

2-B-5-양-8

비SCIE

BIM 모델 내 비유효 간섭 분류를 위
한 다각도 이미지 학습 기반 관통성
분석 모델 성능 비교 연구

2025. 11.

과 제 명	인공지능 기반의 건축설계 자동화 기술개발		
주 관 기 관	경북대학교 산학협력단		
총 연구 기간	2021. 04 . 01 - 2025. 12 . 31(4년 9개월)		
해당연도(5차년)	2025. 01 . 01 - 2025. 12 . 31(1년)		
구 성 기 술 명	구성기술 2	설계 생산성 향상을 위한 지능형 상세설계 자동화 기술 개발	
세 부 과 제 명	2-B	인공지능 기반 건축 상세설계 자동화 기술개발(II)	
공 동 연 구 기 관	-		
연 구 기 관	서울과학기술대학교 산학협력단	연구책임자	구본상

BIM 모델 내 비유효 간섭 분류를 위한 다각도 이미지 학습 기반 관통성 분석 모델 성능 비교 연구

이현우¹ · 유영수² · 이원복³ · 구본상^{4*}

¹서울과학기술대학교 건설시스템공학과 석사과정 · ²한국건설기술연구원 국가건설기준센터 박사후연구원 ·
³서울과학기술대학교 건설시스템공학과 박사과정 · ⁴서울과학기술대학교 건설시스템공학과 교수

Comparative Study on the Performance of Multi-view Image Learning-based Penetrability Analysis Model for Classifying Irrelevant Clashes in BIM model

Hyunwoo Lee¹ · Youngsu Yu² · Wonbok Lee³ · Bonsang Koo^{4*}

¹Graduate Student, Department of Civil Engineering, Seoul National University of Science and Technology
²Postdoctoral Researcher, Korea Construction Standards Center, Korea Institute of Civil Engineering and Building Technology
³Ph.D. Student, Department of Civil Engineering, Seoul National University of Science and Technology
⁴Professor, Department of Civil Engineering, Seoul National University of Science and Technology

Abstract : BIM models are developed in a fragmented manner by discipline and integrated during the detailed design phase, leading to numerous clashes. Many of these are irrelevant clashes that do not require intervention, yet significant effort is needed for classification. Sleeve installation feasibility assessment is a key task in this process, and various studies have explored automated penetrability analysis. However, existing methods relied on manually defined inference rules or failed to capture detailed clash patterns. This study developed penetrability analysis models using Multi-view CNN (MVCNN) and Multi-view Vision Transformer (MVT), both of which enable multi-view image training. Experimental results showed that MVT achieved an accuracy (ACC) of 0.98, outperforming MVCNN by 0.13 ACC. MVT's superiority was attributed to its attention mechanism, which focused on clash-prone regions, unlike MVCNN's emphasis on overall object geometry. These findings demonstrate practical value by enabling the early identification of irrelevant clashes to enhance design efficiency and accuracy, while supporting more precise construction planning through detailed penetration information.

Keywords : Penetrability, Sleeve installation, Multi-view Vision Transformer, Multi-View CNN, BIM

1. 서론

1.1 연구의 배경 및 목적

현행 건축 분야 Building Information Modeling (BIM) 설계는 각 공종별(건축, 구조, Mechanical, Electrical and Plumbing; MEP) 참여자에 의해 분리되어 수행되며, 개별

적으로 설계된 BIM 모델은 시공 단계 직전에 통합된다. 분절된 모델링 프로세스 특성상 BIM 모델을 통합하는 과정에서 부재 간 간섭이 다수 발생하며, 이러한 간섭은 설계 변경 및 공기 지연 등 문제의 주된 원인 중 하나로 작용한다(Lee, 2024). 이로 인해, BIM 간섭 검토 툴을 활용한 간섭 검토 작업은 설계 오류를 조기에 탐지하기 위한 중요도가 높은 작업으로 여겨지고 있다(Kermanshahi et al., 2020).

그러나, 대부분의 BIM 간섭 검토 툴은 단순히 두 부재 간의 물리적 충돌 또는 이격거리만을 기준으로 간섭을 탐지하기 때문에, 실제로는 설계 변경이 필요 없는 '비유효 간섭(irrelevant clash)'까지 함께 도출된다는 문제점이 있다(Lin & Huang, 2019; Shehadeh et al., 2024). 비유효 간섭은 향

* **Corresponding author:** Bonsang Koo, Department of Civil Engineering, Seoul National University of Science and Technology, 232 Gongneung-ro, Nowon-gu, Seoul 01811, Korea
E-mail: bonsang@seoultech.ac.kr
Received March 31, 2025; **revised** June 13, 2025
accepted June 24, 2025



후 시공 단계에서 단순 위치 조정이나 추가 시공 작업을 통해 해결 가능한 경우로, 설계 단계에서 별도의 조치를 요구하지 않는다. 그럼에도 간섭 검토 틀에서는 이들을 유효 간섭(relevant clash)과 동일하게 표시하므로, 실무에서는 우선적으로 비유효 간섭을 선별하는 추가 작업을 수행하게 되고, 이는 전체 검토 프로세스의 효율성을 저해하는 주요 원인 중 하나로 작용하고 있다(Hu et al., 2019).

비유효 간섭 중 슬리브(sleeve) 설치를 통해 해결 가능한 간섭은 BIM 설계에서 가장 빈번하게 나타나는 대표적 사례이다(Lin & Huang, 2019). 슬리브는 덕트, 배관, 케이블 트레이 등 MEP 부재가 벽, 바닥, 천장과 같은 건축 또는 구조 부재를 관통할 때 사용하는 보호 튜브로, 설계 및 시공 단계에서 유연성을 확보하는 데 활용된다. 일례로, <Fig. 1(a)>와 같이 BIM 모델 내 덕트가 벽을 완전히 관통하여 간섭이 발생한 경우에는, 시공 단계에서 슬리브를 설치함으로써 별도의 설계 변경 없이 간섭을 해결할 수 있으므로<Fig. 1(b)>, 설계 단계에서 별도의 조치가 필요하지 않다. 그러나 슬리브는 실시설계 단계의 Level of Development (LOD) 300-350 수준에서는 일반적으로 요구되지 않는 BIM 모델 요소로, 실무에서는 슬리브 모델링을 생략하는 경우가 많다. 이로 인해 시공 단계에서 슬리브 설치를 통해 해결 가능한 다수의 비유효 간섭이 BIM 간섭 검토 틀에서는 <Fig. 1(a)>와 같이 유효 간섭과 동일하게 탐지되며, 실무에서는 각 간섭에 대해 슬리브 설치 가능 여부를 별도로 식별하여 비유효 간섭을 선별하고 있다.




Fig. 1. Clash resolution by sleeve installation

슬리브 설치 가능 여부를 식별하기 위해서는 MEP 부재가 건축 또는 구조 부재를 완전히 관통하고 있는지, 아니면 부분적으로 교차하거나 일부만 삽입되어 있는지 확인하는 것이 필요하다. 더불어 완전히 관통한다면 어떤 양상으로 관통하는지 구분하는 것 또한 요구된다. 기존 연구(Nepal et al., 2012; Hu et al., 2019) 및 실무에서는 BIM 간섭 검토 틀 내에서 추론 규칙을 정의하여 관통성(penetrability)을 식별하였다. 그러나 이러한 규칙 기반 접근법은 관통성을 식

별하기 위한 기하적 특징과 다수의 규칙을 일일이 정의해야 하기에 유연성이 부족하다는 문제점이 존재하였다. 또한, 기존 관통성 식별 방법들은 수평 관통, 수직 관통, 사선 관통 등 실무에서 요구되는 세부적인 관통 양상을 구분하지 않아 실무적 효율성이 저하된다는 한계점 또한 존재하였다.

본 연구는 상기 한계점에 대응하기 위해 딥러닝 기반 접근법을 활용하여, 기존 규칙 기반 방식의 유연성 부족과 실무 적용의 한계를 개선하고자 하였다. 이때, 단일 시점의 기하 정보만으로는 모델이 관통 경로, 각도 등으로 구성된 관통 양상을 충분히 학습하기 어려우므로, Su et al. (2015)이 제안한 다양한 시점의 정보를 통합적으로 활용하는 다각도 이미지 학습 방식을 채택하였다. 구체적으로, 이미지 분류 분야에서 가장 널리 사용되는 Convolutional Neural Network (CNN) 기반의 Multi-View CNN (MVCNN)과 최근 이미지 분류에서 State-of-the-art (SOTA) 성능을 달성한 Vision Transformer (ViT) 기반의 Multi-View ViT (MVT)를 활용하였으며, 두 모델의 성능 비교를 통해 최적의 관통성 분석 모델을 선정하였다.

1.2 연구의 범위 및 방법

본 연구는 3차원 BIM 모델에서 추출한 다각도 이미지 학습이 가능한 딥러닝 모델(MVCNN, MVT)을 통해 슬리브 설치 가능 여부를 식별하여 비유효 간섭을 분류하는 동시에, 설치가 가능한 경우에는 실무에서 요구되는 세부 관통 양상까지 분류하는 것을 목표로 하였다.

딥러닝 모델의 학습 및 성능 평가를 위해 4층 규모(지하 2층, 지상 2층)의 실시설계 단계 BIM 모델을 활용하였다. 해당 모델은 업무시설 용도로 설계되었으며, 건축, 구조 및 MEP 관련 4개 공종(기계, 소방, 전기, 통신)의 총 6가지 공종으로 구성되어 있다.

이후 BIM 모델 검토 틀을 활용하여 간섭 검토를 수행하고, 탐지된 개별 간섭 인스턴스를 다각도 간섭 이미지로 변환하였다. 단, 이때의 적용 범위는 실무에서 슬리브 설치가 고려되는 건축 및 구조 공종의 '벽, 바닥, 천장' 부재와 MEP 공종의 '덕트, 배관, 케이블 트레이' 부재 간 간섭으로 한정하였다. 한편, 건축 및 구조 공종의 '기둥, 보' 부재의 경우 MEP 공종과의 간섭 발생 빈도는 높으나, 구조적 손실 우려로 인해 일반적으로 슬리브 설치가 제한되므로 본 연구의 분석 대상에서 제외하였다.

최종적으로, 변환된 다각도 간섭 이미지를 활용해 MVCNN 및 MVT 모델을 학습시켰으며, 두 모델의 성능을 비교·분석하여 최적의 관통성 분석 모델을 선정하였다. 본 연구의 구체적인 방법론은 다음과 같다.

1) 슬리브 설치를 위한 실무적 고려사항 분석

관통성 분석 모델을 구축하기에 앞서, 슬리브 설치와 관련된 실무적 고려사항을 파악하기 위해 건축설계 전문가 인터뷰를 진행하고, 관통 특성에 따른 분류 기준을 수립하였다.

2) 간섭 인스턴스 수집 및 데이터 증강

활용 BIM 모델 대상 간섭 검토를 수행하여 간섭 인스턴스를 수집하고 유형별로 라벨링(labeling) 하였으며, 학습 과정 내 데이터 불균형 문제를 예방하기 위해 데이터 증강(data augmentation)을 수행하였다.

3) 다각도 이미지 변환

Navisworks API 기반 add-in을 개발하여 수집된 간섭 인스턴스를 다각도 이미지로 변환하고, 이를 학습 및 검증 데이터셋으로 구성하였다.

4) 학습모델 구축

다각도 이미지를 학습할 수 있도록 Convolutional Neural Network (CNN) 기반의 MVCNN 모델과 Vision Transformer (ViT) 모델을 백본(backbone)으로 활용하는 MVT 모델 기반의 학습모델을 구축하였다.

5) 학습모델 비교 및 검증

정확도(ACC), F_1 - score, Intersection over Union (IoU) 지표를 활용하여 두 모델의 성능을 비교·분석하고 최적의 관통성 분석 모델을 선정하였다.

2. 연구 배경

2.1 선행 연구 분석

2.1.1 비유효 간섭 분류 연구

비유효 간섭은 프로젝트에 영향을 주지 않아 실무에서 실질적인 집중을 요구하지 않는 간섭으로, 다수의 비유효 간섭이 존재할 경우 BIM 모델의 신뢰도에도 부정적인 영향을 미친다(Hu, 2020). 그럼에도, 대표적인 상용 간섭 검토 소프트웨어인 Solibri Model Checker (SMC)나 Autodesk Navisworks의 가장 최신 버전도 기본적인 기하 규칙에 기반한 간섭 여부만을 제공할 뿐, 이들의 유효성(relevance)을 구분하지는 못한다. 상기 문제 해결을 위해 간섭의 유효성을 기준으로 간섭을 분류하여 검토 업무의 효율성을 높이려는 연구가 활발히 진행되어 왔다.

Kwon and Cho (2015)는 SMC를 활용하여 간섭 검토 및 간섭 관련 정보를 수집 후, 간섭을 유효/비유효로 구분하기 위해 간섭 양상, 부재 공종, 부재 유형 및 재료 등에 따라 분

류 기준을 수립하고 이를 Java 기반의 JESS 추론 엔진으로 구현하였다. Hasannejad et al. (2022)는 fuzzy-AHP 프로세스를 활용해서 구조 및 MEP 부재의 우선순위를 선정하고 이를 Navisworks 간섭 검토 결과에 적용하여 비유효 간섭을 구분하였다. 이러한 규칙 기반 접근법은 경직적일 뿐만 아니라, 모든 규칙을 일일이 정의해야 하고, 예외 상황 발생 시 이를 수정하거나 추가해야 하는 어려움이 있다. 반면, 인공지능은 명시적인 규칙 없이 학습 데이터를 통해 스스로 패턴을 인식하므로, 규칙을 개별적으로 정의하지 않아도 되기에 자동화와 유연성 측면에서 장점이 있다. 이에 따라 최근에는 규칙 기반 접근법을 활용한 연구 이외에도 인공지능 모델을 학습시켜 유효 간섭과 비유효 간섭을 분류한 연구가 진행된 바 있다.

Hu and Castro-Lacouture (2019)는 부재 크기 및 간섭 부피와 같은 특정 변수를 활용하여 6가지 인공지능 모델을 학습시켜 유효 간섭과 비유효 간섭을 구분하였다. Lin and Huang (2019)은 규칙 기반 접근법과 기계 학습 접근법을 순차적으로 활용하는 하이브리드 기법을 통해 유효 및 비유효 간섭을 분류하였다. 이때 비유효 간섭은 슬리브 설치를 고려한 의도적 간섭(deliberate clash)과 현장에서 쉽게 해결할 수 있는 거짓 충돌(pseudo clash)로 분류하였다. Ahmadpanah et al. (2023)은 YOLO5 알고리즘을 활용하여 간섭 이미지 내 보 또는 트러스 부재가 탐지된 경우 유효 간섭으로 분류하였으며, 탐지되지 않는 경우 비유효 간섭으로 분류하였다.

그러나, 이들 연구는 주로 특정 공종에만 집중되어, 건축-MEP, 구조-MEP 등 다양한 공종 간 간섭을 포괄적으로 다루는 데에는 한계가 존재하였다.

2.1.2 관통성 식별 연구

상기의 비유효 간섭 분류 연구 외에도 슬리브 설치 가능 여부에 집중한 연구 또한 일부 진행된 바 있다. Nepal et al. (2012)은 9-intersection model (9-IM)¹⁾에 기반한 위상학적 관계를 활용하여 간섭 양상을 교차(intersect), 분리(disjoint), 관통(penetration)으로 구분하였다. Hu et al. (2019)는 9-IM과 객체 간 교차 곡선(intersection curve)을 추가적으로 활용하여 삽입(inserted), 관통(penetrated through), 교차(intersected), 포함(contained)으로 유형을 세분화하였다(Fig. 2).

1) 공간 객체 간의 관계를 표현하는 개념으로, 두 객체 사이의 교차, 포함, 인접 관계를 3X3 매트릭스를 통해 기술하는 프레임워크임.




Fig. 2. Clash type division (Hu et al., 2019)

이들 연구는 이러한 구분을 통해 MEP 부재가 타 부재를 완전히 관통하는 경우에는 슬리브 설치가 가능하지만, 삽입되거나 교차하는 경우에는 슬리브 설치가 불가능하다고 분류하였다.

그러나, 이들 연구가 활용한 9-IM과 교차 곡선 기반 규칙 기반 접근법으로는 모든 간섭 양상에 대한 포괄적인 검토가 불가능하다는 한계점이 존재하였다. 특히, 입상 배관과 바닥 간 관통처럼 방향이 수직인 경우 검토가 불가능하였다.

이에 본 연구는 딥러닝 기반 접근법을 통해 다각도 간섭 이미지 기반 관통성 분석 모델을 구축하고, 슬리브 설치로 해결 가능한 비유효 간섭을 효과적으로 분류하고자 하였다. 이를 위해, 기존 연구들이 주로 특정 공종에 한정된 간섭만을 대상으로 하였던 것과 달리, 본 연구는 건축-MEP, 구조-MEP 간 간섭을 통합적으로 활용하여 분석 범위를 확장하였다. 또한, BIM 모델로부터 취득한 다각도 간섭 이미지를 활용하여 관통 방향에 따른 세부 관통 양상을 자동으로 분류하고, 이를 통해 실무에서 슬리브 설치 검토에 필요한 정보를 함께 도출함으로써 기존 규칙 기반 접근 방식의 한계를 보완하고자 하였다.

2.2 다각도 이미지 활용 딥러닝 모델

본 연구에서는 슬리브 설치 여부 및 세부 관통 양상을 구분하기 위해서 BIM 모델을 통해 취득 가능한 간섭 인스턴스의 다각도 이미지를 활용하고자 하였다. 이는 단일 시점의 이미지보다 관통 양상에 대한 정확한 정보를 제공해 줄 수 있기 때문이며, BIM 모델로부터 특정 기하 형식 변환 없이 손쉽게 취득할 수 있기 때문이다.

다각도 이미지 학습에는 MVCNN 및 MVT를 각각 활용하고자 하였다. 3D 형상 인식을 위한 딥러닝 모델은 PointNet, VoxelNet, MeshCNN 등 다수 존재하지만, 이들은 주로 포인트 클라우드, 복셀, 메시 등 변환된 형태의 입력을 요구하며, 이때 원 기하적 특징의 손실이 발생할 수 있다. 반면, MVCNN과 MVT는 다각도 이미지를 직접 사용함으로써 BIM 모델에서 추출한 시각 정보를 효과적으로 처리할 수 있어 본 연구의 목적에 적합한 것으로 판단되었다.

2.2.1 Multi-view CNN

MVCNN은 다중 뷰에서 촬영된 다각도 이미지를 CNN으로 학습할 수 있도록 변형된 딥러닝 모델이다. <Fig. 3>에 제시한 MVCNN의 구조에서 볼 수 있듯, CNN1을 통해 복수의 2D 이미지를 개별적으로 처리하여 개별 뷰에 대한 특징을 수집하고, 이를 통합한다. 이후 통합된 특징을 다시 CNN2로 처리하여 최종 분류를 수행한다. 이를 통해 3D 객체를 복셀이나 포인트 클라우드 형태로 변환하는 데이터 전처리 과정을 거치지 않고, 이미지세트를 직접 딥러닝 모델에 공급할 수 있기에 해상도 저하로 인한 객체의 기하적 특징이 손실되지 않는다는 특징이 있다(Su et al., 2015).

이러한 특징으로, MVCNN은 3D 객체 인식 문제에서 기존의 3D 기하 딥러닝 모델 대비 우수한 성능을 보인 바 있다. 일례로, 3D 객체 벤치마크 데이터셋 중 하나인 ModelNet²⁾ 대상으로 3D 기하 딥러닝 모델 간의 성능을 비교한 결과, MVCNN의 분류 정확도는 90.1%로 VoxNet (83%)과 PointNet (89.2%)보다 우수한 성능을 보였다 (Daniel & Sebastian, 2015; Qi et al., 2016).

또한, MVCNN은 선행 연구를 통해 타 딥러닝 모델 대비 BIM 모델 부재에 대한 높은 인식 정확도를 보인 바 있다. 건축 BIM 모델의 부재를 대상으로 MVCNN, Support Vector Machine (SVM), PointNet을 비교 분석한 결과, MVCNN은 미세한 기하 형상 차이를 인식하여 부재의 하위 유형까지 높은 정확도로 분류하는 등 우수한 성능을 보였다(Koo et al., 2021a). 또한, 토목 부재 대상으로 한 실험에서도 MVCNN은 PointNet 대비 15% 높은 98%의 정확도를 기록하며 뛰어난 성능을 입증하였다(Koo et al., 2021b). 이러한 결과는 MVCNN이 다각도 이미지를 활용하여 BIM 부재의 미세한 차이까지 학습하는 것에서 기인한 것으로 분석되었다.




Fig. 3. MVCNN architecture (Su et al., 2015)

2.2.2 Multi-view Vision Transformer

Transformer는 문장 속 단어와 같은 시퀀스 데이터 간 관계를 추적하여 문장의 맥락과 의미를 학습하는 딥러닝 모

2) <https://modelnet.cs.princeton.edu/>

델로, 자연어처리(Natural Language Processing) 분야에서 SOTA 성능을 달성한 바 있으며(Vaswani et al., 2017)³⁾, 최근에는 Generative Pretrained Transformer (GPT)와 같은 생성형 AI 모델 개발의 핵심 기술로 활용되고 있다.

ViT는 상기의 Transformer 모델을 이미지 분류가 가능하도록 변형한 모델로(Dosovitskiy et al., 2020), 대규모 벤치마크 데이터세트인 CIFAR-10⁴⁾ 대상으로 최고의 분류 성능을 보인 바 있다. 또한, CNN이 주로 활용하던 지역적 필터링 방식과 달리, attention 메커니즘을 통해 이미지 내 전 영역의 관계를 동시에 고려할 수 있는 장점으로 인해 최근 컴퓨터 비전 분야에서 활발히 활용되고 있다. 특히 이미지 분류뿐 아니라 객체 탐지, 세그멘테이션 등 다양한 시각적 인지 작업에 적용되며 기존 CNN 기반 모델을 대체하거나 보완하는 구조로 활용되고 있다.

MVT는 2D 이미지 분류에 특화된 ViT의 아키텍처를 토대로 3D 객체 분류가 가능하도록 발전시킨 모델로, (Fig. 4)는 MVT의 구조를 보여준다(Chen et al., 2021). MVT는 개별 이미지에서 로컬 특징을 추출하는 Local Transformer Encoder와 추출된 로컬 특징을 통합하여 전체적인 맥락(global context)을 파악하는 Global Transformer Encoder로 구성되어 있다.

개별 이미지의 로컬 특징을 추출 및 통합한 후, 통합된 특징으로부터 전체적인 맥락을 파악한다는 점은 MVCNN과 유사하지만 CNN이 아닌 ViT를 기반으로 이미지가 처리된다는 점에서 차이가 있다. 또한, ModelNet40⁵⁾ 데이터세트를 대상으로 3D 객체 인식을 수행한 결과, 97.5%의 정확도를 보이며 MVCNN (93.8%) 대비 우수한 성능을 보인 바 있다.

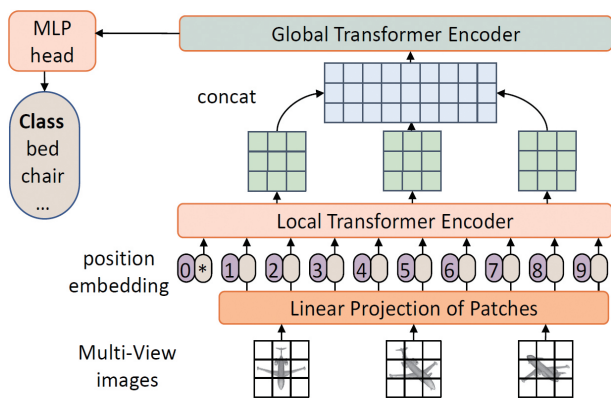


Fig. 4. MVT architecture (Chen et al., 2021)

3) https://huggingface.co/spaces/HuggingFaceH4/open_llm_leaderboard
 4) <https://paperswithcode.com/sota/image-classification-on-cifar-10>
 5) <https://paperswithcode.com/sota/3d-object-recognition-on-modelnet40>

3. 연구 방법

본 연구는 다각도 이미지 학습에 특화된 두 가지 딥러닝 모델인 MVCNN과 MVT를 활용하였다. 이를 통해 기하적 특징과 규칙을 일일이 정의하지 않고도, 개별 간섭 인스턴스에 대한 슬리브 설치 가능 여부를 분류하여 비유효 간섭을 식별하는 관통성 분석을 수행하였다. 연구의 전체 과정은 (Fig. 5)에 제시되어 있다.

우선, 슬리브 설치와 관련된 실무적 고려사항을 파악하기 위해 건축설계 전문가를 대상으로 인터뷰를 진행하였으며, 이를 바탕으로 관통성 분석 모델의 분류 기준을 수립하였다. 이후, BIM 모델에 대해 Navisworks를 활용하여 간섭 검토를 수행하고, 이 중에서 부재의 공종과 유형을 기준으로 슬리브 설치가 고려되는 건축 및 구조 공종의 '벽, 바닥, 천장' 부재와 MEP 공종의 '덕트, 배관, 케이블 트레이' 부재 간 간섭 인스턴스만을 선별하여 추출하였다. 추출된 간섭 인스턴스는 딥러닝 모델 학습을 위해 간섭 양상에 따라 라벨링하고, 데이터 전처리를 수행하였다. 라벨링 이후에는 클래스 간 데이터 불균형을 해소하기 위해 Autodesk Revit의 비주얼 프로그래밍 툴인 Dynamo를 활용하여 데이터 증강을 실시하였으며, 모델 학습을 위해 각 간섭 인스턴스를 다각도 간섭 이미지로 변환하였다. 해당 이미지 변환은 Navisworks API를 기반으로 개발한 전용 add-in을 통해 수행되었다.

최종적으로, 생성된 다각도 간섭 이미지를 활용하여 MVCNN과 MVT를 각각 학습시킨 후, 정확도, F_1 - score, IoU 성능 지표를 바탕으로 두 모델의 성능을 비교·분석하고, 최적의 관통성 분석 모델을 도출하였다.

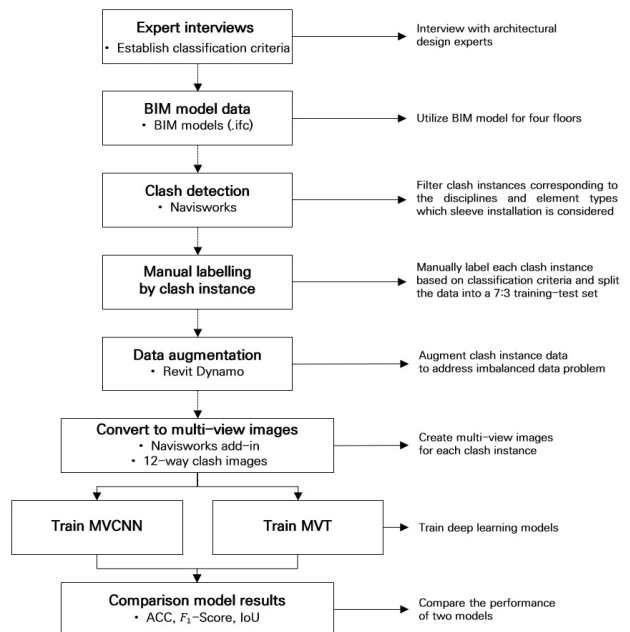


Fig. 5. Research process

3.1 슬리브 설치 검토 관련 실무적 고려사항 분석

관통성 분석 모델 구축에 앞서 건축설계 전문가 대상 인터뷰를 실시하여 슬리브 설치 가능 여부 검토 시 고려되는 사항을 조사하고, 이를 관통성 분석 과정에 반영하고자 하였다. 구체적으로, 건축설계 전문가 그룹을 구성하고 이들과의 인터뷰를 실시하였으며, <Table 1>은 전문가 그룹 참여인원 및 인터뷰 정보를 보여준다. 이들은 건축사사무소 S사 소속의 20년 이상 경력 1인, 5년 경력의 1인 및 설비 엔지니어링 업체 소속 20년 이상 경력자 1명으로 이루어져 있다.

Table 1. Interview participants' information

Interviewee	Affiliation	Qualification	Interview date	Interview methods
A	Architectural firm 'S'	Over 20 years	March 16, 2024	Offline meeting
B		Over 5 years	March 16, 2024	Offline meeting
C	MEP engineering firm 'B'	Over 20 years	January 16, 2024	Online meeting

조사 결과, 실무에서는 MEP 부재가 건축 및 구조 부재를 완전히 관통하지 않고 교차(intersected)하거나(Fig. 6(a)), 온전히 관통하지 못하고 일부만 삽입(inserted)된 경우(Fig. 6(b)) '일부 관통(partially penetrated)'으로 판단하여 슬리브를 설치하지 않는 것으로 확인되었다. 이는 일부만 관통하여 교차하는 경우 슬리브 설치를 위한 여유 공간이 부족하여 설치가 불가능하고, 설치 후 보강이 어려워 구조적 문제가 발생할 수 있기 때문이다. 또한, 일부만 삽입된 경우 역시 슬리브 설치로 해결이 되지 않으며 이에 대한 유효 간섭 여부를 별도로 파악해야 한다. 반면, MEP 부재가 온전히 관통하는 경우에는 수평, 수직, 사선 등 관통 방향과 관계없이 '완전 관통(fully penetrated)'으로 판단하여 슬리브를 설치한다. 또한, '완전 관통'으로 판단될 시 실무적 고려사항은 MEP 부재의 단면 크기와 형상에 따라 구분되었으며, <Table 2>는 이에 대한 세부 조사 결과를 나타낸다.




Fig. 6. Partially penetrated cases in practice

1) 단면 크기

실무에서는 슬리브 설치 시 MEP 부재의 단면 크기에 별다른 제한을 두지 않는 것으로 조사되었다. 관통하는 MEP 부재의 단면이 크더라도 슬리브를 설치하며, 이는 슬리브 설치 과정에서 발생하는 단면손실에 대한 보강을 시행하기 때문이다. 이때, 보강을 위해 주로 설치 경계부에 철근을 배근하거나 슬리브 위에 인방보(lintel)를 설치하는 것으로 확인되었다. 또한, 경우에 따라 설계 및 시공 단계에 구조검토를 실시하여 보강 수준을 결정하는 것으로 확인되었다. 반면, 단면이 작은 경우에는 별도의 보강 없이 슬리브만을 설치한다. 이는 단면이 작은 경우 슬리브에 의한 단면손실이 기존 부재의 구조적 기능에 미치는 영향이 미미하기 때문으로 조사되었다.

2) 단면 형상

MEP 부재의 형상에 따라 슬리브 설치 시 요구되는 보강 유형이 상이한 것으로 조사되었다. 일반적으로 원형 단면을 가진 배관의 경우 응력이 균등하게 분산되기 때문에, 단면 형태에 맞춘 슬리브 설치만으로 충분하며 추가적인 보강이 필요하지 않은 경우가 많다. 반면, 덕트나 케이블 트레이 처럼 사각형 단면을 가진 부재는 슬리브 크기가 상대적으로 크고 설치 경계부에 응력 집중이 발생할 우려가 있어, 슬리브 주변에 별도의 보강을 실시하는 것이 일반적이다. 또한, 관통 방향이 사선일 경우에는 단면이 원형인 배관이라 하더라도 시공 난이도가 높아지므로, 슬리브를 단면보다 크게 설치한 후 시멘트 몰탈이나 우레탄 폼 등으로 보강하는 방식이 주로 활용되는 것으로 확인되었다.

종합하면, 실무에서는 개별 간섭 인스턴스에 대해 우선 슬리브 설치 가능 여부를 식별한 후, 설치가 가능한 경우에는 적절한 보강 방법을 결정하기 위해 세부적인 관통 양상을 추가로 분석하는 것으로 확인되었다. 이에 따라 본 연구는 상기 과정을 통해 도출된 실무적 절차를 반영하여, <Table 3>에 제시한 바와 같이 간섭 인스턴스를 우선 '일부 관통(partially penetrated)'과 '완전 관통(fully penetrated)'의 두 범주로 구분하여 슬리브 설치 가능 여부를 식별하고, 설치 가능 인스턴스에 대해서는 '수평(horizontal)', '수직(vertical)', '사선(diagonal)'의 세부 관통 양상으로 분류하는 기준을 수립하였다.

Table 2. Practical considerations for sleeve installation

Consideration	Penetration condition	Action for sleeve installation
Size of cross section	Large	<ul style="list-style-type: none"> Place rebar at sleeve boundary or install lintel above sleeve for reinforcement Determine reinforcement level through structural analysis
	Small	<ul style="list-style-type: none"> Install sleeve without reinforcement
Shape of cross section	Rectangular	<ul style="list-style-type: none"> Perform reinforcement at sleeve boundary due to potential stress concentration, especially for large cross-section elements like ducts or cable trays
	Circular	<ul style="list-style-type: none"> Install circular sleeve without additional reinforcement
	Diagonal	<ul style="list-style-type: none"> Install oversized rectangular sleeves first due to construction difficulty then reinforce; generally reinforce even for circular-section pipes Apply cement mortar or urethane foam around sleeve boundary for reinforcement

Table 3. Classification criteria for penetrability analysis

Penetration type	Sample image	Description
Partially penetrated		<ul style="list-style-type: none"> MEP element is partially intersected or inserted into the architectural or structural element without full penetration
Fully penetrated	Horizontal	<ul style="list-style-type: none"> MEP element fully penetrates the architectural or structural element horizontally, allowing sleeve installation
	Vertical	<ul style="list-style-type: none"> MEP element fully penetrates the architectural or structural element vertically, allowing sleeve installation
	Diagonal	<ul style="list-style-type: none"> MEP element fully penetrates the architectural or structural element at an oblique angle, where reinforcement needs to be significantly considered

단, 단면 형상은 '사각형', '원형', '사선' 형태가 존재하나, 본 연구에서는 슬리브 시공의 난이도 및 보강 필요성과 직결되는 '사선' 형상만을 관통 양상 분류 기준에 포함하였다. '사각형' 및 '원형'과 같은 MEP 부재 자체의 단면 형상은 BIM 모델 내에 이미 정의되어 있어 별도로 분류할 필요가 없으며, 보강 여부 결정 시에도 실무적으로 관통 방향에 비해 중요도가 낮은 것으로 판단되어 분류 체계에서 제외하였다. 또한, 단면 크기의 경우 실무자 인터뷰 결과 명확한 기준이 존재하지 않고 구조 기술사의 경험적 판단에 전적으로 의존하고 있어, 그 객관적 기준을 정립하기 어려워 본 연구의 분류 범위에 포함하지 않았다.

3.2 BIM 모델 대상 간섭 검토 및 데이터 수집

본 연구에서 활용한 BIM 모델은 앞서 1.2절에서 언급한 바와 같이 4개 층으로 구성된 업무시설 BIM 모델을 활

용하였다. 해당 모델에는 총 32가지 유형의 부재가 있으며, <Table 4>에는 이들을 IFC 엔티티 명으로 기재하였다.

이들 대상으로 Navisworks를 활용하여 간섭을 검토한 결과 총 2,387건이 탐지되었다. 이 중 슬리브 설치가 고려되는 공종 간 간섭, 즉, 건축 및 구조 공종의 '벽, 바닥, 천장' 부재와 MEP 공종의 '덕트, 배관, 케이블 트레이' 부재 간 간섭은 937건으로 총 간섭의 39.3%를 차지하였다.

해당 간섭 인스턴스 대상으로 '일부 관통'과 '완전 관통'에 해당하는 '수평 관통(fully penetrated-horizontal)', '수직 관통(fully penetrated-vertical)', '사선 관통(fully penetrated-diagonal)'의 4가지 클래스로 라벨링하였다. 이후, 딥러닝 모델의 학습을 위해 각 클래스를 7:3 비율로 나누어 훈련 세트(training set)와 검증 세트(test set)로 구성하였다(Table 5).

Table 4. List of element types in the utilized BIM model

Discipline	Architectural	Structural	Mechanical
Element type	<i>IfcBuildingElementProxy</i>	<i>IfcBeam</i>	<i>IfcAirTerminal</i>
	<i>IfcBeam</i>	<i>IfcColumn</i>	<i>IfcBuildingElementProxy</i>
	<i>IfcCovering</i>	<i>IfcSlab</i>	<i>IfcDuctFitting</i>
	<i>IfcDoor</i>	<i>IfcWall</i>	<i>IfcDuctSegment</i>
	<i>IfcRailing</i>	<i>IfcStairflight</i>	<i>IfcPipeSegment</i>
	<i>IfcSlab</i>		<i>IfcPipeFitting</i>
	<i>IfcSpace</i>		<i>IfcValve</i>
	<i>IfcWall</i>		
	<i>IfcWindow</i>		
	<i>IfcStairflight</i>		
Discipline	Fire protection	Electrical	Telecommunications
Element type	<i>IfcFireSuppressionTerminal</i>	<i>IfcCableCarrierFitting</i>	<i>IfcCableCarrierFitting</i>
	<i>IfcPipeSegment</i>	<i>IfcCableCarrierSegment</i>	<i>IfcCableCarrierSegment</i>
	<i>IfcPipeFitting</i>	<i>IfcLightFixture</i>	<i>IfcElectricAppliance</i>
	<i>IfcValve</i>	-	-

* Element types in bold were used in this study for penetration analysis.

Table 5. Training and test sets for penetrability analysis

Datasets	Partially penetrated	Fully penetrated			Total
		Horizontal	Vertical	Diagonal	
No. of clash instances	179	554	114	90	937
Training set	125	388	80	63	656
Test set	54	166	34	27	281

3.3 데이터 전처리: 데이터 증강

<Table 5>에 제시한 데이터 분포를 보면, 데이터세트 내에서 클래스 간 불균형이 존재한다. 이러한 불균형은 딥러닝 모델이 높은 ACC를 목표로 학습하는 특성상, 상대적으로 데이터가 많은 클래스에 집중하여 데이터가 적은 클래스의 학습이 충분히 이루어지지 않는 '비대칭 데이터 문제(imbalanced data problem)'를 야기할 수 있다. 예를 들어, '사선 관통' 클래스와 같이 데이터 수가 적은 경우, 모델이

해당 클래스를 제대로 학습하지 않더라도 전체 정확도에 미치는 영향이 미미하기 때문에 학습 과정에서 충분한 고려가 이루어지지 않을 가능성이 크다.

본 연구에서는 이러한 비대칭 데이터 문제를 해결하기 위해 소수 클래스 데이터를 증강하는 오버 샘플링(over sampling) 기반의 데이터 증강 기법을 적용하였다. 단, 일반적인 2D 이미지 증강 기법과 달리, 본 연구에서는 파라메트릭(parametric) 모델링을 활용하여 3D 객체 자체를 증강하는 방식을 채택하였다. 이는 2D 이미지 증강 기법이 간섭 양상을 왜곡시킬 가능성이 있으며, 다각도 이미지를 활용하는 경우 중복된 이미지만을 생성하여 데이터 증강 측면에서 실질적인 이점을 제공하지 못하기 때문이다.

데이터 증강의 구현은 비주얼 프로그래밍 인터페이스를 활용하여 파라미터와 규칙을 코드화할 수 있는 Autodesk Revit Dynamo를 통해 수행하였다. 구체적으로, ‘벽, 바닥, 천장’ 부재의 크기와 ‘배관, 덕트, 케이블 트레이’ 부재의 크기 및 각도를 주요 파라미터로 설정하고, ‘Math.Random’과 ‘Number Slider’ 노드를 통해 각 파라미터의 최댓값과 최솟값 범위 내에서 필요한 개수만큼 무작위 값을 생성하여 각 부재를 모델링하였다. 이후, ‘벽, 바닥, 천장’ 부재와 ‘배관, 덕트, 케이블 트레이’ 부재 간 간섭이 발생하도록 위치를 조정하여 증강 데이터를 최종 생성하였다.

데이터 증강 결과를 나타난 <Table 6>을 보면, 본 연구에서는 데이터 증강을 통해 모든 클래스의 훈련 데이터 수를 최대 클래스인 ‘수평 관통’의 데이터 개수(388개)로 맞추는 것을 목표로 설정하였으며, 총 896개의 증강 데이터를 생성하여 최종적으로 1,552개의 데이터를 확보하였다.

Table 6. Original and augmented training set

Penetration type		No. of original training set	No. of augmented data	Total
Partially penetrated		125	263	388
Fully penetrated	Horizontal	388	0	388
	Vertical	80	308	388
	Diagonal	63	325	388
Total		656	896	1,552

3.4 데이터 전처리: 다각도 간섭 이미지 변환

증강된 데이터셋을 MVCNN과 MVT 학습이 가능하도록 다각도 이미지 형태로 변환하였다. 기존 MVCNN 모델(Su et al., 2015)은 측면에서 30도 간격으로 촬영한 12장의 이미지를 활용했으나, 본 연구에서는 측면 36도 간격의 10방향과 위·아래 방향을 추가로 포함한 12방향 이미지를 사용하였다. 이는 BIM 부재의 기하 형상을 식별하기 위한 선행연구(Koo et al., 2021a; Koo et al., 2021b)에서 위·아래 이

미지를 추가 활용하는 것이 분류 성능을 확보하는 데 유의미한 것으로 입증된 것에 기반한 것으로, 본 연구에서도 ‘수평 관통’, ‘수직 관통’ 등의 세부 관통 양상을 명확히 구분하기 위해 이를 적용하였다.

다각도 이미지 변환 작업은 Navisworks API의 ‘Document.ActiveView’ 속성과 ‘Rotation3D’ 메서드(method)를 활용하여 촬영 각도를 회전시키고, ‘GenerateThumbnail’ 메서드로 각 간섭 이미지를 저장하는 C# 스크립트를 통해 별도의 add-in을 개발하여 구현하였다. <Fig. 7>은 간섭 인스턴스를 다각도 간섭 이미지로 변환한 예시를 보여준다.

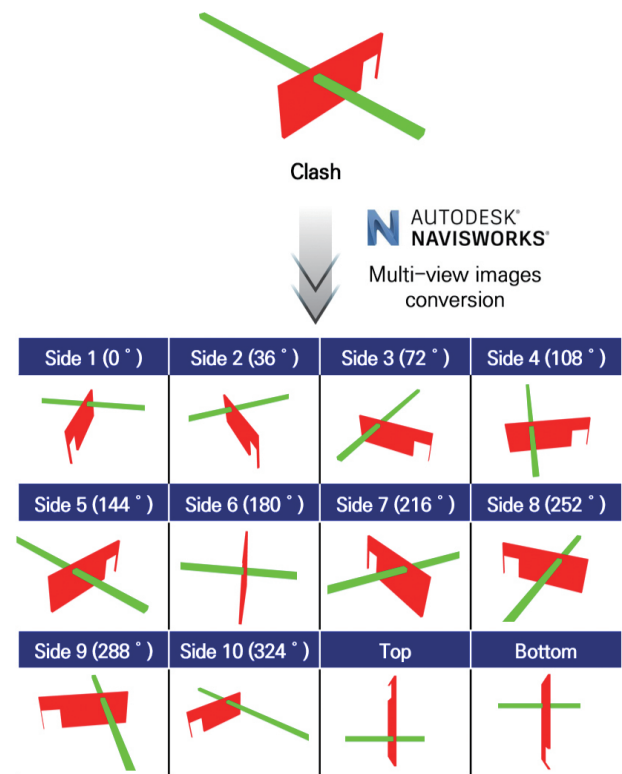


Fig. 7. Multi-view images conversion by clash instances using Navisworks add-in

상기 과정을 통해 증강된 훈련 데이터셋(1,552건)에서 총 18,624장의 이미지를 수집하였고, 검증 데이터셋(281건)에서는 3,372장의 이미지를 수집하였다. 최종적으로, 총 21,996장의 이미지를 딥러닝 모델의 학습 및 검증에 활용하였다(<Table 7>).

Table 7. Converted training & test set

Penetration type	Training set (augmented)	Test set	Total
Partially penetrated	4,656	648	5,304
Fully penetrated	Horizontal	1,992	6,648
	Vertical	408	5,064
	Diagonal	324	4,668
Total	18,624	3,372	21,996

3.5 학습모델 구축

앞서 구축된 다각도 간섭 이미지 데이터셋트를 활용해 MVCNN과 MVT를 학습하였다. 학습모델의 구현은 Python Pytorch 기반의 MVCNN⁶⁾ 및 MVT⁷⁾ 관련 라이브러리를 활용하였으며, 모델별 학습 과정은 다음과 같다.

3.5.1 MVCNN 모델 구축

(Fig. 8)은 간섭 인스턴스별 12방향 다각도 간섭 이미지 데이터를 학습하기 위한 MVCNN 모델 구축 과정을 보여준다. 다각도 간섭 이미지는 각각 CNN₁으로 입력되며, CNN₁은 VGG-M 구조 기반의 5개 convolutional layer로 구성되어 있다. CNN₁은 각 이미지에서 특징을 추출하며, 이렇게 추출된 특징은 View-pooling 층에서 element-wise maximum 연산을 통해 1차원 벡터로 축약된다. 축약된 벡터는 2개의 fully Connected layer와 1개의 softmax 층으로 구성된 CNN₂로 전달되며, CNN₂는 이를 기반으로 간섭 인스턴스의 슬리브 설치 가능 여부와 세부 관통 양상을 분류한다.

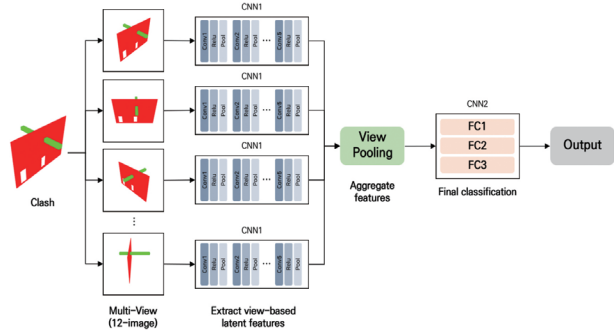


Fig. 8. MVCNN architecture for penetrability analysis

3.5.2 MVT 모델 구축

(Fig. 9)은 MVT 모델의 구축 과정을 보여준다. 먼저, 간섭 인스턴스의 다각도 간섭 이미지를 각각 196개의 비중첩 패치로 분할한다. 각 패치는 선형 투영(linear projection)을 통해 고차원 임베딩 벡터로 변환되며, 위치 정보를 포함한 위

치 임베딩을 추가하여 Transformer 모델이 시퀀스 데이터를 처리할 수 있도록 구성하였다. 이후 Local Transformer Encoder를 통해 개별 이미지의 패치 간 특징을 추출하며, 이 과정에서 attention 메커니즘이 활용된다.

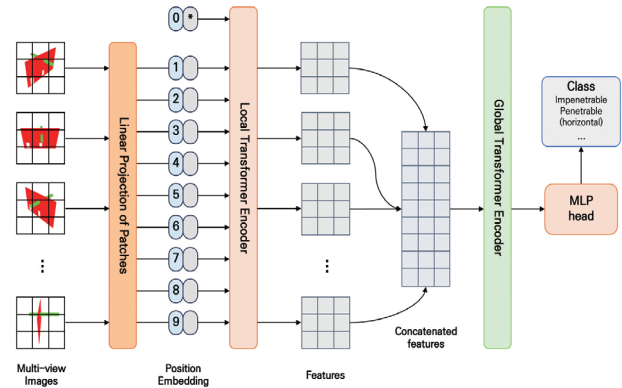


Fig. 9. MVT architecture for penetrability analysis

Multi-head self-attention (MSA)은 각 패치에 부여된 지역적 특징을 통합하여 향상된 패치 특성 세트를 생성한다. 다음 단계인 Global Transformer Encoder에서는 통합된 패치 특성을 입력으로 사용하며, 이 과정에서 global attention을 수행하여 다각도 시점 간 관계를 모델링한다. 이를 통해 개별 이미지들 간의 상호 관계를 학습하고 추출된 특징을 집계한 후, 최종적으로 Multi-layer Perceptron (MLP)을 적용하여 3D 형태의 간섭 인스턴스를 분류한다.

3.6 모델 평가 지표

구축된 딥러닝 모델의 성능 평가를 위해 실제 값과 모델의 예측값을 비교한 confusion matrix를 사용하였다. Confusion matrix를 기반으로 MVCNN, MVT와 같은 지도 학습(supervised learning) 딥러닝 모델에서 주로 활용되는 성능 지표인 정확도(ACC)와 F_1 -score를 활용하였다⁸⁾. 여기서 ACC는 전체 샘플 중 올바르게 예측된 샘플의 비율로 모델이 전체적으로 얼마나 분류를 잘 수행하는지 직관적으로 나타내는 지표이다. F_1 -score는 정밀도(precision)와 재현율(recall)의 조화평균으로 계산되며, 개별 클래스에 대한 모델의 상세 성능을 평가하는 데 유용한 지표이다(Lipton et al., 2014). 이에 따라, 본 연구는 모델의 전체 성능 평가에는 ACC를, 클래스별 성능 평가에는 F_1 -score를 활용하였다.

8) 본 연구에 활용된 성능평가지표는 아래와 같은 방법으로 산출됨.
 $ACC = (True\ Positive + True\ Negative) / (True\ Positive + False\ Positive + True\ Negative + False\ Negative)$
 $F_1 - score = 2 * Precision * Recall / (Precision + Recall) = True\ Positive / (True\ Positive + 1/2(False\ Positive + False\ Negative))$

6) <https://github.com/shanshuo/MVT>
 7) https://github.com/jongchysisu/mvcnn_pytorch

추가적으로, 이미지 내 간섭 부위에 대한 모델별 주목 정도를 평가하기 위해 heat map과 heat map 기반 Intersection over Union (IoU)을 활용하였다. Heat map은 특정 클래스를 예측할 때 모델이 주목한 영역을 나타내는 도구로, 이를 활용하여 모델이 관통성 분석 시 이미지 내에서 주목하는 주요 영역을 시각적으로 확인하였다. 더불어, 두 모델이 간섭 부위에 얼마나 주목했는지를 정량적으로 비교하기 위해, 간섭 부위를 나타내는 경계상자와 heat map 기반 경계상자 간 IoU를 산출하였다. IoU는 일반적으로 객체 탐지 분야에서 예측 영역과 실제 영역 간 겹침 정도를 평가하는 지표로, 본 연구에서는 간섭 부위와 각 모델이 주목하는 영역 간 IoU 대소비교를 통해 두 모델이 실제 간섭 부위에 주목하는 정도를 정량적으로 비교하였다.

4. 관통성 분석 모델 구축 결과

4.1 MVCNN 학습 결과

〈Table 8〉은 간섭 인스턴스 대상 학습된 MVCNN 모델의 검증 결과를 보여준다. MVCNN 모델은 평균 0.85의 ACC를 기록하였으며, 클래스별로는 ‘수평 관통’ 및 ‘수직 관통’ 케이스에서 0.90 이상의 높은 $F_1 - score$ 를 나타냈다. 그러나, ‘일부 관통’ 케이스에서는 0.69, ‘사선 관통’ 케이스에서는 0.74의 낮은 $F_1 - score$ 를 기록하였다.

〈Table 9〉에 제시된 confusion matrix를 분석한 결과, MVCNN 모델은 ‘일부 관통’ 케이스를 주로 ‘수평 관통’으로, 반대로 ‘수평 관통’ 케이스는 주로 ‘일부 관통’으로 오분류하는 것으로 확인되었다.

또한, MVCNN은 ‘사선 관통’을 ‘수평 관통’으로 오분류하며, 이 두 관통 양상을 구분하기 위한 기하적 차별점 또한 충분히 학습되지 않은 것으로 판단되었다. 반면, ‘수직 관통’ 케이스에서는 모든 사례를 정확히 분류하며, 해당 관통 양상의 기하적 특징을 명확히 인지하고 있는 것으로 나타났다.

이러한 결과는 기존 BIM 부재 분류 연구(Koo et al., 2021a; Koo et al., 2021b)에서도 유사하게 확인된 바 있다. MVCNN 모델은 평행과 입상처럼 관통 양상에서 명확한 기하적 차이가 존재하는 경우 효과적으로 분류할 수 있으나, 교차 상태나 관통 각도와 같은 미세한 차이를 학습하는 데 한계를 드러낸다는 점을 보여준다.

Table 8. Performance metrics for MVCNN

Penetration type		ACC	Precision	Recall	$F_1 - score$
Partially penetrated		0.65	0.75	0.65	0.69
Fully penetrated	Horizontal	0.93	0.86	0.93	0.90
	Vertical	1.00	0.89	1.00	0.94
	Diagonal	0.59	1.00	0.59	0.74
Total		0.85	0.88	0.79	0.82

Table 9. Confusion matrix for MVCNN

Actual \ Predicted		Partially penetrated	Fully penetrated			Total
			Horizontal	Vertical	Diagonal	
Partially penetrated		35	15	4	0	54
Fully penetrated	Horizontal	12	154	0	0	166
	Vertical	0	0	34	0	34
	Diagonal	0	11	0	16	27
Total		47	180	38	16	281

4.2 MVT 학습 결과

〈Table 10〉은 MVT 모델의 검증 결과를 보여준다. MVT 모델은 평균 0.98의 ACC를 기록하였으며, 클래스별 $F_1 - score$ 가 모두 0.90을 상회하여 전반적으로 높은 분류 성능을 기록하였다. 특히, 앞선 MVCNN에서 낮은 성능이 관측되었던 ‘일부 관통’ 클래스 또한 다른 클래스 대비 상대적으로 낮은 $F_1 - score$ 를 보였으나 0.96으로 여전히 준수한 분류 성능을 나타냈다.

〈Table 11〉의 confusion matrix를 보면, MVT 모델도 MVCNN 모델과 유사하게 ‘일부 관통’ 케이스를 ‘수평 관통’ 케이스로 혼동하는 경향이 확인되었다. 그러나 MVT는 MVCNN에 비해 오분류 사례가 현저히 적었으며, MVT의 오분류는 다각도 이미지에서 ‘완전 관통’으로 잘못 인식될 수 있는 예외적 상황에서 발생하였다. 일례로 〈Fig. 10〉에 제시된 간섭 인스턴스는 MEP 부재가 벽의 일부만 교차(intersected)하는 ‘일부 관통’ 사례이지만, 해당 벽에 문이나 창과 같은 다른 개구부 요소가 포함되어 있어 벽 형상이 일반적인 경우와 상이하였다. 이로 인해 특정 시점에서는 MEP 부재가 완전히 관통하는 것과 유사하게 보일 수 있으며, 이와 같은 시각적 왜곡으로 인해 MVT가 해당 인스턴스를 ‘완전 관통’으로 오분류한 것으로 확인되었다.

결론적으로, MVT는 관통 양상을 구분하는 데 필요한 차이를 명확히 학습하고 있으며, 특정 조건에서 예외적으로 오류를 범할 수는 있으나, 전반적으로 정확한 분류 성능을 보여주는 것으로 확인되었다.

Table 10. Performance metrics for MVT

Penetration type		ACC	Precision	Recall	F_1 -score
Partially penetrated		0.93	1.00	0.93	0.96
Fully penetrated	Horizontal	1.00	0.98	1.00	0.99
	Vertical	1.00	1.00	1.00	1.00
	Diagonal	1.00	1.00	1.00	1.00
Total		0.98	0.99	0.98	0.99

Table 11. Confusion matrix for MVT

Actual \ Predicted		Partially penetrated	Fully penetrated			Total
			Horizontal	Vertical	Diagonal	
Partially penetrated		50	4	0	0	54
Fully penetrated	Horizontal	0	166	0	0	166
	Vertical	0	0	34	0	34
	Diagonal	0	0	0	27	27
Total		50	170	34	27	281




Fig. 10. Misclassification of 'partially penetrated (intersected)' case as 'fully penetrated-horizontal'

4.3 모델 성능 비교 및 오분류 분석

두 모델의 분류 성능을 종합적으로 분석한 결과, MVCNN은 0.85의 ACC를 기록한 반면, MVT는 0.98의 ACC를 달성하여 MVT가 현저히 우수한 성능을 보였다. 클래스별 성능 비교에서는 두 모델 모두 '일부 관통' 케이스를 '수평 관통' 케이스로 혼동하는 경향이 나타나 F_1 -score가 하락하는 요인으로 작용하였으나, MVT는 MVCNN보다 혼동 비율이 낮은 것으로 확인되었다(Table 12). 또한, '사선 관통' 케이스에 대해서는 MVCNN이 0.74의 F_1 -score를 보인 반면, MVT는 1.00의 F_1 -score를 기록하며, 모델 간 성능 차이를 더욱 뚜렷하게 보여주었다.

Table 12. Performance comparison between MVCNN and MVT

Penetration type		ACC (MVT - MVCNN)	F_1 -score (MVT - MVCNN)
Partially penetrated		▲ 0.28	▲ 0.27
Fully penetrated	Horizontal	▲ 0.07	▲ 0.09
	Vertical	- 0.00	▲ 0.06
	Diagonal	▲ 0.41	▲ 0.26
Total		▲ 0.13	▲ 0.17

이러한 성능 차이는 두 모델의 이미지 특징 추출 방식의 차이에서 기인한 것으로 분석된다. 이를 검토하기 위해, 각 모델이 간섭 인스턴스에서 어떤 영역에 주목했는지를 시각적으로 확인할 수 있는 heat map을 추출하였다.

(Fig. 11)은 MEP 부재가 벽을 부분적으로만 교차하여 '일부 관통'으로 분류되는 사례에 대한 모델별 heat map을 제시한 것으로, 좌측 하단은 MVCNN 모델의 class activation map (CAM), 우측 하단은 MVT 모델의 Transformer Encoder에서 생성된 attention map을 나타낸다. 분석 결과, MVT는 간섭이 발생한 국소 영역에 집중한 반면, MVCNN은 이미지의 전체적인 형상에 주목하는 경향을 보였다.

이러한 차이를 정량적으로 비교하기 위해, (Fig. 11)과 같이 원본 이미지에서 간섭 부위를 나타내는 기준 경계상자를 설정하고, 각 모델의 heat map을 기반으로 생성된 예측 경계상자와의 IoU를 산출하고 대소비교를 수행하였다.

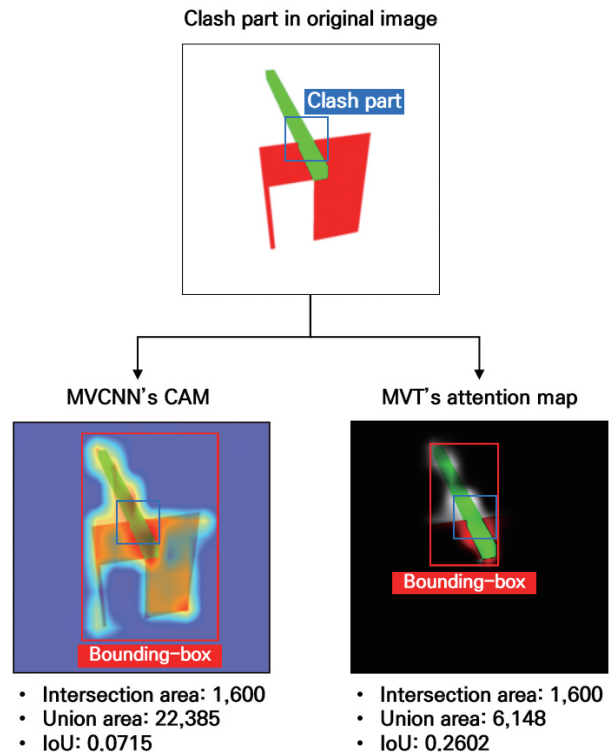


Fig. 11. IoU for MVCNN and MVT

검증 세트 내 281개의 간섭 인스턴스를 대상으로 각 간섭 인스턴스에 대한 모델별 평균 IoU를 산출한 결과 MVT는 0.0336의 IoU를 기록하였으며, 이는 MVCNN의 0.0117 대비 약 3배 높은 수치로(Fig. 12), MVT가 간섭 부위에 보다 정확하게 주목하고 있다는 것을 나타낸다. 이러한 대소비교 결과는 MVT가 attention 메커니즘을 통해 관통 양상을 식별하는 과정에서 국소적인 특징에 보다 정밀하게 집중할 수 있다는 것을 의미하며, 이러한 특성이 MVCNN 대비 우수한 분류 성능을 나타낸 주요 요인으로 판단된다.

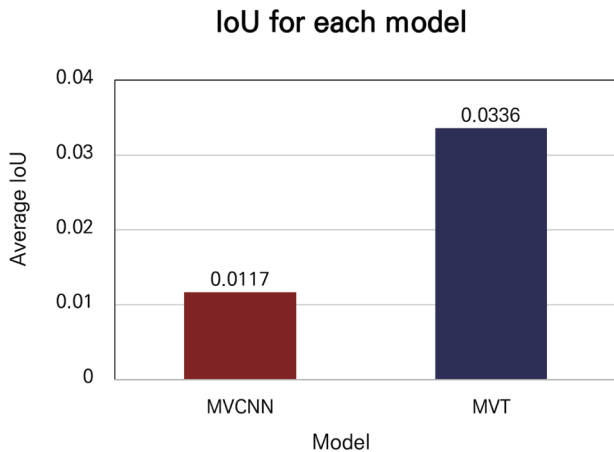


Fig. 12. Average IoU comparison between models

5. 결론

본 연구는 복합 공종 BIM 모델 내에서 슬리브 설치로 해결 가능한 비유효 간섭을 자동으로 식별하기 위한 관통성 분석 방법론을 제시하였다. 특히, 기존의 규칙 기반 접근법이 가지는 유연성 부족 및 실무 적용의 한계를 극복하고자, 다각도 이미지 기반 딥러닝 모델을 활용하여 개별 간섭 인스턴스의 슬리브 설치 가능 여부와 관통 양상을 자동으로 분류하는 모델을 개발하였다. 건축·구조 공종의 '벽, 바닥, 천장' 부재와 MEP 공종의 '덕트, 배관, 케이블 트레이' 부재 간 간섭을 대상으로 MVCNN과 MVT를 적용하여 학습을 수행한 결과, MVT는 0.98 ACC를 기록하며 MVCNN 대비 0.13 포인트 높은 성능을 나타냈다. 모든 관통 양상에 대한 F_1 - score 기준에서도 우수한 성능을 보였으며, heat map 및 IoU 분석을 통해 MVT가 간섭 부위에 보다 효과적으로 주목하고 있는 것이 확인되었다.

이러한 결과는 단순한 딥러닝 모델 간 성능 비교를 넘어 다음과 같은 실무적 의의를 갖는다. 첫째, 설계 초기 단계에서 슬리브 설치가 가능한 비유효 간섭을 자동으로 식별함으

로써, 불필요한 간섭 검토 및 수정 작업을 최소화하고 설계의 효율성과 정확성을 향상시킬 수 있다. 둘째, 세부 관통 양상 정보를 함께 제공함으로써 슬리브 설치가 필요한 간섭에 대해 보강 방법을 설계 단계에서 미리 결정할 수 있어 시공 단계에서의 공법 및 관련 비용을 더 정확하게 제시할 수 있다. 이를 통해 기존 실무자의 경험에 기반한 판단을 데이터 기반으로 보완하는 기술적 수단으로 활용될 수 있다.

또한, 본 연구는 실무 활용도가 높은 Navisworks API 기반 모듈을 포함하기 때문에 실무 적용 측면에서도 의의가 있다. 실무자는 Navisworks를 활용하여 간섭 인스턴스를 탐지한 뒤, 본 연구에서 개발한 add-in 모듈 내지 Blender와 같은 상용 소프트웨어 등을 통해 해당 인스턴스를 다각도 이미지로 자동 변환하고, 이를 관통성 분석 모델에 입력하는 절차로 활용할 수 있다. 더불어, 기존의 규칙 기반 접근법이 단순한 관통 여부만을 판단하는 데 그쳤던 것에 비해, 본 연구는 동일한 간섭 상황에 대해 세부 관통 양상까지 분류할 수 있는 학습 기반 모델을 제시함으로써, 표현력과 분류 정밀도 측면에서 개선 가능성을 확인하였다는 데에 의의가 있다.

그러나 본 연구는 슬리브 설치 가능 여부에 대한 분류에 초점을 맞추었으며, 슬리브 단면 크기에 따른 구조적 보강 필요성은 구조 기술사의 경험적 판단에 의존하고 있어, 해당 판단 기준을 정량화하지 못한 한계가 있다. 또한, 제안한 딥러닝 기반 분석 모델은 관통 양상의 다양성을 유연하게 처리할 수 있는 장점이 있으나, 예측 결과의 신뢰성 확보는 실무 적용에 있어 여전히 중요한 과제로 남아 있다.

따라서 향후 연구에서는 구조 기술사의 경험적 판단 기준을 정량화하여 슬리브 단면 크기에 따른 보강 여부까지 분류 가능한 통합 모델을 개발할 계획이다. 또한, 모델의 신뢰도를 높이기 위해 추가 학습 데이터를 확보하는 동시에, 모델의 추론 결과를 전문가가 최종 검토 후 확정하는 프로세스를 도입하여, 실무적 신뢰성과 활용성을 강화하고자 한다.

감사의 글

본 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 수행되었음(과제번호 22AATD-C163269-02).

ORCID

Hyunwoo Lee, <https://orcid.org/0009-0000-1953-5935>

Youngsu Yu, <https://orcid.org/0000-0002-4725-6041>

Wonbok Lee, <https://orcid.org/0000-0003-3593-0657>

Bonsang Koo, <https://orcid.org/0000-0002-1029-337>

References

- Ahmadpanah, H., Haidar, A., and Latifi, S.M. (2023). "BIM and Machine Learning (ML) Integration in Design Coordination: Using ML to automate object classification for clash detection." *eCAADe*, 41(2), 619-628. <https://doi.org/10.52842/conf.ecaade.2023.2.619>
- Chase Lipton, Z., Elkan, C., and Narayanaswamy, B. (2014). "Thresholding classifiers to maximize F1 score." *arXiv:1402.1892*, arXiv preprint, <https://doi.org/10.48550/arXiv.1402.1892>
- Chen, S., Yu, T., and Li, P. (2021). "Mvt: Multi-view vision transformer for 3d object recognition." *arXiv:2110.13083*, arXiv preprint. <https://doi.org/10.48550/arXiv.2110.13083>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, Z., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., and Houslyby, N. (2020). "An image is worth 16x16 words: Transformers for image recognition at scale." *arXiv:2010.11929*, arXiv preprint. <https://doi.org/10.48550/arXiv.2010.11929>
- Hasannejad, A., Majrouhi Sardroud, J., Shirzadi Javid, A.A., Purrostam, T., and Ramesht, M.H. (2022). "An improvement in clash detection process by prioritizing relevance clashes using fuzzy-AHP methods." *Building Services Engineering Research and Technology*, 43(4), pp. 485 - 506. <https://doi.org/10.1177/01436244221080023>
- Hu, Y., Castro-Lacouture, D., and Eastman, C.M. (2019). "Holistic clash detection improvement using a component dependent network in BIM projects." *Automation in Construction*, 105, 1-16. <https://doi.org/10.1016/j.autcon.2019.102832>
- Hu, Y. (2020). "Clash Resolution Optimization based on Component and Clash Dependent Networks." Ph.D. dissertation, Georgia Institute of Technology
- Hu, Y., and Castro-Lacouture, D. (2019). "Clash relevance prediction based on machine learning." *Journal of computing in civil engineering*, 33(2), 1-15. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000810](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000810)
- Kermanshahi, E.K., Tahir, M.B.M., Lim, N.H.A.S., Balasbaneh, A.T., and Roshanghalb, S. (2020). "Implementation of building information modeling for construction clash detection process in the design stage: a case study of Malaysian police headquarter building." *In IOP Conference Series: Earth and Environmental Science*, 476(1), 1-9. <https://doi.org/10.1088/1755-1315/476/1/012009>
- Koo, B.S., Jung, R.K., and Yu, Y.S. (2021a). "Automatic classification of wall and door BIM element subtypes using 3D geometric deep neural Network." *Advanced Engineering Informatics*, 47, 1-11. <https://doi.org/10.1016/j.aei.2020.101200>
- Koo, B.S., Jung, R.K., Yu, Y.S., and Kim, I.H. (2021b). "A geometric deep learning approach for checking element-to-entity mappings in infrastructure building information models." *Journal of Computational Design and Engineering*, 8(1), 239-250. <https://doi.org/10.1093/jcde/qwaa075>
- Kwon, O.C., and Cho, J.W. (2015). "BIM clash quality control by expert system." *Korean Journal of Computational Design and Engineering*, 20(1), 22 - 35. <https://doi.org/10.7315/cadcam.2015.022>
- Lin, W.Y., and Huang, Y.H. (2019). "Filtering of irrelevant clashes detected by BIM software using a hybrid method of rule-based reasoning and supervised machine learning." *Applied Sciences*, 9(24), 1-25. <https://doi.org/10.3390/app9245324>
- Lee, W.B. (2024). "A Study on Automated Clash Type Classification of Building Information Modeling Based on Artificial Intelligence." Master Dissertation, Seoul National University of Science and Technology
- Daniel, M., and Sebastian, S. (2015). "Voxnet: A 3d convolutional neural network for real-time object recognition." *In 2015 IEEE/RSJ international conference on intelligent robots and systems*, IEEE, 922-928. <https://doi.org/10.1109/IROS.2015.7353481>
- Nepal, M.P., Staub-French, S., Pottinger, R., and Webster, A. (2012). "Querying a building information model for construction-specific spatial information." *Advanced Engineering Informatics*, 26(4), 904-923. <https://doi.org/10.1016/j.aei.2012.08.003>
- Qi, C.R., Su, H., Mo, K., and Guibas, L.J. (2017). "Pointnet: Deep learning on point sets for 3d classification and segmentation." *Proceedings of the IEEE conference on computer vision and pattern recognition*, IEEE, 652-660. <https://doi.org/10.48550/arXiv.1612.00593>
- Shehadeh, A., Alshboul, O., Taamneh, M.M., Jaradat, A.Q., and Alomari, A. H. (2024). "Enhanced clash detection in building information modeling: Leveraging modified extreme gradient boosting for predictive analytics." *Results in Engineering*, 24, <https://doi.org/10.1016/j.rineng.2024.103439>
- Su, H., Maji, S., Kalogerakis, E., and Learned-Miller, E. (2015). "Multi-view convolutional neural Network for 3D shape recognition." *Proceedings of the 2015 IEEE International Conference on Computer Vision*, IEEE, 945-953. <https://doi.org/10.1109/iccv.2015.114>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, L., and Polosukjin, I. (2020).

“Attention is all you need.” *Advances in neural information processing systems*, 30, <https://doi.org/10.48550/arXiv.1706.03762>

요약 : BIM 모델은 분야별로 분절된 상태에서 설계가 진행된 후, 실시설계 단계에서 통합되며 다수의 간섭이 발생한다. 이 중 상당수는 실제 시공 시 별도 조치가 필요 없는 비유효 간섭으로, 이를 분류하는 데 많은 시간과 노력이 소요된다. 특히, 슬리브 설치 가능 여부 식별은 비유효 간섭을 분류하는 핵심 과정으로, 이를 자동화하기 위한 관통성 분석 연구가 진행되어 왔다. 그러나 기존 연구는 수동 추론 규칙에 의존하고, 실무에 필요한 세부 관통 양상을 충분히 반영하지 못하는 한계가 있었다. 이에 본 연구는 이러한 한계를 극복하고자, 다각도 이미지 학습이 가능한 Multi-view CNN(MVCNN) 및 Multi-view Vision Transformer(MVT) 기반 관통성 분석 모델을 구축하고, 두 모델의 성능을 비교하여 최적의 분류 모델을 구축하고자 하였다. 실험 결과, MVT는 정확도 0.98을 기록하며 MVCNN 대비 0.13포인트 높은 성능을 보였고, 세부 관통 양상 분류에서도 우수한 결과를 나타냈다. 이는 MVCNN이 전체 형상에 주목한 반면, MVT는 attention 메커니즘을 통해 간섭 부위에 집중했기 때문으로 분석된다. 이러한 결과는 단순히 딥러닝 모델 간 성능 비교를 넘어 설계 초기 단계에서 비유효 간섭을 자동으로 식별토록 하여 설계 효율성과 정확성을 향상시키고, 분류된 관통 양상 정보를 토대로 시공 단계에서의 공법 및 관련 비용을 더 정확하게 제시할 수 있다는 점에서 실무적 의의를 가진다.

키워드 : 관통성, 슬리브 설치, Multi-View Vision Transformer, Multi-View CNN, BIM
