

推薦そのものがユーザに与える影響を考慮した情報推薦

The Recommendation Algorithm Including Effects on a User.

大知 正直*1 関 喜史*1 川上 登福*2 小野木 大二*3 野村 眞平*3 吉永 恵一*3 松尾 豊*1

Masanao Ochi Yoshifumi Seki Takayoshi Kawakami Daiji Onogi Shinpei Nomura Keiichi Yoshinaga Yutaka Matsuo

*1 東京大学

*2 株式会社 経営共創基盤

*3 株式会社リクルート住まいカンパニー

The University of Tokyo

Industrial Growth Platform, Inc.

Recruit Sumai Company Ltd.

When people buy an electronics goods, a car, or a house which is called “shopping goods,” they consider and search items which to buy for long term. These days, users can consider and search such items on the Web more easily. Users can learn much knowledge from items they watched and find which characteristics are important for themselves gradually. But, past most recommendation algorithms ignore such process to buy and they always recommend the most likely item to users at the time. These algorithms are not effective for users who don't decide to buy items yet. In this paper, we focus on Shopping goods which is considered for long term and propose the recommendation algorithm to motivate users who will not buy such items but be considering. Our experimental results shows that the proposed algorithm has 1.14 times higher CV rate than the past algorithm and our proposed algorithm work well when the transition probability to recommended pages is higher than 40%. Our proposed method will be able to have users decide to buy “shopping goods” by giving them good knowledge about items they want.

1. はじめに

近年、電気製品、家具、自動車、家などの買い回り品 (Shopping goods)[Melvin 23] と呼ばれる商品を Web 上で比較検討することがますます盛んになってきており、一部については Web 上で直接商品を購入できるようになっている。買い回り品の特徴は、ユーザがさまざまな商品の比較検討を行い、ユーザ自身にとって最も必要な商品を見つけ出すところにある。こうした比較検討を行う中で、ユーザ自身は検討の初期の段階より商品に対する知識を獲得し、よりユーザ自身の要求を明確にすることが可能になる。

一方、多くの E コマースサイトや Web 上の広告は、過去のユーザの履歴を元に新たな商品を画面上に推薦するサービスを稼働させている。ユーザにどの商品を推薦するか、は商業的にも重要な技術で、さかんに研究されている [Goldberg 92, 神島 07, 神島 08a, 神島 08b, Bobadilla 13]。代表的な技術である、ユーザベースの協調フィルタリングでは、ユーザの過去の商品購入履歴と類似しているユーザの商品購入履歴から、まだ購入していない商品を推薦する。つまり、現在の商品推薦システムはユーザが次に最も購入する可能性の高い商品を推薦することを目的としており、購入したい商品が具体的に決まっているユーザには有効に作用する。

しかし、サイト訪問時に購入したい商品を具体的に決めていないユーザも多い。こうしたユーザが買い回り品を購入する際には、まずはさまざまな商品を閲覧し、比較検討する中で、商品に対する知識を獲得し、ユーザ自身の要求を明確化する必要がある。ユーザが商品に対する知識を獲得するために見るべき商品と、その時点で最も購入しそうな商品は異なる可能性がある。まだ購入の意思が固まっていないユーザに対し、ある時点で最も購入しそうな商品を推薦しても、ユーザは購入しないだろう。

この問題を解決するために、本研究では、こうした検討期間の長い商品を対象にし、ユーザの商品知識獲得を手助けし、将来的な購入の可能性を上昇させる情報推薦手法を提案する。

具体的には、その時点のみでなく、将来に渡る購買可能性を算出し、将来的な購買可能性を含めた上で最も高い購買可能性を示す商品を推薦する。これによって、これまで商品を欲しいと思い、購入の検討を始めたが、商品に対する知識を獲得できず、購入を諦めてしまっていたユーザに対する需要を呼び起こすことが可能になる。

本稿では、データとして、ユーザが長い期間検討し、様々な商品を比較した上で、購入すると考えられる不動産の商品情報サイトにおけるユーザ行動履歴を利用する。実験の結果、従来の CV 率見積もり手法と比較し、推薦した商品ページへの遷移確率を 100%と仮定した場合、提案手法では平均 1.14 倍の向上が見込まれる結果となった。この仮定は繰り返し推薦した商品に必ず遷移することを示しており、提案手法の効果が最大限現れた場合を示している。遷移確率を下げた場合、実験では 40%以上の場合、提案手法の効果があることがわかった。

これらの結果から本手法が将来的な CV 率の向上に有効であることを示した。

本研究の貢献は以下の 3 点があげられる。

- 直接 CV 率が高い物件を提示するよりも、その時点では低い物件の閲覧を通すことで将来の CV 率を高める手法の適用可能性を示した。
- 商品を推薦することによって、その商品で CV しなかったとしてもユーザの将来の購買行動に影響を与えることを示した。
- 将来的な CV を考慮した推薦手法を提案することで、検討期間の長い高価な商材に合った推薦手法を示した。

本稿は以下のように構成される。2 章で関連研究について述べ、本稿の論点を明確にする。次に本研究で使うデータセットについて述べる。そして、4 章で提案手法の説明を行い、5 章で実験と結果について議論する。6 章の考察では、本研究が効果を発揮する条件、応用可能性について議論を行う。最後に結論と今後の展望を述べる。

2. 関連研究

2.1 推薦アルゴリズムの研究

1990 年代に始まった協調フィルタリングを利用した情報推薦の研究 [Goldberg 92] は、E コマースサイトを始めさまざま

連絡先: 大知 正直, 東京大学大学院工学系研究科技術経営戦略学専攻, masanao.oochi@gmail.com

な分野でその成果が応用されている。特にユーザの行動履歴や属性によって提示する情報を変更する推薦手法は個人化推薦と呼ばれ、商用ではアイテム間のユーザ類似度を元にした協調型推薦を利用していることが報告されている [Linden 03]。本稿では、アイテム (物件) を推薦するためにユーザの履歴を元にした類似度指標を用いるのではなく、CV 率の向上に役立つアイテムを推薦する手法を提案する。CV 率はウェブサービスの基本となる指標で、CV 率を予測する成果 [Richardson 07] や、ユーザの閲覧履歴を元にして個人化した広告提示を行う成果 [Lee 12] が報告されている。これらの研究は閲覧履歴を元に広告提示を行う点で長期の CV 率を予測しており、本研究と類似している。しかし、本研究は単に最も CV の可能性が高い商品の提示を行うのではなく、提示によってユーザに影響を与え、それを利用することでユーザ自身の将来的な CV 率向上を目指すものである。

2.2 商品閲覧による嗜好変化の研究

本研究は、ユーザが商品を購入するかどうか長期間にわたり検討し、さまざまな商品を検討した上で決定することを前提としている。これは検討初期の段階から、購買の時点までのユーザは自身の嗜好を選択したり、具体的にしたりしている。これはユーザの嗜好が変化していることと同義である。こうしたユーザの嗜好の変化に合わせた推薦の研究は広く行われている。まず、ユーザインタフェースでユーザの希望に合わせて意外性のある商品を提示するアプローチが挙げられる [高玉 13]。本研究はユーザが推薦結果に満足できないときのみ新たな商品推薦を申し出る手法をとっており、インタフェースによって嗜好の変化に対応していると位置づけることができる。次に、時系列の興味変化に対応するアプローチが挙げられる [中辻 13]。これはユーザの嗜好は直近の履歴と強く相関することを利用して、過去の履歴の重要度を小さく見積ることでユーザの興味の変化に対応している。最後に推薦の意外性を向上させることでシステムの満足度を向上させるアプローチ [村上 09] が挙げられる。これはあえてユーザの過去の嗜好と関係の無い商品を推薦結果に含めることで、結果的にユーザの推薦システムそのものに対する満足度を向上させることを示したものである。推薦結果に多様性を持たせることで、ユーザの嗜好の変化に対応できていることを示している。

しかし、これらの研究はユーザのある時点での履歴に基き、その時点で購入する可能性が最も高い商品を推薦しようとするという点で共通している。本研究では、その時点だけで無く、将来のユーザ購買の可能性を考慮するため、その時点では購買の可能性の低い商品を推薦する場合がある。つまり、ある時点で、将来的にユーザが購入するであろう商品を推定し、他のユーザがその商品の購入前に検討した商品を推薦することで、推定した商品の良さを具体的に理解してもらうことを目的としており、本研究と異なる。

3. 本研究に用いるデータの概要

本研究では、不動産情報のポータルサイトの一つである、Suumo^{*1}におけるアクセスログを用いる。本稿では以降、この Suumo のアクセスログを元に実験を進めていく。Suumo は (株) リクルート住まいカンパニーによって開発、運営が行われており、不動産情報のポータルサイトとして日本国内で最も大きなアクセス数を誇る住宅情報サイトの一つである。Suumo の Web サイト上でユーザはさまざまな物件を閲覧することが

できる。ただし、Web サイト上でユーザは住宅を購入することはできず、ユーザは興味を持った住宅情報の資料送付を申し込むことができる。

通常、商用の Web サイトではそれぞれ CV (コンバージョン) というものを定義している。CV とは、Web サイト上で獲得できる最終的な成果のことを示し、“CV する”とは、ゴールを達成していないユーザが、ゴールを達成したユーザに変わることを指す。この CV は Web サイト、ページごとに異なる。そこで本稿では、CV はユーザが物件の資料請求をサイト上で行うことと定義する。

本研究では Suumo 内で取り扱っている新築戸建、中古戸建、中古マンション、土地、新築マンションの 5 つの領域のサイトのアクセスログを対象にする。使用するデータはある特定の 21ヶ月間のものである。

このデータを元に、ユーザを CV ユーザと非 CV ユーザに分けて検討期間、アクセス回数を比較した。CV ユーザは非 CV ユーザと比較し、約 3.9 倍のアクセス期間、約 15.8 倍のアクセス回数であった。ユーザが不動産情報を真剣に検討する場合、長期間にわたり検討を行い、その間に繰り返しサイトを訪問していることがわかる。

4. 提案手法

本章では、検討期間の長い商品を対象とした推薦手法について提案を行う。3. 章で述べたように、ユーザは必ずしも高い購入意欲を持ってサイトを訪問しているわけではない。こうしたユーザにその時点で最も購買する可能性が高い商品を推薦しても、そもそも購入意欲が低いので CV を得ることはできないだろう。本研究ではこの問題を解決するために、既存研究にあるようなその時点で最も購買する可能性の高い商品を推薦するアプローチでは無く、その時点より先の将来的な購買可能性を考慮した推薦を行うアプローチを取る。

4.1 将来の購買を考慮した CV 率算出手法

我々は、買い回り品の購入を検討するユーザ行動に合わせるために、過去の関連研究と異なり、その時点でのユーザの興味だけでなく将来に渡る興味の変化を考慮する手法を提案する。この手法は、ユーザが検討している商品に対する知識獲得を手助けし、将来的な購入の可能性を上昇させる情報推薦を行うことを可能にする。

実験で利用するデータは不動産の物件情報である。不動産は文字通り動かさない商品であり、完全に同じ商品は存在しない。このため、本研究では、ユーザ、商品を完全に別々に見るのではなく、分類して同一のカテゴリに所属するものは同一なもののみとする。こうした方法は頻繁に商材が変わる場合に用いられる方法で、在庫が必ず 1 つしかない不動産という商品に良く当てはまる。

分類手法には完全に自動で行う k-means に代表される手法、分類のルールを自動的に構築する決定木のようなもの、手動で設定したルールで行うものが挙げられる。本研究では、実験結果の解釈のしやすさから手動で設定したルールに基づき、商品を分類する方法を取った。

表 1 に提案する推薦アルゴリズムを示す。アルゴリズム内で、 $Transition.Rate(c_i, c_j)$ は閲覧中のページ c_i から推薦したページ c_j への遷移確率を表す。また、 $History[-n]$ は閲覧履歴の最新の n 件を表すものとする。11 行目で呼び出す $Prediction$ 関数はある閲覧履歴を持つユーザに物件カテゴリ c_i のページを推薦した場合に、 $Future.c$ 回のページ閲覧以内に CV する確率を計算する。将来的な CV 率は 22 行目で再帰

*1 <http://suumo.jp>

表 1: 提案手法 (将来的な CV 率を上昇させる推薦手法).

```

Algorithm 1.
1: Input :  $AllHistory$  = あるユーザの閲覧履歴.
2: Input :  $N_{latest}$  = 閲覧履歴のうち利用する最新の件数.
3: Input :  $History = AllHistory[-N_{latest}]$ .
4: Input :  $Future_c$  = 考慮する将来の閲覧回数.
5: for  $i = 1$  to  $N(C)$ 
6:   for  $j = 1$  to  $N(C)$ 
7:     Input :  $Transition\_Rate(c_i, c_j) =$ 
        $c_i$ ページから  $c_j$ ページへの遷移確率.
8:   endfor
9: endfor
10: for  $i = 1$  to  $N(C)$ 
11:    $CVRate(c_i) = Prediction(History, c_i, Future_c)$ 
12: endfor
13:  $c^* = \operatorname{argmax}_{c_i \in \{c_1, \dots, C\}} CVRate(c_i)$ 
14: Output :  $c^*$ .

15: Function :  $Prediction(History, c, n)$ .
16:   UpdateHistory :  $newHistory = Array(History, c)$ .
17:   IF ( $n = 1$ ).
18:     return  $Transition\_Rate(History[-1], c)$ 
19:        $\times p(\text{conversion} | newHistory)$ .
20:   ELSEIF ( $n > 1$ ).
21:     for  $i = 1$  to  $N(C)$ 
22:        $CVRate(c_i) = Prediction(newHistory, c_i, n - 1)$ 
23:     endfor
24:     return  $Transition\_Rate(History[-1], c)$ 
        $\times (p(\text{conversion} | newHistory))$ 
        $+ (1 - p(\text{conversion} | newHistory)) \times \frac{\sum_{i=1}^{N(C)} CVRate(c_i)}{N(C)}$ .

```

的に $Prediction$ 関数を呼び出すことで計算する。24 行目で、推薦されたページでの CV 率に n 回先の閲覧以内に CV する確率を上乗せしている。その後、13 行目で、推薦候補となる各物件カテゴリページの中から将来的な CV 率が最も高いページを選択し、そのページを推薦するページ c^* として出力する。

従来手法は提案アルゴリズムの $Future_c = 1$ と設定した場合で、この場合は推薦したカテゴリページでの CV 率を 18 行目で算出し、出力する。

従来手法との相違点は、考慮する将来の閲覧回数の分だけ再帰的に CV 率を計算する点である。これによって、従来手法ではその時点で最も CV 率が高い物件を推薦するのに対し、提案手法では将来的な CV 率を含めて推薦する物件を決定する。

ここで説明した従来手法は、Richardson らの提案した CTR(Click Through Rate) 見積もり手法 [Richardson 07] に相当する。この手法は単語や広告をクラスタリングし、それぞれの CTR を見積もることで、新規の広告に対する CTR を推定する手法である。こうした Web 上での広告はページ閲覧中のユーザにとって最も CTR の高い広告を提示することが求められる。

5. 実験と結果

本章では、提案手法の有効性の評価を行う。Suumo のログデータを利用し、各ユーザの提案手法による CV 率、従来手法による CV 率を算出する。そしてそれぞれの手法の平均的な CV 率を比較することで、提案手法の方が従来手法より優れていることを示す。

5.1 実験方法

実験は対象データから、サイト内の初アクセスから最終アクセスを行ったユーザのうち、約 400 万ユーザを抽出して行った。まず、ユーザ、物件を分類するために 4.1 節で説明した通り、手作業でルールを作り、閲覧履歴の分類を行った。ルール

は物件の種類、所在地、価格に基づきそれぞれの所属する物件の量が同じくらいになるよう、東京都にある物件のみを対象とし、28 のカテゴリに分類するものを設定した。以後、この分類を物件カテゴリと呼ぶ。次に、ある物件カテゴリを閲覧中のユーザにとってその時点で最も高い CV 率を持つ物件カテゴリを算出する (従来手法)。さらにその時点より先の将来を含めた上で最も高い CV 率を持つ物件カテゴリを算出する (提案手法)。最後に算出された CV 率の比較を行う。ただし、提案手法は将来の $Future_c$ 回の閲覧で見込まれる CV 率を上乗せした形で算出しているため、比較する CVR は従来手法で推薦された物件の場合で、 $Future_c$ 回の閲覧で見込まれる CV 率を上乗せしたものとする。

比較の結果、提案手法の CV 率が高ければ、将来の CV を考慮した推薦手法がユーザの購買行動にとって有効であることが言える。

表 1 内の $p(\text{conversion} | History)$ は以下のように求める。また、従来手法と比較し、どれくらい CV 率が高いかを示すために $CVR\ ratio$ を以下のように求める。最後に、提案手法が従来手法と比較し、高い CV 率であることを示すために、使用したデータ内で $History$ を持つユーザ数と算出した CV 率を元に z 検定を行った。検定は、片側 $p = 0.05$ の有意水準で評価した。

$$p(\text{conversion} | History) = \frac{History[-1] \text{ で CV したユーザ数}}{History \text{ の閲覧履歴を持つユーザ数}}$$

$$CVR\ ratio = \frac{CVR(\text{提案手法})}{CVR(\text{従来手法})}$$

5.2 結果

結果を表 2 に示す。ここで、 $CVR(\text{従来手法})$ はその時点で最も CV 率が高い物件カテゴリを推薦する従来手法による結果、 $CVR(\text{提案手法})$ はその時点から $Future_c$ 回以内での CV する確率を上乗せした提案手法による結果を示している。それぞれ各カテゴリのページ閲覧中のユーザ ($History$ の項目) のユーザに対し、 c_i のカテゴリのページを推薦した場合の CV 率をまとめている。今回設定したカテゴリの数 $N(C) = 28$ なので、28 の結果があるが、ここでは $Future_c = 3$ の場合の $CVR\ ratio$ が高い上位 10 件を示した。提案手法はこの 28 個中 $Future_c = 2$ の場合で 12 個、 $Future_c = 3$ の場合で 14 個、検定の結果従来手法より有意に上回っていた。

それぞれの結果からわかったことを述べる。表の $Future_c = 3$ の結果で最も $CVR\ ratio$ の高い場合、物件カテゴリ 5 を閲覧中のユーザに、その時点で最も CV 率が高いと予想される物件カテゴリ 27 を提示するよりも、将来を含めた CV 率が最も高くなる物件カテゴリ 8 を推薦した方が、CV 率が 2.92 倍高くなることを示している。物件カテゴリ 5 は郊外の中古の高価格なマンション、27 は郊外の高価格な新築マンション、8 は郊外の高価格な新築戸建を表している。つまり、郊外で中古だが高額なマンションを探しているユーザは、実は中古の物件よりも新築の物件の方が購買意欲が高まり、特に新築の戸建を推薦する方が将来的な購買意欲を高めることができることを示している。ユーザに同一地域で別の領域の物件を推薦することで、地域の物件の相場を学ぶ機会を与えていると考えることができる。その他の結果を見ると、高額な物件を探すユーザには同一地域で、別の領域の物件を薦め、低額な物件を探すユーザにはより都心で同様の価格帯の物件、中古の物件を探しているユーザには郊外の新築の物件を推薦する傾向がみられた。

これらの結果から、ユーザが閲覧した履歴に対して、価格、地域、領域のいずれかのみを変えるような物件を推薦することが、ユーザの将来的な購買の可能性を高めていると考えられる。

表 2: 結果の一部 (*Future.c* = 3 の場合の *CVR ratio* が高い上位 10 件, “*” は $p=0.05$ で有意であることを示す.)

History	<i>Future.c</i> = 3		<i>Future.c</i> = 2		<i>CVR ratio</i>	<i>z test</i>
	c_i	<i>CVR</i> (従来手法)	c_i	<i>CVR</i> (提案手法)		
5	27	1.06%	8	3.09%	2.92	*
9	27	1.39%	26	3.57%	2.56	*
2	20	1.37%	16	2.95%	2.16	*
8	8	2.90%	5	5.42%	1.87	*
6	8	1.72%	4	2.44%	1.41	*
22	27	4.05%	21	5.59%	1.38	*
28	23	4.46%	19	5.26%	1.18	*
24	24	4.09%	23	4.62%	1.13	*
4	12	2.11%	9	2.36%	1.12	*
3	7	2.59%	6	2.89%	1.12	*

表 3: 平均 CV 率 (“*” は $p=0.05$ で有意であることを示す.)

	<i>Future.c</i> = 2	<i>Future.c</i> = 3
	平均 <i>CVR</i>	平均 <i>CVR</i>
従来手法	2.99%	3.55%
提案手法	3.48%	4.06% *
<i>CVR ratio</i>	1.16	1.14

次に、全体の平均の CV 率を表 3 に示す。 *Future.c* = 2, 3 どちらの場合の CV 率でも、提案手法の結果の方が有意に優れていることを示している。この結果は提案手法による推薦がユーザの CV 率向上に有効であることを示している。ただし、この実験では全ての遷移確率 *Transition.Rate*(*, *) = 1.0 としている。ユーザが推薦された物件のページに遷移する確率は、通常低い。

そこで、この遷移確率を変化させた場合のグラフを図 1 に示す。遷移確率 (*Transition Rate*) を低くするにつれ、従来手法と同様の CV 率を示すことがわかる。このため、表 2 の結果は提案手法の効果が最大限表れた場合の結果となる。

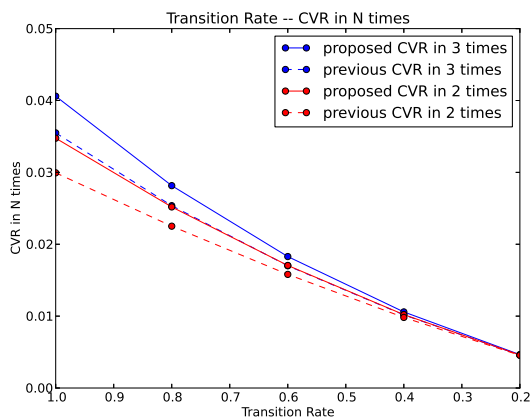


図 1: 推薦したページへの遷移確率と平均 CVR の変化。

6. 考察

本研究は検討期間の長い商品で、ユーザがさまざまな商品を比較検討するタイプの商材に対する推薦手法である。例として、買い回り品と総称される自動車、家電製品、家具などが考えられる。これらは今回評価した住宅と同様の購買行動が考えられ、本研究で提案した手法が有効に働くと考えられる。しかし、検討せずに購入する商品（極端に安いものや提供される機能に大差が無いもの）や提供する機能が商品によって異なる商材には有効ではないだろう。例として、最寄り品 (*Convenience goods*) [Melvin 23] と総称される日常的に購入する食品、雑貨、映画や本などのコンテンツ商品が考えられる。こうした商品を購入する場合に、ユーザは比較検討をしないので、従来手法による推薦と同等の結果になると考えられる。

本稿では、推薦によるページ遷移確率 (*Transition.Rate*) を一定と仮定している。今回の実験では *TransitionRate* = 0.4 以上のとき検定の結果が有意であった。そのため、推薦したページへユーザが遷移する確率が 40% 程度あれば提案手法は有効に働く。推薦するページへの遷移は推薦ページの提示方法や推薦物件の質に大きく依存するため、なるべく高くなるように調整することで、提案手法の効果を高めることができる。

今回の実験では、サイトの構造上現在は推薦システムが無く、推薦の結果に対する実際の遷移確率を得ることができなかった。ページ遷移の確率は推薦の品質にもよるため、推定が難しい。正確な推定手法を発明することでより実用的な効果を調査することができるだろう。

7. おわりに

本稿では、商品推薦によってユーザ自身に影響を与えることで、将来的な購入の可能性を上昇させる情報推薦手法を提案した。実験の結果、その時点で最も購買確率の高い商品を推薦する従来の手法と比較し、提案したアルゴリズムの方が平均で 1.14 倍高いことを示した。また、本稿で提案した手法は、検討期間の長い商材において、将来的な CV を考慮した推薦がユーザの購買の向上に有効に働くことを示した。特に推薦したページへの遷移確率が 40% 以上の場合、有効に働く。これによって、これまで商品が欲しいと思い、購入の検討を始めたが、商品に対するユーザ自身にとって重要な知識を獲得できず、購入を諦めてしまっていたユーザの需要を呼び起こすことが可能になるだろう。

参考文献

[Bobadilla 13] Bobadilla, J., Ortega, F., Hernando, A., and Gutiérrez, A.: *Recommender Systems Survey, Know.-Based Syst.*, Vol. 46, pp. 109–132 (2013)

[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)

[Lee 12] Lee, K.-c., Orten, B., Dasdan, A., and Li, W.: Estimating conversion rate in display advertising from past performance data, in *Proc. of SIGKDD*, pp. 768–776, ACM (2012)

[Linden 03] Linden, G., Smith, B., and York, J.: Amazon.com Recommendations: Item-to-Item Collaborative Filtering, *IEEE Internet Computing*, Vol. 7, No. 1, pp. 76–80 (2003)

[Melvin 23] Melvin, C., Thomas: Relation of Consumers' Buying Habits to Marketing Methods, *Harvard Business Review*, pp. 282–289 (1923)

[Richardson 07] Richardson, M., Dominowska, E., and Ragno, R.: Predicting clicks: estimating the click-through rate for new ads, in *Proc. of WWW*, pp. 521–530, ACM (2007)

[高玉 13] 高玉 圭樹, 佐藤 史盟, 大谷 雅之, 服部 聖彦, 佐藤 寛之, 山口 智浩 別カテゴリ商品提示による好みの明確化を促す推薦システム, *人工知能学会論文誌*, Vol. 28, No. 2, pp. 210–219 (2013)

[神島 07] 神島 敏弘 推薦システムのアルゴリズム (1), *人工知能学会論文誌*, Vol. 22, No. 6, pp. 826–837 (2007)

[神島 08a] 神島 敏弘 推薦システムのアルゴリズム (2), *人工知能学会論文誌*, Vol. 23, No. 1, pp. 89–103 (2008)

[神島 08b] 神島 敏弘 推薦システムのアルゴリズム (2), *人工知能学会論文誌*, Vol. 23, No. 2, pp. 248–263 (2008)

[村上 09] 村上 知子, 森 紘一郎, 折原 良平 推薦の意外性向上のための手法とその評価, *人工知能学会論文誌*, Vol. 24, No. 5, pp. 428–436 (2009)

[中辻 13] 中辻 真, 藤原 靖宏, 内山 俊郎, 戸田 浩之 動的なユーザ興味に対応したセマンティクスに基づく情報推薦手法, *人工知能学会論文誌*, Vol. 28, No. 6, pp. 457–467 (2013)