

# 複数の施策を対象とした処置効果推定手法に関する一考察

坪井 優樹\*  
早稲田大学\*

阪井 優太†  
早稲田大学†

清水 良太郎‡  
早稲田大学/ZOZO 研究所‡

後藤 正幸§  
早稲田大学§

## 1. 研究目的・背景

企業が施策を実施する際、正確な効果検証を行った結果を用いて、適切な意思決定につなげることが非常に重要であり、近年では行動履歴データを活用した効果検証への期待が高まっている。ユーザの行動履歴データから施策効果を正しく評価するための方法として、与えられたデータから変数間の関係性を明らかにする因果推論に基づく施策効果の推定が活用されることが多い。近年、一般に大きなサービスを運営する企業における広告配信等の施策において、同時期に複数施策が実施されている。またこの際、全ての施策に関して、実施対象とするユーザの選定を同一部署で管理しているとは考えにくい。そのため、施策ごとにユーザの選定は独立に実施され、同時期に同一ユーザに対して複数施策が実施される状況は発生しやすいと考えられる。一方、一般に因果推論に基づく施策効果推定手法は、単一種類の施策における効果推定のみ焦点が当てられているため、同時期に実施した複数種類の施策効果を推定可能な手法の提案が実務上求められている。

ここで、複数種類の施策の効果を推定可能な手法として Task Embedding based Causal Effect Variational Autoencoder (以下、TECE-VAE) [1]が提案されている。この手法は潜在変数を用いて、本来施策に関係があると考えられるが観測が困難な変数を考慮した施策効果の推定を可能にしている。しかし TECE-VAE では、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ことを仮定しており、これは実データでは満たされない場合が多いことが知られている。一方で、多様な因果関係を考慮した施策効果の推定が可能な手法として、Treatment Effect by Disentangled Variational Autoencoder (以下、TEDVAE) [2]が提案されているが、この手法は単一種類の施策効果の推定のみを対象としている。

そこで本研究では、TECE-VAE と TEDVAE を参考に、同時期に実施した複数種類の施策効果を、多様な因果関係を考慮して推定可能な手法を提案する。最後に人工データを用いた推定精度評価を行い、提案手法の有効性を示す。

## 2. 施策効果の定義

施策効果を表す指標として、Average Treatment

A Study on a Method for Estimating Multiple Treatment Effects

\* Yuki Tsuboi, Waseda University

† Yuta Sakai, Waseda University

‡ Ryotaro Shimizu, Waseda University/ ZOZO Research

§ Masayuki Goto, Waseda University

Effect (以下、ATE) と Individual Treatment Effect (以下、ITE) がある。ATE は施策が実施されたユーザ群と実施されなかったユーザ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。ITE はユーザの属性等の、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。ここで、全  $N$  人中、 $i$  番目のユーザに関する  $d$  次元の共変量を  $\mathbf{x}_i \in \mathbb{R}^d$ 、目的変数を  $y_i \in \mathbb{R}$ 、施策実施の有無を  $\mathbf{t}_i = [t_{i1}, \dots, t_{ik}, \dots, t_{iK}] (t_{ik} \in \{0,1\})$  とする。例えば、 $i$  番目のユーザに対して、計 3 種の施策のうち 1 番目の施策のみ実施された場合、 $\mathbf{t}_i = [1,0,0]$  と表され、ITE は  $E[y_i | \mathbf{x}_i, \mathbf{t}_i = [1,0,0]] - E[y_i | \mathbf{x}_i, \mathbf{t}_i = [0,0,0]]$  である。

## 3. 従来手法

### 3.1 TECE-VAE

TECE-VAE は、任意の次元数の変換行列  $\mathbf{W}$  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、複数種類の施策を同時期に実施する状況における ITE の推定を可能とした手法である。また、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であり、潜在変数  $\mathbf{z}$  を用いることで、本来施策に関係すると考えられるが、観測が困難な変数を考慮した施策効果を推定することができる。TECE-VAE の損失関数  $\mathcal{F}$  は式 (1) で表される変分下限  $\mathcal{L}(\mathbf{x}, \mathbf{y}, \mathbf{t}, \mathbf{z})$  を用いて式 (2) で表される。

$$\mathcal{F} = \mathcal{L}(\mathbf{x}, \mathbf{y}, \mathbf{t}, \mathbf{z}) + \mathbb{E}_{q(\mathbf{z}|\mathbf{x}, \mathbf{y}, \mathbf{t})} [\log q(\mathbf{t} = \mathbf{t}^* | \mathbf{x}^*) + \log q(\mathbf{y} = \mathbf{y}^* | \mathbf{x}^*, \mathbf{t}^*)] \quad (2)$$

ただし、 $q(\cdot)$  はエンコーダに関する確率分布、 $p(\cdot)$  はデコーダに関する確率分布、 $D_{KL}$  は KL 情報量、 $\mathbf{x}^*$ 、 $\mathbf{y}^*$ 、 $\mathbf{t}^*$  はそれぞれ学習データにおける共変量ベクトル、目的変数、施策実施の有無に関するベクトルを表す。

### 3.2 TEDVAE

TEDVAE とは、エンコーダとデコーダから構成される ITE 推定手法であり、対象とする単一施策の ITE のみ推定できる。TEDVAE で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 1)。ただし、 $\mathbf{z}$  は全ての観測された変数に影響を及ぼす潜在変数、 $\mathbf{z}_i$  は共変量と施策実施の有無に影響を及ぼす潜在変数、 $\mathbf{z}_y$  は共変量と目的変数に影響を及ぼす潜在変数と定義する。




図 1 TECE-VAE と TEDVAE のグラフィカルモデル

## 4. 提案手法

TECE-VAE は複数の施策を対象にできるが、潜在変

数が他の全変数に影響を与えることを仮定しており、これは実データでは満たされることが多い。一方で、TEDVAEは潜在変数を細分化することで因果関係を詳細に推定可能にしているが、単一施策のみ適用可能である。そこで、本研究ではTECE-VAEをベースとしたモデルに、TEDVAEのグラフィカルモデルを仮定することにより、複数種類の施策効果を多様な因果関係を考慮して柔軟に推定可能な手法を提案する。

提案手法のエンコーダを図2、デコーダを図3に示す。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。提案手法の損失関数 $\mathcal{F}$ は式(3)で表される変分下限 $\mathcal{L}(x, y, t, z)$ を用いて式(4)で表される。

$$\begin{aligned} \mathcal{L}(x, y, t, z) &= \mathbb{E}_{q(z, z_y, z_t|x)} [\log p(x|z, z_y, z_t) \\ &\quad + \log p(y|t, z, z_y)] - D_{KL}[q(z|x)||p(z)] \\ &\quad - D_{KL}[q(z_y|x)||p(z_y)] - D_{KL}[q(z_t|x)||p(z_t)] \\ \mathcal{F} &= \mathcal{L}(x, y, t, z) + \mathbb{E}_{q(z, z_y, z_t|x)} [\log q(t = t^*|z, z_t) \\ &\quad + \log q(y = y^*|t^*, z, z_y)] \end{aligned} \quad (4)$$




図2 提案手法のエンコーダ




図3 提案手法のデコーダ

## 5. 評価実験

### 5.1 実験条件

提案手法の有効性を示すため、3種類の施策を実施した場合を想定し、多様な因果関係を含んだ人工データを用いて評価実験を行う。学習データ数は10,000件、テストデータ数は3,000件である。人工データは[2]を参考に、式(5)の仮定の下で生成した。具体的には、 $i$ 番目のユーザに関する全ての観測された変数に影響を及ぼす潜在変数 $z_i$ 、共変量と施策実施の有無に影響を及ぼす潜在変数 $z_{t_i} = [z_{t_{i1}}, z_{t_{i2}}, z_{t_{i3}}]$ 、共変量と目的変数に影響を及ぼす潜在変数 $z_{y_i}$ が存在することを仮定し、これらを用いて各ユーザに対して、共変量 $x_i = [x_{i1}, \dots, x_{i30}]$ 、目的変数 $y_i$ 、施策実施の有無 $t_i = [t_{i1}, t_{i2}, t_{i3}]$ を生成した。ここで、Bernはベルヌーイ分布を表す。

$$\begin{aligned} z_i &\sim \text{Bern}(0.5); & z_{y_i} &\sim \text{Bern}(0.5); & z_{t_{i1}} &\sim \text{Bern}(0.5); \\ z_{t_{i2}} &\sim \text{Bern}(0.5); & z_{t_{i3}} &\sim \text{Bern}(0.5); & x_{i1}, \dots, x_{i15} &\sim \text{Bern}(0.5); \\ & & & & x_{i6}, \dots, x_{i10} | z_i &\sim \mathcal{N}(z_i, 5z_i + 3(1 - z_i)); \\ & & & & x_{i11}, \dots, x_{i15} | z_{y_i} &\sim \mathcal{N}(z_{y_i}, 10z_{y_i} + 6(1 - z_{y_i})); \\ & & & & x_{i16}, \dots, x_{i20} | z_{t_{i1}} &\sim \mathcal{N}(z_{t_{i1}}, 2z_{t_{i1}} + 0.5(1 - z_{t_{i1}})); \\ & & & & x_{i21}, \dots, x_{i25} | z_{t_{i2}} &\sim \mathcal{N}(z_{t_{i2}}, 2z_{t_{i2}} + 0.5(1 - z_{t_{i2}})); \\ & & & & x_{i26}, \dots, x_{i30} | z_{t_{i3}} &\sim \mathcal{N}(z_{t_{i3}}, 2z_{t_{i3}} + 0.5(1 - z_{t_{i3}})); \end{aligned}$$

$$\begin{aligned} t_{i1} | z_{t_{i1}} &\sim \text{Bern}(0.75z_{t_{i1}} + 0.25(1 - z_{t_{i1}})); \\ t_{i2} | z_{t_{i2}} &\sim \text{Bern}(0.75z_{t_{i2}} + 0.25(1 - z_{t_{i2}})); \\ t_{i3} | z_{t_{i3}} &\sim \text{Bern}(0.75z_{t_{i3}} + 0.25(1 - z_{t_{i3}})); \\ y_i | t_i, z_i, z_{y_i} &\sim \mathcal{N}(z_i + 7t_{i1} + 6t_{i2} + 5t_{i3} + 4t_{i1}t_{i2} + 3t_{i1}t_{i3} + 2t_{i2}t_{i3} \\ &\quad + t_{i1}t_{i2}t_{i3}, 1) + \mathcal{N}(z_{y_i}, 1) \end{aligned} \quad (5)$$

ITEは各施策実施パターンにおける目的変数 $y$ の期待値と全施策が実施されなかった場合の目的変数 $y$ の期待値の差で定義される。評価指標は各施策実施パターンに対して推定したITEに関するMSEとする。従来手法(TECE-VAE)と提案手法に含まれる潜在変数 $z, z_t, z_y$ の次元数はそれぞれ20、変換行列 $W$ の次元数は10とした。また、中間層はエンコーダ、デコーダそれぞれ、[200, 200, 200]の3層とし、エポック数は100として学習を行った。

### 5.2 結果と考察

各施策実施パターンに対して推定したITEに関するMSEを表1に示す。

表1: 各施策実施パターンにおけるITEに関するMSEの比較

施策実施パターン( $t_i$ )	従来手法	提案手法	改善率
[1,0,0]	0.548	<b>0.132</b>	75.9%
[0,1,0]	0.551	<b>0.137</b>	75.1%
[0,0,1]	0.407	<b>0.056</b>	86.2%
[1,1,0]	1.436	<b>0.128</b>	91.1%
[1,0,1]	0.784	<b>0.166</b>	78.8%
[0,1,1]	1.096	<b>0.102</b>	90.7%
[1,1,1]	2.010	<b>0.093</b>	95.4%
全7パターンの平均	0.978	<b>0.116</b>	88.1%

全てのパターンで提案手法は従来手法よりも高い精度を示しており、多様な因果関係を考慮した柔軟な効果推定ができています。また、交互作用が存在する複数の施策が同時期に実施されている状況において、特に提案手法の方が高い精度を示した。以上より、提案手法は従来手法と比較して施策効果に影響を及ぼす変数同士の因果関係を正確に捉えながら、特に複数施策が同時期に実施されている状況において適切に施策効果の推定を実現できることが示唆される。

### 6. まとめと今後の課題

本研究では、TECE-VAEとTEDVAEを参考に、同時期に実施された複数種類の施策効果を、多様な因果関係を考慮して推定可能な手法を提案した。また、人工データを用いた評価実験を行い、提案手法の有効性を示した。今後の課題として、本実験とは異なる設定下での検証や実データを用いた分析などが挙げられる。

#### 謝辞

本研究の一部は、日本学術振興会(JSPS)科学研究費助成金No.21H04600の助成を受けたものです。

#### 参考文献

- [1] Shiv Kumar Saini et al. Multiple treatment effect estimation using deep generative model with taskembedding. *In The World Wide Web Conference*, pp.1601-1611, 2019.
- [2] Weijia Zhang et al. Treatmenteffect estimation with disentangled latent factors. *In Proceedings of the AAAI Conference on Artificial Intelligence*, Vol. 35, pp.10923-10930, 2021.