

---

# 신경회로망을 이용한 직류전동기의 센서리스 속도제어

김종수\* · 강성주\*\*

Sensorless Speed Control of Direct Current Motor  
by Neural Network

Jong-Su Kim\* · Sung-Joo Kang\*\*

## 요 약

근래에는 정확성과 신뢰성이 강한 센서리스 속도추정방법으로 전동기를 구동하기 위한 노력이 전개되고 있으며, 본 논문은 외란에 대한 강인성이 뛰어난 신경회로망을 이용하여 직류전동기의 센서리스 속도제어를 실현한 연구 결과이다.[6-8] 신경회로망은 사람의 뇌가 경험을 통해 학습하듯이 주어진 입력에 대해 학습을 통하여 최적의 출력을 발생한다. 학습은 직류전동기의 수식모델을 통해 얻어진 전압·전류 및 회전자 속도를 입·출력데이터로 사용하여 역전파 학습 알고리즘[8]을 통해 행하여지며, 학습 완료 후 얻은 최적의 연결강도를 이용하여 속도를 추정한다. 신경회로망에 의한 방식은 복잡한 알고리즘을 사용하지 않고도 정확한 속도추정이 가능하며, 직류전동기의 문제점인 회전자 권선의 열에 의한 전동기의 성능 악화 및 속도제어의 어려움을 해소하여 운전조건에 따른 외란 등에도 강인한 제어특성을 가질 뿐만 아니라 전 속도 영역에서 속도응답특성이 우수한 결과를 얻을 수 있었다.

## ABSTRACT

DC motor requires a rotor speed sensor for accurate speed control. The speed sensors such as resolvers and encoders are used as a speed detector, but they increase cost and size of the motor and restrict the industrial drive applications. So in these days, many papers have reported on the sensorless operation of DC motor[3-5]. This paper presents a new sensorless strategy using neural networks[6-8]. Neural network has three layers which are input layer, hidden layer and output layer. The optimal neural network structure was tracked down by trial and error, and it was found that 4-16-1 neural network structure has given suitable results for the instantaneous rotor speed. Also, learning method is very important in neural network. Supervised learning methods[8] are typically used to train the neural network for learning the input/output pattern presented. The back-propagation technique adjusts the neural network weights during training. The rotor speed is gained by weights and four inputs to the neural network. The experimental results were found satisfactory in both the independency on machine parameters and the insensitivity to the load condition.

## Key words

Neural Network(신경회로망), Supervised learning methods(감독 학습방법),  
Back-propagation technique(역전파기법)

---

\*한국해양대학교 해사산업연구소  
접수일자 : 2003. 11. 18

\*\* 한국해양대학교 해사산업대학원

### 1. 서론

직류전동기는 브러시와 정류자의 사용으로 교류전동기에 비해 유지보수가 어려운 점이 있으나 빈번하게 변화하는 위치나 속도의 명령에 대해서 충실하게 추종할 수 있는 장점을 가지고 있으므로 로봇이나 컨테이너크레인 등의 정밀한 제어에 사용되고 있다.

직류전동기의 속도제어는 주로 전기자전압 제어법에 의해 이루어지며 정밀한 속도제어를 위해서는 회전자의 속도정보가 필요한데 이를 위해서 타코제너레이터나 엔코더 등의 센서를 사용한다. 그러나 속도제어에 사용되는 센서는 온도나 노이즈에 민감하여 센서의 이상이 발생되기 쉽고, 또한 센서의 사용으로 전동기의 비용이 상승하고 부피가 커지게 되는 단점이 있다.

이에 최근에는 정확성과 신뢰성이 강한 센서리스 속도제어방법을 이용하여 전동기를 구동하기 위한 노력이 전개되고 있으며, 본 논문에서는 외란에 대한 강인성이 뛰어난 신경회로망을 이용하여 직류전동기의 센서리스 속도제어를 실현하였다[6-8].

신경회로망은 사람의 뇌가 경험을 통해 학습하듯이 주어진 입력에 대해 학습을 통하여 최적의 출력을 발생한다. 학습은 직류전동기의 수식모델을 통해 얻어진 전압·전류 및 회전자 속도를 입·출력데이터로 사용하여 역전과 학습 알고리즘[8]을 통해 행하여지며, 학습 완료 후 얻은 최적의 연결강도를 이용하여 속도를 추정한다.

신경회로망에 의한 방식은 복잡한 알고리즘을 사용하지 않고도 정확한 속도추정이 가능하며, 직류전동기의 문제점인 회전자 권선의 열에 의한 전동기의 성능 악화 및 속도제어의 어려움을 해소하여 운전조건에 따른 외란 등에도 강인한 제어특성을 가질 뿐만 아니라 저속에서도 속도응답특성이 우수한 결과를 얻을 수 있었다.

### II. 직류전동기의 수학적 모델링

직류전동기는 정확하고 손쉬운 속도제어가 가능하며, 기동특성이 우수하기 때문에 가·감속 및

역방향 회전이 용이하다. 본 논문에서는 이러한 장점을 가진 타여자 직류전동기를 사용하였다.[1-2]

직류전동기의 회전력은 자속과 전기자 전류의 곱에 비례하므로 다음과 같이 표현할 수 있다.

$$T = k_1 \phi i_a \tag{1}$$

$$k_1 = \frac{z}{2\pi a} P \tag{2}$$

- 여기서,  $i_a$  : 전기자 전류
- $\phi$  : 공극자속
- $P$  : 극수
- $z$  : 전도체수
- $a$  : 내부 병렬 회로수
- $k_1$  : 토크 상수

또한, 전동기의 역기전력은 다음과 같다.

$$u_b = k_2 \phi n \tag{3}$$

- 여기서,  $n$  : 회전자속도
- $k_2$  : 역기전력 상수

전기자 전류는 단자전압과 역기전력을 이용하여 식(4)와 같이 구할 수 있다.

$$i_a = \frac{u_a - u_b}{R_a} \tag{4}$$

- 여기서,  $u_a$  : 전기자 전압
- $R_a$  : 전기자 저항

직류전동기 회전속도는 식(3)에 식(4)를 대입하여 식(5)와 같이 구한다.

$$n = \frac{u_a - R_a i_a}{k_2 \phi} \tag{5}$$

식(3) 및 (5)로 부터 직류전동기 속도는 자속이 일정 할 경우에 전기자전압에 비례하고, 단자전압

이 일정하면 자속에 반비례함을 알 수 있다. 전기자 전압강하는 단자전압에 비해 매우 작으므로 속도는 단자전압에 비례한다.

Fig. 1은 타여자 직류전동기의 모델이다.




그림 1. 타여자 직류전동기  
Fig. 1 Separate excitation field dc motor

과도상태시의 동특성을 얻기 위해 전기자 권선과 계자권선의 전압방정식 및 기계방정식을 구하면 다음과 같이 나타낼 수 있다.

$$u_a = R_a i_a + L_{aa} \frac{di_a}{dt} + \omega_r L_{af} i_f \quad (6)$$

$$u_f = R_f i_f + L_{ff} \frac{di_f}{dt} \quad (7)$$

$$T_e = L_{af} i_f i_a \quad (8)$$

$$\frac{d\omega_r}{dt} = -\frac{B}{J} \omega_r + \frac{T_e - T_L}{J} \quad (9)$$

- $L_{af}$  : 상호 인덕턴스
- $L_{aa}$  : 전기자 인덕턴스
- $L_{ff}$  : 계자 인덕턴스
- $T_e$  : 토크
- $T_L$  : 부하
- $B$  : 마찰계수
- $\omega_r$  : 회전자 각속도
- $J$  : 관성모멘트

직류전동기 시스템 블록도는 다음과 같다.




그림 2. 직류전동기의 시스템 블록도  
Fig. 2 System block diagram of dc motor

### III. 본 논문에서 제안한 신경회로망을 이용한 직류 전동기 속도추정

#### III. I 신경회로망 입·출력 패턴

속도추정을 위한 신경회로망의 입·출력 데이터는 실제전동기 대신 수식 모델로부터 얻어지며, 식(6)~식(9)로부터 구할 수 있다.

신경회로망의 입력은 전압, 전류 성분과 시간지연항인  $u_a(k)$ ,  $u_a(k-1)$ , 및  $i_a(k)$ ,  $i_a(k-1)$ 들을 사용하였으며, 출력은 식(9)에 의해 구한 회전자 각속도  $\omega_r(k)$ 를 이용하였다.

#### III. II 신경회로망에 의한 속도 추정기

Fig. 3은 본 논문에서 사용한 신경회로망에 의한 속도 추정기 구조이다.

또한, Fig. 4는 속도 추정기 구성을 위해 신경회로망의 목적패턴 데이터로 사용된 직류전동기 수식 모델의 계단속도지령에 대한 속도파형이며, 부하(1[N·m])를 인가한 상태이다.

Fig. 5는 연결가중치를 구하는 시스템 블록도이며, 실제 직류전동기 대신 수식모델을 이용하였다.




그림3. 신경회로망에 의한 속도추정기  
Fig. 3 Speed estimator by neural network




그림 4. 직류전동기 모델의 속도응답  
Fig. 4 Speed responses of dc model

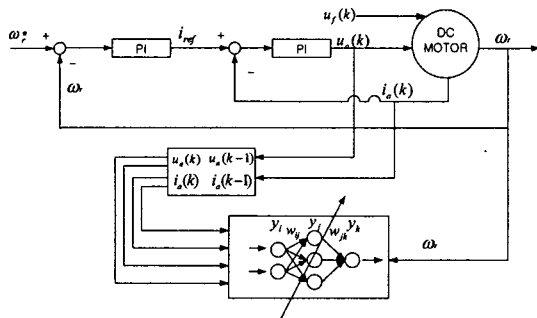


그림 5. 신경회로망 속도추정기의 학습을 위한 블록도  
Fig. 5 Block diagram for training of neural network speed estimator

신경회로망의 추정속도  $\hat{\omega}_{nr}$ 은 직류전동기 수식모델의 회전자 속도  $\omega_r$ 과 비교하여 오차가 발생하면 결국 연결강도가 부정확한 것이므로 신경회로망에 그 오차를 역전파하여 학습시킴으로써 오차를 최소화하려는 학습알고리즘이 필요하다. 오차는 출력층에서 은닉층으로, 은닉층에서 입력층으로 역전파되어 오차에 따른 강도 변화량에 의해 연결강도가 조정된다.

다음 수식들은 신경회로망의 출력을 구하는 과정을 수식으로 표현한 것이다.

$$net_i = x_i \quad (i = 1, 2, 3, \dots, n) \quad (10)$$

$$y_i = f(net_i) \quad (11)$$

$$net_j = \sum_i (w_{ij} y_i + b_j) \quad (12)$$

$$y_j = f(net_j) \quad (13)$$

$$net_k = \sum_j (w_{jk} y_j + b_k) \quad (14)$$

$$y_k = f(net_k) \quad (15)$$

전동기의 실제속도와 신경회로망의 추정속도의 오차는 다음과 같이 정의한다.

$$E = \frac{1}{2} \sum_k (\omega_r - \hat{\omega}_{nr})^2 \quad (16)$$

학습은 이 오차를 최소화하는 방향으로 학습하여 연결강도를 조정하는 것이므로 경사하강법에 따라 출력층에 요구되는 연결강도 변화량은 다음과 같이 나타낸다.

$$\Delta w_{jk} = -\alpha \frac{\partial E}{\partial w_{jk}}, \quad \alpha > 0 \quad (17)$$

그리고 일반화된 오차신호  $\delta_k$ 를 다음과 같이 정의한다.

$$\delta_k = -\frac{\partial E}{\partial net_k} \quad (18)$$

연쇄법칙에 의해 식(17)의 우변항은 다음과 같이 표현된다.

$$\frac{\partial E}{\partial \omega_{jk}} = \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial \omega_{jk}} = -\delta_k \frac{\partial net_k}{\partial \omega_{jk}} \quad (19)$$

위 식은  $net$  입력에 대한 접속된 연결강도 변화의 효과를 표현하므로  $\frac{\partial net_k}{\partial \omega_{jk}}$  는 다음과 같다.

$$\frac{\partial net_k}{\partial \omega_{jk}} = \frac{\partial (\sum_k \omega_{jk} y_j + b_k)}{\partial \omega_{jk}} = y_j \quad (20)$$

그러므로 출력층의 연결강도 변화량은 다음과 같이 구하여 진다.

$$\Delta w_{jk} = \alpha \delta_k y_j \quad (21)$$

신경회로망의 출력인 추정속도  $\widehat{\omega}_{nr}$  을 연쇄법칙에 적용하여  $\delta_k$ 를 다음 식과 같이 표현할 수 있다.

$$\delta_k = -\frac{\partial E}{\partial net_k} = -\frac{\partial E}{\partial \widehat{\omega}_{nr}} \frac{\partial \widehat{\omega}_{nr}}{\partial net_k} \quad (22)$$

식 (16)으로 부터 다음 식을 구한다.

$$\frac{\partial E}{\partial \widehat{\omega}_{nr}} = -(\omega_r - \widehat{\omega}_{nr}) \quad (23)$$

그리고 식(15)을 이용하여 다음 식을 구할 수 있다.

$$\frac{\partial \omega_{nr}}{\partial net_k} = f'(net_k) \quad (24)$$

본 논문에서 사용한 활성화함수는 식(25)와 같으며, 이 식을 미분하여  $x = net_k$ 를 대입하면 식(26)이 된다.

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (25)$$

$$f'(net_k) = (1 + f(net_k))(1 - f(net_k)) \quad (26)$$

활성함수의 출력  $f(net_k)$ 는 결국 신경회로망 출력층의 출력인 추정속도  $\widehat{\omega}_{nr}$  이므로 대치하면 아래 식과 같다.

$$\frac{\partial \widehat{\omega}_{nr}}{\partial net_k} = (1 + \widehat{\omega}_{nr})(1 - \widehat{\omega}_{nr}) \quad (27)$$

그러므로  $\delta_k$ 는 식(28)과 같이 나타낼 수 있다.

$$\delta_k = (1 + \widehat{\omega}_{nr})(1 - \widehat{\omega}_{nr})(\omega_r - \widehat{\omega}_{nr}) \quad (28)$$

은닉층의 오차신호  $\delta_j$  도 출력층의 오차신호  $\delta_k$ 와 같은 방법으로 구하여진다. 따라서, 각 층 사이의 연결강도 변화량은 다음과 같이 조정된다.

$$\Delta w_{jk}(k+1) = \Delta w_{jk} + \alpha \delta_k y_j \quad (29)$$

$$\Delta w_{ij}(k+1) = \Delta w_{ij} + \alpha \delta_j y_i \quad (30)$$

연결강도는 식(29) 및 식(30)에 의해 조정되며 이는 실제속도  $\omega_r$ 과 추정속도  $\widehat{\omega}_{nr}$ 의 오차가 최소화될 때까지 반복된다.

이러한 학습을 통하여 구하여진 최적의 연결강도를 이용하여 직류전동기 회전자 속도를 식(31)과 같이 추정한다.

$$\widehat{\omega}_{nr} = [F_j(X_i w_{ij} + B_j)] w_{jk} + B_k \quad (31)$$

여기서,  $i$ 는 입력층의 노드수, 4

$j$ 는 은닉층의 노드수, 16

$k$ 는 출력층의 노드수, 1

$F_j$ 는 은닉층의 활성화함수

$B_j$ 는 은닉층 바이어스

$B_k$ 는 출력층 바이어스

$w_{ij}$ 는 입력층과 은닉층 사이의 연결강도

$w_{jk}$ 는 은닉층과 출력층 사이의 연결강도

Fig. 6은 학습을 통하여 구하여진 연결가중치에 의해 출력된 추정 속도파형을 보여주고 있다.

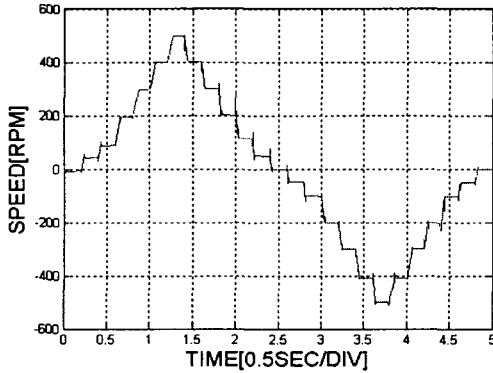


그림 6. 신경회로망 속도추정기의 속도응답  
Fig. 6 Speed response of neural network estimator

Fig. 7은 직류전동기 센서리스 속도제어 구동 시스템의 블록도이다.

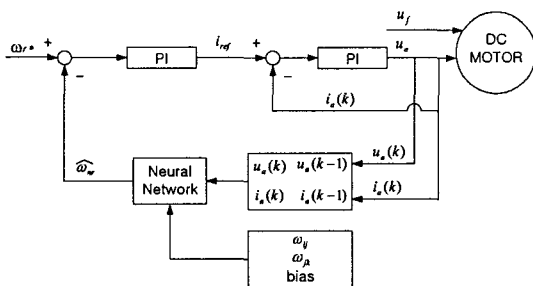


그림 7. 신경회로망에 의한 속도제어 시스템의 블록도  
Fig. 7 Block diagram of speed control system by neural network

#### IV. 실험 결과

실험에 사용한 직류전동기의 파라미터 및 시스템 정수는 Table 1과 같다.

표 1. 실험에 사용된 직류전동기의 파라미터  
Table 1 Parameters of dc motor used for experiment

정격출력	2 [N-m]	$R_a$	2.9 [ $\Omega$ ]
정격전압	110 [v]	$R_f$	360 [ $\Omega$ ]
정격속도	2000 [rpm]	$L_{ff}$	120 [H]
극 수	2	$L_{aa}$	0.02 [H]
J	0.01 [ $kg \cdot m^2$ ]	$L_{af}$	2.3 [H]

Fig. 8, Fig. 9는 각각 0→100[rpm], 0→200[rpm]의 계단속도지령을 가했을 경우의 속도파형이며, 저속에서 응답특성이 양호함을 볼 수 있다. Fig. 10, Fig. 11은 0→500[rpm], 0→1000[rpm]의 계단속도지령을 가했을 경우의 속도파형을 나타내고 있으며, 중·고속에서도 속도응답이 우수함을 보여주고 있다.

Fig. 12와 Fig. 13은 각각 100[rpm]과 300[rpm]의 속도로 구동중 1[N-m]의 부하인가시의 속도응답 특성이며, 부하 운전시에도

속도응답의 속응성이 뛰어난을 볼 수 있다.

Fig. 14는 200[rpm]으로 구동중 200[rpm] → -200 [rpm]의 반전속도 지령을 가했을 경우의 응답이며, 속도응답이 양호함을 볼 수 있다.




Fig. 8 Experimental response for step change of speed setting (0→100[rpm])




Fig. 9 Experimental response for step change of speed setting. (0→200[rpm])




Fig. 13 Experimental response for step change of load torque. (0→1[N-m])




Fig. 10 Experimental response for step change of speed setting. (0→500[rpm])




Fig. 14 Experimental response for step change of speed setting (200[rpm]→-200[rpm])




Fig. 11 Experimental response for step change of speed setting. (0→1000[rpm])




Fig. 12 Experimental response for step change of load torque. (0→1[N-m])

## V. 결론

- 본 논문의 연구결과를 요약하면 다음과 같다.
- 1) 속도센서를 사용하지 않는 직류전동기 가변 속도제어 방식을 제안하였다.
  - 2) 기존의 속도 추정 알고리즘이 가지는 복잡성과 운전 환경의 변화에 대한 제어성능의 민감성에 관심을 두고 연구하였다.
  - 3) 제안된 방식은 직류 전동기 수식 모델에서 얻어진 전압·전류 및 회전자 속도를 신경회로망의 학습을 위한 입·출력 데이터로 사용하였으며, 학습 후 얻어진 연결가중치를 이용하여 전동기 회전자 속도를 추정하였다.
  - 4) 실험을 통하여 속도 추정성이 양호함을 알수 있었고, 전 속도 영역에서 만족할 만한 제어 성능을 얻을 수 있었다.

참고 문헌

- [1] Paul C. Krause, "Analysis of Electric Machinery", McGRAW-HILL, 1986.
- [2] B. K. Bose, Power Electronics and AC Drives, Prentice-Hall, 1987.
- [3] K. Lizuka, H. Uzuhashi, M. Kano, T. Endo and K. Mohri, " Microcomputer Control for Sensorless Brushless Motor", IEEE Trans. Indus. Appli., Vol. IA-21, No. 4, pp. 595-601, 1985.
- [4] Nobuyuki Matsui and Masakane Shigyo, "Brushless dc motor control without position and speed sensors", IEEE Trans. On Ind. Appl., Vol. 28, No. 1, Jan/Feb. 1992.
- [5] U. Baader, M. Depenbrock and G. Gierse, "Direct Self-Control of Inverter Fed Induction Machine: A Basis for Speed Control without Speed Measurement", IEEE Trans. Indus. Appli., Vol. 28, No. 3, pp. 581-588, 1992.
- [6] M. G. Simoes and B. K. Bose, "Neural Network Based Estimation of Feedback Signals for a Vector-Controlled Induction Motor Drive", IEEE Trans. Indus. Appli., Vol. 31, No. 3, pp. 620-629, 1993.
- [7] M. T. Wishart and R. G. Harley, "Identification and Control of Induction Machines Using Artificial Neural Networks", IEEE Trans. on Ind. Appl., vol. 31, No. 3, pp.612~619, 1995
- [8] J. -S. R. Jang, C. -T. Sun, E. Mizutani, "Neuro-Fuzzy and Soft Computing", Prentice Hall, 1997.



**강성주(Sung-Joo Kang)**

1998.2 한국해양대학교 기관시스템  
공학과 졸업 공학사  
2001.3-현재 한국해양대학교 산업  
대학원 석사과정

※ 관심분야 : 전기기기제어, 선박전기

저자 소개



**김종수(Jong-Su Kim)**

2002.2 한국해양대학교 기관시스템  
공학과 대학원 졸업 공학박사  
2002.10-현재 한국해양대학교 전임  
연구원

※ 관심분야 : 전기기기제어, 선박전기, 마이크로프로세서