

Deep Learning-based PID Control for ETB with Parameter Variation and Nonlinear Torque

Kap Rai Lee*

*Professor, Dept. of Smart Mobility, Pyeongtaek University, Pyeongtaek, Korea

[Abstract]

In this paper, an approach based on deep learning and parameter dependent control is proposed for electronic throttle body(ETB) control which has variable parameters and nonlinear torques. Firstly we present parameter estimation method for ETB system using deep neural network. To estimate parameters of ETB, we design deep neural networks and train by use time response characteristic such as rise time, overshoot and settling time. Parameters of ETB are estimated through trained neural networks by using time response data. Secondly we design parameter dependent PID controller which is adjusted automatically with the estimated system parameter of ETB. To design optimal parameter dependent gain of PID controller, we use ITAE(Integral of time multiplied by absolute error) criteria. In addition, we design feed-forward controller to reject nonlinear torque. Finally we present simulation results of ETB system with parameter variation and nonlinear torque to verify controller design method.

▶ **Key words:** Electronic throttle body, Time invariant parameter variation, Nonlinear torque, Deep learning based control, Parameter dependent PID Controller

[요 약]

본 연구에서는 파라미터 변이 및 비선형 토크를 갖는 차량 전자식 스로틀 바디 시스템(ETB)의 딥러닝 기반의 파라미터 종속적인 PID 제어기 설계 방법을 나타낸다. 시스템 변화 및 부하용량 변화로 인하여 변이된 시스템의 주요 파라미터 값을 딥러닝을 이용하여 추정한다. 파라미터를 추정하기 위하여 심층 신경망을 설계하고, 시스템의 시간응답 특성(상승시간, 오버슈트, 정착시간)을 특성값으로 하여 신경망을 훈련한다. 훈련된 신경망으로부터 시간응답 특성값 이용하여 파라미터는 추정된다. 또한 추정된 파라미터에 동조되어 자동 조정되는 파라미터 종속 PID 제어를 설계한다. PID 제어기의 최적 이득값은 ITAE 판별법에 의하여 찾아지며, 추정된 파라미터의 함수로 나타내어진다. 또한 비선형 토크의 영향을 감쇄하기 위하여 추정된 비선형 토크값을 상쇄시켜 줄 피드 포워드 제어를 추가적으로 설계한다. 설계된 제어기의 제어 성능을 나타내기 위하여, 시뮬레이션을 통한 파라미터 변화 및 비선형 토크를 갖는 ETB 시스템의 제어 성능 결과를 나타낸다.

▶ **주제어:** 스로틀 바디, 시불변 파라미터 변이, 비선형 토크, 딥러닝 기반 제어, 파라미터 종속 PID 제어기

• First Author: Kap Rai Lee, Corresponding Author: Kap Rai Lee
*Kap Rai Lee (krlee@ptu.ac.kr), Dept. of Smart Mobility, Pyeongtaek University
• Received: 2024. 10. 07, Revised: 2024. 10. 31, Accepted: 2024. 11. 01.

I. Introduction

전자식 스로틀 바디 시스템(ETB) 차량의 기계적 제어를 센서, 전기모터, ECU로 제어하는 차량의 대표적인 전자 제어장치이다^{1, 2}. 스로틀 바디 시스템의 전자 제어 시스템은 연비와 엔진 토크를 개선할 수 있으며, 속도 제어 및 트랙션 컨트롤 시스템 등과 통합적으로 제어 시스템을 설계할 수 있는 장점이 있다³. 제어기 설계 시에 고려하는 스로틀 바디 시스템이 다양한 동작 환경의 변화로 인하여 파라미터 변화와 비선형성 증가가 발생하는 경우에는 제어 성능 저하가 많이 발생할 수 있다⁴. 따라서 동작 환경 변화에도 성능을 유지할 수 있는 제어기 설계 방법으로 파라미터 변화와 비선형성 특성을 고려한 설계 방법들을 생각할 수 있다.

스로틀 바디의 비선형 부하 토크로 인한 비선형성 특성을 고려하기 위하여, 슬라이딩 모드 제어^{5,6}와 모델 역변환을 이용하는 비선형 다이내믹 인버전(Nonlinear Dynamic Inversion, NDI)^{6,7} 연구 결과가 있다. 비선형성 증가가 발생할 경우 모델 역변환을 이용하는 방법이 적합할 수 있으나, 안정성 보장 조건과 비선형 방정식 자체의 계수값을 정확하게 찾는 어려움이 있다.

실제 현장에서의 제어기 설계는 경험적이고 실험적인 방법들과의 결합으로 설계되는 경우가 많으므로 PID 제어는 매우 효과적으로 사용되는 기법이다. 스로틀 바디 시스템의 파라미터 변이를 고려하기 위하여 파라미터 변이에 동조되어 PID 제어기 이득 값을 자동으로 조절하는 오토 튜닝 제어기 설계기법이 있다. 이 경우에 페루프 시스템에 대한 모델링 추정과 PID 자기 동조 방법⁸이 있으며, 파라미터를 RLS (Recursive Least Square)로 추정하여 추정된 값을 매개로 하여 PID 이득을 자동 조절하는 연구가 있다⁹. 이때 파라미터 추정은 제어 입력과 시스템 출력의 과거 데이터 다수 개를 이용하여 실시간으로 보완(update) 추정하는 방식이다. RLS로 파라미터 추정은 추정 모델의 출력값과 관측 출력값의 오차에 대한 분산값을 최소화 되게 하는 최적 파라미터를 찾는 개념이다. 또한 제어입력이 동작하는 한 주기 이내에서 공분산 행렬과 적응 이득 벡터 값을 계산하여 제어기가 동작하는 시간 동안 계속 전파시켜 나가야 한다. 일반적으로 이 경우에는 백색 가우시안 잡음을 갖는 확률 모델을 이용하게 된다. 설계 대상 제어 시스템이 확률적 모델링이 적합하지 않거나, 과거 데이터의 다수개를 이용하는 것보다 큰용량의 학습 데이터를 이용하여 파라미터를 추정할 수 있는 시스템의 경우에는 다른 파라미터 추정 방법을 고려해 볼 수 있다.

스로틀 바디의 학습 기반의 제어도 연구되어 왔다. 비선형 특성의 간략화된 특성을 고려하는 신경망 기반의 슬라이딩 모드 제어기법과 실시간 적용을 위한 반복적 신경망 제어 기법들이 있다^{10,11}. 또한 신경망 기반의 자기 학습 PID 제어 기법이 있으며¹², 이 경우 PID 제어기의 이득값은 신경망의 연결강도로 처리되고 신경망 알리즘에 따라 제어기 이득값이 찾아지는 방식이다. 따라서 이와 같은 신경망 기반의 자기 학습 PID 제어 기법에서의 PID 제어기 이득값은 학습으로 찾지만 고정된 값을 갖게된다.

또한 시스템의 파라미터 변이에 따라 제어기 이득값이 가변하는 인공 신경망 기반의 오토튜닝 PID 제어기를 쿼드콥터, 수중 운동체 그리고 볼 밸런싱(ball on plate)에 적용한 연구 결과가 있다.¹³⁻¹⁵ 이 경우 파라미터 변이는 시스템의 비선형 및 환경 외란의 불확실성 영향으로 인한 것이다. 이때 오토튜닝 PID 제어기의 이득값은 출력신호 오차값 및 제어 입력값을 특성값으로 하여 출력 오차값을 최소화 시키는 역전파 알고리즘을 이용하여 실시간으로 변화시키는 개념이다. 이들 논문에서의 오토튜닝 PID 제어기는 제어 입력이 동작하는 한 주기 이내에서 신경망의 역전파 알고리즘을 이용하여 제어기 이득값을 변화하기 때문에, 입력 노드와 은닉 노드의 수를 증가시키는 데에는 한계가 있다. 또한 이들 제어기 설계 방법에서는 피드백 제어시스템의 안정성은 수학적으로 보장하지 않는 방법들이다. 시스템의 안정성(stability)을 중요시하는 보수적인 ETB 제어 시스템에서 적용하기에는 한계가 따르는 방법이 될 수도 있다.

본 연구에서는 파라미터 변이 및 비선형 토크가 존재하는 ETB 제어 시스템 설계 방법으로 딥러닝 기반의 파라미터 종속 PID 제어기 설계 방법을 나타낸다. ETB 시스템의 파라미터 변이는 엔진 내부의 실린더 용량과 기구부 사양에 따라 스로틀 평면의 넓이 및 내부 모터의 사양이 달라질 수 있으므로 시불변 파라미터 변이를 갖는 시스템으로 나타낼 수 있다. 비선형 토크는 제어기 동작 동안 실시간으로 작동하기 때문에 비선형 토크의 영향을 시변 파라미터 변이 시스템으로 두고 제어기를 설계할 수도 있지만, 안정성 판별 문제와 큰 용량의 학습 데이터를 제어 입력이 동작하는 한 주기 이내에서 학습시키는 어려움이 있다. 이를 극복하기 위하여 비선형 부하토크의 영향을 시스템 파라미터에 포함하지 않고 외부 외란으로 처리하여 외부 외란을 갖는 선형시스템으로 두고 제어기를 설계한다. 이때 비선형 외란 토크의 영향을 감쇄하기 위하여, 토크 추정기를 이용하여 비선형 토크를 추정하고 추정된 비선형 토크 값을 상쇄시켜줄 피드 포워드 제어기를 추가적으로 설계

한다. 딥러닝 기반 제어기에서 시불변 파라미터변이를 갖는 선형시스템은 오프라인으로 학습시킬 수 있으므로 대용량의 학습 데이터뿐만 아니라 입력 노드와 은닉 노드의 수를 크게하여 학습시키기에 적절하다. 또한 시불변 선형 시스템이므로 안정성 체크도 용이하다. 스로틀 바디 시스템을 비선형 외란토크 및 시불변 파라미터 변이를 갖는 선형 방정식으로 모델링하여 파라미터 종속적인 제어를 설계하기 위하여, 먼저 시스템 사양의 변화로 인하여 변화된 시스템의 주요 파라미터 값을 딥러닝을 이용하여 추정한다. 파라미터를 추정하기 위하여 심층 신경망(Deep Neural Network)을 설계하고, 시스템의 시간 응답값(상승시간, 오버슈트, 정착시간)을 특성값으로 하여 신경망을 훈련시킨다. 훈련된 심층 신경망으로부터 파라미터를 추정하고 추정된 파라미터를 매개변수로 하는 파라미터 종속적인 제어기 이득값은 ITAE 규칙에 따른 최적의 PID 제어를 설계한다. PID 제어기 이득값은 심층 신경망의 추정된 파라미터의 함수로 나타난다. 또한 비선형 외란 토크의 영향을 감쇄하기 위하여 추정된 비선형 토크값을 상쇄시켜줄 피드 포워드 제어를 추가적으로 설계한다. 마지막으로 시뮬레이션을 통한 비선형 토크 및 파라미터 변화를 갖는 ETB 시스템의 제어 성능 결과를 나타낸다.

II. Preliminaries

1. ETB System model

스로틀 바디 시스템은 DC 모터, 기어박스, 스로틀 평면, 복원 스프링 등으로 구성되므로, 수식 모델링은 모터와 스로틀 바디 및 부하 시스템의 모델링을 통하여 나타내낼 수 있다. 스로틀 바디 부하 시스템의 토크 균형 방정식은 아래 식과 같이 나타낼 수 있다.

$$T_p = J_p \frac{dw_p}{dt} + B_p w_p + T_f \quad (1)$$

여기서 w_p 은 스로틀 바디의 각속도, J_p 는 스로틀 바디의 관성 모멘트, B_p 는 스로틀 바디의 점성 마찰 계수이다. T_p 는 스로틀 바디에 인가되는 토크이고, T_f 는 외부 부하 토크이다. DC 모터에 대한 토크방정식 및 전압 방정식은 다음과 같다.

$$T_m = J_m \frac{dw_m}{dt} + B_m w_m + \frac{1}{N} T_p \quad (2)$$

$$V_a = R_a \cdot I_a + L_a \frac{dI_a}{dt} + K_b \cdot w_m \quad (3)$$

여기서 w_m 은 모터의 각속도, J_m 는 모터의 관성모멘트, B_m 는 모터의 점성 마찰계수, T_m 는 모터에 인가되는 토크이다. I_a 는 모터의 아마추어 전류, R_a 는 모터의 아마추어 저항, L_a 는 모터의 인덕턴스, K_b 는 모터의 역기전력 상수이다. 모터에 인가되는 토크식은 $T_m = K_t \cdot I_a$ 이며 $w_m = N \cdot w_p$ 이다. K_t 는 모터 토크 상수이다. 기어비 $N=1$ 로 두고 전기자의 시정수 L_a/R_a 은 무시할 수 있으므로 식 (2) 및 (3)은 다음과 같이 표현된다.

$$\frac{dw_p}{dt} = -\left(\frac{R_a \cdot B}{J \cdot R_a} + \frac{K_t \cdot K_p}{J \cdot R_a}\right)w_p + \frac{K_t}{J \cdot R_a}V_a + \frac{1}{J}T_f \quad (4)$$

여기서 $J = J_m + J_p$ 이며 $B = B_m + B_p$ 이다.

2. Nonlinear Torque model

스로틀 바디 평면에 작용하는 힘은 크게 스프링 반력 (T_{sp})과 마찰 토크(T_f) 이다.^[4,6,16]

2.1 Friction Torque

ETB 평면(plate)에 존재하는 마찰력은 쿨롱 마찰력, 정 마찰력, 점성 마찰력이 있다. 마찰력은 두 물체 사이에 상대 운동을 유도하는 힘과 반대로 작용하는 마찰력인 쿨롱 마찰력이 상대적으로 정 마찰력과 점성 마찰력보다 큰 편이다. 베어링과 기어부 등의 기계적인 요소들 간의 저항으로 인하여 스로틀의 움직임을 방해하며, 외부 진동에 의하여 유입될 수도 있다. ETB 시스템의 마찰 토크는 ETB 시스템의 각속도에 따라 변하는 비선형 특성을 보이며 부호(signum)함수나 하이퍼볼릭 탄젠트(tanh)함수로 나타낸다.

$$T_{fr}(w_p) = K_{fr} \cdot \tan^{-1}(w_p) \quad (5)$$

여기서 K_{fr} 은 마찰 토크의 최대 크기이다.

2.2 Return Spring Torque

ETB 시스템의 복귀 스프링은 모터가 구동되지 않아도 스로틀 평면을 공회전 위치로 복귀시키는 기능을 담당한다. 제어 입력이 인가되지 않을 경우 스로틀 평면은 개폐각이 LH(lipm-home) 위치까지 스프링의 영향을 받는다. 복귀 스프링의 토오크 특성은 스로틀 평면의 개폐각에 따라 변하는 비선형 특성으로 나타나며, 다음 식과 같이 나타낼 수 있다^[4,6].

$$T_{sp}(\theta) = K_{sp}(\theta - \theta_0) + D_d \cdot \text{sign}(\theta - \theta_0)$$

$$\text{sign}(\theta - \theta_0) = \begin{cases} 1, & \theta \geq \theta_0 \\ -1, & \theta < \theta_0 \end{cases} \quad (6)$$

여기서 D_d 는 스프링이 복귀시키는 LH 위치에서의 토크 크기를 나타내며, K_{sp} 는 ETB 스톱 밸브의 개폐각에 대한 스프링 토크의 기울기를 나타내는 상수이다. K_{sp} 가 큰 시스템은 개폐각에 따른 스프링 토크가 크게 작용한다는 의미를 나타낸다.

3. ETB model with Time-invariant Parameter Variation and Nonlinear Torque

식 (4)~(6)으로 표현된 ETB 시스템은 비선형 방정식이다. 본 연구에서는 비선형 ETB 시스템을 파라미터 변이를 갖는 선형 방정식과 비선형 외란 토크로 갖는 시스템으로 처리하여 제어를 설계한다. 식 (4)로 표현된 ETB 시스템은 엔진 내부의 실린더 용량과 기구부 사양에 따라 스톱 밸브 평면의 넓이 및 내부 모터의 사양이 달라질 수 있으므로 시불변 파라미터 변이를 갖는 식 (7)과 같은 시스템으로 나타낼 수 있다. 또한 부하토크 $T_f(t)$ 는 식 (5) 및 (6)과 같이 비선형 특성을 갖는다.

$$\frac{dw(t)}{dt} = A(\rho)w(t) + B(\rho)u(t) + \frac{1}{J}T_f(t) \quad (7)$$

$$A(\rho) = -\left(\frac{R_a \cdot B}{J \cdot R_a} + \frac{K_t \cdot K_p}{J \cdot R_a}\right), \quad B(\rho) = \frac{K_t}{J \cdot R_a} \quad (8)$$

파라미터 변이를 갖는 시스템으로 모델링하여 파라미터 종속적인 제어를 설계할 경우 다음과 같은 장점이 있다. 파라미터가 변하는 각각의 시스템마다 그 시스템에 최적화된 서로 다른 제어기(서로 다른 전자제어 보드)를 설계 제작할 경우에 양산 단가 및 유지보수 비용이 증가한다. 따라서 시운전(테스트 모드)을 통하여 대상 시스템의 주요 파라미터를 스스로 추정하고, 추정된 파라미터에 자동으로 조정되는 파라미터 종속적인 제어가 운전 모드에서 동작한다면 양산 단가 및 유지보수 비용 측면에서 유리하기 때문이다. 본 연구에서 사용된 스톱 밸브 시스템은 기존 연구 논문[5, 7]에서 사용된 시스템 상수값과 유사한 값을 이용하며 아래 표와 같다.

Table 1. Parameters of ETB System

Parameter	Value	Parameter	Value
K	$5.8 \cdot 10^{-5}$ (Nm/A)	K_b	$4.29 \cdot 10^{-2}$ (V·sec/rad)
R_a	3.0 (Ω)	B	$3.5 \cdot 10^{-5}$ (kgm ² /s)
J_m	$1.5 \cdot 10^{-6}$ (kgm ²)	J_p	$4.2 \cdot 10^{-6}$ (kgm ²)
K_{fr}	0.001 (N·m)	K_{sp}	$0.13 \cdot 10^{-3}$ (Nm/rad)
D_d	0.001 (N·m)	θ_0	1 (deg)

본 연구에서는 비선형 마찰 토크 및 시불변 파라미터 변이를 갖는 식 (7)의 ETB 시스템에 대하여 비선형 토크를 감쇄하고 성능 최적화를 꾀하는 파라미터 종속적인 제어를 설계하고자 한다. 성능 최적화는 전체 페루프 시스템이 계단 입력에 대하여 아래와 같은 절대오차-시간-곱적분(ITAE)이 최소가 되도록 하는 제어를 설계한다.

$$ITAE = \int_0^T t \cdot |e(t)| dt \quad (9)$$

여기서 $e(t)$ 는 페루프 시스템의 출력 오차를 나타낸다.

III. The Proposed Scheme

1. Control Scheme of ETB System

비선형 마찰 토크 및 시불변 파라미터를 갖는 김벌 시스템에 대한 성능 개선을 위하여 본 연구에서 제안하는 파라미터 종속적인 제어기 구조는 그림1과 같다.




Fig. 1. Controller Scheme of ETB System.

먼저 시불변 파라미터 변이를 갖는 시스템에 연동되어 동작하는 파라미터 종속제어를 설계하기 위하여 심층 신경망(DNN)을 설계하고 이를 이용하여 파라미터를 추정한다. 이어서 전체 페루프 시스템의 절대오차-시간-곱적

분(ITAE)이 최소가 되도록 하는 파라미터에 종속적인 최적 제어기를 설계한다. 마지막으로 비선형 마찰 토크(\widehat{T}_f)의 크기를 추정하고, 이 추정된 값을 이용하여 마찰 토크를 상쇄시켜 줄 수 있을 만큼의 역토크가 생성되도록 제어 입력을 발생시키는 구조이다. 훈련된 심층 신경망과 설계된 제어기는 시스템에 탑재하여 다음과 같은 과정을 통하여 파라미터 종속적인 제어기로 동작한다. 제어기가 시스템에 탑재되어 맨 처음 작동할 때 시운전 모드를 선택하면, 계단함수를 ETB 시스템에 입력하여 응답특성인 상승시간, 오버슈트, 정착시간을 스스로 측정한다. 이어서 이 값을 훈련된 신경망에 입력으로 인가하여 ETB 시스템의 파라미터 K 및 τ 를 자동으로 추정한 후에 이 파라미터에 연동되어 제어기는 동작하게 된다.

식 (7)의 스로틀 바디 전달함수는 다음과 같이 표현된다.

$$G(s) = \frac{\theta(s)}{V_a(s)} = \frac{K}{s \cdot (\tau s + 1)} \quad (10)$$

$$\begin{aligned} K &= K_t / (R_a \cdot B + K_t \cdot K_b) \\ \tau &= R_a \cdot J / (R_a \cdot B + K_t \cdot K_b) \end{aligned} \quad (11)$$

τ 및 K 는 시불변 변이를 갖는 파라미터이다. 식 (10)의 스로틀 바디 시스템을 제어할 파라미터 종속 PID 제어기를 다음과 같이 나타낸다.

$$C(s) = K_p(\tau, K) + K_d(\tau, K)s + K_i(\tau, K)/s \quad (12)$$

여기서 K_p, K_d, K_i 는 PID 제어기의 이득값이다. 또한 성능 개선을 위하여 $C_f(s) \cdot C(s) = K_i/s$ 가 되도록 예비 필터 $C_f(s)$ 선택한다.

$$C_f(s) = \frac{K_i}{K_d s^2 + K_p s + K_i} \quad (13)$$

식 (10)~(13)으로부터 전체 페루프 시스템은 다음과 같다.

$$\begin{aligned} T(s) &= \frac{C_f(s)G(s)C(s)}{1 + G(s)C(s)} \\ &= \frac{K_i \cdot K}{\tau \cdot s^3 + (1 + K_d \cdot K)s^2 + K_p \cdot K \cdot s + K_i \cdot K} \end{aligned} \quad (14)$$

ETB 시스템의 파라미터 K 및 τ 를 심층 신경망을 이용하여 추정하고, 이어서 추정된 파라미터에 따라 제어기 이득값이 자동 조정되는 PID 제어기 이득값 $K_p(\tau, K)$, $K_i(\tau, K)$, $K_d(\tau, K)$ 를 설계한다.

2. Parameter Estimation Using Neural Network

식 (10)의 스로틀 바디 시스템의 파라미터 K 및 τ 를 신경 회로망을 이용하여 추정한다. 시스템 응답 성능인 상승시간(t_r), 오버슈트(p_o), 정착시간(t_s)을 특성값으로 사용하여 퍼셉트론을 학습한다.

2.1 Training Data Set Construction

설계 대상 시스템 변화 및 부하용량 변화로 인하여 스로틀 바디 시스템인 식 (10)의 τ 및 K 가 다양하게 변하는 경우에 대하여, PID 제어기로 연결된 식 (14)의 응답특성인 상승시간, 오버슈트, 정착시간을 측정한다. K 및 τ 가 증가 및 감소하는 다양한 경우에 대하여 응답특성 데이터 세트를 구축한다. 대상 시스템은 다음 식의 범위 안에서 변한다고 가정하였다.

$$\begin{aligned} 0.6\tau &< \tau < 2.0\tau \\ 0.4 \cdot K &< K < 2.0 \cdot K \end{aligned} \quad (15)$$

위 식으로부터 훈련 데이터 셋 구축은 (τ, K)의 값을 다양하게 변화시키면서 식 (14)의 페루프 시스템의 시간응답 특성인 상승시간(t_r), 오버슈트(p_o), 정착시간(t_s)을 측정한다. 이때 제어기 이득값(K_p, K_i, K_d)은 $\tau = 1.0\tau$ 및 $K = 1.0K$ 인 공칭시스템에 대하여 ITAE 기법으로 최적 설계된 제어기이다. 이렇게 모아진 훈련 데이터셋의 상승시간, 오버슈트, 정착시간은 훈련데이터의 특성값이 되며, τ 및 K 은 훈련데이터의 레이블(target)이 된다. 본 논문에서 사용된 데이터 셋은 (τ, K)의 값을 10%씩 증가 및 감소 시키면서 식 (15)의 범위 내에서 데이터 셋을 구축하였다. 이 경우 데이터셋은 3개의 특성값을 갖는 256개($15 \times 17 = 256$)의 샘플 데이터를 갖는다.

2.2 Deep Neural Network Training

다층 퍼셉트론으로 신경 회로망을 설계하고 학습하는 단계는 다음과 같다.

(i) **훈련데이터 구축** : 시스템 응답 특성값(t_r, p_o, t_s)과 목표값(K, τ)의 상관 데이터를 시뮬레이션 또는 실험을 통하여 수집하여 훈련 데이터셋을 구축한다.

(ii) **다층 퍼셉트론 설계** : 다층 퍼셉트론을 이용하여 심층 신경 회로망을 설계한다. 본 연구에서는 입력노드, 은닉계층 I, 은닉계층 II, 출력계층으로 설계한다. 각 계층의 노드수는 입력 노드는 3개, 은닉계층 I은 100개, 은닉계층 II는 100개, 출력계층은 2개로 선택한다. 활성화 함수는 ReLU함수를 사용한다.

(iii) (연결 강도) : 초기값은 랜덤으로 생성한다.

(iv) (순전파 수행) : 순전파를 통하여 각 노드에서의 출력값과 활성화 미분값을 계산한다.

(v) (출력오차 계산) : 출력 노드에서의 오차 E 의 미분값과 활성화 함수 미분값을 계산한다.

(vi) (역전파 수행) : 역전파 과정을 통하여 각 노드간의 연결 강도를 수정 보완한다. 이때 순전파를 통하여 계산된 각 노드에서의 오차 미분값과 활성화 미분값을 사용한다.

(vii) (수행 반복) : (iv)~(vi) 단계를 샘플 데이터 수만큼 반복 수행하여 연결강도를 보완하며, 일정 횟수(50번 등)의 에폭(epoch)을 수행하여 연결 강도를 확정한다. 또한 전체 출력 오차를 출력하여 학습이 올바른지를 평가한다.

(viii) (파라미터 K, τ 예측) : 최종 훈련된 (ii) 단계 인공 신경망 구조에 대하여, 입력데이터를 받아 (iv) 단계의 순전파 수행을 통하여 파라미터를 예측한다.

표 1과 같은 파라미터를 갖는 ETB 시스템의 훈련데이터를 통한 학습을 진행한다. 학습 진행에 따른 출력 오차를 나타내면 아래 그림 2와 같다. 학습이 진행될수록 에폭 단계마다 출력 오차값이 작아짐을 알 수 있다.




Fig. 2. Output error via learning step.

2.3 Parameter Estimation Using Neural Network

훈련된 심층 신경망에 응답 특성인 상승시간, 오버슈트, 정착시간을 입력으로 인가하여 스톨 바디 시스템의 파라미터 K 및 τ 를 추정한다. 표2는 스톨 바디 시스템의 파라미터 τ 가 변할 때, 심층 신경망을 통하여 추정한 $\hat{\tau}$ 값의 일부를 표로 나타내었다. 심층 신경망은 ETB 시스템의 파라미터를 잘 추정함을 알 수 있다.

표 2로부터 파라미터 추정값은 실제 파라미터를 10%씩 증가 및 감소 시키면서 데이터셋(256개 샘플데이터)을 구축하여도 파라미터 값은 잘 추정되었다. 대상 시스템의 동작 환경에 따라 파라미터값을 5%씩 더 조밀한 간격으로 변화시키면서 데이터 셋을 구축(1,020개 샘플데이터)하여 파라미터 값을 추정할 수도 있다. 이 경우 훈련데이터 셋의 크기는 크게 증가한다.

Table 2. Parameter estimation of neural network.

Parameter variation	Parameter value(τ)	Estimated parameter value($\hat{\tau}$)
$0.8 \cdot \tau$	0.12728	0.18461692
$0.9 \cdot \tau$	0.14319	0.19573302
$1.0 \cdot \tau$	0.1591	0.21301885
$1.1 \cdot \tau$	0.17501	0.22733987
$1.2 \cdot \tau$	0.19092	0.23995132
$1.3 \cdot \tau$	0.20683	0.25173991
$1.4 \cdot \tau$	0.22274	0.2624269
$1.5 \cdot \tau$	0.23865	0.27251829
$1.6 \cdot \tau$	0.25456	0.28244517
$1.7 \cdot \tau$	0.27047	0.29097969
$1.8 \cdot \tau$	0.28638	0.2997479
$1.9 \cdot \tau$	0.30229	0.30726031
$2.0 \cdot \tau$	0.31820	0.3141586

3. Parameter Dependent Controller Design

식 (14)로 표현되는 ETB 페루프 시스템이 계단 입력에 대해 식 (9)와 같은 절대오차-시간-곱적분(ITAE)에 최적이 되기 위해서는 식 (14)의 특성방정식은 다음 식을 만족하도록 제어기 이득값을 찾아야 한다.^[17]

$$s^3 + 1.75w_n s^2 + 2.15w_n^2 s + w_n^3 \quad (16)$$

따라서 ETB 시스템의 파라미터 K 및 τ 가 변한다면 제어기는 (식) 16을 만족하도록 이득값이 변하게 설계되어야 한다. ITAE 규칙에 따르면 식 (16)의 3차계 시스템의 정규화된 정정시간은 14초이므로, $w_n \cdot t_s = 14$ 이다. 정정시간을 1.0초 이내로 하기 위하여 $t_s = 1.0$ 로 두면 $w_n = 14$ rad/s 가 된다. 따라서 식 (14)가 (16)의 표준형이 되기 위해서는 아래 식을 만족해야 한다.

$$\frac{1 + K_d K}{\tau} = 1.75w_n = 24.5$$

$$\frac{K_p K}{\tau} = 2.15w_n^2 = 421.4 \quad (17)$$

$$\frac{K_i K}{\tau} = w_n^3 = 2,744.0$$

식 (17)로부터 PID 제어기의 이득값은 다음과 같다.

$$K_p = 421.4 \tau / K$$

$$K_i = 2,744 \tau / K \quad (18)$$

$$K_d = (24.5 \tau - 1) / K$$

식 (18)로부터 심층 신경망을 통하여 시스템 파라미터 K 및 τ 가 예측이 되면, PID 제어기의 이득값은 시스템 파

라미터에 따라 자동 조정되는 파라미터 종속제어기임을 알 수 있다. 따라서 설계대상인 스로틀 바디 시스템의 부하용량의 변화에 따라 시스템의 파라미터 변화가 생기면 식 (18)의 제어기는 스스로 자동 조정되어 페루프 시스템의 ITAE 성능이 최소가 되도록 하는 제어기이다.

4. Feedforward Controller Design Using Torque Estimation

식 (5)의 마찰 토크는 ETB 평면의 각속도에 비례하는 비선형 식으로 나타나고, 식 (6)의 복귀 스프링 토크 추정치는 ETB 평면의 각도에 따라 변하는 비선형 식으로 나타나므로 추정기는 아래 식과 같다.

$$\widehat{T}_{fr}(w_p) = K_{fr} \cdot \tan^{-1}(w_p) \quad (19)$$

$$\widehat{T}_{sp}(\theta) = K_{sp}(\theta - \theta_0) + D_d \cdot \text{sign}(\theta - \theta_0) \quad (20)$$

식 (19) 및 (20)의 추정기는 칼만 필터를 이용한 바이어스 분리 추정기를 통하여 설계할 수 있다. 본 연구에서는 ETB 시스템의 각속도 및 각도를 이용하여 마찰 토크 \widehat{T}_f 및 \widehat{T}_{sp} 를 추정한다. 식 (19) 및 (20)으로부터 전체 토크 추정치는 아래 식과 같다.

$$\widehat{T}_f = \widehat{T}_{fr} + \widehat{T}_{sp} \quad (21)$$

식 (21)과 같은 비선형 토크가 추정되면, 이 추정치를 이용하여 실제 바이어스에 해당하는 마찰토크 및 스프링 복원 토크를 상쇄시켜 줄 수 있을 만큼의 역 토크가 발생 되도록 피드 포워드 제어 입력을 인가한다. 피드 포워드 제어기는 그림 1과 같이 토크 추정치에 상수이득 F를 곱한 값이 제어 입력으로 작동하는 구조이다. 피드 포워드 제어기 이득값은 다음식과 같이 결정하였다.

$$F = \frac{R_a}{K_t} \quad (22)$$


IV. Simulation Results and Analysis

본 논문에서는 설계된 제어기의 성능을 확인하기 위하여 시뮬레이션을 수행한다. 표 1에서 주어진 스로틀 바디 시스템의 매개변수를 이용하여, 심층 신경망을 이용한 파라미터 추정기와 추정된 파라미터에 동조되어 자동 조정되는 파라미터 종속 PID 제어기를 결합한 페루프 시스템의 응답 특성을 나타낸다.


1. Simulation Result for Parameter Variation

1.1 Simulation Results of Fixed PID Controller


그림 3은 제어기의 이득값이 고정된 PID 제어기를 사용할 경우의 단위 계단 함수 입력에 대한 스로틀 평면의 응답 특성을 나타내고 있다(PID controller). (a)는 파라미터 변동이 없는 경우, (b)는 파라미터 변동 값이 50% 증가한 경우, (c)는 파라미터 변동 값이 80% 증가한 경우에 대한 응답 특성을 나타낸다. 파라미터 변동이 없을 경우에는 정정 시간 1초 및 오버슈트 5% 이내의 사양을 만족했지만, 파라미터 변동이 80% 발생한 경우에는 정정시간 1.5초 이내 및 오버슈트 10%의 사양도 만족하지 못함을 알 수 있다.



(a) No Parameter variation



(b) Parameter Variation Increased by 50%




(c) Parameter Variation Increased by 80%

Fig. 3. Time response for PID controller


1.2 Simulation Results of Deep Learning-based Parameter Dependent PID Controller

아래 그림 4는 심층 신경망의 파라미터 추정기법과 파라미터 종속 PID 제어기를 결합 사용했을 경우의 단위 계단 함수 입력에 대한 스로틀 바디의 응답 특성을 나타내고 있다(DN-PID controller). (a)는 파라미터 변동이 없는 경우의 응답을 나타내고 (b)는 파라미터 변동 값이 50% 증가한 경우이고 (c)는 파라미터 변동 값이 80% 증가한 경우의 응답 특성을 나타낸다. 파라미터 변동이 생긴 경우에


도 정정시간 1초 및 오버슈트 5% 이하의 사양을 만족함을 알 수 있다.



(a) No Parameter variation



(b) Parameter Variation Increased by 50%



(c) Parameter Variation Increased by 80%

Fig. 4. Time response of DN-PID controller


2. Simulation Result for ETB with Parameter Variation and Nonlinear Torque

본 절에서는 파라미터 변이를 갖는 ETB 시스템에 식 (5)~(6)과 같은 부하토크가 작용했을 경우의 시간 응답 시뮬레이션 결과를 나타낸다. 4초 주기로 20도 크기의 구형 파 명령에 대한 응답 결과를 나타낸다. 비선형 토크를 추정하여 피드 포워드 제어를 사용할 경우와 사용하지 않을 경우에 대한 응답 결과를 나타낸다.


2.1 Simulation Results of Controller without Feed-forward

먼저 피드 포워드 제어가 없는 경우의 딥러닝 기반 파라미터 종속 PID 제어기의 페루프 시스템의 응답 특성을 나타낸다(NFF-PID controller). 파라미터 변동이 있는 경우와 없는 경우 모두 정정시간 2초 및 오버슈트 15% 이하의 사양을 만족하지 못함을 알 수 있다. 이의 결과는 ETB 시스템을 파라미터 변이만 있고 비선형 토크가 없는 시스


템으로 두고 제어를 설계한 결과이다. 이는 ETB를 선형 시스템으로 모델링하여 설계한 선형 제어가 비선형 외란 토크 감쇄를 감당할 수 없을 만큼 크게 작용한 현상으로 해석할 수 있다.



(a) No Parameter variation



(b) Parameter Variation Increased by 50%



(c) Parameter Variation Increased by 80%


Fig. 5. Time response of NFF-PID controller

2.2 Simulation Results of Controller with Feed-forward


- 고정 PID 제어기

피드 포워드 제어를 사용하고 되먹임 제어기로 고정 PID 제어를 사용할 경우의 페루프 시스템의 응답 특성을 나타낸다(FF-PID controller). 파라미터 변동이 없는 경우는 정정시간 1초 및 오버슈트 5% 이하의 사양을 만족하지만, 파라미터 변동이 있을 경우는 정정시간 2초 및 오버슈트 15% 이하의 사양을 만족하지 못함을 알 수 있다.


이의 결과는 ETB 시스템의 비선형 토크를 추정하여 피드포워드 제어가 마찰 토크를 상쇄시켜 줄 수 있을 만큼의 역토크가 생성되도록 제어입력을 발생하므로써 나타난 결과이다. 하지만 파라미터가 변이가 생겼을 경우에는 파라미터 고정 제어기는 변이된 시스템에 대한 최적의 제어가 아니기 때문에 나타나는 현상으로 해석할 수 있다.




(a) No Parameter variation




(b) Parameter Variation Increased by 50%



(b) Parameter Variation Increased by 50%



(c) Parameter Variation Increased by 80%




(c) Parameter Variation Increased by 80%

Fig. 6. Time response with FF-PID controller

- 딥러닝 기반 파라미터 종속 PID 제어기

피드 포워드 제어기뿐만 아니라 되먹임 제어기로 딥러닝 기반 파라미터 종속 PID 제어기를 사용할 경우의 페루프 시스템의 응답 특성을 나타낸다(FF-DN-PID controller). 파라미터 변동이 없는 경우는 정정시간 1초 및 오버슈트 5% 이하의 사양을 만족하였으며, 파라미터 변동 50%가 있는 경우에는 정정시간 1초 및 오버슈트 10% 이하의 사양을 만족하였다. 또한 파라미터 변동 80%가 있는 경우에는 정정시간 1초 및 오버슈트 15% 이하의 사양을 만족하였다. 피드포워드 제어기를 사용한 딥러닝 기반 파라미터 종속 제어기는 시스템 성능을 개선함을 알 수 있다. 이의 결과는 ETB 시스템의 비선형 토크에 대한 영향뿐만 아니라 파라미터가 변이에 대한 영향을 고려하기 위하여 피드포워드 제어기와 파라미터를 추정하여 파라미터 종속적인 제어기를 사용한 결과로 해석할 수 있다.



(a) No Parameter variation

Fig. 7. Time response with FF-DN-PID controller

V. Conclusions

본 논문에서는 파라미터 변이 및 비선형 토크를 갖는 전자식 스로틀 바디 시스템(ETB)에 대한 딥러닝 기반의 파라미터 종속 PID 제어기 설계 방법을 나타내었다. 외부 부하의 변동에 의하여 변화된 ETB 시스템의 시불변 파라미터 값을 추정하기 위하여 심층 신경망을 이용하여 추정기를 설계하였다. 신경망 노드 간의 연결 강도 학습을 위하여 ETB 시스템의 시간응답 특성을 특성값으로 하여 학습하였다. 또한 추정된 파라미터에 동조되어 자동 조정되는 파라미터 종속 PID 제어기를 설계하였으며, PID 제어기의 최적 이득값은 ITAE 판별법에 의하여 찾았다. 비선형 토크의 영향을 감쇄하기 위하여 비선형 토크값을 추정하고, 추정된 비선형 토크값을 상쇄시켜 줄 피드 포워드 제어기를 추가적으로 설계하였다. 설계된 제어기의 제어 성능을 나타내기 위하여, 시뮬레이션을 통한 ETB 시스템의 제어 성능 결과를 나타내었다. 일반 PID 제어기와 딥러닝 기반의 파라미터 종속 PID 제어기에 대하여 제어 성능을 비교 평가하였으며, 딥러닝 기반의 파라미터 종속 PID 제어기는 일반 PID 제어기보다 부하 변동에 따른 파라미터 변화에 우수한 제어 성능을 나타냄을 알 수 있었다.

본 연구 결과가 실제 자동차 스로틀 바디 시스템에 적용될 때의 한계점과 향후 연구 방향은 다음과 같다. 비선형 토크의 영향을 고려하기 위하여 비선형 토크값을 시스템의 각 속도 및 각도 정보를 이용하여 모델링 수식으로부터 바로 추정하였으나, 만일 비선형 토크의 모델링 수식이 정확하지 않을 경우 성능 저하가 예상된다. 또한 본 연구에서 설계한 제어기는 비선형 부하토크를 외란으로 처리하고, 시불변 파

라미터 변이를 갖는 선형시스템에 대한 ITAE 성능 최적인 파라미터 종속제어기를 설계하였다. 만일 비선형 부하토크의 영향이 너무 크게 작용할 경우에는 비선형 부하토크의 변화를 파라미터 변이를 갖는 선형 시스템에 적절히 포함하고, 이 시스템에 최적인 파라미터 종속 제어기를 설계하는 것이 더 좋을 것으로 생각된다. 따라서 이에 대한 향후 연구가 필요하며, 또한 비선형 토크 값을 딥러닝을 이용하여 온라인으로 추정하고 이를 이용하는 제어기 설계 방법도 앞으로 필요한 연구 방향이라고 생각된다.

REFERENCES

- [1] H. T. Dorissen and K. Dürkopp, "Mechatronics and Drive-by-Wire Systems Advanced Non-contacting Position Sensors," *Control Engineering Practice*, Vol. 11, No. 2, pp. 191-197, Feb. 2003. DOI: 10.1016/S0967-0661(02)00146-6
- [2] C. Rossi, A. Tilli and A. Tonielli "Robust Control of a Throttle Body for Drive by Wire Operation of Automotive Engines," *IEEE Trans. on Control Systems Technology*, Vol. 8, No. 6, pp. 993-1002 Nov. 2000. DOI: 10.1109 /87.880604.
- [3] Y. J. Kim, A Fault-tolerant Throttle Valve Using Sliding Mode Control, M. S. Thesis, Kyungpook National University, 2009.
- [4] S. T. Jin, J. J. Kang and W. T. Lee, "Electronic Throttle Body Model Allowing for Non-linearity of DC Motor Driver," *Trans. of KSAE*, Vol. 16, No. 1, pp. 71-77, Feb. 2008.
- [5] U. Ozguner, S. Hong and Y. Pan, "Discrete-time Sliding Mode Control of Electronic Throttle Valve," *Proc. of the 40th IEEE Conf. Decision and Control*, pp. 1819-1824, 2001. DOI: 10.1109/CDC.2001.981169.
- [6] I. S. Yangg, M.G. Song and D. I. Lee, "Nonlinear Dynamic Inversion Based Control for Electronic Throttle" *Transaction of KSAE*. vol 20. No. 2, pp. 8-14, March 2012. DOI: 10.7467/KSAE.2012.20.2.008.
- [7] J. Georgie and J. Valasek, "Evaluation of Longitudinal Desired Dynamics for Dynamic-inversion Controlled Generic Reentry Vehicles," *J. Guid. Cont. Dyna*. Vol. 26, No. 5, pp. 811-819, Sept. 2003. DOI: 10.2514/2.5116
- [8] H. Zhang, L. Xie, Y. C. Soh and W. Wang "Optimal and self-tuning State estimation for singular stochastic systems: a polynomial equation approach" *IEEE Trans. on Circuits and Systems*, Vol. 51, No. 6, pp. 327-333, June. 2004. DOI: 10.1109/TCSII.2004.829573
- [9] C. S. Jeon, D. S. Kim and J. M. Lee "PID Gain Auto Tuning of ETB by using RLS" *The Journal of Korea Robotics Society*, Vol. 2, No. 1, pp. 1-8, March 2007.
- [10] M. Baric, I. Petrovic and N. Peric, "Neural network-based sliding mode control of electronic throttle," *Eng. Appl. of Artifi. Intell*. Vol. 18, No. 8, pp. 951-961, Dec. 2005. DOI: 10.1016/j.engappai.2005.03.008
- [11] D. V. Prokhorov, "Training Recurrent Neurocontrollers for Real-Time Applications," *IEEE Trans. on Neural Networks*. Vol. 18 No. 4, pp. 1003-1015, July 2007. DOI: 10.1109/TNN.2007.899521
- [12] X. Yuan and Y. Wang, "Neural networks based self-learning PID control of electronic throttle," *Nonlinear Dynamics*, Vol. 55, No. 4, pp 385-393, June 2008.
- [13] X. R. Hernández-Alvarado, L. G. García-Valdovinos, T. Salgado-Jiménez, A.Gómez-Espinosa and F. Fonseca-Navarro, "Neural Network-Based Self-Tuning PID Control for Underwater Vehicles". *Sensors*, Vol 16, No. 9, pp. 1429. Sept. 2016. DOI: 10.3390/s16091429
- [14] S. Bari, S. S. Z. Hamdani, H. U. Khan, M. ur Rehman and K. Haroon, "Artificial Neural Network Based Self-Tuned PID Controller for Flight Control of Quadcopter," *2019 International Conference on Engineering and Emerging Technologies*, pp. 1-5, 2019.
- [15] A. Mohammadi and J.C. Ryu, "Neural network-based PID compensation for nonlinear systems: ball-on-plate example," *Int. J. of Dynamics and Control*, Vol. 8, pp. 178-188, Mar. 2020. DOI: 10.1007/s40435-018-0480-5
- [16] R. Conatser, J. Wagner, S. Ganta and J. Walker, "Diagnosis of automotive electronic throttle control systems," *Control Engineering Practice*, Vol. 12, No. 1, pp. 23-30, Jan. 2004. DOI: 10.1016/S0967-0661(02)00281-2
- [17] Richard C. Dorf and Robert H. Bishop, "*Modern Control Systems*" Pearson press, pp. 254-263, 2017.

Authors



Kap Rai Lee received the B.S., M.S. and Ph.D. degrees in Electronics Engineering from Kyungpook National University, Korea, in 1987, 1990 and 1999, respectively. Dr. Lee joined the faculty of the Department of

Information & Communication at Pyeongtaek University, Pyeongtaek, Korea, in 2001. He is currently a Professor in the Department of Smart Mobility, Pyeongtaek University. He is interested in deep learning-based control, autonomous vehicle control and embedded system design.