떤 문제의 유일하고 효과적인

* 正會員, 中央大學校 電子工學科

(Dept. of Electronic Eng. Chung-Ang Univ.)

※본 연구는 과학기술부의 뇌과학연구 프로그램의 지원 하에 수행되었습니다.

接受日字:2000年 2月7日, 수정완료일:2000年5月2日

표현을 가능케 하며, 점근적 성질과 망의 초기화에 대한 이론적인 배경을 제공할 수 있다. 그러나 이러한 웨이브릿 신경망도 지금까지 전방향 신경망으로만 구현되었으므로 정적 사상이며 방사 기준 함수(radial basis function; RBF) 신경망과 유사하게 다차원 문제(curse of dimensionality)를 가지고 있다.

이에 본 논문에서는 직교성을 유지하면서 다차원 문제를 해결하고 동시에 동적 사상을 구현하기 위해 전방향 신경망이 아닌 부분 연결 귀환 신경망 부류인 대각 귀환 신경망(diagonal recurrent neural network; DRNN)^{[1][7]}과 웨이블릿 신경망을 결합하여 동적 다차원 웨이블릿 신경망(Dynamic Multidimensional Wavelet Neural Network; DMWNN)을 제안한다.

동적 다차원 웨이블릿 신경망은 은닉층의 각 노드 자체에만 피드백이 존재하는 신경망으로서 웨이브릿의 특성을 그대로 유지하면서 위에서 언급된 기존 웨이브릿 신경망의 단점만을 극복할 수 있다. 또한 웨이브릿 이론을 이용하여 매개변수 초기설정, 최적성, 안정성 등의 DRNN의 문제점들을 해결할 수 있다.

제안한 시스템을 비선형성이 강한 수중 운동체의 제어기에 적용하고, 모의실험을 수행하여 DRNN, WNN과 구조 및 수렴속도를 비교하여 우수성을 검증하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 DRNN의 구조를 설명하고, 3장에서는 제안한 새로운 신경망인 DMWNN을 설계한다. 그리고 4장에서는 제어 시스템에 대해서 설명하고, 5장에서는 DMWNN과 DRNN, WNN의 모의 실험과 결과를 서술하며, 끝으로 본 논문의 결론을 기술한다.

II. 대각 귀환 신경망의 구조(DRNN)

본 장에서 그림 1은 귀환 신경망 중에서 부분 연결 범주에 속하는 대각 귀환 신경망(DRNN)의 구조이다.

위의 그림에서 각각의 이산 시간 k 에 대한 $I_i(k)$ 는 i 번째 입력이다. $S_j(k)$ 는 j 번째 은닉층 뉴런(hidden layer neuron)의 입력 총합이고 $X_j(k)$ 는 출력, $X_j(k-1)$ 은 한 시간 지연된 이전 출력이다. 그리고 $O(k)$ 는 회로망의 최종 출력이다. W_{ij}^I , W_j^D 와 W_j^O , W_{oj}^H 는 각각 입력(input), 대각, 귀환(diagonal, recurrent)과 출력(output), 은닉(hidden) 연결강도

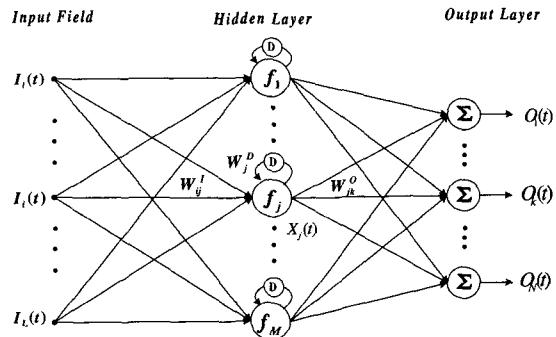


그림 1. 대각 귀환 신경망의 구조

Fig. 1. DRNN's structure.

(weight)를 나타낸다. DRNN의 출력은

$$\begin{aligned} O^{DR}(k) &= \sum_{i=1}^n W_{ij}^I [\sum_{i=1}^m W_{ij}^I I_i(k) + W_j^D X_j(k-1)] \\ &= \sum_{j=1}^n W_{ij}^I [\sum_{i=1}^m W_{ij}^I I_i(k) + W_j^D f_j(\sum_{i=1}^m W_{ij}^I I_i(k-1) \\ &\quad + W_j^D X_j(k-2))] \end{aligned} \quad (1)$$

이고, DRNN의 $O^{DR}(k)$ 이전 입력을 포함하는 동적 사상(dynamic mapping) 신경회로망을 나타내는 비선형 함수(nonlinear function)가 된다. 이것은 DRNN이 비선형 동적 시스템의 상태 공간(state space)을 표현할 수 있음을 의미한다. DRNN이 어떤 플랜트(plant)의 동적 특성(dynamics)을 추측하기 위해서 사용되어 질 때 DRNN의 k 시간의 플랜트 출력이 식 (1)과 같다.

DRNN의 은닉층 뉴런은 플랜트의 이전 입력(past input)과 출력 정보를 저장하는 능력을 가진다. 따라서 DRNN은 다음 시간의 제어대상의 출력을 추측하기 위해서 오직 현재 플랜트의 입력 정보만이 필요하다. DRNN의 이러한 특징은 정적 신경망 보다 필요한 입력 데이터의 수를 줄일 수 있고, 더욱 간단한 구조이기 때문에 처리 시간을 감소시킬 수 있다.

III. 동적 다차원 웨이브릿 신경망(DMWNN)

임의의 함수 $f(x) \in L^2(R)$ 에 대하여, 웨이브릿 이론^{[8][18]}에서 스케일링 함수가

$$\varphi_{m,n}(x) = 2^{m/2} \varphi(2^m x - n) \quad (2)$$

일 때 $f(x)$ 는 다음과 같이 분해(decomposition)될 수

있다.

$$f(x) = \sum_n a_n \varphi(2^m x - n) \quad (3)$$

여기서 a_n 은 함수 $f(x)$ 를 분해하기 위한 기저 함수 $\varphi(\cdot)$ 의 계수이고 2^m , n 은 각각 $\varphi(\cdot)$ 의 신축과 이동 변수가 된다. 따라서 $f(x)$ 를 근사화 할 수 있는 $g(x)$ 를 다음과 같은 형태로 표현할 수 있다.

$$g(x) \approx \sum_n a_n \varphi(2^m x - n) \quad (4)$$

또한 DMWNN의 k 시간에 o 번째 출력 $g_o(x_d(k))$ 은 다음 식 (5)와 같다.

$$\begin{aligned} g_o(x_d(k)) &= \sum_n W_{no}^o \varphi \left[\sum_d 2^m (x_d(k) - n) + W_n^D X_n(k-1) \right] \\ &= \sum_n W_{no}^o \varphi \left[\sum_d 2^m (x_d(k) - n) + W_n^D (\sum_d 2^m (x_d(k-1) - n) + W_n^D X_n(k-2)) \right] + \dots \end{aligned} \quad (5)$$

그림 2는 동적 다차원 웨이브릿 신경망의 구조를 나타낸 것이다.

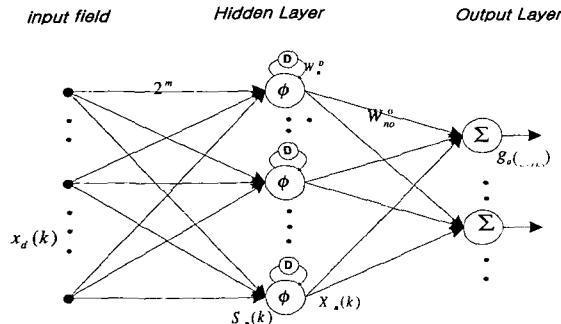


그림 2. 동적 다차원 웨이브릿 신경망의 구조
Fig. 2. DMWNN's structure.

그림 2에서 각각의 이산 시간 k 에 대한 $x_d(k)$ 는 d 번째 입력이다. $S_n(k)$ 는 n 번째 은닉층 뉴런의 입력 총합이고 $X_n(k)$ 는 출력, $X_n(k-1)$ 은 한 시간 지연된 이전 출력이다. 그리고 $g_o(x_d(k))$ 는 회로망의 최종 출력이다. W_{no}^o , W_n^D 는 각각 출력(output)과 대각, 귀환(diagonal, recurrent) 연결강도(weight)를 나타낸다. DMWNN의 입력 연결강도는 웨이브릿의 신축 성분 2^m 으로 고정되었으며 귀환 연결강도, 출력 연결강도 W_n^D 와 W_{no}^o 는 backpropagation(BP) 학습알고리즘을 사용하여 오차가 줄어드는 방향으로 생신된다.

그리고 다차원 구조는 단일 신축(single dilation) 성분을 이용해서 텐서(tensor) 곱 형태로 구현된다. 이렇게 구성된 신경망은 웨이브릿 이론의 결합으로 은닉층 노드 수가 최적화될 수 있기 때문에 DRNN보다 간단한 구조를 가진다. 또한 전방향 웨이브릿 신경망과 달리 귀환 신경망으로 웨이브릿 신경망이 구현되었으므로 이전 정보의 사용으로 필요한 데이터 수가 줄어들어 다차원 구조에 더 뛰어난 특성을 가지며, 내부 상태(state)를 가짐으로 동적 사상으로 구현될 수 있다. 즉, DRNN과 전방향 웨이브릿 신경망의 장점만을 수용할 수 있으며 따라서 더 뛰어난 함수 근사화 능력을 갖게 된다.

연결강도 W_{no}^o 와 W_n^D 는 BP 학습알고리즘을 이용하여 오차가 줄어드는 방향으로 생신된다. 오차함수를 다음과 같이 정의한다.

$$E = \frac{1}{2} (g_{r(k)} - g(k))^2 \quad (6)$$

여기서 $g_{r(k)}$ 는 원하는 출력이고 $g(k)$ 는 신경망의 실제 출력이다.

오차의 gradient는 다음 식 (7)과 같다.

$$\frac{\partial E}{\partial W} = e(k) \frac{\partial g(k)}{\partial W} \quad (7)$$

여기서 오차는 $e(k) = g_{r(k)} - g(k)$ 과 같이 정의한다. 그리고 각각 출력 연결가중치, 귀환 연결가중치 W_{no}^o , W_n^D 의 오차 gradient는 다음과 같다.

$$\frac{\partial g_o(k)}{\partial W_{no}^o} = X_n(k) \quad (8)$$

$$\frac{\partial g_o(k)}{\partial W_n^D} = \sum_o W_{no}^o P_n(k) \quad (9)$$

$$\begin{aligned} P_n(k) &= \varphi'(S_n(k))(X_n(k-1) + W_n^D P_n(k-1)), \\ P_n(0) &= 0 \end{aligned} \quad (10)$$

따라서, 최종 연결가중치 생신은 다음 식 (11)과 같다.

$$W(t+1) = W(t) + \eta \left(-\frac{\partial E}{\partial W} \right) \quad (11)$$

여기서 η 는 학습률(learning rate)이다.

IV. 제어 시스템 설계

외란, 플랜트의 불확실성 그리고 정밀하고 빠른 추

종 응답 특성이 요구되는 비선형 동적 시스템을 효율적으로 제어하기 위해 본 논문에서 제안한 동적 다차원 웨이브릿 신경망을 제어기로서 사용한다.

먼저 상태 공간에 적용할 웨이브릿 기준 함수를 정의하고 제어기로 들어오는 입력 값의 대략적인 범위와 특성을 파악해서 웨이브릿 이론에 근거해 신축(dilation)과 이동(translation) 변수 값을 선택하여 초기 동적 다차원 웨이브릿 신경망을 설계한다. 그리고 그림 3과 같이 플랜트가 참조 모델을 추종하도록 제어 시스템을 설계한다. 참조 모델은 실제 플랜트의 연속된 시간상에서 목표 출력치를 제시함으로서 제어 목표를 구체화해주는 역할을 하며 플랜트의 특성을 고려하여 설계되어 안정한 선형-시불변 시스템으로 표현된다. 선형 제어기는 비선형 제어기인 신경망의 간접적인 학습신호를 부여한다.

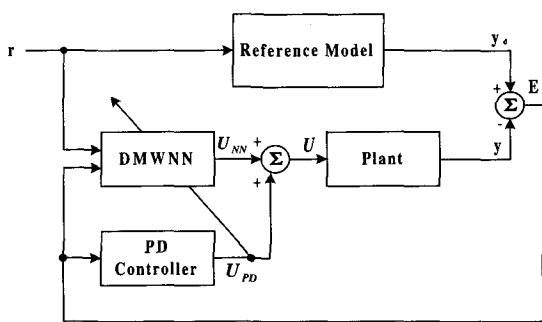


그림 3. 제어 시스템 구조

Fig. 3. Control System Structure.

V. 수중 운동체의 추종 제어 모의 실험

1. 수중 운동체(underwater vehicle)

본 논문에서는 비선형성이 강한 수중 운동체를 플랜트로 적용한다. 수중 운동체는 불확실한 환경 즉, 구조화되지 않는 자연환경에서 주어진 명령을 수행하여야 한다. 또한 수중 운동체의 동적 방정식은 고도의 비선형성을 갖는다. 그러므로 기존의 제어이론으로는 상기의 구조화되지 않는 내외부의 불확실성을 보상하는데 제한성을 갖는다. 따라서 이러한 제한성을 극복하기 위해서 본 논문에서 제안한 동적 다차원 웨이브릿 신경망을 제어기로 사용한다.

수중 운동체는 수직면상 운동 및 수평면상 운동을 고려한 6자유도 동적 방정식을 가지며, 본 논문에서는 수중 운동체의 여러 제어 분야 중에서 수평면 제어의

요각(yaw angle), 롤각(roll angle)제어를 수행한다. 수중 운동체의 수평면 운동방정식은 다음과 같이 상태방정식으로 표현된다.

$$\dot{X} = Ax_o X + Bu_o^2 U + d \quad (12)$$

$$Y = CX \quad (13)$$

$$X = [v \ \dot{\psi} \ \psi \ \dot{\phi} \ \phi] \quad U = [\delta_r \ \delta_\phi] \quad Y = [\psi \ \phi] \quad (14)$$

여기서 v 는 동체 좌표계에서 전방에 대한 우직각 측면 방향으로의 운동체 속도, ψ, ϕ 는 오일러 각(Euler angle) 중 요(yaw), 롤(roll)이며, 제어입력 δ_r, δ_ϕ 는 방향타(rudder), 롤 제어입력이다. 또한 d 는 외란이며 u_o 는 운동체의 변화하는 속도를 나타낸다.

2. 모의실험

본 논문에서 제안된 DMWNN의 성능을 검증하기 위해서 외란(disturbance)이 인가된 수중운동체의 수평면 제어, 즉 요각(yaw angle)과 롤각(roll angle)이 안정한 참조 모델(reference model)의 출력을 추정하는 제어에 대한 모의실험을 수행한다. 모의실험 결과는 DMWNN, DRNN 그리고 WNN의 동일한 제어와 망구조 조건하에서 비교하고 검증한다. DMWNN은 은닉층의 노드 수는 15개, 초기 가중치 랜덤하게 생성하며, DMWNN, WNN의 신축은 4로 정의한다.

모의 실험 결과 다음 그림 4, 5, 6, 7과 같이 수중 운동체 동적 방정식의 출력인 요각과 롤각 모두 DMWNN을 제어기로 사용했을 때 가장 좋은 추종 제어를 수행하며 DRNN과 FWNN은 유사한 결과를 보였다.

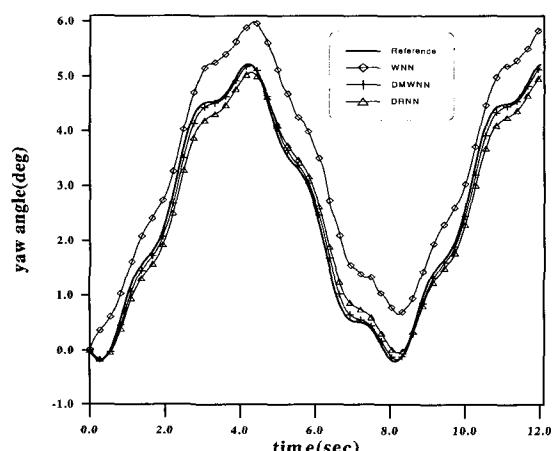


그림 4. 요각

Fig. 4. yaw angle.

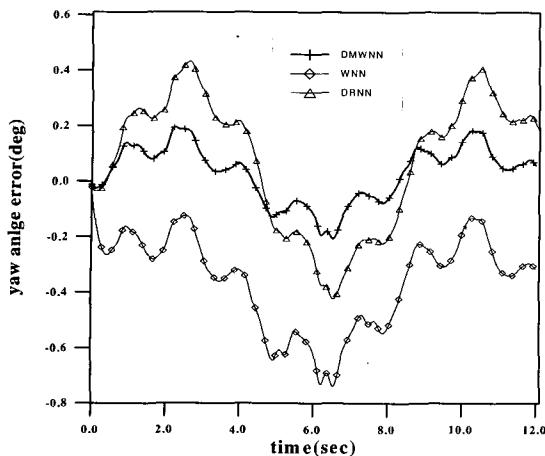


그림 5. 요각의 추종 오차

Fig. 5. Tracing error of yaw angle.

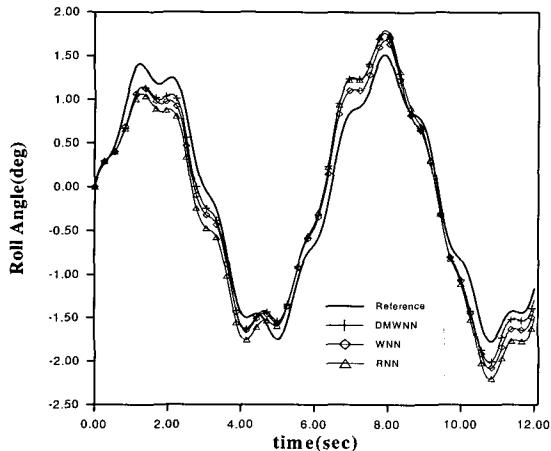


그림 6. 률각

Fig. 6. roll angle.

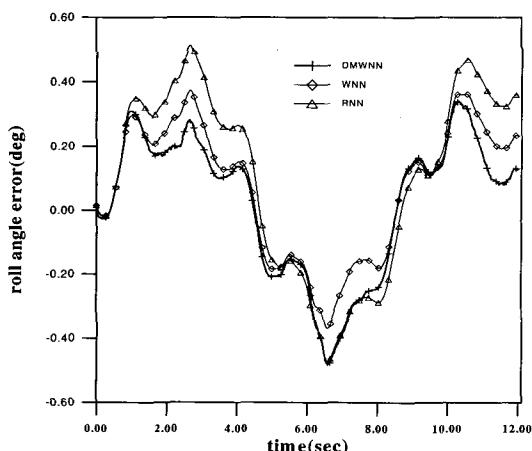


그림 7. 률각의 추종 오차

Fig. 7. Tracing error of roll angle.

VI. 결 론

본 논문에서 제안된 동적 다차원 웨이브릿 신경망(DMWNN)은 모의 실험 결과와 같이 외란이 첨가된 환경에서 전방향 웨이브릿 신경망(WNN)과 대각 귀환 신경망(DRNN)보다 뛰어난 성능을 보였다. 동적 다차원 웨이브릿 신경망은 외란과 불확실성, 은닉층의 노드 수에서 모두 뛰어난 성능을 보였음을 알 수 있다. 따라서, 동적 다차원 웨이브릿 신경망이 전방향 웨이브릿 신경망의 차원 문제와 동적 사상 구성의 단점을 보완하고 귀환 신경망 부류인 대각 귀환 신경망의 매개변수, 구조의 복잡성을 보완함을 알 수 있다.

앞으로의 연구 방향은 새로운 학습 알고리즘의 개발과 시스템 안정성에 있어서의 수학적 증명 그리고 다양한 환경과 플랜트의 많은 모의 실험을 수행하는 것이다.

참 고 문 현

- [1] Chao-Chee Ku, Kwang Y. Lee, "Diagonal Recurrent Neural Networks for Dynamic Systems Control", *IEEE Trans. Neural Network*, vol. 6, pp. 144-156, Jan. 1995.
- [2] J. Zhang, G. G. Walter, Y. Miao and W. N. Lee, "Wavelet neural networks for function learning", *IEEE Trans. Signal Processing*, vol. 43, pp. 1485-1497, June. 1995.
- [3] Q. Zhang and A. Benveniste, "Wavelet networks", *IEEE Trans. Neural Networks*, vol. 3, pp. 889-898, Nov. 1992.
- [4] Y. C. Pati and P. S. Krishnaprasad, "Analysis and synthesis of feedforward neural network using discrete affine wavelet transformations", *IEEE Trans. Neural Network*, vol. 4, pp. 73-85, Jan. 1993.
- [5] K. Hornik, "Multilayer feedforward networks are universal approximators", *Neural networks*, vol. 2, 1989.
- [6] Ah chung Tsoi, Andrew D. Back, "Locally Recurrent Globally Feedforward Networks: A Critical Review of Architectures", *IEEE Trans. Neural Network*, vol. 5, pp. 229-239, March. 1994.

- [7] Yi Cheng, T. W. Karjala, David M. Himmelblau, "Closed Loop Nonlinear Process Identification Using Internally Recurrent Nets", *Neural Networks*, vol. 10, pp. 571-586, July. 1997.
- [8] C. S. Burrus, R. A. Gopinath, and H. Guo, *Introduction to Wavelets and Wavelet Transforms*. Upper Saddle River, NJ: Prentice-Hall, 1998.
- [9] Madan M. Gupta, Dandina H. Rao, *Neuro-Control Systems Theory and applications*, IEEE PRESS, vol. a selected reprint, 1994.
- [10] Yoan D. Landau, *Adaptive Control, The Model Reference Approach*, Marcel Dekker, Inc., 1979.
- [11] Eduardo Liceaga-Castro, Gerrit M. van der Molen, "Submarine H^∞ Depth Control Under Wave Disturbances", *IEEE Trans. Control Systems Technology*, vol. 3, pp. 338-346, Sep. 1995.
- [12] Ah chung Tsoi, Shaohua Tan, "Recurrent neural networks: A constructive algorithm, and its properties", *Neurocomputing* 15, 1997, 309-326. 1345-1350, 1995.
- [13] J. Ludik, W. Prins, K. Meert, T. Catfolis, "A Comparative Study of Fully and Partially Recurrent Networks", *Proceedings of the 1997 International Conference on Neural Networks*, vol. 1, V.1, 1997-06-09.
- [14] Jean-Philippe S. Draye, Davor A. Pavicic, Guy A. Cheron, Gaetan A. Libert, "Dynamic Recurrent Neural Networks: A Dynamical Analysis", *IEEE Trans. Systems, Man and Cybernetics*, vol. 26, pp. 692-706, Oct. 1996.
- [15] J. S. R. Jang, C. T. Sun, E. Mizutani, *Neuro-Fuzzy and Soft Computing*, Prentice-Hall, Inc., 1997.
- [16] 김성현, 최중락, 심귀보, 전홍태, "수중운동체를 위한 퍼지 기증치를 갖는 뉴럴 체어기 설계", 대 한전자공학회 논문지, 제 33권 B편, 제3화, pp. 151-158, 1996년 3월
- [17] 김성현, "불확실한 비선형 동적시스템의 강건한 적응 퍼지-신경망 체어 및 로보트 매니퓰레이터에의 적용", 중앙대학교 전자공학과 박사학위 논문, 제 60회, 1996
- [18] 서승진, "비선형 시스템의 안정한 직접 적응 체어를 위한 웨이브렛 신경회로망", 중앙대학교 전자공학과 석사학위 논문, 제 90회, 1998

저자 소개

趙一(正會員)

1974年 4月 19日生. 1998년 2월 중앙대학교 전자공학과 졸업(학사). 2000년 2월 중앙대학교 대학원 전자공학과 졸업(석사). 2000년 3월~현재: (주) MG Tech. 제작 중. 주관심분야: 퍼지, 신경망, Soft Computing 등임

延 貞 欽(正會員) 第35卷 S編 第12號 參照

1970年 9月 23日生. 1994년 2월 중앙대학교 전자공학과 졸업(학사). 1996년 8월 중앙대학교 대학원 전자공학과 졸업(석사). 1996년 9월~현재: 중앙대학교 대학원 전자공학과 박사과정 재학중. 주관심분야: 퍼지, 유전알고리즘, 신경망, FNN 등임.

全 洪 兌(正會員) 中央대학교 전자공학과 교수

徐在龍(正會員)

1969年 7月 21日生. 1996년 2월 중앙대학교 전자공학과 졸업(학사). 1998년 2월 중앙대학교 대학원 전자공학과 졸업(석사). 1998년 8월~현재: 중앙대학교 대학원 전자공학과 박사과정 재학중. 주관심분야: 퍼지, 유전알고리즘, 신경망, FNN 등임.(第35卷 S編 第12號 참조)

金鑄宅(正會員)

1967年 2月 23日生. 1992년 2월 중앙대학교 전자공학과 졸업(학사). 1994년 8월 중앙대학교 대학원 전자공학과 졸업(석사). 1996년 9월~현재: 중앙대학교 대학원 전자공학과 박사과정 재학중. 주관심분야: 신경망, 로보틱스, 퍼지 등임