

論文2003-40SC-4-3

RBF 신경회로망을 이용한 교류 동기 모터의 강인 속도 제어

(Robust Speed Control of AC Permanent Magnet Synchronous Motor using RBF Neural Network)

金 殷 泰 * , 李 性 烈 *

(Euntai Kim and Sungryul Lee)

요 약

본 논문에서는 RBF 신경망 외란 관측기를 이용한 영구자석형 동기모터의 속도추종 제어기를 제안한다. 먼저 공칭 모델에 대하여 입출력 선형화에 기반한 속도 제어기를 설계하고 RBF 신경망 외란 관측기에 의해 시스템의 불확실성을 보상한다. 시스템의 파라미터와 부하 토크의 변동을 동시에 추정하는 RBF 신경망 외란 관측기를 이용함으로써 제안한 제어 알고리즘은 시스템의 불확실성에 강인한 특성을 갖는다. 마지막으로 모의실험을 통하여 제안된 제어기의 타당성을 검증한다.

Abstract

In this paper, the speed controller of permanent-magnet synchronous motor (PMSM) using the RBF neural (NN) disturbance observer is proposed. The suggested controller is designed using the input-output feedback linearization technique for the nominal model of PMSM and incorporates the RBF NN disturbance observer to compensate for the system uncertainties. Because the RBF NN disturbance observer which estimates the variation of a system parameter and a load torque is employed, the proposed algorithm is robust against the uncertainties of the system. Finally, the computer simulation is carried out to verify the effectiveness of the proposed method.

Keyword : 교류동기모터, 강인속도제어, RBF, 외란관측기

I. 서 론

최근에 산업응용분야에서 교류모터는 빠른 속도로 직류모터를 대체해 나가고 있다. 특히, 영구자석형 동기모터는 여러 분야에 적용되어 고성능의 서보 모터로서

자리잡고 있다. 교류 모터가 직류 모터에 비해 제작이 쉽고 구조가 간단하다는 장점이 있는 반면에 비선형적인 동특성으로 인해 제어가 어렵다는 단점이 있다. 그러나 최근 마이크로 프로세서 기술의 발달과 비선형 제어기술의 발전으로 인해 많은 제어 알고리즘이 연구되고 있다. 영구자석형 교류 동기모터에 대한 최근의 연구는 크게 다음 세 가지로 분류할 수 있다.

첫째는 비선형 모델을 선형화 하여 선형제어 이론을 응용할 수 있게 하는 피드백 선형화에 기반한 연구이다. Kim은 적응 입출력 선형화 기법을 이용한 속도제어기를 제안하였다^[1]. 제안한 속도 제어기는 모델 참조

* 正會員, 延世大學校 電氣電子工學部

(Yonsei University, School of Electrical and Electronic Engr.)

※ 이 논문은 2002년도 산학협동재단의 학술연구비 지원에 의하여 연구되었음

接受日字:2002年9月28日, 수정완료일:2003年6月17日

적응 기법을 이용하여 자속과 부하의 변화를 추정함으로써 시스템의 불확실성에 강인한 특성을 갖는다. Solsona는 시스템의 상태 변수뿐만 아니라 부하토크를 추정하는 관측기를 이용하여 출력 피드백에 의한 피드백 선형화 제어를 제안하였다. 기계적 센서가 필요 없다는 장점이 있는 반면에 모델의 파라미터를 정확히 알아야 한다는 단점이 있다^[2]. Zhu는 로컬 관측기에 기반한 피드백 선형화 제어를 제안하였다. 비선형 관측기 이론에 따른 체계적인 접근 방법을 채택한 반면에 역시 파라미터의 변동과 외란에 민감한 특성을 보인다^[3].

두 번째 연구 방향은 시스템의 불확실성에 강인한 슬라이딩 모드 제어를 이용한 방법이 많이 연구되고 있다. Choi는 입력 토크의 제약을 고려한 슬라이딩 모드 제어를 제안하였고 입력의 제약에 따른 여러 가지 설계변수의 선정 방법을 제시하였다^[4]. Wai는 퍼지 신경망을 이용하여 불확실성의 크기를 실시간으로 추정하는 슬라이딩 모드 제어를 제안하였다^[5]. 불확실성의 크기를 실시간으로 추정함으로써 큰 제어량을 필요로 하지 않는 장점이 있다. 그러나 기계적 동역학만을 고려함으로써 정밀 제어 성능을 보장하지 못한다. Shyu는 LQ방식을 이용한 슬라이딩 모드 위치 제어가 개발하였다^[6]. [5]에서와 같이 기계적인 동역학만을 고려하는 단점이 있다.

세 번째 연구 방향은 퍼지-신경망 시스템을 이용한 제어 방법이다. Lin는 퍼지-신경망 시스템의 구조와 파라미터를 온라인으로 학습함으로써 강인한 성능의 제어를 제안하였다^[7]. 그러나, 단순화된 모델에 기반하므로 역시 정밀 제어 성능을 보장하기 어렵다. C. Lin은 회귀 뉴럴 네트워크를 이용한 적응 하이브리드 제어 방법을 제안하였다^[8]. 위치 추종을 위해 회귀 뉴럴 네트워크를 이용한 제어가 사용되고 근사화 오차를 보상하기 위하여 가변 구조 제어 방식을 사용한다. 그러나 단순화된 모델을 이용하고 제어기 지나치게 복잡하다는 단점이 있다. Elbuluk는 모터의 파라미터와 상태를 동시에 추정하는 뉴럴 네트워크에 기반한 모델 참조 적응 시스템을 제안하였다^[9]. 기존의 관측기와는 달리 파라미터의 변동에 강인한 특성을 나타낸다.

본 논문에서는 RBF 신경망 외란 관측기를 이용한 강인한 속도 제어 알고리즘을 제안한다. 먼저, 영구자석형 동기 모터의 전기적 동역학을 포함하는 전체 모델을 이용함으로써 단순화된 모델에 기반한 제어 방법에

비해 고성능의 제어 시스템을 구성할 수 있도록 한다. 시스템의 파라미터와 부하 토크의 변동을 RBF 신경망 외란 관측기를 이용하여 추정함으로써 기존의 연구에 비해 뛰어난 강인성을 보장한다. 제어기의 설계는 입력력 피드백 선형화된 모델에 기반하여 이루어진다. 선형화된 시스템의 공칭 모델을 이용하여 주어진 속도 명령을 추종하는 피드백 선형화 제어가 설계되고 시스템의 불확실성은 RBF 신경망 시스템을 이용한 외란 관측기에 의하여 보상된다. 마지막으로 모의 실험을 통해 제안된 알고리즘의 타당성을 입증한다.

II. 배경지식

1. 교류 동기 모터와 피드백 선형화

영구자석형 교류 동기 모터는 영구자석이 붙은 회전자와 120도 간격으로 위치한 3상의 고정자 코일로 구성되어 있다. dq축에서 고정자의 전압 방정식은 다음과 같이 표현된다.

$$v_{qs} = R_s i_{qs} + L_s \dot{i}_{qs} + L_s \omega_r i_{ds} + \lambda_m \omega_r \quad (1)$$

$$v_{ds} = R_s i_{ds} + L_s \dot{i}_{ds} - L_s \omega_r i_{qs} \quad (2)$$

여기서 R_s 와 L_s 는 각 고정자 저항과 인덕턴스이고 ω_r 은 전기적 회전각속도이며 λ_m 은 영구자석의 자속결합 (flux linkage)이다. 교류 동기 모터의 전기적 회전 속도는 다음의 식으로 표현된다.

$$\dot{\omega}_r = \frac{3}{2} \frac{p}{J} \lambda_m i_{qs} - \frac{B}{J} \omega_r - \frac{p}{J} T_L \quad (3)$$

여기서 J 는 회전자의 관성모멘트이고 B 는 점성마찰 계수이고 p 는 극쌍 (pole pair)의 수이고 T_L 은 부하토크이다. ω_r , i_{qs} , i_{ds} 을 상태변수로 하여 교류 동기 모터는 다음과 같은 벡터식으로 표현할 수 있다.

$$\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}) + \mathbf{g}\mathbf{v} \quad (4)$$

여기서 $\mathbf{x} = \begin{pmatrix} \omega_r \\ i_{qs} \\ i_{ds} \end{pmatrix}$, $\mathbf{v} = \begin{pmatrix} v_{qs} \\ v_{ds} \end{pmatrix}$ 이며

$$\mathbf{f}(\mathbf{x}) = \begin{pmatrix} \frac{3}{2} \frac{p}{J} \lambda_m i_{qs} - \frac{B}{J} \omega_r - \frac{p}{J} T_L \\ -\frac{R_s}{L_s} i_{qs} - \omega_r i_{ds} - \frac{\lambda_m}{L_s} \omega_r \\ -\frac{R_s}{L_s} i_{ds} + \omega_r i_{qs} \end{pmatrix}$$

$$\mathbf{g} = \begin{pmatrix} \mathbf{g}_1 & \mathbf{g}_2 \end{pmatrix} = \begin{pmatrix} 0 & 0 \\ \frac{1}{L_s} & 0 \\ 0 & \frac{1}{L_s} \end{pmatrix} \text{이다.}$$

이제 피드백 선형화를 위해 다음과 같은 비선형 변환을 생각한다.

$$\begin{aligned} z_1 &= \omega_r \\ z_2 &= L_f z_1 = \frac{3}{2} \frac{p^2}{J} \lambda_m i_{qs} - \frac{B}{J} \omega_r - \frac{p}{J} T_L \quad (5) \\ z_3 &= i_{ds} \end{aligned}$$

새로운 좌표축 $\mathbf{z} = (z_1 \ z_2 \ z_3)^T$ 에 대한 교류 동기 모터의 다이내믹스는 다음과 같이 표현된다.

$$\dot{z}_1 = L_f z_1 + L_{g_1} z_1 v_{qs} + L_{g_2} z_1 v_{ds} = z_2 \quad (6)$$

$$\begin{aligned} \dot{z}_2 &= L^2 \ddot{z}_1 + L_{g_1} L \ddot{z}_1 v_{qs} + L_{g_2} L \ddot{z}_1 v_{ds} \\ &= -\frac{B}{J} \left(\frac{3}{2} \frac{p^2}{J} \lambda_m i_{qs} - \frac{B}{J} \omega_r - \frac{p}{J} T_L \right) \\ &\quad + \frac{3}{2} \frac{p^2 \lambda_m}{J} \left(-\frac{R_s}{L_s} i_{qs} - \omega_r i_{ds} - \frac{\lambda_m}{L_s} \omega_r \right) + \frac{3}{2} \frac{p^2}{J} \frac{\lambda_m}{L_s} v_{qs} \end{aligned}$$

$$\begin{aligned} \dot{z}_3 &= L \ddot{z}_3 + L_{g_1} z_3 v_{qs} + L_{g_2} z_3 v_{ds} \\ &= -\frac{R_s}{L_s} i_{ds} + \omega_r i_{qs} + \frac{1}{L_s} v_{ds} \end{aligned}$$

$$\begin{aligned} \text{즉 } \dot{z}_1 &= z_2 \\ \dot{z}_2 &= a_2(\mathbf{z}) + \beta_2(\mathbf{z})v_1 + d_2 \quad (7) \\ \dot{z}_3 &= a_3(\mathbf{z}) + \beta_3(\mathbf{z})v_2 \end{aligned}$$

여기서 $v_1 = v_{qs}$, $v_2 = v_{ds}$ 이며

$$\begin{aligned} a_2(\mathbf{z}) &= -\frac{B}{J} \left(\frac{3}{2} \frac{p^2}{J} \lambda_m i_{qs} - \frac{B}{J} \omega_r \right) \\ &\quad + \frac{3}{2} \frac{p^2 \lambda_m}{J} \left(-\frac{R_s}{L_s} i_{qs} - \omega_r i_{ds} - \frac{\lambda_m}{L_s} \omega_r \right) \end{aligned}$$

$$\begin{aligned} \beta_2(\mathbf{z}) &= \frac{3}{2} \frac{p^2}{J} \frac{\lambda_m}{L_s} \\ d_2 &= \frac{Bp}{J^2} T_L \end{aligned}$$

$$a_3(\mathbf{z}) = -\frac{R_s}{L_s} i_{ds} + \omega_r i_{qs}$$

$$\beta_3(\mathbf{z}) = \frac{1}{L_s}$$

2. 불확실한 교류 동기 모터 모델링

교류 동기 모터의 다이내믹스는 내부 파라미터 불확실성과 외란이 있는 경우 다음의 식으로 표현될 수 있다.

$$\dot{z}_1 = z_2 \quad (8-1)$$

$$\dot{z}_2 = [a_2(\mathbf{z}) + \Delta a_2(\mathbf{z})] + [\beta_2(\mathbf{z}) + \Delta \beta_2(\mathbf{z})]v_1 + d_2 \quad (8-2)$$

$$\dot{z}_3 = [a_3(\mathbf{z}) + \Delta a_3(\mathbf{z})] + [\beta_3(\mathbf{z}) + \Delta \beta_3(\mathbf{z})]v_2 \quad (8-3)$$

여기서 $a_i(\cdot)$ 와 $\beta_i(\cdot)$ ($i=2,3$)는 공칭 (nominal) 함수이고 $\Delta a_i(\cdot)$ 과 $\Delta \beta_i(\cdot)$ 는 그 내부 파라미터 불확실성을 나타낸다. 본 논문에서는 내부 파라미터 불확실성과 외부 외란을 다음의 식과 같이 하나의 외란으로 다룬다. 즉

$$\dot{z}_1 = z_2 \quad (9-1)$$

$$\dot{z}_2 = a_2(\mathbf{z}) + \beta_2(\mathbf{z})v_1 + \Omega_2(\mathbf{z}, v_1) \quad (9-2)$$

$$\dot{z}_3 = a_3(\mathbf{z}) + \beta_3(\mathbf{z})v_2 + \Omega_3(\mathbf{z}, v_2) \quad (9-3)$$

여기서 $\Omega_2(\mathbf{z}, v_1) = \Delta a_2(\mathbf{z}) + \Delta \beta_2(\mathbf{z})v_1 + d_2$ 과 $\Omega_3(\mathbf{z}, v_2) = \Delta a_3(\mathbf{z}) + \Delta \beta_3(\mathbf{z})v_2$ 는 전체 외란을 나타내며 일반적으로 수학적인 식으로 표현할 수 없다.

3. RBF 신경회로망

기본적인 RBF (Radial Basis Function) 신경회로망은 <그림 1>과 같이 병렬로 이루어진 많은 노드와 이를 연결하는 웨이트로 구성되어 있고 입력 벡터 $\mathbf{z} = (z_1, z_2, \dots, z_n)^T \in X \subset R^n$ 을 출력값 $y \in Y \subset R$ 에 대응시키는 비선형 함수의 역할을 한다. i 번째 노드의 출력은 다음과 같은 가우시안 함수로 표현되며

$$\xi_i(\mathbf{z}) = \exp\left(-\frac{\|\mathbf{z} - \mathbf{m}_i\|^2}{s_i^2}\right) \quad (10)$$

RBF 신경망의 전체 출력은 다음과 같이 각 노드의 가중치 합으로 표현된다.




그림 1. RBF 신경망 신경회로망
Fig. 1 RBF 신경망 neural networks.

$$\hat{\Omega}(z|\hat{W}) = \sum_{i=1}^r \hat{w}_i \xi_i(z) = \hat{W}^T \xi(z) \quad (11)$$

여기서 r 는 RBF 노드의 수이고 m_i 와 s_i 는 i 번째 노드의 중간점과 폭이고 $\hat{W}^T = (\hat{w}_1, \hat{w}_2, \dots, \hat{w}_r)$ 는 조정가능한 웨이트이다.

이러한 RBF 신경망은 비선형 함수를 원하는 수준까지 정확히 표현할 수 있는 것이 알려져 있다^[10]. z 가 콤팩트 집합 M_z 에 소속된 경우, 최적의 신경망 웨이트는 식 (12)와 같이 주어진 비선형 함수와 RBF 신경망과의 차이를 최소화하는 값으로 정의할 수 있다.

$$W^* = \arg \min_{W \in M_w} [\sup_{z \in M_z} \|\Omega(z) - \hat{\Omega}(z|W)\|] \quad (12)$$

여기서 $\Omega(\cdot)$ 는 미지의 비선형 함수를 나타내고 $\hat{\Omega}(\cdot)$ 는 RBF 신경망을 나타내며 M_w 는 신경망의 웨이트 추정치가 존재하는 영역이다. 이러한 성질을 일반 근사성이라 하며 최적의 웨이트를 갖춘 신경망을 이용하면 비선형 함수는 다음과 같이 표현할 수 있다.

$$\Omega(\cdot) = \hat{\Omega}(\cdot|W^*) + \varepsilon(\cdot) \quad (13)$$

여기서 $\varepsilon(\cdot)$ 는 신경망의 복원 오차이며 RBF의 중간 노드 수를 늘임으로서 충분히 작게 할 수 있다.

III. RBF 신경망 외란관측기를 이용한 제어시스템

1. RBF 외란 관측기

RBF 신경망 외란관측기는 RBF 신경망의 일반근사성에 이론적 근거를 둔 것으로 <그림 2>와 같이 교류 동기 모터의 입출력 정보를 이용하여 미지의 전체 외란 $\Omega_i(\cdot)$ ($i=2,3$)을 RBF 신경망 $\hat{\Omega}_i(\cdot)$ 로 근사하는 것이다.

교류 동기 모터 (9)에 대하여 다음과 같은 시스템을 설계한다.

$$\dot{\mu}_2 = -\sigma_2 \mu_2 + \beta_2(z, v_1, \hat{W}_2) \quad (14-1)$$

$$\dot{\mu}_3 = -\sigma_3 \mu_3 + \beta_3(z, v_2, \hat{W}_3) \quad (14-2)$$

여기서 $\beta_i(z, v_{i-1}, \hat{W}_i) = \sigma_i z_i + \alpha_i(z) + \beta_i(z)v_{i-1} + \hat{\Omega}_i(z, v_{i-1}|\hat{W}_i)$ ($i=2,3$)이고 σ_i 는 양수이다.




그림 2. 시스템 구성

Fig. 2. Configuration of system.

이 때 새로운 변수

$$\zeta_i = x_i - \mu_i, \quad (i=2,3) \quad (15)$$

를 정의하면 식 (9)과 식 (14)로부터 다음과 같은 ζ_i 의 다이내믹스를 얻을 수 있다.

$$\dot{\zeta}_i = -\sigma_i \zeta_i + \{\Omega_i(z, v_{i-1}) - \hat{\Omega}_i(z, v_{i-1})\} \quad (16)$$

따라서 $\zeta_i \rightarrow 0$ 는 RBF 신경망 $\hat{\Omega}_i(z, v_{i-1}|\hat{W}_i)$ 가 미지의 전체 외란 $\Omega_i(z, v_{i-1})$ 에 접근하는 것을 의미하게 된다. 즉 새로운 변수는 RBF 신경망이 외란을 얼마나 잘 관측하는 가를 나타내는 척도가 되며 본 논문에서는 '외란 관측 오차'라고 부른다.

2. 제어기

RBF 신경망 $\hat{\Omega}_i(\cdot)$ 이 전체 외란 $\Omega_i(\cdot)$ 을 잘 표현하면 다음의 식 (17)로 표현되는 제어기를 사용할 수 있다.

$$v_{i-1} = \frac{\overline{v_{i-1}} - \alpha_i(z) - \hat{\Omega}_i(z, v_{i-1}|\hat{W}_i)}{\beta_i(z)}, \quad (i=2,3) \quad (17)$$

여기서 한가지 문제점은 제어 입력 v_{i-1} 이 식 (17)의 좌우변에 모두 있어 직접구현이 어렵다는 것이다. 그러나 결국 제어 신호 v_{i-1} 는 상태변수 z 의 함수여야 하므로, 미지의 외란 $\Omega_i(\cdot)$ 은 결국 상태변수 z 만의 함수이고 RBF 신경망 $\hat{\Omega}_i(\cdot|\hat{W}_i)$ 도 z 만의 함수로 만들어도 된다. 이제 다음과 같은 제어기를 설계한다.

$$v_{i-1} = \frac{\overline{v_{i-1}} - \alpha_i(z) - \hat{\Omega}_i(z|\hat{W}_i)}{\beta_i(z)} \quad (18)$$

$$\overline{v_1} = \ddot{\omega}_r^* - k_{22}(z_2 - \dot{\omega}_r^*) - k_{21}(z_1 - \omega_r^*)$$

$$\overline{v_2} = -k_{31}z_3$$

여기서 ω_r^* 는 원하는 회전자의 전기적 회전 각속도이고 $i_{ds}^* = 0$ 으로 한다^[1]. k_{ij} 는 $d_3(s) = s + k_{31}$ 과 $d_2(s) = s^2 + k_{22}s + k_{21}$ 의 근이 좌반면 안정한 영역에 있도록 선정한다. 식 (18)의 제어기를 이용하는 경우 전체 제어 오차는 다음의 식으로 표현된다.

$$\dot{\tilde{z}}_2 = \Lambda_2 \tilde{z}_2 + b_2(\Omega_2(z) - \widehat{\Omega}_2(z, \widehat{W}_2)), \quad (19-1)$$

$$\dot{\tilde{z}}_3 = \Lambda_3 \tilde{z}_3 + b_3(\Omega_3(z) - \widehat{\Omega}_3(z, \widehat{W}_3)), \quad (19-2)$$

여기서 $\tilde{z}_2 = \begin{pmatrix} z_1 - \omega_r^* \\ z_1 - \omega_r^* \end{pmatrix}$, $\tilde{z}_3 = z_3 - i_{ds}^* = z_3$ 이고

$$\Lambda_2 = \begin{pmatrix} 0 & 1 \\ -k_{22} & -k_{21} \end{pmatrix}, b_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix} \text{이고 } \Lambda_3 = -k_{31}, b_3 = 1$$

이다.

3. RBF 신경망의 학습

<그림 2>와 같이 교류 동기 모터와 외란관측기, 제어기로 구성된 전체 시스템의 안정성을 보장하기 위하여 다음과 같은 확장 오차를 고려한다.

$$\tilde{\mathbf{x}}_i = \Pi_i \mathbf{x}_i + B_i(\Omega_i(z) - \widehat{\Omega}_i(z, \widehat{W}_i)) \quad (i=2,3)$$

$$\text{여기서 } \mathbf{x}_i = \begin{pmatrix} \tilde{z}_i \\ \xi_i \end{pmatrix}, \Pi_i = \begin{pmatrix} \Lambda_i & \mathbf{0} \\ \mathbf{0} & -\sigma_i \end{pmatrix}, B_i = \begin{pmatrix} b_i \\ 1 \end{pmatrix} \text{이고}$$

\mathbf{x}_i 는 확장오차로 외란 관측 오차와 제어 오차를 모두 포함하는 오차이다. RBF 신경망은 외란 관측 오차와 제어 오차를 모두 줄이는 방향으로 학습을 한다. 다음의 정리는 RBF 신경망의 학습방법을 나타낸다.

정리 1.

교류 동기 모터 (9)에 외란 관측기 식 (14)와 식 (18)의 제어기를 사용하여 제어한다. RBF 신경망의 웨이트를 다음의 식 (20)과 같이 학습하고 이것이 유계되어 있는 경우 외란 관측 오차 ξ_i ($i=2,3$)과 제어 오차 \tilde{z}_i 를 포함하는 확장오차 \mathbf{x}_i 는 콤팩트한 집합으로 수렴하며 그 집합의 크기는 임의로 작게 할 수 있다.

$$\dot{\widehat{W}}_i = \gamma \mathbf{x}_i^T P_i B_i \xi_i(z) \quad (i=2,3) \quad (20)$$

(증명)

식 (13)을 이용하여 \mathbf{x} 의 오차식을 다음과 같이 표현한다.

$$\begin{aligned} \dot{\tilde{\mathbf{x}}}_i &= \Pi_i \mathbf{x}_i + B_i\{\widehat{\Omega}_i(z, \widehat{W}_i) - \widehat{\Omega}_i(z, \widehat{W}_i)\} + B_i \varepsilon_i(z) \quad (21) \\ &= \Pi_i \mathbf{x}_i + B_i \widetilde{W}_i^T \xi_i(z) + B_i \varepsilon_i(z). \end{aligned}$$

여기서 $\widetilde{W}_i = W_i - \widehat{W}_i$. Π_i 는 안정한 행렬이므로 임의의 양한정 행렬 Q_i 에 대하여 식 (22)을 만족하는 양한정 행렬 P_i 가 존재한다.

$$\Pi_i^T P_i + P_i \Pi_i = -Q_i, \quad (i=2,3) \quad (22)$$

이제 다음과 같은 리아프노프 후보함수를 생각한다.

$$V = \frac{1}{2} \sum_{i=2}^3 \mathbf{x}_i^T P_i \mathbf{x}_i + \frac{1}{2\gamma} \sum_{i=2}^3 \widetilde{W}_i^T \widetilde{W}_i \quad (23)$$

식 (23)를 미분하고 식 (21)을 대입하면

$$\begin{aligned} \dot{V} &= \sum_{i=2}^3 \mathbf{x}_i^T P_i \dot{\tilde{\mathbf{x}}}_i + \frac{1}{\gamma} \sum_{i=2}^3 \widetilde{W}_i^T \dot{\widetilde{W}}_i \\ &= \sum_{i=2}^3 \left\{ \mathbf{x}_i^T P_i \Pi_i \mathbf{x}_i + \mathbf{x}_i^T P_i B_i \widetilde{W}_i^T \xi_i(z) + \frac{1}{\gamma} \widetilde{W}_i^T \dot{\widetilde{W}}_i + \mathbf{x}_i^T P_i B_i \varepsilon_i(z) \right\} \\ &= \sum_{i=2}^3 \left[\frac{1}{2} \mathbf{x}_i^T (\Pi_i^T P_i + P_i \Pi_i) \mathbf{x}_i + \widetilde{W}_i^T \left\{ \mathbf{x}_i^T P_i B_i \xi_i(z) + \frac{1}{\gamma} \dot{\widetilde{W}}_i \right\} + \mathbf{x}_i^T P_i B_i \varepsilon_i(z) \right] \\ &= \sum_{i=2}^3 \left[-\frac{1}{2} \mathbf{x}_i^T Q_i \mathbf{x}_i + \widetilde{W}_i^T \left\{ \mathbf{x}_i^T P_i B_i \xi_i(z) + \frac{1}{\gamma} \dot{\widetilde{W}}_i \right\} + \mathbf{x}_i^T P_i B_i \varepsilon_i(z) \right] \end{aligned}$$

여기서

$$\dot{\widetilde{W}}_i = -\gamma \mathbf{x}_i^T P_i B_i \xi_i(z),$$

즉

$$\dot{\widehat{W}}_i = \gamma \mathbf{x}_i^T P_i B_i \xi_i(z)$$

로 하면,

$$\begin{aligned} \dot{V} &\leq \sum_{i=2}^3 \left\{ -\frac{1}{2} \mathbf{x}_i^T Q_i \mathbf{x}_i + \mathbf{x}_i^T P_i B_i \varepsilon_i(z) \right\} \\ &\leq \sum_{i=2}^3 \left[-\frac{1}{2} \lambda_{\min}(Q_i) \|\mathbf{x}_i\|^2 + \mathbf{x}_i^T P_i B_i \varepsilon_i(z) \right] \\ &\quad + \left\{ \frac{\lambda_{\min}(Q_i)}{4\lambda_{\max}(P_i)} \mathbf{x}_i^T P_i \mathbf{x}_i + \frac{\lambda_{\max}(P_i)}{\lambda_{\min}(Q_i)} B_i^T P_i B_i \varepsilon_i^2(z) \right\} \end{aligned}$$

$$\begin{aligned}
& - \left\{ \frac{\lambda_{\min}(\mathbf{Q}_i)}{4\lambda_{\max}(\mathbf{P}_i)} \mathbf{x}_i^T \mathbf{P}_i \mathbf{x}_i + \frac{\lambda_{\max}(\mathbf{P}_i)}{\lambda_{\min}(\mathbf{Q}_i)} \mathbf{B}_i^T \mathbf{P}_i \mathbf{B}_i \varepsilon_i^2(z) \right\} \\
& = \sum_{i=2}^3 \left[\frac{\lambda_{\min}(\mathbf{Q}_i)}{4\lambda_{\max}(\mathbf{P}_i)} \mathbf{x}_i^T \mathbf{P}_i \mathbf{x}_i + \frac{\lambda_{\max}(\mathbf{P}_i)}{\lambda_{\min}(\mathbf{Q}_i)} \mathbf{B}_i^T \mathbf{P}_i \mathbf{B}_i \varepsilon_i^2(z) \right. \\
& \quad - \frac{1}{2} \lambda_{\min}(\mathbf{Q}_i) \|\mathbf{x}_i\|^2 - \left(\frac{1}{2} \sqrt{\frac{\lambda_{\min}(\mathbf{Q}_i)}{\lambda_{\max}(\mathbf{P}_i)}} \mathbf{x}_i \right. \\
& \quad \left. - \sqrt{\frac{\lambda_{\max}(\mathbf{P}_i)}{\lambda_{\min}(\mathbf{Q}_i)}} \mathbf{B}_i \varepsilon_i(z) \right)^T \\
& \quad \left. \times \mathbf{P} \left(\frac{1}{2} \sqrt{\frac{\lambda_{\min}(\mathbf{Q}_i)}{\lambda_{\max}(\mathbf{P}_i)}} \mathbf{x}_i - \sqrt{\frac{\lambda_{\max}(\mathbf{P}_i)}{\lambda_{\min}(\mathbf{Q}_i)}} \mathbf{B}_i \varepsilon_i(z) \right) \right] \\
& \leq \sum_{i=2}^3 \left\{ -\frac{1}{2} \lambda_{\min}(\mathbf{Q}_i) \|\mathbf{x}_i\|^2 + \frac{\lambda_{\min}(\mathbf{Q}_i)}{4\lambda_{\max}(\mathbf{P}_i)} \mathbf{x}_i^T \mathbf{P}_i \mathbf{x}_i \right. \\
& \quad \left. + \frac{\lambda_{\max}(\mathbf{P}_i)}{\lambda_{\min}(\mathbf{Q}_i)} \mathbf{B}_i^T \mathbf{P}_i \mathbf{B}_i \varepsilon_i^2(z) \right\} \\
& \leq \sum_{i=2}^3 \left\{ -\frac{1}{4} \lambda_{\min}(\mathbf{Q}_i) \|\mathbf{x}_i\|^2 + \frac{\lambda_{\max}^2(\mathbf{P}_i)}{\lambda_{\min}(\mathbf{Q}_i)} \|\mathbf{B}_i \varepsilon_i(z)\|^2 \right\} \quad (24)
\end{aligned}$$

따라서 \dot{V} 는 콤팩트 집합

$$B_{\mathbf{x}} = \left\{ \mathbf{x}_i \mid \|\mathbf{x}_i\| < 2 \frac{\lambda_{\max}(\mathbf{P}_i)}{\lambda_{\min}(\mathbf{Q}_i)} \|\mathbf{B}_i\| \bar{\varepsilon}_i \right\} \quad (25)$$

밖에서는 음이며, 확장오차는 $\hat{\mathbf{W}}_i$ 가 유계된 경우 콤팩트 집합의 안으로 수렴한다. 또 식 (25)에서 $\lambda_{\min}(\mathbf{Q}_i)/\lambda_{\max}(\mathbf{P}_i)$ 는 Π_i 시스템의 최대 감쇄율(maximal decay rate)을 나타낸다. 즉 $\lambda_{\min}(\mathbf{Q}_i)/\lambda_{\max}(\mathbf{P}_i)$ 는 Π_i 의 고유치중에서 우세극점(dominant pole)의 실수부의 반대부호값이다. 따라서 이 값은 k_{ij} 과 σ_i 을 조절하여 원하는 만큼 크게 할 수는 있다. $\|\mathbf{B}_i\|$ 과 $\bar{\varepsilon}_i$ 는 고정되어 있으므로 $\lambda_{\min}(\mathbf{Q}_i)/\lambda_{\max}(\mathbf{P}_i)$ 을 크게 하여 확장오차는 원하는 수준으로 줄일 수 있다.

주의 1

(1) 정리 1의 RBF 신경망 웨이트 학습 규칙 식 (20)를 다음의 식 (26)과 같이 투사규칙(projection rule)을 이용하여 수정하면 학습오차 역시 유계되고 관련된 모든 신호는 유계된다.

$$\hat{\mathbf{W}}_i = P[\gamma \mathbf{x}_i^T \mathbf{P}_i \mathbf{B}_i \xi(z)] \equiv \gamma \mathbf{x}_i^T \mathbf{P}_i \mathbf{B}_i \xi(z) \quad (248)$$

$$- I_{W_i} \gamma \frac{\mathbf{x}_i^T \mathbf{P}_i \mathbf{B}_i \hat{\mathbf{W}}_i^T \xi(z)}{\|\hat{\mathbf{W}}_i\|^2} \hat{\mathbf{W}}_i \quad (26)$$

여기서

$$I_{W_i} = \begin{cases} 0, & \text{if } \left\{ \begin{array}{l} \|\hat{\mathbf{W}}_i\| < M_{W_i} \text{ or} \\ \|\hat{\mathbf{W}}_i\| = M_{W_i} \text{ and } \mathbf{x}_i^T \mathbf{P}_i \mathbf{B}_i \hat{\mathbf{W}}_i^T \xi(z) \leq 0 \end{array} \right. \\ 1, & \text{if } \|\hat{\mathbf{W}}_i\| = M_{W_i} \text{ and } \mathbf{x}_i^T \mathbf{P}_i \mathbf{B}_i \hat{\mathbf{W}}_i^T \xi(z) > 0 \end{cases}$$

식 (2) 위의 식 (26)에서 양변을 시간 $t=0$ 에서 $t=T$ 사이로 적분하면

$$\begin{aligned}
\int_{t=0}^T \|\mathbf{x}_i(t)\|^2 dt & \leq \frac{4}{\lambda_{\min}(\mathbf{Q}_i)} [V(0) - V(T)] \\
& \quad + \left\{ \frac{2\lambda_{\max}(\mathbf{P}_i)}{\lambda_{\min}(\mathbf{Q}_i)} \right\}^2 \int_0^T \|\mathbf{B}_i \varepsilon_i(t)\|^2 dt
\end{aligned}$$

즉 확장 오차의 확장 L_2 놈은 ε_i 의 확장 L_2 놈의 차원에 유계된다 ($\varepsilon_i \in L_2$ 인 경우 $\mathbf{x}_i \in L_2$) (22)에 의해 $\tilde{\mathbf{x}}_i \in L_\infty$, $\mathbf{x}_i \in L_\infty$ 이고 $\hat{\mathbf{W}}_i \in L_\infty$ 이므로 Barbalat의 정리에 의해

$$\lim_{t \rightarrow 0} \|\mathbf{x}_i(t)\| = 0 \quad (27)$$

IV. 컴퓨터 모의실험

본 장에서는 제안한 RBF 신경망 외란관측시스템을 이용하여 교류 동기모터를 속도제어하고 기존의 피드백 선형화 제어기와 제어성능을 비교하여 타당성을 보인다. 본 모의실험에서는 MATLAB을 이용하였고 사용된 파라미터는 다음과 같다.

표 1. 교류 동기 모터 파라미터
Table 1. Simulation parameters of PMSM.

λ_m	0.153(V · sec/rad)	p	2
L_s	10.5×10^{-3} (H)	J	1.75×10^{-4} (Kg m^2)
R_s	3 (Ω)	B	0.015 (N · m · sec/rad)

교류 동기 모터의 원하는 속도 궤적은 다음과 같도록 한다.

$$\omega_r^* = \begin{cases} \frac{\omega_{rf}}{T_f} t - \frac{\omega_{rf}}{2\pi} \sin\left(\frac{2\pi t}{T_f}\right) & \text{if } t \leq T_f \\ \omega_{rf} & \text{if } t > T_f \end{cases}$$

$$\dot{\omega}_r^* = \begin{cases} \frac{\omega_{rf}}{T_f} - \frac{\omega_{rf}}{T_f} \cos\left(\frac{2\pi t}{T_f}\right) & \text{if } t \leq T_f \\ 0 & \text{if } t > T_f \end{cases}$$

$$\omega_{rf} = (2\pi) \times 1800/60 \text{ (rad/sec)}$$

$$T_f = 0.2 \text{ (sec)}$$

본 모의실험에서는 사용한 RBF 신경망 외란관측기는 입력변수로 ω_r , i_{ds} , i_{qs} 를 이용하며 $[-450, 450] \times [-7, 7] \times [-7, 7]$ 구간에 각 변수당 7개의 RBF 함수를 이용하여 중간노드를 형성하였고 RBF의 폭 s_i 는 양의 최대값의 0.7로 하였다. 학습률 γ 는 30, 외란관측기 파라미터 σ_i 는 10으로 하였고 Q_2 와 Q_3 은 대각선에 50을 갖는 대각행렬로 선정하였다. 또 제어기의 경우

$$\dot{v}_1 = \ddot{\omega}_r^* - k_{22}(z_2 - \dot{\omega}_r^*) - k_{21}(z_1 - \omega_r^*)$$

$$\dot{v}_2 = -k_{31}z_3$$

을 사용하였고 $k_{21} = 8000$, $k_{22} = 400$, $k_{31} = 200$ 으로 하였다. 제안한 RBF 신경망 외란관측기를 이용한 제어 방식의 강인한 추적 성능을 보이기 위하여 내부 파라미터 불확실성과 외부 외란이 모두 존재하는 경우를 생각한다. 내부 파라미터는 B 에 불확실성이 있는 것을 가정하는데 실제 \hat{B} 는 공칭 B 의 5배의 값을 갖는 것을 가정한다.

$$\hat{B} = 5B = 5 \times 0.015 (N \cdot m \cdot \text{sec/rad})$$

또 외부 외란 $T_L = 5(N)$ 이 기동순간부터 교류 동기 모터에 주어지는 것으로 가정한다.

<그림 3>은 피드백 선형화 제어기를 이용한 교류 동기 모터의 속도 제어 성능을 보이고 있다. 여기서 점선은 원하는 궤적을 나타내고 실선은 실제 제어 결과를 나타낸다. 점성 마찰계수 B 와 외부 외란의 영향으로 실제 모터의 속도는 원하는 속도와 크게 다른 궤적을 그리고 있음을 볼 수 있다. <그림 4>는 제안한 RBF 신경망 외란관측기를 이용한 결과이다. 2초 정도가 지난 후 동기모터는 내부 파라미터의 불확실성과 외부 외란에도 불구하고 강인한 속도 제어 성능을 보이는 것을 볼 수 있다. <그림 5>는 외란 관측 오차를 나타내고 있다. ξ_i 가 0에 접근하는 것을 볼 수 있고 RBF




그림 3. 피드백선형화를 이용한 제어결과
Fig. 3. Control result of feedback linearization controller.




그림 4. RBF 신경망 외란관측기를 이용한 제어결과
Fig. 4. Control result of RBF NN DO.




그림 5. 외란 관측 오차
Fig. 5. Disturbance observation error.

외란관측기가 전체 외란을 잘 관측하는 것을 의미한다.

V. 결 론

본 논문에서 RBF 신경망 외란 관측기를 이용한 영구자석형 동기모터의 속도 제어 알고리즘을 제안하였다. 영구 자석형 동기모터에 대하여 파라미터와 부하의 변동을 추정하는 RBF 신경망 시스템을 이용한 외란 관측기를 제안하였고 리아푸노프 함수를 이용하여 적응 규칙을 유도하였다. 또한 리아푸노프 방법을 이용하여 전체 시스템의 안정도를 증명하였다. 모의 실험을 통하여 제안된 알고리즘은 시스템의 파라미터와 부하 토크의 변동에도 불구하고 불확실성에 강인한 추종 성능을

보장함을 보였다.

참 고 문 헌


- [1] K.-H. Kim, I.-C. Baik, S.-K. Chung, M.-J. Youn, "Robust Speed Control of Brushless DC Motor Using Adaptive Input-Output Linearization Technique", IEE Proc.-Electr. Power Appl., vol.144, no.6, pp. 469~475, Nov. 1997.
- [2] J. Solsona, M.I. Valla, C. Muravchik, "Nonlinear Control of a Permanent Magnet Synchronous Motor with Disturbance Torque Estimation", IEEE Trans. on Energy Conversion, vol.15, no.2, pp. 163~168, June 2000.
- [3] G. Zhu, A. Kaddouri, L.-A. Dessaint, O. Akhrif, "A Nonlinear State Observer for the Sensorless Control of a Permanent-Magnet AC Machine", IEEE Trans. on Industrial Electronics, vol.48, no.6, pp. 1098~1108, Dec. 2001.
- [4] H.-S. Choi, Y.-H. Park, Y. Cho, and M. Lee, "Global sliding-mode control: Improved design for a brushless DC motor", IEEE Control Systems Magazine, pp. 27~35, June 2001.
- [5] R.-J. Wai, "Total Sliding-Mode Controller for PM Synchronous Servo Motor Drive Using Recurrent Fuzzy Neural Network", IEEE Trans. on Industrial Electronics, vol. 48, no. 5, pp. 926~944, Oct. 2001.
- [6] K.-K. Shyu, C.-K. Lai, Y.-W. Tsai, and D.-I. Yang, "A Newly Robust Controller Design for the Position Control of Permanent-magnet Synchronous Motor", IEEE Trans. on Industrial Electronics, vol. 49, no. 3, pp. 558~565, Jun. 2002.
- [7] F.-J. Lin, C.-H. Lin, P.-H. Shen, "Self-Constructing Fuzzy Neural Network Speed Controller for Permanent-Magnet Synchronous Motor Drive", IEEE Trans. on Fuzzy Systems, vol.9 no.5, pp. 751~759, Oct. 2001.
- [8] C.-H. Lin, W.-D. Chou, and F.-J. Lin, "Adaptive hybrid control using a recurrent neural network for a linear synchronous motor servo-drive system", IEE Proc.-Control Theory Appl., vol. 148, no. 2, pp. 156~168, March 2001.
- [9] M.E. Elbuluk, L. Tong, and I. Husain, "Neural-Network-Based Model Reference Adaptive Systems for High-Performance Motor Drives and Motion Controls," IEEE Trans. on Industry Applications, vol. 38, no. 3, pp. 879~886, May/June 2002.
- [10] J. A. Leonard, M. A. Kramer and L. H. Ungar, "Using radial basis functions to approximate a function and its error bounds," IEEE Trans. Neural Networks, vol. 3, pp. 624~627, 1992.

저 자 소 개



金 殷 泰(正會員)

1992년 2월 : 연세대학교 전자공학과 졸업(공학사). 1994년 2월 : 연세대학교 전자공학과 석사과정 졸업(공학석사). 1999년 2월 : 연세대학교 전자공학과 박사과정 졸업(공학박사). 1999년 3월~2002년 2월 : 국립한경대학교 제어계측공학과 조교수. 2002년 3월~현재 : 연세대학교 전기전자공학부 조교수. 1998년~현재 : IEEE TFS, IEEE SMC, IEEE CAS, FSS등에서 심의위원으로 활동중. <주관심분야 : Computational intelligence, 로보틱스>



李 性 烈(正會員)

1996년 : 연세대학교 전자공학과 졸업(공학사). 1998년 : 동 대학원 전기컴퓨터공학과 졸업(공학석사). 2003년 : 동 대학원 전기전자공학과 졸업(공학박사). 2003년~현재 : 연세대학교 전자정보통신연구소 연구원. <주관심분야 : 비선형제어, 적응제어, 로보틱스>