



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2022-0099415
(43) 공개일자 2022년07월13일

(51) 국제특허분류(Int. Cl.)
H02J 7/00 (2006.01) G01R 31/382 (2019.01)
G06N 3/08 (2006.01)
(52) CPC특허분류
H02J 7/0071 (2020.01)
G01R 31/382 (2019.01)
(21) 출원번호 10-2021-0001620
(22) 출원일자 2021년01월06일
심사청구일자 2021년01월06일

(71) 출원인
연세대학교 산학협력단
서울특별시 서대문구 연세로 50 (신촌동, 연세대학교)
(72) 발명자
신용준
서울특별시 서대문구 연세로 50, 제3공학관 C511호(신촌동, 연세대학교)
김선희
서울특별시 서대문구 연세로 50, 제2공학관 B729호(신촌동, 연세대학교)
임수향
서울특별시 서대문구 연세로 50, 제2공학관 B729호(신촌동, 연세대학교)
(74) 대리인
특허법인우인

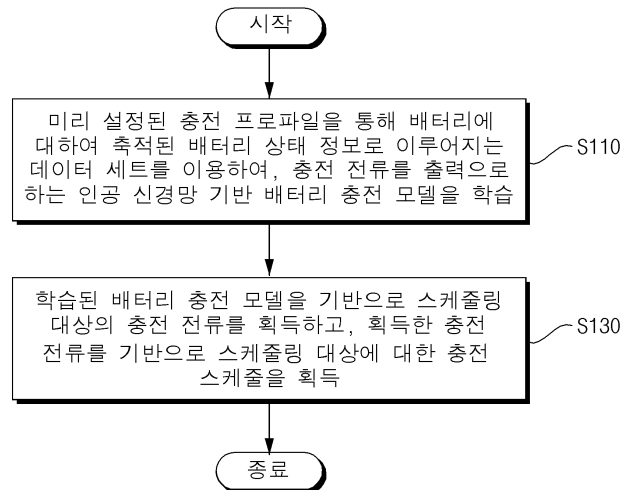
전체 청구항 수 : 총 5 항

(54) 발명의 명칭 **인공 신경망 기반 배터리 고속 충전 효율 향상 장치 및 방법**

(57) 요약

본 발명의 바람직한 실시예에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 장치 및 방법은, 충전 프로파일 등을 통한 배터리의 충전 상태를 지속적으로 관찰하여 축적된 데이터로부터 추출된 배터리 특징을 이용하여 인공 신경망 기반의 배터리 충전 모델을 학습하고, 학습한 배터리 충전 모델을 기반으로 배터리의 충전 스케줄을 획득함으로써, 종래의 CC-CV 충전 방법보다 충전 시간을 단축할 수 있고, 종래의 BC 충전 방법보다 더 빠르고 안전하게 충전이 가능하다.

대표도 - 도11



(52) CPC특허분류

G06N 3/08 (2013.01)

H02J 7/0047 (2013.01)

H02J 7/00712 (2020.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711110384
과제번호	2020R1A2B5B03001692
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	중견연구자지원사업
연구과제명	수퍼 그리드 구현을 위한 차세대 전력망 진단 및 모니터링 기술 개발(1/3)
기 여 율	1/1
과제수행기관명	연세대학교 산학협력단
연구기간	2020.03.01 ~ 2021.02.28

명세서

청구범위

청구항 1

미리 설정된 충전 프로파일을 통해 배터리에 대하여 축적된 배터리 상태 정보로 이루어지는 데이터 세트를 이용하여, 충전 전류를 출력으로 하는 인공 신경망 기반 배터리 충전 모델을 학습하는 학습부; 및

상기 학습부를 통해 학습된 상기 배터리 충전 모델을 기반으로 스케줄링 대상의 충전 전류를 획득하고, 획득한 충전 전류를 기반으로 상기 스케줄링 대상에 대한 충전 스케줄을 획득하는 스케줄링부;

를 포함하며,

상기 배터리 상태 정보는,

충전 전류(charging current), 배터리 전압(battery voltage) 및 배터리 온도(battery temperature)를 포함하는,

인공 신경망 기반 배터리 고속 충전 효율 향상 장치.

청구항 2

제1항에서,

상기 학습부는,

상기 배터리 상태 정보를 정규화(normalization)하고, 정규화된 상기 배터리 상태 정보에서 배터리 특징을 추출하며, 추출된 상기 배터리 특징으로 이루어지는 상기 데이터 세트를 획득하며,

상기 배터리 특징은,

충전 전류(charging current), 배터리 전압(battery voltage), 배터리 온도 증가(battery temperature increment) 및 배터리 온도 미분 계수(battery temperature differential coefficient)를 포함하는,

인공 신경망 기반 배터리 고속 충전 효율 향상 장치.

청구항 3

제2항에서,

상기 학습부는,

상기 데이터 세트를 학습 데이터 세트와 테스트 데이터 세트로 분할하고, 상기 학습 데이터 세트를 훈련 데이터 세트와 검증 데이터 세트로 분할하며, 상기 훈련 데이터 세트를 이용하여 상기 배터리 충전 모델을 구축하고, 구축된 상기 배터리 충전 모델의 오버피팅(overfitting)을 최소화하는 에포치(epoch)를 상기 검증 데이터 세트를 이용하여 K-fold 교차 검증(cross validation, CV)을 통해 획득하고, 획득한 에포치(epoch)를 기반으로 상기 배터리 충전 모델을 최적화하고, 최적화된 상기 배터리 충전 모델을 상기 테스트 데이터 세트를 이용하여 테스트하여, 상기 배터리 충전 모델을 학습하는,

인공 신경망 기반 배터리 고속 충전 효율 향상 장치.

청구항 4

제1항에서,

상기 배터리 충전 모델은,

순방향 신경망(Feedforward Neural Network, FNN) 또는 순환 신경망(Recurrent Neural Network, RNN)을 기반으로 하는 인공 신경망 모델인,

인공 신경망 기반 배터리 고속 충전 효율 향상 장치.

청구항 5

미리 설정된 충전 프로파일을 통해 배터리에 대하여 축적된 배터리 상태 정보로 이루어지는 데이터 세트를 이용하여, 충전 전류를 출력으로 하는 인공 신경망 기반 배터리 충전 모델을 학습하는 단계; 및

학습된 상기 배터리 충전 모델을 기반으로 스케줄링 대상의 충전 전류를 획득하고, 획득한 충전 전류를 기반으로 상기 스케줄링 대상에 대한 충전 스케줄을 획득하는 단계;

를 포함하며,

상기 배터리 상태 정보는,

충전 전류(charging current), 배터리 전압(battery voltage) 및 배터리 온도(battery temperature)를 포함하는,

인공 신경망 기반 배터리 고속 충전 효율 향상 방법.

발명의 설명

기술 분야

[0001] 본 발명은 인공 신경망 기반 배터리 고속 충전 효율 향상 장치 및 방법에 관한 것으로서, 더욱 상세하게는 배터리의 충전 스케줄을 획득하는, 장치 및 방법에 관한 것이다.

배경 기술

[0002] 도 1은 종래의 충전 방법을 설명하기 위한 도면이다.

[0003] 종래의 리튬 이온 배터리의 충전 방법은 정전류-정전압(Constant Current-Constant Voltage, CC-CV) 충전 방법이 표준 방식으로 채택되어 모바일, 에너지 저장 장치, 전기 자동차, 전기 추진 선박 등에 활용되고 있다. CC-CV 충전 방법은 현재까지 배터리를 정상적인 활용 범위 안에서 충전/방전할 때, 가장 안전하고 모든 유형의 배터리에 활용 가능한 방법으로 알려져 있다. 도 1을 참조하면, CC-CV 충전 방법은 초기에는 일정한 전류(I_{ch})로 배터리의 상태를 안정적으로 유지하면서 충전을 하고, 기준 최대 전압(V_{max})에 도달한 후에는 일정한 전압(V_{ch})으로 충전을 하면서 동시에 전류를 감소시켜 밀도 높은 충전을 가능하게 한다. CC-CV 충전 방법으로는 고용량 배터리를 충전하는데 오랜 시간이 걸리고, 동일한 패턴으로 리튬 이온 배터리의 모든 셀들을 충전하기 때문에 각 배터리 셀의 건강 상태를 반영하지 못해 궁극적으로 배터리의 수명을 감소시킬 수 있는 문제가 있다.

[0004] 하지만, 리튬 이온 배터리 기반의 전기 자동차의 고용량 배터리를 충전하기 위해서는 급속 충전 방식의 충전소가 필요하다. 고용량의 리튬 이온 배터리를 충전하기 위하여 고속 충전(Boost Charging, BC) 방법이 제안되고 있다. 도 1을 참조하면, BC 충전 방법은 전류를 단계적으로 낮춰가면서($I_{boost} \rightarrow I_{ch}$) 충전하여 충전 시간을 단축할 수 있는 장점이 있지만, BC 충전 방법은 모든 유형의 배터리에 활용되기에 어렵고, 배터리의 수명을 크게 단축시킬 위험을 가지고 있다.

[0005] 도 2는 종래의 충전 프로파일을 설명하기 위한 도면이다.

[0006] 도 2를 참조하면, 종래의 충전 프로파일 중 하나인 Open-loop 시스템은 충전 프로파일의 표준 설계로서, 미리 설정된 충전 프로파일에 따라 수행되어, 배터리 상태를 반영하기 어려운 문제가 있다. 이에 반면, 종래의 충전 프로파일 중 하나인 Closed-loop 시스템은 배터리 상태를 기반으로 하는 PID 제어를 통해 충전 프로파일을 변경할 수 있지만, PID 제어 설계가 어려운 문제가 있다.

[0007] 전기 자동차에 활용되는 리튬 이온 배터리는 고용량의 배터리로 수백개 단위의 셀이 포함되어 있기 때문에 각 셀마다의 충전 및 잔존 수명의 상태가 다를 수 있고, 고속 충전 방법은 각 배터리의 유형 및 상태를 반영하지 않아 배터리의 수명 감소 및 화재의 위험성이 존재한다.

[0008] 따라서, 각 셀마다의 상태를 반영하여 충전할 수 있는 최적의 충전 방법의 개발이 필요하다.

발명의 내용

해결하려는 과제

- [0009] 본 발명이 이루고자 하는 목적은, 충전 프로파일을 통한 배터리의 충전 상태를 지속적으로 관찰하여 축적된 데이터로부터 추출된 배터리 특징을 이용하여 인공 신경망 기반의 배터리 충전 모델을 학습하고, 학습한 배터리 충전 모델을 기반으로 배터리의 충전 스케줄을 획득하는, 인공 신경망 기반 배터리 고속 충전 효율 향상 장치 및 방법을 제공하는 데 있다.
- [0010] 본 발명의 명시되지 않은 또 다른 목적들은 하기의 상세한 설명 및 그 효과로부터 용이하게 추론할 수 있는 범위 내에서 추가적으로 고려될 수 있다.

과제의 해결 수단

- [0011] 상기의 목적을 달성하기 위한 본 발명의 바람직한 실시예에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 장치는, 미리 설정된 충전 프로파일을 통해 배터리에 대하여 축적된 배터리 상태 정보로 이루어지는 데이터 세트를 이용하여, 충전 전류를 출력으로 하는 인공 신경망 기반 배터리 충전 모델을 학습하는 학습부; 및 상기 학습부를 통해 학습된 상기 배터리 충전 모델을 기반으로 스케줄링 대상의 충전 전류를 획득하고, 획득한 충전 전류를 기반으로 상기 스케줄링 대상에 대한 충전 스케줄을 획득하는 스케줄링부;를 포함하며, 상기 배터리 상태 정보는, 충전 전류(charging current), 배터리 전압(battery voltage) 및 배터리 온도(battery temperature)를 포함한다.
- [0012] 여기서, 상기 학습부는, 상기 배터리 상태 정보를 정규화(normalization)하고, 정규화된 상기 배터리 상태 정보에서 배터리 특징을 추출하며, 추출된 상기 배터리 특징으로 이루어지는 상기 데이터 세트를 획득하며, 상기 배터리 특징은, 충전 전류(charging current), 배터리 전압(battery voltage), 배터리 온도 증가(battery temperature increment) 및 배터리 온도 미분 계수(battery temperature differential coefficient)를 포함할 수 있다.
- [0013] 여기서, 상기 학습부는, 상기 데이터 세트를 학습 데이터 세트와 테스트 데이터 세트로 분할하고, 상기 학습 데이터 세트를 훈련 데이터 세트와 검증 데이터 세트로 분할하며, 상기 훈련 데이터 세트를 이용하여 상기 배터리 충전 모델을 구축하고, 구축된 상기 배터리 충전 모델의 오버피팅(overfitting)을 최소화하는 에포치(epoch)를 상기 검증 데이터 세트를 이용하여 K-fold 교차 검증(cross validation, CV)을 통해 획득하고, 획득한 에포치(epoch)를 기반으로 상기 배터리 충전 모델을 최적화하고, 최적화된 상기 배터리 충전 모델을 상기 테스트 데이터 세트를 이용하여 테스트하여, 상기 배터리 충전 모델을 학습할 수 있다.
- [0014] 여기서, 상기 배터리 충전 모델은, 순방향 신경망(Feedforward Neural Network, FNN) 또는 순환 신경망(Recurrent Neural Network, RNN)을 기반으로 하는 인공 신경망 모델일 수 있다.

- [0016] 상기의 목적을 달성하기 위한 본 발명의 바람직한 실시예에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 방법은, 미리 설정된 충전 프로파일을 통해 배터리에 대하여 축적된 배터리 상태 정보로 이루어지는 데이터 세트를 이용하여, 충전 전류를 출력으로 하는 인공 신경망 기반 배터리 충전 모델을 학습하는 단계; 및 학습된 상기 배터리 충전 모델을 기반으로 스케줄링 대상의 충전 전류를 획득하고, 획득한 충전 전류를 기반으로 상기 스케줄링 대상에 대한 충전 스케줄을 획득하는 단계;를 포함하며, 상기 배터리 상태 정보는, 충전 전류(charging current), 배터리 전압(battery voltage) 및 배터리 온도(battery temperature)를 포함할 수 있다.

발명의 효과

- [0017] 본 발명의 바람직한 실시예에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 장치 및 방법에 의하면, 충전 프로파일을 통한 배터리의 충전 상태를 지속적으로 관찰하여 축적된 데이터로부터 추출된 배터리 특징을 이용하여 인공 신경망 기반의 배터리 충전 모델을 학습하고, 학습한 배터리 충전 모델을 기반으로 배터리의 충전 스케줄을 획득함으로써, 종래의 CC-CV 충전 방법보다 충전 시간을 단축할 수 있고, 종래의 BC 충전 방법보다 더 빠르고 안전하게 충전이 가능하다.
- [0018] 본 발명의 효과들은 이상에서 언급한 효과들로 제한되지 않으며, 언급되지 않은 또 다른 효과들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

도면의 간단한 설명

- [0019] 도 1은 종래의 충전 방법을 설명하기 위한 도면이다.
- 도 2는 종래의 충전 프로파일을 설명하기 위한 도면이다.
- 도 3은 본 발명의 바람직한 실시예에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 장치를 설명하기 위한 블록도이다.
- 도 4는 본 발명의 바람직한 실시예에 따른 배터리 충전 모델의 학습 동작을 설명하기 위한 도면이다.
- 도 5는 본 발명의 바람직한 실시예에 따른 배터리 특징을 설명하기 위한 도면이다.
- 도 6은 본 발명의 바람직한 실시예에 따른 배터리 특징 간의 상관관계를 설명하기 위한 도면이다.
- 도 7은 본 발명의 바람직한 실시예에 따른 배터리 충전 모델의 구축 및 최적화 동작을 설명하기 위한 도면이다.
- 도 8은 본 발명의 바람직한 실시예에 따른 배터리 충전 모델의 테스트 동작을 설명하기 위한 도면이다.
- 도 9는 본 발명의 바람직한 실시예에 따른 배터리 충전 모델의 성능을 설명하기 위한 도면으로, 종래의 배터리 특징을 이용하여 학습한 경우를 나타낸다.
- 도 10은 본 발명의 바람직한 실시예에 따른 배터리 충전 모델의 성능을 설명하기 위한 도면으로, 본 발명에 따른 새로운 배터리 특징도 함께 이용하여 학습한 경우를 나타낸다.
- 도 11은 본 발명의 바람직한 실시예에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 방법을 설명하기 위한 흐름도이다.

발명을 실시하기 위한 구체적인 내용

- [0020] 이하, 첨부된 도면을 참조하여 본 발명의 실시 예를 상세히 설명한다. 본 발명의 이점 및 특징, 그리고 그것들을 달성하는 방법은 첨부되는 도면과 함께 상세하게 후술되어 있는 실시 예를 참조하면 명확해질 것이다. 그러나 본 발명은 이하에서 개시되는 실시예들에 한정되는 것이 아니라 서로 다른 다양한 형태로 구현될 수 있으며, 단지 본 실시예들은 본 발명의 개시가 완전하도록 하고, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 발명의 범주를 완전하게 알려주기 위해 제공되는 것이며, 본 발명은 청구항의 범주에 의해 정의될 뿐이다. 명세서 전체에 걸쳐 동일 참조 부호는 동일 구성 요소를 지칭한다.
- [0021] 다른 정의가 없다면, 본 명세서에서 사용되는 모든 용어(기술 및 과학적 용어를 포함)는 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 공통적으로 이해될 수 있는 의미로 사용될 수 있을 것이다. 또 일반적으로 사용되는 사전에 정의되어 있는 용어들은 명백하게 특별히 정의되어 있지 않는 한 이상적으로 또는 과도하게 해석되지 않는다.
- [0022] 본 명세서에서 "제1", "제2" 등의 용어는 하나의 구성요소를 다른 구성요소로부터 구별하기 위한 것으로, 이들 용어들에 의해 권리범위가 한정되어서는 아니 된다. 예를 들어, 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소도 제1 구성요소로 명명될 수 있다.
- [0023] 본 명세서에서 각 단계들에 있어 식별부호(예를 들어, a, b, c 등)는 설명의 편의를 위하여 사용되는 것으로 식별부호는 각 단계들의 순서를 설명하는 것이 아니며, 각 단계들은 문맥상 명백하게 특정 순서를 기재하지 않는 이상 명기된 순서와 다르게 일어날 수 있다. 즉, 각 단계들은 명기된 순서와 동일하게 일어날 수도 있고 실질적으로 동시에 수행될 수도 있으며 반대의 순서대로 수행될 수도 있다.
- [0024] 본 명세서에서, "가진다", "가질 수 있다", "포함한다" 또는 "포함할 수 있다" 등의 표현은 해당 특징(예: 수치, 기능, 동작, 또는 부품 등의 구성요소)의 존재를 가리키며, 추가적인 특징의 존재를 배제하지 않는다.
- [0025] 또한, 본 명세서에 기재된 '~부'라는 용어는 소프트웨어 또는 FPGA(field-programmable gate array) 또는 ASIC과 같은 하드웨어 구성요소를 의미하며, '~부'는 어떤 역할들을 수행한다. 그렇지만 '~부'는 소프트웨어 또는 하드웨어에 한정되는 의미는 아니다. '~부'는 어드레싱할 수 있는 저장 매체에 있도록 구성될 수도 있고 하나 또는 그 이상의 프로세서들을 재생시키도록 구성될 수도 있다. 따라서, 일 예로서 '~부'는 소프트웨어 구성요소들, 객체지향 소프트웨어 구성요소들, 클래스 구성요소들 및 태스크 구성요소들과 같은 구성요소들과, 프로세스들, 함수들, 속성들, 프로시저들, 서브루틴들, 프로그램 코드의 세그먼트들, 드라이버들, 펌웨어,

마이크로코드, 회로, 데이터 구조들 및 변수들을 포함한다. 구성요소들과 '~부'들 안에서 제공되는 기능은 더 작은 수의 구성요소들 및 '~부'들로 결합되거나 추가적인 구성요소들과 '~부'들로 더 분리될 수 있다.

- [0027] 이하에서 첨부한 도면을 참조하여 본 발명에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 장치 및 방법의 바람직한 실시예에 대해 상세하게 설명한다.
- [0029] 먼저, 도 3을 참조하여 본 발명의 바람직한 실시예에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 장치에 대하여 설명한다.
- [0030] 도 3은 본 발명의 바람직한 실시예에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 장치를 설명하기 위한 블록도이다.
- [0031] 도 3을 참조하면, 본 발명의 바람직한 실시예에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 장치(이하 '배터리 고속 충전 효율 향상 장치'라 한다)(100)는 충전 프로파일을 통한 배터리의 충전 상태를 지속적으로 관찰하여 축적된 데이터로부터 추출된 배터리 특징을 이용하여 인공 신경망 기반의 배터리 충전 모델을 학습하고, 학습한 배터리 충전 모델을 기반으로 배터리의 충전 스케줄을 획득한다.
- [0032] 이를 위해, 배터리 고속 충전 효율 향상 장치(100)는 학습부(110) 및 스케줄링부(130)를 포함할 수 있다.
- [0034] 학습부(110)는 미리 설정된 충전 프로파일을 통해 배터리에 대하여 축적된 배터리 상태 정보로 이루어지는 데이터 세트를 이용하여, 충전 전류를 출력으로 하는 인공 신경망 기반 배터리 충전 모델을 학습한다.
- [0035] 여기서, 배터리 상태 정보는 충전 전류(charging current), 배터리 전압(battery voltage) 및 배터리 온도(battery temperature)를 포함할 수 있다.
- [0036] 그리고, 배터리 충전 모델은 순방향 신경망(Feedforward Neural Network, FNN) 또는 LSTM(Long Short-Term Memory), GRU(Gated Recurrent Unit) 등과 같은 순환 신경망(Recurrent Neural Network, RNN)을 기반으로 하는 인공 신경망 모델일 수 있다.
- [0037] 그리고, 미리 설정된 충전 프로파일은 open-loop 시스템에 기반한 종래의 충전 프로파일을 말한다.
- [0038] 즉, 학습부(110)는 배터리 상태 정보를 정규화(normalization)하고, 정규화된 배터리 상태 정보에서 배터리 특징을 추출하며, 추출된 배터리 특징으로 이루어지는 데이터 세트를 획득할 수 있다.
- [0039] 여기서, 배터리 특징은 충전 전류(charging current), 배터리 전압(battery voltage), 배터리 온도 증가(battery temperature increment) 및 배터리 온도 미분 계수(battery temperature differential coefficient)를 포함할 수 있다.
- [0040] 그리고, 학습부(110)는 데이터 세트를 학습 데이터 세트와 테스트 데이터 세트로 분할하고, 학습 데이터 세트를 훈련 데이터 세트와 검증 데이터 세트로 분할할 수 있다.
- [0041] 그리고, 학습부(110)는 훈련 데이터 세트를 이용하여 배터리 충전 모델을 구축할 수 있다.
- [0042] 그리고, 학습부(110)는 구축된 배터리 충전 모델의 오버피팅(overfitting)을 최소화하는 에포치(epoch)를 검증 데이터 세트를 이용하여 K-fold 교차 검증(cross validation, CV)을 통해 획득하고, 획득한 에포치(epoch)를 기반으로 배터리 충전 모델을 최적화할 수 있다.
- [0043] 그리고, 학습부(110)는 최적화된 배터리 충전 모델을 테스트 데이터 세트를 이용하여 테스트하여, 배터리 충전 모델을 학습할 수 있다.
- [0045] 스케줄링부(130)는 학습부(110)를 통해 학습된 배터리 충전 모델을 기반으로 스케줄링 대상의 충전 전류를 획득하고, 획득한 충전 전류를 기반으로 스케줄링 대상에 대한 충전 스케줄을 획득한다.
- [0046] 여기서, 스케줄링 대상은 배터리 충전 모델의 학습에 이용되는 배터리 또는 배터리 충전 모델의 학습에 이용되는 배터리와 동일한 제품이 탑재된 객체(예컨대, 전기 자동차 등)를 말한다.

- [0049] 그러면, 도 4 내지 도 10을 참조하여 본 발명의 바람직한 실시예에 따른 배터리 충전 모델의 학습 동작에 대하여 보다 자세하게 설명한다.
- [0050] 도 4는 본 발명의 바람직한 실시예에 따른 배터리 충전 모델의 학습 동작을 설명하기 위한 도면이다.
- [0051] 도 4를 참조하면, 본 발명에 따른 배터리 충전 모델의 학습 동작은 아래와 같은 3개의 단계로 이루어질 수 있다.
- [0052] STEP 1 : 배터리의 일반적인 충전 프로파일을 통해서 배터리 상태 정보를 축적하고, 이를 정규화하여 배터리 특징을 추출하여 데이터 세트를 획득함
- [0053] STEP 2 : 데이터 세트를 학습 데이터 세트와 테스트 데이터 세트로 분할하고, 학습 데이터 세트를 훈련 데이터 세트와 검증 데이터 세트로 분할하며, 인공 신경망 기반 배터리 충전 모델을 학습하고, K-fold 교차 검증(CV) 방법과 지속적인 학습을 통해 배터리 충전 모델을 최적화함
- [0054] STEP 3 : 최적화된 배터리 충전 모델을 기반으로 최적의 충전 스케줄을 획득하고, 서로 다른 인공 신경망(FNN, LSTM, GRU)으로 이루어지는 배터리 충전 모델의 성능을 비교함
- [0055] 데이터 세트로, 18650 원통형 리튬-이온 배터리(Cylindrical Li-ion Battery)를 이용하고, 샘플 데이터는 360,000 포인트로 이루어진다.
- [0056] 배터리 충전 모델의 입력 데이터는 충전 전류(charging current), 배터리 전압(battery voltage) 배터리 온도 증가(battery temperature increment) 및 배터리 온도 미분 계수(battery temperature differential coefficient)이다.
- [0057] 배터리 충전 모델의 출력 데이터는 예측된 충전 전류이다.
- [0059] 도 5는 본 발명의 바람직한 실시예에 따른 배터리 특징을 설명하기 위한 도면이고, 도 6은 본 발명의 바람직한 실시예에 따른 배터리 특징 간의 상관관계를 설명하기 위한 도면이다.
- [0060] open-loop 시스템에 기반한 종래의 충전 프로파일을 통해 배터리를 충전하여, 배터리 상태 정보를 축적하여 데이터 세트를 획득한다.
- [0061] 그리고, 데이터 세트를 정규화하고, 도 5에 도시된 바와 같은 충전 전류(charging current), 배터리 전압(battery voltage) 배터리 온도 증가(battery temperature increment) 및 배터리 온도 미분 계수(battery temperature differential coefficient)로 이루어지는 배터리 특징을 추출한다.
- [0062] Pearson의 상관 계수를 통해 배터리 특징 간의 상관관계를 정량적으로 비교한 결과는 도 6에 도시된 바와 같다. 배터리 충전 전류(도 6의 Current)는 배터리 전압(도 6의 Volt)과 배터리 온도 증가(도 6의 Temp)보다 배터리 온도 미분 계수(도 6의 Tempd)와 가장 높은 관련성이 있는 것을 확인할 수 있다.
- [0064] 도 7은 본 발명의 바람직한 실시예에 따른 배터리 충전 모델의 구축 및 최적화 동작을 설명하기 위한 도면이다.
- [0065] 도 7을 참조하면, 데이터 세트를 학습 데이터 세트와 테스트 데이터 세트로 분할하고, 학습 데이터 세트를 훈련 데이터 세트와 검증 데이터 세트로 분할한다.
- [0066] 그리고, 훈련 데이터 세트를 이용하여 FNN 기반 배터리 충전 모델, LSTM 기반 배터리 충전 모델 및 GRU 기반 배터리 충전 모델 각각을 구축한다.
- [0067] LSTM, GRU : 배터리 데이터는 외부 전압이 인가 될 때 시간에 따른 화학적 변화를 보여주며, 시계열 데이터 특성을 반영하는 모델은 RNN 중 LSTM과 GRU이다.
- [0068] FNN : 입력 데이터의 시계열 데이터 특성을 확인하기 위한 기준선으로 이용한다.
- [0069] 그리고, K-fold 교차 검증(cross validation, CV)을 통해, 구축된 3개의 배터리 충전 모델의 오버피팅

(overfitting)을 최소화하는 에포치(epoch)를 검증 데이터 세트를 이용하여 획득하고, 획득한 에포치(epoch)를 기반으로 3개의 배터리 충전 모델을 최적화한다.

[0070] 이때, 입력 데이터를 2개의 그룹으로 나누고, 각각의 그룹에 해당하는 입력 데이터를 이용하여 그룹 별로 FNN 기반 배터리 충전 모델, LSTM 기반 배터리 충전 모델 및 GRU 기반 배터리 충전 모델 각각을 구축한다.

[0071] 그룹 1(k=2) : 종래의 배터리 특징만을 입력 데이터로 이용하는 그룹이다. 즉, 입력 데이터로 배터리 온도 증가(battery temperature increment) 및 배터리 전압(battery voltage)의 2개의 배터리 특징을 이용한다.

[0072] 그룹 2(k=4) : 본 발명에 따른 새로운 배터리 특징도 함께 입력 데이터로 이용하는 그룹이다. 즉, 입력 데이터로 배터리 온도 증가(battery temperature increment), 배터리 전압(battery voltage), 배터리 온도 미분 계수(battery temperature differential coefficient) 및 충전 전류(charging current)의 4개의 배터리 특징을 이용한다.

[0074] 도 8은 본 발명의 바람직한 실시예에 따른 배터리 충전 모델의 테스트 동작을 설명하기 위한 도면이다.

[0075] 도 8을 참조하면, 그룹 1(k=2) 및 그룹 2(k=3) 각각에 대해 구축 및 최적화된 3개의 배터리 충전 모델(FNN 기반 배터리 충전 모델, LSTM 기반 배터리 충전 모델 및 GRU 기반 배터리 충전 모델) 각각을 테스트 데이터 세트를 이용하여 테스트하여, 최종 배터리 충전 모델을 획득한다.

[0076] 즉, 평균 절대 오차(mean absolute error, MAE)와 평균 절대 백분율 오차(mean absolute percentage error, MAPE)를 이용하여, 테스트 데이터 세트를 통해 6개의 배터리 충전 모델(그룹 1의 3개, 그룹 2의 3개)의 충전 프로파일 성능을 평가한다.

[0078] 도 9는 본 발명의 바람직한 실시예에 따른 배터리 충전 모델의 성능을 설명하기 위한 도면으로, 종래의 배터리 특징을 이용하여 학습한 경우를 나타낸다.

[0079] 도 9 및 아래의 [표 1]을 참조하면, LSTM 기반 배터리 충전 모델(LSTM-2)은 종래의 BC 충전 방법(Test set)과 유사하게 설계된 것을 확인할 수 있다. 이는 배터리 상태 데이터가 시계열 데이터이기 때문이다.

[0080] FNN 기반 모델은 종래의 BC 충전 방법(Test set)과 가장 유사하게 설계된 것을 확인할 수 있다.

[0081] 이는, 더 많은 입력 파라미터가 필요하다는 것을 의미한다.

표 1

[0082]

	MAE	MAPE(%)
FNN-2	0.0437	27.00
LSTM-2	0.0355	12.38
GRU-2	0.0651	50.35

[0084] 도 10은 본 발명의 바람직한 실시예에 따른 배터리 충전 모델의 성능을 설명하기 위한 도면으로, 본 발명에 따른 새로운 배터리 특징도 함께 이용하여 학습한 경우를 나타낸다.

[0085] 도 10 및 아래의 [표 2]를 참조하면, FNN 기반 배터리 충전 모델(FNN-4), LSTM 기반 배터리 충전 모델(LSTM-4) 및 GRU 기반 배터리 충전 모델(GRU-4)은 종래의 BC 충전 방법(Test set)과 유사한 충전 스케줄을 제시하지만, 각 배터리 셀의 상태를 반영하여 충전 전류를 변화시키기 때문에 SOC(State of Charge) 결과에서 같은 충전 시간 대비 높은 SOC를 보이는 것을 확인할 수 있다.

[0086] 아울러, LSTM 기반 배터리 충전 모델(LSTM-4)는 사용된 모든 배터리 충전 모델 중 최고의 성능을 보여준다. 이는 4개의 배터리 특징을 입력하여 배터리 충전 프로파일을 예측하는 것이 더 정확하다는 것을 의미한다.

표 2

	MAE	MAPE(%)
FNN-4	0.0288	13.35
LSTM-4	0.0183	11.03
GRU-4	0.0511	25.67

[0087]

[0089]

즉, 본 발명에 따른 배터리 충전 모델은 종래의 CC-CV 충전 방법보다 충전 시간을 단축할 수 있다. 또한, 본 발명에 따른 배터리 충전 모델은 각 배터리 셀의 상태를 반영한 충전 스케줄을 제안하기 때문에, 종래의 BC 충전 방법보다 더 빠르고 안전하게 충전이 가능하다.

[0092]

그러면, 도 11을 참조하여 본 발명의 바람직한 실시예에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 방법에 대하여 설명한다.

[0093]

도 11은 본 발명의 바람직한 실시예에 따른 인공 신경망 기반 배터리 고속 충전 효율 향상 방법을 설명하기 위한 흐름도이다.

[0094]

도 11을 참조하면, 배터리 고속 충전 효율 향상 장치(100)는 미리 설정된 충전 프로파일을 통해 배터리에 대하여 축적된 배터리 상태 정보로 이루어지는 데이터 세트를 이용하여, 충전 전류를 출력으로 하는 인공 신경망 기반 배터리 충전 모델을 학습한다(S110).

[0095]

즉, 배터리 고속 충전 효율 향상 장치(100)는 배터리 상태 정보를 정규화(normalization)하고, 정규화된 배터리 상태 정보에서 배터리 특징을 추출하며, 추출된 배터리 특징으로 이루어지는 데이터 세트를 획득할 수 있다.

[0096]

그리고, 배터리 고속 충전 효율 향상 장치(100)는 데이터 세트를 학습 데이터 세트와 테스트 데이터 세트로 분할하고, 학습 데이터 세트를 훈련 데이터 세트와 검증 데이터 세트로 분할하며, 훈련 데이터 세트를 이용하여 배터리 충전 모델을 구축하고, 구축된 배터리 충전 모델의 오버피팅(overfitting)을 최소화하는 에포치(epoch)를 검증 데이터 세트를 이용하여 K-fold 교차 검증(cross validation, CV)을 통해 획득하며, 획득한 에포치(epoch)를 기반으로 배터리 충전 모델을 최적화하고, 최적화된 배터리 충전 모델을 테스트 데이터 세트를 이용하여 테스트하여, 배터리 충전 모델을 학습할 수 있다.

[0098]

그런 다음, 배터리 고속 충전 효율 향상 장치(100)는 학습된 배터리 충전 모델을 기반으로 스케줄링 대상의 충전 전류를 획득하고, 획득한 충전 전류를 기반으로 스케줄링 대상에 대한 충전 스케줄을 획득한다(S130).

[0101]

이상에서 설명한 본 발명의 실시예를 구성하는 모든 구성요소들이 하나로 결합하거나 결합하여 동작하는 것으로 기재되어 있다고 해서, 본 발명이 반드시 이러한 실시예에 한정되는 것은 아니다. 즉, 본 발명의 목적 범위 안에서라면, 그 모든 구성요소들이 하나 이상으로 선택적으로 결합하여 동작할 수도 있다. 또한, 그 모든 구성요소들이 각각 하나의 독립적인 하드웨어로 구현될 수 있지만, 각 구성요소들의 그 일부 또는 전부가 선택적으로 조합되어 하나 또는 복수개의 하드웨어에서 조합된 일부 또는 전부의 기능을 수행하는 프로그램 모듈을 갖는 컴퓨터 프로그램으로서 구현될 수도 있다. 또한, 이와 같은 컴퓨터 프로그램은 USB 메모리, CD 디스크, 플래쉬 메모리 등과 같은 컴퓨터가 읽을 수 있는 기록 매체(Computer Readable Media)에 저장되어 컴퓨터에 의하여 읽혀지고 실행됨으로써, 본 발명의 실시예를 구현할 수 있다. 컴퓨터 프로그램의 기록 매체로서는 자기기록매체, 광기록매체 등이 포함될 수 있다.

[0102]

이상의 설명은 본 발명의 기술 사상을 예시적으로 설명한 것에 불과한 것으로서, 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자라면 본 발명의 본질적인 특성에서 벗어나지 않는 범위 내에서 다양한 수정, 변경 및

치환이 가능할 것이다. 따라서, 본 발명에 개시된 실시예 및 첨부된 도면들은 본 발명의 기술 사상을 한정하기 위한 것이 아니라 설명하기 위한 것이고, 이러한 실시예 및 첨부된 도면에 의하여 본 발명의 기술 사상의 범위가 한정되는 것은 아니다. 본 발명의 보호 범위는 아래의 청구범위에 의하여 해석되어야 하며, 그와 동등한 범위 내에 있는 모든 기술 사상은 본 발명의 권리범위에 포함되는 것으로 해석되어야 할 것이다.

부호의 설명


100 : 배터리 고속 충전 효율 향상 장치,

110 : 학습부,


130 : 스케줄링부

도면

도면1

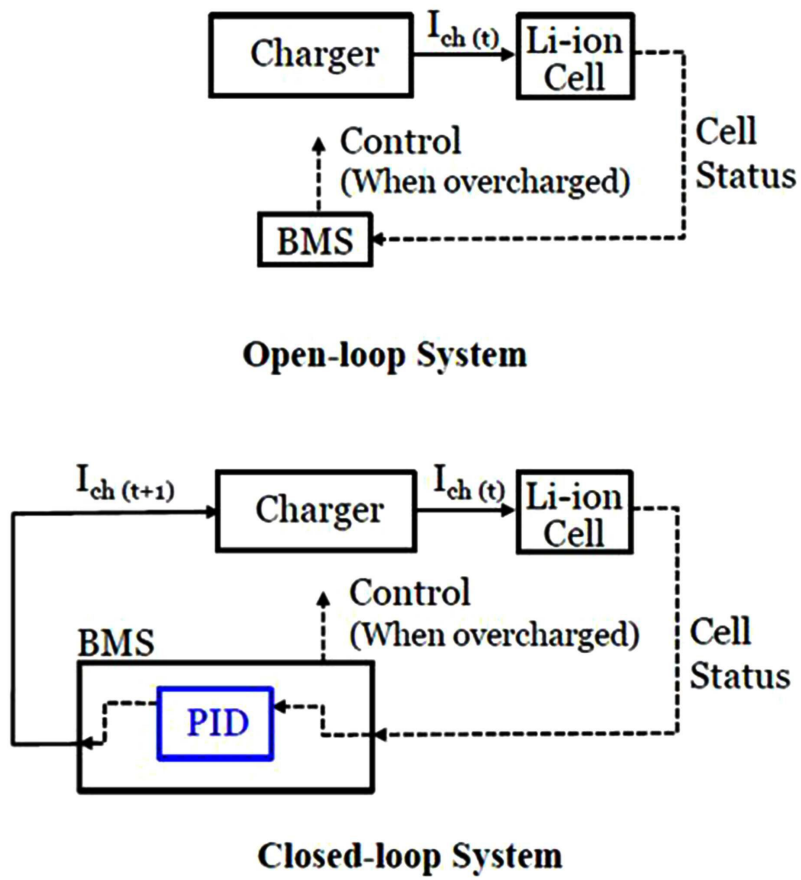


CC-CV
(Constant Current Constant Voltage)




BC
(Boost Charging)

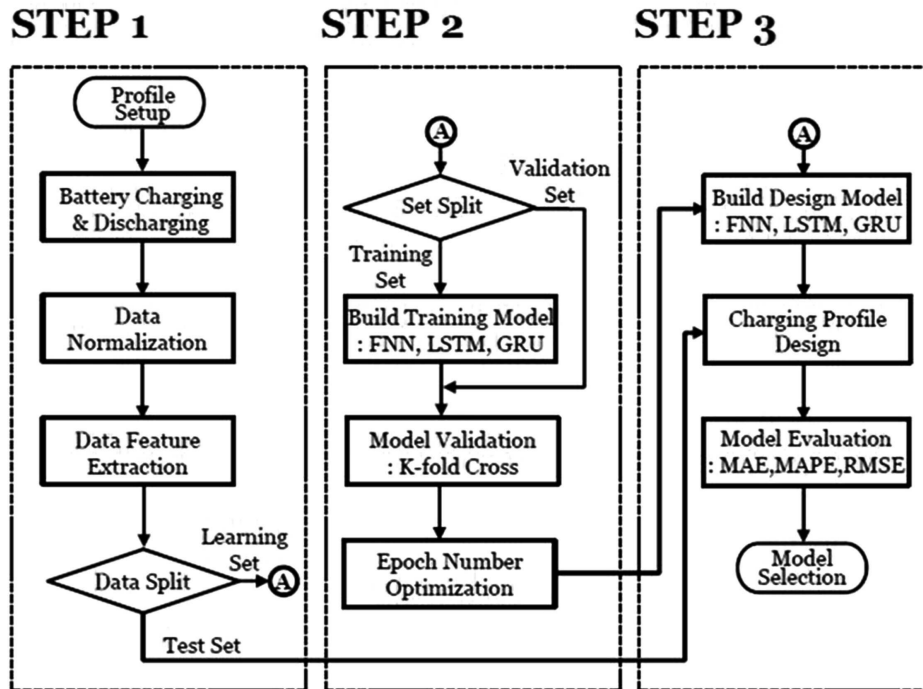
도면2




도면3




도면4




도면5




도면6



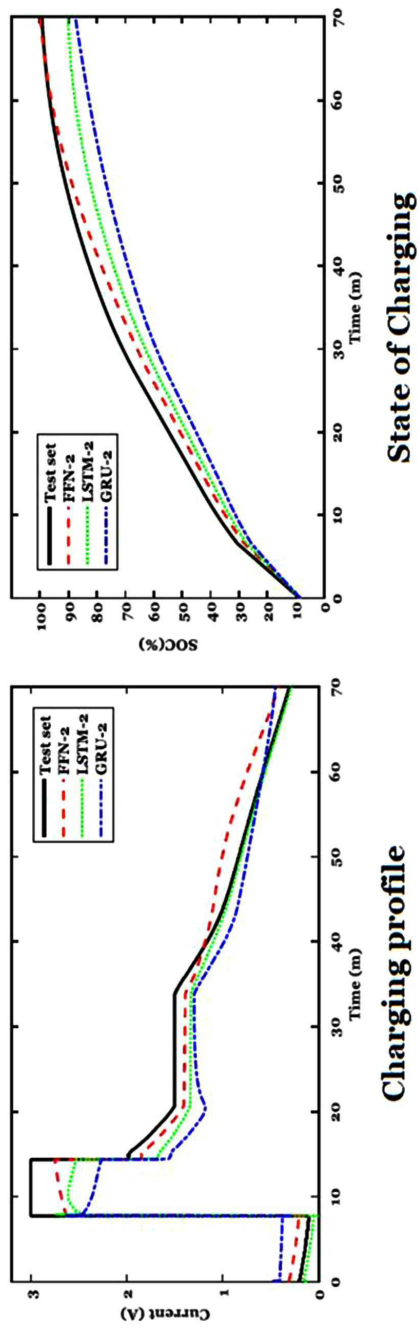
도면7



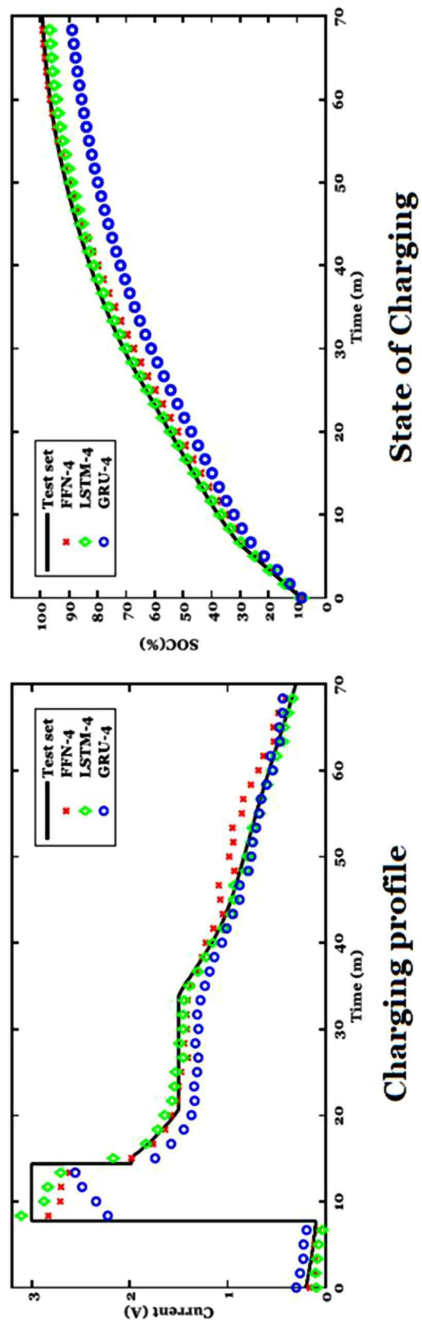
도면8



도면9



도면10



도면11

