

協調フィルタリングと商品の購買間隔を考慮した 補正手法による商品推薦システムの提案

田端 佑介, 堤田 恭太, 生田目 崇

1. はじめに

近年では、店舗やサービスの利便性もしくは店舗の売上向上を目的として、顧客が興味をもつ商品を推定する商品情報推薦手法が盛んに取り挙げられている [1, 2]. その中で、協調フィルタリングによる商品情報推薦手法 [3-7] は、顧客が購入した商品に関連のある商品を推定する手法としてよく知られている。協調フィルタリングは、アイテムベース協調フィルタリングとユーザベース協調フィルタリングに大別される。いずれの手法も過去の購買履歴から、ユーザ間もしくはアイテム間の関連度を計算している。

ところがこの既存の協調フィルタリングを用いて繰り返して購買される商品を対象に推薦しようとする場合、筆者らは下記に示すような問題があると考えている。まず、

問題 1: 推薦商品に時間的な要素や顧客による購入間隔の特性を考えていない。

という問題が挙げられる。Xiong et al. [8] はユーザ、アイテムに時系列要素を入れた 3 次元データの行列分解による時点評価を考慮している。しかし、この問題 1 は、Xiong et al. が考慮した時系列のトレンドの評価だけでなく、むしろ顧客ごとの購買サイクルといったミクロの時間要素の考慮という点が個々の顧客に対する推薦においては重要ともいえる。たとえば、大容量の調味料を購入した直後に同じ種類の調味料を推薦しても購入されることは少ないと想定される。逆に、頻繁に購入するような商品であれば、直後の推薦は効果的

となる。こういう視点に立つと、この問題は、推薦商品のランキング計算のベースとなる商品間のルールや商品と顧客間のルールを定義したグラフや表を作成する際に時間的要素を排除しているために起こる。たとえば、顧客が購入したばかりの商品を再度推薦してしまう、もしくは別の商品にスイッチしてしまい前回購入してから日にちが長期間空いた場合でも、過去の購買履歴に拘った商品でも推薦してしまうといった場合もある。次に、

問題 2: 顧客数・推薦対象商品数が多く、更新頻度の高い商品推薦システムに不向きである。

という問題も挙げられる。この問題 2 は、ランキング生成に利用する購買データが更新されるたびにすべての分析をやり直す必要があることに起因する。顧客数・推薦対象商品数が多ければ購買関係の行列や商品間の関連を表すグラフもそれにつれて大きくなる。したがって、たとえば毎日もしくはユーザがログインするたびに商品の更新をするようなシステムでランキング更新する場合、それらに比例するように時間がかかる。

そこで本稿では、協調フィルタリングの一手法であり、グラフの構造的な特徴に基づいて類似度を求められる Random Walk with Restart (以下、RWR と表記する) [9-12] をベースに、更新頻度の高い商品推薦システムに対応し、顧客の購買間隔を考慮した手法を提案する。具体的には、再購入を行う可能性の高い購買間隔を考慮しながら推薦商品を決定的という処理を追加するために、顧客別購買間隔スコア (A) と全体的購買間隔スコア (B) をランキングに際して考慮する。これにより、RWR とグラフ構築をその都度やり直す代わりに、購買間隔を考慮して推薦商品をリランキングするだけでランキング更新する処理を行う。

2. 提案手法について

本節では時間間隔を考慮した提案手法について説

たばた ゆうすけ, つつみだ きょうた
(株) NTT データ技術革新統括本部 技術開発本部
〒 135-8671 東京都江東区豊洲 3-3-9
なまため たかし
中央大学理工学部
〒 112-8551 東京都文京区春日 1-13-27
受付 15.7.20 採択 15.11.16



図 1 提案手法の全体像

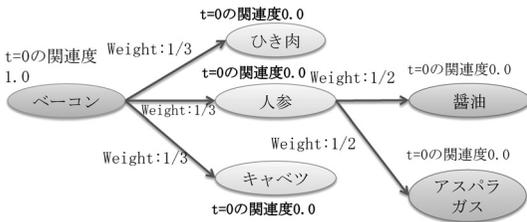


図 2 Random Walk with Restart (RWR) の模式図 ($t = 0$)

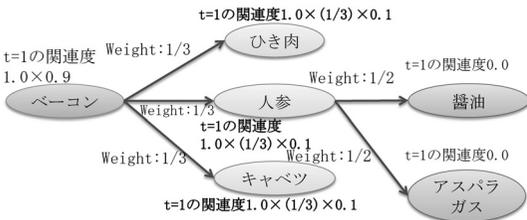


図 3 Random Walk with Restart (RWR) の模式図 ($t = 1$)

明する。提案手法の全体像を図 1 に示す。提案手法は STEP1, STEP2 のランキング生成部と STEP3, STEP4 のランキング補正部に分けられる。

2.1 Random Walk with Restart (RWR)

提案手法では図 1 の STEP1, STEP2 においてグラフ間のノードの関連性の強さを求める手法の一つである RWR (ItemRank [9] と同義) を用いて商品のランキングを生成する。なお、ランキング生成手法については、RWR に限らずランキングを生成できる協調フィルタリングの手法を用いることが可能である。本稿では実店舗の購買履歴データを分析に用いており、顧客が購入したことのない商品が数多く存在することから、RWR のデータ疎性に強い特性に着目し採用した。STEP1, STEP2 は図 2, 3 のようなイメージである。

最初に、商品の購入履歴データを用いて有向グラフを作成する (STEP1)。商品の購入履歴データはある期

間を指定して用い、商品を購入した顧客が同じ日に購入した二つの商品間を関連づける。ノードは商品であり、エッジの重みはノードの 2 商品の組合せを顧客が購入した回数を重みとした遷移確率を付与する。本稿では実店舗の購買履歴データ (POS データ) を用いており、商品に購入順序がなかったため、2 商品間に双方向のエッジを付与した。エッジの重みには 2 商品が同時に購入された回数があるノードから出ているすべてのエッジの重みの合計が 1 となるように重みの和で除算して付与した。

図 2, 3 の例では、「ベーコン」と「ひき肉」間のリンクの重みは「ベーコン」と「ひき肉」を同時に購入した回数を「ベーコン」が購入された回数で除したものとなる。「ベーコン」と「ひき肉」、「ベーコン」と「人参」、「ベーコン」と「キャベツ」がそれぞれ 1 回ずつ同時に購入されている場合、それぞれのエッジの重みは $1/3$ となる。

STEP2 の RWR は、グラフ上の起点となるノードからの各ノードの関連度を計算するアルゴリズムである。通常の Random Walk とは異なり、各ステップにおけるランダムリスタート確率と呼ばれる一定の確率 α ($0 < \alpha < 1$) に従って起点ノード a に値が付与されるという特徴がある。本稿では、直近に購入された商品群すべてを起点ノードとしている。起点ノード a から、 t ステップ後の各ノードの到達確率を表すベクトルを $\mathbf{p}^{(t)}$ 、グラフを表す隣接行列を \mathbf{A} 、 a に対応する要素の和が 1 でそれ以外を 0 とするベクトルを \mathbf{q} とし、式 (1) を再帰的に収束するまで繰り返し計算することにより得られた定常状態の確率を起点ノードからすべてのノードへの関連度とする。そして最終的に、この関連度が高い順に商品のランキングを生成する。

$$\mathbf{p}^{(t+1)} = (1 - \alpha)\mathbf{A}\mathbf{p}^{(t)} + \alpha\mathbf{q} \quad (1)$$

本稿では直近に購入した商品群を複数の起点ノード a に設定し、それらに関連の高い商品群を次回購入の推薦候補の商品として生成する。そのため、直近に購入した商品群が k 個の場合、ベクトル \mathbf{q} の対応する要素の値として $1/k$ を用いた。また、設定した直近 1 回分購入した商品群は、 \mathbf{p} で高い関連度が導出されるため推薦商品から除く。図 2, 3 の例では、はじめに、直近で購入された商品である「ベーコン」に関連度が割り当てられる (図 2)。 $t = 0$ の関連度は関連度計算の開始地点となるノードに割り当てられる関連度であり、「ベーコン」には初期の重み 1.0 が与えられる。次のス

トップ ($t = 1$) で、「ベーコン」に隣接している「ひき肉」、「人参」、「キャベツ」の関連度が計算される。RWR ではランダムリスタート確率に応じて、確率的に関連度における Random Walk の寄与を低くする計算が行われるため、これらの商品の関連度は「ベーコン」の関連度にエッジの重みとランダムリスタート確率を乗算して求められる。

図 3 の例では、ランダムリスタート確率が 0.9 と直近に購入した商品群がより重視され、相対的に Random Walk によって計算される関連度は確率 0.1 が乗算されて低く計算される。たとえば、「ひき肉」はその影響を受けたノードであり、関連度として $1.0 \times (1/3)$ に 0.1 (ランダムリスタート確率が 0.9 のため) が乗算される。また、「ベーコン」の関連度は、 1.0×0.9 と再度計算される。さらに $t = 2$ では、「アスパラガス」は「人参」の関連度 $1.0 \times (1/3) \times 0.1$ に、同様にエッジの重み $1/2$ と 0.1 が乗算される。このように関連度の計算はすべてのノードについて再帰的に収束するまで求められ、収束後の状態を定常状態として終了する。

実際の店舗の ID 付き POS データなどの購入データ量が多い場合、商品のランキングの生成は計算量が多く、計算に時間がかかるため、更新頻度の高いシステムにおいて STEP1, STEP2 はたとえば月 1 回単位での更新やセールス時のみに実行するなど、時間間隔を置いて計算する。

2.2 購買間隔スコアの算出手法

本節では、STEP3 における購買間隔スコアの計算方法について説明する。購買間隔スコアを考慮するメリットとしては、商品の購入間隔から、顧客が商品を購入する確率の高い時期に商品を推薦できることがある。全体的な購買間隔スコア (B) を考慮するメリットとしては、顧客に購入経験の少ない商品を推薦する場合、全体的な購買間隔から顧客が商品を再購入する時期を推測することで購買間隔のばらつきを抑えられる

点が挙げられる。購買間隔スコアは顧客ごとに商品購買データから商品を購入する間隔を集計する顧客別の購買間隔スコア (A) と全体的な購買間隔スコア (B) をそれぞれ算出する。顧客別の購買間隔スコア (A) は顧客ごとに商品購買データから商品を購入する間隔を集計しており、全体的な購買間隔スコア (B) は全顧客の商品購買データから集計する。「もやし」と「ごま油」について全体的な購買間隔 (B) の割合を集計したデータは図 4 のようになり、「もやし」は購入されてから比較的短期間で再購入される割合が高いが、「ごま油」はある程度期間が空いて再購入されることが見て取れる。このとき、購入回数が少ない商品についても購入間隔に応じた購買確率の推定が必要であるため、購入間隔の度数をカーネル密度関数で近似する。本稿で用いるカーネル密度関数 $p(x)$ を式 (2) に示す。

$$p(x) = \frac{1}{N} \sum_{i=1}^N \frac{1}{\sqrt{2\pi d^2}} \exp \left\{ -\frac{(x - x_i)^2}{2d^2} \right\} \quad (2)$$

ここで、 N は処理対象の購入間隔のサンプルサイズであり、 x_i は i 番目の処理対象の購入間隔で購入された回数 (度数) である。本稿では [13] に従い、バンド幅 d を式 (3) で表す。このバンド幅は筆者らが数パターン試し、経験分布との比較および自然な形になったものを選んだ。ただし、 σ は処理対象の購入間隔の度数についての標準偏差である。

$$d = \frac{1.06\sigma}{\sqrt[5]{N}} \quad (3)$$

なお、式 (3) は Silverman's rule-of-thumb bandwidth と呼ばれ、統計解析ソフトなどで広く使われる式である。

ある商品の購入頻度のカーネル密度関数での近似は図 5, 6 (商品はビール) のようになる。顧客別の購買間隔スコア (A) にあたる図 5 は推薦商品がある顧客が

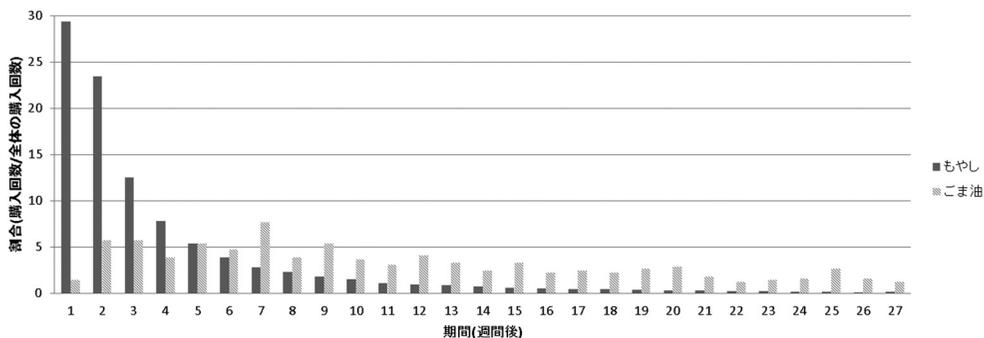


図 4 全体的な購買間隔 (B) の割合の集計

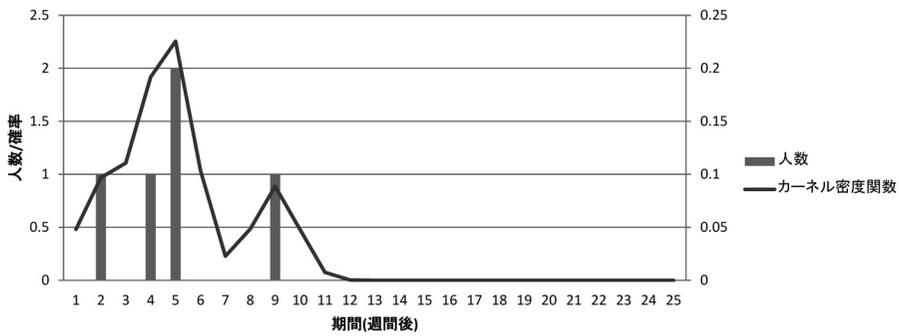


図5 顧客別の購買間隔 (A) の集計

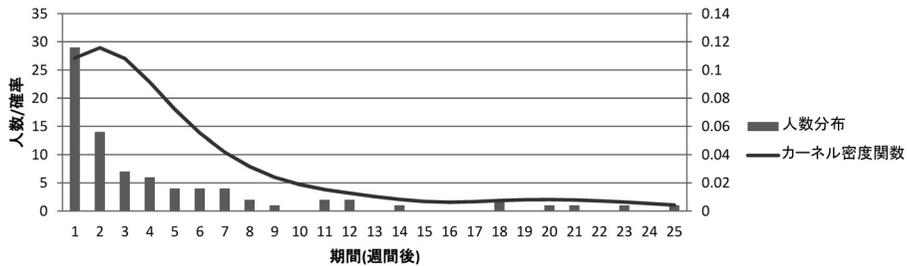


図6 全体的な購買間隔 (B) の集計

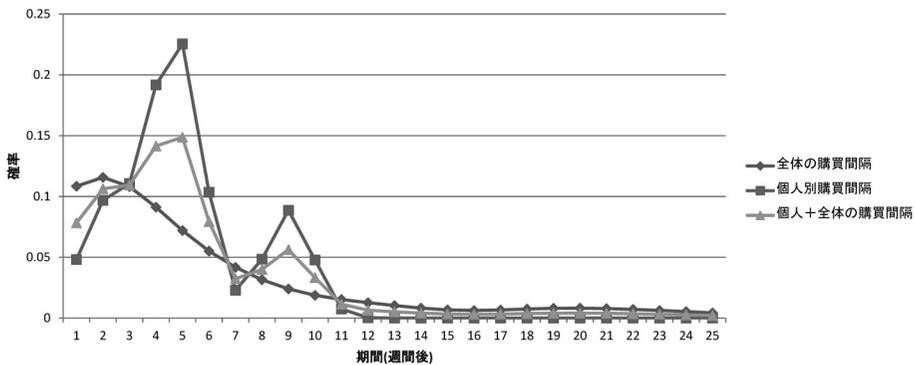


図7 購買間隔スコアの比較

購入した回数と購入期間の関係をヒストグラムにしたものであり、推薦商品を購入してから5週間後に再度購入する確率が高いことがわかる。このヒストグラムをカーネル密度関数で近似したのが図5のグラフであり、顧客の購入数が少なくデータのない購入期間を補完することができる。一方、全体的な購買間隔スコア(B)はある店舗で推薦商品を購入する顧客全員の購入した回数と購入期間の関係を表したものであり、推薦商品は一度購入してからすぐに再度購入する顧客が多いことがわかる。このヒストグラムをカーネル密度関数で近似したのが図6のグラフであり、ヒストグラムの購買間隔のばらつきを関数に近似することで抑えることができる。

リランキングは主に顧客別の購買間隔(A)と全体的な購買間隔スコア(B)を組み合わせで行う。顧客別の購買間隔(A)と全体的な購買間隔スコア(B)を加算した後、図7のように全体の割合が1となるよう平均化した。本稿では、顧客別の購買間隔(A)と全体的な購買間隔スコア(B)を単純に平均化しているが、ある顧客が顧客別の購買間隔(A)に近い購買間隔をしているのか、全体的な購買間隔スコア(B)に近い購買間隔をしているのかを分析することで、平均化のウェイトを変更することも可能である。この購買間隔スコアを用いてシステムは顧客が商品を再度購入している時期と店舗全体で商品が再度購入される時期に商品を推薦できる。商品の購買間隔スコアは、対象顧客がある商品

を購入してから経過した時期をもとに決定される。たとえば、ある顧客が商品 X を購入してから 3 週間が経過している場合、期間が 3 週間における購買間隔スコア（確率）が商品 X の購買間隔スコアとなる。また、同じ日に複数個同じ商品が購入される（まとめ買いされる）場合があるが、これらはまとめて 1 回商品が購入されたとして扱っている。

提案手法では、利用者の購買間隔を考慮してリランキングのみ毎日行うことで推薦商品が毎日更新される。

2.3 店舗別フィルタリング

本節では、STEP4 における店舗別フィルタリングについて説明する。店舗別フィルタリングは STEP3 により補正された商品の関連度を店舗の推薦に基づいて補正するプロセスである。たとえば、ある推薦商品は店舗が決定したセールス期間中に限り関連度を加算する処理を行う。この処理を行うことで店舗の意思決定を商品のランキングに反映できるとともに、推薦したくない商品をランキングから除外することができる。

ただし本稿では、店舗が売り出したい商品を特定することができなかったため、推薦したくない商品をランキングから除外する処理のみ行った。今回は、店舗によっては扱っていない商品のランキングからの除去（たとえば生花の販売実績がない店舗の場合、その店舗で生花の販売そのものをしていないとして関連度を 0 にする）や、重複商品の除去（たとえば豚バラ肉（大パック）と豚バラ肉（小パック）を同時に推薦する）を行った。

STEP3, STEP4 のランキング補正部は推薦対象商品すべてを計算する必要はなく、リランキングする推薦候補の商品のみを計算すればよい。また、関連度スコアを加味するのみで推薦商品を決定できるため計算量は少ない。したがって、更新頻度の高いシステムにおいても、ランキングの補正はたとえば毎日もしくはユーザがシステムにログインするタイミングに合わせて実行するなど、ランキング生成よりも高頻度に行うことになる。

3. 提案手法を用いたシステムの概要

2 節で説明した手法を用いた商品推薦システムについて説明する。システムは店舗の商品を推薦することを想定しており、その概念図を図 8 に示す。はじめに、顧客が購入した商品のデータはレジを通して購買データとしてデータベースに蓄積される。次に RWR による商品推薦手法によって商品のランク付けを行う。その後、2.2 節で提案した手法を行い、購買間隔による

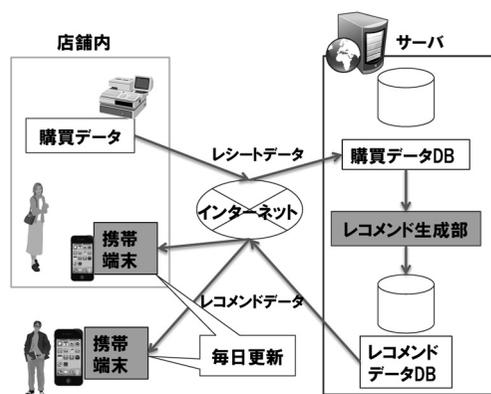


図 8 システムの全体像

推薦商品のリランキングを行う。最後に毎日リランキングされた推薦商品が顧客の携帯端末や店舗の端末に配信される。推薦商品は携帯端末のアプリケーションで配信するため毎日更新が必須である。

4. 提案手法の評価

本節では提案手法の評価について説明する。本稿ではコンペティションで提供された 10 店舗の購買データ¹を用いて評価を行った。1 年分の購買データのうち、前 11 カ月分のデータを訓練データとし、最後の 1 カ月分のデータについてランキング生成を行い、実際に購入されたかどうか確認を行った。使用したデータのレコード数（購入された商品数）は 18,626,994 件、顧客人数は 1,068,553 人、商品数（JAN コードでのユニーク数）は 279,320 個であり、顧客の 1 日の平均購入商品数は 8.59 個である。本稿ではデータの制約上、推薦された商品が最後の 1 カ月で購入されたかを評価しているが、実際にシステムを導入して顧客の行動に変化があったかは見ておらず、推薦システムとしてのレスポンスを直接的に測定したのではない。

4.1 レコメンドの評価

本稿では提案手法の評価を適合率 (Precision)、再現率 (Recall)、F 値 (F-measure) によって行った。適合率は推薦した商品数のうち、実際に購入される商品数の割合であり、推薦された商品の中で購入された商品数を T_p 、購入されなかった商品数を F_p として式 (4) のように表される。

¹ 本論文では、経営科学系研究部会連合協議会主催、平成 26 年度データ解析コンペティションで提供された全日本食品（株）の購買履歴データを用いた。

表 1 適合率による提案手法の評価結果

手法別の適合率	購入数/推薦数	平均適合率
STEP2 までの手法 (既存手法)	23494/64000	36.71%
A) 個人的な購買間隔のみ考慮 (提案手法)	23648/64000	36.95%
B) 全体的な購買間隔のみ考慮 (提案手法)	24678/64000	38.56%
STEP5 までの手法 (提案手法)	24992/64000	39.05%

表 2 再現率による提案手法の評価結果

手法別の再現率	購入数/実際購入数	平均再現率
STEP2 までの手法 (既存手法)	23494/79048	29.72%
A) 個人的な購買間隔のみ考慮 (提案手法)	23648/79048	29.92%
B) 全体的な購買間隔のみ考慮 (提案手法)	24678/79048	31.22%
STEP5 までの手法 (提案手法)	24992/79048	31.62%

$$Precision = \frac{T_p}{T_p + F_p} \quad (4)$$

再現率は実際に顧客が購入した商品数のうち、推薦された商品数の割合であり、推薦された商品の中で購入された商品数を T_p 、実際に購入されたが推薦されなかった商品数を N_p として式 (5) のように表される。

$$Recall = \frac{T_p}{T_p + N_p} \quad (5)$$

予測結果の評価尺度である F 値は適合率と再現率の調和平均で求められ、式 (6) のように表される。

$$F\text{-measure} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (6)$$

本稿では、既存手法 (STEP2 まで) と提案手法 (STEP5 まで) を用いて、顧客ごとに上位 5 商品の推薦対象を決定し、検証期間の最初の来店日の推薦商品を購入したか否かで適合率、再現率、F 値を求めた。本稿の提案システムでは、スマートフォンなど比較的小さい画面に推薦商品を表示することを想定しているため、5 品の推薦が表示の限界としてランキング上位 5 品を対象にした適合率の評価を行った。また、本論文で対象としている日用品に関してはあまり多くの商品を表示することは効果的でないと考えたためである²。ただし、提案手法では推薦商品の入れ替えを行うため、STEP2 時点で 10 品を推薦候補として抽出し、その中で、STEP5 までを経て上位となった 5 品を推薦対象と

² 全日本食品 (株) の現在の推薦方式は、各月の最初の購入時にその月に有効な推薦商品 20 品をレシート形式で表示している。

表 3 F 値による提案手法の評価結果

手法別の F 値	F 値
STEP2 までの手法 (既存手法)	32.85%
A) 個人的な購買間隔のみ考慮 (提案手法)	33.07%
B) 全体的な購買間隔のみ考慮 (提案手法)	34.50%
STEP5 までの手法 (提案手法)	34.94%

した。推薦商品を決定するための訓練データは 100,000 人分を用いており、評価として 12,800 人について推薦を行い、適合率を算出している。評価結果を表 1 から表 3 に示す。STEP2 までの既存手法の適合率 (推薦した商品中の購入数/推薦数) は 36.71% であり、STEP5 までの提案手法の適合率は 39.05% であった (表 1)。評価の結果、既存手法の推薦商品に購買間隔を考慮してリランキングすることで適合率の向上を確認した。また、STEP2 までの既存手法の再現率 (推薦した商品中の購入数/実際の購入数) は 29.72% であり、STEP5 までの提案手法の適合率は 31.62% であった (表 2)。再現率が既存手法、提案手法ともに高いのは、顧客が頻繁に購入する商品がよく推薦されており購入されているためである。手法別の F 値は既存手法が 32.85%、提案手法が 34.94% となった (表 3)。いずれの評価尺度も提案手法が既存手法よりも高く、リランキングの効果が確認できる。

4.2 カテゴリ別の適合率

ここで、既存手法と提案手法の推薦商品においてランキングごとの適合率を確認する。既存手法と提案手法のランキングごとの適合率は図 9 のようになった。

図 9 において既存手法のランキングは 1 位、2 位の適合率が 40% を超えており、全体の適合率である 36.7% を大きく上回っているが、ランキング 3 位、4 位、5 位

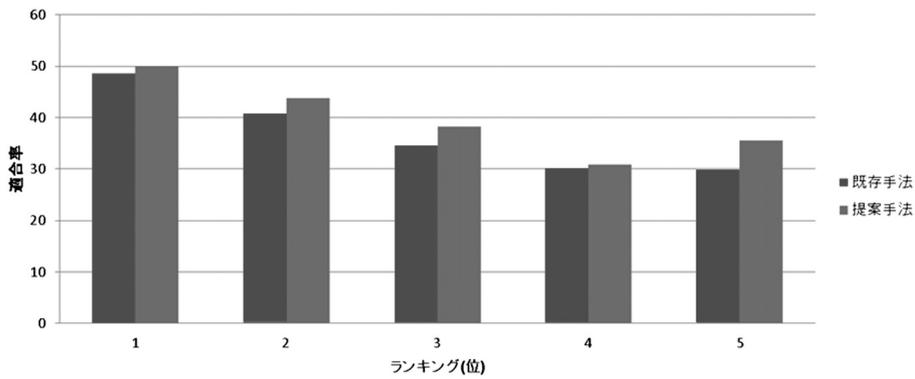


図9 ランキングごとの既存手法と提案方法の適合率の比較

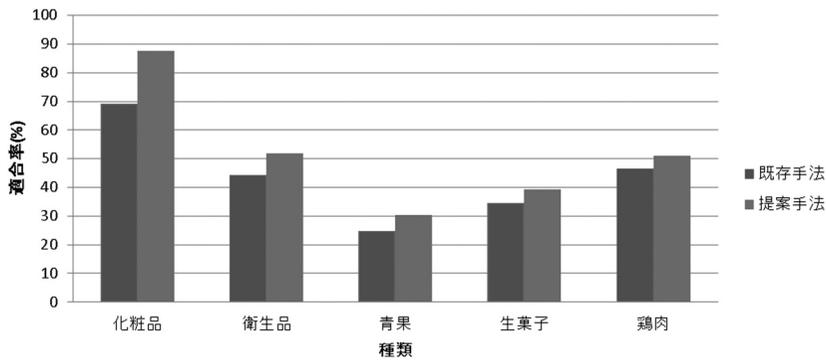


図10 適合率が上昇したカテゴリ別既存手法と提案手法の比較

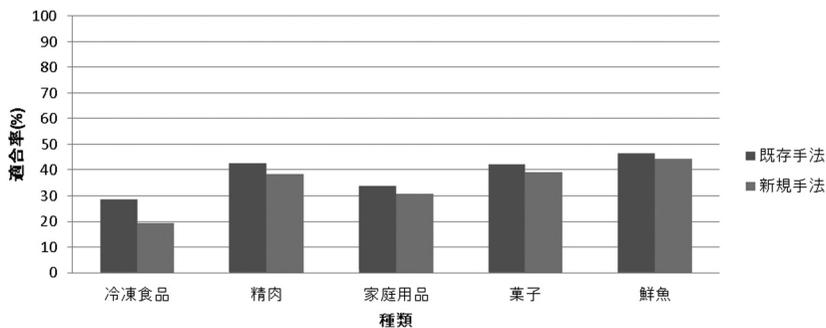


図11 適合率が下降したカテゴリ別既存手法と提案手法の比較

の適合率が全体を大きく下回っている。一方、提案手法のランキングは購入間隔を考慮する手法でランキング上位の商品がランキング下位の商品と入れ替わっており、ランキング下位の適合率が向上していることが確認できる。これは、STEP3において購入間隔を考慮することで、STEP2での6位以下の商品と順位が入れ替わった結果である。また提案手法は既存手法に比べ、すべてのランクにおいて適合率も高く、特に6位以下の商品との入れ替わることの多い5位の商品の適合率が最も向上した(図9)。

本節では商品カテゴリごとの適合率を評価する。購買データから商品をカテゴリ別に選定し、対象カテゴリの中から新たに推薦商品5品を選定した。既存手法と提案手法の適合率を比較して、適合率が上昇した上位5位のカテゴリが図10であり、適合率が下降した下位5位のカテゴリが図11である。

適合率が上昇したカテゴリは化粧品(保湿クリームなど)や衛生品(トイレットペーパーなど)が該当し、保湿クリームやトイレットペーパーなど消費するタイミングが推定しやすい商品の適合率が上昇した。また、

表4 既存手法のランキング

STEP2 時点の関連商品	購入有無
レギュラーバナナ	×
銘柄豚 ロース薄切り	○
てんさい糖	○
ほうれん草	×
銘柄豚 ロース切り身	×
ゴミ袋	○
ごまかりんと	×
ヨーグルト	○
リンゴ	○
醤油	×

適合率が上昇したカテゴリ3位の青果の中で仏花の上昇率が高かった。このような、比較的購入者が特定されやすく、また、購買間隔を推定しやすくプロモーション効果の小さな商品について、提案手法は有効であったといえる。一方、適合率が下降したカテゴリの1位は冷凍食品である。冷凍食品は購入者がまとめ買いして買い置きする場合も多く、購買間隔のばらつきが大きいため購入時期の推定がしづらいことが原因だと思われる。また、冷凍食品はセール日に値引き対象となりやすく、消費ニーズよりむしろ商品価格に購入が左右されやすい商品といえるため、購買間隔を評価しづらいということも考えられる。同じような理由で、3位の家庭用品（ゴム手袋など）に関しても消耗品ではないため、次回購入する時期が推定しにくいと考えられる。また、適合率が下降したカテゴリ5位の鮮魚は冷凍食品とは逆に、冷蔵庫などに長期間保存する商品ではなく、店舗で直接購入者が商品を見て決めるため、11カ月分の購買データがあってもどの種類の鮮魚が購入されやすいか予測しづらかったといえる。これらの問題に対しては、店舗での冷凍食品や鮮魚のセール日などがわかっていれば適合率を上昇させることができると考えられる。本節をまとめると、本手法は以下のような特徴があるといえる。

- ・消費サイクルが一定であることが想定される商品（保湿クリームやトイレットペーパーなど）は購買間隔が推定しやすい。
- ・購買間隔の推定が難しいものとして、長期保存・保管ができる商品（冷凍食品やゴム手袋など）がある。
- ・購買間隔を推定しがたい商品の対策としてはセール日を把握するなどが挙げられる。

4.3 リランキングの定性評価

ランキング補正の効果について定性評価を行うため、

表5 提案手法のランキング

STEP5 時点の関連商品	購入有無
銘柄豚 ロース薄切り	○
リンゴ	○
レギュラーバナナ	×
ゴミ袋	○
ほうれん草	×
ヨーグルト	○
てんさい糖	○
ごまかりんと	×
人参	×
醤油	×

ある顧客にどのような商品が推薦されているのか確認を行った。この顧客は北海道在住であり、全日本食品の北海道のある店舗にある月に10回来店し、合計で123商品を購入している顧客である。この顧客に既存手法（STEP2までの手法）を適用した推薦商品とその結果が表4であり、提案手法（STEP5までの手法）を適用した結果が表5である。表4のSTEP2までのランキングを見ると、推薦商品上位5品の適合率は40%となっている。しかし、ランキング上位にあるにもかかわらず購入されていない商品も多く、ランキング下位でも購入されている商品と入れ替えを行うべきといえる。これに対して、提案手法でリランキングを行った結果（表5）を見ると、推薦商品上位5品の適合率は60%に向上した。STEP3の購買間隔を考慮することで、STEP2においてランキングが下位の商品が、購入期間が適当でないと判定された上位ランキングの商品に変わって推薦商品となった。またSTEP2時点では、「銘柄豚 ロース薄切り」と「銘柄豚 ロース切り身」が推薦商品となっているが、STEP4で店舗別フィルタリングを行うことによって重複商品と認識され、ランキングが高い「銘柄豚 ロース薄切り」のみが推薦されることが確認できる。

5. 考察

本節では提案手法に関する考察を述べる。2.2節の購買間隔算出手法において、本稿では購入回数をカーネル密度関数で近似した。ただし、本稿のカーネル密度関数に限らず、たとえば指数分布、アーラン分布なども提案手法では利用できる。どの関数を選択するかは購買行動やシステムの利用形態にあわせて選択することができる。たとえば、商品を購入してから直近の時期に推薦商品としての評価を高く、商品を購入してから時間が経つと評価されないようにしたい場合、指

数分布を利用することが考えられる。

また、4.1 節の適合率による評価において、図 9 の提案手法のランキング 4 位の適合率よりランキング 5 位の適合率のほうが高かった。このような現象が起こった理由として、ランキング 5 位の商品は 6 位以下のランク外の商品とのスコアが近いことが多く、ランク外の商品との入れ替えが比較的起きやすく、また、既存手法のランク外の商品の購買確率が高かったため適合率が大きく向上したと考えられる。

4.2 節のカテゴリ別の適合率では、適合率が上昇したカテゴリと下降したカテゴリについて調査を行った。この結果から、商品の購買間隔が特定しにくい商品は本手法の適用が難しいと判明したが、各商品の購入間隔を調べた段階で、その分散が大きいカテゴリに関しては通常の推薦を適用するとより効果的だと考えられる。

筆者らは、購買行動を行う顧客が繰り返し同じ商品を購入し、定期的に商品が購入される傾向があることに着目し、繰り返して商品を購入する購買間隔を考慮した推薦手法を提案した。しかしながら、同じ商品の推薦数が多くなると顧客が通常は購買を想定しないような意外性のある商品、すなわちセレンディピティ [14] が失われてしまう可能性が考えられる。この問題に対して本稿では、前回顧客が購入した商品は推薦商品として推薦しておらず、ある一定期間に顧客が購入した商品を推薦しないことが対策として挙げられる。また、推薦商品のセレンディピティをある程度担保するため、顧客別の購買間隔 (A) だけではなく、全体的な購買間隔スコア (B) を購買間隔スコアに加味することで顧客が購入したことのない商品も推薦されやすいように工夫をしている。一方、本稿の評価データは実店舗を対象としているため、集客のためやシステムの利用率向上のためある程度顧客が普段購入している商品を推薦することも必要であり、実店舗の割引セールなどに対応して、いつどの商品を推薦するのか考慮することも重要である。たとえば、他店舗との競争がある地域で顧客の集客効果を高めるためなら、定常的に買われる牛乳や卵なども含めた購買の予測は重要であると考えられる。これらは実店舗の戦略に合わせて利用されるべきであり、A/B テストなどで実店舗の利益や来客数などでの効果を比較して、2.3 節の店舗別フィルタで除く処理が必要である。

本稿では提案システムで、推薦商品の表示画面を携帯端末とすることを想定しているため、5 商品の推薦が表示の限界としてランキング上位 5 商品を対象にした適合率の評価を行ったが、筆者らは推薦商品を 10 商

品としてランキング上位 10 商品を対象にした評価も行った。ところが、既存手法・提案手法ともにランキング下位の商品の適合率が低かったため、全体の適合率も低下してしまった。推薦数を増やした場合、購買間隔による補正は効果が薄れるため、再現率は上昇する一方で適合率は低下した。また本稿では、2.1 節の RWR の結果からランキング上位 10 商品を対象に提案手法を適用したが、筆者らは RWR の結果からランキング上位 20 品を対象に同じく提案手法の評価も試みた。ところが、RWR の結果で関連度に差が開いていたため、ランキング下位の商品 (特に 11 位以下) がランキング上位 5 品に代えて推薦されることが少なく、適合率もさほど上昇しなかった。

6. まとめ

本稿ではグラフベースの協調フィルタリングである RWR をベースに顧客の商品の購買間隔を考慮した商品推薦手法を提案した。商品の購買間隔はある商品を顧客が購入してから再購入にいたる時間間隔を確率として求めたものであり、顧客別の購買間隔スコア (A) と全体的な購買間隔スコア (B) の 2 種類のスコアを考慮した。本手法のメリットとしては、(1) 個々の顧客が商品を購入する確率の高い時期に商品を推薦できる、(2) 全体的な購買間隔から顧客が商品を再購入する時期を推測することでデータが少ない顧客の購買間隔のばらつきを抑えられる点が挙げられる。

提案手法について実際の購買データを使った評価の結果、既存手法と比較して提案手法の適合率、再現率、F 値とも向上を確認できた。また、購買間隔をランキング評価に考慮したことと、店舗別フィルタリングがランキングに影響を与えていることを確認した。ランクごとの適合率では、特にランキング下位の商品の適合率が上昇したことが判明した。また、ランキングの推移を確認したところ、提案手法は商品の推薦時期に合わせて多くの商品のランキングの入れ替えが成功しており、ランキング下位の商品でも購買間隔を考慮することで購買のタイミングを適切に評価できていることがわかった。

筆者らは、購買行動を行う顧客が定期的に商品を購入する傾向があることに着目し、購買間隔を考慮した推薦手法を提案した。定期的に購入される商品を推薦するため、推薦商品のセレンディピティが失われる問題があるが、反面、集客やシステムの利用率を向上・維持させる効果があると考えられる。また提案手法では、直近で購入した商品は推薦せず、全体的な購買間

隔スコア (B) を加味することで推薦商品のセレンディビティが低下する問題を対処しているともいえる。

本稿では購買の有無のみで商品間の関係を求めたが、顧客ごとに、同じカテゴリに属する商品でも、価格帯や商品のサイズによる嗜好差があることも想定される。したがって、今後の課題としては、価格情報などの商品に関する他の情報を加味した推薦方法の提案などが挙げられる。

謝辞 本分析は、経営科学系研究部会連合協議会主催「平成 26 年度データ解析コンペティション」で提供されたデータと、NTT ソフトウェアイノベーションセンタから提供されたグラフマイニングシステム (Grapon) を使用して行ったものである。関係各位に謝意を表す。

参考文献

- [1] 神高敏弘, “推薦システムのアルゴリズム (1)~(3),” 人工知能学会誌, **22**(6), pp. 826–837, 2007, **23**(1), pp. 89–103, 2008, **23**(2), pp. 248–263, 2008.
- [2] 市川裕介, “協調フィルタリングを用いたレコメンドサービスの導入事例と課題,” 情報処理, **48**, pp. 972–978, 2007.
- [3] T. Hofmann, “Collaborative filtering via Gaussian probabilistic latent semantic analysis,” In *Proceedings SIGIR’03*, pp. 259–266, 2003.
- [4] Y. Koren, “Factorization meets the neighborhood: A multifaceted collaborative filtering model,” In *Proceedings KDD’08*, pp. 426–434, 2008.
- [5] P. Resnick, N. Iacovou, M. Suchak, P. Bergstorm and J. Riedl, “GroupLens: An open architecture for collaborative filtering of netnews,” In *Proceedings CSCW’94*, pp. 175–186, 1994.
- [6] B. Sarwar, G. Karvpiš, J. Konstan and J. Reidl, “Item-based collaborative filtering recommendation algorithms,” In *Proceedings WWW’01*, pp. 285–295, 2001.
- [7] 岩永二郎, 鍋谷昂一, 梶谷悠, 五十嵐健太, “関心度と忘却度に基づくレコメンド手法—単調性制約付きレコメンドモデルの構築—,” オペレーションズ・リサーチ: 経営の科学, **59**, pp. 72–80, 2014.
- [8] L. Xiong, X. Chen, T. K. Huang, J. Schneider and J. G. Carbonell, “Temporal collaborative filtering with Bayesian probabilistic tensor factorization,” In *Proceedings SIAM International Conference Data Mining*, pp. 211–222, 2010.
- [9] M. Gori and A. Pucci, “ItemRank, A random-walk based scoring algorithm for recommender engines,” In *Proceedings IJCAI’07*, pp. 2766–2771, 2007.
- [10] L. Page, S. Brin, R. Motwani and T. Winograd, “The PageRank citation ranking: Bringing order to the web,” Technical Report, Stanford Digital Library Technologies Project, 1998.
- [11] 藤原靖宏, 中辻真, 鬼塚真, 喜連川優, “Random Walk with Restart に対する高速な Top-k 検索,” 情報処理学会論文誌データベース, AA11464847-4(2), pp. 25–34, 2011.
- [12] 堤田恭太, 中辻真, 内山俊郎, 戸田浩之, 内山匡, “アクセスログを用いたクロスドメイン環境における情報推薦,” 情報処理学会研究報告, 2012-IFAT-107(4), pp. 1–8, 2012.
- [13] B. W. Silverman, *Density Estimation for Statistics and Data Analysis*, Chapman and Hall, 1986.
- [14] J. L. Herlocker, J. A. Konstan, L. G. Terveen and J. T. Riedl, “Evaluating collaborative filtering recommender systems,” *ACM Transactions on Information Systems*, **22**, pp. 5–53, 2004.