

# SynRM 드라이브의 고성능 제어를 위한 RFNN 제어기 설계

(Design of RFNN Controller for high performance Control of SynRM Drive)

고재섭\* · 정동화\*\*

(Jae-Sub Ko · Dong-Hwa Chung)

## Abstract

Since the fuzzy neural network(FNN) is universal approximators, the development of FNN control systems have also grown rapidly to deal with non-linearities and uncertainties. However, the major drawback of the existing FNNs is that their processor is limited to static problems due to their feedforward network structure. This paper proposes the recurrent FNN(RFNN) for high performance and robust control of SynRM. RFNN is applied to speed controller for SynRM drive and model reference adaptive fuzzy controller(MFC) that combine adaptive fuzzy learning controller(AFLC) and fuzzy logic control(FLC), is applied to current controller. Also, this paper proposes speed estimation algorithm using artificial neural network(ANN). The proposed method is analyzed and compared to conventional PI and FNN controller in various operating condition such as parameter variation, steady and transient states etc.

Key Words : SynRM Drive, RFNN, MFC, ANN, Speed Control

## 1. 서 론

최근, 전 세계적으로 환경문제의 인식이 높아지고 에너지 및 자원의 절약이 요구되면서 가변속 드라이브에 대한 관심이 고조되고 있다. 전력용 반도체의 진보, 마이크로프로세서 및 DSP의 응용으로 가변속 드라이브에 대한 연구는 한층 박차를 가하게 되었다.

SynRM(Synchronous Reluctance Motor) 드라이브

는 냉장고, 에어컨 등의 가전용에서 공작기계, 펌프, 등 산업용에 이르기까지 핵심 전력전자 기기로 응용되고 있다. SynRM은 전력전자 기술의 발전으로 브러시 없는 교류 가변속 드라이브로서의 적용이 가능하게 되었다. SynRM은 표준형 유도전동기의 고정자 구조로 설계되었으며 정현파 회전자계를 발생하므로 유연한 토크특성 및 안정된 운전을 실현할 수 있다. 최근에는 SynRM이 고가의 PM 전동기 및 제어가 복잡한 유도전동기를 대체할 수 있는 가변속 드라이브로 각광을 받고 있으며 이에 관한 연구가 활발히 이루어지고 있다[1-6]. SynRM의 고성능 드라이브는 동적 특성에서 다양한 속도 추정능력, 부하 변화에 적응하여 조절할 수 있는 양호한 응답특성, 드라이브와 부하

\* 주저자 : 순천대학교 전기제어공학과  
\*\* 교신저자 : 순천대학교 전기제어공학과  
Tel : 061-750-3543, Fax : 061-752-1103  
E-mail : hwa777@sunchon.ac.kr  
접수일자 : 2011년 2월 28일  
1차심사 : 2011년 7월 7일, 2차심사 : 2011년 7월 22일  
심사완료 : 2011년 8월 17일

파라미터의 변동에도 강인한 성능이 요구된다. 이러한 시스템에 양호한 성능을 얻기 위한 연구로 적응제어가 연구되었으며 적응제어는 종래의 PI제어기에 비해 매우 양호한 성능을 얻을 수 있다. 최근 적응제어는 STC(Self Tuning Control), MRAC(Model Reference Adaptive Control), SMC(Sliding Mode Control) 및 EKF(Extended Kalman Filter) 등의 다양한 기법들이 제시되었다[7]. 이러한 적응제어 기법은 수학적 모델링에 기초를 두고 있으며 다량의 알고리즘 때문에 매우 복잡하다.

최근 전문가 시스템, 퍼지제어 및 신경회로망을 이용한 지능제어는 전력전자 시스템의 성능을 향상시킬 수 있는 주요한 툴로서 인식되고 있다. 적응제어와 강인성제어를 지능제어와 상호 결합한 형태는 드라이브 분야에서 가장 유망한 연구 성과로 나타나고 있다. 이는 적응성 및 강인성이 요구되는 교류전동기 드라이브에서 지능제어의 특성 및 실제적 구현이 최적화의 개발을 위한 최고의 연구로 각광을 받고 있기 때문이다[8]-[11]. 동적 시스템의 인식과 제어를 위해 NN(Neural Network)에 대한 적용이 이루어지고 있으나 NN은 동적 응답을 나타내기 위하여 많은 수의 뉴런을 필요로 하며, 가중치 업데이트 시 내부 정보를 이용할 수 없으며 함수 근사화는 학습 데이터에 민감하다. 퍼지와 NN을 혼합 적용한 FNN은 피드백 네트워크 구조 때문에 정적인 문제에 한정되는 단점이 있다.

본 논문에서는 더욱 향상된 속도 제어를 위해 RFNN(Recurrent FNN) 제어기를 설계한다. 4층의 신경회로망으로 구성된 RFNN은 내부적으로 피드백 특성을 갖고 있어 시스템의 동적 성능이 우수하다. 또한 학습 단계에서 퍼지 룰을 이용하여 강인한 제어를 할 수 있다. 그리고 RFNN 속도 제어기에서 출력된 전류를 제어하는 전류 제어기인 MFC(Model Reference Adaptive Fuzzy Controller)를 설계하고 속도추정의 양호한 응답특성을 얻기 위하여 ANN(Artificial Neural Network)을 혼합한다. RFNN을 이용한 SynRM 드라이브의 효용성을 입증하기 위해서 시스템을 구성하고 시뮬레이션을 통해 제어특성을 분석한다. 또한 각 제어기의 응답특성을 구하고 응답특성을

분석한다. 본 논문에서 제시한 제어기를 종래의 제어기와 응답특성을 비교하여 타당성을 입증하고 그 결과를 제시한다.

## 2. SynRM 드라이브 시스템

SynRM의 이상적인 등가회로는 그림 1과 같다.




그림 1. SynRM의 등가회로  
Fig. 1. Equivalent circuit of SynRM

이 등가회로에 의한 전압방정식은 다음과 같다.

$$V_d = R_s i_d + L_d \frac{d}{dt} i_d - \omega_r L_q i_q \quad (1)$$

$$V_q = R_s i_q + L_q \frac{d}{dt} i_q + \omega_r L_d i_d \quad (2)$$

SynRM의 토크는 다음과 같다.

$$T_e = \frac{3P}{2} (L_d - L_q) i_d i_q \quad (3)$$

식 (3)을 다시 표현하면 다음과 같다.

$$T_e = \frac{3P}{2} L_d (1 - L_q / L_d) i_d i_q \quad (4)$$

## 3. RFNN 제어기 설계

종래의 FNN 제어기는 퍼지 제어와 신경회로망을

혼합 구성하며 강력한 표현의 유연성과 수치 처리 능력을 가지고 있다. 그러나 FNN은 정적인 방법으로 학습 데이터와 조건에 민감하고 가중치 업데이트 경우 NN의 내부 정보를 이용할 수 없는 단점이 있다. 본 논문에서 제시한 RFNN은 내부에 피드백 루프를 구성하고 뉴런을 통해 나온 NN의 가중치를 지연시켜 순환하여 외부의 피드백을 사용하지 않고 시스템의 동적 응답을 확인한다. 제시한 RFNN 속도 제어기를 이용한 SynRM의 전체 시스템은 그림 2와 같다. 지령속도와 추정속도의 오차를 제시한 RFNN 속도 제어기에 입력하여  $i_q^*$ 를 출력한다.

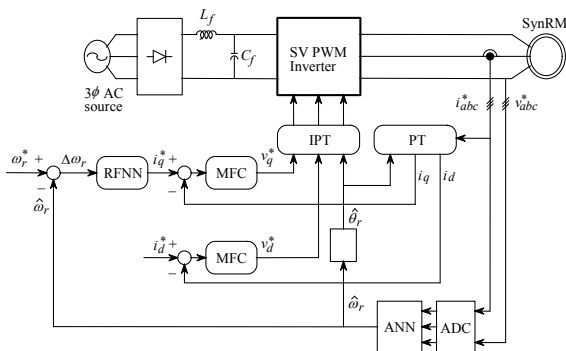


그림 2. RFNN을 이용한 SynRM의 속도제어 시스템  
Fig. 2. Speed control system of SynRM using RFNN

출력된  $i_q^*$ 를 전류 제어기인 MFC에 입력하여  $v_q^*$ 를 출력하고 출력된  $v_q^*$ 를 역변환하여 SV PWM 인버터를 통해 SynRM을 제어한다. 또한 속도 센서리스 제어를 위하여 ANN을 이용해 속도를 추정한다.

그림 3은 RFNN의 제어 시스템 구성을 나타낸다. 여기서 두 개의 입력변수는 오차  $e$ 와 오차 변화분  $ce$ 이고 출력은  $i_q^*$ 이다.




그림 3. RFNN 속도제어기  
Fig. 3. RFNN speed controller

### 3.1 RFNN 구조

그림 4는 RFNN의 원리를 설명하는 그림으로 4층의 RFNN의 구조를 가지고 있으며, 입력층, 멤버쉽층, 규칙층 및 출력층으로 구성되어 있다.




그림 4. 4층의 RFNN 구조  
Fig. 4. Structure of the four-layer RFNN

1층(입력층) : 1층의 모든 노드  $i$ 에 대해 입력망과 출력망은 다음과 같다.

$$net_i^1(N) = \prod_0 x_i^1(N) w_{oi} y_o^1(N-1) \tag{5}$$

$$y_i^1(N) = f_i^1(net_i^1(N)) = net_i^1(N), i = 1, 2 \tag{6}$$

여기서,  $x_i^1$ 는 1층의  $i$ 번째 입력 노드,  $N$ 은 반복횟수,  $w_{oi}$ 는 출력층의 출력값 순환 가중치,  $y_o^1$ 는 RFNN의 출력이다.

2층(멤버쉽층) : 이 층에서 각 노드는 멤버쉽 함수 기능을 수행하며 가우시안 함수를 멤버쉽 함수로 선정한다.  $j$ 번째 노드에 대해 입력망과 출력망은 다음과 같다.

$$net_j^2(N) = -\frac{(x_i^1 - m_{ij})^2}{(\sigma_{ij})^2} \tag{7}$$

$$y_i^2(N) = f_i^2(net_i^2(N)) = \exp(net_i^2(N)), j = 1, \dots, n \tag{8}$$

$m_{ij}$ 와  $\sigma_{ij}$ 는 2층의 노드에 대해  $i$ 번째 입력언어변수  $x_i^2$ 의  $j$ 번째 항에서의 가우시안 함수의 평균과 표준 편차,  $n$ 은 언어변수의 전체 수를 나타낸다.

3층(물층) : 이 층에서 각 노드는  $\prod$ 로 나타낸다.  $\prod$ 는 입력과 출력 결과의 곱을 나타낸다.  $k$ 번째 규칙 노드에 대해 입력망과 출력망은 다음과 같다.

$$net_k^3(N) = \prod_j w_{jk}^3 x_j^3(N) \quad (9)$$

$$y_k^3(N) = f_k^3(net_k^3(N)) = net_k^3(N) \quad k=1, \dots, l \quad (10)$$

$x_j^3$ 는 3층 노드의  $j$ 번째 입력 노드,  $w_{jk}^3$ 는 멤버쉽층과 규칙층 사이의 가중치,  $l=(n/i)$ 는 각 입력노드가 같은 변수일 경우 완벽한 물 결합수를 나타낸다.

4층(출력층) : 이 층의 단일 노드  $o$ 는  $\sum$ 로 표시되며 모든 입력의 합을 계산한다.

$$net_o^4(N) = \sum_k w_{ko}^4 x_k^4(N) \quad (11)$$

$$y_o^4(N) = f_o^4(net_o^4(N)) = net_o^4(N), \quad o=1 \quad (12)$$

$w_{ko}^4$ 은  $k$ 번째 규칙과 연관된  $o$ 번째 출력의 가중치를 나타내고,  $x_k^4$ 는 4층 노드의  $k$ 번째 입력을 나타낸다.

### 3.2 온라인 파라미터 학습

기울기 강하법을 이용하여 RFNN의 온라인 학습을 위한 오차함수는 다음과 같이 정의한다.

$$E = \frac{1}{2}(\omega_r^* - \omega_r)^2 = \frac{1}{2}e_m^2 \quad (13)$$

여기서,  $\omega_r^*$ 은 지령 속도,  $\omega_r$ 은 실제 속도,  $e_m = \omega_r^* - \omega_r$ 를 나타낸다.

역전과 방법에 의한 학습 알고리즘은 다음과 같다.

4층(출력층) : 오차항과 가중치 갱신 규칙은 다음과 같다.

$$\delta_o^4 = -\frac{\partial E}{\partial net_o^4} = \left[ -\frac{\partial E}{\partial e_m} \frac{\partial e_m}{\partial y} \frac{\partial y}{\partial y_o^4} \frac{\partial y_o^4}{\partial net_o^4} \right] \quad (14)$$

$$\Delta w_{ko}^4 = -\eta_w \frac{\partial E}{\partial w_{ko}^4} = \left[ -\eta_w \frac{\partial E}{\partial y_o^4} \frac{\partial y_o^4}{\partial net_o^4} \right] \left( \frac{\partial net_o^4}{\partial w_{ko}^4} \right) = \eta_w \delta_o^4 x_k^4 \quad (15)$$

여기서,  $\eta_w$ 는 연결가중치 학습율이다.

$$w_{ko}^4(N+1) = w_{ko}^4(N) + \Delta w_{ko}^4 \quad (16)$$

3층(규칙층) : 이 층의 가중치는 1이므로 오차항만 계산한다.

$$\delta_k^3 = -\frac{\partial E}{\partial net_k^3} = \left[ -\frac{\partial E}{\partial y_o^4} \frac{\partial y_o^4}{\partial net_o^4} \right] \left( \frac{\partial net_o^4}{\partial y_k^3} \frac{\partial y_k^3}{\partial net_k^3} \right) = \delta_o^4 w_{ko}^4 \quad (17)$$

2층(멤버쉽층) : 이 층에서는 곱셈 연산이 이루어지며, 오차항은 다음과 같다.

$$\delta_j^2 = -\frac{\partial E}{\partial net_j^2} = \left[ -\frac{\partial E}{\partial y_o^4} \frac{\partial y_o^4}{\partial net_o^4} \frac{\partial net_o^4}{\partial y_k^3} \frac{\partial y_k^3}{\partial net_k^3} \right] \left[ \frac{\partial net_k^3}{\partial y_j^2} \frac{\partial y_j^2}{\partial net_j^2} \right] = \sum_k \delta_k^3 y_k^3 \quad (18)$$

그리고  $m_{ij}$ 와  $\sigma_{ij}$ 의 갱신 규칙은 다음과 같다.

$$\begin{aligned} \Delta m_{ij} &= -\eta_m \frac{\partial E}{\partial m_{ij}} = \left[ -\eta_m \frac{\partial E}{\partial y_j^2} \frac{\partial y_j^2}{\partial net_j^2} \frac{\partial net_j^2}{\partial m_{ij}} \right] \\ &= \eta_m \delta_j^2 \frac{2(x_i^2 - m_{ij})}{(\sigma_{ij})^2} \quad (19) \end{aligned}$$

여기서,  $\eta_m$ 은 가우시안 함수의 평균에 대한 학습율이다.

$$m_{ij}(N+1) = m_{ij}(N) + \Delta m_{ij} \quad (20)$$

$$\begin{aligned} \Delta \sigma_{ij} &= -\eta_\sigma \frac{\partial E}{\partial \sigma_{ij}} = \left[ -\eta_\sigma \frac{\partial E}{\partial y_j^2} \frac{\partial y_j^2}{\partial net_j^2} \frac{\partial net_j^2}{\partial \sigma_{ij}} \right] \\ &= \eta_\sigma \delta_j^2 \frac{2(x_i^2 - m_{ij})^2}{(\sigma_{ij})^3} \quad (21) \end{aligned}$$

여기서,  $\eta_\sigma$ 는 가우시안 함수의 표준편차에 대한 학습율이다.

$$\sigma_{ij}(N+1) = \sigma_{ij}(N) + \Delta\sigma_{ij} \quad (22)$$

순환 가중치  $w_{oi}$ 의 갱신 규칙은 다음과 같다.

$$\begin{aligned} \Delta w_{oi} &= -\eta_r \frac{\partial E}{\partial w_{oi}} = \left[ -\eta_r \frac{\partial E}{\partial net_j^2} \frac{\partial net_j^2}{\partial y_i^1} \frac{\partial y_i^1}{\partial net_i^1} \frac{\partial net_i^1}{\partial w_{oi}} \right] \\ &= \sum_j \eta_r \delta_j^2 \frac{2(m_{ij} - x_i^2(N))}{(\sigma_{ij})^2} x_i^1(N) y_o^A(N-1) \end{aligned} \quad (23)$$

$\eta_r$ 은 순환 가중치 학습율이며 순환 가중치는 다음과 같이 업데이트 된다.

$$w_{oi}(N+1) = w_{oi}(N) + \Delta w_{oi} \quad (24)$$

#### 4. MFC 전류 제어기 설계

종래의 FLC는 고정된 파라미터를 사용하므로 동작 조건이 광범위하게 변화하는 적용분야에는 만족할만한 성능을 발휘할 수 없다. 다양한 동작조건 변화에도 적용할 수 있는 MFC가 필요하다. 종래의 적응 제어기인 STC(Self Tuning Controller), MRAC(Model Reference Adaptive Controller) 및 EKF(Extended Kalman Filter) 등은 매우 양호한 성능을 얻을 수 있다. 그러나 다량의 계산 알고리즘 때문에 복잡하고 수학적인 모델링과 시스템의 구현에 기초한다. 퍼지논리를 이용한 적응제어 시스템은 종래의 적응 시스템과 유사한 방법을 사용하여 설계가 가능하다.

AFC(Adaptive Fuzzy Controller)는 퍼지추론을 사용하여 구현할 수 있는 적응 메카니즘으로 구성된다. 퍼지적응 알고리즘은 수학적인 처리가 필요하지 않으므로 매우 간단하다.

그림 5은 기준모델에 의한 AFM(Adaptive Fuzzy Mechanism)을 나타낸다. AFM을 포함하는 시스템을 AFC라고 한다.




그림 5. 기준모델에 의한 AFC  
Fig. 5. AFC with reference model

그림 6은 두 개의 퍼지동작의 상호작용을 나타내며 FLC는 종래의 일반적인 퍼지제어기이고 AFC는 기준 모델을 고려한 적응 퍼지제어기를 나타낸다.




그림 6. MFC의 설계  
Fig. 6. Design of MFC

FLC 알고리즘에 의한 출력은  $\Delta v_{qds1}^*(k)$ 이며 AFC에 의한 출력은  $\Delta v_{qds2}^*(k)$ 이다. 이 두 출력을 합하여 적분기를 통해 지령  $q$ 축 전압을 얻는다. AFC는 기준모델을 사용하여 그림 6에서 전류의 출력  $i_{qds}(k)$ 는 기준모델의 출력  $i_m(k)$ 와 비교하여 오차  $ei_m(k)$ 는 AFC에 의해 수행된다.

기준모델은 안정화 시간 및 오버슈트와 같은 설계기준을 만족하는 요구성능을 충족시키기 위하여 사용하며 1차 시스템을 사용한다. AFC에 의한 출력은  $\Delta v_{qds2}^*(k)$ 를 발생시킨다.  $\Delta v_{qds1}^*(k)$ 과  $\Delta v_{qds2}^*(k)$ 를 합하여  $\Delta v_{qds}^*(k)$ 를 구하여 이를 적분기를 통해  $v_{qds}^*(k)$ 를 발생시켜 SV PWM 인버터에 인가한다.

AFC의 입력은 기준모델의 출력과 실제전류의 오차와 오차 변화분을 사용한다. 오차와 오차의 변화분은 다음과 같다.

$$ei_m(k) = i_m(k) - i_{qds}(k) \quad (25)$$

$$cei_m(k) = ei_m(k) - ei_m(k-1) \quad (26)$$

위의 두 입력은 적응 퍼지의 룰 베이스에 의해 지령  $q$ 축 전압에 보상되는  $\Delta v_{qds2}^*(k)$ 가 발생된다. 여기서  $i_m(k)$ 는 기준모델에 의한 지령전류이며  $i_{qds}(k)$ 는 실제 전류이다.

FLC의 출력에서  $\Delta v_{qds1}^*(k)$ 를 얻어 AFC의  $\Delta v_{qds2}^*(k)$ 와 합하면 퍼지제어기의 지령  $d-q$ 축 전압을 얻을 수 있다.

$$v_{qds}^*(k) = v_{qds}^*(k-1) + [\Delta v_{qds1}^*(k) + \Delta v_{qds2}^*(k)] \quad (28)$$

### 5. ANN에 의한 속도 추정

ANN(Artificial Neural Network)은 인간 두뇌의 간단한 모델에 의해 사고하는 구조로 된 컴퓨팅 시스템이다. ANN은 비선형 동적 시스템의 파라미터를 추정 및 제어를 하는데 사용된다. 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.

$$y(k+1) = f(y(k), \dots, y(k-d_y), u(k), \dots, u(k-d_u)) \quad (29)$$

여기서  $d_u$ 와  $d_y$ 는 입력과 출력 벡터  $u$ 와  $y$ 에서 최대 지연을 나타낸다. 이 모델의 형태는 모델이 전적으로 기지 양으로 표현되기 때문에 시스템의 추정을 추구하는데 이상적이다. 그림 7은 ANN을 이용한 시스템의 추정을 나타낸다. ANN은 시스템의 NARMAX 모델을 추정하는데 사용하며 이를 위해 식 (29)에서 필요한 입력과 예측 출력벡터  $\hat{y}(k+1)$ 로서 ANN의 출




그림 7. ANN을 이용한 시스템 추정  
Fig. 7. System estimation using ANN

력을 구성한다. 시간  $k+1$ 에서 예측 출력벡터를 실제 출력벡터와 비교하여 식 (29)에서 함수  $f(\cdot)$ 를 에뮬레이트하기 위하여 학습한다. 그리고 오차 역전파 알고리즘에 의해 ANN 하층을 새롭게 하기 위하여 오차를 사용한다.

ANN을 이용한 시스템의 추정에서 구한 최종 추정 속도는 다음 식과 같다.

$$\begin{aligned} \hat{\omega}_r(k+1) &= \hat{\omega}_r(k) + \Delta \hat{\omega}_r(k) \\ &= \hat{\omega}_r(k) + \frac{\Delta W_2(k)}{T} \\ &= \hat{\omega}_r(k) + \frac{\eta}{T} \{ [\hat{\phi}_{qr}(k) - \hat{\phi}_{qr}(k-1)] \hat{\phi}_{dr}(k-1) \\ &\quad - [\hat{\phi}_{dr}(k) - \hat{\phi}_{dr}(k-1)] \hat{\phi}_{qr}(k-1) + \frac{\alpha}{T} \Delta W_2(k-1) \end{aligned} \quad (30)$$

여기서  $T$ 는 샘플링 주기를 나타내며  $\eta$ 는 학습계수이며 학습과정에서 학습율을 나타낸다. 계수  $\alpha$ 는 현재 하층에서 변동하는 과거 하층의 영향을 결정한다. 추정속도를 이용한 회전자 자극의 위치는 다음과 같다.

$$\hat{\theta}_r(k+1) = \hat{\theta}_r(k) + T \cdot \hat{\omega}_r(k) \quad (31)$$

### 6. 시스템 성능결과

본 논문에서 사용한 SynRM의 파라미터는 표 1과 같으며 샘플링 시간은  $10[\mu\text{sec}]$ 로 하였다.

표 1. SynRM의 파라미터  
Table 1. Parameter of SynRM

정격 용량	3.75[kW]
정격 전압	220[V]
정격 토크	19.8[N·m]
정격 주파수	60[Hz]
극 수	4
고정자 저항 $R_s$	0.238[Ω]
$d$ 축 인덕턴스 $L_d$	43[mH]
$q$ 축 인덕턴스 $L_q$	3.5[mH]
관성계수 $J_n$	0.026[kg·m <sup>2</sup> ]

표 2~6은 종래의 FNN 제어기의 룰베이스 변화를 나타낸다. FNN 제어기는 제어를 수행한 후에 수정된 룰 베이스를 초기상태로 되돌리기 때문에 현재 상태에 사용된 룰 베이스 값 하나만 변화하게 된다.

표 7~11은 본 논문에서 제시한 RFNN 제어기의 룰베이스 변화를 나타낸다. RFNN 제어기는 수정된 룰 베이스 값을 계속 유지하고 다음 동작상태에 따라서 변화되기 때문에 다수의 룰베이스 값이 변화하게 된다.

표 2. 속도 제어기를 위한 룰 베이스(FNN)  
Table 2. Rule base for speed controller(FNN)

cc \ e	NB	NM	NS	Z	PS	PM	PB
NB	NL	NL	NL	NM	NM	NS	ZE
NM	NL	NL	NM	NM	NS	ZE	PS
NS	NL	NM	NM	NL	ZE	PS	PM
Z	NM	NM	NS	ZE	PS	PM	PM
PS	NM	NS	ZE	PS	PM	PM	PL
PM	NS	ZE	PS	PM	PM	PL	PL
PB	ZE	PS	PM	PM	PL	PL	PL

표 3. 0.28 [sec]에서 룰 베이스(FNN)  
Table 3. Rule base at 0.28 [sec](FNN)

cc \ e	NB	NM	NS	Z	PS	PM	PB
NB	NL	NL	NL	NM	NM	NS	ZE
NM	NL	NL	NM	NM	NS	ZE	PS
NS	NL	NM	NM	NL	ZE	PS	PM
Z	NM	NM	NS	ZE	PS	PM	PM
PS	NM	NS	ZE	PS	PM	PM	PL
PM	NS	ZE	PS	PM	PM	PL	PL
PB	ZE	<b>PM</b>	PM	PM	PL	PL	PL

표 4. 0.31 [sec]에서 룰 베이스(FNN)  
Table 4. Rule base at 0.31 [sec](FNN)

cc \ e	NB	NM	NS	Z	PS	PM	PB
NB	NL	NL	NL	NM	NM	NS	ZE
NM	NL	NL	NM	NM	NS	ZE	PS
NS	NL	NM	NM	NL	<b>NS</b>	PS	PM
Z	NM	NM	NS	ZE	PS	PM	PM
PS	NM	NS	ZE	PS	PM	PM	PL
PM	NS	ZE	PS	PM	PM	PL	PL
PB	ZE	PS	PM	PM	PL	PL	PL

표 5. 0.33 [sec]에서 룰 베이스(FNN)  
Table 5. Rule base at 0.33 [sec](FNN)

cc \ e	NB	NM	NS	Z	PS	PM	PB
NB	NL	NL	NL	NM	NM	NS	ZE
NM	NL	NL	NM	NM	NS	ZE	PS
NS	NL	NM	NM	NL	ZE	PS	PM
Z	NM	NM	NS	<b>PS</b>	PS	PM	PM
PS	NM	NS	ZE	PS	PM	PM	PL
PM	NS	ZE	PS	PM	PM	PL	PL
PB	ZE	PS	PM	PM	PL	PL	PL

표 6. 0.35 [sec]에서 룰 베이스(FNN)  
Table 6. Rule base at 0.35 [sec](FNN)

cc \ e	NB	NM	NS	Z	PS	PM	PB
NB	NL	NL	NL	NM	NM	NS	ZE
NM	NL	NL	NM	NM	NS	ZE	PS
NS	NL	NM	NM	NL	ZE	PS	PM
Z	NM	NM	NS	ZE	<b>ZE</b>	PM	PM
PS	NM	NS	ZE	PS	PM	PM	PL
PM	NS	ZE	PS	PM	PM	PL	PL
PB	ZE	PS	PM	PM	PL	PL	PL

표 7. 속도 제어기를 위한 룰 베이스(RFNN)  
Table 7. Rule base for speed controller(RFNN)

cc \ e	NB	NM	NS	Z	PS	PM	PB
NB	NL	NL	NL	NM	NM	NS	ZE
NM	NL	NL	NM	NM	NS	ZE	PS
NS	NL	NM	NM	NL	ZE	PS	PM
Z	NM	NM	NS	ZE	PS	PM	PM
PS	NM	NS	ZE	PS	PM	PM	PL
PM	NS	ZE	PS	PM	PM	PL	PL
PB	ZE	PS	PM	PM	PL	PL	PL

표 8. 0.28 [sec]에서 룰 베이스(RFNN)  
Table 8. Rule base at 0.28 [sec](RFNN)

cc \ e	NB	NM	NS	Z	PS	PM	PB
NB	NL	NL	NL	<b>NL</b>	<b>NL</b>	<b>NM</b>	ZE
NM	NL	NL	<b>NL</b>	<b>NL</b>	<b>NM</b>	ZE	PS
NS	NL	<b>NL</b>	<b>NL</b>	<b>NS</b>	<b>PM</b>	PS	PM
Z	<b>NL</b>	<b>NL</b>	<b>NM</b>	ZE	PS	PM	PM
PS	<b>NL</b>	<b>NM</b>	ZE	PS	PM	PM	PL
PM	<b>NM</b>	ZE	PS	PM	PM	PL	PL
PB	ZE	<b>PM</b>	<b>PL</b>	PM	PL	PL	PL

표 9. 0.31 [sec]에서 룰 베이스(RFNN)  
Table 9. Rule base at 0.31 [sec](RFNN)

ce \ e	NB	NM	NS	Z	PS	PM	PB
NB	NL	NL	NL	NL	NL	NM	ZE
NM	NL	NL	NL	NL	NM	ZE	PS
NS	NL	NL	NL	NM	PS	PS	PM
Z	NL	NL	NM	PS	PM	PM	PM
PS	NL	NM	ZE	PS	PM	PM	PL
PM	NM	ZE	PS	PM	PM	PL	PL
PB	ZE	PM	PL	PM	PL	PL	PL

표 10. 0.33 [sec]에서 룰 베이스(RFNN)  
Table 10. Rule base at 0.33 [sec](RFNN)

ce \ e	NB	NM	NS	Z	PS	PM	PB
NB	NL	NL	NL	NL	NL	NM	ZE
NM	NL	NL	NL	NL	NM	ZE	PS
NS	NL	NL	NL	NM	PS	PS	PM
Z	NL	NL	PS	NS	PM	PM	PM
PS	NL	NM	ZE	PS	PM	PM	PL
PM	NM	ZE	PS	PM	PM	PL	PL
PB	ZE	PM	PL	PM	PL	PL	PL

표 11. 0.35 [sec]에서 룰 베이스(RFNN)  
Table 11. Rule base at 0.35 [sec](RFNN)

ce \ e	NB	NM	NS	Z	PS	PM	PB
NB	NL	NL	NL	NL	NL	NM	ZE
NM	NL	NL	NL	NL	NM	ZE	PS
NS	NL	NL	NL	NM	PS	PS	PM
Z	NL	NL	ZE	NS	PM	PM	PM
PS	NL	NM	ZE	PS	PL	PM	PL
PM	NM	ZE	PS	PM	PM	PL	PL
PB	ZE	PM	PL	PM	PL	PL	PL

그림 8은 지령속도를 0.1 [sec]에 1,800 [rpm]으로 운전 중, 0.4 [sec]에서 부하 토크를 5[N·m]인가한 후 운전하다가 다시 지령속도를 0.8 [sec]에 1,000 [rpm]으로 속도변화를 주었을 경우의 속도 응답특성을 나타낸다. 그림 8 (a)은 FLC 지령속도와 속도를 나타내고, 그림 8 (b)은 종래의 FNN 지령속도와 속도, 그림 8 (c)은 본 논문에서 제시한 RFNN의 지령속도와 속도를 나타낸다. 그림 8 (d)은  $q$ 축 전류, 그림 8 (e)은  $d$ 축 전류, 그림 8 (f)은 발생토크를 나타낸다. 그림 9

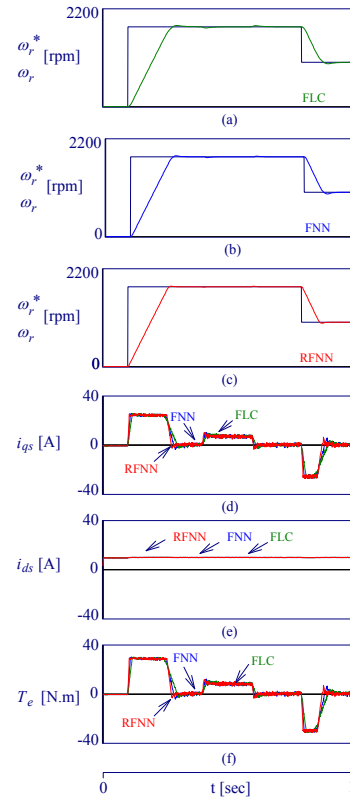


그림 8. 지령속도 및 부하 변화에 대한 응답특성  
Fig. 8. The response characteristics with command speed and load torque variation

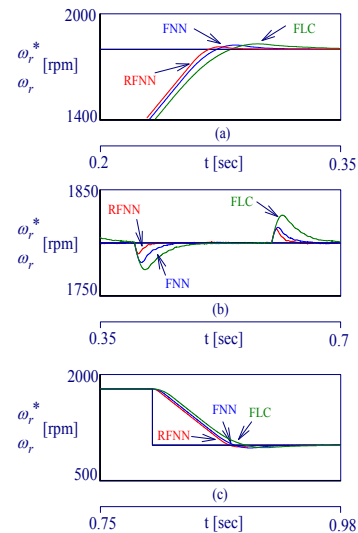


그림 9. 지령속도 및 부하 변화에 대한 응답특성 (그림 9 확대)  
Fig. 9. The response characteristics with command speed and load torque variation



는 그림 8의 속도 상승 부분과 부하토크 변화부분 및 속도 하강 부분을 확대한 그림이다. 본 논문에서 제시한 RFNN 제어기가 속도 상승시와 하강시에 종래의 FNN, FLC 제어기에 비해 오버슈트가 적고 정상상태에 빠르게 도달하고 있음을 알 수 있으며, 부하인가에 대한 속도변화도 양호하게 나타나고 있다.

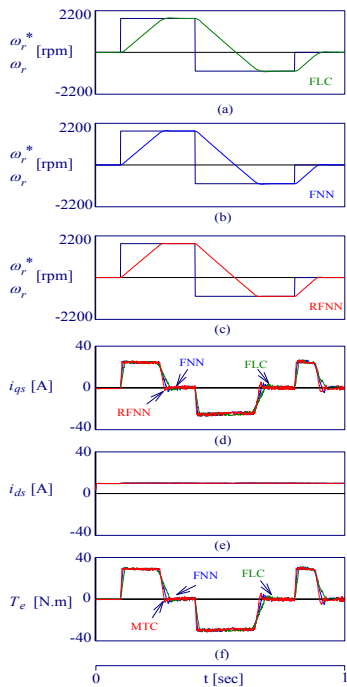


그림 10. 정·역 운전에 대한 응답특성 비교  
 Fig. 10. The comparison of response characteristics with forward and reserve operating

그림 10은 무부하 상태로 정·역 운전시 속도 응답 특성을 나타낸다. 그림 10 (a)은 FLC의 지령속도와 속도를 나타내고, 10 (b)은 FNN 지령속도와 속도, 그림 10 (c)은 RFNN 지령속도와 속도를 나타낸다. 그림 10 (d)은  $q$ 축 전류, 그림 10 (e)은  $d$ 축 전류, 그림 10 (f)은 발생토크를 나타낸다. 지령속도를 정·역으로 속도 변화를 주었을 경우에도 본 논문에서 제시한 RFNN 제어기가 FLC, FNN 제어기에 비하여 오버슈트가 작고 안정화 시간이 빠르게 나타나고 있어 우수한 응답특성을 나타낸다.

그림 11은 4상한 운전시 응답특성을 나타낸다. 그림 11 (a)는 FLC 제어기, 그림 11 (b)는 FNN 제어기, 그

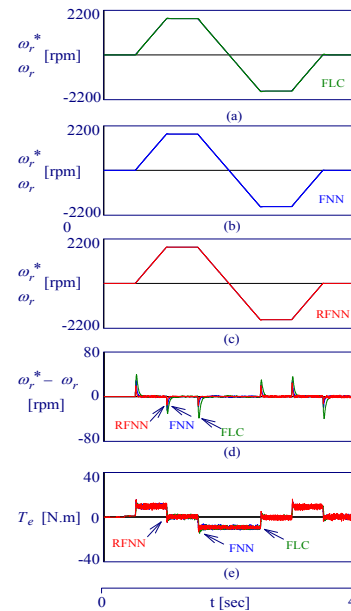


그림 11. 4상한 운전에 대한 응답특성 비교  
 Fig. 11. The comparison of response characteristics with quadrant drive

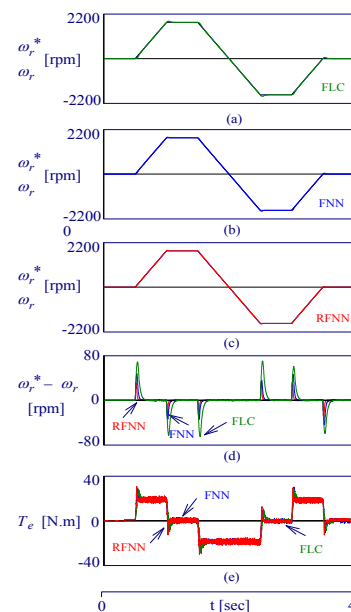


그림 12. 4상한 운전에 대한 응답특성 비교 ( $J_n = 2J_n$ )  
 Fig. 12. The comparison of response characteristics with quadrant drive ( $J_n = 2J_n$ )

림 11 (c)는 RFNN 제어기이다. 그림 11 (d)는 지령속도와 실제속도의 오차를 나타내며, 그림 11 (e)는 발생

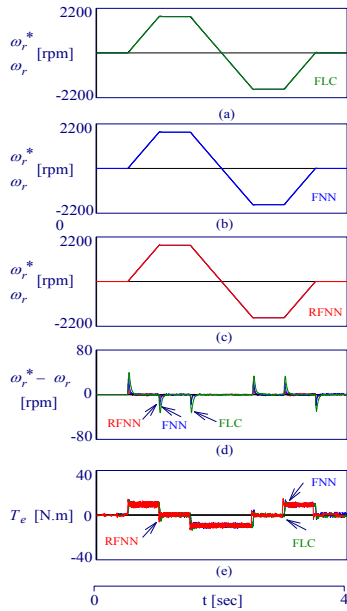


그림 13. 4상한 운전에 대한 응답특성 비교 ( $R_s = 2R_s$ )  
 Fig. 13. The comparison of response characteristics with quadrant drive ( $R_s = 2R_s$ )




그림 14. PI 제어기에 의한 전류제어 응답특성  
 Fig. 14. The current control response characteristics by PI controller

토크를 나타낸다. 그림 11 (d)에서 RFNN 제어기의 속도오차가 FLC 및 FNN 제어기에 비하여 작게 나타나

고 있다.

그림 12는 관성을 2배, 그림 13은 저항을 2배 변화시켜 4상한 운전을 한 응답특성을 나타낸다. 본 논문에서 제시한 RFNN 제어기가 FLC 및 FNN 제어기에 비하여 속도오차가 작게 나타나고 있어 파라미터가 변동한 경우에도 더욱 우수한 응답특성을 나타낸다.

그림 14와 15는 전류 응답특성을 나타낸다. 그림 14는 PI 제어기에 의한 전류제어 응답특성을 나타낸다. 그림 14 (a)은 지령속도와 추정속도, 그림 14 (b)은 지령 a상 전류, 그림 14 (c)은 실제 a상 전류, 그림 14 (d)은 전류오차, 그림 14 (e)은 스위칭 시간을 나타낸다. 그림 15는 본 논문에서 제시한 MFC 제어기에 의한 전류제어 응답특성을 나타낸다. 그림 15 (a)은 지령속도와 추정속도, 그림 15 (b)은 지령 a상 전류, 그림 15 (c)은 실제 a상 전류, 그림 15 (d)은 전류오차, 그림 15 (e)은 스위칭 시간을 나타낸다. 그림 14 (d)과 그림 15 (d)의 전류 오차를 비교해보면 본 논문에서 제시한 MFC 제어기에 의한 전류 오차가 PI 제어기의 전류오차보다 작게 나타난다.

그림 16은 지령속도를 0.1 [sec]에 100 [rpm], 0.5 [sec]에 -100 [rpm], 0.8 [sec]에 1500 [rpm], 1.4 [sec]

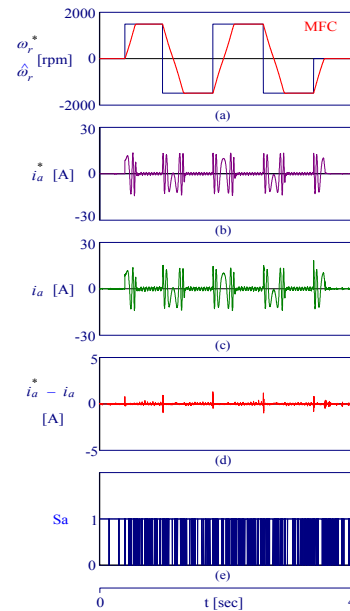


그림 15. MFC 제어기에 의한 전류제어 응답특성  
 Fig. 15. The current control response characteristics by MFC controller

에 -1500 [rpm]으로 변화시켰을 경우 ANN에 의한 속도추정의 응답특성을 나타낸다. 그림 16 (a)은 지령속도와 실제속도, 그림 16 (b)은 지령속도와 추정속도, 그림 16 (c)은 실제속도와 추정속도의 오차를 나타낸다. 그림 16 (c)의 속도오차가 1 [%] 이하로 매우 양호하게 속도를 추정하고 있다.




그림 16. ANN에 의한 속도추정 응답특성  
Fig. 16. The response characteristics with speed estimation by ANN

## 7. 결 론


본 논문에서는 SynRM 드라이브의 고성능 제어를 위하여 순환 신경회로망과 퍼지를 결합한 RFNN을 제시하였다. 제시한 RFNN 제어기는 신경회로망의 물층에서 수정된 룰베이스 값을 계속 보관하고 있기 때문에 지령 속도 변화와 부하 변화에 대하여 종래의 FLC 제어기와 FNN 제어기보다 양호한 응답특성이 나타났다. 또한 파라미터 변화에도 RFNN 제어기가 종래의 제어기에 비해 고속으로 속도를 추종하며 안정화 시간도 빠르게 나타났다. 또한 SynRM의 전류제어를 위해 MFC 전류제어기를 적용하였으며, ANN을 통해 속도를 추정하였다. 본 논문에서 제시한 RFNN 속도제어기는 종래의 제어기인 FLC 제어기와 FNN 제어기보다 응답특성이 우수하게 나타났으며 제시한 RFNN 제어기의 타당성을 입증할 수 있었다.

## References

[1] T. A. Lipo, A. Vagati, L. Malesani, and T. Fukao, Synchronous reluctance motors and drives—a new alternative, IEEE-IAS Annual Meeting, Tutorial, Oct. 1992.

[2] I. Boldea, Reluctance Synchronous Machines and Drives, Oxford university Press Inc., New York, 1996.  
[3] P. J. Lawrenson and L. A. Agu, Theory and performance of polyphase reluctance machines, Proceedings IEE, vol. 111, no. 8, pp. 1435–1445, 1964.  
[4] R. E. Betz, Control of synchronous reluctance machines, IEEE-IAS, Annual Meeting, Detroit, pp. 456–462, Sep. 1991.  
[5] R. E. Betz, Theoretical aspects of control of synchronous reluctance machines, Proceedings IEE, pt. B, vol. 139, no. 4, pp. 355–364, 1992.  
[6] A. Chiba and T. Fukao, A closed-loop operation of super high-speed reluctance motor for quick torque response, IEEE Transactions on Industry Applications, vol. IA-28, no. 3, pp. 600–606, 1992.  
[7] K. J. Astrom and B. Wittenmark, “Adaptive control,” Addison-Wesley, 1989.  
[8] J. H. Mun, J. S. Ko, J. S. Choi, M. G. Jang and D. H. Chung, “Efficiency Optimization Control of SynRM Drive Using Multi-AFLC,” ICEMS2010, pp. 908–913, 2010.  
[9] J. S. Ko, J. S. Choi, K. T. Park, B. S. Park and D. H. Chung, “Efficiency Optimization Control of SynRM Drive by LM-FNN Controller,” ICPE’07, pp. 373–377, 2007.  
[10] J. S. Ko, J. S. Choi, K. T. Park, B. S. Park and D. H. Chung, “Maximum Torque Control of SynRM Drive using ALM-FNN Controller,” ICCAS’07, pp. 1609–1612, 2007.  
[11] J. S. Choi, J. S. Ko and D. H. Chung, “Hybrid artificial intelligent control for speed control of induction motor,” ICCAS’06, TPA-6, 2006.

## ◇ 저자소개 ◇



### 고재섭 (高在涉)

1980년 2월 2일생. 2005년 순천대학교 공대 전기제어공학과 졸업. 2007년 2월 순천대학교 대학원 전기공학과 졸업(석사). 2007년 3월~현재 동 대학원 전기공학과 박사과정.

Tel : (061)750-3540

Fax : (061)752-1103

E-mail : kokos22@scnu.ac.kr



### 정동화 (鄭東和)

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

Tel : (061)750-3543

Fax : (061)752-9841

E-mail : hwa777@scnu.ac.kr