

부하변동을 보상한 유도전동기 신경망 속도 제어기

오원석¹, 조규민², 김희준³, 신태현¹, 김영태⁴
 유한대학 전기과¹, 유한대학 정보통신과², 한양대학교 전기컴퓨터공학부³, 국립원주대학 전기과⁴

Load variation Compensated Neural Network Speed Controller for Induction Motor Drives

Won Seok Oh¹, Kyu Min Cho², Hee Jun Kim³, Sin Tae Hyun¹, Young Tae Kim⁴
 Yuhun College EE¹, Yuhun College Information & Communication², Hanyang Univ. Elec & Computer Eng³, Wonju College EE⁴

Abstract In this paper, recurrent artificial neural network (RNN) based self tuning speed controller is proposed for the high performance drives of induction motor. RNN provides a nonlinear modeling of motor drive system and could give the information of the load variation, system noise and parameter variation of induction motor to the controller through the on-line estimated weights of corresponding RNN. Thus, proposed self tuning controller can change gains of the controller according to system conditions. The gain is composed with the weights of RNN. For the on-line estimation of the weights of RNN, extended kalman filter (EKF) algorithm is used. Self tuning controller that is adequate for the speed control of induction motor is designed. The availability of the proposed controller is verified through the MATLAB simulation with the comparison of conventional PI controller.

1. 서 론

유도전동기의 고성능 운전을 위하여 부하변동이나 환경 변화등 전동기 제어 파라미터 변동하에서 최적의 운전을 보장하는 제어 시스템이 필요하다. 이를 위해 현대제어이론을 도입한 많은 연구들이 있어 왔는데, 그중 자기동조 제어는 시스템 파라미터 변동에 따라 제어 파라미터를 조정하는 제어 방식으로 부하변동등의 보상에 적절한 제어기로 알려져 왔으나 선형제어이기 때문에, 비선형 특성을 갖는 유도전동기등의 적용에는 어려움이 있었다.[1]

최근, 신경망이론은 제어 응용분야에 널리 적용되어 왔다.[1][2][3][4] 신경망은 미리 설정된 모델에 대한 지식없이 비선형 전동기 운전 시스템을 모델링할 수 있으며, 따라서 신경망으로 노이즈, 파라미터 변화, 부하변동등에 강인한 제어기를 만들 수 있다. 그러나, 대부분의 신경망을 도입한 적응제어 방식은 오프라인 학습을 통하여 파라미터를 추정하므로 동작 중에 변화된 파라미터에 효과적으로 대처하기가 불가능하다.[5]

본 연구에서는 비선형 유도전동기 제어를 위하여 온라인 자기동조 속도제어기를 제시한다. 제어기의 구조는 최소분산제어에 기초하고 제어기 파라미터는 모델의 파라미터로 구성되며 유도전동기의 파라미터 변동과 부하변동등을 추정하기 위해 순환형 신경망 모델이 사용된다. 제안된 제어기는 온라인 파라미터 추정과 제어능력을 갖으며 이를 위해 확장 칼만 필터 알고리즘을 도입한다. MATLAB을 이용한 시뮬레이션으로 제어기의 타당성을 입증한다.

2. 본 론

2.1 자기동조제어기

일반적인 제어시스템의 수학적 모델은 식(1)과 같은 단 입력 단출력 ARMAX(autoregressive moving average model with auxiliary input) 모델로 나타낼 수 있다.[6]

$$A(q^{-1})y(k) = q^{-d}B(b^{-1})u(k) + C(q^{-1})w(k) \quad (1)$$

여기서 $y(k)$ 와 $u(k)$ 는 시스템의 출력과 입력이고 $w(k)$

는 이상관 백색잡음 그리고 k 는 샘플링 순간 ($k=1, 2, 3, \dots$), q^{-d} 는 시간지연이 $d(d \geq 1)$ 인 시간지연 연산자이고 A, B 그리고 C 는 q^{-1} 의 다항식이다.

ARMAX 모델의 정확도는 제어되는 시스템의 물리적 특성에 따른 시간지연 상수 d 와 A, B, C 의 차수에 따라 결정된다. 유도전동기 속도제어기를 설계하기 위해 식(2)와 같은 평가함수를 정의한다.

$$J(u, k) = [y(k+d) - y_{ref}(k+d)]^2 + \rho_u [Ru(k)]^2 + \rho_v [v_e(k+d)]^2 \quad (2)$$

$y_{ref}(k)$ 는 출력의 기준값이다. 제어신호의 갑작스런 변동을 줄이기 위해 식(3)과 같이 R 에 적분항을 추가하였다.

$$R = 1 - q^{-1} \quad (3)$$

강인한 제어 성능을 위하여 식(4)(5)와 같이 추적오차의 적분항으로 $v_e(k)$ 를 추가하였다.

$$v_e(k) = v_e(k-1) + e(k) \quad (4)$$

$$e(k) = y_{ref}(k) - y(k) \quad (5)$$

ρ_u 와 ρ_v 는 제어입력과 시스템응답의 정확도 사이의 중요도를 조정하는 상수이다. $J(u, k)$ 를 제어신호 $u(k)$ 에 따라 미분하여 이를 최소로 하는 $u(k)$ 값을 구하게 된다.

2.2 유도전동기 구동 시스템

유도전동기 제어시스템의 부하-토크식은 식(6)이다.[7]

$$\frac{dw_r}{dt} = \frac{P}{2J} (T_e - T_L) \quad (6)$$

여기서, w_r 는 각속도 P 는 극수, J 는 전동기의 관성, T_e 와 T_L 은 각각 유도전동기의 발생토크와 부하토크이다. 동기속도 회전좌표계에서 발생토크는 식(7)과 같이 표현되고, L_m, L_r 은 자화인덕턴스와 회전자 인덕턴스이다. I_{as}, Ψ_{dr} 은 q 축 고정자 전류와 d 축 회전자 자속이다.

$$T_e = \frac{3}{2} \left(\frac{P}{2} \right) \frac{L_m}{L_r} I_{as} \Psi_{dr} \quad (7)$$

부하토크는 식(8)와 같이 표현할 수 있다.

$$T_L = K_1 + K_2 w_r + K_3 w_r^2 + J_L \frac{dw_r}{dt} \quad (8)$$

J_L 는 부하의 관성이다. 식(6),(7)을 이용하여 식(8)은 식(9)와 같은 차동방정식으로 이산화할 수 있다.

$$w_r(k+1) = c_1 w(k) + c_2 w(k-1) + c_3 w_r(k)^2 + c_4 w_r(k-1)^2 + c_0 [I_{as}(k) - I_{ar}(k-1)] \quad (9)$$

여기서, c_0, c_1, c_2, c_3, c_4 는 시스템 파라미터로 표현된 상수이다. 식(9)에서 속도와 입력 전류사이에는 비선형특성이 있음을 알 수 있다. 그러므로, 비선형 모델링을 통한 비선형제어기의 도입이 필요되며 식(9)에 적합한 신경망 모델을 제시하고자 한다.

2.3 순환형 신경망 모델

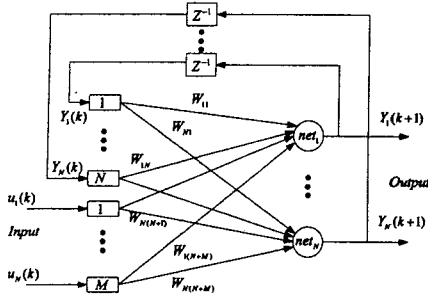


그림1. 순환형 신경망 모델의 기본 구조

그림1에 순환형 신경망 모델의 일반적 구조를 나타내었다. (2) [3] 여기서, Z^{-1} 은 샘플링 시간 지연을 나타내며, $u_M(k)$ 은 신경망 입력이고, $Y_N(k+1)$ 은 신경망의 출력이고, $W_{M(N+M)}(k)$ 는 신경망의 연결강도이다. 본 연구에서 도입한 모델은 $N=2$, $M=1$ 인 모델로 입력 $u_1(k)$ 는 전류 $I_{qs}(k)$ 이고 출력 $Y_1(k)$, $Y_2(k)$ 로 유도전동기 속도 출력 $w_r(k)$ 를 나타낸다.

2.4 확장 칼만 필터

본 연구에서는 신경망의 연결강도를 온라인으로 추정하기 위해서 확장 칼만 필터 추정법을 도입하였다. (2) [4] 시간 스텝 k 에서의 기준 벡터를 식(10)이라고 하자.

$$Y_r(k) = [y_{r1}(k) \dots y_{rN}(k)]^T \quad (10)$$

여기서, N 은 벡터의 길이이고 만일 시스템의 출력 $y_r(k)$ 가 벡터 $Y(k)$ 로 표현된다면, 오차 벡터는 식(11)과 같다.

$$\xi(k) = Y_r(k) - Y(k) \quad (11)$$

순환형 신경망의 연결강도는 M 차원의 벡터 $W(k)$ 로 나타낼 수 있다. 벡터 $H(k)$ 의 신경망의 연결강도에 대한 편미분으로 표현되며 $M \times N$ 행렬의 형태로 나타내어진다.

$$H(k) = \begin{pmatrix} \frac{\partial(y_1(k))}{\partial W_1} & \dots & \frac{\partial(y_N(k))}{\partial W_1} \\ \vdots & \ddots & \vdots \\ \frac{\partial(y_1(k))}{\partial W_M} & \dots & \frac{\partial(y_N(k))}{\partial W_M} \end{pmatrix} \quad (12)$$

여기서, y_r 는 뉴런의 출력이다. $W(k)$ 와 $P(k)$ 는 식 (13)-(16)에 의해 구해진다.

$$A(k) = [(\gamma(k)S(k))^{-1} + H(k)^T P(k)H(k)]^{-1} \quad (13)$$

$$K(k) = P(k)H(k)A(k) \quad (14)$$

$$W(k+1) = W(k) + K(k)\xi(k) \quad (15)$$

$$P(k+1) = P(k) - K(k)H(k)^T P(k) \quad (16)$$

여기서, $\gamma(k)$ 는 학습파라미터이다. 샘플링 시간 k 에서 입력 신호와 순환 노드의 출력들은 신경망을 통하여 전달되고 함수 $Y(k)$ 가 연산된다. 출력오차 $\xi(k)$ 가 계산된 후 칼만 이득인 $K(k)$ 가 갱신되고 새로운 연결강도 $W(k+1)$ 을 구하게 된다. 새로운 연결강도를 이용하여 제어기의 새로운 이득이 구해지며, 다음 샘플링 시간의 연산을 위하여 $P(k+1)$ 을 구하게 된다.

2.5 유도전동기 속도제어계의 설계

식(9)로부터, 유도전동기의 속도 출력 모델은 식(17)과 같은 속도와 입력의 함수로 나타낼 수 있다.

$$y_2(k+1) = f[y_2(k), y_2(k-1), u(k), u(k-1)] \quad (17)$$

식(2)의 평가함수를 최소화하여 샘플링 시간 k 에서 입력을 구하면 식(18)과 같이 된다.

$$u(k) = \frac{1}{b_0} [a_1 y_2(k) + a_2 y_2(k-1) + a_0 y_{ref}(k+1) + b_1 u(k-1) + b_2 v_e(k)] \quad (18)$$

여기서,

$$a_1 = -W_{22} W_{23}(1 + \rho_v), \quad a_2 = -W_{12} W_{21} W_{23}(1 + \rho_v),$$

$$a_0 = W_{23}(1 + \rho_v), \quad b_0 = W_{23}^2(1 + \rho_v) + \rho_{uv}$$

$$b_1 = \rho_{uv} - W_{13} W_{21} W_{23}(1 + \rho_v) \quad \text{그리고} \quad b_2 = W_{23} \rho_v \text{이다.}$$

EKF 알고리즘을 이용하여 연결강도 행렬 W 를 추정할 수 있으며, 연결강도를 식(18)에 대입하여 제어 입력 $u(k)$ 를 구할 수 있다. $u(k)$ 는 유도전동기의 토크 전류인 $I_{qs}(k)$ 이다.

2.6 결과

제안된 자기 동조 신경망 속도제어기의 타당성을 입증하기 위하여 몇가지 시뮬레이션을 MATLAB과 Simulink 프로그램을 이용하여 수행하였다. 그림2는 제안된 제어 시스템의 블록선도이다. 순환형 신경망(RNN) 블록에서 EKF알고리즘을 이용하여 뉴런의 연결강도가 계산되며, 제어기 이득을 조정하기 위해 자기동조 제어기 블록으로 이동된다. 시뮬레이션 결과는 PI 제어기와 비교되었고, 속도제어 명령의 변동과 부하변동 그리고 관성의 변동의 경우의 특성을 비교하였다. 표1은 사용된 제어기 파라미터를 나타낸다. 5hp, 230V, 4극기를 사용하였다. 샘플링 시간은 100 μ s이다.




그림2. 자기동조 신경망 제어 시스템의 블록선도

표1. 시험된 유도전동기 파라미터

Stator resistance	0.5814 Ω
Rotor resistance	0.4165 Ω
Stator leakage inductance	3.479mH
Rotor leakage inductance	4.15mH
Magnetizing inductance	78.25mH
Rotor inertia	0.1 kgm^2
Base frequency	377 rad/s
Rated torque	19.8Nm

그림3은 PI 제어기인 경우의 부하변동시 속도 응답 파형을 보여준다. 제어기의 이득은 최적으로 설계되었다. 그림4는 제안된 신경망 제어기의 결과이다. 속도 명령치는 180rad/sec이고 7초후에 정격토크(T_{LN})의 50%의 부하가 인가되었다. 그림5와 6은 전부하를 인가시의 특성이다. 가변속도 응답 특성과 속도회복 특성을 살펴보면 제안된 제어기의 특성이 매우 양호함을 알 수 있다. 특히, 전부하가 인가된 실험에서 PI제어기가 제안된 제어기보다 심한 오버슈트와 진동특성을 나타내고 있다. 그림 7과 8는 관성이 변동하였을 때의 동작 특성이다. 관성 J_L 은 기

본치 (J_{LN})의 4배까지 증가되었고, 전부하가 7초에서 인가되었다. 제안된 제어가 관성의 변동에 적절히 대처함을 알 수 있다.




그림3. PI제어의 속도응답특성 ($T_L = 0.5 T_{LN}$)




그림4. 제안된 제어기의 속도 응답특성 ($T_L = 0.5 N_{LN}$)




그림5. PI제어의 속도응답특성 ($T_L = T_{LN}$)




그림6. 제안된 제어기의 속도응답특성 ($T_L = T_{LN}$)




그림7. PI제어의 속도응답특성 ($J_L = 4 J_{LN}$)




그림8. 제안된 제어기의 속도 응답특성 ($J_L = 4 J_{LN}$)

3. 결론

본 논문에서는 유도전동기 속도제어를 위한 온라인 자기동조 신경망 제어기를 제시하였다. 제안된 제어기의 구조는 시스템의 파라미터 변동에 따라 자동적으로 제어기의 이득을 조절하는 기능이 있는 자기동조 제어기를 기초로 하여 설계하였고, 순환형 신경망 유도전동기 모델이 유도전동기의 시스템의 변동을 추정하기 위해 사용되었다. 확장 칼만 필터 알고리즘이 신경망의 연결강도를 추정하는데 사용되어 온라인으로 파라미터 변동을 추정할 수 있었다. MATLAB과 Simulink 프로그램으로 수행된 시뮬레이션 결과로 본 연구의 타당성을 입증할 수 있었다. 현재, 실험 연구를 수행중이다.

[참고 문헌]

- [1] M. A. El-Sharkawi and S. Weerasooriya, "Development and Implementation of Self-tuning Tracking Controller for DC Motors," *IEEE Trans. on energy conversion*, pp.122-128, March 1990.
- [2] Joao O. P. Pinto, Bimal K. Bose, Luiz E. B. Silva, "A stator flux oriented vector-controlled induction motor drive with space vector PWM and flux vector synthesis by neural networks," *IAS2000*, pp.1605-1612, Sep. 2000.
- [3] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamic systems using neural networks," *IEEE Trans. Neural Networks*, vol.1, pp.4-27, Jan.1990.
- [4] M. A. Hoque, M.R. Zaman and M.A. Rahman, "Artificial Neural Network Based Permanent Magnet DC Motor Drives," *IAS95*, pp.98-103.
- [5] G. V. Puskorius and L. A. Feldkamp, "Neurocontrol of nonlinear dynamic systems with Kalman filter trained recurrent networks," *IEEE Trans. Neural Networks*, vol.5, pp.279-297, Mar. 1994.
- [6] Goodwin, G. C. and K. S. Sin, *Adaptive Filtering Prediction and Control*, Prentice Hall, 1984.
- [7] B. K. Bose, *Power Electronics and AC Drives*, Prentice-Hall, 1986.