<학술논문> **DOI:10.3795/KSME-B.2010.34.8.783** ISSN 1226-4881

인공신경망을 이용한 가변 기구 터보차저의 터빈 질량유량 모델링

박영섭* · 오병걸* · 이민광* · 선우명호*†
* 한양대학교 자동차공학과

Development of Turbine Mass Flow Rate Model for Variable Geometry Turbocharger Using Artificial Neural Network

Yeongseop Park*, Byounggul Oh *, Minkwang Lee* and Myoungho Sunwoo*†
* Dept. of Automotive Engineering, Hanyang Univ.

(Received February 10, 2010 ; Revised June 24, 2010 ; Accepted June 28, 2010)

Key Words: Turbine Model(터빈 모델), Artificial Neural Network(인공신경망), Diesel Engine(디젤엔진), Variable Geometry Turbocharger(가변 기구 터보차저), Mass Flow Rate(질량 유량)

초록: 이 논문에서는 인공신경망을 이용하여 가변 기구 터보차저(VGT)의 터빈 질량유량을 추정하는 모델을 제안하고자 한다. 터빈 질량유량을 추정하기 위한 모델의 입력변수는 VGT 베인 개도량, 엔진 회전속도, 배기매니폴드 압력, 배기매니폴드 온도, 터빈 출구 압력이 사용되었으며, 터빈 입구 유효 단면적을 추정하는 부분에 인공신경망을 적용하였다. 실험을 통하여 이 논문에서 제안한 모델의 터빈 질량유량 추정 성능을 검증하였으며, 터빈 맵을 이용하여 추정한 결과와 비교를 통하여 제안한 모델의 우수성을 확인하였다.

Abstract: In this paper, we propose a turbine mass flow rate model for a variable geometry turbocharger (VGT) using an artificial neural network (ANN). The model predicts the turbine mass flow rate using the VGT vane position, engine rotational speed, exhaust manifold pressure, exhaust manifold temperature, and turbine outlet pressure. The ANN is used for the estimation of the effective flow area. In order to validate the results estimated by the proposed model, we have compared estimation results with engine experimental results. The results, in addition, represent improved estimation accuracy when compared with the performance using the turbine map.

- 기호설명 -

A : 터빈 입구 단면적 [m^2]
A_{EFA} : 터빈 입구 유효 단면적 [m^2]
C_D : 터빈 입구 유량계수
γ : 배기가스 비열비 [1.36]
$\dot{m}_a$: 흡입공기 질량유량 [kg/s]
$\dot{m}_f$: 연료 분사량 [kg/s]
$\dot{m}_t$: 터빈 질량유량 [kg/s]
$\dot{m}_{t_corr}$: 정규 터빈 질량유량 [kg/s]
$\dot{m}_{t_est}$: 추정 터빈 질량유량 [kg/s]
$\dot{m}_{t_meas}$: 측정 터빈 질량유량 [kg/s]
p_0 : 터빈 입구 압력 [Pa]
P_{cr} : 임계압력 [0.5351]
p_T : 터빈 출구 압력 [Pa]
R : 이상기체상수 [$300\,J/kg\cdot K$]
T_0 : 배기매니폴드 온도 [K]

† Corresponding Author, msunwoo@hanyang.ac.kr
© 2010 The Korean Society of Mechanical Engineers

1. 서 론

지구온난화 문제와 에너지고갈 문제에 대응하기 위하여 세계 각국에서는 차량용 내연기관에 대한 연비규제를 점차 강화하고 있다. 디젤엔진은 가솔린엔진 대비 높은 열효율에 의한 우수한 연비, 낮은 이산화탄소 배출 등의 이유로 차세대 자동차의

동력원으로 각광받고 있다. 그러나 디젤엔진의 경우 압축착화에 의한 연소특성과 높은 압축비에 의한 고속 회전에서의 마찰손실로 인하여 가솔린엔진 대비 출력이 낮고, 질소산화물(NOx)과 입자상물질(Particulate matter, PM)의 배출이 많은 단점이 있다. 이러한 단점을 보완하기 위하여 디젤엔진에서는 일반적으로 과급기를 장착하여 출력을 높이고, 배기가스재순환(Exhaust Gas Recirculation, EGR)[1,2]과 배기 후처리 기술 등을 사용하여 유해배출물을 줄이기 위한 연구[3,4]가 활발히 진행 중이다.

차량에서 사용되는 과급기는 배기가스의 에너지를 이용하는 터보차저와 엔진의 출력을 이용하는 수퍼차저가 있다. 그 중 엔진 출력 손실을 야기하지 않고 배기가스 에너지를 재활용할 수 있는 터보차저가 널리 사용되고 있다. 터보차저는 용량에 따라 운전구간별 동작 특성이 달라진다. 작은 용량의 터보차저를 사용할 경우 고속 고부하 운전에서 최대출력의 저감을 초래하는 반면 저속 운전구간에서 빠른 응답성을 확보할 수 있다. 큰 용량의 터보차저를 사용할 경우 저속 운전에서 응답성이 저감되는 반면 고속 고부하 운전에서 높은 출력을 확보할 수 있다. 근래에는 저속 운전에서의 빠른 응답성과 고속 운전에서의 높은 출력을 모두 확보하기 위하여 가변 기구 터보차저(Variable Geometry Turbocharger, VGT)를 널리 사용하고 있다.

VGT 는 터빈 입구 단면적을 변화시켜 터빈을 통과하는 배기가스 유속을 제어함으로써 저속에서의 빠른 응답과 고속에서의 높은 출력을 동시에 확보할 수 있다. 그러나 배기가스 유속 변화에 의하여 발생하는 터빈 질량유량의 변화는 배기매니폴드 압력 변화와 터빈 회전속도의 변화를 야기하게 된다. 이는 결과적으로 흡기매니폴드의 압력 및 흡입공기 질량유량의 변화를 초래하게 된다. 그리고 배기매니폴드의 압력 변화는 NOx 저감에 매우 효과적인 EGR 유량의 변화도 야기하게 된다.[5] 따라서 엔진 출력을 극대화 하고 EGR 유량을 최적으로 제어하기 위해서는 EGR 밸브 제어와 더불어 정밀한 VGT 제어가 필수적이다.

정밀한 VGT 제어를 위한 제어기 설계용 상태공간 모델의 상태변수 인자로 터빈 질량유량이 사용된다.[6~8] 뿐만 아니라 다변수 제어기의 입력변수 중 하나로 터빈 질량유량을 사용하는 연구도 선행되었다.[9] 그러나 터빈 질량유량은 배기가스의 높은 온도로 인하여 센서를 사용하여 계측하는 것이 매우 어려우므로 터빈 질량유량 맵을 이용하여 도출하거나 수학적 모델을 이용하여 추정하게 된다. 터빈 맵의 입력변수로는 VGT 베인 개도량, 터빈 양단의 압력비, 터빈 회전속도가 필요하다. 그러나 터빈 회전속도는 센서 장착이 어려우므로 엔진 제어시스템에서 실측이 어려운 문제가 있다. 수학적 모델의 경우 터빈 질량유량을 압축성 유체 유동으로 가정하고 오리피스 수식을 이용한다.[6,10~12] 오리피스 수식을 이용하여 질량유량을 계산하는 경우 유량계수에 대한 정보가 필요하다. 그러나 터빈 질량유량의 유량계수는 엔진 운전상태에 따라 비선형적으로 변하게 되므로 정확한 추정에 어려움이 따른다.

이 논문에서는 이러한 비선형성에 의한 문제를 극복하기 위하여 인공신경망(Artificial Neural Network, ANN)을 이용한 터빈 질량유량 모델을 제안하고자 한다. ANN 을 이용하여 터빈 질량유량을 추정하는 모델에 관한 연구는 Z. Filipi 등[13]에 의하여 진행되었으나 터빈 모델의 입력변수로 엔진 제어시스템에서 계측이 어려운 터빈 회전속도를 사용하는 점에서 한계가 있다. 이 연구에서는 기존 터빈 질량유량 모델의 입력변수 중 계측이 어려운 터빈 회전속도를 입력변수에서 제외하였다. 그리고 터빈 질량유량 모델로 사용될 오리피스 수식을 터빈 양단의 압력비에 의한 영향, 배기매니폴드 온도에 의한 영향, 터빈 입구 유효단면적에 의한 영향 등 세 부분으로 나누고, 그 중 유효단면적을 추정하는 부분에 ANN 을 적용하여 터빈 질량유량을 정확히 추정하였다.

2. 터빈 질량유량 모델

터빈 질량유량 모델은 오리피스 수식을 이용하여 도출하였으며 터빈 입구 유효단면적에 의한 영향(A_{EFA}), 터빈 양단의 압력비에 의한 영향(Ψ), 배기매니폴드 온도와 압력에 의한 영향(k)과 같이 세 부분으로 나누어 식 (1)과 같이 나타낼 수 있다.

$$\dot{m}_t = A_{EFA} \times \Psi \times k \tag{1}$$

$$A_{EFA} = C_D A \tag{2}$$

$$\Psi = \left(\frac{p_T}{p_0}\right)^{1/\gamma} \left\{\frac{2\gamma}{\gamma-1}\left[1-\left(\frac{p_T}{p_0}\right)^{(\gamma-1)/\gamma}\right]\right\}^{1/2} \quad \text{for} \left(\frac{p_T}{p_0}\right) > P_{cr} \tag{3}$$

$$\Psi = \gamma^{1/2}\left(\frac{2\gamma}{\gamma-1}\right)^{(\gamma+1)/2(\gamma-1)} \quad \text{for} \left(\frac{p_T}{p_0}\right) \le P_{cr} \tag{4}$$

$$k = \frac{p_0}{\sqrt{RT_0}} \tag{5}$$

터빈 입구 유효단면적에 의한 영향은 유량계수(C_D)와 단면적(A)의 함수로 식 (2)과 같이 나타낼 수 있다.

터빈 양단 압력비에 의한 영향은 식 (3), (4)와 같이 두 형태로 나뉘어진다. 터빈 양단의 압력비(p_T/p_0)가 임계압력비(P_{cr})보다 클 경우 식 (3), 임계압력비(P_{cr})보다 작을 경우 식 (4)를 사용하며, 터빈 입구 압력(p_0)과 터빈 출구 압력(p_T)은 압력센서를 이용하여 계측된 값을 사용하였다.

배기매니폴드 온도와 압력에 의한 영향은 이상기체상수(R)와 함께 식 (5)와 같이 나타낼 수 있다. 배기매니폴드 온도(T_0)는 써모커플을 이용하여 계측된 값을 사용하였다.

앞에서 언급한 터빈 질량유량 모델의 세 부분 중 Ψ와 k는 식 (3)-(5)의 관계식을 사용하고, 엔진 운전 영역에 따라 비선형성이 매우 높은 C_D를 포함하고 있는 A_{EFA} 부분은 3 장에서 소개할 ANN 으로 대체하였다.

3. 인공신경망(ANN)

3.1 ANN 개요

ANN 은 입출력 변수간의 관계를 대수방적식으로 표현하기 어려운 비선형 시스템의 식별에 많이 활용된다.[14,15] 터보차저의 경우 컴프레서 모델링,[16~18] 터보차저 고장진단[19] 등에 ANN 을 활용한 연구가 선행되었다.

ANN 은 기본 연산 단위인 뉴런 모델의 조합에 의한 계층적 구조로 이루어져 있다. 뉴런 모델의 구조는 Fig. 1 에 나타난 바와 같으며, 하나의 뉴런 모델은 다중입력($i_1, i_2, \cdots, i_l$)을 받을 수 있고 하나의 출력(y)만 내보낼 수 있다. 각각의 입력은 가중치($w_1, w_2, \cdots, w_l$)를 통하여 뉴런 모델로 인가되며 바이어스(b)와 함께 전달함수의 입력변수로 사용된다. 전달함수로는 임의의 비선형 또는 선형 수식이 사용될 수 있으며, 전달함수에 의하여 계산된 값이 뉴런 모델의 출력값이 된다. 식 (6)은 Fig. 1 과 같이 l 개의 입력을 갖는 뉴런 모델의 입출력 관계를 나타내고 있다.

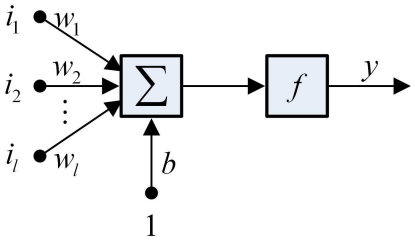

Fig. 1 Diagram of a single neuron

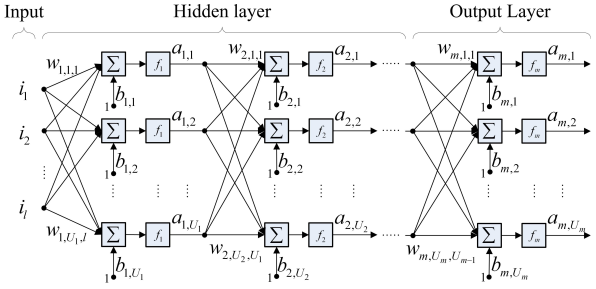

Fig. 2 Diagram of a multi-layer ANN

$$y = f\left(\sum_{k=1}^{l} w_k i_k + b\right) = f\left(\mathbf{WI} + b\right) \tag{6}$$

여기서 $\mathbf{W} = \begin{bmatrix} w_1 & w_2 & \cdots & w_l \end{bmatrix}$, $\mathbf{I} = \begin{bmatrix} i_1 & i_2 & \cdots & i_l \end{bmatrix}^T$ 이다.

Fig. 2 는 l 개의 입력과 U_m 개의 출력을 갖는 다층 구조 ANN 을 나타내며 총 $m-1$ 개의 은닉층(Hidden layer)과 한 개의 출력층(Output layer)으로 구성되어 있다. 식 (7)은 Fig. 2 에 도시된 다층 구조 ANN 의 각 계층별 입출력 관계를 나타내고 있다. 뉴런 모델의 가중치 행렬($\mathbf{W}_n$)과 바이어스 백터($\mathbf{b}_n$)의 각 요소는 Hebbian 학습법, Widrow-Hoff 학습법, 역전파 알고리즘(Back-propagation algorithm) 등에 의한 학습을 통하여 최적화 된다.[20]

$$\begin{aligned} \mathbf{a}_1 &= f_1\left(\mathbf{W}_1\mathbf{I} + \mathbf{b}_1\right) \\ \mathbf{a}_2 &= f_2\left(\mathbf{W}_2\mathbf{a}_1 + \mathbf{b}_2\right) \\ &\vdots \\ \mathbf{a}_m &= f_m\left(\mathbf{W}_m\mathbf{a}_{m-1} + \mathbf{b}_m\right) \end{aligned} \tag{7}$$

여기서 $\mathbf{a}_{n-1} = \begin{bmatrix} a_{n-1,1} & a_{n-1,2} & \cdots & a_{n-1,U_{n-1}} \end{bmatrix}^T$,

$$\mathbf{W}_n = \begin{bmatrix} w_{n,1,1} & w_{n,1,2} & \cdots & w_{n,1,U_{n-1}} \\ w_{n,2,1} & w_{n,2,2} & \cdots & w_{n,2,U_{n-1}} \\ \vdots & \vdots & \ddots & \vdots \\ w_{n,U_n,1} & w_{n,U_n,2} & \cdots & w_{n,U_n,U_{n-1}} \end{bmatrix},$$

$\mathbf{a}_0 = \mathbf{I} = \begin{bmatrix} i_1 & i_2 & \cdots & i_l \end{bmatrix}^T$, $\mathbf{b}_n = \begin{bmatrix} b_{n,1} & b_{n,2} & \cdots & b_{n,U_n} \end{bmatrix}^T$ 이다. 이 때, $n = 1, 2, \cdots, m$ 이고 $U_0 = l$ 이다.

3.2 ANN 구조 및 학습

이 논문에서 사용된 ANN 은 두 개의 은닉층과 하나의 출력층을 가지는 구조로 이루어져 있으며 첫 번째 은닉층은 3 개의 뉴런, 두 번째 은닉층은 7 개의 뉴런으로 형성되어있다. 은닉층의 뉴런 모델에 사용한 전달함수는 0-1 출력 범위를 갖는 식 (8)과 같으며, 출력층의 뉴런에는 은닉층에서 0-1 사이의 값으로 제한된 출력 범위를 가중치에 따라 확장할 수 있는 식 (9)와 같은 전달함수를 사용하였다.

$$f_1(x) = f_2(x) = \frac{1}{1+e^{-x}} \tag{8}$$

$$f_3(x) = x \tag{9}$$

터빈 입구 유효단면적을 추정하기 위한 ANN 의 입력 변수는 VGT 유로 단면적을 결정하는 VGT 베인 개도량(i_1), 배기가스 질량유량과 EGR 유량에 영향을 미치는 엔진 회전속도(i_2), 터빈 양단 압력비를 결정하는 배기매니폴드 압력(i_3)으로 선정하였으며 출력은 터빈 입구 유효단면적(y)으로 선정하였다. ANN 의 가중치와 바이어스의 학습을 위한 데이터는 4 장에서 소개할 3.0L 커먼레일 직분식 디젤엔진의 정상상태 운전일 때 터빈 질량유량을 계측하여 획득하였다. ANN 의 학습에 사용된 터빈 입구 유효단면적은 정상상태 엔진 실험 결과를 이용하여 계산하였다. 터빈 입구 유효단면적은 정상상태 엔진 실험을 통하여 계측한 터빈 질량유량을 오리피스 수식에 대입하여 얻을 수 있다. 이 때 엔진 운전조건은 Table 1 과 같다. 단, 엔진 회전속도가 2500 RPM 일 때 BMEP 6-9 bar 의 고부하 영역에서는 터보차저의 기계적 파손을 방지하기 위하여 VGT 베인 전폐인 경우는 제외하였고, 실린더 흡입 공기량에 영향을 미치는 EGR 밸브는 닫은 상태에서 실험을 수행하였다.

ANN 가중치와 바이어스의 학습은 역전파 알고리즘 중 수렴속도가 빠른 LMBP(Levenberg-Marquardt Back-Propagation)알고리즘[20]을 사용하였다.

4. 실험 환경

이 연구에 사용한 엔진은 VGT 와 EGR 을 장착한 3.0L 커먼레일 직분식 디젤엔진으로 제원은 Table 2 와 같다. EGR 은 엔진 냉각수를 이용하여 배기가스를 냉각시키는 EGR 쿨러를 통과 후 실린더로 유입된다. 컴프레서에 의하여 압축된 흡입공기는 단열압축에 의하여 온도가 상승하므로 인터쿨러를 통하여 냉각된 후 실린더로 유입된다. 실험에 사용된 동력계는 300kW 급 EC 동력계 이며 모든 운전구간에서 엔진 냉각수 온도는 88- 92℃ 로 유지하였다.

실험 환경은 **Fig. 3** 과 같이 구성하였다. 인공신경망 학습을 위한 데이터 획득 실험을 할 때에는 dSPACE 사의 MicroAutobox 를 이용하여 VGT 베인과 EGR 밸브를 제어하고 상용 제어기를 사용하여 연료분사를 제어하였다. 그리고 터빈 질량유량 모델 검증을 위한 실험에서는 모두 상용 제어기를 사용하였다.

Table 1 Engine operating range for ANN learning data acquisition

	Min	Max	Increment	Note
Engine speed [RPM]	1000	2500	250	-
BMEP [bar]	1	9	1	-
VGT vane open [-]	0	1	0.2	0: Full close 1: Full open

Table 2 Specification of test engine

Parameter	Value
Configuration	V6
Bore	84 mm
Stroke	89 mm
Displacement volume	2,959 cc
Number of valves	24
Compression ratio	16:1

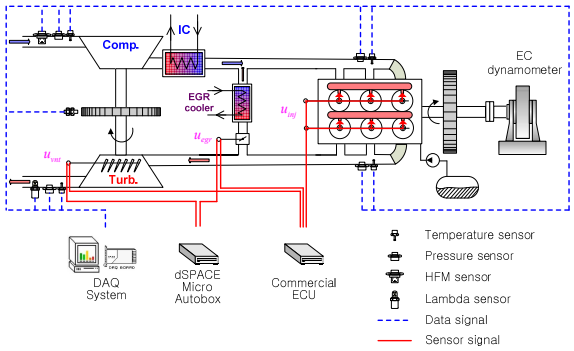

Fig. 3 Experimental environment

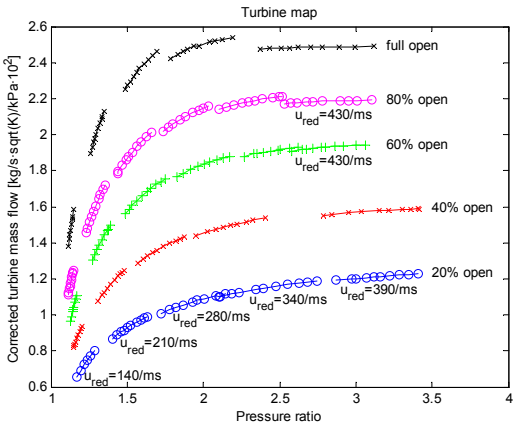

Fig. 4 Turbine mass flow map

터빈 질량유량을 직접 계측하는 것은 어려움이 따르므로 정상상태 운전일 경우 식 (10)에 나타난 바와 같이 질량보존법칙을 따른다고 가정한다. 터빈 질량유량($\dot{m}_t$)은 실린더 내로 유입되는 흡입 공기 질량유량($\dot{m}_a$)과 연료 분사량($\dot{m}_f$)의 합과 동일하다고 가정하고 실린더 내로 유입되는 흡입 공기 질량유량과 연료 분사량을 계측하였다.

$$\dot{m}_t = \dot{m}_a + \dot{m}_f \tag{10}$$

5. 모델 검증

ANN 을 이용하여 개발된 터빈 질량유량 모델은 정상상태 실험을 통하여 계측된 터빈 질량유량과 모델의 추정값 비교를 통하여 검증하였다. 그리고 터빈 맵을 이용하여 추정한 터빈 질량유량과의 비교를 통하여 터빈 맵을 사용하여 추정한 결과 대비 이 연구에서 제안한 터빈 질량유량 모델을 사용하여 추정할 때의 정확도 개선 여부를 확인하였다. 터빈 맵은 Fig. 4 에 나타난 바와 같으며, 터빈 회전속도, 베인 개도량, 터빈 양단 압력차를 이용하여 터빈 질량유량을 도출한다. 터빈 맵을 통하여 구한 터빈 질량유량은 테스트벤치 시험 환경에서 측정된 값이므로 실제 터빈 질량유량을 도출하기 위해서는 식 (11)과 같이 배기매니폴드의 온도와 압력에 대한 보정이 필요하다.

Table 3 Engine operating range for ANN model validation

	Min	Max	Increment
Engine speed [RPM]	1250	2250	250
BMEP [bar]	2	8	1

$$\dot{m}_t = \frac{\dot{m}_{t_corr} \cdot \sqrt{T_0}}{p_0 \cdot 10^{-3}} \tag{11}$$

터빈 질량유량 모델의 검증을 위한 엔진 운전구간은 Table 3 과 같다. VGT 베인 개도량과 EGR 밸브 개도량은 상용 제어기를 사용하여 제어하였다. 이 때 터빈 질량유량은 4 장에서와 동일하게 실린더 내로 유입되는 흡입 공기 질량유량과 연료 분사량의 합과 동일한 것으로 가정하였다.

Fig. 5 부터 Fig. 9 는 터빈 맵을 이용하여 추정한 터빈 질량유량과 ANN 을 적용하여 추정한 터빈 질량유량의 실험결과를 비교한 결과이다. 이 논문에서 제안한 터빈 질량유량 모델을 이용하여 터빈 질량유량을 추정한 결과 5% 미만의 오차를 나타내었으며 이는 터빈 맵을 이용하여 추정한 것 보다 최대 약 40% 개선된 결과이다. 터빈 맵을 이용하여 터빈 질량유량을 추정한 결과의 오차가 큰 원인은 터빈 질량유량 맵을 작성하기 위한 실험이 테스트벤치에서 정상유동을 이용하여 수행되었기 때문에 실제 엔진의 흡입-압축-폭발-배기 등 엔진의 이산적인 운전에 의한 맥동효과 및 엔진의 기계적인 마찰 등을 고려하지 못했기 때문인 것으로 판단된다. 인공신경망을 이용하여 터빈 질량유량을 추정한 결과와 터빈 맵을 이용하여 터빈 질량유량을 추정한 결과 및 추정오차를 Table 4 에 표기하였다. 인공신경망을 이용한 추정 오차의 최대값과 최소값은 각 4.65%와 0.03%이며, 터빈 맵을 이용한 추정 오차의 최대값과 최소값은 42.49%와 1.55%으로 인공신경망을 이용한 터빈 질량유량 추정 결과가 우수함을 확인할 수 있다. 터빈 질량

유량 오차는 측정된 값($\dot{m}_{t_meas}$)과 추정된 값 ($\dot{m}_{t_est}$)을 이용하여 식 (12)와 같이 계산하였다.

$$Error[\%] = \frac{\dot{m}_{t_meas} - \dot{m}_{t_est}}{\dot{m}_{t_meas}} \times 100[\%] \quad (12)$$

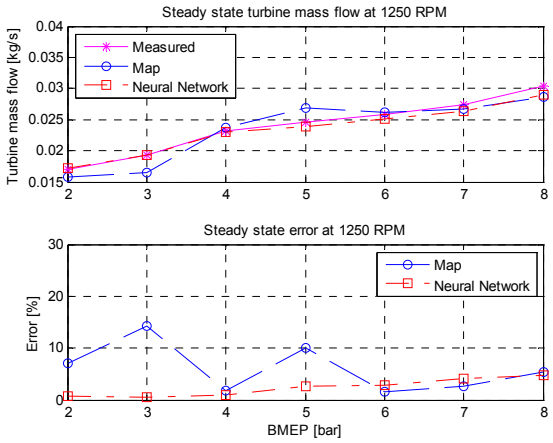

Fig. 5 Turbine mass flow rate at 1250 RPM

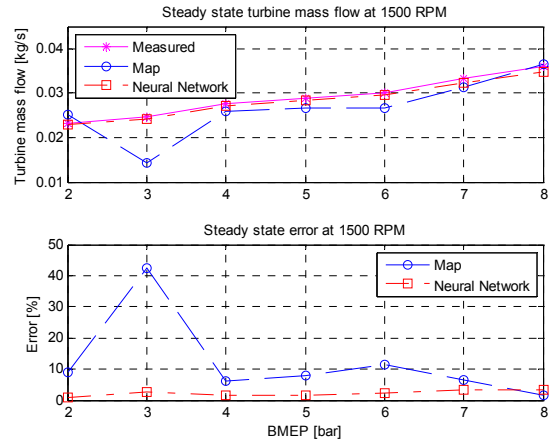

Fig. 6 Turbine mass flow rate at 1500 RPM

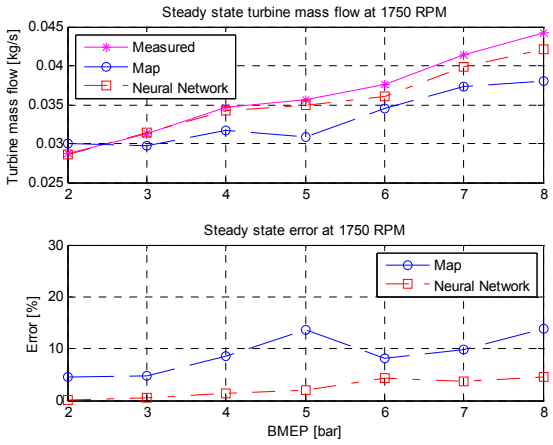

Fig. 7 Turbine mass flow rate at 1750 RPM

Fig. 5 부터 Fig. 8 의 결과에서는 터빈 질량유량이 엔진 속도 증가에 따라 점진적으로 증가하나 Fig. 9 에서는 터빈 질량유량이 급진적으로 증가하는 현상을 나타낸다. 이러한 현상은 Fig. 10 에 나타난 바와 같이 2250 RPM 운전조건에서 실린더 흡입 공기량이 급증한 것이 원인이며, 질량보존법칙에 따라 터빈 질량유량이 증가한 것이다. 일반적으로 실린더 흡입 공기량은 EGR 질량유량의 영향을 많이 받는다.[21] 이 논문에서 EGR 밸브 개도량은 상용 제어기를 사용하여 제어하였으며, 상용 제어기에서 특정 운전영역 이후 다량의 실린더 흡입 공기량을 확보할 수 있도록 EGR 밸브 개도량을 제어한다.

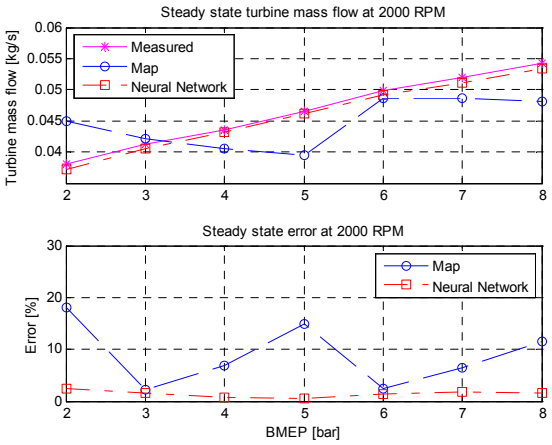

Fig. 8 Turbine mass flow rate at 2000 RPM

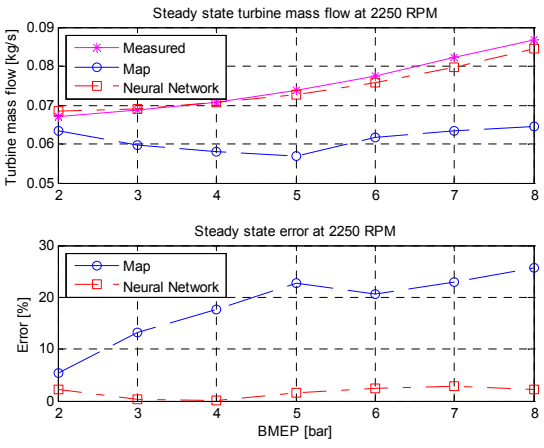

Fig. 9 Turbine mass flow rate at 2250 RPM

Table 4 Turbine mass flow rate estimation and estimation error

Engine speed [RPM] / BMEP [bar]	1250		1500		1750		2000		2250	
	Neural network [kg/s]	Turbine map [kg/s]	Neural network [kg/s]	Turbine map [kg/s]	Neural network [kg/s]	Turbine map [kg/s]	Neural network [kg/s]	Turbine map [kg/s]	Neural network [kg/s]	Turbine map [kg/s]
1	0.0172 (0.72%)	0.0158 (7.13%)	0.0229 (1.02%)	0.0252 (9.00%)	0.0286 (0.08%)	0.0300 (4.49%)	0.0371 (2.47%)	0.0449 (17.99%)	0.0685 (2.12%)	0.0634 (5.40%)
2	0.0194 (0.47%)	0.0165 (14.35%)	0.0241 (2.58%)	0.0143 **(42.29%)**	0.0314 (0.58%)	0.0298 (4.69%)	0.0406 (1.68%)	0.0421 (2.15%)	0.0690 (0.33%)	0.0597 (13.10%)
3	0.0230 (1.00%)	0.0237 (1.77%)	0.0272 (1.54%)	0.0259 (6.18%)	0.0342 (1.31%)	0.0317 (8.64%)	0.0432 (0.82%)	0.0406 (6.88%)	0.0707 **(0.03%)**	0.0581 (17.74%)
4	0.239 (2.61%)	0.0270 (9.97%)	0.0284 (1.54%)	0.0266 (7.75%)	0.0350 (1.97%)	0.0308 (13.66%)	0.0462 (0.62%)	0.0396 (14.98%)	0.0726 (1.51%)	0.0570 (22.68%)
5	0.0250 (2.85%)	0.0262 (1.65%)	0.0295 (2.31%)	0.0268 (11.41%)	0.0360 (4.27%)	0.0345 (8.19%)	0.0492 (1.48%)	0.0487 (2.46%)	0.0757 (2.38%)	0.0617 (20.49%)
6	0.0263 (4.13%)	0.0267 (2.64%)	0.0322 (3.45%)	0.0313 (6.40%)	0.0399 (3.63%)	0.0374 (9.73%)	0.0511 (1.81%)	0.0487 (6.53%)	0.0798 (2.86%)	0.0633 (22.97%)
7	0.0289 **(4.65%)**	0.0287 (5.45%)	0.0347 (3.44%)	0.0365 **(1.55%)**	0.0422 (4.54%)	0.0380 (13.93%)	0.0534 (1.63%)	0.0481 (11.54%)	0.0846 (2.31%)	0.0644 (25.60%)

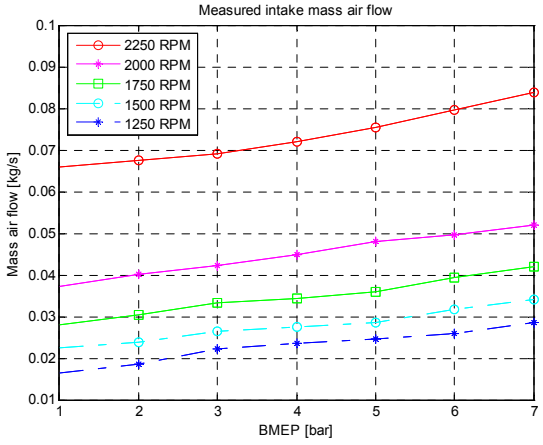

Fig. 10 Measured intake mass air flow

6. 결 론

이 연구에서는 ANN 을 적용한 터빈 질량유량 모델을 이용하여 터빈 질량유량을 추정하는 방법을 제안하였으며, 이를 통하여 다음과 같은 결론을 도출하였다.

후 기

이 연구는 지식경제부와 한국산업기술진흥원의 전략기술인력양성사업, 교육과학기술부의 BK21 사업(201000000000173), 지식경제부 에너지자원기술개발사업(2006ETR11P091C)의 일환으로 수행된 결과이다.

참고문헌

(1) Gao, Z. and Schreiber, W., 2001, "The effects of EGR and Split Fuel Injection on Diesel Engine Emission," *International Journal of Automotive Technology*, Vol. 2, No. 4, pp. 123~133.

(2) Agrawal, A.K., Singh, S.K., Sinha, S. and Shukla, M.K., 2004, "Effect of EGR on the Exhaust Gas Temperature and Exhaust Opacity in Compression Ignition Engines," *Sadhana - Academy Proceedings in Engineering Sciences*, Vol. 29, No. 3, pp. 275~284.

(3) Lee, J., Cho, G., Kim, H., and Jeong, Y., 2007, "A Study on PM Regeneration Characteristics of Diesel Passenger Vehicle with Passive Regeneration DPF

System," *Transactions of the Korean Society of Mechanical Engineers (B)*, Vol. 31, No. 2, pp. 188~194.

(4) Cho, Y.S., Lee, J.S., Yoon, Y.B., Park, Y.J. and Lee, S.W., 2008, "An Experimental Study on Regeneration Characteristics of Catalyzed Diesel Particulate Filter with Variation of Exhaust Gas Temperature and Composition," *Transactions of the Korean Society of Mechanical Engineers (B)*, Vol. 32, No. 8, pp. 597~603.

(5) Zheng, M., Reader, G.T. and Hawley, J.G., 2004, "Diesel Engine Exhaust Gas Recirculation - A Review on Advanced and Novel Concepts," *Energy Conversion and Management*, Vol. 45, No. 6, pp. 883~900.

(6) Plianos, A. and Stobart, R., 2007, "Dynamic Feedback Linearization of Diesel Engines with Intake Variable Valve Actuation," *IEEE International Conference on Control Applications*, pp. 455~460.

(7) Jankovic, M. and Kolmanovsky, I. 1998, "Robust Nonlinear Controller for Turbocharged Diesel Engines," *American Control Conference*, pp. 1389~1394.

(8) Sun, J., Kolmanovsky, I., Cook, J.A. and Buckland, J.H., 2005, "Modeling and Control of Automotive Powertrain Systems: A Tutorial," *American Control Conference*, pp. 3271~3283.

(9) Upadhyay, D., Utkin, V.I., and Rizzoni, G., 2002, "Multivariable Control Design for Intake Flow Regulation of a Diesel Engine Using Sliding Mode," Triennial World Congress.

(10) Ammann, M., Fekete, N.P., Guzzella, L., and Glattfelder, A.H., 2003, "Model Based Control of the VGT and EGR in a Turbocharged Common Rail Diesel Engine: Theory and Passenger car Implementation," SAE World Congress & Exhibition.

(11) Jankovic, M. and Kolmanovsky, I., 2000, "Constructive Lyapunov Control Design for Turbocharged Diesel Engines," *IEEE Transactions on Control Systems Technology*, Vol. 8, No. 2, pp. 288~299.

(12) Ouenou-Gamo, S., Rachid, A., and Ouladsine, M. 1997, "Nonlinear Controller of a Turbocharged Diesel Engine Using Sliding Mode," *IEEE International Conference on Control Applications*, pp. 803~805.

(13) Filipi, Z., Wang, Y., and Assanis, D., 2004, "Variable Geometry Turbine (VGT) Strategies for Improving Diesel Engine in-Vehicle Response: A Simulation Study," *International Journal of Heavy Vehicle Systems*, Vol. 11, No. 3-4, pp. 303~326.

(14) Lippmann, R.P., 1987, "Introduction to Computing with Neural Nets," *IEEE ASSP magazine*, Vol. 4, No. 2, pp. 4~22.

(15) Narendra, K.S. and Parthasarathy, K., 1990, "Identification and Control of Dynamical Systems Using Neural Networks," *IEEE Transactions on Neural Networks*, Vol. 1, No. 1, pp. 4~27.

(16) Nelson Ii, S.A., Filipi, Z.S., and Assanis, D.N., 2003, "The Use of Neural Nets for Matching Fixed or Variable Geometry Compressors with Diesel Engines," *Journal of Engineering for Gas Turbines and Power*, Vol. 125, No. 2, pp. 572~579.

(17) Venturini, M., 2006, "Simulation of Compressor Transient Behavior Through Recurrent Neural Network Models," *Journal of Turbomachinery*, Vol. 128, No. 3, pp. 444~454.

(18) Venturini, M., 2007, "Optimization of a Real-Time Simulator Based on Recurrent Neural Networks for Compressor Transient Behavior Prediction," *Journal of Turbomachinery*, Vol. 129, No. 3, pp. 468~478.

(19) Ludwig, C. and Ayoubi, M. 1995, "Fault Detection Schemes for a Diesel Engine Turbocharger," *American Control Conference*, pp. 2118~2122.

(20) Hagen, M.T., Demuth, H.B., and Beale, M., 1996, Neural Network Design, PWS Publishing Company.

(21) Jung, M. and Glover, K., 2006, "Calibratable Linear Parameter-Varying Control of a Turbocharged Diesel Engine," *IEEE Transactions on Control Systems Technology*, Vol. 14, No. 1, pp. 45~62.