

Semantic Segmentation 기반 딥러닝을 활용한 건축 Building Information Modeling 부재 분류성능 개선 방안

A Proposal of Deep Learning Based Semantic Segmentation to Improve Performance of Building Information Models Classification

이고은¹⁾, 유영수²⁾, 하대목³⁾, 구본상⁴⁾, 이관훈⁵⁾

Lee, Ko-Eun¹⁾ · Yu, Young-Su²⁾ · Ha, Dae-Mok³⁾ · Koo, Bon-Sang⁴⁾ · Lee, Kwan-Hoon⁵⁾

Received July 09, 2021; Received July 19, 2021 / Accepted July 19, 2021

ABSTRACT: In order to maximize the use of BIM, all data related to individual elements in the model must be correctly assigned, and it is essential to check whether it corresponds to the IFC entity classification. However, as the BIM modeling process is performed by a large number of participants, it is difficult to achieve complete integrity. To solve this problem, studies on semantic integrity verification are being conducted to examine whether elements are correctly classified or IFC mapped in the BIM model by applying an artificial intelligence algorithm to the 2D image of each element. Existing studies had a limitation in that they could not correctly classify some elements even though the geometrical differences in the images were clear. This was found to be due to the fact that the geometrical characteristics were not properly reflected in the learning process because the range of the region to be learned in the image was not clearly defined. In this study, the CRF-RNN-based semantic segmentation was applied to increase the clarity of element region within each image, and then applied to the MVCNN algorithm to improve the classification performance. As a result of applying semantic segmentation in the MVCNN learning process to 889 data composed of a total of 8 BIM element types, the classification accuracy was found to be 0.92, which is improved by 0.06 compared to the conventional MVCNN.

KEYWORDS: BIM, IFC, Semantic Segmentation, Multi-View CNN, CRF-RNN

키워드: BIM, IFC, 시멘틱 세그멘테이션, MVCNN, CRF-RNN

1. 서론

1.1 연구의 배경 및 목적

최근 국토교통부는 건설 산업의 디지털 및 스마트화의 일환으로 Building Information Modeling (BIM)의 도입 및 확산을 적극 추진 중이다(Ministry of Land, Infrastructure and Transport, 2020). BIM은 건설 사업 전 생애주기 동안 발생하는 정보를 유기적으로 연계시켜 주며, 정보의 손실이나 누락을 최소화해 줄 수 있다. 따라서 사업 참여자들 간 공통의 의사소통 도구로서 가장 적합한 수단으로 자리 잡아가고 있는 실정이다. 이와 더불어,

BIM은 기존 건설업 내 존재하는 노동 집약적인 저부가가치 작업의 자동화를 통해 생산성을 증대시키는데 활용될 수 있다. 일례로 2D 도면을 통해 수동으로 이루어지던 설계검토, 품질검토 작업을 자동화하여 검토시간을 획기적으로 단축할 수 있어 단순 반복되는 작업을 최소화할 수 있다(Kim et al., 2014).

이처럼 BIM의 활용은 높은 잠재력을 가지고 있다. 그러나 BIM의 활용을 극대화하기 위해서는 우선적으로 구축된 BIM 모델의 정합성이 전제되어야 한다. 즉, BIM 모델 내 개별 부재와 관련된 제반 데이터(부재 속성정보, 부재 간 관계정보, 공간 분류 등)가 올바르게 부여되어 있는 시멘틱 무결성(semantic integrity)이 보

¹⁾학생회원, 서울과학기술대학교 건설시스템공학과 석사과정 (rhdms4570@gmail.com)

²⁾학생회원, 서울과학기술대학교 건설시스템공학과 박사과정 (youngsu@seoultech.ac.kr)

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

⁴⁾정회원, 서울과학기술대학교 건설시스템공학과 교수 (bonsang@seoultech.ac.kr) (교신저자)

⁵⁾학생회원, 고려대학교 컴퓨터학과 석사과정 (rok.lee91@gmail.com)

장되어야 한다. 그러나 BIM 모델링 과정 역시 다수의 참여자(설계자 및 공중별 모델러)에 의해 이뤄지기 때문에, 실제로는 이러한 정합성이 온전히 이뤄지기 쉽지 않다. 특히, BIM 모델 내 개별 부재가 정확히 분류되었는지 여부, 그리고 더 나아가 국제 표준 포맷인 Industry Foundation Classes (IFC) 엔티티 분류에 부합하는지 여부는 가장 기본적이면서도 반드시 사전적으로 체크해야 하는 사항이다.

실제 BIM 내의 부재 분류 또는 매핑, 그리고 IFC와의 매핑 여부를 검토하는 다수의 연구가 등장하고 있으며(Belsky et al., 2016; Cursi et al., 2017; Bloch and Sacks, 2018; Koo et al., 2018), 주된 방식은 추론적 규칙 기반 방식과 인공지능 기반 방식으로 구분할 수 있다. 여기서 추론적 규칙 기반 접근법은 추론 규칙 집합(inference based rule sets)을 사전에 정의한 후 이를 기반으로 BIM 모델 내 부재 분류 오류를 탐색하는 연역적 접근방법을 의미한다. 그러나 이 경우 BIM 모델 내 존재하는 부재와 관련된 모든 규칙을 일일이 지정하고, 이를 전문가가 규명해야 하는 한계점으로 인해 확장성(scalability) 측면에서 제약이 존재한다(Jung et al., 2019).

이에 반해 인공지능 기반 접근법은 개별 BIM 부재의 기하 특성을 학습하고, 이를 통해 부재 식별을 자동화함으로써 시멘틱 무결성을 검증하는 귀납적 접근방법이다. 이는 주로 IFC 데이터 내 존재하는 기하 특성 정보를 추출하거나, 부재의 2D 이미지 혹은 3D 형상정보를 학습에 활용하는 방식으로 이루어져 왔다. 이 중 Jung et al. (2019)은 개별 BIM 부재를 12방향으로 촬영한 후 얻은 2D 이미지 데이터 세트를 대상으로 기하학적 딥러닝 알고리즘인 Multi-View CNN (MVCNN)을 활용하여 벽 부재의 하위 유형을 분류하였으며, 높은 분류 정확성을 검증하였다. 단, 2D 이미지 내 기하학적 차이가 명확함에도 몇몇 부재를 올바르게 분류하지 못하는 한계가 존재하였다. 이는 부재 이미지 내 학습하고자 하는 객체의 영역 범위가 명확하지 않아 학습 과정 내 부재의 기하학적 특성이 적절히 반영되지 못한 것에 기인한 것으로 판단되었다.

이에 본 연구에서는 MVCNN 학습의 선행 단계로 Conditional Random Fields as Recurrent Neural Networks (CRF-RNN) 기반 시멘틱 세그멘테이션을 적용하여 학습용 부재의 기하학적 특성이 학습 과정 내 적절히 반영될 수 있도록 하였다. 즉, 시멘틱 세그멘테이션을 통해 12방향 이미지 내 부재가 위치하고 있는 영역을 뚜렷하게 구분하여 학습모델이 부재의 형상에 집중할 수 있도록 하였다. 구체적으로 동일한 부재 이미지 데이터 세트를 활용하여 1차로 MVCNN 모델을 학습하고, 2차로 CRF-RNN 알고리즘 기반 시멘틱 세그멘테이션을 적용하여 이미지의 선명도를 개선한 후 MVCNN 모델을 학습하여 두 개의 결과 값을 비교함으로써 분류성능 향상 정도를 정량적으로 검증하였다.

1.2 연구의 범위 및 방법

본 연구는 기하학적 딥러닝 알고리즘인 MVCNN 모델 구축과정에 학습용 2D 이미지 대상 시멘틱 세그멘테이션 적용 시 향상되는 분류성능을 검증하고자 하였다. 이를 위해 8가지 건축 부재를 대상으로 분석을 실시하였으며, 구체적인 학습모델 구축과정을 아래에 제시하였다.

1) 건축 BIM 모델 수집 및 분석 대상 선정

개방형 BIM 연구단 성과공개 포털 내 수록된 건축 분야 BIM 부재 라이브러리인 'KBIMS Library v1.02(buildSMART Korea, 2019)'에서 18개 IFC 클래스로 구성된 총 1,207개 부재를 추출하였다. 이 중 학습에 적합한 8가지 IFC 클래스, 총 889개의 부재를 주 분석 대상으로 선정하였다.

2) 데이터 전처리 및 1차 MVCNN 모델 구축

선정된 부재를 대상으로 MVCNN 모델 구축을 위해 부재별 이미지를 12방향으로 촬영하여 학습에 적합한 데이터 형태로 변환하였다. 이후 MVCNN을 활용하여 BIM 부재 자동 분류 모델을 구축하였다.

3) 2차 CRF-RNN + MVCNN 모델 구축

앞서 구축된 부재별 12방향 이미지를 대상으로 CRF-RNN 기반 시멘틱 세그멘테이션을 적용하여 학습 데이터의 선명도를 향상시키고, 이를 활용하여 2차 MVCNN 모델을 구축하였다.

4) 학습모델 분류성능 검증

앞서 구축된 두 학습모델의 분류성능을 검증하기 위해 정확도(accuracy, 이하 ACC), 정밀도(precision), 재현율(recall) 및 F_1 -score를 모델 평가지표로 활용하였다.

5) 검증결과 비교 분석 및 오분류 원인 파악

단순 부재별 12방향 이미지 데이터 대비 CRF-RNN 기반 시멘틱 세그멘테이션된 데이터를 활용할 경우 향상된 분류성능 정도를 검증하였으며, 오분류된 부재의 원인을 파악하였다.

2. 연구 배경

2.1 시멘틱 강화 연구 동향

BIM 부재 및 제반 데이터 간 매핑 정확도를 향상시켜 BIM 모델의 품질 신뢰도를 확보하는 시멘틱 강화(semantic enrichment) 연구는 추론적 규칙 기반(inference rule based) 접근법과 인공지능 기반(artificial intelligence based) 접근법으로

구분할 수 있다.

추론적 규칙 기반 접근법(Belsky et al., 2016; Cursi et al., 2017; Ma et al., 2017)은 개별 부재의 기하 및 위상적 특성을 조합하여 추론적 규칙을 사전에 정의하고, 이를 BIM 모델의 무결성을 검증하는데 사용하는 방식을 의미한다. 그러나 본 방식은 방대한 양의 부재별 고유 특성을 일일이 규정해야하기 때문에 한정된 부재 및 조건에서만 적용 가능하다는 한계점이 존재한다.

이러한 한계점을 극복하기 위해 BIM 부재별 기하정보를 학습 데이터로 활용하는 인공지능 기반 연구 사례가 다수 등장하고 있다. 이와 관련하여 Bloch and Sacks (2018)는 상기 언급한 두 접근법 비교를 위해 주거용 아파트 공간의 기하 및 위상 정보를 추출하여 시멘틱 강화 성능 검증을 실시하였다. 세부적으로 규칙 추론 접근법은 추출정보를 기반으로 규칙 세트를 구축하여 활용하였으며, 인공지능 접근법은 다중 클래스 신경망(Multi-class Neural Network)을 활용하였는데, 그 결과 인공지능 기반 접근법의 성능이 상대적으로 우수하게 나타남에 따라 해당 방법론의 유효성을 증명한 바 있다.

Koo et al. (2018)은 건축 BIM 부재의 기하특성(높이, 폭, 넓이, 면적, 체적, 회전반경 등)을 기반으로 지도학습 기법인 Support Vector Machine (SVM) 알고리즘을 적용하여 분류 정확도 90%의 부재 자동 분류 모델을 구축하였다. 이와 유사하게 Yu et al. (2021)은 BIM 부재별 기하특성을 기반으로 학습하되, Neural Structured Learning 알고리즘을 활용하여 부재 간 관계정보를 학습과정에 활용하는 분류 정확도 94%의 모델을 구축한 바 있으며, 이를 통해 기하특성이 유사한 일부 부재들까지 구분이 가능하였다.

상기 언급한 연구에서 활용한 인공지능 접근법은 부재 내 존재하는 속성정보를 추출한 후 추가 특성 변수로 활용하는 방식으로, 속성정보 추출이 불가능한 부재는 분석이 불가능하다는 한계점이 존재한다. 특히 기하형상이 유사하나 유형이 다른 부재 간의 세밀한 형상 차이까지 인식시키기에는 부족하였다. 더불어, 이들 기하 특성 정보를 일일이 수동으로 학습모델에 제시해줘야 하는 한계가 있다.

이에 대한 개선을 위해 최근 2D 이미지 혹은 3D 형상정보 자체를 학습 과정에 활용하는 연구가 수행된 바 있다. Lu et al. (2018)은 형강, 기둥, 벽, 문 및 창문으로 구성된 5가지 건축 BIM 부재 유형의 이미지를 수집하여 평균 정확도 97.5%의 분류 모델을 구축한 바 있다. 또한, Ying and Lee (2019)는 건물 외관과 내부 또는 다양한 조명 조건 및 용도에 포함된 벽, 문 및 승강기의 이미지를 수집한 후 Mask R-CNN 알고리즘을 활용하여 객체의 표면 경계 모양을 인식하고 분할하였으며, 결과 데이터를 기하학적 특성으로 추가하여 IFC로 추출하는 연구를 진행하였다.

Jung et al. (2019)은 벽 부재의 세부 유형(일반 벽, 창호가 있는 벽 및 문이 있는 벽) 분류를 위해 MVCNN과 PointNet 알고리

즘을 비교 검증하였으며, 그 결과 학습모델의 정확도가 95.0%, 56.3%로 MVCNN의 분류성능이 월등히 뛰어난 것으로 나타났다. 그러나 MVCNN 학습모델 분류결과, 이미지 상에서 벽 부재의 하위 유형 간 기하학적 차이가 뚜렷함에도 불구하고 오분류하는 사례가 존재하였다. 또한 해당 연구는 BIM 부재 유형 중 단 1가지만 하위분류하였기 때문에 MVCNN을 다수의 유형별 데이터 세트에 적용하였을 때에도 그 효용성이 있는지 검증이 필요하다. 이에 본 연구에서는 8가지 주요 건축 부재를 대상으로 MVCNN 알고리즘을 적용하되, 학습 과정 내 시멘틱 세그멘테이션 기반 이미지 선명도 개선을 통해 향상된 분류성능의 학습모델을 구축하고자 하였다.

2.2 Multi-View Convolutional Neural Network

합성곱 신경망(Covolutional Neural Network, 이하 CNN)은 2D 이미지 및 영상 데이터를 활용하여 분석 대상 객체의 특징을 추출하거나 클래스를 분류하는데 활용되는 대표적인 딥러닝 모델이다. 최근에는 컴퓨터 기술의 발전에 따라 3D 데이터를 직접 활용하는 것이 가능해지면서, 3D 모델 기반 CNN 알고리즘을 활용한 객체 인식 연구가 늘어나는 추세이다.

여기서 3D 모델은 복셀(voxel), 폴리곤 메쉬(polygon mesh), 포인트 클라우드(point cloud)와 같은 3차원 원 데이터(raw data)로 표현되며 객체의 위상정보, 부피 기반 픽셀 정보, 공간 위치 및 색상정보 등을 내포하고 있다. 그러나 이들 데이터는 딥러닝 알고리즘에 직접 활용하기에 크기가 매우 방대하여 학습에 적합한 크기로 줄이는 경량화 과정이 필수적으로 수반되어야 하는데(Maturana and Scherer, 2015; Qi et al., 2017; Wu et al., 2015), 이때 객체의 세부적 특징이 소실되어 3D 기반 CNN 모델의 성능이 하락하는 문제점이 발생한다.

MVCNN은 상기 문제를 해결하고자 고안된 기법으로 3D 모델을 다각도 이미지로 렌더링한 후 개별 이미지를 CNN에 적용하였으며, 3D 데이터를 직접 활용한 것보다 성능이 월등히 뛰어난 것으로 검증되었다(Su et al., 2015). 여기서 2D와 3D의 데이터 표현방식에 따라 성능 차이가 존재하는 것은 데이터의 효율성에서 기인한다. 즉, MVCNN에서 활용되는 다각도 이미지는 2D 형태이기 때문에 고해상도 데이터를 생성하더라도 별도의 경량화 과정이 필요하지 않으며, 이로 인해 객체를 표현하는 세부적 특징이 소실되지 않아 3D 원 데이터 활용 대비 효율성이 뛰어나다. 또한, 포인트 클라우드 및 메쉬는 순서 불변(order invariant)이 보장되지 않아 추가 조정 작업이 필요한 데 비해, 다각도 이미지는 정규화되어 있어 기존 2D 딥러닝 알고리즘 활용에 용이하다는 특징이 있다.

본 연구에서 활용하는 MVCNN의 네트워크 구조는 다음과 같다. 먼저 3D 객체에 대해 12방향 이미지로 렌더링한 후 개별

CNN(CNN_i)에 적용하여 각 이미지의 특징을 나타내는 소형 형상 설명자(compact shape descriptor)를 추출한다. 추출된 모든 형상 설명자는 view-pooling 계층에서 하나의 형상 설명자로 축약되고 이를 CNN(CNN_j)으로 전송하여 softmax 함수를 통해 최종 분류한다. MVCNN에서 활용된 CNN은 5개의 convolution 층(CNN_i)과 2개의 fully-connected 층 및 softmax 분류 층(CNN_j)으로 구성된 VGG-M 네트워크를 활용하였다.

그러나 MVCNN과 같은 2D 데이터 기반 딥러닝 모델은 데이터의 해상도 및 선명도 수준에 따라 성능이 매우 의존적이다. 즉, 모델의 분류 성능 향상을 위해 양질의 학습용 이미지 데이터를 수집하거나, 기존 수집된 이미지의 해상도 및 선명도를 개선하는 것이 필요하다. 이에 본 연구에서는 수집된 부재별 이미지를 대상으로 시멘틱 세그멘테이션을 적용하여 선명도를 개선함으로써 MVCNN 모델의 분류 성능을 향상시키고자 하였으며, 세부적인 내용을 아래 2.3절에 제시하였다.

2.3 CRF-RNN 기반 시멘틱 세그멘테이션

2.3.1 시멘틱 세그멘테이션 활용 동향

시멘틱 세그멘테이션(semantic segmentation)은 이미지 내 객체들을 의미론적 단위로 분할하는 것을 의미하며, 객체 분류(classification), 객체 인식(detection)과 더불어 컴퓨터 비전에서 가장 핵심적인 기술 분야이다. 즉 이미지 내 각 픽셀이 속하는 클래스를 예측하는 문제로, 단순히 이미지를 분류하는 것이 아닌 해당 이미지를 컴퓨터가 이해하고 이로부터 객체를 분할하기 때문에 이미지 및 영상 데이터를 활용하는 분야에서 다수 활용되고 있다.

특히 의료 영상 및 이미지 판독 분야에서 활발히 적용되고 있는데, 이는 CT 또는 MRI로 촬영한 의료 데이터에서 장기 및 병변 부위를 의사가 직접 분석하여 진단하는 것이 매우 어렵고 시간이 많이 소요되기 때문이다. 이에 시멘틱 세그멘테이션을 수행하여 병변 부위를 더 빠르게 분석하여 찾아내는데 주로 활용되고 있다(Bauer et al., 2013). 이외에도 시멘틱 세그멘테이션 기반 무릎 연골 분할(Prasoon et al., 2013), 뇌종양 세분화 작업을 통한 암 진단 및 치료 계획·결과 판단(Zhao et al., 2018) 등 다수의 사례가 있다.

또한 최근에는 단순히 객체를 분할하는 것에 그치지 않고, CNN 학습 과정에 시멘틱 세그멘테이션을 적용하여 학습모델의 성능을 향상시키는 연구도 수행된 바 있다. 일례로 Xu et al.

(2018)은 CT로 촬영된 복셀 데이터로부터 환자마다 크기·모양이 다른 방광의 경계를 분할하기 위해 우선 segmentation CNN을 적용하여 분할을 실시하고, 이후 CRF-RNN을 통한 후처리 작업을 추가적으로 진행하여 DSC (dice similarity coefficient)가 V-net(baseline) 대비 8.12% 정도 향상된 모델을 구축하였다.

상기 언급한 바와 같이 타 분야의 경우 시멘틱 세그멘테이션을 활용하는 연구가 활발히 진행되고 있으나 건설 분야는 더딘 실정이며, 기계학습 과정 내 시멘틱 세그멘테이션을 적용하여 성능을 향상시키고자 하는 연구는 거의 없는 것으로 조사되었다. 따라서, 본 연구는 MVCNN 학습 전 건축 부재 이미지를 대상으로 시멘틱 세그멘테이션을 적용하여 전체적인 학습모델의 분류 성능을 향상시키고자 한 점에서 기존 연구들과 차별성이 존재한다.

2.3.2 시멘틱 세그멘테이션 기술 동향

시멘틱 세그멘테이션은 크게 FCN 계열, R-CNN 계열 등으로 구분할 수 있다. 이 중 FCN 기반 시멘틱 세그멘테이션이 가장 범용적으로 활용되고 있으며, 2.3.1절에 제시한 사례들 또한 FCN 기반 접근법을 활용하였다.

기본 CNN의 구조는 입력 이미지 내 존재하는 특징(feature)을 추출한 후 max pooling, average pooling 등의 방법을 통해 유효한 정보만 선별하는 여러 겹의 convolution + pooling 층과 앞서 추출된 특징을 바탕으로 입력 이미지의 분류를 수행하는 fully-connected 층으로 구성되어 있다. 이때 fully-connected 층은 모든 노드를 1차원 배열의 형태로 연결하기 때문에 위치 및 공간 정보가 소실되어 시멘틱 세그멘테이션을 수행하기에는 어려움이 있었다. Long et al. (2015)은 이러한 문제점을 해결하기 위해 fully-connected 층을 1x1 convolution으로 대체하는 Fully Convolution Network (FCN) 구조를 제시하였다. 본 구조를 통해 위치 및 공간 정보 확보뿐만 아니라 입력 이미지의 크기에 구애받지 않을 수 있게 되었으며, 그 결과 이전 최고 성능을 달성한 R-CNN 대비 평균 IoU⁶⁾(Mean IoU)가 약 30% 정도 향상되었다. 그러나 CNN 내 개별 필터가 투영하는 receptive field의 크기가 충분하지 않아 다양한 scale에 대응이 어려우며 여러 겹의 convolution 층과 pooling 층을 거치면서 저하된 해상도를 skip layer를 통해 up-sampling하여 복원하였으나, 여전히 세밀한 분할이 이루어지지 않았다.

상기 언급한 FCN의 한계점 개선을 위해 Noh et al. (2015)은 입력 이미지의 특징을 추출하는 convolution network 뒤에 이와 대칭되는 deconvolution network를 배치하였다. 이를 통해 추출

⁶⁾IoU (Intersection over Union): 이미지 기반 객체 인식 및 분류모델의 정확도를 측정하는데 이용되는 평가지표로 이미지 데이터 내 색상에서의 실제 블록과 예측 블록 간의 합집합 영역 대비 교집합 영역의 비율로 산출함. Mean IoU는 색상별로 구한 IoU의 평균값을 의미함.

된 특징을 기반으로 형상을 생성하여 좀 더 세밀한 분할을 수행하였으며, 해당 구조를 FCN과 앙상블한 후 추가 보안을 위해 조건부 무작위장(Conditional Random Field, 이하 CRF)을 후속 적용하여 높은 성능을 보였다. Yu and Koltun (2015)은 각 픽셀이 위치하는 필터 사이에 zero padding을 추가하여 receptive field의 크기를 확장시키는 'dilated convolution'을 적용하였으며, 이를 통해 convolution + pooling 층 연산 시 이미지 특징 정보가 손실되는 것을 최소화하였다. 또한, 여러 개의 receptive field에 dilated convolution과 동일한 개념인 atrous convolution을 적용하여 하나로 취합해주는 ASPP (Atrous Spatial Pyramid Pooling) 기법을 활용한 DeepLab v2 모델(Chen et al., 2017)이 등장하였다. DeepLab 연구진은 좀 더 정밀한 분할을 위해 Fully connected CRF를 후보정 작업에 사용하였는데, 그 결과 평균적으로 약 3.7%의 정확도가 향상되었다. 그러나 상급 연구들에서는 CRF가 FCN의 후보정 작업으로만 사용되어 CRF의 추론 성능을 충분히 활용하지 못하는 한계점이 존재하였다. 이에 Zheng et al. (2015)은 Conditional random fields as recurrent neural networks (CRF-RNN)를 개발하여 FCN과 CRF의 장점을 하나의 통일된 프레임워크로 결합하였다.

2.3.3 Conditional Random Fields as Recurrent Neural Networks

앞서 2.3.2절에 언급한 CRF는 이미지 내 연속된 픽셀을 라벨링하고 분할하여 패턴 인식 및 구조적 예측에 활용되는 무방향성(undirected) 확률 그래프 모델이다(Lafferty et al., 2001).

Figure 1-(a)에 제시된 바와 같이, 기본 CRF 구조는 인접한 노드(픽셀 또는 이미지 패치)를 엣지(edge)로 연결한 격자 형태로 구성되어 있으며, 이로 인해 이미지 분할 시 경계가 매끄러워지는 문제점(smoothing problem)이 존재한다. 이를 극복하기 위해 Krähenbühl and Koltun (2011)에 의해 고안된 Fully connected CRF는 기본 CRF와 달리 이미지의 모든 픽셀을 쌍(pair)으로 연결함으로써 매우 정교한 분할과 라벨링을 가능하게 한다(Figure 1-(b) 참고).

Eq. (1)은 이미지가 I , 이미지 내 픽셀의 수가 N , 사전 정의된 라벨이 $\mathcal{L} = \{l_1, l_2, \dots, l_L\}$ 각 픽셀에 부여될 라벨의 랜덤 변수 벡터가 $X = \{X_1, X_2, \dots, X_N\}$ 일 때, 무작위장 (I, X) 를 근사 추론할 수 있는 Gibbs 분포를 나타낸 것이며, $E(x)$ 는 $x \in \mathcal{L}^N$ 으로 구성되어 있을 때 전위함수(energy function)를, $Z(I)$ 는 분할함수(partition function)를 의미한다. 전위함수 $E(x)$ 는 아래 Eq. (2)와 같다.

$$P(X = x) = \frac{1}{Z(I)} \exp(-E(x)), \quad (1)$$

$$E(x) = \sum_i \psi_u(x_i) + \sum_{i < j} \psi_p(x_i, x_j), \quad (2)$$

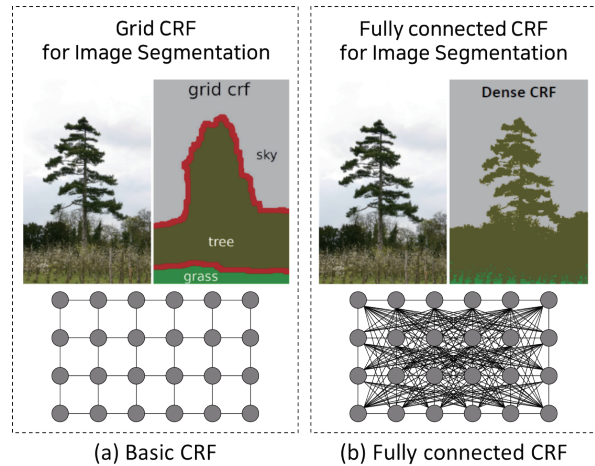


Figure 1. Structural comparison between basic CRF and fully connected CRF (Krähenbühl and Koltun, 2011)

본 전위함수는 픽셀 i 가 라벨 x_i 에 부여되지 않을 때 측정되는 단항 전위(unary energy components) $\psi_u(x_i)$ 의 합과 픽셀 i, j 의 라벨이 동시에 서로 다른 x_i, x_j 에 부여될 때 측정되는 쌍별항 전위(pairwise energy components) $\psi_p(x_i, x_j)$ 의 합으로 구성되어 있다. 단항 전위는 CNN 연산을 통해 얻을 수 있으며, 쌍별항 전위는 두 개의 가중치 가우시안 커널(Gaussian kernel)로 구성되어 있다.

본 전위함수 $E(x)$ 를 최소화함으로써 확률적으로 이미지 I 에 가장 적절한 라벨 x 를 부여받아 정교한 이미지 분할을 수행한다. 그러나 실제 Fully connected CRF에 대한 활용성은 저조한 실정인데, 이는 저해상도 이미지에서도 수만 개의 노드와 수십억 개의 엣지를 가지고 있어 이미지 분할을 위한 연산과정에 매우 긴 시간이 소요되기 때문이다.

이에 Krähenbühl and Koltun (2011)은 Fully connected CRF에 평균장 근사법(Mean Field Approximation)을 적용하여 복잡한 구조를 단순화함으로써 라벨 추론에 소요되는 시간을 0.2초 수준으로 단축시킬 수 있는 방법을 개발하였다. 이는 CRF의 분포를 나타내는 $P(X)$ 를 독립 주변 분포(independent marginal distributions)인 $Q(X)$ 로 치환한 것인데, 이때 $Q(X) = \prod_i Q_i(X_i)$ 로 표현된다.

Zheng et al. (2015)은 CRF를 통해 출력된 가중치를 FCN 학습의 매개변수로 활용하기 위해 두 모델을 하나의 프레임워크, 즉 반복 신경망(Recurrent Neural Network, 이하 RNN)으로 재구성하는 방안을 제시하였다. 본 과정을 통해 재구성된 RNN 신경망이 CRF-RNN이며, T 가 평균장 반복(mean-field iteration)의 횟수를 나타낼 때 CRF-RNN의 구조는 아래 Eq. (3), (4), (5)와 같으며, Figure 2에 형상화하였다.

$$Q_{in}(t) = \begin{cases} \text{softmax}(U), & t=0 \\ Q_{out}(t-1), & 0 < t \leq T, \end{cases} \quad (3)$$

$$Q_{out}(t) = f_{\theta}(U, Q_{in}, I), \quad 0 \leq t \leq T, \quad (4)$$

$$Q_{final}(t) = \begin{cases} 0, & 0 \leq t < T \\ Q_{out}(t), & t = T. \end{cases} \quad (5)$$

한 번의 평균장 반복에 대하여 Q_{in} 은 입력, Q_{out} 은 출력을 의미하며, Q_{final} 은 CRF-RNN의 최종 예측 결과를 의미한다. $\text{softmax}(U)$ 는 FCN 연산에 대한 출력 값을 나타내고, U 는 단항 전위 값을 의미한다. 또한 함수 $f_{\theta}(U, Q_{in}, I)$ 는 Q_{in} 에 의해 추론된 가중치를 의미하며, 이 때 I 는 이미지, θ 는 위에 설명한 CRF의 매개변수이다. 이처럼 FCN과 CRF를 하나의 심층 네트워크로 통합하여 역전파 알고리즘(back-propagation algorithm)을 구현함으로써 종단(end-to-end) 간의 훈련이 가능하게 된다(Zheng et al., 2015). 이와 같은 방식으로 작동하는 CRF-RNN 알고리즘을 활용하여 본 연구에서는 다각도 이미지로 표현된 개별 BIM 부재 데이터를 대상으로 시멘틱 세그멘테이션을 수행하였다.




Figure 2. CRF-RNN architecture (Zheng et al., 2015)

3. 연구 방법

본 연구는 시멘틱 세그멘테이션 기반 이미지 학습데이터의 선명도 개선을 통해 딥러닝 알고리즘의 건축 BIM 부재 분류 성능을 향상시키고자 하였다. 시멘틱 세그멘테이션을 위한 알고리즘은 CRF-RNN, 이미지 딥러닝을 위한 알고리즘은 MVCNN을 활용하였으며, 학습데이터의 선명도 개선 시 성능 향상 정도를 정량적으로 평가하기 위해 Figure 3에 제시된 2단계 절차로 연구를 수행하였다.

세부적으로는 수집된 개별 건축 BIM 부재를 12방향 이미지 데

이터로 변환하고, 해당 데이터를 기반으로 MVCNN 알고리즘을 적용하여 1차 학습모델(baseline)을 구축하였다. 이후 동일한 데이터 세트에 CRF-RNN 알고리즘 기반 시멘틱 세그멘테이션을 적용하여 선명도를 개선시킨 후 2차 MVCNN 학습모델을 구축하였다. 두 학습모델의 분류성능 및 부재별 성능 향상 정도 평가를 위해 정확도, 정밀도, 재현율, F_1 -score 4가지 성능평가지표를 활용하였으며, 이를 기반으로 상세히 비교·분석하였다.

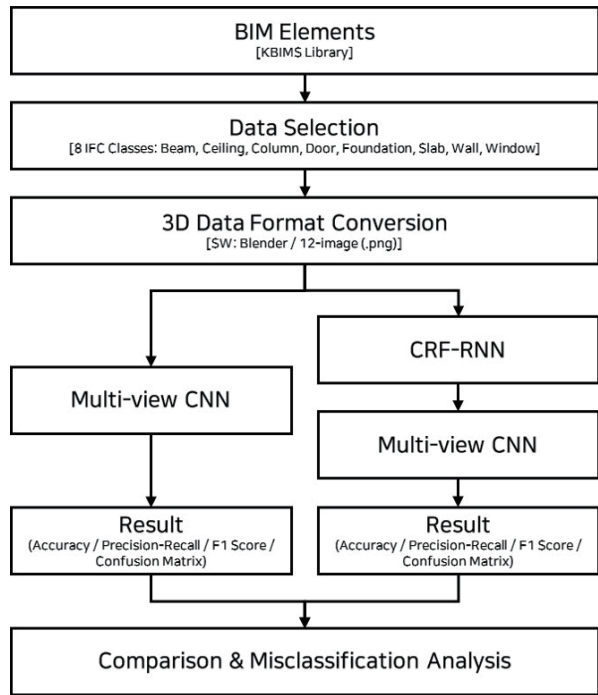


Figure 3. Research flow chart

3.1 분석 데이터 개요 및 데이터 전처리







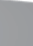

본 연구는 건축 BIM 부재 분류 모델 구축을 위한 학습데이터로 개방형 BIM 연구단에서 제공하는 표준 라이브러리인 KBIMS Library⁷⁾를 활용하였다. 본 연구에서는 1.02 버전을 활용하였으며, 해당 라이브러리 내에는 건축물 설계 과정에 활용도가 높은 18가지 유형으로 구성된 총 1,207개 건축 부재 IFC 모델이 수록되어 있다.

해당 데이터 중 (1) 본 연구의 목적과 부합하지 않는 5가지 부재 유형(조경, 운송설비, 위생설비, 가구 및 장비, 기타 환경(토목)), (2) 학습하기에 개수가 부족한 3가지 부재(지붕, 난간 및 램프), (3) 하나의 객체로 추출이 불가능한 2가지 복합부재(커튼월, 계단⁸⁾)는 분석에 적합하지 않아 연구 범위에서 제외하였다. 이를 통해 최종적으로 분석에 활용된 데이터는 기초(IcfFoundation),

⁷⁾ Korean Building Information Modeling Standards (KBIMS), <http://www.kbims.or.kr/>

⁸⁾ 커튼월은 멤버와 플레이트, 계단은 계단층, 난간, 슬래브 등으로 이루어져있기 때문에 하나의 객체로 추출이 불가능.













Table 1. Status of collected BIM elements

Type	lfcBeam	lfcCeiling	lfcColumn
Rendering			
No. of element	134	91	103
Type	lfcDoor	lfcFoundation	lfcSlab
Rendering			
No. of element	73	21	222
Type	lfcWall	lfcWindow	
Rendering			
No. of element	186	59	
Total No. of elements			889

바닥(*lfcSlab*), 천장(*lfcCeiling*), 형강(*lfcBeam*), 기둥(*lfcColumn*), 문(*lfcDoor*), 벽(*lfcWall*), 창(*lfcWindow*)의 8가지 유형으로 구성된 총 889개의 건축 부재이다(Table 1).

이후 해당 데이터를 활용한 MVCNN 학습을 위해 개별 부재를 12방향의 이미지로 변환하였다. 12방향 이미지는 3D 컴퓨터 그래픽 오픈소스 소프트웨어인 Blender를 활용하여 촬영하였으며, 이는 36° 간격으로 촬영된 10장의 부재 측면 이미지와 밀면, 윗면을 촬영한 2장의 이미지로 구성되어 있다(Table 2).

Table 2. 12 directions images for MVCNN training

Degree	bottom	0°	36°	72°
Image				
Degree	108°	144°	180°	216°
Image				
Degree	252°	288°	324°	top
Image				

3.2 MVCNN 모델 학습

구축된 부재별 12방향 이미지 데이터를 활용한 MVCNN 모델 구축 과정을 Figure 4에 제시하였다. 개별 부재의 12방향 이미지가 각각 순환 신경망(CNN_1)을 통과하면 이미지 내 부재의 특징이 추출된다. 이후 추출된 각 이미지의 특징이 view-pooling 층에서 통합되고, 이는 다시 2차 순환신경망(CNN_2)을 통과한다. 여기서 CNN_2 는 앞서 2.2절에 언급한 바와 같이 softmax 층으로 구성되어 있으며, 이를 통해 개별 부재에 대한 분류 결과를 출력한다. MVCNN 구현은 python 기반 Tensorflow를 활용하였으며, 이를 통해 8가지 건축 부재에 대한 1차 학습모델(baseline)을 구축하였다.




Figure 4. Deep network architecture for MVCNN

3.3 CRF-RNN + MVCNN 모델 학습

Figure 6에는 시멘틱 세그멘테이션을 적용하여 선명도가 개선된 이미지를 활용한 MVCNN 기반 2차 학습모델을 구축하는 프레임워크를 나타내었다. 즉, CRF-RNN 알고리즘을 활용하여 이미지 데이터 내 객체 영역을 명확히 구분하고, 이를 MVCNN 알고리즘 학습에 활용하는 것이다. 이에 본 연구에서는 앞서 구축된 부재별 12방향의 이미지 내 부재가 존재하는 영역을 명확히 구분하여 모델이 부재의 형상에만 집중하여 학습할 수 있도록 CRF-RNN 알고리즘을 적용하였으며, 그 결과에 대한 예시를 아래 Figure 5에 제시하였다.




Figure 5. *lfcWindow* semantic segmentation using CRF-RNN

이후 부재의 영역이 분할된 이미지 데이터 세트를 활용하여 MVCNN 모델을 학습하였다. 본 과정에서 CRF-RNN 적용은 python 기반 Keras를 활용하였으며, 일련의 과정을 통해 2차 학습모델을 구축하였다.




Figure 6. Deep network architecture for CRF-RNN + MVCNN

3.4 학습모델 구축 및 성능 평가

상기 제시한 방법(MVCNN, CRF-RNN + MVCNN)을 통해 2 가지 학습모델을 구축하였다. 두 학습모델 모두 동일한 이미지 데이터 세트를 기반으로 구축되었으며, Table 3에 제시한 바와 같이 데이터 세트 내 개별 부재를 7:3의 비율로 분할하여 훈련(training) 및 검증(test)을 실시하였다. 이를 통해 621개의 부재 데이터가 모델 학습에 활용되었으며, 학습된 모델을 268개의 부재 데이터를 대상으로 검증하였다.

Table 3. Elements divided into training and test set (7:3)

Type	Training set	Test set	Total
IfcBeam	94	40	134
IfcCeiling	64	27	91
IfcColumn	72	31	103
IfcDoor	51	22	73
IfcFoundation	15	6	21
IfcSlab	155	67	222
IfcWall	129	57	186
IfcWindow	41	18	59
Total	621	268	889

학습결과 검증을 위한 성능평가지표로 정확도(accuracy, 이하 ACC), 정밀도(precision), 재현율(recall) 및 F_1 -score를 사용하였다⁹⁾.

여기서 ACC는 학습모델의 전반적인 성능을 제시하는 지표로 전체 검증 데이터 수 대비 학습모델이 정확히 예측한 데이터 수의 비율로 산출된다. 정밀도는 학습모델이 참값으로 분류한 데이터 중 실제 참값의 비율을 의미하며, 재현율은 실제 참값 중 학습모델이 참이라고 예측한 비율이다. F_1 -score는 정밀도와 재현율의 조화평균으로 학습데이터의 분포가 불균형할 경우 모델의 성능을 정확히 평가할 수 있는 지표이다. 본 연구는 위 4가지 성능평가지표를 활용하여 MVCNN 모델 대비 CRF-RNN + MVCNN 모델의 분류성능 향상 정도를 정량적으로 분석하였다.

추가로 부재별 분류성능을 측정하기 위해 micro-average precision (mAP)을 제시하였다. mAP은 임계값 변화에 따라 정밀도와 재현율의 변화를 나타내는 precision-recall curve의 아래 면적을 통해 산출된다. 마지막으로 개별 학습모델의 분류결과를 나타내는 confusion matrix를 제시하여 모델별 오분류 부재 파악 및 어떤 부재를 중심으로 성능이 향상되었는지를 확인하였으며, 세부적 분석 결과를 4장에 제시하였다.

4. 연구 결과 및 비교

4.1 MVCNN 학습모델 검증 결과

8가지 유형의 건축 부재를 대상으로 구축한 MVCNN 학습 모델 검증결과, ACC는 0.86, F_1 -score는 0.84로 도출되었다. Table 4와 Figure 7에 제시한 MVCNN 학습모델의 부재별 분류성능을 보면, 전반적인 성능은 양호하였으나 천장(*IfcCeiling*), 문(*IfcDoor*), 창(*IfcWindow*) 부재의 경우 타 부재에 비해 상대적으로 성능이 낮은 것으로 나타났다. 특히 천장은 ACC가 0.19, F_1 -score가 0.29로 매우 저조한 분류성능을 보였는데, Table 5에 제시한 confusion matrix를 보면 대부분의 천장 부재가 바닥(*IfcSlab*)으로 오분류된 것을 확인할 수 있다. 이와 유사하게 일부 문 부재도 바닥으로 오분류 되었으며, 창의 경우 일부 부재가 창과 형상이 유사한 문으로 오분류된 것을 확인할 수 있었다. Figure 7의 precision-recall curve에서 도출된 mAP의 경우 앞선 평가지표와 유사하게 전반적인 분류성능이 양호하였으며, 천

⁹⁾ 본 연구에 활용된 4가지 성능평가지표는 아래와 같은 방법으로 산출됨.

$$ACC = (True\ Positive + True\ Negative) / (True\ Positive + False\ Positive + True\ Negative + False\ Negative)$$

$$Precision = True\ Positive / (True\ Positive + False\ Positive)$$

$$Recall = True\ Positive / (True\ Positive + False\ Negative)$$

$$F_1\text{-score} = 2 * Precision * Recall / (Precision + Recall) = True\ Positive / (True\ Positive + 1/2(False\ Positive + False\ Negative))$$

장(0.72), 문(0.82), 창(0.89) 부재는 상대적으로 낮은 성능을 보였다.

Table 4. Validation results for MVCNN

Type	Accuracy	Precision	Recall	F_1 -score	mAP
<i>lfcBeam</i>	1.00	1.00	1.00	1.00	1.00
<i>lfcCeiling</i>	0.19	0.63	0.19	0.29	0.72
<i>lfcColumn</i>	0.94	1.00	0.94	0.97	1.00
<i>lfcDoor</i>	0.68	0.71	0.68	0.70	0.82
<i>lfcFoundation</i>	1.00	1.00	1.00	1.00	1.00
<i>lfcSlab</i>	0.96	0.70	0.96	0.81	0.97
<i>lfcWall</i>	1.00	1.00	1.00	1.00	1.00
<i>lfcWindow</i>	0.78	0.93	0.78	0.85	0.89
Average	0.86	0.87	0.82	0.84	0.93

Table 5. MVCNN classification results (confusion matrix)

Actual \ Predicted									
	Beam	Ceiling	Column	Door	Foundation	Slab	Wall	Window	Total
Beam	40	0	0	0	0	0	0	0	40
Ceiling	0	5	0	0	0	22	0	0	27
Column	0	0	29	2	0	0	0	0	31
Door	0	0	0	15	0	6	0	1	22
Foundation	0	0	0	0	6	0	0	0	6
Slab	0	3	0	0	0	64	0	0	67
Wall	0	0	0	0	0	0	57	0	57
Window	0	0	0	4	0	0	0	14	18
Total	40	8	29	21	6	92	57	15	268

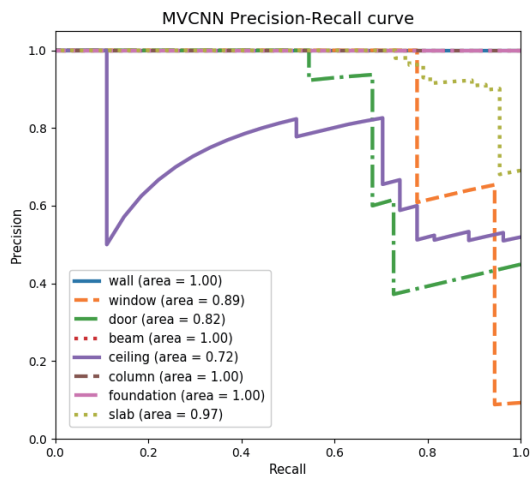


Figure 7. Precision-recall curve for MVCNN

4.2 CRF-RNN + MVCNN 학습모델 검증 결과

CRF-RNN + MVCNN 학습모델의 ACC는 0.92, F_1 -score는 0.91로 도출되었으며, Table 6에 부재별 분류성능 및 Figure

Table 6. Validation results for CRF-RNN + MVCNN

Type	Accuracy	Precision	Recall	F_1 -score	mAP
<i>lfcBeam</i>	1.00	1.00	1.00	1.00	1.00
<i>lfcCeiling</i>	0.37	0.77	0.37	0.50	0.82
<i>lfcColumn</i>	0.97	1.00	0.97	0.98	0.99
<i>lfcDoor</i>	1.00	0.88	1.00	0.94	0.94
<i>lfcFoundation</i>	1.00	1.00	1.00	1.00	1.00
<i>lfcSlab</i>	0.96	0.80	0.96	0.87	0.98
<i>lfcWall</i>	1.00	1.00	1.00	1.00	1.00
<i>lfcWindow</i>	0.94	1.00	0.94	0.97	0.96
Average	0.92	0.93	0.89	0.91	0.96

Table 7. CRF-RNN + MVCNN classification results (confusion matrix)

Actual \ Predicted									
	Beam	Ceiling	Column	Door	Foundation	Slab	Wall	Window	Total
Beam	40	0	0	0	0	0	0	0	40
Ceiling	0	10	0	1	0	16	0	0	27
Column	0	0	30	1	0	0	0	0	31
Door	0	0	0	22	0	0	0	0	22
Foundation	0	0	0	0	6	0	0	0	6
Slab	0	3	0	0	0	64	0	0	67
Wall	0	0	0	0	0	0	57	0	57
Window	0	0	0	1	0	0	0	17	18
Total	40	13	30	25	6	80	57	17	268




Figure 8. Precision-recall curve for CRF-RNN + MVCNN

8에 precision-recall curve를 제시하였다. 시멘틱 세그멘테이션 기반 이미지 선명도를 개선한 CRF-RNN + MVCNN의 각 부재별 분류성능은 앞선 MVCNN보다 양호한 성능을 보였으며, 특히 문(*lfcDoor*) 부재의 ACC가 1.00, 창(*lfcWindow*) 부재가 0.94로 매우 높은 성능을 보였다. 반면 천장(*lfcCeiling*) 부재의 ACC 및 F_1 -score가 0.5 이하의 낮은 분류성능을 보인 것으로 나타났

는데, 이는 앞선 MVCNN의 분류결과와 마찬가지로 일부 부재가 바닥(*IfcSlab*)으로 오분류된 것으로 확인되었다. precision-recall curve에서 도출된 mAP의 경우 대부분의 부재에 대해서는 높은 성능을 보였으나, 앞서 낮은 ACC를 보인 천장의 mAP가 0.82로 타 부재에 비해 낮은 분류성능을 보였다.

4.3 성능 비교 및 오분류 분석

앞서 제시한 MVCNN, CRF-RNN + MVCNN 모델의 ACC는 각각 0.86, 0.92, F_1 -score는 0.84, 0.91로 나타나 MVCNN 학습 과정 내 이미지 선명도 개선 시 ACC는 0.06, F_1 -score는 0.07의 성능이 향상된 것으로 확인되었다.

부재별 성능 향상 정도를 제시한 Table 8을 보면 천장(*IfcCeiling*), 기둥(*IfcColumn*), 문(*IfcDoor*), 창문(*IfcWindow*) 등 4개 부재의 분류성능이 향상된 것을 볼 수 있다. 특히, 문 부재의 ACC가 0.32 (=1.00-0.68), F_1 -score가 0.24 (=0.94-0.70)만큼 향상되어 분류성능의 폭이 가장 큰 것으로 확인되었다. 그에 반해 상기 4개의 부재 대비 형상이 단조로운 바닥(*IfcSlab*) 부재의 경우 분류성능 향상 정도가 미비한 것으로 나타났다.

이로부터 MVCNN 학습 과정 내 시멘틱 세그멘테이션 적용은 부재의 형상이 복잡하고 기하학적 특성이 명확할수록 성능 향상 효과가 높으며, 반대로 형상이 단조로운 경우 그 효과가 낮은 것을 알 수 있다. 즉, 문과 창 부재처럼 전반 형상은 유사하나 세부 디테일이 다른 부재의 분류 정확성 향상에 가장 유효한 것을 알 수 있다.

또한 Table 5와 7에 제시한 MVCNN과 CRF-RNN + MVCNN 모델의 confusion matrix를 보면 두 모델 모두 천장(*IfcCeiling*) 부재를 바닥(*IfcSlab*)으로 오분류한 것을 확인할 수 있다. 이는 실제 현장에 적용하기 위한 BIM 모델 내 부재 형상과 달리 KBIMS 라이브러리 데이터는 일반화된 부재 형상을 띄고 있어 천장과 바닥의 기하학적 형상이 매우 유사한 것에 기인한 것으로 판단된다. 즉, 이 경우 세부 형상의 디테일 차이가 없어 시멘틱 세그멘테이션으로 유의한 효과를 보지 못한 것으로 파악된다.

Table 8. Delta values between MVCNN and CRF-RNN + MVCNN

Type	Accuracy	Precision	Recall	F_1 -score	mAP
<i>IfcBeam</i>	0.00	0.00	0.00	0.00	0.00
<i>IfcCeiling</i>	0.19	0.14	0.19	0.21	0.10
<i>IfcColumn</i>	0.03	0.00	0.03	0.02	-0.01
<i>IfcDoor</i>	0.32	0.17	0.32	0.24	0.12
<i>IfcFoundation</i>	0.00	0.00	0.00	0.00	0.00
<i>IfcSlab</i>	0.00	0.10	0.00	0.07	0.01
<i>IfcWall</i>	0.00	0.00	0.00	0.00	0.00
<i>IfcWindow</i>	0.17	0.07	0.17	0.12	0.07
Average	0.06	0.06	0.07	0.07	0.04

5. 결론

최근 건설업의 고질적인 낮은 생산성 문제 해결을 위해 BIM 도입이 전면적으로 추진되고 있다. 이에 따라 건설 프로젝트 내 의사소통 도구 또는 검토를 위한 기초 데이터로 활용되는 BIM 모델의 품질 신뢰도 중요성 문제가 대두되고 있으며, 이를 위해 시멘틱 무결성 검증과 관련된 다수의 연구가 수행되고 있다.

부재별 12방향 이미지를 학습에 활용하는 MVCNN 기반 자동 부재분류 모델은 그 결과, 몇몇 부재들의 기하학적 차이가 분명함에도 올바르게 분류하지 못하는 문제점이 존재하였다. 이는 이미지 내 학습하고자 하는 영역 범위가 명확히 구분되지 않아 기하학적 특성이 학습 과정에 제대로 반영되지 못한 것에 기인한 것으로 파악되었다. 이에 본 연구에서는 CRF-RNN 기반 시멘틱 세그멘테이션 기법을 적용하여 각 이미지 내 부재 영역 구분 선명도를 높인 후 MVCNN 알고리즘에 적용하여 분류성능을 향상시키고자 하였다.

총 8가지 부재를 대상으로 889개의 학습 데이터 구축 후 시멘틱 세그멘테이션이 적용된 MVCNN을 훈련한 결과, 전반적으로 ACC 0.06, F_1 -score 0.07의 성능이 향상된 것을 확인할 수 있었으며, 이를 통해 MVCNN을 단독으로 학습시키는 것보다 사전에 이미지의 품질을 높일 경우, 학습 결과에 도움이 되는 것을 알 수 있었다. 세부적으로는 천장(*IfcCeiling*), 기둥(*IfcColumn*), 문(*IfcDoor*), 창문(*IfcWindow*) 부재를 중심으로 분류 정확도가 가장 높게 향상되었으며, 이에 반해 상대적으로 형상이 단조로운 바닥(*IfcSlab*) 부재의 경우 분류성능 향상 정도가 미비하였다. 이로부터 MVCNN 학습 과정 내 시멘틱 세그멘테이션 적용은 부재 간 전반 형상은 유사하나 기하 디테일에서 차이를 보이는 부재들을 구분하는데 가장 효과적인 것으로 파악되었으며, 천장과 바닥 부재처럼 기하 디테일의 차이가 없는 부재에는 그 효과가 상대적으로 낮은 것으로 파악되었다.

본 연구는 이처럼 시멘틱 세그멘테이션과 딥러닝 모델을 병합 활용하여 BIM 건축 부재의 분류 정확도를 높이는 방안을 제시한 데 그 의미가 있다. 그러나 전반 건축 부재 중 일부 부재에 국한되었으며, 대상 부재에 대해서도 부분적으로 분류 오류가 발생하였다. 따라서 향후 연구에서는 점차적으로 건축 부재 대상을 넓혀 나갈 것이며, 천장과 바닥처럼 이미지 품질 향상으로 해결이 안 된 부재에 대해서는 추가 특성 정보를 확장하여 실험할 계획이다. 구체적으로 부재 간의 관계 정보(예: 인접 관계 등)를 기계 학습 기반으로 학습시키고 이를 본 연구의 딥러닝 모델과 앙상블(ensemble) 시켜 향상된 분류성능을 향후 달성할 계획이다.

감사의 글

본 연구는 국토교통부 도시건축 연구개발사업의 연구비 지원 (21AUDP-B127891-05)에 의해 수행되었습니다.

References

- Bauer, S., Wiest, R., Nolte, L. P., Reyes, M. (2013). A survey of MRI-based medical image analysis for brain tumor studies, *Physics in Medicine & Biology*, 58(13), pp. 97–129.
- Belsky, M., Sacks, R., Brilakis, I. (2016). Semantic enrichment for building information modeling, *Computer-Aided Civil and Infrastructure Engineering*, 31(4), pp. 261–274.
- 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.
- buildingSMART Korea, KBIMS Library v1.02, <http://step1.kbims.or.kr/sub/Default.aspx> (Jan, 2019).
- Chen, L. C., Papandreou, G., Kokkinos, I., Murphy, K., Yuille, A. L. (2017). Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs, *IEEE transactions on pattern analysis and machine intelligence*, 40(4), pp. 834–848.
- Cursi, S., Simeone, D., Coraglia, U. M. (2017). An ontology-based platform for BIM semantic enrichment, *Educational and research in Computer Aided Architectural Design in Europe* 35, 2, pp. 649–656.
- Jung, R. K., Koo, B. S., Yu, Y. S. (2019). Using Deep Learning for automated classification of wall subtypes for semantic integrity checking of Building Information Models, *Korean Institute of Building Information Modeling*, 9(4), pp. 31–40.
- Kim, I. H., Kim, Y. H., Choi, J. S. (2014). Building Code Typology and Application for Open BIM based Code Checking, *Korean Journal of Computational Design and Engineering*, 19(3), pp. 224–235.
- Koo, B. S., Yu, Y. S., Jung, R. K. (2018). Machine learning based approach to building element classification for semantic integrity checking of building information models, *Korean Journal of Computational Design and Engineering*, 23(4), pp. 373–383.
- Krähenbühl, P., Koltun, V. (2011). Efficient inference in fully connected crfs with gaussian edge potentials, *Advances in neural information processing systems*, 24(13), pp. 109–117.
- Lafferty, D., McCallum, A., Pereira, F. C. N. (2001). Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data, *Proceedings of the Eighteenth International Conference on Machine Learning*, 1(8), pp. 282–289.
- Long, J., Shelhamer, E., Darrell, T. (2015). Fully convolutional networks for semantic segmentation, *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 3431–3440.
- Lu, Q., Lee, S., Chen, L. (2018). Image-driven fuzzy-based system to construct as-is IFC BIM objects, *Automation in Construction*, 92, pp. 68–87.
- Ma, L., Sacks, R., Kattell, U. (2017). Building model object classification for semantic enrichment using geometric features and pairwise spatial relations, *Proceedings of the Joint Conference on Computing in Construction*, 1, pp. 373–380.
- Maturana, D., Scherer, S. (2015). Voxnet: A 3d convolutional neural network for real-time object recognition, *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 922–928.
- Ministry of Land, Infrastructure and Transport. (2020). Basic guidelines for BIM in the construction industry.
- Noh, H., Hong, S., Han, B. (2015). Learning deconvolution network for semantic segmentation, *Proceedings of the IEEE international conference on computer vision*, pp. 1520–1528.
- Prasoon, A., Petersen, K., Igel, C., Lauze, F., Dam, E., Nielsen, M. (2013). Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network, *International conference on medical image computing and computer-assisted intervention*, 2(31), pp. 246–253.
- Qi, C. R., Su, H., Mo, K., 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*, pp. 652–660.
- Su, H., Maji, S., Kalogerakis, E., Learned-Miller, E. (2015). Multi-view convolutional neural networks for 3d shape recognition, *Proceedings of the IEEE international conference on computer vision*, pp. 945–953.

- Wu, Z., Song, S., Khosla, A., Yu, F., Zhang, L., Tang, X., Xiao, J. (2015). 3d shapenets: A deep representation for volumetric shapes, Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1912–1920.
- Xu, X., Zhou, F., Liu, B. (2018). Automatic bladder segmentation from CT images using deep CNN and 3D fully connected CRF–RNN, International journal of computer assisted radiology and surgery, 13(7), pp. 967–975.
- Ying, H. Q., Lee, S. (2019). A Mask R–CNN Based Approach to Automatically Construct As–is IFC BIM Objects from Digital Images, Proceedings of the International Symposium on Automation and Robotics in Construction, 36, pp. 764–771.
- Yu, F., Koltun, V. (2015). Multi–scale context aggregation by dilated convolutions, arXiv preprint arXiv:1511.07122.
- Yu, Y. S., Lee, K. E., Koo, B. S., Lee, K. H. (2021). Modeling Element Relations as Structured Graphs Via Neural Structured Learning to Improve BIM Element Classification, Journal of Civil and Environmental Engineering Research, 41(3), pp. 227–288.
- Zhao, X., Wu, Y., Song, G., Li, Z., Zhang, Y., Fan, Y. (2018). A deep learning model integrating FCNNs and CRFs for brain tumor segmentation, Medical image analysis, 43(8), pp. 98–111.
- Zheng, S., Jayasumana, S., Romera–Paredes, B., Vineet, V., Su, Z., Du, D., Huang, C., Torr, P. H. S. (2015). Conditional random fields as recurrent neural networks, Proceedings of the IEEE International Conference on Computer Vision, pp. 1529–1537.