

Marine Snow Removal

선행 연구 분석

Deep Shark Lap

김태빈

목 차

01 배경 및 문제


02 Marine snow 모델링

03 데이터셋 및 작업

04 벤치마킹 결과

05 한계점 및 향후 과제

배경



Marine snow artifacts in real underwater image

Marine Snow (MS)

수중 장면과 카메라 사이에
떠다니는 유기물, 모래,
플랑크톤 등 작은 입자

발생 과정

수중에서 플래시를 터뜨리면,
입자들이 빛을 반사하여 사진
속에 밝고 흐릿한 반점

문제점

이 입자들은 수중 이미지의 화
질을 떨어뜨리는 가장 대표적인
열화 원인

극한 이미지 복원

(extreme image restoration)

정의

전통적인 영상 처리 방식
이 통하지 않는, 제약이
극심한 촬영 환경
(심해, 위성, 인체 내부)
에서의 이미지 복원


핵심

모델이 학습할
Ground Truth

문제 1

GROUND TRUTH 부재

수중 환경 특성상 부유물이 없는 완벽한 이미지를 얻는 것이 불가능



심층 신경망 훈련 불가

MSE, SSIM, Loss Function 등 계산할 타겟 이미지가 없어 객관적 평가 어려움

Median Fiter

Median Filter(MF)

- **작동 원리:** 이미지의 특정 픽셀 주변(3x3 또는 5x5)의 픽셀 값들을 모은 뒤, 그중 '중간 값'을 선택해 현재 픽셀의 값을 바꿈
- **문제점:** MS이 있든 없든, 모든 픽셀에 필터를 무조건 적용

Adaptive MF

- **작동 원리:** 필터 크기뿐만 아니라, 해양설을 판별하는 기준(임계값)을 설정
- **장점:** 일반 MF보다 이미지의 선 명도를 잘 유지합니다.
→ MS이 아닌것을 건드리지 않기 때문
- **여전한 한계점:** 기본적으로는 MF 기반이라, 크기가 큰 MS 앞에서는 여전히 무력

문 제 2

기존 학습에만 의존

Median Filter(중앙값 필터)
등 단순한 필터링 기술에만
의존해야하는 상황




전체 이미지의 블러 발생

필터가 부유물의 크기를 감당
하지 못해 정상적인 픽셀까지
훼손

MS 모델링

가우시안 함수법



중심점 (0, 0) 에서 가장 밝고 멀어질수록 밝기가
0으로 수렴하는 2차원적 빛의 덩어리


=물리적 현상을 단순화

반박

- 관찰에 따르면 실제 MS은 '타원 원뿔' 형태를 띈다
- 가우시안 모델로 가짜 MS을 만들어서 학습 시킨 모델은 실제 바닷속의 뾰족하고 날카로운 MS을 만났을 때, 제대로 제거하지 못하거나 주변 배경까지 뭉개버리는(Oversmoothing) 현상을 보인다
- 가우시안은 MS의 입체감을 담아내기에 너무나도 2차원적이고 단순하다

MS 모델링


고원형 (Type-H)



중앙이 넓고 평평하며 표면이 거친 형태

유기물이나 모래 입자가 빛을
균일하게 반사

화산 분화구형 (Type-V)




테두리가 솟아오르고 중앙이 파인 형태

빛의 굴절과 입자의 투명도 차이로
인해 테두리 강조 효과

Type-H 모델

c (투명도 상수)
- 부유물이 배경을
가리는 정도를 결정

ϵ (미세 교란 변수)
- 자연스러운 표면의
불규칙성을 모사



바깥 타원 (f_1)
안쪽 타원 (f_2)

및





Fig. 3: Ellipses used for marine snow synthesis.

$h(m,n)$ 은 MS 입자 하나를 구성하는 최소 단위이고, 이들이 모여서 Type-H라는 하나의 입체 도형 완성

Type-V 모델



$$v(m, n) = h(m, n) + g(m, n)$$

$$g(m, n)$$

$$= \begin{cases} c_r \left(1 - \frac{d(\mathbf{p}, \frac{1}{2}(\mathbf{q}_2 + \mathbf{q}_3))}{\frac{1}{2}d(\mathbf{q}_2, \mathbf{q}_3)} \right) \\ 0 \end{cases}$$

Type-H의 자연발생 70%

Type-V의 자연발생 30%


본 데이터셋의 7:3 비율 설정은 저자들의
사전 관찰에 기반한 경험적 수치

MSRB Dataset

Marine snow removal benchmarking(MSRB) Dataset

1


Flickr 원본 수중 이미지(U)



원본 수중 이미지 U
랜덤 좌표 (k,l) 선택

2

가짜 아티팩트(M)



모델 Type-H, V 위치, 크기,
회전 축, 투명도 난수화

3


가우시안 필터(G)



입자가 렌즈 앞에 있으면 그
뒤의 배경이 살짝 흐릿해지는
물리적 블러 현상을 묘사

4

MS 포함된 최종 이미지(I)



MSRB 데이터셋을 사용하여
U-Net을 학습

MSRB 실험

TASK 1(소형 입자 제거)


- 난이도: **쉬움**
- 정의: 최대 입자 크기를 **6픽셀**로 제한(전체 이미지의 약 1.6%)

TASK 2(다양한 크기 입자 제거)


- 난이도: **어려움**
- 정의: 최대 입자 크기를 **최대 32픽셀**로 제한(전체 이미지의 약 8.3%)
- 혼합 비율: 소형 입자 70%, 대형 입자 30%

- 각각 데이터 셋 2300 Train / 400 Test
- 이미지당 생성 입자수(N)는 100~600 의 균등 분포 $U(100,600)$ 로 무작위 생성
- 사용된 방법은 MF , adapt MF , U-Net 입니다. MF의 커널 크기는 3×3 또는 5×5 픽셀로 설정


Task 1 결과




Original underwater images.




Synthesized images for MSR Task 1.



Restoration results by MF.




Restoration results by adaptive MF.




Restoration results by U-Net.

- 기존의 MF로도 어느 정도 지울 수 있다 → 그래도 U-Net 성능이 좋다
- 기존 기술 vs 딥러닝 간의 성능 차이를 확인하는 **입문 단계**


Task 2 결과




Original underwater images.




Synthesized images for MSR Task 2.



Restoration results by MF.



Restoration results by adaptive MF.



Restoration results by U-Net.

- 기존 MF 들은 입자 전체를 지우지 못하거나, 지우더라도 이미지를 뭉개는 현상
- 딥러닝(U-Net)이 가진 능력을 증명하는 **심화단계**

PSNR

- 원본과 얼마나 픽셀 값이 똑같은가? 를 숫자로 나타낸 것
- 두 이미지(원본 vs 복원본)의 픽셀 값 차이인 MSE(평균 제곱 오차)를 기반으로 계산
- 숫자가 높을수록 좋다
- 단점: 픽셀 값의 산술적인 차이만 계산하기 때문에 “사람의 눈에는 자연스러워 보여도 픽셀 값 몇 개가 다르면 점수가 낮게 나오는” 경향

SSIM

- 사람의 눈이 보기에 두 이미지가 얼마나 닮았는가? 를 측정하는 지표
- 단순히 픽셀 값을 비교하는 게 아니라 세가지 요소 **밝기 분포, 명암 대비, 구조 형태나 질감**을 종합
- 0에서 1 사이의 값을 가지며, 1에 가까울수록 원본과 똑같다
- 장점: 인간의 시각 시스템을 모사했기 때문에, PSNR보다 훨씬 더 사람이 보는 화질과 비슷하게 평가

객관적인 지표

TABLE II: Average PSNRs and SSIMs over the test dataset.


Method	Task 1		Task 2	
	PSNR	SSIM	PSNR	SSIM
MF (3×3)	28.55	0.846	22.81	0.770
MF (5×5)	25.98	0.711	21.93	0.645
Adaptive MF (3×3)	29.88	0.910	23.35	0.842
Adaptive MF (5×5)	28.08	0.861	22.83	0.794
U-Net	36.82	0.978	30.95	0.932
Synthesized image	32.20	0.945	23.83	0.876

- 두 MSR 작업 모두에서 U-Net이 MF보다 우수함을 나타낸다
- **유의점** : 모든 MF는 MS가 없는 영역까지 필터링하기 때문에 합성된 이미지보다 더 낮은 PSNR/SSIM을 보인다


실제 MS 제거

- MF, adapt MF, U-Net을 사용
- U-Net은 MSRB Task 2 데이터셋을 사용하여 학습
- Deep Wave Net 적용 :


MS 제거 전용 모델이 아닌 일반적인 **수중 이미지 색상 대비를 보정**하는 모델



Real underwater images.




Restoration results by MF.



Restoration results by adaptive MF.



Restoration results by U-Net.



Restoration results by Deep WaveNet.

U-Net 유의점



Restoration results by U-Net.

복원된 이미지에 두꺼운 MS Artifact가 남아 있다

1. U-Net 자체가 MSR을 위해 특별히 설계된 것은 아니기 때문
2. 제안된 모델은 MS Artifact를 두 가지 대표적 유형으로 분류

MSR 만을 위해 특별히 설계된 신경망으로 성능을 향상 시킬 것이다

Type-H, V 두 모델만 만들었는데 이 유형에 맞지 않는 Artifact는 제거가 어려움

U-Net 한계점 및 향후 과제

MSRB Dataset은 실제 수중 이미지에 MS를 인위적으로 합성하는 방식을 기반으로 하기 때문에 몇 가지 한계가 존재

1. 이 Dataset은 MS Artifact 제거를 위해 설계되었으며, 색상 보정과 같은 다른 수중 이미지 향상을 목표로 하지는 않습니다.
→ MSR과 색상 보정을 동시에 복원하는 설계는 향후 연구 과제

2. MSRB Dataset을 사용하여 학습된 U-Net이 유망한 결과를 보여주지만 MSR Artifact가 모델에 맞지 않는 경우

(ex. 데이터셋보다 크고 밀도가 높을 경우, 조명 조건이 다를 경우)

현재 버전의 U-Net은 복원 실패

- 다양한 수중 장면을 반영하도록 Dataset을 업데이트함으로써 이를 개선



Fig. 9: Limitations. Top: Original images. Bottom: Restoration results by U-Net.

감사합니다