



(19) 대한민국특허청(KR)
(12) 등록특허공보(B1)

(45) 공고일자 2024년11월19일
(11) 등록번호 10-2731011
(24) 등록일자 2024년11월12일

(51) 국제특허분류(Int. Cl.)
G01R 31/367 (2019.01) G01R 31/36 (2019.01)
G01R 31/382 (2019.01) G01R 31/396 (2019.01)
G06N 20/00 (2019.01)

(52) CPC특허분류
G01R 31/367 (2019.01)
G01R 31/3648 (2013.01)

(21) 출원번호 10-2019-0066881
(22) 출원일자 2019년06월05일
심사청구일자 2022년03월17일
(65) 공개번호 10-2020-0140093
(43) 공개일자 2020년12월15일
(56) 선행기술조사문헌
KR101509001 B1*
(뒷면에 계속)

(73) 특허권자
삼성에스디아이 주식회사
경기도 용인시 기흥구 공세로 150-20 (공세동)
포항공과대학교 산학협력단
경상북도 포항시 남구 청암로 77 (지곡동)

(72) 발명자
이경환
경기도 용인시 기흥구 공세로 150-20 (공세동)
김민호
경상북도 포항시 남구 지곡로 83, 6동 204호(지곡동, 포스빌)
한수희
경상북도 포항시 남구 청암로 77, 교수 아파트 4동 1103호(지곡동)

(74) 대리인
리엔목특허법인

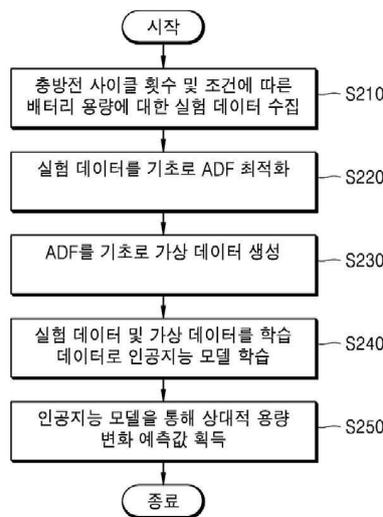
전체 청구항 수 : 총 4 항
심사관 : 김기환

(54) 발명의 명칭 **배터리의 충전 사이클에 따른 용량 변화 예측방법 및 예측시스템**

(57) 요약

본 발명은 배터리의 용량 변화 예측방법 및 예측시스템에 관한 것으로, 특히, 이차전지의 충전 사이클과 관련된 특정 조건에서 용량 변화를 예측하는 방법 및 시스템에 관한 것이다. 배터리의 충전 사이클에 따른 배터리 용량 변화 예측 방법은 복수의 충전 사이클 횟수 및 충전 사이클 조건에 따른 배터리의 용량에 대한 적어도 하나의 제1 데이터를 수집하는 단계, 제1 데이터를 기초로, 배터리의 상대적 용량변화 값을 예측하는 제1 계산식을 최적화하는 단계, 제1 계산식을 기초로, 복수의 충전 사이클 횟수 및 충전 사이클 조건에 대응하는 상대적 용량 변화 값에 대한 적어도 하나의 제2 데이터를 생성하는 단계, 제1 데이터와 제2 데이터를 학습 데이터로, 상대적 용량 변화 값을 출력하기 위한 인공지능 모델을 학습시키는 단계 및 충전 사이클 횟수 및 충전 사이클 조건을 인공지능 모델에 입력하여 출력된 상대적 용량의 변화 예측값을 획득하는 단계를 포함한다.

대표도 - 도2



(52) CPC특허분류

G01R 31/382 (2019.01)

G01R 31/396 (2019.01)

G06N 20/00 (2021.08)

(56) 선행기술조사문헌

CN107238800 A*

KR101952565 B1*

KR1020170085365 A*

WO2019017991 A1*

JP2009052974 A*

*는 심사관에 의하여 인용된 문헌

명세서

청구범위

청구항 1

배터리의 충방전 사이클에 따른 배터리 용량 변화 예측 방법에 있어서,

복수의 충방전 사이클 횟수 및 충방전 사이클 조건에 따른 상기 배터리의 용량에 대한 적어도 하나의 제1 데이터를 수집하는 단계;

상기 제1 데이터를 기초로, 상기 배터리의 상대적 용량변화 값을 예측하는 제1 계산식을 최적화하는 단계;

상기 제1 계산식을 기초로, 복수의 충방전 사이클 횟수 및 충방전 사이클 조건에 대응하는 상대적 용량 변화 값에 대한 적어도 하나의 제2 데이터를 생성하는 단계;

상기 제1 데이터와 상기 제2 데이터를 학습 데이터로, 상대적 용량 변화 값을 출력하기 위한 인공지능 모델을 학습시키는 단계; 및

충방전 사이클 횟수 및 충방전 사이클 조건을 상기 인공지능 모델에 입력하여 출력된 상대적 용량의 변화 예측 값을 획득하는 단계;를 포함하는 배터리 용량 변화 예측 방법

청구항 2

제1항에 있어서,

상기 충방전 사이클 조건은 정전류 충전 구간, 정전압 충전 구간, 제1 휴지 구간, 정전류 방전 구간 및 제2 휴지 구간을 포함하고,

상기 수집하는 단계는 상기 충방전 사이클 조건에 따른 상기 배터리의 용량에 대한 정보를 수집하는 것인 배터리 용량 변화 예측 방법.

청구항 3

제1항에 있어서,

상기 수집하는 단계는,

기설정된 충방전 사이클 횟수마다 RPT(reference performance test)를 수행하는 단계;

상기 RPT 결과를 기초로 OCV-SOC LUT(Lookup table)을 획득하는 단계;를 더 포함하고,

상기 제1 계산식은 충전율, 방전율, 사이클 별 배터리의 최대 최소 SOC(state of charge) 및 온도를 기초로 중복 조합을 수행하여 상대적 용량변화 값을 계산하는 것이고,

상기 제1 계산식을 최적화하는 단계는 상기 OCV-SOC LUT를 기초로 상기 사이클 별 배터리의 최대 최소 SOC(state of charge)를 결정하는 것인 배터리 용량 변화 예측 방법.

청구항 4

제1항에 있어서,

상기 최적화하는 단계는,

상기 제1 계산식을 기초로 획득한 제1 상대적 용량 손실량과 상기 제1 데이터를 기초로 획득한 제2 상대적 용량 손실량 간의 오차가 최소가 되도록 하는 상기 제1 계산식의 파라미터를 획득하는 단계; 및

상기 파라미터를 기초로 상기 제1 계산식을 업데이트하는 단계;를 더 포함하는 배터리 용량 변화 예측 방법.

발명의 설명

기술분야

- [0001] 본 발명은 배터리의 용량 변화 예측방법 및 예측시스템에 관한 것으로, 특히, 이차전지의 충전 사이클과 관련된 특정 조건에서 용량 변화를 예측하는 방법 및 시스템에 관한 것이다.
- [0002] 또한, 본 발명은 기계 학습 알고리즘을 활용하여 인간 두뇌의 인지, 판단 등의 기능을 모사하는 인공지능(Artificial Intelligence, AI) 시스템 및 그 응용에 관한 것이다.

배경기술

- [0003] 이차 전지는 방전되면 다시 충전하여 쓸 수 있는 종류의 배터리를 의미하며, 주로 사용되는 배터리는 에너지 밀도(Energy density)와 전력 밀도(Power density)가 높고 가동 전압 범위(Voltage range)가 높은 리튬이온 배터리이다. 최근 전기 자동차가 많이 사용되면서 전기 자동차의 핵심 기술인 이차 전지의 BMS(Battery Management System) 기술 개발이 중요한 연구로 부상하고 있다. 또한 신재생 에너지 개발의 가속화로 신재생 에너지가 전력 계통(Power System)에 안정적으로 공급되기 위한 에너지 저장장치 ESS(Energy Storage System)의 중요성이 커졌다. 그에 따라 BMS 등 배터리 관련 기술이 어느 때 보다 중요해지고 있다.
- [0004] 이차 전지는 충전 및 방전을 거치면서 노화 과정을 겪으며 내부 저항이 증가하고 용량은 감소하게 된다. 노화된 정도를 배터리의 건강상태(State of Health, SOH) 라는 지표로 정의 하게 되는데 SOH는 일반적으로 현재 배터리의 내부 저항 또는 용량으로 계산하게 된다. 어떠한 입력을 인가 하느냐에 따라 측정되는 내부 저항 값도 달라지고, 노화가 진행됨에 따라 용량의 변화에 비해 내부 저항의 변화는 상대적으로 불규칙하다. 따라서 용량의 변화 량으로 SOH를 정의하는 것이 일반적이다. SOH가 상당히 감소하게 되면(즉, 노화가 상당히 진행되면) 배터리의 에너지를 이용하는 장치의 작동에 상당한 문제를 일으킬 수 있다. 예를 들면, 내부 단락(internal short circuit)이나 열 폭주(thermal runaway) 등 큰 재난을 일으킬 수 있는 현상부터 완전 충전상태에서 다음 충전 시간까지 걸리는 시간이 짧아서 장치의 지속적인 작동에 불편을 겪는 것까지 많은 문제를 일으킬 수 있다.
- [0005] 따라서 적절한 시기, 즉 배터리의 SOH가 일정량 감소했을 때, 배터리를 교체해주어야 경제적으로도 좋고, 인명 피해도 줄일 수 있다. 이에 따라, 배터리의 SOH를 예측하는 모델이 반드시 필요하다. 현재의 SOH 추정뿐만 아니라 특정 배터리 사용 패턴이 지속되었을 때 어느 시점에서 SOH 값이 어떻게 되는지 예측할 수 있는 모델이 필요하다.
- [0006] 한편, 기존의 SOH를 예측하는 방법은 크게 세가지로 나눌 수 있는데, 물리적 원리 기반 모델(Physical model), 경험적 모델(Empirical model), 데이터 기반 모델(Data-driven model) 이 있다.
- [0007] 물리적 원리 기반의 모델은 배터리 내부의 전기화학적 현상들(Electrochemical phenomena) 들을 여러 개의 편미분 방정식으로 모델링하여 사용패턴에 따라서 어떻게 노화가 진행될 것인지를 예측하는 모델이다. 이 방법으로는 배터리에 임의의 입력을 인가 했을 때 어느 정도로 노화가 일어나는지 알 수 있는 범용적인 모델이 대부분이다. 하지만 이 방법은 배터리 내부의 수많은 파라미터 값들을 정확히 알아야 예측의 정확도를 확보 할 수 있다. 배터리 생산과정에서 일부 파라미터 값은 알아낼 수 있지만 모든 파라미터를 알 수 없다. 또한 모델링한 현상들도 배터리 내부의 복잡한 모든 현상을 반영할 수 없기 때문에 아직까지도 배터리의 노화를 정확히 모델링 하는 표준화된 물리적 원리 기반 모델은 없다. 또한 물리적 원리 기반 모델은 복잡한 편미분 방정식을 풀어야하므로 계산 시간이 오래 걸린다.
- [0008] 경험적 모델의 경우는 주로 일정한 패턴의 충전 방전 사이클에 대한 노화가 모델링 된다. 주로 3 가지 정도의 경험적으로 얻은 원리가 통상적으로 적용되는데 첫번째는 용량 변화가 사이클 회수에 대한 지수 법칙(power law)을 따른다는 원리, 두번째는 용량 변화가 배터리에 출입한 총 전하량(Current Throughput)의 함수라는 원리, 세번째는 용량 변화에 대한 온도의 영향은 아레니우스 법칙(Arrhenius law)을 따른다는 원리이다. 경험적 모델의 경우 위의 원리로 이루어진 간단한 수학적모델이 대부분이므로 계산 량이 적어 성능이 매우 높은 컴퓨터가 필요하지 않다. 하지만 경험적 모델의 경우도 위의 원리를 어떻게 조합하느냐에 따라 무수히 많은 모델을 만들 수 있고 그에 대해 정확도가 높다고 검증된 표준화된 모델이 아직 없다. 그리고 이러한 원리들은 다양한 종류와 특성을 가진 이차 전지의 물리적인 원리를 모두 표현하기 힘들기 때문에 특정 배터리에 대해서는 큰 오차를 보이기도 한다.
- [0009] 데이터 기반 모델은 배터리 실험을 통해 얻은 데이터를 이용하여 기계학습(Machine Learning) 모델을 학습하여 용량 변화를 예측하는 방법이다. 이 방법으로는 다양한 배터리의 물리적 특징을 모두 반영하는 것이 가능하고 임의의 입력에 대해서도 용량 변화를 예측할 수 있는 예측 모델을 만드는 것도 가능하다. 하지만 데이터 기반

모델의 가장 큰 단점은 데이터가 부족하면 정확한 예측을 하기 힘들다는 것이다. 배터리에 대한 많은 데이터를 얻는 것은 쉽지 않다. 배터리 실험을 하는 것은 비용도 많이 들고 시간도 많이 들게 된다. 따라서 데이터 기반 모델은 실용적인 모델이 될 수 없다.

발명의 내용

해결하려는 과제

- [0010] 본 발명은 상술한 필요성에 따른 것으로, 다양한 종류의 배터리에 대한 물리적 특성을 반영 할 수 있으며, 계산량이 적고, 비교적 적은 데이터만으로도 모델 구축한 이차 전지의 충전 방전 사이클에 따른 용량의 변화를 예측하기 위한 방법을 제공할 수 있다.
- [0011] 또한, 본 발명은 예측의 신뢰성 및 정확도도 높은 이차 전지의 충전 방전 사이클에 따른 용량의 변화를 예측하기 위한 예측방법 및 예측 시스템을 제공하는 것을 목적으로 한다.
- [0012] 그러나 이러한 과제는 예시적인 것으로, 이에 의해 본 발명의 범위가 한정되는 것은 아니다.

과제의 해결 수단

- [0013] 본 발명의 일 실시 예에 따른 배터리의 충전 사이클에 따른 배터리 용량 변화 예측 방법에 있어서, 복수의 충전 사이클 횟수 및 충전 사이클 조건에 따른 상기 배터리의 용량에 대한 적어도 하나의 제1 데이터를 수집하는 단계; 상기 제1 데이터를 기초로, 상기 배터리의 상대적 용량변화 값을 예측하는 제1 계산식을 최적화하는 단계; 상기 제1 계산식을 기초로, 복수의 충전 사이클 횟수 및 충전 사이클 조건에 대응하는 상대적 용량 변화 값에 대한 적어도 하나의 제2 데이터를 생성하는 단계; 상기 제1 데이터와 상기 제2 데이터를 학습 데이터로, 상대적 용량 변화 값을 출력하기 위한 인공지능 모델을 학습시키는 단계; 및 충전 사이클 횟수 및 충전 사이클 조건을 상기 인공지능 모델에 입력하여 출력된 상대적 용량의 변화 예측값을 획득하는 단계;를 포함한다.
- [0014] 또한, 상기 충전 사이클 조건은 정전류 충전 구간, 정전압 충전 구간, 제1 휴지 구간, 정전류 방전 구간 및 제2 휴지 구간을 포함하고, 상기 수집하는 단계는 상기 충전 사이클 조건에 따른 상기 배터리의 용량에 대한 정보를 수집한다.
- [0015] 또한, 상기 수집하는 단계는, 기설정된 충전 사이클 횟수마다 RPT(reference performance test)를 수행하는 단계; 상기 RPT 결과를 기초로 OCV-SOC LUT(Lookup table)을 획득하는 단계;를 더 포함하고, 상기 제1 계산식은 충전율, 방전율, 사이클 별 배터리의 최대 최소 SOC(state of charge) 및 온도를 기초로 중복 조합을 수행하여 상대적 용량변화 값을 계산하는 것이고, 상기 제1 계산식을 최적화하는 단계는 상기 OCV-SOC LUT를 기초로 상기 사이클 별 배터리의 최대 최소 SOC(state of charge)를 결정한다.
- [0016] 또한, 상기 최적화하는 단계는, 상기 제1 계산식을 기초로 획득한 제1 상대적 용량 손실량과 상기 제1 데이터를 기초로 획득한 제2 상대적 용량 손실량 간의 오차가 최소가 되도록 하는 상기 제1 계산식의 파라미터를 획득하는 단계; 및 상기 파라미터를 기초로 상기 제1 계산식을 업데이트하는 단계;를 더 포함한다.
- [0017] 전술한 것 외의 다른 측면, 특징, 이점은 이하의 발명을 실시하기 위한 구체적인 내용, 청구범위 및 도면으로부터 명확해질 것이다.

발명의 효과

- [0018] 상기한 바와 같이 이루어진 본 발명의 일 실시예에 따르면, 종래의 물리적 모델 기반의 방법과 달리 본 알고리즘은 미분 방정식이 없는 간단한 수식으로 전개가 가능하여 계산 시간이 오래 걸리지 않는다는 효과가 있다.
- [0019] 또한 본 발명의 일 실시예에 따르면, 종래의 경험적 모델들과 달리 모든 배터리의 전류, SOC 및 온도에 따라 노화되는 속도가 다르다는 공통된 경험적 원리를 적용하고 노화되는 속도의 함수(ADF)를 복수의 파라미터들로 튜닝이 가능한 다항식으로 묶으로써, 다양한 종류의 배터리에 맞게 모델링이 가능할 수 있다는 효과가 있다.
- [0020] 또한 본 발명의 일 실시예에 따르면 최적화 해야할 파라미터 개수가 종래의 데이터 기반 방법과 물리적 모델 기반의 방법에서 쓰이는 파라미터 개수보다 현저히 적은 데이터만으로도 예측이 가능하기 때문에, 시간 및 비용의 소모를 줄일 수 있다는 효과가 있다.
- [0021] 또한, 본 발명의 일 실시예에 따르면 최종적으로 인공지능 모델을 사용함으로써 예측값뿐만 아니라 예측의 신뢰

도를 향상시킬 수 있다.

- [0022] 또한, 본 발명의 일 실시예에 따르면 배터리의 충전율, 방전율과 같은 C-rate, 배터리의 SOC 구간, 배터리의 온도 구간을 고려하여 배터리의 노화의 진행여부에 관한 정보를 획득할 수 있고, 이를 이용한 배터리 구동을 통해 배터리의 수명을 늘일 수 있다는 효과가 있다.
- [0023] 또한, 본 발명의 일 실시예에 따르면, 기존의 데이터를 활용하여 사용자에게 해당 조건에 대한 결과를 직접 실험을 하지 않고도 예측할 수 있으므로, 배터리 평가 테스트 비용도 감소한다는 효과가 있다.
- [0024] 물론 이러한 효과에 의해 본 발명의 범위가 한정되는 것은 아니다.

도면의 간단한 설명

- [0025] 도 1은 본 발명의 일 실시예에 따른 배터리의 용량 변화 예측 시스템을 설명하기 위한 간략한 시스템도이다.
- 도 2는 본 발명의 일 실시예에 따른 예측 시스템의 배터리의 충방전 사이클에 따른 용량 변화 예측방법을 설명하기 위한 흐름도이다.
- 도 3은 본 발명의 일 실시예에 따른 예측 시스템이 실험 데이터 획득을 위한 배터리 충방전 사이클을 도시한 것이다.
- 도 4는 본 발명의 일 실시예에 따른 RPT 실험을 설명하기 위한 도면이다.
- 도 5a 및 도 5b는 단위 시간당 변하는 상대적 용량 손실 변화량을 도시하는 그래프이다.

발명을 실시하기 위한 구체적인 내용

- [0026] 이하, 본 개시의 다양한 실시예가 첨부된 도면과 연관되어 기재된다. 본 개시의 다양한 실시예는 다양한 변경을 가할 수 있고 여러 가지 실시예를 가질 수 있는 바, 특정 실시예들이 도면에 예시되고 관련된 상세한 설명이 기재되어 있다. 그러나 이는 본 개시의 다양한 실시예를 특정한 실시 형태에 대해 한정하려는 것이 아니며, 본 개시의 다양한 실시예의 사상 및 기술 범위에 포함되는 모든 변경 및/또는 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다. 도면의 설명과 관련하여, 유사한 구성요소에 대해서는 유사한 참조 부호가 사용되었다.
- [0027] 본 개시의 다양한 실시예에서 사용될 수 있는 "포함한다." 또는 "포함할 수 있다." 등의 표현은 개시 (disclosure)된 해당 기능, 동작 또는 구성요소 등의 존재를 가리키며, 추가적인 하나 이상의 기능, 동작 또는 구성요소 등을 제한하지 않는다. 또한, 본 개시의 다양한 실시예에서, "포함하다." 또는 "가지다." 등의 용어는 명세서상에 기재된 특징, 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것이 존재함을 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.
- [0028] 본 개시의 다양한 실시예에서 "또는" 등의 표현은 함께 나열된 단어들의 어떠한, 그리고 모든 조합을 포함한다. 예를 들어, "A 또는 B"는, A를 포함할 수도, B를 포함할 수도, 또는 A 와 B 모두를 포함할 수도 있다.
- [0029] 본 개시의 다양한 실시예에서 사용된 "제1", "제2", "첫째", 또는 "둘째" 등의 표현들은 다양한 실시예들의 다양한 구성요소들을 수식할 수 있지만, 해당 구성요소들을 한정하지 않는다. 예를 들어, 상기 표현들은 해당 구성요소들의 순서 및/또는 중요도 등을 한정하지 않는다. 상기 표현들은 한 구성요소를 다른 구성요소와 구분하기 위해 사용될 수 있다. 예를 들어, 제1 사용자 기기와 제2 사용자 기기는 모두 사용자 기기이며, 서로 다른 사용자 기기를 나타낸다. 예를 들어, 본 개시의 다양한 실시예의 권리 범위를 벗어나지 않으면서 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소도 제1 구성요소로 명명될 수 있다.
- [0030] 어떤 구성요소가 다른 구성요소에 "연결되어" 있다거나 "접속되어" 있다고 언급된 때에는, 상기 어떤 구성요소가 상기 다른 구성요소에 직접적으로 연결되어 있거나 또는 접속되어 있을 수도 있지만, 상기 어떤 구성요소와 상기 다른 구성요소 사이에 새로운 다른 구성요소가 존재할 수도 있다고 이해되어야 할 것이다. 반면에, 어떤 구성요소가 다른 구성요소에 "직접 연결되어" 있다거나 "직접 접속되어" 있다고 언급된 때에는, 상기 어떤 구성요소와 상기 다른 구성요소 사이에 새로운 다른 구성요소가 존재하지 않는 것으로 이해될 수 있어야 할 것이다.
- [0031] 본 개시의 실시 예에서 "모듈", "유닛", "부(part)" 등과 같은 용어는 적어도 하나의 기능이나 동작을 수행하는 구성요소를 지칭하기 위한 용어이며, 이러한 구성요소는 하드웨어 또는 소프트웨어로 구현되거나 하드웨어 및 소프트웨어의 결합으로 구현될 수 있다. 또한, 복수의 "모듈", "유닛", "부(part)" 등은 각각 개별적인 특정

한 하드웨어로 구현될 필요가 있는 경우를 제외하고는, 적어도 하나의 모듈이나 칩으로 일체화되어 적어도 하나의 프로세서로 구현될 수 있다.

- [0032] 본 개시의 다양한 실시예에서 사용한 용어는 단지 특정일 실시예를 설명하기 위해 사용된 것으로, 본 개시의 다양한 실시예를 한정하려는 의도가 아니다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다.
- [0033] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 본 개시의 다양한 실시예가 속하는 기술 분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 가지고 있다.
- [0034] 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥상 가지는 의미와 일치하는 의미를 가지는 것으로 해석되어야 하며, 본 개시의 다양한 실시예에서 명백하게 정의되지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.
- [0035] 이하에서, 첨부된 도면을 이용하여 본 발명의 다양한 실시 예들에 대하여 구체적으로 설명한다.
- [0036] 도 1은 본 발명의 일 실시예에 따른 배터리의 용량 변화 예측 시스템을 설명하기 위한 간략한 시스템도이다.
- [0037] 도 1을 참조하면, 본 발명의 배터리의 용량 변화 예측 시스템(10)은 ADFM 관리 장치(100)와 서버(110)를 포함할 수 있다.
- [0038] 본 발명의 배터리의 용량 변화 예측 과정은 크게 두 가지로 과정으로 구분될 수 있다. 첫 번째 과정은, ADFM 관리 장치(100)에 의해, 배터리의 충전 방전 사이클에 대한 실험 데이터를 수집하고, 이를 통해 본 발명의 ADFM(Aging Density Function Model)의 파라미터를 최적화(Optimization)하는 과정일 수 있다.
- [0039] 두 번째 과정은, 서버(110)에 의해, 최적화된 ADFM으로 가상 데이터를 생성하고, 실험 데이터와 가상 데이터를 학습 데이터로 BNN(Bayesian Neural Network)을 학습시켜서 BNN을 용량 변화 예측에 활용하는 과정일 수 있다.
- [0040] 구체적으로, ADFM 관리 장치(100)는 실험 데이터 수집부(101), 전처리부(102), ADF 최적화부(103) 및 가상 데이터 생성부(104)를 포함할 수 있다.
- [0041] 실험 데이터 수집부(101)는 복수의 충전 사이클 횟수 및 충전 사이클 조건에 따른 배터리의 용량에 대한 적어도 하나의 실험 데이터 또는 제1 데이터를 수집하기 위한 구성이다. 실험 데이터 수집부(101)는 기정의된 사이클을 기초로 반복적인 사이클 실험을 통해 생성되는 결과를 실험 데이터로 획득할 수 있다. 즉, 배터리에 대한 실험 데이터는 반복적인 충전 사이클 실험을 통해 획득할 수 있다.
- [0042] 본 발명의 일 실시예에 따른 실험데이터 수집부(101)는 기설정된 횟수의 충전 사이클 마다 RPT (Reference performance test) 실험이 수행된 데이터를 획득할 수 있다. 이때, RPT는 SOC(State of charge)가 0%로 정의되는 전압(V_{min})에서 SOC가 100%로 정의 되는 전압(V_{max})에 도달할 때까지 0.01 C-rate 이하의 일정한 전류로 지속적으로 충전 실험을 하는 것을 의미한다. RPT를 수행하는 이유는 배터리의 변하는 용량을 측정하기 위함이다.
- [0043] 전처리부(102)는 수집한 실험 데이터를 전처리하기 위한 구성이다. 이때, 전처리는 획득한 실험 데이터를 기초로 본 발명의 ADFM(Aging density function Model)을 최적화하기 위한 형태로 변환하는 것을 의미할 수 있다.
- [0044] 한편, 전처리부(102)는 RPT 실험을 수행하는 동안의 전류 값에 대한 데이터를 시간에 대하여 적분하여 용량 값(mAh)을 획득할 수 있다. 또한 0.01 C-rate 이하의 일정한 전류로 지속적으로 방전하는 실험을 통해 획득한 데이터를 기초로 OCV-SOC LUT(lookup table)를 획득할 수 있다.
- [0045] ADF 최적화부(103)는 본 발명의 ADF(Aging density function)에 포함된 파라미터를 최적화하기 위한 구성이다. 이때, ADF는 충전 사이클 횟수 및 충전 사이클 조건을 입력으로 받으면, 해당 사이클 횟수에서의 배터리의 상대적인 용량 변화 값을 출력하는 모델일 수 있다.
- [0046] ADF의 인자는 전류의 C-rate, SOC (State of charge), 온도(T)를 포함할 수 있고, 함수 값은 노화 밀도(Aging density)일 수 있다. 이때, 노화 밀도는 단위 시간당 변하는 상대적인 용량(Relative capacity)의 변화량을 의미할 수 있다.
- [0047] 가상 데이터 생성부(104)는 최적화된 ADFM을 이용하여 가상 데이터를 생성하기 위한 구성이다. 이때, 가상 데이

터는 임의의 충전 사이클 횟수 및 임의의 충전 사이클 조건에 대응하는 노화 밀도에 대한 데이터일 수 있다.

- [0048] 본 발명의 일 실시예에 따른 서버(110)는 학습부(111) 및 예측부(112)를 포함할 수 있다. 이때, 서버(110)는 인공지능 모델을 저장하고, 이를 학습시키며, 인공지능 모델을 통해 배터리의 용량 변화를 예측하기 위한 서버(110)일 수 있다.
- [0049] 본 발명의 일 실시예에 따르면, 서버(110)는 하나의 서버로 구현될 수 있고, 일 실시예에 따르면 복수의 서버로 구현될 수 있다. 예를 들면, 서버(110)는 실험 데이터 및 가상 데이터를 저장하는 데이터베이스 서버, BNN과 같은 인공지능 모델을 저장하고 학습시키는 서버, 인공지능을 통해 예측한 데이터 값을 통계화하여 저장하는 통계 서버 등 복수의 서버로 구현될 수 있다.
- [0050] 한편, 학습부(111)는 본 발명의 실험 데이터 및 가상 데이터를 학습 데이터로 하여 인공지능 모델을 학습시키기 위한 구성일 수 있다. 이때, 인공지능 모델은 CNN 모델, RNN 모델, LSTM 모델 등을 통한 딥러닝(Deep Learning) 모델일 수 있다. 다만, 이는 일 실시예에 불과할 뿐, 다른 모델로도 구현될 수 있다.
- [0051] 예측부(112)는 본 발명의 학습된 인공지능 모델을 이용하여 배터리 용량 변화에 대한 예측 값을 획득할 수 있다. 본 발명의 일 실시예에 따르면, 예측부(112)는 임의의 충전 사이클 횟수 및 임의의 충전 사이클 조건을 학습된 인공지능 모델에 입력하면, 해당하는 충전 사이클 횟수 및 충전 사이클 조건에 대응되는 상대적 용량 변화 값을 출력할 수 있다.
- [0052] 도 1에서는 ADFM 관리 장치(100)와 서버(110)가 별도의 구성으로 구현된 것을 도시하였으나, 본 발명의 또 다른 실시예에 따르면 하나의 구성으로 구현될 수 있다. 예를 들어, ADFM 관리 장치(100)는 서버(110)가 수행하는 모든 프로세스를 수행할 수 있다.
- [0053] 본 발명의 일 실시예에 따르면 실험데이터 수집부(101), 전처리부(102), ADF 최적화부(103) 및 가상데이터 생성부(104)는 프로세서(미도시)에 의해 구동되는 별도의 소프트웨어 모듈을 통해 구현될 수 있다. 소프트웨어 모듈들 각각은 본 명세서에서 설명되는 하나 이상의 기능 및 동작을 수행할 수 있다. 또한, 각각의 구성은 별도의 모듈로 구현될 수도 있고, 하나의 모듈로 구현된 것일 수도 있다.
- [0054] 도 2는 본 발명의 일 실시예에 따른 예측 시스템의 배터리의 충전 사이클에 따른 용량 변화 예측방법을 설명하기 위한 흐름도이다.
- [0055] 도 2를 참조하면, 본 발명의 예측 시스템(10)은 충전 사이클 횟수 및 충전 조건에 따른 배터리 용량에 대한 실험 데이터 또는 제1 데이터를 수집할 수 있다(S110).
- [0056] 이때, 실험 데이터는 기정의된 사이클을 기초로 반복적인 사이클 실험을 통해 생성되는 결과를 실험 데이터로 획득할 수 있다. 즉, 배터리에 대한 실험 데이터는 반복적인 충전 사이클 실험을 통해 획득할 수 있다.
- [0057] 구체적으로, 본 발명의 일 실시예에 따른 기정의된 사이클은 정전류(constant current, CC) 충전 구간, 정전압(constant voltage, CV) 충전 구간, 제1 휴지 구간, 정전류 방전 구간 및 제2 휴지 구간을 포함할 수 있다. 이 순서대로 진행되는 하나의 과정을 하나의 충전 사이클로 정의한다.
- [0058] 이때, 정전류(constant current, CC) 충전 구간은 정전류를 통해 충전하는 구간이고, 정전압(constant voltage, CV) 충전 구간은 상단 절단 전압(upper cut-off voltage)에 도달하면 정전압(constant voltage, CV)을 충전하는 구간, 제1 휴지 구간은 절단전류(cut-off current)에 도달하면 전류를 인가하지 않는(rest) 구간, 정전류 방전 구간은 정전류를 통해 방전하는 구간, 제2 휴지 구간은 하단 절단 전압(lower cut-off voltage)에 도달하면 전류를 인가하지 않는 구간일 수 있다.
- [0059] 한편, 본 발명의 예측 시스템(10)은 기설정된 횟수의 충전 사이클 마다 RPT(Reference performance test) 실험이 수행된 데이터를 획득할 수 있다. 이때, RPT는 SOC(State of charge)가 0%로 정의 되는 전압(V_{min})에서 SOC가 100%로 정의 되는 전압(V_{max})에 도달할 때까지 0.01 C-rate 이하의 일정한 전류로 지속적으로 충전 실험을 하는 것을 의미한다. RPT를 수행하는 이유는 배터리의 변하는 용량을 측정하기 위함이다.
- [0060] 본 발명의 예측 시스템(10)은 RPT 실험 동안 측정되는 전류 값을 시간에 대하여 적분하여 용량 값(mAh)을 획득할 수 있다. 또한 0.01 C-rate 이하의 일정한 전류로 지속적으로 방전하는 실험을 통해 획득한 데이터를 기초로 OCV-SOC LUT(lookup table)를 획득할 수 있다.

[0061] 본 발명의 예측 시스템(10)은 배터리 충방전 사이클 실험을 통해 얻은 데이터 및 OCV-SOC LUT 등을 기초로 ADFM의 파라미터를 최적화할 수 있다(S220).

[0062] 이때, ADF는 충방전 사이클 횟수 및 충방전 사이클 조건을 입력으로 받으면, 해당 사이클 횟수에서의 배터리의 단위시간 당 상대적인 용량 변화 값을 출력하는 모델일 수 있다. 구체적으로, 본 발명에서는 ADF를 n차 다항식으로 가정하였다. 만약 3차 다항식으로 설정한다면 ADF는 아래 수학적 식 1과 같이 표현할 수 있다.

수학적 식 1

[0063]
$$ADF(x) = \sum_{m=1}^{2H_3} \sum_{(i,j,k) \in CR(3,3)} \alpha_{3,m} x_i x_j x_k + \sum_{m=1}^{2H_2} \sum_{(i,j) \in CR(3,2)} \alpha_{2,m} x_i x_j + \sum_{m=1}^{2H_1} \sum_{(i,j) \in CR(3,1)} \alpha_{1,m} x_i + \alpha_0$$

[0064] 이때, CR(m,n)은 1,2,3,...,m의 자연수 중에서 n개를 중복으로 뽑을 수 있는 조합, 즉 중복조합의 집합일 수 있다. CR(m,n) 집합 원소의 개수는 ${}^m H_n = {}^{m+n-1} C_n$ 개가 될 수 있다. 예를 들어, CR(3,3) = {(1,1,2), (2,2,2), (1,3,3), (1,1,1),...}가 되며 총 ${}^3 H_3 = 10$ 개의 원소를 가지는 집합일 수 있다.

[0065] ADF는 인자로써 전류의 C-rate, SOC (State of charge), 온도(T)를 포함할 수 있고, 함수 값은 노화 밀도(Aging density)일 수 있다. 이때, 노화 밀도(Aging density)는 단위 시간당 상대적인 용량(Relative capacity)의 변화량을 의미할 수 있다.

[0066] 예측 시스템(10)은 ADFM(Aging Density Function Model)을 구현하기 위해, ADF를 통해 획득한 단위 시간당 상대적인 용량 변화량을 시간에 대하여 적분하여, 상대적 용량 변화량을 획득할 수 있다. 이를 수식으로 나타내면 아래 수학적 식 2와 같다.

수학적 식 2

[0067]
$$\text{상대적 용량 변화량} = -\Delta \left(\frac{\text{Cap}}{\text{Cap}_{\text{fresh}}} \right) = \frac{\text{Cap}(t_1) - \text{Cap}(t_2)}{\text{Cap}_{\text{fresh}}} = \int_{t_1}^{t_2} ADF(C\text{-rate}, SOC, T) dt$$

[0068] 수학적 식 2는 시간 t_1 에서 t_2 까지의 상대적 용량 변화량(Relative capacity loss)을 나타낸 것이다. 이때, Cap_{fresh}는 충방전 사이클을 하나도 겪지 않은 이차 전지의 용량 값을 나타낸 것이다.

[0069] 한편, n번째 사이클 직후의 상대적 용량 손실량(Relative capacity loss) 값을 C(n)이라고 하면, ADF의 정의를 이용하여 각 사이클의 최소 SOC 값, 최대 SOC 값을 OCV-SOC LUT(lookup table) 매핑을 통해 제1 상대적 용량 손실량을 구하기 위한 수학적 식 3을 전개할 수 있다. 이때, 제1 상대적 용량 손실량은 ADF의 정의를 이용해 수학적 식으로 계산된 상대적 용량 손실량이다.

수학적 식 3

[0070]
$$C(n, \theta, Q) = -\frac{B}{A} (1 - (A + 1)^n)$$

[0071] 이때, A와 B는 ADF의 파라미터들 $\theta = (\alpha_0, \alpha_{1,1 \sim 2H_1}, \alpha_{2,1 \sim 2H_2}, \alpha_{3,1 \sim 2H_3})$ 및 충방전 사이클 조건 Q = (C-rate 1, C-rate 2, Cut-off voltage 1, Cut-off voltage 2, Rest time)의 함수일 수 있다.

[0072] 수학적 식 3에서는 절단 전압을 최대 SOC 및 최소 SOC라고 가정하고, 한 사이클에서의 용량 값은 해당 사이클에서는 상수인 것을 가정한 것이다.

[0073] 한편, 예측 시스템(10)은 획득한 실험 데이터를 통해서 실제 배터리의 충방전사이클의 제2 상대적 용량 손실량(Relative capacity loss)을 획득할 수 있다. 이때, 제2 상대적 용량 손실량은 실제 실험 데이터를 통해 획득한 정보를 이용하여 계산된 상대적 용량 손실량이다.

[0074] 실제 배터리의 제2 상대적 용량 손실은 수학적 식 4를 통해 계산할 수 있다.

수학적 식 4

$$\text{상대적 용량 손실량} = C = 1 - \frac{Cap}{Cap_{fresh}}$$

[0075]

[0076] 이때, $C_k(n)$ 은 k번째 데이터에서 n번째 사이클에서의 상대적 용량 손실 값이라고 할 수 있다. 예를 들어, Cap_{fresh} 의 용량이 2000mAh이고, 100회 사이클을 수행한 이후 용량이 1900mAh인 경우를 가정하면, 1번째 데이터에

서 0회 사이클을 수행한 배터리의 상대적 용량 손실값은 $C_1(0) = 1 - \frac{2000}{2000} = 0$ 이고, 1번째 데이터에서 100회 사

이클을 수행한 배터리의 상대적 용량 손실값은 $C_1(100) = 1 - \frac{1900}{2000} = 0.05$ 가 된다.

[0077] 한편, 본 발명의 예측 시스템(10)은 제1 상대적 용량 손실량과 제2 상대적 용량 손실량을 기초로 ADF의 파라미터를 최적화할 수 있다. 구체적으로 예측 시스템(10)은 Levenberg-Marquardt algorithm (LMA)를 통해 용량 손실값 차이의 제곱의 합 오차를 구할 수 있다.

수학적 식 5

$$\theta^* = \operatorname{argmin}_{\theta} \sum_{i=1}^M \sum_{j=1}^{N_i} [C(n_j, \theta, Q_i) - c_i(n_j)]^2$$

[0078]

[0079] 수학적 식 5의 M은 데이터 개수를 말하는 것이고, N_i 는 i번째 데이터에서 용량을 측정된 회수를 말한다. n_j 는 j번째로 용량을 측정했을 때까지 수행한 충방전 사이클 회수를 말한다.

[0080] 본 발명의 예측 시스템(10)은 수학적 식 5와 같은 Levenberg-Marquardt algorithm (LMA)를 이용하여 용량 손실값 제곱의 합 오차를 최소화 하는 θ^* 를 획득할 수 있다. 즉, 예측 시스템(10)은 상술한 θ^* , 즉 최적화 파라미터를 기초로 ADF를 업데이트할 수 있다.

[0081] 예측 시스템(10)은 획득한 θ^* 값을 이용하여 업데이트한 수학적 식 3의 ADFM을 이용해 다양한 사이클 조건을 설정하여 가상의 데이터를 생성하고(S230), 이를 실험데이터와 함께 훈련 데이터(training data)로 지정하여 인공지능 모델을 학습시킬 수 있다(S240).

[0082] 본 발명의 일 실시예에 따르면 예측 시스템(10)은 가상의 데이터가 과도하게 많은 경우 실험 데이터의 인공지능 모델 학습에 대한 영향력이 현저히 감소할 수 있으므로, 실험 데이터와 가상의 데이터가 동등한 비율로 학습에 참여 할 수 있도록 제어할 수 있다. 예를 들면, 예측 시스템(10)은 가상의 데이터가 10000개이고 실험데이터가 10개 이면 개수가 1000배가 차이 나므로 가상의 데이터 1회 학습 당 실험 데이터는 1000회 학습을 수행할 수 있다.

[0083] 한편, 본 발명의 예측 시스템(10)은 학습된 인공지능 모델을 이용하여, 배터리의 충전율, 방전율과 같은 C-rate, 배터리의 SOC 구간, 배터리의 온도 구간을 고려하여 배터리의 노화의 진행여부에 관한 정보를 획득할 수 있고, 배터리의 상대적 용량 변화 예측값을 획득할 수 있다(S250).

[0084] 본 발명에 따르면, 사용자가 특정 조건에 대한 결과를 직접 실험을 하지 않고도 인공지능 모델을 사용함으로써 높은 신뢰도로 효율적인 배터리 용량 예측값을 획득할 수 있다.

[0085] 도 3은 본 발명의 일 실시예에 따른 예측 시스템이 실험 데이터 획득을 위한 배터리 충방전 사이클을 도시한 것

이다.

- [0086] 예측 시스템(10)은 기정의된 사이클을 기초로 반복적인 사이클 실험을 통해 생성되는 결과를 실험 데이터로 획득할 수 있다. 즉, 배터리에 대한 실험 데이터는 반복적인 충전 사이클 실험을 통해 획득할 수 있다.
- [0087] 구체적으로, 본 발명의 일 실시예에 따른 기정의된 사이클은 정전류(constant current, CC) 충전 구간, 정전압(constant voltage, CV) 충전 구간, 제1 휴지 구간, 정전류 방전 구간 및 제2 휴지 구간을 포함할 수 있다. 이 순서대로 진행되는 하나의 과정을 하나의 충전 사이클로 정의한다.
- [0088] 이때, 정전류(constant current, CC) 충전 구간은 정전류를 통해 충전하는 구간이고, 정전압(constant voltage, CV) 충전 구간은 상단 절단 전압(upper cut-off voltage)에 도달하면 정전압(constant voltage, CV)을 충전하는 구간, 제1 휴지 구간은 절단전류(cut-off current)에 도달하면 전류를 인가하지 않는(rest) 구간, 정전류 방전 구간은 정전류를 통해 방전하는 구간, 제2 휴지 구간은 하단 절단 전압(lower cut-off voltage)에 도달하면 전류를 인가하지 않는 구간일 수 있다. 이때, 제1 휴지 구간과 제2 휴지 구간은 서로 동일한 기간일 수 있다.
- [0089] 도 4는 본 발명의 일 실시예에 따른 RPT 실험을 설명하기 위한 도면이다.
- [0090] 본 발명의 일 실시예에 따른 예측 시스템(10)은 기설정된 횟수의 충전 사이클 마다 RPT (Reference performance test) 실험이 수행된 데이터를 획득할 수 있다. 이때, RPT는 SOC(State of charge)가 0%로 정의되는 전압(V_{min})에서 SOC가 100%로 정의되는 전압(V_{max})에 도달할 때까지 0.01 C-rate 이하의 일정한 전류로 지속적으로 충전 실험을 하는 것을 의미한다. RPT를 수행하는 이유는 배터리의 변하는 용량을 측정하기 위함이다.
- [0091] 한편, 예측 시스템(10)은 RPT 실험을 수행하는 동안의 전류 값에 대한 데이터를 시간에 대하여 적분하여 용량 값(mAh)을 획득할 수 있다. 또한 0.01 C-rate 이하의 일정한 전류로 지속적으로 방전하는 실험을 통해 획득한 데이터를 기초로 OCV-SOC LUT(lookup table)를 획득할 수 있다.
- [0092] 즉, OCV-SOC 그래프는 가로축에 SOC(State of Charge), 세로축에 전지의 OCV(개방 상태에서의 단자 전압: 전류가 걸리지 않은 때의 전압)으로 나타낼 수 있다. 도 4와 같은 OCV-SOC 그래프를 이용하면, 전지의 개방 전압을 측정함에 따라 대략의 SOC를 추정할 수 있다.
- [0093] 도 5a 및 도 5b는 단위 시간당 변하는 상대적 용량 손실 변화량을 도시하는 그래프이다.
- [0094] 특히, 도 5a 및 도 5b는 C-rate 조건에 따라 변경되는 단위 시간당 변하는 상대적 용량 손실 변화량, 즉 노화 밀도 예측 값을 예시적으로 도시한다.
- [0095] 도 5a를 참조하면, 3차원 그래프의 X축은 C-rate(1/h)를 나타내고, Y축은 SOC(%)를 나타내고, Z축은 단위시간당 상대적 용량 변화량, 노화 밀도(1/s)를 나타낸다. 즉, 도 5a를 통해 현재 배터리의 충전전시 C-rate에 대응하는 SOC 별 노화 밀도에 대한 예측 값을 획득할 수 있다.
- [0096] 도 5b는 도 5a의 그래프를 2차원으로 도시한 것이다. 도 5b의 X축은 C-rate(1/h)를 나타내고, Y축은 SOC(%)를 나타낸다. 특히, X값, Y값의 교차점에 해당하는 부분에는 이에 대응하는 단위시간 당 상대적 용량 변화량, 노화 밀도(1/s) 값이 등고선 및 색상의 변화로 표현되어 있다.
- [0097] 도 5b를 참조하면, C-rate 값이 0 및 SOC 값이 28%일 때, 배터리의 노화 밀도가 최소가 되는 것을 확인할 수 있다.
- [0098] 즉, 도 5a 및 5b를 이용하여, 배터리의 노화 밀도가 최소가 되는 C-rate 조건에 대한 정보를 획득할 수 있고, 이에 따라 최적의 배터리 사용 모델링이 가능하다.
- [0099] 더불어 사이클 충전전 데이터를 이용하여 최적의 ADF 튜닝을 통해 배터리 사용의 전류 조건, SOC 구간 및 온도 구간에서의 구동에 따른 노화 예측 값 정보를 획득할 수 있다. 상술한 정보를 이용하면 배터리를 구동하면, 배터리의 수명을 늘여줄 수 있다는 효과가 있다.
- [0100] 이와 같이 본 발명은 도면에 도시된 실시예를 참고로 설명되었으나 이는 예시적인 것에 불과하며, 당해 기술분야에서 통상의 지식을 가진 자라면 이로부터 다양한 변형 및 균등한 다른 실시예가 가능하다는 점을 이해할 것이다. 따라서 본 발명의 진정한 기술적 보호 범위는 첨부된 청구범위의 기술적 사상에 의하여 정해져야 할 것이다.

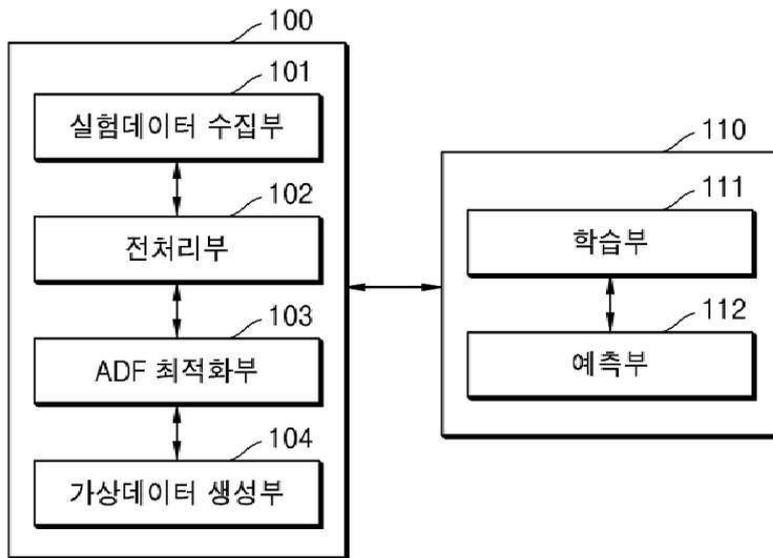
부호의 설명

- [0101] 100: ADFM 관리 장치
- 101: 실험데이터 수집부
- 102: 전처리부
- 103: ADF 최적화부
- 104: 가상데이터 생성부
- 110: 서버
- 111: 학습부
- 112: 예측부

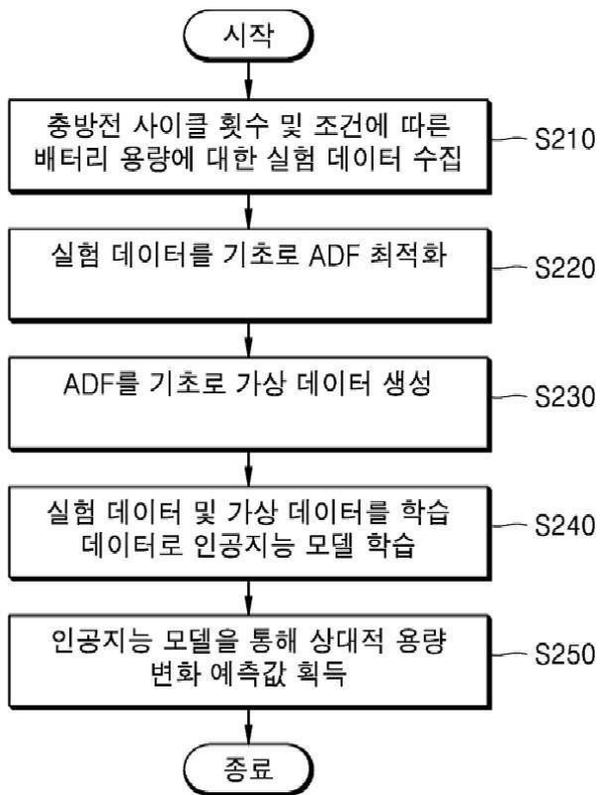
도면

도면1

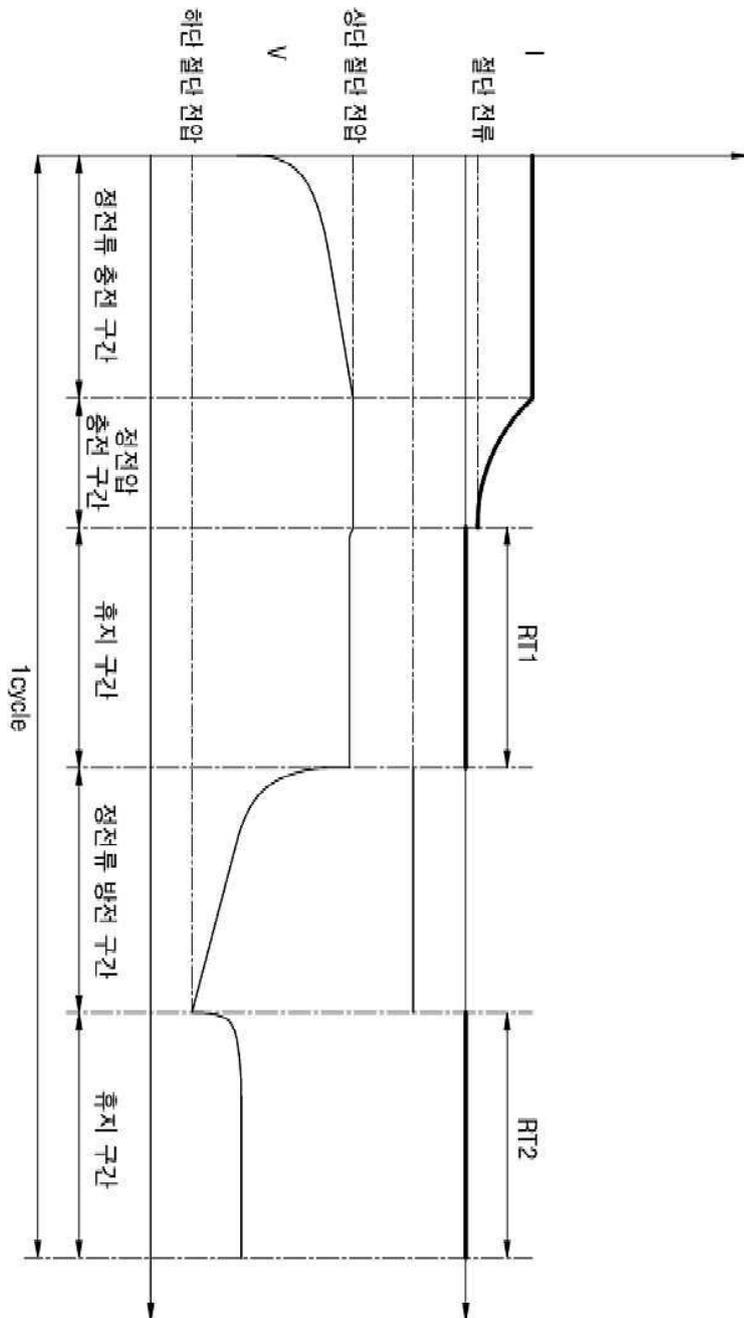
10



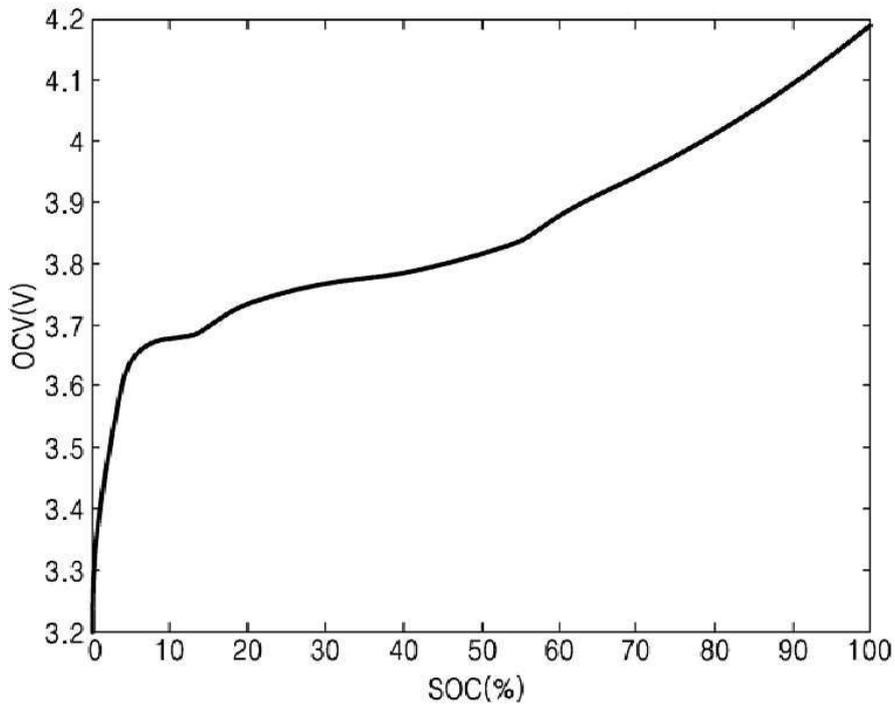
도면2



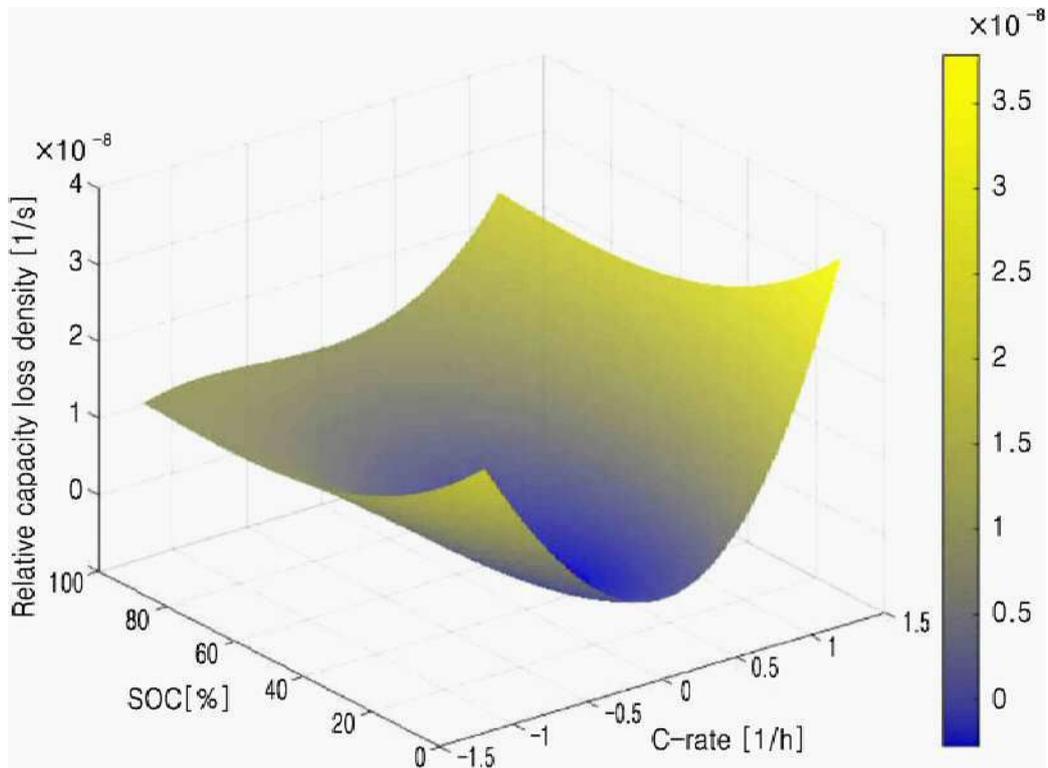
도면3



도면4



도면5a



도면5b

