

동시학습 기반 배터리 열동역학 온라인 잔차 학습

Concurrent Learning-Based Online Residual Learning for Battery Thermal Dynamics

○장 승 훈¹, 박 창 은¹, 최 경 환^{1*}

¹⁾ 한국과학기술원 조천식모빌리티대학원

(TEL: 042-450-1764; E-mail: {shjang7071, aegis2997, kh.choi}@kaist.ac.kr)

Abstract This paper presents a data-driven online identification method for battery thermal dynamics in battery thermal management systems. An offline-identified lumped thermal model is used as a nominal battery thermal model, but its accuracy can deteriorate when operating conditions, ambient temperature, and load conditions vary. To improve model accuracy, a concurrent learning-based approach is introduced to learn the unmodeled thermal dynamics online while keeping the estimation errors bounded. The learning rules utilize the informative stored data together with current measurements, thereby improving parameter convergence without requiring continuous persistent excitation. Simulation studies in the MATLAB/Simulink 2025a EV environment show that the proposed method improves long-horizon temperature prediction and reduces rollout RMSE by up to 32.3% compared with the offline model.

Keywords Concurrent learning, battery thermal management, model predictive control

1. 서론

전기자동차 배터리 열관리 시스템(Battery Thermal Management, BTM)은 배터리의 안전성, 성능 및 수명을 유지하기 위한 핵심 요소이다. BTM에서는 냉각 에너지를 줄이면서 배터리 온도 제약을 만족시키기 위해 모델 예측 제어(Model Predictive Control, MPC)가 널리 활용되며, MPC의 성능은 예측 모델의 정확도에 크게 좌우된다. 그러나 실험 데이터로 식별한 배터리 열모델은 실제 주행 환경에서 주행 부하, 외기 온도, 냉각 시스템 특성 변화 등으로 인해 모델 불일치가 발생할 수 있고, 이는 예측 지평이 길어질수록 누적되어 냉각 입력 결정의 최적성을 저하시킨다.

본 논문에서는 이러한 모델 불일치로 인한 잔차항을 데이터 기반 동시학습(Concurrent Learning, CL)을 통해 온라인으로 학습하는 방법을 제안한다. 제안한 방법은 현재 측정 데이터와 저장된 과거 데이터를 함께 활용하여 잔차 동역학을 보정함으로써, MPC에서 사용하는 배터리 열모델의 장기 예측 성능을 향상시킨다.

2. 배터리 열동역학 모델링

2.1 배터리 열모델

BTM 시스템에서 배터리의 열 모델을 다음과 같은 1차 집중정수 열모델로 표현할 수 있다.

$$\dot{T}_{bat} = \frac{1}{m_{bat}C_{th,bat}} \left(I_{bat}^2 R_{in} + h_a (T_{bat} - T_{env}) + \dot{Q}_c \right), \quad (1)$$

여기서 m_{bat} , $C_{th,bat}$, T_{bat} , h_a , I_{bat} 그리고 R_{in} 은 각각 배터리 등가 질량, 열용량, 온도, 열전달 계수, 전류 그리고 내부 저항을 의미한다. $\dot{Q}_c < 0$ 는 배터리 냉각에 의해 제거되는 냉각 열유량을 나타내며, 냉각에 필요한 전력 P_c 는 아래와 같은 선형 관계를 갖는다 [1].

$$P_c(\dot{Q}_c) = a_c \dot{Q}_c, \quad a_c < 0 \quad (2)$$

식 (1)에서 내부저항은 배터리의 state-of-charge 와 온도에 따라 비선형적으로 변하며, 배터리의 등가 질량 및 열용량 또한 정확하게 식별하기 어렵다.

3. 데이터 기반 온라인 잔차 모델 학습

3.1 잔차 학습을 위한 일반화 모델

식 (1)을 명목 모델과 모델 불확실성에 의한 잔차 항으로 일반화하여 나타내면 아래와 같다.

$$\dot{x}(t) = f(x(t), u(t)) + g(x(t), u(t), w(t)), \quad (3)$$

여기서 f 는 식 (1)의 공칭 모델을 나타내고, $g(\cdot)$ 는 모델 불확실성, 파라미터 오차 및 외란에 의한 잔차 동역학을 의미한다. $x(t)$, $u(t)$, $w(t)$ 는 각각 배터리 온도, 제어 입력, 그리고 주행조건에 따른 측정 가능한 외란을 나타낸다. 잔차 동역학은 이상적인 가중치에 대한 파라미터 $\mathbf{W}^* \in \mathbb{R}^m$ 와 회귀벡터 $\Phi(\cdot) \in \mathbb{R}^m$ 로 표현할 수 있다.

$$g(x(t), u(t), w(t)) = \mathbf{W}^{*T} \Phi(x(t), u(t), w(t)) + \varepsilon(t), \quad (4)$$

여기서 잔차 동역학 추정치 $\hat{g}$ 은 가중치 추정 가중치

* 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (RS-2025-00554087).

$\hat{\mathbf{W}} \in \mathbb{R}^m$ 로 아래와 같이 표현할 수 있다.

$$\hat{g}(x(t), u(t), w(t)) = \hat{\mathbf{W}}^\top \Phi(x(t), u(t), w(t)). \quad (5)$$

3.2 데이터 기반 동시 학습

식 (5)의 잔차 추정 모델은 다음과 같은 데이터 기반 미분 상태 관측기를 설계하여 학습할 수 있다 [2].

$$\begin{aligned} \dot{\hat{x}}(t) &= f(x(t), u(t), w(t)) + (k_x + \alpha)\tilde{x}(t) + \hat{\mathbf{W}}^\top \Phi + \mu(t), \\ \dot{\mu}(t) &= (k_x \alpha + 1)\tilde{x}(t), \end{aligned} \quad (6)$$

여기서 $\tilde{x} := x - \hat{x}$ 는 상태 추정 오차, k_x, α 는 관측기 이득, μ 는 잔차 동역학 추정을 보정하기 위한 보조 신호를 의미한다. 식 (6) 기반 상태 추정 오차를 바탕으로, 잔차 모델의 가중치는 아래와 같이 학습된다.

$$\dot{\hat{\mathbf{W}}} = \Gamma_1 \Phi \tilde{x} + \Gamma_2 \sum_{i=1}^M \Phi_i (\dot{\hat{x}}_i - f_i - \hat{\mathbf{W}}_i^\top \Phi_i), \quad (7)$$

여기서 Γ_1 과 Γ_2 는 학습률, M 은 데이터 히스토리에 저장된 데이터 수를 나타낸다. 식 (7)의 첫 번째 항은 현재 추정 오차 기반 갱신 항이며, 두 번째 항은 저장 데이터를 활용한 동시학습 항이다. 이를 통해 지속 여기 조건을 만족하기 어려운 열관리 시스템에서도 파라미터 수렴성을 향상시킬 수 있다.

4. 시뮬레이션 결과

4.1 추정 성능 비교

제안한 동시학습 기반 잔차 학습 방법의 추정 성능은 MATLAB & Simulink2025a 환경에서 검증하였다. 현재 추정 오차만을 사용하는 방법(INST)과 저장 데이터를 함께 사용하는 방법(CONC)을 비교하였으며, 동시학습에는 1 초 간격으로 버퍼에 저장한 $M=200$ 개의 데이터를 사용하였다. 그림 1 은 각 방법의 가중치 추정값 노름과 상태 추정 오차를 나타낸다.

그림 1 에서 CONC 는 저장 데이터를 활용함으로써 INST 보다 가중치 추정값이 더 안정적으로 수렴하는 경향을 보인다. 또한 상태 추정 오차가 작은 범위 내에 유지되어, 제안한 방법이 모델 불일치를 효과적으로 보정함을 확인할 수 있다.




그림 1. 데이터 기반 동시학습 (CONC)과 현재 오차 (INST) 기반 가중치 학습 및 상태 추정 오차 비교.

4.2 예측 성능 비교

제안한 방법의 장기 예측 성능을 평가하기 위해 OFF, INST, CONC의 배터리 온도 예측 결과와

예측 지평별 RMSE를 비교하였다. OFF는 전체적인 온도 변화 경향을 추종하지만, 예측 지평이 길어질수록 모델 불일치에 의한 오차가 누적된다. 반면 INST와 CONC는 온라인 잔차 보정을 통해 OFF보다 낮은 예측 오차를 보인다. CONC는 저장 데이터를 함께 활용하여 잔차 동역학을 학습하므로 모든 예측 지평에서 가장 낮은 RMSE를 나타낸다. 1초 예측에서는 세 방법의 차이가 작지만, 10초 이상의 예측 지평에서는 성능 개선 효과가 뚜렷하며, CONC는 OFF 대비 10초, 25초, 50초 예측에서 각각 32.3%, 29.6%, 21.9%의 RMSE 감소를 보였다.




그림 2. 배터리 모델 예측 성능 비교.

5. 결론

본 논문에서는 BTM 시스템의 배터리 열모델에서 발생하는 모델 불일치를 보정하기 위해 동시학습 기반 온라인 잔차 학습 방법을 제안하였다. 제안한 방법은 현재 측정 데이터와 저장된 과거 데이터를 함께 활용하여 잔차 동역학을 학습함으로써 모델 예측 성능을 향상시킨다.

MATLAB/Simulink 시뮬레이션에서 동시학습 기반 모델은 현재 오차 기반 적응 모델보다 안정적인 가중치 수렴 특성을 보였으며, 오프라인 명목 모델 대비 장기 배터리 온도 예측 오차를 감소시켰다. 향후 연구에서는 제안한 잔차 학습 모델을 MPC와 결합하여 배터리 온도 제약 만족 및 냉각 에너지 절감 성능을 평가할 예정이다.

참고문헌

- [1] M. R. Amini, J. Sun and I. Kolmanovsky, "Two-Layer Model Predictive Battery Thermal and Energy Management Optimization for Connected and Automated Electric Vehicles," *2018 IEEE Conference on Decision and Control (CDC)*, Miami, FL, USA, 2018, pp. 6976-6981, doi: 10.1109/CDC.2018.8618716.
- [2] Kamalapurkar, Rushikesh, et al. "Concurrent learning for parameter estimation using dynamic state-derivative estimators." *IEEE Transactions on Automatic Control* 62.7 (2017): 3594-3601.