

論文95-32-B-8-9

유전알고리듬을 결합한 퍼지-신경망 제어 시스템 설계

(On Designing A Fuzzy-Neural Network Control System Combined with Genetic Algorithm)

金容虎*, 金成炫*, 全洪兌*, 李鴻奇**

(Yong Ho Kim, Seong Hyun Kim, Hong Tae Jeon and Hong-Gi Lee)

要 约

퍼지논리 제어기는 비선형 시변 시스템에 대한 규칙 베이스 구성시 모델의 불확정성 및 파라미터의 변화로 인해 훨씬 더 복잡하게 되며, 더욱이 제어환경의 갑작스런 변화에 대한 규칙베이스의 조정 능력을 갖지 못한다. 이러한 문제점을 극복하기 위해서는 퍼지 규칙베이스의 자동 동조 방식이 요구된다. 본 논문에서는 최적화 문제 해결에 대단히 효과적인 유전알고리듬에 기초를 둔 퍼지 신경회로망 제어 시스템을 제안 한다. 제안된 시스템의 동조 방식은 두개의 단계(오프라인 동조 과정, 온라인 미세동조 과정)로 수행 된다. 제안된 제어시스템의 효율성은 2자유도의 로보트 매니퓰레이터를 사용하여 컴퓨터 모의실험을 통해 입증된다.

Abstract

The construction of rule-base for a nonlinear time-varying system, becomes much more complicated because of model uncertainty and parameter variations. Furthermore, FLC does not have an ability of adjusting rule-base in responding to some sudden changes of control environments. To cope with these problems, an auto-tuning method of the fuzzy rule-base is required. In this paper, the GA-based Fuzzy-Neural control system combining Fuzzy-Neural control theory with the genetic algorithm(GA), which is known to be very effective in the optimization problem, will be proposed. The tuning of the proposed system is performed by two tuning processes(the course tuning process and the fine tuning/adaptive learning process). The effectiveness of the proposed control system will be demonstrated by computer simulations using a two degree of freedom robot manipulator.

I. 서 론

* 正會員, 中央大學校 電子工學科

(Dept. of Elec. Eng. Chung-Ang Univ. Seoul, KOREA)

**正會員, 中央大學校 制御計測工學科

(Dept. of Control & Instrumentation Eng. Chung-Ang Univ. Seoul, KOREA)

接受日字: 1995年1月27日, 수정완료일: 1995年8月16日

기존의 제어기법이 제어대상 시스템의 수학적 모델링에 기초하여 구성되는 것과는 달리 퍼지 제어기는 정량적으로 표현하기 힘든 전문가의 경험적 지식을 퍼지소속함수와 퍼지 규칙베이스의 형태로 구성하여 언어적 제어전략을 효과적으로 구현할 수 있는 특성을 갖고 있다. 이러한 퍼지 제어기의 응용은 여러가지 제

어문제에서 기준의 제어기에 비해 우수한 결과를 보이고 있다.^{[1][2][3]}

그러나 퍼지 제어기 설계에 있어 가장 어려운 점은 규칙베이스를 구성하는 일이다. 고도의 비선형 동특성을 갖는 시스템의 제어 규칙을 단순히 전문가의 경험적 지식이나 실험에 의해 구성하는 일은 상당히 주관적이고 경험에 의존하기 때문에 최적의 규칙베이스를 결정하기란 쉽지 않다. 따라서 상기와 같은 어려움을 해결하기 위해 규칙베이스의 자동생성을 위한 연구로는 자기동조(self-tuning)방식^[4], 학습능력을 갖는 신경망이론과의 융합방식^{[5][6]}과 유전 알고리듬에 의한 방식^[7] 등을 들 수 있다.

자기 동조 방식은 실행 측정표를 참고하여 현재 사용된 제어규칙의 기여도에 따라 제어규칙의 후건부를 강화 또는 약화시켜 제어규칙을 수정하는 방식이다. 그러나 실행 측정표를 정해주는 기준 역시 전문가의 경험과 지식에 의존하게 되므로 효율적인 방식이라 할 수 없다. 한편, 퍼지-뉴럴 융합방식은 일반적으로 Gradient-type의 학습 알고리듬을 사용하기 때문에 조정 파라미터의 최적값의 결정이 초기 파라미터나 학습률(learning rate) 등의 설정에 크게 의존하게 되며 지역적 최소점(local minimum)에로의 수렴 등의 문제점을 갖고 있다.

본 논문에서는 상기와 같은 문제점을 해결하기 위해서 최근에 최적화 알고리듬으로 널리 알려진 유전알고리듬과 퍼지-뉴럴 제어이론을 결합하여 퍼지-뉴珥 제어기의 퍼지소속함수와 제어규칙을 자동조정할 수 있는 방법을 제시하고, 이를 응용한 제어시스템을 제안한다. 유전 알고리듬은 자연생태계의 진화과정에서 관찰된 '적자생존(Survival of the fittest)'의 원리를 컴퓨터 알고리듬과 결합시켜 정립된 최적화 알고리듬이다.^{[8][9]} 그러나, 유전 알고리듬은 진화과정에서 최적점 근처에서의 미세조정(fine tuning)을 위해 많은 시간이 소비되고, 또한 off-line 학습 특성으로 인해 외부환경의 변화나 시스템 파라미터 변동에 대한 적응성이 문제가 대두된다.

제안되는 GA-퍼지-뉴珥 제어기는 상기의 문제점을 해결하기 위해서 다음과 같은 2단계 동조과정으로 구성된다. 첫번째 단계는 오프라인 동조 과정 단계로 유전 알고리듬을 사용하여 퍼지-뉴珥 제어기의 초기 파라미터(전건부 소속함수와 가중치로 표현되는 후건부 파라미터)를 추정하고, 두번째 단계는 온라인 미세동

조 과정 단계로 이들 파라미터의 미세조정 및 시스템 파라미터 변동이나 외부환경의 변화에 대한 적응성을 부여하기 위해 오차 역전파 학습 알고리듬을 사용하여 제어환경에 적합한 퍼지-뉴珥 제어기의 최적의 파라미터를 추정한다.

II. 유전 알고리듬(Genetic Algorithms)

유전 알고리듬은 자연 생태계의 적응 매카니즘에 기초한 확률적(stochastic) 탐색 알고리듬으로 1970년대 John Holland에 의해 정립된 최적화 알고리듬이다.^{[8][9]} 이러한 유전알고리듬은 최적화 문제, 분류 시스템, 신경회로망의 학습 문제, 퍼지 규칙베이스의 자동생성등 여러 응용 분야에서 적용되고 있다. 유전 알고리듬의 진화과정은 재생산(reproduction), 교배(crossover), 그리고 돌연변이(mutation)등의 연산자(operator)에 의해 처리되며, 일반적인 처리과정은 다음과 같이 요약할 수 있다.

- 단계1) 주어진 문제의 가능한 해를 부호화된 스트링으로 표현하여 초기집단을 구성
- 단계2) 집단의 각각의 스트링에 대한 적합도를 평가
- 단계3) 적합도에 따라 현재 집단에서 스트링을 선택 [재생산]
- 단계4) 선택된 어버이(parents) 스트링간의 교배 및 돌연변이의 진화과정을 통해 새로운 스트링 [자손(offsprings)]을 생성
- 단계5) 새로 생성된 스트링에 대한 적합도를 평가하여 이전 세대와 교체
- 단계6) 최적해를 구할 때까지 3단계 이하의 과정을 반복

이러한 유전알고리듬의 수렴해석에 관한 연구는 schemata 이론에 기초하여 이루어지고 있으며, 유전 알고리듬의 성능은 실제 파라미터의 부호화 기법, 재생산, 교배, 돌연변이 등의 유전 연산자와 평가함수 설정 등에 크게 의존한다. 부호화 기법으로는 주어진 문제에 따라 여러 방법이 있지만, 일반적으로 이진 부호화 기법이 널리 사용되며, 이때 모든 스트링은 이진수로 표현된다. 재생산은 스트링의 선택과 관련되며, 스트링의 선택은 적합도(fitness)에 비례하여 확률적으로 일어난다. 즉, 높은 적합도를 갖는 스트링에 높은 선택 확률을 주어 다음 세대를 구성한다. 적합도는 평가함수에 의해 주어지며, 주어진 문제에 대한 스트링의 성능 척

도가 된다.

III. 유전알고리듬에 기초한 퍼지-뉴럴 제어기 (Genetic algorithms-based Fuzzy-Neural Controller: GFNC)

퍼지 제어기를 설계하는데 있어서 가장 어려운 점은 앞서 설명하였듯이 퍼지 규칙베이스를 구성하는데 있다. 이에 본장에서는 유전 알고리듬과 퍼지-뉴럴 제어 이론을 결합하여 퍼지소속함수와 제어규칙을 자동 조정할 수 있는 방법을 제시한다. 조정방법은 유전알고리듬에 의해 규칙의 전역적 영역을 찾기위한 오프라인 동조 과정(off-line course tuning)과 오차 역전파 알고리듬에 의한 온라인 미세동조 과정(on-line fine tuning) 및 적응학습의 2단계로 수행된다. 여기에서 미세동조 과정이 필요한 이유는 문제 해결을 위한 유전알고리듬의 구성요소(교배율, 집단수, 스트링 길이, 돌연변이율, 양질의 난수발생 문제등) 설정이 충분히 잘되어 있지 않을 경우 정확한 동조가 어렵기 때문이다.

1. 퍼지-뉴珥 제어기 구성

제안된 퍼지-뉴珥 제어기는 식 (1)과 같은 퍼지규칙(fuzzy rule)과 퍼지추론과정을 그림1와 같은 신경망 구조로 구현하여 구성된다. 이러한 퍼지-뉴珥 제어기는 추론과정에 따라 전건부와 후건부로 나누어진다. 퍼지-뉴珥 제어기구성을 위해 사용된 퍼지규칙과 퍼지추론과정 및 이를 구현한 신경망구조는 다음과 같다.

퍼지추론 방법은 혼합법을 선택하였는데 이 방법은 Takaki와 Sugeno가 제안한 바 있으며 후건부 소속함수를 입·출력 선형관계식이나 상수값으로 표현하는 경우로써 비퍼지화기를 추론기에 포함시킨 형태이다. 이러한 혼합추론방식은 입력공간을 퍼지분할하여 각각의 퍼지 부공간에 대한 선형 입출력 관계를 할당함으로써 기존의 선형 근사화 방식(piecewise linear approximation)에 비해 적은수의 규칙으로도, 비선형 특성을 갖는 입출력 관계를 보다 정확하게 표현할 수 있는 장점을 갖는다. 이때 사용되는 퍼지규칙은 다음과 같은 퍼지함의(fuzzy implication)로 표현된다.

$$R_j: \text{IF } x_1 \text{ is } A_{1j} \text{ and } \cdots \text{ and } x_n \text{ is } A_{nj}, \quad (1) \\ \text{THEN } y_j = f_j(x_1, \dots, x_n)$$

여기에서, R_j 는 j 번째 규칙, x_1, \dots, x_n 은 입력, A_{ij} 는 퍼지변수, y_j 는 j 번째 규칙의 출력이며, 이때 후건부 함수는 $f_j(x_1, \dots, x_n) = a_{0j} + a_1x_1 + \dots + a_nx_n$ 이다.

퍼지-뉴珥 제어기의 전건부는 그림2에서 (A)~(C) 층으로 표현된다. (A)층은 입력변수를 전체집합상으로 설정하기 위한 층이며, (B)층에서는 전건부의 각 입력 변수에 소속함수를 할당하여 입력이 주어졌을 때, 그 소속정도를 출력한다. 그리고 소속함수의 형태는 종형으로써 다음과 같이 정의된다.

$$A_{ij}(x_i) = \exp\left(-\frac{1}{2} \cdot \left(\frac{x_i - c_{ij}}{w_{ij}}\right)^2\right) \quad (2)$$

여기서, c_{ij} 와 w_{ij} 는 각각 소속함수의 위치와 소속함수의 넓이, 즉 퍼지정도(fuzziness)를 결정하는 설계 매개변수이다.

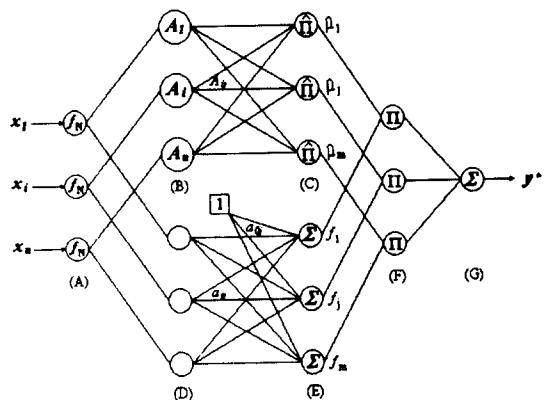


그림 1. 퍼지-뉴珥 제어기의 구조

Fig. 1. The structure of Fuzzy-Neural controller.

퍼지규칙의 전건부 진리값(truth value)은 (C)층의 출력으로부터 결정된다. 이때 입력공간(input space)은 (B)층의 소속함수에 의해 퍼지 분할(fuzzy partition)되어 각각의 퍼지 부공간(fuzzy subspace)에서의 퍼지규칙의 진리값은 product-operation 규칙에 따라 다음과 같이 계산된다.

$$\mu_j = \prod_{i=1}^n A_{ij}(x_i) \quad (3)$$

$$\widehat{\mu_j} = \frac{\mu_j}{\sum_{k=1}^m \mu_k} \quad (4)$$

여기서, μ_j 는 j번째 규칙 R_j 의 진리값을 의미하며, $\hat{\mu}_j$ 는 μ_j 의 정규화된 값으로 (C)층의 출력력이다. 그리고 m은 규칙의 수로 (C)층의 유닛(unit)의 갯수에 해당한다.

퍼지-뉴럴 제어기의 후전부는 그림1의 (D)~(G)-층으로 표현되며, 실제 제어량 발생을 위한 최종 추론값을 계산한다. 식(1)의 퍼지규칙의 후전부 계수 a_{ij} 는 (D)와 (E)층 사이의 가중치(weight)로 표현되며, 각 퍼지규칙의 추론값은 (E)층으로부터 $f_j(x_1, \dots, x_n) = a_{0j} + a_{1j}x_1 + \dots + a_{nj}x_n$ 과 같이 계산된다. 그리고 최종 추론값은 전전부의 진리값을 고려하여 (F), (G)층으로부터 다음과 같이 계산된다.

$$y^* = \frac{\sum_{j=1}^m \mu_j \cdot f_j(x_1, \dots, x_n)}{\sum_{j=1}^m \mu_j} = \sum_{j=1}^m \hat{\mu}_j \cdot f_j(x_1, \dots, x_n) \quad (5)$$

여기서, 최종 추론값 y^* 은 명확한 값(crisp value)으로 실제 제어 입력이 된다.

2. 진화에 의한 퍼지분할과 규칙활당(Course Tuning)

제어환경에 적합한 규칙베이스를 구성하기 위해서는 입력공간의 퍼지분할을 위한 퍼지 소속함수와 각 퍼지부공간에서의 규칙을 적절히 결정하여야 한다. 따라서 본 절에서는 그림1의 (B)층의 퍼지 소속함수와 (D), (E)층의 가중치로 표현되는 후전부 계수를 최적화 대상으로 하여 유전 알고리듬을 적용한다.

각 입력변수에 할당된 퍼지 소속함수는 중심위치(center)와 폭(width)에 의해 특징 지울 수 있다. 따라서 이들 퍼지 소속함수의 파라미터(즉, c_n 와 w_n)와 후전부 계수(a_{nj})를 이진 부호화 하여 하나의 비트스트링(bit string)을 구성한다.

A		A		rule 1			rule m		
center	width	center	width	a_{01}	a_{11}	\dots	a_{0n}	a_{1n}	\dots
10001001	11001010	10101111	01011001	11001100	10011110		10101111	01011001	

그림 2. 스트링 표현

Fig. 2. The string representation.

그림 2은 n개의 입력변수에 각 q개의 소속함수를 할당하였을 때의 비트 스트링을 보여준다. 이때, 규칙의 수 m은 q^n 이 된다. 한편, 평가함수는 상기의 스트링에 의해 표현되는 퍼지-뉴럴 제어기의 성능을 평가하는 기준이 되는 함수로, 집단내의 각 스트링에 대한 적합

도를 측정한다. 따라서 최소의 오차와 오차변화율을 제어목적으로 하여 다음과 같은 평가함수를 설정한다.

$$F(s_i) = \frac{K_1}{Error} + \frac{K_2}{Change\ of\ Error} \quad (6)$$

여기서, s_i 는 i번째 스트링이고, K_1 , K_2 는 상수이다.

상기의 스트링과 평가함수를 이용하여 진화에 의한 최적화 과정이 이루어진다. 본 논문에서는 정상상태 재생산 기법(steady-state reproduction technique)과 Roulette Wheel Parent Selection(RWPS) 알고리듬을 사용하였다. 정상상태 재생산 기법은 엘리트 전략(elitist strategy)의 하나로 세대교체(generational replacement)에 의한 재생산 기법과는 달리 집단에서 낮은 적합도를 갖는 임의의 n개 스트링을 새로 생성된 자손(offsprings)에 의해 교체하는 기법으로 이전세대의 높은 적합도를 갖는 스트링을 보존할 수 있다. 집단내의 각 스트링은 식(6)의 평가함수에 의해 적합도가 결정된다. 이 집단으로부터 RWPS 알고리듬을 사용하여 적합도에 비례하여 스트링을 선택하고, 선택된 스트링은 교배와 돌연변이의 진화과정을 통해 새로운 스트링을 생성한다. 즉, 높은 적합도를 갖는 스트링에 높은 선택확률을 주어 이러한 스트링의 우수한 유전자를 새로운 스트링에 유전할 수 있는 확률을 높여준다. 이와 같은 과정을 반복 실행하여 조정 매개변수의 최적점 또는 최적영역을 찾는다. 이때 교체되는 스트링의 수는 1개 혹은 2개로 설정한다. 교배는 두 스트링간의 교배점을 중심으로 한 교차로 일어나며, 돌연변이는 비트 스트링의 임의 비트 전환으로 이루어진다. 이러한 돌연변이는 진화과정에서 초기에 지역적 최소점에 빠지는 것을 방지하는 역할을 한다. 이와 같은 진화를 통해 구성된 최종 집단에서 가장 높은 적합도를 갖는 스트링은 제어 목적에 가장 부합하는 스트링으로 퍼지-뉴珥 제어기의 초기 파라미터가 된다.

3. 미세조정(fine tuning) 및 적응학습

본 절에서는 앞절의 유전알고리듬을 이용하여 추정한 퍼지-뉴珥 제어기의 매개변수들을 on-line 학습을 통하여 조정하는 방법에 대해 설명한다. 학습 알고리듬은 역전파 학습알고리듬에 기초한 것이며 GFNC의 미세조정 과정은 다음과 같은 2단계로 수행된다. 먼저, 입력 데이터($x_1(t), \dots, x_n(t)$)에 대한 실제출력($y^*(t)$)을 전방향 단계를 통해 계산하고, 목표출력($d(t)$)과의 오

차를 최소화하도록 역방향 단계를 통해 조정 매개변수 즉, 전건부 소속함수의 위치 및 폭과 후건부 선형식의 계수 등을 조정하는 단계로 수행된다. 출력층에서의 오차함수를 $E(t) = \frac{1}{2} (d(t) - y^*(t))^2$ 와 같이 정의 하였을 때 최급강하법(gradient descent method)을 이용하여 식 (8)의 오차함수 E를 최소화하는 매개변수의 조정량은 다음과 같이 결정된다. 전건부 소속함수의 위치와 폭($c_{ij}, w_n \in P_{ij}$) 조정량은 반복구칙(chain rule)을 사용하여 다음과 같이 계산된다.

$$\begin{aligned} \Delta P_n &= -\eta \cdot \frac{\partial E}{\partial P_n} \\ &= \eta \cdot (d - y^*) \cdot (f_i - y^*) \cdot \hat{\mu}_j \cdot \frac{\partial \hat{\mu}_j}{\partial P_n} \end{aligned} \quad (7)$$

또한, 그림의 (D), (E)층 사이의 가중치로 표현되는 후건부 입·출력 선형 관계식의 계수(coefficient)의 조정량은 다음과 같다.

$$\Delta a_n = -\eta \cdot \frac{\partial E}{\partial a_n} = \eta \cdot (d - y^*) \cdot \hat{\mu}_j \cdot x_i \quad (8)$$

여기서 η 는 학습률(learning rate)이고, $i = 1, \dots, n$, $j = 1, \dots, m$ 이다. a_m 를 위해서는 $x_i = 1$ 이다.

IV. 퍼지-뉴럴 제어시스템

앞의 III장에서 제안한 GFNC를 이용한 퍼지-뉴렐 제어시스템의 구조는 그림 3과 같다. 전체 제어시스템은 feedforward형의 제어구조로 병렬로 연결되어 있는 GFNC와 선형제어기, 그리고 제어 대상 시스템으로 구성되어 있다. 여기서 GFNC는 유전 알고리듬에 의한 off-line course tuning과 오차 역전파 알고리듬에 의한 on-line fine tuning 및 적응학습을 통해 제어대상 시스템의 역동력학 특성을 모델링하여 기준 입력에 대한 제어 입력을 생성한다. 또한 선형제어기는 순간적인 제어환경의 변화 등에 대하여 시스템의 안정성을 보장하며, 또한 퍼지-뉴렐 제어기의 on-line 학습시 제어대상 시스템의 자코비안(jacobian)을 알 수 없는 경우에 간접적인 교사 신호를 제공하는 역할을 한다. 이것은 Kawato에 의해 제안된 피드백 학습방법(feedback learning)으로 목표지향 학습방법(goal-directed learning)이다.^[15] 그리고 미세조정을 위한 오차함수는 선형제어기의 출력 u_{PD} 에 의해서

$E = \frac{1}{2} (u_{PD}(t))^2$ 로 재정의된다.

또한 제어 대상에 인가되는 전체 입력 u_{tot} 는

$$u_{tot} = u_{FN}(t) + K_p \cdot e(t) + K_d \cdot \dot{e}(t) \quad (9)$$

과 같이 선형제어기의 출력 u_{PD} 와 GFNC의 출력 u_{FN} 의 합에 의해 결정된다. 여기서 $e(t) = r(t) - y(t)$ 이며, $r(t)$ 는 기준입력(reference input), $y(t)$ 는 시스템의 실제 출력이다.

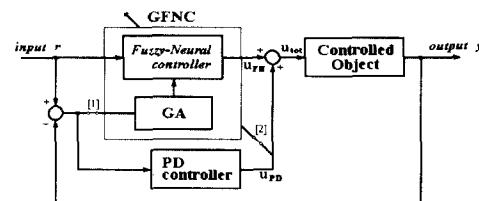


그림 3. 퍼지-뉴렐 제어시스템

Fig. 3. Fuzzy-Neural control system.

V. 컴퓨터 모의실험 및 결과

본 논문에서는 제안된 시스템의 효율성을 보이기 위해 2 종류의 모의실험을 수행하였다. 첫번째는 제안된 시스템의 구성 및 효율성 검증 실험이고, 두번째는 첫번째 실험에서 구성된 제어기의 적응성 검증실험이다. 제안된 제어시스템의 구성 및 검증을 위해 2 자유도 평면 로보트 매니퓰레이터의 위치제어를 선택하였다. 로보크 매니퓰레이터의 링크 파라미터는 길이 및 무게를 각각 0.53m, 0.47m, 그리고 3kg, 2.5kg으로 두었다.

로보트 매니퓰레이터는 다수의 비선형 항을 갖는 고도의 비선형 시스템으로 이를 위한 제어기 구성에 있어서 기존의 제어이론으로는 강건한 제어기 구성이 용이하지 못했다. 본 논문에서는 제어대상의 동적 방정식을 블랙박스로 취급하고, 상태변수는 관찰가능하다고 가정하여 모의실험을 수행하였다.

유전알고리듬에 의한 진화과정에서 퍼지-뉴렐 제어기의 각각의 파라미터는 8 비트 스트링으로 부호화되어 하나의 비트스트링을 구성하며, 평가함수는 식 (10)의 평균자승오차(Mean Squared Error)와 오차변화분(Mean Squared Change of Error)에 의해 다음과 같이 정의된다.

$$MSE = \frac{1}{T} \sum_{t=0}^T (\theta_d(t) - \theta_a(t))^2 \quad (10a)$$

$$MSCE = \frac{1}{T} \sum_{t=0}^T (\theta_d(t) - \theta_a(t))^2 \quad (10b)$$

여기서, θ_d 와 θ_a 는 각각 명령 궤적으로 준 관절 벡터와 시스템의 실제 출력이며, T는 명령 궤적의 한주기 를 나타낸다.

모의실험에서 진화에 사용된 유전 알고리듬의 파라미터는 집단의 수를 30개로, 교배화률을 1로, 돌연변이 확률을 0.01로 설정하였고, 오차 역전파 학습 알고리듬의 학습률은 0.0001로 선택하였다. 또한, PD제어기의 이득은 각각 200, 30으로 하였으며, 샘플링 시간(sampling time)은 0.01 (sec)이다. 제어시스템 의 명령으로는 로보트 매니퓰레이터의 주행경로를 다음과 같은 직교좌표상에서의 타원형 궤적을 설정하였다.

$$X_d(t) = \begin{pmatrix} P_x(t) \\ P_y(t) \\ P_z(t) \end{pmatrix} = \begin{pmatrix} 0.3 + 0.25 \cos \theta(t) \\ 0.3 + 0.15 \sin \theta(t) \\ 0.0 \end{pmatrix} \quad (11)$$

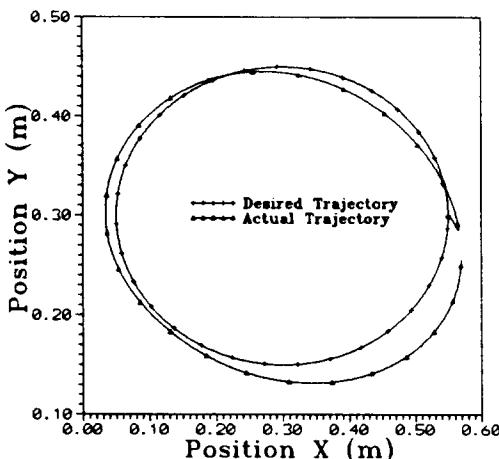


그림 4. 초기집단에서 가장 높은 적합도를 갖는 스트링에 의한 주행결과

Fig. 4. The tracking result with initial population.

모의실험 수행결과는 그림4~그림11로 주어져 있다. 유전알고리듬 수행시 약 800번의 진화 후에 거의 정상 상태(steady state)로 수렴하였다. 그림 4, 5은 초기 집단에서 가장 높은 적합도를 갖는 스트링에 의해 표현되는 퍼지-뉴럴 제어기에 의한 주행결과와 이때의 조인트 오차를 보이고 있으며, 그림 6, 7는 진화후의 로보트 매니퓰레이터의 주행결과와 조인트 오차를 보

이고 있다. 그럼 8은 진화후의 정상상태로 수렴한 파라미터를 퍼지-뉴珥 제어기의 초기 조건으로 하여 미세조정한 후의 주행결과를 보이고 있고, 이때의 조인트 오차는 그림 9과 같으며, 로보트 매니퓰레이터는 주어진 궤적을 거의 완벽하게 추종함을 알 수 있다.

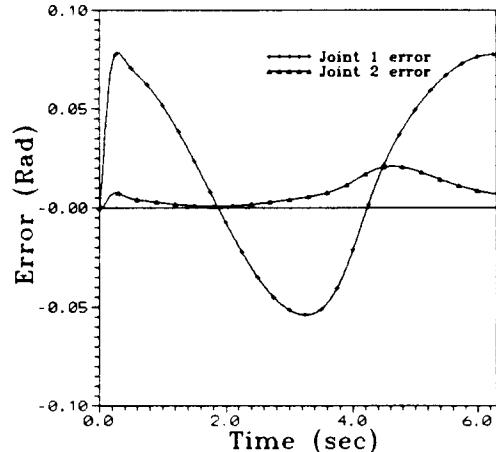


그림 5. 초기집단에서 가장 높은 적합도를 갖는 스트링에 의한 조인트 오차

Fig. 5. The joint error with initial population.

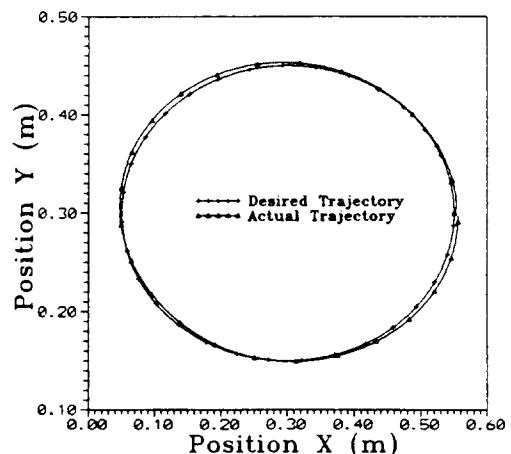


그림 6. 진화후의 가장 높은 적합도를 갖는 스트링에 의한 주행결과

Fig. 6. The tracking result with best string after evolution.

또한, 제어환경의 변화에 따른 제안된 제어시스템의 적응성을 확인하기 위해서 제어대상의 파라미터를 변경하였을 경우의 모의실험을 수행하였다. 시스템 파라

미터의 변동(링크의 무게 30% 증가)에 대한 적응 학습후의 결과는 그림 10, 11과 같다.

이와 같은 결과로부터 제안된 제어시스템은 제어성의 변화에 대해서도 효율적인 케이스제어가 이루어짐을 알 수 있다.

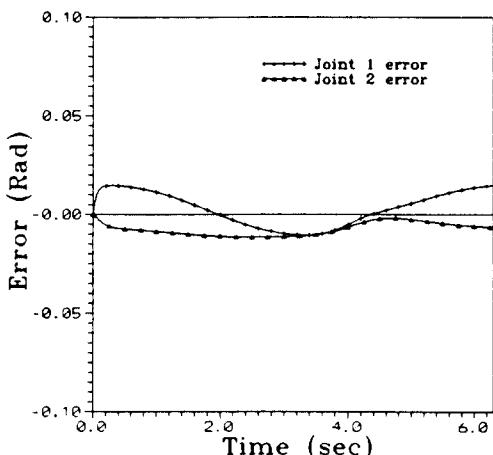


그림 7. 진화후의 가장 높은 적합도를 갖는 스트링에 의한 조인트 오차

Fig. 7. The joint error with best string after evolution.

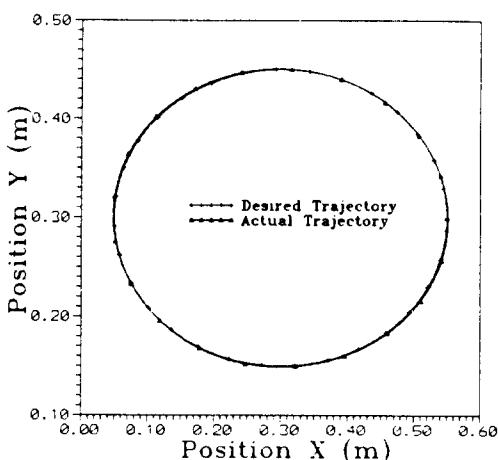


그림 8. 미세조정 후의 주행결과

Fig. 8. The tracking result after fine-tuning.

VI. 결 론

폐지-신경망 제어기능 추론의 장점을 갖는 폐지논리

와 병렬처리 및 학습의 장점을 갖는 신경회로망을 융합하여 구성된 제어시스템으로 매우 훌륭한 실행 특성을 갖는 시스템으로 평가받고 있다. 또한 제어대상에 대한 정확한 수학적 모델링이 요구되지 않으며 하드웨어로 구현할 경우 병렬처리 특성으로 인해 실시간 처리가 가능하다는 잇점을 갖는다. 그러나 제어대상이 고도의 비선형 동적 특성을 갖는 경우에는 전문가의 경험적 지식이나 신경회로망의 학습기능도 제어환경에 적합한 제어규칙의 전역적 영역을 찾는데 별로 도움이 되지 못한다.

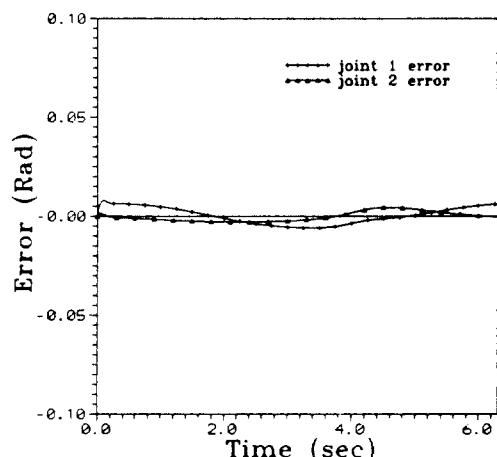


그림 9. 미세조정 후의 조인트 오차

Fig. 9. The joint error after fine-tuning.

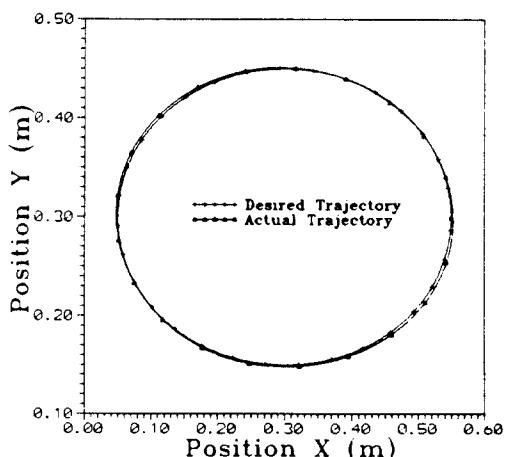


그림 10. 적응학습 후의 주행결과 (시스템 파라미터 변경 후)

Fig. 10. The tracking result to variation of system parameters after adaptive learning.

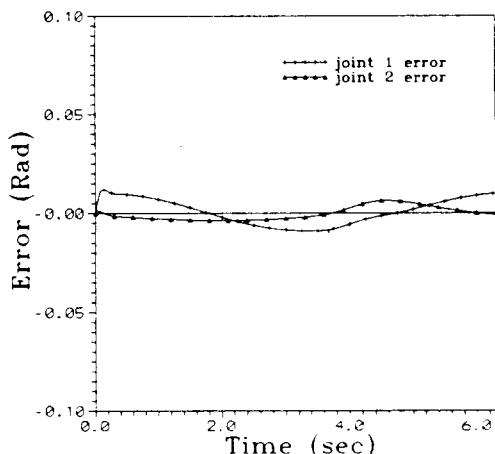


그림 11. 적용학습 후의 조인트 오차 (시스템 파라미터 변경 후)

Fig. 11. The joint error to variation of system parameters after adaptive learning.

따라서 본 논문에서는 제어환경에 적합한 최적의 규칙베이스의 구성을 위해 유전알고리듬과 퍼지-뉴런 제어이론을 결합하여 퍼지 소속함수와 규칙베이스를 자동 조정할 수 있는 방법을 제시하고, 이를 응용한 제어 시스템을 제안하였다. 제안된 퍼지-뉴런 제어기(GFNC)를 위한 조정 방법은 2단계 학습을 통해 수행되어 좋은 결과를 얻었다.

제안된 시스템은 각종 모델링 문제 및 제어시스템에 직접적인 적용이 가능하며, 전문가 시스템, 패턴인식 시스템 등 다른야로의 확장 적용이 가능할것으로 생각된다.

참 고 문 헌

[1] M. Sugeno, M. Nishida, "Fuzzy control

of model car," *Fuzzy Sets and Syst.*, vol. 16, pp. 103-113, 1985.

- [2] J. A. Benard, "Use of a rule-based system for Process control," *IEEE Control Sys. Mag.*, pp. 3-13, Oct. 1988.
- [3] Y. F. Li, C. C. Lau, "Development of fuzzy algorithms for servo systems," *IEEE Control Sys. Mag.*, pp. 65-72, Apr. 1989.
- [4] S. Shao, "Fuzzy Self-Organizing Controller and its Application for Dynamic Processes," *Fuzzy Sets and Syst.*, vol. 26, pp. 151-164, 1988.
- [5] H. Takagi, "Fusion Technology of Fuzzy Theory and Neural Network-Survey and Future Directions," *Int. Conf. on Fuzzy Theory & Neural Network(IIZUKA '90)*, vol. 1, pp 13-26, 1990.
- [6] Y. Dote, "Fuzzy and Neural Network Controller," *Proc. of IECON '90*, vol. 2, pp. 1315-1343, 1990.
- [7] P. Thrift, "Fuzzy logic synthesis with genetic algorithms," *Proc. of the fourth Int. Conf. on Genetic Algorithms*, pp.509-513, 1991.
- [8] David E. Goldberg, *Genetic Algorithms in Search, Optimization & Machine Learning*, Addison-Wesley Publishing Co., 1989.
- [9] L. Davis, *Handbook of Genetic Algorithm*, Van Nostrand Reinhold, 1991.
- [10] J. J. Craig, *Introduction to Robotics : Mechanics and Control-2nd ed.*, Addison-Wesley, 1989.

저자소개

金容虎(正會員) 제31권 B편 제4호
중앙대학교 전자공학과 박사과정

全洪兌(正會員) 제31권 B편 제4호
중앙대학교 전자공학과 교수

金成炫(正會員) 제30권 B편 제4호
중앙대학교 전자공학과 박사과정

李鴻奇(正會員) 제31권 B편 제6호
중앙대학교 제어계측공학과 부교수