

## 자동 양자이득 조절에 의한 퍼지 제어방식

강 성 호\*, 임 중 규\*, 엄 기 환\*

\*동국대학교

전화 : 02-2260-3332/ 핸드폰 : 011-9914-5530

### Fuzzy Control Method By Automatic Scaling Factor Tuning

Seong-Ho Kang\*, Joong-Gyu Lim\*, Ki-Whan Eom\*

Dongguk University

E-mail : ksh7209@dgu.edu

#### Abstract

In this paper, we propose a fuzzy control method for improving the control performance by automatically tuning the scaling factor.

The proposed method is that automatically tune the input scaling factor and the output scaling factor of fuzzy logic system through neural network. Used neural network is ADALINE (ADaptive LInear NEron) neural network with delayed input. ADALINE neural network has simple construct, superior learning capacity and small computation time. In order to verify the effectiveness of the proposed control method, we performed simulation. The results showed that the proposed control method improves considerably on the environment of the disturbance.

#### I. 서론

퍼지 논리이론은 1965년 L.A. Zadeh 교수에 의해 제안된 이론으로, 애매한 정보로부터 유용한 정보를 추론해 낼 수 있는 이론적 바탕을 제공해 주고 있다. 그러나, 퍼지 제어 방식은 전문가로부터 제어 지식 획득, 소속 함수 관계의 조정과 알맞은 양자이득 선정

등의 문제점을 가지고 있어 원하는 제어 특성을 얻기 위해서는 여러 번의 시행착오를 거쳐야 한다[1][3].

최근에 신경회로망의 학습능력과 퍼지이론의 뛰어난 추론성을 바탕으로 두 이론의 융합에 관한 연구가 많이 진행되고 있다. 신경회로망과 퍼지 이론의 융합에 관한 연구는 일반적으로 두 형태로 구분된다. 첫 번째는 퍼지 논리에 신경회로망의 학습기능을 첨가하여 퍼지논리의 추론성을 향상시키는 연구와 신경회로망 구조에 퍼지 논리성을 부가하는 연구로 구분된다[2].

이러한 신경회로망과 퍼지 이론을 융합한 혼합형은 구조가 복잡하고 계산량이 많아 제어방식으로 실시간 제어에 응용할 경우 많은 문제점이 있다.

본 논문에서는 제어 성능을 개선하기 위하여 양자이득을 자동 조절하는 퍼지 제어방식을 제안한다. 제안한 제어방식은 초기의 임출력 양자이득을 LQR (Linear Quadratic Regulator)에 의하여 설정하고, 그 후에는 ADALINE에 의하여 자동조정 된다.

ADALINE 신경회로망은 간단한 구조의 신경회로망이며, 우수한 학습능력과 계산량이 적다. 제안한 방식의 실용성을 확인하기 위해 역 진자를 대상으로 환경 변화에 대응하는 시뮬레이션을 하여 직접 퍼지 제어방식과 성능을 비교 검토한다.

#### II. 적응 퍼지 제어방식

퍼지 제어를 설계하기 위한 처리과정은 전문가로부터

더 경험적인 정보를 기본토대로 한다. 전문가의 경험을 배제하고 퍼지 제어기를 설계하는 경우 몇 가지 문제점이 있다. 첫째 요구되는 성능을 만족하는 소속 함수와 퍼지 규칙을 선택하기 어렵다. 둘째 폐 루프 시스템을 구동하는 동안 플랜트의 파라미터 값이 변한다면, 적당한 제어성을 유지 못 할 수도 있다.

이러한 문제점들을 해결하기 위해 퍼지 제어기를 자동으로 구성하고 조절하는 방식이 적응 퍼지 제어 방식이다. 적응 퍼지 제어방식은 직접 적응방식과 간접 적응방식이 있다. 그림2-1은 직접 적응방식의 블록선도이다.

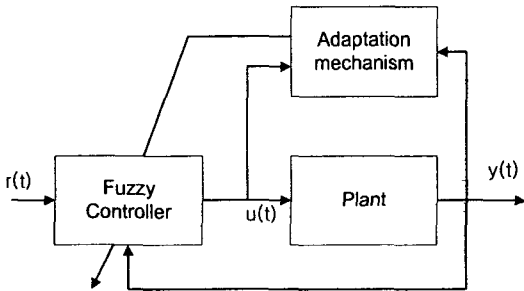


그림2-1. 직접 적응 퍼지방식

직접 적응방식에서 adaptation mechanism은 제어 시스템으로부터 신호를 관찰하고 플랜트로부터 제어성을 유지하기 위해 제어파라미터를 수신한다.

### III. ADALINE 신경회로망

ADALINE(ADaptive Linear NEuron) 신경회로망은 Widrow와 Hoff가 소개하였고, 학습규칙은 LMS (Least Mean Square) 알고리즘으로 ADALINE 신경회로망은 학습된다.

그림3-1은 ADALINE 네트워크의 블록선도이다.

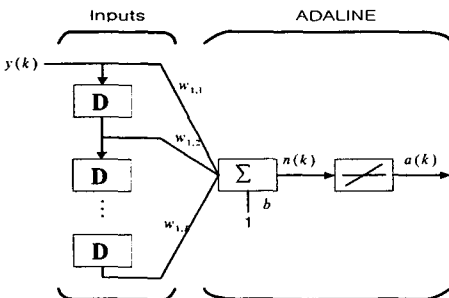


그림3-1. ADALINE 네트워크

네트워크의 출력은 식3.1과 같다.

$$a = \text{purelin}(Wp + b) = Wp + b \quad (3.1)$$

여기서,  $a$ 는 출력벡터,  $\text{purelin}$ 는 선형전달 함수,  $W$ 는 가중치 벡터,  $p$ 는 입력벡터,  $b$ 는 바이어스 벡터이다.

LMS알고리즘으로 다음상태 가중치 벡터와 바이어스 벡터를 계산하면 식3.2와 같다.

$$\begin{aligned} W(k+1) &= W(k) + 2\alpha e(k) p^T(k), \\ b(k+1) &= b(k) + 2\alpha e(k) \end{aligned} \quad (3.2)$$

여기서,  $W(k+1)$ 는 다음상태 가중치 벡터,  $W(k)$ 는 현재상태 가중치 벡터,  $\alpha$ 는 학습률,  $e(k)$ 는 오차 벡터,  $p^T(k)$ 는 입력벡터,  $b(k+1)$ 는 다음상태 바이어스 벡터,  $b(k)$ 는 현재상태 바이어스 벡터를 의미한다.

### IV. 제안한 방식

제안한 방식은 퍼지 제어기의 입출력 양자이득의 초기치를 LQR을 이용하여 설정한다. LQR에 대한 성능인덱스는 식(4.1)과 같다.

$$J = \int_0^{\infty} (x(t)^T Q x(t) + u(t)^T R u(t)) dt \quad (4.1)$$

여기서,  $Q$ 는 상태변수  $x$ 에 대응하는 가중치 행렬이고,  $R$ 은 플랜트 입력  $u$ 에 대응하는 가중치 행렬이다. 함수  $J$ 를 최적화하는 피드백 이득은 Riccati 방정식으로부터 구할 수 있다. LQR에 의한 제어 출력은 식(4.2)와 같다.

$$u(t) = \sum_i k_i x_i(t) \quad (4.2)$$

여기서,  $k_i$ 는 피드백 이득,  $x_i(t)$ 는 플랜트의 현재상태,  $u(t)$ 는 제어 출력을 의미한다.

Riccati 방정식으로부터 구한 피드백 이득은 퍼지제어기의 양자이득으로 이용할 수 있으며, 제어기의 성능을 향상시킬 수 있다.

피드백 이득을 퍼지제어기의 양자이득으로 이용한 경우 시스템 블록선도는 그림4-1과 같다.




그림4-1. 양자이득을 이용한 퍼지제어 블록 선도

여기서, 소속함수는 대칭형 삼각형 소속함수, min-max추론, COG (Center Of Gravity) 비퍼지화를 이용할 수 있다. LQR의 양자이득을  $k_i$ 이고, 퍼지출력 양자이득을  $g_0$  이라면, 블록선도에서 양자이득  $g_i$ 는 LQR이득  $k_i$ 에서 식(4.3)를 이용하여 구할 수 있다.

$$g_i g_0 = k_i \quad \text{단, } i=1, 2, 3, 4 \quad (4.3)$$

정규화된 퍼지제어기의 규칙-베이스는 표4-1과 같이 구성할 수 있다.

표4-1. 퍼지 규칙-베이스

e		Input2				
		NB	NS	ZE	PS	PB
Input1	NB	NB	NM	NS	NVS	ZE
	NS	NM	NS	NVS	ZE	PVS
	ZE	NS	NVS	ZE	PVS	PS
	PS	NVS	ZE	PVS	PS	PM
	PB	ZE	PVS	PS	PM	PB

표4-1에서 "NB","NM","NS","ZE","PS","PB"는 언어적인 변수이며, 각각 "negative big", "negative medium","negative small", "zero", "positive small","positive big"을 의미한다.

제어기 설계를 위한 다음절차로 비 선형적인 환경변화에 적응하기 위한 학습 시스템으로 구조가 간단하고 학습능력이 우수한 ADALINE 신경회로망을 제안한다. 제안한 방식은 환경의 변화에 따라 ADALINE 신경

회로망이 학습하고 대응한다. 퍼지 제어기는 LQR에 의해 선형적으로 동작하며, 비 선형적인 환경변화에 따라 ADALINE 신경회로망은 퍼지 제어기의 양자이득을 조정한다.

제안한 방식의 전체 시스템 블록선도는 그림4-4와 같다.

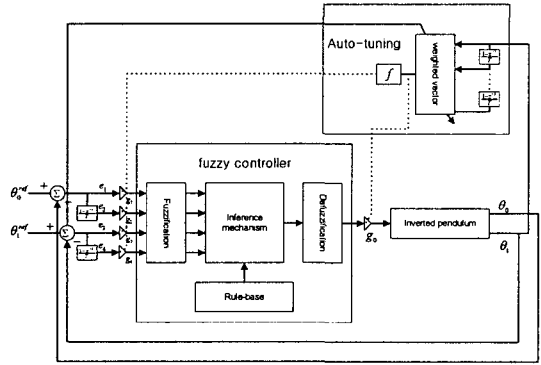


그림4-2. 적응 퍼지제어 블록 선도

### V. 시뮬레이션

시뮬레이션에 이용한 역 진자의 운동방정식은 식(5.1)과 같고, 역 진자의 파라미터는 표5-1과 같다.

$$\begin{aligned} \ddot{\theta}_0 &= -a_p \dot{\theta}_0 + K_p v_a \\ \ddot{\theta}_1 &= -\frac{C_1}{J_1} \dot{\theta}_1 + \frac{m_1 g l_1}{J_1} \sin(\theta_1) + K_1 \ddot{\theta}_0 \end{aligned} \quad (5.1)$$

표5-1 플랜트 파라미터

dc motor parameter ( $K_p$ )	$74.89 \text{ rad} - s^{-2} - v^{-1}$
dc motor parameter ( $a_p$ )	$33.04 \text{ s}^{-2}$
torque constant ( $K_1$ )	$1.9 \text{ kg} - m / \text{rad}$
frictional constant ( $C_1$ )	$2.9790 \text{ N} - m - s / \text{rad}$
pendulum mass ( $m_1$ )	$0.086184 \text{ kg}$
pendulum length ( $l_1$ )	$0.113 \text{ m}$
inertia ( $J_1$ )	$1.3010 \text{ N} - m - s^2$

그림5-1은 역 진자의 끝 부분에 sloshing liquid를 갖고 있을 때 직접 퍼지제어에 대한 시뮬레이션한 결과이고, 그림5-2는 제안한 퍼지 제어방식에 대한 시뮬레이션 결과이다.

참고문헌

- [1] Kevin M. Passino, Stephen Yurkovich, "Fuzzy Control," Addison-Wesley Inc, July 1997.
- [2] Hagan, Demuth, Beale, "Neural Network Design," PWS publishing company, 1996.
- [3] Moeljono Widjaja, Stephen Yurkovich, "Intelligent Control for Swing Up and Balancing of an Inverted Pendulum System," In Proc. of the IEEE conf, September 1995.




그림5-1. 진자의 침단에 sloshing liquid가 있을 경우 직접 퍼지제어 방식




그림5-2. 진자의 침단에 sloshing liquid가 있을 경우 적응 퍼지제어 방식

그림5-1와 그림5-2의 결과를 통하여 직접 퍼지 제어방식인 경우 환경변화에 적응하지 못하는 것을 확인할 수 있으며, 제안한 방식의 경우 환경의 변화에 적응성이 우수함을 확인할 수 있다.

VI. 결 론

본 논문에서는 제어 성능을 개선하기 위하여 양자이득을 자동 조정하는 퍼지 제어방식을 제안하였다. 제안한 방식은 LQR를 이용하여 플랜트의 운동방정식으로부터 양자이득을 얻고, LQR 양자이득을 이용하여 퍼지 제어기의 초기치 양자이득을 결정하고, 퍼지 제어기를 정규화 한다.

환경변화에 적응하기 위해 퍼지 제어기의 양자이득은 ADALINE 신경회로망에 의해 조정되며, 환경의 변화에 적응한다.

제안한 방식의 실용성을 시험하기 위해 역 진자를 대상으로 환경변화에 대한 시뮬레이션을 하였으며, 직접 퍼지 제어방식과 성능을 비교 검토한 결과 제안한 방식의 실용성을 확인하였다.