

AI 기반 전지구 기후 모델링 및 예측 시스템 개발 동향

조현수¹⁾ · 함유근^{2)*} · 오설희³⁾ · 이정길¹⁾ · 성민규¹⁾ · 조동진¹⁾ ·
임소민¹⁾ · 강선유¹⁾ · 정수연⁴⁾ · 이현정¹⁾ · 이수빈²⁾ · 권규희²⁾

¹⁾서울대학교 환경계획연구소, ²⁾서울대학교 환경대학원 환경관리학과,
³⁾한국과학기술원 정보전자연구소, ⁴⁾서울대학교 지속가능발전연구소

(접수일: 2025년 8월 17일, 수정일: 2025년 10월 27일, 게재확정일: 2025년 11월 3일)

Recent Advances in AI-based Global Climate Modeling and Forecasting

Hyun-Su Jo¹⁾, Yoo-Geun Ham^{2)*}, Seol-Hee Oh³⁾, Jeong-Gil Lee¹⁾, Min-Gyu Seong¹⁾, Dongjin Cho¹⁾,
Somin Lim¹⁾, Seon-Yu Kang¹⁾, Suyeon Jeong⁴⁾, Hyun-Jeong Lee¹⁾, Subin Lee²⁾, and Gyuhui Kwon²⁾

¹⁾Environmental Planning Institute, Seoul National University, Seoul, Korea

²⁾Department of Environmental Management, Graduate School of Environmental Studies,
Seoul National University, Seoul, Korea

³⁾Information & Electronics Research Institute, Korea Advanced Institute of Science and Technology,
Daejeon, Korea

⁴⁾Institute for Sustainable Development, Seoul National University, Seoul, Korea

(Manuscript received 17 August 2025; revised 27 October 2025; accepted 3 November 2025)

Abstract Recent advances in artificial intelligence (AI) technologies are broadly integrated across all stages of climate prediction systems, driving significant innovations. Deep learning-based weather prediction models are rapidly progressing worldwide, demonstrating performance surpassing that of traditional numerical model-based integrated forecasting systems. In ocean modeling, deep learning simultaneously learns local detailed structures and global ocean configurations, precisely simulating complex ocean dynamics from mesoscale eddies to extensive current patterns, thereby substantially enhancing prediction ability. For land surface modeling, deep learning adopts hybrid forms combined with physics-based approaches to more accurately reproduce intricate land responses, with the integration of vegetation water stress modules enabling realistic depictions of land-atmosphere interactions. In data assimilation, AI contributions are prominent, where deep learning methods utilizing automatic differentiation, diffusion models, and image restoration techniques offer superior computational efficiency and expressiveness compared to conventional data assimilation approaches. Recent technologies like Variational AutoEncoders and Score-based Diffusion effectively incorporate high-dimensional nonlinear characteristics, continuously improving ocean and atmospheric initial field performance. Various deep learning methods exhibit potential for high-resolution enhancement of climate prediction outputs, while deep learning-based generative models are primarily employed for post-processing techniques to correct model biases. Beyond technical advances, AI-based technologies provide a strategic pathway toward operational implementation and climate services, enhancing both forecast accuracy and computational efficiency. Collectively, these devel-

*Corresponding Author: Yoo-Geun Ham, Department of Environmental Management, Graduate School of Environmental Studies, Seoul National University, 1 Gwanak-ro, Gwanak-gu, Seoul 08826, Korea.
Phone: +82-2-880-8522, Fax: +82-2-885-2096
E-mail: yoogeun@snu.ac.kr

opments point toward an integrated, next-generation climate prediction framework that bridges physical modeling, data-driven methods, and practical applications.

Key words: AI-based global weather forecasting, AI-based data assimilation, AI-based post-processing, AI-based super-resolution, AI-based carbon cycle

1. 서 론

기후 변화로 인한 전지구적 재난과 재해의 빈도가 증가함에 따라, 예측 모델의 정확도 향상과 신뢰성 있는 기후 정보 제공의 필요성이 점점 강조되고 있다. 극한 기상 현상의 빈도 증대, 해수면 상승, 생태계 변화 등은 인류의 지속 가능한 발전과 사회·경제적 안정에 직·간접적인 위협을 초래하며, 이를 대비하기 위해서는 기상·기후 예측 기술의 발전이 필수적이다. 최근 인공지능(artificial intelligence, AI)의 급속한 진보는 기상·기후 예측 분야에 새로운 가능성을 열었으며, 특히 딥러닝(deep learning) 기술은 지구 시스템의 비선형성을 효과적으로 분석하여 기후 변화 대응에 핵심적인 역할을 하고 있다.

전통적으로 기상 및 기후 연구에서는 일반 순환 모델(general circulation models, GCMs)과 수치 기상 예측 모델(numerical weather prediction, NWP)이 기후 변화 추세 분석과 미래 시나리오 예측의 핵심 도구로 활용되어왔다. 이들 모델은 대기, 해양, 지면, 해빙 등 기후 시스템 구성 요소를 물리 법칙에 기반한 복잡한 계산으로 모의한다. 그러나 복잡한 물리 과정의 모수화, 비선형 현상에 따른 불확실성, 높은 계산 비용 등의 한계가 지속적으로 지적되어 왔다.

딥러닝 기술의 발전은 기상·기후 데이터에 존재하는 패턴을 학습하여 복잡한 물리 기작을 대체함으로써 기존 수치 모델의 제약을 극복하고 있다. 빅테크 기업들이 주도하는 딥러닝 기반 기상 예측 모델들은 대규모 학습 데이터를 활용해 전통적인 수치 모델과 비교 시 더 뛰어난 예측 성능을 보여주며 학계와 산업계의 주목을 받고 있다(Pathak et al., 2022; Bi et al., 2023; Bonev et al., 2023; Chen et al., 2023; Lam et al., 2023; Nguyen et al., 2023; Lang et al., 2024). 예를 들어, NVIDIA의 FourCastNet은 적응형 푸리에 신경 연산자(adaptive Fourier neural operator, AFNO)와 구면 푸리에 신경 연산자(spherical Fourier neural operator, SFNO)를 통해 장거리 의존성을 모델링하며, Huawei의 Pangu-Weather는 3D Earth-Specific Transformer (3DEST)와 계층적 시간 집계로 3차원 데이터 처리를 강화했다. Google DeepMind의 GraphCast는 그래프 신경망(graph neural networks, GNN)을 활

용해 고해상도 예측에서 우수성을 입증했다.

해양은 지구 시스템에서 에너지 저장과 수송의 핵심 매개체로, 전지구 평균 기온, 수문 순환, 탄소 흡수에 직접적인 영향을 미친다. 해류와 해양 변동성은 수개월에서 수년에 걸친 중장기 기후 변동의 주요 조절 요인이다. 전지구 해양 순환 모델(ocean general circulation model, OGCM)은 물리 과정의 복잡성, 모수화의 불확실성, 고해상도 운용에 필요한 막대한 연산 자원 등의 한계로 인해 실시간 예측에 제약이 있다(Bryan et al., 2007; Kamenkovich et al., 2021; Ruan et al., 2023). 예를 들어, 중규모 소용돌이나 원격 상관성을 정밀히 모사하려면 1/10° 격자 해상도가 필요하지만, 이는 현재 OGCM의 운영적 한계로 작용한다. 최근 AI 기반 해양 예측 모델은 수치 모델과 위성 관측 데이터를 학습하여 수천 배 빠른 예측 속도를 유지하면서도 주요 변수의 정확도와 시계열 일관성을 향상시키고 있다. 이러한 모델은 전지구 고해상도 예측, 극한 현상 모사, 대기-해양 상호작용 반영에서 학술적·운영적 가치를 제공한다.

지면은 에너지, 물, 탄소의 흐름이 교차하는 지구 시스템의 핵심 요소로, 대기와의 복잡한 상호작용을 통해 기후 시스템에 중대한 영향을 미친다. 초기 지면 모델(land surface model, LSM)은 Manabe and Bryan (1969)의 단순 버킷 모델에서 시작해 토양 수문학, 식생 생리학, 지형 및 기후의 공간적 이질성을 반영하는 물리 기반 모델로 발전했다(Liang et al., 1994; Cox et al., 2000; Takata et al., 2003; Ivanov et al., 2008). 그러나 복잡한 구조와 관측 불가능한 요소들로 인해 예측 정확도는 여전히 제한적이다. 세계기상기구(World Meteorological Organization, WMO)와 FLUXNET의 글로벌 관측 인프라 발전에도 불구하고, 고정밀의 전지구 지면 예측 모델 구축은 기후 변화 대응과 극한 기후 예측의 과제로 남아있다. 최근 AI 기술은 관측 데이터로부터 비선형 패턴을 학습해 토양 수분, 증발산, 식생 수분 스트레스 등의 예측을 개선하며, 물리 기반 모델과 결합한 하이브리드 모델링이 일반화 한계와 물리적 비일관성을 보완하는 새로운 가능성을 제시한다.

정확한 초기 조건은 기상 및 기후 예측 성능의 핵심이다. 수치 모델 기반 예측 시스템은 자료동화(data

assimilation)를 통해 모델과 관측 데이터를 통계적 오차 정보에 기반해 최적화된 초기조건을 사용한다. 전통적인 자료 동화는 복잡한 대수 연산과 높은 계산 비용을 요구한다. 반면, 딥러닝 기반 자료 동화 시스템은 관측 또는 모델 데이터를 손실 함수로 정의하고 경사 하강법으로 가중치를 최적화하며, 이는 전통 변분 자료 동화와 유사한 원리를 따른다(Xiao et al., 2023; Li et al., 2024). 딥러닝은 자동 미분으로 접선 선형 모델과 수반 모델을 암묵적으로 구현하고, 과거 데이터를 통해 오차 공분산을 추정하여 계산 효율성을 높이며 비선형성과 고차원 상호작용을 효과적으로 반영한다(Lu, 2025). 이는 자료 동화의 새로운 가능성을 열어주고 있다.

수치 기상 예측 모델의 예측 편향은 기상 재해의 예방과 지속 가능한 발전을 위해서 반드시 해결해야 할 과제이다. 최근 체계적인 편향 보정을 위한 후보정(post-processing) 기법들이 활발히 개발되고 있다. 특히, 생성 기반 모델은 목표 분포를 보다 정밀하게 모사하고, 지역적 특성을 효과적으로 유지할 수 있는 장점을 가진 것으로 평가되고 있다(Pan et al., 2021; Hess et al., 2022; Ling et al., 2022).

육상 생태계는 전지구 이산화탄소 배출의 25~30%를 흡수하며 기후 변화 완화에 기여하지만, 탄소 흡수량 추정의 불확실성이 여전히 크다(Cramer et al., 2001; Ahlström et al., 2015; Friedlingstein et al., 2022). 또한, 해양은 전지구 탄소 흡수원의 약 25%를 차지하며, 표층 해수의 이산화탄소 분압(pCO₂) 변화는 대기-해양 탄소 플럭스를 조절하여 기후 피드백에 직접 영향을 미친다. 그러나 관측 인프라의 제한과 데이터 편중으로 인해 전지구 pCO₂ 추정은 불확실성을 동반한다(Bakker et al., 2016).

이처럼, AI 기반 기술은 기상-기후 모델링 전 과정에서 예측 정확성과 계산 효율성을 혁신적으로 향상시키며, 차세대 기후 시스템 모델의 방향성을 제시한다. 현재까지 기상 모델 리뷰 논문은 비교적 풍부하지만, 기후 예측 기술의 광범위한 범위와 다양한 요소로 인해 AI 활용의 통합적 정리는 아직 부족하다. 본 리뷰 논문은 AI 기술이 기후 예측 시스템의 각 구성 요소에 어떻게 적용되고, 어떤 성과를 도출하는지를 종합적으로 분석하여 향후 연구의 전략적 방향을 제시한다.

2. 본 론

2.1 AI 기반 전지구 기후모델링

2.1.1 AI 기반 전지구 대기모델 개발

최근 개발된 AI 기반 대기 예측 모델은 합성곱 신경망(convolutional neural network, CNN), 트랜스포머(transformer), 그래프 신경망 등 첨단 아키텍처를 활용하여 기상 시스템의 복잡한 시공간 패턴을 학습하고 미래 상태를 예측한다(LeCun et al., 2002; Scarselli et al., 2008; Vaswani et al., 2017). 대표적인 모델로는 Google DeepMind의 GraphCast, Huawei의 Pangu-Weather, 중국과학원의 FuXi가 있으며, Table 1은 해당 모델들의 특징을 보여준다(Bi et al., 2023; Chen et al., 2023; Lam et al., 2023). GraphCast는 격자 구조 기반의 기존 딥러닝 모델들과 달리, 지구의 구면 구조를 그래프로 표현하여 위상구조를 보존하면서 전지구적 정보 흐름을 학습한다(Lam et al., 2023). Pangu-Weather는 3DEST를 적용하여 각 블록 내에서 자기-주목(self-attention) 기법을 활용하여 계산 복잡도를 줄이면서, 구면 위의 위도와 경도 변형을 인코딩을 통

Table 1. Characteristics of AI-based atmospheric forecast models.

	GraphCast	Pangu-Weather	FuXi	GenCast
Architecture	GNN	3DEST	U-transformer	Diffusion, Graph-transformer
Horizontal resolution	0.25°	0.25°	0.25°	0.25°
Vertical resolution	37	13	13	13
Time interval	6-hour	6-hour	6-hour	12-hour
Variables	T2m, U10, V10, MSLP, Total precipitation, T, U, V, Z, Q, W	T2m, U10, V10, MSLP, T, U, V, Z, Q	T2m, U10, V10, MSLP, T, U, V, Z, RH	T2m, U10, V10, MSLP, Total precipitation, SST, T, U, V, Z, Q, W
Inference time	~1 min / 10 days	1.4s / 24 hours	-	8 min / 15 days
Inference hardware	TPU v4	V100 GPU	A100 GPU	TPU v5
Reference	Bi et al. (2023)	Lam et al. (2023)	Chen et al. (2023)	Price et al. (2025)

Table 2. RMSE of Z500 are evaluated for the year 2020 against ERA5. The values are adopted from WeatherBench 2, with the bold numbers indicating the lowest RMSE.

Lead days	1	3	5	7	10
GraphCast	39	124	274	467	731
Pangu-Weather	44	133	294	501	778
FuXi	40	125	277	433	631
GenCast	39	123	262	420	606
IFS	42	135	304	521	801

해 보정하였다(Bi et al., 2023). FuXi는 U자형 구조의 트랜스포머를 도입하여 지역적 자기 주목 기법을 통해 고해상도 입력을 효율적으로 처리하였다(Chen et al., 2023). 이들 AI 모델은 결정론적 예측을 통해 높은 정확도를 달성하며, 특정 기상 변수 예측에서 유럽중기예보센터(European Centre for Medium-Range Weather Forecasts, ECMWF)에서 운영하는 통합예보시스템(integrated forecasting system, IFS)을 능가한다(Table 2). 그러나 예측 불확실성을 명시적으로 표현하지 못하고, 초기 조건 및 모델 불완전성으로 인한 장기 예측에 과도하게 부드러워지는 문제가 있다. 이를 보완하기 위해 확률론적 접근이 도입되었으며, 확산 모델 기반 GenCast가 대표적이다(Price et al., 2025). GenCast는 그래프 트랜스포머(graph-transformer)를 활용함으로써 지구 구면의 공간 연결성과 이웃 관계를 보존하였다. 또한, 확산 모델(diffusion model)을 통해 초기 가우스 노이즈를 단계적으로 제거하여 앙상블 예측을 수행하며, 12시간 간격의 직전 두 대기장을 조건으로 받음으로써 다음 예측 시점이 물리적으로 연속된 상태를 유지하게 하였다(Fig. 1).

최근 AI 기반 기상 예보 모델이 빠르게 발전함에 따라, 다양한 접근법의 성능을 일관되게 비교할 수 있는 표준화된 평가 체계의 필요성이 제기되었다. 이러한 배경에서 WeatherBench 2 (WB2)는 차세대 데이터 기반 전지구 중기예보 모델의 발전을 가속화하기 위해 제안된 벤치마크 데이터셋이다(Rasp et al., 2024). WB2는 평가 프레임워크, 공개 학습 및 검증용 자료, 그리고 최신 모델들의 성능 지표를 지속적으로 갱신하는 웹 플랫폼으로 구성되어 있다. 주요 자료로는 ECMWF의 5세대 재분석 자료(ERA5)를 기반으로 한 관측 유사 자료, IFS (HRES/ENS) 예보 결과, 그리고 다양한 AI 모델의 예측 결과가 포함된다. 또한, 평균 제곱근 오차 에러(root mean squared error, RMSE), 상관 스킬(correlation skill) 등 WMO와 ECMWF의 검증 체계를 따르는 다중 평가 지표를 제공하여, 물리 기반 예보모델과 AI 모델의 예측 성능을 동일한 기준에서 비교할 수 있다. Table 2는 WB2 벤치마크를 활

한국기상학회 대기 제35권 4호 (2025)

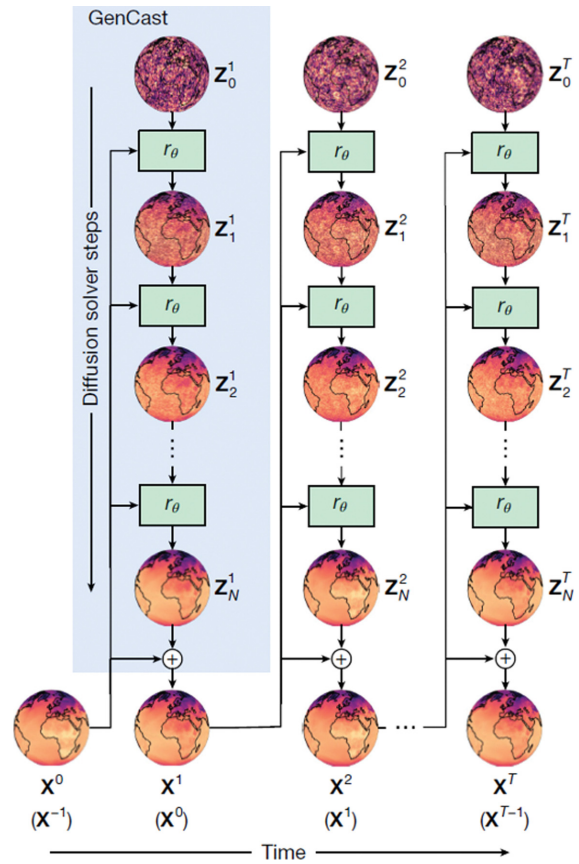


Fig. 1. Schematic diagram of the GenCast model based on a diffusion model for probabilistic forecasting. The blue boxes illustrate the denoising process from the initial noise (Z_0^1), conditioned on the input fields (X^{-1} and X^0) at 12-hour intervals. This process utilizes a neural network (r_θ). Adopted from Fig. 1. in Price et al. (2025).

용하여 GraphCast, Pangu-Weather, FuXi, GenCast의 500 hPa 지위고도장(Z500) 예측 성능(RMSE)을 비교한 결과이다. 모든 AI 기반 전지구 예보 모델의 RMSE가 ECMWF IFS보다 낮았으며, 확산 모델 기반의 GenCast가 모든 리드타임에서 다른 딥러닝 모델들을 능가하는 성능을 보였다. 특히, 10일 예측에서 IFS의 RMSE가 801인 반면, GenCast는 606, FuXi는 631로 나타나 GenCast가 가장 우수한 예측 정확도를 달성하였다. 이러한 결과는 AI 기반 딥러닝 모델들이 기존 물리 기반 수치예보모델의 예측 한계를 빠르게 추월하고 있음을 보여준다. 특히 동일한 데이터셋과 평가 지표를 적용함으로써, 각 모델의 성능 차이를 정량적으로 비교할 수 있다는 점에서 WB2 벤치마크는 AI 예보모델 연구의 공정성과 재현성을 확보하는 핵심

도구로 기능한다. 나아가, 딥러닝 모델 간 비교를 통해 구조적 혁신이 예보 정확도 향상에 미치는 영향을 체계적으로 분석할 수 있다는 점에서 학문적 의미 또한 크다.

AI 기반 전지구 예보 모델들의 발전을 바탕으로, 기상 기초모델이 제안되고 있다. 그 중 Microsoft의 Aurora는 대기, 해양, 대기 오염 등 다양한 지구 시스템 변수를 하나의 통합적 구조 안에서 학습할 수 있도록 설계된 범용 기상 모델이다(Bodnar et al., 2025). 이는 기존의 단일 목적 예보 모델들과 달리, 하나의 대규모 사전학습 과정을 통해 여러 예보 과제를 세분화할 수 있다는 점에서 혁신적이다. 다양한 해상도와 리드타임 조건을 단일 네트워크로 처리할 수 있어 모델 간 비교 가능성과 재현성을 확보하는 데 중요한 역할을 한다. 이러한 특성 덕분에 Aurora는 향후 AI

기반 기상모델 평가의 새로운 기준으로 기능할 가능성이 높으며, 물리기반 수치예보와 데이터 기반 모델 간의 경계를 허무는 기상 예측의 패러다임 전환 모델로 평가된다.

2.1.2 AI 기반 전지구 해양모델 개발

최근, 전지구 해양 예측에서도 딥러닝 모델이 수치 해양모델의 복잡한 계산 과정을 대체하거나 보완하기 위한 대안으로 활발히 개발되고 있다. 대표적으로 Fudan 대학교가 개발한 XiHe 모델과 중국해양대학교와 중국과학기술대학교가 개발한 Wenhai 모델이 있으며, Table 3은 해당 모델들의 특징을 보여준다. XiHe는 Wang et al. (2024)이 제안한 딥러닝 기반 전지구 해양 예측 모델로, 1/12°(약 9 km) 격자 해상도에서 해양 3차원 상태의 시계열 변화를 예측한다(Fig. 2).

Table 3. Key characteristics of the XiHe and WenHai global ocean deep learning prediction models.

	XiHe	WenHai
Architecture	Patch-Transformer	Swin-Transformer
Forecast	60 days (non-autoregressive)	5 days (autoregressive)
Horizontal resolution	1/12° (1,442 × 206)	1/12° (1,442 × 1,206)
Vertical resolution	23 levels (~5,500 m)	23 levels (~643 m)
Time interval	1 day	1 day
Variables	T, S, U/V current, SSH, SST, Wind stress, Heat flux	T, S, U/V current, U10, V10 T2m, 2m dewpoint temperature, SLP
Train data	GLORYS12, ERA5, OSTIA	GLORYS12, ERA5
Reference	Wang et al. (2024)	Cui et al. (2025)

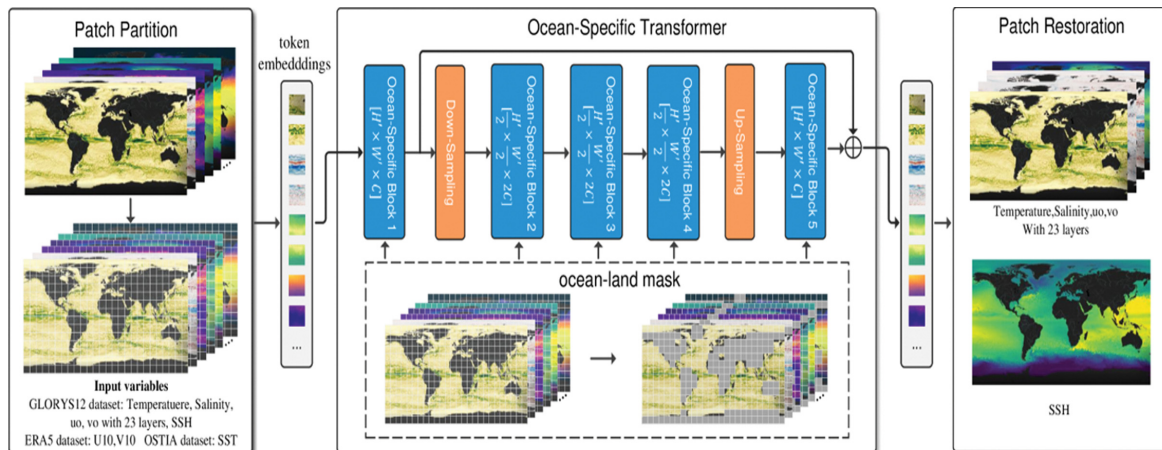


Fig. 2. Schematic diagram of the XiHe model architecture. The Ocean-Specific Transformer effectively learns ocean-dynamics-specific representations by incorporating regional and global SIE modules along with ocean-land masking. Adopted from Fig. 1 in Wang et al. (2024).

이 모델은 수온, 염분, 수평 유속, 해수면온도, 해수면 높이를 포함한 96개 입력 변수를 활용하며, 수직 23개 층의 정보를 통합한다. 해양에 특화된 Patch-Transformer 구조를 채택하여, 전지구 해양장을 패치 단위로 분할해 입력하고, 자기-주목을 통해 지역적 소용돌이부터 대규모 해류에 이르는 다양한 공간 스케일의 상호작용을 동시에 학습한다. 또한 대륙과 섬 영역을 마스킹(masking) 함으로써, 지역 및 전지구적 해양 패턴을 효율적으로 모사하고 해양 역학적 과정에 집중할 수 있도록 설계되었다. 비자기회귀(non-autoregressive) 다단계 시계열 예측 구조로 학습된 XiHe는 GLORYS12 재분석, 위성 관측, 기존 수치모델(PSY4, FOAM) 대비 대부분 변수에서 RMSE와 상관관계수가 개선되었다. 특히 해류 예측에서 PSY4의 10일 정확도를 60일 리드타임까지 증가하며, 단일 GPU로 10일 예측을 0.35초 만에 수행해 높은 계산 효율성을 보인다. 그러나 OGCM 기반 재분석 데이터 의존으로 관측 현실성에 한계가 있으며, 단일 MSE 손실 함수로 인해 Kuroshio, Gulf Stream 등 고변동성 지역에서 예측 표류(drift)나 예측 편차가 발생한다.

WenHai는 Cui et al. (2025)이 개발한 전지구 해양 예측 모델로, 대기-해양 상호작용을 명시적으로 반영한다. 1/12° 해상도에서 상층 643 m의 수온, 염분, 유속, 해수면 높이를 예측하며, 초기 해양장(23개층, 4개변수)과 표면 대기장(10 m 풍속, 해면기압, 2 m 기온, 이슬점)을 입력으로 사용한다. 대기 변수는 bulk formula를 통해 플럭스로 변환되어 해양에 적용된다. WenHai는 변수의 절대값 대신 하루 변화량을 예측하여 단기 변동성과 에너지 보존을 효과적으로 재현한다. Swin Transformer 기반으로 패치 임베딩, 윈도우 attention, 업샘플링 단계를 포함하며, 1일 예측 선행 학습 후 5일 누적 자기회귀 미세조정으로 학습된다. 얇은 수심 가중 손실, 에너지 스케일 정규화, 해양-육지 마스킹 등을 통해 중규모 소용돌이 에너지 재현이 개선되었다. XiHe 및 GLO12v4 대비 RMSE, Skill Score 등 다양한 지표에서 우수한 성능을 보였으며, 해수면 온도, 해수면 높이, 수온-염분 수직 구조, 해류 예측에서 강점을 보인다. 다만, 일평균 단위 예측 구조로 인해 조석, 고주기 진동, 심층 해양, 해빙, 담수 유입 영향은 반영되지 않는다.

2.1.3 AI 기반 지면 모델 개발

지면모델은 머신러닝(machine learning, ML)과의 통합 및 물리 제약을 도입한 머신러닝(physics-constrained ML)이라는 두 축을 중심으로 발전하고 있다. 이러한 변화는 물리 기반 지면모델의 복잡성과 구조적 불확실성을 보완하고, 위성 및 지상 관측으로부터 얻은 대규모 데이터를 효율적으로 활용하기 위한 방향으




Fig. 3. Schematic diagram of the GLEAM4 model architecture. GLEAM4 estimates evapotranspiration by sequentially applying modules for precipitation interception, potential evapotranspiration, soil moisture, and evaporative stress. The evaporative stress is derived using a hybrid approach based on machine learning trained on eddy covariance and sap flow observations. Adopted from Fig. 1 in Miralles et al. (2025).

로 진화하고 있다. 최근 연구들은 특히 증발산(evapotranspiration, ET) 추정과 대기변수 추정 및 불확실성 정량화에 초점을 맞추어 머신러닝 기법을 도입하고 있다.

ET 추정 분야에서는 Miralles et al. (2025)의 Global Land Evaporation Amsterdam Model version 4 (GLEAM4)가 대표적이다. 해당 연구는 기존의 GLEAM에 Koppa et al. (2022)이 제안한 딥러닝 기반 증발 스트레스 모듈을 통합하였다(Fig. 3). 기존 GLEAM은 토양 수분에 기초한 단순한 토양 수지 모델로 식생 스트레스를 산정하였으나, 기온, 증기압 부족, 광량, 이산화탄소 농도 등 비선형적 기후 요인을 충분히 반영하지 못하였다. 반면, GLEAM4는 전 대규모 플럭스타워와 및 수액 흐름 데이터로 학습한 딥러닝 모듈을 물리 기반 모델에 결합함으로써, 복합적인 증산 스트레스를 정밀하게 모사하였다. 검증 결과, 전 세계 473개 플럭스 타워에서 GLEAM v3.8a 대비 RMSE가 0.95 mm day^{-1} 로 감소, 클링-굽타 효율 지수(Kling-Gupta efficiency, KGE)가 0.49로 향상되어 ERA5-Land

보다 우수한 예측 성능을 보였다.

매개변수 추정 및 불확실성 정량화 분야에서도 머신러닝 기반 접근이 활발히 시도되고 있다. Dagon et al. (2020)은 Community Land Model version 5 (CLM5)의 생지구물리적 매개변수 공간을 분석하여, 수문 및 탄소 플럭스 관측자료에 적합하도록 핵심 매개변수를 전지구적으로 보정하였다. 이들은 artificial neural network (ANN)을 이용해 CLM5의 출력을 모사하고, 이를 통해 매개변수 불확실성이 총 1차 생산량과 잠열 시뮬레이션의 전체 불확실성에 기여하는 정도를 정량화하였다. 이는 CLM5를 모사하는 ANN이 내부적으로 작동하는 기작을 보다 깊이 이해할 수 있음을 보여준다.

또한 Abimbola et al. (2021)은 딥러닝 기반 토양 온도 예측 모델에서 깊은 토양층의 예측 정확도 저하 문제를 해결하기 위해, 기상 변수에 시간지연과 이동 평균을 적용한 natural temporal-averaged climate memory adjustment (NT-ACMA) 기법을 제안하였다. 이 방법은 과거 기상 변수의 시계열 패턴을 학습하여 시간지연 효과(time delay effect)와 완충 작용(damping effect)을 모사함으로써, 깊은 토양층에서도 높은 예측 정확도를 달성하였다(RMSE: Lancaster 1.0°C, Polk 1.2°C, 기존 최대 RMSE 3.1°C). 이는 복잡한 모델 구조 없이도 물리적 특성을 반영하여 높은 예측력을 달성한 사례로 평가된다.

최근 들어 지면모델 연구는 기존의 머신러닝 및 인공신경망 기반 접근을 넘어, 시계열 의존성과 공간 일반화를 동시에 학습할 수 있는 딥러닝 모델로 진화하고 있다. 특히, 장단기 기억 네트워크(long short-term memory, LSTM)는 지면 및 생태계 예측 분야에서 널리 활용되고 있으며, 이는 지표면 과정이 종종 마코프 과정(Markov process)처럼 작동하기 때문이다. LSTM의 게이팅(gating) 기작은 이러한 연속적이고 잡음이 많은 입력 신호를 효과적으로 처리하기 때문에 널리 활용된다(Kratzert et al., 2018). 이러한 특성을 기반으로, Kraabel et al. (2025)의 StefaLand는 LSTM 구조를 확장하여 시계열적 안정성과 공간적 일반화를 동시에 구현한 대표적 사례로 제시되었다. StefaLand는 유사한 토양 특성을 가진 지역을 그룹화 마스킹 기법으로 통합 학습함으로써 변수 간 인과 기반 추론을 강화하였다. 그 결과, 하천 유량 예측에서는 TerraMind 대비 낮은 RMSE (1.156)를 토양 수분 예측에서는 RMSE 0.068 및 상관계수 0.783을 기록하여 TerraMind 및 PrithviWxC 모델을 능가하는 성능을 보였다. 이러한 결과는 StefaLand가 지면 과정의 시공간적 패턴을 효율적으로 학습함으로써, 데이터가 제한된 지역에서도 일반화 가능한 지면 예측 모델의 새로운 가능성을 제시한다는 점에서 중요한 시사점을 갖는다.

2.2 AI 기반 전지구 자료동화 기법

2.2.1 전통 방법과의 원리적 접점을 통한 딥러닝 기반 자료동화

딥러닝을 활용한 자료동화는 크게 두 가지 접근법으로 나뉜다. 첫째는, 전통적 변분법적 자료동화와 유사한 경사 하강법 구조에 신경망을 적용하는 방법으로, 자동 미분을 활용해 비용 함수 최적화와 수반 모델 계산을 효율적으로 수행한다. 이는 전통적인 4차원 변분 자료동화(4DVAR)의 높은 연산 비용을 줄이고 비용 함수의 최적 값을 효과적으로 구하는 것에 초점을 둔다.

유럽 중기 예보 센터는 자동 미분을 이용해 접선 선형 모델(tangent linear model, TLM)과 수반모델(adjoint model) 기반 민감도 계산을 수행하는 4DVAR 체계를 개발했다(Hatfield et al., 2021). 이를 자체 개발된 신경망 기반 물리 모수화 에뮬레이터에 적용해 물리 모수화와 자료동화의 통합 가능성을 입증했다. 프랑스 국립 과학 연구 센터는 자동 미분 기반 비용 함수와 수반 모델을 활용한 4DVAR 시스템을 단순 비선형 역학 시스템에 적용하여, 전통적인 자료동화 대비 빠른 연산 속도와 높은 정확도의 분석장을 산출했다(Fablet et al., 2021).

독일 기상청은 전통적인 3DVAR 자료동화를 대체하는 딥러닝 기반 자료동화 프레임워크인 AI-Var를 제안했다(Keller and Potthast, 2024). 이 연구에서는 딥러닝 신경망을 활용하여 3DVAR의 비용함수를 손실 함수로 정의하고, 관측값과 배경장만을 입력으로 사용하여 분석장을 직접 추정하는 자기지도학습(self-supervised learning) 구조를 구현했다. 이는 지도학습과 달리 분석장을 명시적으로 제공하지 않고 최적 해를 도출하며, 독일 중부 지역의 지상 기온 배경장 오차를 효과적으로 보정했다. 이론적인 딥러닝 기반 변분 자료동화의 강점이 알려지면서, 최근 딥러닝 기반 전지구 날씨 예측 시스템에도 활발히 적용되고 있다.

중국 칭화대학교의 FengWu-4DVAR는 전통적 4DVAR 구조를 유지하며 자동 미분을 비용 함수 최적화와 수반행렬에 적용해 자료동화를 수행, 규준실험 대비 초기 조건과 예측 성능을 향상시켰다(Fig. 4). 중국과학원은 딥러닝 기반 전지구 날씨 예측 시스템인 FuXi 모델(Chen et al., 2023)에 적용 가능한 자료동화 체계를 공개하였다(FuXi-En4DVAR; Li et al., 2024). 앞서 FengWu-4DVAR와 동일하게 자동 미분을 최적화 문제 및 수반행렬에 적용하여 자료동화를 수행하였고, 이를 통해, 높은 정확도의 분석장과 예측 결과를 산출했다.

2.2.2 딥러닝 고유 기법 기반 자료동화

딥러닝 고유 기법을 활용한 자료동화는 전통적인

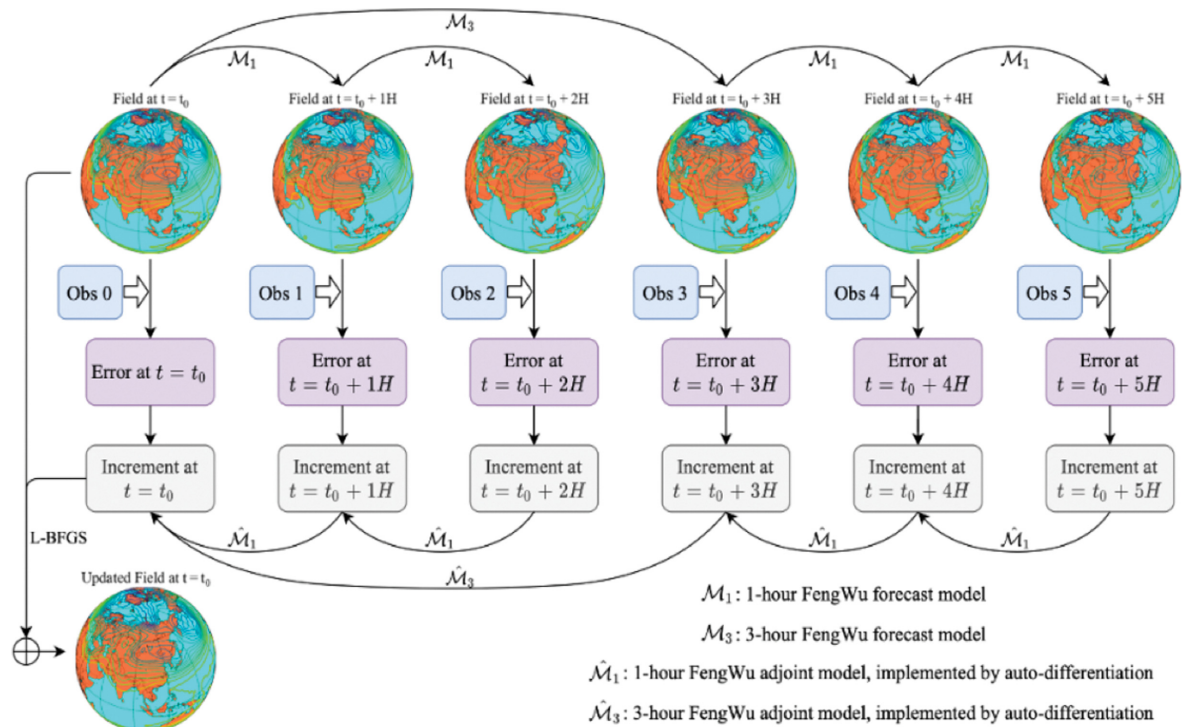


Fig. 4. Schematic diagram of implementing 4DVar on the FengWu forecasting model (corresponding to one step optimization at time $t = t_0$). The temporal aggregation strategy is represented by \mathcal{M}_3 and $\hat{\mathcal{M}}_3$ in the figure, enabling more direct and efficient propagation of gradients. The auto-differentiation strategy is represented by \mathcal{M}_1 and $\hat{\mathcal{M}}_1$ in the figure and is automatically implemented by PyTorch, requiring no manual code writing. Adopted from Fig. 2 in Xiao et al. (2023).

방법과 목적은 유사하나 방법론적으로 차별화된다. 주요 기법으로는 변분 오토 인코더(variational auto encoder, VAE), 점수 기반 확산(score-based diffusion), 부분 합성곱 기반 이미지 복원(image inpainting) 등이 있다. VAE는 고차원 배경장을 저차원 잠재 공간(latent space)으로 압축해 특징을 추출하고, 관측 자료를 잠재 공간에서 동화한 뒤 분석장을 복원한다 (Mack et al., 2020; Peyron et al., 2021; Melinc and Zaplotnik, 2024). 이는 저차원 모델로 연산 비용을 줄이며 고차원 데이터의 주요 패턴을 효과적으로 유지한다. 전통 자료동화에서 최적 가중치 행렬의 역행렬 연산 비용을 줄이기 위해 다양한 필터링 기법이 적용된 저차원의 오차 공분산 행렬을 이용하는 방향성과 유사하다. 하지만 가우시안 가정에 기반한 선형 근사를 통해 데이터의 확률을 표현하는 전통 자료동화와 달리 VAE는 복잡한 비가우시안 및 비선형성을 효과적으로 근사할 수 있다는 강점이 있다.

또한, 점수 기반 확산 모델을 활용한 자료동화 연구가 최근 활발하게 수행되고 있다. 이는 VAE 기반 생성형 모델을 통해 산출되는 결과물의 품질이 생성형

적대적 신경망(generative adversarial network, GAN)이나 확산 모델 등의 다른 생성형 딥러닝 기법에 비해 낫다는 한계를 해결하기 위한 방법으로 알려져 있다(Pandey et al., 2022). 확산 모델은 입력 자료를 정규 분포를 따르는 잡음 과정(noising process)을 거쳐 무작위 패턴으로 만든 후, 그 패턴으로부터 로그 우도 추정을 기반으로 하는 손실함수를 통해 잡음을 단계적으로 제거하면서 입력 자료의 확률 분포를 최대한으로 따르는 새로운 샘플을 생성하는 방법이다(Ho et al., 2020). 벨기에 리에주 대학 연구팀에서는 score-based data assimilation (SDA) 라는 이름의 점수 확산 모델 기반의 자료동화 시스템을 개발하였다(Rozet and Louppe, 2023). Lorenz 모델과 Navier-Stokes 기반 난류 모델을 이용하여 사전 확산 모델을 구축한 뒤, 추론 단계에서 관측 자료를 동화할 때 관측 정보에 대한 조건부 점수 함수를 기반으로 하는 손실 함수를 정의하여 관측 자료의 확률 분포까지 최대화하는 결과를 산출하는 방식으로 자료동화를 수행한다. NVIDIA는 SDA를 고해상도 기상 모델에 적용하여 미국 본토 현장 관측 자료를 동화함으로써 그 효과를 조사하였

다(Manshausen et al., 2024). SDA를 통해 현장 관측 자료의 반영이 모델 데이터에서 표현되는 물리 균형을 보존하고, 특히 다변량 특성을 반영할 수 있음을 보였다. 확산 모델은 추계론적 미분 방정식(stochastic differential equation)에 기반을 두어 앙상블 초기장의 확보가 가능하다는 점에 착안하여 특징도 조사하였지만, 충분한 앙상블 스프레드(ensemble spread)를 담보하는 초기장 생성에는 한계가 있음을 밝혔다. 미국 워싱턴 대학교는 SDA를 이용하여 중규모 와류 규모(eddy-resolving scale) 표층 해양 초기장을 추정하기 위해 고해상도 해양 재분석 자료를 활용하여 위성 기반 해양 관측 자료를 동화하는 시스템(GenDA)을 개발했다(Martin et al., 2025). 이 연구에서는 전통적 자료동화 방법인 최적 내삽법(optimal interpolation)이나 회귀 기반 딥러닝 모델에 비해 SDA의 성능이 우수함을 보였다. 확산 모델을 이용한 자료동화 역시 VAE 처럼 데이터의 복잡한 비가우시안 분포 및 비선형성을 학습할 수 있으며, 관측 연산자가 필수적인 전통 자료동화와 달리 조건부 점수 함수 기반 구조는 별도의 관측 연산자 없이도 관측 정보를 배경장에 반영할 수 있다.

결측 인식형 합성곱 기반의 이미지 복원 기법은 결측 데이터를 고려해 합성곱 연산을 수행하며, 관측된 유효 영역만을 활용하거나 결측 여부에 따라 정보 반영을 조절한다(Liu et al., 2018; Yu et al., 2019). 대표 기법으로는 부분 합성곱(partial convolution)과 게이트 합성곱(gated convolution)이 있다. 독일 기후 컴퓨팅 센터는 부분 합성곱을 이용해 CMIP5 (Coupled Model Intercomparison Project Phase 5) 데이터를 학습, 관측되지 않은 결측 지역의 전지구 해수면 온도를 복원했다(Kadow et al., 2020). 이는 결측 범위가 큰 시기의 관측 데이터를 완전한 분석장으로 재구성하여 자료동화 효과를 입증했다. 서울대학교 함유근 교수 연구팀은 부분 합성곱 기반 이미지 복원 기술과 GAN 모델을 활용한 전진 연산자(time-forward operator)를 구현하여 3차원 전지구 해양 온도 재분석이 가능한 자료동화 시스템을 개발했다(Ham et al., 2024). 이미지 복원 기술의 활용은 대규모 학습 데이터가 요구되고, 학습 데이터에 대한 의존도가 강하다는 유의점이 있지만, 데이터의 물리적 비선형성을 학습할 수 있고, 결측이 포함된 관측자료의 시공간적 연속성 및 관측 밀도 증가에 효과적으로 기여한다는 장점이 있다.

2.2.3 End-to-end 딥러닝 예측 체계 내 자료동화

딥러닝 기반 날씨 예측 모델과 자료동화 체계의 통합은 초기화부터 예측까지의 종단 간(end-to-end) 예측 체계를 구현하는 가능성을 제시한다. 관측 데이터

를 활용해 초기 상태 추정과 예측을 하나의 통합된 모델로 수행하는 연구가 활발히 진행되고 있다.

마이크로소프트의 OMG-HD는 위성, 레이더, 지상 관측 데이터를 동화해 초기 상태를 추정하고 날씨 예측을 수행하는 종단 간 시스템이다(Zhao et al., 2024). Swin Transformer 기반 자료동화 블록(assimilating block)은 불규칙한 관측 데이터를 고해상도 예측 모델의 배경장과 통합하여 격자화 된 초기 조건을 생성한다. 이후 AFNO 기반 예측 블록을 통해 예측을 수행한다.

영국 캠브리지 대학의 Aardvark Weather는 다중 관측 데이터를 동화하는 Vision Transformer 기반 종단 간 날씨 예측 시스템이다(Allen et al., 2025). 이 시스템은 관측 지점의 위치 정보를 활용해 직접 내삽 없이 격자화된 초기 조건을 생성하며, 자기-주목 기작으로 관측 간 상호작용을 학습한다. 자료동화를 통해 얻은 초기 조건을 순방향 신경망(feed-forward neural network)으로 예측한다. 딥러닝 기반 종단 간 모델은 고정된 입력 형식을 요구하지 않아 시공간적으로 불균일한 관측 데이터를 전처리 없이 처리한다. 관측 정보만으로 분석장 또는 재분석 데이터를 정확히 추정하도록 학습되며, 배경장 정보 없이 최적 초기 조건을 생성한다. 이는 재귀적 배경장 업데이트를 제거해 구조를 단순화하고 계산 효율을 높여 실시간 예보에 유리하다.

2.3 AI 기반 기후예측 후보정 기법

2.3.1 AI 기반 계통오차 보정

기존 기후 예측 보정에서는 통계적인 기법인 empirical orthogonal function (Danforth et al., 2007), singular value decomposition (SVD; Ward and Navarra, 1997), anomaly numerical correction with observations (ANO; Qian, 2012; Peng et al., 2013), quantile mapping (QM; Ines and Hansen, 2006)이 주로 사용되었다. QM은 예측값과 관측값의 누적 분포 함수를 매핑해 정량적으로 보정하지만, 공간적 불연속성이나 시공간 구조적 오류 보정에는 한계가 있다(Déqué, 2007; Thrasher et al., 2012).

데이터 과학 발전으로 random forest (Li et al., 2019), lightGBM (Zhong et al., 2021), support vector machines (Pour et al., 2018) 등 머신러닝 기법이 편향 보정에 활용되었으나, 단일 지점 또는 단일 변수 중심으로 공간적 연속성과 시계열 상관성을 충분히 반영하지 못한다.

이러한 한계를 극복하고자 최근 딥러닝 기반 연구가 활발하며, convolutional long short-term memory (Shi et al., 2015), gated recurrent unit (Guo et al., 2020), CNN (Tao et al., 2016; Lebedev et al., 2019;

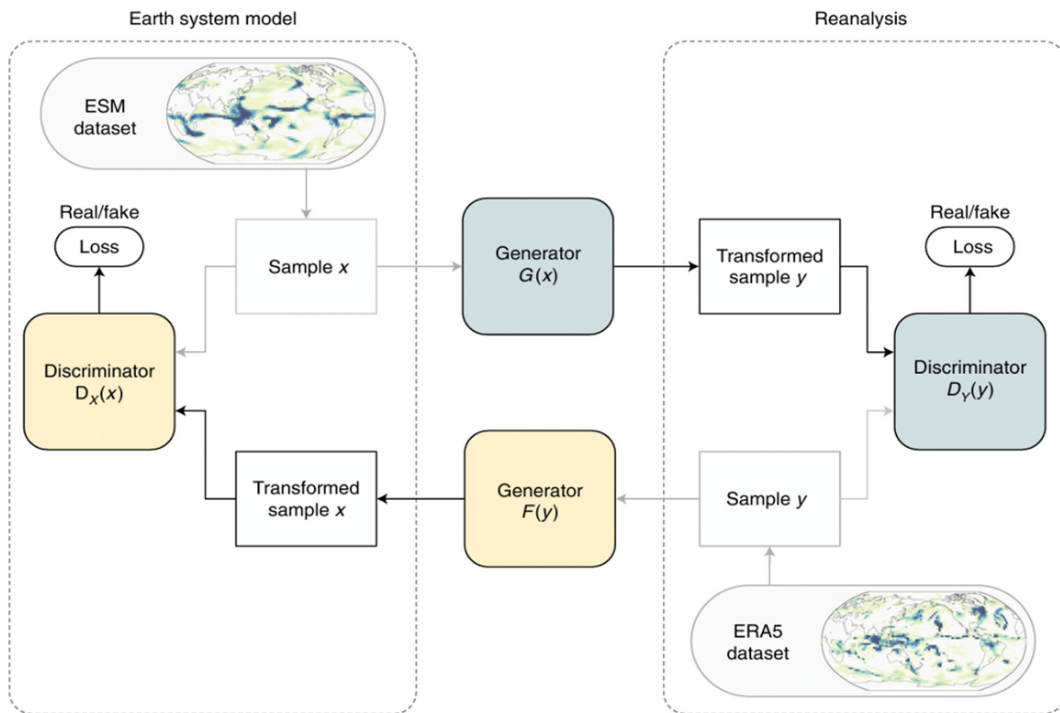


Fig. 5. Schematic diagram of the CycleGAN model. Two generator-discriminator pairs learn to translate samples from the ESM simulations to the ERA5 reanalysis (grey) and vice versa (yellow). Training the two generators to learn inverse mappings of each other allows cycle consistency to be enforced in the translation of the unpaired samples, that is, $x \rightarrow G(x) \rightarrow F(G(x)) \rightarrow \bar{x} \approx x$, and vice versa for y . Adopted from Fig. 1 in Hess et al. (2022).

Han et al., 2020) 및 컴퓨터 비전 분야의 image-to-Image translation 기법이 도입되고 있다. 이들 모델은 비선형 시공간 상호작용을 학습해 기존 통계 기법의 한계를 극복하며 높은 예측 정확도와 일반화 성능을 보여준다(François et al., 2021; Han et al., 2021; Kim et al., 2021; Pan et al., 2021; Hess et al., 2022; Ling et al., 2022).

U-Net은 격자 기반의 공간 패턴을 효과적으로 학습할 수 있어, 기상 예측과 같은 공간 기반 예측에 널리 사용된다. Lyu et al. (2023)은 남중국 여름철 강수 예측을 위해 강수량 및 다양한 대기 변수(풍속, 온도, 습도 등)를 입력으로 한 U-Net 회귀 모델을 제안했다. Han et al. (2021)은 ECMWF 단기-중기 예보(24~240 시간)를 보정하기 위해 ERA5 관측 데이터와 예측값을 입력으로 사용하는 CU-Net을 개발, 온도, 습도, 풍속, 풍향의 격자 기반 편향을 보정했다. 두 연구는 U-Net의 공간 패턴 복원 능력으로 통계 기법 대비 우수한 성능을 입증했다.

단기 예보에서는 관측값과의 일대일 대응으로 지도학습 기반 딥러닝이 효과적이지만, 장기 예측은 지구시스템 모형(Earth system model, ESM)과 재분석

데이터 간 정합성 부족으로 지도학습 적용이 어렵다. 이러한 상황에서 생성형 적대적 신경망(GAN)은 목표 분포를 효과적으로 근사하여 현실적인 샘플을 생성할 수 있기 때문에, 지도 데이터가 부족하거나 쌍을 이루지 않는 데이터 환경에서도 유용하게 활용될 수 있다. 특히 Cycle-Consistent GAN (CycleGAN)은 쌍이 없는 데이터 학습을 통해 목표 분포를 근사하며, 소규모 변동성과 공간적 간헐성을 모사해 CNN 기반 모델의 블러링(blurring) 문제를 완화한다. CycleGAN은 양방향 변환 학습으로 일관된 보정을 수행하며, sub-grid scale 모수화, 다운스케일링, 기상 자료 보정에 활용된다(Fig. 5). Hess et al. (2022)은 CycleGAN에 전지구 강수 총합 보존 제약을 적용해 지구시스템모델(CM2Mc-LPJmL)의 강수장을 재분석 데이터 특성에 맞게 보정, double ITCZ 현상 제거, 강수 빈도와 고주파 공간 구조 복원에서 QM 및 CMIP6 (GFDL-ESM4) 대비 우수한 성능을 보였다. Yang et al. (2025)은 CycleGAN으로 NUIST-CFS 1.0 모델의 중국 동남부 여름철(6~8월) 강수 예측을 보정, 극한 강수의 빈도, 강도, 지속시간 예측에서 QM 대비 개선된 결과를 보고했다.

2.3.2 AI 기반 고해상도 기법

저해상도 전지구 기후 모델 결과를 고해상도로 변환하는 후보정 기법이 활발히 연구되고 있다. 초고해상도화(super-resolution) 딥러닝 기법이 주로 사용되며, 초기 U-Net 기반 접근(Lin et al., 2023)에서 최근 적대적 신경망(GAN) 기반 기법으로 발전해 온도 및 강수 예측 정확도가 향상되었다. Oyama et al. (2023)는 1.25 해상도의 55-year reanalysis (JRA-55) 데이터를 입력으로, 1 km 해상도의 일본 내륙 온도 및 강수 데이터(Agro-Meteorological Grid)를 출력으로 하는 SRGAN (super-resolution GAN) 모델을 개발해 약 50배 해상도 증가를 달성했다. 해면 기압장을 추가 입력으로 사용 시 예측 정확도가 더욱 향상되었다.

그러나 초고해상도 기법은 출력 해상도가 학습 데이터에 종속된다는 한계가 있다. 이를 극복하기 위해 공간적인 분포를 연속적인 함수로서 인식하여 이론적으로는 무제한 해상도를 갖는 implicit neural representation (INR) 기법이 주목받았다(Sitzmann et al., 2020). INR은 위치 인코딩 모듈인 매핑 네트워크와 위치 정보를 입력장으로 하는 multi-layer perceptron (MLP)로 구성된다. 의료 영상 재구성 분야에 활용되고 있는 순수 MLP 기반의 implicit neural representation learning with prior embedding (NERP) 기법(Shen et al., 2022), StyleGAN 기반 매핑 네트워크에 기반한 Poly-INR 기

법(Singh et al., 2023)이 있으며, 최근 확산 모델 기반 INR 기법이 개발되고 있다(Park et al., 2024; Fig. 6). INR은 아직 기후 데이터 후보정에 적용된 사례는 없으나, 무제한 해상도의 데이터를 생성할 수 있다는 장점이 있어 지속적인 연구 가치가 크다.

2.4 AI 기반 전지구 탄소모델링

2.4.1 AI 기반 전지구 육상탄소모델링

지구시스템모델의 탄소플럭스 변수는 높은 불확실성과 모델 간 큰 차이를 보인다(Hu et al., 2022). 신뢰성 있는 전지구 육상 탄소플럭스 평가를 위해 관측 데이터 확보가 우선시된다(Yuan et al., 2014). 이에 따라 머신러닝 기반 탄소순환 추정 연구가 활발히 진행되며, 대표적으로 FLUXCOM 프로젝트가 있다(Jung et al., 2019; Nelson et al., 2024). FLUXCOM은 전 세계 플럭스 타워에서 수집된 현장 관측 자료, 원격탐사 자료, 기상자료, 랜덤 포레스트, 인공신경망 및 extreme gradient boosting (XGBoost) 등의 머신러닝 알고리즘에 학습시켜 탄소플럭스를 추정한다. 이 프로젝트를 통해 총일차생산량 및 순생태계교환량과 같은 탄소플럭스가 자료가 미관측 지역을 포함한 전지구적 규모로 제공된다. 이 데이터는 지구시스템모델 성능 평가와 탄소순환 기작 이해에 기여한다.

신뢰성 있는 관측 기반 데이터 구축과 함께, 딥러닝과 물리 기반 모델을 결합한 하이브리드 모형(Tao

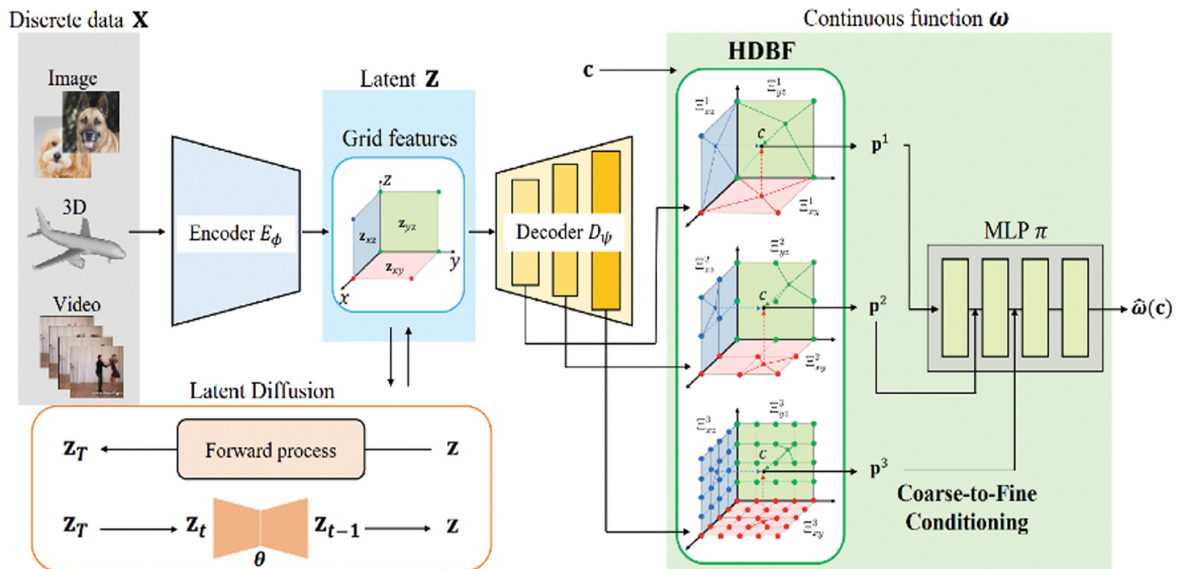


Fig. 6. Schematic diagram of the Domain-agnostic latent diffusion models (DDMI) architecture. Discrete data \mathbf{x} and continuous function ω are connected in the shared latent space \mathbf{z} (D2C-VAE). The decoder generates Hierarchically-decomposed basis fields (HDBFs) given latent variables \mathbf{z} . The MLP returns the signal value for queried coordinate \mathbf{c} using the Coarse-to-Fine Conditioning method. Latent diffusion model operates on the shared latent space. Adopted from Fig. 2 in Park et al. (2024).

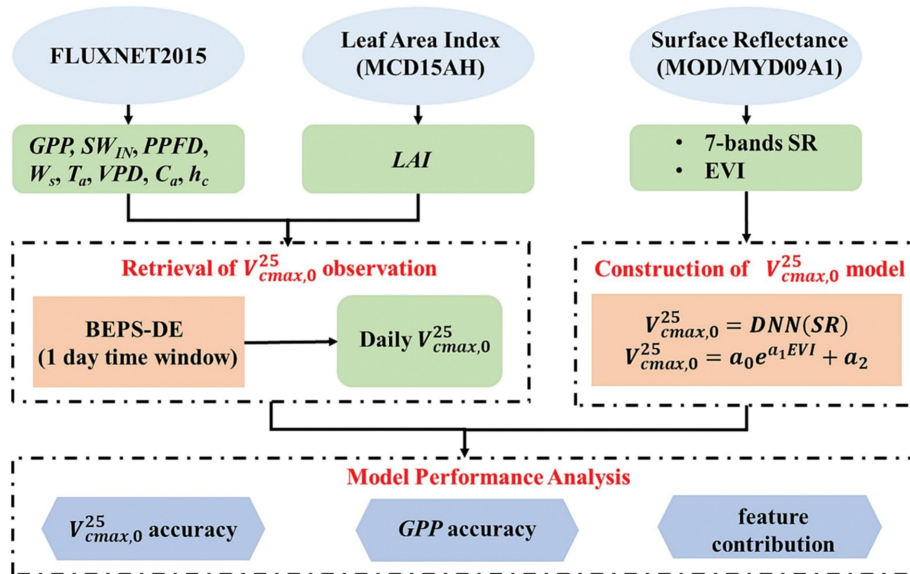


Fig. 7. Schematic diagram of the hybrid model for gross primary productivity (GPP) estimation. This model employs the differential evolution algorithm (BEPS-DE) to back-calculate the optimal daily maximum carboxylation efficiency. These back-calculated values then serve as the true (reference) values for a deep neural network (DNN), which is trained to estimate this optimal efficiency using MODIS surface reflectance as input. Finally, the DNN's estimated maximum carboxylation efficiency is integrated as a parameter into a process-based model, significantly enhancing the accuracy of GPP estimations. Adopted from Fig. 1 in Hu et al. (2024).

et al., 2020; Hu et al., 2024; Son et al., 2024; Xu et al., 2025) 및 지식 기반(knowledge-guided) 딥러닝(e.g., Liu et al., 2024) 연구도 활발하다. Hu et al. (2024)은 심층 신경망(deep neural network, DNN)을 활용하여 물리기반과정모형(boreal ecosystems productivity simulator, BEPS)의 핵심 매개변수인 최대카르복실효율을 개선, 총일차생산량(gross primary productivity, GPP) 예측 성능을 향상시켰다(Fig. 7). Xu et al. (2025)은 생지화학 정보화된 신경망(biogeochemistry-informed neural network, BINN)을 통해 Community Land Model version5 (CLM5)의 생지화학 매개변수를 추정, 토양 유기탄소 저장량을 예측하며 기존 베이지안 추론 대비 50배 이상 연산 효율을 개선했다. 이들 연구는 온도·수분·복사 조건에 따라 비선형적이고 지역적으로 이질적인 생태계 탄소 과정을 경험식이나 선형 근사라도 충분히 설명하기 어렵다는 한계를 극복하기 위해, 신경망의 비선형 학습 능력을 활용하여 물리모형의 반응을 정교하게 보완하고자 했다.

앞서 언급된 연구들이 단일 변수 개선에 집중한 것과 달리, 광합성과 생태계 호흡을 동시에 고려한 연구도 있다. Fang and Gentine (2024)는 육상 생태계 모델(data assimilation linked ecosystem carbon, DALEC)의 토양 수분 스트레스 추정 모듈을 신경망

으로 대체한 하이브리드 모델을 개발, FLUXNET 데이터로 GPP와 생태계 호흡(ecosystem respiration, R_{eco}) 예측 정확도를 높였다. 다만, 물리적 제약이 약한 신경망 구조 특성상, 모델이 관측 자료에 과도하게 적합하거나 여러 파라미터 조합이 동일한 출력을 만드는 과적합 및 등결과성(equifinality) 문제가 지적되었다. Cohrs et al. (2024)는 이중기계학습(double machine learning)을 통해 순생태계교환량(net ecosystem exchange, NEE)을 GPP와 R_{eco} 로 인과적으로 분리, 빛이 NEE에 미치는 ‘순수한 인과 효과’로 명확히 규정하고 추정함으로써, 등결과성과 편향을 줄이며 모델의 해석 가능성과 신뢰성을 강화했다.

2.4.2 AI 기반 전지구 해양탄소모델링

AI 기법을 활용한 해양 pCO_2 추정 및 전지구 해양 재분석장 구축 연구가 활발하다. AI 모델은 해수면 온도, 염분, 엽록소 농도, 혼합층 깊이, 해수면높이, 대기 중 CO_2 농도 등 위성 관측 및 재분석 기반 환경 변수를 입력으로 사용하며, 관측 pCO_2 와의 통계적 관계를 학습해 유연하고 정확한 추정을 수행한다(Landschützer et al., 2014; Gregor et al., 2019). feed forward network (FFNN)과 서포트 벡터 회귀(support vector regression, SVR), 그래디언트 부스팅(gradient

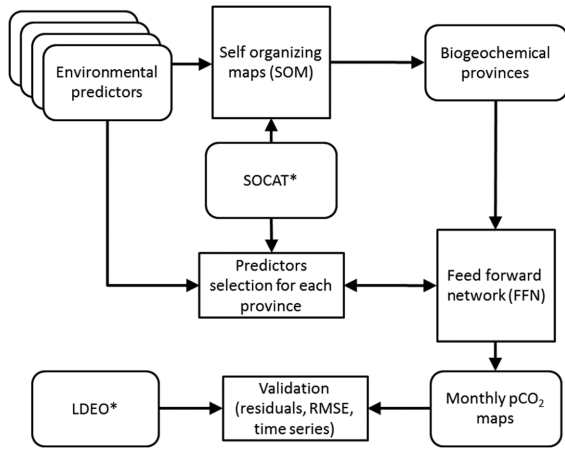


Fig. 8. Schematic diagram of estimating global ocean pCO₂ using SOM-FFNN. Adopted from Fig. 1 in Laruelle et al. (2017).

boosting machine, GBM) 등 AI 기법은 기존 생지화학 모델보다 높은 정확도와 일반화 성능을 제공한다 (Rödenbeck et al., 2013; Friedlingstein et al., 2022).

특히, FFNN은 비교적 단순한 구조를 지니면서도 다양한 해양 물리 변수 간의 비선형적 상호작용을 효과적으로 학습할 수 있다는 점에서 전지구 해양 pCO₂ 재분석장 산출 연구에 널리 활용되어 왔으며, 다양한 구조 및 학습 전략이 제안되었다. 대표적으로 Laruelle et al. (2017)와 Gregor et al. (2019)은 환경 변수를 기반으로 자기조직화지도(self-organizing Map, SOM)를 활용해 전지구 해양을 여러 군집으로 나눈 뒤, 각 군집에 대해 FFNN 기반 회귀를 적용했다(Fig. 8). 이 접근법은 유사한 변동성을 갖는 지역 내 정보를 공유함으로써, 관측이 희소한 지역에 pCO₂ 추정치의 일반화 성능을 높이는데 유리한 장점이 있다. 하지만 군집 간 경계가 불연속적으로 나타날 수 있다는 한계점이 존재한다. 반면, Zeng et al. (2014)와 Denvil-Sommer et al. (2019)은 별도의 군집화를 거치지 않고 위도 및 경도 정보를 추가 예측변수로 활용함으로써, 공간적 연속성을 유지한 상태에서 FFNN 회귀를 구현하였다. 이러한 방법은 군집 경계 문제를 회피할 수 있는 장점이 있으나, 지역 특화된 예측력이 다소 저하될 가능성도 존재한다.

3. 요약 및 토론

AI 기반 대기 예측 모델은 전례 없는 계산 속도와 정확도로 대기 과학 분야의 패러다임을 변화시켰다. 결정론적 모델은 단일 예측을 제공하고, 확률론적 모델은 불확실성을 정량화해 의사결정을 지원한다. 그

러나 온실가스 농도 급변 같은 미경험 조건에서의 일반화 약화(Kochkov et al., 2024), 극지방이나 상층 대기처럼 관측 부족 지역에서의 예측 저하, 소규모 비선형 극한 현상 처리 어려움 등의 한계가 있다. 블랙박스 구조로 인한 해석성 부족도 실제 적용을 제한한다. 향후 연구는 위성·지상 관측·레이더·수치 모델 데이터를 통합한 기초 모델 개발, 인과 추론과 설명 가능한 인공지능(explainable AI)를 활용한 과정 기반 불확실성 분석, 대기 예측을 넘어 해양·지면·해빙 통합 전지구 장기 시스템 확장에 초점을 맞춰야 한다. 이는 예측 정확도와 신뢰성을 높여 기후 변화 시나리오 불확실성을 줄일 것으로 기대된다.

현재 AI 기반 전지구 해양 모델은 빠른 진보에도 불구하고 관측 데이터 부족, 물리적 일관성 미비, 예측 불확실성 등의 제약을 안고 있다. 극지방·심층 해양의 관측 희소성과 물리 제약 미반영은 장기 예측 오류(drift)나 진폭 왜곡 같은 비현실적 결과를 초래할 수 있다. 이를 극복하기 위해 에너지·운동량·질량 보존을 학습에 직접 반영하는 물리 내재형 신경망(physics-informed neural networks, PINNs)과 예측 불확실성을 정량화하고 외삽 안정성을 확보할 수 있는 베이지안 신경망 및 앙상블 학습 기법으로 불확실성을 정량화하고 외삽 안정성을 확보하는 접근이 주목받고 있다 (Lütjens et al., 2021; de Wolff et al., 2021). 이는 AI 기반 해양 예측의 과학적 신뢰도와 장기 안정성을 동시에 제고할 전망이다.

AI 기반 지면 모델은 물리 기반 지면 모델이 가지는 공간적 이질성과 관측 불가능한 매개변수로 인한 예측 한계를 극복하고자 머신러닝 기반 예측 기법과 물리 기반 모델을 결합한 하이브리드 접근이 제안되어 오고 있다. AI 기술이 지면 과정의 복잡한 비선형성과 시간 지연 특성을 효과적으로 반영함으로써 토양온도, 증산 스트레스, GPP/열플럭스의 유의한 예측 성능을 확보하였다. 다만, AI 모델의 일반화 한계, 물리 법칙 위반 가능성, 변수 간 보존 관계 미반영 등은 여전히 주요 과제로 남아 있으며, 향후에는 물리적 제약을 통합한 학습 전략, 복합 관측자료 기반 멀티모달 학습, 지면-대기 연계 모델링 내 AI 통합 등이 지속적인 연구 과제로 요구된다.

자료동화는 예측 성능 향상과 과거·현재 상태 모니터링에 필수적이다. 전통적 방법과 달리 딥러닝 기반 시스템은 데이터 의존적이며, 관측·배경 오차 공분산의 직접 통합이 불가능해 분석장의 물리 보존성 신뢰성 문제가 있다. 최근 연구는 딥러닝이 데이터 내 물리 관계를 암묵적으로 학습해 고품질의 분석장을 생성 사례가 증가하고 있다(Manshausen et al., 2024; Wang et al., 2024; Fan et al., 2025). 이는 효율적 연산 구조로 자료동화의 새 흐름을 형성한다.

기후 예측 후보정 연구는 GAN 기반 기법의 성능 우위를 입증하며, 지구 시스템 모델의 해상도 증대나 보정된 강수장을 입력으로 한 식생 모델 연계 등 확장 가능성을 제시한다. 지속적 연구를 통해 실무 기후 시스템 적용 잠재력이 크다.

육상 탄소 변수 추정 개선을 위한 딥러닝 기법과 물리 기반 모델 결합 시도가 활발하나, 대다수 연구는 단일 변수 최적화에 그친다. 흡수원(식생 성장, 토양 유기물 축적)과 배출원(토양 호흡, 산불, 영구동토 해빙)의 복잡한 상호작용·공간간 특성을 아우르는 통합 모델 개발이 필요하다. 이는 육상 탄소 순환 이해를 심화하고 기후 변화 예측 불확실성을 줄이는 데 기여할 것이다.

AI 기반 해양 pCO₂ 재분석은 통계 보간이나 단일 모델 대비 정확도와 연속성에서 우수하며, 탄소 플럭스 추정의 새 대안으로 부상한다. 그러나 해양·계절별 독립 검증, 신뢰 구간·불확실성 정량화, 극한 환경(고위도, 연안, 해양 프런트) 적용이 미흡하다. 향후 AI와 물리·생지화학 모델의 하이브리드, 외삽 안정성 확보, 앙상블 기반 불확실성 평가가 필요하다. 이는 pCO₂ 추정을 넘어 탄소 순환 동역학 이해, 흡수력 평가·감시, 기후 정책 근거 마련에 활용될 수 있다. 위성·실측 네트워크 연계와 오픈 벤치마크 구축은 AI 기반 해양 탄소 연구 발전을 촉진할 것이다.

한편 이러한 성과의 상당수는 사후 실험과 재분석 자료 기반으로 얻어진 것이므로, 현업 운영 환경에서는 실시간 입력 자료의 지연, 관측 자료의 결측, 계산 자원 제약 등 현실적 요인을 충분히 반영해야 한다. 따라서 표준화된 데이터 처리, 안정적으로 효율적인 예측 시스템 구축이 요구된다. 또한 기후 서비스 관점에서는 예측 결과를 단순히 수치가 아니라 현장에서 바로 활용할 수 있는 실질적 정보로 전달할 필요가 있다. 불확실성 정보를 함께 제공함으로써 사용자가 예측의 신뢰 수준을 이해하고 판단할 수 있어야 하며, 농업·수자원·재난관리 등 분야별 수요에 맞춘 맞춤형 전달 체계가 중요하다. 나아가 이러한 예측 정보는 사회적 대응과 정책 수립 과정에서 활용될 수 있도록 위험 수준이나 영향 지수 등 이해하기 쉬운 방식으로 제공되는 것이 바람직하다.

AI 기술에 기반한 기후 예측의 초기장 생성, 시스템 개발, 후처리, 다운스케일링 성능을 더욱 높이기 위해서는 기후 모델링 및 예측의 전체 과정을 이해한 AI 전문가가 필수적이다. 컴퓨터 공학 분야의 작업과 기후 과학 분야의 작업을 모두 깊이 파악하고, AI 기법을 기후 예측에 최적화할 수 있어야 한다. 기후 변수의 샘플 부족 문제를 해결하기 위한 학습 최적화, 대기-해양-지면-해빙 간 결합 물리 과정의 현실적 모의를 위한 soft/hard 제약 도입, 예측 결과 최적화를

위한 고해상도·스케일 프리·생성형 AI 기반 다운스케일링 등의 문제가 해결되어야 하며, 이러한 과제들을 컴퓨터 공학에서 개발된 다양한 AI 기법을 통해 깊이 이해하고 기후 맥락에 적용할 수 있어야 한다.

감사의 글

이 논문은 2025년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임[NO. RS-2021-II211343, 인공지능대학원지원(서울대학교)]. 이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. RS-2024-00442228).

REFERENCES

- Abimbola, O. P., G. E. Meyer, A. R. Mittelstet, D. R. Rudnick, and T. E. Franz, 2021: Knowledge-guided machine learning for improving daily soil temperature prediction across the United States. *Vadose Zone J.*, **20**, e20151, doi:10.1002/vzj2.20151.
- Ahlström, A., and Coauthors, 2015: The dominant role of semi-arid ecosystems in the trend and variability of the land CO₂ sink. *Science*, **348**, 895-899, doi:10.1126/science.aaa1668.
- Allen, A., and Coauthors, 2025: End-to-end data-driven weather prediction. *Nature*, **641**, 1172-1179, doi:10.1038/s41586-025-08897-0.
- Bakker, D. C., and Coauthors, 2016: A multi-decade record of high-quality fCO₂ data in version 3 of the Surface Ocean CO₂ Atlas (SOCAT). *Earth Syst. Sci. Data*, **8**, 383-413, doi:10.5194/essd-8-383-2016.
- Bi, K., L. Xie, H. Zhang, X. Chen, X. Gu, and Q. Tian, 2023: Accurate medium-range global weather forecasting with 3D neural networks. *Nature*, **619**, 533-538, doi:10.1038/s41586-023-06185-3.
- Bodnar, C., and Coauthors, 2025: A foundation model for the Earth system. *Nature*, **641**, 1180-1187, doi:10.1038/s41586-025-09005-y.
- Bonev, B., T. Kurth, C. Hundt, J. Pathak, M. Baust, K. Kashinath, and A. Anandkumar, 2023: Spherical fourier neural operators: Learning stable dynamics on the sphere. *Proc. 40th Int. Conf. Mach. Learn.*, **202**, 2806-2823 [Available online at <https://proceedings.mlr.press/v202/bonev23a.html>].
- Bryan, F. O., M. W. Hecht, and R. D. Smith, 2007: Resolution convergence and sensitivity studies with North Atlantic circulation models. Part I: The western boundary current system. *Ocean Model.*, **16**, 141-159,

- doi:10.1016/j.ocemod.2006.08.005.
- Chen, L., X. Zhong, F. Zhang, Y. Cheng, Y. Xu, Y. Qi, and H. Li, 2023: FuXi: A cascade machine learning forecasting system for 15-day global weather forecast. *npj Clim. Atmos. Sci.*, **6**, 190, doi:10.1038/s41612-023-00512-1.
- Cohrs, K.-H., G. Varando, N. Carvalhais, M. Reichstein, and G. Camps-Valls, 2024: Causal hybrid modeling with double machine learning—applications in carbon flux modeling. *Mach. Learn. Sci. Technol.*, **5**, 035021, doi:10.1088/2632-2153/ad5a60.
- Cox, P. M., R. A. Betts, C. D. Jones, S. A. Spall, and I. J. Totterdell, 2000: Acceleration of global warming due to carbon-cycle feedbacks in a coupled climate model. *Nature*, **408**, 184-187, doi:10.1038/35041539.
- Cramer, W., and Coauthors, 2001: Global response of terrestrial ecosystem structure and function to CO₂ and climate change: Results from six dynamic global vegetation models. *Glob. Change Biol.*, **7**, 357-373, doi:10.1046/j.1365-2486.2001.00383.x.
- Cui, Y., and Coauthors, 2025: Forecasting the eddying ocean with a deep neural network. *Nature Commun.*, **16**, 2268, doi:10.1038/s41467-025-57389-2.
- Dagon, K., B. M. Sanderson, R. A. Fisher, and D. M. Lawrence, 2020: A machine learning approach to emulation and biophysical parameter estimation with the Community Land Model, version 5. *Adv. Stat. Clim. Meteorol. Oceanogr.*, **6**, 223-244, doi:10.5194/ascmo-6-223-2020.
- Danforth, C. M., E. Kalnay, and T. Miyoshi, 2007: Estimating and correcting global weather model error. *Mon. Wea. Rev.*, **135**, 281-299, doi:10.1175/MWR3299.1.
- de Wolff, T., H. Carrillo, L. Martí, and N. Sanchez-Pi, 2021: Towards optimally weighted physics-informed neural networks in ocean modelling. arXiv:2106.08747, 12 pp [Available online at <https://arxiv.org/abs/2106.08747>].
- Denvil-Sommer, A., M. Gehlen, M. Vrac, and C. Mejia, 2019: LSCE-FFNN-v1: a two-step neural network model for the reconstruction of surface ocean pCO₂ over the global ocean. *Geosci. Model Dev.*, **12**, 2091-2105, doi:10.5194/gmd-12-2091-2019.
- Déqué, M., 2007: Frequency of precipitation and temperature extremes over France in an anthropogenic scenario: Model results and statistical correction according to observed values. *Glob. Planet. Change*, **57**, 16-26, doi:10.1016/j.gloplacha.2006.11.030.
- Fablet, R., B. Chapron, L. Drumetz, E. Mémin, O. Pannekoek, and F. Rousseau, 2021: Learning variational data assimilation models and solvers. *J. Adv. Model. Earth Syst.*, **13**, e2021MS002572, doi:10.1029/2021MS002572.
- Fan, H., and Coauthors, 2025: Physically consistent global atmospheric data assimilation with machine learning in a latent space. arXiv:2502.02884, 46 pp [Available online at <https://arxiv.org/abs/2502.02884>].
- Fang, J., and P. Gentine, 2024: Exploring optimal complexity for water stress representation in terrestrial carbon models: A hybrid-machine learning model approach. *J. Adv. Model. Earth Syst.*, **16**, e2024MS004308, doi:10.1029/2024MS004308.
- François, B., S. Thao, and M. Vrac, 2021: Adjusting spatial dependence of climate model outputs with cycle-consistent adversarial networks. *Clim. Dyn.*, **57**, 3323-3353, doi:10.1007/s00382-021-05869-8.
- Friedlingstein, P., and Coauthors, 2022: Global carbon budget 2022. *Earth System Science Data*, **14**, 4811-4900, doi:10.5194/essd-14-4811-2022.
- Gregor, L., A. D. Lebehot, S. Kok, and P. M. Scheel Monteiro, 2019: A comparative assessment of the uncertainties of global surface ocean CO₂ estimates using a machine-learning ensemble (CSIR-ML6 version 2019a)-have we hit the wall? *Geosci. Model Dev.*, **12**, 5113-5136, doi:10.5194/gmd-12-5113-2019.
- Guo, H. Y., M. X. Chen, and L. Han, 2020: Evaluation of the Conv-GRU deep learning method for convective weather nowcasting. *Proc. 19th Conf. Artif. Intell. Environ. Sci., Boston, MA, Amer. Meteor. Soc.*, **100**, 15B-6.
- Ham, Y. G., Y. S. Joo, J. H. Kim, and J. G. Lee, 2024: Partial-convolution-implemented generative adversarial network for global oceanic data assimilation. *Nat. Mach. Intell.*, **6**, 834-843, doi:10.1038/s42256-024-00867-x.
- Han, L., J. Z. Sun, and W. Zhang, 2020: Convolutional neural network for convective storm nowcasting using 3-D Doppler weather radar data. *IEEE Trans. Geosci. Remote Sens.*, **58**, 1487-1495, doi:10.1109/TGRS.2019.2948070.
- Han, L., and Coauthors, 2021: A deep learning method for bias correction of ECMWF 24-240 h forecasts. *Adv. Atmos. Sci.*, **38**, 1444-1459, doi:10.1007/s00376-021-1152-8.
- Hatfield, S., M. Chantry, P. Dueben, P. Lopez, A. Geer, and T. Palmer, 2021: Building tangent-linear and adjoint models for data assimilation with neural networks. *J. Adv. Model. Earth Syst.*, **13**, e2021MS002521, doi:10.1029/2021MS002521.

- Hess, P., M. Drüke, S. Petri, F. M. Strnad, and N. Boers, 2022: Physically constrained generative adversarial networks for improving precipitation fields from Earth system models. *Nat. Mach. Intell.*, **4**, 828-839, doi:10.1038/s42256-022-00540-1.
- Ho, J., A. Jain, and P. Abbeel, 2020: Denoising diffusion probabilistic models. *Adv. Neural Inf. Process. Syst.*, **33**, 6840-6851, doi:10.48550/arXiv.2006.11239.
- Hu, Q., and Coauthors, 2022: Intercomparison of global terrestrial carbon fluxes estimated by MODIS and Earth system models. *Sci. Total Environ.*, **810**, 152231, doi:10.1016/j.scitotenv.2021.152231.
- Hu, X., L. Shi, L. Lin, S. Li, X. Deng, L. Li, J. Bian, and X. Lian, 2024: A novel hybrid modelling framework for GPP estimation: Integrating a multispectral surface reflectance based Vcmax25 simulator into the process-based model. *Sci. Total Environ.*, **921**, 171182, doi:10.1016/j.scitotenv.2024.171182.
- Ines, A. V. M., and J. W. Hansen, 2006: Bias correction of daily GCM rainfall for crop simulation studies. *Agric. For. Meteorol.*, **138**, 44-53, doi:10.1016/j.agrformet.2006.03.009.
- Ivanov, V. Y., R. L. Bras, and E. R. Vivoni, 2008: Vegetation-hydrology dynamics in complex terrain of semi-arid areas: I. A mechanistic approach to modeling dynamic feedbacks. *Water Resour. Res.*, **44**, 34 pp, doi:10.1029/2006WR005588.
- Jung, M., S. Koirala, U. Weber, K. Ichii, F. Gans, G. Camps-Valls, D. Papale, C. Schwalm, G. Tramontana, and M. Reichstein, 2019: The FLUXCOM ensemble of global land-atmosphere energy fluxes. *Sci. Data*, **6**, 74, doi:10.1038/s41597-019-0081-6.
- Kadow, C., D. M. Hall, and U. Ulbrich, 2020: Artificial intelligence reconstructs missing climate information. *Nat. Geosci.*, **13**, 408-413, doi:10.1038/s41561-020-0582-5.
- Kamenkovich, I., P. Berloff, M. Haigh, L. Sun, and Y. Lu, 2021: Complexity of mesoscale eddy diffusivity in the ocean. *Geophys. Res. Lett.*, **48**, e2020GL091719, doi:10.1029/2020GL091719.
- Keller, J. D., and R. Potthast, 2024: AI-based data assimilation: Learning the functional of analysis estimation. arXiv:2406.00390, 16 pp [Available online at <https://arxiv.org/abs/2406.00390>].
- Kim, H., Y. G. Ham, Y. S. Joo, and S. W. Son, 2021: Deep learning for bias correction of MJO prediction. *Nat. Commun.*, **12**, 3087, doi:10.1038/s41467-021-23406-3.
- Kochkov, D., and Coauthors, 2024: Neural general circulation models for weather and climate. *Nature*, **632**, 1060-1066, doi:10.1038/s41586-024-07744-y.
- Koppa, A., D. Rains, P. Hulsman, R. Poyatos, and D. G. Miralles, 2022: A deep learning-based hybrid model of global terrestrial evaporation. *Nat. Commun.*, **13**, 1912, doi:10.1038/s41467-022-29543-7.
- Kraabel, N., J. Liu, Y. Bian, D. Kifer, and C. Shen, 2025: StefaLand: An Efficient Geoscience Foundation Model That Improves Dynamic Land-Surface Predictions. arXiv:2509.17942, 30pp [Available online at <https://arxiv.org/abs/2509.17942>].
- Kratzert, F., D. Klotz, C. Brenner, K. Schulz, and M. Herrnegger, 2018: Rainfall-runoff modelling using long short-term memory (LSTM) networks. *Hydrol. Earth Syst. Sci.*, **22**, 6005-6022. doi:10.5194/hess-22-6005-2018.
- Lam, R., and Coauthors, 2023: Learning skillful medium-range global weather forecasting. *Science*, **382**, 1416-1421, doi:10.1126/science.adi2336.
- Landschützer, P., N. Gruber, D. C. Bakker, and U. Schuster, 2014: Recent variability of the global ocean carbon sink. *Glob. Biogeochem. Cycles*, **28**, 927-949, doi:10.1002/2014GB004853.
- Lang, S., and Coauthors, 2024: AIFS-ECMWF's data-driven forecasting system. arXiv:2406.01465, 13 pp [Available online at <https://arxiv.org/abs/2406.01465>].
- Laruelle, G. G., P. Landschützer, N. Gruber, J. L. Tison, B. Delille, and P. Regnier, 2017: Global high-resolution monthly pCO₂ climatology for the coastal ocean derived from neural network interpolation. *Biogeosciences*, **14**, 4545-4561, doi:10.5194/bg-14-4545-2017.
- Lebedev, V., Y. Ganin, M. Rakhuba, I. Oseledets, and V. Lempitsky, 2019: Precipitation nowcasting with satellite imagery. *Proc. 25th ACM SIGKDD Int. Conf. Knowl. Discov. Data Min., Anchorage, AK, ACM*, 2680-2688, doi:10.1145/3292500.3330762.
- LeCun, Y., L. Bottou, Y. Bengio, and P. Haffner, 2002: Gradient-based learning applied to document recognition. *Proc. IEEE*, **86**, 2278-2324, doi:10.1109/5.726791.
- Li, H. C., C. Yu, J. J. Xia, Y. C. Wang, J. Zhu, and P. W. Zhang, 2019: A model output machine learning method for grid temperature forecasts in the Beijing area. *Adv. Atmos. Sci.*, **36**, 1156-1170. doi:10.1007/s00376-019-9023-z.
- Li, Y., and Coauthors, 2024: Fuxi-en4dvar: An assimilation system based on machine learning weather forecasting model ensuring physical constraints. *Geophys. Res. Lett.*, **51**, e2024GL111136, doi:10.1029/2024GL111136.

- Liang, X., D. P. Lettenmaier, E. F. Wood, and S. J. Burges, 1994: A simple hydrologically based model of land surface water and energy fluxes for general circulation models. *J. Geophys. Res. Atmos.*, **99**, 14415-14428, doi:10.1029/94JD00483.
- Lin, H., J. Tang, S. Wang, S. Wang, and G. Dong, 2023: Deep learning downscaled high-resolution daily near surface meteorological datasets over East Asia. *Sci. Data*, **10**, 890, doi:10.1038/s41597-023-02898-2.
- Ling, F. H., Y. Li, J.-J. Luo, X. H. Zhong, and Z. B. Wang, 2022: Two deep learning-based bias-correction pathways improve summer precipitation prediction over China. *Environ. Res. Lett.*, **17**, 124025, doi:10.1088/1748-9326/aca68a.
- Liu, G., F. A. Reda, K. J. Shih, T. C. Wang, A. Tao, and B. Catanzaro, 2018: Image inpainting for irregular holes using partial convolutions. *Proc. Eur. Conf. Comput. Vis. (ECCV)*, **11219**, 85-100, doi:10.1007/978-3-030-01252-6_6.
- Liu, L., and Coauthors, 2024: Knowledge-guided machine learning can improve carbon cycle quantification in agroecosystems. *Nat. Commun.*, **15**, 357, doi:10.1038/s41467-023-46571-1.
- Lu, F., 2025: U-net kalman filter (UNetKF): An example of machine learning-assisted data assimilation. *J. Adv. Model. Earth Syst.*, **17**, e2023MS003979, doi:10.1029/2023MS003979.
- Lütjens, B., C. H. Crawford, M. Veillette, and D. Newman, 2021: Pce-pinns: Physics-informed neural networks for uncertainty propagation in ocean modeling. arXiv:2105.02939, 7 pp [Available online at <https://arxiv.org/abs/2105.02939>].
- Lyu, W., X. Zhi, and S. Zhu, 2023: Improving subseasonal-to-seasonal prediction of summer extreme precipitation over southern china based on a deep learning method. *Geophys. Res. Lett.*, **50**, e2023GL106245, doi:10.1029/2023GL106245.
- Mack, J., R. Arcucci, M. Molina-Solana, and Y. K. Guo, 2020: Attention-based convolutional autoencoders for 3d-variational data assimilation. *Comput. Methods Appl. Mech. Eng.*, **372**, 113291, doi:10.1016/j.cma.2020.11329.
- Manabe, S., and K. Bryan, 1969: Climate calculations with a combined ocean-atmosphere model. *J. Atmos. Sci.*, **26**, 786-789, doi:10.1175/1520-0469(1969)026<0786:CCWACO>2.0.CO;2.
- Manshausen, P., and Coauthors, 2024: Generative data assimilation of sparse weather station observations at kilometer scales. arXiv:2406.16947, 25 pp [Available online at <https://arxiv.org/abs/2406.16947>].
- Martin, S. A., G. Manucharyan, and P. Klein, 2025: Generative data assimilation for surface ocean state estimation from multi-modal satellite observations. *J. Adv. Model. Earth Syst.*, **17**, e2025MS005063, doi:10.1029/2025MS005063.
- Melinc, B., and Ž. Zaplotnik, 2024: 3D-Var data assimilation using a variational autoencoder. *Q. J. R. Meteorol. Soc.*, **150**, 2273-2295, doi:10.1002/qj.4708.
- Miralles, D. G., and Coauthors, 2025: GLEAM4: global land evaporation and soil moisture dataset at 0.1 resolution from 1980 to near present. *Sci. Data*, **12**, 416, doi:10.1038/s41597-025-04610-y.
- Nelson, J. A., and Coauthors, 2024: X-BASE: The first terrestrial carbon and water flux products from an extended data-driven scaling framework, FLUXCOM-X. *Biogeosciences*, **21**, 5079-5115, doi:10.5194/bg-21-5079-2024.
- Nguyen, T., J. Brandstetter, A. Kapoor, J. K. Gupta, and A. Grover, 2023: ClimaX: A foundation model for weather and climate. *Proc. 40th Int. Conf. Mach. Learn.*, **202**, 25904-25938 [Available online at <https://proceedings.mlr.press/v202/nguyen23a.html>].
- Oyama, N., N. N. Ishizaki, S. Koide, and H. Yoshida, 2023: Deep generative model super-resolves spatially correlated multiregional climate data. *Sci. Rep.*, **13**, 5992, doi:10.1038/s41598-023-32750-y.
- Pan, B., Y. Guo, and Y. He, 2021: Deep learning based post-processing of precipitation forecasts using CycleGAN. *Remote Sens.*, **13**, 1822, doi:10.3390/rs13091822.
- Pandey, K., A. Mukherjee, P. Rai, and A. Kumar, 2022: Diffusevae: Efficient, controllable and high-fidelity generation from low-dimensional latents. arXiv:2201.00308, 39 pp [Available online at <https://arxiv.org/abs/2201.00308>].
- Park, D., S. Kim, S. Lee, and H. J. Kim, 2024: Ddmi: Domain-agnostic latent diffusion models for synthesizing high-quality implicit neural representations. arXiv:2401.12517, 14 pp [Available online at <https://arxiv.org/abs/2401.12517>].
- Pathak, J., and Coauthors, 2022: Fourcastnet: A global data-driven high-resolution weather model using adaptive fourier neural operators. arXiv:2202.11214, 28 pp [Available online at <https://arxiv.org/abs/2202.11214>].
- Peng, X. D., Y. Z. Che, and J. Chang, 2013: A novel approach to improve numerical weather prediction skills by using anomaly integration and historical data. *J. Geophys. Res. Atmos.*, **118**, 8814-8826, doi:10.1002/jgrd.50682.

- Peyron, M., A. Fillion, S. Gürol, V. Marchais, S. Gratton, P. Boudier, and G. Goret, 2021: Latent space data assimilation by using deep learning. *Q. J. R. Meteorol. Soc.*, **147**, 3759-3777, doi:10.1002/qj.4153.
- Pour, S. H., S. Shahid, E.-S. Chung, and X.-J. Wang, 2018: Model output statistics downscaling using support vector machine for the projection of spatial and temporal changes in rainfall of Bangladesh. *Atmos. Res.*, **213**, 149-162, doi:10.1016/j.atmosres.2018.06.006.
- Price, I., and Coauthors, 2025: Probabilistic weather forecasting with machine learning. *Nature*, **637**, 84-90, doi:10.1038/s41586-024-08252-9.
- Qian, W. H., 2012: How to improve the skills of weather and climate predictions? *Chin. J. Geophys.*, **55**, 1532-1540, doi:10.6038/j.issn.0001-5733.2012.05.010.
- Rasp, S., and Coauthors, 2024: WeatherBench 2: A benchmark for the next generation of data-driven global weather models. *J. Adv. Model. Earth Syst.*, **16**, e2023MS004019, doi:10.1029/2023MS004019.
- Rödenbeck, C., R. F. Keeling, D. C. Bakker, N. Metzl, A. Olsen, C. Sabine, and M. Heimann, 2013: Global surface-ocean pCO₂ and sea-air CO₂ flux variability from an observation-driven ocean mixed-layer scheme. *Ocean Sci.*, **9**, 193-216, doi:10.5194/os-9-193-2013.
- Rozet, F., and G. Louppe, 2023: Score-based data assimilation. *Adv. Neural Inf. Process. Syst.*, **36**, 40521-40541, doi:10.48550/arXiv.2306.10574.
- Ruan, X., D. Couespel, M. Lévy, J. Li, J. Mak, and Y. Wang, 2023: Combined physical and biogeochemical assessment of mesoscale eddy parameterisations in ocean models: Eddy induced advection at non-eddy-resolving resolutions. *Ocean Model.*, **183**, 102204, doi:10.1016/j.ocemod.2024.102396.
- Scarselli, F., M. Gori, A. C. Tsoi, M. Hagenbuchner, and G. Monfardini, 2008: The graph neural network model. *IEEE Trans. Neural Netw.*, **20**, 61-80, doi:10.1109/TNN.2008.2005605.
- Shen, L., J. Pauly, and L. Xing, 2022: NeRP: implicit neural representation learning with prior embedding for sparsely sampled image reconstruction *IEEE Trans. Neural Netw. Learn. Syst.*, **35**, 770-782. doi:10.1109/TNNLS.2022.3148794.
- Shi, X. J., Z. R. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong, and W.-C. Woo, 2015: Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *In Adv. Neural Inf. Process. Syst.*, **28**, 802-810, doi:10.5555/2969239.2969329.
- Singh, R., A. Shukla, and P. Turaga, 2023: Polynomial implicit neural representations for large diverse datasets. *Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit.*, 2041-2051.
- Sitzmann, V., J. Martel, A. Bergman, D. Lindell, and G. Wetzstein, 2020: Implicit neural representations with periodic activation functions. *Adv. Neural Inf. Process. Syst.*, **33**, 7462-7473.
- Son, R., and Coauthors, 2024: Integration of a deep-learning-based fire model into a global land surface model. *J. Adv. Model. Earth Syst.*, **16**, e2023MS003710, doi:10.1029/2023MS003710.
- Takata, K., S. Emori, and T. Watanabe, 2003: Development of the minimal advanced treatments of surface interaction and runoff. *Glob. Planet. Change*, **38**, 209-222, doi:10.1016/S0921-8181(03)00030-4.
- Tao, F., and Coauthors, 2020: Deep learning optimizes data-driven representation of soil organic carbon in Earth system model over the conterminous United States. *Front. Big Data*, **3**, 17, doi:10.3389/fdata.2020.00017.
- Tao, Y. M., X. G. Gao, K. Hsu, S. Sorooshian, and A. Ihler, 2016: A deep neural network modeling framework to reduce bias in satellite precipitation products. *J. Hydrometeorol.*, **17**, 931-945, doi:10.1175/JHM-D-15-0075.1.
- Thrasher, B., E. P. Maurer, C. McKellar, and P. B. Duffy, 2012: Bias correcting climate model simulated daily temperature extremes with quantile mapping. *Hydrol. Earth Syst. Sci.*, **16**, 3309-3314, doi:10.5194/hess-16-3309-2012.
- Vaswani, A., and Coauthors, 2017: Attention is all you need. *Adv. Neural Inf. Process. Syst.*, **30**, 11 pp.
- Wang, W., and Coauthors, 2024: Accurate initial field estimation for weather forecasting with a variational constrained neural network. *npj Clim. Atmos. Sci.*, **7**, 223, doi:10.1038/s41612-024-00776-1.
- Wang, X., and Coauthors, 2024: Xihe: A data-driven model for global ocean eddy-resolving forecasting. arXiv: 2402.02995, 18 pp [Available online at <https://arxiv.org/abs/2402.02995>].
- Ward, M. N., and A. Navarra, 1997: Pattern analysis of SST-forced variability in ensemble GCM simulations: Examples over Europe and the tropical Pacific. *J. Climate*, **10**, 2210-2220, doi:10.1175/1520-0442(1997)010<2210:PAOSFV>2.0.CO;2.
- Xiao, Y., L. Bai, W. Xue, K. Chen, T. Han, and W. Ouyang, 2023: Fengwu-4dvar: Coupling the data-driven weather forecasting model with 4d variational assimilation. arXiv:2312.12455, 18 pp [Available online at <https://arxiv.org/abs/2312.12455>].

- Xu, H., J. Fan, F. Tao, L. Jiang, F. You, B. Z. Houlton, Y. Sun, C. P. Gomes, and Y. Luo, 2025: Biogeochemistry-informed neural network (BINN) for improving accuracy of model prediction and scientific understanding of soil organic carbon. arXiv:2502.00672, 34 pp [Available online at <https://arxiv.org/abs/2502.00672>].
- Yang, S., F. Ling, J. J. Luo, and L. Bai, 2025: Improving the seasonal forecast of summer precipitation in southeastern China using a CycleGAN-based deep learning bias correction method. *Adv. Atmos. Sci.*, **42**, 26-35, doi:10.1007/s00376-024-4003-3.
- Yu, J., Z. Lin, J. Yang, X. Shen, X. Lu, and T. S. Huang, 2019: Free-form image inpainting with gated convolution. *In Proc. IEEE/CVF Int. Conf. Comput. Vis.*, 4471-4480, doi:10.1109/ICCV.2019.00457.
- Yuan, W. P., W. W. Cai, D. Liu, and W. J. Dong, 2014: Satellite-based vegetation production models of terrestrial ecosystem: An overview. *Adv. Earth Sci.*, **29**, 541-550, doi:10.11867/j.issn.1001-8166.2014.05.0541.
- Zeng, J., Y. Nojiri, P. Landschützer, M. Telszewski, and S. I. Nakaoka, 2014: A global surface ocean fCO₂ climatology based on a feed-forward neural network. *J. Atmos. Oceanic Technol.*, **31**, 1838-1849, doi:10.1175/JTECH-D-13-00137.1.
- Zhao, P., and Coauthors, 2024: OMG-HD: A high-resolution AI weather model for end-to-end forecasts from observations, 17 pp [Available online at <https://arxiv.org/abs/2412.18239>].
- Zhong, J. T., and Coauthors, 2021: Robust prediction of hourly PM_{2.5} from meteorological data using LightGBM. *Natl. Sci. Rev.*, **8**, nwaa307, doi:10.1093/nsr/nwaa307.