

論文96-33B-5-16

유전 알고리즘을 이용한 퍼지 제어기의 자동설계

(Automatic Design of Fuzzy Controller Using Genetic Algorithms)

金大鎮 *, 洪政澈 **

(Daijin Kim and Jung Chul Hong)

요약

본 논문은 최적 제어를 위한 퍼지 제어기를 예시 학습법과 유전 알고리즘을 통해 자동적으로 생성시키는 새로운 설계 기법을 제안한다. 설계 과정의 첫 단계는 학습예들을 최대로 포함하는 퍼지 규칙 베이스를 유전학적 진화를 통해 얻어낸다. 두번째 단계는 얻어진 퍼지 규칙 베이스의 소속함수들을 유전학적 진화를 통해 최적의 제어결과를 나타내도록 미세 조정한다. 보다 향상된 제어 성능을 얻고자 이상의 두 단계를 서로 다른 퍼지 분할에 대해 독립적으로 반복 시행하여 얻어진 여러개의 퍼지 제어기를 同오차 가중법에 의해 유전학적으로 결합 시킨 퍼지 제어기群(Ensemble)을 제안한다. 제안한 퍼지 제어기 및 퍼지 제어기群을 Truck Backer-Upper 문제에 적용하여 제어기의 제어 성능 및 일반화 특성이 기존의 Wang과 Mendel[1]이 제안한 설계 방법보다 현저히 개선됨을 보였다.

Abstract

This paper proposes a genetic fuzzy controller ensemble (FCE) for improving the control performance of fuzzy controller in the non-linear and complex problems. The design procedure of each fuzzy controller in the FCE consists of the following two stages, each of which is performed by different genetic algorithms. The first stage generates a fuzzy rule base that covers the training examples as many as possible. The second stage builds fine-tuned membership functions that make the control error as small as possible. These two stages are repeated independently upon the different partition patterns of input-output variables. The control error will be reduced further by invoking the FCE that combines genetically various fuzzy controllers by an equal control error weighting method. Application to the truck backer-upper control problem is presented. The control performance of the proposed method is compared with that of Wang and Mendel's approach[1] in terms of either the percentage of successful controls reaching to the goal or the average traveling distance.

I. 서론

퍼지 제어 문제는 퍼지 집합 이론의 한 응용 분야로

* 正會員, 東亞大學校 컴퓨터工學科

(Dept. of Computer Eng., DongA University)

** 正會員, 基亞 情報 시스템 株式會社

(KIA Information Systems CO., LTD.)

※ 이 논문은 1994년 과학재단의 핵심연구과제(941-0900-057-01) 연구비에 의하여 연구되었음.

接受日字: 1995년 5월 31일, 수정완료일: 1996년 4월 23일

서 최근 공정 제어나 가전 및 산업 전자 분야에서 매우 활발히 연구 및 응용되고 있다^[2]. 특히 시스템의 특성이 복잡하여 입출력 관계의 정량적인 분석이 어렵거나 얻어지는 정보가 정성적이고 부정확한 경우에 기존의 제어기들에 비해 보다 우수한 제어 결과를 나타낸다.

퍼지 제어기의 설계는 퍼지 제어 규칙과 규칙내 각 언어 변수의 소속함수를 결정하는 것이 요구된다. 기존의 설계 방법은 주로 제어 전문가의 주관적인 판단과 경험적 지식에 의존하여 퍼지 규칙과 소속함수를 임의

로 결정하는 것이 보통이었다. 따라서 특정 응용 분야의 제어기 설계를 위해서는 그 분야의 많은 경험과 지식을 갖는 전문가의 도움이 요구된다.

최근에는 입출력 학습예(Training Examples)를 이용한 예시 학습법(Learning from Examples)^[1,3]을 통해 제어기의 입출력 특성을 근사화시키는 설계 방법이 널리 사용된다. 이 방법은 제어기의 수학적 모델링이 필요치 않고 입출력 특성이 학습예에 의해 근사화되므로 전문가의 도움에 의존할 필요성이 크게 준다는 장점이 있다. 학습을 통한 퍼지 제어기 구현에는 신경망 구조를 통한 구현과 유전 알고리즘을 통한 구현이 있는데 전자에 의한 구현은 학습예가 오직 수치 데이터 형태만 가능하고 국부해에 쉽게 빠질 수 있어 최적해를 보장할 수 없으며, 퍼지 제어 규칙이 가중치에 의한 내부적 표현으로 나타나므로 얻어진 제어 규칙에 대한 의미 부여가 어렵다는 단점이 있다.

유전 알고리즘을 이용한 퍼지 제어기 설계 기법은 학습시 수치 데이터 뿐 아니라 언어 변수로 표현된 제어 규칙을 직접 사용할 수 있으며 얻어진 해가 최적해를 나타내므로 최근 큰 주목을 받고 있다. 이 설계 기법 중 제어 규칙과 소속함수를 동시에 진화시키는 방법^[4,5]이 가장 좋은 제어 성능을 갖는 퍼지 제어기를 나타내지만, 퍼지 규칙과 소속함수가 한 Chromosome에 동시에 표현되므로 학습 시간이 과도하게 증가하고, 또한 좋지 못한 제어 규칙들이 잘 진화된 소속함수를 크게 변화시킬 수도 있으므로 최적해를 얻을 가능성이 감소된다.

따라서 본 논문에서는 먼저 주어진 입출력 학습예를 가장 잘 포함(Covering) 하는 퍼지 분할을 퍼지 규칙 베이스의 유전학적 진화를 통해 결정한 다음, 얻어진 퍼지 규칙 베이스가 좋은 제어 성능을 나타내도록 퍼지 규칙의 소속함수를 미세 조정하는 단계적 설계 방법을 제안하였다. 아울러 서로 다른 퍼지 분할하에서 얻어진 퍼지 제어기를 유전학적으로 합성한 퍼지 제어기 Ensemble의 도입을 통해 제어기의 일반화 특성을 크게 향상시킬 수 있음을 보였다.

본 논문의 구성은 다음과 같다. 2장에서는 퍼지 제어기의 구성과 동작 원리, 유전 알고리즘의 일반적 동작, 그리고 퍼지 제어기의 자동 설계 기법 중 퍼지 규칙 생성과 소속함수 미세 조정에 대해 기술한다. 3장에서는 퍼지 제어기 Ensemble의 개념과 이를 통한 일반화 특성의 향상에 대해서 설명한다. 4장에서는 제안한 설계

기법을 Truck Backer~Upper 문제에 적용하여 Wang과 Mendel^[11]이 제안했던 방법과 제어 성능을 비교 분석한다. 마지막으로, 5장에 결론이 뒤따른다.

II. 본 론

1. 퍼지 제어기의 구성과 동작 원리

먼저 퍼지집합 이론의 정의와 이론적 배경을 간단히 설명하고자 한다. 전체집합 U 의 한 퍼지 집합 F 는 원소 u 와 원소 u 가 퍼지집합 F 에 속하는 정도를 나타내는 소속함수 $\mu_F: U \rightarrow [0,1]$ 의 순서쌍, 즉 $F = \{(u, \mu_F(u)) | u \in U\}$ 로 나타내어진다. 전체집합 U 내의 한 언어변수 x 는 $T(x) = \{T_x^1, T_x^2, \dots, T_x^k\}$ 와 $M(x) = \{M_{x1}^1, M_{x2}^2, \dots, M_x^k\}$ 의해 정의되는데, 이때 $T(x)$ 는 언어변수 x 의 용어집합(Term Set)으로 각 원소 T_x^i 는 입력 값이 퍼지 집합 T_x^i 에 소속되는 정도를 나타내는 소속함수 M_x^i 를 갖는다. 따라서, 입력 언어 변수 x_i 를 포함하는 입력 벡터 X 와 출력 언어 변수 y_i 를 포함하는 출력 벡터 Y 는 다음과 같이 정의될 수 있다.

$$X = \{(x_i, U_i, \{T_x^1, T_x^2, \dots, T_x^k\}, \{M_{x1}^1, M_{x2}^2, \dots, M_x^k\}) | i=1, 2, \dots, m\}$$

$$Y = \{(y_j, U_j, \{T_y^1, T_y^2, \dots, T_y^l\}, \{M_{y1}^1, M_{y2}^2, \dots, M_y^l\}) | j=1, 2, \dots, n\} \quad (1)$$

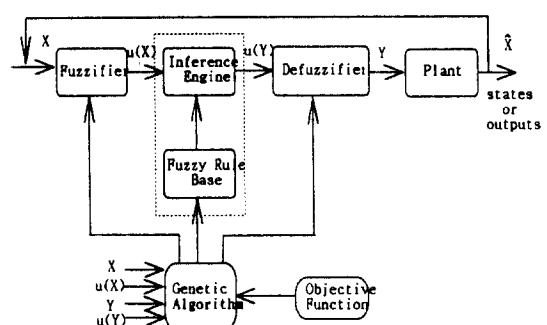


그림 1. 유전학습 기능을 갖는 퍼지 제어기의 구성도
Fig. 1. A typical organization of fuzzy controller having genetic learning unit.

그림 1은 학습 기능을 갖는 퍼지 제어기의 전형적인 기본 구성을 나타낸 것으로 각 부분의 동작 및 제어 원리는 다음과 같다. 퍼지화 도입부(Fuzzifier)에 의해 입력 x_i 를 $M_{x_i}(x_i)$ 의 소속함수 값을 가지는 퍼지집합

T_x 로 변환된다. 퍼지 규칙 베이스(Fuzzy Rule Base)는 제어 목적을 달성하기 위한 "IF-THEN" 형식의 퍼지 제어 규칙들을 저장한다. 이 규칙들은 전문가에 의해서, 또는 학습 과정을 통해 얻어진다. 퍼지 규칙 베이스에 있는 규칙들의 조건부와 입력의 언어변수는 서로 결합한 뒤 MAX-MIN 균사추론 방식에 의해 출력을 유추한다. 얻어진 퍼지 출력 값을 실제 제어에 필요한 확정된(Crisp) 값을 무게중심법(Center of area method)을 사용하여 얻는다. 그림 2는 퍼지 제어기에 서 사용된 추론 과정 및 비퍼지화의 한 예를 나타낸 것이다.

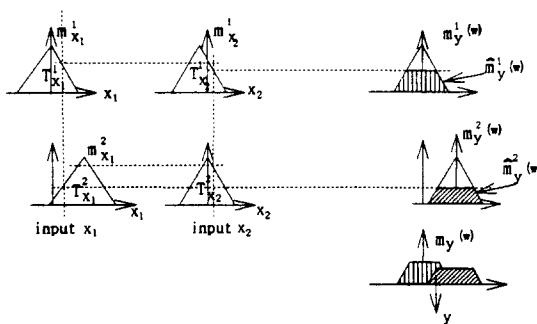


그림 2. 추론 과정 및 비퍼지화의 예

Fig. 2. An illustration of fuzzy inference and defuzzification.

2. 유전 알고리즘의 동작 원리

유전 알고리즘은 자연계의 적자 생존과 유전 현상을 모방한 탐색 알고리즘으로 Michigan대학의 John Holland와 동료 및 학생들에 의해 개발되었다^[6]. 유전 알고리즘에서는 해결하고자 하는 문제를 일차원적 String 형태로 표현하고, 여기에 유전 연산자를 적용하여 얻어지는 새로운 해가 점차로 최적해로 접근해 나간다. 유전 알고리즘의 일반적인 동작과정은 다음과 같이 설명된다. 초기 해집단 P(0)를 무작위로 생성한 뒤 Fitness 값이 큰 두개의 Chromosome을 Roulette-wheel 선택과 같은 확률적인 방법에 의해 선택한 다음 교차 및 변이 연산자를 이들에 적용하여 새로운 Chromosome을 생성시킨다. 이 과정을 해집단 P(t)내 모든 Chromosome들이 변환될 때까지 반복하여 새로운 해집단 P(t+1)을 생성한다. 얻어진 해집단은 일반적으로 전체 집단의 평균 Fitness 값이 증가한다. 이런 과정을 정해진 세대수만큼 반복해서 얻어진 해집단내의 최고 Fitness 값을 가지는 Chromosome이 찾고자하는 최적

해가 된다.

3. 퍼지 제어기의 자동 설계 방법

입력변수 $x_i (i = 1, \dots, m)$ 과 출력변수 $y_i (i = 1, \dots, n)$ 가 가지는 분할수를 각각 P_{x_i} 와 P_{y_i} 로 나타내면, P_{x_i} 와 P_{y_i} 는 각각 K_{x_i} 개의 가능한 분할수를 가지는 입력 변수 x_i 의 분할수 집합 $\{p_{x_i}^1, p_{x_i}^2, \dots, p_{x_i}^{k_{x_i}}\}$ 와 k_{y_i} 개의 가능한 분할수를 가지는 출력 변수 y_i 의 분할수 집합 $\{p_{y_i}^1, p_{y_i}^2, \dots, p_{y_i}^{k_{y_i}}\}$ 내의 한 값을 갖게 된다. 이 경우, 입력 및 출력변수의 분할수 조합으로 얻어지는 분할 패턴 집합 P 는 $|P| = \prod_{i=1}^m k_{x_i} \times \prod_{i=1}^n k_{y_i}$ 개의 분할 패턴을 가지며, P 내 한 분할 패턴 $P_i = (p_{x_1}, p_{x_2}, \dots, p_{x_m}; p_{y_1}, p_{y_2}, \dots, p_{y_n})$ 는 $\prod_{j=1}^m p_{x_j} \times \prod_{j=1}^n p_{y_j}$ 개의 퍼지 규칙으로 이루어진 한 퍼지 규칙 베이스 RB_i 를 생성한다.

본 논문에서는 분할 패턴 집합내 각 분할 패턴이 각기 다른 제어 특성을 나타내는 한 퍼지 제어기의 제어 규칙 베이스에 대응한다고 생각하고, 먼저 얻어진 제어 규칙들이 주어진 입·출력 학습에 대해 높은 포함값 (Coverage Value)을 나타내도록 유전 알고리즘에 의해 각 변수의 퍼지 분할을 대략적으로 정한 다음, 앞 단계에서 얻어진 제어 규칙들에 대해 높은 제어 능력을 나타내도록 퍼지 분할의 소속함수를 또 다시 유전 알고리즘에 의해 미세 조정하는 단계적 방법을 통해 퍼지 제어기를 설계하였다. 이상의 과정을 분할 패턴 집단내의 각 분할 패턴에 대해 독립적으로 시행하여 여러개의 퍼지 제어기를 얻은 후, 보다 나은 일반화 제어 특성을 나타내도록 구해진 여러개의 퍼지 제어기들을 유전학적으로 결합한 퍼지 제어기 Ensemble을 얻었다. 그림 3은 본 논문에서 제안한 퍼지 제어기의 설계과정을 단계별로 나타낸 것이다.

1) 1단계 - 퍼지 규칙 베이스 생성

먼저 T 개의 학습예로 구성된 학습예 집합 $E = \{e^1, e^2, \dots, e^T\}$ 알려져 있다고 가정한다. 여기서 한 학습예 $e^t (t = 1, 2, \dots, T)$ 는 m 개의 입력 변수 값과 n 개의 출력 변수 값의 쌍 $(e_{x_1}^t, \dots, e_{x_m}^t; e_{y_1}^t, \dots, e_{y_n}^t)$ 로 이루어진다. 예를 들어 $m = 2, n = 1$ 의 경우, 두 입력변수를 x, ψ , 한 출력변수를 θ 라고 하면 $e^t = (e_x^t, e_\psi^t; e_\theta^t)$ 의 형태를 갖는다.

만약 한 제어기의 입출력 특성을 되도록 잘 균사화하는 퍼지 규칙 베이스를 생성하려면, 규칙 베이스내

제어 규칙들이 학습에 집합 E 내 입력 출력 쌍을 가능하면 많이 포함(Covering)할 것을 요구한다^[7].

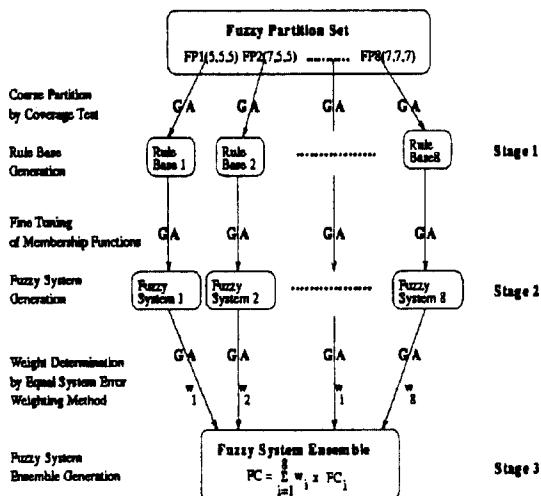


그림 3. 제안한 퍼지 제어기군의 설계 과정
Fig. 3. The proposed design procedure of fuzzy controller ensemble.

한 퍼지 규칙 베이스 RB 내의 각 제어 규칙 R_i ($i = 1, \dots, |RB|$)가 (여기서 $|RB|$ 는 규칙베이스내 규칙의 수) 학습에 집합 E 내의 한 학습예 e^i 를 포함하는 정도 $R_i(e^i)$ 는 아래식과 같이 학습예의 입·출력 값과 제어 규칙내 각 언어 변수의 소속함수와의 일치도(Compatibility Degree)에 의해서 정량화 가능하다.

$$R_i(e^i) = (\bigwedge_{j=1}^m M_{x_j}^i(e^i)) \wedge (\bigwedge_{j=1}^n M_{y_j}^i(e^i)). \quad (2)$$

여기서 \wedge 는 퍼지 AND 연산자로서 본 논문에서는 산술적 곱(Algebraic Product)에 의해 계산된다. 이경우, 하나의 학습예 e^i 가 한 규칙 베이스 RB 내의 제어 규칙 R_i ($i = 1, \dots, |RB|$) 중 몇개에 걸쳐서 중복적으로 포함되는 경우는 가장 큰 일치도를 나타내는 규칙에 포함되는 것으로 간주한다. 따라서 전체 학습예 집합 E 에 의한 한 제어 규칙 R_i ($i = 1, \dots, |RB|$)의 포함값은 아래식과 같이 제어 규칙에 포함되는 각 학습 예중 일치도의 값이 임계값 τ 보다 큰 학습예만의 일치도의 합으로 정의된다.

$$R_i(E) = \sum_{e^i \in R_i} R_i(e^i) > \tau \quad (3)$$

본 단계에서는 주어진 분할하에서 얻어지는 규칙 베

이스내 각 제어 규칙들이 학습에 집합 E 를 가능하게 많이 포함하도록 각 변수가 갖는 언어 변수의 소속함수의 파라메터들(각 변수상의 중심위치 및 폭)을 유전학적 진화에 의해 대략적으로 결정한다. 이때, 얻어진 제어 규칙중 포함되는 학습예가 하나도 없는 제어 규칙은 미리 규칙 베이스에서 제거된다. 본 단계에서 사용된 유전 알고리즘의 표현 특성과 연산 내용은 다음과 같다.

1) 해개체(Chromosome) 표현

한 분할 패턴 $P_i = (p_{x_1}, p_{x_2}, \dots, p_{x_m}; p_{y_1}, p_{y_2}, \dots, p_{y_n})$ 주어질 때, 임의의 해개체 C_r ($r = 1, 2, \dots, M$)는 입력 변수 x_i 를 p_{x_i} 개의 언어변수 $T_{x_i}^j$ ($j = 1, 2, \dots, p_{x_i}$)로, 출력변수 y_j 를 p_{y_j} 개의 언어변수 $T_{y_j}^l$ ($j = 1, 2, \dots, p_{y_j}$)로 각각 분할할 때, 각 언어 변수에 대응하는 삼각형 모양의 소속함수 $M_{x_i}^j$ ($j = 1, 2, \dots, p_{x_i}$)와 $M_{y_j}^l$ ($j = 1, 2, \dots, p_{y_j}$)의 중심 위치와 폭의 한쌍으로 구성된 $(c_{x_i}^j, w_{x_i}^j)$ ($j = 1, 2, \dots, p_{x_i}$)과 $(c_{y_j}^l, w_{y_j}^l)$ ($j = 1, 2, \dots, p_{y_j}$)의 연속된 나열로 나타내어진다. 따라서 해개체 C_r 은 전체 $2 \cdot (\sum_{i=1}^m p_{x_i} + \sum_{j=1}^n p_{y_j})$ 개의 Gene 으로 구성된다. 예를 들면, 두 입력변수 x , ϕ 와 한 출력변수 θ 가 (5,5,5) 분할 패턴을 가지는 경우 각 분할 '5'는 {NB, NS, ZE, PS, PB}이라는 언어 변수를 나타내며 전체 $5 \times 5 \times 5 = 5^3$ 개의 퍼지 규칙이 생성 된다.

2) 초기해 집단의 생성

(c, w) 쌍을 무작위로 $\sum_{i=1}^m p_{x_i} + \sum_{j=1}^n p_{y_j}$ 개 발생시켜 하나의 해개체 C_r 를 만든 뒤, 이를 해집단 크기인 M_1 번 반복 시행하여 초기 해집단을 형성한다. 이때, 초기해집단 속에 전문가에 의해 미리 알려진 퍼지 규칙에 대응하는 분할을 가지는 해정보를 포함시킬 수 있다. 예를 들면, 각 변수의 ZE에 대응하는 언어 변수의 중심은 대략 0근처이라는 사실을 각 해개체에서 이용하면 최적해에 수렴하는 시간을 크게 단축시킬 수 있다.

3) 목적 함수(Fitness Function)

각 해개체에 의해 정의되는 규칙 베이스 RB 가 학습에 집합 E 를 포함하는 정도 $C_{RB}(E)$ 는 아래 식과 같이 규칙 베이스내 제어 규칙에 의한 포함도 $R_i(E)$ 의 전체 합으로 정의된다.

$$C_{RB}(E) = \sum_{i=1}^{|RB|} R_i(E) = \sum_{i=1}^{|RB|} \sum_{j=1}^{|E|} R_i(e^j). \quad (4)$$

여기서, 는 각각 규칙 베이스내 전체 제어 규칙의 수와

학습에 집합내 전체 학습예의 수를 나타낸다.

오직 위에서 정의된 규칙 베이스 RB 가 학습에 집합 E 를 포함하는 정도만을 해개체의 Fitness 값으로 사용되는 경우, 포함되는 학습예의 수가 작지만 포함도가 큰 경우가 발생될 수도 있으므로, 본 논문에서는 아래 식과 같이 규칙 베이스네 규칙중 가장 큰 일치도를 나타내는 제어 규칙 R_i 에 의한 포함값이 임계값 τ 보다 큰 학습예의 수 $N_{RB}(E)$ 도 함께 고려하였다.

$$N_{RB}(E) = \{ \#(e^t) | R_i(e^t) > \tau, e^t \in E \} . \quad (5)$$

따라서, 본 단계에서 고려한 목적 함수 $F_1(E)$ 는 아래 식과 같이 $C_{RB}(E)$ 와 $N_{RB}(E)$ 의 한 단조 증가 함수 $g = \sqrt{\cdot}$ 로 정의된다.

$$F_1(E) = g(C_{RB}(E), N_{RB}(E)) . \quad (6)$$

4) 유전 연산자

그림 4는 분할의 여러 형태를 예시한 것으로 그림 4-a의 경우는 변수의 분할이 학습예를 포함하지 않는 부분이 나타나므로 바람직하지 못하고, 그림 4-c의 경우는 변수의 한 분할이 다른 분할들을 겹치므로 포함도는 크나, 얻어진 제어규칙의 제어 능력이 크게 나빠진다. 따라서, 그림 8-b의 경우처럼 가능한 모든 학습 예를 전부 포함하면서 인접 분할끼리 적절히 충첩되는 규칙 베이스가 바람직하다. 그림 4-c의 경우를 방지하기 위해서 한 해개체의 어떤 변수의 번째 소속함수의 양 끝점 $C_i - w_i$ 와 $C_i + W_i$ 가 각각 인접한 다른 중심값 c_{i-1} 과 c_{i+1} 를 넘지 않도록 한다.

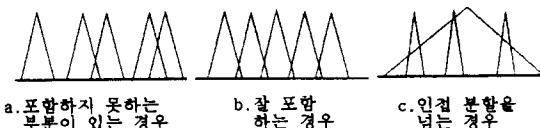


그림 4. 분할의 여러 형태

Fig. 4. Various types of partitions.

다음 세대의 해집단을 얻기 위하여 현재의 해집단내의 Chromosome을 선택하는데 k-tournament 선택법을 약간 수정하여 사용하였다^[8]. 이 방법은 Fitness 값이 큰 상위 집단중 무작위로 k개의 Chromosome을 선택한 후 이들중 가장 큰 Fitness값을 가지는 Chromosome을 선택하는 방법으로 2번에 걸쳐 반복 시행하여 두개의 Chromosome P_1 과 P_2 를 얻는다. 이들

P_1 과 P_2 에 대해 다음에 설명하는 교차와 변이를 통해 새로운 Chromosome C_1 를 얻은 뒤, 이것은 Fitness 값이 작은 하위 집단중 무작위로 k개의 Chromosome을 선택한 후 이들 중 가장 작은 Fitness 값을 가지는 한 Chromosome P' 와 교환된다. 이러한 과정을 전체 해집단의 pselect 비율만큼 반복하여 새로운 Chromosome을 생성시키고, 나머지는 원래의 해집단내의 Chromosome의 Fitness 값의 크기 순으로 그대로 복사한다. 그림 5는 수정된 k-tournament 선택법에 의한 해개체 집단의 세대간 복제 과정을 나타낸 것이다.

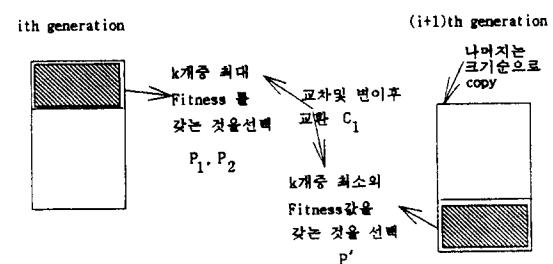


그림 5. k-tournament 선택법에 의한 해개체 집단의 복제

Fig. 5. Reproduction by a modified k-tournament selection.

선택된 두 Chromosome P_1 과 P_2 의 교차는 one-point 교차법의 변형된 형태로 두 Chromosome내 모든 변수에 대해 다음 과정을 독립적으로 수행한다. 두 Chromosome내 대응하는 각 변수의 언어 변수들에 대한 한계 포함값을 계산하면 두 Chromosome의 최소 한계 포함값을 나타내는 언어 변수가 일치하는 경우와 일치하지 않는 경우가 발생된다 ([그림 6] 참조).

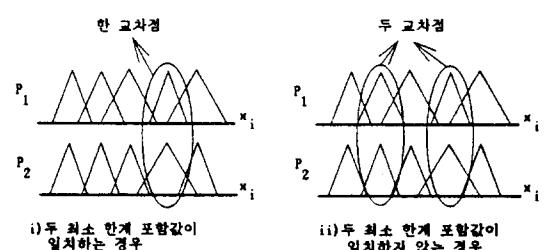


그림 6. 두개체의 한계 포함값의 분포

Fig. 6. Distribution of the marginal covering values between two chromosomes.

교차 연산을 위한 교차점은 먼저 일치하는 경우는

해당 최소 한계 포함값을 나타내는 언어 변수가 선택되고 일치하지 않는 경우는 각 Chromosome의 최소 한계 포함값을 나타내는 두 언어 변수가 선택된다. 그 이유는 최소 한계값을 나타내는 언어 변수가 주어진 학습에 집단에 대해 좋지 못한 포함상태를 나타내므로 교차에 의해 해당 언어 변수가 갖는 소속 함수의 파라메터 값(중심위치 및 폭)를 변화시킬 필요가 있기 때문이다.

선택된 교차점에서 두 소속함수의 중심과 폭을 각각 (c_1, w_1) 과 (c_2, w_2) 라고 하면, 교차에 의해 새로 얻어진 소속함수의 중심과 폭 (c', w') 은 아래 식과 같은 연산에 의해 결정된다.

$$\begin{aligned} c' &= \frac{c_1 + c_2}{2} \\ w' &= \text{random } (\alpha, \beta) \end{aligned} \quad (7)$$

여기서, $\text{random}(\alpha, \beta)$ 은 구간 (α, β) 내에서 무작위로 발생된 임의의 한 값을 나타내고, α 는 $\min(w_1, w_2)$ 이고, β 는 이웃하는 소속함수의 중심을 넘지 않는 최대값을 나타낸다.

해개체의 Fitness값이 큰 상위 집단에서 k-tournament 방식에 의해 선택된 해개체 P_1 내의 각 변수내에 변이점을 무작위로 선택한 뒤, 각 변이점에 대응하는 언어 변수가 원래 갖는 소속함수의 중심과 폭 (c_1, w_1) 을 아래 식과 같은 무작위 발생 연산에 의해 (c', w') 으로 변화시킨다.

$$\begin{aligned} c' &= c_1 + \text{random } (-\Delta c_1, \Delta c_1) \\ w' &= w_1 + \text{random } (-\Delta w_1, \Delta w_1) \end{aligned} \quad (8)$$

여기서, Δc_1 와 Δw_1 는 각각 제 1단계에서 사용한 중심과 폭이 가지는 최대 변동량으로서 일반적으로 다음 단계에서 사용한 중심과 폭이 가지는 최대변동량 Δc_2 와 Δw_2 보다 훨씬 큰 값을 갖는다.

2) 2단계 - 소속함수의 미세조정

퍼지 제어기 자동 설계과정의 두번째 단계는 앞단계에서 얻은 규칙 베이스내 유용한 제어규칙만에 의해 원하는 제어 목적(본 논문의 경우, 최단 주행 거리 또는 최소 도달 시간)을 만족시키도록 각 입·출력 변수의 언어 변수들이 갖는 소속함수의 중심과 폭들을 유전학적 진화를 통해 미세 조정하는 것이다. 본 단계에서 사용된 유전 알고리즘의 표현특성과 연산내용은 다음과 같다.

앞 단계에서 얻어진 규칙 베이스내 각 입·출력 변수의 언어 변수들이 갖는 소속함수의 중심과 폭 (c, w) 을 기준으로 해서 아래식과 같이 무작위로 발생시킨 임의의 변동량을 더해서, 소속함수의 중심과 폭 (c', w') 을 가지는 새로운 규칙 베이스를 얻는다. 이를 Population 크기인 M_2 번 반복 시행하여 초기 해집단을 형성한다.

$$\begin{aligned} c' &= c + \text{random } (-\Delta c_2, \Delta c_2) \\ w' &= w + \text{random } (-\Delta w_2, \Delta w_2) \end{aligned} \quad (9)$$

본 단계에서 사용된 목적함수는 규칙 베이스내 유용한 제어 규칙만에 의해 학습에 집합내 각 학습예의 초기 상태 $s_i = (x_1^i, x_2^i, \dots, x_m^i)$ 로부터 원하는 $s_d = (x_1^d, x_2^d, \dots, x_m^d)$ 상태에 도달하는데 걸리는 시간 t_f 또는 주행거리 l_f 를 사용한다. 현재 상태 s_t 를 규칙 베이스내 유용한 제어 규칙들에 가해 얻어진 퍼지 제어 출력들을 비퍼지화기에 의해 확정된 제어 출력들을 얻은 후, 이들을 Plant에 가해 다음 상태 s_{t+1} 를 얻는다. 다음 상태 s_{t+1} 를 새로운 현재 상태 s_t 로 보고 앞의 과정을 계속 반복하는데, 제어 결과 한계 시간 t_{\max} 내에 원하는 상태 s_d (또는 주어진 오차 범위내)에 도달하는 경우 ($t_f < t_{\max}$)와 도달하지 못한 경우 ($t_f \geq t_{\max}$)로 나눌 수 있다. 각 경우 한 학습예 e' 의 초기 상태 $s_i = (x_1^i, x_2^i, \dots, x_m^i)$ 에 대한 퍼지 제어기의 규칙 베이스의 제어능력을 $F_2(e')$ 에 의해 정량화된다.

$$F_2(e') = \begin{cases} 1 + t_f / t_{\max} & t_f < t_{\max} \\ \prod_{i=1}^m |x_i^f - x_i^d| / |x_i^{\max} - x_i^d| & t_f \geq t_{\max} \end{cases} \quad (10)$$

여기서, x_i^f 는 도달 시간 t_f 에서의 입력 변수 x_i 의 도달상태를 의미하고, x_i^{\max} 는 입력 변수 x_i 가 원하는 도달상태 x_i^d 에서 가장 많이 벗어난 상태를 나타낸다. 따라서 $F_2(e')$ 는 $t_f < t_{\max}$ 는 1과 2사이의 값을 갖게 되고, $t_f \geq t_{\max}$ 는 0과 1사이의 값을 갖게 되며, 각 경우 x_i^f 가 x_i^d 에서 멀리 떨어질수록 $F_2(E)$ 의 값이 작아진다. 본 단계에서 사용된 목적 함수 $F_2(E)$ 는 학습 예 집합 E 에 대한 규칙베이스의 평균 제어능력으로 정의 된다.

$$F_2(E) = \frac{1}{|E|} \sum_{i=1}^{|E|} F_2(e'). \quad (11)$$

여기서, $|E|$ 는 학습에 집합 E 내의 전체 학습에의 수이다.

유전 연산자의 경우 교차 연산시 발생되는 다음 2가지 점을 제외하고는 모든 과정이 제 1단계의 그것과 동일하다. 먼저, 교차점을 선택시 1단계의 경우 각 변수의 한계 포함값을 이용해 변수내 최소의 한계 포함값을 나타내는 언어 변수만을 교차시킨데 반해, 2단계의 경우 선택된 두 Chromosome의 모든 언어 변수를 교차시킨다. 두번째, 선택된 두 Chromosome의 대응하는 각 언어 변수가 갖는 두 소속함수의 중심과 폭을 각각 (c_1, w_1) 와 (c_2, w_2) 라고 하면, 교차에 의해 새로 얻어진 소속함수의 중심과 폭 (c', w') 은 다음식에 의해 결정된다.

$$c' = \frac{c_1 + c_2}{2} \quad (12)$$

$$w' = \frac{w_1 + w_2}{2} + \text{random } (-\delta_w, \delta_w)$$

여기서 $\text{random}(-\delta_w, \delta_w)$ 은 구간 내에서 무작위로 발생된 임의의 한 값을 나타내고, δ_w 는 $(w_1 + w_2)/2$ 의 약 10%에 해당하는 크기를 갖도록 하였다.

III. 퍼지 제어기 Ensemble

퍼지 제어기 Ensemble은 서로 다른 분할 패턴에 대해 같은 학습에 집합을 사용하여 유전학적으로 얻어진 여러개의 퍼지 제어기들로 구성된다. 서로 다른 퍼지 제어기내 제어 규칙들과 소속함수들은 같은 학습에 집합에 대해 서로 다른 제어 특성을 나타낸다. 따라서, 임의의 초기 상태 집합에 대해 각 퍼지 제어기가 나타내는 제어 능력의 일반화 특성은 좋은 것도 있고 나쁠 수도 있다. 하지만, 한 초기 상태 집합에 대한 퍼지 제어기 Ensemble 전체에 의해 얻어진 제어 능력의 일반화 특성은 각 퍼지 제어기가 각기 다른 초기 상태 집합에 대해 좋은 제어 능력을 나타내므로 크게 향상시킬 수 있다.

그림 7은 어떻게 퍼지 제어기 Ensemble이 한 초기 입력 집합에 대해 제어 능력의 일반화 특성을 향상시키는가 보여준다^[9]. 이 그림에서, U 와 E 는 각각 모든 가능한 초기상태의 전체집합과 학습시 사용한 초기 상태 집합이라고 하자. 그리고 서로 다른 분할 패턴들에 대응하는 $|P|$ 개의 퍼지 제어기들이 학습에 집단 E 를 사용하여 독립적으로 진화한다고 하자. 그러면 이들

퍼지 제어기는 $|P|$ 개의 다른 제어 규칙과 소속 함수쌍 $\{(R_1, M_1), (R_2, M_2), \dots, (R_{|P|}, M_{|P|})\}$ 을 생성한다. 각 제어규칙과 소속 함수쌍은 한 임의의 초기상태에 대해 다른 제어 특성을 나타낸다. 즉, 각 제어 규칙과 소속 함수쌍이 좋은 제어 능력을 나타내는 영역 $G_1, G_2, \dots, G_{|P|}$ 는 초기 상태의 전체집합에서 각기 다르게 나타날 것이다. 그럼 12에서 보듯이, 좋은 제어 특성을 나타내는 영역의 크기가 퍼지 제어기 Ensemble에 의해서 점차로 확장되는 것을 알 수 있다. 따라서, 한 퍼지 제어기에 의해 나쁜 제어 결과를 나타내는 한 초기 상태도 Ensemble내 다른 퍼지 제어기에 의해 좋은 제어 결과를 나타낼 수 있으며, 이는 전체적으로 제어 능력의 일반화 특성을 향상시키는 결과를 얻는다.

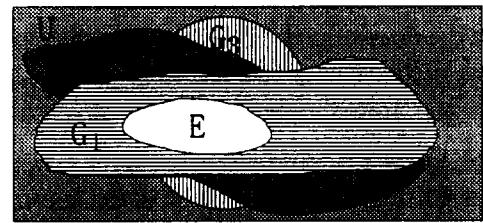


그림 7. 퍼지 제어기군에 의해 좋은 제어 능력을 보이는 영역이 증가한다

Fig. 7. The area showing good control performance is expanding as fuzzy controllers are combined together.

다음은 퍼지 제어기와 제어 대상인 Plant사이의 제어 과정을 설명한 것이다. Plant의 동작 dynamics $x_i(t) = f_i(y_1(t), y_2(t), \dots, y_n(t))$ ($i = 1, 2, \dots, m$)가 알려져 있다고 가정하면, 한 초기상태 입력 $(x_1(0), x_2(0), \dots, x_m(0))$ 에 대한 퍼지 제어기에 의해 얻어진 제어출력 $(y_1(0), y_2(0), \dots, y_n(0))$ 을 Plant에 가해 다음상태 입력 $(x_1(1), x_2(1), \dots, x_m(1))$ 을 얻을 수 있다. 얻어진 상태 입력을 다시 퍼지 제어기의 한 상태로 보고 앞의 과정을 반복하여 원하는 상태에 도달하면 제어 과정을 종료한다. 이때, 시간 t 에서 한 상태입력 $(x_1(t), x_2(t), \dots, x_m(t))$ 에 대해 plant가 원하는 최적의 퍼지 제어기의 제어출력을 $(y_1^d(t), y_2^d(t), \dots, y_n^d(t))$ 라고 하자. 각 퍼지 제어기가 나타내는 제어출력 $(y_1^i(t), y_2^i(t), \dots, y_n^i(t))$ 은 퍼지 제어기가 사용한 제어규칙과 소속함수에 따라 다른 값을 나타낸다. i 번

째 퍼지 제어기의 제어출력과 최적 퍼지 제어기가 나타내는 제어출력과의 제어 오차는 아래식과 같이 나타내어진다.

$$\begin{aligned}\varepsilon^i(t) &= (\varepsilon_1^i(t), \varepsilon_2^i(t), \dots, \varepsilon_n^i(t)) \\ &= (y_1^i(t) - y_1^d(t), y_2^i(t) - y_2^d(t), \dots, y_n^i(t) - y_n^d(t)).\end{aligned}\quad (13)$$

i 경우, i번째 퍼지 제어기에 의해 제어 과정의 모든 시간동안 발생하는 제어 출력들로부터 얻어지는 제어 오차 ε^i 의 각 성분이 독립적으로 얻어진다면, 제어오차 ε^i 의 j번째 ($j = 1, 2, \dots, n$) 성분은 평균이 0이고 분산이 $(\sigma_j^i)^2$ 인 정규 분포 $N(0, (\sigma_j^i)^2)$ 를 갖는다고 생각할 수 있다. 여기서, 퍼지 제어기 Ensemble에 의한 제어 출력 $Y^E(t)$ 를 |P|개의 퍼지 제어기가 나타내는 제어 출력들을 아래 식과 같이 선형적으로 결합하여 얻는다고 가정하자.

$$Y^E(t) = \sum_{i=1}^{|P|} \omega_i \cdot Y^i(t). \quad (14)$$

여기서 $\sum_{i=1}^{|P|} W_i = 1$ 을 만족한다.

그리면 퍼지 제어기 Ensemble에 의한 제어 출력 $Y^E(t)$ 과 원하는 최적 퍼지 제어기가 나타내는 제어 출력 사이의 제어 출력 오차 $\varepsilon^E(t) = Y^E(t) - Y^d(t)$ 은 아래 식과 같이 나타내어지고, $\varepsilon^E(t)$ 내 j번째 ($j = 1, 2, \dots, n$) 성분은 아래 식과 같이 각 퍼지 제어기에 의한 제어 출력 오차와 기중치의 곱의 합으로 나타낼 수 있다.

$$\begin{aligned}y_j^E(t) - y_j^d(t) &= \sum_{i=1}^{|P|} \omega_i \cdot y_j^i(t) - (w_1 + w_2 + \dots + w_{|P|}) \cdot y_j^d(t) \\ &= \sum_{i=1}^{|P|} \omega_i \cdot (y_j^i(t) - y_j^d(t)) = \sum_{i=1}^{|P|} \omega_i \cdot \epsilon_j^i(t)\end{aligned}\quad (15)$$

따라서, i번째 퍼지 제어기에 의한 제어 오차 ε^i 의 j번째 ($j = 1, 2, \dots, n$) 성분은 평균이 0이고 분산이 $(\sigma_j^i)^2$ 인 정규 분포 $N(0, (\sigma_j^i)^2)$ 를 갖는다고 하면, 퍼지 제어기 Ensemble에 의한 제어 출력 오차 $\varepsilon^E(t)$ 내 j번째 ($j = 1, 2, \dots, n$) 성분은 아래 관계식에 의해 평균이 0이고 분산이 $(\sigma_j^E)^2$ 인 정규 분포 $N(0, (\sigma_j^E)^2)$ 를 갖는다^[10].

$$\begin{aligned}m(\varepsilon_j^E) &= \sum_{i=1}^{|P|} \omega_i \cdot m(\varepsilon_j^i) = 0 \\ \sigma^2(\varepsilon_j^E) &= \sum_{i=1}^{|P|} \omega_i^2 \cdot \sigma^2(\varepsilon_j^i) + 2 \sum_{k=1}^{|P|} \sum_{l=k+1}^{|P|} \text{Cov}(\varepsilon_j^k, \varepsilon_j^l) = \sum_{i=1}^{|P|} \omega_i^2 \cdot (\sigma_j^i)^2\end{aligned}\quad (16)$$

여기서 $\text{Cov}(\varepsilon_j^k, \varepsilon_j^l)$ 는 k번째와 l번째 퍼지 제어기에

의한 제어 오차의 j번째 ($j = 1, 2, \dots, n$) 성분간의 공분산으로 퍼지 제어기 Ensemble내 각 퍼지 제어기가 독립적으로 설계되고, 각기 독립적으로 제어를 수행하므로 0이 된다. 나아가, 퍼지 제어기 Ensemble에 의한 제어 오차의 각 성분은 독립적으로 작용하므로 위 식은 제어 오차의 모든 j번째 ($j = 1, 2, \dots, n$) 성분에 대해서 동일한 형태의 분포를 갖는다고 생각할 수 있다.

다음은 퍼지 제어기 Ensemble내 각 퍼지 제어기들을 결합하는 결합 계수 ω_i 를 결정하는 방안에 대해서 알아본다. 퍼지 제어기 Ensemble내 각 퍼지 제어기가 나타내는 제어 오차의 크기가 서로 다르게 나타난다. 그러므로, 본 논문에서는 $\sum_{i=1}^{|P|} \omega_i = 1$ 이라는 조건과 각 퍼지 제어기에 의한 제어 오차를 동일 크기로 만들도록 하는 동(同) 오차 가중법(Equal Control Error Weighting Method)^[11]에 의해 i번째 퍼지 제어기의 결합 계수 ω_i 는 아래식으로 주어진다.

$$\omega_i = \frac{1}{\sigma_i \cdot \sum_{j=1}^{|P|} \frac{1}{\sigma_j}}. \quad (17)$$

퍼지 제어기 Ensemble에 의한 제어 오차의 표준 편차 σ 를 Ensemble내 각 퍼지 제어기들에 의한 제어 오차의 크기(표준 편차)의 조화 평균(Harmonic Mean)으로 정의하면 아래식과 같이 나타난다.

$$\sigma = \frac{1}{\sum_{j=1}^{|P|} \frac{1}{\sigma_j}}. \quad (18)$$

따라서 식 (17)과 (18)을 결합하면 i번째 퍼지 제어기의 결합 계수 ω_i 는 아래 식으로 주어진다.

$$\omega_i = \frac{\sigma}{\sigma_i \cdot |P|}. \quad (19)$$

위 식에 따르면, 각 퍼지 제어기에 의한 제어 오차를 동일 크기로 만들도록 하려면, 퍼지 제어기의 제어 오차의 분산값이 큰 퍼지 제어기의 결합 계수 ω_i 는 작은 값을 가지도록, 퍼지 제어기의 제어 오차의 분산값이 작은 퍼지 제어기의 결합 계수 ω_i 는 큰 값을 갖도록 조정하는 것이 요구된다.

본 논문에서는 퍼지 제어기 Ensemble내 각 퍼지 제어기의 제어 오차의 크기를 미리 알 수 없으므로, 퍼지 제어기의 결합 계수 ω_i 를 유전 알고리즘을 사용하여

주어진 학습에 집단 E 에 대한 퍼지 제어기 Ensemble의 제어 오차가 최소화되도록 결정하는 방법을 제안하였다. 사용된 유전 알고리즘의 상세한 설명은 다음과 같다. 퍼지 제어기 Ensemble의 $|P|$ 개의 퍼지 제어기로 구성되어 있고 각 퍼지 제어기의 결합 계수 w_i 라고 하면, 사용되는 해개체는 $|P|$ 개의 실수값이 연속된 하나의 String으로 나타내어진다. 해개체내 결합 계수를 나타내는 $|P|$ 개의 실수를 $[0,1]$ 의 범위에서 무작위로 발생시킨다. 이때 얻어진 $|P|$ 개의 결합 계수들이 $\sum_{i=1}^{|P|} w_i = 1$ 을 만족시키도록 하기 위해 각 결합 계수 w_i ($i = 1, 2, \dots, |P|$)를 아래식에 의해 정규화시킨다.

$$w_i = \frac{w_i}{\sum_{j=1}^{|P|} w_j}. \quad (20)$$

이상의 과정을 Population 크기인 M_3 번 반복 시행하여 초기 해집단을 형성한다.

본 단계에서 사용된 목적함수는 2단계에서 사용한 목적함수와 정확히 같다. 다만, 시간 t 에서 한 상태입력 $(x_1(t), x_2(t), \dots, x_m(t))$ 에서 시간 $t+1$ 에서의 다음 상태입력 $(x_1(t+1), x_2(t+1), \dots, x_m(t+1))$ 를 얻을 때, Plant에 가해지는 비퍼지화기 출력을 2단계에서와 같이 하나의 퍼지 제어기를 사용하는 것과 달리, 식 (14)에서 보여진 것처럼 퍼지 제어기 Ensemble의 $|P|$ 개의 퍼지 제어기에 의해 합성된 제어출력 $Y^E(t) = \sum_{i=1}^{|P|} w_i \cdot Y^i(t)$ 을 가한다. 따라서, 본 단계에서 사용된 목적 함수 $F_3(E)$ 는 아래 식과 같이 학습에 집합에 대한 퍼지 제어기 Ensemble의 평균 제어능력으로 계산된다.

$$F_3(E) = \frac{1}{|P|} \sum_{i=1}^{|P|} P |F_2^i(E)|. \quad (21)$$

여기서, $F_2^i(E)$ 는 한 학습에 집합 E 에 대한 i 번째 퍼지 제어기의 목적함수를 나타낸다.

1단계에서 수행한 방법과 동일한 복제 과정을 통해 P_c 의 빈도로 선택된 두 해개체 P_1 과 P_2 를 교차시켜 얻는 새로운 해개체의 결합 계수 w_i^c ($i = 1, 2, \dots, |P|$)는 두 해개체내 결합 계수 w_i 와 w_i^c 에 대해 아래 식과 같은 연산을 통하여 얻는다.

$$w_i^c = \frac{w_i + w_i^c}{2}. \quad (22)$$

만약 퍼지 제어기 Ensemble내 $|P|$ 개의 퍼지 제어기가 동일한 크기의 제어 출력을 나타내는 경우라면 각 제어기의 결합 계수 w_i 는 궁극적으로 $1/|P|$ 를 가지게 되므로, 결합계수에 대한 변이 연산을 제어기의 결합 계수 w_i^c 의 P_m 에 대한 반전(Turning-over)으로 생각할 수 있다. 따라서, 변이에 얻어지는 결합 계수는 의 빈도로 선택된 한 해개체내 무작위로 선택한 한 결합 계수 w_i 에 아래 식과 같은 연산을 행하여 얻는다.

$$w_i^m = \min(0, \frac{2}{|P|} - w_i). \quad (23)$$

위 식은 제어기의 결합 계수 w_i 가 $1/|P|$ 보다 큰 경우는 큰 양만큼 $1/|P|$ 보다 작게 만들고, 제어기의 결합 계수가 보다 작은 경우는 작은 양만큼 $1/|P|$ 보다 크게 만드는 것을 보여준다. Min 연산자는 변이에 의해 얻어진 새로운 결합 계수가 음수가 되는 것을 방지한다. 변이가 일어난 해개체는 결합 계수간 만족해야 하는 조건 $\sum_{i=1}^{|P|} w_i = 1$ 을 위반하므로 식 (19)에 의해 해개체내 결합 계수들을 다시 정규화하는 것이 요구된다.

IV. 실험 및 결과 분석

본 장에서는 앞장에서 제시한 퍼지 시스템 및 퍼지 시스템 Ensemble 설계 기법의 시스템 성능을 및 일반화 특성을 여러가지 다른 설계 기법들과 서로 비교 평가하기 위해 Truck Backer-Upper 제어 문제에 대해서 제시한 설계 기법을 적용한다.

Truck Backer-Upper 제어 문제는 공간내 임의의 한점에 놓여 있는 Truck을 후진시켜 일정한 위치에 놓여 있는 화물 적재대로 가장 신속하고 정확하게 도달하도록 Truck을 제어하는 문제이다. 이 제어 문제는 보통의 선형 제어 시스템으로는 제어가 불가능한 비선형 제어 방식의 전형적인 한 예로서, 이 문제를 해결하기 위해 제안된 몇가지 제어기의 예는 Nguyen과 Widrow의 신경망 제어기^[12], Kong과 Kosko의 퍼지 제어기^[13], Wang과 Mendel의 수치 퍼지(Numerical Fuzzy) 제어기^[1]를 들 수 있다. Wang과 Mendel의 연구 결과에 따르면 사용한 학습 정보양이 동일한 경우, 신경망 제어기와 퍼지 제어기의 제어 성능이 별 차이가 없는 것으로 나타났다. 따라서, Wang과 Mendel의 설계한 수치-퍼지 제어기를 비교 기준으

로 삼아 본 논문에서 제시한 설계 방법에 의해 얻어진 퍼지 제어기와 제어 능력과 비교하고 나아가 퍼지 제어기 Ensemble을 이용하여 제어 능력의 일반화 특성이 크게 향상됨을 보이고자 한다.

그림 8은 Truck Backer-Upper 제어 문제에서 사용한 모형 Truck과 화물 적재대를 나타낸 것이다. 공간내 Truck의 위치는 (x, y, ψ) (여기서 ψ 는 Truck의 진행 방향과 x 축이 이루는 각도)에 의해서 정확히 결정되고, Truck에 대한 제어는 θ (여기서, θ 는 Truck의 진행 방향과 바퀴 축이 이루는 각도)에 의해 행해진다. Truck의 위치 변수 (x, y, ψ) 의 변화는 식 (23)과 같은 근사 운동 방정식에 의해서 나타내어진다 [14].

$$\begin{aligned} x(t+1) &= x(t) + \cos [\psi(t) + \theta(t)] + \sin [\theta(t)] \sin [\psi(t)] \\ y(t+1) &= y(t) + \sin [\psi(t) + \theta(t)] - \sin [\theta(t)] \cos [\psi(t)] \\ \psi(t+1) &= \psi(t) - \sin^{-1} [2 \sin(\theta(t)) / b] \end{aligned} \quad (23)$$

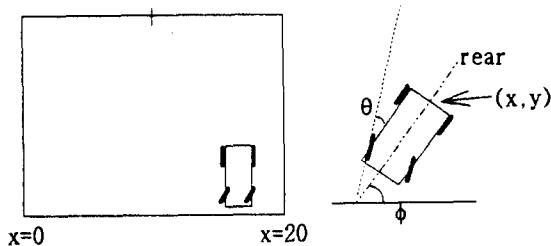


그림 8. 모형 truck과 화물 적재대

Fig. 8. A model truck and a loading duck.

여기서, b 는 Truck의 길이로, 본 논문에서는 $b = 4$ 를 취하였다. 만약 Truck과 화물 적재대 사이의 거리가 충분히 떨어져 있어서 일단 Truck이 화물 적재대가 놓여 있는 $x = 10$, $\psi = 90^\circ$ 근처에 들어오면 곧장 후진하면 되므로, 위치 정보 (x, y, ψ) 중 y 는 퍼지 제어기의 한 상태 입력에서 제외시켜도 큰 상관이 없다. 따라서, Truck Backer-Upper 제어를 위한 퍼지 제어기 설계는 주어진 공간 ($0 \leq x \leq 20$, $-90^\circ \leq \psi \leq 270^\circ$) 내 임의의 한 초기 상태에서 가능한 신속하고 정확하게 $x = 10$, $\psi = 90^\circ$ 에 있는 화물 적재대로 후진하도록 Truck의 바퀴 각도 θ ($-40^\circ \leq \theta \leq 40^\circ$)를 제어하는 것이 요구된다.

설계된 퍼지 제어기의 제어 능력을 공정하게 비교하기 위해 퍼지 제어기의 제어 규칙과 소속함수를 결정하기 위해 Wang과 Mendel이 사용한 것과 동일한 14개의 부드러운 주행 경로에서 얻어진 총 238개의 입·

출력 쌍^[14]을 학습에 집합으로 사용하였다. 나아가, Truck Backer-Upper 제어를 위한 퍼지 제어기의 입·출력 변수내 언어 변수의 분할수를 미리 결정하지 않고 여러가지 다른 분할수 조합에 대응하는 여러개의 퍼지 제어기를 구현하였다. 분할수 조합을 선정할 때, 기존의 Wang과 Mendel에 의한 설계된 퍼지 제어기와 공평한 비교를 위해 각 입·출력 변수를 5분할 또는 7분할하여 다음 식과 같이 전체적으로 8개의 분할수 집합을 고려하였다.

$$\begin{aligned} ((p_x, p_y, p_\theta)) | (5, 5, 5), (5, 5, 7), (5, 7, 5), (5, 7, 7), \\ (7, 5, 5), (7, 5, 7), (7, 7, 5), (7, 7, 7) \end{aligned} \quad (24)$$

분할수 집합내 각 분할수 패턴에 대해 본문에서 제시한 방법을 사용하여 단계적으로 8개의 퍼지 제어기를 얻는다. 표 1은 각 단계에서 수행된 유전알고리즘의 실행 파라미터를 나타낸 것이다. 여기서 τ 는 1단계 수행시 가정한 제어규칙 베이스내 각 제어규칙이 학습에 집합내 한 학습예를 포함하는 정도가 너무 낮을 시 이 학습예를 그 제어규칙에 포함되지 않는 것으로 취급하기 위한 포함도의 임계값이다.

표 1. 각 단계 유전알고리즘의 실행 Parameter값

Table 1. Parameter values of GA at each stage.

	1st stage	2nd stage	Ensemble
No. of generation	2000	2000	2000
No. of Population	50	50	100
No. of genes	30~42	30~42	8
No. of k tourname	3	3	3
P _{sel}	0.2	0.1	0.2
P _c	1.0	1.0	1.0
P _m	0.01	0.001	0.005
τ	0.002	-	-

표 2는 8개의 퍼지 제어기를 결합하여 퍼지 제어기 Ensemble을 구성할 때 얻어진 각 퍼지 제어기가 가지는 가중치와 14개의 초기 상태에 대해 각 제어기가 나타내는 평균 제어 오차를 나타낸 것이다. 이 표에서 알 수 있듯이, 평균 제어 오차가 큰 퍼지 제어기일수록 작은 가중치를 보이므로, 각 퍼지 제어기가 퍼지 제어기 Ensemble에 미치는 제어오차는 거의 동일한 크기를

나타낸다.

표 2. 각 퍼지 제어기가 갖는 가중치와 평균 제어 오차
Table 2. Weights and average control errors.

분할수	가중치	평균 제어오차
FC(5, 5 ; 5)	0.164815	0.149
FC(5, 5 ; 7)	0.155434	0.132
FC(5, 7 ; 5)	0.092831	0.215
FC(5, 7 ; 7)	0.186801	0.125
FC(7, 5 ; 5)	0.047374	0.214
FC(7, 5 ; 7)	0.064412	0.201
FC(7, 7 ; 5)	0.163083	0.159
FC(7, 7 ; 7)	0.125250	0.191

그림 9는 3개의 특정한 분할수 패턴에 대해 퍼지 분할 및 소속함수의 미세 조정의 두단계를 거친 다음 얻어진 각 변수의 소속함수와 Wang과 Mendel에 의해 사용된 소속함수를 같이 나타낸 것이다. 이 그림에서 (5,7;7) 분할수 패턴은 Wang과 Mendel에 의해 사용된 분할수 패턴과 같은 것인데, 얻어진 각 소속함수는 매우 다름을 알 수 있으며, 서로 다른 분할수 패턴에 대응하는 퍼지 제어기가 갖는 소속함수는 서로 매우 상이함을 알 수 있다. 이는 각 분할에 대응하는 퍼지 제어기의 제어 특성이 매우 상이함을 나타내며, 이를 서로 다른 제어 특성을 갖는 여러 퍼지 제어기를 합성하여 얻은 퍼지 제어기群이 보다 나은 제어 능력을 보여주는 원인이 된다.

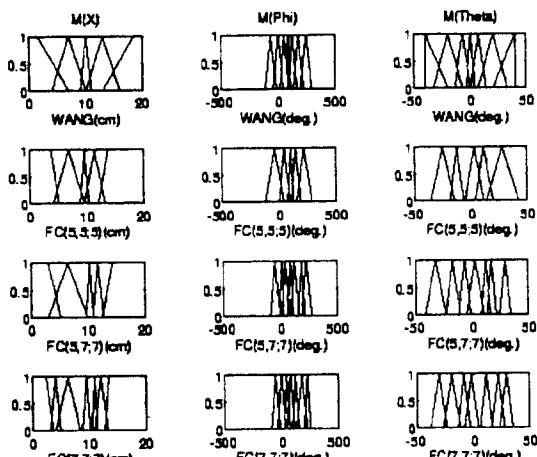


그림 9. 여러 퍼지 제어기의 소속함수들

Fig. 9. Membership function of various FCs.

그림 10은 분할수 패턴 (5,7;7)에 대한 퍼지 제어기 를 설계할 때, 1단계와 2단계 수행시 각 해집단내 모든 Chromosome에 의한 평균 Fitness값을 세대수에 따라 나타낸 것이다. 1단계 수행은 각 변수내 주어진 분 할수 패턴에 대한 학습예집합의 포함도를 최대화되도록 하는 각 변수내 언어 변수들의 근사적 퍼지 분할을 얻는 과정이므로, 세대수에 따른 평균 Fitness값의 변화가 계속적으로 완만하게 진행된다. 따라서, 1단계에서는 많은 세대수동안 진화할 것이 요구되지만, 각 세대당 요구되는 계산이 포함도를 계산하는 정도이므로 전체 진화시간은 바로 제어 오차를 최소화하도록 하는 경우보다 훨씬 적은 학습 시간이 소모된다. 2단계 수행은 1단계에서 얻어진 제어 규칙베이스에 대해 제어 오차를 최소화되도록 각 변수내 언어 변수의 소속함수를 미세 조정하는 과정이므로, 세대수에 따른 평균 Fitness값이 곧바로(약 100 세대수 경과) 최대값에 도달한 후 거의 진화가 일어나지 않는다. 따라서, 2단계에서는 매 세대당 제어 오차를 연산하므로 많은 학습 시간이 요구되지만 진화시 요구되는 세대수가 크지 않으므로 전체 학습시간은 바로 제어 오차를 최소화 하도록 하는 경우보다 역시 훨씬 적은 학습 시간이 소모된다.

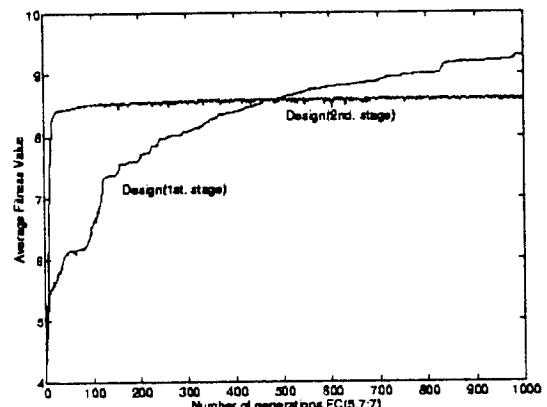


그림 10. 세대수에 따른 평균 Fitness값의 변화

Fig. 10. Avg. fitness value over the number of generations.

그림 11은 공간내 임의의 한 점에서 출발하여 화물 적재대가 놓여 있는 목적지 ($10, *; 90^\circ$)의 인접부근 ($9.9 \leq x \leq 101, *; 89^\circ \leq \phi \leq 91^\circ$)에 도달하기 까지의 주행 경로를 각 퍼지 제어기에 대해 나타낸 것이다. (여기서 *는 임의의 위치값을 가져도 상관없음을 의미 한다.) 이 그림으로부터, 각 퍼지 제어기가 공간내 임

의의 한 시작점에 대해 나타내는 주행 경로 특성은 매우 다름을 알 수 있다. 시작점 (1.6, 6.5; ;38.3°)의 경우, 분할수 패턴 (7, 5; 7)에 대응하는 퍼지 제어기가 가장 빨리 목적지에 도달하는 결과를 보였다.

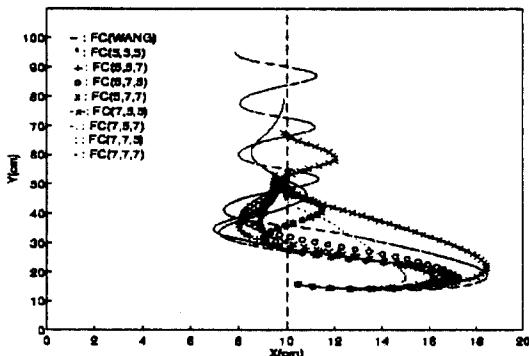


그림 11. 여러가지 퍼지제어기의 주행경로 특성

Fig. 11. Trajectory characteristics.

그림 12는 퍼지 분할수 패턴 (7, 5; 7)에 대해 각 단계에서 얻어진 퍼지 제어기의 주행 경로와 Wang과 Mendel에 의해 사용된 퍼지 제어기의 주행 경로를 4개의 다른 시작점들로부터 구해 서로 비교한 것이다. 1단계 근사 퍼지 분할 과정에서 얻어진 퍼지 제어기는 Wang과 Mendel에 의해 사용된 퍼지 제어기보다 나쁜 제어 특성을 나타내지만, 2단계 소속함수의 미세 조정 과정을 거친 퍼지 제어기는 약간 개선된 제어 특성을 보였으며, 8개의 퍼지 제어기의 합성에 의해 생성된 퍼지 제어기 Ensemble은 매우 향상된 제어 특성을 보였다.

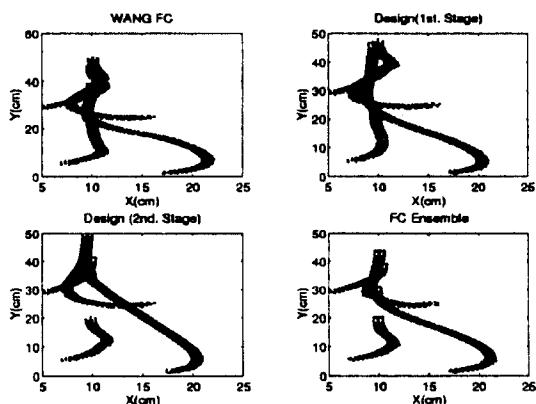


그림 12. 여러 설계 단계에서의 주행경로 특성

Fig. 12. Trajectory characteristics of different design stages.

그림 13은 퍼지 분할수 패턴 (7, 5; 7)에 대해 1단계 각 변수의 근사적 퍼지 분할을 나타내는 제어 규칙 베이스의 진화 정도에 따른 100개의 임의의 시작점에서 도달한 갯수와 도달한 점들에 의한 평균 주행 거리를 Wang과 Mendel이 사용한 퍼지 제어기와 비교한 것이다. 이 그림으로부터, 전체적으로 1 단계에서 얻어진 근사적 제어 규칙 베이스에 기반한 제어 성능은 Wang과 Mendel이 사용한 퍼지 제어기에 비해 떨어졌지만 1 단계의 진화 과정이 계속 될수록 점점 그 제어기의 제어성능이 좋아짐을 알 수 있다.

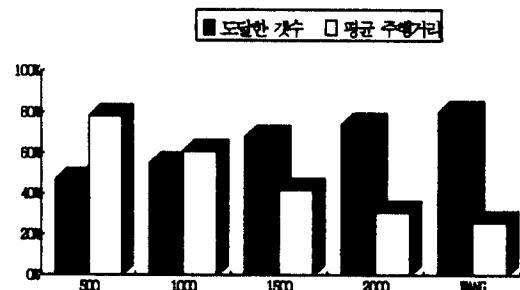


그림 13. 진화정도에 따른 퍼지제어기의 제어능력

Fig. 13. Control performance at different design stages.

그림 14는 각 단계에서 얻어진 퍼지 제어기 및 퍼지 제어기 Ensemble의 제어 능력을 임의로 발생된 1000개의 시작점으로부터 목적지까지 도달하는 점의 갯수와 도달된 점에 의한 평균 주행 거리를 서로 비교한 것을 나타낸다. 여기서 왼쪽 축의 값은 시작점으로부터 목적지까지 도달한 점의 백분율(%)을 나타내고, 오른쪽 축의 값은 도달한 점들의 평균 주행거리(cm)을 나타낸다. 여기서 사용한 퍼지 제어기는 Wang과 Mendel의 제어기와 공평한 비교를 위해 (5,7;5) 분할수 패턴을 갖는 퍼지 제어기를 사용하였다. 먼저, Wang과 Mendel이 사용한 퍼지 제어기는 목표점에 성공적으로 도달한 것이 약 80.5%, 평균 주행 거리는 26.5cm를 나타내었다. 1단계에서 얻어진 근사적 제어규칙에 기반한 제어성능은 Wang과 Mendel의 것보다 도달 성공율 면에서 8.5% 낮고 평균 주행 거리는 4.8cm 길어졌다. 2단계 소속함수의 미세 조정 과정을 거친 퍼지 제어기는 Wang과 Mendel의 것보다 도달 성공율 면에서 9.2% 높고 평균 주행 거리는 3.1cm 짧아졌다. 마지막으로 8개의 퍼지 제어기의 합성에 의해 생성된 퍼지 제어기 Ensemble은 Wang과 Mendel 경우보다

성공률이 8.5% 낮고 평균 주행 거리는 4.8cm 길어졌다. 2단계 소속함수의 미세 조정 과정을 거친 퍼지 제어기는 Wang과 Mendel의 것보다 도달 성공률이 면에서 17.3% 높고 평균 주행 거리는 6.3cm 짧아졌다.

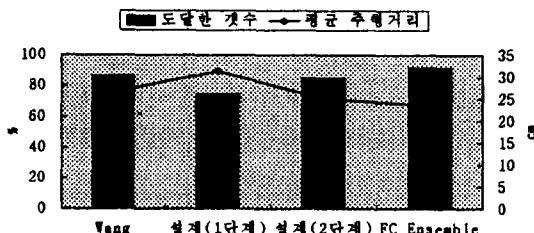


그림 14. 퍼지 제어기 성능 비교

Fig. 14. Comparison of control performance.

V. 결 론

본 논문은 퍼지 제어기를 제어 분야 전문가의 제어 지식이나 경험적 판단에 의존하지 않고 주어진 학습 예로 부터 퍼지 제어기의 제어규칙 베이스와 각 언어변수의 소속함수를 자동적으로 설계하는 방안을 제시하였다. 1단계 과정에서 얻어진 퍼지 제어기는 오직 학습 예 집합의 포함도를 극대화 시키도록 각 언어변수의 소속함수를 극사적으로 결정하였으므로, Wang과 Mendel에 의해 얻어진 퍼지 제어기보다 좋지 않은 제어 성능을 나타내었다. 2단계 과정에서 얻어진 8개의 서로 다른 분할수 패턴에 대응하는 퍼지 제어기는 제어 오차를 최소화 하도록 소속함수를 미세 조정하였으므로, Wang과 Memdel의 퍼지 제어기와 비슷한 분할인 (5,7;7)분할의 경우 훨씬 좋은 제어 성능을 나타내었지만 8개의 퍼지 제어기중에는 Wang과 Mendel의 퍼지 제어기보다 나쁜 제어 성능을 보이는 것도 있었다. 이들 8개의 퍼지 제어기를 유전학적으로 얻어진 가중치를 결합하여 얻어진 퍼지 제어기 Ensemble은 제어 성능과 일반화 특성이 현저히 개선됨을 보였다. 나아가, 본 논문에서 제시한 퍼지 제어기 설계 방법을 활용 및 주가 변동, 기상 변동을 예측하는 시간열 예측 문제에 적용하여 볼 예정이다.

참 고 문 헌

- [1] Li-Xin Wang and Jerry M. Mendel, "Generating Fuzzy Rules by Learning from Examples," *IEEE Transactions on System, Man, and Cybernetics*, vol. 22, no. 6, pp. 1414-1427, Nov. 1992.
- [2] H. Takagi, "Cooperative system of neural networks and fuzzy logic and its application to consumer products," *Industrial Application of Fuzzy Control and Intelligent Systems*, edited by John Yen and Reza Lnagari, Von Nostrand Reinhold, 1993.
- [3] Ioannis Pitas, Evangelos Milios, "A Minimum Entropy to Rule Learning from Examples," *IEEE Transactions on System, Man, and Cybernetics*, vol. 22, no. 4, pp. 621-635, July/August. 1992.
- [4] M. A. Lee and H. Takagi, "Integrating Design Stages of Fuzzy Systems using Genetic Algorithms," *IEEE 2nd Int'l Conf. on Fuzzy Systems*, San Francisco, pp. 612-617, 1993.
- [5] Mark G. Cooper and Jacques J. Vidal, "Genetic Design of Fuzzy Controllers: The Cart and Jointed-Pole Problem," *The Third IEEE International Conference On Fuzzy System*, pp. 1330-13371, June 1994.
- [6] J. Holland, "Adaptation in Matural and Artificial Systems," *University of Michigan Press*, 1976.
- [7] J. L. Castro, M. Delgade and F. Herrera, "A Learning Method of Fuzzy Reasoning by Genetic Algorithms," *The Proceeding of First European Congress on Fuzzy and Intelligent Technologies*, vol. II, pp. 804-809, Aachen, Germany, Sept. 1993.
- [8] David E. Goldberg and Kalyanmoy Deb, "A Comparative Analysis of Selection Schemes Used in Genetic Algorithms," *Fundamental of Genetic Algorithms (Edited by Gregory J. E Rawlins)*, Morgan Kaufmann Publisher, pp. 69-93, 1991.
- [9] L. K. Hansen and P. Salamon, "Neural Network Ensembles," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. PAMI-12, no. 10, pp. 993-1001, Oct. 1990.
- [10] Richard L. Scheaffer and James T. McClave, "Probability and Statistics for

- Engineers," *PWS-KENT Publishing Company*, Boston, USA, 1990.
- [11] John L. Hennessy and David A. Patterson, "Computer Architecture A Quantitative Approach," *Morgan Kaufmann Publishers, INC.* San Mateo, USA, 1990.
- [12] Derrick H. Nguyen and Bernard Widrow, "The Truck Backer-upper: An Example of Self-Learning in Neural Networks," *IEEE Control Systems Magazine*, vol. 10, no. 3, pp. 18-23, 1990.
- [13] Seong-Gon Kong and Bart Kosko, "Adaptive Fuzzy Systems for Backing up a Truck-and-Trailer," *IEEE Transactions on Neural Networks*, vol. 3, no. 2, March 1992.
- [14] Li-Xin Wang And Jerry M.Mendel, "Generating Fuzzy Rules from Numerical Data, with Applications," *USC-SIPI Report*, No. 169, 1991.

저자소개



金 大 鐘(正會員)

1981년 2월 연세대학교 전자공학
과(공학사). 1984년 2월 KAIST
전기 및 전자공학과(공학석사).
1991년 8월 Syracuse 대학
ECE(공학박사). 1984년 3월 ~
1987년 2월 KBS 기술연구소
HDTV 팀. 1992년 3월 ~ 현재 동아대학교 컴퓨터
공학과 조교수. 주관심분야는 화상처리, 소프트 컴퓨팅,
VLSI/ASIC 설계등임



洪 政 澈(正會員)

1993년 2월 동아대학교 컴퓨터공학
과(공학사). 1995년 2월 동아대학교
컴퓨터공학과(공학석사). 1995년 3
월 ~ 현재 기아 정보 시스템 주식회
사 연구원. 주관심분야는 패턴 인식,
퍼지 제어등임