

クーポン配布のロバスト最適化

上原 祐輝[†] Deddy Jobson[‡] Jie Yang[§] Yilin LI[¶]
 筑波大学[†] 株式会社メルカリ[‡] 株式会社メルカリ[§] 株式会社メルカリ[¶]
 松本 健^{||} 西村 直樹^{**} 鮎川 矩義^{††} 高野 祐一^{‡‡}
 株式会社メルカリ^{||} 株式会社リクルート^{**} 法政大学^{††} 筑波大学^{‡‡}

1 はじめに

多数の利用者への電子クーポンの効果的な配布（クーポン配布）は電子商取引を運営する企業にとっての基本的な課題である。クーポン配布には次の二つの段階がある：

- (1) 各クーポンの各利用者への効果の推定
- (2) 全利用者へのクーポンの配布の最適化

一般に、(1) の推定の不確実性を (2) の最適化に反映することが望ましく、そのような性質を有する分析手法は処方分析と呼ばれる。

処方分析の従来モデルに平均・分散モデル [1] がある。同モデルは凸 2 次最適化モデルに帰着できるため計算効率が高いという利点を持つが、一方で推定の不確実性が高く、分散や共分散が有益な情報とならない場面では、性能が不安定になることが知られている。

そこで本研究では、特に推定の不確実性が高い場合の従来モデルの代替案として、クーポン配布のロバスト最適化モデルを提案する。ロバスト最適化モデルは最悪の事態を想定して最適な意思決定をするためのモデルである [2]。

2 従来モデル

従来モデルでは、まず、利用者の集合をいくつかのクラスタに分割する。クラスタの添え字集合を K とおく。また、クーポンの添え字集合を J とおく。二つの段階のうちの (1) では、各クラスタ $k \in K$ に各クーポン $j \in J$ を配布した際の 1 人当たりの効果（例：購買確率や購入金額）を推定する。

(2) では予算を考慮する。予算上限 B と各クーポン $j \in J$ の配布にかかる費用 c_j が既知とする（クラスタには依存しない）。各クラスタ $k \in K$ への各クーポン $j \in J$ の配布量を表す連続型決定変数 γ_{kj} と効果を表す確率変数 π_{kj} を導入すると、効果の平均と分散を考慮したクーポン配布の最適化モデルは以下のように定式化できる：

$$\begin{aligned} \max_{\gamma} \quad & E\left[\sum_{k \in K} \sum_{j \in J} \pi_{kj} \gamma_{kj}\right] - \lambda \text{Var}\left[\sum_{k \in K} \sum_{j \in J} \pi_{kj} \gamma_{kj}\right] \\ \text{s.t.} \quad & \sum_{k \in K} \sum_{j \in J} c_j \gamma_{kj} \leq B \\ & \sum_{j \in J} \gamma_{kj} \leq N_k \quad \forall k \in K \\ & \gamma_{kj} \geq 0 \quad \forall k \in K, \forall j \in J \end{aligned}$$

ただし、 N_k はクラスタ k に属する利用者の数である。各クラスタへの各クーポンの配布割合をポートフォリオとみなしたとき、目的関数の第 1 項は期待収益、第 2 項はリスク（分散）となっており、ブートストラップ法を用いて計算する。ここで λ は正数のパラメータである。

Robust optimization of coupon distribution

[†] Yuki Uehara, University of Tsukuba

[‡] Deddy Jobson, Mercari, Inc.

[§] Jie Yang, Mercari, Inc.

[¶] Yilin LI, Mercari, Inc.

^{||} Takeshi Matsumoto, Mercari, Inc.

^{**} Naoki Nishimura, Recruit Co., Ltd.

^{††} Noriyoshi Sukegawa, Hosei University

^{‡‡} Yuichi Takano, University of Tsukuba

3 提案モデル

まず、従来モデルと同様に、利用者の集合をクラスタに分け、その添え字集合を K とおく。また、クーポンの添え字集合を J とおく。従来モデルでは、(1) において、効果の平均と分散を利用したが、ここでは効果の平均 $\bar{\pi}_{kj}$ の信頼区間

$$[\bar{\pi}_{kj} - \alpha d_{kj}, \bar{\pi}_{kj} + \alpha d_{kj}]$$

を利用する。ここで d_{kj} は、たとえば 95% 信頼区間のように、所与の確率を担保する閾値であり、 α は正数のパラメータである。

提案するロバスト最適化モデルでは、いくつかのクラスタとクーポンの組について、その効果が信頼区間の下限値になる状況を想定する。より具体的には、各解に対して（その解に応じて）高々 Γ 個の組について効果は下限値をとるとする。 Γ は正整数のパラメータである。このような条件下で効果の総和を最大にするロバスト最適化モデルは以下のように定式化できる：

$$\begin{aligned} \max_{\gamma} \quad & \sum_{k \in K} \sum_{j \in J} \bar{\pi}_{kj} \gamma_{kj} + \min_{S \in F_{\Gamma}} \sum_{(k,j) \in S} -\alpha d_{kj} |\gamma_{kj}| \\ \text{s.t.} \quad & \sum_{k \in K} \sum_{j \in J} c_j \gamma_{kj} \leq B \\ & \sum_{j \in J} \gamma_{kj} \leq N_k \quad \forall k \in K \\ & \gamma_{kj} \geq 0 \quad \forall k \in K, \forall j \in J \end{aligned}$$

ただし、目的関数の第 2 項で S が動く範囲は、

$$F_{\Gamma} = \{S \mid S \subseteq K \times J, |S| \leq \Gamma\}$$

である。この定式化は二段階の最適化問題となっている。しかし、目的関数の第 2 項の最小化問題の双対問題を考えることで、単一の線形最適化問題に変換できる [2]。したがって、提案モデルも、従来モデル同様、厳密解の高速な求解が可能である。従来モデルではパラメータは λ のみであったのに対し、提案モデルでは α と Γ の 2 つがある。 α や Γ が大きくなるほど保守的な解が得られる。

4 数値実験

本研究では、クーポン配布実績に関する実データを用い、従来モデルと提案モデルの性能比較の実験を行なった。当日の発表ではこの比較実験の詳細について報告する。以下では、実験方法と結果の概要のみ述べる。

まず、計算時間の性能を比較した。従来モデルも提案モデルもどちらも最適化モデルとして記述できるため、Python から最適化ソルバー SCS (Ver 3.2.1) を呼び出して求解した。実際の状況を想定して数千～数万人規模の利用者を対象とし、利用者のクラスタ数を調整することで問題規模を抑えることができ、どちらのモデルでも、現実的な計算時間で求解できることを予備実験で確認している。

次に、従来モデルと提案モデルのオフライン実験による効果を検証した。無作為に選んだ 80% の利用者のデータを学習データ、残りの 20% の利用者のデータをテストデータとした。効果の推定には条件付き平均処置効果を推定する因果推論手法のうち Meta-Learner (S-Lerner) を用いた。推定結果から最適なクーポン配布案を各モデルで計算し、その有効性をテストデータで検証した。特に結果の安定性の観点から提案モデルが優れた性能を示すことを確認した。

参考文献

- [1] Lo, V. S., & Pachamanova, D. A. (2015). From predictive uplift modeling to prescriptive uplift analytics: A practical approach to treatment optimization while accounting for estimation risk. *Journal of Marketing Analytics*, 3(2), 79-95.
- [2] Bertsimas, D., & Sim, M. (2003). Robust discrete optimization and network flows. *Mathematical Programming*, 98(1), 49-71.