

工學碩士 學位論文

신경회로망을 이용한 직류전동기의  
센서리스 속도제어에 관한 연구

A Study on the Sensorless Speed Control of Direct Current Motor  
by Neural Network

指導教授 金 成 煥

2004年 2月

韓國海洋大學校 海事産業大學院

機關시스템工學科

姜 成 周

## 목 차

|                                  |    |
|----------------------------------|----|
| 목 차 .....                        | i  |
| 그림 및 표목차 .....                   | ii |
| Abstract .....                   | iv |
| 기호 및 약어 .....                    | vi |
| <br>                             |    |
| 1. 서 론 .....                     | 1  |
| <br>                             |    |
| 2. 직류전동기의 구동원리 및 특성 .....        | 3  |
| 2.1 직류전동기의 구동원리 .....            | 3  |
| 2.2 직류전동기의 특성 .....              | 3  |
| 2.3 직류전동기의 수학적 모델링 .....         | 5  |
| <br>                             |    |
| 3. 신경회로망을 이용한 직류전동기의 속도추정 .....  | 8  |
| 3.1 신경회로망의 개요 .....              | 8  |
| 3.1.1 신경회로망의 생물학적 구조 .....       | 8  |
| 3.1.2 신경회로망의 구성요소와 동작특성 .....    | 9  |
| 3.1.3 다층 신경회로망의 구조와 학습 .....     | 11 |
| 3.1.4 모멘텀과 바이어스 .....            | 15 |
| <br>                             |    |
| 4. 신경회로망을 이용한 직류 전동기 속도 추정 ..... | 16 |
| 4.1 신경회로망 입·출력 패턴 .....          | 16 |
| 4.2 신경회로망에 의한 속도 추정기 .....       | 16 |
| <br>                             |    |
| 5. 시뮬레이션 .....                   | 23 |
| <br>                             |    |
| 6. 실험결과 .....                    | 28 |
| <br>                             |    |
| 7. 결 론 .....                     | 35 |
| <br>                             |    |
| 참고문헌 .....                       | 36 |

## 그림 및 표 목차

|   |    |
|---|----|
| Fig. 2.1 Rotation principle of DC motor .....   | 4  |
| Fig. 2.2 Separate excitation field DC motor .....   | 5  |
| Fig. 2.3 Dynamic model of DC motor .....  | 7  |
| Fig. 3.1 Structure of biological neuron .....   | 9  |
| Fig. 3.2 Structure of artificial neuron .....   | 9  |
| Fig. 3.3 Activation function used in neural network .....                                   | 11 |
| Fig. 3.4 Structure of general multilayer neural network .....                               | 12 |
| Fig. 3.5 Flow chart of backpropagation algorithm .....                                      | 14 |
| Fig. 4.1 Speed estimator by neural network .....  | 17 |
| Fig. 4.2 Block diagram for training of neural network speed estimator .....                 | 17 |
| Fig. 4.3 Speed responses of DC motor model .....  | 18 |
| Fig. 4.4 Speed response of neural network estimator .....                                   | 21 |
| Fig. 4.5 Block diagram of speed control system by neural network .....                      | 22 |
| Fig. 5.1 Simulation response to step change of speed setting (0→100[rpm]) .....             | 24 |
| Fig. 5.2 Simulation response to step change of speed setting (0→200[rpm]) .....             | 24 |
| Fig. 5.3 Simulation response to step change of speed setting (0→300[rpm]) .....             | 25 |
| Fig. 5.4 Simulation response to step change of speed setting (0→500[rpm]) .....             | 25 |
| Fig. 5.5 Simulation response to step change of load torque (0→1[N·m]) .....                 | 26 |
| Fig. 5.6 Simulation response to step change of load torque (0→1[N·m]) .....                 | 26 |
| Fig. 5.7 Simulation response to step change of speed setting (200[rpm]→<br>-200[rpm]) ..... | 27 |
| Fig. 6.1 Overall DC motor drive system .....  | 29 |
| Fig. 6.2 Control part .....   | 29 |
| Fig. 6.3 Power conversion part .....  | 30 |
| Fig. 6.4 Direct Current motor and load impression system .....                              | 30 |
| Fig. 6.5 Experimental response to step change of speed setting(0→100[rpm]) .....            | 31 |
| Fig. 6.6 Experimental response to step change of speed setting(0→200[rpm]) .....            | 32 |
| Fig. 6.7 Experimental response to step change of speed setting(0→500[rpm]) .....            | 32 |
| Fig. 6.8 Experimental response to step change of speed setting(0→1000[rpm]) .....           | 33 |

|  |    |
|--|----|
| Fig. 6.9 Experimental response to step change of load torque(0→1[N·m]) .....                   | 33 |
| Fig. 6.10 Experimental response to step change of load torque(0→1[N·m]) .....                  | 34 |
| Fig. 6.11 Experimental response to step change of speed setting(200[rpm]→<br>-200 [rpm]) ..... | 34 |
| Table 4.1 Parameters of DC motor used for experiment .....                                     | 23 |

# **Sensorless Speed Control of Direct Current Motor by Neural Network**

Seong-Ju Kang

Department of Marine Engineering, Graduate School,  
Korea Maritime University

## Abstract

DC motor requires a rotor speed sensor for accurate speed control. The speed sensors such as resolvers and encoders are used as speed detectors, 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.

This paper presents a new sensorless speed control strategy using neural networks.

In classical control systems, knowledge on the controlled system is required in the form of a set of algebraic and differential equation, which analytically relate inputs and outputs. However, these models are often complex, rely on many assumptions, may contain parameters which are difficult to measure or may change significantly during operation and sometimes such mathematical models cannot be determined. Furthermore, classical control theory suffers from some limitations due to the nature of the controlled system. These problems can be overcome by using artificial intelligence-based control techniques, and these techniques can be used even when the analytical models are not known, and they can be less sensitive to parameter variation than classical control systems.

The most commonly used neural networks are feedforward multilayer types.

Multilayer 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 gave correct results for the instantaneous rotor speed.

Also, learning method is very important in neural network. Supervised learning methods are typically used to train the neural network for learn 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, that is, armature voltages and currents. The satisfactory results have been found through the experiment in both the independency on machine parameters and the insensitivity to the load condition.

## 기호 및 약어

|                 |                                      |
|-----------------|--------------------------------------|
| $B$             | : 공극 자속밀도 [ $Wb/m^2$ ]               |
| $B_m$           | : 마찰계수 [ $N \cdot m / rad \cdot s$ ] |
| $F$             | : 전자력 [ $N$ ]                        |
| $i_a$           | : 전동기의 전기자전류 [ $A$ ]                 |
| $i_f$           | : 전동기의 계자전류 [ $A$ ]                  |
| $J$             | : 관성모멘트 [ $Kg \cdot m^2$ ]           |
| $L_{aa}$        | : 전기자 자기인덕턴스 [ $H$ ]                 |
| $L_{ff}$        | : 계자 자기인덕턴스 [ $H$ ]                  |
| $L_{af}$        | : 상호인덕턴스 [ $H$ ]                     |
| $p$             | : 미분연산자                              |
| $r_a$           | : 전기자저항 [ $\Omega$ ]                 |
| $r_f$           | : 계자저항 [ $\Omega$ ]                  |
| $T_e$           | : 출력토크 [ $N \cdot m$ ]               |
| $T_l$           | : 부하토크 [ $N \cdot m$ ]               |
| $u_a$           | : 전기자전압 [ $V$ ]                      |
| $u_b$           | : 역기전력 [ $V$ ]                       |
| $u_f$           | : 전동기의 계자전압 [ $V$ ]                  |
| $V_{dc}$        | : 직류링크전압 [ $V$ ]                     |
| $net$           | : 연결가중치에 대한 입력의 가중치 합                |
| $y$             | : 신경회로망 출력                           |
| $f(net)$        | : 활성화함수                              |
| $\theta$        | : 처리기의 고유바이어스                        |
| $y_i, y_j, y_k$ | : 입력층, 은닉층, 출력층의 뉴런                  |

|                    |                                      |
|--------------------|--------------------------------------|
| $w_{ij}$           | : 입력층과 은닉층 사이의 연결가중치                 |
| $w_{jk}$           | : 은닉층과 출력층 사이의 연결가중치                 |
| $E$                | : 신경회로망의 출력오차                        |
| $\Delta w_{ij}$    | : 은닉층에 대한 가중치의 변화량                   |
| $\Delta w_{jk}$    | : 출력층의 가중치 변화량                       |
| $\delta_j$         | : 은닉층에서의 오차신호                        |
| $\delta_k$         | : 출력층에서의 일반화된 오차신호                   |
| $\eta$             | : 학습률                                |
| $m$                | : 모멘텀 상수                             |
| $u_a(k), u_a(k-1)$ | : 전기자 전압 및 시간 지연항                    |
| $i_a(k), i_a(k-1)$ | : 전기자 전류 및 시간 지연항                    |
| $w_r(k)$           | : 전동기 수식 모델에서의 회전자속도                 |
| $\omega_r^*$       | : 지령 각속도 [rad/s]                     |
| $\omega_r$         | : 전동기의 각속도 [rad/s]                   |
| $\omega_{nr}$      | : 신경회로망에 의한 추정 각속도 [rad/s]           |
| IC                 | : Integrated circuit                 |
| IGBT               | : Insulated gate bipolar transistor  |
| PC                 | : Personal computer                  |
| PI                 | : Proportional + Integral Controller |



## 1. 서론

직류전동기는 브러시와 정류자로 인하여 교류전동기에 비해 유지보수가 어려운 점이 있으나 속도 및 토크특성이 우수하여 빈번하게 변화하는 위치나 속도의 명령에 대해서 충실하게 추종할 수 있는 장점을 가지고 있으므로 로봇이나 컨테이너 크레인 등의 정밀한 제어에 사용되고 있다.

직류전동기의 속도제어방식으로는 계자제어, 저항제어 및 전기자전압제어<sup>[1-2]</sup>등이 있는데 효율이 높고 광범위한 제어가 가능한 전기자전압제어법이 주로 사용된다. 또한, 정밀한 속도제어를 위해서는 회전자의 속도정보가 필요한데 이를 위해서 타코제너레이터나 엔코더 등의 센서를 사용한다. 그러나 속도제어를 위해 부착되는 센서는 온도나 노이즈에 민감하고 복잡한 제어회로를 요할 뿐 아니라 센서의 사용으로 전동기의 비용이 상승하고 부피가 커지게 되는 단점이 있다.

이러한 이유로 1980년대 후반 이후 센서를 사용하지 않는 센스리스 속도제어방식<sup>[3-6]</sup>에 관한 연구가 진행되었다.

본 논문에서는 신경회로망을 직류전동기의 센스리스 속도제어에 응용하였다.

1943년 McCulloch와 Pitts에 의해 연구되기 시작한 신경회로망<sup>[7-9]</sup>은 수학적으로 모델을 구하기 어려운 비선형 시스템이라 할지라도 학습을 통해 연결가중치를 조절함으로써 입·출력 특성을 묘사할 수 있으며, 입력정보의 왜곡, 잡음 등에 강인한 특성을 갖는다. 또한 다수개의 입·출력으로 구성되어 다변수 시스템의 모델링이 쉬운 특성을 가지며, 이러한 신경회로망의 특성들로 인하여 패턴인식, 이미지처리와 음성인식 등에 관한 응용분야에 주로 적용되었으며, 최근에는 비선형 동특성 시스템의 동정과 제어에 응용하기 위해 많이 연구되고 있다<sup>[10-13]</sup>.

제안된 방식은 시뮬레이션에 의해 얻은 입·출력 데이터를 신경회로망의 입력패턴과 출력패턴으로 사용하여 역전과 학습 알고리즘<sup>[7-9]</sup>을 통해 학습함으로써 파라미터, 부하 및 속도 변동에도 정확한 속도 추정이 가능한 최적의 연결강도를 구하여 속도추정기를 구성한다. 직류 전동기는 전압 및 전류방정식에 의해 토크가 구해지며 이 토크를 이용하여 회전자 속도정보를 얻을 수 있다<sup>[1-2]</sup><sup>[14]</sup>. 따라서 신경회로망의 입력패턴과 출력패턴을 위한 데이터는 직류 전동기의 전압 및 전류와 회전자속도 상호간의 비선형 특성에 착안하여 전압 및 전류를 입력으로, 회전자속도를 출력으로 사용한다.

즉, 전동기의 파라미터가 주어지면 시뮬레이션을 통해 전압, 전류 및 회전자속도를 구하여 신경회로망의 입·출력 데이터로 사용하며, 학습을 통하여 최적의 연결가중치를 구한다. 이 연결가중치와 신경회로망의 입력 데이터와의 연산에 의해 실제 회전자속도를 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 저속 운전시에도 우수한 속도응답 특성을 보이도록 한다.

## 2. 직류전동기의 구동원리 및 특성

### 2.1 직류 전동기의 구동원리

서보용 전동기는 큰 가속도에 의해서 기동하거나 정지하는 능력이 필요한데, 이를 위해서는 회전력이 크고 회전자의 관성모멘트가 작아야 한다. 이런 조건을 만족하는 것이 직류전동기이다.


Fig. 2.1은 직류 전동기의 구동원리를 보여주고 있다. (a)에서는 자계에서 유효자속 방향과 직각으로 놓인 길이  $l[m]$ 의 도체에 전류  $i[A]$ 를 흘리면 플레밍의 왼손법칙에 의해 도체에는 힘  $F[N]$ 가 발생하여 회전하는 것을 나타내고 있다. (c)는 정류자와 브러쉬의 위치가 바뀔 때 도체에 흐르는 전류의 방향이 반대가 됨으로써 코일은 같은 방향으로 회전을 계속하게 된다.

계자는 자속을 발생시키기 위한 장치이며 직류 전동기에서는 고정자를 형성하고 있다. 전기자는 회전을 발생하는데 필요한 전류가 흐르는 구성체를 말한다.


### 2.2 직류 전동기의 특성

직류전동기의 토크는 간략한 수식으로 나타낼 수 있기 때문에 서보 시스템의 설계가 계통적이며 간단하다.


또한, 직류전동기의 회전자는 슬롯형의 견고한 구조를 사용하고 있으며, 회전자의 직경을 축소하여 관성 모멘트를 줄일 수 있어 큰 순시토크를 얻을 수 있다. 직류전동기의 문제점은 전기자 권선에 발생하는 줄열을 들 수 있다. 이것은 코일 자체와 절연피막의 온도를 높이며, 코일의 온도가 상승하면 단자에서 본 저항이 상승한다. 이로 인해 전동기의 기계적 시정수가 커지고 전동기의 성능이 악화되는 결점이 있다.



(a)



(b)



(c)

Fig. 2.1 Rotation principle of DC motor.

### 2.3 직류전동기의 수학적 모델링

직류전동기는 정확하고 손쉬운 회전 속도제어가 가능하며, 기동특성이 우수하기 때문에 가·감속 및 역방향 회전이 용이하다. 본 논문에서는 이러한 장점을 가진 타여자 직류 전동기를 사용하였다 .

Fig. 2.2는 타여자 직류전동기의 등가모델을 보여주고 있다.




Fig. 2.2 Separate excitation field DC motor

일반적으로 전기자가 회전할 때 자속과 각속도의 곱에 비례하는 전압이 전기자에 유도된다. 이 유도된 전압은 전기자에 인가되는 전압과 반대방향이 되므로 이를 역기전력이라 한다. 그림 2.2의 등가회로에서 전기자의 전압방정식은 다음과 같이 나타낼 수 있다.

$$u_a - u_b = r_a i_a + L_{aa} \frac{di_a}{dt} \quad (2.1)$$

단,  $u_b$  : 역기전력 ( $= \omega_r L_{af} i_f$ )

그림 2.2 회로에서 계자의 전압방정식은 다음과 같다.

$$u_f = r_f i_f + L_{ff} \frac{di_f}{dt} \quad (2.2)$$

식(2.1)과 식(2.2)를 이용하여 계자권선과 전기자권선의 전압방정식을 행렬 형태로 나타내면 다음과 같다.

$$\begin{bmatrix} u_f \\ u_a \end{bmatrix} = \begin{bmatrix} r_f + pL_{ff} & 0 \\ \omega_r L_{af} & r_a + pL_{aa} \end{bmatrix} \begin{bmatrix} i_f \\ i_a \end{bmatrix} \quad (2.3)$$

단,  $p$ 는 미분연산자( $= \frac{d}{dt}$ )

직류전동기에서 발생하는 토크는 상호인덕턴스, 계자전류 및 전기자전류의 곱으로 표현되고 이를 식으로 표시하면 식(2.4)와 같다.

$$T_e = L_{af} i_f i_a \quad (2.4)$$

식(2.4)에서 계자전압을 일정하게 유지한다면 상호인덕턴스와 계자전류는 일정한 상수 값이 되며 발생토크는 오직 전기자전류에 비례하여 발생할 것이다.

그림 2.3은 직류전동기의 동역학적 모델을 나타낸다. 회전자와 부하의 관성모멘트의 합이  $J$ 이고, 베어링 손실을 포함한 전동기의 마찰계수가  $B_m$ 일 때 동역학적 수식은 다음과 같이 된다.

$$T_e = J \frac{d\omega_r}{dt} + B_m \omega_r + T_l \quad (2.5)$$

단,  $T_l$ 은 부하토크

직류 전동기의 동특성 모델을 나타내면 Fig 2.3과 같다

그림 2.3에서 마찰계수를 무시하면 전동기의 회전속도는 다음의 식으로 표현된다.

$$\frac{d\omega_r}{dt} = \frac{1}{J} (T_e - T_l) \quad (2.6)$$




Fig. 2.3 Dynamic model of DC motor.

## 제3장 신경회로망을 이용한 직류전동기의 속도추정

### 3.1 신경회로망의 개요

신경회로망은 인간이나 동물들이 가지고 있는 생물학적인 뇌의 신경세포(Neuron)을 모델화하여 인공적으로 지능을 만드는 것이다. 즉, 인간의 뇌에 존재하는 생물학적 신경세포와 이들의 연결관계를 단순화시켜 수학적으로 모델링함으로써 인간의 두뇌가 나타내는 지능적 형태를 구하는 것이다. 또한, 병렬 시스템인 인간의 두뇌를 모델링하여 만든 인공적인 두뇌를 공학이나 기타 여러 분야에 적용시키려고 하는 것이 신경회로망의 연구목적이다.

#### 3.1.1 신경회로망의 생물학적 구조

신경회로망의 구조를 알기 위해서는 반드시 인간의 뇌세포가 어떻게 이루어 졌는가를 알아야한다. 왜냐하면 신경회로망 연구는 기본적으로 인간의 두뇌 메카니즘을 구현하는 것을 그 목표로 하고있기 때문이다. 신경조직의 기본 구성요소는 신경세포 즉, 뉴런이다.

뉴런의 구성은 Fig. 3.1과 같으며 뉴런은 생체속에서 정보처리를 위해 특별한 분화를 이룬 세포이다. 그림에서 볼 수 있듯이 뉴런은 본체인 세포체(Soma) 부분과 복잡하게 갈라진 수상돌기(Dendrite)라고 불리는 부분, 그리고 본체에서 한 줄로만 뻗어 나와서 말단에서 다수로 갈라진 축삭(Axon)이라고 불리는 부분의 세 가지로 나누어져 있다. 축삭은 세포체 본체로 부터의 신호를 다른 뉴런에 전달하는 섬유(Nerve Fibers)이다.

수상돌기는 다른 뉴런으로부터의 신호를 받아들이는 부분이다. 즉, 다른 뉴런의 축삭의 말단이 여기에 연결되어 있다. 이 연결 부분을 시냅스(Synapse)라 부른다.

뉴런은 다른 뉴런으로부터의 신호를 받아들이고, 그것에 가중치(Weight)를 곱한 값을 더하고, 그 결과 발화하느냐, 하지 않느냐를 결정한다. 이것을 기본으로 뉴런의 수리 모델을 만들 수가 있다. 이때 중요한 점은 두 가지가 있는데 첫 번째는 선형 가산성으로서 뉴런은 다른 뉴런으로부터의 신호에 가중치를 곱하고 더한다. 두 번째는 비선



형 임계치 특성으로서 합계가 임계치를 넘지 않으면 아무 반응도 일어나지 않으며, 넘으면 펄스를 내보내는 비선형적인 동작을 한다.

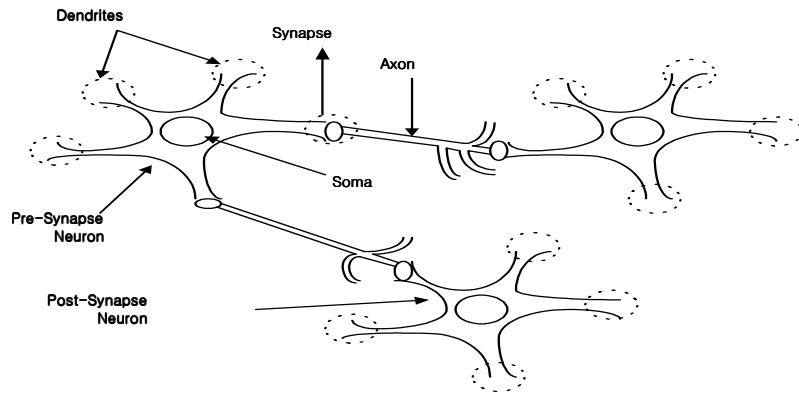


Fig. 3.1 Structure of biological neuron

### 3.1.2 신경 회로망의 구성요소와 동작특성

신경회로망에서 중요한 구성요소는 처리기(Processing Element)와 이들 상호간의 연결(Interconnection)이다. 뉴런의 인공적인 모델을 처리기 혹은 유니트(Unit)라고 한다. 뇌의 신경세포에 해당하는 처리기의 구성은 다음 그림과 같다.

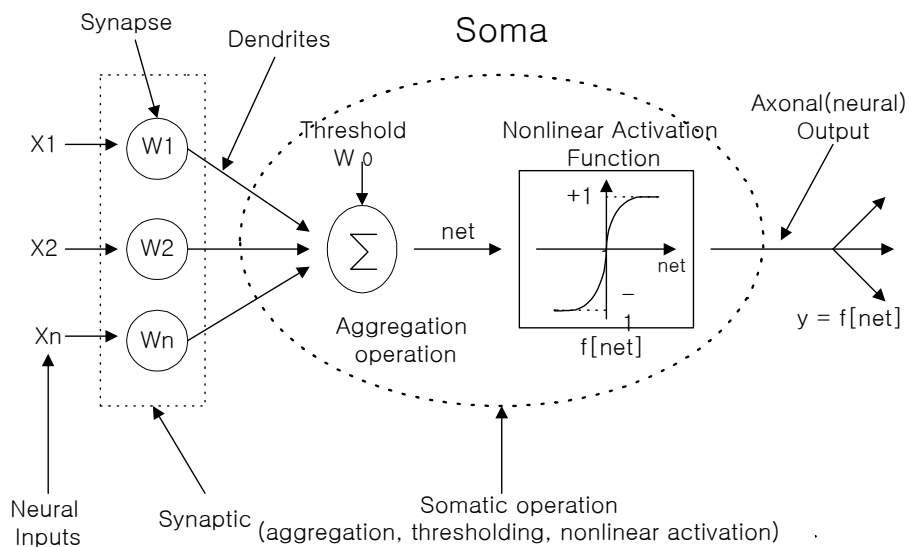


Fig. 3.2 Structure of artificial neuron

한 처리기에 연결된 다른 처리기들로부터의 입력에 연결선의 가중치를 고려하여 더한 후, 그 결과를 적당한 활성화함수(Activation Function)로 처리하여 연결된 다른 처리기로 출력한다.

이를 구체적으로 설명하면 다음과 같다. 하나의 처리기가 다른 처리기의 출력을 그 입력  $x_i$ 로 받아 해당하는 연결가중치  $w_i$ 를 곱한 가중치 합  $net$ 을 다음과 같이 구할 수 있다.

$$net = \sum_{i=1}^n w_i x_i \quad (3.1)$$

이 합을 활성화함수에 적용시켜서 얻은 결과를 그 처리기의 출력으로 하여 이와 연결되어 있는 다른 처리기로 보낸다. 그 출력은 다음과 같다.

$$y = f(net + \Theta) \quad (3.2)$$

여기서,  $f$ : 활성화함수

$\Theta$ : 처리기의 고유 바이어스

식(3.2)는 뉴런의 입력과 각 입력에 대응하는 시냅스 가중치를 곱하여 합한 값  $net$ 에 함수관계  $f$ 를 적용한 값을 출력한다.

신경회로망에서 사용되는 활성화함수는 Fig. 3.3에 나타내었고, 대표적으로 사용되는 활성화함수는 단극성 선형함수(Unipolar linear function), 양극성 선형함수(Bipolar linear function), 양극성 계단함수(Bipolar step function), 단극성 시그모이드 함수(Unipolar sigmoid function) 및 양극성 시그모이드 함수(Bipolar sigmoid function)등이 있다.

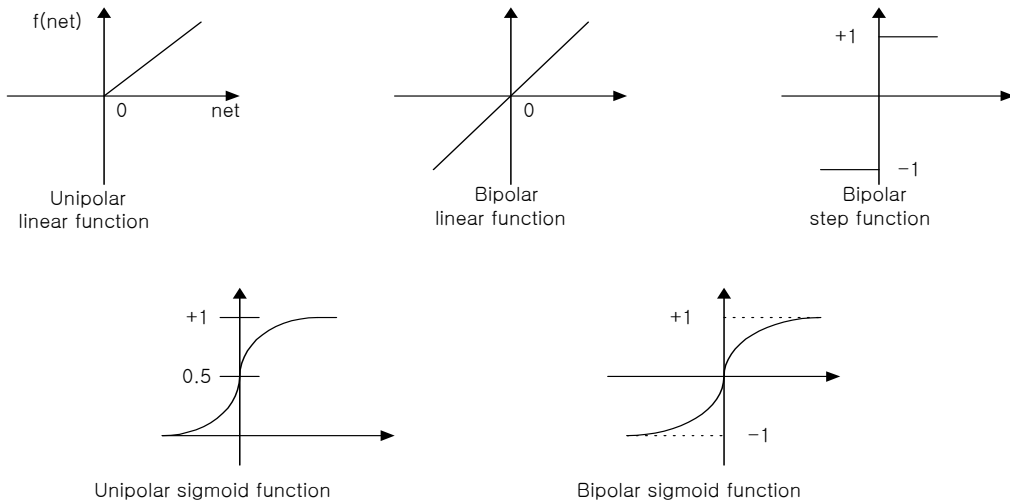


Fig. 3.3 Activation function used in neural network

### 3.1.3 다층 신경회로망의 구조와 학습

인간의 뇌는 수많은 뉴런으로 서로 연결되어 있다. 따라서 인간의 뇌와 유사한 인공적인 신경회로망은 다층의 구조라고 할 수 있다. 그리고 서로 연결된 뉴런에 의해서 더욱 좋은 기능을 발휘할 수 있다. 뉴런을 층에 배열하는 것은 뇌의 일부분인 계층화된 구조를 흉내낸 것이다. 전형적인 다층 신경회로망은 Fig. 3.4와 같다.

이 신경회로망은  $x$ 라는 입력벡터를 갖는 입력층과  $y$ 라는 출력벡터를 갖는 출력층으로 이루어지며 입력층과 출력층 사이의 층을 은닉층(Hidden Layer)이라 한다.

$y_i, y_j, y_k$ 는 입력층, 은닉층 및 출력층들의 각 뉴런의 출력이며, 입력층과 은닉층 사이의 가중치를  $w_{ij}$ , 은닉층과 출력층 사이의 가중치를  $w_{jk}$ 로 표기한다. 모든 정보는 신경회로망의 가중치에 저장되며 학습과정 동안 가중치  $w_{ij}, w_{jk}$ 의 성분은 계속적으로 새로운 정보로 바뀌어 진다.




Fig. 3.4 Structure of general multilayer neural network

신경회로망은 각 입력에 연결된 가중치를 조정함으로써 학습되는 데, 이는 신경회로망의 학습법칙을 이용하여 주어진 입력에 대해 올바른 출력을 내도록 연결가중치를 어떻게 변화시킬 것인가를 결정하게 된다.

신경회로망의 학습 종류는 기준에 따라서 여러 가지로 분류될 수 있다. 가장 일반적인 것으로는 감독학습(Supervised learning)과 무감독 학습(Unsupervised learning)이 있다.[7-9] 감독 학습은 학습 중 주어진 입력에 대하여 올바른 출력이 어떤 것이어야 하는지를 제공해 주는 학습법이다. 즉, 입력 패턴에 대한 신경회로망의 출력 패턴 형태를 지시해 주는 목적 패턴을 갖는 것으로 입력 패턴과 목적 패턴의 쌍들로 이루어진 학습 패턴이 사용된다.

입력 패턴이 신경회로망에 주어지면 신경회로망의 출력 패턴이 구해지고, 여기에 목적 패턴이 간섭하여 출력 패턴과 목적패턴이 같아지도록 연결 가중치를 조절한다. 이런 과정을 반복하여 신경회로망은 주어진 입력 패턴에 대해 그것과 쌍을 이루는 목적 패턴을 출력한다. 이 경우에 신경회로망은 자신의 출력이 올바른지를 판단할 수 있다.

감독 학습방법에는 헤브의 규칙, 델타 규칙, 오차 역전파(Error Back-propagation)

규칙 등이 있으며 무감독 학습방법에는 인스타 규칙, 자기 조직지도 등이 있다. 감독 학습방법 중 델타 학습법칙의 일종인 오차 역전파 규칙은 실제의 문제에 있어서 가장 널리 사용되는 학습법이다. 델타 학습 법칙의 기본은 현재 주어진 연결가중치로 생성되는 오차값을 구하여 이를 감소시키는 방향으로 연결가중치의 값을 조정하는 것으로 이 때 오차값의 계산을 위해 각 노드의 올바른 출력값을 제공해 주어야 한다. 하지만, 간단한 Exclusive OR 문제도 해결하지 못하는 단점을 가진다. 오차 역전파 규칙은 이러한 문제를 해결하기 위한 방법의 일종으로 다층의 신경망을 학습시키는데 적합하다. 오차 역전파 규칙은 일반화된 델타 규칙이라고도 불리우며 1986년 룸멜하트(David E Rumelhart)에 의해 만들어진 학습 규칙으로 오늘날 가장 유명해진 신경회로망 학습규칙 중 하나다.

오차 역전파 학습 알고리즘의 원리는 먼저 입력층에서의 신경회로망 입력  $x_i$ 를 은닉층으로 보낸다. 그리고, 은닉층의 뉴런들은 각각의 입력층으로부터 입력된 값과 가중치들의 곱을 합산함과 동시에 활성화함수를 통해 연산된 결과를 출력층으로 보낸다.

출력층은 은닉층과 같은 뉴런 연산을 행하여 출력한다. 이때 신경회로망의 출력값과 원하는 목표값과의 오차를 구한다. 이 오차를 최소화 하기 위해 각 층에 있는 가중치의 오차 벡터항을 편미분하여 가중치를 조정한다. 즉, 출력층의 출력과 원하는 목표값의 오차를 연산한 후 출력층에서 은닉층으로, 은닉층에서 입력층으로 역전파하여 가중치를 조정한다.

Fig. 3.5는 오차 역전파 알고리즘의 순서도이다.

지금까지 설명했듯이 오차 역전파 알고리즘은 오차 신호를 계산하고 신경회로망의 가중치들을 조정하기 위해서 바라는 응답값이 필요하다.

이러한 초기의 학습 후에 신경회로망은 학습에 사용되지 않은 새로운 데이터의 집합을 입력할 수 있다.

학습된 데이터의 집합이 아닌 다른 데이터에서도 정확하게 응답하는 것을 일반화 능력이라 한다. 그리고, 이것은 곧 신경회로망의 신뢰도를 가리킨다. 학습과 신경회로망의 성능을 검사한 후에 신경회로망은 패턴 분류기, 미지의 비선형 함수 및 복잡한 처리를 모델화하는데 사용될 수 있다.

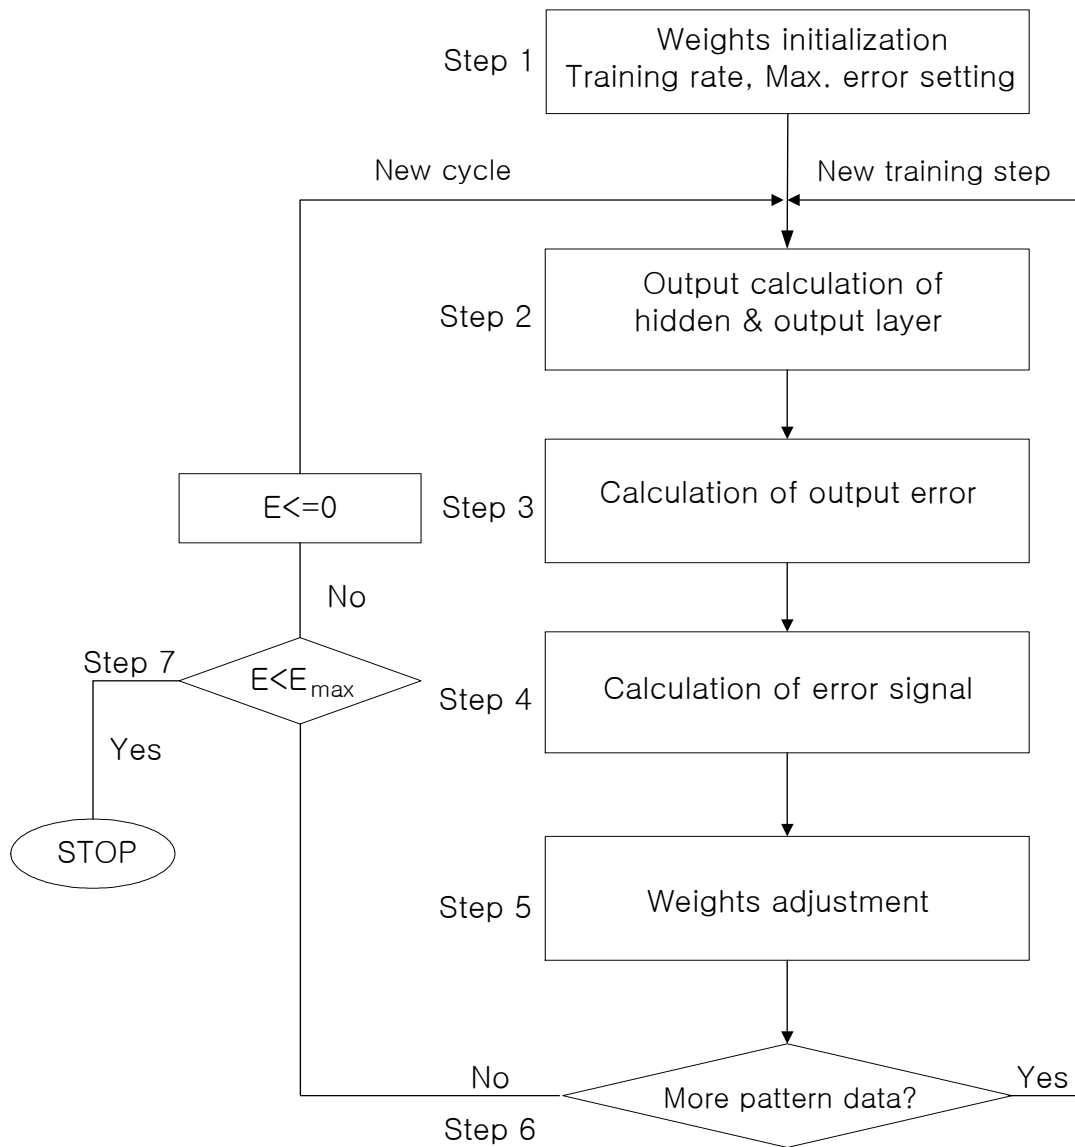


Fig. 3.5 Flow chart of backpropagation algorithm

오차 역전파 알고리즘의 학습 요소로는 초기 가중치, 누적가중치 조정과 증분의 갱신, 활성화함수의 기울기 및 학습률 등을 들 수 있다. 신경회로망을 학습시킬 때 초기 가중치는 작은 무작위 값으로 설정하는 것이 일반적이다. 그러나, 초기 가중치가 최종 출력에 크게 영향을 미칠 수가 있는 데 즉, 초기 가중치가 지역 최소점에 빠졌다면 가중치가 고정된 값에서 머물게 되므로 다른 지점에서 학습을 다시 시작해야 한다.

### 3.1.4 모멘텀(momentum)과 바이어스(bias)

모멘텀은 신경망의 연결 가중치 조정에 관성을 줌으로써 학습 시간을 단축하고 학습 성능의 향상을 위해 고안된 것이다. 모멘텀은 현재의 연결가중치와 그 이전 연결가중치의 차이에 의해 계산된다. 현재의 연결 가중치를  $w_{ij}(new)$ 로 나타내고 그 이전의 연결가중치를  $w_{ij}(old)$ 이라 한다면 현재의 모멘텀  $\Delta w_{ij}$ 는 다음과 같이 표현된다.

$$\Delta w_{ij} = w_{ij}(new) - w_{ij}(old) \quad (3.3)$$

따라서, 모멘텀을 구하기 위해서는 이전의 연결가중치를 저장하고 있어야 한다. 모멘텀은 연결가중치 변화에 관성을 줌으로써 연결가중치가 아주 얇은 지역인 극에 빠지는 것을 어느 정도 해결해 줄 수 있으며 신경망의 학습속도를 다소 향상시킬 수 있다.

바이어스는 신경 세포의 활성화에 참여할 뿐만 아니라 다른 연결가중치들과 마찬가지로 학습에 의해 조절된다.

## 4. 신경회로망을 이용한 직류 전동기 속도추정

### 4.1 신경회로망 입·출력 패턴

속도추정을 위한 신경회로망의 입·출력 데이터는 실제전동기 대신 수식 모델로부터 얻어지며, 식(2.3)~식(2.6)으로 부터 구할 수 있다.

신경회로망의 입력은 전압, 전류 성분과 시간지연항인  $u_a(k), u_a(k-1), i_a(k), i_a(k-1)$  들을 사용하였으며, 출력은 식(2-6)에 의해 구한 회전자 각속도  $\omega_r(k)$ 를 이용하였다.

### 4.2 신경회로망에 의한 속도 추정기

신경회로망의 은닉층 개수와 노드수는 수차례에 걸친 시행착오를 통하여 16개의 노드를 갖는 1개의 은닉층으로 구성하였고 은닉층의 활성화함수는 Tansigmoid 함수를 사용하였으며, 출력층에는 선형함수를 사용하였다.

은닉층 활성화함수로 사용하는 Tansigmoid 함수를 수식으로 표현하면 다음과 같다.

$$\mathcal{A}(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (4.1)$$

Fig. 4.1은 신경회로망에 의한 속도추정기의 구조이다.

신경회로망의 추정속도  $\omega_{rr}$ 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.

Fig. 4.2는 연결가중치를 구하는 시스템 블록도이며 실제 직류전동기 대신 수식모델을 이용하였다.






Fig. 4.1 Speed estimator by neural network

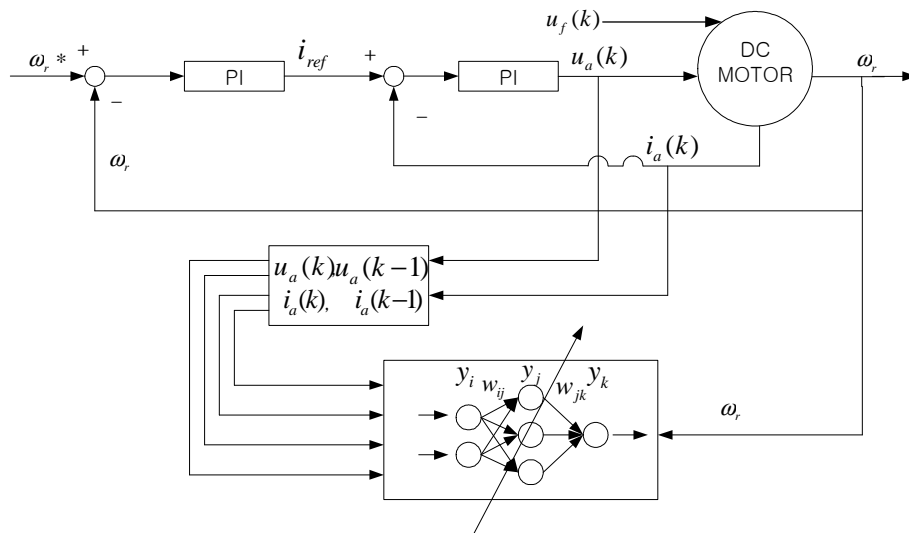


Fig. 4.2 Block diagram for training of neural network speed estimator

Fig. 4.3은 속도추정기 구성을 위해 신경회로망의 목적패턴 데이터로 사용된 직류 전동기 수식 모델의 속도파형이며, 부하(1 [N·m])를 인가한 상태이다.

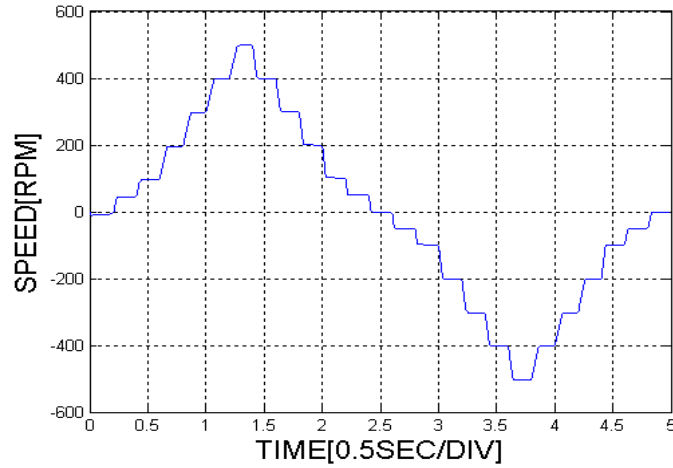


Fig. 4.3 Speed responses of DC model

다음 수식들은 신경회로망의 출력을 구하는 과정을 수식으로 표현한 것이다.

$$net_i = x_i \quad (i = 1, 2, \dots, n) \quad (4.2)$$

$$y_i = f(net_i) \quad (4.3)$$

$$net_j = \sum_j (w_{ij} y_i + b_j) \quad (4.4)$$

$$y_j = f(net_j) \quad (4.5)$$

$$net_k = \sum_k (w_{jk} y_j + b_k) \quad (4.6)$$

$$y_k = f(net_k) \quad (4.7)$$

전동기의 실제속도와 신경회로망의 추정속도의 오차는 다음과 같이 정의한다.

$$E = \frac{1}{2} \sum_k (\omega_r^* - \omega_{nr})^2 \quad (4.8)$$

학습은 이 오차를 최소화하는 방향으로 학습하여 강도를 조정하는 것이므로 경사

하강법에 따라 출력층에 요구되는 연결강도 변화량은 다음과 같이 나타낸다.

$$\Delta\omega_{jk} = -\alpha \frac{\partial E}{\partial \omega_{jk}}, \quad \alpha > 0 \quad (4.9)$$

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

$$\delta_k = -\frac{\partial E}{\partial net_k} \quad (4.10)$$

연쇄법칙에 의해 식(4-9)의 우변항은 다음과 같이 표현된다.

$$\frac{\partial E}{\partial \omega_{jk}} = \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial \omega_{jk}} = -\delta_k \frac{\partial net_k}{\partial \omega_{jk}} \quad (4.11)$$

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

$$\frac{\partial net_k}{\partial \omega_{jk}} = \frac{\partial (\sum_j \omega_{jk} y_j + b_k)}{\partial \omega_{jk}} = y_j \quad (4.12)$$

그러므로 출력층의 연결강도 변화량은 다음과 같이 구하여 진다.

$$\Delta w_{jk} = \alpha \delta_k y_j \quad (4.13)$$

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

$$\delta_k = -\frac{\partial E}{\partial net_k} = -\frac{\partial E}{\partial \omega_{nr}} \frac{\partial \omega_{nr}}{\partial net_k} \quad (4.14)$$

식 (4-8)로 부터 다음 식을 구한다.

$$\frac{\partial E}{\partial w_{nr}} = -(w_r^* - w_{nr}) \quad (4.15)$$

그리고 식(4-7)을 이용하여 다음 식을 구할 수 있다.

$$\frac{\partial \omega_{nr}}{\partial net_k} = f'(net_k) \quad (4.16)$$

본 논문에서 사용한 활성화함수는 다음 식(4-17)과 같으며, 이 식을 미분하여  $x = net_k$ 를 대입하면 식(4.18)이 된다.

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (4.17)$$

$$f'(net_k) = (1 + f(net_k))(1 - f(net_k)) \quad (4.18)$$

활성함수의 출력  $f(net_k)$ 는 결국 신경회로망의 출력층의 출력인 추정속도  $\omega_{nr}$  이므로 대치하면 아래 식과 같다.

$$\frac{\partial \omega_{nr}}{\partial net_k} = (1 + \omega_{nr})(1 - \omega_{nr}) \quad (4.19)$$

그러므로  $\delta_k$ 는 다음 식(4.20)과 같이 나타낼 수 있다.

$$\delta_k = (\omega_r - \omega_{nr})(1 + \omega_{nr})(1 - \omega_{nr}) \quad (4.20)$$

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

$$\Delta w_{jk}(k+1) = \Delta w_{jk} + \alpha \delta_k y_j \quad (4.21)$$

$$\Delta w_{ij}(k+1) = \Delta w_{ij} + \alpha \delta_j y_i \quad (4.22)$$

연결강도는 식(4.21) 및 식(4.22)에 의해 조정되며 이는 실제속도  $\omega_r$ 과 추정속도  $\omega_{nr}$ 의 오차가 최소화될 때까지 반복된다.

이러한 학습을 통하여 구하여진 최적의 연결강도를 이용하여 직류전동기 회전자 속도를 다음식(4.23)과 같이 추정한다.

$$\omega_{nr} = [ F_j(X_i w_{ij} + B_j) ] w_{jk} + B_k \quad (4.23)$$

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 출력층사이의 연결강도

Fig. 4.4는 학습을 통하여 구하여진 연결가중치에 의해 출력된 추정 속도파형을 보여주고 있다.




Fig. 4.4 Speed responses of neural network estimator

Fig. 4.5는 직류전동기 센서리스 속도제어 구동 시스템의 블록도이다.

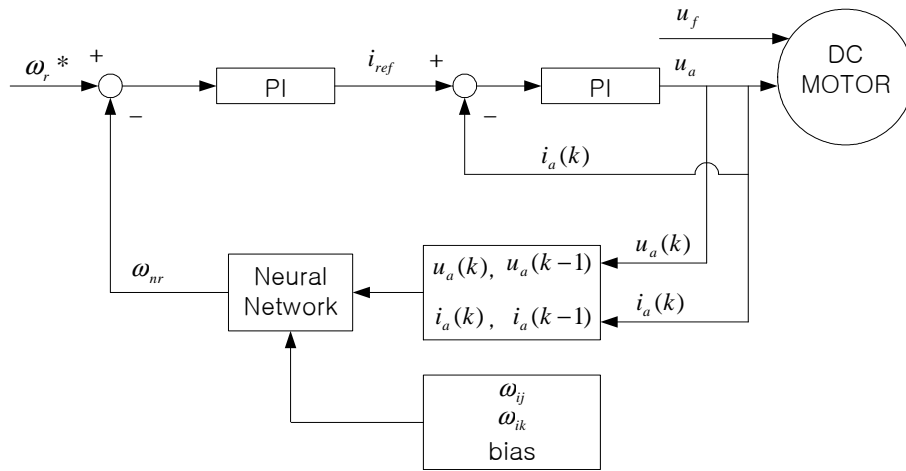


Fig. 4.5 Block diagram of speed control system by neural network

## 5. 시뮬레이션

본 논문에서 제안한 신경회로망을 이용한 직류 전동기의 센서리스 속도제어 알고리즘의 검증을 위해 실험에 앞서 컴퓨터 시뮬레이션을 행하였다. 시뮬레이션 및 실험에 사용한 직류 전동기의 파라미터 및 시스템 정수는 Table 1과 같다.

Table 1 Parameters of DC motor used for experiment

|      |                         |          |                  |
|------|-------------------------|----------|------------------|
| 정격출력 | 0.5 [kW]                | $R_a$    | 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. 5.1, Fig. 5.2는 0→100[rpm], 0→200[rpm]의 계단속도지령을 가했을 경우의 속도를 나타내고 있으며, 중·저속에서의 속도응답 특성이 양호함을 확인할 수 있다.

Fig. 5.3, Fig. 5.4는 0→300[rpm], 0→500[rpm]의 계단속도지령을 가했을 경우의 속도를 나타내고 있으며, 중·고속에서의 속도응답 특성이 우수함을 볼 수 있다.

Fig. 5.5, Fig. 5.6는 100[rpm], 300[rpm]의 속도로 구동중 1[N·m]의 부하인가시의 속도응답특성을 나타내고 있으며 부하운전시에도 속도응답의 속응성이 뛰어난을 알 수 있다.

또한, Fig. 5.7는 200[rpm]의 속도로 구동중 200[rpm] → -200[rpm]의 반전속도지령을 가했을 경우의 응답을 도시한다. 역전 지령시에도 속도응답의 속응성이 뛰어난을 알 수 있다.




Fig. 5.1 Simulation response to step change of speed setting  
(0→100[rpm])

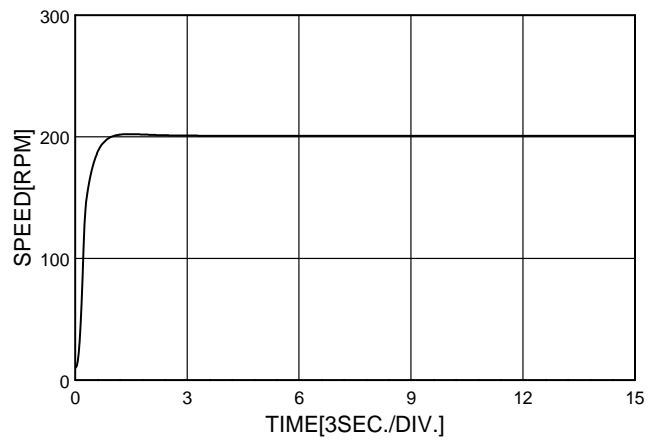


Fig. 5.2 Simulation response to step change of speed setting  
(0→200[rpm])






Fig. 5.3 Simulation response to step change of speed setting  
(0→300[rpm])

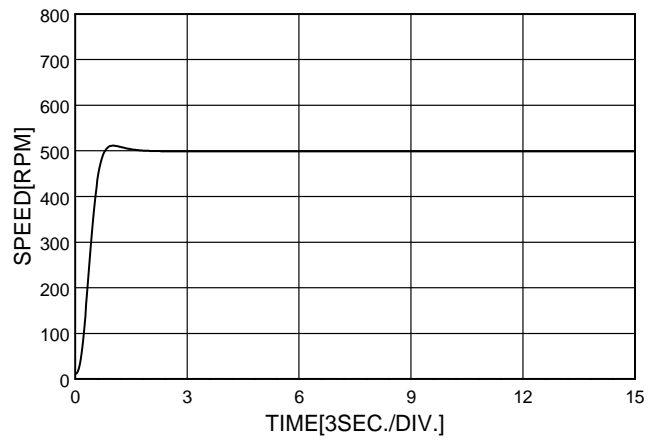


Fig. 5.4 Simulation response to step change of speed setting  
(0→500[rpm])




Fig. 5.5 Simulation response to step change of load torque.  
(0→1[N·m])




Fig. 5.6 Simulation response to step change of load torque.  
(0→1[N·m])




Fig. 5.7 Simulation response to step change of speed setting  
(200[rpm]→-200[rpm])

## 6. 실험결과

본 논문의 속도제어시스템의 전체 구성도를 Fig 6.1에 도시한다. 시스템을 구현하기 위한 하드웨어의 구성은 세부적으로 마이크로프로세서 시스템, 전기자전류 및 직류링크전압 검출회로, 게이트 구동회로, 전력회로로 나누어진다[15]. 또한, 제어성능의 확인을 위해 제어회로와는 별도로 속도검출회로가 사용되어 진다.

마이크로프로세서 시스템은 80586 마이크로프로세서가 장착된 IBM PC를 사용하였고 PCL 818 카드를 이용하여 데이터를 처리하였다.

직류링크전압의 샘플링은 전압검출기 LEM LV25-P 및 저항을 사용하여 0[V]~5[V] 범위의 전압으로 변환시켜 A/D 컨버터를 통해 검출하였다.

초퍼 스위칭을 위한 최종적인 신호발생회로인 게이트 구동회로는 초퍼를 구성하는 스위칭 소자인 IGBT를 구동시키기 위하여 마이크로프로세서에서 발생된 TTL레벨의 신호를 게이트 신호의 레벨로 증폭시켜주는 회로이다. 이러한 게이트 구동회로는 개별 소자로 직접 제작하여 사용할 수도 있지만, 본 실험장치를 위해서는 상용으로 만들어진 게이트 구동용 전용 IC인 TF1205를 사용하였다.

전력회로의 구성은 정류부와 초퍼부, 그리고 제어장치의 전원공급부로 나누어진다. 정류부는 브리지 정류기와 평활용 콘덴서로 이루어지며 전원 오프시에 콘덴서에 남아 있는 고압충전전압은 전자접촉기에 의해 저항을 통하여 방전되도록 하였다. 초퍼부는 IGBT모듈을 사용하여 구성하였는데 다른 소자에 비해 고속의 스위칭 동작이 가능하므로 제어신호에 대한 응답속도가 빠르다.

속도제어 실험의 검증을 위하여 속도검출회로를 구성하였다. 본 실험에서는 출력펄스간의 시간간격을 측정함으로써 속도를 계산하는 T방식을 적용하였고 360[pulses/rev]의 엔코더를 사용하였다. 엔코더 펄스간의 시간간격은 펄스 한 주기 동안 발생하는 1[MHz] 발진기의 클럭을 계수하여 환산하였다.

Fig. 6.1은 본 논문의 전체 하드웨어 블록도를 나타낸 것이다. 또한, Fig. 6.2는 제어부로서 80586 마이크로프로세서, PCL-818 Card를 이용한 카운터 및 A/D 변환부를 나타내며, Fig. 6.3은 전력변환부로서 정류장치, 초퍼, 게이트 구동회로 등으로 구성되어 있다. Fig. 6.4는 본 실험에서 사용한 2마력 직류 전동기와 부하실험을 위한 부하

인가장치를 보여준다.

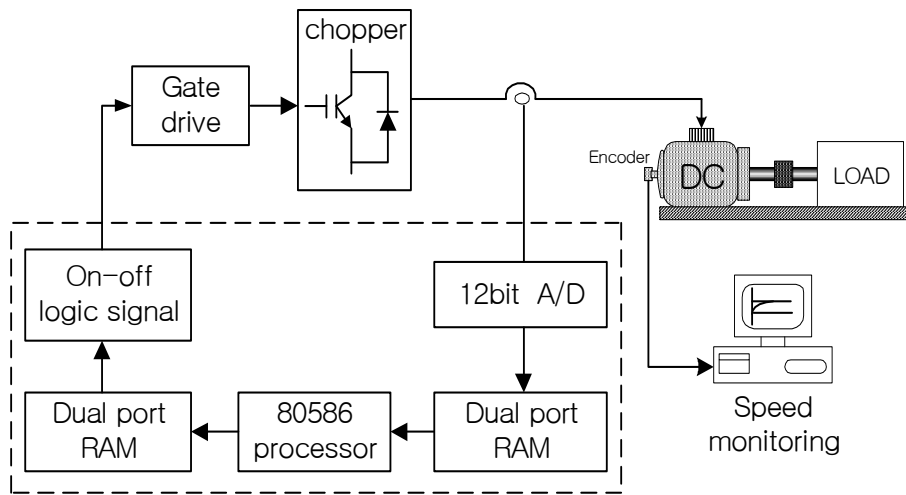


Fig. 6.1 Overall DC motor drive system.



Fig. 6.2 Control part.




Fig. 6.3 Power conversion part.




Fig. 6.4 Direct current motor and load impression system.

Fig. 6.5, Fig. 6.6는 각각 0→100[rpm], 0→200[rpm]의 계단속도지령을 가했을 경우의 속도파형이며, 저속에서 응답특성이 양호함을 볼수 있다.

Fig. 6.7, Fig. 6.8은 0→500[rpm], 0→1000 [rpm]의 계단속도지령을 가했을 경우 속도 파형을 나타내고 있으며 중·고속에서도 속도응답이 우수함을 보여주고 있다.

Fig. 6.9, Fig. 6.10은 각각 100[rpm]과 300[rpm]의 속도로 구동중 1[N·m]의 부하인가시에 속도응답 특성이며 부하 운전시에도 속도응답의 속응성이 뛰어난을 볼 수 있다.

Fig. 6.11은 0→200[rpm]으로 구동중 200[rpm]→-200 [rpm]의 반전속도 지령을 가했을 경우 응답이며 속도응답이 양호함을 볼 수 있다.

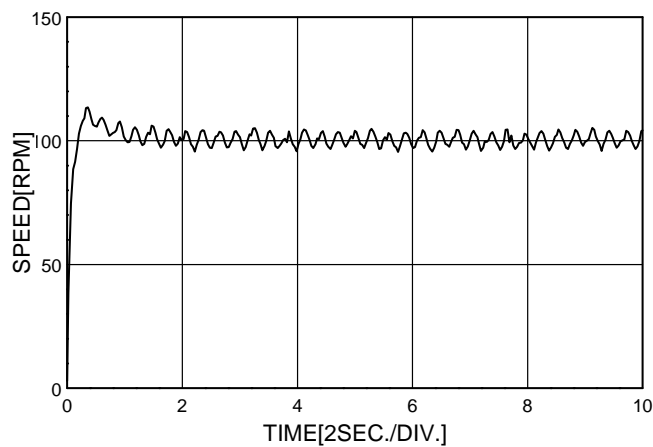


Fig. 6.5 Experimental response to step change of speed setting  
(0→100[rpm])




Fig. 6.6 Experimental response to step change of speed setting.  
(0→200[rpm])




Fig. 6.7 Experimental response to step change of speed setting.  
(0→500[rpm])






Fig. 6.8 Experimental response to step change of speed setting.  
(0→1000[rpm])

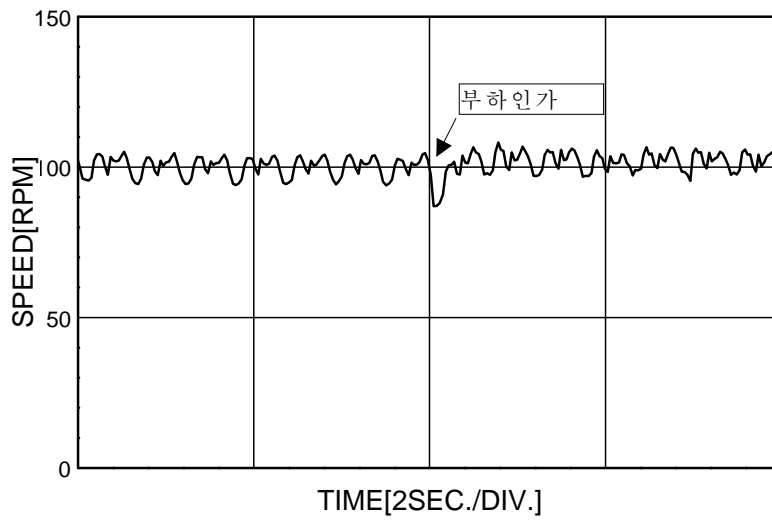


Fig. 6.9 Experimental response to step change of load torque.  
(0→1[N·m])

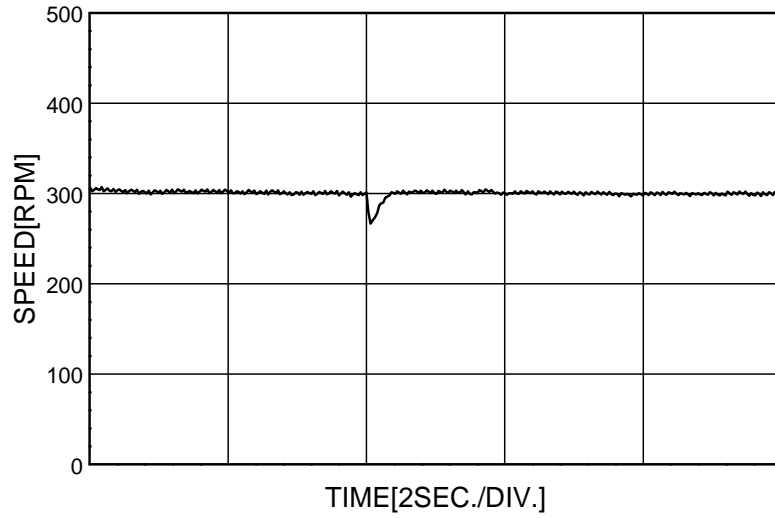


Fig. 6.10 Experimental response to step change of load torque.  
( $0 \rightarrow 1$  [N·m])




Fig. 6.11 Experimental response to step change of speed setting  
( $200[\text{rpm}] \rightarrow -200[\text{rpm}]$ )

## 7. 결 론

본 논문에서는 산업현장 전반에서 널리 사용되고 있는 직류 전동기의 센서리스 속도 제어에 관하여 연구하였으며, 기존의 센서리스 속도제어 방식의 문제점인 저속에서의 동특성 저하와 파라미터 의존성을 보완하고자 신경회로망을 이용하여 속도추정기를 구성하였다.

이 방식은 직류 전동기 모델의 수치 시뮬레이션을 통해 미리 얻어진 전압, 전류 및 회전자속도 정보를 신경회로망의 입·출력 데이터로 사용하여 학습 알고리즘을 통해 연결가중치를 구한 후, 전동기 전압, 전류값과의 연산에 의해 속도를 추정한다.

본 논문의 연구결과를 요약하면 다음과 같다.

- 1) 신경회로망을 이용하여 직류전동기의 속도 추정을 하였다. 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.
- 2) 기존의 속도추정 방식이 가지는 복잡성과 파라미터 의존성의 개선에 관심을 두고 연구하였다.
- 3) 컴퓨터 시뮬레이션과 실제 실험을 통해 속도지령에 대한 추종성이 양호함을 확인할 수 있었고 외란과 파라미터 변화에 대해서도 강인한 제어특성을 보임을 알 수 있었다.

## 참고 문헌

- [1] Katsuhiko Ogata, "Modern Control Engineering", 문운당, 1993.
- [2] Benjamin C. Kuo, "Automatic Control Systems", Prentice Hall, 1991.
- [3] S. Tamai, H. Sugimoto and M. Yano, "Speed Sensorless Vector Control of Induction Motor with Model Reference Adaptive System", IEEE/IAS, pp.185-195, 1997.
- [4] 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.
- [5] 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.
- [6] N. Ertugrul and P.P Acarnley, "A New Algorithm for Speed Operation of Permanent Magnet Motors", *IEEE IAS Conf. Rec.*, pp. 414-421, 1992.
- [7] M. M. Gupta and N. K. Sinha, "Intelligent Control Systems", IEEE Press, 1996
- [8] J. -S. R. Jang, C. -T. Sun, E. Mizutani, "*Neuro-Fuzzy and Soft Computing*", Prentice Hall, 1997.
- [9] 임영도, "퍼지 · 신경망 · 유전진화", 1999.
- [10] 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
- [11] 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.
- [12] K. S. Narendra and K. Parthasarathy, "Identification and Control of Dynamical Systems Using Neural Networks", *IEEE Trans. on Neural Networks.*, vol. 1, No.1, pp.4~27, 1990
- [13] F. C. Chen and H. K. Khalil, "Adaptive Control of a Class of Nonlinear Discrete-Time Systems Using Neural Networks", *IEEE Trans. on Auto. Con.* vol. 1, No. 5, pp. 791~801, 1995

- [14] Paul C. Krause, *"Analysis of Electric Machinery"*, McGRAW-HILL, 1986.
- [15] B. K. Bose, *Power Electronics and AC Drives*, Prentice-Hall, 1987.
- [16] K. K. Shyu and H. J. Shieh, "Variable Structure Current Control for Induction Motor Drives by Space Voltage Vector PWM," *IEEE Trans. Indus. Electron.*, Vol. 42, No. 6, pp. 572-578, 1995.
- [17] 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.