

Neural Network Parameter Estimation of IPMSM Drive using AFLC

고재섭* · 최정식* · 정동화†
(Jae Sub Ko · Jung Sik Choi · Dong-Hwa Chung)

Abstract - A number of techniques have been developed for estimation of speed or position in motor drives. The accuracy of these techniques is affected by the variation of motor parameters such as the stator resistance, stator inductance or torque constant. This paper is proposed a neural network based estimator for torque and stator resistance and adaptive fuzzy learning controller(AFLC) for speed control in IPMSM Drives. AFLC is chaged fuzzy rule base by rule base modifier for robust control of IPMSM. The neural weights are initially chosen randomly and a model reference algorithm adjusts those weights to give the optimum estimations. The neural network estimator is able to track the varying parameters quite accurately at different speeds with consistent performance. The neural network parameter estimator has been applied to slot and flux linkage torque ripple minimization of the IPMSM. The validity of the proposed parameter estimator and AFLC is confirmed by comparing to conventional algorithm.

Key Words : IPMSM, AFLC, Neural network, Parameter change, Torque ripple minimization, Parameter estimator

1. 서론

최근, IPMSM(Interior Permanent Magnet Synchronous Motor)은 토크 및 전력밀도가 높고 고 효율 및 역율 때문에 서보 드라이브의 적용분야에 광범위하게 사용되고 있다. DC 및 AC 전동기와 비교하여 고성능, 잡음이 없고 효율적인 전동기 드라이브에 매우 호응도가 높다.[1] 그리고 토크리플이 작고 광범위한 속도범위에서 자기 轉流 능력을 가지고 있으며 체적이 작고 제어가 용이한 장점을 가지고 있다.[2]

IPMSM은 파라미터의 변동에 비선형이며 고차의 동특성에 의한 다변 결합시스템이다.[3] 벡터제어의 기법을 이용하여 전동기의 모델링과 제어는 비교적 간단하게 처리 할 수 있다. 전기기계인 토크는 고정자 전류와 이와 수직인 자속의 곱에 비례하여 발생한다. 고성능 드라이브 시스템을 위하여 고속이며 정확한 응답을 필요로 한다. 또한 어떤 외란에 대하여 속도추정이 빠르게 이루어져야 하며 파라미터의 변동에 둔감해야 한다.[4]

일반적으로 선형 플랜트 모델과 시불변 파라미터에 기초한 종래의 제어는 파라미터의 변동과 외부 외란에 대하여 어느 정도 해결할 수 있었다.[5]-[6] 그러나 시스템 전달함수의 극과 영점이 파라미터의 변동에 의해 변하고 모델의 불확실성이 제어기의 성능을 저하시킨다. 고정밀 산업 드라

이브의 적용을 위하여 더욱 효율적인 제어기법이 광범위하게 연구가 되고 있다.

PMSM의 전압제어 알고리즘에서 토크정수 및 고정자 인덕턴스를 추정하기 위하여 적응제어 기법인 MRAS[7] 및 STC[8]가 제시되었다. 그러나 저속에서 고정자 저항의 변동을 고려하지 않았다. MRAS를 이용하여 일정한 인덕턴스에서 고정자 저항과 회전자 자속을 추정하거나 일정 자속과 인덕턴스에서 속도와 저항을 추정하였다.[9] 이 방법은 여러 동작점에서 적응 메카니즘의 설계와 PI 이득의 동조가 어려운 문제점이 있었다. 반복 모델링의 방법은 온도의 변화에 따라 고정자 저항의 추정이 충분하지 못했다.[10]

최근 퍼지제어, 신경회로망 및 유전자 알고리즘 등을 이용한 인공지능 제어는 전력전자 시스템의 성능을 향상시킬 수 있는 중요한 기법으로 인식되고 있다. 이러한 기법들은 적응제어 기법과 상호 혼합하여 적응 인공지능 제어기를 개발하고 있다. 이러한 혼합제어는 플랜트의 파라미터에서 불확실성과 미지의 변동을 용이하게 처리할 수 있으며 더욱 효율적으로 취급할 수 있는 구조를 구축할 수 있다. 그리고 이들 기법간의 상호 혼합한 방식은 적응성 및 강인성이 요구되는 유도전동기 드라이브에서 진가를 유감 없이 발휘될 전망이다.[11]-[15]

본 연구에서는 토크정수와 고정자 저항과 같은 파라미터를 위하여 온라인 신경회로망 및 속도제어를 위한 AFLC(Adaptive Fuzzy Learning Controller)를 제시한다. AFLC 제어기는 FLC 제어기에 학습메카니즘을 적용하여 FLC 제어기의 룰베이스를 수정하며 IPMSM의 속도를 제어한다. 그리고 q축 고정자의 인덕턴스는 q축 전류에 의하여 모델링 된다. 회전자 자속에서 고조파를 고려하고 토크리플은 온라인 토크

* 정 회 원 : 순천대 공대 전기공학과 박사과정
† 교신저자, 정회원 : 순천대 공대 전기공학과 정교수 · 공박
E-mail : hwa777@sunchon.ac.kr
접수일자 : 2010년 9월 10일
최종완료 : 2010년 10월 28일

정수의 추정에 의해 최소화한다. 본 신경회로망의 제어기는 복잡한 계산량을 줄이고 제어방법을 간단히 할 수 있으며 백터제어에 의한 IPMSM 드라이브 시스템을 위하여 더욱 실질적이고 효율적인 제어를 구성한다. 본 연구에서 제시한 알고리즘의 추정성능을 분석하고 그 결과를 제시한다.

2. IPMSM의 모델링

그림 1은 IPMSM의 d 와 q 축의 등가회로를 나타낸다.




그림 1 IPMSM의 등가회로
Fig. 1 Equivalent circuit of IPMSM

그림 1의 등가회로에서 전압방정식을 구하면 다음과 같다.

$$v_d = R_s i_d + L_d \frac{di_d}{dt} - \omega_r L_q i_q \tag{1}$$

$$v_q = R_s i_q + L_q \frac{di_q}{dt} + \omega_r L_d i_d + \omega_r \phi_a \tag{2}$$

전기적인 발생토크는 다음과 같다.

$$T_e = \frac{3}{2} P [\phi_a i_q + (L_d - L_q) i_d i_q] \tag{3}$$

$$T_e = J p \omega_r + B \omega_r + T_L \tag{4}$$

식(1)-(4)를 미분방정식의 형태로 표현하면 다음과 같다.

$$p i_d = (-R_s i_d + \omega_r L_q i_q + v_d) / L_d \tag{5}$$

$$p i_q = (-R_s i_q - \omega_r L_d i_d - \omega_r \phi_a + v_q) / L_q \tag{6}$$

$$p \omega_r = \frac{3}{2J} P [\phi_a i_q + (L_d - L_q) i_d i_q] - \frac{B}{J} \omega_r - \frac{T_L}{J} \tag{7}$$

이 식에서 전기적인 속도 ω_r 는 기계적인 속도로 표현하면 $(P/2)\omega_r$ 로 표현되고 ϕ_a 는 자석의 상호 자속계수로서 $L_q k_e$ 로 표현된다. 여기서 k_e 는 토크상수이다. 회전자 속도

에 대한 상태 방정식은 d 축 전류가 일정하게 제어되면 발생토크는 q 축 전류에 비례하여 제어된다는 것을 나타낸다. 따라서 전동기의 토크는 단지 q 축 전류가 제어변수가 된다.

3. 토크 정수와 고정자 저항 추정

추정 알고리즘은 그림 2에 나타내며 병렬 MRAS를 사용한다.




그림 2 토크 정수와 고정자 저항을 위한 MRAS-NN에 의한 추정자

Fig. 2 MRAS-NN based estimator for torque constant and stator resistance

d, q 축의 인덕턴스의 변화는 무시하고 d 축 전류는 일정하게 제어한다. IPMSM으로 된 기준모델을 조절모델과 병렬로 연결한다. 기준모델과 조절모델 사이의 전류오차는 피드포워드 신경회로망의 적응 알고리즘의 입력으로 사용되며 토크정수와 고정자 저항을 추정한다. 전류 오차는 역전파 알고리즘에서 신경망 하중을 학습하는데 사용한다.

식 (5)와 (6)을 $d-q$ 기준 축에서 이산 방정식을 구하면 다음과 같다.

$$i_d(k+1) = i_d(k) + \frac{T_s}{L_d} [v_d(k) + L_q \omega_r(k) i_q(k) - R_s i_d(k)] \tag{8}$$

$$i_q(k+1) = i_q(k) + \frac{T_s}{L_d} [v_q(k) - L_d \omega_r(k) i_d(k) - L_q k_e \omega_r(k) - R_s i_q(k)] \tag{9}$$

여기서, T_s 는 샘플링 주기이며 $i_d(k+1)$ 과 $i_q(k+1)$ 은 $d-q$ 축 고정자 전류이며 $v_d(k)$ 와 $v_q(k)$ 는 $d-q$ 축 고정자 전압을 나타낸다. 조절모델은 기준모델인 IPMSM에서 R 과 k_e 를 \hat{R} 과 \hat{k}_e 로 대체하면 얻을 수 있다. 동특성 오차는 다음과 같은 형태로 나타난다.

$$e_{id}(k+1) = i_d(k+1) - \hat{i}_d(k+1) = -\frac{T_s}{L_d} (R_s - \hat{R}_s) i_d(k) \tag{10}$$

$$e_{iq}(k+1) = i_q(k+1) - \hat{i}_q(k+1) = -\frac{T_s}{L_q} (k_e - \hat{k}_e) \omega_r(k) - \frac{T_s}{L_q} (R_s - \hat{R}_s) i_q(k) \tag{11}$$

모든 파라미터를 정확하게 추종할 경우 전류의 오차를 영으로 된다. 실시간 구현에서 d 축 전류가 영으로 제어되면 d 축 전류오차는 정확한 추종을 하는데 충분하지 않다. 이러한 문제는 자화전류를 주입하여 해결할 수 있다. 특정한 주입의 약 영향은 동손을 증가시켜 저효율의 결과를 초래한다. 전류 노이즈의 영향을 방지하기 위하여 전류오차에 대한 LPF를 사용한다. 필터링 전류오차와 이 전류오차의 변화분은 신경회로망의 입력으로 사용한다. 신경회로망의 출력은 추정 파라미터의 변화 분이다.

전류 LPF는 다음과 같다.

$$e_{id}^{\Sigma} = \frac{1}{m} \sum_{n=0}^{m-1} z^{-n} e_{id} \quad e_{iq}^{\Sigma} = \frac{1}{m} \sum_{n=0}^{m-1} z^{-n} e_{iq} \quad (12)$$

여기서 m 은 LPF의 부 사이클의 수이며 z 는 지연 연산자이다. 신경회로망에서 다른 두 입력은 전류오차의 변화분이다.

$$ce_{id}^{\Sigma} = (1-z^{-1})e_{id}^{\Sigma} \quad ce_{iq}^{\Sigma} = (1-z^{-1})e_{iq}^{\Sigma} \quad (13)$$

오차지수는 다음과 같이 정의한다.

$$E = 0.5e_{id}^{\Sigma} \cdot e_{id}^{\Sigma} + 0.5e_{iq}^{\Sigma} \cdot e_{iq}^{\Sigma} \quad (14)$$

신경회로망의 하중적응은 LSM(Least Square Method)에 기초한다.

$$v_{ij}(k+1) = v_{ij}(k) - \gamma \frac{\partial E}{\partial v_{ij}} \quad (15)$$

여기서 E 는 필터링 된 전류오차의 지수이며 v_{ij} 는 신경 하중의 하나이며 γ 는 학습율을 나타낸다.




그림 3 신경회로망의 새로운 하중
Fig. 3 Neural network weights updating

예를 들면, v_{11} 은 그림 3에서 나타난 첫 입력신경에서 첫 히든신경까지 하중이다. 이 하중에 대한 오차지수의 미분은 식(16)과 같다.

여기서 $\frac{\partial e_{iq}^{\Sigma}}{\partial dk_e}$, $\frac{\partial e_{id}^{\Sigma}}{\partial dR}$ 는 시스템의 Jacobean 합수이며 이는 신경회로망에서 $\frac{\partial dk_e}{\partial e_{iq}^{\Sigma}}$, $\frac{\partial dR}{\partial e_{id}^{\Sigma}}$ 에 의해

계산할 수 있다. 간단하게 $\frac{\partial e_{iq}^{\Sigma}}{\partial dk_e} = 1$, $\frac{\partial e_{id}^{\Sigma}}{\partial dR} = 1$ 을 놓고 사용한다. $f'(y_{in1})$ 은 초기 비선형 함수의 미분이며 z_{in1} 은 첫 번째의 히든 신경의 합성출력이다. 그리고 z_1 은 첫 번째의 히든신경의 출력이며 y_{in1}, y_{in2} 는 첫째와 둘째 출력신경의 합성출력이고 x_1 은 첫 번째의 입력신경의 입력이다. 마지막으로 적용법칙을 식(17)과 같이 표현할 수 있다.

$$\begin{aligned} \frac{\partial E}{\partial v_{11}} &= \frac{\partial E}{\partial e_{iq}^{\Sigma}} \frac{\partial e_{iq}^{\Sigma}}{v_{11}} + \frac{\partial E}{\partial e_{id}^{\Sigma}} \frac{\partial e_{id}^{\Sigma}}{v_{11}} \\ &= e_{iq}^{\Sigma} \frac{e_{iq}^{\Sigma}}{\partial d\hat{\omega}_r} \frac{\partial d\hat{\omega}_r}{\partial v_{11}} + e_{id}^{\Sigma} \frac{e_{id}^{\Sigma}}{\partial d\hat{R}} \frac{\partial d\hat{R}}{\partial v_{11}} \\ &= e_{iq}^{\Sigma} \frac{e_{iq}^{\Sigma}}{\partial d\hat{\omega}_r} \frac{\partial d\hat{\omega}_r}{\partial y_{in1}} \frac{\partial y_{in1}}{\partial z_1} \frac{\partial z_1}{\partial z_{in1}} \frac{\partial z_{in1}}{\partial v_{11}} \\ &\quad + e_{id}^{\Sigma} \frac{e_{id}^{\Sigma}}{\partial d\hat{R}} \frac{\partial d\hat{R}}{\partial y_{in2}} \frac{\partial y_{in2}}{\partial z_1} \frac{\partial z_1}{\partial z_{in1}} \frac{\partial z_{in1}}{\partial v_{11}} \\ &= e_{iq}^{\Sigma} f'(y_{in1}) w_{11} f'(z_{in1}) x_1 \\ &\quad + e_{id}^{\Sigma} f'(y_{in2}) w_{12} f'(z_{in1}) x_1 \end{aligned} \quad (16)$$

$$\begin{aligned} v_{11}(k+1) &= v_{11}(k) - \gamma \frac{\partial E}{\partial v_{11}} \\ &= v_{11}(k) - \gamma [e_{iq}^{\Sigma} f'(y_{in1}) w_{11} f'(z_{in1}) x_1 \\ &\quad + e_{id}^{\Sigma} f'(y_{in2}) w_{12} f'(z_{in1}) x_1] \end{aligned} \quad (17)$$

그림 4는 제시한 혼합 토크 최소화 블록도를 나타낸다. 속도제어기는 전류제어기를 위하여 지령 q 축 전류 대신에 지령토크를 출력한다. 슬롯 토크리플을 위하여 오프라인 동정은 회전자 위치에 대해 보상전류의 테이블을 발생하기 위하여 사용한다.[16] 슬롯 토크리플은 주어진 위치는 토크정수에 비례하기 때문에 고정된 q 축 전류를 보상한다. 자속 토크리플을 위하여 토크정수는 전류제어 루프에서 추정한다. 적응 메카니즘의 고속응답과 전류루프의 큰 밴드 폭은 토크상수의 온라인 추정과 자속리플의 보상에 이용한다.

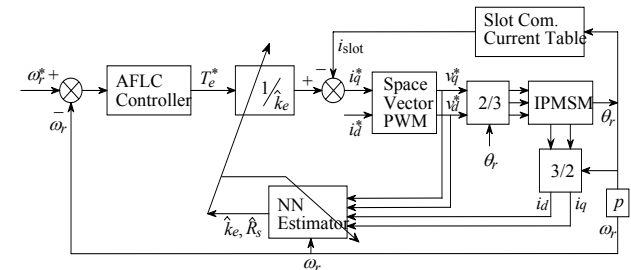


그림 4 혼합 토크리플의 최소화 제어기에 대한 블록도
Fig. 4 Block diagram of the hybrid torque ripple minimization controller

4. AFLC의 설계

그림 5는 AFLC의 원리를 설명하는 블록도를 나타낸다.

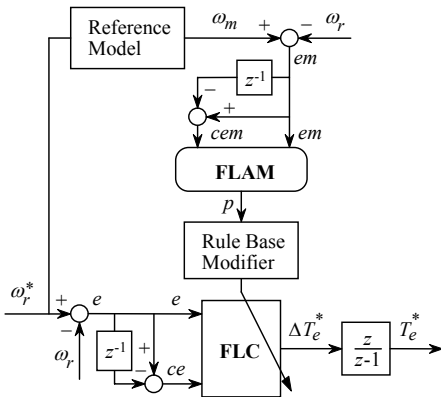


그림 5 AFLC 제어기
Fig. 5 AFLC controller

FLAM(Fuzzy Learning Adaptive Mechanism)의 설계는 시스템 응답의 각 동적 측면이 룰 그룹에 의해 주로 영향을 받는다는 사실에 기초하여 설정한다. 바로 평가되는 설정 룰에서 후반부의 변화는 시스템의 상승시간, 오버슈트, 정상상태 및 과도상태의 오차 등에 영향을 준다. 따라서 FLC(Fuzzy Logic Controller)에 학습 메카니즘을 적용하여 룰 베이스의 규칙을 수정한다. 학습 메카니즘은 퍼지 역모델 및 지식베이스 수정자를 포함한다. 드라이브 시스템의 속도 성능은 기준모델의 속도와 추정속도의 오차에 의해 좌우된다.

$$em(kT) = \omega_m(kT) - \omega_r(kT) \tag{18}$$

$$cem(kT) = em(kT) - em(kT - T) \tag{19}$$

여기서 오차 $em(kT)$ 는 각 시간순서에서 얻어지는 필요한 속도 성능의 측정 정도이다. 성능이 만족할 경우인 $em(kT) = 0$ 에서 학습 메카니즘은 FLC에서 수정할 필요가 없다. 그렇지 않으면 학습 메카니즘은 요구되는 속도 성능을 얻기 위하여 FLC의 룰 베이스를 동조시켜 수정을 해야한다. 퍼지 역모델은 오차 $em(kT)$ 를 사상하여 프로세서의 입력 $p(kT)$ 를 변화시키며 $em(kT)$ 를 영이 되도록 강제화 시킨다. 역모델의 입력은 식 (18)과 식 (19)와 같이 오차와 오차 변화 분으로 정의한다. 퍼지의 수행과정은 FLC에서 사용한 방법과 유사하게 사용한다. 프로세서에서 변화 $p(kT)$ 는 입력 오차 $em(kT)$ 에 기초하여 퍼지 역모델에 의해서 발생한다. 지식베이스의 수정자는 $p(kT)$ 에 따라서 FLC의 지식베이스를 변화시킨다. 이 변화는 FLC에서 출력의 멤버십 함수의 중앙을 수정하여 구현한다.

$$C_i(kT) = C_i(kT - T) + p(kT) \tag{20}$$

여기서 첨자 i 는 역모델에 의해 동작하는 i 번째 멤버십 함수를 나타낸다. 여기서 각 부분 변화는 각 시간에서 이루어진다. 이 방법에서 FLC는 요구되는 $i_q^*(kT)$ 를 발생하기 위하여 강제화 시킨다. 이는 기준모델과 같이 동작시키기 위하여 전동기를 강제화 시킨다. 이러한 개념을 사용하여 FLAM의 룰 베이스는 표 1에서 나타난 구조로 설계되며 멤버십 함수는 FLC에서 사용한 함수와 같다. 학습과정은 룰 베이스의 설계에 의하여 설명할 수 있다. 정격 속도 상태에서 지령속도를 반복적으로 변화시킨 경우의 시뮬레이션에 의해 0.15, 1.0 초에서 룰 베이스의 표를 예로서 나타내면 표 2에서 표 3과 같다.

표 1 속도 제어를 위한 룰 베이스

Table 1 Rule base for speed controller

ce \ e	NB	NM	NS	Z	PS	PM	PB
NB	NVB	NVB	NB	NB	NM	NS	Z
NM	NB	NB	NM	NM	NS	Z	PS
NS	NB	NM	NS	NS	Z	PS	PM
Z	NB	NM	NS	Z	PS	PM	PB
PS	NM	NS	Z	PS	PS	PM	PB
PM	NS	Z	PS	PM	PM	PB	PB
PB	Z	PS	PM	PB	PB	PVB	PVB

표 2 0.15초에서 룰 베이스 표

Table 2 Rule base table at 0.15[sec]

ce \ e	NB	NM	NS	Z	PS	PM	PB
NB	Z	Z	Z	Z	Z	Z	Z
NM	Z	Z	Z	Z	Z	Z	Z
NS	Z	Z	Z	NS	Z	Z	Z
Z	Z	Z	Z	PS	Z	Z	Z
PS	Z	Z	Z	PS	Z	Z	Z
PM	Z	Z	Z	Z	Z	Z	Z
PB	Z	Z	Z	Z	Z	Z	Z

표 3 1.0초에서 룰 베이스 표

Table 3 Rule base table at 1.0[sec]

ce \ e	NB	NM	NS	Z	PS	PM	PB
NB	NB	Z	Z	Z	Z	Z	Z
NM	Z	NB	NS	NS	NS	NS	PS
NS	Z	NS	NS	NS	Z	Z	PS
Z	Z	NS	NS	Z	Z	Z	Z
PS	NS	NS	PS	PS	Z	Z	Z
PM	Z	Z	PS	Z	Z	Z	Z
PB	Z	Z	Z	Z	Z	Z	PB

5. 시스템의 성능결과

본 연구에서 사용한 IPMSM의 파라미터는 표 4와 같다.

표 4 IPMSM의 파라미터

Table 4 Parameter of IPMSM

극수	4
전기자 저항 R_s	0.98[Ω]
영구자석 쇄교자속 ϕ_a	0.174[Wb]
정격 주파수	60[Hz]
d 전기자 인덕턴스 L_d	9.1[mH]
q 전기자 인덕턴스 L_q	18.1[mH]
정격 토크	5[N·m]
정격 속도	1800[rpm]

그림 6은 0.3[sec]에 1800[rpm]으로 운전 중, 0.9[sec]에서 1.2[sec]까지 부하토크를 5[N.m] 증가하고, 지령속도를 1.5[sec]에 1000[rpm]으로 변화하였을 경우의 응답특성을 나타낸다. 그림 7은 그림 6의 과도상태를 명확하게 분석하기 위하여 확대하여 해석한 결과를 나타낸다. 본 논문에서 제시한 AFLC 제어기는 FLC 제어기 및 PI 제어기에 비하여 오버슈트가 작고 안정화 시간도 짧은 양호한 성능이 나타난다.

그림 8은 0.1[sec]에 지령속도를 1000[rpm]으로 운전하고 있을 때 추정파라미터를 정격값의 50[%]로 설정한 후 0.8[sec]에서 1.2[sec]에 토크정수와 고정자 저항이 150[%] 상승하였을 경우의 PI 제어기의 추정특성을 나타내고 있다. 그림 9는 그림 8과 같은 조건에서 본 논문에서 제시한 신경회로망에 의한 추정특성을 나타낸다. 본 논문에서 제시한 신경회로망을 이용한 파라미터 추정은 PI 제어기보다 빠르게 토크정수 및 고정자 저항을 추정하고 있다.

그림 10은 토크 정수와 고정자 저항의 추정성능 비교를 나타낸다. 그림 10(a)와 (b)는 PI 제어기에 의한 파라미터이며 그림 10(c)와 (d)는 본 연구에서 제시한 신경회로망에 의한 파라미터이다. 본 논문에서 제시한 방법이 종래의 PI 제어기 보다 우수한 추정성능을 나타내고 있다.

그림 11과 12는 토크정수와 고정자 저항값이 4상한으로 변화하였을 경우 응답특성을 나타내고 있다. 그림 11은 PI제어기의 응답특성이며 12는 본 연구에서 제시한 신경회로망에 의한 응답특성을 나타내고 있다. 그림 (a)는 토크정수와 추정토크정수, (b)는 고정자 저항과 추정 고정자 저항, (c)는 토크정수 오차, (d)는 고정자 저항 오차를 나타낸다. 그림 (c)와 (d)에 나타난것과 같이 본 연구에서 제시한 신경회로망에 의한 파라미터 추정이 PI제어기보다 오차가 매우 작으며 양호하게 추정하고 있음을 나타내고 있다.

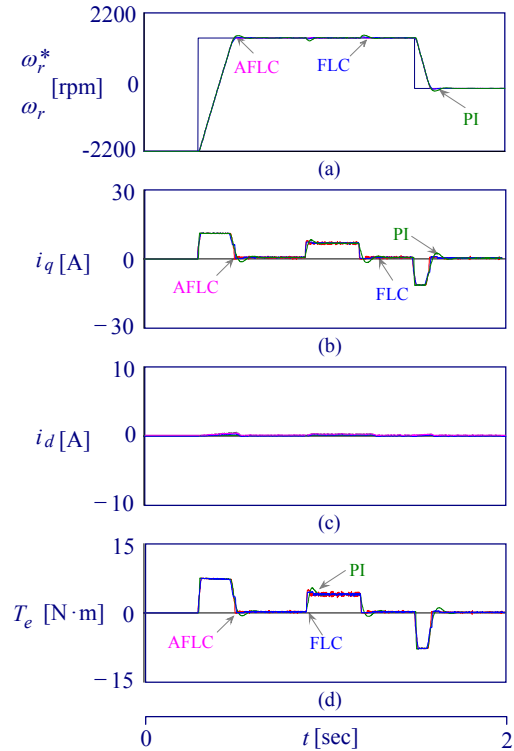


그림 6 지령속도 및 부하변화에 대한 응답특성
Fig. 6 Response characteristic with command speed and load variation

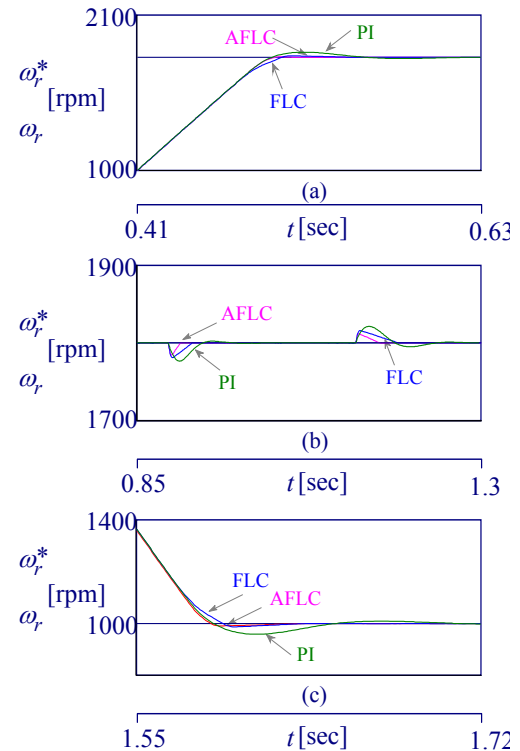


그림 7 지령속도 및 부하변화에 대한 응답특성(확대)
Fig. 7 Response characteristic with command speed and load variation

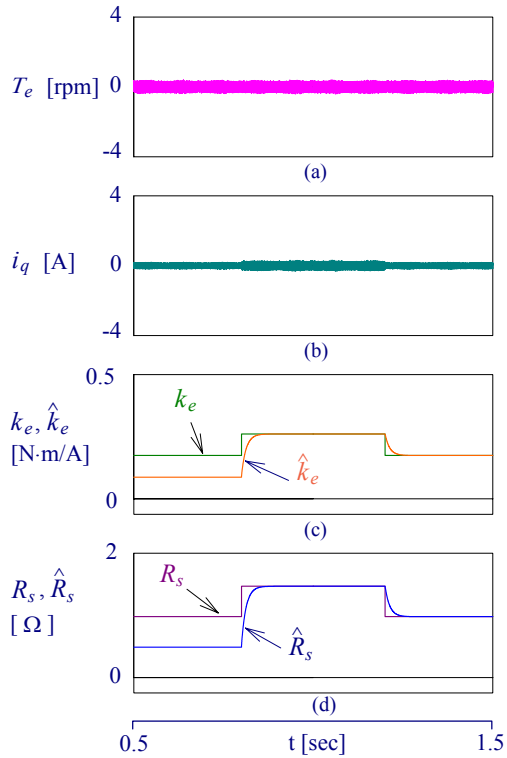


그림 8 PI 제어기에 의한 파라미터 응답특성
 Fig. 8 Response characteristics of Parameter with PI controller

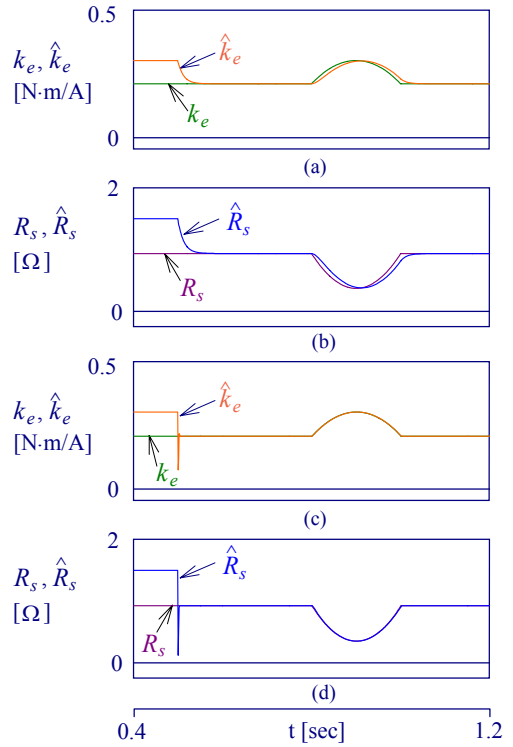


그림 10 토크 정수와 고정자 저항의 추정 특성 비교
 Fig. 10 Comparison of estimated characteristics in torque constant and state resistance

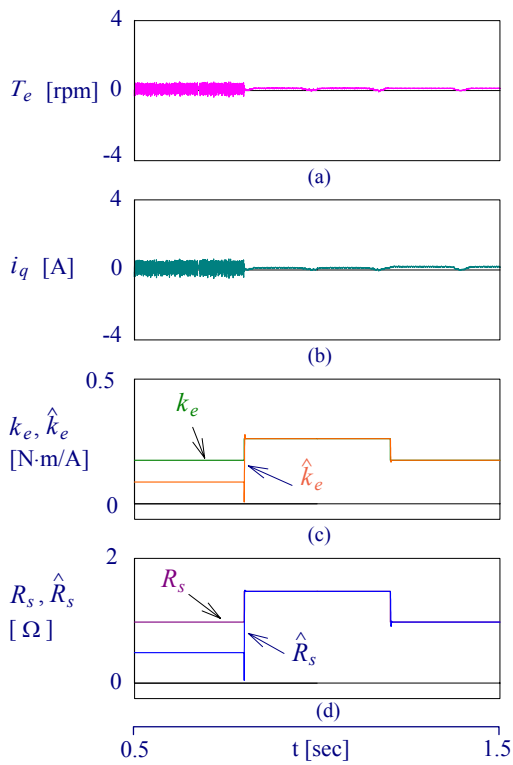


그림 9 NN에 의한 파라미터 응답특성
 Fig. 9 Response characteristics of Parameter with Neural Networks




그림 11 PI 제어기에 의한 파라미터 추정특성
 Fig. 11 Estimation characteristics of Parameter with PI controller

참 고 문 헌




그림 12 신경회로망에 의한 파라미터 추정 특성
 Fig. 12 Estimation characteristics of Parameter with Neural Networks

6. 결 론

본 논문에서는 토크정수와 고정자 저항과 같은 파라미터를 위하여 온라인 신경회로망에 기초하여 추정자를 제시하였으며, 속도제어를 위해 AFLC 제어기를 제시하였다. 신경회로망을 이용한 추정자는 다양한 동작조건에서 파라미터의 변동을 아주 정확하게 추정할 수 있었다. 제시한 AFLC 제어기는 종래의 FLC 및 PI 제어기에 비해 오버슈트가 적고 빠르게 안정화되어 우수한 성능을 나타냈다. 또한 신경회로망에 의한 파라미터 추정은 본 연구에서 제시한 방법이 종래의 PI 제어기 방법 보다 추정성능이 우수하게 나타났다. 그리고 토크리플 최소화 제어기를 사용하여 토크리플을 저감할 수 있었다. 따라서 본 연구에서 제시한 AFLC 및 신경회로망에 의한 알고리즘은 속도제어와 추정성능이 매우 양호하게 나타남을 알 수 있었으며 본 연구의 타당성을 입증하였다.

감사의 글

본 과제(결과물)는 교육과학기술부·지식경제부의 출연금으로 수행한 산학협력중심대학육성사업의 연구결과입니다.

[1] G. R. Slemon, "Electric machines and drives," Reading, MA: Addison-Wesley, 1992.
 [2] T. J. E. Miller, "Brushless permanent magnet and reluctance motor drives," Oxford, U. K.: Clarendon, 1989.
 [3] C. M. Ong, "Dynamic simulation of electric machinery using Matlab/simulink," Upper Saddle River, NJ: Prentice-Hall, 1998.
 [4] M. A. Rahman and M. A. Hoque, "On-line adaptive artificial neural network based vector control of permanent magnet synchronous motors," IEEE Trans. EC, vol. 13, pp. 311-318, 1998.
 [5] B. K. Bose, "High Performance control and estimation in ac drives," in Proc. IEEE IECON'97, vol. 2, pp. 377-385, 1997.
 [6] P. Pillay and R. Krishnan, "Control characteristics and speed controller design for a high performance permanent magnet synchronous motor drive," IEEE Trans. PE, vol. 5, pp. 151-159, 1990.
 [7] N. Matsui and H. Ohashi, "DSP based adaptive control of brushless motor," IEEE IAS, Conf. Rec. Annu. Meet., pp. 375-380, 1988.
 [8] K. Ohshi, N. Matsui and Y. Hori, "Estimation, identification and sensorless control system," Proceedings of IEEE, vol. 82, no. 8, pp. 1253-1265, 1994.
 [9] K. H. Kim, et al., "Parameter estimation and control of permanent magnet synchronous motor drive using model reference adaptive technique," IEEE IAS, Conf. Rec. Annu. Meet., pp. 387-392, 1995.
 [10] S. Weisgerber, et al., "Estimation of permanent magnet synchronous motor parameters," IEEE IAS, Conf. Rec. Annu. Meet., pp. 29-34, 1997.
 [11] J. S. Ko, J. S. Choi, K. T. Park, B. S. Park and D. H. Chung, "Development of HBPI Controller for High Performance Control of IPMSM Drive", pp. 368-372, ICPE'07, 2007.
 [12] J. S. Choi, J. S. Ko, J. H. Lee and D. H. Chung, "Speed control of IPMSM drive using neural network PI controller," CEE 06, pp. 102, 2006.
 [13] J. S. Choi, J. S. Ko, J. H. Lee and D. H. Chung, "Maximum torque control of IPMSM drive with ALC-FNN controller," ICEE 06, pp. 101, 2006.
 [14] J. S. Ko, J. S. Choi, J. H. Lee and D. H. Chung, "Maximum torque control of IPMSM drive with hybrid artificial intelligent controller," Proceeding of ICMATE'06, Session B1, pp. 177-182, 2006.
 [15] H. G. Lee, S. M. Nam, J. S. Ko, J. S. Choi, J. C. Lee and D. H. Chung, "The speed control and estimation of IPMSM using adaptive FNN and ANN," ICCAS 2005, p. 134, 2005.

- [16] J. Holtz and L. Springob, "Identification and compensation of torque ripple in high precision permanent magnet motor drives," IEEE Trans. IE, vol. 43, no. 2, pp. 309-330, 1996.

저 자 소 개




최 정 식 (崔 正 植)

2005년 순천대학교 공대 전기제어공학과 졸업 2007년 2월 순천대학교 대학원 전기공학과 졸업(석사). 2007년 3월 동 대학원 전기공학과 박사과정

Tel : 061-750-3543

Fax : 061-752-1103

E-mail : cjs1108@scnu.ac.kr



고 재 섭 (高 在 涉)

2005년 순천대학교 공대 전기제어공학과 졸업 2007년 2월 순천대학교 대학원 전기공학과 졸업(석사). 2007년 3월 동 대학원 전기공학과 박사과정

Tel : 061-750-3543

Fax : 061-752-1103

E-mail : kokos22@naver.com



정 동 화 (鄭 東 和)

1979년 영남대 공대 전기공학과 졸업. 1981년 한양대 대학원 전기공학과 졸업(석사). 1987년 동 대학원 전기공학과 졸업(박사). 1988년~1989년 현대중전기(주) 기술연구소 책임연구원. 1989년~현재 순천대학교 정보통신공학부 교수.

Tel : 061-750-3543

Fax : 061-752-1103

E-mail : hwa777@sunchon.ac.kr

WebPage : <http://pelab.sunchon.ac.kr/~hwa777>