

Weighting approachを用いた 消費者セグメンテーションの提案

同志社大学大学院 文化情報学研究科 統計科学研究室

修士1年 小林 拓

稗田 涼真, 岡部 格明, 宿久 洋

目次

1. はじめに

- 消費者セグメンテーションと広告効果
- 本研究の目的・意義

2. データ概要

- インテージデータセット
- 広告接触と購入個数の関係について

3. 分析方法

- 正則化項付きWeighting approach
- 傾向スコア

4. 広告効果の推定と考察

- コーヒーBへの適用結果
- 既存のセグメントとの比較

5. ここまでの問題点と改善方法

- データの特徴
- Multiple Co-Inertia Analysis
- 適用結果

6. おわりに

目次

1. はじめに

- 消費者セグメンテーションと広告効果
- 本研究の目的・意義

2. データ概要

- インテージデータセット
- 広告接触と購入個数の関係について

3. 分析方法

- 正則化項付きWeighting approach
- 傾向スコア

4. 広告効果の推定と考察

- コーヒーBへの適用結果
- 既存のセグメントとの比較

5. ここまでの問題点と改善方法


- データの特徴
- Multiple Co-Inertia Analysis
- 適用結果

6. おわりに

消費者セグメンテーション

■消費者セグメンテーションとは
消費者を何らかの基準を用いて**複数のグループに分割**すること^[19]

- 消費者セグメンテーションに基づく広告戦略は、
消費者の購買行動への**有効なアプローチ**である^[15]
- セグメントごとに適切な内容の広告を、適切なタイミングで提供することで、
消費者の**購買意欲を向上**できる^[1]



[15] Valentini, S., Neslin, S. A., and Montaguti, E. (2020). Identifying omnichannel deal prone segments, their antecedents, and their consequences, *Journal of Retailing*, 96(3), 310–327.

[19] 佐藤忠彦 (2015). マーケティングの統計モデル, 統計解析スタンダード, 朝倉書店, 東京.

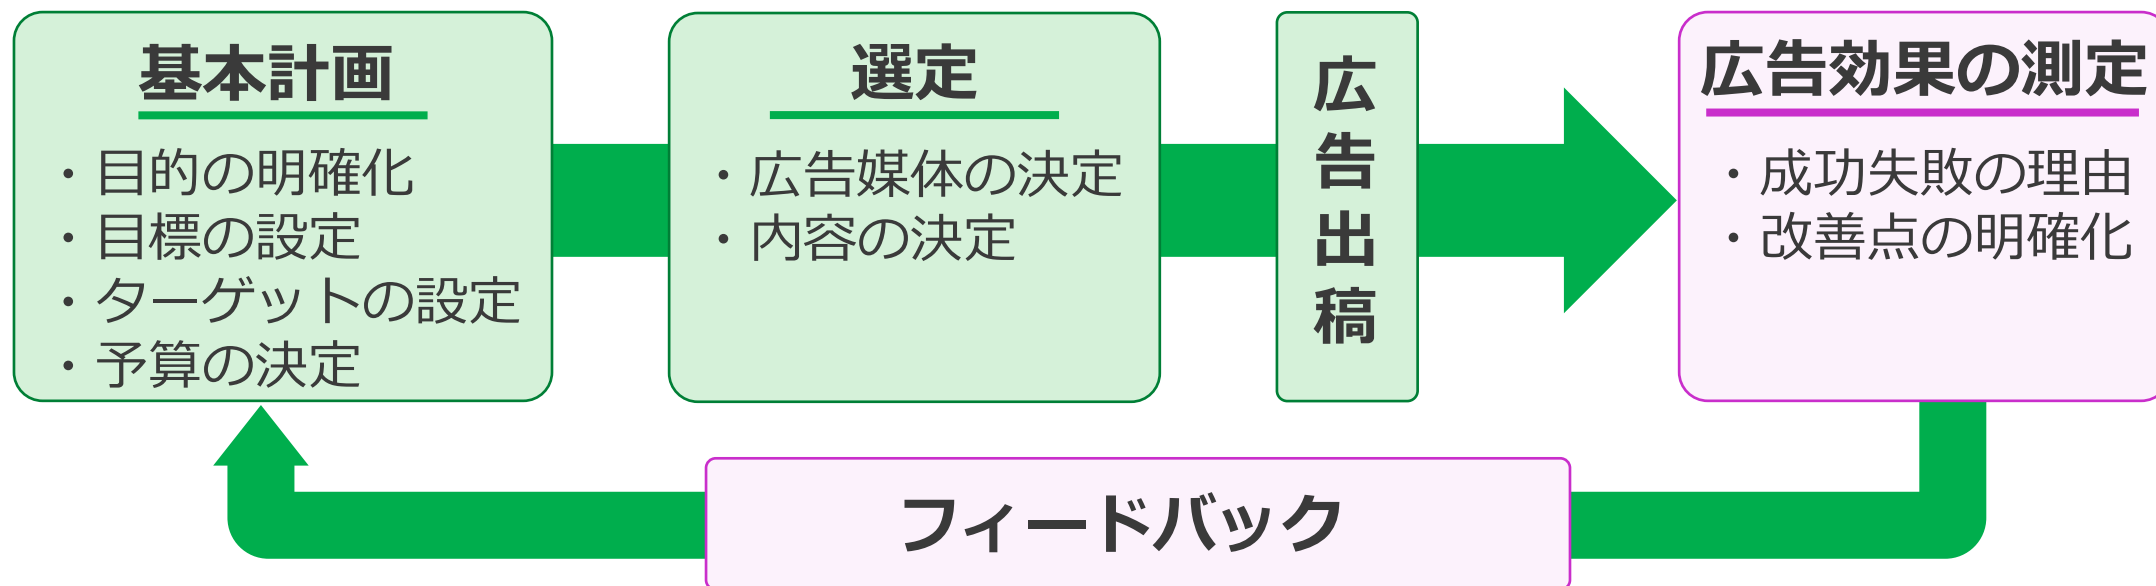
[1] Aguirre, E., Mahr, D., Grewal, D., De Ruyter, K., and Wetzels, M. (2015). Unraveling the personalization paradox: The effect of information collection and trustbuilding strategies on online advertisement effectiveness, *Journal of Retailing*, 91(1), 34–49.

広告効果

■広告効果とは、
広告出稿によって売上などのビジネス上重要な値に**与えた影響**のこと

➤広告出稿前の計画と、出稿後に行う**広告効果の測定**は同程度に**非常に重要**^[21]

・ 広告計画策定プロセス



関連研究と問題点

[-] セグメントに基づく広告効果の研究 [23]

年齢や性別の属性と消費に対する価値観をもとにしたセグメントを作成し、**それぞれのセグメントの広告効果**を商品別で求め、**広告の影響**を考察

問題点


- 1 客観的に収集された**行動ログデータに基づいた分析がされていない**
 - [-] Ohme et al. (2021)はアンケート調査では不正確さを含んでいると指摘[8]
- 2 セグメントごとの適切な**広告出稿のタイミング**を明らかにしていない
 - [-] 中野・近藤 (2018) は誰にどのようなアプローチをすべきかに加え、いつアプローチするかというタイミングが重要[24]
- 3 広告効果とは関係なく作られたセグメントにも関わらず、同じセグメントに割り振られた消費者同士は**共通の広告効果であるという仮定**がある

[23]石渡崇晶, 奥窪隆文, 本多理紗 (2020). 傾向スコアを用いた商品・顧客層別の広告効果分析 人工知能学会全国大会論文集 第34 回, 1I3GS202-1I3GS202, 一般社団法人人工知能学会.

[8] Ohme, J., Araujo, T., de Vreese, C. H., and Piotrowski, J. T. (2021). Mobile data donations: Assessing self-report accuracy and sample biases with the iOS Screen Time function, *Mobile Media and Communication*, **9**(2), 293-313.

[24]中野暁, 近藤文代 (2018). 混合隠れマルコフモデルによるオンライン・オフラインチャネル選択行動のモデリング, *オペレーションズ・リサーチ*, **63** (10), 635-646.

関連研究と問題点



- 3 広告効果とは関係なく作られたセグメントにも関わらず，同じセグメントに割り振られた消費者同士は**共通の広告効果であるという仮定**がある

本研究の目的・意義

目的

広告が影響しやすいセグメントを明らかにする方法を検討

課題の解決案

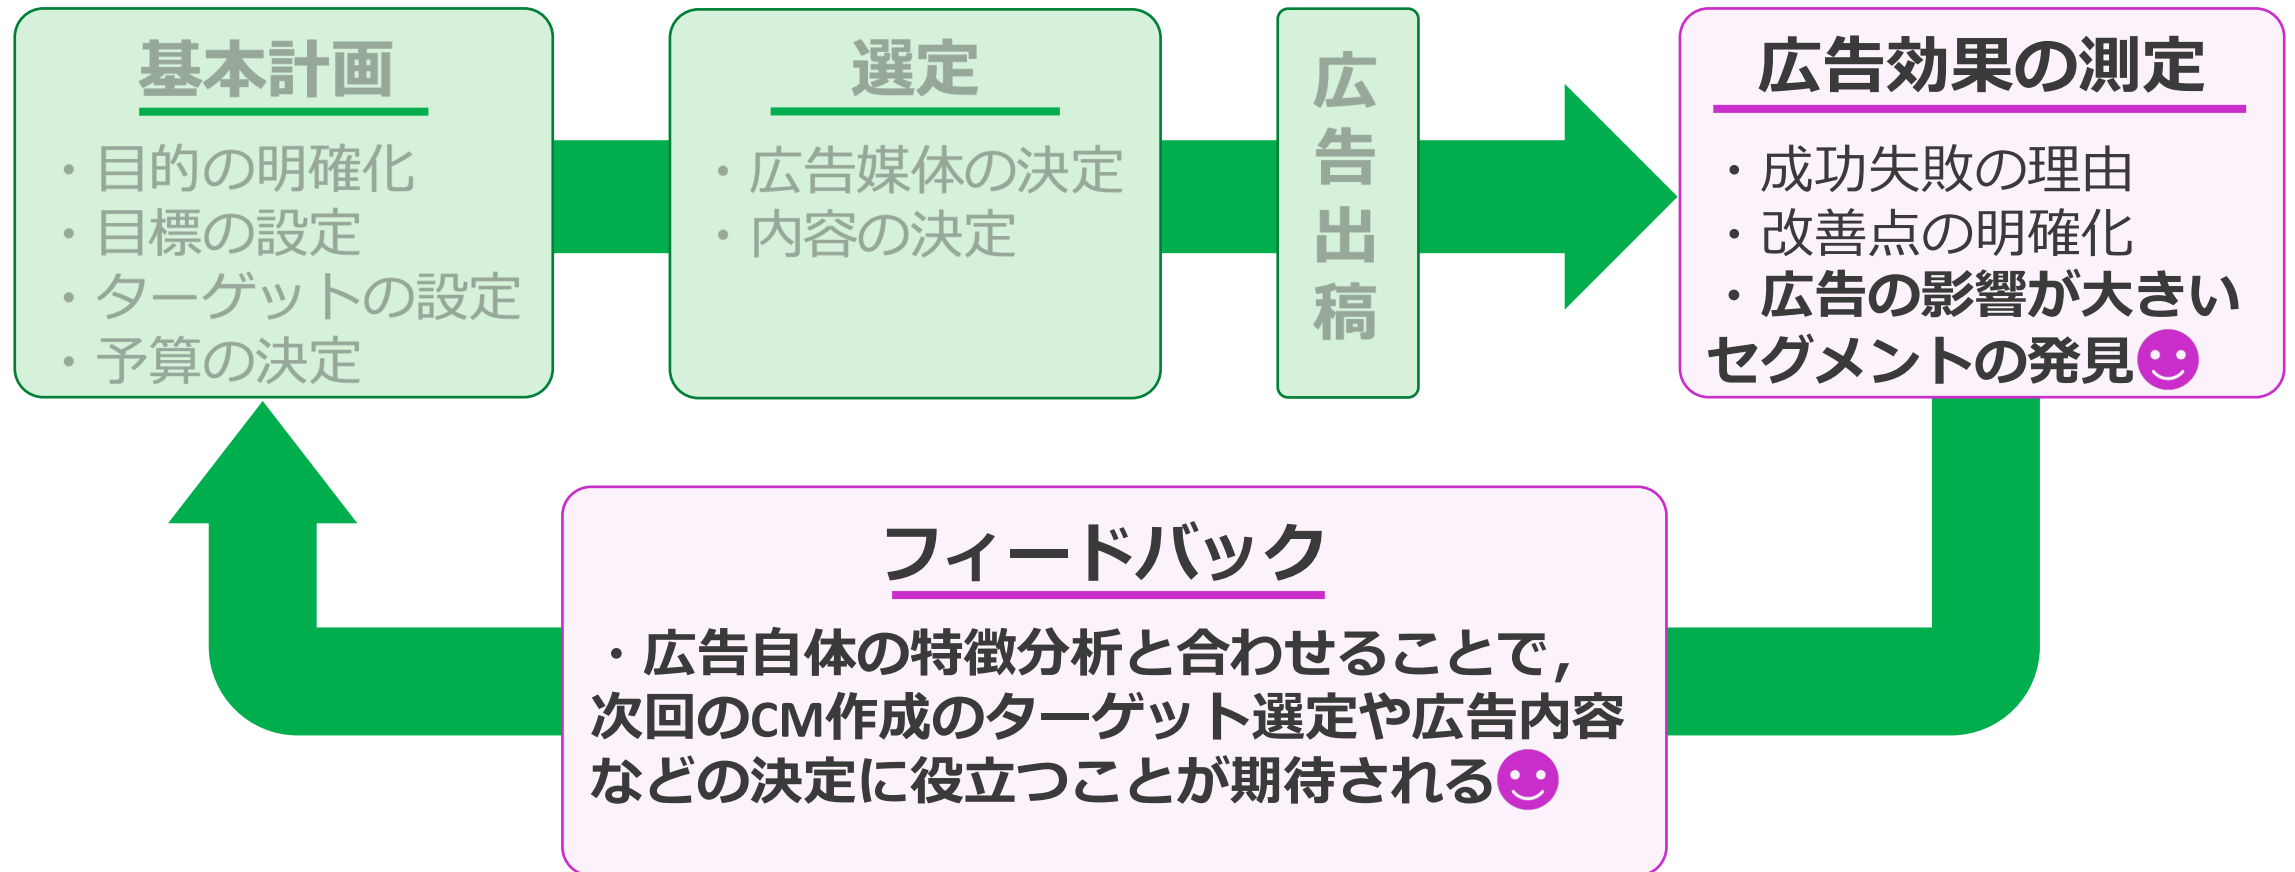
- ・ 広告効果を推定し、その大きさにセグメントに分ける
- ・ 実際の行動ログデータを用いて現実の様々なタイミングを考慮した消費者セグメンテーションを実施

意義

広告計画段階では**着目していないが広告が購買行動に強く影響を及ぼしたセグメント**を明らかにすることができる。

期待される成果

■広告の効果検証を強化でき、新たな広告作成の一助となる



目次

1. はじめに

- 消費者セグメンテーションと広告効果
- 本研究の目的・意義

2. データ概要

- インテージデータセット
- 広告接触と購入個数の関係について

3. 分析方法

- 正則化項付きWeighting approach
- 傾向スコア

4. 広告効果の推定と考察

- コーヒーBへの適用結果
- 既存のセグメントとの比較

5. ここまでの問題点と改善方法

- データの特徴
- Multiple Co-Inertia Analysis
- 適用結果

6. おわりに

データ概要

- 国立情報学研究所の IDR データセット提供サービスを通して株式会社インテージから提供されたインテージパネルデータ



インテージパネルデータ (n=700)

- ・ 個人を特徴づけるデータ
モニタ属性データ, アプリ閲覧データ,
ウェブ閲覧データ, TV番組閲覧データ
- ・ 広告との接触を表すデータ
TVCM接触データ
- ・ 購買に関するデータ
購買データ, マーケットサイズデータ

- ・ 30代男性
- ・ 主に休日にショッピングサイトを閲覧
- ・ 平日は7時と19時にニュースを閲覧



- ・ 9月29日の週にTVCMに接触

- ・ 12月10日の週にコーヒー購入

分析概要

12


基礎分析



標本の傾向

広告接触と購入個数

データ加工



変数の選定

不均衡データへの対応

本分析



広告効果推定
セグメントの解釈

適用段階の差異

分析概要

13


基礎分析



標本の傾向

広告接触と購入個数

データ加工



変数の選定

不均衡データへの対応

本分析



広告効果推定
セグメントの解釈

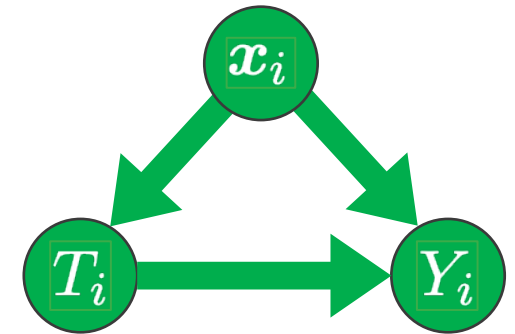
適用段階の差異

データの加工

15

■ インタージパネルデータを用いて作成 (227人×1050変数)

処置変数 T_i	TVCMの閲覧有無
結果変数 Y_i	TVCMを 閲覧した週, または翌週 の購入の有無
共変量 x_i	性別, 年齢, アプリ・ウェブ・TV番組の閲覧傾向 通常の購買量・購買傾向 (全て実際の行動)



- アプリ・ウェブ・TV番組の閲覧傾向は, 1年間のログデータを用いて作成
 <アプリ閲覧データを用いた場合>

アプリジャンル (23パターン) × 平日・休日 × 時間帯 (6パターン)

よって, 1人につき $23 \times 2 \times 6 = 276$ 列である. 値は閲覧時間 (秒数)

	ショッピングアプリ /休日/11-13時	...	ニュースアプリ /平日/6-10時	...
Aさん	3600s	...	0s	...
Bさん	300s	...	1800s	...

目次

1. はじめに

- 消費者セグメンテーションと広告効果
- 本研究の目的・意義

2. データ概要

- インテージデータセット
- 広告接触と購入個数の関係について

3. 分析方法

- 正則化項付きWeighting approach
- 傾向スコア

4. 広告効果の推定と考察

- コーヒーBへの適用結果
- 既存のセグメントとの比較

5. ここまでの問題点と改善方法

- データの特徴
- Multiple Co-Inertia Analysis
- 適用結果

6. おわりに

広告効果の推定手法

■正則化項付き Weighting approach^[2]

➤以下の目的関数を最小化する γ を推定

目的関数

$$L_{WR}(\gamma) = \frac{1}{n} \sum_i \frac{Y_i \log(1 + \exp(-T_i \mathbf{x}_i^\top \gamma / 2))}{T_i \pi(\mathbf{x}_i) + (1 - T_i) / 2} + \lambda(\alpha \|\gamma\|_1 + (1 - \alpha) \|\gamma\|_2^2)$$

Y_i : 結果変数

\mathbf{x}_i : 共変量ベクトル

γ : 共変量に対する偏回帰係数

$\pi(\mathbf{x}_i)$: 傾向スコア (後述)

λ : 大きいほど単純なモデルとなるパラメータ (非負実数)

$\alpha \in [0, 1]$: L1, L2正則化項の混合比率を表すパラメータ

$$T_i = \begin{cases} 1 & \text{(処置群)} \\ -1 & \text{(対照群)} \end{cases} : \text{処置変数}$$

i : 対象 (= 1, ..., n)

傾向スコア

■傾向スコア^[10]

- 共変量 \mathbf{X} が与えられた下での条件付き確率
- 観察データにおける選択バイアスの低減のために用いられる

傾向スコアの定義

$$\pi(\mathbf{X}) = \Pr(T = 1 | \mathbf{X})$$

傾向スコアモデル

$$\text{logit}(\pi(\mathbf{X})) = \log \frac{\pi(\mathbf{X})}{1 - \pi(\mathbf{X})} = \beta_0 + \boldsymbol{\beta}^\top \mathbf{X}$$

$\text{logit}(\cdot)$: ロジット関数

$\mathbf{X} \in \mathbb{R}^p$: 共変量ベクトル

β_0 : 切片項

$\boldsymbol{\beta}$: 偏回帰係数ベクトル

目次

1. はじめに

- 消費者セグメンテーションと広告効果
- 本研究の目的・意義

2. データ概要

- インテージデータセット
- 広告接触と購入個数の関係について

3. 分析方法

- 正則化項付きWeighting approach
- 傾向スコア

4. 広告効果の推定と考察

- コーヒーBへの適用結果
- 既存のセグメントとの比較

5. ここまでの問題点と改善方法

- データの特徴
- Multiple Co-Inertia Analysis
- 適用結果

6. おわりに

適用商品と日付

- データがなるべく偏らないように「処置を行った週」を設定
 - ▶TVCMの閲覧有り（**処置**）と購入あり（**結果**）がそれぞれ少なくとも10人以上（227人中）である週の中で無作為に1つの週を選ぶ

- コーヒー B の処置を行った週と、本分析で推定されたパラメータは以下の通り

商品	処置を行った週	α	λ
コーヒーB	9月11日	0.05	0.65

コーヒーBへの適用結果・考察

■偏回帰係数の値が上位の共変量からセグメントを考える

上位5つの共変量


personal 収入

年間購入数/野菜ジュース

age 年齢

年間購入数/コーヒー A

年間購入数/お茶 B



- ・ **収入**や**年齢**が高いセグメント
- ・ 商品に関わらず**飲み物への購買意欲**があるセグメント

適用段階での比較結果

- **広告効果によるセグメント**「広告効果の分析結果からセグメント作成」と **属性によるセグメント**「属性のセグメント作成し広告効果の分析」を比較

ターゲットを「40代以上かつ年収 400 万以上」としていた場合

広告効果によるセグメント

上位 5 つの共変量

personal 収入
年間購入数/野菜ジュース
age 年齢
年間購入数/コーヒー A
年間購入数/お茶 B

- + ターゲットとしていないが広告の影響が強い「**様々な飲み物の購買意欲があるセグメント**」の存在を明らかに

属性によるセグメント

上位 5 つの共変量

web テレビ・ラジオ/土日祝日/23~5 時
web まとめ/土日祝日/23~5 時
web まとめ/土日祝日/17~19 時
app ビジネス/土日祝日/6~10 時
app ミュージック/土日祝日/23~5 時

- + 「40代以上かつ年収 400 万以上」の **セグメント内での細かい特徴**を明らかに

分析手法	対象者	α	λ
広告効果によるセグメント	227人	0.05	0.65
属性によるセグメント	59人	0.15	1.00

適用段階での比較結果

■分析の目的に合わせて**分析の流れ**を選ぶことが望ましいといえる

広告効果によるセグメント

広告効果の大きさにセグメントがわかる
「収入や年齢が高い傾向」
「飲み物への購買意欲がある傾向」

- + 広告効果が高いセグメントを特定できる
- セグメントの解釈が難しくなる可能性

属性によるセグメント

セグメントを最初に決める
「40代以上」
「年収400万以上」

- + 決めたセグメントの広告効果がわかる
- 生活習慣や購買傾向などでセグメントを作ることができない（無数）

目次

1. はじめに

- 消費者セグメンテーションと広告効果
- 本研究の目的・意義

2. データ概要

- インテージデータセット
- 広告接触と購入個数の関係について

3. 分析方法

- 正則化項付きWeighting approach
- 傾向スコア

4. 広告効果の推定と考察

- コーヒーBへの適用結果
- 既存のセグメントとの比較

5. ここまでの問題点と改善方法

- データの特徴
- Multiple Co-Inertia Analysis
- 適用結果

6. おわりに

適用段階での比較結果（再掲）

26

■分析の目的に合わせて**分析の流れ**を選ぶことが望ましいといえる

広告効果によるセグメント

広告効果の大きさにセグメントがわかる
「収入や年齢が高い傾向」
「飲み物への購買意欲がある傾向」

- + 広告効果が高いセグメントを特定できる
- セグメントの解釈が難しくなる可能性

属性によるセグメント

セグメントを最初に決める
「40代以上」
「年収400万以上」

- + 決めたセグメントの広告効果がわかる
- 生活習慣や購買傾向などでセグメントを作ることができない（無数）

ここまでの課題

■分析の目的に合わせて**分析の流れ**を選ぶことが望ましいといえる

広告効果によるセグメント

広告効果の大きさにセグメントがわかる
「収入や年齢が高い傾向」
「飲み物への購買意欲がある傾向」

- + 広告効果が高いセグメントを特定できる
- **セグメントの解釈が難しくなる**可能性

属性によるセグメント

セグメントを最初に決める
「40代以上」
「年収400万以上」

- + 決めたセグメントの広告効果がわかる
- 生活習慣や購買傾向などでセグメントを作ることができない（無数）


➤ **説明変数**をある程度まとめ、**解釈性を向上させたい**

➤ **次元縮約手法**を用いる

次元縮約する上での問題点


■データの特徴

- ▶ ゼロ過剰のカウントデータ
- ▶ 5種類のデータセットは、スケールが異なる
- ▶ データセット間に関係がある



次元縮約手法の一つ **MCIA-FT** を用いる

データ	Min	Q1	Q2	Q3	Max
web	0	0	0	1505	4224407
app	0	0	0	1505	1859753
tv	0	0	840	9360	3037080
purchase	0	0	0	0	35722
others	0	0	0	1	10



M CIA-FT (Multiple Co-Inertia Analysis using the Freeman-Tukey transformation)

■モデル式と目的関数

$$\tilde{\mathbf{X}}_k \mathbf{Q}_k = \mathbf{F} \mathbf{u}_k^\top + \mathbf{E}_k \quad k = 1, \dots, K$$

$$\text{maximize}_{\mathbf{F}, \mathbf{u}_1, \dots, \mathbf{u}_K} \sum_{k=1}^K w_k (\mathbf{F}^\top \mathbf{D} \tilde{\mathbf{X}}_k^\top \mathbf{Q}_k \mathbf{u}_k)^2$$

ただし, $\mathbf{Q}_k \mathbf{u}_k$ と $\mathbf{D} \mathbf{F}$ は、それぞれ列間が無相関

$\tilde{\mathbf{X}}_k \in \mathbb{R}^{n \times p_k}$: 対象 n に対して観測されたカウントデータ \mathbf{X}_k に **Freeman-Tukey変換** を行った行列

$\mathbf{Q}_k = \text{diag}\{q_1, \dots, q_{p_k}\} \in \mathbb{R}^{p_k \times p_k}$: $\tilde{\mathbf{X}}_k$ の変数 (列空間) の正の重み (所与)

$\mathbf{D} = \text{diag}\{d_1, \dots, d_n\} \in \mathbb{R}^{n \times n}$: $\tilde{\mathbf{X}}_k$ のサンプル (行空間) の正の重み (所与)

$\mathbf{u}_k \in \mathbb{R}^{p_k \times m}$: $\tilde{\mathbf{X}}_k \mathbf{Q}_k$ を共通の空間へ飛ばす負荷ベクトル

$\mathbf{F} \in \mathbb{R}^{n \times m}$: 次元縮約後のスコア (ただし、 $m \ll n, p_k$)

w_k : データ間で重要度をつける重み (所与) . ただし, $\sum_k w_k = 1, 0 \leq w_k \leq 1$

Freeman-Tukey変換

■Freeman-Tukey変換（FT変換）は次の通り

$$\tilde{\mathbf{X}}_k = \sqrt{p_{ij}} + \sqrt{p_{ij} + \frac{1}{N}} - \sqrt{4p_{i.}p_{.j} + \frac{1}{N}}$$

ただし、観測されたカウントデータを $\mathbf{X}_k = x_{ij} \in \mathbb{N}^{n \times p_k}$ とするとき、

$$p_{ij} = \frac{x_{ij}}{N}, N = \sum_{i=1}^n \sum_{j=1}^{p_k} x_{ij}, p_{i.} = \sum_{j=1}^{p_k} p_{ij}, p_{.j} = \sum_{i=1}^n p_{ij}$$

- 主に**カウントデータ**や**非負のデータ**に用いられる
- この変換は分散を安定させ、**データセットの正規性を高める**ために用いられる

広告効果の推定手法（再掲）

■正則化項付き Weighting approach^[2]

➤以下の目的関数を最小化する γ を推定

目的関数

$$L_{WR}(\gamma) = \frac{1}{n} \sum_i \frac{Y_i \log(1 + \exp(-T_i \mathbf{x}_i^\top \gamma / 2))}{T_i \pi(\mathbf{x}_i) + (1 - T_i) / 2} + \lambda(\alpha \|\gamma\|_1 + (1 - \alpha) \|\gamma\|_2^2)$$

Y_i : 結果変数

\mathbf{x}_i : 共変量ベクトル

γ : 共変量に対する偏回帰係数

$\pi(\mathbf{x}_i)$: 傾向スコア（後述）

λ : 大きいほど単純なモデルとなるパラメータ（非負実数）

$\alpha \in [0, 1]$: L1, L2正則化項の混合比率を表すパラメータ

$$T_i = \begin{cases} 1 & \text{(処置群)} \\ -1 & \text{(対照群)} \end{cases} : \text{処置変数}$$

i : 対象 (= 1, ..., n)

広告効果の推定手法

■ MCIA-FTを用いた正則化項付きWeighting approach

➤以下の目的関数を最小化する γ を推定

目的関数

$$L_{WR}(\gamma) = \frac{1}{n} \sum_i \frac{Y_i \log(1 + \exp(-T_i(\mathbf{F}_i)^\top \gamma/2))}{T_i \pi(\mathbf{F}_i) + (1 - T_i)/2} + \lambda(\alpha \|\gamma\|_1 + (1 - \alpha) \|\gamma\|_2^2)$$

Y_i : 結果変数

\mathbf{F}_i : 共変量ベクトルの次元縮約後のスコア

γ : 主成分スコアに対する偏回帰係数

$\pi(\mathbf{F}_i)$: 傾向スコア (後述)

λ : 大きいほど単純なモデルとなるパラメータ (非負実数)


$\alpha \in [0,1]$: L1, L2正則化項の混合比率を表すパラメータ

$$T_i = \begin{cases} 1 & \text{(処置群)} \\ -1 & \text{(対照群)} \end{cases} : \text{処置変数}$$

i : 対象 (= 1, ..., n)

MCIA-FTを用いたWeighting approachの流れ

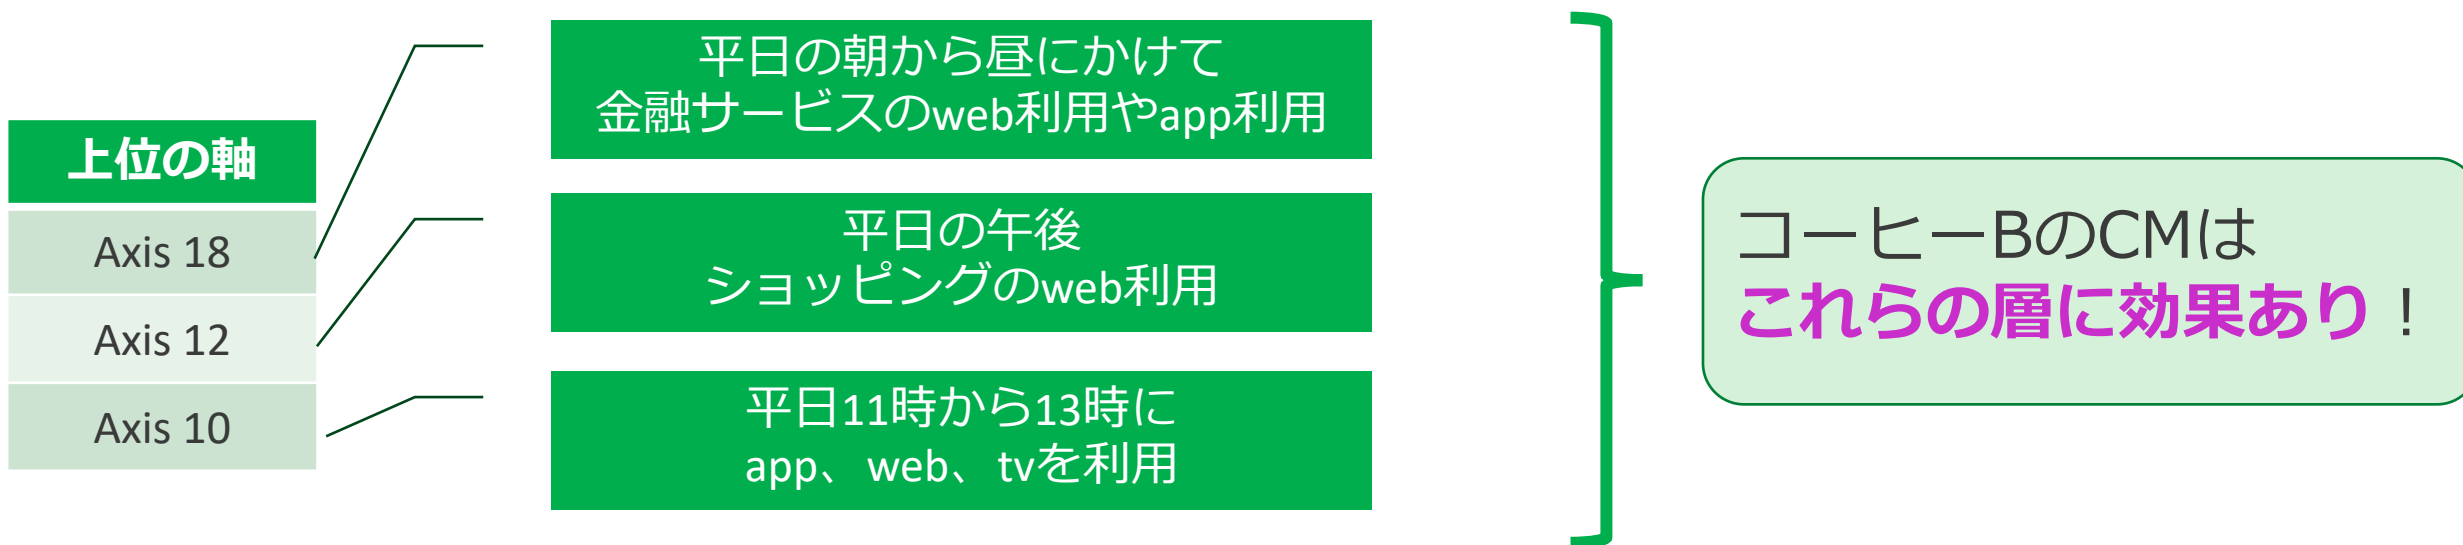
- ① それぞれのデータ行列に対し、Freeman-Tukey変換で正規化
- ② MCIAによって、説明変数を次元縮約
 - 全てのデータ行列に共通する変動を捉えた次元縮約後のスコアを取得する
- ③ 次元縮約後のスコアを用いてWeighting approachを適用
 - スコアを説明変数とし、広告効果を推定する
- ④ 偏回帰係数の値が上位の共変量の**主成分負荷量**からセグメントを考える



コーヒーBへの適用結果・考察

35

④ 偏回帰係数の値が上位の共変量の**主成分負荷量**からセグメントを考える



分析手法	対象者	α	λ
本手法 (MCIA-FT)	227人	0.05	0.25
本手法	227人	0.05	0.65
既存手法	59人	0.15	1.00

目次

1. はじめに

- 消費者セグメンテーションと広告効果
- 本研究の目的・意義

2. データ概要

- インテージデータセット
- 広告接触と購入個数の関係について

3. 分析方法

- 正則化項付きWeighting approach
- 傾向スコア

4. 広告効果の推定と考察

- コーヒーBへの適用結果
- 既存のセグメントとの比較

5. ここまでの問題点と改善方法

- データの特徴
- Multiple Co-Inertia Analysis
- 適用結果

6. おわりに

まとめ

目的

広告が**影響しやすいセグメント**を明らかにする方法を検討

分析方法

行動ログデータを用いて広告効果を推定し、その大きさを消費者セグメンテーションを行った

結果と考察

ウェブ利用傾向や**購買傾向**によるセグメントを特定した既存の考えとの差異から分析手法の強みを明らかにした

展望

色や音など広告自体の特徴量と合わせて考えることで、効果的な広告やその**影響**を強く受けるセグメントをより一層明確にすることが期待される

今後の課題

① アンケートデータとログデータの併用

- ▶ アンケートデータとともに分析することで、潜在的な考えや購買意向を考慮

② 負の広告効果の考慮

☞ 菅田（2018）は、過剰な広告接触回数により購買意欲が低下する可能性を指摘^[22]

- ▶ 接触回数や接触時間等によって異なるパラメータの値を取るモデルの開発

③ クロスメディア効果の検討

☞ Danaher et al.（2020）は様々な広告媒体を考慮した広告効果の存在を指摘^[4]

- ▶ 複数の広告媒体に接触した際の交互作用を取り入れる

[22] 菅田恭介（2015）. メディア接触と消費者特性を踏まえた負の広告効果の発生要因分析.

[4] Danaher, P. J., Danaher, T. S., Smith, M. S., and Loaiza-Maya, R. (2020). Advertising effectiveness for multiple retailer-brands in a multimedia and multichannel environment, *Journal of Marketing Research*, 57(3), 445–467.

参考文献

- [1] Aguirre, E., Mahr, D., Grewal, D., De Ruyter, K., and Wetzels, M. (2015). Un-raveling the personalization paradox: The effect of information collection and trust-building strategies on online advertisement effectiveness, *Journal of Retailing*, **91**(1),34–49.
- [2] Chen, S., Tian, L., Cai, T., and Yu, M. (2017). A general statistical frameworkfor subgroup identification and comparative treatment scoring, *Biometrics*, **73**(4),1199–1209.
- [3] Cui, X. and Jin, F. (2022). Unraveling mobile internet behavior through customersegmentation: a latent class analysis, *Electronic Commerce Research*, 1–20
- [4] Danaher, P. J., Danaher, T. S., Smith, M. S., and Loaiza-Maya, R. (2020). Adver-tising effectiveness for multiple retailer-brands in a multimedia and multichannelenvironment, *Journal of Marketing Research*, **57**(3), 445–467.
- [5] Goh, K.-Y., Heng, C.-S., and Lin, Z. (2013). Social media brand community andconsumer behavior: Quantifying the relative impact of user-and marketer-generatedcontent, *Information Systems Research*, **24**(1), 88–107.
- [6] Hoeck, L. and Spann, M. (2020). An experimental analysis of the effectiveness ofmulti-screen advertising, *Journal of Interactive Marketing*, **50**, 81–99.
- [7] Huang, J. and Ling, C. X. (2005). Using AUC and accuracy in evaluating learningalgorithms, *IEEE Transactions on knowledge and Data Engineering*, **17**(3), 299–310.
- [8] Kondo, F. N. and Okubo, T. (2022). Understanding multi-channel consumer behav-ior: A comparison between segmentations of multi-channel purchases by productcategory and overall products, *Journal of Retailing and Consumer Services*, **64**, 102792
- [9] Ohme, J., Araujo, T., de Vreese, C. H., and Piotrowski, J. T. (2021). Mobile datadonations: Assessing self-report accuracy and sample biases with the iOS ScreenTime function, *Mobile Media and Communication*, **9**(2), 293–313.
- [10] Rosenbaum, P. R. and Rubin, D. B. (1983). The central role of the propensity scorein observational studies for causal effects, *Biometrika*, **70**(1), 41–55.
- [11] Shanahan, T., Tran, T. P., and Taylor, E. C. (2019). Getting to know you: Socialmedia personalization as a means of enhancing brand loyalty and perceived quality,*Journal of Retailing and Consumer Services*, **47**, 57–65
- [12] Shi, S., Wang, Y., Chen, X., and Zhang, Q. (2020). Conceptualization of omnichan-nel customer experience and its impact on shopping intention: A mixed-methodapproach, *International Journal of Information Management*, **50**, 325–336.
- [13] Tao, L., Wang, X., Kawahara, T., and Yamasaki, T. (2020). Television advertisementanalysis using attention-based multimodal network, 人工知能学会全国大会論文集 第34 回 (2020) , 1H4OS12b01–1H4OS12b01, 一般社団法人 人工知能学会
- [14] Tibshirani, R. (1996). Regression shrinkage and selection via the lasso, *Journal ofthe Royal Statistical Society: Series B (Methodological)*, **58**(1), 267–288.
- [15] Valentini, S., Neslin, S. A., and Montaguti, E. (2020). Identifying omnichannel dealprone segments, their antecedents, and their consequences, *Journal of Retailing*,**96**(3), 310–327.
- [16] Zou, H. and Hastie, T. (2005). Regularization and variable selection via the elasticnet, *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*,**67**(2), 301–320
- [17] 安井翔太 (2020). 効果検証入門: 正しい比較のための因果推論/計量経済学の基礎, 技術評論社, 東京.
- [18] 岩崎学 (2015). 統計的因果推論, 統計解析スタンダード, 朝倉書店, 東京.
- [19] 佐藤忠彦 (2015). マーケティングの統計モデル, 統計解析スタンダード, 朝倉書店, 東京.
- [20] 佐和隆光 (2020). 回帰分析 (新装版), 統計ライブラリー, 朝倉書店, 東京.
- [21] 照井伸彦, W.D. ダハナ, 伴正隆 (2009). マーケティングの統計分析, 朝倉書店, 東京.
- [22] 菅田恭介 (2015). メディア接触と消費者特性を踏まえた負の広告効果の発生要因分析.
- [23] 石渡崇晶, 奥窪隆文, 本多理紗 (2020). 傾向スコアを用いた商品・顧客層別の広告効果分析 人工知能学会全国大会論文集 第 34 回 , 1I3GS202–1I3GS202, 一般社団法人 人工知能学会.
- [24] 中野暁, 近藤文代 (2018). 混合隠れマルコフモデルによるオンライン・オフラインチャネル選択行動のモデリング, オペレーションズ・リサーチ, **63** (10), 635–646.23