

## 3차원 기하 딥러닝 기술의 BIM 공간 정합성 검토 적용 사례



**구본상** 서울과학기술대학교 건설시스템공학과 교수, bonsang@seoultech.ac.kr

### 1. 서론

4차 산업 혁명 기술의 핵심 중 하나인 인공지능 기술의 도입이 건설 산업 내에서도 점차 확산되는 추세이다. BIM 분야에서 인공지능 기술과의 융합을 통해 새로운 기술 창출을 도모하고자 하는 연구 및 실무 사례가 다수 증가하고 있다. 특히 인공지능을 활용하여 BIM 모델링 및 정합성 검토를 자동화하여 BIM 구축에 필요로 하는 수작업을 줄이려는 노력이 전개되고 있다.

그러나 BIM은 3차원 기하 형상을 기본 정보 단위로 하기 때문에 일반적으로 접하는 2차원 이미지나 텍스트와는 데이터 성격이 다르다. 따라서 BIM을 분석하기 위해서는 3차원 정보를 학습할 수 있는 인공지능 모델이 필요하며 이를 기하 딥러닝(Geometric deep learning) 기술이라 한다. 기하 딥러닝 기술은 비유클리드(non-Euclidean) 공간에서 다루어지는 데이터를 대상으로 구축된 기술로서 3차원 형상 및 그래프

구조의 데이터 학습을 위해 특화된 인공지능 분야이다. 본 고에서는 기하 딥러닝 기술에 대한 소개와 본 기술을 BIM 모델의 공간 정합성 검토에 적용 및 검증한 연구 사례를 제시하였다.

### 2. 기하 딥러닝 기술

기존의 딥러닝은 유클리드 공간(Euclidean space)에 해당하는 데이터를 위주로 개발되었다. 즉, 이미지나 동영상 및 텍스트처럼 순서, 시리즈 및 2차원 그리드 등과 같이 구조가 정해진 데이터를 대상으로 하였다. 이렇듯 구조가 정형화된 상태에서 이에 특화된 딥러닝 모델들이 비약적으로 발전하였는데 이미지 및 동영상에는 CNN, 텍스트나 음성에서는 RNN 등이 대표적 학습 모델들이다.

그러나 비유클리드 공간에 속하는 3차원 객체 또는 그래프 형태의 데이터는 기존의 딥러닝 방식으로는 학습이 불가능

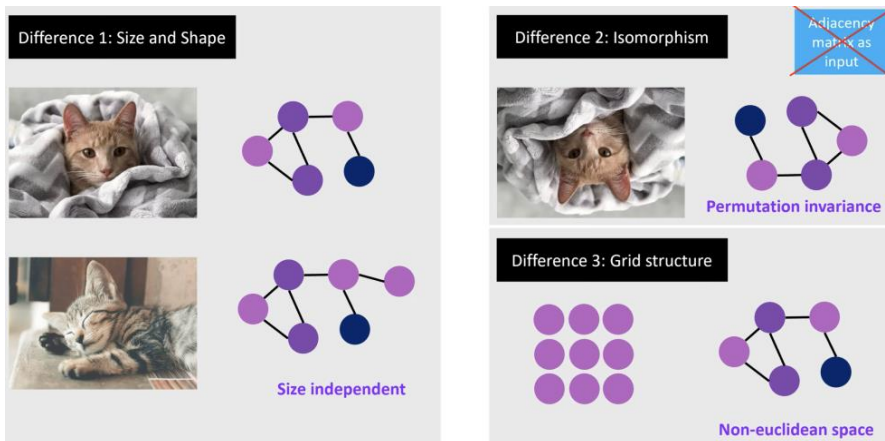


그림 1. 비유클리드 데이터 특징 (출처: <https://youtu.be/fOctJB4kVIM>)




그림 2. 기하 딥러닝 데이터 형태 (출처: Bronstein et al., 2017)

하다. <그림 1>에서와 같이 데이터 형태는 샘플마다 크기가 다르고, 구조가 동형적(isomorphic)이며 동시에 순서상 불변적(invariant)일 수 있다.

따라서, 이러한 데이터를 학습하기 위해 별도로 '기하 딥러닝' 분야가 탄생했으며, 본 기술은 학습을 위해서 데이터의 표현을 새롭게 구상해야 하기에 '표현 학습'(Representation learning)이라고도 하며, 그리드, 그룹, 그래프 및 측지선 형태의 데이터에 적용 가능하다 (Bronstein et al., 2017)<그림 2>.

기하 딥러닝에서도 데이터 형태에 따라 특화된 모델이 등장하였다. 일례로, 3차원 객체의 경우 데이터 포맷에 따라 세분화 되었는데, 복셀 형태일 경우 3D CNN, 포인트 클라우드일 경우 PointNet, 메쉬 형태일 경우 MeshNet 등이 있다. 반면 그래프의 경우에는 대표적으로 GCN이 등장하였다.

본 고에서는 BIM 모델의 공간 정합성 검토를 위해 GCN을 활용한 사례를 소개하였다.

### 3. GCN 이용한 BIM 공간 객체 정합성 검토

#### 3.1. GCN 작동 원리

그래프는 개별 노드(node)와 엣지(edge) 형태의 네트워크

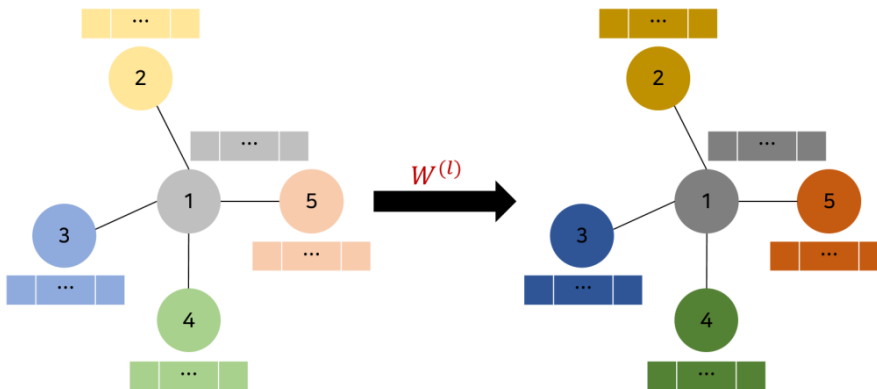


그림 3. GCN 작동 원리

형태 구조로 이뤄져 이미지나 시계열 데이터와 같이 재래식 딥러닝 기법으로는 관독이 불가능하였다. 이에 그래프에 특화된 학습 모델이 개발되었으며 Deepwalk, Node2Vec 과 같은 그래프 임베딩 연구를 비롯하여 그래프의 노드 및 엣지를 분류 및 예측할 수 있는 Graph Convolution Network (GCN)이 등장하였다(Kipf and Welling, 2016).

GCN은 합성곱(convolution) 연산을 통한 가중치 공유(weight sharing)와 지역적 특성 학습(local feature learning)을 기반으로 노드와 이웃 노드의 정보를 동시에 학습에 활용하는 모델이다<그림 3>. GCN은 또한 준지도학습 방식으로 레이블된 데이터의 양이 부족해도 높은 정확도를 도출할 수 있다. 즉, GCN은 그래프의 각 노드에 공유된 학습 변수를 적용할 수 있어 적은 수의 변수만으로도 높은 성능을 발휘하여 주목받은 바 있다.

<그림 4>에서와 같이 GCN은 노드 간 관계를 나타내는 인접 행렬(adjacency matrix, A)과 노드의 특성을 나타내는 노드 특성 행렬(node feature matrix, H)로 구현된다.

#### 3.2. BIM 공간 객체 정합성 검토

##### 1) 연구 필요성

BIM의 장점 중 하나는 기존 CAD에서 폐합면으로만 표현되

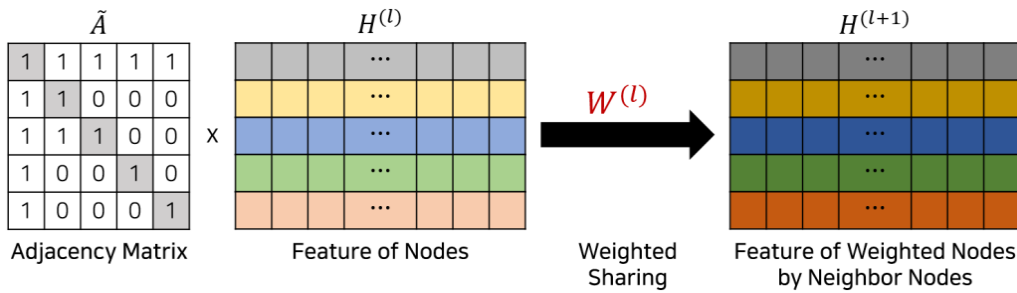


그림 4. GCN 구현 위한 노드 인접 및 특성 매트릭스

던 공간이 개별 객체로 인식될 수 있다는 것이다. 객체화된 공간의 속성정보는 법규검토, 에너지 분석, 피난 경로 분석 등을 위한 기반 데이터로 사용 가능하기에 BIM의 활용성을 넓힐 수 있는 발판이 된다.

그러나 다수의 참여자에 의해 수작업으로 진행되는 BIM 모델링 과정 특성 상 모델 내 기입된 공간 정보의 시멘틱 정합성을 보장하지는 못한다. 이는 BIM 소프트웨어 사용자가 모델을 검토할 때마다 공간경계를 새로이 정의하고 공간 레이블을 수동으로 명기해야 하는 문제를 야기한다(Bloch and Sacks, 2018). 따라서 BIM 내의 공간에 대한 분류가 올바른지 자동으로 검토하는 필요성이 제기되고 있다.

2) 연구 방법

공간은 그 공간의 경계를 구성하는 벽, 바닥, 천장 등에 의해 정의되며, 공간에 속해 있는 부재나 장비에 의해서도 구분될 수 있다. 또한 공간의 배치, 즉, 인접공간과의 관계에 의해서도 유사성을 띄는 경우가 많다. 예를 들어, 화장실에만 필수적으로 들어가는 부재(세면대, 타일 벽 등)가 있기 마련이고, 화장실은 복도와 인접해 있다.

이에 본 연구에서는 공간을 구성하는 개별 BIM 부재와 공간 간 시멘틱 관계로부터 이들 공간의 유사성을 그래프 형태로 표현하고(그림 5), 인공지능으로 학습하여 주어진 제반 공간 분류를 자동화하고자 하였다. 즉, 공간 별로 포함하고 있는 부재 집합이 일정 수준 이상 유사할 경우 그래프에서 해당 공간들을 연결함으로써, 연결된 공간의 관계 특징을 그래프 형태로 모델링 한 것이다. 구축된 그래프의 학습을 위해서는 상기 소개한 GCN을 통해 개별 공간을 자동 인식하도록 개발하였다.

3) 학습 데이터 구축 및 검증 결과

공간 데이터 구축을 위해 12층 규모의 업무시설 BIM 모델을 활용하였다. 본 모델은 LOD (Level of Detail) 300 수준인 실시 설계 단계 표준 IFC 모델로, 9가지 유형의 총 247개 공간과 19가지 유형의 총 11,066개의 부재로 구성되어 있다. <표 2>에 검증 결과를 제시하였다. 전체적으로 ACC가 0.94, F1-score가 0.91로 양호한 결과가 나온 것을 볼 수 있다. 구체적으로 승강기홀(Elevator hall), 복도(Hallway), 사무실(Office room) 등의 공간은 모두 올바르게 분류하였다. 이에

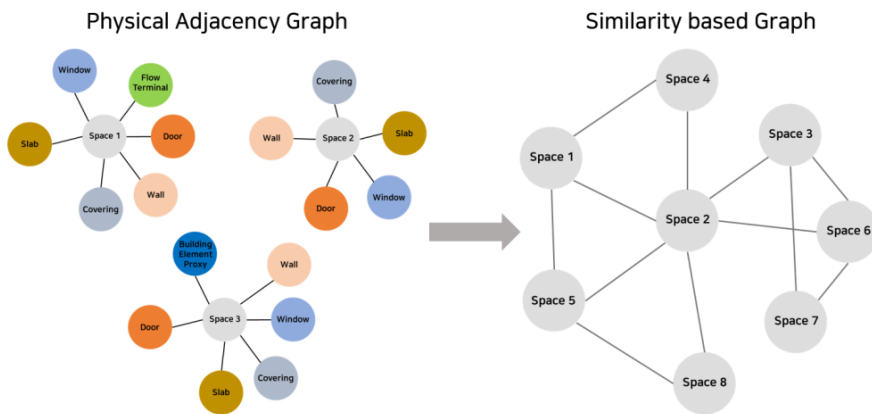


그림 5. BIM 공간 객체의 유사도 그래프 변환 과정

표 1. BIM 모델 내 공간 종류

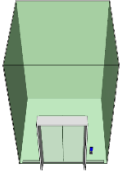

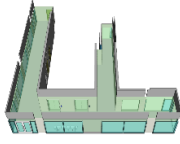
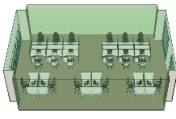
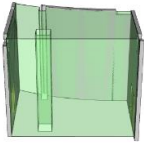
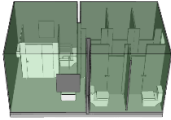
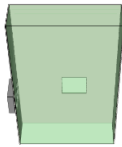

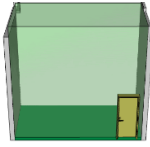
Label	Elevator hall	Elevator vestibule	Hallway	Office room	Plant room
Image					
No. of space	39	13	11	79	79
Label	Restroom	Shaft	Stairway	Storage	Total
Image					247
No. of space	20	40	25	6	

표 2. GCN의 공간 분류 성능 결과

IFC Class	Label	Accuracy	Precision	Recall	F1-score	No. of spaces
IfcSpace	Elevator hall	1.00	0.80	1.00	0.89	39
	Elevator vestibule	1.00	1.00	1.00	1.00	13
	Hallway	1.00	1.00	1.00	1.00	11
	Office room	1.00	0.92	1.00	0.96	79
	Plant room	0.57	1.00	0.57	0.73	14
	Restroom	1.00	1.00	1.00	1.00	20
	Shaft	0.87	1.00	0.87	0.93	40
	Stairway	1.00	1.00	1.00	1.00	25
	Storage	0.50	1.00	0.50	0.67	6
Average / Total		0.94	0.97	0.94	0.91	247

비해 설비룸(Plant room) 및 창고(Storage)는 ACC가 0.5로 사실상 제대로 분류하지 못하는 것으로 파악되었다. 이는 두 가지 문제로 귀결되는데, 하나는 해당 공간에 특징적인 부재가 존재하지 않는다는 점과 둘째는 두 공간의 데이터 샘플 개수가 다른 공간에 비해 상대적으로 적다는 것이다. <그림 6>의 Precision-recall curve도 이러한 한계점을 도식화하고 있다. 상기 문제는 향후 연구에서 데이터 샘플을 증대하고 특징적 부재를 선별하여 개선하고자 한다.

#### 4. 활용 방안

<표 2>에서 제시된 바와 같이 인공지능 기법을 쓸 경우 공간을 일부 오분류하는 경우가 생긴다. 이처럼 인공지능 기법은




그림 6. Precision Recall curve

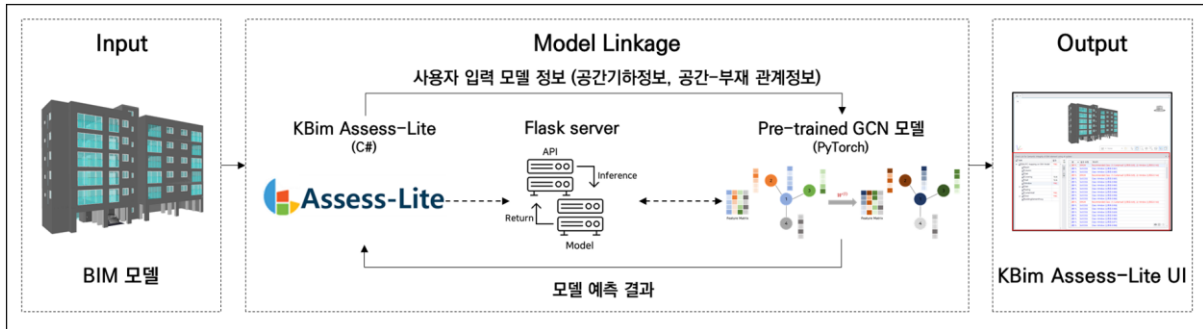


그림 7. REST API 기반 BIM 공간 및 GCN 연동 방안

귀납적 방식으로 그 결과에는 오류가 생길 위험이 상존한다. 따라서 앞서 소개된 알고리즘 활용 시, 분류 결과를 바로 반영하기보다는 자동 체크 기능으로 쓰고, 최종 의사결정은 사용자에게 맡길 필요가 있다. <그림 7>은 본 방식을 시스템화한 것으로서 국내에서 개발된 KBim-Assess Lite<sup>1)</sup>에 학습 알고리즘을 REST API 서버 방식으로 연계하였다. 특정 BIM 모델이 주어지면, Assess Lite에서 부재 및 공간에 대한 특성값을 서버에 전송하고, 서버에 탑재된 GCN이 분류 결과를 재전송한다. 이후 공간의 오류가 있다면 GCN의 결과를 추천해 주되, 이에 대한 반영 여부는 사용자가 최종 결정한다.

## 5. 맺음말

본 고에서는 3차원 기하 딥러닝 기술의 소개와 이를 BIM 모델의 정합성 검토에 활용한 연구 사례를 소개하였다. 그래프 데이터에 특화된 GCN 학습 모델을 통해 BIM 모델 내 공간 분류를 검토하였으며 이는 규칙 기반 혹은 재래식 기계학습 기반 모델보다 월등한 성능을 발휘할 수 있는 것을 검증하였다. 또한 구축된 학습모델을 서버 기반으로 상용 BIM 소프트웨어에서 원격으로 활용하는 방안도 제시하였다.

BIM을 설계 및 시공단계에 전면 적용할 것을 요구하는 추세가 증가하고 있으나 실무에서는 BIM 모델 구축에 대한 부담과 기존 2D 도면과의 병행 작업으로 인해 부담을 갖는 것이 사실이다. 따라서 이러한 인공지능 기술을 통한 BIM 자동화 및 고도화가 현안 이슈들을 해소하는데 일조할 것으로 사료된다. 본 연구자는 BIM 모델의 시멘틱 정합성 검토를 비롯하여 향후에는 BIM 모델의 LOD 자동 상세화 및 라이브러리

기반 전면 자동 설계를 위한 연구를 진행하고자 한다. 비단 BIM의 영역 뿐 아니라 건설 프로세스 전반에 걸쳐 급속도로 발전하는 인공지능 기술을 적재적소에 도입하여 우리 산업이 한층 업그레이드 될 수 있기를 기대해 본다.

## 감사의 글

본 연구는 국토교통부/국토교통과학기술진흥원의 지원으로 수행되었습니다. (과제번호 22AATD-C163269-2)

## 참고문헌

1. Bloch, T., & Sacks, R. (2018). Comparing machine learning and rule-based inferencing for semantic enrichment of BIM models. *Automation in Construction*, 91, 256-272.
2. 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), 18-42.
3. Welling, M., & Kipf, T. N. (2016). Semi-supervised classification with graph convolutional networks. In *J. International Conference on Learning Representations (ICLR 2017)*.

1) <https://www.inno-lab.co.kr/kbimassesslite/>