

퍼지-신경회로망을 적용한 강인한 AC드라이브 시스템에 관한 연구

(A Study on the Robust AC Drive Systems using Fuzzy-Neural Network)

田喜鍾* · 金載哲* · 金炳鎭** · 文學龍** · 孫珍勳** · 盧榮男***

(Hee-Jong Jeon · Jae-Chul Kim · Beung-Jin Kim · Hark-Yong Moon

Jin-Geun Son · Nam-Young Noh)

요 약

본 논문에서는 퍼지제어기와 신경회로망 적용 관측기를 적용하여 강인성을 가진 AC드라이브 시스템을 제안 하였다. 퍼지제어기는 유도전동기의 속도제어시 빠른 속도 응답 특성을 얻기 위하여 사용하였다. 신경회로망 적용 관측기는 전동기 파라미터 변화에 대하여 강인한 제어 시스템이 되도록 자속관측기와 토크관측기로 구성하였다. 사용된 신경회로망은 자속과 토크의 동특성을 학습시키기 위하여 역전파 알고리즘을 사용하였다. 컴퓨터 시뮬레이션의 결과를 통해 제안된 시스템이 전동기 파라미터 변동과 부하외란에 강인하고 속도응답 특성이 우수함을 입증하였다.

Abstract

In this paper, a fuzzy controller and a neural network adaptive observer are proposed and applied to the case of induction motor control. The high performance AC drive systems require exact knowledge of rotor flux. Because rotor time constant is needed to observe rotor flux, the accurate estimation of rotor time constant is important. For these problems, the proposed observer which comprises neural network flux observer and neural network torque observer is trained to learn the flux dynamics and torque dynamics and subjected to further on-line training by means of a backpropagation algorithm. And the results show that the robust control of induction motor neglects the rotor time constant variations.

1. 서 론

AC드라이브 시스템에 의한 유도전동기의 제어

기술은 1972년 F.Blaschke가 처음으로 교류전동기를 타여자 직류 전동기 처럼 계자자속과 회전자자속 사이의 간섭이 일어나지 않도록 제어하는

*正會員 : 숭실대학교 전기공학과 교수

**正會員 : 숭실대 대학원 전기공학과 박사과정.

***正會員 : 숭실대 대학원 전기공학과 석사과정.

接受日字 : 1996年 7月 15日

벡터제어 방식을 제안한 이후 그 성능 향상에 있어서 큰 진전이 있었다. 순시 토오크 제어 수단인 벡터 제어를 원활히 수행하기 위해서는 공간 벡터 평면상에서 유도전동기의 회전자 쇄교자속 벡터의 크기와 각도를 정확히 알아내야 한다. 이를 위해 대부분의 경우에는 전동기 내부의 자속 벡터를 직접 검출하기 힘들기 때문에 유도전동기의 시정수와 고정자 전류값을 이용하여 회전자 쇄교자속을 추정하게 된다¹⁾.

그러나 유도전동기의 벡터제어는 전동기의 시정수 변동과 비선형성 그리고 측정하기 어려운 상태변수로 인하여 정교한 제어를 어렵게 한다²⁾. 이러한 제어의 어려움에 대하여 최근에는 적응 제어기법의 적용으로 전동기 시정수의 변화에 따른 상태변수 추정 오차를 줄여 강인한 제어를 수행하고 있으나 제어환경 변화에 대한 적응능력이 미흡하다는 문제점이 있다. 이러한 문제점을 해결하기 위하여 최근 학습기능을 가지고 있어서 외부환경이나 시스템 자체에 관한 지식없이도 제어환경의 변화에 스스로 적응할 수 있는 신경회로망을 제어분야에 응용하기 위한 연구가 활발히 진행되고 있다³⁾.

본 논문에서는 유도전동기의 제어시스템에 대하여 전동기 입출력 관계를 모의할 수 있고 부하 외란에 적응능력이 우수한 신경회로망을 사용하여 관측기를 구성하였다. 신경회로망을 이용한 관측기는 회전자 쇄교자속과 토오크의 동특성을 각각 학습시킨 두 개의 신경회로망으로 구성하였으며 학습을 위해서는 역전파(backpropagation) 알고리즘을 사용하였다. 회전자 자속과 토오크의 관측기에 대한 오차신호는 신경회로망 구조에 있어서 연결강도를 바꾸어 신경회로망 관측기가 회전자 시정수의 변화를 추종하도록 하여 유도전동기 시정수 변화에 강인하도록 시스템을 구성하였다.

또한 본 논문에서는 전동기 속도제어기를 구성하기 위하여 퍼지이론을 도입하였다. 퍼지이론은 인간의 애매한 사고나 표현을 효과적으로 처리해주는 수학적 이론으로 퍼지제어를 비롯하여 많은 산업응용 분야에서 사용되고 있다. 특히 퍼지제어기는 기존의 산업계에서 적용하여온 PI, PID제

어기 보다 오버슈트가 적고 빠른 응답특성을 얻을 수 있는 장점이 있다.

따라서 본 논문에서는 이러한 퍼지-신경회로망을 유도전동기의 드라이브 시스템에 적용하여 전동기 속도의 응답특성이 빠르고, 전동기 시정수 변동에 강인한 제어특성을 가지는 고성능 벡터제어 시스템을 제안하고 디지털 시뮬레이션을 통하여 제안한 시스템의 타당성을 입증한다.

2. 적응관측기와 신경회로망학습

2.1 적응관측기의 고찰

유도전동기의 순시 토오크 제어를 위한 벡터제어는 회전자 쇄교자속을 정확히 알아내야 하며 이를 위해 대부분 전동기의 시정수를 이용하게 되는데 이들 시정수는 온도나 표피효과에 의해 변하게 된다. 따라서 종래의 방식에 의한 자속관측기는 회전자 시정수의 변화에 따라 정확한 관측이 불가능하여 성능저하를 유발시키는 단점이 있다. 이러한 문제점을 해결하기 위하여 그림1과 같은 적응 관측기를 구성할 수 있다⁵⁾.

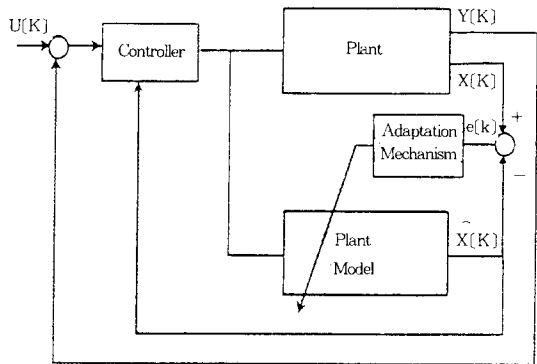


그림 1. 적응 관측기의 구성도
Fig. 1. Configuration of adaptive observer.

그림 1의 적응관측기 구성에서 제어기의 출력은 플랜트와 플랜트 모델에 인가되어 각각의 출력을 낸다. 만약 오차 $e[k]$ 가 발생하면 이 오차가 감소되는 적응 메커니즘을 이용하여 플랜트의 모델을 변화시킨다. 즉 플랜트 모델에 대한 오차를 최소화하여 플랜트의 상태를 잘 추종할 수 있도록 관측기의 구조를 변경해 제어 할 수 있다.

그러나 이 기법은 플랜트 자체의 정확한 모델링을 필요로 하고 제어성능이 플랜트의 시정수 변동에 민감하며, 부하외란에 대하여 강인성이 떨어지는 문제점이 존재한다.

이러한 문제점을 해결하기 위하여 본 논문에서는 유도전동기의 제어시스템에 대하여 플랜트 자체에 관한 정보없이도 플랜트 입출력 관계를 모의할 수 있고 외부환경이나 제어환경의 변화에 스스로 적응할 수 있는 학습기능의 신경회로망을 도입한다.

2.2 신경회로망 학습 방법

신경회로망은 학습기능, 병렬처리의 특징이 있으며 신경회로망 자체가 필터역할을 하여 외란에 둔감한 특징을 가지고 있다^{4) 6)}. 신경회로망은 뉴런이라는 기본처리 요소로 구성되어 있다. 이러한 뉴런들은 층을 이루고 각 층들은 서로 연결된 다층구조를 갖는다. 모든 뉴런은 연결 강도로서 서로의 연결성을 나타내고 있으며 많은 종류의 형태가 있다. 신경회로망 학습은 이러한 연결강도를 바꾸는 과정으로 출력 오차로 이루어진 평가 함수를 최소로 하는 방향으로 연결강도를 바꾸어 나간다.

학습방법으로는 최소자승(LMS) 알고리즘의 비선형 확장인 오차역전파 학습알고리즘을 사용하였다. 이 학습 알고리즘의 기본 원리는 입력층의 각 층에 입력패턴을 주면, 이 신호는 각 층에서 변환되어 중간층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 입력패턴으로부터 출력과 목표출력과의 오차의 제곱 총합을 최소로 하도록 연결강도를 조정하며 이를 델타 규칙이라고 한다.

그러나 일반적으로 은닉층이 있는 경우에 오차의 미분을 구하는 것이 어렵고 최급하강법 (gradient descent method)이 오차의 지역최소값을 나타내는 연결강도에 수렴할 가능성이 있다. 따라서 델타규칙을 일반화하여야 한다. 일반화된 델타 규칙에서 p번째 연결강도의 변화(ΔW_p)는 식 (1)과 같이 그 연결의 종점층에 관한 오차신호(δ_{pk})와 그 연결의 시점층 출력(O_p)의 곱에 비례한다. 여기서 η 는 학습률이며 첨자 p는 입력층

을 i는 은닉층을 k는 출력층을 각각 나타낸다.

$$\Delta W_{pi} = \eta \delta_{pk} O_{pi} \quad (1)$$

오차신호의 계산은 출력층에 대한 오차를 초기값으로 하여 재귀적으로 수행된다. 먼저 출력에 대한 오차신호는 델타규칙과 거의 같이 네트워크의 출력과 목표출력의 차이로부터 구해지며, 은닉층에 대한 오차신호는 출력을 받는 층의 오차신호 δ_{pk} 와 연결강도 W_{ki} 를 이용하여 구한다. 일반화된 델타 규칙에 의한 학습은 두 순서에 의해 이루어진다고 할 수 있다.

첫째, 입력을 네트워크에 제시하면 이것이 네트워크의 전방향으로 전파되어 출력을 낸다. 이 출력과 목표출력과의 차이에 미분계수를 곱하여 출력 층에 대한 오차를 계산한다.

둘째, 오차신호가 네트워크의 역방향으로 전파되어 가면서 위의 식과 같이 각 층의 오차신호가 계산되어, 이것을 바탕으로 연결강도를 수정한다.

일반적으로 보다 빠른 학습속도를 위해 많이 사용되는 연결강도의 변화 ΔW_p 에 대한 관계는 식 (2)와 같다.

$$\Delta W_p(n+1) = \eta \delta_{pk} O_{pi} + \alpha \cdot \Delta W_p(n) \quad (2)$$

여기서 n은 학습횟수, α 는 수렴속도를 조절하는 모멘텀 파라미터이다. 오차 역전파 학습 알고리즘은 기울기를 따라가는 방법 (gradient descent)의 하나인데 이 알고리즘의 단점중의 하나는 지역 최소값에 빠질 염려가 있다. 이를 개선하기 위하여 은닉층 수를 증가시키거나 모멘텀 파라미터 α 와 학습률 η 를 조절해 나가는 방식을 사용하거나 또는 연결강도의 초기값을 여러가지 임의의 수를 주어 학습시키는 방법도 제시되고 있다^{5) 6)}.

3. 신경회로망 적응 관측기를 이용한 유도전동기의 제어

3.1 신경회로망 적응 관측기의 구성

유도전동기의 d-q축 등가회로에서 정지좌표계의 고정자 전압 방정식을 구할 수 있으며, 회전하는 d-q좌표계에서의 d축 성분 전압과 q축 성분 전압으로 식 (3)과 같이 표시할 수 있다. 또

회전자가 ω_r 의 속도로 회전한다면 회전자에 고정된 d-q 축은 전기각에 동기되어 회전하는 좌표계를 기준으로 할 때 $(\omega_e - \omega_r)$ 의 속도로 회전하며 이로 부터 동기회전좌표계에서의 전압 방정식은 식 (3), (4)와 같이 표현된다.

$$V_{ds}[k] = R_{sd}i_{ds}[k] + \frac{\lambda_{ds}[k]}{T_0} - \omega_e \lambda_{qs}[k] \quad (3)$$

$$V_{qs}[k] = R_{sq}i_{qs}[k] + \frac{\lambda_{qs}[k]}{T_0} - \omega_e \lambda_{ds}[k]$$

$$V_{dr}[k] = R_{rd}i_{dr}[k] + \frac{\lambda_{dr}[k]}{T_0} - (\omega_e - \omega_r) \lambda_{qr}[k] \quad (4)$$

$$V_{qr}[k] = R_{rq}i_{qr}[k] + \frac{\lambda_{qr}[k]}{T_0} - (\omega_e - \omega_r) \lambda_{dr}[k]$$

여기서 $V_s[k]$, $i_s[k]$, $\lambda_s[k]$ 는 동기회전좌표계에서 전압, 전류, 자속의 순시치 벡터를 나타내며 첨자 d, q는 각각 d-q좌표계에서의 축을 나타낸다. ω_e 는 동기각속도, $\omega_e \lambda_s[k]$ 는 좌표축의 회전에 의한 속도 기전력이다. T_0 는 제어기의 샘플링 주기이다. 따라서 이들의 전압방정식과 자속의 관계로 부터 동기회전좌표계에서의 슬립 각속도 $(\omega_{sl}[k])$ 를 얻을 수 있으며, 전동기의 출력 토크를 산출해 낼 수 있다^{3) 7)}.

유도전동기의 회전자 시정수($T_r[k]$) 계산은 식 (5)를 이용하여 구할 수 있으며, 식 (6)의 관계에 의하여 계산이 반복적으로 된다. 반복하여 구해진 회전자 시정수는 관측된 회전자 시정수($\hat{T}_r[k]$)라 정의하고 관측된 $\hat{T}_r[k]$ 는 식 (6)과 같이 슬립 각속도의 관측($\hat{\omega}_{sl}[k]$)에 또다시 사용된다. 이러한 관계에 의하여 관측된 $\hat{T}_r[k]$ 는 실제의 전동기 회전자 시정수에 수렴하도록 근사화된다. $\hat{T}_r[k]$ 는 전동기의 운전중 변화된 회전자 시정수값과 일치되고, 이렇게 관측된 값에 의하여 정확한 자속의 관측이 이루어진다. 이때의 근사화에는 신경회로망의 오차 역전과 알고리즘이 사용된다.

$$\hat{T}_r[k] = \frac{L_{m^2} i_{dq(avg)}[k]}{\hat{\lambda}_r[k] \hat{\omega}_{sl}(avg)[k]} \quad (5)$$

$$\hat{\omega}_{sl}[k] = \frac{L_{m^2} i_{dq(avg)}[k]}{\hat{\lambda}_r[k] \hat{T}_r[k]} \quad (6)$$

여기서 시정수의 변화는 매우 천천히 이루어지므로 400[ms]의 샘플링 시간을 주었고 $\hat{\omega}_{sl}[k]$ 이 실제값에서 진동하므로 필터를 이용하여 $i_{dq(avg)}$,

$\hat{\omega}_{sl(avg)}$ 를 각각 얻을 수 있다.

그림 2는 유도전동기 구동을 위한 신경회로망 적응관측기의 벡터제어 전체 시스템을 나타내고 있다. 이는 자속과 토크를 관측할 수 있는 두개의 신경회로망 적응관측기와 퍼지제어기 그리고 필터링부, 슬립연산부, 시정수연산부 등으로 구성하였다. 두개의 신경회로망 관측기는 병렬로 위치하여 좌표변환이나 제어기의 중요한 정보인 회전자 쇄교자속의 각 $\hat{\theta}[K]$ 를 관측한다.

그림 3은 신경회로망 자속 관측기의 구성을 나타낸 것으로써 식 (7)로 표현되는 자속모델의 동특성을 학습시키며 3개 뉴런을 갖는 입력층, 10개의 뉴런을 갖는 은닉층 그리고 1개 뉴런의 출력층을 갖도록 구성하였다. 입력은 고정자의 자속분 전류($i_{ds}[k]$)와 자속($\hat{\lambda}_r[k]$)이며, 출력은 다음상태의 자속 관측값인 $\hat{\lambda}_r[k+1]$ 가 된다. 여기서 사용되는 회전자 시정수는 회전자 시정수 연산부에서 계산된 새로운 시정수 값이다. 자속모델과 신경회로망 관측기의 출력오차는 시정수변화로 기인되므로 이 오차를 줄이는 방향으로 학습이 이루어 진다.

$$\hat{\lambda}_r[k+1] = \hat{\lambda}_r[k] \left(\frac{1-T_0}{\hat{T}_r[k]} \right) + i_{ds}[k] \left(L_m \frac{T_0}{\hat{T}_r[k]} \right) \quad \dots(7)$$

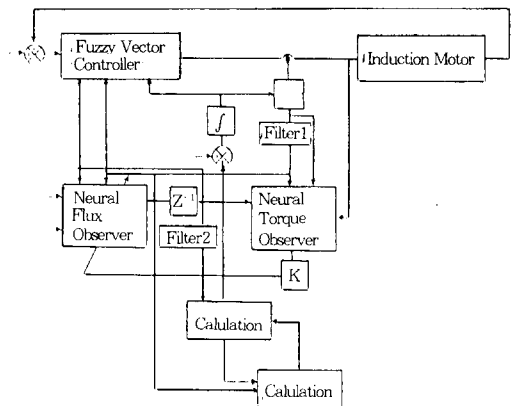


그림 2. 신경망에 의한 유도전동기 제어시스템
Fig. 2. Control system of Induction Motor using neural network.

그림 4는 신경회로망 토크 관측기의 구성을

나타낸 것으로써 식(10)으로 표현되는 토오크 모델의 동특성을 학습시키며 2개의 뉴런으로 구성된 입력층, 10개의 뉴런으로 구성된 은닉층과 1개 뉴런의 출력층으로 구성하였다. 관측된 회전자자속과 추정전류를 이용하여 계산된 동기회전좌표계에서의 순시 토오크값($T(k)$)과 신경회로망 관측기의 출력 토오크값($\hat{T}(k)$)의 오차가 줄어들도록 가중치를 바꾸어 준다. 또한 고정자 전압을 측정하여 적분한 고정자 자속($\hat{\lambda}_s[k]$)과 추정전류($i_s^*[k]$)를 이용해 토오크($T_d[k]$)를 알 수 있고 이 값과 신경회로망 관측기의 출력과의 오차($e_T[k]$)를 이용하여 신경회로망 자속 관측기를 다시 학습시킨다.

$$\lambda_s^*[k+1] = \lambda_s^*[k] + (V_s^*[k] - R_s i_s^*[k]) T_0 \quad (8)$$

$$T_d[k] = \frac{3P}{4} (\lambda_{ds}^*[k] i_{qs}^*[k] - \lambda_{qs}^*[k] i_{ds}^*[k]) \quad (9)$$

$$\hat{T}(k) = \frac{3PL_m}{4L_r} \hat{\lambda}_s[k] i_{qs}[k] \quad (10)$$

식 (8)에서 처럼 정지좌표계에서 측정한 전압과 전류를 적분하여 자속($\lambda_s[k+1]$)을 얻어낼 수 있으며 이 자속은 추정 전류와 곱해져서 식 (9)와 같은 토오크를 얻을 수 있다. 따라서 식 (9)의 토오크식은 정지좌표계에서 간접적으로 측정된 모델 토오크식이다. 식 (10)은 자속관측기에서 얻어진 동기회전좌표계에서의 자속 $\hat{\lambda}_s[k]$ 및 전류에 의한 관측 토오크식이다. 이러한 관계에 의하여 식 (9)의 모델 토오크식과 식 (10)의 관측 토오크식에 대한 오차발생은 없어야 한다. 만약 오차가 발생한다면 이를 줄이는 방향으로 다시 학습시킨다.

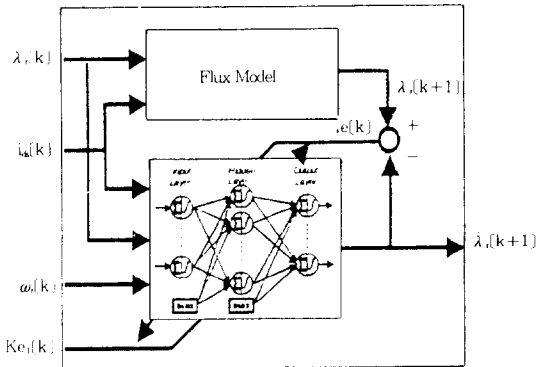


그림 3. 신경회로망 자속 관측기
Fig. 3. Neural network flux observer

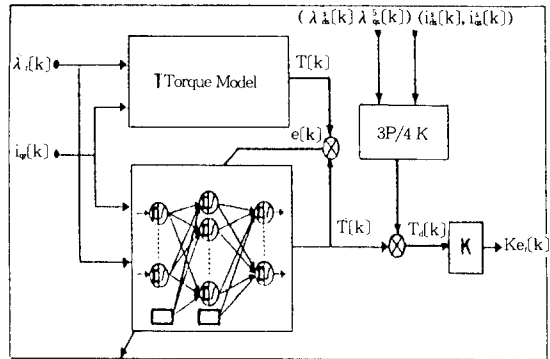


그림 4. 신경회로망 토오크 관측기
Fig. 4. Neural Network torque observer

3.2 오차 수정방법

신경회로망 자속 관측기의 학습은 자속모델과 신경회로망 자속 관측기의 오차($e_s[k]$)를 이용하였다. 신경회로망 토오크 관측기의 학습은 토오크 모델과의 오차($e_T[k]$)를 이용하여 학습한다. 고속에서의 전압측정은 정확하나 저속에서의 전압측정이 어렵고 부정확하므로 속도에 비례하는 이득을 곱해서 학습시키었다. 즉 식 (11)과 같이 속도에 따라서 가중치를 주어서 저속에서의 측정 오차를 최소한으로 줄이고자 하였다.

또한 신경회로망의 관측은 자속 관측기와 토오크 관측기에 대해서 각각 $S_T T_0$, $S_T T_0$ 의 주 샘플링 주기를 갖으며 모델과의 오차를 줄여 나가는 방법으로는 오차 역전과 알고리즘을 사용하였다.

$$K = \hat{\omega}_s[k] g \quad (11)$$

여기서, g 는 조정 계수이다.

매 시간에 신경회로망 관측기의 출력 오차는 신경회로망을 통하여 오차 역전과 알고리즘에 따라서 가중치를 바꾼다. 학습은 식 (12)와 같은 관측기 전체 평가지수를 최소로 하도록 학습시킨다.

$$E = \frac{K^2 e_T[k]^2 + e_s[k]^2}{2} \quad (12)$$

3.3 퍼지제어기의 구성

본 논문에서는 전동기 속도제어기를 구성하기 위하여 퍼지이론을 도입하였다. 퍼지 시스템에서 사용할 수 있는 퍼지화 방법은 측정치를 퍼지 싱글톤으로 변환시키는 방법과 측정된 수치의 확률

적인 특성을 고려하여 가우시안 분포곡선, 이등변삼각형 또는 사다리꼴 형태의 퍼지 값으로 바꾸는 방법이 있다”.

본 논문에서의 플랜트인 유도전동기의 정격 속도는 1,800[rpm]이므로 전체 시스템의 속도 오차와 오차의 변화율을 [-10, 10]범위로 정규화하였고 이등변 삼각형 모형의 멤버십 함수를 이용하였다.

퍼지 제어 규칙은 전문가의 제어 지식을 수치적 표현보다 언어적 표현으로 구체화시킨 “If...Then...” 형태의 퍼지 조건 문으로 구성된다. 퍼지 규칙의 선정시, 적당한 제어 변수와 퍼지 집합의 선택은 퍼지 제어 시스템의 성능에 큰 영향을 미친다. 보통 퍼지 제어 시스템의 제어 변수로는 상태 변수 오차, 상태 변수 오차의 미분과 상태 오차의 적분값등이 주로 쓰인다.

본 논문에서는 전동기 속도지령에 대한 오차를 상태변수로 선정하여 이에 대한 오차(E)와 오차 변화량(CE)을 표 1과 같이 구분 작성하여 퍼지 제어 규칙을 만들어 사용하였다.

표 1. 퍼지 규칙
Table 1. Fuzzy rule

CE \ E	S3	S2	S1	ZO	B1	B2	B3
S3	S3	S3	B3	S3	S2	S1	ZO
S2	S3	S3	S3	S2	S1	ZO	B1
S1	S3	S3	S3	B1	ZO	B1	B2
ZO	S3	S2	S1	ZO	B1	B2	B3
B1	S2	S1	ZO	B1	B2	B3	B3
B2	S1	ZO	B1	B2	B3	B3	B3
B3	ZO	B1	B2	B3	B3	B3	B3

4. 시뮬레이션 결과 및 고찰

시뮬레이션을 수행하기 위한 전동기의 모델은 표 2와 같은 농형 유도전동기로 설정하였다. 표 3은 시뮬레이션 수행의 파라미터이다. 제어기는 0.5[msec]의 샘플링 시간을 가지며, 관측기는 10 [msec]의 샘플링 시간을 갖게하였다.

전체 시뮬레이션은 벡터 제어기와 신경회로망 적응 관측기 및 시정수 계산이 동시에 이루어진다. 제안된 관측기의 성능은 관측기의 샘플링 주

표 2. 유도전동기의 사양

Table 2. Induction Motor Specification

정격	출력	30[HP]
	속도	1,800[RPM]
상	고정자 저항	$R_s=0.0413[\Omega]$
	회전자 저항	$R_r=0.0407[\Omega]$
수	고정자 자기 인덕턴스	$L_s=36.4[mH]$
	회전자 자기 인덕턴스	$L_r=35.6[mH]$
	상호 인덕턴스	$M=35[mH]$
	회전자 관성 모멘트	$J=0.122[kg \cdot m^2]$

표 3. 시뮬레이션 파라미터

Table 3. Simulation Parameters.

시뮬레이션 파라미터	과도시	정상시	
관측기 샘플링 주기	$P_\lambda T_0$	T_0	$5T_0$
	$P_\tau T_0$	T_0	$5T_0$
신경망 반복 학습횟수	N_λ	5	1
	N_τ	1	1
신경망 학습률	η_λ	0.1	0.3
	η_τ	0.1	0.3

기($P_\lambda T_0$, $P_\tau T_0$), 온라인 학습할 때에 신경회로망의 학습 반복횟수(N_λ, N_τ) 및 신경회로망의 학습률(η_λ, η_τ)에 의해 영향을 많이 받으므로 본 논문에서는 변화가 심한 과도시에는 짧은 샘플링 주기를 주었고 시스템이 정상시에는 샘플링 주기를 줄였다.

따라서 과도시간동안에 $P_\lambda = P_\tau = 1$ 로 설정하여 관측기의 추종성능을 극대화시켰고 정상상태에서는 $P_\lambda = P_\tau = 5$ 로 설정하여 계산량을 줄여 시스템의 속도를 향상시킬 수 있었다. 신경회로망의 학습 반복횟수도 역시 샘플링 주기와 같은 역할을 하므로 과도시에는 $N_\lambda = 5$, $N_\tau = 1$ 로 정상시에서는 $N_\lambda = N_\tau = 1$ 로 설정하였다.

신경회로망의 학습률은 값을 크게하면 수렴 속도가 증가하나 실제 값 주위에서 진동하는 성질을 가지므로 적절한 값을 주어야 한다. 오프라인 학습시 학습속도를 높이기위해서 학습률을 바꾸어가며 학습시키는 적응 학습률기법을 이용하여 학습시간을 단축하므로 온라인 학습시에는 과도시에는 $\eta_\lambda = 0.1$ 과 $\eta_\tau = 0.1$ 그리고 정상시에서는 $\eta_\lambda = 0.3$, $\eta_\tau = 0.3$ 으로 설정하였다.

그림 5는 무부하 1,800[rpm] 지령속도에 대하여 기존의 PI제어기의 속도응답이다. 오버슈트가

있고 약 900[ms]의 느린 응답을 보이고 있다. 응답특성을 개선하기 위하여 PI제어기의 각 이득을 높일 수 있으나 오버슈트가 일어나고 적분기의 포화 현상이 일어나므로 이득을 무리하게 높이는 것은 한계가 있다. 그림 6은 그림 5와 동일조건




그림 5. PI 제어기 속도응답
Fig. 5. Speed response of PI controller




그림 6. 퍼지 제어기의 속도응답
Fig. 6. Speed response of fuzzy controller




그림 7. d-q축 자속과 리사주
Fig. 7. Lissajous figure and waveforms of d-q axes rotor flux

에서 퍼지제어기의 속도 응답을 보여주고 있는데 훨씬 빠르고 오버슈트 없는 응답을 나타내고 있다. 또한 그림 7은 고정 좌표계에서의 d,q축의 추정된 자속리사주 파형이 정현적으로 나타나고 있음을 보여주고 있다.

그림 8은 전동기 제어시스템이 정상 동작할때의 학습 횟수를 3으로 설정하여 갖은 학습을 했을 경우에서 토오크 모델의 출력이며 (a), (b)는 신경회로망 관측기의 출력이고 (c)에서는 모델의 출력에 대한 관측기의 출력의 오차를 나타내었다. 실제 토오크와 신경회로망 적응 토오크 관측기의 출력 토오크와의 오차는 매우 작은 것을 볼 수 있다.

그러나 그림 9와 같이 학습 횟수를 5로 인가하면 토오크가 많이 변화하는 약계자 부분에서 추종 성능이 현저히 떨어짐을 볼 수 있었다.

그림 10은 회전자 시정수를 전동기 기동후 0.7초 후에 인위적으로 2.5배 변화시켰다. 과도시 생기는 오차는 오프라인 학습시, 이 부분이 정확히 학습이 안되었다는 것을 보여주고 있다. 이때 자속 모델에서는 갑작스러운 시정수 변화로 자속이 급격히 변하는 것을 볼 수 있으며, 자속 관측기에서는 오차를 감소시키는 방향으로 학습이 이루어져 약 0.5초 후에는 오차가 줄어들었음을 볼 수 있다.

마찬가지로 그림 11은 약 0.7초 후에 전압 또는 전류를 측정할 때에 센서의 측정 오차와 갑작스러운 부하 변동의 외란을 대신한 오차를 인가

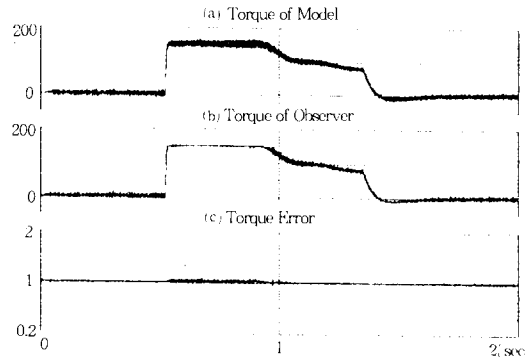


그림 8. 토오크 모델과 토오크관측기의 출력 및 오차 ($P_{\lambda}=P_T=3$)
Fig. 8. Output and error waveforms of torque model and observer ($P_{\lambda}=P_T=3$)

했다. 역시 짧은 시간에 외란으로 생기는 오차를 줄여 나가는 모습을 보여주고 있다.




그림 9. 토오크모델과 토오크관측기의 출력 및 오차 ($P\lambda=PT=5$)
Fig. 9. Output and error waveforms of torque model and observer ($P\lambda=P_T=5$)




그림 10. 시정수 변화시 자속 모델과 자속관측기의 출력 및 오차 ($P\lambda=P_T=5$)
Fig. 10. Output and error waveforms of flux model and observer with time constants varying ($P\lambda=P_T=5$)




그림 11. 외란에 따른 자속모델과 자속관측기의 출력 및 오차 ($P\lambda=P_T=5$)
Fig. 11. Output and error waveforms of flux model and observer with disturbance ($P\lambda=P_T=5$)

5. 결 론

본 논문에서는 유도전동기의 순시토크를 제어하기 위한 벡터제어에 있어서 퍼지 속도제어기와 신경회로망 적응관측기를 제안하였다. 신경회로망 적응관측기는 유도전동기의 동특성을 학습시켜 과도상태나 정상상태에서 강인한 속도제어가 가능함을 시뮬레이션으로 확인하였으며 다음과 같은 결과를 얻었다.

(I) 속도제어에 있어서는 퍼지 속도제어기를 이용하여 빠르고 오버슈트 없는 속도응답을 얻었다.

(II) 자속과 토크에 대한 두개의 신경회로망 적응관측기를 이용하여 회전자 시정수 변화와 부하 변동에 강인한 시스템을 구축하였다.

(III) 신경회로망 자체의 필터링 효과로 외부 잡음에 대하여 둔감하게 하였다.

이상의 결과로 퍼지제어기는 속도제어 시스템 등에 다양하게 적용할 수 있음을 확인하였으며, 특히 신경회로망 적응 관측기는 유도전동기 제어 시스템과 같은 비선형적이고 시변적인 시스템에 적용한다면 성능을 보다 개선할 수 있으리라 기대할 수 있었다.

이 논문은 1995년도 한국학술진흥재단의 대학부설연구소 연구과제 연구비에 의하여 연구되었음.

참 고 문 헌

- 1). F. Blaschke, "The Principle of Field Orientation as Applied to the New Transvector Closed Loop Control System for Rotating Machines," *Simens Review*, Vol. 39, No. 5, pp. 217~220, 1972.
- 2). Robert D. Lorenz and Donald B. Lawson "A Simplified Approach to Continuous On-Line Tuning of Field-Oriented Induction Machine Drives," *IEEE Trans. on Ind. Appl.*, Vol. 26, No. 3, May/June, 1984.
- 3). Kazuo Shimane, Shigeru Tanaka and Susumu Tanaka, "Vector Controlled Induction Motor Using Neural Network," *IEEJ Transactions*, Vol. D-113, No.10, 1993.
- 4). Hans Butlers, *Model Reference Adaptive Control from theory to practice*, Prentice-Hall, 1992.
- 5). Kumpati S. Narendra and Kannan Partha-sarathy,

"Identification and Control of Dynamical Systems Using the Neural Networks", IEEE Trans. on Neural Network, Vol. 1, No. 1, pp. 4~27, March, 1991.

- 6) D. H. Nguyen and B. Widrow, "Neural Network for Self-Learning Control System," IEEE Control system, Vol. 10, pp. 18~23., April, 1990.
- 7) Edward Y. Ho and Paresh C. Sen, "Decoupling Control of Induction Motor Drives," IEEE Trans. on Ind. Electron., Vol. 35, No. 2, pp. 253~262, May, 1988.

◇ 著者紹介 ◇



전희종(田喜鍾)

1953년 1월 6일생. 1975년 숭실대 공대 전기공학과 졸업. 1977년 서울대 대학원 전기공학과 졸업(석사). 1977년~1981년 공군사관학교 전자공학과 교수. 1987년 중앙대 대학원 전기공학과 졸업(박사). 1995년~1996년 Univ. of Victoria, CA. 객원교수. 1983년~현재 숭실대 공대 전기공학과 교수.



손진근(孫珍劬)

1964년 8월 13일생. 1990년 숭실대 공대 전기공학과 졸업. 1992년 동대학원 전기공학과 졸업(석사). 1992년~1995년 현대중공업(주) 중앙연구소 주임연구원. 1996년 숭실대 대학원 전기공학과 졸업(박사). 현재 경원전문대 전기과 전임강사.



노영남(盧榮男)

1969년 12월 8일생. 1996년 숭실대 공대 전기공학과 졸업. 현재 숭실대 대학원 전기공학과 석사과정.



김재철(金載哲)

1955년 7월12일생. 1979년 2월 숭실대학교 공과대학 전기공학과 졸업(공학사). 1983년 8월 서울대학교 대학원 전기공학과 졸업(공학석사). 1987년 8월 서울대학교 대학원 전기공학과 졸업(공학박사). 1988년 3월~현재 숭실대학교 공과대학 전기공학과 재직(교수). 1995년 9월~현재 숭실대학교 공과대학 전기공학과 학과장.



김병진(金炳鎭)

1970년 6월 26일생. 1994년 숭실대 공대 전기공학과 졸업. 1996년 숭실대 대학원 전기공학과 졸업(석사). 1996년~현재 숭실대 대학원 전기공학과 박사과정.



문학룡(文學龍)

1963년 9월 5일생. 1990년 숭실대 공대 전기공학과 졸업. 1993년 숭실대 대학원 전기공학과 졸업(석사). 1994년~1995년 삼흥중공업 개발부. 1995년~현재 숭실대 대학원 전기공학과 박사과정.