

신경회로망을 이용한 예측 PID 제어기에 관한 연구

윤광호*, 조현철**, 김정자***, 이권순****

*부산전자공업고등학교, **동아대 RRC,

동아대 산업시스템공학과, *동아대 전기공학과

A Study on Predictive PID Controller using Neural Network

Yoon Kwang Ho*, Cho Hyun Cheol**, Kim Jung Ja***, Lee Kwon soon****

*Pusan electronic technical high school, **RRC, Dong-A Univ.

***Dept. of Industrial & systems Eng., Dong-A Univ.

****Dept. of Electrical Eng., Dong-A Univ.

Abstract

In this paper predictive PID control system using neural network (NNPPID) is proposed to control temperature system. NNPPID is composed of neural network predictor, PID controller and neural network self-tuner. Neural predictor forecasts the future output of plant based on the present input and output of plant. Neural self-tuner yields parameters of PID controller. Experiments prove that NNPPID temperature control system has better performances than conventional PID control.

1. 서론

현대 제어이론의 눈부신 발전으로 인해 여러 가지 제어이론들이 발표되고 있으나, 산업현장에서는 아직까지 PID(Proportional Integral Derivative) 제어기가 많이 이용되고 있다. PID 제어기에서 중요한 것은 제어기의 파라미터값을 주어진 플랜트에 대해 가장 적절한 값으로 동조(tuning)하는 것이며, 일반적으로 산업현장에서는 숙련된 기술자의

경험과 노하우를 바탕으로 이루어지고 있다. 그러나, 플랜트의 동특성(dynamics)이 변화하거나 환경적 외란이 인가하는 경우에는 이 값을 다시 동조해야 원하는 제어성능을 얻을 수 있다[1]. 따라서, 제어기에 적응성을 갖는 적응제어에 대한 연구가 많이 이루어지고 있다. 적응제어는 Åström의 자기동조(self-tuning)를 시초로 하여 그 이후 많은 연구가 발표되었으며, 최근에는 신경회로망, 퍼지이론, 그리고 유전알고리즘 등의 지능 알고리즘을 제

어이론에 적용하는 방식을 많이 채택하고 있다.

특히, 신경회로망은 인간의 두뇌 및 신경구조모델을 본 따서 구성한 것으로서 복잡하고 광대한 정보량을 적절하고 유효하게 처리할 뿐만 아니라, 미지의 구조를 학습(learning) 및 훈련(training)을 통해 정확하게 제어할 수 있는 특징을 가진다[2].

본 논문에서는 지능형 알고리즘의 하나인 신경회로망을 이용하여 예측 PID 제어시스템을 구성한다. 신경회로망은 예측기와 자기동조기로 이용되었으며, 제어기는 PID로 구성하였다. 제어대상은 백열전구를 이용한 온도시스템을 구성하여 실시간으로 온도제어를 실시하였다. 그리고, 기존의 온도제어기와 비교분석을 하여 본 논문에서 구성한 제어기의 성능을 검증해 보고자 한다.

2. 신경회로망 예측 PID 제어시스템

본 논문에서 제안하는 신경회로망 예측 PID(NNPPID) 제어시스템은 그림 1과 같다. 시스템의 구성은 신경회로망 예측기와 PID 제어기 그리고 PID의 파라미터를 산출하는 신경회로망 자기동조기로 구성된다.

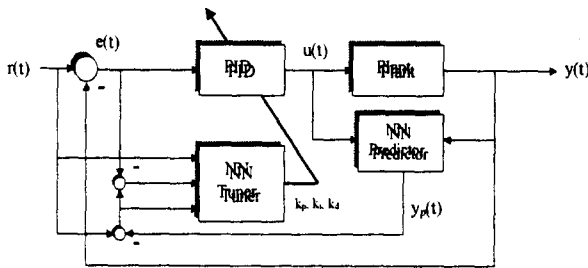


Fig. 1. Neural network predictive PID control system.

신경회로망 예측기는 플랜트의 현재 입출력을 바탕으로 플랜트의 출력을 예측한다. 신경회로망 예측기가 구성되기 전 신경회로망은 플랜트에 대한 모델링이 이루어져야 한다[3]. 신경회로망 모델

링은 그림 2와 같이 플랜트에 인가되는 입력을 신경회로망에 동일 입력으로 하여 플랜트와 동일한 출력이 나오도록 주어진 학습법으로 신경회로망을 학습시키는 것을 말한다.

신경회로망 모델이 플랜트의 동특성을 충분히 내포할 수 있도록 학습이 완료되면 신경회로망 모델은 플랜트에 대한 가상 플랜트로 간주할 수 있다. 그리고, 이 신경회로망 모델에 플랜트의 현재 입출력을 인가하여 다음 단계에 산출될 플랜트의 출력을 미리 예측을 할 수 있다[4]. 그리고, 그림 3과 같이 예측기에서 산출된 예측출력을 피드백(feedback)하여 다시 예측기의 입력정보로 이용하는 다단계 예측기(multi-step predictor)의 구성도 가능하다.




Fig. 2. Neural network modeling.

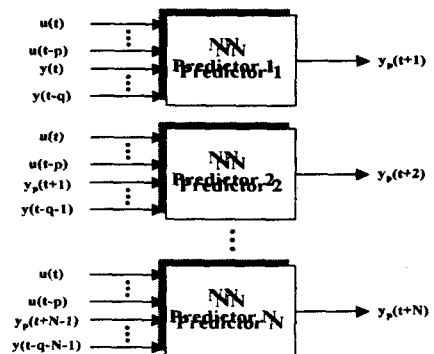


Fig. 3. Multi-step predictor.

예측기에서 산출한 예측출력은 플랜트의 현재 출력과 함께 신경회로망 자기동조기의 입력정보로

이용하여 PID 제어기의 파라미터값을 산출하게 된다. 그림 4와 같은 구조를 갖는 신경회로망 자기동조기의 입력으로는 예측출력과 설정치와의 오차, 예측오차와 현재오차에 대한 변화분 그리고 설정치로 하였으며, 출력은 PID의 파라미터를 산출하게 된다. PID는 식 (1)과 같은 속도형으로 하였다.

평가함수는 식 (2)와 같은 2차형 오차함수로 하였으며, 자기동조기는 이 오차함수를 줄이는 방향으로 학습하게 된다.

$$\Delta u(t) = k_p (e(t) - e(t-1)) + k_i e(t) + k_d (e(t) - 2e(t-1) + e(t-2)) \quad (1)$$

$$E = \frac{1}{2} [r(t) - y(t)]^2 \quad (2)$$




Fig. 4. Neural network self-tuner.

학습법은 오차 역전파법을 이용하였으며, 은닉층과 출력층 그리고 입력층과 은닉층 사이의 새로운 가중치의 변화량은 각각 식 (3)과 (4)와 같다.

$$\Delta W_{jk}(t) = -\eta \delta_k O_k + \alpha \Delta W_{jk}(t-1) \quad (3)$$

$$\Delta W_{ij}(t) = -\eta \delta_j O_j + \alpha \Delta W_{ij}(t-1) \quad (4)$$

여기서, η 는 학습율이며, α 는 모멘트계수를 나타낸다. $\Delta W_{jk}(t-1)$ 는 은닉층과 출력층 사이의 전회의 가중치의 변화량을 나타내며, $\Delta W_{ij}(t-1)$ 는 입

력층과 은닉층 사이의 전회의 가중치의 변화량을 나타낸다. 그리고, O_j 와 O_k 는 은닉층과 출력층의 출력을 각각 나타내며, 여기서 O_k 는 PID 제어기의 파라미터로써 다음과 같다.

$$O(1) = k_p = f(net_1) \quad (5)$$

$$O(2) = k_i = f(net_2) \quad (6)$$

$$O(3) = k_d = f(net_3) \quad (7)$$

여기서, f 는 활성화 함수를 나타낸다.

그리고, δ_k 와 δ_j 는 출력층과 은닉층의 각각에 대한 오차신호를 나타내며, 연쇄법칙(chain rule)을 적용하면 다음과 같이 나타낼 수 있다.

$$\delta_k = e(t) \frac{\partial y(t)}{\partial u(t)} f'(net_{jk}) \frac{\partial u(t)}{\partial O(k)} \quad (8)$$

$$\delta_j = \sum_k \delta_k W_{jk} f'(net_j) \quad (9)$$

여기서, $f'(\cdot)$ 은 활성화 함수에 대한 미분식을 나타낸다.

3. 컴퓨터 시뮬레이션

본 논문에서 구성한 NNPPID 제어기의 성능을 검토하기 위하여 우선 컴퓨터 시뮬레이션을 실시하였다. 플랜트는 시간지연을 갖는 온도시스템을 이용하였으며, 차분방정식은 식 (10)과 같다[5].

$$y(t) = 1.557y(t-1) - 0.576y(t-2) + 0.105u(t-3) + 0.087u(t-4) \quad (10)$$

NNPPID 제어기를 구성하는데 있어 모델링에 사용된 신경회로망은 3층 구조로 하였으며, 각 층에 대한 노드 수는 각각 3, 7, 1개로 하였다. 학습율과 모멘트 계수는 각각 0.005, 0.003으로 설정하였다. 각 층에 대한 연결강도의 초기값은 모두 0.1로 하였다. 학습법은 오차 역전파법을 이용하였으

며, 학습 오차범위는 0.001로 하였다. 모델링 학습에 적용된 학습패턴은 단위계단입력과 이 입력에 의해 나타나는 출력응답을 입출력 학습패턴으로 하였다. 예측기는 10단계로 구성하였으며, 예측시간은 2초로 하였다.

신경회로망 자기동조기도 3층 구조로 하였으며, 각 층에 대한 노드 수는 3, 5, 3개로 하였으며, 학습율과 모멘트 계수는 각각 0.003, 0.001로 하였다. 초기 연결강도는 -0.5~1 사이의 무작위 값으로 하였다. 학습법은 오차 역전파법으로 하였으며, 활성화 함수는 선형함수를 사용하였다.

신경회로망 자기동조기의 학습은 그림 5와 같이 설정치를 100[°C]로 하여 실시하였으며, 약 35초 부근에서 정상상태에 진입함으로써 이 부근에서 학습이 완료되었음을 알 수 있다.




Fig. 5. Neural network self-tuner learning.

그림 6과 7은 설정치를 100[°C]로 하였을 경우 일반 PID와 NNPPID 제어기의 입·출력을 나타낸다. 제어성능을 비교 분석해보면, 우선 오버슈트는 PID가 12.9%, NNPPID는 0.63%이며 상승시간은 PID의 경우는 1.4초이며 NNPPID는 1.9초이나, 정정시간은 PID가 6.7초이고 NNPPID는 3.9초로 나타났다. 이것은 PID의 제어입력이 초기에 과도하게 인가되었기에 상승시간이 보다 빠르고 정정시간이 느린 것으로 분석된다. 제어입력 양에서도 알 수 있듯이 제어초기에 최대제어입력을 산출하는데 그 값은 PID의 경우 18.48이고 NNPPID는 15.89로 나타났다. 그리고, 정상상태 편차는 두 가지의 경

우 거의 발생하지 않는 것으로 나타났다.




Fig. 6. PID control.

4. 온도 제어시스템

본 논문에서 구성한 NNPPID 제어기는 백열전구를 이용한 온도시스템을 구성하여 실시간으로 온도제어를 실험하였다. 실험에 사용된 온도 제어시스템의 블록선도는 그림 8과 같다.




Fig. 7. NNPPID control.

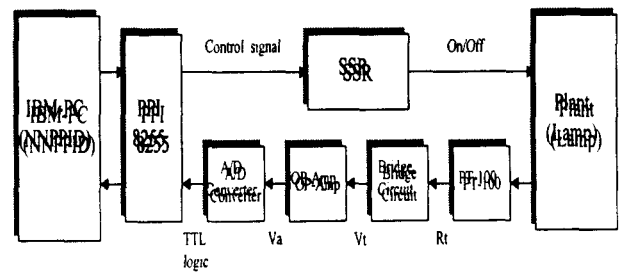


Fig. 8. Temperature control systems.

온도센서는 백금 측온 저항체 센서를 이용하였다. 백금 측온 저항체에서 검출된 저항값은 전압값으로 변환하기 위해 평형 브리지회로를 거치게 되

고 이 회로에서 검출된 전압은 매우 미세한 값이므로 11배의 증폭도를 갖는 비반전 증폭회로를 통해 전압을 증폭한다. 그리고, 검출전압은 아날로그 값이므로 신호변환기(signal converter)를 거쳐 디지털 값으로 변환되어 인터페이스(interface) 회로를 통해 PC의 NNPPID 제어프로그램에 인가된다. NNPPID 제어프로그램은 Borland C++ 3.0으로 프로그래밍을 하였다. 센서를 거쳐 인가된 출력전압은 설정치 온도에 해당되는 전압과의 오차를 바탕으로 NNPPID 제어기는 제어입력을 산출하며, 이 제어기의 출력은 액츄에이터(actuator)를 작동하게 되는 제어입력이 된다. 액츄에이터는 반도체를 이용한 무접점 릴레이인 SSR를 이용하였으며, 백열전구에 인가되는 전원을 온-오프(on-off) 스위칭 동작을 함으로서 제어동작이 이루어진다.

5. 실험결과 및 고찰

실험은 백열전구에 시험입력을 인가하여 백열전구의 입·출력 값을 획득한 후 오프-라인(off-line)으로 신경회로망 모델에 대한 학습을 먼저 해야 한다. 다음은 신경회로망 자기동조기에 대한 학습을 해야하며, 이것은 실시간 온-라인(on-line)으로 실시한다. 이 두 실험들이 완료되면 NNPPID 제어기를 구성할 수 있다.

기존의 PID 제어기와 특성을 비교 분석하기 위하여 현재 산업현장에서 많이 사용되고 국내 중소기업 A사 제품으로 PID 파라미터는 기술자가 임의로 설정할 수 있는 기능과 자동으로 동조할 수 있는 기능 두 가지가 있다. 실험에서는 이 두 가지 기능과 NNPPID와 응답출력에 대한 특성들을 비교 분석하였다. 제어시간은 500초로 하였으며, 설정치는 100℃로 하였다. 백열전구의 온도출력은 오실로스코프를 이용하여 전압으로 나타내었다.

그림 9는 기술자가 임의로 PID의 파라미터값을 설정하였을 경우 백열전구에 대한 출력을 나타낸

것이다. 그림 10은 자동동조기법을 이용하였을 경우를 나타내며, 그림 11은 NNPPID 제어에 대한 출력을 나타낸다. 그림 4.9의 경우 최대오버슈트는 140초 부근에서 약 2% 정도 발생하고 2% 정도의 언더슈트가 발생하는 것을 알 수 있으며, 그림 10과 4.11의 경우는 오버슈트와 언더슈트는 거의 발생하지 않는 것을 알 수 있다. 상승시간은 그림 9의 경우는 약 100초이며, 그림 10과 11은 110초와 105초로 각각 나타났다. 이것은 그림 9의 경우는 초기에 과도한 제어입력이 인가됨으로 상승시간이 보다 빠르고, 따라서 오버슈트가 발생하는 것으로 분석된다. 정정시간은 각각 260초, 175초, 160초로서 NNPPID의 경우 정상상태에 가장 빨리 도달하는 것으로 나타났다. 그러나, 정상상태 오차의 경우는 모두 발생하지 않음을 알 수 있다.




Fig. 9. Fixed PID control.




Fig. 10. Auto tuning control.




Fig. 11. NNPPID control.

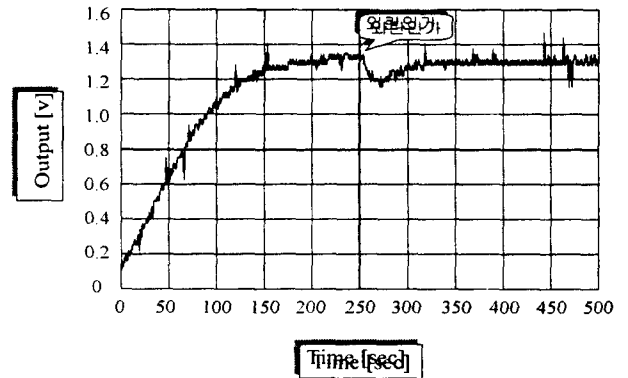


Fig. 12. Auto tuning control(with disturbances).

다음은 외란을 인가하였을 경우 제어특성에 대한 실험이다. 외란은 백열전구에 젖은 수건을 10초간 접촉하는 것으로 하였다. 설정치 온도는 앞 실험과 마찬가지로 100℃로 하였고, A사 제품은 앞 실험에서 자동동조기법으로 구한 PID 파라미터값을 그대로 적용하였으며, 외란을 인가하였을 경우의 하강온도와 정상상태 복귀시간 그리고 외란을 제거하였을 경우의 여러 가지 제어특성을 비교 분석하였다. 그림 12와 13은 자동동조 제어와 NNPPID 제어에 대한 출력을 각각 나타낸다. 그림 12의 경우 외란을 인가 시 18℃ 정도 온도가 하강하며, 외란인가 후 약 65초 후에 정상상태에 도달하는 것으로 나타났다. 그림 13의 경우 외란 인가 시 약 20℃ 정도 온도가 하강하며, 40초 이후에 정상상태에 도달하는 것으로 나타났다. 외란이 제거된 후에 정상상태 오차는 두 제어의 경우 모두 발생하지 않음을 알 수 있었다. 전체적으로 볼 때 NNPPID는 외란이 인가된 후 온도가 급격히 하강하더라도 정상상태에 복귀하는 시간이 보다 빠름을 알 수 있었다.




Fig. 13. NNPPID control(with disturbances).

6. 결론

본 논문에서는 신경회로망을 이용하여 예측 제어시스템을 구성하였으며, 백열전구의 온도시스템을 구성하여 실시간 제어를 실험하였다. 그리고, 제어성능을 비교 분석하기 위하여 현재 산업현장에서 많이 사용되고 있는 국내 중소기업 A사의 제품과 함께 실험을 하였다.

실험을 통해 외란을 인가하지 않는 경우, NNPPID 제어기는 A사의 자동동조 제어에 비해 정정시간이 약 15초 가량 감소되었으나, 전체적으로 거의 비슷한 제어성능을 가지는 것으로 분석되었다. 외란을 인가하였을 경우, NNPPID 제어기는 약 10℃ 정도 온도가 하강하며, 정상상태에 도달하는 시간은 외란 인가 후 약 60초였으며, 이것은 A사의 자동동조 제어에 비해 약 25초 정도의 시간

이 감소되었다. 그리고, A사의 자동동조는 외란인가 후 오버슈트가 조금 발생하지만, NNPPID 제어의 경우 외란 인가 후에도 오버슈트가 거의 발생하지 않음을 알 수 있었다.

[참고문헌]

- [1] 김동화, 이은웅, "PID 제어기 튜닝 기술에 대한 연구현황과 전망," 전기학회지, Vol. 44, No. 5, pp. 13-23, 1995.
- [2] M. Saerens and A. Soquet, "Neural controller based on back-propagation algorithm," IEE Proc. F, Vol. 138, No. 1, pp 55-62, 1991.
- [3] G. F. Page, J. B. Gomm, and Williams, Application of neural networks to modelling and control, Chapman & Hall, 1993, pp. 141-168.
- [4] D. Soloway and P. J. Haley, Neural generalized predictive control, NASA Technical Memorandum 110244, 1997, pp. 1-17.
- [5] Sigeru Omatu, Marzuki Khalid, and Rubiyah Yusof, Neuro-control and its applications, Springer, 1995, pp. 159-267.