

TVCMの視聴印象と表現要素を同時最適化する ベイジアンネットワークモデルの提案

明治学院大学 心理学部心理学科 川端ゼミ

小原克揮 大谷昂生 澤村音穂 菊地凜華 大塚光 三橋怜史 箕輪碧斗 久保田美琴 清水絢香 田中紗葵 吉川日菜

1. 背景・目的

- 1.1 背景
- 1.2 CM効果の分析
事例と課題
- 1.3 分析目的
- 1.4 分析の流れ



2. データと特徴量

- 2.1 使用データ
- 2.2 TVCMの選定と特定
- 2.3 TVCM特徴量行列の作成
- 2.4 選定されたTVCM特徴量
(全79個)



3. 視聴効果の推定

- 3.1 共変量選択とIRTによる尺度化
- 3.2 傾向スコアの推定と重みの定義
- 3.3 順序プロビット回帰によるCATEの推定

4. モデル構築

- 4.1 BNによる順方向推論/逆方向推論
- 4.2 ターゲット層(8)×評価(PI, PS)別に全16個のBNを構築
- 4.3 モデル説明率と分析対象の選定
- 4.4 CATEに寄与する特徴量(視聴印象・表現要素)の抽出
- 4.5 CM改善シミュレーション1(確率推論)
- 4.6 CM改善シミュレーション2(期待値予測)



5. 提言

- 5.1 分析結果の確認
- 5.2 分析手法の提言
- 5.3 利点と活用方法



6. 課題
7. 文献

1.1 背景

日本の媒体別の広告費(2023)^{[1][2]*1}


テレビメディア広告費=1兆7347億円

インターネット広告費=3兆3330億円

2019年以降、ネット広告が上回る状態が継続(図1)



図1. 広告費の推移(単位: 億円)



TVCMの利点

- ・テレビCMは商品認知の形成や購買行動の喚起において中心的な役割を担っている^[3]
 - ・主要なゴールデンタイム帯の平均世帯視聴率は10%前後^[4]
- ➡数百万から一千万人単位の消費者に一斉にリーチできる

TVCMの短所

作成には100~5,000万円/本という高額な費用が必要^[5]
インターネット広告と比較すると1件当たりのコストは非常に大きい

近年はTVCMに割ける予算が減少傾向



- ➡ TVCMを最大限に活かすには効果的なCM構成を明確にし、費用対効果を高める必要性
- ➡ CM内容と広告効果の関係を把握することで、最大の広告効果を得ることが可能になる

*1. 合計の広告費からプロモーションメディアの広告費を引いたものを新たな合計とし、プロモーションメディアの広告費は削除。インターネット、テレビメディア、ラジオ、雑誌、新聞の五媒体とした。



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

1.2 CM効果の分析事例と課題

広告効果と構成要素のネットワークグラフからみるテレビ広告制作の提案^[6]

- ・認知・購入意向・購買行動を説明するCM内の**表現要素**(ex. 商品説明・ナレーションなど)を検証。**視聴印象は扱っていない**。また**ターゲット層や商品カテゴリの層別分析も実施されていない**。



視聴覚的なテンポを考慮したテレビCMの広告効果分析^[7]

- ・消費者層別に効果的なCM内の**表現要素**(視覚的テンポと聴覚的テンポ)を特定。**視聴印象は扱っていない & 商品カテゴリ別分析は未実施**



CMの広告効果に関する要因の探求と予測モデルの考案^[8]

- ・商品カテゴリごとに効果的なCMの**表現要素**(質的・量的特徴量)を抽出し、カテゴリ別の最適構成を特定。**視聴印象は扱っていない & ターゲット層別分析も未実施**



課題の統合

商品カテゴリとターゲット層の区別に配慮しつつ、効果量の観点から視聴印象と表現要素を同時に最適化する予測モデルは提案されていない




1.3 分析目的

CMの表現要素は、映像や演出を通じて視聴者の感情・印象に直接影響を与える^[9]。表現要素は視聴印象の前提となる構成要素と解釈できる。
両者を同時に扱うことが効果的な予測において重要

ターゲット層と商品カテゴリは組み合わせで考えるのが一般的^[10]

予測モデル



CMの特徴量を視聴印象と表現要素の両面から収集し、商品カテゴリとターゲット層を考慮した Bayesian Network(BN)^[11]を構築し、視聴印象と表現要素を最適化する予測システムを提言する。
また、企業が所有、収集可能なデータをより有効に活用できる分析枠組みを提供する。

CM出稿を考えている
企業へ手法を提言



層・商品別に
視聴印象・表現要素
を最適化したCM出稿



継続的な使用により
予測モデルの発展が可能



1.4 分析の流れ



1.基礎分析

1. 提供データの加工, 視聴回数データの作成(P.6)
2. CM動画の選定, 及びそれらを基にした特徴量行列作成(P.6~9)
3. 視聴回数データ, メインデータを基にした広告効果推定用データ作成(P.10,11)



2.広告効果推定

1. 傾向スコアを利用した重み付き順序プロビット回帰分析による, 潜在変数上の効果推定(P.12)
2. ターゲット層別効果量“CATE”の定義, 及び考察(P.13,14)



3.予測モデル構築

1. CATEと商品カテゴリ, 特徴量行列を基にした層別, 評価別BN構築, 分析対象の選定(P.15~17)
2. 順方向推論による, CATEにおける最適な視聴印象, 表現要素の抽出(P.18~20)



4.CM改善 シミュレーション1

逆方向推論による, 視聴印象及び表現要素を改善した場合における特定CMのCATE予測確率の変化の検証(P.21~23)



5.CM改善 シミュレーション2

回帰モデルを再利用した, 高CATEが予測できる場合における特定CMの視聴者評定期待値の算出, 及び比較検討(P.24,25)



6.考察,提言

1. 分析で得られた結果と考察のまとめと提言(P.26)
2. 本分析枠組みの妥当性, 有効性についての主張(P.27,28)



2.1 使用データ

提供データ



アンケートデータ

1. メインデータ, 2. テレビ番組別視聴状況

1. 個人属性, チャンネル利用, 商品別の購入実態・購入意向など
2. 2025年1月1日~3月15日における個人のテレビ番組(地上波)視聴状況



テレビ出稿データ

テレビ出稿

➡ テレビ番組別のテレビCM出稿データ



1. CM特徴量行列(P.8参照)

➡ 収集した98本のCM動画を評価者11名で視聴し, CMの視聴印象や表現要素を測定し**CM特徴量行列**を作成。




3. 視聴回数データ

➡ メインデータ, TV番組別視聴状況, テレビ出稿データから各CMの**視聴回数データ**行列を定義。



2. 広告効果推定用データ

➡ メインデータと視聴回数データを用いて, **広告効果推定のためのデータ**行列を作成。このデータ行列に基づき, 傾向スコアの推定とそれによって共変量の偏りを補正した**広告効果(ATE)**を推定する。



4. Bayesian Network 構築用データ

➡ 1. CM特徴量行列に2. 広告効果推定用データから推定した**広告効果量(ATE)**を併合し, **BN構築用データ**とした。



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

2.2 TVCMの選定と特定

cm_codeに基づく選定

「出稿データ.csv」に含まれるcm_code
➔ TVCMのコード番号

放映時間が15秒

- 該当するcm_codeは5,377本(全10,786本)
- 15秒に限定することで**放映時間の長さの違いが視聴効果に及ぼす影響を統制**

放映期間がPI, PSの測定期間に含まれている

- メインデータの商品名に対応しているcm_codeを抽出
- さらにPI, PSの測定期間に放映期間が重複していない(視聴効果が検討できない)cm_codeを削除

CM放映回数が100回以上

- 放映回数が100回未満のものは視聴効果を妥当に評価できないと判断し分析から削除した

該当するcm_codeは135個

*1. この仮定を置くことで、後のベイジアンネットワークの構築の際に利用するオブザベーションの数を確保する。さらに大規模なデータ収集が可能であるならこの仮定は不要。

CM動画の特定

Youtube / X で情報収集

- 抽出された135個のcm_codeに対応するCM動画を収集
- 分析期間中に**既に公式アカウントから削除されている**CM動画も多く、135個のcm_codeに対応するCM動画は**98本**。

複数のCM動画が存在する場合

- 同一商品やcm_codeに複数のCM動画が存在する場合(表1)にはCMを区別し、後に算出するCM特徴量と広告効果量との関係を探した。その際の効果量は同一商品内では一定とした*1。

表1. 例：cm_codeに複数のCM動画が存在する場合

商品名	CMコード	動画名
Newヤクルト類	1888090	【ヤクルト公式】受験「カラダの中のお守り（娘）」篇 15秒
Newヤクルト類		【ヤクルト公式】受験「カラダの中のお守り（母）」篇 15秒

商品カテゴリ	動画数	商品カテゴリ	動画数
(サ) サービス	25	(食) 食品	13
(パ) パーソナルケア製品	11	(生) 生活必需品	21
(飲) 飲料	9	(耐) 耐久消費財	13
(携) 携帯キャリア	6	計	98

集まった98本のCM動画を7つのカテゴリに分類した



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

2.3 TVCM特徴量行列の作成

本分析では98本のCM動画の**特徴量**とCM視聴の**効果量**の関連をBNでモデル化する
 ➡下記のフローでCMの**特徴量行列**(サイズは CM×特徴量)を作成した

！ 機械学習による特徴量抽出は技術的には可能。しかし98本のCM動画**全ての**使用許諾を得ることは難しい
 また"情緒のある"といった複雑な視聴印象は**人による評価**の方が妥当性が高いと判断

特徴量項目収集

TVCMに関する視聴印象と表現要素について**文献研究を実施**

- ・ 浅川(2009)^[12], 河原(2016)^{[9]*1}にTVCMの特徴量に関する情報が縮約。
 両論文に掲載されている文言を参考に**79個の特徴量項目(次頁に掲載)**を作成*2。
- ・ 両論文に含まれていないが重要と思われる特徴量を**分析チーム(11名)**の合議にて作成。

*1. 浅川(2009)の表1, 2, 4, 河原(2016)の表1, 3, 4に掲載されている文言をそれぞれ参考にした。

*2. 浅川先生, 河原先生には文言の引用や, 原文を踏まえた改変についてご許可を頂いた。

特徴量の測定

作成した特徴量項目に基づき**98本のCM動画を人の目で評価**

実施期間：2025年9月1日～9月8日

手続き：

- ・ 11名の評価者がCM動画を複数回視聴
- ・ 後日, 評価者全員により動画を繰り返し視聴。
 評価基準に関するコンセンサスを形成
- ・ その後, 各評価者はそれぞれ10本程度のCM動画を丁寧に視聴し, **特徴量項目リストに評価結果を記入した。**
- ・ 判断に迷う評価に関しては, その都度合議で検討し, より**妥当性の高い評価**となるよう配慮した。

特徴量行列の作成

98行(CM)×79列(特徴量)の特徴量行列を作成

表現要素 BGMや字幕の有無など **43個**

- ・ 連続量を測定する項目以外(ex. 商品名を言う回数)に該当する=1, 該当しない=0のフラグを付与(表1)

視聴印象 美しさやインパクトなど **36個**

- ・ **全項目**に該当する=1, 該当しない=0のフラグを付与*3

表1. 例：特徴量行列のイメージ

商品名	新鮮である	印象的である	頭に残る	平凡である
アゴダ	0	1	1	0
アタック	0	1	1	1
アリエール	0	1	0	1

*3. 評定尺度で測定することが理想だが, 評価負担の軽減とBNモデルの適用可能性に配慮して, 一律バイナリデータとして特徴量を測定した。



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

2.4 選定されたTVCM特徴量(全79個)

表現要素(43個)

放送回数	実写か	商品使用時のSE(回数)	ナレーションがキャッチコピーを言っているか	BGM歌詞の有無
電話番号の有無	オリジナルのキャラクターが映っているか	ネットへの誘導の有無	背景に屋内が映っているか	背景に屋外が映っているか
キャンペーンの有無	男性ナレーションか	特定層をターゲットにしているか	女性ナレーションか	流行の有無
商品との乖離	ストーリー仕立てか	メッセージ性の有無	アニメーションか	BGM歌唱の有無
男性が映っているか(エキストラを除く)	女性が映っているか(エキストラを除く)	商品が写っている秒数	BGMの有無	商品の使用結果
商品の成分	他社コラボのキャラクターが映っているか	出演者のセリフの有無	商品使用(飲食含む)秒数	使用者の意見の有無
有名人の起用	動物が映っているか	キャッチコピーの有無	商品ロゴが出るまでの秒数	ランキングの有無
出演者が踊っているか	企業名を言う回数	商品名を言う回数	企業ロゴが出るまでの秒数	商品・サービス内容の説明の有無
商品の実演	字幕の有無	テロップ文字数		

視聴印象(36個)

日常感のある	テンポが速い	商品によって味覚が刺激されそうか	商品によって触覚が刺激されそうか
商品によって嗅覚が刺激されそうか	新鮮である	面白い	印象的である
しつこい	頭に残る	飽きる	平凡である
親しみのある	情緒のある	温かみのある	分かりやすい
説明が十分である	説得力のある	信頼感のある	さわやかな
ありふれている	穏やかな	インパクトが強い	不快感がある
上品な	美しい	洗練されている	ユニークな
元気な	刺激的な	健康イメージが出ている	迫力のある
高級な	色彩が明るい	清潔な	意外性がある

先行研究に基づきTVCMの視聴印象(43個)と表現要素(36個)を抽出。
全79個の特徴量の内、**21個は当分析チームによるオリジナル**
(視聴印象では16個、表現要素では5個)。

- 本研究オリジナル
- 浅川 (2009)
- 河原 (2016)
- 浅川 (2009) & 河原 (2016)

3.1 共変量選択とIRTによる尺度化

10

以降では、ターゲット層を **男女 (M/F) 20,30,40,50代** の8層とし、広告効果の推定を行う

③ 視聴回数データから、消費者の各CMの視聴有無フラグ^{*1}を付与

^{*1}. 番組を視聴していてもCMを視聴していない場合にも配慮し、スリーヒッツ理論^[13]に基づき、視聴回数3回以上で「CM視聴有」と定義した。

③ 傾向スコア^{*2}の算出に利用するために、メインデータから共変量群を抽出(図1)

^{*2}. 共変量の各水準が持つ「処置群(視聴群)に割り当てられる確率」の情報を総合して算出される、サンプル個々の処置群(視聴群)に割り当てられる確率。

⚠ 制御焦点尺度、認知要求尺度、製品認知尺度については総計185項目あり、そのまま共変量に含めると傾向スコアが妥当に推定されなかった

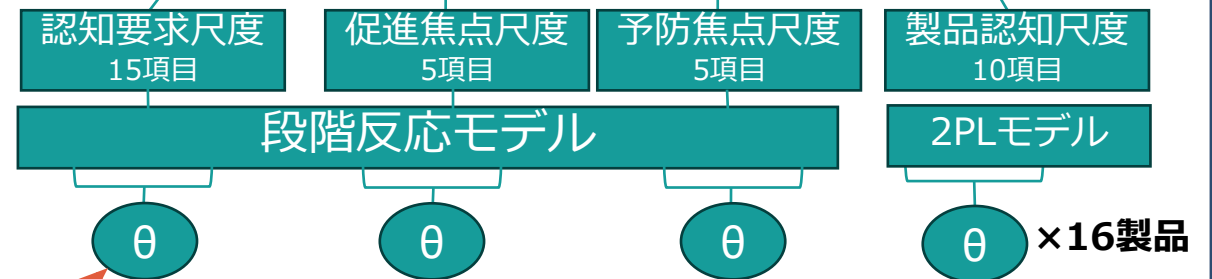
↓
IRT(項目反応理論)における潜在特性パラメタ(θ)^[14]を個人毎に推定し^{*3}共変量に含めた

続いて、以上の情報を用いて消費者別の傾向スコアを推定する

図1. 選定された共変量群

性別	年齢	未婚既婚	子どもの有無
子どもの人数	家族構成	居住地(関東)	職業
持ち家	BS視聴可否	世帯保有金融資産	世帯年収

認知要求尺度 制御焦点尺度(促進焦点) 制御焦点尺度(予防焦点) 製品認知尺度16製品



製品認知尺度：2母数ロジスティックモデル(2PLモデル)

$$P(X_j = 1 | \theta) = \frac{1}{1 + \exp[-a_j(\theta - b_j)]}$$

認知要求尺度、制御焦点尺度：段階反応モデル

$$P(X_j \geq k | \theta) = \frac{1}{1 + \exp[-a_j(\theta - b_{jk})]}$$

$$P(X_j = k | \theta) = P(X_j \geq k | \theta) - P(X_j \geq k + 1 | \theta)$$

^{*3}. 各尺度の ω 係数はmin \approx 0.55, max \approx 0.83, mean \approx 0.68



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

3.2 傾向スコアの推定と重みの定義

🎯 **傾向スコア**の推定^{*1}にはロジスティック回帰分析を利用

$$e_i = P(T_i = 1|X_i) = \frac{1}{1 + \exp[-(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})]}$$

e_i : 傾向スコア

X_i : 共変量

$T_i = \text{treat}_i$: 処置フラグ (1=視聴群, 0=非視聴群)

*1. 全消費者の全商品に対する傾向スコアを推定

🎯 **98本のCMについて同一の共変量群を基に傾向スコアを推定。**
次に、視聴群と非視聴群間の共変量の**標準化平均値差^{*2}**を当該傾向スコアに基づく**逆確率重み(IPW, Inverse Probability Weightning)**で補正した上で可視化(図1)。**補正効果を評価。**

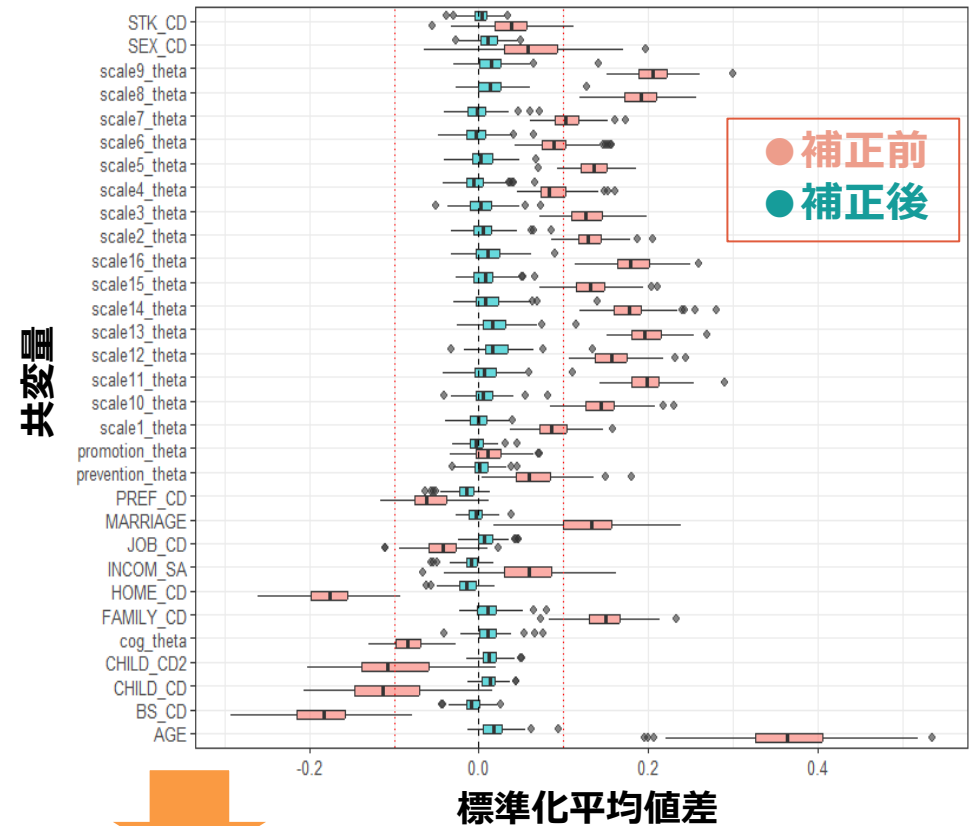
*2. ± 0.1 の範囲内で分布しているならば、両群で共変量に偏りがないと考える^[15]

❗ **購入意向(PI)・購入実態(PS)^{*3}の2時点の評価情報と**
IPWを併合した広告効果推定用データを全CM分作成した^{*4}。

*3. メインデータに含まれる、2時点で回答された様々な企業、商品の評価情報。4~7段階の順序尺度であり、特にPSは低得点部分で認知段階、高得点部分で購買傾向を測定する尺度である。

作成した広告効果推定量データに対して傾向スコア重み付き順序プロビット回帰分析を適用し、ターゲット層別にCM視聴効果を推定する

図1. 標準化平均値差の分布



補正後の平均値差は**全て ± 0.1 の範囲内に分布**。補正効果を示唆

*4. 傾向スコア上位・下位5%のデータと欠損値のあるデータを除外した。

3.3 順序プロビット回帰分析によるCATEの推定

12

⚠ **PI, PSに視聴効果が反映されると仮定。しかしPI, PSには4~7段階のスケールが混在(図1)**

➡ **傾向スコアによる重み付き順序プロビット回帰分析を適用し、離散値の背後の**潜在変数 Z^*** の尺度上で補正済みCM視聴効果を推定(尤度を傾向スコアで重みづけてパラメタ推定)**

回帰式↓

$$Z_i^* = \beta_0 + \beta_1 T_i + \beta_2 \text{PI(PS)}_{1i} + \beta_3 G_i + \beta_4 T_i \times G_i + \varepsilon_i$$

予測確率↓

$$P(K_i = k) = \Phi(\tau_k - Z_i^*) - \Phi(\tau_{k-1} - Z_i^*)$$

Z_i^* : 潜在的な連続変数

β_0 : 切片

β_1 : 視聴有無の効果

β_2 : 1時点目の評価の効果

β_3 : 所属層の効果

β_4 : 視聴有無と所属層の交互作用

PI(PS)_{1i} : 1時点目の評価

G_i : 所属層

K_i : 観測される順序尺度得点

τ_k : 順序カテゴリの閾値

ε_i : 誤差項

Φ : 標準正規分布の累積分布関数

モデリングのポイント

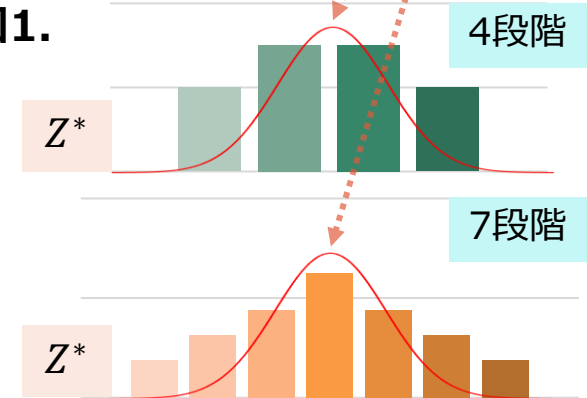
1. **1時点目のPI, PSは統制変数として投入。その影響を排除**

→2時点での差得点を従属変数とすると視聴効果が負になりやすく解釈が難しい

2. **β_4 にターゲット層別の視聴効果を表現**

→視聴有無とターゲット層の交互作用効果として視聴効果を定義。元来, TVCMはターゲット層を想定して構成されている^[10]ので層別分析が妥当と判断

図1.



尤度を傾向スコアで重み付けすることによる標準誤差の過小評価を避けるため、Rの関数: svydesignとsvyolr^[16]を用いて**ロバスト標準誤差**を算出。順序プロビット回帰の係数も上述の関数を用いて推定。

続いて、回帰式を全消費者に適用して得られた全CMに対する補正済み Z^* から効果量を定義、推定する



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

3.3 順序プロビット回帰分析によるCATEの推定

13

補正済みZ*を視聴群と非視聴群で比較。その平均差を効果量(ATE, Average Treatment Effect)として定義。さらに, ターゲット層で条件づけたATEを**CATE(Conditional ATE)**とする。

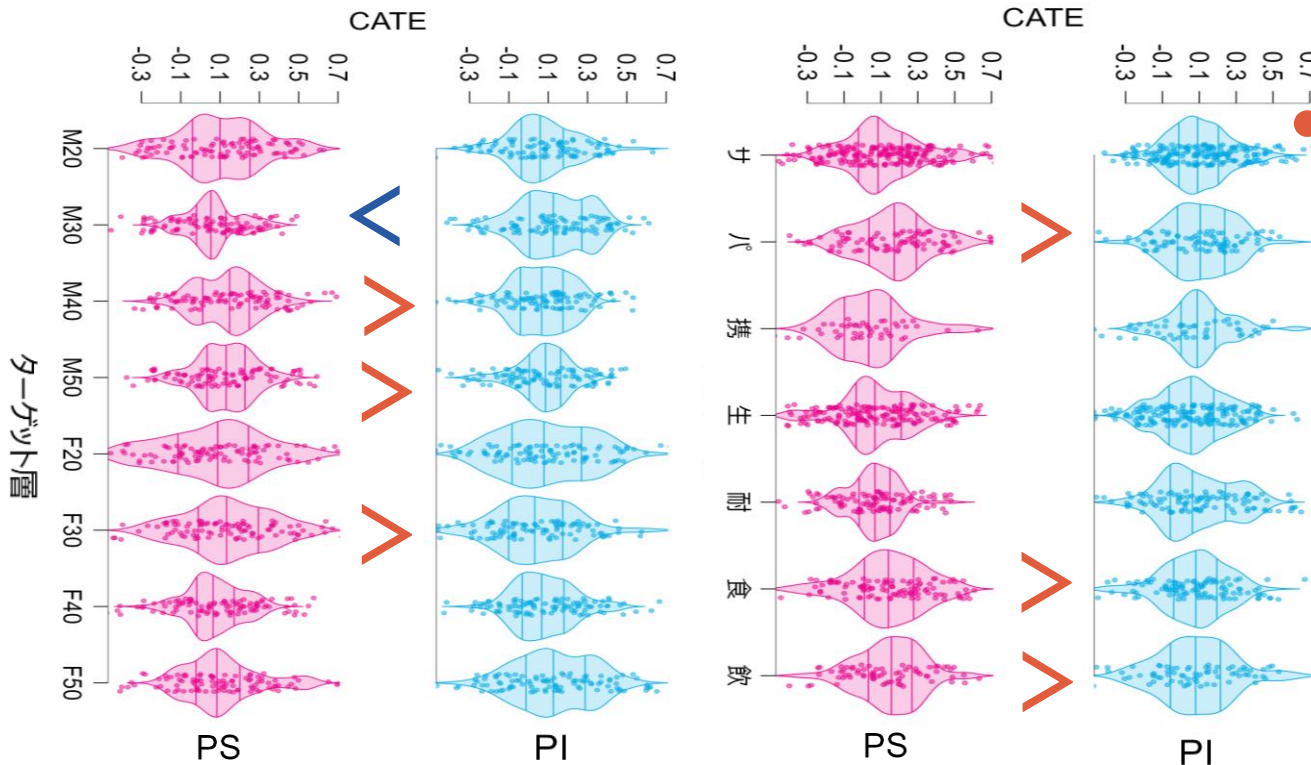
$$CATE(G = g)$$

$$= [\beta_0 + \beta_1(T = 1) + \beta_2PI(PS)_1 + \beta_3g + \beta_4(T = 1, g)]$$

$$- [\beta_0 + \beta_1(T = 0) + \beta_2PI(PS)_1 + \beta_3g + \beta_4(T = 0, g)] = \beta_1 + \beta_4g$$

図1. 評定・ターゲット層別CATE分布

図2. 評定・商品カテゴリ別CATE分布



①ターゲット層別比較(図1)

- ・ M30では **PS < PI**
- ・ M40, 50, F30では **PS > PI**

②商品カテゴリ別比較(図2)

- ・ パーソナルケア用品, 飲料, 食品の3カテゴリで **PS > PI**

全体的にPSの平均値が有意に大きくなる傾向

CATE分布と得られた比較結果の考察

1. テレビCMの広告効果は, 購入実態の方がより期待できる場合が多い
2. 特に中高年齢層や, 安価な消費物には安定した効果を見込める可能性が高い

続いて, ロバスト標準誤差で補正したp値を基に5%水準で有意なCATEを持つCM群について, より詳細な考察を行う



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

3.3 順序プロビット回帰分析によるCATEの推定

表1. M40PIで有意なCATEを持つCM群

テレビCM	カテゴリ	CATE
マクドナルド 1	食品	0.340
マクドナルド 9	食品	0.316
レノア2	生活必需品	0.312
UQ_mobile1	携帯キャリア	-0.293
マクドナルド6	食品	0.276
doda1	サービス	-0.260
金麦4	飲料	0.229
ユーキャン6	サービス	0.228
トヨタ自動車2	耐久消費財	0.211
PayPay	サービス	0.181

表3. F20PIで有意なCATEを持つCM群

テレビCM	カテゴリ	CATE
UQ_mobile1	携帯キャリア	0.740
マクドナルド10	食品	0.492
積水ハウス	耐久消費財	0.438
アート引越センター1	サービス	0.401
ユーキャン5	サービス	-0.390
SoftBank2	携帯キャリア	0.389
PayPay	サービス	0.386
マクドナルド5	食品	0.363
レノア2	生活必需品	0.328
楽天モバイル	携帯キャリア	-0.272

表2. M40PSで有意なCATEを持つCM群

テレビCM	カテゴリ	CATE
トヨタ自動車2	耐久消費財	0.358
金麦1	飲料	0.330
丸亀製麺2	食品	0.324
本麒麟1	飲料	0.278
Galaxy2	生活必需品	-0.277
マクドナルド4	食品	0.269
積水ハウス	耐久消費財	0.231
金麦4	飲料	0.226
アゴダ2	サービス	0.211
UQ_mobile1	携帯キャリア	0.199

表4. F20PSで有意なCATEを持つCM群

テレビCM	カテゴリ	CATE
Galaxy3	生活必需品	-0.569
TSUBAKI (シャンプー,コンディショナー)	パーソナルケア用品	0.520
SoftBank3	携帯キャリア	0.433
一番搾り	飲料	-0.350
ニトリ5	生活必需品	0.347
クラリチンEX	パーソナルケア用品	0.330
金麦4	飲料	-0.307
丸亀製麺1	食品	0.307
ドコモ光	サービス	0.290
アゴダ1	サービス	0.276

有意なCATEを持つCM群(表1～4は一部抜粋)の考察

- ・食品や日用品のCMは効果が安定傾向
 - ・飲料, 特にお酒のCMは高年齢層に効果的
 - ・携帯キャリアのCMは若年層, 特にPIに効果的
- ➡1. 商品カテゴリによる訴求力の差異をキャッチしている可能性
- ・同じ企業, 商品でもターゲット層で効果的なCMが異なる
(例: マクドナルド, 丸亀製麺)
- ➡2. CM構成段階での企業のターゲティング戦略の現れと考えられる
- ・同じ層内でPIは逆効果でも, PSに高効果なCMが一定数存在
(例: M40におけるUQ_mobile)
 - ・反対に「PSが逆効果でPIには高効果」というCMは少数
- ➡3. 優先順位はPS>PIで, 良くも悪くも印象的なCMは認知段階に好影響と解釈可能

以上のように分析結果についてある程度一般性を持った解釈が可能。推定されたCATEと分析過程の妥当性の証左と捉えることができる。


4.1 BNによる順方向推論/逆方向推論

15

推定されたCATEを用いて、**視聴印象と表現要素を同時最適化するBNを層別に構築する**^{*1}。

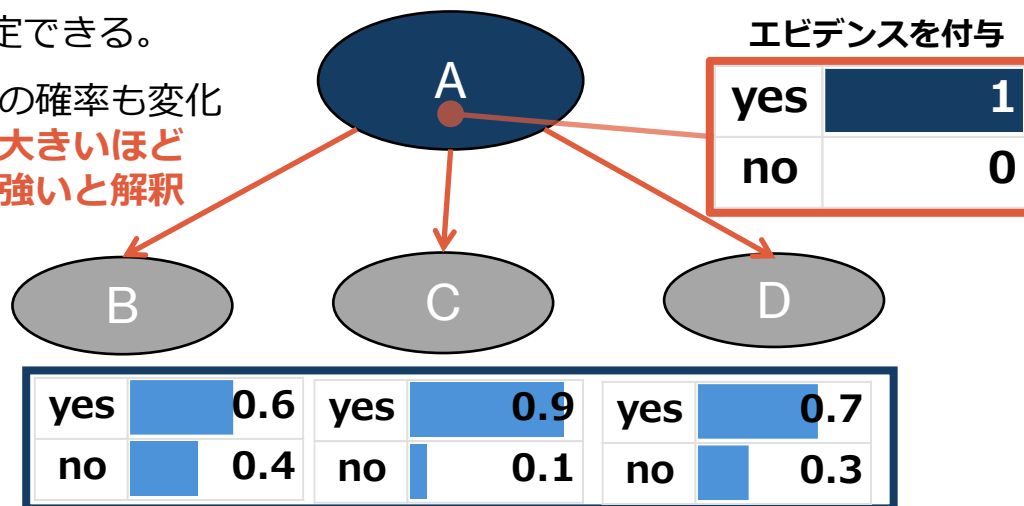
Bayesian Network (BN)とは^[11]

複数の確率変数の間の定性的な依存関係をグラフ構造によって表し、個々の変数の間の定量的な関係を条件付確率で表した確率モデル

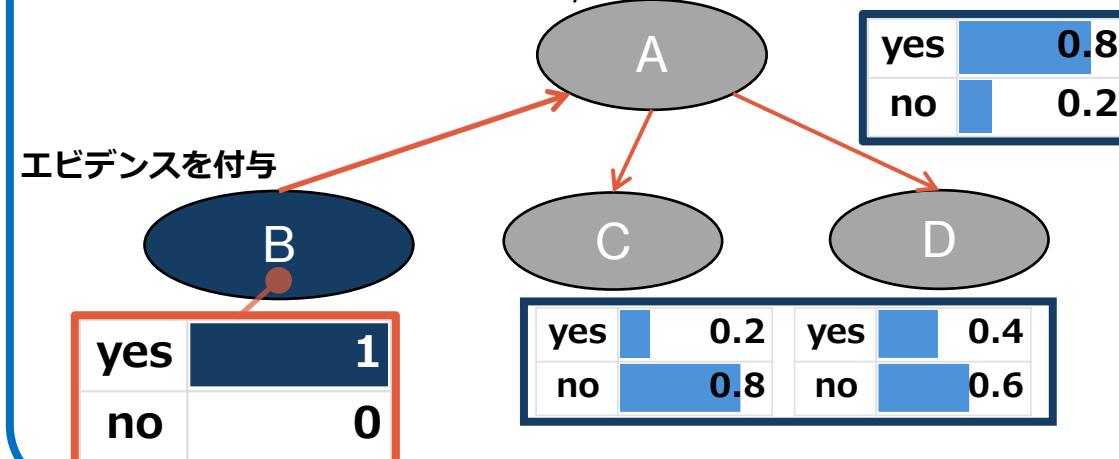


【**順方向推論**】 $P(B|A)$ というBNが構築されたとして、Aの水準に**エビデンス**(evidence)を与えたときの、Bの条件付き確率を推定できる。

他事象の確率も変化
変化が大きいほど
関連が強いと解釈



【**逆方向推論**】 $P(B|A)$ というBNが構築されたとして、ベイズの定理から $P(A|B)$ の逆方向推論も可能となる。例えば、Bの水準に**エビデンス**を与えることで、Aの事後確率を推定できる。



^{*1}. BNの構築にはRのパッケージbnlearn^[17], gRain^[18]を使用。bn.fit()で各ノードの条件付確率分布を学習。as.grain()で確率伝搬ネットワークに変換。querygrain()で各ノードの確率を取得。setEvidence()でノードの観測値を固定し、各ノードの周辺確率を更新。



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

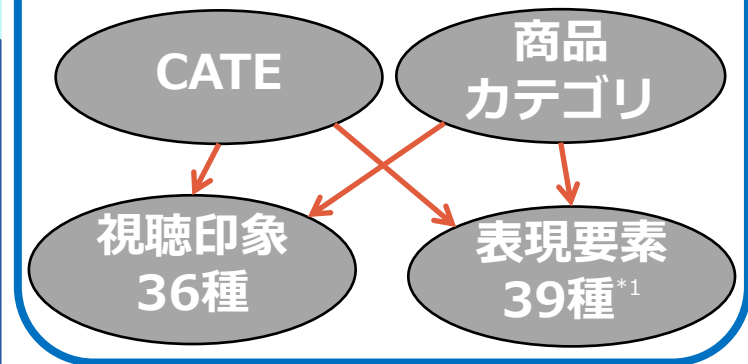
4.2 ターゲット層(8)×評価(PI, PS)の全16個のBNを構築¹⁶

商品カテゴリとCATEを親ノード、CMの全特徴量を子ノードとする単層構造
特徴量間の依存関係はモデリングしないNaive Bayes的モデル

モデリングのポイント

- 効果量CATEをNaive Bayes の**ターゲットノード**(説明変数)とする(図1)
 >>> 全特徴量でCATEを条件づけた場合のパラメタ数の**爆発的増加**を回避
 (特徴量カテゴリ数×CATEのカテゴリ数×特徴量数！)
- モデル構築後に逆方向推論**で特徴量のCATEに与える影響を安定的に評価。
- 特徴量数に対して、CM本数(標本サイズ)が少ないため、BNモデルの**過学習**に
 配慮して特徴量間には**独立性の仮定**を置く
- ノードはすべて離散化**(以下に説明)

図1. 構築するBNの概略図



連続変数	離散変数
CATE	低/中/高

- 収集した特徴量には連続変数が含まれているが、
 かならずしも**正規性の仮定**は満たされず(図2)、
 変数間の**関連性**も線形に限定されない(図3)。
- ➔正規分布を仮定した **Gaussian Bayesian Network** は適用できない
- 結果の解釈可能性の観点からも離散型の確率分布を扱う方が有利^{*2}
- ➔連続変数を全て離散化した上でBNを構築した^{*3}。




図2. 非正規性を示す連続変数




図3. 非線形関係を示す連続変数

*1. 少数派の回答が全体の5%未満となる特徴量は除外した。除外した特徴量は「他社コラボのキャラクターが映っているか、実写か、アニメーションか、電話番号の有無」の4種である。

*2. 離散変数にエビデンスを与えたときの事後確率はカテゴリ別に推定されるため、連続変数で定義するよりも結果の解釈が容易。

*3. 四分位数を用いて段階化した。またCATEについては、低 = CATEが負値、中 = 効果量0~0.2未満、高 = 効果量が0.2以上として離散化した。

4.3 モデルの説明率と分析対象の選定

- 構築したBNモデル16個が妥当かどうかを検証するために、
目的変数(商品カテゴリ・CATE)ごとにモデルの説明率を算出
- 説明率：モデル予測値と実測値の一致率
を示す指標 = **モデルの説明力・予測力**の評価

分析によって**安定した結果を得るために**、今回構築したBNの説明率を**CATE = 50%以上**、**商品カテゴリ = 60%以上**を分析対象とした
表1は各ターゲット層のBNにおけるCATEの説明率

ターゲット層	説明率	ターゲット層	説明率
M20PI	0.438	F20PI	0.367
M20PS	0.357	F20PS	0.367
M30PI	0.418	F30PI	0.428
M30PS	0.530	F30PS	0.408
M40PI	0.479	F40PI	0.428
M40PS	0.448	F40PS	0.530
M50PI	0.602	F50PI	0.367
M50PS	0.561	F50PS	0.510

表1. 各ターゲット層におけるCATEの説明率

表2は**CATEの説明率が50%以上のターゲット層における商品カテゴリごとの説明率**
商品カテゴリ内のCM数が多い**M50PIの生活必需品**を事例研究の分析対象とした

50代男性の購入意向における
生活必需品のCMを対象とした
CATE=**0.602**
商品カテゴリ=**0.810**

	生活必需品	サービス	パーソナル ケア製品	耐久消費財	飲料	携帯 キャリア	食品
M30PS	0.524	0.440	0.273	0.615	0.444	0.500	0.923
M50PI	0.810	0.640	0.273	0.308	0.667	0.833	0.615
M50PS	0.429	0.720	0.455	0.769	0.222	0.833	0.462
F40PS	0.476	0.560	0.818	0.769	0.111	0.167	0.538
F50PS	0.571	0.400	0.545	0.308	0.667	0.500	0.692

表2. 商品カテゴリの説明率



商品名一覧

- AOKI1
- AOKI2
- AOKI3
- Galaxy1
- Galaxy2
- Galaxy3
- アタック
- アリエール1
- アリエール2
- ニトリ
- ユニクロ
- レノア1
- レノア2
- レノア3
- レノア4
- レノア5
- レノア6
- レノア7
- 日立_冷蔵庫1
- 日立_冷蔵庫2
- 無印良品

4.4 CATEに寄与する特徴量の抽出

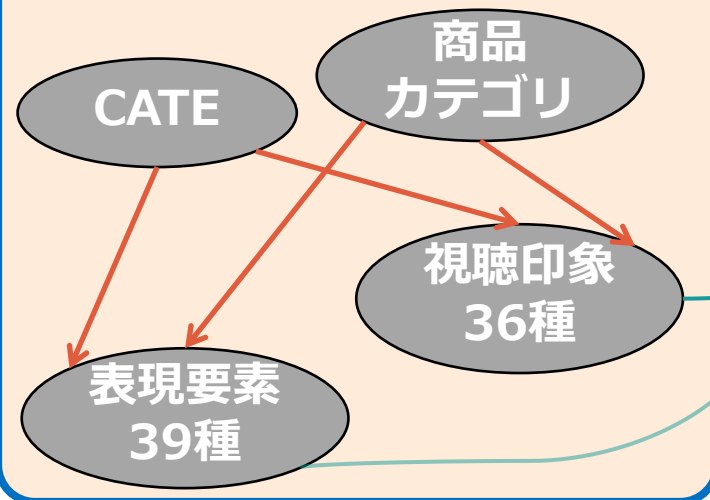
18

BNの順方向推論(P.15)の性質を利用することで**CATEが特徴量に与える影響を推定可能なため**、分析対象とするM50PIの生活必需品のCMにおける**重要な視聴印象・表現要素を抽出できる**

・分析手順

- BNを構築した時点での周辺確率を**事前確率**(図1), 商品カテゴリ:**生活必需品**とCATE:**高(低)**群にエビデンスを与えた場合の周辺確率を**事後確率**(図2)とする
- 視聴印象・表現要素で事後確率と事前確率の差が大きかった上位10個を抽出
➡ 差分が大きい視聴印象・表現要素ほど, **重要(不要)**だということができる

図1. 事前確率のBN



yes	0.72
no	0.28

I

yes	0.81
no	0.19

I

yes	0.34
no	0.66

II

yes	0.46
no	0.54

II



差分による
重要(不要)度の特定

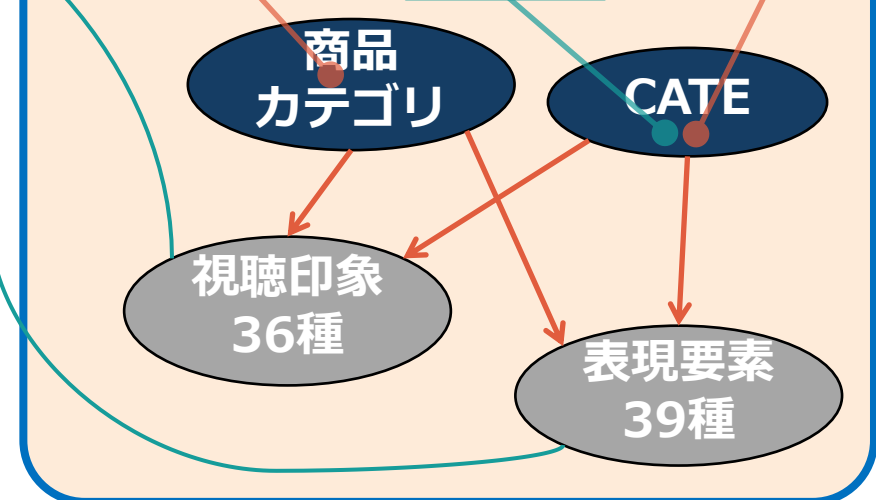
図2. 事後確率のBN

生活必需品	1
他	0

高	1
中	0
低	0

or

高	0
中	0
低	1



問題・目的



データと特徴量



視聴効果の推定



モデル構築




提言

4.4 CATEに寄与する視聴印象の抽出

表1. CATE"高"を説明する視聴印象

さわやかな_あり	0.720
清潔な_あり	0.670
洗練されている_あり	0.670
説明が十分である_あり	0.495
平凡である_あり	0.458
ありふれている_あり	0.436
親しみのある_なし	0.403
日常感のある_なし	0.402
インパクトが強い_なし	0.369
元気な_なし	0.364



50代男性の購入意向向上を図るには(表1)

- ・視聴者に**さわやか**で**清潔**, **洗練された印象**を与え, **商品の説明が十分だ**と感じさせるようなCM構成が有効と示唆
- ・奇抜さを抑えた構成のほうが効果的である可能性

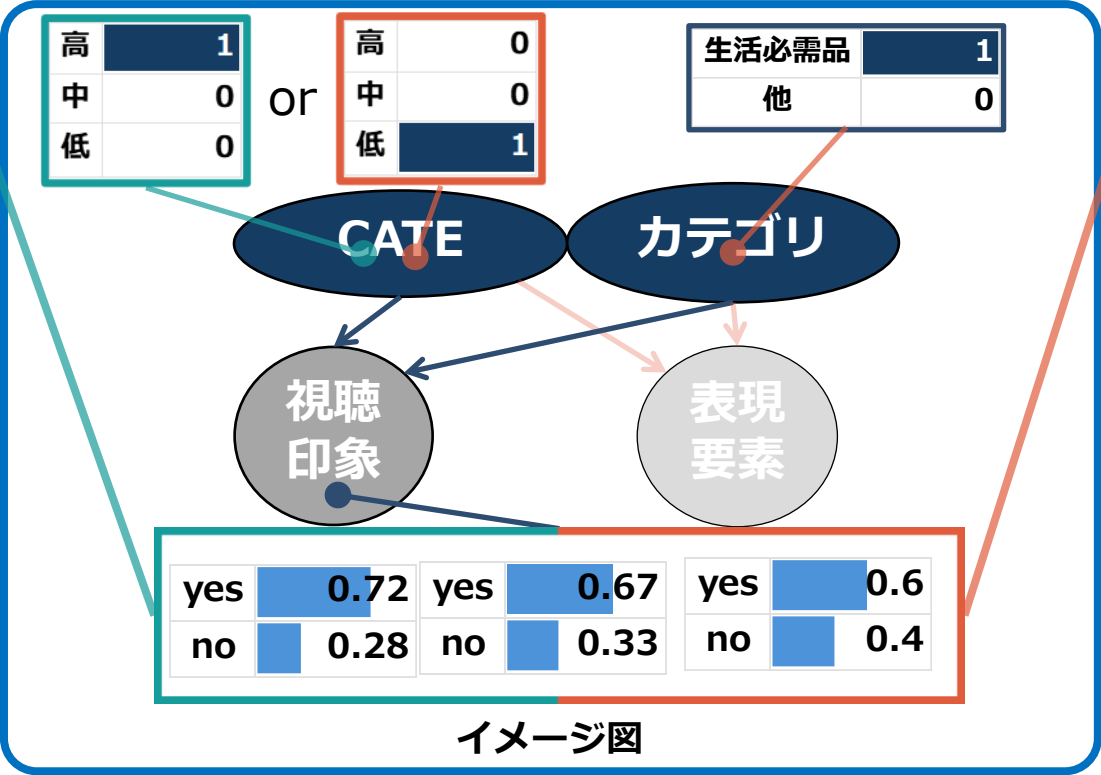



表2. CATE"低"を説明する視聴印象

日常感のある_なし	0.402
意外性がある_あり	0.380
頭に残る_あり	0.333
洗練されている_なし	0.329
穏やかな_なし	0.310
面白い_あり	0.280
さわやかな_なし	0.279
刺激的な_あり	0.278
温かみのある_なし	0.267
美しい_なし	0.267



50代男性の購入意向向上には(表2)

- ・**日常感**, **穏やかさ**, **洗練さ**を感じさせないCM構成は有効ではないと示唆
- ・**頭に残る**ことを意図して**意外性**を狙わなくても良い可能性

4.4 CATEに寄与する表現要素の抽出

表1. CATE"高"を説明する表現要素	
テロップ文字数_70~110文字	0.768
BGM歌唱の有無_なし	0.514
字幕の有無_あり	0.494
男性が映っているか(エキストラを除く)_あり	0.490
男性ナレーション_なし	0.486
商品ロゴが出るまでの秒数_0~4秒	0.483
BGM歌詞の有無_なし	0.441
商品・サービス内容の説明の有無_あり	0.432
放送回数_100回以上200回未満	0.420
メッセージ性の有無_なし	0.393

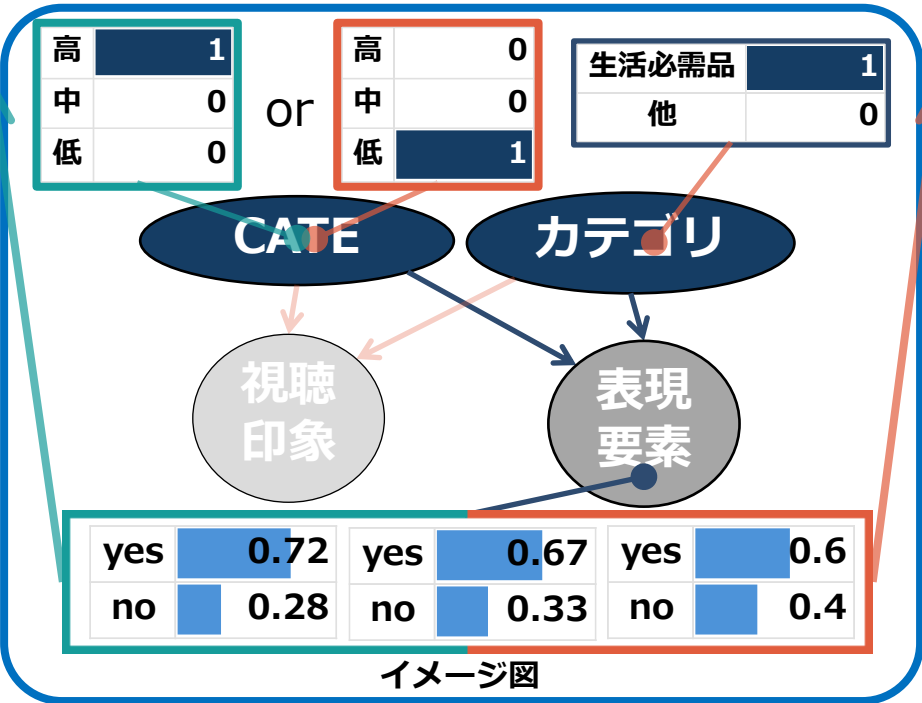


表2. CATE"低"を説明する表現要素	
背景に屋内が映っているか_なし	0.701
キャッチコピーの有無_なし	0.658
企業ロゴが出るまでの秒数_0~4秒	0.529
字幕の有無_なし	0.505
テロップ文字数_0~69文字	0.461
ナレーションがキャッチコピーを言ってるか_なし	0.439
メッセージ性の有無_なし	0.393
商品の使用結果_なし	0.369
女性ナレーション_なし	0.377
動物が映っているか_あり	0.365

50代男性の購入意向向上を図るには(表1)

- ・テロップ文字数は70~110文字の間に収め、字幕を含み、CMの中心人物に男性を起用しているCM構成が有効な可能性
- ・BGM歌唱、男性ナレーションはCM構成に含めないほうが良い可能性を示唆

50代男性の購入意向向上には(表2)

- ・室内での演出、キャッチコピー、字幕がないCM構成は影響を与えない可能性
- ・企業ロゴをCMの前半に出すこと、テロップ文字数が少ないことが広告効果を低くしている可能性

💡 **BN順方向推論の性質により、生活必需品のCMにおける含めるとよい視聴印象・表現要素の特定が可能**
視聴印象・表現要素で重要な特徴を含んでいる実際のCM：**アリエール・ニトリ・無印良品**

4.5 CM改善シミュレーション1(確率推論)

21

抽出した重要特徴量をCMに反映させた場合にどの程度CATEが改善するかをBNモデルで検証する

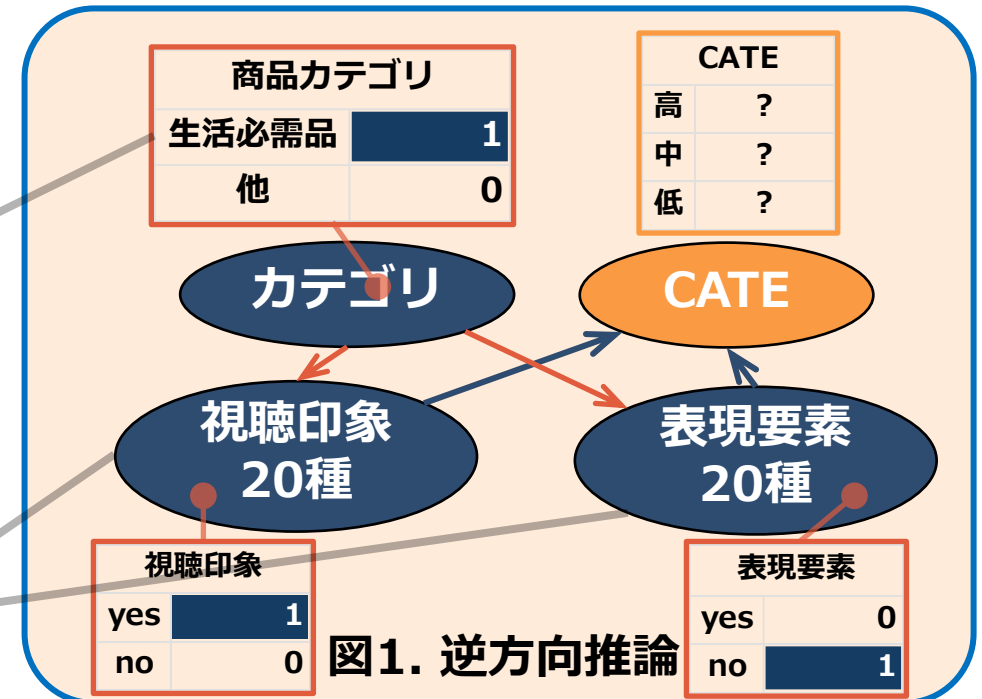
🎯 BNの**逆方向推論**(P.15)の性質により、**視聴印象・表現要素をエビデンスとして与えることで、CATEの確率推定による予測が可能**となる

分析対象：M50PIの生活必需品で**CATEが低い(負の値)商品**=AOKI1・Galaxy2(ソフトバンク)

分析手順：CATEが低かった実際の**CM構成**と、重要な特徴量抽出で得られた特徴量=**最適特徴量**を反映した構成の2パターンにおいて、対象の**特徴量にエビデンス**を与え、CATEの確率推定結果を比較する
これを**CMの改善シミュレーション**とする

モデリングのポイント

- ・特徴量の影響と商品カテゴリーの影響が交絡する可能性
→**生活必需品にエビデンスを与え、商品カテゴリーの影響を統制(図1)**
- ・CATEに強く影響を持つ特徴量に焦点をあて、考察の価値のあるシミュレーション条件を限定。
→**事前の分析(P.19,20)で特定された、20種の視聴印象・表現要素に限定してエビデンス付与(図1)**



4.5 CM改善シミュレーション1(確率推論)

視聴印象	CM構成	最適特徴量に変更後
新鮮である	あり	なし
平凡である	なし	あり
わかりやすい	なし	あり
説得力のある	なし	あり
刺激的な	あり	なし
清潔な	なし	あり
さわやかな	なし	あり
説明が十分である	なし	あり
ありふれている	なし	あり
インパクトが強い	あり	なし
洗練されている	なし	あり

表1. 視聴印象のCM構成と最適特徴量

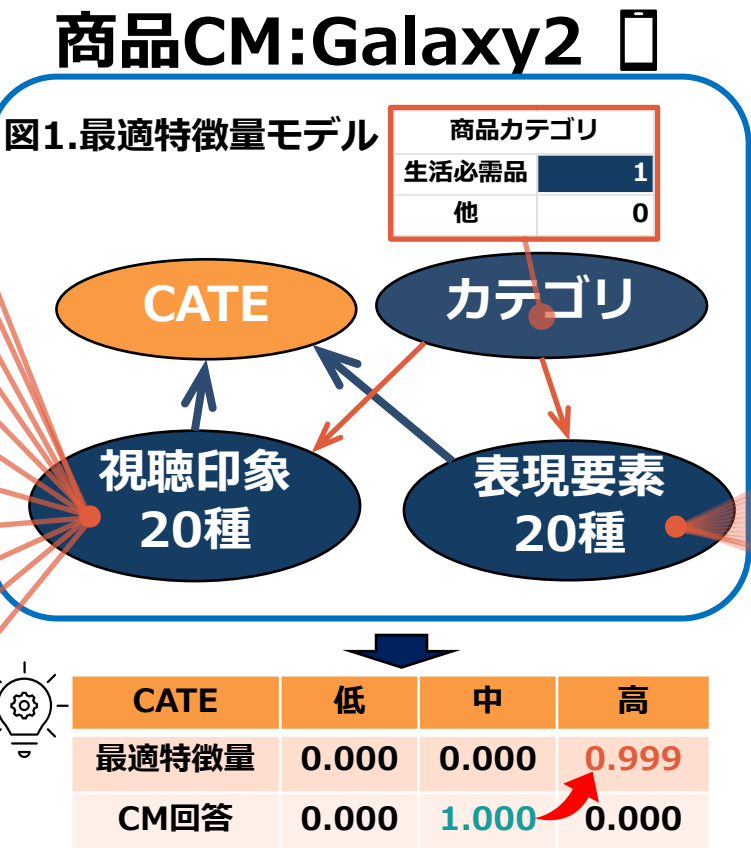


表3. CATEの確率

表現要素	CM構成	最適特徴量に変更後
背景に屋内が映っているか	なし	あり
背景に屋外が映っているか	あり	なし
字幕の有無	なし	あり
キャッチコピーの有無	なし	あり
商品名を言う回数	3回以上	1回
商品・サービス内容の説明の有無	なし	あり
商品が映っている秒数	1~4秒	9秒~
商品ロゴが出るまでの秒数	5~15秒	0~4秒
男性ナレーション	あり	なし
BGM歌詞の有無	あり	なし
BGM歌唱の有無	あり	なし
使用者の意見の有無	なし	あり
テロップ文字数	0~69文字	70~110文字

表2. 表現要素のCM構成と最適特徴量

実際のCMから与えられる視聴印象から、最適な印象を与えるように狙ってCMを制作することで、CM効果を改善できる可能性がある(表1)

実際のCM構成にエビデンスを与えた場合と、最適特徴量にエビデンスを与えた場合(図1)とでは、高効果群に分類される確率に顕著な差が認められた(表3)

実際のCMでは商品の説明から離れたCM構成であった^[19]。商品に焦点を当てたCM構成に表現要素を変更することでCMの効果を上げることができる可能性が結果から示された(表2)



4.5 CM改善シミュレーション1(確率推論)

視聴印象	CM構成	最適特徴量に変更後
親しみのある	あり	なし
さわやかな	なし	あり
洗練されている	なし	あり
元気な	あり	なし

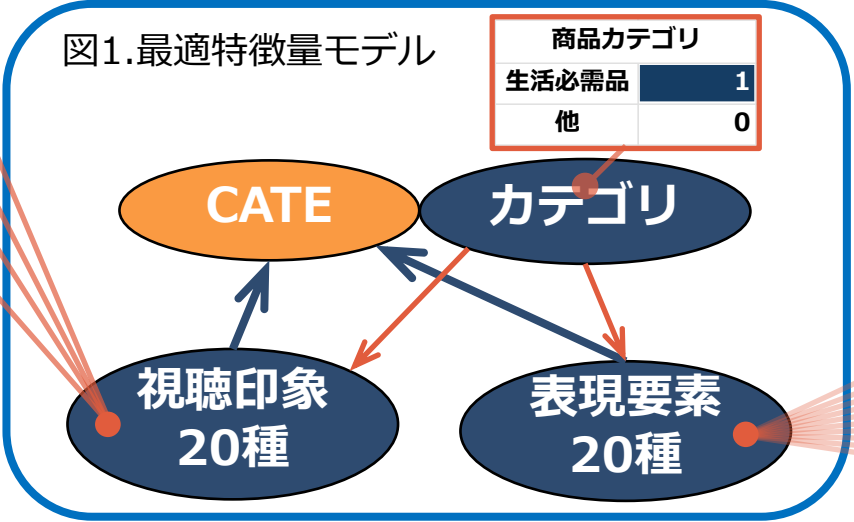
表1. 視聴印象のCM構成と最適特徴量



実際のCMから与えられる視聴印象から、最適な印象を狙ってCMを制作することで、CM効果を改善できる可能性がある(表1)

商品CM:AOKI1

図1.最適特徴量モデル



CATE	低	中	高
最適特徴量	0.000	0.000	0.999
CM構成	0.999	0.000	0.000

表3. 表現要素のCM構成と最適特徴量

表現要素	CM構成	最適特徴量に変更後
男性が映っているか(エキストラを除く)	なし	あり
背景に屋内が映っているか	なし	あり
字幕の有無	なし	あり
キャッチコピーの有無	なし	あり
企業名を言う回数	1回	2回以上
商品名を言う回数	0回	1回
商品ロゴが出るまでの秒数	表示なし	0~4秒
使用者の意見の有無	なし	あり
特定層をターゲットにしているか	あり	なし
テロップ文字数	0~69文字	70~110文字

表2. 表現要素のCM構成と最適特徴量

Galaxy同様、高効果群に分類される確率(図1)に顕著な差が認められた(表3)



BNの逆方向推論により、抽出した重要特徴量をエビデンスとして与えることで、CMに反映させた場合にCATEが高群に改善することをモデルに基づき確認できた

実際のCMは女性タレントが商品を着て商品を紹介していた^[20]。CMの主演に男性を起用して全体的に広告訴求性の高い構成にすることで、効果が向上する傾向が確認された(表2)



4.6 CM改善シミュレーション2(期待値予測)

24

⚠ CATE低群から高群への変化量を評定尺度上(PI, PS)で評価したい

🎯 **推定済み順序プロビット回帰式** (p.12,13参照) を利用して評定尺度の期待値を推定

1. 回帰式を再利用し, 改善シミュレーションに用いたCMの**潜在変数の平均値**を, 対象層($G = g$)について改めて推定
回帰式(p.12の一部改変) : $Z^* = \beta_0 + \beta_1(T = 1) + \beta_2\text{PI}(\text{PS})_1 + \beta_3g + \beta_4(T = 1, g)$

2. CATE推定式から**CATEを推定**した後, その値をCATE"高群"の**最小値/平均値/最大値に置き換える**
CATE推定式(p.13の一部改変) : $\text{CATE}^*(G = g) = \beta_1 + \beta_4g = \text{min/mean/max}$

3. 置き換えたCATEに**合致する新たな係数と回帰式**を導出, 潜在変数の平均値を再推定し評定尺度における期待値を算出

新係数 : $\beta_4^*g = \text{CATE}^*(G = g) - \beta_1$ **新回帰式** : $Z^* = \beta_0 + \beta_1(T = 1) + \beta_2\text{PI}(\text{PS})_1 + \beta_3g + \beta_4^*g$

期待値算出式 : $E[K | T = 1] = \sum_{k=1}^K k \{ \Phi(\tau_k - \bar{Z}^*) - \Phi(\tau_{k-1} - \bar{Z}^*) \}$

💡 **CATEの改善の効果をより解釈しやすく表現し, 費用対効果をより鮮明に検討可能**



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

4.6 CM改善シミュレーション2(期待値予測)

実践例^{*1} : AOKI1, Galaxy2のM50PI評価

表1. AOKI1におけるPI評価値の期待値

期待値 (1~4)	非視聴群	視聴群	差分
無補正	1.021	1.016	-0.005
補正(小) 0.2	1.021	1.033	0.012
補正(中) 0.29	1.021	1.041	0.02
補正(大) 0.4	1.021	1.051	0.03

表2. Galaxy2におけるM50PI評価の期待値

期待値 (1~4)	非視聴群	視聴群	差分
無補正	3.599	3.594	-0.005
補正(小) 0.2	3.599	3.687	0.088
補正(中) 0.29	3.599	3.723	0.124
補正(大) 0.4	3.599	3.763	0.144

表3. 評価値と回答内容との対応

評価値 (1~4)	AOKI1	Galaxy2
4	ぜひ行きたい	ぜひ買いたい
3	行きたい	買いたい
2	どちらともいえない	わからない
1	行きたいとは思わない	買いたくない

AOKI1

元CMは元来高くない期待値をさらに下げていたが、構成要素改善によって「1.行きたいとは思わない」から「2.どちらともいえない」へ近づいた。

Galaxy2

元CMは元来高い期待値を後押しできなかったが、構成要素改善によって「3.買いたい」から「4.ぜひ買いたい」へさらに近づいた。

^{*1}.今回は「生活必需品」高CATE条件で観測された最小値0.2を補正(小), 平均値0.29を補正(中), 最大値0.4を補正(大)と定義した。



5.1 提言 -分析結果の確認-

26

以上の分析の結果を総括し、分析対象への示唆を提供する

CATEに寄与する特徴量の抽出

視聴印象(P.19)

- ・視聴者にさわやかで清潔, 洗練された印象を与え, 商品の説明が十分だと感じさせるようなCM構成が有効と示唆
- ・奇抜さを抑えた構成のほうが効果的である可能性

表現要素(P.20)

- ・テロップ文字数は70~110文字の間に収め, 字幕を含み, CMの中心人物に男性を起用しているCM構成が有効な可能性。
- ・BGM歌唱, 男性ナレーションはCM構成に含めないほうがよい可能性を示唆。

BNの順方向推論により、今回分析対象とした
M50PIの生活必需品において重要なCMの
視聴印象・表現要素の抽出ができた。



CM改善シミュレーション

AOKI1, Galaxy2のCMともに特定した視聴印象・表現要素に
変更することで、広告効果の改善が見込まれた(P.22,23)

AOKI1(P.25)

構成改善によって購入意向が中立的評価へと回復し、マイナス効果を抑制する
傾向が示された

Galaxy2(P.25)

改善後に購入意向の期待値が上昇し、より積極的な購買態度への変化が見られた

BNの逆方向推論による重要特徴量への構成変更で、生活必需品
の低効果CMが高効果群に近づく傾向が確認された。



そして、広告効果の改善を視聴者評定の期待値を算出
することによって数値的に把握した。



M50PI(50代男性の購入意向)の生活必需品の商品AOKI1, Galaxy2(ソフトバンク)において
広告効果の改善が可能となり、そのまま広告制作に反映できる、再現性と実務適合性を示した



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

5.2 提言 -分析手法の提言-


27



本研究の目的は、ターゲット層と商品カテゴリに応じてCMの視聴印象と表現要素を最適化し、広告効果を高めるための予測システムを提案することであった。
まず、分析結果から読み取れる分析手法の妥当性を示す。

1

広告効果推定 P.10~14




ターゲット層別にCATEを算出し、広告効果の差異を精緻に把握した。両者に共通する傾向が確認され、推定結果の妥当性も確認できた

➡**広告効果分析手法として有用**

3

CM改善シミュレーション1(確率推論) P.21~23



CATEの低いCMを重要な視聴印象・表現要素へ置換し、改善シミュレーションを実施したところ、CATEが高群に遷移する確率が上昇

➡**構成改善による広告効果向上を確認**

2

CATEに寄与する視聴印象・表現要素の抽出 P.15~20



ターゲット層×商品カテゴリ別に広告効果のある特徴量を特定。表現要素だけでなく、視聴者の印象・感情を喚起する要因まで把握可能

➡**狙う印象を起点に表現要素を設計**

4

CM改善シミュレーション2(期待値予測) P.24,25



CATEの低いCMが構成改善により高効果群へ遷移した際の影響を、実際の評定期待値の上昇という形で確認

➡**広告効果向上の明確化に成功**



分析手法が**広告効果とTVCMの視聴印象・表現要素との関係**を妥当に捉え、**ターゲット層・商品カテゴリ別の効果を予測**できることを確認した。また、視聴印象・表現要素変更時の広告効果を直感的に示すシミュレーションが可能かつ、**新CM制作の参考**にもなるため、**提案手法はCM制作方針を実証的に検証できる応用的枠組みとしても有効である。**



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

5.3 提言 -利点と活用方法-



TVCMの広告効果を捉え、視聴印象・表現要素の改善による
広告効果向上を妥当に予測・検証できる実務的アプローチを示した。



本手法を用いることによる利点

- 1 ターゲット層/商品カテゴリ別に有効な視聴印象・表現要素を特定でき、最適な**CM設計を提案可能**。視聴者の印象・感情を反映した**心理的效果に基づく戦略立案に有用**。また、得られた示唆は**CMを新規制作する際の参考情報**としても利用可能。
- 2 CATEを目的変数とする**ナীবベイズ型BN**は、離散中心の高次元データでも次元の呪い^[21]を回避して予測可能。
- 3 特徴量ごとの寄与を数値化して提示可能で、**分析結果を予算配分や制作判断に直結させやすい**。
- 4 ベイジアンネットワークは**再学習が可能**なため、新規CM・調査データを追加して**モデルを継続的に精緻化**できる。
- 5 データ蓄積時には、ノード間依存を導入する**TAN(Tree Augmented Naive Bayes)**へ拡張し、**安定性と解釈可能性を両立**できる。また、**視聴印象・表現要素間の相互作用を含む解析**とクロスバリデーション等による汎化性能評価が可能となる。



本手法を用いた分析サイクルの提案

- 1 **問題発見**
ターゲット層/商品カテゴリ別に広告効果の低い商品进行特定
- 2 **改善案提示**
本手法より重要視聴印象・表現要素を特定→CM再構成案の獲得
- 3 **シミュレーション**
BN逆方向推論で高効果群への遷移確率と評定期待値を試算
- 4 **実地検証**
改善版を出稿し、実測データで効果を確認
→効果あり：CM構成を継続的に出稿
効果なし：不要な特徴量の特定・再度データ収集しモデルを再学習(再設計)する
- 5 **学習ループ**
実測結果をモデルに追加
再学習：データ蓄積でTANモデルに変更可能
→視聴印象・表現要素間の関係が可視化される → ①へ

このサイクルにより「分析→改善→実証→モデル改良」を繰り返し、費用対効果の高い運用体制を構築可能。



問題・目的



データと特徴量



視聴効果の推定



モデル構築



提言

6. 課題

29

1. データ量の制約によるモデルの説明力の限界

・CM数に対して特徴量が多く過学習の懸念があった。そのため、特徴量間の独立性を仮定するナイーブベイズモデルを採用し、安定性/解釈可能性/汎化可能性を優先したモデル構築を行った。

一定の解釈可能性を確保できたが、視聴印象と表現要素の直接的な相互関係を捉えるまでには至らなかった。
理想的にはTANを使用すべきである。

2. BNモデルの説明率

・本研究では提供データや**エンリッチメントした特徴量行列**に基づいてCATEと特徴量についてBNモデルを構築し、それぞれのデータへの適合について検証している(P.17)。モデルの妥当性を明示しながら分析したことには一定の価値があるが、**適合が悪いモデルも存在**している。

・より大規模なデータを前提とし、クロスバリデーションを実行することで、妥当性(そして信頼性)の高い予測モデルを構築する必要がある。

3. CM視聴に関する不確実性

・データ内容の都合上、CMの視聴有無については「該当CMが出稿された番組を視聴しているか」を判断基準とした(P.10)。

これは「番組の視聴者は必ずその番組に出稿されたCMも視聴している」という仮定を前提とし、**確実性を欠いたもの**である。より正確な広告効果推定のためには、**CM単位で視聴有無を把握する仕組みが必要である。**

4. 特徴量抽出における人的要因の関与

・CM表現要素は、人による評価で測定したが、再現性/客観性の点で限界がある。また全CM動画の著作権者から利用許諾をとることも難しかった。実務では、さらに大量のCM動画を扱う必要があると予想されるので、**映像解析技術や自然言語処理を用いた自動抽出を併用することが望ましい**(P.8)。

・視聴印象は現時点では**人による評価が現実的**。
・人的評価はコストを要するが、**機械学習では捉えにくい感情的・心理的側面を反映できる点で有用である。**

7. 文献

30

- [1]電通. 「日本の広告費」 https://www.dentsu.co.jp/knowledge/ad_cost/ (最終閲覧日:11月6日)
- [2]総務省. 「令和6年版 情報通信白書の概要 本編 第Ⅱ部 情報通信分野の現状と課題 第1章 ICT市場の動向 第3節 放送・コンテンツ分野の動向 2 コンテンツ市場 (2) 広告」 <https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/r06/html/nd213220.html>(最終閲覧日:11月6日)
- [3]三好哲也・藤本義治(2015). TV広告の効果とデジタルユーザーのタイプからみた商品認知. 大阪経大論集, 66巻, 1号, p. 343-357.
- [4]株式会社ビデオリサーチ. 「バックナンバー|週間リアルタイム視聴率ランキング」 https://www.videor.co.jp/tvrating/past_tvrating/backnumber/2025/(最終閲覧日:11月6日)
- [5] Crevo株式会社. 「テレビCMの制作費用はいくら？制作費・放映料の料金相場や費用を抑える方法まで解説」. <https://crevo.jp/video-square/product/commercial-price/>(最終閲覧日:11月6日)
- [6]澤田慶. 「広告効果と構成要素のネットワークグラフからみるテレビ広告制作の提案」 <https://www.is.nri.co.jp/contest/2021/download/mac2021grand.pdf>(最終閲覧日:11月6日)
- [7]上村春佳. 「視聴覚的なテンポを考慮したテレビCMの広告効果分析」 <https://www.is.nri.co.jp/contest/2022/download/mac2022grand.pdf>(最終閲覧日:11月6日)
- [8]内藤宏明. 「CMの広告効果に関する要因の探求と予測モデルの考案」 <https://www.is.nri.co.jp/contest/2018/download/mac2018yushu.pdf>(最終閲覧日:11月6日)
- [9]河原達也(2016). TVCM表現要素の消費者反応に対する効果, 行動計量学, 43巻, 1号, p.85-105.
- [10]鈴木, 元也, 生田目, 崇, 2013, 消費者の異質性を考慮したテレビCM効果の分析: 専修大学情報科学研究所, 1-19 p.
- [11]本村 陽一・佐藤 泰介 (2000) . ペイジアンネットワーク：不確定性のモデリング技術, 人工知能, 15 巻, 4 号, p. 575-582.
- [12]浅川 雅美 (2009). テレビCMの「視聴印象」の多次元的特性の分析, 行動計量学, 36巻, 1号, p.47-61
- [13]faxdm屋ドットコム. 「3ヒット理論を徹底解説！営業・広告で信頼を築く接触回数の活用法」 <https://www.faxdmya.com/adwords/threehitstheory>(最終閲覧日:11月6日)
- [14]加藤健太郎・山田剛史・川端一光 (2014). Rによる項目反応理論, オーム社
- [15]漆畑充・五百井亮 (2025). マーケティングのための因果推論, ソシム.
- [16]Lumley, T. (2004). Analysis of Complex Survey Samples. Journal of Statistical Software, 9(8), 1-19. <https://doi.org/10.18637/jss.v009.i08>(最終閲覧日:11月6日)
- [17]Scutari, M. (2010). Learning Bayesian Networks with the bnlearn R Package. Journal of Statistical Software, 35(3), 1-22. <https://doi.org/10.18637/jss.v035.i03>(最終閲覧日:11月6日)
- [18]Højsgaard, S. . (2012). Graphical Independence Networks with the gRain Package for R. Journal of Statistical Software, 46(10), 1-26. <https://doi.org/10.18637/jss.v046.i10>(最終閲覧日:11月6日)
- [19]【HD】乃木坂46 五百城茉央 CM「りんごとトラック」「おおきなかぶ」ソフトバンク <https://www.youtube.com/watch?v=lfbhur2Do4k>(最終閲覧日:11月6日)
- [20]【AOKI】1着で選べるスタイル | 3Wayコート <https://www.youtube.com/watch?v=pbF506tNNp4>(最終閲覧日:11月6日)
- [21]生成AI活用普及協会(GUGA). 「機械学習における次元の呪い(Curse of dimensionality)とは何？対策方法まで徹底解説」 <https://gen-ai-media.guga.or.jp/glossary/curse-of-dimensionality/>(最終閲覧日:11月6日)

謝辞：本研究において参照した浅川(2009)および河原(2016)の表中の文言について, 原著者から引用および原文を踏まえた改変のご許可を頂きました。ご多忙の中, ご丁寧にご対応いただいた浅川先生, 河原先生に深く感謝申し上げます。また貴重な分析の機会を下さった野村総合研究所様にも深く感謝申し上げます。