

# 불확실성 인지 기반 지식 증류를 통한 고효율 위성 영상 품질 개선 연구

□ 이재협 / 경북대학교

## 요약

고해상도 위성 및 항공 영상은 재난 보도, 환경 감시, 도시 변화 분석, 해양·농업 모니터링 등 현대 미디어와 공공 서비스에서 중요한 시각 정보로 활용된다. 그러나 위성 센서는 높은 공간 해상도와 풍부한 분광 정보를 동시에 얻기 어렵기 때문에, 저해상도 다중분광 영상(LRMS)과 고해상도 전정색 영상(PAN)을 결합하는 PAN-sharpening이 핵심적인 품질 개선 수단이 된다. 본 기고문은 CVPR 2025에 발표된 U-Know-DiffPAN 연구를 중심으로, 확산 모델 기반 PAN-sharpening에서 고성능 교사 모델의 복원 지식을 작은 학생 모델로 전달하는 불확실성 인지 지식 증류를 소개한다. 특히 PAN-sharpening은 새로운 의미 정보를 자유롭게 생성하는 문제가 아니라, 입력 PAN의 공간 정보와 입력 LRMS의 분광 정보를 최대한 보존하는 입력 데이터 자체 정보의 복원 문제라는 점에 주목한다. 따라서 일반적인 단순 지식 증류를 통하여 학습된 학생 모델은 교사 모델의 평균적 출력을 모방하면서 세부 복원 성능을 떨어뜨릴 수 있지만, 본 연구에서 제안된 U-Know loss는 불확실성 지도를 이용해 교사가 확실하는 영역과 어려워하는 영역을 다르게 학습시킨다. 이 손실은 겉보기에는 학습 샘플에 더 강하게 맞추는, 즉 오버피팅을 향한 손실처럼 보일 수 있으나, 본 태스크에서는 입력 영상에 존재하는 정보를 더 충실히 보존하도록 유도하며 실제 평가 지표를 개선하는 것으로 실험적으로 확인되었다. 본 기고문은 이러한 설계가 Efficient AI for Media 관점에서 갖는 의미와 향후 응용 가능성을 논의한다.

## 1. 서론

미디어 AI의 효율성은 단순히 모델의 크기를 줄이는 문제가 아니다. 실제 미디어 환경에서는 영상이 만들어지고, 전송되고, 분석되고, 다시 사용자에게 전달되는 전 과정에서 지연 시간, 장치 메모리, 전력, 네트워크 대역폭이 동시

에 제약으로 작용한다. 방송·미디어 분야에서 효율적 AI가 중요한 이유도 여기에 있다. 고품질 결과를 얻는 것만큼이나, 그 결과를 제한된 장치와 제한된 시간 안에서 안정적으로 생산하는 것이 중요해지고 있다.

위성 영상은 이러한 논의를 확장하기에 적합한 미디어 데이터다. 위성은 지구 표면을 주기적으로 관측하며, 재

난 상황, 해양 변화, 도시 개발, 농업 생육 상태처럼 사람이 직접 접근하기 어려운 장면을 시각 정보로 제공한다. 특히 방송 보도나 공공 의사결정에서 위성 영상은 “멀리서 보는 이미지”가 아니라 상황을 해석하는 증거 자료가 된다. 하지만 위성 센서는 물리적 제약 때문에 넓은 파장대의 분광 정보를 높은 공간 해상도로 동시에 획득하기 어렵다. 따라서 낮은 해상도의 다중분광 영상과 높은 해상도의 전정색 영상을 결합해 고해상도 다중분광 영상을 생성하는 인공지능 기반의 PAN-sharpening[1], [3]-[8]이 중요한 전처리 기술이자 미래 국방, 감시 경찰[9] 등의 핵심 소요기술로 자리 잡았다.

최근 딥러닝 기반 PAN-sharpening은 전통적인 성분치환 및 다중해상도 분석 기법[2]을 넘어, PAN 영상의 공간 구조와 LRMS 영상의 분광 정보를 학습적으로 융합한다. 더 나아가 확산 모델은 반복적인 복원 과정을 통해 세밀한 고주파 디테일을 회복하는 데 강점을 보인다. 그러나 확산 모델은 일반적으로 파라미터 수와 연산량이 크고, 여러 번의 샘플링 과정을 필요로 하므로 실제 위성 영상 서비스나 엣지 환경에서 부담이 된다. 결국 핵심 질문은 다음과 같다. “고품질 복원 모델이 가진 세부 표현 능력을 유지하면서도, 더 작고 빠른 모델로 실제 활용 가능한 위성 영상 품질 개선을 구현할 수 있는가?”

본 기고문에서 소개하는 U-Know-DiffPAN[1] 방법은 이 질문에 대한 하나의 답이다. 이 연구는 고성능 교사 모델이 복원하기 어려워하는 영역을 불확실성 지도로 드러내고, 그 정보를 지식 증류 과정에 사용한다. 학생 모델은 모든 영역을 동일하게 따라 배우는 것이 아니라, 교사가 확신하는 영역에서는 교사의 복원 지식을 효율적으로 모방하고, 교사도 어려워하는 영역에서는 실제 정답 신호를 더 강하게 반영한다. 이러한 U-Know loss의 핵심은 단순히 작은 모델을 만드는 데 있지 않다. PAN-sharpening이라는 태스크의 본질, 즉 입력 PAN과 LRMS에 이미 존재하는 공간·분광 정보를 얼마나 충실히 보존할 것인가를 지식 증류의 설계 원리로 끌어온다는 데 있다. 즉, 단순 경량화가 아니라 미디어 품질과 계산 효율 사이의 균형을 설

계하는 관점이다.

## II. 위성 영상 품질 개선과 효율적 AI의 필요성

### 1. PAN-sharpening의 미디어적 의미

PAN-sharpening은 고해상도 전정색 영상의 공간 디테일과 저해상도 다중분광 영상의 색·분광 정보를 결합해 고해상도 다중분광 영상을 생성하는 문제다. 전정색 영상은 넓은 파장대를 하나의 채널로 받아들이기 때문에 도로, 건물 경계, 차량, 선박, 해안선 같은 구조를 선명하게 포착한다. 반면 다중분광 영상은 청색, 녹색, 적색, 근적외선 등 여러 밴드의 분광 정보를 제공하지만 공간 해상도가 낮다. 두 영상은 서로 다른 강점을 지니므로, PAN-sharpening은 단순 업샘플링이 아니라 공간 정보와 분광 정보를 균형 있게 융합하는 미디어 복원 문제로 볼 수 있다.

방송·미디어 응용에서 이 기술은 여러 방식으로 활용될 수 있다. 재난 보도에서는 홍수 범위, 산불 피해 지역, 도로 차단 여부를 빠르게 확인해야 한다. 환경 미디어에서는 해안 오염, 녹조, 산림 변화와 같은 장기 현상을 시각화해야 한다. 국방·안전·스마트시티 응용에서는 작은 객체의 위치와 주변 맥락을 함께 읽어야 한다. 이런 장면에서 공간 디테일만 강조하면 색이나 분광적 의미가 왜곡되고, 분광 정보만 보존하면 사용자가 해석할 수 있는 구조가 흐려진다. 따라서 위성 영상 품질 개선은 시각적 선명도와 정보 신뢰성을 요구하는 도메인 특화 미디어 AI 문제다.

### 2. 고품질 확산 모델의 장점과 한계

기존 많은 연구에서 활용되던 CNN 프레임워크 기반 방법[3]-[7]과 트랜스포머 기반의 방법[8]은 효율적이고 안정적이지만, 지역 수용 영역의 한계로 인해 장거리 구조나 고주파 디테일을 충분히 복원하지 못할 수 있다. GAN 기반

방법은 보다 사실적인 질감을 생성할 수 있으나 학습 불안정, 모드 붕괴, 인공적인 아티팩트의 위험이 있다. 확산 모델[1]은 점진적인 노이즈 제거 과정을 통해 안정적인 생성·복원 성능을 제공하지만, 여러 번의 역확산 단계를 거치므로 추론 시간이 길고 메모리 사용량도 커진다.

하지만 본 분야의 특성상, 위성 영상은 하나의 이미지만 다루는 것이 아니라, 넓은 지역을 타일 단위로 나누어 처리하고 시간에 따라 반복적으로 갱신한다. 같은 모델이라도 한 장의 데모 이미지에서는 문제가 없지만, 수천 장의 타일을 처리하거나 재난 상황에서 신속하게 결과를 제공해야 할 때는 연산 비용이 실제 서비스 가능성을 결정한다. 따라서 위성 영상 품질 개선 모델은 성능뿐 아니라 모델 크기, FLOPs, 추론 시간, 메모리 사용량을 함께 고려해야 한다.

### 3. PAN-sharpening에서 오버피팅의 의미

본 절에서 강조하는 핵심은 PAN-sharpening에서 오버피팅의 의미를 일반적인 인식 문제와 다르게 해석할 필요가 있다는 점이다. 지식 증류가 특히 효과적일 수 있는 이유는 이 문제의 목표가 일반적인 분류나 의미 인식 문제와 다르기 때문이다. 분류 모델은 학습 데이터에서 보지 못한 새로운 객체, 장면, 도메인에 대해서도 올바른 의미 판단을 내려야 한다. 이때 특정 학습 샘플의 우연한 패턴에 과도하게 맞춰지는 오버피팅은 일반화 성능을 떨어뜨리는 중요한 위험 요소가 된다. 반면 PAN-sharpening은 외부 세계에 대한 새로운 의미 추론을 수행하는 문제라기보다, 입력으로 주어진 PAN 영상과 LRMS 영상의 상보적 정보를 가능한 한 손실 없이 결합하는 복원 문제다.

이 관점에서 보면 PAN-sharpening에서의 “오버피팅”은 조금 더 조심스럽게 해석할 필요가 있다. 물론 학습 데이터셋의 센서 특성이나 특정 장면 통계에 지나치게 맞춰져 새로운 센서나 지역에서 성능이 떨어지는 문제는 여전히 존재한다. 그러나 한 장의 입력 PAN과 LRMS가 주어졌을 때, 복원 모델이 그 입력 신호에 강하게 의존하고 세부

구조를 최대한 보존하려는 것은 반드시 부정적인 현상이 아니다. 오히려 이 태스크에서는 입력 영상에 이미 담긴 고주파 공간 정보와 분광 정보를 충분히 활용하지 못하는 것이 더 직접적인 품질 저하 원인이 된다.

따라서 PAN-sharpening에서 중요한 질문은 “모델이 학습 데이터를 덜 외우는가”만이 아니라, “입력 영상의 공간·분광 정보를 얼마나 충실히 보존하는가”가 된다. 이러한 관점은 지식 증류의 설계에도 영향을 준다. 일반적인 Knowledge Distillation(KD) 기반의 학습에서는 교사 모델의 출력을 학생 모델이 평균적으로 모방하도록 만들지만, PAN-sharpening에서는 모든 영역을 동일하게 모방하는 전략이 오히려 작은 객체, 경계, 질감, 그림자, 해안선처럼 난이도가 높은 영역의 복원력을 떨어뜨릴 수 있다. 결국 복원형 미디어 AI에서는 지식 증류가 단순한 모델 압축이 아니라, 어떤 입력 정보를 더 강하게 유지할 것인가를 결정하는 학습 설계가 되어야 한다.

## III. 불확실성 인지 지식 증류 기반 경량화

### 1. 불확실성 지도와 선택적 학습

일반적인 지식 증류는 큰 교사 모델의 출력이나 중간 특징을 작은 학생 모델이 따라하도록 학습시킨다. 그러나 복원 문제에서는 모든 픽셀이 같은 난이도를 갖지 않는다. 넓고 균일한 지붕이나 논밭 영역은 상대적으로 예측하기 쉽지만, 차량, 도로 경계, 항만 구조물, 건물 그림자, 복잡한 해안선처럼 고주파 구조가 많은 영역은 훨씬 어렵다. 학생 모델이 모든 영역을 동일하게 따라 배우면, 중요한 세부 영역에 충분한 학습 자원이 배분되지 않을 수 있다.

U-Know-DiffPAN은 이 문제를 해결하기 위해 교사 모델이 복원 결과와 함께 픽셀 단위 불확실성 지도를 예측하도록 한다. 불확실성이 낮은 영역은 교사가 비교적 확신하는 영역이고, 불확실성이 높은 영역은 교사도 복원에 어려

움을 느끼는 영역이다. 이 지도는 단순한 부가 출력이 아니라 학생 모델을 가르치는 학습 가중치로 사용된다. 불확실성이 높은 영역에서는 학생 모델이 실제 정답을 더 강하게 참고하도록 하고, 불확실성이 낮은 영역에서는 교사 모델의 부드럽고 안정적인 출력을 모방하도록 한다. 이러한 설계는 교사의 장점과 정답 감독의 장점을 영역별로 달리 활용한다는 점에서 의미가 있다.

## 2. 경량 학생 모델

경량 모델인 학생 모델은 교사 모델과 달리 추가적인 조건 모듈을 제거하고, 보다 단순한 인코더-디코더 구조로 동작한다. 이는 모델 파라미터와 연산량을 줄이는 직접적인 효과를 낸다. 하지만 단순히 모듈을 제거하면 성능 저하가 발생할 수 있으므로, U-Know-DiffPAN은 교사가 학습한 주파수 풍부한 특징과 불확실성 정보를 학생에게 전달한다. 특히 중간 특징 정렬 손실을 통해 학생 모델이 교사의 표현 공간을 따라가도록 하고, hard loss와 soft loss를 불확실성에 따라 다르게 가중한다.

이 구조의 핵심은 “작은 모델을 큰 모델처럼 만들기”가 아니라 “작은 모델이 꼭 배워야 할 부분을 더 잘 배우게 하기”에 있다. 미디어 AI에서 효율성은 평균적인 계산량 감소만으로 평가되기 어렵다. 사용자가 실제로 민감하게 인식하는 영역, 또는 분석 알고리즘이 후속적으로 의존하는 영역에서 품질을 유지해야 한다. U-Know 방식은 복원 난이도를 명시적으로 추정하고, 그 난이도 정보를 경량화 과정의 안내 신호로 활용한다는 점에서 실용적이다.

## 3. U-Know loss

경량 학생 모델을 학습시키는 가장 직접적인 방법은 교사 모델의 출력 영상을 그대로 모방하도록 하는 것이다. 하지만 PAN-sharpening에서는 이 단순한 접근이 항상 충분하지 않다. 교사 모델이 평균적으로 우수하더라도 모든 픽셀과 모든 주파수 영역에서 완벽한 것은 아니기 때문

이다. 특히 차량, 건물 경계, 선박, 도로 교차부, 해안선처럼 세부 구조가 복잡한 영역에서는 교사 모델도 상대적으로 높은 불확실성을 가질 수 있으며, 이러한 영역까지 무조건 교사의 출력을 따라가게 하면 교사 모델의 불확실한 예측까지 학생 모델에 함께 전달될 수 있다.

U-Know loss는 이러한 문제를 해결하기 위해 hard loss, soft loss, feature loss를 결합한다. Hard loss는 학생 모델의 출력이 실제 정답 HRMS와 가까워지도록 유도하고, soft loss는 교사 모델의 출력을 부드러운 감독 신호로 사용하며, feature loss는 교사와 학생의 중간 표현을 정렬한다. 여기서 핵심은 불확실성 지도  $\theta$ 를 이용해 hard loss와 soft loss의 상대적 중요도를 공간적으로 조절한다는 점이다. 교사가 확인하는 낮은 불확실성 영역에서는 교사의 출력이 좋은 학습 신호가 되므로 soft supervision을 활용하고, 교사 모델이 복원하기 어려워하는, 높은 불확실성이 예측되는 영역에서는 정답 신호, 즉 hard loss의 가중치를 더 강하게 반영한다.

수식으로 쓰면 전체 손실은  $L_{U-Know} = L_{hard} + \lambda_s L_{soft} + \lambda_f L_{feat}$ 의 형태로 정리할 수 있다. 이 구조에서  $L_{hard}$ 는 불확실성이 높은 영역에 더 큰 가중치를 부여해 학생 모델이 실제 정답에 더 가까워지도록 하고,  $L_{soft}$ 는 불확실성이 낮은 영역에서 교사의 안정적인 복원 지식을 전달한다. 결국 U-Know loss는 교사를 맹목적으로 모방하는 손실이 아니라, 교사의 강점은 가져오고 교사의 약점은 정답 신호로 보완하는 선택적 증류 손실이다.

이 지점에서 U-Know loss는 겉보기에는 “오버피팅을 향한 손실”처럼 보일 수 있다. 높은 불확실성 영역에서 학생 모델을 실제 정답에 더 강하게 맞추도록 만들기 때문이다. 그러나 PAN-sharpening의 목적이 입력 PAN과 LRMS가 제공하는 정보를 충실히 보존하는 것임을 고려하면, 이는 단순한 과적합이 아니라 태스크 목적에 맞춘 입력 충실성 강화로 해석하는 편이 더 적절하다. 즉, 본 연구에서의 핵심은 학생 모델이 훈련 샘플을 무비판적으로 암기하도록 만드는 것이 아니라, PAN-sharpening에서 가장 중요한 공간-분광 정보 보존 방향으로 학습 자원을 집

중시키는 것이다.

## IV. 제안 학습 방법의 효과 및 효율성 분석

### 1. 데이터셋과 평가 방법

U-Know-DiffPAN은 WorldView-3(WV3), QuickBird(QB), GaoFen-2(GF2) 데이터셋을 사용해 평가되었다. 축소 해상도 실험에서는 정답 고해상도 다중분광 영상이 존재하므로 PSNR, SSIM, SAM, ERGAS, SCC, Q4/Q8과 같은 지표를 사용할 수 있다. 반면 실제 전체 해상도 실험에서는 정답 HRMS가 없기 때문에 HQNR,  $D_\lambda$ ,  $D_S$ 와 같은 no-reference 계열 지표를 사용해 분광 왜곡과 공간 왜곡을 함께 본다. 이는 위성 영상 품질 개선이 단일 지표로만 설명되기 어렵다는 점을 보여준다.

정량 결과에서 교사 모델은 여러 데이터셋에서 우수한 성능을 보였고, 더 복잡한 WV3와 QB에서는 학생 모델이 일부 지표에서 교사를 넘어서는 결과도 보였다. 이는 지식 증류가 단순 압축이 아니라 일반화 성능을 개선하는 학습 전략이 될 수 있음을 시사한다. 특히 불확실성 지도를 이용하면 교사 모델의 약한 영역을 학생이 보완하도록 만들 수 있어, 복잡한 장면에서 더 안정적인 복원이 가능하다.

### 2. U-Know loss 기반 지식 증류 효과에 대한 실험적 검증

U-Know loss의 효과는 학생 모델을 세 가지 방식으로 학습해 비교했다. 첫째는 정답 영상에 대한 L1 손실만 사용하는 경우이고, 둘째는 일반적인 지식 증류 손실  $L_{KD}$ 를 사용하는 경우이며, 셋째는 불확실성 지도를 반영한 제안 U-Know loss를 사용하는 경우다. 이 비교는 단순히 교사 모델을 따라하게 하는 KD가 PAN-sharpening에 항상 충분하지, 그리고 불확실성 기반 선택적 증류가 실제 품질

개선으로 이어지는지를 확인하기 위한 실험이다.

〈표 1〉은 GF2 전체 해상도 실험에서의 비교 결과를 정리한 것이다.  $D_\lambda$ 와  $D_S$ 는 낮을수록 좋고, HQNR은 높을수록 좋다. 일반 L1 손실 함수 대비 일반 KD를 적용하면 일부 지표가 소폭 개선되지만, U-Know loss를 적용했을 때  $D_\lambda$ ,  $D_S$ , HQNR이 모두 가장 좋은 값을 보인다. 특히  $D_\lambda$ 가 0.026에서 0.018로 감소하고 HQNR이 0.935에서 0.944로 증가한 결과는, 불확실성 기반 손실이 단순한 경량화 기법을 넘어 복원 품질 자체를 개선할 수 있음을 보여준다.

<표 1> U-Know loss 설계에 따른 GF2 전체 해상도 PAN-sharpening 성능 비교. U-Know loss는 일반 L1 및 단순 KD 대비 모든 지표에서 가장 좋은 값을 보인다.

| 손실 함수        | $D_\lambda \downarrow$ | $D_S \downarrow$ | HQNR $\uparrow$ |
|--------------|------------------------|------------------|-----------------|
| $L_1$        | 0.026                  | 0.040            | 0.935           |
| $L_{KD}$     | 0.025                  | 0.038            | 0.938           |
| $L_{U-Know}$ | 0.018                  | 0.037            | 0.944           |

본 정량적 비교 표에서 볼 수 있듯, PAN-sharpening에서는 정답 HRMS가 입력 PAN과 LRMS의 상보적 정보를 가장 잘 보존한 목표 영상이므로, 높은 불확실성 영역을 정답에 더 강하게 맞추는 것이 성능 지표 개선으로 이어질 수 있다. 즉, U-Know loss는 “무작정 교사를 따라 하는 KD”가 아니라 “복원 목적에 맞는 정보 보존형 KD”라고 볼 수 있다.

## V. 결론

### 1. 원격탐사 미디어 파이프라인의 효율화

위성 영상은 더 이상 연구실에서만 다루는 특수 데이터가 아니다. 기후 위기, 도시 재난, 해양 안전, 국가 기반 시설 모니터링처럼 사회적 관심이 높은 주제에서 위성 영상

은 대중에게 상황을 설명하는 미디어 자료가 된다. 하지만 원시 위성 데이터는 해상도, 센서 종류, 촬영 조건, 구름, 대기 영향에 따라 품질 편차가 크다. 실제 서비스에서는 수신된 영상을 빠르게 전처리하고, 품질을 개선하며, 분석 가능한 형태로 변환하는 파이프라인이 필요하다.

경량 PAN-sharpening 모델은 이 파이프라인의 앞단을 최적화할 수 있다. 대용량 위성 타일을 클라우드 서버에서만 처리하는 방식은 비용과 지연이 크다. 반면 경량 학생 모델은 제한된 GPU나 엣지 서버에서도 더 빠르게 구동될 수 있어, 현장 중심의 재난 대응이나 실시간 관측 서비스에 유리하다. 또한 모델이 작아지면 여러 센서, 여러 지역, 여러 시간대의 데이터를 병렬로 처리하기 쉬워지고, 미디어 제작자는 더 빠르게 고품질 시각 자료를 확보할 수 있다.

## 2. 다양한 미디어 AI 문제로의 확장

U-Know-DiffPAN의 설계 철학은 위성 영상에만 한정되지 않는다. 고품질 교사 모델, 불확실성 기반 영역 선택, 경량 학생 모델이라는 구조는 다양한 미디어 복원 문제에 적용될 수 있다. 예를 들어 저조도 영상 개선, 노이즈 제거, 초해상도, 영상 압축 복원, 드론 영상 안정화, 의료 영상 복원에서도 모든 픽셀이 같은 난이도를 갖지는 않는다. 복잡한 경계, 작은 객체, 움직임이 큰 영역, 센서 노이즈가 강한 영역에 더 많은 학습 자원을 배분하는 방식은 공통적으로 유용하다.

특히 방송·미디어 환경에서는 품질 기준이 사람의 시각적 인식과 후속 분석 목적에 따라 달라진다. 뉴스 영상에

서는 중요한 객체가 선명해야 하고, 문화 콘텐츠에서는 질감과 자연스러움이 중요하며, 공공 모니터링에서는 색이나 분광적 의미가 왜곡되지 않아야 한다. 불확실성 인지 지식 증류는 이러한 목적별 중요 영역을 학습 과정에 반영하는 방향으로 확장될 수 있다. 향후에는 사람의 주관적 품질 평가, 후속 인식 모델의 실패 사례, 센서 물리 모델을 불확실성 지도와 결합하는 연구가 가능하다.

## 3. 남은 과제

물론 한계도 분명하다. 본 제안 방법을 활용하여 학습된 학생 모델이 기존 교사 모델보다 효율적이라 하더라도, 본 실험은 확산 모델 기반의 교사, 학생 모델로 실험되며 검증되었다. 본 실험에서 활용된 모델들의 기반이 되는 확산 모델 구조는 여전히 비확산 모델보다 추론 시간이 길 수 있다. 따라서 실제 실시간 서비스로 확장하려면 샘플링 단계 축소, 모델 프루닝 등의 추가적인 경량화 모델링이 함께 연구되어야 한다. 또한 위성 영상은 센서별 공간 해상도와 밴드 구성이 다르기 때문에, 특정 데이터셋에서 학습한 모델이 다른 센서에 얼마나 잘 일반화되는지도 지속적으로 검증해야 한다.

미디어 AI 관점에서는 결과 영상의 시각적 품질뿐 아니라 정보 보존성이 중요하다. 너무 강한 복원은 보기에는 선명하지만 실제 분광 정보를 왜곡할 수 있고, 너무 보수적인 복원은 해석 가능한 구조를 충분히 살리지 못할 수 있다. 따라서 향후 효율적 위성 영상 AI는 경량화, 고품질 복원, 정보 신뢰성, 해석 가능성을 동시에 만족하는 방향으로 발전해야 한다.

## 참 고 문 헌

- [1] S. Kim, J. Do, J. Lee and M. Kim, "U-Know-DiffPAN: An Uncertainty-aware Knowledge Distillation Diffusion Framework with Details Enhancement for PAN-Sharpener," 2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).
- [2] G. Vivone et al., "A Critical Comparison Among Pansharpening Algorithms," IEEE Transactions on Geoscience and Remote Sensing, vol. 53, no. 5, pp. 2565-2586, 2015.
- [3] J.-S. Choi, Y. Kim and M. Kim, "S3: A Spectral-Spatial Structure Loss for Pan-Sharpener Networks," IEEE Geoscience and Remote Sensing Letters, vol. 17, no. 5, pp. 829-833, 2020.
- [4] J. Lee, S. Seo and M. Kim, "SIPSA-Net: Shift-Invariant Pan Sharpener with Moving Object Alignment for Satellite Imagery," 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).
- [5] S. Seo et al., "UPSNet: Unsupervised Pan-Sharpener Network With Registration Learning Between Panchromatic and Multi-Spectral Images," IEEE Access, vol. 8, pp. 201199-201217, 2020.
- [6] J. Park et al., "RPM: Robust PAN-Sharpener With Multispectral Misalignment Correction," IEEE Geoscience and Remote Sensing Letters, vol. 23, pp. 1-5, 2026.
- [7] Y. Duan, X. Wu, H. Deng and L.-J. Deng, "Content-Adaptive Non-Local Convolution for Remote Sensing Pansharpening," 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).
- [8] J. Do, S. Kim, G. Youk, J. Lee and M. Kim, "PAN-Crafter: Learning Modality-Consistent Alignment for PAN-Sharpener," 2025 IEEE/CVF International Conference on Computer Vision (ICCV).
- [9] W. Lee, H. Chang, J. Moon, J. Lee and M. Kim, "ABBSPo: Adaptive Bounding Box Scaling and Symmetric Prior based Orientation Prediction for Detecting Aerial Image Objects," 2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).

## 저 자 소 개



## 이 재 협

- 2018년 : 한국과학기술원 전기 및 전자공학부 학사
- 2020년 : 한국과학기술원 전기 및 전자공학부 석사
- 2024년 : 한국과학기술원 전기 및 전자공학부 박사
- 2024년 3월 ~ 2024년 8월 : 삼성전자 종합기술원 Staff Researcher
- 2024년 9월 ~ 현재 : 경북대학교 IT대학 컴퓨터학부 조교수
- 주관심분야 : 멀티미디어방송 기반기술, 영상처리 및 패턴인식, 위성 및 항공 영상처리