

신경망 보상기를 이용한 PMSM의 간단한 지능형 장인 위치 제어

고종선, 윤성구, 이태호
원광대학교 전기-전자 및 정보 공학부

Simple AI Robust Digital Position Control of PMSM using Neural Network Compensator

Jong-Sun Ko, Sung-Koo Youn, Tae-Ho Lee

School of Electric-Electronic and Information Engineering, Wonkwang University

ABSTRACT

A very simple control approach using neural network for the robust position control of a Permanent Magnet Synchronous Motor(PMSM) is presented. The linear quadratic controller plus feedforward neural network is employed to obtain the robust PMSM system approximately linearized using field-orientation method for an AC servo. The neural network is trained in on-line phases and this neural network is composed by a feedforward recall and error back-propagation training. Since the total number of nodes are only eight, this system can be easily realized by the general microprocessor. During the normal operation, the input-output response is sampled and the weighting value is trained multi-times by error back-propagation method at each sample period to accommodate the possible variations in the parameters or load torque. And the state space analysis is performed to obtain the state feedback gains systematically. In addition, the robustness is also obtained without affecting overall system response. This method is realized by a floating-point Digital Signal Processor DS1102 Board (TMS320C31). The basic DSP software is used to write C program, which is compiled by using ANSI-C style function prototypes.

1. 서론

최근 산업용 응용 분야에서는 작고 강력한 구동기의 필요에 의해서 직류 전동기는 영구자석 동기 전동기로 대체 되어가고 있다. 영구자석 동기 전동기는 직류 전동기와 비슷한 속도-토오크 특성을 가지며, 더욱이 같은 출력을 갖는 직류 전동기와 비교해 낮은 관성률, 적은 잡음과 크기가 작아진다는 장점이 있다. 반면 비선형적 특성으로 복잡한 제어기가 필요하고, 가격이 비싼 단점을 가진다^[1]. 위치 제어에서 장인한 제어를 하기 위해서는 외부 외란을 빨리 제거해주는 것이 필요하게 되고, 장인 자기 동조 제어 방식이 제시되었으나^[2], 충분히 빠

른 적용을 나타내지는 못하고 있다. 최근 많은 응용 분야에서 인공 신경망을 사용하고 있는데, 그 중에 역전파 네트워크는 Werbos에 의해 제시되었고^[3], 교사 학습에서 다층 전향 네트워크를 사용하고 있다. 또한 비선형 시스템을 근사화시키는 성질은 제어 분야에서 신경망을 사용하는 중요한 이유가 되고 있다^[4]. 정밀 위치 제어를 위한 방법으로 적응형 외란 관측기의 적용은 만족한 결과를 얻었으나^[5], 이론이 어렵고 초기 적용 시간이 3분 정도 필요하였다. 따라서 본 논문에서는 매우 간단하며 수학적 접근이 적어 산업현장 인원이 매우 간단히 쓸 수 있는 제어기를 연구하였다. 선형 2차 제어(Linear Quadratic Control)를 기초한 추가된 상태 변수 제환 제어기를 기본 제어기로 사용하여 위치제어를 하였다. 특히 부하 변화에 장인한 제어를 위해서 신경망을 사용하여 정체화 보상하도록 하였다. 영구자석 동기 전동기의 비선형 특성은 AC 전동기의 벡터 제어 방법인 자속 기준 제어(Field-Oriented Control)를 사용해 선형화하였다^[6]. 실험은 계산 시간을 줄이고, 실시간 제어를 위해서 TMS320C31 프로세서를 내장한 DS1102 보드를 사용하였다.

2. PMSM의 수학적 모델

영구자석 동기 전동기는 비선형적 특성을 나타내는데, AC 전동기의 벡터 제어 방법인 자속 기준 제어 의해 i_{ds} 를 0으로 만들 수 있고^[6], 영구자석 동기 전동기의 선형화된 시스템 방정식은 다음과 같이 된다^[6].

$$\dot{\omega}_r = \frac{3}{2} \frac{1}{J} \left(\frac{p}{2} \right)^2 \lambda_m i_{qs} - \frac{B}{J} \omega_r - \frac{p}{2J} T_L \quad (1)$$

$$T_e = \frac{3}{2} \frac{p}{2} \lambda_m i_{qs} = k_t i_{qs} \quad (2)$$

$$\dot{y} = \omega_r \quad (3)$$

p :극 수	T_L :부하 토크
J :관성	T_e :전동기 토크
B :침성마찰계수	i_{qs} :q-상 고정자 전류
k_t :토오크 상수	ω_r :회전자 각속도
λ_m :자속	

여기서 $k_i = \frac{3}{2} \left(\frac{p}{2} \right) \lambda_m$ 으로 토오크 상수이다. 자속 기준의 실현을 위해서는 각 3상의 전류 명령치는 각각 분리해서 생성되어야 하며 이는 회전자 기준 제어 전류 명령치를 고정자 기준으로 바꿔서 구할 수 있다. 각 상의 전류 명령치 i_{ac} , i_{bc} , i_{cc} 는 Current Regulated PWM (CRPWM)을 따르고 있다^[6]. 이 경우 전류 제어기는 회전자의 절대 위치를 필요로 하게 된다.

3. 제어 알고리즘

3.1 위치 제어기

본 논문에서 추적 제어기의 목표 값은 계단 함수를 사용하였고, 일반적으로 시스템 방정식은 다음과 같다.

$$\dot{x}(t) = Ax(t) + bu(t) \quad (4)$$

$$y(t) = cx(t) \quad (5)$$

여기서 행렬 A , b , c 는 $n \times n$, $n \times 1$, $1 \times n$ 행렬이다. 일반적으로 선형 2차 제어기는 상태 변수를 궤환해서 레귤레이터 문제를 푸는데 사용한다. 서보 문제를 풀기 위해 새로운 상태 $\dot{z} = y - y_r$ 를 정의하고, 추가된 상태변수를 포함하여 최적제어를 구현하면 이것은 추적 제어기가 된다. 여기서 y_r 은 회전자 위치의 목표 값이고, 제어 입력은 다음과 같다.

$$u = -kx - k_1 z \quad (6)$$

여기서 k 는 $1 \times n$ 벡터이고, k_1 은 스칼라 양이다. 위와 같은 제어기는 실제 값을 알 수 없고, 찾아내기 어려운 외란의 영향에 의해서 생기는 정상 상태 오차(Steady State Error)를 줄이는데 사용하고 있고, 위의 폐루프 시스템이 점근적으로 안정하다면, 전체 시스템은 파라미터 변화나 궤환 이득 변화에 강인한 시스템이 된다^[5]. 영구자석 동기 전동기의 위치 제어를 위한 추가된 상태 시스템은 다음과 같다.

$$\begin{bmatrix} \dot{\omega}_r \\ \dot{y} \\ \dot{z} \end{bmatrix} = \begin{bmatrix} -\frac{B}{J} & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} \omega_r \\ y \\ z \end{bmatrix} + \begin{bmatrix} k_i \frac{p}{2} \frac{1}{J} \\ 0 \\ 0 \end{bmatrix} i_{qs} - \begin{bmatrix} \frac{p}{2} \frac{1}{J} \\ 0 \\ 0 \end{bmatrix} T_L - \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} y_r \quad (7)$$

$$y = [0 \ 1 \ 0] \hat{x} \quad (8)$$

위 시스템의 가제어성 행렬의 계수는 3이므로, 제어 가능하다. 강인한 제어를 위해 외란에 의한 오차를 빨리 줄이려면 아주 큰 궤환 이득이 필요하게 되고, 이는 모든 동작에서 아주 큰 전류 명령치를 생성하게 된다. 이러한 이유에서 전체 시스템에 영향을 주지 않고 과도 상태에서 외란의 영향을 줄일 수 있는 새로운 알고리즘이 필요하다.

3.2 제안한 신경망과 알고리즘

Hornick이 적용한 함수 근사화(Functional Approximation)의 방법으로 신경망의 응용은 다층 전방향 신경

망이 일반 근사기(Universal Approximator)로 사용되었다^[7]. 위 신경망의 특성은 알 수 없는 파라미터와 부하 변화에 의한 영향을 보상해주는 데 적당한 알고리즘이다. 정밀 위치 제어를 위해 적응형 외란 관측기의 적용은 이론이 어렵고 초기에 적응 시간이 3분 정도 필요하였다^[6]. 또한 PI 제어기나 추가된 상태 궤환에서 적분기는 위치 에러를 줄이기 위해서 시간 지연을 발생시킨다. 그러나 신경망은 위치, 목표 위치, 회전자 속도 등에서 시간 지연 없이 곧바로 그 동안 학습한 전류 입력을 연산할 수 있다. 그러나 빠른 보상을 위해서는 신경망의 학습 속도가 빨라야 한다. 그림 1은 추가된 상태 궤환을 기초로 많이 쓰이는 역전파 신경망(Back-Propagation Neural Network: BPNN)을 사용한 제어기를 나타낸다.

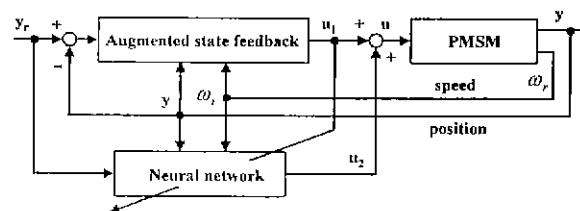


그림 1 추가된 상태 궤환을 사용한 신경망 위치 제어기의 블록도

본 논문에서 사용한 신경망 네트워크는 그림 2와 같으며, 그림에서 보는 바와 같이 다양한 상황을 학습시키기 위해 위치 y , 위치 목표 y_r , 위치와 위치 목표의 차 $y - y_r$, 속도 ω_r 를 신경망의 입력으로 선택하고 원하는 출력 u_1 을 통해 학습을 하였다. 입력 패턴은 출력이 생길 때까지 각 층으로 진행한다. 계산된 출력은 원하는 출력과 비교해서 오차 신호를 출력층에서 은닉층으로 역전파된다. 일반적으로 제어 입력이나 시스템 출력이 음과 양의 값을 가지고 있어서 다음과 같은 양극성 활성 함수를 사용하였다.

$$f(\text{net}_k) = \frac{2}{1 + \exp(-\lambda \text{net}_k)} - 1 \quad (9)$$

$$\text{net}_k = \sum_i w_{ki} y_i \quad (10)$$

위 식에서 λ 는 활성함수의 기울기이며, 본 논문에서는 간단히 λ 를 1로 선택하였다. 연결강도의 개선을 위해 델타 학습 규칙(Delta Learning Rule)을 사용하였으며, 학습 규칙은 실제 출력 o_k 와 원하는 출력 d_k 사이의 최소 자승 오차(Least Squared Error)를 기초하였다.

$$E = \frac{1}{2} \sum_{k=1}^n (d_k - o_k)^2 \quad (11)$$

j 번째 은닉층의 뉴런으로부터 k 번째 출력층의 뉴런 간의 연결강도를 W_{kj} 로 표기하고, 학습의 목적이 연결강도를 조정하여 오차 E 를 최소화하는 것이므로, 오차를 최소화하기 위해 연결강도를 음의 경사방향으로 변화시켜준다.

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} \quad (12)$$

여기서, η 는 학습률이다. 각 노드에서 뉴런의 출력값은 다음과 같이 된다.

$$o_k = f(\text{net}_k) \quad (13)$$

오차신호 δ 를 연쇄규칙(Chain Rule)을 사용해서 나타내면 다음과 같음이 잘 알려져 있다.

$$\delta_{ok} = -\frac{\partial E}{\partial net_k} = -\frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial net_k} \quad (14)$$

식 (27)에서 (32)의 수식을 통해서 오차 신호는 다음과 같이 주어진다.

$$\delta_{ok} = \frac{1}{2} (d_k - o_k)(1 - o_k^2) \quad (15)$$

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

$$w_{kj}(k+1) = w_{kj}(k) + \eta \delta_{ok} y_j \quad (16)$$

위 식에서 y_j 는 j -번쩨 층에서의 출력이다. 같은 방식으로 은닉층에서 오차신호는 다음과 같다.

$$\delta_{ij} = \frac{1}{2} (1 - y_i^2) \sum_{k=1}^n \delta_{ok} w_{kj} \quad (17)$$

은닉층에서 연결강도의 조정은 다음 식과 같이 된다.

$$w_{ji}(k+1) = w_{ji}(k) + \eta \delta_{ij} x_i \quad (18)$$

여기서 x_i 는 i -번쩨 층의 입력이다. 제안한 신경망은 그림 2와 같이 구성하고, 위치, 위치 목표, 속도, 위치 목표와 위치의 차, 추가된 상태 케환의 출력 u_1 을 입력으로 해서 신경망의 출력 u_2 를 생성하게 된다. 제어 입력 u 는 추가된 상태 케환에서 u_1 과 신경망의 출력 u_2 를 합해서 구하게 된다. 식 (2)에 의해 부하 토오크로 인한 등가 전류를 구할 수 있고, 신경망의 학습에 의해서 외란의 상황에 맞는 학습된 출력을 한 샘플링 시간(Sampling Time)에 계산하여 제어 신호를 보상 출력 하므로, 부하 토오크의 영향을 빠르게 줄일 수 있게 된다.

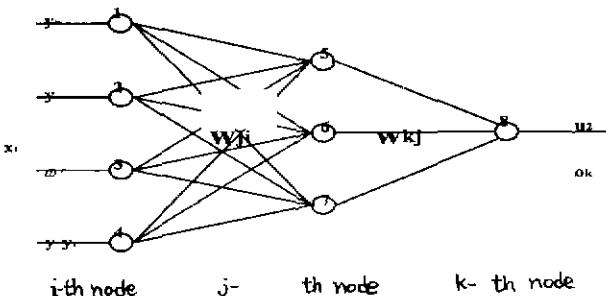


그림 2 오류 역전파를 사용한 제안한 신경망의 네트워크

4. 전체 시스템 구성

신경망 보상기를 이용한 지능형 장인 위치 제어기는 크게 두 부분으로 나누어진다. 한 부분은 디지털 제어기 부분으로 오류 역전파 학습을 하는 신경망과 최적 이론을 적용한 이득을 사용하는 추가된 상태 케환 제어기로 구성되어 외부 외란은 신경망에서 정제화 보상한다. 위치 제어기는 추가된 상태 케환을 포함하고 있는데, 평행사변형 방법에 의해서 근사화시켰다.

$$z(k+1) = z(k) + \frac{h}{2} \{ e(k) + e(k-1) \} \quad (19)$$

위 식에서 $e(k) = y(k) - y_r$ 이다. 나머지 부분은 전력 제어 부분으로 자속 기준 제어를 하고 있다. 전력 제어부는 2상-3상 변환기와 CRPWM 인버터를 포함하고 있다.

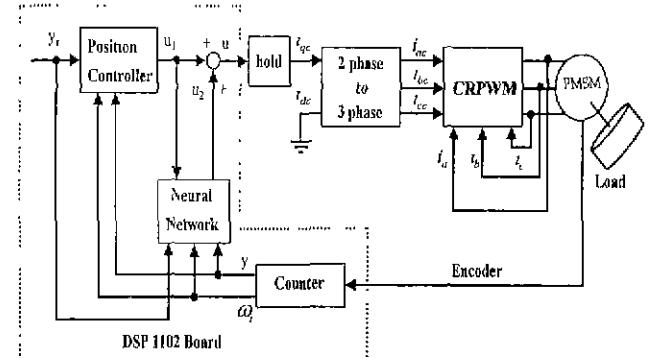


그림 3 제안한 위치 제어기의 블록선도

그림 3은 제안한 제어기의 블록선도를 나타내고 있다. 위의 제어기를 실제 구현함에 있어서 TMS320C31 프로세서를 사용하는 DSP1102 보드를 사용하였으며, C-언어를 사용하여 프로그램 하였다. 외부 외란의 빠른 보상을 위해서 한 샘플링 주기 동안에 3번의 학습을 하도록 하였으며, 프로그램에서 식 (9)의 양극성 활성 함수를 사용하였는데, DSP용 C-프로그램에서 지수 함수(Exponential Function) 표현의 어려움은 3차의 멱급수 함수를 이용하여 근사적으로 표현하였다.

$$e^x = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} \quad (20)$$

5. 실험 결과

실제 실험에서 사용한 영구자석 동기 전동기의 파라미터는 표 1과 같다.

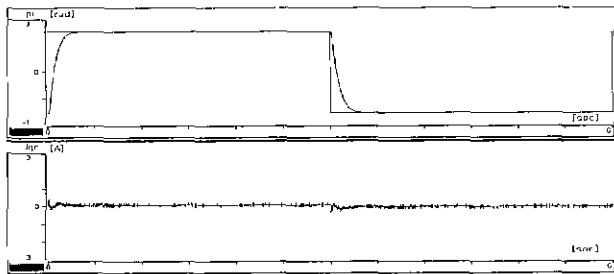
표 1 영구자석 동기 전동기의 파라미터

파라미터	값
전력	400 [watt]
관성	0.363×10^{-4} [kg m ²]
시정수	0.5 [ms]
정격 전류	2.7 [A]
정격 토오크	1.3 [Nm]
고정자 저항	1.07 [Ω/phase]
점성마찰계수	0.0725 [Kgm ² /sec]

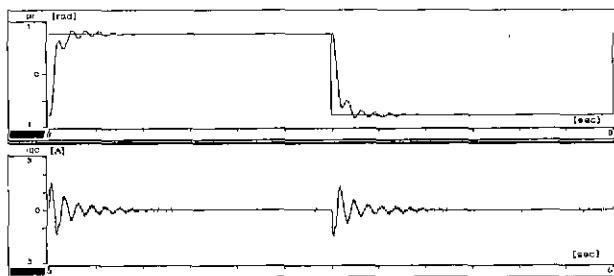
실험에서 사용한 샘플링 주기 Ts는 0.2 [ms]이다. 가중 행렬(Weighting Matrix)은 $Q = diag[0.1 80 30000]$, $R = 1$ 로 선택하고, 최적 이득 행렬을 구하면 $k = [0.0772 4.9762 62.4520]$ 이 된다. 또한 신경망 보상을 위해 사용한 역전파 알고리즘의 학습률은 0.55이다.

그림 4는 추가된 상태 케환만을 사용한 경우로 (b)에서는 관성 부하의 영향으로 위치 정보의 진동이 발생함을 볼 수 있다. 그림 5는 신경망 보상을 한 경우로 관성 부하에 의한 진동이 없어진 것을 볼 수 있다. 그림 4의 추가된 상태 케환 시스템에서는 관성 부하가 있는 경우에 1.5 [A]의 전류가 흐르는데, 신경망 보상한 경우의 그림 5에서는 최대 2.5 [A]의 전류가 흐르면서 학습된 상황에 따라서 외부 외란의 영향을 줄이고 있음을 알 수가 있다. 그림 6은 실험 결과에서 두 시스템의 성능 비교를 위해 확대한 그림으로 스케일은 0.2 [rad]으로 부

하가 있는 경우에 추가된 상태 변수 궤환만을 사용한 경우에는 0.136 [rad] 정도의 오차가 발생하고 있으나, 부하의 영향을 신경망을 사용해서 보상한 경우에는 거의 위치 오차가 발생하지 않음을 볼 수 있다.

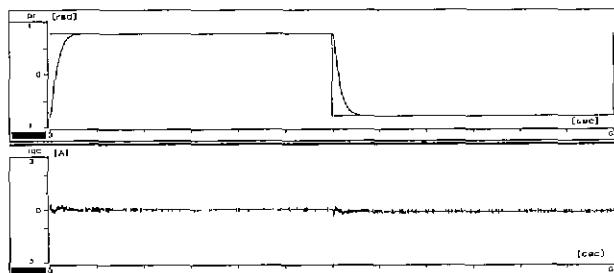


(a) 추가된 상태 궤환 (부하가 없는 경우)

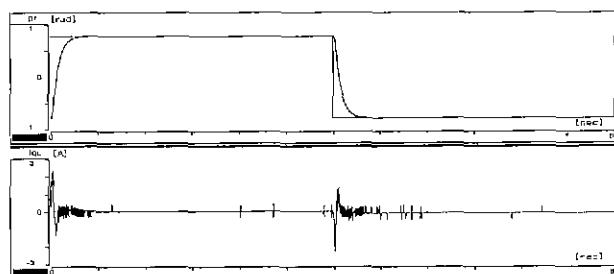


(b) 추가된 상태 궤환 (부하가 있는 경우)

그림 4 추가된 상태 궤환에서 실험 결과
(회전자 위치와 q-상 전류 명령)



(a) 신경망 보상 (부하가 없는 경우)



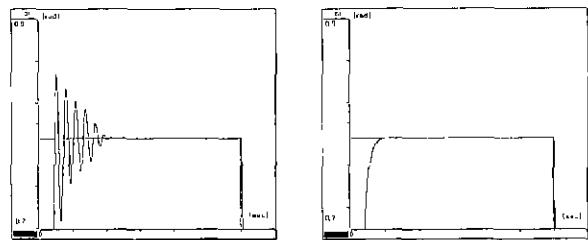
(b) 신경망 보상 (부하가 있는 경우)

그림 5 신경망 보상에서 모의 실험 결과
(회전자 위치와 q-상 전류 명령)

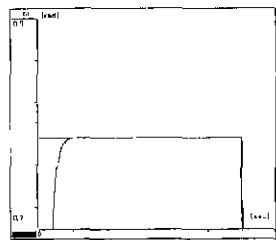
6. 결론

본 논문에서는 외란에 강인한 정밀 위치 제어 방법으로 매우 간단한 신경망에 의한 보상을 제시하였다. 기본

제어기로 사용한 추가된 상태 변수 궤환 시스템은 디지털 제어기에서 최적 이득을 사용하였으며, 외부 외란을 시간 지연 없이 직접 신경망에 의해서 정궤환하여 보상해주는 시스템이다. 위의 시스템은 계산 시간을 줄이고 실시간 제어를 위해 DS1102 (TMS320C31) 보드를 이용해 z-domain에서 최적 이득을 사용하여 구현하였으며, TI용 C-언어를 사용해서 프로그램 하였다. 프로그램에서 각 뉴런의 출력을 결정하는 활성 함수를 사용함에 있어서 지수 함수 사용상의 어려움은 3차의 멱급수 함수를 이용하였다. 정밀 강인 위치 제어를 위해서 역전파 알고리즘을 사용하였으며, 역진파 학습은 한 샘플링 주기 동안에 3번 정도의 반복 학습을 하도록 하였다. 본 시스템의 안정성을 실제 실험을 통해서 보였으며, 빠른 보상이 필요한 정밀 강인한 시스템에서 과도 응답 없이 제어가 가능함을 보였다. 또한 제안된 시스템은 매우 간편하게 기존 제어기에 프로그램을 이식하여 구현할 수 있다.



(a) 추가된 상태 궤환



(b) 신경망 보상

그림 6 추가된 상태 궤환과 신경망 보상의 성능 비교
(부하가 있는 경우)

참 고 문 헌

- [1] Paul C. Krause, *Analysis of Electric Machinery*, McGraw-Hill, 1984.
- [2] K. Furuta, K. Kosuge, and H. Kobayashi, "VSS-Type Self-Tuning Control of Direct-Drive Motor", *Proc. of IECON 89*, pp. 281-286, 1989.
- [3] P. Werbos, "Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences", *PhD Thesis. Harvard, Cambridge, MA*, August, 1974.
- [4] Chen, F. "Back-Propagation Neural Networks for Nonlinear Self-Tuning Adaptive Control", *IEEE Control System Magazine*, April, 1990.
- [5] Jong-Sun Ko, Sung-Koo Youn, and Bimal K. Bose, "A Study on Adaptive Load Torque Observer for Robust Precision Position Control of BLDC Motor" *Proc. of the 25th Annual Conference of the IEEE Industrial Electronics Society (IECON'99)*, pp. 1091-1096, October, 1999.
- [6] D.W. Novotny and R.D. Lorentz, *Introduction to Field Orientation and High Performance AC Drives, IAS-Tutorial Course*, 1988.
- [7] Hornick K., Stinchcombe M., and White H., "Multi-layer Feedforward Networks are Universal Approximators", *Neural Networks*, Vol. 2, 1989.