

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あげるためには、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。生存時間解析を応用し、ログデータから効率的に購買パターンの抽出を行う。また、効果的なレコメンドにするため、最大エントロピーモデルを用いてユーザの嗜好を推定する。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. Using survival analysis techniques, we efficiently extract information from the log data for finding the patterns. Furthermore, we infer user's interests from purchase histories based on maximum entropy models, and use the interests to improve the recommendations. 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かかわらず、サービスを利用した期間の分だけ課金される。定額制は、サブスクリプションサービスとも呼ばれ、近年、音楽、テレビ番組、映画、ソフトウェア、携帯電話サービスなど様々なオンラインストアで導入されている。収益を増加させるためには、従量制の場合、ユーザにより多くの商品を購入してもらうことが必要であり、一方、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。つまり、従量制と定額制では、オンラインストアがユーザに望む行動が異なる。

レコメンドはユーザの利便性を向上させるとともに収益の増加につながるため、多くのオンラインストアで用いられている¹⁷⁾。レコメンドはオンラインストアにとってユーザの購買行動に影響を与える1つの手段である。上述のように、従量制と定額制ではユーザに望む行動が異なるため、異なる戦略でレコメンドする必要があると考えられる。従来レコメンド法では、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^{5),9),12),13),15)}。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。

[†] 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, NTT Corporation

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、生存時間解析の手法を用いて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。また、ユーザの嗜好と合致しない商品をレコメンドしても効果はないため、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。定額制の場合、ユーザが生涯を通じてもたらす利益を表す顧客生涯価値は契約期間に比例する⁸⁾。そのため、提案法は顧客生涯価値を最大化するレコメンド法ということもできる。

以下の本文では、まず 2 章で関連研究について述べる。3 章では本研究で提案する契約期間を延ばすためのレコメンド法について詳述する。さらに 4 章で携帯電話用漫画配信サイトにおけるログを用い提案法の有効性を検証する。最後に 5 章で結論と今後の課題を示す。

2. 関連研究

レコメンド法として、協調フィルタリング^{12),15)}、コンテンツフィルタリング⁹⁾、および、そのハイブリッド方式^{5),13)} など数多く提案されている。協調フィルタリングでは、似た嗜好を持つ他のユーザの情報を用いて嗜好を推定する。また、コンテンツフィルタリングでは、商品情報を利用して嗜好を推定する。これらの手法は購入される確率を上げるために、ユーザの嗜好と合致する商品をレコメンドするものであり、契約期間を延ばすためのレコメンドである提案法とは目的が異なる。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^{1),7),8),10),16),18)} 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。

3. 提案法

本研究では、レコメンドしたときに契約期間が延びる確率が最大となる商品を提示するレコメンド法を提案する。以下に、提案法の詳細を述べる。

3.1 準備

定額制サービスを提供するオンラインストアで入手可能なログとして、契約ログと購買ログがある。契約ログとは、各ユーザの契約開始時刻、契約状況（契約

表 1 契約ログの例

Table 1 An example subscription log.

ユーザ	契約状況	契約開始時刻	解約時刻
u_1	1	2004/8/16 11:50	2005/01/08 20:14
u_2	0	2004/8/16 18:01	
u_3	1	2004/8/17 16:10	2004/08/25 13:01
u_4	1	2004/8/17 21:39	2004/08/29 07:21
u_5	0	2004/8/18 01:44	
\vdots	\vdots	\vdots	\vdots
u_N	0	2005/10/28 23:10	

表 2 購買ログの例

Table 2 An example purchase log.

ユーザ	商品	時刻
u_1	s_3	2004/8/16 12:06
u_1	s_1	2004/8/16 13:01
u_2	s_2	2004/8/16 18:51
u_1	s_6	2004/8/16 21:35
u_3	s_2	2004/8/17 16:42
\vdots	\vdots	\vdots
u_N	s_{10}	2005/10/28 23:15

中か解約済みか)、解約済みの場合の解約時刻のログである。表 1 に契約ログの例を示す。購買ログとは、各購買のユーザ、時刻、商品のログである。表 2 に購買ログの例を示す。

ユーザ集合を $U = \{u_n\}_{n=1}^N$ 、商品集合を $S = \{s_i\}_{i=1}^V$ 、ユーザ u_n の契約期間を t_n 、契約状況を e_n (解約済みの場合 $e_n = 1$ 、契約中の場合 $e_n = 0$) とする。契約期間 t_n は、契約ログから得ることができる。ユーザ u_n の契約開始時刻を d_n^{start} 、解約済みの場合の解約時刻を d_n^{end} 、ログの最終更新時刻を d_{end} とする。このとき契約期間は

$$t_n = \begin{cases} d_n^{end} - d_n^{start} & \text{if } e_n = 1, \\ d_{end} - d_n^{start} & \text{if } e_n = 0, \end{cases} \quad (1)$$

となる。

各ユーザを購買系列 $u_n = \langle s_1^n, s_2^n, \dots \rangle$ 、 $s_k^n \in S$ として表現する。ここで s_k^n はユーザ u_n が k 番目に購入した商品を表す。購買系列 u_n は購買ログから得ることができる。契約期間を推定する際に、購買履歴は時間依存変数として扱う必要があるため、各商品が購入されたときの契約期間の情報も利用する。表 3 に提案法の入力データの例を示す。

3.2 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 \hat{s} をレコメンドする。

表 3 入力データの例
Table 3 An example input data.

ユーザ	契約状況	契約期間	購買商品 (購買時の契約期間)
u_1	1	145	$s_3(0), s_1(0), s_6(1), \dots$
u_2	0	438	$s_2(0), s_8(3), s_1(5), \dots$
u_3	1	8	$s_2(0), s_{13}(7)$
u_4	1	12	$s_3(0), s_1(2), s_2(12)$
u_5	0	411	$s_5(0), s_1(0), s_8(2), \dots$
\vdots	\vdots	\vdots	\vdots
u_N	0	0	$s_{10}(0)$

$$\hat{s} = \arg \max_{s_i \in S} P(l|u, r(s_i)), \tag{2}$$

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 (たと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 $r(s_i)$ は購買行動 s_j に影響を与え, 購買行動 s_j は契約期間 l に影響を与える, すなわち, 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商品 s_j がユーザ u に購入される確率 $R(s_j|u, r(s_i))$ とに分解できる.

$$\begin{aligned} P(l|u, r(s_i)) &= \sum_{s_j \in S} P(l, s_j|u, r(s_i)) \\ &= \sum_{s_j \in S} Q(l|u, s_j)R(s_j|u, r(s_i)). \end{aligned} \tag{3}$$

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 $R(s_j|u, r(s_i))$ も考慮する必要がある.

図 1 に提案法の流れを示す. 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を用い推定する. そして, 式 (3) に従い $P(l|u, r(s_i))$ を計算し, 式 (2) にあるようにレコメンドしたとき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.

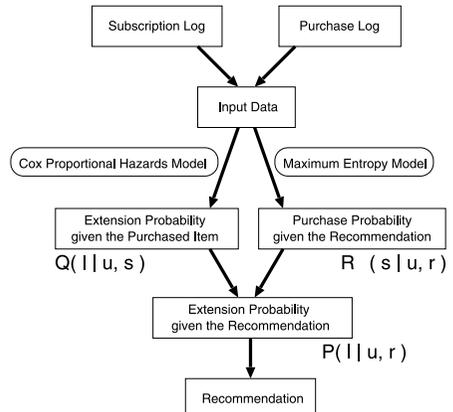


図 1 提案法の流れ
Fig. 1 The framework of our method.

3.3 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. ユーザが契約中の場合は解約時刻が得られないため, 真の契約期間は分からない. このようなデータは打ち切りデータと呼ばれる. 生存時間解析³⁾の手法を用いることにより, 打ち切りデータに含まれる情報も有効に活用しハザード関数を推定できる.

一般に契約期間は購買履歴に依存すると考えられる. その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. $x(u)$ の具体例は 4.1 節で示す. 次式で表される Cox 比例ハザードモデル⁴⁾ をハザード関数として用いる.

$$h(t|x) = \lambda_0(t) \exp(\beta^T x), \tag{4}$$

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

ザード関数は、特徴量がない場合 ($\mathbf{x} = \mathbf{0}$) のハザード関数である。後述のように、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。 β が大きくなるほどハザード関数の値も大きくなるため、低い β (< 0) を持つ特徴量は契約期間の長いユーザに特徴的なパターンであり、また、高い β (> 0) を持つ特徴量は契約期間の短いユーザに特徴的なパターンであることが分かる。

Cox 比例ハザードモデルの Breslow 近似による対数部分尤度³⁾ は次式で表される。

$$\begin{aligned} PL(\beta) &= \log \prod_t \frac{\prod_{n \in D(t)} h(t|\mathbf{x}_n(t))}{(\sum_{m \in R(t)} h(t|\mathbf{x}_m(t)))^{|D(t)|}} \\ &= \sum_t \sum_{n \in D(t)} \beta^T \mathbf{x}_n(t) \\ &\quad - \sum_t |D(t)| \log \sum_{m \in R(t)} \exp(\beta^T \mathbf{x}_m(t)), \end{aligned} \quad (5)$$

ここで $D(t)$ は期間 t で解約したユーザの集合 ($D(t) = \{n|t_n = t, e_n = 1\}$)、 $|D(t)|$ は集合 $D(t)$ の要素数、 $R(t)$ は期間 t で契約しているユーザの集合 ($R(t) = \{n|t_n \geq t\}$)、 $\mathbf{x}_n(t)$ は期間 t におけるユーザ u_n の特徴ベクトルを表す。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。対数部分尤度は未知パラメータに関して上に凸であるため、準ニュートン法⁶⁾ などの最適化手法により最大化することで、大域的最適解を推定することができる。

3.4 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。 \mathbf{x} をユーザ u の購買履歴、 \mathbf{x}_{+s_j} をユーザ u に新たに s_j が購入されたときの購買履歴とする。簡単のため、 s_j が購入されたときのユーザを 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 $h(t|\mathbf{x})$ および $h(t|\mathbf{x}_{+s_j})$ を用いて記述できる。

$$\begin{aligned} Q(l|u, s_j) &= \frac{h(t|\mathbf{x})}{h(t|\mathbf{x}) + h(t|\mathbf{x}_{+s_j})} \\ &= \frac{1}{1 + \exp(-\beta^T(\mathbf{x} - \mathbf{x}_{+s_j}))}. \end{aligned} \quad (6)$$

Cox 比例ハザードモデルを仮定しているため、

$Q(l|u, s_j)$ は期間 t によらず、更新された購買履歴のみをパラメータとして持つシグモイド関数により記述される。

3.5 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 に商品 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

$$R(s_j|u, r(s_i)) = \begin{cases} \frac{\gamma}{Z(u, s_i)} R(s_i|u) & j = i, \\ \frac{1}{Z(u, s_i)} R(s_j|u) & j \neq i, \end{cases} \quad (7)$$

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 (たとえば位置や大きさ) 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。最大エントロピーモデルは、与えられたデータに関する制約を満たす確率分布のなかでエントロピーが最大となるものを求める手法であり、協調フィルタリング^{5),12),19)} だけでなく、自然言語処理^{11),14)} など幅広い応用分野で使用されている。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。 $y_c(u, s_j)$ の具体例は 4.2 節で示す。このとき、ユーザ u に商品 s_j が購入される確率は

$$R(s_j|u) = \frac{1}{Z(u)} \exp\left(\sum_c \alpha_c y_c(u, s_j)\right), \quad (8)$$

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。

最大エントロピーモデルにおける対数尤度は次式で表される。

$$\begin{aligned} L(\alpha) &= \sum_n \sum_k \log R(s_k^n | u_k^n) \\ &= \sum_n \sum_k \sum_c \alpha_c y_c(u_k^n, s_k^n) \\ &\quad - \sum_n \sum_k \log \sum_j \exp\left(\sum_c \alpha_c y_c(u_k^n, s_j)\right), \end{aligned} \quad (9)$$

ここで s_k^n はユーザ u_n に k 番目に購入された商品、 u_k^n は k 番目の商品が購入される前までの u_n の購買

履歴を表す．未知パラメータは，準ニュートン法などの最適化手法を用い対数尤度を最大化することにより推定できる．なお，最大エントロピーモデルでは大域的最適解を得ることができる．過学習を抑えるため，実験では，未知パラメータの事前分布として平均 0 の正規分布を用いた²⁾．

3.6 レコメンドしたとき契約期間が延びる確率

提案法ではレコメンドしたときに契約期間が延びる確率が最大となる商品 \hat{s} を提示する．3.4 節の $Q(l|u, s_j)$ および 3.5 節の $R(s_j|u)$ ， γ を用いると，レコメンドする商品は次式で表される．

$$\hat{s} = \arg \max_{s_i \in S} \frac{1}{Z(u, s_i)} \left(\sum_j R(s_j|u) Q(l|u, s_j) + (\gamma - 1) R(s_i|u) Q(l|u, s_i) \right). \quad (10)$$

従来法では購買確率 $R(u|s_j)$ が最も高い商品，つまり嗜好と最も合致している商品をレコメンドする¹²⁾．提案法は購買確率 $R(u|s_j)$ を契約期間を延ばす効果 $Q(l|u, s_j)$ で重み付けしたものが最大となる商品をレコメンドする手法と見なすこともできる．

4. 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，ユーザは月ごとに一定額を払い漫画を読む．契約ログ，購買ログが存在し，オンラインストアにとってユーザの契約期間を延ばすことが望まれるビジネスモデルであるため，提案法が適用可能である．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．

4.1 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，3.3 節で述べた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 $h(t|x) = \lambda_0(t) \exp(\beta^T x)$ と，契約期間が購買履歴に依存しないと仮定するモデル $h(t) = \lambda'_0(t)$ 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以下のものを用いた．

- F1: ユーザ u は商品 s_i を購入したことがあるか (商品の unigram)，

$$x_{s_i}(u) = \begin{cases} 1 & \text{if user } u \text{ has purchased} \\ & \text{item } s_i, \\ 0 & \text{otherwise,} \end{cases}$$

- F2: ユーザ u は商品 s_i かつ商品 s_j を購入したことがあるか (要素数 2 の商品集合)，

$$x_{s_i, s_j}(u) = \begin{cases} 1 & \text{if user } u \text{ has purchased} \\ & \text{item } s_i \text{ and item } s_j, \\ 0 & \text{otherwise,} \end{cases}$$

- F3: ユーザ u は商品 s_i の次に商品 s_j を購入したことがあるか (商品の bigram)，

$$x_{s_i \rightarrow s_j}(u) = \begin{cases} 1 & \text{if user } u \text{ has purchased} \\ & \text{item } s_j \text{ next to item } s_i, \\ 0 & \text{otherwise,} \end{cases}$$

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．表 4 に特徴量数，表 5 に学習データおよびテストデータの契約ユーザ数，解約ユーザ数を示す．

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 6 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い．また，購買の順序を考慮した特徴量 (F3) のテストデータに対する平均部分尤度が最も高く，購買順序は契約期間を予測する際に有用な情報となることを示唆している．2005 年 10 月 28 日までのログを用いて 10-fold クロスバリデーションを行った結果，図 2 のようになった．Cox 比例ハザードモデル (F3) は履歴非依存モデルに比べ平均対数部分尤度が高く，購買履歴を使うことで，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．

4.2 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，特徴量として以下の 1 次マルコフを用いた．

表 4 特徴量数

Table 4 The number of features.

	2005/06/30	2005/07/31	2005/08/31
Cox 比例ハザードモデル (F1)	75	80	84
Cox 比例ハザードモデル (F2)	2,671	3,159	3,485
Cox 比例ハザードモデル (F3)	3,711	4,455	5,250

表 5 契約ユーザ数と解約ユーザ数

Table 5 The number of subscribers and unsubscribers.

	2005/06/30		2005/07/31		2005/08/31	
	学習	テスト	学習	テスト	学習	テスト
契約ユーザ数	13,284	7,221	14,669	9,608	28,409	17,028
解約ユーザ数	4,988	6,063	8,802	5,061	9,765	11,381

表 6 平均対数部分尤度

Table 6 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 (F1)	-8.727	-9.205	-9.048	-9.445	-9.415	-9.812
Cox 比例ハザードモデル (F2)	-8.709	-9.179	-9.029	-9.422	-9.325	-9.839
Cox 比例ハザードモデル (F3)	-8.604	-9.129	-9.048	-9.351	-9.325	-9.798

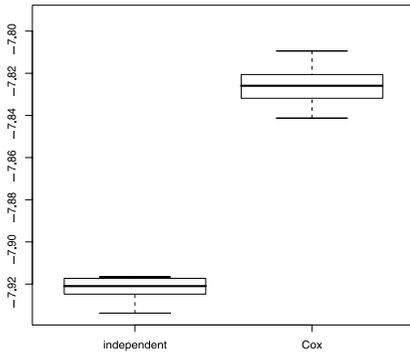


図 2 10-fold クロスバリデーションによる平均対数部分尤度 (左から履歴非依存モデル, Cox 比例ハザードモデル)

Fig. 2 Average log partial likelihoods with 10-fold cross-variation.

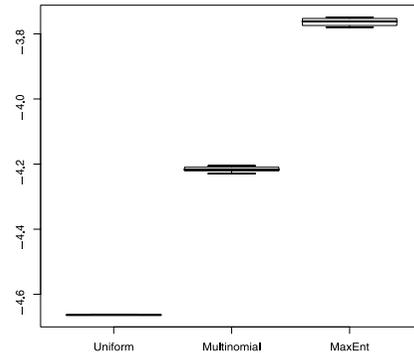


図 3 10-fold クロスバリデーションによる平均対数尤度 (左から一様分布, 多項分布, 最大エントロピーモデル)

Fig. 3 Average log likelihoods with 10-fold cross-variation.

$$y_{s_a, s_b}(u, s_j) = \begin{cases} 1 & \text{if item } s_a \text{ is the last item} \\ & \text{of user } u \text{ and } s_b = s_j, \\ 0 & \text{otherwise,} \end{cases}$$

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. このときの遷移数, 商品数を表7に示す. 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8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とらえているといえる. また, 2005年10月28日までのログを用いて10-foldクロスバリデーションを行った結果, 図3のようになり, 最大エントロピーモデルは一様分布, 多項分布に比べ平均対数尤度が高いといえる.

4.3 購買パターンの生起確率と契約期間延長効果
従来レコメンド法は購入される確率が最も高いと推

表 7 遷移数, 商品数

Table 7 The number of transitions and items.

	2005/06/30		2005/07/31		2005/08/31	
	学習	テスト	学習	テスト	学習	テスト
遷移数	300,486	122,904	382,778	171,749	459,456	197,476
商品数	75		81		86	

表 8 平均対数尤度

Table 8 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

測される商品を提示する。もし契約期間の長いユーザは、契約期間の短いユーザに比べ、購入確率の高い商品を購入する傾向が強ければ、従来法でも契約期間を延ばす効果があると考えられる。そこで、購買パターンの生起確率と契約期間を延ばす効果の関係を調べた。

商品 s_i の次に商品 s_j を購入するという購買パターンを $s_i \rightarrow s_j$ とする。 $s_i \rightarrow s_j$ の生起確率は 4.2 節で述べた 1 次マルコフ特徴量を用いた最大エントロピーモデルにより推定できる。また、購買履歴中に $s_i \rightarrow s_j$ がある (4.1 節の F3 で $x_{s_i \rightarrow s_j} = 1$) 場合、ハザード関数は $\exp(\beta_{s_i \rightarrow s_j})$ 倍される。したがって $\exp(-\beta_{s_i \rightarrow s_j})$ は、その購買パターンの契約期間を延ばす効果を表している。2005 年 8 月 31 日までのデータを用い Cox 比例ハザードモデル (F3) と最大エントロピーモデルを学習し、購買パターンの生起確率と契約期間を延ばす効果をプロットした結果、図 4 のようになった。このとき相関係数は 0.159 であり、相関は小さい。生起確率が高い購買パターンの契約期間を延ばす効果は高いとはいえず、従来レコメンド法では契約期間を延ばす目的には不十分であることを示唆する。

4.4 シミュレーションによる試算

4.1 節で Cox 比例ハザードモデルにより契約期間が予測できることを示した。これは契約期間の長いユーザに特徴的な購買パターンが存在することを表し、そのような購買パターンをレコメンドすることにより契約期間が延びる可能性を示唆する。また、4.2 節で最大エントロピーモデルにより購買行動が予測できることを示した。この結果より、購入される確率の低い商品をレコメンドすることなく、効果的なレコメンドができると期待できる。本節では、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。

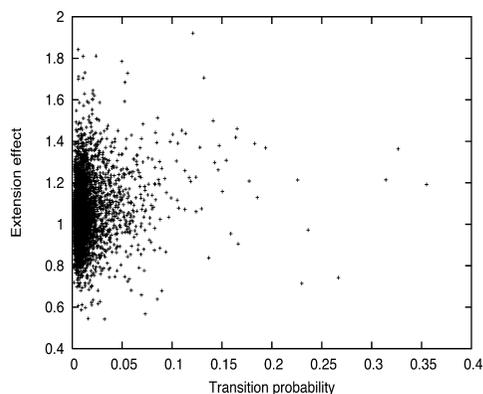


図 4 購買パターンの生起確率 (横軸) と契約期間延長効果 (縦軸)
Fig. 4 Transition probability vs extension effect.

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基に構築した。このとき商品数は 107 であった。

表 9 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、 $Bernoulli(\theta)$ は成功確率 θ のベルヌーイ分布、 $Multinomial(\psi)$ 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 9 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 $h(t|x)$ 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 によ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

表 9 ユーザシミュレーションアルゴリズム
Table 9 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  $t$ 

```

法により推定した。

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レコメンドする。表 9 の行 12 を以下のように変更する。

$$\hat{s} \leftarrow \arg \max_{s_i} Q(l|u, s_i).$$

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レコメンドする。行 12 を以下のように変更する。

$$\hat{s} \leftarrow \arg \max_{s_i} R(s_i|u).$$

この手法は従来法と同じく購買確率が高い商品をレコメンドする。

- **No Recommend** 何もレコメンドしない。購入される商品はユーザの嗜好によって決定される。行 12 を省き、行 13 を以下のように変更する。

$$\text{Sample } s_j \sim \text{Multinomial}(R(s_j|u)).$$

この手法は、表 9 で、 $\gamma = 1$ (レコメンドは購買行動に影響を与えない) とすることによっても実現できる。

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 5 のようになった。提案法によるレコメンドにより契約期間が最も延びている。また、レコメンド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ている。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

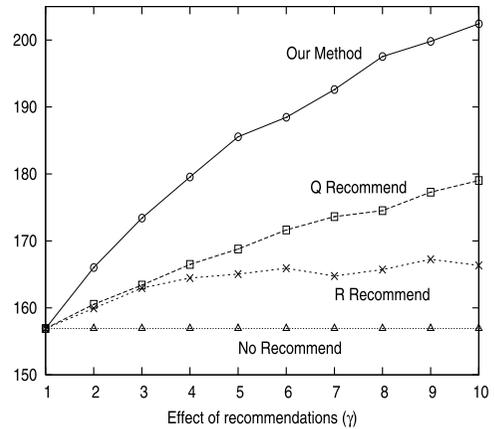


図 5 平均契約期間
Fig. 5 Average subscription periods.

購入される確率がない商品もレコメンドしているためと考えられる。4.3 節で示したように、購買パターンの生起確率と契約期間を延ばす効果に若干の相関があるため、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。

5. まとめ

契約期間を延ばすためのレコメンド法を提案し、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。たとえば、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。

今後の課題として、レコメンドの購買行動に与える影響の大きさをログデータから自動的に学習できるようにする必要がある。レコメンドした場合としない場合のログデータから推定できると考えられる。また、オンラインストアに新たな商品が加わることや、人気商品が変わることなどが考えられるため、提案法を時間的変化に対応できるように拡張する必要がある。実環境で提案法を評価することは、多くのユーザを対象とした長期にわたる実験が必要であり、さらに、同じサービスで対照実験をしなければならないため、困難である。そのため、本研究では提案法の効果をシミュレーションにより試算した。しかし、今後、オンラインストアに提案法を導入し、実際にユーザの契約期間が延びるかを検証したい。

参 考 文 献

- 1) Au, W.H., Chan, K.C.C. and Yao, X.: A novel evolutionary data mining algorithm with applications to churn prediction, *IEEE Trans. Evolutionary Computation*, Vol.7, No.6, pp.532–545 (2003).
- 2) Chen, S.F. and Rosenfeld, R.: A Gaussian prior for smoothing maximum entropy models, Technical report, CMUCS-99-108 (1999).
- 3) Cleves, M., Gould, W.W. and Gutierrez, R.: *An Introduction to Survival Analysis Using Stata*, Revised Edition, Stata Press (2004).
- 4) Cox, D.R.: Regression Models and Life-Tables, *Journal of the Royal Statistical Society, Series B*, Vol.34, No.2, pp.187–220 (1972).
- 5) Jin, X., Zhou, Y. and Mobasher, B.: A maximum entropy web recommendation system: Combining collaborative and content features, *Proc. ACM SIGKDD Conference on Knowledge Discovery and Data Mining* (2005).
- 6) Liu, D.C. and Nocedal, J.: On the limited memory BFGS method for large scale optimization, *Math. Programming*, Vol.45, No.3, pp.503–528 (1989).
- 7) Lu, J.: Modeling customer lifetime value using survival analysis—An application in the telecommunication industry, *Proc. SUGI 28*, pp.120–128 (2003).
- 8) Mani, D.R., Drew, J., Betz, A. and Datta, P.: Statistics and data mining techniques for lifetime value modeling, *Proc. 5th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pp.94–103 (1999).
- 9) Mooney, R.J. and Roy, L.: Content-based book recommending using learning for text categorization, *Proc. 5th ACM Conference on Digital Libraries*, pp.195–204 (2000).
- 10) Mozer, M.C., Wolniewicz, R., Grimes, D.B., Johnson, E. and Kaushansky, H.: Predicting subscriber dissatisfaction and improving retention in the wireless telecommunications industry, *IEEE Trans. Neural Networks*, Vol.11, No.3, pp.690–696 (2000).
- 11) Nigam, K., Lafferty, J. and McCallum, A.: Using maximum entropy for text classification, *Proc. IJCAI-99 Workshop on Machine Learning for Information Filtering*, pp.61–67 (1999).
- 12) Pavlov, D.Y. and Pennock, D.M.: A maximum entropy approach to collaborative filtering in dynamic, sparse, high-dimensional domains, *Proc. Neural Information Processing Systems*, pp.1441–1448 (2002).
- 13) Popescul, A., Ungar, L., Pennock, D. and Lawrence, S.: Probabilistic Models for Unified Collaborative and Content-Based Recommendation in Sparse-Data Environments, *Proc. 17th Conference on Uncertainty in Artificial Intelligence*, pp.437–444 (2001).
- 14) Ratnaparkhi, A.: A maximum entropy model for part-of-speech tagging, *Proc. Conference on Empirical Methods in Natural Language*, pp.133–142 (1996).
- 15) Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P. and Riedl, J.: Grouplens: An open architecture for collaborative filtering of netnews, *Proc. ACM Conference on Computer Supported Cooperative Work*, pp.175–186 (1994).
- 16) Rosset, S., Neumann, E., Eick, U. and Vatnik, N.: Customer lifetime value models for decision support, *Data Mining and Knowledge Discovery*, Vol.7, pp.321–339 (2003).
- 17) Schafer, J.B., Konstan, J.A. and Riedl, J.: E-commerce recommendation applications, *Data Mining and Knowledge Discovery*, Vol.5, pp.115–153 (2001).
- 18) Shono, Y., Takada, Y., Komoda, N., Oiso, H., Hiramatsu, A. and Fukuda, K.: Customer analysis of monthly-charged mobile content aiming at prolonging subscription period, *Proc. IEEE Conference on Computational Cybernetics*, pp.279–284 (2004).
- 19) Zitnick, L. and Kanade, T.: Maximum entropy for collaborative filtering, *Proc. 20th Conference on Uncertainty in Artificial Intelligence*, pp.636–643 (2004).

(平成 18 年 8 月 17 日受付)

(平成 18 年 10 月 3 日再受付)

(平成 18 年 11 月 4 日採録)

岩田 具治 (正会員)



昭和 54 年生。平成 13 年慶應義塾大学環境情報学部環境情報学科卒業。平成 15 年東京大学大学院総合文化研究科広域科学専攻修了。同年 NTT 入社。異常値検出、可視化、機械学習の研究に従事。現在、NTT コミュニケーション科学基礎研究所社員。FIT 船井ベストペーパー賞受賞 (平成 16 年)。電子情報通信学会会員。



齊藤 和巳（正会員）

昭和 38 年生。昭和 60 年慶應義塾大学理工学部数理科学科卒業。工学博士。同年 NTT 入社。平成 3 年より 1 年間オタワ大学客員研究員。神経回路網，機械学習の研究に従事。

現在，NTT コミュニケーション科学基礎研究所主任研究員（特別研究員）。情報処理学会論文賞受賞（平成 9 年）。人工知能学会論文賞受賞（平成 11 年）。FIT 船井ベストペーパー賞受賞（平成 16 年）。人工知能学会研究会優秀賞受賞（平成 17 年）。電子情報通信学会，人工知能学会，日本神経回路学会，IEEE 各会員。



山田 武士（正会員）

昭和 39 年生。昭和 63 年 3 月東京大学理学部数学科卒業。同年 NTT 入社。平成 8 年より 1 年間英国コペンハーゲン大学客員研究員。現在，NTT コミュニケーション科学基礎

研究所創発環境研究グループリーダー。主としてネットワーク分析，機械学習，データマイニング，メタヒューリスティクスによる組合せ最適化等の研究に従事。博士（情報学）。電子情報通信学会，ACM，IEEE 各会員。