

딥러닝을 활용한 실가상 데이터 기반 가상환경 차량 동역학 모델링 자동화 프로세스 구축

전형석¹⁾ · 유재승²⁾ · 김도연²⁾ · 이기범^{*2)}
주식회사 모라이¹⁾ · 가천대학교 기계공학과²⁾

Automated Modeling Pipeline for Vehicle Dynamics Incorporating the Virtual-Real Dataset Using Deep Learning

Hyeongseok Jeon¹⁾ · Jaeseung Yu²⁾ · Doyeon Kim²⁾ · Kibeom Lee^{*2)}

¹⁾MORAI Inc., 16 Teheran-ro 78-gil, Gangnam-gu, Seoul 06194, Korea

²⁾Department of Mechanical Engineering, Gachon University, Gyeonggi 13120, Korea

(Received 9 May 2025 / Revised 19 August 2025 / Accepted 22 August 2025)

Abstract : Since various systems are becoming automated, ensuring the safety and robustness of their software is crucial. Automated systems in robots and/or vehicles often rely on various virtual simulation pipelines, as failures observed on hardware platforms can lead to critical safety issues. The introduced simulation system can support virtual testing of the automated system, and digital twin technology is combined to replace the hardware testing procedure. However, the dynamic characteristics of the platform must be modeled using numerous parameters, many of which are difficult to obtain in real-world settings. Therefore, in this study, we introduce an automated pipeline for setting up a virtual hardware platform that takes dynamic characteristics into account, using vehicle maneuvering datasets from both real-world and virtual environments. This deep learning-based automated virtual dynamics setup pipeline ensures sufficient modeling scalability and accuracy to serve as an effective substitute for hardware platform testing.

Key words : Virtual vehicle dynamics(가상 차량 동역학), Simulation(시뮬레이션), Deep learning(딥러닝), Multi-domain dataset(다중 도메인 데이터셋)

Nomenclature

s_t^{ch} : chassis hidden status at time t
 s_t^{veh} : vehicle status at time t
 x_t : control input from the driver at time t
 f_{pt} : time propagation network module for chassis
 vx_t^{veh} : x-directional velocity of the vehicle at time t
 vy_t^{veh} : y-directional velocity of the vehicle at time t
 ω_t^{veh} : angular velocity of the vehicle at time t
 acc_t : pedal input from the driver (0~1) at time t
 brk_t : pedal input from the driver (0~1) at time t
 str_t : steering angle of the vehicle at time t
 f_{sus} : network module which describes the suspension

s_t^{body} : body status at time t
 r_t^{body} : roll angle of the body at time t
 p_t^{body} : pitch angle of the body at time t
 \hat{s}_t^{body} : predicted body status at time t

1. 서론

모바일 로봇, 자율주행 자동차를 포함하여 최근에는 농업이나 방산업계의 다양한 플랫폼에 무인화가 계속적으로 진행되고 있다.¹⁾ 이와 같이 다양해진 플랫폼들은 온로드 영역뿐 아니라 오프로드의 험란한 지형에서도 미션을 수행할 수 있도록 동작 영역이 확대되고 있다. 기존의 자율주행 시스템은 급격한 움직임과 떨림 등으로 인하여

*Corresponding author, E-mail: kibeom.lee@gachon.ac.kr

¹⁾This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium provided the original work is properly cited.

오프로드 환경에서 알고리즘 성능이 저하될 수 있어, 다양한 환경에서의 검증이 필수적이다. 하지만 다양한 지형 및 노면에서의 자율주행 시스템의 시험 및 검증은 많은 비용과 시간이 소비되기 때문에 시뮬레이션으로 많은 검증이 대체되고 있다.

이와 같이 가상환경에서 모션이 중요한 상황을 시뮬레이션하기 위해서는 실제 플랫폼이 보이는 동역학적 특성을 정밀하게 모델링 하여 정합성을 높이는 것이 매우 중요하다. 하지만 비선형성을 가지는 차량 거동을 모델링 하는 것은 매우 어렵고, 정밀하게 모델링을 한다고 하더라도 여러 파라미터가 얽여있는 차량의 거동을 몇몇 시험을 통하여 정확하게 튜닝하는 것은 매우 많은 시간이 소요된다.

또한 실험을 통하여 측정 가능한 파라미터가 제한될 뿐만 아니라 새로운 플랫폼 또는 차량이 개발될 때마다 파라미터 튜닝에 매우 많은 노력과 시간이 반복적으로 소요된다. 특히 야지 환경 등으로 인해 노면 특성이 변화하는 환경에서는 단순히 플랫폼만의 주행 특성이 아니라 노면과의 상호작용에 대한 모델링과 파라미터의 측정도 요구되고 있다.²⁾

복잡해지는 환경에서 단위 시험을 통하여 개별 파라미터를 측정하며 동역학 정합성을 높이는 것은 한계가 있다. 따라서 본 연구에서는 동역학 모델링의 물리적인 특성을 활용하여 데이터 기반의 인공지능 기술을 접목한 딥러닝 아키텍처를 제안한다. 이러한 데이터 기반의 가상 동역학 모델링 기법을 통해서 새로운 플랫폼 또는 차량에 적용하더라도 기본적인 테스트 주행 데이터를 통해서 빠른 시간 내에 파라미터를 추출하고 가상 환경에서의 정합률이 높은 동역학 모델을 구현하는 것이 가능하다.

2. 동역학 시뮬레이션

로봇 혹은 차량 등 무인인동체에 대한 동역학 시뮬레이션에 있어서는 Carsim, CarMaker, VSM, ASM 등이 많이 사용되고 있다. 이러한 시뮬레이션 도구들은 차량의 동역학적 특성을 모델링하기 위해 정교한 수학적 모델과 물리 법칙에 기반하여 구현되어 있다. 시뮬레이션에 사용되는 차량 동역학 모델링은 전통적으로 파라미터 기반의 접근법이 주류를 이루어 왔으나, 최근에는 데이터 기반 방식과 하이브리드 접근법이 점차 주목을 받고 있다.

2.1 파라미터 기반 동역학 모델링

파라미터 기반 모델링은 물리 법칙과 수학적 공식을 통해 시스템의 동역학적 특성을 표현하는 방식이다. 이

접근법은 뉴턴-오일러 방정식, 라그랑지안 역학 등의 이론적 체계를 바탕으로 구현된다. 차량의 경우 질량, 관성 모멘트, 서스펜션 강성, 감쇠 계수, 타이어 특성 등 수십에서 수백 개의 파라미터가 필요하다.³⁾ 이러한 모델의 장점은 물리적 직관성과 높은 정확도이나, 복잡한 환경에서의 적용에는 여러 제약이 따른다.

- 1) 파라미터 측정 및 캘리브레이션에 상당한 시간과 비용이 소요된다.⁴⁾
- 2) 비선형적 거동이나 예측하기 어려운 환경조건(비정형 지형, 극한 주행 조건 등)에서의 정확도가 감소한다.⁵⁾
- 3) 새로운 차량이나 로봇 플랫폼에 적용할 때마다 전체 파라미터를 재조정해야 한다.⁶⁾

2.2 데이터 기반 동역학 모델링

최근 머신러닝 및 딥러닝 기술의 발전으로 데이터 기반 모델링 방식이 주목받고 있다. 이는 시스템의 물리적 구조에 대한 명시적 모델링 없이, 입력력 데이터의 패턴을 학습하여 동역학을 예측하는 방식이다.⁷⁾

기계학습의 주요 방법으로는 RNN(Recurrent Neural Network), LSTM(Long Short-Term Memory), GRU(Gated Recurrent Unit)와 같이 시계열 예측을 위한 순환 신경망, 물리 법칙을 제약 조건으로 활용하는 물리 기반 신경망 PINN(Physics-Informed Neural Network) 등이 있다. 이러한 접근법은 실측 데이터에 기반하므로 실제 거동을 더욱 정확하게 반영할 수 있으며, 복잡한 물리적 상호작용도 학습이 가능하다. 또한, 새로운 플랫폼에 대해 데이터가 확보될 경우 빠르게 적용할 수 있다는 장점이 있다. 다만 데이터가 확보되지 않은 환경 및 상황에 대해서 성능이 떨어질 수 있다는 단점이 있다.

2.3 노면-차량 상호작용 모델링

실제 환경에서 차량의 거동은 노면 조건에 크게 영향을 받는다. 특히 오프로드 환경이나 험지에서의 주행은 노면-차량 간 상호작용을 정확히 모델링해야 예측 가능하다.⁸⁾ 노면-차량 상호작용을 모델링하기 위한 접근 방법은 토양 변형 및 접촉 역학을 고려한 테라메카닉스 기반의 모델,⁹⁾ 센서 데이터를 활용한 노면 특성 추정 및 거동 예측 기반의 모델링,¹⁰⁾ 실시간으로 노면 조건을 추정하고 모델을 조정하는 적응형 모델링 방법 등이 있다.¹¹⁾ 이러한 접근법은 자율주행 시스템이 다양한 환경에서 안정적으로 운용되기 위해 필수적이다. 이와 같은 모델링 방법은 주로 파라미터 기반의 동역학 모델과 수학적으로 상호작용되며, 데이터 기반의 동역학 모델링을 사용할

경우에는 이와 같은 모델링 방법을 활용할 수 없어 노면 또한 데이터를 수집하고 학습해야 한다.

2.4 시뮬레이션-현실 융합 접근법

실제 환경에서의 데이터 취득은 비용과 시간이 많이 소요되며, 위험한 상황에서의 테스트는 제한적일 수밖에 없다. 이러한 한계를 극복하기 위해 시뮬레이션 데이터와 실제 데이터를 효과적으로 융합하는 접근법이 연구되고 있다.¹²⁾

따라서, 본 연구에서는 이러한 다양한 접근법의 장점을 결합하여, 가상 데이터와 실제 데이터를 효과적으로 활용하는 딥러닝 기반의 차량 동역학 모델링 파이프라인을 제안한다. 특히 최소한의 실제 데이터로도 높은 정확도를 달성할 수 있는 하이브리드 학습 전략을 중점적으로 다룬다.

3. 딥러닝 아키텍처

본 연구에서 고안된 딥러닝 모델은 차량의 새시 시스템 및 관측 데이터 간의 기구학적 특성이 반영된 구조를 갖고 있다. 이는 기구학적 특성 및 구조가 반영되지 않고 데이터의 특성과 성격만 고려된 딥러닝 아키텍처의 경우에는 데이터의 의존도가 과도하게 높아질 수밖에 없게 된다. 하지만 오프로드 및 산악환경과 같은 복잡한 지형에서의 차량거동 특성에 대한 데이터 확보는 매우 어려우며 이에 따라 동역학 모델의 정확도는 기하급수적으로 낮아질 수밖에 없다. 따라서 동역학적 특성을 모델링하기 위한 딥러닝 네트워크는 이러한 플랫폼의 기구학적 특성이 반드시 반영되어야만 범용적으로 활용 가능한 결과물을 얻을 수 있다.

실제 자동차에서는 구동 및 조향 거동을 담당하는 새시와 대부분의 데이터 측정 센서가 장착되며 운전자가

타승하는 공간인 바디의 구조로 이루어져 있다. 또한 이 두개의 구성은 서스펜션을 통해서 연결되어 있다. Fig. 1 과 같이 본 논문에서 고안한 네트워크 구조는 이러한 차량 시스템의 기구학적 구성이 고려된 구조이기 때문에 데이터를 활용한 학습 기반의 동역학 모델링이 가능하면서도 데이터에 대한 의존도를 낮출 수 있다.

3.1 새시(Chassis) 네트워크 모듈

차량을 구성하는 모듈 중 새시(Chassis)에서 차량의 거동을 담당하는 요소는 조향계와 동력계라고 볼 수 있다. 조향계는 운전자가 조작하는 핸들의 회전 각도를 실제 타이어의 회전으로 전달해줘서 차량의 횡방향 거동을 나타나게 해주고 동력계에서는 가속페달 혹은 브레이크 페달의 입력 값을 바탕으로 종방향 거동을 나타나게 해준다. 즉, 지면과 직접적으로 접촉하면서 운전자의 입력을 바탕으로 차량의 움직임을 결정하는 모듈이다.

이러한 모듈의 동작 특성을 고려하여 네트워크 구조를 개발했으며 아래의 수식과 같이 표현할 수 있다.

$$s_t^{veh} = \{vx_t^{veh}, vy_t^{veh}, \omega_t^{veh}\} \quad (1)$$

$$x_t = \{acc_t, brk_t, str_t\} \quad (2)$$

$$s_{t+1}^{ch} = f_{pt}(s_t^{ch}, s_t^{veh}, x_t) \quad (3)$$

즉, 식 (3)과 같이 새시의 상태 정보를 차량의 상태 정보 및 운전자의 제어 입력을 바탕으로 1 단계 업데이트 하는 것이 새시 네트워크 모듈의 역할이라고 볼 수 있다.

하지만 이러한 모듈의 가장 큰 문제점은 새시의 상태 정보를 뜻하는 s_t^{ch} 를 관측하거나 얻어내는 것이 불가능하다는 점이다. 실제로 데이터 취득 차량에 부착되는 다수의 측정 장치는 강제로 이루어진 차량의 바디(Body)에

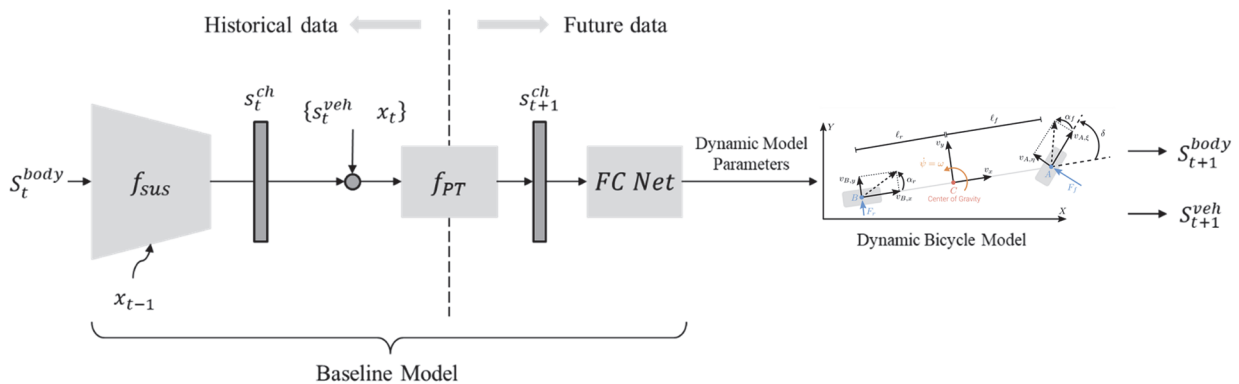


Fig. 1 Overall architecture of the physics-informed neural network for automated vehicle dynamic parameters setting pipeline using the dynamic bicycle model

부착되게 되어 있으며 이 몸체는 서스펜션(Suspension)을 통해서 새시와 연결되어 있다. 따라서 측정 장치를 통해 얻을 수 있는 데이터는 바디의 상태정보이지 새시의 상태정보가 아닌 점이 거두 된다. 따라서 연구에서는 서스펜션 네트워크 모듈을 별도로 구성하였다.

3.2 서스펜션(Suspension) 네트워크 모듈

실제 차량에서의 서스펜션은 바디와 새시 사이를 다양한 스프링, 댐퍼 등의 요소들을 통해서 유기적으로 연결해주는 파트라고 볼 수 있다. 가장 큰 역할은 노면으로부터 전달되는 진동 등을 감쇠하여 승차감을 향상시켜 주고 지면과의 접지력을 최적화해서 차량의 주행 안정성을 높여주는 역할을 한다.

이러한 특성을 딥러닝 기반의 네트워크 구조로 모델링한 본 연구에서는 데이터를 측정할 수 있는 차량의 바디 파트와 지면과 접촉하여 실질적인 차량의 거동을 수행하는 새시 파트 사이를 연결해줄 수 있는 모듈로 고안되었다. 이를 통해 측정 가능한 데이터인 차량의 상태 정보와 전파 시간(Time propagation)에 사용하는 데이터인 새시의 상태 정보 사이의 상관관계를 분석할 수 있다.

이를 위해 식 (4)와 같이 차량 바디의 상태정보(s_t^{body})는 Roll 각도와 Pitch 각도로 정의하였으며 서스펜션 네트워크 모듈은 식 (5)와 같이 바디의 상태정보와 제어 입력(x_{t-1})을 분석해서 새시의 Hidden state(s_t^{ch})를 추려해주는 역할을 한다. 이때 서스펜션 네트워크의 역함수는 새시의 Hidden state를 바디의 상태정보로 치환해줄 수 있도록 식 (6)을 구성하였으며 이를 바탕으로 Fig. 2와 같은 네트워크 구성을 고안했다.

$$s_t^{body} = \{r_t^{body}, p_t^{body}\} \tag{4}$$

$$s_t^{ch} = f_{sus}(s_t^{body}, x_{t-1}) \tag{5}$$

$$s_t^{body} = f_{sus}^{-1}(s_t^{ch}, x_{t-1}) \tag{6}$$




Fig. 2 Flow diagram of the co-pretraining phase for suspension network module and its inverse module

즉, 이러한 역함수를 통해서 바디-새시, 새시-바디의 상태 정보에 대한 도메인 친이를 자유롭게 진행할 수 있는 네트워크 아키텍처를 고안했다.

4. 네트워크 학습 프레임워크

앞서 소개된 딥러닝 아키텍처를 효과적으로 학습하고 실제 타겟 플랫폼에 적용하기 위해서는 총 3단계에 거친 학습 및 파인 튜닝(Fine-tuning)단계가 필요하다. 1차적으로 측정할 수 없는 데이터인 새시의 상태 정보를 추출하기 위한 서스펜션 네트워크 모듈에 대해서 자기지도학습(Self-supervised learning)기법을 활용한 사전 학습 단계(Pre-training phase)가 필요하다. 또한 학습이 완료된 이후에는 타겟이 되는 플랫폼에 대한 최적화를 진행하기 위한 사후 학습 단계(Post-training phase)를 진행하며 이때에는 Pseudo-GT를 이용하여 가상환경 기반의 시뮬레이션에서 설정된 동역학 파라미터에 대해서 학습 가능한(Trainable) 최적화 과정을 진행하게 된다.

또한 각 학습 단계에서 시뮬레이터에서 추출된 가상 환경 데이터와 실제 환경에서 취득된 실 환경 데이터를 최적의 단계에서 사용하는 학습 전략을 제안한다. 가상 환경 데이터의 경우에는 취득 및 구축하는 데 있어서 굉장히 손쉽게 구축할 수 있다는 장점이 있지만 아직 타겟 플랫폼의 동역학적 특성에 대한 세팅이 진행되기 이전 단계이기 때문에 실제와의 유사성이 떨어질 수밖에 없다.

따라서 본 논문에서는 사전 학습 단계에서는 다수 다종의 가상환경에서 취득된 차량 주행 데이터, 기준 모델(Baseline model) 학습 단계에서는 최대한 유사한 차종 1종에 대한 가상 데이터, 사후 학습 단계에서는 실 환경 데이터를 활용하여 학습을 진행하는 프레임 워크를 제안한다. 이러한 전략으로 이종의 데이터에 대해 가장 효율적으로 학습에 사용할 수 있으며 이러한 방법론을 통해서 새로운 타겟 플랫폼에 대해서 초단기간에 가상 동역학 모델링을 진행할 수 있다는 장점이 있다.

4.1 사전 학습 단계(Pre Training Phase)

사전 학습 단계에서는 측정 불가능한 상태 변수에 대한 은닉 벡터를 추출해 내기 위한 자기지도학습이 진행된다. 이를 통해서 서스펜션 네트워크 모듈을 학습하게 되며 역함수 또한 학습이 가능하여 바디상태정보와 새시 상태 정보를 자유롭게 매핑 시킬 수 있는 네트워크를 확보할 수 있게 된다.

이 단계에서는 Fig. 2와 같이 서스펜션 네트워크 모듈과 이의 역함수 모듈을 이어 붙여서 처음에 입력된 s_t^{body}

를 재생성 해낼 수 있도록 네트워크를 구성한다. 이러한 네트워크에 대해서 식 (7)과 같이 Roll 각도와 Pitch 각도로 이루어진 차량 바디의 상태값을 예측하여 정답데이터와의 Mean Squared Error를 계산하는 손실 함수를 통해서 학습을 진행한다.

이러한 사전 학습 단계에서는 MORAI 시뮬레이터에 구성된 다수의 차종에서 취득한 가상데이터를 활용해서 학습을 진행한다. 이는 바디와 새시 사이에 존재하는 서스펜션의 특징을 일반화해서 학습하기 위함이며 이를 통해서 차량의 기구학적 특성을 학습할 수 있게 된다.

$$\mathcal{L} = MSE(s_t^{body}, \hat{s}_t^{body}) \quad (7)$$

4.2 기준 모델(Baseline Model) 학습 단계

사전 학습 단계에서 학습된 서스펜션 네트워크를 활용하여 플랫폼의 가상환경에서의 동역학 파라미터를 추출하기 위한 학습단계이다. 이때 시뮬레이터는 렌더링 기반의 게임엔진을 활용한 시뮬레이터이기 때문에 여기서 사용하는 동역학 파라미터를 직접적으로 네트워크와 연결 지어서 학습시키는 것은 불가능하다.

따라서 이러한 한계점을 극복하기 위해 본 연구에서는 단순화되어 있으면서 학습 단계에서 직접적으로 반영할 수 있는 바이시클 모델(Bicycle model)을 활용한 동역학 모델을 활용바탕으로 물리정보 신경망(Physics-informed neural network)를 구성하였다. 이를 통해서 동역학 시뮬레이션이 가능한 파라미터를 추출할 수 있으며 추출된 파라미터 기반의 차량 거동을 연산하여 최종적인 손실함수를 계산하여 가중치(Weight) 업데이트가 가능한 파이프라인을 구축했으며 이 단계에서는 시뮬레이터에 설정된 단일 차종의 가상데이터를 활용하여 학습을 시켜 해당 차종 고유의 동역학적 경향성이 학습되도록 유도한다.

하지만 이러한 물리정보 신경망을 도입하기 위해 활용한 바이시클 모델의 경우에는 실제 시뮬레이션에서 사

용되는 동역학 모델과 비교해서 제한조건이 많고 자유도가 적어서 유사도가 떨어진다는 단점이 있다. 따라서 본 연구에서 제안된 파이프라인 중 기준 모델 학습단계의 목표는 실제 시뮬레이션에서 사용되는 동역학 모델과 동일한 경향성을 갖도록 네트워크를 학습시키는 것이며 이에 대한 정확도는 사후 학습 단계에서 경향성 기반의 수도 레이블링(Pseudo label)을 활용한 파인 튜닝을 거치면서 최종 성능이 확보되게 된다.

4.3 사후 학습 단계(Post Training Phase)

사후 학습단계에서는 실제 환경에서 취득한 데이터를 통해서 학습된 경향성에 따라서 동역학적 정합성을 최적화하기 위한 학습을 진행한다. Fig. 3과 같이 사후 학습 단계에서는 이전에 학습된 기준 모델의 파라미터는 고정시킨 이후에 동일한 아키텍처를 갖는 테일러링 모듈(Tailoring module)을 학습하는 것을 목표로 한다. 이 테일러링 모듈은 기준 모델에서 추출되는 동역학적 파라미터를 실 환경에서 취득된 데이터셋에 최적화하여 빠르게 수렴할 수 있는 파라미터를 찾아주는 역할을 하게 된다.

여기서 실제 네트워크들이 학습되기 위해서는 바이시클 모델의 출력 정보를 바탕으로 손실함수가 계산되어야만 역전파가 가능하다. 하지만 본 연구는 시뮬레이터에 내재화 되는 동역학 모듈의 파라미터 추출이기 때문에 정답데이터는 시뮬레이터에서 나온 출력 값에 대한 손실 함수를 계산해야만 한다. 따라서 이러한 학습 가능한 정보의 흐름과 손실함수 계산을 위해 필요한 정보의 흐름 사이에 발생하는 간극을 해결하기 위해 사전에 확보된 동역학 모델 간의 동일한 경향성을 이용해서 수도 레이블링의 개념을 도입했다.

수도 레이블링을 활용한 수도 손실(Pseudo loss)를 계산하기 위해서는 먼저 식 (8) 및 (9)와 같이 시뮬레이터에서 출력된 데이터를 정답데이터와 비교하여 손실함수를 1차적으로 계산한다.

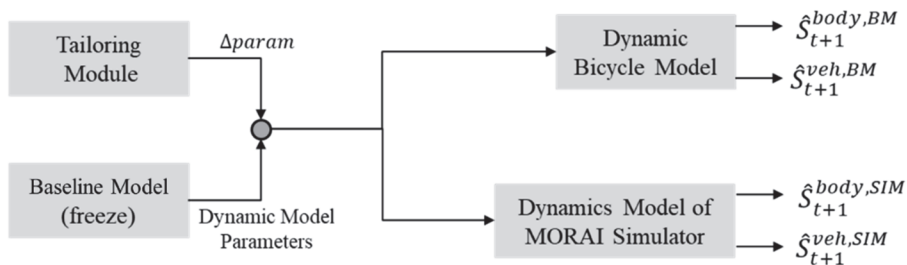


Fig. 3 The proposed training scheme for post training phase which incorporate pseudo label and pseudo loss concept for enabling the backpropagation considering the simulation tool

$$\mathcal{L}_{body} = \mathcal{L}(\hat{S}_{t+1}^{body, SIM}, S_{t+1}^{body}) \quad (8)$$

$$\mathcal{L}_{veh} = \mathcal{L}(\hat{S}_{t+1}^{veh, SIM}, S_{t+1}^{veh}) \quad (9)$$

하지만 여기서 계산된 손실함수는 3D 렌더링 기반의 시뮬레이터에 내재화된 동역학 모듈의 출력이기 때문에 정보의 흐름이 끊겨 있을 수밖에 없으며 이에 따라 이 손실함수를 활용한 역전파가 불가능 하다. 따라서 식 (10) 과 같이 수도 레이블링 및 수도 로스의 개념을 제안하였으며 이는 실제 정답데이터와 비교하여 계산된 손실함수의 크기를 바이시클 모델을 통해서 출력된 정보에 강제적으로 반영해서 역전파 가능하면서도 정답데이터와의 오차에 대한 경향성을 파악할 수 있는 시스템을 개발하였다.

$$\mathcal{L}_{pseudo} = \mathcal{L}(\hat{S}_{t+1}^{body, BM}, \mathcal{L}_{body}) + \mathcal{L}(\hat{S}_{t+1}^{veh, BM}, \mathcal{L}_{veh}) \quad (10)$$

5. 정합성 검증

본 연구에서는 인공지능을 활용하여 차량의 동역학적 모델링을 자동화하는 방법론을 제안했으며 실제로 가상 시뮬레이터에서 나오는 데이터와 실제 차량을 활용해서 취득한 데이터를 활용해서 학습 및 비교 분석을 진행했다. 모든 그래프에 있어서 실제 차량을 운행하면서 로깅된 데이터(빨간색)와 같은 제어 입력을 시뮬레이터에 주입했을 때 시뮬레이터 내에 동역학 파라미터가 추출되어 구축된 가상 차량의 주행 데이터(파란색)를 차량 속도 기준으로 비교했으며 노이즈, 센서 오류 등 취득된 실 데이터의 품질이 좋지 않은 구역에 대해서는 검정색으로 표시가 되어 있다.

먼저, 가상데이터만을 사용해서 기준 모델을 학습해서 경향성 정도만 학습했을 때의 결과 양상이 Fig. 4에




Fig. 4 Result of the baseline model which is trained using the synthetically generated dataset from the simulator for enabling the fundamental of the vehicle dynamics

나와 있다. Fig. 4의 좌측 그림에 표현된 경로는 실제 차량이 주행한 경로이다. Fig. 4의 우측 그래프와 같이 기준 모델을 통해 계산된 동역학 파라미터를 이용해서 움직인 차량의 거동 경향성이 실제 차량과 매우 유사하다는 것을 알 수 있다. 하지만 경향성만 유사할 뿐 수치적인 오차는 매우 큰 것을 알 수 있으며 이는 사후 학습 단계의 필요성을 보여주는 것으로 해석할 수 있다. 즉 아무리 기준 모델이 좋은 성능을 보여준다고 하더라도 새로운 플랫폼 혹은 신규 차량에 대한 동역학 파라미터를 추출하기 위해서는 실 주행 데이터를 활용한 사후 학습 단계를 통해서 추출해야만 한다.

사후 학습 단계를 거치고 난 이후에 변화하는 동역학 모델링 성능을 보기 위해서 Fig. 5와 같은 경로를 주행한 실 데이터와 비교했다. 그 결과 Fig. 6과 같은 결과를 볼 수 있다. Fig. 6의 좌측은 기준 모델만을 이용한 결과이고 우측 그래프는 기준 모델을 시작으로 실제데이터를 바탕


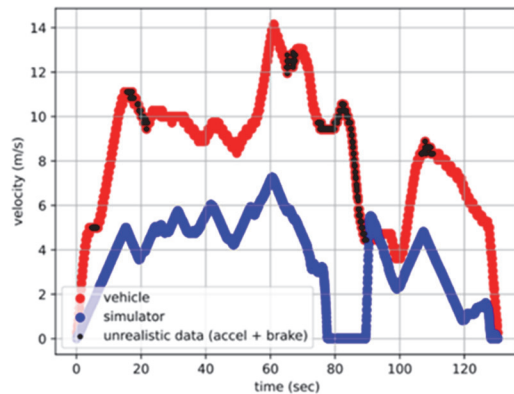


Fig. 5 Test trajectory description which is utilized for comparing the baseline model and post-trained overall network as illustrated in Fig. 6



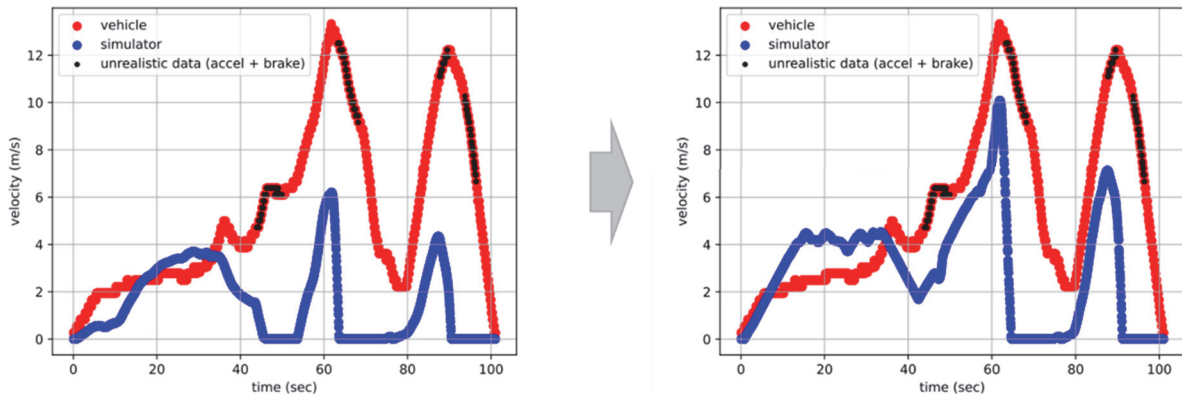


Fig. 6 Performance comparison of the dynamic parameter between vanilla baseline model and post-trained baseline model

으로 사후 학습까지 완료된 결과이다. Fig. 4와 마찬가지로 Fig. 6의 좌측 그래프에서도 차량의 거동 경향성은 유사하게 관측됐지만 오차는 많이 발생한 것을 알 수 있다. 반면에 우측 그래프에서는 실제 데이터를 통해서 딥러닝을 통해 추출되는 동역학 파라미터의 미세조정 및 최적화가 가능했기 때문에 경향성뿐만 아니라 수치적인 오차도 많이 줄어든 것을 확인할 수 있다.

6. 결론

본 논문에서는 가상 데이터 및 실 데이터를 활용해서 시뮬레이터라는 가상공간내에 차량의 동역학적인 특성을 반영할 수 있는 프레임워크를 개발했다. 또한 단순히 동역학 모델을 만드는 것이 아니라 향후 새로운 차종이나 플랫폼에 대한 도입이 필요했을 때에는 다수의 가상 데이터와 소수의 실 데이터만 있어도 실제 차량의 동역학적 퍼포먼스를 가상환경내로 빠르게 전이시킬 수 있는 인공지능 기술을 개발했다. 측정 불가능한 정보가 굉장히 많다는 점이 동력계의 특성이기 때문에 인공지능 기술을 도입하는 것에 제한이 많이 있었다. 하지만 본 연구에서는 자기지도학습, 수도 레이블링, 수도 손실 등 미지(Unknown)데이터를 고려한 학습 기법을 고안하여 해결하였다.

향후에는 차량의 속도 정보뿐만 아니라 승차감, 제동 성능 등 다양한 요소에 대해서 평가를 진행할 예정이며 이러한 과정에서 정량적인 지표 측정을 통한 분석을 진행하여 고성능 동역학 가상 모델을 확보하기 위해서 필요한 실 주행 데이터 취득 경로 및 상황 등에 대해서 분석하고자 한다. 그 이후에는 차량 시스템에 대한 가상화 단계에서 인공지능을 통해서 고속, 고성능의 가상화 프로세스를 확보할 수 있을 것으로 기대된다.

후 기

본 논문은 방위사업청 국방기술진흥연구소 지원에 의한 연구임(No. KRIT-CT-22-087, 합성전장 환경의 초실감 통합전투훈련 플랫폼).

References

- 1) D. -Y. An and C. M. Kang, "Robust Control for Personal Mobility Using Linear Parameter Varying Method," Transactions of KSAE, Vol.32, No.2, pp.167–172, 2024.
- 2) S. Kim, B. Pyun, H. Choi and G. Choi, "Road Surface Friction Coefficient Estimation and Actual Vehicle Verification Using Recursive Least Square Method," Transactions of KSAE, Vol.32, No.1, pp.49–57, 2024.
- 3) M. Blundell and D. Harty, The Multibody Systems Approach to Vehicle Dynamics, Elsevier, Oxford, 2015.
- 4) G. J. Heydinger, W. R. Garrott, J. P. Chrstos and D. A. Guenther, "A Methodology for Validating Vehicle Dynamics Simulations," SAE Transactions, Vol.99, pp.126–146, 2002.
- 5) H. B. Pacejka, Tire and Vehicle Dynamics, 3rd Edition, Butterworth-Heinemann, Oxford, 2012.
- 6) H. J. Kim, H. S. Yang and Y. P. Park, "Improving the Vehicle Performance with Active Suspension Using Road-Sensing Algorithm," Computers & Structures, Vol.80, No.18–19, pp.1569–1577, 2002.
- 7) N. A. Spielberg, M. Brown, N. R. Kapania, J. C. Kegelman and J. C. Gerdes, "Neural Network Vehicle Models for High-Performance Automated Driving," Science Robotics, Vol.4, No.28, eaaw1975, 2019.
- 8) S. Taheri, C. Sandu, S. Taheri, E. Pinto and D. Gorsich, "A Technical Survey on Terramechanics Models for Tire–Terrain Interaction Used in Modeling and Simulation of Wheeled Vehicles," Journal of Terramechanics, Vol.57,

- pp.1–22, 2015.
- 9) J. Y. Wong, Theory of Ground Vehicles, 4th Edition, John Wiley & Sons, New York, 2008.
 - 10) K. Iagnemma and S. Dubowsky, Mobile Robots in Rough Terrain: Estimation, Motion Planning, and Control with Application to Planetary Rovers, Springer, Berlin, 2004.
 - 11) B. Li, H. Du and W. Li, “Comparative Study of Vehicle Tyre–Road Friction Coefficient Estimation with a Novel Cost-Effective Method,” Vehicle System Dynamics, Vol.52, No.8, pp.1066–1098, 2014.
 - 12) M. Cutler, T. J. Walsh and J. P. How, “Reinforcement Learning with Multi-Fidelity Simulators,” Proceedings of the IEEE International Conference on Robotics and Automation (ICRA), pp.3888–3895, 2014.