

ページ内要因の選好度変化を考慮したランディングページ最適化手法の提案

プロフィットエンジニアリング研究

5215F023-1 松林 航祐
指導教員 大野 高裕

Landing Page Optimization considering user's dynamic preference toward page factors

MATSUBAYASHI Kosuke

1. はじめに

近年、ECサイトを運営する企業は、サイト上での最終成果であるコンバージョン¹（以下 CV）向上のため、様々な施策を行っている。本研究では、その中の一つであるランディングページ最適化（以下 LPO）に注目する。ここで LPO とは、インターネットユーザーが自社サイト訪問した時、最初に表示されるページ（ランディングページ（以下 LP））を複数のパターンから各ユーザーに適したものにすることで、CV を増やす施策である。LPO には、様々なアプローチが存在するが²、近年では獲得収益の向上を目的に、LPO を多腕バンディット問題 (Multi-Armed Bandit Problem) の一種として捉える取り組みが行われている。

多腕バンディット問題とは、活用と探索という 2 つの行動を逐次的に使い分け、複数の選択肢から得る報酬の最大化を目指す問題である。多腕バンディット問題の応用により、企業は従来 LPO 実施時に発生していた実験配信を必要最小限まで削減し、その分期待値の高い LP の配信に充てることで、収益拡大を見込める。

そのため本研究では、企業の更なる利益獲得のため、多腕バンディット問題の達成手法であるバンディットアルゴリズム（以下 BA）を用いた LPO 手法の構築を目標とする。ここで、BA を LPO に応用する際には、他の応用事例とは異なり、各選択肢の時系列的な期待値の変化を考慮する必要があると考えられる。一般的な BA の応用事例³では、選択肢の期待値は時点問わず一定であるとされている。しかし LPO の場合、ページに対するユーザーの好みや、トレンドの変化といった要因によって、時間経過に伴い各 LP の期待値は動的に変化すると予想される。すなわち、LPO への BA の応用においては、各 LP の選好度の変化を捉えながら活用と探索の配分を考える必要があるが、通常の BA では配信された LP のみの期待値の変化しか捉えることができないため、推定精度の問題から機会損失が発生する恐れがある。

そこで本研究では、ユーザーの LP に対する選好度の変化を考慮した BA による LPO 手法を構築する。

2. 従来研究

2.1. Schreiber and Baier[1]

Schreiber and Baier[1] は、LPO を効用最大化理論の枠組みで捉えた研究である。Schreiber and Baier[1] では、各 LP の CV 確率の差は、ページ内の要因⁴の水準⁵の違いによって生ずるとしている。ユーザー i が j 個ある LP の中から、 k 番目の LP を選択する確率 $P_{i,k}$ は以下のように定式化される。

$$P_{i,k} = \frac{\exp(\beta_i^\top \mathbf{x}_{i,k})}{\sum_j \exp(-\beta_i^\top \mathbf{x}_{i,j})} \quad (1)$$

ここで、 $\mathbf{x}_{i,j}$ は、 j 番目の LP を閲覧したときユーザー i が認識したページ内の水準ベクトル、 β_i はユーザー i の各水準に対する反応パラメータベクトルである。しかし、Schreiber and Baier[1] は、「 j 番目の LP を表示したときユーザー i が CV するかしないか」を把握できるモデリングにはなっていない。

2.2. Xu et al. [3]

Xu et al.[3] は、Thompson[2] の考案した BA である Thompson Sampling（以下 TS）に状態空間表現を導入し、時系列の視点を取り入れた BA を提案している。Xu et al. [3] では、時点 t において、特徴量 x_t が与えられた際のイベント生起確率 θ_t と、状態 β_t の時間変化を以下のように定式化している。

$$\theta_t = \frac{1}{1 + \exp(-\beta_t^\top \mathbf{x}_t)} \quad (2)$$

$$\beta_t = \beta_{t-1} + \epsilon_t \quad \epsilon_t \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_t) \quad (3)$$

ここで、 ϵ_t は白色ノイズであり、i.i.d としている。Xu et al.[3] では、各選択肢の事後分布を推定し、そこから発生させた乱数が最大の値をとった選択肢を選択する TS のアルゴリズムにより、活用と探索のバランスを図る。時点 t において、TS によって選択される選択肢 $a^*(t)$ は、事後分布からの乱数ベクトル $\tilde{\beta}_t$ を用いて以下のように表される。

$$a^*(t) = \arg \max_{a' \in \mathcal{A}} \tilde{\beta}_t^\top \mathbf{x}_{t,a'} \quad (4)$$

¹商品購入や資料請求など、web 上から獲得できる最終成果。

²統計的検定、多変量解析など

³複数のスロットマシンから獲得するコインの最大化など

⁴ページ内の画像や文字のサイズ、フォントなど

⁵例えば画像という要因に対して、大、中、小という 3 つの水準を考慮することができる

ここで, Xu et al.[3] では, 上述の通り事後分布をラプラス近似によりガウス分布で近似しているが, 事後分布は必ずしもガウス分布に従うとは限らないため, 場合によっては近似精度の問題があると考えられる. そのため本研究では, 解析的な近似ではなく, 分布表現をモンテカルロ近似で行なう推定手法であるパーティクルフィルタ (以下 PF) によって事後分布の状態推定を行ない, その分布を用い TS を実施するモデルを提案する.

3. 提案モデル

3.1. モデリング

本研究では, Schreiber and Baier[1] を参考に LP の CV 確率の定式化を行い, Xu et al.[3] を参考に, 状態空間表現の導入と TS モデルを構築する. まず, 状態空間表現を取り入れた, 各 LP の CV 確率のモデリングを行なう. ユーザー i の p 番目の LP 上での CV 有無の観測変数を $y_{i,p}$ とすると, CV の発生 ($y_{i,p} = 1$) は確率 $\theta_{i,p}^t$ をパラメータに持つベルヌーイ過程に従うものとし, 時点 t に, ユーザー i が p 番目の LP を閲覧した際, CV に至る確率 $\theta_{i,p}^t$ を以下のようにロジスティック回帰モデルで定式化する.

$$P(y_{i,p}|\theta_{i,p}^t) = (\theta_{i,p}^t)^{y_{i,p}}(1 - \theta_{i,p}^t)^{1-y_{i,p}} \quad (5)$$

$$\theta_{i,p}^t = \frac{1}{1 + \exp(-\beta^t \mathbf{x}_p)} \quad \forall p \in \mathcal{P} \quad (6)$$

$$\beta^t = [\beta_1^t, \beta_2^t, \beta_3^t, \beta_4^t] \quad (7)$$

ここで期間 t の単位は 1 週間とする. 式 5 は状態空間モデルにおける観測モデルである. \mathbf{x}_p は, p 番目の LP が持つページ内要因の水準をバイナリで表現するダミー変数ベクトル, β^t は時点 t の時変パラメータベクトルである. また, システムモデルを以下のように定式化する.

$$\beta^t = \mathbf{I}\beta^{t-1} + \mathbf{I}\mathbf{v}_{\beta^t} \quad \mathbf{v}_{\beta^t} \sim \mathcal{N}(\mathbf{0}, \Sigma_{\beta}) \quad (8)$$

$$\Sigma_{\beta} = \text{diag} [\sigma_{\beta_1}^2, \sigma_{\beta_2}^2, \sigma_{\beta_3}^2, \sigma_{\beta_4}^2] \quad (9)$$

ここで, \mathbf{I} は単位行列, \mathbf{v}_{β^t} は時点 t での各時変パラメータのシステムノイズベクトルであり i.i.d としている. このシステムノイズの分散は, ハイパーパラメータである. 経験データから推定したハイパーパラメータをモデルに与え PF を実行することで, 新たに得られるデータから状態 β^t の逐次推定が可能となる. PF は, 粒子と呼ばれる多数の実現値をヒストグラム状に分布させ, 事後分布の近似を行なう状態推定法である. システムノイズにより一期先の予測を行なった後, 各時点で得られるデータによる尤度評価で分布を補正するフィルタリングを逐次的に行なうことで事後分布を更新していく.

この事後分布の実現値を, LP 毎にランダムに選択し最大値をとるパターンを配信することで, BA の一種である TS が実現される. 時点 t に含まれる機会 s において,

ユーザーに表示する LP の番号 $p^*(s)$ は以下ようになる.

$$p^*(s) = \arg \max_{p' \in \mathcal{P}} \tilde{\beta}^t \mathbf{x}_{s,p'}^{\top} \quad (10)$$

3.2. 推定

本研究では時変パラメータの推定に PF, ハイパーパラメータの推定に非線形最適化手法の一つである Nelder-Mead 法を採用する. PF の状態推定時に用いる粒子数を 10,000 とする. また, 状態推定における事前情報として, 粒子に初期分布を与えることができる. ハイパーパラメータ推定時はホールドアウトデータ 1 期分を静的なモデルで最尤推定した値を全粒子に一様に与え, その他の検証においてはホールドアウトデータに対して PF で状態推定を行った際の最終期の分布を初期分布として与える.

4. 検証

4.1. 検証方法

本研究の検証は, PF による状態推定に関する検証と, その結果を利用した TS の検証の 2 つを行なう. 前者では, 定式化したモデルでの状態推定の結果を考察し, 後者では TS の動作の分析や従来手法との獲得 CV のパフォーマンス比較を行い, 提案モデルの妥当性を検証する.

4.2. 使用データ

本研究では, 首都圏を中心に展開する某アイクニック EC の 2015 年 4 月 1 日~2016 年 3 月 31 におけるログデータと, 分析者が主観的に生成したその EC の仮想データを用いる. 前者はハイパーパラメータの推定に, 後者は TS の各実験において用いる. 以下は両データに共通の設定である. 本研究では, レーシック手術の検査申し込みフォーム到達, を CV とする. 対象ユーザーは EC に PC を通じて流入するユーザーであり, そのユーザー群に対して 2 つのセグメントを設け, 適宜セグメント毎に検証を行う. ここで, セグメント 1 を「平日に訪問したユーザー」, セグメント 2 を「休日に訪問したユーザー」とする. 次に, 分析対象とする LP についてであるが, ページ内の要因として, 「CV ボタンの個数」と「クリエイティブ画像位置」の 2 つを挙げ, それぞれに 2 水準を設ける. すなわち計 4 パターンの LP で, LPO を行なう. 具体的な, 各 LP と水準の対応関係を表 1 に示す.

表 1. 各 LP と水準の対応関係

要因	要因 1 “CV ボタン数”		要因 2 “クリエイティブ画像位置”	
	水準 1 (x_1) “1”	水準 2 (x_2) “2”	水準 3 (x_3) “右”	水準 4 (x_4) “左”
ページ 1	1	0	1	0
ページ 2	1	0	0	1
ページ 3	0	1	1	0
ページ 4	0	1	0	1

4.3. 検証結果

4.3.1. 状態推定に関する検証

まず、平日ユーザーのデータを用いて、ハイパーパラメータを推定し、それを用いて逐次的に状態推定を行った結果に関して検証を行う。図1は、セグメント1の各LPのCV確率を各期（1週間）毎に、2015年4月1日から26期間分集計したものである。一方図2は、同期間のホールドアウトデータを用いて推定されたハイパーパラメータを与え、状態推定を行った際のCV確率の推移である。

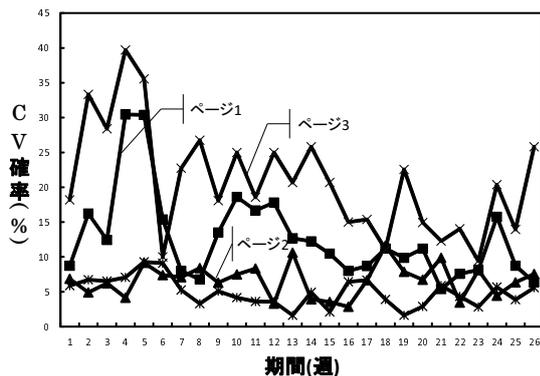


図1. 各LPのCV確率の推移

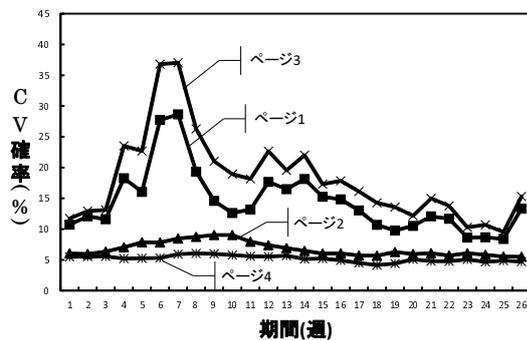


図2. 各LPのCV確率の状態推定結果

図2の結果を図1の結果と比較すると、CV確率の高いページ1とページ3に関しては、比較的うまくCV確率をトラッキングできていることがわかる。一方、ページ2とページ4に関しては、少々変化を正確に捉えられていないようにも見える。これは、CVへの影響を各LPの効用値に固有定数項を含めず、ページ内の水準のみで各LPの効用値を説明していることが、原因として考えられる。なお効用値に固有定数項を含めなかった理由は、ハイパーパラメータ推定の計算時間増加と局所解収束への回避、無属性のページがCVに一定数寄与するという結果が得られることを防ぐためである。この状態推定上の問題への対策として、今後はより多くの要因・水準を用いてページの効用値を定式化する、といったことが考えられる。

4.3.2. Thompson Sampling に関する検証

次に、提案モデルのTSに関する検証を行なう。検証方法は、仮想データに対し、各期の状態を前節で求めたハイパーパラメータを用いて推定し、その状態分布を利用してTSを行った場合のシミュレーション実験である。このシミュレーション実験を通じ、提案モデルのTSによって配信されるLPの回数の推移に関する検証と、従来手法と提案モデルでLPOを実施した際の獲得CV数の比較検証を行う。まずは前者に関して検証を行なう。

検証においては、1期間（1週間）あたり3,000のユーザーのセッション⁶に対して、提案モデルのTS計算結果に基づいたLP配信を行なうものとする。その際、各LPのCV確率が全体的に高い場合（Test 1）と、低い場合（Test 2）の、2つの仮想データに対して検証を行ない、異なる状況での提案モデルの動作を比較する。ここで、 t 期の p 番目のページのCV数 N_p^t を、 t 期の p 番目のページのセッション数を S_p^t 、 t 期の p 番目のページの仮想的なCV確率を θ_p^t として以下のように定める。

$$N_p^t = [\theta_p^t S_p^t] \quad (11)$$

はじめに、Test 1の状況設定下で、提案モデルのTS結果に関する考察を行う。図3は、各LPの仮想的なCV確率 θ_p^t の推移をまとめた図であり、一方図4は、提案モデルのTSによって、各LPが配信された回数の推移をまとめたものである。図4を見ると、各期で最も多く表示されるLPは図3の各期において最大のCVRをとるLPの変化を追うように推移しており、多くの配信においてBAの活用が行なわれているとわかる。また、各期において期待値が最大でない他のLPについても、わずかに配信が行われており、これは探索に相当すると考えられる。以上より、PFによって時系列の変化を捉えつつ、TSによって活用と探索が行われているといえる。

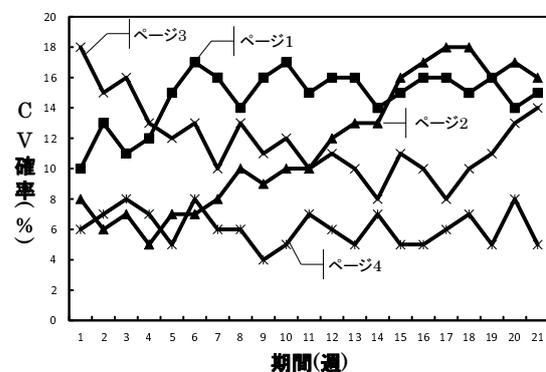


図3. test 1における各LPのCV確率

⁶サイトの訪問数のこと

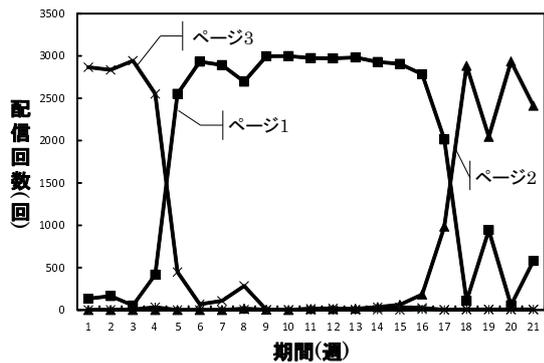


図 4. test 1 の各 LP の配信回数

一方、Test 2 の設定 CV 確率の推移を図 5 に、TS を行った結果を図 6 に示す。Test1 同様、各 LP の仮想的な CV 確率の推移と、各 LP の配信回数には対応関係があるとわかる。しかし、11~15 期にかけてページ 2 とページ 3 の TS 結果に注目すると、設定 CV 確率では 11 期頃にページ 2 の CV 確率がページ 3 を上回っているのに対し、TS でページ 2 の配信回数がページ 3 を上回るのは 17 期頃であり、タイムラグが見られる。これは、ページ 2 が 11 期頃までは表示回数が 0 に近い値で推移していたため、なかなかページ 2 の CV データが得られず分布が更新されなかったことが原因として挙げられる。この問題に対しては、定期的な分布をリセットするなどの対応が有効であると考えられる。

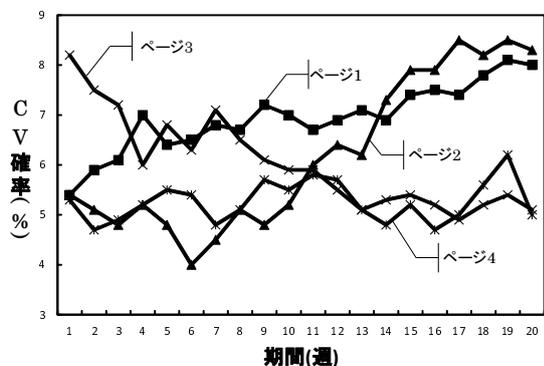


図 5. test 2 における各 LP の CV 確率

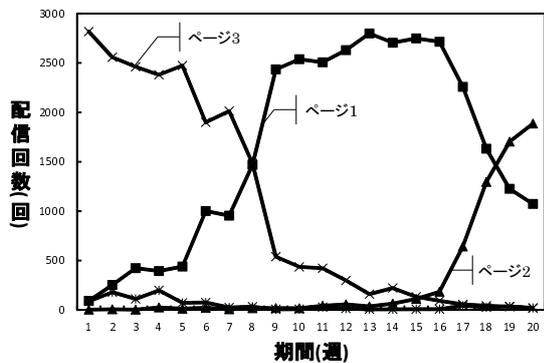


図 6. test 2 の各 LP の配信回数

最後に、提案モデルと従来手法 (ランダム配信と通常の TS) で LPO を行った際の獲得 CV 数の比較を行う。ここでは、1 期あたり 3000 セッションに対し、各手法で LPO を行なうものとする。各期の CV 数は図 4 の仮想的な CV 確率を用いて前検証と同様の方法で求める。全期を通じて得られた総 CV 数は表 2 のようになり、各期において各手法で獲得された CV 数は図 7 のようになった。全期間を通じて提案モデルが最も多くの CV を獲得しており、提案モデルの有用性が示されたといえる。

表 2. 全期間で獲得した総 CV 数

	ランダム配信	通常の TS	提案モデルの TS
獲得 CV 数	6864	8731	9378

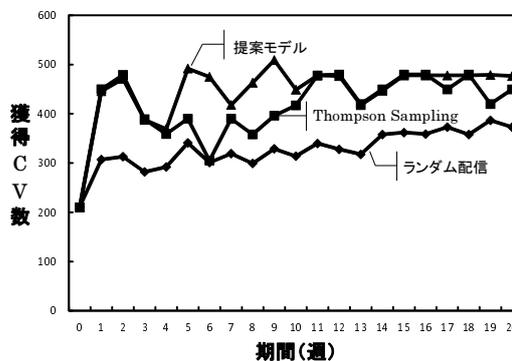


図 7. 各手法の獲得 CV 数の推移

5. おわりに

本研究では、LPO の問題状況に多腕バンディット問題で対応することを目標に、時系列の視点を取り入れた BA を考案した。その結果、各ページパターンに対するユーザーの動的な選好度の変化を捉えた上で BA を実施でき、従来手法に対して高い成果を獲得することができた。今後の課題としては、ロジスティック回帰上のモデリングの改善や、あまり配信されなくなった LP の分布更新の遅れへの対応、などが挙げられる。

参考文献

- [1] Shereiber, S. and Baier, D.: “Multivariate Landing Page Optimization Using Hierarchical Bayes Choice-Based Conjoint,” *Data Science, Learning by Latent Structures, and Knowledge Discovery*, Springer, pp.465-474 (2014)
- [2] Thompson, W. R.: “On the Likelihood That One Unknown Probability Exceeds Another in View of the Evidence of Two Samples.” *Biometrika* 25-3,4, pp.285-294 (1933)
- [3] Xu, T., Yu, Y., Turner, J. and Regan, A.: “Thompson Sampling in Dynamic Systems for Contextual Bandit Problems,” *arXiv* 1310.5008 (2013)