비지도 외부-내부 심층 학습을 사용한 해수면 온도 위성 영상 복원

Restoration of Satellite Sea Surface Temperature Imagery Using Unsupervised External-Internal Deep Learning

김문업, 김성주, 최재영[1)]
Mun Eob Kim, Seong Joo Kim, Jae Young Choi

(17035) 경기도 용인시 처인구 모현읍 외대로 81 한국외국어대학교 공과대학 컴퓨터공학부
패턴인식 및 기계지능(PMI) 연구실
hub99op@hufs.ac.kr, seongjbee1110@gmail.com, jychoi@hufs.ac.kr

요 약

인공 위성을 통해 촬영된 해수면 위성 영상 정보를 실제 응용 분야에 활용하기 위해서는 손실된 온도 정보를 인위적으로 복원하는 기술이 필수적이다. 본 논문에서는 해수면 온도 위성영상 복원을 위해 정답 영상이 필요 없는 비지도(Unsupervised) 기반 외부-내부 학습으로 구성된 딥 러닝 모델을 제안한다. 제안 방법에서는 손실된 해수면 온도 영상의 정답 영상이 부재해도 손실된 해수면 온도 정보를 신뢰성 있게 복원할 수 있게 한다. 제안 복원 방법은 외부-내부 학습 2단계의 과정으로 구성되어 있으며 1단계 외부 학습 과정에서는 비지도 학습을 기반으로 손실된 영역의 구조적 복원을 진행한다. 2단계 내부 학습 과정에서는 구조적 복원 결과와 손실 영상을 기반으로 색상 복원을 진행한다. 제안 비지도 학습 기반 복원 딥 러닝 모델은 최신 다른 비지도 학습 모델들과 비교할 때 우수한 복원 성능을 달성했으며 정답 영상을 필연적으로 활용하는 지도 학습 기반 복원 모델들과 비교해도 유사한 복원 정확도를 보였다. 또한 실제 측정한 해수면 온도 값과 비교하여 평균적으로 섭씨 1.8도 오차내에 복원 정확도를 달성하였다.

Abstract

In order to utilize Sea Surface Temperature (SST) satellite image in practical applications, the techniques for restoring the lost temperature information is essential. We proposed a so-called unsupervised external-internal learning (UNEIL) model that does not require ground-truth images during the restoration of SST satellite images. Using the proposed UNEIL, it is possible to restore sea surface temperature information lost due to occluded clouds without using ground-truth images and excellent quality restoration results can be obtained. The proposed UNEIL largely consists of two-step learning steps: external and internal learning. In external learning, structural information of the lost area is restored in an unsupervised learning way. Next, internal learning

1) 교신저자

논문투고일자 : 2022. 07. 04 심사일자 : 2022. 07. 14 게재확정일자 : 2022. 08. 18 http://doi.org/10.23019/kingpc.18.5.202210.006

based color restoration is performed based on structural restoration results. Experimental results showed that our UNEIL outperforms other state-of-the-art unsupervised restoration methods in terms of restoration accuracy and also achieves quite similar restoration accuracy, even compared to supervised restoration models that inevitably utilizes ground-truth images. The restoration accuracy of our UNEIL is achieved within an error of 1.8 degree Celsius on average compared to the actual sea surface temperature value.

키워드: 위성 영상, 해수면 온도 영상, 영상 복원, 비지도 학습, 외부-내부 학습
Keyword: Satellite imagery, Sea surface temperature(SST) imagery, Image restoration, Unsupervised learning, External-Internal Deep Learning

1. 서론

인공위성을 통해 촬영한 해수면 온도 영상은 해양학에 있어서 날씨 예보, 해상 날씨를 통한 배의 출항 여부 등을 결정하는 주요한 요소이다. 하지만 기상 상황에 따라 촬영할 수 있는 해수면 온도 영상의 범위는 제한이 된다. Guan and Kawamurs[1]는 일본 남부 해역의 NOAA AVHRR(National Oceanic and atmospheric Administration, Advanced Very High Resolution Radiometer)를 통한 연 평균 적외선 관측치가 48% 임을 보여준다. 이러한 문제를 해결하기 위해 국립수산과학원(NIFS)은 구름 제거를 위해 현장 관측 자료와 데이터 동화를 통한 보정 시스템을 개발했다[2]. 하지만 보정을 위한 작업이 1~2일 정도 소요돼 실시간 운영이 불가능하다. 마이크로파 센서를 이용하면 약간의 신호 감쇠가 존재하지만 구름으로 가려진 상황에서도 해수면 온도를 측정할 수 있다. 하지만 영상 픽셀당 0.5~1km 정도의 고해상도를 가지는 최신 적외선 센서에 비해 마이크로파 센서는 50km 정도의 저해상도를 가진다. 이로 인해 적외선 센서로 촬영한 해수면 온도 영상이 더 범용적으로 사용되고 구름에 의해 온도 정보가 손실 되기 때문에 적외선 센서로 촬영한 해수면 온도 영상 복원이 매우 중요하다.

영상 인페인팅(Image Inpainting) 기술[3]은 영상내에서 특정 누락된 영역을 복원하는 작업을 의미한다. 딥러닝 기술의 발전을 통해서 영상 인페인팅 모델의 복원 성능은 크게 발전됐다. Jiahui et. al.[6]는 생성적 적대 신경망[4]과 Contextual Attention[5] 기반의 Generative Image Inpainting 모델[6]을 제안했다. 해당 모델은 Coarse-to-Fine 의 2단계 영상 복원 과정을 통해 왜곡된 구조나 흐릿한 질감의 문제를 해결했다. Jiahui et. al.는 해당 모델을 바탕으로 Gated Convolution[7]와 자유형태 마스크를 적용한 Free-Form Inpainting 모델[8] 또한 제안했다. Haitian은 누락된 영역이 큰 영상을 복원하기 위한 다중 스케일의 특징을 추출하는 합성곱 신경망으로 구성된 CM-GAN[9]을 제안했다. Recurrent Feature Reasoning(RFR)[10] 모델은 Knowledge-consistent Attention 메커니즘을 기반으로 손실영역의 가장자리부터 복원을 진행하는 복원 모델이다. 이러한 복원 모델들은 직간접적으로 정답영상을 참고하는 지도학습(혹은 약지도학습)의 형태로 구성된다.

해수면 온도 영상 복원 연구에서는 영상 인페인팅 기술을 확장해서 사용한다. Enomoto는 구름을 제거하고 구름 아래의 색을 예측하는 McGANs[9]을 제안했다. 하지만 제안한 방법은 적외선이 구름을 투과할 수 있을 만큼 얇을 때 효과적이기 때문에 실제 적용에는 많은 제한사항이 따르게 된다. 본 논문 저자들의 사전 연구로서[12] Generative Image Inpainting 모델를 기반으로 구름에 가려진 SST 영상 복원에 특화된 Generative Inpainting Network (GIN) [12]을 제안했다.

지금까지 제안된 생성적 적대 네트워크 기반 복원 모델들의 가장 큰 문제점은 정답 영상(Ground-Truth)으로 구성된 데이터셋으로부터 데이터의 분포를 학습하는 것이다. 즉 구름 밑의 해수면 온도 영상을 복원하기 위해서는 구름에 가려진 해수면 온도 영상과 구름 아래의 실제 해수면 온도 영상이 필요하다. Guan and Kawamurs[1]이 언급했듯이 인공위성 적외선 센서로부터 촬영한 연평균 해수면 온도 영상은 48%에 불과하다. GIN[12]에서 사용한 정답영상은 Merge Observation&Memory (MOM)기법을 통해 예년치와 이상수온 자료를 활용하여 만들어진다. 즉 직접 측정한 해수면 온도 자료가 아닌 추정치라고 할 수 있다. 결국 학습에 필요한 원본 해수면 온도 정답 영상을 획득하는 것은 매우 어려우며 MOM 기법을 통해 정답 영상 데이터셋을 산출해내는데도 많은 비용과 시간이 소모된다.

본 논문에서는 해수면 온도 정답 영상(Ground-truth)이 존재하지 않아도 해수면 온도 복원을 할 수 있는 비감독 딥 러닝(Unsupervised deep learning) 모델을 제안한다. 정답 영상을 필수적으로 활용하는 지도학습 기반 복원 기술의 문제점을 해결하기 위해 이른바 비지도 외부-내부 학습 모델을 개발 하였다. 지도학습 기반 복원 모델과 달리 정답 영상 획득 및 구축이 필요 없으며 2단계 학습 기반 복원 절차를 통해 손실 영역에서 왜곡된 구조 및 색상의 문제점을 동시에 해결하여 정확한 복원 결과를 도출할 수 있다. 제안하는 비지도 외부-내부 학습 모델(Unsupervised external-internal learning, UNEIL)의 장점 및 기술적 특징들은 다음과 같다.

제안 UNEIL 모델은 해수면 구조 복원을 위해 외부 학습을 수행하고 색상 복원을 위해서는 내부 학습을 수행하는 총 2단계 학습 과정으로 구성되어 있으며 UNEIL 모델의 학습 과정 동안 정답 영상을 활용할 필요가 없다.

구조 및 색상 복원을 개별적인 네트워크 모듈로 진행하기 때문에 복원 영역이 왜곡되거나 색상특징이 흐릿한 문제를 해결할 수 있다.

최신 비지도 학습 기반 복원 모델과 비교하여 제안 모델이 향상된 복원 성능을 보였으며 심지어 정답 영상을 참조하는 지도학습 복원 모델과 비교하여도 평균절대오차 성능이 섭씨 0.3도로 근소한 차이를 보였다.

2. 관련연구

2장에서는 기존 지도학습 기반의 영상 복원 모델과 비지도 학습 기반의 영상 복원 모델에 대해 소개하고 기존 연구 내용 대비 제안 방법의 기술적 독창성에 대해 설명한다.

2.1 지도학습 기반 복원 모델

딥러닝을 활용한 손실 영역 복원을 위한 연구는 다양한 사람의 얼굴, 자연 풍경 등 다양한 데이터셋에 대해서 진행됐다. 그리고 대부분의 연구는 정답 영상을 참고하는 지도학습 기반으로 이뤄졌다. Recurrent Feature Reasoning(RFR)[10] 모델은 Encoder-Decoder 기반의 복원 모델이다. Perceptual loss와 Style loss를 사용하여 정답 영상과 복원 영상과의 구조와 질감의 차이를 계산한다.

Generative Inpainting Network(GIN)[12] 모델은 생성적 적대 신경망[4] 기반의 지도학습 모델로 구름에 가려진 해수면 온도 위성 영상 복원에 최적화된 모델이다. 2 단계의 생성자를 통해 손실영역에 대해서 거친 특징부터 세부적인 특징을 섬세하게 복원한다. Local/global Wasserstein GAN[13] loss와 Reconstruction Loss, Sea surface Loss를 사용하며 Reconstruction Loss와 Sea surface Loss를 계산 시 정답 영상을 직접적으로 참조하게 된다. 지도학습 복원 모델은 실제 데이터셋의 데이터 분포를 직접적으로 학습하기 때문에 좋은 성능을 보이나 정답 영상 데이터셋이 필요하다는 것이 가장 큰 단점이다.

2.2 비지도학습 기반 복원 모델

비지도 학습은 데이터셋에 대한 사전 지식이 없거나 라벨 또는 정답이 주어지지 않은 상태에서 진행되는 학습방식이다. 생성적 적대 신경망[4] 또한 비지도 학습이지만 생성자가 생산해낸 가짜 산출물은 판별자를 통해서 진위 여부가 판단된다. 2.1에서 소개한 GIN 모델[12] 또한 생성적 적대 신경망[4]을 바탕으로 설계됐지만, Loss 계산 시 정답 영상을 직접 참조한다. Unsupervised Adversarial Image Reconstruction(UNIR)[14]는 생성적 적대 신경망[4]을 바탕으로 오직 손실 영상만을 활용하여 학습하는 비지도 학습 기반 복원 학습 모델이다. 광범위한 상황과 데이터에 적용 가능한 효율적인 모델이다. 생성적 적대 신경망[4]은 결과물과 정답이1:1짝 지어지지는 않지만(Unpaired) 정답 혹은 타겟의 집합이 존재해야 하며 이 집합을 통해서 데이터의 분포를 학습한다. UNIR모델[14]은 기존의 지도학습과 생성적 적대 신경망[4]과 달리 정답의 집합이 필요 없다. 복원하고자 하는 손실 영상의 집합만을 통해서 학습한다.

외부-내부 학습[15]은 기존의 복원 모델의 색 번짐 현상과 뭉툭한 구조 문제를 해결하기 위해 제안되었다. 외부 학습 과정을 통해서 구조적 복원을 진행하고 내부 학습 과정을 통해서 색상 복원을 진행한다. 외부 학습 과정에서는 그레이스케일(Grayscale) 1채널 단색 영상을 사용하여 학습한다. 이를 통해 모델의 복잡도를 감소시키고 모델이 구조적 복원에 더 집중할 수 있도록 할 수 있다. 그리고 단색 복원 결과물을 내부 학습으로 전달해준다. 내부 학습은 외부 학습을 통해 나온 단색 복원 영상과 컬러 손실 영상, 마스크 영상을 통해서 색상 복원을 진행한다. 이때 다른 데이터셋을 참고하지 않고 손실 영상 중 손실되지 않은 영역의 색상만 참고하여 복원한다. 또한 N개의 피라미드를 구성하여 작은 크기의 영상부터 복원하고 점진적으로 큰 크기의 영상 복원을 진행한다. 이를 통해 색상의 큰 특징부터 세부적인 특징까지 복원을 진행할 수 있고 기존 복원 모델의 부자연스러운 색상 문제를 해결할 수 있다.

제안 방법에서 외부-내부 학습에서 내부 학습은 손실 영역의 실제 정답 영상을 참고하지 않고 색상 복원을 진행한다. 기존의 외부-내부 학습 모델의 경우 외부학습에 정답 영상을 참조하는 지도학습 기반의 모델을 적용하여 개발이 이루어졌다. 본 논문에서는 외부학습에 비지도 학습 모델을 적용하여 전체의 복원 과정을 완전 비지도 학습으로 구성했다.

3. 제안 비지도 외부-내부 학습 기반 모델

3장에서는 본 논문에서 제안한 비지도 외부-내부 학습에 대해 구체적으로 설명한다. 구조복원과 색상복원의 구분이 따로 없는 일반적인 복원[10,12,14]와 달리 비지도 외부-내부 학습은 외부 학습 과정에서 구조복원을 내부 학습 과정에서 색상 복원을 개별적으로 진행한다. (그림 1)은 전체 비지도 외부-내부 학습에 대한 구조를 나타낸다. 비지도 외부 학습 시 학습 데이터셋을 RGB 3채널의 영상을 1채널 단색 영상으로 변환하여 학습하고 테스트 데이터셋 또한 1채널 단색 영상으로 변환하여 비지도 외부 학습을 통해 나온 모델을 통해 복원된다. 비지도 외부 학습을 통해 복원된 단색 복원 영상을 내부 학습으로 전달하여 색상 복원을 진행한다. 이때 복원하고자 하는 영상만을 참고하여 복원을 진행한다. 테스트 영상이 n개가 존재한다면 n번의 내부 학습을 진행한다.

3.1 데이터셋 구성을 위한 구름 손실 함수

본 실험에서는 기존의 지도 학습 복원 모델과 성능 비교 평가를 위해 지도 학습 모델에서 사용한 정답 영상 데이터셋에 Corruption Function[14]통해 구름 손실을 가하여 데이터셋을 구성한다. 구름 마스크 데이터셋 D는 복원하고자 하는 영역에서 실제로 촬영된 구름 영상으로 구성된다. 이때 육지영역을 제외하고 구름으로 인해 가려진 영역이 10% 이상 90% 미만인 구름 영상만을 사용한다. 임의 손실 함수는 구름 마스크 데이터셋 D에서 임의 손실 변

수 θ를 통해 구름 마스크 손실을 가하는 것으로 정의한다. 이때 θ는 최대값이 구름 마스크 데이터셋 D의 크기인 양의 정수인 난수이다. 구름 마스크 데이터셋 D를 통해서 임의 손실 함수 $F(X;\theta)$를 식 (1)과 같이 정의할 수 있다. 정의된 임의 손실 함수 $F(X;\theta)$를 통해 지도 학습의 데이터셋에 구름 손실을 가하여 비지도 외부 학습을 위한 손실 학습 데이터셋을 구성한다.

$$F(X;\theta)_{i,j} = \begin{Bmatrix} 254 & \text{if } D[\theta]_{i,j} = 1 \\ X_{i,j} & otherwise \end{Bmatrix} \quad (1)$$
$$D = Cloud\,Mask\,Dataset$$

X는 입력영상을 의미하며 i,j는 영상에 대한 픽셀 좌표를 의미한다. $D[\theta]$는 구름 마스크 데이터셋 D 에서 θ번째에 위치하는 구름 마스크를 의미한다.

3.2 비지도 외부 학습

비지도 외부-내부 학습은 구조 복원을 위한 위한 비지도 외부 학습, 색상 복원을 위한 내부 학습으로 총 2단계로 구성된다. 외부 학습 모델은 (그림 1)과 같이 비지도 학습 모델 UNIR[14]을 적용하여 3.1절에서 설명한 임의 손실 함수를 통해 구축한 단색 손실 데이터셋을 통해서 정답을 참고하지 않고 학습한다. 단일 채널 단색 영상으로 학습하기 때문에 모델의 복잡도가 감소한다. 이를 통해 외부학

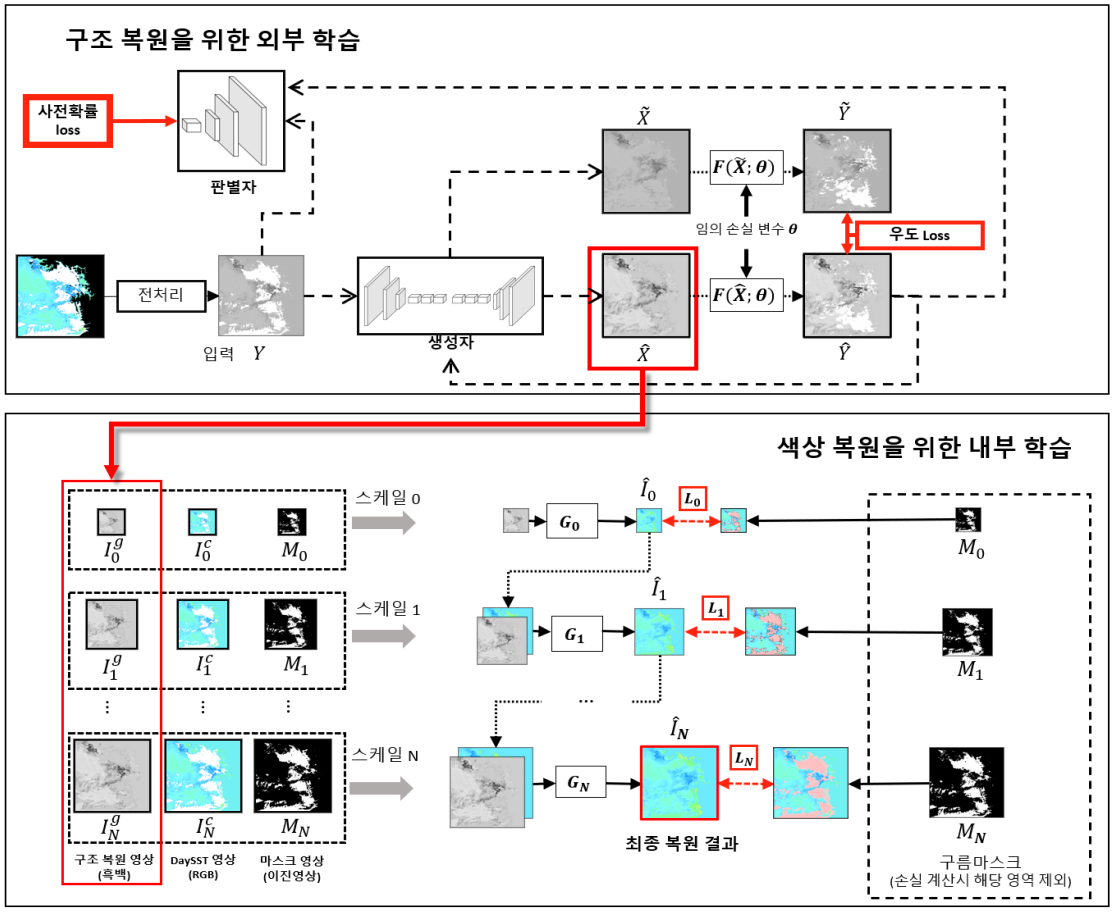

(그림 1) 제안하는 비지도 외부-내부 학습 모델 전체 구조도

습 모델이 구조적 복원에 집중할 수 있도록 해준다. 비지도 외부 학습 모델(UNIR[14])은 최대사후확률(Maximum a Posteriori)을 찾는 것을 학습 과정의 목표로 한다. 사후확률 $P_{X \mid Y}(x \mid y)$는 사전확률 $P_X(x)$와 우도 $P_{Y \mid X}(y \mid x)$로 분리해서 표현하고 이를 모델의 손실 값으로 활용한다. 제안 외부-내부 학습 모델에서 우도 손실(Likelihood loss)은 식 (2)와 같이 평균제곱오차를 기반으로 표현되며 [14], 사전확률 손실(Prior loss)는 식 (3)과 같이 표현된다 [14].

$$L^{likeli}(G) := E_{P_\theta P_{\hat{X}}^G,\, \hat{Y} \sim p_{Y \mid X,\theta}} \parallel \hat{y} - F(G(\hat{y});\theta) \parallel_2^2 \quad (2)$$

$$L^{prior}(G) := \max_D E_{Y \sim p_Y,\, \hat{Y} \sim p_Y^G} \left\{ \begin{matrix} \log D(y) \\ + \log(1 - D(\hat{y})) \end{matrix} \right\} \quad (3)$$

우도 손실(Likelihood loss)는 확률 관점에서 생성자가 만들어낸 영상이 얼마나 일관되는 지를 정규분포 식에 기반한 평균제곱오차 식으로 표현된다. 이때 생성자 G에 손실 영상 $\hat{Y}$를 입력으로 넣어 복원 영상 $\tilde{X}$를 만들고 복원 영상 $\tilde{X}$에 $\hat{Y}$와 동일한 임의 손실 변수 θ를 적용한 임의 손실 함수 $F(X;\theta)$를 통해 재 손실영상 $\tilde{Y}$를 생성한다. 그리고 $\hat{Y}$와 $\tilde{Y}$사이의 평균제곱오차를 계산하여 우도 손실(Likelihood loss)로 사용한다[14]. 우도 손실(Likelihood loss)은 임의 손실 변수 θ에 대해서 주변 확률로 표현 표현되며 확률변수 E를 통해서 $\hat{Y}$의 분포인 $P_{Y \mid X,\theta}$가 실제 영상 분포 $p_{Y \mid X,\theta}$와 유사해지도록 설정한다. 사전확률 손실(Prior loss)는 판별자 D를 통해 실제 손실 영상 Y와 생성자 G를 통해 만들어진 Y의 복원 영상 $\hat{X}$에 임의 손실 함수 $F(X;\theta)$을 통해 만들어진 $\hat{Y}$를 구별하는 적대적 손실을 통해 계산된다. 사전확률 손실(Prior loss)는 생성자 G를 통해 만들어진 가짜 손실 영상 분포 p_Y^G가 실제 손실 영상 분포 p_Y와 유사해지도록 강요한다. 가짜 손실 영상 분포 p_Y^G가 실제 손실 영상 분포 p_Y와 유사해지기 위해서는 생성자 G가 실제와 같은 복원 영상을 만들도록 학습되어야 한다.[14] 정리된 우도 손실(Likelihood loss)와 사전확률 손실(Prior loss)를 합쳐서 표현하면 식 (4)와 같이 표현할 수 있으며 외부 학습의 전체 학습 구조는 (그림 1)의 비지도 외부 학습 부분과 같다.

$$\arg\min_G L^{prior(G)} + \lambda \cdot L^{likeli(G)} \quad (4)$$

λ는 우도 손실(Likelihood loss)를 반영할 비율

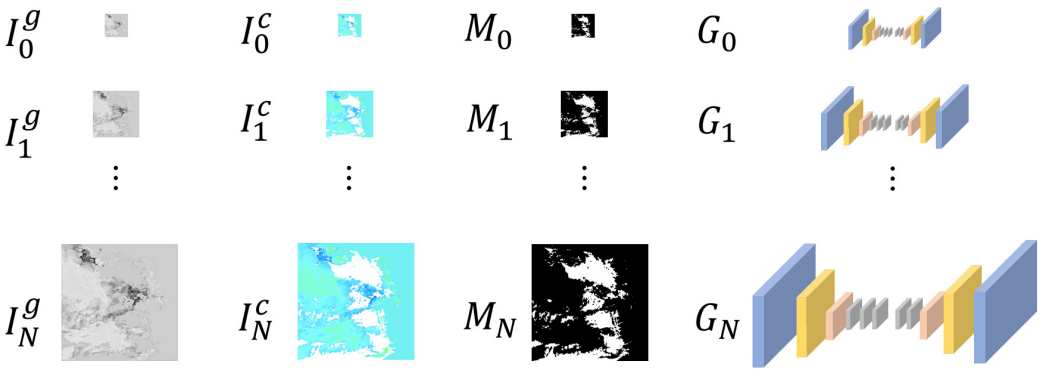

(그림 2) 내부 학습을 위한 단색 복원 영상 피라미드 $\{I_0^g, I_1^g, ..., I_N^g\}$, 컬러 손실 영상 피라미드 $\{I_0^c, I_1^c, ..., I_N^c\}$, 구름 마스크 영상 피라미드 $\{M_0, M_1, ..., M_N\}$, 생성자 피라미드 구성 $\{G_0, G_1, ..., G_N\}$ 과정 시각화 묘사

을 의미하며 식 (4)를 통해 정답 영상을 참고하지 않는 비지도 방식으로 학습을 진행하고 최적의 모델을 도출한다. 학습된 모델을 통한 단색 테스트 데이터셋의 복원 결과는 내부 학습으로 전달된다.

3.3 내부 학습

비지도 외부 학습을 통해 복원된 단색 복원 영상은 내부 학습으로 전달된다. 내부 학습에서는 단색 복원 영상을 기반으로 색상 복원을 진행한다. 내부 학습은 다른 데이터셋을 참고하지 않고 복원하고자 하는 영상 정보만을 참고한다. 내부 학습을 위해 (그림 2)와 같이 단색 복원 영상 피라미드 $\{I_0^g, I_1^g, \ldots, I_N^g\}$, 컬러 손실영상 피라미드 $\{I_0^c, I_1^c, \ldots, I_N^c\}$, 구름 마스크 영상 피라미드 $\{M_0, M_1, \ldots, M_N\}$ 그리고 각 크기에 해당하는 생성자 피라미드$\{G_0, G_1, \ldots, G_N\}$을 구성한다. 구성된 영상과 생성자를 바탕으로 순차적으로 가장 작은 크기의 영상부터 더 큰 크기의 영상을 복원한다. 크기별 생성자는 지정된 반복횟수만큼 학습한다. 영상의 크기를 점진적으로 증가시켜 학습하여 자연스러운 색 복원을 진행할 수 있다. 생성자 G_0는 가장 작은 크기의 I_0^g만 입력으로 받아 학습하며 식 (5)과 같이 표현할 수 있다.

$$\hat{I}_0 = G_0(I_0^g) \tag{5}$$

가장 작은 크기를 제외한 복원에서는 이 전 크기에서 복원된 결과물 $\widehat{I_{n-1}}$ 을 업샘플링한 결과와 현재 크기의 단색 복원 영상 I_n^g을 채널 방향으로 연결하여 생성자 G_n에 넣어 $\hat{I}_n$을 만들어낸다. 식으로 일반화하면 식 (6)와 같다.

$$\hat{I}_n = G_n(I_n^g \oplus \widehat{I_{n-1}}\uparrow), n = 1, \ldots, N \tag{6}$$

$\uparrow$ 은 업샘플링 연산을 의미하며 $\oplus$은 채널 방향으로의 연결을 의미한다. 생성자 G_n을 통해 만들어낸 복원 결과 $\hat{I}_n$은 컬러 손실영상 I_n^c와 비교하여 손실값(Loss)를 계산한다. 손실값 계산 시 손실되지 않은 영역만을 참고한다. 손실영역을 표시해주는 마스크 영상 M_n을 통해서 손실영역은 손실값 계산에 관여되지 않도록 값을 0으로 처리해준다. 지금까지 설명한 손실값 계산 방식은 식 (7)과 같이 표현할 수 있다.

$$L_n = \| (\hat{I}_n - I_n^c) \odot (1 - M_n) \|_1 \tag{7}$$

식에서 $\odot$은 아다마르 곱을 의미한다. 식 (7)을 통해서 확인할 수 있듯 내부 학습 중에는 손실영역에 대한 정답 영상을 참고하지 않는다.

4. 실험 및 결과 분석

4.1 데이터셋

해수면 온도 영상 데이터셋은 1989년부터 2018년까지 NOAA위성의 AVHR(Advanced Very Resolution Radiometer) 센서에서 수신된 데이터를 1km 공간해상도로 합성해 만들어진다. 제안한 비지도 외부-내부 학습 모델은 학습 시 정답 영상이 필요하지 않지만 다른 모델과의 정량적 비교 평가를 위해 참고문헌[12]에서 제시한 방법과 동일하게 복원 영역과 학습, 테스트 데이터셋 및 전처리 방법 참고한다. 테스트 데이터셋은 구름으로 인해 손실된 영역이 존재하는 256x256x3 크기의 대한민국 서해 영역의 해수면 온도 영상을 활용하며 DaySST라고 한다 [12].

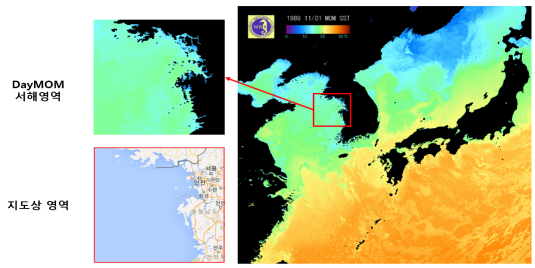

(그림 3) 데이터 구성을 위한 서해 영역 영상 예시

학습 데이터셋은 Merge Obeservation&Memoery (MOM) 기법으로 DaySST의 손실영역을 복원한 결과물로 DayMOM이라 명칭한다. (그림 3)은 원본 DayMOM 영상으로부터 학습을 위해 추출된 (Cropped) 서해영역의 영상 예시를 보여준다. 학습 데이터셋 DayMOM과 테스트 데이터셋 DaySST 모두 해당 서해영역에서 추출해서 구성하였다.

DaySST와 DayMOM 영상 모두 참고문헌[12]에서 제안한 전처리 방법을 통해 육지영역을 해수면 온도 RGB값의 평균값으로 채워 넣어주고 전처리 된 영상을 모두 2차원의 단색 영상으로 변환시킨다. 이는 외부 학습 시 사용된다. 그리고 해수면 온도 값은 월별로 크게 차이가 나기 때문에 학습, 테스트 데이터셋을 월별로 나눠서 구성해 준다. 본 논문에서는 계절별 대표가 되는 4개의 월(3월, 6월, 9월, 12월)에 대해서 학습, 테스트를 진행하며 테스트 시 각 월별 데이터셋에서 구름으로 인한 영상의 손실률이 10% 이상 90% 미만인 영상만을 사용한다. 학습에 관여되지 않은 월에서는 구름 영상을 추출하여 3.1절에서 설명한 방법으로 구름 마스크 데이터셋 D를 구성한다. 본 실험에서는 외부 학습 시 3.1절에서 정의된 임의 손실 함수 $F(X;\theta)$를 통해 단색 DayMOM 학습 데이터셋에 구름 손실을 가하여 단색 손실 DayMOM 학습 데이터셋을 구성한다. (그림 4)을 통해서 단색 손실DayMOM 학습 데이터셋에 대한 구성 방법을 확인할 수 있다. 외부학습 시에는 단색 DayMOM 학습 데이터셋과 구름 마스크 데이터셋 D를 통해서 학습하고 단색 DaySST 테스트 데이터셋을 복원시킨다. 내부 학습 시에는 복원된 단색 DaySST 테스트 데이터와 컬러 DaySST 테스트 데이터, 해당 영상의 마스크를 사용하여 색상 복원을 진행한다.

4.2 실행환경

본 논문에서 제안한 비지도 외부-내부 학습 모델은 GPU Nvidia GeForce RTX 3090(Ampere), CPU AMD Ryzen Threadripper PRO 3955WX 16-cores, Memory 256GB 환경에서 실행된다. 외부 및 내부 학습 모두 PyTorch 1.8.0을 사용하며 800장의 훈련 데이터 집합을 활용할 때 외부-내부 학습 시간은 5일 정도 소요된다. DaySST 테스트 영상 한 장당 평균 복원 시간은 4분이다. 외부 학습의 Hyper parameter는 Learning rate 0.0001, Epoch 15000, batch size 16을 설정했다. 내부 학습의 Hyper parameter는 Pyramid height 3으로 설정하였으며 각 Pyramid 크기 별로 10000, 10000, 15000 iteration과 0.03, 0.01, 0.01 Learning rate로 구성했다.

4.3 복원 성능 지표

본 논문에서 제안한 비지도 외부-내부 학습 모델에 대한 객관적인 성능을 비교 분석하기 위해 평

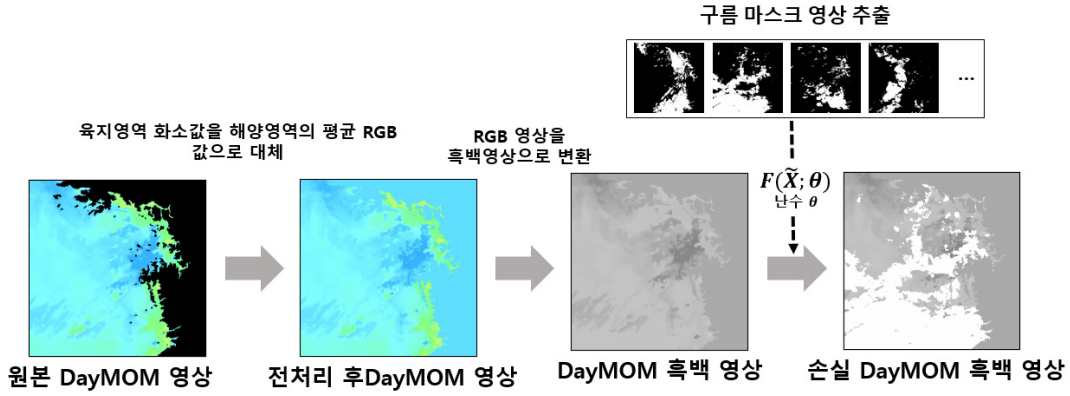

(그림 4) 비지도 외부 학습을 위한 단색 손실 DayMOM 데이터셋 구축 과정

균(AVG), 표준편차(SD), 평균 절대 오차(MAE), 제곱근 평균 오차(RMSE)를 사용했다. 성능 비교, 분석 전에 RGB 컬러 매칭 그래프 [12]를 통해 도출된 영상들에 대해서 RGB 픽셀값을 섭씨온도로 변환시켰다. 그리고 정답 영상 X와 복원 영상 Y 사이의 차이를 계산하여 성능지표를 계산했다. 평균은 X와 Y사이의 온도 값 차이에 평균을 뜻하며 식 (8)과 같이 표현된다.

$$AVG = \frac{1}{\sum_{i=1}^{w}\sum_{j=1}^{h} M(i,j)} \sum_{i=1}^{w}\sum_{j=1}^{h} (X(i,j) - Y(i,j)) \times M(i,j) \quad (8)$$

식 (8)에서 M은 구름 마스크 영상을 뜻하며 0과 1로 구성되어 있다. 1은 구름으로 가려져 손실된 영역, 0은 구름이 없어 손실되지 않은 영역을 뜻한다. X와 Y의 차이에 M을 곱하여 손실된 영역의 복원 성능만을 참고할 수 있도록 수식을 구성했으며 다른 성능지표에도 손실된 영역만 계산할 수 있도록 동일하게 적용했다. w,h는 각각 영상의 너비, 높이를 뜻한다. 표준편차(SD)는 식 (9)와 같이 표현한다.

$$SD = \sqrt{\frac{1}{\sum_{i=1}^{w}\sum_{j=1}^{h} M(i,j)} \sum_{i=1}^{w}\sum_{j=1}^{h} (X(i,j) - Y(i,j))^2 \times M(i,j) - AVG^2} \quad (9)$$

X와 Y 사이의 값의 차이가 얼마나 편차가 큰지를 나타내는 지표로 표준편차가 낮을수록 안정적인 복원을 했다고 판단된다. 평균 절대 오차(MAE)는 X와 Y의 차이의 절대 값의 평균을 뜻하며 식 (10)과 같이 표현한다.

$$MAE = \frac{1}{\sum_{i=1}^{w}\sum_{j=1}^{h} M(i,j)} \sum_{i=1}^{w}\sum_{j=1}^{h} |X(i,j) - Y(i,j)| \times M(i,j) \quad (10)$$

평균 절대 오차(MAE)와 더불어서 제곱근 평균 오차(RMSE)를 사용한다. 식 (11)과 같이 표현하며 모델의 정밀도를 평가할 수 있다.

〈표 1〉 제안 모델과 UNIR[14] 모델과의 월별 복원 성능 비교

		모델	
월	성능지표	제안 모델	UNIR[14]
3월	AVG	1.0563	-4.3894
	SD	1.6493	2.1192
	MAE	1.6339	5.0574
	RMSE	2.1844	5.4292
6월	AVG	1.2302	2.5726
	SD	1.7536	2.8666
	MAE	2.0187	3.4644
	RMSE	2.4044	3.9975
9월	AVG	0.8096	1.7186
	SD	1.5593	1.6232
	MAE	1.6568	2.3657
	RMSE	2.0638	2.6996
12월	AVG	0.7047	-2.7052
	SD	2.06	2.8714
	MAE	2.0962	4.1633
	RMSE	2.5328	4.8135

$$RMSE = \sqrt{\frac{1}{\sum_{i=1}^{w}\sum_{j=1}^{h} M(i,j)} \sum_{i=1}^{w}\sum_{j=1}^{h} (X(i,j) - Y(i,j))^2 \times M(i,j)} \quad (11)$$

4.4 복원 결과 분석

본 논문에서 제안한 비지도 외부-내부 학습 모델의 객관적인 성능 평가를 위해 3, 6, 9, 12월의 손실률 10% 이상 90% 미만의 테스트 데이터 셋 DaySST에 대한 복원 성능지표를 도출했다. 그리고 본 논문에서 제안한 비지도 외부-내부 학습 모델의 기반이 되는 비지도 학습 모델 UNIR[14]와 지도 학습 기반의 GIN[12],RFR[10]과 성능을 비교 분석했다. <표 1>에서는 본 논문에서 제안 모델과 제안모델의 기반이 되는 UNIR 모델[14]의 월별 복원 성능지표를 확인할 수 있다. 본 논문에서 제안한 모델은 실험한 모든 달과 성능지표에서 대표적인 비지도 학습 기반의 UNIR모델[14]과 비교하여 성능이 대폭 향상한 것을 확인할 수 있다. 특히 평균절대오차(MAE) 수치에 경우 3월 3.4, 6월 1.4, 9월 0.7, 12월 2.1만큼 복원 오차가 개선됨을

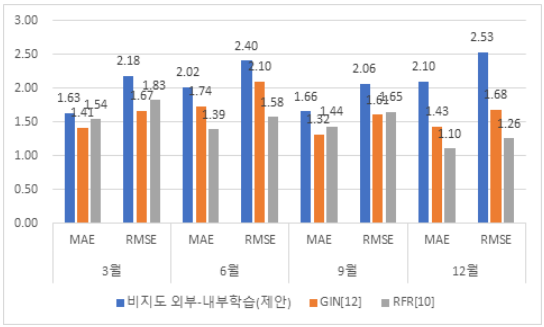

(그림 5) 제안 비지도 복원 모델과 지도학습 기반 복원 모델 GIN[12] 및 RFR[10] 모델과의 월별 평균 절대오차(MAE)와 평균제곱근오차(RMSE) 비교

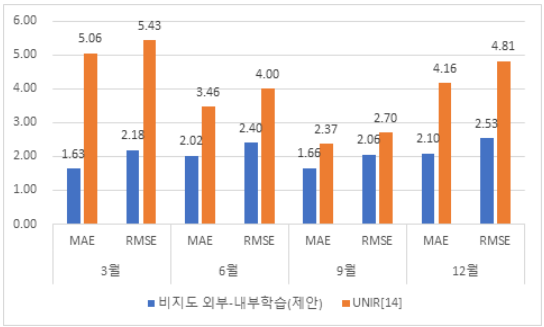

(그림 6) 제안 비지도 복원 모델과 기존 비지도 복원 모델 UNIR[14]간에 월별 평균절대오차(MAE)와 평균제곱근오차(RMSE) 비교

확인할 수 있었다. (그림 5)의 월별 평균절대오차(MAE)와 평균제곱근오차(RMSE) 그래프를 통해서도 제안한 비지도 외부-내부 학습(UNEIL) 모델 활용을 통해 향상된 성능을 확인할 수 있다.

본 논문에서는 비지도 학습 모델과의 비교뿐만 아니라 지도학습 모델과도 성능지표를 비교 분석했다. <표 2>에서는 제안한 비지도 외부-내부 학습 모델과 지도학습 기반 모델인 GIN[12]과 RFR[10]의 월별 복원 성능지표를 확인할 수 있다. 본 논문에서 제안한 비지도 외부-내부 학습 모델은 비지도 학습임에도 불구하고 지도학습 모델의 성능지표와 거의 유사한 성능을 도출하는 것을 확인할 수 있다. (그림 6)의 평균절대오차(MAE), 평균제곱근 오차(RMSE) 그래프를 통해서도 모델별 성능을 확인할 수 있다. 전반적인 수치는 지도학습 모델(GIN[12], RFR[10])의 성능이 더 뛰어난 것을 확인할 수 있다. (그림 7)은 3월, 6월, 9월 및 12월 각 계절별 시점에 따라 손실률 10%, 30%, 50%, 80%를 가지는 손실 영상과 활용한 모델별 복원 영상을 보여준다. 가장 왼쪽부터, DaySST 입력 영상, 입력 영상에 대한 구름 마스크 , GIN[12] 모델을 통한 복원 영상, RFR[10] 모델을 통한 복원 영상, UNIR[14] 모델을 통한 복원 영상, 제안한 모델을 통한 복원 영상, DayMOM정답 영상을 뜻한다. (그림 7)에 결과를 통해 제안 비지도 외부-내부 학습(UNEIL) 모델이 비지도 학습 기반임에도 불구하고 지도학습

〈표 2〉 제안 모델과 지도학습 기반 GIN[12], RFR[10] 모델과의 월별 복원 성능 비교

		모델		
월	성능지표	제안모델	GIN(12)	RFR(10)
3월	AVG	1.0563	1.205	1.0164
	SD	1.6493	1.0265	1.1014
	MAE	1.6339	1.4117	1.5435
	RMSE	2.1844	1.6659	1.8255
6월	AVG	1.2302	1.1794	1.1371
	SD	1.7536	1.5269	0.9055
	MAE	2.0187	1.7358	1.3899
	RMSE	2.4044	2.1031	1.5761
9월	AVG	0.8096	0.8428	1.1735
	SD	1.5593	1.1530	0.9592
	MAE	1.6568	1.3190	1.4365
	RMSE	2.0638	1.6080	1.6486
12월	AVG	0.7047	1.0581	0.8308
	SD	2.0600	1.1812	0.8015
	MAE	2.0962	1.4290	1.1044
	RMSE	2.5328	1.6808	1.2578

결과와 비교해도 매우 유사한 복원 성능을 보이는 것을 확인할 수 있다. 색상 특징뿐 만 아니라 해류의 흐름을 확인할 수 있는 구조적 특징까지도 복원하여 지도 학습에 준하는 성능을 도출한것으로 판단된다. 이에 반해 제안한 방법의 참조 모델인 UNIR 모델[14]의 경우 학습 시 모델이 학습 및 검증 손실을 통해 수렴하는 것을 확인했으나 실제 복원 영상을 확인했을 때 정확한 복원이 되지 않았다.

5. 토의 및 결론

본 논문에서 정답 영상 데이터셋(Ground- truth)이 존재하지 않아도 구름에 가려진 해수면 온도 위성영상을 복원할 수 있는 비지도 외부-내부 학습 모델을 제안했다. 기존의 비지도 학습 모델에 비해 뛰어난 복원 성능 향상과 동시에 지도학습 모델과 유사한 성능을 실험을 통해 확인할 수 있었다. 기존의 지도학습 기반의 해양 데이터 복원 모델은 정답 영상 데이터셋을 구축하기 위해 많은 비용과 시간이 소모되었다. 하지만 제안한 비지도 외부-내부 학습 모델은 인공위성을 통해 촬영한 손실 영상만을 가지고도 구름에 가려진 영역을 복원할 수 있기 때문에 정답 영상 데이터셋 구축을 할 수 없는 복원 조건에서 적용 가능하다.

기존 비지도 모델들의 부정확한 복원 문제를 해결하기 위해 본 논문에서는 외부-내부 학습 방식에서 외부 학습에 UNIR 모델[14]을 적용했으며 나아가 3채널 컬러 영상을 통해 학습 하던 기존 UNIR[14] 모델과 달리 단일 채널 흑백(Grayscale) 영상을 통해 학습하여 합성곱 연산에 사용된 필터의 개수를 1/3 수준으로 감소시켰다. 이를 통해 학습 가능한 가중치의 개수가 감소되어 모델의 복잡도 또한 감소시켰다. 복잡도가 줄어든 모델은 RGB 3개의 채널별 특징과 구조적 특징을 포착해야 됐던 기존 UNIR[14]와 달리 Grayscale 단일 채널을 통해서 구조적 특징을 포착하는 데에 집중할 수 있게 됐다. 결과적으로 기존의 UNIR 모델[14]에 비해 복원 성능 향상과 동시에 지도 학습 모델과 유사한 복원 성능을 달성했다.

이와 같은 장점을 가짐에도 불구하고 상대적으로 복원 처리 시간이 많이 소요되는 점은 제안 모델이 보완해야 할 부분이다. RFR[10], GIN[12], UNIR[14] 모델은 복원 소요 시간이 1초 이내로 측정되지만 제안한 비지도 외부-내부 학습은 외부 학습에서의 추론 시간과 내부 학습에서의 추론 시간을 합치면 평균적으로 4분 이상의 시간이 소요된다. 하지만 상대적으로 긴 추론시간에도 불구하고 정답 영상을 참조하지 않고 높은 정확도를 가지는 복원 결과를 도출할 수 있다는 점은 기술적 장점 및 실제 해양 분야 응용 적용 측면에서 큰 의미가 있다고 사료된다. 향후 연구 및 개발에서는 복원 시간을 단축시키고 더욱더 정확한 복원 결과를 획득하는 비지도 학습 기반 방법을 고안할 계획이다.

Acknowledgments

이 연구는 해양수산과학기술진흥원의 '해양위성영상 분석 활용 기술 개발(20210046)' 연구사업 및 한국외국어대학교 교내학술연구비의 지원에 의하여 이루어진 것임.

참고문헌

[1] L. Guan, and H. Kawamura, "SST availabilities of satellite infrared and microwave measurements," Journal of Oceanography, Vol. 59, pp. 201-209, 2003.

[2] Y. S. Wang, S. J. Park, and J.C. Lee, "Development of Retreatment Techniques for NOAA Sea Surface Temperature Imagery," NIFS annual report 2006, pp. 180.

[3] M. Bertalmio, G. Sapiro, V. Caselles, and C. Ballester,"Image inpainting. In Proceedings of the 27th annual conference on Computer graphics and interactive techniques", pp. 417-424, July 2000.

[4] I. Goodfellow, et al. "Generative adversarial nets," Advances in neural information processing systems 27, 2014.

[5] R. Yeh, C. Chen, T. Y. Lim, M. Hasegawa-Johnson, and M. N. Do, "Semantic image inpainting with perceptual and contextual losses," arXiv preprint arXiv:1607.07539, 2016.

[6] J. Yu, Z. Lin, J. Yang, X. Shen, X. Lu, and T. S. Huang, "Generative image inpainting with contextual attention," In Proceedings of the

IEEE conference on computer vision and pattern recognition, pp. 5505-5514, 2018.
〔7〕 H. Wang, Y. Wang, Q. Zhang, S. Xiang, and C. Pan, "Gated convolutional neural network for semantic segmentation in high-resolution images," Remote Sensing, Vol. 9, No. 5, 446, 2017.
〔8〕 J. Yu, Z. Lin, J. Yang, X. Shen, X. Lu, and T. S. Huang, "Free-form image inpainting with gated convolution," In Proceedings of the IEEE/CVF International Conference on Computer Vision, pp. 4471-4480, 2019.
〔9〕 H. Zheng, Z. Lin, J. Lu, S. Cohen, E. Shechtman, C. Barnes, and J. Luo, "CM-GAN: Image Inpainting with Cascaded Modulation GAN and Object-Aware Training," arXiv preprint arXiv:2203.11947, 2022.
〔10〕 J. Li, N. Wang, L. Zhang, B. Du, and D. Tao, "Recurrent feature reasoning for image inpainting," In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 7760-7768, 2020.
〔11〕 K. Enomoto, K. Sakurada, W. Wang, H. Fukui, M. Matsuoka, R. Nakamura, N. Kawaguchi, "Filmy cloud removal on satellite imagery with multispectral conditional generative adversarial nets," Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, pp. 48-56, 2017.
〔12〕 S. H. Kang, Y. Choi, and J. Y. Choi, "Restoration of missing patterns on satellite infrared sea surface temperature images due to cloud coverage using deep generative inpainting network," Journal of Marine Science and Engineering, Vol. 9, No. 3, 310, 2021.
〔13〕 M. Arjovsky, S. Chintala, and L. Bottou, "Wasserstein generative adversarial networks," In International conference on machine learning, pp. 214-223, July 2017.
〔14〕 A. Pajot, E. De Bezenac, and P. Gallinari, "Unsupervised adversarial image reconstruction," In International conference on learning representations, September 2018.
〔15〕 T. Wang, H. Ouyang, and Q. Chen, "Image inpainting with external-internal learning and monochromic bottleneck," In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 5120-5129, 2021.

저자소개

◆ 김문업



•2014년 한국외국어대학교 컴퓨터공학부 학사
•2020년~현재 한국외국어대학교 컴퓨터공학부 석사과정
•관심분야: 영상처리, 인공지능

◆ 김성주



•2021년 한국외국어대학교 컴퓨터공학부 학사
•2021년~현재 한국외국어대학교 컴퓨터공학부 석사과정
•관심분야: 딥러닝, 인공지능

◆ 최재영



•2011년 KAIST 전기및전자공학과 박사
•2008년~2012년 토론토대학 연구원
•2012년~2013년 펜실베니아대학(UPen) 연구원
•2013년~2014년 삼성전자 책임연구원
•2014년~2016년 중원대학교 의료공학과 조교수
•2016년~현재 한국외국어대학교 컴퓨터공학부 부교수
•관심분야: 딥러닝, 머신러닝, 패턴인식, 영상처리

3월 해수면 위성 영상(DaySST) 복원 결과 비교

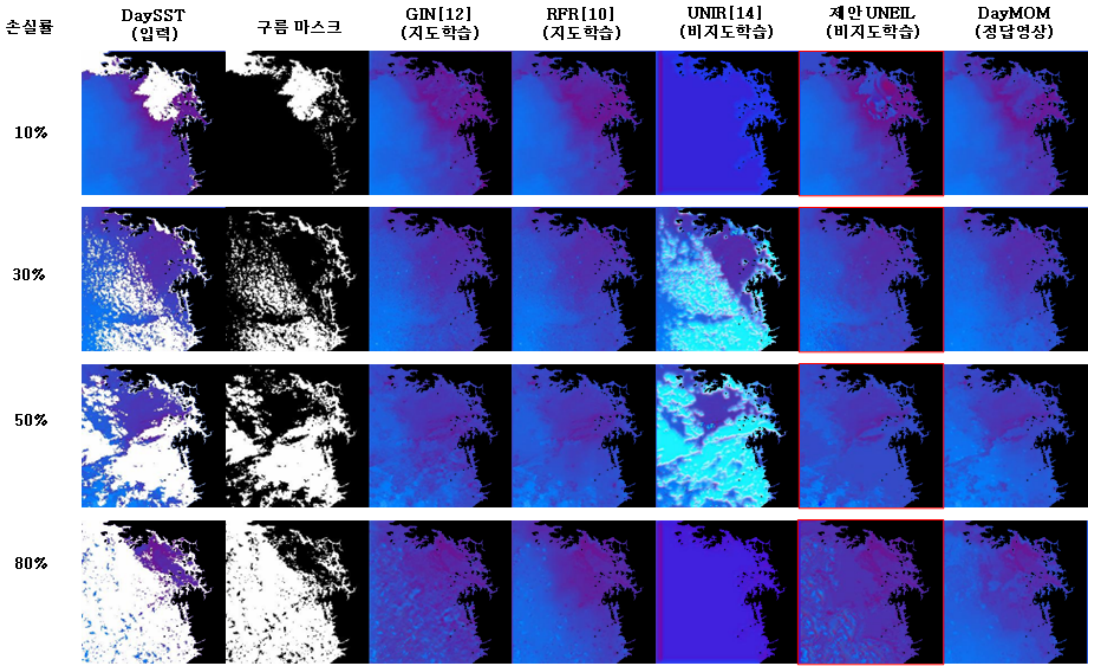

6월 해수면 위성 영상(DaySST) 복원 결과 비교

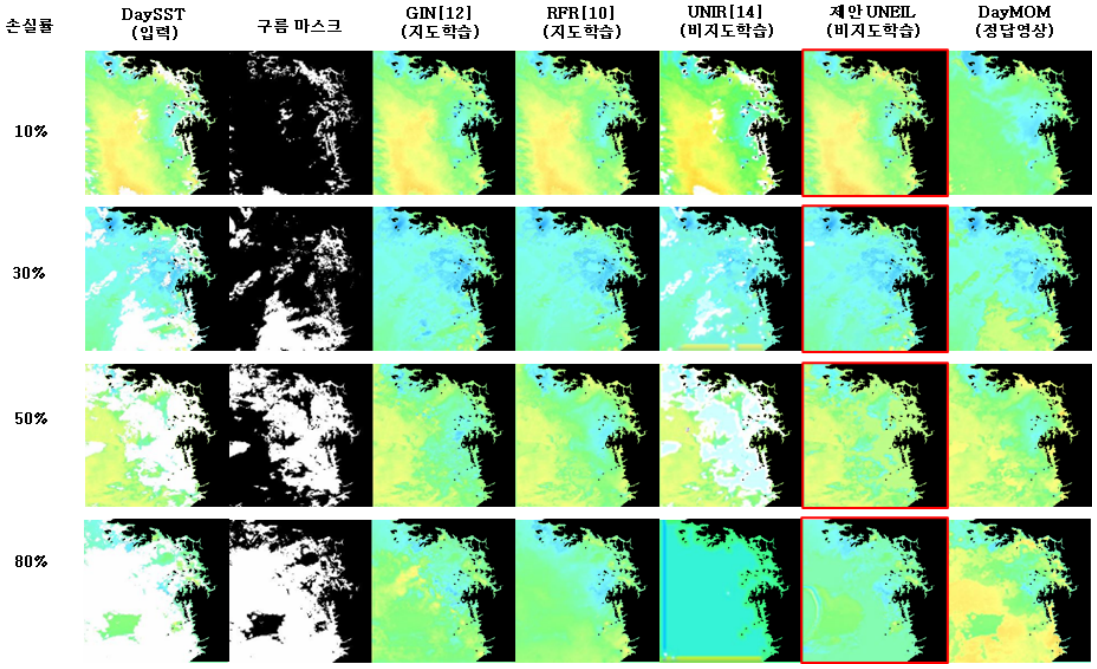

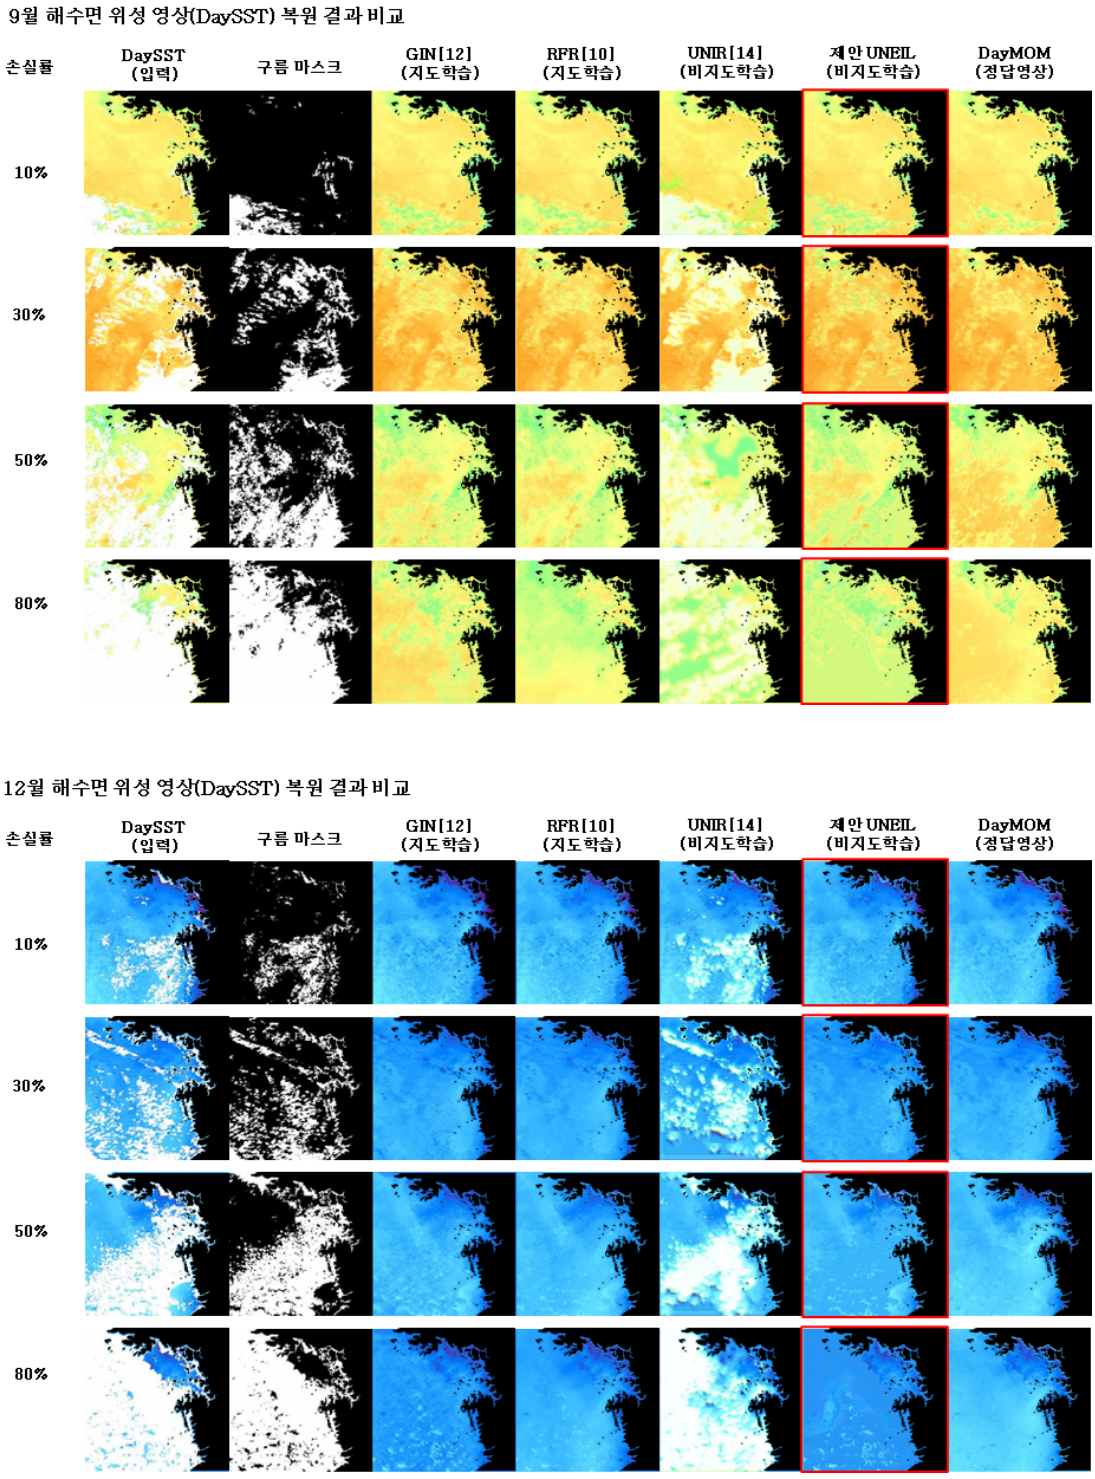

(그림 7) 손실률 10%, 30%, 50%, 80% 영상에 대한 각 모델별(GIN[12], RFR[10], UNIR[14], 제안 UNEIL 모델) 해수면 위성 영상(DaySST) 복원 결과 비교