

기준 모델 추종 기능을 이용한 뉴로-퍼지 적응 제어기 설계

A Design of Neuro-Fuzzy Adaptive Controller using a Reference Model Following Function

이영석, 유동완, 서보혁

(Young-Seog Lee, Dong-Wan Ryoo, Bo-Hyeok Seo)

Abstract : This paper presents an adaptive fuzzy controller using an neural network and adaptation algorithm. Reference-model following neuro-fuzzy controller(RMFNFC) is invesgated in order to overcome the difficulty of rule selecting and defects of the membership function in the general fuzzy logic controller(FLC). RMFNFC is developed to tune various parameter of the fuzzy controller which is used for the discrete nonlinear system control. RMFNFC is trained with the identification information and control closed loop error. A closed loop error is used for design criteria of a fuzzy controller which characterizes and quantize the control performance required in the overall control system. A control system is trained up the controller with the variation of the system obtained from the identifier and closed loop error. Numerical examples are presented to control of the discrete nonlinear system. Simulation results show the effectiveness of the proposed controller.

Keywords: neuro-fuzzy controller, back-propagation method, reference-model fuzzy control, self-organizing fuzzy controller

I. 서론

미지의 변수를 가진 선형 시스템의 적응제어에 관한 연구는 지난 수십년간 꾸준히 연구되어 괄목할 만하게 진보하였다. 하지만 기존의 적응 제어 기법은 시스템의 동특성에 관한 상세한 지식을 필요로 하였으나 동특성의 모든 정보를 실제로 시스템에서 찾아내기가 쉽지 않다. 많은 시스템의 상태 변수 표현에는 동적 시스템과 같은 비선형 특성, 불확정성, 시간지연 특성과 시스템 변수의 변동 등의 동특성 정보들이 존재하게 된다. 이러한 동특성 정보를 가진 시스템의 적응제어는 기존의 적응제어 기법[1]으로는 불가능하다. 그러나 동특성이 있는 시스템 모형을 인간 두뇌의 정성적인 언어로 표현할 수 있으며 이를 바탕으로 하는 퍼지 추론[2]은 애매한 지식들을 정량적으로 표현하고 이를 통해 적절한 의사 결정을 수행할 수 있는 수단으로 제어문제, 패턴 분류 문제[3] 등 여러 분야에서 활용되고 있다. 퍼지 추론은 언어변수들의 결합으로 이루어지는 퍼지 규칙을 이용하여 여러 개의 퍼지 명제들로부터 어떤 하나의 퍼지 명제를 이끌어 낼 수 있는 연역적인 추론 방법이다. Zadeh에 의해 제안된 퍼지 집합 이론은 Mamdani등에 의해 1974년에 제어에 도입되면서 퍼지제어는 퍼지이론 응용에 관한 가장 성공적인 분야로 평가되어 왔으며 실제로 많은 성공 사례들이 이론의 발전과 더불어 보고되고 있다. [4]-[7] 퍼지 제어의 이론적 개념은 플랜트의 동특성에 대한 상세한 지식이 없어도 경험적인 지식과 정보를 이용하여 효과적인 제어를 수행 할 수 있다는 것에 그 근본을 둔다. 따라서 퍼지 제어는 플랜트의 수학적 모형화가 어렵거나 부분적으로 불가능할 경우, 비선형인 경우나 기존의 제어 방법으로는 성능 향상에 한계가 있는 경우에 주로 적용되어 왔다[8][9]. 퍼지 제어기는 비선형성과 잡음에 강하며 또한, 제어가 용

이하다. 인간의 사고 작용을 본뜬 퍼지 추론법에 따라 제어량을 결정하는 과정이 실시간 병렬처리가 가능하기 때문이기도 하다. 그러므로 인간이 경험적으로 얻은 제어 규칙을 쉽게 퍼지 관계로 기술할 수 있는 퍼지 제어가 많은 분야에 응용되고 있지만 퍼지 제어기의 설계에는 많은 매개변수 즉, 제어규칙, 퍼지 집합의 수, 멤버쉽 함수, 입출력 이득 등의 선정에 있어서 수많은 시행착오가 필요하다.

이러한 퍼지 추론에 있어서의 문제점을 해결하기 위해 여러 가지 방법으로 연구가 진행되고 있다. 예를 들면 퍼지 패턴 공간의 분할을 통하여 퍼지 규칙의 자동 생성에 이용하고자 하는 퍼지 공간 분할 방법[8], 경사법을 이용하는 방법[8], 자기구성 제어기(SOC)[10]와 같은 규칙 테이블을 자동 조정이 가능한 방법[11]등이 그것이다. 최근에는 신경망의 학습 기능을 이용하여 최적의 제어규칙을 찾아내고자 하는 연구[12][13]가 활발히 진행되고 있다. 이러한 퍼지 기법과 신경 회로망기법을 융합한 퍼지-신경망 제어 기법[14][15][16]은 기존의 퍼지 제어에서 문제점으로 남아있는 퍼지 규칙의 동정과 소속함수의 조정을 신경망의 학습[17]을 통하여 자동적으로 구현한다.

본 논문에서는 기준 모델 추종기능을 이용한 뉴로-퍼지 제어기의 제어규칙 동조법을 보이며 제어기의 최적의 매개변수를 추정함에 있어 시스템의 역동력학에 기인하지 않고 시스템의 특성을 가진 식별기와 기준 모델로부터의 정보를 이용한다. 시스템의 동력학을 학습하기 위한 식별기의 매개변수를 적용시키기 위한 피드백 루프와 식별기와 기준 모델로부터 제어기의 매개변수를 학습하기 위한 루프로 전체 시스템은 구성된다. 기준 모델은 기준입력에 대해 전체 제어 시스템에 요구되는 제어성능을 특성화하고 수량화하는 뉴로-퍼지 제어기의 설계 기준으로 사용되었다. 비선형 시스템의 제어를 위해 퍼지와 신경망을 합성하고 이를 이용한 제어기와 식별기의 소속함수 매개변수들은 학습을 통하여 자동적으로 동정된다. 학습 알고리듬은 잘 알려져 있는 오차 역전파법을 사용하였으며 플랜트와 모델의 제어오차와 학습된 식별기의 정보로 부터 시스템의 정보를 산출하고 이

를 제어기 구성에 이용하였다.

II. 퍼지제어기의 표현

퍼지 제어기는 숙련 전문가의 경험과 지식에 근거하여 언어적 표현으로 나타내고 이를 제어 전략으로 변환하는 기능을 수행한다. 일반적인 퍼지 제어기는 조건문과 각각의 제어 상황을 정의하는 언어 규칙으로 구성된다[18].

IF (a set of conditions are satisfied)

THEN (a set of consequences can be inferred)

기본적으로 퍼지 제어 규칙은 제어 전략과 지식을 쉽게 표현할 수 있는 기능이 있으며, 전건부와 후건부에 여러 가지 언어변수를 포함한다. 2-입력 1-출력 퍼지 시스템의 경우, i번째 퍼지 제어 규칙은 (1)과 같은 형태로 표현될 수 있다.

$$R_i: \text{If } x_1 \text{ is } A_{il} \text{ and } x_2 \text{ is } A_{2l} \text{ then } y \text{ is } B_i \quad (1)$$

여기서, $i = [1, 2, \dots, n]$ 이며 제어 규칙의 번호이다. x_1, x_2 는 전건부 변수, y 는 후건부 변수이다. A_{il}, A_{2l} 는 퍼지 부분집합으로 정의될 수 있으며 B_i 는 후건부 멤버쉽 함수를 의미한다. i번째 퍼지 규칙은 입출력 변수들의 Cartesian 공간에서 퍼지 관계 R 로 (2)와 같이 정의될 수 있다.

$$\mu R_i \approx \mu(A_{il} \text{ and } A_{2l} \rightarrow B_i) = [\mu A_{il} \oplus \mu A_{2l}] \rightarrow B_i \quad (2)$$

여기서 \oplus 는 퍼지 연산자를 나타내며, \rightarrow 는 퍼지 합의 (implication)를 나타낸다. i번째 규칙의 전건부에 대한 추론 결과는 i번째 규칙의 출력값 B_i 가 플랜트 제어 입력에 대한 기여 정도를 의미한다. i번째 규칙의 기여 정도는 W_i 는 (3)과 같이 정의된다.

$$W_i = \frac{\mu A_{il} \oplus \mu A_{2l}}{\sum_{i=1}^n [\mu A_{il} \oplus \mu A_{2l}]} \quad (3)$$

i번째 규칙에 의한 제어 입력은 i번째 규칙의 후건부 값에 기여 정도를 곱함으로서 얻어지며 플랜트의 총 제어 입력은 모든 제어 규칙에 대한 합으로 구한다.

$$\Delta U = \sum_{i=1}^n W_i \times y \quad (4)$$

이러한 형태로 표현되는 퍼지 제어 규칙에서의 퍼지 연산방법, 룰의 구성과 멤버쉽 함수의 모양, 그리고 후건부의 이득상수를 어떻게 설정하느냐에 따라 제어기의 제어 성능은 달라지게 된다.

그래서 구성상의 복잡성과 퍼지 제어규칙의 자동 생성의 어려움을 극복하기 위한 적절한 형태의 퍼지-신경망을 구성할 필요가 있으며 이러한 구성에 적합한 학습법이 필요하다.

III. 뉴로-퍼지망

1. 뉴로-퍼지망의 구조

2장에서 서술한 퍼지 추론의 문제점을 극복하기 위해 구성된 뉴로-퍼지망은 그림 1과 같은 구성을 가지며 다음과 같은 특성을 가진다. 첫째, 전체 모양이 입력층, 출력층 그리고 3개의 은닉층 즉 5개의 층으로 구성됨으로서 신경망의 구조를 가짐으로서 학습이 용이한 형태가 된다. 둘째, 입력 층에서 출력층으로의 전송 과정은 퍼지추론을 가능케 하는 형태를 가진다. 그리고 세째, 각각의 멤버쉽 함수는 가우시안 활률 함수를 사용함으로서 멤버쉽 함수의 확률 분포를 고려할 수 있다. 네째, 전건부의 멤버쉽 함수의 매개변수와

비퍼지화의 스케일링 계수를 신경망의 학습 알고리듬에 의해 간신히 나감으로서 동적 시스템의 변화에 잘 적응할 수 있다. 이러한 특성을 가지는 뉴로-퍼지망의 구조는 다음과 같다.

①층은 입력층으로서 I개의 입력신호에 대해 I개의 입력단, 멤버쉽 함수의 중심값을 나타내는 I개의 바이어스단과 멤버쉽 함수의 폭을 나타내는 I개의 바이어스단을 가진다. ②층은 각 입력신호에 대한 멤버쉽 함수를 (5)과 같이 표현하는 층으로 퍼지 추론의 전건부에 해당한다. ③층과 ④층을 연결시키는 두 가지 변수 σ, μ 즉, 가우시안 함수의 학습 매개변수가 되는 분산값과 평균값으로 적절한 가우시안 함수를 구현함으로서 다양한 멤버쉽 함수가 구현될 수 있다.

$$H_{ij} = g(X_i, \mu_{ij}, \sigma_{ij}) \quad (5)$$

$$\text{여기서 } g(X_i, \mu_{ij}, \sigma_{ij}) = e^{-\frac{(X_i - \mu_{ij})^2}{2\sigma_{ij}^2}}$$

$$X = [X_1 \ X_2 \ \dots \ X_I]^T$$

$$\mu = [\mu_1 \ \dots \ \mu_n \ \dots \ \mu_{I_1} \ \dots \ \mu_{I_p}]^T$$

$$\sigma = [\sigma_1 \ \dots \ \sigma_n \ \dots \ \sigma_{I_1} \ \dots \ \sigma_{I_p}]^T$$

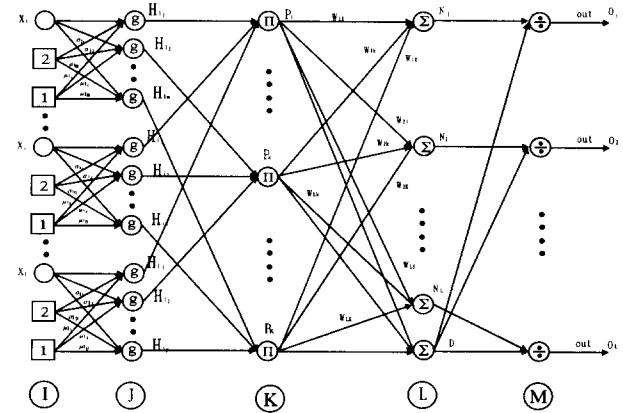


그림 1. 뉴로-퍼지망의 구조.

Fig. 1. Construction of neuro-fuzzy network.

⑤층은 ④층에서 구현된 멤버쉽 함수를 이용해서 다양한 퍼지 규칙 대응을 하기위한 층으로서 (6)으로 표현된다

$$P_k = \prod_{i,j=1}^{I,M} H_{ij} \quad (6)$$

⑥층은 퍼지 규칙에 대응된 퍼지논리에 의해서 생성된 퍼지 값들의 합을 구하는 층으로서 N과 D 노드로 구분시킨다. N노드는 스케일링이 곱해진 퍼지값을, D노드는 퍼지값들을 합한 노드로서 (7),(8)과 같이 나타낼 수 있다. 여기서 ⑥층과 ①층사이에 연결되어 있는 W_{ik} 는 비퍼지화시에 사용되는 스케일링 계수를 나타낸다.

$$N_i = \sum_{k=1}^K P_k W_{ik} \quad (7)$$

$$D = \sum_{k=1}^K P_k \quad (8)$$

⑦층은 ⑥층에서 구한 N_i 과 D를 계산하는 층으로서 (9)과 같다. 이 층은 비퍼지화를 이루는 층으로 뉴로-퍼지망의 최종 출력값이 된다.

$$O_i = out = \frac{N_i}{D} = \frac{\sum_{k=1}^K P_k W_{ik}}{\sum_{k=1}^K P_k} \quad (9)$$

2. 뉴로-퍼지망의 학습

제어 목적에 맞는 퍼지 규칙 베이스를 얻기 위한 출력층에서의 에너지 함수를 (10)과 같이 정의한다. 뉴로-퍼지망의 연결 가중치를 학습 시키는 방법은 이러한 에너지 함수를 최소화하는 알고리듬으로서 역전파 학습 알고리듬에 기초한 것인데 입, 출력 데이터가 필요하며, 최급 강하법을 이용하여 뉴로-퍼지망의 각 매개변수의 갱신량을 계산하게 된다. 그러므로 자동적으로 멤버쉽 함수를 조정하여 최적의 퍼지 규칙을 동정하게 된다.

$$E(t) = \frac{1}{2} \sum_{i=1}^I (d_i(t) - O_i(t))^2 \quad (10)$$

여기서 $d_i(t)$ 는 뉴로-퍼지망의 i 번째 노드의 교사 신호이고 $O_i(t)$ 는 뉴로-퍼지망의 i 번째 노드의 출력신호이다. 뉴로-퍼지망은 (10)과 같은 에너지 함수를 최소화 하도록 각 매개변수가 오차 역전파법에 의해 계산되며 이들의 식들은 다음과 같다. 비퍼지화를 이루는 가중치인 $W_{ik}(t)$ 의 증분량은 오차 신호에 대한 가중치 $W_{ik}(t)$ 의 미분으로서 (11)와 같고, 갱신치는 (12)과 같다.

$$\begin{aligned} \Delta W_{ik} &= -\eta \frac{\partial E}{\partial W_{ik}} = -\eta \frac{\partial E}{\partial O_i} \frac{\partial O_i}{\partial W_{ik}} \\ &= \eta (d_i - O_i) \frac{1}{D} \frac{\partial N_i}{\partial W_{ik}} = \eta (d_i - O_i) \frac{1}{D} P_k \end{aligned} \quad (11)$$

$$W_{ik}(t+1) = W_{ik}(t) + \Delta W_{ik}(t) \quad (12)$$

여기서 η 는 학습률을 나타낸다.

멤버쉽 함수로 사용되고 있는 가우시안 함수의 두 가지 변수인 σ 와 μ 은 (13),(14),(15),(16)에 의해 계산된다.

$$\begin{aligned} \Delta \sigma_{ij} &= -\eta \frac{\partial E}{\partial \sigma_{ij}} = \eta (d - O) \frac{\partial O}{\partial \sigma_{ij}} \\ &= \eta (d - O) \frac{\partial}{\partial \sigma} \left(\frac{N}{D} \right) P_k \\ &= \eta (d - O) \frac{1}{D} W_j f_{ij}(H_{lm}) g'(\cdot)_\sigma X_i \end{aligned} \quad (13)$$

$$\sigma_{ij}(t+1) = \sigma_{ij}(t) + \Delta \sigma_{ij} \quad (14)$$

$$\begin{aligned} \Delta \mu_{ij} &= -\eta \frac{\partial E}{\partial \mu_{ij}} = \eta (d - O) \frac{\partial O}{\partial \mu_{ij}} \\ &= \eta (d - O) \frac{1}{D} W_j f_{ij}(H_{lm}) g'(\cdot)_\mu \end{aligned} \quad (15)$$

$$\mu_{ij}(t+1) = \mu_{ij}(t) + \Delta \mu_{ij}(t) \quad (16)$$

여기서

$$f_{ij}(H_{lm}) = \prod_{l,m} H_{lm}, \begin{cases} H_{lm} = 1 & \text{if } l=i \text{ and } m=j \\ H_{lm} = H_{lm} & \text{otherwise} \end{cases}$$

여기서 $g(\cdot)$ 과 $g'(\cdot)_\sigma, g'(\cdot)_\mu$ 는 멤버쉽 함수값, σ 에 대한 멤버쉽 함수의 미분과 μ 에 대한 멤버쉽 함수의 미분을 나타내며 $g'(\cdot)_\sigma = \frac{\partial g(\cdot)}{\partial \sigma}, g'(\cdot)_\mu = \frac{\partial g(\cdot)}{\partial \mu}$ 이다.

기준의 퍼지 신경망과 비교를 해보면 Horikawa[12]등은 세가지 형태의 퍼지 신경망과 이들의 학습에 대한 방법을 제안하고 퍼지 모델링과 퍼지 제어기를 구성하였다. T. Hasegawa[19]등은 이들을 가지고 식별기와 제어기를 구성하는 한편 “rule-to-rule mapping” 알고리듬을 이용한 제어기 구성 방법에 대해 연구하였다. Horikawa의 시스템은 2-입력, 1-출력으로 구성되어 있으며 구성상 많은 수의 노드와 멤버쉽 함수를 요구하고 있으며 특히 MIMO로 확장

하기 위해서는 많은 형태의 노드가 필요하게 된다. 이러한 형태의 퍼지 신경망은 규칙 맵핑을 위해서도 시행 착오적인 방법을 요구하게 되고 학습시 구조의 불균일성으로 인해서 역전파 알고리듬 사용의 어려움이 생기게 된다. Lin등은 FALCON (Fuzzy Adaptive Learning Control Network)이라는 새로운 형태의 퍼지-신경망을 제안하면서 입, 출력 공간 분할 방법에 대해서 연구하였으나 FALCON-ART의 방법에서는 부적절한 여러 파라메타에 의해 여분의 많은 퍼지 규칙이 생성될 수 있으며 Layer 2와 Layer 4에 멤버쉽 함수가 존재하므로 계산량이 많아지게되고 Layer 3의 룰 설정에 많은 어려움이 있으며 룰의 구성과 제거에 대한 복잡성으로 인해 학습의 어려움이 생기게 된다.

본 시스템은 1개의 층에 멤버쉽 함수의 표현이 가능하고 주어진 멤버쉽 함수의 개수에 따라 학습에 의해 룰을 구성하며 멤버쉽함수는 가우시안 함수를 사용함에 의해 연속시 간영역에 존재하게 되고 MIMO의 형태가 기본적으로 가능함으로 대상 시스템에 따라 확장이 용이하며 전체의 구조가 균일하고 간단하므로 역전파 알고리듬의 사용이 용이하다.

IV. 제어 시스템의 구성

일반적인 기준 모델 추종 적용 제어기[1]의 구성을 그림 2에 나타내었다. 여기서 이상적인 제어기는 시스템의 역동력학을 가지며 기준모델의 특성을 충족시키는 형태로 구성되어야 한다. 이를 식으로 표현하면 (17)과 같이 나타낼 수 있다.

$$C = \frac{M}{P} \quad (17)$$

여기서 C 는 제어기를, M 은 기준 모델 시스템을, P 는 비선형 시스템을 나타낸다.

제어기 설계시에 M 은 요구되는 사양에 맞추어 설계하므로 설계자는 시스템을 완전히 알 수 있다. 그러나 실제로 제작할 수 있는 제어기는 한정된 차수, 시스템의 비선형성, 불확정성등의 표현이 미비하므로 (17)를 만족 시키지 않는다. 그래서 제작된 제어기가 플랜트와 기준 모델의 특성을 잘 추종하며, 기준모델의 출력과 시스템의 출력을 일치 시킬 수 있는 적용 제어 알고리듬이 필요하다. 그림 2는 이를 나타낸것이며 (18)과 같이 표현할 수 있다.

$$\hat{C} \approx \frac{M}{P} \quad (18)$$

그러나 제어할려는 미지의 시스템의 차수, 비선형성, 불확정성, 매개변수의 변동, 그리고 외란등의 여러가지 요인이 있는 비선형 시스템이라면 제어기의 매개변수를 완전히 알 수는 없다. 그러므로 시스템으로부터 여러가지 정보를 알기 위해서 그림 2에 시스템의 식별기를 첨가하여 시스템의 정보를 제어기 설계시 이용할 필요가 있다. (18)은 시스템 식별기의 정보를 이용하면 (19)로 바뀐다.

$$\hat{C} = \frac{M}{\hat{P}} \quad (19)$$

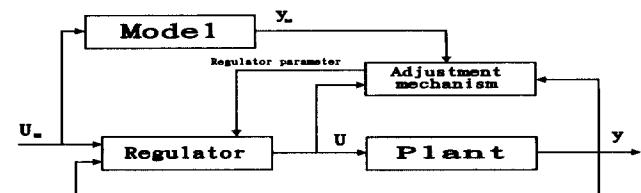


그림 2. 일반적인 기준 모델 적용 제어기의 구성.

Fig. 2. Construction of model reference adaptive control in generally.

여기서 식별기의 구성은 설계자에 의해서 구현이 되므로 그 구성요소를 설계자는 알 수 있다. 그러므로 만약 식별 오차가 최소의 상태에 있다면 미지의 시스템에 대한 정보를 시스템의 식별기는 근사적으로 구할 수 있다. 식별기의 구성 요소로는 시스템의 입력값들과 출력값들이며, 시스템의 출력값과 식별기의 출력값의 오차를 최소화하기 위한 적응 알고리듬에 의해 식별기는 최적의 상태로 시스템을 학습하게 된다.

시스템에 근사한 식별기가 구성되면 제어기의 출력, 즉 시스템의 입력이 식별기의 입력이되고 이에 따른 식별기의 출력이 시스템의 출력이라고 생각할 수 있으므로 제어기의 매개변수를 적용시키기 위한 시스템의 정보를 식별기로부터 이끌어 낼 수 있으며 기준 모델과 시스템 출력의 차를 최소화 하기 위한 적응 제어 알고리듬을 이용하여 제어기의 매개변수를 개선한다. 이렇게 개선된 매개변수를 제어기의 매개변수로 사용하여 시스템을 제어한다. 제어기의 출력에 대한 시스템의 응답을 식별기는 다시 오차를 줄이기 위한 알고리듬에 의해 학습하게 되고 이러한 식별기를 제어기는 이용한다. 이러한 형태로 전체 폐루프 시스템은 동작한다. 그림 3은 이러한 전체 제어 시스템의 구성을 나타낸 것이다.

그림 3에서 식별기의 구성을 위한 폐루프와 적응 알고리듬이 있고, 제어기의 구성을 위한 적응 알고리듬과 루프가 있다. 식별기가 개선되면 식별기의 정보를 제어 알고리듬 루프의 식별기 부분에서 이를 이용하여 적응 제어알고리듬을 수행한다. 여기에서 얻은 제어기의 정보를 이용하여 제어기를 구성하고 그 제어기의 출력을 시스템 제어에 사용한다. 식별기와 제어기는 그림 1에서 나타낸 뉴로-퍼지망을 사용하여 어떠한 미지의 시스템에 대한 적응성을 가지게 하며, 적응 알고리듬은 신경회로망의 학습 알고리듬으로 많이 사용되고 있는 오차 역전파법을 사용하여 식별기와 제어기에 사용된 여러 매개변수들을 학습한다. 오차 역전파법에 사용할 에너지 함수로는 식별기를 위해서는 (20), 제어기를 위해서는 (21)를 사용한다.

$$E_I(t) = \frac{1}{2} \sum_{k=1}^{N_I} (y^k(t) - y_I^k(t))^2 \quad (20)$$

$$E_C(t) = \frac{1}{2} \sum_{k=1}^{N_C} (y_M(t) - y^k(t))^2 \quad (21)$$

여기서 I 는 식별을, C 는 제어를 나타낸다. N_I , N_C 는 출력의 수를 나타내며, $y^k(t)$ 는 미지의 시스템의 k 노드 출력을, $y_I^k(t)$ 는 뉴로-퍼지망으로 구성된 식별기의 출력을, 그리고 $y_M(t)$ 는 기준 모델의 출력을 각각 나타낸다.

이렇게 구성된 시스템은 퍼지의 추론 기능과 신경망의 학습기능을 이용하여 비선형 시스템의 근사적인 모형화를 이를 수 있으며 이러한 식별기의 정보를 가지고 제어기 구성함으로써 기준 모델에 적응적으로 추론하는 퍼지 적응 제어기의 구성이 가능하다.

V. 사례연구와 검토

사례연구를 통하여 본 논문에서 구성된 뉴로-퍼지망과 그의 학습방법을 이용하여 구성된 제어 시스템의 유용성을 살펴보자 한다. 첫 번째 사례연구로는 (22)와 (23)으로 표현 되는 비선형 모형 시스템[21]을 고려한다.

(모형 시스템)

$$y(t+1) = \frac{y(t) \cdot y(t-1) \cdot (2.5 + y(t))}{1 + y(t)^2 + y(t-1)^2} + u(t) + \eta(t+1) \quad (22)$$

$$\eta(t+1) \sim N(0, 0.0206) \quad (23)$$

여기서 $y(t)$ 는 시스템 출력, $u(t)$ 는 시스템 입력, $\eta(t)$ 는 관측 잡음으로 가우시안 백색잡음을 나타낸다. 기준 모형식은 (24), (25)와 같다.

$$y_M(t+1) = 0.6 y_M(t) + 0.2 y_M(t-1) + r(t) \quad (24)$$

$$r(t) = 0.4 \sin(\frac{2\pi}{75})t + 0.4 \cos(\frac{2\pi}{40})t \quad (25)$$

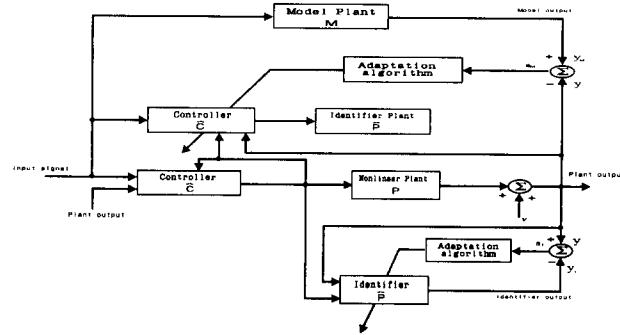


그림 3. 뉴로-퍼지 적용 제어기를 이용한 제어 시스템의 구성.

Fig. 3. Construction of overall controll system using neuro-fuzzy adaptive controller.

여기서 $y_M(t)$ 는 기준 모형의 출력, $r(t)$ 는 기준 모형의 입력을 나타낸다. 둘째로, 제안한 방식의 다입력 다출력 (MIMO)에 대한 효용성을 보기위한 사례연구이다. 비선형 시스템은 2-입력, 2-출력의 비선형 시스템[21]으로서 (26), (27)과 같다.

$$\begin{bmatrix} y_{p1}(t+1) \\ y_{p2}(t+1) \end{bmatrix} = \begin{bmatrix} \frac{y_{p1}(t)}{1 + y_{p2}^2(t)} \\ \frac{y_{p2}(t)}{1 + y_{p1}^2(t)} \end{bmatrix} + \begin{bmatrix} u_1(t) \\ u_2(t) \end{bmatrix} + \eta(t+1) \quad (26)$$

$$\eta(t+1) \sim N(0, 1.2475E-5) \quad (27)$$

여기서 $y_{p1}(t)$, $y_{p2}(t)$ 는 시스템의 출력이며, $u_1(t)$, $u_2(t)$ 는 시스템 입력 그리고 $\eta(t+1)$ 는 센서의 관측 잡음을 나타낸다. 기준 모형식은 (28),(29)와 같다.

$$\begin{bmatrix} y_{m1}(t+1) \\ y_{m2}(t+1) \end{bmatrix} = \begin{bmatrix} 0.6 & 0.2 \\ 0.1 & -0.8 \end{bmatrix} \begin{bmatrix} y_{m1}(t) \\ y_{m2}(t) \end{bmatrix} + \begin{bmatrix} r_1(t) \\ r_2(t) \end{bmatrix} \quad (28)$$

$$r_1 = 0.4 \sin(\frac{2\pi}{75})t + 0.4 \cos(\frac{2\pi}{100})t \quad (29)$$

$$r_2 = 0.3 \sin(\frac{2\pi}{80})t + 0.5 \cos(\frac{3\pi}{90})t$$

여기서 $y_{m1}(t)$, $y_{m2}(t)$ 는 기준 모형식을 나타내며 $r_1(t)$, $r_2(t)$ 는 기준 모형의 입력을 나타낸다.

이러한 비선형 시스템의 사례연구에 대한 결과를 그림 4에서 그림 9에 나타내었다. 그림 4, 그림 5, 그림 6, 그림 7은 사례연구 1의 시뮬레이션 결과를 나타낸다. 사례연구 1의 모형 시스템의 제어를 위한 식별기와 제어기의 구조와 초기치는 표 1과 같다. 그림 4는 모형 시스템의 출력, 일반 퍼지 제어기 사용시 시스템의 출력, [12]에서 제안한 뉴로-퍼지 제어기 사용할 때의 시스템의 출력 그리고 RMRFNFC에 의한 출력의 결과를 나타낸것으로 Iteration이 진행될수록 퍼지 제어기의 결과 보다 RMRFNFC 방식의 뉴로-퍼지 제어기가 모형 시스템의 출력에 훨씬 더 균접함을 보여준다. [12]의 방식과는 근사하게 비선형 시스템이 제어 됨을 알 수 있으나 기준모델의 출력에 대해 RMRFNFC의 출력이 일반 FLC보다도, 기존의 퍼지 신경망 보다도 진동의 폭이

적으며 모델의 출력을 따라 제어가 되고 있음을 알 수 있다. 그림 5는 학습후의 멤버쉽 함수를 나타내고 있다. 비선형 시스템의 제어에 적절한 함수를 구현하였다. 그림 6은 전체 시스템의 RMS오차를 보여준다. 그림 7은 제어기의 출력 즉, 시스템을 제어하기 위한 제어 입력을 나타낸다.

표 1. 모형 시스템에 대한 뉴로 퍼지망의 구조와 초기치들.

Table 1. Neuro fuzzy networks structure and initial values.

Step	No.	300	
Neuro Fuzzy Networks	NFNI	Structure	5-25-5-2-1
		Wlk	0.
		σ_{ij}	0.3
		μ_{ij}	-1. ~ 1.
NFNC		$\eta_{\sigma}, \eta_{\mu}, \eta_w$	0.006, 0.006, 0.006
		Structure	2-14-49-2-1
		Wck	0.
		σ_{ij}	0.3
		μ_{ij}	-1. ~ 1.
		$\eta_{\sigma}, \eta_{\mu}, \eta_w$	0.003, 0.003, 0.003

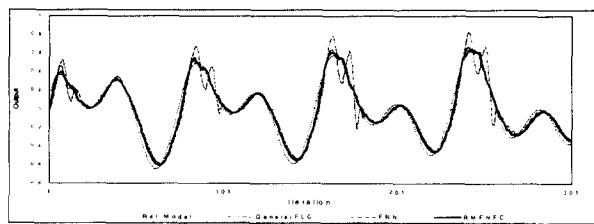


그림 4. RMFNFC와 기준 제어기의 시스템 출력과 기준 모델 출력의 비교.

Fig. 4. Comparision between system and model output of the RMFNFC and general controller.



그림 5. 뉴로-퍼지제어기 사용할 때 학습한 후의 멤버쉽 함수와 제어 규칙.

Fig. 5. Membership function and rule base after training using NFC.

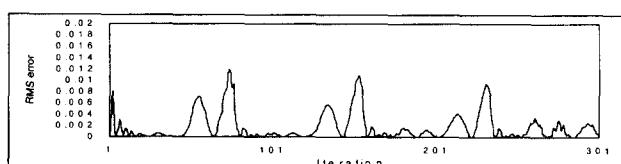


그림 6. 뉴로-퍼지제어기 사용할 때 시스템 출력과 기준입력 사이의 RMS 오차.

Fig. 6. RMS error of system and reference model output using NFC.

그림 8, 그림 9는 사례연구 2의 시뮬레이션 결과를 나타낸다. 그림 8은 기준 모델 시스템 1의 출력과 비선형 다변수 시스템 1의 출력을, 그림 9는 기준 모델 시스템 2의 출력과 비선형 다변수 시스템 2의 출력을 비교한 것이다. Iteration초기에 두가지 제어기가 모두 약간의 진동이 있으나 점차 안정된 제어가 이루어 점을 알 수 있다.

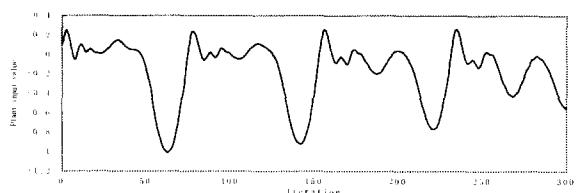


그림 7. 뉴로-퍼지제어기 사용할 때 제어기 출력(시스템 입력).

Fig. 7. Controller output(system input) using NFC.

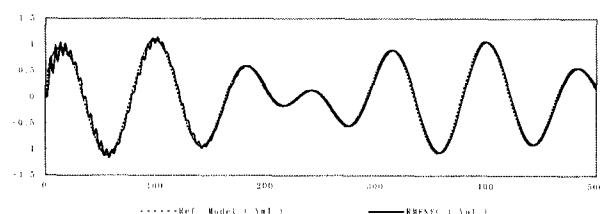


그림 8. 뉴로-퍼지제어기 사용할 때 시스템의 출력과 (y_{pl})과 기준 모델 출력(y_{ml})의 비교.

Fig. 8. Comparision between system(y_{pl}) and model plant(y_{ml}) output using NFC.

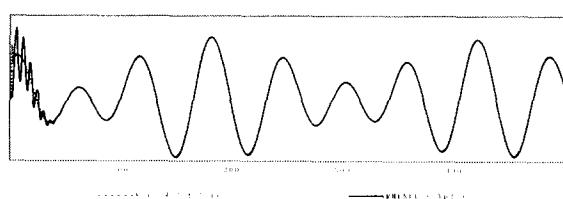


그림 9. 뉴로-퍼지제어기 사용할 때 시스템의 출력 (y_{pl})과 기준 모델 출력(y_{ml})의 비교.

Fig. 9. Comparision between system(y_{pl}) and model plant(y_{ml}) output using NFC.

VI. 결론

본 연구에서는 뉴로-퍼지망을 사용하여 퍼지 제어의 규칙도출과 비선형 이산 시간 시스템의 식별과 제어에 관해서 고찰하였다. 두개의 뉴로-퍼지망으로 식별기와 제어기를 구성하였고 기준모델 추종 방식을 이용하여 전체 시스템을 구성하고 비선형 시스템에 적용하여 기존의 퍼지 제어, 기존의 뉴로-퍼지 방법과 비교하였다. 적용 메카니즘은 시스템과 기준모델 사이의 출력 오차 정보를 이용하여 시스템 출력이 기준모델의 출력을 추종하는데 필요한 규칙 수정량을 학습을 통하여 제어 규칙을 반복 동조함으로서 완벽한 추종이 되게 하는 역할을 한다.

본 연구에서는 다음과 같은 결론을 얻을 수 있었다.

1. 뉴로-퍼지망을 이용한 기준모델 추종 방식의 제어 루프를 구성함으로서 알아 내기 어려웠던 퍼지 제어기의 여러 매개변수들을 학습에 의해서 쉽게 찾을 수 있었다.

2. 뉴로-퍼지망을 사용하여 식별기의 정보를 이용한 선형 다변수 시스템의 제어에 적용한 결과에서 시스템의 출력이 원하는 기준모델의 출력에 잘 추종함을 알 수 있었다.

3. 기존의 퍼지 제어기, 뉴로-퍼지망보다 적용성, 견실성이 우수하고 시스템을 기준 모델에 더 잘 제어 함으로서 제어기의 설계에 범용성을 가질 수 있었다.

이러한 회로망을 이용한 퍼지 식별기와 제어기를 구성하는데 있어서 식별기의 정보를 이용한 시스템의 제어가 이루

어지는 만큼 비선형 시스템의 더욱 더 정밀한 근사화 방법과 뉴로-퍼지망의 최적의 퍼지 규칙을 이루기 위한 합수 맵핑 방법은 추후의 연구과제가 될 것이다.

참고문헌

- [1] J. A. Karl, W. Bjorn, *Adaptive Control*: Addison Wesley, 1989.
- [2] L. A. Zadeh, "Fuzzy sets," *Information and control*, vol. 8, pp. 338-353, 1965.
- [3] H. K. Kwan, Y. Cai, "A fuzzy neural network and its application to pattern recognition," *IEEE Trans. Fuzzy Systems*, vol. 2, no. 3 pp. 185-192, Aug., 1994.
- [4] E. H. Mamdani and S. Apilian, "An experiment in linguistic synthesis with a fuzzy logic controller," *Int. J. Man-Machine Stud.*, vol. 7, pp. 1-13, 1975.
- [5] Y. F. Li and C. C. Lau, "Development of fuzzy algorithms for servo systems," *IEEE Control System Magazine*, vol. 9, no. 3, pp. 65-72, 1989.
- [6] 전순용, TITO모형 엔진-펌프 결합시스템의 퍼지 케 환재어기 설계, 경북대학교 공학박사학위논문, pp. 62-69, 1995.
- [7] 전순용, 서보혁, "굴삭기의 부하 조건 자동 인식을 통한 비선형 궤환 제어기의 설계", 전기학회 논문지, 제43권, 제9호, pp. 1563-1571, 1994. 9.
- [8] H. Ishibuchi, K. Nozaki and H. Tanaka, "Efficient fuzzy partition of pattern space for classification problems," *Fuzzy Sets and Systems*, vol. 59, pp. 295-304, 1993.
- [9] H. Nomura, I. Hayashi and N. Wakami, "A learning method of fuzzy inference rules by descent method," *IEEE Int. Conf. Fuzzy Systems*, pp. 203-210, 1992.
- [10] T. J. Procyk and E. H. Mamdani, "A Linguistic self-organizing process controller," *Automatica*, vol. 15, pp. 15-30, 1979.
- [11] J.-S. R. Tang, "Self-Learning fuzzy controllers based on temporal back propagation," *IEEE Trans. Neural Networks*, vol. 3, no. 5, pp. 714-723, Sept., 1992.
- [12] S. Horikawa, T. Furuhashi, Y. Uchikawa, "On fuzzy modeling using fuzzy neural networks with the back-propagation algorithm," *IEEE Trans. Neural Networks*, vol. 3, no. 5, pp. 801-806, Sept., 1992.
- [13] M. L. Presti, R. Poluzzi, A. M. Zanaboni, "Synthesis of fuzzy controllers through neural networks," *Fuzzy Sets and Systems*, vol. 71, pp. 47-70, 1995.
- [14] K. Tanaka, M. Sano, "Frequency shaping for fuzzy control systems with unknown nonlinear plants by a learning method of neural network," *Fuzzy Sets and Systems*, vol. 71, pp. 71-84, 1995.
- [15] M. M. Gupta, "Fuzzy logic and neural networks," *Proc. of the Tenth Int. Conf. Multiple Criteria Decision Making*, Japan, vol. 3, pp. 281-294, 1992.
- [16] T. Yamakawa, E. Uchino, T. Miki, and Hiroaki Kusanagi, "A neo fuzzy neuron and its application to system identification and prediction of the system behavior," *Proc. of the 2nd Int. Conf. Fuzzy Logic and Neural Networks*, Japan, pp. 477-483, 1992.
- [17] A. Cichocki, R. Unbehauen, *Neural Networks for Optimization and Signal Processing*, Wiley, 1993.

이영석



1991년 경북대학교 전기과 졸업. 동대학원 석사(1994), 동대학원 박사수료(1996). 1997년 8월~현재 영진전문대 전기과 전임강사. 관심분야는 지능이론에 의한 지능제어, 신호처리 및 응용, 모델링.

유동완



1995년 영남대학교 전기과 졸업. 경북대학교 대학원 석사(1997), 1997년~현재 경북대학교 전기과 박사과정. 관심분야는 시스템이론, 적응제어, 지능제어 등.

서보혁



1975년 서울대학교 전기과 졸업. 동대학원 석사(1980), 동대학원 박사(1985). 현재 경북대 전자·전기 공학부 교수. 관심분야는 각종 제어이론과 퍼지, 신경망, 최적화등을 이용한 제어이론 연구와 제어기 구현, 개발 그리고 설비

의 설계와 응용.