

인공 신경망을 이용한 PID 제어기 최적 튜닝 방법

이 용호, 이 문용*, 박선원

한국과학기술원 화학 공학과, 영남 대학교 화학 공학과*

Optimal PID tuning method based on Neural Network

Yongho Lee, Moonyong Lee* and Sunwon Park

Dept. of Chem. Eng., KAIST, Dept. of Chem. Eng., Yeungnam Univ.*

I. 서론

PID 제어기는 고급 제어 알고리즘의 유용성에도 불구하고 간단한 구조 그리고 대부분의 화학 공정에서의 강건성에 기인하여 보편적으로 널리 사용되어지고 있다. PID 제어기의 튜닝에 관련된 연구는 정량적인 규칙들과 정성적인 방법들에 대해서 행하여져 왔는데 여러 가지 접근 방법에 따라서 많은 방법들이 제시 되어지고 있다. Settling time 의 최소화를 위한 방법으로 1/4 Decay Ratio 방법, Maximum Deviation 의 최소화를 위한 5% Overshoot, No Overshoot 방법, Error Integral 의 최소화를 위한 ISE, IAE, ITAE 방법 그리고 적정 안전성을 위한 Gain Margin, Phase Margin 방법들이 있다. 1/4 Decay Ratio 방법은 Overshoot 가 크며 공정이 Nonlinear 한 경우 Unstable 해지기 쉬워 화학 공정에 맞지 않는데 이러한 방법중에 대표적인 것이 Ziegler-Nichols 방법과 Cohen & Coon 방법이다. 화학 공정은 Nonlinear 하고 Dead Time이 크므로 출력 반응이 Reference Trajectory에 따르도록 하는 방향으로 연구가 진행되어 Dahlin 방법과 IMC 방법이 대두 되었다. 이 방법의 장점은 Closed Loop Response 가 일차 시간 지연 함수 형태로 나오도록 튜닝이 가능하다는 것이다. 이 IMC 와 Dahlin 방법은 시간 지연항을 Pade Approximation 을 통하여 근사를 했기 때문에 시간 지연이 큰 시스템인 경우 불안정한 경향을 보인다. 이에 본연구는 Reference Trajectory 를 따르는 최적의 PID Parameter 들을 찾는 것으로, 출력 반응의 Reference Trajectory 에 대한 ISE를 줄이는 최적화를 통하여 PID 튜닝을 한다. 최적화를 통하여 구한 parameter 들은 각 K , τ , θ 에 대해서 K_c , τ_I , τ_D 로의 nonlinear한 mapping 을 하게 되는데 최근에 각광 받고 있는 인공 신경망을 통하여 각각의 패턴을 학습함으로써 비선형 관계를 모델링할 수 있다. 본 논문의 목적은 최적의 튜닝 값을 얻는데 있어서 공정 실무자들이 그때마다 최적화 패키지를 이용하여 Tuning parameter 를 얻는데에는 어려움이 있으므로 비선형

의 모델링이 가능한 Neural Network을 이용함으로써 손쉽게 최적의 튜닝값을 얻는데 있다.

II. 이론

최적의 Tuning Parameter는 Reference Trajectory를 시간 지연함에 상관없이 가장 잘 따라가야하는데 최적의 출력 반응은 (1) 식이 항상 만족

$$C(s) = K_C (1 + \frac{1}{\tau_I s} + \tau_D s) = \frac{\tau s + 1}{K} \frac{1}{\lambda s + 1 - e^{-\theta s}} \quad (1)$$

이 되도록 목적함수 (2)를 최적화를 통하여 K_C, τ_I, τ_D 를 얻음으로써 가능해진다.

$$\text{Obj } \text{Min} \int_0^{st} (Y - Y^{Ref})^2 dt \quad \text{Variables : } K_C, \tau_I, \tau_D \quad (2)$$

이 식은 dead time 으로 인하여 상당히 비선형을 띠게 되므로 nonlinear optimization method 인 SQP 를 이용한다. Reference 에 따른 SSE(Sum of Square Error)를 출력이 Steady State 에 도달할때까지 적분하여 이 적분값이 최소가 되는 Tuning 값을 SQP 를 이용하여 구한다.

이 λ 와 K, τ, θ 가 입력 변수가 되고 K_C, τ_I, τ_D 가 하나의 출력 변수가 된다. 이 Set 이 하나의 Pattern 이 되어 공정 전반을 모두 커버 할 수 있는 영역에서 Data Set 을 만들어 인공 신경망의 Multi Perceptron 모델을 이용하여 Back Propagation 방법으로 학습을 한다. BP 알고리즘은 학습 알고리즘 중에서 가장 널리 사용되어 지고 있는 Powerful 한 방법으로 인공 신경망 발전 역사를 다르게 했을 정도로 중요하다. 이 BP 알고리즘은 입력 패턴에 대한 인공 신경망의 출력 값이 교사된 출력 패턴과 같도록 Gradient Decent Method 를 이용하여 차이를 최소화 한다. 이 BP 알고리즘을 이용하여 대부분의 Multi Perceptron 모델을 학습한다. 이러한 인공 신경망 알고리즘은 패턴 인식, 공정 제어등 많은 분야에서 각광 받고 있으며 특히 비선형 형상을 보여주는 화학 공정들에 유용하다.

III. 결과 및 토론

최적화를 통해서 얻어진 각각의 Set을 인공 신경망을 통하여 모델링을 하였다. 입력 변수는 무차원 변수를 만들어 넣어 주었는데 이 무차원 변수는 인공 신경망의 입력 값들의 수 뿐만아니라 Training Set 의 수도 상당히 줄여 준다. 이 무차원 변수는 최적화 시뮬레이션을 통하여 얻어졌는데 그것은 입력 패턴에 대하

여 나오는, KK_c , $\frac{\tau_I}{\tau}$, $\frac{\tau_D}{\tau}$ 결과는 θ , τ 의 값이 달라도 그 비가 같으면 같은 값을 갖는다는 것이다. 그리고 튜닝 조절 변수인 λ 에 대해서도 $\frac{\lambda}{\tau}$ 의 비가 같으면 같은 KK_c , $\frac{\tau_I}{\tau}$, $\frac{\tau_D}{\tau}$ 값을 보여준다. 그리하여 인공 신경망 구조를 다음과 같이 결정하였다. 인공 신경망 구조에서 $\frac{\lambda}{\tau}$, $\frac{\theta}{\tau}$ 가 입력 패턴이고 각각의 입력 패턴에 대해서 KK_c , $\frac{\tau_I}{\tau}$, $\frac{\tau_D}{\tau}$ 가 출력 패턴이 된다. 이 구조는 그림 1에 나타내었다. 이렇게 비에 따라서만 변하는 결과를 토대로

$$0.1 \leq \frac{\lambda}{\tau} \leq 10 \quad (3)$$

$$0.1 \leq \frac{\theta}{\tau} \leq 10 \quad (4)$$

에서 random 하게 sampling을 통하여 20 개의 set 을 만들고 이러한 방식으로 5 번을 반복하여 100 개의 set을 마련한후 Cross-Validation 방법으로 100 개의 data set 중 80 개의 set을 학습시키고 나머지 20 개의 set 을 이용하여 학습된 인공신경망을 test한다. 또 rotation 하여 80 개의 set 을 학습시키고 나머지 20 개의 set 으로 인공신경망을 test한다. 이것은 data set을 적게 이용하여 인공 신경망을 학습시키는 방법이다. 이러한 방법으로 Data set 을 결정한 뒤 학습을 통하여 최적의 trajectory를 모델링하였다. BP 알고리즘을 이용한 학습에 따른 Error 의 감소가 그림 2에 나와 있다. 이 모델링 결과로 얻어진 tuning 값을 이용하여 공정 Response 를 그림 3에 나타내었다.

감사

본 연구는 한국과학재단지정 우수연구센터인 공정산업의 지능자동화연구센터의 연구비 지원에 의해 수행된 연구 결과임.

IV. 참고 문헌

1. A. Brambilla, S. Chen, C. Scali, "Robust tuning of conventional controllers", Hydrocarbon Processing, 53-58p, 1991
2. Rivera, D. E., Morari, M., Skogestad, S., "Controller Tuning from Simple Process Models", Ind. Eng. Chem. Process Des. Dev., 252, 1986
3. Dahlin, E. B., "Design and Tuning Digital Controllers", Instrum. Control Syst., 41, 1968
4. Fruehauf, Paul S, "Simplified IMC-PID Tuning Rules", ISA Transaction, 43-49p, 1994

그림 1. 신경망의 구조




그림 2. BP 알고리즘을 이용한 학습의 Error의 감소




그림 3. Optimal Tuning 방법과 다른 방법들의 Response 의 비교

