

## 퍼지학습법을 이용한 크레인 제어 Control of Crane System Using Fuzzy Learning Method

노상현\*      임윤규\*\*  
Sang-Hyun Noh\*, Yoon-Kyu Lim\*\*

### <Abstract>

An active control for the swing of crane systems is very important for increasing the productivity. This article introduces the control for the position and the swing of a crane using the fuzzy learning method. Because the crane is a multi-variable system, learning is done to control both position and swing of the crane. Also the fuzzy control rules are separately acquired with the loading and unloading situation of the crane for more accurate control. And We designed controller by fuzzy learning method, and then compare fuzzy learning method with LQR. The result of simulations shows that the crane is controlled better than LQR for a very large swing angle of 1 radian within nearly one cycle.

**Key Words** : Crane system, Fuzzy control, Learning algorithm, Multi-variable system, LQR(Linear Quadratic Regulator).

### 1. 서론

크레인은 산업체 현장 전반에서 무거운 장비나 운반물을 옮길 때 이용하고 있다. 그래서 이에 대한 많은 연구가 이루어지고 있다<sup>(1)</sup>. 산업 현장에서 사용되고 있는 크레인의 전달함수(transfer function)를 구하기란 매우 힘든 경우가 많다. 또한 마모나 주위 환경에 노출되어 있기 때문에 시스템의 변형은 막을 수 없게 된다. 이런 시스템의 변형이 생길 때마다 새로이 전달함수를 구해야 한다<sup>(2-3)</sup>. 이 두 가지 문제를 해결하기 위해서는 시스템의 전달함수 없이도 제어기를 설계할 수 있어야 하고 시스템의 변형에 강건성을 가지거나 아니면 능동적으로 대처할 수 있는 제어기가 필요하다<sup>(4-5)</sup>. 그래서 본 논문에서는 퍼지 학습법을 사용하여 이 시스템의 제어기를 설계하고자 한다.

그리고 크레인의 고유진동수는 고정된 것이 아니라 운반 물을 잡고 놓는 과정에서 변하게 된다. 즉, 크레인의 고유진동수는 트레일러의 하중, 로프에 달린 크레인 하중과 운반물의 하중의 합한 하중과 로프의 길이에 의해 결정된다. 만약, 로프의 길이가 일정하다면 트레일러의 하중과 크레인 및 운반물의 하중 비에 의해 고유진동수가 결정된다. 이 비에 의해 크레인이 운반물을 잡기 전의 고유진동수와 잡고 난 후의 고유진동수가 다르며, 얼마만한 하중의 운반물을 잡느냐에 따라 달라진다는 것이다. 그리고 다변수 시스템이기 때문에 트레일러의 정확한 이송거리와 크레인의 진동을 동시에 제어하는 제어기가 필요하다. 이 제어기를 설계하는 것은 인간의 경험이나 전문가의 지식에 의해서는 불가능하기<sup>(4-9)</sup> 때문에, 본 논문에서는 퍼지 학습법을 쓰하고자 한다.

\* 정회원, 대구공업대학 자동차과 조교수, 工博, 영남대학교대학원 졸업.

704-35 대구광역시 달서구 본동 831

\*\* 영남대학교 기계공학과 대학원, 박사과정수료

Assis. Prof. Dept. of Automotive Engineering, Taegu Technical College.

Graduate Student, Dept. of Mechanical Engineering Yeungnam University.

논제에서 사용한 퍼지 학습법은 기존의 성능지수표 대신에 원하는 진동각과 운반물의 실제 진동각 사이의 에러와 에러 변화량, 그리고 원하는 트레일러의 이동 거리와 실제 이동거리 사이의 에러와 에러 변화량을 포함하는 함수를 목적 함수로 정하여 이를 최소화하는 학습법이다<sup>(6-9)</sup>. 이 학습법을 이용하여 로프의 길이를 일정하게 두고, 운반물을 잡으러 갈 때의 제어기와 운반물을 잡고 옮길 때의 퍼지 4차원 규칙 제어기를 설계하였다. 이 제어기를 LQR로 설계된 제어기와 비교하여 성능을 평가하였다.

## 2. 시스템의 고유값과 LQR 제어

### 2.1. 시스템의 고유값(eigen value)

크레인 시스템은 Fig.1에서 보듯이 상단에 트레일러가 이동할 수 있는 궤도가 있다. 그리고 아래쪽으로 로프에 매달려서 운반물을 잡을 수 있는 크레인이 있고, 이 크레인 안에 담긴 운반물로 구성되어 있다. 트레일러가 이동할 때 마다 로프에 매달린 크레인과 운반물의 흔들림이 발생하고, 크레인과 운반물의 흔들림에 의해 트레일러가 궤도 위에서 좌우로 흔들린다. 이러한 시스템의 운동방정식은 아래 식(1)과 (2)로 나타낼 수 있다.

$$\ddot{x} = \frac{m_c \sin \theta (l \dot{\theta}^2 + g \cos \theta) + F}{m_t + m_c \sin^2 \theta} \quad (1)$$

$$\ddot{\theta} = \frac{-g \sin \theta - \cos \theta \ddot{x}}{l} \quad (2)$$

여기서,  $m_t$ 는 트레일러의 하중,  $m_c$ 는 크레인과 운반물의 하중,  $l$ 는 로프의 길이,  $F$ 는 힘, 그리고  $g$ 는 중력 가속도이다. 위 식(1)은 트레일러의 이송에 대한 운동방정식이고, 식(2)는 크레인의 진동에 대한 운동 방정식이다. 이들(eigen value)  $\lambda$ 를 구하면 다음과 같이 된 여기서,  $m_t$ 는 트레일러의 하중,  $m_c$ 는 크레인과 운반물의 하중,  $l$ 는 로프의 길이,  $F$ 는 힘, 그리고  $g$ 는 중력 가속도이다. 위 식(1)은 트레일러의 이송에 대한 운동방정식이고, 식(2)는 크레인의 진동에 대한 운동 방정식이다. 이들 식에서 고유값(eigen value)  $\lambda$ 를 구하면 식(3)과 같이 된다.

$$\lambda \begin{bmatrix} \theta \\ x \end{bmatrix} = \begin{bmatrix} -\frac{g}{l}(1+\gamma) \\ 0 \end{bmatrix} \begin{bmatrix} \theta \\ x \end{bmatrix} \quad (3)$$

여기서,  $\gamma$ 는 트레일러와 크레인 및 운반물의 하중 비( $m_c/m_t$ )이다. 이 식(3)에서 알 수 있듯이 고유진동수(natural frequency)는 로프의 길이  $l$ 와  $\gamma$ 에 의해 좌우된다. 여기서 로프의 길이를 일정하게 둔다면, 고유진동수는  $\gamma$ 만에 의해 좌우된다. 즉, 크레인이 운반물을 잡을 때와 잡지 않았을 때의 고유진동수가 달라진다. 또한 트레일러와 크레인 및 운반물의 하중비가 얼마냐에 따라 진동 정도가 달라짐을 알 수 있다.




Fig.1 Modeling for crane system.

### 2.2. LQR 제어

LQR 설계를 하기 위해서는 먼저 시스템의 운동방정식을 선형화한 다음 이 식을 상태공간(state space)으로 나타낸 다음, 이 식을 Riccati 식을 이용하여 피드백 게인(feedback gain)을 구한다. 먼저 일반적인 시스템의 상태 방정식은 식(4)로 표현 할 수 있다.

$$\begin{aligned} \dot{X}(t) &= AX(t) + BU(t) \\ Y(t) &= CX(t) \end{aligned} \quad (4)$$

식(1)과 (2)를 선형화 시켜 상태공간으로 표현하면 시스템 행렬 A,B,C는 각각 식(5)와 같이 된다. 그리고 여기서  $X = [x \ \dot{x} \ \theta \ \dot{\theta}]^T$ 이고 입력  $U = F$ 이다.

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & \frac{m_c}{m_t}g & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & -\frac{(m_c+m_t)}{m_t l}g & 0 \end{bmatrix}$$

$$B = \left[ 0 \quad \frac{1}{m_t} \quad 0 \quad -\frac{1}{m_t l} \right]^T$$

$$C = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (5)$$

LQR 제어기 설계에서 파라미터 변수는 상태가중치 Q와 제어 가중치 R이 있다. 이 두 값을 설계하여야 한다. 본 논문에서는 운반물을 잡지 않은 상태, 즉  $\gamma=2$ 일 때의 상태 가중치 Q와 제어 가중치 R은 식(6)과 같이 선정하였다.

$$Q = \begin{bmatrix} 10 & 0 & 0 & 0 \\ 0 & 5 & 0 & 0 \\ 0 & 0 & 10 & 0 \\ 0 & 0 & 0 & 5 \end{bmatrix} \quad R = 0.0001 \quad (6)$$

위에서 선정한 Q, R을 Riccati 식인 식(7)에 대입하면 식 (8)과 같은 피드백 게인(K)을 구할 수 있다.

$$K(t)A + A^T K(t) + Q - K(t)BR^{-1}B^T K(t) = 0 \quad (7)$$

$$K = [316.228, 489.396, 3.534, 270.578] \quad (8)$$

이 게인을 이용하여 제어한 결과를 그림4-5에 점선으로 나타내었다. 그리고 운반물을 잡은 경우, 즉  $\gamma=10$ 일 때의 상태 가중치 Q와 제어 가중치 R을 식(9)와 같이 선정하였다.

$$Q = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 50 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 50 \end{bmatrix} \quad R = 0.0001 \quad (9)$$

위에서 선정한 Q, R을 앞에서 마찬가지로 Riccati 식에 대입하면 식 (10)과 같은 피드백 게인(K)을 구할 수 있다.

$$K = [100.000, 850.007, -123.195, 78.509] \quad (10)$$

이 게인을 이용하여 제어한 결과를 그림6-7에 점선으로 나타내었다.

### 3. 퍼지 학습법

#### 3.1 퍼지 제어

퍼지 논리 제어기란 프로세스의 입력과 출력의 애매한 관계를 인간의 경험과 지식을 기초로 한 언어적 제어규칙으로 표현하여, 이를 제어원리로 변환시킨 것이다. 일반적인 제어입력  $u(k)$ 는 다음과 같이 표현할 수 있다.

$$u(k) = f[y_d(k+n), \dots, y_d(k+1), y(k), \dots, y(k-p+n), u(k-1), \dots, u(k-m+n)] \quad (11)$$

여기서,  $n$ 은 시스템의 시간지연,  $m$ 은 입력 차수,  $p$ 는 시스템 차수,  $y(k)$ 는  $k$ 번째 출력,  $y_d(k+n)$ 는 원하는  $(k+n)$ 번째 출력이다.  $u(k)$ 는 과거의 입력과 출력뿐만 아니라 미래의 출력으로 이루어진 함수이다. 즉, 미래의 출력에 대한 정확한 예측이 가능해야만 현재의 제어 입력을 제대로 추정할 수 있다. 따라서 시스템의 역모델을 구하기 위해 식(12)와 같이 퍼지 제어 입력을 에러와 에러 변화율들에 대한 함수로 나타낼 수 있다.

$$u(k) = F[e_i(k), c_i(k)], \quad (i = \theta, x) \quad (12)$$

여기서,  $e_i(k) = y_d(k) - y_i(k)$ ,  $c_i(k) = [e_i(k) - e_i(k-1)] / \Delta t$ 이다. 퍼지 함의 R은 다음과 같이 표현 할 수 있다.

$$R : E_\theta(e_\theta) \wedge C_\theta(c_\theta) \wedge E_x(e_x) \wedge C_x(c_x) \rightarrow v \quad (13)$$

여기서, 퍼지 후건부의 값  $v$ 는 비퍼지 값(defuzzified value)이다.  $k$ 번째 제어규칙  $R_k$ 를 표현하면 다음과 같이 표현할 수 있다.

$$R_k : E_{\theta k}(e_{\theta k}) \wedge C_{\theta k}(c_{\theta k}) \wedge E_{xk}(e_{xk}) \wedge C_{xk}(c_{xk}) \rightarrow v_k \quad k=1, 2, 3, \dots, M \quad (14)$$

여기서,  $M$ 은 전체 규칙의 개수이다. 멤버십 함수는 다음과 같이 표현 할 수 있다.

$$R_k : \mu_{E_{\theta k}(e_{\theta k})} \wedge \mu_{C_{\theta k}(c_{\theta k})} \wedge \mu_{E_{xk}(e_{xk})} \wedge \mu_{C_{xk}(c_{xk})} \rightarrow v_k \quad (15)$$

제어 입력을 결정할 때, 후건부의 값을 얼마나 반영해야 할 것인가를 결정하는  $k$ 번째 규칙의 적합도(fitness)  $\phi_k$ 는 다음과 같이 계산할 수 있다.

$$\phi_k = \frac{\mu_{E_{\theta_0}}(e_{\theta_0}) \wedge \mu_{C_{\theta_0}}(c_{\theta_0}) \wedge \mu_{E_{x_0}}(e_{x_0}) \wedge \mu_{C_{x_0}}(c_{x_0})}{\sum_{k=1}^M \mu_{E_{\theta_0}}(e_{\theta_0}) \wedge \mu_{C_{\theta_0}}(c_{\theta_0}) \wedge \mu_{E_{x_0}}(e_{x_0}) \wedge \mu_{C_{x_0}}(c_{x_0})} \quad (16)$$

식(16)에서 구해진 k번째 적합도와 k번째 후건부 값을 곱하면 k번째 규칙에 의한 제어 입력량이 계산되고, 마찬가지로 각각의 규칙에 대한 제어 입력의 합을 계산하면 플랜트에 적용하게 될 최종적인 제어입력을 다음과 같이 구할 수 있다.

$$u = \sum_{k=0}^M \phi_k \times v_k \quad (17)$$

### 3.2 학습 알고리즘

크레인 시스템을 제어하기 위한 제어 규칙의 학습은 모델규범형 퍼지 학습 제어기를 사용하여 원하는 출력과 시스템의 실제 출력의 차이를 구한 다음, 이를 퍼지 제어 규칙에 피드백하여 과거에 사용되었던 규칙을 수정하는 학습법이다.

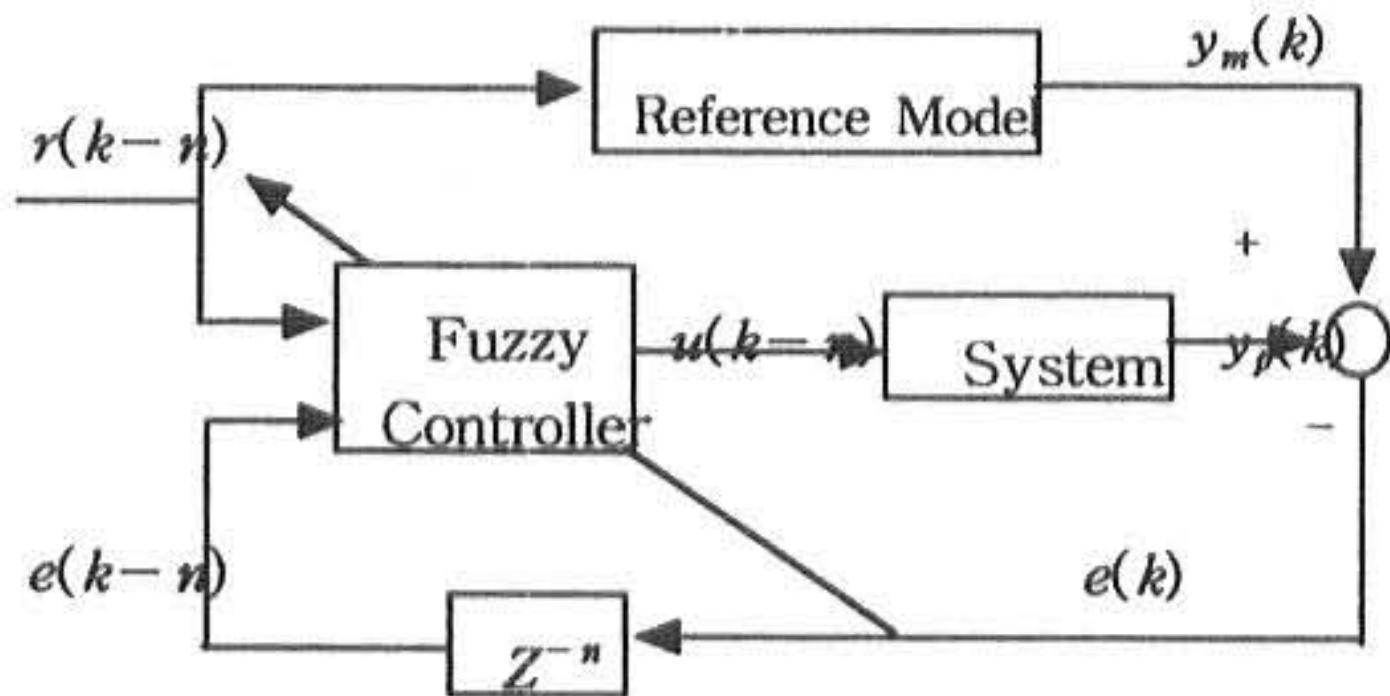


Fig.2 Block diagram of the Model Based Fuzzy Control.

이 학습법을 Fig.2와 같이 나타내었다. 여기서, n스텝은 시스템의 시간지연이고, r(k-n)은 모델의 입력이고, u(k-n)는 시스템의 입력이고, y\_m(k)는 모델의 출력이고, y\_p(k)는 시스템의 실제 출력이고, e(k)는 모델의 출력과 시스템의 출력차이다. y\_p(k)와 y\_m(k)이 일치하도록 u(k-n)를 결정하는 것이 제어기의 역할이다. 시스템 출력이 모델의 출력과 일치하도록 하기 위해서 비용함수를 식 (18)과 같이 에러와 에러 변화율들의 함수로 설정하였다.

$$J(h) = \frac{w_{e_0}}{2} e_{\theta_0}(h)^2 + \frac{w_{c_0}}{2} c_{\theta_0}(h)^2 + \frac{w_{e_x}}{2} e_x(h)^2 + \frac{w_{c_x}}{2} c_x(h)^2$$

(18)

여기서, w\_{e\_0}, w\_{e\_x}, w\_{c\_0}, w\_{c\_x}는 weighting 상수이다. 그리고 e\_{\theta\_0}, c\_{\theta\_0}은 크레인의 진동각에 대한 에러, 에러 변화율이고, e\_x, c\_x은 트레일러의 이송거리에 대한 에러, 에러 변화율이다. 현재의 입력은 미래의 출력에만 영향을 미치므로 비용함수는 식(19)와 같은 학습법칙으로 수정되어야 한다.

$$\Delta v_i \propto - \frac{\partial (\sum_{h=0}^{\infty} J(k+h))}{\partial v_i} \quad (19)$$

현재의 입력이 n스텝 지난 후의 k번째 출력에 가장 큰 영향을 준다고 가정하여 이 출력에 대한 비용함수만 최소화하도록 퍼지 제어 규칙을 수정한다면 식(19)는 식(20)과 같이 표현되어 온라인 학습이 가능하게 된다.

$$\begin{aligned} \Delta v_i \propto & - \frac{\partial J(k+n)}{\partial u(k)} \frac{\partial u(k)}{\partial v_i(k)} \\ = & [ w_{e_0} \frac{\partial y_{\theta_0}(k+n)}{\partial u(k)} e_{\theta_0}(k+n) \\ & + w_{c_0} \frac{\partial y_{\theta_0}(k+n) - y_{\theta_0}(k+n-1)}{\partial u(k)} c_{\theta_0}(k+n) \\ & + w_{e_x} \frac{\partial y_x(k+n)}{\partial u(k)} e_x(k+n) \\ & + w_{c_x} \frac{\partial y_x(k+n) - y_x(k+n-1)}{\partial u(k)} c_x(k+n) \frac{\partial u(k)}{\partial v_i} \end{aligned} \quad (20)$$

여기서, [ \partial y\_i(k+n) - y\_i(k+n-1) ] / \Delta t = \dot{y}\_i(k+n) 이고, \partial u(k) / \partial v\_i = \phi\_i 이므로, 식(20)은 식(21)과 같이 표현된다.

$$\begin{aligned} \Delta v_i = & [ w_{e_0} \frac{\partial y_{\theta_0}(k+n)}{\partial u(k)} e_{\theta_0}(k+n) \\ & + w_{c_0} \frac{\partial \dot{y}_{\theta_0}(k+n)}{\partial u(k)} \Delta t c_{\theta_0}(k+n) \\ & + w_{e_x} \frac{\partial y_x(k+n)}{\partial u(k)} e_x(k+n) \\ & + w_{c_x} \frac{\partial \dot{y}_x(k+n)}{\partial u(k)} \Delta t c_x(k+n) ] \phi_i \end{aligned} \quad (21)$$

위 식(21)을 정리하면 다음 식과 같은 이산 자코비안(discrete jacobian) 매트릭스로 나타낼 수 있다.

$$Jaco = \begin{bmatrix} \frac{\partial y_{\theta_0}(k+n)}{\partial u(k)} & \frac{\partial \dot{y}_{\theta_0}(k+n)}{\partial u(k)} & \frac{\partial y_x(k+n)}{\partial u(k)} & \frac{\partial \dot{y}_x(k+n)}{\partial u(k)} \end{bmatrix} \quad (22)$$

이 자코비안 매트릭스의 부호가 변하지 않는다면, 식(21)은 다음과 같이 간단히 나타낼 수

있다.

$$\Delta v_i = [\eta_{e_e} e_{e_e}(k+n) + \eta_{c_e} c_{e_e}(k+n) + \eta_{e_x} e_x(k+n) + \eta_{c_x} c_x(k+n)] \phi_i \quad (23)$$

여기서,  $\eta_{e_e}$ ,  $\eta_{c_e}$ 는 크레인의 진동각에 대한 에러, 에러변화율의 학습율이고,  $\eta_{e_x}$ ,  $\eta_{c_x}$ 는 트레일러의 이동거리에 대한 에러, 에러변화율의 학습율이다. 식(23)은 목적함수를 최소화하는 방향의 기울기를 나타내므로, 규칙의 학습은 식(24)와 같이 이루어질 수 있다.

$$v_{i(new)} = v_{i(old)} + \Delta v_i \quad (24)$$

#### 4. 시뮬레이션

시뮬레이션 조건은 로프의 길이를 2m로 고정시키고, 초기 진동각을  $57^\circ$  (1 rad), 이동거리를 1m, 운반물을 잡지 않았을 때  $\gamma=2$  ( $\lambda=0.61$ [hz])로, 운반물을 잡았을 때의  $\gamma=10$  ( $\lambda=1.17$ [hz])으로 설정하여 실험하였다. 퍼지 학습에 있어서 설계변수는 각각의 입력 변수에 대한 퍼지 집합의 수와 멤버쉽함수의 형상, 학습 지연시간 그리고 각각의 입력 변수에 대한 학습을 이렇게 4가지이다. 본 실험에서는 진동각도에 대한 에러와 에러변화율 그리고 위치에 대한 에러와 에러 변화율을 입력변수로 하였다. 그리고 퍼지 집합의 수는  $5^4$  ( $5 \times 5 \times 5 \times 5$ )으로 선정하였다. 그리고 멤버쉽함수는 전 영역을 포함하는 강건성이 있는 가우스함수<sup>(7)</sup>를 사용하였으며, 퍼지 양자화(quantization)는 Fig. 3에서와 같이 선정하였다. 그리고 학습지연 시간(n)은 2스텝으로 설정하였고, 학습율은 다음과 같이 설정하였다. 크레인 시스템은 다변수 시스템이기 때문에 어느 한 쪽을 좋게 하면 다른 한쪽이 나빠지는 간섭(coupling)효과가 있다. 그래서 학습율을 각 변수의 에러와 에러 변화율에 대한 기여도를 동일하게 주어야 하지만, 트레일러의 과잉 응답(overshot)이 크게 나타나므로 이를 더 많이 고려하게 되면 다른 요소의 응답은 다소 나빠지지만 전체 응답에서 볼 때 이익이 된다. 그래서 크레인의 진동각에 대한 에러 변화율을 학습에서 더 고려하여 학습율을  $\eta_{e_e}=16.7\%$ ,  $\eta_{c_e}=16.7\%$ ,  $\eta_{e_x}=16.7\%$ ,  $\eta_{c_x}=50\%$ 로 선

정하였다. 그 결과는 Fig.4~Fig.7에 실선으로 나타내었다. Fig.4와 Fig.5는 운반물을 잡지 않았을 경우에 대한 LQR과 퍼지 학습 결과이다. 그림에서 LQR의 성능 보다 퍼지 학습한 결과가 다소 좋음을 알 수 있다. 이 때의 학습 횟수는 192회이다. Fig.6과 Fig.7은 운반물을 잡았을 경우에 대한 LQR과 퍼지 학습 결과이다. Fig.7에서 보듯이 LQR의 정착 시간이 퍼지 학습한 결과 보다 매우 길음을 알 수 있었다. 이 때의 학습 횟수는 307회이다. 그리고, Fig.8은 운반물을 잡지 않았을 경우의 학습된 4차원의 퍼지 규칙을 3차원으로 나타내었다. 그리고 Fig.9는 운반물을 잡지 않았을 경우의 학습된 4차원의 퍼지 규칙을 3차원으로 나타내었다.

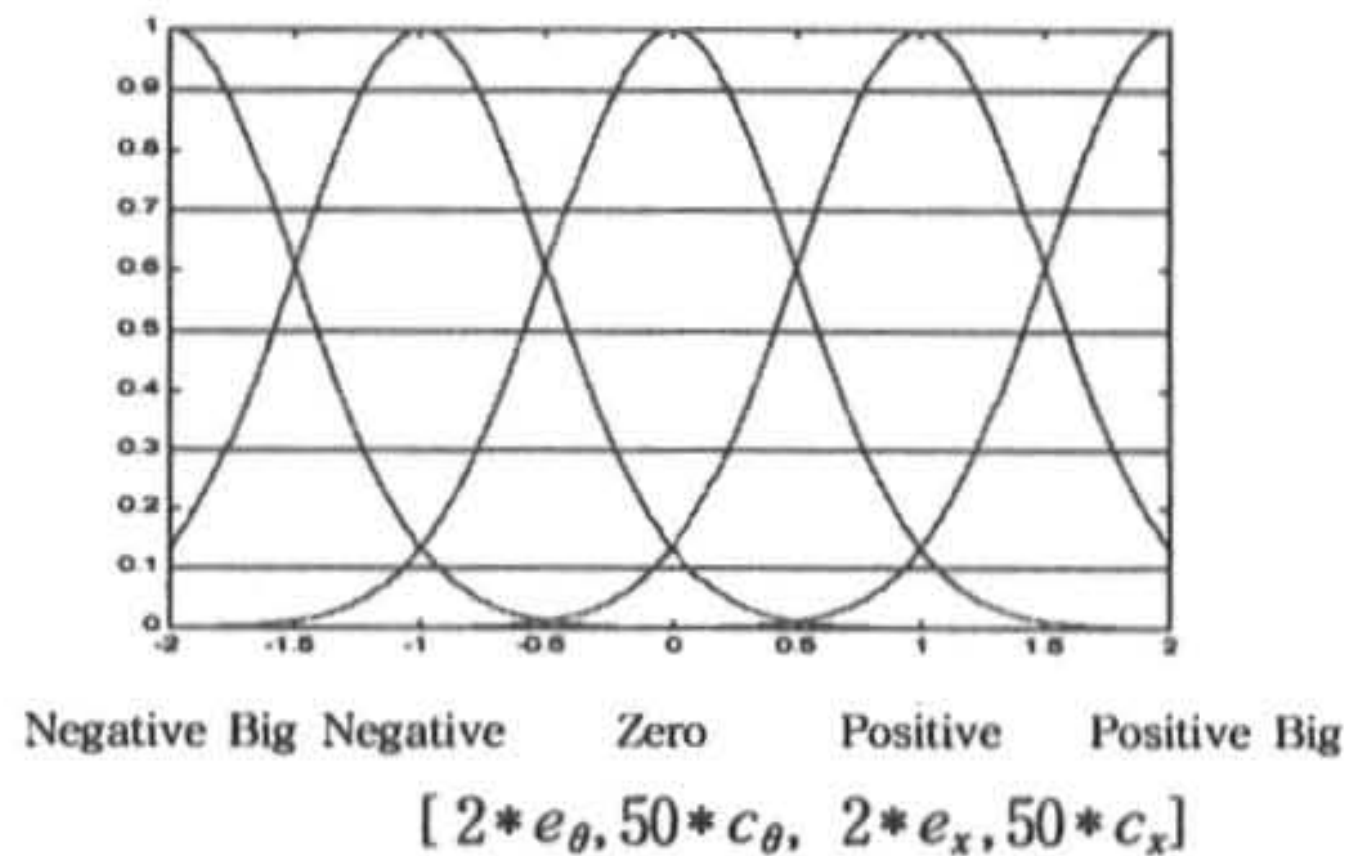


Fig.3 Membership function for error and error change in crane and trailer.




Fig.4 LQR and fuzzy Learning response for swing of crane in  $\gamma=2$ .




Fig.5 LQR and fuzzy Learning response for distance of trailer in  $\gamma=2$ .




Fig.6 LQR and fuzzy Learning response for swing of crane in  $\gamma=10$ .




Fig.7 LQR and fuzzy Learning response for distance of trailer in  $\gamma=10$ .




Fig.8 Fuzzy rules after learning in  $\gamma=2$ .




Fig.9 Fuzzy rules after learning in  $\gamma=10$ .

### 5. 결론

본 논문에서는 크레인 시스템의 고유 진동수를 변화시키는 요인이 크레인을 지지하는 로프의 길이와 크레인 및 운반물의 하중과 트레일러의 하중 비(ratio)임을 알 수 있었다. 그래서 크레인 시스템의 운행에 있어서 운반물을 잡고 놓는 행동을 반복하기 때문에 로프의 길이를 고정시키고 이 비가 달라지는 경우인 운반물을 잡은 경우와 잡지 않은 경우에 대해 각각의 제어를 LQR과 퍼지 학습법을 이용하여 설계하였다. LQR 제어기 설계는 시스템의 전달 함수를 바탕으로 설계되기 때문에 퍼지 학습에 의해 설계된 제어기에 비해 좋은 성능을 가질 것이라 기대 하였다. 그런데 결과는 그 반대로 퍼지 학습에 의해 설계된 제어기의 성능이 더 좋았음을 시뮬레이션을 통해 알 수 있었다. 그 이

유는 여러 가지가 있을 수 있다. 그 중에서 가장 큰 이유는 LQR 제어에서 사용하는 시스템의 전달 함수는 선형화 시킨 전달함수에 의해 피드백 계인을 구하였다. 그리고 본 논문에서의 실험 조건인 초기 에러를 57도, 즉 1라디안이라는 큰 값을 주었기 때문에 선형화 과정에서 무시한 비선형 항들의 값이 커졌기 때문인 것 같다. 따라서 다변수 시스템의 전달 함수를 구하기 힘든 경우 혹은 비선형성을 많이 가지고 있는 시스템의 경우는 본 논문에서 제안한 퍼지 학습법을 사용하는 것이 더 좋은 결과를 얻을 수 있음을 알 수 있었다.

### 참고문헌

1. 이호훈 and 조성근, An anti-swing control for 2 axis overhead cranes, *KACC*, 5(1), 1428-1431 (1996).
2. W. Gharieb and G. Nagib, Fuzzy control to multivariable systems case study : Helicopter Model, *Fuzzy-IEE*, 1, 400-405 (1996).
3. M. A. Goodrich, W. C. Stirling and R. L. Frost, A Satisficing Fuzzy Logic controller, *Fuzzy-IEE*, 1, 272-276 (1996).
4. T. J. Procyk, A Self-Organizing Controller For Dynamic Processes, Ph. D. Thesis, Queen Mary College, Univ. of London (1977).
5. T. Procyk and E. Mandani, A linguistic self-organizing process controller, *Automatica*, 15(1), 15-30 (1979).
6. S. Lee and R. Kil, A Gaussian Potential Function Network with Hierarchically Self-Organizing Learning, *Neural network*, 4, 207-224 (1991).
7. B. Chung and J. Oh, Control of dynamic systems using fuzzy learning algorithm, *Fuzzy sets and Systems*, 59(1), 1-14, (1993).
8. B. Chung and J. Oh, Autotuning method of membership function in a fuzzy learning control, *Journal of Intelligent & Fuzzy Systems*, 1(4), 335-349 (1993).
9. B. Chung and Y. Lim, Hybrid Fuzzy Learning Controller for an Unstable Nonlinear System, *IASTED*, 1, 79-81 (1996).

---

(1999년 1월 14일 접수, 1999년 3월 20일 채택)