

## 뉴로퍼지방식 광유도식 무인반송차의 경로추종 제어

### A Path-Tracking Control of Optically Guided AGV Using Neurofuzzy Approach

임 일 선, 허 육 열  
(Il-Seon Lim and Uk-Youl Huh)

**Abstract :** In this paper, the neurofuzzy controller of optically guided AGV is proposed to improve the path-tracking performance. A differential steered AGV has front-side and rear-side optical sensors, which can identify the guiding path. Due to the discontinuity of measured data in optical sensors, optically guided AGVs break away easily from the guiding path and path-tracking performance is being degraded. Whenever the On/Off signals in the optical sensors are generated discontinuously, the motion errors can be measured and updated. After sensing, the variation of motion errors can be estimated continuously by the dead reckoning method according to left/right wheel angular velocity. We define the estimated contour error as the sum of the measured contour in the sensing error and the estimated variation of contour error after sensing. The neurofuzzy system consists of incorporating fuzzy controller and neural network. The center and width of fuzzy membership functions are adaptively adjusted by back-propagation learning to minimize the estimated contour error. The proposed control system can be compared with the traditional fuzzy control and decision system in their network structure and learning ability. The proposed control strategy is experienced through simulated model to check the performance.

**Keywords :** AGV, neurofuzzy, path-tracking control

#### I. 서론

각종 물류의 흐름과 제어를 빠른 시간 내에 효율적으로 처리하기 위하여 자체적으로 진행방향을 변경할 수 있는 조향기능을 갖고 지정된 경로를 지능적으로 주행할 수 있는 무인반송차(AGV)의 필요성이 증가되고 있다[1]. 대부분의 AGV는 유도경로를 필요로 하는데 경로의 형태에 따라 다음과 같이 분류할 수 있다. 지정된 경로를 연속적으로 추종하는 고정경로식, 주행 경로 상에 표식을 적당한 위치에 설치하고 AGV가 이를 검출하여 주행하는 반경로식, 유도선이나 유도설비 등의 외부의 지원 없이 차체에 설치된 바퀴의 엔코더나 카메라의 비전시스템 등으로 위치 측정을 하면서 스스로 주행경로를 생성하는 자율 주행식으로 나눌 수 있다[2].

광유도식은 고정 경로식의 한 형태인데 바닥 표면에 광학테이프를 설치하여 유도경로로 한다. 광유도식은 레일 설치에 비하여 궤도를 이탈할 가능성이 크지만 생산공정의 변경 시에 대처하기 용이하고 직선 및 곡선 등 작업공간의 형태에 따라 설치가 용이하고 경제적이므로 공장에서의 작업에 투입하기가 적합하다. 차체가 광센서를 부착하여 유도 경로상을 주행하는데, 추종상태에 따라서 광센서에서 온/오프 신호가 검출되어 진다. 센서검출 신호로부터 경로 추종상의 동적오차가 계산되어지는데, 경로로부터의 이탈 거리인 윤곽오차( $e_c$ )와 원치 않는 조향 각도인 방향 오차

( $e_\theta$ )로서 나누어진다. 광유도식AGV는 필연적으로 수반되는 동적 오차와 센서검출의 비연속성으로 인하여 경로를 이탈하게 되며 경로 추종시에 성능저하의 원인이 된다[3].

본 연구에서는 광센서로부터 검출되는 이산적이며 비연속적인 정보로부터 연속적인 동적 오차를 계산하는 알고리즘을 제안하였다. 또한 시스템의 모델에 기초하지 않고 인간의 지식이나 경험을 바탕으로 구성할 수 있는 퍼지제어기에 시스템의 동적 오차를 최소화시키기 위하여, 퍼지 제어기의 멤버쉽 함수의 계수를 적응조정 하는 학습능력을 가진 신경회로망을 설계하여 구해진 오차를 동시에 보상하는 뉴로퍼지제어기를 사용하였다.

뉴로퍼지제어기는 신경회로망을 기본으로 하여 퍼지 제어기를 통합하여 피드퍼워드의 다층의 망의 형태를 갖는다. 퍼지 추론엔진의 합성을 수행하기 위해 전건부 멤버쉽 함수는  $e_c$ ,  $e_\theta$ 의 두 입력을 갖고 함수의 클립 값이 각 룰 베이스에 의하여 가중되어지고, 무게 중심법에 의하여 적절한 출력을 발생시킨다. 즉, 조향각도  $\hat{\nu}_d$ 와 추종속도  $\hat{v}$ 의 지령이 계산되어 진다. 이때 부가된 신경회로망에 의하여, 퍼지제어기의 가우시안 분포를 가진 멤버쉽 함수에서 자승 오차를 규정하고, 최소자승오차를 얻기 위하여 멤버쉽 함수의 평균과 분산을 조정한다. 학습상의 계수들은 Gradient decent 알고리즘을 사용함으로써 신경계층의 역전파(Back-Propagation) 학습에 의해 적응적으로 조정되어 진다.

본 연구의 뉴로퍼지제어기의 자승오차로서는 추정 윤곽 오차가 사용되는데, 이는 본 연구에서 제안된 알고리즘을 통하여 비연속적인 윤곽오차를 연속적인 윤곽오차의 형태로서 변형시킨 것이다. 센서의 온/오프 상태가 검출될 때 계산되어지는 윤곽오차를 추정 윤곽 오차라 하면, 차체 양

접수일자 : 2001. 6. 15., 수정완료 : 2001. 8. 10.  
임일선, 허육열 : 인하대학교 대학원 전기공학과(islim@kopo.or.kr/  
uyuhuh@inha.ac.kr)  
※ 본 논문은 산업자원부에서 차세대 신기술연구개발사업 지원하  
에 연구하였습니다.

바퀴에 부착된 펄스엔코더에서 각속도를 검출하여 Dead-Reckoning방법에 의하여 도출된 윤곽오차의 증분(variation)을 측정윤곽오차에 가산하면 차체의 윤곽오차가 샘플링 시간마다 연속적으로 추정되며 이를 추정윤곽오차로 규정하였다.

본 연구에서는 추정윤곽오차의 절대크기를 오차함수로서 설정하였다. 이 오차함수를 최소화하는 것을 적응제어의 지표로 함으로써 연속적인 학습이 가능케 되었고, 이로써 경로추종에서의 이탈을 방지하고 경로추종 성능이 향상되어 진다.

## II. 광유도식 AGV의 구조와 동적오차 분석

그림 1에서는 본 연구에서 사용한 광유도식 AGV의 구조를 보여준다. 구동 방식은 양 바퀴의 속도차를 이용한 조향방식으로서 조향과 구동을 동일한 모터로 수행하는 차륜구동 방식을 사용하였다. 직류 모터가 차체의 양쪽 바퀴에 연결되어 있는데, 모터에는 무인차의 위치와 진행 방향 각을 계산하기 위해 엔코더가 내장되어 있다. 마루 위에 자기테이프 표식을 붙임으로써 유도경로가 생성되며, 차체에 전방 5개, 후방 5개의 광학 센서를 부착함으로써 유도경로를 인식할 수 있다.

로보트의 동적오차는 그림 2에서 보여진 대로  $e_\theta$ ,  $e_c$ 와  $e_r$ 의 성분으로 분해되어진다. 여기서 방향 오차( $e_\theta$ )는 AGV의 진행방향과 원하는 위치의 접선과의 각도의 차이로서 규정된다. 윤곽오차  $e_c$ 는 실제 AGV의 위치에서 원하는 위치와의 접선과 평행한 접선을 그어 이 두 접선 사이의 거리로 나타내고, 추적오차  $e_r$ 는 실제위치와 원하는 위치와의 진행 방향으로의 거리이다. 이 중 방향오차와 윤곽오차는 경로추종에 있어서 반드시 보상해야 할 중요한 오차성분이고, 이것을 최소화시키는 것이 경로 추종의 핵심이다.

그림 3에서 차량의 위치와 방향각에 따라 광센서에서 온/오프 신호가 비연속적으로 발생되는데, 광센서와 유도선이 인접하는 순간 윤곽오차와 방향 오차가 생신되어 식(1), (2)와 같이 이론적으로 계산되어진다.

$$e_c(0) = \frac{2z - f - r}{2} S_d \cos e_\theta(0) \quad (1)$$

$$e_\theta(0) = \tan^{-1} \left( \frac{\overline{ed}}{ae} \right) = (-1)^q \tan^{-1} \frac{|r-f|}{L} S_d \quad (2)$$

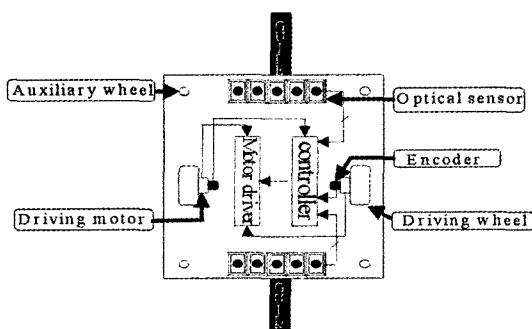


그림 1. AGV의 구조.

Fig. 1. The structure of AGV.

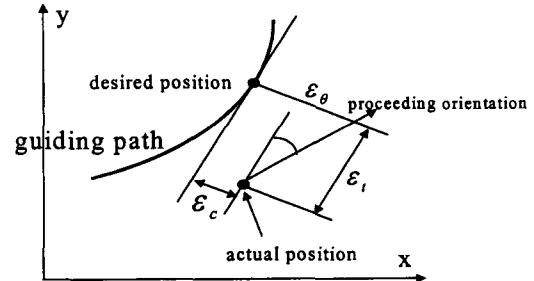


그림 2. 동적오차의 성분.

Fig. 2. Motion error decomposition.

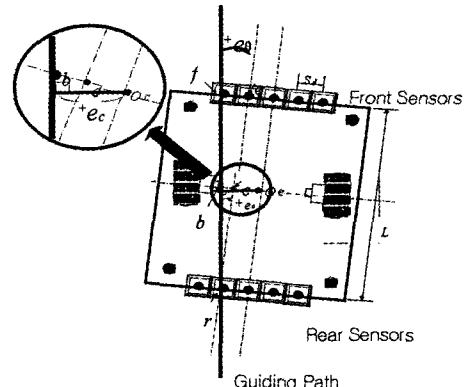


그림 3. AGV의 동적오차 분해.

Fig. 3. Motion error decomposition of AGV.

여기서  $S_d$ 는 센서 사이의 거리,  $L$ 은 전방센서와 후방센서 사이의 직선거리,  $f$ 와  $r$ 은 전방센서와 후방센서의 각각 순번이다.

$$(r-f) > 0\text{일 때}, q=0\text{이 되며},$$

$$(r-f) < 0\text{일 때}, q=1\text{이 된다.}$$

$$n\text{이 짹수일 때 } z = \frac{n}{2} + 0.5 \text{ 이고,}$$

$$n\text{이 홀수일 때 } z = \frac{n}{2} - 0.5 \text{ 가 된다.}$$

그림 4에서와 같이, 모터에 부착된 엔코더로부터 양바퀴의 각속도  $\nu_L(t)$ ,  $\nu_R(t)$ 가 각각 계측되며, 바퀴의 각속도에 따라서 선속도( $w(t)$ ), 각속도( $\nu(t)$ ), 윤곽오차의 변위  $\Delta e_c(t)$  그리고 방향오차의 변위( $\Delta e_\theta(t)$ )가 Dead-reckoning 방법에 의하여 추정되어지며 다음과 같다.

$$w(t) = \frac{\nu_L(t) - \nu_R(t)}{D} R, \quad \nu(t) = \frac{\nu_L(t) + \nu_R(t)}{2} R \quad (3)$$

$$\Delta e_c \cong \frac{R}{2} \int_0^t \{ \nu_L(t) + \nu_R(t) \} \sin \theta(t) dt \quad (4)$$

$$\Delta e_\theta \cong - \frac{R}{D} \int_0^t \{ \nu_L(t) - \nu_R(t) \} dt \quad (5)$$

(1)(2)는 센서검출 때마다 생신되는 동적오차의 대신호 성분(직류분)이라 할 수 있는데 센서가 검출시에 생신되는 비연속적인 신호이다. (4)(5)는 동적오차가 생신된 후 Dead-

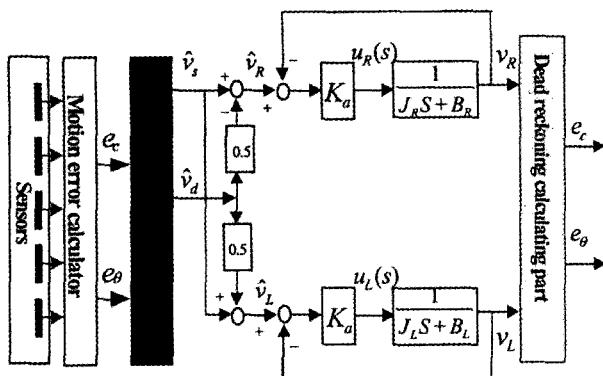


그림 4. AGV 시스템의 블록도.

Fig. 4. Block diagram of AGV system.

reckoning 방법에 의해서 계산되어지는 동적 오차의 소신호 성분(교류분), 즉 동적 오차의 증분이라고 할 수 있다[4]. (1)(2)와 (4)(5)를 합성함으로써 AGV의 추정윤곽오차가 연속적으로 정의되며 각각 (6),(7)과 같다.

$$e_c(t) = e_c(0) + \Delta e_c(t) \quad (6)$$

$$e_\theta(t) = e_\theta(0) + \Delta e_\theta(t) \quad (7)$$

본 연구에서는 (6)의 추정윤곽오차의 절대크기를 뉴로퍼지제어기에서 학습의 오차함수,  $E$ 로서 규정하여 사용되어 진다.

$$E = |e_c(t)| = |e_c(0) + \Delta e_c(t)| \quad (8)$$

### III. 뉴로퍼지제어기 설계

#### 1. 퍼지논리 제어기의 기본적 구조

그림 5는 본 연구의 퍼지논리제어기의 기본적 구조를 보여주는데, 제어기는 조향 각도 구동계와 주행 속도 구동계로 나누어지며 각각 퍼지집합과 언어적 변수로서 구성되어 있다.

Universe of discourse에 있어서 퍼지집합  $F$ 는  $\mu_F$ 의 멤버쉽 함수에 의해 특성화되어 지는데 가우시안 분포를 이루며  $[0,1]$  구간의 값으로 주어진다.

$$\text{즉 } \mu_F : U \rightarrow [0,1].$$

$U$ 에 있어서 언어적 변수  $x$ 는

$$T(x) = \{T_x^1, T_x^2, \dots, T_x^k\} \text{ 와}$$

$$M(x) = \{M_x^1, M_x^2, \dots, M_x^k\} \text{ 로 특성화되어 진다.}$$

여기서  $M(x)$ 는  $U$ 에서 정의된 멤버쉽 함수  $M_x^i$ 의 집합이고,  $T(x)$ 는 언어적 값에 의해 명명되어진  $T_x^i$  집합이다.

예를 들어  $x$ 가 윤곽오차를 가르친다면  $T(x)$ 는 {NL(Negative Large), NS(Negative Small), Z(Zero), PS(Positive Small), PL(Positive Large)}로 표현된다.

위의 정의에 따라 입력벡터  $X$ 는 입력상태 언어적 변수  $x_i$ 들을 포함하고, 출력벡터  $Y$ 는 출력상태 언어적 변수  $y_i$

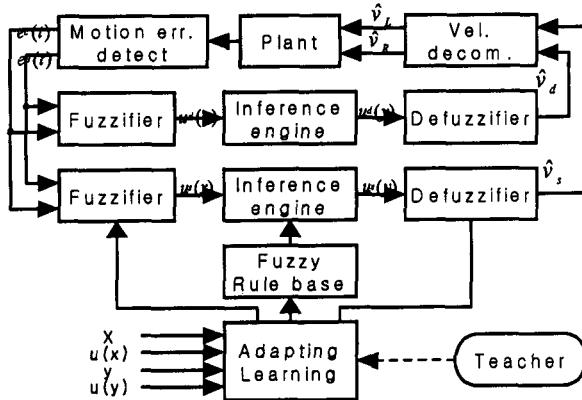


그림 5. 퍼지제어기와 결정시스템의 기본적 구조.

Fig. 5. Basic model of fuzzy logic controller and decision making system.

들을 포함한다.

시간  $t$ 에서 특정한 값  $x_i(t)$ 에 대하여,  $M_{x_i}^1(x_i(t))$ 의 등급에서 퍼지집합  $T_{x_i}^1$ 이 그리고  $M_{x_i}^2(x_i(t))$ 의 등급에서, 퍼지집합  $T_{x_i}^2$ 가 사상되어 진다.

퍼지 룰베이스는 퍼지논리를  $R$ 의 집합으로 표현되는데, 본 연구의 퍼지제어기는 MISO(multi input and single output) 시스템의 형태를 가지며, 시스템의 룰베이스는  $R = \{R_{MISO}^1, R_{MISO}^2, \dots, R_{MISO}^n\}$  이 되고,

여기서  $j$ 번째의 퍼지논리 룰은

$$R_{MISO}^j : \text{IF } (x_1 \text{ is } T_{x_1}^1, \text{ 그리고 } \dots, \text{ 그리고 } x_p \text{ is } T_{x_p}^p)$$

Then ( $y$ 는  $T_y$ )이 된다[5].

$R_{MISO}^j$ 의 전진부의  $j$ 번째 firing strengths는  $\alpha = \min(M_{x_1}^j, \dots, M_{x_p}^j)$ 의 클립(clip)값이 되고, 후진부는  $\widehat{M}_y(w) \max(\widehat{M}_y^1(w) \vee \dots \vee \widehat{M}_y^n(w))$ 의 제어기 출력으로 된다.

여기서  $\vee$ 는 퍼지의 OR 연산이고  $w$ 는 멤버쉽 함수의 지지값(support value)을 나타내는 변수이다.

그림 5의 비퍼지화(defuzzifier) 블록에서 클리스 결정(crisp decision)을 얻는다. 이때 무게중심법(centroid gravity)을 사용한 비퍼지화 출력은

$$y = \frac{\sum_i \widehat{M}_y^i(w_i) w_i}{\sum_i \widehat{M}_y^i(w_i)} \quad (9)$$

가 된다.

#### 2. 뉴로퍼지시스템

##### 2.1 뉴로 퍼지논리제어 및 결정시스템

본 연구에서는 그림 6에서와 같이 신경망으로 구성된 5 계층의 연결형(Connecionist) 모델이 사용되었다.

신경망은 다른 유니트들로부터 입력값을 받아 가중치에 곱하여 출력하는 fan-in과, fan-in으로부터의 입력값을 받아 함수 연산후 출력하여 연결시키는 fan-out으로 이루어져 있는데, 신경망 입력 출력 기본 함수들이 각각 (10)과 (11)로서 정의되었다.

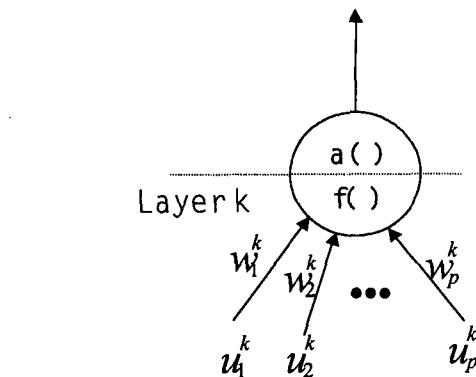


그림 6. 신경망 노드의 기본구조.

Fig. 6. Basic structure of a node in a neural Network.

$$\text{네트입력} = f(u_1^k, u_2^k, \Lambda, u_p^k, w_1^k, 1w_2^k, \Lambda, w_p^k) \quad (10)$$

여기서 웨이트는 계층을 나타내며,  $u_1^k, u_2^k, \Lambda, u_p^k$ 는 입력 그리고  $w_1^k, 1w_2^k, \Lambda, w_p^k$ 는 가중치를 나타낸다.

$$\text{네트출력} = o_i^k = a(f) \quad (11)$$

여기서  $a(\cdot)$ 은 네트출력 함수를 나타낸다.

이러한 연결형(connectionist) 모델은 퍼지논리제어와 신경망 구조를 조합한 통합형태로서, 즉 신경망을 기반으로 한 퍼지논리제어와 결정시스템의 feedforward 다중망의 형태가 된다.

AGV 시스템에서는 그림 7에서와 같이 앞절에 기술된 퍼지제어기를 5개의 계층의 신경망의 연결형 모델로서 구성하였다. 각각의 계층에서 노드의 함수가 제안되었으며, 계층간의 연결형모델은 다음과 같다[6].

$$\text{계층 1 : } f = u_i^1 \text{ and } a = f \quad (12)$$

$$\text{계층 2 : } f = M_{xi}^i(m_{ij}, \sigma_{ij}) = \frac{(u_i^2 - m_{ij})^2}{\sigma_{ij}^2} \text{ and } a = e^f \quad (13)$$

$$\text{계층 3 : } f = M_{xi}^i(m_{ij}, \sigma_{ij}) = \frac{(u_i^2 - m_{ij})^2}{\sigma_{ij}^2} \text{ and } a = e^f \quad (14)$$

$$\text{계층 4 : } f = \sum_{i=1}^p u_i^4 \text{ and } a = \min(1, f) \quad (15)$$

$$\text{계층 5 : } f = \sum w_{ij}^5 u_i^5 = \sum (m_{ij} \sigma_{ij}) u_i^5 \text{ and } a = \frac{f}{\sum \sigma_{ij} u_i^5} \quad (16)$$

계층 2와 계층 5에서 fan-in은 가우시안(Gaussian) 형태의 퍼지멤버쉽 함수로 이루어져 있는데, 여기에서  $M_{xi}^i(m_{ij}, \sigma_{ij})$ 는  $i$ 번째 입력의 언어적 변수의  $j$ 번째 룰의 중심값이  $m_{ij}$ , 분산이  $\sigma_{ij}$ 가 된다. 계층 5의 링크웨이트  $w_{ij}$ 는  $m_{ij} \sigma_{ij}$ 가 된다.

본 연구에서는 신경망의 연결형 구조에 기초하여 하이

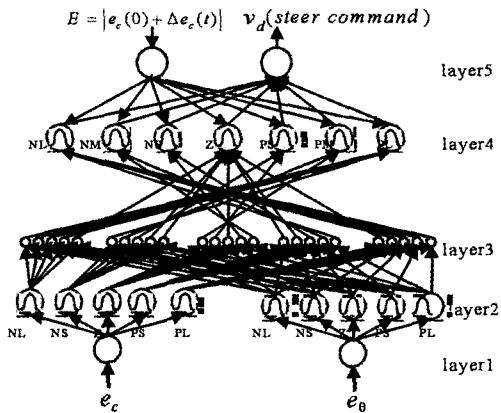


그림 7. 연결형 퍼지논리 제어/결정 시스템(조향각도 구동계).

Fig. 7. The connectionist fuzzy logic Control/decision systems (steering driving part).

브리드 학습 알고리즘이 사용되었다.

먼저 에러함수  $E$ 가 설정되고 이 함수값을 최소화하기 위하여 Gradient descent 알고리즘을 사용한 역전파(BP: Back-Propagation) 학습을 통해 최적화된 계수값 평균( $m$ )과 분산( $\sigma$ ) 값이 적응 조정되어 사용되어진다. 또한 전방향 경로를 통하여 방향 오차와 윤곽 오차 값이 제어기에 입력되면, 퍼지 제어 및 결정 시스템에서 조정된 계수값으로써의 구동 출력이 발생되어 시스템 구동을하게 된다. 이와 같이 퍼지제어 구조와 신경망 구조가 혼합된 하이브리드 학습알고리즘을 통한 학습을 통하여 최적의 적응제어를 행하게 되는데 이를 뉴로퍼지제어 시스템이라고 한다.

한편 계층 1에서 윤곽 오차와 방향오차를 입력받아 계층 5에서 조향각도 지령( $\hat{v}_d$ )과 주행속도 지령( $\hat{v}_s$ )을 각각 출력하게 된다.

## 2.2 뉴로퍼지제어알고리즘

에러함수에 대하여 출력마디로부터 시작하여 역방향으로 전파에 의한 학습을 하여 모든 숨겨진 마디(hidden node)의 중심과 폭의 계수를 조정도록 하는데,  $w$ 를 마디에서 조정되어질 수 있는 계수라 하면 일반적인 Gradient descent 학습률은 다음과 같다.

$$\Delta w \propto -\frac{\partial E}{\partial w} \quad (17)$$

$$w(t+1) = w(t) + \eta \left( -\frac{\partial E}{\partial w} \right) \quad (18)$$

여기서  $\eta$ 는 학습률(learning rate)이며, 에러함수  $E$ 는 추정 윤곽오차의 절대크기로서 규정된다.

## 조향각도 구동계에서

$$\frac{\partial E}{\partial w} = \frac{\partial E}{\partial v_d} = -\frac{|E(t+1) - E(t)|}{v_d(t+1) - v_d(t)} \quad (19)$$

이며, 최소자승 학습 알고리즘을 통하여 그림 7에서의 계층 2와 계층 5의 현재의 계수( $m(t), \sigma(t)$ )로부터 학습된

계수  $(m(t+1), \sigma(t+1))$  가 최신화되어 진다.

각 계층의 뉴우런에서 사용된 역전파 학습 알고리즘은 다음과 같다.

[계층 5] 계층 5에서 무게중심에 의한 비퍼지화수와 BP 학습률은 다음과 같다

조향각도 구동계에서

1) 비퍼지화수:

$$f = \sum w_{ij}^5 u_i^5 = SSum(m_{ij}\sigma_{ij})u_i^5 \text{ and } a = \frac{f}{\sum \sigma_{ij}u_i^5} \quad (20)$$

2) BP학습률 :

$$m_i(t+1) = m_i(t) - \eta_m^5 \frac{\partial e}{\partial m_i} = m_i(t) - \eta_m^5 \frac{\partial E(t)}{\partial v_d} \cdot \frac{\partial_i u_i}{\sum \sigma_i u_i} \quad (21)$$

$$\sigma_i(t+1) = \sigma_i(t) - \eta_\sigma^5 \frac{\partial E(t)}{\partial v_d} \cdot \frac{m_i u_i (\sum \sigma_i u_i) - u_i (\sum m_i \sigma_i u_i)}{(\sum \sigma_i u_i)^2} \quad (22)$$

3) 역전파에러신호:

$$\delta^5 = -\frac{\partial E}{\partial f^5} = -\frac{|E(t+1) - E(t)|}{v_d(t+1) - v_d(t)} \quad (23)$$

가 되는데, 역전파 에러신호는 하위 계층에 역전파되어 학습에 이용되어 진다.  $u_i$ 값은 후건부 멤버쉽 함수의  $i$ 번째 Max-clip값으로 규정된다.

$\eta_m^5, \eta_\sigma^5$ 는 각각 계층 5에서의 조향각도 구동계의 평균과 분산의 학습률로 규정되는데, 계층 5에서는 이러한 학습율을 가지고 퍼지의 후건부에서의 언어적 변수의 평균과 분산값이 학습률에 의해 에러 함수값이 최소화 되도록 적응적으로 조정되어진다. 본연구에서는 주행 속도구동계에서는 학습을 행하지 않았으며, 따라서 퍼지제어기의 분산 및 평균값도 초기치로부터 변화되지 않도록 하였다.

[계층 4] : 이 계층에서 조정되어지는 계수값은 없고, 단지 에러신호  $\delta_i^4$ 만이 역전파 되어진다.

$$\delta_i^4 = \frac{\partial E}{\partial f_i} = -\frac{|E(t+1) - E(t)|}{v_d(t+1) - v_d(t)} \cdot \frac{m_i \sigma_i (\sum \sigma_i u_i) - \sigma_i (\sum m_i \sigma_i u_i)}{(\sum \sigma_i u_i)^2} \quad (24)$$

가 된다.

[계층 3]

$$-\delta_i^3 = -\delta_i^4 \quad (25)$$

[계층 2]  $m_{ij}$ 의 적용률은 다음과 같다.

$$\frac{\partial E}{\partial m_{ij}} = \frac{\partial E}{\partial a_i} \frac{\partial a_i}{\partial f_i} \frac{\partial f_i}{\partial m_{ij}} = \delta_i^4 \frac{\partial E}{\partial a_i} e^{f_i} \frac{2(u_i - m_{ij})}{\sigma_i^2} \quad (26)$$

$$m_{ij}(t+1) = m_{ij}(t) - \eta_m^2 \frac{\partial E}{\partial a_i} e^{f_i} \frac{2(u_i - m_{ij})}{\sigma_i^2} \quad (27)$$

여기서  $u_i$ 값은 전건부 멤버쉽 함수의 Min-clip값이다. 마찬

가지로  $\sigma_{ij}$ 의 학습률은

$$\sigma_{ij}(t+1) = \sigma_{ij}(t) - \eta_\sigma^2 \delta_{kj}^4 e^{f_i} \frac{2(u_i - m_{ij})^2}{\sigma_{ij}^3} \quad (28)$$

이 된다.  $\eta_m^2, \eta_\sigma^2$ 는 각각 계층2에서의 조향각도의 평균과 분산의 학습률로 규정되어 선정되어진다

#### IV. 모의실험

본 연구의 AGV 시스템은 그림 10에서 보여진 데로 Matlab 코딩을 사용하였고, 10[ms]의 샘플링 시간으로써 모의실험을 행하였다. 그림 3의 차체(AGV) 부분에서

- 센서간의 거리( $S_d$ )는 0.02[m],
- 전방센서와 후방센서의 직선거리( $L$ )은 0.75[m],
- 양바퀴간의 거리는 0.35[m],
- 양바퀴의 반지름은 0.085[m]로 각각 선정하였다.
- 양바퀴에 커플링된 모터의 관성 모멘트와 마찰계수는
  - $J_R = 1.4008, J_L = 1.4666 [kg \cdot cm^2]$ ,
  - $B_E = 4.2194, B_L = 4.4444 [N \cdot mm/rad/sec]$ 로서 선정하였다.

그림 10의 모의실험 블록도에서 센서 검출시 동적 오차를 개선하였고, 센서에서 파형이 개선되지 않을 때에는 모터에 부착된 펄스엔코더의 속도를 계측하여 Dead-Reckoning 방법을 사용하여 동적오차의 변화분을 추정하고, 이를 추정 윤곽 오차의 교류분으로 이용하였다. 센서계산부에서 계산된 동적오차 직류바이어스 분과 Dead-Reckoning부에서 추정된 동적오차 변화분을 중첩하면 추정윤곽 오차값이 추정되며 추정윤곽 오차의 절대크기를 gradient descent 학습 알고리즘의 에러함수  $E$ 로서 사용하여 계수조정 학습을 행하였다.

모의실험에 사용된 룰베이스와 멤버쉽함수의 계수값은 그림 8, 9와 같다. 여기서 멤버쉽함수는 가우시안 분포를 이루고 있다.

$$M(x) = \{M_x^1, M_x^2, \dots, M_x^k\} = \{(m, \sigma)^1, (m, \sigma)^2, \Lambda, (m, \sigma)^k\} \quad (29)$$

라고 규정하면, 그림 8에서의 전건부 멤버쉽 함수의 학습 전 계수 (평균 및 분산)의 초기값은 다음과 같다.

$$M(e_\theta) = \{(m, \sigma)^1, (m, \sigma)^2, \Lambda, (m, \sigma)^k\} \\ = \{(-7, 1.4)^{NL}, (-3.3, 1.4)^{NS}, (0, 0.5)^z, (3.3, 14)^{PS}, (7, 1.4)^{PL}\} \quad (30)$$

$$M(e_c) = \{(-0.02, 0.004)^{NL}, (-0.01, 0.004)^{NS}, (0, 0.002)^z, (0.01, 0.004)^{PS}, (0.02, 0.004)^{PL}\} \quad (31)$$

그림 9에서의 후건부 멤버쉽 함수는 조향각도 구동계에서는 조향각도지령의 단일출력으로, 주행속도 구동계에서는 주행 속도지령의 단일 출력으로 구성되어 있고 각각의 분산과 평균값은 다음과 같다.

$$M(\hat{V}_d) = \{(-1, 0.18)^{NL}, (-0.6, 0.125)^{NM}, (-0.3, 0.125)^{NS}, (0, 0.125)^z, (0.3, 0.125)^{PS}, (0.6, 0.125)^{PM}, (1, 0.18)^{PL}\} \quad (32)$$

$$M(\hat{V}-s) = \{(0, 0.5)^z, (1, 0.75)^S, (2.7, 0.5)^M, (4.5, 1)^L\}$$

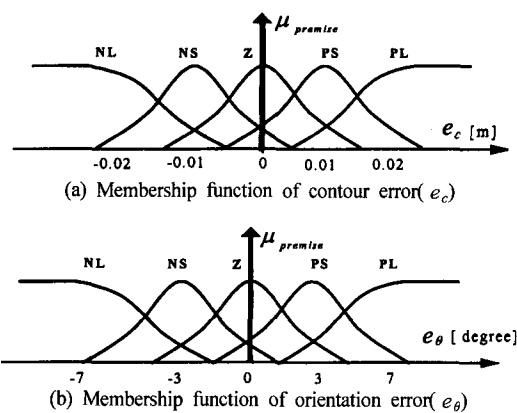


그림 8. 전건부 멤버쉽함수.

Fig. 8. Membership functions of premises term.

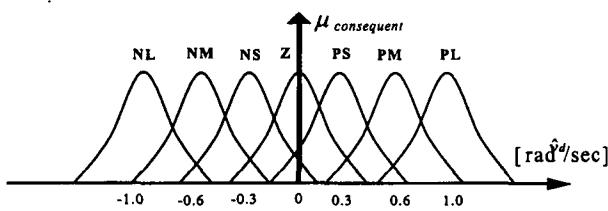


그림 9. 후건부 멤버쉽함수.

Fig. 9. Membership functions of consequent term.

조향각도 구동계와 주행속도 구동계의 언어적 룰베이스는 표 1과 같다.

뉴로퍼지제어부에서는 제어해석용 패키지인 matlab의 S-func.(그림 10의 new\_nf\_adapt)을 사용하여 제안된 뉴로퍼지제어 알고리즘을 코딩하여 프로그램 하였다.

표 1. 언어적 룰베이스(조향각도 구동계).

Table 1. Linguistic rule-base(Steering angular driving part).

(a) 조향각도  $\hat{V}_d$  구동계

		$e_\theta$				
		NL	NS	Z	PS	PL
$e_c$	NL	PL	PL	PM	Z	NS
	NS	PL	PM	PS	NS	NM
	Z	PM	PS	Z	NS	NM
	PS	PM	PS	NS	NM	NL
	PL	PS	Z	NM	NL	NL

(b) 주행속도  $\hat{V}_s$  구동계

		$e_\theta$				
		NL	NS	Z	PS	PL
$e_c$	NL	M	S	M	M	Z
	NS	S	S	M	M	S
	Z	S	S	L	S	S
	PS	S	M	M	S	S
	PL	Z	M	M	S	M

계수학습에서  $\partial v_d = -\eta_d^5 \frac{\partial E}{\partial v_d}$  인 적응률을 사용하여 최적화된  $\hat{v}_d$ 를 추정하는데, 특히 학습률  $\eta_d^5$ 의 값이 경로 추종의 성능에 민감한 영향을 미치게 된다. 본 연구에서는 모의실험을 하면서 학습률에 대한 제한조건을 두었는데 다음과 같다.

- △  $v_d > 0$  일 경우:  $\partial v_d = \Delta E * 10$
- △  $v_d$  일 경우:  $\partial v_d = -\Delta E * 10$
- |△  $v_d$ | > 0.0001 일 경우:  $\partial v_d = 0.0001 * \Delta v_d / |\Delta v_d|$
- 센서검출신호시 계수조정을 행하지 않음.
- 센서의 검출과 검출 사이의 시간에 최소한 1회 이상 학습토록 샘플링 시간을 선정: 0.01[sec]

즉 본 연구에서 학습률이 0.0001 이상이 되면 경로 추종 시 문제가 발생되어, 학습률을 0.0001로 제한하였고, 센서의 상태가 변하는 과정상태 시점에서 학습을 행하면 안정성이 저하되어 경로를 이탈하는 원인이 되므로 학습을 행

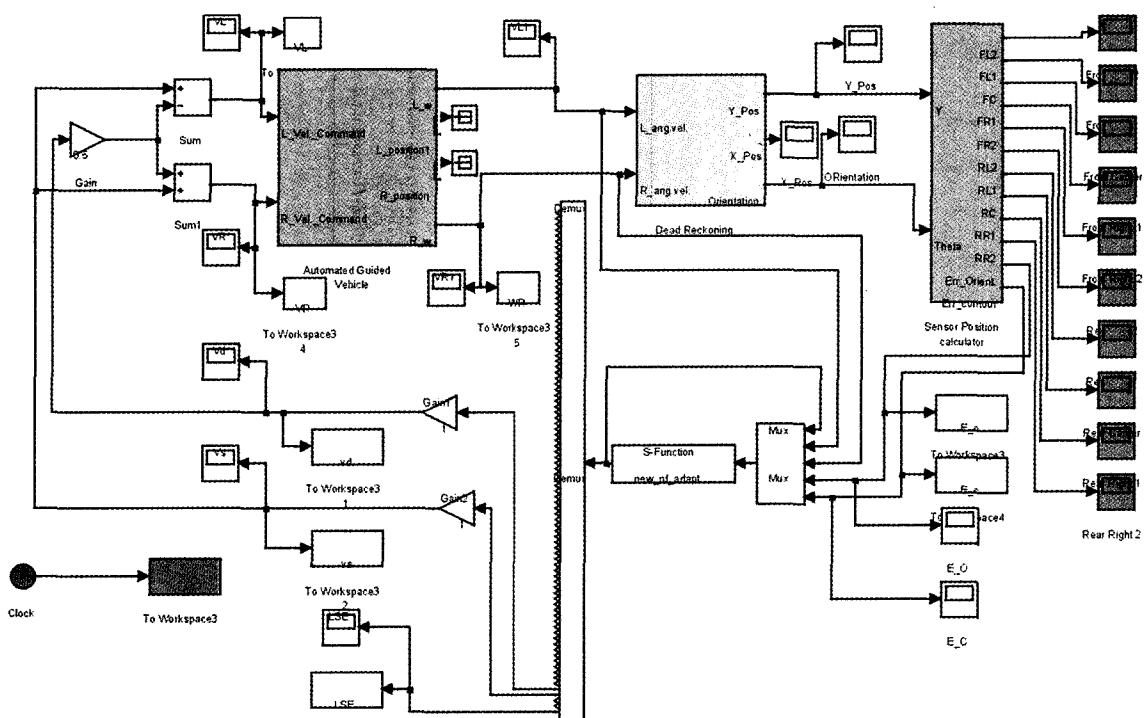


그림 10. Metlab 코딩에 의한 AGV 시스템 모의실험 블록도.

Fig. 10. The block diagram of AGV system by using Metlab coding.

하지 않는다. 센서의 검출된 후부터 센서의 검출값이 개선될 때까지 사이의 구간에서 최소한 1회 이상 학습이 일어나도록 샘플링 시간을 선정하여야 한다.

샘플링 시간이 너무 길으면 경로추종 성능이 저하되어 진다.

그림 11과 그림 12은 각각 학습전의 조향각도 구동계와 주행속도 구동계의 멤버쉽함수의 계수이다.

그림 13은 학습을 행하지 않는 순수폐지 제어기 AGV 시스템이 차체의 초기 윤곽오차와 방향오차를 영으로 설정하여, 직선궤적을 유도경로로 하여 경로추종을 할 때 발생하는 각부의 동작파형을 보여주고 있다.

이때 멤버쉽 함수의 계수값은 항상 초기치로서 고정되어 진다. 차체가 처음 주행되면서, 윤곽오차가 센서 사이의 거리인 0.02[m]가 되기까지는 가장 빠른 주행 속도로 주행하며 조향각도 지령이 영이 되어 최적의 조건으로 주행되고 있다. 차체가 왼쪽으로 점차 기울어져 70[sec] 부근에서 윤곽오차가 0.02[m]가 되면 전방왼쪽 첫 번째 센서에서 펄스가 출력되어 (3-5)에 의해 윤곽오차와 방향오차가 계산되어 조향각도 구동계 및 주행속도 주행계의 전진부 변수로 입력된다. 퍼지제어기의 룰베이스에 의해 주행속도 지령이

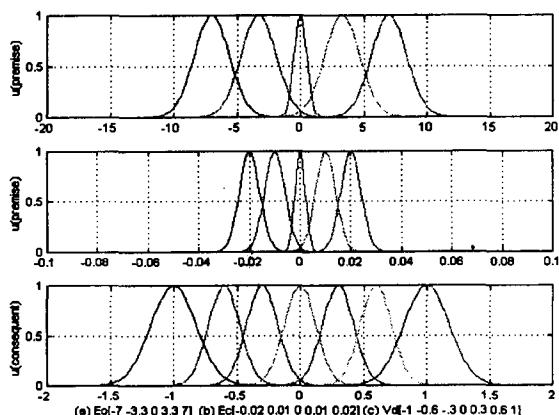


그림 11. 조향각도 구동계의 학습치 않는 멤버쉽함수.  
Fig. 11. Unlearned membership function of Steering angular driving part.

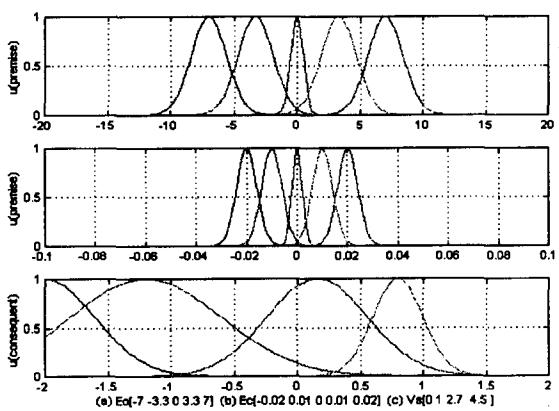
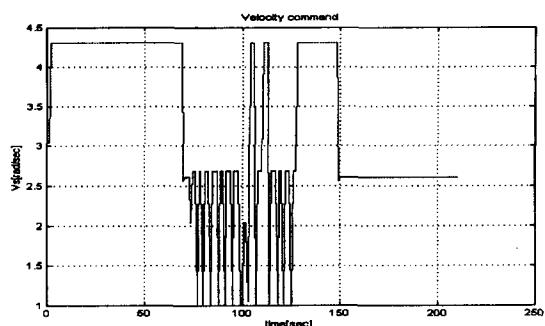
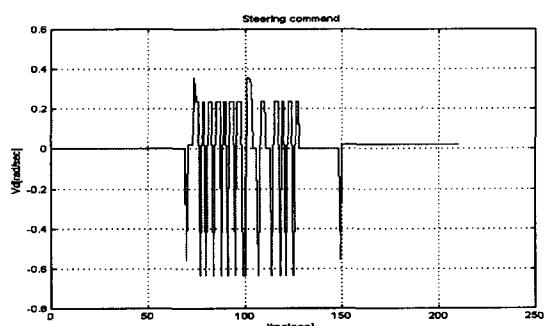


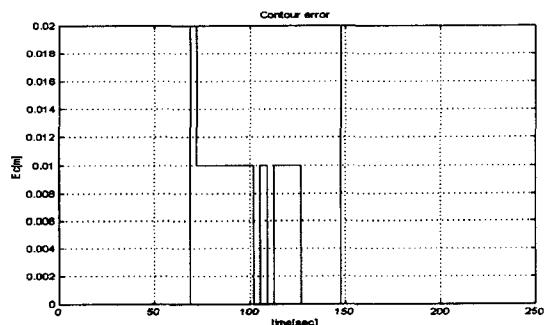
그림 12. 주행속도 구동계의 학습치 않는 멤버쉽함수.  
Fig. 12. Unlearned membership function of tracking speed angular driving part.



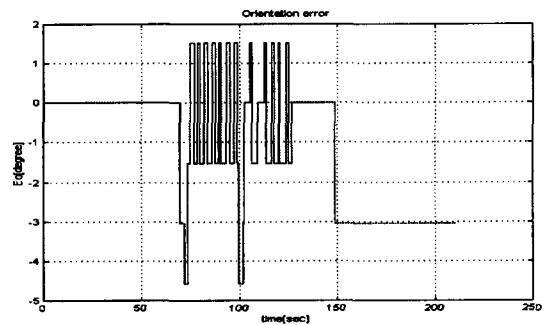
(a) 주행속도 지령( $\hat{V}_s$ )



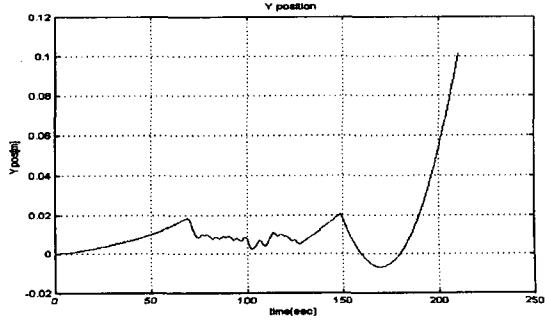
(b) 조향각도 지령( $\hat{V}_d$ )



(c) 센서검출 윤곽오차( $e_c(0)$ )



(d) 센서검출 방향오차( $e_\theta(0)$ )



(e) 윤곽오차( $e_c(t)$ )

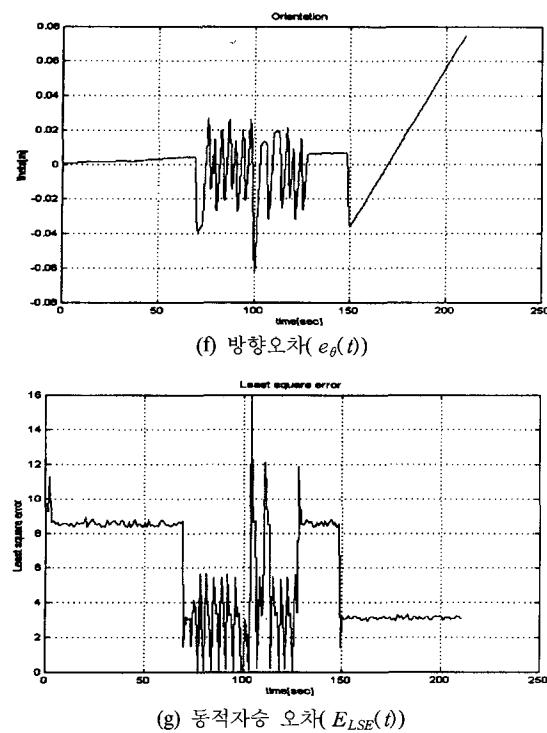


그림 13. 학습 없는 AGV시스템의 모의실험결과.  
Fig. 13. Simulation result of unlearned AGV system.

4.3[rad/s]에서 2.6[rad/s]로 떨어지고 조향각도 지령이  $0^\circ$ 에서  $-5.5^\circ$ 로 개선된다. 퍼지제어기에 의한 언어적 풀에 의해서 윤곽 오차는 줄어들어 직선경로를 추종하게 된다. 주행중에 AGV시스템이 진동하다가 150[sec] 부근에서 센서에서 윤곽오차와 방향오차가 겹쳐지지 않게 되어, 속도 및 조향 각도 지령의 개선이 전혀 일어나지 않고 결국 차체가 직선 궤적을 이탈하게 되었다. 시스템 오차의 지표로써 동적자승오차  $E_{LSE}$ 를 사용하였는데 윤곽오차와 방향 오차의 자승의 합으로써 규정하였다.

$$E_{LSE}(t) = e_c(t)^2 + e_\theta(t)^2 \quad (33)$$

100[sec] 부근에서 센서의 방향오차가 양에서 음으로 급

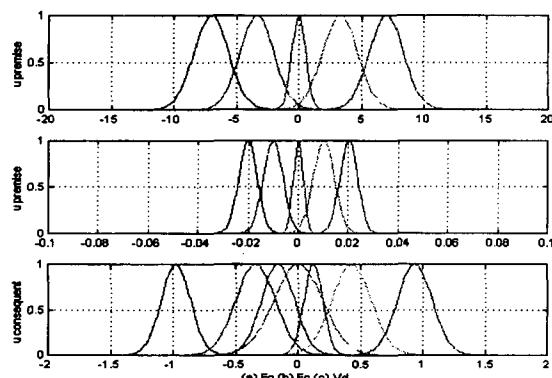


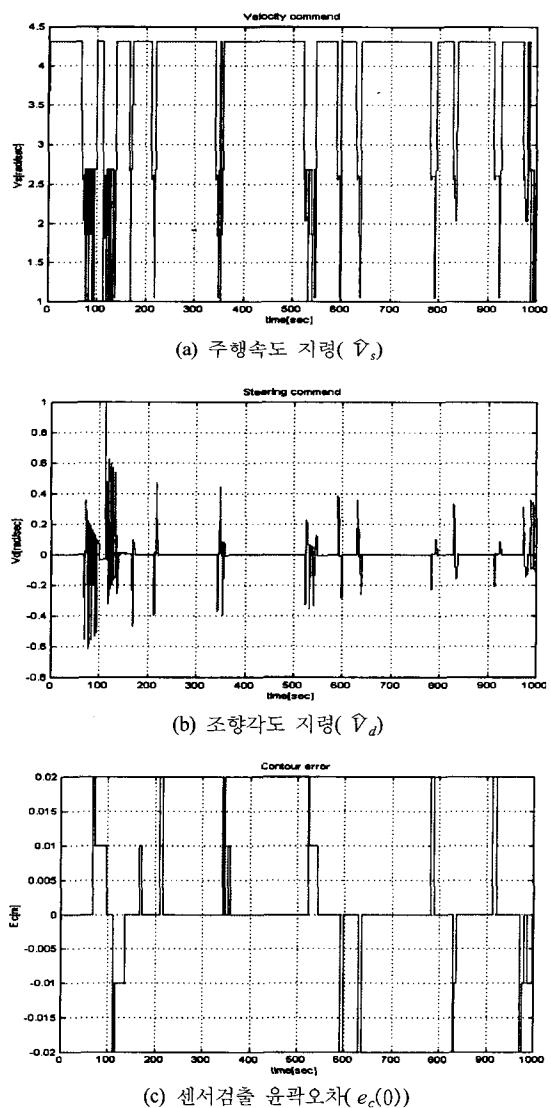
그림 14. 조향각도 구동계의 학습후 멤버쉽함수.  
Fig. 14. learned membership function with the contour of sensors at steering part.

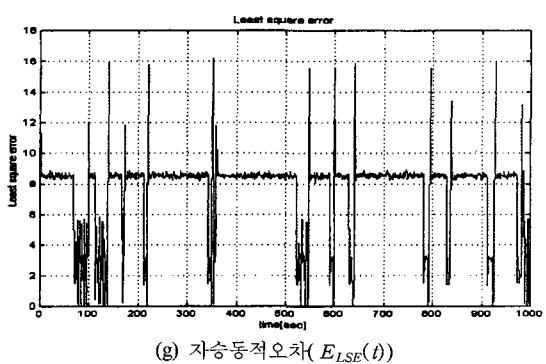
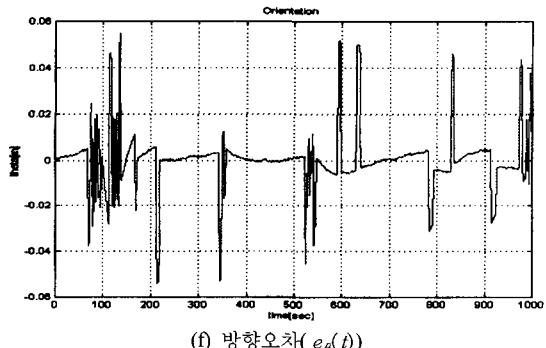
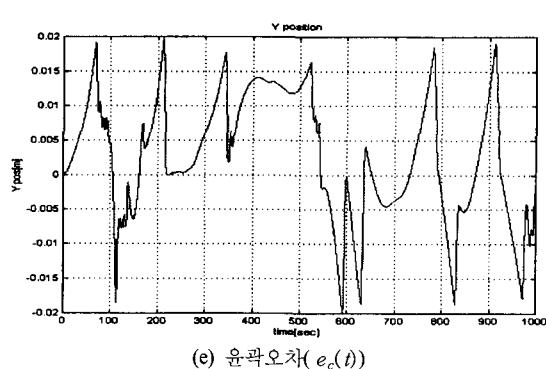
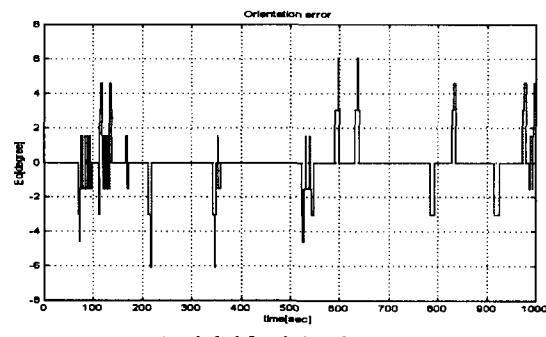
작스럽게 진동함으로써 시스템의 불안정을 초래함을 알 수 있다. 이때 자승동적오차가 16까지 증가됨을 보여준다.

그림 15에서는 추정윤곽오차를 여러함수로써 사용하지 않고 다만 센서검출에 의하여 (3-5)에서 도출한 윤곽오차를 여러함수로 사용하면서 계수조정을 행하여 경로추종을 할 때 발생하는 각부의 동작파형을 보여 준다. 계수조정을 행하지 않은 경우에서와 같이 경로를 이탈하지는 않고 윤곽 오차가 좌우 센서 한 개의 간격 ( $\pm 0.02[m]$ ) 안에서 수렴함을 보여주고 있다. 그러나 자승동적오차가 16까지 나타남으로써 의란이 존재하거나 센서의 잡음이 유입시 차체가 직선경로를 이탈 할 가능성을 배제할 수 없다.

센서에서 검출한 윤곽오차를 여러함수로써 사용하였을 때 조향각도 구동계에서 전진부와 후진부의 멤버쉽 함수의 분산과 평균에 대하여 계수조정을 하게 되는데 그림 14는 200초 주행후의 멤버쉽 함수의 변화를 보여주고 있다. 본 연구에서는 주행속도 구동계에서는 계수조정을 행하지 않고 계수값의 초기 설정값을 고정하여 사용하고 조향각도 구동계에서만 학습이 이루어지도록 설정하였다.

그림 16에서는 (8)의 추정윤곽 오차를 여러함수로써 사





좌우 센서 한 개 이내의 간격 (0.004~0.008[m]) 내에서 안정되게 제어됨을 보여준다.

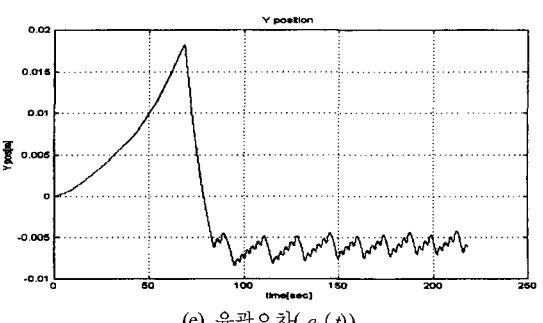
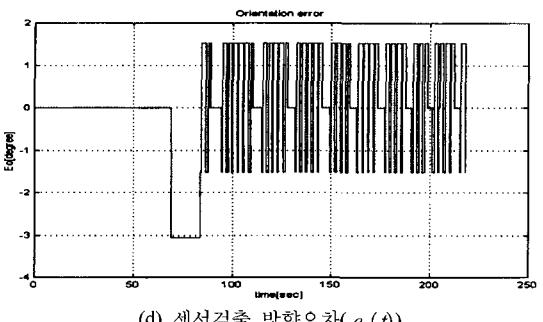
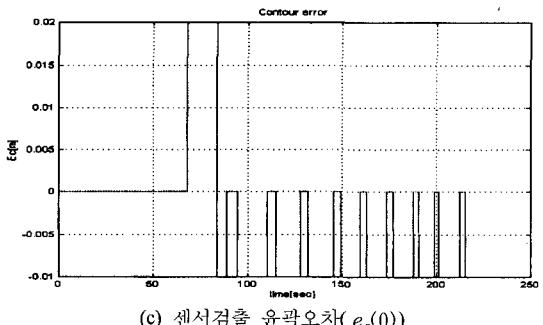
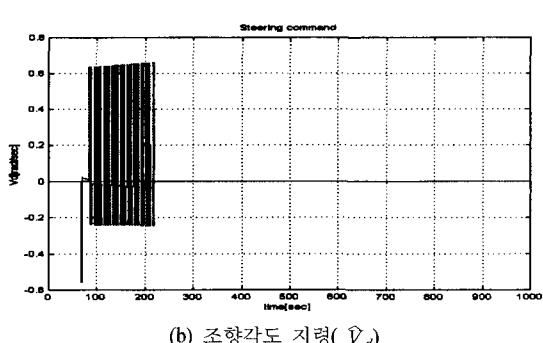
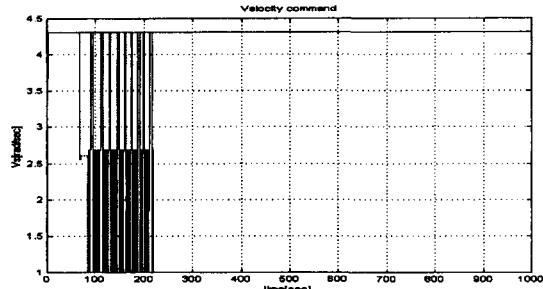


그림 15. 센서검출 윤곽오차만으로써 학습된 AGV 시스템의 모의실험 결과.

Fig. 15. Simulation result of learned AGV System with sensor detected contour error.

용하면서 학습을 통한 계수조정을 행하면서 직선경로를 추종할 때 발생하는 각부의 동작파형을 보여주고 있다. 경로를 이탈하지 않았고 첫 번째 센서 검출 신호가 발생후 방향오차가 급격히 변화되면 학습을 통하여 이를 잘 추종하여, 자승동적오차가 12범위 내에서 발생되며 윤곽 오차가

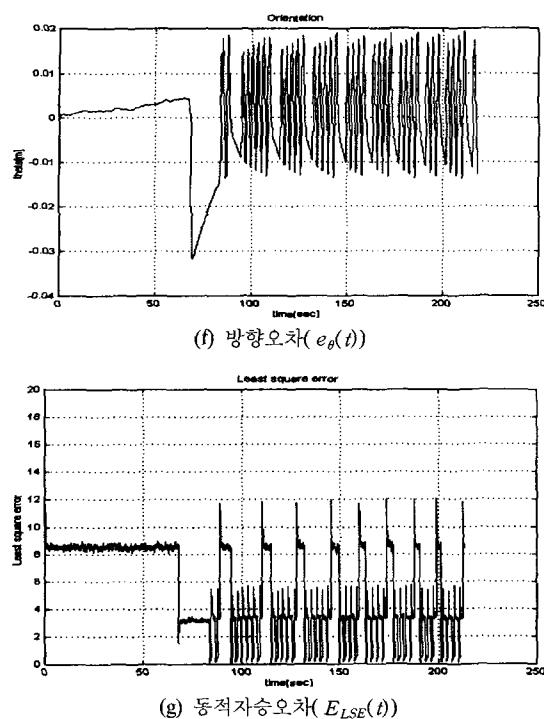


그림 16. 추정윤곽오차로써 학습된 AGV시스템의 모의실험 결과.

Fig. 16. Simulation result of learned AGV System With estimated contour error.

그림 16-(e)서 보여진 바와 같이 정상상태 오차가 생겼지만 이는 양쪽 모터의 관성모멘트 및 마찰계수의 차이에 기인한 것이고 제로 오프셋점인 -0.005[m] 지점을 정상오차값으로 충분히 수렴함을 확인할 수 있다.

## V. 결론

광유도식 AGV시스템의 비선형성과 센서검출의 이산성과 비연속성을 효율적으로 제어하기 위하여 경험자의 지식을 기반으로 제어할 수 있는 퍼지논리 제어기를 설계하였다.

본 논문에서는 광센서로부터의 이산적인 정보로부터 AGV 경로추종상의 윤곽오차와 방향오차를 계산하는 알고리즘을 제시하였고 이를 퍼지제어기의 전건부 입력으로 사용하였다.

퍼지제어기의 최적제어를 하기 위하여, 여러함수를 설정하고 이를 최소화하는 가우시안 형태의 멤버쉽 함수의 분산과 평균값 계수를 찾는 신경망 구조를 갖는 학습제어 알고리즘을 사용하였다.

광센서 검출의 비연속성에 따른 학습의 한계를 극복하

기 위하여 추정윤곽 오차를 제안하였고, 이것의 절대값을 여러 함수로 설정하여 학습에 이용함으로써 경로이탈이 방지되었고 또한 경로추종 제어성능을 향상 시켰다.

모의실험을 통하여 제안된 뉴로퍼지 제어기의 성능을 입증하였다.

모의실험 결과 순수한 퍼지제어에서는 경로이탈이 발생하였으나 제안된 동적오차 계산 알고리즘을 사용하여 역전파 학습하여 멤버쉽 함수의 계수를 조정함으로써 차체의 이탈이 방지되었다.

제안된 추정윤곽오차를 여러함수로 설정하여 역전파 학습하여 계수를 추정하여 모의실험을 함으로써 경로추종 제어성능이 향상됨을 입증하였다. 제어성능의 지표로서 설정한 동적자승오차의 변화폭이 16에서 12까지 감소되어 차체의 급작스런 진동이 방지됨을 알 수 있었고, 차체가 센서거리 간격 이내 (-0.004~0.008[m])에서의 윤곽오차를 발생시키며 안정되게 주행함으로써 경로추종성능이 향상되고 경로이탈이 방지됨을 보여주었다.

제안된 알고리즘을 통하여 경로추종성능이 향상됨을 입증하였지만 본 알고리즘으로써 실시간 제어를 행하기 위해 고속의 프로세서가 필요로 하는데, 이를 실시간 제어에 적합하도록 계산시간을 단축시키는 빠른 보상 알고리즘(Fast Compensated Algorithm)의 개발이 추후의 과제라 할 것이다.

## 참고문헌

- [1] A. J. Bostel and V. K. Sagar, "Dynamic control systems for agvs.", *Computing & control Engineering Journal*, June 1996 [1] Koren, Y., "Robotics for Engineers," McGraw-Hill, New York, pp. 8-10, 1985.
- [2] S. Cameron and P. Provert, "Advanced guided vehicles: aspects of oxford AGV project," World Scientific, Singapore, 1994.
- [3] L. Feng, Y. Koren and J. Borenstein, "Cross-coupling motion controller for mobile robot," *IEEE Control Systems Magazine*, pp. 35-43, Dec., 1993.
- [4] Prof.Dr.Ing.Dr.he. Jozsef Cselenyi, Szilveszter Kovacs, and Lajos Pap, "New concepts in the fuzzy logic controlled path tracking strategy of the differential steered AGVs," *Proc. of 5th Int. Workshop on Robotics*, pp. 587-592, 1996.
- [5] Koren, Y., "Robotics for engineers," McGraw-Hill, New York, pp. 8-10, 1985.
- [6] Chin-Teng Lin & C. S. George Lee, "Neural-network based fuzzy logic control and decision system," *IEEE transactions on Computers*, vol. 40, no. 12, 1991.

## 임 일 선

1987년 인하대 전기공학과 졸업. 1991년 동대학원 전기공학과 졸업 (석사), 현재 동대학원 박사과정중, 1996년-현재 인천기능 대학 메카 트로닉스과 조교수. 관심분야는 서보제어 및 인공지능 제어.



## 허 목 열

1974년 서울대 전기공학과 졸업. 동대학원 석사(1978), 동대학원 박사(1982), 1985년-1986년 미국 일리노이드대 방문교수, 1980(현재 인하대학교 전기공학과 교수. 관심 분야는 서보제어 및 인공지능 제어.

