

住居用不動産間取り画像を用いた住み心地推定および 街の魅力解析への応用

北林 遼大[†] 笠西 哲^{††} 檜原 太郎^{†††} 山崎 俊彦^{††}

[†] 東京大学工学部電子情報工学科 〒113-8656 東京都文京区本郷 7-3-1

^{††} 東京大学大学院情報理工学系研究科 〒113-8656 東京都文京区本郷 7-3-1

^{†††} ニュージャージー工科大学 Hillier College of Architecture and Design, Newark, NJ 07102, USA

E-mail: [†]kitabayashi@cvm.t.u-tokyo.ac.jp, ^{††}kasanishi@hal.t.u-tokyo.ac.jp, ^{†††}narahara@njit.edu,

^{†††}yamasaki@cvm.t.u-tokyo.ac.jp

あらまし 我々は、不動産物件における主観的な「住み心地」に着目し、間取り図画像から得られる情報から人々が物件に対して抱く印象を予測する研究を行っている。具体的には、間取り図画像およびその間取りを反映したグラフ構造を深層学習により解析することで、開放感や現代感、プライバシーなどの観点における各物件の魅力度を予測することが可能になる。本論文では、住み心地推定の応用例として、住み心地という観点からの街の魅力度の解析を試みた。実際に我々の手法を東京都内に存在する物件に対して適用して各物件の住み心地の予測を行い、地域間における予測値の違いを分析した。

キーワード 不動産物件, 間取り画像, 住み心地, 街の魅力, Graph Neural Networks (GNN)

1 はじめに

不動産間取り図には、物件内の部屋の種類や大きさ、部屋同士のつながりなどの情報が含まれており、これらの間取り図の情報は長年にわたり、人々が物件を評価するために広く用いられてきた。近年では、深層学習を用いて間取り図を解析するという研究が広く行われている。代表的なものとして、例えば Liu ら [1] の研究が挙げられる。彼らは、Convolutional Neural Network (CNN) を用いて、間取り図上の壁の交差点や部屋の種類、家具などの物体を認識し、間取り図画像からベクターイメージに変換することを試みている。

この他にも、不動産間取り図を用いた先行研究では主に、間取りの構造に関する解析や賃料推定など、客観的な観点に着目したタスクがこれまでに広く行われている。一方で、多くの人々は間取り図を見た際、物件の構造自体を認識するだけにとどまらず、住み心地や開放感の有無など、数値的なデータで表現することが難しいような、主観的な印象を抱く場合が多い。このことを踏まえると、間取り図から住居の住み心地などの主観的な印象を予測することはある程度可能であると考えられるが、このようなタスクに取り組んでいる研究はまだ少ないというのが現状である。

そこで、本研究は、住み心地という主観的な観点に着目し、間取り図から得られる情報を深層学習を用いて解析することにより、開放感や現代感の有無などといったような、人々が物件に対して感じる主観的な印象の推定を高い精度で行うことを目的とする。さらに、上記の間取りの印象解析により得られた知見を、実際に東京都内に存在する物件に対して適用することで、住み心地という観点からの街ごとの魅力を解析するというタス

クにも取り組んだ。具体的には、本研究で構築した間取りの印象予測モデルを用いて、それぞれの間取りに対して住み心地に関する予測値を算出した上で、地域ごとにおけるスコアの違いを比較することにより、住み心地という観点から見たときにそれぞれの街がどのような点で魅力的であるかということについての解析を試みた。

2 関連研究

本研究に関連する先行研究として、間取り図画像の解析を行う研究、および間取り図を用いた不動産タスクの例を挙げる。

2.1 間取り図画像の解析を行う研究

間取り図に含まれる重要な情報として、“間取りの中に含まれる部屋の種類や数”と“部屋同士の構造的なつながり”が挙げられる。間取り図を自動的に解析するには、まずこれら2つの情報を間取り図から抽出することが重要となる。

Ahmed ら [2] は、間取り図の領域分割の問題に取り組んだ。まず、間取り図をテキスト部分とそれ以外の部分に分割したのち、非テキスト部分に対しては線の検出による壁の認識を行い、また、テキスト部分には OCR を用いた文字検出を行うことにより、既存手法と比べて間取りに含まれる部屋の検出率を向上させることに成功した。

前節でも述べたように、近年では深層学習が間取り図画像の解析に対して積極的に応用されている。例えば、Zeng ら [3] は、間取り図画像の Semantic Segmentation についての研究を行った。彼らは、壁を認識するためのネットワークと部屋を認識するためのネットワークの2つの部分で構成されたモデルを提案しており、前者のネットワークで取得した特徴を活用しつ

つ、これら2つのネットワークを用いたマルチタスク学習を行うことにより、高い精度で間取り図の Semantic Segmentation を行うことに成功している。

また、間取り図の中に含まれる部屋の数や種類についての解析を行った後、これらの情報を用いて間取りのグラフ化を行う研究も行われている。例えば、山田ら [4] は、まず間取り図画像に対して Semantic Segmentation を行い、間取りに含まれる部屋に関する情報の抽出を行った後、各部屋の領域を走査して接続関係を調べ、各部屋をノード、それぞれの部屋同士の接続関係をエッジとするグラフをルールベースで作成することを試みている。

2.2 間取り図を用いた不動産関連タスク

ここでは、間取り図を用いて賃料の推定や不動産推薦タスクなどに取り組んだ先行研究を挙げる。深層学習が開発される以前、瀧澤ら [5] は、間取り図画像 996 枚から、部屋をノード、ドアなどによる部屋同士の繋がりをエッジとしたグラフデータを手動で作成し、グラフマイニングの手法を用いて間取り図の隣接グラフ構造と賃貸料の関係を分析することで、リッジ回帰による賃料推定モデルを構築した。しかし、人手で間取り図の隣接グラフを作成するコストは非常に高く、また、グラフマイニングの過程で、作成したグラフデータを部分グラフの出現有無というデータに置き換えて解析しているため、グラフの持つ全ての情報を利用できていないという課題があった。

近年では深層学習を用いて間取り図を自動的に解析し、これにより得られた特徴量を不動産推薦などのタスクに利用することも多い。例えば、高田ら [6] は、類似している間取り図を画像のみから検索するというタスクに取り組んだ。彼らは、間取り図画像に対して間取りタイプを推定する学習、および各部屋タイプの有無を推定する学習の2通りの学習を同時に行い、学習したモデルから得られる深層特徴量を利用して、メタデータに頼らずに間取り画像のみから類似している間取りを提示することができることを示した。また、加藤ら [7] は、不動産物件の自動推薦を目的として、その第一歩としてユーザの物件に対する嗜好予測を行った。その際、ユーザの属性データや物件の属性データに加えて、間取り図画像から得られる深層特徴量を予測に組み込むことで推薦の精度を向上させることに成功した。服部ら [8] は、間取り図が賃料予測に与える影響を明らかにするために、間取り図を考慮した賃料予測モデルと間取り図を考慮しない賃料予測モデルを構築し、間取り図の有無での予測精度の差の比較を行った。その結果、予測アルゴリズムに線形回帰を採用した場合、間取り図を考慮することで予測のばらつきを軽減できることを明かにした。

前節や本節で述べたように、不動産分野における先行研究では主に、間取り図自体の解析や価格の推定などに関する研究が行われてきた。しかし、住居の「住み心地」のような、主観的な観点に着目した不動産関連の先行研究は少ない。本研究では、物件に対する主観的な印象を予測するモデルを構築し、住み心地という観点から間取りを解析することを目指す。

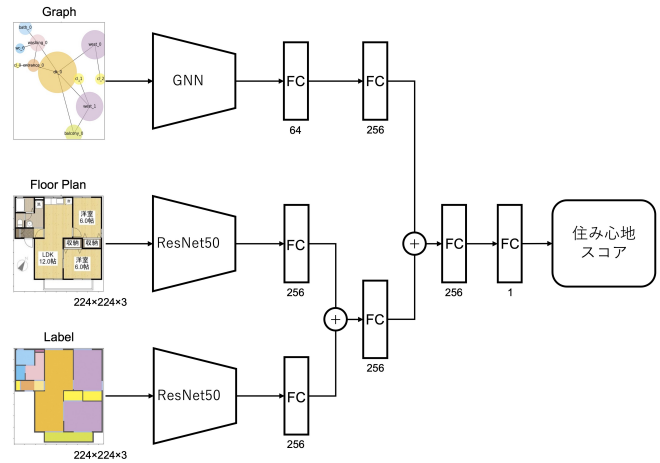


図 1: 提案するネットワーク

3 提案手法

本研究で提案する手法は、間取り図から得られる情報、特に間取り図やそれに対応するグラフ構造（間取りグラフ）を用いて、不動産物件の住み心地の推定を行うというものである。本研究で構築した予測モデルの概要を図 1 に示す。ここで、間取りグラフとは、間取り図中の部屋をノード、部屋同士の接続関係をエッジに対応させたものである。

まず、[4] と同様の方法を用いて、元の間取り図画像からそれに対応するピクセルラベルおよびグラフ構造の作成を行う。そして、間取り図画像と、作成されたラベル画像および間取りグラフを入力とし、深層学習を用いて解析することにより、住み心地の推定スコアを出力するモデルを構築する。間取り図画像およびそれに対応するラベル画像に対しては、ImageNet [9] で学習済みの ResNet50 [10] を用いることで、特徴量の抽出を行う。また、間取りグラフは、グラフを直接扱うことのできるニューラルネットワークである Graph Neural Networks (GNN) に入力し解析することで、グラフ全体の情報から予測に適切な特徴量の抽出を行う。そして、上記で得られた2つの特徴量を組み合わせることで、最終的に住み心地の予測を行う。

このように、間取り図画像だけでなく、それに対応する間取りグラフを予測モデルの入力として採用することにより、間取り図全体の「見た目」から得られる情報だけでなく、間取りに含まれる「部屋の種類」や「部屋同士の接続関係」といった、グラフ構造に含まれている間取りに関するより詳細な情報を基に予測を行うことが可能となる。

4 実験：不動産物件の住み心地推定

4.1 間取り図の解析

間取り図画像を用いた物件の魅力度解析を行うに先立ち、我々は [4] と同様の手順により、部屋を表すノードと、部屋間のつながりを表すエッジからなるグラフを間取り図画像から自動的に抽出するための実験を行った。まず、間取り図画像に対して




図 2: 間取り図解析の実験結果例。まず, Semantic Segmentation により, 間取り図画像 (Floor plan) から部屋のラベルを予測し (Predicted), 次に, 予測ラベルをもとにルールベースでグラフを作成した (Graph)。なお, GT label は間取り図画像に付与されたアノテーションラベルである。

DeepLabv3+ [11] を用いた Semantic Segmentation を行うことで, 間取りに含まれる部屋の種類に関する情報を抽出した。次に, 各部屋の領域を走査して接続関係を調べ, 各部屋をノードとして部屋同士の接続関係をエッジとするグラフをルールベースで作成した。この実験では, モデルを学習させるためのデータセットとして, [4] と同様に, LIFULL HOME'S データセット [12] に含まれる 4,800 枚の国内の間取り画像と, それに対応するアノテーションラベルの組のうち, 後述の 4.2 で用いるデータセット [13] には含まれない 3,800 件のデータを用いた。

このようにして, 間取り図画像から対応するグラフを自動的に抽出した結果の一例を図 2 に示す。この図を見ると, Semantic Segmentation により間取り図画像からその中に含まれる部屋のラベルが予測され, その結果に基づいてグラフ化が行われていることがわかる。

4.2 間取りの魅力度予測

前節で示した手順により間取り図画像からグラフを抽出し, 抽出されたグラフおよび間取り図画像を 3 節で述べた予測モデルに対する入力として利用することにより, 間取りの住み心地に関する予測を行った。

間取りの住み心地を解析するにあたり, ここでは檜原ら [13] が作成した, 1,000 件の間取り図およびそれぞれの間取りに付随する 9 種類の「魅力度スコア」からなるデータセット (図 3) を使用して実験を行った。ここで「魅力度スコア」とは, クラウドソーシングによって得られた以下に示す 9 つの属性 (主に Q1~Q3 は印象, Q4~Q6 は機能性, Q7~Q9 は環境面に関する属性) に対する各間取りの評価スコアのことである。

- Q1. 開放感
- Q2. 現代感
- Q3. 高級感
- Q4. 動線
- Q5. 水回り
- Q6. 収納
- Q7. 風通し
- Q8. 日照条件
- Q9. プライバシー

上記の 9 種類の魅力度スコアおよびそれらの平均値である Total スコアの予測値を出力するように予測モデルを各項目ごとに学習させ, 実スコアと予測値とのピアソンの積率相関係数

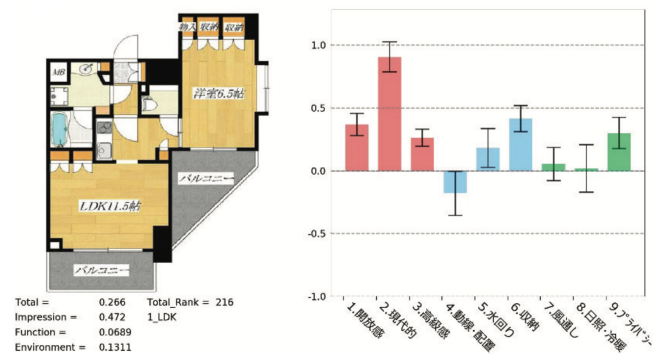


図 3: 間取りの住み心地予測に用いたデータセット [13]

によりその予測精度の評価を行った。ただし, 1 回の試行が終わるごとにデータセットを適当にシャッフルし, 訓練に用いるデータを毎回変更しながら同じ実験を 25 回繰り返した上で, その平均値により精度の評価を行った。

本実験では, 間取り図画像とそれに対応するグラフ構造の両方を予測モデルの入力として採用することの有効性を確かめるために, 提案手法 (Proposed) と次の 2 つの手法との比較を行った。

- Graphs only : 間取りグラフのみを用いて予測
- Images only : 画像情報のみを用いて予測

それぞれの手法において, テストデータにおける実スコアと予測スコア間の相関係数を計算した結果を表 1 に示す。提案手法を用いた場合, 10 項目における相関係数の平均値は 0.694 となり, 他の比較手法と比べても高い精度で住み心地の予測を行うことができていることがわかる。また, 項目別に比較しても, 10 項目全てにおいて提案手法の精度が最も優れており, このことから間取り図画像とそれに対応するグラフ構造の両方をモデルの入力とする手法が有効であるといえる。次に, この結果を項目ごとに見ていくと, まず, Q2 (現代感) や Q9 (プライバシー) に関してはグラフ構造のみを用いた手法でも予測精度が高いことがわかる。これらの項目は間取りグラフのみからでも比較的予測が容易な項目であると考えられる。また, Q1 (開

表 1: 間取りの住み心地予測における実スコアと予測スコア間の相関係数

Methods	Graph	Images	Q1	Q2	Q3	Q4	Q5	Q6	Q7	Q8	Q9	Total	Average
Proposed	✓	✓	0.791	0.813	0.793	0.604	0.527	0.704	0.568	0.557	0.802	0.781	0.694
Graphs only	✓	×	0.528	0.740	0.694	0.515	0.423	0.626	0.382	0.464	0.744	0.541	0.566
Images only	×	✓	0.490	0.600	0.549	0.432	0.392	0.518	0.363	0.402	0.567	0.553	0.491

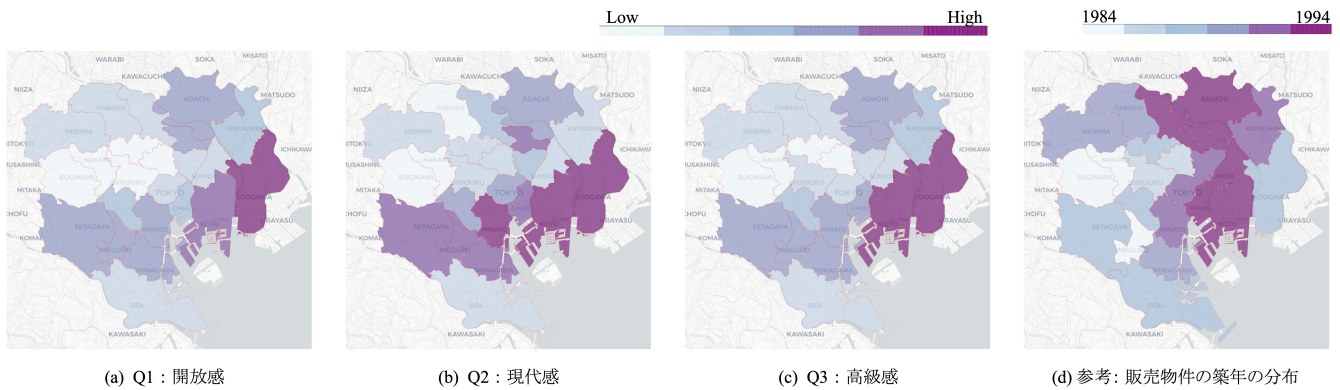


図 4: 東京 23 区における住み心地の予測結果および販売物件の築年の比較. ただし、各図において塗りつぶしの色が濃ければ濃いほど、その区における各スコアの平均値が高い（図 (d) では、築年数が浅い）ということを示している。

放感) や Q3 (高級感) などに関しては、グラフから得られる特徴量のみでなく画像から得られる特徴量を組み合わせて予測を行うことで、精度が大きく向上していることがわかる。これは、間取りの全体的なまとまりや、間取り図の見た目 (高級感がある見た目であるか等) など、間取りグラフには含まれていない情報を予測に反映させることで、グラフのみを用いた手法 (Graphs only) と比べてより正確な予測を行うことができたと考えられる。一方、Q5 (水回り) や Q7 (風通し)、Q8 (日照条件) など、提案手法を用いても予測精度が大きくは向上しなかったものも存在した。これは、グラフ化する際に、洗濯機や台所、窓など、これらの項目に影響を与える可能性のある部分を省いて行っていたことが一因として考えられる。これらの項目における精度改善は今後の課題としたい。

5 実験：街の魅力解析

本研究の提案手法による間取り図を用いた住み心地の予測を応用して、住み心地という観点からの街の魅力度の解析を行った。具体的には、実際に東京都内に存在する物件に対してそれぞれ住み心地の予測を行い、地域ごとにおける住み心地に関するスコアの違いを比較することで、住み心地という観点から見たときにそれぞれの街がどのような点で魅力的であるかということについての解析を行った。なお、本実験では、東京 23 区内で売買された物件のうち、7,915 件の物件を対象として実験を行った。

5.1 東京 23 区における住み心地スコアの比較

まず、住み心地という観点から見た際の 23 区それぞれの魅力の違いについて解析するための実験を行った。具体的には、それぞれの間取りに対して、前節で構築した予測モデルを用いて 3 種類の住み心地スコア (開放感, 現代感, 高級感) の予測

表 2: 23 区全体における築年と各スコア間の相関係数

	開放感	現代感	高級感
相関係数	0.232	0.337	0.165

値を算出し、23 区別にそれぞれ平均値を計算し比較を行った。その結果を図 4 に示す。これを見ると、江東区や江戸川区、港区などの湾岸エリアや、足立区や荒川区などの荒川に面した地域において比較的予測スコアが高い傾向にあることがわかる。また、販売物件の築年の平均値を 23 区ごとに計算した結果を図 4(d) に、築年と 3 種類のスコアとの相関係数を表 2 にそれぞれ示す。これらを踏まえると、上記の地域では販売物件のうち築年数が浅いものの割合が高く、それに応じて予測スコアも他の地域に比べて全体的に高くなっていると考えられる。

5.2 駅ごとに着目した住み心地スコアの比較

前節では、23 区ごとに住み心地に関する大まかな傾向を確認した。ここでは、より詳細な分析として、駅ごとに着目して分析を行った結果を示す。具体的には、23 区ごとに主要駅を数個ピックアップした後、それぞれの駅周辺に存在する物件の住み心地スコアの予測値を前節と同様に算出し、主要駅周辺エリアごとにその比較を行った。ここでは、駅ごとの分析結果の具体例として、江東区および港区に対して分析を行った結果を示す。

5.2.1 江東区の場合

江東区の主要駅として「亀戸駅」および「豊洲駅」の 2 つを取り上げて実験を行った。それぞれの駅周辺 (以下、それぞれ「亀戸エリア」/「豊洲エリア」と呼ぶ) に存在する物件に対して住み心地スコアの予測を行い、それらの比較を行った。

それぞれのエリアの対象物件に対して 3 種類の住み心地スコア (開放感, 現代感, 高級感) を予測し、その平均を計算した

表 3: 江東区主要エリアにおける住み心地スコア（平均値）の比較

エリア	対象件数	開放感	現代感	高級感
亀戸	110	-0.050	0.018	-0.129
豊洲	111	0.259	0.257	0.177

表 4: 港区主要エリアにおける住み心地スコア（平均値）の比較

エリア	対象件数	開放感	現代感	高級感
田町	80	-0.027	-0.070	-0.129
青山一丁目	62	0.220	0.234	0.157
六本木	117	0.016	0.225	-0.043

結果を表 3 に示す。前節で述べたように、江東区は他の区と比べ住み心地スコアの予測値が高い地域であったが、この結果を見ると、その中でもより湾岸に近い豊洲周辺の物件の方が特にスコアが高いということがわかる。また、上記の 2 つのエリアにおける物件の築年と 3 種類のスコア間の関係を図 5 に示す。これを見ると、豊洲エリアでは特に 2000 年以降に建築された物件の割合が非常に高く、亀戸と比べて比較的新しい街であるということが窺える。このように、豊洲エリアでは販売されている物件のうち築年数が浅い物件の割合が高く、そのため亀戸エリアと比べて予測スコアも全体的に高いと考えられる。

5.2.2 港区の場合

港区の主要駅として「田町駅」、「青山一丁目駅」および「六本木駅」の 3 つを取り上げて実験を行った。先ほどと同様に、それぞれの駅周辺（以下、それぞれ「田町エリア」/「青山一丁目エリア」/「六本木エリア」と呼ぶ）に存在する物件に対して 3 種類の住み心地スコア（開放感、現代感、高級感）の予測を行った結果を表 4 に示す。また、上記の 3 つのエリアにおける物件の築年と 3 種類のスコア間の関係を図 6 に示す。まず、田町エリアの結果を見ると、1990 年以前に建てられた築年数が古い物件における予測スコアの値が低く、このため他の港区のエリアよりも全体的なスコアが低いと考えられる。一方、青山一丁目エリアでは、築年数が古い物件でも高いスコアを持つ物件の割合が他の地域と比べても高いということがわかる。また、六本木エリアでは、他の 2 つのエリアと比べても、築年数に関係なくスコアが幅広く分布している、つまり、物件の新旧に関係なくスコアが高いものから低いものまで物件が幅広く存在し販売されているということがわかる。

6 おわりに

本研究の目的は、間取り図から得られる情報を解析することにより、人々が物件に対して感じる主観的な印象、すなわち「住み心地」を予測することである。本研究で提案する予測手法を、グラフのみから予測する手法などと比較した結果、間取り図画像およびそれに対応するグラフ構造の両方を予測に用いることの有効性を確かめることができた。そして、本研究で提案する予測モデルを実際に東京 23 区内に存在する物件に対して適用することで、住み心地という観点に基づいた街ごとの魅力の解析を行った。

本研究の成果は以下のようにまとめることができる。

- 間取り図画像から得られる情報をもとに、「住み心地」の予測を行う手法を提案した。
- 応用として、住み心地に基づいた街の魅力の解析できる例を示した。

次に、本研究の課題を述べる。まず、住み心地の予測実験において、高い精度で予測を行えなかった項目（水回りや風通し、日照条件）の予測の基準を改善することが挙げられる。また、住み心地の予測に用いるデータをより増やして精度の改善を図ることや、街の魅力解析の実験を東京だけでなく他の都市に対しても行うことでさらに詳細な分析を行うことも今後の課題としたい。さらに、今回行った街の魅力度に関する解析を年代別に行うことで、それぞれの街の魅力の推移についての解析も今後行いたいと考えている。

謝 辞

本研究の一部は、国立情報学研究所の IDR データセット提供サービスにより株式会社 LIFULL から提供を受けた「LIFULL HOME'S データセット」を利用した。また、一部のデータについては株式会社 DEVEL の協力を得た。本論文の一部は東京大学事業化推進助成制度（東京大学 GAP ファンドプログラム）の支援を受けた。

文 献

- [1] C. Liu, et al. Raster-to-vector: Revisiting floorplan transformation. In *ICCV*, pp. 2195–2203, 2017.
- [2] S. Ahmed, et al. Improved automatic analysis of architectural floor plans. In *ICDAR*, pp. 864–869, 2011.
- [3] Z. Zeng, et al. Deep floor plan recognition using a multi-task network with room-boundary-guided attention. In *ICCV*, pp. 9096–9104, 2019.
- [4] M. Yamada, et al. Graph structure extraction from floor plan images and its application to similar property retrieval. In *ICCE*, pp. 1–5, 2021.
- [5] 瀧澤重志ほか. グラフマイニングを用いた室配置を考慮した賃料分析 京都市郊外の 3ldk を中心とした賃貸マンションを対象として. 日本建築学会環境系論文集, Vol. 73, No. 623, pp. 139–146, 2008.
- [6] Y. Takada, et al. Similar floor plan retrieval featuring multi-task learning of layout type classification and room presence prediction. In *ICCE*, pp. 1–6, 2018.
- [7] N. Kato, et al. Users' preference prediction of real estate properties based on floor plan analysis. *IEICE Trans. Inf. & Syst.*, Vol. E103.D, No. 2, pp. 398–405, 2020.
- [8] 服部凌典ほか. 賃料予測モデルにおける間取り図の影響分析. 知能と情報, Vol. 33, No. 2, pp. 640–650, 2021.
- [9] J. Deng, et al. Imagenet: A large-scale hierarchical image database. In *CVPR*, pp. 248–255, 2009.
- [10] K. He, et al. Deep residual learning for image recognition. In *CVPR*, pp. 770–778, 2016.
- [11] L.-C. Chen, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation. In *ECCV*, pp. 801–818, 2018.
- [12] LIFULL HOME'S Dataset. <https://www.nii.ac.jp/dsc/idr/en/>.
- [13] 植原太郎ほか. 不動産間取り図を対象にした物件魅力度データセットの構築と分析. In *JSAT*, 2020.

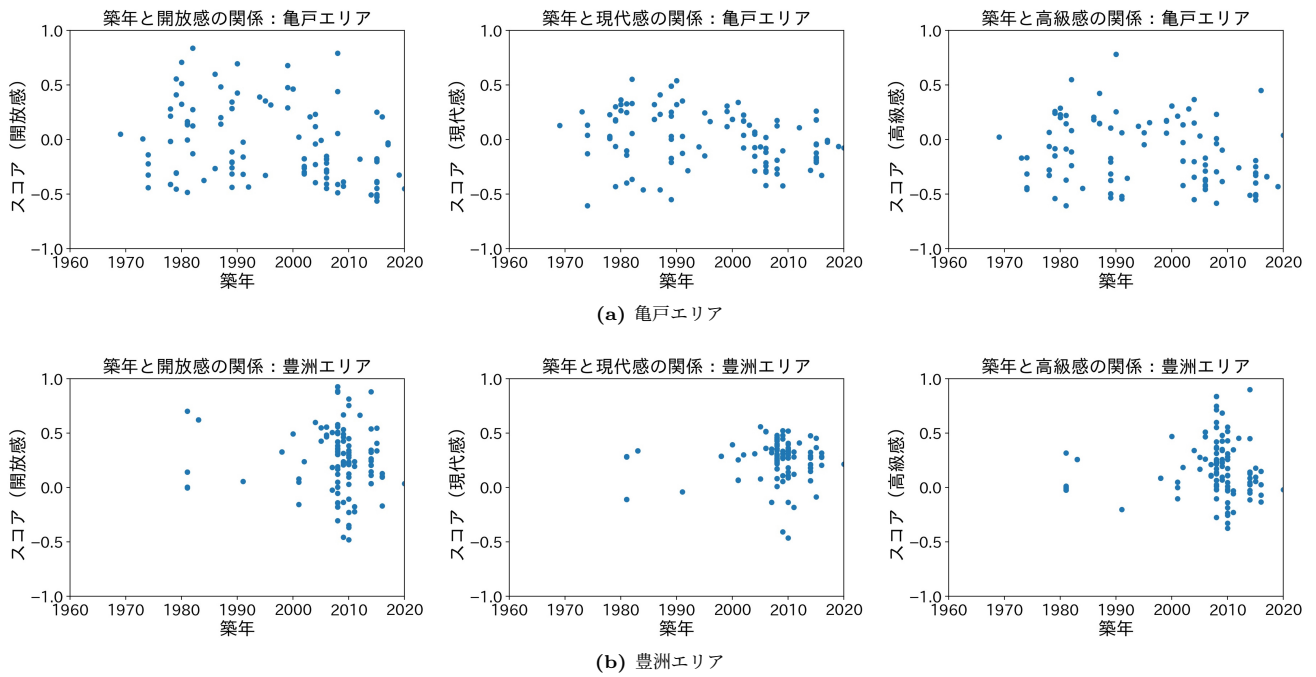


図 5: 江東区主要エリアにおける築年と各スコア（開放感, 現代感, 高級感）の関係

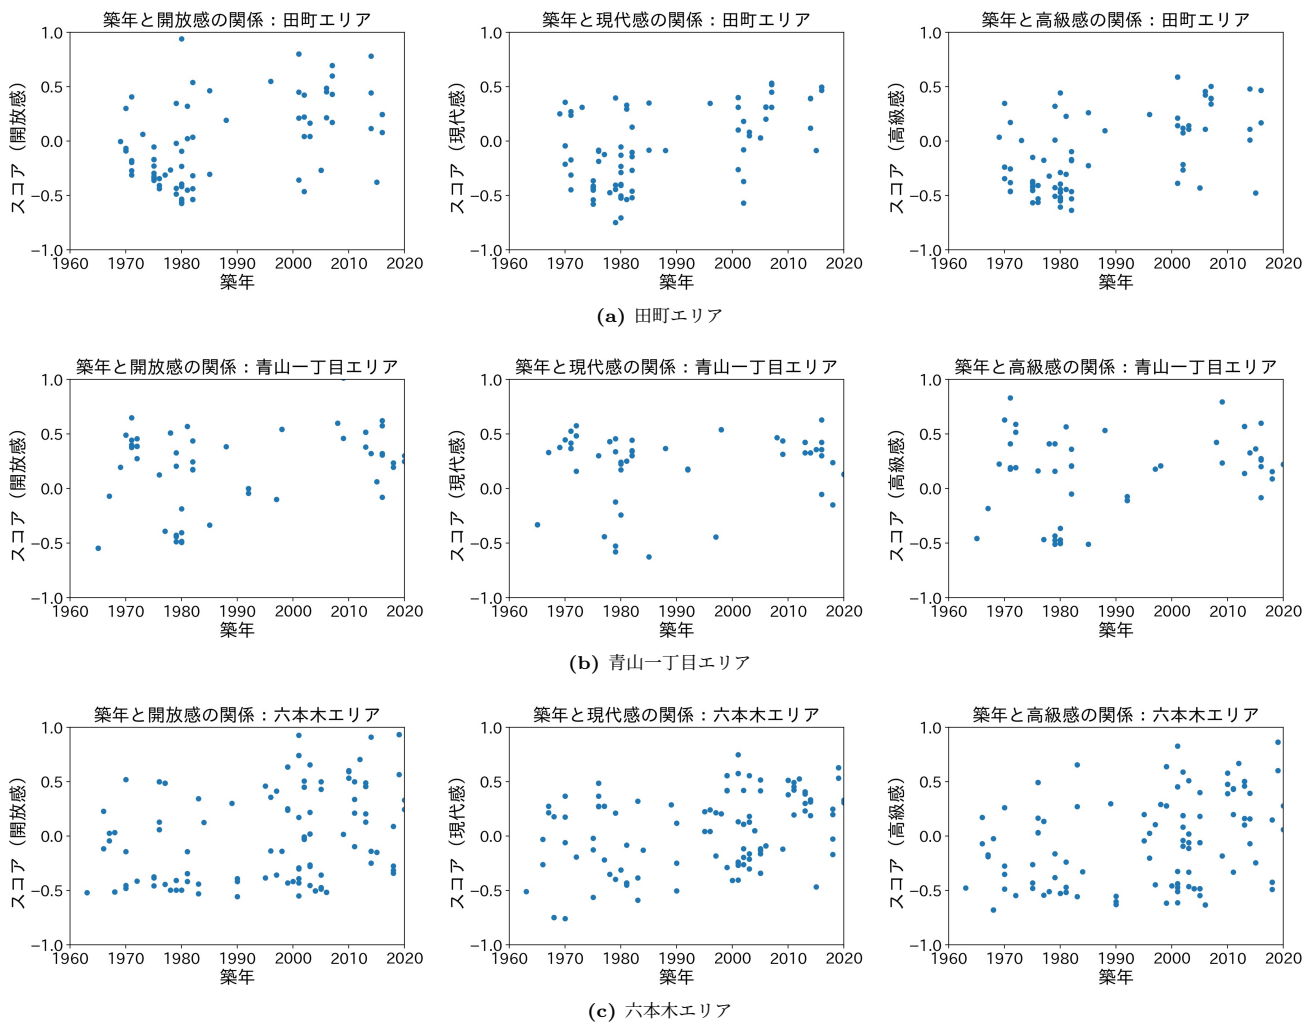


図 6: 港区主要エリアにおける築年と各スコア（開放感, 現代感, 高級感）の関係