



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0119731
(43) 공개일자 2024년08월06일

(51) 국제특허분류(Int. Cl.)

G01N 15/02 (2024.01) G01N 1/10 (2006.01)
G01N 15/14 (2024.01) G06N 3/04 (2023.01)
G06N 3/08 (2023.01)

(52) CPC특허분류

G01N 15/0227 (2024.01)
G01N 1/10 (2013.01)

(21) 출원번호 10-2023-0012097

(22) 출원일자 2023년01월30일
심사청구일자 2023년01월30일

(71) 출원인

충남대학교산학협력단

대전광역시 유성구 대학로 99 (궁동, 충남대학교)

주식회사 이담환경기술

대전광역시 중구 대둔산로350번길 107-9, 1층 (사정동)

(72) 발명자

장경선

세종특별자치시 대평로 56 해들마을5단지
516-1401

정지현

대전광역시 중구 대둔산로350번길 107-9

(74) 대리인

특허법인 신태양

전체 청구항 수 : 총 9 항

(54) 발명의 명칭 미세플라스틱 계수 장치


(57) 요약

본 발명은 미세플라스틱을 메쉬망으로 거른 후 메쉬망을 촬영한 이미지를 심층 학습 신경망으로 인식하여 미세플라스틱을 계수하는 미세플라스틱 계수 장치에 관한 것으로서, 완전연결층(Fully Connected Layer)을 중간에 배치한 개량된 U-Net 기반의 신경망으로 세그멘테이션(Segmentation)을 수행하고, 검출할 객체인 미세플라스틱에 상

(뒷면에 계속)

대표도 - 도4

세그멘테이션 신경망(200)



대적으로 큰 가중치를 부여한 손실 함수(Loss function)로 훈련시켜서, 메쉬망을 배경으로 처리하며 인식하기 쉽지 않은 미세플라스틱을 보다 정확하게 인식하며 적어도 크기별로 구분하며 계수할 수 있고 종류별로도 구분하며 계수할 수 있다.

본 연구는 2022년도 중소벤처기업부의 기술개발사업 지원에 의한 연구임 [S3250881](This work was supported by the Technology development Program(S3250881) funded by the Ministry of SMEs and Startups(MSS, Korea)).

(52) CPC특허분류

G01N 15/0272 (2013.01)

G01N 15/14 (2024.01)

G06N 3/04 (2023.01)

G06N 3/08 (2023.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1425163712
과제번호	S3250881
부처명	중소벤처기업부
과제관리(전문)기관명	중소기업기술정보진흥원
연구사업명	산학연CollaboR&D
연구과제명	미세플라스틱 신속 검출 및 판별 장비 개발
기 여 율	1/1
과제수행기관명	주식회사 이담환경기술
연구기간	2022.05.01 ~ 2022.12.31

명세서

청구범위

청구항 1

미세플라스틱이 걸러진 메쉬망의 이미지를 획득하는 이미지 획득부(100);

메쉬망 이미지를 입력받아 미세플라스틱의 영역을 픽셀 단위로 구분한 세그멘테이션(segmentation) 맵을 생성하는 세그멘테이션 신경망(200);

미세플라스틱의 경계상자(bounding box)를 추출하고, 미세플라스틱을 종류 구분하며 검출하는 객체검출 신경망(300);

검출한 미세플라스틱을 적어도 크기별로 분류하며 계수하는 계수부(400);

를 포함하되,

상기 세그멘테이션 신경망(200)은

인코더(encoder)와 디코더(decoder)에 스킵 커넥션(skip connection)을 실시한 U-Net 구조를 취하고, 인코더와 디코더를 연결하는 전환 구간(Bottle neck)에는 완전연결층(Fully Connected Layer)을 배치하며,

손실 함수(loss function) $L_{segmentation} = \lambda_{bce} L_{pos} + L_{neg}$ 를 사용하여 심층 학습(Deep learning)되며, 여기서, L_{pos} 는 미세플라스틱인 전경(foreground)에 대한 바이너리 크로스-엔트로피(binary cross-entropy) 손실이고, L_{neg} 는 메쉬망인 배경(background)에 대한 바이너리 크로스-엔트로피 손실이며, λ_{bce} 는 심층 학습에 사용되는 그라운드 트루쓰(ground truth)에서 전경과 배경의 픽셀 빈도 불균형에 따라 그라운드 트루쓰별로 가변 설정되는 가중치인

미세플라스틱 계수 장치.

청구항 2

제 1항에 있어서,

상기 가중치 λ_{bce} 는

그라운드 트루쓰에서 전경 픽셀 개수 대비 배경 픽셀 개수의 비율로 설정되는

미세플라스틱 계수 장치.

청구항 3

제 1항에 있어서,

상기 가중치 λ_{bce} 는

그라운드 트루쓰에서 전경 픽셀 개수 대비 배경 픽셀 개수의 비율에 사전 설정한 스케일 상수를 가중한 값으로 설정되는

미세플라스틱 계수 장치.

청구항 4

제 1항에 있어서,

상기 손실 함수는

그라운드 트루쓰에서의 픽셀 단위 전경 영역과 세그멘테이션 맵으로 예측된 픽셀 단위 전경 영역 사이의

IoU(intersection over union)의 역수를 손실 항목으로 추가한
미세플라스틱 계수 장치.

청구항 5

제 1항에 있어서,
전환 구간의 완전연결층은 적어도 2개 이상 배치한
미세플라스틱 계수 장치.

청구항 6

제 1항에 있어서,
전환 구간은 채널 수를 단계적으로 줄이는 컨볼루션 연산을 수행한 후 1차원 배열로 평탄화(flatten)하여 완전
연결층에 입력시키고, 완전연결층의 출력은 2차원 배열로 재정렬(reshape)하여 디코더로 임베딩하는
미세플라스틱 계수 장치.

청구항 7

제 6항에 있어서,
전환 구간에 직접 연결되어 가장 깊은 층에 해당되는 인코더의 마지막 단계 및 디코더의 첫번째 단계는 스킵 커
넥션을 생략하고, 대신에, 인코더의 마지막 단계에서는 컨볼루션 연산 중에 채널 수를 줄이고, 디코더의 첫번째
단계에서는 컨볼루션 연산 중에 채널 수를 늘려 업샘플링 없이 디코더의 두번째 단계에 전달할 수 있게 한
미세플라스틱 계수 장치.

청구항 8

제 1항에 있어서,
상기 세그멘테이션 신경망(200)의 인코더에서 적어도 첫번째 및 두번째 단계의 컨볼루션 레이어(Convolution
Layser)는
서로 다른 커널 크기(kernel Size)를 갖는 커널로 각각 추출한 특징맵(Feature Map)을 합하여 출력하는 모듈로
대체한
미세플라스틱 계수 장치.

청구항 9

제 8항에 있어서,
상기 모듈은 커널 크기가 5이하인 커널과 13이상인 커널을 사용하는
미세플라스틱 계수 장치.

발명의 설명

기술 분야

[0001] 본 발명은 미세플라스틱에 의한 수질 오염 정도를 평가하기 위해 취수한 시료에 포함된 미세플라스틱을 검출하
여 계수하는 장치에 관한 것으로서, 보다 상세하게는 미세플라스틱을 메쉬망으로 거른 후 메쉬망을 촬영한 이미
지를 심층 학습 신경망으로 인식하여 미세플라스틱을 계수하는 미세플라스틱 계수 장치에 관한 것이다.

배경 기술

[0002] 본 연구는 2022년도 중소벤처기업부의 기술개발사업 지원에 의한 연구임 [S3250881](This work was supported
by the Technology development Program(S3250881) funded by the Ministry of SMEs and Startups(MSS,
Korea)).

- [0004] 일반적으로 미세플라스틱은 5mm 미만 크기의 작은 플라스틱 조각을 말하는 것으로 미세플라스틱은 처음부터 미세플라스틱으로 제조되거나 또는 플라스틱 제품이 부서지면서 생성된다.
- [0005] 이러한 미세플라스틱은 일상생활에서 쉽게 접할 수 있는 치약, 세정제 또는 스크럽 등에 포함되어 있는데, 예컨대, 150ml 제품에는 대략 280만 개의 미세 플라스틱이 함유돼 있는 것으로 알려져 있으며, 미세플라스틱은 너무 작아 하수처리시설에 걸러지지 않고 바다와 강으로 그대로 유입되어 해양과 담수 환경에 존재한다.
- [0006] 2015년 사이언스지에 실린 <해양 플라스틱 쓰레기> 논문에 따르면, 2010년도에 바다로 유입된 플라스틱 쓰레기는 대략 480만~1,270만t으로 이 플라스틱은 폴리스틸렌(PS), 폴리에틸렌(PE), 폴리프로필렌(PP) 또는 나일론 등이 포함된 석유화합물이기 때문에, 다른 오염 물질과 만나 새로운 환경 문제를 야기하게 되며, 또 버려진 플라스틱이 시간이 지나면서 미세플라스틱으로 변하기도 한다. 2015년 영국에서 발표된 <해양 속 작은 플라스틱 쓰레기에 관한 국제 목록> 논문에 따르면, 바닷속에는 최소 15조에서 최대 51조 개의 미세플라스틱이 있는 것으로 추정된다.
- [0007] 상기와 같은 미세플라스틱은 환경을 파괴하는 것은 물론 인간의 건강을 위협한다는 점에서도 문제가 된다. 미세플라스틱을 먹이로 오인해 먹은 강·바다의 생물들을 결국 인간이 섭취하게 되기 때문이다. 미세플라스틱은 장폐색을 유발할 수 있으며 에너지 할당 감소, 성장 등에도 악영향을 미칠 수 있다.
- [0008] 미세플라스틱은 모양, 크기, 색상 등이 다양하기 때문에 형태를 특정하기 어렵다. 현재 미세플라스틱의 검출을 위한 전처리, 분석 프로토콜 및 방법은 정립되지 않은 상태이다 지속적으로 논의 중에 있다.
- [0009] 통상 미세플라스틱을 분석하기 위해서 해수 또는 담수 환경에서 시료를 채취하여 여과 및 체거름한 후 실체현미경으로 성분 분석하는 과정을 거치게 되므로, 시료의 특성에 따라 최소 1일에서 3일 이상 소요된다.
- [0010] 따라서 미세플라스틱의 분류 및 분석에 소요되는 시간을 획기적으로 단축하여 신속하게 판독이 가능하며, 종래 실험실에서만 행해지던 분석 과정을 탈피하여 현장에서도 즉석으로 신속하게 수행할 수 있는 미세플라스틱 검출기의 개발이 대두된다.
- [0011] 그런데, 미세플라스틱을 체거름하기 위해서 매우 작은 공극을 갖는 메쉬망을 사용하게 되므로, 도 1(a)에 예시한 메쉬망 촬영 사진에서 알 수 있듯이, 메쉬망에 남아 있는 매우 작은 미세플라스틱을 바탕에 해당하는 메쉬망과 구별이 잘 되지 않는 경우가 많다.
- [0012] 이와 같이 육안으로도 구별이 잘 되지 않으므로, 도 1(b)에 예시한 ground truth를 이용한 딥러닝과 같은 자동적인 방법을 사용하더라도 쉽게 인식하기 어렵고, 결국 계수 성능 향상을 시키기 어려운 특성을 가지고 있다.

선행기술문헌

특허문헌

- [0013] (특허문헌 0001) KR 10-2296894 (B1) 2021.08.26.
(특허문헌 0002) KR 10-2401716 (B1) 2022.05.20.

발명의 내용

해결하려는 과제

- [0014] 따라서, 본 발명의 목적은 미세플라스틱이 포함된 시료를 단계적으로 작은 공극을 갖는 다수의 메쉬망으로 걸러낸 후 촬영한 각 메쉬망의 촬영 이미지를 딥러닝 기반으로 자동 계수하는 미세플라스틱 계수 장치를 제공하는 것이다.

과제의 해결 수단

- [0015] 상기 목적을 달성하기 위해 본 발명은 미세플라스틱 계수 장치에 있어서, 미세플라스틱이 걸러진 메쉬망의 이미지를 획득하는 이미지 획득부(100); 메쉬망 이미지를 입력받아 미세플라스틱의 영역을 픽셀 단위로 구분한 세그멘테이션(segmentation) 맵을 생성하는 세그멘테이션 신경망(200); 미세플라스틱의 경계상자(bounding box)를

추출하고, 미세플라스틱을 종류 구분하며 검출하는 객체검출 신경망(300); 검출한 미세플라스틱을 적어도 크기 별로 분류하며 계수하는 계수부(400);를 포함한다.

[0016] 상기 세그멘테이션 신경망(200)은 인코더(encoder)와 디코더(decoder)에 스킵 커넥션(skip connection)을 실시한 U-Net 구조를 취하고, 인코더와 디코더를 연결하는 전환 구간(Bottle neck)에는 완전연결층(Fully Connected

Layer)을 배치하며, 손실 함수(loss function) $L_{segmentation} = \lambda_{bce} L_{pos} + L_{neg}$ 를 사용하여 심층 학습(Deep learning)되며, 여기서, L_{pos} 는 미세플라스틱인 전경(foreground)에 대한 바이너리 크로스-엔트로피(binary cross-entropy) 손실이고, L_{neg} 는 메쉬망인 배경(background)에 대한 바이너리 크로스-엔트로피 손실이며, λ_{bce} 는 심층 학습에 사용되는 그라운드 트루쓰(ground truth)에서 전경과 배경의 픽셀 빈도 불균형에 따라 그라운드 트루쓰별로 가변 설정되는 가중치이다.

[0017] 본 발명의 일 실시 예에 따르면, 상기 가중치 λ_{bce} 는 그라운드 트루쓰에서 전경 픽셀 개수 대비 배경 픽셀 개수의 비율로 설정된다.

[0018] 본 발명의 일 실시 예에 따르면, 상기 가중치 λ_{bce} 는 그라운드 트루쓰에서 전경 픽셀 개수 대비 배경 픽셀 개수의 비율에 사전 설정한 스케일 상수를 가중한 값으로 설정된다.

[0019] 본 발명의 일 실시 예에 따르면, 상기 손실 함수는 그라운드 트루쓰에서의 픽셀 단위 전경 영역과 세그멘테이션 맵으로 예측된 픽셀 단위 전경 영역 사이의 IoU(intersection over union)의 역수를 손실 항목으로 추가한다.

[0020] 본 발명의 일 실시 예에 따르면, 전환 구간의 완전연결층은 적어도 2개 이상 배치한다.

[0021] 본 발명의 일 실시 예에 따르면, 전환 구간은 채널 수를 단계적으로 줄이는 컨볼루션 연산을 수행한 후 1차원 배열로 평탄화(flatten)하여 완전연결층에 입력시키고, 완전연결층의 출력은 2차원 배열로 재정렬(reshape)하여 디코더로 임베딩한다.

[0022] 본 발명의 일 실시 예에 따르면, 전환 구간에 직접 연결되어 가장 깊은 층에 해당되는 인코더의 마지막 단계 및 디코더의 첫번째 단계는 스킵 커넥션을 생략하고, 대신에, 인코더의 마지막 단계에서는 컨볼루션 연산 중에 채널 수를 줄이고, 디코더의 첫번째 단계에서는 컨볼루션 연산 중에 채널 수를 늘려 업샘플링 없이 디코더의 두번째 단계에 전달할 수 있게 한다.

[0023] 본 발명의 일 실시 예에 따르면, 상기 세그멘테이션 신경망(200)의 인코더에서 적어도 첫번째 및 두번째 단계의 컨볼루션 레이어(Convolution Layer)는 서로 다른 커널 크기(kernel Size)를 갖는 커널로 각각 추출한 특징맵(Feature Map)을 합하여 출력하는 모듈로 대체한다.

[0024] 상기 모듈은 커널 크기가 5이하인 커널과 13이상인 커널을 사용한다.

발명의 효과

[0025] 상기와 같이 구성되는 본 발명은 메쉬망의 형상적 특징에 의해 미세플라스틱과 잘 구분되지 않는 메쉬망 이미지임에도 미세플라스틱을 메쉬망과 구분하며 인식할 수 있는 신경망 구조와 학습 방식을 갖추어, 다양한 모양, 크기, 색상 등을 갖는 미세플라스틱을 보다 정확하게 인식하여 종류 및 크기로 분류하며 계수할 수 있는 장점을 갖는다.

도면의 간단한 설명

[0026] 도 1은 미세플라스틱이 걸러진 메쉬망을 현미경으로 촬영하여 얻은 이미지(a)와, 해당 이미지에 대해 픽셀 레이블을 지정하여 얻은 그라운드 트루쓰(ground truth)의 이미지(b).

도 2는 본 발명의 실시 예에 따른 미세플라스틱 계수 장치의 블록도.

도 3은 이미지 세그멘테이션(segmentation) 모델로 사용되던 종래 U-Net의 아키텍처.

도 4는 본 발명에서 U-Net을 백본(BackBone)으로 개량한 세그멘테이션 신경망(200)의 아키텍처.

도 5는 인코더에서 첫번째 및 두번째 단계의 컨볼루션 레이어(Convolution Layer)를 대체하여 사용한 ADD 모듈의 아키텍처.

도 6은 본 발명의 실시 예에 따른 미세플라스틱 계수 장치를 훈련시킨 후 테스트한 결과를 보여주는 메쉬망 이미지, 그라운드 트루쓰(ground truth) 및 예측 결과 이미지.

도 7은 본 발명의 실시 예에 따른 미세플라스틱 계수 장치의 훈련 및 테스트 중에 얻은 재현율(Recall) 및 정밀도(Precision)를 보여주는 그래프.

발명을 실시하기 위한 구체적인 내용

- [0027] 이하, 본 발명의 실시 예들에 대하여 첨부한 도면을 참고로 하여 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 구체적이고 다양한 예시들을 보여주며 설명한다. 그러나, 본 발명의 실시 예들은 본 발명의 범위 내에서 다양한 변경이나 수정을 통해 실시될 수 있음은 분명하므로, 설명하는 실시 예들에 한정되지는 않는다. 그리고, 본 발명의 실시예들은 잘 알려진 구성요소, 방법, 전형적인 상세한 내용에 대해서는 본 발명이 속한 기술 분야에서 통상의 지식을 가진 자가 추가하여 실시할 수 있으므로, 자세히 기술하지 않기로 한다.
- [0028] 어떤 구성요소를 ‘포함’ 한다는 것은 특별히 반대되는 기재가 없는 한 다른 구성요소를 제외하는 것이 아니라 다른 구성요소를 더 포함할 수 있다는 것을 의미한다.
- [0029] 본 발명의 실시 예는 소프트웨어와 하드웨어가 결합된 형태로 구현되어 심층 학습(Deep learning)되는 신경망에 의해 데이터 처리되게 하며, 부분적 구성요소를 모듈, 부 등으로 기술될 수 있고, 예를 들어 프로세서, 디스플레이, 메모리, 입력 장치, 데이터 인터페이스등과 같은 데이터를 입력, 처리 및 출력하는데 필요한 컴포넌트들을 포함한 컴퓨팅 장치로 구현될 수 있고, 기록매체에 구현된 컴퓨터에서 읽을 수 있는 프로그램 코드의 형태로 구현될 수도 있다.
- [0031] 도 2은 본 발명의 일 실시 예에 따른 미세플라스틱 계수 장치의 블록도이다.
- [0032] 도 2를 참조하면, 본 발명의 미세플라스틱 계수 장치는 미세플라스틱이 걸러진 메쉬망을 촬영한 메쉬망 이미지를 처리하여 미세플라스틱을 종류별 및 크기별로 구분하며 계수하기 위한 것으로서, 이를 위해서, 메쉬망 이미지를 획득하는 이미지 획득부(100)와, 획득한 메쉬망 이미지를 입력 처리하여 세그멘테이션(segmentation) 맵을 생성 출력하는 세그멘테이션 신경망(200)과, 미세플라스틱을 포착하여 종류를 구분하며 검출하는 객체검출 신경망(300)과, 세그멘테이션 신경망(200) 및 객체검출 신경망(300)의 처리 결과를 이용하여 미세플라스틱을 종류별 및 크기별로 구분하며 계수하는 계수부(400)와, 세그멘테이션 신경망(200) 및 객체검출 신경망(300)을 심층 학습(Deep learning)시키기 위한 훈련부(500)를 포함한다.
- [0033] 구체적인 실시 예에 따르면, 상기 이미지 획득부(100)는 하수, 폐수, 하폐수처리시설의 방류수, 하천수, 담수, 해양수 등에서 채취한 시료를 메쉬망으로 필터링하여 미세플라스틱을 걸러내는 미세플라스틱 포집기(10)에서 미세플라스틱이 걸러진 메쉬망을 촬영한 이미지를 입력받는다. 하지만, 이에 한정하는 것은 아니고, 상기 이미지 획득부(100)는 미세플라스틱 포집기(10)에 설치한 촬영수단(13)일 수 있고, 또는 촬영수단(13)을 설치한 미세플라스틱 포집기(10)로 구성하여서, 본 발명의 미세플라스틱 계수 장치이 미세플라스틱 포집기(10)와 일체화하여 하나의 장치로 구성할 수도 있다.
- [0034] 여기서, 미세플라스틱 포집기(10)는 공극의 큰 순서로 배치한 다단의 메쉬망(12)에 시료를 통과시켜서, 미세플라스틱이 크기에 따라 분리되며 걸러진 메쉬망(12)의 이미지를 얻게 할 수 있다. 이를 위해서, 공극이 서로 다른 메쉬망(12)이 내부에 구비된 복수의 검출통(11)을 공극 크기 순서로 배치되게 다단으로 적층하고, 공극이 가장 큰 메쉬망(12)이 구비된 검출통(11)을 통해 시료를 투입하게 한다. 유기물을 제거하기 위한 과산화수소 시약, 미세플라스틱을 염색하기 위한 염료 시약, 및 세척을 위한 염산 시약을 순차적으로 투입할 수 있다. 여기서 염료는 걸러진 다른 이물질과 구분하며 미세플라스틱을 인식하기 좋게 하는 것으로서, 다양한 종류의 미세플라스틱을 염색할 수 있는 염료를 사용한다.
- [0035] 그리고, 각 검출통(11)을 개별적으로 분리하거나 회동시키며 메쉬망(12)을 촬영하여, 미세플라스틱이 크기별로 걸러진 메쉬망 이미지를 얻을 수 있다. 이때, 촬영수단(13)은 이동시켜 검출통(11) 내의 메쉬망(12)을 근접 촬영하는 현미경을 사용함으로써, 마이크로 단위의 크기를 갖는 미세플라스틱도 포착할 수 있게 하는 것이 좋다.
- [0037] 상기 세그멘테이션 신경망(200)은 상기 이미지 획득부(100)에서 획득한 메쉬망 이미지를 입력받아 미세플라스틱

의 영역을 픽셀 단위로 구분할수 있도록 분할한 세그멘테이션 맵(Segmentation Map)을 생성하여 출력한다. 본 발명에 따르면, 상기 세그멘테이션 신경망(200)은 컨볼루션 네트워크 기반의 이미지 세그멘테이션 모델로 사용되는 U-Net의 구조를 취하되, 미세플라스틱과 구분하기 쉽지 않은 메쉬망을 배경으로 처리하며 미세플라스틱을 인식하도록 개량한다.

[0038] 상기 객체검출 신경망(300)은 미세플라스틱에 대해 경계상자(bounding box)를 추출하여 위치를 포착하고, 미세플라스틱을 종류별로 분류하며 검출한다. 여기서 분류는 예를 들어 입자형과 섬유형의 분류를 포함할 수 있다. 이러한 객체검출 신경망(300)은 faster-RCNN이나 transformer 기반의 DETR(End to End Object Detection with Transformers)와 같은 잘 알려진 신경망을 사용할 수 있으므로, 상세 설명을 생략한다.

[0039] 한편, 상기 객체검출 신경망(300)은 상기 세그멘테이션 신경망(200)에서 출력하는 세그멘테이션 맵을 사용하는 것으로 도시하였으나, 이에 한정하는 것은 아니며, 상기 이미지 획득부(100)에서 획득한 메쉬망 이미지를 입력받아 미세플라스틱의 위치 및 종류를 찾도록 구성할 수도 있음은 자명하다.

[0040] 상기 계수부(400)는 상기 세그멘테이션 신경망(200)과 객체검출 신경망(300)에서 출력하는 결과물에 따라 미세플라스틱을 적어도 크기별로 분류하며 개수를 계수한다. 추가적으로 미세플라스틱을 종류별로 분류하며 계수할 수도 있다. 예를 들어, 검출한 미세플라스틱을 픽셀 단위의 맵을 이용하여 크기별로 분류하며 계수할 수 있고, 검출한 미세플라스틱을 종류별로 분류한 후 픽셀 단위의 맵을 이용하여 크기별로 계수할 수 있다.

[0041] 한편, 서로 다른 크기의 공극을 갖는 메쉬망으로 미세플라스틱을 걸러낸 후 촬영한 메쉬망 이미지를 처리하여 인식하므로, 다양한 크기 및 형상의 미세플라스틱을 더욱 잘 인식할 수 있게 된다.

[0042] 이에 더하여, 상기 계수부(400)는 각 메쉬망 이미지별로 미세플라스틱의 계수 결과를 생성하게 할 수도 있다.

[0043] 또한, 상기 계수부(400)는 각 메쉬망 이미지를 처리하여 인식한 미세플라스틱을 크기별로 계수하고, 이후 각 메쉬망 이미지의 공극 크기에 따라 검증하고 수정할 수도 있다. 예를 들어, 인식한 미세플라스틱의 크기 또는 성상이 공극을 통과할 정도인 경우, 인식 오류로 판단하여 계수 결과에서 감산 처리할 수 있다.

[0045] 상기 훈련부(500)는 사전 준비된 학습 데이터 셋을 사용하여 상기 세그멘테이션 신경망(200)과 객체검출 신경망(300)을 심층 학습시키며, 잘 알려진 바와 같이 이때의 학습 데이터 셋은 모델 훈련을 위한 데이터와 모델 테스트를 위한 데이터로 구분될 수 있다.

[0046] 심층 학습 과정에서 손실 함수(Loss Function)는 아래의 수학적 식 1에 예시한 바와 같이 세그멘테이션 손실 $L_{segmentation}$ 과 객체검출 손실 $L_{detection}$ 을 가중치 α 를 부여하며 합산하는 함수를 사용할 수 있다.

수학적 식 1

$$L = (1 - \alpha) \times L_{segmentation} + \alpha \times L_{detection}$$

[0048] 여기서, 가중치 α 는 0~1 사이의 값이고, 0.5일 때에는 동일한 가중치를 부여하게 된다.

[0049] 하지만, 손실 함수는 상기 수학적 식 1에 한정하는 것은 아니며, 세그멘테이션 신경망(200) 및 객체검출 신경망(300)을 각각의 손실에 따라 개별적으로 훈련시킬 수도 있다.

[0051] 그런데, 도 1을 참조하며 살펴본 바와 같이, 미세플라스틱은 인식할 전경(foreground)에 해당되는 것으로서 크기, 모양, 색상 등이 다양하여 과산화수소 시약으로 제거되지 않고 메쉬망에 잔류하는 다른 이물질과 구분하기 쉽지 않고, 더욱이, 마이크로(micro) 단위의 크기를 갖는 것도 인식하여야 하지만, 배경(background)에 해당되는 메쉬망과 잘 구분되지 아니하여서, 세그멘테이션 과정에서 인식률이 저하되는 문제가 발생할 수 있고, 결국 계수 결과의 신빙성을 보장하기 어렵게 된다.

[0052] 이에 본 발명에 따른 미세플라스틱 계수 장치에서 상기 세그멘테이션 신경망(200)은 U-Net을 백본(BackBone)으로 개량한 구조를 취하고, 미세플라스틱에 대해 WBCE(weighted binary cross-entropy) 손실과 IoU(intersection over union)의 역수로 적용한 손실을 항목으로 갖는 손실 함수(loss function)를 사용하여

훈련시켜서, 메쉬망에 걸러진 미세플라스틱을 잘 인식한 세그멘테이션 맵을 얻게 한다.

- [0054] 이하, 본 발명의 특징적인 세그멘테이션 아키텍처와 훈련(train)을 위한 손실 함수(Loss function)에 대해 상세히 설명한다.
- [0056] < 세그멘테이션 신경망(200)의 아키텍처 >
- [0057] 본 발명에 따르면, 상기 세그멘테이션 신경망(200)은 서로 다른 커널 크기(kernel Size)를 갖는 커널로 각각 추출한 특징맵(Feature Map)을 합하여 출력하는 모듈(211)을 U-Net 구조의 인코더(210)의 초기 단계에 사용한다. 이를 통해, 미세플라스틱의 형상(shape) 및 텍스처(texture)를 잘 포착한 특징 맵(feature map)을 이용할 수 있게 한다.
- [0058] 또한, U-Net 신경망 구조의 중간에 완전연결층(Fully Connected Layer, 231)을 사용한다. 이를 통해, 필요 이상의 연산량은 줄이면서 전역적 특징을 반영하여, 미세플라스틱의 분할 구역의 크기 및 경계를 보다 명확하게 하며, 결국 재현율(Recall)은 잘 살리면서 정밀도(Precision)을 향상시킨다.
- [0059] 이와 같이 개량된 구조를 종래 U-Net과 비교하며 설명하기 위해서, 종래 U-Net에 대해 먼저 살펴본다.
- [0061] 도 3은 이미지 세그멘테이션(Segmentation) 모델로 사용되던 종래 U-Net의 구조를 개략적으로 나타내는 아키텍처이다.
- [0062] U-Net은 대표적인 세그멘테이션(Segmentation) 기법 중 하나로서, 기본적으로 대칭적으로 배치하여 'U'자 형태의 구조를 형성하는 인코더(Encoder, 1)와 디코더(decoder, 2)를 포함한다.
- [0063] 인코더(1)는 복수의 컨볼루션 레이어 블록을 직렬 접속하여 다단의 구조를 갖게 구성된다. 각각의 컨볼루션 레이어 블록은 3*3 커널 크기(kernel size)를 사용하는 2개의 컨볼루션 레이어(Convolution Layer)에 의해 2차례 3*3 컨볼루션 연산을 연속 수행하여, 이미지의 컨텍스트(context)를 포착한 특징 맵(feature map)을 생성하고, 다음으로 특징 맵을 다운샘플링(downsampling, 또는 최대 풀링(max-pooling))하여 다음 단계로 넘기게 하여서, 맵의 크기는 감소시키고 채널(channel)은 증가시키는 수축 경로(contracting path)를 형성하게 한다. 여기서, 3*3 컨볼루션 연산을 하는 컨볼루션 레이어는 배치 정규화(batch normalization)와 ReLU(Rectified Linear Unit) 활성화 함수 연산도 수행한다.
- [0064] 한편, 인코더(1)의 마지막 단계에서 다운 샘플링하며 넘겨진 특징 맵은 인코더(1)와 디코더(2)를 연결하는 전환 구간(Bottle Neck, 3)을 통해 디코더(3)에 임베딩(Embedding)된다. 이런 전환 구간(3)에서도 일반적으로 3*3 컨볼루션 연산을 2차례 연속 수행한다.
- [0065] 디코더(3)는 인코더와 동일한 개수의 컨볼루션 레이어 블록을 인코더(1)와 대칭을 이루도록 직렬 접속한 다단 구조를 갖추되, 다운샘플링 대신에 임베딩된 특징 맵을 업샘플링(upsampling) 및 스킵 커넥션(skip connection)을 실시하며 각 블록으로 순차적으로 처리하여서, 맵의 크기는 증가시키면서 채널은 감소시키는 팽창 경로(expansive path)를 형성한다. 즉, 각 단계에서는 우선적으로 업샘플링한 후 수축 경로의 각 단계에서 생성된 특징 맵 중에 동일 레벨(level)의 특징 맵과 합치고(concatenation), 컨볼루션 레이어 블록에 의한 컨볼루션 연산을 수행한다. 이에, 맵의 크기를 입력 이미지의 크기로 복원하는 팽창 경로(expansive path)를 형성함은 물론이고, 스킵 커넥션(skip connection)을 통해 수축 경로의 동일 레벨에서 생성된 특징 맵의 컨텍스트와 결합하게 한다. 이러한 스킵 커넥션은 컨텍스트를 픽셀 위치 정보와 결합하여 지역화(localization)의 정확도를 높일 수 있다.
- [0066] 디코더(2)의 마지막 단계에 있는 컨볼루션 레이어 블록의 출력 측에는 1*1 컨볼루션 레이어를 배치하여 차원을 줄인 세그멘테이션 맵을 생성하여 출력되게 한다. 이때의 1*1 컨볼루션 레이어는 1*1 컨볼루션 연산을 수행한 후 일반적으로 sigmoid 활성화 함수로 처리한다.
- [0068] 다음으로, 종래 U-Net 구조와 대비되는 구조는 갖는 본 발명의 상기 세그멘테이션 신경망(200)에 대해 설명한다.

- [0069] 도 4는 본 발명에서 U-Net을 백본(BackBone)으로 개량한 세그멘테이션 신경망(200)의 아키텍처이다. 도 4를 도 3의 종래 U-Net과 비교하며 참조할 시에는 각 레이어를 텍스트로 표현한 점을 고려하며 참조하면 된다.
- [0070] 도 4를 참조하면, 인코더(210)와 디코더(220)를 연결하는 전환 구간(Bottle Neck, 3)에 완전연결층(Fully Connected Layer, 231)을 배치하여, 인코더(210)에서 디코더(220)로 임베딩하는 특징 맵의 2차원 배열을 1차원 배열로 평탄화(flatten, 235)한 후 완전연결층(231)을 통해 처리되게 하고, 완전연결층(231)에서 출력되는 1차원 배열을 다시 2차원 배열로 재정렬(reshape, 236)한 후 디코더로 임베딩되게 한다.
- [0071] 여기서, 완전연결층(231)은 노드(node) 사이의 면밀한 정보 교환을 유도하며, 이를 통해 디코더(220)에서 전역적 특징을 잘 반영하며 맵을 재구성할 수 있게 하고, 적어도 2개 이상 배치하여 재구성 성능을 향상시키는 것이 바람직하다.
- [0072] 한편, 도 4에 예시한 본 발명의 구체적인 실시 예에 따르면, 전환 구간(Bottle Neck, 230)은 인코더(210)의 가장 깊은 층에서 생성된 특징 맵을 2개의 컨볼루션 레이어(232)로 연산 후 1*1 커널을 사용하는 2개의 컨볼루션 레이어(233, 234)로 단계적으로 채널 수를 줄인 후 평탄화(flatten, 235)하여 완전연결층(231)로 처리되게 하였다. 아울러, 인코더(210)의 가장 깊은 층과 디코더(220)의 가장 깊은 층은 스킵 커넥션을 생략하고, 대신에 평탄화(235)하기 전의 채널 감소와 2차원 배열로의 재정렬(reshape, 236)에 기여하게 하였다.
- [0073] 보다 상세하게 설명하면, 도면에 예시한 바와 같이 512*512*3 크기의 메쉬망 이미지를 입력받아 인코더(210)의 첫번째 단계의 컨볼루션 레이어 블록에 의해 512*512*35 특징 맵을 생성하고, 이후, 단계를 넘어갈 때마다 최대-풀링(max-pooling)하여, 크기는 1/2씩 줄어들고 채널을 2개씩 증가하는 특징 맵이 생성된다. 다만, 인코더(210)의 가장 깊은 층인 4번째 단계에서는 첫번째 컨볼루션 연산에 의해 64*64*256 맵이 생성되게 하지만, 두번째 컨볼루션 레이어(212)로 컨볼루션 연산할 시에 채널을 절반으로 줄여 64*64*128 특징 맵을 생성되게 하며, 스킵 커넥션을 생략하고, 최대-풀링만 수행하여 전환 구간(230)으로 넘긴다.
- [0074] 전환 구간(230)에서는 2회 컨볼루션 연산(232)할 시에 채널을 절반으로 줄여 32*32*64 맵을 생성한 후 1*1 커널을 사용한 2회 컨볼루션 연산(233, 234)을 수행하여 32*32*32 맵 및 32*32*4 맵으로 순차 변환하고, 32*32*4 맵을 1차원 벡터로 평탄화(flatten, 235)하여 완전연결층(231)에 입력되게 한다. 완전연결층(231)의 1차원 배열 출력은 2차원 배열로 재정렬(reshape, 236)하여 디코더(220)의 가장 깊은 층에 임베딩한다.
- [0075] 여기서, 완전연결층(231)은 32*32*4 맵을 입력받기 위해 4096개의 입력 노드를 구비하며, 출력 노드와 입력 노드를 동일 개수로 구비하고, 출력은 채널 수가 1인 2차원 배열로 재정렬(reshape, 236)하여 64*64*1 맵으로 디코더(220)에 임베딩한다.
- [0076] 이에, 디코더(220)의 가장 깊은 층인 첫번째 단계의 컨볼루션 레이어 블록(221, 222)은 임베딩되는 1채널의 64*64*1 맵을 업샘플링(도면에는 'Resize'로 표시)하여 128*128*1 맵을 처리하게 하였다. 다시 말해서, 가장 깊은 층의 레벨이 아니고, 두번째로 깊은 층에 해당되는 두번째 단계의 레벨의 맵을 처리하게 하고, 앞서 언급하였듯이 이 레벨에서는 스킵 커넥션을 생략하며, 대신에, 2회의 컨볼루션 연산(221, 222)을 할 시에 채널 수를 64 및 128로 순차 증가시킨다. 즉, 두번째 단계의 레벨에 맞춰 맵을 생성하여 업샘플링 없이 전달할 수 있는 맵을 생성하여 넘겨주게 한다.
- [0077] 이와 같이, 전환 구간(230)에 직접 연결되어 가장 깊은 층에 해당되는 인코더(210)의 마지막 단계 및 디코더(220)의 첫번째 단계를 병행하여 스킵 커넥션을 생략하고 채널 수를 단계적으로 조절하여 완전연결층(231)에 접속되게 하며, 이를 통해, 정보 손실을 줄이고, 완전연결층(231)을 추가함에도 연산량 증가를 최소화하며, 훈련 속도의 향상을 도모할 수 있다.
- [0078] 한편, 도 4에 표시한 바와 같이 인코더(210), 전환 구간(230) 및 디코더(220)에서 사용되는 컨볼루션 레이어는 분리형 컨볼루션(Separable Convolution, 도면에는 'Separable Conv2D') 레이어를 적용하여, 연산량은 줄이고 훈련 속도는 높인다. 커널 크기는 별도 표시하지 않은 경우 일반적으로 사용되는 커널로서 예를 들어 3*3 크기의 커널을 사용할 수 있고, 배치 위치에 따라 커널의 채널 수를 적절하게 하고, 배치 정규화와, 도시하지 아니한 ReLU 활성화 연산을 적절한 수행하게 한다. 디코더(220)의 마지막 단계에서 재구성한 맵을 출력할 시에는 컨볼루션 레이어(Convolution Layer)에 의해 1채널의 세그멘테이션 맵으로 출력하며, 여기서, 시그모이드(sigmoid) 활성화 함수를 사용할 수 있다.
- [0080] 도 4를 다시 살펴보면, 인코더(210)에서 적어도 첫번째 및 두번째 단계의 컨볼루션 레이어 블록을 구성하는 2개

의 컨볼루션 레이어(Convolution Layer)는 'ADD Module'로 명명한 ADD 모듈(211)로 대체된다.

[0081]

도 5는 상기 ADD 모듈(211)의 아키텍처이다.

[0082]

도 5를 참조하면, 상기 ADD 모듈(211)은 서로 다른 커널 크기(kernel Size)를 갖는 커널을 사용하는 2개의 컨볼루션 레이어(211a, 211b)로 각각 특징 맵(Feature Map)을 추출한 후 합하여 출력한다.

[0083]

여기서, 2개의 컨볼루션 레이어(211a, 211b) 중에 어느 하나의 컨볼루션 레이어(211b)의 커널은 5이하의 커널 크기를 갖고, 다른 하나의 컨볼루션 레이어(211a)의 커널은 13이상의 커널 크기를 갖는 것이 바람직하다. 도 5에 도시한 구체적인 실시 예에서 컨볼루션 레이어(211a, 211b)는 커널 크기가 5 및 21인 커널을 사용하여 각각 연산한 후 배치 정규화를 실시하며, 도시하지는 아니하였지만, ReLU 활성화 함수로 처리할 수 있다.

[0084]

종래 U-Net 구조와 대비하면, 종래에는 3*3 커널을 사용하는 하나의 레이어로 연산하지만, 본 발명에서는 적어도 13*13 커널을 사용한 레이어를 추가하여 병렬적으로 연산한 후 합한다.

[0085]

이와 같이, 13이상의 크기를 갖는 커널을 사용하는 컨볼루션 레이어(211a)를 병렬적으로 추가함으로써, 크기, 모양, 색상 등이 다양한 미세플라스틱의 특징을 잘 포착할 수 있고, 특히, 크기 및 모양의 차이가 심하게 나는 입자형 및 섬유형의 미세플라스틱의 특징을 모두 잘 포착하여서, 세그멘테이션의 성능 향상을 도모할 수 있다.

[0086]

한편, 디코더(220)의 출력 측인 마지막 단계에서 컨볼루션 연산을 수행하기에 앞서 ADD 모듈(223)로 처리되게 하였는데, 이는 맵의 재구성 성능을 도모하기 추가한 것이며, 훈련 및 테스트 결과에 따라 생략할 수도 있다.

[0087]

도 4에서 디코더에 표시한 'ADD'는 U-Net에서 잘 알려진 바와 같이 업샘플링(도면에서 'Resize')하며 스킵 커넥션에 의해 수축 경로의 특징 맵의 컨텍스트를 결합(concatenation)하는 것을 의미한다.

[0089]

< 세그멘테이션 신경망(200)의 트레이닝 >

[0090]

상기 세그멘테이션 신경망(200)의 학습을 위한 세그멘테이션 손실 $L_{segmentation}$ 은 미세플라스틱의 예측에 대한 가중치 기반 바이너리 크로스-엔트로피(WBCE : weighted binary cross-entropy) 손실 L_{wbce} 와, IoU(intersection over union)에 따라 추가한 손실 L_{IoU} 을 손실 항목으로 갖게 하며, 다음과 같은 손실 함수로 표현할 수 있다.

수학식 2

[0091]

$$L_{segmentation} = L_{wbce} + L_{IoU}$$

[0092]

본 발명에 따르면, 미세플라스틱의 예측에 대한 손실 L_{wbce} 는 아래의 수학식 3으로 표현한 바 같이 미세플라스틱의 예측에 대한 바이너리 크로스-엔트로피(binary cross-entropy) 손실에 상대적으로 큰 가중치 λ_{bce} 를 부여한다.

수학식 3

[0093]

$$L_{wbce} = \lambda_{bce} L_{pos} + L_{neg}$$

[0094]

여기서, L_{pos} 는 미세플라스틱인 전경(foreground)의 예측에 대한 바이너리 크로스-엔트로피(binary cross-entropy) 손실이고, L_{neg} 는 메쉬망인 배경(background)의 예측에 대한 바이너리 크로스-엔트로피 손실이며, 아래의 수학식 4와 같이 구체적으로 표현할 수 있다.

수학식 4

$$L_{pos} = \sum_{p=1}^P y_{true}(p) \log y_{pred}(p)$$

$$L_{neg} = \sum_{p=1}^P (1 - y_{true}(p)) \log(1 - y_{pred}(p))$$

수학식 4에서, p 는 그라운드 트루쓰(ground truth)에서의 픽셀 위치를 나타내고, $y_{true}(p)$ 는 그라운드 트루쓰(ground truth)에서 픽셀 p 의 값으로서 미세플라스틱으로 레이블된 픽셀인 경우에 1이고 그외에는 0이며, $y_{pred}(p)$ 는 세그멘테이션 신경망(200)에서 출력된 세그멘테이션 맵에서 픽셀 p 의 값으로서 세그멘테이션 신경망(200)으로 예측한 값이 된다.

수학식 3에서, 가중치 λ_{bce} 는 배경(background)의 예측에 대한 손실 L_{neg} 에 비해 전경(foreground)의 예측에 대한 손실 L_{pos} 에 상대적으로 큰 가중치를 부여하기 위한 것으로서, 그라운드 트루쓰(ground truth)에서 전경과 배경의 픽셀 빈도 불균형에 따라 그라운드 트루쓰별로 가변 설정된다.

즉, 배경에 해당되는 메쉬망보다 전경에 해당되는 미세플라스틱이 차지하는 면적이 매우 적은 관계로, 이를 반영하여 전경에 상대적으로 큰 가중치를 부여하여 학습이 잘되게 한다. 특히, 메쉬망은 규칙적인 패턴을 보이고, 메쉬망의 공극(또는 망눈)의 형상과 유사한 형태의 미세플라스틱이 걸러질 시에 인식하기 쉽지 않으므로, 이를 고려하여 잘 학습되게 하는 것이다.

더욱이, 다양한 모양, 크기, 색상 등을 갖는 미세플라스틱이 서로 다른 수량으로 분산되어 걸리진 메쉬망 이미지를 고려하여, 훈련을 위한 각 메쉬망 이미지의 그라운드 트루쓰별로 가변 설정함으로써, 잘 학습시킬 수 있다.

이러한 가중치 λ_{bce} 는 그라운드 트루쓰에서 전경 픽셀 개수 대비 배경 픽셀 개수의 비율로 설정하여서 매우 큰 값으로 가중되게 하는 것이 바람직하며, 아래와 같이 표현된다.

수학식 5

$$\lambda_{bce} = \frac{\sum_{p=1}^P (1 - y_{true}(p))}{\sum_{p=1}^P (y_{true}(p))}$$

수학식 4와 마찬가지로, p 는 그라운드 트루쓰(ground truth)에서의 픽셀을 나타내고, $y_{true}(p)$ 는 그라운드 트루쓰(ground truth)에서 픽셀 p 의 값이다.

변형 실시 예로서, 반복적 경험에 따라 정한 스케일 상수를 사전 설정하여 두어서, 전경 픽셀 개수 대비 배경 픽셀 개수의 비율에 스케일 상수를 곱셈한 값을 가중치 λ_{bce} 의 값으로 설정할 수도 있다.

한편, 전경 픽셀 개수는 배경 픽셀 개수에 비해 너무 적은 경우, 가중치 λ_{bce} 이 너무 큰 값을 갖게 되므로, 가중치 λ_{bce} 의 상한값을 제한할 수 있는 값을 사용하는 것이 좋다.

그런데, 가중치 λ_{bce} 로 가중한 손실을 사용함으로써, 재현율(Recall)을 향상시킨 결과를 얻을 수 있었으나, 정밀도(Precision)는 가중치의 증가에 따라 저하되는 경향을 보였다. 즉, 가중치 λ_{bce} 를 올려 위치는 잘 잡는데

비해, 과도하게 올리면 너무 큰 영역을 미세플라스틱으로 예측하는 경향을 보였다.

[0108] 이에, 본 발명의 실시 예에서는 재현율(Recall)의 손상을 최대한 줄이면서 정밀도(Precision)를 향상시키기 위해서, 수학식 2에서 보여준 바와 같이 IoU(intersection over union)를 적용한 손실 L_{IoU} 를 손실 항목으로 추가한다.

[0109] 이때의 손실 L_{IoU} 는 그라운드 트루쓰에서의 픽셀 단위 전경 영역과 세그멘테이션 맵으로 예측된 픽셀 단위 전경 영역 사이의 IoU를 산출한 후, IoU의 역수를 취하게 하였다.

[0110] 여기서, IoU는 그라운드 트루쓰에서의 전경 영역 A와 세그멘테이션 맵으로 예측된 전경 영역 B를 겹쳤을 경우에, 영역 A와 B가 교차하는 영역의 면적을 영역 A 및 B 전체가 차지하는 면적으로 나눈 값으로서 아래의 수학식 6으로 표현할 수 있다.

수학식 6

$$IoU = \frac{Area(A \cap B)}{Area(A \cup B)}$$

[0111]

[0112] 한편, 세그멘테이션 맵으로 예측된 전경 영역은 미리 정한 임계값 이상의 픽셀만 전경 영역의 픽셀로 선별하여 정하는 것이 좋다.

[0113] 이와 같이, IoU의 역수를 손실 항목으로 추가 도입한 손실 함수를 사용하여 상기 세그멘테이션 신경망(200)을 훈련시킴으로써, 정밀도(Precision)와 재현율(Recall)을 모두 향상시킨 결과를 얻을 수 있다.

[0115] < 트레이닝 및 테스트 결과 >

[0116] 본 발명의 실시 예에 따른 미세플라스틱 계수 장치를 훈련 데이터 세트로 훈련시킨 후 테스트 데이터 세트로 세그멘테이션 성능을 살펴보았다.

[0117] 도 6은 본 발명의 실시 예에 따른 미세플라스틱 계수 장치를 훈련시킨 후 테스트한 결과를 보여주는 메쉬망 이미지, 그라운드 트루쓰(ground truth) 및 예측한 모델의 결과 이미지이다.

[0118] 먼저, 도 6(a)를 살펴보면, 메쉬망의 공극(또는 망눈)과 크게 차이나지 않는 크기의 미세플라스틱이 걸려져 있어서 미세플라스틱을 구분하기 쉽지 않는 메쉬망 이미지를 테스트 데이터로 사용하였을 시의 결과를 보여준다. 그럼에도, 세그멘테이션 이미지로 얻은 예측 결과를 그라운드 트루쓰(ground truth)와 비교하면, 영역을 대체로 정확하게 찾고, 영역 중심은 거의 일치함을 알 수 있다.

[0119] 다음으로, 도 6(b)를 살펴보면, 테스트용으로 사용한 메쉬망 이미지는 촬영할 시에 조명 밝기 조절을 잘못하였거나 아니면 주변 빛을 충분히 차단하지 아니하여, 메쉬망과 미세플라스틱을 더욱 구분하기 어렵고, 입자형 및 섬유형 미세플라스틱이 다양한 크기 및 형상으로 혼재되어 있음을 보여준다. 예측 결과를 그라운드 트루쓰(ground truth)와 비교하면, 일부 배경을 오인하여 찾기는 하지만 미세플라스틱을 누락 없이 찾고, 영역은 이미지의 상태가 좋지 않음에도 형태를 따라 잘 찾고, 굵기 차이가 남을 알 수 있다.

[0120] 도 7은 본 발명의 실시 예에 따른 미세플라스틱 계수 장치의 훈련(Train) 및 테스트(Test) 중에 얻은 재현율(Recall) 및 정밀도(Precision)를 보여주는 그래프이다.

[0121] 도 7에서 보라색 선으로 표시한 그래프는 가중치 기반 바이너리 크로스-엔트로피 손실을 사용한 결과를 보여주기 위해서 전환 구간(230)에 완전연결층(231)을 배치하지 아니하고 실험한 결과를 보여주고, 초록색 선으로 표시한 그래프는 전환 구간(230)에 완전연결층(231)을 배치하고 실험한 결과를 보여준다.

[0122] 먼저, 훈련 및 테스트 결과의 보라색 선을 살펴보면, 가중치 기반 바이너리 크로스-엔트로피 손실을 사용함으로써, 재현율(Recall)이 상당히 좋게 나오고, 정밀도(Precision)가 좋게 나오고 있음을 알 수 있다.

[0123] 다음으로, 훈련 및 테스트 결과의 초록색 선을 살펴보면, 전환 구간에 완전연결층을 배치함으로써, 재현율(Recall)은 크게 손상되지 아니하면서 정밀도(Precision)는 상당히 향상시킴을 볼 수 있다.

[0124] 물론, IoU의 역수를 손실로 추가할 경우에, 정밀도(Precision)도 더욱 좋게 나옴을 확인할 수 있었다.

[0125] 실험 결과에서 알 수 있듯이, 본 발명에 따라 개량한 세그멘테이션 신경망과, 손실 함수를 사용함으로서, 재현율(Recall) 및 정밀도(Precision) 모두를 향상시켜 세그멘테이션의 성능을 높일 수 있음을 확인할 수 있고, 이를 통해 미세플라스틱을 크기별로 계수하는 성능 또한 향상시킨 수 있다.

[0127] 이상에서 본 발명의 기술적 사상을 예시하기 위해 구체적인 실시 예로 도시하고 설명하였으나, 본 발명은 상기 와 같이 구체적인 실시 예와 동일한 구성 및 작용에만 국한되지 않고, 여러가지 변형이 본 발명의 범위를 벗어나지 않는 한도 내에서 실시될 수 있다. 따라서, 그와 같은 변형도 본 발명의 범위에 속하는 것으로 간주해야 하며, 본 발명의 범위는 후술하는 특허청구범위에 의해 결정되어야 한다.

부호의 설명

[0128] 10 : 미세플라스틱 포집기

11 : 검출통

12 : 메쉬망

13 : 촬영수단

100 : 이미지 획득부

200 : 세그멘테이션 신경망

210 : 인코더

211 : ADD 모듈

220 : 디코더

230 : 전환구간

231 : 완전연결층

300 : 객체검출 신경망

400 : 계수부


500 : 훈련부

도면


도면1

(a)


(b)




도면2



도면3




도면4




도면5

ADD Module(211,223)




도면6




도면7

(a) Train



보라색 : Fully Connected Layer의 사용 전
초록색 : Fully Connected Layer의 사용 후

(b) Test



보라색 : Fully Connected Layer의 사용 전
초록색 : Fully Connected Layer의 사용 후