

# ユーザ・物件特徴と間取り特徴を用いた嗜好予測

Preference Prediction using User/Property Features and Floorplan Images

加藤尚輝 <sup>\*1</sup>

Naoki Kato

山崎俊彦 <sup>\*1</sup>

Toshihiko Yamasaki

相澤清晴 <sup>\*1</sup>

Kiyoharu Aizawa

大浜毅美 <sup>\*2</sup>

Takemi Ohama

<sup>\*1</sup>東京大学

The University of Tokyo

<sup>\*2</sup>株式会社 ietty

ietty Co., Ltd.

Due to the advancement of E-commerce in recent years, recommendation for not only mass-produced daily items but also special items that are not mass-produced is an important task. In this research, we present an algorithm for real estate recommendation. There is no identical property in the world, properties already occupied by someone else can not be recommended, and users rent or buy properties only a few times in their lives. Therefore, automatic recommendation of property is one of the most difficult tasks. As the first step of property recommendation, we predict users' preference for properties by combining content-based filtering and multilayer perceptron (MLP). In the MLP, we used not only attribute data of users and properties but also deep features extracted from floorplan images of properties. As a result, we succeeded in predicting preference with accuracy of 60.7%.

## 1. はじめに

近年、オンラインサービスの普及に伴い E-commerce の利用者は増加傾向にある。E-commerce のウェブサイトでは商品の推薦が行われていることが多い、近年のデータの大規模化によりその精度は向上傾向にある。推薦システムには大きく分けてコンテンツベースフィルタリングと Goldberg ら [Goldberg 92] が提唱した協調フィルタリングの 2 種類がある。しかし、これらはアイテムが量産されているような場合にしか利用できず、各アイテムがこの世に 1 つしかないような分野、例えば不動産業界では不動産物件の推薦を行うのが困難である。

そのような状況の中、不動産業界では 2013 年以降、Real Estate Tech (不動産テック) とも呼ばれる不動産テクノロジー企業が急成長し始め、日本でもそのような企業が相次いで登場している。また、国土交通省もネット上の不動産業の規制緩和に向けて社会実験を行う等、積極的に不動産業界に IT を取り入れる動きがある。そのため、ウェブサイト上での物件の推薦は重要な課題の 1 つとなっている。

本研究では、上述したような一般的な推薦システムをそのまま使うことのできない特殊なデータにおける推薦システムの実装を最終的な目標とし、その例として不動産物件の推薦を扱う。物件推薦の第一歩として、不動産の賃貸会社である ietty<sup>\*1</sup> が所有する、ユーザによる物件評価が含まれるデータセットを用いてユーザの物件に対する嗜好予測を行う。通常の不動産賃貸と異なり、ietty ではウェブサイト上でユーザに物件を推薦し、ユーザはその物件を評価して実際に内見したり賃貸契約したりするという方法を取っている。ユーザの物件に対する嗜好予測において有効な手法を提案できれば、物件の推薦も比較的容易に行うことができると考えられる。

## 2. 関連研究

### 2.1 推薦に関する研究

協調フィルタリングは Goldberg ら [Goldberg 92] のメモリベースなものと、Breeze ら [Breeze 98] が新たに提唱したモデルベースなもののが存在する。また、Pennock [Pennock 00] は

連絡先: 加藤尚輝, kato@hal.t.u-tokyo.ac.jp

<sup>\*1</sup><https://ietty.me/>

それらを組み合わせたハイブリッド協調フィルタリングを考案し、Xue [Xue 05] はクラスタリングを用いたデータ補間によりハイブリッド協調フィルタリングの性能を向上させた。

一方、Simon [Func 06] は Netflix Prize<sup>\*2</sup> において、行列因子分解を用いたアルゴリズムにより推薦システムの性能を大きく向上させた。行列因子分解は式 (1) を満たすユーザ因子行列  $p$  及びアイテム因子行列  $q$  を求めるというものである。尚、 $\kappa$  は train データとして存在する評価値  $r_{ui}$  が既知であるようなユーザ  $u$  とアイテム  $i$  のペア  $(u, i)$  の集合であり、 $\hat{r}_{ui} = q_i^T p_u$  がユーザ  $u$  に対するアイテム  $i$  の予測評価値になる。

$$\min_{q, p} \sum_{(u, i) \in \kappa} (r_{ui} - q_i^T p_u)^2 + \lambda (\|q_i\|^2 + \|p_u\|^2) \quad (1)$$

Simon [Func 06] は式 (2)(3)(4) を反復させる確率的勾配降下法を用いてこれを解いた。

$$e_{ui} = r_{ui} - q_i^T p_u \quad (2)$$

$$q_i \leftarrow q_i + \gamma \cdot (e_{ui} \cdot p_u - \lambda \cdot q_i) \quad (3)$$

$$p_u \leftarrow p_u + \gamma \cdot (e_{ui} \cdot q_i - \lambda \cdot p_u) \quad (4)$$

この Netflix Prize で優勝した Koren ら [Koren 09] は確率的勾配降下法だけでなく、Alternating Least Squares (ALS) という  $q_i$  と  $p_u$  を交互に最適化するアルゴリズムで解く方法も紹介し、行列因子分解がデータが高次元になると発生する次元の呪いを解消して高次元データでも精度の高い推薦を実現することを示した。

また、Hidasi ら [Hidasi 15] は RNN (再帰型ニューラルネットワーク) の一種である Gated Recurrent Unit (GRU) により、E-commerce のウェブサイト上でのユーザの過去のクリックデータを全て用いた推薦システムを提案している。しかし、データのスパース性が高い特殊なアイテムに対してこれらの手法はうまく機能しない。現在の不動産物件の自動推薦システムに関しては、ietty では各ユーザの希望条件に対して徐々に条件を緩和しながら物件の推薦を行う、ルールベースなアルゴリズムを適用するという方法をとっている。

<sup>\*2</sup><http://www.netflixprize.com/>

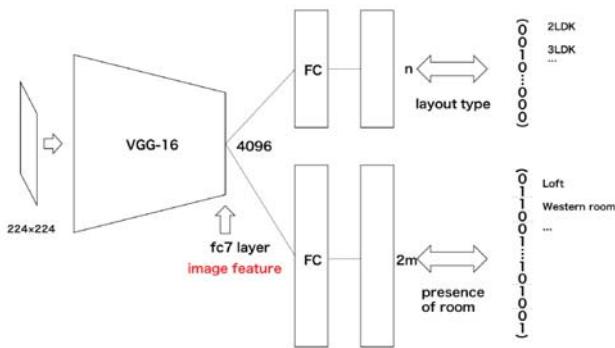


Fig. 1: 高田らの手法のネットワーク [Takada 18]

## 2.2 不動産物件の間取りの構造に関する研究

近年の深層学習の発展以前の物件の間取りの構造に関する研究は、間取り図をグラフで解析するというものであった。瀧澤ら [Takizawa 08] は、京都市内の 3LDK, 3K, 3DK の集合住宅の間取り図を用いて、部屋や廊下等をラベル付きノード、ドアやガラス等をラベル付きエッジとした隣接グラフによる物件の賃料の分析を行った。彼らは隣接グラフから部分グラフを抜き出し、共通な部分グラフの有無等から家賃推定を行い、その有効性を示した。しかし、隣接グラフによる間取りの構造の取得には、隣接グラフを作成するコストが非常に大きいという問題がある。

大原ら [Ohara 16] は間取りの共通部分グラフを用いてユーザの希望を反映した物件検索システムを開発した。また、高田ら [Takada 18] は大原ら [Ohara 16] の作成したデータセットを用いて、間取り図からグラフ構造を推定し、類似している間取り図の検索を行った。具体的には、Fig. 1 のネットワークを用い、間取りのタイプと部屋の有無の 2 種類の学習を同時に行う、マルチタスク学習によりモデルを作成し、そのモデルを使用して間取り画像から抽出した深層特徴を用いて検索を行った。

## 3. 提案手法

### 3.1 データセット

ietty ではウェブサイト上でユーザに不動産物件を数件推薦し、ユーザが推薦された各物件に対して「内見する、お気に入り、興味なし」を選択して評価できるようになっている。本研究では 2016 年から 2017 年にかけて連続した期間の評価データを取得し、それを間取り画像が存在する 220,094 件に絞り、3:1:1 の割合で train データ、validation データ、test データに分割して用いる。このデータセットに含まれるユーザ数は 19,538 人、物件数は 131,947 件である。

### 3.2 手法の概要

ユーザによる物件評価のうち「内見する、お気に入り」を positive、「興味なし」を negative と定義して、これらをユーザの物件に対する嗜好と呼称し、スパースなデータにも利用可能な手法によりこれを予測する。本研究では、ユーザ間類似度とアイテム間類似度を共に用いたコンテンツベースフィルタリングによる嗜好予測、物件の間取り画像から CNN (畳み込みニューラルネットワーク) を用いて抽出した深層特徴を入力に加えた MLP (多層ペーセプトロン) による嗜好予測をそれぞれ行う。これらの手法は推薦対象のユーザの過去の評価データがなくても使用することができるため、スパースなデータに比

較的強い。また、それらを組み合わせたシステムをハイブリッドフィルタリングと呼称し、それによる嗜好予測も行う。

物件の間取りのメタデータ (1DK, 1K, 1LDK 等) は物件の属性データに含まれているが、間取りの構造まで考慮することで嗜好予測の精度が上がる事が期待される。例えば、同じ 2LDK でも部屋と部屋のつながり方が異なっている事があり、幼い子供が勝手に外に出ないよう玄関と子供部屋が直接つながらないようにすることが可能な物件と、どの部屋からでも廊下に出られるような利便性の高い物件では推薦対象となるユーザの層も異なる。そのため、本研究では間取りの構造を考慮するために MLP に間取り画像の深層特徴を入力として加えることを提案した。以下の節で各手法の詳細を述べる。

### 3.3 コンテンツベースフィルタリング

ユーザ間の属性の類似度及び物件間の属性の類似度を共に用いたコンテンツベースフィルタリングにより嗜好予測を行う。ユーザの属性データを  $u$ 、物件の属性データを  $i$  で表し、positive の評価値を  $w$  (train データ内の negative なデータの数と positive なデータの数の比)、negative の評価値を -1 とする。test データ ( $u_{test}, i_{test}$ ) に対し、評価値  $r_{ui}$  が既知である train データ  $(u, t) \in \kappa$  との、ユーザの属性に対するコサイン類似度  $\cos(u_{test}, u)$  を取り、 $u$  の類似度上位  $k_u\%$  の集合を  $U_{CBF}$  とする。同様に、物件の属性に対するコサイン類似度  $\cos(i_{test}, i)$  を取り、 $i$  の類似度上位  $k_i\%$  の集合を  $I_{CBF}$  とする。その後、式 (5) により test データ  $(u_{test}, i_{test})$  の予測値  $v_{CBF}$  を求める。

$$v_{CBF} = \sum_{u \in U_{CBF}} \sum_{i \in I_{CBF}} \cos(u_{test}, u) \cdot \cos(i_{test}, i) \cdot r_{ui} \quad (5)$$

予測値  $v_{CBF}$  が 0 より大きいとき positive、0 以下のとき negative と予測する。

### 3.4 MLP

ユーザ・物件の属性データと、物件の間取り画像から CNN を用いて抽出した深層特徴を入力とした Fig. 2 のネットワークを用いて嗜好予測を行う。その際、dropout や batch normalization を用いて汎化性を向上させる。訓練時は train データと validation データを、テスト時は dropout を除いて test データを用いる。FC 最終層では negative, positive に対応した 2 次元ベクトル  $(x_n, x_p)$  が output され、test データの予測値  $v_{MLP} = x_p - x_n$  が 0 より大きいとき positive、0 以下のとき negative と予測する。

間取りの深層特徴の抽出には、高田ら [Takada 18] の手法を改良して訓練を行ったモデルを用いる。具体的にはファインチューニングの際に VGG-16 の代わりに ResNet50 を使用し、データの増強として間取り画像をランダムに回転させて入力に用いる。また、データセットは高田ら [Takada 18] が訓練に用いたものと同一のものを用い、20,000 枚の間取り画像を訓練に用いる。これにより作成した学習済みモデルを抽出器とし、pool5 層の 2,048 次元のベクトルを間取り画像の深層特徴量とする。

### 3.5 ハイブリッドフィルタリング

3.3, 3.4 で求めた予測値  $v_{CBF}$ ,  $v_{MLP}$  の重み付き和を予測値  $v_{HF}$  として嗜好予測を行う。概略図を Fig. 3 に示す。それぞれに積算する重み  $w_{CBF}$ ,  $w_{MLP}$  として、本研究では 3.3, 3.4 において test データの代わりに validation データを用いたときの予測値の集合の標準偏差  $\sigma_{CBF}$ ,  $\sigma_{MLP}$  の逆数を用い

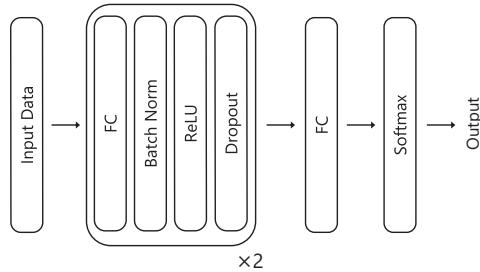


Fig. 2: MLP のネットワーク

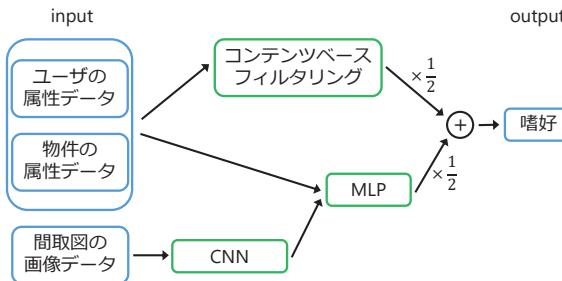


Fig. 3: ハイブリッドフィルタリングの概略図

る。式で表すと式 (6) のようになる。

$$v_{HF} = w_{CBF} \cdot v_{CBF} + w_{MLP} \cdot v_{MLP} = \frac{v_{CBF}}{\sigma_{CBF}} + \frac{v_{MLP}}{\sigma_{MLP}} \quad (6)$$

このようなスケーリングを行うことで 2 手法を同程度に重視した予測値  $v_{HF}$  が求まる。他の手法同様、予測値  $v_{HF}$  が 0 より大きいとき positive、0 以下のとき negative と予測する。

## 4. 実験

### 4.1 評価手法

全 220,094 件の評価データに対し、positive なデータは 76,871 件 (35%)、negative なデータは 143,223 件 (65%) 存在する。このようにデータセットに偏りがあるので、平等な評価をするために Matthews Correlation Coefficient (MCC) を評価に用いた。予測結果における true positive の数を  $TP$ 、true negative の数を  $TN$ 、false positive の数を  $FP$ 、false negative の数を  $FN$  としたときの MCC は式 (7) により算出される。MCC の最大値は 1、最小値は -1 であり、大きい方が性能が良いということになる。

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (7)$$

### 4.2 コンテンツベースフィルタリング

3.3 の手法において、train データのユーザの属性に対する類似度上位  $k_u (= 1, 10, 100\%)$ 、不動産物件の属性に対する類似度上位  $k_i (= 1, 10, 100\%)$  を用いたときのコンテンツベースフィルタリングの MCC は Fig. 4 のようになった。

ユーザ・物件共に train データの属性に対する類似度上位 10% を用いたときに最も性能が良く、MCC は 0.140 となった。 $k_u$  が小さすぎると参考にできる train データの数が極端に減ってしまってうまく予測し難く、逆に大きすぎると属性が全く類似していないユーザを参考にしてしまうためにうまく予測できないということが見て取れる。その一方で  $k_i$  については、

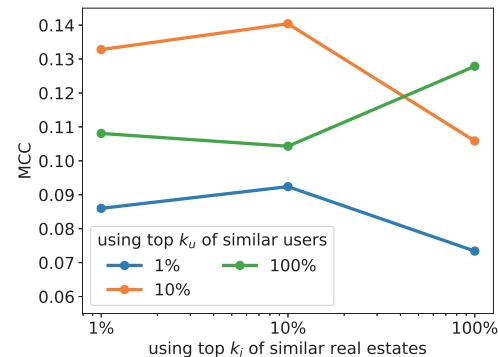


Fig. 4: コンテンツベースフィルタリングによる予測結果

Table 1: MLP による予測結果

Input	w/o image feature	w/ image feature (pre-trained)	w/ image feature (fine-tuned)
MCC	0.127	0.142	<b>0.149</b>
Accuracy	0.612	0.616	<b>0.619</b>
Precision	0.439	0.446	<b>0.451</b>
Recall	0.396	0.418	<b>0.423</b>
Confusion matrix	$\begin{pmatrix} TN & FP \\ FN & TP \end{pmatrix} = \begin{pmatrix} 20843 & 7802 \\ 9281 & 6094 \end{pmatrix}$	$\begin{pmatrix} 20678 & 7967 \\ 8954 & 6421 \end{pmatrix}$	$\begin{pmatrix} 20725 & 7920 \\ 8866 & 6509 \end{pmatrix}$

$k_u$  が小さいとき ( $k_u = 1, 10\%$ ) は同様に小さすぎず大きすぎない値を選ぶのが良さそうであるものの、 $k_u = 100\%$ 、つまり train データ内の全てのユーザの情報を用いる場合は train データ内の物件の情報も全て用いる方が性能が良くなるという結果となった。

### 4.3 MLP

3.4 の手法において、以下の 3 通りの入力を用いた場合の MLP による嗜好予測を行った。

#### w/o image feature:

ユーザ・物件の属性データだけを用いた場合

#### w/ image feature (pre-trained):

ユーザ・物件の属性データだけでなく、ImageNet の学習済みモデルにより間取り画像から抽出した深層特徴も用いた場合

#### w/ image feature (fine-tuned):

ユーザ・物件の属性データだけでなく、3.4 においてファインチューニングを行ったモデルにより間取り画像から抽出した深層特徴も用いた場合

このときの嗜好予測結果は Table 1 のようになった。

3 通りの入力の MLP の中では、間取り画像の深層特徴をファインチューニングを行ったモデルにより抽出して入力に加えた MLP の性能が最も良く、MCC は 0.149 となった。間取り画像の深層特徴を入力に加えたことにより、MLP の性能が上昇していることがわかる。このことから、間取りの構造を考慮することは、ユーザの物件に対する嗜好予測において有効であると考えられる。また、間取り画像の深層特徴の抽出器として、ImageNet の学習済みモデルを用いるより、ファイン

Table 2: ハイブリッドフィルタリングによる予測結果

Input	w/o image feature	w/ image feature (pre-trained)	w/ image feature (fine-tuned)
MCC	0.150	0.159	<b>0.166</b>
Accuracy	0.600	0.604	<b>0.607</b>
Precision	0.437	0.442	<b>0.446</b>
Recall	0.500	0.507	<b>0.514</b>
Confusion matrix			
$\begin{pmatrix} TN & FP \\ FN & TP \end{pmatrix}$	$\begin{pmatrix} 18748 & 9897 \\ 7693 & 7682 \end{pmatrix}$	$\begin{pmatrix} 18796 & 9849 \\ 7579 & 7796 \end{pmatrix}$	$\begin{pmatrix} 18823 & 9822 \\ 7479 & 7876 \end{pmatrix}$

チューニングを行ったモデルを用いた方が MLP の性能は高くなることもわかる。このことから、ファインチューニングによって間取りの構造の特徴がうまく取れるようなより良い深層特徴が抽出できていると考えられる。

#### 4.4 ハイブリッドフィルタリング

3.5 の手法において、4.3 と同じ 3 通りの入力を用いたときの嗜好予測結果は Table 2 のようになった。

前述した全ての予測システムの中で最も性能が良いのは、間取り画像の深層特徴をファインチューニングを行ったモデルにより抽出して入力に加えたハイブリッドフィルタリングであり、MCC は 0.166 となった。ハイブリッドフィルタリング内での比較としては、3 通りの入力による予測性能の傾向は 4.3 と同様であった。また、MLP との比較を行うと、全体的に予測性能がかなり向上していることがわかる。このことから、コンテンツベースフィルタリングと MLP を組み合わせて用いることにより、機械学習におけるアンサンブルのように汎化性能が向上する効果があると考えられる。

### 5. 結論

量産されていないような特殊なアイテムに対する推薦システムの構築を目的とし、その第一歩としてユーザ間類似度とアイテム間類似度を共に用いたコンテンツベースフィルタリング、物件の間取り画像から CNN を用いて抽出した深層特徴を入力に加えた MLP、それらを組み合わせたハイブリッドフィルタリングによってユーザの不動産物件に対する嗜好予測を行った。その結果、間取り画像の深層特徴をファインチューニングを行ったモデルにより抽出して入力に加えたハイブリッドフィルタリングが最も優秀であることが示された。

本研究の課題は大きく分けて 2 つ存在する。まず、本研究では間取り図の深層特徴を抽出する際に高田ら [Takada 18] の手法を用いたが、他の手法との比較・検討を行うことができていない。例えば、Liu ら [Liu 17] は深層学習を利用してラスター形式の間取り画像からベクトル形式の間取り構造を取り出すことに成功している。この手法において入力画像から junction layer を取り出す際に使用するネットワークを本研究の提案手法に応用することが考えられる。次に、実際に物件推薦に提案手法を用いる際は処理の速さも重要になってくるが、本研究で用いたコンテンツベースフィルタリングは計算量が非常に多くなりやすいものであるため、より効率的な設計をしなければ実際の物件推薦に用いることはできない。また、物件を推薦する毎に間取り画像を読み込んで抽出器に通すのも時間的なコストが大きく、予め深層特徴を抽出しておく等の対策が必要となる。これらを解決できれば、本研究の提案手法を実際の推薦に用いることができるため、これらを今後の課題としたい。

### 参考文献

- [Breese 98] Breeze, J. S., Heckerman, D., and Kadie, C.: Empirical analysis of predictive algorithms for collaborative filtering, in *Proceedings of the Fourteenth Conference on Uncertainty in Artificial Intelligence (UAI)*, pp. 43–52 Morgan Kaufmann Publishers Inc. (1998)
- [Func 06] Func, S.: Netflix Update: Try This at Home (2006), <http://sifter.org/simon/journal/20061211.html>
- [Goldberg 92] Goldberg, D., Nichols, D., Oki, B. M., and Terry, D.: Using Collaborative Filtering to Weave an Information Tapestry, *Commun. ACM*, Vol. 35, No. 12, pp. 61–70 (1992)
- [Hidasi 15] Hidasi, B., Karatzoglou, A., Baltrunas, L., and Tikk, D.: Session-based Recommendations with Recurrent Neural Networks, *CoRR*, Vol. abs/1511.06939, (2015)
- [Koren 09] Koren, Y., Bell, R., Volinsky, C., et al.: Matrix factorization techniques for recommender systems, *Computer*, Vol. 42, No. 8, pp. 30–37 (2009)
- [Liu 17] Liu, C., Wu, J., Kohli, P., and Furukawa, Y.: Raster-To-Vector: Revisiting Floorplan Transformation, in *The IEEE International Conference on Computer Vision (ICCV)* (2017)
- [Ohara 16] Ohara, K., Yamasaki, T., and Aizawa, K.: An Intuitive System for Searching Apartments using Floor Plans and Areas of Rooms, *The 78th national convention of IPSJ* (2016), (in Japanese)
- [Pennock 00] Pennock, D. M.: Collaborative filtering by personality diagnosis : A hybrid memory and model-based approach, *Proceedings of the Sixteenth Conference on Uncertainty in Artificial Intelligence (UAI)* (2000)
- [Takada 18] Takada, Y., Inoue, N., Yamasaki, T., and Aizawa, K.: Similar Floor Plan Retrieval Featuring Multi-Task Learning of Layout Type Classification and Room Presence Prediction, *IEEE International Conference on Consumer Electronics (ICCE)*, pp. 931–936 (2018)
- [Takizawa 08] Takizawa, A., Yoshida, K., and Kato, N.: Applying graph mining to rent analysis considering room layouts, *Journal of Environmental Engineering*, Vol. 73, No. 623, pp. 139–146 (2008)
- [Xue 05] Xue, G.-R.: Scalable collaborative filtering using cluster-based smoothing, *Proc. 28th Annual ACM SIGIR Conf. on Research and Development in Information Retrieval* (2005)