Transactions of KSAE, Vol. 34, No. 11, pp.1253-1263 (November, 2026)

Check for updates

Copyright © 2026 KSAE / 252-03
pISSN 1225-6382 / eISSN 2234-0149
DOI http://dx.doi.org/10.7467/KSAE.2026.34.11.1253

GA-SQP 파라미터 최적화 및 Extended Kalman Filter 기반 리튬이온 배터리 SOC 추정 고도화

이 상 승 · 공 태 현 · 이 승 현 · 홍 기 준 · 김 종 훈*

충남대학교 전기공학과

Enhanced State-of-Charge Estimation for Lithium-Ion Batteries Using GA-SQP Parameter Optimization and Extended Kalman Filter

Sangseung Lee · Taehyeon Gong · Seunghyun Lee · Gijun Hong · Jonghoon Kim*

Department of Electrical Engineering, Chungnam National University, Daejeon 34134, Korea
(Received 26 January 2026 / Revised 9 May 2026 / Accepted 27 May 2026)

Abstract : This study proposes an enhanced state-of-charge(SOC) estimation method for lithium-ion batteries by integrating genetic algorithm(GA) with sequential quadratic programming(SQP). The parameters of a 1-RC equivalent circuit model(ECM) were optimized using GA-SQP to enhance extended Kalman filter(EKF) based SOC estimation. A low-error candidate solution was initially identified by GA across the global parameter space, after which SQP refines it through local optimization. By reducing terminal voltage prediction errors, the optimized parameters improve the reliability of SOC estimation. The method was experimentally validated with capacity and hybrid pulse power characterization(HPPC) tests, as well as federal urban driving schedule(FUDS) profiles. The results confirm that GA-SQP optimization yields lower mean absolute error(MAE) and maximum error than the initial or GA-only optimization, especially in low SOC regions. Compared with the 2-RC ECM, the optimized 1-RC ECM achieved lower SOC estimation error and shorter computation time, confirming the effectiveness of the proposed approach.

Key words : Lithium-ion battery(리튬이온 배터리), State-of-charge(충전 상태), Equivalent circuit model(등가회로 모델), Genetic algorithm(유전 알고리즘), Sequential quadratic programming(순차적 이차 계획법), Extended Kalman filter(확장 칼만 필터)

1. 서 론

오늘날 전 세계적으로 화석 에너지의 고갈 문제와 더불어 온실가스 및 오염 물질 증가로 인한 환경 오염 문제가 심각해지고 있다. 이에 따라, 지속 가능한 에너지원에 대한 연구개발과 수요가 급격히 증가하고 있다.[1,2] 이러한 흐름에 따라 전기자동차(Electric vehicle; EV)와 에너지저장장치(Energy storage system; ESS) 등 다양한 응용 분야에 활용되는 리튬이온 배터리(Lithium-ion battery; LIB)가 친환경적인 에너지 저장 기술로서 주목받고 있다.[3,4] 리튬이온 배터리는 높은 에너지 밀도와 낮은 자가 방전 특성 등의 장점을 바탕으로 수요가 증가하고 있다.[5]

최근 배터리 사용량이 증가하고, 응용 분야가 확대됨에 따라, 배터리 시스템의 안정성과 효율을 동시에 확보하기 위한 정밀한 상태 추정 기술의 중요성이 커지고 있다.[6,7] 배터리 상태 추정 중 하나인 배터리 충전 상태(State-of-charge; SOC)를 정확하게 추정하는 과정을 통해 배터리의 성능을 최적화하고, 수명을 연장하고, 안전성을 확보할 수 있다.[8,9] 기존 SOC 추정 연구에서는 대표적으로 전류 적산 방식을 이용한 상태 추정 방법이 활용되어 왔다. 전류 적산 방식은 측정 전류를 시간에 따라 적분하여 SOC를 계산하는 방식으로 구현이 용이하다는

*A part of this paper was presented at the KSAE 2025 Fall Conference and Exhibition

*Corresponding author, E-mail: whdgns0422@cnu.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.

장점이 있으나, 초기 오차, 센서 노이즈 및 누적 오차로 인해 장기간 운용 시 SOC 추정 정확도가 저하될 수 있다.[10] 따라서, 최근 연구에서는 확장 칼만 필터(Extended Kalman filter; EKF)를 적용하여 전류 적산 시 추정된 배터리 SOC의 오차를 보정하고, 이를 통해 SOC 추정 정확도를 높이고자 하는 연구가 수행되고 있다.[11,12]

EKF와 같은 모델 기반 방식은 단자 전압 추정 시 사용하는 등가회로 모델(Equivalent circuit model; ECM)의 정확도에 크게 의존하므로, ECM을 구성하는 파라미터가 실제 배터리 전압 거동을 얼마나 잘 모사하는지가 배터리의 SOC 추정 성능을 크게 좌우한다.[13] 이에 따라, 기존 ECM 기반 SOC 추정 연구에서는 HPPC 실험 및 펄스 전류 응답 분석을 통해 ECM 파라미터를 도출하고, 이를 SOC 추정 모델의 초기 파라미터로 적용하였다.[14] 그러나, 실험 기반으로 도출된 초기 파라미터를 별도의 보정 없이 그대로 적용할 경우, 실험 조건, 모델 단순화 및 SOC 구간별 전압 응답 특성에 따라 측정 전압과 모델 기반 추정 전압 사이의 오차가 발생할 수 있다. 이러한 오차를 줄이기 위해 단일 최적화 기법 또는 재귀 최소자승법(Recursive least square; RLS)과 같은 온라인 식별 기법을 적용한 연구가 수행되어 왔다.[15,16] 그러나, 단일 최적화 기법은 적용 알고리즘의 탐색 특성에 따라 전역 탐색 성능과 지역 수렴 성능을 동시에 확보하는 데 한계가 있을 수 있으며, RLS 기반 온라인 식별 방법은 배터리 운용 중 발생하는 전압 오차를 바탕으로 파라미터를 갱신하는 방식이므로, 초기 파라미터로 인한 모델 오차를 사전에 저감하기보다는 오차 발생 이후 이를 보정하는 특성을 가진다.[17] 따라서, SOC 추정 정확도를 향상시키기 위해서는 실험 기반 초기 파라미터를 그대로 적용하거나 운용 중 오차를 사후적으로 보정하는 방식에서 나아가, ECM 파라미터를 오프라인에서 최적화하여 단자 전압 추정 오차를 사전에 저감하는 과정이 필요하다.

따라서, 본 논문은 리튬이온 배터리의 ECM 파라미터를 오프라인에서 최적화하여 단자 전압 추정 오차를 사전에 감소시키고, 최적화된 파라미터를 EKF 기반 SOC 추정 모델에 연계함으로써 배터리 상태 추정 정확도를 높이고자 한다. 이를 위해 유전 알고리즘(Genetic algorithm; GA)과 순차적 이차 계획법(Sequential quadratic programming; SQP)을 결합한 GA-SQP 기반 ECM 파라미터 최적화 기법을 적용한다.[18]

GA는 생물학적 진화 과정을 모방한 전역 최적화 기법으로, 개체군 기반 탐색을 통해 넓은 탐색 공간에서 해를 탐색할 수 있어 초기값 의존성을 완화할 수 있다는 장점이 있다. 그러나, 확률적 탐색 특성으로 인해 최적해 근방에서의 정밀 수렴성은 제한될 수 있다. 반면, SQP는 목적 함수와 제약 조건이 미분 가능한 경우 적용 가능한 지역 최적화 기법으로, 최적해 근방에서 빠른 수렴과 높은 정밀도의 해를 도출할 수 있다는 장점이 있다. 다만, 초기값에 따라 국소해에 수렴할 가능성이 있으며, 탐색 범위가 초기값 주변으로 제한될 수 있다. 따라서, 본 연구에서는 GA의 전역 탐색성과 SQP의 지역 정밀 수렴성을 순차적으로 결합하여 ECM 파라미터 최적화 시 두 기법의 장점을 함께 활용하고자 한다.

이후, 최적화된 파라미터를 활용해 ECM을 구성하고, EKF 기반 리튬이온 배터리 SOC 추정 모델을 설계 및 구현한다. 마지막으로, 다양한 실험 조건에서 획득한 데이터를 통해 제안한 방법의 성능을 검증 및 평가하기 위해 단자 전압 추정 오차 및 SOC 추정 오차를 비교한다. 이를 통해 제안한 방법의 유효성과 실효성을 확인하고자 한다.

2. 리튬이온 배터리 ECM 파라미터 추출 목적 전기적 특성 실험

2.1 배터리 셀 시험 환경 구성

본 연구에서 리튬이온 배터리의 1-RC ECM 파라미터 최적화를 위해 필요한 전기적 특성 데이터를 확보하기 위해 배터리 셀 시험 환경을 구성하였다. 실험에 사용된 배터리는 SK ON 社의 55.6 Ah 용량을 가진 E556 NCM 배터리를 사용하였다. 실험은 Fig. 1과 같이 배터리의 충전 및 방전을 위해 사용하는 배터리 충·방전기와 실험 환경 온도를 일정하게 유지하기 위한 항온 챔버로 구성하였으며, 장비 제어 및 데이터 저장을 위한 Host PC를 사용하였다. 실험 온도는 25 ℃로 설정하였다.

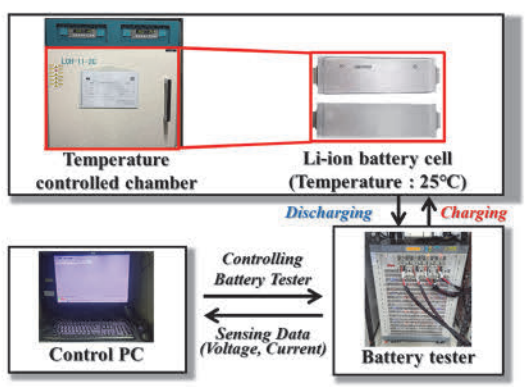


Fig. 1 Lithium-ion battery experiment setup

2.2 배터리 셀 전기적 특성 실험

배터리 전기적 특성 시험은 용량 실험과 HPPC(Hybrid pulse power characterization) 실험을 Fig. 2에 표시된 순서로

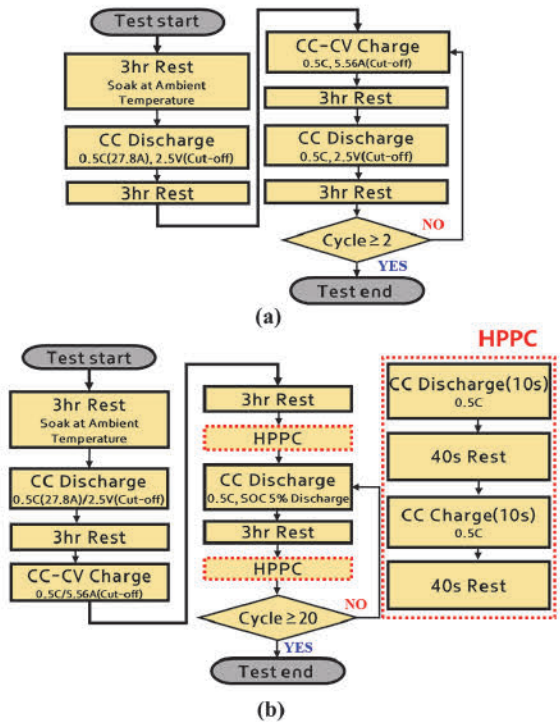


Fig. 2 Lithium-ion battery experiment procedure : (a) Capacity test (b) HPPC test

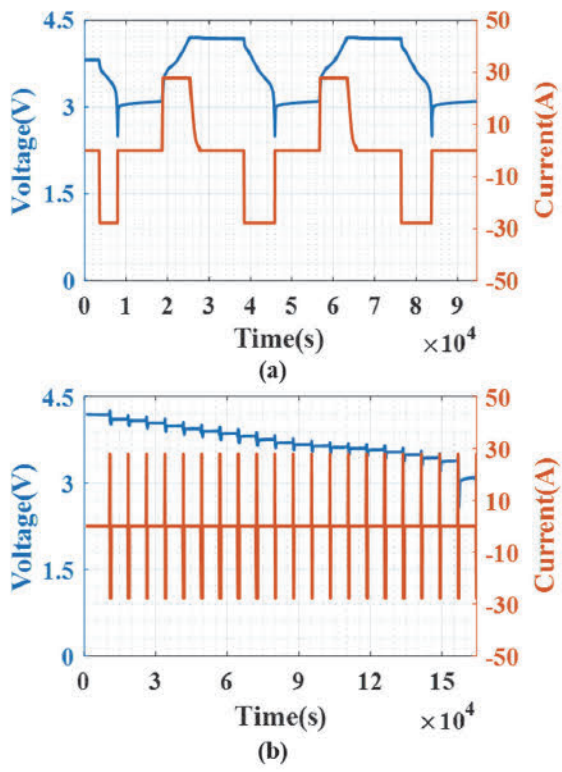


Fig. 3 Lithium-ion battery test data (a) Capacity (b) HPPC

실험 프로파일을 수립하여 수행하였다. 먼저, 용량 시험은 0.5 C-rate 조건 내에서 CC-CV(Constant current-constant voltage) 충전과 CC 방전을 수행하였으며, 충전 및 방전 이후 3시간의 휴지 시간을 포함한 1 Cycle을 총 2회 반복하여 수행하였다. 이때 측정된 전압 및 전류 데이터를 기반으로 배터리의 현재 용량을 산출하였고, 해당 값을 이후 진행하는 실험의 기준 용량으로 활용하였다.

HPPC 실험은 용량 실험과 동일한 조건(0.5 C-rate)으로 CC 방전 및 CC-CV 충전을 수행한 뒤 3시간 휴지 시간을 갖는 프로파일로 진행하였다. 용량 시험 결과를 기반으로 산정된 배터리의 용량을 기준으로 SOC 5 % 방전 구간마다 배터리에 10초 동안 충전 및 방전 펄스 교대로 인가한 후 40초 휴지하는 방식으로 진행하였다. 이 과정을 총 20회 반복하여 SOC 100 %에서 0 %까지 감소시키며 실험을 진행하였다. 용량 및 HPPC 실험을 통해 Fig. 3에 나타난 것과 같이 전압 및 전류 데이터를 확보하였다.

본 연구에서 3시간 휴지는 충·방전 이후 다음 실험 단계로 넘어가기 전 배터리 전압이 충분히 안정되도록 하기 위해 적용하였다. 이를 통해, 기준 용량 산정과 SOC-OCV 특성 확인에 필요한 안정된 실험 조건을 확보하였다. 충·방전 직후에는 배터리 전압이 바로 일정해지지 않고 일정 시간 동안 변화하므로, 40초와 같은 짧은 휴지 시간만으로는 기준 용량 및 SOC-OCV 특성 확인에 필요한 안정된 전압을 확보하기 어렵다. 반면, HPPC 실험 중 적용한 40초 휴지 시간은 기준 용량이나 SOC-OCV 특성을 확인하기 위한 시간이 아니라, 10초 충·방전 펄스 인가 이후 짧은 시간 동안 나타나는 전압 변화를 확인하기 위한 구간이다. 본 연구에서는 이 구간의 전압 변화 데이터를 이용하여 1-RC ECM의 R_{diff} 및 C_{diff}를 도출하였다. 따라서, 3시간 휴지와 40초 휴지는 각각 기준 특성 확보와 모델 파라미터 도출이라는 서로 다른 목적을 가진다.

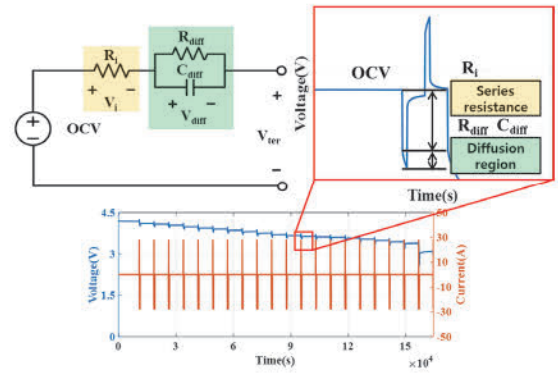


Fig. 4 Schematic of the 1RC ECM equivalent circuit model and parameter extraction

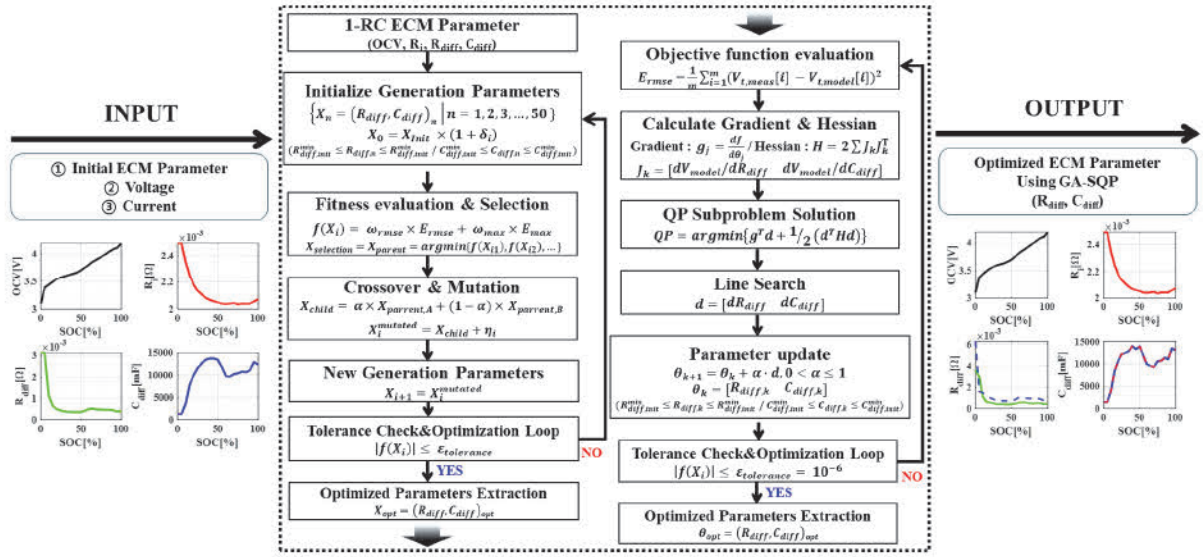


Fig. 5 Flowchart of GA-SQP based ECM parameter optimization

2.3 1-RC ECM 파라미터 도출

본 연구에서는 배터리의 동특성을 효율적으로 표현하기 위해 1-RC 등가회로 모델(ECM)을 적용하여 SOC 추정을 진행하였다. 해당 모델은 전압원과 직렬 저항, 그리고 1개의 저항-커패시터 병렬단으로 구성되어 비교적 단순한 구조로 배터리의 전기적 거동을 효과적으로 모사할 수 있는 등가회로 모델이다.

1-RC 등가회로 모델을 선택한 이유는 직렬 저항만 포함된 등가회로 모델인 Rint 모델 대비 비선형 전압 응답 및 과도 구간을 보다 정확히 모사할 수 있고, 2-RC 모델 대비 연산량이 적어 배터리 어플리케이션 내 실시간 SOC 추정에 있어 유리한 장점이 있다. 따라서, 본 연구에서는 1-RC 등가회로 모델에 파라미터 최적화 기법을 결합함으로써, 연산 효율을 확보하면서도 모델의 상태 추정 정확도는 높일 수 있는 방식을 제안하고자 한다.

1-RC 등가회로 모델 파라미터 추출에는 전기적 특성 실험에서 수행한 HPPC 실험 데이터를 활용하여 파라미터를 도출하였다. Fig. 4와 같이 HPPC 실험 데이터 내 충전 및 방전 펄스 전류를 인가할 때 발생하는 즉각적인 전압 강하 구간으로부터 직렬 저항을 산출하였고, 이후 확산(과도) 구간에서 나타나는 전압 변화 내에서 병렬단의 저항 및 커패시턴스를 도출하였다. 본 연구의 HPPC 실험은 SOC 5 % 방전 구간마다 반복 수행되었으므로, 1-RC ECM 파라미터 또한 전체 SOC 구간에서 하나의 고정값으로 도출한 것이 아닌 각 SOC 구간별로 도출하였다. 즉, SOC 100 %에서 0 %까지 5 % 간격으로 구분된 각 구간의 펄스 응답을 이용하여 $R_i(SOC)$, $R_{diff}(SOC)$, $C_{diff}(SOC)$ 형태의 SOC 구간별 파라미터를 구성하였다.

3. GA-SQP 기반 ECM 파라미터 최적화

본 연구에서는 리튬이온 배터리의 상태 추정 정확도 향상을 위해 1-RC ECM 기반 단자 전압 추정 오차를 최소화하는 방향으로 ECM 파라미터 최적화를 수행하였다. 최적화 문제는 i번째 샘플에서 실험을 통해 측정된 배터리 단자 전압인 $V_{t,meas}[i]$와 동일한 전류 입력 조건에서 1-RC ECM을 통해 추정된 단자 전압인 $V_{t,\mathrm{model}}[i]$ 사이의 오차를 최소화하는 문제로 정의하였다. 여기서, i는 최적화에 사용된 데이터 샘플의 인덱스이며, N은 전체 샘플 수를 나타낸다. 따라서, 해당 최적화의 목적함수는 전체 샘플 구간 내 측정 전압과 추정 전압 사이의 오차를 최소화하도록 구성하였다.

최적화 설계 변수는 1-RC ECM의 저항-커패시터 병렬단을 구성하는 R_{diff}와 C_{diff}로 설정하였다. HPPC 실험을 통해 도출한 초기 파라미터를 이용해 구성한 1-RC ECM 기반 추정 단자 전압과 실제 HPPC 실험을 통해 측정한 전압 간의 단자 전압 추정 오차를 분석한 결과, 확산 전압 구간에서 1-RC ECM 기반 추정 전압과 실험 측정 전압 사이의 오차가 상대적으로 크게 발생하는 것을 확인하였다. 이에 따라, 본 연구에서는 확산 전압 추정 시 영향을 미치는 R_{diff}와 C_{diff}를 최적화 설계 변수로 선정하였다. 이때 최적화는 2.3절에서 SOC 5 % 간격으로 도출한 $R_{diff}(SOC)$ 및 $C_{diff}(SOC)$를 대상으로 SOC 구간별로 수행하였으며, 최적화 결과 또한 SOC에 따른 파라미터 형태로 구성하였다.

최적화 과정에서 물리적으로 타당한 범위를 벗어난 파라미터가 도출되는 것을 방지하기 위해 R_{diff}와 C_{diff}에 대한 상·하한 제약 조건을 설정하였다. 본 연구에서

는 HPPC 실험을 통해 도출한 SOC별 초기 파라미터의 최소값과 최대값을 기준으로 각 설계 변수의 탐색 범위를 제한하였다. 즉, R_{diff}는 초기 파라미터의 최소값인 $R_{diff,init}^{\min}$ 과 최대값인 $R_{diff,init}^{\max}$ 을 기준으로 각 설계 변수의 최적화 범위를 제한하였으며, C_{diff} 또한 초기 파라미터의 최소값인 $C_{diff,init}^{\min}$ 과 최대값인 $C_{diff,init}^{\max}$ 을 기준으로 최적화 범위를 제한하였다. 해당 제약 조건은 GA 기반 최적화 내에서는 개체 생성 과정에 적용하였으며, SQP 기반 최적화에서는 파라미터 갱신 과정에 반영하였다.

최적화 절차는 Fig. 5와 같이 GA와 SQP를 순차적으로 결합한 구조로 구성하였다. GA는 개체군 기반 최적화 기법으로 단일 초기값에서 탐색을 시작하는 것이 아닌 여러 후보해를 동시에 생성한 후 선택, 교차, 돌연변이 연산을 반복함으로써 탐색 공간 전반을 탐색한다. 이러한 특성으로 인해 GA는 특정 초기값 주변의 탐색에 제한되지 않고, 다양한 영역의 후보해를 평가할 수 있어 초기값 주변에서 해를 갱신하는 SQP 대비 전역 탐색 측면에서 유리하다. 반면, SQP는 주어진 초기값 주변에서 목적함수의 기울기와 곡률 정보를 이용해 빠르게 수렴하는 지역 최적화 기법으로, 초기값이 적절하게 설정될 경우 높은 정밀도의 해를 도출할 수 있다. 따라서, 본 연구에서는 GA를 통해 넓은 탐색 공간에서 전압 오차가 작은 초기해를 우선적으로 도출하고, 이를 SQP의 초기값으로 활용하여 최종 파라미터를 정밀하게 보정하였다.

3.1 GA 기반 파라미터 최적화

GA는 생물학적 진화 과정을 모사한 전역 최적화 기법으로, 개체군 기반의 해 집합을 초기화한 후 선택, 교차, 돌연변이 등의 연산을 반복함으로써 최적의 해를 도출하는 최적화 알고리즘이다. 본 연구에서는 R_{diff}와 C_{diff}를 식 (1)과 같이 하나의 개체 $X_n = (R_{diff}, C_{diff})_n$로 정의하고, 최적화 과정에서 실험 측정 단자 전압과 1-RC ECM 기반 추정 단자 전압 사이의 오차를 기반으로 한 적합도 함수(Fitness function)를 활용하여 최적화를 수행하였다. 적합도 함수는 전압 추정 오차가 작을수록 우수한 개체로 평가되도록 구성하였으며, 이를 통해 다음 세대에 전달될 후보 파라미터를 선택하였다.

최적화 과정은 다음과 같다. 먼저, 식 (2)와 같이 무작위로 초기 개체군인 X_0을 생성하고, 각 개체에 대해 1-RC ECM을 이용한 단자 전압을 계산한다. 이후, 식 (3)~(4)를 이용하여 실제 측정 전압인 $V_{t,meas}$와 1-RC ECM 기반 추정 전압인 $V_{t,\mathrm{model}}$간의 평균 제곱근 오차(Root mean square error; RMSE)인 E_{RMSE}와 최대 오차(Max error)인 E_{MAX}를 계산하고, 계산된 오차와 각 오차의 영향성을 반영하기 위한 가중치인 ω_{rmse}와 $\omega_{\max}$를 통해 식 (5)와 같이 적합도인 $f(X_i)$를 평가한다. 적합도가 우수한 개체는 식 (6)과 같이 다음 세대의 부모 개체인 X_{parent}로 선택된다.

$$X_n = (R_{diff}, C_{diff})_n,\ n = 1,2,3,\cdots,50\ , \quad R_{diff,init}^{\min} \le R_{diff,n} \le R_{diff,init}^{\max}\ , \quad C_{diff,init}^{\min} \le C_{diff,n} \le C_{diff,init}^{\max} \tag{1}$$

$$X_0 = X_{init} \times (1+\delta_i),\ \delta_i \in -0.05 \sim 0.05 \tag{2}$$

$$E_{RMSE} = \sqrt{\left(\frac{1}{N}\cdot\Sigma_{i=1}^{N}\left(V_{t,meas}[i] - V_{t,\mathrm{model}}[i]\right)^2\right)} \tag{3}$$

$$E_{MAX} = \max\left(\left|V_{t,meas}[i] - V_{t,\mathrm{model}}[i]\right|\right) \tag{4}$$

$$f(X_i) = \omega_{rmse}\cdot E_{rmse} + \omega_{\max}\cdot E_{\max} \tag{5}$$

$$X_{parent} = \arg min\left(f(X_1), f(X_2), \ldots\right) \tag{6}$$

$$X_{child} = \alpha\cdot X_{parent,A} + (1-\alpha)\cdot X_{parent,B},\ \alpha \in [0,1] \tag{7}$$

$$X_{mutated} = X_{child} + \eta_i,\ \eta_i \sim N(0,\sigma^2) \tag{8}$$

$$X_{i+1} = X_{mutated} \tag{9}$$

$$\left|f(X_i)\right| \le \epsilon_{tolerance} = 10^{-6} \tag{10}$$

선택된 부모 개체들은 식 (7)과 같이 교차 연산을 통해 자식 개체인 X_{child}를 생성하며, 이 과정에서 식 (8)과 같이 일정 확률로 돌연변이 연산이 수행된다. 돌연변이인 $X_{mutated}$는 해집합 내 다양성을 유지하고, 국소 최적해에 갇히는 것을 방지하며, 새로운 유전자의 탐색을 가능하게 하는 데 중요한 역할을 한다. 돌연변이 연산이 완료되면 식 (9)와 같이 다음 세대의 개체들인 X_{i+1}가 생성된다.

이러한 진화 기반 탐색 과정을 반복하여 전압 오차를 최소화하는 방향으로 식 (10)과 같이 설정한 수렴 기준인 $\epsilon_{tolerance}$을 만족할 때까지 최적화를 수행하며, GA 최적화 결과는 이후 SQP 기반의 정밀 지역 탐색을 위한 초기 해로 활용된다.

3.2 SQP 기반 파라미터 최적화

GA 기반 전역 최적화 결과로 도출된 해는 탐색 공간 내에서 비교적 양호한 해를 제공하지만, 미세한 정밀도

측면에서는 한계가 존재한다. 이에 본 연구에서는 GA를 통해 얻은 최적해를 SQP의 초기 해로 활용하여 지역 최적화를 수행하였다. SQP는 현재 파라미터에서 목적함수의 기울기와 헤시안 근사 정보를 이용하여 파라미터 변화량을 계산하고, 목적함수인 단자 전압 추정 오차가 감소하는 방향으로 R_{diff}와 C_{diff}를 반복적으로 갱신하여 설정한 수렴 기준 이하가 될 때까지 수행한다. 이를 통해 SQP는 GA를 통해 확보된 후보해 주변에서 파라미터를 정밀하게 보정함으로써 단자 전압 추정 오차를 감소시키는 역할을 수행한다.

$$f(X_i) = E_{MAE} = abs(\frac{1}{N} \cdot \Sigma_{i=1}^{N} (V_{t,meas}[i] - V_{t,\mathrm{model}}[i])) \quad (11)$$

$$g_j = \partial f / \partial \theta_j \quad (12)$$

$$H = 2\Sigma J_k J_k^T \quad (13)$$

$$J_k = [\partial V_{\mathrm{model}} / \partial R_{diff} \ \partial V_{\mathrm{model}} / \partial C_{diff}] \quad (14)$$

$$QP = \arg min_d (g^T d + \frac{1}{2} d^T H d), \ \theta + d \geq 0 \quad (15)$$

$$d = [dR_{diff} \ dC_{diff}] \quad (16)$$

$$\theta_{k+1} = \theta_k + \alpha \cdot d, \ 0 < \alpha \leq 1 , \quad (17)$$
$$\theta_k = [R_{diff}, \ C_{diff}]$$
$$R_{diff,init}^{\min} \leq R_{diff,k} \leq R_{diff,init}^{\max} ,$$
$$C_{diff,init}^{\min} \leq C_{diff,k} \leq C_{diff,init}^{\max}$$

$$|f(X_i)| \leq \epsilon_{tolerance} = 10^{-6} \quad (18)$$

SQP는 각 반복 단계에서 목적 함수의 테일러 급수 2차 근사를 기반으로 이차 계획법(Quadratic programming; QP)를 구성하고, 이를 계산하여 구한 해를 다음 반복의 해로 갱신하는 방식으로 진행된다.

먼저, 실험 측정 전압과 ECM을 통해 추정된 전압 간의 오차인 식 (11)의 E_{MAE}을 목적 함수로 설정하고, 식 (12)를 이용하여 목적 함수를 파라미터에 대해 미분하여 기울기인 g_j를 구한다. 해당 과정에서 도출된 기울기는 파라미터 변화에 따른 오차 감소 방향을 결정한다. 이후 식 (13)-(14)와 같이 파라미터 민감도인 J_k를 이용해 헤시안 H를 근사하여 곡률 정보를 반영하여 파라미터 갱신 방향과 크기를 산출한다. 이후 식 (15)를 이용하여 산출한 g_j와 H를 이용해 QP 서브 문제를 구성하고, 식 (16)과 같이 파라미터 변화량인 d를 계산한다. 마지막으로, 식 (17)을 이용해서 파라미터 변화량 d에 대한 스텝 크기인 α를 조절하여 파라미터를 갱신하며, 갱신한 파라미터인 θ_{k+1}가 식 (18)과 같이 설정한 수렴 기준인 $\epsilon_{tolerance}$를 만족 시 최적해를 도출한다.

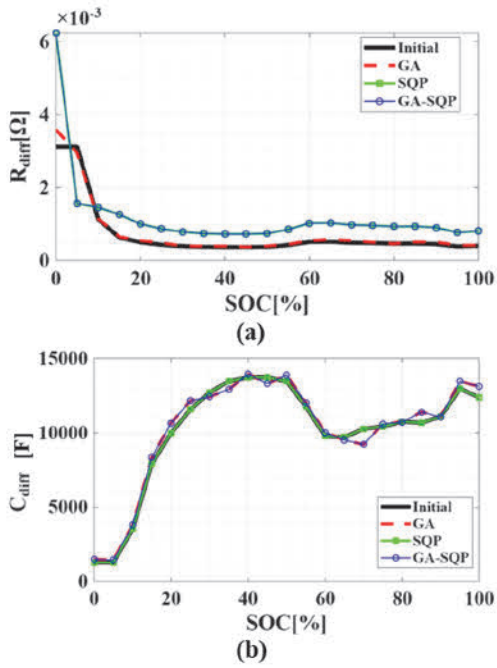


Fig. 6 GA-SQP based ECM parameter optimization result (a) R_{diff} (b) C_{diff}

초기 파라미터와 GA, SQP, GA-SQP 적용 후의 파라미터 변화를 Fig. 6(a)에는 R_{diff}를 Fig. 6(b)에는 C_{diff}를 나타내었다. R_{diff}의 경우 저 SOC 영역에서 단자 전압 오차가 크게 발생하는 것에 따라 해당 구간의 오차를 보정하는 방향으로 저 SOC에서 변화가 크게 발생함을 확인할 수 있으며, 최적화가 적용됨에 따라 SOC 전 구간에서 전반적으로 R_{diff}의 값이 소폭 증가한 것을 확인할 수 있다. C_{diff}의 경우 SOC 전 구간의 단자 전압 오차를 전반적으로 감소시키기 위해 비교적 작은 폭으로 변화한 것을 확인할 수 있다.

3.3 GA-SQP 최적화 파라미터 이용 단자 전압 추정 결과

제안한 GA-SQP 기반 ECM 파라미터 최적화 기법의 유효성을 검증하기 위해, 도출된 최적화 파라미터를 이용하여 단자 전압 추정을 수행하였다. 이를 위해 최적화된 파라미터를 적용한 1-RC 등가회로 모델을 구성하고, 실제 차량의 주행 조건을 모사한 FUDS 프로파일을 이용한 실험 데이터를 활용하여 단자 전압 추정을 진행하였다. 이후, 예측된 단자 전압과 실험에서 측정된 실제 전

압 간의 오차를 정량적으로 평가하고자 평균 절대 오차(Mean absolute error; MAE)와 최대 오차(Max error)를 활용하여 오차를 산출하였다. Fig. 7에 초기 파라미터와 GA 및 SQP, GA-SQP 최적화 파라미터를 이용한 단자 전압 추정 결과를 나타내었고, Table 1에 ECM 파라미터별 단자 전압 추정 오차를 정리하였다.

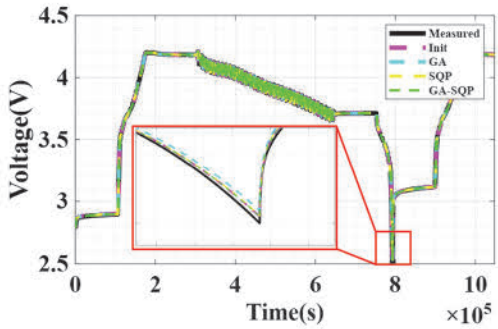


Fig. 7 Terminal voltage estimation results using different ECM parameters

Table 1 Terminal voltage estimation error using different ECM parameters

Parameter	Max error (%)	MAE (%)
Pre optimized	1.959	0.026
GA optimization	1.491	0.020
SQP optimization	0.888	0.014
GA-SQP optimization	0.786	0.012

비교 분석 결과, 초기 파라미터를 기반으로 한 전압 추정의 경우 최대 오차는 1.959 %, MAE는 0.026 %로 나타났고, GA와 SQP 단일 최적화 파라미터를 적용하였을 때 GA의 경우 최대 오차가 1.491 %, MAE는 0.020 %로 나타났으며, SQP의 경우 최대 오차가 0.888 %, MAE는 0.014 %로 최적화 파라미터를 적용하였을 때 단자 전압 추정 오차가 유의미하게 감소함을 확인할 수 있었다. 나아가, GA 결과를 초기 해로 활용하여 SQP 기반 파라미터 최적화를 적용한 GA-SQP 최적화 방식의 경우 단자 전압 추정 오차가 더 낮아진 것을 확인할 수 있었다. 특히, MAE는 0.012 %를 기록하여 전체 SOC 범위에서의 전압 추정 정밀도가 균일하게 개선되었고, 최대 오차는 0.786 %로 SOC가 낮은 구간에서 기존 초기 파라미터와 GA 및 SQP 단독 파라미터 최적화 알고리즘을 적용한 단자 전압 추정 오차 대비 낮은 오차가 발생하는 것을 확인할 수 있다.

Table 1의 결과에서 SQP 단독 적용만으로도 큰 오차 감소가 나타난 것은, 본 연구의 초기 파라미터가 실험실 환경의 HPPC 실험 데이터를 기반으로 도출되어 SQP가 효과적으로 수렴 가능한 범위 내에 있었기 때문으로 판단된다. 그러나, 실제 배터리 응용 분야에서는 센서 노이즈, 온도 변화, 운전 조건 변동 및 노화 등에 의해 초기 파라미터 불확실성이 증가할 수 있다. 따라서, 본 연구에서는 GA를 통해 탐색 공간 전반에서 초기 후보해를 확보하고, 이를 SQP의 초기값으로 활용함으로써 추정 정확도를 향상시키고자 하였다.

4. EKF 기반 SOC 추정

본 연구에서는 GA와 SQP를 결합한 GA-SQP 최적화 기법을 통해 도출한 1-RC ECM 파라미터를 기반으로 단자 전압 추정 정확도를 향상시켰으며, 추정된 단자 전압과 실험을 통해 측정된 전류 데이터를 EKF의 입력 값으로 활용하여 리튬이온 배터리의 SOC 추정 정확도를 높이고자 하였다.

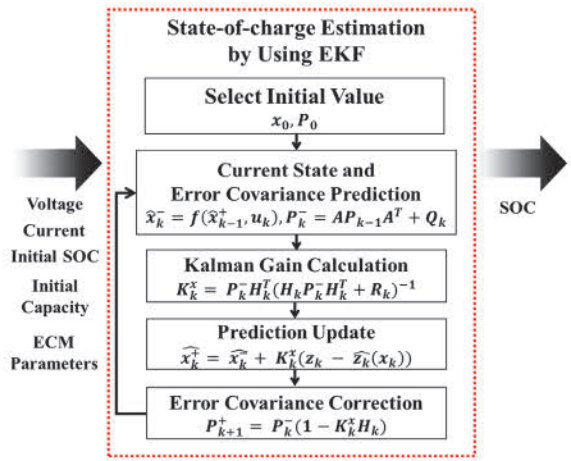


Fig. 8 EKF based SOC estimation flowchart

Fig. 8에 나타낸 것과 같이 EKF는 비선형 시스템을 대상으로 예측 단계에서는 상태 방정식을 통해 현재 상태를 추정하고, 보정 단계에서는 예측값과 실제 측정값 간의 차이를 바탕으로 오차 공분산과 노이즈 파라미터를 이용하여 칼만 이득(Kalman gain)을 계산하여 상태를 보정하는 필터링 방식이다.

4.1 EKF 기반 SOC 추정 알고리즘

본 연구에서는 1-RC ECM 파라미터의 최적화를 통해 도출된 파라미터를 기반으로 ECM을 구성하고, 구성된 ECM을 활용하여 EKF를 기반으로 리튬이온 배터리의 SOC를 추정하는 알고리즘을 설계하였다.

EKF 기반 SOC 추정 모델에서 상태 방정식은 SOC와 저항-커패시터 병렬단의 전압을 모델링하며, 측정 방정

식은 배터리의 단자 전압을 나타낸다. 배터리의 상태를 나타내는 지표인 SOC_k와 $V_{diff,k}$를 상태 변수로 설정하며, 측정값인 전류 I_k를 u_k로 설정하며, Q_k와 R_k는 각각 상태 방정식과 측정 방정식의 잡음을 나타내며, 이는 식 (19)와 같이 정의된다. 식 (20)은 첫 번째 항이 전류 적산법을 통해 SOC를 추정하고, 두 번째 항이 단자 전압의 특성을 반영하는 저항-커패시터 병렬단의 전압을 추정하는 배터리의 상태 방정식을 의미한다. 식 (21)은 ECM을 이용한 단자 전압 추정과 관련된 측정 방정식이다. EKF는 비선형 함수를 적용하기 위해 식 (22)-(23)과 같이 상태 및 측정 방정식의 편미분을 통해 자코비안 행렬을 구성하며, 시스템 방정식 행렬은 SOC에 따른 R_{diff}와 C_{diff}를 통해 도출되는 시정수와 OCV 값을 반영해 구성되며, 파라미터는 LUT(Lookup table) 형태로 모델에 적용한다.

예측값을 보정하기 위한 칼만 게인(K_k) 계산 과정은 상태 값과 오차 공분산을 식 (24)와 같이 예측하고, 오차 공분산은 상태 방정식을 편미분한 A_k와 Q_k를 통해 상태 추정값의 오차 공분산(P_k^-)을 예측한다. 여기서 P_k는 상태 변수 $\hat{x}_k$의 오차 공분산을 나타낸다. 오차 공분산은 추정된 시스템의 상태와 실제 시스템의 상태 값 간의 오차의 공분산을 나타내는 지표이다. K_k는 시스템의 오차 공분산의 데이터를 활용하여 식 (25)의 형태로 최종적으로 계산된다. 식 (26)에서 입력된 측정값과 추정값 간의 오차와 K_k을 이용해 추정값을 보정한다. 현재 상태 변수가 보정됨에 따라 오차 공분산 또한 식 (27)로 계산되어 보정된다. 이와 같은 과정을 반복적으로 수행하여 배터리의 SOC를 추정한다.

$$x_k = [SOC_k \; V_{diff,k}], \; u_k = I_k \\ w_k \sim N(0, Q_k), \; v_k \sim N(0, R_k) \tag{19}$$

$$f(x_k, u_k) = \begin{bmatrix} 1 & 0 \\ 0 & \exp(-\dfrac{\Delta t}{R_{diff,k-1} C_{diff,k-1}}) \end{bmatrix} \begin{bmatrix} SOC_{k-1} \\ V_{diff,k-1} \end{bmatrix} + \begin{bmatrix} \dfrac{-\Delta t}{Q} \\ R_{diff,k-1}\left(1 - \exp(\dfrac{-\Delta t}{R_{diff,k-1} C_{diff,k-1}})\right) \end{bmatrix} \cdot i_k + w_k \tag{20}$$

$$z(x_k, u_k) = OCV(SOC_{k-1}) - i_k R_{i,k-1} - R_{diff,k-1} i_k + v_k \tag{21}$$

$$A_k = \frac{\partial f}{\partial x}_{x_k = \hat{x}_k^+} = \begin{bmatrix} 1 & 0 \\ 0 & \exp(-\dfrac{\Delta t}{R_{diff,k-1} C_{diff,k-1}}) \end{bmatrix} \tag{22}$$

$$H_k = \frac{\partial z}{\partial x}_{x_k = \hat{x}_k^-} = \begin{bmatrix} \dfrac{\partial OCV}{\partial SOC}\Big|_{x_k = \hat{x}_k^-} & 1 \end{bmatrix} \tag{23}$$

$$\hat{x}_{k+1}^+ = f(\hat{x}_k^+, u_k), \quad P_{k+1}^- = A_k P_k A_k^T + Q_k \tag{24}$$

$$K_k = P_k(-) H_k^T [H_k P_k(-) H_k^T + R_k]^{-1} \tag{25}$$

$$\hat{x}_k^+ = \hat{x}_k^- + k_k(z_k - \hat{z}_k^-) \tag{26}$$

$$P_k^+ = (I - K_k H_k) P_k^- \tag{27}$$

4.2 GA-SQP 최적화 파라미터 이용 EKF 기반 SOC 추정 결과

제안한 GA-SQP 기반 ECM 파라미터 최적화와 EKF를 결합하여 SOC 추정 알고리즘을 개발하고, 주행 모사 데이터를 사용해 성능을 검증하였다. Fig. 9에 초기 파라미터와 GA 및 SQP, GA-SQP 최적화 파라미터를 이용한 SOC 추정 결과를 나타내었고, Table 2에 ECM 파라미터별 SOC 추정 오차를 정리하였다.

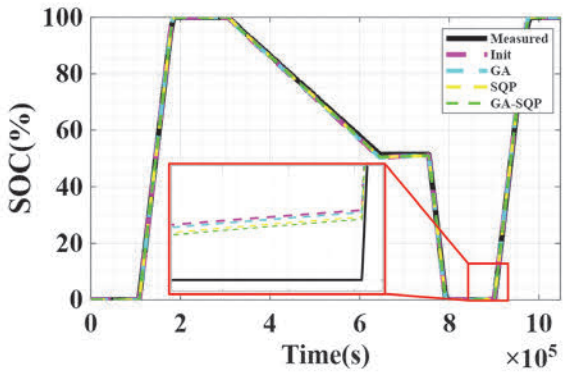


Fig. 9 EKF-based SOC estimation results using different ECM parameters

Table 2 SOC estimation error using different ECM parameters

Parameter	Max error (%)	MAE (%)
Pre optimized	1.994	0.459
GA optimization	1.832	0.444
SQP optimization	1.091	0.328
GA-SQP optimization	1.059	0.322

초기 파라미터를 적용하여 SOC를 추정한 결과, MAE는 0.459 %, 최대 오차는 1.994 %로 나타났다. 단일 최적화 기법과 비교하면, GA 최적화를 적용한 경우 최대 오차는 1.832 %, MAE는 0.444 %의 결과를 보였으며, SQP 최적화를 적용한 경우 최대 오차는 1.091 %, MAE는 0.328 %를 기록하였다. GA-SQP 최적화 파라

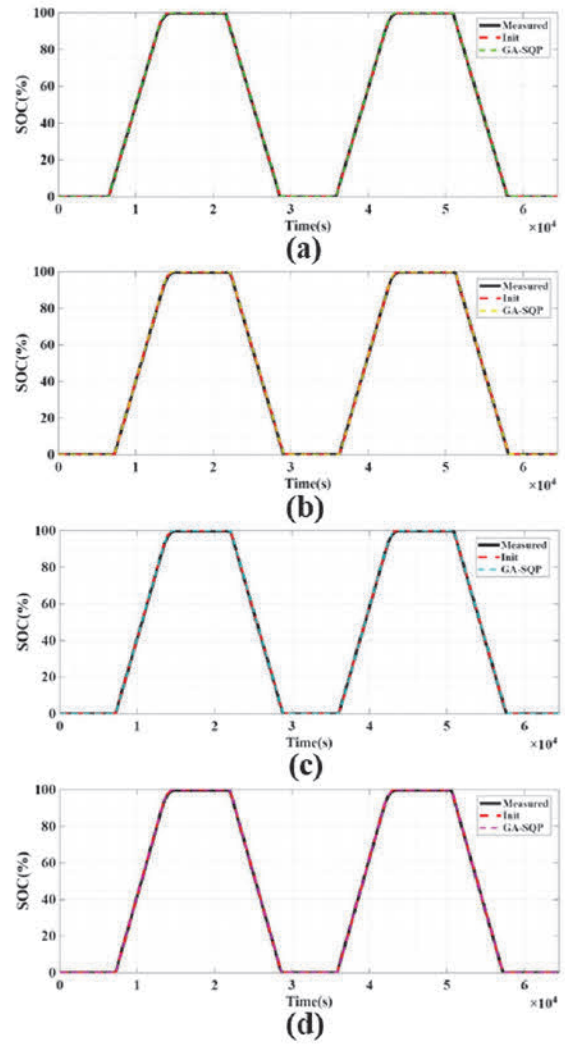


Fig. 10 EKF-based SOC estimation results using different ECM parameters under various SOH conditions (a) 98.0 % (b) 96.1 % (c) 94.4 % (d) 92.7 %

미터를 적용한 결과 최대 오차는 1.059 %, MAE는 0.322 %로 이는 최대 오차를 가장 낮게 유지하면서 MAE도 초기 대비 유의미하게 감소한 것을 확인할 수 있다.

추가적으로, 제안한 알고리즘을 서로 다른 노화 상태의 리튬이온 배터리 데이터를 이용하여 성능을 평가하였다. 노화 조건에 대한 검증을 위해 총 4가지의 서로 다른 SOH(State-of-health)를 가진 데이터를 각각 사용하여 동일한 추정 알고리즘을 적용하였다. 노화가 진행됨에 따라 용량 감소와 내부저항 증가로 인해 배터리의 전압 거동이 변화하지만, GA-SQP 기반으로 최적화된 ECM 파라미터는 이러한 변화를 반영하여 각 SOH 단계에서의 배터리 동특성을 효과적으로 묘사하였다.

Table 3 SOC estimation error using different ECM parameters under various aging conditions

SOH (%)	Pre optimized		GA-SQP optimization	
	MAE (%)	Max error (%)	MAE (%)	Max error (%)
98.0	0.650	2.054	0.143	0.668
96.1	0.594	2.016	0.115	0.677
94.4	0.624	2.234	0.131	0.727
92.7	0.584	2.028	0.116	0.743

Fig. 10에 노화 조건별 초기 파라미터와 GA-SQP 최적화 파라미터를 적용한 SOC 추정 결과를 나타내었고, Table 3에 노화 조건별 초기 파라미터와 GA-SQP 최적화 파라미터 적용 시 SOC 추정 오차를 정리하였다. 해당 결과를 분석하였을 때, 다양한 노화 조건에서의 ECM 파라미터에 최적화를 적용한 결과 초기 파라미터 대비 EKF 기반 SOC 추정 MAE 및 최대 오차 모두 감소하는 것을 확인하여 제안한 GA-SQP 파라미터 최적화 알고리즘이 다양한 노화 조건 내에서도 강건하게 동작함을 확인하였다.

마지막으로, 2.3절에서 언급한 1-RC ECM의 연산 효율과 본 연구에서 제안한 최적화 기반 1-RC ECM의 SOC 추정 정확도를 정량적으로 확인하기 위해 초기 파라미터를 이용한 1-RC ECM 및 2-RC ECM, 최적화 파라미터가 적용된 1-RC ECM을 동일한 주행 모사 데이터에 적용하여 비교하였다. 본 비교에서 연산 시간은 각 ECM을 EKF 기반 SOC 추정 모델에 적용한 후 전체 주행 모사 데이터 구간에 대해 SOC 추정 알고리즘을 수행하는 데 소요된 시간으로 산정하였다. 본 연구의 GA-SQP 파라미터 최적화는 오프라인 단계에서 수행되므로 연산 시간 비교에는 포함하지 않았으며, 연산 시간은 최적화된 파라미터를 EKF 기반 SOC 추정 모델에 적용한 후 SOC 추정 시 소요된 시간을 의미한다.

Table 4에 나타낸 바와 같이 초기 파라미터 적용 1-RC ECM과 최적화 파라미터가 적용된 1-RC ECM의 연산 시간은 각각 15.54초와 15.80초로 유사한 수준을 보였으며, 2-RC ECM의 연산 시간은 24.49초로 상대적으로 길게 나타났다. 이는 2-RC ECM이 1-RC ECM보다 추가적인 저항-커패시터 병렬단을 포함하여 EKF 계산 과정에서 고려해야 하는 상태 변수와 모델 파라미터가 증가하기 때문으로 판단된다. SOC 추정 정확도 측면에서 2-RC ECM은 최대 오차 1.205 %, MAE 0.385 %로 초기 파라미터 적용 1-RC ECM의 최대 오차 1.994 %, MAE 0.459 % 대비 낮은 오차를 보였다. 그러나, 최적화 파라미터 적용 1-RC ECM의 최대 오차와 MAE는 각각 1.059 %, 0.322 %로 나타나 2-RC ECM 대비 낮은 오차를 보였다. 이를 통

Table 4 SOC estimation error and computation time for different ECM models

Model type	Computation time (s)	Max error (%)	MAE (%)
1-RC ECM	15.54	1.994	0.459
Optimized 1-RC ECM	15.80	1.059	0.322
2-RC ECM	24.49	1.205	0.385

해, 제안한 최적화 파라미터 적용 1-RC ECM이 2-RC ECM 대비 짧은 연산 시간과 높은 SOC 추정 정확도를 확보할 수 있음을 확인하였다.

결론적으로, EKF 기반 SOC 추정은 제안한 GA-SQP 최적화 파라미터 적용 시 초기 파라미터 대비 뚜렷한 오차 감소를 보였으며, 동일한 조건에서 2-RC ECM과 비교하였을 때도 짧은 연산 시간과 낮은 SOC 추정 오차를 나타냈다. 이를 통해, 제안한 GA-SQP 기반 1-RC ECM 파라미터 최적화 방법의 적용 가능성과 유효성이 실험적으로 확인되었다.

5. 결 론

본 연구에서는 리튬이온 배터리의 SOC 추정 정확도 향상을 위해 GA-SQP 기반 최적화 기법을 적용하여 1-RC ECM 파라미터를 최적화하고, 최적화된 모델을 기반으로 EKF를 활용한 SOC 추정 방법을 제안하였다. GA를 통해 전역 최적화를 진행한 후, SQP를 이용하여 지역 최적화를 진행하여 최적화된 ECM 파라미터를 확보하였다.

최적화 파라미터를 적용한 단자 전압 추정 결과, 초기 파라미터 대비 MAE와 최대 오차가 모두 감소하여 전압 추정 정확도가 개선됨을 확인하였다. 또한, 최적화 파라미터가 적용된 ECM을 활용하여 수행한 EKF 기반 SOC 추정에서도 추정 오차가 유의미하게 감소하였으며, 특히 저 SOC 영역 내 오차 감소가 뚜렷하게 나타났다. 더불어 제안한 GA-SQP 기반 파라미터 최적화 및 EKF 기반 SOC 추정 방식은 초기 파라미터와 GA 및 SQP 최적화만을 적용한 방식 대비 MAE와 최대 오차 측면에서 가장 우수한 성능을 보여 제안한 방법의 유효성을 확인하였다.

또한, 동일한 주행 모사 데이터에서 2-RC ECM과 비교한 결과, 최적화 파라미터를 적용한 1-RC ECM은 초기 파라미터를 적용한 2-RC ECM 대비 짧은 연산 시간을 보이면서도 최대 오차와 MAE 측면에서 낮은 SOC 추정 오차를 나타냈다. 이를 통해, 제안한 GA-SQP 기반 1-RC ECM 파라미터 최적화 방식이 1-RC ECM의 연산 효율을 유지하면서도 SOC 추정 정확도를 향상시킬 수 있음을 확인하였다.

따라서, 본 연구에서 제안한 GA-SQP 기반 ECM 파라미터 최적화 및 EKF 기반 SOC 추정 방법은 리튬이온 배터리 어플리케이션에서 보다 정확하고 신뢰성 있는 상태 추정을 가능하게 하는 유용한 방법임을 확인하였다. 향후 연구에서는 파라미터 최적화 알고리즘의 계산량을 줄이는 동시에 정확도를 향상시키는 방향으로 확장 연구를 진행할 예정이다.

후 기

본 논문은 2024년도 정부(기후에너지환경부)의 재원으로 한국에너지기술평가원(RS-2024-00398346, ESS 빅데이터 기반 O&M 및 자산관리 기술인력 양성)의 지원과 산업기술평가관리원의 재원으로 인지컨트롤스(No.00404229, 직접냉각 기술적용 80 kWh 이상급 대용량 배터리 열관리 기술개발)의 재원을 받아 수행되었음.

References

1) F. Degen, M. Winter, D. Bendig and J. Tübke, “Energy Consumption of Current and Future Production of Lithium-Ion and Post Lithium-Ion Battery Cells,” Nature Energy, Vol.8, No.11, pp.1284-1295, 2023.
2) L. Ihlbrock, A. Sehnal, M. Gutsch and S. Lux, “Future Energy Demand for Automotive and Stationary Lithium- and Sodium-Ion Battery Production towards a European Circular Economy,” Energy & Environmental Science, Vol.18, pp.8724-8743, 2025.
3) K. R. Ngoy, V. T. Lukong, K. O. Yoro, J. B. Makambo, N. C. Chukwuati, C. Ibegbulam, O. Eterigho-Ikelegbe, K. Ukoba and T. C. Jen, “Lithium-Ion Batteries and the Future of Sustainable Energy: A Comprehensive Review,” Renewable and Sustainable Energy Reviews, Vol.223, Paper No.115971, 2025.
4) J. Menyhart, “Overview of Sustainable Mobility: The Role of Electric Vehicles in Energy Communities,” World Electric Vehicle Journal, Vol.15, No.6, Paper No.275, 2024.
5) N. Nasajpour-Esfahani, H. Garmestani, M. Bagheritabar, D. J. Jasim, D. Toghraie, S. Dadkhah and H. Firoozeh, “Comprehensive Review of Lithium-Ion Battery Materials and Development Challenges,” Renewable and Sustainable Energy Reviews, Vol.203, Paper No.114783, 2024.

6) S. Zheng, J. Teh, B. Alharbi and C. M. Lai, "A Review of Equivalent-Circuit Model, Degradation Characteristics and Economics of Li-Ion Battery Energy Storage System for Grid Applications," Journal of Energy Storage, Vol.101, Paper No.113908, 2024.
7) S. Piller, M. Perrin and A. Jossen, "Methods for State-of-Charge Determination and Their Applications," Journal of Power Sources, Vol.96, No.1, pp.113-120, 2001.
8) J. Lee, C. Park, G. Yang, G. Shim and C. Bae, "Development and Performance of BMS Modules for Urban Electric Car Using Life Prediction Method," Transactions of KSAE, Vol.26, No.1, pp.20-25, 2018.
9) C. Zheng, Y. I. Park, W. Lim and S. W. Cha, "A Study on Battery SOC Estimation by Regenerative Braking in Electric Vehicles," Transactions of KSAE, Vol.25, No.4, pp.492-499, 2017.
10) K. Movassagh, A. Raihan, B. Balasingam and K. Pattipati, "A Critical Look at Coulomb Counting Approach for State of Charge Estimation in Batteries," Energies, Vol.14, No.14, Paper No.4074, 2021.
11) B. Yoon, S. Yoo and S. Seong, "Compensation Method of EKF Based on LSTM for Estimating State of Charge of Li-Polymer Battery," Transactions of KSAE, Vol.31, No.1, pp.55-61, 2023.
12) N. Shi, Z. Chen, M. Niu, Z. He, Y. Wang and J. Cui, "State-of-Charge Estimation for the Lithium-Ion Battery Based on Adaptive Extended Kalman Filter Using Improved Parameter Identification," Journal of Energy Storage, Vol.45, Paper No.103518, 2022.
13) R. Guo and W. Shen, "A Review of Equivalent Circuit Model Based Online State of Power Estimation for Lithium-Ion Batteries in Electric Vehicles," Vehicles, Vol.4, No.1, pp.1-29, 2022.
14) H. Kim, S. Heo and G. Kang, "Modeling and Characteristic Analysis of HEV Li-Ion Battery Using Recursive Least Square Estimation," Transactions of KSAE, Vol.24, No.4, pp.400-407, 2016.
15) Q. Zhu, M. Xu, W. Liu and M. Zheng, "A State of Charge Estimation Method for Lithium-Ion Batteries Based on Fractional Order Adaptive Extended Kalman Filter," Energy, Vol.187, Paper No.115880, 2019.
16) X. Lai, W. Yi, Y. Zheng and L. Zhou, "An All-Region State-of-Charge Estimator Based on Global Particle Swarm Optimization and Improved Extended Kalman Filter for Lithium-Ion Batteries," Electronics, Vol.7, No.11, Paper No.321, 2018.
17) S. Zhang, H. Tao, K. Bi, W. Yan and H. Ni, "SOC Estimation of Lithium-Ion Battery Based on RLS-EKF for Unmanned Aerial Vehicle," Journal of Physics: Conference Series, Vol.2216, Paper No.012002, 2022.
18) S. Lee, T. Gong, G. Hong and J. Kim, "Enhanced State-of-Charge Estimation for Lithium ion Batteries Based on Extended Kalman Filter Using Genetic Algorithm-Sequential Quadratic Programming Parameter Optimization," KSAE Annual Conference Proceedings, p.1540, 2025.