

Neural Observer를 이용한 PMSM의 정밀 속도 제어

고종선, 이용재, 이태훈
원광대학교 전기-전자 및 정보 공학부

Precision Speed Control of PMSM Using Neural Observer

Jong-Sun Ko, Yong-Jae Lee and Tae-Hoon Lee
School of Electric-Electronic and Information Engineering, Wonkwang University

ABSTRACT

This paper presents neural observer that used to deadbeat load torque observer. Most practical systems are nonlinear, and it is general practice to use linear models to simplify their analysis and design. However, the locally linearized model is invalid for a large signal change. The neural observer is suggested to increase the performance of the load torque observer and main controller. The output error and estimated state is trianed by neural network of neural observer. As a result, the state estimation error is minimised and deadbeat load torque observer make use of corrected esimation state. To reduce of the noise effect of deadbeat load torque observer, the post-filter which is implemented by MA process, is adopted. As a result, the proposed control system becomes a robust and precise system against the load torque. A stability and usefulness, through the verified computer simulation, are shown in this paper.

1. 서 론

최근 자성체, 반도체 전력소자, 제어이론 등의 향상으로 중·소용량 영역에서 영구자석 동기전동기(PMSM)를 이용한 동작 제어(motion control)의 응용은 매우 중요한 부분이 되었다.

본 논문에서는 영구자석 동기 전동기의 정밀 속도 제어의 방법으로 기존의 외란 관측기와 신경망 알고리즘을 융용한 Neural Observer를 이용하여 외란을 보상하는 정밀 속도 제어 방법을 제안한다. 일반적으로 관측기는 비선형 시스템을 선형화한 모델을 사용하는데 이러한 경우 시스템의 입력이 변화가 작을 경우 관측기를 통해 실제 상태를 근사 추정할 수 있지만 입력의 변화가 큰 경우는 추정한 상태가 실제 상태와 큰 차이를 갖게 된다. 제안된 제어기는 추가 상태 궤환 제어기를 기본 제어기로 하고 외란 관측기는 잘 알려진 데드비트 외란 관측기를 이용하였다. 관측기를 통해 추정한 상태와 실제 상태와의 오차를

줄이기 위해 사용된 신경망은 back-propagation 알고리즘을 사용하였다. 신경망에서는 실제 출력 값과 추정한 출력 값에 대한 오차와 추정한 상태를 학습하여 관측기의 상태 추정 오차를 줄여 보정된 상태를 관측기에 피드포워드시켜 외란에 의한 문제를 해결하였다. 이와 같이 제안된 제어기는 외란에 강인한 정밀 제어를 할 수 있으며, 이의 안정성과 효용성을 컴퓨터를 이용한 모의실험을 통하여 보였다.

2. 제어 알고리즘

2.1 상태 궤환 제어 알고리즘

PMSM의 추적 제어를 위해서 추가 상태를 식 (1)와 같이 정의하면 PMSM의 추가 상태 시스템 방정식은 식 (2)(3)과 같으며 제어 규칙은 식 (4)과 같이 정할 수 있다.

$$\dot{z} = w - w_r, \quad (1)$$

$$\begin{bmatrix} \dot{w} \\ \dot{z} \end{bmatrix} = \begin{bmatrix} -\frac{B}{J} & 0 \\ 1 & 0 \end{bmatrix} w + \begin{bmatrix} k_t \frac{P}{2J} \\ 0 \end{bmatrix} i_{qs} - \begin{bmatrix} \frac{P}{2J} \\ 0 \end{bmatrix} T_L - \begin{bmatrix} 0 \\ 1 \end{bmatrix} w_r, \quad (2)$$

$$y = [1 \ 0] \begin{bmatrix} w \\ z \end{bmatrix} \quad (3)$$

$$u = -kw - k_1 z \quad (4)$$

외란에 의한 오차를 빨리 줄이기 위해서는 큰 궤환이득이 필요하게 되며, 이 것은 매우 큰 전류를 만들게 된다. 만일 부하 토크 T_L 을 알게 되면,

$T_L = k_t i_{qcl}$ 에 의하여 등가 전류 i_{qcl} 를 구할 수 있으며 외란의 보상 입력을 선택적으로 생성할 수 있다. 따라서 제어 입력 i_{qc} 는 속도 제어기 출력 i_{qcl} 과 등가 전류 i_{qcl} 로 구성된다. 외부 외란의 영향은 등가의 q-상 전류로 피드포워드(feedforward)하여 보상한다.

2.2 데드비트 외란 관측기

일반적으로 시스템의 모든 입력을 알면 상태 추정 (estimation)을 할 수 있고 빠른 샘플링에 의해 외란은 구간상수로 가정할 수 있으므로 다음과 같은 0차 관측기에 의해 부하 토크를 추정할 수 있다.

$$\dot{T}_L = 0 \quad (5)$$

$$\begin{bmatrix} \hat{w} \\ \hat{T}_L \end{bmatrix} = \begin{bmatrix} -\frac{B}{J} & -\frac{P}{2J} \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \hat{w} \\ \hat{T}_L \end{bmatrix} \quad (6)$$

$$+ \begin{bmatrix} k_t \frac{P}{2J} \\ 0 \end{bmatrix} i_{qc} + L \left[w - [1 \ 0] \begin{bmatrix} \hat{w} \\ \hat{T}_L \end{bmatrix} \right]$$

빠른 추정을 위해 테드비트 알고리즘을 사용하면, 극점을 z도메인의 0점에 정의하여 궤환 이득을 Ackermann 공식에 의해 얻을 수 있다. 또한 데드비트 관측기의 단점인 잡음 증폭 문제는 MA(moving average) 처리에 의한 저대역통과필터(LPF)를 적용하여 고주파 잡음을 저감하였다.

2.3 제안된 신경망 관측기

제안된 신경망 관측기에서는 관측기를 통해 추정한 상태와 실제 상태의 오차를 줄이기 위해 실제 출력과 추정한 출력의 오차 e_{k+1} 과 추정한 상태 $\hat{x}_{k+1/k}$ 를 신경망의 입력으로 하였다. 다음은 실제 출력과 추정한 출력의 오차이다.

$$e_{k+1} = y_{k+1} - \hat{y}_{k+1/k} \quad (7)$$

신경망의 학습을 통해 보정된 상태는 출력 오차와 추정한 상태를 이용해 구할 수 있다.

$$\hat{x}_{k+1/k+1} = g(\hat{x}_{k+1/k}, e_{k+1}) \quad (8)$$

여기서 비선형 함수 $g(\cdot)$ 은 성능 지수를 최적하여 얻어지고 이때 출력 오차가 $e_{k+1} = 0$ 이라면 보정된 상태 $\hat{x}_{k+1/k+1}$ 은 추정한 상태 $\hat{x}_{k+1/k}$ 와 같게 된다.

$$\hat{x}_{k+1/k+1} = g(\hat{x}_{k+1/k}, 0) = \hat{x}_{k+1/k} \quad (9)$$

함수 $g(\hat{x}_{k+1/k}, e_{k+1})$ 는 Taylor series 의해 다음과 같이 전개되어 진다.

$$g(\hat{x}_{k+1/k}, e_{k+1})$$

$$= g(\hat{x}_{k+1/k}, 0) + \left(\frac{\partial g}{\partial e_{k+1}} \Big|_{e_{k+1}=0} \right) e_{k+1}$$

$$+ e_{k+1}^T \left(\frac{\partial^2 g}{\partial e_{k+1}^2} \Big|_{e_{k+1}=0} \right) e_{k+1} + \dots$$

$$= \hat{x}_{k+1/k} + \left[\left(\frac{\partial g}{\partial e_{k+1}} \Big|_{e_{k+1}=0} \right) \right. \\ \left. + e_{k+1}^T \left(\frac{\partial^2 g}{\partial e_{k+1}^2} \Big|_{e_{k+1}=0} \right) + \dots \right] e_{k+1} \quad (10)$$

식 (10)은 식 (9)를 이용하여 얻어졌고 식 (10)은 다음과 같이 정리할 수 있다.

$$g(\hat{x}_{k+1/k}, e_{k+1}) = \hat{x}_{k+1/k} + L(\hat{x}_{k+1/k}, e_{k+1}) e_{k+1} \quad (11)$$

출력 오차 e_{k+1} 이 최소가 되도록 학습이 된 후에 식 (12)와 같이 최종 보정된 상태를 얻을 수 있고 보정된 상태를 얻기 위한 성능 지수는 식 (13)과 같다.

$$\hat{x}_{k+1/k+1} = \hat{x}_{k+1/k} + L(\hat{x}_{k+1/k}, e_{k+1}) e_{k+1} \quad (12)$$

$$J = \frac{1}{2} \sum_{k=1}^N \|x_{k+1} - \hat{x}_{k+1/k}\|^2 \quad (13)$$

학습을 통해 최종 보정된 상태는 관측기로 다시 피드포워드되어 진다. 즉, 다음 샘플링의 상태 추정에 사용된다. 실제 상태와 추정한 상태와 오차를 학습하기 위한 신경망 알고리즘으로는 역전파 신경망을 사용하였고 그림 1은 역전파 알고리즘을 이용한 신경망의 블록도이다.

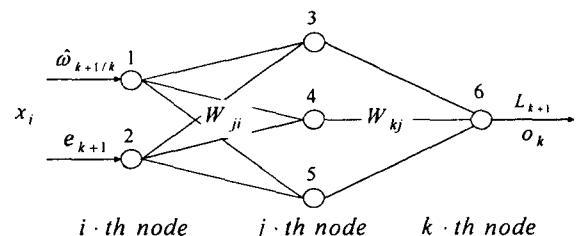


그림 1 오류 역전파를 사용한 신경망의 블록도
Fig. 1 Diagram of the neural network using error back-propagation

본 논문에서 사용한 신경망 네트워크는 그림에서 보는 바와 같이 실제 출력과 추정한 출력의 오차 e_{k+1} 과 추정한 상태 $\hat{\omega}_{k+1/k}$ 를 신경망의 입력으로 하였고 원하는 출력 ω_{k+1} 를 통해 학습을 하였다. 오차 신호는 다음과 같은 양극성 활성 함수를 사용하여 계산된 출력과 원하는 출력을 비교해서 출력층에서 은닉층으로 역전파된다.

$$f(net_k) = \frac{2}{1 + \exp(-\lambda net_k)} - 1 \quad (14)$$

$$net_k = \sum_j w_{kj} y_j \quad (15)$$

본 논문에서는 활성함수의 기울기 λ 는 간단히 1로 선택하였고 학습규칙은 성능지수에 기초한 최소자승법을 사용하였고 연결강도의 갱신을 위해 멀타 학습 규칙(delta learning rule)을 사용하였다.

$$E = \frac{1}{2} \sum_{k=1}^n (d_k - o_k)^2 \quad (16)$$

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} \quad (17)$$

j 번째 은닉층의 뉴런으로부터 k 번째 출력층의 뉴런간의 연결강도를 W_{kj} 로 표기하고, 오차 E 를 최소화하기 위해 연결강도를 음의 경사방향으로 변화시켜준다. 여기서, η 는 학습률이다. 각 노드에서 뉴런의 출력값은 식 (18)과 같이 되고 오차신호 δ 를 연쇄규칙(chain rule)을 사용해서 나타내면 식 (19)와 같음이 잘 알려져 있다.

$$o_k = f(net_k) \quad (18)$$

$$\delta_{ok} = -\frac{\partial E}{\partial net_k} = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial net_k} \quad (19)$$

식 (14)과 (19)의 수식을 통해서 출력층에서의 오차신호와 멀타 학습 규칙을 기초로 한 연결 강도 조정은 다음과 같다.

$$\delta_{ok} = \frac{1}{2} (d_k - o_k)(1 - o_k^2) \quad (20)$$

$$w_{kj}(k+1) = w_{kj}(k) + \eta \delta_{ok} y_j \quad (21)$$

위 식에서 y_j 는 j 번째 층에서의 출력이다. 다음은 위와 같은 방식으로 은닉층에서 오차신호와 연결 강도 조정에 관한 식이다.

$$\delta_{yj} = \frac{1}{2} (1 - y_j^2) \sum_{k=1}^n \delta_{ok} w_{kj} \quad (22)$$

$$w_{ji}(k+1) = w_{ji}(k) + \eta \delta_{yj} x_i \quad (23)$$

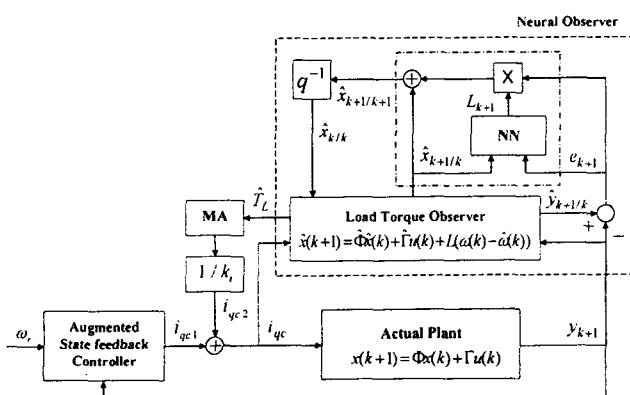


그림 2 제안된 알고리즘의 블록선도

Fig. 2 Block diagram of the proposed algorithm

제어 입력 i_{qc} 는 상태 계환 제어기에서 i_{qc1} 과 신경망관측기의 i_{qc2} 를 합해서 구하게 된다. 신경망의 학습에 의해서 관측기의 추정 오차를 줄임으로서 관측기의 추정 성능이 향상되고 보다 정밀한 외란 보상이 가능하게 된다. 이상의 알고리즘 블록선도를 그림 2에 나타내었다.

3. 전체 시스템 구성

제안한 시스템의 구성은 그림 3에 나타냈다. 여기서 제어알고리즘은 속도제어기, 신경망 관측기로 구성된다. 속도 제어기는 추가 상태 궤환(augmented state feedback)으로 이루어지며, 추가 상태 $z(k+1)$ 의 구현은 평행사변형 방식을 이용하였다. 신경망 관측기의 추정된 상태와 실제 상태의 오차를 줄이도록 학습을 하게 된다. 또한 외란 변화 모의실험은 추를 매단 막대바를 이용하여 회전 위치에 의해 변화하는 부하를 사용하였다.

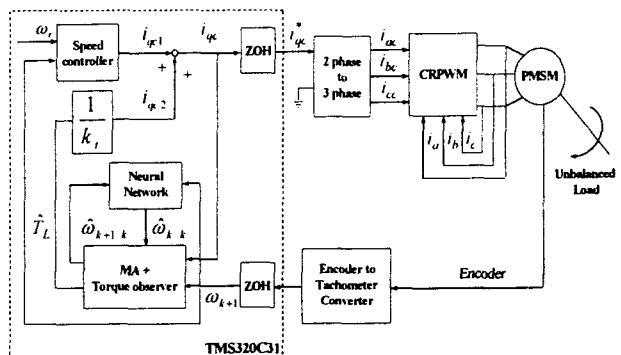


그림 3 제안된 제어 시스템의 블록선도
Fig. 3 block diagram of the proposed control system

4. 모의실험 결과

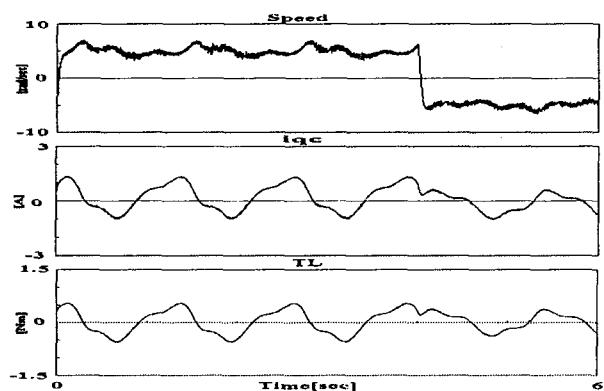
모의실험에서 사용한 영구자석 동기 전동기의 파라미터는 표 1과 같다.

표 1 모터 파라미터
Table 1 Motor parameter

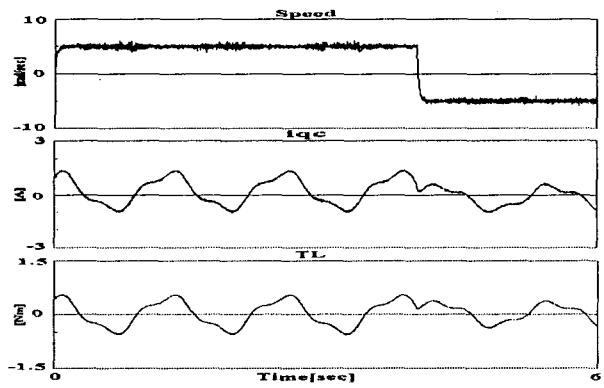
Power : 400 Watt	Inertia : $0.363 \times 10^{-4} \text{ kgm}^2$
Rated torque : 1.3 Nm	Stator resistance : 1.07Ω
Rated current : 2.7 A	Phase inductance : 4.2 mH

히스테리시스 간격은 0.01 [A]이고, 샘플링 주기 T_s 는 0.2 [ms]이다. 원하는 목표 도달시간과 과도응답이 있는 가중 행렬(weighting matrix)은 $Q=diag[1 3000]$, $R=1$ 로 선택하여 최적 이득 행렬을 구하면 $k=[0.0763 6.1802]$ 이 되며, Dead beat 관측기 이득 $L=[1.6703 -0.0549]$ 이 된다. 신경망 관측기에 사용한 역전파 알고리즘의 학습률은 0.55이고 한 샘플링 주기 동안에 3번

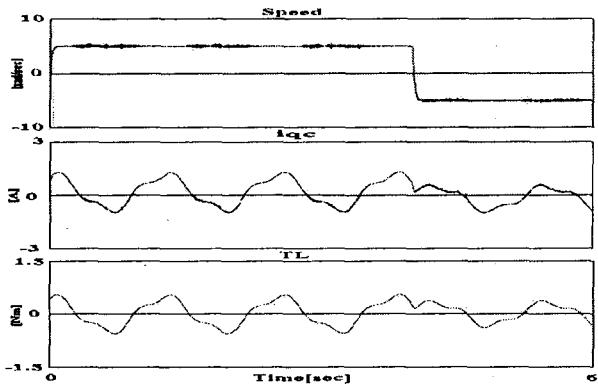
의 반복 학습을 하도록 하였다. 그림 4는 막대 부하에 의한 부하변화에 대한 시뮬레이션 결과이다. (a)는 상태 케환 제어기에 의한 결과로 고정이득을 사용하기 때문에 외란에 의해 큰 정상상태 오차를 가짐을 알 수 있고 (b)는 외란 관측기를 갖는 제어기의 응답으로 정상 상태 오차를 많이 제거하였으나 제안된 제어기의 응답인 (c)는 추정된 상태의 오차를 학습을 통해 실제 상태에 가까운 보정된 상태를 사용함으로써 정상상태에서 보다 더 오차가 적고 안정적임을 알 수 있다.



(a) 상태 케환 제어기



(b) 데드비트 외란 관측기



(c) 제안된 신경망 관측기

그림 4 막대 부하에 대한 회전자의 속도, q상 전류 명령 및 추정 부하의 모의실험 결과

5. 결 론

본 논문은 제안된 신경망 관측기를 이용하여 외란에 강인한 속도 제어 방법을 제시하였다. 제안된 신경망 관측기는 관측기가 추정한 상태와 실제 상태와 오차를 역전파 알고리즘을 이용한 신경망으로 학습을 하여 보정된 상태를 출력하게 되고 이를 관측기에 피드포워드시킴으로서 관측기의 성능을 향상시키고 보다 정밀하게 외란을 보상하게 된다. 제안된 알고리즘을 모의실험을 통하여 기존 시스템과 성능을 비교하여 더욱 우수한 특성을 나타내고 있음을 보였다.

참 고 문 헌

- [1] D. W. Novotny and R. D. Lorentz "Introduction to field orientation and high performance AC drives" *IEEE-IAS Tutorial Course*, 1986.
- [2] P. C. Krause, *Analysis of electric machinery*, McGraw-Hill, 1984.
- [3] K. J. Åström and B. Wittenmark *Computer controlled system*, Prentice Hall, International, 1997.
- [4] J. S. Ko, J. H. Lee, S. k. Chung, and M. J. Youn "A Robust Position Control of Brushless DC motor with Dead Beat Load Torque Observer", *IEEE Transaction on Industrial Electronics*, vol. 40, no. 5, pp. 512-520, 1993.
- [5] C. T. Chen, *Linear System Theory and Design*, Holt, Rinehart and Winston, Inc., 1984.
- [6] C. Y. Huang, T. C. Chen, C. L. Huang "Robust Control of Induction Motor with A Neural-Network Load Torque Estimator and A Neural-Network Identification" *IEEE Transaction on Industrial Electronics*, vol. 46, no. 5, pp 990-998, 1999.
- [7] J. D. Landau, *System Identification and Control Design*. Englewood Cliffs, NJ, Prentice-Hall, 1990
- [8] G. C. Goodwin, K. S. Sin, *Adaptive Filtering Prediction and Control*. Englewood Cliffs, NJ, Prentice-Hall, 1984.
- [9] M.S.Ahmed and S.H.Riyaz "Design of dynamic neural observers" *IEE Proc.-Control Theory Appl.*, vol. 147. No. 3, May 2000.
- [10] Chen, F. "Back-Propagation Neural Networks for Nonlinear Self-Tuning Adaptive Control", *IEEE Control System Magazine*, April 1990.
- [11] Hornick K., Stinchcombe M., and White H., "Multi-layer Feedforward Networks are Universal Approximators", *Neural Networks*, V.2, 1989.
- [12] Jacek M. Zurada, "Introduction to Artificial Neural System", West Publishing Company, 1992.