

# 修士論文概要書

## Master's Thesis Summary

Date of submission: 01/09/2024 (MM/DD/YYYY)

専攻名 (専門分野) Department	経営システム 工学専攻	氏名 Name	中村 友香 Nakamura Yuka	指導 教員 Advisor	後藤 正幸 印 Seal
研究指導名 Research guidance	情報数理応用研究	学籍番号 Student ID number	5222C028-8		
研究題目 Title	施策効果の高い顧客グループの特定を目的とした機械学習に基づく実験計画手法 Experimental Design Based on Machine Learning for Finding Customer Groups with High Measure Effects				

### 1. はじめに

EC サイト上でビジネスを行う多くの企業にとって、クーポン配布などのマーケティング施策は一般的になっており、より施策が合致する顧客を抽出するなど、それら施策を効率的に行う方法に関する研究も盛んに行われている[1]。本研究では、ファッション通販サイト ZOZOTOWN 内で古着を販売する ZOZOUSED[2](以下、対象企業)を対象事例とし、ポイント付与等の施策を講じる対象ユーザの選定に関する問題を考える。ZOZOUSED では、ユーザの離反を防ぐとともに定着化を図るためポイント付与等の施策を講じている。この施策では施策対象者数に応じたコストがかかるうえ、施策による影響の大小は個人差があるため、効率的かつ効果的に施策を講じるためには施策によって Life Time Value(LTV)の向上が見込まれるような施策効果が高い顧客群を特定することが重要である。これまで ZOZOUSED では、独自のロジックに基づき施策対象のユーザグループを選定していた。このような経験則に基づいた選定では施策対象が属人的な判断に依存してしまい、施策を適用することでその後の購買頻度が向上するようなユーザに対して適切にコミュニケーションが取れなかったり、施策効果が低いユーザに対する無駄打ちをしまったりする可能性がある。実際 ZOZOUSED の過去実施した施策においては、ポイントを付与したユーザが離反予備群に偏っているものもあった。この結果より、施策の非対象者中に定着率向上の効果が望めるような未開拓のユーザ群が存在する可能性が考えられる。しかし、大量の未開拓のユーザ群の中から高効果が望めるユーザ群を発見することを目的として実験的な施策を実施する場合、施策対象者数の制約に加え、施策対象者に施策効果が低いユーザを多く含んでしまうことによる利益減少リスクを伴う。そこで本研究では、未開拓のユーザ群の中から高効果が望めるユーザ群を特定するための定量的指標に基づいた実験計画手法を提案する。具体的には、予測購買単価と予測利用回数の切り口でユーザをセグメント化し、各セグメントにおける施策効果の平均と分散を基に施策対象とするセグメントを決定することで、より効率的な高効果ユーザ群の特定を目指す。最後に、ZOZOUSED で行った検証実験基に提案手法の有用性を考察する。

### 2. 準備

#### 2.1. 関連研究

機械学習を用いた施策立案手法に坪井らの研究[3]があ

る。この研究は、どのような特徴量を持つユーザ群に対して施策を打つことが有効であるかを推定する手法に関する示唆を与えている。特に効果の解釈性と観察データに含まれるユーザを人為的に選択することによる系統的な誤差(以下、選択バイアス)の除去の両立を考えたものである。効果の解釈性は回帰木のアルゴリズムを用いている因果推論手法 Causal Tree をベースにすることで可能にしている。選択バイアスの除去は、選択バイアスが存在する状況において処置効果が推定可能な手法である Doubly Robust Estimator を用いることで可能にしている。

#### 2.2. 問題設定

本研究で対象とする企業では、ユーザの離反を防ぐとともに定着化を図ることを目的として様々な施策を講じている。現状、その施策対象ユーザは独自のロジックに基づいて選定されているが、その多くは新規顧客や利用が少ない離反しそうなユーザに極端に偏っていることが明らかになっている。ここで問題点が2つ挙げられる。1つは、現状のロジックにおいて対象には当てはまらないユーザ群の中に施策効果が高い顧客が存在する可能性が考慮されていない点である。もう1つは、極端な施策対象顧客の偏りにより、このような過去のデータからは施策効果を正しく推定できない顧客群が多く存在する点である。上記の問題点を解決するためには、すべての顧客に対し施策実験を行う必要があるが、この場合コストの大幅な増加が懸念される。従って本研究では、実験対象として施策効果が未知の顧客群の中から効果が高そうな顧客群を選定する手法について検討する。

#### 2.3. 施策効果の定義

施策効果は一般に、似たようなユーザ群内における施策を実施する群(処置群)と施策を実施しない群(対照群)の群間の結果に関する平均値の差分とされる。本問題設定では、施策の実施による LTV の向上が見込める顧客群を選定することが求められるため、結果は施策前後における LTV の増加分と定義することが妥当である。ここで LTV とは、一人、あるいは法人の顧客が、特定の企業やブランドと取引を始めてから終わりまでの期間(顧客ライフサイクル)内にどれだけの利益をもたらすのかを算出したものである。この定義に準ずると、ZOZOUSED における LTV は顧客の総購入額となるが、商品の金額のばらつきが大きいゆえに、そもそも効果を算出する以前に購入金額を推定することが困難である。また、ZOZOUSED での施策実

施の目的は顧客の定着化にあるため、購入金額の増加より利用回数の増加の方が効果として望ましい。従って本研究では、処置群と対照群の群間の施策前後における平均利用回数の増加分の差分を施策効果と定義する。図1に効果のイメージ図を示す。

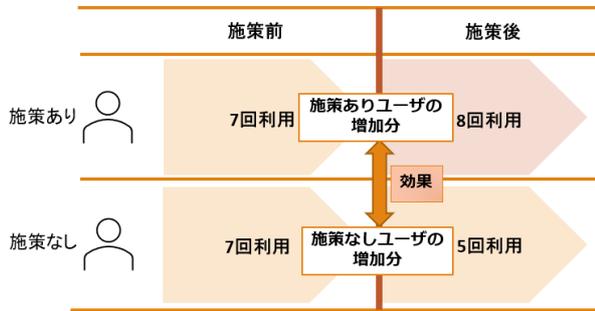


図1. 効果のイメージ図

## 2.4. 統計的因果推論と施策効果の推定

施策効果の大きさは、同じユーザに対して施策を講じなかった場合のLTVと、講じた場合のLTVの差分が観測できれば容易に算出することができる。しかし、同一ユーザに対して両者の場合のLTVを同時に観測することは不可能である。そこで、そのような場合でも疑似的に効果を算出する手法として統計的因果推論の枠組み[4]がある。

因果推論は何らかの処置  $t = \{0,1\}$  が結果  $Y$  に及ぼす効果を推測するアプローチである。通常、私たちは同一個体に対して処置を施した場合の結果  $Y_1$  と、施していない場合の結果  $Y_0$  を同時に観測することはできない。そのため、以下の「強く無視できる割り当て条件」を仮定し、処置効果を推定するというアプローチをとる。

<強く無視できる割り当て条件>

$$(Y_0, Y_1) \perp t | \mathbf{x}, \text{ and } 0 < p(t = 1 | \mathbf{x}) < 1 \text{ for all } \mathbf{x} \quad (1)$$

処置以外で結果に影響を与える特徴量である共変量を所与とするとき「強く無視できる割り当て」であるとは、「処置が施されるかどうかを表す割り当ては観測された共変量の値に依存し、観測結果の値の高低によっては依存しない」という条件のことである。割り当ては結果の測定より時間的に先行しているため、結果の値によって割り当てが決まるということはほとんどありえない。従ってこの条件の重要な点は「割り当て時までには観測された共変量」によって割り当てを説明できなくてはならず、観測されていない共変量が割り当てに影響を与えていないという点である。この条件を満たすとき、処置が施される確率は共変量によって推定でき、この確率を傾向スコアと呼ぶ。傾向スコアに近い個体同士の比較は共変量の割り当てへの影響を無視できるため、一個体の処置効果を算出する際になどに用いられる。また、処置効果は次式で表される。

(1) 平均処置効果 (ATE)

$$\begin{aligned} \mathbb{E}_{\mathbf{x} \sim p(\mathbf{x})}[\tau(\mathbf{x})] &= \mathbb{E}[Y_1 - Y_0] \\ &= \mathbb{E}[Y_1 | t = 1] - \mathbb{E}[Y_0 | t = 0] \end{aligned} \quad (2)$$

(2) 個別処置効果 (ITE)

$$\begin{aligned} \tau(\mathbf{x}) &= \mathbb{E}[Y_1 - Y_0 | \mathbf{x}] \\ &= \mathbb{E}[Y_1 | \mathbf{x}, t = 1] - \mathbb{E}[Y_0 | \mathbf{x}, t = 0] \end{aligned} \quad (3)$$

このように、ある対象者の処置効果  $Y_1 - Y_0$  は直接推定でき

なくても、処置  $t$  ごとの結果の期待値をとることで期待処置効果が推定できる。しかし因果推論は観察データを基に効果を推定する手法であるため、処置が全く行われていないユーザ群に対する効果推定を行うことは難しい。

施策実験を行ううえで、最終的に得られた結果から各ユーザの施策効果を高い精度で推定できることが望まれる。そのための実験計画手法として、ランダム化比較試験が挙げられる。これは、ユーザをランダムに施策対象(処置群)と非対象(対照群)に分ける手法である。ランダム化することで、検証したい効果以外の要因がバランスよく分かれるため、公平に比較することが可能となる。しかし本問題設定においてこの手法を用いた場合、実験が大規模になりすぎてしまううえ、今までに得られた観察データにおける施策効果に関する情報の活用が困難となる。従って本問題設定では、観察データを活用して高い施策効果が見込まれる施策実験対象者を適切に定義することが求められる。

## 3. 提案手法

本研究では、大量のログデータ(観察データ)に基づき高い施策効果が期待できるユーザグループを特定し、評価するための施策実験対象グループを設計する手法を提案する。以下に、まず概要を述べてから、詳細について示す。

### 3.1. 概要

ユーザを適切にセグメント化したうえで、因果推論を用いた正確な効果推定が難しいユーザ群の中から効果がありそうな群を特定することを考える。まずユーザのセグメント化において、一般に顧客価値が購入単価と利用回数によって定められることから、これらに基づいてセグメント化することを考えた。一方、実際の値には異常値となるものも含まれてしまうため、機械学習モデルを用いて予測購入単価と予測利用回数を算出し、これらを指標とする。機械学習モデルの構築には分析対象の過去の施策に関する情報を含む観察データとは異なる過去のデータを使用し、セグメント化したユーザ群に関して2.3節で述べたように効果を算出する。ここで、得られる効果の値は、観察データにおける施策対象者の割合がかなり小さいため不確かなものである。そこで効果の分散を Gaussian Process Upper Confidence Bound(GP-UCB)の考え方にに基づき考慮することで効果の推定を行う。

### 3.2. 手順

本研究では、過去の観察データを用いて構築した機械学習モデルによる予測購入単価と予測利用回数の切り口でユーザをグルーピングし施策効果が高そうなユーザ群を定義する。具体的な手順を以下に示す。

[提案手法の手順]

STEP1) 利用の有無を予測する2値分類器を用いて、今後の利用があると予測されたユーザのみを抽出する。

利用が少なく離反の恐れがあるユーザについては既に施策対象となっているため除外する。2値分類器は、過去のデータを用いて Light gbm[5]により構築する。

STEP2) STEP1で抽出されたユーザに対して似たようなユーザ同士でグルーピングを行うため、各ユーザの予測購入単価と予測利用回数を算出し、それに基づいて「予測利用回数が2回以上3回未満」、「予測購入単価が3000円以

上 4000 円未満」などのようにグルーピングする。

一般に、顧客価値は購入単価と利用回数によって定められる一方、実際の値には異常値となるものも含まれてしまうため、予測値を用いた。購入単価、利用回数においても過去のデータを用いて Light gbm により構築する。

STEP3) 実験対象となる顧客グループについて、各グループで適切に処置群と対照群に分け、処置群に属するユーザを施策対象とする。

対象グループには観察データを基に期待効果が高そうなグループを選定する。ここで、効果の値はグループに属する人数や施策有無の比率によって不確かさを伴うため、ここでは効果の期待値にユーザの数や偏りが考慮された標準偏差を加味したものを期待効果とする。効果の期待値を  $\mu$ 、標準偏差を  $\sigma$ 、パラメータを  $\alpha$  とすると、期待効果は式(4)のように定義される。

$$\hat{y} = \mu + \alpha\sigma \quad (4)$$

なお、処置群と対照群は効果の推定精度を上げるため 1:1 になるように分割する。

提案手法のイメージを図 2 に示す。色づけられているセグメントに属するユーザ群が施策対象者を示す。

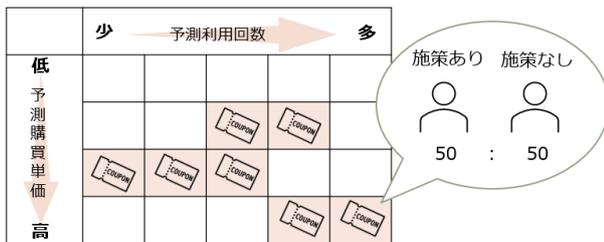


図 2. 提案手法のイメージ図

#### 4. 人工データによるシミュレーション実験

本研究で扱うデータに対し適切に式(4)のパラメータ  $\alpha$  を設定するため、実データに即して生成した人工データを用いてシミュレーション実験を行う。

##### 4.1. 人工データの生成

シミュレーション実験において、実データに対し適切にパラメータ  $\alpha$  を設定するため、人工データにおける効果の期待値と標準偏差が実データと同等の規模感である必要がある。まず各グループに適切なユーザ数を設定し、各ユーザに施策対象の有無、施策前の利用回数、施策後の利用回数を設定した。施策対象かどうかは、各グループに実データに即した施策実施割合を設定したうえで決定した。施策前の利用回数はハイパーパラメータ  $\lambda$  を持つポアソン分布からサンプリングした。  $\lambda$  は、各グループに実データに即した平均利用回数  $a$  を設定したうえで、  $k = a$ 、  $\theta = 1$  をハイパーパラメータを持つガンマ分布に従い生成した。施策後の利用回数は、離反確率  $b$  を設定し、離反の場合は 0、そうでないかつ施策対象でない場合は前述した施策前の利用回数と同様の方法で作成、施策対象の場合は前述した施策前の利用回数と同様の方法で作成したものに施策効果を決める変数  $c$  をかけたものとした。  $c$  の値はビジネス上の知見により適切に設定した。

#### 4.2. ハイパーパラメータ $\alpha$ の決定

前節で用いた各グループの平均利用回数  $a$ 、離反確率  $b$ 、施策効果を決める変数  $c$  より真の効果の値  $y$  を定義したものを式(5)に示す。

$$y = a \times (1 - b) \times (c - 1) \quad (5)$$

施策対象者数の上限を設定し、その範囲内で人工データに提案手法を適用し算出した期待効果が高い順に施策対象グループを決定し、各グループに属するユーザ数と真の効果との積の総和を算出する。これを  $\alpha = \{0.5, 1.0, 1.5, 2.0, 2.5, 3.0\}$  で行い、その結果に基づいて適切な  $\alpha$  を決定する。

#### 4.3. 実験結果と考察

図 3 に、  $\alpha$  を変化させたときの施策効果の総和の推移を示す。

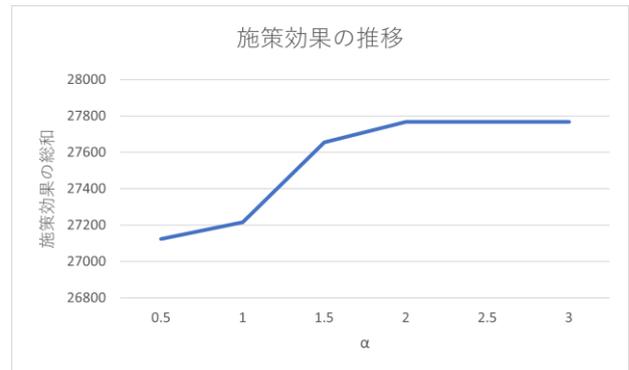


図 3.  $\alpha$  と施策効果の総和の関係

図 3 より、  $\alpha$  の値が 2.0 以上のときに施策効果の総和が高いことがわかる。一方、本研究における検証実験では、施策利用の上限に応じて施策実施期間を決定する。そのため、効果の不確か性を大きく考慮、つまり探索を重視した実験計画は、施策効果がないかつ施策利用率が高いユーザ群の存在を誘発させ、施策実施期間が短くなるという形で実験に悪影響を及ぼす可能性が高い。従って、本研究では  $\alpha = 2.0$  とする。

#### 5. 検証実験

本実験では、ZOZOUSSED における過去の購入履歴データを基に施策実験対象者を決定し、実際に施策を実施し効果検証を行う。

##### 5.1. 分析条件

提案手法内で構築する利用有無の 2 値分類器、購入単価予測モデル、利用回数予測モデルは、2020 年に購買を行ったユーザ群を対象とし学習を行った。説明変数には RFM(Recency, Frequency, Monetary) を主としたものを用いた。パラメータ  $\alpha$  は人工データを用いたシミュレーション実験より  $\alpha = 2.0$  に設定した。観察データには 2021 年に購買を行ったユーザを対象とし、施策は 2021 年 12 月に実施したものを用いた。現状施策対象になりづらいユーザの施策効果を推定することが目的のため、現状対象に含まれている新規ユーザは実験対象からは除外する。また、純粋な施策効果を検証するため、直近で施策が打たれたユーザも除外する。表 1 に観察データによって決定した施策対象グループの効果の期待値と標準偏差、期待効果を示す。

表 1. 施策対象グループの期待効果

グループ	$\mu$	$\sigma$	期待効果
(1)	0.181	1.833	3.847
(2)	2.550	0.542	3.634
(3)	2.101	0.589	3.279
(4)	1.264	0.691	2.646
(5)	-0.371	1.342	2.313
(6)	0.424	0.893	2.210
(7)	1.279	0.305	1.889
(8)	1.032	0.406	1.844
(9)	1.019	0.391	1.801
(10)	-0.047	0.831	1.615
(11)	0.666	0.316	1.298
(12)	0.571	0.336	1.243
(13)	0.424	0.399	1.222
(14)	0.646	0.261	1.168
(15)	0.712	0.228	1.168

本実験では直近1年以内に購買を行ったユーザを対象に提案手法を適用し2023年5月に施策を実施し検証を行う。また、本実験は施策実験における予算が予め決まっているため、ポイント利用数が予算の上限に達した時点で施策実施を終えた。

### 5.2. 分析結果と考察

前節に基づいて実際に施策を実施し、現段階における効果を検証した。現段階では施策実施後半年間の購買履歴のみが得られるため、施策前1年間におけるLTVの二分の一との差分を施策前後における増加分として効果を算出した。表2に検証結果を示す。

表 2. 施策対象グループの実際効果

グループ	ユーザ数	実際効果	総効果
(1)	52	-0.384	-19.968
(2)	518	0.004	2.072
(3)	392	0.066	25.872
(4)	327	0.280	91.560
(5)	86	0.034	2.294
(6)	123	-0.085	-10.455
(7)	1383	-0.007	-9.681
(8)	643	-0.107	-68.801
(9)	795	0.039	19.305
(10)	268	-0.162	-43.416
(11)	533	0.024	12.792
(12)	694	0.086	59.684
(13)	462	-0.048	-22.176
(14)	842	-0.018	-15.156
(15)	1438	0.075	107.850
合計			132.406

表2より、効果のあるユーザ群の存在が確認できた。これらは表2の標準偏差からわかるように現状施策が打たれていないユーザであるため、施策効果があると判明したことで企業にとって有益な情報をもたらすことができたといえる。効果の値は期待効果に比べてかなり小さいが、今後より長期的なスパンで改めて検証することでさらに効

果が増大することが見込める。また、施策効果の総和の合計が正の値であったことから、本実験における全体の施策効果はプラスに働いたといえる。一方で、観察データに基づいて算出した期待効果とは異なる値をとった。この要因として2つ考えられる。1つは年による需要の変化や季節要因がもたらす変動である。もう1つは短期的な効果検証に基づいている点である。古着は生活必需品ではないため、購入頻度は少ない傾向にある。それ故に短期的な効果検証による結果は、同一グループであってもユーザ間のばらつきが大きく効果の値は安定しないと考えられる。

### 6. 考察

検証実験より、提案手法によって未開拓の顧客群の中から施策効果がある顧客群を定量的な評価に基づき抽出できることが明らかになった。マーケティングにおいて顧客開拓は重要である。顧客を顧客ロイヤリティ別に5段階で分けた場合、多くの新規ユーザや離反予備軍に対する施策は1段階目の顧客を2段階目にするためのものである。しかし1段階目のみに着目した開拓が長期的かつ全体的に見たときに、必ずしも最適な方法とは限らない。本提案手法ではその他の段階における顧客開拓に着目し、その中に効果のある顧客群を特定することを可能にしたものであり、これは企業に大きな発見を与えたといえる。

### 7. 結論と今後の課題

本研究では、ファッション通販サイトZozotown内で古着を販売するZOZUSEDを対象として、ポイント付与施策未実施のユーザー群の中から高効果が望めるユーザー群を特定するための定量的指標に基づいた実験計画の手法を提案した。提案手法では、予測購買単価と予測利用回数の切り口でユーザをセグメント化し、各セグメントにおける施策効果の平均と分散を基に施策対象とするセグメントを決定した。また、検証実験により提案手法の実用性を示した。今後の課題として、観察データと実験データの融合方法の考案などが挙げられる。

### 参考文献

- [1] 平野洋介, 楊添翔, 雲居玄道, 阿部永, 立花徹也, 後藤正幸. 顧客成長を促す施策立案のための特徴転移型クラスタリングモデル. 情報処理学会論文誌, Vol. 62, No. 10, pp. 1704-1715, 2021
- [2] ZOZUSED - ブランド古着の通販・買取 - ZOZO-TOWN. <https://zozo.jp/zozoused/>
- [3] 坪井優樹, 鈴木佐俊, 後藤正幸. Causal tree に基づく選択バイアスを考慮した頑健な条件付き平均処置効果推定手法の提案. 情報処理学会論文誌, Vol. 64, No. 9, pp. 1399-1412, 2023
- [4] 星野崇宏, 岡田謙介. 傾向スコアを用いた共変量調整による因果効果の推定と臨床医学・疫学・薬学・公衆衛生分野での応用について. *J.Natl. Inst. Public Health*, 55(3), 2006
- [5] Guolin Ke, Qi Meng, Thomas Finley, Taifeng Wang, Wei Chen, Weidong Ma, Qiwei Ye, and Tie-Yan Liu. Lightgbm: A highly efficient gradient boosting decision tree. *Advances in neural information processing systems*, Vol. 30, 2017