

신경망-유전자 알고리즘을 이용한 전기·유압 서보시스템의 파라미터 식별

곽동훈*, 정봉호*, 이춘태*, 이진걸**

Parameter Identification Using Hybrid Neural-Genetic Algorithm in Electro-Hydraulic Servo System

Dong-Hoon Kwak*, Bong-Ho Jung*, Choon-Tae Lee* and Jin-Kul Lee**

ABSTRACT

This paper demonstrates that hybrid neural-genetic multimodel parameter estimation algorithm can be applied to structured system identification of electro-hydraulic servo system. This algorithm are consist of a recurrent incremental credit assignment (ICRA) neural network and a genetic algorithm. The ICRA neural network evaluates each member of a generation of model and genetic algorithm produces new generation of model. We manufactured electro-hydraulic servo system and the hybrid neural-genetic multimodel parameter estimation algorithm is applied to the task to find the parameter values(mass, damping coefficient, bulk modulus, spring coefficient) which minimize total square error.

Key Words : hybrid neural-genetic multimodel parameter estimation algorithm(하이브리드 신경망-유전자 알고리즘), electro-hydraulic servo system(전기·유압 서보시스템)

기호설명

K_a : Servo amp. gain [mA/V]

M : Mass [kg]

B : Viscosity coefficient of cylinder [Nm/sec]

K : Spring coefficient [N/m]

C_d : Discharge coefficient

F_L : Disturbance

w : Area gradient [m]

x_v : Spool displacement [m]

V : Total volume in cylinder [m^3]

1. 서론

전자계측장치와 마이크로 프로세서의 발달로 유압시스템은 고도로 정밀하고 신뢰성 있는 제어가 가능해졌다. 유압의 고출력의 특징과 전기적 신호 처리의 장점을 결합한 전기·유압 서보시스템은 그 응용범위가 점점 더 확대되어가고 있으나, 제어입력의 포화, 밸브 방향의 절환, 누유, 마찰 등으로 인해 강한 비선형성을 가지고 있고, 부하변동, 외부온

* 2002년 4월 18일 접수

* 부산대학교 대학원 지능기계공학과

** 부산대학교 기계공학부

도의 변화와 구성품 마모로 인한 체적탄성계수 변화와 같은 외부 환경 요인으로 인해 파라미터 변동이 심한 특징을 가지고 있다.

전기·유압 서보 시스템에서의 파라미터 식별에 관해 실험을 통해 수행한 연구는 Navid 등이 입력과 출력 값에 따라 작동점 근처에서 선형적인 모델과 파라미터를 구하여 강인한 힘제어기를 제시하였고¹⁾, Tan은 유압식 현가장치에서 각각의 구성품에 대한 입·출력 데이터를 이용하여 파라미터를 식별하여 모델식을 구현하였으며²⁾, Majjad 또한 유압식 현가장치에서의 감쇠특성을 추정하는 부분에 대한 연구를 수행하였다³⁾. 그러나, 이를 대부분의 연구들은 시스템을 제어하기 위해 단순히 식별을 수행하였고, 식별에 사용된 방법은 주로 최소자승법이었다. 이러한 방법은 전역해를 구하지 못하고 국부해에 빠지는 위험 요소를 가지고 있다. 따라서, 본 논문에서는 비선형성이 강한 전기 유압 서보 시스템의 파라미터를 구하기 위해 전역해를 구할 수 있는 추정 알고리즘인 하이브리드 신경망-유전자 알고리즘을 이용하여, 입·출력 실험 데이터를 이용하여 시스템의 파라미터인 질량 M , 감쇠계수 B , 스프링 상수 K , 체적탄성계수 K_m 을 구하였다. 또한 결과의 타당성을 확인하기 위해 실험에서 구한 파라미터를 이용하여 추정한 궤적과 실험궤적의 비교 분석을 수행하였다.

2. 시스템 구성 및 모델링

2.1 시스템 구성

본 연구에서 설계 제작한 전기유압 서보시스템의 구성은 Fig. 1과 같다.

시험기의 상부는 다양한 관성부하 조건에서 실험할 수 있도록 하중을 가변 할 수 있게 제작하였고, 스프링, 댐퍼 시스템과 유압실린더를 병렬로 설치하고, 양단에 수직하중이 작용하도록 하기 위해 크래비스 베어링을 설치하였다.

스프링, 댐퍼 시스템은 차량용 현가장치를 이용하였으며, 유압실린더는 행정 140mm의 편로드 실린더를 사용하였다.

센서로는 변위를 측정하기 위하여 포텐ショ미터를 장착하였으며, 시스템의 제어를 위한 제어기로는 66MHz급의 퍼스널 컴퓨터를 사용하였다. 인터페이스 장치로는 12비트 분해능을 가지는 A/D, D/A 보드를 사용하였다.

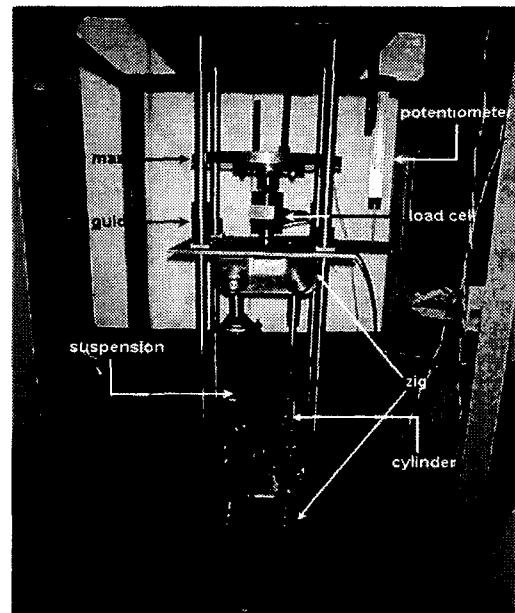


Fig. 1 Schematic of electro-hydraulic servosystem

2.2 전기·유압 서보시스템 모델링

Fig. 2는 전기·유압 서보시스템의 위치제어를 위한 계통도이다. 유압실린더의 피스톤 변위는 변위 계측 센서인 포텐ショ미터에 의해 전기적 신호로서 검출되고, 기준입력과의 오차를 보정하기 위한 제어입력이 서보 증폭기에 가해지고, 서보 밸브 스플의 변위를 발생시켜 실린더에 유입되는 유량을 조절함으로써 변위를 제어하도록 구성되어 있다.

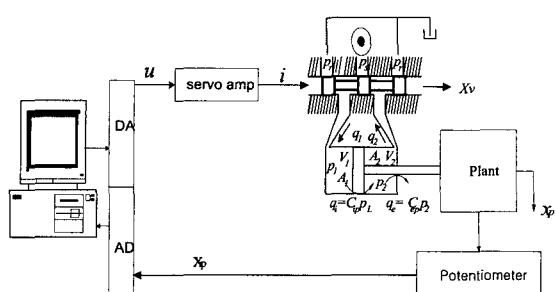


Fig. 2 Schematic diagram of electro-hydraulic position control system

서보 밸브의 입력전류 $i(t)$ 와 제어입력 $u(t)$ 는 $i(t) = K_a u(t)$ 와 같은 비례관계를 가진다고 가정한다.

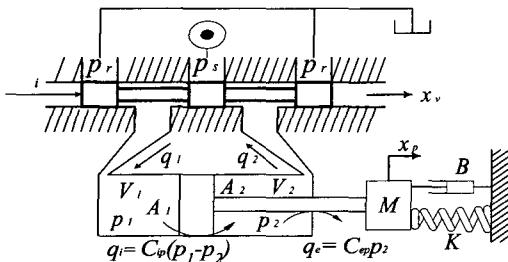


Fig. 3 Single-rod electro-hydraulic servosystem

서보밸브와 실린더 부하계는 Fig. 3과 같다. 스플 변위에 따라 실린더에 유입되는 유량 q_1 은 식(1)과 같다.

$$q_1 = Av_1 = C_d w x_v \sqrt{\frac{2(p_s - p_1)}{\rho}} \quad (1)$$

실린더의 유량이 공급되는 부분을 검사체적으로 설정하고 질량보존의 법칙을 적용하여, 압력과 스플 변위에 관한 운동방정식을 구하면 식(2)와 같은 관계가 구해진다.

$$\rho \frac{dV}{dt} + V \frac{d\rho}{dt} = \rho A V \quad (2)$$

유량이 유출되는 실린더의 반대편에 대해서도 동일하게 식(2)가 적용되므로, 밀도에 대한 항을 압력에 대한 관계로 변환하면 식(3)과 같이 된다. 편로드 실린더를 사용하였으므로, 두 개의 방정식이 하나로 합쳐지지는 않는다.

$$\begin{aligned} \frac{dV_1}{dt} + \frac{V_1}{K_m} \frac{dp_1}{dt} &= q_1 \\ \frac{dV_2}{dt} + \frac{V_2}{K_m} \frac{dp_2}{dt} &= q_2 \end{aligned} \quad (3)$$

서보밸브의 스플변위 x_v 가 0보다 클때와 0보다 작을 때 두 가지 경우가 발생하므로, 부호함수 $sgn(n)$ 을 도입하여 압력변화에 대해 정리하면 식

(4)와 같이 표현되어진다.

$$\begin{aligned} \dot{p}_1 &= \frac{K_m}{V_1} (C_d w x_v sgn(p_s - p_1) \sqrt{\frac{2}{\rho} |p_s - p_1|} - A_1 \dot{x}_p) \\ \dot{p}_2 &= \frac{K_m}{V_2} (C_d w x_v sgn(p_2 - p_r) \sqrt{\frac{2}{\rho} |p_2 - p_r|} - A_2 \dot{x}_p) \end{aligned} \quad (4)$$

편로드 유압 실린더와 부하의 운동 방정식은 식(5)과 같이 표현되어진다.

$$\begin{aligned} M \frac{d^2 x_p(t)}{dt^2} + B \frac{dx_p(t)}{dt} + K x_p(t) + F_L \\ = (A_1 p_1 - A_2 p_2) \end{aligned} \quad (5)$$

식(1)~(5)에서 $p_1 = x_1$, $p_2 = x_2$, $x_p = x_3$, $\dot{x}_p = x_4$ 라 두고, 외란 F_L 을 무시하고, 정리하면 식(6)과 같은 상태방정식을 구할 수 있다.

$$\begin{aligned} \dot{x}_1 &= \frac{K_m}{V_1} (C_d w x_v sgn(p_s - p_1) \sqrt{\frac{2}{\rho} |p_s - x_1|} - A_1 x_4) \\ \dot{x}_2 &= \frac{K_m}{V_2} (C_d w x_v sgn(p_2 - p_r) \sqrt{\frac{2}{\rho} |x_2 - p_r|} - A_2 x_4) \\ \dot{x}_3 &= x_4 \\ \dot{x}_4 &= -\frac{B}{M} x_4 - \frac{K}{M} x_3 + \frac{1}{M} (A_1 x_1 - A_2 x_2) \end{aligned} \quad (6)$$

3.하이브리드 신경망-유전자 알고리즘

3.1 개요

일반적으로 동적 시스템은 식(7)과 같이 표현된다.

$$\begin{aligned} x_t^\theta &= f(x_{t-1}^\theta, u_t; \theta) \\ y_t^\theta &= g(x_t^\theta, u_t; \theta) + v_t \end{aligned} \quad (7)$$

여기서, $f(\cdot, \cdot, \cdot)$, $g(\cdot, \cdot, \cdot)$ 은 비선형 함수이고 $t = 1, 2, \dots$ 는 시간변수, θ 는 유클리언 공간상에서 값을 취하는 미지의 파라미터이다. 따라서, 미지의 파라미터는 입력이 주어지면 상태 x_t^θ 가 변화하게 되고, 이때 y_t^θ 를 관측함으로써 결정할 수 있다. 동적 구조가 결정되어진 상태에서의 식별에 대한 연구는 현재까지 수십 년 간 진행되어 왔으나, $f(\cdot, \cdot, \cdot)$, $g(\cdot, \cdot, \cdot)$ 가 비선형일 경우와 θ 가 저차수일 경우에는 값을 찾을 수 없었다.⁴⁾⁵⁾⁶⁾

따라서, 본 연구에서는 비선형 시스템의 식별 조건을 만족하는 유일해(unique solution)를 찾기 위해 다중 모델로 구성된 하이브리드 신경망-유전자 알고리즘⁷⁾을 사용하였다.

3.2 하이브리드 신경망-유전자 알고리즘

이 알고리즘의 주 구성요소는 모델의 세대 당 각각의 개체들끼리의 신뢰도 함수를 제공하는 회귀적 신뢰도 평가 신경망(recurrent incremental credit assignment(ICRA) neural network)과 새로운 모델의 세대를 생성하기 위해 확률적 선택으로서 신뢰도 함수를 사용하는 유전자 알고리즘이다.

신뢰도 함수는 실제 출력에 대한 모델 각각의 출력의 근사 정도를 반영하고 유전자 알고리즘은 교배와 돌연변이에 의한 파라미터 공간을 탐색한다.

본 논문에서 신뢰도 평가 신경망을 이용해서 그 세대의 모든 모델을 평가하고, 모든 평가는 유전자 알고리즘이 평가해서 새로운 세대의 모델을 생산하게 된다. 더욱이 유전자 알고리즘은 전역 최적해를 탐색하는 장점을 가지고 있다.

3.2.1 신뢰도 평가 신경망

신뢰도 평가 신경망은 모델 $Q = (\theta_1, \theta_2, \dots, \theta_K)$ 를 평가하는데 사용한다. 여기서, Q 는 K 개의 파라미터 집합을 가지고 있다.

신뢰도 평가 신경망의 구조는 Fig. 4와 같이 구현할 수 있다. 시스템 출력은 식(8)과 같고, 모델의 출력은 식(9)와 같이 나타낼 수 있다.

$$Y_1 = \begin{vmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{vmatrix}, \quad Y_2 = \begin{vmatrix} y_{N+1} \\ y_{N+2} \\ \vdots \\ y_{2N} \end{vmatrix}, \dots \quad (8)$$

$$Y_1^k = \begin{vmatrix} y_1^k \\ y_2^k \\ \vdots \\ y_N^k \end{vmatrix}, \quad Y_2^k = \begin{vmatrix} y_{N+1}^k \\ y_{N+2}^k \\ \vdots \\ y_{2N}^k \end{vmatrix}, \dots, \quad Y_s^k = \begin{vmatrix} y_{(s-1) \cdot N+1}^k \\ y_{(s-1) \cdot N+2}^k \\ \vdots \\ y_{(s-1) \cdot 2N}^k \end{vmatrix}, \dots \quad (9)$$

Y_s 는 시스템의 N 회의 출력을 갖고 있고, Y_s^k 는 k 번째 모델의 N 회 출력을 가지고 있다. 여기서, 데이터 획득횟수를 시간 s 로서 정의하면 $s = 1$ 에 대해서 $t = 1, 2, \dots, N$, $s = 2$ 일 때

$t = N+1, N+2, \dots, 2N$ 과 같은 형태로 계속되어진다. 그리고, 오차함수 $g(\cdot)$ 는 식(10)과 같이 E_s^k 로 정의할 수 있다.

$$E_s^k = Y_s - Y_s^k, \quad g(E_s^k) = e^{-|E_s^k|/\sigma} \quad (10)$$

여기서, $\|\cdot\|$ 는 유clidean인 놈(norm)이고, σ 는 오차의 분산 파라미터이다.

신뢰함수 p_s^k 를 식(11)과 같이 정의한다.

$$p_s^k = p_{s-1}^k + \gamma \cdot p_{s-1}^k \left[g(E_s^k) - \left(\sum_{j=1}^K p_{s-1}^j g(E_s^j) \right) \right] \quad (11)$$

식(11)은 $s = 1, 2, \dots$ 에 대해 반복해서 계산되어지고, 0뿐만 아니라 모든 s 에 대해서 식(12)와 같은 관계를 만족한다.

$$0 < p_s^k \leq 1 \text{ and } \sum_{k=1}^K p_s^k = 1 \quad (12)$$

여기서, 초기값 p_0^k ($k = 1, 2, \dots$)는 임의적으로 정한다. 단, 초기값도 식(12)의 조건을 만족한다. 식(11)의 결과 $g(E_s^k)$ 가 $g(E_s^j)$ 보다 더 크면 p_s^k 는 증가한다. $g(E_s^k)$ 가 크다는 것은 E_s^k 가 작다는 것을 의미하고, s 의 시간 안에 모델의 거동을 관측하여, k 번째 모델이 얼마나 잘 맞는지 거동을

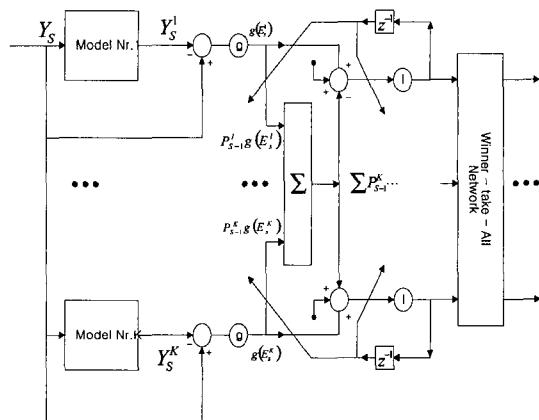


Fig. 4 ICRA Neural Network

분석한 후 양질의 p_s^k 를 선정한다. 따라서, 식(12)에 의해 $\lim_{s \rightarrow \infty} p_s^k = 1$ 이면 $g(E_s^k)$ 가 크다는 것이고, 이것은 E_s^k 가 가장 작다는 것을 의미하므로 파라미터 공간상에 존재하는 모델 중 가장 좋은 모델이다.

3.2.2 유전자 알고리즘(Genetic algorithm)

유전자 알고리즘을 시스템 식별 문제로 변환하면 개체가 파라미터 벡터 θ_k 에 의해 모델을 결정하게 되고, 개체군은 Q 의 부분집합을 탐색하게 된다. 각각의 파라미터는 문자열 비트에 의해 부호화되어, 파라미터 벡터 θ_k 를 입력한 문자열이 된다. 각각의 개체 적합도는 예측한 시스템 거동의 정확도와 관련 있으며, 유전자 알고리즘의 궁극적 목적은 개체의 적합도를 찾는 것이다.

유전자 알고리즘은 ICRA 네트워크를 사용한 후 모델의 신뢰도 결과를 유전자 알고리즘으로 보내 새로운 모델을 생산하기 위해 다음의 구성요소를 사용한다.

1) 선택 매커니즘

룰렛 훈은 정확한 ICRA 신뢰도인 선택율에 따라 무작위로 모델을 선택하는데 사용한다. 이런 방법은 선택확률이 모델의 적합도와 관련되고, 결국 모델의 전체 제곱오차와 관련된다.

2) 유전연산자

이전 모델에서 하나의 모델을 발생시키는 돌연변이는 $n \cdot d$ 길이의 유전형질의 문자열에서 m 번째 비트를 반대로 해준다(0일 경우 1로, 1일 경우 0으로 바꾼다). 이전 모델에서 두 개의 모델을 발생시키는 교배 연산자는 결국 무작위로 선택된 두 모델에서 같은 절환점(break-point)에서 m 부분으로 나뉘어진다. 자손세대의 모델은 각각 부모세대로부터 반대로 물려받은 유전형질의 조각을 선택하게 된다.

3) 엘리티즘(Elitism)

이것은 각각의 세대에서 항상 최고의 모델을 다음 세대로 포함시킨다는 것이다. 엘리티즘이란 각각의 세대에서 최고의 성능을 나타내는 국부 최소값을 의미하는 등고선(hill-climbing)법을 보완한 것이다. 엘리티즘과 등고선법은 유전적 탐색의 속도를 향상시킨다. 비록 유전 알고리즘이 이론상 전역 해를 찾는 좋은 방법이지만 많은 시간을 소모한다.

4) 엔트로피 기준 (entropy criterion)

각각 세대의 차이를 확인하기 위해 엔트로피 기준을 사용한다. 비록 엘리티즘과 등고선법을 사용함으로써 알고리즘의 속도는 향상되지만 전역해보다 국부해에 빠질 가능성을 가지고 있다. 이것을 피하기 위해 매 세대마다 해를 탐색하기에 적당한 수를 가지고 있는 충분히 다양한 모델을 요구한다.

신뢰도 평가 신경망을 긴 시간동안 연산하게 되면 신뢰도 p_s^k 는 '0'이나 '1'로 수렴하게 된다. 만일 p_s^k 가 '0'이나 '1'로 수렴하게 되면 유전 연산자의 연산은 이전세대의 적합도를 단지 그대로 다음세대로 전달할 뿐이다. 이렇게 유전자 알고리즘은 추정오차의 국부 최소값만 제공하는 모델로 수렴한다. 이 문제는 현재모델의 적합도를 더 강화하는 엘리티즘이나 등고선법에 의해 더욱 악순환하게 되지만, p_s^k 가 하나의 값에 충분히 집중되지 않는다면 파라미터 공간을 무작위로 충분히 탐색하게 된다.

이런 문제들을 피하기 위해 신뢰도 평가 신경망 네트워크는 p_s^k 가 기대할 수 있는 모델에 집중하기 시작한 후 '0'이나 '1'로 근접하기 이전에 그 연산을 멈춰야 한다. 목표를 달성하기 위해서는 매회 신뢰도 평가 신경망은 가변 하는 단계의 수를 연산해야 하고, 가변 단계의 수는 엔트로피 기준에 따라 그 회수를 결정해야한다. $p_s^1, p_s^2, p_s^3, \dots, p_s^K$ 에 대한 엔트로피 함수 H_s 는 식(13)과 같이 정의한다.

$$H_s = - \sum_{k=1}^K p_s^k \cdot \log(p_s^k) \quad (13)$$

H_s 의 최대값은 $\log(K)$ 이고 $p_s^1 = p_s^2 = p_s^3 = \dots = p_s^K = 1/K$ 일 때이다. 즉, p_s^k 의 값이 모든 모델이 같을 때이다. 엔트로피 함수 H_s 의 최소값은 '0'이고 $p_s^k = 1, p_s^m = 0, m \neq k$ 일 때 즉, 모든 확률이 하나의 모델에 집중될 때이다. p_s^k 가 '0'이나 '1'로 수렴한다면 그것은 H_s 가 '0'으로 수렴한다. 여기서, 동적 스레스홀드(threshold)를 식(14)와 같이 정의한다.

$$\overline{H}_s: \overline{H}_s = \log(K) \cdot (s/T) \quad (14)$$

식(14)는 단순히 선형적으로 증가하는 함수가

된다. 이것은 $s \leq T$ 를 만족하면 항상 부등식(15)를 만족한다.

$$H_s < \bar{H}_s \quad (15)$$

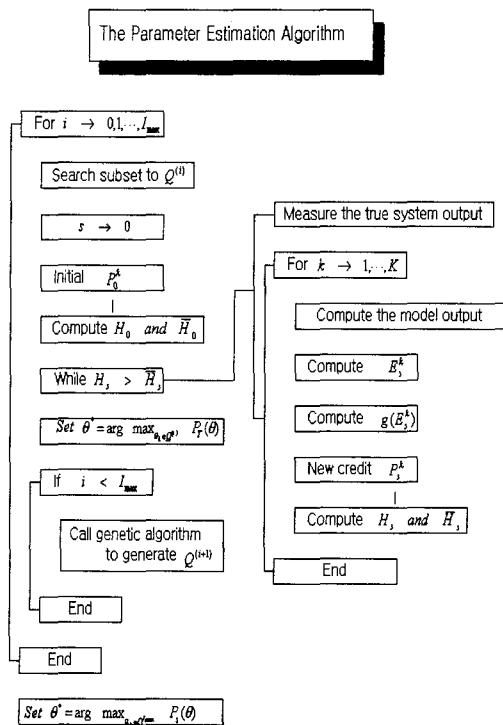


Fig. 5 A flowchart of parameter estimation algorithm

식(15)가 신뢰도 평가 신경망의 가변하는 단계의 수를 결정하는 엔트로피 기준(entropy criterion)이다. $p_s^1, p_s^2, \dots, p_s^K$ 의 엔트로피가 \bar{H}_s 보다 떨어지면 신뢰도 평가 연산은 멈추게 된다. \bar{H}_s 가 선형적으로 증가하고 H_s 가 '0'으로 수렴하면 그 결과 엔트로피 H_s 의 최소값인 '0'과 최대값인 $\log(K)$ 사이의 어떤 엔트로피의 중간값에서 멈추게 되고 그 값은 p_s^k 가 너무 수렴하지도 발산하지도 않는 값이다.

Fig. 5는 신뢰도 평가 신경망 알고리즘과 유전자 알고리즘이 결합된 전체적인 흐름도를 나타내고 있다.

4. 실험 결과 및 고찰

실험에서는 1자유도 전기·유압 서보시스템을 구성하여 획득한 입·출력 데이터를 이용하여 질량 M , 감쇠계수 C , 스프링 상수 K , 채적탄성계수 K_m 을 식별하였고, 이들 파라미터의 타당성을 확인하기 위해 실험값과 식별된 파라미터를 이용해 추정한 값의 궤적비교를 수행하여 검증하였다.

실험 장치에 대한 파라미터는 전혀 알려져 있지 않다. 그러므로 실제 파라미터와 추정된 파라미터를 직접 비교하는 것은 불가능하므로 실제 실험 궤적과 추정된 시스템 궤적을 상호 비교하였다.

실험 데이터는 2장에서 언급된 Fig. 1의 장치에 유사랜덤이진신호(Pseudo Random Binary Signal)를 입력신호로 가하고 변위를 계측하였다. 이때 샘플링 시간을 100Hz로 하여 12000개의 입출력 데이터를 획득하였다.

파라미터공간을 탐색하기 위해 각각의 미지의 파라미터 집합을 하나의 개체단위로 정하고, 개체군의 크기를 30개로 하였다. 교배율은 0.8, 돌연변이율은 0.05, 반복 학습 회수는 1000번으로 하였다. 신뢰도 평가 신경망 파라미터 계수 γ 는 15로 하였으며, 이때 한 세대당 신뢰도 개선은 약 500번에서 600번 이루어졌다.

Fig. 6은 각 세대에서 선택된, 최고의 신뢰도를 나타낸 결과이다. 단지 34번의 반복 학습으로 최고의 신뢰도에 수렴하였으며, 엘리티즘에 의해 9번의 신뢰도 개선으로 가장 좋은 신뢰도를 구하였다. 이 때 신뢰도 값은 0.4008이다.

이상과 같은 신뢰도 개선에 의해 식별된 파라미터는 $M = 58.0$, $C = 3.7$, $K = 214.12$, $K_m = 16324.71$ 이다. 실제 측정 가능한 질량 M 과 유사한 값을 구해내었다.

Fig. 7에서는 실험에서 계측한 12000개의 데이터 중 일부분인 2000개의 데이터만을 그림으로 나타낸 것으로서 식별을 통해 구한 계수 값을 이용하고, 유사랜덤이진신호를 가했을 때 구한 계산된 변위 궤적과 실험 궤적을 나타내고 있다. Fig. 8은 실제 변위 데이터와 계산된 변위 출력을 자세하게 나타내기 위해 임의의 구간, 260번째에서 410번째까지의 출력결과를 나타내고 있다.

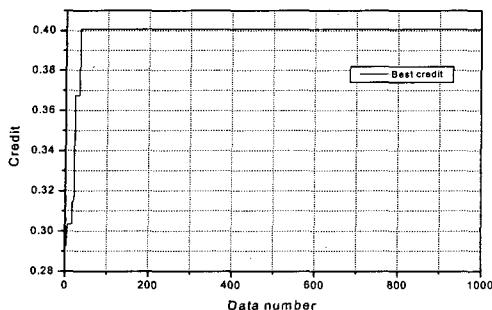


Fig. 6 Best credit in each generation

그림에서 확인할 수 있듯이 최대 오차는 약 1.0V가 발생하였는데, 변위로 환산을 하면 약 14mm에 해당하는 오차이다. 계산된 변위 출력 결과와 실제 변위 출력 결과를 비교해 보면, 계산된 변위가 실제 실험 변위를 경향은 잘 추정하고 있음을 볼 수 있으나, 오차가 존재하는 것을 볼 수 있다. 이것은 모델링 부분에서 특히, 가이드부분의 가이드 봉과 베어링 사이의 마찰과 밸브 스플의 방향 변경시 생기는 비선형성과 서보밸브에서 발생하는 시간지연, 그리고, 센서의 잡음과 같은 영향들이 모델링에 고려되지 못했기 때문이다. 이러한 문제를 다루기 위해서는 모델링에서 빠져있는 서보밸브에 대한 운동방정식과 외란과 쿨롱마찰에 대한 항을 시스템의 모델링에 추가하여 상태방정식을 구현하여야 한다. 즉, 밸브와 쿨롱 마찰들을 식별해야 할 파라미터 인자로 추가하여 식별을 수행하여야 한다. Fig. 9는 각각의 세대에서 최고의 신뢰도를 가지는 개체에 의한 변위 출력값과 실제 변위 출력값의 제곱오차의 합을 나타낸 결과이다.

최소의 값에 수렴하지 않은 원인은 앞서 언급한 신뢰도 함수가 개신되면 단지 오차만 최소로 하는 것이 아니라 실제 변위 출력의 경향까지 추종하여 전역해를 탐색하기 때문이다.

실험결과에서는 쿨롱마찰 등과 같은 더 많은 비선형성을 고려함으로써 파라미터 추정성능의 향상이 가능함을 알 수 있다.

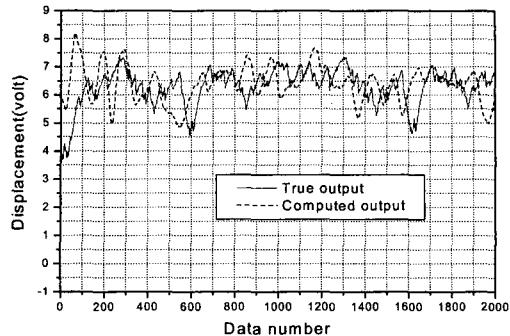


Fig. 7 Comparison true output with estimated output

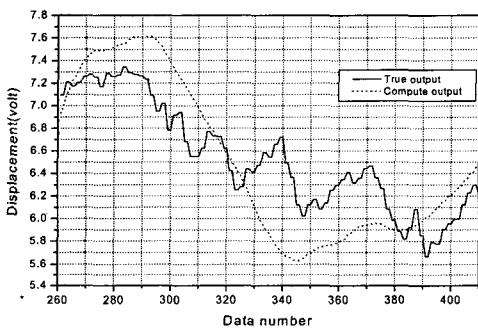


Fig. 8 Detail comparison true output with estimated output in position

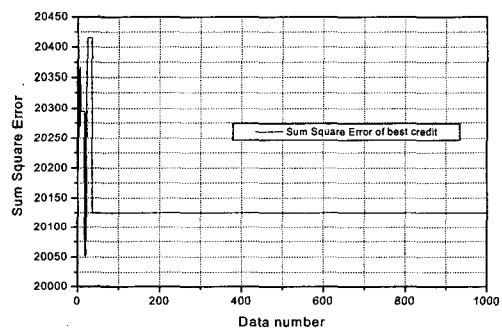


Fig. 9 Squared error in each generation

5. 결론

본 연구에서는 하이브리드 신경망-유전자 알고리즘을 이용하여 파라미터 값이 알려져 있지 않은 전기·유압 서보시스템을 구성하였다. 실험을 통해 획득한 입·출력 데이터를 이용하여 질량 M , 감쇠 계수 B , 스프링 상수 K , 체적탄성계수 K_m 을 식별하였다. 식별한 파라미터 값은 $M = 58.0$, $C = 3.7$, $K = 214.12$, $K_m = 16324.71$ 이며, 이 알고리즘이 최적 해를 찾는데 효과적임을 보였다. 또한, 이를 파라미터의 타당성을 확인하기 위해 실험 값과 식별한 파라미터로 추정한 값의 궤적비교를 수행하여 식별한 파라미터의 타당성을 확인하였다.

향후 연구과제로는 파라미터 수를 늘임으로써 모델링의 정밀도를 높이고, 파라미터 값을 좀더 정확하게 찾을 수 있도록 분해능을 높이는 연구가 필요할 것으로 생각된다.

참고문헌

1. Navid Niksefat and Nariman Sepehri, "Robust Force Controller Design for an Electro-Hydraulic Actuator Based on Nonlinear Model," Proc. Int. Conf. on robotics and automation, pp. 200-206, 1999.
2. Han-Shue Tan, "Model Identification of an Automotive Hydraulic Active Suspension System," Proc. AAC, pp. 2920-2924, 1997.
3. R.Majjad, "Estimation of Suspension Parameters," Proc. IEEE Int. Conf. on control application, pp. 522-527, 1997.
4. L. A. Feldkamp, G. V. Puskorius, L.I. Davis,Jr. and F. Yuan, " Neural Control Systems Trained by Dynamic Gradient Methods for Automotive Applications," IEEE Int. Joint Conf. on neural network, Vol. 2, pp. 798-804, 1992.
5. Ahmet Onat, Hajime Kita, Yokohama and Yoshikazu Nishikawa, "Recurrent neural networks for Reinforcement Learng: Architecture, Learning Algorithms and Internal Representation," IEEE Int. Conf. on neural network, Vol. 3, pp. 2010-2015, 1998.
6. Ahmed Rubaai and Raj Kotaru, "Adaptation Learning Control Scheme a High Performance

Permanent Magnet Stepper Motor Using Online Random Training of Neural Networks," IEEE Trans. on industry applications, Vol. 37, No. 2, 2001.

7. Vassilios Petridis, Emmanuel Paterakis and Athanasios Kehagiaas, "A Hybrid Neural Genetic Multimodel Parameter Estimation Algorithm," IEEE Trans. on neural networks, Vol. 9, No. 5, pp. 862-876, 1998.