



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2021-0041511
(43) 공개일자 2021년04월15일

- | | |
|---|--|
| <p>(51) 국제특허분류(Int. Cl.)
 <i>G01R 31/367</i> (2019.01) <i>G01R 31/36</i> (2019.01)
 <i>G01R 31/382</i> (2019.01) <i>G01R 31/392</i> (2019.01)
 <i>G06N 20/00</i> (2019.01) <i>G06N 3/08</i> (2006.01)</p> <p>(52) CPC특허분류
 <i>G01R 31/367</i> (2019.01)
 <i>G01R 31/3648</i> (2013.01)</p> <p>(21) 출원번호 10-2020-0128013
 (22) 출원일자 2020년10월05일
 심사청구일자 없음</p> <p>(30) 우선권주장
 62/911,874 2019년10월07일 미국(US)
 62/992,362 2020년03월20일 미국(US)</p> | <p>(71) 출원인
 삼성에스디아이 주식회사
 경기도 용인시 기흥구 공세로 150-20 (공세동)
 포항공과대학교 산학협력단
 경상북도 포항시 남구 청암로 77 (지곡동)</p> <p>(72) 발명자
 이장우
 경기도 용인시 기흥구 공세로 150-20 (공세동)
 김정수
 경기도 용인시 기흥구 공세로 150-20 (공세동)
 (뒷면에 계속)</p> <p>(74) 대리인
 리엔특허법인</p> |
|---|--|

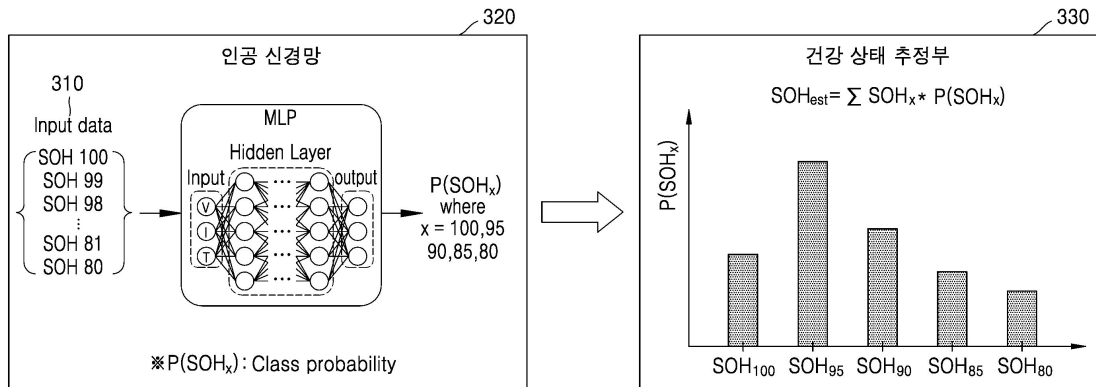
전체 청구항 수 : 총 20 항

(54) 발명의 명칭 **배터리의 건강 상태를 추정하는 방법 및 장치**

(57) 요약

컴퓨팅 장치에 의해 수행되는 배터리의 건강 상태 추정 방법은 미리 학습된 인공 신경망을 준비하는 단계, 배터리의 적어도 하나의 파라미터를 측정하여 입력 데이터를 생성하는 단계, 상기 입력 데이터를 상기 인공 신경망에 입력하여 복수의 클래스들에 각각 대응하는 복수의 출력값들을 획득하는 단계, 및 상기 복수의 클래스들에 각각 대응하는 미리 설정된 복수의 건강 상태 구간들, 및 상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들을 이용하여 상기 배터리의 건강 상태 값을 추정하는 단계를 포함한다.

대표도



(52) CPC특허분류

G01R 31/382 (2019.01)

G01R 31/392 (2019.01)

G06N 20/00 (2019.01)

G06N 3/08 (2013.01)

(72) 발명자

이태경

경기도 용인시 기흥구 공세로 150-20 (공세동)

한수희

경기도 용인시 기흥구 공세로 150-20 (공세동)

명세서

청구범위

청구항 1

적어도 하나의 컴퓨팅 장치에 의해 수행되는 방법에 있어서,

미리 학습된 인공 신경망을 준비하는 단계;

배터리의 적어도 하나의 파라미터를 측정하여 입력 데이터를 생성하는 단계;

상기 입력 데이터를 상기 인공 신경망에 입력하여 복수의 클래스들에 각각 대응하는 복수의 출력값들을 획득하는 단계; 및

상기 복수의 클래스들에 각각 대응하는 미리 설정된 복수의 건강 상태 구간들, 및 상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들을 이용하여 상기 배터리의 건강 상태 추정값을 생성하는 단계를 포함하는 배터리의 건강 상태를 추정하는 방법.

청구항 2

제1 항에 있어서,

상기 적어도 하나의 파라미터는 상기 배터리의 전압 및 전류를 포함하는 배터리의 건강 상태를 추정하는 방법.

청구항 3

제1 항에 있어서,

상기 적어도 하나의 파라미터는 상기 배터리의 전압, 전류 및 온도를 포함하는 배터리의 건강 상태를 추정하는 방법.

청구항 4

제1 항에 있어서,

상기 입력 데이터를 생성하는 단계는,

사용 중인 상기 배터리의 상기 적어도 하나의 파라미터를 미리 설정된 샘플링 주기마다 측정하는 단계; 및

미리 설정된 제1 시간동안 측정한 상기 적어도 하나의 파라미터의 측정값들에 기초하여 상기 입력 데이터를 생성하는 단계를 포함하는 배터리의 건강 상태를 추정하는 방법.

청구항 5

제1 항에 있어서,

상기 입력 데이터를 생성하는 단계는,

사용 중인 상기 배터리의 상기 적어도 하나의 파라미터를 미리 설정된 샘플링 주기마다 측정하여 상기 적어도 하나의 파라미터의 측정값들을 생성하는 단계;

미리 설정된 제2 시간씩 경과한 후 미리 설정된 제1 시간동안 생성된 상기 적어도 하나의 파라미터의 측정값들에 기초하여 복수의 입력 서브 데이터를 생성하는 단계; 및

상기 복수의 입력 서브 데이터를 기초로 상기 입력 데이터를 생성하는 단계를 포함하는 배터리의 건강 상태를 추정하는 방법.

청구항 6

제1 항에 있어서,

상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들은 상기 입력 데이터가 상기 복수의 클래스들 각각

에 속할 확률 값들인 배터리의 건강 상태를 추정하는 방법.

청구항 7

제1 항에 있어서,

상기 배터리의 건강 상태 추정값은 상기 복수의 클래스들에 각각 대응하는 상기 복수의 건강 상태 구간들의 대표 값들과 상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들을 각각 곱한 후 모두 가산함으로써 산출되는 배터리의 건강 상태를 추정하는 방법.

청구항 8

제1 항에 있어서,

상기 미리 학습된 인공 신경망을 준비하는 단계는,

인공 신경망을 생성하는 단계;

상기 미리 설정된 복수의 건강 상태 구간들 각각에서 상기 배터리의 상기 적어도 하나의 파라미터를 측정된 측정 데이터들을 준비하는 단계;

상기 측정 데이터들을 이용하여, 각각 자신이 속하는 클래스가 라벨링된 복수의 학습 데이터들을 생성하는 단계; 및

상기 복수의 학습 데이터들을 이용하여 상기 인공 신경망을 학습시키는 단계를 포함하는 배터리의 건강 상태를 추정하는 방법.

청구항 9

제8 항에 있어서,

상기 복수의 학습 데이터들을 준비하는 단계는,

모델 파라미터들을 포함하는 배터리 전기 화학 모델을 준비하는 단계;

상기 측정 데이터들을 이용하여 상기 미리 설정된 복수의 건강 상태 구간들 각각에 대응하는 상기 배터리 전기 화학 모델의 모델 파라미터 데이터들을 생성하는 단계;

상기 모델 파라미터 데이터들 각각이 적용된 상기 배터리 전기 화학 모델에 전류 데이터를 입력하여, 상기 미리 설정된 복수의 건강 상태 구간들 각각에 대응하는 복수의 합성 전압 데이터를 생성하는 단계; 및

상기 전류 데이터 및 상기 복수의 합성 전압 데이터에 기초하여 상기 복수의 학습 데이터를 생성하는 단계를 포함하는 배터리의 건강 상태를 추정하는 방법.

청구항 10

제9 항에 있어서,

상기 복수의 학습 데이터들을 준비하는 단계는,

상기 모델 파라미터 데이터들 각각이 적용된 상기 배터리 전기 화학 모델에 전류 데이터를 입력하여, 상기 미리 설정된 복수의 건강 상태 구간들 각각에 대응하는 복수의 합성 온도 데이터를 더 생성하는 단계; 및

상기 전류 데이터, 상기 복수의 합성 전압 데이터 및 상기 복수의 합성 온도 데이터에 기초하여 상기 복수의 학습 데이터를 생성하는 단계를 더 포함하는 배터리의 건강 상태를 추정하는 방법.

청구항 11

제8 항에 있어서,

상기 인공 신경망은 다중층 퍼셉트론(multi-layer perceptron; MLP)을 기초로 생성되는 배터리의 건강 상태를 추정하는 방법.

청구항 12

제1 항에 있어서,

상기 인공 신경망은 입력층, 적어도 하나의 은닉층, 및 출력층을 포함하고,

상기 출력층은 상기 입력층에 입력되는 상기 입력 데이터가 상기 복수의 클래스들 각각에 속할 확률을 출력하는 소프트맥스 함수를 포함하는 배터리의 건강 상태를 추정하는 방법.

청구항 13

미리 학습된 인공 신경망, 및 배터리의 적어도 하나의 파라미터를 측정함으로써 생성되는 입력 데이터를 저장하는 메모리; 및

상기 입력 데이터를 상기 인공 신경망에 입력하여 복수의 클래스들에 각각 대응하는 복수의 출력값들을 획득하고, 상기 복수의 클래스들에 각각 대응하는 미리 설정된 복수의 건강 상태 구간들, 및 상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들을 이용하여 상기 배터리의 건강 상태 값을 추정하도록 구성되는 적어도 하나의 프로세서를 포함하는 배터리의 건강 상태를 추정하는 장치.

청구항 14

제13 항에 있어서,

상기 적어도 하나의 파라미터는 상기 배터리의 전압 및 전류를 포함하거나, 상기 배터리의 전압, 전류 및 온도를 포함하는 배터리의 건강 상태를 추정하는 장치.

청구항 15

제13 항에 있어서,

상기 입력 데이터는 사용 중인 상기 배터리의 상기 적어도 하나의 파라미터를 미리 설정된 샘플링 주기마다 미리 설정된 제1 시간동안 측정하여 생성되는 상기 적어도 하나의 파라미터의 측정값들에 기초하여 생성되는 배터리의 건강 상태를 추정하는 장치.

청구항 16

제13 항에 있어서,

상기 입력 데이터는 복수의 입력 서브 데이터를 기초로 생성되고,

상기 복수의 입력 서브 데이터들은 사용 중인 상기 배터리의 상기 적어도 하나의 파라미터를 미리 설정된 샘플링 주기마다 측정하여 생성되는 상기 적어도 하나의 파라미터의 측정값들에 기초하여 생성되고,

상기 복수의 입력 서브 데이터들 각각은 미리 설정된 제2 시간씩 경과한 후 미리 설정된 제1 시간동안 생성된 상기 적어도 하나의 파라미터의 측정값들에 기초하여 생성되는 배터리의 건강 상태를 추정하는 장치.

청구항 17

제13 항에 있어서,

상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들은 상기 입력 데이터가 상기 복수의 클래스들 각각에 속할 확률 값들인 배터리의 건강 상태를 추정하는 장치.

청구항 18

제13 항에 있어서,

상기 배터리의 건강 상태 값은 상기 복수의 클래스들에 각각 대응하는 상기 복수의 건강 상태 구간들의 대표 값들과 상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들을 각각 곱한 후 모두 가산함으로써 산출되는 배터리의 건강 상태를 추정하는 장치.

청구항 19

제13 항에 있어서,

상기 인공 신경망은 입력층, 적어도 하나의 은닉층, 및 출력층을 포함하고,

상기 출력층은 상기 입력층에 입력되는 상기 입력 데이터가 상기 복수의 클래스들 각각에 속할 확률을 출력하는 소프트맥스 함수를 포함하는 배터리의 건강 상태를 추정하는 장치.

청구항 20

컴퓨팅 장치를 이용하여 제1 항 내지 제12 항 중 어느 한 항의 방법을 실행시키기 위하여 매체에 저장된 컴퓨터 프로그램.

발명의 설명

기술 분야

[0001] 본 발명은 배터리의 건강 상태를 추정하는 방법 및 장치에 관한 것으로서, 더욱 구체적으로는 학습된 인공 신경망을 이용하여 배터리로부터 직접 측정할 수 있는 데이터에 기초하여 배터리의 건강 상태를 추정하는 방법, 컴퓨터 프로그램 및 장치에 관한 것이다.

배경 기술

[0002] 종래의 건강 상태(State of Health, SOH) 추정 알고리즘은 사전에 오프라인으로 배터리의 수명 또는 열화에 대한 데이터를 수집하고, 이를 룩업 테이블(Lookup table) 형태로 저장하여 사용하거나, 수명을 산출하는 수식으로 변환하고 사용 패턴에 따라 계산을 수행함으로써 건강 상태를 추정하거나, 배터리 모델과 추정 알고리즘을 이용하여 배터리의 용량 및 내부 저항을 온라인으로 추정을 하거나, 아니면 오프라인 방식과 온라인 방식, 두가지 방식을 혼합한 방식을 사용하고 있다.

[0003] 그러나, 오프라인에서 확보한 데이터의 범위를 벗어나거나, 온라인에서 추정할 수 있는 배터리 모델의 영역을 벗어날 경우, 건강 상태를 추정을 할 수 없으며, 오프라인 방식과 온라인 방식을 혼합하더라도 이러한 문제를 해결할 수 없다.

발명의 내용

해결하려는 과제

[0004] 본 발명이 해결하고자 하는 과제는 전술한 문제점을 극복하기 위한 것으로서, 학습된 인공 신경망을 이용하여 배터리로부터 직접 측정할 수 있는 데이터에 기초하여 배터리의 건강 상태를 추정하는 방법, 컴퓨터 프로그램 및 장치를 제공하는 것이다.

과제의 해결 수단

[0005] 상술한 기술적 과제들을 달성하기 위한 기술적 수단으로서, 본 발명의 일 측면에 따른 컴퓨팅 장치에 의해 수행되는 배터리의 건강 상태를 추정하는 방법은 미리 학습된 인공 신경망을 준비하는 단계, 배터리의 적어도 하나의 파라미터를 측정하여 입력 데이터를 생성하는 단계, 상기 입력 데이터를 상기 인공 신경망에 입력하여 복수의 클래스들에 각각 대응하는 복수의 출력값들을 획득하는 단계, 및 상기 복수의 클래스들에 각각 대응하는 미리 설정된 복수의 건강 상태 구간들, 및 상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들을 이용하여 상기 배터리의 건강 상태 추정값을 생성하는 단계를 포함한다.

[0006] 일 예에 따르면, 상기 적어도 하나의 파라미터는 상기 배터리의 전압 및 전류를 포함할 수 있다.

[0007] 다른 예에 따르면, 상기 적어도 하나의 파라미터는 상기 배터리의 전압, 전류 및 온도를 포함할 수 있다.

[0008] 또 다른 예에 따르면, 상기 입력 데이터를 생성하는 단계는 사용 중인 상기 배터리의 상기 적어도 하나의 파라미터를 미리 설정된 샘플링 주기마다 측정하는 단계, 및 미리 설정된 제1 시간동안 측정된 상기 적어도 하나의 파라미터의 측정값들에 기초하여 상기 입력 데이터를 생성하는 단계를 할 수 있다.

[0009] 또 다른 예에 따르면, 상기 입력 데이터를 생성하는 단계는 사용 중인 상기 배터리의 상기 적어도 하나의 파라미터를 미리 설정된 샘플링 주기마다 측정하여 상기 적어도 하나의 파라미터의 측정값들을 생성하는 단계, 리 설정된 제2 시간씩 경과한 후 미리 설정된 제1 시간동안 생성된 상기 적어도 하나의 파라미터의 측정값들에 기초하여 복수의 입력 서브 데이터를 생성하는 단계, 및 상기 복수의 입력 서브 데이터를 기초로 상기 입력 데이

터를 생성하는 단계를 포함할 수 있다.

- [0010] 또 다른 예에 따르면, 상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들은 상기 입력 데이터가 상기 복수의 클래스들 각각에 속할 확률 값들일 수 있다.
- [0011] 또 다른 예에 따르면, 상기 배터리의 건강 상태 추정값은 상기 복수의 클래스들에 각각 대응하는 상기 복수의 건강 상태 구간들의 대표 값들과 상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들을 각각 곱한 후 모두 가산함으로써 산출되는 배터리의 건강 상태를 추정하는 방법.
- [0012] 또 다른 예에 따르면, 상기 미리 학습된 인공 신경망을 준비하는 단계는 인공 신경망을 생성하는 단계, 상기 미리 설정된 복수의 건강 상태 구간들 각각에서 상기 배터리의 상기 적어도 하나의 파라미터를 측정하는 측정 데이터들을 준비하는 단계, 상기 측정 데이터들을 이용하여, 각각 자신이 속하는 클래스가 라벨링된 복수의 학습 데이터들을 생성하는 단계, 및 상기 복수의 학습 데이터들을 이용하여 상기 인공 신경망을 학습시키는 단계를 포함할 수 있다.
- [0013] 또 다른 예에 따르면, 상기 복수의 학습 데이터들을 준비하는 단계는 모델 파라미터들을 포함하는 배터리 전기 화학 모델을 준비하는 단계, 상기 측정 데이터들을 이용하여 상기 미리 설정된 복수의 건강 상태 구간들 각각에 대응하는 상기 배터리 전기 화학 모델의 모델 파라미터 데이터들을 생성하는 단계, 상기 모델 파라미터 데이터들 각각이 적용된 상기 배터리 전기 화학 모델에 전류 데이터를 입력하여, 상기 미리 설정된 복수의 건강 상태 구간들 각각에 대응하는 복수의 전압 추정 데이터를 생성하는 단계, 및 상기 전류 데이터 및 상기 복수의 전압 추정 데이터에 기초하여 상기 복수의 학습 데이터를 생성하는 단계를 포함할 수 있다.
- [0014] 또 다른 예에 따르면, 상기 복수의 학습 데이터들을 준비하는 단계는 상기 모델 파라미터 데이터들 각각이 적용된 상기 배터리 전기 화학 모델에 전류 데이터를 입력하여, 상기 미리 설정된 복수의 건강 상태 구간들 각각에 대응하는 복수의 온도 추정 데이터를 더 생성하는 단계, 및 상기 전류 데이터, 상기 복수의 전압 추정 데이터 및 상기 복수의 온도 추정 데이터에 기초하여 상기 복수의 학습 데이터를 생성하는 단계를 더 포함할 수 있다.
- [0015] 또 다른 예에 따르면, 상기 인공 신경망은 다중층 퍼셉트론(multi-layer perceptron; MLP)을 기초로 생성될 수 있다.
- [0016] 또 다른 예에 따르면, 상기 인공 신경망은 입력층, 적어도 하나의 은닉층, 및 출력층을 포함할 수 있다. 상기 출력층은 상기 입력층에 입력되는 상기 입력 데이터가 상기 복수의 클래스들 각각에 속할 확률을 출력하는 소프트맥스 함수를 포함할 수 있다.
- [0017] 상술한 기술적 과제들을 달성하기 위한 기술적 수단으로서, 본 발명의 일 측면에 따른 컴퓨터 프로그램은 컴퓨팅 장치를 이용하여 전술한 배터리의 건강 상태를 추정하는 방법을 실행시키기 위하여 매체에 저장된다.
- [0018] 상술한 기술적 과제들을 달성하기 위한 기술적 수단으로서, 본 발명의 일 측면에 따른 배터리의 건강 상태를 추정하는 장치는 미리 학습된 인공 신경망, 및 배터리의 적어도 하나의 파라미터를 측정함으로써 생성되는 입력 데이터를 저장하는 메모리, 및 상기 입력 데이터를 상기 인공 신경망에 입력하여 복수의 클래스들에 각각 대응하는 복수의 출력값들을 획득하고, 상기 복수의 클래스들에 각각 대응하는 미리 설정된 복수의 건강 상태 구간들, 및 상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들을 이용하여 상기 배터리의 건강 상태 값을 추정하도록 구성되는 적어도 하나의 프로세서를 포함한다.
- [0019] 일 예에 따르면, 상기 적어도 하나의 파라미터는 상기 배터리의 전압 및 전류를 포함하거나, 상기 배터리의 전압, 전류 및 온도를 포함할 수 있다.
- [0020] 다른 예에 따르면, 상기 입력 데이터는 사용 중인 상기 배터리의 상기 적어도 하나의 파라미터를 미리 설정된 샘플링 주기마다 미리 설정된 제1 시간동안 측정하여 생성되는 상기 적어도 하나의 파라미터의 측정값들에 기초하여 생성될 수 있다.
- [0021] 또 다른 예에 따르면, 상기 입력 데이터는 복수의 입력 서브 데이터를 기초로 생성될 수 있다. 상기 복수의 입력 서브 데이터들은 사용 중인 상기 배터리의 상기 적어도 하나의 파라미터를 미리 설정된 샘플링 주기마다 측정하여 생성되는 상기 적어도 하나의 파라미터의 측정값들에 기초하여 생성될 수 있다. 상기 복수의 입력 서브 데이터들 각각은 미리 설정된 제2 시간씩 경과한 후 미리 설정된 제1 시간동안 생성된 상기 적어도 하나의 파라미터의 측정값들에 기초하여 생성될 수 있다.
- [0022] 또 다른 예에 따르면, 상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들은 상기 입력 데이터가 상기

복수의 클래스들 각각에 속할 확률 값들일 수 있다.

[0023] 또 다른 예에 따르면, 상기 배터리의 건강 상태 값은 상기 복수의 클래스들에 각각 대응하는 상기 복수의 건강 상태 구간들의 대표 값들과 상기 복수의 클래스들에 각각 대응하는 상기 복수의 출력값들을 각각 곱한 후 모두 가산함으로써 산출될 수 있다.

[0024] 또 다른 예에 따르면, 상기 인공 신경망은 입력층, 적어도 하나의 은닉층, 및 출력층을 포함할 수 있다. 상기 출력층은 상기 입력층에 입력되는 상기 입력 데이터가 상기 복수의 클래스들 각각에 속할 확률을 출력하는 소프트맥스 함수를 포함할 수 있다.

발명의 효과

[0025] 본 발명에 따르면, 사용 중인 배터리로부터 직접 측정할 수 있는 데이터에 기초하여 학습된 인공 신경망을 이용하여 배터리의 건강 상태를 실시간으로 정확하게 추정할 수 있다.

도면의 간단한 설명

- [0026] 도 1은 본 발명의 일 실시예에 따른 배터리 팩을 개략적으로 도시한다.
- 도 2는 본 발명의 일 실시예에 따른 배터리 컨트롤러(120)의 내부 구성을 개략적으로 도시한다.
- 도 3은 본 발명의 일 실시예에 따른 프로세서(121)의 내부 구성을 개략적으로 도시한다.
- 도 4는 본 발명의 일 실시예에 따른 프로세서(121)의 동작을 설명하기 위한 예시적인 도면이다.
- 도 5는 본 발명의 일 실시예에 따른 입력 데이터(310)를 설명하기 위한 예시적인 도면이다.
- 도 6은 본 발명의 일 실시예에 따른 인공 신경망(320)을 설명하기 위한 예시적인 도면이다.
- 도 7은 본 발명의 일 실시예에 따른 인공 신경망(320)을 학습하는 방법을 설명하기 위한 예시적인 도면이다.
- 도 8a 및 도 8b는 본 발명의 일 실시예에 따라서 입력 데이터(720)를 합성하는 방법을 설명하기 위한 도면이다.
- 도 9a는 예시적인 전류 프로파일을 도시한다. 도 9b와 도 9c는 도 9a의 전류 프로파일을 도 8b의 건강 상태 값들(SOHx)에 각각 대응하는 모델 파라미터 값들(Θ_{SOHx})이 적용된 전기 화학 모델들(820b)에 입력하여 생성되는 합성 전압 데이터와 합성 온도 데이터를 도시한다.
- 도 10a 및 도 10b는 본 발명의 일 실시예에 따라서, 충방전 프로파일에 따라 획득된 측정 데이터(710)를 이용하여 학습시킨 인공 신경망의 클래스 확률 분포를 도시한다.
- 도 11a 및 도 11b는 본 발명의 일 실시예에 따라서, 전류 프로파일에 따른 전류 데이터, 합성 전압 데이터 및 합성 온도 데이터를 포함하는 합성 입력 데이터를 이용하여 학습시킨 인공 신경망의 클래스 확률 분포를 도시한다.

발명을 실시하기 위한 구체적인 내용

[0027] 아래에서는 첨부한 도면을 참조하여 본 개시가 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 다양한 실시예들을 상세히 설명한다. 그러나 본 개시의 기술적 사상은 다양한 형태로 변형되어 구현될 수 있으므로 본 명세서에서 설명하는 실시예들로 제한되지 않는다. 본 명세서에 개시된 실시예들을 설명함에 있어서 관련된 공지 기술을 구체적으로 설명하는 것이 본 개시의 기술적 사상의 요지를 흐릴 수 있다고 판단되는 경우 그 공지 기술에 대한 구체적인 설명을 생략한다. 동일하거나 유사한 구성요소는 동일한 참조 번호를 부여하고 이에 대한 중복되는 설명은 생략하기로 한다.

[0028] 본 명세서에서 어떤 요소가 다른 요소와 "연결"되어 있다고 기술될 때, 이는 "직접적으로 연결"되어 있는 경우 뿐 아니라 그 중간에 다른 요소를 사이에 두고 "간접적으로 연결"되어 있는 경우도 포함한다. 어떤 요소가 다른 요소를 "포함"한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 요소 외에 또 다른 요소를 배제하는 것이 아니라 또 다른 요소를 더 포함할 수 있는 것을 의미한다.

[0029] 일부 실시예들은 기능적인 블록 구성들 및 다양한 처리 단계들로 설명될 수 있다. 이러한 기능 블록들의 일부 또는 전부는 특정 기능을 실행하는 다양한 개수의 하드웨어 및/또는 소프트웨어 구성들로 구현될 수 있다. 예를 들어, 본 개시의 기능 블록들은 하나 이상의 마이크로프로세서들에 의해 구현되거나, 소정의 기능을 위한 회

로 구성들에 의해 구현될 수 있다. 본 개시의 기능 블록들은 다양한 프로그래밍 또는 스크립팅 언어로 구현될 수 있다. 본 개시의 기능 블록들은 하나 이상의 프로세서들에서 실행되는 알고리즘으로 구현될 수 있다. 본 개시의 기능 블록이 수행하는 기능은 복수의 기능 블록에 의해 수행되거나, 본 개시에서 복수의 기능 블록이 수행하는 기능들은 하나의 기능 블록에 의해 수행될 수도 있다. 또한, 본 개시는 전자적인 환경 설정, 신호 처리, 및/또는 데이터 처리 등을 위하여 종래 기술을 채용할 수 있다.

- [0031] 도 1은 본 발명의 일 실시예에 따른 배터리 팩을 개략적으로 도시한다.
- [0032] 도 1을 참조하면, 배터리 팩(100)은 배터리(110), 배터리 컨트롤러(120) 및 스위치(130)를 포함할 수 있다.
- [0033] 배터리(110)는 적어도 하나의 배터리 셀(111)을 포함하며, 배터리 셀(110)은 충전가능한 이차 전지일 수 있다. 예컨대, 배터리 셀(110)은 니켈-카드뮴 전지(nickel-cadmium battery), 납 축전지, 니켈-수소 전지(NiMH: nickel metal hydride battery), 리튬-이온 전지(lithium ion battery), 리튬 폴리머 전지(lithium polymer battery) 등으로 이루어진 그룹으로부터 선택되는 적어도 하나를 포함할 수 있다.
- [0034] 배터리(110)에 포함되는 배터리 셀들(111)의 개수 및 연결 방식은 배터리 팩(100)에 요구되는 전력량 및 전압 등을 기초로 결정될 수 있다. 도 1에는 오로지 개념적인 목적으로 배터리(110)에 포함된 배터리 셀들(111)이 직렬로 연결되는 것으로 도시되지만, 배터리 셀들(111)은 서로 병렬로 연결되거나, 직렬 및 병렬로 연결될 수 있다. 도 1에는 오로지 개념적인 목적으로 배터리 팩(100)이 하나의 배터리(110)를 포함하는 것으로 도시되지만, 직렬, 병렬 또는 직렬과 병렬로 연결되는 복수의 배터리(110)를 포함할 수 있다. 배터리(110)는 오직 하나의 배터리 셀(111)을 포함할 수도 있다.
- [0035] 배터리(110)는 각각 복수의 배터리 셀들(111)로 구성되는 복수의 배터리 모듈들을 포함할 수 있다. 배터리 팩(100)은 전기 부하 또는 충전 장치가 연결될 수 있는 한 쌍의 팩 단자(101, 102)를 포함한다.
- [0036] 본 명세서에서 건강 상태를 추정하는 대상으로서 배터리는 배터리(110)일 수도 있고, 배터리(110)에 포함되는 적어도 하나의 배터리 셀(111) 각각일 수도 있다. 본 명세서에서는 하나의 배터리의 건강 상태를 추정하는 방법에 대하여 설명하지만, 배터리(110)에 포함되는 복수의 배터리 셀들(111) 각각의 건강 상태를 추정하는 방법에도 동일하게 적용될 수 있다.
- [0037] 스위치(130)는 배터리(110)와 팩 단자들(101, 102) 중 하나(예컨대, 101)사이에 연결된다. 스위치(130)는 배터리 컨트롤러(120)에 의해 제어될 수 있다.
- [0038] 배터리 컨트롤러(120)는 배터리(110)를 관리할 수 있다. 배터리 컨트롤러(120)는 배터리(110)의 충전 상태, 충전 전류 등을 관리할 수 있다. 예컨대, 배터리 컨트롤러(120)는 배터리(110)의 배터리 셀들(111) 각각의 셀 전압을 측정하고, 배터리(110)의 온도를 측정하고, 배터리(110)의 충전 전류를 측정할 수 있다. 배터리 컨트롤러(120)는 배터리 셀들(111)의 셀 전압을 균등화할 수도 있다. 배터리 컨트롤러(120)는 배터리(110)가 과충전, 과방전, 또는 고온 상태가 되면, 이를 감지하고 스위치(130)를 개방시킬 수도 있다.
- [0039] 배터리 컨트롤러(120)는 배터리(110)로부터 측정된 데이터를 이용하여 배터리(110)의 건강 상태를 추정할 수 있다. 배터리(110)로부터 측정된 데이터는 배터리 셀들(111) 각각의 셀 전압, 배터리(110)의 단자 전압, 배터리 셀(110)의 충전 전류, 배터리(110)의 온도 중 적어도 하나를 포함할 수 있다. 배터리 컨트롤러(120)가 배터리(110)의 건강 상태를 추정하는 방법에 대해서는 아래에서 더욱 자세히 설명한다.
- [0040] 도 1에 도시되지 않았지만, 배터리 팩(100)은 배터리 보호 회로, 퓨즈, 전류 센서 등을 더 포함할 수 있다.
- [0042] 도 2는 본 발명의 일 실시예에 따른 배터리 컨트롤러(120)의 내부 구성을 개략적으로 도시한다.
- [0043] 도 2를 참조하면, 배터리 컨트롤러(120)는 프로세서(121) 및 메모리(123)를 포함한다.
- [0044] 프로세서(121)는 배터리 컨트롤러(120)의 전반적인 동작을 제어한다. 프로세서(121)는 기본적인 산술, 로직 및 입출력 연산을 수행하고, 예컨대 메모리(123)에 저장된 프로그램 코드, 예컨대, 미리 학습된 인공 신경망을 실행할 수 있다. 프로세서(121)는 데이터를 메모리(121)에 저장하거나, 메모리(121)에 저장된 데이터를 로딩할 수 있다.
- [0045] 메모리(123)는 프로세서(121)가 판독할 수 있는 기록 매체로서, RAM, ROM 및 디스크 드라이브와 같은 비소멸성

대용량 기록장치(permanent mass storage device)를 포함할 수 있다. 메모리(123)에는 운영체제와 적어도 하나의 프로그램 또는 어플리케이션 코드가 저장될 수 있다. 메모리(123)에는 본 발명의 일 실시예에 따라서 배터리의 건강 상태를 추정하기 위해 미리 학습된 인공 신경망을 구현하기 위한 프로그램 코드가 저장될 수 있다. 메모리(123)에는 배터리(110)의 적어도 하나의 파라미터를 측정함으로써 생성되는 입력 데이터가 저장될 수 있다. 메모리(123)에는 배터리(110)의 적어도 하나의 파라미터를 측정함으로써 생성되는 입력 데이터를 이용하여 인공 신경망을 추가로 학습시키기 위한 프로그램 코드가 저장될 수 있다. 배터리(110)의 적어도 하나의 파라미터는 배터리(110)의 단자 전압, 충전전 전류, 및/또는 주변 온도와 같은 요소(component) 또는 변수(variable)를 의미한다.

[0046] 배터리 컨트롤러(120)는 배터리(110)의 적어도 하나의 파라미터를 측정하기 위한 센싱 모듈을 더 포함할 수 있다. 배터리 컨트롤러(120)는 차량의 전자 제어 장치, 충전 장치의 컨트롤러 등과 같은 다른 장치와 통신하기 위한 통신 모듈을 더 포함할 수 있다.

[0048] 도 3은 본 발명의 일 실시예에 따른 프로세서(121)의 내부 구성을 개략적으로 도시한다.

[0049] 도 3을 참조하면, 프로세서(121)는 인공 신경망(320) 및 건강 상태 추정부(330)를 포함한다. 인공 신경망(320)과 건강 상태 추정부(330)는 프로세서(121)에 의해 구현될 수 있다.

[0050] 인공 신경망(320)에 입력 데이터(310)가 입력될 수 있다. 인공 신경망(320)은 입력 데이터(310)에 대응하여, 복수의 클래스들에 각각 대응하는 복수의 출력값들을 출력할 수 있다. 건강 상태 추정부(330)는 인공 신경망(320)이 출력한 복수의 출력값들, 및 복수의 클래스들에 각각 대응하는 미리 설정된 복수의 건강 상태 구간들에 기초하여 배터리(110)의 건강 상태 추정값을 생성할 수 있다.

[0051] 입력 데이터(310)는 배터리(110)의 적어도 하나의 파라미터를 측정된 측정 데이터로부터 생성될 수 있다. 적어도 하나의 파라미터는 배터리(110)의 전압 및 전류일 수 있다. 적어도 하나의 파라미터는 배터리(110)의 전압, 전류 및 온도일 수 있다. 적어도 하나의 파라미터는 배터리(110)의 누적 사용 시간, 또는 충전전 횟수 등을 더 포함할 수도 있다.

[0052] 아래에서는 배터리(110)의 적어도 하나의 파라미터가 배터리(110)의 전압, 전류 및 온도인 실시예들에 대해서 설명한다. 이 경우, 배터리(110)의 적어도 하나의 파라미터를 측정된 측정 데이터는 배터리(110)의 전압 데이터, 전류 데이터, 및 온도 데이터를 포함한다.

[0053] 배터리(110)의 전압 데이터, 전류 데이터, 및 온도 데이터는 시계열 데이터로서, 미리 설정된 샘플링 주기마다 측정된 전압 값들, 전류 값들 및 온도 값들을 포함한다. 미리 설정된 샘플링 주기는 예컨대, 1초일 수 있다. 그러나, 샘플링 주기는 1초보다 짧거나 길 수도 있다. 배터리(110)의 전압 데이터, 전류 데이터, 및 온도 데이터는 아래에서 측정 데이터로 통칭할 수 있다.

[0054] 입력 데이터(310)는 배터리(110)의 측정 데이터 중에서 미리 설정된 윈도우 크기에 해당하는 일부의 측정 데이터들을 포함할 수 있다. 윈도우 크기는 샘플링 주기의 L(L은 자연수) 배에 해당하는 제1 시간에 대응할 수 있다. 입력 데이터(310)는 미리 설정된 제1 시간동안 측정된 적어도 하나의 파라미터의 측정값들에 기초하여 생성될 수 있다. 다른 예에 따르면, 입력 데이터(310)는 배터리(110)의 측정 데이터를 전처리한 데이터들을 포함할 수 있다. 전처리는 예컨대, 노이즈를 제거하기 위한 필터링 및/또는 전압 데이터, 전류 데이터, 및 온도 데이터 각각의 평균과 분산을 일정하게 하기 위한 정규화를 포함할 수 있다.

[0055] 입력 데이터(310)가 인공 신경망(320)에 입력되면, 인공 신경망(320)은 입력 데이터(310)에 대응하여 복수의 클래스들에 각각 대응하는 복수의 출력값들을 출력할 수 있다. 본 명세서에서 복수의 클래스들은 미리 설정된 복수의 건강 상태 구간들에 각각 대응할 수 있다. 예컨대, 인공 신경망(320)은 6개의 클래스에 각각 대응하는 6개의 출력값들을 출력하는 경우, 제1 내지 제6 클래스는 각각 99% 내지 100%의 제1 건강 상태 구간, 89% 내지 91%의 제2 건강 상태 구간, 79% 내지 81%의 제3 건강 상태 구간, 69% 내지 71%의 제4 건강 상태 구간, 59% 내지 61%의 제5 건강 상태 구간, 및 49% 내지 51%의 제6 건강 상태 구간에 대응할 수 있으며, 제1 내지 제6 건강 상태 구간의 대표값은 각각 100%, 90%, 80%, 70%, 60%, 및 50%일 수 있다.

[0056] 입력 데이터(310)가 입력된 인공 신경망(320)이 출력하는 복수의 클래스들에 각각 대응하는 복수의 출력값들은 입력 데이터(310)가 복수의 클래스들 각각에 속할 확률 값들일 수 있다. 위의 예에서, 제1 출력값은 입력 데이터(310)를 취득한 배터리(110)의 건강 상태가 제1 건강 상태 구간, 예컨대, 99% 내지 100%에 속할 확률 값을 의

미하고, 제2 출력값은 입력 데이터(310)를 취득한 배터리(110)의 건강 상태가 제2 건강 상태 구간, 예컨대, 89% 내지 91%에 속할 확률 값을 의미하고, 제3 출력값은 입력 데이터(310)를 취득한 배터리의 건강 상태(110)가 제3 건강 상태 구간, 예컨대, 79% 내지 81%에 속할 확률 값을 의미하고, 제4 출력값은 입력 데이터(310)를 취득한 배터리(110)의 건강 상태가 제4 건강 상태 구간, 예컨대, 69% 내지 71%에 속할 확률 값을 의미하고, 제5 출력값은 입력 데이터(310)를 취득한 배터리(110)의 건강 상태가 제5 건강 상태 구간, 예컨대, 59% 내지 61%에 속할 확률 값을 의미하고, 제6 출력값은 입력 데이터(310)를 취득한 배터리(110)의 건강 상태가 제6 건강 상태 구간, 예컨대, 49% 내지 51%에 속할 확률 값을 의미한다.

[0057] 예컨대, 입력 데이터(310)가 80%의 건강 상태인 배터리(110)로부터 획득된 데이터인 경우, 인공 신경망(320)은 제3 건강 상태 구간, 예컨대, 79% 내지 81%에 속할 확률 값에 해당하는 제3 출력값이 상대적으로 높을 것이고, 제1 및 제2, 제4 내지 제6 출력값은 상대적으로 매우 낮을 것이다. 예컨대, 입력 데이터(310)가 95%의 건강 상태인 배터리(110)로부터 획득된 데이터인 경우, 인공 신경망(320)은 제1 및 제2 출력값이 상대적으로 높을 것이고, 제3 내지 제6 출력값은 상대적으로 매우 낮을 것이다.

[0058] 건강 상태 추정부(330)는 인공 신경망(320)으로부터 복수의 출력값들을 수신하고, 복수의 출력값들에 기초하여 배터리(110)의 건강 상태 추정값을 생성할 수 있다.

[0059] 예를 들면, 건강 상태 추정부(330)는 복수의 클래스들에 각각 대응하는 복수의 건강 상태 구간들의 대표 값들과 인공 신경망(320)으로부터 수신되는 복수의 출력값들을 각각 곱한 후 모두 가산함으로써 건강 상태 추정값을 산출할 수 있다. 예를 들면, 제1 내지 제4 출력값이 0이고, 제5 출력값이 0.3이고, 제6 출력값이 0.7인 경우, 제5 클래스에 대응하는 제5 건강 상태 구간의 대표 값인 60%와 0.3을 곱한 값과, 제6 클래스에 대응하는 제6 건강 상태 구간의 대표 값인 50%와 0.7을 곱한 값을 가산한 값인 53%가 입력 데이터(310)를 취득한 배터리(110)의 건강 상태 추정값으로 결정될 수 있다.

[0061] 도 4는 본 발명의 일 실시예에 따른 프로세서(121)의 동작을 설명하기 위한 예시적인 도면이다.

[0062] 도 4를 참조하면, 인공 신경망(320)에 입력 데이터(310)가 입력될 수 있다. 입력 데이터(310)는 배터리(110)의 적어도 하나의 파라미터를 미리 설정된 샘플링 주기로 측정된 측정값들의 시계열 데이터일 수 있다. 배터리(110)는 100%의 건강 상태를 가질 수도 있고, 80%의 건강 상태를 가질 수도 있다. 도 4에서 입력 데이터(310)로서 도시된 "SOH x"은 x%의 건강 상태의 배터리(110)로부터 생성된 입력 데이터(310)를 의미한다. 본 실시예에서, 입력 데이터(310)는 배터리(110)의 전압 데이터(V), 전류 데이터(I) 및 온도 데이터(T)를 포함하는 것으로 예시한다.

[0063] 인공 신경망(320)은 입력층, 적어도 하나의 은닉층 및 출력층을 포함할 수 있다. 인공 신경망(320)은 다중층 퍼셉트론(multi-layer perceptron; MLP)을 기반으로 생성될 수 있으며, 출력층은 복수의 노드를 포함할 수 있다. 인공 신경망(320)에서 출력되는 출력 값은 클래스들 각각(즉, SOH_x)에 속할 확률 값(P(SOH_x))일 수 있다. 본 실시예에서, x는 100, 95, 90, 85, 80으로 예시하며, 출력층의 노드는 5개일 수 있다. 본 실시예에서, 클래스의 개수는 5개이며, 클래스들 각각은 SOH100, SOH95, SOH90, SOH85, SOH80에 대응할 수 있다. SOH_x는 건강 상태가 x%임을 의미하며, x%의 값을 갖는 것으로 이해될 수 있다. 인공 신경망(320)의 출력 값들은 도 4의 건강 상태 추정부(330)에 도시된 바와 같이 SOH100, SOH95, SOH90, SOH85, 및 SOH80 각각에 속할 확률 값들(P(SOH100), P(SOH95), P(SOH90), P(SOH85), P(SOH80))일 수 있다.

[0064] 건강 상태 추정부(330)는 SOH_x와 P(SOH_x)의 곱을 모든 x에 대해 가산한 값을, 입력 데이터(310)가 추출된 배터리(110)의 건강 상태 추정 값(SOH_{est})으로 결정할 수 있다. 즉, 건강 상태 추정 값(SOH_{est})은 $\sum SOH_x \cdot P(SOH_x)$ 와 같은 수식에 의해 산출될 수 있다.

[0066] 도 5는 본 발명의 일 실시예에 따른 입력 데이터(310)를 설명하기 위한 예시적인 도면이다.

[0067] 도 5를 참조하면, 입력 데이터(310)는 미리 설정된 샘플링 주기(1 step)마다 측정된 배터리(110)의 전압 값들(V_t), 전류 값들(I_t), 및 온도 값들(T_t)로부터 생성될 수 있다. 입력 데이터(310)는 시계열 데이터로서, 예컨대 배터리(110)의 전압 데이터(V), 전류 데이터(I) 및 온도 데이터(T)를 포함할 수 있다.

[0068] 일 예에 따르면, 입력 데이터(310)는 미리 설정된 윈도우 크기(L = n+1 steps)를 가질 수 있다. 입력 데이터(310)는 L개의 전압 값들(V_{t-n}, ..., V_t), L개의 전류 값들(I_{t-n}, ..., I_t), 및 L개의 온도 값들(T_{t-n}, ..., T_t)

을 포함할 수 있다.

[0069] 다른 예에 따르면, 입력 데이터(310)는 미리 설정된 윈도우 스트라이드(m steps)에 의해 구별되는 복수의 입력 서브 데이터(311, 312)를 포함할 수 있다. 윈도우 스트라이드(m steps)만큼 윈도우를 이동시키면서, 미리 설정된 샘플링 주기(1 step)마다 측정된 배터리(110)의 전압 값들(Vt), 전류 값들(I_t), 및 온도 값들(T_t)로부터 복수의 입력 서브 데이터(311, 312) 각각이 선택될 수 있다.

[0070] 입력 서브 데이터(311)는 L개의 전압 값들(V_{t-n}, 썸, V_t), L개의 전류 값들(I_{t-n}, 썸, I_t), 및 L개의 온도 값들(T_{t-n}, 썸, T_t)을 포함할 수 있다. 입력 서브 데이터(312)는 L개의 전압 값들(V_{t-n+m}, 썸, V_{t+m}), L개의 전류 값들(I_{t-n+m}, 썸, I_{t+m}), 및 L개의 온도 값들(T_{t-n+m}, 썸, T_{t+m})을 포함할 수 있다. 윈도우 스트라이드가 m이므로, 입력 데이터(310)에 포함되는 다른 입력 서브 데이터는 L개의 전압 값들(V_{t-n+2m}, 썸, V_{t+2m}), L개의 전류 값들(I_{t-n+2m}, 썸, I_{t+2m}), 및 L개의 온도 값들(T_{t-n+2m}, 썸, T_{t+2m})을 포함할 수 있다. 입력 서브 데이터들(311, 312)은 (L-m)/L만큼 중복되고, m/L만큼 서로 상이하다. 입력 데이터(310)가 복수의 입력 서브 데이터(311, 312)를 포함할 경우, 측정 노이즈와 같은 노이즈 성분이 상대적으로 감소되므로, 건강 상태 추정 값(SOHest)의 신뢰도와 정확도는 더 높아질 수 있다.

[0071] 오로지 예시적으로 윈도우 크기(L)는 180일 수 있고, 윈도우 스트라이드(m)는 10 또는 3일 수 있으나, 이러한 수치는 본 발명을 한정하지 않는다.

[0073] 도 6은 본 발명의 일 실시예에 따른 인공 신경망(320)을 설명하기 위한 예시적인 도면이다.

[0074] 도 6을 참조하면, 인공 신경망(320)은 입력층(321), 적어도 하나의 은닉층(322) 및 출력층(323)을 포함할 수 있다. 인공 신경망(320)은 다중층 퍼셉트론(multi-layer perceptron; MLP)을 기반으로 생성될 수 있으며, 미리 학습될 수 있다.

[0075] 입력층(321)은 입력 데이터(310)의 값들에 대응하는 개수의 노드를 포함할 수 있다. 입력 데이터(310)의 윈도우 크기가 L이고, 입력 데이터(310)는 전압 데이터, 전류 데이터, 및 온도 데이터를 포함하므로, 입력층(321)은 3L개의 노드들을 포함할 수 있다.

[0076] 적어도 하나의 은닉층(322)은 입력층(321)과 출력층(323) 사이에 위치한다. 은닉층(322)의 개수는 예컨대, 3개 또는 4개일 수 있으나, 본 발명을 한정하지 않는다. 첫번째 은닉층(322a)의 노드들은 입력층(321)의 노드들과 완전히 연결될 수 있고, 마지막 은닉층(322b)의 노드들은 출력층(323)의 노드들과 완전히 연결될 수 있다. 첫번째 은닉층(322a)은 오로지 예시적으로 2048개의 노드들을 포함할 수 있고, 마지막 은닉층(322b)은 오로지 예시적으로 256 또는 512개의 노드들을 포함할 수 있다.

[0077] 출력층(323)은 클래스의 개수에 대응하는 개수의 노드들을 가질 수 있다. 도 4를 참조로 앞에서 설명한 예시에 따르면, 출력층(323)은 5개의 출력 노드들(SOH100, SOH95, SOH90, SOH85, SOH80)을 포함할 수 있다. 그러나 이는 오로지 예시적이며 출력층(323)의 노드 개수는 본 발명을 한정하지 않는다.

[0078] 출력층(323)은 입력 데이터(310)가 클래스들 각각에 속할 확률을 출력하는 소프트맥스 함수를 포함할 수 있다. 다른 예에 따라서, 입력 데이터(310)가 복수의 입력 서브 데이터를 포함하는 경우, 출력층(323)은 복수의 입력 서브 데이터 각각이 클래스들 각각에 속할 평균 확률을 출력하는 소프트맥스 함수를 포함할 수 있다. 출력층(323)의 제k 출력 노드의 출력 값(P_{mean,k})은 소프트맥스 함수를 이용하여 다음의 수식으로 표현될 수 있다.

$$P_{mean,k} = \frac{1}{N} \sum_{n=1}^N \left(\frac{e^{X_n^T w_k}}{\sum_{j=1}^5 e^{X_n^T w_j}} \right)$$

[0079]

[0080] 여기서, P_{mean,k}는 입력 데이터(310) 내의 모든 입력 서브 데이터가 제k 클래스에 속할 확률의 평균 값을 의미한다. N은 입력 데이터(310)에 포함되는 입력 서브 데이터의 개수이고, X는 출력층(323)의 입력 벡터이며, X_n은 n에 해당하는 입력 서브 데이터가 입력될 때 출력층(323)의 입력 벡터를 의미한다. W는 마지막 은닉층(322b)과 출력층(323) 사이의 가중치 행렬을 의미하며, W_k는 마지막 은닉층(322b)의 노드들과 출력층(323)의 제k 노드 사이의 가중치 행렬을 의미한다. 위 수식은 클래스의 개수가 5개인 경우의 수식이다.

[0081] 건강 상태 추정부(도 4의 330)는 출력층(323)의 출력 노드들에서 출력되는 출력 값(P_{mean,k})을 이용하여 건강

상태 추정 값(E_{SOH})을 결정할 수 있다. 예를 들면, 건강 상태 추정 값(E_{SOH})은 다음의 수식에 의해 산출될 수 있다.

$$E_{SOH} = SOH^T \cdot P_{mean}$$

[0082]

여기서, 벡터 SOH는 제1 내지 제k 클래스들에 각각 대응하는 제1 내지 제k SOH 값들의 벡터이고, 벡터 Pmean은 출력 값($P_{mean,k}$)의 벡터이다. 예를 들면, 위의 예에서, 벡터 SOH는 (100, 95, 90, 85, 50)일 수 있고, 벡터 Pmean는 ($P_{mean,1}$, $P_{mean,2}$, $P_{mean,3}$, $P_{mean,4}$, $P_{mean,5}$)일 수 있다.

[0084]

아래에서는 미리 학습된 인공 신경망을 준비하는 방법에 대하여 설명한다.

[0086]

도 7은 본 발명의 일 실시예에 따른 인공 신경망(320)을 학습하는 방법을 설명하기 위한 예시적인 도면이다.

[0087]

도 7을 참고하면, 학습할 인공 신경망(도 6의 320)이 준비될 수 있다. 인공 신경망(320)은 예컨대 도 6에 도시된 바와 같이 디자인될 수 있다.

[0088]

미리 설정된 복수의 건강 상태 구간들 각각에서 배터리(110)의 적어도 하나의 파라미터를 측정된 측정 데이터(710)를 획득할 수 있다. 복수의 건강 상태 구간들은 예컨대, 99.5% 내지 100%의 제1 건강 상태 구간, 94.5% 내지 95.5%의 제2 건강 상태 구간, 89.5% 내지 90.5%의 제3 건강 상태 구간, 84.5% 내지 85.5%의 제4 건강 상태 구간, 및 79.5% 내지 80.5%의 제5 건강 상태 구간과 같이 미리 설정될 수 있다. 적어도 하나의 파라미터는 예컨대 전압, 전류, 온도일 수 있다. 측정 데이터(710)는 미리 알고 있는 건강 상태 값의 배터리(110)로부터 미리 설정된 샘플링 주기로 획득되는 시계열 데이터이다. 측정 데이터(710)는 도 5에 도시된 바와 같이 시간 순서대로 나열되는 전압 값들을 포함하는 전압 데이터, 시간 순서대로 나열되는 전류 값들을 포함하는 전류 데이터, 및 시간 순서대로 나열되는 온도 값들을 포함하는 온도 데이터를 포함할 수 있다.

[0089]

일 실시예에 따르면, 측정 데이터(710)는 미리 설정한 충방전 프로파일에 따라 배터리(110)를 충전 및 방전시키면서 측정된 전압 값들, 전류 값들 및 온도 값들을 포함할 수 있다. 충방전 프로파일은 1C로 정전류 충전하는 단계; 셀 전압이 4.1V가 되면 4.1V로 정전압 충전하는 단계; 및 충전 전류가 145mA가 되면 충전을 중단하고 10분간 휴지하는 단계를 포함할 수 있다. 충방전 프로파일은 0.5C 또는 1C로 정전류 방전하는 단계; 셀 전압이 3.0V가 되면 방전을 중단하고 10분간 휴지하는 단계를 포함할 수 있다.

[0090]

측정 데이터(710)에 기초하여 입력 데이터(720)를 생성할 수 있다. 입력 데이터(720) 중 일부는 학습 데이터(721)이고 나머지 일부는 시험 데이터(723)일 수 있다. 입력 데이터(720)는 도 5에 도시된 바와 같이 L의 윈도우 크기에 대응하는 데이터를 선택한 후, 미리 알고 있던 건강 상태 값을 라벨링함으로써 생성될 수 있다. 입력 데이터(720)는 (V_{t-L+1} , I_{t-L+1} , T_{t-L+1} , 플 , V_t , I_t , T_t)일 수 있으며, 해당 측정 값들이 획득된 배터리의 건강 상태값(SOH_x)가 라벨링될 수 있다. 입력 데이터(720)는 (V_t , I_t , T_t)_L로 표시한다. 건강 상태 값은 복수의 클래스 중에서 대응하는 클래스의 식별 번호의 형태로 입력 데이터(720)에 라벨링될 수 있다.

[0091]

입력 데이터(720) 중 학습 데이터(721)를 이용하여 인공 신경망(320)을 학습시킬 수 있다. 도 7에 도시된 바와 같이, 인공 신경망(320)은 제1 내지 제5 건강 상태 구간에 각각 대응하는 학습 데이터(721)을 분류할 수 있다. 인공 신경망(320)은 학습 데이터(721)를 구별하도록 학습(730)이 수행될 수 있다. 인공 신경망(320)은 미리 설정한 오차가 최소화되도록 내부의 가중치들을 결정하는 과정을 반복함으로써 학습(730)이 수행될 수 있다. 도 7에서, SOH_{100} 은 100%의 건강 상태 값이 라벨링된 학습 데이터를 의미한다.

[0092]

도 7에 도시된 바와 같이, 학습된 인공 신경망(320)은 시험 데이터(723)를 이용하여 검증(740)될 수 있다. 시험 데이터(723)를 학습된 인공 신경망(320)에 입력한 결과를 시험 데이터(723)에 라벨링된 건강 상태 값과 비교할 수 있다.

[0093]

본 발명에 따르면, 인공 신경망(320)을 학습하는데, 모든 건강 상태 구간에 대해 측정 데이터(710)를 획득하지 않고, 미리 설정된 건강 상태 구간에 대해서만 측정 데이터(710)가 획득될 수 있다. 측정 데이터(710)를 획득하고, 해당 측정 데이터(710)를 획득한 배터리(110)의 건강 상태 값을 알기 위해서는 매번 기준 성능 시험(RPT, reference performance test)이 수행되어야 한다. 기준 성능 시험을 수행하는데 상당한 시간과 비용이 필요하다. 기준 성능 시험은 초기화 단계 및 용량 측정 단계를 포함할 수 있다. 초기화 단계는 배터리를 1C로 1시간 동안 충전하는 단계, 및 1시간 휴지하는 단계를 포함할 수 있다. 용량 측정 단계는 배터리를 0.04C로 25시간

동안 방전하는 단계, 1시간 휴지하는 단계, 배터리를 0.04C로 25시간 동안 충전하는 단계, 및 1시간 휴지하는 단계를 포함할 수 있다. 기준 성능 시험에 총 54시간이 소요될 수 있다. 기준 성능 시험을 수행하는 과정에서도 배터리(110)가 열화될 수 있다. 본 발명에 따르면 미리 설정된 건강 상태 구간에 대해서만 측정 데이터(710)를 획득하기 때문에 상당한 시간과 비용을 필요로 하는 기준 성능 시험의 횟수를 감소시킬 수 있다.

- [0095] 도 8a 및 도 8b는 본 발명의 일 실시예에 따라서 입력 데이터(720)를 합성하는 방법을 설명하기 위한 도면이다.
- [0096] 도 8a를 참조하면, 모델 파라미터들을 포함하는 배터리 전기 화학 모델(820a)이 생성될 수 있다. 일 실시예에 따라서, 충전 프로파일 데이터(810)는 미리 설정한 충전 프로파일에 따라 배터리(110)를 충전 및 방전시키면서 측정한 전압 값들, 전류 값들 및 온도 값들을 포함할 수 있다. 충전 프로파일 데이터(810)는 도 7의 입력 데이터(720)에 대응할 수 있다. 충전 프로파일 데이터(810)에는 건강 상태값(SOHx)이 라벨링될 수 있다.
- [0097] 건강 상태값(SOHx)이 라벨링된 충전 프로파일 데이터(810)는 전기 화학 모델(820a)이 입력되고, 예컨대 하모니 검색(harmony search)과 같은 최적화 알고리즘을 이용하여 건강 상태값(SOHx)에 대응하는 모델 파라미터 값들(830)이 결정될 수 있다. 건강 상태값들(SOHx)에 각각 대응하는 모델 파라미터 값들(Θ_{SOHx})이 결정될 수 있다.
- [0098] 배터리 전기 화학 모델(820a)의 모델 파라미터들은 예컨대 고체 입자 전위, 전해질 전위 유효 고체 입자 전도도, 고체 입자 전도도, 두께, 인가 전류, 이온 플럭스, 고체 입자 표면적, 고체 입자 반지름, 전극 표면적, 유효 고체 입자 확산 계수, 고체 입자 확산 계수, 유효 전해질 확산 계수, 고체 입자 내의 리튬 농도, 전해질 내의 리튬 이온 농도, 최대 고체 입자 농도, 표면 농도, 전해질 확산 계수 등 중에서 선택될 수 있다.
- [0099] 도 8b를 참조하면, 건강 상태값들(SOHx)에 각각 대응하는 모델 파라미터 값들(Θ_{SOHx})이 적용된 전기 화학 모델들(820b)이 준비될 수 있다. 미리 설정된 전류 프로파일(840)에 따른 전류 데이터를 모델 파라미터 값들(Θ_{SOHx})이 적용된 전기 화학 모델들(820b)에 입력하여, 건강 상태값들(SOHx)에 각각 대응하는 합성 전압 데이터(V_{SOHx})를 생성할 수 있다. 또한, 건강 상태값들(SOHx)에 각각 대응하는 합성 온도 데이터(T_{SOHx})도 함께 생성될 수 있다.
- [0100] 측정 데이터(710) 대신에, 미리 설정된 전류 프로파일(840)에 따른 전류 데이터, 합성 전압 데이터(V_{SOHx}) 및 합성 온도 데이터(T_{SOHx})를 이용하여 도 7의 입력 데이터(720)가 생성될 수 있다.
- [0101] 미리 설정된 전류 프로파일(840)은 배터리(110)가 적용될 장치의 사용 패턴에 따라 설정될 수 있다. 예컨대, 차량에 적용할 배터리(110)라면, 차량의 표준 속도 프로파일을 이용하여 전류 프로파일(840)을 생성할 수 있다. 도 9a는 예시적인 전류 프로파일을 도시한다. 도 9b와 도 9c는 도 9a의 전류 프로파일을 도 8b의 건강 상태값들(SOHx)에 각각 대응하는 모델 파라미터 값들(Θ_{SOHx})이 적용된 전기 화학 모델들(820b)에 입력하여 생성되는 합성 전압 데이터와 합성 온도 데이터를 도시한다.
- [0103] 도 10a 및 도 10b는 본 발명의 일 실시예에 따라서, 충전 프로파일에 따라 획득된 측정 데이터(710)를 이용하여 학습시킨 인공 신경망의 클래스 확률 분포를 도시한다.
- [0104] 도 10a를 참조하면, 클래스 1은 99.5% 내지 100%의 제1 건강 상태 구간에 대응하고, 클래스 2는 94.5% 내지 95.5%의 제2 건강 상태 구간에 대응하고, 클래스 3은 89.5% 내지 90.5%의 제3 건강 상태 구간에 대응하고, 클래스 4는 84.5% 내지 85.5%의 제4 건강 상태 구간에 대응하고, 클래스 5는 79.5% 내지 80.5%의 제5 건강 상태 구간에 대응한다.
- [0105] SOH 100은 제1 건강 상태 구간에 속하는 건강 상태 값을 갖는 배터리로부터 획득한 입력 데이터를 인공 신경망에 입력한 결과를 나타낸다. 도시된 바와 같이, 클래스 1에 속할 확률이 가장 높고, 클래스 2 내지 4에 속할 확률은 매우 낮다. SOH 95는 제2 건강 상태 구간에 속하는 건강 상태 값을 갖는 배터리로부터 획득한 입력 데이터를 인공 신경망에 입력한 결과를 나타낸다. 도시된 바와 같이, 클래스 2에 속할 확률이 가장 높고, 나머지 클래스들에 속할 확률은 매우 낮다. SOH 90은 제3 건강 상태 구간에 속하는 건강 상태 값을 갖는 배터리로부터 획득한 입력 데이터를 인공 신경망에 입력한 결과를 나타낸다. 도시된 바와 같이, 클래스 3에 속할 확률이 가장 높고, 나머지 클래스들에 속할 확률은 매우 낮다. SOH 85는 제4 건강 상태 구간에 속하는 건강 상태 값을

갖는 배터리로부터 획득한 입력 데이터를 인공 신경망에 입력한 결과를 나타낸다. 도시된 바와 같이, 클래스 4에 속할 확률이 가장 높고, 나머지 클래스들에 속할 확률은 매우 낮다. SOH 80은 제5 건강 상태 구간에 속하는 건강 상태 값을 갖는 배터리로부터 획득한 입력 데이터를 인공 신경망에 입력한 결과를 나타낸다. 도시된 바와 같이, 클래스 5에 속할 확률이 가장 높고, 나머지 클래스들에 속할 확률은 매우 낮다.


- [0106] 도 10b는 100%, 95%, 90%, 85%, 80% 외의 다른 건강 상태 값을 갖는 배터리로부터 획득한 입력 데이터를 인공 신경망에 입력한 결과를 나타낸다. 도 10b에 도시된 바와 같이, 특정 건강 상태 값에 대응하는 입력 데이터가 입력될 경우, 특정 건강 상태 값에 인접한 클래스들의 확률이 높으며, 더 인접한 클래스의 확률이 더 높다.
- [0107] 인공 신경망의 결과를 이용하여 건강 상태 추정 값을 생성하는 건강 상태 추정부(도 4의 330)는 $\sum SOH_x \cdot P(SOH_x)$ 와 같은 수식을 이용하여 건강 상태 추정 값을 산출할 수 있다. 이렇게 산출하는 경우, 실제 건강 상태 값과 건강 상태 추정 값의 평균 오차율은 1.6%이었고, 최대 오차율은 3.8%이었다.
- [0109] 도 11a 및 도 11b는 본 발명의 일 실시예에 따라서, 전류 프로파일에 따른 전류 데이터, 합성 전압 데이터 및 합성 온도 데이터를 포함하는 합성 입력 데이터를 이용하여 학습시킨 인공 신경망의 클래스 확률 분포를 도시한다.
- [0110] 도 11a에 도시된 결과는 도 10a에 도시된 결과와 유사하고, 도 11b에 도시된 결과 역시 도 10b에 도시된 결과와 유사하였다. 합성 입력 데이터를 이용한 경우, 실제 건강 상태 값과 건강 상태 추정 값의 평균 오차율은 0.49%이었고, 최대 오차율은 1.87%이었다.
- [0112] 본 발명에 따르면 인공 신경망을 학습하는데 필요한 기준 성능 시험의 시행 횟수를 감소시킬 수 있다. 종래에 20번 이상 기준 성능 시험이 시행되어야 했지만, 본 발명에 따르면 5번의 기준 성능 시험이 수행되면 된다. 이렇게 감소된 기준 성능 시험에도 불구하고, 인공 신경망이 각 클래스에 속할 확률을 출력하도록 설계하고, 해당 확률을 이용하여 건강 상태 추정값을 산출하더라도, 실제 건강 상태 값과 오차가 대략 1% 정도였으며, 최대 오차도 4%미만이었다. 따라서, 본 발명의 방법에 따르면, 기준 성능 시험의 시행 횟수를 감소시키면서도 매우 정확한 건강 상태 값을 추정할 수 있다.
- [0114] 이상 설명된 다양한 실시예들은 예시적이며, 서로 구별되어 독립적으로 실시되어야 하는 것은 아니다. 본 명세서에서 설명된 실시예들은 서로 조합된 형태로 실시될 수 있다.
- [0115] 이상 설명된 다양한 실시예들은 컴퓨터 상에서 다양한 구성요소를 통하여 실행될 수 있는 컴퓨터 프로그램의 형태로 구현될 수 있으며, 이와 같은 컴퓨터 프로그램은 컴퓨터로 판독 가능한 매체에 기록될 수 있다. 이때, 매체는 컴퓨터로 실행 가능한 프로그램을 계속 저장하거나, 실행 또는 다운로드를 위해 임시 저장하는 것일 수도 있다. 또한, 매체는 단일 또는 수개 하드웨어가 결합된 형태의 다양한 기록수단 또는 저장수단일 수 있는데, 어떤 컴퓨터 시스템에 직접 접속되는 매체에 한정되지 않고, 네트워크 상에 분산 존재하는 것일 수도 있다. 매체의 예시로는, 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체, CD-ROM 및 DVD와 같은 광기록 매체, 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical medium), 및 ROM, RAM, 플래시 메모리 등을 포함하여 프로그램 명령어가 저장되도록 구성된 것이 있을 수 있다. 또한, 다른 매체의 예시로, 애플리케이션을 유통하는 앱 스토어나 기타 다양한 소프트웨어를 공급 내지 유통하는 사이트, 서버 등에서 관리하는 기록매체 내지 저장매체도 들 수 있다.
- [0116] 본 명세서에서, "부", "모듈" 등은 프로세서 또는 회로와 같은 하드웨어 구성(hardware component), 및/또는 프로세서와 같은 하드웨어 구성에 의해 실행되는 소프트웨어 구성(software component)일 수 있다. 예를 들면, "부", "모듈" 등은 소프트웨어 구성 요소들, 객체 지향 소프트웨어 구성 요소들, 클래스 구성 요소들 및 태스크 구성 요소들과 같은 구성 요소들과, 프로세스들, 함수들, 속성들, 프로시저들, 서브루틴들, 프로그램 코드의 세그먼트들, 드라이버들, 펌웨어, 마이크로 코드, 회로, 데이터, 데이터베이스, 데이터 구조들, 테이블들, 어레이들 및 변수들에 의해 구현될 수 있다.
- [0117] 진술한 본 발명의 설명은 예시를 위한 것이며, 본 발명이 속하는 기술분야의 통상의 지식을 가진 자는 본 발명의 기술적 사상이나 필수적인 특징을 변경하지 않고서 다른 구체적인 형태로 쉽게 변형이 가능하다는 것을 이해할 수 있을 것이다. 그러므로 이상에서 기술한 실시예들은 모든 면에서 예시적인 것이며 한정적이 아닌 것으로

이해해야만 한다. 예를 들어, 단일형으로 설명되어 있는 각 구성 요소는 분산되어 실시될 수도 있으며, 마찬가지로 분산된 것으로 설명되어 있는 구성 요소들도 결합된 형태로 실시될 수 있다.


[0118] 본 발명의 범위는 상기 상세한 설명보다는 후술하는 특허청구범위에 의하여 나타내어지며, 특허청구범위의 의미 및 범위 그리고 그 균등 개념으로부터 도출되는 모든 변경 또는 변형된 형태가 본 발명의 범위에 포함되는 것으로 해석되어야 한다.

도면


도면1



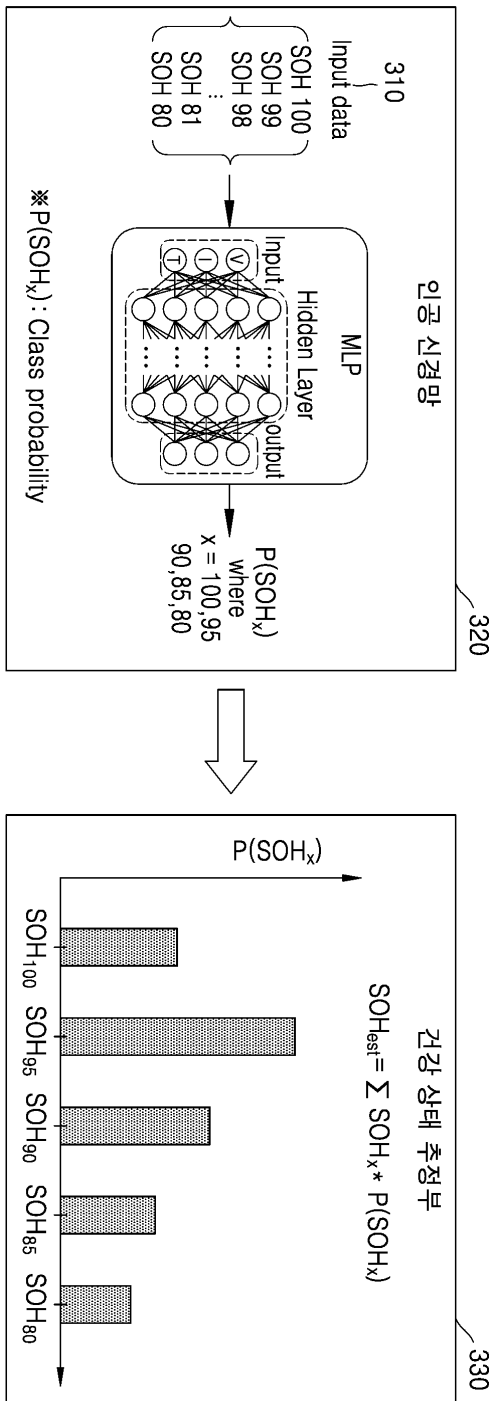
도면2




도면3




도면4



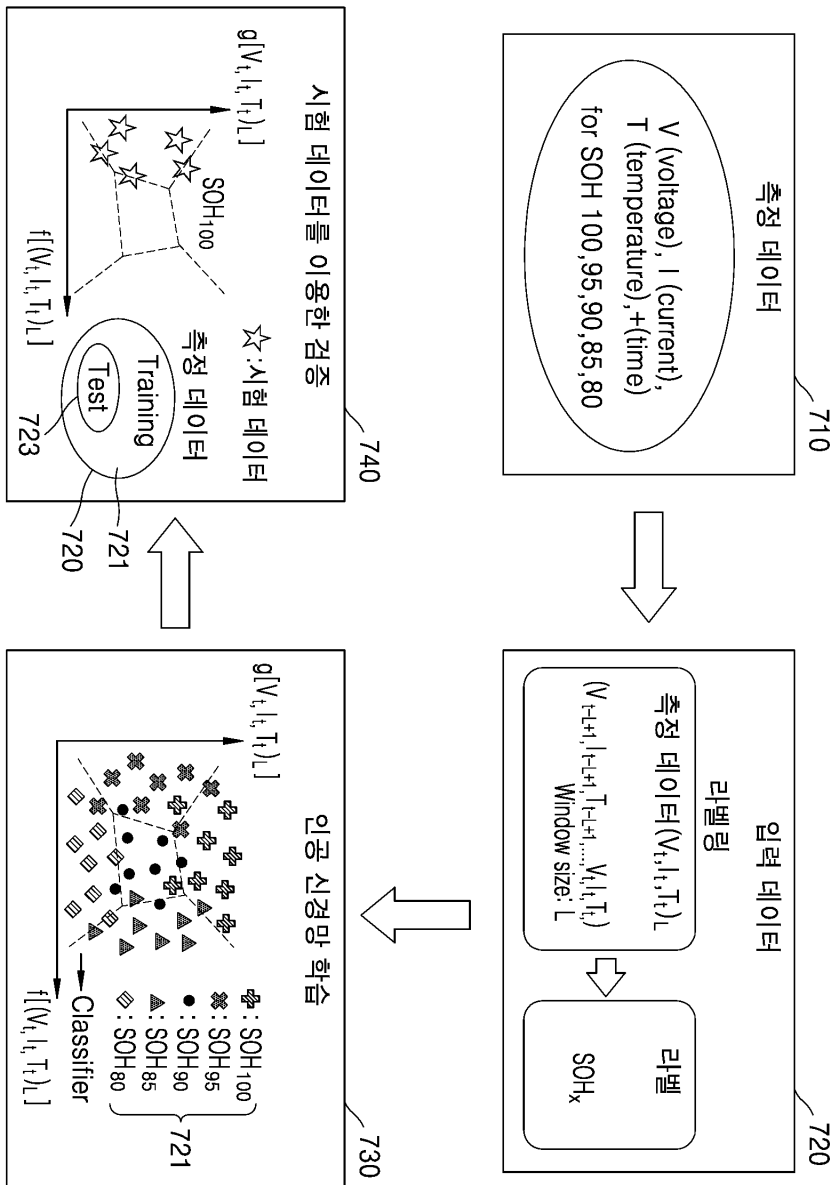
도면5



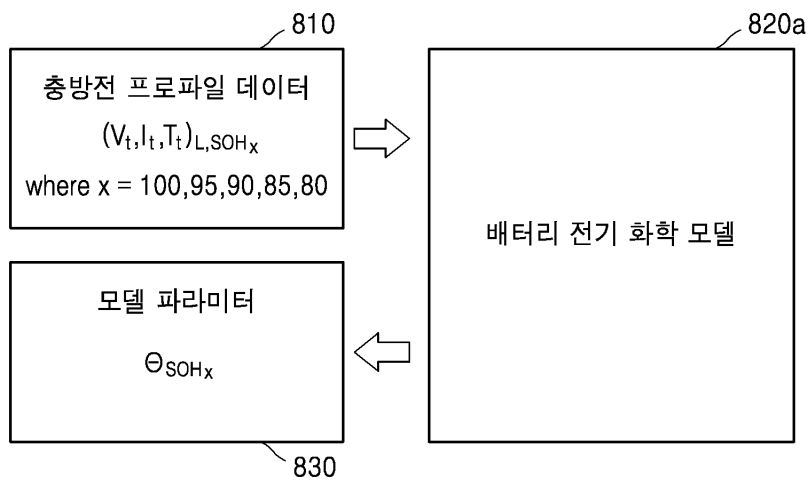
도면6



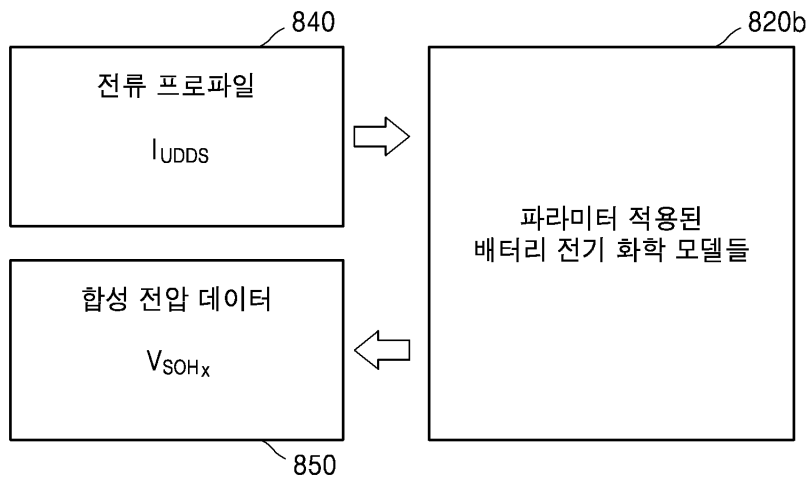
도면7




도면8a



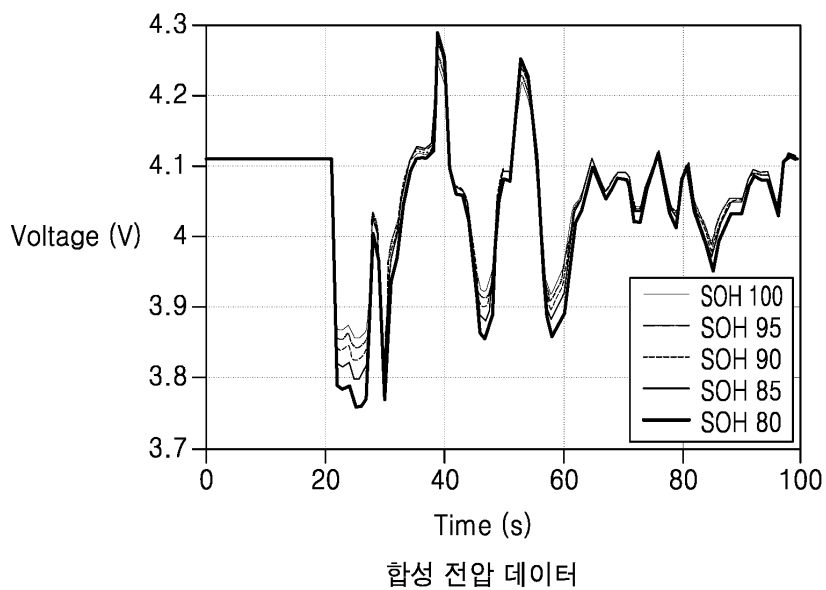
도면8b




도면9a




도면9b



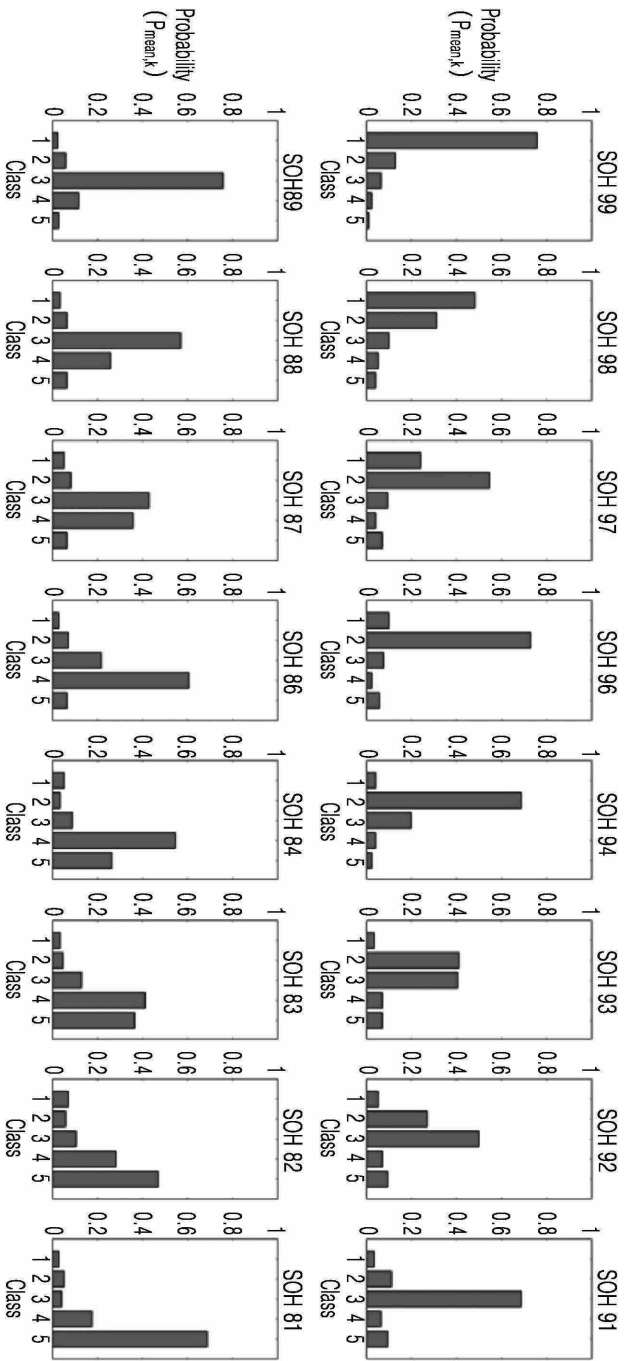
도면9c




도면10a



도면10b



도면11a



도면11b

