3-A-4-양-10
국내학술발표

시뮬레이션에서 예측까지: 파라메트릭 도구인 Ladybug Tools와 Deep Learning을 기반으로 한 빌딩 성능 최적화 연구

- 한국CDE학회 2024 하계학술대회 -

2024.11.

과 제 명	인공지능 기반의 건축설계 자동화 기술개발		
주 관 기 관	경북대학교 산학협력단		
총 연 구 기 간	2021. 04 . 01 - 2025. 12 . 31(4년 9개월)		
해당연도(4차년)	2024. 01 . 01 - 2024. 12 . 31(1년)		
구 성 기 술 명	구성기술 3	설계 품질검토 자동화를 위한 지능형 설계서비스 보급·활용 기술개발	
세 부 과 제 명	3-A	지능형 설계적법성 평가 및 건축행정 서비스 지원 기술개발	
공 동 연 구 기 관	경희대학교 산학협력단, ㈜코스펙이노랩		
연 구 기 관	경희대학교 산학협력단	**연구책임자**	김인한

ISSN 2983-3760

CDE

한국CDE학회 2024 하계 학술대회

2024 Summer Conference of Society for Computational Design and Engineering

2024. 8. 21(수) ~ 23(금)

라마다프라자 제주호텔

생성형 AI로 열리는 CDE의 문 : 생성형 AI가 가져올 CDE 기술의 혁신

PROCEEDINGS

주최·주관 사단법인 한국CDE학회

공동주관 제주대학교

후원 제주지역혁신플랫폼

문의 한국CDE학회 사무국

Tel. 02-501-6862 Fax. 02-501-6863

Email. info@cde.or.kr URL. http://cde.or.kr

Program

	Time \ Room	Ballroom 1	Ballroom 2	Ballroom 3	Ballroom 4	Mara Hall	Udo Hall
21 (Wed)	10:00-11:50	등록					
	11:50-13:00	중식					한국CDE학회 리더십
	13:00-13:10	**Opening Session** (Ballroom 1)					
	13:10-14:00	**Keynote Speech I** (Ballroom 1) / **박준** (SK C&C)					
	14:00-14:10	휴식					
	14:10-15:30	**Session 1** VR/AR/XR/ Metaverse	**Session 2** 제조 디지털 트윈 워크샵 1	**Session 3** Ship & Ocean Engineering 1	**Session 4** Geometric Modeling & Graphics	**Session 5** PHM/Robot Applications	
		좌장: 김형중	좌장: 손지연	좌장: 민천홍	좌장: 신종호	좌장: 박광필	
	15:30-15:40	휴식					
	15:40-17:00	**Session 6** Ship & Ocean Engineering 2	**Session 7** 제조 디지털 트윈 워크샵 2	**Session 8** [기획] KAIST iCAD Reunion	**Session 9** 데이터 품질 평가와 개선	**Session 10** [기획] 이미지 형식 P&ID 내 설계 정보 추출 및 디지털 변환 시스템 개발	
		좌장: 우종훈	좌장: 이은서	좌장: 황호진	좌장: 이정원	좌장: 문두환	

	Time \ Room	Ballroom 1	Ballroom 2	Ballroom 3	Ballroom 4	Mara Hall	Udo Hall
22 (Thu)	08:30-09:30	등록					
	09:30-10:50	**Session 11** Ship & Ocean Engineering 3	**Session 12** [기획] 중견중소 조선소 Smart HSE 기술 적용	**Session 13** Ship & Ocean Engineering 4	**Session 14** Smart Manufacturing 1	**Session 15** Modeling & Simulation	
		좌장: 황세윤	좌장: 김환석	좌장: 김광식	좌장: 신종호	좌장: 강형석	
	10:50-11:00	휴식					
	11:00-12:20	**Session 16** BIM	**Session 17** CAD/CAM/CAE/ CFD	**Session 18** Ship & Ocean Engineering 5	**Session 19** Smart Manufacturing 2	**Session 20** IoT/AI Applications	
		좌장: 최중식	좌장: 권순조	좌장: 유원선	좌장: 김형기	좌장: 박승화	
	12:20-13:50	한국CDE학회 이사회	중식				
	13:50-14:40	**Keynote Speech II** (Ballroom 1) / **임채호** (한국생산기술연구원)					
	14:40-14:50	휴식					
	14:50-16:10	[14:50-17:00] Fast Forward Session*	**Session 21** [기획] XAI-DTw : 설명가능한 AI 기반 디지털트윈 자율운영 서비스 기술 개발 사례	**Session 22** 디지털 정밀 의료를 위한 의료 지능화 기술	**Session 23** [기획] 설계 품질검토 자동화를 위한 지능형 설계 서비스 보급·활용 기술개발	**Session 24** x-DT, 중소제조기업 맞춤형 디지털트윈 구축 및 운영 기술	우수논문상 선정 심사위원회 회의
			좌장: 유병현	좌장: 이득희	좌장: 최중식	좌장: 김덕영	
	16:10-17:00	좌장: 박광필	휴식				
	17:00-18:00	**포스터 세션**** (2F, 로비)					
	18:00-19:30	**만찬** (Ballroom)					

* Fast Forward Session: 1분 포스터 발표
** 포스터 세션: 포스터 심사

23 (Fri)	Time \ Room	Ballroom 1	Ballroom 2	Ballroom 3	Ballroom 4	Mara Hall	Udo Hall
	10:00-12:00	Panel Discussion					**연구윤리워크숍**

Session 16 BIM — 좌장: 최중식

S16-1	BIM 기반 데이터를 활용한 녹색건축 인증의 절성토량 최소화 평가 방법론 *[1]유은상, [2]황혜빈, [1]안용한, [#2]최중식 (한양대학교[1], 강원대학교[2])	138
S16-2	교량의 공간 온톨로지를 활용한 BIM 기반 부재 자동 조립 프레임워크 - 교각을 중심으로 - *차현우, [#]문현석 (과학기술연합대학원대학교)	140
S16-3	시뮬레이션에서 예측까지: 파라메트릭 도구인 Ladybug Tools와 Deep Learning을 기반으로 한 빌딩 성능 최적화 연구 *양우붕, 환경은, [#]김인한 (경희대학교)	145
S16-4	2D 지형 도면에 대한 3차원 형상 복원 방법 연구 *이노준, 한은진, [#]권기연 (금오공과대학교)	151

Session 17 CAD/CAM/CAE/CFD — 좌장: 권순조

S17-1	가공 부품에 대한 제작 오차 검사 방법 *정대진, 김상우, 공세연, [#]권기연 (금오공과대학교)	153
S17-2	점군 데이터 기반 대칭 부품 식별 방법 연구 *한은진, 정대진, [#]권기연 (금오공과대학교)	154
S17-3	열저항 네트워크와 집중질량의 상변화를 이용한 극저온 탱크의 증발 현상 해석과 실험 검증 *김민석A, 김민석B, 명인선, 윤재덕, [#]이장현 (인하대학교)	155
S17-4	로터세일의 실험 모형 제작을 위한 축소기법 *정주원, 박광필, [#]김선제 (충남대학교)	156

Session 18 Ship & Ocean Engineering 5 — 좌장: 유원선

S18-1	해군 함정의 교전급 피격성 평가를 위한 시뮬레이터 개발 *변건웅, 오승헌, 윤희창, 조기영, [#]우종훈 (서울대학교)	158
S18-2	강화학습 기반 조선소 트랜스포터의 동적 스케줄링 최적화 *한승우, 오승헌, [#]우종훈 (서울대학교)	159
S18-3	최적화 기법을 사용한 SI 엔진 연료 성층화의 대한 기초 연구 *손종윤, 이정우, 김기연, [#]박광필 (충남대학교)	160
S18-4	조선소 장기 계획 최적화 시스템 개발 *[1]최재호, [2]조기영, [#2]우종훈 (삼성중공업[1], 서울대학교[2])	164

시뮬레이션에서 예측까지: 파라메트릭 도구인 Ladybug Tools와 Deep Learning을 기반으로 한 빌딩 성능 최적화 연구

From simulation to prediction: Research on building performance optimization based on parametric tools Ladybug Tools and Deep Learning

*[1] 양우붕, [2] 환경은, [#1] 김인한
[1] 경희대학교 건축학과, [2] 경희대학교 건축학과
*[1]Yupeng Yang, [2]Kyungeun Hwang, and [#1]Inhan Kim
[1]Department of Architectrue, Kyung Hee University,
[2]Department of Architectrue, Kyung Hee University

ABSTRACT
Recently, deep learning technology has revolutionized building performance optimization design. Compared to traditional rule-based methods like Ladybug Tools, deep learning offers significant advantages in simulating building performance. This study introduces a novel approach that converts Ladybug Tools simulation results into graph structures suitable for Graph Neural Networks (GNNs). Representing the simulation mesh as a graph allows GNNs to capture complex data relationships. Additionally, Transformer models are proposed to process heterogeneous graphs, using their self-attention mechanism to focus on node relationships. This method enhances the model's ability to handle complex building geometries and irregular meshes, providing a foundation for future building performance prediction and optimization.

Key Words: building performance simulation, building performance prediction, ladybug tools, deep learning, GNNs, Transformer

1. 서론

건축 설계에서 시뮬레이션과 예측은 매우 중요하다. 기술이 발전함에 따라, 설계자들은 다양한 환경 조건에서 건물 성능을 예측하고 설계 방안을 최적화하기 위해 정교한 도구와 방법에 점점 더 의존하게 되었다. 건물 성능 시뮬레이션은 설계 초기 단계에서 잠재적인 문제를 예측하고 개선을 위한 과학적 권장 사항을 제공할 수 있게 한다. 에너지 소비, 일조량, 열적 쾌적성 등의 매개변수를 시뮬레이션함으로써, 설계자는 높은 에너지 효율과 향상된 생활 쾌적성을 위한 최적의 설계를 선택할 수 있다.

Ladybug Tools 는 Grasshopper 환경에 통합된 오픈 소스 플러그인 모음으로 강력한 환경 시뮬레이션 기능 덕분에 건물 성능 분석에 필수적이다. 설계자가 다양한 기후 조건에서 에너지 소비, 일조량, 쾌적성을 시뮬레이션할 수 있도록 도와주며, 설계 결정에 대한 과학적 지원을 제공한다. 또한, Ladybug Tools 는 복잡한 환경 데이터를 직관적으로 이해하고 보다 정보에 입각한 설계 결정을 내릴 수 있도록 사용자 친화적인 시각화 도구를 제공한다[1][15][12][2].

딥러닝 기술의 등장으로 건축 설계 분야가 혁신적으로 변하고 있다. 인간의 뇌 신경망의 작동을 모방하여, 딥러닝은 방대한 데이터 집합에서 가치 있는 정보를 자동으로 학습하고 추출할 수 있으며, 건축 설계에서 최적화 문제에 대한 혁신적인 해결책을 제공한다. Ladybug Tools 와 딥러닝 기술의 통합은 건축 설계의 과학적 정확성과 정밀성을 높이는 동시에, 이 분야의 혁신과 발전을 촉진한다. 전통적인 시뮬레이션 방법은 높은 계산 비용과 긴 처리 시간이 필요하다. 반면, 딥러닝 기술은 자동화된 데이터 처리 및 패턴 인식을 통해 시뮬레이션 및 예측 효율성을 크게 향상시킨다. 이러한 결합 응용 모델은 건축 설계의 연구 핫스팟이자 최첨단 기술로 부상하고 있다. 딥러닝 모델은 다양한 설계 매개변수 하에서 건물 성능을 신속하게 예측할 수 있어 설계 반복 횟수와 소요 시간을 크게 줄일 수 있다[5].

본 연구의 핵심 목적은 건축 설계 과정에서 Ladybug Tools 와 딥러닝의 통합을 탐구하여 설계 효율성과 품질을 향상시키는 것이다. 본 연구는 Ladybug Tools 의 시뮬레이션 결과를 딥러닝 모델에 적합한 그래프 구조로 변환하는 새로운 방법을 제안한다. 메쉬 데이터를 그래프 표현으로 변환하여, 그래프 신경망(Graph Neural Networks, GNNs)와 Transformer 모델의 기능을 활용해 건축 설계에서 복잡한 기하학적 구조와 불규칙한 메쉬를 보다 효과적으로 처리하고자 한다. 이러한 이론적 프레임워크는 향후 지능형 예측 모델 개발의 기초를 마련한다.

본 연구는 Ladybug Tools 를 사용하여 초기 건물 성능 시뮬레이션을 수행하는 방법과 시뮬레이션 결과와 시각화 메쉬 간의 관계를 이론적으로 분석한다. 나아가 이러한 시뮬레이션 결과를 전통적인 이미지나 행렬 형식이 아닌 기본적인 딥러닝 응용에 적합한 그래프 구조로 변환하는 방법을 탐구한다. 본 연구는 GNNs 와 Transformer 모델을 간단히 통합하여 건물 성능 데이터를 보다 효과적으로 표현하는 방법을 제안하며, 향후 건축 최적화 방법론에 대한 이론적 기초를 제공한다.

2. 건물 성능 최적화 설계에서 Ladybug Tools 의 응용

2.1 Ladybug Tools 소개

Ladybug Tools 는 Grasshopper 와 Rhino 환경에 통합

*발표자(yupeng@khu.ac.kr), #교신저자(ihkim@khu.ac.kr)

된 오픈 소스 플러그인 모음으로, 건축 설계자와 환경 엔지니어가 환경 분석 및 건물 성능 시뮬레이션을 수행할 수 있도록 설계되었다. 이 모음은 강력한 환경 데이터 분석 기능과 높은 사용자 맞춤화 기능으로 유명하다. Ladybug, Honeybee, Butterfly, Dragonfly 등 여러 구성 요소로 이루어져 있으며, 각각 특정 기능과 응용을 위해 설계된다.

Ladybug 는 기상 데이터를 가져와 시각화하여 초기 환경 평가를 수행할 수 있다. Honeybee 는 EnergyPlus 와 Radiance 같은 시뮬레이션 엔진과 통합하여 에너지 소비 및 조명 시뮬레이션을 수행할 수 있다. Butterfly 는 OpenFOAM 엔진을 사용하여 CFD(유체역학) 시뮬레이션을 수행한다. Dragonfly 는 도시 규모의 환경 모델링을 위해 설계되었다. 이 모음은 고급 시뮬레이션 기술을 활용하여 포괄적인 환경 분석을 제공한다[15].

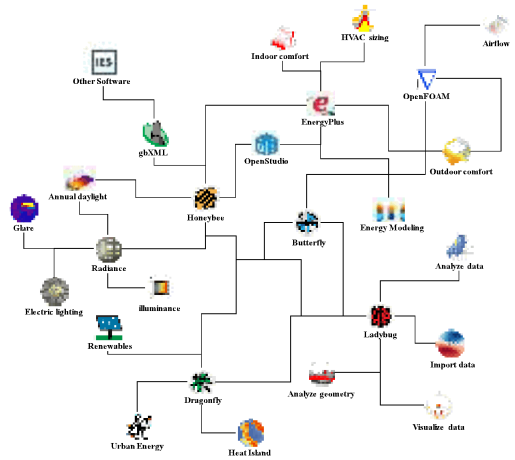


Fig. 1 Ladybug Tools (source: Ladybug Tools Home Page)

예를 들어, Ladybug 는 EPW(EnergyPlus Weather) 데이터 파일을 가져와 태양 복사량 및 바람 장미 차트와 같은 시각화를 생성하여 설계자가 프로젝트 사이트의 기후 조건을 이해하는 데 도움을 준다. Honeybee 는 건물 에너지 소비를 시뮬레이션하고 일조량 분석을 수행할 수 있다. Butterfly 는 OpenFOAM 엔진을 사용하여 공기 흐름을 모델링하고 자연 환기 설계를 최적화한다. Dragonfly 는 도시 열섬 효과 및 도시 규모의 에너지 소비를 평가하는 데 도움을 준다. 이 통합된 모음을 통해 설계자는 정밀하고 광범위한 시뮬레이션을 수행하여 건물 및 도시 설계를 향상시키고 보다 지속 가능하고 효율적인 환경을 조성할 수 있다.

2.2 건축 설계에서 Ladybug Tools 의 실용적인 응용

Ladybug Tools 는 고급 시뮬레이션 기술을 통해 설계자에게 정확한 데이터 지원을 제공하여 건축 설계에서 중요한 역할을 한다. 개략 설계 단계에서는 Ladybug Tools 가 초기 환경 성능 평가를 수행하는 데 도움을 준다. 다양한 설계 방안의 에너지 소비, 일조량, 환기 성능을 시뮬레이션하여 설계자가 최적의 설계를 도출할 수 있도록 안내한다[12]. 설계 개발 단계에서도 Ladybug Tools 는 상세한 시뮬레이션 분석을 제공하여 최종 설계가 환경 성능 요구사항을 충족하도록 정확한 성능 데이터와 최적화 제안을 제공한다[1].

Ladybug Tools 의 실용적 잠재력은 수많은 실제 프로젝트에서 입증되었다. 표 1 은 구체적인 실용적 응용 사례 몇 가지를 강조한다.

Table 1 Case Studies of Ladybug Tools in Practical Applications

사례 이름	사례 유형	설명
Amazon in the Regrade, Sphere	상업용 건물	에너지 및 일조 분석을 위해 Ladybug 와 Honeybee 를 사용하여 건물의 조명 및 에너지 효율성을 최적화
샌프란시스코 국제공항 확장 계획	대규모 건설	Honeybee 와 클라우드 컴퓨팅을 사용한 대규모 일조 분석[9]
아이오와 대학교 심리 및 뇌과학 건물 외관 연구	연구 프로젝트	복잡한 기하학적 구조 분석을 위해 Ladybug 사용

3. 건물 성능 최적화 설계에서 Ladybug Tools 와 딥러닝 모델의 응용

최근 몇 년간 딥러닝 기술은 건축 설계 분야를 혁신적으로 변화시켰다. 기계 학습의 고급 하위 분야인 딥러닝은 데이터 내의 복잡한 패턴과 고유한 관계를 포착할 수 있는 다층 신경망 모델을 구축한다[10]. 이 접근 방식은 Ladybug Tools 에서 사용하는 전통적인 규칙 기반 방법에 비해 건물 성능을 시뮬레이션하는 데 있어 상당한 이점을 제공한다[3]. Ladybug Tools 는 성능 시뮬레이션을 위해 사전 정의된 규칙에 의존하는 반면, 딥러닝 방법은 데이터 기반 접근 방식을 활용하여 복잡한 데이터 집합에서 주요 특징을 자동으로 추출할 수 있다. 이 기능은 건축 설계에서 예측 및 생성 작업의 정확성과 효율성을 향상시켜 딥러닝을 건물 성능 최적화에 강력한 도구로 만든다.

3.1 딥러닝 모델 개요

3.1.1 컨볼루션 신경망

컨볼루션 신경망(Convolutional Neural Networks, CNNs)은 이미지 인식 및 처리에서 탁월한 성능을 발휘하는 딥러닝 모델로 잘 알려져 있다. 이들 모델은 특히 이미지와 같은 격자형 토폴로지를 가진 데이터 구조를 처리하도록 설계되었다. CNNs 의 핵심 구성 요소는 컨볼루션 층, 풀링 층, 완전 연결 층으로 구성된다. 컨볼루션 층은 국소 수용 필드를 통해 이미지에서 공간적 특징을 추출하여 가장자리, 질감, 형태와 같은 패턴을 감지한다. 풀링 층은 특징 맵 패치에서 특징의 존재를 요약하여 계산 복잡성과 매개변수 수를 줄인다. 마지막으로, 완전 연결 층은 고수준의 추상적 특징을 최종 출력으로 변환한다.

CNNs 은 의료 이미지 분석, 자율 주행, 얼굴 인식 등 다양한 분야에서 성공적으로 적용되어 시각 데이터를 처리하는 데 있어 그 다재다능성과 효과를 입증하고 있다[14].

3.1.2 생성적 적대 신경망

생성적 적대 신경망(Generative Adversarial Networks , GANs)은 2014 년 Goodfellow 등에 의해 도입된 두 개의 신경망, 즉 생성자와 판별자로 구성된다. 생성자는 현실적인 데이터 샘플을 생성하는 데 목표를 두고, 판별자는 진짜 데이터와 합성 데이터를 구별하는 역할을 한다. 적대적 훈련 동안 생성기와 판별기는 서로 경쟁하여 생성 샘플의 품질을 지속적으로 개선한다[4].

GANs 은 이미지 생성, 초해상도, 이미지 복원, 데이터 증강 등 다양한 분야에서 광범위하게 사용되고 있다. 이미지 생성에서의 성공은 주로 생성자 내부에서 사용되는 CNNs 덕분이며, 이들은 여러 컨볼루션 층을 통해 이미지의 해상도와 세부 사항을 점진적으로 개선한다. 동시에, 판별자도 컨볼루션 층을 사용하여 실제 이미지와 생성된 이미지를 효과적으로 구별한다. GANs 의 응용 예로는 저해상도 입력에서 고해상도 이미지 생성, 손상된 이미지 복원, 기계 학습에서 훈련 데이터 집합을 증강하기 위한 합성 데이터 생성 등이 있다[7].

3.1.2 그래프 신경망

고정된 격자 구조를 처리하는 데 능한 CNNs 과 달리, 그래프 구조 데이터는 더 큰 불규칙성을 나타냅니다. 일반적으로 노드와 엣지로 구성된 그래프 데이터는 노드 수와 상호 연결이 동적으로 변한다.

이 네트워크는 메시지 전달 메커니즘을 통해 계산을 수행하며, 노드 특징을 이웃 노드의 정보를 사용해 반복적으로 집계하고 업데이트한다. 이 과정에서 각 노드는 메시지를 이웃에게 보내고, 이웃으로부터 메시지를 받음으로써 로컬 그래프 구조를 효과적으로 캡처한다. 업데이트된 노드 특징은 종합적인 노드 표현을 학습하는 데 사용됩니다. GNNs 의 강점은 노드 간의 복잡한 종속성을 포착하는 능력으로, 이를 통해 사회 네트워크 분석, 분자 그래프 분류, 건축 설계 최적화와 같은 복잡한 관계 데이터를 처리하는 데 매우 효과적이다[17].

3.1.3 그래프 컨볼루션 네트워크

그래프 컨볼루션 네트워크(Graph Convolutional Networks, GCNs)는 그래프 구조 데이터를 대상으로 컨볼루션 작업을 수행하는 그 GNNs 의 중요한 변형이다. GCNs 의 기본 원리는 그래프 컨볼루션을 통해 이웃 노드의 특징을 집계하여 노드 표현을 반복적으로 업데이트하는 것이다. 이 과정은 그래프에서 로컬 패턴과 글로벌 구조를 모두 효과적으로 캡처하는 일종의 로컬 필터링으로 볼 수 있다. 여러 컨볼루션 층을 쌓아 올림으로써, GCNs 은 그래프의 점점 더 추상적인 표현을 학습할 수 있어, 건축 설계에서 노드 분류, 링크 예측 및 그래프 분류와 같은 작업에 적합하다[8].

3.1.4 Transformer

이미지 데이터의 구조화된 격자 및 그래프 데이터의 불규칙한 연결과 달리, 순차 데이터는 순서 및 시간적 종속성을 강조한다. 건물 최적화 설계에서는 순차 데이터가 건물 환경의 시간에 따른 조건을 나타낼 수 있다. Self-Attention 에 기반한 Transformer 모델은 입력 시퀀스 내의 다양한 위치 간의 종속성을 포착한다. 이 딥러닝 아키텍처는 시퀀스 요소 간의 상관관계를 평가하여 주의 가중치를 계산하고, 그 요소들 간의 가중 평균을 통해 주의 메커니즘을 활용한다. 여러 층의 주의 메커니즘과 피드포워드 신경망을 쌓아 올림으로써, Transformer 는 복잡한 시퀀스 데이터를 처리할 수 있는 강력한 딥 모델을 구축한다[16]. 이 능력은 건축 설계에서 동적 환경 조건을 모델링하고 예측하며, 시간에 따른 건물 성능을 최적화하는 데 특히 유리하다.

3.2 건축 최적화 설계에서 Ladybug Tools 와 딥러닝 모델에 관한 관련 연구

인공지능의 발전으로, 점점 더 많은 연구자들이 전통적인 규칙 기반 분석 방법을 대체할 프록시 모델

Table 2 Related literature on environmental prediction based on Deep Learning

문헌	분야	딥러닝 모델	입력	출력
Huang 등[6]	종합 분석	GANs	매개변수화된 도시 블록 인코딩	보행자 레벨 바람(PLW), 태양 복사(Radiation), 보편적 열적 쾌적성 지수(UTCI)
Hou 등[5]	일조 분석	Attention 층을 가진 GANs	2D 이미지	블록 플랜 컬러링(BPC), 문제 건물 표시 (PBM)
Zhong 등[18]	실외 열적 쾌적성	CNNs	형상을 나타내는 행렬	UTCI 행렬
Lu 등[11]	일조 시뮬레이션	GANs	펼쳐진 파사드 이미지	DA 및 TA 시뮬레이션 이미지

을 개발하여 건축 설계 솔루션을 예측하고 최적화하고 있다. 주거 블록의 일조 분석을 예측하기 위해 GANs 과 같은 프록시 모델이 사용되었다[5]. 표 2 는 이 분야의 관련 연구 몇 가지 예를 제공한다.

연구는 건물 환경 성능 분석에서 딥러닝 모델의 상당한 잠재력과 다양한 응용 가능성을 나타낸다. 예를 들어, GANs 및 기타 딥러닝 기술은 에너지 소비 예측, 일조 분석, 공기 질 시뮬레이션 등에 성공적으로 적용되었다. 그러나 많은 기존 연구는 입력과 출력 모두에 대해 규칙적으로 격자화된 데이터를 사용한다. 이 접근 방식은 예측 및 최적화 정확도를 어느 정도 개선했지만, 건축 설계에서 복잡한 기하학적 형상 및 불규칙한 메쉬를 다룰 때는 인코딩 프로세스를 필요로 하며, 이는 정보의 손실이나 왜곡을 초래할 수 있어 모델의 정확도 및 일반화 가능성에 영향을 미친다.

4. 메쉬-그래프 변환 및 딥러닝 기법을 사용한 건물 성능 예측에 대한 새로운 접근법

이 연구는 건축 설계에서 복잡한 기하학적 형상 및 불규칙한 메쉬를 효과적으로 처리하기 위해 GNN 및 Transformer 모델의 강점을 활용하여 건물 성능 예측을 위한 새로운 이론적 프레임워크를 제안한다. 시뮬레이션 결과 격자를 GCN 에 적합한 그래프 구조로 변환하고, 이종 그래프 데이터를 처리하기 위해 Transformer 모델을 활용함으로써, 이 방법은 모델의 복잡한 기하학적 형상 및 불규칙한 메쉬를 처리하는 능력을 향상시킨다.

4.1 메쉬의 그래프 표현

Ladybug Tools 는 일반적으로 다면체 객체의 기하학을 개략하는 다각형 및 정점으로 구성된 메쉬로 시각화 결과를 표시한다.

Rhino 에서는 메쉬가 정점(Vertices), 엣지(Edge), 면(Face)으로 구성된다. 정점은 메쉬의 형태와 크기를 정의하는 기본 요소이다. 엣지는 정점을 연결하여 메쉬의 윤곽과 경계를 형성한다. 면은 일반적으로 삼각형 또는 사각형으로 구성된 정점 및 엣지로 이루어져 있으며, 메쉬의 외관을 정의한다. 각 면은 조명 및 렌더링 효과에 영향을 미치는 3 차원 공간에서의 방향을 결정하는 법선(Normals)을 가지고 있다. 올바른 정점 순서는 잘못된 표면 방향을 방지하여 올바른 면의 법선을 보장한다. 텍스처 좌표 및 색상 정보도 정점 또는 면에 부착될 수 있으며, 텍스처 매핑 및 음영을 위한 것이다.

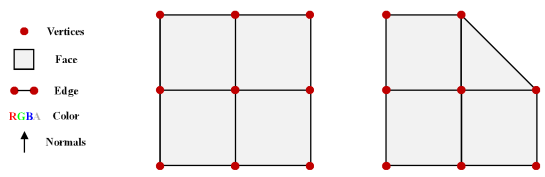


Fig. 2 Meshes in Rhino

시뮬레이션 메쉬는 모델링된 객체의 기하학에 따라 가변 해상도를 제공하여 불규칙성을 가지고 있다[13]. 이 불규칙성은 CNNs 과 같은 모델에 어려움을 주어, 대부분의 연구는 행렬 또는 이미지와 같은 규칙적인 격자 구조를 사용한다.

Ladybug Tools 는 이러한 메쉬에 시뮬레이션 결과를 투영하여 각 셀에 대한 단위 면적당 태양 복사량과 같은 성능 지표 값을 할당한다. 자세한 시각화를 위해 이러한 결과를 메쉬의 정점에 보간해야 한다. 보간 기술은 각 셀의 값을 해당 노드에 분포시켜 각 정점이 성능 지표 값을 가지게 한다. 이러한 노드 값을 그라디언트 매핑을 통해 색상 값으로 변환하여 직관적인 시각화를 제공한다. 딥러닝 모델의 입력으로 메쉬 데이터를 사용할 때 메쉬 데이터와 그래프 구조 간의 대응을 확립하는 것이 필수적이다. 그래프 데이터는 노드와 엣지로 구성된다. 각 노드를 메쉬의 정점으로 보고, 각 엣지를 이러한 정점을 연결하는 경계로 보는 것이 건물 성능 예측에 중요하다.

본 연구는 Ladybug Tools 의 시뮬레이션 결과를 그래프 데이터로 변환하는 새로운 방법을 제시한다. GNNs 와 같은 딥러닝 기법을 적용하여 복잡한 기하학적 형상 및 불규칙한 메쉬를 처리하는 능력을 크게 향상시킨다. 이 방법은 보다 효율적이고 정확한 건물 성능 예측을 달성하는 것을 목표로 한다. 자세한 방법론은 아래에 설명되어 있다. 메쉬 $M = (V, E, F)$에서 V는 정점 집합, E는 엣지 집합, F는 면 집합인 그래프 $G = (V, E)$로의 변환은 다음 단계로 구성된다.

Table 3 Method for converting simulated meshes to graph

단계	설명
정점 수집	메쉬의 모든 정점을 수집한다. 각 정점 $v_i \in V$ 는 그래프의 노드가 되어 좌표 및 법선 벡터와 같은 기하학적 정보를 유지한다. 노드는 또한 성능 메트릭을 저장할 수 있다.
엣지 수집	메쉬에서 연결된 정점 쌍 간의 엣지를 정의한다. 이러한 엣지 $(v_i, v_j) \in E$는 그래프의 연결을 형성한다. 엣지는 정점 간의 관련 정보를 가질 수 있다.
면 수집	정점 및 엣지로 구성된 면을 정의한다. 그래프의 방향성을 유지하기 위해 각 면의 정점 순서를 지정해야 한다.
법선 벡터	각 면의 법선 벡터를 계산하고 부착한다.
텍스처 좌표 및 색상	선택적으로 텍스처 좌표 및 색상 정보를 정점 또는 면에 부착한다.

속성 부착	각 노드 및 엣지에 추가 속성을 부착한다. 노드는 기하학적 속성(예: 좌표, 법선 벡터) 및 시뮬레이션 결과 데이터(예: 태양 복사)를 가질 수 있다. 엣지는 가중치 또는 기타 속성을 가질 수 있다.
인접 행렬 구성	노드 간의 연결을 나타내는 그래프의 인접 행렬 또는 인접 목록을 구성한다. 이 구조는 그래프 신경망 처리에 필수적이다.

그래프 G의 인접 행렬 A는 다음과 같이 정의될 수 있다.

$$A_{i,j} = \begin{cases} 1, \text{if } (v_i, v_j) \in E \text{ and edge } (v_i, v_j) \text{ respects the vertex order of face} \\ 0 \end{cases}$$

시뮬레이션 메쉬 데이터를 그래프 기반 형식으로 재구성함으로써, 중요한 기하학적 및 위상 세부 사항을 유지하면서 GNNs 및 유사 딥러닝 방법론을 배포할 수 있다. GNNs 은 노드 및 엣지 특징 추출에 능숙하여 복잡한 기하학적 구성 및 비표준 메쉬를 처리하는 데 능하다. 이 기능은 건물 성능 예측의 정확도와 효율성을 크게 향상시킬 수 있다.

3.2 Transformers 와 이종 그래프

시뮬레이션 메쉬를 처리하는 것은 이종 그래프 데이터를 처리하는 것을 포함하며, 이는 노드 수와 특징이 다양하기 때문에 어려움을 겪다. 전통적인 GNNs 및 GCNs 은 고정 구조 그래프 데이터를 처리하는 데 능숙하지만, 이종 그래프 데이터의 복잡성과 다양성에 어려움을 겪을 수 있다. 이를 해결하기 위해 Transformer 모델이 효과적이다. 이는 가변 길이 시퀀스 데이터를 유연하게 처리하여, 고정된 노드 수나 특징 차원에 의존하지 않고 노드 간의 관계를 캡처한다. Self-Attention 메커니즘을 통해 Transformer 는 노드 간의 관계에 동적으로 초점을 맞추어 그래프 내의 복잡한 종속성을 효과적으로 포착한다.

이를 해결하기 위해 Transformer 모델은 변동 길이 시퀀스 데이터를 유연하게 처리하여, 고정된 노드 수나 특징 차원에 의존하지 않고 노드 간의 관계를 캡처하는 데 뛰어난다. Self-Attention 메커니즘은 Transformer 가 노드 간의 관계에 동적으로 초점을 맞추어 그래프 내의 복잡한 종속성을 효과적으로 포착할 수 있게 한다.

Transformer 의 Self-Attention 메커니즘은 그래프의 다양한 노드 간의 관계에 동적으로 초점을 맞추어 복잡한 종속성을 포착할 수 있게 한다. Transformer 는 고정 구조 입력 데이터를 필요로 하지 않으며, 이종 그래프 데이터를 처리하는 데 매우 적합하다. 또한 다양한 노드의 특징을 적응적으로 처리할 수 있어, 모델이 복잡하고 다양한 시뮬레이션 설계 시나리오에 유연하게 대처할 수 있게 한다.

더욱이, Transformer 모델을 다른 딥러닝 기법과 통합하면 이종 그래프 데이터를 처리하는 능력을 크게 향상시키고, 건축 설계의 다양한 과제를 해결할 수 있다. 이 하이브리드 접근 방식은 복잡한 설계 시나리오를 관리하는 유연성을 높일 뿐만 아니라, 전통적인 컨볼루션 방법보다 모델 예측 정확도를 향상시킨다.

5. 결론

본 연구에서는 Ladybug Tools 와 딥러닝 모델을 통합한 새로운 이론적 프레임워크를 제안했다. Ladybug Tools 의 시뮬레이션 결과를 그래프 구조로 변환하여 GNNs 및 Transformer 모델의 기능을 활용함으로써 복잡한 기하학적 형상 및 불규칙한 메쉬를 보다 효과적으로 처리할 수 있음을 확인했다.

본 연구는 Ladybug Tools 와 같은 전통적인 규칙 기반 시뮬레이션 방법이 유용하지만, 복잡하고 비표준 데이터 처리에 한계가 있음을 시사한다. GNNs 의 도입은 그래프 구조 데이터 내의 복잡한 관계 및 종속성을 추출할 수 있어 건물 성능 예측의 정확성을 향상시킨다. 또한, Transformer 모델의 이종 그래프 데이터를 관리하는 유연성과 다양한 노드 간의 관계에 초점을 맞추는 능력은 모델의 견고성과 예측력을 향상시킨다.

제안된 프레임워크는 건축 최적화 분야의 미래 연구 및 개발을 위한 기초를 마련한다. 딥러닝 기법을 활용함으로써 전통적인 시뮬레이션 방법과 관련된 계산 비용 및 시간을 크게 줄일 수 있어 설계 과정을 가속화할 수 있다. 이 통합은 더 지능적이고 적응력 있는 설계 솔루션을 가능하게 하여 궁극적으로 더 효율적이고 지속 가능한 건축물을 창조하는 데 기여한다.

이 접근법의 성공은 고급 기계 학습 모델과 전통적인 시뮬레이션 도구의 결합 가능성을 강조한다. 향후 연구는 이 프레임워크의 실제 구현 및 실제 건축 프로젝트에서의 응용 탐색에 중점을 둘 것이다. 이러한 방법을 계속 개선함으로써 스마트 건축 기술 및 건축 설계 분야의 발전에 기여하고자 한다.

감사의 글

본 연구는 국토교통부/국토교통과학기술진흥원의 2024 년도 지원으로 수행되었다.(과제번호: RS-2021-KA163269)

참고문헌

1. Crawley, D.B., Lawrie, L.K., Pedersen, C.O., Winkelmann, F.C., Witte, M.J., Strand, R.K., Liesen, R.J., Buhl, W.F., Huang, Y.J., Henninger, R.H., Glazer, J., Fisher, D.E., Shirley, D.B., Griffith, B.T., Ellis, P.G., & Gu, L., 2004, EnergyPlus: An Update, *Proceedings of the 10th International Building Performance Simulation Association*

Conference, Boulder, Colorado, USA, pp. 381-388
2. Fang, Y., 2017, Optimization of Daylighting and Energy Performance Using Parametric Design, Simulation Modeling, and Genetic Algorithms, *A dissertation submitted to the Graduate Faculty of North Carolina Stfate University*, pp.1-150
3. Gao, Y., Ruan, Y., Fang, C., & Yin, S., 2020, Deep learning and transfer learning models of energy consumption forecasting for a building with poor information data, *Energy and Buildings*, 223, 110156
4. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y., 2014, Generative Adversarial Nets, *Advances in Neural Information Processing Systems*, 27, pp. 2672-2680
5. Hou, D., 2024, Conditional Generative Adversarial Networks for Image-Based Sunlight Analysis of Residential Blocks, *Energy and Buildings*, 316, 114295.
6. Huang, C., Zhang, G., Yao, J., Wang, X., Calautit, J.K., Zhao, C., An, N., & Peng, X., 2022, Accelerated Environmental Performance-Driven Urban Design with Generative Adversarial Network, *Building and Environment*, 224, 109575
7. Isola, P., Zhu, J.Y., Zhou, T., Efros, A.A., 2017, Image-to-Image Translation with Conditional Adversarial Networks, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.1125-1134
8. Kipf, T. N., & Welling, M., 2017, Semi-Supervised Classification with Graph Convolutional Networks, *International Conference on Learning Representations*.
9. Kyropoulou, M., Ferrer, P., & Subramaniam, S., 2018, Optimization of Intensive Daylight Simulations: A Cloud-based Methodology using HPC (High Performance Computing), *PLEA 2018 HONG KONG Smart and Healthy within the 2-degree Limit*
10. LeCun, Y., Bengio, Y., Hinton, G., 2015, Deep learning, *Nature*, 521(7553), pp.436-444
11. Lu, Y., Wu, W., Geng, X., Liu, Y., Zheng, H., & Hou, M., 2022, Multi-objective optimization of building environmental performance: An integrated parametric design method based on machine learning approaches, *Energies*, 15(19), 7031.
12. Mackey, C., & Sadeghipour Roudsari, M., 2017, The Tool(s) vs. The Toolkit, *Proceedings of the Design Modeling Symposium*, Paris, France, pp.18-20.
13. Pfaff, T., Fortunato, M., Sanchez-Gonzalez, A., 2020, & Battaglia, P. W., Learning mesh-based simulation with graph networks. *arXiv preprint arXiv*:2010.03409.
14. Rawat, W., Wang, Z., 2017, Deep convolutional neural networks for image classification: a comprehensive review, Neural Computation, 29(9), pp.2352-2449
15. Sadeghipour Roudsari, M., & Pak, M., 2013, Ladybug: A Parametric Environmental Plugin for Grasshopper to Help Designers Create an Environmentally-Conscious Design, *Proceedings of the 13th International Conference of Building Performance Simulation Association*, Chambery, France, pp.3128-3135
16. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I., 2017, Attention is All You Need, *Advances in Neural Information Processing Systems,* 30, pp. 5998-6008
17. Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., Yu, P.S., 2020, A Comprehensive Survey on Graph Neural Networks, *IEEE Transactions on Neural Networks and Learning Systems,* 32(1), pp. 4-24
18. Zhong, G, 2022 Convolutional Neural Network Model to Predict Outdoor Comfort UTCI Microclimate Map *Atmosphere,* 13.11, 1860.