

レコメンデーションに誘導されやすい顧客の抽出方式の拡張と評価

太田 光雄[†] 高山 肇[†] 村田 嘉利[†] 佐藤 永欣[†] 松本 謙治[†]
岩手県立大学ソフトウェア情報学部[†]

1はじめに

近年、売り上げの向上を目的とする「レコメンデーション」への注目が高まっている。これは、商品や顧客ごとの特性に注目して、購入される可能性が相対的に高い商品を、店側からプッシュ型サービスとして顧客側へお勧めするものである¹⁾。著者らの研究グループでは、レコメンデーションに誘導されやすい顧客の抽出方式を検討している。具体的には、頻出時系列パターン A→B に基づき A を既購入の顧客に B をレコメンドする際、吉兆度という尺度を用いることを提案している²⁾。本稿では、文献 2)の方式を拡張してレコメンド精度の向上を目指す。

2文献 2)の方式

2.1 分析単位

本研究では、データの単位として「品番」という概念を採用している。一部例外はあるが、品番とはデパート内の個々のお店、売場と考えて良い。本研究では、共同研究中のデパート X 社との協議より、個々の商品単位ではなく品番単位で議論を進めている。

2.2 参考期と誘導期

頻出する時系列パターン A→B は、時期によって変動し得る。そこで、パターンの前側として考える期間を「参考期」、後ろ側として考える期間を「誘導期」と呼んでいる。例えば、参考期を 3/1~5/31、誘導期を 7/1~8/31 としたときに、過年に頻出するパターン A→B を使うと、以下のことが考えられる。すなわち、夏期に直近の春期の購入履歴を基にしてレコメンデーションを実施することである。

2.3 偏り比 $D_{A \rightarrow B}$ と正規化偏り比 $ND_{A \rightarrow B}$

パターン A→B の順方向、逆方向の各発生回数 $m_{A \rightarrow B}$, $m_{B \rightarrow A}$ を用いて、著者らは、偏り比 $D_{A \rightarrow B}$ と正規化偏り比 $ND_{A \rightarrow B}$ を以下のように定義している。

$$D_{A \rightarrow B} = \frac{m_{A \rightarrow B}}{m_{B \rightarrow A}} \dots (1)$$

$$ND_{A \rightarrow B} = \frac{(m_{A \rightarrow B} - m_{B \rightarrow A})}{\max(m_{A \rightarrow B}, m_{B \rightarrow A})} \dots (2)$$

そして、 $D_{A \rightarrow B}$ や $ND_{A \rightarrow B}$ に基づき、順方向が逆方向より相対的に多い、方向の偏りが強めの頻出時系列パターンを用いたレコメンデーションに関する検討を進めている。

2.4 吉兆度

一般に、A→B が頻出時系列パターンであるとき、各顧客は参考期に A に加えて A, B 以外の品番 H_i ($i=1, \dots, n-2$; n は品番の総数) のいずれかでも購入していることが少なくない。そこで文献 2)では、参考期に A に加えてどの品番 H_i でも購入していると、誘導期に B で購入しやすいかを示す尺度として、以下の通り「吉兆度」を提案している。すなわち、ある参考期に品番 A かつ H_i で購入した顧客が、対応する誘導期に品番 B で

- 購入したという事実が発生した回数:

$Y_num(A \rightarrow B, H_i)$

- 購入しなかったという事実が発生した回数:

$N_num(A \rightarrow B, H_i)$

Extension and Evaluation of Expectable Customers Picking up Method in a Recommendation
†M. Ota, T. Takayama, Y. Murata, N. Sato, and K. Matsumoto(Faculty of Software and Information Science, Iwate Prefectural University)

とした上で、パターン A→B に対する品番ごとの吉兆度 $K(A \rightarrow B, H_i)$ は、

$$K(A \rightarrow B, H_i) = \frac{Y_num(A \rightarrow B, H_i)}{N_num(A \rightarrow B, H_i)} \dots (3)$$

ただし、右辺の分母分子がともに 0 の場合には、

$$K(A \rightarrow B, H_i) = 0 \dots (4)$$

分母のみ 0 の場合には、

$$K(A \rightarrow B, H_i) = \infty \dots (5)$$

2.5 顧客抽出とレコメンデーション

文献 2)では、吉兆度が相対的に上位にあり、レコメンデーション時に吉兆と見なして利用する品番のことを、「吉兆品番」と呼んでいる。そして、誘導期の B での購入のレコメンデーションを、参考期に A に加え吉兆品番で購入している顧客へ行なうことを提案している。

3 本稿での拡張

3.1 パターン発生数のカウント法の拡張

单一の顧客の参考期に A が $count(A)$ 回、誘導期に B が $count(B)$ 回登場する場合、パターン A→B の発生回数のカウント法としては、以下の四通りが考えられる。

表 1 単一の顧客ごとのパターン発生回数のカウント法

*1 binary(x)は、x があれば回数によらずに 1。なければ 0.

*2 count(x) = 品番 x での購入回数。トランザクション単位でカウントする。

*3 binary(A) = 1 の場合が以下の各値、binary(A) = 0 の場合、パターン A→B の発生回数は 0.

カウント法	参考期側 評価値	誘導期側 評価値	パターン A→B の 発生回数*
両側圧縮法	binary(A) ^{*1}	binary(B)	binary(B)
価値考慮法	count(A) ^{*2}	count(B)	<u>count(B)</u> <u>count(A)</u>
参考期圧縮法	binary(A)	count(B)	count(B)
誘導期圧縮法	count(A)	binary(B)	<u>binary(B)</u> <u>count(A)</u>

両側圧縮法は、参考期の品番 A、誘導期の品番 B の購入の有無のみを考慮する。価値考慮法は、参考期の A での購入 1 回が、誘導期での B での何回の購入に結びつくかを考慮する。参考期圧縮法、誘導期圧縮法はいずれも、両側圧縮法と価値考慮法の中間的なカウント法である。また、全顧客を通じてのパターン A→B の発生回数は、顧客ごとの発生回数の総和とする。文献 2)では参考期圧縮法を採用していたが、本稿では両側圧縮法と価値考慮法も導入し、三者相互の差異を検討する。なお、誘導期圧縮法は、X 社との打合せに基づき、レコメンデーション上の利用価値は高くないと考え、検討の対象外とする。

3.2 吉兆度を算出する粒度の改良

文献 2)では品番単位で吉兆度を算出しているが、細粒度過ぎてデータ量が充分となりにくい。そこで本稿では、品番群 G_j という単位を用いて粗粒度化し吉兆度を算出する。品番群とは、デパート側の組織構成に基づき、同一カテゴリに属する品番を 1 グループにまとめたものである。

3.3 吉兆度の算出式の改良

2.4 項の(5)式は、 $Y_num(A \rightarrow B, G_j)$ の値の大小による吉兆度の差異を表現できない。そこで吉兆度の算出式を

$$K(A \rightarrow B, G_j) = \frac{Y_{\text{num}}(A \rightarrow B, G_j)}{Y_{\text{num}}(A \rightarrow B, G_j) + N_{\text{num}}(A \rightarrow B, G_j)} \dots (6)$$

と変更する。ここで $Y_{\text{num}}(A \rightarrow B, G_j)$, $N_{\text{num}}(A \rightarrow B, G_j)$ は、パターン発生数のカウント法により変化させる。紙幅の都合により導出過程の詳細は省くが、表 2 の通りとする。

表 2 単一の顧客ごとのパターン $A \rightarrow B$ に対する品番群 G_j の Y_{num} と N_{num}

	$Y_{\text{num}}(A \rightarrow B, G_j)$	$N_{\text{num}}(A \rightarrow B, G_j)$
両側圧縮法	1	1
値考慮法	$\frac{\text{count}(B)}{(\text{count}(A) + \text{count}(G_j)) \times \frac{1}{2}}$	$\frac{\text{count}(A)}{(\text{count}(A) + \text{count}(G_j)) \times \frac{1}{2}}$
参考期圧縮法	$\text{count}(B)$	1

なお、全顧客を通じての Y_{num} と N_{num} は顧客ごとの値の総和とする。

4 実データを用いた分析

レコメンデーションの精度向上には、ルール抽出した過年の傾向が、レコメンデーションの実施年にも再現されることが望ましい。

4.1 頻出時系列パターンの再現性の分析

頻出時系列パターンのランクイング作成時に、サポート値をどう設定すれば過年の傾向が再現されやすいのかは、明らかではない。そこで、3.1 項で提案したカウント法ごとに、表 3 の三期間で「サポート値 - 3 年共通パターン数」特性を分析し平均した(図 1)。具体的には、以下の手順で分析を行った。

- Step1) サポート値を S_1 とし、偏り比と正規化偏り比のランクイングを 2006~8 年で年ごとに 100 位まで作成;
- Step2) 3 年間に共通するパターン数を数える;
- 上記のサポート値 S_1 を種々変えてみる。

表 3 分析期間

期間番号	参考期	誘導期
1	3/1~5/31	7/19~8/31
2	3/1~5/31	6/19~7/31
3	4/1~6/30	7/19~8/31




図 1 「サポート値 - 3 年間共通パターン数」特性

分析の結果、三つのカウント法とも山型の形状になった。そして、頂上になるときのサポート値は、いずれも 100 位までのランクイングを作成できる限界のサポート値(以降、「臨界サポート値」と呼ぶ)付近である。また、参考期圧縮法は他の二つと比べて、サポート値、3 年間共通パターン数とも高い値を取りやすい。

4.2 吉兆品番群の再現性の分析

吉兆品番群のランクイング作成時に、サポート値をどう設定すれば過年の傾向が再現されやすいのかは、明らかではない。そこで、表 3 の期間番号 1 で、「サポート値 - 順位再現の相関係数、再現される品番群数、再現されない品番群率」特性を分析した(図 2-3)。具体的には、以下の手順で分析を行

った。

- Step1) 両側圧縮法と参考期圧縮法で、臨界サポート値を用いた頻出時系列パターンランクイングから、3 年共通かつランクイング上位のパターンを三つずつ選択;
- Step2) サポート値を S_2 とした上で、種々変える;
- Step3) 2006,7 年学習データと 2008 年評価データの吉兆度順位を相対比較し、順位再現の相関係数、再現される品番群数、再現されない品番群率を算出;




図 2 「サポート値 - 順位再現の相関係数、再現される品番群数」特性




図 3 「サポート値 - 順位再現の相関係数、再現されない品番群率」特性

「順位再現の相関係数」、「再現される品番群数」、「再現されない品番群率」の三つのバランスを考慮すると、以下のことと言える。すなわち、各品番群の Y_{num} の値の相加平均を $\text{avg}(Y_{\text{num}})$ 、 Y_{num} の最大値を $\text{max}(Y_{\text{num}})$ とするとき、

$$\frac{1}{4} (\text{max}(Y_{\text{num}}) + 3 \times \text{avg}(Y_{\text{num}})) \dots (7)$$

周辺をサポート値とすると、比較的吉兆品番群が再現されやすい。

5まとめと今後の展望

本稿では、レコメンデーションに誘導されやすい顧客を抽出する方式²⁾を拡張した。そして、抽出されるルールの再現状況を、デパートの実データを用いて分析した。

今後の展望として、以下のことが考えられる: i) 値考慮法の場合の吉兆品番群の再現性の分析, ii) レコメンデーションを実施して、有効な結果を得ること。

参考文献

- 1) 土方嘉徳: 情報推薦・情報フィルタリングのためのユーザプロファイリング技術, 人工知能学会誌, Vol.19, No.3, pp.365-372, 2004.
- 2) 恵津森真仁, 高山毅, 村田嘉利, 佐藤永欣: レコメンデーションに誘導されやすい顧客の抽出方式と評価, 情報処理学会第 70 回全国大会 2T-7, 2008.