



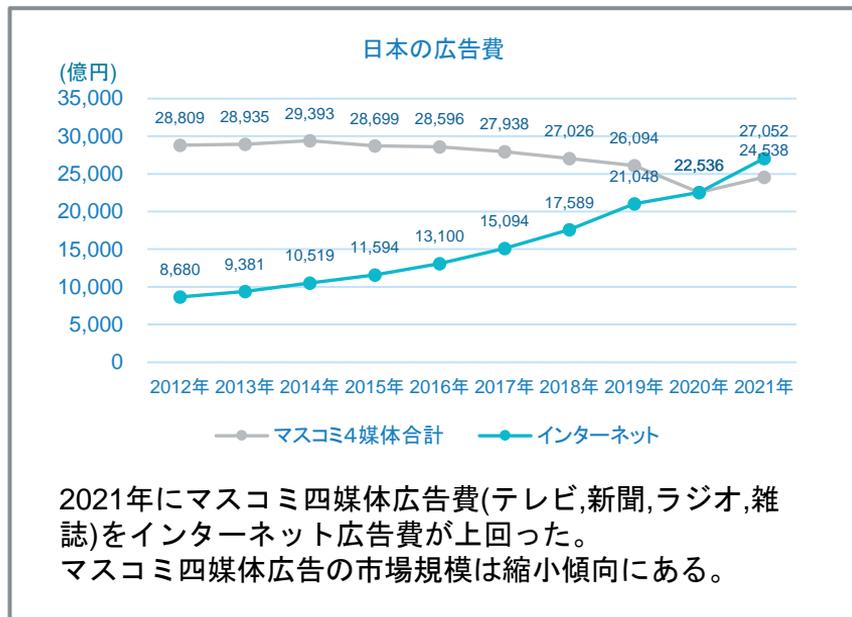
消費者属性を考慮した インターネット広告配信媒体の最適化 ～Netflixを事例として～

上智大学 理工学部情報理工学科
薦田怜奈

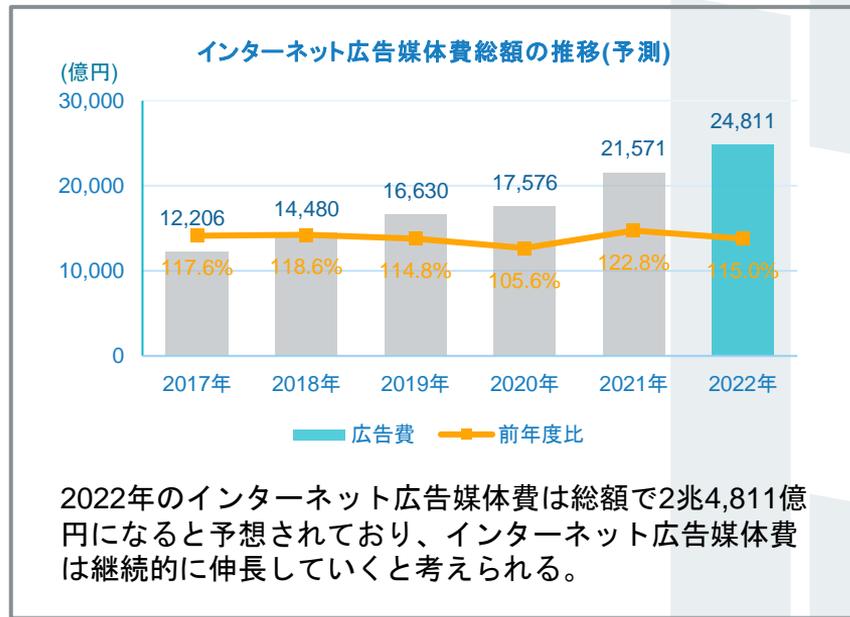
目次

- ▶ 概要
 - ▶ 研究背景
 - ▶ 研究目的
 - ▶ 先行研究
 - ▶ 研究フロー
 - ▶ 提案モデル
- ▶ データ
 - ▶ データ概要
 - ▶ データ加工
- ▶ 分析
 - ▶ 変数の定義
 - ▶ パラメータ推定
 - ▶ 評価
- ▶ 結果
 - ▶ 分析1の結果
 - ▶ 分析2の結果
- ▶ 考察・まとめ

✓ 広告業界の現状

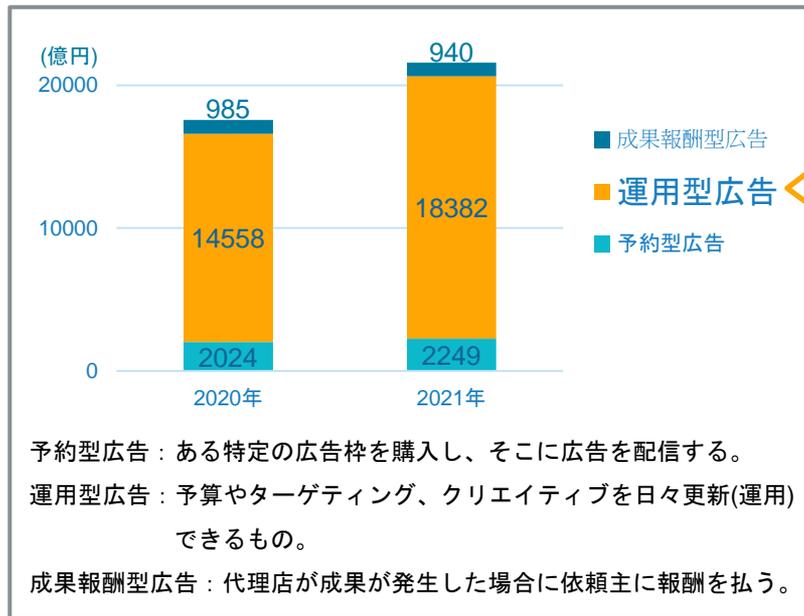


✓ インターネット広告の現状



インターネット広告は今後も伸び続けることが予想される。
効果的なインターネット広告を配信することで、利益の拡大を見込めるのでは！？

✓ インターネット広告媒体費の取引手法別構成比

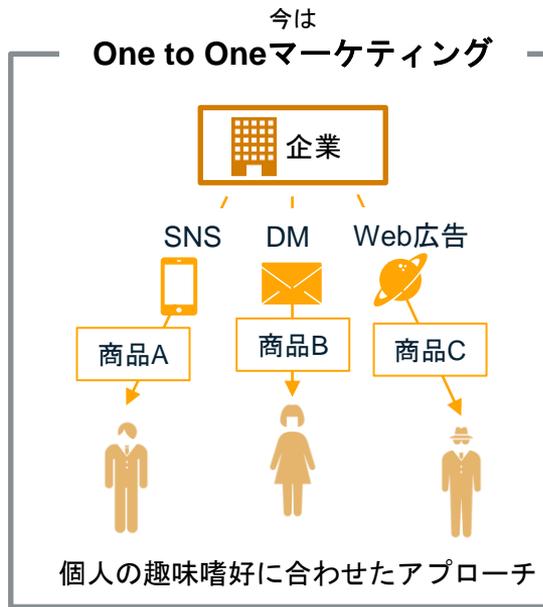


インターネット広告費で最も多いのは運用型広告で1兆8382億円、広告費全体の85.2%を占めている。運用型広告の比率は年々増加しており、2021年も前年比126.3%と大きく伸びた。

種類		配信媒体
運用型広告	検索連動型広告	Google検索ネットワーク
		Yahoo!検索広告
	ディスプレイ広告	Googleディスプレイネットワーク
		Yahoo!ディスプレイ広告
ソーシャル広告	Facebook	
	Instagram	
	Twitter	
		LINE

インターネット広告の中でもターゲティングができる運用型広告が成長を続けている。
ターゲット属性ごとに効果のある配信面を分析することで利益を上げられるのでは！？

✓ 企業のマーケティング方法



Netflixでは...



‘嵐’の広告

‘アニメ’の広告

同一企業でもターゲット属性を変えながら、消費者の好みに合わせた宣伝をしている。

同一企業であっても、その時に売り出したい商品などによってターゲット属性が変わる。属性ごとにどの配信面が最適か分析することでよりマーケティングに活用できるのでは？



商品ごとの消費者属性の違いにおける
インターネット広告の最適な配信媒体を明らかにする

分析1

商品ごとの
各媒体(SNSや検索エンジン)
と消費者属性における
インターネット広告効果を明らかにする。

分析2

消費者属性を考慮した
商品の最適な広告出稿先
を明らかにする。

これからも成長していくインターネット広告市場で
適切な広告配信をすることで利益の増加が見込める

✓ 消費者異質性を考慮した効果分析

消費者異質性を考慮した分析を行うために階層ベイズモデルを導入した分析がされている。

研究者名	論文名	年度	研究目的	手法
日高徹司 佐藤忠彦	消費者ブランドとの関係を考慮した 階層ベイズモデルによる クロスメディア効果推定	2016	消費者異質性を考慮した 複数広告素材の相乗効果を 測定・推定する	階層ベイズ順序ロジットモデル
山田浩喜 佐藤忠彦	同一商業累積地に隣接する 店舗間のストア・イメージに 基づく店舗評価	2019	ストア・イメージ評価が スーパーマーケットの最重要店舗とし ての 評価にどのように影響してるか分析	階層ベイズ二項ロジットモデル

✓ インターネット広告に関する研究

研究者名	論文名	年度	最適化指標
Jian X., et al.	Smart Pacing for Effective Online Ad Campaign Optimization	2015	広告出稿予算に合わせた最適化
Georgios T., et al.	Personalized Ad Recommendation Systems for Life-Time Value Optimization with Guarantees	2015	LTVによる最適化 広告そのものが良いものか 悪いものか判断する
石川ら	Web リスティング広告における基本広告データを用いたコンバージョン分析と予測	2017	基本広告データ (インプレッション数など)のうち、 CV予測に大きく関与する指標の 分析
Alessandro .et al.	A Combinatorial-Bandit Algorithm for the Online Joint Bid / Budget Optimization of Pay-per-Click Advertising Campaigns	2018	入札額の最適化

研究考察

- 出稿予算に合わせた広告最適化
- クリック数による最適化
- 入札額による最適化



課題

- 消費者一人ひとりの属性を考慮した分析
- 入札額による最適化は行われているが、広告配信面に関する最適化が行われていない。

階層ベイズモデルを用いて消費者異質性を考慮した分析を行う。
異質性を考慮したパラメータを用いて最適化を行う。

データ加工

データを以下の3つに分類する。

1. アンケートデータ
2. 消費者属性データ
3. SNS利用量データ

分析 1

配信媒体ごとの属性別
広告効果分析

インターネット使用量と
広告効果の関係性の分析

手法

階層ベイズモデル

目的変数

消費者の購入意向変化量

説明変数

1. SNS使用量
2. 消費者属性

分析 2

属性別の広告配信媒体
最適化シミュレーション

広告配信媒体の最適化

分析 1 の階層ベイズモデル
で求めたパラメータ値を
足し合わせることで、
最適な広告配信媒体を
推測する。

分析1 提案モデル

概要

データ

分析

結果

考察
まとめ

階層
ベイズ
モデル

一般化線形モデル(GLMM)をベイズモデル化したものであり、事前分布となる確率分布のパラメータに事前分布を指定する。GLMMはパラメータ推定を最尤法に基づき行うがモデルが複雑になった時に計算が非常に困難になる。そこでパラメータに縛りを導入する階層ベイズモデルが適用される。今回は各媒体で2500人分のパラメータがあるため階層ベイズモデルを用いる。

提案モデル

観測
モデル

購入意向の変化量を目的変数
消費者ごとのSNS利用量を説明変数

$$y \sim \text{Normal}(\beta X, \sigma)$$

h : 消費者数 ($h = 1, 2, \dots, H$)
 j : 媒体数 ($j = 1, 2, \dots, J$)
 q : 消費者の属性変数の個数
($q = 1, 2, \dots, Q$)

$H (= 2500 \text{人})$ $J (= 7)$ $Q (= 22)$

階層
モデル

消費者ごとのパラメータベクトル β $\beta = \theta Z + \eta; \eta \sim N(\mathbf{0}, V)$

共通性パラメータ θ

$$\text{vec}(\theta|V) \sim N(\text{vec}(\bar{\theta}), V \otimes A^{-1})$$

分散 V

$$V \sim IW(v, V)$$

事前
分布の
設定

$A = 0.01$
 $v = 7 + 3 = 10$
 I : 単位行列

10

分析2 提案モデル

概要

データ

分析

結果

考察
まとめ

配信媒体
の推測

分析1の階層ベイズモデルで求めたパラメータ θ の値を利用して、ターゲット商品、ターゲット属性における最適な広告配信媒体を推測する。

▼ 提案モデル ▼

ターゲット
設定

ターゲット商品の設定 | P7に示した商品の中からターゲット商品を決める

ターゲット属性の設定 | P12に示した消費者属性の中から適当に属性を選ぶ

推測

分析1で求めたパラメータ値をターゲット設定に基づいて抜粋し、各配信媒体のパラメータ値の合計を計算する。
合計値が高いものが効果的であり、低いものは効果が薄くなる。

	配信媒体			
属性				
合計				

データ概要

概要

データ

分析

結果

考察
まとめ



アンケートデータ

特定商品の購入意向アンケートデータ2回分(1ヶ月の期間)



消費者属性データ

性別,年齢,未既婚,子供有無,家族構成,居住地,職業



Web利用データ

Twitter,Facebook,Instagram,LINE,YouTube,Yahoo!JAPAN,Google

対象商品
Netflix

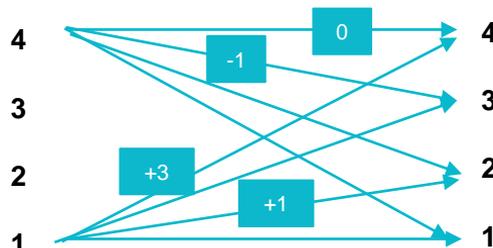


NETFLIX

✓ 購入意向の変化量の設定

アンケート1回目

ぜひ~したい	4
~したい	3
わからない	2
~したくない	1



アンケート2回目

ぜひ~したい	4
~したい	3
わからない	2
~したくない	1

ポイントの変化量を
データの平均0、分散1となるよう標準化

計算方法：
$$x_{new} = \frac{x - \bar{x}}{s}$$

\bar{x} : データの平均
 s : 標準偏差

- ぜひ~したい
4ポイント
 - ~したい
3ポイント
 - わからない
2ポイント
 - ~したくない
1ポイント
- それぞれのアンケート実施時点での結果を数値に置き換え、1回目と2回目のポイント差をもとに消費者の購入意向の変化量を定義した。

✓ Web利用量の設定

利用頻度だけでなく、1日あたりの利用時間も考慮することでより一人当たりに変化のある値の設定ができるのではないかな？

web利用頻度

利用頻度	ポイント
ほぼ毎日	7
週4,5回	6
週2,3回	5
週1回	4
月1回	3
月1回未満	2
利用なし	1



1日あたりの利用時間

利用時間/日	ポイント
4時間以上	8
3~4時間	7
2~3時間	6
1~2時間	5
30分~1時間	4
15分~30分未満	3
15分未満	2
利用なし	1

ポイントの変化量を
データの平均0
分散1となるよう標準化

計算方法：

$$x_{new} = \frac{x - \bar{x}}{s}$$

\bar{x} : データの平均

s : 標準偏差

変数の定義

概要

データ

分析

結果

考察
まとめ

📌 SNS利用量

x_h は消費者それぞれのSNS利用量を標準化した値である。また定数項 $x_{h,0}$ は全て1。

説明変数 $x_h = (x_{h,0}, x_{h,1}, \dots, x_{h,j})$	
定数項	$x_{h,0}$
Twitter	$x_{h,2}$
Facebook	$x_{h,3}$
Instagram	$x_{h,4}$
LINE	$x_{h,5}$
YouTube	$x_{h,6}$
Yahoo!JAPAN	$x_{h,7}$
Google	$x_{h,8}$

📌 消費者属性（ダミー変数）

z_h は消費者それぞれの属性をダミー変数化した値である。定数項 $z_{h,0}$ は全て1。省略されているダミー変数は、「性別:女性」「年齢:50代」「未既婚:離婚・死別」「子供有無:いない」「家族構成:その他」「居住地:茨城」「職業:その他」である。

説明変数 $z_h = (x_{h,0}, x_{h,1}, \dots, x_{h,j})$					
定数項	$z_{h,0}$	家族構成:单身	$z_{h,8}$	居住地:東京	$z_{h,16}$
性別:男性	$z_{h,1}$	家族構成:1世帯	$z_{h,9}$	居住地:神奈川	$z_{h,17}$
年齢:20代	$z_{h,2}$	家族構成:2世帯	$z_{h,10}$	職業:主婦	$z_{h,18}$
年齢:30代	$z_{h,3}$	家族構成:3世帯以上	$z_{h,11}$	職業:自営業	$z_{h,19}$
年齢:40代	$z_{h,4}$	居住地:栃木	$z_{h,12}$	職業:会社員	$z_{h,20}$
未既婚:未婚	$z_{h,5}$	居住地:群馬	$z_{h,13}$	職業:アルバイト	$z_{h,21}$
未既婚:既婚	$z_{h,6}$	居住地:埼玉	$z_{h,14}$	職業:学生	$z_{h,22}$
子供有無:いる	$z_{h,7}$	居住地:千葉	$z_{h,15}$		

パラメータの推定

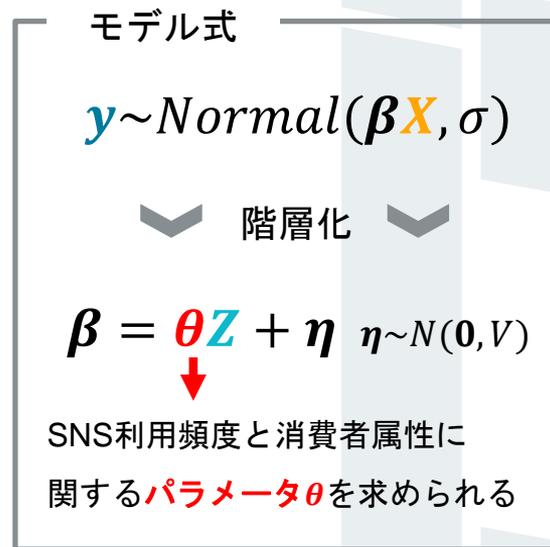
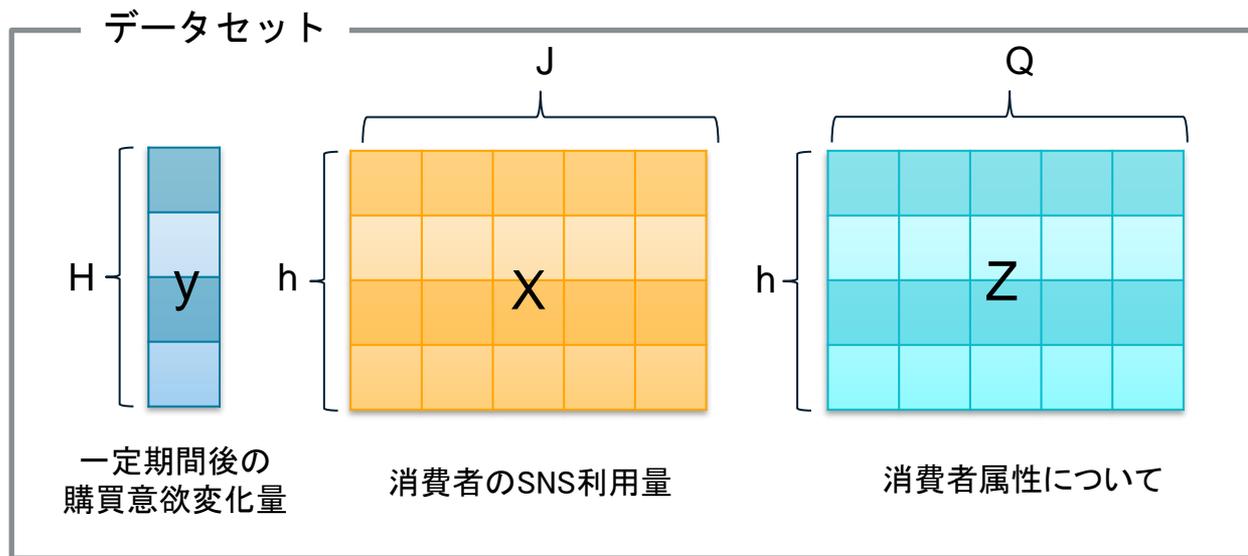
概要

データ

分析

結果

考察
まとめ



提案モデルの推定はマルコフ連鎖モンテカルロ法(MCMC法)を採用する。

MCMCの繰り返し回数は1000回を1セットとし、4セット行った。

最初の200回をバーンイン期間として設定し、初期値の影響を受けたサンプルとして捨てた。

MCMCのアルゴリズムは、ハミルトニアンモンテカルロ法(HMC法)の1つであるNUTSを使用した。

✓ 収束判定 < \hat{R} 指数による判定 >

\hat{R} 指数

サンプル列間の乖離の大きさを調べるために \hat{R} 指数による判定を行った。

$$\hat{R} = \sqrt{\widehat{var}^+ / W}$$

\widehat{var}^+ : 周辺事後分布の分散 W : サンプル列ごとの分散の平均

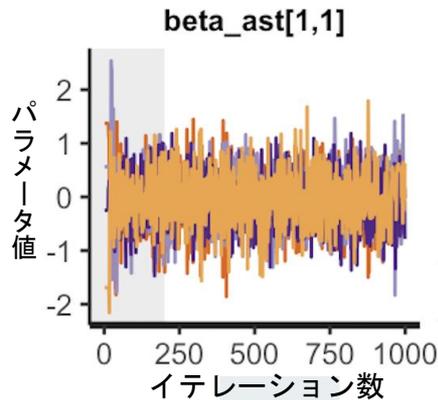
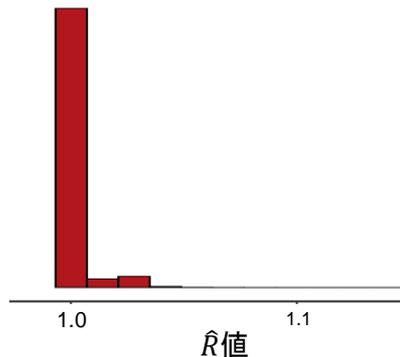
$$\widehat{var}^+ = \frac{n-1}{1} W + \frac{1}{n} B$$

B : サンプル列間の分散

\hat{R} が 1 に近ければ良い。

$\hat{R} < 1.1$ であれば収束しているとみなす。

パラメータの
個数



- 全てのパラメータにおいて \hat{R} が 1.1 未満である
- Traceplot より実行した 4 回のサンプルがほぼ同一線上



MCMC 計算は収束している！！

✓ モデルの比較 <WAICによる判定>

WAIC

ベイズ推論のための情報量基準である。
MCMCで生成されたサンプルから直接平均対数尤度を
計算して、AICに相当する情報量基準を算定する。

$$\text{WAIC} := - \sum_i^n \log \int p(y_i | \theta) \prod (\theta | y_i) d\theta$$

$$+ 2 \sum_i^n \text{Var}_{\Pi(\theta | y_i)} [\log p(y_i | \theta)]$$

WAICの値が小さいモデルが良いモデルとなる。

正規分布のモデル式

$$y \sim \text{Normal}(\mu, \sigma)$$

一般化線形モデルのモデル式

$$y \sim \text{Normal}(\beta X, \sigma)$$

	WAICの値
正規分布	1.42
一般化線形モデル	2.85
階層ベイズモデル	0.62



階層化することで、WAICの値を小さくすることができた。
消費者属性を考慮した**階層ベイズモデルの方が精度が示された。**

結果1

概要

データ

分析

結果

考察
まとめ



マーケティング手法によって、用いる項目を変える

マスマーケティング

定数項

One to One マーケティング

性別,年齢,未婚既婚,子供有無,家族構成,居住地,職業

定数項

変数	定数項	Twitter	Facebook	Instagram	LINE	YouTube	Yahoo!JAPAN	Google
定数項	-0.328	-0.271	0.054	0.661	0.091	-0.210	-0.456	-0.251

- Instagramでの広告効果は高い
- Yahoo!JAPANでの広告効果は低い

Netflixの広告はInstagram利用者に積極的に広告をうつことで、利益の増加を見込める。

性別

変数	定数項	Twitter	Facebook	Instagram	LINE	YouTube	Yahoo!JAPAN	Google
男性	0.064	-0.065	0.115	-0.026	-0.056	0.034	0.021	-0.005

- 定数項より、性別で配信先を分けた方が良い
- 男性はFacebookのパラメータ値が大きい
- 女性はLINEのパラメータ値が大きい



男性はFacebookへ配信
女性はLINEへ配信すべき！ 19

結果1

概要

データ

分析

結果

考察
まとめ

年代

変数	定数項	Twitter	Facebook	Instagram	LINE	YouTube	Yahoo!JAPAN	Google
20代	-0.078	-0.177	-0.003	0.005	0.008	0.088	0.057	-0.118
30代	0.023	-0.119	0.096	-0.238	-0.009	0.068	-0.032	0.015
40代	-0.082	-0.205	0.141	-0.006	-0.075	0.095	0.078	-0.077

- 定数項より、30代への配信が効果的
- 20代はYouTubeのパラメータが高い
- 30代、40代はFacebookのパラメータが高い



20代にはYouTubeへの配信
30代,40代にはFacebookへの
配信が効果的！

未既婚

変数	定数項	Twitter	Facebook	Instagram	LINE	YouTube	Yahoo!JAPAN	Google
未婚	-0.153	0.087	0.081	-0.067	-0.162	0.074	-0.009	0.098
既婚	-0.107	0.063	0.061	-0.124	-0.235	0.165	0.004	0.090

- 未婚者も既婚者もパラメータの値はほぼ同じ値。
正負もほぼ一致している
- 未婚者はGoogleのパラメータが高い
- 既婚者はYouTubeのパラメータが高い



未婚者はGoogleへの広告配信
既婚者はYouTubeへの広告配信が
効果が高いと考えられる。
両者ともLINEへの配信は効果が低い。

結果1

概要

データ

分析

結果

考察
まとめ

子供有無

変数	定数項	Twitter	Facebook	Instagram	LINE	YouTube	Yahoo!JAPAN	Google
いる	-0.044	-0.093	-0.094	0.070	0.096	-0.005	-0.009	0.028

- ・ 子持ちはLINE、Instagramのパラメータが高い
- ・ 子なしはTwitter、Facebookのパラメータ値が高い



子供のいる人にはInstagramとLINEへの配信、子供のいない人にはTwitterとFacebookへの配信が効果が高いと考えられる。

家族構成

変数	定数項	Twitter	Facebook	Instagram	LINE	YouTube	Yahoo!JAPAN	Google
単身	0.095	0.050	-0.254	-0.052	-0.121	0.050	0.013	0.268
1世帯	0.182	0.011	-0.221	-0.029	-0.151	0.121	0.048	0.121
2世帯	-0.541	-1.543	0.548	0.221	-1.120	0.273	0.773	1.214
3世帯以上	0.100	0.019	-0.101	-0.076	-0.333	0.105	-0.335	0.247

- ・ 単身世帯ではGoogleのパラメータが高い
- ・ 1世帯ではYouTubeとGoogleのパラメータが高い
- ・ 2世帯ではGoogleのパラメータ値がい
- ・ 3世帯以上ではGoogleのパラメータ値がい



家族構成により配信の正値を示す媒体先は変化が見られなかった。一方で、負の影響を与える媒体先には世帯数ごとにながることが明らかになった。

結果1

概要

データ

分析

結果

考察
まとめ

居住地

変数	定数項	Twitter	Facebook	Instagram	LINE	YouTube	Yahoo!JAPAN	Google
栃木	0.062	0.483	0.342	-0.734	0.155	-0.355	0.405	0.174
群馬	0.358	0.094	0.060	-0.308	0.306	0.191	0.095	0.049
埼玉	0.097	0.137	0.154	-0.482	0.283	0.134	0.213	-0.043
千葉	0.139	0.252	0.097	-0.498	0.096	0.075	0.235	0.102
東京	0.215	0.034	0.221	-0.346	0.308	-0.004	0.217	-0.066
神奈川	0.209	0.153	0.183	-0.321	0.280	0.032	0.231	-0.124

- ・ 栃木はTwitter、Yahoo! JAPANのパラメータ値が高い
- ・ 群馬はLINEのパラメータ値が高い
- ・ 埼玉はLINE、Yahoo! JAPANのパラメータ値が高い
- ・ 千葉はTwitterのパラメータ値が高い
- ・ 東京はFacebook、LINEのパラメータ値が高い
- ・ 神奈川はLINE、Yahoo! JAPANのパラメータ値が高い



都道府県別になると、県によって最適な広告配信先が異なることが明らかになった。

結果1

概要

データ

分析

結果

考察
まとめ

職業

変数	定数項	Twitter	Facebook	Instagram	LINE	YouTube	Yahoo!JAPAN	Google
主婦	0.222	0.269	-0.147	-0.076	0.010	-0.210	0.233	0.073
自営業	0.072	0.283	-0.215	-0.190	0.193	-0.185	0.138	0.012
会社員	0.133	0.303	-0.164	-0.167	0.062	-0.068	0.132	0.046
アルバイト	0.166	0.267	-0.274	-0.152	0.067	-0.144	0.214	0.132
学生	0.141	0.330	-0.155	-0.388	0.155	-0.314	-0.075	0.428

- 主婦はTwitterのパラメータ値が高く、YouTubeのパラメータ値が低い
- 自営業はTwitterのパラメータ値が高く、Facebookのパラメータ値が低い
- 会社員はTwitterのパラメータ値が高く、FacebookとInstagramのパラメータ値が低い
- アルバイトはTwitterとYahoo! JAPANのパラメータ値が高く、Facebookのパラメータ値が低い
- 学生はGoogleのパラメータ値が高く、InstagramとYouTubeのパラメータ値が低い



職業別に見るとTwitterに正の値をとる職業が多い。一方で学生はTwitterも値が大きいが、Googleが最も正の影響を与える結果になった。

分析2

概要

データ

分析

結果

考察
まとめ

ターゲット設定



売り込みたい商品



ターゲット属性

性別:男性
年齢:30代
居住地:神奈川県
職業:会社員

目標属性におけるNetflixのパラメータ値

変数	定数項	Twitter	Facebook	Instagram	LINE	YouTube	Yahoo!JAPAN AN	Google
性別:男性	0.064	-0.065	0.115	-0.026	-0.056	0.034	0.021	-0.005
年齢:30代	0.023	-0.119	0.096	-0.238	-0.009	0.068	-0.032	0.015
居住地:神奈川県	0.209	0.153	0.183	-0.321	0.280	0.032	0.231	-0.124
職業:会社員	0.133	0.303	-0.164	-0.167	0.062	-0.068	0.132	0.046
合計	0.429	0.272	0.23	-0.752	0.277	0.066	0.352	-0.068

効果的な配信先

Twitter, LINE, Yahoo! JAPAN

会社員の男性は情報収集のためにTwitterを頻繁に使っており、連絡手段としてのLINEも使う頻度が高いことが要因だと考えられる。

効果の低い配信先

Instagram

若い会社員の男性はInstagramの使用頻度は低いことが要因だと考えられる。

分析2

概要

データ

分析

結果

考察
まとめ

ターゲット設定



売り込みたい商品



ターゲット属性

性別:女性
年齢:40代
家族構成:2世帯
職業:アルバイト
居住地:東京

目標属性におけるNetflixのパラメータ値

変数	定数項	Twitter	Facebook	Instagram	LINE	YouTube	Yahoo!JAP AN	Google
性別:女性	-0.064	0.065	-0.115	0.026	0.056	-0.034	-0.021	0.005
年齢:40代	-0.082	-0.205	0.141	-0.006	-0.075	0.095	0.078	-0.077
家族構成: 2世帯	-0.541	-1.543	0.548	0.221	-1.120	0.273	0.773	1.214
職業:アル バイト	0.166	0.267	-0.274	-0.152	0.067	-0.144	0.214	0.132
居住地:東 京	0.215	0.034	0.221	-0.346	0.308	-0.004	0.217	-0.066
合計	-0.306	-1.382	0.521	-0.257	-0.764	0.186	1.261	1.208

効果的な配信先

Yahoo! JAPAN, Google

40代の女性は検索エンジンを使用して、検索をかけていることが多いと考えられる。
また2世帯かつアルバイトをしている女性は忙しく、SNSの利用頻度が低い。

効果の低い配信先

Twitter

40代の女性は、情報収集はSNSではない媒体であることが多いことが予想できる。

分析1

Netflixにおける購入意向の変化量と、個人毎のSNS利用量との関係性を分析した。消費者属性によってパラメータの値は細かく異なるので、ターゲット属性によって広告配信媒体を変えるべきである。



性別



居住地



職業



子供有無

分析2

Netflixにおける消費者属性と各媒体の共通性パラメータの値から、ターゲット属性における最適な配信先の特定が可能であることを提案した。消費者ごとに最も効果的な配信先を選ぶことが可能になった。



女性



LINE?



東京住み



Facebook?

今後、媒体ごとの広告配信にかかる費用に関するデータを含めて分析を行うことで、予算に合わせた最適な広告配信媒体の推測が可能になる。

ターゲット属性ごとの広告効果と媒体ごとの予算を考慮した上で、最適な配信媒体を明らかにすることができ、企業のマーケティング施策においてどの媒体を優先すべきか知ることができる。

本研究の目的

任意の商品についてターゲット属性における最適なインターネット広告配信先を推測すること

Netflixについてモデル推定した結果

Netflix広告はマーケティング方法や属性によって最適な出稿媒体が異なること、効果の大きさが異なることが明らかになった。また共通性広告効果の予測シミュレーションを行うことで、最適な広告配信先を推定できた。

今後の課題

- 広告配信先の推定結果の評価
→最適化を行ったものの具体的な検証ができていないので、評価も行っていく必要がある。
- 広告予算も含めた最適化
→本研究では、属性における広告効果のみを考慮して最適化を行った。しかし効果だけでなく費用面も考慮しなくては企業のマーケティング施策を講じるのには不十分である。

参考文献

- [1] Alessandro Nuara Trovo, Nicola Gatti, Marcello Restelli Francesco. (2018). A Combinatorial-Bandit Algorithm for the Online Joint Bid / Budget Optimization of Pay-per-Click Advertising Campaigns .
- [2] Georgios Theodorou S. Thomas, Mohammad Ghavamzadeh Philip. (2015). Personalized Ad Recommendation Systems for Life-Time Value Optimization with Guarantees .
- [3] Jian Xu Lee, Wentong Li, Hang Qi, Quan Lu Kuang-chih. (2015). Smart Pacing for Effective Online Ad Campaign Optimization .
- [4] Matthew D. Hoffman Gelman Andrew. (2014). The No-U-Turn Sampler: Adaptively Setting Path Lengths in Hamiltonian Monte Carlo. Journal of Machine Learning Research 15 (2014).
- [5] 株式会社 CARTA COMMUNICATIONS. (2022年4月21日). 「2021年インターネット広告媒体費」解説。ビデオ(動画)広告、ソーシャル広告、現在のトレンドは？ 参照先: 電通報: <https://dentsu-ho.com/articles/8162>
- [6] 株式会社電通 .. 2020年日本の広告費 . 参照先 : 株式会社電通 : https://www.dentsu.co.jp/knowledge/ad_cost/2020/
- [7] 佐藤忠彦 山田浩喜. (2019). 同一商業累積地に隣接する 店舗間のストア・イメージに基づく店舗評価 . マーケティングサイエンス Vol.27.
- [8] 佐藤忠彦 日高徹司. (2016). 消費者ブランドとの関係を考慮した階層ベイズモデルによるクロスメディア効果推定 . 日本オペレーションズ・リサーチ学会和文論文誌.
- [9] 崇善一郎 奥 牧人 河野石川. (2017). Web リスティング広告における基本広告データを用いた コンバージョン分析と予測
- [10] 伸彦 照井. (2008). ベイズモデリングによるマーケティング分析. 東京電機大学出版局.

補足資料

✓ NUTSアルゴリズム BuildTree関数の設定

BuildTree関数

$j = 0$ の時

1: リーフフログ法を用いて θ', r' を以下のように設定

$$r' = r + \left(\frac{v\epsilon}{2}\right) \nabla_{\theta} \mathcal{L}(\theta)$$

$$\theta' = \theta + v\epsilon r'$$

$$r' = r' + \left(\frac{v\epsilon}{2}\right) \nabla_{\theta} \mathcal{L}(\theta')$$

以下の式を満たした時、得られた候補サンプル θ', r を採用し
 $C' \leftarrow \{(\theta', r')\}$ とする。

$$u \leq \exp \left\{ \mathcal{L}(\theta') - \frac{1}{2} r' \cdot r' \right\}$$

2: s' を以下のように計算する。

$$s' = \begin{cases} 1 & \mathcal{L}(\theta') - \frac{1}{2} r' \cdot r' > \log u - \Delta_{max} \\ 0 & \text{otherwise} \end{cases}$$

$j = 0$ でないとき

1つ前のBuildTreeの結果を $\theta^-, \theta^+, r^-, r^+, C', s'$ に入れる。

1: v の値に合わせてサンプリング

① $v = -1$ の時

$\theta^-, r^-, u, v, j-1, \epsilon$ を入力として、 θ^-, r^-, C'', s'' を返す。

② $v = -1$ でない時

$\theta^+, r^+, u, v, j-1, \epsilon$ を入力として、 θ^+, r^+, C'', s'' を返す

2: s' を以下のように計算する。

$$s' = \begin{cases} s' s'' & (\theta^+ - \theta^-) \cdot r^- \geq 0 \text{ and } (\theta^+ - \theta^-) \cdot r^+ \geq 0 \\ 0 & \text{otherwise} \end{cases}$$

3: C' を以下のように更新する。

$$C' \leftarrow C' \cup C''$$

補足資料

✓ NUTSアルゴリズム 推定アルゴリズム

- 1: パラメータの初期値 θ^0 、更新の幅 ϵ と負の位置エネルギー関数 \mathcal{L} を設定する。
- 2: 勾配の初期値ベクトル r^0 を平均 $\mathbf{0}$ 、分散 I (単位行列)の正規分布に従うように設定
- 3: スライス変数 u を0から $\exp\{\mathcal{L}(\theta^{m-1}) - \frac{1}{2}r^0 \cdot r^0\}$ の値をとる一様分布に従うように設定。
- 4: $\theta^-, \theta^+, r^-, r^+, C, s$ の初期値を以下のように設定。
$$\begin{aligned} \theta^- &= \theta^{m-1} & \theta^+ &= \theta^{m-1} \\ r^- &= r^0 & r^+ &= r^0 \\ C &= \{(\theta^{m-1}, r^0)\} & s &= 1 \end{aligned}$$
- 5: $s = 1$ の間、以下のようにサンプリングする。
サンプリングの方向 v_j を-1から1の一様分布に従うように設定する

5-1 v_j の値に合わせてサンプリングする。

① $v_j = -1$ の時

$\theta^-, r^-, u, v_j, j, \epsilon$ を入力としてBuildTree関数を実行する。

② $v_j = -1$ 以外の時

$\theta^+, r^+, u, v_j, j, \epsilon$ を入力としてBuildTree関数を実行する。

5-2 s' の値に合わせてBuildTree関数よりサンプリングする。

① $s' = 1$ の時

$$C \leftarrow C \cup C'$$

② $s' = 0$ の時

$$s = \begin{cases} s' & (\theta^+ - \theta^-) \cdot r^- \geq 0 \text{ and } (\theta^+ - \theta^-) \cdot r^- \geq 0 \\ & 0 \end{cases}$$

$$j = j + 1$$

6: $s = 0$ の時

θ^m, r を C からランダムに決めて更新する

7: 2~6をMCMCのにおける繰り返し回数だけ繰り返す。