

LVQNN을 이용한 공압 근육 매니플레이터의 지능 스위치 제어 Intelligent Switching Control of a Pneumatic Muscle Robot Arm using Learning Vector Quantization Neural Network

안경관·윤홍수

K. K. Ahn and H. S. Yoon

1. 서론

산업용 로봇은 액추에이터의 세 가지 기본적인 타입인 전기모터(DC 또는 AC), 유압 실린더 또는 공압 실린더로 사용되고 있다. 이러한 액추에이터의 성능은 중량대비 출력, 강도, 응답성, 시스템 크기, 운동속도, 신뢰성, 제어성, 컴플라이언스, 비용 등으로 평가된다. 오늘날 대부분의 매니플레이터는 서보모터나 스텝핑 모터의 형태로 된 전기드라이버를 채택하고 있지만, 전기시스템의 단점인 낮은 출력, 중량 대비 저출력 및 토크, 스파크의 가능성 등을 가지고 있다. 유압 액추에이터가 고속작동에 사용되고 있더라도 작동유 오염 등의 문제점들을 가지고 있다. 그러므로 공압 액추에이터는 중량과 체적에 비해 높은 출력, 빠른 응답성, 경제성 등으로 사용이 늘어나고 있다. 그러나 공압 액추에이터는 압축성 및 외부부하의 변동이 존재할 때 고정도 위치제어와 컴플라이언스를 동시에 만족시키기가 힘들다. Repperger와 그의 팀은 게인 스케줄링(gain scheduling) 방법을 사용하여 공압 액추에이터가 가지는 비선형적인 요소를 제어 하였다.¹⁾ 또한, McKibben Muscle, Rubber 액추에이터와 인공 공압 근육 매니플레이터 (Pneumatic Muscle Manipulator, 이하 PAM)와 같은 획기적인 액추에이터의 개발로 위의 문제점을 해결 할 수 있게 되었다. PAM은 실제 생물학적인 근육에서 보여지는 많은 특성을 가지고 있다. 시스템 구성과는 달리, 비선형성, 공기의 압축성, 진동, 시간에 따른 시스템의 변동 및 해석적인 모델링의 어려움 등으로 인하여 PAM의 제어는 매우 어렵다. 그러므로 다양한 외부 부하에 대해서도 고정도 위치제어의 구현은 어렵다.

결과적으로 PAM의 다양한 위치제어에 대한 연구가 활발히 이루어지고 있다. Caldwell 은 피드포워드(feedforward)의 불연속적인 시간에 대해서 공압 근

육을 제어하기 위해 PID제어기를 사용하였다.²⁾ 이 제어기는 작은 오버슈트를 가지는 적절한 페루프의 대역폭을 얻기 위해 시행착오법을 수행한다. Robb은 PAM의 수학적 모델을 구현하였다.³⁾ 이 모델은 이 해설의 시뮬레이션 결과로부터 바이오 로봇으로 확장 시킬 수 있다. Gustavo는 한 쌍의 PAM에 대하여 적응 극배치 제어기를 사용하여 극점을 $\pm 2^\circ$ 로 고정도 위치제어를 구현하였다.⁴⁾ 또한, Ted는 Kohonen의 신경망 방식의 제어기를 적용하여 1cm 이내의 위치제어를 구현하였다.⁵⁾ 최근에 Patrick는 피드포워드 신경망 제어기를 개발하였는데, 여기서 회전각과 공압 근육 챔버의 압력은 참조 데이터로 사용되었으며, 정확한 궤적제어를 구현하였다.⁶⁾

Gustavo, Ted, Darwin, Tsagarakis, Chan, Osuka, Kishore은 각각 적응 제어⁴⁾, 신경망 제어⁵⁾, PID 제어⁸⁾, fuzzy PD+I 학습제어⁹⁾, H infinity 제어¹⁰⁾, 퍼지 제어¹¹⁾ 등의 제어기를 PAM 제어에 적용하였다. 이는 비록 스텝 입력에 대해서 액추에이터가 부드러운 움직임을 보여준다고 할지라도, 외부 관성부하가 일정하고 변동이 느리다는 가정을 하였다.

본 해설에서는 외부 부하변동을 고려하여 PAM을 제어 하는데 있어서 빠르고 정확하며, 지능적인 인공 공압 근육의 제어시스템을 구현 하고 한 쌍의 PAM을 제작하여 상기 제안한 알고리즘의 유효성을 실험을 통하여 검토한 결과에 대하여 해설하고자 한다.

2. 실험 장치

인공 공압 근육 매니플레이터의 시스템 개략도와 사양을 Fig. 1과 Table 1에 나타낸다.

컴퓨터에서 계산된 제어 값은 D/A 보드를 통하여 PWM신호로 변환되고 변환된 신호는 축에 있는 밸브에 전달된다. 제어신호에 따라 각 밸브 조합이 작

동되고, 복동 실린더의 해당 챔버에 공압이 공급됨으로써 공압 매니플레이터의 기구학적인 동작이 이루어진다. 각 축의 움직임은 로터리 엔코더에 의해 검출되고 카운트 보드를 통해 읽어진다.

실험은 무부하(0kg)에서 10kg까지 변화 시키며 압력은 5bar로 실험하며 모든 제어 소프트웨어는 C언어로 하였다. 실험장치의 사진은 Fig. 3에 나타내었다.




Fig. 1 Schematic diagram of the robot arm using pneumatic artificial muscle

공압 근육의 작동원리를 Fig. 2에 나타내고 있다. 두 개의 근육은 사슬 물개로 교차되는 체인으로 연결되어 있고, 이때 다른 공기압이 근육에 공급되며, 다른 평형상태의 길이가 조인트에 대한 평형각의 변화의 결과를 낸다.




Fig. 2 Antagonistic muscle scheme

Table 1 Specification of the system

PC	Pentium III 1GHz
복동 실린더	SMC, CGIA 63-220
비례제어밸브	FESTO, MPYE-5-1/8HF -710 B
공압근육	FESTO, MAS-10-N-220-AA-MCFK
Rotary Sensor	MATRONIX, S48-8-3600,ZO, 10Pulse/Degree
Pneumatic Sensor	FESTO, SDE 10-10V
DIO Board	Advantech, PCI 1711, 12bit
Counter Board	Advantech, PCL833, 24bit




Fig. 3 Photograph of the experimental apparatus

3. 제어 알고리즘

3.1 전체 제어 시스템

외부부하에 따라 적절한 제어 파라미터 값들을 조절하기 위하여 공압 근육의 동적 특성을 실시간으로 부하상태를 분류할 수 있어야 한다. 여기서 교사기(Supervisor)의 역할로서 LVQNN을 적용하였다. LVQNN을 적용시킨 시스템은 Fig. 4에 나타나고 있다.

PAM을 제어하기 위해 기본적인 제어기로 고전 PID제어를 이 논문에 적용시켰다. PID제어기의 출력은 시간영역에서 부하상태에 따라 다음과 같이 표현된다.

$$u(t) = K_p e(t) + \frac{K_p}{T_i} \int_0^t e(t) dt + K_p T_d \frac{de(t)}{dt} \quad (1)$$

식(1)을 라플라스 변환을 하면

$$U(s) = K_p E(s) + \frac{K_p}{T_i s} E(s) + K_p T_d s E(s) \quad (2)$$

그리고 PID의 전달함수는

$$\frac{U(s)}{E(s)} = K_p \left(1 + \frac{1}{T_i s} + T_d s \right) \quad (3)$$

상기 PID 제어기의 이산화 표현은 다음과 같다.

$$u(k) = K_p e(k) + u(k-1) + \frac{K_p T}{T_i} e(k) + K_p T_d \frac{e(k) - e(k-1)}{T} \quad (4)$$

여기서 $u(k)$, $e(k)$ 는 각각 제어 밸브의 제어입력값과, 조인트 회전각의 출력값과 목표값의 오차값이다.

3.2 LVQNN을 이용한 외부부하의 구분

3.2.1 신경 분류기의 구조

신경망에는 감독 학습, 비감독 학습과 하이브리드 학습과 같은 몇몇 방식의 학습들이 있다. 감독 학습은 주어진 자극에 대해서 요구되는 응답을 사용하는 것에 대한 훈련이다; 비감독 학습은 특정 응답 없이 자극을 클러스터링함으로써 구분되어진다.




Fig. 4 Structure of proposed control algorithm

그리고 하이브리드 학습은 위의 두 가지 학습법의 조합이다. LVQNN은 비감독 학습의 형태이지만, 감독 학습을 조합 할 수 있다.

Fig. 5는 입력 패턴을 분류하기 위해 사용된 LVQNN의 구조를 보여준다. 여기서 P, y, W1, W2, R, S1, S2와 T는 각각 입력 벡터, 출력벡터, 경쟁층(competitive layer)의 가중치, 선형층(linear layer)의 가중치, 입력층(input layer)에서 신경의 개수, 경쟁층, 선형층과 목표층을 나타낸다. LVQNN의 핵심은 다음 방정식과 같은 유클리드 거리-무게를 계산하는 최단 거리법에 기초를 둔다.

$$D(P, W_i(i)) = \sqrt{\sum_{i=1}^R (P(i) - W_i(i))^2} \quad (5)$$

C는 경쟁층 전달함수(competitive transfer function)를 나타낸 것으로, 경쟁층 전달함수는 1을 가지는 출력 벡터를 반환하는데, 각 망(net)의 입력 벡터는 입력벡터의 최대값을 가지고 그 밖에는 0을 가진다.

LVQNN은 숨겨진 경쟁층과 선형 출력층(linear output layer)으로 구성된다. 외부부하를 인지하기 위해 경쟁 학습(competitive learning)은 클러스터를 형성한다.

이 과정에서 가장 작은 오차값을 찾기 위해 경쟁층의 가중치를 저명한 식(6)의 Kohonen 법칙에 의해 학습한다. 다음으로 각 클래스의 클러스터에 출력값을 할당하게 된다. 마지막으로 목표로 하는 클래스로 입력이 분류되면 클러스터 표현은 강화된다.

$$\begin{cases} W_i^{t+1}(i) = W_i^t(i) + \alpha(P - W_i^t(i)), \\ \quad i = 1, 2, \dots, S_1 \text{ if P is classified correctly} \\ W_i^{t+1}(i) = W_i^t(i) - \alpha(P - W_i^t(i)), \\ \quad i = 1, 2, \dots, S_1 \text{ if P is classified incorrectly} \end{cases} \quad (6)$$




Fig. 5 Structure of the LVQNN




Fig. 6 Training data for LVQNN

식(6)에 의하여 데이터를 생성할 때, 경쟁층은 가장 작은 오차 값을 가지게 된다.

3.2.2 LVQNN의 양성에 대한 데이터 생성

이 절에서 LVQNN에 대한 데이터 학습을 자세히

설명한다. Fig. 5에서 $P(1), P(2) \dots P(R)$ 은 입력벡터이다. 여기서 R 은 제어입력, 위치데이터 근육1, 2의 압력의 입력 수이다. LVQNN의 데이터 학습은 Fig. 6에 나타낸다. 일반적으로 입력 벡터가 많을수록 제어 성능은 좋아진다. 그러나 계산 시간이 더 길어지며 인식 시간도 길어진다. 이 실험에서는 LVQNN에 입력 벡터는 공압 근육 1과 2에서의 제어 입력, 위치데이터 및 각 챔버의 압력으로 설정하였다; LVQNN의 출력은 1과 3 사이의 정수이며 클래스 1, 2, 3은 로봇 암에 대한 외부부하가 0, 5, 10kg을 각각 의미한다. LVQNN에 대한 학습 데이터를 얻기 위해, 3가지 다른 외부부하에 대해서 일련의 실험을 하였다. Fig. 7 (a)~(d)에서 학습 데이터는 비례제어밸브의 제어 입력, 조인트의 위치 및 근육 1과 2의 압력을 보여준다. 학습 데이터 생성에 대한 실험에서 참고 각은 45도이며 고정 이득 PID 제어기를 사용하였다. LVQNN 학습의 주요 특징은 외부부하를 구분하는데 있다. 그래서 LVQNN의 경쟁층에서 뉴런의 수와 적절한 입력의 결정은 신경 분류기의 실제적인 구현에 있어서 필수 요소이다. 입력벡터의 수를 결정하기 위해 10~18 입력벡터 수를 조절 하면서 실험을 하였다. 여기서 경쟁층의 뉴런 수는 12개에서 30개




Fig. 7 Experiment results for training data generation

로 변화시켰다. 그 결과는 Table 2와 Fig. 7에 나타내었다.

이것으로부터 학습 결과는 학습 성공률 78.19%의 경쟁층에서 15개의 뉴런과 14개의 입력 데이터를 만족한다. 이것은 외부부하 상태의 인지를 충분하게 하는 것이다. 15개의 뉴런과 14개의 입력 데이터보다 증가시켰을 때, 학습성공률이 증가하지 않는 것은 학습과정에서 특정 뉴런의 개수와 입력 수만이 외부부하를 인지하는데 높은 학습성공률을 가지기 때문이다.

이것으로부터 학습 결과는 학습 성공률 78.19%의 경쟁층에서 15개의 뉴런과 14개의 입력 데이터를 만족한다.

Table 2 Learning success rate of LVQNN

Input Neuron	10	12	14	16	18
12	71.78	70.50	70.79	73.49	73.45
15	76.24	73.50	78.19	74.06	76.52
18	69.96	71.86	71.48	73.37	77.56
20	74.73	73.18	69.06	72.96	76.19
23	70.59	75.52	76.90	75.13	71.65
25	76.95	76.38	75.03	75.07	74.32
28	73.69	76.90	72.89	74.08	73.12
30	76.07	74.76	75.11	69.62	76.54

3.3.3 유연 스위칭 알고리즘 제안

외부부하가 이전 학습 시 사용한 부하와 다른 경우, LVQNN의 출력은 각각 부하상태를 일정비율로 혼합된 클래스 값들을 출력 값으로 얻게 될 것이다. (다시 말해서 외부부하가 0에서 5kg사이라면 클래스 1또는 2가 될 것이다.) 그러므로 갑작스런 플랜트 변화에 적용시키기 위해 다음과 같은 알고리즘을 제안하였다.




Fig. 8 Learning success rate of the LVQNN

$$class(k) = \lambda \times class(k-1) + (1-\lambda) \times class(k) \quad (7)$$

식(7)에서 k는 이산시간, λ는 이동평균계수, Class(k)는 이산시간에서의 LVQNN의 출력값을 나타낸다.

각 외부부하 조건의 PID 제어기의 최적 파라미터는 실험에 의하여 시행착오법으로 선정하였다. 그 결과를 Table 3에 나타내었다. 여기서 속도, 가속도는 엔코더에서 나오는 신호를 수학적으로 차분하여 이용하였다.

Table 3 Optimal parameters of PID gain

Class No	K _P	K _I	K _D
Class 1 (0 Kg)	9.10 ⁻⁵	1.10 ⁻⁷	75.10 ⁻⁶
Class 2 (5 Kg)	85.10 ⁻⁶	1.10 ⁻⁷	66.10 ⁻⁶
Class 3 (10 Kg)	69.10 ⁻⁶	8.10 ⁻⁸	32.10 ⁻⁶

4. 실험 결과

Fig. 7(b)는 제어 이득(무부하 조건에서 최적화시킨 이득)은 고정시키고, 3가지 다른 조건의 외부부하에 대하여 위치제어 실험을 실시한 결과를 나타내고 있다. 시스템 응답이 외부부하가 커짐에 따라 불안하게 됨을 알 수 있었다. 그러므로 제어 파라미터는 외부부하에 따라 적절히 조절되어야 한다. 여기서 LVQNN의 신경 분류기는 외부부하의 변화를 인식하고자 한다.

그 실험 결과를 Fig. 9, 10, 11에 나타내었다. 각각의 부하는 최소 외부부하(class1), 중간 외부부하(class2) 및 최대 외부부하(class3)에 대한 것이다. 이 그림에서 근육 1과2의 매니플레이터 회전각과 제어 입력, 압력과 출력을 각각 나타내고 있다.

실험 결과로부터 외부부하는 클래스에 대해 거의 정확하게 인지하는 것을 알 수 있었고, 위치제어는 1도의 정상상태 오차가 발생하는 것을 알 수 있었다. 그러므로 제어 파라미터는 외부부하에 따라 적절히 조절되어야 한다. 다시 말해 LVQNN의 신경 분류기는 외부부하의 변화를 인식하는데 필요하다. 또한 5kg과 10kg의 두 개의 다른 부하를 비교해 보면 LVQNN를 사용하는 것과 하지 않는 경우를 Fig. 12와 Fig. 13에 나타내었다. 제안된 알고리즘은 외부부하가 변한다 할지라도 공압 근육을 사용하는 매니

플래이더의 정확한 위치제어에 효과적인 제어성능을 가지는 것을 알 수 있다.




Fig. 9 Experiment results when external load is 0Kg




Fig. 10 Experiment results when external load is 5Kg




Fig. 11 Experiment results when external load is 10Kg




Fig. 12 Comparison of experiment results with and without the LVQNN in case 5Kg




Fig. 13 Comparison of experiment results with and without the LVQNN in case 10Kg

5. 결 론

본 고에서는 공압 매니플레이터에 대하여 실제적인 로딩/언로딩 작업에 사용될 수 있는 단순 구조의 공압 액추에이터 매니플레이터(PAM)의 제어기 개발에 대하여 해설하였다.

또한 본 고에서는 공압 매니플레이터의 외부부하에 상관없이 항상 일정한 제어 성능을 얻기 위하여, LVQNN을 이용하여 외부부하 상태를 구분하여 제어 파라미터를 자동적으로 스위칭하는 알고리즘을 적용하였다. 3가지 외부부하의 조건에서의 공압 매니플레이터의 위치제어 실험 결과, 제안한 LVQNN에 의한 스위칭 알고리즘이 실제 현장에 적용될 공압 매니플레이터도 유효함을 나타내었다. 끝으로 여전히 매니플레이터의 큰 관성과 작은 댐핑 때문에 약간의 오버슈트를 가진다. 이 문제점을 해결하기 위해 매니플레이터에 반응동 감쇠기를 추가하여 성능을 개선한 연구에 대해서는 차후에 해설할 예정이다.

후 기

이 연구는 한국학술진흥재단, 2단계 BK21 사업의 지원을 받았음.

참고 문헌

- 1) D. W. Repperger, K. R. Johnson and C. A. Phillips, "Nonlinear feedback controller design of a pneumatic muscle actuator system" Proc American control conference, 3, pp.1525~1529, 1999.
- 2) D. G. Caldwell, A. Razak and M. J. Goodwin, "Braided Pneumatic Muscle Actuator", IFAC Conf. on Int. Autonomous Vehicles, Southampton, UK, 1993.
- 3) R. W. Colbrunn, G. M. Nelson and R. D. Quinn, "Modeling of Braid Pneumatic Actuators for Robotic Control", In Proc. IEEE, Int. Conf. on Intelligent robots and systems, pp. 964~1970, 2001.
- 4) G. A. Medrano-Cerda, C. J. Bowler and D. G. Caldwell. "Adaptive Position Control of Antagonistic Pneumatic Muscle Actuators", In IEEE, Int. Journal, pp. 378~383, 1995.
- 5) T. Hesselroth, K. Sarkar, P. van der Smagt and K. Schulten, "Neuron Network Control of a Pneumatic Robot Arm", In IEEE Trans. On Systems, Vol. 24, No. 1, pp. 28~38, 1994.
- 6) P. van der Smagt, P. Groen and F. Schulten, "Analysis and control of a Rubbertuator arm", Biol. Cybernetics, Vol. 75, pp. 433~440, 1996.
- 7) D. G. Caldwell, T. agarakis, G. A. Medrano-Cerda and S. J. Brown, "Development of a Pneumatic Muscle Actuator driven Manipulator Rig for Nuclear Waste Retrieval Operations", Proc. IEEE, Int. Conf. on Robotics & Automation, pp. 525~530, 1999.
- 8) N. Tsagarakis, D. G. Caldwell and G. A. Medrano-Cerda, "A 7 DOF pneumatic muscle actuator (PMA) powered exoskeleton", IEEE International Workshop on Robot and Human Interaction, Pisa, Italy, pp. 327~333, 1999
- 9) S. W. Chan, H. L. John, D. W. Repperger and J. E. Berlin, "Fuzzy PD+I Learning Control for a Pneumatic Muscle", IEEE Int. Conf. on Fuzzy Systems, pp. 278~283, 2003.
- 10) K. Osuka, T. Kimura and T. Ono, " H^∞ control of a certain nonlinear actuator", Proc. IEEE Int. Conf., Decision and Control, Honolulu, Hawaii, Vol. 1 pp. 370~371, 1990
- 11) K. Balasubramanian and K. S. Rattan, "Fuzzy Logic Control of a Pneumatic Muscle System Using a Linearizing Control Scheme", IEEE, Int. Journal, pp. 432~436, 2003

[저자 소개]

안경관(책임저자)



E-mail : kkahn@ulsan.ac.kr

Tel : 052-259-2282

1966년 12월 16일생

1990년 서울대학교 기계공학과 졸업, 1992

년 한국과학기술원 기계공학과 석사 졸업,

1999년 동경공업대학 정밀 기계시스템 박사

졸업, 2000년 울산대학교 기계자동차공

학부 조교수, 2004년 동대학 부교수, 2007년 동대학 교수, 유
공압 시스템의 지능제어, 에너지 회생을 위한 유압시스템 및
기능성 유체를 이용한 새로운 액추에이터 연구에 중사, 유공
압시스템 학회 총무이사, 대한기계학회, 한국정밀공학회, 제
어자동화시스템공학회, IEEE, AMSE, JSME, 일본유공압학
회, 일본계측자동제어학회, 일본로봇 학회 등의 정회원

[저자 소개]

윤홍수



E-mail : floodyoon@hanmail.net

Tel : 052-259-1432

1981년 4월 25일생

2007년 울산대학교 기계자동차공학부 학

사 졸업 동대학원 석사과정 재학 중, 연구

분야는 유공압 시스템의 지능제어, 에너지

회생을 위한 유압 시스템 및 하이브리드

굴삭기 개발, 제어자동화시스템공학회 학생회원