

P2 HEV의 LSTM 기반 엔진 클러치 접합/해지 이상치 탐지 알고리즘

지용혁¹⁾ · 이형철^{*2)}

한양대학교 전기공학과¹⁾ · 한양대학교 전기생체공학부²⁾

The LSTM-based Engine Clutch Engagement/Disengagement Anomaly Detection Algorithm for P2 HEV

Yonghyeok Ji¹⁾ · Hyeongcheol Lee^{*2)}

¹⁾Department of Electric Engineering, Hanyang University, Seoul 04763, Korea

²⁾Division of Electrical and Biomedical Engineering, Hanyang University, Seoul 04763, Korea

(Received 6 October 2021 / Revised 18 October 2021 / Accepted 24 October 2021)

Abstract : This paper presents an anomaly detection algorithm for an engine clutch engagement/disengagement process of P2 type hybrid electric vehicles that use long short-term memory(LSTM). We proposed a structure of an LSTM-based model that can predict data at present, and trained the model with normal data. When the difference between the predicted values of the model and the measured values exceeds a certain threshold, the algorithm determines the data as anomalies. We used simulation data in the model training, and developed a threshold that considers the data prediction characteristics of the LSTM-based model. The developed anomaly detection algorithm predicted normal data well, and showed the results of anomaly detection with high accuracy. Since other vehicle data have similar characteristics to the target data of this paper, this algorithm is expected to be applied successfully to other vehicle data.

Key words : Anomaly detection(이상치 탐지), Long short-term memory(장단기 메모리), Hybrid electric vehicle(하이브리드 전기자동차), Engine clutch engagement/disengagement(엔진 클러치 접합/해지), P2 type HEV(P2 타입 하이브리드 전기자동차)

Nomenclature

ω : rotational speed, RPM
 ΔT : step time, sec
 V : longitudinal speed, km/h
 P : pressure, bar
 T : torque, Nm
 x : LSTM network input vector (raw data)
 \hat{y} : LSTM network output vector (raw data)
 r : residual (difference between predicted value and measured value)
 μ : mean of training data
 σ : standard deviation of training data
 C : output matrix
 τ : threshold for anomaly detection
 X, Y : training data sample (input, output data)
 L : sequence input length for training data sample

Subscripts

clt : clutch
 e : engine
 m : motor
 cmd : command
 t : time index
 I : element index of vector
 l : lower
 u : upper

1. 서론

하이브리드 전기자동차 (HEV)는 내연기관 자동차나 배터리 전기자동차보다 복잡한 시스템을 가지고 있으며 이로 인해 복잡한 제어 기능을 필요로 한다. 제어기 개발과

*Corresponding author, E-mail: hclee@hanyang.ac.kr

^{*}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.

정에서 이러한 제어 기능은 Model-in-the-Loop Simulation (MILS), Hardware-in-the-Loop Simulation(HILS), 실차 시험을 통해 이상 동작 없이 정상적으로 동작하는지 검증된다.^{1,2)} 하지만 하이브리드 전기자동차의 복잡한 구조와 다양한 제어 기능은 검증에 다양한 테스트 시나리오를 요구하며, 이로 인해 엔지니어는 많은 데이터에 대한 분석을 수행하게 된다. 따라서 제어 기능이 정상적으로 동작하는지, 즉 테스트 데이터에 이상 데이터가 없는지에 대한 1차 검토를 자동으로 할 수 있는 이상치 탐지 알고리즘은 이러한 분석 과정을 효율적으로 만들 수 있다.

이상치 탐지는 IoT,^{3,4)} 항공,^{5,6)} 의료^{7,9)} 등의 다양한 분야에서 연구되고 있다. 차량에 대해서는 자율주행차량에 대한 악의적인 공격/도용 탐지에 대한 연구,¹⁰⁾ 배터리^{11,12)}에 대한 이상치 탐지에 대한 연구가 수행되었으나, 차량의 파워트레인 제어에 대한 이상치 탐지 관련 연구는 찾기 어렵다. 차량의 파워트레인 제어에 대한 데이터는 Multivariate time-series 데이터로 볼 수 있는데, 이러한 Multivariate time-series 데이터에 대한 이상치 탐지 연구는 다음과 같이 분류될 수 있다.^{6,13,14)}

- 1) Univariate time-series technique을 적용
- 2) Model-based technique
- 3) Dissimilarity-based technique
- 4) Histogramming
- 5) Ensemble-based technique
- 6) Domain-based technique
- 7) Temporal logic-based technique

여기서 Model-based technique은 현재 시점의 데이터를 추정하고, 추정된 값과 측정된 값을 비교하여 이상치를 탐지하는 방법이다. 측정 값과 추정 값과의 차이가 일정 수준을 넘어갈 경우 해당 데이터를 이상치로 판단하게 된다. 이러한 Model-based technique은 Estimation model-based technique과 Prediction model-based technique으로 구분할 수 있다.¹³⁾ Estimation model-based model technique은 현재 시점의 데이터를 추정할 때, 과거, 현재, 미래의 데이터를 모두 사용하며, Prediction model-based technique은 과거의 데이터만을 이용한다. Model-based technique은 Time-series 데이터의 정상적인 거동을 캡처하는 모델을 기반으로 이상치를 탐지하며,¹³⁾ 이러한 특징으로 인해 Time-series 데이터의 이상치 탐지에 많이 적용되고 있다.⁶⁾ 특히 Basora는 Recurrent Neural Network (RNN)을 사용한 Model-based technique들이 Multivariate time-series 데이터의 시간적, 비선형적 연관성을 캡처하는데 유리하다고 하였으며,⁶⁾ Chalapathy는 RNN, Long Short-Term Memory(LSTM)를 이용하여 Multivariate time-series 데이터의 이상치를 효과적으로 탐지한 Model-based

technique들이 많이 연구되었다고 서술하였다.¹⁵⁾

파워트레인 제어에 대한 데이터는 현재 시점의 데이터가 과거 시점의 데이터와 동역학적으로 연관되어 있고 그 관계가 비선형적인 특성을 가지고 있다. 이에 따라, 본 연구에서는 LSTM 기반의 Prediction model-based technique을 이용하여 하이브리드 전기자동차의 파워트레인 제어에 대한 이상치 탐지를 수행하였다. P2 타입 병렬형 HEV의 EV↔HEV 모드 변환 시에 필요한 엔진 클러치 접합/해지 기능에 대한 이상 데이터를 탐지하였으며, 이를 위해 관련 신호들을 예측할 수 있는 LSTM 모델을 학습하였다. 학습된 모델로 예측한 값과 측정된 값의 차이를 기반으로 이상치를 탐지하였는데, 이를 위해 차량 데이터 및 학습된 모델의 예측 특징을 고려한 Threshold를 제안하고, 이를 이용하여 이상치를 탐지하였다. 데이터는 Mathworks에서 제공하는 P2 타입 하이브리드 전기자동차 모델의 시뮬레이션을 통해 얻었으며, LSTM 모델의 학습 및 알고리즘의 개발에는 Matlab을 활용하였다.

본 논문의 구성은 다음과 같다. 2장에서는 본 연구에서 대상으로 한 차량 구조와 제어 기능을 소개하였다. 3장에서는 제안하고자 하는 LSTM 기반 이상치 탐지 알고리즘에 대해 서술하였으며, 4장에는 해당 알고리즘의 정상, 비정상 데이터에 대한 테스트 결과를 기재하였다. 마지막으로 5장에서는 본 연구의 결론을 서술하였다.

2. 대상 차량 구조 및 대상 제어 기능

2.1 대상 차량 구조




Fig. 1 Powertrain structure of the target vehicle

본 연구의 대상 차량은 Fig. 1과 같은 구조를 가지는 P2 타입 병렬형 하이브리드 전기자동차이다. Fig. 1에서 MG는 전인 모터를, ENG는 엔진을, BAT는 고전압 배터리를, TM은 변속기를, FD는 종감속 기어를 의미한다.¹⁶⁾ 대상 차량의 제원은 Table 1과 같다.

Table 1 Specification of target vehicle

Engine	Type	1,500 cc gasoline
Motor	Max power [kW]	30
	Max torque [Nm]	200
Battery	Type	Li-Ion
	Voltage [V]	270
	Capacity [Ah]	5.3
Clutch	Type	Dry clutch
	Clutch force equivalent net radius [m]	0.11
	Effective applied pressure area [m ²]	0.03
	Static, kinetic friction coefficient [-]	0.45, 0.4
Transmission	Type	6 speed AT
Vehicle	Mass [kg]	1623

2.2 대상 제어 가능

하이브리드 전기자동차의 주행 모드는 크게 견인 모터만 사용하는 EV 모드와 견인 모터와 엔진을 함께 사용하는 HEV 모드로 구분할 수 있다. Fig. 1에 나타난 대상 차량의 경우, EV 모드에서는 MG만을 이용하여 차량을 구동하며, HEV모드에서는 MG와 엔진을 함께 사용하여 차량을 구동한다. 차량 주행 시, HCU는 동력 분배 전략에 따라 차량을 EV 모드 또는 HEV 모드로 구동하게 되는데, 이에 따라 차량 주행 시에 EV 모드와 HEV 모드 사이의 변환이 나타나게 된다. 이 때 발생하는 EV→HEV 모드 변환은 다음과 같은 과정을 통해 이루어진다.¹⁷⁾

- 1) 스타터/견인 모터를 이용하여 엔진 크랭킹
- 2) 엔진, 견인 모터의 속도 동기화
- 3) 엔진 클러치 접합 및 HEV 모드로 천이

HEV→EV 모드 변환 또는 차량 정차시에는 엔진 클러치가 해제되게 된다. 본 연구에서는 이러한 상황에서 발생하는 엔진 클러치 접합/해지 제어 기능에 대한 데이터의 이상치를 탐지하는 것을 목표로 하였다.

3. LSTM 기반 이상치 탐지 알고리즘

3.1 대상 신호

엔진 클러치 접합/해지 제어 기능의 정상/비정상 여부는 엔진 클러치 유압 정도에 따른 엔진과 견인 모터의 속도로 판단할 수 있다. 이에 따라 LSTM 네트워크를 이용하여 엔진 클러치 유압, 엔진/모터 속도를 예측하고, 이를 이용하여 이상치를 탐지하고자 하였다. 여기서 LSTM 네트워크는 고장이나 이상치 데이터가 없는 정상 데이터를 예측하는 것이 목적이므로, 학습은 고장이나 이상치가 없는 정상 데이터만을 이용하여 수행하였다.

이 때 데이터 기반 방식의 특성상, 정상 데이터라도 학습에 사용된 데이터와 많이 다른 거동을 보인다면 이상치로 판단될 수 있다. 이러한 부분을 해결하기 위해서는 기본적으로 정상 데이터의 특징을 적절하게 표현할 수 있는 많은 학습 데이터가 필요하다. 본 연구에서는 이러한 문제를 최소화하기 위해 LSTM 모델이 시스템 동역학을 모사할 수 있도록 입출력 구조를 구성하였다. 즉 $y_{t+1} = F(x_t, u_t)$ 의 형태로 표현될 수 있는 동역학적 시스템에 대해, LSTM을 이용하여 F 를 모사하고자 하였다. 여기서 x, u 는 각각 시스템의 상태 변수와 입력을, y 는 시스템의 출력을 의미한다. 예를 들어 엔진 속도에 대한 동역학은 아래 식 (1)과 같이 쓸 수 있다. 식에서 볼 수 있는 것과 같이 t+1 시점의 엔진 속도는 t 시점의 엔진 토크, 엔진 클러치 유압, 엔진 속도를 이용하여 계산될 수 있다. 이에 따라 t+1 시점의 엔진 속도를 LSTM 네트워크의 출력 신호로, t 시점의 엔진 토크 명령, 엔진 클러치 유압, 엔진 속도를 LSTM 네트워크의 입력 신호로 구성하였다. 엔진 토크의 경우 직접적인 측정이 어렵기 때문에 엔진 토크 명령을 대상 신호로 선정하였다. 엔진 클러치 유압, 모터 속도도 마찬가지로 관련된 신호를 대상 신호로 선정하였으며, 선정된 대상 신호는 Table 2와 같다.

$$\omega_{e,t+1} = \omega_{e,t} + \{T_{e,t} - g(P_{clt})\}\Delta T = F(T_{e,t}, P_{clt}, \omega_{e,t}) \tag{1}$$

where $g()$: engine load torque function

ΔT : step time

Table 2 Target signals

Target signals	Meaning	Unit
V	Vehicle longitudinal speed	km/h
$P_{clt.cmd}$	Engine clutch pressure command	bar
P_{clt}	Engine clutch pressure	bar
ω_e	Engine speed	RPM
ω_m	Traction motor speed	RPM
$T_{e.cmd}$	Engine torque command	Nm
$T_{m.cmd}$	Traction motor torque command	Nm

3.2 LSTM 기반 이상치 탐지 알고리즘

LSTM 기반 이상치 탐지 알고리즘의 구조는 Fig. 2와 같다. 그림에서 볼 수 있는 것과 같이, t 시점까지의 데이터를 LSTM 네트워크에 입력하여 t+1 시점의 데이터를 예측하며, 예측된 값과 측정된 값을 이용하여 Residual r 을 생성하게 된다. 여기서 x 는 대상 신호로 Table 2에 나타난 신호들이며, \hat{y} 는 예측하고자 하는 값인 엔진 클러치 유압, 엔진 속도, 견인 모터 속도이다.

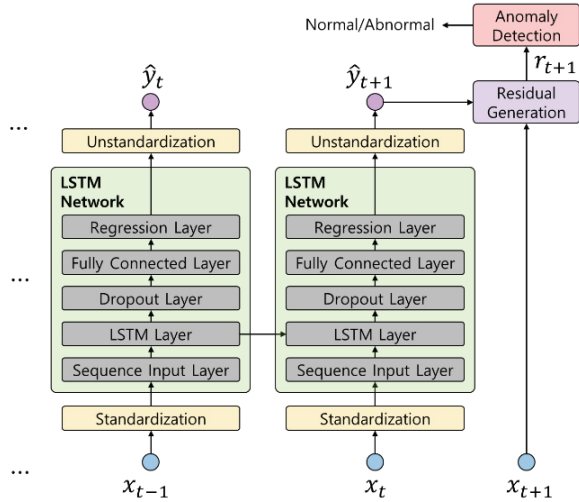


Fig. 2 LSTM-based anomaly detection algorithm structure

3.2.1 데이터 표준화, 비표준화

Table 2에 나타난 각 대상 신호는 신호의 범위가 모두 다르기 때문에 효과적인 학습을 위해서는 표준화가 필요하다. 이에 따라 각 신호 별로 아래 식 (2)를 이용하여 표준화를 수행한 후, 표준화된 데이터를 LSTM 네트워크에 입력하였다. 이 때 표준화를 위한 μ, σ 는 학습 데이터 세트로부터 계산된다.

$$z_{input,t,i} = \frac{(x_{t,i} - \mu_i)}{\sigma_i} \quad (2)$$

where x : raw data, z : standardized data
 i : element index of vector
 μ : mean of training data,
 σ : standard deviation of training data

표준화된 입, 출력 데이터로 학습을 수행하기 때문에, LSTM 네트워크의 출력 데이터도 입력 데이터와 마찬가지로 표준화된 데이터를 출력하게 된다. 따라서 표준화되지 않은 측정 값과 예측 값을 비교하기 위해 아래 식 (3)을 이용하여 출력된 데이터를 다시 비표준화 한다.

$$\hat{y}_{t+1,i} = z_{output,t+1,i} \times \sigma_i + \mu_i \quad (3)$$

3.2.2 LSTM 네트워크

LSTM 네트워크는 각 시점의 대상 신호를 입력으로 받아, 예측하고자 하는 값인 엔진 클러치 유압, 엔진 속도, 견인 모터 속도를 출력한다. 이 때, LSTM 네트워크의 입출력 신호는 모두 표준화된 신호이다. LSTM 네트워크는 Sequence input layer, LSTM layer, Dropout layer, Fully connected layer, Regression layer가 차례로 연결되어 구성된다.

3.2.3 Residual 생성 및 이상치 탐지

Residual은 아래 식 (4)와 같이 LSTM 네트워크에 의해 예측된 값과 해당 시점의 측정 값 차이로 계산된다. 식 (4)에서 C 는 대상 신호 벡터에서 엔진 클러치 유압, 엔진 속도, 견인 모터 속도만 출력해주는 행렬이다.

$$r_t = \hat{y}_t - Cx_t \quad (4)$$

where C : output matrix

이와 같이 계산된 Residual은 식 (5)와 같이 일정 수준을 넘어갈 경우, 해당 시점의 데이터를 이상치로 판단한다. 기존 연구에서는 이러한 Threshold를 대부분 고정 값으로 사용한다.¹⁸⁻²¹⁾

$$Anomaly : |r_{t,i}| > \tau_i \quad (5)$$

where τ_i : threshold of each residual element for anomaly detection

Fig. 3은 Fig. 2의 이상치 탐지 알고리즘을 이용하여 견인 모터 속도를 예측하고 이에 대한 Residual을 계산한 예시이다. 그림에서 볼 수 있는 것과 같이, Residual이 특정 부분에서 커지는 현상을 볼 수 있는데, 이는 모두 값이 상대적으로 크게 변하는 과도 상태 구간이다.




Fig. 3 Prediction result and residual for motor speed

모든 차량 데이터는 이러한 과도 상태 구간을 항상 포함하고 있으며, 과도 상태 구간에서는 Fig. 3에서 본 것과 같이, 예측 정확도가 떨어질 수 있다. 따라서 고정된 Threshold를 이용하여 이상치를 탐지할 경우, 과도 상태에서의 오탐지를 방지하기 위해 Threshold를 크게 설정해야 한다. 이 경우, 과도 상태가 아닌 구간에서의 이상

데이터가 탐지되지 않을 수 있으므로, 본 연구에서는 아래 식 (6), (7)과 같은 Threshold를 이용하여 이상치를 탐지하였다. 식에서 $\tau_{l,i}$, $\tau_{u,i}$ 는 각각 예측 신호 별 Lower, upper threshold를 의미하며, $\tau_{l,offset,i}$, $\tau_{u,offset,i}$ 는 각각 예측 신호 별로 설정해주어야 하는 Lower, upper threshold offset이다. 식을 통해, 예측 대상 신호의 측정값 변화량이 클 경우, Lower threshold $\tau_{l,i}$ 는 작게, Upper threshold $\tau_{u,i}$ 는 크게 변화되는 것을 확인할 수 있다.

$$\tau_{l,i} = \min \left[\begin{matrix} \tau_{l,offset,i} \\ \{\tau_{l,offset,i} - \text{sgn}(r_{t,i}) \times |y_{t,i} - y_{t-1,i}|\} \end{matrix} \right] \quad (6)$$

$$\tau_{u,i} = \max \left[\begin{matrix} \tau_{u,offset,i} \\ \{\tau_{u,offset,i} + \text{sgn}(r_{t,i}) \times |y_{t,i} - y_{t-1,i}|\} \end{matrix} \right] \quad (7)$$

- where $\tau_{l,offset,i}$: threshold offset (lower)
- $\tau_{u,offset,i}$: threshold offset (upper)
- $\tau_{l,i}$: final lower threshold
- $\tau_{u,i}$: final upper threshold

이상치 탐지는 식 (8)과 같이, 식 (6), (7)에 의해 결정된 Threshold와 Residual을 비교하여 이상치를 탐지하게 된다. 이 때, 순간적인 외란 등에 의한 오탐지를 방지하기 위해 비교 결과에 1차원 중앙값 필터를 적용하여 이상치를 탐지하였다. 필터의 윈도우 사이즈는 200 step으로 하였으며, 해당 값은 시행착오를 통해 적절한 값으로 선정되었다.

$$Anomaly : \text{med1}\{r_{t,i} < \tau_{l,i} \text{ or } (r_{t,i} > \tau_{u,i})\} \quad (8)$$

where med1 : 1-D median filter

3.3 LSTM 네트워크 학습

3.3.1 학습 데이터

LSTM 학습을 위한 데이터는 Mathworks에서 제공하는 P2 타입 하이브리드 전기자동차 모델²²⁾의 시뮬레이션을 통해 취득하였다. LSTM 네트워크는 고장이나 이상치가 없는 정상 상태의 데이터를 예측하는 것이 목적이므로, 학습은 고장이나 이상치가 없는 정상 데이터만을 이용하여 수행하였다. 해당 시뮬레이션 모델에서 제공하는 주행 사이클 시뮬레이션을 통해 얻은 데이터를 이용하였으며, 각 대상 신호는 10 [ms] 간격으로 취득되었다. 학습 데이터의 차량 총 주행 시간은 10,954초이며, 주행 중 엔진 클러치 접합/해지는 총 109번 이루어졌다.

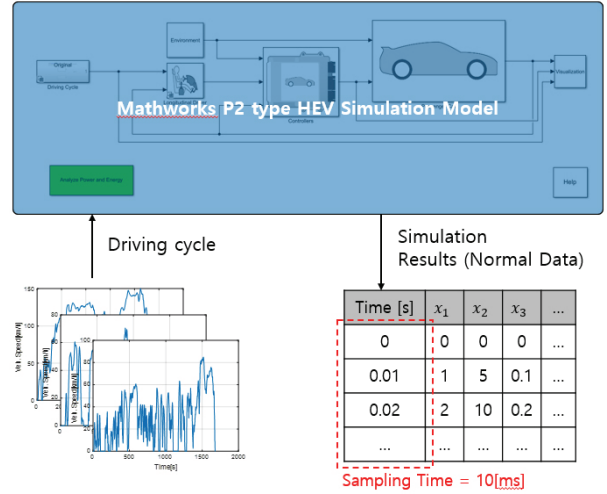


Fig. 4 Training data acquisition process

3.3.2 LSTM 네트워크 학습 구조

LSTM 네트워크는 Matlab 2020b Deep Learning Toolbox를 사용하여 구현되었으며, Fig. 2에서 보였던 것과 같이, Sequence input layer, LSTM layer, Dropout layer, Fully connected layer, Regression layer가 차례로 연결되어 구성되어 있다. 평균 제곱 오차의 절반 값을 Cost function으로 하여 학습을 수행하였으며, Dropout 확률은 50[%]로 설정하였다. 학습 데이터는 Fig. 5와 같이 일정한 시퀀스 길이를 가지도록 입력 데이터를 구성하였으며, 1-step prediction을 위해 출력 데이터는 1-step (10 [ms]) 이후의 값으로 구성하였다. 그림에서 (X_1, Y_1), (X_2, Y_2)는 각각 학습을 위한 입출력 데이터 샘플을 의미하며, L 은 시퀀스 길이를 의미한다.




Fig. 5 Training data sample configuration

학습은 Table 3과 같이 학습 데이터의 시퀀스의 길이와 LSTM layer의 Hidden unit 개수에 따라 수행하고 그 결과를 비교하였다. 학습 시간은 시퀀스의 길이와 Hidden unit의 개수에 따라 조금씩 다른데, 시퀀스의 길이, Hidden unit의 개수가 각각 300일 경우, Intel(R) Xeon(R) Gold 6230 CPU, 128GB RAM 기준으로 약 25시

간이 소요되었다. 다른 시퀀스 길이, Hidden unit 구성에 대해서는 약 5시간 내외의 시간 차이를 보였다.

Table 3 Hyperparameter setting for training

Case	The number of LSTM layers	Sequence length (L)	The number of hidden units per LSTM layers
1	1	100	100
2			200
3			300
4		200	100
5			200
6			300
7		300	100
8			200
9			300

4. 테스트 결과

4.1 Hyperparameter에 따른 예측 정확도 비교

Tables 4~6은 Table 3의 Hyperparameter 조합 별로 학습된 모델에 대해, 학습 데이터와 테스트 데이터(정상 데이터)에 대한 예측 신호 별 예측 정확도를 나타낸 것이다. 여기서 테스트 데이터는 FTP-75 주행 사이클 시뮬레이션 결과 데이터를 이용하였는데, 해당 데이터는 학습에 이용되지 않은 데이터이다. FTP-75 주행 사이클의 총 주행 시간은 2474초이며, 주행 중 엔진 클러치 접합/해지는 총 23번 이루어졌다. Tables 4~6에 표기된 값들은 예측 값과 측정 값의 평균제곱오차를 의미한다. 예측 신호 별로 값의 범위가 다르기 때문에 용이한 비교를 위해 Case 1(Sequence 길이, Hidden unit 개수 = 100, 100)의 평균제곱오차에 대한 상대적인 값으로 표현하였다. 학습 데이터와 테스트 데이터 모두 Layer 별 Hidden unit의 개수가 증가할수록 예측 정확도가 높아지는 경향을 보이는 것을 확인할 수 있으며, Sequence의 길이는 예측 신호와 Hidden unit의 개수에 따라 적절한 값이 달라지는 것을 알 수 있다. 학습 데이터에 대한 예측 정확도를 비교해보면, 엔진 클러치 유압과 견인 모터 속도의 경우, Case 6 (Sequence 길이, Hidden unit 개수 = 200, 300)가, 엔진 속도의 경우에는 Case 9(Sequence 길이, Hidden unit 개수 = 300, 300)이 가장 좋은 예측 정확도를 나타내고 있는 것을 확인할 수 있다. 하지만 Case 6가 엔진 속도에 대해서도 충분히 좋은 예측 정확도를 나타내고 있는 것을 함께 확인할 수 있다. 테스트 데이터에 대한 예측 정확도를 비교해보면, 엔진 속도와 견인 모터 속도의 경우, Case 6가, 엔진 클러치 유압의 경우에는 Case 3(Sequence 길이, Hidden unit 개수 = 100, 300)가 가장 좋은 예측 정확도를

나타내고 있는 것을 확인할 수 있다. 하지만 Case 6가 엔진 클러치 유압에 대해서도 충분히 좋은 예측 정확도를 나타내고 있음을 함께 확인할 수 있다. 이에 따라 본 연구에서는 Sequence 길이와 Hidden unit 개수가 각각 200, 300인 Case 6의 모델을 이용하여 이상치 탐지를 수행하였다.

Table 4 Prediction accuracy of case 1~9 (engine clutch pressure)

Relative mean square error for training set [%]		The number of hidden units per layers		
		100	200	300
Sequence length	100	100.0	39.0	20.0
	200	124.0	45.1	14.5
	300	119.7	52.5	20.4
Relative mean square error for test set [%]		The number of hidden units per layers		
		100	200	300
Sequence length	100	100.0	40.9	10.0
	200	105.0	39.4	11.5
	300	106.8	43.8	20.2

Table 5 Prediction accuracy of case 1~9 (engine speed)

Relative mean square error for training set [%]		The number of hidden units per layers		
		100	200	300
Sequence length	100	100.0	40.1	37.4
	200	71.2	144.2	34.5
	300	181.7	95.4	34.1
Relative mean square error for test set [%]		The number of hidden units per layers		
		100	200	300
Sequence length	100	100.0	33.5	59.2
	200	61.2	173.6	32.0
	300	117.6	67.8	39.0

Table 6 Prediction accuracy of case 1~9 (motor speed)

Relative mean square error for training set [%]		The number of hidden units per layers		
		100	200	300
Sequence length	100	100.0	27.0	27.4
	200	60.8	37.3	19.6
	300	91.5	44.0	22.2
Relative mean square error for test set [%]		The number of hidden units per layers		
		100	200	300
Sequence length	100	100.0	21.6	13.5
	200	25.3	22.3	11.2
	300	88.9	25.2	14.4

Figs. 6~7은 각각 최종 선택된 LSTM 모델(Case 6, Sequence 길이, Hidden unit 개수 = 200, 300)의 학습 데이터, 테스트 데이터에 대한 예측 결과를 나타낸 것이다. 각 그림에서 볼 수 있는 것과 같이, 학습, 테스트 데이터 모두 예측 신호들을 높은 정확도로 예측하고 있는 것을 확인할 수 있다.




Fig. 6 LSTM-based model prediction result for training data




Fig. 7 LSTM-based model prediction result for test data

4.2 이상치 탐지 알고리즘 테스트(정상 데이터)

Figs. 8~10은 최종 선택된 LSTM 모델(Case 6, Sequence 길이, Hidden unit 개수 = 200, 300)이 적용된 이상치 탐지 알고리즘의 정상 데이터에 대한 테스트 결과이다. 각 그림의 Residual에 대한 그래프에서 점선은 Upper, lower threshold를 의미한다. Residual의 Threshold offset 값 $\tau_{l,offset,i}$, $\tau_{u,offset,i}$ 는 FTP-75 주행 사이클 시뮬레이션 데이터 예측 결과를 통해 적절히 선정하였으며, 테스트 데이터로는 WLTP class 3 주행 사이클 시뮬레이션 데이터를 이용하였다. 테스트 결과, 제안한 이상치 탐지 알고리

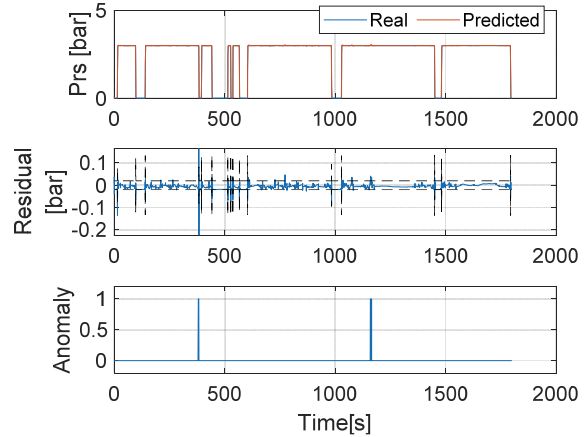


Fig. 8 Anomaly detection result for normal test data (clutch pressure)




Fig. 9 Anomaly detection result for normal test data (engine speed)




Fig. 10 Anomaly detection result for normal test data (motor speed)

증은 거의 모든 정상 데이터를 정상으로 잘 판단하는 것을 확인할 수 있다. Fig. 9의 엔진 속도에 대한 테스트 결과에 대해서 380초 부근에서 예측 오차가 Threshold를 넘어가는 현상이 나타났지만 매우 짧은 시간동안 발생하였으며, 이에 따라 1차원 중앙값 필터에 의해 최종적으로 정상으로 판단한 것도 함께 확인할 수 있다.

Fig. 11은 Fig. 10의 견인 모터 속도 예측 결과에서 일부 구간을 확대한 것이다. 그림에서 볼 수 있는 것과 같이, 견인 모터 속도가 순간적으로 변함에 따라 Residual의 Threshold도 함께 변화하고 있는 것을 볼 수 있으며, 이에 따라 제안한 Threshold가 오탐지를 적절하게 방지하고 있는 것을 확인할 수 있다.

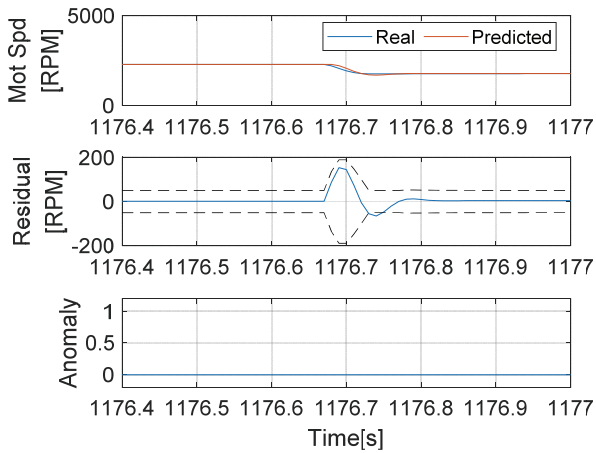


Fig. 11 Anomaly detection result for normal test data (motor speed, 1176~1177[s])

4.3 이상치 탐지 알고리즘 테스트 (비정상 데이터)

4.3.1 비정상 데이터 생성

비정상 데이터는 파라미터 값이 변경된 시뮬레이션 모델의 시뮬레이션을 수행하여 취득하였다. 클러치에 인가되는 엔진 클러치 유압 값과 클러치 유압 동작에 대한 시상수 파라미터를 변경시켰으며, 정상일 때의 파라

Table 7 Simulation model parameter setting for anomalous data

Case	Engine clutch pressure [bar]	Engine clutch actuation time constant [s]
Normal	3	0.25
Abnormal case 1	0	0.25
Abnormal case 2	0.07	0.25
Abnormal case 3	0.1	0.25
Abnormal case 4	2.5	0.25
Abnormal case 5	3	1

미터와 비정상 Case에 따른 파라미터는 Table 7과 같다. 각 Case에 대해, 엔진 클러치 유압 명령 값은 모두 3[bar]로 동일하다.

Table 7에 나타낸 Case 별 시뮬레이션 결과는 Figs. 12~17과 같다. 비정상 Case 1~2의 경우, 엔진 클러치 유압이 작아짐에 따라 엔진과 견인 모터의 속도 차이가 발생하고 있는 것을 확인할 수 있다. 비정상 Case 3의 경우, 엔진과 견인 모터의 속도 차이는 크게 발생하지 않지만, 정상일때에 비해 엔진과 견인 모터의 속도 동기화가 늦어지고 있는 것을 볼 수 있다. 이러한 현상은 Case 2에서도 발생하고 있다. 비정상 Case 4의 경우에도 엔진과 견인 모터의 속도 차이가 크게 발생하지 않지만, 유압 명령 추종 오차가 발생하고 있는 것을 확인할 수 있다. 엔진 속도의 경우에는 클러치가 떨어지는 시점이 빨라져 엔진과 모터의 속도 차이가 발생하는 시점이 더 빠르게 나타나며, 이러한 현상은 Case 3에서도 발생하고 있다. 비정상 Case 5의 경우에는 유압이 생성, 해제되는 시간이 정상보다 더 오래 걸리는 것을 볼 수 있다.




Fig. 12 Normal simulation results




Fig. 13 Abnormal simulation results (case 1)

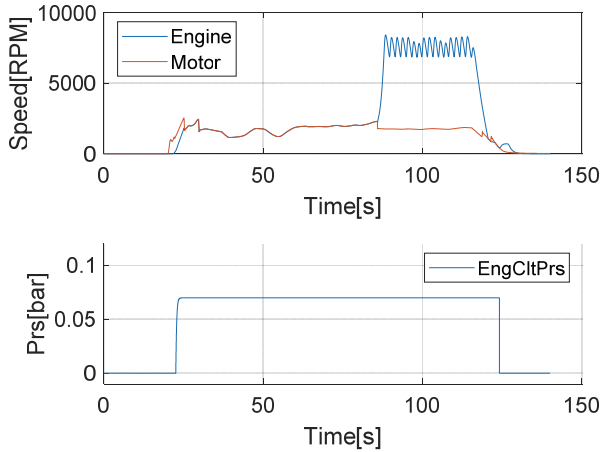


Fig. 14 Abnormal simulation results (case 2)




Fig. 17 Abnormal simulation results (case 5)




Fig. 15 Abnormal simulation results (case 3)




Fig. 16 Abnormal simulation results (case 4)

4.3.2 비정상 데이터에 대한 테스트 결과

Figs. 18~32는 Table 7과 같이 구성한 비정상 데이터에 대한 이상치 탐지 알고리즘 테스트 결과이다. 먼저 비정상 Case 1의 경우(Figs. 18~20), 엔진 클러치 유압이 전혀 가해지지 않아 엔진과 견인 모터의 속도 차이가 계속해서 나타나는 경우이다. 이에 따라 엔진 클러치 유압, 엔진 속도, 견인 모터 속도가 모두 비정상적인 거동을 나타내며, 이상치 탐지 알고리즘은 이러한 비정상적인 거동이 나타나는 구간을 이상으로 적절히 판단하고 있음을 확인할 수 있다. 비정상 Case 2, 3(Figs. 21~26)은 엔진과 견인 모터의 속도 오차가 일부 또는 대부분의 구간에서 크게 나타나지 않을 정도로 엔진 클러치 유압이 가해지는 경우이다. 비정상 Case 2, 3 모두 엔진 클러치 유압은 계속적으로 작은 값이 가해지기 때문에 이상치 탐지 알고리즘이 유압이 생성되어 있는 전체 구간을 이상으로 판단하고 있는 것을 볼 수 있다. 비정상 Case 2의 엔진, 견인 모터 속도에 대해서는 속도 오차가 커지는 100초 부근의 구간과 엔진, 모터 속도 동기화가 늦어지는 25초 부근의 구간을 이상으로 잘 판단하고 있는 것을 확인할 수 있다. 마찬가지로 Case 3의 엔진, 견인 모터 속도에 대해서도 엔진, 모터 속도 동기화가 늦어지는 25초 부근의 구간을 이상으로 잘 판단한다. 비정상 Case 2, 3의 50초 부근의 구간과 Case 3의 100초 부근의 구간은 실제 엔진, 견인 모터의 속도 오차가 큰 구간이 아니지만 이상치 탐지 알고리즘의 예측 오차가 Threshold보다 조금 커지면서 이상으로 판단되는 구간이다. 해당 구간에서 예측 오차가 조금 커지는 원인은 비정상적으로 설정된 엔진 클러치 유압이 엔진, 견인 모터 속도의 예측에 사용되기 때문으로 추정된다. 이러한 추정은 비정상 Case 4(Figs. 27~29)에 대한 테스트 결과를 통해서도 확인될 수 있다. 비

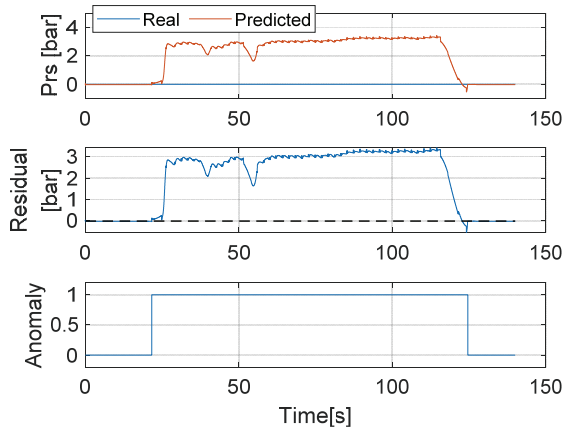


Fig. 18 Anomaly detection result for abnormal test data (abnormal case 1, clutch pressure)




Fig. 21 Anomaly detection result for abnormal test data (abnormal case 2, clutch pressure)




Fig. 19 Anomaly detection result for abnormal test data (abnormal case 1, engine speed)




Fig. 22 Anomaly detection result for abnormal test data (abnormal case 2, engine speed)




Fig. 20 Anomaly detection result for abnormal test data (abnormal case 1, motor speed)




Fig. 23 Anomaly detection result for abnormal test data (abnormal case 2, motor speed)




Fig. 24 Anomaly detection result for abnormal test data (abnormal case 3, clutch pressure)




Fig. 27 Anomaly detection result for abnormal test data (abnormal case 4, clutch pressure)




Fig. 25 Anomaly detection result for abnormal test data (abnormal case 3, engine speed)




Fig. 28 Anomaly detection result for abnormal test data (abnormal case 4, engine speed)




Fig. 26 Anomaly detection result for abnormal test data (abnormal case 3, motor speed)




Fig. 29 Anomaly detection result for abnormal test data (abnormal case 4, motor speed)




Fig. 30 Anomaly detection result for abnormal test data (abnormal case 5, clutch pressure)

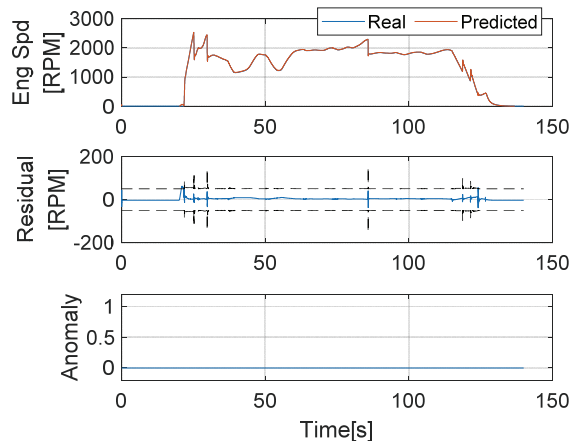


Fig. 31 Anomaly detection result for abnormal test data (abnormal case 5, engine speed)




Fig. 32 Anomaly detection result for abnormal test data (abnormal case 5, motor speed)

정상 Case 4는 엔진 클러치 유압이 정상적일 때보다 조금 작게 가해지는 경우이다. 이상치 탐지 알고리즘은 엔진 클러치 유압이 작게 가해지는 구간을 이상으로 판단하면서 엔진, 견인 모터 속도에 대해서는 정상으로 판단하고 있는 것을 확인할 수 있다. Case 2, 3과 Case 4는 엔진 클러치 유압이 가해지는 정도만 다르기 때문에, Case 2, 3의 50초 부근, Case 3의 100초 부근의 엔진, 모터 속도 예측 오차는 엔진 클러치 유압 때문으로 추정할 수 있다. 또한 이상치 탐지 알고리즘은 Case 4의 엔진 속도에 대해 126초 부근을 이상으로 판단하고 있는데, 해당 구간은 클러치가 떨어지는 시점이 빨라져 엔진과 모터의 속도 차이가 발생하는 시점이 더 빠르게 나타나는 구간이다. 마지막 비정상 Case 5(Figs. 30~32)는 엔진 클러치 유압의 생성, 해제 시간이 정상보다 더 오래 걸리는 경우로, 이상치 탐지 알고리즘이 엔진 클러치 유압에 대해서 유압이 생성, 해제되는 구간을 이상으로 잘 판단하고 있는 것을 볼 수 있다.

5. 결론

본 연구에서는 P2 타입 HEV의 EV↔HEV 모드 변환 시 필요한 엔진 클러치 접합/해지 제어 기능의 이상치 탐지를 위한 LSTM 기반 이상치 탐지 알고리즘을 제안하였다. 제안된 알고리즘은 LSTM을 이용한 예측 신호 예측, 예측 값과 측정 값의 차이로 계산되는 Residual 생성, Threshold를 이용한 이상치 탐지로 구성되어 있다. 이를 위해 예측 신호 예측을 위한 LSTM 모델 구조를 제안하고 학습을 수행하였으며, 학습된 모델의 예측 특징을 고려한 Threshold를 제안하였다. 또한 학습 데이터의 Sequence 길이, LSTM layer의 Hidden unit 개수에 따라 학습을 수행하고 그 결과를 비교함으로써 예측 정확도가 가장 높은 Sequence 길이, Hidden unit 개수를 탐색하였다. 테스트 결과, 알고리즘은 정상, 비정상 데이터 모두에 대해서 높은 정확도로 이상치를 탐지하는 것을 확인할 수 있었다. 이러한 결과를 통해 LSTM이 엔진 클러치 접합/해지 데이터 예측에도 충분히 적용될 수 있음을 확인할 수 있었으며, 제안한 Threshold가 LSTM을 이용한 이상치 탐지에 효과적으로 활용될 수 있음을 검증할 수 있었다. 추후에는 다른 차량 제어 기능과 실제 차량 데이터에 제안한 이상치 알고리즘을 적용하는 것에 대한 연구가 필요하다. 다른 차량 제어 기능에 대한 적용의 경우, 다른 차량 제어 기능에 대한 데이터도 엔진 클러치 접합/해지와 유사한 특징을 가지고 있을 것이기 때문에 제안한 알고리즘이 다른 제어 기능에 대한 데이터에도 충분히 적용될 수 있을 것으로 기대된다. 실제 차량 데이터에 대한 적용의 경우, 제안한 알고리즘의 대상 신호는

모두 CAN 신호에서 취득 가능하기 때문에, 실제 차량에서도 같은 방법으로 알고리즘의 적용이 가능하다. 다만, 실제 차량에서는 시뮬레이션 모델이 표현하지 못하는 거동, 노이즈 등이 발생할 수 있기 때문에, 시뮬레이션 데이터로 학습한 모델을 바로 적용하는 것보다는, 실제 차량 데이터로 LSTM 모델을 다시 학습하고, 이상치 탐지를 위한 Residual의 Threshold offset, 신호 변화량에 따른 Threshold 변화 정도를 튜닝하는 것이 추가적으로 필요할 것으로 예상된다. 만약 신호의 노이즈가 심할 경우에는, 신호에 대한 필터링을 추가 적용하는 것이 효과적일 수 있을 것으로 예상된다.

후 기

이 연구는 2021년도 산업통상자원부 및 산업기술평가관리원(KEIT) 연구비 지원에 의한 연구임('20010132').

References

- 1) T. Lee, S. Kim and Y. Ko, "A Study on the Control Algorithm of VCU for Micro-mobility," Transactions of KSAE, Vol.26, No.1, pp.32-41, 2018.
- 2) T. Lee, M. Kim and Y. Kang, "Nonlinear Model Predict Controller Strategy considering Velocity Reduction by Large Steering Angle in Extreme Maneuver," Transactions of KSAE, Vol.27, No.2, pp.133-144, 2019.
- 3) W. Zhang, W. Guo, X. Liu, Y. Liu, J. Zhou, B. Li, Q. Lu and S. Yang, "LSTM-based Analysis of Industrial IoT Equipment," IEEE Access, Vol.6, pp.23551-23560, 2018.
- 4) A. Gaddam, T. Wilkin, M. Angelova and J. Gaddam, "Detecting Sensor Faults, Anomalies and Outliers in the Internet of Things: A Survey on the Challenges and Solutions," Electronics, Vol.9, No.3, 2020.
- 5) A. Nanduri and L. Sherry, "Anomaly Detection in Aircraft Data using Recurrent Neural Networks (RNN)," 2016 Integrated Communications Navigation and Surveillance(ICNS), pp.5C2-1-5C2-8, 2016.
- 6) L. Basora, X. Olive and T. Dubot, "Recent Advances in Anomaly Detection Methods Applied to Aviation," Aerospace, Vol.6, No.11, Paper No.117, 2019.
- 7) S. Chauhan, L. Vig and S. Ahmad, "ECG Anomaly Class Identification using LSTM and Error Profile Modeling," Computers in Biology and Medicine, Vol.109, pp.14-21, 2019.
- 8) M. Thill, S. Däubener, W. Konen and T. H. W. Bäck, "Anomaly Detection in Electrocardiogram Reading with Stacked LSTM Networks," Proceedings of the 19th Conference Information Technologies – Applied and Theory (ITAT 2019), pp.17-25, 2019.
- 9) Z. Ji, J. Gong and J. Feng, "A Novel Deep Learning Approach for Anomaly Detection of Time Series Data," Scientific Programming, Vol.2021, Article ID 6636270, 2021.
- 10) N. Negi, O. Jelassi, S. Cléménçon and S. Fischmeister, "A LSTM Approach to Detection of Autonomous Vehicle Hijacking," 32nd Conference on Neural Information Processing System (NIPS 2018), 2018.
- 11) J. Hong, Z. Wang and Y. Yao, "Fault Prognosis of Battery System Based on Accurate Voltage Abnormality Prognosis using Long Short-Term Memory Neural Networks," Applied Energy, Vol.251, Paper No.113381, 2019.
- 12) D. Li, Z. Zhang, P. Liu, Z. Wang and L. Zhang, "Battery Fault Diagnosis for Electric Vehicles based on Voltage Abnormality by Combining the Long Short-Term Memory Neural Network and the Equivalent Circuit Model," IEEE Transactions on Power Electronics, Vol.36, No.2, pp.1303-1315, 2021.
- 13) A. Blázquez-García, A. Conde, U. Mori and J. A. Lozano, "A Review on Outlier/Anomaly Detection in Time Series Data," arXiv preprint arXiv:2002.04236, 2020.
- 14) A. A. Cook, G. Mısırlı and Z. Fan, "Anomaly Detection for IoT Time-Series Data: A Survey," IEEE Internet of Things Journal, Vol.7, No.7, pp.6481-6494, 2019.
- 15) R. Chalapathy and S. Chawla, "Deep Learning for Anomaly Detection: A Survey," arXiv preprint arXiv:1901.03407, 2019.
- 16) J. Kim and Y. Park, "Fuel Economy Analysis of Novel Hybrid Powertrain for PHEV," Transactions of KSAE, Vol.27, No.4, pp.325-332, 2019.
- 17) H. Kim, J. Kim and H. Lee, "Mode Transition Control Using Disturbance Compensation for a Parallel Hybrid Electric Vehicle," Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, Vol.225, No.2, pp.150-166, 2011.
- 18) X. Li, J. Liu, M. Bai, J. Li, X. Li, P. Yan and D. Yu, "An LSTM based Method for Stage Performance Degradation Early Warning with Consideration of Time-Series Information," Energy, Vol.226, Paper No.120398, 2021.

- 19) H. Ouyang, J. Zeng, Y. Li and S. Luo, "Fault Detection and Identification of Blast Furnace Ironmaking Process Using the Gated Recurrent Unit Network," Processes, Vol.8, No.4, Paper No.391, 2020.
- 20) H. Shi, S. Hu and J. Zhang, "LSTM based Prediction Algorithm and Abnormal Change Detection for Temperature in Aerospace Gyroscope Shell," International Journal of Intelligent Computing and Cybernetics, Vol.12, No.2, pp.274-291, 2019.
- 21) J. S. Chou and A. S. Telaga, "Real-Time Detection of Anomalous Power Consumption," Renewable and Sustainable Energy Reviews, Vol.33, pp.400-411, 2014.
- 22) MATLAB & Simulink, Explore the Hybrid Electric Vehicle P2 Reference Application, <https://www.mathworks.com/help/autoblks/ug/explore-the-hybrid-electric-vehicle-p2-reference-application.html>, 2021.