深層学習を用いた不動産間取り図のグラフ化と物件検索への応用

Conversion of Floor Plan Images to Graph Structures using Deep Learning and Application to Retrieval

山田 万太郎 Mantaro Yamada

汪 雪婷 Xueting Wang

山﨑 俊彦 Toshihiko Yamasaki

相澤 清晴 Kiyoharu Aizawa

東京大学

The University of Tokyo

The purpose of this research is to automatically convert real estate floor plan images into graph structures that reflect the floor plans. In order to do this, we recognize each room or door in the images with semantic segmentation using deep learning, and create graph structures based on their adjacencies. By this proposed method, it was confirmed that floor plan images could be converted to the graphs with the similarity of 81% with the ground truth graphs. Representing floor plans as structured representations-graph structures- makes it easy to compare and evaluate floor plans, and even search, and is expected to be applied to any systems that handles floor plans.



Fig. 1: 間取り図の例 [1]

はじめに 1.

不動産間取り図とは、不動産物件においてその間取りを表現 した図である.間取り図は、人々が物件を評価する際に非常に 有用な情報となる.しかし,間取り図はその作成者や作成方法 が様々であるため、表記ゆれが大きくなっている. その様子を Fig. 1 に示す. このような表記ゆれが,間取り図を直接処理 することを困難にしていると考えられる.

この問題が表れている一例として,既存の不動産物件検索 システムが挙げられる.既存の物件検索システムは、賃料や立 地, 築年数などに対しては詳細な検索ができる一方, 間取りに 対してはワンルームや 2LDK といった部屋のタイプでしか検 索できない.これは、例えば「10帖以上のリビングに水回り が集中している利便性の高い配置がいい」といった間取りに対 する詳細な希望を持っているユーザーのニーズを満たしていな い.このようなニーズに沿った検索を可能にするには、間取り 図の内容をコンピュータに認識させ,その情報で検索を行う必 要がある.しかし、そのために間取り図画像を直接処理するの は、上述の理由から難しい問題であるといえる.

そこで本研究では、間取り図を表記ゆれの大きい画像という 形態から、グラフ構造という構造化された表現に変換すること を目指す.これによって,間取りの比較や評価,さらには検索 が容易になり、間取りを扱う様々な応用に繋がることが期待で きる. ここでは, 深層学習による画像認識を用いて間取り図の 内容を認識することによって, 間取り図を自動でグラフ化する 手法を提案する.

連絡先: 東京大学大学院情報理工学系研究科 相澤山崎研究室 〒113-8656 東京都文京区本郷 7-3-1 TEL: 03-5841-6761 mail: yamada@hal.t.u-tokyo.ac.jp



(a) Step1: 間取り図の semantic segmentation [4]



Fig. 2: 提案手法の概要図

関連研究 2.

間取り図の解析や認識を行っている研究自体は多く存在す る. 代表的なものとしては例えば Liu [2] らの研究が挙げられ る. 彼らは, 壁の交差点や各部屋の領域と家具等の物体を深層 学習を用いて認識することにより, 間取り図をベクターイメー ジへ変換することを試みている.

間取り図のグラフ構造への変換を行っている例としては, Yamasaki [3] らの研究が挙げられる.しかし、ここで作成さ れているグラフは間取り構造を正しく反映できていないという 問題がある.これは単に距離の近い部屋同士を隣接と判定して いるためであり,実際には行き来できない部屋の間にもエッジ が存在してしまう結果となっている.また,変換したグラフに ついての定量的評価も行われていない.

提案手法 3.

本研究では、以下の2ステップで不動産間取り図のグラフ 変換を実現する.その概要図を Fig. 2 に示す.

- 1. 間取り図画像の semantic segmentation を行う.
- 2. 各部屋やドアの接続関係からグラフ構造を作成する.

Table 1: クラスラベルの定義

| ラベル | 説明 |
|----------|-----------------|
| wall | 外壁, 内壁 |
| tatami | 和室 |
| west | 洋室 |
| dk | ダイニング,キッチン,リビング |
| wc | トイレ |
| bath | 浴室 |
| washing | 洗面所,脱衣所 |
| entrance | 玄関 |
| balcony | バルコニー,ベランダ,テラス |
| rouka | 廊下 |
| stairs | 階段 |
| cl | クローゼット,押入れ,下駄箱 |
| doors | 開き戸,引き戸,折戸,窓 |
| unknown | 記載のない箇所,不明箇所 |

提案手法では,まず深層学習による semantic segmentation を行い,間取り図をピクセルレベルで認識する.これによっ て,画像中のどこにどのような部屋が存在するのかがわかる. 本研究では,深層ネットワークモデル FCN-8s [4] を用いてこ れを行う.モデルの学習のためのデータセットとしては,間取 り図画像とそれに対応する独自生成の正解ラベルマスク 4,800 組を用意している.ラベルは Table 1 に示す計 14 種類とし, 間取りを構成する主要な要素が含まれている.

次に,各部屋の領域を走査して接続関係を調べ,ルールベー スでグラフの作成を行う.ノードの作成は,一定以上の面積を 持つ領域を抽出することで行う.エッジの作成は,同じドアに 隣接している部屋間,あるいは直接隣接している部屋間にのみ 行う.これにより,実際の部屋の接続関係を正しく反映したグ ラフ構造を作成することができる.

4. 実験

4.1 Semantic segmentation の評価

まず,提案手法の Step1 にあたる semantic segmentation の精度を評価する実験を行う.データセットを Train/Validation/Test data として 3,800/500/500 枚に分割 し, FCN-8s で間取り図画像と正解ラベルマスクの対応関係を 学習する.学習の後, Test data に対して式 (1) と式 (2) で評 価を行う.ただし, n_c はクラス数, t_i はクラス *i* に属するピ クセルの総数, n_{ij} はクラス*i* に属しクラス *j* と予測されたピ クセルの総数である.

mean accuracy =
$$\frac{1}{n_c} \sum_{i=1}^{n_c} \frac{n_{ii}}{t_i}$$
 (1)

mean IoU =
$$\frac{1}{n_c} \sum_{i=1}^{n_c} \frac{n_{ii}}{t_i + \sum_{i'=1}^{n_c} n_{i'i} - n_{ii}}$$
 (2)

実験の結果, Test data に対する平均の評価値は, mean accuracy が 90.6%, mean IoU が 84.0% となった. クラスごと の精度は Fig. 4 の通りである. これより, 面積が大きく文字 表記がある洋室や和室, リビングの認識精度は高く, 面積が小 さいあるいは文字表記がない領域であるドアや壁, 廊下の精度 は低くなる傾向があることがわかる.



Fig. 3: クラスごとの accuracy と IoU



Fig. 4: Semantic segmentation(中段) とグラフ化 (下段) の例

4.2 グラフ化の評価

Step2 におけるルールベースでのグラフ化をし、その精度 の評価をする実験を行う. Test data に対する semantic segmentation 後にルールベースでのグラフ化を行い、その結果 作成されたグラフがどれだけ正解グラフに類似しているかを 調べる. グラフの類似度指標としては、一般的で扱いやすい ことから、MCS による類似度を用いる. グラフ G_1 のノード 数とエッジ数の和を $|G_1|$ と表し、グラフ G_1 とグラフ G_2 の MCS(Maximum Common Subgraph:最大のエッジ数を持つ 共通サブグラフ)を MCS(G_1, G_2) とすると、グラフ G_1 とグ ラフ G_2 の類似度は式 (3) で計算される. MCS 類似度は 2つ のグラフが全く異なる場合は 0、全く等しい場合は 1 となり、 0~1 に正規化されている.

$$\sin(G_1, G_2) = \frac{|\mathrm{MCS}(G_1, G_2)|}{\max(|G_1|, |G_2|)} \tag{3}$$

この実験の結果,提案手法によって間取り図から変換した グラフと正解グラフとの平均の類似度は、0.810となった.ま た,その一例を Fig. 4 の下段に示す.右端の例は精度の低い 例である.この例は semantic segmentaion の精度が低く,特 に玄関付近と洋室での誤認識が目立つ.その結果,変換された グラフにも誤りが反映されており,本来の間取り図には存在し ない部屋のノードができてしまっていることがわかる.一方, 左の 2 つの例は精度が高い例であり,間取りを正しく表現し たグラフ化ができている.

4.3 物件検索への応用

以上の提案した手法による間取り図のグラフ化を応用して, 間取り類似物件の検索を行う.ここでは,クエリとして任意の 間取り図画像を入力し,その間取りとの類似度が高い間取り を持つ物件の間取り図画像を出力するという実験を行う.ク エリとしては Test data を用い,検索候補としては LIFULL HOME'S データセットからさらに 25,000 件の間取り図を用 いる.この 25,000 件にはこれまでの実験で用いた 4,800 枚は 含まれていない.検索の手順は以下の通りである.

- 1. 検索候補の間取り図 25,000 件をあらかじめグラフ化する.
- 2. システムにクエリとなる間取り図画像を入力する.
- 3. 提案手法を用いてクエリ画像をグラフ化する.
- 4. クエリと検索候補のグラフとの間の類似度を計算する.
- 5. 類似度が高い順に検索結果を表示する.

このようにして類似する間取り図を検索した結果の例を Fig. 5 に示す. Fig. 5a は 2DK で和室と洋室をひとつずつ持つ間 取り図をクエリとした例である,検索結果を見るとと,クエリ と同様の間取り構造を持っていることがわかる.和室と洋室が 存在するだけではなく,その繋がり方や付随する収納の有無, 水回りへのアクセスまでもが一致していることがわかる.Fig. 5b はクエリを 2 階建ての間取り図とした例である.検索結果 も同様に 2 階建ての構造で,水回りが 1 階に,バルコニー付き の洋室が 2 階にという配置も一致していることがわかる.特 に 3 位までの間取り図はクエリによく一致している.4位と 5 位は 2 階部分の部屋がひとつ多いが,その点以外は概ね一致 しているといえる.

一方で, Fig. 5c は類似の間取り図を検索できなかった例で ある. クエリとなる間取りは, 玄関が LDK と洋室の両方に繋 がっていて, 中央に位置する洗面所を介して LDK と洋室を行 き来できるという特徴的な間取りである. しかし, 検索結果に そのような間取りを含む物件は現れなかった. この場合, クエ リとなっている間取り構造が極めてユニークであったことが原 因である可能性もある.

以上の結果から,間取りをグラフで表現しその類似度での検 索を行うことで,間取り図のスタイルやカラーリングは異なっ ていたとしても間取りの構造が類似している物件を検索できる 例があることが確認できた.

5. まとめ

本研究の目的は、不動産間取り図の画像を自動でグラフ構造 に変換することである.本研究で提案した手法により、間取り 図画像をおよそ8割の精度でその間取りを反映したグラフ構 造に変換することができることを示した.さらに、それを用い ることによって任意の間取り図に対してそれと構造的に類似し ている間取りを検索する仕組みを実現できることを確認した. 本研究の成果は以下のようにまとめることができる.

- 間取りを反映したグラフへの変換手法を提案したこと
- 変換したグラフについて定量的な評価を行ったこと
- 応用として類似の間取りを検索できる例を示したこと

一方で,類似物件検索への応用については多くの課題が残さ れており,例えばその評価がひとつである.さらに,ユーザー の間取りに対する要望をシステムに伝えるためのインタフェー スをどう設計するかは重要な課題であるといえる.

謝辞

本研究データの一部は, NII-IDR より提供されている LI-FULL HOME'S データセットを用いている.

参考文献

- 国立情報学研究所 IDR 事務局. LIFULL HOME'S データ セット, 2010-2019.
- [2] Chen Liu, Jiajun Wu, Pushmeet Kohli, and Yasutaka Furukawa. Raster-to-Vector: Revisiting Floorplan Transformation. In *IEEE International Conference on Computer Vision*, pp. 2214–2222, 2017.
- [3] Toshihiko Yamasaki, Jin Zhang, and Yuki Takada. Apartment Structure Estimation Using Fully Convolutional Networks and Graph Model. In ACM Workshop on Multimedia for Real Estate Tech, pp. 1–6, 2018.
- [4] Jonathan Long, Evan Shelhamer, and Trevor Darrell. Fully Convolutional Networks for Semantic Segmentation. In *IEEE Conference on Computer Vision and Pattern Recognition*, 2015.

3N4-J-10-03



(c) 失敗例

法面所 浴室

バルコニ

Fig. 5: 類似間取り図検索の例 左上が検索クエリとなる間取り図.右へ順に5位までの検索結果.