논문 2011-48IE-2-4

차량 연료 소모량 예측을 위한 신경회로망 기반 모델링

(Neural Network-Based Modeling for Fuel Consumption Prediction of Vehicle)

이 민 구*, 정 경 권*, 이 상 회**

(Min Goo Lee, Kyung Kwon Jung, and Sang-Hoi Yi)

요 약

본 논문에서는 연료 소모량을 예측하기 위해 차량 데이터를 이용한 신경회로망 모델링 방식을 제안하였다. 제안한 신경회로망의 훈련과 시험 데이터를 획득하기 위해 시내를 중형 가솔린 차량을 주행하였고, OBD-II 포트에서 입력 데이터로 속도, 엔진 RPM, 쓰로틀 위치 센서(TPS), 흡기 공기량(MAF)을 측정하였고, 목표값으로 연료 소모량을 측정하였다. 입력과 출력 데이터의 빈선형 맵핑을 위해 다층 퍼셉트론 네트워크를 사용하였다. 신경회로망 모델은 평균 제곱오차가 1.306×10^{-6}로 연료 소모량을 매우 잘 예측함을 확인하였다.

Abstract

This paper presented neural network modeling method using vehicle data to predict fuel consumption. To acquire data for training and testing the proposed neural network, medium-class gasoline vehicle drove at downtown and parameters measured include speed, engine rpm, throttle position sensor (TPS), and mass air flow (MAF) as input data, and fuel consumption as target data from OBD-II port. Multi layer perception network was used for nonlinear mapping between the input and the output data. It was observed that the neural network model can predict the vehicle quite well with mean squared error was 1.306×10^{-6} for the fuel consumption.

Keywords : fuel consumption, neural network, OBD-II, RPM, TPS, MAF

Ⅰ. 서 론

차량정보를 운전자에게 실시간으로 제공해줌으로 운전을 더욱 효율적으로 유도할 수 있는 시스템에 대한 연구는 지속적으로 수행되고 있다. 이때 관련된 해당 차량정보로는 주행거리, 주행속도, 주행시간, 연료소모량, 주행연비, 연료비용, 탄소배출량 등 다양한 값들이 그 대상으로 더욱 확장되고 있다. 이러한 차량정보를 제공하기 위해서는 차량 내부의 엔진 데이터가 필요하다. 현재 차량에서는 OBD-II(On Board Dignosis) 포트를 통해 차량의 진단 상태를 접근할 수 있다. OBD-II는 MIL(Malfunction Indicator Lamp)이라고 하는 안내 표시등을 통해서 차량의 문제를 사용자나 정비사에게 보여 주는 기능을 한다. 이 램프가 들어오면, 사용자는 차량에 이상이 있다는 것을 알게 되고, 정비사에게 가서 문제를 해결 하는데 기본적인 목적을 두고 있다. 내부적으로는 문제점에 대한 자체 진단한 결과를 저장해 두어서 정비사가 문제 해결을 하기 위한 세부 기술정보를 전달해 주는 기능을 가지고 있다. 운전자가 차량을 운행할 때, OBD-II 장치는 지속적으로 차량의 상태를 감시하게 되어 있다[1~3].

본 논문에서는 OBD-II로부터 차량의 속도, RPM,

* 정회원, 전자부품연구원
(Korea Electronics Technology Institute)
** 평생회원, 동서울대학 디지털전자과
(Dept. of Digital Electronics, Dong Seoul College)
※ 본 연구는 2011년도 지식경제부의 재원으로 지식경제 기술혁신사업(국가플랫폼기술개발사업)의 지원을 받아 수행한 연구 과제입니다. (No. 10033847)
접수일자: 2011년4월26일, 수정완료일: 2011년6월15일

TPS(Throttle Position Sensor), MAF(Mass Air Flow) 정보를 획득하고, 신경회로망을 이용하여 연료 소모량을 추정하는 방법을 제안한다. 테스트 차량을 이용하여 제안한 방법으로 연료 소모량을 계산하고, 전문 업체의 지원으로 실제 엔진에서 분사되는 연료 분사량과 비교·검토한다.

Ⅱ. 차량 OBD-II 정보

캘리포니아 대기 자원국(CARB)은 LA유역의 심각한 대기 문제에 대한 대응책으로 1966년도 차량 모델부터 배기가스 제어 시스템 장착을 의무화 했으며, 1968년에 미국 전역으로 확대하였다. 이후 1970년에 미국 의회가 대기오염방지법을 제정하였고, 미국 환경보호국(EPA)을 설립하여 법적인 기반과 함께 OBD(On Board Diagnostics)가 EPA의 법적인 규정을 감시할 수 있는 수단으로 인식하게 되었다. 하지만 차량 자체 진단 기능인 OBD에 대한 기술적 표준이 없었고, CARB에서 OBD1 표준이라 불리는 요구사항을 내 놓았지만 기술적인 표준은 정하지 못하였다.

커넥터는 하나로 통일되어 있으며 DLC(Diagnostic Link Connector)라 불리는 이 커넥터는 총 16개의 핀으로 구성되며 실제 9개의 핀들이 사용된다. 일반적으로 운전석 왼편 아래 부분 또는 중앙 재떨이 아래 부분에 위치하고 있으며 한국에서 2000년 이후에 생산된 차들은 대부분 OBD-II를 지원한다[4].

OBD-II PID(Parameter ID)는 진단장치 등을 통해 차량에 정보를 요청할 때 사용되는 코드로 SAE Standard J/1979를 따르며 OBD-II PID는 10개의 모드를 가지고 있다.

본 논문에서 사용한 PID는 모드 01로 진단정보를 이용하였으며 세부 PID는 표 1과 같다. 차량의 OBD-II 정보는 Mode와 PID를 이용하여 접근이 가능하다[5].

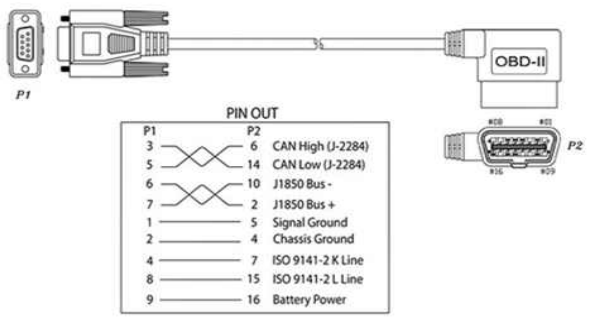

그림 1. OBD-II 커넥터
Fig. 1. OBD-II connector.

표 1. OBD-II의 PID 예
Table 1. Example of OBD-II PIDs.

Mode (hex)	PID (hex)	Data bytes returned	Description	Units	Formula
01	0C	2	Engine RPM	rpm	((A*256)+B)/4
01	0D	1	Vehicle speed	km/h	A
01	10	2	MAF air flow rate	g/s	((256*A)+B)/100
01	11	1	Throttle position	%	A*100/255

본 논문에서는 연료 소모량과 연관이 되는 엔진 RPM, 차량 속도, TPS(악셀레이터 정도), MAF(공연비, 공기와 연료의 혼합율)을 이용한다.

Ⅲ. 신경회로망

1957년 Rosenblatt에 의해 최초의 신경회로망 모델인 단층 퍼셉트론이 발표된 신경회로망은 인간의 뇌구조의 모델에 기반을 두고 제안되어 패턴 인식이나 제어 등 많은 분야에서 응용되고 있다. 신경회로망의 장점은 제어될 플랜트나 그 환경 모델이 필요하지 않고, 불확실성이나 플랜트의 환경의 변화에 적응이 가능하고, 학습에 의한 성능 개선이 가능하다. 또한 신경회로망의 병렬 계산에 의한 고속 실시간 제어가 가능하다는 것이다.

역전파 신경회로망(back-propagation neural network)은 선형 뉴런의 입력층과 출력층 사이에 하나 이상의 중간층, 즉 비선형 뉴런으로 구성된 은닉층을 갖는 다층 구조의 회로망이다. 입력층의 입력신호들은 은닉층의 뉴런을 거쳐 출력층으로 전달되는 전방향 회로망이다. 출력층의 출력신호는 신경회로망이 추종하고자 하는 목표 출력신호와 비교되어 오차신호를 발생하고, 이 오차의 제곱을 최소화하도록 출력층으로부터 은닉층을 거쳐 입력층으로 역전파되어 연결강도를 조정한다[6].

역전파 학습 알고리즘은 연결 강도 공간상에 주어지는 오차의 제곱을 높이로 하는 곡면에 대하여 오차의 제곱이 가장 많이 감소하는 방향으로 연결강도를 조정하는 gradient descent 법을 사용한다.

다층 신경회로망의 구조는 그림 2와 같다.

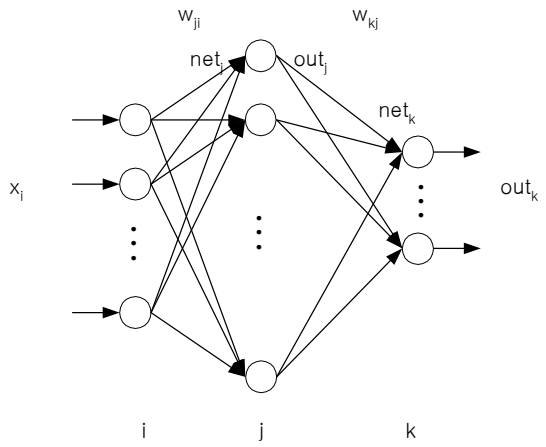

그림 2. 다층 신경회로망
Fig. 2. Multi-layered neural networks.

은닉층 각 뉴런의 입력으로 가해지는 가중합을 각각 net_j이라 정의한다.

$$net_j = \sum_{i=1}^{n} w_{ji} \cdot x_i \tag{1}$$

이 뉴런의 입력은 일반적으로 비선형 함수($f(\cdot)$)를 통과하여 뉴런의 출력이 된다.

은닉층 뉴런의 출력은 식(2)와 같다.

$$out_j = f(net_j) \tag{2}$$

사용하는 함수 $f(\cdot)$는 미분이 가능한 시그모이드(sigmoid) 함수 또는 선형 함수를 사용한다.

$$f(net) = \frac{2}{1+e^{-net}} - 1 \tag{3}$$

출력층 뉴런의 입력신호를 net_k라 하면

$$net_k = \sum_{j=1}^{m} w_{kj} \cdot out_j \tag{4}$$

이다. 출력층 뉴런의 출력 out_k는

$$out_k = f(net_k) \tag{5}$$

로 되고, 이것이 바로 신경회로망의 출력이 된다.

역전파 신경회로망은 전방향 신경회로망의 출력 out_k가 목표값 d_k를 학습하기 위하여 out_k와 d_k 사이의 오차가 최소화되도록 gradient descent법에 의해 출력층에서 은닉층, 은닉층에서 입력층으로 오차를 역전파하면서 연결강도를 조정한다.

신경회로망이 학습하기 위한 목적함수(object function)는 식(6)과 같다.

$$E = \frac{1}{2} \sum_{k=1}^{l} [d_k - out_k]^2 \tag{6}$$

이 목적함수 E가 w_{kj}, w_{ji}에 대하여 최소화되도록 gradient descent 법을 적용한다.

은닉층과 출력층 사이의 연결강도 w_{kj}의 조정은 식(7)과 같다.

$$w_{kj}(t+1) = w_{kj}(t) + \eta \cdot [d_k - out_k] \cdot f'(out_k) \cdot out_j \tag{7}$$

입력층과 은닉층 사이의 연결강도 w_{ji}에 대하여 gradient descent법을 적용하면 식(8)과 같다

$$w_{ji}(t+1) = w_{ji}(t) + \eta \sum_{k=1}^{l} [(d_k - out_k) \cdot f'(net_k) \cdot w_{kj}] \cdot f'(net_j) \cdot x_i \tag{8}$$

본 논문에서는 도로주행에서 얻어진 RPM, 차량속도, TPS, MAF 정보를 신경회로망의 입력으로 사용하고, 목표값은 실제 차량 엔진에서 분사되는 연료량을 사용한다.

Ⅳ. 실험 및 검토

가. 차량 주행 정보 획득

그림 3과 같이 OBD-II 인터페이스를 이용하여 테스트환경을 구성하였다. OBD-II 인터페이스를 통해 획득된 속도, RPM, TPS, MAF 정보를 이용하여 연료 소모량을 계산하였다.

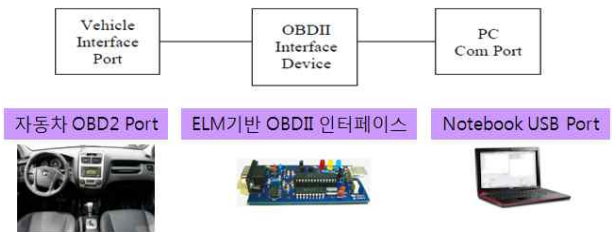

그림 3. 테스트 환경 구성
Fig. 3. Configuration of test environments.

그림 4. 주행 코스
Fig. 4. Driving course.

본 논문에서는 제네시스 330(2009연식, 자동변속, 가솔린)차량을 이용하여 그림 4와 같이 주행경로 총 5km (도심환경)를 주행하면서 차량 정보를 측정하고 연료소모량을 분석하였다.

주행에서 얻은 차량 정보는 다음과 같다.

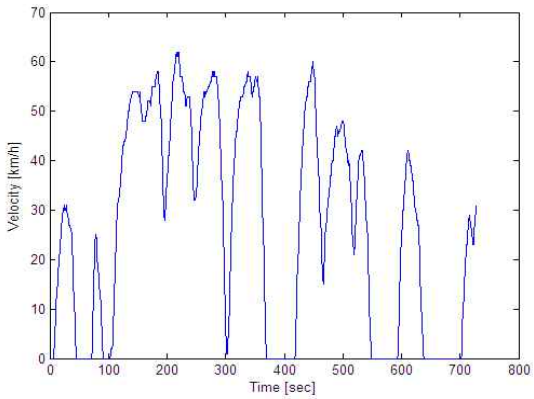

그림 5. 차량 속도
Fig. 5. Vehicle speed.

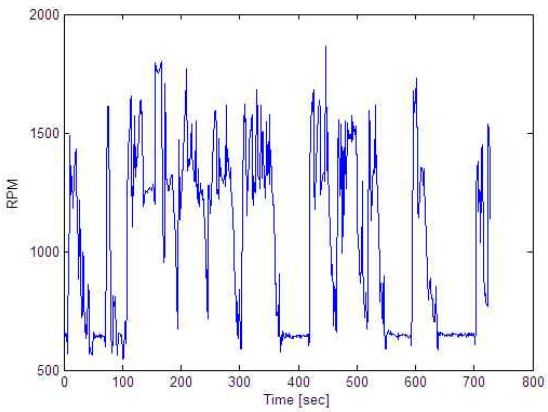

그림 6. 엔진 RPM
Fig. 6. Engine RPM.

실제 엔진 연료 분사량은 OBD-II로 측정할 수 없는 정보로, 차량 전문업체의 지원을 받아서 엔진 ECU에서 고속 CAN 방식으로 수집하였다. 이 정보는 신경회로망

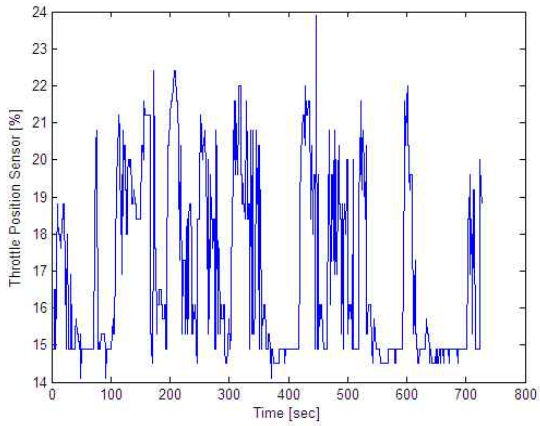

그림 7. TPS
Fig. 7. Throttle position sensor.

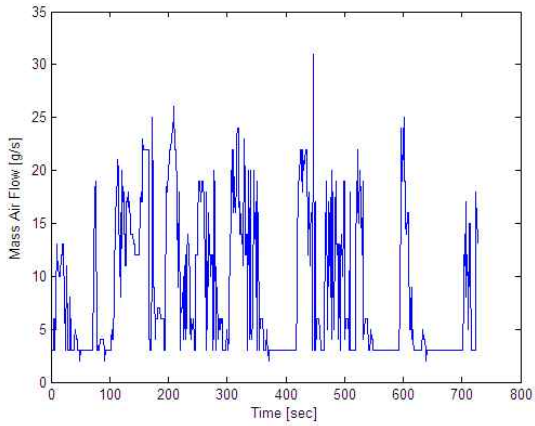

그림 8. 흡기 공기량
Fig. 8. Mass air flow.

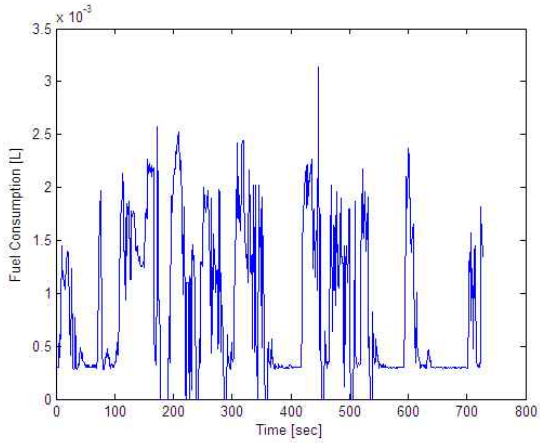

그림 9. 엔진 연료 분사량
Fig. 9. Fuel injection of engine.

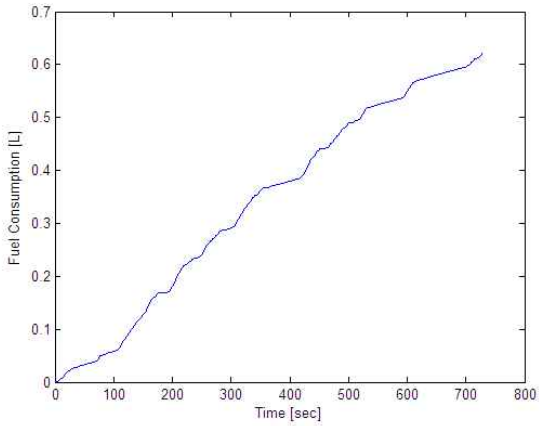

그림 10. 연료 소모량
Fig. 10. Total fuel consumption.

의 학습에서 목표값으로 활용된다. 그림 9는 실제 엔진의 연료 분사량이고, 그림 10은 이 값을 누적한 차량의 연료 소모량이다.

나. 신경회로망을 이용한 모델링

차량의 속도, RPM, TPS, MAF 정보를 이용하여 연료 소모량을 예측하기 위해 다층 신경회로망 구조를 구성한다.

표 2. 신경회로망 구성
Table 2. Configuration of neural networks.

입력층 뉴런수	4개
은닉층 뉴런수	10개
출력층 뉴런수	1개
연결강도 초기값	입력패턴의 평균값
학습률	0.1
학습회수	1000회

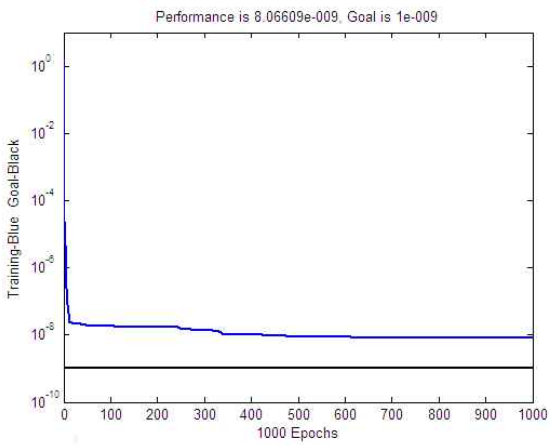

그림 11. 신경회로망 학습 성능
Fig. 11. Learning performance of neural networks.

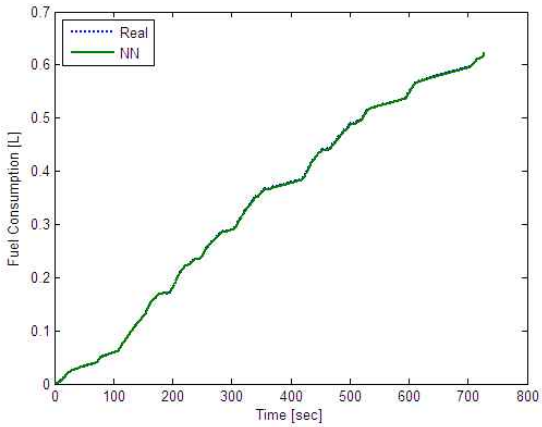

그림 12. 학습 결과
Fig. 12. Learning results.

신경회로망 구조는 표 2와 같다.

1000회 학습을 진행하면서 신경회로망의 학습 성능은 그림 11과 같이 8.066×10^{-9}으로 수렴이 되었다.

학습이 종료된 후 실제 연료 소모량과 제안한 신경회로망 방식의 연료 소모량의 결과는 그림 12와 같다.

학습 성능의 평가방법으로 목표값과 출력값의 평균제곱 오차를 계산하면 1.306×10^{-6}로 실제 연료 소모량과 신경회로망으로 모델링한 결과가 유사함을 확인할 수 있다.

다. 신경회로망 예측 모델 검증

제안한 신경회로망을 이용한 연료 소모량 예측 모델의 평가를 위해 동일한 주행경로에서 정속주행과 급가속/급감속 주행 정보를 사용하였다.

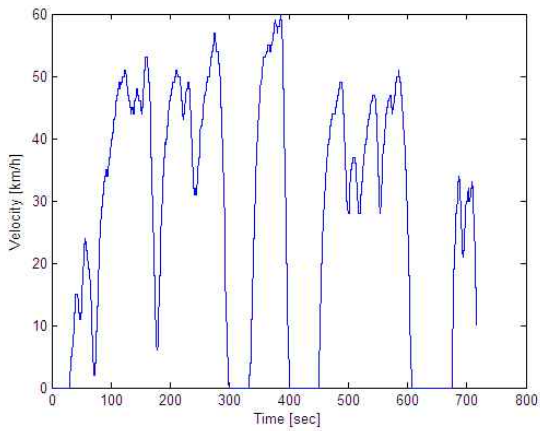

그림 13. 정속주행 차량 속도
Fig. 13. Vehicle speed of normal driving.

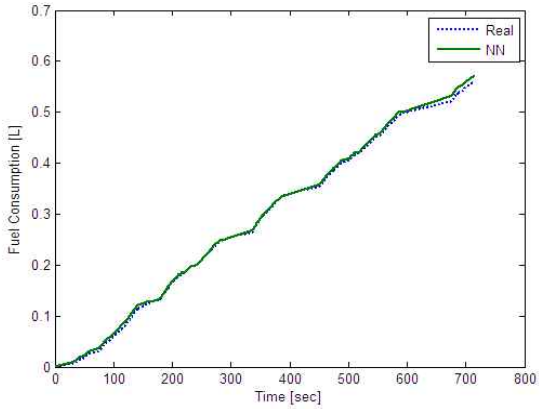

그림 14. 정속주행 예측 결과
Fig. 14. Prediction results of normal driving.

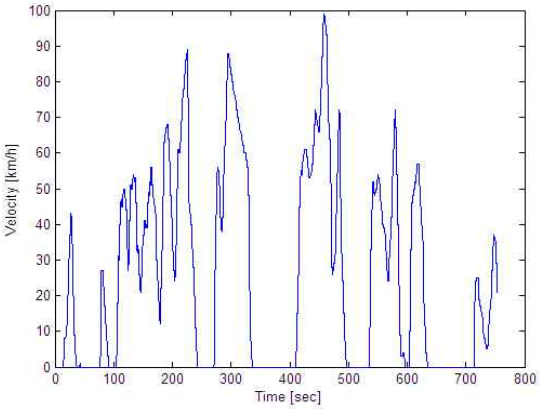

그림 15. 급가속/급감속 차량 속도
Fig. 15. Vehicle speed of rapid acceleration/deceleration driving.

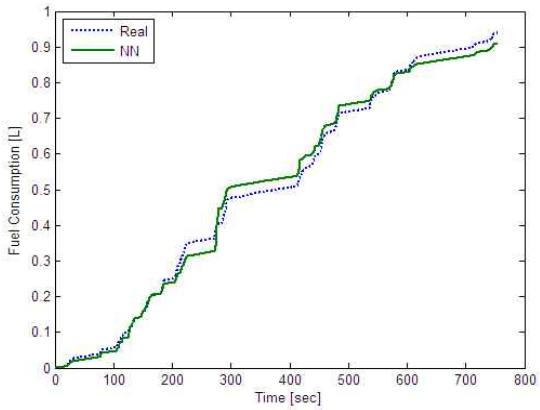

그림 16. 급가속/급감속 예측 결과
Fig. 16. Prediction results of rapid acceleration/deceleration driving.

그림 13과 같은 정속주행에서 신경회로망을 이용한 연료 소모량 예측 결과는 그림 14와 같다. 실제 연료 소모량과 예측값의 평균 제곱 오차는 1.177×10^{-4}로 측정되었다.

그림 15와 같은 급가속/급감속 주행에서는 그림 16과 같은 연료 소모량 예측 결과를 확인하였고, 실제 연료 소모량과 예측값의 평균 제곱 오차는 6.118×10^{-4}로 측정되었다.

V. 결 론

본 논문에서는 차량의 연료 소모량 예측을 위해 신경회로망을 이용한 모델링을 제안하였다. OBD-II로부터 차량의 속도, RPM, TPS(Throttle Position Sensor), MAF(Mass Air Flow) 정보를 획득하고, 실제 엔진의 연료 분사량을 목표값으로 신경회로망을 학습하고 연료 소모량을 추정하였다. 5km 도심 구간에서 제네시스 차량을 이용하여 실험 한 결과, 학습에서는 평균 제곱오차 1.306×10^{-6}의 결과를 얻었고, 정속주행과 급가속/급감속 주행의 시험에서는 1.177×10^{-4}, 6.118×10^{-4}의 결과를 확인하였다.

향후 엔진부하나 적재하중, 운전자 운전패턴 등 연료 소모량에 영향을 줄 수 있는 인자를 추가하여 정확한 연료 소모량 모델을 구성한다.

참 고 문 헌

[1] Delia Ajtay, Martin Weilenmann, "Compensation of the Exhaust Gas Transport Dynamics for Accurate Instantaneous Emission Measurements," Environ. Sci. Technol., Vol. 38, No. 19, pp. 5141-5148, 2004,
[2] Joeri Van Mierlo, Gaston Maggetto, Erik van de Burgwal Raymond Gense, "Driving style and traffic measures-influence on vehicle emissions and fuel consumption," Journal of Automobile Engineering, Vol. 218, No. 1, pp.43-50, 2004.
[3] 이민구, 정경권, 박용국, 유준재, "차량 OBD-II 데이터를 이용한 연료 소모량 추정의 수식적 모델링 및 실증 분석," 전자공학회논문지, 제48권 SC편, 제2호, 9-14쪽, 2011년 3월.
[4] Scantool, http://www.scantool.net/
[5] OBD-II, http://en.wikipedia.org/wiki/OBD-II_PIDs
[6] Martin T. Hagan, Howard B. Demuth, Mark H. Beale, Neural Network Design, Martin Hagan, 2002.

저 자 소 개

이 민 구(정회원)
2000년 서강대학교 전자공학과 학사 졸업.
2004년 서강대학교 전자공학과 석사 졸업.
2001년~현재 전자부품연구원 선임연구원 재직
<주관심분야 : 차량-IT, Green IT, 무선 센서 네트워크, 임베디드 시스템>

정 경 권(정회원)
1998년 동국대학교 전자공학과 학사 졸업.
2000년 동국대학교 전자공학과 석사 졸업.
2003년 동국대학교 전자공학과 박사 졸업.
2009년~현재 전자부품연구원 위촉연구원 재직
<주관심분야 : 차량-IT, 무선 센서 네트워크, 임베디드 시스템>

이 상 회(평생회원)
대한전자공학회 논문지
제 48권 IE편 제1호 참조