

Visibility Graph と GNN を用いた間取りのクラスタリングに関する研究

Floor Plan Clustering Using Visibility and GNN

○中田 千香^{*1}, 前田 雄飛^{*2}, 加戸 啓太^{*3}

Chika NAKADA^{*1}, Yuhi MAEDA^{*2} and Keita KADO^{*3}

^{*1} 千葉大学 工学部 総合工学科 建築学コース

Undergraduate, Faculty of Engineering, Chiba University

^{*2} 千葉大学 大学院融合理工学府 博士前期課程

Graduate Student, Graduate School of Science and Engineering, Chiba University

^{*3} 千葉大学 大学院工学研究院 助教 博士(工学)

Assistant Professional, Graduate School of Engineering, Chiba University, Ph.D.

キーワード : 建築; 構造; 環境; 計画; 情報

Keywords: Architecture; structure; environment; planning; information.

1. はじめに

深層学習は、第三次 AI ブームのきっかけとなった画像分類のタスクをはじめ、近年注目を集める画像や文章などの生成タスクなど、様々なタスクに適用される。教師なしクラスタリングにも適用され、オートエンコーダを用いる手法¹⁾や相互情報量を用いる手法 (Invariant Information Clustering : IIC)²⁾³⁾などを挙げることができる。これらの手法は、深層学習により構造化されていない画像などの非構造データを直接入力できるという特徴を有している。

住宅などにおける空間の構成を意味する間取りは、非構造データであり、これを平易に表現するために従来から nLDK (n は個室数、LDK はそれぞれリビング、ダイニング、キッチンを指す) や各室あるいは全体の面積などの指標によって表されてきた。言うまでもなくこれら指標は間取りをある側面から評価したものに過ぎず、間取りの持つ性質を広く表現するものではない。例えば、2LDK と表現される間取りにも様々なものが存在する。より高度な間取りの表現方法およびその活用方法として、ノードとエッジからなるグラフとして表現し、グラフ理論の適用により分析することも行われている。近年では Graph Neural Network (GNN) と呼ばれるグラフを処理する深層学習を適用することも試行されており、瀧澤は間取りと不動産価値との関係について、グラフ表現した間取りを入力にその不動産価値を推定する手法およびその価値に作用する因子を可視化する手法を報告している⁴⁾。

間取りのグラフ表現はノードないしエッジに様々な特徴量を持たせることで拡張の余地が多く、加えて GNN による処理も可能となったことから多くの展開を秘めていると考えられる。本研究では、グラフ表現した間取りにつ

いて、IIC による教師なしクラスタリングを行うことを試行し、考察を行う。

2. 研究概要

本研究は図1に示すように、グラフ表現した間取りを IIC によるクラスタリングを行うものである。IIC によるクラスタリングの概要、これに向けたグラフ表現の方針を示し、続いて具体的に間取りのクラスタリングを行いつつ、その結果について考察する。




図1 IIC による間取りのグラフのクラスタリング

2.1. IIC による教師なしクラスタリング

IIC による教師なしクラスタリングは、①同じクラスターに割り振られることを期待するペアのデータを、②同じネットワークにて特徴量表現およびクラスタリングを行い、③それぞれのクラスター確率の分布から相互情報量を求め損失とし、これが最大化するよう学習を行うものである (図1)。

相互情報量は式(1)によって求められる。確率変数 X, Y が依存していると大きくなり、独立していると小さくなる

(0 になる) ものである。加えて情報量であるので、確率分布の分散が大きいほうが相互情報量は大きくなる (図 2)。

$$I(X, Y) = H(X) - H(X|Y) \\ = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log \frac{p(x, y)}{\alpha p(x)p(y)} \quad (1)$$

IIC においては、確率変数 X, Y はあるバッチにおいて入力される複数のペアであり、そのクラスター確率の分布の平均から相互情報量が求められる。ペアが同じクラスターに割り振られることを直接学習するわけではないが、ペアを構成する 2 つのデータのクラスタリングには同じネットワークが用いられる。このため、結果的にペアのデータからはその共通の特徴が抽出され同じクラスターに割り振られるよう、かつ、バッチ全体としては各クラスターに分散するよう学習が行われる。通常、式(1)の α は 1 であるが、このバランスを取るハイパーパラメータとして作用し、 α を大きくすると、よりクラスター分布が分散するよう学習が進む。

なお、深層学習のフレームワークでは損失が最小となるよう学習が行われるため式(1)に -1 を乗じ負の値としたものが学習時の損失として用いられる。

XとYが独立である場合

	x: 0	x: 1	x: 2
y: 0	1/9	1/9	1/9
y: 1	1/9	1/9	1/9
y: 2	1/9	1/9	1/9

$I(X, Y) = 0.0$

XとYが非独立
(依存が最大) である場合

	x: 0	x: 1	x: 2
y: 0	3/9	0/9	0/9
y: 1	0/9	3/9	0/9
y: 2	0/9	0/9	3/9

$I(X, Y) \approx 1.099$

XとYに依存関係がある場合

	x: 0	x: 1	x: 2
y: 0	2/9	0.5/9	0.5/9
y: 1	0.5/9	2/9	0.5/9
y: 2	0.5/9	0.5/9	2/9

$I(X, Y) \approx 0.231$

XとYが非独立であるが
分散が小さい場合

	x: 0	x: 1	x: 2
y: 0	4.5/9	0/9	0/9
y: 1	0/9	4.5/9	0/9
y: 2	0/9	0/9	0/9

$I(X, Y) \approx 0.693$

図2 クラスター数3へのクラスタリングを例とした相互情報量の変化

2.2. 間取りのグラフ表現の方針

IIC による教師なしクラスタリングでは、入力するデータはペアである必要があるため、間取りグラフに適用する場合、一つの間取りから複数 (少なくともペアとなる二つ) のグラフ表現を得る必要がある。よって、間取りのグラフ表現に一般的な室をノードとしその接続をエッジとする

グラフ表現は適用しにくい。ノードのもつ特徴量については後述するが、例えば各ノードが用途と面積を特徴量として持つとして、一般的なデータ強化のようにこれらの特徴量を操作することを考えると、その操作の程度に十分な検討が必要となる。リビングから個室といった用途の変更はもちろん、面積の変更もその程度によっては不適当な特徴になってしまう可能性がある。エッジの操作も同様である。

本研究では、空間分析手法の一つである可視性グラフの分析 (Visibility Graph Analysis : VGA) ⁵⁾ に着目した。これは、分析対象の空間を均質なグリッドで覆い、グリッド点をノードとし、ノード点同士が障害物で遮られず可視であればエッジを接続するかたちでグラフ表現し分析を行うものである。VGA ではグリッドに基づきノードが配置されるが、ランダムに間取りに配置することで同じ間取りから複数のグラフを取得できる (図 3)。本研究ではランダムに配置したノードを用いた可視性グラフを Random Visibility Graph : RVG と呼ぶこととし、これを基本に間取りをグラフ表現し、クラスタリングを行うことを試みる。




図3 ランダムに配置したノードを用いた可視性グラフ

3. RVG におけるノードとエッジの特徴量の検討

VGA ではこれにより得たグラフについて、Space Syntax 理論で提案される Integration Value などを用い分析や可視化が行われる。VGA ではノードやエッジに特徴量を持たせることが行われないが、GNN ではこれら特徴量を用い計算が行われるため、RVG におけるノードとエッジの特徴量について検討を行う。

3.1. ノード特徴量

RVG では間取り上にランダムにノードが配置されるため、まず、これらの位置 (x, y) を特徴量とする XY パターンことが考えられる。また、ノードのもつ領域のようなものの面積 a を特徴量として加えることも考えられる。ノードを視点とした際の isovist を求め可視領域の面積 $a_{isovist}$ を特徴量に加える XYA_i パターン、ボロノイ領域に isovist のような可視性を加味した領域の面積 $a_{isovistic-voronoi}$ を特徴量に加える XYA_{iv} パターン (図 4) を挙げることができる。 XYA_{iv} パターンは、間取りにおいて単にボロノイを適用すると壁越しに領域ができてしまうので、それを避けたものである。あるノードの可視領域のうち、最近傍のノードが自身である領域である。間取りやノードの配置によっては領域が複数に渡ることもあるが、その場合はノード自身が含まれる領域のみを用いることとした。




図4 ボロノイ領域に可視性を加味した XYA_{iv} パターン

3.2. エッジ特徴量

エッジについては、単純にノード間の可視性 *visibility* を用いる V パターン、XYA_i パターンにおいて isovist 領域の交差面積 $a_{intersection}$ を用いる A_i パターン、XYA_{iv} パターンにおいて領域同士の共有境界長 $l_{shared-boundary}$ を用いる L_{sb} パターンが考えられる。

3.3. 検討

ノード特徴量3パターンとエッジ特徴量3パターンを組み合わせた以下のグラフパターンについて、間取り 10 プランを 10 クラスターに分類するタスクを行い検討する。
{ノード特徴量のパターン}-{エッジ特徴量のパターン} のように表記しており、XYA_i-L_{sb} のようにノードとエッジで異なる特徴量パターンを用いる組み合わせは省略した。

- ・ XY-V
- ・ XYA_i-V
- ・ XYA_i-A_i
- ・ XYA_{iv}-V
- ・ XYA_{iv}-L_{sb}

データセットには間取りのデータセット RPLAN⁶⁾を用いた。このデータセットは実在する住宅をマニュアルでアノテーションしたもので、戸建てであれば平屋のような一層の間取り 80,788 プランで構成されている。ここでの検討では検討用データセットとして、上記の 5 つのグラフパターンを用い、ID: 0~ID: 9 の 10 プランについて各 100 個のグラフを生成したものを用意した。ノード数は、XYA_{iv} において空白の領域が目立たない程度に調整した。また、ノードおよびエッジ特徴量はグラフパターンごとに平均が 0.0、分散が 1.0 となるよう標準化 (z-score normalization) した。ただし、エッジ特徴量が V パターンのものについては可視であれば 1 と単一の値しか取らないためそのまま用いる。

クラスタリングに用いるネットワークは図5に示すものである。グラフの畳み込みには Graph Attention Convolution (GATConv)⁷⁾を用いる。また、特徴量を分析することを目的に、潜在特徴量を Linear 層に入力しそれを各クラスターに対する確率分布とするのではなく、距離学習を行う L2-normalized Softmax⁸⁾を介して確率分布とすることとした。加えて、IIC では、目的とするクラスター数より多いクラスターへのクラスタリングを同時に行うことで学習を促進させるオーバークラスタリングというテクニックが採用されており、ここでは 5 倍の 50 クラスターでのオーバークラスタリングを行った。




図5 クラスタリングに用いるネットワーク

3.4. FPS によるノードのランダム配置の採用

RVG では、間取りにランダムに配置したノードを用いるものである。本検討の初期においては、間取り画像に十分な数のノード候補を用意したうち、室内にあるもののみを抽出し、そこから所定数のノードを Random Sampling する方法を採った。

ここでの検討に用いたネットワークは、オーバークラスタリングを除いた部分については、事前の検討において教師ありの分類タスクを十分に行えることを確かめたものである。各グラフは元のプランが推定できるような特徴を有していると言い換えられ、適切なクラスタリングが行えることを期待したが、10 クラスターのうち 3~4 クラスターのみに割り振られたり、分散するよう式(1) α を大きくするとペアが別のクラスターに割り振られたりとうまく処理されなかった。これは、教師なし学習においてはプランの違いよりもランダムなノード配置に伴うグラフ表現の違いが大きく扱われたことに起因すると考察した。

この結果を受け、ランダムなノード配置において、Random Sampling ではなく、Farthest Point Sampling : FPS を用いるよう改良を行った。FPS は三次元点群のダウンサンプリングに用いられるアルゴリズムの一つで、サンプリングに際して最初の一点をランダムに採用し、以降は採用済みの点群から最も遠い点を採用済みに加えていくことで、適切に概形が残るようサンプリングする手法である。本研究におけるグラフ表現においては、ランダムさを持ちつつも間取り内を適度に分布するようノードを設置することができる (図6)。



図6 Random Sampling によるノード配置 (左) と FPS によるノード配置

3.5. グラフ表現のパターンの検証

FPS の適用を経て、5 つのグラフ表現のパターンにおいて、式(1) $\alpha = 1.0$ でのクラスタリングが概ね 8~9 クラスターへと分布するようになった。この検証における正解である 10 クラスターへの分布される結果が散見されるようになる $\alpha = 1.5$ において、5 つのパターンのクラスタリング傾向を検証する。

IIC でのクラスタリングは教師なし学習であり、ネットワークの重みの初期値によって結果が異なることから、5 つのパターンをそれぞれ 10 回学習した際の最終的な損失を観察することにする。図 7 はこの結果を箱ひげ図で示したものである。損失は相互情報量に-1 を乗じたのであるため、小さいほど適切にクラスタリングが行われたということになり、損失が-8.3 以下になると 10 クラスターへの分布されるようになる。

グラフパターン毎に観察すると、XY-V では外れ値として示される一回を除いて損失が-8.35 以下と最も適切にクラスタリングが行われていることが確認できる。

ノード特徴量の観点から XY-V、XYAi-V、XYAi-V を比較すると、XYAi-V、XYAi-V は XY-V より情報量が多いにも関わらず損失が大きい傾向にある。考えられる原因としては、XYAi-V においては可視領域を単に面積として単純化して扱ったことや、間取り内での重複を許していることが挙げられる。

エッジ特徴量の観点から XYAi-V と XYAi-Ai および XYAi-V と XYAi-Lsb を比較すると、V 系のほうが、損失が低い傾向が確認できる。これは V 系と比較して Ai や Lsb はノード同士が壁を跨いでいてもエッジが接続しやすく、結果的にグラフ全体では間取りの特徴が現れにくくなった可能性が指摘できる。

以上から、検証した 5 つのグラフパターンにおいては、XY-V がクラスタリングに適していると判断し、次節の全プランを対象としたクラスタリングに用いることとした。




図 7 各グラフパターンにおける損失の分布

4. クラスタリングと結果の考察

グラフパターン XY-V により RPLAN 全 80,788 プランについて、各 5 個のグラフを作成しクラスタリングを行った。図 8 上はクラスタリングの結果から 1000 プランを取り出し、その潜在特徴量を t-SNE⁹⁾を用い二次元のプロットし

たものである。これに総面積、個室数などの指標を設定し、その多寡に応じて色付けし観察したところ、一部のクラスターに室数の多いプランが多く集まる傾向が確認できたが、総面積や他の指標においてもクラスタリングの傾向を明快に説明することは難しかった。しかしながら、潜在特徴量の類似するプランを確認すると、図 9 のように似たプランとなっており、局所的には間取りの特徴が抽出されたことが示唆された。




図 8 特徴量のプロット




図 9 類似した潜在特徴量をもつプランの例

5. まとめ

IIC とグラフを用いた間取りのクラスタリング手法について示した。

[参考文献]

- 1) 加戸啓太、他、オートエンコーダを用いた外構設計情報の管理とクラスタリングに関する研究、日本建築学会大会(東北)、学術講演梗概集、(社)日本建築学会、2018.9
- 2) Xu Ji, et.al., Invariant Information Clustering for Unsupervised Image Classification and Segmentation, International Conference on Computer Vision (ICCV), pp. 9865-9874, 2019
- 3) 福本健人、他、深層学習を用いた 3D isovist の処理による建築空間の視界の分析手法、日本建築学会技術報告集、第 29 巻、第 73 号、pp.1642-1647、2023.10
- 4) 瀧澤重志、グラフ畳み込みネットワークを用いた賃貸住宅の間取りの不動産的価値の推計方法の改良、日本建築学会大会学術講演梗概集(近畿) 情報システム部門、pp.101-102、2023.9
- 5) Turner, A., Depthmap 4 - A Researcher's Handbook, 2004 <https://discovery.ucl.ac.uk/id/eprint/2651/1/2651.pdf> (accessed 2023-09-26)
- 6) Wenming Wu et.al., Data-driven Interior Plan Generation for Residential Buildings, ACM Transactions on Graphics (SIGGRAPH Asia) vol.38 no.6, 2019
- 7) Petar Veličković et.al., Graph Attention Networks, International Conference on Learning Representations, 2018
- 8) Hao Wang et.al, CosFace: Large Margin Cosine Loss for Deep Face Recognition, Computer Vision and Pattern Recognition, 2018
- 9) Laurens van der Maaten et.al., Visualizing Data using t-SNE, Journal of Machine Learning Research 9, pp.2579-2605, 2008