(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0170687
(43) 공개일자 2024년12월04일

(51) 국제특허분류(Int. Cl.)
G06N 3/096 (2023.01) *B08B 1/00* (2024.01)
B63B 59/10 (2006.01) *G06N 3/045* (2023.01)
G06N 3/0464 (2023.01) *G06N 3/047* (2023.01)
G06N 3/08 (2023.01) *G06T 3/40* (2024.01)
G06T 5/00 (2024.01)
(52) CPC특허분류
G06N 3/096 (2023.01)
B08B 1/12 (2024.01)
(21) 출원번호 10-2023-0068206
(22) 출원일자 2023년05월26일
심사청구일자 2023년05월26일

(71) 출원인
한국기술교육대학교 산학협력단
충청남도 천안시 동남구 병천면 충절로 1600 (한국기술교육대학교내)
(72) 발명자
김병철
세종특별자치시 달빛로 211 범지기마을10단지 1012-101
(74) 대리인
특허법인(유한) 대아

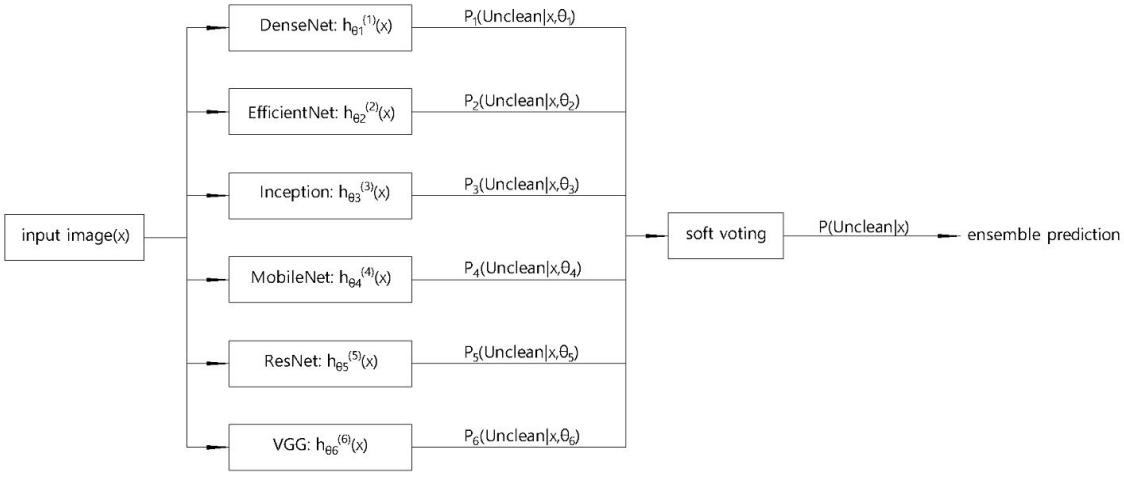
전체 청구항 수 : 총 6 항

(54) 발명의 명칭 **전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체 표면 상태 검사 시스템**

(57) 요 약

본 발명은 수중 차량의 카메라 유닛을 통해 촬영된 선체 표면 이미지로 이루어진 훈련 데이터를 이용한 전이학습을 통해 서로 다른 CNN 모델로 이루어진 복수의 분류기를 재학습하고, 분류기의 개별 결정을 병합하여 가중 확률을 합산한 후 평균을 내어 최종 예측 값을 획득하는 소프트 보팅 앙상블을 통해 카메라 유닛에 의해 촬영된 선체 표면 이미지 입력 값의 클래스 분류 정확도를 향상시키며, 입력된 이미지의 클래스 분류 결과에 따라 수중 차량의 브러쉬 유닛 또는 구동 유닛의 작동이 제어되는 전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체 표면 상태 검사 시스템에 관한 것이다.

대 표 도 - 도3



(52) CPC특허분류
B08B 1/30 (2024.01)
B63B 59/10 (2013.01)
G06N 3/045 (2023.01)
G06N 3/0464 (2023.01)
G06N 3/047 (2023.01)
G06N 3/082 (2023.01)
G06T 3/40 (2024.01)
G06T 5/92 (2024.01)
G06T 2207/20084 (2013.01)

명 세 서

청구범위

청구항 1

선체(1) 표면을 촬영하여 이미지 데이터를 획득하기 위한 카메라 유닛(11)과, 선체(1)를 청소하기 위한 브러쉬 유닛(12) 및 선체(1) 표면을 따라 이동하기 위한 구동 유닛(13)을 포함하는 수중 차량(10);

수중 환경 조건을 달리한 상태로 수중 차량(10)의 카메라 유닛(11)을 통해 촬영된 다수의 선체(1) 표면 이미지로 이루어진 훈련 데이터;

사전 학습이 완료된 서로 다른 CNN(Convolutional Neural Network) 모델로 이루어지며, 전이학습 기법을 통해 훈련 데이터를 데이터 세트(dataset)로 재학습함으로써, 카메라 유닛(11)에 의해 촬영된 선체(1) 표면 이미지 입력 값을, 선체(1) 청소가 필요한 상태인 포지티브 클래스(positive class)와, 선체(1) 청소가 불필요한 상태인 네거티브 클래스(negative class)로 레이블을 이진(binary) 분류하여 출력하기 위한 파라미터를 개선하는 다수의 분류기(classifier);

각 분류기별로 선체(1) 표면 이미지 입력 값이 포지티브 클래스 또는 네거티브 클래스 중 선택되는 어느 하나의 클래스에 속하도록 지정하기 위한 확률 값을 기반으로 가중치를 부여한 후, 각 분류기의 개별 결정을 병합하여 가중 확률을 합산하며, 평균을 내어 최종 예측 값을 획득하는 소프트 보팅 앙상블(soft voting ensemble);

전이학습 또는 선체(1) 표면 검사를 위한 데이터가 저장되는 저장부와, 전이학습이나 클래스 분류 또는 소프트 보팅 앙상블의 연산을 수행하는 연산부를 포함하는 연산 모듈;

로 구성되며,

선체(1) 표면 상태 검사 과정에서 수중 차량(10)의 카메라 유닛(11)으로부터 입력된 선체(1) 표면의 이미지를, 소프트 보팅 앙상블을 기반으로 포지티브 또는 네거티브 클래스(negative class)로 분류하여, 클래스 분류 결과에 따라 브러쉬 유닛(12) 또는 구동 유닛(13)을 작동을 실시간으로 제어하는 것을 특징으로 하는 전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체 표면 상태 검사 시스템.

청구항 2

제1항에 있어서,

훈련 데이터의 전이학습은, 사전 학습된 분류기 모델의 입력 크기를 재정의하여 입력 이미지의 픽셀 값이 0 내지 1 사이에 형성되도록 정규화하고,

전역 평균 풀링 계층(global average pooling layer)과 드롭아웃 계층(dropout layer)이 사전 학습된 분류기 모델의 컨볼루션 계층(convolution layer)으로 추가되어, 사전 학습된 분류기 모델의 클래스 분류를 위한 계층을 이진(binary) 분류를 위한 계층으로 대체하며,

$f(x)=\frac{1}{1+e^{-x}}$ (x: 마지막 선형 계층의 출력 값)

로 정의되는 활성화 함수를 통해, 하나의 노드를 가지는 완전 연결 계층(fully connected layer)이 추가되면서 이루어짐으로써, 재정의된 분류기 모델이 생성되는 것을 특징으로 하는 전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체 표면 상태 검사 시스템.

청구항 3

제2항에 있어서,

재정의된 분류기 모델의 학습은,

재정의된 분류기 모델의 계층 중 새로 추가된 계층의 가중치만이 훈련에 의해 조정되고,

훈련은 모든 데이터 세트를 미리 정해진 학습률 및 횟수 만큼 반복 학습하도록 지속되며,

모든 계층의 가중치가 새로운 학습 속도로 미리 정해진 횟수 만큼 미세 조정되어, 미세 조정 과정 중 가장 높은 검증 정확도에 해당하는 가중치가 선택되는 것을 특징으로 하는 전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체 표면 상태 검사 시스템.

청구항 4

제1항에 있어서,

훈련 데이터의 데이터 세트는,

이미지 데이터의 밝기를 임의로 조정하는 밝기 조정,

이미지의 대비를 임의로 조정하는 대비 조정,

이미지의 채도를 임의로 조정하는 채도 조정,

이미지의 특정 영역을 임의로 제거하는 자르기 조정

중 무작위로 선택되는 어느 하나 이상의 방식을 적용하는 이미지 강화를 통해, 분류기 모델 및 소프트 보팅 앙상블의 레이블 분류 정확도를 향상시키는 것을 특징으로 하는 전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체 표면 상태 검사 시스템.

청구항 5

제1항에 있어서,

소프트 보팅 앙상블을 통한 획득한 최종 예측 값이 미리 설정된 임계값을 초과하는 경우, 선체(1) 표면 이미지 입력 값을 포지티브 클래스(positive class)로 분류하는 것을 특징으로 하는 전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체 표면 상태 검사 시스템.

청구항 6

제1항에 있어서,

소프트 보팅 앙상블의 최종 예측 값을 획득하기 위한 각 분류기는,

DenseNets, EfficientNets과 Inceptions, MobileNets, ResNets, VGGs를 포함하는 CNN 모델 및 각 CNN 모델의 하위 모델로 구성되는 것을 특징으로 하는 전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체 표면 상태 검사 시스템.

발명의 설명

기 술 분 야

[0001] 본 발명은 수중의 선체 표면에 붙은 이물질을 제거하는 수중 차량의 제어를 무인화 및 자동화하기 위하여, 선체 표면 상태 검사를 기계 학습시키는 시스템에 관한 것으로, 보다 상세하게는 수중 차량의 카메라 유닛을 통해 촬영된 선체 표면 이미지로 이루어진 훈련 데이터를 이용한 전이학습을 통해 서로 다른 CNN 모델로 이루어진 복수의 분류기를 재학습하고, 분류기의 개별 결정을 병합하여 가중 확률을 합산한 후 평균을 내어 최종 예측 값을 획득하는 소프트 보팅 앙상블을 통해 카메라 유닛에 의해 촬영된 선체 표면 이미지 입력 값의 클래스 분류 정확도를 향상시키며, 입력된 이미지의 클래스 분류 결과에 따라 수중 차량의 브러쉬 유닛 또는 구동 유닛의 작동이 제어되는 전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체 표면 상태 검사 시스템에 관한 것이다.

배 경 기 술

[0002] 물 속에 잠긴 선박의 선체 하부 표면에는 이끼나 해초 또는 따개비와 같은 기타 유기체로 구성되는 생물 오염 물질이 붙어 서식하게 된다.

[0003] 생물 오염 물질은 강재로 이루어진 선체 표면을 보호하기 위한 도장막을 손상시켜 선체 표면의 부식이 발생하기 쉬워지고, 선박의 선체 표면 저항 크기를 높여 선박 운행속도 저하 발생 및 연료 소모량의 증가에 따른 운항 비

용 증가의 원인이 되며, 타국의 해역으로 이동하는 선박을 통해 외계 수생 생물이 유입되면서 해양 생태계의 교란이 발생할 수 있다.

[0004] 따라서 선박이 항구에 정박하는 동안 수중 선체 표면의 생물 오염 물질을 제거하는 청소 작업을 주기적으로 수행하게 되며, 수중 선체 표면의 청소는 잠수부의 투입을 통해 이루어지게 되는데, 잠수부 투입에 의한 수중 선체 표면의 청소 작업 시, 안전 사고 발생의 위험이 수반되며, 투입된 잠수부가 작업할 수 있는 시간이 한정되어 작업 속도의 저하 및 인건비 소요 비용이 증가하는 문제가 있다.

[0005] 이와 같은 문제를 해결하기 위하여, 대한민국 등록특허공보 제10-1505427호(2015.03.18.등록)에서는 로봇 바디를 선체 표면을 주행시키는 주행 유닛과, 로봇 바디에 연결된 청소 유닛과, 선체를 촬영하여 영상을 획득하는 비전 모듈 및 영상 정보를 기반으로 로봇의 주행 경로를 제어하는 컨트롤러로 구성되는 선체의 표면 청소 시스템을 제시하고 있으며, 상기 선체 표면 청소 시스템에서는 비전 모듈에서 획득한 영상의 명도 차이로부터 경계를 구분하는 에지추출법을 통해, 선체 표면의 수중 바닥부 경계선의 기울기 변화에 대응하여 로봇 바디의 주행 경로를 보정하도록 구성된다.

[0006] 그러나 위와 같은 선체 표면 청소 시스템은 주어진 경로를 이동하면서, 이동 경로 상에 포함된 선체 표면의 모든 영역을 청소하도록 구성되기 때문에, 생물 오염 물질에 의한 선체 오염 정도가 심하지 않은 선박의 경우 오염 발생 부위를 탐지하여 청소를 위한 이동 경로를 새로 지정해야 하는 불편함이 있었다.

[0007] 또한, 생물 오염 물질에 의한 선체 오염 발생 정도 및 오염이 발생한 선체 위치를 탐지하기 위해서는 잠수부를 별도로 투입하거나, 로봇에 장착된 비전 모듈로부터 촬영된 영상을 분석할 필요가 있는데, 인력에 의해 수중 선체 표면 상태 검사를 수행하는 경우 검사 비용의 증가 및 검사에 소요되는 시간 증가에 따른 작업 지연 발생의 원인이 되며, 특히 잠수부를 투입 시 안전 사고 발생의 위험이 수반되기 때문에, 수중 선체 표면 상태 검사를 무인화 및 자동화할 필요성이 점차 높아지고 있다.

[0008] 하지만, 기계 학습 등의 방법을 통해 무인화 및 자동화 수중 선체 표면 상태 검사 시스템을 구축하기 위해서는 다양한 수중 환경에서 촬영된 선체 표면 이미지 데이터를 필요로 하는데, 시중에 공개된 데이터 세트에는 수중 선체 표면 상태 검사를 수행하는데 필요한 데이터의 수량이 부족하며, 특히 선박의 수중 선체 표면 이미지를 획득하기 위해서는 선주의 허가를 필요로 하기 때문에, 기계 학습의 학습 정확도를 높이기 위해 필요한 충분한 분량의 훈련 데이터를 확보하기 어려운 문제가 있었다.

선행기술문헌

특허문헌

[0009] (특허문헌 0001) 대한민국 등록특허공보 제10-1505427호

발명의 내용

해결하려는 과제

[0010] 본 발명에서는 무인화 및 자동화를 이루어, 수중 선체 표면 상태 검사에 소요되는 시간 및 비용을 절감할 수 있는 수중 선체 표면 검사 시스템을 제공하는 것을 목적으로 한다.

[0011] 본 발명에서는 한정된 적은 수량의 이미지 데이터로부터 선체 표면 상태 검사 시스템 학습 효율을 높이고, 선체 표면의 청소 필요 여부를 판정하기 위한 분류 정확도를 높일 수 있는 수중 선체 표면 상태 검사 시스템을 제공하는 것을 목적으로 한다.

과제의 해결 수단

[0012] 본 발명에 따른 전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체 표면 상태 검사 시스템은, 선체 표면을 촬영하여 이미지 데이터를 획득하기 위한 카메라 유닛과, 선체를 청소하기 위한 브러쉬 유닛 및 선체 표면을 따라 이동하기 위한 구동 유닛을 포함하는 수중 차량; 수중 환경 조건을 달리한 상태로 수중 차량의 카메라 유닛을 통해 촬영된 다수의 선체 표면 이미지로 이루어진 훈련 데이터; 사전 학습이 완료된 서로 다른 CNN(Convolutional Neural Network) 모델로 이루어지며, 전이학습 기법을 통해 훈련 데이터를 데이터 세트(dataset)로 재학습함으로써, 카메라 유닛에 의해 촬영된 선체 표면 이미지 입력 값을, 선체 청소가 필요한 상

태인 포지티브 클래스(positive class)와, 선체 청소가 불필요한 상태인 네거티브 클래스(negative class)로 레이블을 이진(binary) 분류하여 출력하기 위한 파라미터를 개선하는 다수의 분류기(classifier); 각 분류기별로 선체 표면 이미지 입력 값이 포지티브 클래스 또는 네거티브 클래스 중 선택되는 어느 하나의 클래스에 속하도록 지정하기 위한 확률 값을 기반으로 가중치를 부여한 후, 각 분류기의 개별 결정을 병합하여 가중 확률을 합산하며, 평균을 내어 최종 예측 값을 획득하는 소프트 보팅 앙상블(soft voting ensemble); 전이학습 또는 선체 표면 검사를 위한 데이터가 저장되는 저장부와, 전이학습이나 클래스 분류 또는 소프트 보팅 앙상블의 연산을 수행하는 연산부를 포함하는 연산 모듈;로 구성되며, 선체 표면 상태 검사 과정에서 수중 차량의 카메라 유닛으로부터 입력된 선체 표면의 이미지를, 소프트 보팅 앙상블을 기반으로 포지티브 또는 네거티브 클래스(negative class)로 분류하여, 클래스 분류 결과에 따라 브러쉬 유닛 또는 구동 유닛을 작동을 실시간으로 제어한다.

[0013] 본 발명의 실시 예에 따르면 훈련 데이터의 전이학습은, 사전 학습된 분류기 모델의 입력 크기를 재정의하여 입력 이미지의 픽셀 값이 0 내지 1 사이에 형성되도록 정규화하고, 전역 평균 풀링 계층(global average pooling layer)과 드롭아웃 계층(dropout layer)이 사전 학습된 분류기 모델의 컨볼루션 계층(convolution layer)으로 추가되어, 사전 학습된 분류기 모델의 클래스 분류를 위한 계층을 이진(binary) 분류를 위한 계층으로 대체하며, $f(x)=\frac{1}{1+e^{-x}}$ (x: 마지막 선형 계층의 출력 값)로 정의되는 활성화 함수를 통해, 하나의 노드를 가지는 완전 연결 계층(fully connected layer)이 추가되면서 이루어짐으로써, 재정의된 분류기 모델이 생성된다.

[0014] 본 발명의 실시 예에 따르면 재정의된 분류기 모델의 학습은, 재정의된 분류기 모델의 계층 중 새로 추가된 계층의 가중치만이 훈련에 의해 조정되고, 훈련은 모든 데이터 세트를 미리 정해진 학습률 및 횟수 만큼 반복 학습하도록 지속되며, 모든 계층의 가중치가 새로운 학습 속도로 미리 정해진 횟수 만큼 미세 조정되어, 미세 조정 과정 중 가장 높은 검증 정확도에 해당하는 가중치가 선택된다.

[0015] 본 발명의 실시 예에 따르면 훈련 데이터의 데이터 세트는, 이미지 데이터의 밝기를 임의로 조정하는 밝기 조정, 이미지의 대비를 임의로 조정하는 대비 조정, 이미지의 채도를 임의로 조정하는 채도 조정, 이미지의 특정 영역을 임의로 제거하는 자르기 조정 중 무작위로 선택되는 어느 하나 이상의 방식을 적용하는 이미지 강화를 통해, 분류기 모델 및 소프트 보팅 앙상블의 레이블 분류 정확도를 향상시킨다.

[0016] 본 발명의 실시 예에 따르면 소프트 보팅 앙상블을 통한 획득한 최종 예측 값이 미리 설정된 임계값을 초과하는 경우, 선체 표면 이미지 입력 값을 포지티브 클래스(positive class)로 분류한다.

[0017] 본 발명의 실시 예에 따르면 소프트 보팅 앙상블의 최종 예측 값을 획득하기 위한 각 분류기는, DenseNets, EfficientNets과 Inceptions, MobileNets, ResNets, VGGs를 포함하는 CNN 모델 및 각 CNN 모델의 하위 모델로 구성된다.

발명의 효과

[0018] 본 발명의 실시 예에 따르면 수중 선체 표면의 이물질 제거를 위한 자동화된 무인 검사 알고리듬이 구축된 선체 표면 상태 검사 시스템을 제공함으로써, 수중 선체 표면 상태 검사에 소요되는 시간 및 비용을 절감할 수 있는 효과가 있다.

[0019] 본 발명의 실시 예에 따르면 소프트 보팅 앙상블을 구성하는 사전 학습이 완료된 분류기들을 전이학습 기법을 통해 재학습시켜, 클래스를 분류하기 위한 각 분류기들의 파라미터를 개선함으로써, 수중 선체 표면 상태 검사를 위해 촬영된 선체 표면 이미지 클래스 분류 정확도를 향상시킬 수 있는 효과가 있다.

[0020] 본 발명의 실시 예에 따르면 사전 학습된 분류기 모델을 데이터 세트로 전이학습함으로써, 학습 효율성을 향상시키며, 원본 이미지 데이터의 밝기, 대비, 채도를 임의로 조정하거나, 또는 특정 영역을 임의로 제거하는 자르기 처리를 수행하는 이미지 강화를 통해 데이터 세트를 보강함으로써, 데이터 세트 확보가 어려운 수중 선체 표면 이미지의 학습 효율성을 보다 향상시킬 수 있는 효과가 있다.

도면의 간단한 설명

[0021] 도 1은 기존의 유인 시스템을 통해 선박의 선체 표면에 수중 차량을 투입한 후, 수중 차량의 카메라 유닛으로 촬영된 이미지를 분석하여 선체 표면 청소 여부 결정을 위한 선체 표면 상태 검사를 실시하는 작업을 나타내는 도면이다.

도 2는 수중 차량의 구조를 나타내는 도면이다.

도 3은 수중 차량의 카메라 유닛으로 촬영한 수중 선체 표면 이미지 데이터의 클래스 분류를 위한 소프트 보팅 앙상블의 실행 과정을 나타내는 도면이다.

도 4는 카메라 유닛으로 촬영된 이미지 상에 포함된 마스크 영역과, 원본 이미지로부터 마스크 영역을 절단하여 추출한 순수한 이미지 데이터 영역을 나타내는 도면이다.

도 5a 및 도 5b는 선체 청소가 필요하지 않은 상태인 clean 이미지를 나타내며, 도 5c와 도 5d 및 도 6e 내지 도 6h는 선체 청소가 필요한 상태인 unclean 이미지를 나타내는 도면이다.

도 7a는 수중 선체 표면을 촬영한 원본 이미지이며, 도 7b 내지 도 7e는 사전 훈련 데이터 및 데이터 세트를 보강하기 위해 원본 이미지 데이터의 밝기를 임의로 조정하거나, 대비를 임의로 조정하거나, 채도를 임의로 조정하거나, 또는 특정 영역을 임의로 제거하는 자르기 처리를 수행한 이미지 데이터를 나타내는 도면이다.

도 8 및 도 9는 소프트 보팅 앙상블 분류기를 통해 분류한 수중 선체 표면 이미지를 포지티브 클래스 또는 네거티브 클래스로 올바르게 이진 분류한 예시를 나타낸다.

도 10은 수중 선체 표면 이미지의 클래스를 잘못 분류한 예시를 나타낸다.

도 11 내지 도 17은 각 분류기 유형별로 임계값에 대한 수신기 작동 특성 및 정밀 재현율 곡선을 나타내는 도면이다.

도 18은 분류기 모델 중 하나가 제거된 상태에서의 민감도 분석 결과를 나타내는 도면이다.

발명을 실시하기 위한 구체적인 내용

[0022] 이하, 본 발명의 실시 예를 첨부된 도면을 참조하여 설명한다.

[0023] 본 발명에 따른 동작 및 작용을 이해하는 데 필요한 부분을 중심으로 상세히 설명한다.

[0024] 본 발명의 실시 예를 설명하면서, 본 발명이 속하는 기술 분야에 익히 알려졌고 본 발명과 직접적으로 관련이 없는 기술 내용에 대해서는 설명을 생략한다.

[0025] 이는 불필요한 설명을 생략함으로써 본 발명의 요지를 흐리지 않고 더욱 명확히 전달하기 위함이다.

[0026] 또한, 본 발명의 구성 요소를 설명하는 데 있어서, 동일한 명칭의 구성 요소에 대하여 도면에 따라 다른 참조부호를 부여할 수도 있으며, 서로 다른 도면임에도 동일한 참조부호를 부여할 수도 있다.

[0027] 그러나 이와 같은 경우라 하더라도 해당 구성 요소가 실시 예에 따라 서로 다른 기능을 갖는다는 것을 의미하거나, 서로 다른 실시 예에서 동일한 기능을 갖는다는 것을 의미하는 것은 아니며, 각각의 구성 요소의 기능은 해당 실시 예에서의 각각의 구성 요소에 대한 설명에 기초하여 판단하여야 할 것이다.

[0028] 또한, 본 명세서에서 사용되는 기술적 용어는 본 명세서에서 특별히 다른 의미로 정의되지 않는 한 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자에 의하여 일반적으로 이해되는 의미로 해석되어야 하며, 과도하게 포괄적인 의미로 해석되거나, 과도하게 축소된 의미로 해석되지 않아야 한다.

[0029] 또한, 본 명세서에서 사용되는 단수의 표현은 문맥상 다르게 뜻하지 않는 한, 복수의 표현을 포함한다.

[0030] 본 출원에서, "구성된다" 또는 "포함한다" 등의 용어는 명세서 상에 기재된 여러 구성요소들, 또는 여러 단계들을 반드시 모두 포함하는 것으로 해석되지 않아야 하며, 그 중 일부 구성 요소들 또는 일부 단계들은 포함되지 않을 수도 있고, 또는 추가적인 구성 요소 또는 단계들을 더 포함할 수 있는 것으로 해석되어야 한다.

[0032] 본 발명에 따른 전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체 표면 상태 검사 시스템은, 수중 차량(10)을 통해 선박의 물 속에 잠긴 선체(1) 표면에 붙은 이끼나 해초 기타 유기체와 같은 생물 오염 물질을 제거하기 위한 수중 차량(10)과, 입력된 이미지를 선체(1) 청소가 필요한 상태 또는 선체(1) 청소가 불필요한 상태로 분류하는 다수의 분류기(classifier)와, 각 분류기의 개별 결정을 병합 및 합산하여 최종 예측 값을 획득하는 소프트 보팅 앙상블(soft voting ensemble) 및 전이학습을 통해 사전 학습된 분류기를 재학습시키는 연산 모듈로 이루어진다.

[0033] 수중 차량(10)은 도 2에서 도시하는 바와 같이 수중 차량(10) 차체의 전방이나 후방, 또는 전후방 양측에 선체(1) 표면을 촬영하여 이미지 데이터를 획득하기 위한 하나 이상의 카메라 유닛(11)이 장착되며, 선체(1) 표면과 대향하는 수중 차량(10)의 차체 하부에는 회전 또는 왕복 운동을 통해 선체(1) 표면을 청소하여 오염 물질을 제거하는 브러쉬 유닛(12)이 장착된다.

[0034] 그리고 선체(1) 표면과 대향하는 수중 차량(10)의 차체 하부에는 수중 차량(10)이 선체(1) 표면을 따라 이동하기 위한 구동 유닛(13)이 장착되며, 구동 유닛(13)은 수중 차량(10)이 수중의 선체(1) 표면 상태 검사 과정에서 물살에 휩쓸리는 것을 방지하기 위해 전자석 등의 자기력을 이용하여 강재로 이루어진 선체(1) 표면과 부착 또는 분리될 수 있는 부착 모듈과, 수중 차량(10)이 선체(1) 표면에 부착된 상태에서 이동할 수 있도록 하는 구동 모듈로 구성된다.

[0035] 브러쉬 유닛(12) 또는 구동 유닛(13)의 작동 제어는 수중 차량(10)에 장착된 CPU(Central Processing Unit)를 통해 이루어지게 된다.

[0036] 또한, 수중 차량(10)의 카메라 유닛(11)을 통해 다양한 환경 조건에서 촬영된 다수의 수중 선체(1) 표면의 디지털 이미지 데이터는, 각 분류기의 전이학습을 위한 훈련 데이터로 활용되며, 연산 모듈은 전이학습이나 선체(1) 표면 상태 검사 수행을 위해 카메라 유닛(11)에 의해 촬영된 수중 선체(1) 표면의 디지털 이미지 데이터가 저장되는 저장부와, 훈련 데이터를 통한 분류기의 전이학습 또는 이미지 데이터의 클래스 분류를 위한 분류기 및 소프트 보팅 앙상블의 연산을 수행하는 연산부를 포함하도록 구성된다.

[0037] 분류기의 재학습을 위한 훈련 데이터는 수중 환경 조건을 달리한 상태로 수중 차량(10)의 카메라 유닛(11)을 통해 촬영된 다수의 선체(1) 표면 이미지로 이루어지며, 수중 환경에서 카메라 유닛(11)을 통해 획득한 훈련 데이터는 촬영 위치의 수심에 따라 투과되는 광량 저하와 수중 부유물에 의한 가시도 저하 등의 환경적인 요인에 의해, 동일 카메라 유닛(11)을 통해 육상 환경에서 촬영한 이미지보다 선명도가 크게 저하되기 때문에, 이미지 강화 및 전이학습(transfer learning) 기법을 통해 선체(1) 표면 상태를 인식하는 정확도를 높이게 된다.

[0038] 기계 학습(machine learning)은 지도 학습(supervised learning)이나 강화 학습(reinforcement learning) 등의 알고리듬을 기반으로, 주어진 훈련 데이터로부터 훈련 데이터를 평가하는 표현(representation)과, 훈련 완료 후 아직 주어지지 않은 데이터를 처리하는 일반화(generalization)로 이루어지는 인공지능 분야이며, 기계 학습의 학습 정확도를 높이기 위해서는 많은 수의 훈련 데이터를 필요로 한다.

[0039] 그러나 수중 환경에서 촬영된 선체(1) 표면 이미지의 공개된 데이터 세트는 기계 학습을 수행하기 위한 훈련 데이터로 적용하기에 그 수량이 부족하며, 수중 차량(10)의 카메라 유닛(11)을 통해 선박의 수중 선체(1) 표면 이미지를 획득하기 위해서는 선주의 허가를 필요로 하기 때문에, 카메라 유닛(11)을 통해 획득 가능한 훈련 데이터의 수량은 기계 학습의 학습 정확도를 높이기 위해 필요한 훈련 데이터 수량에 못미치게 된다.

[0040] 따라서 본 발명에서는, 기존의 이미지에 약간의 변형을 가하여 훈련 데이터의 수량을 보강하는 이미지 강화(image augmentation) 기법을 적용하며, 훈련 데이터를 통해 이미 학습이 완료된 각 분류기를 재학습함으로써, 한정된 적은 수량의 훈련 데이터로부터 선체(1) 표면 상태를 인식하는 정확도를 높일 수 있도록 한다.

[0041] 특히, 전이학습은 이미 학습된 모델을 사용하여 문제 해결을 수행하기 때문에, 카메라 유닛(11)을 통해 획득한 훈련 데이터를 적용 데이터와 학습 데이터로서 적용하는 연산 모듈 구성에 적용 시 높은 효율을 나타내는 장점을 가진다.

[0042] 연산 모듈은 전이학습을 통해 개선된 파라미터 데이터나 선체(1) 표면 검사를 위한 데이터 또는 훈련 데이터를 포함하는 각종 데이터가 저장되는 저장부와, 분류기의 전이학습이나 분류기를 통한 클래스 분류 또는 소프트 보팅 앙상블의 연산을 수행하는 연산부로 구성된다.

[0043] 분류기(classifier)는 사전 학습이 완료된 CNN(Convolutional Neural Network) 모델로 구성되며, 입력된 이미지 데이터를 선체(1) 오염이 발생하여 수중 차량(10)을 이용한 선체(1) 청소가 필요한 상태인 포지티브 클래스(positive class)와, 선체(1) 오염이 발생하지 않아 수중 차량(10)을 이용한 선체(1) 청소가 불필요한 상태인 네거티브 클래스(negative class)의 두 개의 클래스로 이진(binary) 분류함으로써, 포지티브 클래스(positive class)와 네거티브 클래스(negative class)로 분류되는 레이블을 출력한다.

[0044] 그리고 각 분류기는 카메라 유닛(11)을 통해 획득 가능한 훈련 데이터를 기반으로 선체(1) 표면 상태 이미지 분류를 위한 각종 파라미터를 개선함으로써, 입력된 이미지 데이터의 클래스 분류 정확도를 높이는 전이학습 기법을 반복함으로써 재학습을 수행한다.

[0045] 또한, 분류기는 서로 다른 종류로 이루어진 다수의 분류기 모델의 조합으로 이루어지기 때문에, 동일한 이미지 데이터가 입력되더라도 각 분류기에서 출력된 클래스 분류 결과가 다르게 형성될 수 있으며, 각 분류기별 출력 결과를 합쳐 하나의 출력을 생성하기 위하여 소프트 보팅 앙상블(soft voting ensemble)을 적용하게 된다.

[0046] 도 3에서 도시하는 바와 같이 소프트 보팅 앙상블은, 서로 다른 종류로 이루어진 각 분류기 모델로 이미지 데이터 입력 시, 각 분류기 모델별로 데이터 이미지가 포지티브 클래스 또는 네거티브 클래스 중 선택되는 어느 하나의 클래스에 속하도록 개별적으로 출력된 클래스 분류 결정에, 확률 값을 기반으로 가중치를 부여한 후, 각 분류기 모델의 개별 결정을 병합하여 가중 확률의 합을 얻으며, 가중 확률 합산의 평균 값을 구함으로써 하나의 최종 예측 값을 획득한다.

[0047] 이때, 각 분류기에서 출력된 클래스 분류 결정에 부여되는 가중치는 분류기의 중요도에 따라 결정되며, 분류기 조합으로는 DenseNet, EfficientNet, Inception, MobileNet, ResNet, VGG를 포함하는 CNN 모델로 이루어진 다수의 공개 플랫폼 분류기 모델이 적용된다.

[0048] 소프트 보팅 앙상블을 이용한 클래스 분류 결정은 다음과 같이 5개의 스텝을 거쳐 수행된다.

[0049] [소프트 보팅 앙상블 제1 스텝]

[0050] 각 분류기 모델에서 분류된 클래스 분류 확률은 아래의 방정식으로 나타낼 수 있으며,

[0051] $$P_k(unclean|\mathbf{x}, \theta_k) = h^{(k)}_{\theta_k}(\mathbf{x})$$

[0052] k는 소프트 보팅에 참여하는 각 분류기를 나타내는 숫자, $h^{(k)}_{\theta_k}(\mathbf{x})$는 k번째 분류기, θ_k는 k번째 분류기의 가중치, x는 입력되는 이미지 데이터를 의미하며, 도 3에서는 k=1 내지 k=6은 각각 DenseNet(1), EfficientNet(2), Inceptions(3), MobileNet(4), ResNet(5), VGG(6)를 의미한다

[0053] [소프트 보팅 앙상블 제2 스텝]

[0054] 각 분류기 모델에서 가중치 θ_k를 결정하기 위하여, 전이학습 기법을 통해 훈련 데이터를 재학습한다.

[0055] [소프트 보팅 앙상블 제3 스텝]

[0056] 각 분류기 모델에서, 입력된 이미지 데이터가 포지티브 클래스로 분류될 확률을 구하며, $P_k(unclean|\mathbf{x}, \theta_k)$는 k번째 분류기에서 훈련 데이터의 이미지 x가 포지티브 클래스로 분류될 확률로, 각 분류기에 대하여 $P_k(unclean|\mathbf{x}, \theta_k)$ 값을 평가한다.

[0057] [소프트 보팅 앙상블 제4 스텝]

[0058] 모든 $P_k(unclean|\mathbf{x}, \theta_k)$의 평균을 구함으로써, 소프트 보팅 앙상블의 최종 예측 값$P(unclean|\mathbf{x}) \in [0,1]$을 획득하며, 소프트 보팅 앙상블이 각 분류기 모델 DenseNet(1), EfficientNet(2), Inceptions(3), MobileNet(4), ResNet(5), VGG(6)로부터 최종 예측 값을 획득하는 공식은 아래와 같이 표현된다.

[0059] $$P(unclean|\mathbf{x}) = \frac{1}{6}\sum_{k=1}^{6} P_k(unclean|\mathbf{x}) = \frac{1}{6}\sum_{k=1}^{6} h^{(k)}_{\theta_k}(\mathbf{x})$$

[0060] [소프트 보팅 앙상블 제5 스텝]

[0061] 클래스 분류를 위해 소프트 보팅 앙상블에 주어진 임계값 ?로부터, 최종 예측 값이 임계값보다 큰 경우($P(unclean|\mathbf{x}) > \varepsilon$), 훈련 데이터의 이미지 x는 포지티브 클래스로 판단되어 선체(1) 청소가 필요한 클래스의 데이터 세트로 분류된다.

[0062] 최종 예측 값이 임계값 이하인 경우($P(unclean|\mathbf{x}) \leq \varepsilon$), 훈련 데이터의 이미지 x는 네거티브 클래스로 판단되어 선체(1) 청소가 필요없는 클래스의 데이터 세트로 분류된다

[0063] 이때, 제1 내지 제5 스텝에 적용되는 분류기 모델의 수량이 변경(추가 또는 감소)되는 경우, 변경된 수량의 크기로 k값이 변경되어 적용되며, 소프트 보팅 앙상블을 구성하는 분류기는 아래의 표 1과 같이 각 CNN 모델의 하

위 모델이 부가되도록 구성될 수 있다.

표 1

[0064]

분류기 모델	하위 모델
DenseNet	DenseNet121,DenseNet169,DenseNet201
EfficientNet	EfficientNetB0~EfficientNetB7
Inception	InceptionV3,InceptionResNetV2,Xception
MobileNet	MobileNetV3-Small
ResNet	ResNet101,ResNet152,ResNet50,ResNet101V2
VGG	VGG16,VGG19

[0066] 또한, 소프트 보팅 앙상블을 구성하는 각 분류기 모델의 최적 가중치는 사전 훈련 완료된 분류기 모델의 전이학습을 이용한 재학습을 통해 선택되며, 소프트 보팅 앙상블을 이용한 클래스 분류 제2 스텝의 전이학습은 다음과 같이 진행된다.

[0067] 전이학습은 특정 임무를 수행하기 위해 개발된 모델을 두 번째 임무를 수행하기 위한 시작점으로 재사용하는 기계 학습 기술로, 본 발명에 따른 분류기 모델의 전이 학습은 각 분류기 모델의 하이퍼파라미터 튜닝을 통해, 최적의 하이퍼파라미터와 가중치를 선택하도록 한다.

[0068] 분류기 모델의 전이학습은 다음과 같이 3개의 단계로 구성된다.

[0069] [전이학습 제1 단계]

[0070] 사전 학습된 분류기 모델의 훈련 데이터 이미지 입력 크기를 입력 이미지의 크기로 재정의하여, 입력 이미지의 픽셀 값이 0 내지 1 사이에 형성되도록 정규화한다.

[0071] [전이학습 제2 단계]

[0072] 사전 학습된 분류기 모델의 다중 클래스 분류를 위한 계층(layer)을 이진(binary) 분류를 위한 계층으로 대체한다

[0073] 사전 학습된 분류기 모델의 다중 클래스 분류를 이진(binary) 분류를 위한 계층으로 대체하기 위하여, 전역 평균 풀링 계층(global average pooling layer)과 드롭아웃 계층(dropout layer)이 사전 학습된 모델의 컨볼루션 계층(convolution layer)으로 추가된다.

[0074] [전이학습 제3 단계]

[0075] $f(x)=\frac{1}{1+e^{-x}}$ (x: 마지막 선형 계층의 출력 값)로 정의되는 활성화 함수를 통해, 하나의 노드를 가지는 완전 연결 계층(fully connected layer)이 추가되어, 재정의된 분류기 모델을 생성한다.

[0077] 컨볼루션 신경망(CNN,Convolution Neural Network)에 입력된 학습 데이터는, 특징 추출 신경망을 먼저 통과하여 추출된 이미지가 분류 신경망에 다시 입력되면, 분류 신경망이 이미지의 특징을 기반으로 이미지의 클래스를 분류하며, 특징 추출 신경망은 컨볼루션 계층과 풀링 계층을 차례로 적층한 형태를 이루게 된다.

[0078] 컨볼루션 계층은 컨볼루션 필터를 통해 입력 이미지와 컨볼루션 필터를 연산하여 특징이 부각된 변환 이미지인 특징맵(feature map)을 생성하고, 컨볼루션 필터로 처리된 특징맵은 활성함수를 거쳐 최종 출력되며, 풀링 계층은 데이터 처리 연산량과 메모리 사용량을 감소시키기 위해 이웃하는 픽셀을 묶어 하나의 대표 픽셀로 전환하여 이미지의 차원을 축소함으로써 파라미터를 감소시킨다.

[0079] 전역 평균 풀링 계층은 분류할 클래스 수량만큼 특징맵을 마지막에 생성하며, 각 특징맵의 평균을 계산하여 특징맵마다 하나의 결과를 출력함으로써, 파라미터 연산량을 감소시킬 수 있다.

[0080] 전이학습 제3 단계에서 재정의된 분류기 모델의 학습은, 재정의된 분류기 모델의 계층 중 새로 추가된 계층의 가중치만이 훈련에 의해 조정되고, 훈련은 모든 데이터 세트를 미리 정해진 학습률 및 횟수 만큼 반복 학습하도록 지속되며, 모든 계층의 가중치가 새로운 학습 속도로 미리 정해진 횟수 만큼 미세 조정되어, 미세 조정 과정

중 가장 높은 검증 정확도에 해당하는 가중치가 선택된다.

[0082] <재정의된 분류기 모델의 학습 실시 예>

[0083] 재정의된 분류기 모델의 계층 중, 새로 추가된 계층의 가중치만을 훈련에 의해 조정하며, 훈련은 주어진 학습 속도 α_1 으로 20 epoch (1 epoch는 인공 신경망에서 전체 데이터 세트에 대하여 한 번 학습을 완료한 상태를 의미)동안 지속하며, 미니 배치 경사 하강법(mini-batch gradient descent method)을 적용한다.

[0084] 이때, 옵티마이저로는 아담 옵티마이저(Adam optimizer)를 적용한다.

[0085] 손실 함수는 실제 레이블 값들 사이의 이진 교체 엔트로피 값의 평균 $y^{(i)}$, 평가된 이미지의 예측 값 $h_{\theta_k}^{(k)}\left(\mathbf{x}^{(i)}\right)$ 를 적용한다. (m은 훈련에 사용된 이미지의 수량)

[0086] $$J(\theta)=\frac{1}{m}\sum_{i=1}^{m}\left[-y^{(i)}\log\left(h_{\theta_k}^{(k)}\left(x^{(i)}\right)\right)-\left(1-y^{(i)}\right)\log\left(1-h_{\theta_k}^{(k)}\left(x^{(i)}\right)\right)\right]$$

[0087] 모든 계층의 가중치가 α_1 보다 감소된 새로운 학습 속도 $\alpha_2(=\lambda\cdot\alpha_1)$ 에 의해 10 epoch 동안 미세 조정된다(이때, $\lambda(<1)$).

[0088] 최종적으로 모든 epoch 중 가장 높은 검증 정확도에 해당하는 가중치를 선택한다.

[0089] 드롭아웃 확률, 학습 속도, 배치(batch) 크기 및 CNN 모델로 이루어진 분류기 모델의 하위 모델과 같은 최적의 하이퍼파라미터는 하이퍼파라미터 튜닝을 사용하여 선택되며, 하이퍼파라미터는 분류기 모델의 하위 모델에 의해 조정된다.

[0090] 무작위 검색 방법에 의해 최적의 하이퍼파라미터를 선택하며, 각각의 하이퍼파라미터의 값은 이들을 포함하는 검색 공간으로부터 랜덤하게 샘플링되어 검증 정확도가 측정된다.

[0091] 각 분류기 모델의 하위 모델 중에서 검증 정확도가 가장 높은 모델을 선택한다.

[0093] <데이터 세트를 생성하기 위한 실시 예>

[0094] 사전 훈련된 데이터 세트를 다시 훈련시키기 위해서는, 카메라 유닛(11)을 통해 촬영한 수중 선체(1) 표면 이미지 및 clean(청소 불필요 상태) 또는 unclean(청소 필요 상태)로 구분되어 표시되는 레이블의 이미지를 필요로 한다.

[0095] 수중 선체(1) 표면 이미지는, 카메라 유닛(11)을 통해 512*512픽셀의 해상도 및 10fps로 촬영된 영상으로부터 1초 간격으로 추출되었으며, 각 이미지의 레이블 지정은 수동으로 이루어졌다.

[0096] 도 4에서 도시하는 바와 같이 카메라 유닛(11)에 의해 촬영된 수중 선체(1) 표면 이미지 상에, 수중 차량(1)의 차체 일부와 같이 데이터 세트 생성에 불필요한 이미지 영역인 마스크 영역이 포함되는 경우, 불린 교차(boolean intersection)을 이용하여 마스크 영역을 절단하여 순수한 이미지 데이터 영역을 추출한다.

[0097] 추출된 이미지 데이터 영역 중, 도 5a 및 도 5b는 선체(1) 청소가 필요하지 않은 상태(negative class)인 clean 이미지를 나타내며, 도 5c와 도 5d 및 도 6e 내지 도 6h는 선체(1) 청소가 필요한 상태(positive class)인 unclean 이미지를 나타낸다.

[0098] 도 5b에는 선체(1) 표면에 그려진 드래프트 이미지가, 도 5c 및 도 5d에는 선체(1) 표면에 부착된 따개비가, 도 6e 내지 도 6h에는 녹색 이끼가, 도 5d에는 물고기의 꼬리 지느러미가, 도 6g에는 선체(1) 도장의 손상면이, 도 6e에는 수중 부유 물질이 관찰되며, 도 6h는 조명이 강하게 촬영되었다.

[0099] 이와 같이 카메라 유닛(11)을 통해 촬영한 수중 이미지는 선체(1) 표면의 상태를 clean 또는 unclean 으로 명확하게 구분하기 어려운 환경에서 촬영되며, 촬영된 이미지 상에서 드래프트 마크와 선체(1)의 도장면 손상부 및 따개비는 모두 흰색으로 나타나는데, 드래프트 마크나 도장면 손상부가 포함된 이미지는 clean으로 분류하고,

따개비가 포함된 이미지만을 unclean으로 분류하여야 한다.

[0100] 따라서 서로 다른 일자와 위치에서 촬영된 20개의 선체(1) 표면 영상으로부터 5683개의 이미지를 추출하여 훈련 데이터를 생성하였으며, 훈련 데이터 중 2035개는 clean 이미지로, 나머지 3648개는 unclean 이미지로 클래스를 분류하여 두 종류의 데이터 세트를 형성하였다.

[0101] 그리고 위의 데이터 세트에서 각각 2000개의 이미지를 무작위로 선택하고, 각 이미지 세트는 60:20:20의 비율로 학습 세트와 검증 세트 및 테스트 세트로 분할하여, clean 이미지와 unclean 이미지 클래스 별로 각각 1200개, 400개, 400개의 학습 세트와 검증 세트 및 테스트 세트를 형성하였다.

[0102] 또한, 카메라 유닛(11)을 통해 촬영되는 위치의 수심이나 조명에 의해 밝기나 대비 또는 채도가 변경되거나, 수중 부유물에 의해 형성되는 비인식 영역이 형성될 수 있으므로, 도 7에서 도시하는 바와 같이 데이터 세트의 선체(1) 표면 수중 촬영 이미지 데이터의 밝기를 임의로 조정하거나, 대비를 임의로 조정하거나, 채도를 임의로 조정하거나, 또는 특정 영역을 임의로 제거하는 자르기를 수행함으로써, 데이터 세트를 보강할 수 있다.

[0103] 전이학습의 반복에 따른 각 분류기 모델의 재학습이 완료되면, 자동화된 무인 검사 알고리듬이 구축된 수중 선체(1) 표면 상태 검사 시스템을 통해 수중 선체(1) 표면 검사를 수행하며, 전이학습을 통해 재학습된 분류기 모델 및 소프트 보팅 앙상블 기법을 기반으로 수중 차량(10)의 카메라 유닛(11)으로 촬영한 선체(1) 표면의 이미지 데이터를 포지티브 또는 네거티브 클래스로 분류한다.

[0104] 촬영된 수중 선체(1) 표면의 이미지 데이터가 포지티브 클래스로 분류되면, 브러쉬 유닛(12)을 가동하여 선체(1) 표면에 붙은 생물 오염 물질을 제거하며, 촬영된 수중 선체(1) 표면의 이미지 데이터가 네거티브 클래스로 분류되면, 구동 유닛(13)을 통해 검사가 아직 이루어지지 않은 수중 선체(1) 표면 영역으로 수중 차량(10)을 이동하여 카메라 유닛(11)을 통한 수중 선체(1) 표면 상태 검사를 수행하는 과정을 반복한다.

[0105] 또한, 소프트 보팅 앙상블의 정확도를 향상시키기 위해서는 전위학습을 위한 데이터 세트의 수량 확보가 중요하지만, 획득 가능한 훈련 데이터가 한정된 선체(1) 표면 촬영 이미지 데이터의 특성상, 기확보된 훈련 데이터의 이미지 특성을 변환함으로써, 전이학습을 위한 데이터 세트를 보강할 필요가 있다.

[0106] 이를 위해 데이터 세트의 선체(1) 표면 수중 촬영 이미지 데이터의 밝기를 임의로 조정하는 밝기 조정이 이루어지거나, 이미지의 대비를 임의로 조정하는 대비 조정이 이루어지거나, 이미지의 채도를 임의로 조정하는 채도 조정이 이루어지거나, 또는 이미지의 특정 영역을 임의로 제거하는 자르기 조정이 이루어질 수 있으며, 이들 이미지 조정 방법 중 무작위로 선택되는 어느 하나 또는 둘 이상의 방식을 조합 적용하여, 데이터 세트를 보강할 수 있다.

[0107] 이때, 이미지의 평행 이동, 회전, 뒤집기, 크기 조정 등의 타 증강 기술은 전이학습의 정확도 향상에 영향을 미치지 않음을 실험을 통해 확인하였으며, 따라서 전 훈련 데이터 세트 및 데이터 세트를 보강하기 위한 증강 이미지 생성 방식으로서 자르기 방식을 적용하는 것이 바람직하다.

[0108] 증강 이미지 생성을 통해 형성된 최종 데이터 구성은 아래의 표 2와 같다.

표 2

[0109]

분류	학습 세트	검증 세트	테스트 세트	합계
clean (negative)	6000	400	400	6800
unclean (positive)	6000	400	400	6800
	12000	800	800	136000

[0111] 또한, 본 발명의 소프트 보팅 앙상블의 분류기는 Python과 TensorFlow 2를 적용하여 구현하였으며, TensorFlow 2에서 제공하는 사전 훈련된 분류기 모델과 가중치가 사용되었다.

[0112] 각 분류기 모델의 평균 재훈련에 소요되는 시간은 다음 표 3과 같다.

표 3

[0113]

분류기 모델	평균 재훈련 시간(h)
DenseNet	1.41
EfficinetNet	2.75
Inception	0.66
MobileNet	0.58
ResNet	0.69
VGG	0.93

[0115] 하이퍼파라미터 튜닝을 위한 검색 공간은 다음 표 4와 같다.

표 4

[0116]

하이퍼파라미터	값
초기 학습 속도(α_1)	0.3, 0.01, 0.03, 0.01, 0.003, 0.001, 0.0003, 0.0001
학습 속도 가속기(ε)	0.1, 0.01, 0.001, 0.0001
배치 크기	4, 8, 16, 32, 64, 96, 128

[0118] 하위 분류기 모델에 대한 하이퍼파라미터의 최적 값을 결정하기 위해 하위 분류기 모델당 50개의 샘플을 아래의 표 5로부터 무작위로 선택하여 적용하였고, 이후 하위 분류기 모델은 선택된 하이퍼파라미터 값으로 훈련되었으며, 검증 세트의 경우 정확도가 가장 높은 하위 분류기 모델을 최적의 분류기 모델로 선택하였다.

표 5

[0119]

모델	하위 모델	초기 학습 속도	학습 속도 가속기	드롭아웃 확률	배치 크기
DenseNet	DenseNet 201	0.003	0.01	0.1	32
EfficientNet	EfficientNet B4	0.01	0.01	0.2	8
Inception	InceptionV3	0.03	0.001	0.1	128
MobileNet	MobileNeV3 Large	0.01	0.01	0.2	32
ResNet	ResNet50V2	0.03	0.001	0.3	32
VGG	VGG16	0.0001	0.1	0.3	16

[0121] 정확도(accuracy)는 다음의 공식에 의해 결정된다.

[0122]
$$Accuracy = \frac{True\ positive + True\ negative}{Total}$$

[0123] 분류의 임계값 ε=0.5로 설정되었으며, 아래의 표 6에서 학습 정확도와 검증 정확도가 각각 98% 및 97%보다 크게 형성되었음을 확인할 수 있다.

표 6

[0124]

	DenseNet	EfficientNet	Inception	MobileNet	ResNet	VGG
학습 정확도	99.38	98.85	99.58	98.66	99.58	99.45
검증 정확도	97.88	97.75	97.84	97.00	97.60	97.60

[0126] 그리고 정밀도(precision)와 재현율(recall) 및 F_1 점수는 다음의 공식에 의해 계산된다.

[0127] $$Precision = \frac{True\ positive}{True\ positive + False\ positive}$$

[0128] $$Recall = \frac{True\ positive}{True\ positive + False\ negative}$$

[0129] $$F_1\ score = 2\frac{Precision \times Recall}{Precision + Recall}$$

[0131] 최적의 분류기 모델로 구성된 소프트 보팅 앙상블 분류기를 사용하여 테스트 세트를 분류한 결과는 아래의 표 7과 같다.

표 7

[0132]

	DenseNet	Efficient Net	Inception	MobileNet	ResNet	VGG	Voting
true positive	380	392	384	386	382	387	390
false negative	20	8	16	14	18	13	10
false positive	11	9	5	9	8	9	5
true negative	389	391	395	391	392	391	395
합계	800	800	800	800	800	800	800
정확도	96.13	97.88	97.38	97.13	96.75	97.25	98.13
정밀도	97.19	97.76	98.71	97.72	97.95	97.73	98.73
재현율	95.00	98.00	96.00	96.50	95.50	96.75	97.50
F_1-점수	96.08	97.88	97.34	97.11	96.71	97.24	98.11

[0134] 위의 표와 같이 6개 분류기 모델의 정밀도와 F_1 점수는 96% 이상 형성되었으며, 전위학습을 위한 클래스 분류를 위해 분류기를 독립적으로 사용하더라도 6개의 개별 분류기 모델은 96%의 정확도를 달성할 수 있다.

[0135] 소프트 보팅 앙상블 분류기는 개별 분류기 모델보다 더 높은 정밀도와 재현율 및 F_1 점수를 획득할 수 있으며, 소프트 보팅 앙상블 분류기의 재현율(recall) 값 만이 분류기 모델 중 하나인 EfficeientNet보다 낮게 형성되므로, 소프트 보팅 앙상블 분류기 적용 시 수중 선체(1) 표면 촬영 이미지의 분류 정확도를 보다 높일 수 있음을 확인할 수 있다.

[0136] 도 8 및 도 9는 소프트 보팅 앙상블 분류기를 통해 분류한 수중 선체(1) 표면 이미지를 포지티브 클래스 또는 네거티브 클래스로 올바르게 이진 분류한 예시를 나타내며, 도 8a 내지 도 8d는 선체(1) 표면에 해초나 따개비가 형성된 포지티브 클래스 이미지를 나타내고, 도 9e 내지 도 9h는 선체(1) 표면에 드래프트 마크 또는 도장면 손상이 형성되거나, 수중 부유물 또는 조명 그림자가 함께 촬영되었지만 해초나 따개비가 형성되지 않은 네거티브 클래스 이미지를 각각 나타낸다.

[0137] 도 10은 수중 선체(1) 표면 이미지의 클래스를 잘못 분류한 예시를 나타낸다.

[0138] 도 10a 내지 도 10c에서는 이미지 상의 작은 영역에 해초가 포함되어 네거티브 클래스로 잘못 분류되었고, 도

10d에서는 조명이 도달하지 않아 어둡게 촬영된 해수 영역과 짙은 색의 해초가 중첩되면서 해초가 붙은 선체(1) 표면을 해수 영역으로 인식하여 네거티브 클래스로 잘못 분류되었으며, 도 10e에서는 수중 부유물에 의한 교란으로 해초를 인식하지 못하여 네거티브 클래스로 잘못 분류되었고, 도 10f에서는 해초를 인식하여 네거티브 클래스로 분류하였으나, 함께 촬영된 드래프트 마크는 인식하지 못하고 해초만이 인식되었다.

[0139] 도 11 내지 도 17은 다양한 종류의 분류기 임계값에 대한 수신기 작동 특성(Receiver Operating Characteristic,ROC) 곡선 및 정밀 재현율(Precision Recall,PR) 곡선을 각각 나타내며, 도 11에서 소프트 보팅 앙상블 분류기의 곡선 아래 면적은 거의 하나로 형성되어, 도 12 내지 도 17에 따른 다른 6개의 분류기 모델보다 수중 선체(1) 표면 상태를 분류하는 능력이 가장 우수함을 확인할 수 있다.

[0140] 도 18은 분류기 모델 중 하나가 제거된 상태의 민감도 분석 결과를 나타내며, 표 6의 결과와 비교해보면 6개의 분류기 모델 중 5개의 분류기 모델만을 이용한 경우에도 오직 하나의 분류기 모델을 이용한 경우보다 우수한 결과를 얻을 수 있다.

[0141] 분류기 모델 중 EfficientNet을 제거한 경우 정밀도 측면에서는 열등한 결과를 얻었지만, 우수한 정확도와 재현율 및 F_1-점수 결과를 얻을 수 있으며, 특히 정밀도와 재현율의 조화 평균(harmonic mean)인 F_1-점수는 6개의 분류기 모델을을 적용하였을 때가 5개의 분류기 모델을 적용하였을 때보다 우수한 결과를 얻을 수 있다.

[0142] 또한, 수중 차량(10)의 카메라 유닛(11)으로 촬영한 수중 선체(1) 표면 이미지를 클래스 별로 분류하는 처리 속도는, 본 발명의 전이학습모델의 소프트 보팅 앙상블을 이용한 수중 선체(1) 표면 상태 검사 시스템에서 수중 선체(1) 표면 이미지의 클래스 분류 결과에 따른 브러쉬 유닛(12) 또는 구동 유닛(13)의 실시간 작동 제어의 핵심 요소 중 하나이다.

[0143] 아래의 표 8은 각 분류기 모델 별로, 수중 차량(10)의 CPU만을 사용하여 하나의 이미지의 클래스를 분류하는데 소요되는 시간을 측정한 결과로, 수중 차량(10)에 장착되는 CPU는 카메라 유닛(11)으로 촬영한 수중 선체(1) 표면 이미지를 클래스 별로 분류하며, 브러쉬 유닛(12) 또는 구동 유닛(13)의 작동을 제어한다.

[0144] 소프트 보팅 앙상블 분류기를 통해 테스트 세트로부터 하나의 이미지를 클래스 분류하는데 평균 56.25ms가 소요되었고, 이는 17FPS의 처리 속도에 해당하게 된다.

표 8

[0145]

	DenseNet	EfficientNet	Inception	MobileNet	ResNet	VGG	Voting
시간 (ms)	14.25	14.23	6.90	4.95	6.72	9.20	56.25
FPS	70	70	144	202	148	108	17

[0147] 이와 같은 소프트 보팅 앙상블 분류기의 이미지 클래스 분류 처리 속도는, 60cm/s 이하로 형성되는 구동 유닛(13)을 통한 수중 차량(10)의 이동 속도와, 수중 차량(10)에 장착되는 상대적으로 낮은 성능의 CPU를 통해서도 수중 선체(1) 표면 이미지의 클래스 분류 결과에 따른 브러쉬 유닛(12) 또는 구동 유닛(13)의 실시간 작동 제어가 충분히 이루어질 수 있도록 한다.

[0149] 상기 내용을 참조하여 본 발명의 실시 예들을 설명하였지만, 본 발명이 속하는 기술분야의 당업자는 본 발명이 그 기술적 사상이나 필수적 특징을 변경하지 않고 다른 구체적인 형태로 실시될 수 있다는 것을 이해할 수 있을 것이다.

[0150] 그러므로 이상에서 기술한 실시예들은 모든 면에서 예시적인 것이며 한정적인 것이 아닌 것으로서 이해되어야 하고, 상기 상세한 설명에서 기술된 본 발명의 범위는 후술하는 특허청구범위에 의하여 나타나며, 특허 청구범위의 의미 및 범위 그리고 그 등가 개념으로부터 도출되는 모든 변경 또는 변형된 형태가 본 발명의 범위에 포함되는 것으로 해석되어야 한다.

부호의 설명

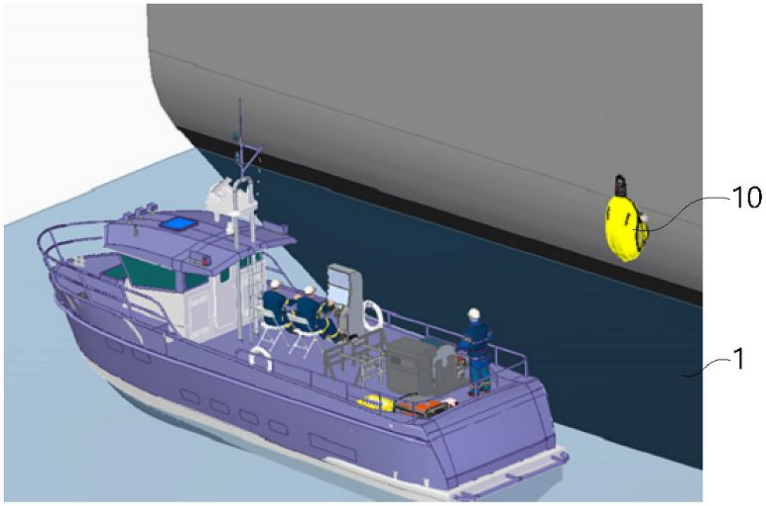
[0151] 1: 선체 10: 수중 차량

11: 카메라 유닛 12: 브러쉬 유닛

13: 구동 유닛

도면

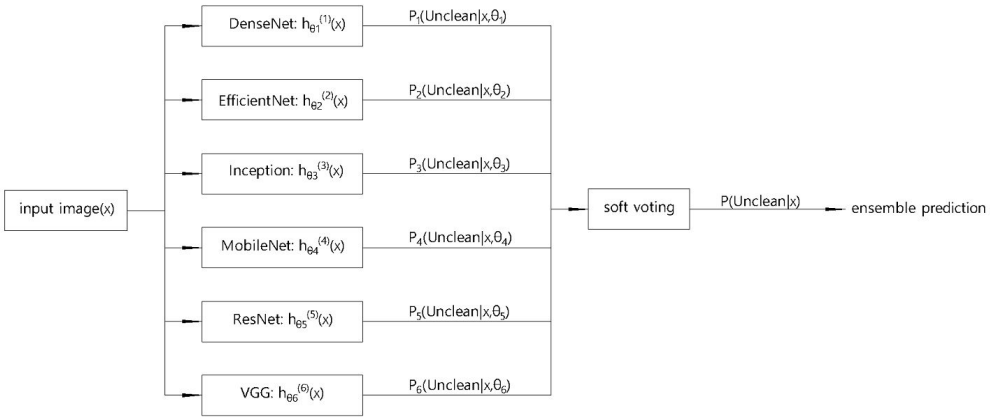
도면1



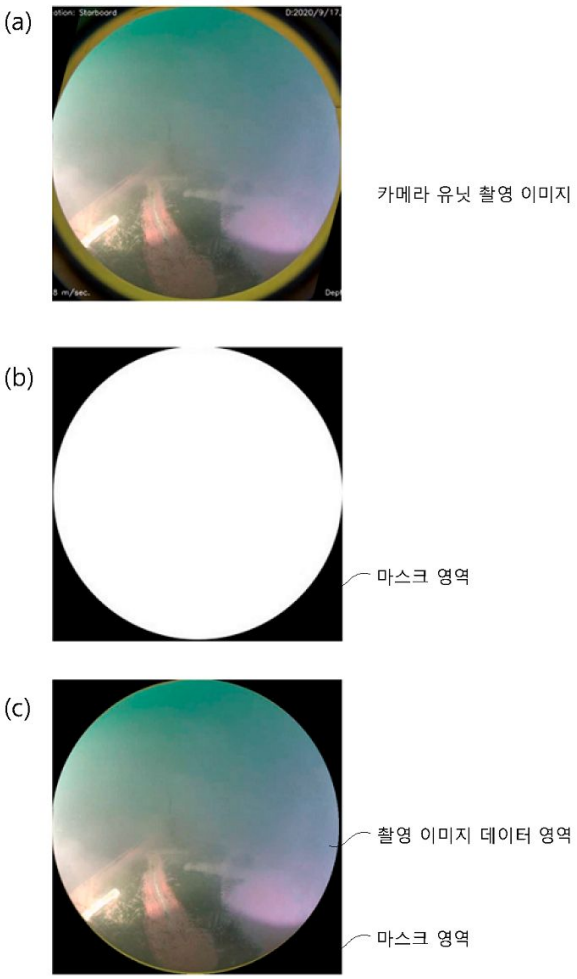
도면2



도면3

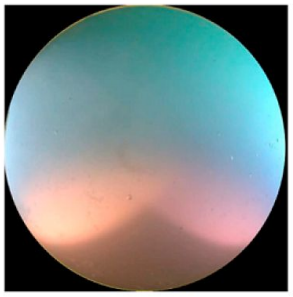


도면4



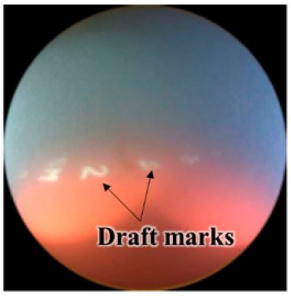
도면5

(a)



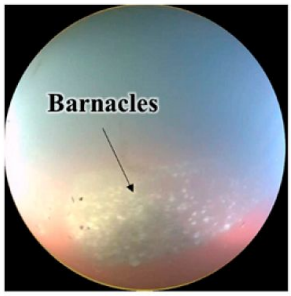
clean 이미지

(b)



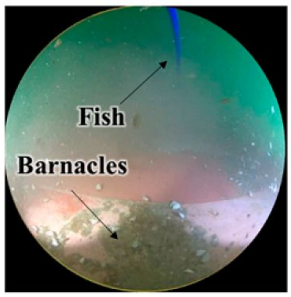
clean 이미지

(c)



unclean 이미지

(d)



unclean 이미지

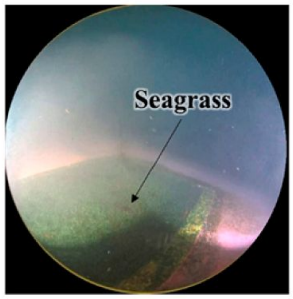
도면6

(e)



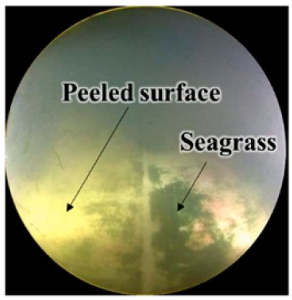
unclean 이미지

(f)



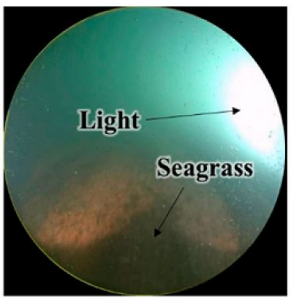
unclean 이미지

(g)



unclean 이미지

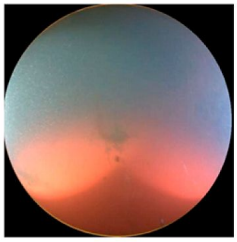
(h)



unclean 이미지

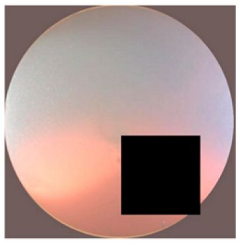
도면7

(a)



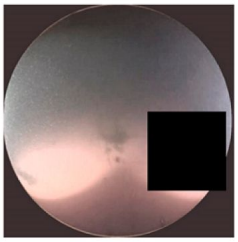
원래 이미지

(b)



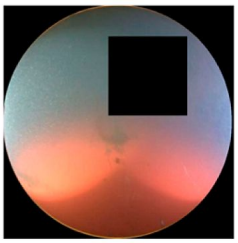
밝기, 대비, 자르기 조정 이미지

(c)



밝기, 대비, 채도, 자르기 조정 이미지

(d)



자르기 조정 이미지

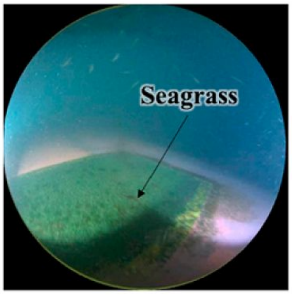
(e)



채도 조정 이미지

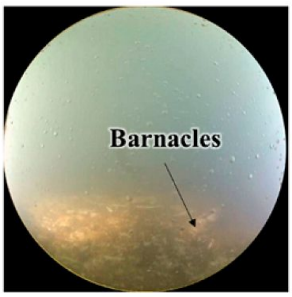
도면8

(a)



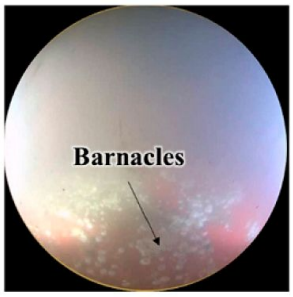
unclean 이미지
(positive class)

(b)



unclean 이미지
(positive class)

(c)



unclean 이미지
(positive class)

(d)



unclean 이미지
(positive class)

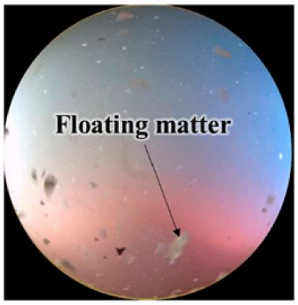
도면9

(e)



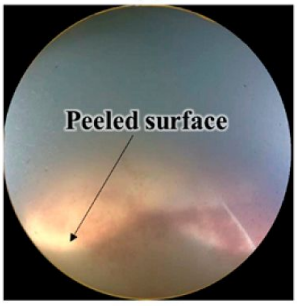
clean 이미지
(negative class)

(f)



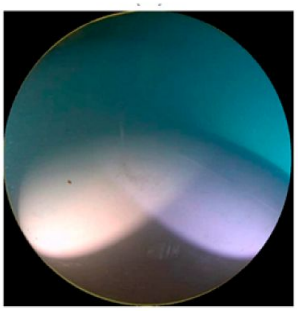
clean 이미지
(negative class)

(g)



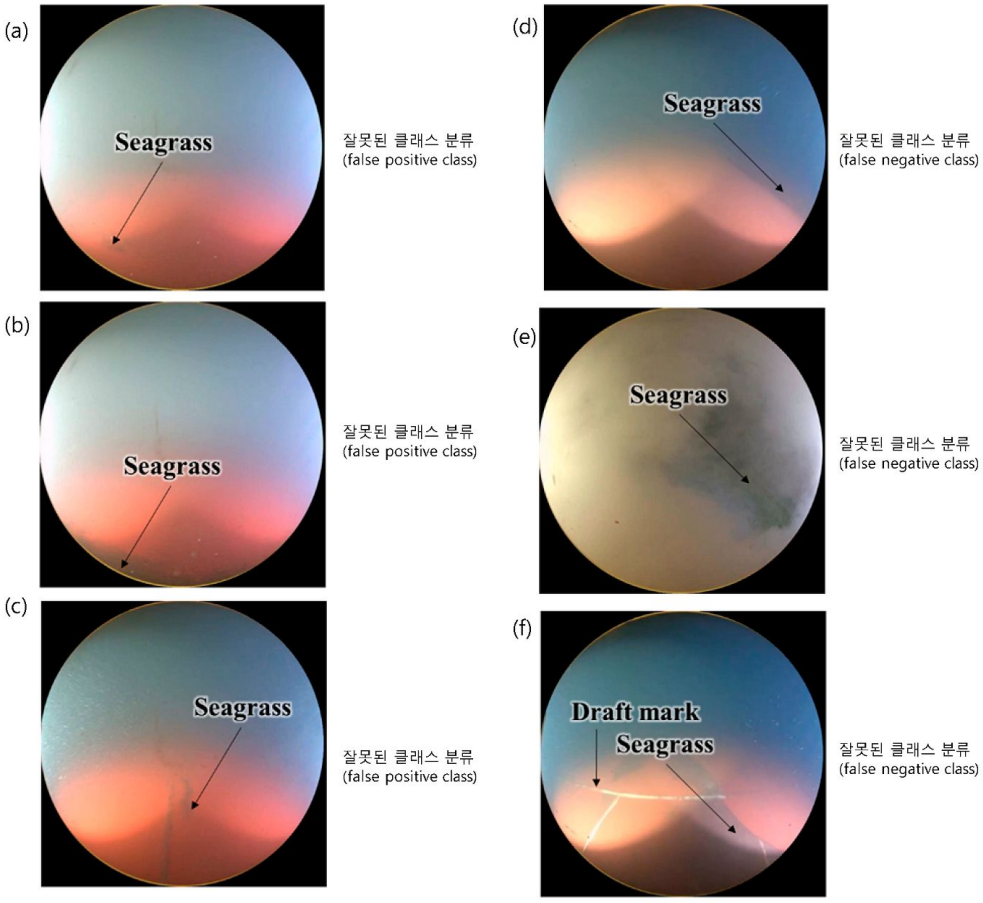
clean 이미지
(negative class)

(h)



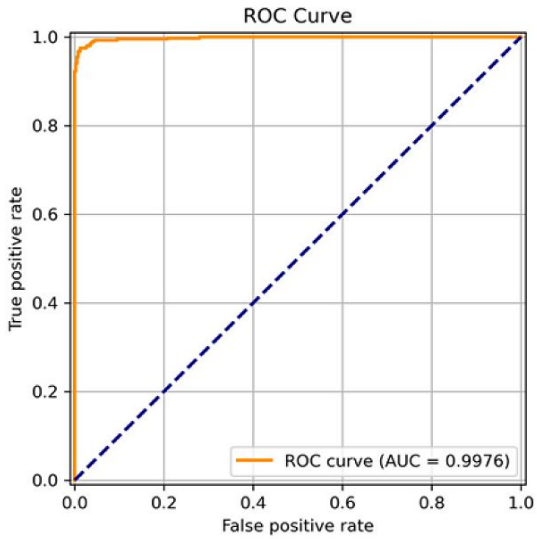
clean 이미지
(negative class)

도면10


(a)
Seagrass
잘못된 클래스 분류
(false positive class)
(b)
Seagrass
잘못된 클래스 분류
(false positive class)
(c)
Seagrass
잘못된 클래스 분류
(false positive class)
(d)
Seagrass
잘못된 클래스 분류
(false negative class)
(e)
Seagrass
잘못된 클래스 분류
(false negative class)
(f)
Draft mark
Seagrass
잘못된 클래스 분류
(false negative class)

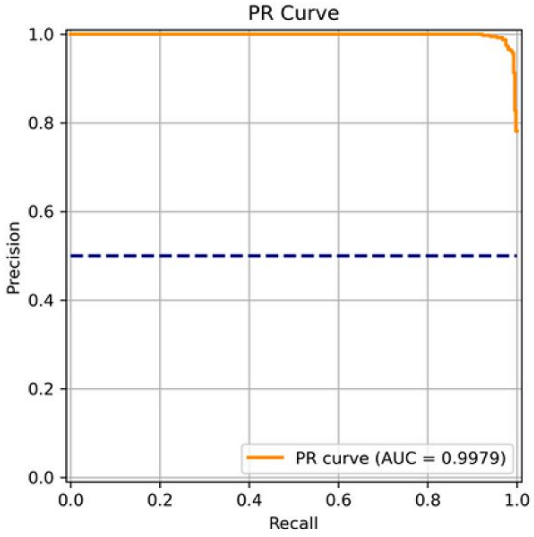
도면11

(a)



soft voting ensemble 분류

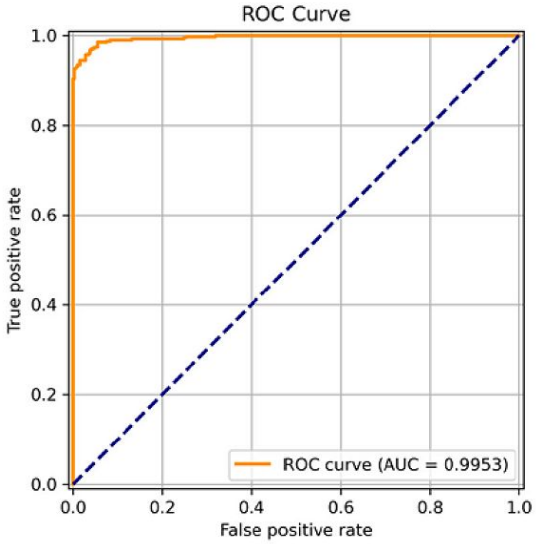
(b)



soft voting ensemble 분류

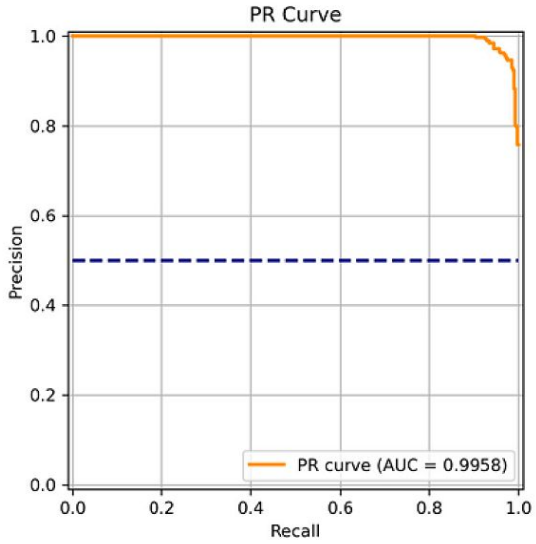
도면12

(a)



DenseNet

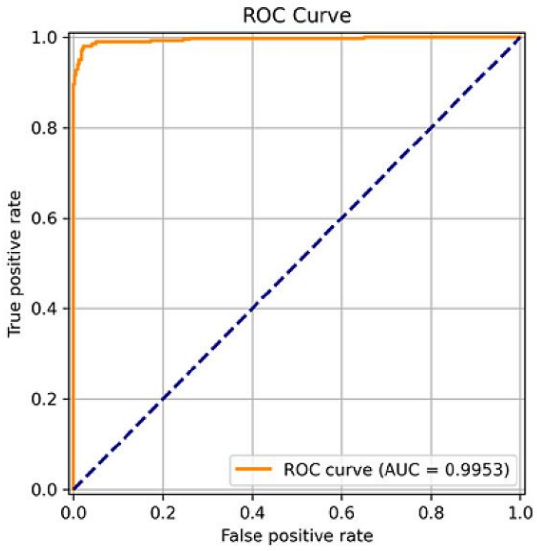
(b)



DenseNet

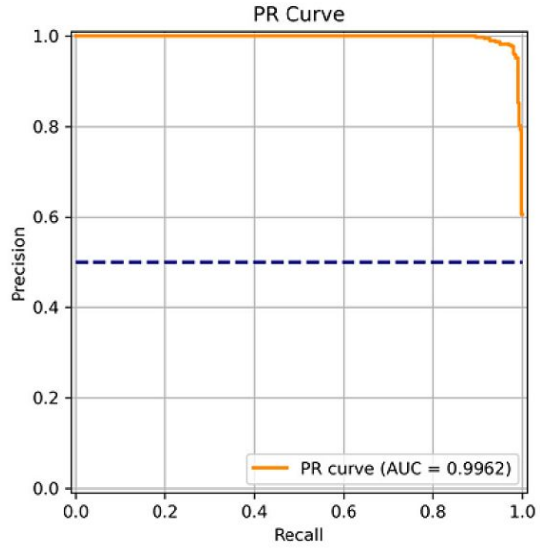
도면13

(a)



EfficientNet

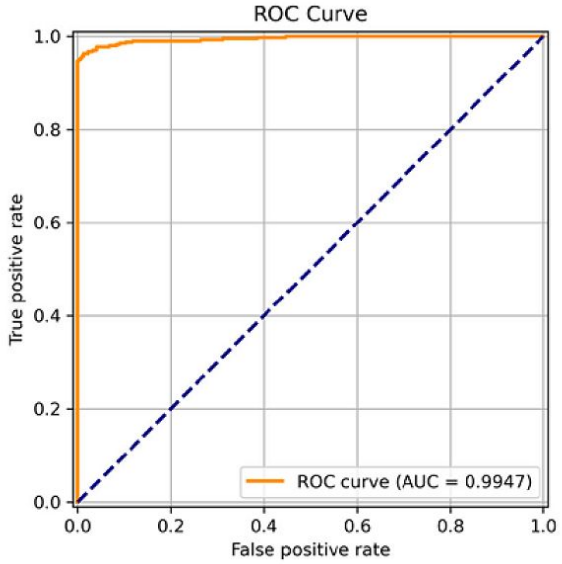
(b)



EfficientNet

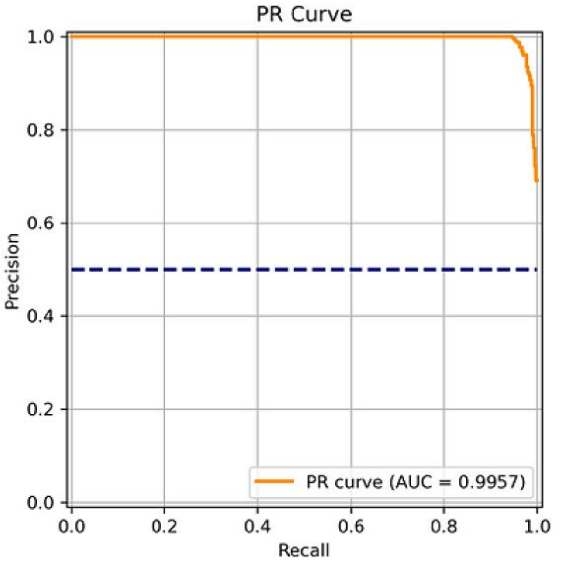
도면14

(a)



Inception

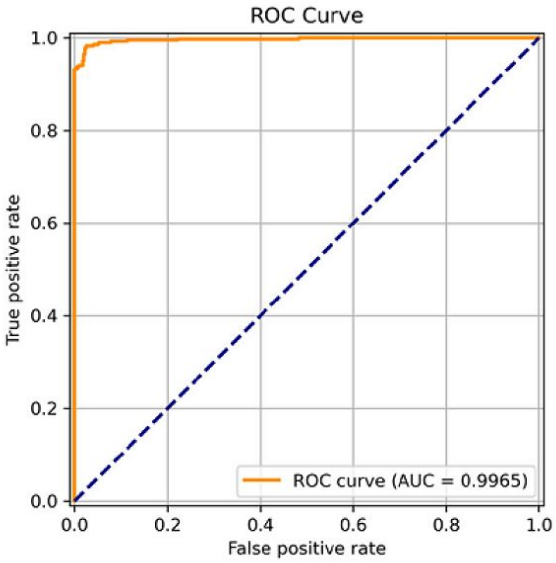
(b)



Inception

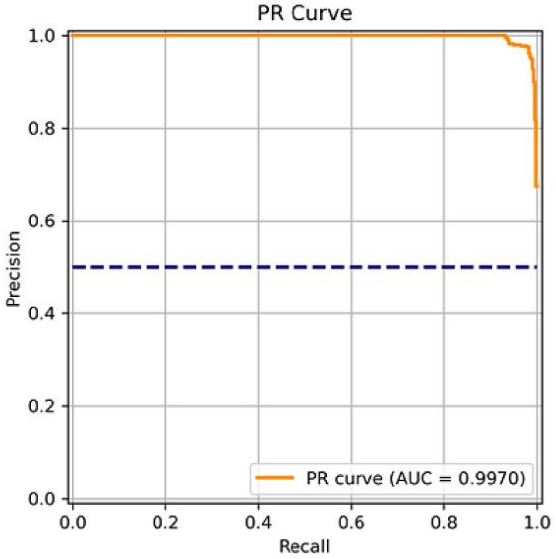
도면15

(a)



MobileNet

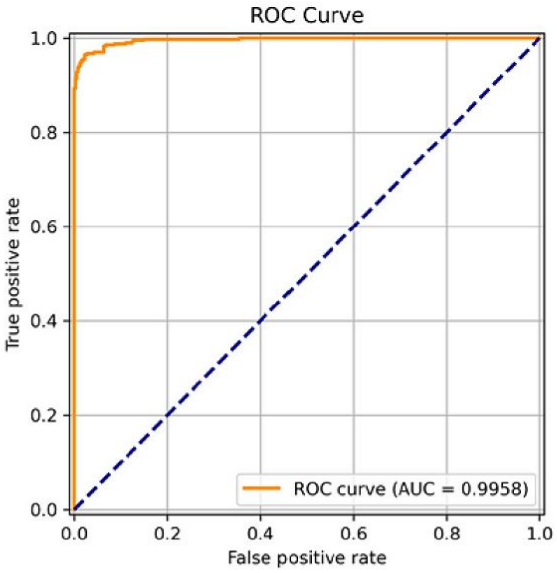
(b)



MobileNet

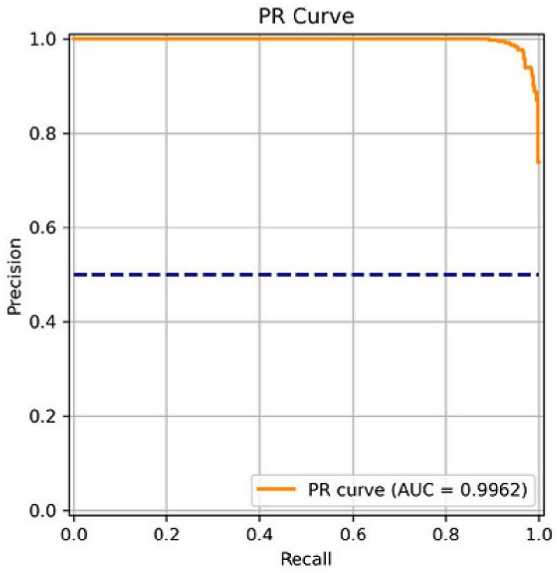
도면16

(a)



ResNet

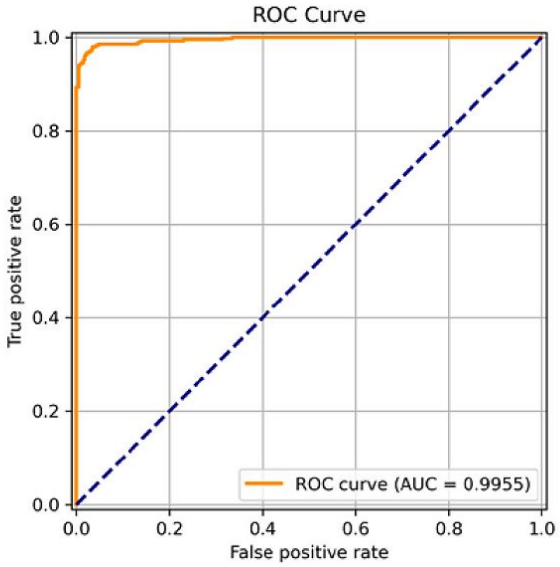
(b)



ResNet

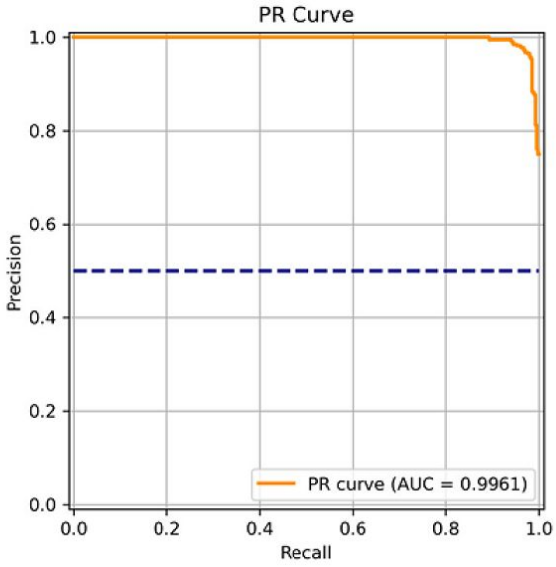
도면17

(a)



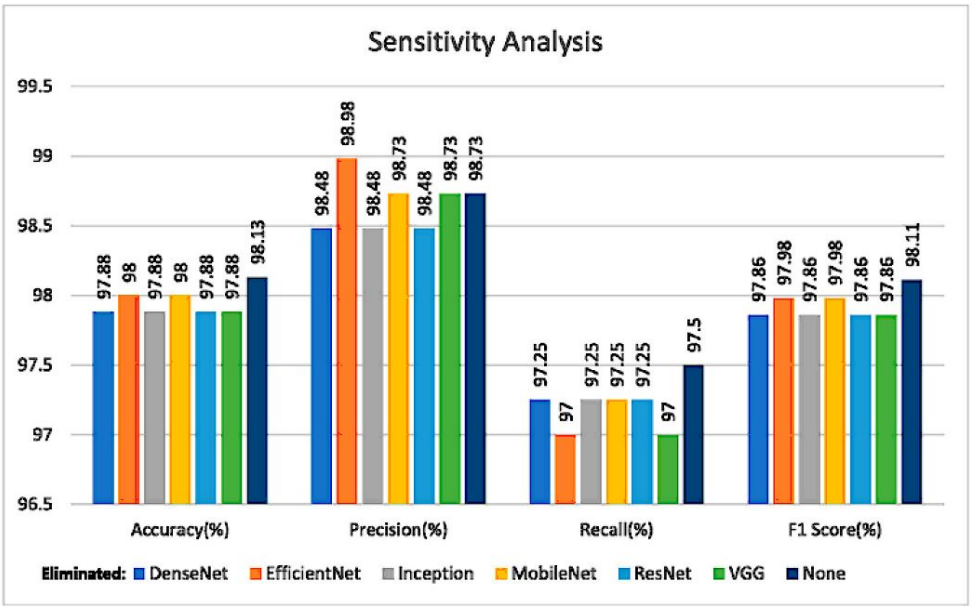
VGG

(b)



VGG

도면18


Sensitivity Analysis
99.5
99
98.5
98
97.5
97
96.5
97.88
98
97.88
98
97.88
97.88
98.13
98.48
98.98
98.48
98.73
98.48
98.73
98.73
97.25
97
97.25
97.25
97.25
97
97.5
97.86
97.98
97.86
97.98
97.86
97.86
98.11
Accuracy(%)
Precision(%)
Recall(%)
F1 Score(%)
Eliminated: DenseNet EfficientNet Inception MobileNet ResNet VGG None