



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0081161
(43) 공개일자 2025년06월05일

(51) 국제특허분류(Int. Cl.)
G01W 1/10 (2006.01) G06F 30/20 (2020.01)
G06Q 50/26 (2024.01) G08B 21/10 (2014.01)
G08B 31/00 (2006.01)
(52) CPC특허분류
G01W 1/10 (2013.01)
G06F 30/20 (2020.01)
(21) 출원번호 10-2023-0169210
(22) 출원일자 2023년11월29일
심사청구일자 2023년11월29일

(71) 출원인
울산대학교 산학협력단
울산광역시 남구 대학로 93(무거동)
(72) 발명자
김종호
울산광역시 남구 봉월로8번길 20, 202호 (신정동)
안성호
충청북도 괴산군 감물면 주월로 345
전 득 총
울산광역시 남구 대학로52번길 5-3, 301호 (무거동)
(74) 대리인
특허법인태백

전체 청구항 수 : 총 4 항

(54) 발명의 명칭 전지구 지역파고 단기예보 방법


(57) 요약

본 발명은, 전지구 지역파고 단기예보 방법에 관한 것이다.

본 발명에 따르면, 전지구 지역파고 단기예보 방법은 글로벌 장기 파도 예측 데이터에서 기 설정된 시간 단위의 파도 높이 데이터 및 풍속 데이터를 추출하는 단계; 상기 추출된 파도 높이 데이터 및 풍속 데이터에서 학습용

(뒷면에 계속)

대표도 - 도1



데이터를 선별하는 단계; 모델 학습을 위한 하이퍼파라미터를 결정하는 단계; 상기 파도 높이 데이터, 풍속 데이터 및 결정된 하이퍼파라미터를 이용하여 LSTM을 이용한 파고 예측 모델을 구축하는 단계; 및 상기 구축된 파고 예측 모델을 활용하여 지역 파고를 예측하는 단계를 포함한다.

이와 같이 본 발명에 따르면, 수치 파고 모델에 의해 생성된 장기 파고 예측을 활용하여 충분한 공간 해상도와 적용범위를 갖춘 지역 파고를 예측할 수 있고, 가장 빈번하게 발생하는 해상 상태와 파도 에너지를 가장 많이 기여하는 상태를 높은 정확도로 예측할 수 있다.

(52) CPC특허분류

G06Q 50/26 (2024.01)

G08B 21/10 (2013.01)

G08B 31/00 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호 1711186324

과제번호 2022R1A2C2008584

부처명 과학기술정보통신부

과제관리(전문)기관명 한국연구재단

연구사업명 개인기초연구(과기정통부)

연구과제명 연구 패러다임의 전환: 외삽능력을 탑재한 4세대 Physics-informed 머신러닝-대체모

형 개발

기 여 율 1/1

과제수행기관명 울산대학교

연구기간 2023.03.01 ~ 2024.02.29

명세서

청구범위

청구항 1

글로벌 장기 파도 예측 데이터에서 기 설정된 시간 단위의 파도 높이 데이터 및 풍속 데이터를 추출하는 단계;

상기 추출된 파도 높이 데이터 및 풍속 데이터에서 학습용 데이터를 선별하는 단계;

모델 학습을 위한 하이퍼파라미터를 결정하는 단계;

상기 파도 높이 데이터, 풍속 데이터 및 결정된 하이퍼파라미터를 이용하여 LSTM을 이용한 파고 예측 모델을 구축하는 단계; 및

상기 구축된 파고 예측 모델을 활용하여 지역 파고를 예측하는 단계를 포함하는 전지구 지역파고 단기예보 방법.

청구항 2

제 1 항에 있어서,

상기 파도 높이 데이터는,

$$S(f, \theta)$$

하기의 수학적식을 통해 계산되고, 는 무작위 위상 스펙트럼 작용 밀도 균형 방정식으로 계산된 파도 주파

f

θ

수-방향 스펙트럼의 값이며, 는 파도 주파수이고, 는 파도의 방향인 전지구 지역파고 단기예보 방법:

$$H_{m0} = 4 \sqrt{\int \int S(f, \theta) df d\theta}$$

청구항 3

제 1 항에 있어서,

상기 하이퍼 파라미터를 결정하는 단계는,

기 정의된 하이퍼파라미터를 고려한 무작위 탐색 기법을 통해, 각 하이퍼파라미터의 통계적 분포에서 무작위 값을 추출한 후 이들 값을 조합하여 값을 결정하는 전지구 지역파고 단기예보 방법.

청구항 4

제 1 항에 있어서,

상기 파고 예측 모델은,

다중 작업 학습을 사용하여 단일 모델 실행으로 모든 작업을 동시에 학습시키는 전지구 지역파고 단기예보 방법.

발명의 설명

기술 분야

본 발명은 전지구 단기예보 방법에 관한 것으로, 더욱 상세하게는 수치화된 파도 모델에 의해 생성된 장기 파고 예측 정보를 LSTM에 대한 훈련 데이터 세트로 사용하여 충분한 공간 해상도와 적용범위에서 지역 파고를 예측하

[0001]

는 전지구 지역파고 단기에보 방법에 관한 것이다.

배경 기술

- [0002] 해양 파도 예측은 파도 에너지 개발, 극한 환경 분석, 해양 구조물 설계 및 항해와 같은 해양 과학 및 공학 프로그램의 계획과 운영에 중요한 역할을 하고 있다.
- [0003] 때문에, 파도를 예측하는 수치 파도 모델은 과거에도 널리 사용되어 왔다.
- [0004] 하지만, 에너지 균형 방정식을 해결하는 수치 모델은 많은 양의 입력 데이터가 필요하며 높은 계산 비용이 발생하고, 이러한 모델을 적용하기 위해 모델 사양과 풍력 예보에 크게 의존하며 이는 파도 예측에 큰 불확실성을 야기한다.
- [0005] 또한, 긴급한 결과가 필요한 긴급 상황에서 종래의 수치 모델은 신뢰성이 부족할 수 있다는 한계가 있다.
- [0006] 이러한 한계를 극복하기 위하여 최근에는 파도 예측을 위해 훨씬 작은 계산 부하와 더 높은 정확도를 요구하는 소프트 컴퓨팅 및 특히 기계 학습에 기반한 간단한 접근 방식이 개발되고 있다.
- [0007] 그에 따라 검증된 장기 파도 과거 예측 데이터에 대한 접근성이 높아지고 있지만 파도 과거 예측을 기반으로 한 기계 학습 파도 예측 모델에 대한 연구는 거의 진행되지 않고 있다.
- [0008] 또한, 과거 기계학습 기반 파고 예측에서는 현장 관측자료(in-situ data)만을 학습하여, 관측 값이 없는 지역, 관측이 어려운 시기(허리케인 등으로 파손되는 경우), 현장 관측자료의 학습범위를 넘어서서 외삽이 필요한 경우 등에 대한 예측은 불가능하다는 한계 역시 존재하고 있다.

선행기술문헌

특허문헌

- [0009] (특허문헌 0001) KR 10-1861065(2018.05.18)

발명의 내용

해결하려는 과제

- [0010] 본 발명에 따르면, 수치화된 파도 모델에 의해 생성된 장기 파고 예측 정보를 LSTM에 대한 훈련 데이터 세트로 사용하여 충분한 공간 해상도와 적용범위에서 지역 파고를 예측하는 전지구 지역파고 단기에보 방법을 제공하기 위한 것이다.

과제의 해결 수단

- [0011] 이러한 기술적 과제를 이루기 위한 본 발명의 일 실시예에 따르면 전지구 지역파고 단기에보 방법은 글로벌 장기 파도 예측 데이터에서 기 설정된 시간 단위의 파도 높이 데이터 및 풍속 데이터를 추출하는 단계; 상기 추출된 파도 높이 데이터 및 풍속 데이터에서 학습용 데이터를 선별하는 단계; 모델 학습을 위한 하이퍼파라미터를 결정하는 단계; 상기 파도 높이 데이터, 풍속 데이터 및 결정된 하이퍼파라미터를 이용하여 LSTM을 이용한 파고 예측 모델을 구축하는 단계; 및 상기 구축된 파고 예측 모델을 활용하여 지역 파고를 예측하는 단계를 포함한다.

발명의 효과

- [0012] 이와 같이 본 발명에 따르면, 수치 파고 모델에 의해 생성된 장기 파고 예측을 활용하여 충분한 공간 해상도와 적용범위를 갖춘 지역 파고를 예측할 수 있고, 가장 빈번하게 발생하는 해상 상태와 파도 에너지를 가장 많이 기여하는 상태를 높은 정확도로 예측할 수 있다.

도면의 간단한 설명

- [0013] 도 1은 본 발명의 일 실시예에 따른 전지구 지역파고 단기에보 방법의 흐름을 도시한 도면이다.
- 도 2는 본 발명의 일 실시예에 따라 결정된 하이퍼파라미터 범위와 무작위 탐색 방법을 통해 결정된 최적 값을

예를 도시한 도면이다.

도 3은 LSTM을 설명하기 위한 도면이다.

도 4는 본 발명의 일 실시예에 따른 다중 작업 학습을 위한 하드 파라미터 공유 아키텍처의 예를 도시한 도면이다.

도 5는 본 발명의 일 실시예에 따른 모델을 검증하기 위한 지역의 파도 기후를 설명하기 위한 도면이다.

도 6은 본 발명의 일 실시예에 따른 모델의 예측 결과를 설명하기 위한 도면이다.

발명을 실시하기 위한 구체적인 내용

[0014] 이하 첨부된 도면을 참조하여 본 발명에 따른 바람직한 실시예를 상세히 설명하기로 한다. 이 과정에서 도면에 도시된 선들의 두께나 구성요소의 크기 등은 설명의 명료성과 편의상 과장되게 도시되어 있을 수 있다.

[0015] 또한 후술되는 용어들은 본 발명에서의 기능을 고려하여 정의된 용어들로서, 이는 사용자, 운용자의 의도 또는 관례에 따라 달라질 수 있다. 그러므로 이러한 용어들에 대한 정의는 본 명세서 전반에 걸친 내용을 토대로 내려져야 할 것이다.

[0016] 도 1은 본 발명의 일 실시예에 따른 전지구 지역파고 단기예보 방법의 흐름을 도시한 도면이다.

[0017] 도 1에 도시된 바와 같이, 전지구 지역파고 단기예보를 위해 먼저 글로벌 장기 파도 예측 데이터에서 기 설정된 시간(예를 들어, 3시간) 단위의 파도 높이 데이터 및 풍속 데이터를 추출한다(S100).

$$H_{m0}$$

[0018] 이 때, 파도 높이 데이터()는 하기의 수학적 식 1을 통해 계산된다.

수학적 식 1

$$H_{m0} = 4 \sqrt{\int \int S(f, \theta) df d\theta}$$

[0019]

$$S(f, \theta)$$

[0020] 이 때, 는 무작위 위상 스펙트럼 작용 밀도 균형 방정식으로 계산된 파도 주파수-방향 스펙트럼의 값이며, 는 파도 주파수이고, 는 파도의 방향이다

[0021] 다음으로, 추출된 파도 높이 데이터 및 풍속 데이터에서 학습용 데이터를 선별한다(S200).

[0022] 도 2는 본 발명의 일 실시예에 따라 결정된 하이퍼파라미터 범위와 무작위 탐색 방법을 통해 결정된 최적 값을 예를 도시한 도면이다.

[0023] 다음으로, 모델 학습을 위한 하이퍼파라미터를 결정한다(S300).

[0024] 좀 더 상세하게는, 도 2와 같이, 기 정의된 하이퍼파라미터(예를 들어, 은닉계층 수, 은닉유닛 수, 배치 크기, 드롭아웃 비율 및 에포크 수)를 고려한 무작위 탐색 기법을 사용하여 최적의 하이퍼파라미터 세트를 결정한다.

[0025] 이 때, 무작위 탐색 기법을 통해, 각 하이퍼파라미터의 통계적 분포에서 무작위 값을 추출한 후 이들 값을 조합하여 최적의 값을 결정한다.

[0026] 다음으로, LSTM을 이용한 파고 예측 모델을 구축한다(S400).

[0027] 도 3은 LSTM을 설명하기 위한 도면이다.

[0028] 도 3에 도시된 바와 같이, LSTM은 특수한 형태의 구조화된 RNN으로, RNN을 훈련할 때, 매개변수 업데이트에 필요한 정보를 운반하는 기울기가 역전파 과정 중에 소실되거나 폭발할 수 있는 문제를 해결하기 위해 기존의 RNN 블록에 "셀 상태"라는 추가 요소를 도입하고 정보의 갱신, 버리기 및 출력을 제어하는 3개의 "게이트"를 도입한

형태이다.

[0029] 좀 더 상세하게는, LSTM은 입력 시퀀스로부터 제공되는 정보를 학습하는 과정에서, 입력 게이트 (i)는 어떤 정보가 셀 상태에 들어가야 하는지를 결정하고, 망각 게이트 (f)는 어떤 정보를 삭제할지 결정하며, 출력 게이트 (o)는 새로운 숨겨진 상태 (h)로 라우팅될 셀 상태를 제어하고, 숨겨진 상태에 의해 출력 값인 y_t 가 계산된다.

[0030] 구축된 파고 예측 모델은 하기의 수학적 식 2와 같이 현재 시간 t에 대한 입력변수인 H_t 와 $WS_{n,t}$ 를 사용하여 미래의 파고 값 $H(t+k)$ 를 예측할 수 있다.

수학적 식 2

$$(H_{t+1}^{fcst}, H_{t+2}^{fcst}, \dots, H_{t+k}^{fcst}) = \text{LSTM}_{k,n}(H_t^{pres}, WS_{1,t}^{pres}, WS_{2,t}^{pres}, \dots, WS_{n,t}^{pres})$$

[0031]

[0032] 이 때, k는 미래의 시간 단계이고, n은 LSTM에서 고려된 바람 입력 위치의 수고, $\text{LSTM}_{k,n}$ 은 k와 n에 대해 다른 값을 갖는 LSTM 예측이다.

[0033] 예를 들어, $\text{LSTM}_{k=4,n=5}$ 는 현재 시간에서부터 4개의 미래 시간 단계동안 3시간 간격으로 시계열의 파고 값 H를 WS_{1-5} 를 사용하여 예측하는데 H와 WS_{1-5} 를 사용한다.

[0034] 이 경우, $\text{LSTM}_{k=4,n=5}$ 에서 예측된 시계열의 파고 값 H를 $H_{k=4,n=5}$ 로 정의한다.

[0035] 도 4는 본 발명의 일 실시예에 따른 다중 작업 학습을 위한 하드 파라미터 공유 아키텍처의 예를 도시한 도면이다.

[0036] 이 때, y_k 와 x_k 는 각각 k번째 작업의 입력 예측변수와 출력이고, Block_t 는 시간 단계 t에서의 LSTM 블록이 $c_t^{[i]}$ 및 $h_t^{[i]}$ 1번째 레이어의 시간 단계 t에서의 셀 상태와 은닉 상태이다.

[0037] k가 1보다 클 경우, 파고 예측 모델은 단일 모델 실행으로 모든 작업을 동시에 학습시킨다.

[0038] 이 때, 모델의 학습은 다중 작업 학습을 사용하여 모든 작업을 동시에 완료하고, 여러 작업에서 유용한 데이터의 일반화된 표현을 학습하며, 서로 다른 작업의 모든 사용 가능한 데이터를 활용한다.

[0039] 또한, 하드 매개변수 공유 개념을 적용하여 모든 작업 간의 숨겨진 레이어를 연결하여 작업별 출력 레이어로 반환하며, 모든 작업의 출력을 제공한다.

[0040] 또한, 이 과정에서의 손실 함수는 각 개별 작업의 손실을 합산한 것으로 구성된다.

[0041] 도 5는 본 발명의 일 실시예에 따른 모델을 검증하기 위한 지역의 파도 기후를 설명하기 위한 도면이고, 도 6은 본 발명의 일 실시예에 따른 모델의 예측 결과를 설명하기 위한 도면이다.

[0042] 이 때, 도 5의 (a), (b), (c)는 각 검증 지역의 31년 평균 파도 파워 로즈(wave-power rose)이고, (d), (e), (f)는 각 검증 지역의 31년간의 유의한 파고 시계열, 전역 풍속 간의 상관 계수를 나타내며, x는 3개의 파도 지점을 의미한다.

[0043] 또한, 도 6의 (a)는 북태평양 지점, (b)는 멕시코만 지점, (c)는 북대서양 지점을 의미하고, 좌측 부분 그림은 유효 기간 동안 가장 큰 H_{LWWIII} 사건을 강조한 3개월 동안의 시계열 비교이고, 가운데와 우측 부분 그림은 각

각 산점도와 퍼센트 편향 (PBIAS)의 오차 막대 그림이다

[0044] 구축된 모델은 도 5에 도시된 바와 같이 서로 다른 파도 기후를 가진 지역에 적용하여 검증하였다.

[0045] 좀 더 상세하게는, 북태평양, 멕시코 만, 북대서양 내에서 서로 다른 해양 분지에 위치한 미국의 세 지역을 검증 지역으로 채택하여 글로벌 파도 사이트에서의 모델 성능을 검토하고, 모델이 다양한 파도 기후에 걸쳐 적용 가능한지를 확인하였다.

[0046] 종래의 WWIII모델에서 계산된 검증 지역 내 유의 파고와 본 발명의 파고 예측 모델이 예측한 검증 지역 내 파고 정보를 비교한 결과, 도 6과 같이, $H_{k=1,n=0}$ 는 WWIII모델의 유의 파고와 밀접한 일치도를 보임을 확인하였다.

[0047] 또한, 상관계수 R은 북태평양, 멕시코 만, 북대서양 지점에서 각각 0.968, 0.977 및 0.985의 수치를 기록했다.

[0048] 또한, $H_{k=1,n=0}$ 와 WWIII모델의 유의 파고 사이의 제곱 평균 오차 (RMSE) 및 퍼센트 편향도 $LSTM_{k=1,n=0}$ 의 높은 정확도를 지원한다.

[0049] 파고 예측 모델을 구축한 후, 구축된 모델을 활용하여 지역 파고를 예측한다(S500).


[0050] 이와 같이 본 발명에 따르면, 수치 파고 모델에 의해 생성된 장기 파고 예측을 활용하여 충분한 공간 해상도와 적용범위를 갖춘 지역 파고를 예측할 수 있고, 가장 빈번하게 발생하는 해상 상태와 파도 에너지를 가장 많이 기여하는 상태를 높은 정확도로 예측할 수 있다.

[0051] 또한, 본 발명에 따르면, 과거의 현장 관측자료만을 통한 학습으로는 예측이 불가능했던 과거 기계학습 기반 파고 예측의 문제를 극복하기 위해 현장 관측자료 이외에 수치 재현(hindcast) 자료를 수집/검토/재구성하여 기계 학습을 수행하는 시스템을 제시하여 현장 관측자료가 존재하는 지역뿐만 아니라 없는 지역, 즉, 전지구에 대해서도 충분한 공간해상도를 갖는 지역파고 예측을 가능하게 할 수 있다.

[0052] 본 발명은 도면에 도시된 실시예를 참고로 하여 설명되었으나 이는 예시적인 것에 불과하며, 당해 기술이 속하는 분야에서 통상의 지식을 가진 자라면 이로부터 다양한 변형 및 균등한 타 실시예가 가능하다는 점을 이해할 것이다. 따라서 본 발명의 진정한 기술적 보호범위는 아래의 특허청구범위의 기술적 사상에 의하여 정해져야 할 것이다.

도면


도면1




도면2

Hyperparameter	Range	$k = 1$	$k \geq 2$
The number of layers	[1-10]	2	2
The number of hidden units	[10-1000]	150	250
The number of epochs	[10-1000]	150	250
Dropout rate	[0.1-0.9]	0.5	0.4
Batch size	[2-1024]	32	16


도면3



도면4



도면5



도면6

