

2025년 추계학술발표대회 : 일반부문

실시간 도시 기후지도 추론을 위한 물리학 기반 기계학습 프레임워크

Physics-informed machine learning framework for reasoning real-time urban climate map

○ 최 진 우* 공 민 진* 홍 태 훈**
Choi, Jinwoo Kong, Minjin Hong, Taehoon

Abstract

The aim of this study was to suggest a machine learning-based framework to predict integrated urban climate maps with airflow and temperature information of urban domains in real time. To achieve this, a combined machine learning architecture of physics-informed neural networks and physics-informed neural operators was developed to ensure both computational efficiency and prediction accuracy. The framework adopted sub-model layers to minimize learning noise derived from physics-informed constraints, effectively predicting flow velocity, flow direction, temperature, and relative humidity of urban regions simultaneously. The framework facilitates practical applications in energy-efficient urban planning and climate adaptation.

키워드 : 도시 기후지도, 기계 학습, 물리학 기반 신경망, 물리학 기반 신경 연산자

Keywords : Urban climate map, Machine learning, Physics-informed neural network, Physics-informed neural operator

1. 서론

1.1 연구 배경

도시 미기후에 대한 신속하고 정확한 예측은 건축 및 도시계획 분야에서 에너지 효율적 건물 설계, 쾌적한 외부 공간 조성, 도시 열섬 현상 완화 등 다양한 실질적 기여를 가져올 수 있어 수십 년간 핵심 연구 주제로 자리 잡았다 [1]. 특히 도시 규모에서의 기후지도(urban climate map) 산정은 기온, 습도, 풍향, 풍속의 공간적 분포를 종합적으로 파악함으로써 건물 에너지 소비 최적화, 도시 열환경 개선 대책 수립, 대기질 관리 전략 도출, 보행자 쾌적성 향상 등 광범위한 사회적·환경적 이득을 창출할 수 있다 [2]. 그러나 이러한 도시 기후지도를 정확하고 신속하게 산정하는 것은 대기 흐름의 복잡한 난류 특성에 따른 예측의 본질적 어려움과, 특히 도시 단위의 광역 해석을 위한 막대한 계산 비용으로 인해 아직까지도 완전히 해결되지 못한 상황이다 [3].

관련 연구 분야의 발전 과정을 살펴보면, 초기에는 단순화된 경험적 모델(empirical model)을 활용한 추론이나

제한된 지점에서의 센서 측정에 의존하는 방식이 주로 활용되었다. 그러나 이러한 접근법들은 복잡한 도시 형태학적 특성을 충분히 반영하지 못하고, 공간적 해상도와 정확도가 제한적이며, 다양한 기상 조건에 대한 일반화 능력이 부족하다는 근본적 한계를 가지고 있었다.

이후 전산유체역학(Computational Fluid Dynamics, CFD)이 산업계 전반에 걸쳐 급속히 발전하면서 도시 미기후 분야에서도 상당한 연구 진전이 이루어졌다. CFD 시뮬레이션은 건설 분야 전반의 분석 및 최적화를 위한 필수 도구로 자리하며, 작게는 실내 공간에서 크게는 도시 영역을 아우르는 공간 영역 전반에 걸쳐 복잡한 기류 분포, 오염물질 확산, 도시 미기후 등 다양한 거주환경 관련 현상들을 해석하는 데 탁월한 능력을 보여주었다 [4].

CFD 접근법의 유연하고 신뢰도 높은 시뮬레이션 역량 덕분에 연구자들과 실무진들은 막대한 비용과 시간이 소요되는 물리 실험이나 실제 건설을 수행하지 않고도 다양한 설계 대안을 정량적으로 비교 및 검토할 수 있게 되었고, 이를 바탕으로 건축 환경 분야의 지속적 혁신이 가속화될 수 있었다. 그러나 여전히 막대한 계산 비용, 민감한 경계조건 설정의 복잡성, 높은 전문성 요구, 모델 정확도와 계산 효율성 간의 상충관계(trade-off)와 같은 CFD 시뮬레이션의 핵심적인 한계들은 대부분의 산업 분야에서 수십 년간 완전히 해결되지 못하고 있는 실정이다. 이러한 제약사항들은 넓은 공간 영역을 동시에 고려해야 하며 해석 결과의 높은 정확도와 빠른 응답성을 모두 요구하는 도시 미기후 분야에서 더욱 뚜렷하게 부각되어, 실시간 도시 기후지도 산정은 여전히 요원한 과제로 남아있다 [5].

* 연세대학교 건축공학과 박사과정

** 연세대학교 건축공학과 교수, 공학박사

(Corresponding author : Department of Architecture and Architectural Engineering, Yonsei University, hong7@yonsei.ac.kr)

이 연구는 2025년도 한국연구재단 연구비 지원에 의한 결과의 일부분임. 과제번호:NRF-2021R1A3B1076769

한편, 최근 수년간 급속히 발전한 컴퓨터 과학 기술에 힘입어 인공지능 기술은 이러한 CFD 시뮬레이션 응용의 한계를 극복할 혁신적 해결책으로 주목받고 있다. 대리모델(surrogate model), 축소차수모델(reduced order model), 심층학습(deep learning) 프레임워크와 같은 다양한 데이터 기반 접근법들은 CFD 시뮬레이션을 가속화, 보완 또는 대체할 수 있을 것으로 전망되고 있다. 특히 기존의 수치해석 방법만으로는 달성하기 어려웠던 도시환경 문제에 대한 다중 충실도(multi-fidelity) 해석과 실시간 예측 및 제어에 AI 기반 접근법을 통해 실현될 수 있을 것으로 기대되면서, 기존에 사용되지 못했던 혁신적인 방식으로 복잡한 유동장을 해석하거나 추론할 수 있는 새로운 가능성이 제시되고 있다 [6].

그러나 데이터 기반 방법을 통해 도시 기후지도 추론을 수행하고자 했던 기존 연구들을 살펴보면 상당한 제약사항들이 존재함을 확인할 수 있다. 첫째, 대부분의 연구들이 온도와 습도를 제외하고 풍속과 풍향 데이터만을 추론 대상으로 하여 종합적인 기후지도 구성에 한계를 보였다. 둘째, 순수한 데이터 기반 접근법들은 종종 물리 법칙을 위반하는 결과를 도출하여 질량 보존, 운동량 보존 등 기본적인 유체역학 원리를 준수하지 못하는 문제를 나타냈다. 셋째, 학습된 모델들의 외삽 능력이 제한적이어서 학습 데이터 범위를 벗어난 새로운 기상 조건이나 도시 형태에 대한 일반화 성능이 부족했다. 넷째, 모델의 물리적 해석 가능성과 예측 결과에 대한 신뢰성 검증이 어려워 실무 적용에서 요구되는 재현성과 효율성 측면에서 실질적으로 활용되기 어려운 상황이었다.

최근 들어서는 물리학 정보 신경망(Physics-Informed Neural Network, PINN), 물리학 정보 신경 연산자(Physics-Informed Neural Operator, PINO) 등 물리 법칙을 명시적으로 고려하는 기계학습 기법들이 각광받으면서, 기존 데이터 기반 방법들의 한계를 극복할 수 있는 새로운 가능성이 제시되고 있다. 이러한 물리학 기반 기계학습 접근법들은 편미분방정식으로 표현되는 물리 법칙을 손실 함수에 직접 포함시킴으로써 데이터의 양이 제한적인 상황에서도 물리적으로 타당한 예측을 수행할 수 있으며, 외삽 성능과 일반화 능력이 크게 향상될 것으로 기대되고 있다 [7].

그러나 현재까지의 물리학 기반 기계학습 연구들은 대부분 상대적으로 단순한 기하학적 형상이나 제한된 물리 현상에 국한되어 있으며, 도시 미기후와 같이 복잡한 다중 물리 현상과 불규칙한 3차원 도시 형태를 동시에 다루는 대규모 실세계 문제의 적용은 아직 초기 단계에 머물러 있다. 특히 기존 PINN 기반 연구들은 단일 물리량(예: 온도 또는 속도장)에 대한 예측에 주로 집중되어 있어, 온도, 습도, 풍속, 풍향을 종합적으로 고려해야 하는 도시 기후지도 산정 문제에 직접 적용하기에는 상당한 기술적 확장과 검증이 필요한 상황이다. 또한 물리 제약조건과 데이터 손실 함수 간의 가중치 균형 조정, 복잡한 경계조건 처리, 대규모 도메인에서의 계산 효율성 확보 등 실용적 구현을 위한 다양한 기술적 도전과제들이 여전히 해결되

지 못하고 있어, 실시간 도시 기후지도 산정을 위한 포괄적이고 효율적인 물리학 기반 기계학습 프레임워크의 개발이 절실히 요구되고 있다.

1.2. 연구 목적

이러한 연구 배경 하에서 본 연구는 최근 각광받고 있는 PINN과 PINO 등의 물리학 기반 기계학습 기법을 통합하여 도시 형태학적 특성, 기상 조건, 경계층 물리학을 복합적으로 고려하는 통합 기계학습 프레임워크를 제안하고자 한다.

구체적인 연구 목적은 다음과 같다. 첫째, 나비에-스토크스 방정식, 에너지 보존 방정식, 습도 수송 방정식 등 핵심적인 물리 법칙들을 손실 함수에 명시적으로 포함시킨 물리학 기반 신경망 아키텍처를 개발하여, 기존 데이터 기반 방법들이 가지고 있던 물리 법칙 위반 문제를 근본적으로 해결하고자 한다. 둘째, 온도, 습도, 풍향, 풍속을 동시에 예측할 수 있는 다 변수 출력 구조를 구현하여 종합적인 도시 기후지도 구성을 가능하게 하고자 한다. 셋째, 도시 건물 형태, 지표면 특성, 대기 경계층 조건 등을 체계적으로 인코딩하는 특징 추출 모듈을 설계하여 다양한 도시 환경 조건에 대한 일반화 성능을 확보하고자 한다. 최종적으로 전통적인 CFD 시뮬레이션 대비 수 백 배 이상의 계산속도 향상을 달성하면서도 충실한 예측 정확도를 유지할 수 있는 실시간 도시 기후지도 산정을 위한 효율적인 추론 프레임워크를 제안하고자 한다.

이를 통해 본 연구는 기존의 계산 비용과 시간적 제약으로 인해 실현되지 못했던 실시간 도시 기후지도 추론을 가능하게 하여, 에너지 효율적 도시 설계, 기후 변화 적응 전략 수립, 도시 열 환경 개선 등 지속가능한 도시 개발에 실질적으로 기여할 수 있는 혁신적 기술적 해결책을 제공하고자 한다.

2. 실시간 도시 기후지도 산정을 위한 물리학 기반 기계학습 프레임워크

본 장에서는 실시간 도시 기후지도 산정을 위한 물리학 기반 기계학습 프레임워크 개발을 위한 설계 원칙과 구조를 제안한다. 특히 기존 연구에서 충분히 고려되지 못했던 다중 기후 인자(풍속, 풍향, 온도, 상대습도)를 동시에 학습·추론하기 위하여, PINN과 PINO의 장점을 상호 보완적으로 결합하는 방식을 채택하였다. 이를 통해 도시 스케일 기후지도의 복잡성을 유지하면서도, 실시간에 가까운 모델을 확보할 수 있다.

2.1 물리학 기반 신경망 (Physics-informed neural network)

PINN은 기존 데이터 기반 기계학습이 가지는 물리 법칙 무시로 인한 일반화력 부족을 보완하기 위해 Raissi et al. (2017)에서 처음 제안된 방법론이다 [8]. PINN은 신경망 출력에 대한 자동미분(automatic differentiation)을 적용하여 편미분 방정식(partial derivative equation, PDE)의 잔차를 직접 계산하고, 이를 손실 함수(loss function)에 포함시킨다. 따라서 학습 데이터가 부족한 상황에서도 물리 법

칙을 강제하여 기계학습 모델의 외삽 능력을 강화하고 해석적으로 타당한 해를 얻을 수 있다는 장점이 있다. PINN의 기본 개념은 수식 1과 같이 나타낼 수 있다.

$$L_{PINN} = L_{data} + \lambda L_{physics} \dots\dots\dots (1)$$

여기서, L_{data} 은 관측 데이터와의 오차; $L_{physics}$ 은 PDE 잔차, 경계조건, 초기조건 위반 정도; λ 는 두 손실항의 가중치 계수이다.

PINN은 물리 법칙 준수를 통해 설명 가능한 해(explainable solution)를 도출할 수 있으나, 복잡한 PDE를 다룰 때에는 스케일 불균형, 수렴 난제, 파라미터 민감도가 단점으로 지적된다.

2.2 물리학 기반 신경 연산자 (Physics-informed neural operator)

PINO는 Li et al. (2021)에 의해 처음 제안되었으며, PINN과 달리 해를 직접 근사하지 않고, 입력 조건 $\rightarrow$ 해 전체로 가는 연산자(operator) 자체를 학습한다 [9]. 즉, PINO는 특정 조건이 주어졌을 때 PDE를 풀지 않고도 해 전체를 빠르게 산출할 수 있는 맵핑 함수를 근사한다 (수식 2).

$$G: (BC, IC, \Omega) \mapsto u(x, t) \dots\dots\dots (2)$$

여기서 G 는 학습된 연산자; BC 는 경계조건; IC 는 초기조건; Ω 는 해석 영역; $u(x, t)$ 는 해 전체이다.

PINO는 한 번 학습되면 다양한 초기조건 및 경계조건에 빠르게 대응할 수 있어 도시 규모의 대규모 시뮬레이션을 대리하는 데 강점이 있다. 그러나, 고주파 난류 구조나 벽 근처 세밀한 특성을 정확히 포착하는 데는 한계가 있어, 정밀 PDE 적용이 필요한 부분에서는 PINN에 비해 정확도가 낮아질 수 있다.

2.3 하이브리드 아키텍처

앞서 설명된 PINN의 경우 물리적 정밀도가 높은 유동장을 추론할 수 있으나 변수가 많아질수록 스케일 불균형, 수렴 난제 등의 문제가 발생할 수 있음을 언급하였다.

도시 기후지도(풍속·풍향·온도·상대습도)를 추론하기 위한 독립변수는 공간 좌표 (x, y, z)와 시간 (t), 파라미터는 유입 풍향·풍속, 외기 온·습도, 도시 형태, 표면 물성 등이다. 이때 표면 경계조건(표면온도 T_s , 열·수증기 플럭스 q_h, q_v)은 일사량 G , 알베도 α , 방사율 ϵ , 대류계수 $h(u, \text{dir})$ 로 결정되는데, h 는 다시 유동장(풍속 u , 풍향 dir)에 의존한다. 즉 경계조건-유동장 상호의존으로 인해 단일 PINN에 모든 매개변수를 일괄 학습시키면 스케일 불균형·수렴 경직성이 커진다. 따라서 본 연구는 표면 경계조건 연산자를 PINO에 위임하고(기상 입력·표면 물성·임시 대류항 $\rightarrow T_s, q_h, q_v$ 로의 빠른 사상), PINN은 이를 받아 연속·운동량·에너지·종 수송·난류 보조식 잔차 최소화로 유동장·온습도장을 추론하도록 역할을 분리한

다. 이렇게 하면 경계조건-유동장 간 반복 계산이 안정·경량화되어, 학습 부하와 수렴 시간을 동시에 줄일 수 있다. 특히 일사량, 알베도, 방사율 등은 건물/지표 표면 조건의 출력에만 관여하기 때문에 미리 학습된 보조 모델을 통해 주 모델의 학습 루프를 보조하는 것이 가능하다.

다중 기후 인자를 추론하기 위한 주 모델과 건물/지표 표면 조건만을 추론하기 위한 보조 모델을 결합하는 하이브리드 아키텍처를 제안함으로써, PINN / PINO 적용에 따른 부작용을 최소화하고 모델의 추론 성능을 향상시키기 위한 하이브리드 기계학습 아키텍처는 다음과 같이 요약될 수 있다.

보조 모델은 PINO 기반으로 구현되며, 복잡한 복사·대류·전도 경계 조건을 빠르게 대리하는 역할을 한다. 도시 기상조건 (일사량, 풍속, 풍향, 외기 온습도, 표면 물성)을 입력으로 하며, 주 모델의 입력으로 사용될 건물/지표 표면 조건 관련 변수들을 출력한다. 여기서 풍속과 풍향은 주 모델을 통해 반복적으로 업데이트된다.

주 모델은 PINN 기반으로 구현되며, 다중 기후 인자 관련 지배 방정식인 연속방정식, 운동량방정식, 에너지방정식, 종 수송 방정식, 난류 보조 방정식의 PDE 잔차를 직접 최소화하며 물리적 일관성을 확보하는 역할을 한다. 공간 좌표, 시간, 외기 유입 조건, 보조 모델이 제공한 경계조건을 입력으로 하며, 도시 스케일 기후지도를 출력한다. 즉, 보조 모델은 경계 조건 서로게이트, 주 모델은 유체장 서로게이트라는 명확한 역할 분담을 통해 학습 안정성과 계산 효율성을 동시에 확보한다.

2.4 기계학습 프레임워크

앞서 설명된 하이브리드 아키텍처에 따라, 최종적으로 제안하는 프레임워크는 보조 모델(PINO)과 주 모델(PINN)이 상호작용하는 다단계 구조로 요약된다. 본 프레임워크의 목표는 도시 기상 조건(풍속, 풍향, 온도, 상대습도, 일사량 등)과 표면 특성(알베도, 방사율 등)이 주어졌을 때, 실시간으로 도시 스케일 기후지도를 추론하는 것이다. 전체 과정은 다음과 같은 단계로 구성된다.

(1) 보조 모델(PINO)의 역할과 핵심 수식

보조 모델은 물리학 기반 신경 연산자(PINO)로 구현되며, 입력 조건을 바탕으로 경계 조건 전체를 직접 맵핑한다. 보조 모델의 기본 개념은 다음과 같다 (수식 3).

$$G_\phi: (BC, IC, \Omega) \mapsto \{T_{wall}(x, t), q_{wall}''(x, t), m_{wall}''(x, t)\} \quad (3)$$

여기서 G_ϕ 는 학습된 연산자; BC 는 일사 조건, 외기 대류 조건, 외기 온습도 조건, 표면 물성; IC 는 표면 초기 온도 분포; Ω 는 도시 블록, 지면, 건물 외벽, 도메인 상부(대기층 상단)까지 포함한 3D 해석 영역; $T_{wall}(x, t)$, $q_{wall}''(x, t)$, $m_{wall}''(x, t)$ 는 각각 표면 온도, 열 플럭스, 수증기 플럭스이다.

(2) 주 모델(PINN)의 역할과 핵심 수식

주 모델은 물리학 기반 신경망(PINN)으로 구현되며, 보

조 모델의 출력(경계 조건)을 입력받아 도시 기후장을 추론한다. 주 모델의 기본 손실 함수는 다음과 같다 (수식 4).


$$L_{PINN} = \lambda_c \|R_c\|^2 + \lambda_m \|R_m\|^2 + \lambda_e \|R_e\|^2 + \lambda_s \|R_s\|^2 + \lambda_k \|R_k\|^2 + \lambda_\epsilon \|R_\epsilon\|^2 + \lambda_f \|R_f\|^2 + L_{data} \quad (4)$$

여기서 R_c 은 연속 방정식 잔차; R_m 은 운동량 방정식 잔차; R_e 는 에너지 방정식 잔차; R_s 은 종 수송 잔차; R_k 과 R_ϵ 은 난류 보조식 잔차; R_f 는 경계조건 잔차; λ 은 가중치 계수이다.

(3) 반복적 갱신 및 수렴 프로세스

앞서 언급한 바와 같이 보조 모델의 경계조건에 해당되는 대류 조건은 주 모델의 유동장 추론 결과에 따라 변동되기 때문에 보조 모델과 주 모델 간의 출력을 반복적으로 교환하며 수렴을 달성하는 피드백 루프 구조를 취하여야 한다. 구체적으로, 보조 모델에 초기 대류 조건을 입력할 경우 초기 건물/지표 표면 조건이 출력되며, 이를 주 모델에 입력할 경우 갱신된 대류 조건을 출력하게 된다. 갱신된 대류 조건을 다시 보조 모델에 입력하면 갱신된 건물/지표 표면 조건을 출력하게 된다. 보조 모델은 이미 학습이 완료된 PINO 모델이기 때문에 주 모델만 PDE 잔차를 최소화하는 방향으로 학습시킬 수 있다.

요약하면, 제안된 프레임워크는 PINO 기반 보조 모델의 빠른 경계조건 대리 성능과 PINN 기반 주 모델의 정밀한 PDE 기반 추론 기능을 결합하여, 기존 단일 PINN 접근의 수렴 불안정성과 학습 부하 문제를 극복하면서도 실시간 도시 기후지도 산정에 적합한 구조를 제공한다 (그림 1).



<그림 1> 도시기후지도 추론을 위한 물리학 기반 하이브리드 기계학습 프레임워크

3. 결론

본 논문에서 제안한 PINN·PINO 기반 하이브리드 기계 학습 프레임워크는 경계조건(PINO)-유체장(PINN) 역할 분리와 상호 피드백 루프로 수렴 안정성·스케일링을 확보하고, 풍속·풍향·온도·상대습도의 동시 추론 및 도시 형태학·표면 물성·경계층의 체계적 인코딩 측면에서 기존 연구와 뚜렷한 차별점을 갖는다. 이는 단일 PINN/순수 데이터 기반 접근의 물리 일관성·일반화 한계를 보완하여 실시간에 근접한 도시 기후지도 산정을 가능케 한다. 제안 프레임워크는 에너지 효율적 도시 설계, 열섬 완화, 보행자 쾌적성 및 대기질 관리 등 정책-설계-운영의 실시간 의사결정에 기여할 것으로 기대된다.

참고문헌

1. Yang, S., Zhan, D., Stathopoulos, T., Zou, J., Shu, C., & Wang, L. L. (2024). Urban microclimate prediction based on weather station data and artificial neural network. *Energy and Buildings*, 314, 114283.
2. Zhou, Y., An, N., & Yao, J. (2022). Characteristics, progress and trends of urban microclimate research: a systematic literature review and bibliometric analysis. *Buildings*, 12(7), 877.
3. Mirzaei, P. A. (2021). CFD modeling of micro and urban climates: Problems to be solved in the new decade. *Sustainable Cities and Society*, 69, 102839.
4. Toparlar, Y., Blocken, B., Maiheu, B., & van Heijst, G. J. F. (2017). A review on the CFD analysis of urban microclimate. *Renewable and Sustainable Energy Reviews*, 80, 1613-1640.
5. Mortezaazadeh, M., & Wang, L. L. (2020). Solving city and building microclimates by fast fluid dynamics with large timesteps and coarse meshes. *Building and Environment*, 179, 106955.
6. Torres, P., Le Clainche, S., & Vinuesa, R. (2021). On the experimental, numerical and data-driven methods to study urban flows. *Energies*, 14(5), 1310.
7. Kamrowska-Zańska, D. (2021). Impact of AI-based tools and urban big data analytics on the design and planning of cities. *Land*, 10(11), 1209.
8. Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2017). Physics informed deep learning (part i): Data-driven solutions of nonlinear partial differential equations. *arXiv preprint arXiv:1711.10561*.
9. Li, Z., Zheng, H., Kovachki, N., Jin, D., Chen, H., Liu, B., ... & Anandkumar, A. (2021). Physics-informed neural operator for learning partial differential equations. *arXiv preprint arXiv:2111.03794*.