

선형 회귀 분석법을 이용한 머신 러닝 기반의 SOH 추정 알고리즘

강승현¹, 노태원¹, 이병국[†]

Machine Learning-based SOH Estimation Algorithm Using a Linear Regression Analysis

Seung-Hyun Kang¹, Tae-Won Noh¹, and Byoung-Kuk Lee[†]

Abstract

A battery state-of-health (SOH) estimation algorithm using a machine learning-based linear regression method is proposed for estimating battery aging. The proposed algorithm analyzes the change trend of the open-circuit voltage (OCV) curve, which is a parameter related to SOH. At this time, a section with high linearity of the SOH and OCV curves is selected and used for SOH estimation. The SOH of the aged battery is estimated according to the selected interval using a machine learning-based linear regression method. The performance of the proposed battery SOH estimation algorithm is verified through experiments and simulations using battery packs for electric vehicles.

Key words: BMS (Battery Management System), SOH (State-of-Health), ML (Machine Learning), OCV (Open Circuit Voltage), Linear coefficient

1. 서 론

리튬이온 배터리는 충·방전 횟수가 증가할수록 배터리가 노화되어 전류 용량이 감소하게 되며, 특히 전기자동차의 경우 다양한 조건에서 동작할 수 있기 때문에 전류 용량의 감소가 급속히 진행될 수 있다. 이러한 전류 용량의 감소는 과충전 및 과방전뿐만 아니라 다양한 상태 지표의 추정 정확도 저하를 야기한다. 따라서, 감소된 배터리의 전류 용량을 실시간으로 추정할 수 있는 state of health(SOH) 추정 알고리즘이 반드시 필요하다^{[1]-[4]}.

SOH는 노화되지 않은 배터리의 전류 용량 대비 현재 전류 용량을 나타내는 상태 지표로 사용된다. 이러한

SOH를 추정하는 알고리즘은 전류 용량의 변화와 유사한 경향이 나타나는 파라미터를 규명하고 규명된 파라미터를 실시간으로 추출할 수 있는 알고리즘을 통해 파라미터를 추정함으로써 SOH를 산출하게 된다. 따라서 SOH 추정을 위해서는 실제 어플리케이션의 동작 환경에서 추출이 가능한 파라미터의 선정이 필요하며, 파라미터를 실시간으로 추출할 수 있는 알고리즘의 개발이 필요하다.

기존 SOH 추정 알고리즘에서는 SOH를 추정하기 위한 파라미터로써 배터리의 내부 저항이 사용되었다^[5]. 하지만 내부 저항의 경우 배터리가 노화됨에 따라 증가하는 경향을 가지고 있지만, 배터리 전류 용량의 감소와 비례하여 증가하지 않기 때문에 직접적인 관계 규명이 어려워 내부 저항을 이용한 SOH 추정에는 한계가 존재한다. 이러한 이유로 인해 SOH 변화에 따라 직접적인 변화 관계를 가지는 파라미터의 선정이 필요하며, 기존 연구에서는 직접적인 연관 관계를 갖는 파라미터로써 incremental capacity(IC) 및 differential voltage(DV) curve가 제안되었다. 그러나 IC 및 DV curve 추출을 위해서는 0.2C의 정전류 충·방전이 요구되기 때문에 충·방전 전류의 크기가 크고 가변적인 어플리케이션에 적용하기에는 한계가 존재한다^{[6],[7]}. 따라서 전류 프로파일이

Paper number: TKPE-2021-26-4-1

Print ISSN: 1229-2214 Online ISSN: 2288-6281

[†] Corresponding author: bklee@skku.edu, Dept. of Electrical Engineering, Sungkyunkwan University, Korea

Tel: +82-31-299-4581 Fax: +82-31-299-4612

¹ Dept. of Electrical & Computer Engineering, Sungkyunkwan University, Korea

Manuscript received Mar. 2, 2021; revised Apr. 1, 2021;

accepted Apr. 20, 2021

— 본 논문은 2020년 추계학술대회 우수추천논문임

— 본 논문은 2020년 추계학술대회 우수논문상 수상논문임

동작 환경에 따라 변화하는 전기자동차와 같은 어플리케이션에 적용하기 위해서는 실제 동작 환경이 고려된 실시간 SOH 추정 알고리즘의 개발이 요구된다.

실시간 SOH 추정 알고리즘의 구현을 위해 확장 칼만 필터 등의 재귀적 필터를 이용한 방법이 제안되었으며, 배터리 내부 저항 및 방전과 충전 사이의 시간 간격을 활용한 health indicator(HI)등의 파라미터를 실시간으로 추출하였다^{[8],[9]}. 그러나 이와 같은 방법을 통해 실시간으로 파라미터를 추정하는 경우 필터의 가중치에 의해 실제 파라미터와의 오차가 발생할 수 있으며, 이러한 오차는 SOH의 추정 정확도 감소를 야기시킬 수 있다.

따라서 최근에는 다수의 배터리에서 추출된 데이터를 활용한 머신 러닝(machine learning) 기반의 SOH 추정 알고리즘의 연구가 진행 중이다^{[10]-[13]}. 머신 러닝을 이용한 SOH 추정 방법으로는 support vector regression (SVR), 선형 및 비선형 회귀 모델 등이 제안되었으며, 이러한 머신 러닝 기반의 SOH 추정 알고리즘은 SOH 변화에 따라 변화하는 많은 수의 데이터 간의 경향성을 모사하는 모델을 규명하고 도출함으로써 기존 SOH 추정 알고리즘 대비 높은 정확도의 SOH를 추정할 수 있게 된다.

따라서 본 논문에서는 머신 러닝 기반의 SOH 추정 알고리즘을 제안한다. 이를 위해 배터리 노화에 따라 감소하는 전류 용량과 비례하여 선형적으로 변화하는 파라미터인 open circuit voltage(OCV)의 기울기 변화를 분석한다. 또한 머신 러닝 기반의 선형 회귀 분석을 이용하여 선정된 파라미터를 실시간으로 추출하고, 추출된 파라미터를 통해 노화된 배터리의 SOH를 실시간으로 추정한다.

본 논문은 아래와 같이 구성된다. 2장에서는 6개의 배터리 셀을 이용한 노화 실험을 진행하였으며, 배터리 등가 회로 모델을 이용하여 SOH 변화와 관련된 파라미터 분석 및 선정을 진행한다. 3장에서는 알고리즘의 순서도 및 배터리 셀을 이용한 검증을 통해 제안하는 알고리즘의 동작 원리를 설명한다. 4장에서는 제안하는 알고리즘의 검증을 위해 전기자동차의 주행 프로파일인 highway fuel economy test(HWFET) 및 new european driving cycle(NEDC)를 활용하여 알고리즘의 실시간 SOH 추정 정확도를 검증한다.

2. SOH 추정을 위한 파라미터 선정

2.1 배터리 ECM 파라미터 추출 및 분석

표 1은 SOH가 각각 다르게 조성된 lithium nickel manganese cobalt oxide(NMC) 타입의 배터리 셀(B1-B6) 정보를 보여준다. B1은 begin of life(BOL) 배터리를 의미하고, B2-B6은 1C-rate의 정전류 충·방전을 통해 서로 다른 전류 용량을 갖도록 노화 실험을 진행하였으며, B6은 수명이 종료된 상태(End-of-Life, EOL)의 셀을 나타낸다.

TABLE I
SYSTEM PARAMETERS

Battery Type		Lithium Nickel Manganese Cobalt Oxide	
Voltage Range [V]		2.9-4.2	
Cell	Capacity [Ah] (SOH)	Cell	Capacity [Ah] (SOH)
B1	28.033 (100%)	B4	25.071 (89.4%)
B2	27.144 (96.8%)	B5	24.754 (88.3%)
B3	25.612 (91.6%)	B6	22.873 (81.6%)

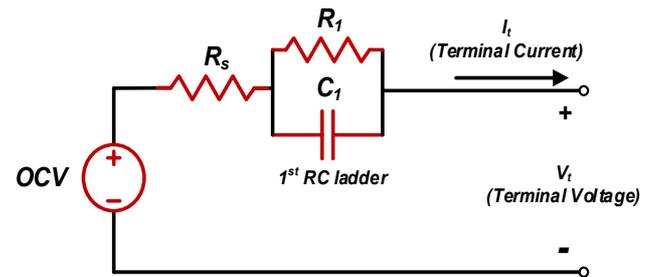


Fig. 1. Equivalent circuit model of battery.

배터리 모델로는 그림 1과 같이 R_s , R_1 , C_1 , OCV로 구성된 배터리 등가 회로 모델(Equivalent Circuit Model, ECM)을 사용하여 B1-B6 셀의 파라미터를 추출하였으며, 잔존 용량에 따른 파라미터의 변화는 그림 2와 같이 나타낼 수 있다. 이때, 잔존 용량은 배터리의 남아 있는 전류 용량으로써 노화가 진행될수록 잔존 용량의 최댓값이 감소한다.

그림 2의 파라미터 중 R_s , R_1 , C_1 의 경우 SOH 감소에 따른 파라미터의 변화 경향이 비선형적으로 나타나기 때문에 SOH 추정을 위한 파라미터로서의 선정에 한계가 존재한다. 반면 OCV의 경우 SOH 감소에 따라 곡선이 응축하여 곡선의 기울기가 선형적으로 증가하는 양상을 보이기 때문에 SOH 추정을 위한 파라미터로 OCV 곡선의 기울기를 선정하였다.

이때, SOC 20-90% 영역의 경우 OCV 곡선의 기울기가 다른 영역에 비해 선형적으로 증가하며, 일반적으로 SOC 20-90% 구간에서 배터리 운용이 이루어지기 때문에 실시간으로 OCV를 추정하여 기울기를 산출하는 것이 용이하다^[14]. 하지만 SOC 60%를 기점으로 서로 다른 기울기 값을 가지는 경향을 보이기 때문에 그림 2(a)와 같이 기울기 추출 구간을 구간 1, 2로 구분하여 분석을 진행해야 한다. 구간 1과 2에서 OCV의 기울기를 추출하는 경우 OCV 데이터의 변화가 선형적일수록 OCV 곡선의 일정한 기울기를 추출하는데 유리하다. 그러므로 OCV 데이터가 높은 선형 관계를 가지는 구간을 선정하기 위해 구간 1과 2에 대한 선형성 분석이 요구된다.

따라서 데이터의 선형성을 나타내는 계수인 Pearson 계수를 도입하여 그림 3(a), (b)에 대하여 잔존 용량에

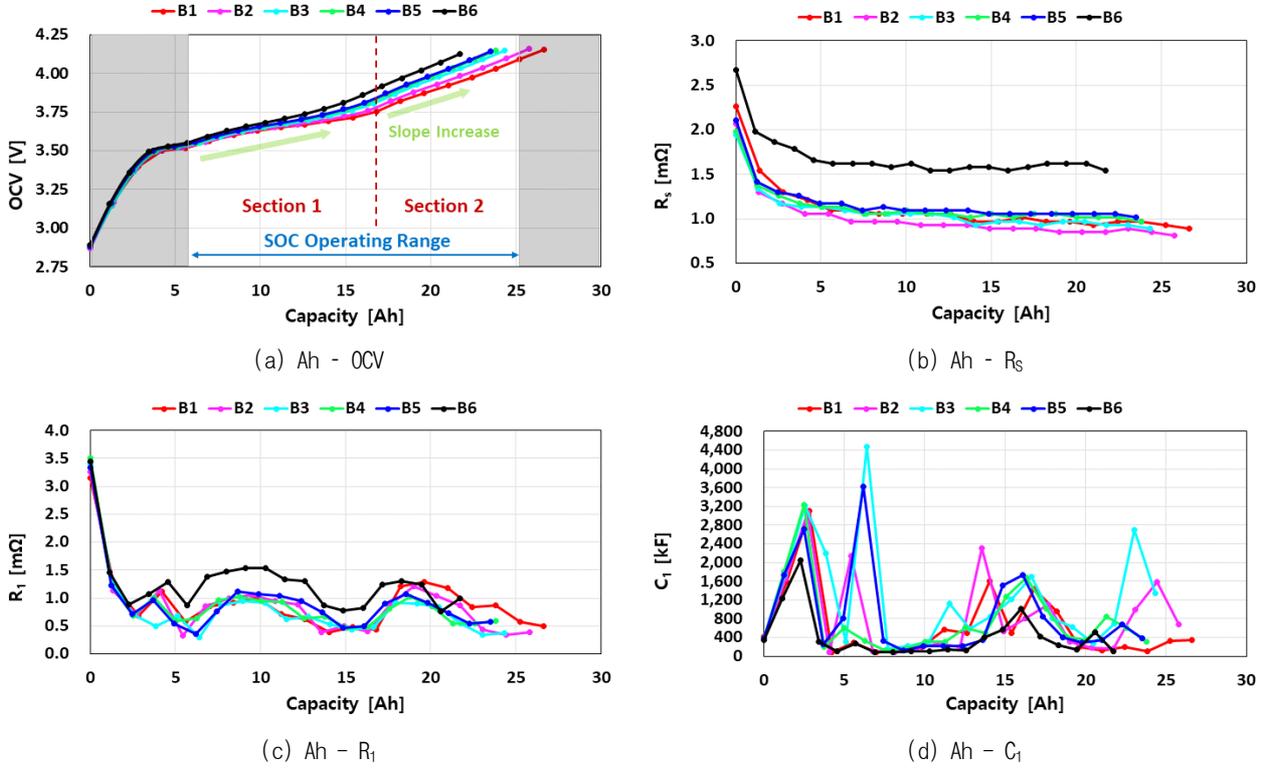


Fig. 2. Parameters lookup table of 6 battery cells with different SOH.

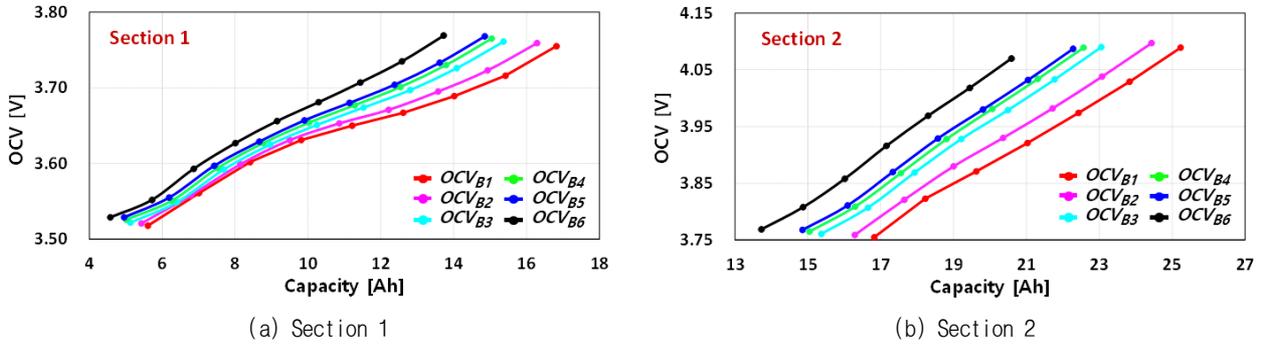


Fig. 3. OCV data distribution according to SOC operating area.

따른 OCV 곡선의 선형성 분석 및 비교를 통해 높은 선형성을 가지는 구간을 선정하였다. 이때, 구간별 Pearson 계수는 (1)를 통해 도출할 수 있다.

$$r = \frac{\sum_{i=1}^n (x_k - \bar{x}_k)(y_k - \bar{y}_k)}{\sqrt{\sum_{i=1}^n (x_k - \bar{x}_k)^2 \sum_{i=1}^n (y_k - \bar{y}_k)^2}} \quad (k=1, 2, \dots, 6) \quad (1)$$

$$x_k = \{Ah_1, Ah_2, \dots, Ah_n\},$$

$$y_k = \{OCV_1, OCV_2, \dots, OCV_n\}$$

식 (1)에서 x_k, y_k 는 구간별 각 배터리 셀의 잔존 용량 및 OCV 데이터, \bar{x}_k, \bar{y}_k 는 데이터의 평균값을 의미한다. 또한 r 은 곡선의 선형성을 나타내며 r 이 +1 또는

-1에 가까울수록 강한 양 또는 음의 선형 관계를 가져 기울기 도출이 가능하므로 SOH 추정에 사용되기에 적합하지만, r 이 0에 가까울수록 데이터 간의 낮은 선형 관계로 인해 기울기 도출의 어려움이 존재하여 SOH 추정에 사용되기엔 부적합하다.

표 2는 (1)를 통해 구간 1, 2의 선형성을 분석한 결과를 나타낸다. 표 2에서 각 배터리 셀을 통해 추출한 선형성의 평균값이 구간 2의 경우 0.9994로 나타나 0.9956으로 나타난 구간 1에 비해 더 높은 선형 관계를 갖는 것을 확인하였으며, 따라서 구간 2의 OCV 곡선의 기울기를 SOH와 연관된 파라미터로 선정하였다.

2.2 SOH에 따른 OCV 곡선의 기울기 분석

SOH 추정 시 OCV 곡선의 기울기에 따른 SOH의 관계를 규명하기 위해서는 OCV 곡선의 기울기와 SOH의 관

TABLE II
PEARSON CORRELATION ACCORDING TO SECTION

	B1	B2	B3	B4	B5	B6	Average
Section 1	0.9900	0.9938	0.9967	0.9972	0.9975	0.9982	0.9956
Section 2	0.9992	0.9996	0.9996	0.9995	0.9995	0.9992	0.9994

계식 도출이 반드시 필요하다. 따라서 그림 3(b)의 구간 2에 해당하는 각 배터리 셀의 OCV 데이터의 기울기를 도출하기 위해 Matlab의 Curve fitting tool을 사용하여 그림 4와 같이 나타내었다. 그림 4의 $Linear\ model_{B1-B6}$ 은 B1-B6 셀의 OCV 데이터를 모사하는 선형 함수로써, 도출된 선형 함수의 기울기를 통해 OCV 데이터의 기울기를 산출할 수 있다.

$$OCV_i(Ah_i) = W_i \times Ah_i + b_i \quad (2)$$

선형 함수는 식 (2)과 같이 표현이 가능하며, (2)에서 W 와 b 는 각각 OCV 곡선의 기울기 및 bias를 나타내고 i 는 배터리 셀의 번호를 의미한다.

식 (2)에서 도출된 각 배터리 셀의 W 및 SOH를 통해 SOH와 OCV 곡선의 기울기에 대한 관계식을 (3)와 같이 정의할 수 있으며, 그림 5와 같이 배터리 셀의 노화가 진행됨에 따라 W 는 증가하는 경향을 가진다.

$$SOH_i(W_i) = -2701W_i + 205.9 \quad (3)$$

따라서 제안하는 알고리즘은 OCV를 실시간으로 추정하고, 추정된 OCV의 W 를 도출함으로써 (3) 및 그림 5를 통해 SOH를 산출할 수 있다.

3. 제안하는 SOH 추정 알고리즘

그림 6은 제안하는 SOH 추정 알고리즘의 순서도를 나타내며, 그림 7은 배터리 셀 B2를 기반으로 제안하는 알고리즘을 구현한 결과를 나타낸다. 구간 2의 OCV 곡선의 기울기를 도출하기 위해 저역 통과 필터(Low Pass Filter, LPF)를 이용하여 배터리의 단자 전압으로부터 실시간으로 OCV 데이터를 추출한다. 이때, SOC가 구간 2에 해당하는 60-90% 영역을 만족할 경우, 추출된 OCV 데이터를 학습 데이터(training set)로 활용하여 머신 러닝 기반의 선형 회귀법(linear regression)을 통해 W 를 도출한다. 도출된 W 는 2.3절의 (4) 및 그림 5를 통해 배터리 셀의 SOH로 산출된다. 제안하는 SOH 추정 알고리즘의 동작은 크게 3단계(Step 1-3)로 구성되며, 세부 동작 원리는 아래와 같다.

Step 1: OCV가 배터리의 내부 임피던스에 인가되는 전압에 비해 변화율이 작은 특성을 이용하여 (4)와 같이

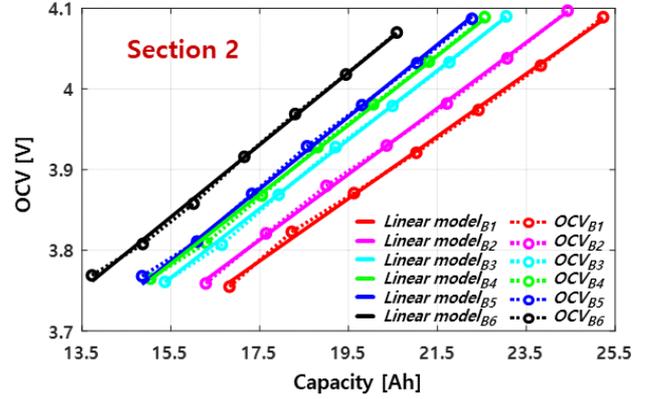


Fig. 4. Data and linear model of OCV curve in section 2.

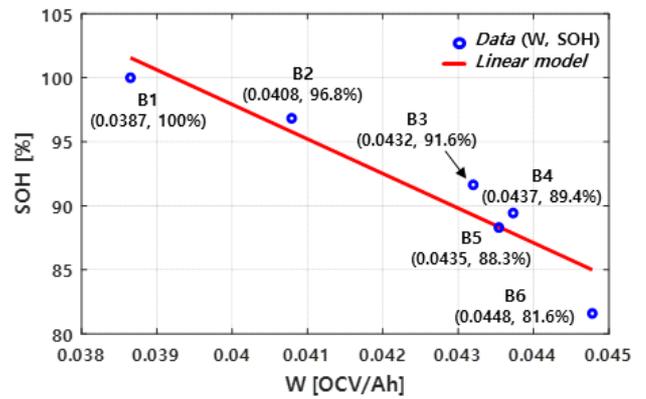


Fig. 5. Correlation between W and SOH according to aging.

LPF 기반의 OCV 추정 알고리즘을 사용한다^[15].

$$OCV_{est}(k) = \alpha \cdot OCV_{est}(k-1) + (1-\alpha) \cdot v_t(k) \quad (4)$$

식 (4)의 $v_t(k)$ 는 그림 1의 단자 전압을 의미하며, battery management system(BMS)의 측정 및 연산 주기인 0.1[s] 간격으로 단자전압이 측정된다. OCV 추정의 정확도를 향상시키기 위해 (5)에 나타난 필터의 계인 (α) 실시간 업데이트 방식을 사용하여 α 를 실시간으로 업데이트한다.

$$\alpha = 1 - \frac{1}{1 + \frac{-OCV(k-1) - v_t(k-1) - R_s(k) \cdot \Delta i_t(k)}{OCV(k) - OCV(k-1)}} \quad (5)$$

이때, 추출된 R_s 및 OCV 파라미터를 이용하여 α 를 업데이트할 수 있으며, 그림 7(a)는 highway fuel economy test(HWFET) 프로파일 인가 시의 추출된 실시간 OCV 추정 결과를 나타낸다. 추출된 OCV 데이터의 root mean square error(RMSE)는 11.41[mV]로 높은 정확도를 가지고 실시간으로 OCV를 추정하는 것을 확인하였다. 추출된 OCV 데이터는 Step 2의 선형 회귀 모델의 학습 데이터로 사용된다.

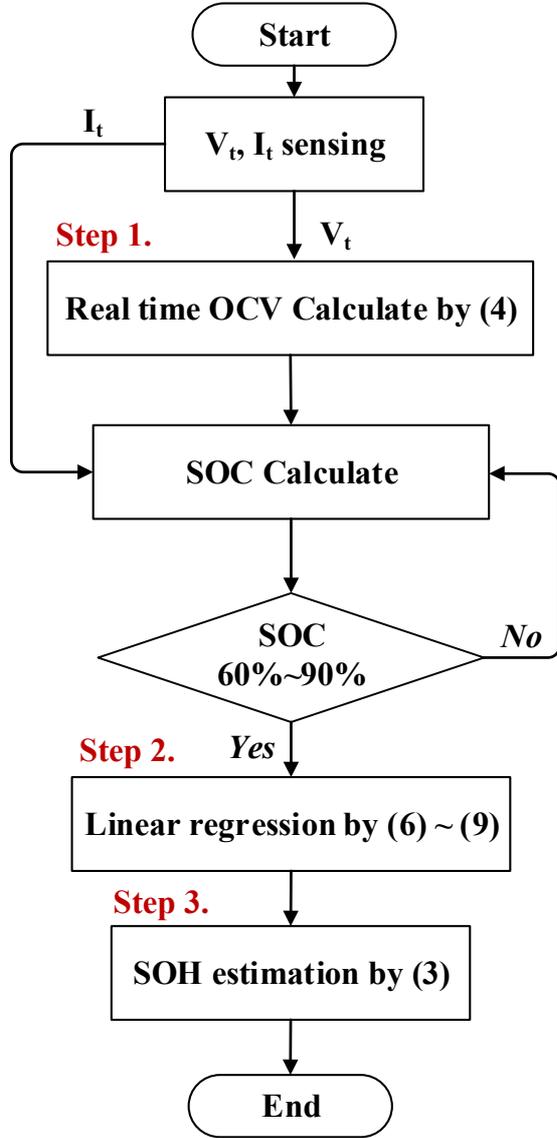


Fig. 6. Flowchart of proposed SOH estimation algorithm.

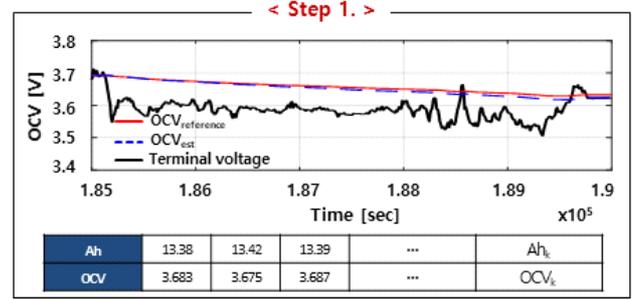
Step 2 Step 1에서 확보한 OCV 학습 데이터를 기반으로 W를 도출하기 위해 머신 러닝 기반의 선형 회귀법을 이용한다. 선형 회귀법을 통해 도출된 선형함수는 (6)과 같은 OCV의 hypothesis 모델(\hat{OCV})로 표현이 가능하다.

$$\hat{OCV}(Ah_k) = \hat{W}_i \times Ah_k + \hat{b}_i \quad (6)$$

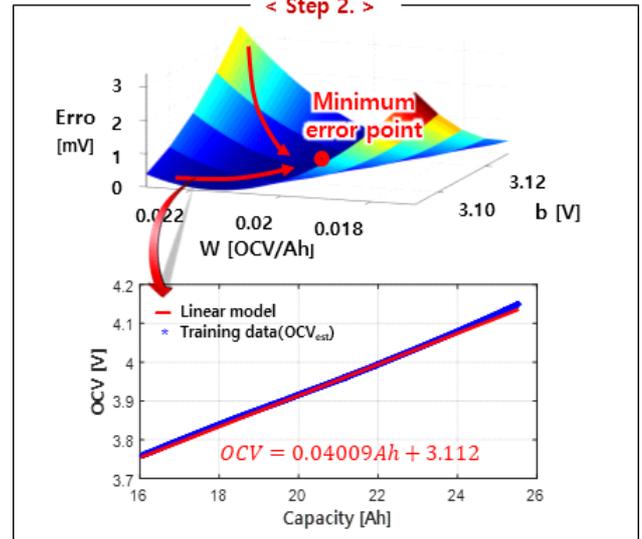
여기서 \hat{W}_i 와 \hat{b}_i 는 각각 hypothesis 모델의 기울기와 bias를 의미하며, k는 학습 데이터의 index를 나타낸다.

$$\text{cost}(\hat{W}, \hat{b}) = \frac{1}{n} \times \sum_{i=1}^n (\hat{OCV}(Ah_k) - y_k)^2 \quad (7)$$

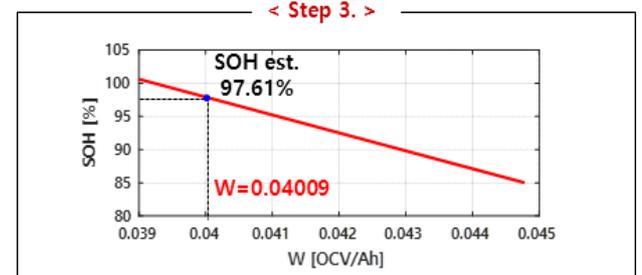
식 (7)은 hypothesis 모델과 Step 1에서 추출된 학습 데이터 사이의 오차로 표현되는 비용(cost) 함수를 나타내



(a) Realtime OCV data extraction using LPF



(b) Derivation of W through linear regression



(c) SOH estimation

Fig. 7. Verification process of the proposed algorithm using B2.

며, 학습 데이터의 정확한 hypothesis 모델을 찾기 위해서는 비용 함수를 최소화하는 \hat{W}_i 와 \hat{b}_i 를 도출해야 한다.

$$\hat{W}_k = \hat{W}_{k-1} - \alpha_1 \frac{1}{n} \sum_{i=1}^n (\hat{W}_{k-1} Ah_{k-1} - y_{k-1}) x_{k-1} \quad (8)$$

$$\hat{b}_k = \hat{b}_{k-1} - \alpha_2 \frac{1}{n} \sum_{i=1}^n (\hat{b}_{k-1} Ah_{k-1} - y_{k-1}) \quad (9)$$

따라서 (8), (9)와 같이 경사 하강법(gradient descent

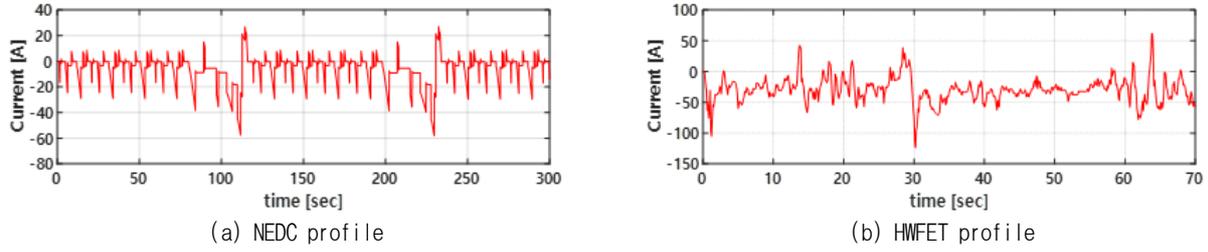


Fig. 8. Driving profile for electric vehicles for proposed algorithm verification.

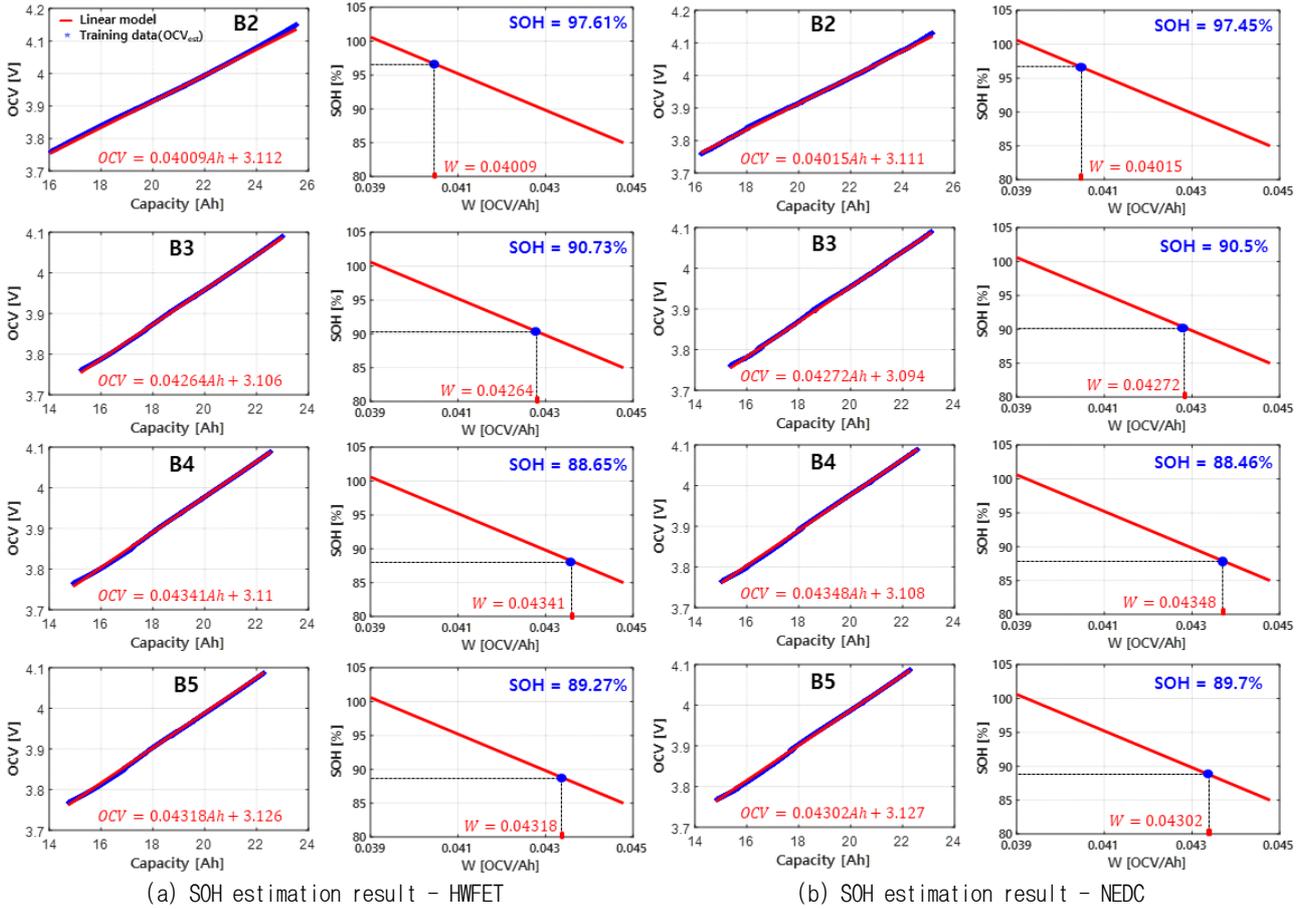


Fig. 9. Verification results of the proposed SOH estimation algorithm using battery cells B2-B5 with various current profiles.

algorithm)을 이용하여 최적의 \hat{w}_i 와 \hat{b}_i 를 도출한다. 식 (8), (9)의 α_1 및 α_2 는 학습률(learning rate)을 나타내는 파라미터로써 사용자 임의로 값을 지정하여 사용할 수 있으며, 본 논문에서 사용된 학습률(α_1, α_2)은 각각 $1 \times 10^{-6}, 1 \times 10^{-8}$ 을 사용하였다. 그림 7(b)는 \hat{w}_i 와 \hat{b}_i 에 따른 hypothesis 모델의 비용 함수를 보여주며 경사 하강법을 통해 비용 함수가 최소가 되는 \hat{w}_i 와 \hat{b}_i 의 값은 각각 0.04009 및 3.112로 나타난다.

Step 3 Step 2에서 도출된 \hat{w}_i 를 (3)에 대입하여 배터리 셀의 SOH를 산출한다. Step 2의 선형 회귀법을 통해 추정된 B2의 SOH는 97.61%로써, B2의 실제 SOH가

96.8%임을 고려할 때 오차율 0.81%의 높은 SOH 추정 정확도를 확인할 수 있다.

4. 실험을 통한 SOH 추정 알고리즘 검증

제안하는 SOH 추정 알고리즘을 검증하기 위하여 그림 8과 같은 전기자동차용 주행프로파일인 HWFET 및 NEDC를 표 1의 배터리 셀 B2-B5에 반복적으로 인가하여 검증을 진행하였다. 그 결과 알고리즘의 Step 1에 의한 OCV 추정 오차가 표 3과 같이 나타나며, OCV 추정 최대 오차는 35.69[mV]로 그림 3(a)의 OCV값 대비 약 1%의 오차가 발생하는 것으로 확인되었다. 그림 9는 Step 1을 통해 추정된 OCV를 이용하여 SOH를 추정한다

TABLE III
SOH ESTIMATION ERROR OF THE PROPOSED
ALGORITHM

Battery Cell	HWFET Profile		NEDC Profile	
	OCVest. RMSE [mV]	SOH err.	OCVest. RMSE [mV]	SOH err.
B2	11.41	0.81	30.76	0.65
B3	13.14	0.87	25.87	1.1
B4	13.64	0.75	35.69	0.94
B5	12.42	0.97	23.01	1.4
Average	12.65	0.85 %	28.83	1.02 %

결과이다. SOH 추정은 3장에서 설명한 *Step 2* 및 *Step 3*과 동일한 방법을 통해 진행하였다. 각 배터리 셀 B2-B5의 실시간으로 추출된 OCV 데이터(training data)를 통해 hypothesis 모델(linear model)이 도출되었으며, linear model의 W를 (3)에 대입하여 실제 SOH와 비교한 결과는 표 3과 같다. 표 3에서 HWFET 프로파일 인가 시의 SOH 오차가 NEDC 프로파일 대비 SOH 추정 정확도가 높은 것을 확인하였으며, NEDC 또한 평균 1.02%의 SOH 추정 오차를 가져 높은 SOH 추정 정확도를 갖는 것을 확인하였다.

5. 결 론

본 논문에서는 머신 러닝 기반의 선형 회귀 분석법을 통해 배터리의 SOH를 추정하는 알고리즘을 제안하였다. SOH와 연관된 파라미터인 OCV를 이용하여 SOH와의 관계식을 도출하고, OCV 곡선의 기울기를 선형 회귀 분석을 통해 추정하여 SOH 산출 및 정확도 분석을 진행하였다. 추정 오차는 최소 0.65%, 최대 1.4%로써 높은 정확도로 SOH를 추정함을 확인하였으며, 제안하는 알고리즘이 배터리 SOH 추정에 적합함을 검증하였다.

References

- [1] P. Shen, M. Ouyang, L. Lu, J. Li, and X. Feng, "The co-estimation of state of charge, state of health, and state of function for lithium-ion batteries in electric vehicles," *IEEE Transactions on Vehicular Technology*, Vol. 67, No. 1, pp. 92-103, Jan. 2018.
- [2] A. El Mejdoubi, H. Chaoui, H. Gualous, P. Van Den Bossche, N. Omar, and J. Van Mierlo, "Lithium-ion batteries health prognosis considering aging conditions," *IEEE Transactions on Power Electronics*, Vol. 34, No. 7, pp. 6834-6844, Jul. 2019.
- [3] N. Li, F. Gao, T. Hao, Z. Ma, and C. Zhang, "SOH balancing control method for the MMC battery energy storage system," *IEEE Transactions on Industrial Electronics*, Vol. 65, No. 8, pp. 6581-6591, Aug. 2018.
- [4] Z. Ma et al., "Multilayer SOH equalization scheme for MMC battery energy storage system," *IEEE Transactions on Power Electronics*, Vol. 35, No. 12, pp. 13514-13527, Dec. 2020.
- [5] J. S. Goud, R. Kalpana, and B. Singh, "Modeling and estimation of remaining useful life of single cell Li-ion battery," in *2018 IEEE International Conference on Power Electronics Drives and Energy Systems (PEDES)*, Chennai, India, pp. 1-5, 2018.
- [6] D. Stroe and E. Schaltz, "Lithium-ion battery state-of-health estimation using the incremental capacity analysis technique," *IEEE Transactions on Industry Applications*, Vol. 56, No. 1, pp. 678-685, Jan./Feb. 2020.
- [7] S. Torai et al., "State-of-health estimation of LiFePO₄/graphite batteries based on a model using differential capacity," *Journal of Power Sources*, Vol. 306, pp. 62-69, Feb. 2016.
- [8] D. Liu, X. Yin, Y. Song, W. Liu, and Y. Peng, "An on-line state of health estimation of lithium-ion battery using unscented particle filter," *IEEE Access*, Vol. 6, pp. 40990-41001, Jul. 2018.
- [9] N. A. Azis, E. Joelianto, and A. Widyotriatmo, "State of charge (SoC) and state of health (SoH) estimation of lithium-ion battery using dual extended kalman filter based on polynomial battery model," in *2019 6th International Conference on Instrumentation, Control, and Automation (ICA)*, Bandung, Indonesia, pp. 88-93, 2019.
- [10] X. Feng et al., "Online state-of-health estimation for Li-ion battery using partial charging segment based on support vector machine," *IEEE Transactions on Vehicular Technology*, Vol. 68, No. 9, pp. 8583-8592, Sep. 2019.
- [11] P. Lee and J. Kim, "Impact analysis of deterioration and SOH estimation based on multiple regression analysis," *2019 IEEE Transportation Electrification Conference and Expo, Asia-Pacific (ITEC Asia-Pacific)*, Seogwipo, Korea, pp. 1-6, 2019.
- [12] X. Tan, Y. Tan, D. Zhan, Z. Yu, Y. Fan, J. Qiu, and J. Li, "Real-time state-of-health estimation of lithium-ion batteries based on the equivalent internal resistance," *IEEE Access*, Vol. 8, pp. 56811-56822, 2020.
- [13] H. Li, D. Pan, and C. L. P. Chen, "Intelligent prognostics for battery health monitoring using the mean entropy and relevance vector machine," *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, Vol. 44, No. 7, pp. 851-862, Jul. 2014.

- [14] B. Chokkalingam, S. Padmanaban, P. Siano, R. Krishnamoorthy, and R. Selvaraj, "Real-time forecasting of EV charging station scheduling for smart energy systems," *Energies*, Vol. 10, No. 377, pp. 377, 2017.
- [15] T. Noh, J. Bae, H. Han, and B. Lee, "Online SOH estimation algorithm based on aging tendency of open circuit voltage and low pass filter," in *The Korea Institute of Power Electronics Power Electronics Annual Conference*, pp. 47-49, Jul. 2019.



강승현(姜勝弦)

1995년 7월 3일생. 2020년 인제대 전자공학과 졸업. 2020년~현재 성균관대 전자전기 컴퓨터공학과 석사과정.



노태원(盧泰元)

1991년 10월 21일생. 2016년 성균관대 전자 전기공학과 졸업. 2016년~현재 동 대학원 전자전기컴퓨터공학과 석·박통합과정.



이병국(李秉國)

1968년생. 1994년 한양대 전기공학과 졸업. 1996년 동 대학원 전기공학과 졸업(석사). 2001년 Texas A&M University 전기공학과 졸업(공학박). 2002년~2003년 Postdoctoral Research Associate, Texas A&M University. 2003년~2005년 한국전기연구원 산업전기연구단 전력전자그룹 선임연구원. 2006년~현재 성균관대 정보통신대학 전자전기공학부 교수. 2004년~현재 IEEE Senior Member, IEEE VPPC2012 조직위원장. 2016년~현재 국제전기기술위원회 (IEC) 적합성평가위원회(CAB) 이사. 당 학회 재무이사.