

첨단 AI 기법을 이용한 전력 변환기의 고성능 제어기 개발

고종선, 이용재, 김규겸, 한후석
원광대학교 전기 전자 및 정보 공학부, 기초전력연구소

A Development of Intelligent Robust Precision Control System for Power Conversion System using AI

Jong-Sun Ko, Yong-Jae Lee, Kyu-Gyeom Kim, Hoo-sek Han
School of EE and I Engineering, Wonkwang University, EESRI

ABSTRACT

This study presents neural load disturbance observer that used to deadbeat load torque observer and regulation of the compensation gain by parameter estimator. As a result, the response of PMSM follows that of the nominal plant. The load torque compensation method is compose of a neural deadbeat observer. To reduce of the noise effect, the post-filter, which is implemented by MA process, is proposed. The parameter compensator with RLSE (recursive least square method) parameter estimator is suggested to increase the performance of the load torque observer and main controller. The proposed estimator is combined with a high performance neural torque observer to resolve the problems. As a result, the proposed control system becomes a robust and precise system against the load torque and the parameter variation. A stability and usefulness, through the verified computer simulation, are shown in this paper.

1. 서론

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

본 연구에서는 영구자석 동기 전동기의 정밀 속도 제어의 방법으로 외란관측기를 이용한 외란 보상방법과 파라미터 추정에 의해 보상기의 이득을 조절하도록 함으로서, 외란이 없는 등가 지표시스템의 응답 특성을 추정하는 시스템에서 외란 관측기를 신경망에 의하여 학습하는 시스템을 제안하였다. 외란 관측기에 의한 보상방법은 잘 알려진 데드비트 외란 관측기를 이용하였으며 잡음에 의한 데드비트 관측기의 단점을 보완하기 위하여 후단필터로서 MA처리를 통하여 잡음에 대한 영향을 줄이도록 하는데 이 필터 효과도 학습 대상에 포함하였다. 또한 관측기의 파라미터와 실제 시스템의 파라미터의 차이로 발생하는 외란 추정 오차를 줄이고자 실

제 시스템과 파라미터 보상기로 구성된 등가 시스템이 지표 시스템이 되도록 구성하고 실험하였다. 시스템에 사용된 RLSE 파라미터 추정기는 외란에 의하여 편향된 추정 특성을 가진다. 이러한 실험에서 일어난 파라미터 추정문제에 대하여, 파라미터 추정기가 높은 성능을 갖는 데드비트 외란 관측기를 학습한 지능형 관측기를 포함하도록 함으로서 외란에 의한 문제를 해결하였다. 이와 같이 제안된 제어기는 외란 및 파라미터 변화를 갖는 시스템에서 강인한 고정밀 제어를 할 수 있으며, 이의 안정성과 효율성을 컴퓨터를 이용한 모의 실험을 통하여 보였다.

2. 본론

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.

$$\dot{z} = \omega - \omega_r \tag{1}$$

$$\begin{bmatrix} \dot{\omega} \\ \dot{z} \end{bmatrix} = \begin{bmatrix} -\frac{B}{J} & 0 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} \omega \\ z \end{bmatrix} + \begin{bmatrix} k_r \frac{P}{2J} \\ 0 \end{bmatrix} i_{as} - \begin{bmatrix} \frac{p}{2J} \\ 0 \end{bmatrix} T_L - \begin{bmatrix} 0 \\ 1 \end{bmatrix} \omega_r \tag{2}$$

$$y = [1 \ 0] \begin{bmatrix} \omega \\ z \end{bmatrix} \tag{3}$$

$$u = -k\omega - k_1 z \tag{4}$$

외란에 의한 오차를 빨리 줄이기 위해서는 큰 제환 이득이 필요하게 되며, 이것은 매우 큰 전류를 만들게 된다. 만일 부하 토크 T_L 을 알게 되면,

$T_L = k_1 i_{ac2}$ 에 의하여 등가 전류 i_{ac2} 를 구할 수 있으며 외란의 보상 입력을 선택적으로 생성할 수 있다. 따라서 제어 입력 i_{ac} 는 위치 제어기 출력 i_{ac1} 과 등가 전류 i_{ac2} 로 구성된다. 외부 외란의 영향은 등가의 q-상 전류로 정제환(feed-forward)하여 보상한다.

일반적으로 시스템의 모든 입력을 알면 상태 추정

(estimation)을 할 수 있다. 그러나, 실제 시스템에서 많은 경우에 몇몇 입력은 정확한 값을 알 수 없거나 찾아내기 힘든 경우가 있다. 빠른 샘플링에 의해 외란은 구간상수로 가정할 수 있으므로 다음과 같은 0차 관측기에 의해 추정 가능하다.

$$T_L = 0 \quad (5)$$

$$\begin{bmatrix} \hat{\omega} \\ T_L \end{bmatrix} = \begin{bmatrix} -\frac{B}{J} & -\frac{P}{2J} \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \hat{\omega} \\ T_L \end{bmatrix} + \begin{bmatrix} k_i \frac{P}{2J} \\ 0 \end{bmatrix} i_{qs}(k) + L \left(\omega - [1 \ 0] \begin{bmatrix} \hat{\omega} \\ T_L \end{bmatrix} \right) \quad (6)$$

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

추가 상태 제한 제어기와 외란 관측기를 이용한 외란 보상은 고정 이득을 사용하기 때문에 파라미터 변화에 대하여 동일한 성능을 얻을 수 없으며, 외란 관측기는 파라미터 변화에 의해 과도 응답 특성을 갖는다. 실제 시스템의 파라미터 변화 혹은 정확하지 않은 파라미터를 이용한 고정이득설정은 시스템의 성능 변화를 가져오게 된다. 따라서 등가 지표(nominal) 시스템으로 보상하여 파라미터의 변화에 의한 성능 변화를 제거할 수 있다. 영구자석 동기 전동기의 이산방정식은 다음과 같다.

$$\omega(k+1) = a\omega(k) + \beta i_{qs}(k) - \gamma T_L(k) \quad (7)$$

여기서, $\alpha = e^{-\frac{B}{J}h}$ (8)

$$\beta = -\frac{P}{2J} \left(-\frac{1}{B} e^{-\frac{B}{J}h} + \frac{1}{B} \right) k_i, \quad (9)$$

$$\gamma = \frac{\beta}{k_i}. \quad (10)$$

파라미터의 변화를 등가지표시스템으로 보상하기 위하여 부하토크의 영향이 없다고 가정하고, 부재한 이득 및 정제한 이득을 각각 C_1 , C_2 라 정의하면 보상기를 통한 제어명령은 다음과 같다.

$$i_{qs}^*(k) = C_1(k) \cdot i_{qs}(k) + C_2(k) \cdot \omega(k) \quad (11)$$

파라미터 보상기에 의해 보상된 시스템과 등가 지표 시스템의 응답이 같다고 가정하면 다음과 같이 표현할 수 있다.

$$a\omega(k) + \beta i_{qs}(k) C_1(k) + \omega(k) C_2(k) = \alpha_n \omega(k) + \beta_n i_{qs}(k) \quad (12)$$

여기서 α , β 와 α_n , β_n 은 각각 시스템의 실제 파라미터와 명판에 주어진 지표파라미터이다. 따라서 보상기의 이득은 식 (12)로부터 다음과 같이 간단히 얻을 수 있다.

$$C_1(k) = \beta_n / \beta \quad (13)$$

$$C_2(k) = (\alpha_n - a) / \beta \quad (14)$$

파라미터 추정을 위하여 영구자석 동기전동기의 이산

방정식을 파라미터 벡터와 측정 벡터로 구분하면 다음과 같다.

$$\omega(k+1) = a\omega(k) + \beta i_{qs}(k) = \theta^T \phi(k) \quad (15)$$

여기서, $\theta^T = [\alpha \ \beta]$ (16)

$$\phi(k)^T = [\omega(k) \ i_{qs}(k)] \quad (17)$$

파라미터 추정 알고리즘으로 RLSM을 사용하며, 외란에 의한 추정 오차를 제거하기 위해 외란 보상을 포함한 시스템의 입력력을 측정 벡터로 사용하면 다음 식에 의해 파라미터 추정을 할 수 있다.

$$\hat{\theta}(k+1) = \hat{\theta}(k) + F(k+1)\phi(k)E(k+1) \quad (18)$$

$$F(k+1) = F(k) - \frac{F(k)\phi(k)\phi(k)^T F(k)}{1 + \phi(k)^T F(k)\phi(k)} \quad (19)$$

$$E(k+1) = y(k+1) - \hat{\theta}(k)^T \phi(k) \quad (20)$$

여기서, $\theta^T = [\alpha \ \beta]$,

$$\phi(k)^T = \left[\omega(k) \ i_{qs}(k) - \frac{T_L}{k_i} \right],$$

$$F(0) = \frac{1}{\delta} I \quad (0 < \delta \ll 1)$$

Hornick이 적용한 함수 근사화의 방법으로 신경망의 응용은 다층 전방향 신경망이 일반 근사기로 사용되었다. 위 신경망의 특성은 알 수 없는 파라미터와 부하 변화에 의한 영향을 보상해주는 데 적당한 알고리즘이다. 그림 1은 추가된 상태 제한을 기초로 많이 쓰이는 역전파 신경망(back-propagation neural network: BPNN)을 사용한 제어기를 나타낸다.




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

본 논문에서 사용한 신경망 네트워크는 그림 2와 같으며, 그림에서 보는 바와 같이 다양한 상황을 학습시키기 위해 속도 w , 속도 목표 w_r , 속도와 속도 목표의 차 $w - w_r$, 등가전류 i_{qs} 를 신경망의 입력으로 선택하고 원하는 출력 i_{qs} 를 통해 학습을 하였다. 오차 신호는 다음과 같은 양극성 환상 함수를 사용하여 계산된 출력과 원하는 출력을 비교해서 출력층에서 은닉층으로 역전파된다.

$$f(net_k) = \frac{2}{1 + \exp(-\lambda net_k)} - 1 \quad (21)$$

$$net_k = \sum_j w_{kj} y_j \quad (22)$$

본 논문에서는 활성화함수의 기울기 λ 는 간단히 1로 선택하였고 연결강도의 갱신을 위해 델타 학습 규칙(delta learning rule)을 사용하였다.

$$E = \frac{1}{2} \sum_{k=1}^n (d_k - o_k)^2 \quad (23)$$

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} \quad (24)$$

j 번째 은닉층의 뉴런으로부터 k 번째 출력층의 뉴런 간의 연결강도를 W_{kj} 로 표기하고, 오차 E 를 최소화하기 위해 연결강도를 음의 경사방향으로 변화시켜준다. 여기서, η 는 학습률이다. 각 노드에서 뉴런의 출력 값은 다음과 같이 된다.

$$o_k = f(net_k) \quad (25)$$

오차신호 δ 를 연쇄규칙(chain rule)을 사용해서 나타내면 다음과 같음이 잘 알려져 있고 식 (21)과 (26)의 수식을 통해서 오차 신호는 식 (27)과 같이 주어진다.

$$\delta_{ok} = -\frac{\partial E}{\partial net_k} = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial net_k} \quad (26)$$

$$\delta_{ok} = \frac{1}{2} (d_k - o_k)(1 - o_k^2) \quad (27)$$

이상의 수식을 통해서 델타 학습 규칙을 기초로 각 연결강도의 값은 다음 값으로 조정된다.

$$w_{kj}(k+1) = w_{kj}(k) + \eta \delta_{ok} y_j \quad (28)$$

위 식에서 y_j 는 j 번째 층에서의 출력이다. 같은 방식으로 은닉층에서 오차신호와 연결 강도 조정은 다음과 같다.

$$\delta_{vj} = \frac{1}{2} (1 - y_j^2) \sum_{k=1}^n \delta_{ok} w_{kj} \quad (29)$$

$$w_{ji}(k+1) = w_{ji}(k) + \eta \delta_{vj} x_i \quad (30)$$

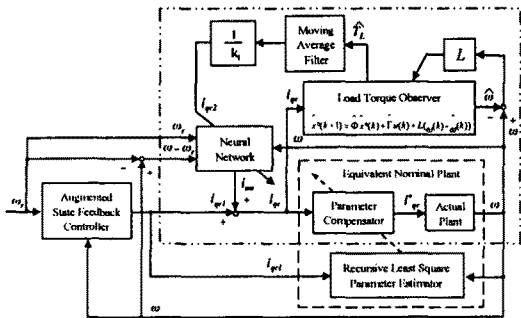


그림 2 제안된 알고리즘의 블록선도

Fig. 2 Block diagram of the proposed algorithm

제어 입력 i_{ac} 는 추가된 상태 궤환에서 i_{ac1} 과 신경망의 출력 i_{nn} 을 합해서 구하게 된다. 신경망의 학습에 의해서 외란의 상황에 맞는 학습된 출력을 한 샘플링 시간(sampling time)에 계산하여 제어 신호를 보상 출력하므로, 부하 토크의 영향을 빠르게 줄일 수 있게

된다. 이상의 알고리즘 블록선도를 그림 2에 나타내었다.

제안한 시스템의 구성은 그림 3에 나타났다. 여기서 제어알고리즘은 속도제어기, 지능형 외란 관측기 및 파라미터 보상기로 구성된다. 속도 제어기는 추가 상태 궤환(augmented state feedback)으로 이루어지며, 추가 상태 $z(k+1)$ 의 구현은 평행사변형 방식을 이용하였다. 지능형 외란 관측기는 데드비트 관측기의 출력을 MA필터에 통과시킨 i_{ac2} 를 학습한다. 또한 파라미터 변화 실험은 관성부하를 이용하였으며, 외란 변화 실험은 추를 매단 막대바를 이용하여 회전 위치에 의해 변화하는 부하를 사용하였다.

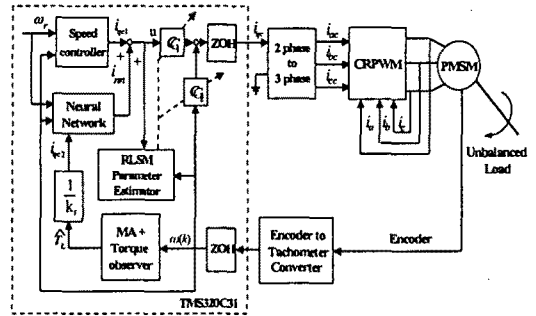


그림 3 제안된 제어 시스템의 블록선도

Fig. 3 block diagram of the proposed control system


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 : 1.07 Ω
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 없는 가중 행렬(weighting matrix)은 $Q = \text{diag}[1 \ 3000]$, $R = 1$ 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 보상을 위해 사용한 역전파 알고리즘의 학습률은 0.55이고 한 샘플링 주기 동안에 3번 정도의 반복 학습을 하도록 하였다. 그림 4는 파라미터 변화가 없는 경우의 부하변화에 대한 시뮬레이션 결과이다. 상태 궤환 제어기에 의한 결과는 외란에 의해 정상상태 오차를 가집을 알 수 있고 외란 관측기를 갖는 제어기의 응답과 외란 관측기와 파라미터 보상기를 갖는 제어기의 응답은 정상 상태 오차를 많이 제거하였으나 제안된 제어기는 이보다 더 높은 성능을 보임을 알 수 있다. 그러나 그림 5와 같이 파라미터 변화와 외란의 변화를 갖는 경우는 외란 관측기를 가지는 제어기의 용



(a) 상태 궤환 제어기 (b) 외란 관측기를 갖는 제어기 (c) 외란 관측기와 파라미터 보상기를 갖는 제어기 (d) 제안된 제어기

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



(a) 상태 궤환 제어기 (b) 외란 관측기를 갖는 제어기 (c) 외란 관측기와 파라미터 보상기를 갖는 제어기 (d) 제안된 제어기

그림 5. 불명형 부하와 40배의 관성 파라미터 변화에 대한 속도 및 q상 전류 명령의 모의실험 결과

답이 상태 궤환 제어기에 비해 정상상태의 오차가 적으나 관측기의 과도 응답에 의해 진동등을 유발하고 외란 관측기와 파라미터 보상기를 갖는 제어기에서는 진동 등의 오차 또한 현저히 제거되었으나 제안된 제어기는 이보다 더 안정적임을 알 수 있다.

3. 결론

본 연구에서는 파라미터 보상기를 제안하고 실험한 후 그 결과를 신경망으로 학습하여 더욱 범용성을 가지는 전력 변환기를 연구하였다. 본 초록에는 그 일부인 외란 관측기, 파라미터 보상기 및 제안된 신경망을 이용하여 외란과 파라미터 변화에 강인한 속도 제어 방법을 제시하였다. 외란 관측기와 파라미터 보상기로 이루어진 기존 시스템을 역전파 알고리즘을 이용한 신경망으로 학습을 하도록 하였고 제안된 알고리즘을 모의실험을 통하여 기존 시스템과 성능을 비교하여 더욱 우수한 특성을 나타내고 있음을 보였다.

4. 참고 문헌

[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. Aström 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