



(19) 대한민국특허청(KR)

(12) 등록특허공보(B1)

(45) 공고일자 2020년03월24일

(11) 등록번호 10-2092860

(24) 등록일자 2020년03월18일

(51) 국제특허분류(Int. Cl.)  
H02S 10/20 (2014.01) G06N 20/00 (2019.01)  
G06N 3/08 (2006.01)

(52) CPC특허분류  
H02S 10/20 (2015.01)  
G06N 20/00 (2019.01)

(21) 출원번호 10-2019-0007968

(22) 출원일자 2019년01월22일

심사청구일자 2019년01월22일

(56) 선행기술조사문헌

JP2013074695 A

(뒷면에 계속)

(73) 특허권자

인천대학교 산학협력단

인천광역시 연수구 아카데미로 119 (송도동)

(72) 발명자

김관호

인천광역시 연수구 컨벤시아대로42번길 77 (송도동, 더샵 익스포)

이동훈

충청남도 천안시 동남구 문화1길 11 1007호

(74) 대리인

김효성

전체 청구항 수 : 총 8 항


심사관 : 이종은

(54) 발명의 명칭 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치 및 방법

### (57) 요약

미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치 및 방법이 개시된다. 본 발명은 불확실성을 갖는 미래의 기상 예보 데이터를 이용하여 피크 시간대에서의 태양광 발전량을 예측하는 것이 아니라, 하루 중 피크 시간대 이전의 시간대에서 측정 완료된 기상 데이터를 기초로 그날 피크 시간대에서의 태양광 발전량을 예측할 수 있는 기법을 제시함으로써, 태양광 발전소의 관리자가 피크 시간대에서의 태양광 발전량을 보다 정확하게 예측할 수 있도록 지원할 수 있다.

대표도 - 도1



(52) CPC특허분류  
G06N 3/08 (2013.01)

(56) 선행기술조사문헌  
JP2014063372 A  
KR101761686 B1  
JP2013099143 A  
JP2016125341 A  
JP2018007347 A  
KR1020170124215 A

이 발명을 지원한 국가연구개발사업

과제고유번호 NRF-2017R1D1A1B03035639

부처명 교육부

연구관리전문기관 한국연구재단

연구사업명 개인기초연구(교육부)

연구과제명 인간-공간 상호작용의 전체최적화를 위한 딥러닝 기반의 지능공간 의사결정 모델연구

기 여 율 1/1

주관기관 인천대학교

연구기간 2017.06.01 ~ 2020.05.31

---

## 명세서

### 청구범위

#### 청구항 1

삭제

#### 청구항 2

삭제

#### 청구항 3

삭제

#### 청구항 4

하루 중 기설정된(predetermined) 피크 시간대 이전의 시간대에서 기설정된 단위 시간 간격으로 측정된 서로 다른 종류의 기상 데이터들의 집합과 상기 피크 시간대에서 상기 단위 시간 간격으로 측정된 태양광 발전량 데이터가 일(day)별로 구분되어 기록되어 있는 데이터 테이블을 저장하여 유지하는 측정 테이블 유지부;

상기 데이터 테이블에 일별로 구분되어 기록되어 있는 기상 데이터들의 집합과 태양광 발전량 데이터를 기계학습을 위한 트레이닝 세트와 기계학습 결과의 검증을 위한 테스트 세트로 랜덤하게 분류하되, 상기 트레이닝 세트의 개수가 상기 테스트 세트의 개수를 초과하도록 분류하는 세트 분류부;

상기 트레이닝 세트로 분류된 기상 데이터들의 집합을 입력으로 지정하고, 대응되는 일자의 태양광 발전량 데이터를 출력으로 지정하여 제1 신경망(neural network) 기반 모델, 제2 신경망 기반 모델 및 제3 신경망 기반 모델을 생성하기 위한 지도 학습(supervised learning) 기반의 기계학습을 각각 수행함으로써, 상기 피크 시간대에서의 태양광 발전량을 예측하기 위한 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델을 각각 생성하는 예측 모델 생성부;

상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델이 각각 생성되면, 상기 테스트 세트로 분류된 기상 데이터들의 집합과 대응되는 일자의 태양광 발전량 데이터를 기초로 상기 제1 신경망 기반의 예측 모델에 대한 제1 예측 정확도, 상기 제2 신경망 기반의 예측 모델에 대한 제2 예측 정확도 및 상기 제3 신경망 기반의 예측 모델에 대한 제3 예측 정확도를 측정하는 정확도 측정부;

상기 제1 예측 정확도, 상기 제2 예측 정확도 및 상기 제3 예측 정확도 간의 비율에 기초하여 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델에 가중치 - 각 예측 모델에 할당된 가중치의 총합은 1임 - 를 할당하는 가중치 할당부;

사용자로부터 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터에 대한 예측 명령이 인가되면서, 상기 제1 일자를 구성하는 시간 중 상기 피크 시간대 이전의 시간대에서 상기 단위 시간 간격으로 측정된 제1 기상 데이터들의 집합이 입력되는 경우, 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각에 상기 제1 기상 데이터들의 집합을 입력으로 인가하여 출력 데이터를 산출하고, 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각에 할당되어 있는 가중치를 기초로 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델로부터 산출된 출력 데이터의 가중 평균을 연산한 후 상기 연산된 가중 평균을 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터로 산출하는 예측부; 및

상기 예측부를 통해 산출된 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 상기 예측 명령에 대응하는 예측 데이터로 화면 상에 표시하는 표시부

를 포함하고,

상기 가중치 할당부는

하기의 수학적 식 1에 따른 연산에 기초하여 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델에 가중치를 할당하는 미래의 기상 예보 데이터를 이용하지 않는 기계 학습 기반의 태양광 발전량 예측 장치.

[수학적 식 1]

$$\alpha_n = \frac{A_n}{\sum_{k=1}^3 A_k}$$

여기서, n은 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각을 구분하기 위한 인덱스,  $\alpha$ 은 각 신경망 기반의 예측 모델에 할당될 가중치, A는 각 신경망 기반의 예측 모델에서 측정된 예측 정확도를 의미함.

#### 청구항 5

제4항에 있어서,

상기 제1 신경망은 RNN(Recurrent Neural Network)이고, 상기 제2 신경망은 LSTM(Long Short Term Memory)이며, 상기 제3 신경망은 GRU(Gated Recurrent Unit)인 미래의 기상 예보 데이터를 이용하지 않는 기계 학습 기반의 태양광 발전량 예측 장치.

#### 청구항 6

제4항에 있어서,

상기 데이터 테이블에 기록되어 있는 기상 데이터들의 집합을 구성하는 서로 다른 종류의 기상 데이터들은 온도, 습도, 구름양(cloudiness), 일사량(solar radiation quantity)인 미래의 기상 예보 데이터를 이용하지 않는 기계 학습 기반의 태양광 발전량 예측 장치.

#### 청구항 7

삭제

#### 청구항 8

삭제

#### 청구항 9

삭제

#### 청구항 10

삭제

#### 청구항 11

하루 중 기설정된(predetermined) 피크 시간대 이전의 시간대에서 기설정된 단위 시간 간격으로 측정된 서로 다른 종류의 기상 데이터들의 집합과 상기 피크 시간대에서 상기 단위 시간 간격으로 측정된 태양광 발전량 데이터가 일(day)별로 구분되어 기록되어 있는 데이터 테이블을 저장하여 유지하는 단계;

상기 데이터 테이블에 일별로 구분되어 기록되어 있는 기상 데이터들의 집합과 태양광 발전량 데이터를 기계 학습을 위한 트레이닝 세트와 기계 학습 결과의 검증을 위한 테스트 세트로 랜덤하게 분류하되, 상기 트레이닝 세트의 개수가 상기 테스트 세트의 개수를 초과하도록 분류하는 단계;

상기 트레이닝 세트로 분류된 기상 데이터들의 집합을 입력으로 지정하고, 대응되는 일자의 태양광 발전량 데이터를 출력으로 지정하여 제1 신경망(neural network) 기반 모델, 제2 신경망 기반 모델 및 제3 신경망 기반 모델을 생성하기 위한 지도 학습(supervised learning) 기반의 기계 학습을 각각 수행함으로써, 상기 피크 시간대

에서의 태양광 발전량을 예측하기 위한 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델을 각각 생성하는 단계;

상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델이 각각 생성되면, 상기 테스트 세트로 분류된 기상 데이터들의 집합과 대응되는 일자의 태양광 발전량 데이터를 기초로 상기 제1 신경망 기반의 예측 모델에 대한 제1 예측 정확도, 상기 제2 신경망 기반의 예측 모델에 대한 제2 예측 정확도 및 상기 제3 신경망 기반의 예측 모델에 대한 제3 예측 정확도를 측정하는 단계;

상기 제1 예측 정확도, 상기 제2 예측 정확도 및 상기 제3 예측 정확도 간의 비율에 기초하여 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델에 가중치 - 각 예측 모델에 할당된 가중치의 총합은 1임 - 를 할당하는 단계;

사용자로부터 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터에 대한 예측 명령이 인가되면서, 상기 제1 일자를 구성하는 시간 중 상기 피크 시간대 이전의 시간대에서 상기 단위 시간 간격으로 측정된 제1 기상 데이터들의 집합이 입력되는 경우, 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각에 상기 제1 기상 데이터들의 집합을 입력으로 인가하여 출력 데이터를 산출하고, 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각에 할당되어 있는 가중치를 기초로 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델로부터 산출된 출력 데이터의 가중 평균을 연산한 후 상기 연산된 가중 평균을 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터로 산출하는 단계; 및

상기 산출하는 단계를 통해 산출된 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 상기 예측 명령에 대응하는 예측 데이터로 화면 상에 표시하는 단계

를 포함하고,

상기 가중치를 할당하는 단계는

하기의 수학적 식 2에 따른 연산에 기초하여 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델에 가중치를 할당하는 미래의 기상 예보 데이터를 이용하지 않는 기계 학습 기반의 태양광 발전량 예측 방법.

[수학적 식 2]

$$\alpha_n = \frac{A_n}{\sum_{k=1}^3 A_k}$$

여기서, n은 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각을 구분하기 위한 인덱스,  $\alpha$ 은 각 신경망 기반의 예측 모델에 할당될 가중치, A는 각 신경망 기반의 예측 모델에서 측정된 예측 정확도를 의미함.

## 청구항 12

제11항에 있어서,

상기 제1 신경망은 RNN(Recurrent Neural Network)이고, 상기 제2 신경망은 LSTM(Long Short Term Memory)이며, 상기 제3 신경망은 GRU(Gated Recurrent Unit)인 미래의 기상 예보 데이터를 이용하지 않는 기계 학습 기반의 태양광 발전량 예측 방법.

## 청구항 13

제11항에 있어서,

상기 데이터 테이블에 기록되어 있는 기상 데이터들의 집합을 구성하는 서로 다른 종류의 기상 데이터들은 온도, 습도, 구름양(cloudiness), 일사량(solar radiation quantity)인 미래의 기상 예보 데이터를 이용하지

않는 기계학습 기반의 태양광 발전량 예측 방법.

#### 청구항 14

삭제

#### 청구항 15

제11항, 제12항 또는 제13항 중 어느 한 항의 방법을 컴퓨터와의 결합을 통해 실행시키기 위한 컴퓨터 프로그램을 기록한 컴퓨터 판독 가능 기록 매체.

#### 청구항 16

제11항, 제12항 또는 제13항 중 어느 한 항의 방법을 컴퓨터와의 결합을 통해 실행시키기 위한 저장매체에 저장된 컴퓨터 프로그램.

### 발명의 설명

#### 기술 분야

[0001] 본 발명은 하루 중 태양광 발전량이 최대인 피크 시간대에서의 태양광 발전량을 예측하기 위한 장치 및 방법에 대한 것이다.

#### 배경 기술

[0002] 최근, 온실가스의 증가로 인한 기상 변화 대응의 필요성과 전력수요의 증가로 인해 태양광 발전량 예측의 중요성이 급격히 증가하고 있다.

[0003] 특히, 하루 중 태양광 발전량이 최대인 피크 시간대에서의 태양광 발전량을 예측하는 것은 전력의 정확한 가격 결정, 시스템 안정성 및 전력 생산 균형 등 다양한 문제들을 효과적으로 해결하고 전력 생산 계획을 합리적으로 계획하는데 도움이 될 수 있다.

[0004] 보통, 태양광 발전량은 하루 중 일사량이 최대인 오전 10시에서 오후 2시 사이에 가장 많은 발전량을 보이는 특징을 가지고 있다.

[0005] 태양광 발전량은 온도, 습도, 일사량(solar radiation quantity), 구름량(cloudiness) 등과 같은 기상 영향을 많이 받고 있기 때문에, 피크 시간대의 태양광 발전량을 예측하는데 있어, 기상 데이터를 활용하는 방안이 고려될 수 있다.

[0006] 기존의 피크 시간대에서의 태양광 발전량을 예측하는 기법은 피크 시간대에 대한 미래의 기상 예보 데이터를 기초로 태양광 발전량이 어느 정도 될 것이라고 예측하는 기법이 자주 사용되었다.

[0007] 하지만, 이러한 기상 예보 데이터를 이용하여 태양광 발전량을 예측하는 기법은 기상 예보 데이터의 특성상 잘못된 예보 데이터가 존재할 수 있다는 점에서 정확한 태양광 발전량을 예측하기가 어려운 점이 존재한다.

[0008] 따라서, 불확실성을 갖는 미래의 기상 예보 데이터를 이용하여 피크 시간대에서의 태양광 발전량을 예측하는 것이 아니라, 하루 중 피크 시간대 이전의 시간대에서 측정 완료된 기상 데이터를 기초로 그날 피크 시간대에서의 태양광 발전량을 예측할 수 있는 기법을 제시함으로써, 태양광 발전소의 관리자가 피크 시간대에서의 태양광 발전량을 보다 정확하게 예측할 수 있도록 지원할 수 있는 기술의 연구가 필요하다.

### 발명의 내용

#### 해결하려는 과제

[0009] 본 발명은 불확실성을 갖는 미래의 기상 예보 데이터를 이용하여 피크 시간대에서의 태양광 발전량을 예측하는 것이 아니라, 하루 중 피크 시간대 이전의 시간대에서 측정 완료된 기상 데이터를 기초로 그날 피크 시간대에서의 태양광 발전량을 예측할 수 있는 기법을 제시함으로써, 태양광 발전소의 관리자가 피크 시간대에서의 태양광 발전량을 보다 정확하게 예측할 수 있도록 지원하고자 한다.

#### 과제의 해결 수단

[0010] 본 발명의 일실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치는 하루 중 기설정된(predetermined) 피크 시간대 이전의 시간대에서 기설정된 단위 시간 간격으로 측정된 서로 다른 종류의 기상 데이터들의 집합과 상기 피크 시간대에서 상기 단위 시간 간격으로 측정된 태양광 발전량 데이터가 일(day)별로 구분되어 기록되어 있는 데이터 테이블을 저장하여 유지하는 측정 테이블 유지부, 상기 데이터 테이블에 일별로 구분되어 기록되어 있는 기상 데이터들의 집합을 입력으로 지정하고, 대응되는 일자의 태양광 발전량 데이터를 출력으로 지정하여 신경망(neural network) 기반 모델을 생성하기 위한 지도 학습(supervised learning) 기반의 기계학습을 수행함으로써, 상기 피크 시간대에서의 태양광 발전량을 예측하기 위한 예측 모델을 생성하는 예측 모델 생성부, 사용자로부터 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터에 대한 예측 명령이 인가되면서, 상기 제1 일자를 구성하는 시간 중 상기 피크 시간대 이전의 시간대에서 상기 단위 시간 간격으로 측정된 제1 기상 데이터들의 집합이 입력되는 경우, 상기 예측 모델에 상기 제1 기상 데이터들의 집합을 입력으로 인가하여 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 출력으로 산출하는 예측부 및 상기 예측부를 통해 출력으로 산출된 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 상기 예측 명령에 대응하는 예측 데이터로 화면 상에 표시하는 표시부를 포함한다.

[0011] 또한, 본 발명의 일실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 방법은 하루 중 기설정된 피크 시간대 이전의 시간대에서 기설정된 단위 시간 간격으로 측정된 서로 다른 종류의 기상 데이터들의 집합과 상기 피크 시간대에서 상기 단위 시간 간격으로 측정된 태양광 발전량 데이터가 일별로 구분되어 기록되어 있는 데이터 테이블을 저장하여 유지하는 단계, 상기 데이터 테이블에 일별로 구분되어 기록되어 있는 기상 데이터들의 집합을 입력으로 지정하고, 대응되는 일자의 태양광 발전량 데이터를 출력으로 지정하여 신경망 기반 모델을 생성하기 위한 지도 학습 기반의 기계학습을 수행함으로써, 상기 피크 시간대에서의 태양광 발전량을 예측하기 위한 예측 모델을 생성하는 단계, 사용자로부터 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터에 대한 예측 명령이 인가되면서, 상기 제1 일자를 구성하는 시간 중 상기 피크 시간대 이전의 시간대에서 상기 단위 시간 간격으로 측정된 제1 기상 데이터들의 집합이 입력되는 경우, 상기 예측 모델에 상기 제1 기상 데이터들의 집합을 입력으로 인가하여 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 출력으로 산출하는 단계 및 상기 산출하는 단계를 통해 출력으로 산출된 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 상기 예측 명령에 대응하는 예측 데이터로 화면 상에 표시하는 단계를 포함한다.

### 발명의 효과

[0012] 본 발명은 불확실성을 갖는 미래의 기상 예보 데이터를 이용하여 피크 시간대에서의 태양광 발전량을 예측하는 것이 아니라, 하루 중 피크 시간대 이전의 시간대에서 측정 완료된 기상 데이터를 기초로 그날 피크 시간대에서의 태양광 발전량을 예측할 수 있는 기법을 제시함으로써, 태양광 발전소의 관리자가 피크 시간대에서의 태양광 발전량을 보다 정확하게 예측할 수 있도록 지원할 수 있다.

### 도면의 간단한 설명

[0013] 도 1은 본 발명의 일실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치의 구조를 도시한 도면이다.

도 2는 본 발명의 다른 실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치의 구조를 도시한 도면이다.

도 3은 본 발명의 일실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 방법을 도시한 순서도이다.

도 4는 본 발명의 다른 실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 방법을 도시한 순서도이다.

### 발명을 실시하기 위한 구체적인 내용

[0014] 이하에서는 본 발명에 따른 실시예들을 첨부된 도면을 참조하여 상세하게 설명하기로 한다. 이러한 설명은 본 발명을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다. 각 도면을 설명하면서 유사한 참조부호를 유사한 구

성요소에 대해 사용하였으며, 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 본 명세서 상에서 사용되는 모든 용어들은 본 발명이 속하는 기술분야에서 통상의 지식을 가진 사람에 의해 일반적으로 이해되는 것과 동일한 의미를 가지고 있다.

[0015] 본 문서에서, 어떤 부분이 어떤 구성요소를 "포함"한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있다는 것을 의미한다. 또한, 본 발명의 다양한 실시예들에 있어서, 각 구성요소들, 기능 블록들 또는 수단들은 하나 또는 그 이상의 하부 구성요소로 구성될 수 있고, 각 구성요소들이 수행하는 전기, 전자, 기계적 기능들은 전자회로, 집적회로, ASIC(Application Specific Integrated Circuit) 등 공지된 다양한 소자들 또는 기계적 요소들로 구현될 수 있으며, 각각 별개로 구현되거나 2 이상이 하나로 통합되어 구현될 수도 있다.

[0016] 한편, 첨부된 블록도의 블록들이나 흐름도의 단계들은 범용 컴퓨터, 특수용 컴퓨터, 휴대용 노트북 컴퓨터, 네트워크 컴퓨터 등 데이터 프로세싱이 가능한 장비의 프로세서나 메모리에 탑재되어 지정된 기능들을 수행하는 컴퓨터 프로그램 명령들(instructions)을 의미하는 것으로 해석될 수 있다. 이들 컴퓨터 프로그램 명령들은 컴퓨터 장치에 구비된 메모리 또는 컴퓨터에서 판독 가능한 메모리에 저장될 수 있기 때문에, 블록도의 블록들 또는 흐름도의 단계들에서 설명된 기능들은 이를 수행하는 명령 수단을 내포하는 제조물로 생산될 수도 있다. 아울러, 각 블록 또는 각 단계는 특정된 논리적 기능(들)을 실행하기 위한 하나 이상의 실행 가능한 명령들을 포함하는 모듈, 세그먼트 또는 코드의 일부를 나타낼 수 있다. 또, 몇 가지 대체 가능한 실시예들에서는 블록들 또는 단계들에서 언급된 기능들이 정해진 순서와 달리 실행되는 것도 가능함을 주목해야 한다. 예컨대, 잇달아 도시되어 있는 두 개의 블록들 또는 단계들은 실질적으로 동시에 수행되거나, 역순으로 수행될 수 있으며, 경우에 따라 일부 블록들 또는 단계들이 생략된 채로 수행될 수도 있다.

[0017] 도 1은 본 발명의 일실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치의 구조를 도시한 도면이다.

[0018] 도 1을 참조하면, 본 발명에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치(110)는 측정 테이블 유지부(111), 예측 모델 생성부(112), 예측부(113) 및 표시부(114)를 포함한다.

[0019] 측정 테이블 유지부(111)는 하루 중 기설정된(predetermined) 피크 시간대 이전의 시간대에서 기설정된 단위 시간 간격으로 측정된 서로 다른 종류의 기상 데이터들의 집합과 상기 피크 시간대에서 상기 단위 시간 간격으로 측정된 태양광 발전량 데이터가 일(day)별로 구분되어 기록되어 있는 데이터 테이블을 저장하여 유지한다.

[0020] 이때, 본 발명의 일실시예에 따르면, 상기 데이터 테이블에 기록되어 있는 기상 데이터들의 집합을 구성하는 서로 다른 종류의 기상 데이터들은 온도, 습도, 구름양(cloudiness), 일사량(solar radiation quantity)일 수 있다.

[0021] 그리고, 상기 피크 시간대와 상기 피크 시간대 이전의 시간대는 사용자에게 의 해 미리 설정된 시간대를 의미하는 것으로, 상기 피크 시간대는 하루 중 오전 10~오후 2시로 설정될 수 있고, 상기 피크 시간대 이전의 시간대는 오전 6~오후 9시로 설정될 수 있으며, 상기 단위 시간 간격은 1시간 간격으로 설정될 수 있다.

[0022] 이때, 상기 피크 시간대를 오전 10시~오후 2시라고 하고, 상기 단위 시간 간격을 1시간 간격이라고 하며, 상기 피크 시간대 이전의 시간대를 오전 6시~오후 9시라고 하는 경우, 상기 데이터 테이블에는 하기의 표 1과 같이 데이터가 기록되어 있을 수 있다.

표 1

[0024]

| 일자    | 기상 데이터들의 집합(D)<br>(온도, 습도, 구름양, 일사량 순임)                                                                         | 태양광 발전량 데이터(G)                                                   |
|-------|-----------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------|
| 3월 4일 | 오전 6시: (D1, D2, D3, D4)<br>오전 7시: (D5, D6, D7, D8)<br>오전 8시: (D9, D10, D11, D12)<br>오전 9시: (D13, D14, D15, D16) | 오전 10시: G1<br>오전 11시: G2<br>오후 12시: G3<br>오후 1시: G4<br>오후 2시: G5 |

|       |                                                                                                                          |                                                                   |
|-------|--------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------|
| 3월 5일 | 오전 6시: (D21, D22, D23, D24)<br>오전 7시: (D25, D26, D27, D28)<br>오전 8시: (D29, D30, D31, D32)<br>오전 9시: (D33, D34, D35, D36) | 오전 10시: G6<br>오전 11시: G7<br>오후 12시: G8<br>오후 1시: G9<br>오후 2시: G10 |
| 3월 6일 | ...                                                                                                                      | ...                                                               |
| ...   | ...                                                                                                                      | ...                                                               |

- [0026] 본 발명의 일실시예에 따르면, 상기 표 1과 같은 상기 데이터 테이블에 기록되어 있는 기상 데이터들의 집합에 포함되는 기상 데이터의 종류로는 앞서 언급한 온도, 습도, 구름양, 일사량뿐 아니라, 사용자의 선택에 따라 데이터의 측정 날짜와 측정 월, 상기 피크 시간대 이전의 시간대에서 상기 단위 시간 간격으로 측정된 태양광 발전량 데이터가 추가로 포함될 수도 있다.
- [0027] 이렇게, 상기 데이터 테이블이 존재하는 상태에서, 예측 모델 생성부(112)는 상기 데이터 테이블에 일별로 구분되어 기록되어 있는 기상 데이터들의 집합을 입력으로 지정하고, 대응되는 일자의 태양광 발전량 데이터를 출력으로 지정하여 신경망(neural network) 기반 모델을 생성하기 위한 지도 학습(supervised learning) 기반의 기계학습을 수행함으로써, 상기 피크 시간대에서의 태양광 발전량을 예측하기 위한 예측 모델을 생성한다.
- [0028] 이때, 본 발명의 일실시예에 따르면, 상기 신경망은 RNN(Recurrent Neural Network), LSTM(Long Short Term Memory) 또는 GRU(Gated Recurrent Unit) 중 하나일 수 있다.
- [0029] RNN은 인공 신경망의 한 종류로, 유닛간의 연결이 순환적 구조를 갖는 특징을 가지며, 시변적 동적 특징을 모델링 할 수 있도록 신경망 내부에 상태를 저장할 수 있게 해주고, 메모리를 이용해 시퀀스 형태의 입력을 처리할 수 있게 한다. 이로 인해 RNN은 필기체 인식이나 음성 인식과 같이 시변적 특징을 가지는 데이터를 처리하기 위한 모델 생성에 주로 활용된다.
- [0030] 그리고, LSTM은 RNN의 일종으로 전통적인 RNN이 시간에 따라 학습이 계속 진행됨에 따라, 앞에서 입력으로 받은 정보가 학습에 미치는 영향이 점점 감소하다가 결국에는 사라져버리는 Vanishing Gradient Problem을 가지고 있는 것을 해소하기 위해, RNN 구조에 장/단기 기억을 가능하게 설계한 신경망 구조이다.
- [0031] 마지막으로, GRU는 LSTM의 장점을 유지하면서도 계산의 복잡성을 감소시킨 구조로, Vanishing Gradient Problem을 극복했다는 점에서 LSTM과 유사하지만 게이트 일부를 생략한 형태를 갖는 신경망 구조이다.
- [0032] 그리고, 지도 학습이란 입력과 그에 대응하는 출력으로 구성된 트레이닝 데이터를 이용하여 신경망을 학습시키기 위한 기계학습의 한 방법으로, 예측 모델 생성부(112)는 상기 데이터 테이블에 일별로 구분되어 기록되어 있는 기상 데이터들의 집합을 입력으로 지정하고, 대응되는 일자의 태양광 발전량 데이터를 출력으로 지정하여 RNN, LSTM 또는 GRU 기반의 모델을 생성하기 위한 각 신경망 구조에 따른 지도 학습 알고리즘을 수행함으로써, 상기 피크 시간대에서의 태양광 발전량을 예측하기 위한 예측 모델을 생성할 수 있다.
- [0033] 예컨대, 예측 모델 생성부(112)는 상기 표 1에서 3월 4일자에 측정된 기상 데이터들의 집합을 입력으로, 3월 4일자에 측정된 상기 피크 시간대에서의 태양광 발전량 데이터를 출력으로 두고 RNN, LSTM 또는 GRU 구조에 대응하는 지도 학습 기반의 기계학습을 수행할 수 있고, 3월 5일자에 측정된 기상 데이터들의 집합을 입력으로, 3월 5일자에 측정된 상기 피크 시간대에서의 태양광 발전량 데이터를 출력으로 두고 RNN, LSTM 또는 GRU에 대응하는 지도 학습 기반의 기계학습을 수행하는 방식으로 신경망을 학습시킴으로써, 상기 피크 시간대에서의 태양광 발전량을 예측하기 위한 RNN, LSTM 또는 GRU 기반의 예측 모델을 생성할 수 있다.
- [0034] 이렇게, 상기 예측 모델이 생성된 이후, 예측부(113)는 사용자로부터 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터에 대한 예측 명령이 인가되면서, 상기 제1 일자를 구성하는 시간 중 상기 피크 시간대 이전의 시간대에서 상기 단위 시간 간격으로 측정된 제1 기상 데이터들의 집합이 입력되는 경우, 상기 예측 모델에 상기 제1 기상 데이터들의 집합을 입력으로 인가하여 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 출력으로 산출한다.
- [0035] 예컨대, 상기 제1 일자가 5월 10일이고, 5월 10일 오전 6시~오전 9시까지 1시간 간격으로 측정된 상기 제1 기상 데이터들의 집합이 하기의 표 2와 같다고 가정하자.

표 2

| 일자     | 제1 기상 데이터들의 집합(D)<br>(온도, 습도, 구름양, 일사량 순임)                                                                               |
|--------|--------------------------------------------------------------------------------------------------------------------------|
| 5월 10일 | 오전 6시: (D50, D51, D52, D53)<br>오전 7시: (D54, D55, D56, D57)<br>오전 8시: (D58, D59, D60, D61)<br>오전 9시: (D62, D63, D64, D65) |

이때, 예측부(113)는 상기 표 2와 같은 상기 제1 기상 데이터들의 집합을 상기 예측 모델에 입력으로 인가함으로써, 하기의 표 3에서 나타낸 바와 같이 5월 10일자의 피크 시간대인 오전 10시~오후 2시 사이의 태양광 발전량 데이터를 산출할 수 있다.

표 3

| 일자     | 예측된 태양광 발전량 데이터(G)                                                    |
|--------|-----------------------------------------------------------------------|
| 5월 10일 | 오전 10시: G20<br>오전 11시: G21<br>오후 12시: G22<br>오후 1시: G23<br>오후 2시: G24 |

이렇게, 예측부(113)를 통해 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터의 산출이 완료되면, 표시부(114)는 예측부(113)를 통해 출력으로 산출된 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 상기 예측 명령에 대응하는 예측 데이터로 화면 상에 표시할 수 있다.

이를 통해, 태양광 발전소를 운영하는 사용자는 미래의 기상 예보 데이터가 아닌 당일 피크 시간대 이전의 시간대에서 측정된 기상 데이터들로부터 당일 피크 시간대에 예상되는 태양광 발전량을 확인할 수 있어서, 기상 예보 데이터가 잘못됨으로 인해서 발생하는 피크 시간대에서의 태양광 발전량에 대한 예측 오류를 방지할 수 있다.

지금까지는 하나의 신경망 기반 예측 모델을 생성해서 피크 시간대에서의 태양광 발전량을 예측하는 기법에 대해 설명하였지만, 본 발명의 변형된 다른 실시예에 따르면, 본 발명은 피크 시간대에서의 태양광 발전량에 대한 예측 정확도를 향상시키기 위해, 다수의 신경망 기반의 예측 모델을 생성하여 피크 시간대에서의 태양광 발전량을 예측한 후 각 신경망 기반 예측 모델을 통해 예측된 태양광 발전량 데이터를 각 신경망 기반 예측 모델의 예측 정확도에 따라 적절히 반영하여 피크 시간대에서의 태양광 발전량을 예측하는 실시예를 포함할 수 있다.

관련해서, 도 2를 참조하여 본 발명의 다른 실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치를 설명하면 다음과 같다.

도 2는 본 발명의 다른 실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치의 구조를 도시한 도면이다.

도 2를 참조하면, 본 발명의 다른 실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치(210)는 측정 테이블 유지부(211), 세트 분류부(212), 예측 모델 생성부(213), 정확도 측정부(214), 가중치 할당부(215), 예측부(216) 및 표시부(217)를 포함한다.

측정 테이블 유지부(211)는 하루 중 기설정된 피크 시간대 이전의 시간대에서 기설정된 단위 시간 간격으로 측정된 서로 다른 종류의 기상 데이터들의 집합과 상기 피크 시간대에서 상기 단위 시간 간격으로 측정된 태양광 발전량 데이터가 일별로 구분되어 기록되어 있는 데이터 테이블을 저장하여 유지한다.

이때, 본 발명의 일 실시예에 따르면, 상기 데이터 테이블에 기록되어 있는 기상 데이터들의 집합을 구성하는 서로 다른 종류의 기상 데이터들은 온도, 습도, 구름양, 일사량일 수 있다.

그리고, 상기 피크 시간대를 오전 10시~오후 2시라고 하고, 상기 단위 시간 간격을 1시간 간격이라고 하며, 상

기 피크 시간대 이전의 시간대를 오전 6시~오전 9시라고 하는 경우, 상기 데이터 테이블에는 상기 표 1과 같이 데이터가 기록되어 있을 수 있다.

[0052] 세트 분류부(212)는 상기 데이터 테이블에 일별로 구분되어 기록되어 있는 기상 데이터들의 집합과 태양광 발전량 데이터를 기계학습을 위한 트레이닝 세트와 기계학습 결과의 검증을 위한 테스트 세트로 랜덤하게 분류하되, 상기 트레이닝 세트의 개수가 상기 테스트 세트의 개수를 초과하도록 분류한다.

[0053] 예컨대, 상기 데이터 테이블에 100일치에 해당하는 기상 데이터들의 집합과 태양광 발전량 데이터가 저장되어 있다고 하는 경우, 세트 분류부(212)는 100일치의 데이터 세트들 중 랜덤하게 선택된 70일치의 데이터 세트를 트레이닝 세트로 분류하고, 나머지 30일치의 데이터 세트를 테스트 세트로 분류할 수 있다.

[0054] 예측 모델 생성부(213)는 상기 트레이닝 세트로 분류된 기상 데이터들의 집합을 입력으로 지정하고, 대응되는 일자의 태양광 발전량 데이터를 출력으로 지정하여 제1 신경망 기반 모델, 제2 신경망 기반 모델 및 제3 신경망 기반 모델을 생성하기 위한 지도 학습 기반의 기계학습을 각각 수행함으로써, 상기 피크 시간대에서의 태양광 발전량을 예측하기 위한 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델을 각각 생성한다.

[0055] 이때, 본 발명의 일실시예에 따르면, 상기 제1 신경망은 RNN이고, 상기 제2 신경망은 LSTM이며, 상기 제3 신경망은 GRU일 수 있다. 이 경우, 예측 모델 생성부(213)는 상기 트레이닝 세트로 분류된 기상 데이터들의 집합을 입력으로 지정하고, 대응되는 일자의 태양광 발전량 데이터를 출력으로 지정하여 RNN 기반 모델, LSTM 기반 모델 및 GRU 기반 모델을 생성하기 위한 지도 학습 기반의 기계학습을 각각 수행함으로써, 상기 피크 시간대에서의 태양광 발전량을 예측하기 위한 RNN 기반의 예측 모델, LSTM 기반의 예측 모델 및 GRU 기반의 예측 모델을 각각 생성할 수 있다.

[0056] 정확도 측정부(214)는 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델이 각각 생성되면, 상기 테스트 세트로 분류된 기상 데이터들의 집합과 대응되는 일자의 태양광 발전량 데이터를 기초로 상기 제1 신경망 기반의 예측 모델에 대한 제1 예측 정확도, 상기 제2 신경망 기반의 예측 모델에 대한 제2 예측 정확도 및 상기 제3 신경망 기반의 예측 모델에 대한 제3 예측 정확도를 측정한다.

[0057] 관련해서, 정확도 측정부(214)는 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델에 상기 테스트 세트로 분류된 기상 데이터들의 집합을 입력으로 인가하여 출력 데이터를 산출해 보고, 각 예측 모델에서 산출된 출력 데이터가 각 기상 데이터들의 집합에 대응되는 일자의 태양광 발전량 데이터와 일치하는지 여부를 비교함으로써, 각 예측 모델에 대응하는 예측 정확도를 측정할 수 있고, 상기 예측 정확도는 백분율로 산출될 수 있다.

[0058] 가중치 할당부(215)는 상기 제1 예측 정확도, 상기 제2 예측 정확도 및 상기 제3 예측 정확도 간의 비율에 기초하여 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델에 가중치를 할당한다. 이때, 각 예측 모델에 할당된 가중치의 총합은 1이어야 한다.

[0059] 이때, 본 발명의 일실시예에 따르면, 가중치 할당부(215)는 하기의 수학식 1에 따른 연산에 기초하여 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델에 가중치를 할당할 수 있다.

### 수학식 1

$$\alpha_n = \frac{A_n}{\sum_{k=1}^3 A_k}$$

[0061]

[0063] 여기서, n은 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각을 구분하기 위한 인덱스로 1, 2, 3이 순차적으로 지정되고,  $\alpha$ 은 각 신경망 기반의 예측 모델에 할당될 가중치, A는 각 신경망 기반의 예측 모델에서 측정된 예측 정확도를 의미한다. 예컨대, 상기 제1 신경

망 기반의 예측 모델의 인덱스를 1, 상기 제2 신경망 기반의 예측 모델의 인덱스를 2, 상기 제3 신경망 기반의 예측 모델의 인덱스를 3이라고 하는 경우,  $\alpha_1$ 은 상기 제1 신경망 기반의 예측 모델이 할당될 가중치,  $\alpha_2$ 은 상기 제2 신경망 기반의 예측 모델이 할당될 가중치,  $\alpha_3$ 은 상기 제3 신경망 기반의 예측 모델이 할당될 가중치를 의미하고,  $A_1$ 은 상기 제1 예측 정확도,  $A_2$ 는 상기 제2 예측 정확도,  $A_3$ 은 상기 제3 예측 정확도를 의미한다.

$$\alpha_1 = \frac{A_1}{\sum_{k=1}^3 A_k} \quad \alpha_2 = \frac{A_2}{\sum_{k=1}^3 A_k} \quad \alpha_3 = \frac{A_3}{\sum_{k=1}^3 A_k}$$

따라서,  $\alpha_1$ 으로 연산되고,  $\alpha_2$ 으로 연산되며,  $\alpha_3$ 으로 연산될 수 있다.

예측부(216)는 사용자로부터 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터에 대한 예측 명령이 인가되면서, 상기 제1 일자를 구성하는 시간 중 상기 피크 시간대 이전의 시간대에서 상기 단위 시간 간격으로 측정된 제1 기상 데이터들의 집합이 입력되는 경우, 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각에 상기 제1 기상 데이터들의 집합을 입력으로 인가하여 출력 데이터를 산출하고, 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각에 할당되어 있는 가중치를 기초로 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델로부터 산출된 출력 데이터의 가중 평균을 연산한 후 상기 연산된 가중 평균을 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터로 산출한다.

예컨대, 상기 제1 일자가 5월 10일이고, 5월 10일 오전 6시~오전 9시까지 1시간 간격으로 측정된 상기 제1 기상 데이터들의 집합이 상기 표 2와 같다고 가정하자.

이때, 예측부(113)는 상기 표 2와 같은 상기 제1 기상 데이터들의 집합을 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각에 입력으로 인가함으로써, 각 예측 모델에서의 출력 데이터를 산출할 수 있다.

이때, 각 예측 모델에서 산출된 출력 데이터가 하기의 표 4와 같다고 가정하자.

표 4

| 예측 모델            | 일자     | 예측된 태양광 발전량 데이터(G)                                                    |
|------------------|--------|-----------------------------------------------------------------------|
| 제1 신경망 기반의 예측 모델 | 5월 10일 | 오전 10시: G30<br>오전 11시: G31<br>오후 12시: G32<br>오후 1시: G33<br>오후 2시: G34 |
| 제2 신경망 기반의 예측 모델 | 5월 10일 | 오전 10시: G40<br>오전 11시: G41<br>오후 12시: G42<br>오후 1시: G43<br>오후 2시: G44 |
| 제3 신경망 기반의 예측 모델 | 5월 10일 | 오전 10시: G50<br>오전 11시: G51<br>오후 12시: G52<br>오후 1시: G53<br>오후 2시: G54 |

이때, 예측부(216)는 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각에 할당되어 있는 가중치를 기초로 상기 표 4에서 나타난 각 예측 모델로부터 산출된 출력 데이터의 가중 평균을 연산한 후 상기 연산된 가중 평균을 상기 제1 일자의 상기 피크 시간대에서의 상기

단위 시간 간격의 태양광 발전량 데이터로 산출할 수 있다.

- [0073] 상기 표 4의 실시예에서 예측부(216)는 동일 시간에서의 각 예측 모델에서 산출된 태양광 발전량 데이터의 가중 평균을 연산함으로써, 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 산출할 수 있다. 즉, 예측부(216)는 오전 10시에 대해 G30, G40, G50의 가중 평균을 연산하여 오전 10시에 대한 태양광 발전량 데이터를 산출할 수 있고, 오전 11시에 대해 G31, G41, G51의 가중 평균을 연산하여 오전 11시에 대한 태양광 발전량 데이터를 산출할 수 있다.
- [0074] 이렇게, 예측부(216)를 통해 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터의 산출이 완료되면, 표시부(217)는 예측부(216)를 통해 출력으로 산출된 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 상기 예측 명령에 대응하는 예측 데이터로 화면 상에 표시할 수 있다.
- [0075] 결국, 본 발명의 다른 실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치(210)는 이미 측정된 기상 데이터와 피크 시간대의 태양광 발전량 데이터를 기초로 다수의 신경망 구조에 따른 기계학습을 수행함으로써, 다수의 신경망 기반의 예측 모델을 생성하고, 각 예측 모델의 정확도에 기반하여 각 예측 모델에 대한 가중치를 할당한 후 사용자로부터 특정 일자에서 측정된 기상 데이터가 입력으로 인가되면서, 해당 일자에서의 피크 시간대의 태양광 발전량에 대한 예측 명령이 인가되면, 각 예측 모델을 이용하여 태양광 발전량에 대한 예측 값을 산출하고, 각 예측 모델에 할당된 가중치를 기초로 각 예측 모델에서 산출된 예측 값에 대한 가중 평균을 태양광 발전량에 대한 최종 예측 결과로 산출함으로써, 태양광 발전소를 관리하는 사용자에게 보다 정확한 피크 시간대에서의 태양광 발전량 예측치를 제공할 수 있다.
- [0076] 도 3은 본 발명의 일실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 방법을 도시한 순서도이다.
- [0077] 단계(S310)에서는 하루 중 기설정된 피크 시간대 이전의 시간대에서 기설정된 단위 시간 간격으로 측정된 서로 다른 종류의 기상 데이터들의 집합과 상기 피크 시간대에서 상기 단위 시간 간격으로 측정된 태양광 발전량 데이터가 일별로 구분되어 기록되어 있는 데이터 테이블을 저장하여 유지한다.
- [0078] 단계(S320)에서는 상기 데이터 테이블에 일별로 구분되어 기록되어 있는 기상 데이터들의 집합을 입력으로 지정하고, 대응되는 일자의 태양광 발전량 데이터를 출력으로 지정하여 신경망 기반 모델을 생성하기 위한 지도 학습 기반의 기계학습을 수행함으로써, 상기 피크 시간대에서의 태양광 발전량을 예측하기 위한 예측 모델을 생성한다.
- [0079] 단계(S330)에서는 사용자로부터 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터에 대한 예측 명령이 인가되면서, 상기 제1 일자를 구성하는 시간 중 상기 피크 시간대 이전의 시간대에서 상기 단위 시간 간격으로 측정된 제1 기상 데이터들의 집합이 입력되는 경우, 상기 예측 모델에 상기 제1 기상 데이터들의 집합을 입력으로 인가하여 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 출력으로 산출한다.
- [0080] 단계(S340)에서는 단계(S330)을 통해 출력으로 산출된 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 상기 예측 명령에 대응하는 예측 데이터로 화면 상에 표시한다.
- [0081] 이때, 본 발명의 일실시예에 따르면, 상기 신경망은 RNN, LSTM 또는 GRU 중 하나일 수 있다.
- [0082] 또한, 본 발명의 일실시예에 따르면, 상기 데이터 테이블에 기록되어 있는 기상 데이터들의 집합을 구성하는 서로 다른 종류의 기상 데이터들은 온도, 습도, 구름량, 일사량일 수 있다.
- [0083] 이상, 도 3을 참조하여 본 발명의 일실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 방법에 대해 설명하였다. 여기서, 본 발명의 일실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 방법은 도 1을 이용하여 설명한 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치(110)의 동작에 대한 구성과 대응될 수 있으므로, 이에 대한 보다 상세한 설명은 생략하기로 한다.
- [0084] 도 4는 본 발명의 다른 실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 방법을 도시한 순서도이다.
- [0085] 단계(S410)에서는 하루 중 기설정된 피크 시간대 이전의 시간대에서 기설정된 단위 시간 간격으로 측정된 서로

다른 종류의 기상 데이터들의 집합과 상기 피크 시간대에서 상기 단위 시간 간격으로 측정된 태양광 발전량 데이터가 일별로 구분되어 기록되어 있는 데이터 테이블을 저장하여 유지한다.

- [0086] 단계(S420)에서는 상기 데이터 테이블에 일별로 구분되어 기록되어 있는 기상 데이터들의 집합과 태양광 발전량 데이터를 기계학습을 위한 트레이닝 세트와 기계학습 결과의 검증을 위한 테스트 세트로 랜덤하게 분류하되, 상기 트레이닝 세트의 개수가 상기 테스트 세트의 개수를 초과하도록 분류한다.
- [0087] 단계(S430)에서는 상기 트레이닝 세트로 분류된 기상 데이터들의 집합을 입력으로 지정하고, 대응되는 일자의 태양광 발전량 데이터를 출력으로 지정하여 제1 신경망 기반 모델, 제2 신경망 기반 모델 및 제3 신경망 기반 모델을 생성하기 위한 지도 학습 기반의 기계학습을 각각 수행함으로써, 상기 피크 시간대에서의 태양광 발전량을 예측하기 위한 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델을 각각 생성한다.
- [0088] 단계(S440)에서는 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델이 각각 생성되면, 상기 테스트 세트로 분류된 기상 데이터들의 집합과 대응되는 일자의 태양광 발전량 데이터를 기초로 상기 제1 신경망 기반의 예측 모델에 대한 제1 예측 정확도, 상기 제2 신경망 기반의 예측 모델에 대한 제2 예측 정확도 및 상기 제3 신경망 기반의 예측 모델에 대한 제3 예측 정확도를 측정한다.
- [0089] 단계(S450)에서는 상기 제1 예측 정확도, 상기 제2 예측 정확도 및 상기 제3 예측 정확도 간의 비율에 기초하여 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델에 가중치(각 예측 모델에 할당된 가중치의 총합은 1임)를 할당한다.
- [0090] 단계(S460)에서는 사용자로부터 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터에 대한 예측 명령이 인가되면서, 상기 제1 일자를 구성하는 시간 중 상기 피크 시간대 이전의 시간대에서 상기 단위 시간 간격으로 측정된 제1 기상 데이터들의 집합이 입력되는 경우, 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각에 상기 제1 기상 데이터들의 집합을 입력으로 인가하여 출력 데이터를 산출하고, 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델 각각에 할당되어 있는 가중치를 기초로 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델로부터 산출된 출력 데이터의 가중 평균을 연산한 후 상기 연산된 가중 평균을 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터로 산출한다.
- [0091] 단계(S470)에서는 단계(S460)을 통해 산출된 상기 제1 일자의 상기 피크 시간대에서의 상기 단위 시간 간격의 태양광 발전량 데이터를 상기 예측 명령에 대응하는 예측 데이터로 화면 상에 표시한다.
- [0092] 이때, 본 발명의 일실시예에 따르면, 상기 제1 신경망은 RNN이고, 상기 제2 신경망은 LSTM이며, 상기 제3 신경망은 GRU일 수 있다.
- [0093] 또한, 본 발명의 일실시예에 따르면, 상기 데이터 테이블에 기록되어 있는 기상 데이터들의 집합을 구성하는 서로 다른 종류의 기상 데이터들은 온도, 습도, 구름양, 일사량일 수 있다.
- [0094] 또한, 본 발명의 일실시예에 따르면, 단계(S450)에서는 상기 수학적 식에 따른 연산에 기초하여 상기 제1 신경망 기반의 예측 모델, 상기 제2 신경망 기반의 예측 모델 및 상기 제3 신경망 기반의 예측 모델에 가중치를 할당할 수 있다.
- [0095] 이상, 도 4를 참조하여 본 발명의 다른 실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 방법에 대해 설명하였다. 여기서, 본 발명의 다른 실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 방법은 도 2를 이용하여 설명한 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치(210)의 동작에 대한 구성과 대응될 수 있으므로, 이에 대한 보다 상세한 설명은 생략하기로 한다.
- [0096] 본 발명의 일실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 방법은 컴퓨터와의 결합을 통해 실행시키기 위한 저장매체에 저장된 컴퓨터 프로그램으로 구현될 수 있다.
- [0097] 또한, 본 발명의 일실시예에 따른 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로

또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 본 발명을 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.

[0098] 이상과 같이 본 발명에서는 구체적인 구성 요소 등과 같은 특정 사항들과 한정된 실시예 및 도면에 의해 설명되었으나 이는 본 발명의 보다 전반적인 이해를 돕기 위해서 제공된 것일 뿐, 본 발명은 상기의 실시예에 한정되는 것은 아니며, 본 발명이 속하는 분야에서 통상적인 지식을 가진 자라면 이러한 기재로부터 다양한 수정 및 변형이 가능하다.

[0099] 따라서, 본 발명의 사상은 설명된 실시예에 국한되어 정해져서는 아니되며, 후술하는 특허청구범위뿐 아니라 이 특허청구범위와 균등하거나 등가적 변형이 있는 모든 것들은 본 발명 사상의 범주에 속한다고 할 것이다.

## 부호의 설명

[0100] 110: 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치

111: 측정 테이블 유지부                      112: 예측 모델 생성부

113: 예측부                      114: 표시부

210: 미래의 기상 예보 데이터를 이용하지 않는 기계학습 기반의 태양광 발전량 예측 장치

211: 측정 테이블 유지부                      212: 세트 분류부


213: 예측 모델 생성부                      214: 정확도 측정부

215: 가중치 할당부                      216: 예측부


217: 표시부

## 도면


도면1



도면2



도면3



도면4

