

영구자석 동기모터를 위한 CTRNN모델 기반 적응형 PI 제어기 설계

Adaptive PI Controller Design Based on CTRNN for Permanent Magnet Synchronous Motors

김 일 환*
(Il-Hwan Kim)

Abstract - In many industrial applications that use the electric motors robust controllers are needed. The method using a neural network in order to design a robust controller when a disturbance occurs is studied. Backpropagation algorithm, which is used in a conventional neural network controller is used in many areas, but when the number of neurons in the input layer, hidden layer and output layer of the neural network increases the processing speed of the learning process is slow. In this paper an adaptive PI(Proportional and Integral) controller based on CTRNN(Continuous Time Recurrent Neural Network) for permanent magnet synchronous motors is presented. By varying the load and the speed the validity of the proposed method is verified through simulation and experiments.

Key Words : LPF, PMSM, Current control, Permanent magnet Synchronous motor, VCF, Cutoff frequency

1. 서 론

최근 급격하게 변화하는 산업현장에서는 구조가 간단하고 특성이 강인한 PI 제어기가 많이 이용되고 있다[1]. 하지만 시스템이 점점 복잡해지고 정교해짐에 따라 에너지 변환장치로서 전동기의 사용이 점점 증가함에 따라 전동기의 외란의 대한 강인함에 대한 요구가 점점 커지고 있으며 생산 공정에서의 전동기의 외란에 따른 오류가 생산성의 저하를 초래할 뿐 아니라 고장이 발생한 시스템에서의 안정성이 위협받기에 강인한 제어기의 필요성이 커지고 있다[2].

한편, 최근 인공 신경망 등에 의한 실시간 검출 진단 기법에 대한 연구가 증가되고 있다. 신경망의 학습에 이용되고 있는 역전파 알고리즘은 여러 분야에서 응용되고 있지만 신경망의 입력층, 은닉층 그리고 출력층의 뉴런수가 증가하면 학습과정의 연산속도가 늦어지고, 부분 최소점에 빠질 수 있고, 연결강도의 초기치나 학습율에 민감하게 반응하며 그리고 주어진 입력과 출력 데이터를 기본으로 학습하기 때문에 새로운 입력 데이터에 대해서 정밀성을 보장할 수 없는 문제점이 있다[2].

본 논문에서는 이러한 기존의 신경망에서의 문제점을 보완하기 위해서 연속 시간 회귀 신경망 (Continuous Time Recurrent Neural Network) 모델을 이용하는 기존의 신경망 기법에 적용한

신경망으로 설계하여 강인한 PI 제어기가 되도록 하였다. 이 제어기를 Matlab Simulink을 통한 시뮬레이션과 실제 시스템에 적용하여 그 타당성을 검증 하였다.

2. 시스템의 구성

2.1 PMSM (Permanent Magnet Synchronous Motor)

계자용 영구 자석이 고정자에, 전기자 권선이 회전자에 배치되어 브러시와 정류자에 의한 기계적 정류작용으로 전기자가 회전하는 직류 전동기와 달리 PMSM은 영구자석을 회전자에, 전기자 권선을 고정자에 배치하여 기계적 정류 작용을 반도체의 스위칭 작용으로 대신한 구조를 가지고 있다[3].

PMSM의 전압 방정식은 전동기가 정지하고 있는 경우를 제외하고 시변 계수를 갖는 미분 방정식(time varying differential equation)으로 표현된다. 이러한 시변 계수를 갖는 미분 방정식의 해석은 쉽지 않다.

전형적인 역기전력을 갖는 영구자석 동기전동기의 고정자 권선은 동일한 권선수로 전기각 120° 의 대칭구조를 갖고 있어 각 상에서 발생하는 자속은 다른 상에 $1/2$ 씩 쇄교하게 된다. 각 고정자 자기 인덕턴스는 누설 자속 쇄교 수들의 조합에 의존하고 자속 쇄교 수들은 고정자 위상들을 동등하게 공유하게 되며, 상호 인덕턴스는 회전자 위치와 독립된 변수로 취급할 수 있다. 고정자 권선은 a, b, c 로 표시되어 있으며, R_s 는 권선의 저항, L_s 는 권선의 누설 인덕턴스, M 은 권선 사이의 상호 인덕턴스이다. 여

* Corresponding Author : Dept. of Electrical and Electronic Engineering, Kangwon National University, Korea

E-mail : ihkim@kangwon.ac.kr

Received : July 7, 2015; Accepted : January 27, 2016

기서 고정자 권선 a, b, c 에 V_{as}, V_{bs}, V_{cs} 의 전압이 인가될 때 주어진 변수들로 전압방정식은 식 (1)과 같다[4].

$$\begin{bmatrix} V_{as} \\ V_{bs} \\ V_{cs} \end{bmatrix} = \begin{bmatrix} R_s + \frac{d}{dt}(l_s + M) & -\frac{1}{2} \frac{d}{dt} M & -\frac{1}{2} \frac{d}{dt} M \\ -\frac{1}{2} \frac{d}{dt} M & R_s + \frac{d}{dt}(l_s + M) & -\frac{1}{2} \frac{d}{dt} M \\ -\frac{1}{2} \frac{d}{dt} M & -\frac{1}{2} \frac{d}{dt} M & R_s + \frac{d}{dt}(l_s + M) \end{bmatrix} \begin{bmatrix} i_{as} \\ i_{bs} \\ i_{cs} \end{bmatrix} + \begin{bmatrix} e_{as} \\ e_{bs} \\ e_{cs} \end{bmatrix} \quad (1)$$

여기서 e_{as}, e_{bs}, e_{cs} 는 회전자에 의한 역기전력이며 i_{as}, i_{bs}, i_{cs} 는 각 권선에 흐르는 상전류이다. 일반적으로 위의 전압방정식은 $i_{as} + i_{bs} + i_{cs} = 0$ 이라는 조건을 이용하여 간단히 나타낼 수 있으며, 이는 다음 식 (2)와 같이 간략히 표현된다.

$$\begin{bmatrix} V_{as} \\ V_{bs} \\ V_{cs} \end{bmatrix} = \begin{bmatrix} R_s + \frac{d}{dt}(l_s + \frac{3}{2}M) & 0 & 0 \\ 0 & R_s + \frac{d}{dt}(l_s + \frac{3}{2}M) & 0 \\ 0 & 0 & R_s + \frac{d}{dt}(l_s + \frac{3}{2}M) \end{bmatrix} \begin{bmatrix} i_{as} \\ i_{bs} \\ i_{cs} \end{bmatrix} + \begin{bmatrix} e_{as} \\ e_{bs} \\ e_{cs} \end{bmatrix} \quad (2)$$

각 상의 유기기전력 e_{as}, e_{bs}, e_{cs} 는 각 상 권선에 쇄교되는 자속의 미분 향으므로 a, b, c 상 권선 쇄교 자속 수 Φ_a, Φ_b, Φ_c 의 최대치를 Φ_f 라고 하면 각각의 표현은 식 (3)과 같다.

$$\begin{aligned} \Phi_a &= \Phi_f \cos \theta_e \\ \Phi_b &= \Phi_f \cos(\theta_e + \frac{2\pi}{3}) \\ \Phi_c &= \Phi_f \cos(\theta_e - \frac{2\pi}{3}) \end{aligned} \quad (3)$$

여기서 θ_e 는 a상 전기자 권선을 기준으로 반 시계 방향으로 회전한 계자의 전기 각이며, 전기 각속도와 $\theta_e = \int \omega_e dt$ 과 같은 관계가 있다. 따라서 e_{as}, e_{bs}, e_{cs} 는 식 (4)와 같다.

$$\begin{aligned} e_{as} &= -\omega_e \Phi_f \sin \theta_e \\ e_{bs} &= -\omega_e \Phi_f \sin(\theta_e + \frac{2\pi}{3}) \\ e_{cs} &= -\omega_e \Phi_f \sin(\theta_e - \frac{2\pi}{3}) \end{aligned} \quad (4)$$

따라서 d-q축 변환이라 하는 좌표 변환 기법을 적용하는데 이는 abc 3상의 시변미분방정식인 PMSM 모델은 d-q축 좌표계로 변환하여 해석한다. d-q축 변환을 통해 고정자에 정지되어 있는 3상 변수들이 회전자와 동기속도로 회전하는 d-q축으로 이루어진 직교 좌표계의 값으로 변환되는데 이에 의해 시변계수가 제거되어 일정한 계수를 갖는 시 불변 미분 방정식으로 전환된다. d-q동기좌표계에서는 PMSM을 마치 직류 전동기와 같이 용이하게 제어 할 수 있어 고성능의 빠른 응답 특성을 얻을 수 있다. 따라서 좌표변환은 PMSM의 벡터제어에 필수적 사항이다[1].

$$f_{dq}^e = T(\theta) f_{abc}$$

$$T(\theta) = \frac{2}{3} \begin{bmatrix} \cos \theta & \cos(\theta - \frac{2}{3}\pi) & \cos(\theta + \frac{2}{3}\pi) \\ -\sin \theta & -\sin(\theta - \frac{2}{3}\pi) & -\sin(\theta + \frac{2}{3}\pi) \end{bmatrix}$$

$$f_{abc} = T(\theta)^{-1} f_{dq}^e$$

$$T(\theta)^{-1} = \begin{bmatrix} \cos \theta & -\sin \theta \\ \cos(\theta - \frac{2}{3}\pi) & -\sin(\theta + \frac{2}{3}\pi) \\ \cos(\theta + \frac{2}{3}\pi) & -\sin(\theta + \frac{2}{3}\pi) \end{bmatrix} \quad (5)$$

고로, 영구자석 동기전동기의 d-q축 좌표계에서의 전압방정식을 구하면 다음의 식 (6)과 같다.

$$\begin{bmatrix} V_{ds} \\ V_{qs} \end{bmatrix} = \begin{bmatrix} (R_s + \frac{d}{dt} L_s) & 0 \\ 0 & (R_s + \frac{d}{dt} L_s) \end{bmatrix} \begin{bmatrix} i_{ds} \\ i_{qs} \end{bmatrix} + \begin{bmatrix} e_{ds} \\ e_{qs} \end{bmatrix} \quad (6)$$

2.2 인지 제어 신경망 PI 제어기의 구현

2.2.1 인공신경망 (Artificial Neural Network)

신경망 연구의 목적은 인간에 가까운 능력을 가진 정보처리 시스템을 근접하게 실현하는 것이다. 신경망은 순차적인 컴퓨터와 달리 인간의 뇌와 유사하게 지식 표현과 정보처리를 병렬적으로 수행하는 병렬 연산 모델로서 그 활용 분야가 넓다. 현재 여러 분야에서 신경망의 특성을 이용하는 연구가 활발히 진행되고 있다[5].

신경망의 구조는 인간의 신경 조직과 비교해 볼 수 있다. 조직은 뉴런이라는 수많은 신경세포들의 집합체인데, 이들 각각의 신경세포들은 수상 돌기를 통해 외부에서 오는 여러 자극을 받아들이고 이 자극을 적절히 처리한 신호를 축색돌기를 통해 전달하게 된다. 마지막으로 시냅스라는 것을 통해 다음 뉴런의 수상돌기에 정보를 전달하게 된다[6].

마찬가지로 신경망에서는 인공 뉴런(artificial neuron, 마디)이라고 불리는 기본 소자들이 신경 세포와 같은 역할을 하게 되며 이것들은 그물망처럼 서로 연결되어 신경망을 이루게 된다. 그림 2는 마디의 구조를 나타낸 것이다. 외부로부터 값을 받으면 각각의 값들은 연결된 가중치와 곱한 뒤 모두 합한다. 더해진 값은 활성화함수(activation function)를 통해 변환된다.

다층 신경망은 입력 층과 출력 층 사이에 하나 이상의 중간층이 존재하는데, 이때의 중간층을 은닉 층이라 부른다. 망은 입력 층, 은닉 층, 출력 층으로 방향으로 연결되어 있으며 각 층 내의 연결과 출력 층에서 입력 층으로의 직접적인 연결은 존재하지 않는 전 방향(feedforward)의 망이다.

다층 신경망은 단층 신경망과 유사한 구조를 가지고 있지만 은닉 층과 각 마디의 입력력 특성을 활성화 함수를 사용하여 비선형으로 함으로써 신경망 능력을 향상시켜 단층 신경망의 여러 가지 단점을 극복했다. 다층 신경망에서 주로 사용되는 활성화함수




그림 1 신경망 (Neuron)의 구조
Fig. 1 The structure of the neural network

로는 Sigmoid 함수, hyperbolic tangent 함수 등의 비선형 함수를 사용한다. 다층 신경망은 이론적으로 가장 단순한 신경망이며, 일반화 성능이 뛰어나고 정확도나 수렴도 등에서 매우 안정적이어서 그 사용 범위가 넓다[6].

다층 신경망의 학습 방법으로 주로 사용되는 역전파 알고리즘은 신경망의 지도학습 방법과 같이 출력 값과 목표 값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조절하고, 상위 층에서 역전파하여 하위 층에서는 이를 근거로 다시 하위 층의 연결강도를 조정해 나간다. 역전파 학습 알고리즘의 단점 중 하나는 지역 최소 값에 빠질 염려가 있다는 것이다. 이를 개선하기 위한 많은 연구가 이루어져 있지만 아직 완벽한 방법은 존재하지 않는다. 그리고 일반적으로 학습이 완료되기까지 많은 회수의 반복학습이 필요하며 학습파라미터(parameter)의 조절이 필요하다는 단점이 있다. 또한 학습과정이 수렴하기까지 많은 양의 학습 데이터를 필요로 하고, 기억된 패턴의 수정, 추가학습 등이 불가능하다.

신경망의 설계란 신경망의 구조를 결정하는 것으로 은닉층의 마디의 수, 은닉층의 수, 활성화함수, 초기 연결강도, 학습에러, 학습상수, 모멘텀 등의 변수가 적용 가능하다. 다층 신경망의 학습 능력은 은닉층에 의해 형성되므로 주어진 문제에 적절한 크기의 신경망을 설계하는 것이 매우 중요하다. 따라서 이에 대한 많은 연구가 이루어지고 있다[7].

그러나 신경망에 대한 현재까지의 많은 연구에도 불구하고 해당 문제에 대한 적절한 은닉층이나 은닉마디의 수를 결정할 수 있는 만족할 만한 결론적인 방법은 아직까지 존재하지 않으며, 가장 확실한 방법은 은닉층과 은닉 마디의 수를 변화시켜 가면서 많은 시행착오를 통해 직접 확인하는 방법이다. 활성화함수는 은닉층과 출력층에 제시되는 값을 변형시켜 출력하는데 사용하는 함수이다. 신경망에서 주로 사용되는 활성화 함수에는 각 변수들을 [0, 1]의 범위로 변환하는 Sigmoid 함수, [-1, 1]로 변환하는 Hyperbolic Tangent 함수 등 여러 가지가 있으나 다층 신경망에서 활성화 함수로서 Sigmoid 함수를 가장 많이 사용하고 있다.

이러한 인공신경망의 장점으로는 첫째, 계량적인 변수뿐만 아




그림 2 Sigmoid 함수와 Hyperbolic Tangent 함수
Fig. 2 Sigmoid function and Hyperbolic Tangent function

니라 정성적인 변수도 동시에 고려할 수 있다. 둘째, 결점 허용 시스템(fault-tolerant system)에 의해 데이터의 잡음(noise)에 대해 대처할 수 있는 기능적 특성이 있다. 셋째, 기존의 통계적 방법과는 달리 여러 가지 통계적 가정을 필요로 하지 않기 때문에 자료의 특성을 마음대로 활용할 수 있다. 넷째, 신경망은 결과 값을 직교 블록 범위 안에 제한시키지 않기 때문에, 비선형(non-linear)의 문제를 해결할 수 있다는 장점이 있다.

한편, 인공신경망 모델의 가장 큰 문제점으로 지목되는 것이 바로 모델의 설명력(explanation)이다. 즉 모델이 어떻게 만들어졌고 예측 변수들이 어떻게 예측 결과에 영향을 미치는가를 알 수 없다는 것이다. 신경망 또한 다른 예측모델 구축기법들과 마찬가지로 모델의 과적응(over-fitting)을 줄이는 노력이 필요하다. 보편적으로 신경망은 주어진 훈련 집합에 대하여 임의의 결과 값에 수렴하고, 이 때 얻어진 결과 값이 최선의 자료 모형을 제시한다는 보장이 없다.

2.2.2 연속 시간 회귀 신경망 PI 제어기의 구성

인간의 인지적 행동들은 계층적 제어시스템에 기반하고 있다는 것은 잘 알려진 뇌 과학 분야의 연구 결과이다. 재사용이 가능한 단위 행동들은 결합하여 복잡한 행동들을 구성하고 이러한 단위 행동들의 재현과 단위행동들의 결합방식은 환경의 변화에 밀접하게 연관되어 수행된다[5].

이러한 특성은 돌발적인 환경의 변화에 적절히 대응할 수 있도록 하는 필수적 요소이다. 한편 뇌가 불확실성이 포함된 상황에서 수행하는 인식과 행동의 패턴은 베이지안 이론에 가깝다는 베이지안 브레인 이론이 있다, 결국 베이지안 브레인이란 뇌에 의해서 예측한 센서 정보가 실제로 획득한 센서정보의 차이를 최소화 하도록 뇌가 시냅스를 조정하여 내재적 표현(internal representation)을 수정하는 것이라고 주장하고 있다[8, 9].

인공신경망 모델에 기반 한 여러 인지 제어 연구 중에서 위에서 언급한 바와 같은 뇌과학 연구에 동기부여 됐을 뿐만 아니라 기존의 유사한 연구들과는 다른 특성을 나타내고 있다. 기존의 유사 연구들이 설계에 의한 명시적 계층구조를 사용하거나 단위 행동을 결합하기 위한 인공신경망 이외의 추가적인 모듈을 사용하는 것과는 달리 하나의 인공신경망이 자기조직화를 통해서 계층을 생성하고 환경변화에 대해서 적절한 인지 제어를 할 수 있

는 모델을 제안하였다[10].

제안된 모델은 CTRNN에 기반하고 있다. CTRNN은 미분방정식으로 표현되는데 각 뉴런의 발화는 현재 시간의 입력 값과 이전 시간에서의 뉴런들의 상태에 의해서 결정된다. 따라서 CTRNN은 RNN과 함께 주로 시간적으로 연속된 정보를 모델링하기 위해 사용된다.

앞에서 논의한 인공지능경망에서의 단점을 개선하기 위해 본 논문에서는 연속 시간 재발 성 신경 네트워크 (CTRNN)을 제시한다.

CTRNN은 신경 세포의 동적 시스템 모델이다. CTRNN는 착신의 신경 세포에 대한 효과를 모델링 상미 분 방정식들의 시스템을 사용하며 세밀한 수준에서 신경 활성화를 모델링하지 않는 한 직접 네트워크에 있는 관련 신경망 시뮬레이션 보다 효율적이다[3]. 이 CTRNN의 방정식은 식 (7)과 같다.

$$\tau_i \frac{dy_i}{dt} = -y_i + \sum_{j=1}^n w_{ji} \sigma(y_j - \theta_j) + I_i(t) \quad (7)$$

- τ_i 노드 i번째 뉴런의 시간상수
- y_i 노드 i 번째 뉴런의 상태
- w_{ji} j번째 뉴런에서 i번째 뉴런의 Weight Factor
- θ_j j번째 뉴런의 바이어스 값
- $\sigma(X)$ logistic sigmoid function

sigmoid 함수의 수식은 식 (8)과 같이 표현 된다.

$$\sigma(X) = \frac{1}{1 + e^{-x}} \quad (8)$$

이 CTRNN의 수식을 구성도로 변환 시키면 그림 3과 같다. CTRNN을 적용한 PI제어기 구성도는 그림 4와 같다.

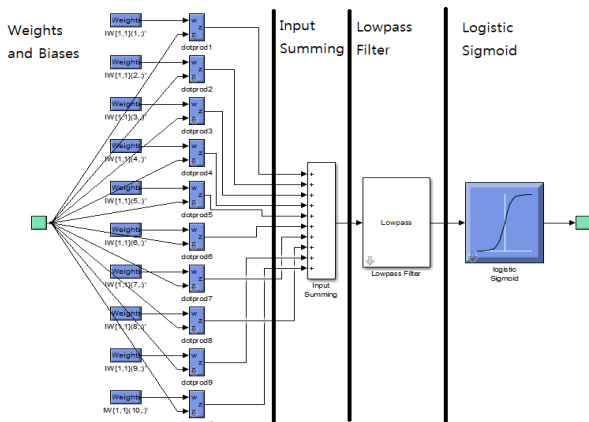


그림 3 CTRNN 신경망 구성도
Fig. 3 CTRNN Neural Network Diagram




그림 4 CTRNN PI 제어기의 구성도
Fig. 4 CTRNN PI controller diagram

3. 시뮬레이션

Matlab/simulink 상에서 CTRNN PI 제어기와 이를 시뮬레이션하기 위해 PMSM의 수학적 모델인 식 (6)을 사용하였다. 또한 외부에서의 외란은 Gaussian Noise Generator로 발생시켰으며 그림 5는 simulation 모델이다.

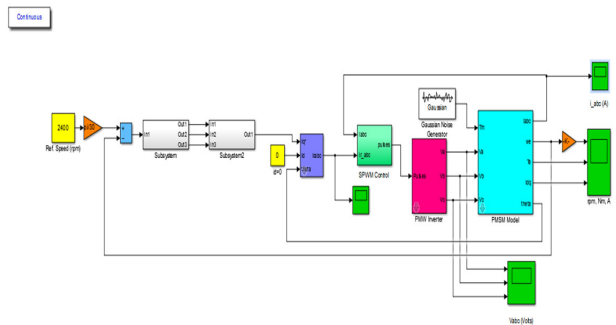


그림 5 CTRNN PI 제어기의 시뮬레이션 모델
Fig. 5 CTRNN PI controller simulation model

그림 6은 1200RPM을 입력 시 기존의 인공지능경망 제어기와 CTRNN을 적용한 제어기의 속도와 토크의 시뮬레이션 결과를 보여주고 있는데 제안한 제어기의 결과가 기존의 제어기보다 높은




그림 6 인공지능경망 제어기와 CTRNN 적용 제어기 시뮬레이션 결과 (1200RPM)
Fig. 6 Simulation results of Artificial NN and CTRNN controllers (1200RPM)

적응력을 가지고 강인한 제어하는 것을 보여주고 있다. 상기 그림에서 편차의 평균값은 인공신경망 PI 제어기는 4.2176, CTRNN 적응 PI 제어기는 3.5876으로 편차치 또한 성능 대비 우수성을 확인할 수 있다. 그림 7과 8은 그림 6의 P gain 값 및 I gain 값의 변화이다.




그림 7 CTRNN 적응 PI제어기의 P gain 값 (1200rpm)
Fig. 7 P gains of CTRNN PI controller




그림 8 CTRNN 적응 PI제어기 I gain 값 (1200rpm)
Fig. 8 I gains of CTRNN PI controller

그림 9는 2400RPM을 입력 시 기존의 인공신경망 제어기와 CTRNN을 적용한 제어기의 속도 및 토크의 시뮬레이션 결과를 보여주고 있는데 제안한 제어기의 결과가 기존의 제어기보다 높은 적응력을 가지고 강인한 제어하는 것을 보여주고 있다. 편차의 평균값은 인공신경망 PI 제어기는 12.4451, CTRNN 적응 PI




그림 9 인공신경망 제어기와 CTRNN 적응 제어기의 시뮬레이션 결과 (2400RPM)
Fig. 9 Simulation results of Artificial NN and CTRNN controllers (2400RPM)

제어기는 11.1788으로 속도가 2배인 경우에도 편차치 또한 성능 대비 우수성을 확인할 수 있다.

4. 실험

4.1 실험 시스템 구성

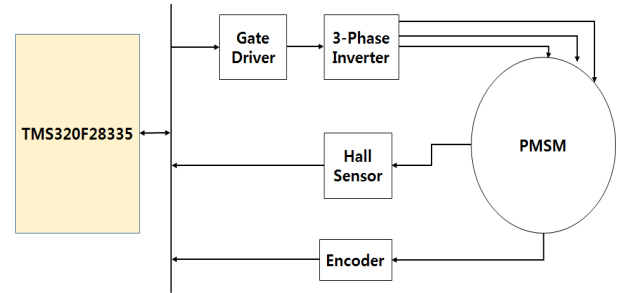


그림 10 실험 시스템 구성도
Fig. 10 Experimental System

본 논문에서 제안한 CTRNN모델 기반 PI 적응제어기의 성능 개선 여부의 확인을 위해 구성된 실험 시스템의 구성도는 그림 10과 같다.

실험시스템은 Ti사(Texas instrument)의 TMS320F28335를 사용하여 구현하였으며 실험에 사용된 전동기는 26W급 8pole PMSM이며 상세 사양은 다음 표 1과 같다.

표 1 실험에 사용된 PMSM의 사양
Table 1 The specification of PMSM

모터	사양	엔코더	사양
Motor Form.	P.M. 8Poles, 3Ph. Y-Connect	Rated Voltage	DC 5V
Voltage	DC 24V	Resolution	2,000 C/T
Rated Current	2.9A	Outputs	A, B, Z(Index)
Rated Power	26W		
Rated Speed	4,000RPM		
Rated Torque	0.062N.m (0.63kgf*cm)		
Max. Torque	0.185N.m (1.89kgf*cm)		
Stall Torque	0.062N.m (0.63kgf*cm)		
No Load Speed	5,000RPM		
Rotor Moment of Inertia	0.004gf*cm*s ²		
Mounting Flange	Φ 22		
Approximate Mass	190g		
No Operating Temp. Range	-10°C ~ +85°C		
Operating Temp. Range	0°C ~ +40°C		

4.2 실험 결과

4.2.1 저속 영역

그림 11에 본 논문에서 구성한 실험 시스템에서 일반적인 PI

제어기의 무부하시와 부하시의 엔코더를 통해 얻은 전동기의 속도를 나타낸다.




그림 11 일반적인 PI 제어기의 무부하 및 부하 실험 결과 (1200RPM)

Fig. 11 Experimental results of a normal PI controller with no load and load (1200RPM)




그림 12 인공신경망 제어기 및 CTRNN 적응 제어기의 실험 결과 (1200RPM)

Fig. 12 Experimental results of Artificial NN and CTRNN controllers (1200RPM)

그림 12에 부하시의 기존의 인공신경망 제어기와 CTRNN 적응 제어기를 적용시켜 엔코더를 통해 얻은 전동기의 속도를 측정 한 결과를 나타낸다.

그림 11에서 일반적인 제어기의 속도출력은 부하시의 적응하

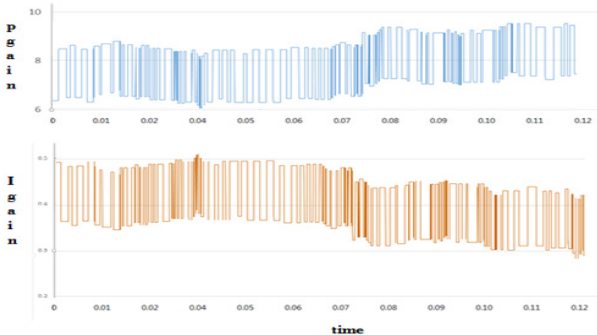


그림 13 CTRNN 적응 제어기 PI gain 값 (1200RPM)

Fig. 13 PI gains of CTRNN controller (1200RPM)

지 못하고 변화하는 것을 알 수가 있으나, 그림 14에서 인공신경망 제어기와 CTRNN 적응 제어기의 속도는 부하에 적응하여 PI gain값이 변화하여 강인하게 대응하는 것이 확인 가능하다. 하지만 인공신경망 PI제어기에서는 적응하는 모습을 보이나 빠르게 대처하는 모습을 보이지는 않으나, 본 논문에서 제시한 CTRNN 제어기에서는 일반적인 PI 제어기의 출력보다 빠르고 정확한 출력을 확인할 수 있다. 그림 15에 CTRNN 적응 제어기의 PI 값의 변화를 나타낸다.

4.2.2 고속 영역

그림 14에 지령 속도가 2400 RPM일 때의 일반적인 PI 제어기의 무부하시와 부하시의 엔코더를 통해 얻은 전동기의 속도를 나타낸다. 그림 15는 부하시의 기존의 인공신경망 제어기와 본 논문에서 제시한 CTRNN 제어기의 실험결과를 나타낸다. 2400RPM에서도 일반적인 PI 제어기와 인공신경망 제어기 보다 본 논문에서 제시한 CTRNN 적응 제어기의 출력이 우수한 것을 확인할 수 있다. 그림 16에 CTRNN 제어기의 PI gain 값의 변화를 나타낸다.




그림 14 일반적인 PI 제어기의 무부하 및 부하 실험 결과 (2400RPM)

Fig. 14 Experimental results of a normal PI controller with no load and load (2400RPM)




그림 15 인공신경망 제어기 및 CTRNN 적응 제어기의 실험 결과 (2400RPM)

Fig. 15 Experimental results of Artificial NN and CTRNN controllers (2400RPM)




그림 16 CTRNN 적응 제어기 PI gain 값 (2400RPM)
 Fig. 16 PI gains of CTRNN controller (2400RPM)

5. 결 론

본 논문에서는 전동기 구동 중 발생하는 외부 외란에 대해 대처하기 위해 구성된 기존의 인공신경망에서의 문제점을 보완하기 위해서 연속 시간 회귀 신경망(Continuous Time Recurrent Neural Network) 모델을 적용한 강인한 PI 제어를 제시하였다.

먼저 시뮬레이션을 통하여 외란에 의해 변화하는 속도 영역에 대응하기 위한 기존의 인공신경망 PI 제어기와 CTRNN 적응 PI 제어기를 구성하였으며 이를 가우시안 백색잡음을 통한 불규칙한 외란을 줌으로써 강인한 제어를 설계하였고 실험을 통하여 실제 제어기가 외란에 대응하는 모습을 비교하면서 기존의 PI 제어기 및 인공신경망 PI 제어기 보다 진보된 적응 제어기임을 보였다.

또한 CTRNN 적응 PI 제어기는 기존의 PI제어기보다 속도 추종의 최적화를 위하여 복잡한 PI 제어기의 gain 값을 구하지 않고 자동적으로 gain 값의 최적화 과정을 거칠 수 있음을 확인할 수 있다.

감사의 글

본 연구는 2014년도 강원대학교 학술연구조성비로 연구하였음(과제번호-120140231).

References

[1] M. H. Shin, D. S. Hyen, S. B. Cho and S. Y. Choe, "An improved stator flux estimation for speed sensorless stator flux orientation control of induction motors", IEEE PESC, pp. 1581-1586, 1998.
 [2] K. Y. Nam, W. T. Lee, C. Lee, and J-Pyo Hong, "Reducing torque of DC motor by varying input voltage", IEEE Trans. Magn. vol. 42, pp. 1307-1311, 2006.

[3] L. Zhang and W. L. Qu, "Commutation torque ripple restraint in BLDC motor over whole speed range", in Proc. IEEE ICEMS, pp. 1501-1507. 2005.
 [4] Y. Liu, Z. Q. Zhu, and D. Howe, "Direct torque control of brushless DC drives with reduced torque ripple", IEEE Trans. Ind. Appl., vol. 41, no. 2, pp. 599-608, 2005.
 [5] Y. Liu, Z. Q. Zhu, and D. Howe, "Instantaneous torque estimation in sensorless direct torque controlled brushless DC motors", IEEE Trans. Ind. Appl., vol. 42, no. 5, pp. 1275-1283, 2006.
 [6] Z. Q. Zhu, Y. Liu, and D. Howe, "Steady-state dynamic performance of a direct torque controlled PM brushless DC drive accounting for influence of PWM chopping and cogging torque", in Proc. IEE Int. Conf. Power Electron., Mach. and Drives, Dublin, pp. 556-560, 2006.
 [7] Tae-Sung Kim, Sung-Chan Ahn, and Dong-Seok Hyun, "A new current control algorithm for torque ripple reduction of BLDC motors", IECON '01. The 27th Annual Conf. of the IEEE, vol. 2, pp. 1521-1526, 2001.
 [8] K. Friston, "The free-energy principle: a unified brain theory?", Nature, vol. 11, no. 2, pp. 127-138, 2010.
 [9] K. Friston, "The history of the future of the Bayesian brain", Neuro Image, vol. 62, no. 2, pp. 1230-1233, 2012.
 [10] Y. Yamashita and J. Tani, "Emergence of functional hierarchy in a multiple timescale neural network model: a humanoid robot experiment", PLoS Computational Biology, vol. 4, no. 11, 2008.

저 자 소 개



김 일 환 (Il-Hwan Kim)

1959년 12월 18일생. 1982년 서울대학교 제어계측공학과 졸업. 1988년 서울대학교 제어계측공학과 석사졸업. 1993년 Tohoku University 졸업(Ph.D.). 1995. 3~현재 강원대학교 전기전자공학부 교수