

LM-FNN 제어기에 의한 IPMSM의 고성능 속도제어

南守明*, 崔正植*, 鄭東和†

High Performance Speed Control of IPMSM with LM-FNN Controller

Su-Myeong Nam, Jung-Sik Choi, and Dong-Hwa Chung

요약

본 논문에서는 LM-FNN(Learning Mechanism-Fuzzy Neural Network) 제어기를 이용하여 IPMSM 드라이브의 고성능 속도를 제어한다. 고성능제어를 위하여 신경회로망과 퍼지제어를 혼합 적용한 FNN을 설계하고 더욱 성능을 개선하기 위하여 학습 메카니즘을 이용하여 FNN 제어기의 파라미터를 갱신시킨다. 그리고 ANN(Artificial Neural Network)을 이용하여 IPMSM 드라이브의 속도 추정기법을 제시한다. 추정속도의 타당성을 입증하기 위하여 시스템을 구성하여 제어특성을 분석한다. 그리고 추정된 속도를 지령속도와 비교하여 전류제어와 공간벡터 PWM을 통하여 IPMSM의 속도를 제어한다. 본 연구에서 제시한 LM-FNN과 ANN 제어기의 제어특성과 추정성을 분석하고 그 결과를 제시한다.

ABSTRACT

Precise control of interior permanent magnet synchronous motor(IPMSM) over wide speed range is an engineering challenge. This paper considers the design and implementation of novel technique of high performance speed control for IPMSM using learning mechanism-fuzzy neural network(LM-FNN) and ANN(artificial neural network) control. The hybrid combination of neural network and fuzzy control will produce a powerful representation flexibility and numerical processing capability. Also, this paper proposes speed control of IPMSM using LM-FNN and estimation of speed using artificial neural network controller. The back propagation neural network technique is used to provide a real time adaptive estimation of the motor speed.

The error between the desired state variable and the actual one is back-propagated to adjust the rotor speed, so that the actual state variable will coincide with the desired one. The back propagation mechanism is easy to derive and the estimated speed tracks precisely the actual motor speed. Analysis results to verify the effectiveness of the new hybrid intelligent control proposed in this paper.

Key Words : IPMSM Drive, LM-FNN, FNN, ANN, BPA, Speed Estimation, Speed Control

1. 서 론

IPMSM(Interior Permanent Magnet Synchronous

*교신저자 : 정희원, 순천대 전기전자정보통신공학부 교수
E-mail : hwa777@sunchon.ac.kr

*학생회원, 순천대 전기전자정보통신공학부 석사과정
접수일자 : 2005. 6. 27 1차 심사 : 2005. 9. 5
2차 심사 : 2005. 10. 19 3차 심사 : 2005. 12. 1
심사완료 : 2005. 12. 7

Motor)은 토크 및 전력밀도가 높고 고 효율 및 역율 때문에 서보 드라이브의 적용분야에 광범위하게 사용되고 있다. 직류전동기 및 유도전동기와 비교하여 고 성능, 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].

종래에는 IPMSM을 제어하기 위하여 비선형 및 적

응제어 방식을 많이 사용하였다^[3]. 이 방식에서는 상태 추정 및 파라미터 동정은 선형모델에 기초를 하고 있다. 모델이 물리적인 시스템을 이탈하면 제어성능이 저하된다. 또한 이 방식은 시스템에 국한된 정확한 제어 방정식 및 정밀한 수치적인 값을 필요로 한다.

최근에는 퍼지논리 제어기법이 고성능 전동기 드라이브의 제어에 적용되고 있다^[4-5]. 퍼지제어는 비선형 시스템에 효과적으로 적용할 수 있으며 간단하고 용이한 수학적인 설계조건이 필요한 장점을 가지고 있다. 그러나 다양한 부하변동과 관성변화에 대하여 고성능의 응답특성을 기대하기가 어려우며 만족할만한 성능을 얻을 수 없다^[5].

최근, 인공 신경회로망의 진가가 인정되어 많은 관심을 가지게 되었으며 함수를 근사화하기 위하여 다양하게 연구되고 있다^[6-10]. 이러한 방법들은 일반적인 벡터제어 방법과 비교하여 우수한 성능을 얻을 수 있었다. 그러나 자속을 제어할 수 없으므로 포화의 영향이 나타나고 속도센서를 사용하고 있다.

IPMSM의 드라이브 시스템에서 속도와 위치의 정보를 얻기 위하여 엔코더와 리졸버와 같은 센서를 사용한다. 그러나 이러한 센서는 실제의 적용분야에서 많은 문제점이 도출되며 시스템의 적용분야가 제한된다. 이러한 센서는 값이 비싸고 시스템의 가격을 증가시킨다. 그리고 센서의 정밀도에 영향을 주는 온도, 습도 및 먼지 등 환경적인 요인에 민감하며 시스템의 강인성을 약화시킨다. 이러한 문제점을 해결하기 위하여 센서리스 제어에 관한 연구가 활발히 진행되고 있다^[11-13].

본 연구에서는 LM-FNN(Learning Mechanism-Fuzzy Neural Network) 제어기를 이용하여 IPMSM 드라이브의 고성능 속도를 제어한다. PI 제어기에서 나타나는 문제점을 해결하기 위하여 신경회로망과 퍼지제어를 혼합 적용한 FNN을 설계한다. 더욱 성능을 개선하기 위하여 학습 메카니즘을 이용하여 FNN 제어기의 파라미터를 갱신시킨다. 그리고 ANN(Artificial Neural Network)을 이용하여 IPMSM 드라이브의 속도 추정기법을 제시한다. 2층 구조를 가진 신경회로망에 BPA(Back Propagation Algorithm)를 적용하여 IPMSM 드라이브의 속도를 추정한다. 추정속도의 타당성을 입증하기 위하여 시스템을 구성하여 제어특성을 분석한다. 그리고 추정된 속도를 지령속도와 비교하여 전류제어와 공간벡터 PWM을 통하여 IPMSM의 속도를 제어한다. 본 연구에서 제시한 LM-FNN과 ANN 제어기의 제어특성과 추정성능을 분석하고 그 결과를 제시한다.

2. 시스템 구성

본 논문에서는 공간벡터 PWM 인버터에 의해 구동되는 고성능 IPMSM의 벡터제어 시스템을 고려한다. 이러한 시스템 구성은 로봇, 항공기 및 전기자동차 등의 드라이브와 같은 고성능 제어 시스템에 응용된다.

그림 1은 공간벡터 PWM 인버터에 의하여 구동되는 일반적인 IPMSM 드라이브의 벡터제어 시스템을 나타낸다.

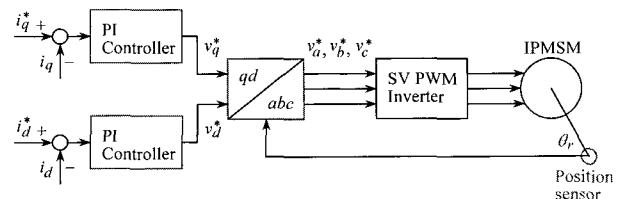


그림 1 IPMSM의 벡터제어 시스템

Fig. 1 Vector control system of IPMSM

i_d^* 와 i_q^* 는 지령 토크 및 자속 성분의 전류를 나타내며 실제전류 i_d 와 i_q 와 비교하여 종래의 PI 제어기를 이용하여 제어한다. PI 제어기의 출력은 v_d^* 와 v_q^* 이며 이는 좌표변환에 의해 v_a^*, v_b^*, v_c^* 로 변환하여 공간벡터 PWM 인버터에 의해 IPMSM을 제어한다. 회전자의 위치정보 θ_r 는 좌표변환에 이용한다.

동작특성을 분석하기 위한 IPMSM의 미분 방정식은 다음과 같다.

$$pi_d = (v_d - Ri_d + \omega_r L_d i_q) / L_d \quad (1)$$

$$pi_q = (v_q - Ri_q - \omega_r L_d i_d - \omega_r \phi_{af}) / L_q \quad (2)$$

$$p\omega_r = (T_e - T_L - B\omega_r) / J \quad (3)$$

여기서, 발생토크는 다음 식으로 표현된다.

$$T_e = \frac{3}{2} P [\phi_{af} i_q + (L_d - L_q) i_d i_q] \quad (4)$$

3. FNN 제어기

FNN은 신경회로망과 퍼지제어를 혼합 구성하여 강력한 표현의 유연성과 수치 처리능력을 가지고 있다.

FNN는 퍼지룰의 조건부와 결론부를 클러스터링 방법과 다중 신경회로망으로 구성한다. FNN은 신경회로망과 같은 고도의 적용제어의 능력 및 퍼지제어와 같은 강인성 제어의 장점을 가지게 된다.

그림 2는 FNN의 구성을 나타내며 여기서 두 개의 입력변수는 오차 e 와 오차의 변화분 ce 이고 출력변수는 제어변수 u^* 이다.

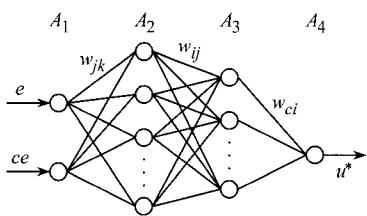


그림 2 FNN 제어기의 구성

Fig. 2 The construction of FNN controller

3.1 제어기의 조건부의 구현

그림 2에서 A_1 층에서 A_3 층 사이에 신경회로망은 퍼지룰의 조건부의 구현을 나타낸다. 조건부의 멤버쉽 함수를 효과적으로 설계하기 위하여 신경회로망의 구조를 간단하게 하고 수렴속도를 개선하기 위하여 클러스터링 방법을 적용한다. 표 1은 퍼지제어룰의 집합을 나타낸다.

표 1 퍼지룰 표

Table 1 Fuzzy rule table

$e\omega_r$	NL	NM	NS	ZE	PS	PM	PL
$ce\omega_r$	NL	NL	NL	NL	NM	NS	ZE
NL	NL	NL	NL	NM	NS	ZE	PS
NM	NL	NL	NL	NM	ZE	PS	PM
NS	NL	NL	NM	NS	ZE	PS	PM
ZE	NL	NM	NS	ZE	PS	PM	PL
PS	NM	NS	ZE	PS	PM	PL	PL
PM	NS	ZE	PS	PM	PL	PL	PL
PL	ZE	PS	PM	PL	PL	PL	PL

퍼지 룰베이스에서 입력공간은 49개의 부분 공간으로 나눈다. 룰이 동일한 동작일 경우 같은 입력공간으로 클러스터링한다. 그런 다음 새로운 클러스터링과 일치하는 룰은 전문가에 의해 재 설계되고 신경회로망으로 구현한다. 퍼지룰의 수는 클러스터링 방법에 의해 매우 감소시킬 수 있다. 또한 이러한 구현은 비선

형 함수를 설계할 수 있으며 신경세포의 sigmoid 특성에 의해 퍼지의 입력공간을 분할한다. A_3 층에서 각 신경세포의 출력은 각 부분 공간에서 퍼지룰의 진리값이다. 퍼지 클러스터링과 학습을 실현하기 위하여 이전 49룰과 같은 효과를 얻는 FNN 제어기는 오차의 함수가 필요하다.

오차함수를 정의한 후, 오차를 최소화하기 위하여 다음 단계는 오차 역전파 알고리즘에 의해 A_1 층과 A_3 층 사이에 가중치 W_{jk} 와 W_{ij} 를 조절한다. 가중치 조절을 통하여 신경회로망은 클러스터 된 퍼지룰의 조건부를 완전하게 구현할 수 있다.

학습과정 동안 진동을 피하고 수렴속도를 개선하기 위하여 다음과 같은 모멘텀(momentum) 항으로 새로운 조절을 수행한다.

$$W_{jk}(t+1) = W_{jk}(t) + \Delta W_{jk} + \alpha[W_{jk}(t) - W_{jk}(t-1)] \quad (5)$$

$$W_{ij}(t+1) = W_{ij}(t) + \Delta W_{ij} + \alpha[W_{ij}(t) - W_{ij}(t-1)] \quad (6)$$

3.2 제어기의 결론부의 구현

그림 2에서 A_3 층과 A_4 층 사이의 신경회로망은 퍼지룰의 결론부의 구현을 나타낸다. 오차함수를 정의한 후, 오차를 최소화하기 위하여 다음 단계는 오차 역전파 알고리즘에 의해 A_3 층과 A_4 층 사이에 가중치 W_{ci} 를 조절한다.

$$W_{ci}(t+1) = W_{ci}(t) + \Delta W_{ci} + \alpha[W_{ci}(t) - W_{ci}(t-1)] \quad (7)$$

4. LM-FNN 제어기

IPMSM 드라이브 시스템을 위한 LM-FNN 제어기 및 ANN은 그림 3과 같다. FNN 제어기는 드라이브 시스템의 동작을 관측하고 요구되는 지령치로 실제 성능을 비교한다. 학습 메카니즘은 요구되는 시스템 동

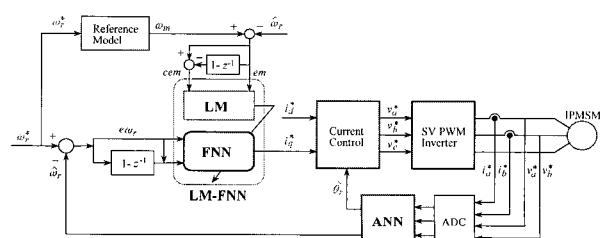


그림 3 LM-FNN 및 ANN 제어기

Fig. 3 LM-FNN and ANN controller

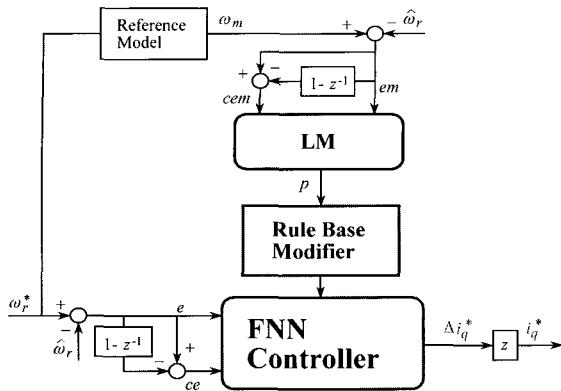


그림 4 학습 메카니즘에 의한 FNN 제어기
Fig. 4 FNN controller with learning algorithm

작으로 거의 일치시키기 위하여 FNN 제어기를 수정한다. FNN의 입력은 속도오차 e 및 속도오차의 변화분 ce 이다. FNN의 출력 Δi_q^* 는 중심 비퍼지화 방법에 의해 계산한다. 이전 출력 $i_q^*(k-1)$ 에 출력 $\Delta i_q^*(k)$ 를 합하여 최종 $i_q^*(k)$ 를 얻고 이를 전동기의 입력으로 한다.

그림 4는 학습 메카니즘을 이용한 FNN 제어기의 구조를 나타낸다.

학습 메카니즘의 설계는 시스템 응답의 각 동적 측면이 를 그룹에 의해 주로 영향을 받는다는 사실에 기초하여 설정한다. 바로 평가되는 설정 를에서 후반부의 변화는 시스템의 상승시간, 오버슈트, 정상상태 및 과도상태의 오차 등에 영향을 준다. 따라서 FNN 제어기에 학습 메카니즘을 적용하여 를 베이스의 규칙을 수정한다. 학습 메카니즘은 페지 역모델 및 지식베이스 수정자를 포함한다. 드라이브 시스템의 속도성능은 기준모델의 속도와 추정속도의 오차에 의해 좌우된다.

$$em(kT) = \omega_m(kT) - \hat{\omega}_r(kT) \quad (8)$$

$$cem(kT) = em(kT) - em(kT-T) \quad (9)$$

여기서 오차 $em(kT)$ 는 각 시간순서에서 얻어지는 필요한 속도성능의 측정 정도이다. 성능이 만족할 경우인 $em(kT)=0$ 에서 학습 메카니즘은 FNN 제어기에서 수정할 필요가 없다. 그렇지 않으면 학습 메카니즘은 요구되는 속도성능을 얻기 위하여 FNN 제어기의 를 베이스를 동조시켜 수정을 해야 한다.

페지 역모델은 오차 $em(kT)$ 를 사상하여 프로세서

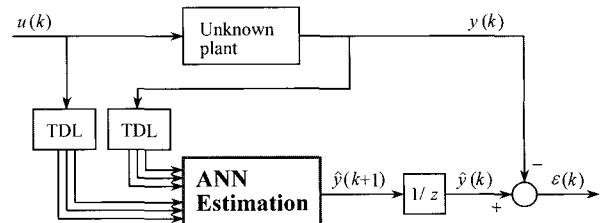


그림 5 ANN을 이용한 시스템 추정
Fig. 5 System estimation using ANN

의 입력 $p(kT)$ 를 변화시키며 $em(kT)$ 를 영이 되도록 강제화 시킨다. 역모델의 입력은 식 (8)과 식 (9)와 같이 오차와 오차 변화분으로 정의한다. 페지의 수행 과정은 FNN 제어기에서 사용한 방법과 유사하게 사용한다. 프로세서에서 변화 $p(kT)$ 는 입력오차 $em(kT)$ 에 기초하여 페지 역모델에 의해서 발생한다.

지식베이스의 수정자는 $p(kT)$ 에 따라서 FNN 제어기의 지식베이스를 변화시킨다. 이 변화는 FNN 제어기에서 출력의 멤버쉽 함수의 중앙을 수정하여 구현한다.

$$C_i(kT) = C_i(kT-T) + p(kT) \quad (10)$$

여기서 첨자 i 는 역모델에 의해 동작하는 i 번째 멤버쉽 함수를 나타낸다. 여기서 각 부분 변화는 각 시간에서 이루어진다. 이 방법에서 FNN 제어기는 요구되는 $i_q^*(kT)$ 를 발생하기 위하여 강제화 시킨다.

5. ANN에 의한 속도 추정

ANN은 인간 두뇌의 간단한 모델에 의해 사고하는 구조로 이루어진 컴퓨팅 시스템이다. ANN은 비선형 동적 시스템의 파라미터를 추정 및 제어를 하는데 사용한다.

ANN을 위한 이상적인 적용은 비선형 시스템의 추정문야에 있다. 실질적으로 어떤 이산 비선형 시스템은 지연 입·출력에서 시스템을 표현할 수 있는 NARMAX (Nonlinear AutoRegressive Moving Average with eXogenous inputs) 모델에 의해서 나타낼 수 있다. 일반적으로 NARMAX 모델은 다음과 같은 형태로 나타낼 수 있다.

$$\mathbf{y}(k+1) = \mathbf{f}(\mathbf{y}(k), \dots, \mathbf{y}(k-d_y), \mathbf{u}(k), \dots, \mathbf{u}(k-d_u)) \quad (11)$$

여기서 d_u 와 d_y 는 입력과 출력 벡터 u 와 y 에서 최대 지연을 나타낸다. 이 모델의 형태는 모델이 전적

으로 기지 양으로 표현되기 때문에 시스템의 추정을 추구하는데 이상적이다. 그림 5는 ANN을 이용한 시스템의 추정을 나타낸다. ANN은 시스템의 NARMAX 모델을 추정하는데 사용하며 이를 위해 식 (11)에서 필요한 입력과 예측 출력벡터 $\hat{y}(k+1)$ 로서 ANN의 출력을 구성한다. 이산시간 $k+1$ 에서 예측 출력벡터를 실제 출력벡터와 비교하여 식 (11)에서 함수 $f(\cdot)$ 를 업데이트하기 위하여 학습한다. 그리고 오차 역전파 알고리즘에 의해 ANN 하중을 새롭게 하기 위하여 오차를 사용한다.

ANN을 이용한 시스템의 추정에서 구한 IPMSM의 최종 추정속도는 다음 식과 같다.

$$\begin{aligned}\hat{\omega}_r(k+1) &= \hat{\omega}_r(k) + \Delta\hat{\omega}_r(k) \\ &= \hat{\omega}_r(k) - \frac{\Delta W_2(k)}{T} \\ &= \hat{\omega}_r(k) - \frac{\eta}{T} \left\{ [\phi_q(k) - \hat{\phi}_q(k)] [\hat{\phi}_d(k-1)] - [\phi_d(k) - \hat{\phi}_d(k)] [\hat{\phi}_q(k-1)] \right\} \\ &\quad - \frac{\alpha}{T} \Delta W_2(k-1)\end{aligned}\quad (12)$$

여기서 T 는 샘플링 주기를 나타내며 η 는 학습계수이며 학습과정에서 학습율을 나타낸다. 이 계수가 크면 하중 변화가 크다. 실제 구현을 위하여 학습율은 진동이 유발되지 않는 범위에서 큰 값으로 설정한다. 계수 α 는 현재 하중에서 변동하는 과거 하중의 영향을 결정한다.

추정속도를 이용한 회전자 자속의 위치는 다음과 같다.

$$\hat{\theta}_r(k+1) = \hat{\theta}_r(k) + T \cdot \hat{\omega}_r(k) \quad (13)$$

6. 시스템의 시뮬레이션 결과

본 연구에서 사용한 IPMSM의 파라미터는 표 2와 같다.

표 2 IPMSM의 파라미터
Table 2 Parameters of IPMSM

극수	4
전기자 저항 R_s	0.98[Ω]
영구자석 쇄교자속 ϕ_a	0.147[Wb]
정격 주파수	60[Hz]
전기자 최대전류 I_{am}	15[A]
전기자 최대전압 V_{am}	200[V]
d 축 인덕턴스 L_d	9.1[mH]
q 축 인덕턴스 L_q	18.82[mH]
정격 속도	1800[rpm]

그림 6은 0.2[sec]에서 스텝 지령속도를 1800[rpm]으로 운전 중, 0.6[sec]에서 0.8[sec]까지 부하토크를 3[N·m]로 인가하였을 경우의 응답특성이다. 이 경우 PI, FNN 및 LM-FNN 제어기의 응답특성을 비교하였다.

그림 7은 그림 6의 응답특성을 명확하게 분석하기 위하여 확대한 그림이다. 그림 7(a)는 초기 기동상태의 응답특성이며 LM-FNN 제어기는 종래의 PI 및 FNN 제어기 보다 응답특성이 양호하게 나타난다. 그림 7(b)는 부하인가에 따른 응답특성을 나타낸다. 이 경우에도 LM-FNN 제어기가 PI 및 FNN 제어기 보다 오버슈트도 작고 빠르게 안정화하고 있다. 따라서 LM-FNN 제어기의 성능이 양호하다는 결과이다.

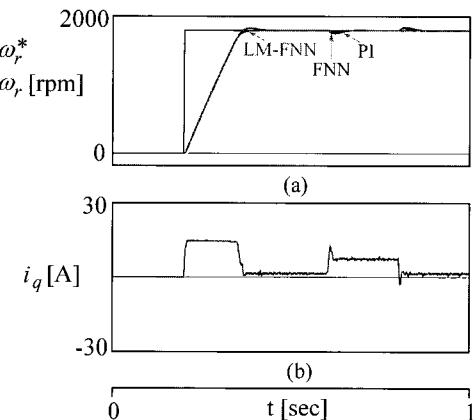


그림 6 PI, FNN 및 LM-FNN 제어기의 응답특성의 비교
Fig. 6 The comparison of response characteristics with PI, FNN and LM-FNN controller

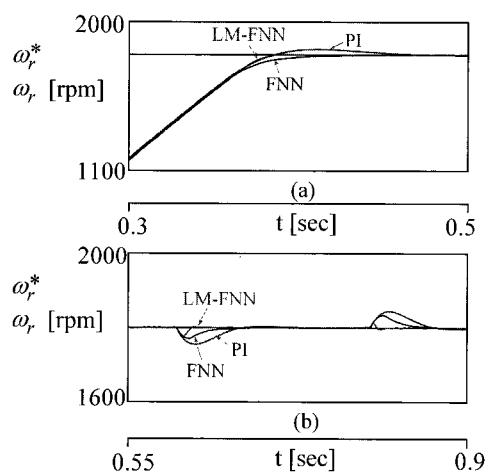


그림 7 초기와 부하인가에 대한 제어기의 응답특성의 비교
Fig. 7 The comparison of response characteristics with starting state and load torque

그림 8은 그림 6과 같은 조건에서 정격 관성을 2배로 하였을 경우에 나타나는 응답특성이다. 이 경우에도 LM-FNN 제어기의 성능이 양호하게 나타난다.

그림 9는 그림 6과 같은 조건에서 정격 저항을 2배로 하였을 경우에도 나타나는 응답특성이다. 이 경우에도 LM-FNN 제어기의 성능이 양호하게 나타난다. 따라서 LM-FNN 제어기는 관성과 저항 등 파라미터의 변동에 대하여 더욱 양호한 특성을 발휘할 수 있다.

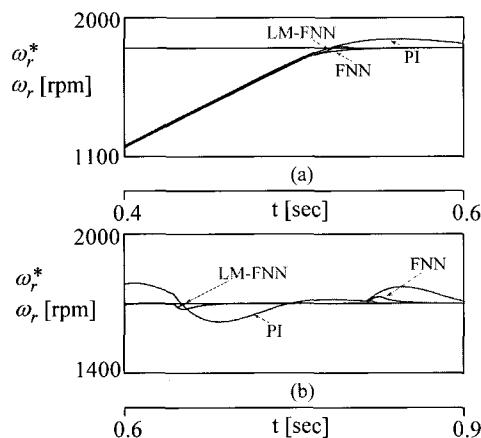


그림 8 관성 2배에 대한 응답특성의 비교 ($J = 2J_n$)
Fig. 8 The comparison of response characteristics with twice inertia

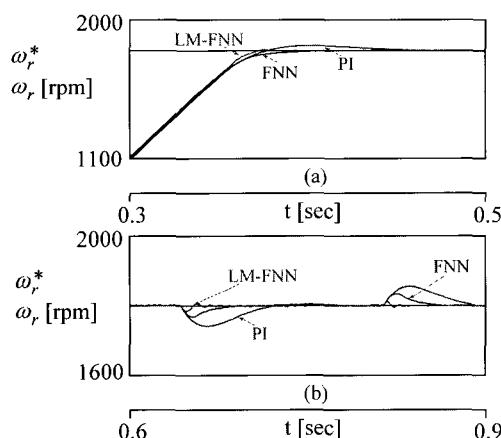


그림 9 저항 2배에 대한 응답특성의 비교 ($R_a = 2R_{an}$)
Fig. 9 The comparison of response characteristics with twice resistance

그림 10은 0.2[sec]에서 지령속도 1000[rpm], 0.5[sec]에서 지령속도 1500[rpm], 0.8[sec]에서 지령속도 500[rpm], 1.1[sec]에서 지령속도 1800[rpm] 및 1.4[sec]에 지령속도 1000[rpm]를 다양하게 변화시켰을 경우에

나타나는 응답특성이다. 이 경우에도 LM-FNN 제어기의 성능이 우수하게 나타나고 있다.

그림 11은 0.2[sec]에 지령속도 1000[rpm]으로 운전시켜 주기적으로 스텝 지령속도를 1000[rpm] 및 -1000[rpm]을 반복으로 하였을 경우의 응답특성이다. 이 경우에도 LM-FNN 제어기의 성능이 우수하게 나타나고 있다.

그림 12는 정격관성에서 4상한 운전을 시켰을 경우에 나타나는 응답특성이다. 그림 12(a)는 지령속도와 실제속도, 그림 (b)는 지령속도와 추정속도, 그림 (c)는 q 축 전류, 그림(d)는 지령 위치와 실제 위치, 그림 (e)는 지령속도와 추정속도의 오차를 나타내고 있다. 추정속도는 실제속도에 양호하게 추정하고 있으며 실제 위치도 지령위치에 양호하게 추정하고 있다.

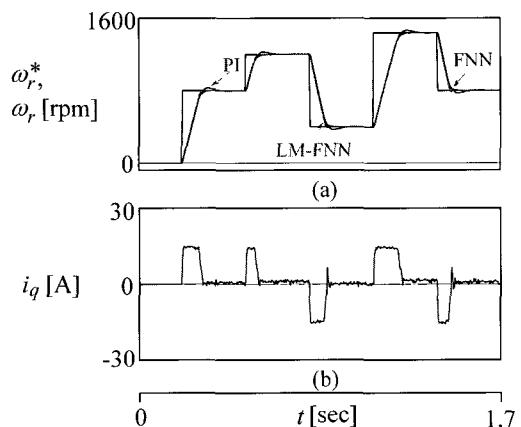


그림 10 속도변화에 대한 응답특성의 비교
Fig. 10 The comparison of response characteristics with speed change

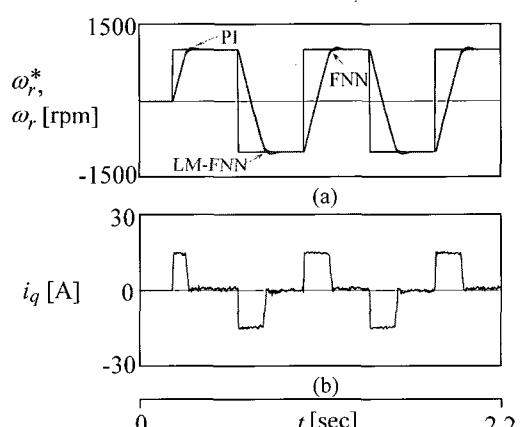


그림 11 정역회전에 대한 응답특성의 비교
Fig. 11 The comparison of response characteristics with forward and reverse revolution

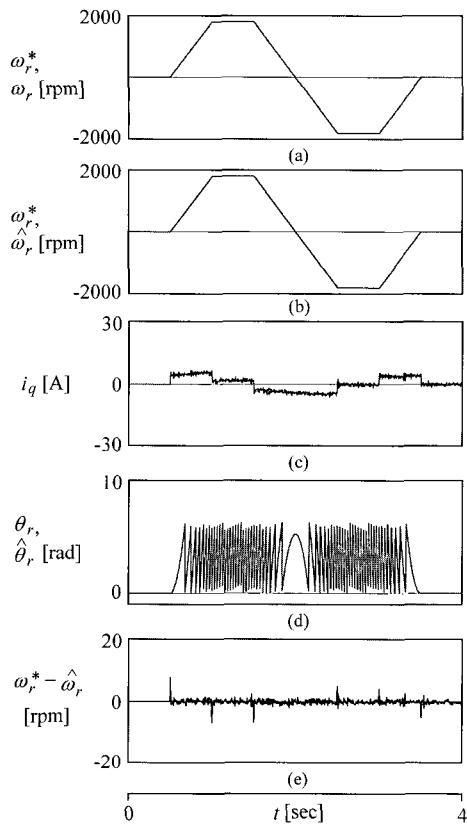


그림 12 4상한 운전에 대한 응답특성 ($J = J_n$)
Fig. 12 Response characteristics with quadrant drive

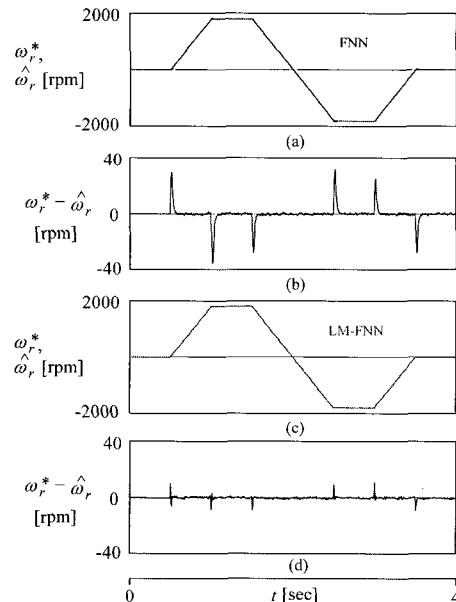


그림 13 관성 2배에 대한 4상한 운전의 응답특성 ($J = 2J_n$)
Fig. 13 Response characteristics of quadrant drive with twice inertia

그림 13은 관성을 2배로 했을 경우의 응답특성을 나타낸다. 그림 13(a)는 FNN 제어기의 지령속도와 추정속도이고 그림 13(b)는 이 속도의 오차이다. 그림 13(c)는 LM-FNN 제어기의 지령속도와 추정속도이며 그림 13(d)는 이 속도의 오차이다. 그림 13(d)에서 LM-FNN 제어기의 오차가 그림 13(b)에서의 FNN 제어기의 오차 보다 매우 작게 나타나고 있다. 따라서 LM-FNN 제어기는 FNN 제어기 보다 성능이 매우 양호하다는 타당성을 알 수 있다.

7. 시스템의 실험 결과

그림 14는 본 논문의 타당성을 입증하기 위하여 설계 제작한 IPMSM 드라이브 시스템의 전체 구성도를 나타낸다.

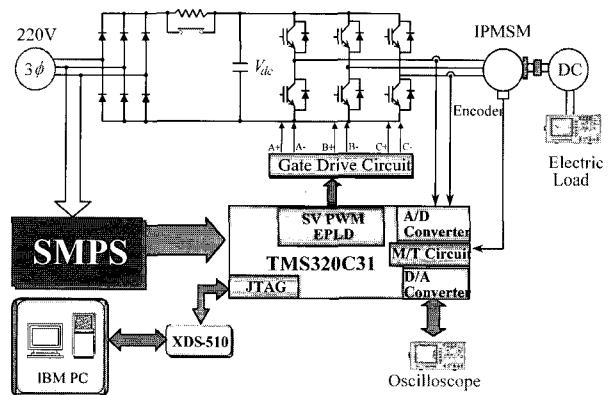


그림 14 IPMSM 드라이브 시스템의 구성
Fig. 14 The configuration of IPMSM drive system

다음은 실험결과 과정에 대한 응답특성을 나타낸다. 그림 15와 그림 16은 무부하 상태에서 4000[rpm]으로 운전 중, 부하토크를 4[N·m]인가하여 3000[rpm]으로 운전속도를 변화시켰을 경우 FNN과 LM-FNN의 응답 특성을 나타낸다. 부하를 인가한 경우에도 LM-FNN제어기의 응답성능은 FNN 제어기 보다 상승 시간이 빠르며 속도 추종이 양호하게 나타난다.

그림 17과 그림 18은 다양한 속도변화에 대한 응답 변화로 무부하 상태에서 운전속도를 0[rpm] → 2000[rpm] → 4000[rpm] → 4000[rpm] → -4000[rpm] → 0[rpm]로 운전 속도를 변화하였을 때 FNN과 LM-FNN의 응답특성을 나타낸다. 다양한 속도변화에서도 LM-FNN 제어기는 FNN 제어기에 비해 오버슈트가 적고 상승 시간이 빠르며 정상상태에 빠르게 도달한다.

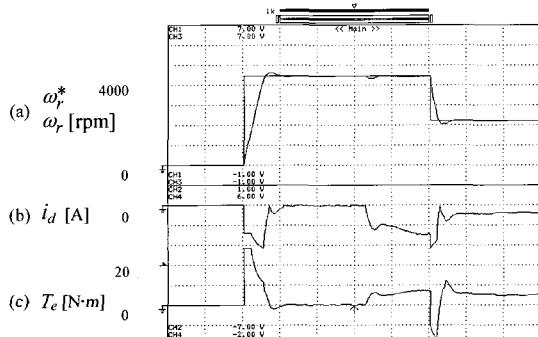


그림 15 지령속도 변화와 부하인가에 대한 FNN의 응답특성
Fig. 15 Response characteristics of FNN with command speed change and load torque

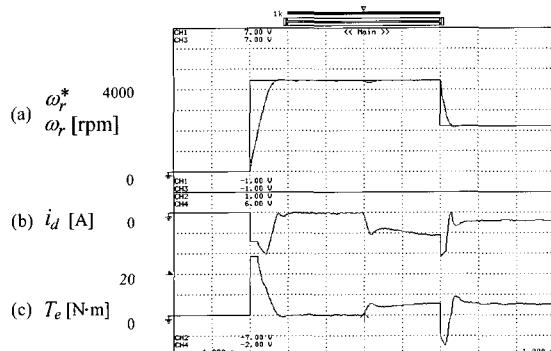


그림 16 지령속도 변화와 부하인가에 대한 LM-FNN의 응답 특성
Fig. 16 Response characteristics of LM-FNN with command speed change and load torque

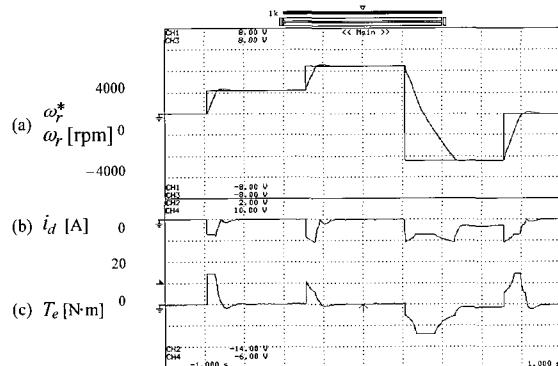


그림 17 스텝 지령속도에 변화에 대한 FNN의 응답특성
Fig. 17 Response characteristics of FNN in command speed change

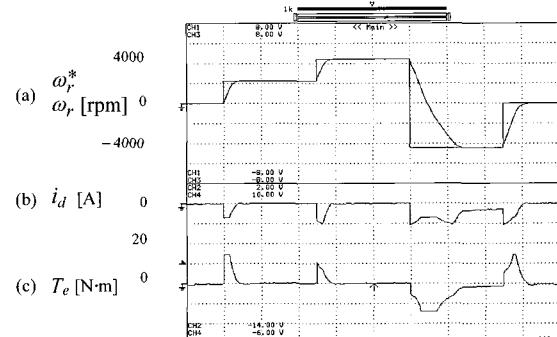


그림 18 스텝 지령속도에 변화에 대한 LM-FNN의 응답특성
Fig. 18 Response characteristics of LM-FNN in command speed change

8. 결 론

본 연구에서는 LM-FNN과 ANN을 이용하여 IPMSM의 고성능 속도 제어 및 추정을 제시하였다. LM-FNN 제어기를 이용하여 속도를 제어하였으며 ANN을 이용하여 속도를 추정하였다.

제시한 LM-FNN 제어기는 종래의 PI 및 FNN 제어기 보다 성능이 우수한 결과를 얻었으며 고성능 및 강인성 제어를 확인할 수 있었다. ANN을 이용하여 다양한 지령속도의 변화에도 추정속도는 실제속도에 양호하게 추정하였다. 지령속도를 정·역회전 운전 및 4상한 운전시켰을 경우에도 추정속도는 실제속도에 양호하게 추정하였다. 그리고 부하토크를 인가할 경우에도 추정속도는 실제속도에 양호한 추정성능을 확인할 수 있었다.

본 연구에서는 제시한 LM-FNN과 ANN은 시스템의 응답특성이 양호하게 나타났으며 속도의 제어 및 추정에도 만족할만한 결과를 얻을 수 있었다. 따라서 본 연구에서 제시한 LM-FNN 제어기의 타당성을 입증할 수 있었다.

본 과제는 교육인적자원부와 산업자원부의 출연금 및 보조금으로 수행한 산학협력중심대학육성사업의 연구 결과입니다.

참 고 문 헌

- [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] K.J. Astron and B. Wittenmark, "Adaptive control," Addison-Wesley, 1989.
- [4] D. H. Chung, "Fuzzy control for high performance vector control of PMSM drive system," KIEE, Vol. 47, No. 12, pp. 2171-2180, 1998.
- [5] Y. Tang and L. Xu, "Fuzzy logic application for intelligent control of a variable speed drive," IEEE Trans. EC, Vol. 9, pp. 679-685, 1994.
- [6] K. S. Narendra and K. Parthasarthy, "Identification and control of dynamical system using neural network," IEEE Trans. Neural Networks, Vol. 1, No. 1, pp. 4-27, 1990.
- [7] Cybenko, "Approximations by superposition of a sigmoidal function," Mathematics of Contr., Signals and Syst., Vol. 2, pp. 303-314, 1989.
- [8] A. K. Toh, E. P. Nowicki and F. Ashrafszadeh, "A flux estimator for field oriented control of an induction motor using an artificial neural network," IEEE IAS Conf. Rec. Ann. Meet., Vol. 1, pp. 585-592, 1994.
- [9] M. G. Simoes and B. K. Bose, "Neural network based estimation of feedback signals for a vector controlled induction motor drive," IEEE Trans. IA, Vol. 31, No. 3, pp. 620-629, 1995.
- [10] M. T. Wishart and R. G. Harley, "Identification and control of induction machines using neural networks," IEEE Trans. IA, Vol. 31, No. 3, pp. 612-619, 1995.
- [11] C. Schauder, "Adaptive speed identification for vector control of induction motors," IEEE Trans. on IA, pp. 1054-1061, 1992.
- [12] F. Z. Feng, T. Fukao, "Robust speed identification for speed sensorless vector control of induction motors," IEEE Trans. on IA, Vol. 30, No. 5, pp. 1234-1240, 1994.
- [13] H. Kubota and K. Matsuse, "Speed sensorless field oriented control of induction motor with rotor resistance adaption," IEEE Trans. on IA, Vol. 30, No. 5, pp. 1219-1224, 1994.

**최정식(崔正植)**

1980년 2월 9일생. 2005년 순천대 전기제어공학과 졸업. 2005년 현재 동 대학원 전기공학과 석사과정.

**정동화(鄭東和)**

1955년 8월 15일생. 1979년 영남대 공대 전기공학과 졸업. 1981년 한양대 대학원 전기공학과 졸업(석사). 1987년 동 대학원 전기공학과 졸업(공박). 1988년~1989년 현대중전기(주) 기술연구소 책임연구원. 1989년~현재 순천대 전기전자정보통신공학부 교수.

저자 소개

**남수명(南守明)**

1979년 2월 18일생. 2004년 순천대 전기제어공학과 졸업. 2004년~현재 동 대학원 전기공학과 석사과정.