

CMAC를 이용한 비선형 시스템의 적응 제어

안대찬* 이영석 김성식 서보혁
경북대학교 전기공학과

Adaptive Control of Nonlinear System Using CMAC

Dae-Chan Ahn Young-Seog Lee Sung-Sik Kim Bo-Hyeok Seo
Department of Electrical Engineering Kyung-pook National University

Abstract - In this paper, an adaptive control scheme is proposed for slowly time-varying discrete-time nonlinear dynamic system. CMAC networks are employed to identify system from input-output data and to construct the controller based on this identifier. All of learning procedures are performed on-line. Computer simulation result shows the usefulness of the proposed scheme.

1. 서 론

신경망을 이용한 제어방법은 제어대상 시스템의 정확한 수학적 모델링 없이 입출력쌍의 자료만으로 학습을 통해 제어대상 시스템의 모델링이 가능하여 [3][4], 기존의 복잡한 수학적 제어 이론을 바탕으로 하는 제어방법의 한계점을 극복할 수 있다는 점 때문에 많은 연구가 진행되었다. 그러나 기존의 역전달 알고리즘을 사용하는 정방향 다층 신경망을 기본으로 하는 제어기는 오프라인 학습시 전체적인 모델링 성능이 우수한 반면 주된 문제점인 학습시의 모든 연결강도의 갱신으로 인한 학습속도의 매우 느림과 국부 최소(local minimum)에 빠질 가능성을 가지고 있어서 온라인 적응제어에 적합하지 않다.

1975년 Albus는 온라인 로봇 매니퓰레이터의 적응 제어에 Cerebellar Model Articulation Controller (CMAC)를 제안했다[2]. CMAC는 기존의 신경망과 유사한 구조를 가지고 있으면서 다른 독특한 성질을 소유하고 있다. 즉 초기의 빠른 학습속도로 인한 좋은 수렴특성, 입력공간의 분할을 통한 국부적 출력 정보의 저장과 연결강도의 갱신, 전체 연결강도의 수렴이 전역 최소(global minimum)를 보장한다. 이러한 특성 때문에 주로

온라인, 비선형 적응제어 분야뿐만 아니라 적응 비평 학습 제어, 신호처리, 분류 임무 등에 응용되었다[6][7].

또한, 1990년 이후 Albus의 binary CMAC를 보완하기 위해 퍼지 논리에서 사용하는 멤버십 함수와 퍼지 연산[5]을 CMAC 입력층의 기저함수(basis function)에 도입하여 퍼지의 장점인 모호한 자료를 처리하는 능력과 출력값의 연속성을 가지도록 함으로써 좀더 우수한 모델링 능력을 가지게 된다.

본 논문에서 제안한 전체적인 제어구조는 slowly time-varying 비선형 시스템을 모형화하는 식별기와, 이 식별기로 부터 얻은 정보를 이용하여 시스템의 출력이 기준 입력을 추정하도록 하는 제어기로 구성된다. 제한한 전체 제어시스템을 시변 비선형 동적 시스템의 적응제어에 유용함을 사례연구를 통해 입증한다.

2. CMAC의 구조와 특성

CMAC network의 기본 구조는 그림 1과 같이 Rosenblatt의 Perceptron과 유사한 3층 구조로 두 개의 사상으로 구분된다[1][2]. 첫 번째 사상은 고정된 비선형사상이고 두 번째 사상은 학습에 의해 변화하는 연결강도를 가진 적응 선형사상이다. 첫 번째 층에서 입력공간을 격자 형태의 모양의 등간격으로 분할하여 표준화한다. 두 번째 층의 기저함수(basis function)는 모두 일정한 크기의 대(support) -영이 아닌 기저함수값을 가지도록 하는 입력공간 -를 가지면서 첫 번째 층의 입력공간을 증첩하도록 설계자가 배열하게 된다. 여기서 설계자는 일반화 변수(generalization parameter), ρ 를 설정해야 한다. 이 ρ 에 의해서 대의 크기와 각 입력층의 각 격자에서 증첩되는 대의 수(ρ)가 일정하게 된다. 이와 같은 사상으로 인하여 임의의 한 국부 입력공간에 의해 사상되는 기저




그림 1. CMAC network의 구조

함수와 다른 국부 입력공간에 의해 사상되는 기저 함수가 다르다. 따라서 출력층으로의 적응 선형사상에서 CMAC의 출력값에 영향을 미치는 기저함수의 수(ρ)가 전체 기저함수의 수(p)의 일부부만 이 영향을 주게 되고 학습에 의한 연결강도의 갱신에서 출력값에 영향을 미치는 연결강도만을 갱신하면 된다. CMAC의 출력은 식 (1)과 같이 표현된다.

$$y(k) = \sum_{i=1}^{\rho} a_i(k) w_i(k) = \sum_{i=1}^{\rho} a_{ad(i)}(k) w_{ad(i)}(k) \quad (1)$$

여기서 $\rho \ll p$ 이며, $a_i(k)$ 는 기저함수의 값이며, $w_i(k)$ 는 연결강도이며, $ad(i)$ 는 영이 아닌 기저함수의 번지(address)가 된다. 기저함수는 퍼지에서 사용되는 멤버십함수와 퍼지 연산을 도입하여 각 격자에서의 기저함수의 활성화 정도를 0과 1사이의 값으로 줄 수 있다.

CMAC의 학습 알고리즘은 식 (2)와 같이 최급강화법을 이용하여 연결강도를 갱신한다.

$$w_i(k+1) = w_i(k) + \eta e(k) a_i(k) \quad (2)$$

여기서 η 는 학습계수이고, $e(k)$ 는 $y_d(k) - y(k)$ 로 원하는 출력값과 CMAC의 출력값 사이의 오차이다.

3. CMAC를 이용한 식별기와 제어기

식 (3)은 본 논문에서 다루게 되는 slowly time-varying 비선형 동적 시스템[4]이다.

$$y(k+1) = f(x(k), k) + g(x(k), k) \cdot u(k) \quad (3)$$

$$x(k) = [y(k), y(k-1), \dots, y(k-n+1),$$

$$u(k-1), \dots, u(k-m+1)]^T$$

여기서 $x(k) \in R^{n+m-1}$ 는 과거의 출력값과 과거의 입력값의 벡터이며, $f(x(k), k)$ 와 $g(x(k), k)$ 는 시스템의 미지의 시변 비선형 함수이다.

식별기의 구조는 식 (4)와 같이 표현된다.

$$\hat{y}(k+1) = \hat{f}(x(k) | w_f) + \hat{g}(x(k) | w_g) \cdot u(k) \quad (4)$$

w_f 와 w_g 는 각각 $f(x(k), k)$ 와 $g(x(k), k)$ 를

식별하는 CMAC의 연결강도 벡터이다.

적절한 제어기의 설계를 위해 함수 근사화 이론을 다음의 가정으로 둔다.

가정 1. 비선형 함수 $f(x(k), k)$ 와 $g(x(k), k)$ 를 어떤 compact영역 $x(k) \in D$ 에서 임의의 $\epsilon_f > 0$, $\epsilon_g > 0$ 이내로 근사화할 수 있는 CMAC 식별기 $\hat{f}(x(k) | w_f^*)$ 와 $\hat{g}(x(k) | w_g^*)$ 가 존재할 수 있는 연결강도 w_f^* 와 w_g^* 가 존재한다. 즉

$$\sup_{x(k) \in D} |\hat{f}(x(k) | w_f^*) - f(x(k), k)| < \epsilon_f \quad (5)$$

$$\sup_{x(k) \in D} |\hat{g}(x(k) | w_g^*) - g(x(k), k)| < \epsilon_g$$

식별기는 식 (6)의 식별 오차함수를 최소화하도록 학습한다.

$$E_I = \frac{1}{2} e_I^2(k+1) = \frac{1}{2} (y(k+1) - \hat{y}(k+1))^2 \quad (6)$$

w_f 와 w_g 에 대한 식별 오차의 기울기는 식 (7)과 같이 표현 된다.

$$\frac{\partial E_I}{\partial w_f} = -e_I \frac{\partial \hat{y}}{\partial w_f} = -e_I a_f(k) \quad (7)$$

$$\frac{\partial E_I}{\partial w_g} = -e_I \frac{\partial \hat{y}}{\partial w_g} = -e_I a_g(k) u(k)$$

따라서 CMAC의 연결강도의 학습법칙은 식 (8)과 같다.

$$w_f(k+1) = w_f(k) + \eta_f e_I a_f(k) \quad (8)$$

$$w_g(k+1) = w_g(k) + \eta_g e_I a_g(k) u(k)$$

만약 $f(x(k), k)$ 와 $g(x(k), k)$ 를 알고 있을 때 시스템의 출력이 기준 입력을 따라가게 하는 최적의 제어입력은 식 (9)와 같다.

$$u^*(k) = \frac{y_{ref}(k+1) - f(x(k), k)}{g(x(k), k)} \quad (9)$$

그러나 $f(x(k), k)$ 와 $g(x(k), k)$ 가 미지의 함수이므로 제어기는 식별기로부터의 $\hat{f}(x(k) | w_f)$ 와 $\hat{g}(x(k) | w_g)$ 를 바탕으로 제어입력을 식 (10)와 같이 구성한다[4].

$$u(k) = \frac{y_{ref}(k+1) - \hat{f}(x(k) | w_f)}{\hat{g}(x(k) | w_g)} \quad (10)$$




그림 2. 전제 제어 시스템의 블록선도

그림 2는 CMAC를 이용한 전체 제어 시스템의 블록선도를 나타낸 것이다.

4. 사례연구와 검토

제안된 제어 시스템을 이용하여 slowly time-varying 비선형 동적 시스템의 온라인 학습을 통한 적응제어에 적용하여 그 유용성을 보인다.

식 (11)로 표현되는 비선형 모형 시스템을 고려한다.

$$y(k+1) = f(y(k), y(k-1), k) + g(y(k), k) \cdot u(k)$$

$$f(y(k), y(k-1), k) = \frac{y(k)y(k-1)(y(k)+0.25)}{1+y^2(k)+y^2(k-1)} + 0.2 \sin(2\pi k/50)y(k)$$

$$g(y(k), k) = \frac{1+0.5 \sin(2\pi k/200)}{1+y^2(k)} \quad (11)$$

기준입력 신호는 식 (12)와 같이 준다.

$$y_{ref}(k) = 0.5 \sin(2\pi k/100) + 0.3 \sin(2\pi k/40) + 0.1 \cos(2\pi k/200) \quad (12)$$




그림 3. 시스템 출력($y(k)$)과

식별기 출력($\hat{y}(k)$)의 비교




그림 4. 시스템 출력($y(k)$)과

기준 입력($y_{ref}(k)$)의 비교




그림 5. 실제 제어 입력($u(k)$)과

최적의 제어 입력($u^*(k)$)의 비교

그림 3은 식별기 출력과 시스템 출력을 나타내며 식별기 출력이 시스템 출력을 추정함을 볼 수 있다. 그림 4는 기준 입력과 시스템 출력을 나타내며 시스템의 시변성에도 불구하고 추정함을 볼 수 있다. 그림 5는 최적의 제어 입력과 제안한 제어 방법에 의한 제어 입력을 비교하였다.

5. 결 론

제안한 제어기는 CMAC의 장점인 빠른 학습속도와 모델링 능력의 우수성을 이용하여 온라인 slowly time-varying 비선형 시스템의 적응 제어에 유용함을 보였다. 전체적인 제어 시스템의 구조는 식별기가 시스템의 출력을 추종하도록 학습을 하고 동시에 식별기로부터의 정보를 이용하여 최적의 제어 입력에 근사화하도록 제어기를 구성하였다.

[참 고 문 헌]

- [1] M. Brown and C. Harris, "Neurofuzzy adaptive modelling and control", Prentice-Hall, inc, 1994
- [2] J. Albus, "A New approach to manipulator control: the cerebellar model articulation controller(CMAC)", Trans ASME J. Dyn. Sys., Meas., and Contr., vol 97, pp. 220- 227, Sept. 1975
- [3] K.S. Narendra and K.P. Parthasarathy, "Identification and control of dynamical systems using neural networks", IEEE Trans. NN, Vol. 1, pp. 4, Mar. 1990
- [4] K.S. Narendra, J. Balarkrishnan, and M.K. Ciliz, "Adaptation and learning using multiple models, switching, and tuning", IEEE Contr. Syst. Mag, vol 15, No 3, pp37-51, Jun. 1995
- [5] S.H. Lane, D.A. Handelman, and J.J. Gelfand, "Theory and development of higher-order CMAC neural networks", IEEE Contr. Syst. Mag, vol 12, No 2, pp23-30, April 1992
- [6] W. T. Miller, "Sensor-based control of robotic manipulators using a general learning algorithm", IEEE Journal of Robotics and Automation, vol. RA-3, No 2, pp157-165, April 1987
- [7] W. T. Miller, F. H. Glanz, and L. G. Kraft, "CMAC : An associative neuralnetwork alternative to backpropagation", Proc. IEEE, vol 78, No 10, pp1561-1567, Oct. 1990