論文

신경회로망 구조 최적화를 통한 비행제어시스템 설계

최규호*, 최동욱*, 김유단**

Optimum Design of Neural Networks for Flight Control System

Gyu-Ho Choi*, Dong-Wook Choi* and Youdan Kim**

ABSTRACT

To reduce the effects of the uncertainties due to the modeling error and aerodynamic coefficients, a nonlinear adaptive control system based on neural networks is proposed. Neural networks parameters are adjusted by using an adaptive law. The sliding mode control scheme is used to compensate for the effect of the approximation error of neural networks. Control parameters and neural networks structures are optimized to obtain better performance by using the genetic algorithm. By introducing the concept of multi-groups of populations, the genetic algorithm is modified so that individuals and groups can be simultaneously evolved. To verify the performance of the proposed algorithm, the optimized neural networks control system is applied to an aircraft longitudinal dynamics.

초 록

본 논문에서는 모델링 오차나 공력계수의 불확실성이 포함되어 있는 항공기 시스템에 대해서 신경회로망을 이용한 새로운 비선형 제어시스템 설계기법을 제안하였다. 비선형 적응제어법칙을 이용하여 신경회로망의 연결가중치를 변화시켰으며, 슬라이딩 제어법칙을 이용하여 신경회로망의 추정오차를 보상하였다. 제어시스템의 성능을 결정짓는 제어 매개변수들과 신경회로망 구조를 설계하기 위한 방법을 제안하였으며, 유전자 알고리즘을 이용하여 제어 매개변수들과 신경회로망 구조를 최적화하였다. 신경회로망의 구조탐색에 적합하도록 다수의 개체군을 형성하여 개체와 군이 동시에 진화하도록 하였다. 제안된 유전자 알고리즘에 의해 최적화된 구조를 갖는 신경회로망을 이용한 제어시스템을 항공기 종운동 모델에 적용하여 성능을 검증하였다.

Key Words : neural networks(신경회로망), flight control(비행제어), genetic algorithm(유전자 알고리즘), sliding mode controller(슬라이딩 모드 제어기법)

1. 서 론

항공기의 동특성은 일반적으로 비선형성이 매우 강하기 때문에, 선형제어기법을 이용한 비행

제어시스템은 제한된 작동범위에서만 성능이 보장된다. 항공기의 경우 비선형성이 강할 뿐만 아니라 다양한 비행환경에 대해 불확실성이 존재하므로 항공기의 동특성을 정확하게 모델링하기가 매우 어렵다. 이러한 모델링 오차나 변수들의 변화, 그리고 외란의 영향에 대처하기 위해 강건제어이론과 적응제어이론을 이용하는 연구가 많이 이루어져 왔으며, 최근에는 신경회로망을 이용한 적응제어기법이 연구되고 있다[1]. 신경회로망은

† 2003년 1월 22일 접수 ~ 2003년 5월 1일 심사완료

* 정회원, 서울대학교 항공우주공학과 대학원

** 정회원, 서울대학교 항공우주공학과
연락처, E-mail : ydkim@snu.ac.kr
서울시 관악구 신림동 산56-1

비선형 시스템의 제어기 설계에 많이 응용되고 있으나, 신경회로망의 구조와 학습에 관한 일반적인 방법은 아직 존재하지 않는다. 이와 관련하여 최근에는 최적의 신경회로망 구조를 찾는 연구들이 수행되고 있으며, [2-4] 자연계의 유전법칙을 이용한 최적화 알고리즘인 진화연산을 이용하는 연구들도 수행되고 있다[5-8].

본 논문에서는 신경회로망을 이용하여 항공기 시스템의 공력계수 불확실성에 강건한 비선형 제어기를 설계하였다. 신경회로망의 연결가중치는 시스템의 안정성을 보장하는 적응제어법칙을 이용하여 변화시켜 나갔으며, 신경회로망의 추정오차를 보상하기 위해 슬라이딩 모드 제어기법을 이용하였다. 유전자 알고리즘을 이용하여 제어기 매개변수들과 신경회로망의 구조와 연결가중치의 초기값을 최적화 하였다. 신경회로망 구조와 연결가중치의 동시 최적화를 위하여 새로운 형태의 유전자 알고리즘을 제안하였다. 새로운 알고리즘에서는 교차연산자의 자유로운 적용을 위하여 은닉층 노드수에 따라 다수의 개체군을 형성하였으며, 개체군 내부에서의 개체 진화뿐만 아니라 개체군 사이의 경쟁을 통한 군 단위의 진화를 할 수 있도록 하였다.

본 논문의 구성은 다음과 같다. 먼저, 2장에서는 불확실성을 포함하는 비선형 항공기 모델에 대해 적응법칙을 적용한 신경회로망을 이용하여 제어법칙을 설계한다. 3장에서는 유전자 알고리즘을 이용하여 최적의 제어 매개변수들과 제어법칙에 적합한 신경회로망의 구조를 찾기 위한 새로운 방법을 제시한다. 4장에서는 제안한 알고리즘의 성능을 검증하기 위해 항공기에 대한 수치예를 보이고, 마지막으로 5장에서 결론을 맺는다.

II. 신경회로망을 이용한 비선형 적응제어

2.1 항공기 모델

본 논문에서는 다음과 같이 항공기의 중운동 단주기 모델을 고려하였다[9].

$$\begin{aligned}\dot{\alpha} &= Z_{\alpha}(\alpha)\alpha + (Z_{\alpha}(\alpha) + 1)q + Z_{\delta_e}(\alpha)\delta_e \\ \dot{q} &= M_{\alpha}(\alpha)\alpha + M_q(\alpha)q + M_{\delta_e}(\alpha)\delta_e\end{aligned}\quad (1)$$

본 논문에서 사용한 항공기 모델의 공력계수는 아래 Table 1에 정리하였다.

본 논문에서는 항공기가 주어진 피치 각속도 명령 q_d 를 오차한계 내에서 추종하는 것을 제어

목적으로 설정하였다. 이를 위해서 오차를 $e = q - q_d$ 와 같이 정의하면, 오차 동역학은 다음과 같이 표현된다.

$$\begin{aligned}\dot{e} &= M_{\alpha}\alpha + M_q q + M_{\delta_e}\delta_e - \dot{q}_d \\ &= f(\alpha, q) + g(\alpha)\delta_e - \dot{q}_d\end{aligned}\quad (2)$$

여기서 함수 $f(\alpha, q) = M_{\alpha}\alpha + M_q q$, $g(\alpha) = M_{\delta_e}$ 는 공력계수와 관련된 불확실성을 포함하는 비선형 함수이며, $\dot{q}_d$ 항은 주어진 명령이다.

Table 1. Aerodynamic Data

α	Z_{α}	Z_q	Z_{δ_e}	M_{α}	M_q	M_{δ_e}
-5.289	-0.600	0.029	-0.309	-0.571	-0.869	-13.07
0.800	-0.674	0.029	-0.311	-0.603	-0.869	-13.11
6.960	-0.789	0.029	-0.320	-0.631	-0.869	-13.27
9.004	-0.871	0.029	-0.327	-0.774	-0.869	-13.33
9.970	-0.860	0.029	-0.331	0.453	-0.869	-13.38
11.790	-0.820	0.029	-0.326	2.256	-0.869	-13.02
13.639	-0.811	0.028	-0.312	1.113	-0.869	-12.32
14.588	-0.804	0.028	-0.310	-0.190	-0.869	-12.37
16.577	-0.803	0.028	-0.313	-2.562	-0.869	-12.25
21.489	-0.841	0.028	-0.325	-5.926	-0.869	-11.56

2.2 신경회로망

본 논문에서는 다층 퍼셉트론 신경회로망을 사용하였다. 은닉층은 하나로 하였으며, 은닉층 노드수는 N 개인 완전연결(feedforward) 구조로 다음과 같은 수확모델로 표현된다[10].

$$\hat{h}(x, w) = w_{out}^T \phi(w_{in}^T \bar{x})\quad (3)$$

여기서 $\bar{x} = [1 \ x^T]^T$ 는 입력, w 는 연결가중치이며, 은닉층에 bias 항을 갖는다. ϕ 는 활성화 함수로서 sigmoid 함수를 사용하였다.

2.3 슬라이딩 모드 제어법칙

본 논문에서는 다음과 같은 슬라이딩 모드 제어법칙을 고려한다.

$$\delta_e = \hat{g}^{-1} \{ -\hat{f} + \dot{q}_d - \rho \text{sat}(e/\beta) \}\quad (4)$$

여기서 $\hat{f}[\alpha \ q]^T, \hat{g}(\alpha, \nu)$ 는 불확실성을 포함하는 비선형 함수 f, g 를 신경회로망을 이용하여 추정한 값이다. 추정오차를 보상하기 위해서, 슬라이딩 제어항 $\rho \text{sat}(e/\beta)$ 를 제어법칙에 포함시켰다. 그리고 슬라이딩 면에서의 떨리는 채

터링 현상을 피하기 위해서 β 만큼의 경계두께를 가지는 포화(saturation) 함수를 사용하였다.

식 (4)를 식 (2)에 대입하여 정리하면 다음과 같다.

$$\begin{aligned}\dot{e} &= f + g \hat{g}^{-1} \{-\hat{f} + \dot{q}_d - \rho \text{sat}(e/\beta)\} - \dot{q}_d \\ &= f + (g - \hat{g} + \hat{g}) \hat{g}^{-1} \{-\hat{f} + \dot{q}_d \\ &\quad - \rho \text{sat}(e/\beta)\} - \dot{q}_d \\ &= f + (g - \hat{g}) \hat{g}^{-1} \{-\hat{f} + \dot{q}_d - \rho \text{sat}(e/\beta)\} \\ &\quad - \hat{f} - \rho \text{sat}(e/\beta) \\ &= (f^* - \hat{f}) + (g^* - \hat{g}) \delta_e - \rho \text{sat}(e/\beta) \\ &\quad + (f - f^*) + (g - g^*) \delta_e \\ &= (f^* - \hat{f}) + (g^* - \hat{g}) \delta_e - \rho \text{sat}(e/\beta) + o(\epsilon)\end{aligned}\quad (5)$$

여기서 상첨자 (*)는 신경회로망이 함수를 원하는 정확도로 표현하였을 때를 의미한다. 식 (5)의 마지막 두 항은 ϵ 만큼 매우 작은 값이 되므로 다음과 같이 표현할 수 있다.

$$\dot{e} = \hat{f} - f + (\hat{g} - g) \delta_e - \rho \text{sat}(e/\beta) + o(\epsilon) \quad (6)$$

이제, 다음과 같이 $\bar{w}$, J , $\eta(t)$ 를 정의하자.

$$\begin{aligned}\bar{w} &= w - w^*, \quad w = [w_A^T w_B^T]^T \\ J &= \left[\frac{\partial \hat{f}}{\partial w_A} \quad \frac{\partial \hat{g}}{\partial w_B} \delta_e \right]^T \\ \eta(t) &= o(\|\bar{w}\|^2) + o(\epsilon)\end{aligned}\quad (7)$$

여기서 w_A 와 w_B 는 각각 비선형 함수 f 와 g 를 추정하기 위한 연결가중치이다. 식 (6)을 테일러 시리즈 전개하고, 식 (7)를 이용하면 다음 결과를 얻을 수 있다.

$$\dot{e} \leq -\bar{w}^T J - \rho \text{sat}(e/\beta) + \eta(t) \quad (8)$$

본 논문에서는 연결가중치가 다음과 같은 적응법칙을 따르도록 하였다[11].

$$\dot{\bar{w}} = J(e - \beta \cdot \text{sat}(e/\beta)) \quad (9)$$

한편, 식 (8)에서 $\rho \text{sat}(e/\beta)$ 항의 ρ 는 응답 오차를 고려하여 다음 식에 의해 추정된 값을 사용한다[11].

$$\begin{aligned}\rho &= \bar{p} + \delta \\ \frac{d\bar{p}}{dt}(t) &= |e - \beta \text{sat}(e/\beta)|, \quad \bar{p}(0) = 0\end{aligned}\quad (10)$$

여기서 δ 는 임의의 양의 상수이다.

본 논문에서는 다음 가정을 한다.
(가정) 다음 부등식을 만족하는 유한한 미지상수 p 가 존재한다.

$$|\eta(t)| < p \quad (11)$$

앞에서 서술한 가정과 수식들로부터 다음과 같은 정리를 얻을 수 있다.

(정리) 식 (1)에 의해 표현되는 시스템에 대해 식 (4)의 제어법칙과 식 (9), (10)으로 표현되는 적응법칙을 적용하여 신경회로망의 연결가중치와 슬라이딩 제어이득을 변화시키면, 시스템의 모든 신호들과 오차는 uniformly bound 된다.

증명) 다음과 같은 르야프노프 후보함수를 정의하자.

$$\begin{aligned}V(e, \bar{w}, p) &= \frac{1}{2} [e - \beta \text{sat}(e/\beta)]^2 \\ &\quad + \frac{1}{2} \bar{w}^T \bar{w} + \frac{1}{2} (\bar{p} - p)^2\end{aligned}\quad (12)$$

데드존 외부와 내부에 대해서 나누어 증명하자.

(i) 데드존 외부 ($|e| > \beta$)

데드존 외부에서는 $\text{sat}(e/\beta)$ 항은 1 또는 -1의 값을 가지는 상수항이 되므로 식 (12)에서 정의된 V 를 시간에 대해 미분하면 다음과 같이 쓸 수 있다.

$$\dot{V} = \{e - \beta \text{sat}(e/\beta)\} \dot{e} + \bar{w}^T \dot{\bar{w}} + (\bar{p} - p) \dot{\bar{p}} \quad (13)$$

식 (9), (10)을 위 식에 대입하고 식 (7), (11)을 이용하여 정리하면 다음과 같다.

$$\begin{aligned}\dot{V} &= [e - \beta \text{sat}(e/\beta)] \dot{e} + \bar{w}^T \dot{\bar{w}} + (\bar{p} - p) \dot{\bar{p}} \\ &= [e - \beta \text{sat}(e/\beta)] \dot{e} + \bar{w}^T \cdot J [e - \beta \text{sat}(e/\beta)] \\ &\quad + (\bar{p} - p) |e - \beta \text{sat}(e/\beta)| \\ &\leq [e - \beta \text{sat}(e/\beta)] \times \\ &\quad \left\{ -\bar{w}^T \cdot J - (\bar{p} + \delta) \text{sat}(e/\beta) + \eta(t) \right\} \\ &\quad + \bar{w}^T \cdot J [e - \beta \text{sat}(e/\beta)] \\ &\quad + (\bar{p} - p) |e - \beta \text{sat}(e/\beta)| \\ &= -(\bar{p} + \delta) [e - \beta \text{sat}(e/\beta)] \text{sat}(e/\beta) \\ &\quad + \eta(t) [e - \beta \text{sat}(e/\beta)] \\ &\quad + (\bar{p} - p) |e - \beta \text{sat}(e/\beta)| \\ &\leq -(\bar{p} + \delta) |e - \beta \text{sat}(e/\beta)| \\ &\quad + \bar{p} |e - \beta \text{sat}(e/\beta)| \\ &\quad + (\bar{p} - p) |e - \beta \text{sat}(e/\beta)| \\ &= -\delta |e - \beta \text{sat}(e/\beta)| < 0\end{aligned}\quad (14)$$

따라서 $\dot{V} < 0$ 이 됨을 알 수 있다.

(ii) 데드존 내부 ($|e| \leq \beta$)

데드존 내부에서는 $e - \beta \text{sat}(e/\beta)$ 이 0이 되므로, 식 (9)와 식 (10)에 의해 $\bar{w}$ 와 $\bar{p}$ 는 상수값이 되고, 식 (12)는 다음과 같이 된다.

$$V = \frac{1}{2} \bar{w}^T \bar{w} + \frac{1}{2} (\bar{p} - p)^2 \quad (15)$$

따라서 테드존 내부에서는 $\dot{V} = 0$ 이 된다.

위 결과들을 종합하면 식 (4)의 제어법칙으로 e , w , p 가 uniformly bound 됨을 알 수 있다.

2.4 수치 시뮬레이션

설계된 제어기의 성능을 평가하기 위해서 고도 5000m에서 마하 0.5의 속도로 비행하는 항공기 모델에 다음과 같은 피치 각속도 명령 q_d 를 고려하였다.

$$q_d = \begin{cases} 5 \text{ deg/sec} & (0 \text{ sec} \leq t \leq 2 \text{ sec}) \\ -5 \text{ deg/sec} & (2 \text{ sec} < t \leq 4 \text{ sec}) \\ 0 \text{ deg/sec} & (4 \text{ sec} < t \leq 7 \text{ sec}) \end{cases} \quad (16)$$

위 명령을 다음과 같은 3차 명령 필터를 통과하여 미분가능 하도록 하였다.

$$T(s) = \frac{\omega_{n1}\omega_{n2}^2}{(s + \omega_{n1})(s^2 + 2\zeta\omega_{n2}s + \omega_{n2}^2)} \quad (17)$$

여기서 $\omega_{n1} = 12$, $\omega_{n2} = 5$, 그리고 $\zeta = 0.8$ 로 설정하였다. 본 논문에서는 함수 f 와 g 를 예측하기 위한 신경회로망 은닉층 노드를 각각 6개로 설정하였다. 연결가중치의 초기값들은 역전파 학

Fig. 1. Angle of Attack History

Fig. 2. Pitch Rate History

Fig. 3. Control Input History

습법을 이용하여 학습시켰으며, [10] 학습자료로는 Table 1에 표로 주어진 수치들을 이용하였다. 슬라이딩 제어기의 매개변수는 $\delta = 1.0$, $\beta = 0.2$ 를 선택하였다. 적분구간은 0.01 sec, 초기조건은 $\alpha = 2 \text{ deg}$, $q = 0 \text{ deg/sec}$ 이다.

Fig. 1은 받음각의 궤적, Fig. 2는 피치 각속도의 궤적, Fig. 3은 제어입력 궤적을 보이고 있다. 그림에서 보듯이 각속도 명령을 비교적 잘 추종하고 있으며, 제어입력과 받음각의 변화도 적당한 범위 내에 있음을 알 수 있다. 그러나 제어입력에 진동이 있음을 알 수 있다. 피치 각속도 명령궤적에 대한 오차궤적의 노름(norm)은 25.7이다. 이 경우 슬라이딩 모드 파라미터와 포화함수를 최적화 과정을 통해서 적절하게 선택하면 채터링 현상은 해소될 수 있다. 따라서 본 논문에서는 신경회로망 구조에 해당하는 변수 뿐 아니라 제어시스템에 영향을 주는 슬라이딩 모드 파라미터도 최적화 변수로 선정하여 최적화를 수행하도록 한다.

III. 유전자 알고리즘을 이용한 신경회로망 구조최적화

3.1 신경회로망 최적 설계방법

3.1.1 신경회로망 구조설계방법

신경회로망의 설계는 신경회로망의 은닉층 수, 노드수, 연결구조 등 구조의 설계와 연결가중치의 학습으로 나뉜다. 다층 퍼셉트론 신경회로망의 연결가중치는 일반적으로 역전파 기법으로 학습하지만 신경회로망의 구조가 커짐에 따라 성능이 급격히 떨어진다는 단점이 있다[12]. 한편, 진화 알고리즘에 의한 학습은 다른 종류의 신경회로망 학습에도 사용가능하며, 전역 최적해를 찾는 성능이 우수하다고 알려져 있다[13].

신경회로망 구조설계 연구는 다음 세 가지 방

법으로 분류된다[10]. 첫 번째는 사전 분석적 방법으로 해석하여 설계하는 방법인데, 이 방법은 복잡한 문제에 대해 적용이 매우 어렵다. 두 번째는 신경회로망 구조를 충분히 크게 정하는 방법인데, 학습시간이 길고 일반화 성능이 나쁘다. 세 번째는 증축적 알고리즘과 파괴적 알고리즘으로, 필요한 최적의 구조를 찾기 위해서 사용하는 알고리즘이다[2, 14]. 그러나 이 방법들은 시행착오에 의한 방법이며 전역 최적해라고 보장할 수 없다.

3.1.2 유전자 알고리즘의 적용

유전자 알고리즘은 함수 최적화를 위해 널리 사용되고 있으며, 멀티 모달, 불연속 함수, 심지어 NP-hard 조합 최적화문제에 효과적이다. 신경회로망의 구조와 학습에 대해 유전자 알고리즘을 이용한 기존의 연구는 크게 다음과 같이 분류할 수 있다.

첫째, 학습은 역전파 기법으로 수행하고, 신경회로망의 구조만 유전자 알고리즘으로 설계하는 방법이 있다[6]. 이 방법은 동일 구조라 하더라도 학습결과가 다를 수 있다는 단점이 있다. 두 번째는 구조는 정해졌다고 가정하고, 학습만 유전자 알고리즘을 사용하는 방법이다[7]. 이 방법은 노드수에 대한 설계가 제외되는 것이 단점이다. 세 번째는 구조와 학습을 모두 유전자 알고리즘으로 설계하는 것으로,[8] 앞의 두 방법이 갖고 있는 문제점을 극복하여 진보된 방법이라 할 수 있다. 그러나 이 방법은 각 개체의 노드수가 달라 이에 따른 연결가중치의 크기가 다르게 된다. 결국, 염색체의 길이가 다르게 되어, 교배 연산을 제대로 적용할 수 없다는 문제가 있다. 이러한 문제점을 극복하기 위하여 본 논문에서는 노드수가 다름에 따라 염색체 길이가 다른 개체들을 동시에 고려하면서 최적인 신경회로망 구조를 최적 설계하기 위해서, 염색체 길이가 다른 개체들을 그룹화 하여 진화 알고리즘을 적용하는 그룹진화 알고리즘을 제안한다.

3.2 구속조건과 적합도 함수

3.2.1 구속조건

항공기의 제어면은 타각 뿐만 아니라 조종면의 각속도에 제한이 있다. 이와 같은 구동기 특성에 대한 제한을 구속조건으로 고려할 필요가 있다. 구속조건을 위반하는 해는 적합도 함수의 분모에 일정한 벌칙 값을 추가하였다.

3.2.2 적합도 함수

본 논문에서는 신경회로망의 구조와 연결가중

치를 동시에 설계하므로, 오차제치의 노름(norm) 뿐 아니라 복잡성도 최소화하도록 하였다. 신경회로망의 또 다른 중요한 성능으로써 일반화 성능을 들 수 있는데,[15] 구조가 단순할수록 일반화 성능이 우수한 것으로 알려져 있다. 본 논문에서는 신경회로망의 구조를 전체 연결구조로 가정하였으므로, 구조에 관하여는 노드수를 최소화하도록 하였다. 또한 시스템의 실제 출력과 기준 입력간의 오차로 정의하였다. 본 논문에서는 적합도 함수에 구속조건을 고려하여 다음과 같이 정의하였다.

$$f = \frac{1}{\sum_{i=0}^{n_T} e_i^2 + R \cdot (N_A + N_B) + PNT} \quad (18)$$

여기서 e_i 는 출력과 기준입력간의 오차, R 은 오차와 노드수 간의 가중치, N_A 와 N_B 는 A, B 신경회로망의 노드수, n_T 는 최종시간을 적분구간으로 나눈 값, 그리고 PNT 는 구속조건의 벌칙 값이다.

3.2.3 인코딩 방법

신경회로망 구조를 염색체로 표현하는 방식은 최적화 결과에 많은 영향을 주므로 매우 중요하다. 전통적으로 이진표현(binary string coding)이 많이 사용된다. 그런데 이러한 표현들은 최적화 과정에서 정밀도를 조정할 수 없고,[16] 실제 모델에서의 작은 차이가 염색체 표현에서 큰 차이로 나타나는 Hamming cliff 문제가 발생한다. 반면, 부동점(floating point) 표현방법은 이와 같은 문제점이 없고, 동적인 연산자를 쉽고 효율적으로 구현할 수 있다는 장점이 있다. 본 논문에서는 부동점 표현방법인 실수표현을 사용하였다.

3.3 그룹진화 유전자 알고리즘

3.3.1 그룹진화 알고리즘의 개념

본 논문에서 제안하는 그룹진화 알고리즘은 신경회로망의 노드수에 따라 M개의 그룹을 형성한다. 각 그룹 내 개체들의 염색체 유전인자는 슬라이딩 매개변수와 노드수에 따른 연결가중치로 구성된다. 본 논문에서는 그룹 나이(Age)라는 개념을 도입하였는데, 나이는 초기화 이후 진화를 거듭하여 변동 없이 진화할 때까지의 기간을 의미한다. 그룹의 나이의 단위는 세대수이며, 재초기화하면 0으로 환원된다. 각 그룹에서는 그룹 내의 개체들을 일반적인 유전자 알고리즘에 의해 진화시키고, 매 일정시기(경쟁주기)마다 각 그룹

의 최고 개체의 적합도(그룹 적합도)를 비교한다. 여기서 가장 우수한 적합도를 가진 최고 그룹은 노드수나 소속 염색체의 변동 없이 진화를 계속한다. 나머지 그룹은 최고 그룹적합도와 비교를 거쳐, 최고 그룹처럼 변동 없이 계속 진화하는 그룹과 재초기화 한 뒤 진화를 다시 시작하는 그룹으로 나뉜다.

그룹진화 알고리즘은 병렬 유전자 알고리즘의 섬 모델과 비슷한 면이 있으나, 그룹을 대표하는 노드수의 선택에 유전자 알고리즘을 적용하고, 한 그룹 내의 염색체들은 다른 그룹에 있는 염색체들과 길이가 다르다는 점에서 구별된다.

3.3.2 초기화

본 논문에서는 각각 함수 f 와 g 를 추정하기 위해서 두개의 A, B 신경회로망을 사용한다. 따라서 두 신경회로망 노드수 (N_A , N_B)를 한 쌍으로 갖는 M개의 그룹을 고려한다.

처음에는 노드수의 조합을 임의로 생성하고, 각 그룹마다 n개의 후보 해를 형성한다. 각 후보 해의 유전인자는 Fig. 4에 보이고 있는 것과 같이 슬라이딩 매개변수 (β , δ), 신경회로망의 연결가중치 (w_A , w_B)가 순서대로 배치된다. 염색체 $X_{i,j}$ 의 하첨자 i 는 그룹 번호, j 는 그룹 내 각 염색체 번호이다.

Fig. 4. Multi-Groups and Genes

3.3.3 그룹 내에서의 진화

각 그룹 내의 개체들은 다른 그룹과 독립적으로 진화한다. 유전 연산자는 동일한 그룹 내의 염색체 사이에서만 작용하며, 그룹 간의 염색체 교환이나 기타 정보교환은 없다. 그룹 내의 진화 연산자로 선택, 교배, 돌연변이 연산자와 엘리트 기법을 사용하였다.

선택 연산자는 비선택법의 한 종류인 룰렛

(Roulette wheel) 선택법을 이용하였다. 각 그룹 내의 염색체의 길이는 모두 동일하기 때문에 교배 연산에서 염색체의 길이는 문제되지 않는다. 본 논문에서는 실수 형태로 표현된 유전인자의 장점을 살릴 수 있도록, 다음과 같은 균일한 산술적 교배를 사용하였다.

$$\begin{aligned} x_1' &= ax_1 + (1-a)x_2 \\ x_2' &= (1-a)x_1 + ax_2 \end{aligned} \quad (19)$$

여기서 교배상수 a 는 균일한 임의 변수로 생성되며, $0 \leq a \leq \phi$ 사이의 값이 되도록 한다. ϕ 는 세밀한 탐색을 위하여 세대수가 증가하면서 점차 작은 값이 되도록 설정하였다. 최적화 수행 초기에는 전역적 탐색을 위하여 교배 연산자 적용확률(P_{cr})을 높게 설정하고, 진화가 진행된 후에는 세밀한 탐색을 위하여 적용확률을 감소시키도록 하였다.

돌연변이 연산자는 해의 다양성을 높이는 기능을 한다. 본 논문에서는 유전자 알고리즘의 전역적인 최적해를 보장하면서 수렴속도를 높이 기 위하여, 돌연변이 적용확률(P_{ml})을 점차 증가시키도록 하였다[8]. 돌연변이 값을 생성하는 방법은 다양하다. 본 논문에서는 실수 표현을 사용하므로, 세대수에 따라 변이의 범위를 조정할 수 있는 정규분포 방식을 사용하였다. 이 방식은 해당 유전인자에 $N(0, \sigma_{ml}^2)$ 의 정규분포로부터 생성된 변이값을 더하여 새로운 유전인자를 구하는 방식이다. 여기서 표준편차 σ_{ml} 는 각 그룹의 나이에 따라 작게 변화하도록 하였다. 유전인자 중에서 슬라이딩 매개변수 β 와 δ 는 σ_{ml} 를 각각 다르게 설정하였으며, 연결가중치는 모두 동일한 σ_{ml} 를 적용하였다.

한편, 다음 세대로 복제를 하는 과정에서 가장 우수한 적합도를 가지는 개체는 확률값에 관계없이 다음 세대로 복제를 하도록 하는 엘리트 기법(elitism)도 함께 적용하였다.

3.3.4 그룹간의 경쟁

그룹간의 경쟁을 위해서 그룹간 비교 시기때마다 그룹 적합도를 기준으로 순위를 정한다. 이때, 1위 그룹은 변동 없이 진화를 계속한다. 그 외의 그룹은 변동 없이 진화하는 그룹과 재초기화를 수행한 후 진화를 다시 시작하는 그룹으로 나뉜다. 그 기준은 다음과 같다. 그룹 i 의 적합도(F_i)를 그 그룹나이(Age_i)에서의 최고 그룹 적합도($F_{best}(Age_i)$)와 비교하여, 그룹 적합도가 최고

그룹 적합도의 일정 비율(생존문턱, Cut-off Ratio(CR))을 넘을 경우에는 변동 없이 진화하도록 한다. 이를 수식으로 표현하면 다음과 같다.

$$\begin{aligned} F_i / F_{best}(Age_i) &\geq CR ; \text{ 계속 진화} \\ F_i / F_{best}(Age_i) &< CR ; \text{ 초기화 후 진화} \end{aligned} \quad (20)$$

만일, 후순위 그룹의 나이가 최고 그룹의 나이보다 많은 경우에는 최고 그룹의 최후 나이에에서의 적합도와 비교한다.

생존 문턱(CR)의 설정은 수행 결과에 매우 중요한 영향을 준다. 생존 문턱을 너무 작은 값으로 설정하면 경쟁을 통과하는 그룹은 많아지나 최적해와 거리가 먼 그룹이 포함될 확률이 높으며, 결국 수렴 시간이 길어지게 된다. 반대로 생존 문턱을 너무 큰 값으로 설정하면 최적해의 가능성이 있는 그룹이 진화 초반 또는 중반의 부진으로 인하여 탈락되어 최적해를 찾지 못하는 경우가 발생할 수 있다. 따라서 진화 초반에는 동일한 그룹이라 하더라도 발전 속도의 차이를 고려하고 다양한 영역을 탐색하기 위하여 생존 문턱을 비교적 낮게 하여야 한다. 진화가 상당히 진행된 중반 이후에는 각 그룹의 우열이 적합도에 제대로 반영될 확률이 높기 때문에 생존 문턱을 낮게 설정하지 않아도 우수한 그룹이 탈락하는 경우는 적다. 그러므로 중반 이후에는 생존 문턱의 높이를 높여서 수렴 속도를 촉진시키는 것이 좋다.

3.3.5 경쟁에서 탈락한 그룹의 재초기화

경쟁에서 탈락한 그룹은 노드수와 그룹 내의 모든 염색체를 초기화하여야 한다. 그룹 내의 염색체는 그룹의 노드수가 정해지면 그에 따라 염색체의 길이가 결정되고, 각 유전인자의 값은 정해진 범위 내에서 임의의 값으로 정해진다. 그룹간의 경쟁은 노드수 탐색을 위한 것이므로 노드수를 어떻게 정하느냐에 따라 결과가 많이 달라진다. 노드수 초기화는 임의의 값으로 설정할 수 있으나 효율적이지 못하다.

본 논문에서는 노드수의 순서쌍을 유전자처럼 취급하여, 새로운 노드수를 설정하는데 유전자 알고리즘을 적용하였다. 재초기화 하는 그룹들의 노드수는 초기화 직전의 모든 그룹의 노드수 쌍들에 대하여 선택 연산을 적용하여 필요한 수만큼 추출한 다음, 그들 사이에서 교배 연산, 돌연변이 연산을 적용하여 새로운 노드수의 순서쌍들을 구한다. Fig. 5에 이를 도식화하였는데, 점선으로 표시된 그룹이 노드수를 재초기화하는 그룹이고, 실선으로 표시된 그룹은 노드수 변동 없이 진화를 계속하는 그룹이다.

Fig. 5. Resetting Method of Neurons' Number

적용되는 연산자의 세부적인 설명은 다음과 같다. 진화 연산자에서는 사용되는 적합도에 비례하여 다음 세대를 구성하는 룰렛 선택법이 사용된다. 이 방법은 나이가 작은 그룹에 과도하게 불리하다. 나이가 많은 그룹은 계속 진화하므로 신생 그룹에 비하여 적합도가 월등히 크지만, 신생그룹이 나이가 많은 그룹에 비하여 발전 가능성이 낮은 것도 아니다. 따라서 본 논문에서는 순위기반 방법을 사용하기로 하였다. 순위기반 방법에서 M 개의 그룹 중 s 번째 순위를 가진 그룹의 선택 적합도를 다음과 같이 설정한다.

$$f = \max + \frac{s-1}{M-1} (\min - \max) \quad (21)$$

여기서 $\max$ 와 $\min$ 의 차이를 바꿈으로써 선택압(selective pressure)을 조절할 수 있다.

교배 연산에서는 신경회로망 A, B의 노드수 ($N_{i,A}$, $N_{i,B}$)를 일점 교배하여 치환하는 방법을 사용하였다. 또한, 돌연변이 연산에서는 정규분포 $N(0, \sigma_{mG}^2)$ 로부터 생성되는 임의의 값에서 가장 가까운 정수 값을 원래의 노드 값에 더하는 방식을 사용하였다. 여기서 σ_{mG} 는 세대수에 따라 점차로 작게 변화하도록 설정하였다.

IV. 수치 시뮬레이션

본 논문에서 제안한 그룹진화 알고리즘의 성능을 평가하기 위하여, 2장에서 설명한 슬라이딩 모드 제어기의 최적화에 적용하였다. 항공기 모델과 피치 각속도 명령 등 기타 실험환경은 2장에서 다루었던 문제와 동일하게 설정하였다. 최적화 대상의 탐색범위는 다음과 같다.

$$\begin{aligned} 2 \leq N_{i,A} \leq 20, \quad 2 \leq N_{i,B} \leq 20 \\ 0 < \beta \leq 0.3, \quad 0 < \delta \leq 20, \quad -5 \leq w_k \leq 5 \end{aligned}$$

적합도 함수 식 (18)에서 출력과 기준입력간의 오차 e_i 는 최적화가 진행되는 동안 매우 작음으로 수렴된다. 그러나 신경회로망 노드수는 정수이므로 오차와의 오더(order) 차이가 매우 크다. 따라서 오차신호와 노드수의 상대적인 비중을 고려하여 가중치를 선정하여야 한다. 본 논문에서는 적합도 함수에서 가중치 R 은 0.00001로 설정하였고, 실험은 10000 세대까지 수행하였다. 그룹 수 M 은 15, 각 그룹 내의 개체 수 n 은 20으로 설정하였다.

각 그룹 내에서 작용하는 교배 연산자 적용확률, 교배 연산자의 교배상수, 돌연변이 연산자 적용확률, 돌연변이 표준편차는 그룹 나이에 따라 변화하도록 설정하였으며, Table 2에 정리하였다.

Table 2. GA Operators' Variables

Age	P_{cr}	ϕ	P_{mt} of			σ_{mt} of		
			β	δ	w_i	β	δ	w_i
1	0.7	1.0	0.1	0.1	0.06	0.75	5	5
100	0.45	0.3	0.1	0.1	0.11	0.45	3	3
200	0.2	0.1	0.1	0.1	0.14	0.15	1	1

Table 2에서 보듯이 나이가 200 이상에서는 200에서의 값으로 일정하게 하였다. 교차연산 적용확률 P_{cr} 과 돌연변이 연산 적용확률 P_{mt} 는 각 구간 내에서 선형적으로 변화한다. 식 (20)에서 α 의 최대값 ϕ 와 돌연변이 연산 표준편차 σ_{mt} 는 구간 내에서 일정하게 하였다. 그룹간 경쟁주기는 100 세대로 하였으며, 생존 문턱은 수행 초기에 0.15로 선형적으로 증가하여, 800 세대에 0.6이 되고, 그 이후는 일정하게 유지하였다.

노드수 재초기화에 적용되는 유전 연산자의 인수 중에서 순위기반 선택연산의 최소는 6, 최대는 20으로 설정하였다. 교배연산 적용확률 P_{cr_G} = 0.75과 돌연변이 연산 적용확률 P_{mt_G} = 0.3은 나이나 세대에 상관없이 일정하게 설정하였다. 그러나 돌연변이 연산의 표준편차 σ_{mt_G} 는 300 세대까지는 7, 600 세대까지는 5, 그 이후는 3으로 세대수에 따라 감소하게 하였다.

Fig. 6과 7은 각각 각 그룹의 최고 적합도를 세대수에 따라 나타낸 것이다. 최고 적합도는 그룹 5에서 나왔으며 그 값은 9712.7이었다. 이때 그룹 5의 나이는 5700 세대, A, B 신경회로망의 노드수는 모두 3이다. 슬라이딩 매개변수의 최적값은 $\beta=0.1032$, $\delta=19.1202$ 이며 신경회로망의 연결가중치는 다음과 같다.

Fig. 6. Group Fitness History (2D)

Fig. 7. Group Fitness History (3D)

Fig. 8. Group Fitness History (Low CR)

$$w_A = \begin{bmatrix} -2.9321 & 1.5385 & -3.5673 & -1.2012 \\ 0.3164 & 0.7503 & -5.0000 & 0.4179 \\ 0.4413 & -0.0325 & -4.4646 & -3.0471 \end{bmatrix}$$

$$w_B = \begin{bmatrix} 2.9622 & -4.6891 & -4.8884 \\ -0.0671 & 0.0922 & 0.1643 \\ -5.0000 & 4.8874 & 3.2937 \end{bmatrix}$$

이때, 오차제적 노움은 4×10^{-5} 으로 유전자 알고리즘을 사용하지 않은 2장의 결과인 25.7 보다 현저하게 작아진 것을 알 수 있다. Fig. 8은 생존 문턱을 낮추었을 경우의 그룹 적합도이다. 경쟁을 통과하는 그룹의 수가 많아지나 수렴이 늦어짐을 알 수 있다. Fig. 9와 10은 수치 시뮬레이션 결과이다. 받음각은 2장의 결과와 거의 동일하였고, 피치 각속도와 제어입력 시간 반응은

Fig. 9. Pitch Rate History

Fig. 10. Control Input History

각각 Fig. 9와 10과 같다. 2장의 결과인 Fig. 2-3과 비교해 보았을 때 피치각속도 추종성능과 제어입력 형상이 상당히 향상되었음을 알 수 있다. 적합도 함수 식 (18)의 분모에 노드수가 들어가 있으며, 따라서 오차를 최소화시키면서 동시에 노드수를 줄이는 형태로 진화가 진행된다. 2장의 예제에서 노드수를 3으로 두고 신경회로망으로 최적화시키면 신경회로망의 구조를 최적화 시켜 얻은 결과와 유사한 성능의 결과를 얻을 것으로 사료된다. 그러나 노드수를 선택하는 방법을 제안하는 것이 본 논문의 주제이며, 따라서 원하는 오차범위 내에서 최소의 노드수를 갖는 구조를 선택하게 된 것이 최적화 결과라고 볼 수 있다.

V. 결 론

본 논문에서는 신경회로망을 이용한 비선형 항공기의 제어시스템을 설계하기 위해서 신경회로망의 구조를 최적화하는 방법을 제안하였다. 항공기 시스템에 대해 적응 제어법칙으로 개선되는 신경회로망을 이용하여 비선형 제어시스템을 설계하였다. 그리고 슬라이딩 모드 제어를 이용하여 신경회로망의 추정오차를 보상하였다. 신경회로망은 뛰어난 함수추정 능력을 가지고 있지만 문제에 적합한 구조를 설계하기가 쉽지 않다. 따

라서 복수의 개체군을 형성하여 개체군간의 진화를 통한 방법으로 제어 매개변수뿐만 아니라 신경회로망의 구조탐색에도 적합한 유전자 알고리즘을 제안하였다. 제안한 알고리즘을 항공기 중운동 시스템에 적용하여 수치 시뮬레이션을 수행하여 그 성능을 검증하였다.

후 기

본 연구는 과학기술부 국가지정연구실사업 (과제번호 M1-0104-00-0028)의 지원으로 연구되었습니다.

참고문헌

- [1] B. S. Kim, and A. J. Calise, "Nonlinear Flight Control Using Neural Networks," *Journal of Guidance, Control, and Dynamics*, Vol. 20, No. 1, 1997, pp. 26-33.
- [2] G. B. Sheble, and K. Britting, "Refined Genetic Algorithm Economic Dispatch Example," *IEEE Transaction on Power Systems*, Vol. 10, No.1, 1995, pp.117-124.
- [3] E. F. M. Filho, and A. de Carvalho, "Evolutionary Design of MLP Neural Network Architectures," *Proceedings of IVth Brazilian Symposium on Neural Networks*, Goiania, Brazil, December 1997.
- [4] K. J. Hintz, and J. J. Spofford, "Evolving a Neural Network," *Proceedings of the 5th IEEE International Symposium on Intelligent Control*, Vol. 1, No. 37, 1990, pp. 479 -484.
- [5] D. Dasgupta, and D. R. McGregor, "Designing Application-Specific Neural Networks Using The Structured Genetic Algorithm," *International Workshop on Combinations of Genetic Algorithms and Neural Networks*, Baltimore, Maryland, June 1992.
- [6] D. Whitley, and C. Bogart, "The Evolution of Connectivity, Pruning Neural Networks Using Genetic Algorithms," *Proceedings of International Joint Conference on Neural Networks*, San Diego, California, June 1990.
- [7] D. Whitley, and T. Hanson, "Optimizing Neural Networks Using Faster, More Accurate Genetic Search," *Proceedings of 3rd International Conference on Genetic Algorithms*, Edited by J. D. Schaffer, 1989.

[8] J. R. Koza, and J. P. Rice, "Genetic Generation of Both the Weights and Architecture for a Neural Network," *International Joint Conference on Neural Network(IJCNN)*, Vol. 2, Seattle, Australia, July, 1991.

[9] R. Somakumar, and J. Chandrasekhar, "Neural Networks Based Nonlinear Inverse Dynamics for Flight Controller Design," *Proceedings of the 1998 IEEE International Conference on Control Applications*, Trieste, Italy, 1998.

[10] S. Haykin, *Neural Networks : A Comprehensive Foundation*, New Jersey, Prentice Hall, 1999.

[11] O. Barambones, and V. Etxebarria, "An Adaptive Neural Control Scheme for Mechanical Manipulators with Guaranteed Stability," *1999 IEEE International Symposium on Computational Intelligence in Robotics and Automation*, Monterey, California, November 1999.

[12] K. S. Tang, C. Y. Chan, K. F. Man, and

S. Kwong, "Genetic Structure for NN Topology and Weights Optimization," *First International Conference on Genetic Algorithms in Engineering Systems: Innovations and Applications*, University of Sheffield, UK, September 1995.

[13] 한재홍, 이인, "유전자 알고리즘을 이용한 압전 작동기 배치 최적화에 관한 연구," 한국항공우주학회지, 제 25권, 제 1호, 1997, pp. 71-81.

[14] V. Maniezzo, "Genetic Evolution of the Topology and Weight Distribution of Neural Networks," *IEEE Transactions on Neural Networks*, Vol. 5, Issue 1, 1994, pp. 39-53.

[15] X. Yao, and Y. Liu, "Ensemble Structure of Evolutionary Artificial Neural Networks," *Proceedings of IEEE International Conference on Evolutionary Computation*, Nagoya University, Japan, May 1996.

[16] 김수환, 권장혁, 김효태, "유전 알고리즘을 이용한 공력 및 RCS 익형 최적 설계," 한국항공우주학회지, 제 29권, 제 6호, 2001, pp. 1-8.