

생성형 AI 기반 지반구조물 설계를 위한 기초연구

정기과제 2025-062호

생성형 AI 기반 지반구조물 설계를 위한 기초연구

지은이	심영중, 박종배, 박용부, 박인건
발행인	정창무
발행처	한국토지주택공사 토지주택연구원
주 소	(34047) 대전 유성구 엑스포로 539번길 99
홈페이지	http://lhri.lh.or.kr
전화번호	042-866-8426

이 출판물은 우리 공사의 업무상 필요에 의하여 연구·검토한 기초자료로서 공사나 정부의 공식적인 견해와 관계가 없습니다.

우리 공사의 승인 없이 연구내용의 일부 또는 전부를 다른 목적으로 이용할 수 없습니다.

정기과제 2025-062

생성형 AI 기반 지반구조물 설계를 위한 기초연구

Fundamental Research for Generative AI-based Geo-structure Design

심영종·박종배·박용부·박인건

LH토지주택연구원

참여연구진

연구책임

심영중 LH 토지주택연구원 팀장

연구진

박종배 LH 토지주택연구원 선임연구위원

박용부 LH 토지주택연구원 연구위원

박인건 LH 토지주택연구원 연구원

연구심의위원

전주영 LH 토지주택연구원 실장(심의위원장)

강인규 브니엘건설턴트 대표 강인규

윤형구 대전대학교 교수

박찬교 LH 세종특별본부 소장

이영호 LH 스마트단지기술처 차장

정종석 LH 토지주택연구원 연구위원

자문위원(가나다순)

윤태섭 연세대학교 교수

임해식 서영엔지니어링 부사장

장일한 아주대학교 교수

■ 설계 패러다임 전환의 필요성

- 현행 지반구조물 설계는 설계자의 경험과 반복 해석에 크게 의존해 비효율적이며, 다양한 대안 탐색에 구조적 한계가 존재함.
- 기존 판별형 AI는 안전을 예측·기준 만족 여부 판별 등 ‘평가·진단’에는 활용될 수 있었으나, 새로운 설계안을 직접 ‘생성’하지 못하는 근본적 제약이 있어 설계 자동화 패러다임 전환이 요구됨.

■ 생성형 AI의 이론적 배경 및 핵심 원리 분석

- 본 연구는 생성형 AI의 핵심 개념인 잠재공간(latent space)과 이를 구현하는 VAE, GAN, Diffusion 등 대표 모델의 구조·학습 메커니즘을 체계적으로 정리함.
- 이를 통해 생성형 AI가 기존 분석·예측 중심 접근을 넘어, 조건 기반의 다양한 설계안을 ‘탐색·생성’하는 기술적 기반을 갖추고 있음을 제시함.

■ 공학 설계 연구 동향 분석 및 핵심 전략 도출

- 최신 생성형 설계 연구를 이미지, 텍스트, 파라메트릭 기반 접근으로 구분해 비교 분석하고, 각 접근법의 장단점과 지반설계 적용성을 검토함.
- 지반 설계는 지반정수·개수·길이·간격 등 수치 변수 조합을 통해 목표 안전율(FS)을 만족하는 단면을 찾는 전형적 파라메트릭 문제이므로, 데이터 구조·성능 제어 측면에서 파라메트릭 기반 생성형 AI가 가장 직접적·효율적임을 도출함.

■ 파일럿 연구를 통한 표준 방법론(CVAE)의 가능성 및 한계 규명

- 파라메트릭 기반 접근법의 실효성을 검증하기 위해, 조건부 변이형 오토인코더(CVAE)를 사면 네일 보강 설계 문제에 적용한 파일럿 연구를 수행함.
- 파괴거동이 비교적 일관된 사면 조건에서는 생성된 설계안의 실제 FS가 목표 FS 주변에 안정적으로 분포하는 등 설계 생성 가능성을 확인함.
- 반면 상부 연약·하부 강성의 2층 사면과 같이 파괴 모드가 급변하는 조건에서는 얇은

파괴↔깊은 파괴가 전환되는 ‘모드 점핑(mode jumping)’ 현상이 발생하였고, 이로 인한 불연속성 때문에 CVAE·MLP 기반 연속 모델은 충분한 성능 제어에 한계를 보임.

■ 차세대 프레임워크 및 향후 연구 로드맵 제시

- 파일럿 연구를 통해 확인된 불연속적 파괴거동 문제를 극복하기 위해, 다중 모드 학습에 강점을 가진 확산 모델(Diffusion Model) 기반 생성 프레임워크를 도입·검증하는 것을 최우선 연구 과제로 제시함.
- 중장기적으로는 검증된 파라메트릭 생성·검증 체계를 옹벽·기초 등 타 지반구조물로 확장하고, 이미지·텍스트 기반 기술과의 융합을 통해 실무적 활용성을 강화하는 지능형 지반설계 생태계 구축을 목표로 함.

주제어

생성형 AI, 지반구조물, 설계자동화, 파라메트릭 설계, 사면 보강, CVAE

차례 Contents

제1장 서론

1. 연구 배경 및 목적	1
1. 1. 연구배경	1
1. 2. 연구목적	3
2. 연구범위 및 방법	3
2. 1. 연구범위	3
2. 2. 연구방법	4

제2장 이론적 배경: 생성형 AI

1. 개요	5
1. 1. 인공지능 기술의 발전과 생성형 AI의 등장	5
1. 2. 생성형 AI와 판별형 AI의 차이	7
2. 생성형 AI의 핵심 원리	9
2. 1. 잠재 공간(Latent Space): 데이터의 압축과 표현	9
2. 2. 딥러닝 기반 패턴 학습: 잠재공간의 구현	10
3. 대표적인 생성형 AI 모델	11

제3장 설계자동화를 위한 생성형 AI 적용 현황

1. 개요	19
2. 이미지 데이터 기반	21
2. 1. 주요 연구 사례 분석: 철근콘크리트 전단벽 설계	22
2. 2. 이미지 데이터 기반 접근법 종합 및 지반공학 적용 가능성	27
3. 파라메트릭 데이터 기반	29
3. 1. 주요 연구 사례 분석: 성능 기반 역설계	30
3. 2. 파라메트릭 데이터 접근법 종합 및 지반공학 적용 가능성	33

4. 텍스트 데이터 기반	35
4. 1. 주요 연구 사례 분석: BIM 상세설계 및 건설안전정보 생성	36
4. 2. 텍스트 기반 접근법 종합 및 지반공학 적용 가능성	40

제4장 지반구조물 설계를 위한 생성형 AI 적용 전략

1. 지반구조물 설계의 고유 난제와 자동화 필요성	43
2. 주요 지반구조물 설계 체계와 기존 자동화의 한계	45
2. 1. 주요 지반구조물의 설계 체계 분석	45
2. 2. 기존 최적화 기반 설계자동화의 성과와 한계	47
3. 생성형 AI: 지반구조물 설계의 새로운 패러다임 가능성	49
4. 본 연구의 접근 전략 및 파일럿 연구 대상 선정	51

제5장 파일럿 연구: CVAE 기반 사면 보강 설계자동화

1. 연구 개요 및 목표	55
2. 연구 방법론	58
2. 1. 설계 변수 정의 및 데이터셋 구축	58
2. 2. CVAE 기반 생성형 설계 프레임워크	61
2. 3. 안정성 평가 기준의 단순화	62
3. 실험 결과 및 분석	64
3. 1. Case 1: 상부 강성 / 하부 연약 지층 (Stiff-over-Weak)	64
3. 2. Case 2: 상부 연약 / 하부 강성 지층 (Weak-over-Stiff)	68
4. 한계점 발견 및 향후 발전 방향	72

제6장 결론 및 향후 연구 로드맵

1. 연구 요약 및 핵심 기여	75
2. 향후 연구 방향 및 로드맵	76

참고문헌	77
------	----

부 록	83
------	----

표 차례 List of Tables

[표 2-1] 판별형 AI와 생성형 AI의 비교	8
[표 2-2] 주요 생성형 AI 모델 비교	18
[표 3-1] 다양한 공학 분야의 이미지 기반 생성형 AI 적용 사례	27
[표 3-2] 다양한 공학 분야의 파라메트릭 기반 생성형 AI 적용 사례	33
[표 4-1] 주요 설계자동화 접근 방식 비교 (Liao et al., 2024)	50
[표 4-2] 주요 설계자동화 접근 방식 비교	53
[표 5-1] 설계적용 기반정수 예시	55
[표 5-2] 기반 물성치 샘플링 범위	60
[표 5-3] 네일 설계 변수 샘플링 범위	60
[표 5-4] Case 1의 대표적인 최종 설계 대안	67
[표 5-5] Case 2의 대표적인 최종 설계 대안	70

그림 차례 List of Figures

[그림 2-1] 인공지능의 주요 개념과 생성형 AI의 관계 (한국방송통신전파진흥원, 2023)	5
[그림 2-2] 생성형 AI의 대표적인 활용 사례	6
[그림 2-3] 개와 고양이 이미지를 분류하도록 훈련된 판별형 AI 모델	7
[그림 2-4] 새로운 개 이미지를 생성하도록 훈련된 생성형 AI 모델	8
[그림 2-5] 인코더-디코더 구조를 활용한 잠재 공간의 개념	9
[그림 2-6] MLP 및 CNN 딥러닝 아키텍처 구조도	10
[그림 2-7] VAE 모델의 기본 구조	12
[그림 2-8] VAE의 잠재 공간을 활용한 숫자 필기체 생성 예시	12
[그림 2-9] GAN 모델의 경쟁 학습 구조	13
[그림 2-10] GAN 기술 발전에 따른 가상 인물 이미지 품질 변화	14
[그림 2-11] 트랜스포머의 인코더-디코더 및 셀프 어텐션 구조	15
[그림 2-12] Transformer 아키텍처 기반 대형 언어 모델(LLM)의 발전 흐름	15
[그림 2-13] 확산 모델의 순방향 및 역방향 프로세스 개념도	16
[그림 2-14] 텍스트 조건을 바탕으로 확산 모델이 생성한 고품질 이미지 예시	17
[그림 2-15] 대표 생성형 AI 모델의 아키텍처 비교	18
[그림 3-1] 공학 설계를 위한 주요 데이터 표현 방식:	20
[그림 3-2] 이미지 기반 AI 설계 자동화 워크플로우 예시 (Liao et al., 2024)	21
[그림 3-3] StructGAN 학습 구조	23
[그림 3-4] 학습된 StructGAN의 설계 적용	23
[그림 3-5] StructGAN-PHY 모델 구조 (GAN + Physics Estimator 결합)	24
[그림 3-6] StructDiffusion 모델 구조	26
[그림 3-7] StructDiffusion의 End-to-End 워크플로우	26
[그림 3-8] 파라메트릭 기반 생성형 AI의 기본 워크플로우 (Salamanca, 2025)	29
[그림 3-9] 정방향 설계와 성능 기반 역설계의 개념 비교 (Salamanca, 2025)	30
[그림 3-10] 잠재 공간과 성능 슬라이더를 활용한 직관적 설계 탐색	31

[그림 3-11] 설명가능 AI(XAI)가 적용된 교량 설계 인터페이스	32
[그림 3-12] NADIA의 대화형 BIM 상세설계 워크플로우	37
[그림 3-13] NADIA 시스템의 자연어 기반 BIM 설계 인터페이스	37
[그림 3-14] RAG-GPT 모델 개발 및 평가 프로세스	39
[그림 3-15] 대화형 건설안전정보 생성 시스템 (RAG-GPT) 인터페이스	39
[그림 4-1] 보강토 옹벽 설계 프로세스 예시 (한국철도시설공단, 2012)	44
[그림 4-2] 주요 지반구조물의 파라메트릭 설계 변수 예시:	46
[그림 4-3] 다목적 최적화의 개념과 파레토 최적해 (Huang et al., 2022)	48
[그림 4-4] 파일럿 연구 대상인 사면 보강 공법 예시	53
[그림 5-1] 실무 사면 보강 설계 단면 예시 (어스 앵커)	56
[그림 5-2] 외적 안정성 검토 예시 (건기, 우기, 지진 시)	57
[그림 5-3] 사면 네일 보강 설계를 위한 CVAE 모델 입출력 변수	59
[그림 5-4] 시뮬레이션 기반 데이터셋 구축 절차	60
[그림 5-5] CVAE 기반 생성형 설계자동화 프레임워크	63
[그림 5-6] Case 1에서 생성된 설계안의 실제 안전율 분포	65
[그림 5-7] Case 1의 Surrogate 모델 기반 설계안 필터링 결과	66
[그림 5-8] Case 1의 대표 설계안 시각화 및 보강 방식 비교	67
[그림 5-9] Case 2에서 생성된 설계안의 실제 안전율 분포	69
[그림 5-10] Case 2의 Surrogate 모델 기반 설계안 필터링 결과	69
[그림 5-11] Case 2의 대표 설계안 시각화 및 파괴 메커니즘 비교	71

제1장 서론

1. 연구 배경 및 목적

1. 1. 연구배경

1) 지반구조물 설계의 현황과 한계

지반구조물(기초, 옹벽, 흙막이 등)의 설계는 불확실성이 높은 지반 조건과 다양한 하중 조건을 바탕으로 안전성, 경제성, 시공성을 동시에 만족시켜야 하는 복합적인 의사결정 과정이다. 현재 실무에서는 설계자의 경험과 기존 설계 기준에 의존하여 초기 설계안을 가정한 뒤, 안정성 해석과 검토를 반복하며 제원을 수정하는 방식으로 최종안을 도출한다.

그러나 이러한 전통적인 방식은 설계에 많은 시간이 소요될 뿐만 아니라, 한정된 시간 내에 소수의 대안만을 검토할 수밖에 없어 최적의 설계안을 놓치거나 과도하게 보수적인 설계로 이어질 가능성이 상존한다.

2) 기존 설계자동화 연구의 한계

1990년대 이후, 이러한 비효율성을 개선하기 위해 유전 알고리즘과 차분 진화와 같은 최적화 알고리즘을 활용한 설계자동화 연구가 활발히 진행되어왔다. 이러한 시도들은 반복적인 계산 부담을 줄이는 데 일부 기여했으나, 미리 정의된 규칙이나 단일 목적함수에 의존하기 때문에 복잡하고 비선형적인 지반 문제에 대한 확장성과 유연성에 명확한 한계를 보였다. 무엇보다 기존의 최적화 연구는 대부분 '하나의 최적해'를 찾는 데 집중하여, 설계자에게 다양한 대안을 비교 검토할 수 있는 기회를 제한하는 한계가 있었다.

3) 판별형 AI 기반 건설기술의 성과와 설계 생성의 근본적 난제

2020년 LH 토지주택연구원의 "AI 기반 건설기술 현황 및 연구전략"은 건설 분야 전반에 AI 기술을 도입하기 위한 청사진을 제시한 연구이다. 이 연구는 이미지 인식을 통한 시설물 손상 탐지, 시공 관리 및 안전 모니터링 등 AI를 활용한 건설 기술의 성과

와 가능성을 체계적으로 제시했다. 동시에, AI를 활용한 설계 단계의 혁신을 위한 향후 연구 방향도 제시되었다. ① BIM과 연계된 최적설계 도출, ② 기존 설계 경험 기반의 최적 개념설계 도출, ③ 지반구조물 개념설계를 위한 딥러닝 기반 사전학습 등의 가능성을 언급하였으며, 데이터 기반 설계의 필요성을 강조하였다.

건설 분야 이미지 인식 및 수치 데이터 분석 등에서의 활발한 활용에도 불구하고, AI를 활용한 설계안 도출 연구는 비전 제시에 그쳤는데, 이에 대한 근본적인 원인은 당시 주류였던 판별형 AI(Discriminative AI) 기술의 본질적 한계 때문이다. 설계안 도출은 하나의 설계 조건(입력)에 대해, 안전성과 경제성을 만족하는 수많은 설계 대안(출력)이 존재할 수 있는 일대다 관계에 있다. 판별형 AI는 주어진 입력에 대한 분석을 통한 단일한 값(예: 안전율)을 예측하는 다대일 문제 해결에는 뛰어나지만, 정답이 여러 개 존재하는 생성 문제에는 구조적으로 적합하지 않았다.

4) 생성형 AI의 등장과 설계 패러다임의 전환

최근 빠르게 발전하며, 다양한 분야에서 높은 활용성을 보이는 생성형 AI(Generative AI)는 앞서 제기된 한계를 극복하는 새로운 패러다임을 제시한다. 생성형 AI는 대규모 데이터를 학습하여 데이터의 잠재적 분포와 패턴을 이해하고, 이를 바탕으로 주어진 조건에 맞는 새롭고 사실적인 결과물을 직접 생성해내는 기술이다. 이는 기존의 분석과 예측 중심의 판별형 AI에서 탐색과 생성으로의 근본적인 전환을 의미한다. ChatGPT, Stable Diffusion, Sora와 같은 성공 사례들은 생성형 AI가 복잡한 데이터의 본질을 학습하여 고품질의 결과물을 만들어내는 강력한 잠재력을 입증했다.

이러한 생성형 AI의 생성 능력은 공학 설계 분야에서도 다양한 고품질 설계 대안군의 생성이라는 혁신을 가능하게 하고 있다. 건축물의 평면 레이아웃, 기계 부품의 위상 최적화 등 다양한 공학 분야에서 생성형 AI는 설계자의 창의성을 확장하고 설계 프로세스를 가속하는 핵심 기술로 발전이 되어가고 있다.

5) 지반공학 분야의 연구 격차와 기회

생성형 AI 기반 설계자동화는 반복적이고 경험 중심적인 비효율성을 가진 지반구조물 설계 분야를 혁신할 가능성을 갖는다. 지반공학 설계의 본질은 '옹벽의 두께', '기초의 폭', '사면 보강재의 길이와 간격' 등 설계 변수(Parameter)의 최적 조합을 찾는 파라메트릭 문제로 귀결된다. 이는 수많은 설계 데이터의 통계적인 분포를 학습하여 새로운 해를 생성하는 생성형 AI가 가장 효과적으로 다룰 수 있는 문제 유형이다.

이에 따라, 생성형 AI를 지반구조물에 적용하여 설계 패러다임의 혁신을 시도하는 것은 중요한 연구 기회로 판단된다. 반복적이고 경험 중심적이었던 기존 설계의 효율을 크게 개선하고, 데이터 기반의 설계 자동화 시스템 구현의 첫걸음이 될 수 있을 것이다. 단기적으로는 파라메트릭 생성 모델을 통한 설계 조건에 따른 설계 치수 자동 생성에 적용될 수 있으며, 장기적으로는 이미지, 텍스트, BIM 등 다양한 데이터를 융합하는 지능형 설계 생태계의 기반이 될 것이다.

1. 2. 연구목적

본 연구의 궁극적인 목적은 생성형 AI 기술을 도입하여, 전통적 경험 기반 설계와 기존 최적화 연구의 한계를 넘어서는 새로운 지반공학 설계 패러다임을 정립하는 데 있다. 이를 위한 첫 단계로서, 본 연구에서는 생성형 AI 기반 지반구조물 설계자동화의 핵심 방법론을 개발하고 제안한다. 제안된 방법론의 실현 가능성은 파일럿 연구를 통해 실증적으로 검증하며, 이를 통해 경험과 반복 작업에 의존해온 설계 프로세스를 데이터 기반 자동화 체계로 전환함으로써 설계의 효율성과 품질을 동시에 향상시키는 것을 목표로 한다. 세부 목표는 다음과 같다.

- 데이터 유형별(이미지, 텍스트, 파라메트릭) 생성형 AI 접근법 분석 및 지반공학 적용 전략 도출
- 사면 보강 설계 대상 파일럿 연구를 통한 방법론 검증 및 한계점 발견
- 차세대 생성형 AI 프레임워크 및 향후 연구 방향 제시

2. 연구범위 및 방법

2. 1. 연구범위

본 연구는 생성형 AI 기반 지반구조물 설계자동화의 방법론적 기틀을 마련하는 것을 주요 범위로 하며, 장기적으로 지반구조물 전반에 적용 가능한 확장성을 염두에 두고 진행한다.

- 이론적 범위
 - 기존 설계자동화 기술(최적화 기반, 판별형 AI)의 발전 과정과 한계 분석

- 생성형 AI의 이론적 배경 체계화 및 대표 모델 특성 분석
- 국내외 공학 설계 분야의 생성형 AI 적용 동향 조사
- 방법론적 범위
 - 데이터 유형별(이미지, 텍스트, 파라메트릭) 접근법 분석 및 지반공학 적용 전략 도출
 - 파라메트릭 접근법 중심의 지반구조물 설계자동화 프레임워크 개발
- 실증적 범위
 - 사면 보강 설계를 대상으로 한 CVAE 기반 파일럿 사례 연구 수행
 - 생성된 설계안의 성능 검증 및 차세대 프레임워크 필요성 실증
- 확장적 범위
 - 옹벽, 기초 등 타 지반구조물로의 확장 방안 제시
 - 실무 적용을 위한 구현 전략 및 로드맵 도출

2. 2. 연구방법

본 연구를 수행하기 위한 방법은 다음과 같다.

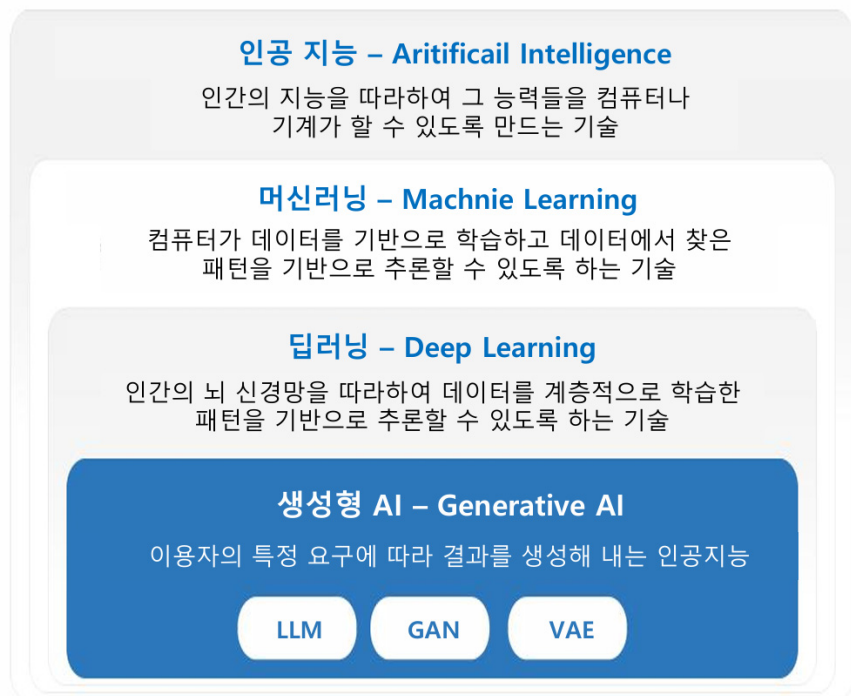
- 문헌조사 및 이론 연구
 - 기존 설계자동화 연구(최적화 기반, 판별형 AI)의 성과와 한계 분석
 - 생성형 AI의 핵심 개념 및 대표 모델의 작동 원리 분석
 - 데이터 유형별 생성형 AI 접근법의 장단점 비교
 - 공학 설계 분야(건축, 기계 등)의 생성형 AI 적용 사례 조사 및 시사점 도출
- 방법론 개발
 - 지반구조물(옹벽, 사면 보강 등) 설계의 파라메트릭 특성 및 변수 체계 분석
 - 사면 보강 설계 문제의 입출력 변수 및 데이터셋 구축 방안 수립
 - 생성 모델 학습 전략 및 성능 평가 지표 개발
- 파일럿 연구 수행
 - 사면 보강 설계 데이터 수집 및 전처리
 - CVAE 모델 구현 및 학습
 - 생성된 설계안의 성능 평가 및 검증
 - 방법론의 한계점 분석 및 향후 연구 방향 도출

제2장 이론적 배경: 생성형 AI

1. 개요

1. 1. 인공지능 기술의 발전과 생성형 AI의 등장

인공지능 기술의 발전은 크게 인공지능(AI) → 머신러닝 → 딥러닝 → 생성형 AI의 네 단계로 구분할 수 있다. 각 단계는 이전 기술의 한계를 극복하며 발전해왔으며, 특히 2020년대 이후로 빠르게 발전한 생성형 AI는 기존의 분석과 예측 중심에서 창작과 생성으로 AI의 역할을 근본적으로 확장시켰다는 점에서 중요한 의미를 가진다.



[그림 2-1] 인공지능의 주요 개념과 생성형 AI의 관계 (한국방송통신전파진흥원, 2023)

1950년대에 시작된 초기 인공지능(AI)은 전문가의 지식을 명확한 규칙으로 정의하는 전문가 시스템 형태로 구현됨에 따라, 복잡한 실제 환경에서는 확장성에 한계를 보였다. 1980년대부터 발전한 머신러닝(Machine Learning)은 명시적인 프로그래밍 없이 데이터로부터 스스로 학습하고 패턴을 발견하는 방식으로 이러한 한계를 극복했다. 이후 등장한 딥러닝(Deep Learning)은 인간의 뇌 신경망을 모방한 다층의 인공신경망을 통해 복잡하고 추상적인 데이터 패턴까지 학습하게 되면서 음성 인식, 이미지 분류 등 다양한 분야에서 혁신적인 성과를 달성했다.

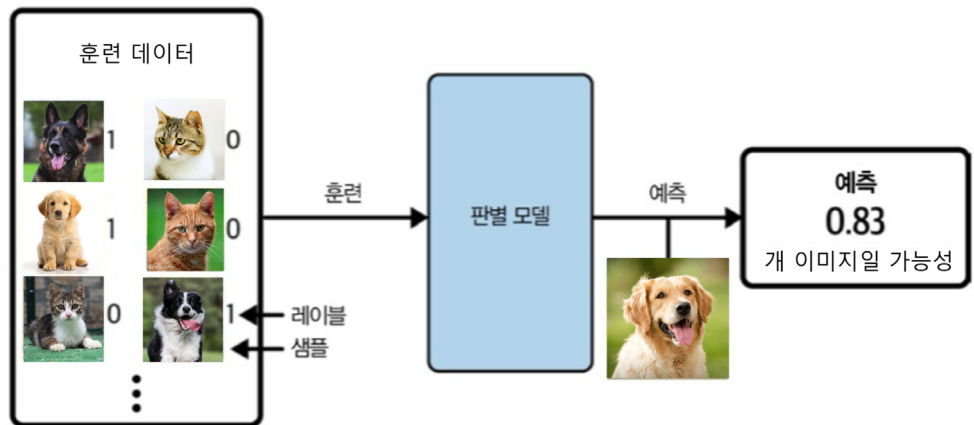
2020년 이후, 생성형 AI(Generative AI)는 ChatGPT, Stable Diffusion 등의 성공적인 사례를 통해 AI 패러다임의 중심을 '분석과 예측'에서 '창작과 생성'으로 급속히 이동시킨 혁신 기술로 부상했다. 이에 따라 높은 퀄리티의 텍스트 및 이미지 생성이 가능해졌고, 인간의 창의적 활동 영역에 AI가 본격적으로 기여할 수 있게 되었다.



[그림 2-2] 생성형 AI의 대표적인 활용 사례

1. 2. 생성형 AI와 판별형 AI의 차이

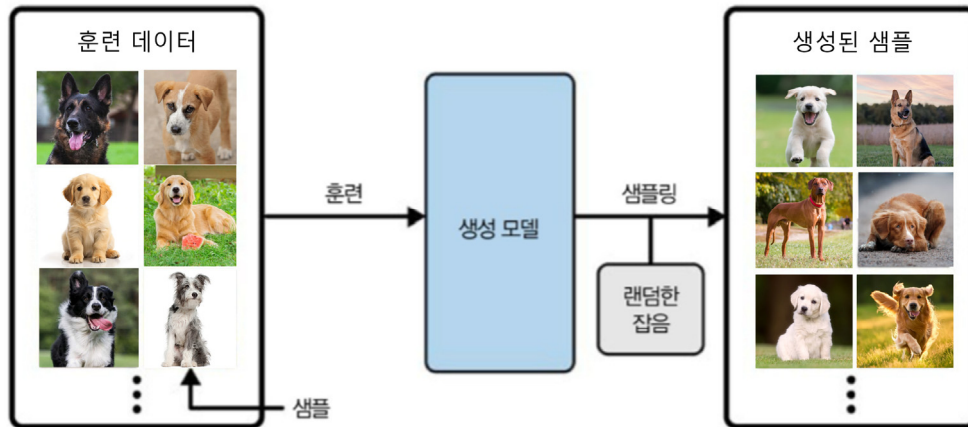
생성형 AI는 지금까지 AI 기술의 주류를 이루었던 판별형 AI와 근본적인 차이점을 갖는다. 판별형 AI는 입력 데이터와 정답 간의 관계를 학습하여 새로운 입력에 대해 명확한 판단 결과를 제공하는 작업에 특화되어 있다. 주어진 입력 데이터를 특정 범주로 분류(Classification)하거나 연속적인 값을 예측(Regression)한다. 예를 들어, 학습된 판별형 모델은 [그림 2-3]과 같이 이미지를 입력받아 "이것이 개인가, 고양이인가?"를 분류하거나, 구조물 데이터를 분석하여 "안전율은 얼마일까?"를 예측하는 것이 대표적인 예이다.



[그림 2-3] 개와 고양이 이미지를 분류하도록 훈련된 판별형 AI 모델

반면, 생성형 AI는 데이터에 내재된 구조와 패턴을 스스로 학습하여, 실제로 존재하지 않는 새롭고 사실적인 데이터를 만들어낼 수 있다는 점에서 판별형 AI와 본질적으로 다르다. 예를 들어, [그림 2-4]와 같이 다양한 개 이미지를 학습한 생성형 AI 모델은 기존에 없던 새로운 개 이미지를 창의적으로 생성할 수 있다. 이러한 생성 능력이 설계 분야에 적용되면, 수많은 설계 사례를 학습한 생성형 AI 모델은 새로운 설계 조건에 맞는 설계안을 다양하게 생성할 수 있다.

이러한 생성 능력은 본 연구가 주목하는 핵심적인 차별점이다. 이는 단순한 분류와 예측을 넘어, 다양한 고품질 설계 대안을 탐색하는 새로운 가능성을 열어준다. 복잡한 설계 데이터에 대한 이해를 통해 다양한 설계안 생성이 요구되는 공학 설계 분야에서 생성형 AI는 새로운 패러다임을 제시한다. [표 2-1]에서는 판별형 AI와 생성형 AI의 핵심적인 차이를 정리한다.



[그림 2-4] 새로운 개 이미지를 생성하도록 훈련된 생성형 AI 모델

[표 2-1] 판별형 AI와 생성형 AI의 비교

구분	생성형 AI	판별형 AI
정의	주어진 조건을 바탕으로 새로운 데이터를 생성하는 AI	입력 데이터를 분류하거나 판단하는 AI
학습 방식	데이터 자체의 패턴과 구조를 비지도 또는 조건부 학습	데이터와 정답(레이블)을 이용해 지도 학습
대표 모델	VAE, GAN, Diffusion, Transformer(LLM)	CNN, MLP, XGBoost, SVM
출력 결과	이미지, 텍스트 등 창의적 생성	정답 라벨, 예측값 등 명확한 판단 결과
설계 적용	다양한 고품질 설계안 생성	설계안 평가 및 성능 예측

2. 생성형 AI의 핵심 원리


2. 1. 잠재 공간(Latent Space): 데이터의 압축과 표현

생성형 AI의 작동 원리는 잠재 공간(Latent Space)이라는 개념에 있다. 잠재 공간이란, 이미지나 설계 도면과 같이 복잡하고 고차원적인 데이터를 다루기 쉬운 저차원의 수치 벡터 공간으로 압축하여 표현한 추상적인 공간을 의미한다. 생성형 AI는 이 잠재 공간을 탐색하고 조작함으로써 새로운 데이터를 만들어낸다.

잠재 공간은 다음과 같은 핵심 특성을 가진다.

- 압축성: 복잡한 고차원 데이터를 다루기 쉬운 저차원의 벡터로 요약하여 표현
- 연속성: 유사한 데이터들이 공간상에서 인접하게 위치하며, 이를 통해 특정 방향이 데이터의 속성 변화를 나타내도록 의미 있는 구조를 형성
- 조작 가능성: 구조화된 잠재 공간상의 벡터를 제어하거나 조합함으로써, 기존에 없던 새롭고 타당한 결과물을 창의적으로 생성

이러한 잠재 공간을 활용한 생성 과정은 [그림 2-5]와 같으며, 일반적으로 세 단계로 이루어진다. 먼저, 인코딩(Encoding) 단계에서 기존 데이터의 분포와 구조를 학습하여 잠재 공간에 매핑한다. 다음으로, 샘플링(Sampling) 단계에서 이 잠재 공간 내의 특정 지점을 선택하거나 무작위로 새로운 벡터를 추출한다. 마지막으로, 디코딩(Decoding) 단계에서 샘플링된 잠재 벡터를 다시 고차원의 실제 데이터로 복원한다. 이 과정을 통해 원본 데이터의 핵심적인 특성은 유지하면서도 완전히 새로운 결과물을 생성하는 것이 가능해진다.



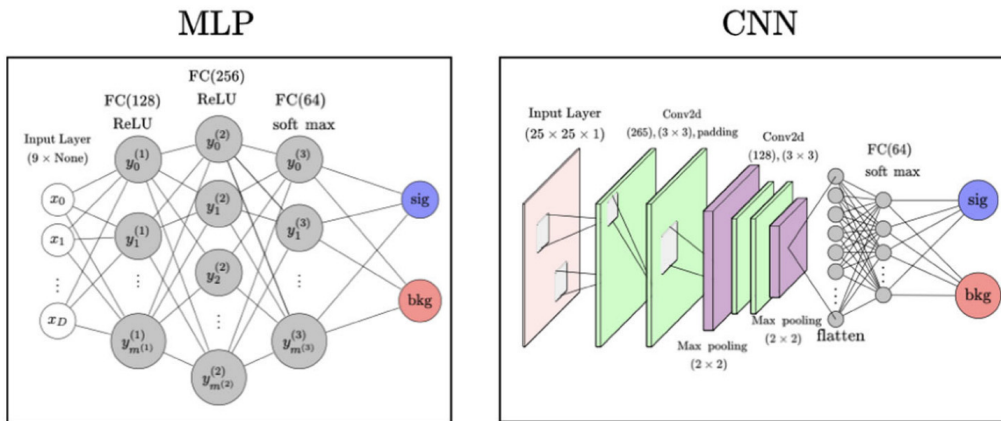
[그림 2-5] 인코더-디코더 구조를 활용한 잠재 공간의 개념
(Bryan-Kinns et al., 2024)

2. 2. 딥러닝 기반 패턴 학습: 잠재공간의 구현

생성형 AI가 복잡한 데이터에 대해 이처럼 정교한 잠재 공간을 구축하고 유의미한 결과물을 생성하는 데에는 딥러닝(Deep Learning) 기술이 결정적인 역할을 한다. 딥러닝 이전의 통계적 생성 기법들은 주로 단순한 패턴이나 저차원 데이터에만 적용 가능했다.

딥러닝의 핵심 강점은 다층 신경망(Multi-layer Neural Network)을 통해, 인간이 직접 규칙으로 정의하기 어려운 복잡하고 추상적인 패턴을 데이터로부터 자동으로 학습할 수 있다는 점이다. 과거에는 사람이 일일이 데이터의 특징(feature)을 정의해야 했지만, 딥러닝은 계층적인 표현 학습을 통해 훨씬 다양하고 창의적인 데이터 생성을 가능하게 했다.

딥러닝 기술의 도입 이후 생성형 AI는 급속도로 발전했으며, 초기 모델이 생성하던 흐릿하고 비현실적인 결과물에서 실제와 구별하기 어려운 고품질의 결과물을 생성하는 수준까지 기술적 진보를 이루었다. 생성형 모델은 데이터의 특성과 생성 목적에 따라 다양한 딥러닝 아키텍처를 유연하게 활용하며, 대표적으로 수치 데이터의 패턴 학습에는 다층 퍼셉트론(MLP)을, 이미지와 같은 2D 공간 데이터 처리에는 합성곱 신경망(CNN)을 사용한다.



[그림 2-6] MLP 및 CNN 딥러닝 아키텍처 구조도
(Hammad et al., 2023)

3. 대표적인 생성형 AI 모델


생성형 AI 기술은 앞서 설명한 잠재 공간(Latent Space)을 구성하고 활용하는 방식에 따라, 서로 다른 특성과 장단점을 가진 여러 모델로 발전해왔다. 본 절에서는 현재 가장 널리 활용되는 주요 생성형 AI 모델들의 구조적 특성과 학습 방식, 적용 분야를 체계적으로 살펴본다.

1) 변이형 오토인코더 (Variational Autoencoder, VAE)

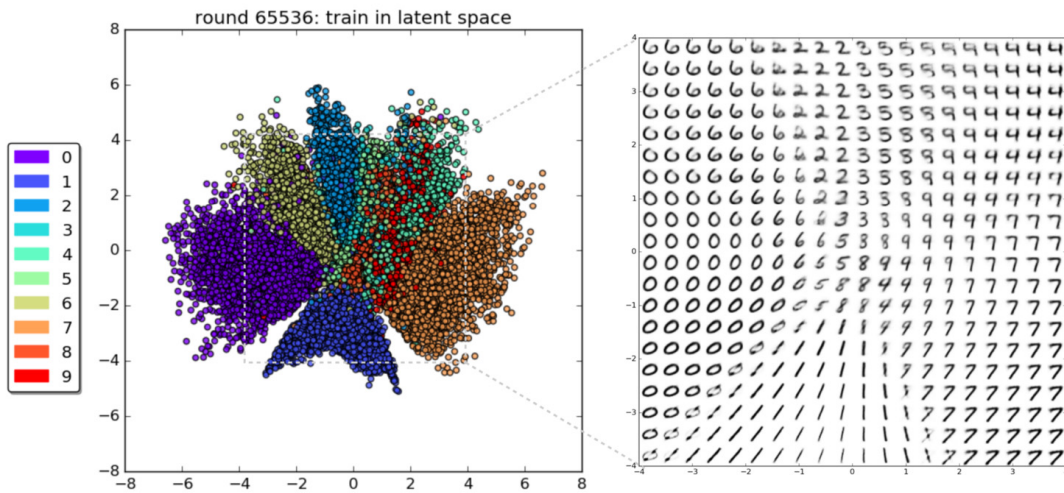
변이형 오토인코더(VAE)는 2013년에 제안된 생성 모델로, 구조화된 잠재 공간을 학습하는 초기 성공 사례 중 하나이다. [그림 2-7]과 같이 인코더가 입력 데이터를 잠재 공간의 확률 분포로 압축하고, 디코더가 이 분포에서 샘플링된 벡터를 다시 원본 데이터로 복원하는 구조를 가진다.

VAE의 가장 큰 특징은 잠재 공간이 정규분포와 같은 특정 확률 분포를 따르도록 명시적으로 제약하여, 잠재 공간 전체가 의미 있는 데이터로 채워지도록 유도한다는 점이다. 이러한 구조 덕분에 학습이 안정적이고, 잠재 공간 내에서 벡터 값을 조금씩 변경하면 그에 따라 생성되는 결과물도 부드럽게 변하는 특징이 있다. 이는 [그림 2-8]과 같이 잠재 공간의 한 좌표에서 다른 좌표로 이동할 때, 하나의 숫자가 다른 숫자로 자연스럽게 변형되는 예시를 통해 확인할 수 있다.

이러한 특성은 다양한 가능성을 연속적으로 탐색해야 하는 설계 공간 탐색(Design Space Exploration)에 매우 유리하다. 또한, VAE는 무작위로 결과물을 생성하지만, 여기에 '조건(Condition)'이라는 추가 정보(예: '안전율 1.5를 만족시켜라')를 인코더와 디코더에 함께 주입하여 생성 과정을 제어하는 조건부 VAE(Conditional VAE, CVAE)로 확장될 수 있다. 이처럼 특정 목표를 가지고 결과물 생성을 유도하는 조건부 생성(Conditional Generation) 방식은 본 보고서 5장의 파일럿 연구에서 활용된 핵심 원리이다.



[그림 2-7] VAE 모델의 기본 구조
(Kingma and Welling, 2013)

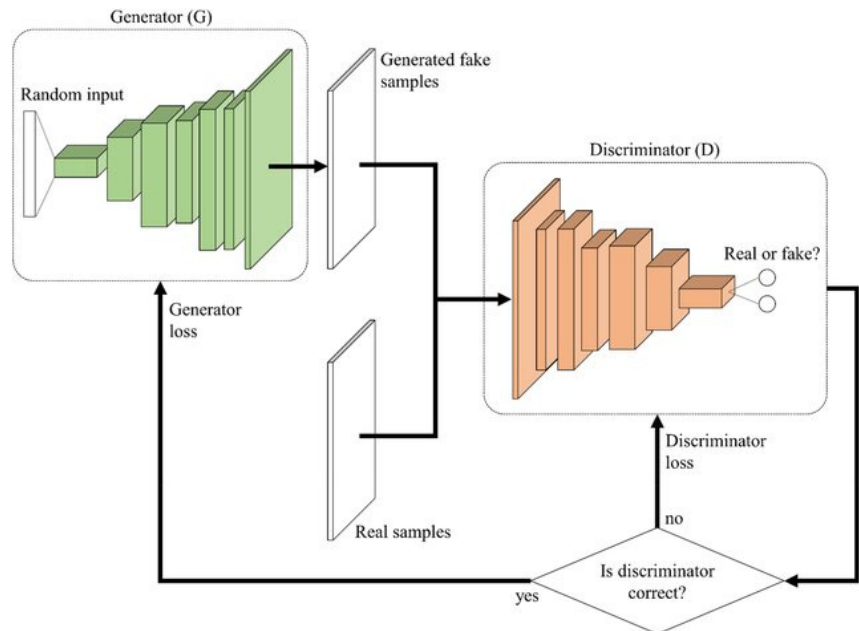


[그림 2-8] VAE의 잠재 공간을 활용한 숫자 필기체 생성 예시
(Valletti et al., 2024)


2) 생성적 적대 신경망 (Generative Adversarial Network, GAN)

생성적 적대 신경망(GAN)은 2014년에 제안된 모델로, [그림 2-9]와 같이 생성자(Generator)와 판별자(Discriminator)라는 두 신경망이 서로 경쟁하며 학습하는 독특한 구조를 가진다. 생성자는 '위조지폐범'처럼 실제 데이터와 유사한 가짜 데이터를 만들고, 판별자는 '경찰'처럼 진짜와 가짜를 구별하도록 학습한다. 이 과정이 반복되면서 생성자는 판별자를 속이기 위해 점점 더 정교하고 사실적인 결과물을 만들어낸다.

GAN은 매우 선명하고 사실적인 결과물을 생성하는 데 강력한 성능을 보인다. 특히 [그림 2-10]에서 볼 수 있듯이, 2014년 초기 GAN이 생성한 흐릿한 흑백 이미지에서 불과 4년 만인 2018년 StyleGAN이 생성한 실제 사람과 구별하기 어려운 컬러 이미지에 이르기까지, 그 발전 속도는 매우 폭발적이었다. 이러한 기술적 발전 덕분에 시각적으로 완성도 높은 결과가 중요한 이미지 기반 설계 자동화에서 널리 활용된다. 하지만 두 네트워크 간의 균형을 맞추기 어려워 학습 과정이 불안정하고, 특정 결과물만 반복해서 생성하는 '모드 붕괴(Mode Collapse)' 현상이 발생하기 쉽다는 단점이 있다.



[그림 2-9] GAN 모델의 경쟁 학습 구조
(Goodfellow et al., 2014)



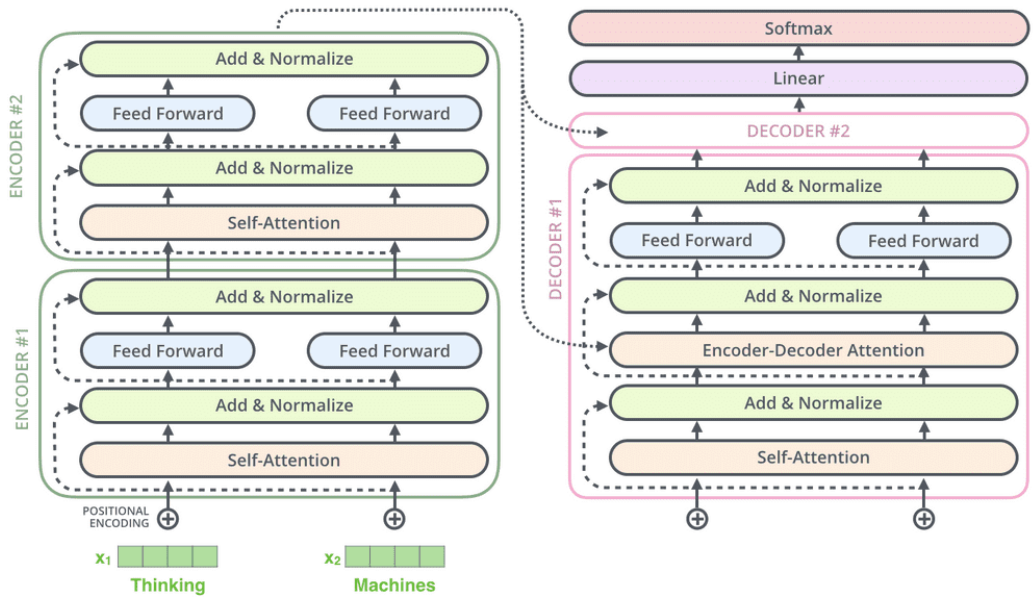
[그림 2-10] GAN 기술 발전에 따른 가상 인물 이미지 품질 변화
(Abdolahnejad and Liu, 2020)

3) 트랜스포머 (Transformer)

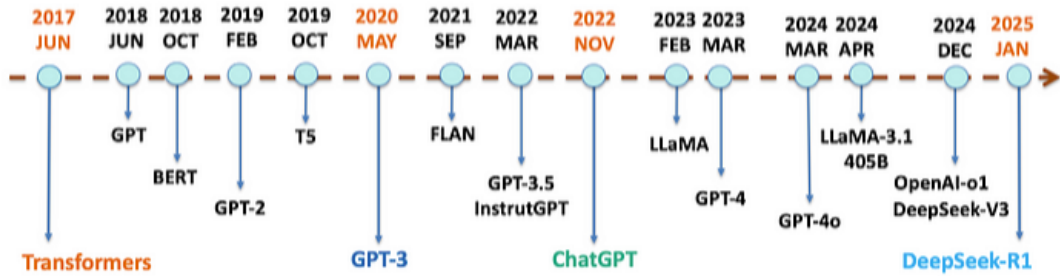
트랜스포머는 2017년 구글의 "Attention Is All You Need" 논문에서 처음 등장하여, 이후 AI 기술의 흐름을 완전히 바꾼 혁신적인 아키텍처이다. [그림 2-11]과 같이 인코더-디코더 구조를 가지며, 그 핵심에는 셀프 어텐션(Self-Attention) 메커니즘이 있다. 이는 문장 내 모든 단어 간의 관계를 한 번에 병렬적으로 계산하여, 각 단어가 문맥 속에서 다른 단어들과 얼마나 중요한 관계를 맺고 있는지를 파악하는 방식이다.

이는 단어를 순서대로만 처리하던 기존 방식(RNN, LSTM)의 한계를 극복하고, 문맥 전체를 종합적으로 이해하는 능력을 비약적으로 향상시켰다. 이 병렬 처리 능력 덕분에 이전과는 비교할 수 없는 규모의 데이터로 모델을 학습시키는 것이 가능해졌고, 이는 [그림 2-12]와 같이 BERT, GPT, ChatGPT 등 대형 언어 모델(LLM)의 폭발적인 발전으로 이어졌다.

트랜스포머는 텍스트나 코드와 같은 순차적 데이터의 생성에 매우 강력한 성능을 보인다. 공학 설계 분야에서는 설계 기준서, 공사 시방서, 기술 보고서와 같은 방대한 텍스트 정보를 이해하고 요약하거나, 사용자의 자연어 요구사항을 해석하는 데 핵심적인 역할을 할 수 있다. 다만, 학습과 운영에 막대한 연산 자원이 필요하며, 수치적으로 정밀한 제어가 필요한 설계안 생성에는 직접 적용하기 어렵다는 한계가 있다.



[그림 2-11] 트랜스포머의 인코더-디코더 및 셀프 어텐션 구조 (Vaswani et al., 2017)



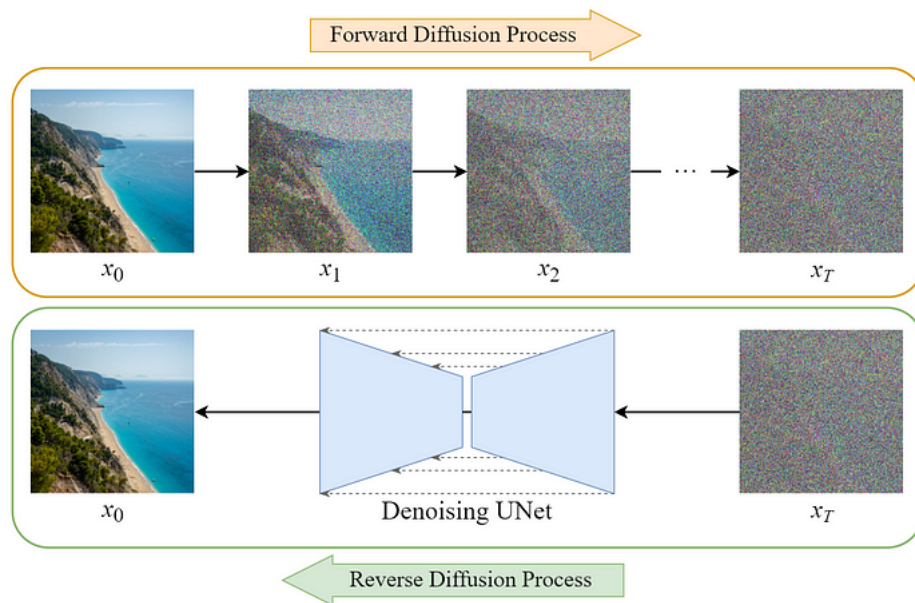
[그림 2-12] Transformer 아키텍처 기반 대형 언어 모델(LLM)의 발전 흐름

4) 확산 모델 (Diffusion Model)

확산 모델은 2020년 이후로 본격적으로 주목받기 시작한 모델로, 현재 가장 뛰어난 품질의 결과물을 생성하는 기술 중 하나로 평가받는다. [그림 2-13]과 같이 원본 데이터에 점진적으로 노이즈를 추가하여 완전한 노이즈로 만드는 순방향 과정(Forward Process)과, 반대로 이 노이즈로부터 점진적으로 노이즈를 제거하여 원본 데이터를 복원하는 역방향 과정(Reverse Process)을 학습한다. 이는 마치 깨끗한 이미지에 노이즈를 뿌렸다가, 그 노이즈 낀 이미지에서 원래 이미지가 어땠을지를 추론해 복원하는 과정과 유사하다.

이러한 점진적인 노이즈 제거 방식 덕분에 학습이 안정적이면서도, [그림 2-14]와 같이 매우 복잡하고 사실적인 고품질의 결과물을 생성할 수 있다. 특히, "a cute doll writing a letter"과 같은 구체적인 텍스트 조건을 정확히 반영하여 이미지를 생성하는 조건부 생성(Conditional Generation) 능력이 매우 뛰어나다.

또한, 확산 모델은 복잡하고 여러 개의 그룹(Multi-modal)으로 나뉘는 데이터 분포를 효과적으로 학습하는 강점을 갖는다. 다만, 노이즈 제거를 통한 생성 과정이 점진적으로 수행되어 다른 모델에 비해 생성 속도가 느리다는 단점이 존재한다.



[그림 2-13] 확산 모델의 순방향 및 역방향 프로세스 개념도 (Rombach et al., 2022)



"a cute doll writing a letter"



"a bored smoking lizard surrounded by soldiers"



"a parking meter near a graffiti wall"



"a corgi in a field"



"a monkey eating a banana"

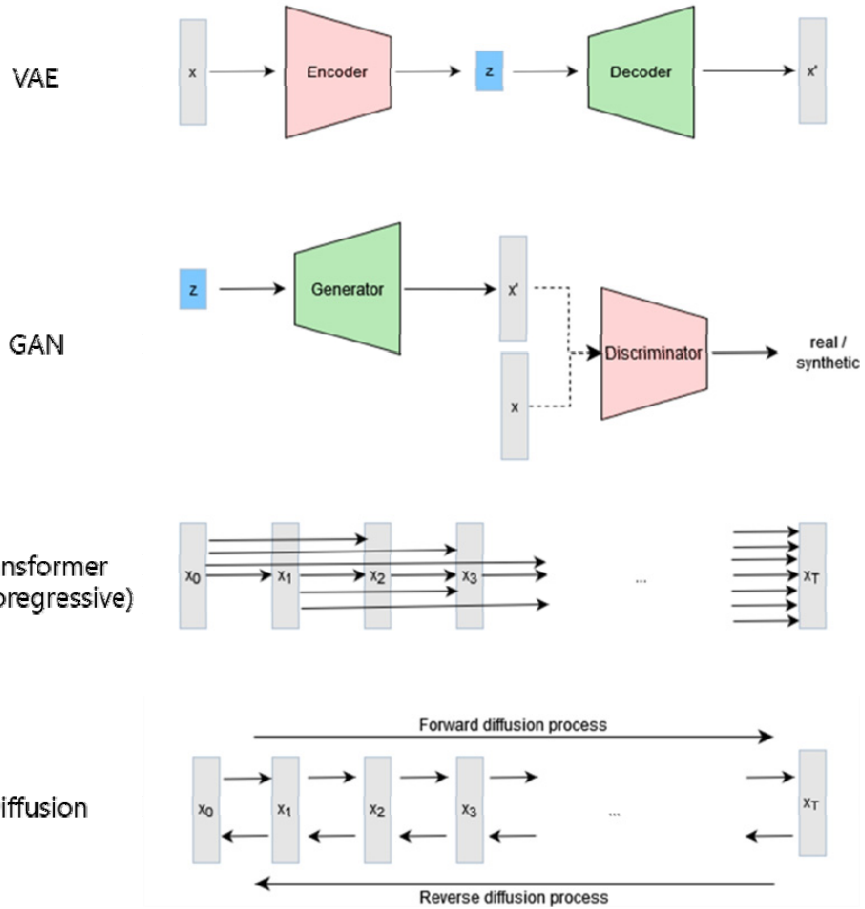


"a neapolitan pizza with mozzarella and tomatoes"

[그림 2-14] 텍스트 조건을 바탕으로 확산 모델이 생성한 고품질 이미지 예시 (Corvi et al., 2023)

[표 2-2] 주요 생성형 AI 모델 비교

구분	VAE	GAN	Transformer	Diffusion
핵심 원리	잠재공간 압축 및 복원	적대적 경쟁 학습	어텐션 기반 순차 생성	점진적 노이즈 제거
강점	안정적 학습, 해석 가능한 잠재 공간	빠른 생성, 다양한 구조 변형	긴 문맥 이해, 순차 데이터 처리	안정적 학습, 정밀한 조건 제어
단점	상대적으로 낮은 품질	학습 불안정, 모드 붕괴	막대한 연산 자원 필요	느린 생성 속도
주요 활용	설계 공간 탐색, 데이터 증강	실시간 이미지 생성	텍스트 및 코드 생성	고품질 조건부 이미지 생성



[그림 2-15] 대표 생성형 AI 모델의 아키텍처 비교 (Seiler and Ritter, 2024)

제3장 설계자동화를 위한 생성형 AI 적용 현황

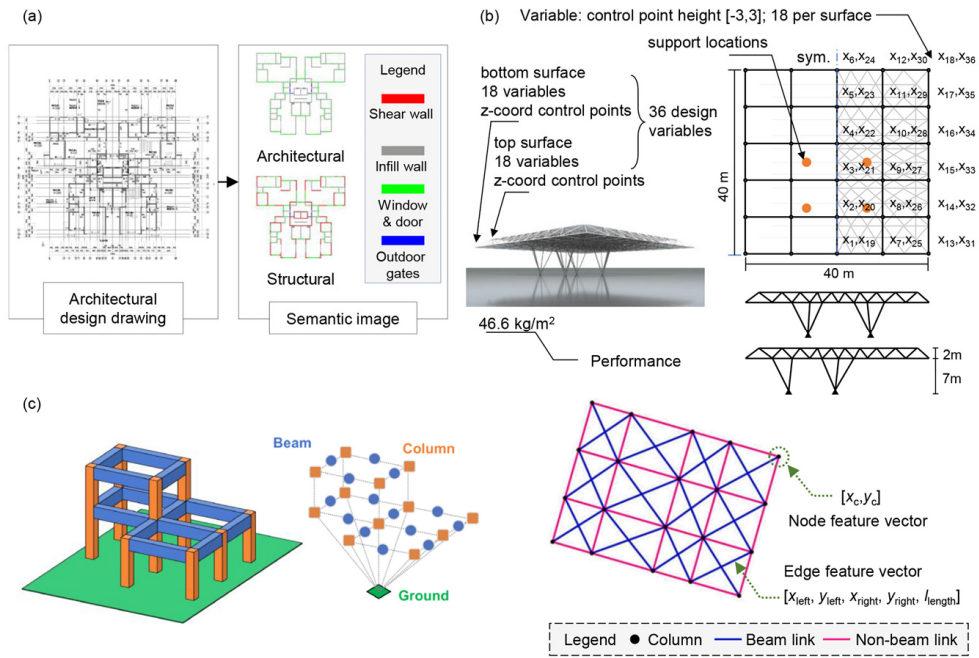
1. 개요

앞선 2장에서 생성형 AI의 이론적 배경과 핵심 모델들을 살펴보았다면, 본 장에서는 이 기술이 실제 공학 설계 분야에서 어떻게 적용되고 있는지를 구체적인 사례를 통해 분석한다. 생성형 AI는 데이터의 잠재적 패턴을 학습하여 새로운 결과물을 생성하는 기술로, 창의적 대안 탐색과 반복 업무 자동화의 핵심 도구로 부상하고 있다. 기존의 수학적 최적화 방법론이 '단일 최적해' 탐색에 집중했던 것과 달리, 생성형 AI는 데이터 기반 학습을 통해 다양한 설계 대안을 동시에 탐색할 수 있다는 점에서 새로운 설계 패러다임으로서의 의미를 가진다.

생성형 AI의 설계자동화 적용 방식을 이해하는 가장 효과적인 방법은 활용 데이터 표현 방식(Data Representation)에 따라 접근법을 분류하는 것이다. 입출력 데이터의 형태는 모델의 학습 전략과 성능은 물론, 해결할 수 있는 공학 문제의 종류와 실무 적용성까지 직접적으로 연결되기 때문이다. 공학 설계에서 활용되는 데이터 표현 방식은 아래와 같이 다양하다.

- 이미지(Image): 설계 도면이나 형태를 2D 픽셀 그리드로 표현한다.
- 파라메트릭(Parametric): 설계의 핵심 변수들을 길이, 각도, 개수 등 수치 매개변수로 정의한다.
- 그래프(Graph): 구조물의 부재를 노드(Node)로, 부재 간의 연결 관계를 엣지(Edge)로 표현하여 위상적 관계를 나타낸다.
- 3차원 모델(3D Model): 복셀(Voxel)이나 메쉬(Mesh) 등을 사용하여 3차원 형상을 직접 표현한다.
- 텍스트(Text): 설계 요구사항, 기준, 지식 등을 자연어로 기술한다.

본 보고서에서는 이들 중 널리 활용되며, 특히 지반구조물 설계 자동화 적용 잠재력이 높을 것으로 판단되는 이미지, 파라메트릭, 텍스트 기반 접근법에 집중하여 심층적인 분석을 진행한다.



[그림 3-1] 공학 설계를 위한 주요 데이터 표현 방식:
 (a) 이미지, (b) 파라메트릭, (c) 그래프 (Liao et al., 2024)

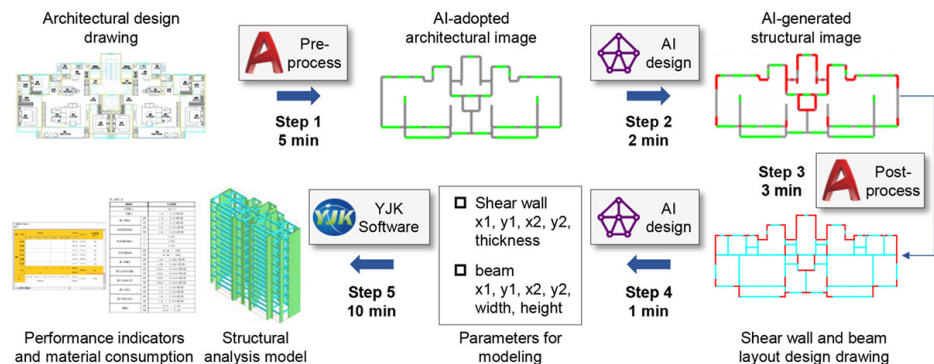
2. 이미지 데이터 기반

이미지 데이터 기반 접근법은 건축 평면도, 구조 도면 등의 시각적 데이터를 입력받아 공간 배치나 구조 형태를 자동으로 생성하는 방식이다. 이는 설계자가 도면을 보며 직관적으로 구조적 맥락을 파악하는 사고 과정을 생성형 AI를 통해 모방하려는 시도로, 컴퓨터 비전 기술의 발전에 힘입어 빠르게 발전되었다. [그림 3-2]는 건축 도면을 생성형 AI가 인식하여 구조 도면을 생성하고, 이를 해석 모델까지 연계하는 전체 워크플로우를 보여주는 대표적인 예시이다.

이 접근법의 강점은 직관성과 속도에 있다. 복잡한 제약 조건이나 수식을 명시적으로 정의하지 않아도, 생성형 AI가 기존 설계 사례의 시각적 패턴을 학습해 새로운 설계안을 신속히 제시할 수 있다. 따라서 설계 초기 단계에서 다양한 대안을 탐색하거나 반복적 도면 작업을 대체하는 데 효과적이다.

그러나 시각적 패턴 학습만으로는 안전율, 변형률과 같은 정량적 성능을 보장할 수 없다는 근본적인 한계를 가진다. 학습된 기존 데이터의 분포를 통해 생성된 ‘그럴듯해 보이는 설계안’과 ‘공학적으로 타당한 설계안’ 사이에는 명확한 간극이 존재한다.

본 절에서는 먼저 이러한 한계를 극복하기 위해 발전된 기술적 진화 과정을 대표적인 사례인 철근콘크리트 전단벽 자동설계 연구(StructGAN, StructGAN-PHY, StructDiffusion)를 통해 단계적으로 살펴본다. 이어서, 사례 분석을 통해 얻은 통찰을 바탕으로 이미지 기반 접근법의 전반적인 특징을 종합하고, 최종적으로 본 연구의 핵심 분야인 지반구조물에 대한 적용 가능성과 과제를 심층적으로 탐색한다.



[그림 3-2] 이미지 기반 AI 설계 자동화 워크플로우 예시 (Liao et al., 2024)

2. 1. 주요 연구 사례 분석: 철근콘크리트 전단벽 설계

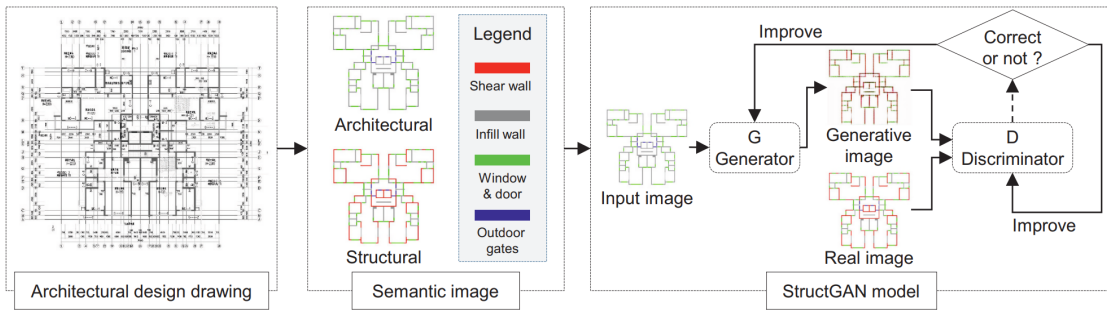
1) StructGAN: GAN을 활용한 전단벽 배치의 패턴 학습 (Liao et al., 2021)

이미지 기반 생성형 AI 설계자동화의 가능성을 처음으로 입증한 대표적인 연구는 2021년 중국 칭화대학교에서 제안된 StructGAN이다. 이 모델은 고층 철근콘크리트 주거 건물의 구조 시스템 설계를 목표로, [그림 3-3]과 같이 조건부 GAN(cGAN)을 활용하여 "건축 평면도" 이미지를 입력받아 "구조적으로 합리적인 전단벽 배치도" 이미지를 출력하는 매핑 관계를 학습한다.


학습을 위해 약 250쌍의 실제 건축-구조 도면을 데이터로 사용했으며, 단순히 이미지를 모방하는 것을 넘어 공학적 의미를 학습시키기 위한 전처리를 수행했다. 구조벽(빨강), 비내력벽(회색), 창호(녹색) 등 각 요소를 색상으로 코딩하여 모델이 건축 요소와 구조 요소 간의 의미론적 관계를 쉽게 이해하도록 유도했다. 또한, 건물 높이나 내진 설계강도와 같은 공학적 조건을 데이터 라벨로 부여하여, 조건에 따른 특화된 설계를 생성할 수 있도록 했다.

이렇게 학습된 모델은 [그림 3-4]와 같이 새로운 건축 평면도가 주어졌을 때, 학습된 패턴을 기반으로 적절한 전단벽 배치를 자동으로 생성해낸다. StructGAN은 설계 효율성과 결과물의 품질 측면에서 의미 있는 성과를 거두었다. 먼저, 효율성 측면에서는 기존에 평균 3.5시간이 소요되던 예비 설계 시간을 단 10분으로 단축시켜 약 20배의 효율 향상을 보였다. 품질 및 안전성 측면에서는, 전문가 평가에서 약 30%의 설계안이 인간의 설계와 구별하기 어려울 정도의 현실성을 확보했으며, 기존 엔지니어 설계 대비 지진 손실비용 증가를 6% 이내로 억제하여 구조적 신뢰성을 유지했다.

이처럼 StructGAN은 GAN을 활용하여 설계자의 암묵적인 지식과 시각적 패턴을 학습하고 재현할 수 있음을 보여주었다. 그러나 동시에 명확한 한계도 드러났다. 생성된 전단벽 배치는 시각적으로는 타당해 보였지만, "왜 이러한 배치가 구조적으로 합리적인가"라는 물리적 근거를 설명하지 못했다. 즉, 데이터에 나타난 형태적 패턴을 효과적으로 모방하는 데 성공했으나, 그 수준은 여전히 겉모습의 재현에 머물러 있었다는 근본적인 한계점을 가졌다.



[그림 3-3] StructGAN 학습 구조
(Architectural drawing → Semantic image 변환, GAN 모델을 통한 학습)



[그림 3-4] 학습된 StructGAN의 설계 적용
(새로운 평면도 입력 후 전단벽 배치 자동 생성 과정)

2) StructGAN-PHY: 물리 성능을 결합한 지식 기반 설계 (Lu et al., 2022)

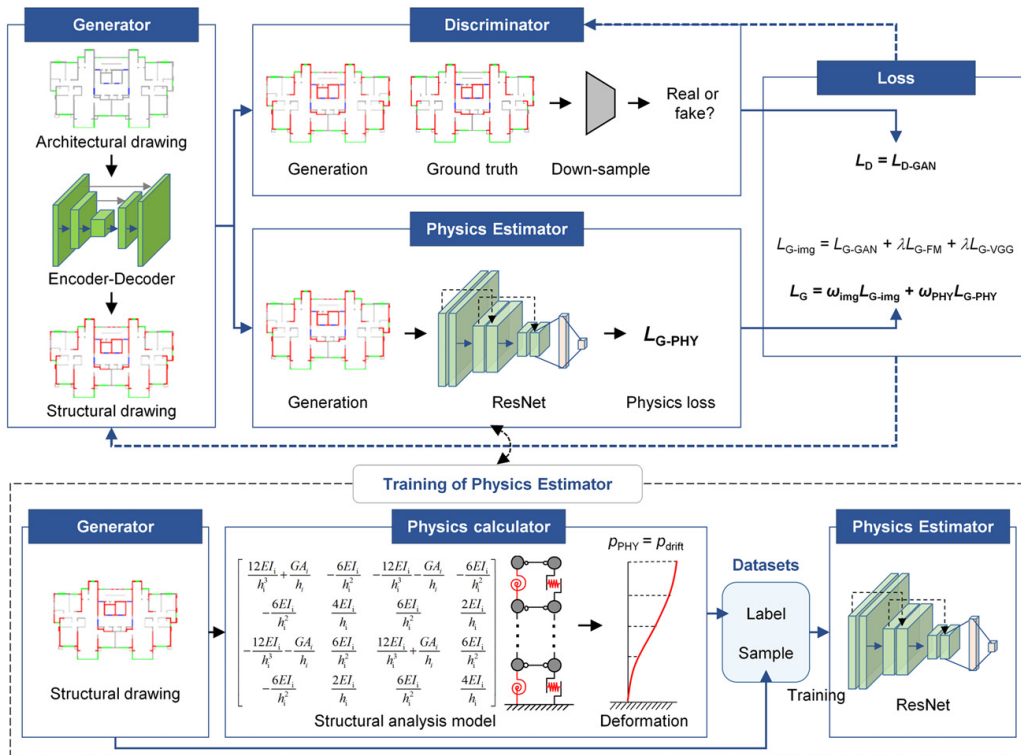
StructGAN이 보여준 형태 모방의 한계를 극복하기 위해, 2022년 칭화대학교와 ETH 취리히의 공동 연구진은 StructGAN-PHY(Physics-enhanced GAN)를 제안했다. 이 연구의 핵심 아이디어는 [그림 3-5]와 같이 기존 GAN 구조에 성능 추정 모듈(Physics-based Estimator)이라는 제3의 신경망을 결합하여, 생성 과정에 물리적 제약을 가하는 것이다.

[그림 3-5]의 아키텍처를 자세히 살펴보면, 이 프레임워크는 두 단계로 학습된다. 먼저, 하단의 'Training of Physics Estimator' 과정에서는 별도의 성능 예측 모델을 사전 학습시킨다. 이는 다양한 전단벽 배치 이미지(Structural drawing)를 입력받아, 간이 구조 해석 모델(Physics calculator)을 통해 계산된 변형(Deformation)과 같은 물리적 성능 지표를 예측하도록 훈련된다. 이 과정을 통해 'Physics Estimator'는 특정 도면이 주어졌을 때 그 구조적 성능을 빠르게 추정하는 능력을 갖추게 된다.

이후, 상단의 메인 학습 과정에서는 생성자(Generator)가 건축 평면도(Architectural drawing)로부터 전단벽 배치(Generation)를 생성한다. 이 생성된 이미지는 두 갈래로

평가된다. 하나는 기존 GAN처럼 판별자(Discriminator)에게 보내져 실제 도면 (Ground truth)과 비교되며 시각적 유사도를 평가받는다. 다른 하나는 사전 학습된 'Physics Estimator'에게 보내져 구조적 성능(Physics loss)을 평가받는다. 최종적으로 생성자의 손실 함수(Loss)는 이 시각적 손실(LD-GAN)과 물리적 손실(LG-PHY)을 모두 포함하게 된다. 이와 같은 설계 덕분에 모델은 단순히 원본 도면과 시각적으로 유사하게 그리는 것을 넘어, 구조적으로 더 우수한 성능을 갖는 방향으로 배치를 생성 하도록 학습된다.

실험 결과, StructGAN-PHY는 기존 StructGAN 대비 지진 취약도 평가에서 더 낮은 손실 비용과 높은 안전성을 확보했으며, 특히 고층 건물이나 고강도 내진 조건과 같은 까다로운 상황에서도 안정적인 성능을 보였다. 이 연구의 가장 큰 의의는 생성형 설계 모델이 단순한 데이터 모방을 넘어, 물리 법칙에 기반한 '성능 기반 설계 (Performance-based Design)'로 확장될 수 있다는 가능성을 제시했다는 점이다.



[그림 3-5] StructGAN-PHY 모델 구조 (GAN + Physics Estimator 결합)

3) StructDiffusion: 확산 모델을 통한 안정성과 다양성 향상 (Zhou et al., 2024)

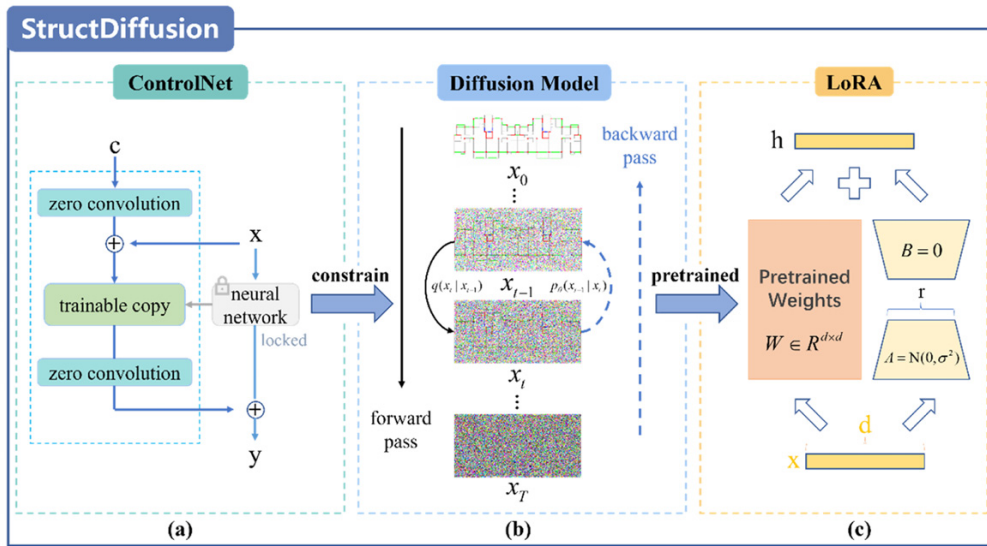
StructGAN-PHY는 물리적 성능을 결합하여 큰 진전을 이루었지만, 기반 모델인 GAN 자체가 가진 모드 붕괴(mode collapse), 학습 불안정성 등의 고질적인 문제는 여전히 과제로 남았다. 이를 해결하기 위해 2024년 중국 동지대학교 연구진은 차세대 생성 모델인 확산 모델(Diffusion Model)에 기반한 StructDiffusion을 제안했다.

[그림 3-6]은 StructDiffusion 프레임워크를 구성하는 세 가지 핵심 기술 요소의 결합을 보여준다. 이 프레임워크는 각 기술의 장점을 활용하여 높은 성능을 달성한다.

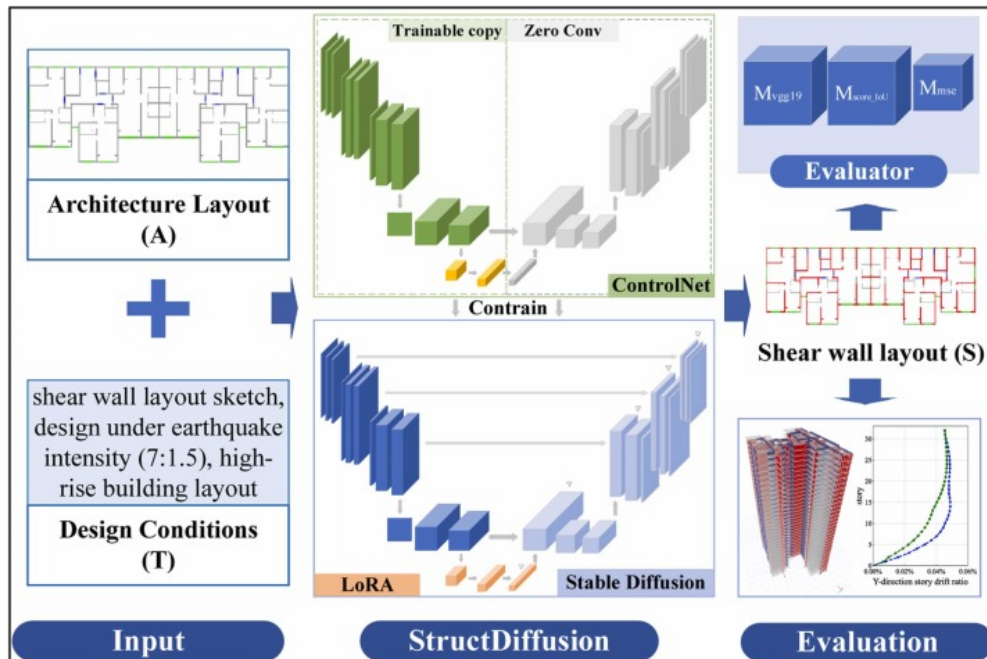
- 첫째, (b) 확산 모델(Diffusion Model)은 프레임워크의 핵심 엔진으로서, 노이즈로부터 점진적으로 이미지를 복원하며 고품질의 결과물을 생성한다.
- 둘째, (a) ControlNet은 생성 과정을 정밀하게 제어하는 가이드 역할을 수행한다. 이는 건축 평면도와 같은 조건 이미지를 입력받아, 확산 모델의 각 노이즈 제거 단계에 제약(constrain)을 가함으로써 최종 생성물이 주어진 평면도의 경계선을 벗어나지 않도록 정밀하게 유도한다.
- 셋째, (c) LoRA(Low-Rank Adaptation)는 거대 모델을 효율적으로 튜닝하는 기법이다. 수십억 개의 파라미터를 가진 사전 학습 가중치(Pretrained Weights) 전체를 재학습시키는 대신, 훨씬 적은 수의 파라미터를 가진 작은 어댑터만 추가하여 학습시킨다. 이를 통해 250쌍이라는 비교적 적은 데이터만으로도 Stable Diffusion과 같은 거대 모델을 전단벽 생성이라는 특정 작업에 맞게 성공적으로 최적화할 수 있었다.

이러한 세 가지 기술의 결합을 통해 StructDiffusion은 [그림 3-7]과 같이 실무와 연계된 End-to-End 워크플로우를 구현했다. 건축 평면도(Architecture Layout)와 텍스트 기반의 설계 조건(Design Conditions)을 입력(Input)으로 받아, 학습된 모델이 전단벽 배치도(Shear wall layout)를 생성한다. 이 과정의 가장 큰 진전은 생성된 이미지 배치를 기반으로 ETABS와 같은 상용 구조해석 소프트웨어의 모델을 자동으로 구축하고 성능을 평가(Evaluation)하는 단계까지 포함했다는 점이다.

결론적으로 StructDiffusion은 단순히 시각적 패턴을 모방하거나 성능을 보조적으로 반영하는 수준을 넘어, 조건 제어·성능 검증·해석 연계까지 아우르는 실무 지향적 프레임워크로 발전했다는 점에서 큰 의의가 있다. 이는 이미지 기반 설계 자동화 연구가 이제 실제 설계 프로세스와 접목될 수 있는 단계로 나아가고 있음을 보여주는 중요한 사례이다.



[그림 3-6] StructDiffusion 모델 구조
((a)ControlNet, (b)Diffusion, (c)LoRA의 결합)



[그림 3-7] StructDiffusion의 End-to-End 워크플로우

2. 2. 이미지 데이터 기반 접근법 종합 및 지반공학 적용 가능성

1) 이미지 데이터 기반 접근법의 기술적 진화와 의의

앞서 살펴본 StructGAN에서 StructDiffusion에 이르는 일련의 연구들은 이미지 기반 생성형 설계가 걸어온 뚜렷한 기술적 진화 과정을 보여준다. 초기의 연구는 GAN을 활용하여 설계 데이터에 내재된 시각적 패턴을 모방하는 수준에 머물렀다면, 후속 연구는 물리 기반 성능 예측 모델을 결합하여 성능 기반 설계로 나아갔다. 그리고 가장 최신 연구는 확산 모델과 제어 기술을 통해 생성 품질을 극대화하고 상용 소프트웨어와 연계하는 실무 지향적 워크플로우를 구현하는 단계에 이르렀다.

이러한 기술적 발전은 비단 전단벽 설계에만 국한되지 않는다. [표 3-1]과 같이 건축, 도시, 기계 등 다양한 공학 분야에서 이미지 기반 생성형 AI는 설계 초기 단계의 창의적인 아이디어를 발상하거나, 반복적인 도면 작업을 자동화하는 데 폭넓게 활용되고 있다.

[표 3-1] 다양한 공학 분야의 이미지 기반 생성형 AI 적용 사례

분야	주요 과업	활용 기술	주요 성과 및 의의
건축	전단벽 자동 배치	GAN, Diffusion	건축 평면도 이미지 기반 합리적인 전단벽 배치를 자동 생성
도시	도시 건물 레이아웃 생성	GAN, CycleGAN	부지 경계와 설계 조건 기반 2D 건물 레이아웃 생성
기계	위상 최적화 (Topology Opt.)	GAN, VAE	경량화, 고강성 등 목표 성능을 만족하는 부품의 2D 형상 생성
제조	제품 외형 및 텍스처 생성	GAN, Diffusion	스케치, 텍스트를 기반으로 제품의 2D 렌더링, 텍스처 등의 시안 생성

2) 지반공학 분야 적용 가능성 탐색

이러한 이미지 기반 접근법을 지반공학 분야에 적용한다면, 다음과 같은 시나리오를 구상해볼 수 있다.

- 초기 부지 계획 및 개략 설계: 광역 부지의 지형도(이미지)를 입력받아, 절토 및 성토 영역을 개략적으로 구분하고 옹벽이나 사면 보강이 필요한 구간의 위치와 대략적인

형식을 시각적으로 생성하는 데 활용될 수 있다. 이는 복잡한 계산 이전에 신속한 대안 검토를 가능하게 할 것이다.

- 지층 단면도 생성 및 해석: 시추 조사로 얻은 불연속적인 주상도 데이터를 바탕으로, 통계적으로 가장 가능성이 높은 2차원 지층 단면도(이미지)를 생성하는 데 활용될 수 있다. 이는 불확실성이 높은 지반 조건을 시각화하고, 다양한 지층 시나리오에 대한 해석의 기반 자료로 사용될 수 있다.
- 터널 단면 보강 패턴 설계: NATM 터널 등의 굴착 단면도(이미지)가 주어졌을 때, 지반 조건에 따라 학습된 록볼트(Rock Bolt)나 슛크리트의 표준 보강 패턴을 자동으로 생성하는 데 적용할 수 있다.

3) 내재적 한계와 과제

앞서 살펴본 바와 같이 이미지 기반 접근법은 상당한 잠재력을 가지고 있지만, 실제 지반공학 문제에 적용할 때는 몇 가지 고려해야 할 점들이 있다.

- 물리 정보의 부재 가능성: 2D 도면 이미지는 형태적 특징을 잘 표현하지만, 안전을 계산에 필요한 핵심 물리 정보(예: 지반의 전단강도 정수, 지하수위, 하중 조건 등)를 모두 포함하지 않을 수 있다. AI가 옹벽 단면 이미지를 보고 그 형태를 학습할 수는 있지만, 해당 단면이 특정 토압 조건에서 안정성을 확보하는지 판단하기 위해서는 이미지 외 추가적인 정보가 필요할 수 있다.
- 데이터의 비표준성: 건축 평면도와 달리, 지반구조물 설계는 현장마다 지반 조건이 달라 표준화된 대규모 이미지 데이터셋을 구축하는 데 상대적으로 더 많은 노력이 필요할 수 있다. 이는 모델의 일반화 성능에 영향을 미칠 수 있는 요인이다.
- 2차원 표현의 한계: 지반의 파괴 거동은 본질적으로 3차원 현상이다. 2차원 단면도 이미지만을 학습할 경우, 3차원적인 파괴 모드나 공간적 상호작용을 온전히 반영하지 못할 가능성이 있다.

이러한 점들을 고려할 때, 지반공학 분야에서 이미지 기반 접근법은 개략적인 형태를 제안하거나 시각화 자료를 생성하는 보조적인 역할로서 높은 활용 가치를 가질 것으로 기대된다. 다만, 구조적 안정성과 정량적 성능이 핵심인 상세설계 단계에 직접 적용하기 위해서는 추가적인 검증이나 보완이 필요할 수 있다. 따라서 이미지 기반 접근법의 한계를 보완하고 정량적 성능을 직접 제어하기 위한 대안으로서, 설계 변수 자체를 다루는 다음 절의 파라메트릭 접근법에 대한 심층적인 분석이 필요하다.

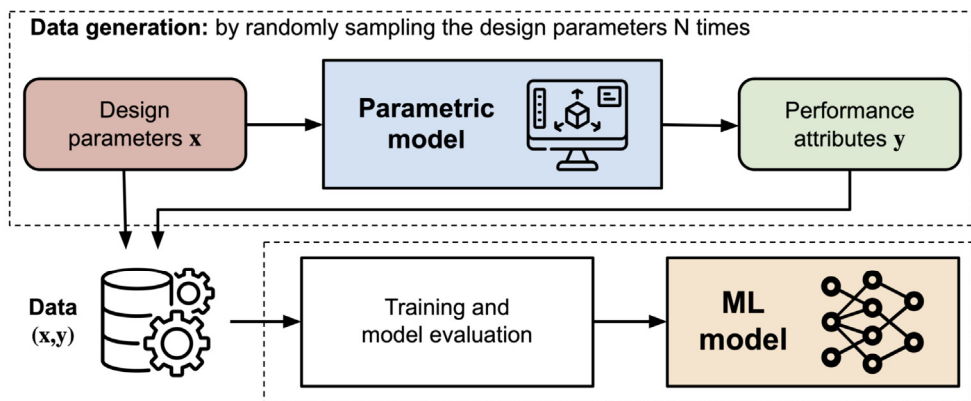
3. 파라메트릭 데이터 기반

앞선 이미지 기반 접근법이 설계안의 공간적·형태적 패턴을 시각 데이터로부터 학습하는 데 강점이 있다면, 파라메트릭 기반 접근법은 설계의 '성과와 관련된 정량적 변수'를 직접 다룬다는 점에서 차별화된다. 이 접근법은 [그림 3-8]과 같이 설계안을 구성하는 핵심 변수(Design parameters, x)를 수치적 매개변수로 정의하고, 시뮬레이션 등을 통해 얻어진 성능 지표(Performance attributes, y)와의 관계를 학습한다.

이 방법의 주요 장점은 정량적 제어성과 예측 가능성에 있다. 설계자는 안전율 등의 특정 성능 수준을 조건으로 명확하게 지정할 수 있으며, 모델은 이를 충족하는 다양한 설계 변수 조합을 제시한다. 이는 시각적 패턴 학습만으로는 공학적 타당성을 보장하기 어려웠던 이미지 기반 접근법의 한계를 보완하는 방식이다.

물론 파라메트릭 접근법에도 해결해야 할 과제는 존재한다. 설계 공간의 매개변수화가 부적절하면 결과의 품질이 제한될 수 있으며, 변수 차원이 커질수록 학습에 필요한 데이터가 기하급수적으로 증가하는 차원의 저주(curse of dimensionality) 문제가 발생할 수 있다. 또한, 실제 성능 함수가 복잡하고 비선형적일 경우, 이를 정확히 모델링하는 데 어려움이 따른다.

본 절에서는 먼저 파라메트릭 접근법의 핵심 패러다임인 '성능 기반 역설계'의 개념을 정립하고, 이어서 이를 구현한 대표적인 연구 사례들을 통해 기술의 역할과 가능성을 심층적으로 탐색한다.



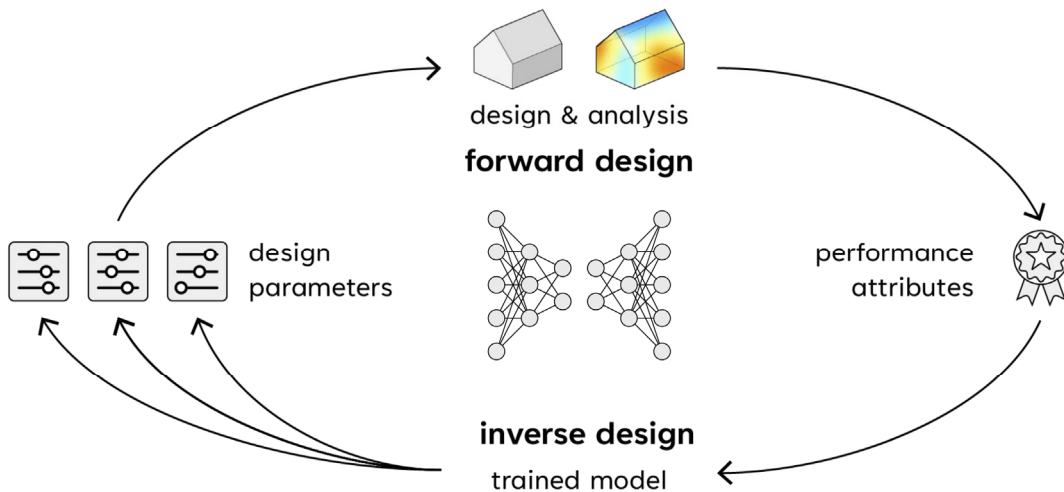
[그림 3-8] 파라메트릭 기반 생성형 AI의 기본 워크플로우 (Salamanca, 2025)

3. 1. 주요 연구 사례 분석: 성능 기반 역설계

전통적인 설계 과정은 [그림 3-9]의 위쪽 경로와 같이, 주어진 설계 변수(design parameters)로 구조물을 모델링한 뒤 시뮬레이션을 통해 성능(performance attributes)을 확인하는 정방향 설계(forward design) 방식에 기반한다. 이는 설계안을 수정한 뒤 다시 성능을 검토하는 반복적이고 시간이 많이 소요되는 과정이다.

생성형 AI를 활용한 파라메트릭 접근법은 [그림 3-9]의 아래쪽 경로처럼 이러한 과정을 역전시킨다. 즉, 설계자가 원하는 성능 목표를 먼저 제시하면 학습된 모델(trained model)이 그 목표를 만족하는 다양한 설계 변수 조합을 생성해내는 역설계(inverse design)를 가능하게 한다. 이는 단순히 하나의 최적해를 찾는 기존의 최적화(optimization) 방식과는 근본적으로 다르다. 최적화가 정해진 규칙에 따라 최고의 해 하나를 도출하는 데 집중한다면, 역설계는 데이터 기반 학습을 통해 성능은 동등하지만 형태나 특성은 다양한 대안을 탐색할 기회를 제공한다.

이러한 워크플로우의 구현에는 조건부 변이형 오토인코더(CVAE)와 같은 생성 모델이 주로 활용된다. CVAE는 수많은 설계 데이터로부터 성능 조건과 설계 변수 사이의 복잡한 관계를 학습한다. 학습이 완료된 모델의 디코더(decoder)는 특정 성능 조건을 입력받으면, 해당 조건을 만족하는 새롭고 타당한 설계안들을 실시간으로 다양하게 생성해낼 수 있다. 이처럼 생성형 AI는 설계 패러다임을 반복적 검증에서 목표 지향적 생성으로 전환하는 데 기여한다.



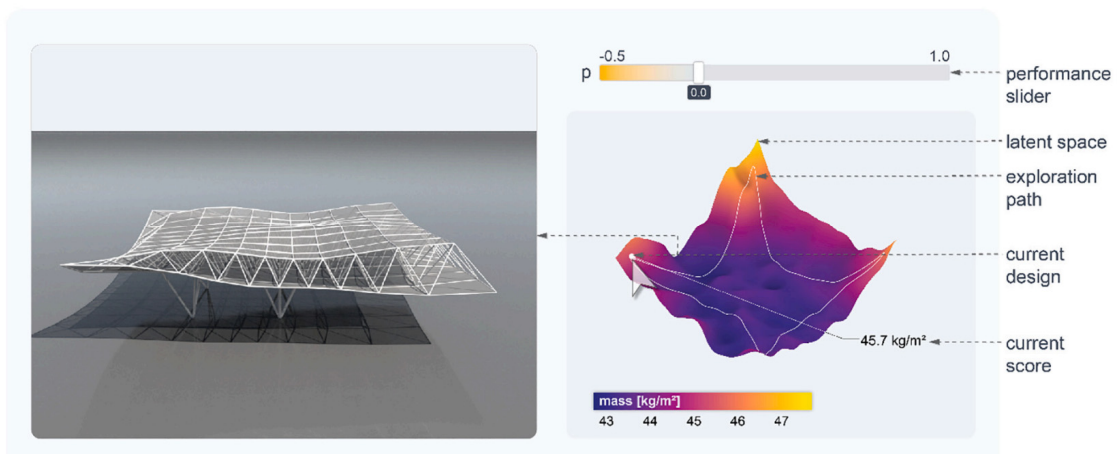
[그림 3-9] 정방향 설계와 성능 기반 역설계의 개념 비교 (Salamanca, 2025)

1) 대표 적용 사례 1: 직관적 설계 공간 탐색 (Danhaive and Mueller, 2021)

성능 기반 역설계가 어떻게 복잡한 설계 문제를 직관적인 탐색의 과정으로 바꾸는지는 2021년 MIT에서 수행된 'Design Subspace Learning' 연구에서 확인할 수 있다. 이 연구는 36개의 변수로 제어되는 복잡한 장스팬 지붕 구조물의 설계를 목표로 한다. 36차원의 설계 공간을 인간이 직접 탐색하는 것은 사실상 불가능하다.

연구진은 이 문제를 해결하기 위해 성능 조건부 VAE(PVAE)를 사용하여, 36차원의 설계 공간을 단 2차원의 잠재 공간(Latent Space)으로 압축했다. 동시에, 설계자가 원하는 성능 수준(예: 상위 10% 성능)을 'p-value'라는 0과 1 사이의 값으로 입력할 수 있게 했다.

그 결과, [그림 3-10]과 같이 설계자는 단지 2차원 평면(latent space) 위에서 마우스를 움직이는 것만으로 수많은 고성능 설계안들의 형태 변화를 실시간으로 확인할 수 있었다. 또한, 'performance slider'를 조절하며 성능 조건을 완화하거나 강화하면서, 동일한 위치의 점이 어떻게 다른 형태의 설계안으로 변화하는지 직관적으로 탐색할 수 있었다. 이처럼 복잡한 36차원 최적화 문제는 '2차원 공간 탐색 + 1개의 성능 슬라이더'라는 보다 직관적인 설계 과정으로 전환되었다. 이는 생성형 AI가 설계 공간 탐색을 보조하는 효과적인 도구로 활용될 수 있음을 보여준 대표적인 사례이다.



[그림 3-10] 잠재 공간과 성능 슬라이더를 활용한 직관적 설계 탐색

2) 대표 적용 사례 2: 설명가능성(XAI)을 통한 신뢰도 확보 (Balmer et al., 2024)

생성형 AI가 아무리 뛰어난 설계안을 제안하더라도, 엔지니어가 그 결과를 신뢰할 수 없다면 실무에 적용되기는 어렵다. 특히 안전과 직결되는 구조 설계 분야에서는 AI 모델이 "왜" 그런 제안을 했는지 이해하는 것이 매우 중요하다. 이러한 블랙박스 문제를 해결하기 위한 기술이 바로 설명가능 AI(Explainable AI, XAI)이다.

2024년 ETH 취리히 연구진이 발표한 보행자 교량 설계 연구는 [그림 3-11]과 같이 CVAE(Conditional VAE)에 XAI를 결합하여 모델의 신뢰도를 확보한 사례이다. 연구의 핵심은 CVAE 모델이 미분 가능 함수라는 점을 활용한 민감도 분석이다.

민감도 분석은 "특정 설계 변수를 조금 바꿨을 때, 성능이 얼마나 변하는가?"를 정량적으로 보여준다. 예를 들어, 아래 그림의 다이어그램은 교량의 비용(Cost)이 거더 두께(Thickness of girder)에 가장 민감하게 반응하고, 거더 높이(Height of girder)가 그다음으로 큰 영향을 미친다는 것을 명확히 보여준다. 이러한 정보는 엔지니어의 직관 및 공학적 원리와 일치하며, 모델이 데이터로부터 타당한 물리적 관계를 학습했음을 입증한다.

이처럼 XAI는 단순히 결과물을 생성하는 것을 넘어, 설계 변수와 성능 간의 인과관계에 대한 통찰을 제공한다. 이를 통해 설계자는 AI의 제안을 맹목적으로 수용하는 것이 아니라, 공학적 판단의 근거로 활용하며 '인간-AI 협업'을 지원할 수 있다. 이는 생성형 AI가 실무에 성공적으로 정착하기 위해 중요한 요소로 고려된다.



[그림 3-11] 설명가능 AI(XAI)가 적용된 교량 설계 인터페이스

3. 2. 파라메트릭 데이터 접근법 종합 및 지반공학 적용 가능성

1) 파라메트릭 접근법의 기술적 의의

앞서 살펴본 대표 사례들은 파라메트릭 기반 접근법이 기존의 설계 패러다임을 근본적으로 전환할 수 있는 강력한 잠재력을 가지고 있음을 명확히 보여준다. 초기 연구가 성능 조건부 VAE를 통해 복잡한 고차원 설계 공간을 저차원의 성능 맵으로 압축하여 직관적인 탐색을 가능하게 하는 데 집중했다면, 후속 연구들은 이를 더욱 발전시켜 다양한 공학 문제에 적용하고 있다. 특히 최근에는 미분 가능한 모델의 장점을 활용하여 민감도 분석과 같은 설명가능 AI(XAI) 기법을 결합함으로써, AI 모델의 예측 근거를 제시하고 엔지니어의 신뢰를 확보하는 단계로 나아가고 있다. 이러한 기술적 흐름은 파라메트릭 접근법이 단순히 대안을 생성하는 것을 넘어, 성능 기반 역설계(Inverse Design), 직관적 공간 탐색, 신뢰성 확보라는 세 가지 핵심 가치를 제공함을 의미한다. 파라메트릭 접근법은 특정 분야에 국한되지 않고, 정량적 변수와 성능이 중요한 여러 공학 분야에서 그 효용성을 입증하고 있다.

[표 3-2] 다양한 공학 분야의 파라메트릭 기반 생성형 AI 적용 사례

분야	주요 과업	활용 기술	주요 성과 및 의의
건축	보행자 교량 개념설계	VAE	성능 기반 역설계 및 XAI를 통한 직관적 설계 공간 탐색
항공	에어포일(날개 단면) 형상 설계	VAE, GAN	특정 공력 성능 조건을 만족하는 새로운 에어포일 형상 생성
기계	선박 선체(Hull) 형상 생성	VAE, Diffusion	다중 목표 및 제약조건을 만족하는 고성능 선체 형상 생성
화학	신규 분자 구조 생성	VAE, GAN	목표 특성을 만족하는 신규 약물 후보 분자 구조 생성

2) 지반공학 분야 적용 가능성 탐색

이러한 파라메트릭 접근법은 지반공학 분야의 여러 문제에 직접적으로 적용될 수 있는 잠재력을 가진다.

- 옹벽 단면 설계: 주어진 지반 조건과 옹벽 높이에서 전도, 활동, 지지력에 대한 목표 안전율을 만족시키는 다양한 옹벽 단면(벽체 두께, 기초판 폭 등) 조합을 자동으로 생성할 수 있다.

- 사면 보강 설계: 목표 안전율 1.5와 같은 조건을 입력하면, 이를 만족하는 다양한 네일 및 앵커의 배치(길이, 간격, 각도 등) 대안을 탐색할 수 있다.
- 기초 구조물 설계: 상부 하중과 허용 침하량 조건에 따라, 최적의 기초 형식과 제원(폭, 깊이, 파일 개수 등)을 제안하는 데 활용될 수 있다.

3) 고려사항 및 본 연구의 전략

물론 이러한 잠재력에도 불구하고, 파라메트릭 접근법을 지반공학에 적용하기 위해서는 몇 가지 사항을 신중하게 고려해야 한다. 첫째, 학습 데이터에 대한 높은 의존성이다. 모델의 성능은 신뢰도 높은 대규모 데이터셋(기존 설계 사례 또는 수치해석 시뮬레이션)에 크게 의존하며, 이를 구축하기 위한 초기 비용과 시간이 요구된다. 둘째, 설계 공간의 적절한 매개변수화(Parameterization) 자체의 어려움이다. 만약 설계의 핵심을 반영하지 못하는 변수 체계를 사용한다면, 생성된 결과물의 품질과 다양성이 제한될 수 있다.

그럼에도 불구하고, 지반공학 설계는 최종적으로 '안전율' 등의 정량적 성능 목표를 만족시키는 수치적 제원의 최적 조합을 찾는 문제로 귀결되는 강력한 특성을 가지므로, 생성형 AI 기반 지반구조물 설계자동화의 가능성을 탐색하는 데 있어 파라메트릭 접근법은 가장 직접적이고 적절한 방식으로 판단된다. 이는 이미지 기반 접근법이 형태적 유사성은 모방할 수 있으나 안전율과 직결되는 물리 정보를 직접 다루기 어려운 한계를 보완한다.

이러한 이유로 본 연구에서는 파라메트릭 접근법을 핵심 방법론으로 설정하고, 5장에서 파일럿 연구를 통해 그 가능성과 한계를 심층적으로 검증한다. 또한, 앞서 제기된 데이터 의존성 및 복잡한 분포 학습의 한계를 극복하기 위한 방안으로, 최근 테이블 형태의 정형 데이터 생성에서도 뛰어난 성능을 보이는 확산 모델(Diffusion Model)의 적극적인 활용 역시 향후 중요한 연구 방향으로 고려될 수 있다. 이어지는 4장에서는 이러한 전략을 구체화하기 위해 지반구조물의 파라메트릭 특성을 심층적으로 분석할 것이다.

4. 텍스트 데이터 기반

텍스트 기반 생성형 설계는 인간의 언어를 직접 설계의 입력으로 활용한다는 점에서 가장 직관적이고 사용자 친화적인 접근법이다. 설계자는 복잡한 파라메트릭 모델이나 코드 대신 자연어로 자신의 요구사항을 서술할 수 있고, 시스템은 이를 해석하여 설계 지식이나 규정을 반영한 결과를 생성한다. 초기에는 단순한 규정 검색이나 문서 질의응답 수준에 머물렀으나, 최근 대규모 언어모델(LLM)의 발전과 함께 자연어 명령을 통한 설계 생성, 수정까지 가능해지며 설계 자동화의 중요한 축으로 부상하고 있다. 텍스트 기반 접근법은 설계 프로세스에 크게 두 가지 방식으로 기여한다. 첫째는 자연어 명령으로 설계를 직접 제어하는 지능형 인터페이스(Intelligent Interface)의 역할이며, 둘째는 방대한 설계 기준과 전문 지식을 정확하게 제공하여 설계자의 의사결정을 지원하는 설계 보조(Design Co-pilot)의 역할이다.

이 접근법의 가장 큰 장점은 접근성과 지식 통합 능력에 있다. 전문 소프트웨어나 수학적 모델링 경험이 없는 사용자도 자연어 인터페이스를 통해 설계 의도를 효과적으로 전달할 수 있으며, 동시에 방대한 설계 기준과 법규를 실시간으로 반영할 수 있다. 특히 검색 증강 생성(RAG) 기법을 결합하면 외부 데이터베이스에서 법규·안전 지침·설계 기준을 검색해 결과에 반영할 수 있어, 도메인 특화 지식의 정확성이 크게 향상된다.

그러나 텍스트 기반 접근법은 태생적 한계도 지닌다. 자연어는 기하학적 형태나 공간적 비례를 정확히 표현하기 어렵기 때문에 복잡한 구조 치수나 세밀한 배치 설계를 직접 생성하는 데에는 제약이 따르며, LLM 특유의 환각(hallucination) 문제로 인해 실제 존재하지 않는 규정이나 부정확한 수치를 제시할 위험이 있다. 따라서 전문가의 검증 과정과, CAD·BIM 등 정량적 설계 도구와의 연계가 필수적이다.

본 절에서는 이러한 텍스트 기반 접근법의 성과와 한계를 정리하고, 실제 적용을 보여주는 두 가지 대표 사례를 검토한다.

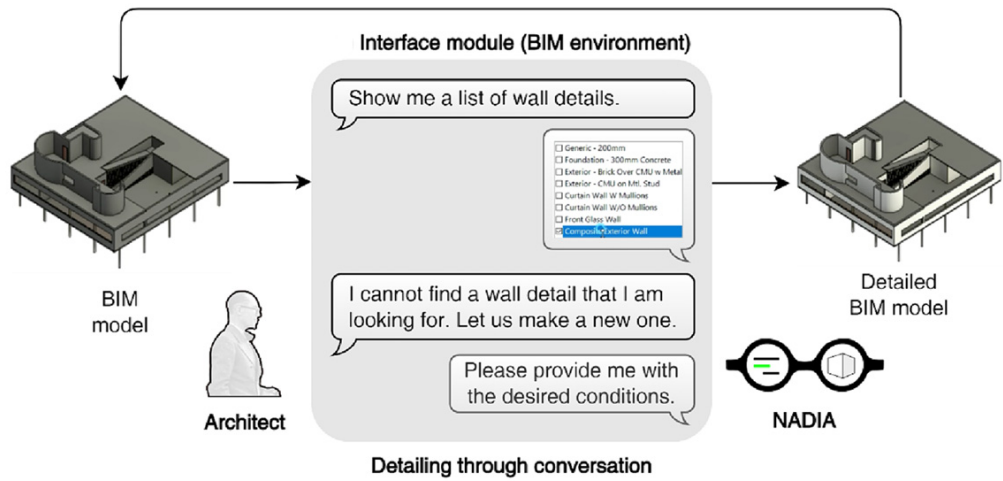
4. 1. 주요 연구 사례 분석: BIM 상세설계 및 건설안정정보 생성

1) 대표 적용 사례 1: NADIA - 자연어 기반 BIM 상세설계 (Jang et al., 2024)

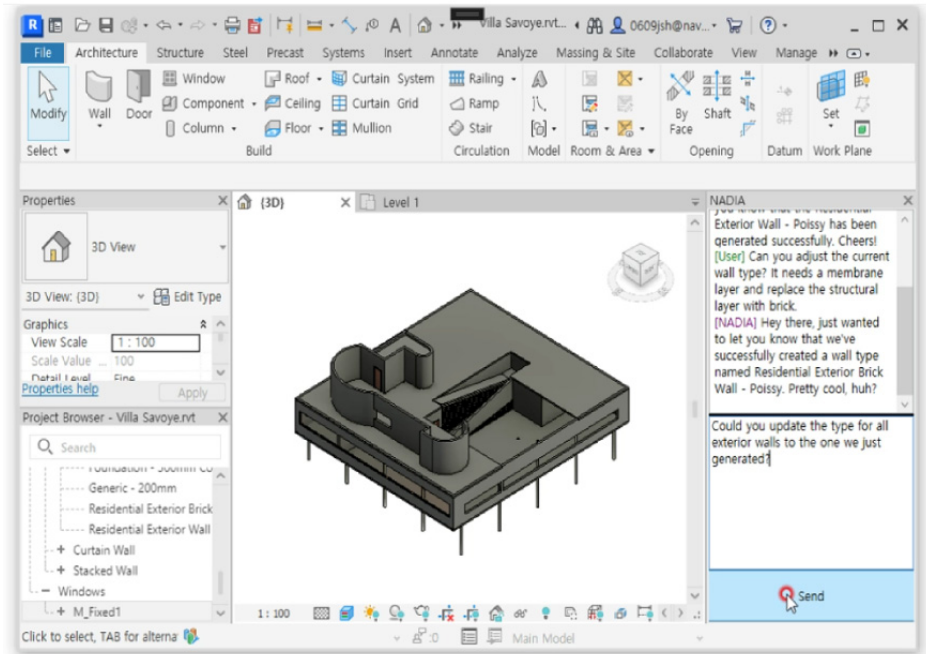
NADIA(Natural-language-based Architectural Detailing through Interaction with AI)는 2024년 연세대학교 연구진이 제안한 시스템으로, 자연어를 통한 BIM(Building Information Modeling) 환경에서의 건축 외벽 상세설계 자동화를 지원한다. 기존 BIM 소프트웨어는 기능이 방대하고 사용법이 복잡해 전문가가 아닌 설계자가 직접 다루기 어렵다는 한계가 있었다. NADIA는 이러한 문제를 해결하기 위해 [그림 3-12]와 같이 대화형 자연어 인터페이스를 통해 상세설계를 수행하도록 설계되었다.

NADIA의 핵심 원리는 LLM-BIM 체이닝(Chaining) 기법에 있다. 사용자가 "Poissy 지역 주택에 어울리는 흰색 마감의 외벽을 제안해줘"와 같은 자연어 명령을 입력하면, 시스템은 이를 여러 하위 작업으로 분해한다. 먼저 LLM이 사용자의 의도를 해석하여 벽체 레이어, 재료, 두께 등의 속성을 포함하는 구조화된 데이터(JSON 형식)로 변환한다. 그 후, 이 데이터를 BIM 소프트웨어의 API와 연동하여 실제 BIM 객체를 생성하거나 수정한다.

성능 평가 결과, NADIA는 설계자가 요구한 조건을 준수하는 데 평균 83.3%의 정확도를 보였으며, ASHRAE 90.1-2019 열성능 기준과 같은 공학적 요구사항은 98.5%의 높은 정확도로 충족했다. 이는 NADIA가 단순한 '자연어-코드 변환기'를 넘어, 복잡한 모델링 작업을 자동화하고 공학적 지식까지 일부 내재화했음을 보여준다. NADIA는 "자연어 → BIM 상세설계"라는 새로운 워크플로우를 실현함으로써, LLM이 설계 소프트웨어의 직관적인 인터페이스 역할을 수행할 수 있는 가능성을 입증한 대표적인 사례로 평가된다.



[그림 3-12] NADIA의 대화형 BIM 상세설계 워크플로우



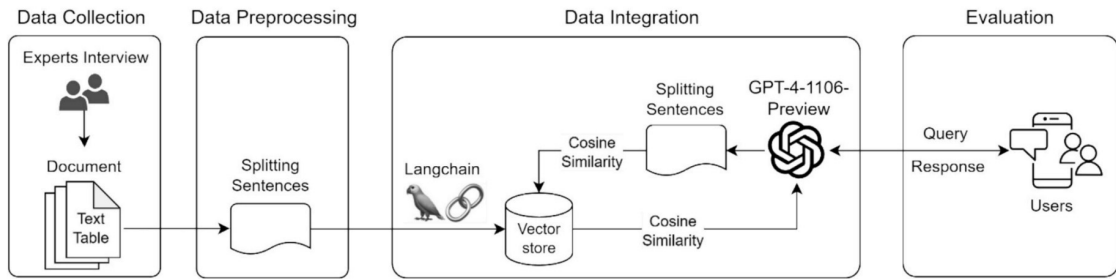
[그림 3-13] NADIA 시스템의 자연어 기반 BIM 설계 인터페이스

2) 대표 적용 사례 2: RAG-GPT - 건설안전정보 생성 (Uhm et al., 2025)

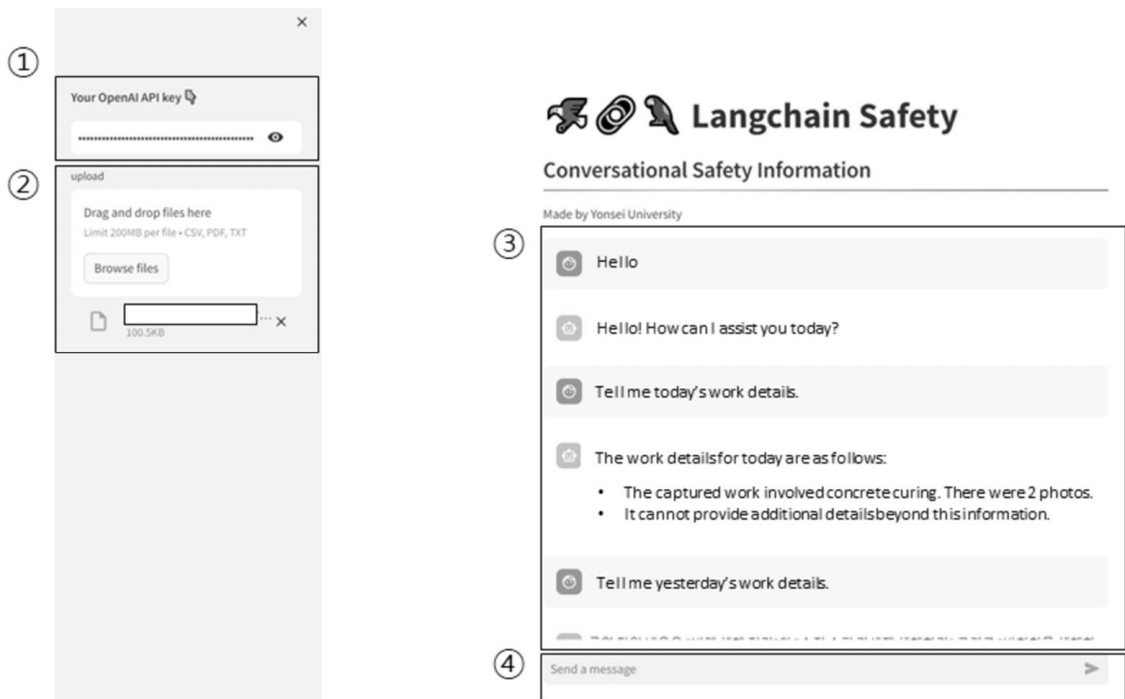
RAG-GPT는 2025년 연세대학교 연구진이 개발한 검색 증강 생성(Retrieval-Augmented Generation, RAG) 기반 시스템으로, 건설 현장에서 요구되는 신뢰도 높은 안전정보를 생성하는 것을 목표로 한다. 기존 GPT 모델들은 건설안전 분야에서 수치 정보 오류, 세부 규정 누락, 환각(hallucination) 문제로 인해 신뢰도가 낮다는 한계를 보였다. RAG-GPT는 이러한 문제를 해결하기 위해, [그림 3-14]과 같이 LLM을 방대한 외부 지식 데이터베이스와 연계하여 답변의 정확성과 신뢰도를 높이도록 설계되었다.

RAG의 핵심 원리는 사용자의 질문에 대해 LLM이 자체적으로 답변을 생성하기 전에, 먼저 벡터화된 외부 데이터베이스(Vector store)에서 가장 관련성 높은 정보를 '검색(Retrieval)'하는 단계를 거치는 것이다. 이 연구에서는 KOSHA 안전 가이드라인, 관련 법규, 사고 사례 보고서 등을 데이터베이스로 구축했다. LLM은 이렇게 검색된 신뢰할 수 있는 정보를 바탕으로 답변을 생성하므로, 환각 현상을 획기적으로 줄이고 사실에 기반한 정확한 정보 제공이 가능하다.

성능 평가 결과, 수치 정확도 측면에서 RAG-GPT는 80%의 정답률을 기록하여, 다른 GPT 모델들(0~50%) 대비 압도적으로 우수한 성능을 보였다. 또한 전문가 패널 평가에서도 관련성(4.45/5), 정확성(4.41/5), 완전성(4.10/5) 등 모든 항목에서 가장 높은 점수를 받았다. RAG-GPT는 건설 현장에서 "검색-생성 결합"을 통해 신뢰도 높은 정보 제공의 가능성을 보여준 대표적 사례로, LLM 기반 설계지원 기술의 실무적 확장성을 입증했다는 점에서 큰 의미를 가진다.



[그림 3-14] RAG-GPT 모델 개발 및 평가 프로세스
(건설안전 데이터베이스, LangChain 벡터검색, GPT-4 통합 프로세스)



[그림 3-15] 대화형 건설안전정보 생성 시스템 (RAG-GPT) 인터페이스

4. 2. 텍스트 기반 접근법 종합 및 지반공학 적용 가능성

1) 텍스트 기반 접근법의 기술적 의의

앞서 살펴본 NADIA와 RAG-GPT 사례는 텍스트 기반 생성형 설계가 걸어온 뚜렷한 기술적 진화 과정을 보여준다. 초기 Transformer 기반 모델이 자연어 이해와 생성의 가능성을 열었다면, 최신 연구들은 LLM을 BIM과 같은 전문 소프트웨어의 API와 연동하거나(LLM-BIM Chaining), 외부 지식 데이터베이스와 결합하는(RAG) 단계로 발전했다.

이러한 기술적 발전은 텍스트 기반 접근법이 단순한 질의응답을 넘어, 다음과 같은 두 가지 핵심적인 역할을 수행할 수 있음을 의미한다. 첫째, 직관적인 제어 인터페이스로서 복잡한 소프트웨어의 기능을 자연어 명령으로 자동화한다. 둘째, 신뢰도 높은 지식 전문가로서 방대한 설계 기준, 법규, 안전 지침 등을 정확하게 검색하고 요약하여 제공한다.

2) 지반공학 분야 적용 가능성 탐색

이러한 텍스트 기반 접근법을 지반공학 분야에 적용한다면, 다음과 같은 시나리오를 구상해볼 수 있다.

- 설계 기준 검토 자동화: 설계자가 "내진 1등급 지역의 흙막이 벽체에 대한 설계 기준을 알려줘"라고 질문하면, RAG 시스템이 내장된 설계 기준 데이터베이스를 검색하여 해당 조항과 요구사항을 정확하게 제시한다. 이는 수작업으로 법규를 찾는 시간을 획기적으로 줄여준다.
- 보고서 초안 작성: 파라메트릭 모델링으로 도출된 옹벽의 설계 제원(두께, 철근량 등)과 안전율 계산 결과를 바탕으로, "이 결과를 이용해 안정성 검토 보고서의 초안을 작성해줘"라고 명령하면, LLM이 표준 보고서 양식에 맞춰 서술적인 보고서를 자동으로 생성한다.
- 개념 설계 보조: 초기 단계에서 "연약지반 위에 성토를 계획 중인데, 적용 가능한 지반 개량 공법의 종류와 각각의 장단점을 알려줘"라고 질문하면, LLM이 DCM, PBD 등 다양한 공법의 특징과 적용 사례를 요약하여 설계자의 의사결정을 지원한다.

3) 고려사항 및 본 연구의 전략

그러나 텍스트 기반 접근법의 역할과 한계를 명확히 이해하는 것이 중요하다. 자연어는 옹벽의 두께나 보강재의 간격과 같은 정밀한 수치적, 기하학적 정보를 생성하고 최

적화하는 데에는 근본적인 한계를 가진다. 또한 LLM 고유의 환각 문제는, RAG를 통해 상당 부분 완화될 수 있지만, 여전히 전문가의 최종 검증을 필요로 한다.

결론적으로, 텍스트 기반 접근법은 정량적인 설계안을 직접 생성하는 '핵심 엔진' 역할보다는, 설계자가 복잡한 정보와 소프트웨어를 더 쉽고 정확하게 다룰 수 있도록 돕는 '지능형 인터페이스' 또는 '설계 보조(Co-pilot)'로서의 역할에 더 적합하다고 판단된다.

따라서 본 연구의 전체적인 프레임워크에서 텍스트 기술은 파라메트릭 기반의 핵심 설계 생성 모델과 융합되어, 설계 기준을 검토하거나 생성된 설계안에 대한 보고서를 작성하는 등 설계 프로세스 전반의 효율성을 높이는 중요한 보조 도구로 활용될 수 있을 것이다.

제4장 지반구조물 설계를 위한 생성형 AI 적용 전략

1. 지반구조물 설계의 고유 난제와 자동화 필요성

앞서 3장에서는 데이터 유형에 따른 다양한 생성형 AI 기반 설계 접근법을 살펴 보았다. 이제 본 장에서는 연구의 핵심 분야인 지반구조물 설계로 논의의 초점을 옮겨, 이 분야가 가진 고유한 특성과 난제를 분석하고 이를 해결하기 위한 생성형 AI의 적용 전략을 수립한다.

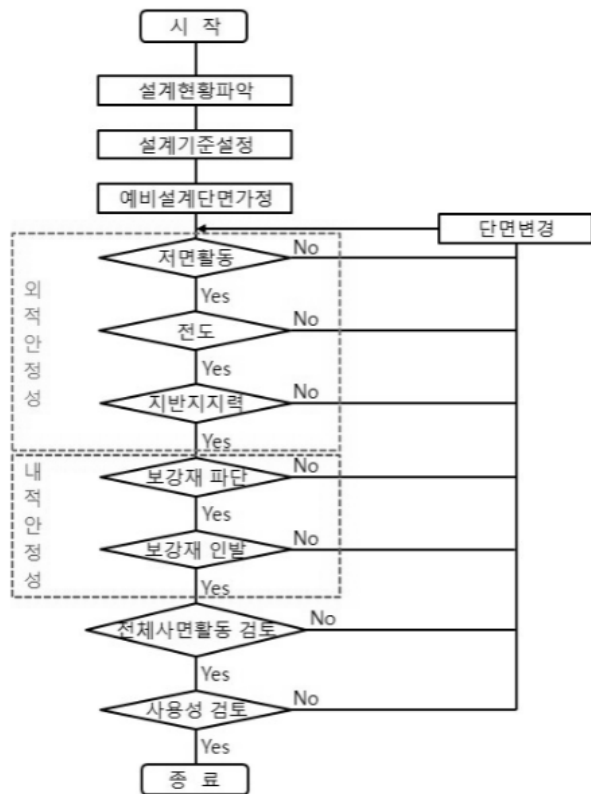
타 공학 분야와 달리, 지반공학 설계는 인공 재료가 아닌 자연 재료 ‘흙’을 대상으로 한다는 점에서 근본적인 복잡성을 내포한다. 강재나 콘크리트처럼 물성이 균일하게 관리되는 재료와 달리, 흙은 지층의 생성 과정과 역사에 따라 그 특성이 공간적으로 매우 불균질하며 예측하기 어려운 불확실성을 가진다. 이러한 지반공학 설계의 고유한 난제는 다음과 같이 요약할 수 있으며, 이는 실제 프로젝트에서 공기 지연과 비용 상승의 주된 원인으로 작용한다.

- 지반의 본질적 불확실성: 시추 조사를 통해 얻을 수 있는 정보는 광범위한 부지의 극히 일부 지점에 대한 데이터에 불과하다. 이처럼 제한된 정보를 바탕으로 전체 지반의 거동을 예측해야 하므로, 지반정수의 공간적 불균질성과 불확실성은 설계의 가장 큰 난제로 작용한다. 이는 결정론적(deterministic)인 단일 설계안 도출의 한계를 명확히 보여준다.
- 복잡한 지반-구조물 상호작용: 지반 위에 놓이는 구조물은 단순히 하중을 전달하는 것을 넘어, 지반과 상호 변형하며 복잡한 거동을 보인다. 이러한 비선형적인 상호작용은 해석을 매우 어렵게 만들며, 설계 변수의 미세한 변화가 전체 시스템의 안정성에 예상치 못한 영향을 미치기도 한다.
- 경험 의존적 설계 관행: 앞서 언급된 불확실성과 복잡성 때문에, 지반설계는 이론적 계산만으로는 완결되기 어렵다. 따라서 유사한 지반 조건에서의 과거 성공 사례, 지역별 설계 관행, 시공 중 발생할 수 있는 변수 등 수치화하기 어려운 요소들을 종합적으로 고려하는 설계자의 경험과 암묵적 지식에 의존하는 경향이 있다.

이러한 난제들로 인해, 전통적인 지반설계는 초기 설계안을 가정한 뒤 안정성 기준을 만족할 때까지 수많은 해석과 검토를 반복하는 노동집약적인 형태를 띠게

된다. [그림 4-1]은 비교적 절차가 표준화된 보강토 옹벽의 설계 순서도를 통해 이러한 반복적 과정을 단적으로 보여준다. 이 순서도의 각 의사결정 단계는 앞서 언급한 불확실성과 복잡한 상호작용을 내포하고 있으며, 어느 한 기준이라도 만족하지 못하면 설계자는 다시 '단면 변경'으로 돌아가 경험에 기반한 또 다른 가정을 시도해야 한다. 보강토 옹벽과 같은 비교적 간단한 구조물의 설계조차 이러한 시행착오를 거치며, 이는 더 복잡한 설계 문제에서 기하급수적으로 심화된다.

따라서 지반공학 분야에 필요한 설계자동화는 단순히 반복 계산을 줄이는 수준을 넘어, 불확실성 속에서 다양한 가능성을 탐색하고, 수식화하기 어려운 경험적 설계 지식을 데이터 패턴으로 학습하여 설계자의 의사결정을 효과적으로 지원할 수 있는 새로운 패러다임을 요구한다. 바로 이 지점에서 생성형 AI는 기존 자동화 기술의 한계를 뛰어넘는 혁신적인 해결책이 될 수 있다.



[그림 4-1] 보강토 옹벽 설계 프로세스 예시
(한국철도시설공단, 2012)

2. 주요 지반구조물 설계 체계와 기존 자동화의 한계

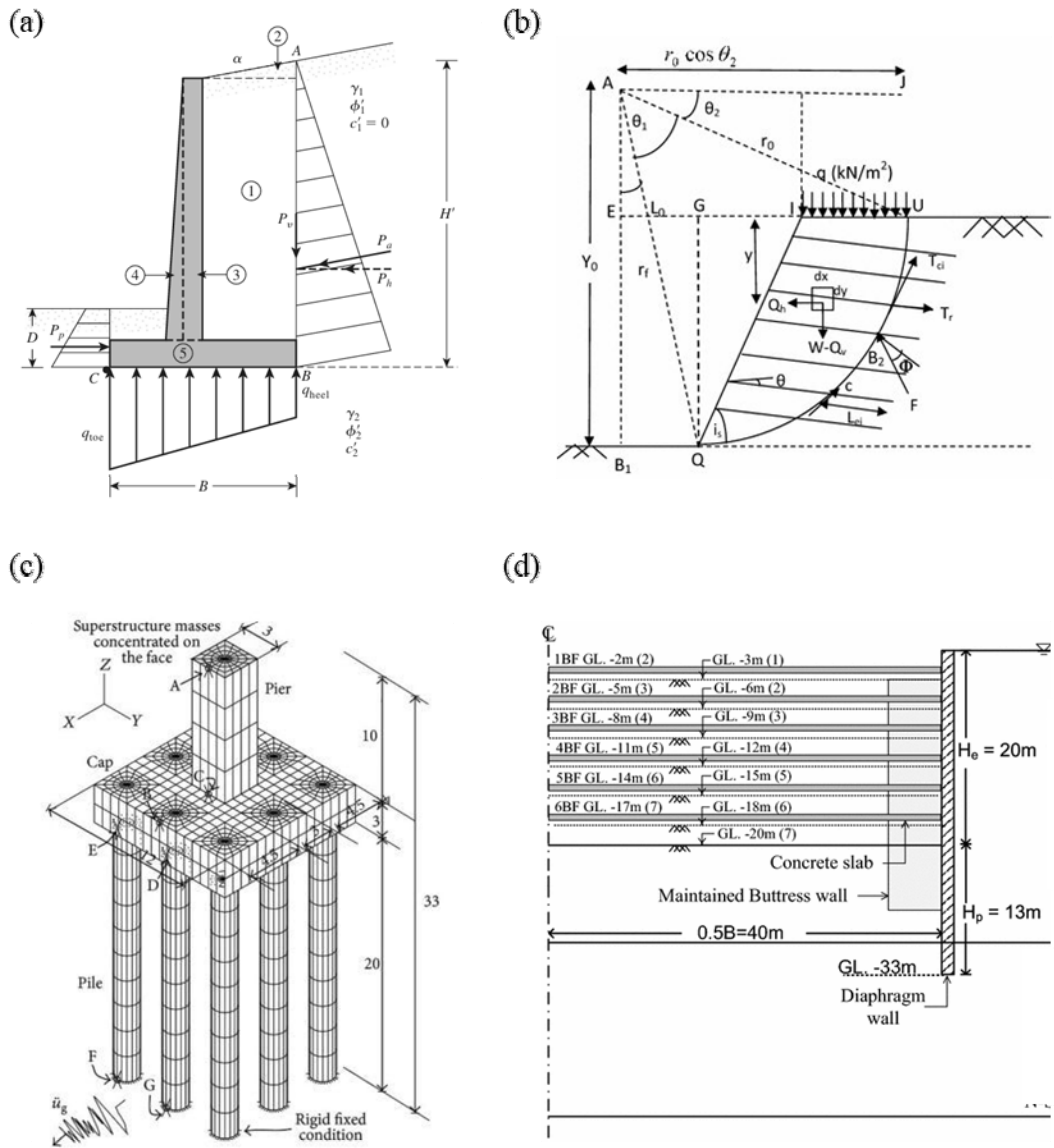
지반설계의 고유한 난제들을 보다 구체적으로 이해하기 위해, 본 절에서는 대표적인 지반구조물의 설계 체계를 분석한다. 각 구조물은 고유한 역할을 가지지만, 결국 다차원의 설계 변수 조합을 통해 상충하는 성능 목표(안전성, 경제성 등)를 만족시켜야 한다는 공통점을 가진다. 또한, 이러한 문제들을 해결하기 위해 과거부터 시도되어 온 최적화 기반 설계자동화의 성과와 근본적인 한계를 함께 고찰한다.

2. 1. 주요 지반구조물의 설계 체계 분석

지반공학 설계가 공통적으로 가지는 파라메트릭 특성을 이해하기 위해, [그림 4-2]와 같이 네 가지 대표적인 구조물의 설계 체계를 분석한다.

- **옹벽 (Retaining Wall):** 옹벽 설계의 핵심 과제는 토압에 저항하여 구조물의 전도, 활동, 지지력 안정성을 확보하는 것이다. 이를 위해 벽체 두께, 기초판 폭, 근입 깊이 등 단면의 기하학적 형상을 결정하는 변수들을 주로 다룬다.
- **사면 보강 (Slope Reinforcement):** 사면 보강은 잠재적 활동 파괴에 대한 저항력을 증대시키는 것이 목표이다. 보강재(네일, 앵커 등)의 길이, 간격, 각도, 위치 등 보강 패턴을 결정하는 변수들이 핵심이다.
- **깊은 기초 (Deep Foundation):** 깊은 기초의 핵심 과제는 상부 구조물의 하중을 견고한 지지층까지 안전하게 전달하는 것이다. 말뚝 직경, 길이, 개수, 간격, 두부 보강 등이 주요 설계 변수이다.
- **흙막이 구조물 (Earth Retaining Structure):** 흙막이 설계는 도심지 굴착 시 주변 지반의 변형을 억제하고 안정성을 확보하는 것이 중요하다. 벽체 형식(강널말뚝, CIP 등), 버팀대/앵커의 단수와 간격, 굴착 단계 등이 주요 설계 변수로 고려된다.

이처럼 다양한 지반구조물들은 각기 다른 변수와 성능 지표를 가지지만, 본질적으로는 '제한된 정보 하에서 복잡한 변수들의 최적 조합을 찾는 문제'라는 공통된 구조를 공유한다.



[그림 4-2] 주요 지반구조물의 파라메트릭 설계 변수 예시:
 (a) 옹벽 (Khajehzadeh et al., 2013), (b) 사면 보강 (Ghosh and Paul, 2013),
 (c) 깊은 기초 (Metwally, 2016), (d) 흙막이 구조물 (Lim et al., 2018)

2. 2. 기존 최적화 기반 설계자동화의 성과와 한계

이러한 문제들을 자동화하기 위해 1990년대 이후부터 유전 알고리즘(Genetic Algorithm) 등의 최적화 기법들이 활발히 적용되어 왔다. 이러한 연구들은 기존 수동 설계 방식 대비 10~25% 수준의 비용을 절감하는 등의 실질적인 성과를 거두며 설계 효율성 개선에 기여했다.

- **옹벽 설계:** Gandomi et al.(2017)은 다양한 진화 알고리즘을 활용하여 옹벽의 비용과 중량을 최소화하는 최적 설계를 수행했다.
- **사면 보강 설계:** Huang et al.(2022)은 신뢰성 이론에 기반하여 파일-앵커 구조물의 안전성(파괴 확률)과 경제성(총비용)을 동시에 고려하는 다목적 최적 설계를 수행했다.
- **깊은 기초 설계:** Chan et al.(2009)은 하이브리드 유전 알고리즘을 활용하여 말뚝 기초의 재료 부피를 최소화하는 연구를 수행하며, 말뚝의 개수, 배치, 단면 크기 등을 최적화했다.
- **흙막이 설계:** Taiyari et al.(2021)은 다양한 군집 지능 기법을 활용하여 도심지 지하철 공사의 깊은 굴착에 사용되는 흙막이 말뚝벽 시스템의 총공사비를 최적화하는 연구를 수행했다.

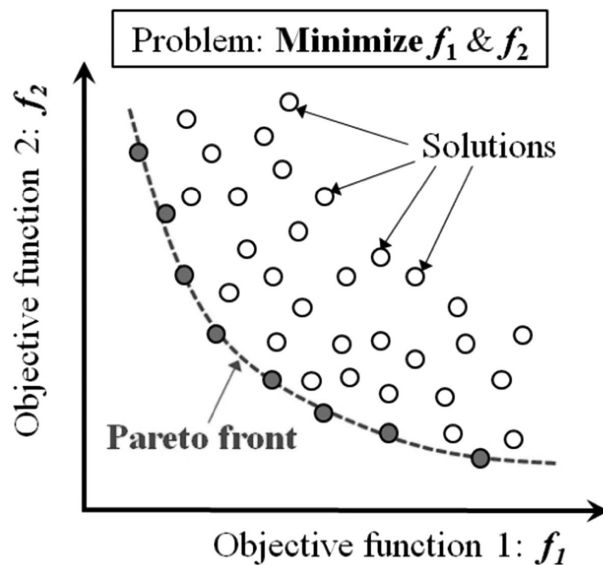
최적화 알고리즘 기반 설계자동화 초기 연구는 주로 비용 최소화와 같은 단일 목적함수에 집중했으나, 이후에는 [그림 4-3]과 같이 비용과 안전성처럼 상충하는 여러 목표를 동시에 고려하는 다목적 최적화(Multi-objective Optimization)로 발전하여, 설계자에게 여러 절충안(파레토 최적해)을 제공하는 단계에 이르렀다.

하지만 이러한 괄목할 만한 성과에도 불구하고, 최적화 기반 자동화는 실무 현장에서의 활용이 제한적이었는데, 이는 최적화 패러다임 자체가 가진 다음과 같은 내재적 한계 때문이었다.

- **최적해 중심의 제한된 다양성:** [그림 4-3]은 다목적 최적화의 개념을 보여준다. 여기서 파레토 최적해(Pareto Front)는 가장 효율적인 설계안들의 집합을 의미한다. 이는 분명 여러 대안을 제공하지만, 이 대안들은 모두 '최적이라는 경계선' 위에만 존재한다. 최적화의 본질은 이 경계선을 향해 '수렴(Convergence)'하는 것이므로, 이 경계선 밖에 존재하는 수많은 다른 고품질의 합리적인 설계안(Solutions)들은 탐색 과정에서 자연스럽게 배제된다. 즉, 최적화는 '가장 효율적인 해'를 찾는 데는 뛰어나지만, '다양한 설계 철학을 반영한 창의적인 해'를 탐색하는 데에는 구조적인 한계를 가진다.

- 높은 구현 난이도와 낮은 활용성: 최적화 알고리즘을 특정 프로젝트에 적용하기 위해서는 매번 문제에 맞는 목적함수와 제약조건을 수학적으로 정밀하게 정의해야 한다. 또한, 알고리즘의 성능을 보장하기 위해 다양한 파라미터를 조정하는 전문적인 튜닝 과정이 필수적이다. 이러한 높은 구현 난이도는 각기 다른 조건을 가진 새로운 프로젝트에 유연하게 적용하기 어렵게 만들어 실무적 활용성을 저해하는 주요 요인이 되었다.
- 경험적·정성적 지식 반영의 어려움: 최적화는 '비용', '안전율'처럼 명시적인 수학 함수로 정의할 수 있는 문제에 강점을 보인다. 하지만 '시공 용이성', '유지관리 편의성'과 같은 정성적 요구나, 수십 년간 축적된 베테랑 엔지니어의 암묵적 지식 및 설계 노하우는 목적함수로 공식화하기 어렵다. 이로 인해 최적화 결과물은 이론적으로는 우수할지라도, 실제 현장의 복합적인 요구사항을 충분히 반영하지 못하는 경우가 많았다.

결론적으로, 최적화 기반 자동화는 명확하게 정의된 문제에 대한 정답 찾기 (Problem-Solving) 도구로서는 뛰어난 성능을 보였지만, 다양한 가능성을 탐색하고 설계자의 직관과 경험을 확장시키는 창의적 설계 파트너(Creative Design Partner)로서의 역할을 수행하기에는 근본적인 한계가 있었다. 바로 이 지점에서, 수많은 데이터로부터 다양한 설계 패턴 자체를 학습하는 생성형 AI는 기존 최적화 기반의 설계자동화 방식을 넘어설 새로운 가능성을 제시한다.



[그림 4-3] 다목적 최적화의 개념과 파레토 최적해 (Huang et al., 2022)

3. 생성형 AI: 지반구조물 설계의 새로운 패러다임 가능성

앞서 살펴본 바와 같이, 기존 최적화 기반 설계자동화는 '최적'이라는 명확한 목표를 향해 수렴하는 강력한 도구이지만, 그 과정에서 다양한 가능성을 탐색하거나 수식화하기 어려운 경험적 지식을 반영하는 데에는 근본적인 한계를 보였다. 생성형 AI는 바로 이 지점에서, 데이터 기반의 패턴 학습을 통해 설계 문제에 접근하는 근본적으로 다른 패러다임을 제시한다.

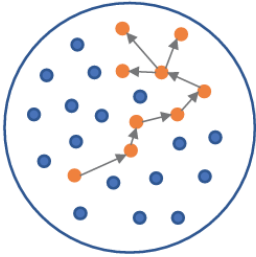
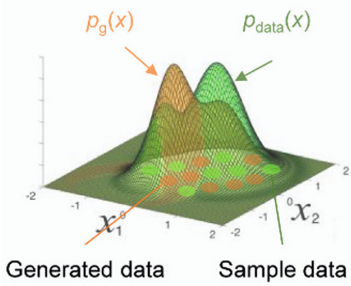
이러한 패러다임의 전환이 가져오는 가장 큰 차별점은 해(solution)에 대한 관점의 변화이다. 최적화의 목표가 주어진 제약조건 하에서 가장 효율적인 단일 해(The Best Solution) 또는 파레토 최적해 집합(Pareto Optimal Solutions)을 찾는 것이라면, 생성형 AI의 목표는 주어진 조건을 만족하는 가능성 있는 좋은 해들의 분포(Distribution of Good Solutions) 자체를 학습하는 것이다. 이 근본적인 차이로부터 앞선 절에서 제기된 최적화의 한계를 극복할 다음과 같은 새로운 가능성이 파생된다.

- 다양한 고품질 대안 생성: 생성형 AI는 학습된 '좋은 해들의 분포'로부터 확률적으로 샘플링함으로써, 동일한 성능 목표(예: 안전율 1.5)를 만족시키면서도 각기 다른 설계 철학을 반영하는 다채로운 대안들을 동시에 생성할 수 있다. 예를 들어, 비용은 유사하지만 보강재의 길이는 짧고 개수는 많은 설계안과, 보강재의 개수는 적고 길이는 긴 설계안을 함께 제시하는 것이 가능하다. 이는 설계자에게 단일 최적해나 파레토 최적해가 제공하지 못했던, 정성적 판단이 개입될 수 있는 폭넓고 실용적인 선택지를 부여한다.
- 신속한 생성과 높은 활용성: 한번 학습된 생성형 AI 모델은 새로운 조건에 대해 매우 빠른 속도로 설계안을 생성할 수 있으며, 데이터셋만 확보된다면 동일한 학습 프레임워크를 다른 구조물 설계 문제에도 유연하게 적용할 수 있다. 이는 매번 문제에 맞는 목적함수와 제약조건을 수학적으로 정밀하게 정의하고 알고리즘 파라미터를 조정해야 했던 기존 최적화 방식의 높은 구현 난이도와 낮은 재사용성 문제를 해결할 수 있는 가능성을 보여준다.
- 경험적 지식의 내재화: 최적화 기법이 수식으로 정의하기 어려운 경험적 지식을 반영하는 데 한계를 보인 반면, 생성형 AI의 가장 큰 강점 중 하나는 데이터로부터 복잡한 패턴을 학습하는 능력이다. 수천 건의 성공적인 과거 설계 사례나 시뮬레이션 데이터를 학습함으로써, 생성형 AI는 "연약 점토층에서는 앵커 정착장을 더 깊게 확보해야 한다"거나, "특정 지역의 화강풍화토에서는 표준 설계보다 보강재 간격을 조

밀하게 적용한다"와 같은 명문화되지 않은 경험적 지식과 암묵적 노하우를 모델에 내재화할 수 있다. 이는 특정 조건이 주어졌을 때, 과거 유사한 조건에서 성공했던 설계 패턴을 바탕으로 가장 합리적인 설계안을 생성하는 기반이 된다.

결론적으로, 이를 통해 생성형 AI는 설계자의 경험을 데이터로 확장하고 창의적인 대안 탐색을 지원하는 잠재력을 가진다. [표 4-1]은 개념 도식을 포함하여 최적화 기반과 생성형 AI 기반 접근 방식의 핵심적인 차이를 요약하여 보여준다.

[표 4-1] 주요 설계자동화 접근 방식 비교 (Liao et al., 2024)

구분	최적화 기반	생성형 AI 기반
핵심 원리	목표 함수와 제약 조건에 따른 반복적 최적해 탐색	학습된 설계 패턴을 기반으로 한 다양한 설계안 생성
개념 도식		
대표 기법	유전 알고리즘, 다목적 최적화	VAE, GAN, Diffusion
계산 비용	높음 (반복적 시뮬레이션 필요)	낮음 (학습 후 즉시 생성)
모델 구현 복잡성	높은 복잡성 (목적함수 정의, 파라미터 조정)	중간 복잡성 (데이터 준비, 모델 훈련)
설계안 다양성	제한적 (최적 해 중심 수렴)	높음 (다양한 실현 가능해 탐색)
경험 지식 활용	어려움 (명시적 수식화 필요)	용이함 (데이터 기반 패턴 학습)
적합 분야	명확한 성능 기준 최적화	다양성과 창의성이 요구되는 설계

4. 본 연구의 접근 전략 및 파일럿 연구 대상 선정

앞선 논의를 통해 지반공학 설계의 고유한 난제와 이를 해결하기 위한 생성형 AI의 가능성을 확인했다. 이를 바탕으로, 본 절에서는 생성형 AI 기반 설계자동화의 실현 가능성을 검증하기 위한 구체적인 연구 접근 전략을 수립하고, 파일럿 연구의 대상을 선정한다.

1) 핵심 방법론 선정: 파라메트릭 접근법

3장에서 검토한 바와 같이, 생성형 AI는 데이터 표현 방식에 따라 이미지, 텍스트, 파라메트릭 등 다양한 접근법을 가진다. 이 중, 본 연구는 파라메트릭(Parametric) 기반 생성 모델을 핵심 방법론으로 채택한다. 그 이유는 다음과 같다.

- 정량적 성능 제어의 직접성: 지반공학 설계의 최종 목표는 '안전율'과 같은 정량적 성능 기준을 만족하는 최적의 수치 제원 조합을 찾는 것이다. 파라메트릭 접근법은 설계 변수와 성능 지표를 직접 수치로 다루므로, 이러한 목표를 가장 직접적으로 달성할 수 있다.
- 지반설계 본질과의 부합: 옹벽의 두께, 기초의 폭, 사면 보강재의 길이와 간격 등 지반설계의 본질은 결국 정량화된 변수들의 조합을 찾는 문제로 귀결된다. 따라서 파라메트릭 데이터는 지반설계 자동화를 위한 가장 본질적이고 직접적인 데이터 형식이라 할 수 있다.

2) 단계적 연구 전략

본 연구는 파라메트릭 생성 모델의 단순한 적용을 넘어, 지반공학 분야의 특수성을 고려한 체계적인 연구 전략을 따른다.

1. 파일럿 연구를 통한 실현성 검증: 먼저 표준적인 생성 모델(예: CVAE)을 대표적인 지반공학 문제에 적용하여 기본적인 실현 가능성을 검증한다.
2. 한계점 분석 및 기술적 과제 도출: 파일럿 연구 과정에서 발견되는 기술적 한계, 특히 지반공학 고유의 문제점을 명확히 규명한다.
3. 차세대 프레임워크 제시: 식별된 한계를 극복하기 위한 차세대 생성 모델(예: 확산 모델)의 도입 등 구체적인 기술적 해결 방향을 제시한다.

3) 파일럿 연구 대상 선정: 사면 보강

이러한 단계적 전략의 첫걸음이 될 파일럿 연구의 대상으로 사면 보강(Slope Reinforcement) 설계를 최종 선정했다. [표 4-2]는 여러 후보 구조물 중 사면 보강을 선택한 이유를 체계적으로 보여준다. 사면 보강 설계는 생성형 AI 모델의 성능과 잠재력을 검증하기에 다음과 같은 최적의 조건을 갖추고 있다.


- 명확하고 정량적인 성능 지표: 사면 설계의 성패는 '안전율(Factor of Safety, FS)'이라는 명확한 단일 지표로 평가된다. 이는 생성된 설계안의 유효성을 객관적으로 측정하고 모델의 성능을 정량적으로 비교·검증하는 데 매우 유리한 기준을 제공한다.
- 적절한 수준의 복잡성: 사면의 안정성은 보강재의 개수, 길이, 간격, 각도, 위치 등 다수의 설계 변수들이 복합적이고 비선형적인 상호작용을 통해 결정된다. 이는 흙막이 설계처럼 단계별 해석이 필요한 과도한 복잡성은 피하면서도, 생성형 AI가 고차원의 설계 공간을 효과적으로 탐색하는 능력을 검증하기에 매우 적합한 수준의 문제이다.
- 데이터 확보의 용이성: 한계평형해석(LEM) 등 검증된 시뮬레이션 기법을 자동화하여, 모델 학습에 필요한 대규모 데이터셋을 비교적 용이하게 구축할 수 있다. 이는 데이터 품질이 모델 성능에 결정적인 영향을 미치는 생성형 AI 연구의 초기 단계에서 큰 장점으로 작용한다.

파일럿 연구의 대상인 사면 보강 공법은 [그림 4-4]와 같이 지반 내부에 강재 보강재(네일, 앵커 등)를 조밀하게 삽입하여 전단 저항력을 증가시키는 원리를 기반으로 한다.

이상의 논의를 바탕으로, 이어지는 5장에서는 CVAE(Conditional Variational Autoencoder)를 기반으로 사면 보강 설계자동화 파일럿 연구를 수행한 구체적인 과정과 그 결과를 상세히 서술한다.

[표 4-2] 주요 설계자동화 접근 방식 비교

평가 기준	옹벽 설계	사면 보강 설계	깊은 기초 설계	흙막이 설계
성능 지표의 명확성	전도, 활동, 지지력 등 다수	활동 안전율(FS) 중심으로 명확	지지력, 침하량 등 복합적	벽체 변위, 안정성 등 복합적
변수의 복잡성	단면 형상 중심 (주로 연속 변수)	보강재 배치 중심 (이산/연속 혼합)	말뚝 배치/제원 중심 (이산/연속 혼합)	단계별 시공 고려 (매우 복잡)
데이터 확보 용이성	용이 (LEM/FEM)	용이 (LEM)	보통 (SSI 해석)	어려움 (단계별 해석)
파일럿 적합성	중	상	중	하



[그림 4-4] 파일럿 연구 대상인 사면 보강 공법 예시 (국토해양부, 2012)

제5장 파일럿 연구: CVAE 기반 사면 보강 설계자동화

앞선 4장에서는 지반설계의 고유한 난제와 기존 최적화 알고리즘 기반 설계자동화의 한계를 분석하고, 그 해결책으로 생성형 AI 기반의 파라메트릭 접근법이 가장 효과적인 전략임을 논증했다. 이를 바탕으로 본 장에서는 생성형 AI 방법론의 실질적인 구현 가능성과 유효성을 검증하기 위한 파일럿 연구를 수행한다. 파일럿 연구 대상으로는 4.4절에서 논의된 바와 같이, 명확한 성능 지표와 데이터 확보 용이성 등에서 가장 적합한 사면 보강 설계를 선정했다.

1. 연구 개요 및 목표

1) 실무 설계 현황 분석 (브사렐건설, 2024)

기존의 사면 보강 설계는 설계자가 초기 제원을 가정한 뒤 안정성 해석을 반복적으로 수행하며 수정하는 방식으로, 많은 시간과 노력이 소요되며 설계자의 경험에 크게 의존하는 한계가 있다. 실제 사면 앵커(Anchor) 보강 설계 사례를 통해, 이러한 다단계의 복합적인 검토 과정을 명확히 분석한다.


설계 프로세스는 [표 5-1]과 같이 현장 조사를 통해 얻어진 설계 지반정수를 바탕으로 시작된다. 설계자는 이 값을 기초로, 경험에 근거하여 [그림 5-1]과 같이 앵커의 길이, 간격, 개수 등을 가정한 초기 설계 단면을 구성한다.

[표 5-1] 설계적용 지반정수 예시

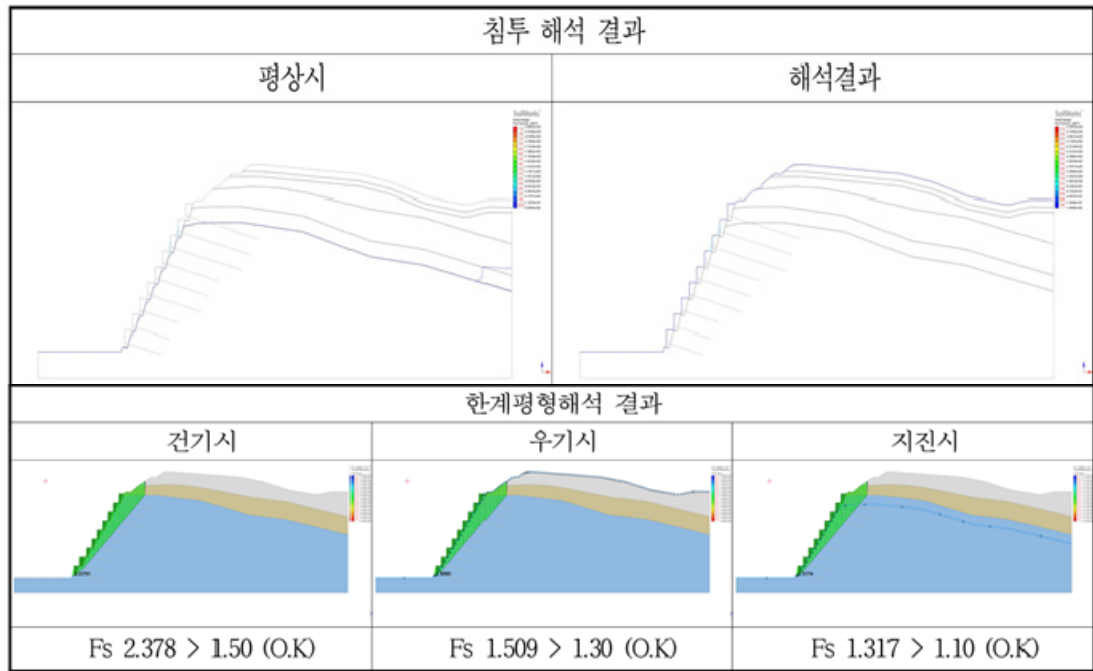
구분	단위중량(kN/m ³)	점착력 (kPa)	내부마찰각 (°)
쌓기재 (토사)	19.0	15.0	25.0
풍화토	19.0	23.0	30.0
풍화암	21.0	30.0	32.0
연암(절리면)	24.0	31.0	34.0

이후, [그림 5-2]와 같이 침투해석과 한계평형해석을 통해 사면 전체의 잠재적 파괴에 대한 안정성, 즉 외적 안정성(External Stability)을 검토한다. 이 과정은 건기, 우기, 지진 시 등 다양한 조건에 대해 각각의 기준 안전율(예: 건기 시 FS > 1.5)을 만족하는지 확인하는 작업을 포함한다.

여기에 더해, 설계자는 각 보강재가 흙의 저항력을 초과하여 뽑히거나(인발 파괴) 자체의 인장 강도를 초과하여 끊어지지(인장 파괴) 않는지를 확인하는 내적 안정성/Internal Stability) 검토까지 개별적으로 수행해야 한다. 만약 외적 또는 내적 안정성 기준 중 어느 하나라도 만족하지 못하면, 설계자는 다시 [그림 5-1]의 설계 단면으로 돌아가 보강재의 제원을 수정한 뒤 이 모든 검토 과정을 반복해야 한다. 이러한 다단계의 복합적인 시행착오 과정은 4.1절에서 제기된 전통적 설계 방식의 비효율성과 한계를 명확히 보여준다.



[그림 5-1] 실무 사면 보강 설계 단면 예시 (어스 앵커)



[그림 5-2] 외적 안정성 검토 예시(건기, 우기, 지진시)

2) 파일럿 연구의 목표

본 파일럿 연구는 이러한 기존 설계 패러다임의 한계를 극복하는 것을 목표로 하며, 설계 초기 단계에서 엔지니어가 더 폭넓은 선택지를 바탕으로 합리적인 의사 결정을 내릴 수 있도록 지원하는 새로운 설계 패러다임의 가능성을 실증적으로 검증하고자 한다. 이를 위해, 생성형 AI, 그중에서도 조건부 변이형 오토인코더(Conditional Variational Autoencoder, CVAE)를 활용하여, 주어진 설계 조건(지반 조건, 목표 안전율)에 따라 다양한 고품질 설계 대안을 자동으로 생성하는 프레임워크를 구축하고 그 성능을 검증한다. 구체적인 설계 대상으로는 앞서 예시로 든 앵커 공법과 함께 대표적인 사면 보강 공법으로 널리 사용되는 소일 네일링(Soil Nailing)을 선정하였다.

2. 연구 방법론

본 절에서는 파일럿 연구의 핵심적인 과정인 설계 변수 정의와 데이터셋 구축 과정을 먼저 상세히 설명하고, 이어서 CVAE 기반 생성형 설계 프레임워크와 안정성 평가에 대해 서술한다.

2. 1. 설계 변수 정의 및 데이터셋 구축

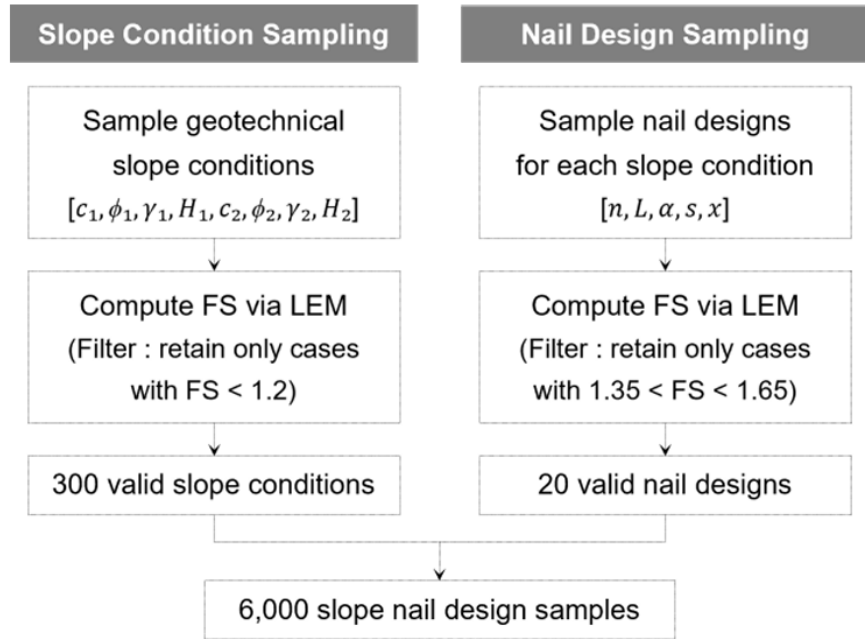
생성형 AI 모델의 성능은 학습 데이터의 품질에 의해 결정되므로, 잘 정의된 변수 체계와 신뢰도 높은 대규모 데이터셋을 구축하는 것은 연구의 가장 핵심적인 과정이다.

1) 설계 변수 정의

본 연구의 생성형 설계 프레임워크는 [그림 5-3]과 같이 주어진 ‘설계 조건’을 입력받아 최적의 ‘설계 대안’을 생성하는 것을 목표로 한다. 이를 위해 입출력 변수를 다음과 같이 파라미터 형태로 정의하였다.

- 입력 변수 (설계 조건): 생성 모델이 참조해야 할 외부 조건으로, 총 9개의 변수로 구성된다. 여기에는 2개 층으로 구성된 사면의 지반정수(점착력 c , 내부마찰각 ϕ , 단위중량 γ) 및 각 층의 두께(H) 등 총 8개의 지반 조건 변수가 포함된다. 또한, 설계자가 달성하고자 하는 목표 안전율(FS_{req}) 역시 중요한 조건 변수로 함께 입력된다.
- 출력 변수 (설계 대안): 모델이 최종적으로 생성해야 할 결과물로, 사면 보강을 위한 네일(Nail)의 레이아웃을 결정하는 5개의 핵심 파라미터로 구성된다. 여기에는 네일의 개수(n), 길이(L), 간격(s), 설치 각도(α), 그리고 사면 정상부로부터의 설치 시작 위치(x)가 포함된다. 이 5가지 변수는 소일 네일링 설계의 안전성과 경제성을 결정하는 가장 지배적인 요소들이다.

본 연구에서는 방법론의 근본적인 성능 검증에 집중하기 위해, 사면 형상 변수인 전체 사면의 높이(15m)와 경사각(63.4°)은 고정 값으로 설정하였다.



[그림 5-4] 시뮬레이션 기반 데이터셋 구축 절차

[표 5-2] 지반 물성치 샘플링 범위

지반 유형	단위중량 γ (kN/m ³)	점착력 c (kPa)	내부마찰각 ϕ (°)
모래(SD)	16-19	0-5	30-38
풍화토(WS)	17-19	5-25	22-30
풍화암(WR)	20-22	30-80	30-38
연암(SR)	22-24	80-150	35-45

[표 5-3] 네일 설계 변수 샘플링 범위

설계 변수	기호	범위	단위
네일 개수	n	3-10	-
네일 길이	L	6-18	m
네일 설치 각도	α	10-30	°
네일 간격	s	1.0-2.5	m
네일 이격거리	x	0-10	m

2. 2. CVAE 기반 생성형 설계 프레임워크

본 연구는 위 데이터셋을 기반으로, [그림 5-5]와 같이 총 4단계로 구성된 CVAE 기반 생성형 설계 프레임워크를 개발하였다.

- (a) 1단계: 데이터셋 구축: 앞서 설명한 바와 같이, 시뮬레이션을 통해 ‘설계 조건(C) - 설계안(Y) - 안전율(FS)’로 구성된 6,000개의 유효한 데이터 샘플을 확보한다.
- (b) 2단계: VAE 모델 학습: 데이터셋에 내재된 ‘설계 변수(C, Y, FS) 간의 복잡한 관계를 모델이 학습하여 잠재공간(Latent Space)에 압축 및 매핑한다. CVAE 모델은 인코더(Encoder)와 디코더(Decoder)를 통해 데이터의 복잡한 관계를 저차원의 잠재 공간에 압축하고, 이를 다시 복원하는 과정을 반복하며 설계 변수 간의 물리적 관계를 스스로 터득한다.
- (c) 3단계: 설계안 생성: 학습된 디코더를 이용하여, 새로운 사면 조건(C_{req})과 목표 안전율(FS_{req})을 만족하는 다양한 네일 설계안(Y)을 신속하게 생성한다. 무작위 잠재 벡터(Z)를 계속 다르게 샘플링함으로써, 동일한 조건을 만족하는 다양한 형태의 대안을 생성할 수 있다.
- (d) 4단계: Surrogate 모델 기반 설계안 필터링: CVAE는 확률 기반 모델이므로 3 단계에서 생성된 모든 설계안이 목표 안전율을 정확하게 만족한다고 보장할 수는 없다. 따라서 생성된 설계안들의 성능을 신속하고 정확하게 검증하는 필터링 과정이 필수적이다. 이를 위해, 본 연구에서는 별도로 사전 학습된 성능 예측용 인공지능망, 즉 Surrogate 모델을 도입했다. 이 Surrogate 모델(MLP, 다층 퍼셉트론)의 신뢰도를 확보하기 위해, CVAE 학습에 사용된 6,000개 데이터셋과는 별개로, 총 48,000

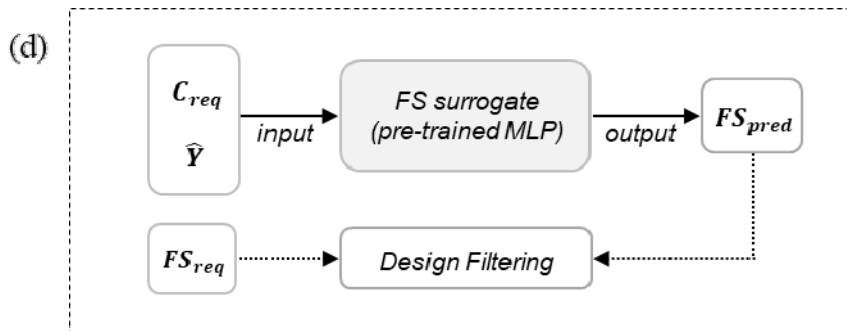
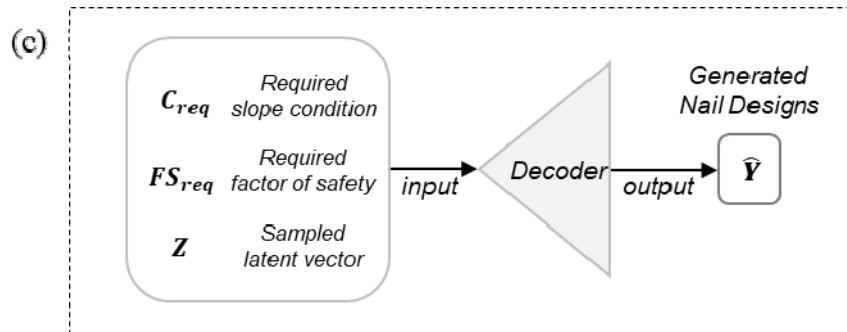
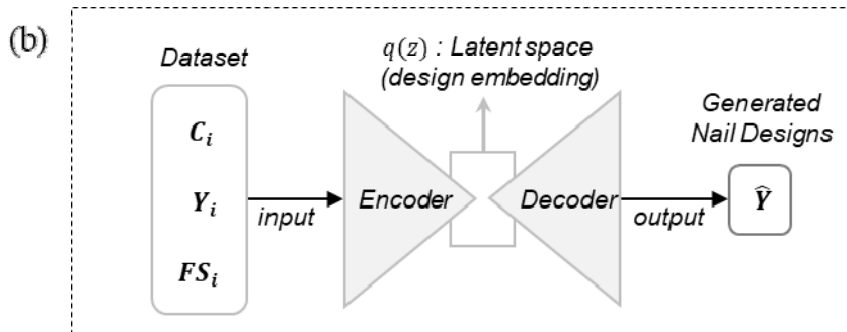
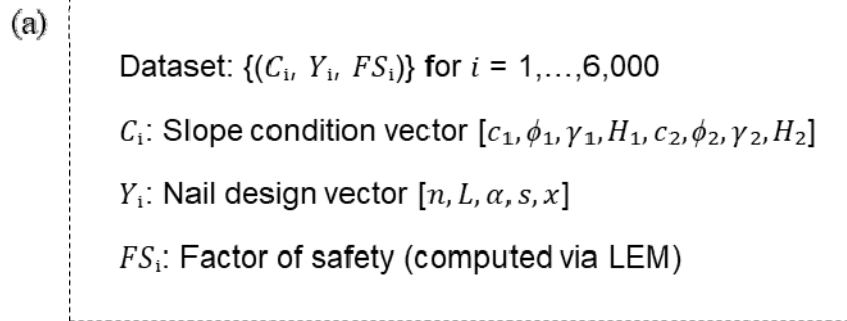
개의 샘플로 구성된 더 광범위한 데이터셋을 구축하여 사전 학습을 수행했다. 이 데이터셋에는 의도적으로 안전한 설계안과 불안정한 설계안이 모두 포함되어, 모델이 다양한 경우에 대해 강건한 예측 성능을 갖도록 유도했다. 학습 결과, Surrogate 모델은 평균 절대 오차(MAE) 0.03 미만의 높은 예측 정확도를 확보했다. 이렇게 검증된 Surrogate 모델의 예측 결과를 바탕으로, 생성된 수많은 설계안 중에서 목표 안전율(FS_{req})에 충분히 근접하는 유효한 설계안들만 최종적으로 선별한다. 이처럼 생성과 검증 단계를 분리함으로써, 모델의 창의적인 탐색 능력은 유지하면서도 최종 결과물의 공학적 신뢰성을 확보할 수 있다.

2. 3. 안정성 평가 기준의 단순화

본 파일럿 연구에서는 생성형 AI 모델의 다양한 설계안을 생성하는 핵심 성능에 집중하기 위해, 안정성 평가 기준을 의도적으로 단순화하였다. 실제 사면 보강 설계에서는 5.1절에서 언급한 바와 같이 외적 안정성과 내적 안정성을 모두 검토해야 하지만, 본 연구에서는 다음과 같은 접근법을 사용했다.

먼저, 각 보강재(네일)가 발휘할 수 있는 허용 가능한 최대 저항력(인장 및 인발 저항력)을 관련 기준에 따라 사전 계산하였다. 그리고 한계평형해석 시뮬레이션에 이 최대 저항값을 보강재의 작동 성능(Working Load)으로 직접 입력하였다.

이러한 접근법은 내적 안정성은 이미 확보되었다고 가정하고, 전체 사면의 외적 안정성(Global Factor of Safety)만을 생성 모델의 목표 성능 지표로 삼는 것을 의미한다. 이는 복잡한 문제를 분리하여 CVAE 모델의 근본적인 생성 성능을 명확히 검증하기 위한 전략적 선택이다. 실제 작용력을 고려한 완전한 내적 안정성 검토는 향후 모델 고도화 단계에서 다룰 과제로 남겨두었다.



[그림 5-5] CVAE 기반 생성형 설계자동화 프레임워크: (a)데이터셋 구축, (b)VAE 모델 학습, (c)설계안 생성, (d)설계안 필터링

3. 실험 결과 및 분석

5.2절에서 설계한 CVAE 기반 생성형 설계 프레임워크의 실질적인 성능을 검증하기 위해, 학습된 CVAE 모델을 통해 서로 다른 지층 구조를 가진 두 가지 대표적인 사면 조건에 대한 설계 생성을 수행하였다. 두 사례 모두 목표 안전율(FS_{req})은 실무에서 일반적으로 사용되는 기준인 1.5로 설정하였으며, 각 사례별로 300개의 설계 대안을 생성한 뒤 그 성능을 심층적으로 분석하였다.


3. 1. Case 1: 상부 강성 / 하부 연약 지층 (Stiff-over-Weak)

첫 번째 사례는 상부에 강성 지반(풍화암, WR)이, 하부에 연약 지반(풍화토, WS)이 위치하는 '상부강성-하부연약' 지층 조건이다. 이 사면은 상부층 ($H_1=10.0$ m, $\gamma_1=21.0$ kN/m³, $c_1=55.0$ kPa, $\phi_1=34.0^\circ$), 하부층 ($H_2=5.0$ m, $\gamma_2=18.0$ kN/m³, $c_2=15.0$ kPa, $\phi_2=26.0^\circ$)로 구성되며, 보강 전 초기 안전율은 $FS_{LEM}=1.10$ 으로 불안정한 상태이다. 이러한 조건에서의 파괴면은 주로 하부의 연약층을 따라 깊게 형성되는 비교적 일관된 파괴 거동을 보인다.

1) 설계안 생성 분포 및 필터링 성능


[그림 5-6]은 학습된 CVAE 모델을 통해 생성된 300개 설계안의 실제 안전율 (FS_{LEM}) 분포를 보여준다. 전체적으로 목표 안전율(Target FS=1.5)을 중심으로 정규 분포와 유사한 안정적인 분포를 보였으며, 이는 CVAE 모델이 주어진 조건을 잘 이해하고 목표 성능에 부합하는 설계안을 주로 생성했음을 의미한다. 다만 CVAE는 확률적 생성 모델(probabilistic generative model)이므로, 학습된 잠재 공간(latent space)에서의 무작위 샘플링(latent sampling) 과정에서 발생하는 고유의 무작위성으로 인해 생성된 안전율이 정확히 1.5가 아닌 목표값 주위로 퍼져있는(scattered) 형태를 보인다. 따라서 그래프에서 보듯이 생성 분포가 넓게 형성되어 일부 설계안들은 목표치에서 벗어나므로, Surrogate 모델을 통한 필터링이 필수적이다.

생성된 300개의 설계안 중에는 안전율 1.15 미만 또는 2.05를 초과하는 약간의 이상치(outlier) 설계안들도 포함되어 있었으나, [그림 5-6]과 [그림 5-9] 등의 결과 분석 그래프에서는 가시성을 위해 제외되었다. 전체 300개 설계안에 대한 상세 목록은 부록을 통해 확인할 수 있다.



[그림 5-6] Case 1에서 생성된 설계안의 실제 안전율 분포

[그림 5-7]은 Surrogate 모델의 필터링 성능을 보여준다. x축은 실제 안전율(FS_{LEM}), y축은 Surrogate 모델이 예측한 안전율(FS_{pred})을 나타낸다. 파란색 점으로 표시된 300개의 생성된 설계안들이 $y=x$ 직선 주위에 강하게 밀집해 있어, Surrogate 모델이 매우 높은 정확도로 실제 안전율을 예측했음을 알 수 있다. 그림 중앙의 분홍색 음영 영역(Filtering region for FS_{pred})은 목표 안전율 1.5에 대해 ± 0.05 의 허용 오차를 적용한 필터링 구간($1.45 < FS_{pred} < 1.55$)을 나타낸다. 이 구간 내에 포함된 57개의 설계안(붉은색 점)이 최종 설계안 후보로 선별되었다.



[그림 5-7] Case 1의 Surrogate 모델 기반 설계안 필터링 결과


2) 최종 설계 대안

[표 5-4]는 최종 필터링된 57개의 설계안 중에서 최소 비용($n \times L$), 최소 네일 길이 (L) 등 다양한 실무적 기준에 따라 선별한 대표적인 설계 대안들이다. 모든 대안이 목표 안전율 1.5에 근접한 실제 안전율(FS_{LEM})을 만족시키면서도, 네일의 개수, 길이, 배치 등에서 뚜렷한 차이를 보인다. 이는 설계자가 단일 최적해가 아닌, 프로젝트의 특수한 요구(경제성, 시공성 등)에 맞춰 가장 적합한 안을 선택할 수 있는 폭 넓은 의사결정 기회를 제공함을 의미한다.

[그림 5-8]은 필터링된 설계안 중 두 가지 대표적인 레이아웃을 시각적으로 비교한다. 왼쪽은 네일을 사면 상부에 집중시킨 설계안이고, 오른쪽은 하부에 집중시킨 설계안이다. 두 경우 모두 임계 파괴면이 하부 연약층(WS)을 통과하는 유사한 형태를 보이지만, 오른쪽 설계안이 더 적은 수의 네일로 더 높은 안전율(1.541)을 확보했음을 알 수 있다. 이는 하부 연약층이 안정성을 지배하는 이 지층 조건에서는 하부에 보강재를 집중하는 것이 더 효율적이라는 공학적 직관과 일치하는 결과이다.

[표 5-4] Case 1의 대표적인 최종 설계 대안

유형	최소 비용 (n×L)	최소 길이 (L)	최대 네일 간격 (s)	최소 이격 거리 (x)
n	3	6	4	5
L (m)	9.1	6.7	8.3	11.1
α (°)	14.0	30.0	16.7	23.5
s (m)	2.1	2.1	2.4	1.9
x (m)	10.0	4.2	6.6	1.1
Cost (n×L)	27.2	40.4	33.3	55.5
FS _{pred}	1.47	1.47	1.45	1.49
FS _{LEM}	1.54	1.55	1.52	1.48



[그림 5-8] Case 1의 대표 설계안 시각화 및 보강 방식 비교 (상부 집중 vs 하부 집중 보강)


3. 2. Case 2: 상부 연약 / 하부 강성 지층 (Weak-over-Stiff)

두 번째 사례는 상부에 연약 지반(풍화토, WS)이, 하부에 강성 지반(풍화암, WR)이 위치하는 '상부연약-하부강성' 지층 조건이다. 이 사면은 상부층 ($H_1=10.0$ m, $\gamma_1=18.0$ kN/m³, $c_1=15.0$ kPa, $\phi_1=26.0^\circ$), 하부층 ($H_2=5.0$ m, $\gamma_2=21.0$ kN/m³, $c_2=55.0$ kPa, $\phi_2=34.0^\circ$)로 구성되며, 보강 전 초기 안전율은 $FS_{LEM}=0.99$ 로 매우 불안정한 상태이다. 이 경우는 파괴면의 형태가 보강 방식에 따라 민감하게 변할 수 있어 보강재 변수와 안전율의 관계가 더 복잡한 양상을 갖는다.


1) 설계안 생성 분포 및 필터링 성능

[그림 5-9]에서 볼 수 있듯이, Case 2의 안전율 분포는 Case 1과 달리 두 개의 봉우리를 갖는 이중 분포(Bimodal distribution) 형태를 보인다. Case 1과 마찬가지로 하나의 봉우리는 목표 안전율 1.5 근처에 형성되었지만, 다른 하나는 FS 1.8 근처에서 뚜렷하게 나타났다. 이는 CVAE 모델이 해당 사면 조건에서는 종종 과도하게 안정적인, 즉 비경제적인 설계안을 생성하는 경향이 있음을 시사한다.

[그림 5-10]의 필터링 성능 분석 결과, Case 1에 비해 Surrogate 모델의 예측 정확도가 다소 감소하고 데이터의 분산이 커진 것을 확인할 수 있다. 특히 FS=1.50과 FS=1.82 근처의 군집 영역에서 예측 오차가 크게 나타나는 경향을 보인다. 그 결과, 실제 안전율이 목표치에 근접함에도 불구하고 필터링에서 부당하게 제외되는 설계안이 발생하거나, 실제 안전율이 부정확한 설계안이 포함되는 경우가 일부 나타났다. 그럼에도 불구하고, 분홍색 음영으로 표시된 필터링 구간 ($1.45 < FS_{pred} < 1.55$)은 목표 안전율 범위 내의 유효한 설계안 45개를 성공적으로 선별해내는 데 기여했다.



[그림 5-9] Case 2에서 생성된 설계안의 실제 안전율 분포



[그림 5-10] Case 2의 Surrogate 모델 기반 설계안 필터링 결과

2) 최종 설계 대안


[표 5-5]는 필터링을 통해 최종 선별된 45개의 유효 설계안 중 대표적인 사례들을 보여준다. Case 1과 마찬가지로, 모든 대안들은 목표 안전율 1.5에 근접하면서도 서로 다른 설계 변수 조합을 가진다. 이는 생성형 설계 프레임워크가 복잡한 변수 관계 분포를 가진 지반 조건 하에서도 여전히 설계자에게 다양한 선택지를 제공할 수 있음을 보여준다.

[표 5-5] Case 2의 대표적인 최종 설계 대안

유형	최소 비용 (n×L)	최소 길이 (L)	최대 네일 간격 (s)	최소 이격 거리 (x)
n	3	6	3	4
L (m)	7.9	6.0	12.1	9.0
α (°)	16.7	23.2	23.8	24.1
s (m)	1.6	2.0	2.2	1.9
x (m)	3.5	0.0	5.7	0.0
Cost (n×L)	23.6	36.0	36.3	35.9
FS _{pred}	1.45	1.55	1.49	1.51
FS _{LEM}	1.48	1.56	1.50	1.55

3) 불연속적 파괴 거동 분석

[그림 5-9]와 [그림 5-10]에서 관찰된 생성 및 예측 오류의 근본적인 원인은 [그림 5-11]과 같이 Case 2에서 나타나는 불연속적 파괴 거동에 있다. 상부 연약층이 존재하는 경우, 네일의 배치나 길이를 조금만 변경해도 임계 파괴면이 하부 강성층(WR)까지 연장되는 깊은 파괴(우측 그림)에서 상부 연약층(WS)에 국한되는 얇은 파괴(좌측 그림)로 급격하게 변하는 현상이 발생한다.



[그림 5-11] Case 2의 대표 설계안 시각화 및 파괴 메커니즘 비교
(얕은 파괴 vs 깊은 파괴)

이처럼 설계 변수의 연속적인 변화가 안전율의 비연속적인 변화를 유발하는 복잡한 관계는, 연속 함수 근사에 최적화된 CVAE나 Surrogate 모델(MLP)이 학습하기 매우 어려운 문제이다. 이것이 바로 모델이 두 가지 뚜렷한 분포의 설계안을 생성하고 예측 정확도가 저하된 근본적인 원인이다.

4. 한계점 발견 및 향후 발전 방향

본 파일럿 연구는 파괴거동이 비교적 일관된 사면 조건인 Case 1에서는 목표 성능을 만족하는 다양한 설계 대안을 성공적으로 생성할 수 있음을 입증하며, 생성형 AI의 지반공학 설계 적용 가능성을 보여주었다. 변수 분포가 보다 불연속적이고 복잡한 Case 2의 사면 조건에서는 표준적인 생성 모델 CVAE이 근본적인 한계점을 드러내었고, 이는 향후 연구 방향을 명확히 한다.

1) 핵심 한계점: 불연속적 물리 거동의 학습 실패

가장 핵심적인 한계는 Case 2에서 관찰된 ‘불연속적 파괴 거동’을 현재의 CVAE 모델이 효과적으로 학습하지 못한다는 점이다. 상부 연약층 조건에서는 설계 변수의 미세한 변화가 임계 파괴면의 급격한 천이(얕은 파괴 ↔ 깊은 파괴)를 유발하며, 이는 설계 변수와 안전율 간의 관계를 비선형적일 뿐만 아니라 불연속적으로 만든다.

하지만 CVAE나 Surrogate 모델로 사용된 MLP와 같은 대부분의 표준 신경망 모델은 본질적으로 연속적인 함수 관계를 근사하는 데 최적화되어 있다. 이로 인해 모델은 두 개의 뚜렷한 파괴 모드에 해당하는 데이터 분포를 단일한 연속 관계로 학습하려 시도하게 되고, 그 결과 목표에서 벗어난 설계안을 생성(이중 분포 현상)하거나 성능 예측의 정확도가 저하되는 문제가 발생한 것이다. 지반공학 설계는 다른 공학 분야와 달리, 이와 같은 불연속적 파괴 모드의 변화라는 고유한 특성을 수반하며, 이를 고려한 모델 설계가 필요함을 시사한다.

2) 향후 발전 방향: 확산 모델 기반의 차세대 프레임워크 도입

이러한 한계를 극복하기 위해서는, 불연속적이거나 다중 모드(Multi-modal)를 갖는 복잡한 데이터 분포를 학습하는 데 더욱 뛰어난 성능을 보이는 차세대 생성형 AI 모델의 도입이 필수적이다.

본 연구에서는 그 해결책으로 확산 모델(Diffusion Model)의 적용을 제안한다. 확산 모델은 점진적인 노이즈 제거 과정을 통해 데이터를 생성하는 방식으로, GAN이나 VAE보다 학습이 안정적이면서도 매우 복잡하고 다양한 형태의 데이터 분포를 정밀하게 학습하는 능력으로 잘 알려져 있다.

확산 모델을 적용할 경우, Case 2에서 나타난 두 가지의 뚜렷한 설계안 분포(FS

≈ 1.5 , $FS \approx 1.8$)를 별개의 모드로 인식하고 학습할 수 있을 것으로 기대된다. 이를 통해 사용자가 목표 안전율($FS=1.5$)을 조건으로 제시했을 때, 불필요한 과다 설계안을 배제하고 목표에 집중된 고품질의 설계 대안만을 생성할 수 있게 될 것이다.

표준 CVAE 방법론은 지반공학 설계 자동화의 가능성을 열었지만, 실무적 복잡성을 해결하기 위해서는 한 단계 더 나아간 접근이 필요하다. 향후 연구는 이 확산 모델을 기반으로 한 차세대 프레임워크를 개발하고, 그 성능을 검증하는 방향으로 나아가야 한다. 이는 이어지는 6장에서 제안하는 최종 연구 로드맵의 핵심적인 기반이 된다.

제6장 결론 및 향후 연구 로드맵

1. 연구 요약 및 핵심 기여

본 연구는 전통적인 경험 기반 설계 방식이 가진 비효율성과 한계를 극복하기 위한 대안으로, 생성형 AI 기반의 지반구조물 설계자동화 방법론을 제안하고 그 실현 가능성을 검증하는 것을 목표로 하였다.

이를 위해 VAE, GAN, Diffusion 등 대표적인 생성형 AI 모델의 이론적 배경과 최신 기술 동향을 체계적으로 분석하였다. 특히 설계 데이터 유형에 따른 이미지, 텍스트, 파라메트릭 접근법을 비교 분석한 결과, 정량적 수치 조합이 핵심인 지반구조물 설계의 본질에는 파라메트릭 접근법이 가장 직접적이고 강력한 전략임을 논증하였다.

이러한 전략의 타당성을 검증하기 위해, 표준 파라메트릭 설계 생성 모델인 CVAE를 사면 보강 설계 문제에 적용하는 파일럿 연구를 수행하였다. 파일럿 연구 결과, CVAE 프레임워크는 일관된 파괴 거동을 보이는 사면 조건(Case 1)에서는 목표 안전율을 만족하는 다양한 설계 대안을 성공적으로 생성하며 높은 잠재력을 보여주었다. 하지만 상부 연약층으로 인해 파괴 모드가 급변하는 사면 조건(Case 2)에서는, 물리적 거동의 불연속성을 효과적으로 학습하지 못하는 명확한 기술적 한계를 드러냈다.

본 연구의 핵심 기여는 다음과 같이 요약할 수 있다.

- 지반공학 분야 설계자동화의 새로운 패러다임 제시: 국내외적으로 초기 단계에 머물러 있는 지반구조물 설계자동화 분야에 생성형 AI 기술의 적용 가능성을 파일럿 연구를 통해 실증적으로 검증하였다.
- 핵심 기술 과제 식별 및 해결 방향 제시: 표준 생성 모델이 지반공학 특유의 불연속적 파괴 거동 문제에 직면할 때 명확한 한계를 보임을 최초로 규명하였고, 복잡한 다중 모드 분포 학습에 강점을 가진 확산 모델(Diffusion Model)이라는 구체적인 차세대 기술 해결책을 제시하였다.

2. 향후 연구 방향 및 로드맵

본 연구에서 발견된 가능성과 한계점을 바탕으로, 생성형 AI 기반 지능형 지반설계 생태계 구축을 위한 단계별 연구 로드맵을 다음과 같이 제안한다.

■ 1단계: 기반 기술 고도화(기술 심화 및 적용 확대)

- 확산 모델 기반 프레임워크 개발: 파일럿 연구에서 확인된 불연속 분포 학습 문제를 해결하기 위해, 확산 모델(Diffusion Model)을 적용한 차세대 생성형 설계 프레임워크를 개발하고 성능을 검증한다.
- 실무 적용성 강화: 지하수위, 다층 지반, 지진 하중 등 복잡한 실제 설계 조건을 변수로 추가하여 모델의 실무 적용성을 강화한다.
- 타 지반구조물 확장: 검증된 방법론을 옹벽, 기초 등 타 지반구조물 설계 문제로 확장하여 기술의 범용성을 확보한다.

■ 2단계: 활용 영역 다각화(데이터 융합)

- 다중 데이터 형식 융합: 파라메트릭 기반 생성 기술을 중심으로, 이미지(Image) 기반의 지층 분석 및 상태 평가, 텍스트(Text) 기반의 설계 기준 검토 및 정보 연계 기술을 개발하고 융합한다.
- 지원 영역 확대: 단순 설계안 생성을 넘어, 안정성 검토 자동화, 설계 조건 분석 등 설계 프로세스 전반을 지원하는 다양한 모듈로 기능을 확대한다.

■ 3단계: 지능형 플랫폼 생태계 완성(실무 연계)

- 실무 프로세스 연동: 개발된 AI 엔진들을 BIM(Building Information Modeling) 등 실무 설계 플랫폼과 API로 연동하여, 설계-해석-도면화 과정의 효율성을 극대화한다.
- 통합 설계 플랫폼 구축: 최종적으로 설계 전 과정을 혁신하는 데이터 기반의 지능형 통합 설계 플랫폼 생태계를 구축하여, 설계 품질과 생산성을 획기적으로 향상시키는 것을 최종 비전으로 한다.

참고문헌 Reference

제1장

심영중, 진규남, 권석민, 서형중, 김예진 (2020), AI 기반 건설기술 현황 및 연구전략, 한국토지주택공사 토지주택연구원

제2장

데이비드 포스터 (2023), 만들면서 배우는 생성 AI, 한빛미디어.

양지훈, 윤상혁 (2023) ChatGPT를 넘어 생성형(Generative) AI 시대로 : 미디어 · 콘텐츠 생성형 AI 서비스 사례와 경쟁력 확보 방안, 한국방송통신전파진흥원.

Abdolahnejad, M., & Liu, P. X. (2020). Deep learning for face image synthesis and semantic manipulations: a review and future perspectives. *Artificial Intelligence Review*, 53(8), 5847–5880.

Bryan-Kinns, N., Zhang, B., Zhao, S., & Banar, B. (2024). Exploring variational auto-encoder architectures, configurations, and datasets for generative music explainable AI. *Machine Intelligence Research*, 21(1), 29–45.

Corvi, R., Cozzolino, D., Zingarini, G., Poggi, G., Nagano, K., & Verdoliva, L. (2023, June). On the detection of synthetic images generated by diffusion models. In *ICASSP 2023–2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 1–5). IEEE.

Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative adversarial nets. *Advances in neural information processing systems*, 27.

Hammad, A., Khalil, S., & Moretti, S. (2023). Search for mono-Higgs signals in bb

- final states using deep neural networks. *Physical Review D*, 107(7), 075027.
- Ho, J., Jain, A., & Abbeel, P. (2020). Denoising diffusion probabilistic models. *Advances in neural information processing systems*, 33, 6840–6851.
- Karras, T., Laine, S., & Aila, T. (2019). A style-based generator architecture for generative adversarial networks. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 4401–4410).
- Kingma, D. P., & Welling, M. (2013). Auto-encoding variational bayes. arXiv preprint arXiv:1312.6114.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521 (7553), 436–444.
- Rombach, R., Blattmann, A., Lorenz, D., Esser, P., & Ommer, B. (2022). High-resolution image synthesis with latent diffusion models. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 10684–10695).
- Saha, P. K., Nadeem, S. A., & Comellas, A. P. (2023). A survey on artificial intelligence in pulmonary imaging. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 13(6), e1510.
- Seiler, M., & Ritter, K. (2025). Pioneering new paths: the role of generative modelling in neurological disease research. *Pflügers Archiv–European Journal of Physiology*, 477(4), 571–589.
- Sohn, K., Lee, H., & Yan, X. (2015). Learning structured output representation using deep conditional generative models. *Advances in neural information processing systems*, 28.
- Valletti, M., Ziatdinov, M., Liu, Y., & Kalinin, S. V. (2024). Physics and chemistry from parsimonious representations: image analysis via invariant variational autoencoders. *npj Computational Materials*, 10(1), 183.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.

제3장

- Bagazinski, N. J., & Ahmed, F. (2023). Shipgen: A diffusion model for parametric ship hull generation with multiple objectives and constraints. *Journal of Marine Science and Engineering*, 11(12), 2215.
- Balmer, V., Kuhn, S. V., Bischof, R., Salamanca, L., Kaufmann, W., Perez-Cruz, F., & Kraus, M. A. (2024). Design space exploration and explanation via conditional variational autoencoders in meta-model-based conceptual design of pedestrian bridges. *Automation in Construction*, 163, 105411.
- Bucher, M. J. J., Kraus, M. A., Rust, R., & Tang, S. (2023). Performance-based generative design for parametric modeling of engineering structures using deep conditional generative models. *Automation in Construction*, 156, 105128.
- Danhaive, R., & Mueller, C. T. (2021). Design subspace learning: Structural design space exploration using performance-conditioned generative modeling. *Automation in Construction*, 127, 103664.
- Jang, S., Lee, G., Oh, J., Lee, J., & Koo, B. (2024). Automated detailing of exterior walls using NADIA: Natural-language-based architectural detailing through interaction with AI. *Advanced Engineering Informatics*, 61, 102532.
- Jang, S., Roh, H., & Lee, G. (2025). Generative AI in architectural design: Application, data, and evaluation methods. *Automation in Construction*, 174, 106174.
- Jiang, F., Ma, J., Webster, C. J., Li, X., & Gan, V. J. (2023). Building layout generation using site-embedded GAN model. *Automation in Construction*, 151, 104888.
- Lee, J. K., Jeong, H., Kim, Y., & Cha, S. H. (2024). Creating spatial visualizations using fine-tuned interior design style models informed by user preferences. *Advanced Engineering Informatics*, 62, 102686.
- Liao, W., Lu, X., Fei, Y., Gu, Y., & Huang, Y. (2024). Generative AI design for building structures. *Automation in Construction*, 157, 105187.
- Liao, W., Lu, X., Huang, Y., Zheng, Z., & Lin, Y. (2021). Automated structural design

- of shear wall residential buildings using generative adversarial networks. *Automation in Construction*, 132, 103931.
- Lu, X., Liao, W., Zhang, Y., & Huang, Y. (2022). Intelligent structural design of shear wall residence using physics-enhanced generative adversarial networks. *Earthquake Engineering & Structural Dynamics*, 51(7), 1657–1676.
- Oh, S., Jung, Y., Kim, S., Lee, I., & Kang, N. (2019). Deep generative design: integration of topology optimization and generative models. *Journal of Mechanical Design*, 141(11), 111405.
- Regenwetter, L., Nobari, A. H., & Ahmed, F. (2022). Deep generative models in engineering design: A review. *Journal of Mechanical Design*, 144(7), 071704.
- Sanchez-Lengeling, B., & Aspuru-Guzik, A. (2018). Inverse molecular design using machine learning: Generative models for matter engineering. *Science*, 361(6400), 360–365.
- Salamanca, L. (2025). AIXD | Generative AI toolbox for architects and engineers. SDSC. www.datascience.ch/articles/aixd-a-toolbox-for-generative-ai-for-architects-and-engineers
- Uhm, M., Kim, J., Ahn, S., Jeong, H., & Kim, H. (2025). Effectiveness of retrieval augmented generation-based large language models for generating construction safety information. *Automation in Construction*, 170, 105926.
- Wang, X., Qian, W., Zhao, T., Chen, H., He, L., Sun, H., & Tian, Y. (2025). A generative design method of airfoil based on conditional variational autoencoder. *Engineering Applications of Artificial Intelligence*, 139, 109461.
- Wang, Y., Shimada, K., & Barati Farimani, A. (2023). Airfoil GAN: Encoding and synthesizing airfoils for aerodynamic shape optimization. *Journal of Computational Design and Engineering*, 10(4), 1350–1362.
- Zhou, Y., Leng, H., Meng, S., Wu, H., & Zhang, Z. (2024). StructDiffusion: End-to-end intelligent shear wall structure layout generation and analysis using diffusion model. *Engineering Structures*, 309, 118068.

제4장

- 국토교통부 (2016), 건설공사 비탈면 설계기준.
- 국토해양부 (2012). 도로설계편람 - 토공 및 배수 편.
- 백세환, 이장덕, 이명환, 남순성, & 정상삼. (2001). 구조물기초 설계 기준. 지반 (한국지반공학회지), 17(4), 16-26.
- 한국철도시설공단 (2012). 철도 설계지침 및 편람 - KR C-06030 보강토 옹벽.
- Chan, C. M., Zhang, L. M., & Ng, J. T. (2009). Optimization of pile groups using hybrid genetic algorithms. *Journal of Geotechnical and Geoenvironmental Engineering*, 135(4), 497-505.
- Gandomi, A. H., Kashani, A. R., Roke, D. A., & Mousavi, M. (2017). Optimization of retaining wall design using evolutionary algorithms. *Structural and Multidisciplinary Optimization*, 55(3), 809-825.
- Ghosh, S., & Paul, A. (2016). Analysis of soil nail excavation considering Rayleigh wave with log-spiral failure surface. *International Journal of Geosynthetics and Ground Engineering*, 2(2), 18.
- Huang, Y., He, Z., Yashima, A., Chen, Z., & Li, C. (2022). Multi-objective optimization design of pile-anchor structures for slopes based on reliability theory considering the spatial variability of soil properties. *Computers and geotechnics*, 147, 104751.
- Katagiri, J., Yoneda, J., & Tenma, N. (2016). Multiobjective optimization of the particle aspect ratio for gravel pack in a methane-hydrate reservoir using pore scale simulation. *Journal of Natural Gas Science and Engineering*, 35, 920-927.
- Khajehzadeh, M., Taha, M. R., & Eslami, M. (2013). Efficient gravitational search algorithm for optimum design of retaining walls. *Structural Engineering and Mechanics*, 45(1), 111-127.
- Liao, W., Lu, X., Fei, Y., Gu, Y., & Huang, Y. (2024). Generative AI design for building structures. *Automation in Construction*, 157, 105187.

- Lim, A., Ou, C. Y., & Hsieh, P. G. (2018). Investigation of the integrated retaining system to limit deformations induced by deep excavation. *Acta Geotechnica*, 13(4), 973–995.
- Metwally, M. I. (2016). Design of Transfer Slabs Using Strut-and-Tie Model (Doctoral dissertation, Mansoura University).
- Taiyari, F., Kharghani, M., & Hajihassani, M. (2020, December). Optimal design of pile wall retaining system during deep excavation using swarm intelligence technique. In *Structures* (Vol. 28, pp. 1991–1999). Elsevier.

제5장

- 브사렐건설. (2024). 남부내륙철도 제10공구 기본 설계 DAP 앵커패널 옹벽 구조검토서.
- 브사렐 건설. (2024). 남부내륙 10공구 기본 설계 비탈면 안정성 검토.
- Kim, T., Sim, Y. J., Kim, H., & Yun, T. S. (2026). Feasibility of conditional VAE-based generative design for slope nail reinforcement. In *Proceedings of the 21st International Conference on Soil Mechanics and Geotechnical Engineering (ICSMGE 2026)*, Vienna, Austria.

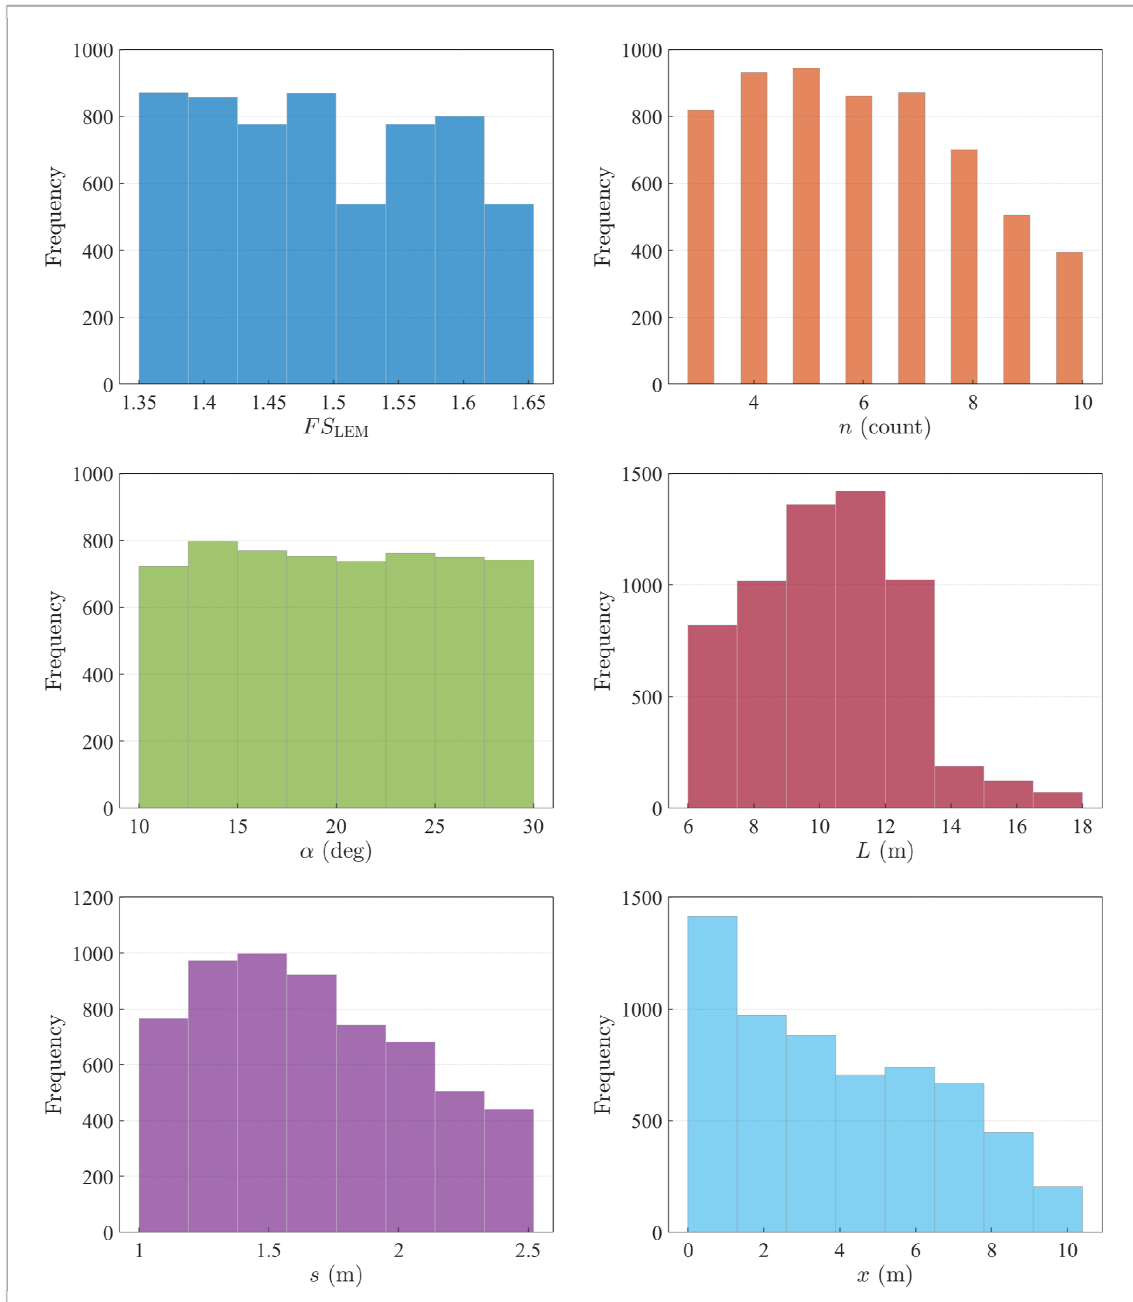
부 록 Appendix

1. CVAE 모델 학습 데이터

CVAE 모델 학습 데이터의 수치형 변수 통계 (n=6,000)

변수	평균 (Mean)	표준편차 (Std. Dev)	최소값 (Min)	최대값 (Max)
FS_{LEM} (실제값)	1.5	0.1	1.4	1.7
n (개수)	6.0	2.1	3.0	10.0
α (각도, °)	19.9	5.8	10.0	30.0
L (길이, m)	10.3	2.3	6.0	17.7
s (간격, m)	1.7	0.4	1.0	2.5
x (거리, m)	3.9	2.8	0.0	10.0
H_1 (상부층, m)	21.5	3.5	15.1	27.0
γ_1 (kN/m ³)	18.4	1.8	16.0	24.0
c_1 (kPa)	21.8	34.4	0.1	148.6
ϕ_1 (°)	31.6	4.3	22.3	41.4
H_2 (하부층, m)	8.5	3.5	3.0	14.9
γ_2 (kN/m ³)	19.2	2.1	17.0	23.9
c_2 (kPa)	36.7	35.8	5.4	149.4
ϕ_2 (°)	29.3	5.3	22.1	41.9

CVAE 모델 학습 데이터의 안전율(FS_{LEM}) 및 주요 설계 변수(n, α, L, s, x) 분포 ($n=6,000$)



2. CVAE 모델 생성 데이터

Case 1 (n=300)

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
1	4	27.3	16.4	1	9.3	1.946	2.086
2	3	30	16.9	1.3	8.9	1.833	2.08
3	6	20.3	17.6	1.5	5.9	2.033	2.038
4	4	29.8	16	1.5	9.1	1.99	2.031
5	4	30	16.5	1.7	8.6	2.025	2.024
6	6	30	13.3	1.9	5.6	1.959	2.005
7	4	24.7	16.1	1.7	7.1	1.885	1.994
8	10	30	12.6	1	5.8	1.954	1.992
9	4	30	13.1	1.7	9.4	1.849	1.976
10	6	26.3	13.7	1.3	7.5	1.888	1.95
11	8	18.1	15.1	1.7	1.7	1.896	1.921
12	6	20.8	13.3	1.7	6.4	1.865	1.918
13	5	20.9	14.8	1.9	5.5	1.852	1.899
14	5	23.8	13.1	1.5	7.8	1.82	1.882
15	10	24.6	12.2	1	5.5	1.845	1.88
16	7	19.1	13.5	1.9	3.2	1.861	1.876
17	4	24.4	12.8	1.9	8.6	1.781	1.875
18	3	14.6	16	1.9	8.5	1.741	1.874
19	5	24.1	14.7	1.3	6.2	1.816	1.86
20	6	30	11.6	1.4	7.3	1.81	1.86
21	4	23.2	12.7	1.9	8.6	1.77	1.86
22	5	10	17.6	2.4	2	1.827	1.857
23	6	23.1	14	1.7	4.2	1.82	1.854
24	6	24	13.4	1.1	7.5	1.805	1.851
25	4	22.2	12.9	1.9	8.5	1.76	1.844
26	5	15.9	13.2	1.5	8.6	1.775	1.832
27	8	30	11.5	1.4	4	1.774	1.824
28	9	28.1	13.4	1.2	1.8	1.797	1.817
29	5	24.3	14.6	1	6.3	1.775	1.812
30	5	28.3	12.9	1	8	1.755	1.811
31	4	30	12.6	2.2	6.2	1.748	1.809
32	10	21.4	12	1	4.9	1.778	1.805

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
33	8	19.7	13.4	1.7	1.5	1.785	1.803
34	4	18	12.5	1.9	8.8	1.725	1.803
35	3	28.3	12.9	2.3	8	1.666	1.802
36	6	30	13.2	1.3	4.6	1.775	1.791
37	6	24.2	11.4	1.6	6	1.746	1.783
38	5	15.7	13.4	2.1	5.5	1.753	1.78
39	6	23.6	11.2	2	4.5	1.742	1.769
40	4	18.9	15.8	1.4	4.6	1.702	1.769
41	3	19.2	14.8	1	7.9	1.647	1.769
42	8	27.1	10.5	1.7	2.6	1.726	1.766
43	5	21.9	12.3	1.9	5.7	1.734	1.765
44	5	14.6	14.5	1.5	5.7	1.744	1.763
45	4	21.2	13	2.2	6.2	1.714	1.761
46	6	23.5	11.5	1.6	5.8	1.728	1.76
47	5	16.2	12.2	2.2	5.6	1.721	1.759
48	5	29.2	12.9	1.2	6.3	1.72	1.757
49	6	30	9.8	1.9	5.4	1.71	1.756
50	7	28.4	12.1	1.2	5	1.733	1.755
51	9	23.5	10.5	1.6	1.7	1.733	1.751
52	4	14.4	13	1.9	8.1	1.697	1.75
53	8	23.5	10.3	1.5	4.1	1.69	1.732
54	8	30	11.5	1	5.1	1.698	1.73
55	5	27.6	11.2	2.2	4.5	1.7	1.728
56	5	24.6	14.8	1.7	1.6	1.687	1.722
57	4	22.3	13.4	1.9	5.1	1.682	1.717
58	7	25.9	10.7	1.8	3.2	1.704	1.714
59	5	27.4	15.3	1.2	2.2	1.662	1.714
60	9	21.7	9.9	1.4	4.1	1.678	1.712
61	6	30	10.6	1.2	7.2	1.669	1.707
62	8	30	12.4	1.5	0	1.716	1.705
63	7	21.4	12.6	1.2	4.2	1.703	1.705
64	5	20.1	10.9	1.5	8	1.647	1.703
65	8	30	11.7	1	4.4	1.683	1.701
66	6	17.5	12.6	1.6	4.6	1.688	1.696
67	5	10.4	14.5	1.5	5.3	1.689	1.694
68	6	13	11.3	1	9.7	1.652	1.693
69	5	21.8	13.5	1.6	3.8	1.689	1.69
70	4	10	13.9	2	6.4	1.658	1.689
71	7	16.8	11.3	1.9	2.8	1.685	1.68
72	4	19.5	13.6	2	4.3	1.658	1.68

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
73	10	19.9	10.1	1.3	2.8	1.654	1.68
74	7	21.2	10.7	1.7	3.8	1.669	1.679
75	5	20.6	12.1	1.4	6.4	1.658	1.679
76	4	24.3	11.8	1.6	7.1	1.624	1.678
77	6	30	10.9	1.1	6.7	1.653	1.677
78	8	24.4	9.2	1.3	5.5	1.62	1.677
79	7	16.4	12.8	1.2	4.5	1.674	1.676
80	4	18.3	12.6	2.1	5.7	1.651	1.676
81	4	16.6	13.7	1.1	6.5	1.634	1.674
82	9	22.2	9.8	1.4	3.3	1.648	1.673
83	4	23.8	12.3	1.7	6.1	1.635	1.673
84	3	25.5	11.2	1	10	1.582	1.662
85	3	20.6	11.4	2.3	8.3	1.571	1.662
86	7	21.1	10.1	1.9	2.7	1.647	1.656
87	6	19.4	12.1	1.7	3.4	1.663	1.655
88	5	15.8	12.7	2.2	3.2	1.657	1.653
89	7	13.7	12.2	1.5	3.6	1.656	1.648
90	5	29.3	12.4	1.2	4.5	1.631	1.648
91	10	19.9	11.3	1	3.1	1.634	1.643
92	4	16.5	13.5	1.8	4.6	1.628	1.642
93	5	30	9.9	1.3	7.6	1.58	1.639
94	6	30	10.6	1.5	4.7	1.632	1.638
95	5	30	10.8	1.6	5.3	1.613	1.638
96	5	23.9	11.7	1.3	5.8	1.62	1.637
97	4	15.4	11.8	1.5	8	1.592	1.633
98	5	30	9.2	2	5.5	1.578	1.63
99	5	14.6	12.1	1.8	4.9	1.621	1.629
100	4	30	10.1	1.9	6.8	1.561	1.628
101	4	21.5	10.3	2.2	7	1.568	1.627
102	6	26.7	10.8	2	2.2	1.641	1.626
103	4	24.8	12.8	2	3.5	1.607	1.625
104	6	30	8.8	1.3	7.3	1.568	1.622
105	9	25.2	9.8	1.2	3.3	1.607	1.621
106	8	29.3	10.6	1	4.4	1.6	1.621
107	5	23.3	12.7	1.3	4.2	1.628	1.617
108	4	14.8	12.5	2.5	4.2	1.618	1.617
109	6	17.3	9.8	1.6	6	1.575	1.615
110	7	20.4	9.2	1.5	5.6	1.562	1.613
111	9	11.1	10.2	1.5	2.5	1.593	1.611
112	5	20.2	12.4	1.3	4.9	1.619	1.609

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
113	8	16.9	10.3	1.4	3.5	1.57	1.596
114	9	11.2	10.5	1.4	3.1	1.577	1.595
115	3	16.1	11.8	1.5	8.6	1.548	1.594
116	7	10	11.4	1.8	2.8	1.599	1.59
117	3	10	12.6	1.2	9.2	1.56	1.586
118	7	22.9	11	1.9	0	1.615	1.583
119	5	16.4	10	1.7	6.9	1.535	1.583
120	5	18.3	12	1	6.2	1.584	1.581
121	8	25.6	9.5	1.7	0.7	1.561	1.58
122	5	27.3	9.2	1.7	6.1	1.527	1.58
123	7	28.6	9.4	1.2	5	1.554	1.579
124	5	24.2	7.7	1.1	10	1.487	1.579
125	4	30	10.6	2.5	3.8	1.55	1.573
126	7	30	9	1.3	4.8	1.54	1.572
127	4	18.6	11.4	1	7.9	1.537	1.568
128	10	14.7	9.3	1.3	2.2	1.52	1.561
129	5	12.6	9.9	1.8	6.6	1.5	1.558
130	4	14.6	12	1.8	5.1	1.553	1.557
131	6	30	6.7	2.1	4.2	1.469	1.554
132	3	28.8	11.5	1.2	6.8	1.476	1.553
133	3	23.1	15.4	1.3	3.1	1.465	1.552
134	3	16.7	11.4	2.4	6.6	1.498	1.551
135	6	25.9	8	1.5	6.3	1.49	1.551
136	5	17.1	11.7	1.8	3.4	1.571	1.549
137	6	11.6	11.8	1.4	4.4	1.538	1.547
138	4	20.7	7.6	2.1	8.2	1.434	1.545
139	8	11.4	9.7	1.1	6.1	1.487	1.544
140	3	14	9.1	2.1	10	1.471	1.541
141	8	13.5	9	1.2	5.4	1.479	1.54
142	8	17.2	10.6	1	4.5	1.522	1.537
143	4	30	13.3	1.4	2.3	1.507	1.536
144	4	19.8	10.7	1.5	6.5	1.51	1.535
145	5	17.8	10.4	2.2	3.2	1.535	1.533
146	4	16.2	11.9	1	6.5	1.517	1.531
147	5	14.6	10.9	1.2	6.9	1.511	1.53
148	5	10.4	12.3	2.3	1	1.552	1.528
149	8	23.9	10.8	1	2.8	1.535	1.528
150	4	21.3	12	1.9	3.3	1.533	1.528
151	6	10	9.1	1.5	6.8	1.465	1.528
152	3	23	8.5	2.2	9	1.439	1.525

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
153	5	16.9	12.5	1.4	2.2	1.544	1.523
154	4	18.6	11.7	1.5	4.8	1.523	1.523
155	4	27.3	8.3	2.5	5.7	1.454	1.52
156	4	26.2	8.9	1.8	7.1	1.455	1.516
157	5	10	12.1	1.8	3.2	1.534	1.515
158	5	18	9.7	1.4	6.7	1.479	1.514
159	5	14.3	11.6	1	5.8	1.517	1.513
160	6	21	7.7	1.9	4.6	1.451	1.512
161	6	24.2	12.1	1	1.7	1.52	1.51
162	3	18.7	11.2	1.6	6.9	1.471	1.509
163	4	14.4	9.2	2.1	7.4	1.451	1.508
164	8	12	7.6	1.8	2.5	1.446	1.506
165	4	21.2	10.4	1.8	5.5	1.493	1.504
166	6	15.5	7	1.5	7.4	1.43	1.504
167	10	20.5	8.8	1	3.6	1.467	1.499
168	4	19.3	8.6	1	10	1.439	1.493
169	4	16	10.4	1.5	6.9	1.475	1.492
170	3	10	10.7	2.1	8	1.461	1.492
171	3	17.9	12.2	1.3	5.4	1.452	1.492
172	3	25.7	10.7	2.3	5.1	1.426	1.491
173	3	17.7	10.9	1.5	7.1	1.458	1.49
174	3	23.3	11.2	1.8	5.4	1.439	1.49
175	4	22.1	10.5	1.7	5	1.483	1.488
176	4	13	11.2	1.1	7	1.473	1.487
177	3	13.7	10.9	1.6	7.8	1.462	1.487
178	3	27.4	11.4	1.3	5.4	1.426	1.487
179	4	19.1	10.9	1.9	4.3	1.49	1.485
180	5	13.6	7.5	2.2	5.9	1.391	1.481
181	5	23.5	11.1	1.9	1.1	1.495	1.48
182	4	17.8	10.7	2.2	3.7	1.484	1.48
183	3	22.2	8	2.2	8.8	1.396	1.48
184	7	19	10.1	1.1	4.3	1.488	1.479
185	6	30	9.9	1	4.6	1.497	1.474
186	4	22.9	9	1.2	8.3	1.431	1.474
187	6	18.7	10.5	1.5	2.4	1.494	1.47
188	4	20.8	10.3	1.9	4.5	1.463	1.469
189	8	20.7	10.5	1.3	0.5	1.486	1.467
190	4	18	9.4	1.4	7.5	1.434	1.467
191	7	24.1	9.5	1	4.6	1.471	1.465
192	5	29.3	8.4	1.1	7	1.413	1.463

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
193	5	20.6	10.7	1	5	1.474	1.461
194	5	18.6	9.1	1.5	6	1.425	1.461
195	3	17.6	10.6	1.7	6.5	1.426	1.46
196	8	20.6	8.4	1.6	1.1	1.423	1.46
197	5	27.5	8.6	1.9	4.1	1.419	1.458
198	7	17.6	10.6	1.3	1.4	1.492	1.447
199	6	21.2	9.4	1.2	4.5	1.433	1.447
200	3	13.5	7.9	2.2	9.4	1.381	1.447
201	6	28.8	7.7	1.7	3.8	1.401	1.442
202	6	18.4	10.8	1	3.2	1.435	1.436
203	3	26.1	11	1.5	4.7	1.393	1.436
204	4	27.3	11.9	1.4	2.2	1.443	1.435
205	4	21.4	10.3	2.5	1.8	1.425	1.433
206	8	18.7	10.3	1	1.8	1.429	1.429
207	4	23.4	10.5	1	4.9	1.412	1.429
208	7	27	7.7	1.5	3.3	1.39	1.429
209	10	17.3	8.5	1	2.9	1.389	1.429
210	5	10.3	10.1	2.1	2.5	1.414	1.428
211	6	12.6	6.6	1	9.4	1.371	1.428
212	6	26.8	10.3	1.6	0	1.438	1.427
213	4	28.7	10.2	1	4.7	1.397	1.424
214	3	16.5	7.4	1.7	9.9	1.362	1.422
215	5	15.5	8.2	2.2	4	1.36	1.421
216	8	21.1	6.3	1.5	3.2	1.353	1.418
217	3	13.7	12.7	1.7	3.6	1.413	1.416
218	9	22.5	8.2	1.4	0	1.389	1.416
219	6	18.8	9.6	1.2	3.5	1.403	1.413
220	4	10	8.7	1.7	7.4	1.359	1.409
221	5	11.6	10.7	1.7	2.1	1.409	1.408
222	8	20.7	9.5	1.3	0.2	1.406	1.408
223	8	17.7	8.4	1.1	4	1.365	1.406
224	5	17.5	8.3	2.5	1.8	1.347	1.402
225	3	24.6	9.7	1.2	6.1	1.353	1.4
226	4	21.1	9.2	1.3	5.8	1.374	1.394
227	7	18.9	6	1.9	2.1	1.313	1.392
228	7	22.7	7.6	1.3	3.7	1.345	1.391
229	5	24	8	1.9	3.4	1.325	1.39
230	4	21	7.4	2	6	1.303	1.389
231	3	23.8	10.4	1.1	5.4	1.36	1.388
232	4	11.9	8.8	2	5.7	1.338	1.388

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
233	7	10	9	1	5.6	1.351	1.387
234	5	14.8	8.8	1.3	6	1.34	1.384
235	5	19.4	8.2	2.1	2.6	1.326	1.383
236	9	10	9	1	3.1	1.355	1.382
237	4	15.9	8.4	2	5.1	1.315	1.376
238	6	18	7.8	1.3	5	1.309	1.376
239	8	22.1	6.6	1.2	3.7	1.296	1.374
240	3	16.3	9.7	1.8	5.4	1.337	1.371
241	3	13.2	8.5	1.6	8.1	1.312	1.369
242	5	19.5	8.4	1.2	5.3	1.316	1.368
243	6	21.2	10.1	1	1.1	1.334	1.363
244	7	21.5	7.1	1	5.6	1.303	1.362
245	6	17.4	9.3	1.8	0	1.346	1.361
246	7	27.9	7.1	1.2	3.6	1.296	1.361
247	3	23.8	11.6	1.6	3	1.365	1.359
248	3	11.2	11.8	1.7	3.2	1.351	1.357
249	8	14.3	9	1.2	1	1.323	1.357
250	5	15.4	8.8	1.7	3.1	1.314	1.351
251	4	30	11.7	1	2.1	1.371	1.349
252	5	30	9	1	3.7	1.318	1.346
253	3	30	8.4	1.3	6.5	1.288	1.346
254	3	14.9	9.2	1.6	6.2	1.31	1.345
255	5	12.3	6.5	1.8	5.6	1.241	1.342
256	3	15.3	11.8	2.2	1.9	1.357	1.341
257	3	18.4	11.1	1.9	3	1.35	1.337
258	3	30	11.7	1.7	2.4	1.346	1.336
259	8	12.7	7.6	1	4.5	1.259	1.33
260	3	26.4	10.8	1.9	2.7	1.333	1.327
261	6	26.9	6.2	1.1	6	1.248	1.327
262	3	30	8.6	1.3	6	1.284	1.324
263	4	28.6	11.4	1.9	0	1.371	1.322
264	4	10	9.8	1.2	4.5	1.298	1.322
265	4	30	9	1.3	3.6	1.305	1.319
266	3	19.7	7.7	1.8	6.8	1.256	1.313
267	3	20.2	9.4	2	4.1	1.3	1.311
268	3	19.6	8.3	2.4	4.9	1.251	1.309
269	7	10	9.5	1	0.3	1.247	1.303
270	4	16.9	8.2	1.5	5.3	1.267	1.299
271	3	10	11.1	1.1	2.9	1.261	1.297
272	5	21.5	8.7	1.1	3.5	1.272	1.289

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
273	3	10	8.7	2.4	4.7	1.237	1.282
274	7	19.1	6	1.3	4.3	1.21	1.282
275	6	10.5	6.9	1.1	6.1	1.191	1.277
276	3	24.8	9.1	1.6	4.1	1.275	1.276
277	3	24.4	7.4	1.5	6.6	1.23	1.269
278	3	16.6	13.3	1.8	0	1.309	1.264
279	6	23.6	6.8	1.6	2.2	1.206	1.26
280	5	23.6	10	1	0	1.243	1.258
281	6	20.5	8.3	1	2.2	1.228	1.257
282	4	14.5	8.7	1	4.1	1.224	1.254
283	3	10	9.6	1.4	3.2	1.228	1.25
284	7	12.5	7	1.2	3.7	1.191	1.25
285	4	14.5	7.5	1	6.8	1.205	1.248
286	3	27.2	11.3	1.2	1.3	1.272	1.244
287	6	28.5	7	1.9	0.1	1.206	1.244
288	4	10	9.8	1.7	0	1.254	1.235
289	4	12.7	7.7	1.6	4.9	1.2	1.233
290	5	10	7.2	2	2.8	1.174	1.227
291	4	12.1	7	1.2	7	1.178	1.225
292	3	25.4	9.2	1.3	2.7	1.242	1.223
293	3	15.2	8.7	1.7	2.5	1.214	1.215
294	4	14.5	6.7	1.7	4.8	1.145	1.196
295	3	18.9	7.3	2.5	2.1	1.162	1.171
296	5	15.3	6.5	1.2	3.9	1.132	1.158
297	4	17.4	6.6	1.2	4.8	1.127	1.155
298	5	14.5	6	2.1	0.8	1.12	1.134
299	3	11.3	6.4	1.1	1.9	1.104	1.131
300	4	10	6.1	1.2	1.6	1.094	1.13

Case 2 (n=300)

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
1	8	21.8	13.3	2	0.8	2.482	3.267
2	9	12.8	8.7	1.4	2.7	2.144	3.251
3	8	22	17.7	1.5	0	2.488	3.038
4	7	14.3	12.4	2.1	1.3	2.357	2.949
5	10	17.5	9	1.3	2.4	2.235	2.858
6	6	22.9	14.3	1.9	0	2.35	2.828
7	10	23.9	11.1	1.2	1.7	2.328	2.817
8	10	18.8	14	1.4	0	2.463	2.796
9	8	16.1	13.2	1.6	0.5	2.327	2.793
10	9	22.7	9.2	1.3	0.8	2.079	2.729
11	7	24.9	13.1	1.4	3	2.232	2.697
12	5	26.1	12.4	2.1	1.8	2.287	2.652
13	7	19.7	9.5	1.7	3.4	2.189	2.635
14	7	18.8	13.4	1.7	2.3	2.415	2.604
15	6	16.5	13.2	2	1.9	2.338	2.604
16	9	29.9	7.5	1.8	0.3	2.309	2.604
17	7	27.8	9.7	1.9	0.9	2.239	2.604
18	7	20.3	10.1	1.8	2	2.177	2.604
19	5	24.5	12.6	1.8	2.1	2.15	2.604
20	7	25	12.1	1.3	1.4	2.128	2.604
21	6	17.9	12.5	1.2	2.7	2.103	2.604
22	9	25.1	10.6	1	0	1.988	2.604
23	8	28.5	12.2	1.6	2.5	2.234	2.603
24	5	19.2	13.4	1.6	3.3	2.226	2.559
25	5	25.6	13.9	2	3.5	2.211	2.544
26	6	19.3	10.6	2.1	3.5	2.197	2.532
27	7	25.3	13.7	1.3	0.5	2.245	2.518
28	7	23.3	12.7	1.4	3.3	2.227	2.499
29	6	11.2	11.6	1.9	0.8	2.064	2.47
30	7	29.3	9.9	1.6	3.3	2.192	2.409
31	4	25.1	11	2.5	0.5	1.88	2.336
32	5	14.5	13	1.4	3.3	2.114	2.329
33	7	17.5	12.4	1.4	0	2.076	2.322
34	7	29.8	9.8	1.6	2.1	2.157	2.294
35	8	25.5	8.3	1.6	1.1	2.123	2.287
36	8	19	9.6	1.3	2.4	2.116	2.251
37	8	24.9	8.1	1.7	1.3	2.13	2.246
38	9	14.6	10.8	1.3	0	2.103	2.22
39	5	20.2	12.3	1.7	2	2.085	2.208
40	5	23	14.1	1.5	0.8	2.028	2.195

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
41	7	18.3	9.6	1.3	2.3	1.981	2.179
42	10	10	7.8	1.6	0.3	2.122	2.165
43	7	21.5	11.7	1.4	0.1	2.068	2.151
44	5	18.6	8.8	1.8	2.9	1.903	2.148
45	4	20.1	14	2	1.1	1.987	2.137
46	8	18.2	8.5	1.9	0.2	2.127	2.127
47	6	22.1	12	1.4	0	1.968	2.114
48	10	25.8	8.4	1	1.4	2.003	2.089
49	4	11.3	12.9	1.8	3	1.994	2.087
50	7	21.8	7.7	1.6	2.1	2.024	2.08
51	7	22.8	7.9	1.4	2.8	2.016	2.078
52	10	14.2	6	1.4	1.1	2.041	2.075
53	9	18.1	7.6	1.4	0.5	1.979	2.064
54	3	13	13.6	1.2	2.7	1.87	2.062
55	8	14.1	10.3	1.5	0	2.036	2.061
56	6	21.1	13.8	1	1.3	2.047	2.042
57	6	20.3	10.8	1.2	1.8	1.964	2.039
58	8	13.8	8.1	1.8	1.4	2.058	2.013
59	7	15.3	7.9	2	0.9	1.992	2.002
60	10	13.5	10.6	1	0	1.976	1.981
61	6	17.3	12.3	1.3	0.4	1.971	1.978
62	5	25.6	14.3	1.5	0.2	1.943	1.978
63	5	20.3	9.9	1.9	1.7	1.941	1.954
64	6	25.1	9.8	1.4	1.4	1.91	1.94
65	5	19.3	12.1	1.5	2.3	2.043	1.937
66	7	22.2	8.2	1.5	1.3	1.871	1.936
67	8	13.2	8.7	1	3.4	1.893	1.934
68	6	29	8.4	1.9	0.3	1.882	1.929
69	5	16.3	11.4	1.5	1.5	1.902	1.924
70	7	18	9.8	1.7	3.8	1.839	1.921
71	4	21.4	12.3	1.2	2.6	1.884	1.915
72	5	18.8	14.1	2.3	4	1.857	1.914
73	5	12.1	16.2	1.4	4.6	1.775	1.913
74	6	20.2	10.4	1.7	0	1.918	1.902
75	3	24.7	12.1	2	4	1.838	1.893
76	8	12.1	10	1.2	3.8	1.83	1.891
77	5	23.2	9.1	1.8	3.7	1.84	1.889
78	7	28.2	14.3	1.4	4	1.855	1.886
79	7	18.2	11.4	1.2	4	1.844	1.881
80	6	18	9.3	1.6	3.6	1.85	1.863

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
81	10	14.4	7.5	1.3	0	1.869	1.862
82	5	15.5	9.5	2.2	2.6	2.027	1.842
83	9	10	9.3	1.2	1.6	2.01	1.842
84	4	17.2	13.5	1.7	1.9	2.008	1.842
85	10	21.4	6.4	1.5	0	1.98	1.842
86	4	13.2	13.4	1.8	0.9	1.964	1.842
87	7	21.7	7.2	1.8	1.1	1.92	1.842
88	6	10	10.7	1.7	0.9	1.899	1.842
89	6	13.8	8.3	1.6	3.2	1.876	1.842
90	5	11.4	11.3	1.5	2.3	1.875	1.842
91	8	26.2	10.6	1.1	3.6	1.847	1.842
92	4	19.3	9.4	2.5	4	1.82	1.842
93	7	16.9	8	1.5	3.9	1.816	1.842
94	3	18.3	10.8	2.1	4.4	1.807	1.842
95	7	10	9.8	1	3.7	1.798	1.842
96	5	10	12.6	2.1	4.7	1.78	1.842
97	5	13.6	13.9	1.2	4.7	1.767	1.842
98	4	13.5	12.3	1.5	4.8	1.761	1.842
99	7	18.8	9.6	1.1	4.8	1.757	1.842
100	8	13.9	9.1	1.1	4.8	1.753	1.842
101	4	25.1	12.2	1.9	1	1.745	1.842
102	3	17.6	12.5	2.1	2.3	1.742	1.842
103	5	23.4	8	1.3	4.6	1.736	1.842
104	8	26.9	9.8	1	0	1.734	1.842
105	7	15.7	7.6	2	2.4	1.725	1.842
106	5	27.9	9.7	1.8	0.5	1.714	1.842
107	4	10	10.1	1.8	3.4	1.712	1.842
108	5	23.9	6	1.9	4.3	1.708	1.842
109	7	14.8	9	1.5	0.2	1.697	1.842
110	4	12.4	12.4	1.7	0	1.689	1.842
111	7	24	7.4	1.6	0	1.662	1.842
112	6	22.1	9.2	1.5	0.3	1.661	1.842
113	9	13.8	8.7	1	0.2	1.624	1.842
114	3	19	10.3	1.1	3.3	1.617	1.842
115	4	20.8	7	1.4	4.5	1.549	1.842
116	8	15.2	16	1.2	3.8	1.867	1.837
117	8	22.6	9.9	1.2	4.2	1.811	1.835
118	9	20.2	6.4	1.2	4.4	1.835	1.83
119	5	15.1	6	1.9	3.8	1.617	1.829
120	7	15.5	9.7	1.3	4	1.817	1.824

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
121	8	22.2	9.2	1.5	4.3	1.78	1.821
122	5	22.9	14.1	1.5	4.7	1.802	1.815
123	8	14.7	10.7	1.3	3.7	1.84	1.813
124	5	24.6	9.5	1.6	4.1	1.837	1.811
125	7	16.1	12.5	1.7	4.5	1.808	1.806
126	6	19.5	8.3	1	3.3	1.646	1.803
127	5	21.7	9.6	2.1	4.8	1.775	1.79
128	3	22.7	11.2	1.6	4.1	1.812	1.779
129	7	15.9	8.8	1.6	0	1.719	1.774
130	5	15.5	9.8	1.5	4.7	1.758	1.763
131	5	18.7	11.2	1.1	1.8	1.742	1.763
132	3	12.8	11.7	2	2.6	1.712	1.761
133	4	23.7	9.2	1.8	2	1.645	1.761
134	4	18.1	10.7	1	4.8	1.755	1.759
135	8	19.4	7.8	1.5	0.1	1.731	1.755
136	4	29.5	11.8	2	1	1.723	1.752
137	8	21.7	8.3	1.3	4.1	1.769	1.75
138	7	17.7	9.6	1.4	0	1.728	1.741
139	3	15.9	11.8	1.6	3.5	1.722	1.733
140	4	17.8	8.4	1	2.2	1.451	1.732
141	5	22.4	9.6	1	3	1.692	1.728
142	4	10	10.9	1.1	4.6	1.719	1.721
143	4	18.5	10.1	1	3	1.656	1.719
144	3	11.6	14.6	1.3	1.3	1.717	1.714
145	7	29.1	6.7	1.5	1.5	1.692	1.709
146	6	10	9.7	1.6	0.7	1.667	1.706
147	6	14.1	6	2.5	0	1.684	1.697
148	6	12.3	10.3	1.2	4	1.807	1.694
149	3	20.5	10.2	1.8	2.8	1.631	1.686
150	5	12.8	7.8	1.9	2.8	1.667	1.679
151	4	29.4	10.6	1.5	1.3	1.631	1.679
152	3	12.5	11.5	1.5	3.2	1.688	1.665
153	5	30	6.8	1.8	2.4	1.606	1.661
154	9	10.6	6	1.3	1.6	1.67	1.659
155	3	19.3	10.7	1	4.1	1.657	1.652
156	8	18	6	1.2	2.5	1.645	1.65
157	5	23.5	9.9	1.6	0.6	1.699	1.646
158	4	16.7	10	2.2	0.7	1.637	1.645
159	5	21.2	11.8	1	0	1.62	1.641
160	4	22.8	10.6	1.2	1.1	1.638	1.64

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
161	5	28.9	10.5	1.1	0	1.546	1.636
162	8	11.7	6.9	1.6	0	1.651	1.633
163	4	24.7	12	1.6	0	1.591	1.623
164	4	20.4	9.8	1.7	0.9	1.611	1.621
165	4	16.7	11.4	1	0.2	1.601	1.621
166	5	10	10.7	1.4	0	1.61	1.613
167	3	21.3	9.1	1.7	2.7	1.564	1.613
168	4	10.1	10.3	1.8	0	1.554	1.613
169	3	23.3	10.7	1.4	2.5	1.622	1.611
170	7	25.9	6	1.8	0	1.616	1.594
171	7	13.3	8.2	1.3	0.8	1.587	1.587
172	3	15.3	9.7	2.4	1.7	1.581	1.58
173	4	13.5	8.3	1.5	4.3	1.613	1.578
174	3	25.1	9.9	1	2.4	1.564	1.577
175	5	18.2	6	1.9	3.3	1.593	1.575
176	4	20.2	9.4	1.1	1.7	1.569	1.571
177	4	22.9	7.1	1.6	3.7	1.527	1.567
178	8	10	6	1.4	1.8	1.544	1.566
179	6	13.5	12.7	1.6	5.2	1.502	1.565
180	4	25.5	12	1.4	0	1.567	1.564
181	6	17.4	6.3	1.2	4.1	1.562	1.564
182	8	19.3	8.3	1	0	1.567	1.562
183	6	23.2	6	2	0	1.552	1.562
184	4	24.1	9	1.9	0	1.542	1.558
185	4	21.3	6	1.9	4.4	1.547	1.557
186	5	24.6	8	1	1.9	1.514	1.549
187	6	19.1	7.4	1	2.1	1.509	1.548
188	6	15.7	9.5	1.2	0	1.581	1.546
189	3	25.6	11.1	1.3	5.3	1.484	1.546
190	3	22.3	8.6	1	3.1	1.512	1.545
191	7	10	6	1.4	2	1.523	1.54
192	4	21.4	9.2	1.2	0.9	1.53	1.537
193	5	16.4	9	1.3	0	1.513	1.536
194	6	19.9	8	1.9	5.1	1.504	1.534
195	4	14.1	10.8	1	0	1.524	1.532
196	4	28.5	7.9	1.4	2.3	1.527	1.527
197	4	10	10.5	1	0	1.508	1.527
198	3	13.7	9.3	1.2	2.8	1.525	1.525
199	5	12.8	11.1	2.1	4.9	1.508	1.523
200	4	21.4	12	2.3	5.4	1.497	1.521

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
201	4	21.2	8	1.7	5.1	1.484	1.521
202	5	21.5	8.4	1.2	1.2	1.526	1.515
203	5	24.7	13.7	2.2	6.1	1.5	1.513
204	3	10.9	9.1	2	5.5	1.481	1.508
205	4	10	10.9	1.3	5.2	1.492	1.507
206	6	21.4	8.6	1.8	0	1.694	1.498
207	6	26.9	12	1.1	0	1.654	1.498
208	5	30	11.9	1.2	0.2	1.575	1.498
209	3	24.8	8.2	1.4	4.5	1.563	1.498
210	5	13.4	9.1	1	2.3	1.562	1.498
211	6	17.1	9.3	1.1	0	1.56	1.498
212	4	27	7.8	1.3	3.4	1.558	1.498
213	4	26	11.7	1.4	0	1.536	1.498
214	4	23.4	7.4	1.9	2.3	1.535	1.498
215	6	24.8	7.7	1	1.9	1.533	1.498
216	4	12.7	9.8	1	1.1	1.521	1.498
217	5	27.6	6.7	1.4	2.7	1.517	1.498
218	7	16.5	7.8	1.4	4.9	1.495	1.498
219	8	17.8	9.6	1	5.1	1.487	1.498
220	3	23.8	12.1	2.2	5.7	1.477	1.498
221	4	10	12	1.7	5.6	1.476	1.498
222	4	18.7	11.2	1.7	5.7	1.473	1.498
223	8	18.5	8.7	1.3	5.7	1.464	1.498
224	3	19.9	12.3	1	5.7	1.462	1.498
225	5	25.9	6	1.4	5.9	1.454	1.498
226	6	17.5	6.8	1.2	1.8	1.419	1.498
227	3	15.8	8.1	2.5	0.8	1.414	1.498
228	3	22.5	8.8	1	1.8	1.4	1.498
229	4	18.5	6.1	1.6	2.2	1.349	1.498
230	3	10	11.7	1.5	5.4	1.486	1.495
231	5	21	16.9	1	5.8	1.471	1.485
232	4	15	10.9	2	5.2	1.501	1.484
233	3	16.7	7.9	1.6	3.5	1.44	1.483
234	4	26.3	11	2	6.1	1.455	1.477
235	4	14.9	7.3	1.9	2.8	1.451	1.471
236	6	13.4	7.4	1.6	0	1.445	1.469
237	4	18.4	8.9	1.4	0	1.443	1.462
238	3	16	8.8	1	2.2	1.423	1.455
239	6	25.3	7.4	1.1	6.1	1.454	1.453
240	3	10.5	8.9	1	2	1.412	1.445

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
241	4	16.2	6	1.3	4.7	1.401	1.445
242	7	11.7	6	1.6	0	1.435	1.44
243	4	16.1	6	1.8	3.8	1.417	1.44
244	4	20	6.8	1.1	3.2	1.401	1.44
245	6	22	6.2	1.7	0	1.41	1.439
246	4	17.1	8.4	1	1	1.419	1.437
247	4	17.7	7.4	1.3	3.1	1.422	1.436
248	4	15.7	6	1.8	3	1.385	1.42
249	4	10.3	6.9	2.1	1.2	1.393	1.419
250	4	15.1	7	1	3.4	1.397	1.416
251	3	11.4	8.5	1.7	1.8	1.405	1.411
252	6	16.5	6	1.4	1.2	1.389	1.41
253	5	17	7.7	1	0	1.354	1.404
254	5	27.7	7	1	2	1.402	1.403
255	5	27.1	7	1.3	0.8	1.402	1.398
256	4	16	6	1.7	2.6	1.352	1.393
257	5	17.1	6	1.4	2.6	1.393	1.39
258	4	12.8	6.1	2.4	3	1.365	1.389
259	5	23.6	6.3	1.6	0	1.343	1.386
260	8	21.5	6	1	0	1.365	1.382
261	4	20.9	6	1.8	3.3	1.408	1.378
262	6	16.7	7.6	1	1.2	1.422	1.372
263	3	16.9	6.8	1.5	2.6	1.318	1.372
264	3	24.6	11.8	1.5	0	1.313	1.372
265	6	21.8	12	1	6.6	1.31	1.37
266	3	24.2	7.8	1.6	1.6	1.374	1.362
267	3	28	6.3	1	3.4	1.314	1.36
268	6	10	6	1.4	0	1.311	1.359
269	3	10	7.9	1.1	2.2	1.321	1.357
270	3	24.6	11.7	1.5	0.2	1.347	1.347
271	4	15.3	6	1.4	2.7	1.316	1.337
272	3	12.8	6	1.2	7	1.284	1.334
273	6	13.8	6	1.6	6.3	1.31	1.329
274	4	25.1	8.9	2.5	6.7	1.305	1.326
275	6	14.5	6	1	2.8	1.378	1.317
276	4	12.9	7.3	1.9	0	1.34	1.308
277	4	24	6	1	2.1	1.263	1.308
278	4	19.5	6.5	1.2	2.8	1.367	1.301
279	3	17.3	10	1.9	0	1.364	1.301
280	3	18.8	7.2	1.8	1.7	1.323	1.301

No.	n (개수)	α (각도, °)	L (길이, m)	s (간격, m)	x (거리, m)	FS _{pred} (예측값)	FS _{LEM} (실제값)
281	3	19.2	6	1	4.3	1.314	1.301
282	4	14.1	9.8	2.5	7	1.308	1.301
283	3	19.1	13.3	1.7	7.4	1.286	1.301
284	3	20.9	8.7	1.7	7.1	1.276	1.301
285	3	25.4	9.1	1.7	7.1	1.276	1.301
286	3	26	9.4	1.7	0	1.239	1.301
287	3	19.3	6.3	1.9	0.8	1.223	1.301
288	5	21.1	11.6	1	7.3	1.276	1.298
289	3	27	6	2.3	1.2	1.262	1.269
290	4	28	13.1	2	7.6	1.223	1.261
291	3	11.7	10.4	1.3	0	1.314	1.25
292	5	16.8	10.7	1.4	7.1	1.296	1.23
293	4	21.5	10.2	1.8	7.6	1.203	1.228
294	3	19	11.9	2.5	7.6	1.205	1.221
295	4	23.9	6	1.3	1.9	1.27	1.166
296	3	30	10.1	1.9	0	1.258	1.166
297	3	25.2	6.3	1.6	1.1	1.229	1.166
298	3	18.2	9.8	2.1	8.2	1.17	1.166
299	4	14.5	10.9	1.5	8.5	1.162	1.166
300	4	10.3	7.9	1.5	10	1.012	1.066