

Super-Resolution Model Based on Wavelet Domain Loss for Improving Wind Speed Forecasting Accuracy

Wonji Jo[†] · Sung-wook Park^{††} · Yong-seok Kim^{†††} · Se-hoon Jung^{††††} · Chun-bo Sim^{†††††}

ABSTRACT

This study proposes a novel GAN-based Super-Resolution (SR) model leveraging wavelet domain loss to improve the accuracy of wind speed prediction. The proposed model integrates an enhanced generator structure into the existing Wavelet-Guided Super-Resolution (WGSR) framework to transform low-resolution wind speed images into high-resolution representations. The generator is composed of three modules: feature extraction, feature refinement, and reconstruction. Dense blocks and Channel Instance Residual Blocks (CIRB) with instance normalization are incorporated to reduce distortion and improve reconstruction performance. Experimental results using the NREL WIND Toolkit dataset demonstrate that the proposed model achieves performance improvements of 9.57% in PSNR, 21.20% in SSIM, and 21.05% in RMSE compared to the original WGSR's RRDBNet. This indicates that the model effectively enhances wind speed images from 10 km per pixel resolution to 2 km per pixel resolution, suggesting its potential applicability in weather forecasting and energy management applications.

Keywords : Super-Resolution, Image Restoration, GAN, Wavelet Transform, Wind Speed Prediction

풍속 예측 정밀도 향상을 위한 웨이블릿 도메인 손실 기반 초해상화 모델

조원지[†] · 박성욱^{††} · 김용석^{†††} · 정세훈^{††††} · 심춘보^{†††††}

요약

풍속 예측의 정밀도 향상을 위해 웨이블릿 도메인 손실을 활용한 새로운 GAN 기반 초해상화 모델을 제안한다. 제안하는 모델은 저해상도 풍속 이미지를 고해상도로 변환하기 위해 기존 Wavelet-Guided Super-Resolution 프레임워크에 개선된 생성자 구조를 통합한다. 생성자 구조는 특징 추출, 특징 정제, 재구성의 세 가지 모듈로 구성되며, 인스턴스 정규화를 포함한 Dense Block과 Channel Instance Residual Block을 도입하여 기존 모델의 왜곡 현상을 완화하고, 복원 성능을 극대화한다. NREL의 WIND Toolkit 데이터셋을 활용한 실험 결과, 제안하는 모델은 기존 WGSR의 RRDBNet 대비 PSNR, SSIM, RMSE 지표에서 각각 9.57%, 21.20%, 21.05%의 성능 향상을 보인다. 이는 픽셀당 10 km 해상도의 풍속 이미지를 픽셀당 2 km 해상도로 효율적으로 변환하며, 기상 예측 및 에너지 관리 분야에서의 활용 가능성을 시사한다.

키워드 : 초해상화, 이미지 복원, GAN, 웨이블릿 변환, 풍속 예측

1. 서론

풍속 예측은 에너지 생산, 기상 예측, 농업, 교통 등 다양한

에서 중요한 역할을 한다[1]. 특히 대한민국과 같이 비교적 지형이 복잡한 지역에서는 좁은 범위에서도 다양한 기상현상이 발생할 수 있어 정밀한 풍속 예측이 요구된다. 이로 인해 고해상도(High-Resolution, HR) 풍속 정보 제공은 필수적이다. 풍속 정보는 재해 피해 예방과 효율적인 대응 전략 수립을 위한 기초 자료로 활용된다.

전통적인 기후 모델은 장기적인 풍속 예측에는 유용하지만, 낮은 공간해상도로 인해 세밀한 풍속 정보를 제공하기 어렵다. 이를 보완하기 위해 딥러닝 기반 초해상화(Super-Resolution, SR) 기술이 연구되고 있다[2]. SR 기술은 저해상도(Low-Resolution, LR) 이미지를 HR로 변환하는 것을 목표

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

† 준회원: 국립순천대학교 IT-Bio융합시스템전공 석사과정

†† 준회원: 국립순천대학교 IT-Bio융합시스템전공 박사수로

††† 비회원: 농촌진흥청 국립농업과학원 농업연수사

†††† 준회원: 국립순천대학교 컴퓨터공학과 교수

††††† 정회원: 국립순천대학교 인공지능공학부 교수

Manuscript Received: October 11, 2024

First Revision: December 11, 2024

Accepted: December 30, 2024

*Corresponding Author: Chun-bo Sim(cbsim@snu.ac.kr)

로 하며, 기존의 전통적 보간법에 비해 더 정교한 결과를 생성할 수 있어 주목받고 있다.

그러나 대부분의 SR 모델은 실제 이미지 품질 향상에 중점을 두어, 물리 데이터 복원에는 한계가 있다. 예를 들어, 확산 모델(Diffusion Model)은 확률적 샘플링(Stochastic Sampling)을 수행하여 각 샘플에 대한 제어력이 부족하고[3], 생성적 적대 신경망(Generative Adversarial Networks, GAN) 기반 SR 모델은 종종 모드 붕괴(Mode Collapse) 문제가 발생한다[4]. 이와 같은 구조적 제약은 풍속 이미지와 같은 물리 데이터의 정밀한 복원을 저해할 수 있다.

본 연구는 이러한 한계를 극복하고자 Wavelet-Guided Super-Resolution(WGSR) 프레임워크[3]를 기반으로 한 풍속 이미지 복원에 최적화된 새로운 SR 모델을 제안한다. WGSR 프레임워크는 GAN 기반 생성자(Generator)와 판별자(Discriminator) 구조에 웨이블릿 변환(Wavelet Transform)을 결합하여 다중 규모 및 특징을 효과적으로 학습한다. 초기 실험에서 WGSR 프레임워크는 풍속 이미지 학습 과정에서 기존 GAN에서 발생하는 모드 붕괴 문제가 관찰되지 않았다. 그러나, WGSR 프레임워크는 본래 실제 이미지 품질 개선에 초점을 맞춰 설계되어, 물리 데이터인 풍속 이미지 복원을 위해서는 구조적 개선이 필요하다.

본 연구는 WGSR 프레임워크의 생성자를 특징 추출(Feature Extraction), 특징 정제(Feature Refinement), 재구성(Reconstruction)의 세 가지 핵심 모듈로 재구성한다. 해당 구조는 풍속 이미지의 변동성을 정밀하게 반영하고, 왜곡(Distortion)을 최소화하는 데 중점을 둔다. 실험 결과, 제안한 모델은 기존 WGSR 모델[3] 대비 풍속 이미지 SR 작업의 정량 및 정성 평가 모두에서 향상된 복원 성능을 보였다.

2. 관련 연구

2.1 GAN 기반 SR

GAN 기반 모델은 SR 분야에서 중요한 기술적 진전을 이뤄왔다. SRGAN은 SRResNet을 생성자로 사용한 첫 번째 GAN 기반 모델로, SR 분야의 기초를 마련했다[5]. 이후 ESRGAN은 SRGAN을 개선하여 Residual in Residual Dense Block(RRDB) 구조를 도입해 학습 안정성을 높이고, 상대적 지각 손실(Relative Perceptual Loss)을 추가하여 더 사실적이고 품질 높은 이미지를 생성했다[6]. 현재 ESRGAN은 GAN 기반 SR의 성능 비교 기준 모델로써 널리 사용되고 있다.

최근에는 다양한 변형을 통해 생성된 이미지의 품질을 향상하는 연구가 활발히 이뤄지고 있다. 훈련 메커니즘을 개선한 RankSRGAN[7], 실제 환경의 열화 요인(Degradation Factor)을 반영하여 Blind SR 문제를 해결한 BSRGAN 및 Real-ESRGAN[8-9] 등이 대표적인 예다. 이러한 연구들은 SR 모델의 성능을 높이고, 실제 환경에서의 적용 가능성을 확장

하는 데 기여하고 있다.

2.2 풍속 이미지 SR

풍속 이미지에도 SR 기술이 적용된 연구가 있다. WindSR은 픽셀당 28 km 해상도의 LR 이미지와 픽셀당 7 km 해상도의 HR 이미지 쌍을 활용해 4배 업스케일링(Upscaling)을 수행하는 SR 모델이다[1]. [1]의 연구는 GEOS-5 Nature Run 데이터셋을 사용해 20,046개의 훈련 데이터와 2,102개의 검증 데이터를 통해 훈련됐으며, SRResNet 구조를 기반으로 RRDB를 적용한 모델을 제안했다. 경량 버전인 tiny-WindSR은 하나의 RRDB를 사용한다. WindSR과 tiny-WindSR은 전통적인 보간(Interpolation) 기법 및 BSRGAN, SwinIR과 같은 딥러닝 기반 기술에 비해 최대 17.79%까지 성능 개선을 보였다.

적대적 훈련(Adversarial Training)을 사용한 연구[10]에서는 글로벌 기후 모델(Global Climate Model, GCM)의 출력 개선을 위해 SR 기술을 적용하여 일사량 및 풍속의 HR 이미지를 생성했다. 풍속의 경우, Wind Integration National Dataset(WIND) Toolkit 데이터를 사용해 모델을 훈련하고, Mean Squared Error(MSE)와 난류의 물리적 특성을 기준으로 검증했으며, 적대적 훈련 방식이 생성된 이미지가 실제 이미지와 일관성을 유지하도록 보장함을 시사했다.

3. 제안하는 방법

3.1 데이터셋 구축 및 전처리 과정

본 연구에서는 National Renewable Energy Laboratory(NREL)에서 제공하는 WIND Toolkit[11]을 사용한다. WIND Toolkit은 미국 전역의 126,000개 이상의 지점에서 수집된 다양한 기상 변수를 2 km×2 km의 공간해상도로 제공한다. 대한민국 HR 풍속 데이터의 부재로 인해, 기후 조건이 유사한 미국 중남부, 서부 내륙, 동부 해안 중부 지역을 대상 지역으로 선정하고, 해당 지역들의 데이터를 본 연구에 사용했다.

대상 지역의 위도 및 경도 정보는 Lambert Conformal Conic(LCC) 투영법을 통해 변환한 후, 선행 연구[12]의 가이드라인에 따라 지표면으로부터 100m 높이에서의 풍속 및 풍향 정보를 추출했다. 추출된 풍속 데이터는 동서 방향(Eastward) 성분인 'ua'와 남북 방향(Northward) 성분인 'va'로 분리하여 구성했다.

Table 1에 요약된 바와 같이, 2007년 1월 1일부터 2013년 12월 31일까지 4시간 간격으로 수집된 풍속 및 풍향 데이터를 100×100 크기의 HR 이미지로 변환했다. 이후, 생성된 이미지를 픽셀당 10 km 해상도의 20×20 LR 이미지로 다운샘플링(Downsampling)하여 HR-LR 쌍의 데이터셋을 구축했다. 최종적으로 총 4,326쌍의 HR-LR 데이터를 확보했다.

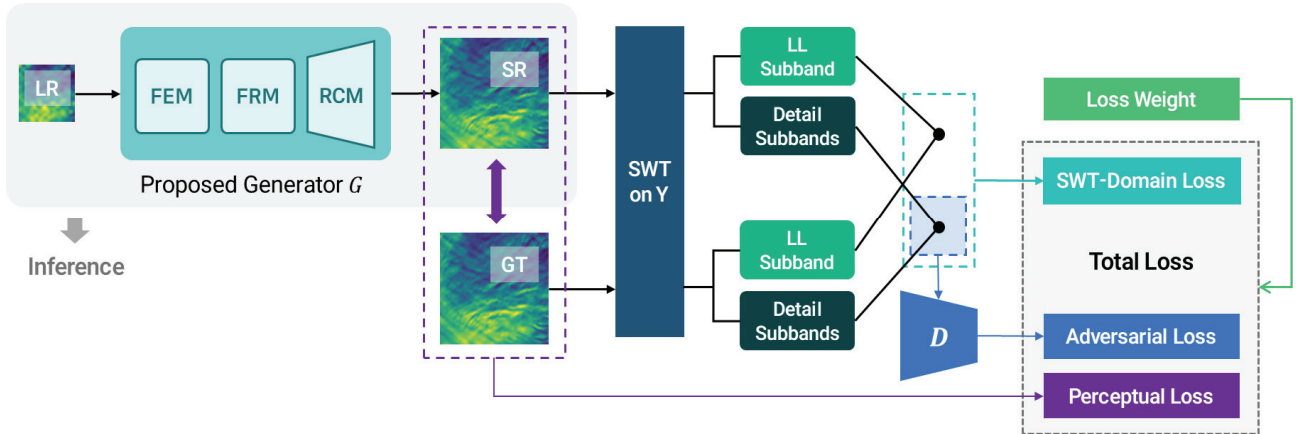


Fig. 1. WGSR Framework with Proposed Generator for Wind Speed Super-Resolution

Table 1. Dataset Summary

Item	Description
Data Source	WIND Toolkit of NREL
Spatial Resolution	2 km×2 km
Temporal Resolution	4-hour intervals, 2007.01.01~2013.12.31
Target Area	South Central, Interior West, Mid-Atlantic
Variables	Windspeed_100, Winddirection_100

3.2 WGSR 프레임워크 구조

Fig. 1은 3.3절에서 논의될 제안하는 생성자를 포함한 WGSR 프레임워크의 개요다. WGSR 프레임워크는 생성자 G 와 판별자 D 로 구성되며, LR 풍속 이미지를 입력받아 HR 풍속 이미지를 생성한다. 생성자는 LR 이미지를 기반으로 SR 이미지를 생성하며, 판별자와의 훈련을 통해 Ground Truth(GT) 이미지와 최대한 유사한 HR 이미지를 생성하도록 최적화된다.

생성된 SR 이미지와 GT 이미지는 YCbCr 색 공간으로 변환한 후, Y 채널에 대해 정지 웨이블릿 변환(Stationary Wavelet Transform, SWT)을 적용한다. SWT는 이미지를 저주파수 하위 대역(Subband)인 Low-Low(LL)와 고주파수 하위 대역인 Low-High(LH), High-Low(HL), High-High(HH)로 분해한다. LL 대역은 이미지의 전반적인 구조를 나타내고, 고주파수 대역은 세부적인 디테일(Detail)을 나타낸다.

본 프레임워크의 손실 함수는 세 가지 주요 항목으로 구성된다. SWT 도메인 손실은 각 하위 대역의 기여도를 개별적으로 가중하여 SR 이미지의 충실도(Fidelity)와 디테일 간의 균형을 유지한다. 적대적 손실(Adversarial Loss)은 판별자를 피드백을 활용해 SR 이미지의 고주파수 대역이 GT 이미지와 유사한 디테일과 질감을 가지도록 유도한다. 시각 손실(Perceptual Loss)은 픽셀 도메인에서 작동하며, Deep Image Structure and Texture Similarity(DISTS)[13] 지표를 사용해 SR 이미지와 GT 이미지 간의 구조적 차이를 특징 공간(Feature Space)에서 정량화하며, 이를 통해 시각적 유사성을

반영한다. 각 손실 항목은 손실 가중치(Loss Weight)를 통해 조정되며, 생성자는 이를 기반으로 최적의 HR 이미지를 복원하도록 학습된다.

3.3 제안하는 생성자 구조


Fig. 2는 제안하는 생성자의 전체적인 구조와 각 모듈의 세부 구성을 보여준다. 생성자는 입력 이미지를 HR 이미지로 변환하기 위해 특징 추출 모듈, 특징 정제 모듈, 재구성 모듈 세 단계로 구성된다. 각 단계는 유기적으로 연결되어 작동하며, Fig. 2(a)는 생성자 전체 구조를, Fig. 2(b)는 특징 정제 모듈에서 사용되는 Chanel Instance Residual Block(CIRB)의 세부 구성을, Fig. 2(c)는 재구성 모듈의 최종 HR 이미지를 생성한다.

기존 WGSR 연구에서는 ESRGAN의 RRDB를 생성자의 백본(Backbone)으로 사용했으나, 이는 풍속 이미지의 복잡한 패턴을 충분히 반영하지 못하는 한계가 있다. 이를 해결하기 위해 본 연구는 Dense Block 기반의 특징 추출, CIRB 기반의 특징 정제, 다단계 업스케일링 기반의 재구성 모듈로 구성된 생성자 구조를 제안한다. Dense Block은 입력 데이터에서 중요한 LR 특징을 효과적으로 추출하고, CIRB는 채널 및 인스턴스 정보를 결합하여 정제된 특징을 학습한다. 재구성 모듈은 다단계 업스케일링을 통해 복잡한 고주파수 세부 정보를 보존하며 최종 HR 이미지를 생성한다. 추가적으로, 입력부와 출력부의 컨볼루션 레이어는 입력 데이터의 초기 특징을 추출하고 HR 이미지의 디테일을 강화하여 최종적으로 높은 품질의 결과물을 보장한다.

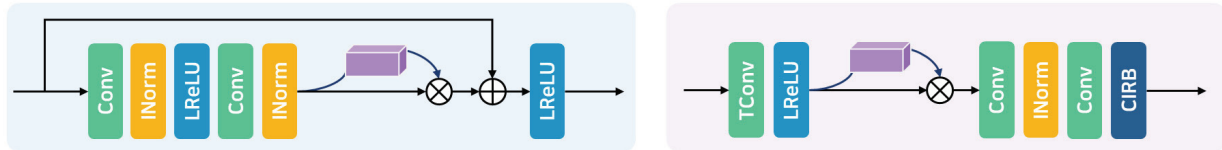
제안한 생성자의 모듈에 대한 세부 사항은 1) 특징 추출 모듈, 2) 특징 정제 모듈, 3) 재구성 모듈에서 자세히 다룬다.

1) 특징 추출 모듈

특징 추출 모듈은 DenseNet의 Dense Block[14]을 기반으로 설계했다. Dense Block은 밀집 연결(Dense Connections)을 통해 다양한 수준의 정보 흐름을 효율적으로 유지하고 특



(a) Proposed Generator Architecture



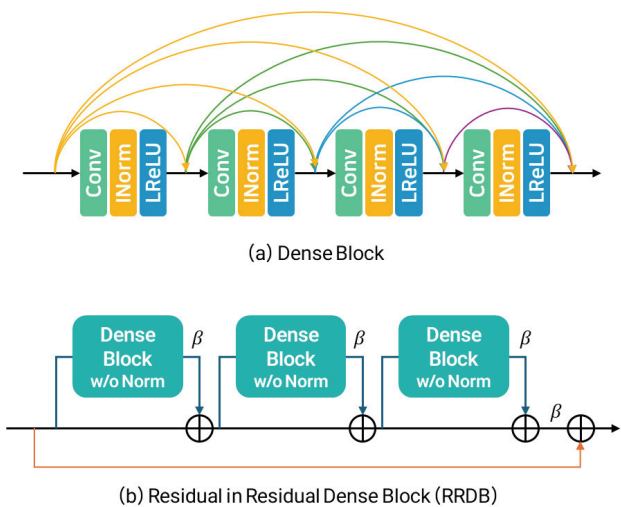
(b) Channel Instance Residual Block (CIRB)

(c) Reconstruction Module

Fig. 2. Proposed Generator Architecture: Feature Extraction, Refinement, and Reconstruction Modules

정 재사용을 촉진한다. 본 연구에서 Dense Block과 RRDB로 대체하여 실험한 결과, 풍속 이미지 복원에는 Dense Block이 더 효과적임을 확인했다. 이는 Dense Block의 깊은 연결 구조가 복잡한 패턴을 학습에 유리하다는 점을 시사한다.

Dense Block은 일반적으로 배치 정규화(Batch Normalization)를 사용하지만, 배치 정규화 기법은 GAN 훈련 과정에서 불필요한 아티팩트(Artifact)를 유발할 수 있다[6]. 이에 따라, 본 연구는 배치 정규화 대신 인스턴스 정규화(Instance Normalization)를 적용하여 데이터 분포를 안정화하고 아티팩트를 줄였다. 이 접근법은 Half Instance Normalization을 적용한 최근 연구[15]에서 인스턴스 정규화의 효과를 확인한 데서 영감을 얻었다. 본 연구에서 사용한 Dense Block과 RRDB의 구조적 차이는 Fig. 3(a)와 Fig. 3(b)에 제시한 바와 같다.



(a) Dense Block

(b) Residual in Residual Dense Block (RRDB)

Fig. 3 Structural Comparison: Dense Block vs. Residual in Residual Dense Block (RRDB)

2) 특징 정제 모듈

특징 정제 모듈은 Fig. 2(b)의 CIRB를 이용하여 이전 모듈에서 추출된 특징을 더욱 정교하게 조정한다. 본 모듈은 중요한 특징을 기반으로 고주파수 정보를 추가로 강화하여 생성된 이미지가 자연스럽게 선명하게 보이도록 한다.

CIRB의 첫 단계는 입력 특징을 3×3 컨볼루션 레이어로 처리하고, 각 샘플을 독립적으로 정규화하기 위해 인스턴스 정규화를 적용한다. 이를 통해 특징 간의 일관성을 유지할 수 있다. 이후 LeakyReLU 활성화 함수를 통해 비선형성을 도입하여 기울기 소실 문제를 완화한다. 이어지는 두 번째 컨볼루션 레이어와 인스턴스 정규화를 거친 특징 맵(Feature Map)에는 채널 어텐션 메커니즘(Channel Attention Mechanism)을 적용하여 중요한 정보를 강조한다.

3) 재구성 모듈

Fig. 2(c)의 재구성 모듈은 전치 컨볼루션(Transposed Convolution) 연산을 통해 이전 모듈에서 추출된 특징 맵을 업스케일링한다. 이후, LeakyReLU 활성화 함수를 사용하여 비선형성을 도입하고, 채널 어텐션 메커니즘을 적용하여 중요한 패턴과 고주파수 정보를 더 선명하게 반영한다. 강조된 채널 정보를 바탕으로 첫 번째 컨볼루션 레이어는 입력된 특징 맵을 정제하고, 인스턴스 정규화를 통해 데이터 분포를 안정화한다. 두 번째 컨볼루션 레이어는 복잡한 패턴을 학습하기 위해 데이터를 추가 처리한 후 CIRB를 적용한다. 이러한 과정을 통해 재구성 모듈은 HR 이미지를 자연스럽게 명확하게 재구성할 수 있다.

4) 채널 어텐션 메커니즘

Fig. 2(b)와 Fig. 2(c)에 이용된 채널 어텐션 메커니즘은 Fig. 4와 동일하며, Convolution Block Attention Module(CBAM)[16]의 채널 어텐션 구조를 기반으로 한다. 입력 특징 맵 $F \in \mathbb{R}^{C \times H \times W}$ 에




Fig. 4 Channel Attention Mechanism in Proposed Generator

대해 평균 풀링(Average Pooling)과 최대 풀링(Max Pooling)을 독립적으로 수행하여 두 가지 통계적 정보를 얻는다. 이 과정은 Equation (1)과 같다.

$$F_{avg} = AvgPool(F), F_{max} = MaxPool(F) \quad (1)$$

두 풀링 결과 F_{avg} 와 F_{max} 는 Shared MLP 모듈 내부의 FC-ReLU-FC 구조를 공유하여 각각의 통계적 특징을 학습하며, 이는 Equation (2)로 나타낼 수 있다.

$$\begin{aligned} W_{avg} &= \sigma(W_2 \cdot ReLU(W_1 \cdot F_{avg})), \\ W_{max} &= \sigma(W_2 \cdot ReLU(W_1 \cdot F_{max})) \end{aligned} \quad (2)$$

여기서 W_1 과 W_2 는 Shared MLP 내부에서 공유하는 Fully Connected(FC) 레이어의 가중치 행렬이고, σ 는 시그모이드(Sigmoid) 활성화 함수이다. 두 경로의 가중치 W_{avg} 와 W_{max} 는 동일한 Shared MLP 구조를 거친 후 결합되어 최종 채널 가중치 W_{final} 을 생성하며, 이는 Equation (3)으로 표현된다.

$$W_{final} = W_{avg} + W_{max} \quad (3)$$

최종적으로 채널 가중치 W_{final} 은 입력 특징 맵 F 에 곱해져 중요한 채널이 강조된 출력 특징 맵 F' 을 생성한다. 이 과정은 Equation (4)로 나타낼 수 있다.

$$F' = W_{final} \cdot F \quad (4)$$

3.4 손실 함수 및 훈련 전략

WGSR 프레임워크는 RGB 도메인 손실 대신 SWT 도메인 손실 L_{SWT} 을 사용한다. 각 하위 대역에서 손실 기여도를 개별적으로 조정하고, SR 이미지의 충실도와 지각적 품질(Perceptual Quality) 간의 균형을 맞춘다. 손실 함수는 Equation (5)와 같다. Equation (5)에서 G 는 생성자를 의미하고, λ_j 는 각 하위 대역의 기여도를 조정하는 스케일링 계수(Factor)다. 입력 이미지 x 로부터 생성된 이미지 $G(x)$ 와 GT 이미지 y 를 각각 SWT 도메인으로 변환한 후, 동일한 하위 대역 간의 L_1 손실을 계산한다. 이때 손실 값은 미니 배치 크기만큼 평균내어 전체 손실로 사용되고, 이를 통해 각 주파수 대역에서 SR 이미지의 복원 성능을 극대화할 수 있다.

$$L_{SWT} = \mathbb{E}[\sum_j \lambda_j \|SWT(G(x))_j - SWT(y)_j\|_1] \quad (5)$$

Equation (6)은 적대적 손실이다. D 는 판별자를 의미하고, $*$ 는 고주파수 하위 대역 간의 연결을 나타낸다. 적대적 손실은 판별자가 생성된 이미지와 GT 이미지를 올바르게 구분할 수 있도록 유도하고, 생성자는 판별자가 생성된 이미지 $G(x)$ 와 GT 이미지 y 를 구분하지 못하도록 학습한다.

$$L_{adv,G} = -\mathbb{E}[\log(1 - D(SWT(y)_*))] - \mathbb{E}[\log D(SWT(G(x))_*)] \quad (6)$$

Equation (7)은 생성자의 전체 손실 함수를 나타낸다. L_{perc} 는 DISTS[13]의 특징 공간에서 오류를 측정하는 지각 손실을 의미한다. $\lambda_{adv,G}$ 와 λ_{perc} 는 각각 적대적 손실과 지각 손실의 가중치를 조정하는 계수로, 생성자의 최종 손실에 포함되어 모델이 다양한 관점에서 균형 잡힌 학습을 수행할 수 있도록 한다.

$$L_G = L_{SWT} + \lambda_{adv} \cdot L_{adv,G} + \lambda_{perc} \cdot L_{perc} \quad (7)$$

Equation (8)은 판별자 손실을 정의한다. 판별자는 LH, HL, HH와 같은 고주파수 하위 대역만을 입력으로 사용하여, 생성된 이미지와 GT 이미지 간의 세부 차이를 학습한다.

$$L_D = -\mathbb{E}[\log D(SWT(y)_*)] - \mathbb{E}[\log(1 - D(SWT(G(x))_*))] \quad (8)$$

기존 WGSR 연구에서는 경험적으로 계수 값을 $\lambda_{LL} = 0.1$, $\lambda_{LH} = \lambda_{HL} = 0.01$, $\lambda_{HH} = 0.05$, $\lambda_{adv} = 0.005$, $\lambda_{perc} = 1$ 로 설정했을 때, 지각적 품질과 왜곡 간의 트레이드 오프(Trade-Off) 최적점을 달성한다고 보고했다. 따라서 본 연구에서도 동일한 값을 사용하여 실험을 진행한다.

4. 실험 및 결과

4.1 실험 환경 설정

구축한 데이터셋을 8:1:1 비율로 훈련, 검증, 테스트용으로 분할했다. 정량적 평가 지표로는 Peak Signal-to-Noise Ratio

Table 2. Experimental Environment Settings

Component	Details
CPU	Intel Core i9-12900K
GPU	NVIDIA GeForce RTX 3090 Ti, 24GB
RAM	Samsung DDR5 32GB × 4
Operating System	Ubuntu 20.04.6 LTS
CUDA Version	11.8.89
cuDNN Version	8.7.0
Programming Language	Python 3.9.19
Deep Learning Library	PyTorch 2.4.0

(PSNR)와 Structural Similarity Index Measure(SSIM), 그리고 Root Mean Square Error(RMSE)를 사용했다. 특히 RMSE는 풍속 이미지의 실제 값과 동일한 단위를 사용하여 직관적으로 예측 성능을 평가하는 항목이다.

모델 훈련 시, 생성자와 판별자의 학습률(Learning Rate)은 1×10^{-4} 로 설정하고, Adam 옵티마이저(Optimizer)와 모멘텀(Momentum) 값 0.9를 사용했다. 학습률은 MultiStepLR 스케줄러(Scheduler)를 통해 3,000, 10,000, 15,000, 20,000 스텝(Step)에서 0.5배씩 감소시켰다. 웨이블릿 변환은 sym7 필터와 1단계 변환을 적용하였으며, 판별자는 Visual Geometry Group(VGG) 기반 구조를 사용했다. 생성자와 판별자의 가중치는 각각 0.1과 0.005로 설정하여 모델의 균형을 맞췄고, 전체 학습은 21,600 스텝 동안 진행됐다. 손실 함수 계수는 3.4 절의 값을 사용했으며, 실험 환경의 세부 설정은 Table 2와 같다.

4.2 성능 비교를 위한 기준 모델

본 연구에서는 기존 WGSR의 공식 구현에서 사용된 RRDBNet과 SRResNet을 비교 대상으로 선정했다. 특히 RRDBNet은 해당 논문에서 다양한 최신 모델들과 비교하여 높은 성능을 보였기 때문에 동일한 WGSR 프레임워크 내에서 제안하는 모델과의 성능 차이를 분석하는 데 적합하다.

제안하는 생성자의 성능 향상에 있어 특징 정제 모듈의 기여도를 평가하기 위해, 해당 모듈을 제거한 구조를 추가적으로 비교했다. 또한, 특징 추출 모듈에서 Dense Block의 효과를 검증하기 위해, Dense Block을 기존의 RRDB로 대체한 구조를 함께 실험하여 비교했다.

4.3 정량적 평가

Table 3은 다양한 모델 구조에 대한 정량적 평가 결과를 나타낸다. 실험 결과, 제안하는 생성자를 사용한 모델이 PSNR, SSIM, RMSE 모든 지표에서 기존 생성자 기반 모델보다 우수한 성능을 보였다. Table 3에서 본 연구의 모델을 'WS-SRNet'으로 표기했으며, 특징 정제 모듈을 제거한 모델은 'NoRefine',

Table 3. Quantitative Comparison of Proposed and Existing Generator Models

Generator Type	PSNR ↑	SSIM ↑	RMSE ↓
RRDBNet	22.670	0.566	0.076
SRResNet	22.080	0.541	0.082
DB→RRDB (Ours)	22.573	0.532	0.077
NoRefine (Ours)	23.800	0.647	0.067
WS-SRNet (Ours)	24.839	0.686	0.060

Dense Block을 RRDB로 대체한 모델은 'DB→RRDB'로 표기했다. 또한, 기존 생성자 구조를 사용한 모델은 'RRDBNet'과 'SRResNet'으로 각각 표기했다.

제안하는 모델과 비교했을 때, 'NoRefine' 모델은 PSNR이 4.18%, SSIM이 5.69% 감소하고, RMSE는 11.67% 증가하여 특징 정제 모듈이 SR 이미지의 품질 개선에 중요한 역할을 한다는 것을 확인할 수 있었다. 또한, 제안하는 모델과 'DB→RRDB' 모델을 비교한 결과, PSNR이 9.12% 감소하고, SSIM이 22.45% 감소했으며, RMSE는 28.33% 증가했다. 이는 Dense Block이 풍속 이미지의 SR 성능 향상에 RRDB보다 더 적합한 구조임을 의미한다.

마지막으로, 제안하는 모델과 기존 생성자를 사용한 모델을 비교한 결과, 제안하는 모델을 기준으로 'RRDBNet'은 PSNR이 9.57%, SSIM이 21.20%, RMSE가 21.05% 성능 차이를 보였고, 'SRResNet'은 각각 12.50%, 26.80%, 26.83%의 차이를 보여 전반적으로 제안하는 모델이 기존 모델들보다 우수한 성능을 보였다.

4.4 정성적 평가

Fig. 5는 제안한 생성자와 비교 대상 모델들의 'ua' 및 'va' 성분에 대한 샘플 출력 결과를 시각적으로 비교한 결과다. 각 샘플 아래에 표기된 값은 해당 이미지의 SSIM 및 RMSE 값을 나타낸다. 'RRDBNet'과 'SRResNet'은 GT 이미지와 비교했을 때, 풍속 이미지의 세부 패턴을 정확히 복원하지 못하는 경향을 보였다. 두 모델은 경계 영역과 복잡한 패턴의 표현에서 왜곡이 발생했으며, 정량적 평가에서도 낮은 성능을 보였다.

특징 정제 모듈을 제거한 'NoRefine'과 Dense Block을 RRDB로 대체한 'DB→RRDB' 또한 세부 정보가 부정확하게 재현되어 시각적 품질이 저하되는 결과를 보였다. 반면, 'Ours'로 표기한 우리 모델은 GT와 가장 유사한 결과를 보여줬으며, 'ua' 및 'va' 성분 모두에서 세밀한 구조와 경계선을 정확하게 복원했다. 이는 제안하는 모델이 기존 모델 대비 풍속 이미지의 특성을 더 효과적으로 학습하고, 세부적인 텍스처와 패턴을 정밀하게 재현할 수 있음을 시사한다.

4.5 추가 분석 및 고찰

제안하는 생성자 구조에서 인스턴스 정규화와 채널 어텐션 메커니즘의 효과를 분석하기 위해, 각 요소를 제거한 실험을

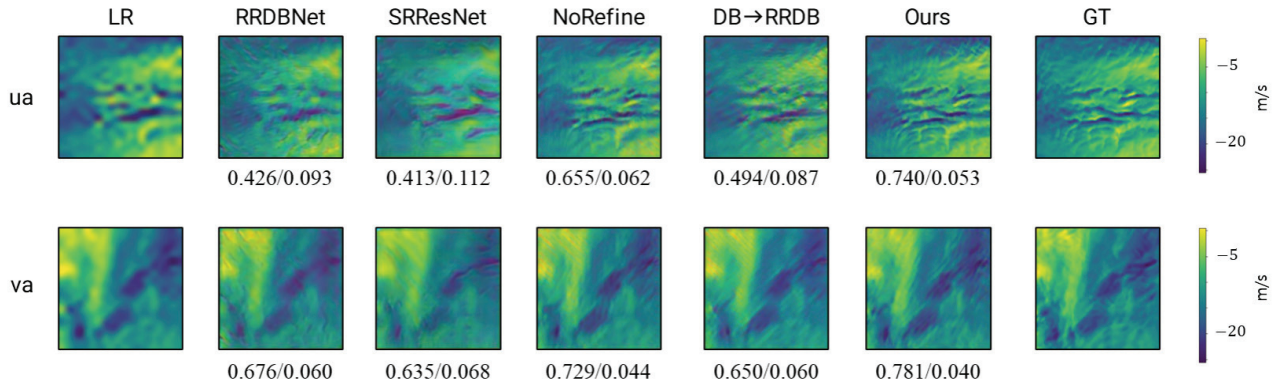


Fig. 5. Visual Comparison of SR Results for Eastward (ua) and Northward (va) Wind Components

추가로 진행했다. Table 4는 정량적 평가 결과를, Fig. 6은 대각선 아티팩트가 두드러지는 밝은 영역을 확대하여 비교한 결과다.

Fig. 6에서 볼 수 있듯이, 채널 어텐션 메커니즘과 인스턴스 정규화를 모두 적용했을 때 대각선 아티팩트가 가장 크게 감소했다. 이는 두 기법이 고주파수 성분에 과도하게 집중되는 현상을 효과적으로 억제함을 나타낸다. 반면, Table 4의 PSNR, SSIM, RMSE 지표에서는 각 실험 간 차이가 미미하다. 이는 정량적 평가 지표들이 이미지의 미세한 디테일을 충분히 반영하여 평가하지 못한다는 한계를 보여준다.

Table 4. Ablation Study: Impact of Channel Attention and Instance Normalization

	PSNR ↑	SSIM ↑	RMSE ↓
w/o Instance Normalization	24.704	0.648	0.061
w/o Channel Attention	24.496	0.678	0.062
Ours	24.839	0.686	0.060

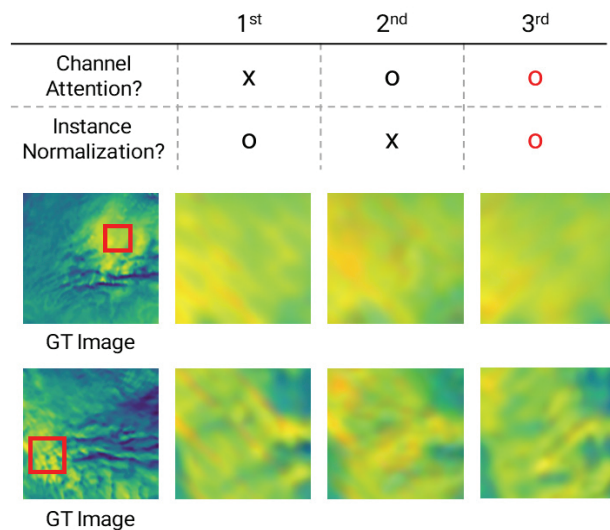


Fig. 6. Impact of Channel Attention and Instance Normalization on SR Quality

5. 결론

본 논문에서는 풍속 이미지의 공간해상도 향상을 위해 WGSr 프레임워크와 개선된 생성자 구조를 결합한 모델을 제안했다. 제안하는 모델은 기존 생성자 구조를 사용한 모델 대비 정량적 및 정성적 평가 결과에서 더 높은 품질을 나타냈다. 하지만, 정량적 평가 지표만으로는 이미지의 미세한 디테일과 시각적 품질 차이를 충분히 평가하기 어려워 각 모듈의 구체적인 기여를 명확히 규명하는 데 한계가 있었다.

향후 연구에서는 다양한 SR 모델들과의 비교 실험을 통해 제안하는 모델의 성능을 체계적으로 분석하고, 각 모듈이 풍속 이미지의 고주파수 성분 및 세부 정보 복원에 미치는 영향을 심층적으로 연구할 계획이다. 이러한 연구는 풍속 이미지 SR 모델의 실질적인 응용 가능성을 높이고, 복잡한 기상 데이터에서의 활용도를 극대화하는 데 기여할 것으로 사료된다.

References

- [1] A. Kumar, T. Islam, J. Ma, T. Kashiyama, Y. Sekimoto, and C. Mattmann, "WindSR: Improving spatial resolution of satellite wind speed through super-resolution," *IEEE Access*, Vol.11, pp.69486-69494, 2023.
- [2] L. Schmidt and N. Ludwig, "Wind Power Assessment based on Super-Resolution and Downscaling--A Comparison of Deep Learning Methods," *arXiv preprint arXiv:2407.08259*, 2024.
- [3] C. Korkmaz, A. M. Tekalp and Z. Dogan, "Training Generative Image Super-Resolution Models by Wavelet-Domain Losses Enables Better Control of Artifacts," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp.5926-5936, 2024.
- [4] H. Li, Y. Yang, M. Chang, S. Chen, H. Feng, Z. Xu, Q. Li and Y. Chen, "Srdiff: Single image super-resolution with diffusion probabilistic models," *Neurocomputing*, Vol.479,

pp.47-59, 2022.

[5] C. Ledig, L. Theis, F. Huszar, J. Caballero, A. Cunningham, A. Acosta, A. Aitken, A. Tejani, J. Totz and W. Shi, "Photo-realistic single image super-resolution using a generative adversarial network," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.4681-4690, 2017.

[6] X. Wang, K. Yu, S. Wu, J. Gu, Y. Liu, C. Dong, C. C. Loy, Y. Qiao and X. Tang, "Esrgan: Enhanced super-resolution generative adversarial networks," in *Proceedings of the European Conference on Computer Vision Workshops*, pp.0-0, 2018.

[7] W. Zhang, Y. Liu, C. Dong and Y. Qiao, "Ranksrgan: Generative adversarial networks with ranker for image super-resolution," in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp.3096-3105, 2019.

[8] K. Zhang, J. Liang, L. Van Gool and R. Timofte, "Designing a practical degradation model for deep blind image super-resolution," in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp.4791-4800, 2021.

[9] X. Wang, L. Xie, C. Dong and Y. Shan, "Real-esrgan: Training real-world blind super-resolution with pure synthetic data," in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp.1905-1914, 2021.

[10] L. Stengel, A. Glaws, D. Hettinger and R. N. King, "Adversarial super-resolution of climatological wind and solar data," *Proceedings of the National Academy of Sciences*, Vol.117, No.29, pp.16805-16815, 2020.

[11] C. Draxl, B. M. Hodge, A. Clifton and J. McCaa, "Overview and Meteorological Validation of the Wind Integration National Dataset Toolkit (Technical Report, NREL/TP-5000-61740)," Golden, CO: National Renewable Energy Laboratory, 2015.

[12] R. Kurinchi-Vendhan, B. Lujens, R. Gupta, L. Werner and D. Newman, "Wisosuper: Benchmarking super-resolution methods on wind and solar data," *arXiv preprint arXiv: 2109.08770*, 2021.


[13] K. Ding, K. Ma, S. Wang and E. P. Simoncelli, "Image quality assessment: Unifying structure and texture similarity," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.44, No.5, pp.2567-2581, 2020.

[14] G. Huang, Z. Liu, L. Van Der Maaten and K. Q. Weinberger, "Densely connected convolutional networks," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.4700-4708, 2017.

[15] X. Guo, Z. Tu, H. Zhang and H. Dong, "Super-resolution reconstruction based on generative adversarial networks with dual branch half instance normalization," *IET Image Processing*, Vol.18, No.6, pp.1434-1446, 2024.

[16] S. Woo, J. Park, J. Y. Lee and I. S. Kweon, "Cbam: Convolutional block attention module," in *Proceedings of the European Conference on Computer Vision*, pp.3-19, 2018.

[17] Y. Zhang, K. Li, K. Li, L. Wang, B. Zhong and Y. Fu, "Image super-resolution using very deep residual channel attention networks," in *Proceedings of the European Conference on Computer Vision*, pp.286-301, 2018.



조 원 지

<https://orcid.org/0000-0001-8042-7220>

e-mail : wonji1283@naver.com

2024년 국립순천대학교

멀티미디어공학과(학사)

2024년~현재 국립순천대학교

스마트융합학부 멀티미디어공학전공

(석사과정)

관심분야 : 컴퓨터 비전, 딥러닝, 생성모델



박 성 옥

<https://orcid.org/0000-0003-1051-9263>

e-mail : 411050@scnu.ac.kr

2018년 국립순천대학교 컴퓨터공학과

졸업(공학사)

2020년 국립순천대학교 컴퓨터공학과

졸업(공학석사)

2023년 국립순천대학교 스마트융합학부 멀티미디어공학전공

박사수료

관심분야 : 컴퓨터 비전, 딥러닝, 생성모델, 설명 가능한 AI, 적대적 공격



김 용 석

<https://orcid.org/0000-0003-0515-1388>

e-mail : cyberdoli@korea.kr

2007년 경북대학교 응용생물화학부(학사)

2011년~현재 국립농업과학원 농업연구사

관심분야 : 기상 모델링



정 세 훈

<https://orcid.org/0000-0002-1776-9823>

e-mail: shjung@scnu.ac.kr

2012년 국립순천대학교 멀티미디어공학과
졸업(공학석사)

2017년 국립순천대학교 멀티미디어공학과
졸업(공학박사)

2018년 영산대학교 빅데이터융합전공 조교수

2020년 국립안동대학교 창의융합학부 조교수

2022년~현재 국립순천대학교 컴퓨터공학과 조교수

관심분야: 블록체인, 딥러닝, 생성모델, 빅데이터 분석 및 예측



심 춘 보

<https://orcid.org/0000-0003-0802-6355>

e-mail: cbsim@scnu.ac.kr

1996년 전북대학교 컴퓨터공학과
졸업(공학사)

1998년 전북대학교 컴퓨터공학과
졸업(공학석사)

2003년 전북대학교 컴퓨터공학과 졸업(공학박사)

2005년~현재 국립순천대학교 인공지능공학부 교수

관심분야: 빅데이터, 블록체인, 딥러닝, 생성모델, 자연어 처리,
강화 학습