

S.I. 엔진 모델링을 위한 신경회로망 기반의 시스템 식별에 관한 연구

A Study on the System Identification based on Neural Network for Modeling of S.I. Engines

윤 마 루*, 박 승 범**, 선 우 명 호***, 이 승 종****
Maru Yoon, Seungbum Park, Myoungho Sunwoo, Seungjong Lee

ABSTRACT

This study presents the process of the continuous-time system identification for unknown nonlinear systems. The Radial Basis Function(RBF) error filtering identification model is introduced at first. This identification scheme includes RBF network to approximate unknown function of nonlinear system which is structured by affine form. The neural network is trained by the adaptive law based on Lyapunov synthesis method. The identification scheme is applied to engine and the performance of RBF error filtering identification model is verified by the simulation with a three-state engine model. The simulation results have revealed that the values of the estimated function show favorable agreement with the real values of the engine model. The introduced identification scheme can be effectively applied to model-based nonlinear control.

주요기술용어 : System identification(시스템 식별), Error filtering model(오차 필터링 모델), Neural Network(신경회로망), Radial basis function(방사상 기반 함수), Lyapunov stability(리아푸노프 안정성), Engine model(엔진 모델)

1. 서 론

날로 강화되고 있는 연비 및 유해 배기ガ스 규제에 대처하기 위해서는 과도상태에서 엔진의 제어성능을 향상시키는 것이 중요한 문제이다. 특히 3원 축매장치를 이용한 유해 배출물 저감에 있어서 효과적인 전환율 확보를 위해서는 평균

공연비의 변동률이 0.2%이내로 제어되어야 한다.¹⁾ 이와 같은 문제를 해결하기 위하여 제어기 설계를 목적으로 하는 엔진의 동적 모델링과 모델 기반 제어(Model-based control)에 많은 연구가 진행되어 왔으며²⁻⁵⁾ 이들은 제어 대상에 대한 수학적 모델을 기반으로 한다.

이 연구에서는 비선형 엔진 제어기 설계를 위해 신경회로망(Neural Network)을 포함한 오차 필터링 모델(Error filtering model)⁶⁻⁸⁾을 이용하여 엔진에 대한 시스템 식별(System identification)⁹⁻¹¹⁾을 수행하였으며, 시뮬레이션을 통해 그 정확

* 회원, 한양대학교 대학원 자동차공학과

** 회원, 한양대학교 대학원 자동차공학과

*** 회원, 한양대학교 자동차공학과

**** 회원, 한양대학교 자동차공학과

성을 검증하였다. 이 식별 모델(identification model)은 엔진의 제어를 위해 외부에서 조절되는 두 개의 입력(스로틀 개도, 분사 연료 유량)과 세 개의 상태변수(흡기 매니폴드 압력, 실린더 내로 유입되는 연료 유량 및 엔진 회전수)의 총 다섯 개의 변수를 입력으로 하여 추정된 세 상태 변수 값을 출력으로 한다.

2. 미지의 비선형 시스템의 식별

2. 1 연속시간 식별

공학의 관점에서 접근할 수 있는 대부분의 연속시간(Continuous-time) 비선형 시스템은 다음의 affine form으로 나타낼 수 있다.⁶⁾

$$\dot{x} = f(x) + g(x)u \quad (1)$$

여기서, $u \in R$ 는 입력, $u \in R^n$ 은 상태변수로서 측정 가능한 값들이며 $f(x)$ 와 $g(x)$ 는 R^n 에서 정의 되는 미지의(unknown) 매끄러운 벡터장(Smooth vector field)이다. Feedback Linearization 제어 등을 포함한 대부분의 비선형 제어 기법들은 이와 같은 affine 시스템을 기반으로 제공되며 non-affine 시스템 또한 동적 확장(Dynamic extension)을 통하여 대부분 affine form으로 변환할 수 있다.⁷⁾

어떤 시스템에 대한 식별(Identification)은 적절한 식별 구조의 선정과 임의의 입력 u 에 대한 식별 모델의 출력 $x(t)$ 가 실제 시스템의 응답 $\hat{x}(t)$ 를 추정할 수 있도록 하는 적응 법칙(Adaptation law)을 통한 모델 파라미터의 수정으로 구성된다.

미지의 비선형성 $f(x)$ 와 $g(x)$ 가 수정 가능한 파라미터 벡터 θ_f 와 θ_g 로 구성되는 임의의 함수 $\hat{f}(x, \theta_f)$ 와 $\hat{g}(x, \theta_g)$ 로 추정되고 있을 때, 식 (1)의 비선형 시스템은 다음의 식으로 다시 쓸 수 있다.

$$\dot{x} = \hat{f}(x, \theta_f^*) + \hat{g}(x, \theta_g^*)u + \nu \quad (2)$$

$$\text{where, } \nu(t) = \{f(x(t)) - \hat{f}(x(t), \theta_f^*)\} + \{g(x(t)) - \hat{g}(x(t), \theta_g^*)\}u(t)$$

여기서 θ_f^* 와 θ_g^* 는 최적의 파라미터로서 각각 $f(x) - \hat{f}(x, \theta_f)$ 와 $g(x) - \hat{g}(x, \theta_g)$ 를 최소화 하는 값을 나타내며, $\nu(t)$ 는 함수 추정 오차(Function approximation error)이다.

위의 식에서 미지의 비선형성을 적절한 구조의 함수로 대체하면 연속시간 시스템 식별을 수행할 수 있다. 입력 u 와 상태변수 $x(t)$ 가 제한(bound)되어 있다고 가정하면 추정 오차는 식 (3)의 ν_0 로 제한되어진다.

$$\nu_0 := \sup | \{f(x(t)) - \hat{f}(x(t), \theta_f^*)\} + \{g(x(t)) - \hat{g}(x(t), \theta_g^*)\}u(t) | \quad (3)$$

2. 2 RBF 오차 필터링 모델^{6,8)}

이 연구에서는 식 (2)의 식별 구조에서의 비선형 항 $f(x)$ 와 $g(x)$ 를 모델링하기 위하여 고정된 중심(Center)과 폭(Width)을 갖는 Gaussian Radial Basis Function Network(GRBFN)을 사용하였으며^{9,10)}, output layer에는 선형함수 뉴런(Linear neuron)을 사용하였다. 여기서 $f(x)$ 와 $g(x)$ 의 추정에 사용되는 Radial Basis Function(RBF)의 출력을 각각 $\xi(x) \in R^{n_1}$, $\zeta(x) \in R^{n_2}$ 로 나타내면 추정되는 비선형 항은 다음과 같이 쓸 수 있다.

$$\begin{aligned} \hat{f}(x, \theta_f^*) &= W_1^* \xi(x) \\ \hat{g}(x, \theta_g^*) &= W_2^* \zeta(x) \end{aligned} \quad (4)$$

여기서 W_1^* 과 W_2^* 는 $n \times n_1$, $n \times n_2$ 행렬로, n , n_1 , n_2 는 각각 output layer의 뉴런 개수, $f(x)$ 의 추정에 사용되는 GRBFN의 중심의 개수, 그리고 $g(x)$ 의 추정에 사용되는 GRBFN의 중심의 개수이다.

식 (4)를 식 (2)에 대입하면 미지의 비선형 시스템을 다음과 같이 나타낼 수 있다.

$$\dot{x} = W_1^* \xi(x) + W_2^* \zeta(x)u + \nu \quad (5)$$

상태변수 추정 오차(State estimation error)를 다음과 같이 정의하고,

$$\begin{aligned} e_x &= \hat{x} - x \\ &= \{\hat{f}(x, \theta_f) - f(x)\} + \{\hat{g}(x, \theta_g) - g(x)\}u \end{aligned} \quad (6)$$

이 오차에 임의의 역학을 제공하기 위하여 이를 필터링 된 형태(Filtered version)로 대체하면 오차 동역학(Error dynamics)은 다음과 같이 전개 할 수 있다.

$$\dot{e}_x + \alpha e_x = \{\hat{f}(x, \theta_f) - \hat{f}(x, \theta_f^*)\} + \{\hat{g}(x, \theta_g) - \hat{g}(x, \theta_g^*)\} - \nu \quad (7)$$

여기서 α 는 설계 변수로서 양의 값을 가진다. 이 식에 $e_x = \hat{x} - x$ 를 대입하여 정리하면 추정기(Estimator), 혹은 식별 모델(Identification model)에 대한식을 얻을 수 있다.

$$\dot{\hat{x}} = -\alpha \hat{x} + \alpha x + W_1 \xi(x) + W_2 \zeta(x) u \quad (8)$$

여기서 \hat{x} 은 식별 모델의 출력이며, W_1 과 W_2 는 각각 W_1^* 과 W_2^* 의 추정치이다. 식 (8)의 식별 모델은 계인(Gain) α 를 포함하는 관측기(Observer) 항과 신경회로망으로 추정된 비선형 항의 합으로 나타남을 알 수 있다. Fig. 1은 이상의 구조로 이루어진 RBF 오차 필터링 모델의 블록 선도를 나타낸다.

2.3 리아푸노프 종합법

기계적인 혹은 전기적인 시스템이 가진 에너지의 총합이 계속적으로 소진된다면 그 시스템은 결국 평형점(Equilibrium point)으로 안정하게 된다. 따라서 어떠한 시스템의 안정도(Stability)는 단일의 스칼라 함수의 변화량으로 설명될 수

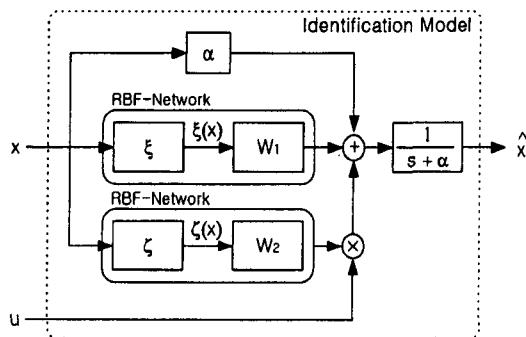


Fig. 1 A block diagram representation of the error filtering identification model developed using RBF networks

있다. 이와 같은 관점에서 어떤 시스템에 대한 안정도를 리아푸노프(Lyapunov) 안정도라 하며, 리아푸노프 종합법(Lyapunov synthesis method)은 이 안정도를 보장하는 파라미터 수정 법칙(Update law)을 찾아내는 일련의 과정이다. 식 (5)를 다음과 같이 재구성하고,

$$\dot{x} = -\alpha x + \alpha x + W_1^* \xi(x) + W_2^* \zeta(x) u + \nu \quad (9)$$

가중치 추정 오차(Weight estimation error)를 다음과 같이 정의하면,

$$\begin{aligned} \Phi_1 &= W_1 - W_1^* \\ \Phi_2 &= W_2 - W_2^* \end{aligned} \quad (10)$$

식 (8)로부터 다음의 식을 얻을 수 있다.

$$\dot{e}_x = -\alpha e_x + \Phi_1 \xi(x) + \Phi_2 \zeta(x) u - \nu \quad (11)$$

리아푸노프 함수¹¹⁾는 다음과 같이 정의하였다.

$$V(e_x, \Phi_1, \Phi_2) = \frac{1}{2} |e_x|^2 + \frac{1}{2\gamma_1} \|\Phi_1\|_F^2 + \frac{1}{2\gamma_2} \|\Phi_2\|_F^2 \quad (12)$$

선정된 함수는 상태변수 추정 오차와 가중치 추정 오차의 조합으로 이루어져 있으므로 오차들의 에너지를 표현하고 있음을 알 수 있다. 여기서 γ_1 과 γ_2 는 양의 상수로서 훈련 속도(Learning rate), 혹은 적응 계인(Adaptive gain)이라 하며 리아푸노프 함수의 시간에 대한 일차 미분은 식 (13)의 형태가 된다.

$$\begin{aligned} \dot{V}(e_x, \Phi_1, \Phi_2) &= -\alpha |e_x|^2 \\ &\quad + \frac{1}{\gamma_1} \text{tr}\{(\gamma_1 e_x \xi^T + \Phi_1) \Phi_1^T\} \\ &\quad + \frac{1}{\gamma_2} \text{tr}\{(\gamma_2 e_x u \zeta^T + \Phi_2) \Phi_2^T\} - e_x^T \nu \end{aligned} \quad (13)$$

따라서 신경회로망에 대한 가중치 수정 법칙은 다음과 같이 선정할 수 있다.

$$\begin{aligned} \dot{W}_1 &= -\gamma_1 e_x \xi^T \\ \dot{W}_2 &= -\gamma_2 e_x u \zeta^T \end{aligned} \quad (14)$$

즉, $\nu_0 = 0$ 의 조건과 식 (14)의 수정 법칙은 $\dot{V} \leq 0$ 의 조건을 만족하므로 식별 모델 내부의 함수 추정 오차 및 식별 모델 출력인 상태변수 추정 오차는 0으로 수렴하게 된다.

3. 엔진 모델

3. 1 Three-state MIMO 엔진 모델

제어기 설계를 목적으로 하는 모델은 최소한의 변수를 포함하는 수학적으로 간단한 형태를 가져야 하며, 광범위한 운전영역에서 그 정확도가 보장되어야 한다.

이 논문에서는 실제 엔진의 모의실험을 위하여 기 개발된 엔진 모델을 사용하였다.²⁾ 이 평균값(Mean value) 엔진 모델은 스로틀 개도(δ)와 점화시기 및 연료 분사량(\dot{m}_f)을 입력으로 하고 흡기 매니폴드 압력(P_m)과 연료막의 연료 질량 및 엔진 회전수(N)에서 세 개의 동역학(Dynamics)을 가지며, 부하 토크가 외란(Disturbance)으로 작용하는 MIMO(Multi-Input Multi-Output) 시스템이다.

점화 진각(Spark advance)은 미리 결정된 룩업테이블(Look-up table)에 따라 MBT로 개루프(Open-loop) 제어 된다고 가정하고, 상태 변수와 입력 및 출력을 다음과 같이 정의하면

$$\begin{aligned} \mathbf{x} &= [P_m \quad \dot{m}_f \quad N]^T \\ \mathbf{u} &= [\delta \quad \dot{m}_f]^T \\ \mathbf{y} &= [N \quad \beta]^T \end{aligned} \quad (15)$$

이 엔진 모델은 2-입력/2-출력의 MIMO시스템이 된다. 여기서 \dot{m}_f 는 실린더 내부로 유입되는 연료유량이며 β 는 공연비(Air-to-fuel ratio)이다. 이를 식 (15)의 affine form으로 표현하면 다음과 같은 상태방정식을 얻을 수 있다.

$$\begin{aligned} \dot{x}_1 &= f_1(x) + g_1(x) \bar{u}_1 \\ \dot{x}_2 &= f_2(x) + g_2(x) \bar{u}_2 \\ \dot{x}_3 &= f_3(x) \end{aligned} \quad (16)$$

$$\text{where, } f_1(x) = -\frac{V_D}{120 V_m} x_3 [w_1(x_3) + w_2(x_3)x_1]$$

$$g_1(x) = -\frac{RT_m}{V_m} C_D \cdot MA \cdot PRI(x_1)$$

$$f_2(x) = -\frac{x_2}{\tau_f}$$

$$g_2(x) = 1$$

$$f_3(x) = \frac{30}{\pi J_{eff}} (t_0 + t_1 x_1 t_2 x_3 - T_L)$$

여기서, w_1 과 w_2 는 표준 공기 충전량(Normalized air charge)을 근사화 하는 데 사용되는 다항식이며, MA 는 스로틀 벨브의 형상에 따른 최대 유량을, PRI 는 스로틀 통과 공기 유량에 대한 압력비의 영향을 나타내는 인자이고, t_0 , t_1 , t_2 는 제동 토크 제동 토크(Brake torque)에 대한 근사식의 상수이다.

식 (16)의 제어 입력 \bar{u} 는 엔진 모델식을 affine form으로 나타내기 위하여 선택된 것으로 다음의 형태를 가진다.

$$\begin{aligned} \bar{u}_1 &= 1 - \cos(h_0 + h_1 u_1) \\ \bar{u}_2 &= (1 - X) \dot{u}_2 + \frac{1}{\tau_f} u_2 \end{aligned} \quad (17)$$

여기서 h_0 과 h_1 은 스로틀의 개방 단면적을 근사화 하기 위하여 사용된 상수이다.

3.2 엔진의 RBF 오차 필터링 모델

이 연구에서는 비선형 엔진제어기 설계를 위한 기초 단계로, 앞 장에서 소개된 오차 필터링 모델을 이용하여 엔진에 대한 시스템 식별을 수행하였다. 엔진의 식별을 위하여 수행한 시뮬레이션에서 식 (15)의 입력 중 스로틀 개도는 임의의 파형으로 제공하였고, 연료 분사 유량은 공연비를 PI(Proportional Integral) 제어기로 제어하였으며, 엔진의 한 사이클마다 세 상태 변수에 대한 샘플을 취하는 이벤트 기반(Event-based) 식별을 수행하였다.

Fig. 2는 엔진 식별에 사용된 식별 모델의 구성

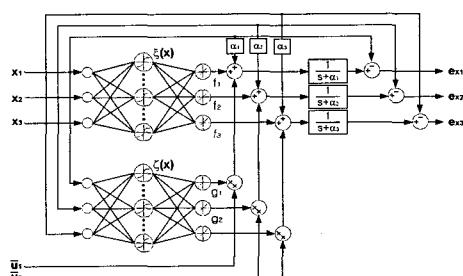


Fig. 2 Block diagram of RBF error filtering identification model for engine

도로서 식 (17)에 따라 재정의된 스로틀 개도와 분사 연료 유량 및 세 개의 상태변수를 입력으로 하여 크랭크 각 720도 이후의 세 상태 변수 값을 출력으로 하는 형태로 구성되었다.

3.3 시뮬레이션 결과

Fig. 3은 시뮬레이션 과정에서 엔진의 세 상태 변수의 궤적을 나타낸 그림이다. 각 상태 변수에 대하여 6개의 중심을 사용하였고 중심들 간의 거리를 정규화 하였으므로 총 216개의 중심을 갖는 정육면체 형태의 입력 공간이 형성된다.

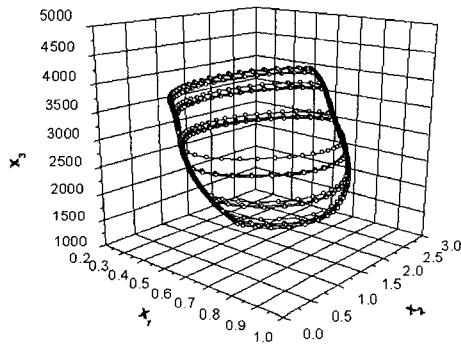


Fig. 3 State contour during simulation

식별을 위한 시뮬레이션은 MATLAB[®]을 사용하여 엔진의 1670사이클 동안 수행되었으며 Fig. 4는 엔진 식별 과정에서 엔진 모델에 포함된 미지의 비선형 함수, $f_1(x)$, $f_2(x)$, $f_3(x)$, $g_1(x)$, $g_2(x)$ 에 대한 추정 성능을 보여주고 있다. 함수 $g_1(x)$ 에는 $0 < PRK < 1$ 의 제한이 존재하므로 상대적으로 미흡한 추정 성능을 보이고 있으며, 이로 인해 $f_1(x)$ 의 추정 성능도 영향을 받고 있는 모습을 볼 수 있다. 나머지 함수들은 적응이 진행되면서 실제의 함수를 잘 추정하고 있다.

Fig. 5는 엔진의 세 상태 변수의 추정 결과를 나타낸 것이다. 훈련 초기에는 오차가 크며, 특히 과도 상태에서 큰 오차가 발생하고 있으나 훈련이 진행되면서 함수 추정오차가 줄어듦으로 인해 상태 변수가 효과적으로 추정되고 있음을 볼 수 있다.

4. 결 론

이 연구에서는 모델 기반 제어의 기초 연구로서 미지의 비선형 시스템에 대한 식별(Identification)을 수행하였으며, 엔진의 식별에 이를 적

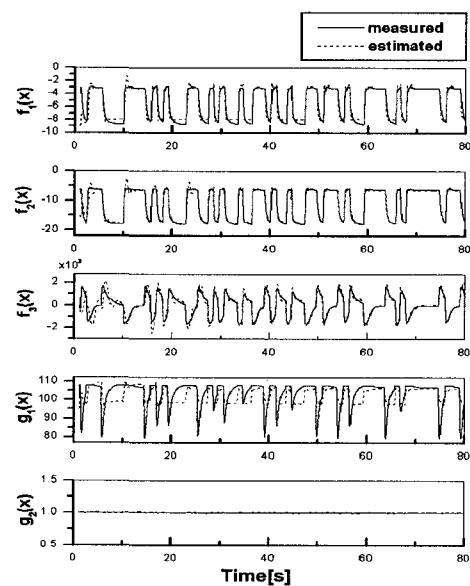


Fig. 4 Performance of function approximation
: Simulation

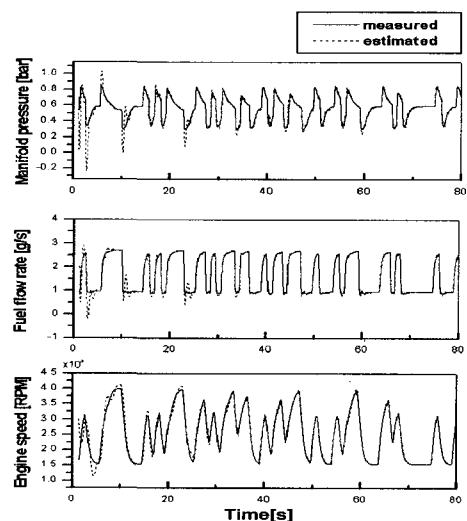


Fig. 5 Performance of state estimation : Simulation

용하였다. 이를 통하여 얻은 결론은 다음과 같다.

1) 이 식별 모델은 GRBFN(Gaussian Radial Basis Function Network)을 이용하여 함수를 추정하고 이로부터 상태 변수를 추정한 후, 그 오차를 필터링하여 리아푸노프 안정도에 기초한 적응법칙에 따라 신경회로망을 훈련시키는 구조로 이루어져 있다.

2) 두 개의 입력변수(스로틀 개도, 연료 유량)와 3개의 상태 변수(흡기 매니폴드 압력, 연료막 내의 연료 질량 및 엔진 회전수)로 구성된 MIMO 엔진 모델에 대하여 식별을 수행하였으며, 식별 모델의 출력과 실제 값을 비교하여 식별 모델의 정확성을 검증하였다.

3) 식별 모델을 통해 추정된 함수를 모델 기반 제어(Model-based control)에 활용하여 미지의 비선형 시스템에 대해 정밀한 제어를 수행할 수 있을 것으로 기대된다.

참 고 문 헌

- 1) N. F. Benninger, G. Plapp, "Requirements and Performance of Engine Management System under Transient Conditions," SAE 910083, 1991.
- 2) 선우명호, 윤팔주, "제어기 설계를 위한 비선형 동적 엔진 모델링," 한국자동차공학회 논문집, 제7권 제 7호, 1999.
- 3) M. Nasu, A. Obata, S. Abe, "Model-based Fuel Injection System for SI Engines," SAE 961188, 1996.
- 4) J. J. Moskwa, J. H. Hedrick, "Modeling and Validation of Automotive Engines for Control Algorithm Development," Trans. ASME, Journal of Dynamic Systems, Measurement and Control, Vol.114, 1992.
- 5) E. Hendricks, S. C. Sorenson, "SI Engine Controls and Mean Value Engine Modeling," SAE 910258, 1991.
- 6) C. T. Leondes, "Neural Network Systems Techniques and Applications , In Control and Dynamic Systems," ACADEMIC PRESS, Vol.7, 1998.
- 7) H. Nijmeijer, A. J. Van der Schaft, "Nonlinear Dynamical Control Systems," Springer-Verlag, New York, 1990.
- 8) L. Praly, G. Bastin, J. -B. Pomet, Z. P. Jiang, "Adaptive Stabilization of Nonlinear Systems. In Foundation of Adaptive Control(P. V. Kokotovic, Ed.)," Springer-Verlag, Berlin, 1991.
- 9) M. Sanner, "Stable Adaptive Control and Recursive Identification of Nonlinear Systems Using Radial Gaussian Networks," Ph.D Thesis, Department of Aeronautics and Astronautics, Massachusetts Institute of Technology, 1993.
- 10) M. Sanner, J. -J. E. Slotine, "Gaussian Networks for Direct Adaptive Control," IEEE Trans. Neural Networks, Vol.3, 1992.
- 11) C. Parks, "Lyapunov Redesign of Model Reference Adaptive Control Systems," IEEE Trans. Automat. Control AC, Vol.11, 1996.