



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학석사 학위논문

증분 용량 분석과 Transformer를
이용한 리튬 이온 배터리의 SOH 추정
방안 연구

A Study on Lithium-ion Battery SOH
Estimation Based on Incremental Capacity
Analysis and Transformer

울 산 대 학 교 대 학 원
전기전자컴퓨터공학과
박 민 식

증분 용량 분석과 Transformer를
이용한 리튬 이온 배터리의 SOH 추정
방안 연구

지도 교수 김병우

이 논문을 공학석사학위 논문으로 제출함

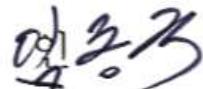
2023년 08월

울산대학교 대학원

전기전자컴퓨터공학과

박민식

박 민 식의 공학석사학위 논문을 인준함

심사위원장 임 동 국 

심사위원 김 병 우 

심사위원 곽 수 진 

울 산 대 학 교 대 학 원

2023년 08월

감사의 글

연구실에 들어와 대학원에 입학한 지가 엇그제 같은데 어느덧 졸업논문을 쓰고 있습니다. 부족했던 제가 조금 더 발전할 수 있었던 이유는 제 주변의 많은 분의 관심과 격려가 있어서 가능했습니다. 이 자리를 빌려 많은 저에게 많은 응원을 해주신 모든 분께 감사의 마음을 전합니다.

우선 지난 3년 동안 부족했던 저를 지도해주신 김병우 교수님께 감사의 마음을 전해드리고 싶습니다. 많은 경험을 쌓을 수 있도록 기회를 주신 덕분에 새롭고 다양한 경험과 부족함 없는 성과를 달성할 수 있었습니다. 교수님께서 제게 주신 가르침은 삶을 살아가기 위해 꼭 필요한 밑거름이 될 것입니다. 또한, 바쁘신 와중에도 시간을 내주시어 저의 부족한 석사학위논문을 심사해주신 임동국 교수님과 곽수진 센터장님께 감사의 말씀을 드립니다.

석사과정 동안 함께 동고동락했던 자동차 전자제어 연구실의 선배들과 후배들에게도 감사의 마음을 전합니다. 석사과정 동안 많은 것을 배울 수 있었던 것은 연구실의 동료들이 있었기 때문입니다. 가족보다 더 많은 시간을 함께 보내며 서로 밀어주고 당겨주었던 시간을 잊지 못할 것이며, 앞으로도 소중히 간직하며 지내겠습니다. 누구보다 연구실을 생각하고 많은 조언을 해주는 재우형, 엄마 같은 마음으로 따뜻한 조언과 공감을 통해 많은 도움을 주신 경은이누나, 랩장으로 연구실을 이끌며 항상 많은 도움을 주며 배울 게 많은 정은이누나, 항상 밝고 긍정적인 모습으로 조언해주는 팽도형, 저의 고충과 이야기를 자주 들어준 동희형과 종규형, 동기로서 함께 많은 이야기를 나누며 생활한 수진이, 열심히 연구실에 적응하고 있는 정수와 차니 등 모두에게 감사의 인사를 드립니다. 또한, 바쁘신 와중에도 조언과 응원을 해주신 자동차 전자제어 연구실 선배님들께도 감사의 인사를 드립니다.

제가 지금까지 잘 성장할 수 있었던 것은 항상 사랑하는 마음으로 지켜봐 주던 가족이 있었기 때문입니다. 무사히 공부를 마칠 수 있도록 무한한 응원과 믿음을 보여주신 아버지, 항상 할 수 있다고 응원해주신 이모, 묵묵히 응원하면서 지켜봐 준 형과 누나들에게 고맙다는 말을 전합니다. 그리고 하늘에서 항상 응원해주고 지켜보고 계실 사랑하는 어머니께 진심으로 감사드립니다.

2023. 07. 12.

박민식 올림

증분 용량 분석과 Transformer를 이용한 리튬 이온 배터리의 SOH 추정 방안 연구

박 민 식

울산대학교대학원 전기전자컴퓨터공학과

요 약

리튬 이온 배터리는 높은 에너지 밀도, 긴 수명 그리고 높은 효율과 같은 장점으로 인해 전기차의 에너지원으로 활용되고 있다. 전기차의 다양한 주행 조건에서 리튬이온 배터리의 안전한 상태를 보장하기 위해서는 리튬이온 배터리의 정확한 State of Charge(SOH) 상태를 추정하여야 한다. 따라서 정확한 SOH 추정을 위해 본 논문에서는 증분 용량 분석법을 통해 리튬 이온 배터리의 열화 상태와 열화 원인을 분석하고, SOH 추정을 위한 특성 파라미터를 추출하였다. 추출한 특성 파라미터를 이용하여 현재 배터리의 열화 원인을 파악하였으며, 특성 파라미터의 유용성을 검증하기 위해 상관관계 분석을 진행하였다. 상관관계 분석을 통해 검증한 특성 파라미터를 SOH 추정을 위한 Transformer의 입력으로 사용하여 SOH 추정 방안에 대하여 연구하였다.

주요어 : Lithium-ion Battery, Incremental Capacity Analysis, Correlation analysis, Deep learning, RNN(Recurrent Neural Network), LSTM(Long Short Term Memory), GRU(Gate Recurrent Unit), Transformer, SOH Estimation.

목 차

목 차	i
그림 목차	ii
표 목차	iii
I. 서론	1
1. 연구 배경 및 필요성	1
2. 연구 이론 및 내용	5
1) RNN(Recurrent Neural Network)	5
2) Long-Short Term Memory(LSTM)	6
3) GRU(Gated Recurrent Unit)	8
4) Transformer	10
II. 본론	12
1. 연구개요	12
2. 리튬 이온 배터리 데이터	13
3. 증분 용량 분석법 및 특성 파라미터 추출	17
1) 증분 용량 분석 및 Gaussian filtering	17
2) 리튬 이온 배터리 열화 상태 및 원인 분석	20
3) 특성 파라미터 추출	22
4) 특성 파라미터 상관관계 분석	24
4. SOH 추정 알고리즘	27
1) SOH 추정 알고리즘에 따른 Parameter setting	27
III. 결과 및 분석	28
1. 모델 성능 평가 기준	28
2. SOH 추정 알고리즘 정확도 평가	29
IV. 결론	36
ABSTRACT	40

그림목차

<그림 1> RNN(Recurrent Neural Network) 구조.....	5
<그림 2> LSTM(Long Short Term Memory) 구조.....	7
<그림 3> GRU(Gated Recurrent Unit) 구조.....	9
<그림 4> Transformer 구조.....	11
<그림 5> 연구 개요.....	12
<그림 6> B0005의 충전 및 방전 프로세스.....	15
<그림 7> 4개 배터리 데이터의 사이클에 따른 용량 변화.....	15
<그림 8> 그림3 CC-CV 충전에서 사이클에 따른 B0005의 전압 변화.....	16
<그림 9> 그림3 CC-CV 충전에서 사이클에 따른 B0005의 전류 변화.....	16
<그림 10> Initial IC Curve of B0005.....	19
<그림 11> Gaussian filtering result of IC curve.....	19
<그림 12> B0005의 사이클에 따른 IC curve의 변화.....	23
<그림 13> Peak와 Capacity와의 상관관계 그래프.....	25
<그림 14> Peak position과 Capacity와의 상관관계 그래프.....	25
<그림 15> Area과 Capacity와의 상관관계 그래프.....	26
<그림 16> B0005 SOH 추정 결과.....	31
<그림 17> B0006 SOH 추정 결과.....	31
<그림 18> B0007 SOH 추정 결과.....	32
<그림 19> B0018 SOH 추정 결과.....	32
<그림 20> soh 추정 알고리즘별 상태 오차의 Boxplot.....	34

표 목차

<표 1> 리튬 이온 배터리 사양.....	14
<표 2> 리튬 이온 배터리의 열화 상태 및 열화 원인	21
<표 3> 특성 파라미터와 배터리 용량간의 상관관계 분석 결과	24
<표 4> 추정 알고리즘 별 파라미터 값.....	27
<표 5> 추정 모델에 따른 SOH 추정 결과	30
<표 6> Definitions of Boxplot indicator.....	34
<표 7> B0005의 SOH 추정 알고리즘별 상대 오차.....	35

I. 서론

1. 연구 배경 및 필요성

화석 연료를 사용하는 내연기관 차량의 수가 증가하면서 이산화탄소 배출량이 증가하여 이에 따른 기후 변화 문제가 세계적인 화두로 떠오르고 있다. 이러한 문제를 극복하기 위해 내연기관 차량을 대체할 수 있는 전기 자동차에 대한 연구가 대두되고 있다[1]. 리튬 이온 배터리는 높은 에너지 밀도, 긴 수명 그리고 높은 효율과 같은 장점으로 인해 전기 자동차의 에너지원으로 활용되고 있다[1]. 리튬 이온 배터리는 전기 자동차의 다양한 주행 조건에 따라 과충전, 과방전으로 과열되어 화재 그리고 폭발 사고의 원인이 된다[3]. 즉 리튬 이온 배터리의 상태에 따라 전기 자동차의 안전성에 큰 영향을 준다. 따라서 리튬 이온 배터리의 상태는 전기자동차 안전성에 큰 영향을 주기 때문에 배터리 상태 추정이 필수적이다[4].

배터리 상태추정은 배터리의 상태를 나타내는 SOH(State Of Health)와 SOC(State Of Charge)를 추정한다. 그중 SOH는 배터리의 수명을 나타내는 중요한 지표로 초기 용량과 비교하여 현재 시점에서 완충된 배터리의 용량의 백분율로 정의한다. 배터리의 열화가 진행될수록 수명이 줄어 안전성이 떨어진다[5]. 따라서 SOH는 배터리의 안전성과 직접적인 연관이 있는 지표이며, 이를 정확하게 추정하는 것은 매우 중요하다. 리튬 이온 배터리는 충전, 방전, 내부 저항 그리고 전류와 같은 다양한 조건들에 의해 성능이 저하된다[6-7]. 그래서 배터리의 성능 저하는 이론상으로 명확하게 수식화하기 어렵다. 이러한 이유로 SOH를 정확하게 추정하는 알고리즘의 개발이 필요하다[8].

배터리의 SOH를 추정하는 방법은 모델 기반 추정 방법, 데이터 기반 추정 방법이 있다. 모델 기반 추정 방법은 전기화학적 배터리 등가회로 모델과 Adaptive Filter를 이용하여 SOH를 추정한다[9]. Adaptive filter는 Kalman Filter(KF)와 Particle Filter(PF) 등이 있다. KF는 재귀적 방법을 이용하여 이전

추정값과 현재 측정값을 비교하여 오차를 줄여나가며 추정 정확도를 높인다[10]. 하지만 일반적인 KF는 선형 모델에 사용되기 때문에 비선형성이 포함된 배터리 모델에는 적합하지 않다. 그래서 Sepasi et al. [11]는 Extended Kalman Filter(EKF)로 비선형 시스템을 선형화하여 SOH를 추정했다. 그러나 EKF는 자코비안 행렬을 통해 비선형 시스템을 선형화하여 상태 변수를 추정하기 때문에 추정 오차가 존재한다[9]. Chen et al.[12]는 Unscented Kalman Filter(UKF)를 이용하여 SOH를 추정하였다. UKF는 선형화하는 과정에서 EKF와 달리 선형화를 위해 자코비안 행렬을 구하지 않고 근사치를 이용하여 상대적으로 오차 없이 상태 변수를 추정하여 더 정확한 SOH 추정이 가능하다. 앞서 말한 EKF와 UKF는 노이즈가 가우스 분포를 만족해야 한다. 이에 반해 PF 다양한 전기화학적 반응으로 비선형, 비가우시안 시스템인 리튬 이온 배터리의 상태추정에 적합하다[13]. PF는 사후 확률 밀도와 연관된 가중치를 갖는 무작위 입자 샘플을 찾는다. 이 과정이 반복되면 가중치가 0이 되는 경향이 있다[14]. 이 문제를 해결하기 위해 Datong et al.[15]는 UKF와 PF 알고리즘을 결합한 Unscented Particle Filter(UPF)을 통하여 실제 사후 분포에 더 가까운 분포를 제공하여 SOH를 추정했다. 그러나 리튬 이온 배터리 모델에 물리적, 화학적 변화와 다양한 노이즈를 해결하는 것은 한계가 존재하였다.[16]

데이터 기반 방법은 전기화학적 변화를 고려하지 않고 Machine learning 접근 방식을 사용하여 SOH를 추정한다[17]. 따라서 최근 데이터 기반 방법은 많은 연구가 이루어졌다. Nuhic et al.[18]는 데이터를 분석하여 패턴을 찾고, 비선형을 근사화하는 알고리즘인 Support Vector Machine(SVM)을 사용하여 SOH를 추정했다. Liu et al.[19]는 배터리 SOH 추정의 정확성과 안정성 개선을 위해 Relevance Vector Machine(RVM)을 사용했다. Li et al.[20]는 배터리 데이터에서 6개의 노화 특징을 추출하여 Ensemble learning으로 SOH를 추정했다. 또한, Ren et al.[SA1]는 Deep Neural Network(DNN)와 autoencoder를 결합하여 SOH를 추정하는 알고리즘을 제안했다. You et al.[22]는 시간변화에 따른 voltage,

current 데이터를 시계열 학습에 유리한 Recurrent Neural Networks(RNN)을 통하여 SOH를 추정했다. RNN의 경우 입력이 길어질수록 Vanishing gradient가 발생하여 데이터의 loss가 발생한다. 이러한 한계로 인해 RNN의 한계를 극복하고자 Park et al.[23]은 Long Short-Term Memory(LSTM)을 통하여 SOH 추정 방안을 제안했다. 하지만 RNN과 LSTM의 경우 입력 데이터가 클수록 기울기가 소실되는 현상이 발생한다. 이와 같이, 데이터 기반 방법의 경우 전기화학적 변화를 고려하지 않고 SOH를 추정할 수 있지만 리튬 이온 배터리의 열화 상태와 원인을 분석할 수 없다.

따라서 본 논문에서는 배터리 전기화학적 분석법인 증분 용량 분석법(Incremental Capacity Analysis, ICA)과 딥러닝 알고리즘인 Transformer를 이용한 SOH 추정 방안을 제안한다. ICA는 전극 수준에서 배터리의 열화 상태를 분석하여 열화 원인을 식별할 수 있는 분석 방법이다[24]. IC(Incremental Capacity)는 전압 변화에 따른 용량의 미분으로 계산되며, 이를 통해 IC curve가 생성된다[25].

IC curve는 두 전극의 전기화학적 신호를 포함하고 고유한 모양과 강도를 나타낸다[24]. 따라서 셀이 열화 됨에 따라 IC curve의 peak 크기 및 위치 그리고 Area가 변화하며 배터리 SOH 추정에 주요한 특성 파라미터가 된다. 하지만 이러한 특성 파라미터는 노이즈에 취약하기 때문에 가우시안 필터(Gaussian Filter, GF) 알고리즘 기반의 신호 평활화 방법을 제안하여 높은 신뢰성을 갖는 특성 파라미터를 추출한다. Transformer는 Vaswani et al.[26]가 처음 제안한 딥러닝 모델로, self-attention mechanism을 통해 입력과 출력의 관계를 학습하여 기존의 RNN, LSTM에서 발생하는 기울기 소실 문제를 해결하여 더 높은 정확도를 갖고, 병렬화가 가능해 학습 속도도 줄어든다. 따라서 본 논문은 이러한 높은 신뢰성을 갖는 데이터와 Transformer를 이용한 SOH 추정 방안을 제안한다.

본 논문의 구성은 다음과 같다. 2장에서는 본 논문의 연구 이론 및 내용을 기

술하였다. 3장에서는 데이터의 구성, ICA의 과정 그리고 HI를 추출하는 과정을 기술하였다. 4장에서는 Deep learning 기법인 RNN, LSTM, GRU, Transformer에 대하여 설명하고, SOH를 추정하기 위한 모델의 구성과 모델 기술하였다. 5장에서는 여러 SOH 추정 모델의 성능을 비교하여 제안한 SOH 추정 모델의 타당성을 판단하였다.

2. 연구 이론 및 내용

1) Recurrent Neural Network(RNN)

RNN은 시계열 데이터를 사용하여 지정된 시간 동안 미래 데이터를 예측할 수 있는 신경망이다. 한 방향으로만 연산되는 인공신경망과 달리 RNN은 현재 시간 단계에서 입력된 값과 이전 시간 단계에서 출력된 값이 순환 신경망의 Cell 에 입력되므로 이전 상태가 현재 상태에 영향을 준다는 특징이 있다. RNN의 식은 (1)와 같다.

$$h_t = \tanh(W[h_{t-1}, x_t] + b) \quad (1)$$

(1)의 식에서 W 는 Weight, b 는 Bias, h_t 와 h_{t-1} 는 현재 시점의 Hidden state 와 이전 시점의 Hidden state를 각각 나타낸다. RNN은 인공신경망과 유사한 연산을 수행하며, 입력 시퀀스 값의 각 요소에 대한 가중치, Bias 및 활성화 함수를 사용한다. RNN은 h_{t-1} 과 x_t 를 결합하고 가중치를 곱한 다음 bias를 추가한다. 그 다음 h_t 를 반환하는 하이퍼볼릭 탄젠트 함수를 통과하는 단일 하이퍼볼릭 탄젠트 함수를 가진다.

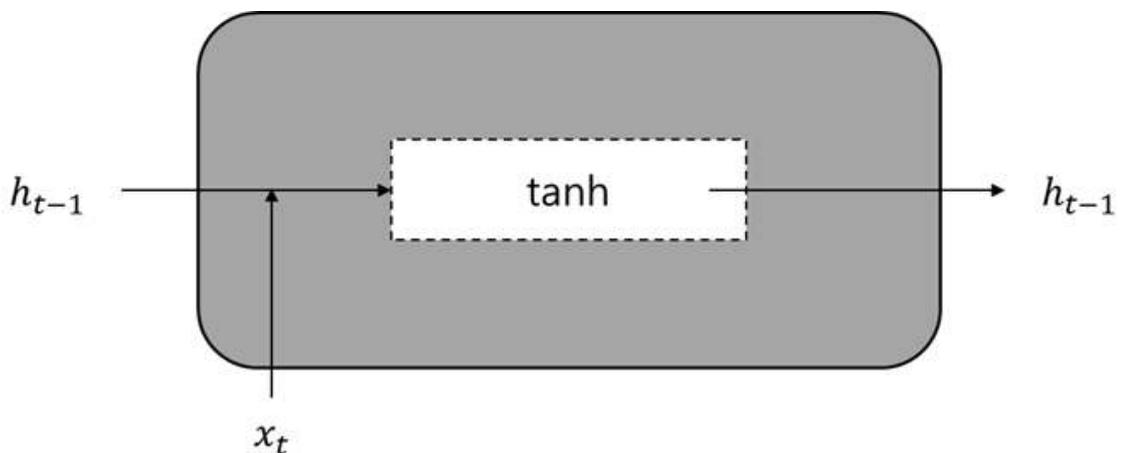


그림 1 RNN(Recurrent Neural Network) 구조

2) Long-Short Term Memory(LSTM)

RNN은 최근 정보를 다시 수집할 수 있지만 입력이 긴 시퀀스에 대해 기억하는 메모리가 짧아져 gradient 소실 및 폭주 문제가 발생할 수 있다. 이러한 단점을 극복하기 위해 LSTM(Long-Short Term Memory) 셀을 사용한다. LSTM은 gradient 소실 및 폭주 문제를 극복하기 위해 제안되었다. 그림2와 같이 LSTM은 Input, Output, Forget, Update gate로 구성된다. Forget gate에서는 이전 메모리 단위에서 무엇을 잊을지 결정하고, Input gate에서는 입력을 받아들일지 결정하고 Output gate에서는 새로운 장기간 메모리를 생성한다. 이러한 LSTM의 네 가지 주요 구성 요소는 주어진 특정 단계에서 장기 기억, 단기 기억, 입력 시퀀스 값을 받아들이고 새로운 장기 기억, 새로운 단기 기억을 생성하여 서로 상호작용한다. Input gate는 어떤 정보가 셀로 전송되어야 하는지 결정하는 역할을 한다. Input gate의 수학적 식은 (2)과 같다.

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (2)$$

식 (2)에서 연산자 *는 벡터의 요소 별 곱셈을 나타낸다. Forget gate는 이전 메모리에서 무시할 정보를 결정하며, 식(3)과 같다.

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (3)$$

셀의 상태는 Update gate에 의해 업데이트되며, 식 (4), (5)와 같다.

$$\tilde{C}_t = \tanh(W_c [h_{t-1}, x_t] + b_c) \quad (4)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (5)$$

이전 Step의 Hidden layer는 다음과 같이 출력을 업데이트 하는 Output gate에 의해 업데이트 되며 식 (6), (7)과 같다.

$$o_t = \sigma(W_o^*[h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t * \tanh(c_t) \quad (7)$$

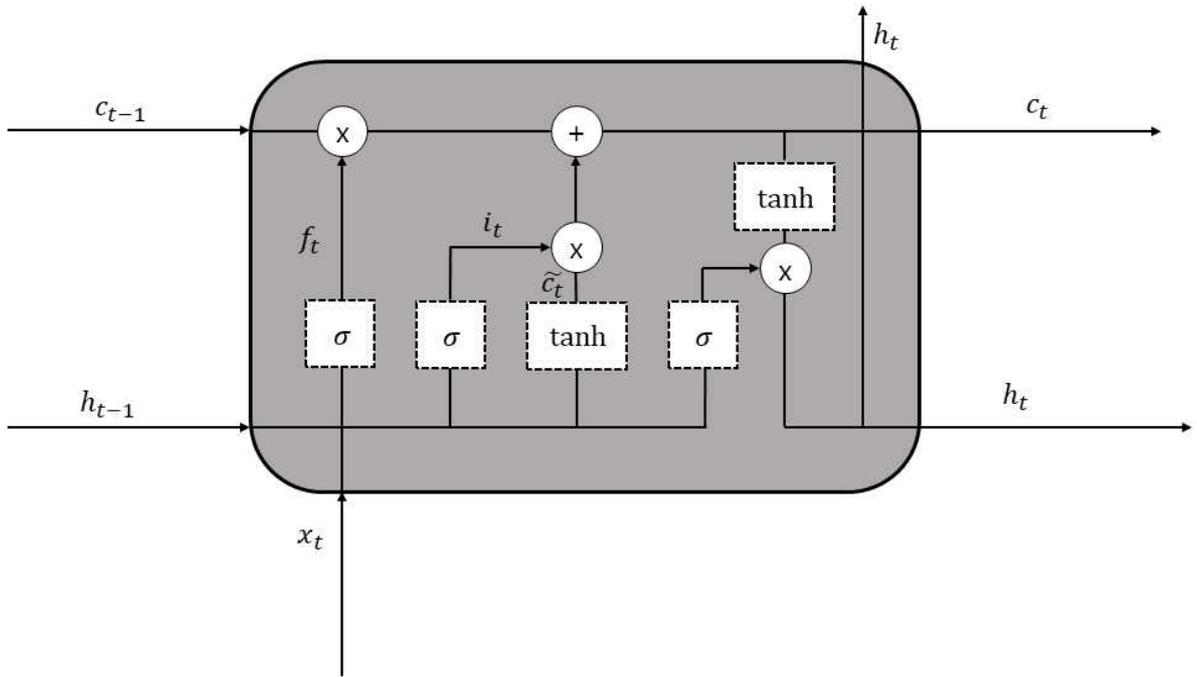


그림 2 LSTM(Long Short Term Memory) 구조

3) Gated Recurrent Unit(GRU)

GRU는 LSTM의 구조를 간단하게 개선하여 Reset gate와 Update gate로 구성된다. LSTM에 비해 파라미터 수가 줄어들기 때문에 연산량이 줄어든다.

Update gate는 LSTM의 Forget gate와 Input gate 역할을 담당한다. 이전 정보와 현재 정보를 얼마나 반영할 것인지에 대해 결정하며, 식(8)과 같다.

$$z_t = \sigma(W_z * [h_{t-1}, x_t]) \quad (8)$$

식(8)에서 *는 벡터의 요소 곱셈을 나타낸다. Update gate의 결과는 Hidden state로 보낸다. Reset gate는 이전 시점의 정보를 초기화 하며, 식(9)과 같다.

$$r_t = \sigma(W_r * [h_{t-1}, x_t]) \quad (9)$$

Hidden state는 이전 정보에 Reset gate의 결과를 곱해 출력으로 내보낼 정보를 선택한다. Hidden state의 식은 (10), (11)과 같다.

$$\tilde{h}_t = \tanh(W * [r_t * h_{t-1}, x_t]) \quad (10)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (11)$$

4) Transformer

RNN과 LSTM의 경우 입력이 길어질수록 기울기 소실 문제가 발생하게 되는데 Transformer는 Self-Attention Mechanism을 통해 입력과 출력의 관계를 학습하여 이러한 문제를 극복하였다.

시계열 데이터 처리를 위한 Transformer는 encoder와 decoder로 구성되어 있으며, 각각의 encoder와 decoder는 Multi-Head Attention Mechanism과 Feed-Forward Neural Network로 구성된다. Attention mechanism의 수학적 수식은 (12)와 같다

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_h}}\right)V \quad (12)$$

식에서 Q는 Query, K는 Key, V는 Value를 의미한다.

$$MultiHead(H^{l-1}) = [head_1, head_2, \dots, head_h] W^O \quad (13)$$

Transformer는 RNN, LSTM과 달리 한 번에 전체 데이터를 입력받기 때문에 Positional Encoding을 통해 데이터의 위치 관계를 표현한다. 이 후 한 번에 들어온 입력 데이터에 대하여 Multi-Head Attention을 통하여 데이터간의 연관 관계를 스스로 학습하는 구조를 갖는다.

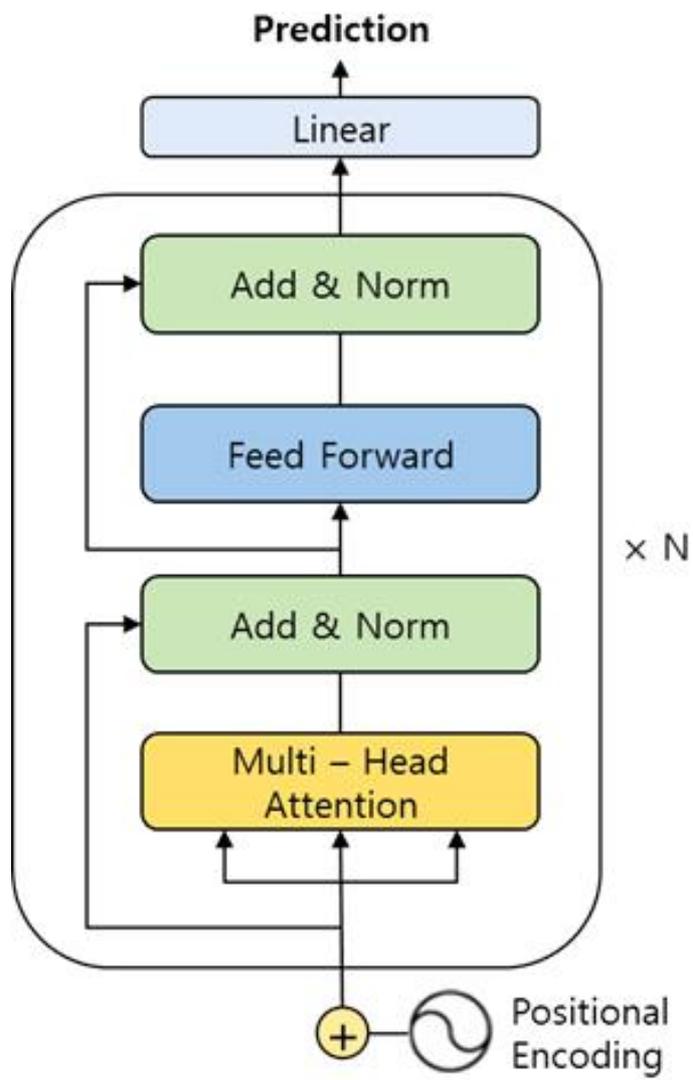


그림 4 Transformer 구조

II. 본론

1. 연구개요

그림 5과 같이 증분 용량 분석법과 Transformer를 이용한 SOH 추정 과정을 나타내었다. 먼저, 기존 배터리 데이터에 증분 용량 분석법을 적용하여 IC curve 추출 후 노이즈 제거를 위해 Gaussian filtering을 진행한다. 그 후 리튬 이온 배터리의 열화 상태와 원인을 분석하고, SOH와 관련된 특성 파라미터를 추출한다. 그리고 특성 파라미터와 리튬 이온 배터리 SOH와의 연관성을 검증하기 위해 상관관계 분석을 진행한다. 마지막으로 추출한 특성 파라미터를 입력으로 Transformer 모델을 학습하여 SOH를 추정한다.

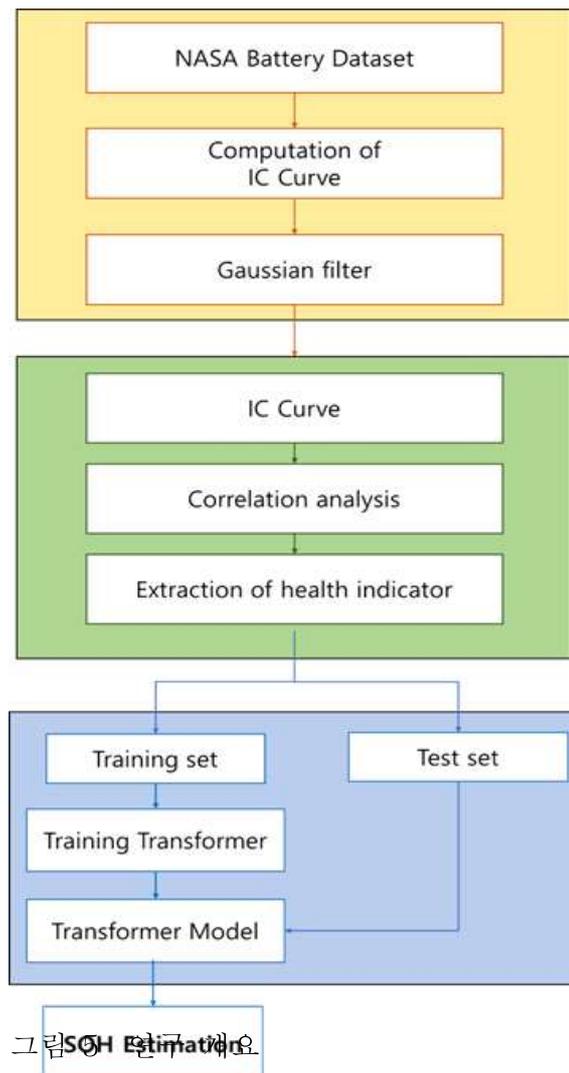


그림 5 SOH 연구개요

2. 리튬 이온 배터리 데이터

본 연구에서는 NASA Ames Prognostics Center of Excellence에서 측정된 Aging data for 18650 LIBs를 활용하였다[27]. 표 1은 각 배터리 셀의 초기 용량, 충전 전류, 방전 전류, Cut-off voltage를 나타낸다. 4개의 배터리(B0005, B0006, B0007, B0018)는 실온에서 Reference charge, Reference discharge를 반복하여 실험을 진행한다. 그림 6은 B0005의 충전 및 방전 프로세스를 나타낸다. Reference charge의 경우 CC-CV(Constant Current-Constant Voltage) 조건으로 충전된다. 1.5A의 정전류(CC)로 전압이 4.2V에 도달할 때까지 유지되고, 충전 전류가 20mA로 떨어질 때까지 정전압(CV)으로 계속 충전한다. Reference discharge의 경우 Cut-off 전압까지 떨어질 때까지 2A의 CC로 방전한다. 배터리의 임피던스 측정은 전기화학 임피던스 분광법(Electrochemical Impedance Spectroscopy, EIS)으로 수행된다.

표 1 리튬 이온 배터리 사양

Battery label	Initial Capacity (Ah)	Charge Current (A)	Discharge Current (A)	Cut-off Voltage (V)
B0005	1.86	2	1.5	2.7
B0006	2.04	2	1.5	2.5
B0007	1.89	2	1.5	2.2
B0018	1.86	2	1.5	2.5

그림 7는 사이클에 따른 4개 배터리의 용량 변화를 보여준다. 아래의 그림과 같이 사이클이 증가함에 따라 용량이 감소한다. 하지만 감소 후 상승하는 구간이 존재한다. 이는 배터리 열화를 위한 충전과 방전 이후 휴지 시간을 갖기 때문이다. 휴지 시간동안 배터리의 내부 화학 반응이 안정되어 용량이 상승하게 된다.

그림8와 그림9는 배터리 노화에 따른 CC-CV 충전에서 B0005의 전압과 전류의 변화를 보여준다. 사이클이 증가할수록 CC 충전 시간이 짧아지고, CV 충전 시간이 증가하는 것을 볼 수 있다. 이는 사이클이 증가할수록 배터리의 내부 저항이 증가하여 용량 저하에 영향을 끼치는 것을 알 수 있다. 따라서 본 논문은 4개 cell의 충전 곡선에 증분 용량 분석을 적용하여 특징점을 추출하였고, 딥러닝 기법을 적용하여 배터리의 SOH를 추정하였다.

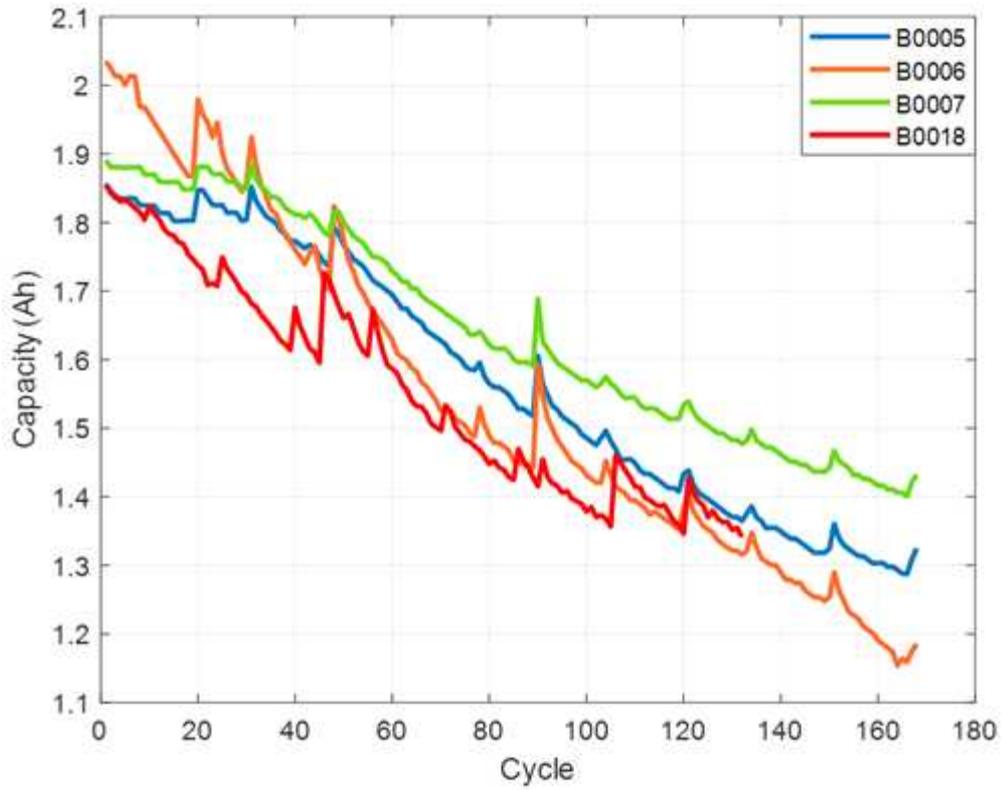


그림 6 4개 배터리 데이터의 사이클에 따른 용량 변화

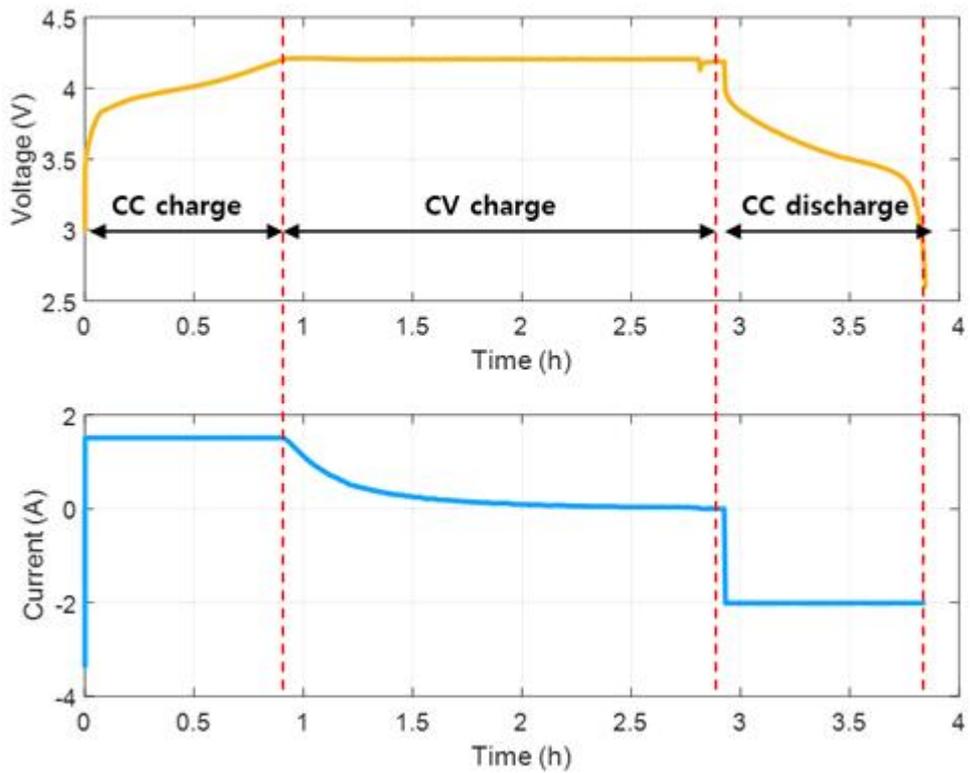


그림 7 B0005의 충전 및 방전 프로세스

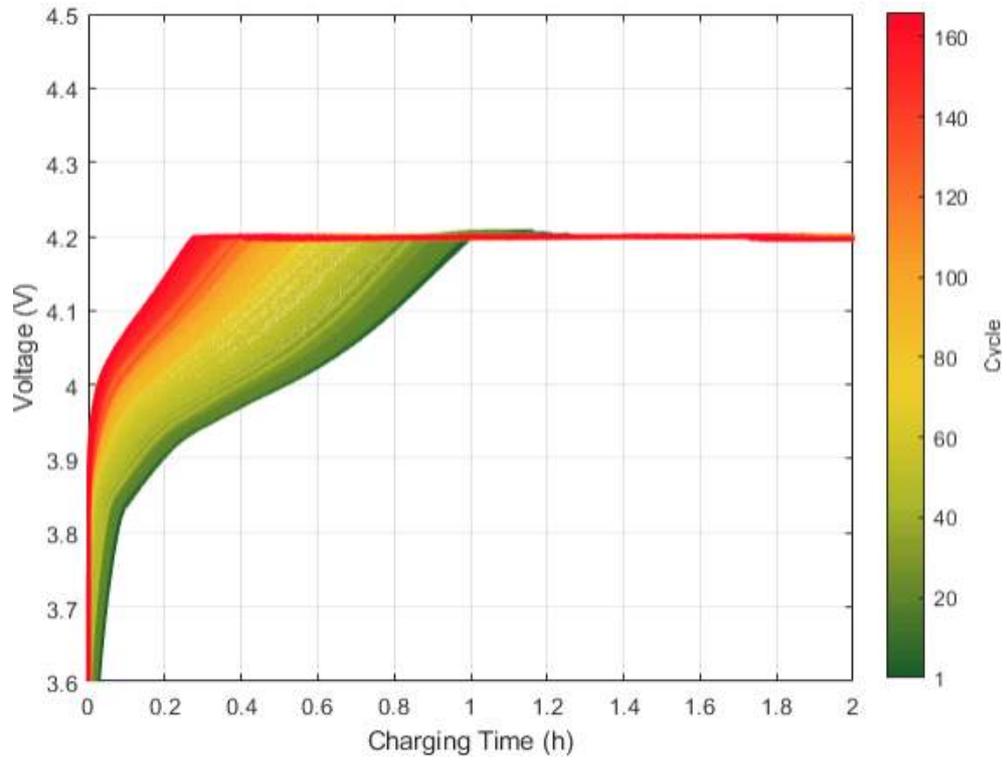


그림 8 CC-CV 충전에서 사이클에 따른 B005의 전압 변화

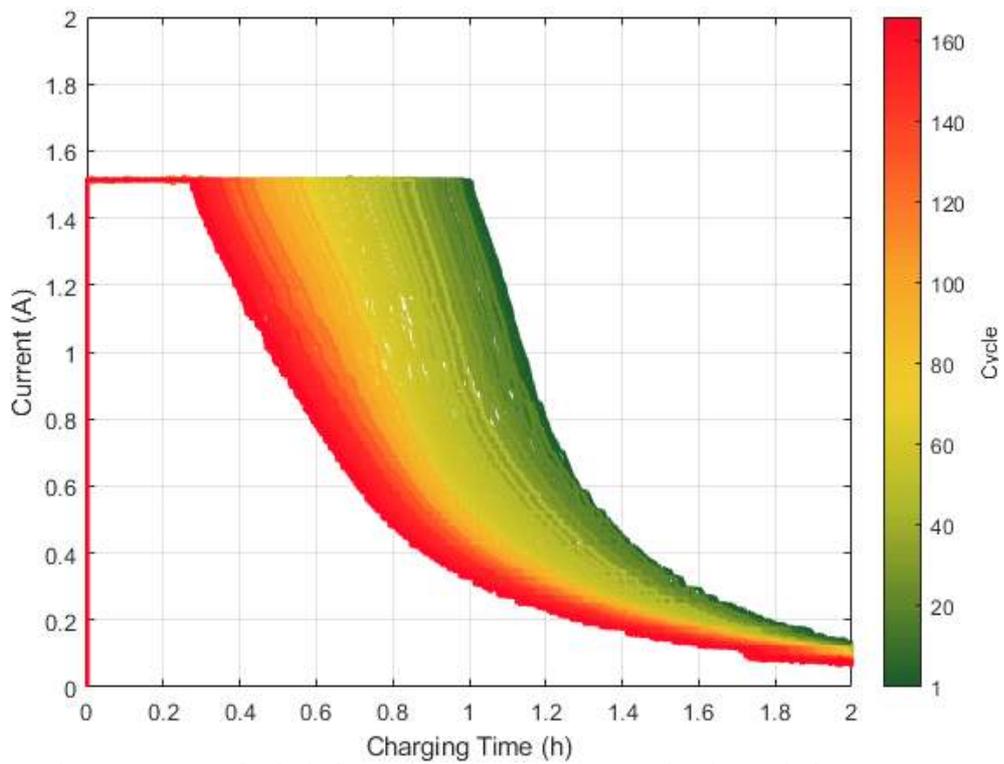


그림 9 CC-CV 충전에서 사이클에 따른 B005의 전류 변화

3. 증분 용량 분석법 및 특성 파라미터 추출

1) 증분 용량 분석 및 Gaussian filtering

증분 용량 분석법은 전극 수준에서 배터리의 열화 원인을 식별할 수 있는 분석 방법이다. 배터리의 전압 및 전류 데이터에서 얻은 IC(Incremental capacity) curve는 리튬 이온 배터리의 두 전극의 전기화학적 특성을 포함하고 고유한 모양과 강도를 나타낸다. 따라서 셀이 열화 정도에 따라 IC curve의 모양이 변화하며, 이를 통해 배터리 셀 내부의 전기 화학적 변화를 분석할 수 있다.

증분 용량 분석법은 전압 변화에 따른 용량의 미분으로 계산되며, 본 논문에서는 정전류 단계 동안의 데이터를 사용하여 증분 용량 분석을 실시하기 때문에 식 (12)와 같이 표현할 수 있다.

$$\frac{dQ}{dV} = \frac{I \times dt}{dV} = I \times \frac{dt}{dV} \quad (14)$$

식에서 Q 는 용량, V 는 전압, I 는 전류, t 는 시간을 나타낸다.

이처럼 기존의 증분 용량 분석법을 통해 얻은 IC curve의 경우 그림10과 같이 노이즈로 인해 정확한 데이터를 얻기가 어렵다. 이 문제를 해결하기 위해 고주파의 노이즈를 분리하여 필터링하는 기법인 GF(Gaussian filtering)를 사용하여 IC curve를 필터링하였다. GF의 수학적 식은 (13)와 같다.

$$G(x) = \frac{1}{\sigma \sqrt{2\pi}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \quad (15)$$

여기서 μ 와 σ 는 각각 평균값과 표준편차이다. GF가 적용되면 각 데이터 포인트는 이웃의 가중 평균으로 대체될 수 있습니다. 따라서 가장 가까운 데이터는 평균에 더 많은 영향을 미치고 먼 데이터는 더 작은 영향을 미치게 된다[24].

GF가 Smoothing에 사용되는 경우 μ 는 일반적으로 0으로 설정된다. σ 는 최종 곡선의 평활도, 보다 구체적으로 평균화에 사용하는 창의 크기를 제어하는 매개 변수로 사용된다. σ 가 클수록 더 부드러운 효과를 얻을 수 있지만 σ 가 너무 크면 곡선에서 일부 중요한 정보가 손실될 수 있다. 반대로 값이 너무 작으면 Smoothing 효과가 상대적으로 약할 수 있다. 따라서 σ 의 값은 적절한 범위를 유지해야 한다[28]. 본 논문에서는 σ 를 10로 설정하여 IC curve를 Smoothing하였다. 아래의 그림 11과 같이 Smooth IC curve를 나타내었다.

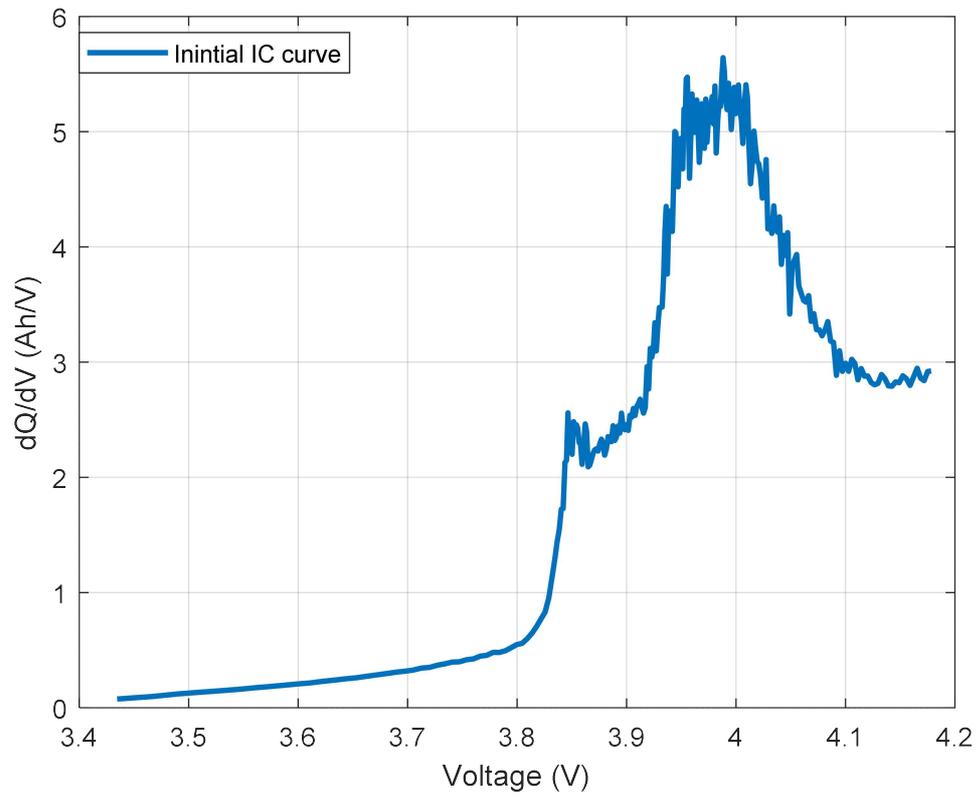


그림 10 Initial IC curve of B0005

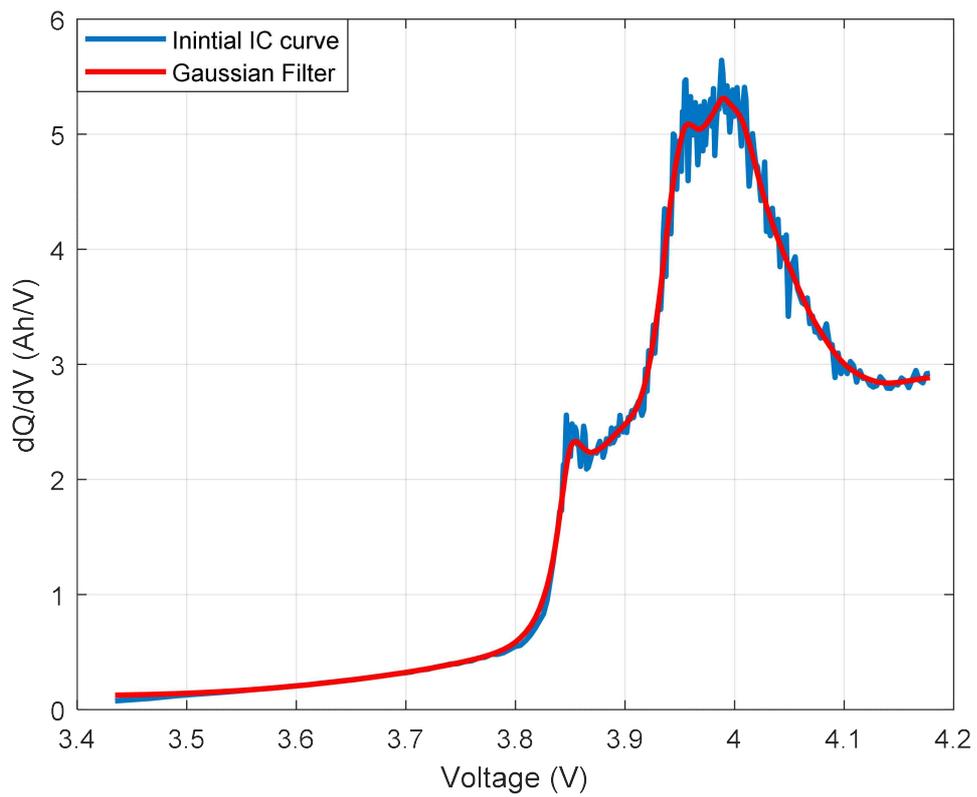


그림 11 Gaussian filtering results of IC Curve

2) 리튬 이온 배터리의 열화 상태 및 원인 분석

리튬 이온 배터리의 노화 상태는 Loss of Lithium Inventory(LLI), Loss of Active Material(LAM), Conductivity Loss(CL)로 분류할 수 있다[29-30].. 표2는 각 노화 상태에 따른 원인을 나타내었다.

LLI는 배터리 충전 및 방전 과정에서 발생하는 부반응에 의해 사용 가능한 리튬 이온이 감소하는 현상이다. 주로 Solid Electrolyte Interface(SEI) 층의 성장, lithium plating으로 인하여 발생한다[31]. 사용 가능한 리튬 이온의 감소로 인하여 배터리가 열화된다.

LAM은 전극의 구조적인 열화로 인하여 전극 활물질이 감소하는 현상이다. 주로 배터리의 충전 및 방전 과정에서 리튬 이온의 유입 및 유출이 반복되어 전극에 물리적인 손상이 발생하고, 리튬 이온의 확산에 영향을 끼치게 된다. 이로 인해 배터리가 열화된다. 그리고, lithium plating으로 인한 전극 손상에 의해서도 전극 활물질이 손상되어 배터리 열화를 가속화 한다.

IC curve 특성 분석을 기반으로 리튬 이온 배터리의 열화 상태에 대한 연구 [23]에 따르면 LLI는 IC curve의 peak의 변화 그리고 LAM은 IC curve의 Area 변화와 연관이 있다. 따라서 본 논문에서는 IC curve의 Peak, Peak position 그리고 Area의 변화를 통해 배터리 열화 원인을 분석하였으며, 추정을 위한 파라미터로 추출하였다.

[표 2] 리튬이온 배터리의 열화 상태 및 열화 원인[32]

Degradation Mode	Potential aging mechanisms	Effect
LLI	Electrolyte decomposition	Capacity fade & Power fade
	Oxidation of electrolyte	Power fade
	Lithium plating	Capacity fade & Power fade
	Formation of Li grains	Capacity fade & Power fade
	Solvent co-intercalation	Capacity fade & Power fade
LAM	Crystal structure disordering	Capacity fade & Power fade
	Electrode decomposition	Capacity fade & Power fade
	Formation of LI grains	Capacity fade
	Transition metal dissolution	Power fade
	Oxidation of the electrolyte	Power fade
CL	Lithium plating	Capacity fade & Power fade
	Current collector corrosion	Power fade
	Binder Decomposition	Capacity fade

3) 특성 파라미터 추출

그림 12은 B0005 리튬 이온 배터리의 사이클에 따른 IC curve의 변화를 나타내었다. 열화 상태에 따른 B0005의 IC curve의 변화를 나타내었다.

사이클이 증가할수록 IC curve의 Peak가 감소하고 Peak Position이 변화하는 것을 볼 수 있다. 이는 LLI의 영향으로 리튬 이온이 감소하여 이전 사이클보다 배터리의 최대 용량이 감소하였기 때문임을 알 수 있다. 사이클이 증가할수록 리튬 이온 배터리의 내부 저항 또한 증가한다. 이전 사이클 대비 동일한 용량만큼 충전을 해도 단자 전압이 증가하기 때문에 Peak Position이 증가하게 된다. 마지막으로, 사이클이 증가할수록 Area가 감소하는 것을 볼 수 있다. 이는 전 LAM의 영향으로 모든 구간에서 이전 사이클보다 증가하는 용량이 감소하였기 때문에 Area가 감소하였음을 알 수 있다.

따라서 IC curve의 Peak, Peak position 그리고 Area를 SOH 추정을 위한 특성 파라미터로 선택하였다.

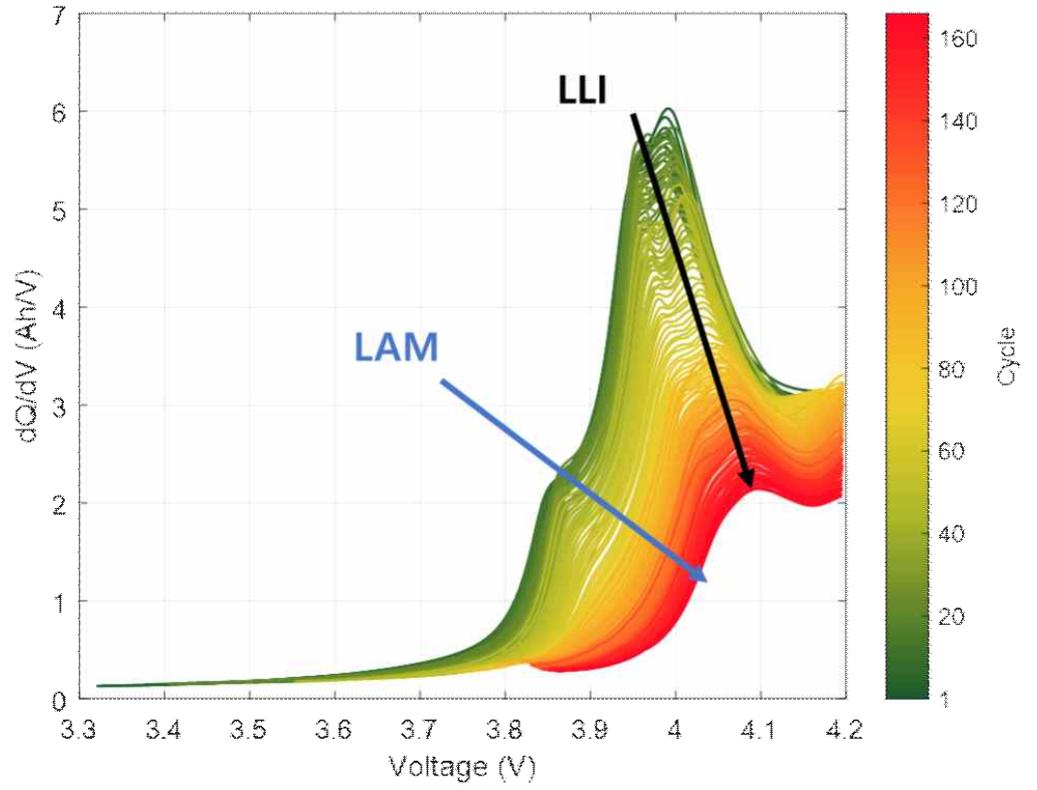


그림 12 B0005의 사이클에 따른 IC curve의 변화

4) 특성 파라미터 상관관계 분석

추출한 Peak, Peak position 그리고 Area가 배터리 용량의 변화와의 유용성을 정량적으로 검증하기 상관관계 분석을 진행하였다. 상관계수 분석의 경우 일반적으로 Pearson 상관계수 분석과 Spearman 상관계수 분석이 있다.

Pearson 상관관계 분석의 경우 데이터가 정규 분포를 갖는 경우에 적합하다. 반면, Spearman 상관계수 분석의 경우 위와 같은 제약 없이 사용할 수 있다. 본 연구에 사용된 NASA 배터리 데이터의 경우 정규 분포를 따르지 않아 Spearman 상관계수 분석을 사용했다. Spearman 상관계수 분석법의 식은 (14)와 같다.

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (16)$$

식(14)에서 ρ 는 Spearman correlation coefficient이다. ρ 는 $-1 \sim 1$ 의 값을 갖고, 절댓값이 클수록 높은 상관관계를 갖는다. n 은 샘플 크기이다.

상관관계 분석결과는 표 3과 같다. 4개 Cell의 모든 특성 파라미터가 0.95보다 크고, 이는 특성 파라미터와 배터리 용량 변화와 높은 상관관계가 있음을 나타낸다. 그림 13, 그림 14, 그림 15는 배터리 용량과 특성 파라미터간의 상관관계를 그래프로 나타낸 것이다. 값이 1에 가까울수록 상관관계가 높다.

표 3 특성 파라미터와 배터리 용량간의 상관관계 분석 결과

	B0005	B0006	B0007	B0018
Peak	0.9873	0.9973	0.9730	0.9683
Peak Position	-0.9613	-0.9919	-0.9530	0.9683
Area	0.9964	0.9962	0.9948	0.9817

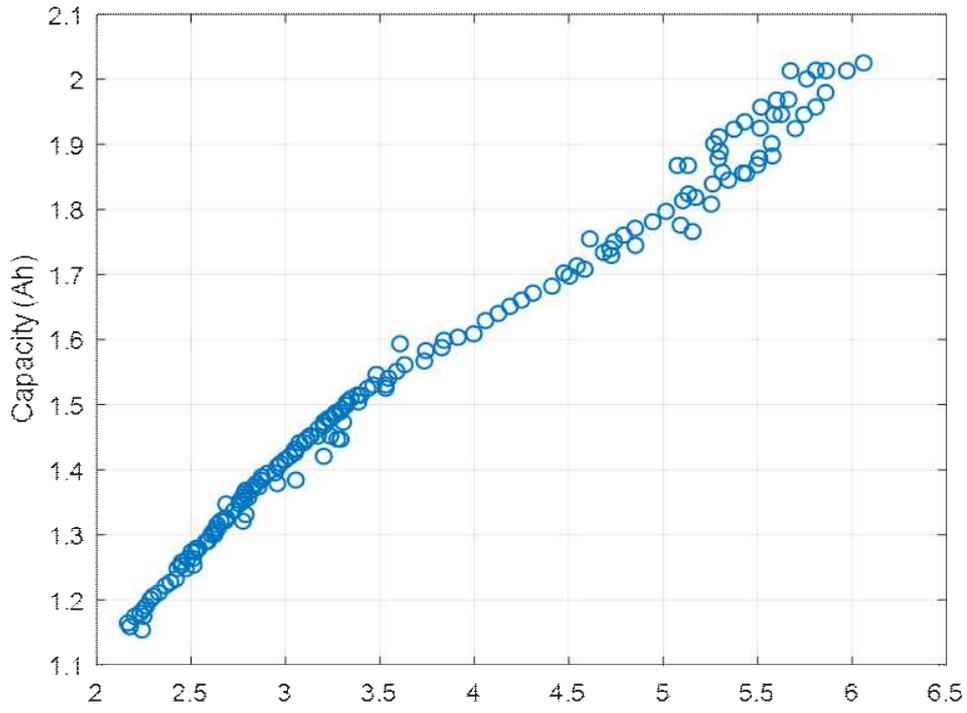


그림 13 Peak와 Capacity와의 상관관계 그래프

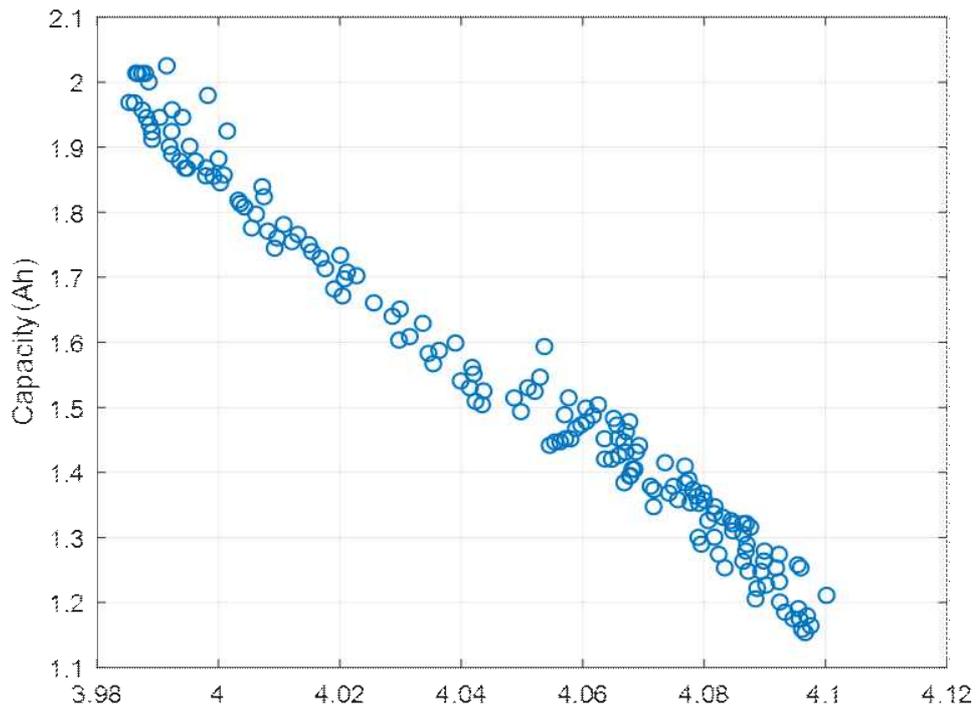


그림 14 Peak position과 Capacity와의 상관관계 그래프

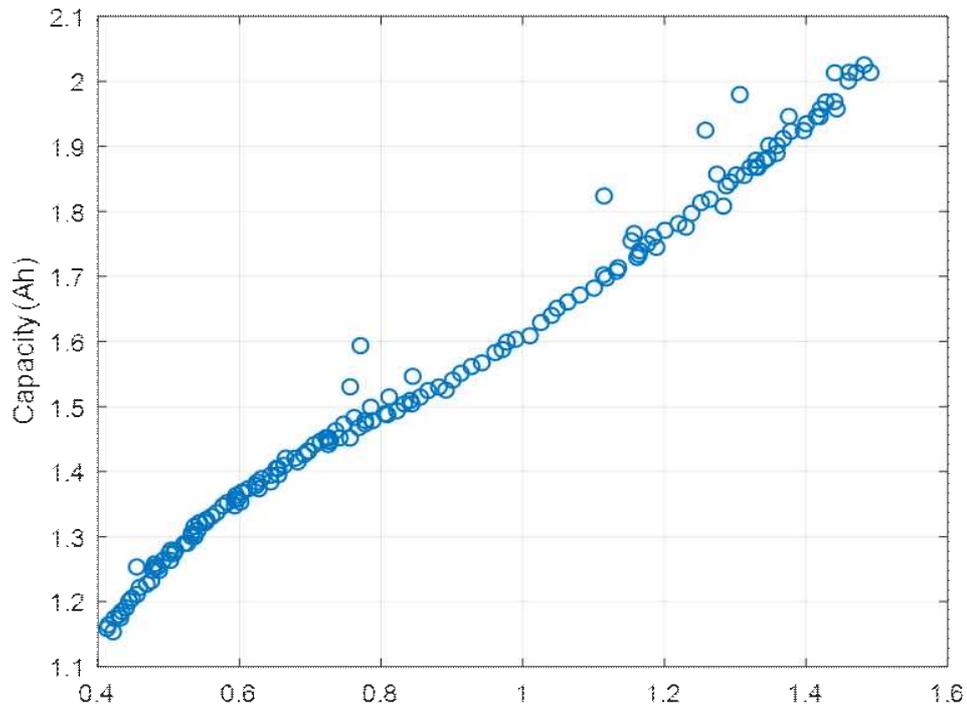


그림 15 Area와 Capacity와의 상관관계 그래프

4. SOH 추정 알고리즘

본 논문에서는 Transformer를 이용한 SOH 추정 알고리즘을 제안하고, 기존의 SOH 추정 알고리즘들과의 결과를 비교하여 성능을 검증하였다.

1) SOH 추정 알고리즘에 따른 Parameter setting

SOH 추정 알고리즘별 Parameter는 표4와 같다. m 은 Sample size, τ 는 Learning rate l 은 depth, s 는 Hidden size 그리고 λ 는 Regularization for learning을 나타낸다.

표 4 추정 알고리즘 별 파라미터 값

Models	m	τ	l	s	λ
RNN	16	0.001	2	64	10^{-6}
LSTM	16	0.001	2	64	10^{-6}
GRU	16	0.001	2	64	10^{-6}
Transformer	16	0.005	1	32	10^{-6}

III. 결과 및 분석

1. 모델 성능 평가 기준

본 논문에서는 SOH 추정 성능을 평가하기 위해 Root Mean Square Error(RMSE), Mean Absolute Error(MAE)와 Relative Error(RE)를 사용하였다. MAE와 RMSE의 식은 아래와 같다.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \tilde{y}_i| \quad (17)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \tilde{y}_i)^2}{n}} \quad (18)$$

$$RE(\%) = \frac{|y_i - \tilde{y}_i|}{y_i} \times 100 \quad (19)$$

위 식에서 n 은 Test data의 개수, y_i 는 실제 값, \tilde{y}_i 추정값을 나타낸다. 여기서 RMSE는 추정의 robustness와 오차의 평균을 직관적으로 볼 수 있고, MAE는 SOH 추정 정확도를 나타낸다 그리고, 상대 오차의 분산을 평가하기 위해 Boxplot을 사용하여 성능을 비교하였다.

본 논문에서는 훈련 데이터와 테스트 데이터를 7:3 비율로 나누어 평가를 진행하였다.

2. SOH 추정 알고리즘 정확도 평가

알고리즘 별 배터리 SOH 추정 성능을 비교하였다. 그림 16, 17, 18, 19는 리튬 이온 배터리 4개 cell의 실제 SOH와 알고리즘 별 SOH 추정 그래프를 나타내었다. 추정 알고리즘별 MAE 및 RMSE는 표 5와 같다.

먼저, RNN을 이용한 SOH 추정 알고리즘은 MAE와 RMSE가 가장 낮은 수치를 보여주었다. 이는 RNN의 문제점인 입력이 길어질수록 발생하는 기울기 소실 문제로 인해 데이터의 loss가 발생하고, 추정 성능이 가장 낮다고 판단된다.

LSTM과 GRU의 경우 RMSE가 4개 Cell에서 4% 개선되었다. GRU의 경우 LSTM의 구조를 간소화하여 학습 속도가 더 빠르고 성능 또한 비슷한 알고리즘이다. 일반적으로, 데이터의 양이 적을 때 GRU의 성능이 상대적으로 높다고 알려져 있다. 본 논문에서 입력으로 사용한 데이터의 경우 원본 데이터에서 특성 파라미터를 추출했기 때문에 상대적으로 입력 데이터의 크기가 작다. 따라서 GRU의 성능이 LSTM보다 좋다고 판단된다.

Transformer의 경우 RMSE가 GRU와 비교하여 4개 Cell에서 평균 35.6%가 증가하였다. 모든 경우에서 SOH 추정 성능이 가장 뛰어나다는 것을 알 수 있다. Transformer는 기존의 딥러닝 알고리즘과 달리 self-attention mechanism을 사용하여 학습한다. 따라서 RNN, LSTM, GRU와 달리 시계열 데이터를 순차적으로 처리할 필요가 없고, 중요한 정보의 위치를 반영하여 기울기 손상이 발생하지 않기 때문에 성능이 가장 높다고 판단된다. 이를 통해 제안하는 방법이 SOH 추정 정확도가 가장 높다는 것을 알 수 있었다.

표 5 추정 모델에 따른 SOH 추정 결과

		RNN	LSTM	GRU	Transformer
B0005	MAE	0.0124	0.0085	0.0080	0.0039
	RMSE	0.0141	0.0099	0.0097	0.0078
B0006	MAE	0.0221	0.0205	0.0219	0.0075
	RMSE	0.0266	0.0253	0.0239	0.0090
B0007	MAE	0.0100	0.0082	0.0080	0.0042
	RMSE	0.0126	0.0103	0.0095	0.0069
B0018	MAE	0.0102	0.0085	0.0088	0.0052
	RMSE	0.0156	0.0137	0.0135	0.0089

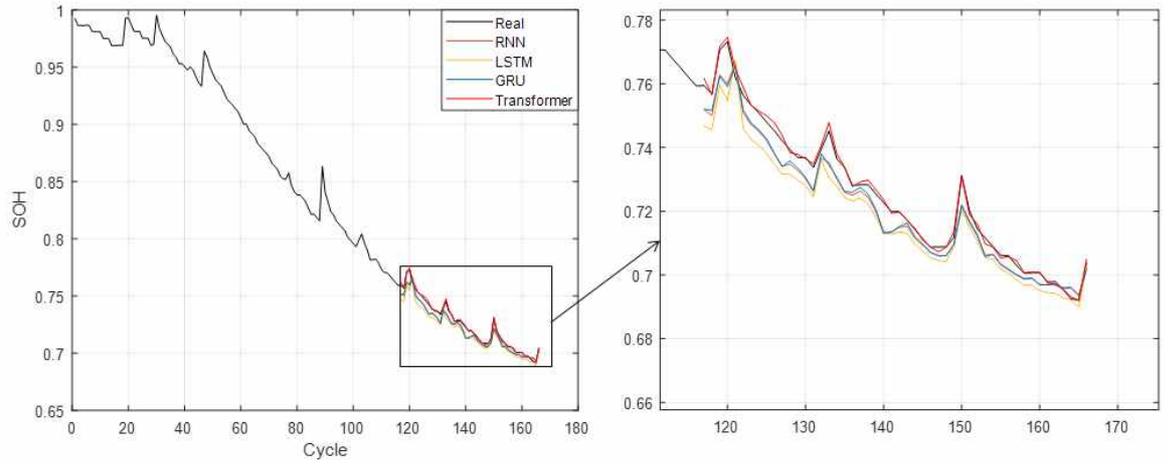


그림 16 B0005 SOH 추정 결과

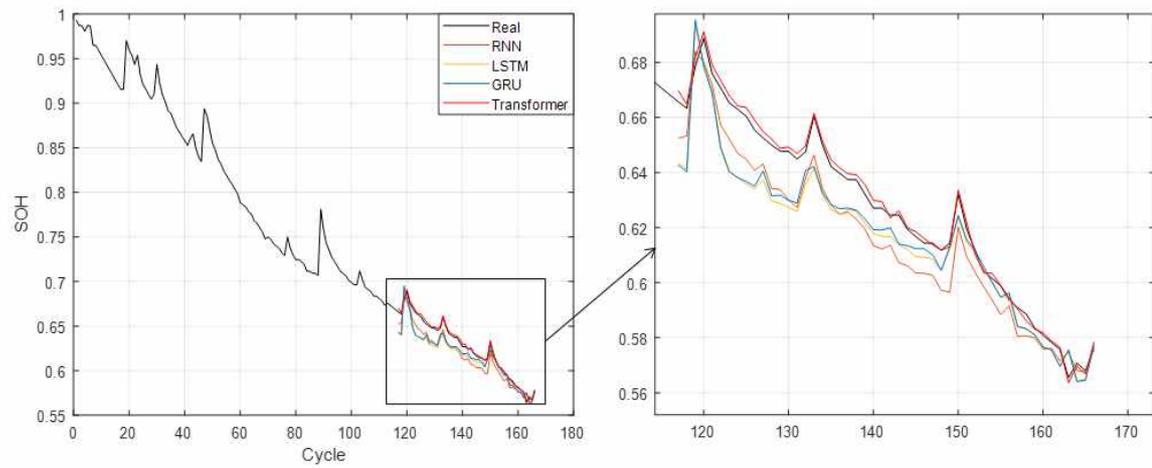


그림 17 B0006 SOH 추정 결과

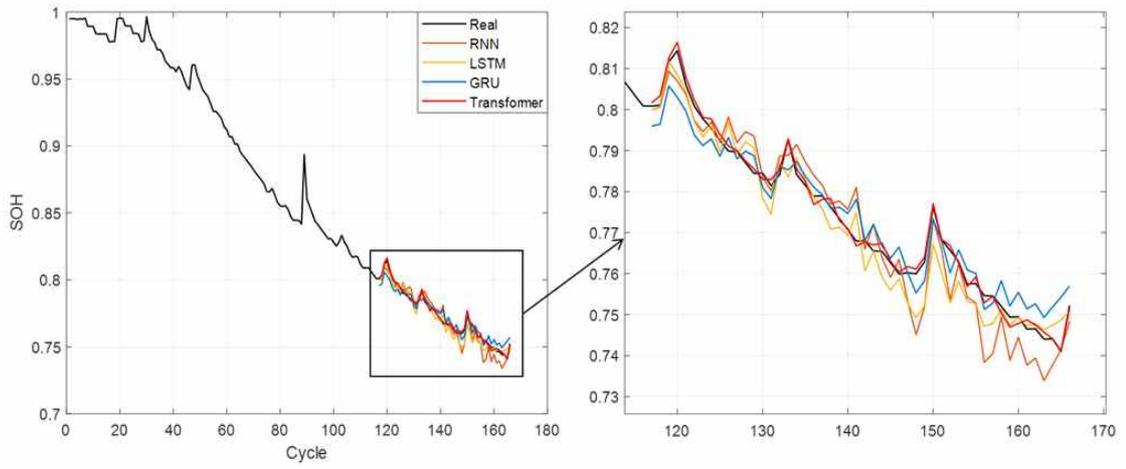


그림 18 B0007 SOH 추정 결과

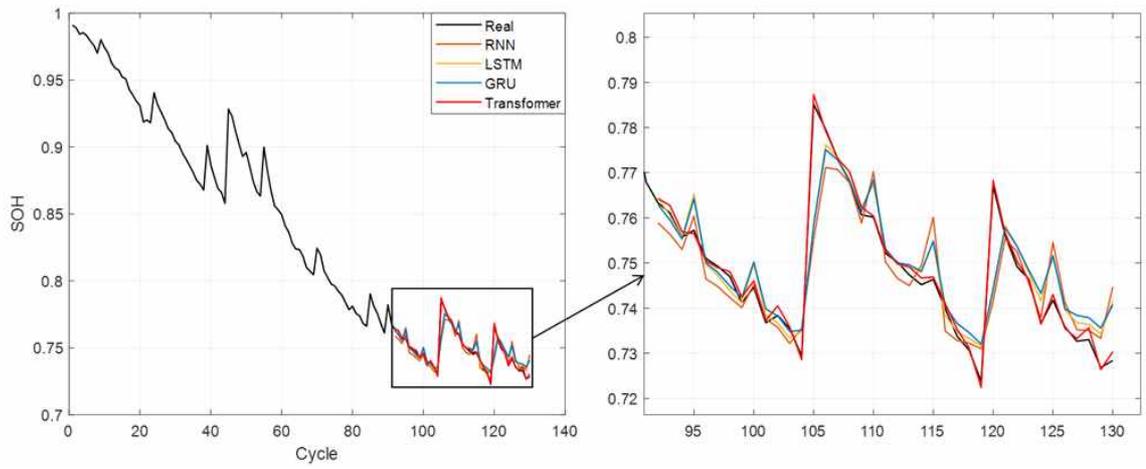


그림 19 B0018 SOH 추정 결과

다음으로, SOH 추정 알고리즘별 추정 결과의 안정도를 평가하였다. 이를 위해 상대 오차의 분산을 Boxplot을 사용하여 평가하였다. Boxplot은 Maximum, Minimum, Median, Third quartile, First quartile와 같은 지표들이 있고, IQR을 통해 성능을 평가한다.. IQR은 Third quartile과 First quartile 간의 차이이다. 각각의 요소에 대해서는 표 6에서 설명하였다. 상대 오차에 대한 결과는 표 7, 그림20과 같다.

먼저, RNN의 경우 상대 오차 분산이 가장 넓은 것을 확인할 수 있었고, 모든 평가 지표에서 가장 낮은 수치를 보였다. 이를 통해, RNN의 SOH 추정 결과가 안정성이 가장 낮은 것을 알 수 있다. 이는 RNN의 문제점인 입력이 길어질수록 발생하는 기울기 소실 문제로 인해 데이터의 loss가 발생하고, 추정 성능이 가장 낮다고 판단된다.

LSTM과 GRU의 상대 오차 분산의 경우 그래프와 결과 값이 유사하지만, IQR의 경우 GRU가 1.862% 감소하였다. 이를 통해 GRU의 SOH 추정 정확도와 추정 안정도가 향상되는 것을 확인하였다.

Tansformer의 경우 모든 SOH 추정 알고리즘과 비교하여 상대 오차의 분산이 가장 낮은 것을 알 수 있었다. 뿐만 아니라 GRU와 대비하여 IQR이 66.03% 향상 되었다. 따라서 본 논문에서 제안하는 방법이 SOH 추정결과의 정확도와 안정성에서 가장 우수한 것을 알 수 있었다.

표 6 Definitions of Boxplot indicator

Indicator	Definitions
Maximum	The Smallest data larger than $\text{median} + 1.5 \cdot \text{IQR}$
Third quartile	The middle value between the median and the highest value of dataset
Median	The middle value of the dataset
First quartile	The middle value between the median and the lowest value of the dataset
Minimum	The highest value larger than $\text{median} - 1.5 \cdot \text{IQR}$

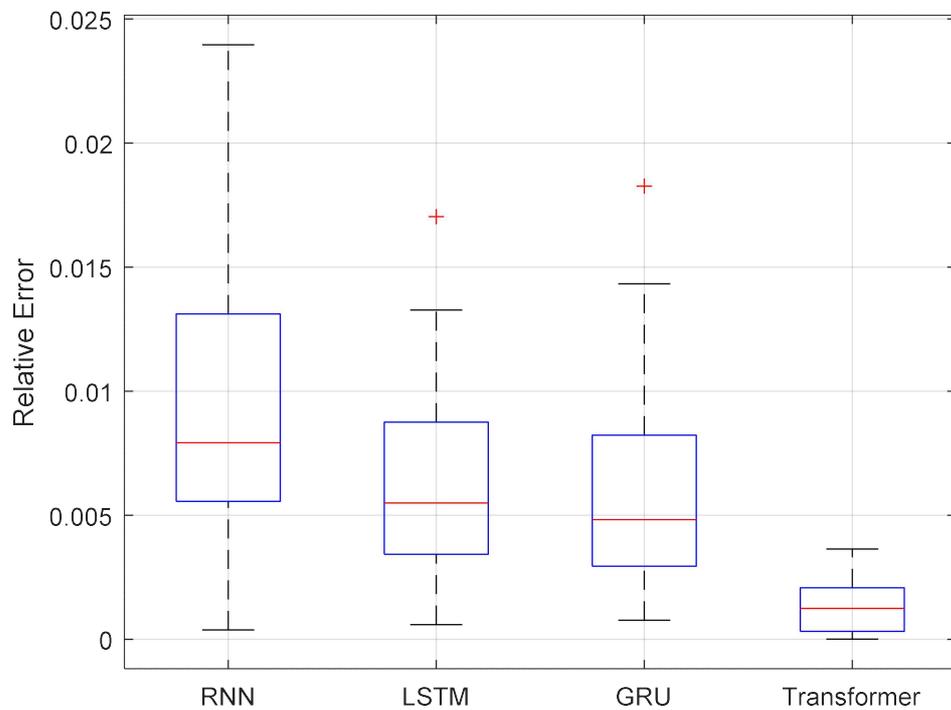


그림 20 SOH 추정 알고리즘별 상대 오차의 Boxplot

표 7 B0005의 SOH 추정 알고리즘별 상대 오차

Methods	Maximum	Third quartile	Median	First quartile	Minimum	IQR
RNN	0.0234	0.0131	0.0079	0.0056	0.0004	0.0075
LSTM	0.0170	0.0088	0.0055	0.0034	0.0006	0.0054
GRU	0.0183	0.0082	0.0048	0.0029	0.0008	0.0053
Transformer	0.0036	0.0021	0.0012	0.0003	0.0001	0.0018

IV. 결론

본 논문에서는 증분 용량 분석법과 딥러닝 알고리즘인 Transformer를 이용한 SOH 추정 방안을 제안하였다. 이를 검증하기 위해 NASA Ames Prognostics Center of Excellence에서 측정한 Aging data for 18650 LIB 데이터를 사용하였다.

증분 용량 분석법은 리튬 이온 배터리의 전기화학적 분석법으로, 현재 배터리의 열화 상태를 분석하여 열화 원인을 식별할 수 있다. 증분 용량 분석을 진행하여 IC curve를 추출하였고, Gaussian filter를 통해 IC curve를 Smoothing 하였다. 정제된 IC curve에서 리튬 이온 배터리의 열화와 관련된 특성 파라미터들을 추출하였고, 상관관계 분석을 통해 관련성을 검증하였다.

이를 통해, IC curve의 Peak, Peak position, Area를 특성 파라미터로 추출하여 SOH 추정 알고리즘의 입력데이터로 활용하였다. 본 논문에서는 기존의 RNN, LSTM, GRU 기반의 SOH 추정 모델과 제안하는 Transformer 기반의 SOH 추정 모델의 성능 비교를 통해 검증하였다.

SOH 추정 모델을 검증하기 위해 Train data와 Test data를 7:3으로 나누어 진행했고, MAE, RMSE 그리고 상대오차를 비교하여 SOH 추정 알고리즘별 정확도와 추정 안정성을 검증하였다. 이를 통해, 제안하는 방법의 SOH 추정 정확도와 안정성이 가장 우수한 것을 확인할 수 있었다.

참고문헌

- [1] Cano, Z.P.; Banham, D.; Ye, S.; Hintennach, A.; Lu, J.; Fowler, M.; Chen, Z. Batteries and fuel cells for emerging electric vehicle markets. *Nat. Energy* 2018, 3, 279 - 289.
- [2] Nishi, Y. Lithium ion secondary batteries; Past 10 years and the future. *J. Power Sources* 2001, 100, 101 - 106.
- [3] Abada, S.; Marlair, G.; Lecocq, A.; Petit, M.; Sauvant-Moynot, V.; Huet, F. Safety focused modeling of lithium-ion batteries: A review. *J. Power Sources* 2016, 306, 178 - 192.
- [4] Wang, Y.; Zhang, C.; Chen, Z. An adaptive remaining energy prediction approach for lithium-ion batteries in electric vehicles. *J. Power Sources* 2016, 305, 80 - 88.
- [5] Feng, X.; Lu, L.; Ouyang, M.; Li, J.; He, X. A 3D thermal runaway propagation model for a large format lithium ion battery module. *Energy* 2016, 115, 194 - 208.
- [6] Stroe, D.I.; Swierczynski, M.; Stan, A.I.; Teodorescu, R.; Andreassen, S.J. Accelerated lifetime testing methodology for lifetime estimation of lithium-ion batteries used in augmented wind power plants. *IEEE Trans. Ind. Appl.* 2014, 50, 4006 - 4017.
- [7] Khumprom, P.; Yodo, N. A data-driven predictive prognostic model for lithium-ion batteries based on a deep learning algorithm. *Energies* 2019, 12, 660.
- [8] Khumprom, P.; Yodo, N. A data-driven predictive prognostic model for lithium-ion batteries based on a deep learning algorithm. *Energies* 2019, 12, 660.
- [9] Plett, G.L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs—Part 1. Background. *J. Power Sources* 2004, 134, 252 - 261.
- [10] Kim, Y.; Bang, H. Introduction to Kalman Filter and Its Applications. *Introd. Implement. Kalman Filter* 2019, 1, 1 - 16.
- [11] Sepasi, S.; Ghorbani, R.; Liaw, B.Y. Inline state of health estimation of lithium-ion batteries using state of charge calculation. *J. Power Sources* 2015, 299, 246 - 254.

- [12] Chen, Z.P.; Wang, Q.T. The Application of UKF Algorithm for 18650-type Lithium Battery SOH Estimation. *Appl. Mech. Mater.* 2014, 519 - 520, 1079 - 1084.
- [13] Liang, J.; Peng, X.-Y. Improved particle filter for nonlinear system state. *Electron. Lett.* 2008, 44, 1275 - 1277.
- [14] Miao, Q.; Xie, L.; Cui, H.; Liang, W.; Pecht, M. Remaining useful life prediction of lithium-ion battery with unscented particle filter technique. *Microelectron. Reliab.* 2013, 53, 805 - 810
- [15] Liu, D.; Yin, X.; Song, Y.; Liu, W.; Peng, Y. An on-line state of health estimation of lithium-ion battery using unscented particle filter. *IEEE Access* 2018, 6, 40990 - 41001.
- [16] Qu, J.; Liu, F.; Ma, Y.; Fan, J. A Neural-Network-Based Method for RUL Prediction and SOH Monitoring of Lithium-Ion Battery. *IEEE Access* 2019, 7, 87178 - 87191.
- [17] Oji, T.; Zhou, Y.; Ci, S.; Kang, F.; Chen, X.; Liu, X. Data-Driven Methods for Battery SOH Estimation: Survey and a Critical Analysis. *IEEE Access* 2021, 9, 126903 - 126916.
- [18] Nuhic, A.; Terzimehic, T.; Soczka-Guth, T.; Buchholz, M.; Dietmayer, K. Health diagnosis and remaining useful life prognostics of lithium-ion batteries using data-driven methods. *J. Power Sources* 2013, 239, 680 - 688
- [19] Liu, D.; Zhou, J.; Liao, H.; Peng, Y.; Peng, X. A health indicator extraction and optimization framework for lithium-ion battery degradation modeling and prognostics. *IEEE Trans. Syst. Man Cybern. Syst.* 2015, 45, 915 - 928.
- [20] Li, Y.; Zhong, S.; Zhong, Q.; Shi, K. Lithium-ion battery state of health monitoring based on ensemble learning. *IEEE Access* 2019, 7, 8754 - 8762.
- [21] Ren, L.; Zhao, L.; Hong, S.; Zhao, S.; Wang, H.; Zhang, L. Remaining Useful Life Prediction for Lithium-Ion Battery: A Deep Learning Approach. *IEEE Access* 2018, 6, 50587 - 50598.
- [22] You, G.W.; Park, S.; Oh, D. Diagnosis of Electric Vehicle Batteries Using Recurrent Neural Networks. *IEEE Trans. Ind. Electron.* 2017, 64, 4885 - 4893.
- [23] Park, M.-S.; Lee, J.-k.; Kim, B.-W. SOH Estimation of Li-Ion Battery Using Discrete Wavelet Transform and Long Short-Term Memory Neural Network. *Appl. Sci.* 2022, 12, 3996. <https://doi.org/10.3390/app12083996>

- [24] D. Anseán et al., "Lithium-Ion Battery Degradation Indicators Via Incremental Capacity Analysis," in *IEEE Transactions on Industry Applications*, vol. 55, no. 3, pp. 2992–3002, May–June 2019, doi: 10.1109/TIA.2019.2891213.
- [25] LI, Xiaoyu, et al. State of health estimation for Li-Ion battery using incremental capacity analysis and Gaussian process regression. *Energy*, 2020, 190: 116467.
- [26] Vaswani, Ashish, et al. "Attention is all you need." *Advances in neural information processing systems* 30 (2017).
- [27] B. Saha, K. Goebel, Battery data set, Available online: <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/>
- [28] B. Jia and M. Xin, "Data-Driven Enhanced Nonlinear Gaussian Filter," in *IEEE Transactions on Circuits and Systems II: Express Briefs*, vol. 67, no. 6, pp. 1144–1148, June 2020.
- [29] VETTER, Jens, et al. Ageing mechanisms in lithium-ion batteries. *Journal of power sources*, 2005, 147.1-2: 269–281.
- [30] DUBARRY, Matthieu; TRUCHOT, Cyril; LIAW, Bor Yann. Synthesize battery degradation modes via a diagnostic and prognostic model. *Journal of power sources*, 2012, 219: 204–216.
- [31] VERMA, Pallavi; MAIRE, Pascal; NOVÁK, Petr. A review of the features and analyses of the solid electrolyte interphase in Li-ion batteries. *Electrochimica Acta*, 2010, 55.22: 6332–6341.
- [32] PASTOR-FERNÁNDEZ, Carlos, et al. A comparison between electrochemical impedance spectroscopy and incremental capacity-differential voltage as Li-ion diagnostic techniques to identify and quantify the effects of degradation modes within battery management systems. *Journal of Power Sources*, 2017, 360: 301–318.

ABSTRACT

A Study on Lithium-ion Battery SOH Estimation Based on Incremental Capacity Analysis and Transformer

Min Sick Park

Graduate school of Electrical Electronic and computer
Engineering
University of Ulsan
Ulsan, Korea

Lithium-ion batteries are used as an energy source for electric vehicles due to their advantages such as high energy density, long life, and high efficiency. In order to ensure the safe state of lithium-ion batteries under various driving conditions the accurate state of charge (SOH) state of lithium-ion batteries must be estimated. Therefore, for accurate SOH estimation, this paper analyzes the deterioration state and deterioration causes of lithium-ion batteries by incremental capacity analysis method, and extracts the characteristic for SOH estimation. Using the extracted characteristic parameters, we grasped the cause of deterioration of the current battery, and performed a correlation analysis to verify the usefulness of the characteristic parameters. The SOH estimation method was studied using the characteristic parameters verified by correlation analysis as the input of Transformer for SOH estimation.

Key Words : Lithium-ion Battery, Incremental Capacity Analysis, Correlation analysis, Deep learning, RNN(Recurrent Neural Network), LSTM(Long Short Term

Memory), GRU(Gate Recurrent Unit) ,Transformer, SOH Estimation.