

리커런트 신경회로망을 이용한 공압 로드레스 실린더의 정밀위치제어

노철하*, 김영식#, 김상희**

The Precision Position Control of the Pneumatic Rodless Cylinder Using Recurrent Neural Networks

Cheol-Ha Roh*, Yeung-Shik Kim#, Yeung-Shik Kim**

ABSTRACT

This paper develops a control method that is composed of the proportional control algorithm and the learning algorithm based on the recurrent neural networks (RNN) for the position control of a pneumatic rodless cylinder. The proportional control algorithm is suggested for the modeled pneumatic system, which is obtained easily simplifying the system, and the RNN is suggested for the compensation of the modeling errors and uncertainties of the pneumatic system. In the proportional control, two zones are suggested in the phase plane. One is the transient zone for the smooth tracking and the other is the small movement zone for the accurate position control with eliminating the stick-slip phenomenon. The RNN is connected in parallel with the proportional control for the compensation of modeling errors and frictions, compressibilities, and parameter uncertainties in the pneumatic control system. This paper experimentally verifies the feasibility of the proposed control algorithm for such pneumatic systems.

Key Words: recurrent neural networks, stick-slip, pneumatic rodless cylinder, proportional control algorithm

1. 서론

최근 자동화 추세에 맞게 급성장하고 있는 위치제어 시스템 중에는 전기식, 유압식 및 공압식 등으로 구분할 수 있다. 공압식 위치제어 시스템은 유압식에 비해 유지보수가 간편하고 작업환경이 청결하며 소음이나 진동이 적고 장치비용이 저렴하다는 이점을 가지고 있고, 또한 전기식에 비해서는 높은 출력을 낼 수 있으며 요구조건이 직

선 운동일 경우에는 전기식의 회전운동을 직선운동으로 전환하는데 소요되는 에너지 손실을 줄일 수 있으며, 무엇보다도 성능 및 비용이 아주 우수하다는 점이다. 하지만, 공압의 위치제어 시스템에서 정밀 위치제어가 용이하지 못한 이유는 작동유체인 공기의 압축성과 마찰 등으로 인한 비선형성 때문이다. 특히 기준점 가까이에 도달하였을 때 피스톤은 정지상태에 근접하게 되어 정지-미끄럼(stick-slip)현상이 발생하게 된다. 이런 현상에

** 접수일: 2002년 11월 6일; 게재승인일: 2003년 4월 15일

* 금오공과대학교 기전공학과 대학원

교신저자: 금오공과대학교 기계공학부

Email: yskim@kumoh.ac.kr, Tel: (054) 467-4217

** 금오공과대학교 전자공학부

대한 정확한 모델을 얻기가 매우 어려우며, 이는 제어 성능을 저하시키는 요인이 된다. 이러한 제어 한계를 극복하기 위한 인공 신경회로망(ANN: Artificial Neural Networks) 및 여러 제어 알고리즘에 대한 연구가 활발히 진행되었으나 아직 만족할 만한 결과를 얻지 못하였다.

본 논문에서는 공압 시스템의 수학적 모델은 매우 복잡하나 시스템을 간단화 한 수학적 모델은 쉽게 얻을 수 있다는 이점으로부터 비례 제어기를 개발하였고, 시스템의 모델오차와 불확실성등으로 인한 비례 제어기의 미비점을 보완하기 위하여 리커런트 신경회로망(RNN: Recurrent Neural Networks)을 개발하고자 한다. 개발된 두 제어 알고리즘을 병렬로 연결하여 공압시스템 제어 시 미비점을 상호 보완하고자 하며, 그 타당성을 실험을 통하여 검증하고자 한다.¹⁻⁵

2. 공압 시스템 모델링

공압 시스템의 수학적 모델은 실린더내의 공기가 이상기체이며 등엔트로피 과정으로 가정하여 질량, 모멘텀, 에너지보존 방정식들과 피스톤의 운동방정식으로부터 얻을 수 있다. 그러나 피스톤에 공급되는 압력은 질량, 모멘텀, 에너지보존 방정식들로부터 얻을 수 있지만, 이는 서보밸브의 입력 전압과 압력과의 상관관계로부터 얻을 수 있다는 가정으로부터 복잡한 관계식을 간단화 할 수 있다. 이러한 수학적 모델은 쉽게 얻을 수 있고 계산식이 간단하다는 이점이 있으며 모델링과정에서 발생한 모델오차는 리커런트 신경회로망의 제어알고리즘으로 보완하고자 하였으며, 간단화한 로드레스 실린더의 운동 방정식은 다음과 같이 하였다.

$$M\ddot{x}(t) = F_f(t) + u(t) \tag{1}$$

여기서, M 은 피스톤, 이송부 및 외부 하중을 합한 질량이고, $u(t)$ 는 제어입력이며 다음과 같이 표시된다.

$$u(t) = A_p[P_1(t) - P_2(t)] \tag{2}$$

여기서, A_p 는 피스톤 단면적이며, P_1 과 P_2 는 피스톤 양면에서의 공기압이며 전압과의 관계식으로 부터 결정된다. F_f 는 정지 마찰력(Static Friction)

으로 다음과 같이 가정하였다.

$$F_f = F_0 \operatorname{sgn}(\dot{x}) \tag{3}$$

$$\operatorname{sgn}(\dot{x}) = \begin{cases} 1 & \text{if } \dot{x} > 0 \\ -1 & \text{if } \dot{x} < 0 \end{cases}$$

F_0 는 피스톤이 움직이기 시작하는 순간 최대 정지 마찰력이다.

3. 제어 이론

공압 시스템의 수학적 모델에 기초한 비례 제어기를 개발하였고, 시스템의 모델오차와 불확실성등으로 인한 비례 제어기의 미비점을 보완하기 위하여 신경회로망을 개발하였다. 비례 제어기는 공압 시스템의 위치제어를 위하여 과도영역과 미소 이동영역으로⁶ 구분하여 각 영역에 맞는 제어를 제시하였다.

3.1 비례제어기

비례제어기는 공압 시스템의 수학적 모델로부터 피스톤이 매끄럽게, 즉 요동 없이 기준위치에 도달하기 위하여 개발되었으며, Fig. 1 에 보여주는 바와 같이 미소이동영역과 과도영역으로 구분하였다. 미소이동영역(Small Movement Zone)은 기준점 부근에서의 영역을 나타내며 과도영역(Transient Zone)은 시작점에서 미소이동영역 전까지의 영역을 나타낸다.

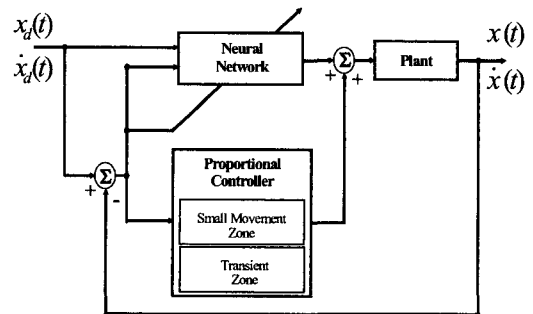


Fig. 1 Block diagram for the position control of the rodless cylinder

3.1.1 과도영역

과도영역은 시작점부터 미소이동영역의 시작

점인 경계영역까지 정의하였다. 피스톤이 기준경로를 따라 경계영역에 도달하기 위한 제어력은 피스톤 양측 압력차($P_1 - P_2$)에 비례하지만 압력차($P_1 - P_2$)를 얻는 방법은 P_1 또는 P_2 을 어떻게 결정하는가에 따라 무수히 많지만 실린더 입구측 압력 P_1 을 P_{max} 로 하고 P_2 압력을 조절하여 압력차를 결정하였다. P_1 의 압력을 P_{max} 로 한 이유는 높은 압력하에서 실린더 내 공기의 비선형성을 줄일 수 있기 때문이다. 공압 시스템의 운동방정식인 식(1)로부터 P_2 의 압력을 다음과 같이 설정하였다.

$$P_2 = P_c - k_p(x_i - x(t)) \quad \text{단, } 0 \leq x(t) < x_i \quad (4)$$

여기서,

- P_c : 미소이동제어를 시작하는 경계점에서의 압력
- k_p : 비례제어의 게인 값
- x_i : 경계영역까지의 변위

이송 도중 과도영역에서 미소이동영역으로 전환하는 과정에서 급격한 압력변화를 최소화하기 위해, 비례제어의 게인 값을 다음과 같이 설정하였다.

$$k_p = \frac{P_c - P_{min}}{x_i} \quad (5)$$

여기서, P_{min} 은 마찰력을 극복하기 위한 최소의 압력이다.

3.1.2 미소이동 영역

기존 알고리즘에 의한 위치제어는 공압 실린더가 기준점 부근에 도달하였을 때 피스톤의 속도가 매우 작아지게 되며, 이 때 정지 미끄럼(Stick-slip)현상이 발생하여 정밀위치제어가 힘들게 된다. 본 논문에서는 미소이동 영역을 설정하여 피스톤이 안정하게 기준점에 도달할 수 있도록 제어입력을 결정하였다. 피스톤의 이동은 피스톤 양단의 압력 차에 의해 결정되지만 입구측 압력을 최대한 상황에서 피스톤 출구측 압력을 변화하여 피스톤을 이동할 경우에 최소 이동을 얻을 수 있었다.⁶ 이것에 기초로 하여 미소이동 영역에서의 제어입력은 기초 실험을 통하여 압력 차와 미소이동 변화량과의 관계를 파악하여 설정하였다. 결정된 제어입력은 전압과 압력의 관계식에 의하여 전압

으로 환산된 값을 이용하여 표기하면 다음과 같이 쓸 수 있다.

$$P_2 = P_c + \frac{(P_{max} - P_c)}{X_d - x_i}(x(t) - x_i) \quad (6)$$

단, $x_i \leq x(t) \leq X_d$

여기서, X_d 는 기준 변위이다.

3.2 신경회로망 제어 이론

현재 가장 기본적이며 많이 사용되는 신경회로망의 구조인 FNN(Feedforward Neural Networks)에 적용되는 대표적인 학습 규칙이 Rumelhart에 의해 제안되었다. 단일 입출력(Single Input Single Output)의 시스템에 적용된 시간 지연 신경회로망(Time Delay Neural Networks)은 실제 제어할 시스템이 다중 입출력(Multi Input Multi Output)이라는 문제뿐만 아니라, 시간에 따라 시스템의 특성이 변화하는 동적 시스템 제어에 있어서 한계를 가진다. 따라서 동적 시변 시스템의 제어를 위한 새로운 구조의 신경회로망 제어를 요구하게 되었다. Elman과 Jordan은 동적시스템에서 케환제어가 가능하다는 것을 응용한 내부케환루프를 새로운 구조의 신경회로망으로 제안하였다. 이러한 내부케환루프를 가지는 신경회로망 구조를 리커런트 신경회로망(RNN: Recurrent Neural Networks)이라 부른다. 최근 RNN 학습 알고리즘의 개발에 관심의 초점이 모아지고 있다. RNN은 FNN에서는 없는 attractor dynamics과 케환에 사용할 정보 저장 능력 등 중요한 능력을 가지고 있다는 점에서 많은 호응을 얻었다. Jordan 모델은 지연된 신경회로망의 출력이 은닉층(hidden layer)으로 케환되는 구조를 가진다. 출력에서의 케환은 비용함수(cost function)가 신경회로망의 출력단에서 나타난다는 장점을 충분히 고려하여 이 오차를 다시 케환함으로써 동적 제어 시스템을 더욱 효율적으로 제어할 수 있다.⁷ 반면, Elman은 은닉층 뉴런의 지연된 값이 자신에게로 케환되는 자기 케환 경로를 설정하였다. 이 구조는 각 유닛이 지연된 유닛 출력을 입력으로 가짐으로써 제어 시스템의 복잡성을 충분히 추정할 수 있다는 장점을 가진다. Kuan⁸은 은닉층에서의 케환과 출력 층에서의 케환을 가지는 신경회로망에 대한 확장된 BP(Back-Propagation) 알고

리즘의 수렴성에 대하여 고찰하였다. 한편, Narendra⁹는 인공 신경회로망을 이용한 제어 알고리즘을 제안하고 이에 대한 모의실험을 정리하였다. 그는 신경회로망을 이용한 제어를 직접 제어와 간접 제어로 구분하고 이에 대하여 각각 고찰하였다. 직접 제어는 제어 대상의 입력 부분에 직접 신경회로망을 뭉으로써 제어 요소를 조절하도록 하였으나 안정성 문제를 가지고 있다. 또한 간접 제어 기법은 제어 대상을 모사할 추가적인 신경회로망을 요구하므로 안정성의 문제는 없지만 실시간 처리의 어려움을 가진다. 따라서 신경회로망을 단독적으로 사용하는 것 보다는 비례 제어기와 동시에 사용하여 그 문제점을 보완하는 보상기로 사용하는 것이 일반적이다. 따라서 본 논문에서도 미소이동법이라는 비례 제어기를 신경회로망을 이용하여 그 문제점을 보완하였다.

3.2.1 리커런트 신경회로망의 설계 및 구조

하나의 은닉 층을 가지는 RNN의 구조는 Fig. 2와 같다. 다중 입출력 시스템의 동특성 시험 모델을 구현하기 위해 사용된 RNN의 구조는 바이어스 유닛 $z_0(k)$ 1개와 주어진 시스템의 입력 $x(k)$ n 개, 은닉 층으로부터의 케환되는 입력 L_0 개를 합하여 모두 $L_0 + n + 1$ 개이다. 한편, 은닉 층의 유닛 수를 N , 이 중 출력 층으로부터 케환되는 케환 유닛의 수를 L_1 이라 하면, 은닉 층 유닛의 총수는 $N + L_1$ 이다. 그리고 출력 유닛의 개수는 m 개로 구성된다. 여기서, 케환되는 유닛의 수에 따라 신경회로망을 부분케환 신경회로망(Partially Recursive Neural Network)과 전케환 신경회로망(Fully Recursive Neural Network)으로 구분된다. 부분적으로 케환하는 신경회로망은 $L < N$ 관계를 가지며 또한 은닉 층의 모든 유닛이 입력 층으로, 출력 층의 모든 유닛이 은닉 층으로 케환되는 신경회로망은 $L = N$ 의 관계를 가진다.

각 학습 입력에 대한 은닉 층의 출력 $h_i(k)$ 는 다음과 같이 나타낼 수 있다.

$$h_i(k) = \frac{1}{1 + \exp(-I_{ij}(k)/s_i)}, \quad i = 0, 1, \dots, N + L_1 - 1, j = 0, 1, \dots, L - 1 \quad (7)$$

신경회로망의 최종 출력 $y(k)$ 는 다음과 같다.

$$y(k) = \sum_{i=0}^{N+L_1-1} w_{mi}(k) \cdot h_i(k), \quad m = 0 \quad (8)$$

여기서, $w_{mi}(k)$ 는 은닉 층과 출력 층 사이의 연결강도이고, $h_i(k)$ 는 은닉 층의 출력을 의미한다.




Fig. 2 RNN structure of the multi-input multi-output system

3.2.2 리커런트 신경회로망의 학습 법칙

Fig. 2의 RNN에서 각각의 연결강도에 대한 학습법칙은 일반적으로 오차 BP 학습알고리즘(learning algorithm)을 사용한다. 출력 층의 오차 함수 $J(k)$ 를 원하는 출력 $y(k)$ 와 신경회로망의 실제 출력 $\hat{y}(k)$ 와의 차이로 다음과 같이 정의한다.

$$J(k) = \frac{1}{2} [y(k) - \hat{y}(k)]^2 \quad (9)$$

따라서, 오차함수 $J(k)$ 에 대한 은닉 층과 입력 층 간의 음의 변화율은 다음과 같다.

$$-\frac{\partial J(k)}{\partial w_{ij}(k)} = [y(k) - \hat{y}(k)] \cdot w_{mi}(k) \cdot \delta h_i(k) \cdot z_j(k) \quad (10)$$

위에서 식을 정리하여 각 신경회로망의 연결강도는 식(11),(12)을 사용하여 갱신(updating)된다.

먼저 출력 층과 은닉 층 사이의 연결강도는

$$w_{mi}(k+1) = w_{mi}(k) - \eta \cdot \frac{\partial J(k)}{\partial w_{mi}(k)} + \alpha \cdot \Delta w_{mi}(k-1) \quad (11)$$

이며, 은닉 층과 입력 층 사이의 연결강도는

$$w_{ij}(k+1) = w_{ij}(k) - \eta \cdot \frac{\partial J(k)}{\partial w_{ij}(k)} + \alpha \cdot \Delta w_{ij}(k-1) \quad (12)$$

이다. 여기서, $w_{mi}(k)$ 와 $w_{ij}(k)$ 는 갱신되기 이전의 연결강도, $w_{mi}(k+1)$ 와 $w_{ij}(k+1)$ 는 학습에 의해 갱신된 연결강도이고, $-\frac{\partial J(k)}{\partial w_{mi}(k)}$ 와 $-\frac{\partial J(k)}{\partial w_{ij}(k)}$ 는 오차 함수를 각 층 사이의 연결강도에 대하여 편미분한 것이며,

$$w_{mi}(k+1) = w_{mi}(k) - \eta \cdot \frac{\partial J(k)}{\partial w_{mi}(k)} + \alpha \cdot \Delta w_{mi}(k-1) \text{ 와}$$

$$w_{ij}(k+1) = w_{ij}(k) - \eta \cdot \frac{\partial J(k)}{\partial w_{ij}(k)} + \alpha \cdot \Delta w_{ij}(k-1) \text{ 는}$$

연결강도의 이전의 변화량을 의미한다. η 는 신경회로망의 학습률(learning rate), α 는 신경회로망의 모멘텀률(momentum rate)을 나타낸다. 위의 학습법칙은 기존의 오차 BP 알고리즘에 계환 특성이 추가된 반복 공식 형태를 갖는다. 일반적으로 RNN 은 계환이 추가됨에 따라 신경회로망의 크기가 커져 메모리 용량이 증가하기 때문에 학습에 보다 많은 시간이 소요되는 경향이 있으나, 기존의 다층 신경회로망이 시스템에 대한 동특성 구현에 있어서의 한계를 해결해 주는 장점이 있다.¹⁰⁻¹²

4. 실험 결과

4.1 실험장치의 구성

Fig. 3 은 실험장치의 전체적인 구성을 나타내며, Fig. 4 는 실험 장치의 회로도로서 다음과 같다. 에어 유닛(air unit) 전압 비례 밸브, 에어 조정기, 로드레스 실린더, 리니어 엔코더(linear encode), 파워 앰프(power amp.), 고속 카운터, 교류전원 공급장치(power supply), D/A 변환기, 압력센서, 586 컴퓨터로 구성되었다. 로드레스 실린더는 직경이 40mm 이고 행정은 2000mm 이다. 그리고 변위를 측정하기 위해 1 회전에 2000 펄스를 발생시키는 엔코더와 타이밍 벨트와 풀리를 사용하여 0.1mm 까지 측정 가능하도록 하였으며, 고속 카운터기를 사용하여 이동 시 발생하는 펄스를 카운팅하여 빠른 속도에서의 위치 검출장치를 범용으로 사용할 수 있도록 개발하였다. 제어기법에 의해 계산된

입력 전압은 0 ~ 4.9V 범위에 있으며, 본 연구에서는 안정성을 고려하여 최고 전압 4V 로 하였다.



Fig. 3 Close-up fixture of the pneumatic control system

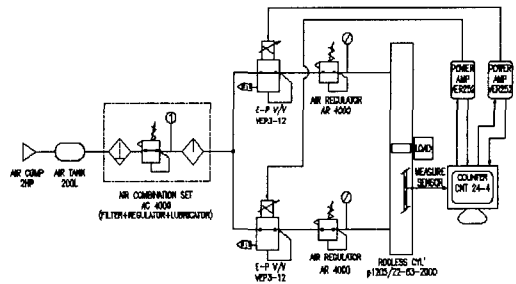


Fig. 4 Schematic diagram of the pneumatic servo system

4.2 실험방법

신경망의 추적제측은 기초실험을 토대로 설정하였으며, Fig. 5 는 기준거리 1m 에 대한 추적제측을 나타낸 것으로 피스톤이 기준변위 (X_d) 까지 이동하는데 걸리는 시간을 다음과 같이 하였다.

$$T_{desire} = T_{target} + T_{delay} \quad (13)$$

여기서, T_{target} 은 시간지연 (T_{delay}) 을 제외한 순수 이동 시간이다. T_{target} 는 피스톤이 움직이기 시작하는 시점에서 시간과 변위의 관계를 선형화 한 식으로부터 다음과 같이 설정하였다.

$$\left. \begin{aligned} T_{target} &= 0.549 + 1.16X_d \\ T_{delay} &= 0.24[\text{sec}] \end{aligned} \right\} \quad (14)$$

한편, 추적 변위와 추적 속도는 다음과 같이 하였다.

$$x_d(t) = \frac{X_d}{2} \left(1 - \cos \frac{\pi}{T_{target}} t\right) \quad (15)$$

$$\dot{x}_d(t) = \frac{X_d \pi}{2T_{target}} \sin \frac{\pi}{T_{target}} t \quad (16)$$

식(14)에서 기준변위에 따른 T_{target} 의 변화는 이동속도의 변화를 의미하며 이동구간이 짧을수록 이동속도가 느려지고 구간이 길어질수록 이동속도가 빨라진다.

이동속도가 빨라지는 이유는 과도영역이 상대적으로 미소이동영역보다 크기 때문이다.




Fig. 5 Example of desire point 1 [m]

4.3 실험결과

Fig. 6 ~ Fig. 8 은 실린더의 기준 구간별 실험 결과이며, 좌측 Y 축은 변위이고 우측 Y 축은 출구측 밸브의 입력 전압이다. 처음 시작 시 입구측 (챔버 1) 서보밸브의 인가전압 v_1 과 출구측 (챔버 2) 서보밸브의 인가전압 v_2 는 동일한 4v ($5.7 \text{ kg}_f/\text{cm}^2$)을 가하여 출구측 서보밸브의 인가전압을 조절하여 기준위치에 도달하도록 하였다.

각 그림에서 입력 전압의 변화로부터 과도영역과 미소이동 영역을 확인할 수 있다. 이 때 미소이동영역에서의 전압은 0.1m 인 경우(Fig. 6) 가 0.5m 인 경우(Fig. 7) 보다 낮으며 그 이유는 과도영역에서의 속도가 느리기 때문이다. 하지만, 다시 기준거리가 증가하면 전압이 낮아지는 것을 알 수 있는데, 그것은 과도영역에서의 속도는 빨라지지만, 반대로 이동거리가 증가할 수록 출구측에 가까워 배압이 실린더에 작용하기 때문이다. 각 구

간별로 오버슈트(overshoot)가 없으며, $\pm 1 \text{ mm}$ 허용 오차 범위 내에서 정밀위치제어가 가능하다는 것을 볼 수 있다.




Fig. 6 Displacement and input voltage of the cylinder for $X_d = 0.1$ [m] start from 0[m]




Fig. 7 Displacement and input voltage of the cylinder for $X_d = 0.5$ [m] start from 0[m]




Fig. 8 Displacement and input voltage of the cylinder for $X_d = 2$ [m] start from 0[m]

Fig. 9 는 이동목표 1m 를 200 회 학습하는 과정에서 오차를 나타낸 것이며 학습을 시작함과 동시에 오차가 감소하는 것을 확인할 수 있었다. 횟수 50 회 이상부터는 목표치를 일정하게 만족시킨다.

실제 연속 100 회를 학습하면서 챔버 입구측의 순간 압력강하로 인하여 온도가 현저하게 떨어짐을 볼 수 있었고, 이런 효과로 마찰력증가와 함께 비선형성도 증대된다. 하지만, 신경회로망에서 보완하여 제어가 됨으로 Fig. 9 와 같이 만족할 만한 제어성능을 얻을 수 있었다.




Fig. 9 Error vs. iteration in the learning process of the RNN for $X_d = 1[m]$

5. 결론

본 연구에서는 공압 시스템의 단순 모델에 기초로 한 비례 제어기와 이의 미비점을 보완하기 위해 제안한 신경회로망을 병렬로 연결하여 학습 시킴으로써 정밀위치제어가 가능하다는 것을 확인하였으며 다음과 같은 결론을 얻었다.

제안된 병렬 신경회로망 제어기는 온라인으로 학습되어 시스템의 지속적인 운전으로 인한 챔버 입구측의 온도저하, 공기의 압축성, 비선형성 및 불확실성에도 멈춤 현상이나 오버슈트 없이 정밀 위치제어가 가능함을 보였으며, 비례 제어기의 도움으로 약 50 회 정도의 학습으로 최종위치 오차범위가 $\pm 0.5mm$ 를 유지하면서 지속적인 제어 성능을 얻을 수 있었다.

후 기

이 논문은 2001 년도 금오공과대학교 일반공모 과제의 연구비에 의하여 연구되었음.

참고문헌

1. Shearer, J. L., "Study of Pneumatic Processes in The Continuous Control of Motion with Compressed Air,

I, II," Trans. of the ASME, pp. 233-249, Feb. 1956.
 2. Burrow, C. R., "Effect of Position on The Stability of Pneumatic Servomechanism," J. Mech. Eng. Sci., Vol. 11, No. 6, pp. 615-616, 1969.
 3. Eun, T., Cho, Y. J. and Cho, H. S., "Stability and Positioning Accuracy of a Pneumatic On-off Servomechanisms," Proceedings of American Control Conference, June 1982.
 4. Choi, S. H., Hong, Y. S. and Lee, C. O., "A Study on the Position Control and Simulation of Pneumatic Servo System," Journal of the Korean Society of Precision Engineering, Vol. 13, No. 6, 1996.
 5. Lin, X., "Modeling and Test of an Electropneumatic Servovalve Controlled Long Rodless Actuator," ASME, J. of Dynamic Systems, Measurement and Control, Vol. 118, pp. 457-467, 1996.
 6. Kim, Y. S. and Roh, C. H., "Development of the Small-displacement-movement of a Pneumatic Piston and the Hybrid Control Algorithm for Precision Position Control," Journal of the Korean Society of Precision Engineering, Vol. 18, No. 7, pp. 40-45, 2001.
 7. Williams, R. J. and Zipser, D., "A Learning Algorithm for Continually Running Fully Recurrent Neural Networks," Neural Computation Vol. 1, pp. 270-280, 1989.
 8. Kuan, C. M., Hornik, K. and White H., "A Convergence Result for Learning in Recurrent Neural Networks," Neural Computation, Vol. 1, pp. 420-440, 1993.
 9. Narendra, K. S. and Parthasarathy, K., "Identification and Control of Dynamical Systems Using Neural Networks," IEEE Trans. Neural Networks, Vol. 1, No. 1, pp. 4-27, Mar. 1990.
 10. Matsukuma, T. and Fujiwara, A., "Non-Linear PID Controller Using Neural Networks," IEEE Trans. Neural Networks, Vol. 2, No. 1, pp. 811-814, Jun 1997.
 11. Narendra, K. S., "Neural Networks for Control: Theory and Practice," IEEE, Vol. 84, No. 10, pp. 1385-1406, Oct. 1996.
 12. Williams, R. J. and Jing Peng, "An Efficient Gradient-Based Algorithm for On-Line Training of Recurrent Network Trajectories," Neural Computation, Vol. 2, pp. 490-501, 1990.