

퍼지-신경망을 이용한 강인한 유도전동기 벡터제어

전희종, 김병진*, 손진근, 문 학룡, 김수곤
 숭실대학교 전기공학과

The Robust Vector Control for I.M. using Fuzzy-Neural Network

Hee-Jong Jeon · Beung-Jin Kim · Jin-Geun Son · Hark-Yong Moon · Soo-Gon Kim

Song Sil University, Dept. of Electrical Engineering

ABSTRACT

In this article a fuzzy controller and neural network adaptive observer is proposed and applied to the case of induction motor control. The proposed observer which comprises neural network flux observer and neural network torque observer is trained to learn the flux dynamics and torque dynamics and subjected to further on-line training by means of a backpropagation algorithm. Therefore it has been shown that the robust control of induction motor neglects the rotor time constant variations

1. 서 론

퍼지이론은 인간의 애매한 사고나 표현을 효과적으로 처리해주는 수학적 이론으로 퍼지제어를 비롯하여 많은 응용 분야에서 사용되고있다. 특히 퍼지제어기는 기존 산업계에서 주로 사용되어온 PI, PID제어기 보다도 오버슈트가 작은 빠른 응답을 얻을 수 있다.^[1]

본 연구에서는 유도전동기의 속도제어를 위해 퍼지제어기를 사용하였고, 운전시 발생하는 파라미터의 변화를 보상하기 위하여 신경망 적응관측기를 이용하였다. 신경망을 이용한 비선형 적응제어 기법(Neural Adaptive Control Technology: NACT)을 이용하여 복잡한 적응제어 알고리즘을 간략화하였으며, 플랜트의 입,출력 정보를 이용한 비선형 모델링으로 고성능 유도전동기 제어에 적용하였다.^[1,2] NACT기법을 이용한 관측기는 회전자 자속과 토오크를 각각 학습한 두 개의 신경망으로 구성하였으며 적응제어는 토오크 관측오차를 기초로 이루어진다. 이 오차신호는 연결강도를 바꾸어 신경망 관측기가 회전자 시정수의 변화를 추종하도록 하여 유도전동기의 시정수 변화에 강인한 특성을 나타내도록하였고 시뮬레이션을 통하여 이를 입증하였다.

2. 퍼지 제어기

퍼지제어기의 기본 구조는 그림 2.1과 같다. 퍼지화에서는 입력변수값을 전체 집합으로 대응시키는 역할을 한다. 이 퍼지집합의 모습은 그림 2.2와 같다. 지식베이스는 "If..Then.."의 언어적 표현으로 제어 룰을 만든다. 이 지식베이스의 출력값은 추론과정을 거쳐 역퍼지화되어 출력된다. 본 논문에서는 그림 2.3과 같이 Max-Min추론 방법과 무게중심법을 사용하여 속도제어기와 자속제어기를 퍼지제

어기로 구성 할 수 있다.

$$DU = \sum_{i=1}^n \frac{m_{oi}(z_i)z_i}{m_{oi}(z_i)} \quad (2.1)$$




그림 2.1 퍼지 시스템의 기본구조




그림 2.2 멤버십 함수




그림 2.3 역퍼지화

3. 신경망 적응 관측기의 고찰

3.1 신경망 적응 관측기 방법

신경망은 학습기능, 병렬처리의 특징을 지니며 신경망 자체가 필터 역할을하여 외란에 둔감한 특징을 가지고 있다. 특히 학습기능을 이용하여 고차의 비선형 모델링이 가능하다.

본 연구에서는 이러한 신경망의 성질을 이용하여 기존의 유도전동기 전향 보상방식의 자속 관측기 대신에 그림 3.1과 같은 신경망 적응관측기를 구축하였다. 관측기는 플랜트의 오차를 최소화하여 플랜트의 상태를 잘 추종할 수 있도록 관측기의 구조를 변경하여 제어 할 수 있도록 하였다.




그림 3.1 신경망 관측기 구성도

3.2 신경망 적응 관측기의 오차 수정방법

신경망 자속 관측기의 학습은 자속모델과 신경망 자속 관측기의 오차(\$e_s[k]\$)를 이용하여 신경망 토오크 관측기의 학습은 토오크 모델과의 오차(\$e_T[k]\$)의 코히어런트 파워(coherent power)를 이용하여 학습한다. 여기서 \$g\$는 조정계수이다.

$$K = \hat{\omega}_e[k] g \quad (3.1)$$

매 시간에 신경망 관측기의 출력 오차는 신경망을 통하여 오차역전파 알고리즘에 따라서 가중치를 바꾼다. 학습은 식 (3.2)의 평가지수를 최소로 한다.

$$E = \frac{(K^2 e_T[k]^2 + e_s[k]^2)}{2} \quad (3.2)$$

4. 시스템의 구성

그림 4.1은 전체 시스템 구성도로 유도전동기의 회전자 시정수 계산은 운전중에 온라인으로 관측해서 식 (4.1)를 이용하여 신경망 자속 관측기와 토오크 관측기의 학습에 사용된다. 이때 \$\hat{T}_r\$이 실제 \$T_r\$에 수렴하도록하여 관측기가 실제의 자속 및 토오크 모델에 근사화 시키도록 오차역전파(backpropagation) 알고리즘을 이용하였다. 400[ms]의 샘플링 시간을 갖으며 \$\hat{\omega}_{sl}[K]\$ 이 실제값(\$\omega_{sl}[K]\$)에서 진동하므로 필터를 이용하여 \$i_{qs(avg)}\$, \$\hat{\omega}_{sl(avg)}\$를 각각 얻을 수 있다.

$$\hat{T}_r[k] = \frac{L_m i_{qs(avg)}[k]}{\hat{\lambda}_r[k] \hat{\omega}_{sl(avg)}[k]} \quad (4.1)$$

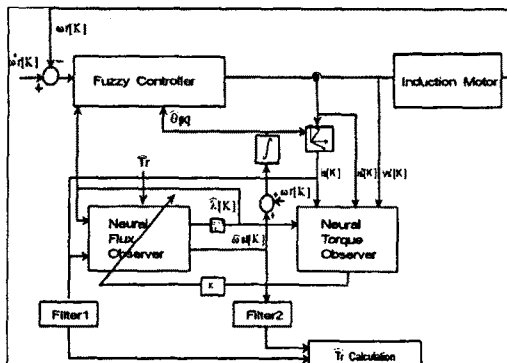


그림 4.1 시스템 구성도

그림 4.2는 신경망 자속 관측기로서 식 (4.2)으로 표현되는 자속모델의 동특성을 학습한다. 관측된 슬립속도

(\$\hat{\omega}_{sl}[K]\$)와 회전자 속도(\$\omega_r[K]\$)을 더하여 자속각(\$\hat{\theta}_e[k]\$)을 알아낸다. 여기서 \$T_0\$는 샘플링 시간이다.

$$\hat{\lambda}_r[k+1] = \hat{\lambda}_r[k] \left(\frac{1-T_0}{T_r} \right) + i_{ds}[k] \left(L_m \frac{T_0}{T_r} \right) \quad (4.2)$$




그림 4.2 신경망 자속 관측기

이와 유사하게 그림 4.3에서는 신경망 토오크 관측기에서는 식 (4.4)으로 표현되는 토오크모델의 동특성을 학습한다. 관측된 자속(\$\hat{\lambda}_r[k]\$)과 측정전류를 이용하여 계산된 회전자속계에서의 순시 토오크값(\$T[k]\$)과 신경망 관측기의 출력 토오크(\$\hat{T}[k]\$)의 오차가 줄어들도록 가중치를 바꾸어 준다. 또한 고정자 전압을 측정하여 적절한 고정자 자속(\$\hat{\lambda}_s^*[k]\$)과 측정전류(\$i_s^*[k]\$)를 이용해 토오크(\$\hat{T}_d[k]\$)를 알수있고 이 값과 신경망 관측기의 출력과의 오차(\$e_T[k]\$)를 이용하여 신경망 자속 관측기를 다시 학습시킨다.

$$\lambda_s^*[k+1] = \lambda_s^*[k] + (V_s^*[k] - R_s i_s^*[k]) T_0$$

$$T[k] = \frac{3PL_m}{4L_r} \hat{\lambda}_r[k] i_{qs}[k] \quad (4.3)$$

$$(4.4)$$

$$T_d[k] = \frac{3P}{4} (\lambda_{ds}^*[k] i_{qs}^*[k] - \lambda_{ds}^*[k] i_{qs}^*[k]) \quad (4.5)$$

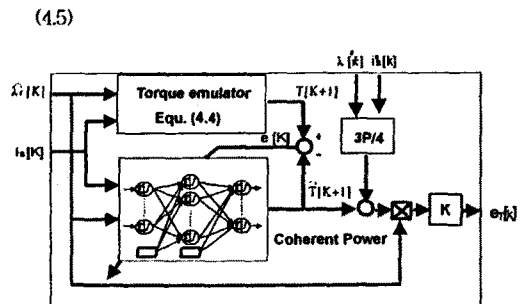


그림 4.3 신경망 토오크 관측기

5. 시뮬레이션 결과

유도 전동기를 모델은 30[hp] 능형 유도전동기로 설정하였고 제어기는 0.5[msec]의 샘플링 시간을 가지며 관측기는 1

0[msec]의 샘플링 시간을 갖게 설정하였다. 전류의 측정 과정 및 디지털값으로의 변화시 발생하는 오차를 0.4[%]의 백색 잡음을 인가하여 시뮬레이션을 하였고 시뮬레이션 파라미터는 표 5.1과 같다.

관측기 샘플링 주기와 반복 학습횟수는 과도시 급격한 자속변화를 학습하기 위해 고려했고 학습률은 K번째 학습을 수행 할 때에 이전의 상태값을 얼마 정도의 비중을 둘것인가를 결정하는 요소로서 값이 크면 수렴 속도가 증가하나 실제 값 주위에서 진동하는 성질을 가지므로 적절한 값을 주어야 한다.

그림 5.1은 1800[rpm] 지령속도에 대한 퍼지속도제어기 성능을 보여주고 있다.




그림 5.1 퍼지제어기 속도응답




그림 5.2 토오크 모델, 토오크 관측 출력 및 오차 ($P_\lambda = P_T = 3$)

그림 5.2에서는 정상동작시의 학습횟수를 3으로 설정하여 작은 학습을 했을 경우 우수한 추종성능을 보인 것이며, 그림 5.3에서는 학습횟수를 5로 인가하면 토오크가 많이 변화하는 약계자 부분에서 추종성능이 현저히 떨어짐을 볼 수 있었다.




그림 5.3 토오크 모델, 토오크 관측 출력 및 오차 ($P_\lambda = P_T = 5$)
그림 5.4에서는 회전자 시정수를 0.7초 후에 인위적으로 2.5

배 변화시켜 보았다. 자속 관측기에서는 오차를 감소시키는 방향으로 학습이 이루어져서 약 1.3초 후에는 오차가 줄어들었음을 볼 수있다. 그림 5.4(c)는 자속 모델과 관측기 출력의 비를 나타내고있다.




그림 5.4 시정수 변화시 자속 모델, 자속 관측 출력 및 오차($P_\lambda = P_T = 5$)

표 5.1 시뮬레이션 파라미터

시뮬레이션 파라미터	과도시	정상시
관측기의 샘플링 주기	$P_\lambda T_0$	T_0
	$P_T T_0$	$5T_0$
신경망 반복 학습 횟수	N_λ	5
	N_T	1
신경망 학습률	η_λ	0.1
	η_T	0.3

4. 결 론

정확한 자속의 관측은 고성능 유도전동기 벡터제어의 중요한 상태값이다. 또한 이 시정수 관측은 유도전동기 회전자 시정수에 이용하므로 운전중에 생기는 시정수의 변화를 정확히 추정한다는 것은 가장 중요한 부분이다. 따라서 이런 문제를 해결하기 위해서 신경망 자속 관측기와 토오크 관측기로 구성된 관측기를 이용하여 유도전동기의 자속 및 토오크 다이내믹스를 각각 학습시켜서 각 시간마다 변화하는 자속 및 토오크 관측기와와의 오차가 감소하도록 하였다. 학습된 관측기는 벡터제어와 함께 동작하며 오차역전파 알고리즘을 이용하여 온라인으로 학습시켰다. 시뮬레이션을 통하여 제안된 관측기는 과도상태나 정상상태에서의 급격한 변화에서도 강인한 성능을 나타냄을 보여주고있다.

참 고 문 헌

- [1] Kumpati S. Narendra & Kannan Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks", IEEE Trans. on Neural Network, vol. 1, no. 1, pp. 4-27, March, 1991.
- [2] D.H. Nguyen B. Widrow, "Neural Network for Self-Learning Control System," IEEE Control system Mag., vol. 10, pp.18-23, April, 1990
- [3] Ying-Shich Kung and Chang-Ming Liaw, "A Fuzzy Controller Improving a Linear Model Following Controller for Motor Drives" IEEE Tran on Fuzzy systems, vol. 2, No. 3, August 1994.