





### 2019 년 8 월

석사학위논문

# 실시간 수치해석을 위한 신경망 기반의 가상의 디젤 엔진 평균값 모델 구축에 대한 수치적 연구

# 조 선 대 학 교 대 학 원 기계공 학과 고 은 희



# 실시간 수치해석을 위한 신경망 기반의 가상의 디젤 엔진 평균값 모델 구축에 대한 수치적 연구

A numerical study on real time simulation for mean value model of diesel engine based on artificial neural network

2019년 8월 23일

## 조선대학교 대학원

기계공학과

고 은 희





# 실시간 수치해석을 위한 신경망 기반의 가상의 디젤 엔진 평균값 모델 구축에 대한 수치적 연구

## 지도교수 박 정 수

이 논문을 공학석사학위신청 논문으로 제출함

2019년 4월 15일

조선대학교 대학원

기계공학과

고 은 희





# 고은희의 석사학위논문을 인준함

위욱	신장	조선대학교	교수	조	ङे	현	_印
위	원	조선대학교	교수	<u> </u>	동	욱	_印
위	원	조선대학교	교수	박	정	수	印

2019년 5월

조선대학교 대학원





## 목 차

LIST	OF	TA	BLES	••••••	IV
LIST	OF	FIG	URES		v
ABST	RA	СТ	•••••		х

- 제 1 장 서 론.....1 제 1 절 연구 배경 ......1
  - 제 2 절 연구 동향 .....7
- 제 2 장 방법론 .....12
  - 제 1 절 상세 모델 .....12
    - - 라. Ignition delay .....17





마. Premixed combustion
바. Diffusion combustion18
2. $NO_x$ model
제 2 절 실험 계획법
1. DI-Pulse 보정 승수 최적화
2. Model reduction process
제 3 절 평균값 엔진 모델24
제 4 절 SISO 모델 연계
제 3 장 결 과
제 1 저 사세 모데 격과
제 1 월 8개 도월 철거
제 1 철 8개 도를 설의 제제 30 제 2 절 Artificial neural network training and Mean
제 2 절 Artificial neural network training and Mean value model
제 2 절 Artificial neural network training and Mean value model
제 2 절 Artificial neural network training and Mean value model
제 2 절 Artificial neural network training and Mean value model



# 





## LIST OF TABLES

Table 1	Engine specification	12
Table 2	2 Operating condition	12
Table 3	3 Input Variables and Their Ranges	21
Table 4	4 Input Variables and Their Ranges	22
Table 5	5 Mean value model operating condition	39
Table 6	6 Optimized parameter values at each conditions	44





## LIST OF FIGURES

Figure 1 Low-carbon strategy for 2050 (EU)1
Figure 2 Multi-pulse Injection2
Figure 3 Multi-pulse Injection advantage2
Figure 4 Efficiency map of Turbocharger (right: Turbine map, left:
compressure)3
Figure 5 Surge and choke limits of compressor efficiency map $\cdots 3$
Figure 6 Exhaust system schematic4
Figure 7 Signal flow of real system and HIL simulations5
Figure 8 Flow chart for model-based design
Figure 9 Final mean value engine model in GT-Power7
Figure 10 The comparison of emission results (in transient
conditions) from the Neuro-MVM and the GT-Power model
(right : CO emission, left : NOx emission)8
Figure 11 The comparisons of NN based model with experimental
results for testing set(diesel engine without intercooling) $\cdots 8$
Figure 12 The performance of NN based model for diesel engine
without intercooling
Figure 13 Flow chart for Co-simulation





Figure 18 Multi-pulse model in GT-Power
Figure 19 Latin Hypercube Sampling diagram20
Figure 20 Comparison between response value and factor value (all
samples)21
Figure 21 RMS error 23
Figure 22 Training modeling for neuron network training23
Figure 23 Radial Basis mode diagram
Figure 24 Self-Organizing Local Linear mode diagram25
Figure 25 Multi-layer feed forward26
Figure 26 Diesel mean value engine model
Figure 27 Single input single output(SISO) system : A sampled-data
feedback control system
Figure 28 Block diagram of PID control
Figure 29 Mean value SISO model
Figure 30 Comparison between measured result and predicted result
: BSFC
Figure 31 Comparison between measured result and predicted result
: P <sub>max</sub> 31
Figure 32 Comparison between measured result and predicted result
: EGR ratio
Figure 33 Comparison between measured result and predicted result
$\therefore BNO_x \cdots 32$
Figure 34 In-cylinder pressure and Gross heat release rate of
detailed model : 1000RPM ·······33





Figure 35 In-cylinder pressure and Gross heat release rate of
detailed model : 1500RPM ·······33
Figure 36 In-cylinder pressure and Gross heat release rate of
detailed model : 2000RPM
Figure 37 In-cylinder pressure and Gross heat release rate of
detailed model : 2500RPM
Figure 38 Training input data : Volumetric Efficiency of NNT
results ·······35
Figure 39 Training output data : Volumetric Efficiency of NNT
results ·······35
Figure 40 Point with zero error : Volumetric Efficiency of NNT
results ·······36
Figure 41 NNT total data : Volumetric Efficiency
Figure 42 Training input data : Exhaust temperature of NNT
results
Figure 43 Training output data : Exhaust temperature of NNT
results
Figure 44 Point with zero error : Exhaust temperature of NNT
results
Figure 45 NNT total data : Exhaust temperature
Figure 46 Comparison between detailed model result and mean
value model result : Volumetric efficiency, Air40
Figure 47 Comparison between detailed model result and mean
value model result : Air/Fuel Ratio41





Figure 48 Comparison between detailed model result and mean
value model result : Brake Torque
Figure 49 Comparison between detailed model result and mean
value model result :BSFC
Figure 50 Comparison between detailed model result and mean
value model result : EGR rate
Figure 51 Acceleration step transient conditions as a function of
speed and BMEP45
Figure 52 Acceleration step transient conditions as a function of
time and speed
Figure 53 Deceleration step transient conditions as a function of
speed and BMEP 46
Figure 54 Deceleration step transient conditions as a function of
speed and BMEP 46
Figure 55 Comparison between mean value model result and mean
value SISO model result at acceleration step transient
conditions : Volumetric efficiency
Figure 56 Comparison between mean value model result and mean
value SISO model result at acceleration step transient
conditions : EGR rate48
Figure 57 Comparison between mean value model result and mean
value SISO model result at deceleration step transient
conditions : Volumetric efficiency
Figure 58 Comparison between mean value model result and mean

- VIII -





	val	ue	SISO	model	result	at	decele	ration	ı ste	эр	transient
	con	nditi	ons : E	EGR rate	•••••			•••••	•••••	•••••	
Figure	59	Tra	ade-off	of mode	el error	and	model	run 1	time	•••••	



### ABSTRACT

## A numerical study on real time simulation for mean value model of diesel engine based on artificial neural network

Eun Hee Ko Advisor : Prof. Park, Jungsoo, Ph.D. Department of Mechanical Engineering, Graduate School of Chosun University

Modern diesel engines employ complex engine sub-units to meet higher performance and enhanced exhaust regulations. The trade-off relationship between the response and accuracy of the applied control system is very important. Therefore, verification process is required in the simulation environment in the initial system design stage. Real time numerical analysis is more needed because it can save time and cost compared to existing vehicle system verification test. This study proposes a method of constructing a plant model for real-time numerical analysis through hardware-in-the-loop (HiL) real-time numerical analysis system. The detail is the construction of a virtual diesel mean value plant engine model with sufficient accuracy and fast execution speed through Co-simulation of 1D-Plant model and EGR control





system. In addition, the average value model combined with EGR logic, that is, the SISO model, verifies the accuracy and responsiveness of the EGR control logic model through a step-transient step. By comparing the engine performance results of the SISO model with the average value model, the SISO model achieves the desired target EGR rate within 10 seconds. Not only the EGR rate but also the volume efficiency of the engine cylinder and the amount of fuel are predicted similarly. This is due to the intuitive prediction of the main performance of the engine model through artificial neural networks and the combination of control logic in a simple feedback loop rather than a complex control system.

Finally, the mean value model had about 3% accuracy loss compared to the detail model, but the model execution time was shortened by about 2 times.





## 제1장서 론

#### 제 1 절 연구 배경

악화되는 환경에 대해 세계 주요 국가들은 강력한 환경 규제를 내세우고 있다. 특히 EU는 1990년대 대비 2020년까지 전반적으로 배출되는 배기가스 20% 감소 및 에너지 효율 20% 향상을 목표로 하고 있다.



Low-carbon strategy for 2050 Targets compared to 1990 levels

Figure 1 Low-carbon strategy for 2050 (EU)

내연기관 엔진 역시, 에너지 효율 향상과 강력해진 배기가스 규제의 기준을 만족 해야한다[1~4]. 특히 스파크 점화(spark ignition) 엔진에 비해 높은 압축비를 가지 고 있어 엔진 성능이 높은 압축착화(compression ignition) 엔진은 배출되는 유해 배기가스 저감을 위해 엔진 sub-system과 배출가스 후처리기술이 발전해왔다. 대 표적인 엔진 sub-system은 다단분사(Common rail Direct Injection)시스템, 터보차 저(Turbocharger)시스템, EGR(Exhaust gas recirculation) 시스템으로서 엔진 핵심 부품으로 자리잡아 왔다. 다단분사 시스템은 단일 분사와 달리 연료를 나눠 실린더 에 분사하는 방식이다. 특히 연료는 고압으로 분사되는데, 이는 단일분사에 비해 향상된 연료 미립화 환경을 제공 해준다. 분사 이벤트는 그림 2와 같이 주분사 (main injection) 전에 소량의 연료를 분사하는 보조분사(pilot injection)와 주분사 뒤에 소량의 연료를 분사하는 후분사(post injection)으로 나눌 수 있다. 다단분사의





장점으로는 여러 번의 분사를 통해 연소 온도를 낮추는 것뿐만아니라 그림 3처럼 소량의 pilot injection을 통해 진동과 소음 및 NOx 배출을 감소시킬 수 있으며, 엔 진의 성능은 main injection으로 구현할 수 있다.



Figure 2 Multi-pulse Injection

그리고 post injection을 통해 Soot과 미연탄화수소(HC, CO) 배출을 줄일 수 있다. 또한, *NO<sub>x</sub>*를 저감하는 SCR(Selective catalytic reduction)의 촉매활성 온도 및 미 립자 물질(particulate matter, PM)과 매연(soot)을 제거할 수 있는 DPF(diesel particulate filter)의 촉매활성 온도를 제공해 줄 수 있다. 이러한 장점으로 현대의 디젤 엔진의 연료 분사 방식으로 많이 사용하고 있다.



Figure 3 Multi-pulse Injection advantageure



터보차저 시스템은 자연 흡기 엔진에 비해 대기압의 공기보다 높은 압력의 공기 가 비교적 더 많은 양이 실린더 내로 공급 될 수 있도록, 터빈을 통해 압축공기가 연소실로 강제로 유입되어 디젤 엔진의 효율과 출력을 높일 수 있다. 터보차저는 압축기와 터빈으로 이루어져 있으며, 그림 4의 터빈과 압축기의 효율 map을 기반 으로 터보차저의 성능을 평가할 수 있다. 특히 압축기의 효율 map의 surge limit와 choke section은 주어진 속도에 대해 압축기의 작동이 불안정해지는 유량을 말하 며, 유량이 한계 이하 혹은 초과하게 되면 소음과 진동이 발생되며 심각한 기계적 손상을 이끌 수 있다. 압축기 효율 map의 한계 라인들은 그림 5에 나타내었다. 그 러므로 엔진의 운전 범위에 맞는 압축기와 터빈의 효율 map의 라인을 최적화하는 것이 매우 중요하다.



Figure 4 Efficiency map of Turbocharger (right: Turbine map, left: Compressure)



Figure 5 Surge and choke limits of compressor efficiency map

EGR 시스템은 엔진의 배기가스 일부를 다시 엔진 실린더로 재순환 시켜, 실린더 로 들어오는 공기의  $O_2$ 를 희석시키고  $CO_2$ ,  $H_2O$ 를 연소열 흡수제로 사용하여 실 린더의 최고 온도, 즉 연소 온도를 낮추는 이점이 있다. 특히 EGR 시스템은 구성 방법에 따라 그림 6과 같이 고압 EGR 시스템과 저압 EGR 시스템으로 나눌 수 있다. 고압 EGR은 낮은 HC, CO 배기량을 가지며 빠른 응답성의 가지고 있지만, 흡기 매니폴드에 균일한 EGR를 넣어줄 수 없기에 불안정한 EGR 편차가 존재한다. 저압 EGR의 경우 고압 EGR에 비해 안정된 EGR 편차를 가지고 있지만, 응답성이 늦고, 높은 HC, CO 가스를 배출한다. 하지만 위에서 언급한 것처럼 들어오는 공기 의  $O_2$ 를 희석시키기 때문에 유해 배출 가스인  $NO_x$  가스를 줄일 수 있다. 이에 최근에는 Dual loop EGR 시스템을 사용하여  $NO_x$ 의 배출은 줄이고, 연비를 향상시 키고자 한다. 하지만 이 방식은 제어 난이도가 높으며, 운전영역에 따라 HP/LP split rate 최적화가 매우 중요하다[5~9].



Figure 6 Exhaust system schematic

앞서 살펴본 바, 오늘날의 내연기관은 복잡한 엔진 서브장치를 적용하고 있다. 따 라서, 내연기관의 광범위한 운전점에서 제어 시스템 설계 및 검증 과정은 시간과 비용이 많이 소요된다. 이에 제어 시스템 설계 초기 단계에서 가상 환경 검증 과정 은 차량 테스트 이전에 실시하여 검증할 수 있다. 특히 실시간 수치해석(Real-time simulation)은 기존의 차량 시스템 검증 테스트 보다 시간과 비용을 절감 할 수 있 기 때문에 필요성이 증가되어 가고 있다[10~21]. 실시간 수치해석 프로그램으로서 HiL(Hardware-in-the-loop) 시뮬레이션은 엔진, 모터 등 주요 부품 모델이 탑재 되어 있는 가상 환경에 실제 하드웨어가 추가된 형태의 테스트 환경을 제공하는 검사장치로, 그림 7에 실제 시스템과 HiL 시스템의 신호호름을 알 수 있다. HiL 시 스템은 실시간 수치해석 시스템으로 서 플랜트 엔진 모델과 실제 엔진 시스템 부 품을 결합하여 실제 차량과 유사한 상태를 재현하고 다양한 매개변수를 포함하는 성능 검증이 가능하다. 또한 HiL시스템은 가상의 테스트 환경에서 대상 시스템 해 석으로 시스템 개발 비용과 시간을 단축할 수 있어 제품 개념 설계 단계에서의 필 요성이 증가 하고 있다[10~13].



Figure 7 Signal flow of real system and HIL simulations

HiL 시스템을 통한 제어 부품 해석을 위해서는 신뢰도가 높고, 수치해석 시간이 빠른 플랜트 모델 구성이 중요하며, simulation 환경과 하드웨어 환경간의 time 도 메인 인터페이싱 매칭이 필요하다. 따라서 제어 시스템과 1D 플랜트 모델간의 공





통의 인터페이스로 구축된 모델 기반(Model-based) 수치해석 모델이 필요하다. HiL 시스템에 사용되는 기존의 플랜트 모델은 모델 구성이 제약적이며, 엔진 모델 시스템 제원이 바뀌는 경우 모델 탄력성이 저하된다.이를 위해 HiL 시뮬레이션에 앞서, SiL(Software-in-the-simulation) 과정을 통해 모델 기반 플랜트 모델의 유효 성 검사를 먼저 수행할 수 있다. SiL 시뮬레이션은 하드웨어가 포함하지 않는 오로 지 소프트웨어로 이루어진 모델 검증 단계이다. 특히 SiL 시스템을 통해 프로젝트 초기의 문제나 엔진 구성 요소 상호작용의 수와 복잡성을 크게 줄일 수 있으며, 엔 진 디자인 변경을 확인할 수 있다.



Figure 8 Flow chart for model-based design

모델 기반 가상의 플랜트 모델을 구축하기 위해서는 모델 정확도가 높고, 실시간 으로 시뮬레이션 하기 위해 수치해석 실행 속도가 빠른 모델을 구축해야한다. 모델 정확도와 실행 속도 간의 trade-off 균형을 이루기 위해, 평균값 모델(Mean value model)은 엔진 모델링의 보편적인 방법이라 할 수 있다.





### 제 2 절 연구 동향

평균값 모델은 높은 정확도를 가진 상세 모델을 바탕으로 인공 신경망(Neural network) 기능을 통해 구축되며 모델 단축(Model reduction)과정을 통해 모델 해석 속도를 줄인다. 실린더 내부의 열 방출, 흡기 매니폴드 유량 흐름, 엔진의 성능을 예측하는 수치해석 모델 구축에 대해 연구가 활발히 진행되어왔다[14~26]. He는 1D 상용 해석 프로그램을 사용하여 상세 모델을 기반으로 인공 신경망을 사용하여 모델 단축과정을 통해 그림 9과 같이 단순한 형태의 평균값 모델을 구축하였다. 평 균값 모델을 일시적인 조건 내에서 엔진 모델과 제어 시스템의 동적 응답 파악을 검증하였으며 모델 정확도 및 실행 속도의 trade-off 균형을 맞추었다[15].



Figure 9 Final mean value engine model in GT-Power

Shamekhi은 multi-point fuel injection의 spark ignition engine을 위한 고정밀 control-oriented model을 제시하였다. 인공 신경망을 이용하여 기존의 mean value model과 결합한 실시간 모델(Neuro-MVM)은 steady state 및 transient state에서 배기 배출 가스에 대해서 실시간적으로 정확하게 예측하였다(그림 10, [17]). Lujan 는 인공 신경망 방법 중 다층 구조 연산(Multi-layer feed forword) 모드를 사용하 여 parameter 연구를 통해 흡기 시스템의 공기 질량 흐름 예측을 통해 체적 효율 의 정확도를 평가하였다. 특히 네트워크 계층 간의 다양한 학습 속도 최적화를 통 해 빠른 학습 속도 및 낮은 복잡성을 가진 인공 신경망 훈련 방법을 도출하였다 [16].







Figure 10 The comparison of emission results (in transient conditions) from the Neuro-MVM and the GT-Power model (right : CO emission, left : NOx emission)

Uzun, A.는 인공 신경망을 사용하여 터보차저 디젤 엔진의 Intercooling이 엔진의 공기 질량 흐름에 미치는 영향을 검증하였다. 공기 질량 흐름 인자는 에너지의 보 존을 기반으로 FF(Feed-Forwaed) 네트워크 모델을 통해 예측하였고, 상세 실험 데이터와 비교하여 정확도를 검증하였다. 특히 실험 데이터와 비교 결과, NN 기반 모델은 터보차저 디젤 엔진의 공기 흡입 질량 흐름의 성능에 대해 Intercooling의 효과를 결정할 수 있는 결과를 확인하였다(그림 11~12, [18]).



Figure 11 The comparisons of NN based model with experimental results for testing set (diesel engine without intercooling)







Figure 12 The performance of NN based model for diesel engine without intercooling

Roy는 인공신경망을 활용하여 다양한 EGR 변화에서 single-common rail direct injection engine의 성능 및 배출 가스를 예측하는 수치해석 연구를 하였다[20]. 하 지만 인공 신경망을 이용한 많은 연구는 연소실 내부의 일부 기능에만 초점을 맞 췄으며, 복잡한 제어 시스템을 포함하는 엔진 모델링에 관한 연구는 많지 않다. 특 히 강력해진 배기가스 규제에 대응하기 위해, 질소 산화물 배출을 감소시킬 수 있 는 EGR 시스템의 중요성은 높아졌다. EGR 시스템은 빠른 응답 속도 및 높은 정 확도를 주요 관점으로 검증을 해야 한다. 그러므로 엔진 성능 예측 뿐만 아니라 제 어 엔진 시스템을 효과적으로 개발 하기 위해서는 통합 제어 시스템의 제어 logic 이 필요하다.



Figure 13 Flow chart for Co-simulation

- 9 -





통합된 제어 logic을 가진 수치해석 모델은 Simulink를 활용한 Co-simulation을 통해 제어 성능 예측 및 검증할 수 있으며, Co-simulation는 각 서브 시스템의 요 구 사항에 맞는 모델링 및 솔루션 기술을 사용할 수 있다[27~32]. Co-simuation은 서로 다른 subsystem을 결합하여 다중 time 도메인이나 특정 및 전반적인 시스템 의 성능을 검증 할 수 있는 유연한 솔루션이다(그림 13~14). 특히 서브 시스템간의 통신은 그림 14처럼 특정 시간 간격에서 입력 및 출력량의 교환을 통해 조정된다.



Figure 14 Time domain of Co-simulation

두 하위 모델간의 simulation 변경과 하드웨어 환경간의 time 도메인은 Simulink 에서 제공하는 공통의 인터페이스인 Functional Mock-Up Interface(FMI) 표준과 S-Function 기능을 통해 해결할 수 있다[16-19]. FMI 표준은 Model-based system 개발 수단을 제공하며 자동차 내부의 전자 장치에 의해 구동되는 기능을 설계하는 데 사용된다. 이에 본 연구에서는 FMI 표준을 지원하는 MATLAB/Simulink를 사 용하여 Plant model의 EGR 시스템의 제어 logic을 구성하였다.





### 제 3 절 연구목표

본 연구에서는 HiL을 통한 실시간 수치해석 구현을 위한 Plant model 구축 방법 을 제시하고자한다. 더 나아가 1D-Plant model과 EGR 제어로직 간의 Co-simulation을 통해 충분한 정확도와 빠른 실행 속도를 지닌 가상의 Diesel mean value Plant engine model을 구축하는데 목적이 있다. 추가적으로 Plant model과 결합된 EGR 제어 logic 모델의 정확도 및 응답성을 검증하고자 한다. 이 를 위해 1D Plant model의 Draft model을 구축하여 엔진 주요 성능 결과 값을 실 험 값과 비교를 통해 모델 정확도를 검증하였다. 또한 인공 신경망 훈련을 사용하 여 Model reduction 과정을 진행하여 모델 실행 속도를 단축하였다. EGR 제어 logic 모델링은 MATLAB/ Simulink를 사용하여 구축하였다.



Figure 15 Flow chart for research in this thesis





## 제 2 장 방법론

#### 제 1 절 상세 모델

실시간 수치해석 접근을 위한 Plant model의 Base가 될 가상 엔진은 1차원 상용 해석 프로그램인 Gamma Technology사의 GT-SUITE을 사용하여 구축하였다. 그 릮 17는 플랜트 모델의 기본이 Detailed 될 diesel engine model로 서, intake/exhaust manifold, 4-cylinder, EGR, high-pressure turbocharger/intercooler와 같은 엔진 구성 요소를 포함하고 있고, 보정할 수 있는 포괄적 컨트롤러 모델(Target BMEP control, target EGR control, target fuel mass injection control)이 포함되어 있다. 사용된 엔진의 제원과 해석 되는 운전 영 역은 표 1-2에 나타냈었고, 그림 16을 통해 모델링된 운전영역을 나타내었다.

Item	Specification			
Displacement volume	1.4L			
Compression ratio	17:1			
Injection Type	Common rail direct injection			
EGR system	HP EGR			
Turbocharger	Waste-gate type			

Table 1 Engine specification

Engine speed[rpm]	BMEP[bar]
1000	2, 4, 8
1500	2, 9, 16
2000	2, 9, 16
2500	2, 9, 16

Table 2 Operating condition







Figure 16 Validated point of diesel detailed engine model



Figure 17 Detailed model







#### 1. Combustion modeling



Figure 18 Multi-pulse model in GT-Power

상세 모델의 연소 모델은 공기 흡입율, 연료 액적의 침투율, 점화지연, 기화 및 연소율을 계산하는 DI-Pulse(Direct-injection diesel multi-pulse) 연소 모델을 사용 했다[33, 34]. DI-Pulse 연소 모델은 현대의 분사 전략을 구현할 수 있도록 설계된 예측 연소 모델로서, 각 분사 펄스를 개별적으로 추적하고 직분사 디젤 엔진의 연 소 속도 및 관련 물리량을 예측할 수 있다. 이 모델은 그림 18처럼 현상학적인 다 구역 연소 모델로 실린더 내 체적을 3개의 구역으로 나눌 수 있다. 첫 번째 구간은 main un-burnt zone으로 흡기 밸브 닫힘(Intake valve closing)때 갇힌 질량을 포 함하며, 두 번째 구간은 spray un-burnt zone으로 분사 중에 포획된 연료와 가스 의 혼합물을 포함하고 있다. 마지막 구간은 spray burnt zone으로 연소된 연소 생 성물을 포함하고 있다. 이렇게 3구간 마다 실린더 내 연소 및 배출 관련 변수를 예 측한다. 특히 DI-Pules 모델는 연료가 분사되어 연소하기까지의 6단계 중에 디젤 연소 특징을 잘 나타내주는 4단계에서 다른 보정 승수를 사용하여 각 단계마다 다 른 방정식으로 계산할 수 있다.

#### 가. Fuel injection

DI-Pulse는 펄스 수에 제한 없이 단일/다단 펄스 인젝션 이벤트를 지원한다. 각 펄스는 별도로 추적되어 spray un-burnt zone에 추가된다. 연료 침투 길이 'S'는 분사 전에는 방정식 (1), 분사 후에는 방정식 (2)으로 시간 's' 도메인으로 계산된 다.





$$S = u_{inj} \bullet t \bullet \left[1 - \frac{1}{16} (\frac{t}{t_b})^8\right]; \quad when \frac{t}{t_b} \le 1$$
<sup>(1)</sup>

$$S = u_{inj} \bullet t \bullet \frac{15}{16} (\frac{t}{t_b})^{0.5}; \quad when \frac{t}{t_b} \ge 1$$
(2)

 $u_{inj}$ 는 인젝터 노즐 팁의 인젝션 속도이며,  $t_b$ 는 물방울에 스프레이가 분열 될 때 이다.  $u_{inj}$ 과  $t_b$ 는 방정식 (3) ~ (4)를 통해 계산 할 수 있다.

$$t_b = \sqrt{\frac{2 \cdot \rho_l}{\rho_g}} \cdot \frac{d_n}{C_d^* u_{inj}} \tag{3}$$

$$u_{inj} = C_d \sqrt{\frac{2\Delta P}{\rho_l}} \tag{4}$$

△P는 인젝터 노즐 양단의 압력 차이다.

#### 나. Entrainment model

Entrainment model은 운동량 보존에 기반을 두고, 연료가 실린더 환경에 분사됨 에 따라 신선한 공기, 잔류 가스 및 다른 펄스의 연료를 동반하여 방정식 (5)와 같 이 계산된다.  $m_{inj}$ 는 분사 연료 포켓의 초기 질량이며,  $m_{inj-entrained}$ 는 포켓에 수반되 는 공기의 질량 그리고 u는 들어오는 공기-연료 혼합물의 최종 속도이다.

$$m_{inj} \bullet u_{inj=(m_{inj}+m_{inj-entrained})} \bullet u; \quad where \ u = \frac{ds}{dt}$$
(5)

질량은 사출 속도에 밀접하게 의존하는 걸 알 수 있다(6).





$$m_{air-entrained} = \frac{m_{inj} \cdot u_{inj}}{u} \tag{6}$$

최종적으로 동반된 연료-가스 혼합물의 비율은 다음 방정식인 (7)과 같이 모델링 된다. *C<sub>ent</sub>는* 동반 승수(Entrainment multuplier)로 이 승수를 통해 연소 단계를 보 정할 수 있다.

$$\frac{dm}{dt} = -C_{ent} \cdot m_{inj} \cdot u_{inj} \cdot \frac{du}{dt}$$
(7)

#### 다. Evaporation

동반 연료 혼합 모델링 이후 다음 단계로서, 연료의 증발 단계 계산이다. 컨트롤 체적이 방울 주위에 가정되고 에너지 균형을 기반으로 방정식 (8)으로 나타낼 수 있다. 물방울의 내부 에너지의 변화는 뜨거운 동반 기체로부터 대류 열전달과 자체 증발의 결과로서의 에너지 방출의 합으로 계산된다.  $m_d$ 는 물방울의 질량이며,  $C_{pd}$ 는 물방울의 비열 용량이다.

$$m_d \cdot c_{pd} \cdot \frac{dT}{dt} = \frac{dQ_c}{dt} + \frac{dQ_e}{dt} \tag{8}$$

대류 열전달 비율은 다음 방정식 (9)로 나타낼 수 있다.  $d_d$ 는 물방울의 길이,  $T_g$ 는 동반 기체의 온도,  $T_d$ 는 물방울의 온도이다.

$$\frac{dQ_c}{dt} = h \cdot \pi \cdot d_d^2 \cdot (T_g - T_d)$$
(9)





엔탈피 변화로 인한 컨트롤 체적이 흡수된 열은 방정식 (10)에 의해 주어진다.  $\Delta H_{vd}$ 는 액적의 기화 잠열이며,  $\frac{dm_d}{dt}$ 는 액적의 증발 속도이다.

$$\frac{dQe}{dt} = -\frac{dm_d}{dt} \cdot \Delta H_{v_d} \tag{10}$$

#### 라. Ignition delay

점화 지연은 연료 분사 시작과 연소 시작 사이의 시간이다. 점화지연은 EGR의 방정식, 실린더 온도 및 세탄가의 함수로서 각 펄스에 대해 개별적으로 모델링된다 (11). *C<sub>ian</sub>는* 점화지연의 보정 승수이며, 승수를 통해 모델의 보정할 수 있다.

$$\tau_{ign} = C_{ign} \bullet \rho^{C_{ign2}} \bullet e^{\frac{C_{ign3}}{T}} \bullet f(EGR)$$
(11)

온도와 압력이 크랭크 각도의 함수로서 일정하게 변하기 때문에 점화 지연은 다 음 관계식의 의해 평가된다.

$$\int_{t_{soi}}^{t_{soi}+t_{id}} \frac{dt}{\tau(p,T)} = 1$$

$$\tag{12}$$

#### 마. Premixed combustion

예혼합 연소는 실린더 내부에서 자발화 가능한 조건에 도달 할 때 발생한다. 점화 지 연 기간 이후 전개된 혼합기가 연소의 예혼합 단계에서 사용되며, 또한 공연비 비율, EGR 분율, 운동 속도 상수와 같은 다른 인자들을 포함하여 방정식 (13)으로 계산된다. *C*<sub>m</sub>는 예혼합 연소의 보정 승수이며, 승수를 통해 모델의 보정할 수 있다.

$$\frac{dm}{dt} = C_{pm} \bullet m \bullet (t - t_{ign}) \bullet f(k, T, \lambda, EGR)$$
(13)

- 17 -

Collection @ chosun

위 방정식의 t는 연료 분사 후 시간이며,  $t_{ign}$ 는 점화지연 시간, k는 연소 반응에 대한 운동 속도 상수, m는 점화지연 기간 동안 발단된 공기-연료 혼합물의 질량이다.

#### 바. Diffusion Combustion

예혼합 연소 과정이 지난 후, reaction rate는 연료 및 공기 혼합물이 상대 속도에 의 해 제어된다. 확산 제어 연소에서 혼합물이 연소되는 속도는 EGR rate, 산소 농도, 실 린더 체적 및 혼합물의 질량에 의존한다. 확산 연소 승수인  $C_{df}$ 를 통해 연소를 보정할 수 있으며, 확산 연소 모델의 방정식은 (14)로 나타낼 수 있다.  $V_{cyl}$ 은 실린더의 체적, *m*는 확산 연소 단계에서 이용 가능한 공기-연료 혼합물의 질량이다.

$$\frac{dm}{dt} = C_{df} \bullet m \bullet \frac{\sqrt{k}}{\sqrt[3]{V_{cul}}} \bullet f(EGR, [O_2])$$
(14)





#### 2. $NO_x$ model

질소산화물(NOx) 배출 가스는 온도의 함수로 이루어진 extended Zeldovich mechanism으로 계산하였다. 일산화질소(NO)와 이산화질소(NO<sub>2</sub>)은 일반적으로 NOx 배기로 함께 분류되며, 이 중, 일산화 질소가 실린더 내부에서 생성되는 질소의 주된 생성물이다. 일반적으로, NO 형성을 지배하는 주요 반응 식은 다 음의 방정식에 의해 형성된다[35, 36].

$$O + N_2 \leftrightarrow NO + N$$
 (15)

$$N + O_2 \leftrightarrow NO + O$$
 (16)

$$N + OH \leftrightarrow NO + H \tag{17}$$

화염 구간에서의 NO형성은 다음의 방정식을 통해 빠르게 NO2로 형성 된다.

$$NO + HO_2 \leftrightarrow NO_2 + OH$$
 (18)

이어서, NO2의 NO로의 전환은 다음의 반응식을 통해 형성 된다.

$$NO_2 + O \leftrightarrow NO + O_2$$
 (19)





### 제 2 절 실험 계획법

#### 1. DI-Pulse 보정 승수 최적화

Reference model의 정상 상태 시험 결과와 DI-Pulse 연소 모델이 사용된 상세 디젤 모델 결과 사이의 신뢰도를 확보하기 위해 벨리데이션 포인트마다 실험 계획 법을 통해 DI-Pulse 보정 승수 최적화 과정을 진행하였다. 사용된 실험계획법 방법 으론 LHS(Latin Hypercube sampling) 방식을 사용하였다. LHS 모드는 그림 19와 같이 정의된 입력 범위를 균등하게 분할하여 샘플링 포인트를 무작위로 지정해주는 장점이 있다.



Figure 19 Latin Hypercube Sampling diagram

각각의 운전점에 대해서 표 3와 같이 DI-Pulse 모드의 보정 승수의 범위를 지정 하였고, 출력 변수로는 실린더의 최대 압력, BSFC, bsNOx를 출력 변수로 지정하 여 승수 최적화를 진행하였다.




Entrainment Rate Multiplier	[ 0.5 - 2.8 ]
Ignition Delay Multiplier	[ 0.1 - 2.0 ]
Premixed Combustion Rate Multiplier	[ 0.01 - 2.5 ]
Diffusion Combustion Rate Multiplier	[ 0.1 - 1.4 ]

Table 3 Input Variables and Their Ranges

DoE 과정이 끝나고 response optimization 과정을 통해 각 벨리데이션 포인트의 정상상태의 실런더 최대 압력, BSFC, *NO<sub>x</sub>* 배기량 결과 값과 적합한 승수들의 값 을 구하였다.



Figure 20 Comparison between response value and factor value(all samples)





#### 2. Model reduction process

이 연구의 초점은 광범위한 작동 조건에서 EGR 시스템의 제어 logic 알고리즘을 평가할 수 있는 충분한 정확도와 빠른 실행 속도를 가진 가상의 Diesel mean value plant engine model을 개발하는 것이다. Mean value model을 구축하기 위해 서는 Detailed model의 신뢰도를 바탕으로 mean value cylinder model에 입력되는 체적효율과 배기가스 온도와 같은 연소와 관련된 변수를 근사화 하는 과정이 필요 하다. 본 연구에서 사용된 고압 EGR을 갖는 터보 과급기 엔진의 경우, 체적 효율에 미치는 주요 인자는 엔진 속도, 연료량, 연료 분사 시기, EGR rate, 과급 온도 및 압력, 배기 온도 및 압력, EGR rate이다. 각 변수의 범위는 평균값 모델에서 일어 날 수 있는 작동조건을 충족 시키기 위해 변수의 범위를 과범위하게 지정하였다.

Engine Speed (rpm)	[ 1000 - 2500 ]
Total fueling (mg)	[ 3 - 38 ]
Injection timing (deg)	[ -35 - 0 ]
EGR rate (fraction)	[ 0 - 0.39 ]
Boost pressure (bar)	[ 1 - 2.5 ]
Boost temperature (K)	[ 300 - 410 ]
Back pressure (bar)	[ 1 - 1.35 ]
Back temperature (K)	[ 430 - 770 ]

Table 4 Input Variables and Their Ranges

표 4은 체적 효율에 영향을 주는 입력 변수와 변수 범위를 나타내었다. 인공 신경망 훈련에 충분한 입력값들을 얻기 위해, DI-Pulse 보정 승수 최적화를 위해 사용했던 LHS 모드를 사용하였다. 이는 시뮬레이션에 실용적이지 않은 조건을 배 제하고, 신경 네트워크를 학습하는데 필요한 충분한 시뮬레이션 값들을 얻기 위해 서 매우 중요하다. 이 연구에서는 물리적인 제약이 시뮬레이션 설계에 포함되어있 고, 이에 GT-Power에서 제공하는 RMS(Root mean squared) error를 참고하였다 [21]. 실험 설계 방법에 사용 된 샘플 수를 선택하고 상세 모델에 시뮬레이션 했다. 그림 22과 같이 인공 신경망 훈련 시에 많은 수의 시뮬레이션 실행 시간을 줄이기

- 22 -





위해 터보차저 부분은 detailed model에서 제거되었다. 제거된 터보차저를 대신하 여 압축기 출력 압력 및 온도, 터빈 입구 압력 및 온도를 과범위로 입력하였다.



Figure 22 Training modeling for neuron network training



Collection @ chosun

#### 제 3 절 평균값 엔진 모델

평균값 모델을 구축하는데 있어 가장 중요한 단계는 실린더의 세부 연소 모델을 하나의 평균값 실린더 모델로 대체하는 것이다. 자세히는 흡배기 매니폴드의 유량 흐름 구성 요소를 함께 묶음으로서 완전히 단순화시켰다. 또한 실린더 내 주요 성 능을 효율적으로 예측하기 위해 인공 신경망(Neural network)방법을 사용하였다 [37~46]. 인공 신경망 훈련은 기본적으로 각 뉴런을 통과하는 모든 입력 값에 대한 결과 값을 직관적으로 인식하게 함으로서, 수치해석 시간을 단축시키는 장점이 있 다. GT 프로그램을 통해 사용된 인공 신경망 훈련 방법은 총 5가지 방법으로 각각 의 다른 변형이 자동으로 테스트 되며, 최적의 신경망을 선택하였다.

첫 번째 방법은 전역 다항식(Global Polynomial)으로 아래의 2차 방정식을 사용 하여 출력 값을 계산한다[39, 40]. 아래의 방정식의 *u*는 모든 *m* 입력의 벡터이다.

$$y = \sum_{i=1}^{m} a_i u_i + \sum_{j=1}^{m} \sum_{i=1}^{m} b_{ij} - u_i u_j + C$$
(20)

두 번째 방법은 방사 기반의 함수를 사용하여 계산하는 방사형 기준(Radial



Figure 23 Radial Basis mode diagram

Basis)모드이다[41, 42]. 신경망을 구성하기 위해 함께 결합되는 개별 방사 기반 기능의 수(n)와 방정식 (21)에서 최적의 r값을 결정할 때 사용할 수 있는 반복과정

- 24 -

Collection @ chosun



의 수(I)를 입력해야한다. 아래의 방정식의 n는 뉴런의 수이며, u는 모든 m 입력의 벡터이다.

$$y = \sum_{j=1}^{n} (a_j \cdot \exp(-r^2 \| w_j - u \|)) + C$$
(21)

세 번째 방법은 자체 조직 로컬 선형(Self-Organizing Local Linear) 모드로서 그 림 24과 같으며 방정식 (22)으로 계산된다[43]. 이 수식의 *n*는 뉴런의 수이며 신경 망을 구성하기 위해 함께 결합되는 개별 선형 함수의 수를 나타낸다. 특히 각 뉴런 은 반복적인 방법을 사용하여 입력 공간 내의 물리적 위치에 할당된다. 또한 *Comp<sub>j</sub>*는  $||w_j - u||$ 의 최소값(가장 가까운 뉴런)에 해당하는 요소를 제외하고 모 든 요소가 0인 *n*×1 벡터를 의미한다.

$$y = \sum_{j=1}^{n} \left[ \left( \sum_{i=1}^{m} (a_{ij}u_i) + C_j \right) \bullet Comp_j (\|w_j - u\|) \right]$$
(22)



Figure 24 Self-Organizing Local Linear mode diagram





네 번째 방법으로 자체 조직 로컬 비선형(Self-Organizing Local Non-Linear) 모 드로서 방정식 (23)과 같이 계산된다[44]. 방정식의 변수는 자체 조직 로컬 선형 모 드와 같다. *Comp<sub>j</sub>는* ॥*w<sub>j</sub>−u*॥의 최소값(가장 가까운 뉴런)에 해당하는 요소를 제 외하고 모든 요소가 0인 *n*×1 벡터를 의미한다.

$$y = \sum_{j=1}^{n} \left[ \left( \left( \sum_{i=1}^{m} (a_{ij} u_i) + \sum_{i=1}^{m} (b_{ij} u_i^2) \right) C_j \right) \bullet Comp_j (\parallel w_j - u \parallel) \right]$$
(23)

마지막 인공 신경망 훈련 방법으로 다층 구조 연산 방식(Multi-layer feed forward) 모드로 모델 단축과정. 다층 구조 연산 방식은 그림 25와 같이 입력되는 값이 한 방향으로만 이동하여 각 층의 뉴런을 통과하며 결과 값을 얻으며, 네트워 크에 순환이나 루프가 없는 가장 단순한 유형이다. 다층 구조 연산 방정식은 방정 식 (24) 와 같이 결과 값을 계산하며, 각 층의 함수와 각층의 가중치와 특성 값을 방정식 (25)~(27) 에 나타내었다[45, 46].



Figure 25 Multi-layer feed forward

Multi-layer feed forward :  $y = f(w \cdot q \cdot (z \cdot h(v \cdot u + a) + b) + c)$  (24)

1<sup>st</sup> Layer : 
$$h(x) = -1 + \frac{2}{(1 + e^{-2x})}$$
 (25)

$$2^{st}$$
 Layer :  $h(x) = -1 + \frac{2}{(1 + e^{-2x})}$  (26)

Output Layer : 
$$f(x) = x$$
 (27)

v,a은 1층의 가중치와 특성 값이며 z,b는 2층의 가중치와 특성 값, w,c는 출력 층의 가중치와 특성 값을 포함하고 있다.



이 연구에서는 5가지의 인공 신경망 훈련을 진행하고, 최적의 인공 신경망 방법 으로 3중 구조 연산 방식(3-Layer Feed Forward)을 채택하였다. 인공 신경망 훈련 의 입력 값은 Detailed model의 시뮬레이션 결과 값을 사용하였다. 총 7가지 매개 변수(엔진 속도, 흡기 매니폴드의 압력과 연료 가스 분율, 배기 매니폴드의 압력, 연료량, EGR rate, 연료 분사시기)를 평균값 모델의 주요 성능 인자인 실린더의 체 적 효율과 배기가스 온도를 예측하였다. 인공 신경망 훈련 결과 값들은 하위 모델 로 평균값 엔진 모델의 평균값 실린더 모델링에 포함하였다. 또한 흡기/배기 매니 폴드의 유량의 흐름을 하나의 객체로 단축하였다. 이는 인공 신경망을 통해서 실린 더의 체적 효율을 직관적으로 예측가능하기 때문에 단축 할 수 있다. 평균값 실린 더 모델은 전반적은 엔진 모델의 실행 속도를 감소하였으며, 엔진 모델의 단축 과 정을 통해 모델의 복합성을 크게 감소시켰다. 최종적인 평균값 모델은 그림 26와 같이 4개의 평균값 실린더, 단축된 흡기 및 배기 매니폴드, HP-EGR와 같은 주요 엔진 시스템 구성 요소만을 포함하고 있다.



Figure 26 Diesel mean value engine model



## 제 4 절 SISO 연계

이 연구는 실시간 수치 해석을 위한 짦은 시간의 실행 속도를 가진 mean value model 구축뿐만 아니라, 구축한 diesel mean value model과 EGR 제어 logic을 결 합하여 EGR 제어 시스템의 응답성 및 정확도를 검증하고자 한다. 검증을 위해 본 연구에 사용 된 프로그램 인 MATLAB/Simulink는 FMI 표준 기능을 가지고 있으 며 1D-diesel mean value model을 MATLAB 환경에서 모델 시뮬레이션을 할 수 있습니다. 위에서 구축된 diesel mean value model에 사용되는 고압 EGR 제어 시 스템은 SISO(single-input and single-output)시스템으로 간단한 가변 제어 logic을 구성하였다. SISO 시스템은 그림 27와 같이 하나의 입력에 대해 하나의 출력을 다 루는 시스템으로, 시스템의 입력과 출력간의 관계를 다루며 전달함수를 계산하여 제어 대상을 제어한다.



Figure 27 Single input single output(SISO) system : A sampled-data feedback control system

EGR 제어 로직에는 일반적인 컨트롤러 유형 인 PID 컨트롤러가 사용되었습니다. PID 컨트롤러는 기본적으로 피드백 루프를 포함하고 있어, 제어하고자 하는 대상 의 출력 값을 측정하여 측정값과 원하고자 하는 참조 값(reference value) 혹은 설 정 값(set point)과 비교하여 오차(error)를 계산한다. PID 컨트롤러의 제어 출력 값 은 방정식 (28)으로 나타낼 수 있다[47].

$$u(t) = k_p \left( e(t) + \frac{1}{T_I} \int_0^t e(\tau) d\tau + T_D \frac{de(t)}{dt} \right)$$
(28)

- 28 -



위 방정식의 u(t)는 제어 출력이며,  $k_p$ 는 비례이득 상수,  $T_I$ 는 적분 시간 상수,  $T_D$ 는 미분 시간 상수를 포함하고 있으며, e(t)라는 오차 신호를 포함하고 있다. u(t)는 현재의 오차 e(t)에 비례하는 양을 만들어 내는 비례동작과 과거에서 현재 까지의 오차 누적값에 비례하는 양을 생성하는 적분 동작 및 오차의 증가 혹은 감 소하는 경향의 정도에 비례하는 양을 만들어 내는 미분 동작 등의 3가지 값들을 합산한 값으로 주어진다.



Measured State

Figure 28 Block diagram of PID control

그림 29는 최종적으로 MATLAB/simulink와 결합한 1D Plant model을 보여준다.



Figure 29 Mean value SISO model

- 29 -





# 제 3 장 결과

#### 제 1 절 상세 모델 신뢰도

가상의 plant model의 모델 정확도를 평가하기 위해 엔진 속도 및 부하가 다른 조건에서 시뮬레이션 평가를 수행하였다. GT-Power로 구축된 모델은 과도 응답 테스트에서 요구하는 작동 조건을 만족시키기 위해 다양한 운전 조건을 구현하였 다. 구현된 수치 모델 내의 보정 매개변수가 포함되어 있다. 이러한 엔진 시스템 보정 매개변수는 실험계획법을 통해 실행착오를 걸쳐 최종적으로 결정하였다. 전반 적으로 엔진 시스템과 제어 시스템을 포함하고 있는 detailed model은 NEDC cycle 의 다빈도 운전 영역의 정상상태 시험 결과에 대해 광범위하게 검증하였다. 그림 30는 엔진 시스템의 주요 성능인 BSFC, 실린더 최대 압력, EGR rate, BNOx의 정 상 상태 시험 결과와 시뮬레이션 해석 결과를 보여준다. Detailed model는 엔진 시 스템의 주요 성능 인자에서 정상상태 시험 결과와 5%이내의 오차를 가지는 걸 확 인 할 수 있다.



Figure 30 Comparison between measured result and predicted result : BSFC

- 30 -







Figure 31 Comparison between measured result and predicted result :  $P_{\text{max}}$ 



Figure 32 Comparison between measured result and predicted result : EGR ratio

- 31 -







Figure 33 Comparison between measured result and predicted result :  $BNO_x$ 

DI-Pulse 연소 모델을 통해 디젤 연소를 구현하는 detailed model는 그림 34~37 을 통해 엔진 실린더의 압력 및 열 방출 율을 볼 수 있다. 특히 열 방출 율은 low phase/high phase, 총 2단계로 나눠지는 형태를 볼 수 있는데, 이는 다단분사 (Common rail direct injection, CR-DI)를 통해 단계적으로 연소 하는 다단 압축착 화 엔진의 특징을 알 수 있다. 이러한 열 방출율의 영향을 받아 실린더의 압력 역 시, 모든 운전 포인트에서 열 방출 율과 유사한 시기에 실린더 압력이 증가하는 경 향을 볼 수 있다.







Figure 34 In-cylinder pressure and Gross heat release rate of detailed model : 1000RPM



Figure 35 In-cylinder pressure and Gross heat release rate of detailed model : 1500RPM







Figure 36 In-cylinder pressure and Gross heat release rate of detailed model : 2000RPM



Figure 37 In-cylinder pressure and Gross heat release rate of detailed model : 2500RPM





# 제 2 절 Artificial neural network training and Mean value model

인공 신경망 훈련을 통해 구축된 diesel mean value model의 정확도를 파악하기 위해 전반적인 엔진 및 제어 시스템의 성능을 detailed model과 비교하였다.그림 38~45은 mean value model의 실린더에 들어가는 체적효율과 배기가스 온도에 대 한 인공 신경망 훈련 결과이다.



Figure 39 Training output data : Volumetric Efficiency of NNT results

- 35 -







Figure 41 NNT total data : Volumetric Efficiency







Figure 43 Training output data : Exhaust temperature of NNT results











Figure 45 NNT total data : Exhaust temperature

체적 효율의 경우(그림 39) 훈련 입력 값과 인공 신경망 훈련 결과는 비선형적인 모습을 보여준다. 특히 훈련 결과 데이터의 경우 0.6과 0.7 부분은 예측하지 못하였 다. 이는 체적효율을 예측 훈련을 할 때, 필요 없는 변수를 제거 하지 않았기 때문 에 정확도의 손실이 생겼다. 또한 배기가스 온도의 경우 400K~1200K까지는 선형적 으로 잘 예측하였지만, 입력 데이터의 부족으로 1200K~1400K 부분은 예측하지 못 하였다. 이러한 예측 부정확성은 mean value model의 성능 인자에 정확도 손실을 이끈다.

인공 신경망 훈련을 통해 예측된 체적 효율과 배기가스 온도로 구축된 diesel mean value model을 표 5의 주요 운전 조건에서 엔진 성능 예측 시뮬레이션을 진 행했다.

Case number	Engine speed [RPM]	BMEP [bar]	Fuel mass rate [cycle/mg]	Total EGR rate [%]
Case 1	1500	2	5.52	34.7
Case 2	1500	9	20.51	13.3
Case 3	1500	16	37.55	0
Case 4	2500	2	6.19	14.8
Case 5	2500	9	20.01	9.9
Case 6	2500	16	34.01	0

Table 5 Mean value model operating condition

또한 그림 46~50는 detailed model과 mean value model의 엔진 성능을 비교한 그래프이다. 체적 효율의 경우(그림 46) case 3과 case 4의 운전 조건에서 mean value model은 detailed model에 비해 낮은 값으로 예측하는 걸 알 수 있다. 또한 전반적인 운전 점에서 mean value model은 detailed model에 비해 낮은 BSFC를 예측한다. 공연비의 경우(그림 47), case 1, 4와 case 3, 6와 같은 저부하, 고부하 운 전 영역에서는 detailed model의 비해 mean value model이 적은 값을 얻는 걸 볼 수 있다. 특히 case 4의 경우 가장 큰 BSFC 차이를 보인다. 이는 위에서 언급한 인공 신경망 훈련 결과의 오차 때문에 큰 오차를 가진다. 인공 신경망 훈련 결과의 오차는 결과적으로 체적효율과 공연비에서 저부하와 고부하에서 비교적 수용할 수 있는 오차가 존재하며, 체적 효율의 인공 신경망 훈련 오차는 BSFC를 과소하 게 예측한다. 또 다른 이유로서 mean value model의 분사방식이다. Detailed model



은 다단 분사 방식으로 일정 기간에 연료를 분사하는 방식이었다면, mean value engine model의 분사 방식은 단일 분사 방식을 사용한다. Mean value model에 사 용하는 단일 연료 분사 방식은 1-cycle 동안에 연료량을 균일하게 나눠 분사하는 방식이다. 즉, detailed model과 달리 mean value model의 연료 분사 방식이 변경되 어, 연료 분사시기에 상관없이 연료가 분사되기 때문에 연료 소비 율에 영향을 주 게 되었다.



Figure 46 Comparison between detailed model result and mean value model result : Volumetric efficiency, Air







Figure 47 Comparison between detailed model result and mean value model result : Air/Fuel Ratio



Figure 48 Comparison between detailed model result and mean value model result : Brake Torque







Figure 49 Comparison between detailed model result and mean value model result :BSFC



Figure 50 Comparison between detailed model result and mean value model result : EGR rate





이 연구의 주 목적은 빠른 실행속도를 가진 평균값 모델 구현 및 EGR 제어 logic 검증이므로 mean value model의 IMEP, 터보차저의 경우 Lookup-table으로 입력하 였다. 그러므로 평균값 모델의 Brake Torque(그림 48)는 detailed model의 결과와 일치한다.특히 연구의 목적인 EGR 제어 logic(그림 50)의 정확도 경우, mean value model은 목표 EGR rate를 정확하게 예측하였다. 결과적으로 인공 신경망 훈 련의 예측 손실로 약간의 엔진 성능 변수의 정확도가 감소하였지만, mean value model은 detailed model의 해석 결과와 합리적으로 일치함을 알 수 있었다. 이에 추가적으로 연속적인 엔진 속도를 포함하는 광범위한 작동 조건에서 EGR 제어 logic을 결합한 diesel mean value SISO model을 제어 시스템 관점으로 평가하고 자 한다.





## 제 3 절 Step-transient Test

Simulink의 EGR 제어 logic과 결합한 가상의 diesel mean value SISO model의 제어 정확도를 심층적으로 검증하기 위해 시간에 따라 속도와 목표 EGR rate이 변화하는 연속적인 가속 및 감속 조건 모사 시뮬레이션 진행했다. Step-transient test의 기준점을 삼고자 simulink의 EGR 제어 logic이 포함하지 않는 mean value model을 동일한 운전 조건에서 시뮬레이션 하였다. EGR 제어 logic의 검증을 위해 매우 짧은 시간에 2번의 엔진 속도 변화와 4번의 EGR rate 변화를 가지는 복잡한 과도 단계 시험 조건을 구축하였다. 시험 조건과 속도/목표 EGR rate 변화는 표 6과 그림 51~54에 나타냈다.

Case number	Engine speed	BMEP	Fuel mass rate	Total EGR rate
	[RPM]	[bar]	[cycle/mg]	[%]
Case 1	1500	2	5.52	34.7
Case 2	1500	9	20.51	13.3
Case 3	1500	16	37.55	0
Case 4	2500	2	6.19	14.8
Case 5	2500	9	20.01	9.9
Case 6	2500	16	34.01	0

Table 6 Optimized parameter values at each conditions







Figure 51 Acceleration step transient conditions as a function of speed and BMEP



Figure 52 Acceleration step transient conditions as a function of time and speed











Figure 54 Deceleration step transient conditions as a function of speed and BMEP





## 1. 가속 조건 모사

가속 조건 모사에서 시간에 따른 Total mass flow와 EGR rate 변화를 그림 55~56에서 보여준다. EGR rate(그림 56)을 통해 ST #1 구간에서는 0-8초까지 EGR rate 응답성이 overshooting 형태를 확인 할 수 있다. 이는 PID 컨트롤러의 비례대가 좁기 때문에 보이는 제어 컨트롤러의 응답 특성이다. 또한 체적효율(그림 55)에서 0-3초 사이의 큰 hunting 없이 부드럽게 ST #1의 체적효율을 달성하였다. 체적 효율 역시, 유사한 3.6초에 수렴하였다. 또한 ST #2의 경우 유사한 EGR rate이지만 속도가 가속되기 때문에 10초 동안 undershooting을 확인 할 수 있다. 또한 diesel mean value SISO model은 30초대에서 다소 증가하는 경향으로 인해 생긴 undershooting으로 보인다. 또 다른 이유로는 PID 컨트롤러의 적분시간이 크 기 때문에 생기는 응답 특성으로 볼 수 있다. 하지만 30초 이후 제어 응답성이 안 정화되면서 목표 EGR rate를 달성한다. 따라서 ST #3, ST #4 구간에서는 제어 시 스템의 응답 속도에 지체가 있지만 목표 EGR rate 값에 도달하는 걸 알 수 있다. 모든 구간에서 EGR rate은 10초 이내의 목표 EGR rate 으로 수렴한다. 또한 체적 효율도 EGR rate과 비례하게 구간이 바뀌는 경계층에서 변화가 있다. 하지만 EGR rate에 비해 빠른 시간에 제어 응답이 안정화된다.







Figure 55 Comparison between mean value model result and mean value SISO model result at acceleration step transient conditions : Volumetric efficiency



Figure 56 Comparison between mean value model result and mean value SISO model result at acceleration step transient conditions : EGR rate





## 2. 감속 조건 모사

그림 57758 은 감속 단계 과도 시험 조건에서 시간에 따른 EGR rate, 체적 효율 변화를 보여준다. 감속 조건은 가속 조건과 다르게 모든 속도 변환 구간에서 undershooting을 확인할 수 있다. 특히 ST #1에서 8초만에 목표 EGR rate를 달성 했지만, 속도가 급감되는 ST #2의 경우 30초에서 약 3초간 EGR rate이 10%까지 떨어졌다가 overshooting를 통해 목표 EGR rate에 달성하는 걸 볼 수 있다. 그림 56 의 체적효율에서 볼 수 있듯이, 30초대의 오버 슛에 영향을 받았을 것 이다. 그 리고 EGR rate이 급격하게 줄어드는 ST #3 구간에서는 응답 지연이 있지만, 다른 구간에 비해 비교적 빠르게 목표 EGR rate에 도달한다. 결과적으로 급격한 EGR rate 변화는 응답 속도에 영향을 주어, 응답 속도가 느려지고 수렴시간에도 영향을 준다. 이러한 이유는 PID 제어기의 잔류편자가 작지만, I 동작이 약하기 때문에 응답성이 느려졌다는 걸 나타낸다. 하지만 모든 속도 및 EGR rate 변화 구간에서 10초 이내의 목표 값에 도달하며, PID 제어기의 제어 대상이 정상편차(Steady stat error)에 수렴했다는 걸 보여준다. 또한 체적 효율의 경우 디젤 평균값 엔진 모델과 유사한 형상을 보여준다.



- 49 -





Figure 57 Comparison between mean value model result and mean value SISO model result at deceleration step transient conditions : Volumetric efficiency



Figure 58 Comparison between mean value model result and mean value SISO model result at deceleration step transient conditions : EGR rate





### 제 4 절 Model accuracy and run-time summary

모텔 정확도와 실행속도의 trade-off는 Draft model, mean value model 그리고 simulink와 결합한 mean value SISO model에 대해 비교 평가하였다.그림 59은 무 수히 많은 복잡성을 가진 모델에 대한 모델 예측 정확도 및 수치 해석 실행 속도 를 비교한 것이다. 인공 신경망으로 구축된 mean value model의 모델 정확도는 Draft model과 비교하여 약 3% 정도 정확도의 손실이 있다. 이는 주로 체적 효율 과 배기 가스 온도를 훈련할 때 생긴 사소한 오차와 예측 결과 부족 때문이다. 또한 mean value SISO model의 경우 순수한 mean value model와 유사한 정확도를 가 진다. 그러나 모델 실행 속도의 경우 이 연구를 통해 인공 신경망 훈련을 통해 구 축된 mean value model의 경우 기존의 detailed model에 비해 약 2배 정도 빠른 run-time를 가졌다. 또한 구축된 가상의 mean value SISO model은 제어 시스템의 logic를 단순화 시켜 mean value model에 결합해 주었기 때문에 mean value model에 비해 감소된 run-time를 가진다. 결과적으로 가상의 mean value SISO model은 모델 정확도는 약간 손실하였지만, 기존의 detailed model보다 빠른 해석 시간을 가지게 되었다.



Figure 59 Trade-off of model error and model run time

- 51 -





## 제 4 장 요약 및 정리

본 연구에서는 실시간 수치해석을 위한 가상의 Plant model구축으로 인공 신경망 훈련을 통해 모델 단축 과정을 진행하였고, mean value model과 EGR 제어 logic 를 결합하여 step-transient simulation 진행하여 EGR 제어 logic의 응답 특성을 조 사하였다. 주요 결과는 다음과 같다.

첫째, plant model의 base model을 구축하기 위해 디젤 연소 모드를 모사할 수 있는 DI-Pulse 모드를 사용하여, detailed model를 구축하였다. DI-Pulse 모드의 4 가지의 보정 승수는 실험 계획법의 라틴 하이퍼 큐브 방법을 사용하여 각 운전점 에 대해 최적화하였다.

둘째, diesel mean value engine model 구축을 위해 흡기 및 배기 매니폴드의 유 량 흐름 구성 요소를 함께 묶음으로서 완전히 단순화하였다. 또한 인공 신경망은 mean value cylinder model의 입력 변수인 체적 효율과 배기가스 온도의 경우 detailed model의 시뮬레이션 결과를 근사화 하는데 사용되었다. 인공 신경망 훈련 방식 중 하나인 다층 구조 연산 방정식을 사용하였다. 체적 효율의 경우 detailed model의 시뮬레이션 값들이 비선형적인 모습으로 입력되어 체적 효율의 훈련 결과 는 0.6, 0.7부분은 예측하지 못하였다. 배기가스 온도의 경우 상세 모델의 시뮬레이 션 값들이 충분하지 않아 배기가스 온도의 훈련 결과 1200-1400K 부분은 예측하지 못하였다.

셋째, 가속 조건 모사 시뮬레이션을 통해 모델 기반 제어가 목표 값을 잘 따르도 록 허용하였다. 하지만 체적 효율의 사소한 변화에 따라 EGR rate는 ST #1 구간 과 ST #2 구간에서 초기 10초 동안 overshooting과 undershooting 경향을 보였다. 이러한 응답 특성은 PID 컨트롤러의 비례대가 좁고, 적분 시간이 크기 때문에 보 이는 특징이다. 모든 구간에서 응답 지연이 존재하지만 10초 안에 목표 EGR rate 값에 도달하는 걸 알 수 있다.

넷째, 더욱 복잡한 변화를 가지고 있는 감속 조건 모사 시뮬레이션을 통해 EGR logic의 응답 특성을 재확인하고자 하였다. 가속 조건 모사와 달리 전반적인 속도 변화 구간에서는 undershooting 응답 특성을 확인 할 수 있었다.이러한





undershooting의 경향은 가속 조건 변화에 비해 큰 폭을 가지고 있으며, 이는 PID 제어기의 잔류편자가 작고, I 동작이 약하기 때문에 응답성이 느려진 걸 나타낸다. 다섯째, 모델 정확도와 run-time의 경우 diesel detailed model과 비교할 때, diesel mean value model의 정확도는 실린더의 체적 효율의 손실 때문에 약 3%의 손실을 얻었다. 하지만 mean value model의 시뮬레이션 run-time의 경우, 홉배기 매니폴 드의 유량 흐름 구성요소 단축 및 인공 신경망을 통해 엔진의 주요 성능 변수를 직관적으로 예측하기 때문에 약 2배 정도 감소되었다. 또한 연구를 통해 구축된 mean value SISO model은 모델 정확도와 실행 속도의 좋은 균형을 이루었다.





#### REFERENCES

- Mei, J., et al., Aggregation-induced emission: together we shine, united we soar! Chemical reviews, 2015. 115(21): p. 11718-11940.
- Zhao, Z., B. He, and B.Z. Tang, Aggregation-induced emission of siloles. Chemical science, 2015. 6(10): p. 5347–5365.
- Liu, Z., et al., Reduced carbon emission estimates from fossil fuel combustion and cement production in China. Nature, 2015. 524(7565): p. 335.
- Knecht, W., Diesel engine development in view of reduced emission standards. Energy, 2008. 33(2): p. 264–271.
- Baert, R.S., D. Beckman, and A. Veen, Efficient EGR technology for future HD diesel engine emission targets. SAE transactions, 1999: p. 381–393.
- 6. Arnold, S.D., Dual path EGR system and methods. 2005, Google Patents.
- Wang, J. Air fraction estimation for multiple combustion mode diesel engines with dual-loop EGR systems. in 2007 46th IEEE Conference on Decision and Control. 2007. IEEE.
- Zheng, M., G.T. Reader, and J.G. Hawley, Diesel engine exhaust gas recirculation - a review on advanced and novel concepts. Energy conversion and management, 2004. 45(6): p. 883–900.
- Park, J., et al., Numerical study of a light-duty diesel engine with a dual-loop EGR system under frequent engine operating conditions using the DOE method. International Journal of Automotive Technology, 2010. 11(5): p. 617-623.
- Maroteaux, F. and C. Saad, Combined mean value engine model and crank angle resolved in-cylinder modeling with NOx emissions model for real-time Diesel engine simulations at high engine speed. Energy, 2015. 88: p. 515–527.
- Yu, M.X., et al., Diesel engine modeling based on recurrent neural networks for a hardware-in-the-loop simulation system of diesel generator sets. Neurocomputing, 2018. 283: p. 9–19.





- Yi, L., H. He, and J. Peng, Hardware-in-loop simulation for the energy management system development of a plug-in hybrid electric bus. Energy Procedia, 2016. 88: p. 950–956.
- 13. Heidrich, L., et al., Hardware-in-the-loop test rig for integrated vehicle control systems. IFAC Proceedings Volumes, 2013. 46(21): p. 683-688.
- and L. Eriksson, 14. Wahlström, J. Modelling diesel engines with а variable-geometry turbocharger and exhaust recirculation gas by optimization of model parameters for capturing non-linear system dynamics. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2011. 225(7): p. 960-986.
- He, Y. and C.-C. Lin (2007). Development and validation of a mean value engine model for integrated engine and control system simulation, SAE Technical Paper.
- Lujan, J.M., et al., Volumetric efficiency modelling of internal combustion engines based on a novel adaptive learning algorithm of artificial neural networks. Applied Thermal Engineering, 2017. 123: p. 625–634.
- Shamekhi, A.-M. and A.H. Shamekhi, A new approach in improvement of mean value models for spark ignition engines using neural networks. Expert Systems with Applications, 2015. 42(12): p. 5192–5218.
- Uzun, A., Air mass flow estimation of diesel engines using neural network. Fuel, 2014. 117: p. 833–838.
- Zarghami, M., S.H. Hosseinnia, and M. Babazadeh, Optimal Control of EGR System in Gasoline Engine Based on Gaussian Process. IFAC-PapersOnLine, 2017. 50(1): p. 3750–3755.
- 20. Roy, S., R. Banerjee, and P.K. Bose, Performance and exhaust emissions prediction of a CRDI assisted single cylinder diesel engine coupled with EGR using artificial neural network. Applied Energy, 2014. 119: p. 330–340.
- 21. Theotokatos, G., et al., Development of an extended mean value engine model for predicting the marine two-stroke engine operation at varying settings. Energy, 2018. 143: p. 533-545.





- Turkson, R.F., et al., Artificial neural network applications in the calibration of spark-ignition engines: An overview. Engineering Science and Technology, an International Journal, 2016. 19(3): p. 1346–1359.
- Isermann, R. and H. Sequenz, Model-based development of combustion-engine control and optimal calibration for driving cycles: general procedure and application. IFAC-PapersOnLine, 2016. 49(11): p. 633-640.
- Rida, A., et al., Modeling and simulation of the thermodynamic cycle of the Diesel Engine using Neural Networks. IFAC-PapersOnLine, 2016. 49(3): p. 221-226.
- Xie, H., et al., Model-based decoupling control of VGT and EGR with active disturbance rejection in diesel engines. IFAC Proceedings Volumes, 2013. 46(21): p. 282–288.
- 26. Cieslar, D., et al., Model based approach to closed loop control of 1–D engine simulation models. Control Engineering Practice, 2014. 29: p. 212–224.
- Li, W.L., X.B. Zhang, and H.M. Li, Co-simulation platforms for co-design of networked control systems: An overview. Control Engineering Practice, 2014.
   23: p. 44–56.
- Turkson, R.F., et al., Artificial neural network applications in the calibration of spark-ignition engines: An overview. Engineering Science and Technology, an International Journal, 2016. 19(3): p. 1346–1359.
- Quaglia, D., et al., A SystemC/Matlab co-simulation tool for networked control systems. Simulation Modelling Practice and Theory, 2012. 23: p. 71–86.
- 30. Rao, K.D., Modeling, simulation and control of semi active suspension system for automobiles under matlab simulink using pid controller. IFAC Proceedings Volumes, 2014. 47(1): p. 827–831.
- 31. Casoli, P., et al., Development and application of co-simulation and "control-oriented" modeling in the improvement of performance and energy saving of mobile machinery. Energy Proceedia, 2014. 45: p. 849–858.
- 32. Pedersen, N., J. Madsen, and M. Vejlgaard-Laursen, Co-Simulation of




Distributed Engine Control System and Network Model using FMI & SCNSL. IFAC-PapersOnLine, 2015. 48(16): p. 261–266.

- 33. Jung, J., S. Song, and K.B. Hur, Numerical study on the effects of intake valve timing on performance of a natural gas-diesel dual-fuel engine and multi-objective Pareto optimization. Applied Thermal Engineering, 2017. 121: p. 604-616.
- 34. Ansari, E., et al., Efficiency and emissions mapping of a light duty diesel-natural gas engine operating in conventional diesel and RCCI modes. 2016, SAE Technical Paper.
- Gupta, H.N., Fundamentals of internal combustion engines. 2012: PHI Learning Pvt. Ltd.
- 36. Miller, R., et al., A super-extended Zel'dovich mechanism for NO x modeling and engine calibration. SAE transactions, 1998: p. 1090-1100.
- 37. Haykin, S., Neural networks: a comprehensive foundation. 1994: Prentice Hall PTR.
- 38. Hagan, M.T., et al., Neural network design. Vol. 20. 1996: Pws Pub. Boston.
- 39. Cohen, M.A. and S. Grossberg, Absolute stability of global pattern formation and parallel memory storage by competitive neural networks. IEEE transactions on systems, man, and cybernetics, 1983(5): p. 815–826.
- Karunasinghe, D.S. and S.-Y. Liong, Chaotic time series prediction with a global model: Artificial neural network. Journal of Hydrology, 2006. 323(1-4): p. 92-105.
- 41. Park, J. and I.W. Sandberg, Universal approximation using radial-basis-function networks. Neural computation, 1991. 3(2): p. 246–257.
- 42. Chen, S., C.F. Cowan, and P.M. Grant, Orthogonal least squares learning algorithm for radial basis function networks. IEEE Transactions on neural networks, 1991. 2(2): p. 302–309.
- 43. Becker, S. and G.E. Hinton, Self-organizing neural network that discovers surfaces in random-dot stereograms. Nature, 1992. 355(6356): p. 161.
- 44. Demartines, P. and J. Hérault, Curvilinear component analysis: A





self-organizing neural network for nonlinear mapping of data sets. IEEE Transactions on neural networks, 1997. 8(1): p. 148-154.

- 45. Hornik, K., M. Stinchcombe, and H. White, Multilayer feedforward networks are universal approximators. Neural networks, 1989. 2(5): p. 359–366.
- 46. Svozil, D., V. Kvasnicka, and J. Pospichal, Introduction to multi-layer feed-forward neural networks. Chemometrics and intelligent laboratory systems, 1997. 39(1): p. 43-62.
- 47. Ang, K.H., G. Chong, and Y. Li, PID control system analysis, design, and technology. IEEE transactions on control systems technology, 2005. 13(4): p. 559–576.

