

농업 기상 데이터 상세화를 위한 경량 하이브리드 트랜스포머 기반 일사량 초해상화 모델 (Lightweight Hybrid Transformer-Based Super-Resolution Model for Solar Irradiance Downscaling in Agrometeorological Data)

박영아*, 조원지*, 박성욱*, 김용석**, 허지나**, 정세훈***, 심춘보****

(Yeong-a Park, Won-ji Jo, Sung-wook Park, Yong-seok Kim, Ji-na Hu, Se-hoon Jung, Chun-bo Sim)

요약

고해상도 기상 데이터는 농업 현장에서 정밀 의사결정, 수확량 예측, 기상재해 대응 등의 분야에서 핵심이다. 그중에서도 일사량은 태양광 발전량 효율과 작물 생육 조건을 결정짓는 핵심 요소로, 정밀한 예측을 위해 HR 데이터가 필수적이다. 이에 본 연구는 SwinIR 기반으로, 다중 RSTB를 축소하고, HBCT와 Detail Branch를 결합한 비용 효율적 SR 모델을 제안한다. 제안하는 모델은 전역 문맥 학습 능력을 유지하면서도 연산 비용을 절감하고, 복사 패턴의 지역적 변동성을 정밀하게 복원했다. SARA-3의 지면 도달 일사량 데이터를 활용한 실험 결과, SwinIR 대비 PSNR은 0.0435 dB 향상, SSIM은 0.0002 개선, RMSE와 MAE는 각각 0.0195 W/m², 0.0369 W/m² 감소했다. 특히, 구름 경계와 급격한 복사량 변화 구간에서 세밀한 복원 품질을 보였으며, 연산량은 약 34% 절감하여 계산 효율성을 입증했다.

■ 중심어 : 초해상화 ; 이미지 복원 ; 트랜스포머 ; 일사량 예측 ; 하이브리드 신경망

Abstract

High-resolution meteorological data are essential for precise decision-making in agriculture, improving crop yield prediction, and enhancing resilience to weather-related disasters. Among meteorological variables, solar radiation is a key factor determining photovoltaic power generation efficiency and crop growth conditions, thus requiring HR data for accurate prediction. This study proposes an efficient SR model based on the SwinIR framework, in which multiple Residual Swin Transformer Blocks are reduced and integrated with a Hybrid Block of CNN and Transformer and a Detail Branch. The proposed model maintains strong global context learning ability while reducing computational cost and accurately restoring local variations in radiative patterns. Experimental results using CM SAF's SARA-3 surface solar radiation data show improvements over SwinIR by 0.0435 dB in PSNR, 0.0002 in SSIM, and reductions of 0.0195 W/m² in RMSE and 0.0369 W/m² in MAE. Moreover, the model achieved finer restoration along cloud boundaries and rapid irradiance transitions, while reducing computation by approximately 34%, demonstrating its efficiency and effectiveness for high-fidelity solar radiation reconstruction.

■ keywords : Super-Resolution ; Image Restoration ; Transformer ; Solar Radiation Prediction ; Hybrid Neural Network

I. 서론

고해상도(High-Resolution, HR) 기상 데이터는 농업 현장에서 맞춤형 의사결정, 수확량 예측 정확도 향상, 기상재해 대응력 강화 등 다양한 분야에서 핵심적인 역할을 수행한다[1]. 지역 단위의 기상 변동성이 큰 환경에서, 세분화된 기상 데이터는 소규모 단위까지 기후 요인을 정밀하

게 모의할 수 있어 기존 데이터 대비 훨씬 높은 공간적 표현력을 갖는다[2].

그 중에서도 일사량(Solar Radiation)은 태양광 발전량 산정뿐만 아니라 광합성 유효광(Photosynthetically Active Radiation, PAR)과 증산을 통해 작물 생육과 품질을 결정짓는 핵심 요소다[3]. 특히, 태양광 발전과 농업 생산을 용

* 정회원, 국립순천대학교 스마트융합학부 멀티미디어공학전공

** 준회원, 농촌진흥청 국립농업과학원 연구사

*** 정회원, 국립순천대학교 컴퓨터공학과

**** 정회원, 국립순천대학교 인공지능공학부

이 연구는 신농업기후변화대응체계구축사업(과제 번호: RS-2024-00332198)의 지원으로 수행되었습니다.

접수일자 : 2025년 10월 19일

수정일자 : 2025년 11월 13일

게재확정일 : 2025년 11월 24일

교신저자 : 심춘보 e-mail : cbsim@snu.ac.kr

합한 영농형 태양광 시스템(Agrivoltaics Systems)에서는 태양광 패널의 부분 음영, 반사, 산란으로 인해 지면 일사 분포를 불균등하게 만들어 작물 생육 환경의 공간적 이질성을 초래한다. 이러한 환경을 정밀하게 분석하고 예측하기 위해 고해상도 데이터는 필수적이다[4].

HR 데이터를 획득하기 위해 딥러닝 기반 초해상화(Super-Resolution, SR) 기법이 기후 데이터 복원에 도입되고 있다[5, 6]. 딥러닝 기반 SR은 저해상도(Low-Resolution, LR) 데이터를 HR로 변환하는 것을 목표로, 전통적 보간(Interpolation) 기법에 비해 더 정교한 결과를 재현할 수 있다. 그러나 기존 SR 모델은 자연 이미지의 시각적 품질 향상을 목표로 설계되어 물리 단위의 정확도와 에너지 보존성을 확보하기 어렵다.

합성곱 신경망(Convolutional Neural Network, CNN) 기반 구조는 국지적 패턴 학습에 유리하나 장거리 의존성(Long-range Dependency) 반영에 한계가 있고[7], 트랜스포머(Transformer) 기반 구조는 전역 문맥(Global Context) 학습에 우수하지만 높은 계산 비용으로 인해 대규모 기후 데이터에서 실용성은 저하된다[8]. Diffusion 모델 기반 구조는 고차원 분포 모델링에 탁월하여 자연 이미지 생성에서 우수한 품질을 보이나, 물리량 복원 시 명시적인 물리 제약 없이 일관성을 보장하기 어렵다[9]. 일사량과 같은 물리량 복원에서는 단순한 시각적 품질 향상을 넘어 물리적 단위의 정밀성, 에너지 보존성, 그리고 현장 적용을 위한 연산 효율성 등 추가적인 요구사항에 따른다[10].

본 연구는 이러한 한계를 극복하고자 농업과 기후 환경에서 활용 가능하고, 일사량 복원에 최적화된 경량 SR 모델을 제안하고자 한다. 기존 SwinIR[11]의 구조적 비효율성을 개선하기 위해, 전역 문맥 학습 능력을 유지하면서 연산 비용을 절감할 수 있는 Hybrid Block of CNN and Transformer(HBCT)[12]를 도입하고, 기후 물리량

의 특성을 반영한 구조 설계를 통해 물리 단위의 일관성을 확보한다. 큰 틀은 SwinIR과 같이 얇은 특징 추출(Shallow Feature Extraction), 깊은 특징 추출(Deep Feature Extraction), 재구성(Reconstruction)의 세 단계로 구성한다. 깊은 특징 추출 단계에서 기존의 다중 Residual Swin Transformer Block(RSTB) 구조를 축소하고, HBCT와 Detail Branch를 적용한다. 실험 결과, 제안하는 모델은 기존 SwinIR 대비 낮은 연산 비용으로 정량 및 정성 평가 모두에서 개선된 복원 성능을 보인다.

II. 관련 연구

2.1. Diffusion 모델 기반 SR

Diffusion 모델 기반 SR은 노이즈 제거(Denoising) 과정을 반복적으로 수행하고, LR 입력을 HR로 점진적인 정제(Refinement)를 통해 안정적인 학습과 세밀한 복원이 가능하다. 이러한 다단계 샘플링(Sampling) 과정으로 인한 높은 연산 비용[13]은 대규모 기상 데이터 처리와 실시간 응용에서 효율성이 저하될 수 있다.

이를 개선하기 위해 StableSR[14]은 잠재 확산(Latent Diffusion) 구조를 활용해 샘플링 과정을 단축하였고, ResShift[15]는 잔차 이동(Residual Shifting) 기법을 통해 연산 효율을 향상시켰다. 다만, 두 모델 모두 확률적 특성을 유지하고 있어, 물리량 복원에 필요한 일관성과 재현성을 확보하기 어렵다.

2.2. Transformer 및 CNN 기반 SR

CNN 기반 SR 모델은 LR 데이터를 HR로 직접 복원하는 End-to-End 구조를 통해 성능을 향상해 왔다. EDSR[16]은 잔차 학습(Residual Learning)으로 고주파 세부 정보를 강화했으며, RCAN[17]은 채널 어텐션(Channel Attention)을 통해 주요 특징을 효과적으로 강조했다. 이러한 CNN 기반 모델은 지역적 패턴 복원에 강점을

가지지만, 장거리 의존성 학습에는 한계가 있다.

SwinIR은 Swin Transformer 기반 모델로, 이미지를 윈도우 단위로 분할하여 각 윈도우에 셀프 어텐션(Self-Attention) 연산을 수행함으로써 계산 효율성을 높였다. 또한, 윈도우 이동(Shifted Window) 기법을 통해 전역 정보 교환이 가능하게 하고, RSTB를 활용해 복잡한 텍스처와 세부패턴을 정밀하게 복원했다.

이후 제안된 Hybrid Network of CNN and Transformer(HNCT)는 Swin Transformer 구조를 경량화하고 지역 표현력(Local Representation)과 전역 의존성(Global Dependency)을 통합적으로 학습하기 위한 접근법을 제시했다. 핵심 구성 요소인 HBCT는 Swin Transformer Block(STB), 합성곱 계층(Convolutional Layer), 향상된 공간 어텐션(Enhanced Spatial Attention, ESA)[18]으로 구성된다. 밀집 특성 융합(Dense Feature Fusion)을 통해 계층 간 정보를 효율적으로 통합하여 복원 성능과 계산 효율을 동시에 향상했다.

2.3. 일사량 SR

일사량 데이터의 해상도 향상을 위한 전통적인 방법으로는 통계적 다운스케일링(Statistical Downscaling)과 동적 다운스케일링(Dynamical Downscaling)이 있다. 통계적 접근은 LR 데이터와 HR 간 관계를 회귀(Regression)와 확률 모형(Probabilistic Model)으로 학습해 계산 효율성이 높지만, 지형, 구름 분포, 복사 과정(Radiative Processes) 등 지역의 물리적 특성을 충분히 반영하지 못하는 한계가 있다[19]. 반면, 동적 접근은 지역 기후모델(Regional Climate Model, RCM)과 수치예보모델(Numerical Weather Prediction, NWP)을 활용해 LR 데이터를 물리적으로 재모의함으로써 보다 일관된 복사장(Radiation Field)을 생성하지만, 계산 비용이 크므로 장기 재분석이나 광역 적용에는 제약이 있다[20].

이러한 한계로 인해, 컴퓨터 비전(Computer Vision) 분야에서 발전한 SR 기법이 일사량 데이터

의 공간 해상도 향상을 위한 연구로 확장되고 있다. [21]은 생성적 적대 신경망(Generative Adversarial Network, GAN) 기반 구조를 적용하여 풍속 및 일사량 데이터의 공간 해상도를 약 100km에서 4km로 25배 향상했다. 단순한 픽셀 오차(Pixel-Wise Error) 최소화가 아닌, 물리적 구조와 공간적 자기상관(Spatial Autocorrelation)의 동시 복원을 실현함으로써, 딥러닝 기반 일사량 SR 가능성을 입증했다.

III. 본 론

3.1. 데이터셋 구축 및 전처리

본 연구에서는 EUMETSAT Climate Monitoring Satellite Application Facility(CM SAF)에서 제공하는 Surface Solar Radiation Dataset - Heliosat Edition 3(SARAH-3)[22]을 사용했다. SARAH-3는 Meteosat 위성의 Meteosat Visible and Infra-Red Imager(MVIRI) 및 Spinning Enhanced Visible and InfraRed Imager(SEVIRI) 센서를 통해 1983년부터 현재까지 지면 일사량 데이터를 약 5km의 공간 해상도로 제공한다. 본 연구에서는 지면 도달 일사량(Surface Incoming Shortwave radiation, SIS) 변수를 사용했으며, 2023년 4월부터 2024년 4월까지 1년간의 일일 평균 데이터를 수집했다.

수집된 367개의 Network Common Data Form(NetCDF) 형식 파일을 무작위로 섞은 후, 7:2:1 비율로 훈련, 검증, 테스트 세트로 분할했다. 각 파일에서 200×200 크기의 HR 패치를 비중첩방식으로 추

표 1. Dataset Summary

Item	Description
Data Source	SARAH-3(EUMETSAT CM SAF)
Spatial Resolution	5km×5km
Temporal Resolution	Daily intervals 2023.04.01.~2024.04.01.
Target Area	Meteosat full disk
Variables	Surface Incoming Shortwave radiation(SIS)
Total Patches	Train: 28,715, Val: 8,147, Test: 4,225




그림 1. Overall architecture of the proposed super-resolution network and its sub-modules.

출하고, Block Reduce Mean 방식을 통해 5×5 단위 평균으로 다운샘플링(Downsampling)하여 HR-LR 쌍을 구성했다.

데이터 품질 관리를 위해 NaN 비율이 5%를 초과하거나 유효 픽셀 비율이 95% 미만인 패치를 제거하고, 소량의 NaN 값은 국소 평균으로 대체했다. 또한, 표준편차가 8.0 W/m^2 미만이거나 값의 범위가 20.0 W/m^2 미만인 저변동성 패치를 제거하고, 물리적 범위를 벗어나는 이상값은 $0.0 \sim 1200.0 \text{ W/m}^2$ 범위로 클리핑했다.

정규화는 최소-최대 스케일링(Min-Max Scaling)을 적용하되, 훈련 세트에서 계산된 0.1 백분위수 3.0 W/m^2 와 99.9 백분위수 356.0 W/m^2 를 최솟값과 최댓값으로 설정해 극단값의 영향을 최소화했다. 이후 0 또는 1로 클리핑된 픽셀이 하나라도 포함된 패치는 제거해 안정적인 학습이 가능하도록 했다. 최종적으로 41,087쌍의 데이터를 확보했으며, 데이터셋 구성은 표 1과 같다.

3.2. 제안하는 모델의 개요

그림 1은 제안하는 일사량 SR 모델의 전체 구조와 세부 구성을 나타낸다. LR 이미지를 HR로 변환하기 위해 얇은 특징 추출, 깊은 특징 추출, 재구성 단계를 거친다. 그림 1(a)는 모델의 전체 구조를, 그림 1(b)는 깊은 특징 추출 단계에서 사용되는 RSTB

의 세부 구성을, 그림 1(c)는 고주파 세부 정보를 보강하는 Detail Branch를 나타낸다.

기존 SwinIR은 깊은 특징 추출 단계에서 6개의 RSTB를 사용하지만, 본 연구는 RSTB 개수를 3개로 축소하여 네트워크의 구조적 깊이를 완화한다. 또한, HBCT와 Detail Branch를 추가해 특징 변환 과정을 단순화하고, 연산 오버헤드를 감소시키며, 세부 구조의 손실을 방지한다. 깊은 특징 추출 단계에서 정제된 특징은 재구성 단계로 전달되어 최종적인 HR 이미지를 생성한다.

3.3. 얇은 특징 추출

얇은 특징 추출 단계에서는 LR 이미지에 단일 3×3 합성곱 연산을 적용하여 초기 특징을 추출한다. 이를 통해 지역적 밝기 변화와 경계 정보를 효과적으로 포착하고, 임베딩 차원으로 투영한다. 이후, 추출된 초기 특징은 그림 1(a) 특징 정제 단계의 HBCT 이후로 직접 전달되어 정보 손실을 방지한다.

3.4. 깊은 특징 추출

깊은 특징 추출 단계에서는 3개의 RSTB와 1개의 HBCT로 구성한다. RSTB는 그림 1(b)와 같이 6개의 Swin Transformer Layer(STL)와 1개의 3×3 합성곱으로 구성되며, 블록의 입력과 출력은 잔차 연




그림 3. Enhanced Spatial Attention (ESA)

결(Residual Connection)로 결합된 구조다. 각 STL은 Layer Normalization, window-based Multi-head Self Attention(MSA), Multi Layer Perception(MLP)으로 구성되며, 윈도우 단위의 셀프 어텐션을 통해 전역 문맥을 효율적으로 학습한다. RSTB는 잔차 연결을 통해 안정적인 학습을 보장하며, 광역 일사 패턴과 음영 구조 등의 전역적인 맥락 정보를 효과적으로 포착한다.




그림 2. Hybrid Block of CNN and Transformer (HBCT)

그림 2와 같이 HBCT는 ESA와 STL을 순차적으로 결합해 공간적 어텐션(Spatial Attention)과 전역 문맥 정보를 통합적으로 학습한다. 입력 토큰은 이미지로 변환하고, ESA를 거친다. 그림 3과 같이 ESA는 공간 어텐션과 스킵 연결(Skip Connection)을 결합해 중요한 영역을 강조한다. 입력 특징 F_{in}^{esa} 는 1×1 합성곱으로 채널을 압축하며, 식 (1)과 같다.

$$F_1^{esa} = W_1^{esa} * F_{in}^{esa} \quad (1)$$

식 (1)에서 F_1^{esa} 은 Stride 2인 3×3 합성곱과 최대 풀링(Max Pooling) H_{pool} 로 해상도를 축소하고, 3개의 합성곱 계층으로 구성된 합성곱 그룹(Convolution Group) H_g 에서 지역적 패턴을 보정한다. 이후 Bilinear 업샘플링(Upsampling) H_{up} 으로 롤백(Rollback)해 전역 정보를 통합하며, 식 (2)와 같다.

$$F_2^{esa} = H_{up}(H_g(H_{pool}(W_2^{esa} * F_1^{esa}))) \quad (2)$$

식 (2)에서 확장된 특징 F_2^{esa} 는 초기 입력 특징과

결합해 시그모이드(Sigmoid) 활성화 함수 $H_{sigmoid}$ 를 거치며, 공간별 가중치 생성 과정은 식 (3)과 같다.

$$F_{out}^{esa} = H_{sigmoid}(W_3^{esa} * (F_1^{esa} + F_2^{esa})) \times F_{in}^{esa} \quad (3)$$

식 (3)에서 출력 F_{out}^{esa} 은 토큰으로 변환되어 STL을 통과하며 전역 문맥을 학습하고, 3×3 합성곱과 스킵 연결을 통해 정제된 후 입력 토큰과 잔차 연결된다. 이는 특징 표현 전환 단계를 최소화하여 연산량을 줄이고, 정제된 정보를 안정적으로 전달한다.

Transformer 기반 구조에서는 다중 토큰 변환 과정에서 고주파 세부 정보가 희석될 수 있다. 이를 보완하기 위해 제안한 Detail Branch는 주 경로와 병렬로 동작하며, 세부 텍스처 복원을 전담한다. 구체적으로, 그림 1(c)의 Detail Branch는 연속된 3×3 합성곱과 SiLU(Sigmoid Linear Unit) 활성화 함수, 그리고 1×1 합성곱으로 구성된다. Detail Branch F_{detail} 은 학습 가능한 게이트 g 를 통해 주 경로의 출력 F_{main} 과 적응적으로 결합한다. 게이트는 Detail Branch가 전체 복원 과정에서 차지하는 기여도를 제어하며, 식 (4)와 같다.

$$F_{out} = F_{main} + H_{sigmoid}(g) \cdot F_{detail} \quad (4)$$

식 (4)에서 게이트 값은 $H_{sigmoid}$ 를 거쳐 0과 1 사이 범위로 정규화되고, Detail Branch의 반영 강도를 동적으로 조절하며, 국지적 정보를 선택적으로 주입한다.

3.5. 재구성

그림 1(a)의 우측에 도시된 바와 같이, 재구성 단계에서는 3×3 합성곱과 Leaky ReLU(Rectified Linear Unit) 활성화 함수로 선형성을 확보하고,

Pixel Shuffle 연산으로 해상도를 5배 확장한다. 이후 추가 3×3 합성곱으로 노이즈를 제거하며, 최종 HR 일사량 이미지를 생성한다.

IV. 실험 및 결과

4.1. 실험 환경 설정

정량적 평가지표로는 Peak Signal-to-Noise Ratio(PSNR), Structural Similarity Index Measure(SSIM), Root Mean Square Error(RMSE), 그리고 Mean Absolute Error(MAE)를 사용했다. 특히, RMSE와 MAE는 일사량의 물리 단위로 계산하여 실제 복원 정확도를 직관적으로 평가할 수 있다.

모델 훈련 시, 학습률(Learning Rate)은 1×10^{-4} 로 설정하고, Adam 옵티마이저(Optimizer)를 사용했다. 학습률은 MultiStepLR 스케줄러(Scheduler)를 통해 20,000, 35,000, 45,000, 55,000 스텝(Step)에서 0.5배씩 감쇄했다. 전체 학습은 59,800 스텝 동안 진행했다. 손실함수는 L1 함수를 사용했고, Drop Path Rate는 0.1로 설정했다. 실험 환경의 세부 설정은 표 2와 같다.

4.2. 성능 비교를 위한 기준 모델

본 연구에서는 딥러닝 기반 SR 분야에서 대표적인 CNN 및 Transformer 기반 모델을 비교 대상으로 선정했다. EDSR은 지역적 세부 정보 복원에 강점을 지닌 CNN 기반 모델로, 기후 데이터 SR의 기준으로 활용되어[23] 제안하는 모델의 국지적 패턴 복원 성능 평가에 적합하다. SwinIR은 Swin

표 2. Experimental Environment Settings

Component	Details
CPU	Intel(R) Core(TM) Ultra 7 265KF
GPU	NVIDIA GeForce RTX 3090, 24GB
RAM	Essencore DDR5-6400 16GB x 2
Operating System	Ubuntu 22.04.2 LTS
CUDA version	11.8.89
cuDNN version	8.7.0
Programming Language	python 3.8.20
Deep Learning Library	PyTorch 2.0.0 + cu118

Transformer 기반으로 전역 의존성 학습과 복잡한 공간 패턴 복원에 우수하며, 제안하는 모델의 구조 개선 효과를 검증하는 데 적합하다. RCAN은 Channel Attention 기반 모델로, 제안하는 모델과 학습 메커니즘 차이를 분석하기 위한 비교 대상으로 선정했다.

4.3. 정량적 평가

표 3은 제안하는 모델과 비교 모델의 정량적 평가 결과를 나타낸다. 효율성과 복원 품질을 동시에 비교하기 위해 파라미터(Parameter) 수와 GFLOPs 연산량을 함께 표기했다. 표 3에서 굵게 표시된 수치는 가장 우수한 값을, 밑줄로 표시된 수치는 두 번째로 우수한 값을 의미한다.

실험 결과, 제안하는 모델은 PSNR, SSIM, RMSE, MAE의 정량적 평가지표에서 우수한 성능을 보였으며, 파라미터 수와 GFLOPs 연산량 측면에서는 제안하는 모델이 두 번째로 우수한 결과를 보였다.

표 3. Quantitative results

Model	Efficiency		Quality			
	#Params.(M) ↓	FLOPs(G) ↓	PSNR ↑	SSIM ↑	RMSE ↓	MAE ↓
SwinIR	12.52	20.02	<u>38.0212</u>	<u>0.9107</u>	<u>5.7205</u>	3.9387
EDSR	2.14	3.45	38.0012	0.9101	5.7402	3.9249
RCAN	13.27	21.18	38.0192	0.9104	5.7242	<u>3.9207</u>
Ours	<u>8.4</u>	<u>13.32</u>	38.0647	0.9109	5.7010	3.9018




그림 4. Comparative Visualization of Solar Radiation Super-Resolution Results

특히, 제안하는 모델은 SwinIR 대비 파라미터 수와 GFLOPs가 각각 약 33%와 34% 감소했음에도 불구하고, PSNR은 0.0435 dB, SSIM은 0.0002 향상하고, RMSE와 MAE는 각각 0.0195 W/m^2 , 0.0369 W/m^2 감소했다. 이는 제안하는 모델이 SwinIR의 전역 문맥 학습 능력을 유지하면서도 RSTB 개수 조정과 HBCT 기반 경량화 구조를 통해 연산 효율을 효과적으로 개선했음을 의미한다.

4.4. 정성적 평가

그림 4는 제안하는 모델과 비교 모델의 일사량 복원 결과를 시각적으로 비교한다. 상단은 일사량 이미지를, 하단은 녹색 Crop 영역을 확대하여 구름 경계와 지형 음영이 혼재된 고주파 영역을 나타낸다.

그림 4 상단의 전체 이미지에서는 모든 모델이 전반적인 일사 패턴을 유사하게 복원하는 것처럼 보이지만, 구름 경계 영역을 확대한 하단 이미지에서는 모델 복원 품질 간의 명확한 차이가 드러난다. 구체적으로, EDSR은 확대 구간에서 경계가 평활화되어 구름 윤곽과 미세 음영 변화가 소실되고, 급격한 일사량 변화 구간에서 경계가 퍼지며, 표면 텍스처가 GT(Ground Truth) 대비 단조롭게 표현됐다. RCAN의 경우 전반적인 밝기 분포는 안정적이나, 공간 경계의 세밀 구조가 뭉개져 연속성이 낮다. SwinIR은 전역 문맥 복원은 양호하나, 국지적 고주파 성분이 약화되어 경계의 선명도와 점진적 음영 전이가 희미하게 나타났다.

반면, 제안하는 모델은 확대 영역에서 GT와 가장 근접한 구조를 보인다. 구름 경계의 날카로운 예지

(Edge)와 지형 음영의 점진적 전이가 동시에 보존되며, 미세 텍스처까지 안정적으로 복원했다. 이는 제안하는 모델이 경계 보존, 공간적 연속성, 미세 질감 표현을 동시에 충족한 결과로 해석할 수 있다. 하단에 제시한 RMSE, MAE 값에서 제안 모델은 동일 영역 기준 최저 오차를 기록했고, 시각적 품질 우위를 수치적으로도 확인할 수 있다.

4.5. 추가 분석 및 고찰

제안한 모델에서 HBCT와 Detail Branch의 효과를 검증하기 위해 각 구성 요소를 제거한 Ablation 실험을 수행했다. PSNR, SSIM, RMSE, MAE를 기준으로 정량적 성능을 평가했으며, 결과는 표 4와 같다.

표 4. Ablation Study on HBCT and Detail Branch

Variant	PSNR ↑	SSIM ↑	RMSE ↓	MAE ↓
w/o HBCT	38.0541	0.9108	5.7090	3.9077
w/o Detail Branch	38.0625	0.9109	5.7023	3.9029
Ours	38.0647	0.9109	5.7010	3.9018

표 4에서 HBCT를 제거한 경우, PSNR과 SSIM이 각각 38.0541 dB, 0.9108로 감소했고 RMSE와 MAE는 5.7090 W/m^2 , 3.9077 W/m^2 로 증가했다. 이는 HBCT가 구조적 품질과 오차 안정성 확보에 핵심적인 역할을 수행함을 의미한다. Detail Branch를 제거한 경우, PSNR은 소폭 감소했고 RMSE와 MAE가

각각 5.7023 W/m^2 , 3.9029 W/m^2 로 증가했다. 이는 Detail Branch가 국지적 세부 패턴을 정교하게 복원하여 픽셀 단위의 복원 정확도 향상에 기여함을 시사한다.

V. 결 론

본 연구는 농업 현장의 정밀한 기상 예측을 위해 기존 SwinIR의 장점을 활용하면서도 효율적으로 해상도를 향상하는 일사량 SR 모델을 제안했다. 제안하는 모델은 SwinIR, EDSR, RCAN 대비 더 높은 복원 정확도를 확보하며, 모델 경량화와 성능 간의 균형을 달성했다. 정성적 비교에서도 구름 경계 및 급격한 일사량 변화 구간에서 세밀한 구조를 안정적으로 복원하고 물리적으로 일관된 분포를 유지했다. 이를 통해 물리 단위 복원 정밀도와 연산 효율성을 동시에 확보하여, 농업 현장에서의 상세화된 일사량 예측을 가능하게 하고, 나아가 작물 생육 모니터링에도 활용할 수 있을 것으로 기대된다.

향후에는 제안하는 모델의 각 구성 요소가 성능에 미치는 영향을 체계적으로 분석하고, 구름 경계 등 고주파 영역의 시각적 품질을 향상하기 위한 다양한 구조적 개선 방안을 추가적으로 모색할 예정이다.

REFERENCES

- [1] V. Mereu, A. Gallo, A. Trabucco, G. Carboni, and D. Spano, "Modeling high-resolution climate change impacts on wheat and maize in Italy," *Climate Risk Management*, Vol. 33, pp. 100339, 2021.
- [2] J.D. Mishler, A. Josephson, T. Kilic, and S. Murray, "Estimating the Impact of Weather on Agriculture," *arXiv preprint*, arXiv:2012.11768, 2020.
- [3] R. Jegan, W. D. Lean-Salas, M. A. Vizcardo, and M. P. Malaga, "Photosynthetically Active Radiation (PAR): A Review of Sensing Solutions," *Journal of Applied Science and Engineering*, Vol. 26, No. 3, pp. 387-401, 2022.
- [4] L. Sollazzo, G. Mangherini, V. Diolaiti, and D. Vincenzi, "A Comprehensive Review of Agrivoltaics: Multifaceted Developments and the Potential of Luminescent Solar Concentrators and Semi-Transparent Photovoltaics," *Sustainability*, Vol. 17, No. 5, p. 2206, 2025.
- [5] L. Sun, and Y. Lan, "Statistical downscaling of daily temperature and precipitation over China using deep learning neural models: Localization and comparison with other methods," *International Journal of Climatology*, Vol. 41, No. 2, pp. 1128-1147, 2020.
- [6] D.T. Anh, S.P. Van, T.D. Dang, and L.P. Hoang, "Downscaling rainfall using deep learning Long Short-Term Memory and Feedforward Neural Network," *International Journal of Climatology*, Vol. 39, No. 10, pp. 4170-4188, 2019.
- [7] Y. Zheng, J. Huang, T. Chen, Y. Ou, and W. Zhou, "Transfer of learning in the convolutional neural networks on classifying geometric shapes based on local or global invariants," *Frontiers in computational neuroscience*, Vol. 15, No. 637144, 2021.
- [8] A. Perez, M.S. Cruz, D.S. Martin, and J. M. Gutierrez, "Transformer based super-resolution downscaling for regional reanalysis: Full domain vs tiling approaches," *arXiv preprint*, arXiv:2410.12728, 2024.
- [9] H. Wang, J. Han, W. Fan, W. Zhang, and H. Liu, "PhyDA: Physics-Guided Diffusion Models for Data Assimilation in Atmospheric Systems," *arXiv preprint* arXiv:2505.12882, 2025.
- [10] P. Harder, A.H. Garcia, V. Ramesh, Q. Yang, D. Szwarcman, C. Watson, and D. Rolnick, "Hard-Constrained Deep Learning for Climate Downscaling," *Journal of Machine Learning Research*, Vol. 24, No. 365, pp. 1-40, 2023.
- [11] J. Liang, J. Cao, G. Sun, K. Zhang, L. Van Gool, and R. Timofte, "SwinIR: Image Restoration Using Swin Transformer," in *Proc. of IEEE/CVF Int. Conf. Comput. Vis. Workshops (ICCVW)*, pp. 1833-1844, 2021.
- [12] J. Fang, H. Lin, X. Chen, and K. Zeng, "A Hybrid Network of CNN and Transformer for Lightweight Image Super-Resolution," in *Proc. of IEEE/CVF Conf. Comput. Vis. Pattern Recognit. Workshops (CVPRW)*, pp. 1103-1112, 2022.
- [13] S.R. Cachay, B. Zhao, H. Joren, and R. Yu, "DYffusion: A Dynamics-informed Diffusion Model for Spatiotemporal Forecasting," *Advances in Neural Information Processing Systems*, Vol. 36, pp. 45259-45287, 2023.
- [14] J. Wang, Z. Yue, S. Zhou, K.C.K. Chan, and C.C. Loy, "Exploiting Diffusion Prior for Real-World Image Super-Resolution," *International Journal of Computer Vision*, Vol. 132, No. 12, pp. 5929-5949, 2024.
- [15] Z. Yue, J. Wang, and C.C. Loy, "Resshift: Efficient diffusion model for image super-resolution by

residual shifting,” *Advances in Neural Information Processing Systems*, Vol. 36, pp. 13294-13307, 2023.

- [16] B. Lim, S. Son, H. Kim, S. Nah, and K. M. Lee, “Enhanced Deep Residual Networks for Single Image Super-Resolution,” in *Proc. of IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pp. 136-144, 2017.
- [17] Y. Zhang, K. Li, L. Wang, B. Zhong, and Y. Fu, “Image Super-Resolution Using Very Deep Residual Channel Attention Networks,” in *Proc. of the European Conference on Computer Vision (ECCV)*, pp. 286-301, 2018.
- [18] J. Liu, W. Zhang, Y. Tang, J. Tang, and G. Wu, “Residual Feature Aggregation Network for Image Super-Resolution,” in *Proc. of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 2359-2368, 2020.
- [19] H.J. Fowler, S. Blenkinsop, and C. Tebaldi, “Linking climate change modelling to impacts studies: recent advances in downscaling techniques for hydrological modelling,” *International Journal of Climatology*, Vol. 27, pp. 1547-1578, 2007.
- [20] C. Draeger, V. Radic, R.H. White, and M.A. Tessemam, “Evaluation of reanalysis data and dynamical downscaling for surface energy balance modeling at mountain glaciers in western Canada,” *The Cryosphere*, Vol. 18, No. 1, 2024.
- [21] L. Stengel, A. Glaws, D. Hettinger, and R.N. King, “Adversarial super-resolution of climatological wind and solar data,” in *Proc. of the National Academy of Sciences*, Vol. 117, No. 29, pp. 16805-16815, 2020.
- [22] U. Pfeifroch, J. Drucke, S. Kothe, J. Trentmann, M. Schroder, and R. Hollmann, “SARAH-3 - satellite-based climate data records of surface solar radiation,” *Earth System Science Data*, Vol. 16, No. 11, pp. 5243-5265, 2024.
- [23] S.K. Jha, V. Gupta, P.J. Sharma, A. Mishra, and S. Joshi, “Deep learning super-resolution for temperature data downscaling: a comprehensive study using residual networks,” *Frontiers in Climate*, Vol. 7, 2025.

저 자 소 개




박영아(정회원)

2025년 국립순천대학교 인공지능공학부 졸업(공학사).

2025년~현재 국립순천대학교 스마트융합학부 멀티미디어공학전공 석사과정

<주관심분야: 컴퓨터 비전, 딥러닝, 생성모델, 객체탐지>



조원지(정회원)

2025년 국립순천대학교 인공지능공학부 졸업(공학사).

2025년~현재 국립순천대학교 스마트융합학부 멀티미디어공학전공 석사과정

<주관심분야: 컴퓨터 비전, 딥러닝, 생성모델>



박성욱(정회원)

2018년 국립순천대학교 컴퓨터공학과 졸업(공학사).

2020년 국립순천대학교 컴퓨터공학과 석사 졸업(공학석사).

2025년 국립순천대학교 스마트융합학부 멀티미디어공학전공 박사 졸업(공학박사).

<주관심분야: 컴퓨터 비전, 딥러닝, 생성모델, 설명 가능한 AI, 적대적 공격>



김용석(준회원)

2007년 경북대학교 응용생물화학부 졸업(학사).

2011년~현재 국립농업과학원 기후변화대응과 연구사

<주관심분야: 기상모델링>



허지나(준회원)

2014년 부산대학교 대기환경전공 졸업(박사).

2018년 National University of Singapore (Research Fellow)

2025년~현재 국립농업과학원 기후변화대응과 연구사

<주관심분야: 지역기후 모델링, 기후변화 시나리오, 농업 기상·기후 예측>

**정세훈(정회원)**

2012년 국립순천대학교 멀티미디어공학과 졸업(공학석사).

2017년 국립순천대학교 멀티미디어공학과 졸업(공학박사).

2018년 영산대학교 빅데이터융합전공 조교수.

2020년 안동대학교 창의융합학부 조교수.

2022년~현재 국립순천대학교 컴퓨터공학과 조교수.

<주관심분야: 소프트웨어공학, 강화학습, 블록체인, 딥러닝, 데이터 마이닝, 빅데이터 분석 및 예측>

**심춘보(정회원)**

1996년 전북대학교 컴퓨터공학과 졸업(공학사).

1998년 전북대학교 컴퓨터공학과 졸업(공학석사).

2003년 전북대학교 컴퓨터공학과 졸업(공학박사).

2005년~현재 국립순천대학교 인공지능공학부 교수.

<주관심분야: 빅데이터, 딥러닝, 생성모델, 자연어처리, 강화학습>