

## 論 文

## 신경회로망을 이용한 퍼지룰의 추론과 학습에 관한 연구

正會員 李 啓 浩\* 正會員 任 永 撤\* 正會員 金 伊 坤\* 正會員 曹 京 英\*

The Study on Reasoning and Learning of Fuzzy Rules  
Using Neural Networks

Gyae Ho Lee\*, Young Chul Lim\*, I Gon Kim\*, Kyung Young Cho\* Regular Members

## 要 約

퍼지제어률은 일반적으로 시스템에 대한 전문오퍼레이터나 기술자가 갖고있는 애매모호함을 포함하고 있는 제어지식을 시스템의 입·출력 분할에 의해 if-then이라는 언어적 률로서 표현하는 것으로 전문오퍼레이터나 기술자의 제어지식 자체의 부정확과 률의 불완전등으로 완전하게 표현한다는 것은 대단히 어렵다. 이러한 불완전한 률의 정확도를 시스템 동작후에도 연속적으로 높이기위한 방법으로서 신경회로망에 의한 퍼지 추론과 학습을 제시한다. 이 방식은 시스템의 퍼지룰의 후건부를 층상신경회로망의 역전파(Back-propagation)학습방법에 의해 정확도를 증진시키고, 전건부의 적합도를 연상기억방식에 의해 추론하는 방식으로서, 이 방식을 이용하여 한정된 구역내에서 숙련된 기술과 지식이 필요한 차의 안전하고 신속한 정차를 위한 Auto-Parking Fuzzy Controller를 설계하고 시뮬레이션을 통해 그 타당성을 입증하였다.

## ABSTRACT

A rules of fuzzy control is to represent an expert's and engineer's ambiguous control knowledge of system with some linguistic rules. This rule is very difficult to represent perfectly because expert's knowledge is not precise and the rule is not perfect.

We propose the fuzzy reasoning and learning to upgrade precision of imperfect rules successively after system running. In the proposed method, the precision of the backward part of a fuzzy rule is improved by back propagation learning method. Also, the method reasons the compatibility degree of the forward part of a fuzzy rule by associative memory method. This method this is successfully applied to design auto-parking fuzzy controller in which expert's technology and knowledge are required in the limited area.

\*全南大學校 電氣工學科  
Dept. of Electrical Engineering, Chonnam National Univ.  
論文番號 : 93-25

## I. 서 론

퍼지제어[1,2]는 일반적으로 시스템이 복잡하고,

모델링이 거의 불가능한 시스템을 전문 오퍼레이터와 기술자가 갖고 있는 애매모호함을 포함하고 있는 제어지식을 언어적인 Rule 형식으로 표현하고, 퍼지 추론을 이용해서 제어량을 연산하는 제어 방식이다 [1,2,3]. Mamdani 이후 이 분야에 대한 응용이 넓게 제안되어서 산업분야에서 많은 연구가 진행되고 있다[3,4,5].

퍼지제어 시스템을 구성하는데 가장 곤란한 작업 중의 하나는 전문가나 기술자가 갖고 있는 지식을 획득하고, 획득된 지식을 퍼지룰로서 표현하는 것이다. 따라서, 퍼지룰은 애매모호한 정보나 주관적인 데이터를 취급하는 하나의 기본적인 형식으로 이때 획득된 거대한 전문지식과 데이터를 복수의 if-then 룰의 형식으로 정확하게 표현한다는 것은 전문가에게도 대단히 어렵다. 특히 전전부가 복수의 명제로 된 경우 이를의 전전부와 결론부의 관계를 정확하게 한다는 것은 곤란한 경우가 많다. 설계자는 전문가가 지식을 갖고 있는 제어모델이나 대상모델을 퍼지룰로서 표현하는데, 이때 전문가의 지식이나 시스템에 대한 데 이타가 불완전할 경우, 설계자는 많은 사례나 시뮬레이션의 결과를 이용하여 퍼지룰의 조정을 통해서 설계를 수행하지만, 그렇게 하면 시행착오로 인한 많은 시간과 노력이들므로 경제적이지 못한다. 지금까지는 이와 같이 설계가 시스템의 가동전 off-line 상태에서 퍼지룰의 조정으로 수행되고 있지만, 가동후에 있어서의 퍼지룰의 조정이나 퍼지변수의 가동수정에 의한 연속적 설계방식에 대한 연구는 거의 없는 실정이다. 따라서, 본 논문에서는 인간의 신경활동을 모델로 퍼지추론에서 갖지못하는 학습기능을 갖는 신경회로망[4,5,6,8]을 이용하여 시스템 가동전에 전문가로부터 얻어진 단편적인 지식과 전문가의 동작을 모델링하여 얻어진 한정된 데이터에 의해 지식 전체를 유추하고, 작성된 초기지식을 가동후 신경회로망을 이용하여 학습신호에 따라 수시로 그 지식을 자동조정에 의해 추가, 변경할 수 있는 새로운 방법을 제안한다. 이방법을 이용하여 Auto-parking controller를 설계하고 그 타당성을 시뮬레이션을 통해 입증한다.

## II. 퍼지 룰

퍼지룰의 작성과 추론방식에는 대상에 따라 다양한 방식이 제시되고 있다[3]. 퍼지추론방식에는 크게 3가지 방식으로 분류되는데 직접방식, 간접방식 그리

고 하이브리드방식으로 분류한다. 직접방식으로는 M- andani방식(Max-Min방식)[12]과 Larsen방식(Max-product 방식)[13], Mizumoto방식(Sum-product 방식)[14]이 있고 간접방식으로는 3단계추론방식인 Tsugamato방식이 대표적이다. 하이브리드방식에서는 일반적으로 시스템의 기술능력이 뛰어나고, 시스템의 안정도 판별이 가능한 Sugeno방식[15]과 Sugeno 방식의 후전부 선형방정식 대신에 싱글톤(Singletone)을 이용한 단순화된 방식이 있다. 이들 방식에는 각각의 특징을 갖고 있어 시스템의 특성에 따라 선정될 수 있다. 이들 중 지금까지 Sugeno 방식이 시스템의 기술능력이 가장 뛰어난 방식으로 알려져 있다. 본 연구에서는 전문가의 경험과 동작 모델을 Sugeno 방식의 퍼지모델을 이용하여 룰을 작성한다.

Sugeno 방식으로 퍼지룰을 표현하면 다음식과 같다.

$$\begin{aligned} R^i &= \text{if } x_1 \text{ is } A_1^i \& x_2 \text{ is } A_2^i \& x_3 \text{ is } A_3^i \& \dots \& x_r \text{ is } A_r^i \\ &\text{then } y^i = p_0^i + p_1^i x_1 + \dots + p_r^i x_r \end{aligned} \quad (1)$$

여기에서  $r$ 은 입력변수의 갯수,  $i = 1, 2, 3, \dots, n$ ( $n$ 는 룰의 수),  $x_1, x_2, \dots, x_r$ 은 입력변수이고,  $y^i$ 는  $i$ 번째 룰의 출력변수, 그리고  $p_0^i, p_1^i, \dots, p_r^i$ 는 후전부 선형방정식의 계수,  $A_j^i, j = 1, 2, 3, \dots, r$ ,  $i$ 번째의 룰의 각 입력변수에 대한 퍼지집합이다. 여기서 입력  $x_1^i, x_2^i, \dots, x_r^i$ 가 주어졌을 때  $i$ 번째 룰의 적합도(membership 함수) 값은 다음과 같이 주어진다.

$$w^i = \prod_{j=1}^r A_j^i(x_j^i) \quad (2)$$

그리고 이 값을 이용한 비퍼지값  $y$ 는 Weighted Average를 취하는 방식으로서 다음과 같이  $y$ 를 추론한다.

$$y = \sum w^i y^i / \sum w^i \quad (3)$$

이와같은 Sugeno 방식은 일반적으로 가장 기술능력이 우수한 방식으로 인정받고 있다. 이와 같은 장점에 비해 단점으로는 후전부의 선형방정식의 파라메터는 membership 함수와 관계되기 때문에 사전에 전문가의 지식이나 오퍼레이터의 동작에 따른 입력 공간에 있어서 제어대상에 대한 데이터를 얻어서 이를 membership 함수에 따른 최적의 출력을 얻기위

하여 비선형 프로그램에 의한 최적 파라메터를 찾는데 많은 시간과 노력을 소비하게 됨으로써 경제적이지 못한 결점을 갖고 있다. 이와 같은 단점을 보완하고 불확실한 모델링을 동작후에도 신경회로망의 학습방식[7,9,11,12]을 이용함으로써 보완시킬 수 있는 방식을 제시하고자 한다.

### III. 신경회로망을 이용한 퍼지제어기

#### 3.1 퍼지 룰의 표현

Sugeno 방식에 의한 퍼지룰이 기술능력이 높은 반면에 후건부의 파라미터 설정이 어려운 단점이 있으므로 이 단점을 보완하기 위한 방법으로서 신경회로망을 이용하여 룰의 후건부를 다음식과 같이 나타낼 수 있다.

$$\begin{aligned} R^1 \text{ if } x_1 \text{ is } A_1^1 \& x_2 \text{ is } A_2^1 \& \dots \& x_r \text{ is } A_r^1 \text{ then } \\ & y^1 = \ell_1(x) \\ & \vdots \\ R^n \text{ if } x_1 \text{ is } A_1^n \& x_2 \text{ is } A_2^n \& \dots \& x_r \text{ is } A_r^n \text{ then } \\ & y^n = \ell_n(x) \end{aligned} \quad (4)$$

단 여기서  $x = (x_1, x_2, \dots, x_r)^T$ ,  $\ell_i(\cdot)$ 는 퍼지선형 방정식의 신경회로망표현이다. 여기서 각각의 변수들은 Sugeno표현식에서와 동일하지만 후건부 선형 방정식을 sigmoid 함수로된 비선형방정식으로 표현되는것만이 다를 뿐이다. 본 논문에서 전체구성도는 구조화 신경회로망 연상기억방식으로 그림 1과 같이 표현된다. 전건부의 적합도는 각 입력요소에 대하여 독립적인 신경회로망을 구축한다. 후건부의 출력에 대한 기여도  $a_i (i=1, 2, \dots, n)$ 는 SNN-AM(Structured Neural Net-Associative Memory)[4,5,6]이 갖고 있는 연상기능에 의해 전건부의 적합도에 대한 연상 결과로서 얻어진다. 그림1.와 같이 기여도  $a_i (i=1, 2, \dots, n)$ 을 추론부에서,  $y^i$ 는 모델부에서 독립적으로 연산에 의하여 구해진다.

모델부의 동작은

$$\begin{aligned} y^i &= \ell_i(x) \\ &= s_i(W_{yh} \cdot h + Q_y) \end{aligned} \quad (5)$$

여기서  $h = s_i(W_{hx} \cdot x + Q_h)$ 이며  $s_i$ 는 sigmoid 함

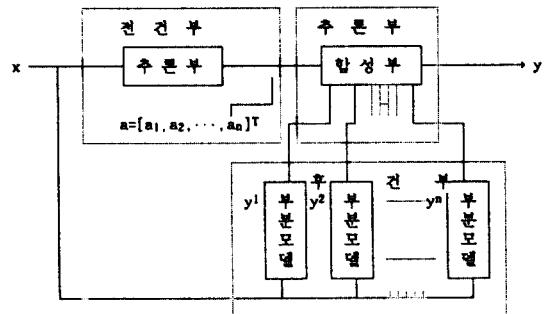


그림 1. SNN-AM의 구성도

Fig. 1. SNN-AM model

수이고,  $Q_h$ ,  $Q_y$ 는 hidden-layer와 output-layer의 bias이다. 또한  $W_{yh}$ 는 output-layer와 hidden-layer 사이의 weight 매트릭스이고  $W_{yx}$ 는 output-layer와 input-layer사이의 weight 매트릭스,  $W_{hx}$ 는 input-layer와 hidden-layer사이의 weight 매트릭스를 나타낸다. 그림1.의 추론부의 동작은 그림2.에서 보듯이 각 뉴런이 독립적으로 구성된다.

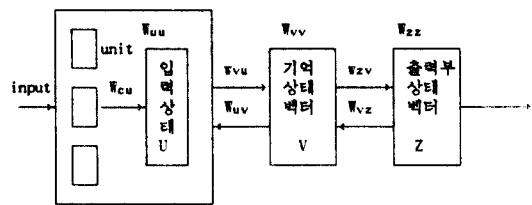


그림 2. 추론부의 구성도

Fig. 2. Architecture of reasoning unit

추론부의 동작을 연상기억의 이산-시(Discrete-Time) 상태로서 다음수식과 같이 표현된다.

$$\begin{aligned} c(k) &= A(x(k)) \\ u(k+1) &= s_i \{ W_{cu} c(k) + W_{uu} u(k) + W_{uv} v(k) \} \\ v(k+1) &= s_i \{ W_{vu} u(k+1) + W_{vv} v(k) + W_{vz} z(k) \} \\ z(k+1) &= s_i \{ W_{zv} v(k+1) + W_{zz} z(k) \} \quad k \geq 0 \quad (6) \end{aligned}$$

단,

$$\begin{aligned} u(0) &= u_0 \\ v(0) &= v_0 \\ z(0) &= z_0 \end{aligned}$$

$$A(x(k))^i = \prod_{j=1}^r A_j^i(x_j) \quad i(1, 2, 3, \dots, n) \quad (7)$$

n : rule의 수

r : 입력변수의 수

여기서  $W_{cu}(n \times n)$ 은 입력벡터  $c(n \times 1)$ 가 입력부로 부가되는 weight 메트릭스이고 다른  $W_{uu}(n \times n)$ ,  $W_{uv}(n \times n)$ ,  $W_{vn}(n \times n)$ ,  $W_{vv}(n \times n)$ ,  $W_{uz}(n \times n)$ ,  $W_{zv}(n \times n)$ ,  $W_{zz}(n \times n)$ 도 마찬가지로 각각의 상태에 대한 weight 메트릭스이다.  $u(n \times 1)$ 은 입력상태벡터,  $v(n \times 1)$ 은 기억상태벡터,  $z(n \times 1)$ 은 룰의 기여도  $a$ 로 출력상태벡터이다. 그리고  $A(x)$ 는 입력  $x$ 에 대한 각 룰의 적합도를 나타내는  $(n \times 1)$ 의 추론부의 입력을 나타낸다.

### 3.2 역전파 방식을 이용한 모델부의 학습

모델부의 중간층과 출력층 간의 weight 계수의 수정은 평가함수  $Ee$ 을 다음식과 같이 상기 오차로 정의한다. 교사데이터는 각 부분모델이 담당하고 있는 특정 공간에 적합한 것을 고른다. 교사데이터는 수시 실행의 제어결과에 따라서 갱신되어 있으므로 이것에 의해 사례에 의한 학습이 가능하게되고 추론결과의 정확도가 높아진다. 항상 학습이 이뤄지는 것이 아니고 기여도의 누적치  $\sigma T$ 가 큰쪽으로 학습이 이루어지는 데 이 값이 sigmoid값보다 클 때 역전파법에 의해 이루어진다. 그래서 출력층과 중간층 간의 계수  $w_{yh}$ 의 수정량  $\Delta W_{yh}$ 는 다음식으로 주어진다. 실시간과는 독립된 시간을 갖고 다음식과 같이 이루어진다. 모델부 자체의 학습으로서 back propagation 학습상태는 다음과으로 표현된다.

$$Ee = 1/2 (y^i - y_d^i)^2 \quad (8)$$

이면

$$\begin{aligned} \Delta W_{yh} &\equiv -\partial Ee / \partial W_{yh} = -(y + y_d) s'(U_y) y_h \\ \Delta W_{hx} &\equiv -\partial Ee / \partial W_{hx} = -(y + y_d) s'(U_y) y_{yh} s'(U_h) x_x \end{aligned}$$

이므로

$$\begin{aligned} \Delta W_{yh} &= q \{ -(y + y_d) s'(U_y) y_h \} \\ \Delta W_{hx} &= q \{ -(y + y_d) s'(U_y) W_{yh} s'(U_h) x_x \} \quad (9) \end{aligned}$$

여기서  $s'(0) = s(0)(1+s(0))$ 이다. 윗식에서  $y^i$ 는 i

번째 룰의 후건부 신경회로망의 실제추론치이고  $y_d^i$ 는 원하는 출력치로 교사신호라 부른다.  $U_h$ ,  $U_y$ 는 hidden-layer와 output-layer의 입력이고  $y_h$ ,  $y_y$ 는 hidden-layer와 output-layer의 출력,  $x_x$ 는 input-layer의 입력이다. 따라서, 학습의 다이나믹스는 다음식과 같이 얻어진다.

$$W_{yh}(k+1) = W_{yh}(k) + \alpha \Delta W_{yh}(k) \quad (10)$$

$$W_{hx}(k+1) = W_{hx}(k) + \alpha \Delta W_{hx}(k) \quad (11)$$

식 (10), (11)식에 의해 학습에 이루어진다. 이때  $\alpha$ 는 학습계수이다. 학습신호는 추론부와 모델부의 다이나믹스를 포함하여 평가함수  $Eet = 1/2(Z - Z_d)^2$ 에서

$$Eet = 1/2(Z - Z_d)^2 \quad (12)$$

여기서  $Z = \sum a^i y^i / \sum a^i$ 이고,  $Z_d$ 는 원하는 추론치이며 식 (12)식은 모델부와 추론부의 다이나믹스를 포함한 평가함수를 이용하여 이 신호의 임계값을 취하여 학습을 실행한다.

### 3.3 추론부의 학습

학습은 추론부와 부분모델부(총상 신경회로망)의 하중 메트릭스의 수정에 의해 달성된다. 따라서 학습은 일정 회수의 추론후에 행하는 것이 효율적이다. 추론부의 학습이라는 것은 룰의 정확도를 변경한다. 즉 결합하중을 조정하는 것이다. 룰의 정확도를 표시하는 메트릭스를  $W_{ac}(W_{ca})$ 라고 할 때 그 수정량  $\Delta W_{ac}$ 는 다음식에 의해 구해진다. 메트릭스 수정의 다이나믹스를 시스템의 동작시간과는 독립인 학습시간  $t$ 를 갖는 식으로 표현하면 다음과 같이된다.

$$w_{ac}(t)' = -w_{ac}(t) + Ra Xc \quad (13)$$

이 미분방정식의 해를 구하면

$$w_{ac}(t) = \exp(-t) \{ w_{ac}(0) - Ra \} + Ra \quad (14)$$

(14)식과 같다. 여기서  $W_{ac}(t) \in [0, \infty]$ ,  $Xc \in \{0, 1\}$ 으로  $c$ 에 대한 관계유무를 나타낸다.(여기서는 관계하는 것으로 1로 한다.)  $t$ 는 시스템의 동작시간과는 독립적인 학습시간이고,  $Ra \in [0, \infty]$ 은 사상  $a$ 에 대한 정확성을 나타낸다. 그러므로 이때 하중 메트릭

스의 각 요소들의 k번째의 학습과 k-1번째의 학습 사이에 대한 수정량은 두 수정량의 변화량이므로

$$\Delta W_{ac} = \exp[-T(k-1)] \{1 - \exp[-\sigma T]\} \{R_A - W_{ac}(0)\} \quad (15)$$

i) 되고 여기서  $\sigma T \cong \beta \min\{1, \eta \sum a_i / W_{ac}(k)\}$

$$\Delta W_{ac} = -\Delta W_{ca}$$

여기에서  $\beta$ 는 학습율,  $\eta$ 는 학습가속계수이며, 1회의 수정량을 조정하기 위한 계수이고  $a_i$ ,  $c$ 는  $W$ 의 각 요소의 지침이고,  $T(k-1)$ 는 k-1번째의 학습시간,  $\sigma T$ 는 k-1번째의 학습으로부터 k번째의 학습까지의 시간이다. 식(15)에 의하면 룰의 정확도에 대한 수정량은 그룹의 후진부의 출력으로의 기여도  $\sum a_i$ 에 비례하고 현재의 정확도( $W_{ac}(k)$ )에 반비례하는 것으로 결정된다. 즉 학습은 룰의 기여도가 큰쪽으로 진행된다.

#### IV. 시뮬레이션

시뮬레이션 대상은 이미 Sugeno교수에 의해 구현했던 한정된 구역내에서 숙련된 오피레이터에 의해 그림3.의 지정된 위치에 정확하게 차를 정차시키는 Auto-Parking Fuzzy Controller를 설계하고자 한다.

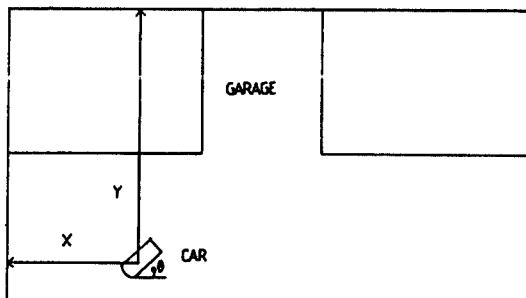


그림 3. 제어 위치

Fig. 3. CONTROL SITUATION

퍼지룰의 표현과 추론

차의 전진시 퍼지변수와 퍼지룰의 표현은

$$R^i \text{ if } x \text{ is } A^i \& y \text{ is } B^i \& \theta \text{ is } C^i \text{ then } f^i = \ell_i(x, y, \theta) \quad (16)$$

으로 그림 4와 같은 membership function을 갖는다.

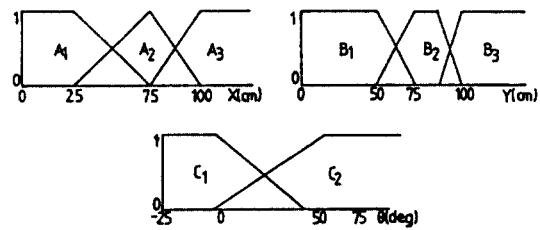


그림 4. 전진시 퍼지변수

Fig. 4. Fuzzy variables in moving forward

후퇴시 퍼지변수와 퍼지룰의 표현은

$$R^i \text{ if } x \text{ is } D^i \& y \text{ is } E^i \& \theta \text{ is } F^i \text{ then } b^i = \ell_i(x, y, \theta) \quad (17)$$

으로 그림5와 같은 membership function을 갖는다.

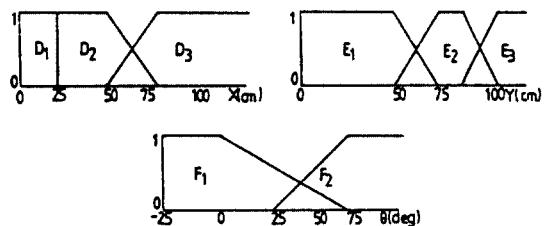


그림 5. 후퇴시 퍼지변수

Fig. 5. Fuzzy variables in moving backward

시뮬레이션에 있어서 과정은 그림 6과 같이 진행된다. 이 과정에서 logic S는 속도제어를 담당하는 부분으로서 전진시 한계구역과 후퇴시 한계구역을 퍼지함수가 아닌 크리스프함수로서 결정하도록 하였다.

#### 4.1 모델부 출력과 학습

모델부의 출력은 식(5)로부터

$$y^i = s_i(W_{yh} h + Q_y)$$

$$\text{여기서 } h = s_i(W_{hx} x + Q_h)$$

이식에서 초기값으로

$$x = \begin{bmatrix} x \\ y \\ \theta \end{bmatrix}, W_{hx} = \begin{bmatrix} .05 & -.2 & -.2 \\ -.2 & .05 & -.2 \\ -.2 & -.2 & .05 \end{bmatrix}, W_{yh} = \begin{bmatrix} .05 & -.2 & .. & -.2 & -.2 \\ -.2 & .05 & .. & -.2 & -.2 \\ .. & .. & .. & .. & .. \\ -.2 & -.2 & .. & .05 & -.2 \\ -.2 & -.2 & .. & -.2 & .05 \end{bmatrix}$$

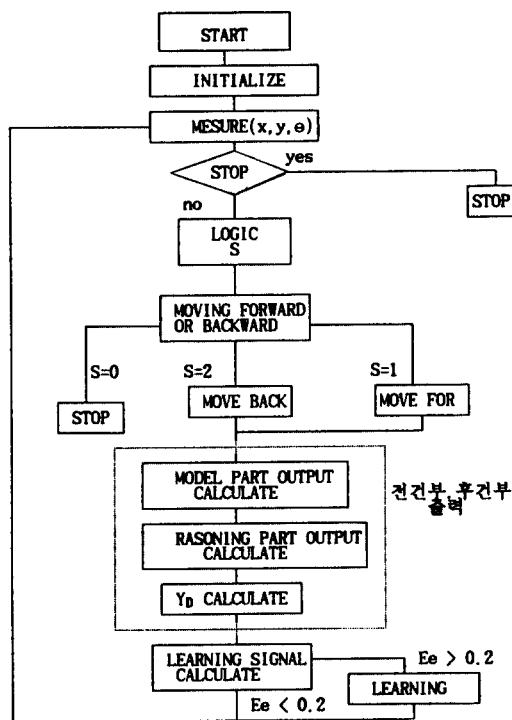


그림 6. 시뮬레이션의 흐름도  
Fig. 6. Flowchart of simulation

바이어스값  $Q_y, Q_h$ 는 편의상 0. 값으로 하였으며, 모델부의 학습은 식(10)의  $E_e = 1/2 (y - y_d)^2$ 를 학습 신호(14)로 하였고, 이때  $W_{hx}$ 와  $W_{yh}$ 의 수정량  $\Delta W_{hx}$ 와  $\Delta W_{yh}$ 는 다음식으로 주어진다. 실시간과는 독립된 시간을 갖고 다음식과 같이 이루어진다.

$$W_{yh}(k+1) = W_{yh}(k) + \alpha \Delta W_{yh}(k)$$

$$W_{hx}(k+1) = W_{hx}(k) + \alpha \Delta W_{hx}(k)$$

학습시간은 실시간과 독립으로 각각 5회, 학습율로서  $\alpha = 0.15$ 로 주었다.

#### 4.2 추론부의 출력과 학습

추론부의 동작은 식(6)에 의하여 연상기억에 의한 동작으로 다음과 같은 이산시 형태로 동작한다.

$$c(k) = A(x(k))$$

$$u(k+1) = s_i \{ W_{cu} c(k) + W_{uu} u(k) + W_{uv} v(k) \}$$

$$v(k+1) = s_i \{ W_{vu} c(k+1) + W_{vv} v(k) + W_{vz} z(k) \}$$

$$z(k+1) = s_i \{ W_{vz} v(k+1) + W_{zz} z(k) \}$$

단,

$$u(0) = u_0$$

$$v(0) = v_0$$

$$z(0) = z_0 \quad k \geq 0$$

이식에서  $c$ 는 전전부의 입력에 대한 퍼지 수를 sigmoid함수로 적절한 변환을 위해 적합한 수치로 시도하였다. 벡터  $u, v, z$ 의 초기치는 모두 0.으로 주었으며, 각각의 Weight Matrix의 초기값은 다음과 같이 주었다.

$$W_{cu} = \begin{bmatrix} 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 0 \end{bmatrix}, \quad W_{uu} = \begin{bmatrix} 0.15 & 0 & \dots & 0 \\ 0.15 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0.15 & 0 & \dots & 0 \end{bmatrix}, \quad W_{uv} = \begin{bmatrix} 0.0 & 0.0 & \dots & 0.0 \\ 0.0 & 0.0 & \dots & 0.0 \\ \vdots & \vdots & \ddots & \vdots \\ 0.0 & 0.0 & \dots & 0.0 \end{bmatrix}$$

$$W_{vu} = \begin{bmatrix} 0.0 & 0.0 & \dots & 0.0 \\ 0.0 & 0.0 & \dots & 0.0 \\ \vdots & \vdots & \ddots & \vdots \\ 0.0 & 0.0 & \dots & 0.0 \end{bmatrix}, \quad W_{vv} = \begin{bmatrix} 0.0 & 0.0 & \dots & 0.0 \\ 0.0 & 0.0 & \dots & 0.0 \\ \vdots & \vdots & \ddots & \vdots \\ 0.0 & 0.0 & \dots & 0.0 \end{bmatrix}, \quad W_{vz} = \begin{bmatrix} 0.0 & 0.0 & \dots & 0.0 \\ 0.0 & 0.0 & \dots & 0.0 \\ \vdots & \vdots & \ddots & \vdots \\ 0.0 & 0.0 & \dots & 0.0 \end{bmatrix}$$

$$W_{zz} = \begin{bmatrix} 0.0 & 0.0 & \dots & 0.0 \\ 0.0 & 0.0 & \dots & 0.0 \\ \vdots & \vdots & \ddots & \vdots \\ 0.0 & 0.0 & \dots & 0.0 \end{bmatrix}, \quad W_{vz} = \begin{bmatrix} 0.0 & 0.0 & \dots & 0.0 \\ 0.0 & 0.0 & \dots & 0.0 \\ \vdots & \vdots & \ddots & \vdots \\ 0.0 & 0.0 & \dots & 0.0 \end{bmatrix}$$

$$\Delta W_{vh} = \begin{bmatrix} 2.0 & -2.0 & -2.0 \\ -2.0 & 2.0 & -2.0 \\ -2.0 & -2.0 & 2.0 \end{bmatrix}, \quad \Delta W_{hh} = \begin{bmatrix} 0 & 15 & \dots & 15 & 15 \\ -15 & 0 & \dots & -15 & -15 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 15 & \dots & 15 & 15 \end{bmatrix}$$

$$\Delta W_{vh} = \begin{bmatrix} -1.25 & 1.25 & -2.0 \\ 1.25 & -1.25 & -2.0 \\ -2.0 & -2.0 & 2.0 \end{bmatrix}, \quad \Delta W_{hh} = \begin{bmatrix} 0 & 15 & \dots & 15 & 15 \\ -15 & 0 & \dots & -15 & -15 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 15 & \dots & 15 & 15 \end{bmatrix}$$

추론부의 학습은 다음식에 의해 이루어진다. 학습은 룰의 정확도를 변경시키는 것으로서,  $W_{vz}$ 하중 매트릭스의 수정으로 이루어진다. 따라서, 이때  $W_{vz}$ 의 각 element들의 수정량은 식(17)에 의하여 다음과 같이 이루어진다.

$$\Delta W_{ii} = \exp[-T_i(k-1)] \{1 - \exp[-\sigma T_i]\} \{R_A - w_{ii}(0)\}$$

$$\sigma T \leq \beta \min\{1, q \sum a_i / W_{ii}(k)\}$$

$$\Delta W_{ij} = \Delta W_{ii} \quad i \neq j$$

따라서 식(15)에 의해 학습이 이루어진다. 학습신호에 의해 학습은 수시로 룰의 기여도가 큰쪽으로 진행된다.

#### 4.3 시뮬레이션 결과 및 고찰

전문가의 동작모델과 경험에 의한 가장 이상적인 50개의 루트를 선정하여 각 위치별 상태에 따른 퍼지 모델링으로 초기지식을 작성하였다. 다음 컴퓨터 상에 나타난 궤적상의 위치 데이터와 오퍼레이터의 원하는 방향에 대한 값으로 학습시킨 하중메트릭스의 값을 초기값으로 시뮬레이션을 실행하였다.

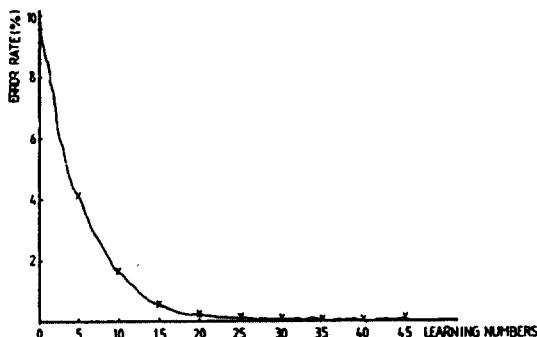


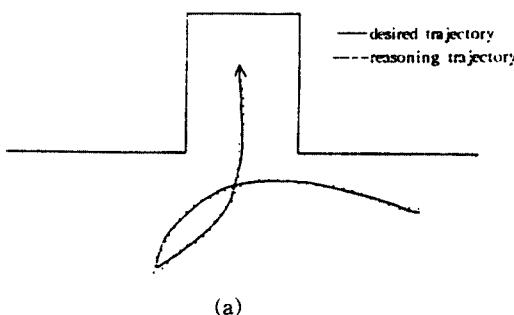
그림 7. 학습결과의 에러율의 분포

Fig. 7. Distribution of error rate

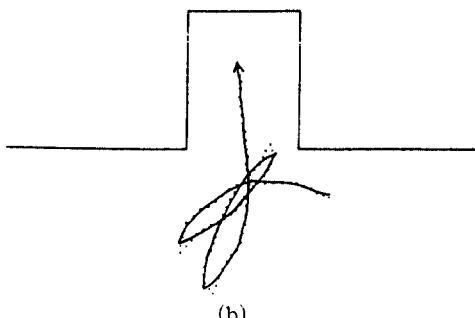
그림 7은 동작후 각위치에서의 시뮬레이션의 결과 원하는 핸들과의 에러분포를 나타낸것으로, 이때 틀의 정확도의 평가는

$$E(\text{에러율}\%) = 1/N \sum (y^i - y_d^i) / y^i \times 100(\%) \quad (18)$$

식(18)을 이용하여 평가하였다. 그림 7에서 보듯이 학습이 진행되는 동안의 에러율의 분포는 학습이 진행됨에 따라서 현저하게 감소하고 있음을 볼 수 있다. 그림8은 주차시 차의 궤적을 보여준다.



(a)



(b)

그림 8. 학습후 차의 궤적

Fig. 8. The Trajectory of a car after learning

20회 이상 학습후 결과치 Y는 전문가의 원하는 진행경로를 거의 완전하게 추적하는 시뮬레이션 결과를 보이고 있음을 알 수 있다. 그러나 더 이상의 학습으로도 리플 형태의 애러가 존재함을 알 수 있으나 거의 무시할 정도의 이 애러의 존재는 모델링을 위한 지식의 한계와 데이터의 한계성 및 Back Propagation의 학습방법의 한계성에 기인 함으로 모델링을 위한 정확한 지식과 충분한 데이터, 그리고 학습 방법의 개선으로 이 문제점은 해결되리라 사료된다.

## V. 결 론

본 논문의 신경회로망을 이용한 퍼지 룰의 추론과 학습 방법을 이용한 정차 시스템의 동작 시뮬레이션의 결과 초기지식에 대한 학습으로 정확도의 개선을 그림8.에서와 같이 원하는 결과에 근접하는 결과를 얻었다. 따라서 실제 퍼지제어기에 있어서 동작후 퍼지 룰의 연속적 조정으로 학습기능을 갖는 제어기 설계가 가능하게됨으로써 모델링이 어려운 복잡한 시스템의 퍼지 제어기 설계에 본 연구의 적용이 기대가 된다. 그러나 본 연구에서 퍼지를과 복잡한 신경회로망의 조합으로 계산시간이 너무 길어져 실시간 제어가 필요한 시스템의 설계가 어렵게되는 단점을 갖고 있다. 앞으로 이 부분에 대한 연구로 퍼지를의 전진부와 후진부의 맨베쉽함수로 표시되는 파라메타를 신경회로망의 부분적 사용에 의해 연속적으로 조정함으로써 신경회로망으로 전체 지식을 표현하지 않아도 같은 효과를 가져올 수 있는 새로운 방법에 대한 연구가 요구된다.

## 참 고 문 헌

1. M.Sugeno and K. Murakami, "An Experimental Study on Fuzzy Parking Control Using A model Car," Industrial Application of Fuzzy Control, Elsevier Science Publishers B.V. (North-Holland), pp125-138, 1985.
2. M.Sugeno, T.Murofushi, T.Mori, T.Tatematsu, J.Tanaka, "Fuzzy Algorithmic Control of A Model Car by Oral Instructions," Fuzzy Sets and Systems 32, pp.207-219, North-Holland, 1989.
3. L.I.Larkin, "A Fuzzy Logic Controller for Aircraft Flight Control," Industrial Application of Fuzzy Control, Elsevier Science Publishers B.V. (North-Holland), pp.87-103, 1985.
4. B.Kosko, "Bidirectional Associative Memories," IEEE, Trans. Syst. Man & Cybern., Vol. 18, No.1, pp.49-60, 1987.
5. S.Nakanishi & T.Takagi, "Construction of Fuzzy Controller using Neural Networks," Computer Today 1990/1(Science-sha), No.35, pp. 177-182(Japanese), 1990.
6. Hideyuki Takagi, "Fusion Technology of Fuzzy Theory and Neural Networks-Survey and Future Directions," proceedings of The International Conference on Fuzzy Logic & Neural Networks, pp.13-26, 1990.
7. T. Yamaguchi, "A Realizing Method for Learning Fuzzy Neural Netowrk," The 5th Fuzzy System Symposium, pp.157-168, 1989.
8. Y.Hayashi and M.Nakai, "Automated Extraction of Fuzzy Production Rules Using Neural Networks," The 5th Fuzzy System Symposium, pp.169-176, 1989.
9. John Yen, "The Role of Fuzzy Logic in The Control of Neural Networks," proceedings of The International Conference on Fuzzy Logic & Neural Networks, pp.771-774, 1990.
10. Norithito Kashiwagi and Toshikazu Tobi, "Neuro Fuzzy Inference System," proceedings of The International Conference on Fuzzy Logic & Neural Netowrks, pp.925-928, 1990.
11. Lee. C.C. "A Self-Learning Rule Based Controller Employing Fuzzy Logic and Neural Network Concepts," International Journal of Intelligent Systems, 1990.



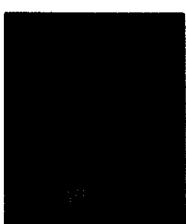
李 啓 浩(Gyae Ho Lee) 정회원  
1926년 1월 30일 생  
1958년 : 서울대 공대 졸업  
1982년 : 전북대 대학원 졸업(석사)  
1965년 12월 14일 ~ 1991년 3월 : 전  
남대 공대 교수  
현재 : 전남대 명예 교수, 포스콘 이  
사



任 永 澈(Young Chul Lim) 正會員  
1953년 4월 23일 생  
1975년 : 전남대 공대 전기공학과  
졸업  
1977년 : 고려대 대학원 전기공학과  
졸업(석사)  
1990년 : 고려대 대학원 전기공학과  
졸업(박사)  
현재 : 전남대 공대 전기공학과 부교수



金 伊 坤(I Gon Kim) 正會員  
1955년 11월 11일 생  
1985년 : 동아대 전자공학과 졸업  
1988년 : 한국항공대 대학원 전자공  
학과 졸업(석사)  
1993년 : 전남대 대학원 전기공학  
과 졸업(박사)  
현재 : 순천대, 여수수대 강사



曹 京 英(Kyung Young Cho) 正會員  
1962년 9월 19일 생  
1987년 : 전남대 공대 전기공학과  
졸업  
1990년 : 전남대 대학원 전기공학과  
졸업(석사)  
현재 : 전남대 대학원 전기공학과  
박사과정