

# 修士論文概要書

Master's Thesis Summary

Date of submission: 01 / 11 / 2023 (MM/DD/YYYY)

専攻名 (専門分野) Department	経営システム 工学専攻	氏名 Name	坪井優樹 Yuki Tsuboi	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	CD 5221C030-6		
研究題目 Title	複数の EC マーケティング施策を対象とした機械学習に基づく施策効果推定モデルに関する研究 A Study on Machine Learning Model for Effect Estimation of Multiple E-commerce Marketing Measures				

## 1. はじめに

企業が効果的なビジネス施策を講じるためには、得られた結果について正確な効果検証を行い、その結果をもとに、適切な意思決定を行うことが非常に重要な課題である。一般に、施策効果の検証のためには、ランダム化比較試験 (RCT) [1]を実施して評価することが望ましい。しかし、ビジネス活動が展開される中で全ての施策に対して RCT を実施することは一般的に困難であるため、過去の施策実施結果等を含む行動履歴データ (観察データ) が用いられる場合も多い。そのため、近年では観察データから変数間の関係性を明らかにする統計的因果推論に基づく施策効果推定が盛んに活用されている。

ここで、対象とするビジネス活動の中で蓄積された観察データには一般に、多様な因果関係の中で、複数の様々な種類の施策が実施された結果が混雑している。そのため、その中のある特定の施策効果のみを把握したいとき、他の施策効果と切り離す必要がある。故に、多様な因果関係を考慮しながら各施策効果を分離し、それぞれの効果を個別に正しく推定できるような手法が実務上求められている。このような背景から、本研究では、EC マーケティング施策の結果を含んだ行動履歴データを対象として、多様な因果関係を考慮しながら複数の様々な種類の施策に対して施策効果を推定し、各ユーザに対して最適な施策を導出することが可能な手法の提案を目指す。

複数種類の施策効果を推定可能な統計的因果推論に基づく手法として、Task Embedding based Causal Effect Variational Autoencoder (TECE-VAE) [2]が提案されている。TECE-VAE は、深層生成モデルに基づく複数種類の施策に対する効果推定手法である。また、TECE-VAE は潜在変数を用いることで、本来施策に対する結果や施策の割り当てに関係があると考えられるが観測が困難な変数も考慮して施策効果の推定ができる。しかしこの手法は、全ての潜在変数が全ての観測変数に影響を及ぼすことを仮定しており、これは観察データでは成り立たないことが多い[3]。さらに、実施の有無を二値変数で表せるような施策 (二値の施策変数) のみを対象としており、一般的に想定されるクーポン配布施策の値引き額等の連続値パラメータを含む施策 (連続的な施策変数) に対し、連続値パラメータを変化させた時の施策効果を推定することはできない。つまり、過去に配布された特定の値引き額に対する効果しか推定できない。

そこで本研究では、TECE-VAE をベースとし、多様な因果関係を考慮しながら、各ユーザに対して本来連続的である施策のパラメータを連続的に変化させた場合の施策効果を推定することが可能なモデルを提案する。まず、多様な因果関係を考慮して施策効果を推定するためには、TECE-VAE のように全ての潜在変数が観測された全ての変数に影響を及ぼすと仮定せずに、Targeted VAE (TVAE) [3]で提案されているように潜在変数を細分化して用いる。次に、連続的な施策のパラメータを連続変数として扱うために、施策をベルヌーイ分布から生成される施策と、正規分布から生成される施策の 2 種類に分けてモデル化する。

提案手法により、実際のビジネスにおいて大いに想定される、因果関係が複雑な状況においても施策効果を適切に推定することが可能となる。加えて、連続的なパラメータを持つ施策が実施されている状況において、施策内容を連続変数として扱うことで、過去に実施していなかった施策パラメータに対する施策効果の推定も可能となる。これにより、各ユーザに対して最も効果的な施策計画の立案が詳細に可能になることが期待される。さらに本稿においては、人工データを用いた推定精度評価と実データを用いたマーケティングへの実応用可能性の検証から、提案手法の有効性を示す。

## 2. 準備

### 2.1. 関連研究

施策効果を最も正しく評価する方法として、RCT の有用性が広く知られている。RCT では、実験対象のユーザを、施策を実施する群 (処置群) と実施しない群 (対照群) にランダムに分割することで、群間の結果に関する平均値の差を施策の効果とみなす。しかし実際のビジネスの現場では、様々な施策が実施されている中で、各施策を評価しなければならないことが多い。また実験的なデータの取得にはコストがかかるため、全ての施策に対して RCT を実施することは一般的に難しい。そのため、観察データから変数間の関係性を明らかにする統計的因果推論に基づく施策効果推定が広く活用されている。

近年では、マーケティング施策としてセグメントマーケティングが行われることが多いため、ユーザが持つ特徴の異質性を考慮した施策効果を推定可能な機械学習モデルの提案が盛んに行われており、代表的な手法として、ニューラルネットワークを用いた手法[2],[3]のほか、機械学習のアルゴリズムを内部的に用いて施策効果を推定する計

算フレームワーク[4]などが提案されている。ただし、これらは主に単一施策の効果推定を対象とした手法であった。

一方、近年のビジネスの活動の中で大量に蓄積された行動履歴データには、複数の様々な施策が実施された結果が混在しており、その中の特定の施策効果を把握したい場合は、他の施策効果と切り離す必要がある。そのため、各ユーザーに対して複数種類の施策効果を推定可能なモデルが実務では求められており、TECE-VAE[2]は、各施策を分離してそれぞれの効果を推定することができる。しかし、TECE-VAEが仮定するグラフィカルモデルは、観察データでは成り立たないことが多いという問題が指摘されている[3]。また、内容を二値変数で表せる施策のみを対象としており、一般的に想定されるクーポン配布施策における割引額や還元ポイント数等の連続的なパラメータを直接連続変数として扱い、効果を推定することは不可能である。

## 2.2. 施策効果の定義

施策効果を表す指標として Average Treatment Effect (ATE) と Conditional Average Treatment Effect (CATE) がある。ATE は処置群と対照群の結果に関する平均値の差であり、集団全体の効果を表す。CATE はユーザーの属性等の、因果関係に影響を及ぼすと想定される変数(共変量)の値が同じ集団に対する ATE を表す。本研究は複数種類の施策の CATE の推定を対象としているため、これを前提として、全  $N$  人中、 $i$  番目のユーザーに関する共変量を  $\mathbf{x}_i \in \mathbb{R}^J$ 、施策による結果を表すアウトカム変数を  $y_i \in \mathbb{R}$ 、全  $K$  種類の施策を、施策実施ベクトル  $\mathbf{t}_i = [t_{i1}, \dots, t_{ik}, \dots, t_{iK}]$  で表す。ここで、 $t_{ik}$  が二値変数で表される場合は  $t_{ik} \in \{0,1\}$ 、連続変数で表される場合は、 $t_{ik} \in \mathbb{R}$  とする。例えば、 $i$  番目のユーザーに対して、計 3 種の二値変数で表現される施策のうち、1 番目の施策のみが実施された場合、 $\mathbf{t}_i = [1,0,0]$  であり、CATE は  $E[y_i | \mathbf{x}_i, \mathbf{t}_i = [1,0,0]] - E[y_i | \mathbf{x}_i, \mathbf{t}_i = [0,0,0]]$  と表される。なお、「連続変数の値が 0 である = 施策を実施していない」という意味になることが望ましくない場合、連続変数に加えてその施策の実施有無を表す二値変数も施策実施ベクトルに含めることで、これを回避する。

## 2.3. TECE-VAE

TECE-VAE はエンコーダとデコーダから構成される深層生成モデルに基づく CATE 推定手法であり、適当な次元数の変換行列  $\mathbf{W}$  を用いて各施策を埋め込み空間に写像し、その空間上の特徴ベクトルを活用することで、複数種類の施策を実施する状況における CATE の推定が可能である。TECE-VAE のエンコーダを図 1、デコーダを図 2 に示す。ただし、 $\mathbf{z}_c$  は全ての観測された変数に影響を及ぼす潜在変数を表す。また、白のノードはパラメータ化されたニューラルネットワークの遷移を表し、灰色のノードは確率分布からサンプルを抽出することを表し、白丸は内積を表す。なおここでの  $\mathbf{t}_i$  は、全て二値変数の  $t_{ik}$  のみから構成される。




図 1. TECE-VAE のエンコーダの構成





図 2. TECE-VAE のデコーダの構成

## 2.4. TVAE

TVAE は、深層生成モデルに基づく CATE 推定であり、二値変数で表せる単一施策の CATE のみ推定できる。この手法は複数種類の潜在変数を仮定することで、多様な因果関係を考慮した推定を可能にしている(図 3)。ただし、 $\mathbf{z}_y$  は共変量とアウトカム変数に影響を及ぼす潜在変数、 $\mathbf{z}_t$  は共変量と施策実施の有無に影響を及ぼす潜在変数、 $\mathbf{z}_o$  は共変量のみに影響を及ぼす潜在変数を表す。



TECE-VAE

TVAE

図 3. TECE-VAE と TVAE のグラフィカルモデル

## 3. 提案手法

### 3.1. 概要

本研究では、EC マーケティング施策結果を含む行動履歴データを対象とし、複数種類の施策に対する CATE を推定し、各ユーザーに対して最適と考えられる施策を導出することが可能な手法を提案する。

ここで一般に企業に蓄積されている行動履歴データには、(1)施策の割り当てをランダムに行っていない、(2)複数種類の施策が実施されている、(3)同一の施策であってもユーザーによって効果が異なる、(4)多様な因果関係が内在している、(5)クーポン配布における割引額等の連続的なパラメータを持つ施策が実施されている、という 5 つの特徴が含まれている可能性がある。TECE-VAE では、上記の(1),(2),(3)の特徴に対応可能である。また TVAE では、(1),(3),(4)の特徴に対応可能である。したがって、提案手法では、TECE-VAE をベースとしたモデルに、TVAE のグラフィカルモデルを仮定する。加えて、内容がベルヌーイ分布から生成される施策と、正規分布から生成される施策の 2 種類に分けた上で、学習を行う。これにより、(1)-(5)の全ての特徴に対応することが可能となり、現実世界における多様な因果関係を考慮し、本来連続的な施策内容を連続変数として扱いながら CATE を推定することができる。

### 3.2. モデル式

提案手法は、TECE-VAE をベースとしたエンコーダとデコーダから構成される深層生成モデルである。提案手法のエンコーダを図 4、デコーダを図 5 に示す。図 4 と図 5 は、それぞれ図 1 と図 2 で表される TECE-VAE のエンコーダとデコーダを TVAE のグラフィカルモデルに拡張している。また、施策実施ベクトルを内容がベルヌーイ分布から生成される施策と、正規分布から生成される施策の 2

種類に分けている．具体的には，エンコーダでは，共変量ベクトル $\mathbf{x}$ を入力し，式(1)で表される各施策の実施有無を表す二値変数ベクトル $\mathbf{t}_b$ の確率分布と式(2)で表される連続変数の施策実施ベクトル $\mathbf{t}_c$ の確率分布を用いて，それぞれパラメータを推定する点を変更する．同様にデコーダでは， $\mathbf{z}_c$ ， $\mathbf{z}_t$ から式(3)-(4)で表される $p(\mathbf{t}_b|\mathbf{z}_c, \mathbf{z}_t)$ と $p(\mathbf{t}_c|\mathbf{z}_c, \mathbf{z}_t)$ を推定する点を変更する．

$$q(\mathbf{t}_b|\mathbf{x}) = \prod_{k=1}^{K_{t_b}} q_B(t_{bk}|\pi_{q_{t_b}}^{(k)}) \quad (1)$$

$$q(\mathbf{t}_c|\mathbf{x}) = \prod_{k=1}^{K_{t_c}} q_N(t_{ck}|\mu_{q_{t_c}}^{(k)}, \sigma_{q_{t_c}}^{(k)2}) \quad (2)$$

$$p(\mathbf{t}_b|\mathbf{z}_c, \mathbf{z}_t) = \prod_{k=1}^{K_{t_b}} p_B(t_{bk}|\pi_{p_{t_b}}^{(k)}) \quad (3)$$

$$p(\mathbf{t}_c|\mathbf{z}_c, \mathbf{z}_t) = \prod_{k=1}^{K_{t_c}} p_N(t_{ck}|\mu_{p_{t_c}}^{(k)}, \sigma_{p_{t_c}}^{(k)2}) \quad (4)$$

ただし， $K_{t_b}$ は二値の施策変数の数， $K_{t_c}$ は連続的な施策変数の数， $q_B(\cdot)$ ， $p_B(\cdot)$ をベルヌーイ分布の確率質量関数， $q_N(\cdot)$ ， $p_N(\cdot)$ を正規分布の確率密度関数， $\pi_{q_{t_b}}^{(k)}$ ， $\pi_{p_{t_b}}^{(k)}$ は直前の層で得られた $\mathbf{t}_b$ の要素に関するベルヌーイ分布に含まれる平均のパラメータ， $\mu_{q_{t_c}}^{(k)}$ ， $\mu_{p_{t_c}}^{(k)}$ と $\sigma_{q_{t_c}}^{(k)2}$ ， $\sigma_{p_{t_c}}^{(k)2}$ は $\mathbf{t}_c$ の要素に関する正規分布に含まれる平均と分散のパラメータを表す．

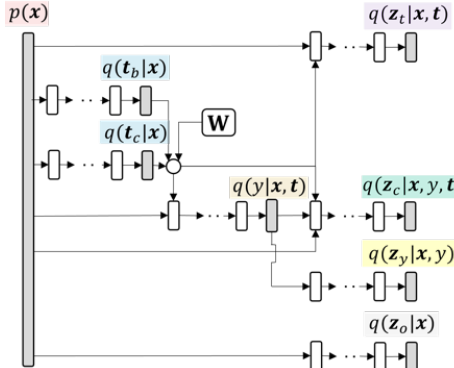


図 4. 提案手法のエンコーダの構成

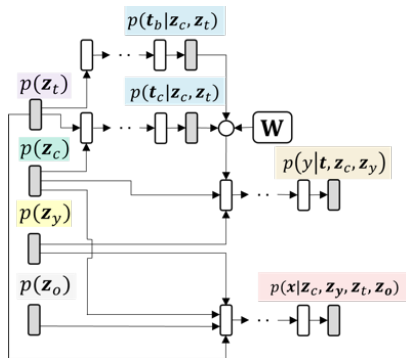


図 5. 提案手法のデコーダの構成

### 3.3. 目的関数

提案手法の目的関数 $\mathcal{F}$ は式(5)で表される変分下限

$\mathcal{L}(\mathbf{x}, \mathbf{y}, \mathbf{t})$ を用いて式(6)で表される．ただし， $q(\cdot)$ はエンコーダに関する確率密度関数または確率質量関数， $p(\cdot)$ はデコーダに関する確率密度関数または確率質量関数， $D_{KL}$ はKL情報量， $\mathbf{x}^*$ ， $\mathbf{y}^*$ ， $\mathbf{t}_b^*$ ， $\mathbf{t}_c^*$ はそれぞれ学習データにおける共変量ベクトル，アウトカム変数，二値変数の施策実施ベクトル，連続変数の施策実施ベクトルを表し， $\mathbf{t}^*$ は $\mathbf{t}_b^*$ と $\mathbf{t}_c^*$ を接続したベクトルとする．

$$\begin{aligned} \mathcal{L}(\mathbf{x}, \mathbf{y}, \mathbf{t}) = & \mathbb{E}_{q(\mathbf{z}_c|\mathbf{x}, \mathbf{y}, \mathbf{t})q(\mathbf{z}_y|\mathbf{x}, \mathbf{y})q(\mathbf{z}_t|\mathbf{x}, \mathbf{t})q(\mathbf{z}_o|\mathbf{x})} \\ & [\log p(\mathbf{x}|\mathbf{z}_c, \mathbf{z}_y, \mathbf{z}_t, \mathbf{z}_o) + \log p(\mathbf{y}|\mathbf{t}, \mathbf{z}_c, \mathbf{z}_y) \\ & + \log p(\mathbf{t}_b|\mathbf{z}_c, \mathbf{z}_t) + \log p(\mathbf{t}_c|\mathbf{z}_c, \mathbf{z}_t)] \\ & - D_{KL}[q(\mathbf{z}_c|\mathbf{x}, \mathbf{y}, \mathbf{t})||p(\mathbf{z}_c)] - D_{KL}[q(\mathbf{z}_y|\mathbf{x}, \mathbf{y})||p(\mathbf{z}_y)] \\ & - D_{KL}[q(\mathbf{z}_t|\mathbf{x}, \mathbf{t})||p(\mathbf{z}_t)] - D_{KL}[q(\mathbf{z}_o|\mathbf{x})||p(\mathbf{z}_o)] \quad (5) \end{aligned}$$

$$\begin{aligned} \mathcal{F} = & \mathcal{L}(\mathbf{x}, \mathbf{y}, \mathbf{t}) \\ & + \mathbb{E}_{q(\mathbf{z}_c|\mathbf{x}, \mathbf{y}, \mathbf{t})q(\mathbf{z}_y|\mathbf{x}, \mathbf{y})q(\mathbf{z}_t|\mathbf{x}, \mathbf{t})q(\mathbf{z}_o|\mathbf{x})} [\log q(\mathbf{t}_b = \mathbf{t}_b^*|\mathbf{x}^*) \\ & + \log q(\mathbf{t}_c = \mathbf{t}_c^*|\mathbf{x}^*) + \log q(\mathbf{y} = \mathbf{y}^*|\mathbf{x}^*, \mathbf{t}^*)] \quad (6) \end{aligned}$$

## 4. 評価実験

実データセットに対して提案手法を適用し，各ユーザーに対する施策効果の分析を行うと共に，実応用の具体的な方法について考察し，検討を行う．なお，事前に人工データを用いて提案手法の推定精度評価を行い，有効性を確認したが，本稿では詳細な結果はスペースの都合で割愛する．

### 4.1. 分析条件

ここでは，株式会社 ZOZO 提供のファッション EC サイトにおけるバナー広告施策に関するデータ及び購買履歴データを用いる．本実験では，EC サイト会員ユーザーに対して，バナー広告によるクーポン配布をしたことによる，対象施策実施期間内の購入金額に関する CATE について分析を行う．施策の結果を表すアウトカム変数 $\mathbf{y}$ は対象施策実施期間内の購入金額とし，実施施策内容は $\mathbf{t}=[$ クーポン獲得のための条件有無，表示方法 A であるか，表示方法 B であるか，配布クーポン額]で表され，配布クーポン額のみ連続変数，それ以外は二値変数である．なお，今回の施策実施期間において実施した施策は，獲得条件ありかつ表示方法 A かつ配布クーポン額 500 円，獲得条件ありかつ表示方法 B かつ配布クーポン額 500 円，獲得条件なしかつ表示方法 A かつ配布クーポン額 1,000 円，獲得条件なしかつ表示方法 B かつ配布クーポン額 1,000 円の 4 種類である．また，共変量 $\mathbf{x}$ には，ユーザーの属性情報や購買履歴や他種の施策実施情報を用いた．バナー広告データのデータ取得期間は 2021 年 8 月 1 日~10 月 31 日であり，購買履歴データのデータ取得期間は 2021 年 5 月 1 日~10 月 31 日，ユーザー数は 39,419，うち施策未実施ユーザー数は 17,854 である．モデルの学習においては，潜在変数 $\mathbf{z}_c$ ， $\mathbf{z}_y$ ， $\mathbf{z}_t$ の次元数をそれぞれ 10，潜在変数 $\mathbf{z}_o$ の次元数を 5， $\mathbf{W}$ によって写像される施策埋め込み空間の次元数を 10，中間層はエンコーダ，デコーダそれぞれ，[500,500,500,500]の 4 層とし，学習率を $1 \times 10^{-4}$ ，最適化アルゴリズムを Adam[5]と設定した．また，本分析では学習された提案手法を用いて，連続変数である配布クーポン額  $t_4 \in \{250,500,750,1000,1250,1500\}$  についての CATE をそれぞれのユーザーに対して予測する．




図 6. 各施策実施パターンにおける CATE

## 4.2. 分析条件

モデルの学習によって推定した、各施策実施パターンに対して推定された CATE の平均値を図 6 の左の図に示す。また、(a)ある施策において CATE が大きく推定されたユーザ (ユーザ 1)、(b)どの施策においても CATE が小さく推定されたユーザ (ユーザ 2) を抽出し、具体的な個別事例として考察する (図 6: (a),(b))。まず、全ユーザに関する CATE の平均値を比較すると、表示方法 B の効果が大きく、加えて、クーポン獲得のための条件がある施策の方が大きな効果を得ていた。また、配布クーポン金額別に CATE の平均値を比較すると、250 円分のクーポンと 1,250 円分のクーポン配布する場合が特に大きな効果を得られていた。このことから、全体的な傾向として、少額でもクーポンが貰えると購入に至るユーザが多いと考えられる。また、クーポンの割引額と利益の関係から 1,250 円分のクーポン配布するのが最も効果的である可能性が示唆される。さらに、(a) に示すユーザ 1 は、全体的に CATE が大きく、その中でも表示方法 B で、クーポン獲得のための条件があり、配布クーポン額が 1,250 円である施策が最も効果が大きいことが分かる。すなわち、このユーザは今後も十分に高い効果が見込め、推定された中で最も大きな効果が見込める上記のような施策を講じることが効果的であると考えられる。一方で、(b) に示すユーザ 2 は全体的に CATE が小さく、このユーザにはクーポン配布施策の効果はほとんどないことが考えられる。したがって、このようなユーザは、クーポンの配布を理由として購入に至る可能性が低い場合、施策実施の優先度の低いユーザであるといえる。

以上のように、提案手法を用いることによって各ユーザにおいて最も効果的な施策を明らかにし、さらに過去に実施していなかった施策パラメータについても効果を推定可能であるため、効果検証に基づく将来のマーケティング施策の立案が可能であるといえる。

## 5. 考察

提案手法から推定された CATE を用いることで、各ユーザの施策に対する効果を把握することが可能となる。また、これに基づいて施策実施の優先度が高いユーザを選定したり、過去に実施したことがない新たな施策を実施したりするなど、マーケティングにおける様々な一助となることが期待される。ただしユーザ選定において、実際に何%のユーザまで施策を講じるかについては、施策における目

的や予算によって検討すべきであり、推定された CATE とコストを比較した適切な判断が必要と考えられる。

## 6. 結論と今後の課題

本研究では、EC サイトの行動履歴データを対象として、ビジネスで起こり得る複数種類の施策が実施された状況やクーポン配布等の連続的な施策が実施されている状況に対応可能な施策効果の推定手法を提案した。提案手法では、潜在変数を細分化したグラフィカルモデルを構築し、施策の種類ごとに分布を仮定して、各施策が設定可能な連続パラメータを、連続入力変数として扱えるようにした。これにより、現実世界における多様な因果関係を考慮しながら、過去に未実施であった施策についても効果を推定することが可能になった。

今後の課題として、ユーザの性質や施策の種類などがより複雑な状況を仮定した人工データセットによる評価、施策効果に影響を与える共変量を特定するための手法の考案などが挙げられる。

## 謝辞

本研究は ZOZO 研究所と早稲田大学の共同研究であり、データ提供元である株式会社 ZOZO に深く感謝致します。

## 参考文献

- [1] John Crofton and DA Mitchison. Streptomycin resistance in pulmonary tuberculosis. *British medical journal*, Vol. 2, No. 4588, p. 1009, 1948.
- [2] Shiv Kumar Saini, Sunny Dhamnani, Akil Arif Ibrahim, and Prithviraj Chavan. Multiple treatment effect estimation using deep generative model with task embedding. *In The World Wide Web Conference*, pp. 1601–1611, 2019.
- [3] Matthew J Vowels, Necati Cihan Camgoz, and Richard Bowden. Targeted vae: Variational and targeted learning for causal inference. *In 2021 IEEE International Conference on Smart Data Services (SMDS)*, pp. 132–141, 2021.
- [4] Sören R Künzel, Jasjeet S Sekhon, Peter J Bickel, and Bin Yu. Metalearners for estimating heterogeneous treatment effects using machine learning. *Proceedings of the national academy of sciences*, Vol. 116, No. 10, pp. 4156–4165, 2019.
- [5] Diederik P Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.