(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2023-0084833
(43) 공개일자 2023년06월13일

(51) 국제특허분류(Int. Cl.)
*G01V 1/40* (2006.01) *E21B 41/00* (2006.01)
*G06N 3/04* (2023.01) *G06N 3/08* (2023.01)
(52) CPC특허분류
*G01V 1/40* (2013.01)
*E21B 41/00* (2020.05)
(21) 출원번호 10-2021-0172917
(22) 출원일자 2021년12월06일
심사청구일자 2021년12월06일

(71) 출원인
**이화여자대학교 산학협력단**
서울특별시 서대문구 이화여대길 52 (대현동, 이화여자대학교)
(72) 발명자
**민배현**
서울특별시 서초구 고무래로 89, 104동 701호(반포동, 반포써밋)
**박가영**
서울특별시 마포구 마포대로 246, 103동 1904호(아현동, 아현아이파크)
*(뒷면에 계속)*
(74) 대리인
**특허법인 무한**

전체 청구항 수 : 총 20 항

(54) 발명의 명칭 **물리 검층 데이터에 기초한 저류층 인자 추정 방법 및 장치**

## (57) 요 약

물리 검층 데이터에 기초한 저류층 인자 추정 방법 및 장치가 개시된다. 저류층 인자 추정용 신경망 학습 방법은 학습용 데이터의 특성에 따라 딥러닝 알고리즘을 선택하는 단계; 선택된 딥러닝 알고리즘에 따라 학습용 데이터의 형태를 변환하는 단계; 형태가 변환된 학습용 데이터를 이용하여 신경망을 학습하는 단계; 및 학습된 신경망을 평가하고, 평가 결과에 따라 저류층 인자 추정용 신경망을 결정하는 단계를 포함할 수 있다.

*대 표 도* - 도1

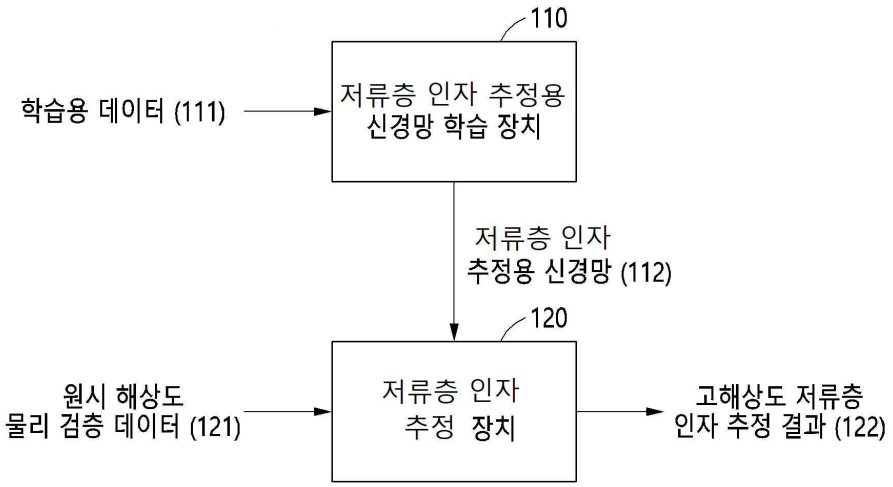

(52) CPC특허분류
*G06N 3/04* (2023.01)
*G06N 3/08* (2023.01)
*E21B 2200/20* (2020.05)
*E21B 2200/22* (2020.05)
(72) 발명자
**권서윤**
경기도 성남시 분당구 동판교로 123, 106동 1003호(백현동, 백현마을1단지판교푸르지오그랑블아파트)
**지민수**
인천광역시 연수구 원인재로 88, 110동 1501호(동춘동, 대우삼환아파트)

이 발명을 지원한 국가연구개발사업

| | |
|---|---|
| 과제고유번호 | 1711144660 |
| 과제번호 | 2019R1C1C1002574 |
| 부처명 | 과학기술정보통신부 |
| 과제관리(전문)기관명 | 한국연구재단 |
| 연구사업명 | 개인기초연구(과기정통부)(R&D) |
| 연구과제명 | 석유가스전 생애주기의 단계별 최적 운영을 위한 저류층 빅데이타와 심층학습 기반의 의사결정지원 자동화 시스템 개발 |
| 기 여 율 | 1/1 |
| 과제수행기관명 | 이화여자대학교 |
| 연구기간 | 2021.03.01 ~ 2022.02.28 |

# 명 세 서

## 청구범위

### 청구항 1

학습용 데이터의 특징에 따라 선택된 딥러닝 알고리즘을 이용하여 학습된 저류층 인자 추정용 신경망을 수신하는 단계;

원시 해상도의 물리 검층 데이터를 입력받는 단계; 및

상기 저류층 인자 추정용 신경망에 물리 검층 데이터를 입력하여 상기 물리 검층 데이터의 원시 해상도보다 해상도가 높은 저류층 인자를 추정하는 단계

를 포함하는 저류층 인자 추정 방법.

### 청구항 2

제1항에 있어서,

상기 저류층 인자 추정용 신경망은,

선택된 딥러닝 알고리즘이 DNN인 경우, 1차원 벡터의 형태로 변환된 학습용 데이터를 이용하여 학습되는 저류층 인자 추정 방법.

### 청구항 3

제1항에 있어서,

상기 저류층 인자 추정용 신경망은,

선택된 딥러닝 알고리즘이 CNN인 경우, 3차원 배열의 형태로 변환된 학습용 데이터를 이용하여 학습되는 저류층 인자 추정 방법.

### 청구항 4

제1항에 있어서,

상기 저류층 인자 추정용 신경망은,

선택된 딥러닝 알고리즘이 LSTM인 경우, 2차원 배열의 형태로 변환된 학습용 데이터를 이용하여 학습되는 저류층 인자 추정 방법.

### 청구항 5

제1항에 있어서,

상기 저류층 인자 추정용 신경망은,

원시 해상도가 1/M으로 변환된 학습용 데이터의 입력 데이터를 입력받아 학습되고, 해상도를 변환하지 않은 입력 데이터를 학습된 신경망에 입력하여 생성된 출력 데이터에 기초한 평가로 결정되는 저류층 인자 추정 방법.

### 청구항 6

제1항에 있어서,

상기 저류층 인자 추정용 신경망은,

상기 학습용 데이터에 코어 데이터가 포함된 경우, 학습용 데이터의 특징에 따라 선택된 딥러닝 알고리즘을 이용하여 1차 학습하고, 상기 학습용 데이터에서 상기 코어 데이터에 대응하는 심도의 정답 데이터를 상기 코어 데이터로 교체하며, 상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 1차 학습된 신경망에 적용한 2차 학습을 수행하여 결정되는 저류층 인자 추정 방법.

**청구항 7**

학습용 데이터의 특성에 따라 딥러닝 알고리즘을 선택하는 단계;

선택된 딥러닝 알고리즘에 따라 학습용 데이터의 형태를 변환하는 단계;

형태가 변환된 학습용 데이터를 이용하여 신경망을 학습하는 단계; 및

학습된 신경망을 평가하고, 평가 결과에 따라 저류층 인자 추정용 신경망을 결정하는 단계

를 포함하는 저류층 인자 추정용 신경망 학습 방법.

**청구항 8**

제7항에 있어서,

상기 딥러닝 알고리즘을 선택하는 단계는,

상기 학습용 데이터의 특성에 따라 DNN(deep neural network), CNN(convolutional neural network), 및 LSTM(long short-term memory) 등 다양한 딥러닝 알고리즘 중 하나를 선택하는 저류층 인자 추정용 신경망 학습 방법.

**청구항 9**

제8항에 있어서,

상기 학습용 데이터의 형태를 변환하는 단계는,

선택된 딥러닝 알고리즘이 DNN인 경우, 상기 학습용 데이터를 1차원 벡터의 형태로 변환하는 저류층 인자 추정용 신경망 학습 방법.

**청구항 10**

제8항에 있어서,

상기 학습용 데이터의 형태를 변환하는 단계는,

선택된 딥러닝 알고리즘이 CNN인 경우, 상기 학습용 데이터를 3차원 배열의 형태로 변환하는 저류층 인자 추정용 신경망 학습 방법.

**청구항 11**

제8항에 있어서,

상기 학습용 데이터의 형태를 변환하는 단계는,

선택된 딥러닝 알고리즘이 LSTM인 경우, 상기 학습용 데이터를 2차원 배열의 형태로 변환하는 저류층 인자 추정용 신경망 학습 방법.

**청구항 12**

제7항에 있어서,

상기 신경망은,

상기 학습용 데이터의 i 번째 입력 데이터와 i+1 번째 입력 데이터의 쌍을 입력 받아 M(i-1)+1 번째 출력 데이터 내지 M i+1 번째 출력 데이터의 쌍을 추정하도록 설계되며,

상기 M은,

상기 신경망을 통하여 증가되는 해상도의 배율인 저류층 인자 추정용 신경망 학습 방법.

**청구항 13**

제7항에 있어서,

상기 학습용 데이터의 형태를 변환하는 단계는,

상기 학습용 데이터의 입력 데이터의 원시 해상도를 1/M으로 변환하고,

상기 결정하는 단계는,

해상도를 변환하지 않은 입력 데이터를 상기 신경망에 입력하여 생성된 출력 데이터를 이용하여 상기 신경망을 평가하는 저류층 인자 추정용 신경망 학습 방법.

**청구항 14**

제7항에 있어서,

상기 신경망의 성능이 기준 성능을 초과할 때까지 상기 학습용 데이터에 훈련, 검증 및 테스트를 반복 수행하여 상기 신경망을 갱신하는 단계

를 더 포함하는 저류층 인자 추정용 신경망 학습 방법.

**청구항 15**

제7항에 있어서,

상기 학습용 데이터는,

출력 저류층 인자가 고해상도 합성 물리 검층 데이터이고, 정답 데이터는 원시 물리 검층 데이터이며, 원시 물리 검층 데이터는 입력 데이터와 동일한 해상도를 가지는 저류층 인자 추정용 신경망 학습 방법.

**청구항 16**

제7항에 있어서,

상기 학습용 데이터에 코어 데이터가 포함되었는지 여부를 확인하는 단계;

상기 학습용 데이터에 코어 데이터가 포함된 경우, 상기 학습용 데이터에서 상기 코어 데이터에 대응하는 심도의 정답 데이터를 상기 코어 데이터로 교체하는 단계;

상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터의 형태를 상기 선택된 딥러닝 알고리즘에 따라 변환하는 단계; 및

상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 상기 학습된 신경망에 적용하여 2차 학습을 수행하는 단계;

를 더 포함하고,

상기 결정하는 단계는,

2차 학습을 수행한 신경망을 평가하는 저류층 인자 추정용 신경망 학습 방법.

**청구항 17**

학습용 데이터의 특성에 따라 딥러닝 알고리즘을 선택하는 단계;

선택된 딥러닝 알고리즘에 따라 학습용 데이터의 형태를 변환하는 단계;

형태가 변환된 학습용 데이터를 이용하여 신경망을 1차 학습하는 단계;

상기 학습용 데이터에서 코어 데이터에 대응하는 심도의 정답 데이터를 상기 코어 데이터로 교체하는 단계;

상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터의 형태를 상기 선택된 딥러닝 알고리즘에 따라 변환하는 단계;

상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 1차 학습된 신경망에 적용하여 2차 학습을 수행하는 단계; 및

2차 학습된 신경망을 평가하고, 평가 결과에 따라 저류층 인자 추정용 신경망을 결정하는 단계

를 포함하는 저류층 인자 추정용 신경망 학습 방법.

**청구항 18**

제1항 내지 제17항 중 어느 한 항의 방법을 실행하기 위한 프로그램이 기록된 컴퓨터에서 판독 가능한 기록 매체.

**청구항 19**

학습용 데이터의 특성에 따라 딥러닝 알고리즘을 선택하고,

선택된 딥러닝 알고리즘에 따라 학습용 데이터의 형태를 변환하며,

형태가 변환된 학습용 데이터를 이용하여 신경망을 학습하고,

학습된 신경망을 평가하고, 평가 결과에 따라 저류층 인자 추정용 신경망을 결정하는 프로세서; 및

상기 저류층 인자 추정용 신경망을 저류층 인자 추정 장치로 전송하는 입출력기

를 포함하는 저류층 인자 추정용 신경망 학습 장치.

**청구항 20**

제19항에 있어서,

상기 프로세서는,

상기 학습용 데이터에 코어 데이터가 포함되었는지 여부를 확인하고,

상기 학습용 데이터에 코어 데이터가 포함된 경우, 상기 학습용 데이터에서 상기 코어 데이터에 대응하는 심도의 정답 데이터를 상기 코어 데이터로 교체하며,

상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 상기 학습된 신경망에 적용하여 2차 학습을 수행하고,

2차 학습을 수행한 신경망을 평가하는 저류층 인자 추정용 신경망 학습 장치.

## *발명의 설명*

### *기 술 분 야*

[0001] 본 발명은 저류층 인자 추정 방법 및 장치에 관한 것으로, 보다 구체적으로는 저류층 인자 추정용 신경망을 이용하여 원시 해상도의 물리 검층 데이터로부터 원시 해상도보다 해상도가 높은 고해상도로 저류층 인자를 추정하는 방법 및 장치에 관한 것이다.

### *배 경 기 술*

[0002] 석유 산업에서 저류층 모델 설계는 석유 및 가스전에서 탄화수소 생산의 경제적 이점을 극대화하는 것을 목표로 하고 있다. 전체 물리 저류층 시뮬레이션(Full-physics reservoir simulation)은 수십 년 동안 산업 표준 생산성 평가 도구로 사용 되었다.

[0003] 저류층 시뮬레이션에서 저류층 인자 해석의 근간이 되는 공극률, 수포화도와 같은 물리 검층 데이터는 시추공에서 취득한 코어 데이터와 데이터의 양, 품질, 해상도 측면에서 서로 다른 특성을 보여 자료 통합 해석이 어려운 실정이다.

[0004] 구체적으로, 시추공을 따라 균일한 간격으로 측정하는 물리 검층 데이터에 비하여 관심 영역에서만 획득하는 코어 데이터는 편재성이 있으며, 코어 데이터와 물리 검층 데이터의 해상도가 상이하므로, 물리 검층 데이터와 코어 데이터를 모두 사용하지 못하고 있는 실정이다.

[0005] 따라서, 입력 데이터보다 고해상도로 저류층 인자를 추정하거나, 물리 검층 데이터와 코어 데이터를 모두 사용하여 저류층 인자를 추정하는 방법이 요청되고 있다.

### *발명의 내용*

### 해결하려는 과제

[0006] 본 발명은 학습용 데이터의 특징에 따라 선택된 딥러닝 알고리즘으로 학습된 저류층 인자 추정용 신경망을 이용함으로써, 원시 해상도의 물리 검층 데이터로부터 원시 해상도보다 해상도가 높은 고해상도로 저류층 인자를 추정 하는 방법 및 장치를 제공한다.

[0007] 본 발명은 신경망에 1차 학습을 수행하고, 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 1차 학습된 신경망에 적용함으로써, 저류층 인자 데이터를 이용하여 저류층 인자 추정용 신경망을 결정하는 방법 및 장치를 제공한다.

### 과제의 해결 수단

[0008] 본 발명의 일실시예에 따른 저류층 인자 추정 방법은 학습용 데이터의 특징에 따라 선택된 딥러닝 알고리즘을 이용하여 학습된 저류층 인자 추정용 신경망을 수신하는 단계; 원시 해상도의 물리 검층 데이터를 입력받는 단계; 및 상기 저류층 인자 추정용 신경망에 물리 검층 데이터를 입력하여 상기 물리 검층 데이터의 원시 해상도보다 해상도가 높은 저류층 인자를 추정하는 단계를 포함할 수 있다.

[0009] 본 발명의 일실시예에 따른 저류층 인자 추정 방법의 상기 저류층 인자 추정용 신경망은, 선택된 딥러닝 알고리즘이 DNN인 경우, 1차원 벡터의 형태로 변환된 학습용 데이터를 이용하여 학습될 수 있다.

[0010] 본 발명의 일실시예에 따른 저류층 인자 추정 방법의 상기 저류층 인자 추정용 신경망은, 선택된 딥러닝 알고리즘이 CNN인 경우, 3차원 배열의 형태로 변환된 학습용 데이터를 이용하여 학습될 수 있다.

[0011] 본 발명의 일실시예에 따른 저류층 인자 추정 방법의 상기 저류층 인자 추정용 신경망은, 선택된 딥러닝 알고리즘이 LSTM인 경우, 2차원 배열의 형태로 변환된 학습용 데이터를 이용하여 학습될 수 있다.

[0012] 본 발명의 일실시예에 따른 저류층 인자 추정 방법의 상기 저류층 인자 추정용 신경망은, 원시 해상도가 1/M으로 변환된 학습용 데이터의 입력 데이터를 입력받아 학습되고, 해상도를 변환하지 않은 입력 데이터를 학습된 신경망에 입력하여 생성된 출력 데이터에 기초한 평가로 결정될 수 있다.

[0013] 본 발명의 일실시예에 따른 저류층 인자 추정 방법의 상기 저류층 인자 추정용 신경망은, 상기 학습용 데이터에 코어 데이터가 포함된 경우, 학습용 데이터의 특징에 따라 선택된 딥러닝 알고리즘을 이용하여 1차 학습하고, 상기 학습용 데이터에서 상기 코어 데이터에 대응하는 심도의 정답 데이터를 상기 코어 데이터로 교체하며, 상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 1차 학습된 신경망에 적용한 2차 학습을 수행하여 결정될 수 있다.

[0014] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법은 학습용 데이터의 특성에 따라 딥러닝 알고리즘을 선택하는 단계; 선택된 딥러닝 알고리즘에 따라 학습용 데이터의 형태를 변환하는 단계; 형태가 변환된 학습용 데이터를 이용하여 신경망을 학습하는 단계; 및 학습된 신경망을 평가하고, 평가 결과에 따라 저류층 인자 추정용 신경망을 결정하는 단계를 포함할 수 있다.

[0015] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법의 상기 딥러닝 알고리즘을 선택하는 단계는, 상기 학습용 데이터의 특성에 따라 DNN(deep neural network), CNN(convolutional neural network), 및 LSTM(long short-term memory) 등 다양한 딥러닝 알고리즘 중 하나를 선택할 수 있다.

[0016] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법의 상기 학습용 데이터의 형태를 변환하는 단계는, 선택된 딥러닝 알고리즘이 DNN인 경우, 상기 학습용 데이터를 1차원 벡터의 형태로 변환할 수 있다.

[0017] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법의 상기 학습용 데이터의 형태를 변환하는 단계는, 선택된 딥러닝 알고리즘이 CNN인 경우, 상기 학습용 데이터를 3차원 배열의 형태로 변환할 수 있다.

[0018] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법의 상기 학습용 데이터의 형태를 변환하는 단계는, 선택된 딥러닝 알고리즘이 LSTM인 경우, 상기 학습용 데이터를 2차원 배열의 형태로 변환할 수 있다.

[0019] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법의 상기 신경망은, 상기 학습용 데이터의 i 번째 입력 데이터와 i+1 번째 입력 데이터의 쌍을 입력 받아 M(i-1)+1 번째 출력 데이터 내지 M i+1 번째 출력 데이터의 쌍을 추정하도록 설계되며, 상기 M은, 상기 신경망을 통하여 증가되는 해상도의 배율일 수 있다.

[0020] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법의 상기 학습용 데이터의 형태를 변환하는 단

계는, 상기 학습용 데이터의 입력 데이터의 원시 해상도를 1/M으로 변환하고, 상기 결정하는 단계는, 해상도를 변환하지 않은 입력 데이터를 상기 신경망에 입력하여 생성된 출력 데이터를 이용하여 상기 신경망을 평가할 수 있다.

[0021] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법은 상기 신경망의 성능이 기준 성능을 초과할 때까지 상기 학습용 데이터에 훈련, 검증 및 테스트를 반복 수행하여 상기 신경망을 갱신하는 단계를 더 포함할 수 있다.

[0022] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법의 상기 학습용 데이터는, 출력 저류층 인자가 고해상도 합성 물리 검층 데이터이고, 정답 데이터는 원시 물리 검층 데이터이며, 원시 물리 검층 데이터는 입력 데이터와 동일한 해상도를 가질 수 있다.

[0023] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법은 상기 학습용 데이터에 코어 데이터가 포함되었는지 여부를 확인하는 단계; 상기 학습용 데이터에 코어 데이터가 포함된 경우, 상기 학습용 데이터에서 상기 코어 데이터에 대응하는 심도의 정답 데이터를 상기 코어 데이터로 교체하는 단계; 상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터의 형태를 상기 선택된 딥러닝 알고리즘에 따라 변환하는 단계; 상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 상기 학습된 신경망에 적용하여 2차 학습을 수행하는 단계;를 더 포함하고, 상기 결정하는 단계는, 2차 학습을 수행한 신경망을 평가할 수 있다.

[0024] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법은 학습용 데이터의 특성에 따라 딥러닝 알고리즘을 선택하는 단계; 선택된 딥러닝 알고리즘에 따라 학습용 데이터의 형태를 변환하는 단계; 형태가 변환된 학습용 데이터를 이용하여 신경망을 1차 학습하는 단계; 상기 학습용 데이터에서 상기 코어 데이터에 대응하는 심도의 정답 데이터를 상기 코어 데이터로 교체하는 단계; 상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터의 형태를 상기 선택된 딥러닝 알고리즘에 따라 변환하는 단계; 상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 1차 학습된 신경망에 적용하여 2차 학습을 수행하는 단계; 2차 학습된 신경망을 평가하고, 평가 결과에 따라 저류층 인자 추정용 신경망을 결정하는 단계를 포함할 수 있다.

[0025] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 장치는 학습용 데이터의 특성에 따라 딥러닝 알고리즘을 선택하고, 선택된 딥러닝 알고리즘에 따라 학습용 데이터의 형태를 변환하며, 형태가 변환된 학습용 데이터를 이용하여 신경망을 학습하고, 학습된 신경망을 평가하고, 평가 결과에 따라 저류층 인자 추정용 신경망을 결정하는 프로세서; 및 상기 저류층 인자 추정용 신경망을 저류층 인자 추정 장치로 전송하는 입출력기를 포함할 수 있다.

[0026] 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 장치의 상기 프로세서는, 상기 학습용 데이터에 코어 데이터가 포함되었는지 여부를 확인하고, 상기 학습용 데이터에 코어 데이터가 포함된 경우, 상기 학습용 데이터에서 상기 코어 데이터에 대응하는 심도의 정답 데이터를 상기 코어 데이터로 교체하며, 상기 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 상기 학습된 신경망에 적용하여 2차 학습을 수행하고, 2차 학습을 수행한 신경망을 평가할 수 있다.

## *발명의 효과*

[0027] 본 발명의 일실시예에 의하면, 학습용 데이터의 특징에 따라 선택된 딥러닝 알고리즘으로 학습된 저류층 인자 추정용 신경망을 이용함으로써, 원시 해상도의 물리 검층 데이터로부터 원시 해상도보다 해상도가 높은 고해상도로 저류층 인자를 추정할 수 있다.

[0028] 본 발명의 일실시예에 의하면, 신경망에 1차 학습을 수행하고, 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 1차 학습된 신경망에 적용함으로써, 저류층 인자 데이터를 이용하여 저류층 인자 추정용 신경망을 결정할 수 있다.

## *도면의 간단한 설명*

[0029] 도 1은 본 발명의 일실시예에 따른 저류층 인자 추정 시스템을 도시한 도면이다.

도 2는 본 발명의 일실시예에 따른 학습용 데이터의 일례이다.

도 3은 본 발명의 일실시예에 따른 신경망(CNN)의 일례이다.

도 4는 본 발명의 일실시예에 따른 신경망(LSTM)의 일례이다.

도 5는 본 발명의 일실시예에 따른 저류층 인자 추정 과정의 개념도이다.

도 6은 본 발명의 일실시예에 따라 고해상도의 저류층 인자를 추정하는 과정의 일례이다.

도 7은 본 발명의 일실시예에 따른 저류층 인자 추정 장치의 입출력 데이터의 일례들이다.

도 8은 본 발명의 일실시예에 따라 딥러닝 알고리즘에 기초하여 학습용 데이터의 형태를 변환하는 일례이다.

도 9는 코어 데이터가 없는 경우,본 발명의 일실시예에 따라 신경망을 학습하는 과정의 일례이다.

도 10은 코어 데이터가 있는 경우,본 발명의 일실시예에 따라 신경망을 학습하는 과정의 일례이다.

도 11은 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법을 도시한 플로우차트이다.

도 12는 본 발명의 일실시예에 따른 저류층 인자 추정 방법을 도시한 플로우차트이다.

## *발명을 실시하기 위한 구체적인 내용*

[0030] 이하에서, 첨부된 도면을 참조하여 실시예들을 상세하게 설명한다. 그러나, 실시예들에는 다양한 변경이 가해질 수 있어서 특허출원의 권리 범위가 이러한 실시예들에 의해 제한되거나 한정되는 것은 아니다. 실시예들에 대한 모든 변경, 균등물 내지 대체물이 권리 범위에 포함되는 것으로 이해되어야 한다.

[0031] 실시예에서 사용한 용어는 단지 설명을 목적으로 사용된 것으로, 한정하려는 의도로 해석되어서는 안된다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 명세서에서, "포함하다" 또는 "가지다" 등의 용어는 명세서 상에 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.

[0032] 또한, 첨부 도면을 참조하여 설명함에 있어, 도면 부호에 관계없이 동일한 구성 요소는 동일한 참조부호를 부여하고 이에 대한 중복되는 설명은 생략하기로 한다. 실시예를 설명함에 있어서 관련된 공지 기술에 대한 구체적인 설명이 실시예의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우 그 상세한 설명을 생략한다.

[0033] 이하, 본 발명의 실시예를 첨부된 도면을 참조하여 상세하게 설명한다.

[0034] 도 1은 본 발명의 일실시예에 따른 저류층 인자 추정 시스템을 도시한 도면이다.

[0035] 저류층 인자 추정 시스템은 도 1에 도시된 바와 같이 저류층 인자 추정용 신경망 학습 장치(110) 및 저류층 인자 추정 장치(120)를 포함할 수 있다.

[0036] 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)의 특성에 따라 딥러닝 알고리즘을 선택할 수 있다. 이때, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)의 특성에 따라 DNN(deep neural network), CNN(convolutional neural network), 및 LSTM(long short-term memory) 등 다양한 딥러닝 알고리즘 중 하나를 선택할 수 있다. 구체적으로, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 딥러닝 알고리즘 학습 과정에서 계산되는 손실 함수(loss function), 학습자료와 예측자료의 상관도 및 정확도를 나타내는 상관 계수(correlation coefficient), 결정 계수(coefficient of determination)과 같은 신경망 성능 지표가 가장 높은 알고리즘을 선정할 수 있다.

[0037] 다음으로, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 선택된 딥러닝 알고리즘에 따라 학습용 데이터(111)의 형태를 변환할 수 있다. 예를 들어, 선택된 딥러닝 알고리즘이 DNN인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)를 1차원 벡터의 형태로 변환할 수 있다. 또한, 선택된 딥러닝 알고리즘이 CNN인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)를 3차원 배열의 형태로 변환할 수 있다. 그리고, 선택된 딥러닝 알고리즘이 LSTM인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)를 2차원 배열의 형태로 변환할 수 있다.

[0038] 또한, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)의 입력 데이터의 원시 해상도를 1/M으로 변환할 수 있다.

[0039] 그 다음으로, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 형태가 변환된 학습용 데이터(111)를 이

용하여 신경망을 학습할 수 있다. 이때, 신경망은, 학습용 데이터(111)의 i 번째 입력 데이터와 i+1 번째 입력 데이터의 쌍을 입력 받아 M(i-1)+1 번째 출력 데이터 내지 M i+1 번째 출력 데이터의 쌍을 추정하도록 설계되며, M은 신경망을 통하여 증가되는 해상도의 배율일 수 있다.

[0040] 그리고, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 신경망의 성능이 기준 성능을 초과할 때까지 학습용 데이터(111)에 훈련, 검증 및 테스트를 반복 수행하여 신경망을 갱신할 수 있다.

[0041] 다음으로, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습된 신경망을 평가하고, 평가 결과에 따라 저류층 인자 추정용 신경망(112)을 결정할 수 있다. 이때, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 해상도를 변환하지 않은 입력 데이터를 신경망에 입력하여 생성된 출력 데이터를 이용하여 신경망을 평가할 수 있다.

[0042] 또한, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)에 코어 데이터가 포함되었는지 여부를 확인할 수 있다. 그리고, 학습용 데이터(111)에 코어 데이터가 포함된 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)에서 코어 데이터에 대응하는 심도의 정답 데이터를 코어 데이터로 교체할 수 있다. 이때, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터(111)의 형태를 선택된 딥러닝 알고리즘에 따라 변환할 수 있다. 그리고, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터(111)를 학습된 신경망에 적용하여 2차 학습을 수행할 수 있다. 이때, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 2차 학습을 수행한 신경망을 평가할 수 있다.

[0043] 학습용 데이터(111)의 출력 저류층 인자가 고해상도 합성 물리 검층 데이터이고, 정답 데이터는 원시 물리 검층 데이터이며, 원시 물리 검층 데이터는 입력 데이터와 동일한 해상도를 가지는 경우, 상기 동작들의 수행으로 저류층 인자 추정용 신경망의 학습이 종료될 수 있다.

[0044] 다만, 학습용 데이터(111)의 출력 저류층 인자가 저류층 인자 데이터인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 2단계로 학습을 수행할 수 있다.

[0045] 이때, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)의 특성에 따라 딥러닝 알고리즘을 선택할 수 있다. 그리고, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 선택된 딥러닝 알고리즘에 따라 학습용 데이터(111)의 형태를 변환할 수 있다. 또한, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 형태가 변환된 학습용 데이터(111)를 이용하여 신경망을 1차 학습할 수 있다. 이때, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)에서 코어 데이터에 대응하는 심도의 정답 데이터를 코어 데이터로 교체할 수 있다. 그리고, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터(111)의 형태를 선택된 딥러닝 알고리즘에 따라 변환할 수 있다. 또한, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터(111)를 1차 학습된 신경망에 적용하여 2차 학습을 수행할 수 있다. 그리고, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 2차 학습된 신경망을 평가하고, 평가 결과에 따라 저류층 인자 추정용 신경망을 결정할 수 있다.

[0046] 저류층 인자 추정용 신경망 학습 장치(110)의 입출력기는 결정된 저류층 인자 추정용 신경망(112)을 저류층 인자 추정 장치(120)로 전송할 수 있다.

[0047] 저류층 인자 추정 장치(120)의 입출력기는 저류층 인자 추정용 신경망 학습 장치(110)로부터 저류층 인자 추정용 신경망(112)을 수신할 수 있다. 또한, 저류층 인자 추정 장치(120)의 입출력기는 물리 검층 데이터(121)를 입력받을 수 있다. 이때, 물리 검층 데이터(121)의 해상도는 원시 해상도일 수 있다.

[0048] 그리고, 저류층 인자 추정 장치(120)의 프로세서는 저류층 인자 추정용 신경망(112)에 물리 검층 데이터(121)를 입력하여 물리 검층 데이터(121)의 원시 해상도보다 해상도가 높은 고해상도로 저류층 인자를 추정할 수 있다.

[0049] 본 발명에 따른 저류층 인자 추정 시스템은 학습용 데이터의 특징에 따라 선택된 딥러닝 알고리즘으로 학습된 저류층 인자 추정용 신경망을 이용함으로써, 원시 해상도의 물리 검층 데이터로부터 원시 해상도보다 해상도가 높은 고해상도로 저류층 인자를 추정할 수 있다.

[0050] 본 발명에 따른 저류층 인자 추정 시스템은 신경망에 1차 학습을 수행하고, 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 1차 학습된 신경망에 적용함으로써, 저류층 인자 데이터를 이용하여 저류층 인자 추정용 신경망을 결정할 수 있다.

[0051] 도 2는 본 발명의 일실시예에 따른 학습용 데이터의 일례이다.

[0052] 기계 학습에 사용되는 학습용 데이터는 학습 데이터(training data)(210), 검증 데이터(validation data)(220), 및 시험 데이터(test data)(230)로 구성될 수 있다.

[0053] 학습 데이터(210)는 알고리즘을 학습시키는 과정에서 사용되는 데이터로 전체 데이터의 50-70%일 수 있다. 또한, 검증 데이터(220)는 알고리즘의 학습 과정에서 현재 학습성능을 평가하기 위하여 학습 데이터와 함께 사용되는 데이터이며, 전체 데이터의 15-25%일 수 있다. 그리고, 시험 데이터(230)는 학습이 모두 완료되고 난 뒤 최종 학습성능을 평가하는데 사용되는 데이터이며, 전체 데이터의 15-25%일 수 있다.

[0054] 이때, 학습 데이터(210), 검증 데이터(220), 시험 데이터(230)는 데이터가 편향되지 않도록 구성되어야 하므로, 교차검증(cross validation)을 통해 알고리즘의 일반화 성능을 확인할 수 있다 예를 들어, 학습용 데이터(111)는 k-fold 교차 검증 방법에 따라 구성될 수 있다.

[0055] k-fold 교차 검증이란 알고리즘의 학습 과정에서 학습용 데이터(111)의 전체 데이터를 단순히 한번 나누어 고정된 학습 데이터와 시험 데이터로 구성하는 것이 아니라 k번 나누어 매번 다른 학습 데이터와 시험 데이터를 구성하여 총 k회 학습되도록 할 수 있다. 예를 들어, k가 5인 경우, 학습용 데이터(111)는 도 2에 도시된 바와 같이 구성될 수 있다.

[0056] 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)의 전체 데이터를 Fold 1에서 Fold 5까지 5등분하여 구분하였을 때 먼저 Fold 1을 시험 데이터(230)로, Fold 2를 검증 데이터(220)로, 나머지 Fold 3, Fold 4, Fold 5를 학습 데이터(210)로 사용하여 학습을 진행하고 현재 학습 성능을 평가한다.

[0057] 그리고, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 도 2에 도시된 바와 같이 이와 같은 과정을 Fold를 바꾸어 가며 5회 반복하여 총 5개의 학습 성능 평가 결과를 획득할 수 있다. 이때, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 5개 결과를 평균한 값을 현재 신경망의 최종 학습성능 평가 결과로 결정할 수 있다.

[0058] 또한 학습용 데이터(111)는 각 시추공에서 얻어진 물리 검층 데이터와 코어 데이터이므로, 최소 수십~최대 수 km 떨어져 있는 시추공 설치지점의 지질학적 비균질성과 이방성을 고려하여 Fold를 섞지 않고 유정별로 구성할 수 있다.

[0059] 도 3은 본 발명의 일실시예에 따른 신경망(CNN)의 일례이다.

[0060] 합성곱 신경망(convolutional neural network, CNN)은 DNN과 달리 입력을 1차원으로 변환하지 않고 다차원 형태를 유지하며 압축시킬 수 있는 신경망 알고리즘이다.

[0061] CNN은 도 3에 도시된 바와 같이 컨볼루션 스테이지(convolution stage)(310) 와 풀 커넥션 스테이지(full-connection stage)(330)로 구성될 수 있다. 컨볼루션 스테이지(310)는 컨볼루션 레이어(convolution layer)과 풀링 레이어(pooling layer)이 두 번 반복 적용된 구조일 수 있다. 이때, 컨볼루션 레이어는 다차원 입력의 특징을 추출하는 구성이고, 풀링 레이어는 입력받은 데이터의 차원을 축소하는 구성일 수 있다.

[0062] 풀 커넥션 스테이지(330)는 컨볼루션 스테이지(310)에서 출력된 중간 결과 데이터를 1차원 데이터로 변환하여 입력 받고, 최종 결과 데이터를 출력할 수 있다.

[0063] 도 4는 본 발명의 일실시예에 따른 신경망(LSTM)의 일례이다.

[0064] 장단기 메모리(long short-term memory, LSTM)는 순차(sequence) 데이터를 처리할 때 데이터 순서 간의 유기성을 고려하도록 설계된 순환 신경망(recurrent neural network, RNN)의 일종으로, 기존 RNN에서 발생하는 장기 의존성(long-term dependency) 문제를 보완한 알고리즘일 수 있다.

[0065] 장기 의존성 문제는 데이터의 순차성을 시점이라 표현할 때, 멀리 떨어진 시점의 데이터일수록 기울기 소실로 인해 그 영향력이 감소하여 가까운 시점의 데이터만 반영되는 현상을 의미할 수 있다.

[0066] 즉, 종래의 RNN(410)은 셀 내에 단기메모리를 담당하는 은닉 상태(hidden state)가 순환되는 구조를 포함하여 단기 메모리만을 고려하는 반면, LSTM(420)은 은닉 상태에 장기메모리를 담당하는 셀 상태(cell state)가 추가되어 함께 순환되는 구조를 포함함으로써, 장단기 메모리를 모두 고려할 수 있다. 이때, 은닉 상태는 이전 시점까지 계산한 은닉층의 결과를 현재 시점의 은닉층에 직접 추가하기 위한 시스템을 의미하며, 셀 상태는 이전 시점까지 계산한 은닉층의 결과를 장기적으로 보존하기 위한 시스템을 의미할 수 있다.

[0067] 종래의 RNN(410)은 현재 시점 t의 은닉 상태 $H^{(t)}$를 계산하기 위하여 이전 시점 t - 1의 은닉 상태 $H^{(t-1)}$와 현재 시점 t의 입력 $X^{(t)}$에 대한 가중치 곱의 합에 편향 $b_h$ 를 추가하여 활성화함수로 tanh를 적용할 수 있다. 즉, 종래의 RNN(410)은 수학식 1을 사용하여 현재 시점 t의 은닉 상태 $H^{(t)}$를 계산할 수 있다.

*수학식 1*

[0068] $$H^{\langle t \rangle} = \tanh\left(W_{hx}X^{\langle t \rangle} + W_{hh}H^{\langle t-1 \rangle} + b_h\right),$$

[0069] 그리고, 계산된 $H^{(t)}$는 은닉층과 출력층 사이의 가중치 $W_{yh}$와 곱한 값에 편향 $b_y$를 추가하고, 활성화 함수로 softmax를 적용하여 현재 시점 t의 출력 $Y^{(t)}$를 도출할 수 있다. 즉, 종래의 RNN(410)은 수학식 2를 사용하여 출력 $Y^{(t)}$를 생성할 수 있다.

*수학식 2*

[0070] $$Y^{\langle t \rangle} = \text{softmax}\left(W_{yh}H^{\langle t \rangle} + b_y\right).$$

[0071] 다만, LSTM(420)은 현재 시점 t의 은닉 상태 $H^{(t)}$를 계산하는 과정이 종래의 RNN(410) 보다 복잡할 수 있다. LSTM 셀은 망각 게이트(forget gate), 입력 게이트(input gate), 출력 게이트(output gate)로 구성될 수 있다. 예를 들어, 망각 게이트(forget gate) $\Gamma_f^{\langle t \rangle}$ 의 출력은 수학식 3으로 나타낼 수 있다.

*수학식 3*

[0072] $$\Gamma_f^{\langle t \rangle} = \text{sigmoid}\left(W_f\left[H^{\langle t-1 \rangle}, X^{\langle t \rangle}\right] + b_f\right),$$

[0073] 또한, 입력 게이트(input gate) $\Gamma_i^{\langle t \rangle}$ 의 출력은 수학식 4로 나타낼 수 있다.

*수학식 4*

[0074] $$\Gamma_i^{\langle t \rangle} = \text{sigmoid}\left(W_i\left[H^{\langle t-1 \rangle}, X^{\langle t \rangle}\right] + b_i\right),$$

[0075] 그리고, 출력 게이트(output gate) $\Gamma_o^{\langle t \rangle}$ 의 출력은 수학식 5로 나타낼 수 있다.

*수학식 5*

[0076] $$\Gamma_o^{\langle t \rangle} = \text{sigmoid}\left(W_o\left[H^{\langle t-1 \rangle}, X^{\langle t \rangle}\right] + b_o\right),$$

[0077] 이때, 게이트들 각각은 수학식 3 내지 5에 도시된 바와 같이 이전 시점 t - 1의 은닉 상태 $H^{(t-1)}$와 현재 시점 t의 입력 $X^{(t)}$에 대한 가중치 곱의 합에 편향을 추가하여 활성화함수로 sigmoid를 적용할 수 있다. 그러나, 게이트들 각각이 수행하는 역할은 서로 다를 수 있다.

[0078] 망각 게이트 $\Gamma_f^{\langle t \rangle}$는 과거 정보를 얼마나 제외하고 유지할지를 결정할 수 있다. 또한, 입력 게이트 $\Gamma_i^{\langle t \rangle}$는 현재 정보를 얼마나 반영할지를 결정할 수 있다. 그리고, 출력 게이트 $\Gamma_o^{\langle t \rangle}$는 얼마나 출력할지를 결정할 수 있다.

[0079] 따라서, 현재 시점 t의 셀 상태 $C^{(t)}$는 이전 시점 t - 1의 셀 상태 $C^{(t-1)}$과 현재 시점 t의 후보 셀 상태 $\tilde{C}^{\langle t \rangle}$에 각각 망각 게이트 $\Gamma_f^{\langle t \rangle}$ 및 입력 게이트 $\Gamma_i^{\langle t \rangle}$를 적용하여 계산될 수 있다. 이때, 현재 시점 t의 후보 셀 상태 $\tilde{C}^{\langle t \rangle}$는 수학식 6에 따라 계산될 수 있다.

*수학식 6*

[0080] $$\tilde{C}^{\langle t \rangle} = \tanh\left(W_C\left[H^{\langle t-1 \rangle}, X^{\langle t \rangle}\right] + b_C\right),$$

[0081] 또한, 현재 시점 t의 셀 상태 $C^{(t)}$는 수학식 7에 따라 계산될 수 있다.

*수학식 7*

[0082] $$C^{\langle t \rangle} = \Gamma_f^{\langle t \rangle} \cdot C^{\langle t-1 \rangle} + \Gamma_i^{\langle t \rangle} \cdot \tilde{C}^{\langle t \rangle},$$

[0083] 그리고, 계산된 $C^{(t)}$는 활성화함수로 tanh를 적용한 값에 출력 게이트 $\Gamma_o^{\langle t \rangle}$를 적용하여 현재 시점 t의 은닉 상태 $H^{(t)}$를 도출할 수 있다. 즉, LSTM(420)은 수학식 8을 사용하여 현재 시점 t의 은닉 상태 $H^{(t)}$를 계산할 수 있다.

*수학식 8*

[0084] $$H^{\langle t \rangle} = \Gamma_o^{\langle t \rangle} \cdot \tanh\left(C^{\langle t \rangle}\right).$$

[0085] 그리고, LSTM(420)은 수학식 2를 사용하여 출력 $Y^{(t)}$를 생성할 수 있다.

[0086] 또한, 신경망에 입력되는 입출력 데이터의 특성에 따라 수학식 1 내지 수학식 8은 다른 활성화 함수로 대체될 수 있다.

[0087] 도 5는 본 발명의 일실시예에 따른 저류층 인자 추정 과정의 개념도이다.

[0088] 저류층 인자 추정 장치(120)는 입력 데이터인 물리 검층의 원시 해상도보다 M배 높은 해상도를 갖는 저류층 인자(합성 물리 검층 데이터 또는 저류층 인자)를 출력할 수 있다.

[0089] 예를 들어, 도 5에 도시된 바와 같이 1.0 m 간격으로 측정된 총 4가지 물리 검층 데이터(NPHI, RHOB, GR, RT)(510)를 입력받는 경우, 저류층 인자 추정 장치(120)는 해상도가 5배 높은 고해상도 DT(520)를 생성할 수 있

다. 이때, DT(520)의 간격은 0.2 m일 수 있다.

[0090] 도 5의 일례는 출력 인자가 특정 물리 검층 데이터에 해당하므로 합성 물리 검층 데이터의 생성에 해당한다. 또한, 저류층 인자 추정용 신경망(112)의 출력 인자를 물리 검층 데이터 대신 공극률과 같은 저류층 인자로 대체하는 경우, 저류층 인자 추정 장치(120)는 저류층 인자를 추정할 수 있다.

[0091] 도 6은 본 발명의 일실시예에 따라 고해상도의 저류층 인자를 추정하는 과정의 일례이다.

[0092] 저류층 인자 추정용 신경망(112)은 입력 데이터(610)의 원시 해상도에 비하여 M배 높은 해상도의 출력 데이터(620)를 출력하므로 입력 데이터(610)의 배열 크기는 (N, p)이나, 출력 데이터(620)의 배열 크기는 (M(N - 1) + 1, q)일 수 있다.

[0093] 이때, 입력 데이터(610), 및 출력 데이터(620)는 신경망 알고리즘 특성에 따라 배열 크기가 조정될 수 있다. 또한, 입력 데이터(610), 및 출력 데이터(620)는 배열 크기를 조정하기 전에 별도의 고해상도 변환 과정(high-resolution conversion process)이 적용될 수 있다.

[0094] 도 7은 본 발명의 일실시예에 따른 저류층 인자 추정 장치(120)의 입출력 데이터의 일례들이다.

[0095] 도 7에서 검은색 점은 측정 데이터이고, 흰색 점은 측정되지 않은 데이터를, 빗금 친 점은 추정한 데이터일 수 있다.

[0096] 종래의 저류층 인자 추정 장치는 i번째의 입력 데이터 쌍(pair)으로부터 i번째의 출력 데이터 쌍을 추정할 수 있다. 종래의 저류층 인자 추정 장치에서 하나의 입출력 데이터 쌍에 대한 배열의 크기는 각각 (1, p), (1, q)이고, 종래의 저류층 인자 추정 장치에서 구성할 수 있는 입출력 데이터 쌍은 총 N개이므로 종래의 저류층 인자 추정 장치에서 전체 입출력 데이터 쌍(710)에 대한 배열의 크기는 각각 (N, p), (N , q)일 수 있다.

[0097] 반면, 본 발명의 일실시예에 따른 저류층 인자 추정 장치(120)는 i 번째 입력 데이터와 i+1 번째 입력 데이터의 쌍으로부터 M(i-1)+1 번째 출력 데이터 내지 M i+1 번째 출력 데이터의 쌍을 추정하도록 설계될 수 있다. 이때, i 번째 입력 데이터 쌍은 M (i - 1) + 1번째 출력 데이터 쌍에 대응하고, i + 1번째 입력 데이터 쌍은 Mi + 1 번째 출력 데이터 쌍에 대응할 수 있다. 따라서 하나의 입출력 데이터 쌍에 대한 배열의 크기는 각각 (1, 2p), (1, (M + 1)q )이고, 구성할 수 있는 입출력 데이터 쌍은 총 N - 1개이므로 전체 입출력 데이터 쌍(720)에 대한 배열의 크기는 각각 (N - 1, 2p), (N - 1, (M + 1)q )일 수 있다.

[0098] 또한, Mi + 1번째 출력 데이터 쌍은 i번째 입력 데이터 쌍과 i+ 1번째의 입력 데이터 쌍으로부터 예측한 데이터 중 마지막 출력 쌍에 해당하며, 동시에 i + 1 번째 입력 데이터 쌍과 i + 2번째 입력 데이터 쌍으로부터 예측한 데이터 중 처음 출력 쌍에 해당할 수 있다. 즉, 저류층 인자 추정 장치(120)는 Mi + 1번째 출력 데이터 쌍을 겹쳐서 추정하며 알고리즘의 손실함수 계산 시 모두 포함할 수 있다. 다만, 저류층 인자 추정 장치(120)는 최종 예측 결과를 결정하는 과정에서 겹치는 Mi + 1번째 출력 데이터 중 하나만을 사용하고 나머지 하나는 결과에서 배제할 수 있다.

[0099] 즉, 저류층 인자 추정 장치(120)는 i + 1 번째 입력 데이터 쌍과 i + 2번째 입력 데이터 쌍으로부터 예측한 데이터 중 처음 Mi + 1번째 출력만을 사용하고, i 번째 입력 데이터 쌍과 i+ 1번째의 입력 데이터 쌍으로부터 예측한 데이터 중 마지막 Mi + 1번째 출력은 배제하여 최종 예측 결과를 결정할 수 있다. 다만, 마지막 입력 데이터 쌍 i이 N-1인 경우, 저류층 인자 추정 장치(120)는 마지막 Mi + 1번째 출력을 포함하여 최종 예측 결과를 결정할 수 있다.

[0100] 정리하면, 저류층 인자 추정 장치(120)의 저류층 인자 추정용 신경망(112)에 사용되는 입출력 데이터 쌍(720)에 대한 배열의 크기는 각각 (N - 1, 2p), (N - 1, (M + 1)q )일 수 있다. 그러나, 저류층 인자 추정 장치(120)의 최종 예측 결과에 나타나는 입력 데이터의 배열 크기는 (N, p)이고, 출력 데이터의 배열 크기는 (M(N - 1) + 1, q)이며, 중복지점은 하나만을 사용할 수 있다.

[0101] 도 8은 본 발명의 일실시예에 따라 딥러닝 알고리즘에 기초하여 학습용 데이터의 형태를 변환하는 일례이다.

[0102] 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 선택된 딥러닝 알고리즘에 따라 학습용 데이터(111)의 형태를 변환할 수 있다.

[0103] 예를 들어, 선택된 딥러닝 알고리즘이 DNN인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)를 $N_p$와 같은 1차원 벡터의 형태로 변환할 수 있다.

[0104] 또한, 선택된 딥러닝 알고리즘이 CNN인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)를 $(l_w N, p, 1)$ 과 같이 이미지로 처리하기 위한 3차원 배열의 형태로 변환할 수 있다. 이때, $l_w$는 윈도우 길이(window length)이며 이미지 행의 개수를 나타낼 수 있다. 또한, 3차원 배열의 3번째 요소는 입력 데이터가 이미지가 아닌 경우 1로 설정하고, 입력 데이터가 컬러 이미지인 경우 3으로 설정할 수 있다.

[0105] 그리고, 선택된 딥러닝 알고리즘이 LSTM인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)를 $(l_w N, p)$ 와 같이 순차 데이터로 처리하기 위한 2차원 배열의 형태로 변환할 수 있다. 이때, $l_w$는 윈도우 길이(window length)이며 시퀀스 길이를 나타낼 수 있다. 또한, 입력 데이터가 1차원인 경우, $l_w$는 1일 수 있다.

[0106] 그리고, 입력 데이터와 달리 출력 데이터는 신경망 알고리즘 특성에 따라 배열 크기의 제약을 받지 않으며, 출력 데이터 배열의 크기는 DNN, CNN, LSTM 모두 $N_q$일 수 있다.

[0107] 학습용 데이터(111)의 원본 입력 데이터(Original resolution)의 배열 크기는 (N - 1, 2p)일 수 있다.

[0108] 그리고, 선택된 딥러닝 알고리즘이 DNN인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 도 8에 도시된 바와 같이 학습용 데이터(111)를 1차원 벡터인 2(N-1)p (810)로 변환할 수 있다.

[0109] 또한, 선택된 딥러닝 알고리즘이 CNN인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 도 8에 도시된 바와 같이 학습용 데이터(111)를 3차원 배열 (2(N-1), p, 1)(820)로 변환할 수 있다.

[0110] 그리고, 선택된 딥러닝 알고리즘이 LSTM인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 도 8에 도시된 바와 같이 학습용 데이터(111)를 2차원 배열 (2(N-1), p)(830)로 변환할 수 있다.

[0111] 도 8에 도시된 실시예는 $l_w$를 2로 설정한 경우의 변환 결과일 수 있다. 또한, 출력 데이터 배열의 크기는 후처리(postprocessing)를 고려하여 DNN, CNN, LSTM 모두 2차원 배열(N- 1, (M + 1)q)로 변환할 수 있다.

[0112] 딥러닝 알고리즘별 입출력 데이터의 배열 크기를 요약하면 표 1에 도시된 바와 같을 수 있다.

표 1

[0113]

| | | Input | Output |
|---|---|---|---|
| 종래 모델 | One dataset | (1, p) | (1, q) |
| | Total dataset | (N, p) | (N, q) |
| | DNN | Np | Nq |
| | CNN | ($l_w$N, p, 1)=(N, p, 1) | Nq |
| | LSTM | ($l_w$N, p)=(N, p) | Nq |
| 본 발명의 모델 | One dataset | (1, 2p) | (1,(M+1)q) |
| | Total dataset | (N-1, 2p) | (N-1, (M+1)q) |
| | DNN | 2(N-1)p | (N-1, (M+1)q) |
| | CNN | ($l_w$(N-1), p, 1)=(2(N-1), p, 1) | (N-1, (M+1)q) |
| | LSTM | ($l_w$(N-1), p)=(2(N-1), p) | (N-1, (M+1)q) |

[0114] 도 9는 코어 데이터가 없거나, 출력 저류층 인자가 고해상도 합성 물리 검층 데이터이고, 정답 데이터는 원시 물리 검층 데이터이며, 원시 물리 검층 데이터는 입력 데이터와 동일한 해상도를 가지는 경우, 신경망을 학습하는 과정의 일례이다.

[0115] 입력 데이터의 원시 해상도($S_{in}$=0.5 m) 보다 5배 조밀한 해상도로 출력하고자 하는 경우($S_{out}$ = 0.1 m), 학습용 데이터에는 $S_{out}$과 같은 고해상도를 가지는 정답 데이터가 없으므로, 저류층 인자 추정용 신경망 학습 장치(110)가 학습을 수행할 수 없다.

[0116] 따라서, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 출력하고자 하는 고해상도 비율에 따라 원시

해상도인 입력 데이터(910)의 해상도를 1/M으로 감소시키는 전처리를 수행할 수 있다. 예를 들어, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 입력 데이터(910)의 원시해상도($S_{in}$=0.5m)에서 일부 데이터를 제거하여 입력 데이터의 해상도를 1/5로 감소시킬 수 있다($S_{in}'$ =2.5m).

[0117] 다음으로, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 전처리된 입력 데이터(920)를 이용하여 출력 데이터(930)이 출력되도록 신경망을 학습할 수 있다. 예를 들어, 딥러닝 모델에 따른 신경망은 전처리된 입력 데이터($S_{in}'$ =2.5 m)(920)를 이용하여 5배 해상도의 출력 데이터($S_{out}'$ =0.5m)(930)를 추정하도록 학습될 수 있다.

[0118] 그리고, 저류층 인자 추정 장치(120)의 프로세서는 저류층 인자 추정용 신경망 학습 장치(110)에서 학습을 완료된 신경망에 원시해상도의 물리 검층 데이터(950)를 입력하여 목표한 고해상도의 합성 물리 검층 데이터(940)를 생성할 수 있다. 예를 들어, 저류층 인자 추정 장치(120)는 원시 해상도($S_{in}$=0.5 m)를 가지는 물리 검층 데이터를 학습된 신경망에 입력하여 출력 데이터($S_{out}'$ =0.1m)(930)를 예측할 수 있다.

[0119] 즉, 저류층 인자 추정 시스템은 원시해상도 보다 낮은 해상도로 가공한 입력 데이터로 원시해상도의 출력 데이터를 재현해내도록 신경망을 학습하고, 학습한 신경망에 물리 검층 데이터를 입력하여 물리 검층 데이터보다 해상도가 높은 고해상도 출력 데이터를 추정할 수 있다.

[0120] 도 10은 코어 데이터가 있는 경우,본 발명의 일실시예에 따라 신경망을 학습하는 과정의 일례이다.

[0121] 출력 저류층 인자가 저류층 인자에 해당하는 경우, 정답 데이터는 코어 데이터일 수 있다. 그러나, 코어 데이터는 데이터 채취 과정의 특성상 균등하지 않은 간격으로 분포할 수 있다. 즉, 학습용 데이터(111)에는 코어 데이터가 존재하는 심도와 코어 데이터가 존재하지 않는 심도가 있을 수 있다.

[0122] 따라서, 저류층 인자를 고해상도로 추정하는 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 도 9에 도시된 바와 같이 원시 해상도인 입력 데이터(910)의 해상도를 1/M으로 감소시키는 전처리를 수행할 수 있다. 예를 들어, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 입력 데이터(910)의 원시해상도($S_{in}$=0.5m)에서 일부 데이터를 제거하여 입력 데이터의 해상도를 1/5로 감소시킬 수 있다($S_{in}'$ =2.5m).

[0123] 다음으로, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 전처리된 입력 데이터(920)를 이용하여 출력 데이터(930)이 출력되도록 신경망을 1차 학습(primary training)할 수 있다. 예를 들어, 딥러닝 모델에 따른 신경망은 전처리된 입력 데이터($S_{in}'$ =2.5 m)(920)를 이용하여 5배 해상도의 출력 데이터($S_{out}'$ =0.5m)(930)를 추정하도록 학습될 수 있다. 이때, 정답 데이터는 물리 검층 데이터로부터 경험식을 활용하여 저류층 인자를 계산한 값일 수 있다.

[0124] 그 다음으로, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터에서 코어 데이터에 대응하는 심도의 정답 데이터를 코어 데이터로 교체할 수 있다. 그리고, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 코어 데이터가 존재하지 않는 심도의 정답 데이터는 초기값을 유지할 수 있다.

[0125] 다음으로, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터(1010)를 이용하여 출력 데이터(1020)가 출력되도록 신경망에 2차 학습(secondary training)을 수행할 수 있다.

[0126] 이때, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 코어 데이터가 존재하는 심도의 데이터만으로 알고리즘의 손실함수를 계산하여 학습을 수행할 수 있다. 예를 들어, 1차 학습을 완료한 딥러닝 모델을 통해 입력 데이터의 원시 해상도($S_{in}$=0.5m) 보다 5배 조밀한 해상도로 출력할 때($S_{out}$=0.1 m), 코어 데이터는 $S_{out}$만큼의 일정한 해상도로 모두 존재하지는 않으나 일부 존재한다. 따라서, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 정답 코어 데이터와 심도가 일치하는 출력 데이터만을 추려 2차 학습을 수행할 수 있다.

[0127] 그리고, 저류층 인자 추정 장치(120)의 프로세서는 저류층 인자 추정용 신경망 학습 장치(110)에서 학습을 완료된 신경망에 원시해상도의 물리 검층 데이터(1030)를 입력하여 목표한 고해상도의 합성 물리 검층 데이터를 생성할 수 있다.

[0128] 도 11은 본 발명의 일실시예에 따른 저류층 인자 추정용 신경망 학습 방법을 도시한 플로우차트이다.

[0129] 단계(1110)에서 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)의 특성에 따라 딥

러닝 알고리즘을 선택할 수 있다. 이때, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)의 특성에 따라 DNN(deep neural network), CNN(convolutional neural network), 및 LSTM(long short-term memory) 등 다양한 딥러닝 알고리즘 중 하나를 선택할 수 있다.

[0130] 단계(1120)에서 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 단계(1110)에서 선택된 딥러닝 알고리즘에 따라 학습용 데이터(111)의 형태를 변환할 수 있다. 예를 들어, 선택된 딥러닝 알고리즘이 DNN인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)를 1차원 벡터의 형태로 변환할 수 있다. 또한, 선택된 딥러닝 알고리즘이 CNN인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)를 3차원 배열의 형태로 변환할 수 있다. 그리고, 선택된 딥러닝 알고리즘이 LSTM인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)를 2차원 배열의 형태로 변환할 수 있다. 또한, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)의 입력 데이터의 원시 해상도를 1/M으로 변환할 수 있다.

[0131] 단계(1130)에서 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 단계(1120)에서 형태가 변환된 학습용 데이터(111)를 이용하여 신경망을 1차 학습할 수 있다.

[0132] 단계(1140)에서 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 단계(1130)에서 학습한 신경망의 성능이 기준 성능을 초과하는지 여부를 확인할 수 있다. 단계(1130)에서 학습한 신경망의 성능이 기준 성능을 초과하는 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 단계(1150)를 수행할 수 있다. 또한, 단계(1130)에서 학습한 신경망의 성능이 기준 성능 이하인 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 단계(1130)에서 학습한 신경망의 성능이 기준 성능을 초과할 때까지 단계(1110) 내지 단계(1140)를 반복 수행하여 신경망을 갱신할 수 있다.

[0133] 단계(1150)에서 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)에 코어 데이터가 포함되었는지 여부를 확인할 수 있다. 학습용 데이터(111)에 코어 데이터가 포함된 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 단계(1170)를 수행할 수 있다. 또한, 학습용 데이터(111)에 코어 데이터가 포함되지 않은 경우, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 단계(1160)를 수행할 수 있다.

[0134] 단계(1160)에서 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 단계(1130)에서 1차 학습된 신경망, 또는 단계(1172)에서 2차 학습된 신경망을 평가할 수 있다. 그리고, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 평가 결과에 따라 저류층 인자 추정용 신경망(112)을 결정할 수 있다. 이때, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 해상도를 변환하지 않은 입력 데이터를 신경망에 입력하여 생성된 출력 데이터를 이용하여 신경망을 평가할 수 있다. 또한, 저류층 인자 추정용 신경망 학습 장치(110)의 입출력기는 결정된 저류층 인자 추정용 신경망(112)을 저류층 인자 추정 장치(120)로 전송할 수 있다.

[0135] 단계(1170)에서 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 학습용 데이터(111)에서 코어 데이터에 대응하는 심도의 정답 데이터를 코어 데이터로 교체할 수 있다.

[0136] 단계(1171)에서 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 단계(1170)에서 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터(111)의 형태를 선택된 딥러닝 알고리즘에 따라 변환할 수 있다.

[0137] 단계(1172)에서 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 단계(1171)에서 형태가 변환된 학습용 데이터(111)를 학습된 신경망에 적용하여 2차 학습을 수행할 수 있다. 이때, 저류층 인자 추정용 신경망 학습 장치(110)의 프로세서는 신경망의 출력 데이터들 중에서 정답 코어 데이터와 심도가 일치하는 출력 데이터만을 추려 2차 학습을 수행할 수 있다.

[0138] 도 12는 본 발명의 일실시예에 따른 저류층 인자 추정 방법을 도시한 플로우차트이다.

[0139] 단계(1210)에서 저류층 인자 추정 장치(120)의 입출력기는 저류층 인자 추정용 신경망 학습 장치(110)로부터 저류층 인자 추정용 신경망(112)을 수신할 수 있다.

[0140] 단계(1220)에서 저류층 인자 추정 장치(120)의 입출력기는 물리 검층 데이터(121)를 입력받을 수 있다. 이때, 물리 검층 데이터(121)의 해상도는 원시 해상도일 수 있다.

[0141] 단계(1230)에서 저류층 인자 추정 장치(120)의 프로세서는 단계(1210)에서 수신한 저류층 인자 추정용 신경망(112)에 물리 검층 데이터(121)를 입력하여 물리 검층 데이터(121)의 원시 해상도보다 해상도가 높은 저류층 인

자를 추정할 수 있다.

[0142] 본 발명은 학습용 데이터의 특징에 따라 선택된 딥러닝 알고리즘으로 학습된 저류층 인자 추정용 신경망을 이용함으로써, 원시 해상도의 물리 검층 데이터로부터 원시 해상도보다 해상도가 높은 고해상도로 저류층 인자를 추정할 수 있다.

[0143] 본 발명은 신경망에 1차 학습을 수행하고, 정답 데이터 중 적어도 하나를 코어 데이터로 교체한 학습용 데이터를 1차 학습된 신경망에 적용함으로써, 저류층 인자 데이터를 이용하여 저류층 인자 추정용 신경망을 결정할 수 있다.

[0144] 한편, 본 발명에 따른 저류층 인자 추정 장치 또는 저류층 인자 추정 방법은 컴퓨터에서 실행될 수 있는 프로그램으로 작성되어 마그네틱 저장매체, 광학적 판독매체, 디지털 저장매체 등 다양한 기록 매체로도 구현될 수 있다.

[0145] 본 명세서에 설명된 각종 기술들의 구현들은 디지털 전자 회로조직으로, 또는 컴퓨터 하드웨어, 펌웨어, 소프트웨어로, 또는 그들의 조합들로 구현될 수 있다. 구현들은 데이터 처리 장치, 예를 들어 프로그램가능 프로세서, 컴퓨터, 또는 다수의 컴퓨터들의 동작에 의한 처리를 위해, 또는 이 동작을 제어하기 위해, 컴퓨터 프로그램 제품, 예를 들어 기계 판독가능 저장 장치(컴퓨터 판독가능 매체)에서 유형적으로 구체화된 컴퓨터 프로그램으로서 구현될 수 있다. 상술한 컴퓨터 프로그램(들)과 같은 컴퓨터 프로그램은 컴파일된 또는 인터프리트된 언어들을 포함하는 임의의 형태의 프로그래밍 언어로 기록될 수 있고, 독립형 프로그램으로서 또는 모듈, 구성요소, 서브루틴, 또는 컴퓨팅 환경에서의 사용에 적절한 다른 유닛으로서 포함하는 임의의 형태로 전개될 수 있다. 컴퓨터 프로그램은 하나의 사이트에서 하나의 컴퓨터 또는 다수의 컴퓨터들 상에서 처리되도록 또는 다수의 사이트들에 걸쳐 분배되고 통신 네트워크에 의해 상호 연결되도록 전개될 수 있다.

[0146] 컴퓨터 프로그램의 처리에 적절한 프로세서들은 예로서, 범용 및 특수 목적 마이크로프로세서들 둘 다, 및 임의의 종류의 디지털 컴퓨터의 임의의 하나 이상의 프로세서들을 포함한다. 일반적으로, 프로세서는 판독 전용 메모리 또는 랜덤 액세스 메모리 또는 둘 다로부터 명령어들 및 데이터를 수신할 것이다. 컴퓨터의 요소들은 명령어들을 실행하는 적어도 하나의 프로세서 및 명령어들 및 데이터를 저장하는 하나 이상의 메모리 장치들을 포함할 수 있다. 일반적으로, 컴퓨터는 데이터를 저장하는 하나 이상의 대량 저장 장치들, 예를 들어 자기, 자기-광 디스크들, 또는 광 디스크들을 포함할 수 있거나, 이것들로부터 데이터를 수신하거나 이것들에 데이터를 송신하거나 또는 양쪽으로 되도록 결합될 수도 있다. 컴퓨터 프로그램 명령어들 및 데이터를 구체화하는데 적절한 정보 캐리어들은 예로서 반도체 메모리 장치들, 예를 들어, 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(Magnetic Media), CD-ROM(Compact Disk Read Only Memory), DVD(Digital Video Disk)와 같은 광 기록 매체(Optical Media), 플롭티컬 디스크(Floptical Disk)와 같은 자기-광 매체(Magneto-Optical Media), 롬(ROM, Read Only Memory), 램(RAM, Random Access Memory), 플래시 메모리, EPROM(Erasable Programmable ROM), EEPROM(Electrically Erasable Programmable ROM) 등을 포함한다. 프로세서 및 메모리는 특수 목적 논리 회로조직에 의해 보충되거나, 이에 포함될 수 있다.

[0147] 또한, 컴퓨터 판독가능 매체는 컴퓨터에 의해 액세스될 수 있는 임의의 가용매체일 수 있고, 컴퓨터 저장매체를 모두 포함할 수 있다.

[0148] 본 명세서는 다수의 특정한 구현물의 세부사항들을 포함하지만, 이들은 어떠한 발명이나 청구 가능한 것의 범위에 대해서도 제한적인 것으로서 이해되어서는 안되며, 오히려 특정한 발명의 특정한 실시형태에 특유할 수 있는 특징들에 대한 설명으로서 이해되어야 한다. 개별적인 실시형태의 문맥에서 본 명세서에 기술된 특정한 특징들은 단일 실시형태에서 조합하여 구현될 수도 있다. 반대로, 단일 실시형태의 문맥에서 기술한 다양한 특징들 역시 개별적으로 혹은 어떠한 적절한 하위 조합으로도 복수의 실시형태에서 구현 가능하다. 나아가, 특징들이 특정한 조합으로 동작하고 초기에 그와 같이 청구된 바와 같이 묘사될 수 있지만, 청구된 조합으로부터의 하나 이상의 특징들은 일부 경우에 그 조합으로부터 배제될 수 있으며, 그 청구된 조합은 하위 조합이나 하위 조합의 변형물로 변경될 수 있다.

[0149] 마찬가지로, 특정한 순서로 도면에서 동작들을 묘사하고 있지만, 이는 바람직한 결과를 얻기 위하여 도시된 그 특정한 순서나 순차적인 순서대로 그러한 동작들을 수행하여야 한다거나 모든 도시된 동작들이 수행되어야 하는 것으로 이해되어서는 안 된다. 특정한 경우, 멀티태스킹과 병렬 프로세싱이 유리할 수 있다. 또한, 상술한 실시형태의 다양한 장치 컴포넌트의 분리는 그러한 분리를 모든 실시형태에서 요구하는 것으로 이해되어서는 안되며, 설명한 프로그램 컴포넌트와 장치들은 일반적으로 단일의 소프트웨어 제품으로 함께 통합되거나 다중

소프트웨어 제품에 패키징 될 수 있다는 점을 이해하여야 한다.

[0150] 한편, 본 명세서와 도면에 개시된 본 발명의 실시 예들은 이해를 돕기 위해 특정 예를 제시한 것에 지나지 않으며, 본 발명의 범위를 한정하고자 하는 것은 아니다. 여기에 개시된 실시 예들 이외에도 본 발명의 기술적 사상에 바탕을 둔 다른 변형 예들이 실시 가능하다는 것은, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에게 자명한 것이다.

## 부호의 설명

[0151] 110: 저류층 인자 추정용 신경망 학습 장치

111: 학습용 데이터

112: 저류층 인자 추정용 신경망

120: 저류층 인자 추정 장치

## 도면

### 도면1

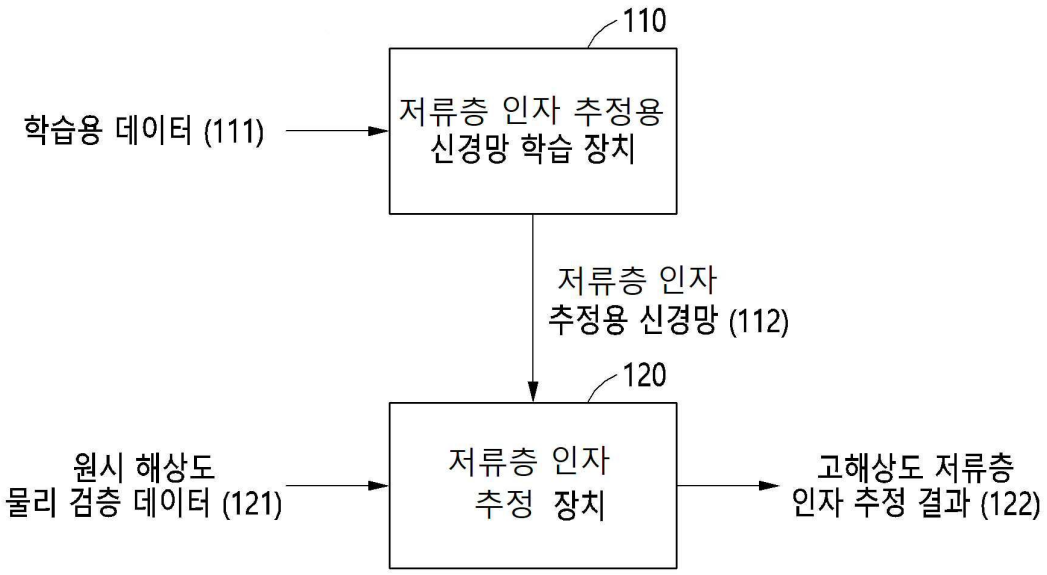

도면2

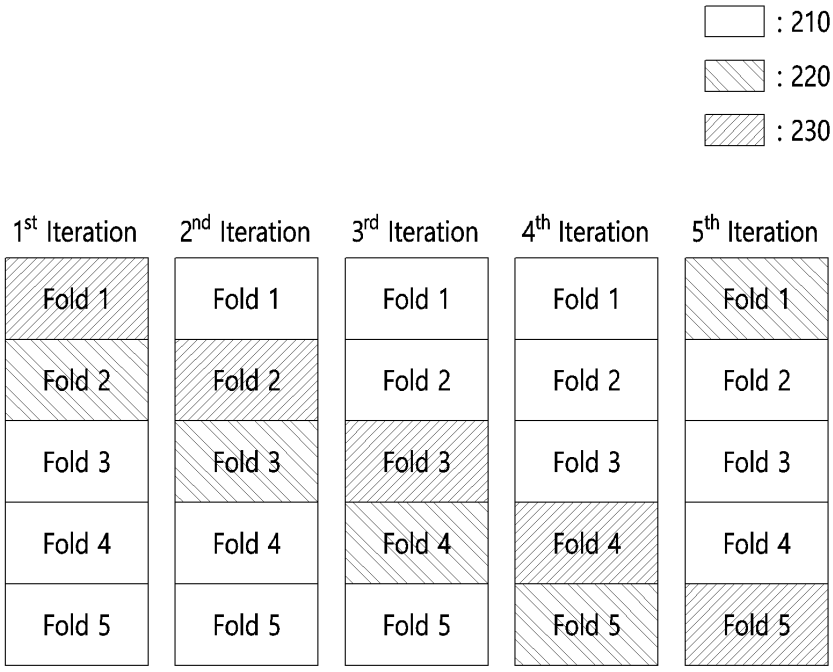
: 210
: 220
: 230
1st Iteration
2nd Iteration
3rd Iteration
4th Iteration
5th Iteration
Fold 1
Fold 2
Fold 3
Fold 4
Fold 5

도면3

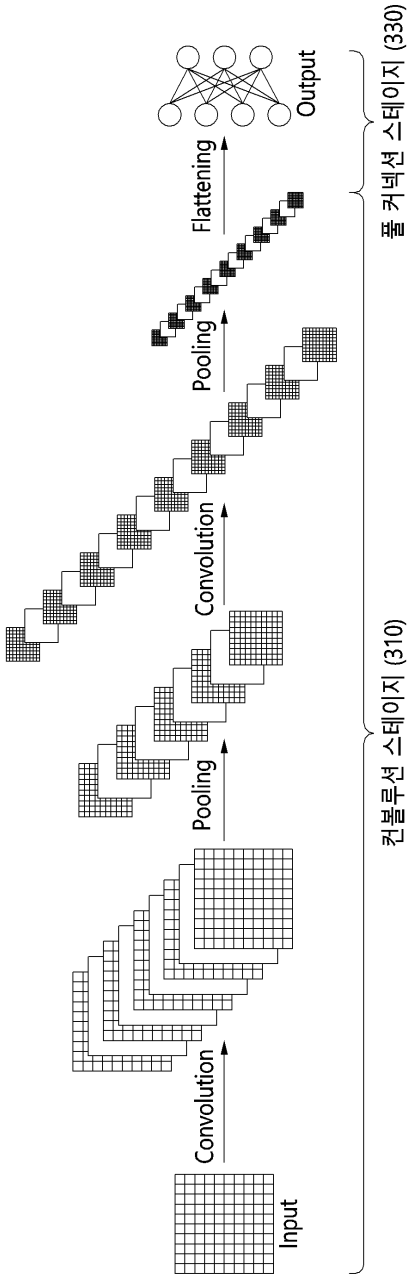
Input
Convolution
Pooling
Convolution
Pooling
Flattening
Output
컨볼루션 스테이지 (310)
풀 커넥션 스테이지 (330)

도면4

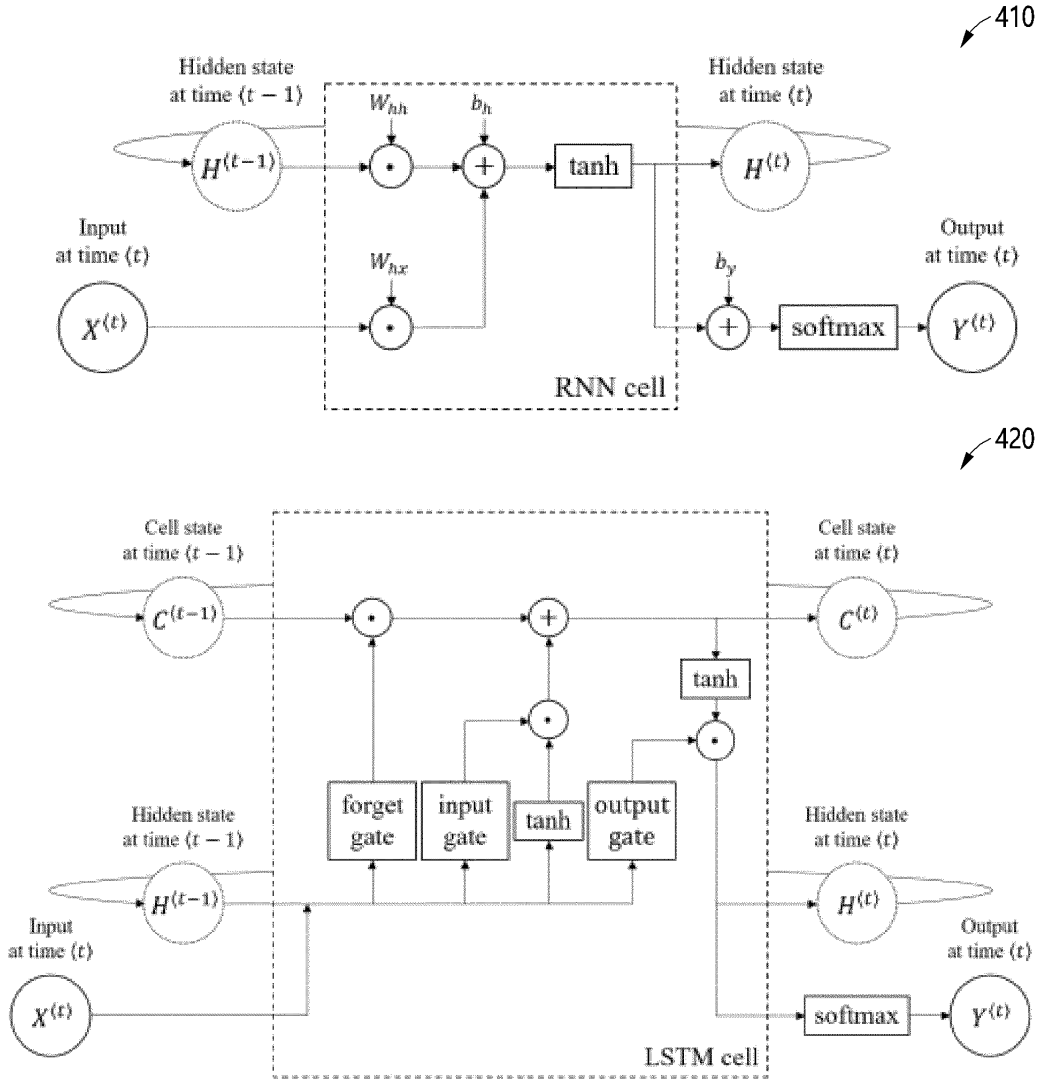
410
Hidden state at time $\langle t-1 \rangle$
$W_{hh}$
$b_h$
Hidden state at time $\langle t \rangle$
$H^{\langle t-1 \rangle}$
tanh
$H^{\langle t \rangle}$
Input at time $\langle t \rangle$
$W_{hx}$
$b_y$
Output at time $\langle t \rangle$
$X^{\langle t \rangle}$
softmax
$Y^{\langle t \rangle}$
RNN cell
420
Cell state at time $\langle t-1 \rangle$
Cell state at time $\langle t \rangle$
$C^{\langle t-1 \rangle}$
$C^{\langle t \rangle}$
tanh
forget gate
input gate
tanh
output gate
Hidden state at time $\langle t-1 \rangle$
Hidden state at time $\langle t \rangle$
$H^{\langle t-1 \rangle}$
$H^{\langle t \rangle}$
Input at time $\langle t \rangle$
Output at time $\langle t \rangle$
$X^{\langle t \rangle}$
softmax
$Y^{\langle t \rangle}$
LSTM cell

도면5

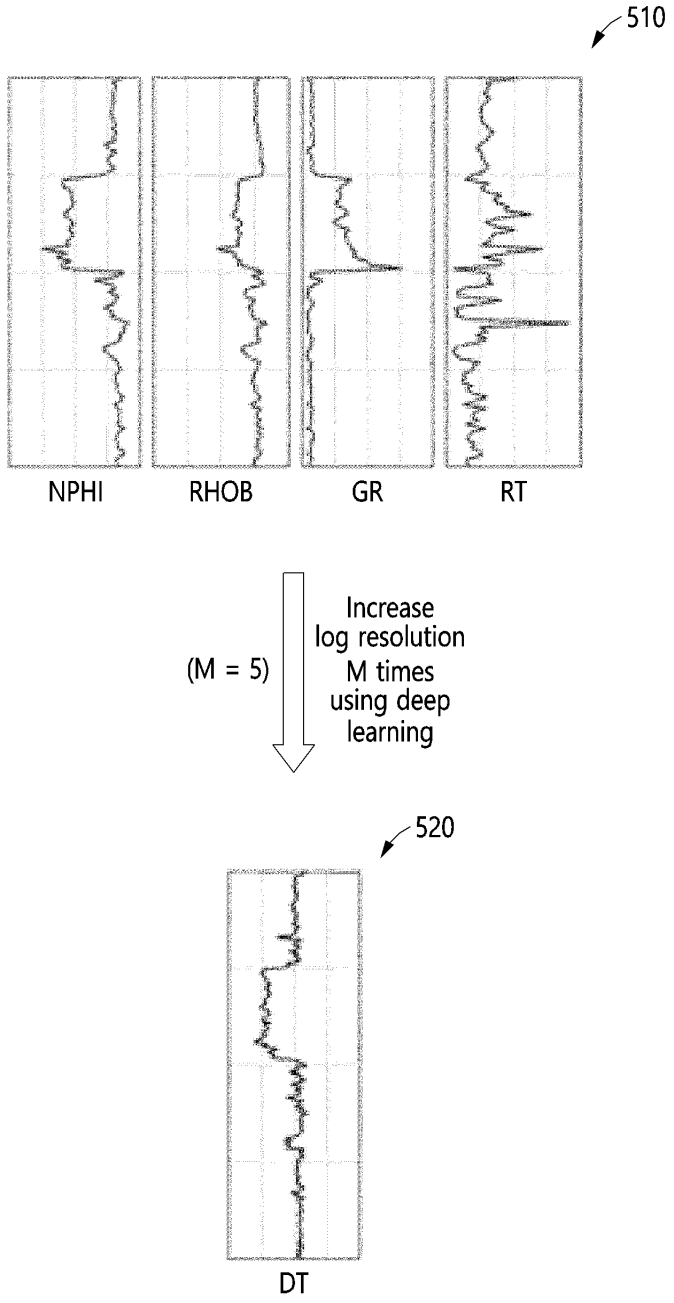
510
NPHI
RHOB
GR
RT
(M = 5)
Increase log resolution M times using deep learning
520
DT

도면6

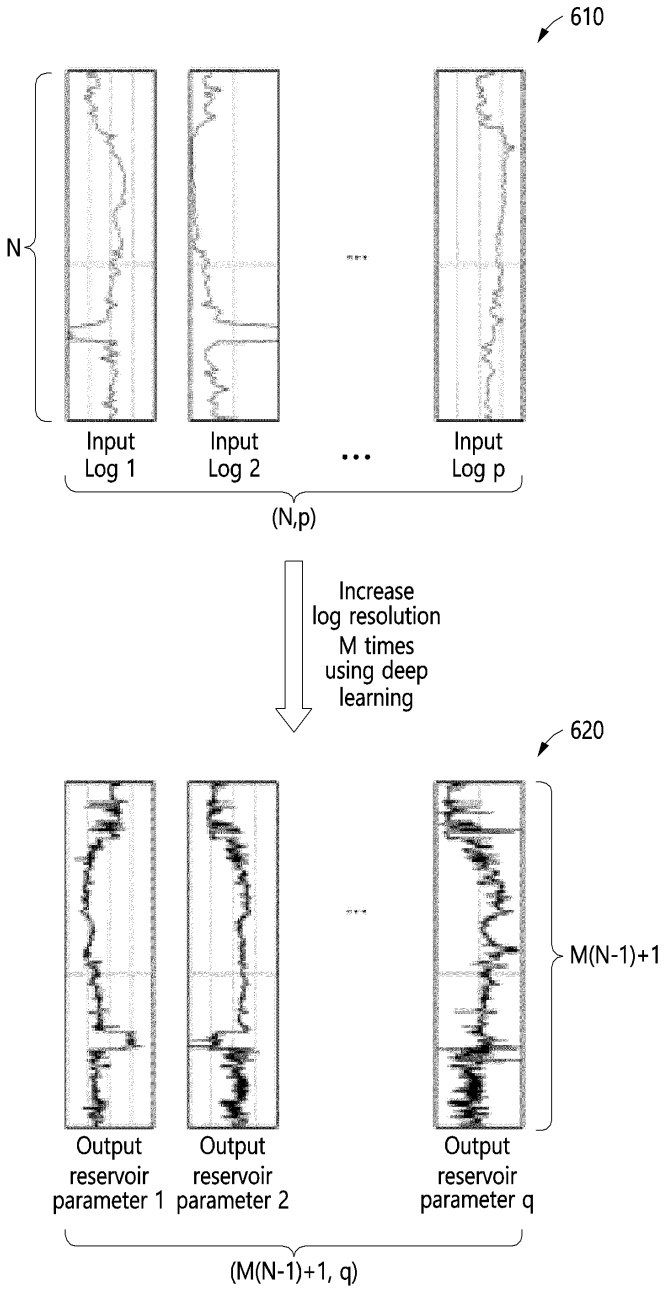
610
N
Input Log 1
Input Log 2
Input Log p
(N,p)
Increase log resolution M times using deep learning
620
M(N-1)+1
Output reservoir parameter 1
Output reservoir parameter 2
Output reservoir parameter q
(M(N-1)+1, q)

도면7

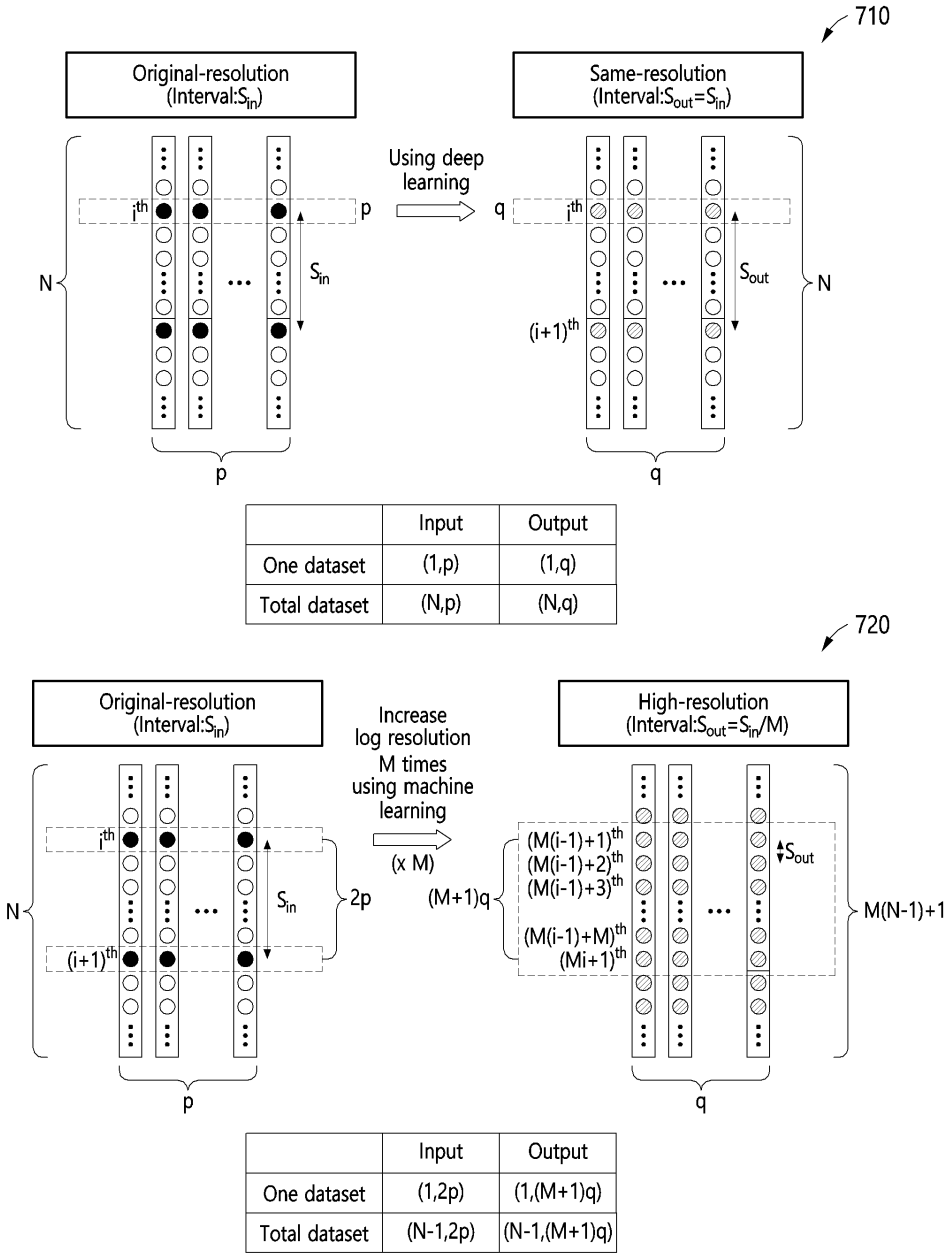


| | Input | Output |
|---|---|---|
| One dataset | (1,p) | (1,q) |
| Total dataset | (N,p) | (N,q) |

| | Input | Output |
|---|---|---|
| One dataset | (1,2p) | (1,(M+1)q) |
| Total dataset | (N-1,2p) | (N-1,(M+1)q) |

도면8

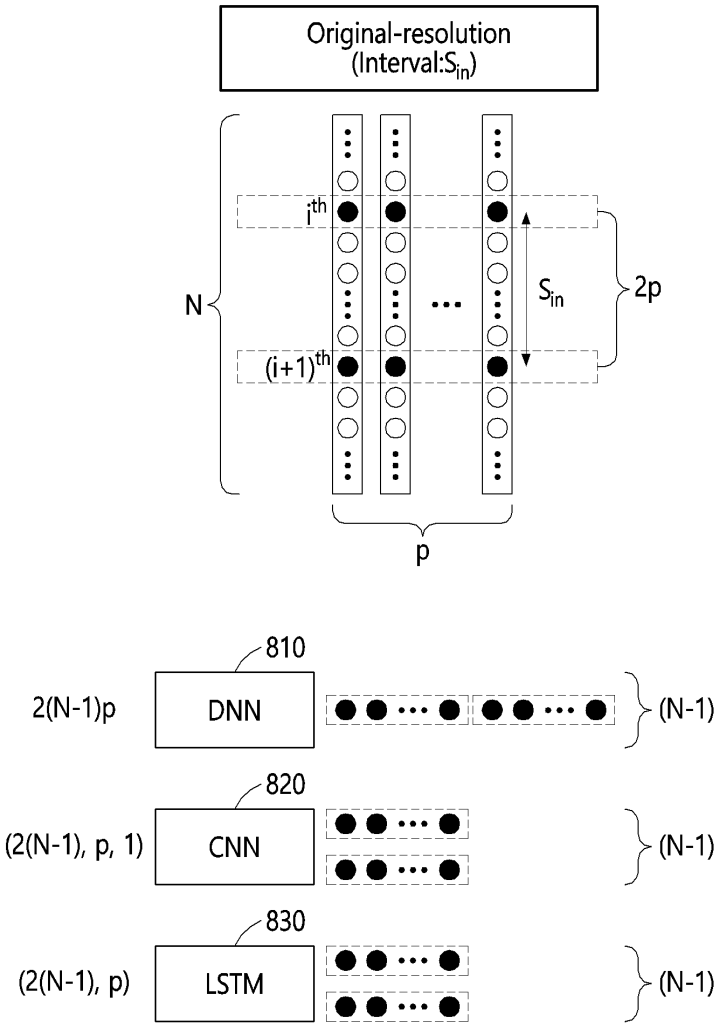
Original-resolution
(Interval:$S_{in}$)
N
$i^{th}$
$(i+1)^{th}$
$S_{in}$
2p
p
810
2(N-1)p
DNN
(N-1)
820
(2(N-1), p, 1)
CNN
(N-1)
830
(2(N-1), p)
LSTM
(N-1)

도면9

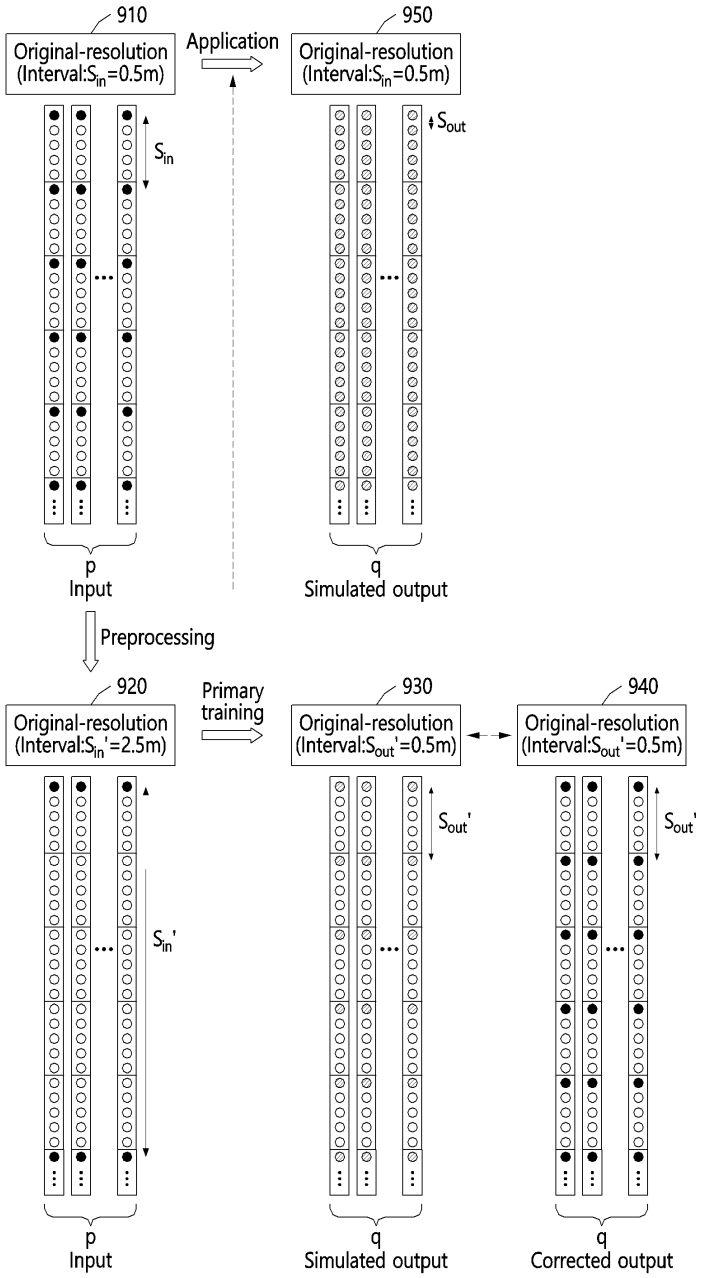
910
Original-resolution
(Interval:$S_{in}$=0.5m)
Application
950
Original-resolution
(Interval:$S_{in}$=0.5m)
$S_{in}$
$S_{out}$
p
Input
q
Simulated output
Preprocessing
920
Original-resolution
(Interval:$S_{in}$'=2.5m)
Primary
training
930
Original-resolution
(Interval:$S_{out}$'=0.5m)
940
Original-resolution
(Interval:$S_{out}$'=0.5m)
$S_{in}$'
$S_{out}$'
$S_{out}$'
p
Input
q
Simulated output
q
Corrected output

도면10

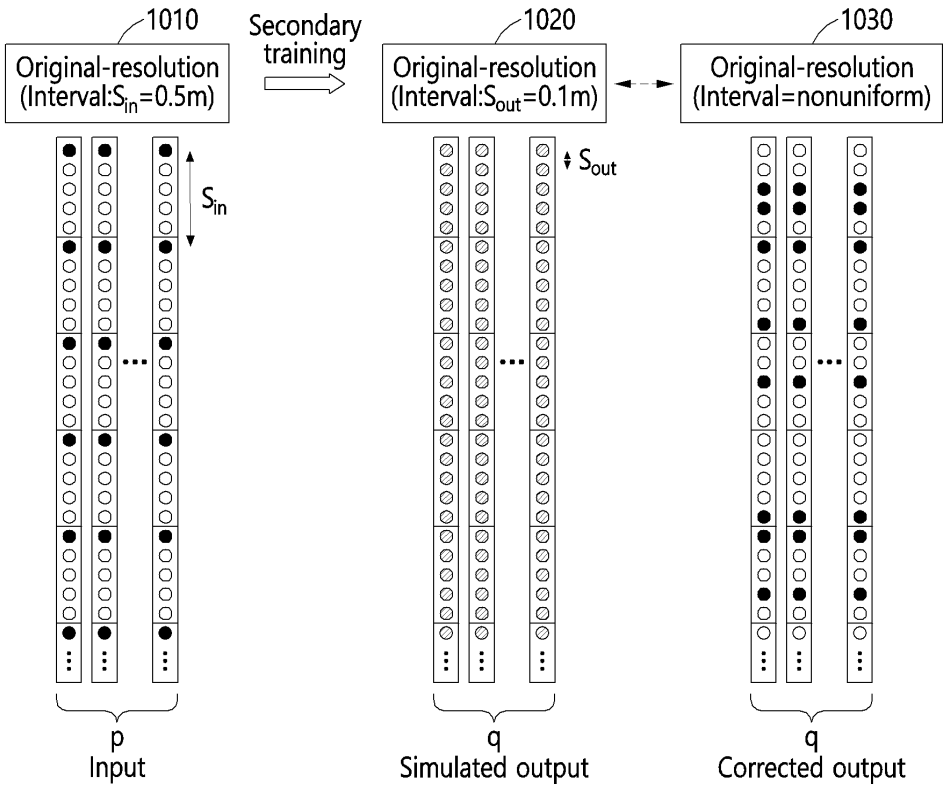
1010
Original-resolution
(Interval:Sin=0.5m)
Secondary
training
1020
Original-resolution
(Interval:Sout=0.1m)
1030
Original-resolution
(Interval=nonuniform)
Sin
Sout
p
Input
q
Simulated output
q
Corrected output

도면11

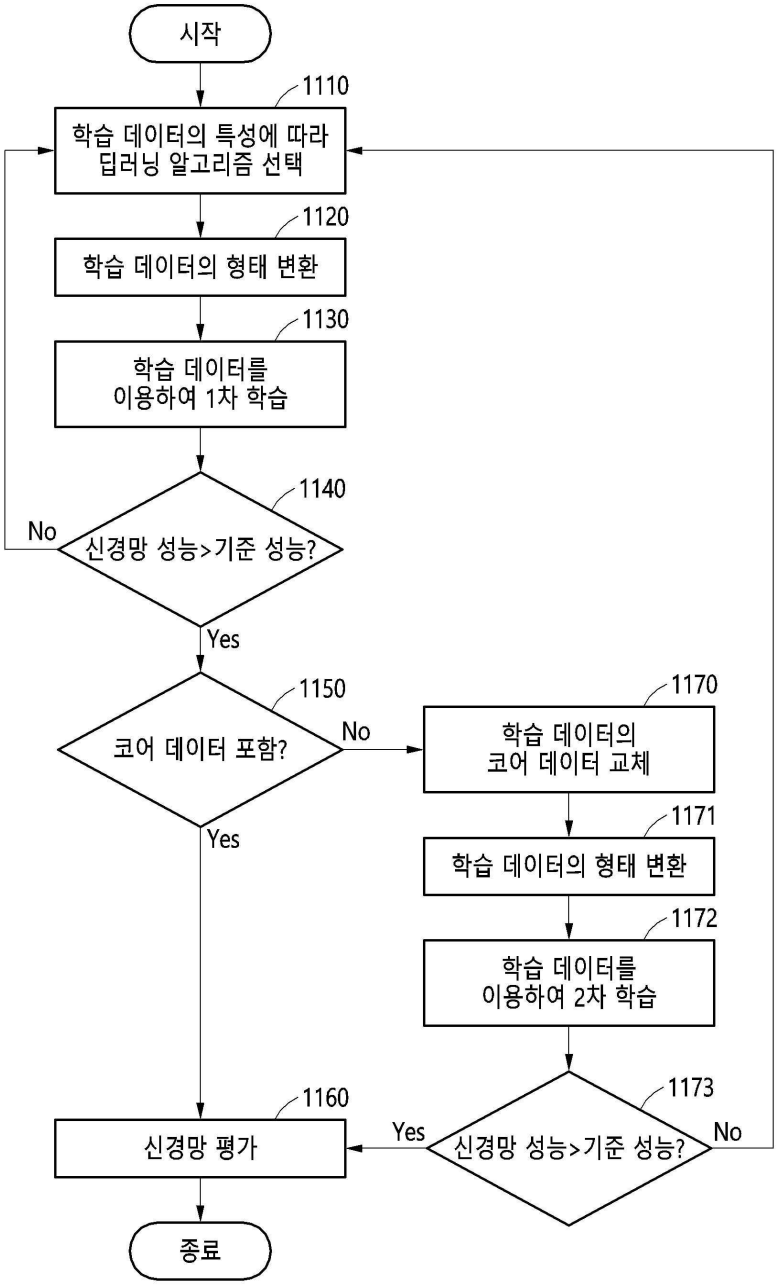
시작
1110
학습 데이터의 특성에 따라 딥러닝 알고리즘 선택
1120
학습 데이터의 형태 변환
1130
학습 데이터를 이용하여 1차 학습
1140
신경망 성능>기준 성능?
No
Yes
1150
코어 데이터 포함?
No
Yes
1170
학습 데이터의 코어 데이터 교체
1171
학습 데이터의 형태 변환
1172
학습 데이터를 이용하여 2차 학습
1173
신경망 성능>기준 성능?
Yes
No
1160
신경망 평가
종료

도면12

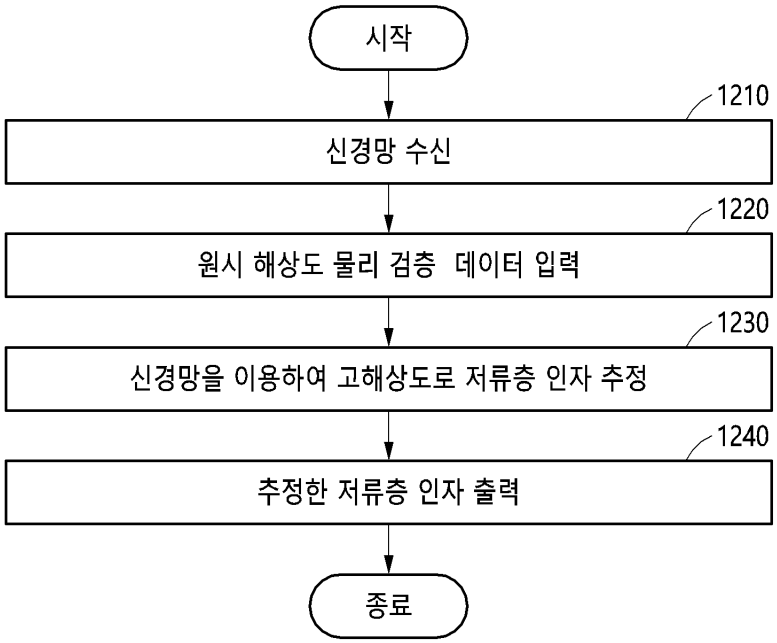
시작
1210
신경망 수신
1220
원시 해상도 물리 검증 데이터 입력
1230
신경망을 이용하여 고해상도로 저류층 인자 추정
1240
추정한 저류층 인자 출력
종료