

유전알고리즘 · 신경회로망 · 퍼지논리가 결합된 지능제어기의 구현

이상부* · 김형수*

*제주한라대학 컴퓨터정보계열

요 약

퍼지 제어기(FLC)는 고전적인 제어기 보다 외란에 강하고 초기치에 대한 과도응답도 우수할 뿐만 아니라 시스템의 수학적 모델과 파라메터 값을 알지 못하더라도 적절한 제어가 가능하다. 그러나 퍼지 제어기의 제어 규칙 생성은 전문가의 경험과 일단 결정된 제어 규칙은 고정됨으로 인해 제어 시스템의 환경변화에 적응할 수 없는 한계성이 있다. 또한 제어기의 출력값은 미세한 오차를 가지고 있어 정확한 목표 값에 수렴할 수 없다. 이러한 미세한 오차를 없애기 위하여 여러 가지 방법이 연구되고 있는데, 본 논문에서는 FLC에 NN(Neural Network)과 GA(Genetic Algorithm)를 결합한 GA-FNNIC(유전알고리즘-퍼지 신경망 지능 제어기 : Genetic Algorithm - Fuzzy Neural network Intelligence Controller)를 제안한다. 제안된 GA-FNNIC와 FLC 제어기 간의 출력 특성, 수렴속도, 과도특성과 상승시간에 대해 비교 분석하고, 최종적으로 본 GA-FNNIC가 오차없이 목표치에 정확하게 수렴하는 것을 보인다.

Realization of Intelligence Controller Using Genetic Algorithm · Neural Network · Fuzzy Logic

Sang-Boo Lee* · Hyung-Soo Kim*

ABSTRACT

The FLC(Fuzzy Logic Controller) is stronger to the disturbance and has the excellent characteristic to the overshoot of the initialized value than the classical controller, and also can carry out the proper control being out of all relation to the mathematical model and parameter value of the system. But it has the restriction which can't adopt the environment changes of the control system because of generating the fuzzy control rule through an expert's experience and the fixed value of the once determined control rule, and also can't converge correctly to the desired value because of having the minute error of the controller output value. Now there are many suggested methods to eliminate the minute error, we also suggest the GA-FNNIC(Genetic Algorithm Fuzzy Neural Network Intelligence Controller) combined FLC with NN(Neural Network) and GA(Genetic Algorithm). In this paper, we compare the suggested GA-FNNIC with FLC and analyze the output characteristics, convergence speed, overshoot and rising time. Finally we show that the GA-FNNIC converge correctly to the desirable value without any error.

I. 서론

고전적인 제어 방법은 제어대상 시스템의 수학적 모델링에 의존하였다. FLC는 수학적 모델이나 파라미터 값을 알지 못하더라도 제어가 가능하며 PID 등의 고전적 제어기에 비해 비선형 시스템에서는 유연한 제어성능을 발휘하고 있지만, 최적규칙의 선정 및 제어변수의 양자화 Level 선정 등에 있어서 문제점이 지적되고 있다. 특히, 속응성과 정확성이 요구되는 서보 시스템을 PID 제어하는 경우 출력응답은 목표치에 정확히 수렴하지만 부하변동에 의한 과도특성과 수렴속도의 성능도 문제가 된다[1]. 이에 비해 FLC는 부하변동에 대해 과도특성은 양호하지만 목표치에서 약간의 오차가 존재하는 결점이 있다. 학습의 능력을 가지고 있는 지능 시스템인 신경망은 오차 역전파(error backpropagation) 학습 규칙에 의해 환경변화의 적응성에는 우수하지만 최급강하법(gradient descent rule)이라는 수학적 방법에 근거함으로써 지역적 최소점(local minimum)에 수렴하여 최적화된 해를 구하지 못하는 경우도 생긴다. 유전알고리즘은 전역적(global)인 최적해를 구하는데 우수하지만 해집합이 클 경우 최적화하는데 많은 시간이 걸리고 off-line의 학습 구조이므로 제어 시스템에 적용할 경우 외부환경의 변화에 대하여 적응 제어를 할 수 없는 문제점을 가진다.

위와 같은 각각의 제어시스템의 알고리즘 문제점을 상호 보완하기 위한 여러 방법이 제안되고 있지만[2-5], 본 논문에서는 퍼지 제어기에 신경망과 유전알고리즘을 결합한 GA-FNNIC(유전알고리즘-퍼지신경망 지능제어기: Genetic Algorithm-Fuzzy Neural Network Intelligence Controller)를

제안한다. 퍼지 제어기의 전진부를 신경망 구조로 하고 비퍼지화부를 신경망으로 학습시켜서, 오차 역전파에 의해 전진부의 소속함수를 시스템에 적용토록 수정시킨다. GA-FNNIC는 먼저 유전알고리즘을 이용하여 최적의 소속함수(membership function)값을 구해서 불확실한 시스템에 대한 근사적 소속함수를 구한다. 이 근사적 소속함수 값을 초기치로하여 지능 제어 구조를 가진 FNNIC가 제어대상에 적용하는 퍼지 제어규칙의 전진부 소속함수 값을 자동으로 수정하여 정밀 제어를 실현한다.

II. FLC · NN · GA

본 논문에서 적용하고 있는 이론은 퍼지제어기(FLC), 신경회로망(NN)과 유전알고리즘(GA)으로 각 이론의 특성을 기술하면 아래와 같다.

2.1 FLC

본 논문에서는 Mamdani가 제안한 MAX-MIN 퍼지 추론 합성 규칙을 사용한다. MAX-MIN 합성 규칙은 식(1), 식(2)와 같다.

$$\text{○합의 : } \mu_R(e, ce, co) = \text{MIN}(\mu_E(e), \mu_{CE}(ce), \mu_{CO}(co)) \quad (1)$$

$$\text{○추론 : } \mu_{CO}(co) = \text{MAX-MIN}(\mu_E(e'), \mu_{CE}(ce'), \mu_{CO}(co)) \quad (2)$$

(단, e' , ce' : 제어기 입력의 실수값 co' : 추론된 제어기 출력값 μ : 소속함수 값)


본 논문에서 사용한 비퍼지화는 식(3)의 무게 중심법(center of gravity)에 의해 실행된다.

$$CO^* = \frac{\sum(\mu_s \times \mu_v)}{\sum \mu} \quad (3)$$

(단, CO^* : 비퍼지값, \sum : 값의 합, μ : 소속함수 값, μ_s : 소속함수값을 갖는 대집합, μ_v : 해당 대집합의 소속 함수값)

2.2 NN

본 논문에서 사용한 다층 신경망(multi layer neural network)의 구조는 [그림 1]과 같이 입력층, 은닉층, 출력층으로 구성되고 다층 신경망의 학습방법으로는 오차 역전파 알고리즘을 사용한다.



(그림 1) 다층 신경망의 구조

은닉층 뉴런 출력 H_j 는 식(4)와 같으며 출력층 뉴런 출력 OUT_i 는 식(5)로 구해진다.

$$H_j = f\left(\sum_{k=1}^n W_{jk} \cdot X_k\right) \quad (4)$$

$$OUT_i = g\left(\sum_{j=1}^m W_{ij} \cdot H_j\right) \quad (5)$$

여기서 $f(\cdot)$ 와 $g(\cdot)$: 임계함수

최소오차 자승법으로 평가함수는 식(6)과 같다.

$$E = \frac{1}{2} \sum_{i=1}^n (R_i - OUT_i)^2 \quad (6)$$

또한 출력층 뉴런과 은닉층 뉴런사이의 연결 가

중치는 델타규칙으로 식(7)과 식(8)에 의해서 수정되고 연결 가중치의 수정은 최급 강하법에 따른다.

$$W_{ij}(n) = W_{ij}(n-1) + \Delta W_{ij}(n) \quad (7)$$


$$\begin{aligned} \Delta W_{ij(n)} &= -\eta \frac{\partial E}{\partial W_{ij}} + \alpha \Delta W_{ij}(n-1) \\ &= \eta \delta_i H_j + \alpha \Delta W_{ij}(n-1) \\ &= \eta (R_i - OUT_i) g'(NET_i) H_j \\ &\quad + \alpha \Delta W_{ij}(n-1) \end{aligned} \quad (8)$$

2.3 GA

GA는 생물학적 유전인자인 염색체에 해당하는 문자열을 가지고 생물과 같은 재생산(reproduction), 교배(crossover), 돌연변이(mutation)를 통하여 진화과정을 발전하면서 다음 세대의 새로운 자손을 만들어 낸다. 이 GA는 전역적(global)인 최적해를 발견할 높은 가능성을 가진다는 장점과 목적 함수값(objective function value)에 대한 수학적 제약이 거의 없기 때문에 여러 분야에 적용할 수 있다[6-10]. GA의 성능은 교배율, 돌연변이율, 해집단의 크기, 각 파라미터의 값, 목적함수 설정과 적합도 값의 scaling등에 좌우된다 [7][8].

III. FLC에 NN을 결합한 FNNIC


FLC에 NN을 결합한 FNNIC 구조는 [그림 2]와 같다.



(그림 2) FNNIC의 구조

(그림 2)는 퍼지 규칙의 조건부와 입력의 부합 정도를 계산하는 BOX A와 부합정도에 따라 결론부의 언어항을 합성하여 비퍼지화 연산을 하는 BOX B의 두 개 부분으로 구성된다. (그림 2)는 입력변수 X_i 가 m 개이고, 출력변수 Y_j 가 n 개인 k 개의 퍼지 규칙 R_k 로 구성된 다음과 같은 퍼지 시스템에 대한 퍼지-신경망이다. (그림 2)에서 a_k 는 퍼지규칙 R_k 와 입력과의 부합정도를 나타낸다. 퍼지 규칙의 조건부에 해당하는 정보는 BOX A에 들어 있고, 결론부에 대한 정보는 BOX B에 구현되어 있다. 따라서 조건부의 소속함수에 대한 조정은 BOX A에서 일어난다. BOX B는 신경회로망의 함수근사화 능력을 이용하여 비퍼지화 연산에 대한 부분을 다층 신경망으로 구현한다. 주어진 부합정도

$(\alpha_1, \alpha_2, \dots, \alpha_t)$ 에 대해 결론부의 언어항을 합성하고 비퍼지화하여 기대하는 값 δ_i 을 구한다. 이 때 학습데이터는 $(\alpha_1, \alpha_2, \dots, \alpha_t, \delta_i)$ 가 된다. 퍼지-신경망 모델의 구성은 (그림 3)과 같고 BOX B는 3층의 다층 퍼셉트론으로 구성된다.



(그림 3) FNNIC의 모델

(그림 3)의 BOX B에서 k 층의 신경세포에는 조건부와 입력의 부합정도가 입력으로 들어오고, i 층의 신경세포에서는 부합정도에 따라 결론부가

합성되어 비퍼지화된 것과 같은 값이 출력된다. j 는 한개 이상의 중간층이다. 이 신경망의 학습에는 오차 역전파 학습 규칙을 사용한다. 성능평가 척도 E 는 식(9)와 같이 기대되는 값 δ_i 와 실제출력값 O_i 의 차와 제곱합을 사용한다.

$$E = \frac{1}{2} \sum (\delta_i - o_i)^2 \quad (9)$$

이 때 오차 역전파 학습 규칙에 따른 출력층 i 와 중간층 j 간의 연결가중치 조정값 ΔW_{ij} 는 연쇄법칙(Chain Rule)에 의해 식(10)과 같이 계산된다.

$$\begin{aligned} \Delta w_{ij} &= -\eta \frac{\partial E}{\partial w_{ij}} = -\eta \frac{\partial E}{\partial o_i} \frac{\partial o_i}{\partial net_i} \frac{\partial net_i}{\partial w_{ij}} \\ &= \eta (\delta_i - o_i) f'_i(net_i) o_j \end{aligned} \quad (10)$$

중간층 j 와 입력층 k 간의 가중치 조정값 ΔW_{jk} 는 식(11)과 같이 계산된다.


$$\begin{aligned} \Delta w_{jk} &= -\eta \frac{\partial E}{\partial w_{jk}} = -\eta \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial w_{jk}} = -\eta \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial net_j} o_k \\ &= \eta \left(-\frac{\partial E}{\partial o_j} \right) f'_j(net_j) o_k = \eta \sum \epsilon_i w_{ij} f'_j(net_j) o_k \\ &= \eta \epsilon_j o_k \end{aligned} \quad (11)$$

실제 학습에서는 학습율 η 뿐만 아니라 관성율(Momentum Rate) β 도 고려하여 가중치 조정값은 식(12)와 같이 계산한다.

$$\begin{aligned} \Delta w_{ij}(t) &= \eta \frac{\partial E}{\partial w_{ij}} + \beta \Delta w_{ij}(t-1) \\ \Delta w_{jk}(t) &= \eta \frac{\partial E}{\partial w_{jk}} + \beta \Delta w_{jk}(t-1) \end{aligned} \quad (12)$$

조건부에 허용되는 언어항은 다음과 같은 삼각 퍼지숫자로 제한한다. 여기에서 x 는 입력이고 cm

은 꼭지점의 위치이며, S_L^m 과 S_R^m 은 각각 중심(꼭지점)에 대한 왼쪽과 오른쪽의 폭이다. 이에 대한 것이 (그림 4)이다.



(그림 4) 조건부 언어항의 삼각퍼지 소속함수

$$N_C^m, S_L^m, S_R^m(x) = \begin{cases} 1 - \frac{x - c^m}{S_R^m} & x \in [c^m, c^m + S_R^m] \\ 1 + \frac{x - c^m}{S_L^m} & x \in [c^m - S_L^m, c^m] \\ 0 & \text{otherwise} \end{cases} \quad (13)$$

(그림 3)의 m층에서 (그림 4)와 같이 입력의 언어항에 대한 소속정도는 식(13)으로 계산된다. 여기서 입력과 퍼지 규칙의 조건부와의 적합정도를 계산하는 BOX A는 (그림 3)과 같이 구성되어 있다. 입력층 n에는 각 입력변수에 대해 한 개의 신경세포가 할당되어 있고, 중간층 m에는 각 입력변수에 대해 정의된 언어항들에 대해 언어항을 나타내는 신경세포가 있다. 중간층의 신경세포는 자신이 가지고 있는 언어항의 소속 함수에 대한 입력의 소속 정도를 출력한다. 중간층 신경세포는 소속 함수를 나타내는 파라미터로서 중심 C_m 과 폭 S_L^m, S_R^m 에 대한 값을 가지고 있고, 이 값들이 성능 향상을 위해 조정될 대상이다. 출력층 l에 있는 신경세포들은 각 퍼지 규칙의 조건부를 나타내게 되고, 이 신경세포들에서는 중간층에서 계산한 입력과 규칙의 언어항간의 부합 정도를 Min 연산에 의해 결합하는 역할을 한다. 그리

고 이들 신경세포의 출력값은 BOX B의 입력으로 들어가게 된다. (그림 3)의 n층에서 각 노드는 하나의 입력변수에 해당하고, 이 입력변수에 대해서 정의된 언어항을 나타내는 m층의 노드들과 연결된다. l층의 노드는 각각 퍼지 규칙의 조건부에 해당하고, m층에서 계산된 부합정도를 최소값 연산등을 통해 합성하는 역할을 한다. k층에는 출력변수에 정의된 언어항의 개수만큼 노드가 있고, 노드는 각 언어항에 대응된다. 그리고 대응하는 언어항을 결론부에 가지고 있는 퍼지 규칙들의 부합 정도를 최대값 연산등을 통해 합성하는 역할을 한다. BOX A에서의 노드 개수, 인접층간의 연결관계 등의 구조는 주어진 퍼지 규칙의 분석을 통해서 구성된다. 이때 인접층 노드간의 연결강도 $W_{k\ell}, W_{\ell m}, W_{mn}$ 는 1로 고정된다. [그림 3] BOX A는 최급강화법을 사용하여 학습하며, 기대 출력을 t_k , 실제 출력을 o_k 라 하고, 시스템의 오차 E' 을 식(14)와 같이 정의한다.

$$E' = \frac{1}{2} \sum_k (t_k - o_k)^2 \quad (14)$$

(그림3) BOX A의 학습을 위해 $-\frac{\partial E'}{\partial o_k} = (t_k - o_k) = \epsilon_k$ 의 값으로 BOX B의 k층에서 역전파된 오차 ϵ_k 를 사용한다. 이 값을 토대로 BOX A의 m층의 언어항 파라미터를 식(15), 식(16), 식(17)과 같이 조정한다. 여기에서는 퍼지 규칙의 조건부 언어항의 입력과의 부합 정도를 최소값 연산에 의해 합성하고, MAX-MIN 추론을 하는 경우에 대한 것이다.

$$\begin{aligned} \Delta c^m &= -\eta \frac{\partial E'}{\partial c^m} = -\eta \sum_k \frac{\partial E'}{\partial o_k} \frac{\partial o_k}{\partial c^m} \\ &= -\eta \sum_k \frac{\partial E'}{\partial o_k} \sum_{\ell} \frac{\partial o_k}{\partial o_{\ell}} \frac{\partial o_{\ell}}{\partial o_m} \frac{\partial o_m}{\partial c^m} \end{aligned}$$

$$= \eta \sum_k \epsilon_k \sum_\ell \frac{\partial o_k}{\partial o_\ell} \frac{\partial o_\ell}{\partial o_m} \frac{\partial o_m}{\partial c^m} \quad (15)$$

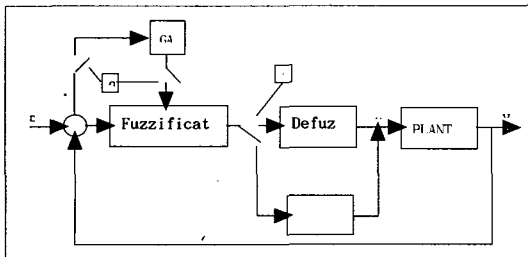
$$\Delta S_L^m = -\eta \frac{\partial E'}{\partial S_L^m} = \eta \sum_k \epsilon_k \sum_\ell \frac{\partial o_k}{\partial o_\ell} \frac{\partial o_\ell}{\partial o_m} \frac{\partial o_m}{\partial S_L^m} \quad (16)$$

$$\Delta S_R^m = -\eta \frac{\partial E'}{\partial S_R^m} = \eta \sum_k \epsilon_k \sum_\ell \frac{\partial o_k}{\partial o_\ell} \frac{\partial o_\ell}{\partial o_m} \frac{\partial o_m}{\partial S_R^m} \quad (17)$$

(그림 3)의 퍼지-신경망 모델을 실험하기 위하여 BOX A에서는 삼각형 소속함수를 사용하여 조건부의 소속함수를 수정하고 BOX B에서는 오차 역전파 학습 규칙으로 신경망을 학습시킨다.

IV. FNNIC에 GA를 결합한 GA-FNNIC

본 논문에서 제안한 FNNIC에 GA를 결합하여 최적의 퍼지 소속함수를 구하는 GA-FNNIC 구조는 (그림 5)와 같다



(그림 5) GA-FNNIC의 구조

GA-FNNIC 구조에서 NN과 GA는 다음과 같은 문제점을 가지고 있다. NN은 반복적인 학습에 의하여 인공 지능적인 기능을 가지고 있지만 학습 시간이 길고 지역 최소점에 빠질 수 있는 문제로 최적화된 해를 구하지 못하는 경우가 생긴다. GA

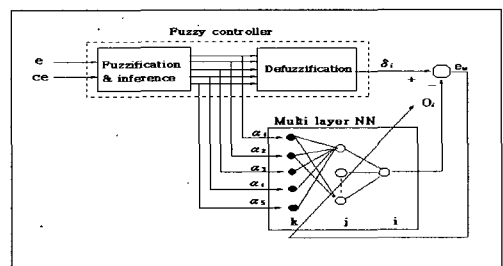
는 전역적인 최적해를 구하는데 있어서는 가장 적합한 알고리즘이지만 적응제어를 위한 on-line 방식을 채택할 수 없는 단점을 가진다. 그래서 이들의 문제점을 서로 보완하기 위하여 (그림 5)의 on-line 제어 방식에 의한 GA-FNNIC의 소속함수 수정 방법은 다음과 같다.

단계 1 : 먼저 퍼지 제어기의 비퍼지화 부분을 신경망을 사용하여 함수 근사화 시켜서 신경망의 가중치를 고정시킨다. 이것은 on-line에 의한 소속함수의 파라미터 조정부분에서 사용하기 위함이다.

단계 2 : ②를 GA로 on 시키고 ①를 비퍼지화로 on 시켜 퍼지 제어기의 소속함수 형태를 GA에 의한 유전자 생성으로서 최적화 값을 얻는다. 이때에는 염색체 선정 방식에 의해 근사화된 소속함수 파라미터 C_m, S_Lm, S_Rm 을 구한다.

단계 3 : 단계 2에서 얻어진 근사화된 초기 소속함수 형태를 퍼지 신경망 제어기의 소속함수로 고정시켜서 신경망의 역전파 알고리즘을 이용하여 on-line 방식에 의한 적응성을 갖도록 한다. 이때에는 ②를 off 시키고 ①를 신경망으로 근사화된 비퍼지화로 on 시킨다.

(그림 5)의 제어기에서 먼저 다층 신경망을 이용하여 비퍼지화 부분을 함수 근사화시키는 것을 (그림 6)에 나타내었다. (그림 6)에서 α_k 는 단순 퍼지 제어기의 퍼지추론부 출력이다.



(그림 6) 신경망을 이용한 비퍼지화 함수의 근사화

(그림 6)에서 다층 신경망으로 비퍼지화 부분을 함수 근사화하기 위하여 입력 e 와 ce 을 -1에서 +1까지 각각 0.005, 0.02씩 증가시킨 값을 입력력으로 하였다. 이것은 실제 제어신호를 구할 수 있도록 하기 위함이다. 제어 신호는 다층 신경망에 의한 비퍼지화 함수근사화를 위한 출력 교차신호로써 사용된다. 다층 신경망의 입력은 퍼지 제어기에서 비퍼지화 연산 전의 규칙에 의해 얻어지는 퍼지화 값을 사용한다. 물론 입력되는 오차, 오차변화가 교차신호와 한 쌍의 입·출력 패턴을 구성한다. 비퍼지화 함수 근사화를 위한 학습 알고리즘은 신경망에서 순방향 부분의 연산을 수행하여 식(18)과 같이 출력을 구하는 것으로부터 시작된다.

$$O_i = f(\text{net}_i)$$

$$\text{net}_i = \sum W_{ij}O_j \quad (18)$$

(단, W_{ij} : j 층과 i 층의 가중치, O_j : j 층의 신경세포 활성화값)

순방향 연산에 의해 얻어진 제어신호 O_i 는 동일, 입력에 대한 단순 퍼지 제어기에서 나오는 제어신호 δ_i 와 학습평가를 위해 비교된다. 그리고 이에 따른 결과로 역방향 학습 알고리즘을 수행한다. 가중치 수정을 위하여 오차 역전과 학습 규칙을 사용한다. 성능평가 척도 E_U 는 기대되는 값 δ_i 와 실제 출력값 O_i 의 차의 제곱으로 식(19)와 같다.

$$E_U = \frac{1}{2}(\delta_i - O_i)^2 \quad (19)$$


이때 오차 역전과 알고리즘에 따른 출력층 i 와 중간층 j 간의 가중치 조정값은 연쇄법칙에 의해 식(10)과 같이 계산된다. 중간층 j 와 입력층 k 간의 가중치 조정은 식(11)에 의해 계산된다.

퍼지 추론부의 언어항 소속함수를 시스템에 맞도

록 수정하기 위해 m 층의 각 파라미터 C_m, L_m, R_m 을 식 (3-10), 식 (3-11), 식(3-12)와 같이 수정한다. 본 논문에서는 근사적인 퍼지 소속함수를 구한 다음 적응학습을 통하여 퍼지 소속함수의 최적 값을 찾는다.

유전자 구조는 (그림 7)과 같이 설정하였다. 여기서 각 유전자는 m 개의 염색체를 갖는다. 오차(e)와 오차변화(ce)의 모든 퍼지소속함수에 대한 중심과 폭을 해로 하여 염색체를 설정할 경우 정상상태의 해를 얻기 위해서는 많은 세대를 반복해야 하므로 본 논문에서는 10개의 염색체로 한정하여 다음과 같이 설정한다.

- a : e 의 PM 중심, b : e 의 PB 중심,
- c : e 의 PM 좌폭, d : e 의 PM 우폭,
- e : e 의 PB 좌폭, f : ce 의 PM 중심,
- g : ce 의 PB 중심, h : ce 의 PM 좌폭,
- i : ce 의 PM 우폭, j : ce 의 PB 좌폭



(그림 7) 10진 형태의 유전자 구조

각 염색체는 실수형 문자열 형태의 유전자 구조를 (그림 7)과 같이 각 소속함수에 3개씩의 실수 스트링을 배당하며 2진 비트에 대한 디코딩 작업을 생략하여서 세대 진화과정을 빠르게 하였다. 이렇게 얻어진 각 염색체 정보는 다음과 같은 시스템의 안정화를 위한 제약사항과 더불어 소속함

수의 형태를 결정하였다. 먼저 ZO를 중심으로 좌측과 우측을 대칭으로 설정하였다. 즉 양의 부분만을 얻어서 음의 부분을 설정하였다. 그리고 ZO의 중심은 고정시키고 ZO의 좌, 우폭값은 PB의 중심에서 PB의 좌폭값을 뺀 것으로 처리하였다. 시스템의 안정화를 위하여 PM의 좌폭은 PM의 중심값보다 크지 않도록 하였다[11]. 초기 세대 유전자는 안정화된 세대진화를 위하여 각 퍼지수에 적절한 영역을 설정하여 다음 세대를 생성하도록 하였다. 세대를 진화시키는 요소는 앞의 염색체 구조와 교배율, 돌연변이율 그리고 다음의 평가함수에 의해 크게 좌우된다. 이 평가함수는 시스템에 있어서 적합한 유전자인가를 평가할 수 있는 적합도 함수이다. 여기서 사용한 평가함수는 오차와 오차변화를 최소로 하는 것을 목적으로 한다. 따라서 식(20)과 같이 오차와 오차변화의 제곱 누적을 평가함수의 항으로 사용하였다. 여기서, $K_1 + K_2 = 1$ 로 하여 K_1, K_2 를 적절하게 설정한다.

$$F(\text{pop}_i) = \frac{K_1}{1 + \sum_k e_k^2} + \frac{K_2}{1 + \sum_k ce_k^2} \quad (20)$$


V. 시뮬레이션 및 결과

시뮬레이션에서 사용한 가상 2차계 플랜트 차분 방정식은 식(21)과 같다.


$$Y(k) = 1.3678 * Y_{-1} - 0.3678 * Y_{-2} + 0.3678 * U_{-1} - 0.2640 * U_{-2} \quad (21)$$

(단, Y_{-1} : 현재의 플랜트 출력, Y_{-2} : 현재보다 한 샘플링 시점 이전의 플랜트 출력, U_{-1} : 현재의 제어기 출력, U_{-2} : 현재보다 한 샘플링 시점 이전의 제어기 출력)


설정치 R은 1600(rpm)의 구형파와 계단파로 정하였고 외란은 설정치의 5%를 가하였다.




(그림 8) FLC출력과 신경망에 의한 비퍼지함수의 FNNIC 출력



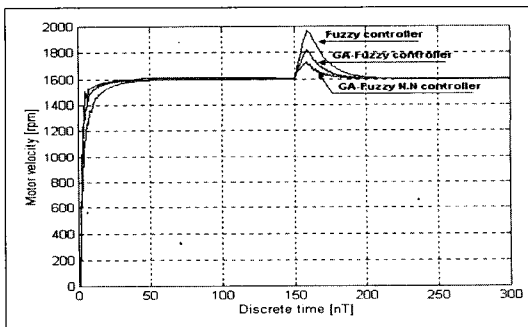
(그림 9) FLC 출력과 GA에 의한 비퍼지함수의 GA-FLC 출력



(그림 10) 구형파 인가시 근사화된 GA-FLC 출력과 NN으로 적응학습후의 FNNIC 출력



(그림 11) 계단과 인가시 근사화된 GA-FLC 출력과 NN으로 적응학습후의 FNNIC 출력



(그림 12) 외란 인가시 FLC, GA-FLC, GA-FNNIC 출력

시뮬레이션에서 각 제어기의 성능을 비교 검토한 결과는 다음과 같다. (그림 8)은 퍼지 제어기에서 비퍼지화 함수를 사용하였을 때의 플랜트 출력파형과 신경망에 의한 함수근사화를 시켰을 때의 플랜트 출력파형을 나타내었다. (그림 8)에서 함수근사화를 위한 신경망의 학습이 거의 완벽하게 나타났다. 신경망에 사용된 각 파라미터 값은 학습을 0.4, 모멘텀을 0.7, 학습수는 2,000이다. (그림 9)는 퍼지 제어기의 퍼지 소속함수 형태를 등간격으로 사용하였을 때의(최적화 전) 플랜트 출력파형과 유전 알고리즘을 이용하여 근사화된

퍼지 소속함수 형태(최적화 후)를 사용하였을 때의 플랜트 출력파형을 비교하였다. 사용된 유전 알고리즘의 파라미터 값은 교배율 0.3, 돌연변이율 0.1, 세대수 40, 집단의 크기는 30개, 40세대 진화후의 누적오차는 0.00493이었다. 유전 알고리즘에 의한 근사화된 퍼지 소속함수 형태가 등간격의 퍼지 소속함수 형태보다 정상상태에 도달하는 시간이 13~15(nT) 정도 빠르다. (그림 10)은 근사화된 퍼지 소속함수 형태를 사용하였을 때의 플랜트 출력파형과 퍼지-신경망 제어기에 의한 적응학습을 시켰을 때의 플랜트 출력파형을 나타내었다. 유전알고리즘을 이용한 근사화된 퍼지 소속함수 형태를 가질 때의 플랜트 출력응답보다도 적응학습후의 소속함수 형태를 가질 때의 플랜트 출력응답은 오버슈트도 없었으며 또한 안정된 출력을 얻을 수 있었다. (그림 11)은 근사화된 퍼지 소속함수 형태를 갖는 플랜트 출력응답과 적응학습 후의 플랜트 출력응답을 비교하기 위하여 계단과 입력에 대한 출력 파형들이다. (그림 11)에서 적응학습 후의 출력파형이 근사화된 퍼지 소속함수 형태를 갖는 출력응답보다 더 우수함을 알 수 있다. (그림 12)는 설정치의 5%를 외란으로 인가 하였을 경우 출력 응답파형을 나타내었다. (그림 12)에서 퍼지 제어기와 GA-퍼지 제어기를 사용한 제어 시스템에서는 각각 20%, 15%의 오차가 발생하였지만 제안된 GA-FNNIC 제어기를 사용한 경우는 7.5%의 편차가 발생하였다.

이상의 결과로부터 본 논문에서 제안한 GA-FNNIC가 FLC보다 외란에도 강하고 정상상태의 오차없이 안정한 정밀제어기가 실현됨을 알 수 있다.

Ⅴ. 결론

퍼지제어기는 제어 환경의 변화에 적응하지 못하는 문제점과 제어 대상이 복잡한 경우 전문가의 경험으로 설계해야하는 어려운 점이 있다. 본 논문에서는 이러한 문제를 해결하기 위하여 FLC에 NN과 GA를 결합한 GA-FNNIC의 인공지능 제어기를 제안하였다. FNNIC에서 NN은 함수 근사화와 학습의 능력을 가져 지능제어를 할 수 있는 장점도 있지만 학습시간이 너무 길고 지역 최소점에 빠질 수 있는 단점도 가지고 있다. 반면에 GA는 전역적인 최적해를 구하는 것에는 가장 적합한 알고리즘이지만 off-line 구조를 가지므로 on-line 적응제어 시스템을 구성할 수 없다.

이러한 문제를 해결하기 위하여 본 논문에서는 GA를 이용하여 NN이 지역 최소점에 빠지는 것을 예방하며 전역적인 최적해를 구해서 불확실한 플랜트에 대한 근사적 소속 함수값을 구한다. 이 근사적 소속 함수값을 초기치로 하여 FNNIC의 on-line 제어기 구조로 플랜트에 적응하는 소속함수를 구하였다. 시뮬레이션 결과 FLC는 목표치에서 미세한 오차를 가지고 있지만 GA-FNNIC은 목표치에 오차없이 정확히 수렴하여 안정된 지능제어가 실현됨을 알 수 있었다. 또한 GA-FNNIC이 FLC보다 수렴속도와 상승시간도 빠르며 외란에도 강한 것을 시뮬레이션을 통해 알 수 있었다.

참고 문헌

- [1] Katsuhiko Ogata, *Discrete-time Control System*, Prentice-Hall, INC., pp. 198-230, 1987.
- [2] 이상부, 김현정, 임영도, "퍼지와 비례제어기를 결합한 Hybrid 제어기의 성능향상에 관한 연구", 인공지능 신경망 및 퍼지시스템 국제 종합 학술대회 논문집, pp. 183-188, 1993.
- [3] 김형수, 이상부, "러프집합 연산에 기초한 퍼지 정보 검색 알고리즘의 설계", 디지털컨텐츠학회 제2회 학술발표대회, 2001
- [4] 이상부, 김형수, "퍼지제어기와 신경망제어기의 응답특성에 관한 연구", 정보처리학회 논문지, Vol.3, No.6, pp. 1473-1482, 11, 1996.
- [5] James J. Buckley, Yoichi Hayashi, "Fuzzy neural networks: A survey", *Fuzzy Sets and Systems*, No.66, pp. 1-11, 1994.
- [6] 李勇, 米澤洋, "DC 모터 사-보系の ファジイ 制御", *日本ファジイ 學會誌*, Vol.2, No.4, pp. 146-151, 1990.
- [7] David E. Goldberg, *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley, INC., PP. 27-82, 1989.
- [8] 이상부, 임영도 공저, 퍼지 신경망 유전진화, 도서출판 영과일, pp. 193-215, 1996.
- [9] L. Davis, *Handbook of Genetic Algorithms*, Van Nostrand Reinhold, 1991.
- [10] Zbigniew Michalewicz, *Genetic Algorithms + Data Structures = Evolution Programs*, Springer-Verlag, INC., pp. 65-69, 1992.
- [11] 이상부, 김승철, 추연규, 임영도, "진화프로그래밍을 이용한 퍼지제어기 소속함수의 추정 에 관한 연구", 대한전자공학회 한국통신학

회 부산경남지부 춘계합동학술대회 논문집,
Vol.5, No.1, pp. 187-194, 1996.



이 상 부

1997년 동아대학교 전자공학과
과 졸 (공학박사)
1985년 동아대학교 전자공학과
과 졸 (공학석사)
1983년 동아대학교 전자공학과
과 졸 (공학사)

1994년~현재 제주한라대학 컴퓨터정보계열교수
관심분야 : 뉴로/퍼지 및 진화연산, 기계학습, 예측시스템, 전자상거래응용



김 형 수

1998년 충북대학교 전자계산학과
학과 졸 (이학박사)
1991년 숭실대학교 정보산업과
과졸 졸(이학석사)
1985년 성균관대학교 정보처리
과 졸 (경영학석사)

1981년 제주대학교 수학교육과 졸(이학사)
1992년~현재 제주한라대학 컴퓨터정보계열교수
관심분야 : 퍼지 및 러프이론, 인공지능, 멀티미디어
컨텐츠, 웹 에이전트 시스템