

契約期間を延ばすためのレコメンド法

岩田 具治[†] 斉藤 和巳[†] 山田 武士[†]

定額制サービスを提供しているオンラインストアが収益を上げるためには、ユーザの契約期間をできるだけ延ばすことが必要である。従来レコメンド法では、購入される確率を最大化するためにユーザの嗜好に合致する商品を提示する。しかしながら、従来法により必ずしも契約期間が延びるとは限らない。本研究では、定額制サービスを想定し、契約期間が延びる確率を最大にするレコメンド法を提案する。提案法では、まず契約期間の長いユーザに特徴的な購買パターンを抽出する。そして、抽出されたパターンと同じような購買行動になるように商品をレコメンドする。契約期間が延びることはユーザがサービスに満足した結果であるため、提案法はオンラインストアだけでなく、ユーザにとっても好ましいレコメンドである。携帯電話用漫画配信サイトのログを用い、提案法の有効性を示す。

Recommendation Method for Extending Subscription Periods

TOMO HARU IWATA[†], KAZUMI SAITO[†] and TAKESHI YAMADA[†]

Online stores providing subscription services need to extend user subscription periods as long as possible to increase their profits. Conventional recommendation methods recommend items that best coincide with user's interests to maximize the purchase probability, which does not necessarily contribute to extend subscription periods. We present a novel recommendation method for subscription services that maximizes the probability of the subscription period being extended. Our method finds frequent purchase patterns in the long subscription period users, and recommends items for a new user to simulate the found patterns. Since a longer subscription period is the result of greater user satisfaction, our method benefits users as well as online stores. We evaluate our method using the real log data of an online cartoon distribution service for cell-phone.

1. はじめに

オンラインストアにおけるビジネスモデルは従量制と定額制に大別できる。従量制では購入した商品の分だけ課金され、一方、定額制では購入した商品に関わらず、サービスを利用した期間の分だけ課金される。収益を増加させるためには、定額制の場合、ユーザにより長い期間契約してもらうことが必要である。従来のレコメンド法では、購入される確率を高くするためにユーザの嗜好に合致する商品を提示する^{3),4)}。従量制の場合、従来法によって購入確率が上がるため、収益増加が期待できる。しかし、定額制の場合、従来法によって必ずしも契約期間が延びるとは限らず、収益増加につながらない可能性もある。

本研究では、定額制サービスを想定し、契約期間が延びる確率を最大化するレコメンド法を提案する。提案法では、契約期間が長いユーザに特徴的な購買パ

ターンを見つけ、各ユーザがそのパターンと同様の購買行動をするように商品をレコメンドする。購買パターンを見つけるため生存時間解析の手法を用い、また、効果的なレコメンドを行うためユーザの嗜好を最大エントロピーモデルを用い推測する。契約期間が延びるということは、ユーザの満足度が高いことの結果であるため、契約期間を延ばすレコメンドは、オンラインストアの収益増加につながるだけでなく、ユーザにとっても好ましいことである。

契約期間の予測や解約するユーザの特定は、Churn Analysis と呼ばれ、生存時間解析やデータマイニングの手法を用いて研究されている²⁾が、これらの手法はレコメンドのために用いられていない。

2. 提案法

2.1 レコメンド法

提案法では、ユーザ u にレコメンドしたとき契約期間が延びる確率 $P(l|u, r(s_i))$ が最大になる商品 s をレコメンドする。

[†] 日本電信電話株式会社

NTT コミュニケーション科学基礎研究所

NTT Communication Science Laboratories

$$\hat{s} = \arg \max_{s_i \in S} P(l|u, r(s_i)), \quad (1)$$

ここで l は契約期間が延びるという事象, $r(s_i)$ は商品 s_i をレコメンドしたという事象を表す. レコメンドの候補は, 全商品 S ではなく一部の商品 (例えばそのユーザに購入されていない商品の集合) に限ってもよい.

レコメンドしたときに購入された商品を s_j とする. レコメンド $r(s_i)$ が購買行動 s_j に影響を与えない場合, レコメンド $r(s_i)$ は契約期間 l にも影響を与えないと一般に考えられる. そこで, s_j と u が与えられたとき, $r(s_i)$ と l は条件付独立であると仮定する. そのとき $P(l|u, r(s_i))$ は, 商品 s_j が購入されたときユーザ u の契約期間が延びる確率 $Q(l|u, s_j)$ と, 商品 s_i をレコメンドしたときユーザ u が商品 s_j を購入される確率 $R(s_j|u, r(s_i))$ とに分解できる.

$$\begin{aligned} P(l|u, r(s_i)) &= \sum_{s_j \in S} P(l, s_j|u, r(s_i)) \\ &= \sum_{s_j \in S} Q(l|u, s_j) R(s_j|u, r(s_i)). \end{aligned} \quad (2)$$

提案法では, まず契約ログと購買ログとから入力データを作成する. 次に, $Q(l|u, s_j)$ を生存時間解析の代表的手法である Cox 比例ハザードモデル¹⁾ を用い推定する. また, $R(s_j|u, r(s_i))$ を協調フィルタリングで使われる最大エントロピーモデル³⁾ を用い推定する. そして, $P(l|u, r(s_i))$ を計算し, 契約期間が延びる確率が最も高い商品をレコメンドする.

2.2 Cox 比例ハザードモデル

商品 s_j が購入されたときユーザ u の契約期間が延びる確率 $Q(l|u, s_j)$ をハザード関数から導く. ハザード関数は, ある期間まで契約しているユーザのうちその期間で解約するユーザの割合を表す. 一般に契約期間は購買履歴に依存すると考えられるため, ハザード関数を購買履歴の関数として表現する. 購買系列から得られるユーザ u のハザード関数を推定するための特徴量を $x(u)$ とする. 簡単のため $x(u)$ を列ベクトル $x = (x_1(u), x_2(u), \dots)^T$ で記述する. ここで $x_k(u)$ は $x(u)$ の k 番目の特徴量を表す. 次式で表される Cox 比例ハザードモデルをハザード関数として用いる.

$$h(t|x) = \lambda_0(t) \exp(\beta^T x), \quad (3)$$

ここで $\lambda_0(t)$ はベースラインハザード関数, β は未知パラメータ, β^T は β の転置を表す. ベースラインハザード関数とは, 特徴量がない場合 ($x = \mathbf{0}$) のハザード関数である. 推定値の大域的最適解が保証され, か

つ, $Q(l|u, s_j)$ を簡易な形で記述することができるため, Cox 比例ハザードモデルを採用する. 対数部分尤度を最大化することによってベースラインハザード関数を推定することなしに未知パラメータを推定することができる.

2.3 購入されたとき契約期間が延びる確率

ハザード関数を用い, ユーザ u に商品 s_j が購入されたとき契約期間が延びる確率 $Q(l|u, s_j)$ を導く. x をユーザ u の購買履歴, x_{+s_j} をそのユーザに新たに s_j が購入された後の購買履歴とする. 簡単のため, s_j が購入された後のユーザを u_{+s_j} と考える. 期間 t で u もしくは u_{+s_j} のどちらかが解約し, もう一方は契約中であるとする. 確率 $Q(l|u, s_j)$ は, 期間 t において解約したユーザが u である確率に等しく, その確率は期間 t における u および u_{+s_j} のハザード関数 $h(t|x)$ および $h(t|x_{+s_j})$ を用い記述できる.

$$\begin{aligned} Q(l|u, s_j) &= \frac{h(t|x)}{h(t|x) + h(t|x_{+s_j})} \\ &= \frac{1}{1 + \exp(-\beta^T(x - x_{+s_j}))}. \end{aligned} \quad (4)$$

購入されたときに契約期間が延びる確率 $Q(l|u, s_j)$ が最も高くなる商品 s_j をレコメンドしてもよいが, レコメンドしたとしてもその商品が購入されるとは限らない. 購入されなかった場合, レコメンドは契約期間を延ばすことができないため, レコメンドにより商品が購入される確率も考慮する必要がある.

2.4 レコメンドしたとき商品が購入される確率

商品 s_i をレコメンドしたときに, ユーザ u に s_j が購入される確率 $R(s_j|u, r(s_i))$ を推定する手法について述べる. レコメンドなしでユーザ u に商品 s_j が購入される確率を $R(s_j|u)$, $\sum_{j=1}^V R(s_j|u) = 1$ とする. 商品 s_i をレコメンドすることにより, しない場合に比べ商品 s_i が購入される確率は高くなると考えられる. レコメンドにより購入確率が γ 倍されるとすると

$$R(s_j|u, r(s_i)) = \begin{cases} \frac{\gamma}{Z(u, s_i)} R(s_i|u) & j = i, \\ \frac{1}{Z(u, s_i)} R(s_j|u) & j \neq i, \end{cases} \quad (5)$$

となる. ここで $\gamma \geq 1$, $Z(u, s_i) = 1 + (\gamma - 1)R(s_i|u)$ は正規化項である. γ はレコメンドの購買行動への影響度を表しており, オンラインストアでのレコメンドの提示法 (例えば位置や大きさ) などに依存する.

ユーザ u に商品 s_j が購入される確率 $R(s_j|u)$ を推定するために, 最大エントロピーモデルを用いる. 購買履歴から得られる商品 s_j がユーザ u に購入される確率を推定するための特徴量を $y_c(u, s_j)$ とする. このとき, ユーザ u に商品 s_j が購入される確率は

$$R(s_j|u) = \frac{1}{Z(u)} \exp\left(\sum_c \alpha_c y_c(u, s_j)\right), \quad (6)$$

となる。ここで $Z(u) = \sum_k \exp(\sum_c \alpha_c y_c(u, s_k))$ は正規化項、 y_c は c 番目の特徴量、 α_c はその特徴量に対応する未知パラメータである。

3. 実データを用いた実験

携帯電話用の漫画を配信するサイトにおけるログを用いて、提案法の評価を行った。このサイトにおいて、ユーザは毎月一定額を払い漫画を読む。なお、1つの漫画が複数巻あるものは同一の商品として扱い、単位時間を1日とした。ログの開始日は2004年8月16日、最終更新日は2005年10月28日であった。

3.1 Cox 比例ハザードモデルの評価

提案法は、購買履歴を利用することにより契約期間をより正確に予測することができることを仮定している。まず、この仮定の妥当性を調べるため、契約期間が購買履歴に依存すると仮定するCox比例ハザードモデルと、契約期間が購買履歴に依存しないと仮定するモデルの予測性能を比較した。Cox比例ハザードモデルで用いる特徴量として、商品 s_i の次に商品 s_j を購入したことがあれば1、なければ0をとるものを用いた。ここで全購買履歴中に10未満しか含まれない特徴量は省いた。

学習データとして、2005年6月30日まで、7月31日まで、8月31日までの3セットを用いた。テストデータとして、学習データの最終日において契約中であるユーザの2005年10月28日までのログを用いた。

評価尺度として平均対数部分尤度を用いた。平均対数部分尤度が高いモデルは予測性能が高い。表1にその結果を示す。Cox比例ハザードモデルのテストデータに対する平均部分尤度は履歴非依存モデルに比べ高く、購買履歴を使うことにより正確に契約期間を予測可能であることを示している。

3.2 最大エントロピーモデルの評価

最大エントロピーモデルを用いて推定したユーザ u に商品 s_j が購入される確率 $R(s_j|u)$ に関する評価を行った。最後に購入された商品が次の購買行動に影響を与えると考え、特徴量として1次マルコフを用いた。学習データとして、2005年6月30日まで、7月31日まで、8月31日までの3セットを用いた。このとき同一商品への遷移は省いた。テストデータは学習データの最終日から2005年10月28日までのデータで、同一商品への遷移、学習データ期間で発売されていない商品を含む遷移を省いたものを用いた。比較手法として一様分布、多項分布を用いた。多項分布の未

表3 ユーザシミュレーションアルゴリズム
Table 3 A user simulation algorithm.

1:	Set $t \leftarrow 0, u \leftarrow \phi$
2:	loop
3:	Sample $r_1 \sim \text{Bernoulli}(h(t \mathbf{x}))$
4:	if r_1 is success then
5:	break
6:	end if
7:	Sample $r_2 \sim \text{Bernoulli}(g)$
8:	if r_2 is success then
9:	if $u = \phi$ then
10:	Sample $s_j \sim \text{Multinomial}(R(s_j))$
11:	else
12:	$\hat{s} \leftarrow \arg \max_{s_i} P(l u, r(s_i))$
13:	Sample $s_j \sim \text{Multinomial}(R(s_j u, r(\hat{s})))$
14:	end if
15:	Set $u \leftarrow u_{+s_j}$
16:	end if
17:	Set $t \leftarrow t + 1$
18:	end loop
19:	Output t

知パラメータは最尤法により推定した。

評価尺度として平均対数尤度を用いた。表2にその結果を示す。一様分布、多項分布の場合に比べ、最大エントロピーモデルのテストデータに対する平均対数尤度は高く、次に購入される商品をより正確に予測でき、ユーザの嗜好をよりの確に捉えていると言える。

3.3 シミュレーションによる試算

提案法によるレコメンドの契約期間に与える効果を試算するため、定額制オンラインストアにおけるユーザ行動のシミュレーションを行った。ユーザ行動モデルは、2005年10月28日までのログから学習したCox比例ハザードモデル、最大エントロピーモデルをもとに構築した。このとき商品数は107であった。

表3に、ユーザの契約期間 t を生成するアルゴリズムを示す。ここで u は購買系列、 u_{+s_j} は商品 s_j 購入後の購買系列、 ϕ は空系列、 $\text{Bernoulli}(\theta)$ は成功確率 θ のベルヌーイ分布、 $\text{Multinomial}(\psi)$ は j 番目の要素の成功確率が ψ_j の試行回数1の多項分布を表す。まず、表3の行3から行4において、単位時間内でユーザが解約するかどうかを確率 $h(t|\mathbf{x})$ を用い決定する。次に行7から行8において、単位時間内で商品を購入するかどうかを確率 g を用い決定する。ここで g は契約期間 t に依らず一定と仮定した。最初に購入される商品は確率 $R(s_j)$ によって決定する(行10)。もしユーザが過去に購入したことがあれば、提案法によりレコメンドし(行12)、確率 $R(s_j|u, r(\hat{s}))$ により購入される商品を決定する(行13)。未知パラメータ $\lambda_0(t)$ 、 g 、 $R(s_j)$ は、ログデータを用い最尤法により推定した。

表 1 平均対数部分尤度.

Table 1 Average log partial likelihoods.

	2005/06/30		2005/07/31		2005/08/31	
	学習	テスト	学習	テスト	学習	テスト
履歴非依存モデル	-8.865	-9.845	-9.165	-9.465	-9.513	-9.904
Cox 比例ハザードモデル	-8.604	-9.129	-9.048	-9.351	-9.325	-9.798

表 2 平均対数尤度

Table 2 Average log likelihoods.

	2005/06/30		2005/07/31		2005/08/31	
	学習	テスト	学習	テスト	学習	テスト
一様分布	-4.317	-4.317	-4.394	-4.394	-4.454	-4.454
多項分布	-3.875	-4.263	-3.938	-4.673	-3.975	-4.454
最大エントロピーモデル	-3.554	-3.551	-3.581	-3.732	-3.605	-3.762

提案法を以下の 3 手法と比較した.

- **Q Recommend** 購入されたとき, 最も契約期間を延ばす確率の高い商品を Recommend する. この手法はユーザの嗜好を考慮しない.
 - **R Recommend** 最も購入される確率の高い商品を Recommend する. この手法は従来法と同じく購買確率が高い商品を Recommend する.
 - **No Recommend** 何も Recommend しない. 購入される商品はユーザの嗜好によって決定される.
- ユーザ数を $N = 100,000$, 最大契約期間を 365 日としたとき, 各手法の平均契約期間は図 1 のようになった. 提案法による Recommend により契約期間が最も延びている. また, Recommend の購買行動への影響度 γ が大きい場合, より契約期間を延ばすことができる. Q Recommend も契約期間を延ばしているが, 提案法に比べ小さい. これは Q Recommend は購入される確率がない商品も Recommend しているためと考えられる. R Recommend も同様に契約期間を延ばしているが, 購買確率を高くすることが目的であるため, 提案法に比べ契約期間を延ばす効果が小さい.

4. まとめ

契約期間を延ばすための Recommend 法を提案し, 携帯電話用漫画配信サイトにおけるログデータを用い提案法の有効性を示した. 提案法は, 契約期間を推定する部分と, ユーザの嗜好を推定する部分に分かれているため, 生存時間解析および協調フィルタリングなどの手法を応用することが可能である. 例えば, 嗜好を推定するためにコンテンツフィルタリングを組み合わせることや, 高次のマルコフ遷移や, ユーザ属性などの特徴量を組み込むことが考えられる.

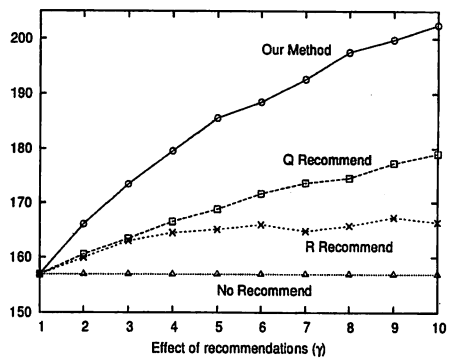


図 1 平均契約期間

Fig. 1 Average subscription periods.

参考文献

- 1) Cox, D. R.: Regression Models and Life-Tables, *Journal of the Royal Statistical Society, Series B*, Vol. 34, No. 2, pp. 187-220 (1972).
- 2) Mani, D. R., Drew, J., Betz, A. and Datta, P.: Statistics and data mining techniques for lifetime value modeling, *Proceedings of the Fifth ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pp. 94-103 (1999).
- 3) Pavlov, D. Y. and Pennock, D. M.: A maximum entropy approach to collaborative filtering in dynamic, sparse, high-dimensional domains, *Proceedings of Neural Information Processing Systems*, pp. 1441-1448 (2002).
- 4) Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P. and Riedl, J.: Grouplens: an open architecture for collaborative filtering of netnews, *Proceedings of the ACM Conference on Computer Supported Cooperative Work*, pp. 175-186 (1994).