

<학술논문>

DOI:10.3795/KSME-A.2010.34.12.1865

ISSN 1226-4873

뉴럴네트워크 모델 기반의 IPMC 셀프 센싱 액추에이터[§]

윤종일* · 딩광정** · 안경관**†

* 울산대학교 기계자동차공학과 , ** 울산대학교 기계자동차공학부

Self-Sensing Actuator Using an Ion-Polymer Metal Composite Based on a Neural Network Model

Jong Il Yoon*, Dinh Quang Truong** and Kyoung Kwan Ahn**†

* Dept. of Mechanical and Automotive Engineering, Univ. of Ulsan.,

** School of Mechanical and Automotive Engineering, Univ. of Ulsan.

(Received July 5, 2010 ; Revised October 18, 2010 ; Accepted October 20, 2010)

Key Words: IPMC(이온고분자금속복합재료), Self-Sensing(셀프 센싱), NNM(뉴럴네트워크모델) , RMLPNN(다층회기지수신경망), SALM(자가조절학습방법)

초록: 이 논문에서는 뉴럴네트워크 모델에 기초하여 셀프 센싱이 가능한 IPMC 액추에이터를 개발하고자 한다. IPMC의 양면에 있는 두 개의 지정된 점에서 측정된 입력 전압과 입력 신호들을 뉴럴네트워크 모델의 입력 신호로 사용한다. CCD 레이저 변위 센서는 제시된 뉴럴네트워크 모델의 학습된 출력값으로 사용되는 IPMC 끝의 변위를 정확히 측정하기 위해 설치된다. 결과적으로 뉴럴네트워크 모델은 수집된 입력/출력 학습데이터에 의해 최대한으로 활용된 IPMC의 끝의 변위를 평가하기 위해 만들어진다. IPMC 액추에이터를 위해 설계된 모델의 효율성은 결과들을 모델링함으로써 증명되어진다.

Abstract: We develop an IPMC actuator with self-sensing behavior based on an accurate neural network model (NNM). The supplied voltage and voltage signals measured at two determined points on both sides of the IPMC sheet are used as inputs to the NNM. A CCD laser displacement sensor is installed in the rig for accurate measurement of the IPMC tip displacement that is used as the training output of the proposed NNM. Consequently, the NNM model is used to estimate the IPMC tip displacement; the NNM parameters are optimized by the collected input/output training data. The effectiveness of the model for the IPMC actuator is then verified by modeling results.

1. 서 론

최근의 연구에 따르면 IPMC(Ion Polymer Metal Composite, 이하 IPMC)는 센서와 액추에이터의 기능이 동시에 가능한 재료이다.⁽¹⁾ IPMC의 특징은 전기적 자극이 인가되었을 때 물리적, 전기적, 화학적 성질에 의해 거동하는 복잡한 동작 특성을 가진다. 또한 유연하고 대변위를 갖는 특성으로 인해 의료 및 생체공학 분야의 구동기에 많이 적용할 수 있다. 하지만 IPMC는 왜곡과 고주파 응답과 같은 히스테리시스와 크리프 행동과 같은 몇 가지의 단점을 가지고 있다. 게다가 IPMC의

변형특성은 작업조건이 크게 영향을 미친다. 그러므로 IPMC의 특성을 연구하기 위해 정확한 모델을 개발하는 것이 중요하다.⁽²⁾ 최근 IPMC 식별을 위해서 IPMC 표면 저항의 변형에 대해 연구가 이루어지고 있다.⁽³⁾

이 논문의 목표는 IPMC의 굽힘 현상 측정을 위한 독창적이고 정확한 뉴럴네트워크 모델(Neural Network Model, 이하 NNM)을 개발하는 것이다. 이 NNM은 IPMC의 끝 변위 추종을 위하여 다층회기지수신경망(Recursive Multi Layer Perceptron Neural Networks, 이하 RMLPNN)과 자가조절학습방법(Self Adjusting Learning Mechanism, 이하 SALM)을 조합한다. 우선, IPMC 액추에이터 특성을 조사하기 위해 시스템이 구성된다. 그리고 모델 변수값은 학습된 데이터 값에 의해 최적화된다.

§ 이 논문은 대한기계학회 2010년도 울산지회 춘계 학술대회(2010. 5. 14., 울산대) 발표논문임

† Corresponding Author, kkahn@ulsan.ac.kr

© 2010 The Korean Society of Mechanical Engineers

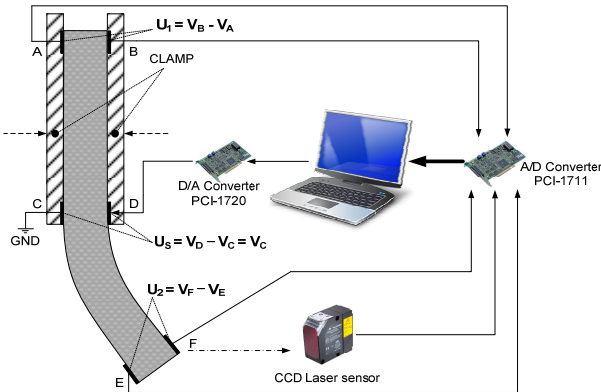


Fig. 1 Experiment Setup for IPMC Actuator

2. 시스템 구성

IPMC를 이용하는 테스트 장비는 Fig. 1과 같이 구성된다. 이 액추에이터는 Environmental Robots사의 IPMC이며 플라스틱 클램프에 의해 고정된다. 여섯 개의 전극을 Fig. 1의 A, B, C, D, E, F와 같이 연결하였다. 시스템의 제어를 위해 데스크탑 컴퓨터와 Simulink/MATLAB을 사용하였다. 데이터 수집보드로 Advantech의 A/D 1711과 D/A 1720을 컴퓨터 PCI 슬롯에 설치하였다. CCD 레이저 변위 센서는 Keyence사의 LK-081을 사용하였으며, IPMC의 끝부분의 변위를 측정하기 위하여 설치하였다. IPMC 액추에이터를 위한 설정된 매개변수는 Table 1에 나타낸다.

전극 C는 그라운드와 연결되어 있고 전극 D에는 PC에서 전압이 인가되어 IPMC 구동이 결정된다. 동시에 다른 전극의 전압들은 인가된 전압과 입력데이터를 알기위해 측정된다. 레이저 센서에 의해 측정된 IPMC 끝단 변위는 출력 데이터이다. 이러한 측정된 입/출력 데이터는 모델링 결과들을 증명하기 위하여 사용되어지고 또한 뉴럴네트워크 모델의 학습을 위해서도 사용된다.

3. 뉴럴네트워크 모델 설계

IPMC 구동 시스템은 비선형성과 불확실성을 보인다. 이 문제의 해결책으로서 비선형 운동의 식별을 위해 뉴럴네트워크가 적용되어왔다. 하지만 더 복잡한 시스템의 경우 식별이 쉽지 않다. 그러므로 복잡한 IPMC 식별의 문제점의 더 나은 해결책으로 RMLPNN과 SALM을 결합하여 더욱 정확하고 복잡한 비선형적인 시스템에 적용이 가

Table 1 Setting parameters for IPMC system

Parameters	Specifications
Operating environment	Dry
Size	(40×6×0.2)mm
Sampling time	0.001s
Driving voltages	3~5V

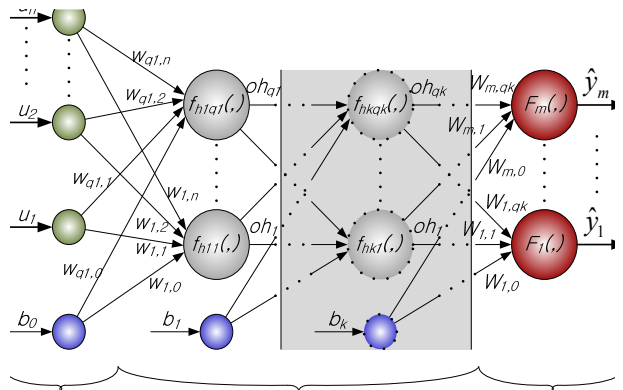


Fig. 2 Structure of a feed-forward MLPNN

능하게 뉴럴네트워크를 설계하였다.

3.1 다층회기지수신경망(RMLPNN)

기존의 RMLPNN은 Fig. 2에 보여진다. $[-1, 1]$ 의 범위에 있는 입력 벡터 (u_1, \dots, u_n) 는 시스템 입력에 의해 표준화된다. 각각의 은닉층의 뉴런의 결합 값(sh)은 식 (1)로 정의된다.

$$sh_j = \begin{cases} \text{For each node in } 1^{st} \text{ hidden layer } (h_1) : \\ \sum_{i=1}^n w_{ji} u_i + w_{j0} b_0, \quad j = 1, \dots, q_1 : \\ \text{For each node in } l^{th} \text{ hidden layer } (l = 2..k) \\ \sum_{i=1}^{q_{l-1}} w_{ji} oh_i + w_{j0} b_{l-1}, \quad j = 1, \dots, q_l : \end{cases} \quad (1)$$

$(b_0, \dots, b_{k-1} : \text{bias factors})$

본 연구에서 시그모이드 활성화 함수 f 가 사용되어지고 결과적으로 은닉층(oh)의 출력값이 산출된다.

$$oh_j = f(sh_j) = \frac{1}{1 + e^{-sh_j}} \quad (2)$$

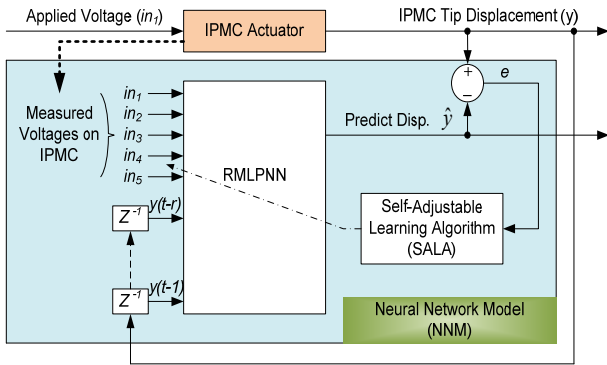


Fig. 3 Block diagram for training NNM model

같은 방법으로 각각의 네트워크 출력값 \hat{y} 는 식 (3)과 같이 얻을 수 있다.

$$\hat{y} = F(SH_p) = \frac{1}{1 + e^{-SH_p}},$$

$$SH_p = \left(\sum_{j=1}^{q_k} W_j oh_j + W_0 b_k \right), p = 1, \dots, m \quad (3)$$

3.2 IPMC 액추에이터 NNM 모델 설계

본 논문에서 제안하는 NNM의 학습 블록 다이어그램은 Fig. 3에 나타낸다. NNM에서 다섯 개의 측정된 전압 신호 A, B, D, E, F는 다섯 개의 모델 입력값으로 사용되어진다. IPMC의 끝단 변위의 예측된 NNM은 하나의 은닉층과 하나의 출력을 가진다. 게다가, 출력과 피드백된 신호는 즉시 NNM으로 보내진다. Fig. 3에서와 같이 뉴럴네트워크의 입력값은 다음과 같이 고려되어진다.

$$U = \begin{bmatrix} u_1 \\ \vdots \\ u_{5+r} \end{bmatrix} = [\epsilon_1 \dots \epsilon_5 \ y_{-1} \dots \ y_{-r}]^{-1} \quad (4)$$

그러므로 모델의 출력값은 식 (5)와 같이 계산되어진다.

$$\hat{y}(t+1) = F(U, w, W) \quad (5)$$

w 와 W 는 각각 은닉층과 출력층의 가중행렬이다.

$$w = \begin{bmatrix} w_{10} & \dots & w_{1n} \\ \vdots & & \vdots \\ w_{q0} & \dots & w_{qn} \end{bmatrix}; W = [W_0 \ \dots \ W_q] \quad (6)$$

식 (5)에서 가중행렬(w, W)은 네트워크의 변화 가능한 변수들이며 결정되어질 필요가 있다. 제시된 NNM은 동적 네트워크이다. 이러한 NNM을 최적화하기 위하여 동적학습 메커니즘인 SALM은 필요하다. 제안된 SALM은 기울기하강법(Gradient descent method), 역전파 알고리즘(Backpropagation algorithm), 예측오차함수(Prediction error function)에 기초하고 있으며 식 (7)과 같이 정의된다.

$$E = \frac{1}{2} \sum_{i=1}^m (\hat{y}_i - y_i)^2 \equiv E = \frac{1}{2} (\hat{y} - y)^2, (m = 1) \quad (7)$$

($k+1$) 번째의 단계를 위한 가중치 \bar{W} (\bar{W} is wor W)는 아래의 식 (8)과 같이 업데이트 된다.

$$\bar{W}(k+1) = \bar{W}(k) + \eta(k+1) \Delta \bar{W}(k+1);$$

$$\Delta \bar{W}(k+1) = \alpha(k+1) \Delta \bar{W}(k) - \frac{\partial E}{\partial \bar{W}(k)}; \quad (8)$$

$\eta(k+1)$: learning rate turned by LRFuzzy

$\alpha(k+1)$: momentum rate turned by MR Fuzzy

출력층의 가중치를 위한 인수 $\frac{\partial E}{\partial W(k)}$ 는 식 (8)에서 다음과 같이 정의된다.

$$\frac{\partial E}{\partial W_j} = \begin{cases} -\delta oh_j & \text{for weights: } W_1, \dots, W_q; \\ -\delta b_1 & \text{for weight: } W_0 \end{cases}; \quad (9)$$

$$\delta = \hat{y}(1 - \hat{y})(y - \hat{y})$$

여기서 δ 는 각 단계에서의 출력층의 뉴럴단위의 검색방향 값이다.

은닉층의 가중치를 위한 인수 $\frac{\partial E}{\partial W(k)}$ 는 식 (8)에서 계산되었다.

$$\frac{\partial E}{\partial W_{ji}} = \begin{cases} -\delta_j u_i & \text{for weights: } W_1, \dots, W_n; \\ -\delta_j b_0 & \text{for weight: } W_0 \end{cases}; \quad (10)$$

$$\delta_j = oh_j(1 - oh_j)\delta W_j$$

여기서 δ_j 는 각 단계의 은닉층의 j 번째 뉴럴단위의 검색방향 값이다.




Fig. 4(a) MFs of LR fuzzy inputs




Fig. 5(a) MFs of MR fuzzy input




Fig. 4(b) MFs of LR fuzzy output




Fig. 5(b) MFs of MR fuzzy output




Fig. 4(c) LR Fuzzy rule surface




Fig. 5(c) MR Fuzzy rule surface

LR Fuzzy : 범위 [0, 1] 안에 있는 두 개의 입력값 $|e(t)^*$ 와 $|dw^*/dt|$ 는 모델링 오차와 가중치 변화 속도의 절대값이다. 각각의 입력값에 대한 다섯 개의 멤버십 함수(MFs)는 Fig. 4(a)에서처럼 분할되어 사용되어진다. LR fuzzy의 출력은 학습률을 계산하기 위한 계인(k_{LR})이다. Fig. 4(b)로부터 이 출력은 다섯 개의 MFs를 가진 범위 [0.5, 1.5]안의 값을 알 수 있다. LF fuzzy를 위해 설계된 IF-THEN추론은 Fig. 4(c)에서 보여진다. 그러므로 SALM의 학습률은 식 (10)에서 산출된다.

$$\eta(k+1) = k_{LR}(k+1) \times \eta_0; \text{constant: } \eta_0 = 0.5 \quad (11)$$

MR Fuzzy : 하나의 입력값 $e(t)^*$ 는 [-1, 1]의 범위에서 출력(k_{MR})하는 동안의 축소된 모델링 에러이다. k_{MR} 은 모멘텀을 조절하기 위해 사용된다.

범위 [0.5, 1.5] 안에 있는 계인값이다. 다섯 개의 멤버십 함수(MFs)는 Fig. 5(a), (b)에서 보여지는 출력값 뿐만 아니라 입력값의 분류를 위해 사용된다. MR fuzzy를 위해 설계된 방식들은 Fig. 5(c)에 나타난다. 결과적으로 출력 계인(k_{MR})은 SALM의 모멘텀을 조절하기 위해 사용된다.

$$\alpha(k+1) = k_{MR}(k+1) \times \alpha_0; \text{constant: } \alpha_0 = 0.5 \quad (12)$$

4. 모델링 결과

NNM 안의 은닉층 속의 적합한 입력과 뉴럴 단위의 수를 결정하는 것은 모델의 실제적인 수행에서 반드시 필요하다.

IPMC 시스템의 일련의 모델 학습과정을 위해 데이터를 얻는 것에 대한 실험은 오픈루프 제어 시스템을 사용하여 실행되었으며, 구동전압은 주




Fig. 6(a) Modeling Result with respect to a (4.2V, 0.1Hz) Square Driving Voltage




Fig. 6(b) Modeling Result with respect to a (3.4V, 0.1Hz) Square Driving Voltage

과수 0.1Hz와 진폭 4.2V의 사각형 전압 신호를 사용하였다. 결과적으로 Fig. 6(a)에서 보여지듯이 이 구동 신호에 관한 한 세트의 실험 데이터가 다른 RMLPNN 구조를 가진 NNM을 훈련하기 위해 사용된다.

은닉층의 뉴럴 번호는 6에서 14의 범위에 있는 동안 입력의 수는 5에서 7로 다양하다. 학습 결과는 다른 NNM 구조를 위한 성공적인 학습률 [%]에 의해 평가되었다. 그 결과, 입력층의 7개의 뉴런과 은닉층의 8개의 뉴런을 가진 세층의 RMLPNN은 NNM을 최적화 할 수 있으며, 이 최적화된 NNM은 최상의 91.5%의 매우 높은 정밀도와 IPMC 끝단 변위를 예측할 수 있다. 그 결과 선택된 NNM을 사용하는 IPMC 모델링 결과를 진폭 4.2V와 3.4V의 사각형 구동 전압에 관하여 Fig. 6(a), 6(b)에 나타낸다. 그 결과는 설계된 모델이 IPMC의 굽힘 현상을 측정하기에 충분함

을 보여준다.

5. 결론

본 논문에서 정밀한 NNM을 새롭게 제안하였고, IPMC 액추에이터를 설계하였다. 제안한 모델은 RMLPNN에 기초하고 SALM에 의해 최적화되었다. 모델링의 결과로 NNM이 높은 정밀도로 IPMC의 동적 굽힘의 특징들을 잘 설명할 수 있다는 것을 증명하였다.

본 논문에서 제안한 모델링 방법은 IPMC 제어 애플리케이션과 IPMC의 끝단의 변위를 측정하여 셀프 센싱 역할이 가능한 NNM에 효과적이다.

후기

이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2009-0080924)

참고문헌

- (1) Chen, Z., Kwon, K. Y. and Xiaobo, T., 2008, "Integrated IPMC/PVDF Sensory Actuator and Its Validation in Feedback Control," *Sensor and Actuator A: Physical*, Vol. 144, No. 2, pp. 231~241.
- (2) Bandopadhyya, D. and Njuguna, J., 2009, "Estimation of Bending Resistance of Polymer Metal Composite (IPMC) Actuator Following Variable Parameters Pseudo-Rigid Body Model," *Material Letter*, Vol. 63, No. 9-10, pp. 745~747.
- (3) Chen, Z. and Tan, X., 2008, "A Control-Oriented and Physics-Based Model for Ionic Polymer-Metal Composite Actuators," *IEEE/ASME Transaction on Mechanics*, Vol. 13, pp. 519~529.
- (4) Ba-Cohen, Y., 2001, "Electro-active Polymer (EAP) Actuators as Artificial Muscles-Reality," *Potential and Challenges*, Spie Press
- (5) Yamakita, M., Kamamichi, N., Kozuki, T., Asaka, K. and Zhi-Wei, L., 2005, "A Snake-Like Swimming Robot Using IPMC Actuator and Verification of Doping Effect," *Proceeding of IEEE/RSJ International Conference*, August, pp. 2035~2040.

- (6) Lavu, B.C., Schoen, M.P. and Mahajan, A., 2005, "Adaptive Intelligent Control of Ionic Polymer-Metal Composites," *Smart Materials & Structure*, Vol. 14, No. 8, pp. 466~474.
- (7) Tung, N.T., Khanh, N.V., Youngtai, Y. and Goo, N.S., 2006, "A Novel Polymeric Micropump Based on a Multilayered Ionic Polymer-Metal Composite," *Proceeding of IECON-32nd Annual Conference*, November, pp. 4888~4893.
- (8) Yun, K. S. and Kim, W. J., 2006, "Microscale Position Control of an Electroactive Polymer Using an Anti-Windup Scheme," *Smart Materials & Structure*, Vol. 15, pp. 924~930.
- (9) Guo, S., Shi, L. and Asaka, K., 2008, "IPMC Actuator-Sensor Based a Biomimetic Underwater Microrobot with 8 Legs," *Proceeding of ICAL 2008. IEEE International Conference*, September, pp. 2495~2500.
- (10) Bonomo, C., Brunetto, P., Fortuna, L., Giannone, P., Graziani, S. and Strazzeri, S., 2008, "A Tactile Sensor for Biomedical Applications Based on IPMCs," *IEEE Sensors*, Vol. 8, No. 8, pp. 1486~1493.
- (11) Jung, H. and Gweon, D. G., 2000, "Creep Characteristics of Piezoelectric Actuators," *Review of Scientific Instruments*, Vol. 71, pp. 1896~1900.