

バリエーションの提示がもたらす長期的効果に着目した ウェブサイト最適化手法

Website Optimization Focusing on the Long-term Effect

飯塚 修平
Shuhei Iitsuka

松尾 豊
Yutaka Matsuo

東京大学工学系研究科技術経営戦略学専攻

Department of Technology Management for Innovation, The University of Tokyo

Website optimization is widely used to improve the performance of websites by comparing users' responses related to different variations. Most of implementations for website optimization merely evaluate instantaneous metrics such as click-through rates and conversion rates, which are not designed to assess long-term effects of showing variations. We propose a new implementation of website optimization which takes long-term effects, which are important to evaluate the actual users' satisfaction and engagement, into consideration by estimating them from users' immediate feedback and past experiments' log data.

1. はじめに

ウェブサイトの収益性を向上させる目的でウェブサイト最適化が広く用いられている。ウェブサイト最適化とは、ウェブサイト上でユーザをサンプルとする比較対象実験を行い、より望ましいユーザ行動を引き出すウェブサイト構築する手法である。A/B テストやランディングページ最適化という名前でも親しまれている。ウェブサイト最適化では、最適化したウェブサイトの一部を変更して複数のバリエーションを生成し、ウェブサイトを訪問したユーザを各バリエーションに振り分ける。それぞれのバリエーションにおけるユーザの振る舞いの違いを比較することで、ウェブサイトの目的となるボタンのクリック率やユーザ登録率などの目的指標を最適化するバリエーションを発見する手法である [Kohavi 09]。

既存のウェブサイト最適化手法では、クリックや商品の購入などのユーザの即時的な反応から直接計測できる指標を評価指標として最適化することが多い。しかし、このような指標に対してウェブサイト最適化を行うと、最適と判断されたバリエーションが長期的にもたらす負の効果を見逃してしまうことがある。たとえば検索エンジンにおいて、検索結果ページに表示する広告の数を増やせば短期的には広告収益を増やすことができるかもしれないが、その結果使いにくくなればユーザが離脱して長期的には広告収益を減少させることになる [Dmitriev 17]。短期的な指標改善のみに注目して最適化を行うと、本来のサービスの使いやすさやユーザの満足度を棄損してしまい、長期的に見ると誤った判断を下してしまう可能性がある。しかし、長期的効果を見積もるために実験期間を長くすれば、ウェブサイト最適化による仮説検証のサイクルを減速させることになり、サービス成長のスピードを鈍化させることになる。企業活動に必要とされるのは、短期間の実験でも長期的な効果を予測して最適なバリエーションを推定できるウェブサイト最適化手法である。

そこで本研究では、ユーザから得られる即時的なフィードバックと過去のウェブサイト最適化から得られた実験データから未知のバリエーションの長期的効果を推定し、長期的に最適なバリエーションの判断を行うウェブサイト最適化手法を提案

連絡先: 飯塚 修平, 東京大学工学系研究科技術経営戦略学専攻, 東京都文京区本郷 7-3-1 工学部 2 号館 92C1 号室, 03-5841-7718, iitsuka@weblab.t.u-tokyo.ac.jp




図 1: 提案手法の概観。

する。提案手法の概観を図 1 に示す。提案手法は、過去に実施したウェブサイト最適化から得られたログデータを用いて、即時的なフィードバックからなる特徴空間における目的指標の分布を推定する。この分布を用いることで、未知のバリエーションについても即時的なフィードバックさえ観測できれば目的指標の値を推定することができる。つまり、観測に時間を要する長期的指標を目的指標としている場合であっても、過去の実験データから目的指標の分布さえ推定できれば、即時的なフィードバックを長期的指標の推定値に変換することができる。

評価実験では、実際のウェブサイトから得られたログデータを用いて提案手法の有効性を評価する。このウェブサイトでは複数の期間でウェブサイト最適化が行われており、各バリエーションに対するユーザの反応がログデータに記録されている。学習期間のログデータから提案手法によって推定された分布を用いることで、テスト期間の未知のバリエーションについて目的指標が観測できない場合でも、即時的なフィードバックから有意に良いバリエーションを推定できることがわかった。

2. 関連研究

2.1 長期的効果に対するウェブサイト最適化

既存のウェブサイト最適化ではクリック率や滞在時間など、ユーザが訪問したら即時に計測できる指標を目的指標とすることが一般的であったが、近年ではバリエーションの提示がも

たらず長期的効果を反映した最適化を行うことの重要性が訴えられはじめている [Dmitriev 17]. たとえば, 長期的指標と短期的に観測される指標との間に乖離を生む原因のひとつに目新しさ効果がある. 目新しさ効果とは, ウェブサイトに新しいユーザインタフェイスを導入した際にはユーザが馴染みがないために, 様々な場所をクリックしたり様々なウェブページを訪問するなどして, 本来よりも過度に活動が活発になる効果のことである. この効果は時間が経過してユーザがユーザインタフェイスの挙動を学習すると薄れるが, ユーザの行動の一部を目的指標としていた場合には, 短期指標に着目すると新しいバリエーションを過大評価してしまうことが指摘されている [Kohavi 09].

長期的効果に着目したウェブサイト最適化に対する解法も提案され始めている. Google は, 検索結果ページにおける広告表示方法を, 長期的な収益性を考慮して最適化する手法を提案している [Hohnhold 15]. この研究では, 広告の表示数, 広告のランディングページの質や検索クエリとの関連度と言った特徴によって各バリエーションを表現し, 過去に実施されたウェブサイト最適化の結果から, 各特徴と長期的な収益性の関係を線形回帰によって推定している. これらの特徴はバリエーションに対して即座に算出できるため, 短期的指標から長期的な目的指標を推定することができる.

バリエーションをある特徴空間で表現し, その特徴空間で長期的指標の分布を推定する点ではこの手法は本研究の提案手法と類似しているが, この手法は各バリエーションの特徴表現が即座に与えられることを前提としている点が異なる. Google のように大手検索エンジンの検索結果ページでは, 広告の質や検索クエリとの関連度を算出する仕組みが確立しているため, あるバリエーションからの特徴抽出が容易にできるかもしれない. しかし, リリースされて間もないウェブサービスやテストをはじめて間もないウェブサイトの場合にもこの前提が成り立つとは考えにくい. また, 新しい機能のテストを行う場合には, 既存の特徴表現が有用でない可能性もある. したがって, あるバリエーションを表す特徴が自明でない状況を想定する方が一般的だと考えられる. 本研究では, バリエーションの特徴表現が直接与えられない場合に, 短期的指標から長期的指標を予測する問題に取り組む.

2.2 バンディット問題

ウェブサイト最適化を定式化する枠組みとして, 確率的バンディット問題が広く用いられている [White 12]. バンディット問題とは, 何らかの報酬を与える複数の選択肢の中から最も期待値の高い選択肢を探索する問題である [本多 16]. 選択肢をバリエーション, 一回の試行をユーザの訪問に対するバリエーションの表示, 報酬をユーザの反応として捉えることで, バンディット問題に対する解法 (バンディットアルゴリズムと呼ばれる) をウェブサイト最適化に導入することができる.

バンディット問題には様々な拡張が提案されている. 特に文脈付きバンディット問題は各選択肢に特徴表現を与えた場合の定式化であり, 各選択肢の特徴量を考慮することでより高度な探索が可能になる. たとえば, Yahoo! はこの拡張を記事のトピックや訪問したユーザの特徴を考慮した推薦エンジンの構築に応用している. 各時刻に訪れるユーザの特徴量と記事の特徴量を合わせたものを各選択肢の特徴量としてみなすことで, パーソナライゼーションを考慮した最適化を実現できる [Li 10]. また, 探索の過程で特徴空間において期待値を推定するモデルを構築するため, 未知の選択肢に対しても特徴量さえ抽出されれば期待値を推定することができる. したがって文脈付きバンディット問題としての定式化は, コールドスタート問

題 *1 への解決策としても利用できる.

文脈付きバンディット問題を一般化した連続腕バンディット問題では, 選択肢が特徴空間の任意の点を取ることができるものとする. 連続腕バンディット問題の解法として代表的なものに GP-UCB アルゴリズムがある [Srinivas 10]. GP-UCB アルゴリズムは, ガウス過程を用いて特徴空間 X における期待値の分布 $\mu(\mathbf{x})$ およびその分散 $\sigma(\mathbf{x})$ を推定し, その信頼区間の上限が最大となる点 $\mathbf{x} \in X$ を選択して観測値 y を得ることで, 期待値が高く不確実な選択肢を優先的に探索するアルゴリズムである. 本研究の提案手法は, 各選択肢の特徴空間 X ではなく, 各選択肢 x を施行した後に得られるフィードバック z によって構成される特徴空間 Z に対して GP-UCB アルゴリズムを適用したものである.

3. 提案手法

まず, 本研究で取り扱う問題設定を整理する. あるウェブサイトに t 番目に訪問したユーザ u_t に対してバリエーション $x_t \in X$ を表示するとき, ユーザから即時的なフィードバック z_t が観測されるものとする. フィードバック z_t にはユーザの滞在時間やウェブページをスクロールした量など, あるバリエーションを表示することで即時的に観測できる指標が含まれる. また, 即時的には観測できないが, バリエーション x_t に対する目的指標 y_t も発生しているものとする. これは週間リピート回数のように定義上の理由や, 目新しさ効果などによって真値の観測に時間を要する長期的指標を想定したものである. この目的指標 y_t はある程度の時刻が経過しないと観測できないため, 過去のログデータの中では観測できるが, 即時的には観測できないものとする. ここで, 目的指標 y_t を観測するまでに要する期間を T とすると, この期間のログデータのまとまり (バッチ) は $D_i = \{(x_t, z_t, y_t) \mid (i-1)T < t \leq iT\}$ と表される. ただし, このログデータバッチ D_i はウェブサイト最適化期間中に複数回観測できるものとし, i はその添字を表す. 今後, ログデータ D は実験期間中に得られたログデータバッチ D_i の集合を表すものとする. また, ここではユーザが訪問する頻度が一定であるとして, バッチ生成に要する期間 T をユーザ数の単位に読み替えている. ログデータバッチ D_i 内では表示するバリエーションが固定されているものとする.

本研究で取り扱う問題の目的は, 学習フェーズでログデータを用いて長期的指標の分布を学習し, 推論フェーズで即時的なフィードバックのみを用いて未知のバリエーションから期待値の高いバリエーションを推定することである. 学習フェーズでは, このログデータ D を用いてフィードバック z によって構成される特徴空間 Z (フィードバック空間とよぶ) から目的指標 y を推定するモデルを得ることを目的とする. 推論フェーズでは, ログデータ D には含まれない未知のバリエーション $x' \in X'$ を T' 回表示することで得られるデータ $D' = \{(x'_t, z_t) \mid 0 < t' \leq T'\}$ に学習フェーズで獲得したモデルを適用することで, 最も期待値の高いバリエーション $x^* = \arg \max_{x' \in X'} \mathbb{E}[y \mid x']$ を探索することが目的となる.

学習フェーズにおいて, ログデータ D からフィードバック空間 Z における長期的指標 y の期待値を推定する方法には線形回帰やサポートベクトル回帰など様々な方法が考えられる. ウェブサイト最適化はユーザとの相互作用によってデータを収集するため, 演算のみで解の評価値を得られる問題に比べると解の評価コストが高く, より少ないサンプル数で高速に最適な

*1 推薦エンジンにおいて, 未知のユーザや商品に対しては十分なデータが無いために有効な推薦ができない問題のこと.

バリエーションを推定することが重要になる。そのため、学習フェーズにおいて逐次的にログデータバッチ D_i で表示すべきバリエーションを効率的に選択する必要がある。バンディットアルゴリズムは、それまでの探索の履歴を用いて逐次的に有望な解を選択するメカニズムを提供するため、この問題と相性が良いと考えられる。そこでここでは、バンディットアルゴリズムをベースにして手法を構築することにする。

提案手法のアルゴリズムを Algorithm1 に示す。提案手法では、まずフィードバック空間 Z において目的指標の期待値 $\mu(z)$ と標準偏差 $\sigma(z)$ の和を最大とする点 z^* を求める。その後、各解 $x \in X$ の中で最もそのフィードバック z^* を引き出すと期待される解、すなわち距離 $(z^* - \mathbb{E}[z | x])^2$ を最小にする解 x_t を求める。この解 x_t を試行することで新たな観測値 y_t および付随情報 z_t が得られた後は、ガウス分布を用いて期待値の分布を更新する。以上の操作を繰り返すことで、付随情報空間 Z の情報を活用しながら最も期待値の高い解 x^* を探索するアルゴリズムである。

Algorithm 1 提案手法のアルゴリズム

Require: X as the set of variations.
Require: Z as the context space.
Require: α as the Gaussian Process prior parameter.
Require: β as the confidence parameter.

- 1: Set $\mu_0(z) \leftarrow 0, \forall z \in Z$.
- 2: Set $\sigma_0(z) \leftarrow \mathcal{N}(\mu_0(z), \alpha^{-1}I)$.
- 3: **for** $t = 1, 2, \dots$ **do**
- 4: Choose $z^* = \arg \max_{z \in Z} \mu_{t-1}(z) + \sqrt{\beta} \sigma_{t-1}(z)$
- 5: Choose $x_t = \arg \min_{x \in X} (z^* - \mathbb{E}[z | x])^2$
- 6: Sample y_t and z_t by trying x_t .
- 7: Update $\mu_t(z)$ and $\sigma_t(z)$ using Gaussian Process.
- 8: **return** x_t as the optimal solution x^* .

以上の手続きをウェブサイト最適化の例で説明する。あるウェブサイト w が3種類のバリエーション $X = \{x_A, x_B, x_C\}$ を持っており、ここからユーザの広告のクリック率 $\mathbb{E}[y | x]$ を最大にするようなバリエーション x^* を求めたいとする。このとき、ウェブサイト w はある t 番目に訪問したユーザ u_t にバリエーション x_t を割り当て、その振る舞いを観察する。ウェブサイト w はクリックの有無 y_t だけではなく、ユーザがウェブサイトへ滞在した時間 z_t も測定しているものとする。ウェブサイト w はクリック y_t および滞在時間 z_t が観測されるとガウス過程による推定を行い、滞在時間に対するクリック率の分布 $\mu(z), \sigma(z)$ を更新する。その結果、観測値の信頼区間の上限を最大化する滞在時間は z^* 秒であることがわかったとする。過去の履歴から z^* に最も近い滞在時間が得られると期待されるバリエーションが $x_B = \arg \min_{x \in X} (z^* - \mathbb{E}[z | x])^2$ だったので次に $x_{t+1} = x_B$ を表示する。以上の手続きを繰り返すのが提案手法による期待値分布の学習方法である。

4. 評価実験

評価実験では、提案手法が未知のバリエーションの長期的効果を推定するのに役立つことを、実際のウェブサイトのログデータを用いたシミュレーションによって検証する。本実験では、人物検索サイト「あの一と検索スパイシー *2」を対象の

表 1: 実験に用いたフィードバックの種類.

z	フィードバック
z_1	セッション終了の有無
z_2	プロフィールページの概要図からの遷移の有無
z_3	「もっと見る」ボタンからの遷移の有無
z_4	関連図ページでの滞在時間 (分)

表 2: バリエーション x_1, \dots, x_8 に対して観測されたクリック率 y およびフィードバック指標 z の分布.

x	y	z_1	z_2	z_3	z_4
x_1	$B(0.040)$	$B(0.175)$	$B(0.173)$	$B(0.412)$	$\Gamma(1.48, 21.0)$
x_2	$B(0.053)$	$B(0.197)$	$B(0.188)$	$B(0.403)$	$\Gamma(1.46, 21.6)$
x_3	$B(0.072)$	$B(0.199)$	$B(0.175)$	$B(0.417)$	$\Gamma(1.24, 22.9)$
x_4	$B(0.055)$	$B(0.183)$	$B(0.174)$	$B(0.411)$	$\Gamma(1.51, 20.7)$
x_5	$B(0.059)$	$B(0.200)$	$B(0.190)$	$B(0.391)$	$\Gamma(1.19, 24.7)$
x_6	$B(0.066)$	$B(0.200)$	$B(0.209)$	$B(0.386)$	$\Gamma(1.32, 20.7)$
x_7	$B(0.068)$	$B(0.180)$	$B(0.192)$	$B(0.376)$	$\Gamma(1.34, 21.6)$
x_8	$B(0.085)$	$B(0.193)$	$B(0.172)$	$B(0.392)$	$\Gamma(1.35, 21.0)$

ウェブサイトとした。スパイシーはウェブ上で観測されるデータから様々な人物のプロフィール情報および人間関係を抽出して可視化するウェブサイトである。各人物のプロフィールおよび人間関係の概要図を掲載したプロフィールページと、人間関係を可視化した関連図ページからなるシンプルな構造のウェブサイトである。定期的に広告のクリック率を目的指標としたウェブサイト最適化を行っていること、クリック率以外にも様々なフィードバック指標を計測していることなどが主な選定要因である。

この実験では関連図ページにおけるディスプレイ広告のクリックの有無 y を目的指標とする。ディスプレイ広告のクリックの有無は、広告が表示される IFRAME 要素のイベントを監視することで即時的に観測することも可能であるが、バリエーションの変更による目新しさ効果を考えると、十分に時間を置いて観測する方が理想である。そこでここでは、ディスプレイ広告のクリック率はログデータの中では観測できるが、即時には観測できない長期的指標として扱う。

バリエーションを表示した際に即時に得られるフィードバックを表 1 に示す。ここでは 2013 年 5 月 16 日にあるバリエーション集合 $X = \{x_1, x_2, x_3\}$ に対してウェブサイト最適化を行なったときのログデータを学習に用いる実験データ D とし、フィードバック空間 Z における目的指標 y の期待値の分布 $\mu(z), \sigma(z)$ を推定する。その後、異なるバリエーション集合 $X' = \{x_4, \dots, x_8\}$ に対してウェブサイト最適化が行われた 2013 年 6 月 6 日のログデータ D' について、この期間に得られる即時的に得られる付随情報 z から最適なバリエーション $x^* \in X'$ を推定できることを評価する。ここでは、ログデータバッチ D_i に含まれるユーザ数を $T = 100$ 、ログデータに含まれるバッチ数を $|D| = 100$ とする。

表 2 に、各バリエーション x_1, \dots, x_8 について観測された目的指標 y およびフィードバック指標 z の推定分布を示す。クリック y およびあるフィードバック事象の有無 z_1, z_2, z_3 は発生有無の二値を取るため、ある平均値を母数とするベルヌーイ分布 $B(p)$ から発生するものとする。一方、滞在時間 z_4 は 0 以上の連続値を取るため、ここではガンマ分布 $\Gamma(k, \theta)$ による当てはめを行っている。ただし、 k は形状母数、 θ は尺度母数とする。

図 2 に学習データ D から得られた、フィードバック空間 Z

*2 あの一と検索スパイシー <http://spyse.jp/>

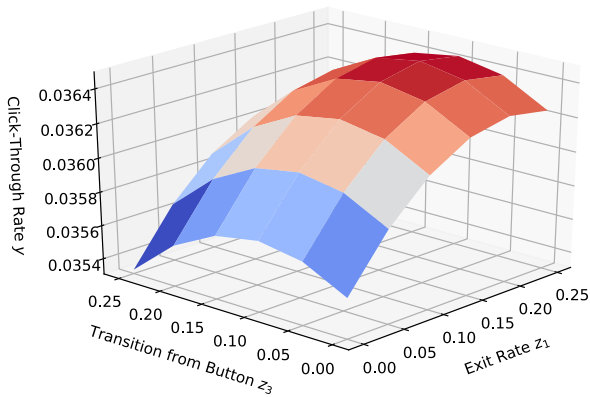


図 2: 付随情報空間 Z における目的指標 y の分布の一例。

における目的指標 y の分布の一例を図示する。この期間のバリエーション集合 X についてはセッションの終了の有無 z_1 が発生する確率が高いほど目的指標 y の期待値が高いことが読み取れる。また、「もっと見る」ボタンからの遷移の有無 z_3 については明確な傾向が読み取れなかった。提案手法を用いて学習を行うことで、フィードバック指標 z と目的指標 y の間の非線形性の関係も捉えられていることが伺える。

次に、提案手法で学習された目的指標 y の分布を用いることで、未知のバリエーション集合 X' からフィードバック指標のみにもとづいて最適なバリエーションを推定できることを評価する。ここでは比較手法として単純にガウス過程を学習データ D に適用した手法 (GP) を設定する。比較手法は学習フェーズにおいて等確率で観測する解 x を選択し、それに対応するフィードバック z と観測値 y から目的指標の分布を推定する手法である。以下では、比較手法および提案手法をそれぞれ 200 回ずつ試行した結果を示す。

図 3 に比較手法および提案手法をテストデータ D' に適用して、フィードバック情報のみから推定された最適解によって得られる目的指標の期待値の分布を示す。比較手法および提案手法によって得られる期待値の平均値はそれぞれ 0.0659, 0.0697 であった。マン・ホイットニーの U 検定の結果、この平均値の間には有意水準 0.01 以下で有意差が見られ、提案手法が比較手法に比べて有意に良い期待値の解を推定できることがわかった。未知のバリエーション集合 X' を無作為に選択した場合でも期待値は 0.0666 であるため、比較手法はパフォーマンスを改善できていないことがわかる。一方で分布に着目すると、提案手法では期待値が少ない選択肢を選ぶ頻度を小さくすることに成功していることがわかる。最も期待値の高い z_8 を支配的に選択する状態には遷移できていないものの、比較手法に比べると高い頻度で選択することができていることがわかる。このことは、提案手法が学習フェーズにおいて有望な解の観測に優先的にサンプルを割いて有効活用することで、より期待値の高い解を推定できる分布を獲得したことを示唆している。つまり提案手法を用いることで、解を提示したときのフィードバックさえ得られれば未知のバリエーションの期待値を予測できる分布を、比較手法に比べて少ないサンプルサイズで獲得できたことがわかる。

5. 結論

本研究では、ウェブサイト最適化においてバリエーションの提示がもたらす長期的効果に着目した最適化手法を提案した。




図 3: 各手法によって推定された最適解によって得られる目的指標の期待値の分布。

提案手法は、バリエーションをユーザに提示したときに得られるフィードバックに対応する目的指標の期待値の分布を効率的に学習する手法である。これによって、未知のバリエーションに対して即時に目的指標の値が得られない場合でも、即時的に観測できるフィードバック情報さえ得られれば、長期的効果を予測することができる。今回の評価実験では広告のクリック率の観測に時間がかかるものと仮定して評価を行なったが、リピート率や使用率など、定義上計測に時間がかかる目的指標についても有効に働くことを確かめるのが今後の課題である。本研究で示した枠組みを発展させていくことで、人間の満足度や共感度など、より長期的で本質的な指標に対するウェブサイト最適化手法を構築していきたいと考えている。

参考文献

- [Dmitriev 17] Dmitriev, P., Frasca, B., Gupta, S., Kohavi, R., and Vaz, G.: Pitfalls of Long-Term Online Controlled Experiments, *IEEE Transactions on Big Data* (2017)
- [Hohnhold 15] Hohnhold, H., O'Brien, D., and Tang, D.: Focusing on the long-term: It's good for users and business, in *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 1849–1858 ACM (2015)
- [Kohavi 09] Kohavi, R., Longbotham, R., Sommerfield, D., and Henne, R. M.: Controlled experiments on the web: survey and practical guide, *Data Mining and Knowledge Discovery*, Vol. 18, No. 1, pp. 140–181 (2009)
- [Li 10] Li, L., Chu, W., Langford, J., and Schapire, R. E.: A contextual-bandit approach to personalized news article recommendation, in *Proceedings of the 19th International Conference on World Wide Web*, pp. 661–670 ACM (2010)
- [Srinivas 10] Srinivas, N., Krause, A., Seeger, M., and Kakade, S. M.: Gaussian Process Optimization in the Bandit Setting: No Regret and Experimental Design, in Frnkranz, J. and Joachims, T. eds., *Proceedings of the 27th International Conference on Machine Learning*, pp. 1015–1022, Omnipress (2010)
- [White 12] White, J.: *Bandit Algorithms for Website Optimization*, O'Reilly (2012)
- [本多 16] 本多 淳也, 中村 篤祥: バンディット問題の理論とアルゴリズム, 講談社 (2016)