

인공신경회로망에 의한 유도전동기의 회전자 저항 추정

김길봉, 최정식, 고재섭, 정동화  
 순천대학교 공과대학 정보통신공학부

Rotor Resistance Estimation of Induction Motor by Artificial Neural-Network

Kil-Bong Kim, Jung-Sik Choi, Jae-Sub Ko, Dong-Hwa Chung  
 School of Information & Communication Engineering, Suncheon National Univ.

**Abstract** - This paper proposes a new method of on-line estimation for rotor resistance of the induction motor in the indirect vector controlled drive, using artificial neural network (ANN). The back propagation algorithm is used for training of the neural networks. The error between the desired state variable of an induction motor and actual state variable of a neural network model is back propagated to adjust the weight of a neural network model, so that the actual state variable tracks the desired value.

The performance of rotor resistance estimator and torque and flux responses of drive, together with these estimators, are investigated variations rotor resistance from their nominal values. The rotor resistance are estimated analytically, using the proposed ANN in a vector controlled induction motor drive.

1. 서 론

유도전동기의 벡터제어는 고속 토크응답을 얻을 수 있으므로 다양한 산업적용에 호응을 받고 있다. 벡터제어 드라이브의 성능은 측정 고정자 전류로부터 얻은 추정 회전자 자속에 영향을 받는다. 실제 회전자 자속과 추정 회전자 자속의 불일치는 실제 토크와 추정 토크 사이에 오차를 발생시켜 동적 성능을 악화시킨다. 추정된 회전자 저항의 정확성은 제어를 위하여 사용되는 추정 회전자 저항의 값에 많은 영향을 준다. 회전자 저항은 회전자의 과열 및 열적 모델 또는 온도 센서 등에 의하여 변동한다. 회전자 저항의 변동에 대한 문제점을 해결하기 위하여 오프-라인으로 파라미터 추정하는 기법이 제시되었다.[1] 이 기법에서는 전동기의 파라미터를 자동적으로 조절하고 매우 정밀한 조절을 하는데는 효율성이 있었다. 그러나 이러한 추정기법은 전동기의 운전 동안 변동하는 파라미터를 동적으로 보상하기 어렵고 파라미터를 추정하기 위한 특별한 동작패턴이 필요하였다. 또한, 오프-라인 추정은 계산이 복잡하고 시간이 많이 소요되는 문제점도 있었다. 이러한 문제점을 극복하기 위하여 온-라인 추정기법이 제시되었다.[2] 그러나 이 기법에서는 자동 학습기능으로 추정하는 방법 및 파라미터의 동적 최적화는 얻는 방법은 제시하지 않았다.

인공신경회로망(Artificial Neural Network)은 학습능력을 가지고 있으므로 공정제어를 위한 매력적인 도구로 인식되었다. 본 논문에서는 온-라인 학습을 이용하여 다층 퍼드포워드 인공신경회로망에 의한 회전자 저항을 추정을 제시한다. 다층 퍼드포워드의 신경회로망은 다양한 근사 기법, 역전파 알고리즘에 의한 학습으로

다양한 시스템의 비선형 관계를 처리할 수 있는 능력을 가지고 있다. 역전파 알고리즘에 의한 2층 인공신경회로망에 의해 회전자 저항을 추정한다. 상태변수의 추정을 위하여 두 모델을 사용하며 이 모델은 실제 유도전동기의 출력과 인공신경회로망 모델의 출력이다. 요구 상태모델과 실제 상태모델 사이에서 나타나는 오차는 인공신경회로망 모델의 하층을 조절하기 위하여 역전파된다. 따라서 인공신경회로망 모델의 출력을 실제 모델과 일치시킨다. 속도제어기는 적응 FNN(Fuzzy-Neural Network)을 이용한다.[3] 본 논문에서 제시한 기법의 추정 성능을 분석하고 타당성을 입증한다.

2. 인공신경회로망에 의한 회전자의 저항추정

그림 1은 인공신경회로망에 의한 회전자 저항의 추정의 블록도를 나타낸다. 상태변수의 추정을 위하여 두 모델을 사용하며 이 모델은 실제 유도전동기의 출력과 인공신경회로망 모델의 출력이다. 인공신경회로망 상태모델과 실제 상태모델 사이에서 나타나는 오차는 역전파 알고리즘을 통하여 인공신경회로망 모델의 하층을 조절한다. 따라서 인공신경회로망 모델의 출력을 실제 모델과 일치시킨다.




그림 1 인공신경회로망을 이용한 파라미터 추정

유도전동기의 기준모델 관측기에 의한 방정식을 구하면 다음 식과 같다.

$$p\phi_r = \frac{L_r}{L_m} [v_s - R_s i_s - \sigma L_s p i_s] \quad (1)$$

여기서,  $\phi_r = \begin{bmatrix} \phi_{dr} \\ \phi_{qr} \end{bmatrix}$ ,  $v_s = \begin{bmatrix} v_{ds} \\ v_{qs} \end{bmatrix}$ ,  $i_s = \begin{bmatrix} i_{ds} \\ i_{qs} \end{bmatrix}$   
 추정모델 관측기에 의한 식은 다음과 같다.

$$p\hat{\phi}_r = \left( \frac{-1}{T_r} \mathbf{I} + \hat{\omega}_r \mathbf{J} \right) \hat{\phi}_r + \frac{L_m}{T_r} i_s \\ = -\frac{1}{T_r} \mathbf{I} \hat{\phi}_r + \hat{\omega}_r \mathbf{J} \hat{\phi}_r + \frac{L_m}{T_r} i_s \quad (2)$$

여기서,  $\hat{\phi}_r = \begin{bmatrix} \hat{\phi}_{dr} \\ \hat{\phi}_{qr} \end{bmatrix}$ ,  $i_s = \begin{bmatrix} i_{ds} \\ i_{qs} \end{bmatrix}$ ,  $\mathbf{I} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$ ,  $\mathbf{J} = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}$ ,  $T_r = \frac{L_r}{R_r}$




그림 2  $R_r$  추정을 위한 인공신경회로망 시스템의 구조

식(1)과 (2)에서 다음 식을 구한다.

$$P \begin{bmatrix} \phi_{dr}^{vm} \\ \phi_{qr}^{vm} \end{bmatrix} = \frac{L_r}{L_m} \begin{bmatrix} v_{ds} \\ v_{qs} \end{bmatrix} - R_s \begin{bmatrix} i_{ds} \\ i_{qs} \end{bmatrix} - \sigma L_s P \begin{bmatrix} i_{ds} \\ i_{qs} \end{bmatrix} \quad (3)$$

$$P \begin{bmatrix} \phi_{dr}^{im} \\ \phi_{qr}^{im} \end{bmatrix} = \begin{bmatrix} -\frac{1}{T_r} & -\omega_r \\ \omega_r & -\frac{1}{T_r} \end{bmatrix} \begin{bmatrix} \phi_{dr}^{im} \\ \phi_{qr}^{im} \end{bmatrix} + \frac{L_m}{T_r} \begin{bmatrix} i_{ds} \\ i_{qs} \end{bmatrix} \quad (4)$$

식(4)는 다음 식으로 나타낼 수 있다.

$$\Phi_r^{im} = \left( -\frac{1}{T_r} \mathbf{I} + \omega_r \mathbf{J} \right) \Phi_r^{im} + \frac{L_m}{T_r} \mathbf{i}_s \quad (5)$$

여기서,

$$\Phi_r^{im} = \begin{bmatrix} \phi_{dr}^{im} \\ \phi_{qr}^{im} \end{bmatrix}, \mathbf{i}_s = \begin{bmatrix} i_{ds} \\ i_{qs} \end{bmatrix}, \mathbf{I} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, \mathbf{J} = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}, T_r = \frac{L_r}{R_r}$$

식(5)를 샘플 데이터 모델로 나타내면 다음 식과 같다.

$$\Phi_r^{im}(k) = (W_1 \mathbf{I} + W_2 \mathbf{J}) \Phi_r^{im}(k-1) + W_3 \mathbf{i}_s(k-1) \quad (6)$$

여기서,

$$W_1 = 1 - \frac{T_s}{T_r}, W_2 = \omega_r T_s, W_3 = \frac{L_m}{T_r} T_s$$

$T_s$ 는 샘플링 주기이며 식(6)은 다음 식으로 나타낼 수 있다.

$$\Phi_r^{im}(K) = W_1 \mathbf{X}_1 + W_2 \mathbf{X}_2 + W_3 \mathbf{X}_3 \quad (7)$$

여기서,

$$\mathbf{X}_1 = \mathbf{I} \Phi_r^{im}(k-1) = \begin{bmatrix} \phi_{dr}^{im}(k-1) \\ \phi_{qr}^{im}(k-1) \end{bmatrix}$$

$$\mathbf{X}_2 = \mathbf{J} \Phi_r^{im}(k-1) = \begin{bmatrix} -\phi_{qr}^{im}(k-1) \\ \phi_{dr}^{im}(k-1) \end{bmatrix}$$

$$\mathbf{X}_3 = \mathbf{I} \mathbf{i}_s(k-1) = \begin{bmatrix} i_{ds}(k-1) \\ i_{qs}(k-1) \end{bmatrix}$$

식(6)에서 나타낸 NN(Neural Network) 모델은 그림 4와 같다. 여기서  $W_1, W_2, W_3$ 는 NN의 가중치를 나타내고  $\mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3$ 는 NN의 3개의 입력이다.  $W_2$ 는 이미 알고 있는 값이며  $W_1$ 과  $W_3$ 는 갱신하는데 필요하고 이를 이용하여  $T_r$ 를 추정할 수 있다.

신경세포 사이의 가중치  $W_1$ 과  $W_3$ 는 에너지 함수를 최소화하기 위하여 학습으로 찾는다.

$$E = \frac{1}{2} \varepsilon^2(k) = \frac{1}{2} [\Phi_r^{vm}(k) - \Phi_r^{im}(k)]^2 \quad (8)$$

가중치 변화분은 다음 식과 같다.

$$\Delta W_1(k) = \eta [\Phi_r^{vm}(k) - \Phi_r^{im}(k)] \mathbf{I} \Phi_r^{im}(k-1) \quad (9)$$

여기서  $\eta$ 는 학습계수이며  $\alpha$ 는 과거 가중치 변화의 영향에 의하여 결정된다.

$$W_1(k) = W_1(k-1) - \eta \delta X_1 + \alpha \Delta W_1(k-1) \quad (10)$$

$$\delta = \frac{\partial E}{\partial \Phi_r^{im}} = [\Phi_r^{vm}(k) - \Phi_r^{im}(k)]^T$$

이와 유사하게  $W_3$ 에 대한 가중치 변화분은 다음 식과

같다.

$$W_3(k) = W_3(k-1) - \eta \delta X_3 + \alpha \Delta W_3(k-1) \quad (11)$$

회전자 시정수  $T_r$ 는 다음 식으로 계산한다.

$$T_r = \frac{T_s}{1 - W_1} \quad (12)$$

$$T_r = \frac{L_m T_s}{W_3} \quad (13)$$




그림 3 2층 NN 모델

그림 4는 온-라인 회전자 저항을 추정하는 벡터제어 유도전동기 드라이브의 블록도를 나타낸다. 인공신경회로망에 의해 회전자 저항을 추정하고 A-FNN(Adaptive FNN)에 의해 속도를 제어한다.[4]




그림 4 온-라인 회전자 저항을 추정하는 벡터제어 유도전동기

### 3. 시스템의 성능결과

그림 5는 PI와 인공신경회로망을 이용한 회전자 저항의 추정을 비교한 결과이다. 스텝 지령속도를 1500[rpm]로 운전 중, 0.5[sec]에서 실제 회전자 저항  $R_r$ 을 2배로 변화시킬 경우의 응답특성을 나타낸다. 인공신경회로망을 이용한 추정 기법이 PI제어기를 이용한 추정 기법보다 추정 회전자 저항은 실제치에 빠르게 추정하고 있다.

그림 6은 그림 5와 같은 조건에서 실제 회전자 저항을 0.5배로 하였을 경우의 응답특성을 비교한 결과이다. 이 경우에도 인공신경회로망을 이용한 추정 기법이 PI제어기를 이용한 추정 기법보다 실제치에 빠르게 추정하고 있다.




그림 5 PI와 인공신경회로망의 응답특성 비교 ( $R_r = 2 \times R_r$ )  
그림 6 PI와 인공신경회로망의 응답특성 비교 ( $R_r = 0.5 \times R_r$ )

그림 7은 스텝 지령속도를 1500[rpm]로 운전 중, 0.5[sec]에서 2[sec]사이 다양하게 스텝 지령속도를 변화시켰을 경우의 응답특성을 나타낸다. 또한 0.5[sec]에서 실제 회전자 저항  $R_r$ 는 점차적으로 증가시켰다. 그림 (a)는 지령속도와 실제속도, 그림 (b)

는 추정 회전자 저항과 실제 회전자 저항, 그림 7(c)는 회전자 자속, 그림 7(d)는 발생토크, 그림 7(e)는 9축 전류를 나타낸다. 스텝 지령속도를 다양하게 변화시킬 경우에도 추정 회전자 저항은 실제 회전자 저항에 양호하게 추정하였다.

그림 8은 그림 7과 같은 조건에서 실제 회전자 저항을 점차적으로 감소하였을 경우의 응답특성이다. 이 경우에도 회전자 저항은 양호하게 추정하고 응답특성도 양호하게 나타났다.

그림 9는 0.2(sec)에서 스텝 지령속도를 1800(rpm)으로 운전하다가 0.5(sec)에서 0.7(sec)까지 부하토크를 5[N·m]인가하였을 경우의 응답특성을 나타낸다. 0.5(sec)에서 실제 회전자 저항을 2배로 변화시킬 경우의 응답특성이다. 부하토크를 인가하였을 경우에도 추정 회전자 저항은 실제 회전자 저항에 양호하게 추정하였다.

그림 10은 스텝 지령속도를 1500(rpm)로 운전 중, 0.5(sec)에서 스텝 지령속도를 -1500(rpm)으로 변화시켰을 경우의 응답특성을 나타낸다. 초기 추정 회전자 저항  $\hat{R}_r$ 을 실제 회전자 저항  $R_r$ 의 2배로 하였다. 그림 10(a)는 지령속도와 실제속도, 그림 10(b)는 추정 회전자 저항과 실제 회전자 저항, 그림 10(c)는 회전자 자속, 그림 10(d)는 발생토크를 나타낸다. 스텝 지령속도를 변화시킬 때 오버슈트가 작게 나타나며 응답특성도 양호하게 나타난다. 추정 회전자 저항은 실제 회전자 저항에 양호하게 추정하였다.

을 실제 회전자 저항의 2배로 하였다. 스텝 지령속도를 상승시킬 경우에도 오버슈트가 작게 나타나며 응답특성도 양호하게 나타난다. 추정 회전자 저항은 실제 회전자 저항에 양호하게 추정하였다.

그림 12는 스텝 지령속도를 4상한 운전으로 하였을 경우의 응답특성을 나타낸다. 그림 12(a)는 지령속도와 실제속도, 그림 12(b)는 추정 회전자 저항과 실제 회전자 저항, 그림 12(c)는 회전자 자속, 그림 12(d)는 발생토크를 나타낸다. 4상한 운전을 하였을 경우에도 추정 회전자 저항은 실제 회전자 저항에 양호하게 추정된다.

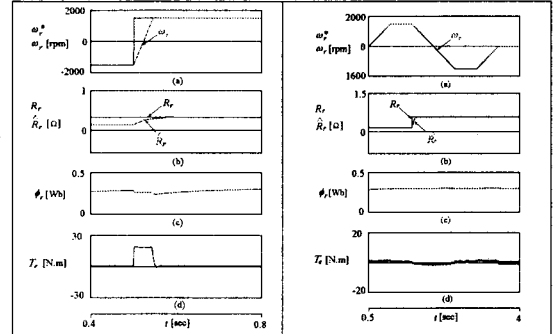


그림 11 스텝 지령속도와  $R_r$ 의 변화에 대한 응답특성 ( $\hat{R}_r = 0.5 \times R_r$ )

그림 12 4상한 운전과  $R_r$ 의 변화에 대한 응답특성 ( $R_r = 2 \times \hat{R}_r$ )

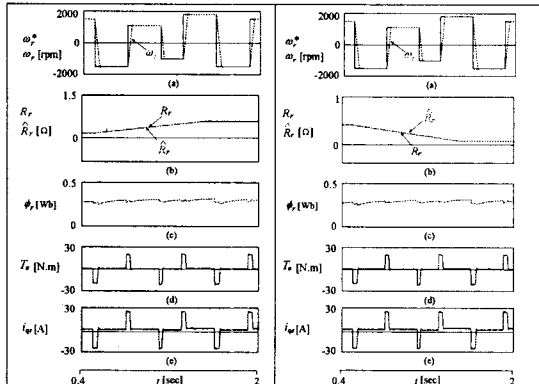


그림 7 스텝 지령속도와  $R_r$ 의 변화에 대한 응답특성

그림 8 스텝 지령속도와  $R_r$ 의 변화에 대한 응답특성

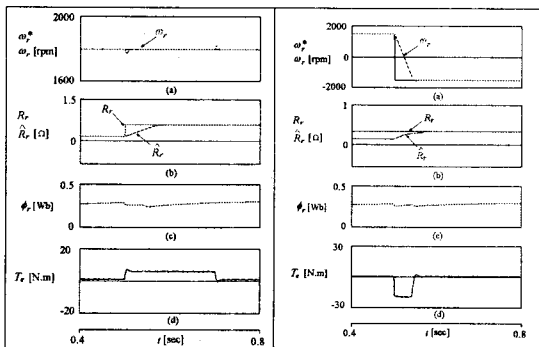


그림 9 부하토크와  $R_r$ 의 변화에 대한 응답특성 ( $R_r = 2 \times \hat{R}_r$ )

그림 10 스텝 지령속도와  $R_r$ 의 변화에 대한 응답특성 ( $\hat{R}_r = 0.5 \times R_r$ )

그림 11은 스텝 지령속도를 -1500(rpm)로 운전 중, 0.5(sec)에서 스텝 지령속도를 1500(rpm)으로 변화시켰을 경우의 응답특성을 나타낸다. 초기 추정 회전자 저항

#### 4. 결 론

본 논문에서는 유도전동기 드라이브의 파라미터 추정을 위하여 인공신경회로망 기법을 제시하였다. 온라인 학습을 이용하여 역전파 알고리즘에 의한 2층 피드포워드 인공신경회로망에 의해 회전자 저항을 추정하였다. 속도제어기는 A-FNN을 이용하였다. 인공신경회로망의 알고리즘을 이용하여 유도전동기의 양호한 성능을 얻을 수 있었다.

일정 속도, 스텝 지령속도 변화, 다양한 속도변화, 부하변화 및 4상한 운전 등 다양한 파라미터의 변화에도 실제 회전자 저항의 증가와 감소에 추정 회전자 저항은 양호하게 추정하였다. 그리고 A-FNN을 이용한 속도제어도 오버슈트가 작게 나타나고 빠르게 안정화되었다.

따라서 본 연구에서 제시한 인공신경회로망을 이용한 추정 알고리즘의 성능은 매우 양호하게 나타났으며 본 연구의 타당성을 입증할 수 있었다.

#### [참 고 문 헌]

- [1] C. Wang, D. W. Novotny and T. A. Lipo, "An automated rotor time constant measurement system for indirect field oriented drives," IEEE Trans. on IA, vol. 24, pp. 151-159, 1988.
- [2] T. Noguchi, S. Kondo and I. Takahashi, "Robust torque control of induction motor against variation of primary and secondary resistance," in IPEC-Tokyo Conf. Rec., pp. 1163-1168, 1995.
- [3] H. G. Lee, J. C. Lee and D. H. Chung, "Adaptive FNN controller for speed control of IPMSM drive," The Trans. of KIEE, vol. 41-SC, no. 3, pp. 39-46, 2004.
- [4] J. C. Lee, H. G. Lee, S. M. Nam and D. H. Chung, "Speed control of induction motor drive using adaptive FNN controller," International Conference ICEMS'04, Conference no. PI-5(430-M09-052), 2004. [CD no. 2]