

뉴로-퍼지 네트워크에 의한 유도전동기 궤적의 학습에 관한 연구

양승호*, 김세찬**, 김덕현**, 유동욱***, 원충연**

* 중경공업전문대학 전자계산기과
 ** 성균관대학교 전기공학과
 *** 한국전기연구소

A Study on the Learning Method for Induction Motor Trajectory using a Neuro-Fuzzy Networks

Yang Seungho*, Kim Seichan**, Kim Dukhun**, Yoo Dongwook***, Won, Chungyuen**

* Dept. of Computer Eng., Jungkyong Tech. Junior College
 ** Dept. of Electrical Eng., Sungkyunkwan Univ.
 *** Korea Electrotechnology Research Institute

Abstract

A learning method for induction motor trajectory using neuro-fuzzy networks (NFN) based on fusion of fuzzy logic theory and neural networks is proposed. The premise and consequent parameters of the NFN affecting the controller's performances are modified during the learning stages by the proposed learning method to implement an optimal controller only with pre-determined target trajectory and the least amount of knowledge about an induction motor. The induction motor position control system is simulated to verify the effectiveness of the learned NF controller(NFC). The simulation results shows that the proposed learning method has good dynamic performance and small steady state error.

퍼지규칙을 NFN의 파라미터로 나타내고, 학습으로 이들을 조정하여 제어를 구현하며, 이 결과를 유도전동기 위치제어 시뮬레이션에 적용하였다[6].




그림 1 NFN의 구조

그림 1은 NFN의 구조로서, 입력층은 전달(transfer)기능을 갖는다. 계층1은 전건부의 퍼지집합을 계산하며, X_1 의 퍼지집합에 대한 소속함수는 식(1)과 같다.

$$\mu_{A_{ii}}(X_1) = \frac{1}{1 + \frac{(X_1 - b_{ii})^2}{2a_{ii}}} \quad (1)$$

식(1)의 a_{ii}, b_{ii} 는 소속함수 파라미터이다.

계층2는 각 규칙의 활성강도를 출력한다.

$$W_{ij} = \mu_{A_{ii}}(X_1) \mu_{A_{jj}}(X_2) \quad (2)$$

계층3은 활성강도를 정규화하는 계층이다.

$$\bar{W}_{ij} = \frac{W_{ij}}{\sum_{i=1}^m \sum_{j=1}^n W_{ij}} \quad (3)$$

계층4는 해당 규칙의 후건부를 구현하는 계층이다.

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

식(4)에서 P_{ij}, Q_{ij}, R_{ij} 는 후건부 파라미터이며, 식(5)는 Sugeno의 퍼지규칙이다. [7]

$$\text{IF } X_1 \text{ is } A_{1i} \text{ and } X_2 \text{ is } A_{2j} \\ \text{then } F_{ij} = P_{ij} X_1 + Q_{ij} X_2 + R_{ij}. \quad (5)$$

출력층은 퍼지제어기의 추론결과를 만들어 준다.

$$U = \sum_{i=1}^m \sum_{j=1}^n F_{ij} \quad (6)$$

식(1)-(6)에서 i 와 j 는 입력 X_1, X_2 의 퍼지집합 수이다. 본 연구에서 X_1, X_2 및 U 는 유도전동기의 회전각

1. 서론

최근 기존의 제어방식에 비해 불확실성에 대한 강인성 범위가 크고 플랜트의 수학적 모델링이 불필요하며, 제어구조가 간단한 지능형 제어(intelligent control)방식인 퍼지논리 및 신경회로망 등이 제어방식에 이용되고 있다 [1]. 퍼지논리에 기반을 둔 퍼지제어기는 인간의 사고와 유사한 언어적 제어규칙을 사용하므로 전문가 지식을 언어적 수단으로만 표현할 수 있는 경우나 시스템이 완전하게 정의되지 않은 경우에도 플랜트의 대략적인 지식으로 제어가 가능하다. 인간의 학습능력을 모델링한 신경회로망은 패턴들이나 데이터베이스 내의 자료들을 기억, 인식할 수 있으며, 최적화 문제나 측정 데이터의 잡음을 필터링할 수 있다. 그러나 퍼지제어기는 설계과정과 지식의 규칙화동의 어려움이 있으며, 신경회로망은 학습과정의 어려움, 학습 데이터 결정의 어려움 등의 문제점이 있다[1].

본 연구에서는 퍼지논리와 신경회로망의 장점을 활용하기 위해 이들을 융합[2]하여 퍼지제어기의 추론과정을 수행하는 NFN를 구성[3]하고, 특정학습방법[4]을 사용하기 위한 지도신호 구성과 학습방법을 제안한다. 학습이 완료된 NFC는 유도전동기 위치제어 시뮬레이션에 적용하여 퍼지회로제어기(FLC)[5]와 비교하여 제어성능을 확인하였다.

2. NFC의 구성

(rad), 각속도(rad/sec) 및 토크 전류(A)이다.

3. NFN의 학습

신경회로망의 학습은 지도학습과 자율학습의 두 종류가 있다. 동작범위가 크고 지도신호 구성이 어려운 경우의 지도학습은 간접학습, 일반학습 또는 특정학습 중 하나를 이용한다[3].




그림 2 특정학습방법

그림 2는 특정학습(specialized learning) 방법으로 지도 입력을 바꿔가며 신경망 제어기와 플랜트를 거친 후 나오는 출력을 지도입력과 근접하도록 신경망 제어기를 학습시킨다.

NFN은 시제역전파(temporal back propagation)알고리즘으로 학습시키며, 매 샘플링 순간 실제궤적과 지도궤적간의 오차가 감소하도록 NFN 내의 각 파라미터를 조정한다.

샘플링시간 k 의 시스템 평가함수는

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

이며, 식(7)에서 X_1 은 실제출력, X_d 는 지도출력이다. 지도궤적은 전동기에 5(A)의 전류를 인가하여 10(rad)로부터 0.0(rad)까지 운전한 궤적으로 1단계학습에 사용한다. 1단계학습이 완료된 궤적의 영점 통과 후의 궤적을 "0.0"으로 한 것을 2차지도궤적으로 한다. 1단계학습 출력궤적의 오버슈터는 크며, 이 후의 학습은 오버슈터가 감소하도록 실시한다. 이 과정은 최종궤적의 정상상태 오차가 ± 0.05 (rad) 이내로 될 때 까지 실시한다. 샘플링시간 k 의

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

으로 하며, P_{ij}, Q_{ij} 및 R_{ij} 의 학습량은

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

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

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

또한 a_{1i}, b_{1i}, a_{2j} 및 b_{2j} 의 학습량은 아래와 같다.

$$\Delta a_{1i}(k) = -\frac{\partial E_k}{\partial a_{1i}(k)} = \Delta E_k \frac{\partial U(k)}{\partial a_{1i}(k)} \quad (12)$$

$$\Delta b_{1i}(k) = -\frac{\partial E_k}{\partial b_{1i}(k)} = \Delta E_k \frac{\partial U(k)}{\partial b_{1i}(k)} \quad (13)$$

$$\Delta a_{2j}(k) = -\frac{\partial E_k}{\partial a_{2j}(k)} = \Delta E_k \frac{\partial U(k)}{\partial a_{2j}(k)} \quad (14)$$

$$\Delta b_{2j}(k) = -\frac{\partial E_k}{\partial b_{2j}(k)} = \Delta E_k \frac{\partial U(k)}{\partial b_{2j}(k)} \quad (15)$$

각 파라미터는 아래 식과 같이 조정된다.

$$Par.(k+1) = Par.(k) + \eta_{Par.} \Delta Par.(k) \quad (16)$$




그림 3 지도궤적과 학습의 결과궤적

그림 3은 지도궤적과 각 단계학습 결과궤적으로 학습이 진행되는 것을 보여준다. 그림 4는 회전각의 학습 전, 후 소속함수로 소속함수를 자동으로 구현됨을 알 수 있다.




그림 4(a) 학습 전 회전각의 소속함수




그림 4(b) 학습 후 회전각의 소속함수

그림 4 학습 전, 후의 회전각의 소속함수

학습은 8단계로 진행되었으며, 각 학습단계별 영점 도달 시간 및 정상상태 최대오차는 그림 5와 같다. 학습이 진행됨에 따라 영점 도달시간은 증가하며, 정상상태 오차는 감소하는 것을 보여준다. 총 학습횟수 832회, 학습 후의 영점 도달시간 1.430(sec), 정상상태 오차 -0.0312(rad)으로 FLC의 영점 도달시간 1.618(sec), 정상상태 오차 -0.0537(rad)에 비하여 우수한 제어성능을 갖는 NFC가 구현되었음을 의미한다.

4. 시뮬레이션 결과

학습이 완료된 NFC는 유도전동기[7] 위치제어 시뮬레이션




그림 5 학습단계별 결과

선에 적용하여 제어성능을 확인하였다. 유도전동기의 초기 위치를 10.0 (rad)으로하여, NFC와 FLC에 대하여 실시하였다.

그림 6은 NFC와 FLC에 의한 시뮬레이션 결과이다. 그림 6(a)는 회전각으로서 목표위치(0.0 rad) 도달시간은 NFC 1.430(sec), FLC 1.618(sec)이며, 정상상태 최대오차는 NFC의 경우 -0.031 (rad), FLC의 경우 -0.053(rad)으로 FLC에 비하여 NFC에 의한 결과가 응답시간과 정상상태 오차가 감소하였다. 그림 6(b)는 토크 전류로서 FLC은 가속구간과 감속구간의 전환시와 정상상태에서 양, 음 방향의 전류가 맥동이 있지만 NFC는 나타나지 않는다. 즉, NFC는 FLC에 비해 신속하게 목표위치에 도달하며, 토크 전류파

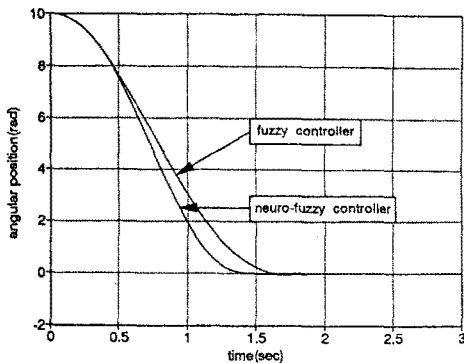


그림 6(a) 회전각




그림 6(b) 토크 전류




그림 6(c) 위상평면

그림 6 시뮬레이션 결과

형에 맥동성분이 없으며, 정상상태 오차도 감소하였다. 그림 6(c)는 위상평면이다. 종합적으로 볼 때 제한된 NFN의 학습의 결과로 구현된 NFC는 FLC보다 우수한 제어성능을 나타내며, 제어대상인 유도전동기 궤적의 학습으로 우수한 제어성능을 갖는 NFC가 구현되는 것을 확인할 수 있다.

5. 결론

본 논문에서는 유도전동기를 최적제어하기 위해, NFN 내의 파라미터를 제어대상인 유도전동기에 대한 전문가의 지식없이 지도궤적의 학습으로 NFC를 구현하였다. 이 NFC에 의한 유도전동기 위치제어 시뮬레이션 결과는 FLC의 결과에 비하여 토크 전류의 양과 음의 펄스가 전혀 나타나지 않았으며, 1.430(sec) 이내에 목표위치에 도달하여 FLC의 1.618(sec)에 비하여 신속한 응답특성을 가진다. 또한, 정상상태 최대오차도 FLC의 -0.0537 (rad)에 비하여 -0.0312 (rad)으로 더 적었다. 이러한 결과로부터 NFC는 정밀한 유도전동기 위치제어에 적용될 수 있음을 확인하였다.

참고 문헌

- [1] Philip D. Wasserman, Advanced Methods in Neural Computing, Van Nostrand Reinhold, 1993.
- [2] C.T. Lin, C.S.G. Lee, "Neural-Network-Based Fuzzy Logic Control and Decision System," IEEE, Trans. on Computer, vol. 40, no. 12, pp. 1320-1336, Dec. 1991.
- [3] J.R. Jang, "Self-Learning Fuzzy controllers Based on Temporal Backpropagation," IEEE, Trans. on Neural Networks, vol. 3, no. 5, pp. 714-723, Sep. 1992
- [4] D. Psaltis, A. Sideris, A. A. Yamamura, "A Multilayered Neural Networks Controller," IEEE, Control System Magazine, pp. 17-21, April 1988.
- [5] 김세찬, 김덕현, 양승호, 원충연, "퍼지로직 제어를 이용한 유도전동기의 강인한 위치제어," 전기학회논문지, 제42권 8호, pp. 22-33, 1993. 8.
- [6] 양승호, 김세찬, 유동욱, 원충연, "자기학습형 뉴럴-퍼지 제어기에 의한 유도전동기 위치제어," 1993년도 대한전기학회 추계학술논문발표회 논문집, pp. 142-144, 1993. 11.
- [7] M. Sugeno(ed.), Industrial applications of fuzzy control, Elsevier Science Publisher B. V. (North-Holland), 1985, pp. 125-138.