

딥러닝 기반 BIM(Building Information Modeling) 벽체 하위 유형 자동 분류 통한 정합성 검증에 관한 연구

Using Deep Learning for automated classification of wall subtypes for semantic integrity checking of Building Information Models

정래규¹⁾, 구본상²⁾, 유영수³⁾

Jung, Rae-Kyu¹⁾ · Koo, Bon-Sang²⁾ · Yu, Young-Su³⁾

Received October 23, 2019; Received November 19, 2019 / Accepted November 19, 2019

ABSTRACT: With Building Information Modeling(BIM) becoming the de facto standard for data sharing in the AEC industry, additional needs have increased to ensure the data integrity of BIM models themselves. Although the Industry Foundation Classes provide an open and neutral data format, its generalized schema leaves it open to data loss and misclassifications. This research applied deep learning to automatically classify BIM elements and thus check the integrity of BIM-to-IFC mappings. Multi-view CNN(MVCC) and PointNet, which are two deep learning models customized to learn and classify in 3 dimensional non-euclidean spaces, were used. The analysis was restricted to classifying subtypes of architectural walls. MVCNN resulted in the highest performance, with ACC and F1 score of 0.95 and 0.94. MVCNN unitizes images from multiple perspectives of an element, and was thus able to learn the nuanced differences of wall subtypes. PointNet, on the other hand, lost many of the detailed features as it uses a sample of the point clouds and perceived only the 'skeleton' of the given walls.

KEYWORDS: BIM, IFC, Subtype Classification, Architectural Walls, Deep Learning

키워드: BIM, IFC, 하위 유형 분류, 건축 벽체, 딥러닝

1. 서론

1.1 연구의 배경 및 목적

국토교통부는 공공시설물을 대상으로 3차원 기반의 정보 모델로 설계하는 Building Information Modeling(BIM) 기술을 우선 적용하는 발주를 확대하고, 이를 위하여 2019년에는 BIM 설계 라이브러리 공유플랫폼을 구축하며, 2021년에는 BIM 설계기준을 정립한다(Kang et al., 2012). 이에 따라 건설 사업 생애주기 전반에 걸쳐 발생하는 각종 정보를 단계별로 연계시켜 효율적으로 관리 및 활용할 수 있게 된다.

실제로 BIM에 기초한 모델은 부재 간 충돌 감지, 설계 품질 보증, 시공성 분석, 유지관리 등 다방면으로 널리 활용되고 있다. 이러한 개별 니즈를 해결하기 위한 전문화된 소프트웨어가 등

장하고 있으며, 이 때 소프트웨어 간 정보 교환 시 상호호환성(Interoperability)이 중요한 문제로 부각되고 있다.

국제 ISO 표준 모델인 Industry Foundation Classes(IFC)는 건설 정보를 중립적이고 개방적인 데이터 포맷으로 제공해 줌으로써 BIM 소프트웨어 간 개별 객체의 속성 및 객체 간 관계 정보의 교환을 가능케 해주는 중추적 역할을 담당하고 있다.

그러나 실제 IFC를 활용하여 데이터 전달 시 건설 정보의 무결성(Integrity)이 보장되지 않는 문제가 존재한다. IFC는 건설 관련 다수 도메인에서 필요로 하는 객체 및 관계 정보를 유연하게 표현할 수 있도록 설계되어 있는데 이런 범용성 때문에 중복적이며 난해한 구조를 가지고 있다(Eastman et al., 2009). 이에 따라 데이터 교환 시 오류 및 누락에 취약한 모습을 보인다(Bazjanac and Kiviniemi, 2007).

¹⁾학생회원, 서울과학기술대학교 건설시스템공학과 석사과정 (forb1214@seoultech.ac.kr)

²⁾정회원, 서울과학기술대학교 건설시스템공학과 부교수 (bonsang@seoultech.ac.kr) (교신저자)

³⁾학생회원, 서울과학기술대학교 건설시스템공학과 석사과정 (digh0935@gmail.com)

기존 연구에서는 이런 IFC의 한계 극복을 위해 개별 BIM 부재와 IFC 엔티티(entity)간의 매핑을 추론적 규칙(inference rules) 기반으로 해결하고자 하였다(Venugopal et al., 2012). 그러나 이는 연역적 접근방법으로서 확장성(scalability)에 제약을 갖고 있다.

이에 본 연구에서는 귀납적 방식인 기계학습(machine learning) 기반으로 본 문제를 해결하고자 하였다. 즉, 개별 BIM 부재의 기하 특성을 학습하여 부재 식별을 자동화하고 이를 통해 IFC 엔티티와의 매핑을 검증하는 방식이다. 기존 연구에서 기계학습 기법인 Support Vector Machine(SVM)을 활용하여 주요 건축 BIM 부재(벽체, 문, 창호, 계단, 난간 등)를 자동 분류할 수 있었다(Koo et al., 2019). 본 연구에서는 한 단계 더 나아가 각 BIM 부재의 하위 유형(subtype)을 자동 세분화할 수 있도록 딥러닝(deep learning) 기법을 적용하였다.

구체적으로 Multi-view Convolutional Neural Network(MVCNN)(Su et al., 2015)과 PointNet(Qi et al., 2017)의 두 가지 기하학적 딥러닝 기법을 사용했다. MVCNN은 BIM 객체를 30° 마다 촬영하여 얻은 12장의 2D 복수 이미지로부터 3D 형상 정보를 인식하여 객체 분류 및 하위 유형을 세분화한다. PointNet은 포인트 클라우드(점군) 데이터를 직접 입력 데이터로 사용하여 객체 분류 및 하위 유형을 세분화 시킬 수 있다.

본 연구에서는 이들 딥러닝 모델을 BIM 부재 중 벽체의 하위 유형을 자동 분류하고, 이들의 정확성을 평가하여 적용 가능성을 비교 분석하였다.

본 연구 결과가 IFC의 상호호환성을 향상시키고, BIM 모델의 정합성 및 품질 보증 등에 활용될 것으로 기대한다.

1.2 연구의 범위 및 방법

본 연구에서는 BIM 부재와 IFC 클래스 간 매핑의 무결성 검증을 위하여 딥러닝 기법인 MVCNN, PointNet을 활용하는 방안을 제시하고자 하였으며, 특히 개별 BIM 부재의 하위 유형(subtype)을 분류하는 데에 적용하고자 하였다. 이에 따라 본 연구에서는 벽체(IfcWall)를 세분류하는 데에 집중하였으며, 다음과 같은 일련의 과정으로 연구를 진행하였다.

1) IFC 운용상 문제점 및 기존 연구 동향

기존 문헌 고찰을 통해 IFC 운용 문제를 정리하고 이를 해결하기 위한 시멘틱 강화(semantic enrichment) 관련 연구 동향 분석을 수행하였다.

2) BIM 모델 수집 및 하위 유형 분류

3개의 건축 BIM 모델에서 벽체를 추출하고 중복 제거하여 총 364개를 수집하였다. 벽체의 하위 유형 분류를 위해서는 적합한 분류 기준이 선결되어야 한다. 국제 표준 분류 시스템 분석 결

과 및 시공단계에서 시공자가 필요로 하는 벽에 대한 특징을 토대로 개구부가 없는 일반 벽체(Generic Wall), 창호가 있는 벽체(Wall with window opening) 및 문이 있는 벽체(Wall with door opening)로 구분하였다.

3) 딥러닝 기반 모델 지도 학습 수행

개별 벽체를 각 딥러닝 모델에 활용 가능한 데이터 포맷 형태로 변환하였다. 즉, MVCNN은 12개의 다각도 이미지로, PointNet은 포인트 클라우드 포맷으로 변화하였다. 이후 훈련 세트(training set)를 구축하여 두 모델을 훈련시켰다. 또한 이들의 성능을 상대 평가 하기 위해, 즉, baseline 모델 설정을 위해 SVM도 함께 훈련 시켰다.

4) 학습 모델 검증

학습 시킨 각 딥러닝 모델의 검증을 위해 테스트 세트(test set)의 예측정확도(ACC, Accuracy), Precision/Recall 및 F1 값들을 성과 지표로 활용하였다.

5) 결과 비교 분석 및 활용 방안 도출

두 모델의 성능 및 오분류 결과를 토대로 장단점을 을 비교 분석하였으며, BIM 부재 분류에 적용성을 평가하고 실무에서의 활용 방안을 제시하였다.

2. 이론적 고찰

2.1 IFC 한계 및 시멘틱 강화 연구

IFC 데이터 스키마는 여러 분야의 정보를 포함하기 위해 폭넓고 유연한 데이터 구조를 제공하지만, 광범위한 건설 산업 전반 분야에 걸쳐 각종 도메인의 객체 및 관계에 대한 정보를 표현해야 하므로 복잡하며 중복성을 가지고 있다(Eastman et al., 2009). 또한 데이터 교환 중 정보를 경량화하거나 단순화하기 때문에 데이터의 왜곡 및 손실, 부정확한 객체 정보 전달 등의 문제점이 발생하고 있다(Bazjanac and Kiviniemi, 2007).

이러한 문제의 일부는 BIM 데이터를 IFC로 변환하기 위해 부재별로 IFC 클래스에 매핑(mapping)이 필요한데, 본 작업이 수동으로 진행됨에 따라 오류 및 누락이 발생하는데서 비롯된다.

이와 같은 IFC 운용 문제 및 개선을 위해 다방면의 연구가 진행되었다.

2.1.1 IDM 및 MVD

본 문제의 해결을 위한 방안으로 국제인증기관인 빌딩스마트협회는 Information Delivery Manual(IDM) 및 Model View Definition(MVD) 사용을 권장한다.

IDM은 건설 프로세스의 분야 간 데이터 교환에 관한 요구사항을 명시한 정의로 어떤 정보가 두 소프트웨어 간 전달되어야 하는지를 정의하고 있다. MVD는 IDM의 데이터 교환 요구사항에 부합하는 IFC 관점과 구현에 필요한 스펙을 명시한 정의로 전체 IFC 스키마 중 일부만 추출하게 해주는 교환 기준이다(Kim et al., 2013, Koo et al., 2019).

그러나 MVD 구현을 위해서는 각 MVD에 맞춘 IFC 입출력(Import/Export) 기능을 소프트웨어 마다 만들어야 한다. 이는 표준 데이터 포맷을 통해 일대일 교환 문제를 해소하려는 IFC의 근본 취지에 어긋난다(Belsky et al., 2016).

2.1.2 시멘틱 강화

최근에는 IFC 내용의 무결성을 검증하고 정확한 매핑을 정립하려는 시멘틱 강화 분야의 연구가 진행되고 있다.

대표적으로, Belsky et al.(2016)은 주어진 BIM 모델의 객체 및 속성을 검토하고 시멘틱 추론 규칙을 통해 오류를 수정 및 보완 할 수 있게 하였다. Pauwels and Terkaj(2016)는 IFC 전용 언어인 ifcOWL를 구축하여 객체 및 속성 표현의 정밀화를 구현하였다.

Ma et al.(2017)는 부재의 기하형상과 부재 간의 관계 정보를 이용하여 부재 간 유사도를 수치화하여 오류를 찾고자 하였다. Bloch and Sacks(2018)은 기계학습 기반으로 BIM 건축모델의 공간을 자동으로 분류하였다.

기존 연구에서는 Ma et al.(2017)과 유사하게 기존 부재 기하형상 및 부재 간의 관계를 기계학습 기법인 SVM을 활용하여 주요 건축 BIM 부재(벽체, 문, 창호, 계단, 난간 등)를 자동 분류하였다(Koo et al., 2019). 이에 본 연구에서는 한 단계 더 나아가 딥러닝 기법을 적용하여 결과적으로 각 BIM 부재의 하위 유형을 자동 세분화하고 이를 통해 매핑 오류를 찾을 수 있는 방안을 모색하였다.

2.2 세부 분류 필요성 및 국제 분류 기준

2.2.1 세부 분류 필요성

주어진 BIM 부재의 세부 분류가 중요한 이유는 다양하지만 궁극적으로 BIM 모델이 담고 있는 정보의 정확성을 높이기 위해서이다. IFC는 주요 부재에 대한 엔티티(ifcProduct)를 매핑할 수 있게 하지만, 기본적으로 1차적 부재 분류만 해준다. 예를 들어, 문의 경우, 하위 유형으로 단문, 복문, 미닫이문, 회전문 등 다양하지만, IFC에서는 이를 통상 모두 ifcDoor로 매핑한다. 물론, ifcDoorTypeOperationEnum 등으로 세부 분류 속성도 제공하지만, 이는 수동으로 지정해야 하는 관계로 BIM 모델에서는 이를 공백으로 남겨지는 경우가 대부분이다. 따라서, 설계 단계에서 구축된 BIM 모델은 이런 세부 유형에 대한 정보 없이 넘겨지는 경우가 다반사다.

또한 시공 단계에서도 요소 하위 유형이 필요하다. 일례로, Nepal et al.(2012)은 시공 공법 결정을 위해서는 부재의 세부 유형 정보가 가장 중요하다고 주장하였다. 예를 들어, 벽체의 경우, 벽체에 개구부 및 관통 여부의 정보가 필요하며 이에 따른 유형 구분이 필요하다고 역설하였다.

유지관리 단계에서도 세부적인 부재 정보가 필요하다. 유지관리 정보 취합을 위해 쓰이는 Construction-Operations Building information exchange (COBie)에서는 설계와 시공단계에서 발생하는 정보 중 구체적인 부재의 재료 타입, 보증(warranty) 등과 함께 부재의 하위 유형을 필수적으로 요구한다.

2.2.2 국제 분류 기준

BIM 부재의 하위 유형 분류는 일반적으로 건설 분야 국제 표준인 Omniclass(Construction Specifications Institute, 2017) 및 UniClass(NBS National BIM Library, 2017) 등에서 제공해주며 BIM 저작도구 등에서 이를 준용하고 있다.

Omniclass는 북미 건축, 엔지니어링 및 건설(AEC) 업계가 구상부터 철거 또는 재사용에 이르는 전체 설비 수명주기 동안 생성 및 사용하는 정보를 표준화된 기반으로 제공하고, 건설 환경을 구성하는 모든 다양한 유형의 건축물을 포괄하도록 설계되었다.

Uniclass는 ISO의 분류 기준을 따르고 있으며, 유럽에서 공통적으로 활용되는 CI/SfB 및 기타 기존의 분류 체계를 대체할 건설 분야 범용 기술정보 분류체제로 개발되었다.

본 연구 대상 부재인 벽체의 경우, OmniClass는 Table 21, Uniclass는 Table EF에서 하위 유형을 제시하고 있다. 이들은 벽체를 주로 용도 및 재료 종류에 따라 구분하고 있다. 즉, 내력벽/일반벽, 외벽/내벽 등으로 구분하거나 사용재료인 목재, 콘크리트, 철골 등으로 분류하고 있다.

2.3 3D 딥러닝 기법

딥러닝 기술은 2D 이미지처럼 평면(plane) 또는 격자(grid)상에 데이터가 존재하는 유클리드 공간 해석에 매우 효과적인 것으로 드러났다.

컴퓨터 비전 분야에서는 오래전부터 이미지 내의 개별 부위 인식 및 분류에 노력해 왔다. 기존에는 이미지의 로컬 특성을 설명하는 특징 기술자 구축 및 적용에 중점을 두었다. 그러나 이런 접근 방식은 많은 수작업과 시행 반복이 요구되며, 데이터 노이즈 및 외부 노출 여건에 따라 결과의 편차가 높았다.

딥러닝의 출현으로 로컬 기술자를 설계하는 고유 필터를 통해 이미지 콘텐츠(예: 사람의 눈 등)를 식별하는 게 가능해졌다. 다수의 필터로 구성된 '템플릿 뱅크'를 사용하고 이를 신경망 형태로 겹겹이 쌓아 가장 관련성이 필터를 채택한 후 이들을 통해 이미지를 구별할 수 있다. 이는 기존 공리 시스템(axiomatic

system) 방법으로 하나의 이미지를 구별하는 방법 대신, 수많은 이미지 인스턴스를 사용하여 신경망을 훈련시켜 구별하는 방식이다.

최근에는 이런 접근 방식을 3D 다양체(3D geometric manifold) 및 그래프와 같은 비유클리드 공간(non-Euclidean space)에 적용하려는 시도가 증가하고 있다. 비유클리드 공간에서는 형상 불변성이 2D 유클리드와 같이 유지되지 않는다. 따라서 3D 공간에 맞는 필터를 새롭게 설계 및 개발돼야 한다. 이러한 연구 분야를 지오메트릭 딥러닝(geometric deep learning) (Bronstein et al., 2017)이라 하며, 딥러닝 기법과 기하학 이론을 접목시킨 것이다. 본 연구에서는 이 분야에서 높은 성과를 보인 두 가지 기법, Multi-View CNN과 PointNet을 사용하였다.

2.3.1 Multi-view CNN

CNN은 2D 이미지 인식 및 분류에서 성능이 가장 높은 딥러닝 모델로 자리잡았다. 최근에는 CNN을 3D 객체 분류 및 세그멘테이션에 적용한 연구가 등장하였다.

이중 Multi-view CNN(MVCNN)은 3D 형상을 다각도에서 촬영한 2차원 다중 이미지를 학습하여 해당 형상을 분류하며(Su et al., 2015), 그 성능은 3차원 모델을 직접 활용한 타 학습모델보다 뛰어난 것으로 드러났다.

그 이유는 3차원 모델을 직접 활용할 경우, 모델 훈련을 위해 본 모델을 복셀(voxel) 또는 폴리곤 매쉬(polyon mesh) 형태로 변환하게 되는데(Maturana and Scherer, 2015; Wu et al., 2015), 이 때 모델의 세세한 특징이 소실되어 분류의 정확성이 떨어지기 때문이다. 이에 비해 MVCNN은 다각도 이미지를 활용하기에 미세한 차이도 구별을 할 수 있게 된다.

Figure 1에서 MVCNN의 네트워크 구조를 볼 수 있다. 개별 이미지에 5 개 층으로 구성된 VGG-M을 각각 인식하게 하고 이들로부터 추출된 feature를 view pooling 층으로 압축하며, 이를 마지막 CNN층과 softmax층으로 학습하여 최종 분류를 한다.

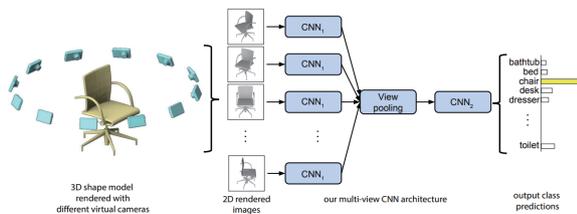


Figure 1. MVCNN architecture(Su et al., 2015)

2.3.2 PointNet

PointNet은 포인트 클라우드 데이터를 직접 사용하여 3차원 객체를 분류하는 첫 딥러닝 모델이다. 최근 건축 및 지형 측정, 자율주행자동차 등에서 LiDAR(Light Detection And Ranging)

및 LADAR(Laser Detection And Ranging)의 사용이 늘어나면서 포인트 클라우드 내의 객체를 직접 분류하는 필요성에 부응하여 개발된 학습모델이다.

기존 딥러닝 모델은 포인트 클라우드를 복셀화 내지 2차원 평면에 투영하는 변환 과정을 거친 후 이를 기반으로 식별하였으나, 전자의 경우 해상도가 낮아지며 후자의 경우 형태 자동 완성 작업에 활용하는데 한계가 있었다.

포인트 클라우드는 픽셀 배열로 이뤄진 이미지와 달리 데이터 순서에 의미가 없는 집합(unordered set)이다. 따라서, 포인트 클라우드를 직접 활용하고자 하는 신경망은 데이터 입력 순서의 무수한 조합에 불변(permutation invariant)해야 한다. PointNet은 이의 해결을 위해 순서에 상관없이 동일한 아웃풋을 내는 max pooling 대칭 함수와 신경망 중에는 Multi-Layer Perceptron(MLP)을 활용한다. 이와 함께 포인트 클라우드가 회전이나 변환에도 불변하도록 정렬 신경망(alignment network)도 학습시킨다. 이런 설계를 통해 PointNet은 객체 분류, 파트 세그멘테이션(Part Segmentation) 및 시멘틱 세그멘테이션(Semantic Segmentation)을 수행할 수 있다(Figure 2).

실제 구현을 위해서는 주어진 포인트 클라우드의 특성을 가장 잘 나타내는 ‘핵심 포인트 집합’(critical point set)을 추출하며 이를 통해 1,024개의 권역 특성을 통해 포인트 클라우드를 분류한다. 즉, 핵심 특성을 대표하는 샘플 포인트를 통해 주어진 포인트 클라우드의 ‘윤곽’(skeleton)을 추출한 후 이를 통해 분류하는 것이다.

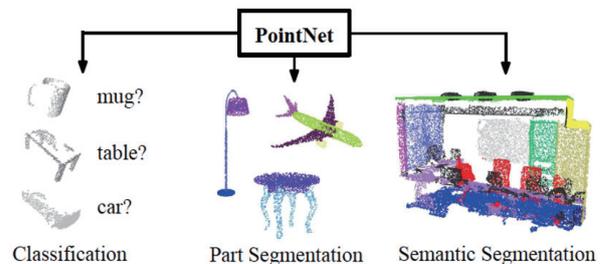


Figure 2. PointNet applications(Qi et al., 2017)

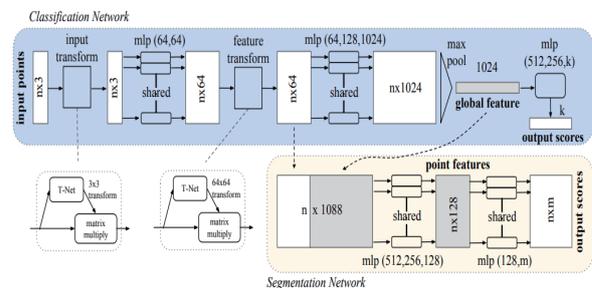


Figure 3. PointNet architecture(Qi et al., 2017)

3. 데이터 수집 및 딥러닝 모델 구축

본 연구에서는 BIM 부재의 하위 유형을 자동 분류하기 위해 앞서 소개한 MVCNN과 PointNet 딥러닝 모델을 적용해 보고 이의 비교 분석을 통해 최적 모델을 선정하는데 두었다.

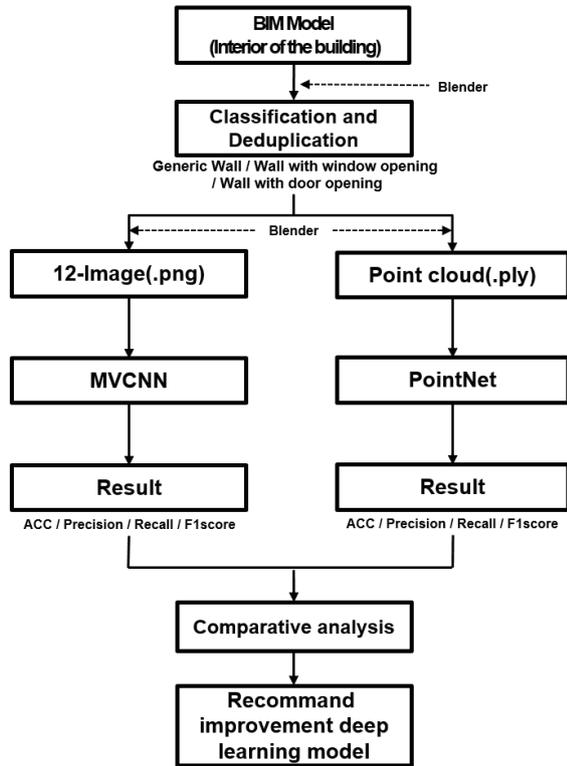


Figure 4. Flow Chart

우선 건축 BIM 부재 중 벽체에 초점을 맞추었으며 그 이유는 크게 두 가지다.

첫째, 벽체는 주어진 건축 BIM 모델에서 일반적으로 부재 개수가 가장 많은 축에 속한다. 둘째, 벽체는 BIM 저작도구의 기존 라이브러리에서 선택하여 BIM 모델에 배치 시 그 형상이 달라진다. 즉, 벽체의 경우 특정 BIM 모델에 배치 시 형태(높이, 폭 및 길이)가 조정되며 창호 나 문과 같은 타 부재의 삽입 및 관통에 따라 모양이 추가로 변형된다. 즉, 제공된 라이브러리와 변형된 형상을 갖추게 된다. 이에 비해 문, 창문, 가구 등과 같은 라이브러리의 경우, BIM 모델에 배치 시 그 원형을 크게 벗어나지 않는다. 따라서, 벽체의 경우, 하위 유형이 다양해지는데 이에 따라 세부 분류에 대한 오류나 누락의 가능성이 크다.

이처럼 다양한 벽체 인스턴스를 수집하기 위해 3개의 국내 건축 BIM 모델로부터 벽체 사례를 개별 수집하였다. 그 후, 개별 벽체를 두 개의 딥러닝 학습에 적합한 데이터 형태로 변환하였다. 즉, MVCNN의 경우 30° 각도에서 촬영한 12개의 이미지 그리고 PointNet의 경우 포인트 클라우드(점군)로 변환하였다. 또한

베이스 라인 구축을 위해 SVM 모델도 학습을 시켰는데, 이 경우 개별 벽체의 기본 기하정보(높이, 두께, 회전 반경 등)를 활용하였다.

이후 수집된 부재들을 다시 7:3의 비율로 학습 모델(training set) 및 평가 모델(test set)으로 나누었다. 전자는 딥러닝 모델의 훈련을 위해, 후자는 그들의 성과를 측정하기 위해 사용되었다.

성능은 정확도(ACC), F1 score, Precision/Recall 및 ROC(Receiver Operating Characteristic) Curve의 AUC(Area Under the Curve)를 사용하여 결과값을 측정하였다. ACC와 F1 score 값이 0.9를 초과하면 예측 성능이 뛰어난 것으로 간주되며, AUC 값이 0.9를 초과하면 이 역시 성능이 높은 모델로 간주된다(Muller et al., 2005).

3.1 벽체 하위 유형 분류, 데이터 수집 및 전처리

본 연구에 사용된 3개의 BIM 모델은 모두 건축 건물이며, Table 1은 건물 유형, 총 바닥 면적 및 구조 구성을 보여준다. BIM 모델의 품질을 보장하기 위해 KBIMS(Korea Building Information Modeling Standard)에서 제공하는 두개의 사무실 모델 및 연세대학교에서 구축한 공학관 모델을 활용하였다. 수집된 BIM 모델에서 추출한 벽체(lfcWall StandardCase)의 총 개수는 4,280개이며, 기하학적 형상 정보가 비슷한 부재를 중복 제거하고, 연구에 적합하지 않은 부재를 제외한 데이터 개수는 364개이다(Table 2).

Table 1. BIM model overview

Building Name	Yonsei ¹⁾	KBIMS1 ²⁾	KBIMS2 ²⁾
Image			
BuildingType	Research Building (Engineering School)	Office Building	Office Building
No. of Floors	6	10	6
Gross Floor Area(m ²)	19,873.50	10,624.20	2,086.50
IFC space designation	Yes	Yes	Yes

1)Building Informatics Group (BIG) lab, Yonsei University, <http://big.yonsei.ac.kr/>
 2)Korean Building Information Modeling Standards (KBIMS), <http://www.kbims.or.kr/>

벽체의 자동 세부 분류에 앞서 하위 유형 분류 기준을 정할 필요가 있다. 앞서 2.2절에 소개한 대로 벽체는 설계, 시공, 유지관리 단계에 따라 필요한 분류 기준이 달라질 수 있다. 여기서는 형상의 차이를 중요시 하는 시공 단계의 기준을 적용하였다.

즉, Nepal et al.(2012)은 시공단계에서 벽체 분류는 관통

4. 결과

4.1 ACC, F1 and Precision/Recall 값

Table 4는 세 가지 모델에 대한 ACC, Precision/Recall 및 F1 Score 결과값을 보여준다. MVCNN이 ACC(0.95) 및 F1 score(0.94)로 세 모델 중 가장 높은 성능을 보였다.

SVM은 ACC(0.615) 및 F1 score(0.55) 그리고 PointNet은 ACC(0.563) 및 F1 score(0.51)로 두 모델 모두 상대적으로 낮은 성능을 보였다.

Table 4. Accuracy (ACC) results for SVM, Multi-view CNN, PointNet (IrcWall)

	Accuracy	Precision	Recall	F1 score
SVM	0.615	0.61	0.54	0.55
MVCNN	0.95	0.96	0.94	0.94
PointNet	0.563	0.56	0.50	0.51

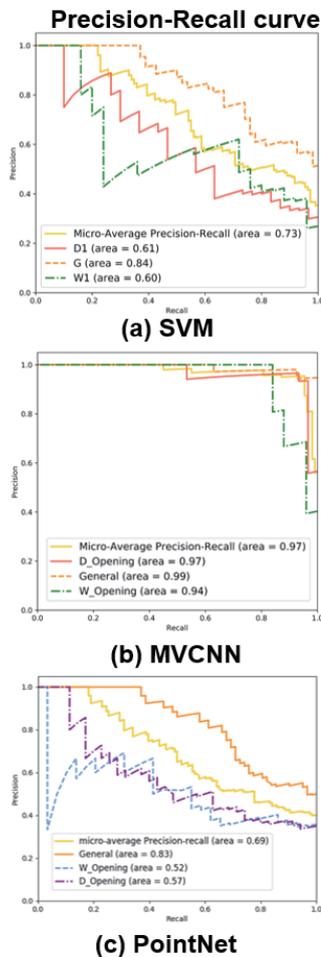


Figure 7. Precision/Recall curve

Figure 7은 세 모델의 Precision/Recall 값을 보여준다. MVCNN은 3개의 벽체 유형 모두에 대해 높은 Precision/Recall 값을 보였다. 다시 말해 낮은 False-Positive(Precision)과 낮은 False-Negative(Recall) 비율을 보이므로 ACC 결과가 편향되지 않음을 확인 할 수 있다.

이와 대조적으로 SVM 및 PointNet의 Precision/Recall 값은 일반 벽체(Generic wall)를 제외한 나머지 부재의 경우 MVCNN에 비해 상대적으로 낮은 값을 보여 분류 모델의 성능이 떨어진다고 볼 수 있다.

4.2 Confusion Tables and ROC

혼동행렬(Confusion Table)과 ROC Curve를 통해 세 모델에 대한 개별 벽체의 분류 결과를 파악할 수 있으며, 이를 통해 오류 유형에 대한 원인파악이 가능하다.

Figure 8에는 세 학습모델에 대한 ROC Curve가 제시됐으며 이를 통해 AUC 값을 확인할 수 있다. MVCNN의 경우 Generic wall(AUC=0.99), Wall with window opening(AUC=0.98), Wall with door opening(AUC=0.97) 값을 보였으며, Table 6의 혼동행

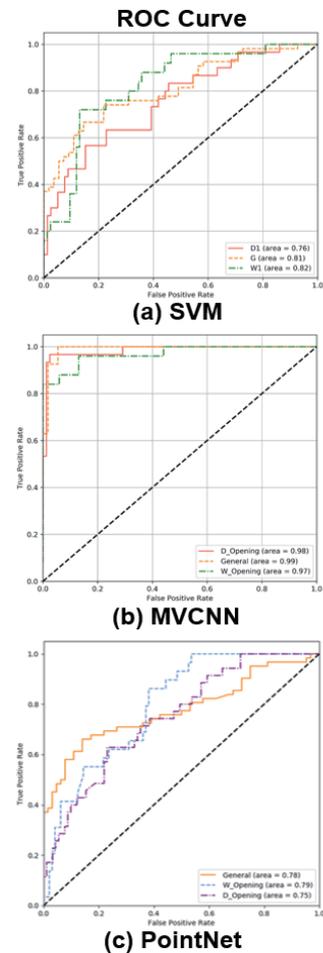


Figure 8. ROC curve

Table 5. SVM classification results (confusion table)

Predicted \ Actual	Generic wall	Wall with window opening	Wall with door opening	Total
Generic wall	45	3	6	54
Wall with window opening	15	7	3	25
Wall with door opening	13	2	15	30
Total	73	12	24	109

Table 6. MVCNN classification results (confusion table)

Predicted \ Actual	Generic wall	Wall with window opening	Wall with door opening	Total
Generic wall	54	0	0	54
Wall with window opening	2	21	2	25
Wall with door opening	2	1	29	30
Total	56	22	31	109

Table 7. PointNet classification results (confusion table)

Predicted \ Actual	Generic wall	Wall with window opening	Wall with door opening	Total
Generic wall	45	1	8	54
Wall with window opening	5	13	7	25
Wall with door opening	12	1	17	30
Total	62	15	32	109

결과(Confusion Table)에서도 5개를 제외한 모든 벽체를 구별한 것을 확인 할 수 있다.

반면, SVM의 경우 Generic wall(AUC=0.81), Wall with window opening(AUC=0.82), Wall with door opening(AUC=0.82) 상대적으로 낮은 성능을 보였으며, Table 5에 의하면 개구부가 존재하는 벽체의 30% 이상을 일반벽체로 오분류한 것을 볼 수 있다.

PointNet 또한 Generic wall(AUC=0.78), Wall with window opening(AUC=0.79), Wall with door opening(AUC=0.75)로 세 학습 모델 중 가장 낮은 성능을 보였다.

Table 7에 제시된 바와 같이, 개구부가 있는 벽체를 일반 벽체로 오분류하고 있으며, 개구부가 있는 벽체끼리도 혼동하고 있는 것을 볼 수 있다.

4.3 결과 해석

세 학습 모델 중 MVCNN의 분류 성능이 가장 높은 것으로 드러났다. MVCNN은 다각도에서 촬영한 이미지를 통해 학습하기에 벽체 형상의 세세한 차이를 인식하므로 분류를 성공적으로 한 것으로 파악된다.

이에 비해 SVM 및 PointNet은 실질적으로 분류에 실패한 것으로 평가되며, 이는 벽체의 상세한 형상 차이를 파악하지 못하여 나온 결과로 해석된다.

SVM의 경우 벽체를 경계박스(bounding box)로 변환 후 이로부터 기하 특성을 추출하기 때문에 개구부를 구분 못하는 것으로, 이는 어느 정도 예상된 결과이다.

PointNet의 경우, 2.3절에서 소개한 바와 같이, 주어진 포인트 클라우드의 권역 특성을 가장 잘 나타내는 샘플 포인트를 통해 그 윤곽 및 전반 형태를 파악하고 이를 통해 해당 객체를 인식한다. 원 논문(Qi et al., 2017)에서 PointNet의 검증으로 활용되었던 ModelNet40 데이터 세트를 살펴보면, 컵이나 전등에서부터 자동차, 비행기 등 다채로운 모델들이 포함돼 있는데, 이들은 비교적 윤곽 차이가 뚜렷하여 높은 성능을 보인 것으로 파악된다. 그러나 본 연구의 대상인 벽체와 같이 전체 형태가 매우 유사한 경우, PointNet이 샘플 포인트만 사용함으로써 그 미세한 차이들이 소실된 것으로 보인다. 즉, 개구부와 그의 위치에 대한 정보 및 차이점의 특성을 잃게 되어, 오히려 성능이 저하된 것으로 파악된다. 원 논문에서도 PointNet의 이런 한계점을 기술하고 있다.

5. 결론

본 연구에서는 BIM 부재와 IFC 클래스 간 매핑 검증을 위해 딥러닝 기반으로 BIM 부재 자동 분류 방법을 제시하였다. 두 개의 딥러닝 기법, MVCNN 및 PointNet과 기계학습 기법인 SVM을 각각 건축 BIM 벽체의 하위 유형 364개를 학습 및 검증한 결과 MVCNN이 ACC(0.95) 및 F1 Score(0.94)로 가장 높은 성능을 보였다.

SVM 및 PointNet은 상대적으로 낮은 성능을 보여 벽체 하위 유형 분류에 적합하지 않은 것으로 드러났다. SVM의 경우 주어진 경계박스 형태의 한계로, PointNet은 포인트 클라우드를 처리하는 과정에서 전체 '뼈대'만 인식하는 문제로 인해, 벽체의 세세한 차이를 분별하지 못하는 것으로 드러났다.

MVCNN은 다각도에서 촬영된 이미지를 기반으로 학습하기에

창문이 있는 벽체와 문이 있는 벽체까지 세세한 구분이 가능한 것으로 파악되었다. 이처럼 BIM 객체의 하위 유형 분류에는 상세한 형상을 구분할 수 있는 학습 모델이 필요한 것을 알 수 있다.

그러나, MVCNN은 다각도 촬영 이미지를 수집하는데 많은 시간이 요구되며, 개별 이미지를 각각의 CNN으로 학습 및 처리하면서 연산 시간이 오래 걸리는 단점 또한 존재한다. 실제로 Qi et al.(2017)에 의하면 MVCNN이 PointNet보다 연산 비용 및 시간이 각각 4배, 9배까지 소요되는 것으로 파악되었다.

따라서, MVCNN을 실무적으로 활용하기 위해서는 다각도 이미지 수집을 자동화하는 방안과 GPU 기반으로 연산속도를 향상시키는 방안이 강구되어야 할 것이다.

본 연구에서는 1개 벽체에 대해서만 검증해 보았다. 수많은 건축 BIM 객체에 확장을 위해서는, BIM 부재 유형별로 데이터 세트를 구축 및 하위 유형으로 레이블링하는 작업 등, 데이터 구축 작업 또한 자동화 작업이 필요할 것으로 사료된다.

감사의 글

본 연구는 국토교통부 도시건축 연구개발사업의 연구비지원(20AUDP-B127891-04)에 의해 수행되었음.

References

Bazjanac, V., Kiviniemi, A. (2007). Reduction, simplification, translation and interpretation in the exchange of model data, In CIB W, 78, pp. 163–168.

Belsky, M., Sacks, R., Brilakis, I. (2016). Semantic enrichment for building information modeling, Computer Aided Civil and Infrastructure Engineering, 31(4), pp. 261–274.

Bennett, K. P., Campbell, C. (2000). Support vector machines: hype or hallelujah?, Acm Sigkdd Explorations Newsletter, 2(2), pp. 1–13.

BIMCollective, IfcOpenShell, <http://ifcopenshell.org> (2016)

Bloch, T., Sacks, R., (2018). Comparing machine learning and rule-based inferencing for semantic enrichment of BIM models, Automation in Construction, 91, pp. 256–272.

Bronstein, M. M., Bruna, J., LeCun, Y., Szlam, A., Vandergheynst, P., (2017). Geometric deep learning: going beyond euclidean data, IEEE Signal Processing Magazine, 34(4), pp. 18–42.

Construction Specifications Institute, Omniclass, <https://www.csiresources.org/practice/standards/omniclass> (2017)

Eastman, C. M., Jeong, Y. S., Sacks, R., Kaner, I. (2009). Exchange model and exchange object concepts for implementation of national BIM standards, Journal of Computing in Civil Engineering, 24(1), pp. 25–34.

Kim, H., Choi, J., Kim, H., Kim, I. (2013). The Development of Data Model for Open BIM-Based Schematic Estimates – Focused on Construction Type for Actual Cost of Public Projects, Journal of the Architectural Institute of Korea Planning and Design, 29(3), pp. 61–70.

Kim, J., Moon, J., Joo, K. (2012). Proposal of roadmap and basic research of Information model standards for application on the BIM on civil engineering, Journal of Korea Academia-Industrial cooperation Society, 13(12), pp. 6176–6186.

Koo, B., La, S., Cho, N. W., Yu, Y. (2019). Using support vector machines to classify building elements for checking the semantic integrity of building information models, Automation in Construction, pp. 98, 183–194.

Ma, L., Sacks, R., Kattell, U. (2017). Building Model Object Classification for Semantic Enrichment Using Geometric Features and Pairwise Spatial Relations, in 2017 Leand and Computing in Construction Congress(LC3), pp. 373–380.

Maturana, D., Scherer, S. (2015). Voxnet: A 3d convolutional neural network for real-time object recognition, In 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), pp. 922–928.

Muller, M. P., Tomlinson, G., Marrie, T. J., Tang, P., McGeer, A., Low, D. E., Gold, W. L. (2005). Can routine laboratory tests discriminate between severe acute respiratory syndrome and other causes of community-acquired pneumonia?, Clinical infectious diseases, 40(8), pp. 1079–1086.

National BIM Library, NBS, <https://www.nationalbimlibrary.com/en/> (2017)

Nepal, M. P., Staub-French, S., Pottinger, R., Zhang, J. (2012). Ontology-based feature modeling for construction information extraction from a building information model, Journal of Computing in Civil Engineering, 27(5), pp. 555–569.

Pauwels, P., Terkaj, W. (2016). EXPRESS to OWL for construction industry: Towards a recommendable and usable ifcOWL ontology, Automation in Construction, 63, pp. 100–133.

Qi, C. R., Su, H., Mo, K., Guibas, L. J. (2017). Pointnet: Deep learning on point sets for 3d classification and segmentation, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 652–660.

Su, H., Maji, S., Kalogerakis, E., Learned-Miller, E. (2015). Multi-view convolutional neural networks for 3d shape recognition, In Proceedings of the IEEE international conference on computer vision, pp. 945–953.

Venugopal, M., Eastman, C. M., Sacks, R., Teizer, J. (2012). Semantics of model views for information exchanges using the industry foundation class schema, *Advanced engineering informatics*, pp. 26(2), 411–428.

Wu, Z., Song, S., Khosla, A., Yu, F., Zhang, L., Tang, X., Xiao, J. (2015). 3d shapenets: A deep representation for volumetric shapes, In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1912–1920.