(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0058270
(43) 공개일자 2025년04월30일

(51) 국제특허분류(Int. Cl.)
G06N 3/04 (2023.01) *G01C 13/00* (2006.01)
G01S 13/50 (2006.01) *G01S 13/524* (2006.01)
G06N 3/0442 (2023.01)
(52) CPC특허분류
G06N 3/049 (2023.01)
G01C 13/002 (2013.01)
(21) 출원번호 10-2023-0141821
(22) 출원일자 2023년10월23일
심사청구일자 2023년10월23일

(71) 출원인
인천대학교 산학협력단
인천광역시 연수구 갯벌로 27, 인천대학교 이노베이션센터(송도동)
(72) 발명자
전광길
인천광역시 연수구 해송로 70, 209동 805호(송도동, 송도웰 카운티2단지)
(74) 대리인
특허법인충정

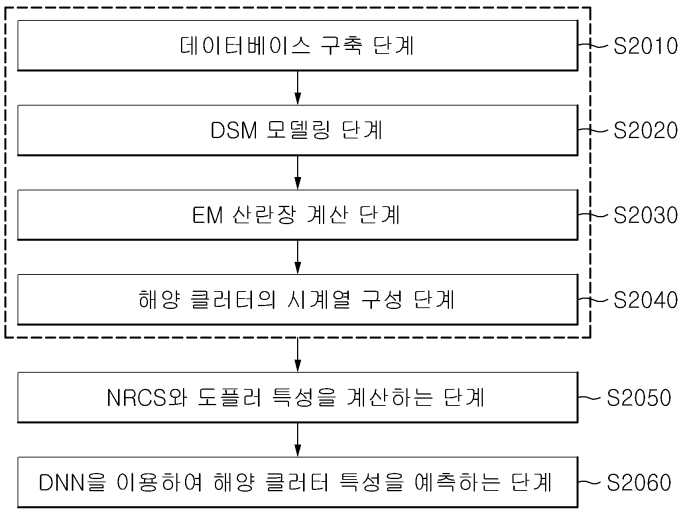
전체 청구항 수 : 총 10 항

(54) 발명의 명칭 **딥러닝 모델을 이용한 해양 환경 특성 예측 방법 및 장치**

(57) 요 약

서로 다른 해역에서 시간에 따른 해양 환경에 대한 데이터베이스를 구축하는 데이터베이스 구축 단계; 상기 데이터베이스로부터 지리 정보 시스템 및 원격 감지 응용프로그램에 사용되는 데이터 세트인 디지털 표면 모델(Digital Surface Model, DSM)을 생성하는 DSM 모델링 단계; 상기 DSM 모델을 활용하여 파도와 관련한 매개변수를 기반으로 하는 중력파와 바람과 관련한 매개변수를 기반으로 하는 장력파(tension ripples)로부터 EM 산란장(Electromagnetic scattering field)을 각 계산하는 EM 산란장 계산 단계; 및 상기 데이터베이스 구축 단계, 상기 DSM 모델링 단계, 상기 EM 산란장 계산 단계를 순차적으로 반복하여 해양 클러터의 시계열을 구성하는 해양 클러터의 시계열 구성 단계;를 포함하는 것을 특징으로 한다.

대 표 도 - 도20



(52) CPC특허분류
G01S 13/505 (2021.01)
G01S 13/5244 (2013.01)
G06N 3/0442 (2023.01)

명 세 서

청구범위

청구항 1

서로 다른 해역에서 시간에 따른 해양 환경에 대한 데이터베이스를 구축하는 데이터베이스 구축 단계;

상기 데이터베이스로부터 지리 정보 시스템 및 원격 감지 응용프로그램에 사용되는 데이터 세트인 디지털 표면 모델(Digital Surface Model, DSM)을 생성하는 DSM 모델링 단계;

상기 DSM 모델을 활용하여 파도와 관련한 매개변수를 기반으로 하는 중력파와 바람과 관련한 매개변수를 기반으로 하는 장력파(tension ripples)로부터 EM 산란장(Electromagnetic scattering field)을 각 계산하는 EM 산란장 계산 단계; 및

상기 데이터베이스 구축 단계, 상기 DSM 모델링 단계, 상기 EM 산란장 계산 단계를 순차적으로 반복하여 해양 클러터의 시계열을 구성하는 해양 클러터의 시계열 구성 단계;를 포함하는, 딥러닝 모델을 이용한 해양 환경 특성 예측 방법.

청구항 2

제1항에 있어서, 상기 데이터베이스 구축 단계에서는,

장단기기억(Long Short-Term Memory, LSTM) 신경망 모델을 활용하여 누락된 시계열 해양 환경 요소를 예측하는, 딥러닝 모델을 이용한 해양 환경 특성 예측 방법.

청구항 3

제1항에 있어서,

상기 해양 클러터의 시계열에 기반하여 해양 클러터 특성인 정규화된 레이더 단면적(Normalized radar cross section, NRCS)과 도플러 특성을 계산하는 단계;를 더 포함하는, 딥러닝 모델을 이용한 해양 환경 특성 예측 방법.

청구항 4

제1항에 있어서,

상기 해양 클러터의 시계열에 기반하고, 심층 신경망(Deep Neural Network, DNN)을 이용하여 실제 바다의 해양 클러터 특성을 예측하는 단계;를 더 포함하는, 딥러닝 모델을 이용한 해양 환경 특성 예측 방법.

청구항 5

제1항에 있어서, 상기 데이터베이스 구축 단계에서,

상기 해양 환경에 대한 데이터는 바람의 속도 및 방향과 파도의 높이, 방향 및 주기를 포함하는, 딥러닝 모델을 이용한 해양 환경 특성 예측 방법.

청구항 6

제1항에 있어서, 상기 EM 산란장 계산 단계에서,

상기 중력파에 상기 장력파를 중첩하는데 선형 중첩 방법을 사용하는, 딥러닝 모델을 이용한 해양 환경 특성 예측 방법.

청구항 7

제1항에 있어서, 상기 시계열 구성 단계에서는,

상기 시계열을 구성하기 전에 정상성을 확인하고, 차분(differencing), 정규화, 역평균화의 방법을 통해 불안정

한 계열 데이터를 안정적인 계열 데이터로 변환하는, 딥러닝 모델을 이용한 해양 환경 특성 예측 방법.

청구항 8

제1항에 있어서, 시계열 구성 단계에서는,

미리 일정 시간을 설정하고, 설정한 시간을 기준으로 풍속, 파도 높이, 파도 주기 및 파도 방향을 샘플링하는, 딥러닝 모델을 이용한 해양 환경 특성 예측 방법.

청구항 9

제3항에 있어서,

예측한 상기 해양 클러터 특징 데이터를 변환하여 유효 파도 높이를 계산하는, 딥러닝 모델을 이용한 해양 환경 특성 예측 방법.

청구항 10

서로 다른 해역에서 시간에 따른 해양 환경에 대한 데이터베이스를 구축하는 데이터베이스 구축부;

상기 데이터베이스로부터 지리 정보 시스템 및 원격 감지 응용프로그램에 사용되는 데이터 세트인 디지털 표면 모델(Digital Surface Model, DSM)을 생성하는 DSM 모델링부;

상기 DSM 모델을 활용하여 파도와 관련한 매개변수를 기반으로 하는 중력파와 바람과 관련한 매개변수를 기반으로 하는 장력파(tension ripples)로부터 EM 산란장(Electromagnetic scattering field)을 각 계산하는 EM 산란장 계산부; 및

상기 데이터베이스 구축 단계, 상기 DSM 모델링 단계, 상기 EM 산란장 계산 단계를 순차적으로 반복하여 해양 클러터의 시계열을 구성하는 해양 클러터의 시계열 구성부;를 포함하는, 딥러닝 모델을 이용한 해양 환경 특성 예측 장치.

발명의 설명

기 술 분 야

[0001] 본 발명은 해양 환경 특징 예측 방법 및 장치에 관한 것으로, 구체적으로는 딥러닝 모델을 이용하여 해양 환경에서 실제 해상 조건에서의 변수를 고려하여 해양 환경의 특성을 예측하기 위한 것이다.

배 경 기 술

[0002] 서로 다른 해역의 실제 해양 환경에서 해양 클러터의 특성은 레이더 탐지, 원격 감지, SAR 이미징 및 상황 인식과 같은 군사 산업에서 중요한 역할을 하는데, 여기서 해양 클러터란 전파가 해면에 반사되어 나타나는 에코를 의미한다.

[0003] 중국에서는 연안 해양환경요소 데이터베이스를 확보하기 위하여 결측치 개선을 위한 해양환경요소 시공간 예측 모델을 개발하고, 서로 다른 규모에서 해수면의 산란 메커니즘을 종합적으로 고려하여 다중 규모 실제 표면의 해면 클러터 시계열의 대규모 데이터베이스를 구축하고 있으나 실제 해양 환경에서 발생하는 해양 클러터는 매우 복잡하다는 어려움이 있다.

[0004] 특히, 레이더 신호처리 분야에서 해양 클러터가 있는 환경에서의 이동표적 탐지 과정에서 레이더 펄스가 해수면으로부터 후방 산란되어 불필요한 반향신호가 발생할 수 있고 이로 인해 표적 탐지는 더욱 어려울 수 있다.

[0005] 따라서, 날씨가 좋지 않은 바다의 상황에 따라 해양 클러터의 특성이 급격히 변할 수 있고 에코 간섭이 발생할 수 있기 때문에 풍속, 풍향, 파고, 파주기 등을 종합적으로 고려하여 해양 클러터 특성을 정확히 예측하기가 어렵다는 문제점이 있다.

선행기술문헌

특허문헌

[0006] (특허문헌 0001) KR 10-2018-0100101 B1

발명의 내용

해결하려는 과제

[0007] 이와 같은 문제점을 해결하기 위하여, 본 발명은 서로 다른 해역에서 시간에 따른 해양 환경에 대한 데이터베이스를 구축하는 데이터베이스 구축 단계; 상기 데이터베이스로부터 지리 정보 시스템 및 원격 감지 응용프로그램에 사용되는 데이터 세트인 디지털 표면 모델(Digital Surface Model, DSM)을 생성하는 DSM 모델링 단계; 상기 DSM 모델을 활용하여 파도와 관련한 매개변수를 기반으로 하는 중력파와 바람과 관련한 매개변수를 기반으로 하는 장력파(tension ripples)로부터 EM 산란장(Electromagnetic scattering field)을 각 계산하는 EM 산란장 계산 단계; 및 상기 데이터베이스 구축 단계, 상기 DSM 모델링 단계, 상기 EM 산란장 계산 단계를 순차적으로 반복하여 해양 클러터의 시계열을 구성하는 해양 클러터의 시계열 구성 단계;를 포함하는, 딥러닝 모델을 이용한 해양 환경 특성 예측 방법 및 장치를 제공하는데 그 목적이 있다.

과제의 해결 수단

[0008] 상기 목적을 달성하기 위한 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 방법은, 서로 다른 해역에서 시간에 따른 해양 환경에 대한 데이터베이스를 구축하는 데이터베이스 구축 단계; 상기 데이터베이스로부터 지리 정보 시스템 및 원격 감지 응용프로그램에 사용되는 데이터 세트인 디지털 표면 모델(Digital Surface Model, DSM)을 생성하는 DSM 모델링 단계; 상기 DSM 모델을 활용하여 파도와 관련한 매개변수를 기반으로 하는 중력파와 바람과 관련한 매개변수를 기반으로 하는 장력파(tension ripples)로부터 EM 산란장(Electromagnetic scattering field)을 각 계산하는 EM 산란장 계산 단계; 및 상기 데이터베이스 구축 단계, 상기 DSM 모델링 단계, 상기 EM 산란장 계산 단계를 순차적으로 반복하여 해양 클러터의 시계열을 구성하는 해양 클러터의 시계열 구성 단계;를 포함할 수 있다.

[0009] 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 방법 중 상기 데이터베이스 구축 단계에서는, 장단기기억(Long Short-Term Memory, LSTM) 신경망 모델을 활용하여 누락된 시계열 해양 환경 요소를 예측할 수 있다.

[0010] 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 방법은, 상기 해양 클러터의 시계열에 기반하여 해양 클러터 특성인 정규화된 레이더 단면적(Normalized radar cross section, NRCS)과 도플러 특성을 계산하는 단계;를 더 포함할 수 있다.

[0011] 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 방법은, 상기 해양 클러터의 시계열에 기반하고, 심층 신경망(Deep Neural Network, DNN)을 이용하여 실제 바다의 해양 클러터 특성을 예측하는 단계;를 더 포함할 수 있다.

[0012] 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 방법 중 상기 데이터베이스 구축 단계에서, 상기 해양 환경에 대한 데이터는 바람의 속도 및 방향과 파도의 높이, 방향 및 주기를 포함할 수 있다.

[0013] 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 방법 중 상기 EM 산란장 계산 단계에서, 상기 중력파에 상기 장력파를 중첩하는데 선형 중첩 방법을 사용할 수 있다.

[0014] 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 방법 중 상기 시계열 구성 단계에서는, 상기 시계열을 구성하기 전에 정상성을 확인하고, 차분(differencing), 정규화, 역평균화의 방법을 통해 불안정한 계열 데이터를 안정적인 계열 데이터로 변환할 수 있다.

[0015] 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 방법 중 시계열 구성 단계에서는, 미리 일정 시간을 설정하고, 설정한 시간을 기준으로 풍속, 파도 높이, 파도 주기 및 파도 방향을 샘플링할 수 있다.

[0016] 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 방법은, 예측한 상기 해양 클러터 특징 데이터를 변환하여 유효 파도 높이를 계산할 수 있다.

[0017] 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 장치는, 서로 다른 해역에서 시간에 따른 해양 환경에 대한 데이터베이스를 구축하는 데이터베이스 구축부; 상기 데이터베이스로부터 지리 정보 시스

템 및 원격 감지 응용프로그램에 사용되는 데이터 세트인 디지털 표면 모델(Digital Surface Model, DSM)을 생성하는 DSM 모델링부; 상기 DSM 모델을 활용하여 파도와 관련한 매개변수를 기반으로 하는 중력파와 바람과 관련한 매개변수를 기반으로 하는 장력파(tension ripples)로부터 EM 산란장(Electromagnetic scattering field)을 각 계산하는 EM 산란장 계산부; 및 상기 데이터베이스 구축 단계, 상기 DSM 모델링 단계, 상기 EM 산란장 계산 단계를 순차적으로 반복하여 해양 클러터의 시계열을 구성하는 해양 클러터의 시계열 구성부;를 포함할 수 있다.

발명의 효과

[0018] 본 발명은 해양 산업에서 표적 레이더의 장거리 탐지, 유도, 조기 경보, 추적 및 식별에 중요한 영향을 미치는 해양 클러터의 특성을 예측하는 모델을 제안할 수 있고, 해역에서 실제 해수면의 미세한 기하학적 구조를 확립할 수 있으며, 바다 클러터 시계열을 설정하기 위한 복합 산란 방법을 개발할 수 있다.

[0019] 특히, 실제 해상 환경에서의 신호에는 필연적으로 자연계에서 반사되는 클러터 신호의 정보도 포함하고 있는데, 해수 클러터의 특성을 복잡하게 만드는 해양 환경요소(풍속, 풍향, 파고, 파향)를 고려한 모델을 개발하기 위하여, 장단기기억(Long Short-Term Memory, LSTM) 신경망 모델과 심층 신경망(Deep Neural Network, DNN)을 이용하여 해양환경요소와 해양클러터 특성과의 상관관계 모델을 구축할 수 있다.

도면의 간단한 설명

[0020] 도 1은 중국 연안 해역의 다양한 해역과 중앙 샘플링 지역

도 2는 다중 규모 해수면 중첩의 개략도

도 3은 해수면 레이더 조사의 개략도

도 4는 입사각이 20도 미만일 때 해수면 산란 메커니즘의 모식도

도 5는 중력파에 의해 변조된 장력파의 EM 산란에 대한 개략도

도 6은 해양 클러터 시계열 모델링의 개략도

도 7은 해양 환경 요소의 시공간 예측

도 8은 해양 환경 요소에 기반한 해양 클러터 예측 방법

도 9는 2017년 남중국해 풍속 및 파도 높이의 통계적 평균 및 표준편차 특성

도 10은 다양한 풍속 데이터 크기가 DNN 정확도에 미치는 영향

도 11은 LTSM을 기반으로 2017년 1월 서해 해상 풍속 및 파도 높이 예측

도 12는 황해 2단계 해상조건에서 S-band의 HH-pol을 이용한 해양 클러터 시계열 시뮬레이션 결과

도 13은 해양 클러터 시뮬레이션 결과와 황해 실측자료 비교

도 14는 가중치 반복 횟수 증가에 따른 RMSE 및 정확도의 변화

도 15는 다양한 은닉층과 노드 수가 훈련 결과에 미치는 영향

도 16은 DNN 기반으로 한 황해 유효 파도 높이 및 파동 주기 예측

도 17은 실제 해수면의 해양 클러터 특성 예측 결과

도 18은 다양한 해양 클러터 특성 데이터 세트에 따른 파도 높이 인버전 결과

도 19는 다양한 해역에 따른 파도 높이 인버전 결과

도 20은 본 발명의 일 실시예에 따른 딥러닝 모델을 이용한 해양 환경 특성 예측 방법 흐름도

도 21은 본 발명의 일 실시에에 따른 딥러닝 모델을 이용한 해양 환경 특성 예측 장치

발명을 실시하기 위한 구체적인 내용

[0021] 본 발명의 목적, 특정한 장점들 및 신규한 특징들은 첨부된 도면들과 연관되어지는 이하의 상세한 설명과 바람

직한 실시예들로부터 더욱 명백해질 것이다. 이때, 각각의 도면에서 동일한 구성요소는 가능한 동일한 부호로 나타낸다. 또한, 이미 공지된 기능 및/또는 구성에 대한 상세한 설명은 생략한다.

[0022] 이하에 개시된 내용은, 다양한 실시 예에 따른 동작을 이해하는데 필요한 부분을 중점적으로 설명하며, 그 설명의 요지를 흐릴 수 있는 요소들에 대한 설명은 생략한다. 또한 도면의 일부 구성요소는 과장되거나 생략되거나 또는 개략적으로 도시될 수 있다. 각 구성요소의 크기는 실제 크기를 전적으로 반영하는 것이 아니며, 따라서 각각의 도면에 그려진 구성요소들의 상대적인 크기나 간격에 의해 여기에 기재되는 내용들이 제한되는 것은 아니다.

[0023] 본 발명의 실시예들을 설명함에 있어서, 본 발명과 관련된 공지기술에 대한 구체적인 설명이 본 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명을 생략하기로 한다. 그리고, 후술되는 용어들은 본 발명에서의 기능을 고려하여 정의된 용어들로서 이는 사용자, 운용자의 의도 또는 관례 등에 따라 달라질 수 있다. 그러므로 그 정의는 본 명세서 전반에 걸친 내용을 토대로 내려져야 할 것이다. 상세한 설명에서 사용되는 용어는 단지 본 발명의 실시 예들을 기술하기 위한 것이며, 결코 제한적이어서는 안 된다. 명확하게 달리 사용되지 않는 한, 단수 형태의 표현은 복수 형태의 의미를 포함한다. 본 설명에서, "포함" 또는 "구비"와 같은 표현은 어떤 특성들, 숫자들, 단계들, 동작들, 요소들, 이들의 일부 또는 조합을 가리키기 위한 것이며, 기술된 것 이외에 하나 또는 그 이상의 다른 특성, 숫자, 단계, 동작, 요소, 이들의 일부 또는 조합의 존재 또는 가능성을 배제하도록 해석되어서는 안 된다.

[0024] 또한, 제1, 제2 등의 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 상기 구성요소들은 상기 용어들에 의해 한정되는 것은 아니며, 상기 용어들은 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 사용된다.

[0025] 이하에서는, 첨부된 도면들을 참조하여, 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 방법 및 장치에 대해 설명하기로 한다.

[0026] 본 발명의 딥러닝 모델을 이용한 해양 환경 특성 예측 방법의 흐름도는 도 20에 나와 있다.

[0027] 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 방법에는 4가지 주요 단계가 있다. 데이터베이스 구축 단계(S2010); DSM 모델링 단계(S2020); EM 산란장 계산 단계(S2030); 및 해양 클러터의 시계열 구성 단계(S2040);를 포함하는 것을 특징으로 한다.

[0028] 한편, 도 21을 참조하면, 본 발명의 일 실시예에 의한 딥러닝 모델을 이용한 해양 환경 특성 예측 장치(2100)에는 프로세서(2102), 메모리(2104), 입출력 인터페이스(2106), 네트워크 통신 인터페이스(2108)를 포함하는 것을 특징으로 한다.

[0030] 도 20을 참조하면, 단계 S2010에서는, 서로 다른 해역에서 시간에 따른 해양 환경에 대한 데이터베이스를 구축할 수 있다.

[0031] 상기 해양 환경에 대한 데이터에는 해양 클러터의 특성을 복잡하게 만드는 해양 환경요소로 바람의 속도 및 방향, 파도의 높이, 방향 및 주기를 포함할 수 있다.

[0032] 도 20을 참조하면, 단계 S2020에서는, 상기 데이터베이스로부터 지리 정보 시스템 및 원격 감지 응용프로그램에 사용되는 데이터 세트인 디지털 표면 모델(Digital Surface Model, DSM)을 생성할 수 있다.

[0033] 디지털 표면 모델(Digital Surface Model, DSM)은 일반적으로 인공 지능 자체의 구성 요소가 아니라 지리 정보 시스템(GIS) 및 원격 감지 응용 프로그램에 사용되는 데이터 유형으로, DSM은 지구 표면의 지형이나 기타 물체의 고도에 대한 정보를 제공할 수 있다.

[0034] DSM은 일반적으로 위성 이미지, 항공 사진, LiDAR(빛 감지 및 거리 측정) 센서 및 기타 원격 감지 기술을 포함한 다양한 소스에서 수집된 데이터를 사용하여 생성될 수 있다.

[0035] DSM의 주요 목적은 지구 표면에 대한 고도 데이터를 제공하는 것으로, 여기에는 산, 계곡, 강과 같은 자연 지형과 건물 및 인프라와 같은 인공 구조물에 대한 정보가 포함될 수 있고, 3D 형식으로 표현되는데 지형의 고도를 제공할 뿐만 아니라 지면 위의 물체 높이도 캡처할 수 있다.

[0036] DSM은 지구 표면과 그 특징에 대한 정확한 고도와 3D 정보가 필요한 다양한 응용 프로그램에 사용되는 지리 공

간 데이터 세트일 수 있다.

[0037] 도 20을 참조하면, 단계 S2030에서는, 상기 DSM 모델을 활용하여 파도와 관련한 매개변수를 기반으로 하는 중력파와 바람과 관련한 매개변수를 기반으로 하는 장력파(tension ripples)로부터 EM 산란장(Electromagnetic scattering field)을 각 계산할 수 있다.

[0038] 도 3은 실제 해수면 EM 산란장의 개략도를 나타낸다.

[0039] 실제 해수면 EM 산란 측정은 날씨, 해역 및 장비 정확도에 따라 제한될 수 있다.

[0040] 바다 표면에서의 EM 산란장 메커니즘을 연구하기 위해 파도 에너지 스펙트럼 $S(f,\varphi)$이 활용될 수 있다.

[0041] 상기 파도 에너지 스펙트럼은 파도 에너지 분포 특성을 나타내고, 이는 수학식 1에 기반하여 계산할 수 있다.

수학식 1

[0042] $$S(f,\varphi) = S(f)D(\varphi,s)$$

[0043] 여기서, $S(f)$는 1차원의 파동 스펙트럼이고, $D(\varphi,s)$는 파도의 진동수와 관련된 각도 분포함수이며, 상기 진동수는 특정 주파수에서 다른 방향의 스펙트럼 에너지의 분포 특성을 나타낼 수 있다.

[0044] $S(f)$는 바람의 면적과 풍속의 제약으로 인하여, 실제 바다 표면에서는 적용이 어려울 수 있으나 일본 해역의 파동 곡선을 수치적으로 분석하여 수학식 2 내지 수학식 4에 기반하여 계산할 수 있다.

[0045] 여기서, $S_J(f)$는 파도 높이와 주파수의 통계적 분포를 설명하는 데 사용되는 수학적 모델인 Joint North Sea Wave Project 파동 스펙트럼을 나타낸다.

수학식 2

[0046] $$S_J(f) = \beta_j H_s^2 T_p^{-4} f^{-5} \exp\left[-1.25\left(T_p f\right)^{-4}\right] \gamma^{\exp\left[-\left(T_p f-1\right)^2/2\sigma^2\right]}$$

수학식 3

[0047] $$\beta_j = \frac{0.06238(1.094 - 0.01915\ln\gamma)}{0.230 + 0.036\gamma - 0.185(1.9+\gamma)^{-1}}$$

수학식 4

[0048] $$T_p = \frac{\bar{T}}{1 - 0.532(\gamma+2.5)^{-0.569}}$$

[0049] 여기서, H_s는 파도 높이를, T_p는 파도 주기를 나타내고, 다른 변수들은 JONSWAP 스펙트럼의 변수와 동일하

다.

[0050] 가장 일반적으로 사용되는 각도 분포 함수는 단측 각도 분포 함수로 수학식 5 내지 수학식 7에 기반하여 다시 계산할 수 있다.

수학식 5

[0051] $$D(\varphi,s)=I(s)\cos^{2s}\left[0.5(\varphi-\varphi_{wave})\right] \quad -\pi\le\varphi\le\pi$$

수학식 6

[0052] $$I(s)=i\frac{\sqrt{\pi}\Gamma(s+1)}{2\pi\Gamma(s+0.5)}$$

수학식 7

[0053] $$s=\begin{cases}s_{\max}(f/f_p)^{\mu_a} & f<f_p\\ s_{\max}(f/f_p)^{\mu_b} & f>f_p\end{cases}$$

[0054] 여기서, φ는 파도의 방향을, φ_{wave}는 평균 파도의 방향을, s는 확산 함수를 나타내는데, 파도 방향의 평균값 근처의 파도의 전파를 제어하는 실제 값을 의미한다.

[0055] $\Gamma()$는 감마 함수를, μ_a와 μ_b 및 $S_{\max}$는 파도의 특성과 관련한 대비 값을 나타낸다.

[0057] 도 2를 참고하면, DSM을 기반으로 중력파에 장력파를 별도로 생성하고 중첩시키는 방법을 제안할 수 있다.

[0058] 한편, 표면장력파(capillary wave)의 발생은 직접적으로 풍속에 의존하기 때문에 표면장력파를 발생시키는 미풍이 멈추면 표면장력파의 진폭은 즉시 사라질 수 있다.

[0059] 여기서, 표면장력파란 표면장력의 영향이 중력의 영향보다 커 유체의 자유표면위에 생기는 파동을 의미한다.

[0060] 중력파는 파도 높이, 파도 주기 및 파도 방향에 의해 결정되며, 실제 파동 매개변수를 사용하여 시뮬레이션할 수 있다.

[0061] 선형 중첩 방법은 중력파에 소규모 장력파를 중첩하는 데 활용될 수 있다.

[0063] 본 발명의 일 실시예로, 수학식 8에 기반하여 실제 해수면의 높이를 계산할 수 있다.

수학식 8

$$\xi(x,y,t)=\sum_{i=1}^{M}\sum_{j=1}^{N}\sqrt{2S(\omega_i,\varphi_j)\Delta\omega_i\Delta\varphi_j}\times \cos\left[\omega_i t-k_i x\cos\varphi_j-k_i y\sin\varphi_j+\varphi_{ij}(seed)\right]$$

[0064]

[0065] 여기서, $S(\omega_i,\varphi_j)$ 는 해양 환경 요소들에 기반한 스펙트럼을, k_i 는 파도의 숫자를, ω_i는 원형 주파수를, φ_j는 방향의 각도를, $\varphi_{ij}(seed)$ 는 초기 단계를 나타낸다.

[0066] 최종적으로 생성된 파도 높이는 수학식 9에 기반하여 계산할 수 있다.

수학식 9

$$\zeta(x,y,t)=\xi_g(\mathbf{\rho}_0,t)+\xi_c(\mathbf{\rho}_c,t)+Z_x x_g+Z_y y_g$$

[0067]

[0068] 여기서, $\xi_g(\mathbf{\rho}_0,t)$ 는 중력파의 높이를, $\xi_c(\mathbf{\rho}_c,t)$ 는 장력파동의 높이를, $\mathbf{\rho}_c(x_c,y_c)$는 장력파의 위치 벡터를, $\mathbf{\rho_0}(x_0,y_0)$ 는 중력파의 중심 좌표를 나타낸다.

[0070] **실제 해양 환경 조건에서 시계열의 SEA CLUTTER의 모델링**

[0071] 단계 S2040에서는, 단계 S2010 부터 단계 S2030까지 각 단계를 순차적으로 반복하여 해양 클러터의 시계열을 구성할 수 있다.

[0072] 중력파와 장력파를 기반으로 한 해양 클러터의 복합 모델링 방법을 제안하여 실제 해양 환경에서의 해양 클러터(sea clutter) 시계열을 구축할 수 있다.

[0073] **A. 중력파로부터 EM 산란장(Electromagnetic scattering field)의 계산**

[0074] 실제 해양의 파도는 DSM을 사용하여 파도 매개변수를 기반으로 하는 중력파와 바람의 속도와 방향을 기반으로 하는 장력 파동(tension ripples)이라는 두 부분으로 모델링할 수 있다.

[0075] 도 4를 참고하면, 입사각이 20도 미만인 경우 해수면의 전자파 산란 메커니즘은 주로 큰 규모의 파도에 의해 영향을 받을 수 있고, 해수면은 접선 평면으로 근사화될 수 있으며, 이와 같은 경우 산란장은 수학식 10 내지 수학식 11에 기반하여 계산할 수 있다.

수학식 10

$$\mathbf{E}_{pq}^{KAS}(\mathbf{k}_i,\mathbf{k}_s)=ik\frac{e^{ikR_0}}{4\pi R_0}U_{pq}I(\cdot)$$

[0076]

[0077] 적분 인자인 $I(\cdot)$는 수학식 11과 같이 확장될 수 있다.

수학식 11

$$I(\cdot)=\int_{S_k} e^{-i\mathbf{q}\cdot\mathbf{r}_0}\,dS = e^{-i(q_x x_0+q_y y_0+q_z z_0)}\cdot \operatorname{sinc}(0.5X_1\Delta x_g)\operatorname{sinc}(0.5X_2\Delta y_g)\Delta x_g\Delta y_g$$

[0078]

[0079] 여기서, U_{pq}는 서로 다른 편광에서의 편향 인자를 나타내고, $X_1=q_x+q_zZ_x$, $X_2=q_y+q_zZ_y$ 및 $\mathbf{q}=k\cdot(\hat{\mathbf{k}}_s-\hat{\mathbf{k}}_i)$는 q_x, q_y, q_z의 값에 의해 결정되며, $k=2\pi/\lambda$는 입사파의 숫자를 나타낸다.

[0081] **B. 소규모의 장력 파동(Tension Ripples)에서의 EM 산란 모델링**

[0082] 도 5를 참고하면, 입사각이 증가함에 따라 전자파(EM) 산란의 산란 메커니즘이 주로 표면장력파(capillary wave)에 의한 브래그 산란(Bragg scattering)으로 나타난다.

[0083] 수학식 12에 기반하여, 소규모 장력파에 해당하는 전자파 산란장을 SPM으로 계산할 수 있다.

수학식 12

$$\mathbf{E}_{pq}^{SPMS}(\mathbf{k}_s,\mathbf{k}_i)=2\pi\frac{e^{ikR_0}}{iR_0}\mathbf{S}_{pq_loc}(\mathbf{k}_s,\mathbf{k}_i)\mathbf{E}_0$$

[0084]

[0085] 여기서, R_0는 레이더으로부터 해수면까지의 거리를 나타낸다.

[0086] 수학식 13에 기반하여, 로컬 좌표계의 진폭 행렬을 계산할 수 있다.

수학식 13

$$\mathbf{S}_{pq_loc}(\mathbf{k}_i,\mathbf{k}_s)=\frac{k^2(1-\varepsilon)}{8\pi^2}\mathbf{F}_{pq_lov}I(\cdot)$$
$$=\frac{k^2(1-\varepsilon)}{8\pi^2}\mathbf{F}_{pq_lov}\iint\zeta(x,y,t)e^{-i\mathbf{q}\cdot\mathbf{r}}d\boldsymbol{\rho}$$

[0087]

[0088] 여기서, $\mathbf{F}_{pq_loc}$는 로컬 좌표계의 편광 인자(polarization factor)를 나타낸다.

[0089] 한편, 편광은 전자기파가 진행할 때 파를 구성하는 전기장이나 자기장이 특정한 방향으로 진동하는 현상을 가리킨다.

[0090] 여기서, $\zeta(x,y,t)$ 은 수학식 9에 기반하여 해수면의 미세한 기하학적 구조를 나타낸다.

[0091] 레이더가 해수면과 상호 작용할 때, 공명 조건을 만족하는 표면장력파 구성이 주로 산란장에 영향을 미칠 수 있고, 이는 수학식 14에 기반하여 단일 파장을 가진 코사인파로 단순화하여 계산할 수 있다.

수학식 14

[0092] $$\xi_c(\boldsymbol{\rho}_c,t) = B(\mathbf{k}_c)\cos(\mathbf{k}_c \cdot \boldsymbol{\rho}_c + \omega_c t + \varphi_{wave})$$

[0093] 여기서, $\mathbf{k}_c$ 는 파수(wave number) 벡터를, $B(\mathbf{k}_c)$ 는 Bragg 공진 표면장력파의 진폭을, φ_{wave}는 바람의 방향을 나타낸다.

[0094] 한편, 파수란 단위 길이 안에 파동이 몇 라디안을 진행하는지 나타내는 값이다.

[0095] 도 5를 참고하면, 국제 좌표계에서 표면장력파 단면의 상대적인 위치 벡터를 나타낸다.

[0096] 수학식 14와 수학식 9를 수학식 13으로 대체하면, 적분 인자 $I(\cdot)$ 는 수학식 15 내지 수학식 16으로 나타낼 수 있다.

수학식 15

[0097] $$I(\cdot) = \frac{B(\mathbf{k}_c)\Delta S}{2n_z} e^{-i\mathbf{q}\cdot\mathbf{r}_0} \sum_{n=-\infty}^{\infty} (-i)^n J_n[q_z B(\mathbf{k}_c)] I_0(\mathbf{k}_c)$$

수학식 16

[0098] $$I_0(\mathbf{k}_c) = e^{-i(1+n)\omega_c t}\,\mathrm{sinc}(0.5\Delta x_g X_3)\cdot\mathrm{sinc}(0.5\Delta y_g X_4) + e^{i(1-n)\omega_c t}\,\mathrm{sinc}(0.5\Delta x_g X_5)\cdot\mathrm{sinc}(0.5\Delta y_g X_6)$$

[0099] 여기서, 는 Δs 표면적을 나타낸다.

[0101] **C. 실제 해양 환경에서의 해양 클러터 모델링**

[0102] 서로 다른 산란 메커니즘은 해수면에서의 각 산란 유닛에 의해 계산될 수 있다.

[0103] 수학식 17에 기반하여 복합 전자기파 산란장의 총합을 계산할 수 있다.

수학식 17

[0104] $$\mathbf{E}_{pq}^{scatt}(\mathbf{k}_i,\mathbf{k}_s,t)=\sum_{m=1}^{M}\sum_{n=1}^{N}\left[\mathbf{E}_{pq}^{KAS}(\mathbf{k}_i,\mathbf{k}_s)+\mathbf{E}_{pq}^{SPMS}(\mathbf{k}_i,\mathbf{k}_s)\right]$$

[0105] 도 6은 실제 해양 환경의 요인을 고려하여 시계열로 모델링한 해양 클러터의 개략도를 나타낸다.

[0106] 상기 해양 클러터의 개략도이 구체적인 단계는 다음과 같을 수 있다.

[0107] (a) 서로 다른 해역에서 시간에 따른 해양 환경에 대한 데이터베이스를 구축할 수 있다. 상기 해양 환경 정보에는 바람의 속도 및 방향, 파도의 높이, 방향 및 주기를 포함할 수 있다.

[0108] (b) 상기 데이터베이스로부터 지리 정보 시스템 및 원격 감지 응용프로그램에 사용되는 데이터 세트인 디지털 표면 모델(Digital Surface Model, DSM)을 생성할 수 있다.

[0109] (c) 상기 디지털 표면 모델을 활용하여 파도와 관련한 매개변수를 기반으로 하는 중력파와 바람과 관련한 매개변수를 기반으로 하는 장력파(tension ripples)로부터 EM 산란장(Electromagnetic scattering field)을 각 계산할 수 있다

[0110] (d) 해양 클러터의 시계열을 구성하기 위해서 상기 모델링 과정을 반복하여 수행할 수 있다.

[0111] (e) 상기 해양 클러터의 시계열에 기반하여 정규화된 레이더 단면적(Normalized radar cross section, NRCS)과 도플러 특성을 계산할 수 있다.

[0112] (f) LSTM를 활용하여 누락된 시계열 해양 환경 요소를 예측할 수 있다.

[0113] (g) DNN을 활용하여 해양 클러터 및 인버전의 특성을 예측할 수 있다.

[0115] **실제 해양 클러터 특징인 NRCS와 도플러 특성 예측**

[0116] 단계 S2050에서는, 구성된 상기 해양 클러터의 시계열에 기반하여 해양 클러터 에코 진폭 특성인 정규화된 레이더 단면적(Normalized radar cross section, NRCS)과 도플러 특성을 계산할 수 있다.

[0117] 해양 환경 요소와 전자파 산란 특성의 상관관계는 각기 다른 해양 표면 환경에서 시뮬레이션 된 해양 클러터 데이터 세트와 이에 대응하는 레이더 매개변수에 기초하여 분석할 수 있다.

[0118] 해양 클러터 특성에는 주로 해양 클러터 에코 진폭 특성, 즉 정규화된 레이더 단면적(NRCS)과 도플러 특성이 포함될 수 있다.

[0119] **A. LSTM에 기반한 해양 환경 예측**

[0120] 단계 S2010에서의 누락된 값을 보완하기 위해 장단기기억(Long Short-Term Memory, LSTM) 신경망 모델을 활용할 수 있다.

[0121] 도 7을 참고하면, 해역별 해양환경 요소에 대한 LTSM 네트워크의 예측 과정나타낸다.

[0122] 도 7을 참고하면, LSTM은 3층 구조를 포함할 수 있는데, ①로 표시된 영역은 뉴런 세포 상태 전달의 주요 채널이고, ②로 표시된 영역은 망각층으로, 뉴런 상태에서 어떤 정보가 폐기되는지 결정할 수 있으며, ③로 표시된 모듈의 작업 프로세스는 새로운 정보를 기억하게 될 뉴런의 상태를 업데이트할 수 있다.

[0123] 시계열 데이터는 특정 시점의 값이 다른 시점의 값과 특정한 방식으로의 연관을 가질 수 있고, 각 값이 서로 완전히 독립적이지 않을 수 있다.

[0124] 특히, 통계적 시계열 분석에서는 어떤 확률 과정(Stochastic process)을 따르는 시계열이 있다고 가정하고 그 통계적 과정으로 부터 나타난 표본(Sample)을 통해 그 통계적 과정을 알아낼 수 있으나, 통계적 과정을 정확하게 알아내는 것은 매우 어렵기 때문에 강한 가정(assumption) 중에 하나인 정상성의 개념을 활용할 수 있다.

[0125] 본 발명의 일 실시예로, 시계열 예측에서 시계열의 고정 값을 반드시 설정해야하므로 시계열을 예측하기 전에

정상성을 확인하고 차분(differencing), 정규화, 역평균화 등의 방법을 통해 불안정한 데이터를 안정적인 계열 데이터로 변환할 수 있다.

[0126] 다양한 해역의 기상 데이터 시계열은 6시간의 샘플링 간격으로 풍속, 파도 높이, 파도 주기 및 파도 방향을 포함할 수 있다.

[0127] **B. 심층 신경망(DNN)에 기반한 해양 클러터 특징 및 매개 변수 인버전(inversion) 예측**

[0128] 단계 S2060에서는, 심층 신경망(Deep Neural Network, DNN)을 이용하여 실제 바다의 해양 클러터 및 인버전의 특성을 예측할 수 있다.

[0129] 도 8을 참조하면, 입력층, 신경망층, 출력층을 포함한 심층 신경망(DNN)을 이용하여 해양 클러터 특징을 예측할 수 있다.

[0130] 해양 클러터의 분석에 기초하면, 풍속, 파도 높이, 파도 주기, 레이더 변수가 가장 영향을 미치는 중요한 변수이다.

[0131] 이들 매개변수는 입력 값으로, 해양 클러터 특징 데이터는 출력 값으로 활용될 수 있다.

[0132] 심층 신경망(DNN)은 데이터 세트의 다차원 특징 매핑 관계를 연구하고 해양 클러터 특징 데이터를 예측하는 데 활용될 수 있다.

[0133] 딥러닝 네트워크는 기본적으로 Adam 최적화 프로그램을 채택할 수 있다.

[0134] 해양 환경 매개변수의 인버전을 실현시키기 위해 심층 신경망(DNN)을 활용하는 것은 입력층과 출력층을 교환하는 것만으로도 가능할 수 있고, 예상되는 유효 파동 높이는 심층 네트워크 학습을 활용하여 해양 클러터 특징 데이터를 변환하여 확보할 수 있다.

[0135] 해수면의 전자파 산란 특성의 예측 및 인버전은 회귀 분석을 활용할 수 있는데, 여기서 회귀 분석은 독립 변인이 종속 변인에 영향을 미치는지 알아보기 위한 하나의 방법일 수 있고, 손실함수로는 평균 제곱근 오차(Root Mean Squared Error, RMSE)를 활용할 수 있으며, 이는 수학식 18에 기반하여 계산할 수 있다.

수학식 18

[0136] $$loss = \frac{1}{N}\sum_{i=1}^{N}\left[pred(i) - y(i)\right]^2$$

[0137] 여기서, pred(i)는 인버전 또는 예측으로 얻은 결과 값을, y(i)는 테스트 세트에서 샘플 데이터 값에 대응하는 값을 나타낸다.

[0139] **시뮬레이션 결과**

[0140] 해양 환경의 정상성을 먼저 탐지하고, LSTM 모델을 활용하여 누락된 값을 보완할 시계열 해양 환경 요소를 예측할 수 있다.

[0141] 해수면 복합 전자기(EM) 산란 알고리즘을 사용하여 해역별 해양 클러터 시계열을 구축할 수 있다.

[0142] 심층 신경망(DNN)은 해양 환경 요소의 해양 클러터 및 인버전의 특성을 예측하는데 사용할 수 있다.

[0143] **A. 시계열 해양 환경 요인 데이터의 예측**

[0144] 도 9는 2017년 남중국해 풍속 및 파도 높이 데이터의 이동 평균(rolling mean) 및 표준 편차를 나타낸다.

[0145] 시간 샘플링은 하루 4회, 6시간마다 1460개의 샘플링 포인트로 수행될 수 있고, 롤링 윈도우는 480(3개월)이다.

[0146] 도 9를 참고하면, 풍속과 파동 높이 데이터의 표준편차는 각 2.1723과 0.5266임 확인할 수 있고, 다양한 해역의 해양 환경 요소의 변동 특성은 모두 일정 범위 내에 있다.

[0147] 도 10을 참고하면, 1월 황해의 풍속을 학습 세트로 하여 데이터 세트의 크기가 각 20, 40, 60일 때 서로 다른 시뮬레이션 실험에서 학습 세트와 테스트 세트의 RMSE를 계산할 수 있다.

[0148] 도 10을 참고하면, 데이터 크기는 테스트 정확도에 큰 영향을 미칠 수 있는데, 데이터 크기가 40이면 결과가 비교적 안정적이다.

[0149] 10일 이내의 기상 데이터에 해당하는 학습 데이터 세트는 합리적이고 실제 상황과 일치한다.

[0150] 데이터 크기가 80(20일)인 경우 테스트 세트의 오차 정확도는 3.75에 달하는데 여기서

[0151] 10일 이상 경과한 풍속 데이터는 시간과의 상관관계에서 약해지고 시계열 예측 정확도가 떨어질 수 있다.

[0152] 도 11을 참고하면, 데이터 크기 40(10일)의 학습 데이터를 제공한 경우에 12개 세트의 풍속 및 파도 높이 데이터에 대한 역방향 예측을 나타낸다.

[0153] 원본 데이터는 2017년 1월 8일 18시부터 2017년 1월 11일 18시까지의 황해에 해당한다.

[0154] 도 11을 참고하면, 예측 풍속과 파도 높이는 모두 원본 데이터와 유사한 경향을 가지며, RMSE는 각각 1.507과 0.328을 나타낸다.

[0155] 도 11을 참고하면, 예측 데이터와 테스트 데이터 사이에는 이동 현상(translation phenomenon)이 있으므로, 데이터 트렌드가 더 분명히 드러나는 상황에서 적합할 수 있다.

[0157] **B. 심층 신경망(DNN)에 기초한 해양 클러터 특징 예측 및 매개변수 인버전의 실현값(realization)**

[0158] 도 12를 참고하면, 황해의 실제 해양 환경 요소에 따른 해양 클러터 시계열의 계산 결과를 나타낸다.

[0159] 시각은 2017년 1월 1일 0시, 풍속 4.17m/s, 풍향 65.81, 파고 4.17m/s, 파향 41.05, 파주기 3.26s 입니다. 레이더 주파수는 3.0GHz이고 입사각은 80° 이다.

[0160] 도 12를 참고하면, 두 편파에 대한 산란 진폭은 10^{-11} ~ 10^{-10} 범위에 있는데, HH 편파 진폭의 변동은 분명하게 VV 편광의 변동보다 더 강하다.

[0161] 한편, 낮은 해상 상태에서는 VV 편파 진폭은 HH 편파보다 훨씬 클 수 있는데, 이는 실제 해상의 조건에서와 일치한다.

[0162] 도 13을 참고하면, 평균 진폭의 계산 결과와 측정 결과를 비교한 것을 나타낸다.

[0163] 데이터는 북대서양의 미국 해군 연구소(U.S. Naval Research Laboratory) 4밴드 레이더의 측정 데이터에서 나온 것으로 레이더 주파수는 8.91GHz이다.

[0164] 도 13을 참고하면, 본 발명의 계산 결과가 측정된 데이터와 잘 일치함을 확인할 수 있다.

[0165] 서로 다른 해양 요소와 해양 클러터 특성 데이터 사이에는 관계가 있는데 해양 클러터 특성의 예측 및 매개변수 인버전을 구현하기 위해 DNN을 이용할 수 있고, Adam 경사하강법과 결합된 ECMWF 기상 데이터는 풍속과 파도 높이 사이의 비선형 관계를 분석하는 데 활용될 수 있다.

[0166] 본 발명에서는 실제 해양 환경 요소에 대한 복합 전자기 산란 알고리즘을 통해 해양 클러터 데이터 세트를 계산할 수 있다.

수학식 19

[0167] $$accuracy = 1 - \left| \left[pred(i) - y(i) \right] / y(i) \right|$$

[0168] 바람에 의한 파도의 영향력하에서는 풍속과 파도 매개 변수 사이의 높은 상관 관계가 있다.

[0169] 2017년 황해해역 데이터 1,196개를 선정하였고, 이는 전체 데이터세트의 81.92%를 차지할 수 있는데, 처음 1000개의 데이터 그룹을 학습 세트로 사용하고 마지막 196개 그룹을 테스트 세트로 사용할 수 있다.

[0170] 도 14를 참고하면, 각 네트워크 가중치 업데이트 중 RMSE 및 정확도의 변화를 나타낸다.

[0171] 심층 신경망(DNN) 모델의 배치 크기(batch size)는 4일 수 있고, 반복 횟수가 증가함에 따라 손실 함수와 정확도는 점차 안정적인 수준에 도달할 수 있다.

[0172] 심층 신경망(DNN)의 적응적 가중치에 의해 가중치 업데이트 횟수가 약 1000에 도달하면 네트워크 훈련은 기본적으로 안정적이며 nb_epoch는 4임을 확인할 수 있다.

[0173] 후속 모델 훈련 결과에는 반환된 RMSE와 정확도만 표시될 수 있다.

[0174] 도 15를 참고하면, 심층 신경망(DNN) 모델에서 숨겨진 레이어가 변경될 때의 레이어 노드에 따라 다른 RESM과 이에 상응하는 정확도를 나타낸다.

[0175] 입력 레이어는 풍속과 바람의 방향이고, 출력 레이어는 유효한 파도 높이일 수 있다.

[0176] 도 15를 참고하면, 숨겨진 레이어 노드 수가 적은 경우에 DNN 모드는 안정성을 달성하기 위해 더 많은 가중치 업데이트가 필요할 수 있고, 최종 정확도는 약 0.7에 근접할 수 있다.

[0177] 도 16을 참고하면, 유효 파도 높이와 파도 주기를 예측하기 위해 12개 노드로 구성된 단층 은닉층 신경망을 활용할 수 있다.

[0178] 도 16(a)를 참고하면, 황해에서의 풍속과 파도 주기를 입력 값으로 하여 이에 대응하는 파도 높이를 예측할 수 있는데, 풍속과 관련된 정보를 이용하여 파도의 높이를 예측하는 것이 더 정확할 수 있다.

[0179] 도 16(b)를 참고하면, 풍속과 파도의 높이를 활용하여 이에 상응하는 파도 주기를 예측할 수 있고, 최종적으로 그 정확도는 91%에 달한다.

[0180] 풍속, 파도 높이, 파도 주기는 해양 클러터의 특성에 영향을 미치는 가장 중요한 매개변수일 수 있다.

[0181] 상기 세 가지 매개변수와 해양 클러터 특징을 입력 값과 출력 값으로 각 설정하고 심층 신경망(DNN)을 활용하여 데이터 세트의 다차원 특성 매핑 관계성을 분석할 수 있다.

[0182] 도 17을 참고하면, 예측된 결과 값과 수학식 17에 기반하여 계산된 시뮬레이션 데이터와의 상관관계를 나타낸다.

[0183] 여기서, 2017년 1월 황해의 시뮬레이션된 해면 혼란 특성 데이터 세트를 활용할 수 있는데, 풍속, 파도 높이, 파동 주기에 각 대응하는 해양 클러터의 평균 진폭과 도플러 확장(Doppler broadening)을 예측할 수 있다.

[0184] 우선, 파도의 평균 진폭과 관련하여, HH 편파와 VV 편파의 결정 계수는 각 0.9249와 0.8872임을 확인할 수 있다.

[0185] 그리고, 도플러 확장(Doppler broadening)과 관련하여, HH 편파와 VV 편파의 계수는 0.8041과 0.9790에서 강한 상관관계를 나타낸다.

[0186] 도 18을 참고하면, 파도 높이 증가에 따른 평균진폭의 포화현상으로 인해 인버전이 가장 심하며 정확도는 55%에 불과하다.

[0187] 도플러 확장, 평균 진폭 및 이 두 특징량으로 구성된 시너지 데이터는 각각 파고를 반전시키는 데 활용될 수 있다.

[0188] 본 발명에서 생성된 중력파는 파도 높이와 직접적인 관련이 있다. 파도 높이가 증가해도 해수면의 변동은 무한히 증가하지 않으며 도 13과 같이 RCS가 파도 높이의 증가에 따라 포화값에 도달하게 된다.

[0189] 도 19를 참고하면, 2017년 10월 황해, 동해, 남해의 도플러 확장 및 진폭 평균 시뮬레이션 데이터를 활용하여 각각 해수면 파고를 인버젼시킨 것이다.

[0190] 동해의 파도 높이는 범위가 가장 넓고 큰 값에 집중되어 있는 반면, 남해의 파도 높이는 작은 값의 영역에 집중되어 있다.

[0191] 파도 높이 인버전 정확도는 해역마다 차이가 있는데, 남해에서 가장 낮고(정확도 78%), 동해에서 가장 높은데(정확도 90%), 이는 훈련모델은 해양 클러터 특성과 파도 높이의 상관관계를 일률적으로 고려하고, 다른 해양 환경 요소가 해양 클러터 특성에 미치는 영향은 고려하지 않기 때문이다.

부호의 설명

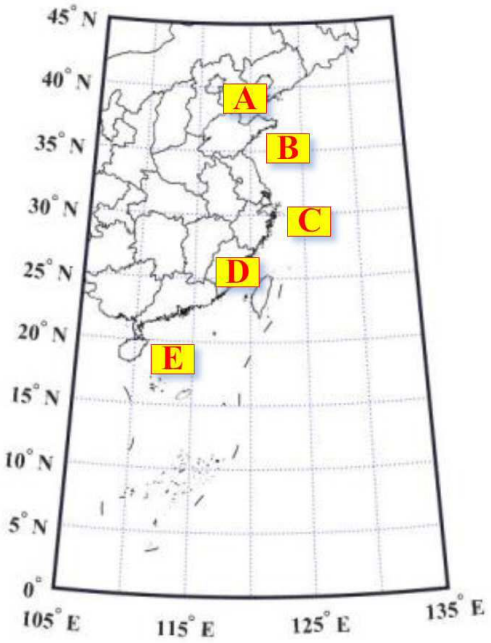
[0193] 2100 : 본 발명의 일 실시예로 딥러닝 모델을 이용한 해양 환경 특성 예측 장치

2102 : 프로세서 2104 : 메모리

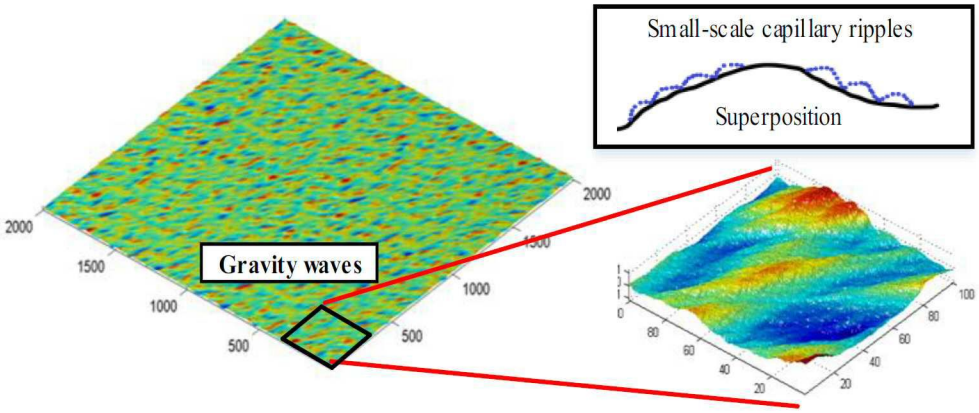
2106 : 입출력 인터페이스 2108 : 네트워크 통신 인터페이스

도면

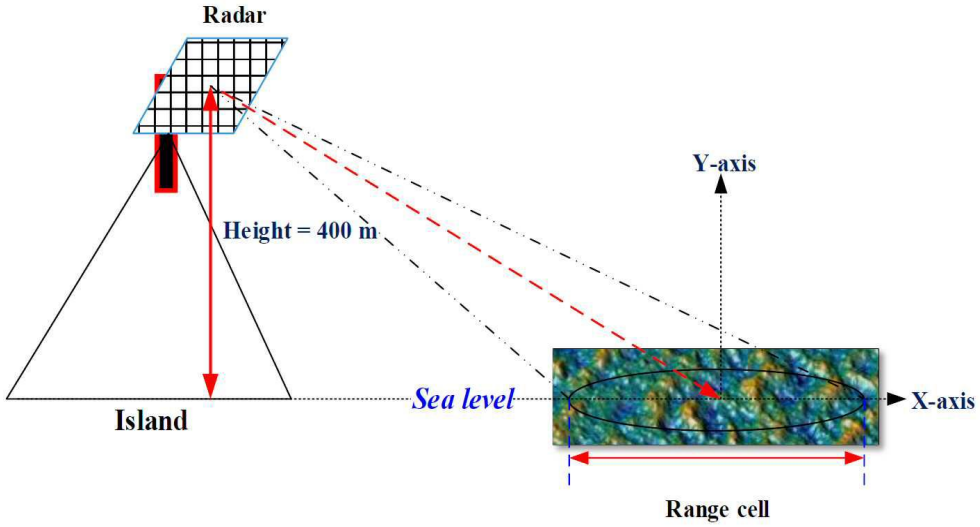
도면1



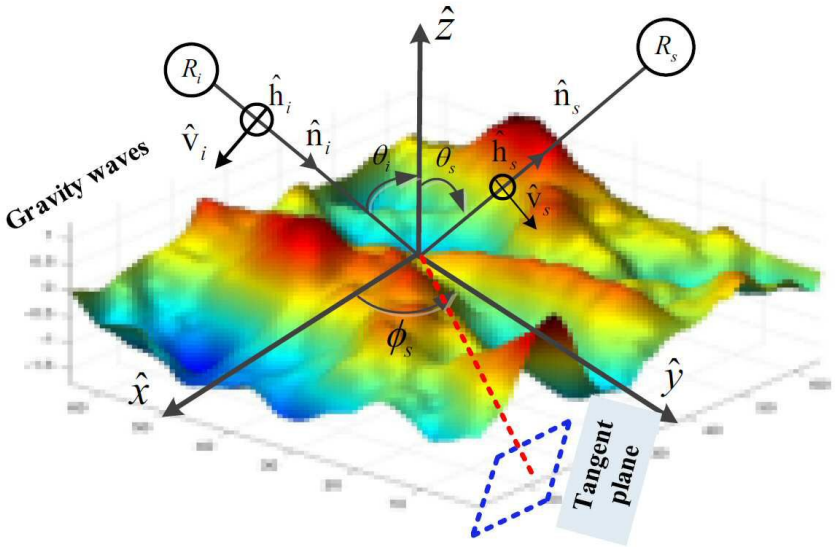
도면2



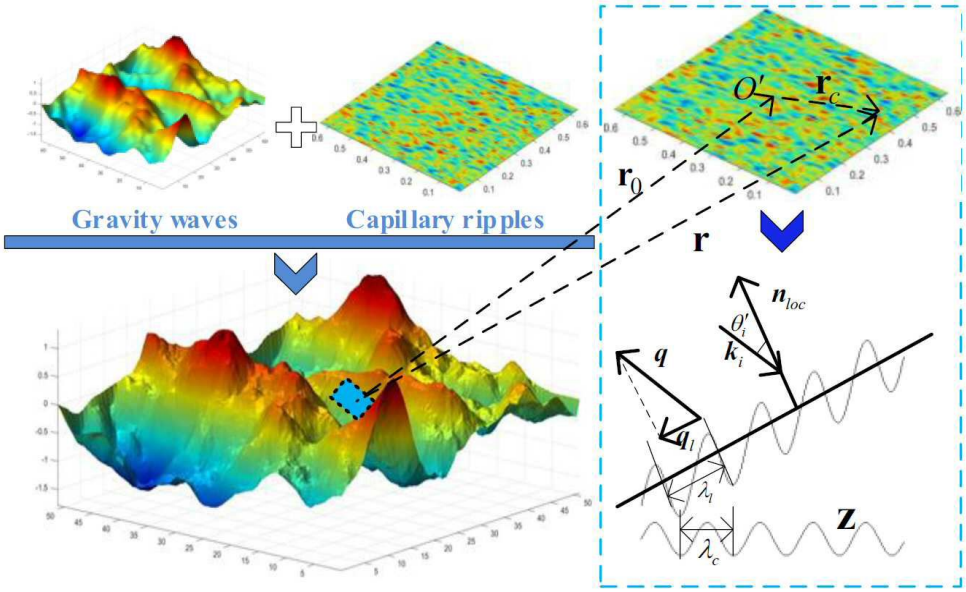
도면3


Radar
Height = 400 m
Island
Sea level
Y-axis
X-axis
Range cell

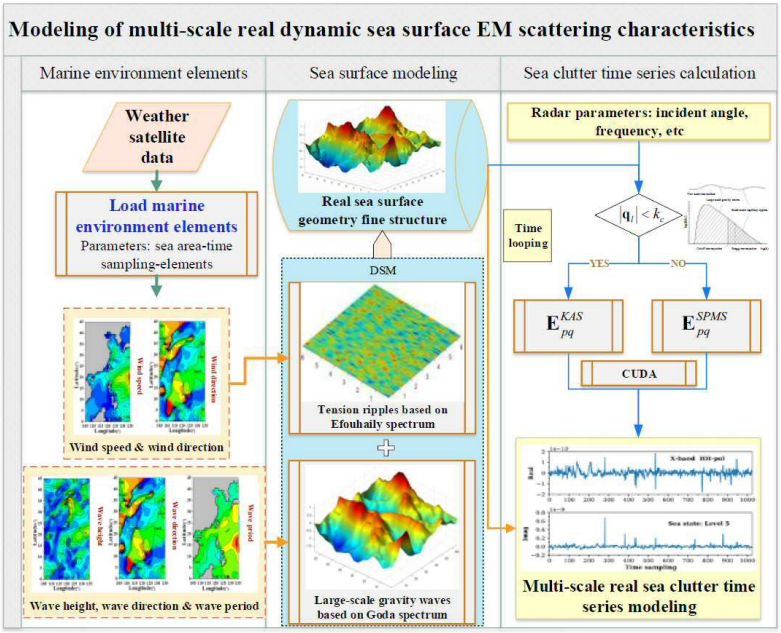
도면4


Gravity waves
Tangent plane

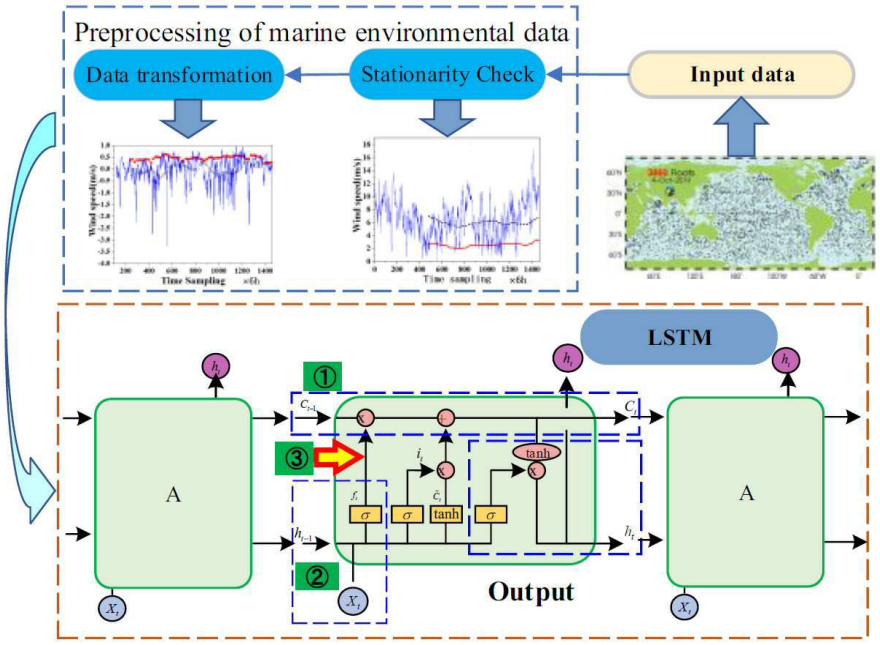
도면5


Gravity waves
Capillary ripples
O'
r_c
r_0
r
n_loc
θ_i'
k_i
q
q_l
λ_l
λ_c
z

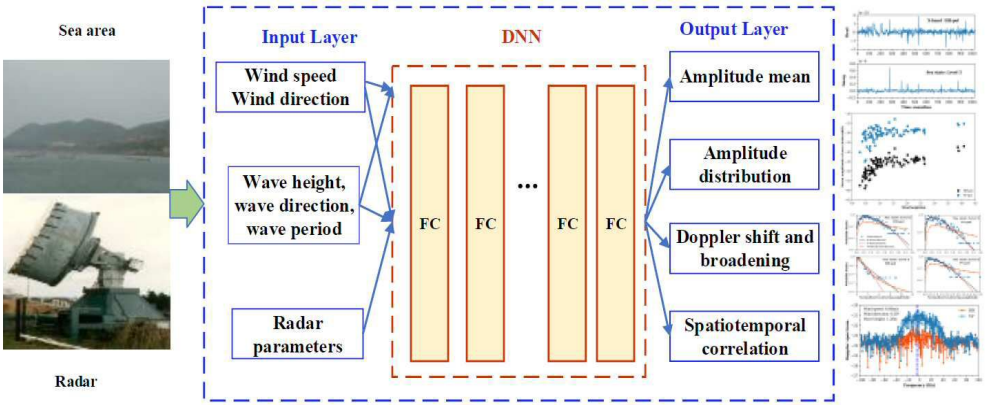
도면6


Modeling of multi-scale real dynamic sea surface EM scattering characteristics
Marine environment elements
Sea surface modeling
Sea clutter time series calculation
Weather satellite data
Load marine environment elements
Parameters: sea area-time sampling-elements
Wind speed & wind direction
Wave height, wave direction & wave period
Real sea surface geometry fine structure
DSM
Tension ripples based on Efouhaily spectrum
Large-scale gravity waves based on Goda spectrum
Radar parameters: incident angle, frequency, etc
Time looping
YES
NO
CUDA
Multi-scale real sea clutter time series modeling

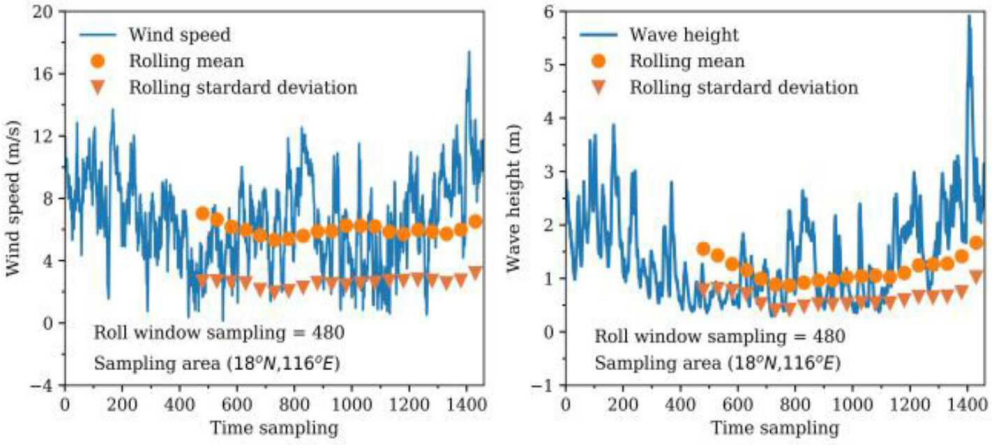
도면7


Preprocessing of marine environmental data
Data transformation
Stationarity Check
Input data
LSTM
A
A
Output

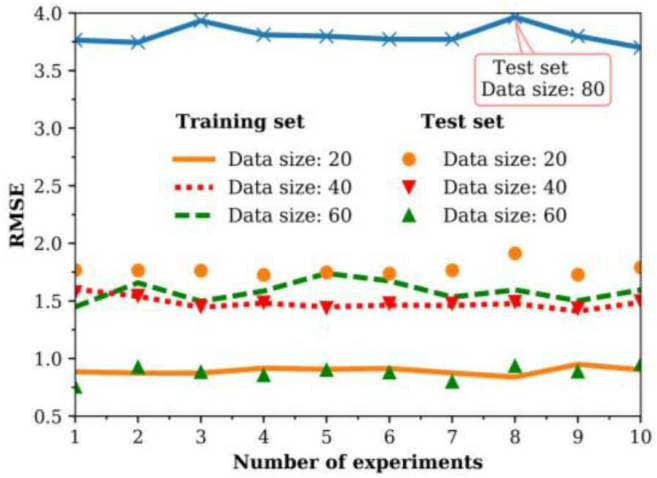
도면8


Sea area
Radar
Input Layer
DNN
Output Layer
Wind speed
Wind direction
Wave height,
wave direction,
wave period
Radar
parameters
FC
FC
FC
FC
Amplitude mean
Amplitude
distribution
Doppler shift and
broadening
Spatiotemporal
correlation

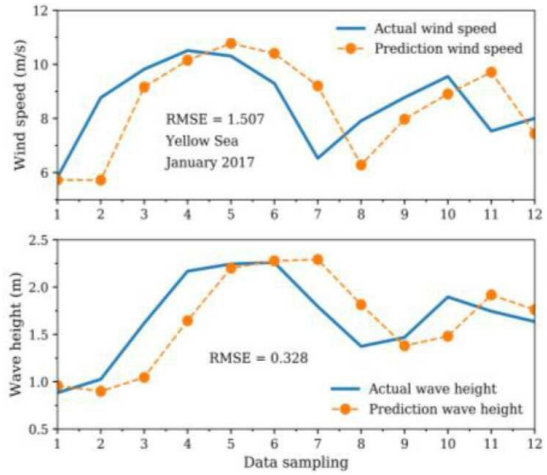
도면9


Wind speed
Rolling mean
Rolling stardard deviation
Wind speed (m/s)
Roll window sampling = 480
Sampling area (18°N,116°E)
Time sampling
Wave height
Rolling mean
Rolling stardard deviation
Wave height (m)
Roll window sampling = 480
Sampling area (18°N,116°E)
Time sampling

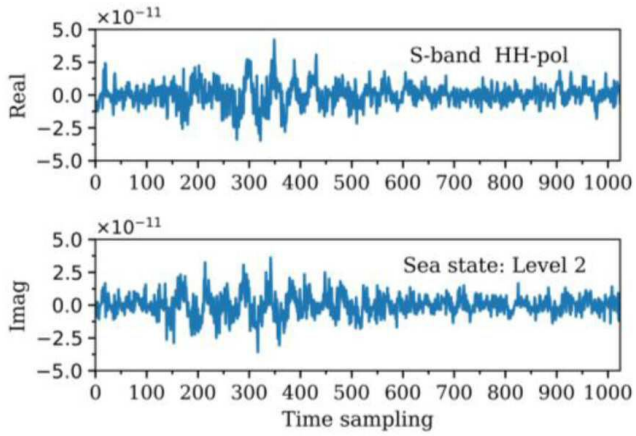
도면10



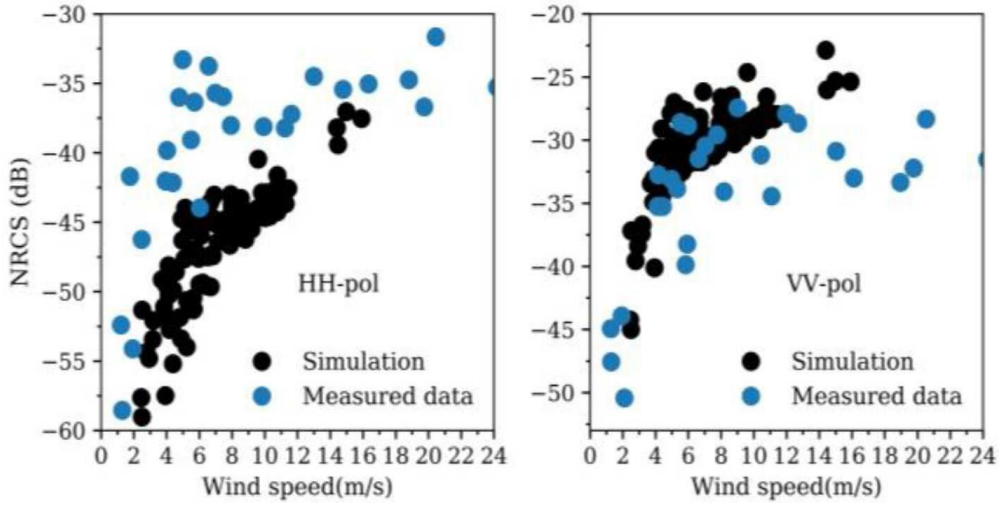
도면11



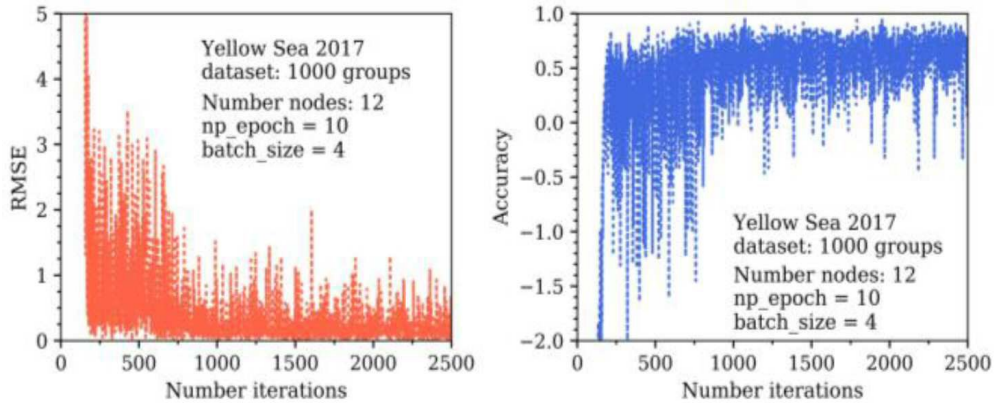
도면12



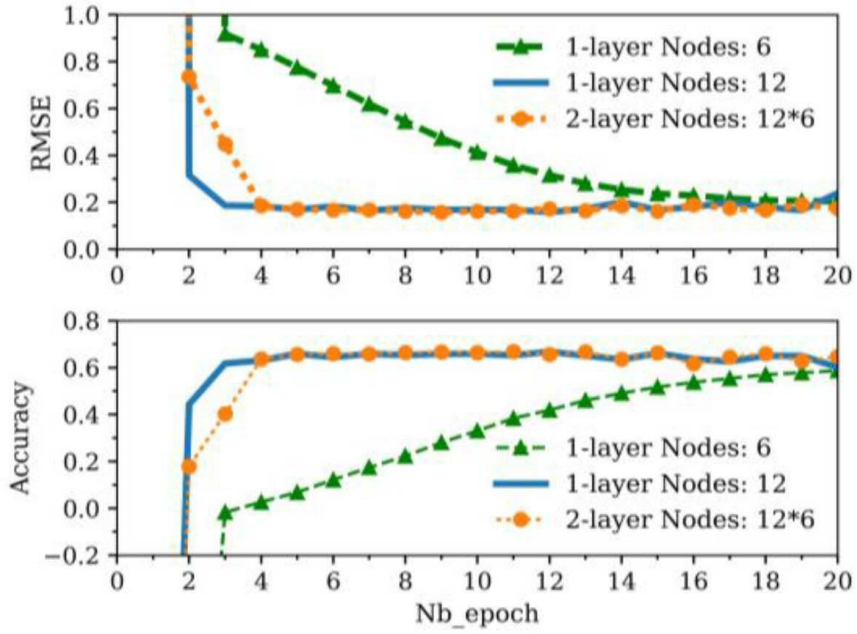
도면13



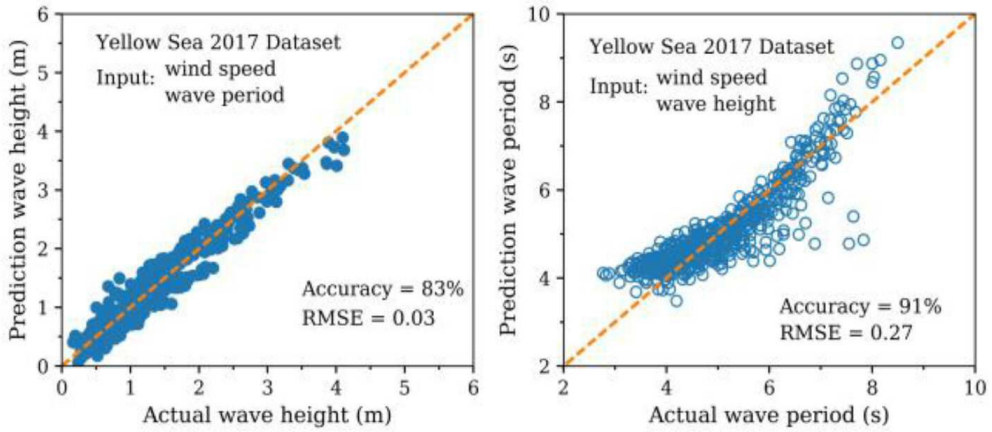
도면14



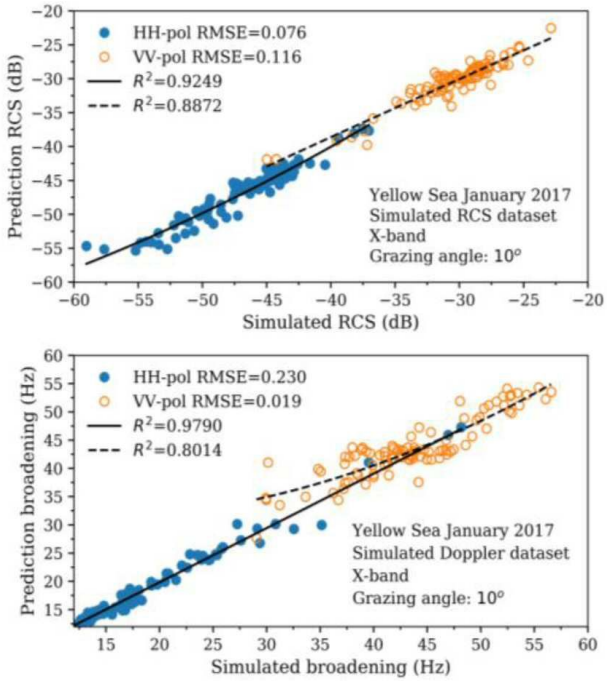
도면15



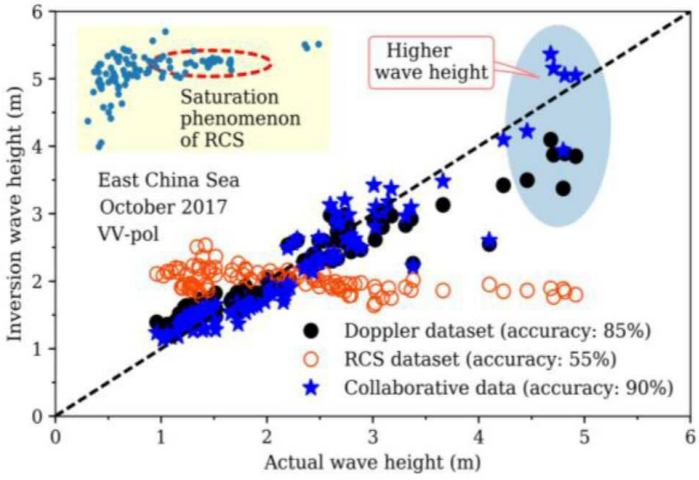
도면16



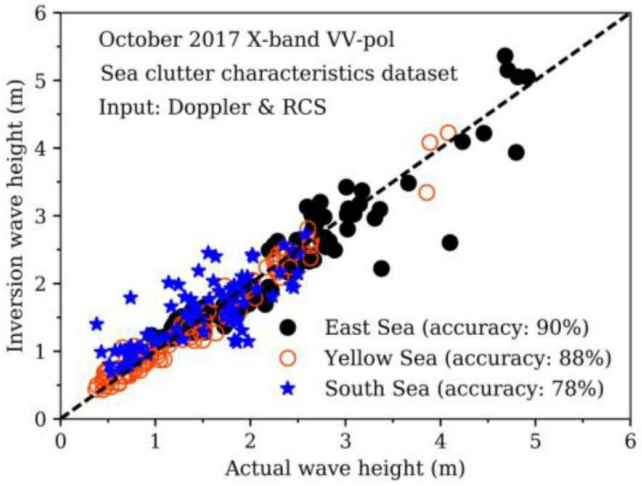
도면17



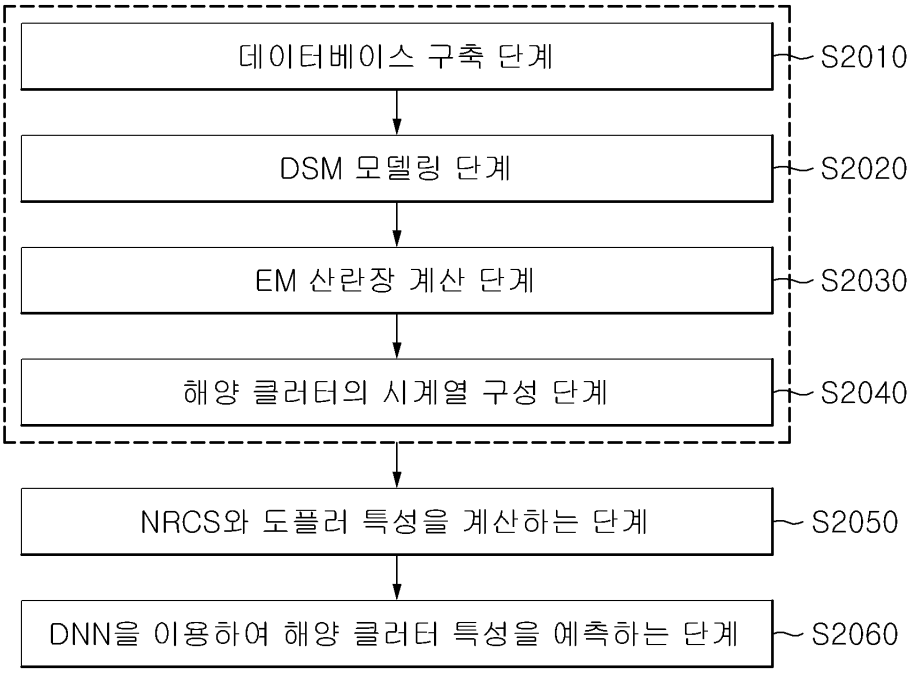
도면18



도면19


October 2017 X-band VV-pol
Sea clutter characteristics dataset
Input: Doppler & RCS
East Sea (accuracy: 90%)
Yellow Sea (accuracy: 88%)
South Sea (accuracy: 78%)
Inversion wave height (m)
Actual wave height (m)
0
1
2
3
4
5
6

도면20


데이터베이스 구축 단계
S2010
DSM 모델링 단계
S2020
EM 산란장 계산 단계
S2030
해양 클러터의 시계열 구성 단계
S2040
NRCS와 도플러 특성을 계산하는 단계
S2050
DNN을 이용하여 해양 클러터 특성을 예측하는 단계
S2060

도면21

