

자기학습형 뉴럴-퍼지 제어기에 의한 유도전동기 서어보시스템

양 승 호*, 김 세 찬*, 원 충 연*, 김 덕 현*

성균관대학교 전기공학과

A study on Induction Motor Servo System using Self-learning Neural-Fuzzy Networks

Seungho Yang*, Sechan Kim*, Chungyuen Won*, Dukheon Kim*
Department of Electrical Engineering,
Sungkyunkwan University

Abstract

In this study, a Self-learning Neural-Fuzzy Networks is presented. Because of the fuzzy controller property, the designing problems of fuzzy if-then rules, membership functions and inference methods are very complex task. Thus in this paper we proposed the Neural-Fuzzy Networks composed by Sugeno and Takagi's fuzzy inference method and learned by using temporal back propagation algorithm. The proposed method can refine automatically the fuzzy if-then rules without human expert's knowledges. The induction motor servo system is used to demonstrate the effectiveness of the proposed control scheme and the feasibility of the acquired fuzzy controller. All results are supported by simulation.

최근, 이러한 문제점을 해결하기 위해, 전문가의 지식 없이 신경회로망의 학습능력을 이용하여 퍼지규칙을 얻고자 하는 연구가 진행되고 있다^{[1]-[5]}.

본 논문에서는 상태평가형 제어규칙을 전건부 소속함수와 후건부 출력함수의 파라메타로 나타낸 뉴럴-퍼지 제어기를 구성 하였다. 또한, 시제역전과(temporal back propogation)알고리즘을 사용하여 최적의 소속함수와 제어규칙을 생성할 수 있도록 각 파라메타를 학습시켰다.^{[1]-[5]}.




그림 1. 뉴럴-퍼지 네트워크의 구조.

그림 1은 뉴럴-퍼지 네트워크의 구조이며, 각 계층(layer)의 기능은 아래와 같다.

계층1은 입력변수 X_1, X_2 을 각각 7개의 전건부 퍼지집합으로 변환하며, 각 퍼지집합은 식(1)로 표현 된다^[1].

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\frac{x - c_i}{a_i} \right]^{2b_i}} \quad (1)$$

식에서, a_i, b_i, c_i 는 전건부의 소속함수의 형태를 결정해 주는 파라메타들로서 학습에 의해 조정된다.

계층2는 퍼지제어기의 전건부를 구성하게 된다. 이 계층의 노드는 계층1로부터 출력된 신호를 곱하여 각 규칙의 적합도를 출력하게 되며, 퍼지 제어기의 Min 연산에 해당한다.^[1].

$$\bar{w}_{ij} = \mu_{A_i}(X_1)\mu_{A_j}(X_2) \quad (2)$$

계층3은 해당 규칙의 활성화도의 정규화(normalize)작용을 하며, 식(3)의 기능을 갖는 노드들로 구성되어 있다^[1].

$$\bar{\bar{w}}_{ij} = \frac{\bar{w}_{ij}}{\sum_{i=1}^p \sum_{j=1}^p \bar{w}_{ij}} \quad (3)$$

1. 서 론

최근, 다양한 분야에서 적용되고있는 퍼지제어기는 종래의 제어방식에 비하여 우수한 성능을 갖는다. 특히, 복잡하거나 시스템의 특성이 완전하게 정의되지 않은 경우에도 탁월한 제어기능을 발휘한다. 그러나, 퍼지제어기는 불확실하고 애매한 정보를 갖는 비선형 시스템을 제어할 경우에는 전문가의 지식을 완벽한 언어적 제어규칙으로 표현하기 어렵고, 전문가의 경험이나 지식을 이용할 수 없는 경우에는 퍼지제어기를 설계하기 위해서는 많은 시행착오를 거쳐야 한다^[2].

본 논문에서는 뉴럴-퍼지 네트워크(Neural-Fuzzy Networks)를 이용하여 자동으로 제어규칙을 추출하고 소속함수를 조정하는 자기학습형 퍼지제어기를 구성하고, 유도전동기 서어보 시스템에 적용한 자기학습형 퍼지제어기의 타당성을 시뮬레이션으로 확인하였다.

2. 뉴럴-퍼지 시스템의 구성

복잡한 동특성을 가진 계통인 경우, 적절한 퍼지규칙을 찾는 것은 상당히 어렵다. 즉, 퍼지제어기는 퍼지집합론에 근거한 많은 변수를 갖는 비선형이기 때문에 퍼지제어기 자체의 변수들을 적절하게 정해주는 작업이 필요하다. 이들 제어규칙, 소속함수의 모양, 입출력이득, 추론방법, 퍼지변수의 갯수, 퍼지화 비퍼지화 방법 등을 적절히 정하지 않으면 원하는 성능을 얻을 수 없다.

식(3)에서

- i : 1 ~ n(입력 X_1 에 대한 언어변수의 수)
- j : 1 ~ m(입력 X_2 에 대한 언어변수의 수)

계층4는 해당 규칙의 후건부를 구성하며, Takagi & Sugeno 형의 규칙을 구현하며, 각 노드들은 아래 식(4)와 같은 합수기능을 갖는다^{[1][2][16]}.

$$F_{ij} = \bar{W}_{ij}(P_{ij}X_1 + Q_{ij}X_2 + R_{ij}) \quad (4)$$

식(4)에서 P_{ij} , Q_{ij} , R_{ij} 는 후건부 파라메타로서 학습에 의해 조정된다.

계층5는 입력되는 모든 값들을 합하여 퍼지제어기 추론결과를 만들어 준다.

$$U = \sum_{i=1}^n \sum_{j=1}^m F_{ij} \quad (5)$$

위와 같은 구조를 갖는 뉴럴-퍼지 네트워크는 퍼지추론 시스템과 유사한 구조를 가지며, 각 파라메타들은 시계역전파 알고리즘에 의해 최적의 퍼지제어기가 구성 되도록 학습된다.

뉴럴-퍼지 네트워크는 2개의 입력과 1개의 출력으로 구성되며, 입력 X_1 은 유도전동기의 위치오차(rad), X_2 는 유도전동기의 속도(rad/sec)로서, 입력값의 범위는 각각 $-10 \leq X_1 \leq +10$, $-20 \leq X_2 \leq +20$ 이다. 출력 U는 유도전동기에 인가되는 토크 전류(A)로서, 출력값의 범위는 $-8 \leq U \leq +8$ 이다. 퍼지제어규칙은 2개 입력 X_1 , X_2 대하여 각각 7개의 언어변수를 지정하여 총 49개의 Takagi와 Sugeno의

If X_1 is A_{1i} and X_2 is B_{2j}

$$\text{then } F_{ij} = \bar{W}_{ij} (P_{ij} X_1 + Q_{ij} X_2 + R_{ij}) \quad (6)$$

형태의 규칙^{[1][16]}들로 구성되어 있다. 식(6)에서 i는 1 ~ n(입력 X_1 에 대한 언어변수의 수), j는 1 ~ m(입력 X_2 에 대한 언어변수의 수)이며, 본 연구에서는 각각 7로 하였다.

3. 퍼지제어기의 학습




그림 2. 궤적 학습과정의 상태천이도.

그림 2는 궤적 학습과정을 나타내는 상태천이도이며, 유도전동기의 궤적을 학습시키기 위한 시스템의 구조를 나타낸다. 학습동안 유도전동기를 뉴럴-퍼지 네트워크에 직접 연결하고, 각 샘플링 순간에 대하여 미리 설정된 궤적과 퍼지제어기의 출력에 의한 유도전동기의 실제출력(위치)값의 차이를 오차로 하여 시계 역전파알고리즘에 의하여 전건부 파라메타와 후건부 파라메타 값을 학습시켰다.

시계역전파 알고리즘은 그림 2와 같이 매 샘플링 순간의 입력 벡터에 대한 뉴럴-퍼지 네트워크의 출력에 의한 유도전동기의 실제출력과 목표출력간의 오차를 최소가 되도록 각 파라메타들을 조정한다.

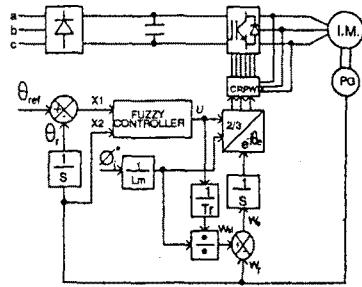


그림 3. 뉴럴-퍼지 제어기에 의한 유도전동기 제어보시시스템의 전체 블록도.

뉴럴-퍼지제어기와 plant(유도전동기)의 구성은 그림 3과 같으며 학습에서는 유도전동기의 실제상태와 지도 출력상태의 오차를 최소가 되도록 학습을 실시한다.

$k+1$ 번째 샘플링 순간의 시스템의 평가함수는

$$E_{k+1} = \frac{1}{2} (X_1(k+1) - X_d(k+1))^2 \quad (7)$$

이 되며, $X_1(k+1)$ 은 k 번째 퍼지제어기의 출력 U에 의한 유도전동기의 위치, $X_d(k+1)$ 은 지도궤적의 $(k+1)$ 번째 위치 값으로, 매 Sampling 순간의 E_{k+1} 을 감소시키는 방향으로 전건부와 후건부의 파라메타를 학습시킨다. 이를 위하여, 지도궤적이 될 지도궤적을 구성하여야 한다.

지도궤적은 유도전동기에 최대 정격전류 8(A)를 인가한 상태에서 초기위치(10rad)로부터 위치가 "0"가 되는 순간 까지 운전한 궤적으로 하며, 이 궤적에 대하여 뉴럴-퍼지 네트워크를 1차 학습시켜 과도상태의 퍼지규칙을 학습시킨다. 이 경우 제동을 고려하여 1차 지도궤적의 "0" 등과 시간에 대하여 마진을 둔 2차 지도궤적이 구성될 때 까지 1차 학습이 실시된다. 이 때 2차 지도궤적에는 상당히 큰 오버슈터가 나타나게 되며, 2차 학습은 이 오버슈터를 최소가 되도록 실시하며, 최종 학습은 정상상태 오차가 정해진 규격 이내로 될 때 까지 실시한다.

학습 단계에서 plant인 유도전동기는 토크전류 U와 위치 X_1 를 1차 비례로 하여 실시한다. 즉, 전동기 부분의 delta값은 $K(X_1(k+1) - X_d(k+1))$ 로 단순화하여, 각 샘플링 마다 이 값을 역전파시켜서 뉴럴-퍼지 네트워크내의 파라메타들을 학습하는데 사용한다.

전체 궤적 중에서 과도상태에서의 오차는 상대적으로 크기 때문에 초기 학습율은 작게 하며, 정상상태 오차가 줄어들 수록 학습율을 감소시키면서 학습을 실시한다.

학습에 사용된 각 파라메타의 delta값들은 아래 식으로 구한다.

유도전동기를 통과한 delta량 ΔE 는

$$\Delta E \propto \frac{\partial E}{\partial U} = -K(X_1(k+1) - X_d(k+1)) \quad (8)$$

후건부의 파라메타 P_{ij} , Q_{ij} 및 R_{ij} 의 delta값은

$$\Delta P_{ij} \propto -\frac{\partial E}{\partial P_{ij}} = \frac{\partial E}{\partial U} \frac{\partial U}{\partial P_{ij}} \quad (9)$$

$$\Delta Q_{ij} \propto -\frac{\partial E}{\partial Q_{ij}} = \frac{\partial E}{\partial U} \frac{\partial U}{\partial Q_{ij}} \quad (10)$$

$$\Delta R_{ij} \propto -\frac{\partial E}{\partial R_{ij}} = \frac{\partial E}{\partial U} \frac{\partial U}{\partial R_{ij}} \quad (11)$$

으로 되며, 전건부 파라메타 a_i, b_i, c_i 의 delta값은 아래의 식으로 표현된다.

$$\Delta a_i \propto \frac{\partial E}{\partial a_i} = \frac{\partial E}{\partial U} \frac{\partial U}{\partial a_i} \quad (12)$$

$$\Delta b_i \propto \frac{\partial E}{\partial b_i} = \frac{\partial E}{\partial U} \frac{\partial U}{\partial b_i} \quad (13)$$

$$\Delta c_i \propto \frac{\partial E}{\partial c_i} \Delta - \frac{\partial E}{\partial u_{ij}} \frac{\partial u_{ij}}{\partial c_i} \quad (14)$$

학습 data set는 desired input-output들의 쌍으로 구성되며 아래의 형태로 표현된다⁽¹¹⁾.


(초기조건 : 지도궤적)

초기조건은 1 element vector이며, 유도전동기의 초기 조건 $\pm 10(\text{rad})$ 으로 한다. 지도궤적은 3000 element vector로서 각 샘플링 순간의 유도전동기의 지도궤적 $X_d(k+1)$ 이다.


4. 시뮬레이션 결과

유도전동기의 위치제어를 위한 뉴럴-퍼지 제어기를 시제역전파 알고리즘으로 학습시켜서, 유도전동기 서어보시스템에 사용하여 제어기의 성능을 확인하였다.


그림 4. (a), (b), (c) 및 (d)는 뉴럴-퍼지 제어기에 의한 유도전동기 서어보시스템의 시뮬레이션 결과로서, 그림 4. (a)는 전동기의 위치오차로서 1.2sec 근처에서 정상상태에 도달하였다. 그림 4. (b)는 토오크분 전류로서 맥동성분이 거의 없다. 그림 4. (c)와 (d)는 각각 학습 후의 위치오차와 속도에 대한 소속함수 모양이다.



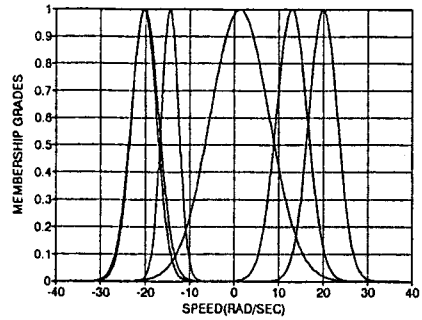
(a) 위치오차.



(b) 토오크 전류.



(c) 학습 후 위치오차 소속함수.



(d) 학습 후 속도 소속함수.

그림 4. 뉴럴-퍼지 제어기에 의한 유도전동기 서어보시스템의 시뮬레이션 결과.

5. 결 론

본 연구에서는 유도전동기를 최적제어하기 위해 뉴럴-퍼지 네트워크를 이용하여 제어규칙을 자동으로 생성하는 자기학습 퍼지 제어기를 구성하고, 시뮬레이션을 통하여 성능을 확인하였다. 유도전동기 서어보시스템의 시뮬레이션 결과 토오크 전류와 위치파형이 우수한 결과를 얻었다.

향후 과제로는 유도전동기의 inverse dynamics를 신경회로망으로 구현하여 뉴럴-퍼지 네트워크로 구성된 퍼지제어기를 학습시키는 것이다.

참고 문헌

- [1] J. R. Jang, "Self-Learning Fuzzy controllers Based on Temporal Back propagation," IEEE Trans. on Neural Networks, Vol. 3, No. 5, pp. 714-723, Sep. 1992.
- [2] 고택범, 하대원, 우방광, "퍼지-뉴럴 네트워크를 이용한 자기 학습 퍼지 제어기에 관한 연구." 대한 전기학회 제어계측연구회 합동학술발표회 논문집, pp. 79-83, 1993.
- [3] C. C. Lee, "Intelligent control based on fuzzy logic and neural network theory," on proc. Int. Conf. Fuzzy Logic and Neural Networks, (Iizuka), pp. 759-764, 1990.
- [4] S. Y. KUNG, Digital Neural Networks, Prentice Hall International, Inc., pp. 203-233, 1993.
- [5] Hamid, R. Berenji, Pratap, Khedkar, "Learning and Tuning Fuzzy Logic Controllers Through Reinforcements," IEE E. Trans. on Neural Networks, Vol. 3, No. 5, pp. 724-740, Sep. 1992.
- [6] M. SUGENO, "An experimental study on fuzzy parking control using a model car," Industrial applications of fuzzy control, Elsevier Science Publishers B.V. (North-Holland), pp. 125-138, 1985.
- [7] 김세찬, 김덕현, 양승호, 원충연, "퍼지제어기를 이용한 유도전동기 강인한 위치제어", 대한전기학회논문집, Vol. 42, No. 8, pp. 22-33, 1993.
- [8] C. T. Lin, C. S. Gorge Lee, "Neural-Network-Based Fuzzy Logic Control and Decision System," IEEE, Trans. on Computer, Vol. 40, No. 12, pp. 1320-1336, Dec. 1991.