

# マーケティングミックスモデリング ガイドブック

2023.9 株式会社博報堂DYメディアパートナーズ

## CHAPTER 1 マーケティングミックスモデリングの 紹介

1. マーケティング効果測定  
の課題 [p.3](#)
2. マーケティングミックス  
モデリングの概要 [p.8](#)
3. MMMが再注目される背景 [p.13](#)

## CHAPTER 2 マーケティングミックスモデリングの 基本

1. データの選択 [p.21](#)
2. データクレンジング [p.30](#)
3. モデル構造の作成 [p.40](#)
4. パラメータの推定 [p.58](#)
5. モデルの検証 [p.63](#)
6. モデルの利用 [p.78](#)
7. MMMに関するその他の  
トピック [p.83](#)

## CHAPTER 3 MMMのモデル構造に関する考察

1. モデル構造の作成方法と類型 [p.88](#)
2. モデル構造が分析結果に  
与える影響の検証 [p.96](#)
3. シミュレーションスタディ [p.102](#)
4. モデル構造に関する問題と  
解決のヒント [p.119](#)
5. 博報堂DYグループの  
MMMソリューション [p.132](#)

CHAPTER

1

# マーケティングミックスモデリングの紹介

## 1.1. マーケティング効果測定 of 課題

---

企業はメディアやマーケティングの効果として  
リーチや認知指標だけでなく事業貢献に対する説明を求めている。

これまで測定されていた指標

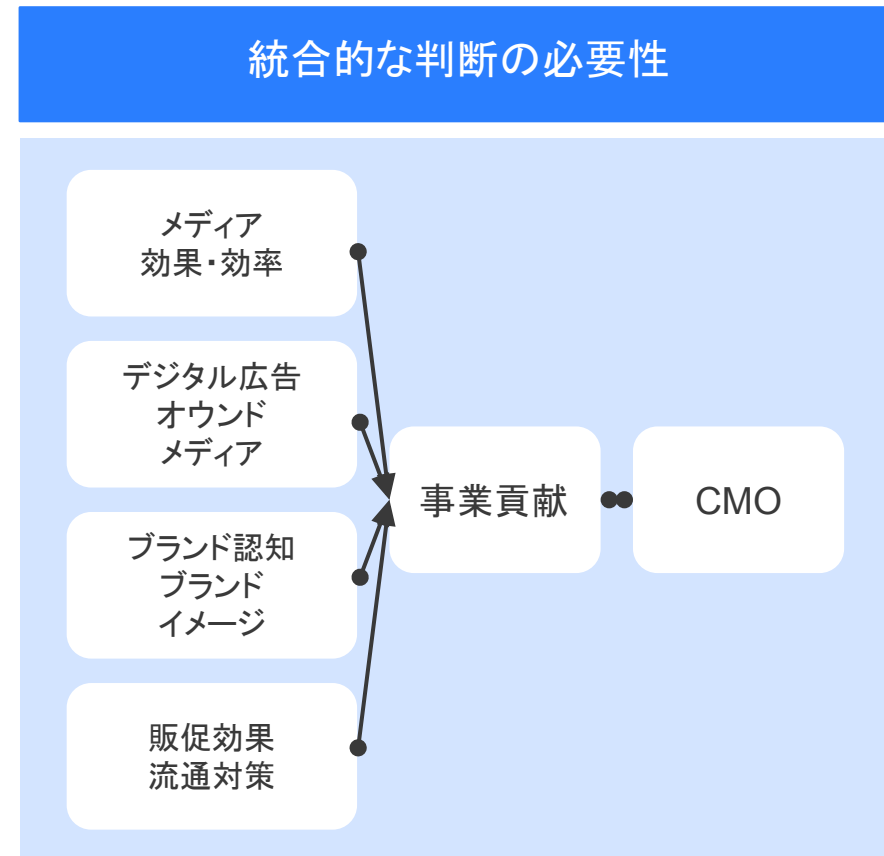
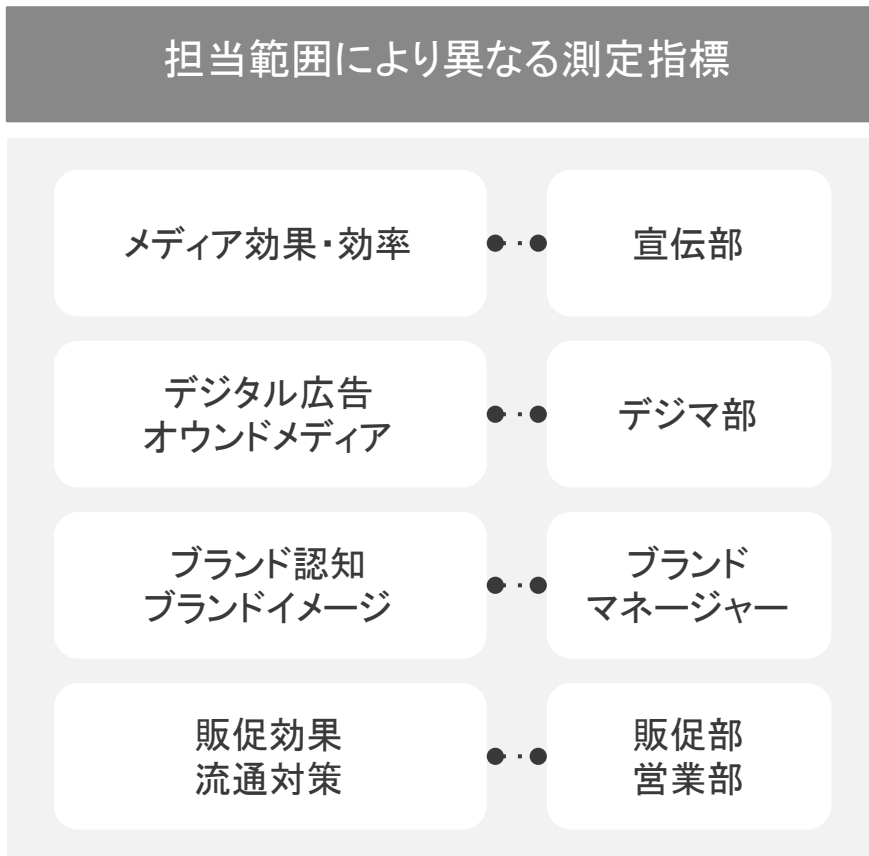
リーチ・リーチ効率  
広告認知率・想起率  
ブランド認知率  
ブランドイメージ  
購入意向率



現在説明が求められる指標

新規獲得人数  
アクティブ人数  
販売数量  
売上・シェア

またマーケティング効果を最大化するため、事業貢献を起点に  
さまざまな施策の効果を統合的に判断する必要がある。



# デジタル広告で発展したクッキー\*活用は事業貢献を測定できる手法であるが クッキーレス時代の到来で、利用範囲が狭まっている。

クッキーへの期待

クッキーでデジタル広告はもちろん  
テレビ視聴ログや調査データ・POSを結合



クッキーによるユーザ行動の測定

クッキーレス時代の到来

個人情報保護の高まりから  
クッキーの利用が段階的に制限

- Apple 2017年よりブラウザにおけるサードパーティクッキーの利用制限
- Google 2024年後半、ブラウザにおけるサードパーティクッキーの利用制限

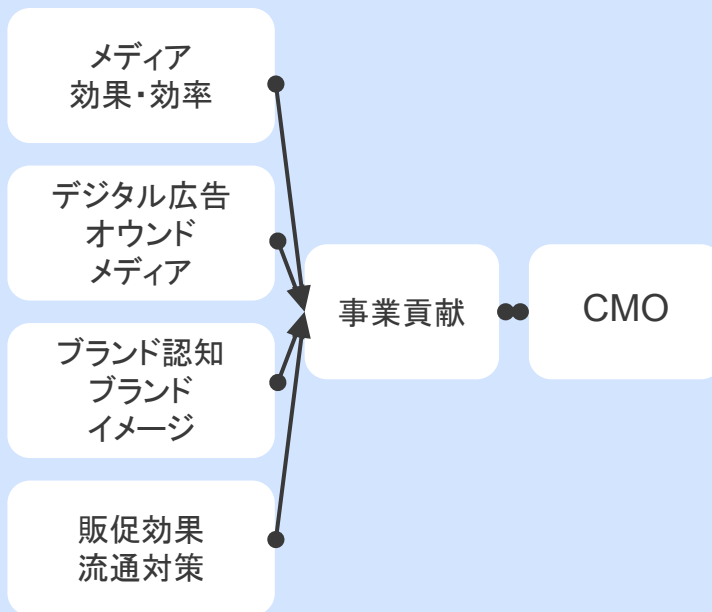
\*以降、本ガイドブック中での「クッキー」「Cookie」は、3rd party Cookieのことを指します。

メディアやマーケティングの事業貢献を、横断的・統合的に、  
クッキーに頼らず測定できる手法が求められている。

現在説明が求められる指標

新規獲得人数  
アクティブ人数  
販売数量  
売上・シェア

統合的な判断の必要性



クッキーレス時代の到来

個人情報保護の高まりから  
クッキーの利用が段階的に制限

- Apple 2017年よりブラウザにおけるサードパーティクッキーの利用制限
- Google 2024年後半、ブラウザにおけるサードパーティクッキーの利用制限

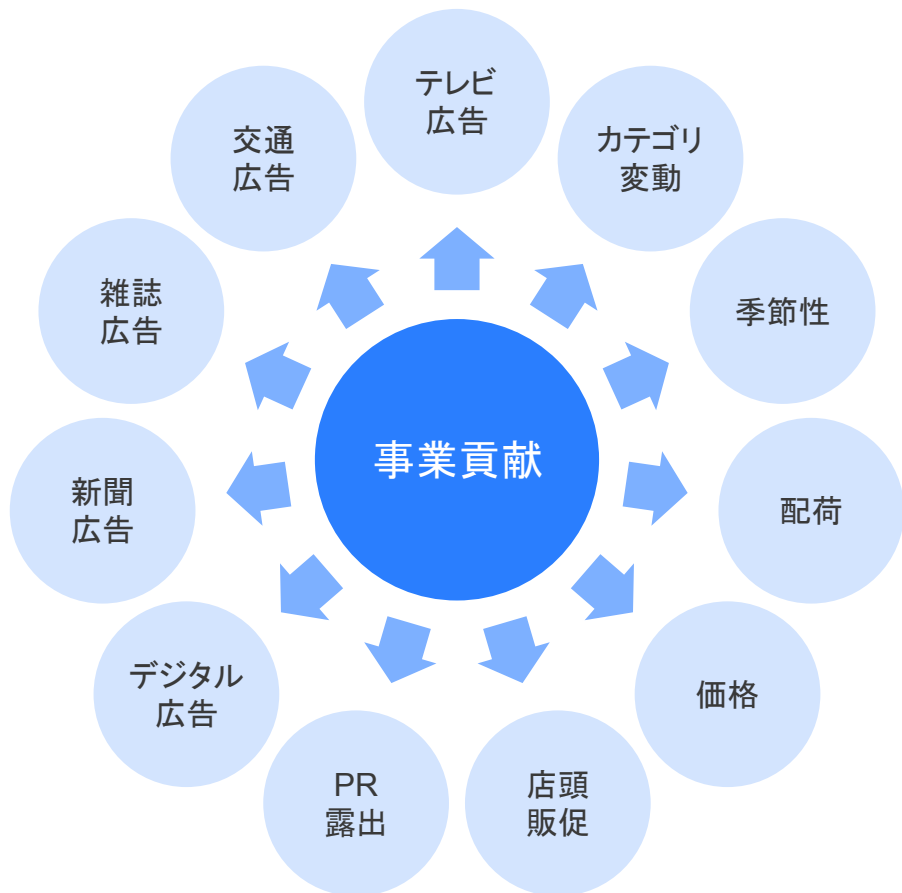


## 1.2. マーケティングミックスモデリングの概要

---

# MMMは、メディアやマーケティング施策の事業貢献を クッキーに頼らず、統計的に推定できる手法である。

▼マーケティングミックスモデルの概念図



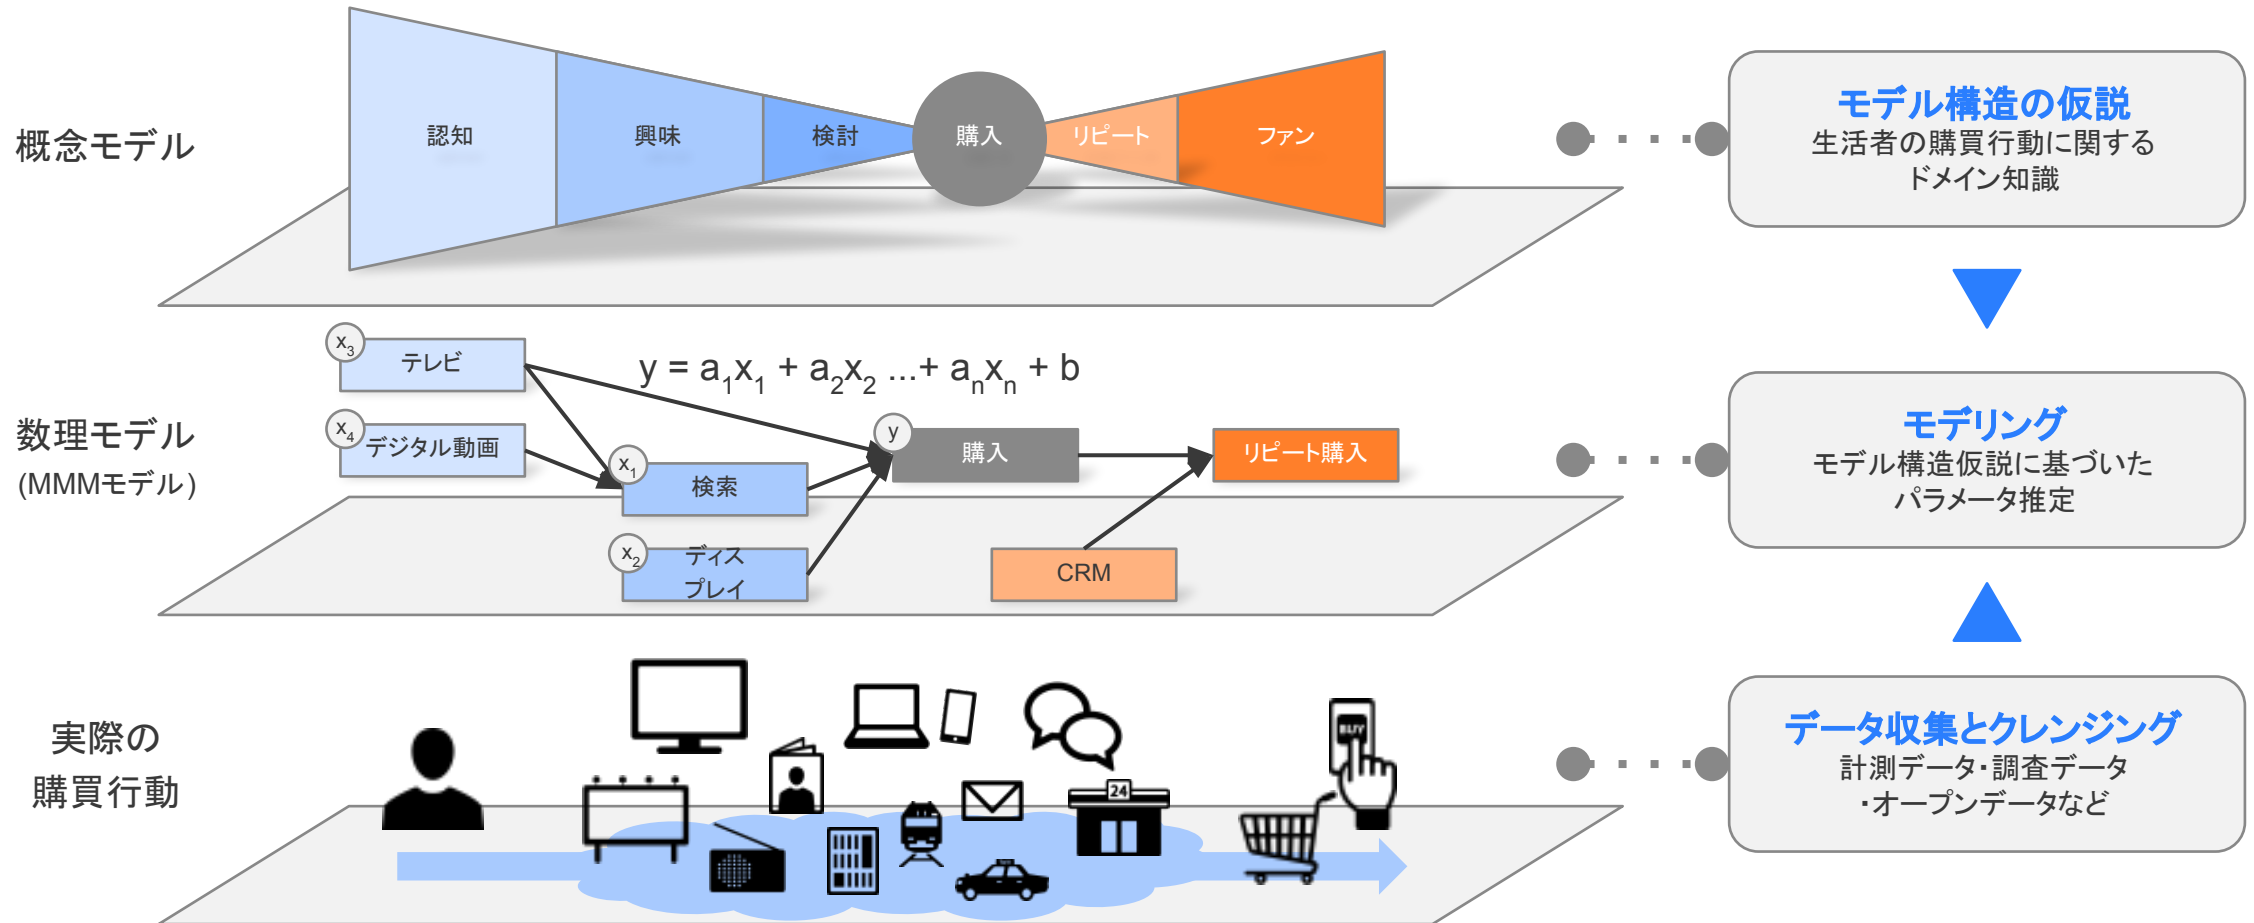
▼マーケティングミックスモデルを活用するメリット

マーケティング効果を **クッキーに頼らず、統計的に推定** する手法である

獲得人数、販売数量や売上といった **事業貢献に対するマーケティング効果** を推定できる

デジタル広告だけでなく、**さまざまなメディアやマーケティング施策、外的要因の効果** を推定できる

MMMでは、生活者の行動や心理を計測したデータを収集・加工し、  
メディアやマーケティング施策と事業成果の関係を数式で表現する。



## MMMを活用することで、事業貢献を起点とした メディアやマーケティング施策の診断・予測・処方が可能となる。

1.

メディアやマーケティング施策の何が、  
どれくらい・どのように事業貢献しているのか？



### マーケティング効果の把握

各要因が事業成果に及ぼす貢献量を横断的に把握できる

2.

マーケティング予算・メディア予算配分は妥当  
なのか？



### 予算配分の最適化

目標とする事業成果に対して、必要な費用や効率的な予算配  
分を計算することができる

3.

将来のマーケティング戦略・メディアプランを  
サポートするエビデンスは何か？



### 事業成果シミュレーション

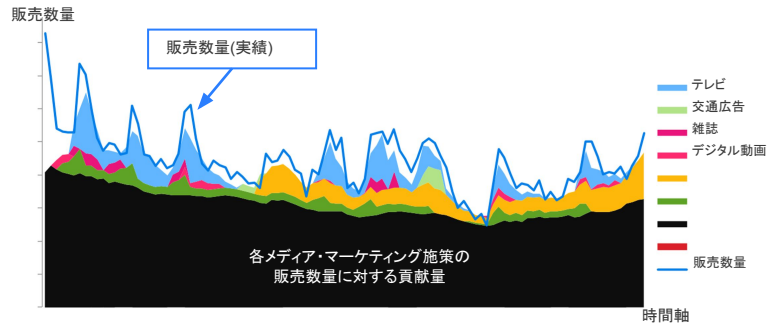
将来のマーケティング戦略・メディアプランの想定される事業貢  
献をシミュレーションできる

1. メディアやマーケティング施策の何が・どれくらい・どのように事業貢献しているのか？



**マーケティング効果の把握**  
各要因が事業成果に及ぼす貢献量を横断的に把握できる

▼各メディア・マーケティング施策の貢献量推定



▼各メディア・マーケティング施策の費用対効果(ROI)


出稿金額(百万円)	貢献量(販売数)	CPA=出稿金額/貢献度		
タイム	2,900	264,481	10,967	タイム
スポット	423	40,304	10,330	スポット
BS	56	26,936	2,075	BS
CS	170	49,140	3,451	CS
新聞	559	28,078	19,902	新聞
ラジオ	193	49,009	3,928	ラジオ
交通	152	26,551	5,732	交通
雑誌	38	4,675	8,021	雑誌
WEB	744	171,810	4,445	WEB

2. マーケティング予算・メディア予算配分は妥当なのか？




**予算配分の最適化**  
目標とする事業成果に対して、必要な費用や効率的な予算配分を計算することができる

▼各メディアの投資に対する弾力性(事業貢献)



▼目標に対する最適予算配分



【最適予算配分】

テレビ	1億5120万円 (75.6%)
雑誌	355万円 (1.8%)
交通広告	1,455万円 (7.3%)
デジタル動画	1,328万円 (6.6%)
ディスプレイ	832万円 (4.2%)
リスティング	386万円 (1.9%)
SNS	524万円 (2.6%)


TTL: 2.0億円

3. 将来のマーケティング戦略・メディアプランをサポートするエビデンスは何か？




**事業成果シミュレーション**  
将来のマーケティング戦略・メディアプランの想定される事業貢献をシミュレーションできる

▼メディアプランと事業成果シミュレーション



事業成果シミュレーション

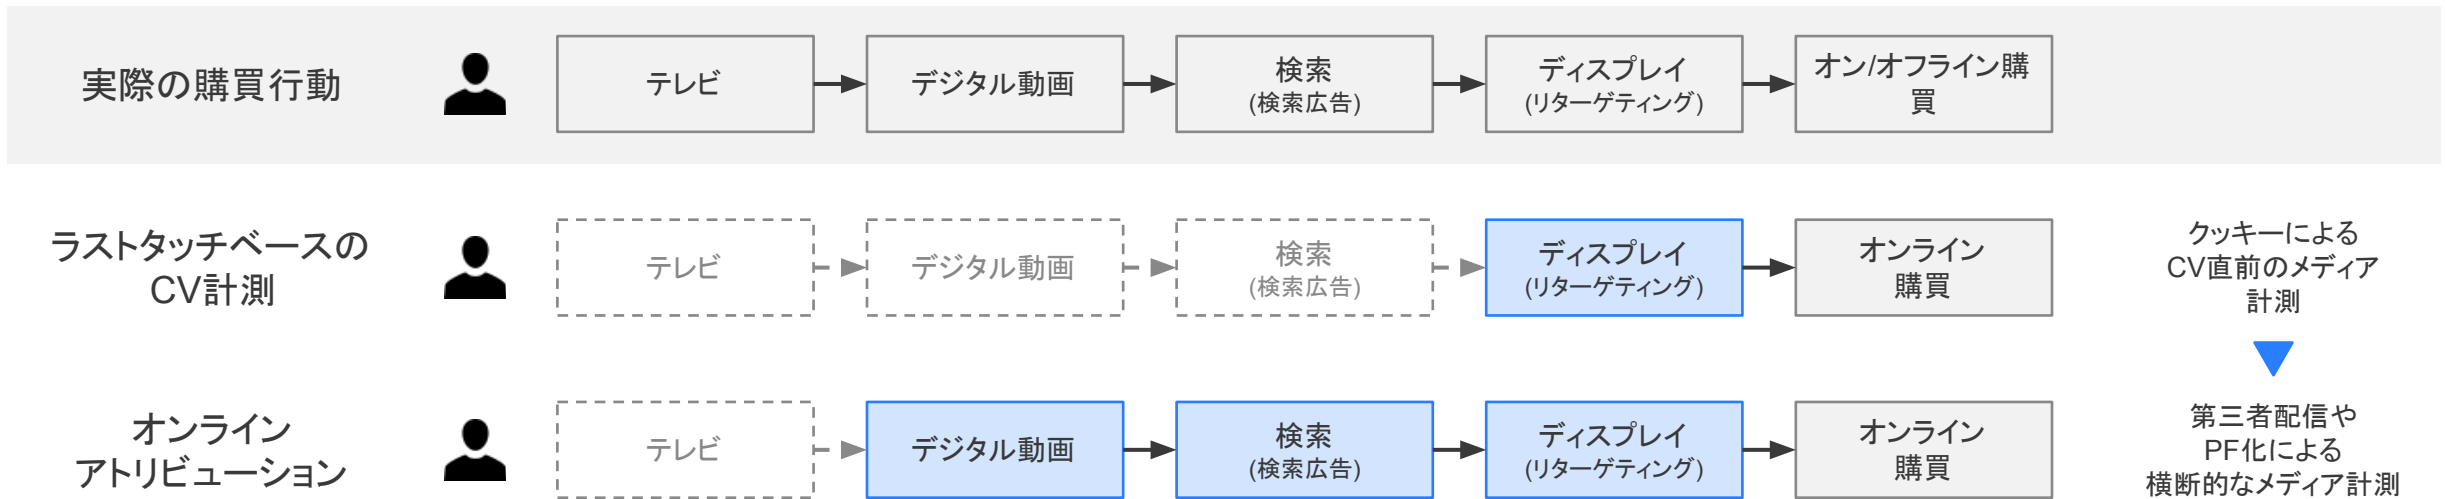


## 1.3. MMMが再注目される背景

---

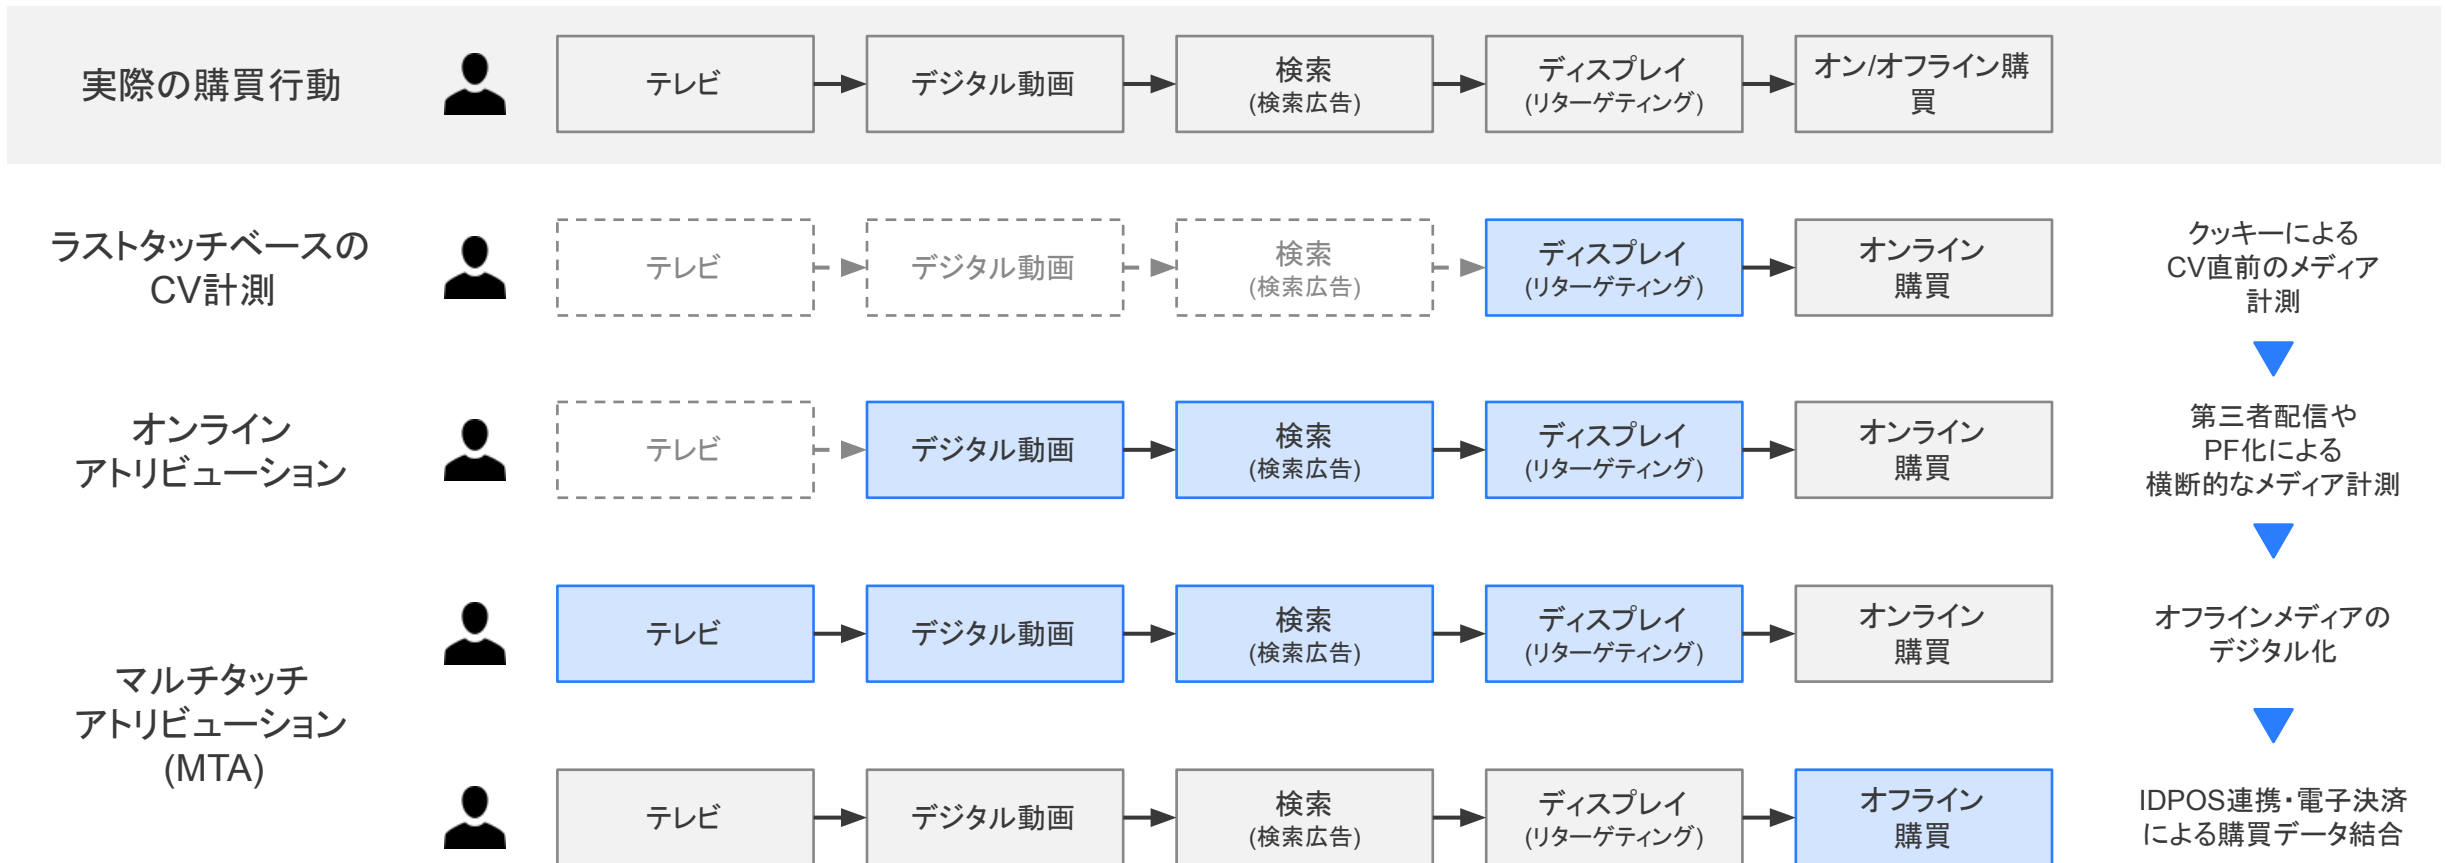
# デジタル広告ではクッキーにより、最初の広告接触から購買までの経路を計測し、各メディア接触の貢献度を算出することが可能。

ファーストタッチ >>> ミドルタッチ >>> ラストタッチ >>> CV



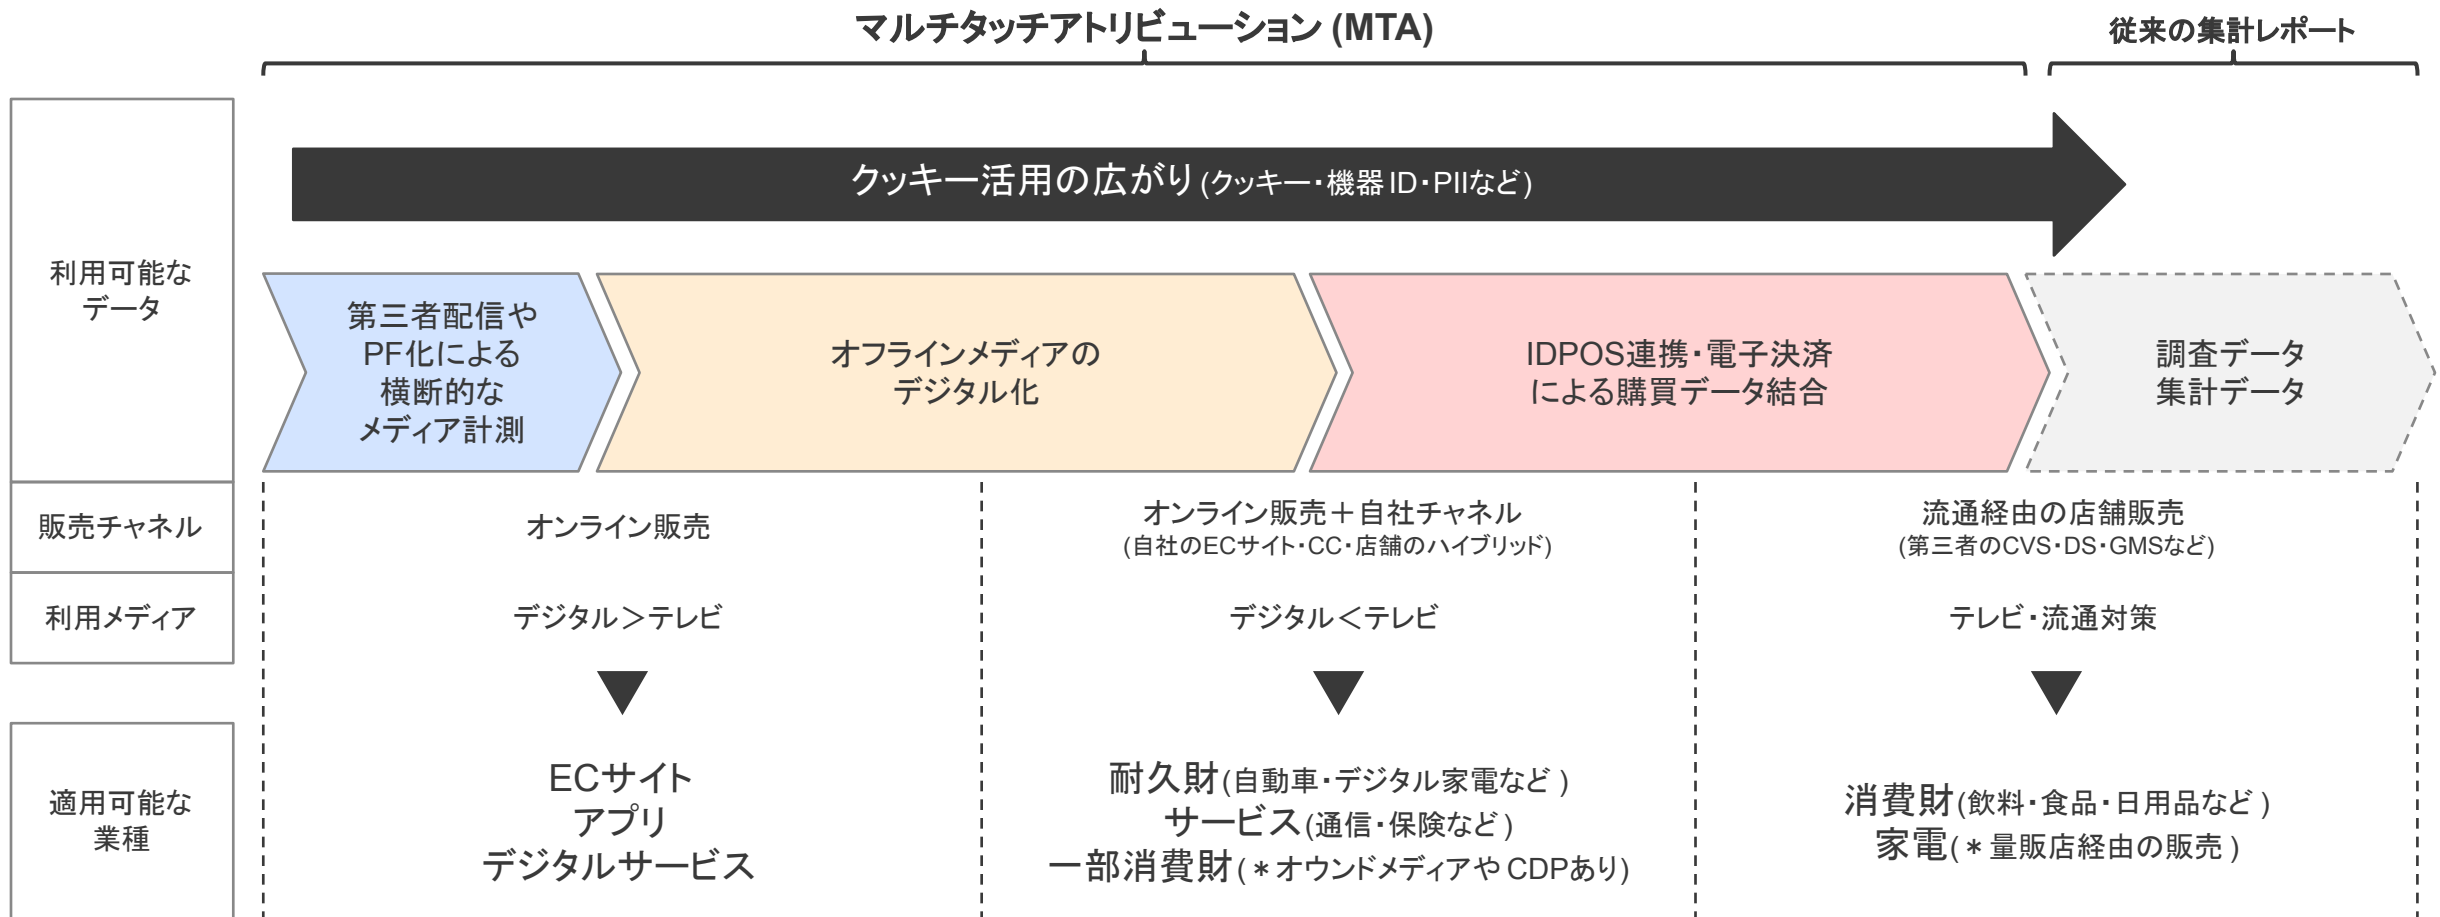
# テレビのネット接続や電子決済の浸透により、オフライン接点もデータ結合。オン・オフ統合で広告接触～購買の経路の分析が可能となった。

ファーストタッチ >>> ミドルタッチ >>> ラストタッチ >>> CV





このようにクッキー活用によりデジタル広告の効果測定方法を  
オフライン販売メインの商材にも拡大できる期待が高まった。



しかし、クッキー規制や低いEC化率といった原因から  
データ結合は十分に実現できず、MTAの活用範囲は現在、限定的である。

クッキー規制


クッキー規制は特にiPhoneシェアの高い日本ではすでに影響大

▼Cookie規制の動向

**Apple** 2017年よりブラウザにおけるサードパーティクッキーの利用制限

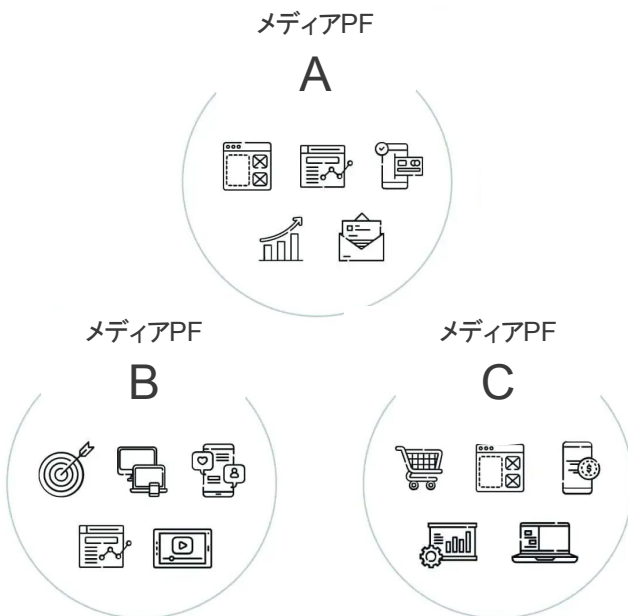
**Google** 2024年後半、ブラウザにおけるサードパーティクッキーの利用制限

▼日本のiPhoneシェア \*1



Walled-Garden化

PFごとにクローズドなデータ活用環境整備が進む



EC化率

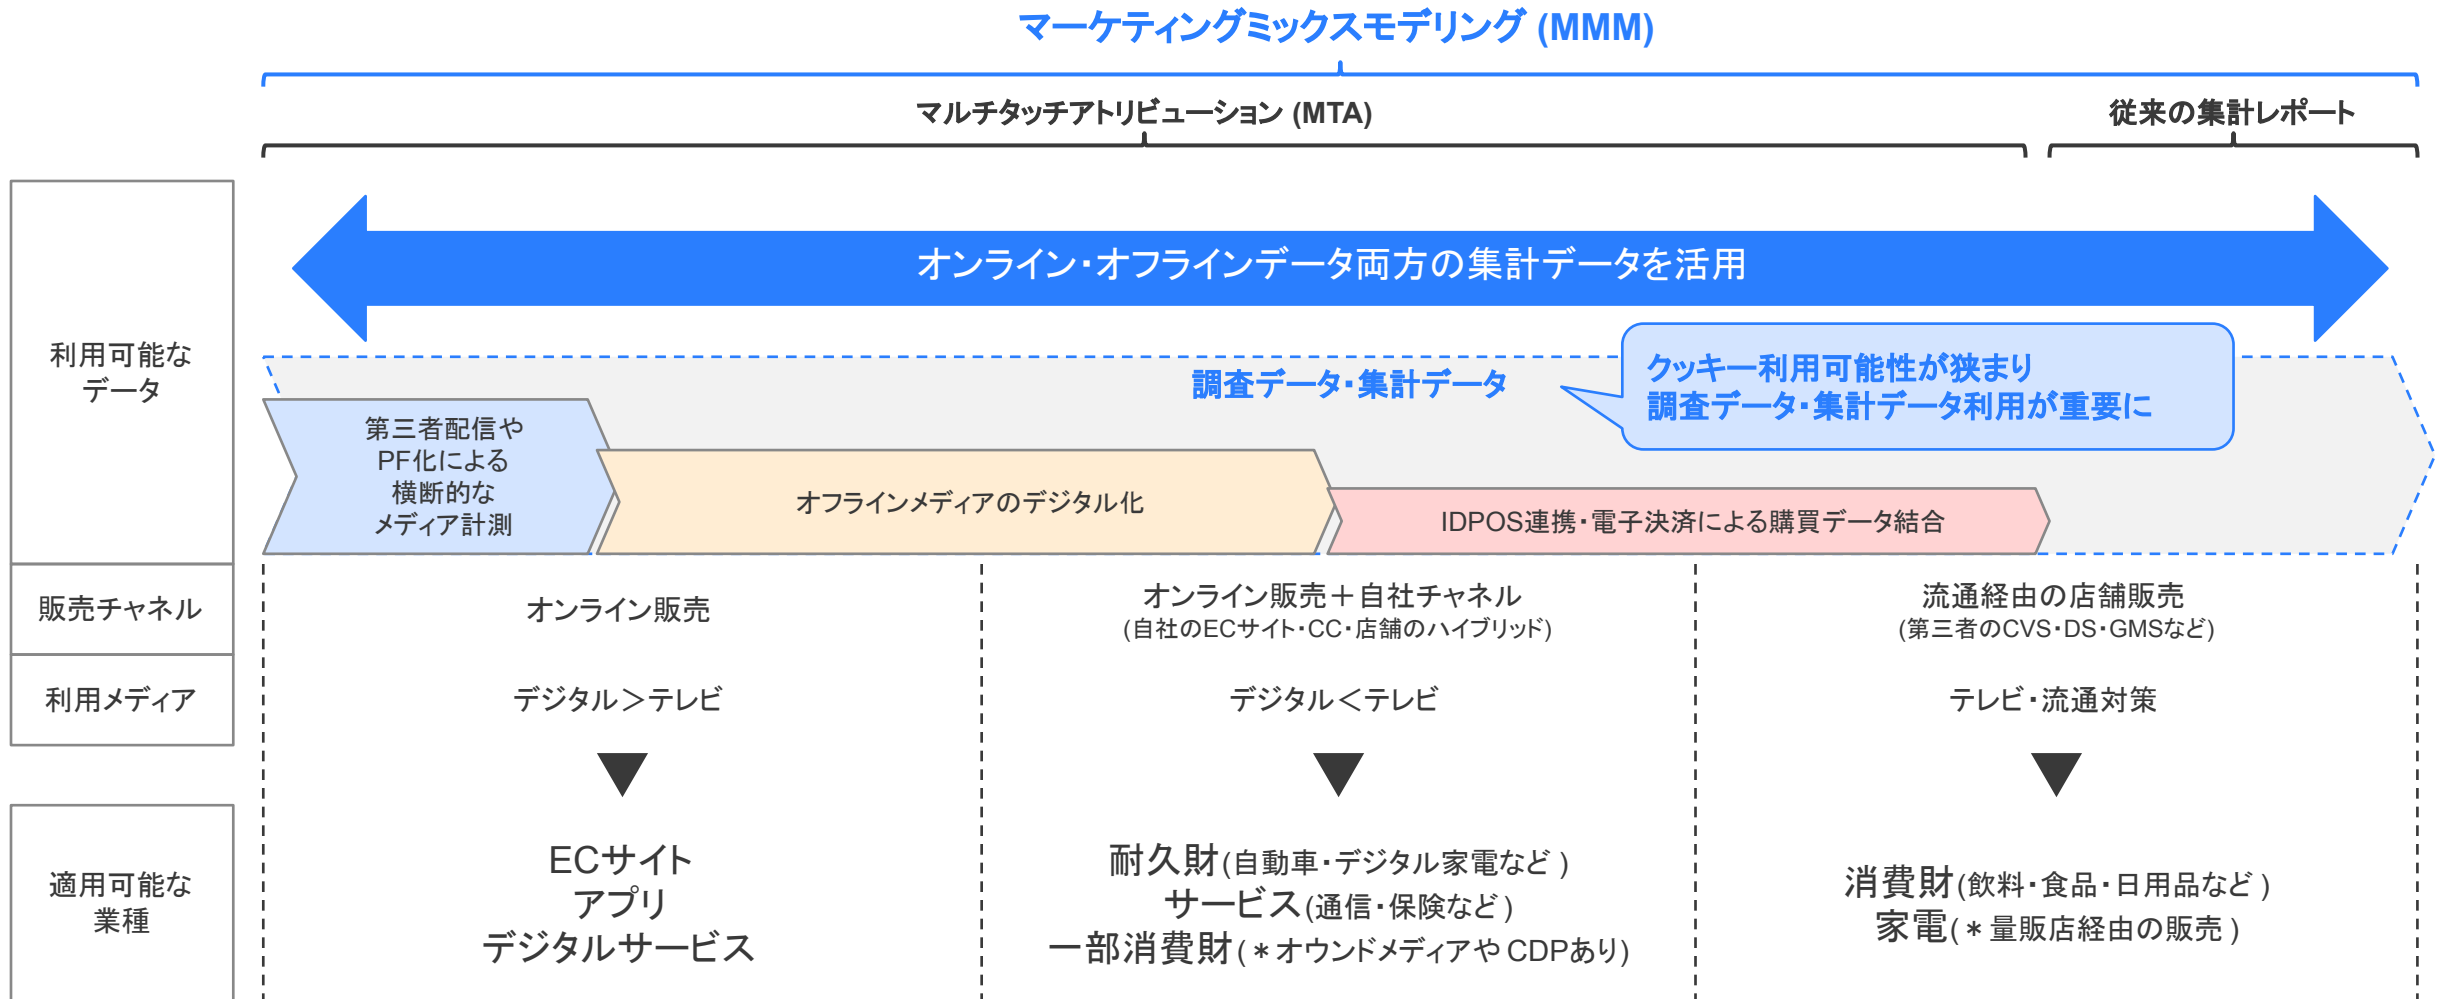
カテゴリによってはEC化率が10%未満に留まる

▼カテゴリ別EC化率 \*2

カテゴリ	2021年
物販平均	8.8%
書籍・映像・音楽	46.2%
家電・AV機器・PC関連	38.1%
生活雑貨・インテリア	28.3%
アパレル	21.2%
化粧品・衣料品	7.5%
食品・飲料・アルコール	3.8%
自動車・バイク	3.9%
その他	2.0%

\*1: statcounter \*2: 経済産業省「令和3年度デジタル取引環境整備事業(電子商取引に関する市場調査)(2021)」

そこで、クッキーに頼らず、集計データを利用して、オンオフ統合でマーケティングの事業貢献を推定できるMMMが再び注目されている。



CHAPTER

2

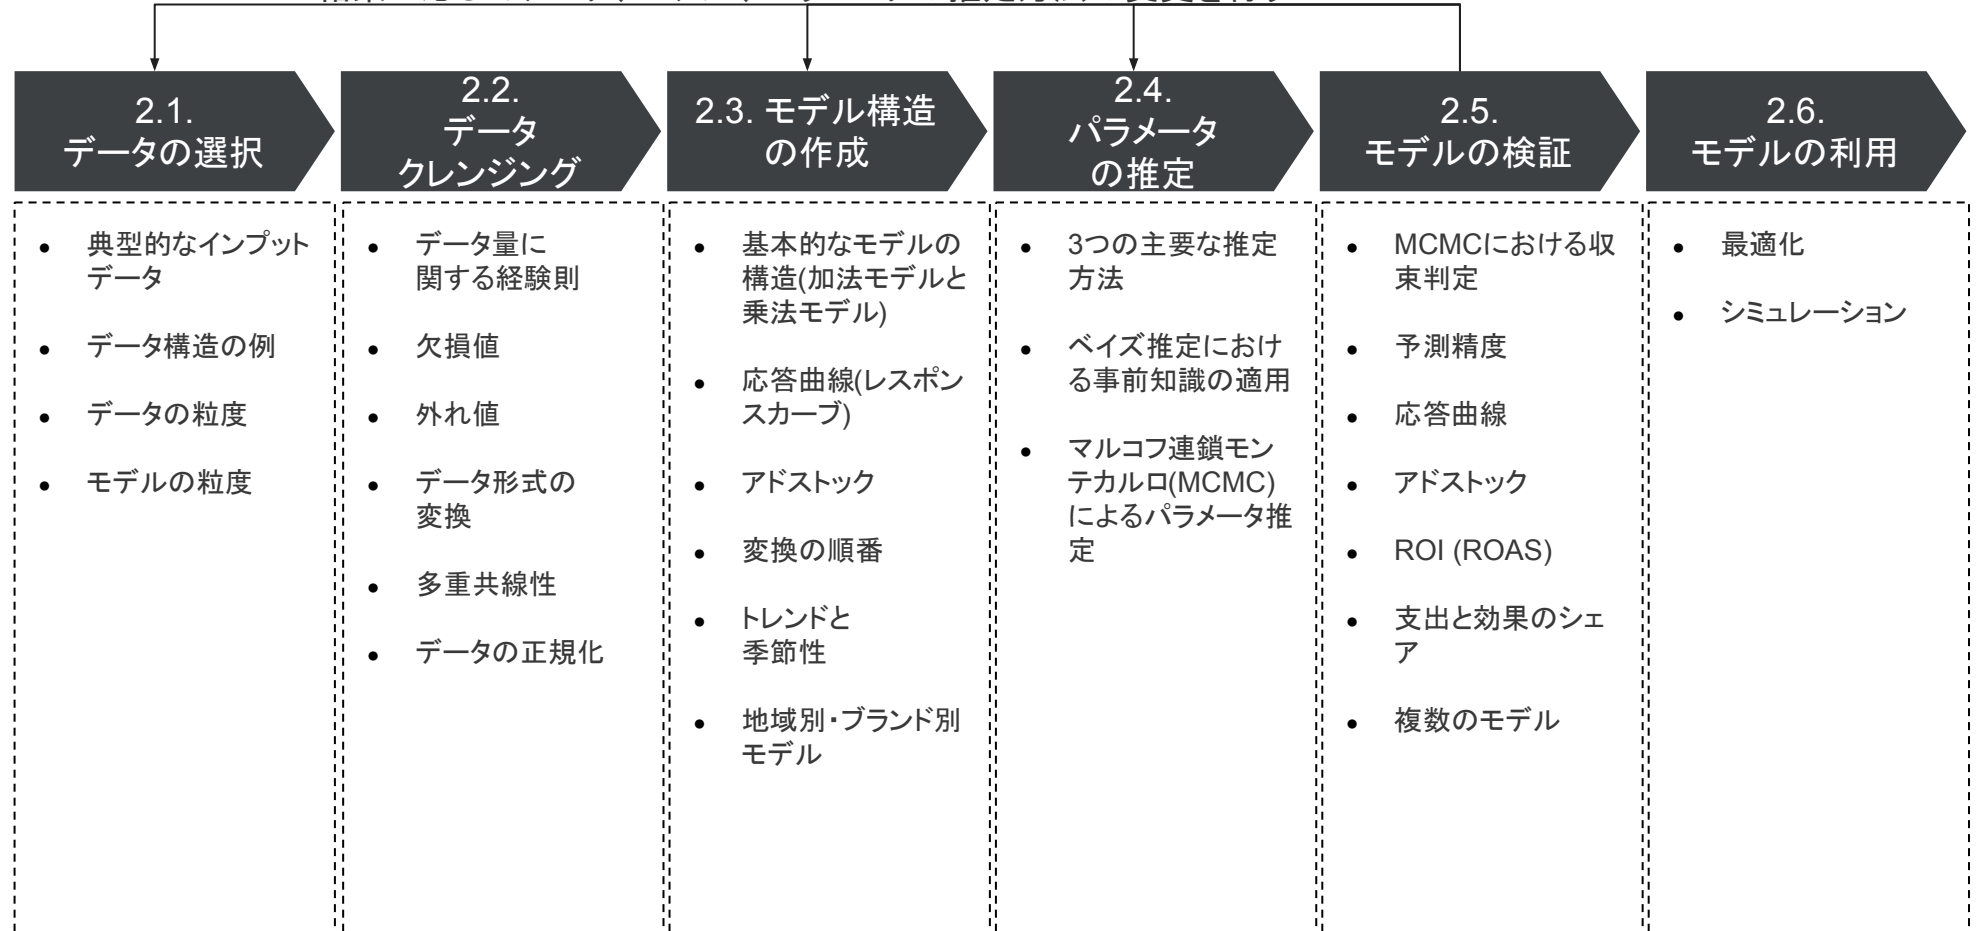
## マーケティングミックスモデリングの基本

一般にマーケティング・ミックス・モデリング(MMM)のプロセスは、データの選択、データのクレンジング、モデル構造の作成、モデルの作成、パラメータの推定、検証、活用からなる。

一般的な回帰モデルの作成と比較すると、入力データの選択、応答曲線の変換、アドストック、結果の検証等について、MMM特有の考慮事項がある。

このセクションではプロセスと一般的に考慮すべき事項について解説する。

結果に応じてデータ、モデル、パラメータの推定方法の変更を行う



## 2.1. データの選択

---

## データの選択の概要

右図では、MMMのためのデータの選択と統合プロセスの概要を示している。モデルは、社内外、オンライン・オフラインを問わず、様々なデータを使用する必要がある。

すべてのデータは同じ粒度の時系列データ(通常は日次または週次)である必要がある。例えば、日次レベルのMMMを作成したい場合、すべてのデータは日次レベルでなければならない。このように、入力データの粒度がモデルの粒度となる。

一般的にデータの収集と統合には最低でも数週間を要する。

一般的には、週単位の時系列データ  
(2年以上\*)

データ(詳細は次のページ)

KPI (売上、インストール数など)

オンラインメディアへの広告

オフラインメディアへの広告

製品・サービスに関するデータ

価格や販促のデータ

競合の活動に関するデータ

製品・サービスの人気度のデータ

その他

データの統合

入力  
データ

モデルの作成

MMM  
モデル

凡例

内部データ

外部データ

\*: 必要なデータ量はビジネスの性質による

## MMMを作成するには、KPIデータ、メディアデータ、メディア以外のデータが必要である

データ		例	データソースの例	
従属変数 (目的変数)	KPI (Key Performance Indicator, ビジネス評価指標)	売上、販売数、コンバージョン数、アクティブユーザー数、アプリインストール数等	内部データ	
独立変数 (説明変数)	メディアに関するデータ	オフラインメディア	テレビ、ラジオ、新聞広告、OOH等のオフラインメディアの広告費またはGRP(TVの場合)	広告代理店または内部データ
		オンラインメディア	デジタルメディアの広告費とインプレッション (YouTube、Google検索、Googleアプリキャンペーン、Facebook、TikTok等)	各メディアの広告マネージャー・API等
	メディア以外のデータ	製品・サービス	KPIに影響を与える可能性のある製品指標 (製品アップデート、アプリ/ウェブユーザーの評価、消費者調査等)	内部データ、アプリプラットフォーム等
		価格・販促	販促データ(価格、販促費、販促タイプ、店頭陳列タイプ、配架率など)及びイベント/トレードショーのスケジュール	内部データ、小売等
		競合の活動	競合他社に関するデータ(プロモーション、新製品発表、メディア活動、ユーザー評価、アプリランキング等)	競合他社のウェブサイト、アプリプラットフォーム等
		製品・サービスの人気度	製品・サービスのトレンドを示すデータ (ハッシュタグ数、グーグルトレンドインデックス、アプリランキング等)	各メディアのインターフェース
		その他	マクロ経済データ(GDP成長率、Covid-19感染症等)、季節性(休日、天候)等	公共機関等のオープンデータソース

一般的には、週単位の時系列データ (2年以上)\*

\*: 必要なデータ量はビジネスの性質による



# KPIの選択は、MMMを作成する上で極めて重要である

MMMでは適切なKPIを選択する必要がある。

一般的には、ブランドの自然検索数、購買数などの中間変数や、売上などの最終結果のKPIが選択される。

しかし、製品の認知から到達までの期間が比較的長いKPI(例えば、生命保険の購入)が選択された場合、MMMでメディアの投資対効果を推定することが困難となることがある。製品の認知から購買までの期間が長く、その間に購買に影響するデータ(例えば、営業のセールススキル等)が得られない場合があるからである。

上記のようなデータ不足を避けるため、KPIの選択を妥協する(例えば、ブランドの自然検索数等の中間変数をKPIとして選択する)選択肢も念頭に置くべきである。



## メディアに関するデータの選択投資額、インプレッション、クリックなど

メディア変数の指標をどのよう  
に選択するかは重要な問題の1つである。

従来のMMMではメディアの  
広告費(広告投資)が利用されてきたが、デジタルメディアを含むMMMIには必ずしも適切ではない。

一般的に、デジタルメディアではインプレッションが  
広告露出を表す有効な変数である。さらに詳細なデータとして、リーチとフリクエンシー(一人当たりのインプレッション数)データの利用に関しても、研究がなされている。

選択肢	説明	一般的な判断基準
<p>広告費</p>	<ul style="list-style-type: none"> <li>MMMモデルのメディア変数として、各メディアの広告費を使用する</li> </ul>	<ul style="list-style-type: none"> <li><b>非推奨:</b> 広告費だけでは、メディアユーザーに配信される広告量を説明できない</li> </ul>
<p>インプレッション</p>	<ul style="list-style-type: none"> <li>MMMモデルのメディア変数として、各メディアの広告インプレッション数を使用する</li> <li>モデルの係数は、インプレッションあたりのKPI(売上等)の増分として計算される。</li> <li>変化系: ビューアブル・インプレッション、GRP(TV)</li> </ul>	<ul style="list-style-type: none"> <li><b>推奨:</b> インプレッションは一般的に、経路広告を見る→オフラインで購入、広告を見る→クリック→購入など)に関係なく広告の配信量を表すのに良い指標である</li> <li>YouTubeの場合は、インターネット接続TVでの共同視聴を考慮すべきである(方法論は複数のアプローチがある)</li> </ul>
<p>リーチとフリクエンシー</p>	<ul style="list-style-type: none"> <li>広告が到達した人数(リーチ)と一人当たりインプレッション数(フリクエンシー)をメディア変数として使う</li> <li>モデルの係数は、リーチとフリクエンシーごとのKPI(売上等)の増分として計算される</li> </ul>	<ul style="list-style-type: none"> <li><b>データに課題あり:</b> 広告のリーチとフリクエンシーは広告の露出を示す有効な指標であるが、異なるメディアやキャンペーン間でリーチとフリクエンシーを計算することは一般的に困難であり、開発途上の方法である</li> </ul>
<p>クリック</p>	<ul style="list-style-type: none"> <li>MMMモデルのメディア変数として、各メディアの帰属クリック数(広告のクリック数)を使用する</li> <li>モデルの係数は、獲得クリックあたりのKPI(売上等)の増分として計算される</li> </ul>	<ul style="list-style-type: none"> <li><b>限られた状況で推奨:</b> クリック数はビューの効果の説明をすることができない(例: 広告を見たが、それをクリックせず、後に商品を購入する場合)。検索広告でブランディング目的のウェブサイトへ誘導するケースであれば、例外的に有効である指標の可能性はある</li> </ul>
<p>ビュー</p>	<ul style="list-style-type: none"> <li>MMMモデルのメディア変数として、各メディアの視聴回数例: 3秒以上の視聴回数)を使用する</li> <li>モデルの係数は、獲得ビューあたりのKPI(収益等)の増分として計算される</li> </ul>	<ul style="list-style-type: none"> <li><b>非推奨:</b> 短尺ビデオフォーマット(例: 3秒未満)等の一瞬の広告の露出が考慮されなくなる。また、ビューの定義はメディアにより異なり、メディア間で同等のデータを収集することが困難である</li> </ul>

## MMMのインプットデータの例

例示的

date	revenue	google_search_clicks	google_search_spend	youtube_bumper_imp	youtube_bumper_spend	youtube_unskippable_imp	youtube_unskippable_spend	num_of_emails
2022-05-28	2,629,157	41,762	187,354	122,578,910	245,158	83,013,377	130,671	115,007
2022-05-29	5,455,074	61,772	70,359	250,073,569	500,147	206,689	58,723	7,884
2022-05-30	2,752,447	1,770,945	124,937	33,634,045	67,267	17,164,564	53,446	79,883
2022-05-31	4,495,993	94,222	46,635	214,849,357	429,698	56,422,041	134,518	44,655
2022-06-01	4,594,333	754,469	298,228	80,448,369	160,896	56,155,803	104,845	68,761
2022-06-02	3,198,586	55,192	9,900	32,198,560	64,397	11,901,778	54,564	93,130
2022-06-03	5,345,409	354,542	59,173	205,844,064	411,687	121,191,369	327,351	88,906
2022-06-04	4,634,572	105,363	511,908	70,692,283	141,384	13,144,918	36,897	55,226
2022-06-05	5,179,344	603,654	13,218	93,235,820	186,471	208,994,326	530,661	42,621
2022-06-06	4,605,407	72,608	164,127	115,014,135	230,028	13,623,608	51,037	30,084
2022-06-07	4,014,675	754,671	6,565	138,992,378	277,984	110,588,001	438,674	10,570
2022-06-08	5,862,088	69,290	245,447	12,007,451	24,015	3,994,038	30,242	57,745
2022-06-09	4,891,005	2,528	50,513	226,324,229	452,648	7,194,686	24,375	126,447

**日付:** 週単位のデータであれば週、日単位のデータであれば日付

**KPI:** 売上、販売数、コンバージョン数、アクティブユーザー数、アプリインストール数等

**メディアデータ:**

- メディア別のインプレッションと広告投資額
- MMMではインプレッションレベルのデータ(インプレッションとタイムスタンプ)は不要
- メディアの内訳のデータが必要(例:メディアの内訳(YouTubeのバンパー/インストリームスキップابل/マストヘッド)など)  
(詳細は次ページ参照)

**メディア以外のデータ:**

- 製品・サービス
- 価格・販促
- 競合の活動
- 製品・サービスの人気度
- その他(マクロ経済データなど)

## メディアの内訳の粒度

打ち手が明確な分析結果を提供するためには、MMMのインプットデータのメディアデータの粒度が重要である。

例えば、単にTVやデジタル全体のような大枠のROIを推定しても、打ち手は明確にならない。

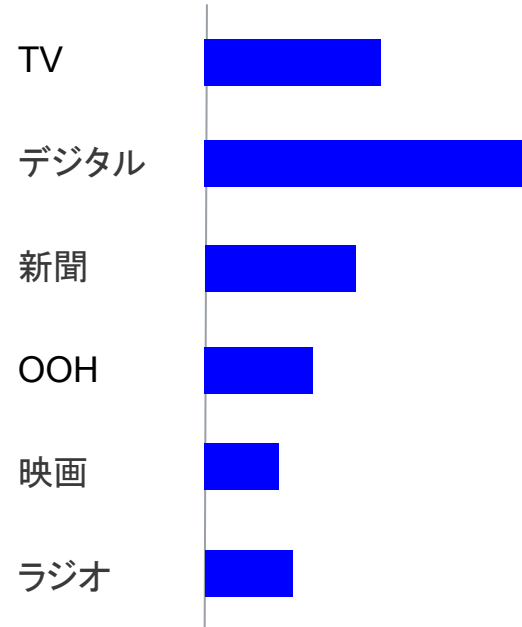
打ち手が明確な分析結果を提供するための理想的な粒度は、パフォーマンスを分析するための広告フォーマットレベル(例: YouTubeバンパー、マストヘッド等)または入札戦略レベル(例: 手動CPC、ターゲットCPA等)である。しかし、粒度を細かくすればするほど、データが不足する可能性がある。データ量に関しては次のページで議論する。

## MMMにおけるアウトプットの粒度

例示的

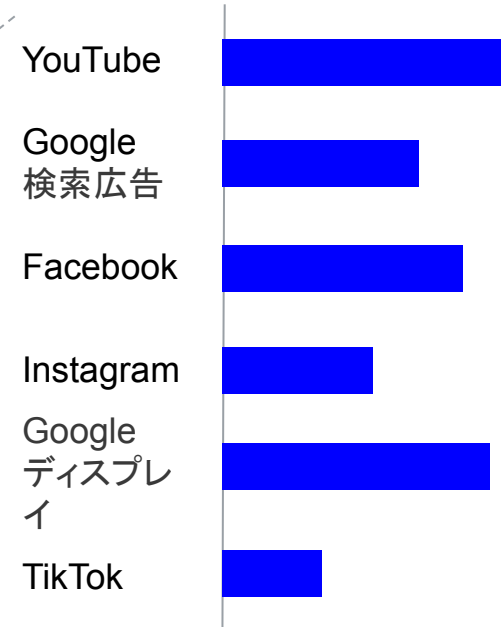
## 曖昧すぎる

## ROI (ROAS)の推定値



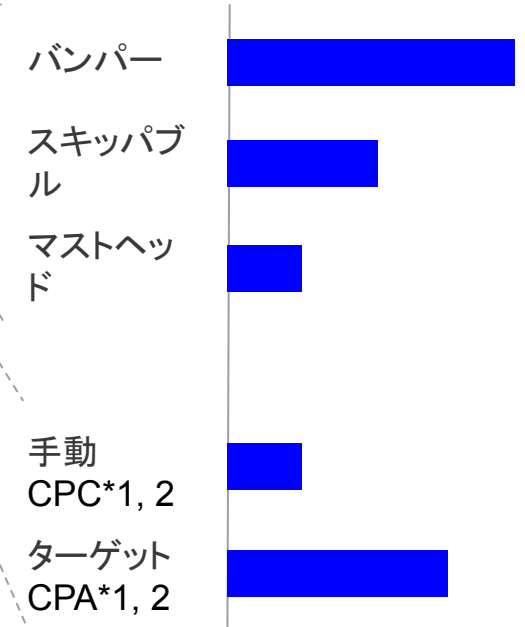
## 不十分

## ROI (ROAS)の推定値



## 理想的

## ROI (ROAS)の推定値



\*1: 自動化されたソリューション(例: GoogleのPerformance Max)は、広告主が広告の配信面をコントロールできないため、ソリューションそのもの(Performance Max)を計測の単位とすることが2023年8月現在一般的である

\*2: コンバージョンを獲得するためのパフォーマンスキャンペーン(例: Google検索広告、アプリキャンペーン等)については、さらなる細分化を推奨する場合があります。例えば、検索におけるワードマッチタイプブロードマッチ、フレーズマッチ、完全一致は、マッチタイプによって消費者の行動が異なる可能性があるため、考慮する価値がある。アプリキャンペーンの場合、デバイス別(iOS、Android、インターネット接続TVなど)の区分は、広告を配信するシステムが異なるため、考慮すべきかもしれない。

## MMMのデータ量(サンプルサイズ)に関する経験則 1/2

データの列数

例示的

date	revenue	google_search_clicks	google_search_spend	youtube_bumper_imp	youtube_bumper_spend	youtube_unskippable_imp	youtube_unskippable_spend	num_of_emails
2022-05-28	2,629,157	41,762	187,354	122,578,910	245,158	83,013,377	130,671	115,007
2022-05-29	5,455,074	61,772	70,359	250,073,569	500,147	206,689	58,723	7,884
2022-05-30	2,752,447	1,770,945	124,937	33,634,045	67,267	17,164,564	53,446	79,883
2022-05-31	4,495,993	94,222	46,635	214,849,357	429,698	56,422,041	134,518	44,655
2022-06-01	4,594,333	754,469	298,228	80,448,369	160,896	56,155,803	104,845	68,761
2022-06-02	3,198,586	55,192	9,900	32,198,560	64,397	11,901,778	54,564	93,130
2022-06-03	5,345,409	354,542	59,173	205,844,064	411,687	121,191,369	327,351	88,906
2022-06-04	4,634,572	105,363	511,908	70,692,283	141,384	13,144,918	36,897	55,226
2022-06-05	5,179,344	603,654	13,218	93,235,820	186,471	208,994,326	530,661	42,621
2022-06-06	4,605,407	72,608	164,127	115,014,135	230,028	13,623,608	51,037	30,084
2022-06-07	4,014,675	754,671	6,565	138,992,378	277,984	110,588,001	438,674	10,570
2022-06-08	5,862,088	69,290	245,447	12,007,451	24,015	3,994,038	30,242	57,745

MMMに必要なデータ量(サンプルサイズ)は状況によって異なるが、MMMモデルの1パラメータあたりの行数(日付の数)は、データ量が十分かどうかを検討するための1つの指標となる。モデル作成者がMMMを作成するために、仮に20個のパラメーター(推定したい回帰モデルの係数等)と100日または100週のデータを使用する場合、パラメーターあたりの行数は $100 \div 20 = 5$ となる。より厳密には、自由度がサンプルサイズを考慮するための指標である。上記の例では、自由度は $100 - 20 = 80$ で、パラメータあたりの自由度は $80 / 20 = 4$ となる。これは事実上、各パラメータを推定するために4つのサンプルを使用することを意味する。一般的に1つのパラメータを推定するのに4つのサンプルでは十分ではないかもしれない。

サンプルサイズが十分でない場合、モデル作成者はモデルのパラメータ数を減らして(例: メディアの変数の粒度を荒くする、一部変数を削除する)パラメータあたりのサンプルサイズを十分に確保するか、サンプルサイズを増やす(例: 日数や週数を増やす)ことを検討するか、データの粒度を国レベルから地理単位レベルやサブブランドレベルに変える(p.56-57)必要がある。

## MMMのデータ量(サンプルサイズ)に関する経験則 2/2


データ量の観点からもうひとつ考慮すべきは、メディアへの投資傾向である。

**メディアへの投資時期:** 広告投資については、クリスマスなど特定の季節に偏るメディアもある。そのようなメディアの場合、サンプル数が事実上小さいため、ROIを推定することが容易でない可能性がある。

**メディアへの合計投資額:** 合計の投資額もメディアデータ量の指標である。MMMでは、投資額が非常に小さいメディアの貢献度を検出することは難しい。投資額の小さいメディアのデータ統合が推奨される。(p.38)

**ターゲットオーディエンスの規模:** ターゲットオーディエンスが限定されたメディアの広告については、KPI(売上等)の増加も限定的であり、MMMでは検出できない可能性がある。ターゲットが狭いメディアは統合して「その他メディア」として扱う必要があるかもしれない。

## 時系列のメディアの広告費例



**OOH(オレンジ)と新聞広告(緑)**はメディア投資額の全体に占める割合が小さく、MMMでは効果を検出できない可能性あり

## 2.2. データクレンジング

---

## MMMにおける欠損値の扱い

データ選択の後、データのクレンジングを行う。

まず、回帰モデル(MMMも回帰モデルの一種である)において欠損値はエラーの原因となるため、モデル作成者は欠損値が存在するかどうかをチェックし、欠損値の原因を特定する必要があります。

一般的に、欠損値はモデリングを開始する前に補完する必要があります。次のページにて、一般的な方法を解説する。

## 欠損値の例

例示的

day	Display_cost	Search_imp	Search_cost	organic_imp	Conversions	hc
2021/1/30	149055	549400	35414	2459	28	
2021/1/31	145045	420468	52115	3035	17	
2021/2/1		360250	73056	4275	35	
2021/2/2		613114	66325	4041	35	
2021/2/3		564660	134438	2282	43	
2021/2/4		1003826	103184	3906	80	
2021/2/5		628812	87997	2258	25	
2021/2/6		966091	78677	2318	45	
2021/2/7		670042	68908	4285	50	
2021/2/8		563921	87062	2813	28	
2021/2/9		471092	90951	3179	56	
2021/2/10		690770	81403	2907	34	
2021/2/11		446356	106596	3355	34	
2021/2/12		545286	100453	3640	30	
2021/2/13		344858	98801	3890	36	
2021/2/14		653477	81645	2327	20	
2021/2/15		530004	117828	3722	47	
2021/2/16		787354	135520	2957	56	

欠損値



統計分析を行うライブラリーは欠損値を持つデータに対してエラーを返すため、欠損値は補完する必要があります

欠損値の存在理由  
(典型的な理由)実質的に  
ゼロ

キャンペーンやイベントがなかったため、データが存在しない

データの粒  
度不足

データの粒度が異なるため、データが存在しない  
(例: デジタルは日次データがあるが、TVには週次データのみ存在する場合)

人的ミスま  
たは  
系統的な  
エラー

システムティックまたは人的ミスによりデータが存在しない  
(例: データ保持期間の満了、システムクラッシュなど)



## 一般的な欠損値の取扱方法

32

欠損値のタイプ	方向性	典型的な欠損値の補完方法*1	説明	強み	弱み	
実質的にゼロ	ゼロで補完	単一代入法	平均値代入	欠損値に、平均値(または中央値)を代入(例: 欠損値に前年同時期の値を代入、または、前年同時期の値を需要比率で調整、等)	最も簡単	同じ値や値を単一の回帰モデルで割り当てることによる、独立変数の分散の過小評価
			回帰代入	回帰モデルを作成(従属変数: 欠損値を含む変数、独立変数: その他)し、予測値で欠損値で補完	比較的簡単	
データの粒度不足	補完方法を検討	回帰モデルによる補完	確率的回帰代入	上記に加えて、ランダムな誤差を加えた値を欠損値に代入	独立変数の分散の過小評価の回避	欠損値を持つ変数が複数ある場合の欠損値の補完順序への依存性
人的ミスまたは系統的なエラー			多重代入法 (multiple imputation)*2	サンプルから複数のデータセットを生成し、確率的回帰代入をそれぞれ実施。結果を統合		上記に加えて、比較的長い計算時間

**確率的回帰代入か、多重代入法が現実的な選択肢**

\*1: 高井啓二, 星野崇宏, 野間久史, 欠測データの統計科学(2016)を参照して作成。\*2: これらの方法が成功するかどうかは、欠損値補完の回帰モデルが真のモデルと同等か、あるいはその一部であるかに依存する。

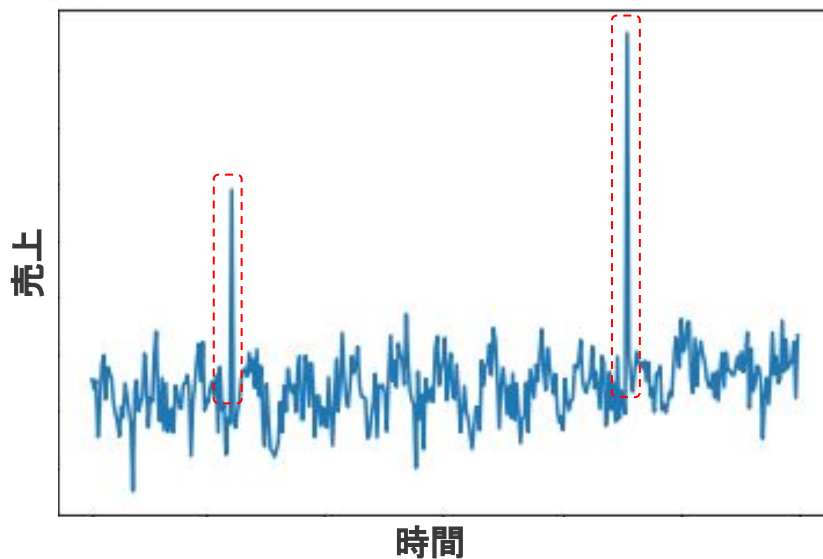
## MMMにおける外れ値の扱い

欠損値の補完後、外れ値のチェックを行う。

外れ値を検出する方法(例: Modified Stahel-Donoho)により、外れ値を発見することが可能である。

MMMにおいては、外れ値は追加すべきデータを考えるための検討材料になり得る。典型的な例として、ビジネスに影響を与える可能性のある休日やイベントの実施等がある。

## 時系列データにおける外れ値の例



MMMの各変数の外れ値は、MMMの作成者や利害関係者が事前に認識し、「モデルの検証」セクションでモデルの主観的なチェックをする際の材料とする

## モデル作成前に行うべき外れ値のチェック

正確性

データセットが手作業で作成されたものである場合、データ入力の過程でエラーが発生する可能性がある。その場合は修正する必要がある

予定された  
イベントの  
存在

主な予定イベント(マーケティング・イベント、新ブランド発表会、休日など)をデータに含めるかどうかの検討が必要

突発的な  
イベントの  
存在

突発的な出来事(例:災害、競合他社の値下げ等)がインプットデータに含まれるかどうかの検討が必要

予定された、または突発的な出来事を説明する変数がインプットデータに含まれていない場合は、追加する\*

\*: 変数の数の過多には注意する必要がある。

## MMMで典型的なデータ形式の変換

## カテゴリ型変数 → バイナリ変数(0か1の変数)

カテゴリ型変数はバイナリ変数に変換する必要がある

day	Event_type	day	Event_1	Event_2
2021/2/1	0	2021/2/1	0	0
2021/2/2	0	2021/2/2	0	0
2021/2/3	0	2021/2/3	0	0
2021/2/4	0	2021/2/4	0	0
2021/2/5	0	2021/2/5	0	0
2021/2/6	1	2021/2/6	1	0
2021/2/7	1	2021/2/7	1	0
2021/2/8	0	2021/2/8	0	0
2021/2/9	0	2021/2/9	0	0
2021/2/10	0	2021/2/10	0	0
2021/2/11	0	2021/2/11	0	0
2021/2/12	0	2021/2/12	0	0
2021/2/13	2	2021/2/13	0	1
2021/2/14	2	2021/2/14	0	1

⋮

⋮

マーケティング・イベント、休日、天候などのメディア以外の変数は、カテゴリ型変数(例:雨、晴、曇のようなカテゴリで表される変数)であることがある。それらは、バイナリ変数(0か1の変数、ダミー変数)に変換されるべきである。なお、カテゴリ型変数が順序変数(例:ランキング順位等)である場合は、バイナリ変数に変更すべきではない。

## 文字型変数 → バイナリ変数または数値型変数

文字型変数は、数値型及びバイナリ変数に変換する必要がある

day	Promotion	day	Discount_pct	Promo_grocery	Promo_fashion
2021/2/1	10% dicsount, grocery	2021/2/1	10	1	0
2021/2/2	10% dicsount, grocery	2021/2/2	10	1	0
2021/2/3	10% dicsount, grocery	2021/2/3	10	1	0
2021/2/4	10% dicsount, grocery	2021/2/4	10	1	0
2021/2/5	10% dicsount, grocery	2021/2/5	10	1	0
2021/2/6	10% dicsount, grocery	2021/2/6	10	1	0
2021/2/7	10% dicsount, grocery	2021/2/7	10	1	0
2021/2/8	5% discount, fashion	2021/2/8	5	0	1
2021/2/9	5% discount, fashion	2021/2/9	5	0	1
2021/2/10	5% discount, fashion	2021/2/10	5	0	1
2021/2/11	5% discount, fashion	2021/2/11	5	0	1
2021/2/12	5% discount, fashion	2021/2/12	5	0	1
2021/2/13	5% discount, fashion	2021/2/13	5	0	1
2021/2/14	5% discount, fashion	2021/2/14	5	0	1

⋮

⋮

販促のデータは文字型変数(テキスト形式)であることが多い。当該データは、割引額、アイテムカテゴリー、キャンペーンの形態(金額割引、パーセント割引、1個買うと1個無料等)、頻度に分けられるべきである。また、プロモーションデータは、プロモーションの種類、カテゴリーなどタイプ別に適切にモデル化されるべきである(後述)。

欠損値、外れ値をチェックした後、カテゴリ変数や文字変数のデータ形式の変更が必要になることがある。

MMMのメディア以外の変数については、カテゴリ型変数や文字型変数である場合がある。これらは、MMMでKPIへの影響を定量化するために、数値変数またはバイナリ変数変換(0か1の変数にする)する必要がある。

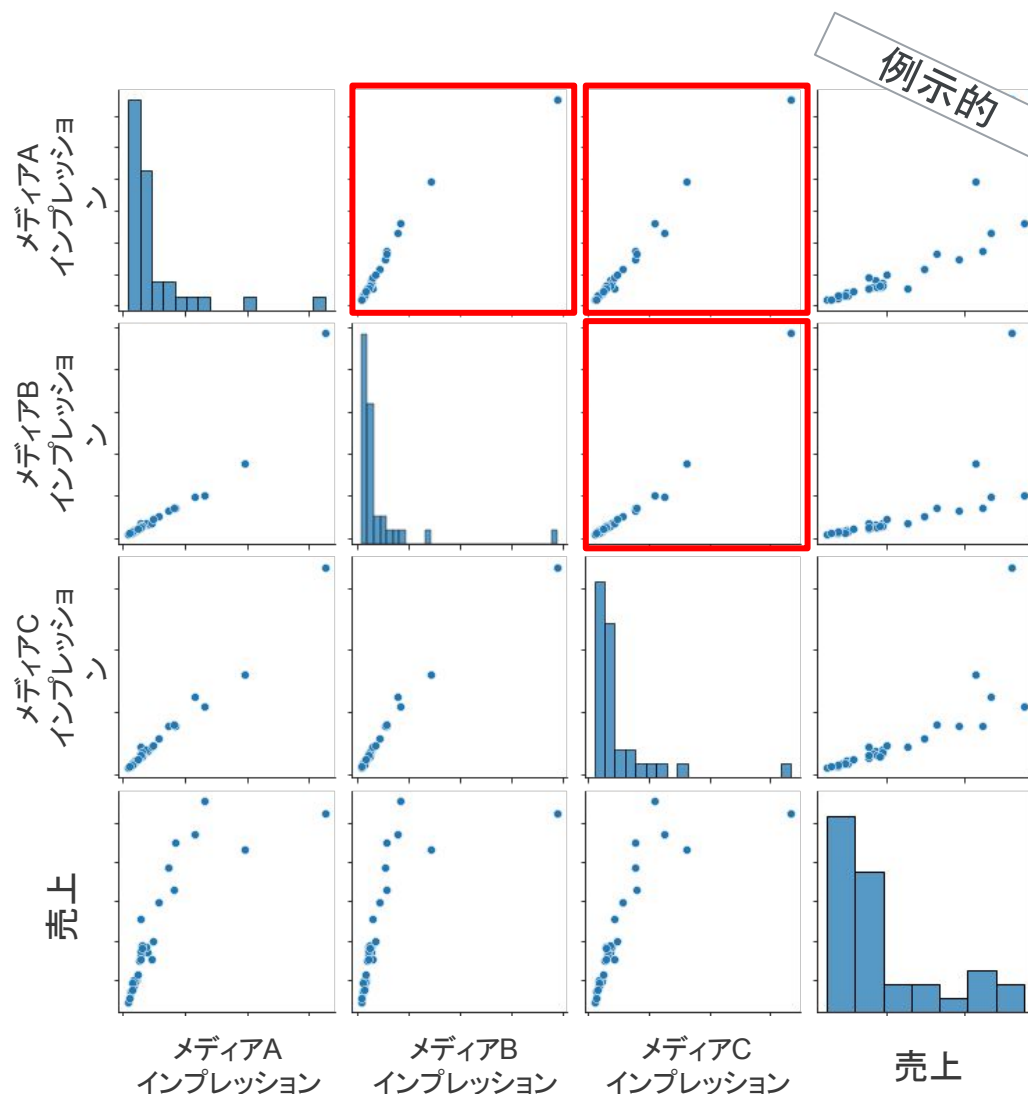
## 多重共線性のメカニズムの概要

35

右図は、多重共線性のメカニズムを説明するために、メディア変数(メディアA、B、C)間の散布図を示している。

メディアAとB、AとC、BとCの間には、それぞれ強い相関(例えば、相関係数 > 0.9)がある。言い換えると、メディアA、B、Cのインプレッションは同時期に増加し、同時期に減少する傾向にある。メディアA、B、Cの売上への寄与を分解するにあたり、これらのメディアは同時に増減しているため、回帰モデルは、媒体A、B、Cの寄与を個別に検出することができない。

当該事象を多重共線性という。次のページでは、多重共線性を検出する指標の1つを紹介する。



## 問題の整理

メディアA、B、Cの週間インプレッションの間に強い相関がある(例:相関係数 > 0.9)

言い換えれば、A、B、Cのメディアの広告のインプレッションは同時に増加、減少している

その結果、どのメディアが売上に貢献したかを特定することはできない

メディアBの係数が負であることは、モデルの数学的な不安定性を意味する

一般的に、週次/日次投資においてメディア間に強い相関(例えば相関係数 > 0.9)がある場合、モデルによるメディア貢献の推定は正確ではない可能性がある


## 多重共線性の紹介

MMMのもう1つの潜在的な落とし穴は、独立変数間の多重共線性であり、推定に誤差をもたらす要因の1つである。

右の例では、回帰モデルでは、独立変数が3つのメディアの広告配信量(インプレッション)、従属変数(KPI)は売上である。

しかし、推定結果は混乱を招くものとなっている。一般的にメディアへの広告投資は売上にプラスの影響を与えるが、メディアBの係数はマイナスである。このモデルは、メディアBへの投資が増えると売上が減ることを示唆している。メディア投資に関する我々の理解と矛盾している。この背景には、多重共線性と呼ばれる事象が生じている。

$$\text{簡易的な例*1,2: } Revenue = a_1 * imp_{\text{mediaA}} + a_2 * imp_{\text{mediaB}} + a_3 * imp_{\text{mediaC}} + b$$



### 回帰分析の結果

$$Revenue = 0.16 * imp_{\text{mediaA}} - 1.02 * imp_{\text{mediaB}} + 1.70 * imp_{\text{mediaC}} + 0.164$$

- メディアBの係数が負の値となっている
- 言い換えると、メディアBの広告費が増えるほど、売上は減少する

これは正しいのか？

\*1: 当該モデルは多重共線性の例を説明するための例であり、実例でこのような単純なモデルを使用することはない。

\*2: 当該データは政府統計の都道府県別産業労働者数と乗用車数のデータを用いて、仮のデータとして作ったものである。実際のメディアに関するデータではない。

## 多重共線性の検知方法の例(VIF)

多重共線性を検出するために、VIF (Variance Inflation Factor) を利用することができる。VIF は、1つの独立変数と他の独立変数との間の重相関係数から計算される。

一般にVIF = 10\*は、重相関係数の0.9または-0.9に相当する閾値である。

多重共線性の取り扱い方は、次のページに説明がある。いくつかの手法(例: リッジ回帰等の正則化(p.59))は、多重共線性によるKPI(例: 売上)の予測におけるオーバーフィッティング(サンプルデータにモデルが適合しすぎて、予測精度が下がること)の問題を回避できるが、MMMのような個別の変数の因果効果を推定する場合は、データ構造の変更が通常必要である。

## 回帰分析の例:

$$Revenue = a_1 * imp_{mediaA} + a_2 * imp_{mediaB} + a_3 * imp_{mediaC} + b$$

変数間の重回帰分析	重相関係数	VIF (Variance Inflation Factor)の式	VIFの値
$imp_{mediaA} = a_{11} * imp_{mediaB} + a_{12} * imp_{mediaC} + b_1$	$R_A$	$VIF_A = \frac{1}{1 - R_A^2}$	97.3
$imp_{mediaB} = a_{21} * imp_{mediaA} + a_{22} * imp_{mediaC} + b_2$	$R_B$	$VIF_B = \frac{1}{1 - R_B^2}$	20.5
$imp_{mediaC} = a_{31} * imp_{mediaA} + a_{32} * imp_{mediaB} + b_3$	$R_C$	$VIF_C = \frac{1}{1 - R_C^2}$	131.4



一般的に、VIFが10を超える変数は、「統合」、「削除」、または「分割」\*する必要がある(次のページを参照)

\*: O'Brien, Robert. (2007). A Caution Regarding Rules of Thumb for Variance Inflation Factors. Quality & Quantity. 41. 673-690. 10.1007/s11135-006-9018-6

## 多重共線性の典型的な対応方法

38

方法	説明	概念図	強み	弱み
統合	多重共線性のある変数を合計する	<p>強い相関</p>	<ul style="list-style-type: none"> <li>• 簡単</li> <li>• 「削除」と比較するとデータの損失が軽微</li> </ul>	<ul style="list-style-type: none"> <li>• 組み合わせが難しい変数がある(例: 気温+メディアインプレッション)</li> <li>• データの粒度が荒くなる</li> </ul>
削除	多重共線性のある変数を取り除く	<p>強い相関</p>	<ul style="list-style-type: none"> <li>• 簡単</li> </ul>	<ul style="list-style-type: none"> <li>• データの損失</li> <li>• 一部の変数の喪失</li> <li>• 売上貢献の配分の推定誤差が増加</li> </ul>
分割	セグメントごとにモデルを分ける(例: 観客、地域等)	<p>強い相関</p>	<ul style="list-style-type: none"> <li>• データの損失が無い</li> </ul>	<ul style="list-style-type: none"> <li>• モデルの複雑さ</li> <li>• セグメントレベルでのデータ入手可能性(例: 視聴者セグメントごとのテレビの広告費)</li> </ul>

➡ 「分割」が最良の選択肢ではあるが、実現可能性はデータの有無による状況により「介入」も可能 ([p.127](#))

## データの正規化

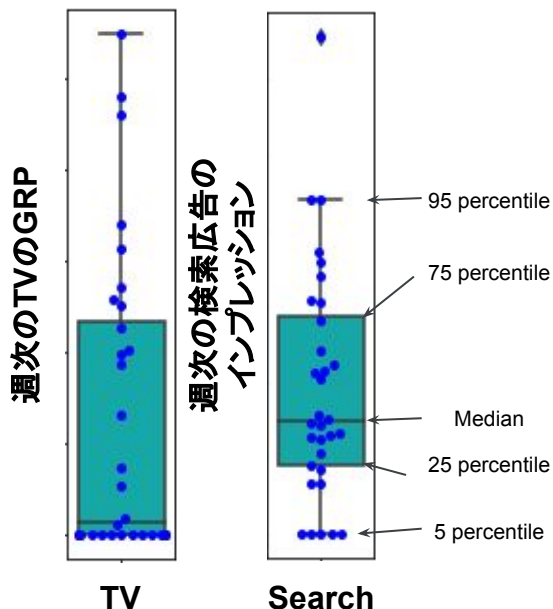
39

次はデータの正規化である。

データの正規化は、異なるスケールを持つ複数の変数を考慮するために必要である。MMMでは大半の変数が正の値をとるので(例:メディアのインプレッションは正の値)、正規化後のMMMで変数を正の値に保つには、平均値による正規化が有力な選択肢である。

さらなるデータ変換(対数、アドストック等)については、次のセクションで説明する。

## なぜ、データの正規化が必要か？



- 尺度が異なる変数は比較できない
- 単位が大きい変数がモデルのパラメータの推定に悪影響を及ぼす可能性がある

## 典型的な正規化の方法


方法

Min-max


平均

標準化


$$x_{scaled} = \frac{x - \min(x)}{\max(x) - \min(x)}$$



$$x_{scaled} = \frac{x}{\text{mean}(x)}$$



$$x_{scaled} = \frac{x - \text{mean}(x)}{\text{std}(x)}$$



正規化後

最小値=0, 最大値=1

平均= 1

平均 = 0, 標準偏差= 1

主な  
利用場面

変数の変域が明確である場合

MMM (売上やメディアの投資は0以上の値をとる)

データの分布を正規分布に近づけたい場合



## 2.3. モデル構造の作成

---

MMMの基本的なモデル構造を中心に説明する。紹介しているモデル構造は単純化しており、実際の場面では適さない場合もある。モデル構造の議論については CHAPTER3を参照。

## MMMの構造

このセクションでは、基本的なMMMの主要要素を説明する。

MMMは回帰分析の一種であるが、特有の要素がある。モデルは、A) 応答曲線変換、B) アドストック変換、C) トレンドと季節性、その他の変数から構成される。

多層モデルのような複雑な構造についてはCHAPTER 3で説明する。このセクションでは、線形回帰モデルと比較したMMMモデルのユニークな要素に焦点を当てる。

## MMMの加法モデルの例\*1

$$Revenue_t = b + \sum_m \beta_m * Hill \left( \text{Adstock}(x_{t,m}, \dots, x_{t-l,m}; L, w_m(l; \alpha_m, \theta_m)), K_m, S_m \right) +$$

$$\text{trend}_t + \text{seas}_t + \sum_c \gamma_c d_{t,c} + \epsilon_t$$

切片 (バイアス)

全てのメディアについて右記の変換を行い、合計する

(A) 応答曲線変換

(B) アドストック変換

(C) トレンド

(C) 季節性

その他の変数\*2

ランダムノイズ

\*1: 当該モデルはMMMの基本的な機能を説明するためのモデルであり、実例ではより複雑なモデルを利用する必要があることがある。詳しくはCHAPTER 3を参照。

\*2: 本ガイドブックでは詳述していないが、メディア以外の変数も適切にモデル化する必要がある。例えば、値引きに対する売上の反応は、値引き率、品目、タイミング等によって異なり、その反応は線形ではないかもしれない。

## 加法モデルと乗法モデルの違い

MMMの各要素の説明の前に、加法構造と乗法構造の違いについて説明する。

加法モデルは、各メディアと他の変数の効果を分離する。一方、乗法モデルは、乗法的な構造により、各メディアと他の変数の間に依存性があることを前提とする。

乗法モデルは式の両辺の対数をとることで加法モデルに変換できるが、モデル結果の解釈は異なる。次の2ページにおいて、その意味を説明する。

加法モデル

乗法モデル

### 加法モデルと乗法モデルの比較

(簡単のため、応答曲線とアドストックは無視した表記となっている \*1)

$$Revenue = \underbrace{b}_{\text{切片}} + \underbrace{w_{TV} * x_{TV} + w_{SEM} * x_{SEM} + \dots}_{\text{メディアの効果}} + \underbrace{w_{prom} * x_{prom} + \dots}_{\text{他の変数の効果}}$$

$$Revenue = \underbrace{b}_{\text{切片}} * \underbrace{x_{TV}^{w_{TV}} * x_{SEM}^{w_{SEM}} * \dots}_{\text{メディアの効果}} * \underbrace{x_{prom}^{w_{prom}} * \dots}_{\text{他の変数の効果}}$$

$$\Leftrightarrow \log Revenue = \log b + w_{TV} \log x_{TV} + w_{SEM} \log x_{SEM} + \dots + w_{prom} \log x_{prom} + \dots$$

➡ 乗法モデルは、売上と各変数の対数部分 (log)を除いて、加法モデルと同様の構造である

\*1: 当該モデルはMMMの基本的な機能を説明するためのモデルであり、実例ではより複雑なモデルを利用する必要があることがある。詳しくはCHAPTER 3を参照。

## 乗法モデルと加法モデルの解釈の違い

右の例は、加算モデルと乗算モデルの解釈の違いを示している。

例えば、広告インプレッションが100万回から200万回に増加した場合、加法モデルでは媒体ごとに売上の増分が計算できる。

一方、乗法モデルでは各媒体の効果推定は不可分である。メディア間の依存関係により、各メディアによる売上の増分は他のメディアに依存することになる。複数のメディアの相乗効果(シナジー)がある場合には有効だが、解釈の容易さには課題がある。

## 加法モデル

## 乗法モデル

売上貢献

売上貢献

例: テレビ予算と検索広告の予算をそれぞれ2倍にする  
(100万(1M)インプレッションから200万(2M)  
インプレッションに増加させた場合)\*1,2

$$Revenue = \dots + 0.7 * x_{TV} + 0.8 * x_{SEM} + \dots$$

Before	1M x 0.7 = 0.7M	1M x 0.8 = 0.8M
After	2M x 0.7 = 1.4M	2M x 0.8 = 1.6M
売上の増分	1.4M - 0.7M = 0.7M	1.6M - 0.8M = 0.8M

加法モデルでは、各メディアの売上貢献が識別可能である。

$$Revenue = \dots * x_{TV}^{0.7} * x_{SEM}^{0.8} * \dots$$

Before	(他の要因) * (1M <sup>0.7</sup> ) * (1M <sup>0.8</sup> )
After	(他の要因) * (2M <sup>0.7</sup> ) * (2M <sup>0.8</sup> )
売上の増分	(他の要因) * (2M <sup>0.7</sup> ) * (2M <sup>0.8</sup> ) - (他の要因) * (1M <sup>0.7</sup> ) * (1M <sup>0.8</sup> )

乗法モデルでは、各メディアの貢献は他の要因に依存する(相乗効果(シナジー))。

\*1: 当該モデルはMMMの基本的な機能を説明するためのモデルであり、実例ではより複雑なモデルを利用する必要があることがある。詳しくはCHAPTER 3を参照。\*2: デジタル広告では例えばインプレッションを倍にした時に、CPMが増加し予算が2倍以上となることがある。本来は予算に応じたCPMの変化も考慮したモデルを作成すべきであるが、サンプル数やパラメータの数の兼ね合いから通常はCPMを一定と仮定する。



## (A) 応答曲線変換の紹介

応答曲線変換は、MMMにおいてメディア投資の飽和を表現するための重要な要素の一つである。

通常の線形回帰モデルは、メディアへの広告投資の増加によって無限の売上成長が可能であると仮定している。しかし、現実にはメディア上のユーザー数、インプレッション数、広告の掲載頻度に限界があるため、広告投資の潜在的な効果は限定的である。このような状況を表現するためには、応答曲線変換が必要となる。

加法  
モデル\*

$$Revenue = b + w_{TV} * x_{TV} + w_{SEM} * x_{SEM} + \dots + w_{prom} * x_{prom} + \dots$$



\*乗法モデルの場合、メディアの売上増分は他のメディアや要因に依存する。各メディアのレスポンス曲線には売上の逓減効果が適用される。

## 典型的な応答曲線

45


典型的な応答曲線の形状は、凹曲線またはS字曲線である。

凹曲線の場合、メディア投資の飽和を表すために指数関数が使われる。

S字曲線の場合は、ヒル関数(hill function)が使われ、広告投資の初期段階における緩やかな上昇を示す。

次のページでは、ヒル関数がさまざまな形状をモデル化するための柔軟な特徴を持っていることを示す。

## 凹曲線

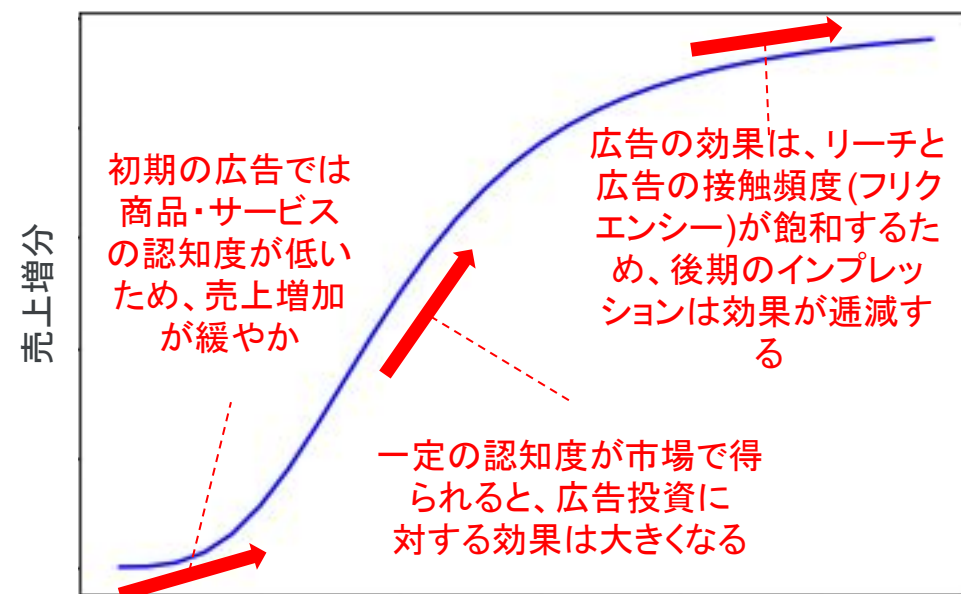


例:

$$y = \beta_{\text{media}} * x_{\text{media}}^{r_{\text{media}}}$$

$(\beta_{\text{media}} > 0, r_{\text{media}} < 1)$

## S字曲線



例:

$$y = \beta_{\text{media}} * \frac{1}{1 + \left(\frac{x_{\text{media}}}{K_{\text{media}}}\right)^{-S_{\text{media}}}}$$

係数  $(\beta_{\text{media}}, K_{\text{media}}, S_{\text{media}} > 0)$

ヒル関数  
(hill  
function)

## ヒル関数(hill function)の特徴

46

典型的なヒル関数には2つのパラメータがある。

**半飽和度(half saturation) K:**  
応答曲線が上限(下記「収束」を参照)の半分に至る広告インプレッション数を表す

**勾配(Slope) S:** 応答曲線の増加の急激さを表す

上記の2つのパラメータにより、ヒル関数の下記の2つの特徴が理解できる。

**1に収束:** 広告のインプレッション(x)を無限大にする( $x \rightarrow \infty$ )にすると、ヒル関数は上限1に収束する


**半飽和:** 広告インプレッション数が半飽和度Kに等しいとき、ヒル関数は1/2に等しくなる

$$\text{Hill}(x_{\text{media}}; K_{\text{media}}, S_{\text{media}}) = \frac{1}{1 + \left(\frac{x_{\text{media}}}{K_{\text{media}}}\right)^{-S_{\text{media}}}}$$

$(x_{\text{media}}, \beta_{\text{media}}, K_{\text{media}}, S_{\text{media}} > 0)$

$$\lim_{x_{\text{media}} \rightarrow \infty} \text{Hill}(x_{\text{media}}; K_{\text{media}}, S_{\text{media}}) = 1$$

$$\text{Hill}(x_{\text{media}} = K_{\text{media}}; K_{\text{media}}, S_{\text{media}}) = \frac{1}{1 + 1^{-S_{\text{media}}}} = \frac{1}{2}$$



勾配Sが大きいと、ヒル関数の増加も急激となる  
半飽和度Kが大きいと、ヒル関数が緩慢に上限に近づく

\*: 実用的には、モデル作成者は極端に急な応答曲線为了避免のために、パラメータ S に制約を導入することがある。これはSが大きすぎると応答曲線が急激となり、最適化(p.80)のアルゴリズムがうまく動作しないことがあるからである。

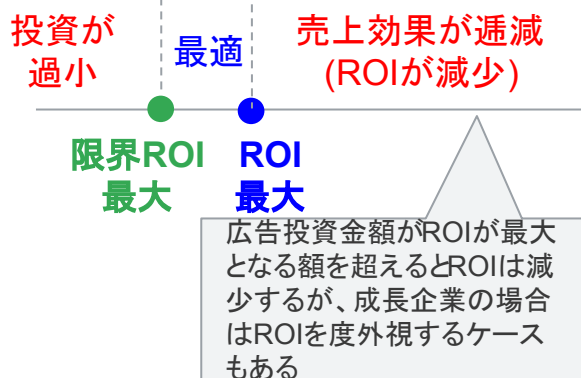



## 応答曲線に基づく主要な指標の定義

47

応答曲線に基づいて、指標を定義することができる。横軸はメディアへの広告投資額(広告インプレッションに平均CPMをかけて算出)、縦軸はメディア投資による売上増分であるため、2つのROI(Return On Investment)指標が定義される。なお、当該ROIは広告投資であることを強調するため、ROAS(Return On Advertising Spend)とも呼ばれる。

**限界ROI (Marginal ROI):**「次の1円の広告投資に対する売上増分」を意味する。数学的には、応答曲線の接線の傾きに対応する。

**ROI(ROAS):**メディアへの広告投資に対する売上増分の比率。数学的には、原点と応答曲線上の点を結んだ直線の傾きに対応する。



### 限界ROI (Marginal ROI)

応答曲線の接線の傾き

"メディアへのさらなる広告投資による売上増加のスピード"  
と考えることができる。

### ROI (ROAS)

原点と応答曲線上の点を  
結んだ直線の傾き

売上の増分  
-----  
メディアへの広告投資額

\*1: ROIを計算するために、応答曲線を推定した後、インプレッションあたりの平均コスト(CPM)を使用して、広告のインプレッションから広告の投資額に横軸の単位を変更する必要がある。



## (B) アドストックの紹介


MMMのもう一つの重要な要素は、アドストックである。アドストックとは、メディアへの広告投資における減衰効果を表す変数変換である。

例えば、YouTubeの広告が今日ユーザーに配信された場合、広告のフォーマットやクリエイティブによっては、その効果は数日～数週間続くかもしれない。一般的に動画フォーマットの広告は、静止画像(減衰率が高い)に比べて効果が長い可能性がある。

上記の仮定に基づき、メディアの変数(広告のインプレッション)に対してアドストック変換を行う。

各週のメディアのインプレッションに対する減衰効果  
(緑=各週のメディアのインプレッション、赤=残存効果)


Adstock of media spend in 2022-01-01  
Decay rate is 0.5 (Geometric decay)



MMMは、各メディアのインプレッションには減衰効果があると仮定している

上記の効果を合計したもの  
(アドストック)

Total adstock as of 2022-01-01



アドストックとは、蓄積された効果のことである。MMMでは、メディアのインプレッションそのものではなく、アドストックをインプット変数として使用する

## 典型的なアドストック変換 1/3

## 幾何的アドストック (Geometric adstock)

例






$$\text{adstock}_{t,media} = x_{t,media} + \lambda_{media} * \text{adstock}_{t-1,media}$$

メディアの  
インプレッション

減衰  
パラメータ

各時点でのメディア  
投資と減衰効果

アドストック

 $\lambda = 0.2$ 各時点でのメ  
ディア投資の影  
響が大きい各時点のメディア  
投資の影響が大きい $\lambda = 0.5$ 減衰率(1- $\lambda$ )  
が中程度の  
場合 $\lambda = 0.8$ 減衰率(1- $\lambda$ )  
が低い場合残存効果の  
影響が大きい残存効果の影響の方  
が大きい

グラフの例

## 典型的なアドストック変換 2/3

50

例\*

## ワイブル分布アドストック (Weibull PDF adstock)\*

L: 減衰期間パラメータ, l: 広告出稿時点tと効果計測時点の時間差

$$\text{adstock}_{t,media} = \sum_{l=0}^L \exp\left(-\frac{l}{\lambda}\right)^k * x_{t-l,media}$$

Lambda: 関数の形を調整するパラメータ  
k: 減衰パラメータ  
x: 広告インプレッション

$$\lambda = \frac{l}{(-\ln(0.001))^{\frac{1}{k}}}$$


## 減衰期間が長期である場合 (L=10)

## 減衰期間が短期である場合 (L=3)

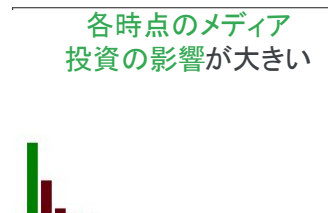
グラフの例

減衰率  
が大きい  
場合


k = 1

各時点でのメ  
ディア投資の影  
響が大きい

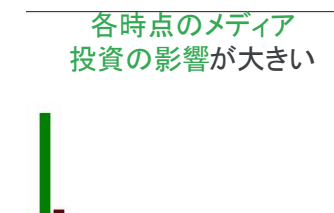
アドストック

各時点のメディア  
投資の影響が大きい



k = 1

各時点でのメ  
ディア投資の影  
響が大きい


アドストック

各時点のメディア  
投資の影響が大きい減衰率  
が中程度の  
場合


k = 3



k = 3

減衰率  
が低い場合

k = 5

残存効果の  
影響が大きい残存効果の影響の方  
が大きい

k = 5

残存効果の  
影響が大きい残存効果の影響の方  
が大きい\*: <https://github.com/annalectnl/weibull-adstock>. PDF: Probability Distribution Function

## 典型的なアドストック変換 3/3

例\*1

## キャリーオーバー効果\*1

w: 減衰のウェイト

x: メディアのインプレッション

Theta: 減衰の遅延パラメータ

$$\text{adstock}_{t,media} = \frac{\sum_{l=0}^{L-1} w_{media}(l) * x_{t-l,media}}{\sum_{l=0}^{L-1} w_{media}(l)}$$

L: 減衰期間, l: 広告出稿時点と効果計測時点の時間差


$$w_{media}(l; \alpha_m, \theta_m) = \alpha_m^{(l-\theta_m)^2}$$

Alpha: 減衰パラメータ



## 減衰効果の遅延がない場合 (theta = 0)

## 減衰効果の遅延がある場合 (theta = 2)\*2









グラフの例

減衰率  
が大きい  
場合 $\alpha = 0.2$ 各時点でのメ  
ディア投資の影  
響が大きい

アドストック

各時点のメディア  
投資の影響が大きい $\alpha = 0.2$ 残存効果の  
影響が大きい

アドストック

残存効果の影響の方  
が大きい $\alpha = 0.5$ 減衰率  
が中程度の  
場合 $\alpha = 0.5$  $\alpha = 0.8$ 減衰率  
が低い場合残存効果の  
影響が大きい残存効果の影響の方  
が大きい $\alpha = 0.8$ 残存効果の  
影響が大きい残存効果の影響の方  
が大きい

\*2: 広告主が将来の売上を目的としたキャンペーンを実施した場合、上記のパターンが発生する可能性がある(例えば、クリスマスの売上を増加させるために、12月上旬に広告を配信する)

## 変数変換の順序

前ページまで応答曲線変換とアドストック変換を紹介した。変換に関しては、順序の選択肢が2つある。

1) 応答曲線変換の後にアドストック変換を行う方法と、2) アドストック変換の後に応答曲線変換を行う方法である。

Yuxue\*1らは右のように選択する際の経験則を示している。

応答曲線  
変換の  
後に  
アドストック  
変換

アドストック  
変換  
の後に  
応答曲線  
変換

## 例と利用場面

$$\mathbf{x}_{\text{media,Hill}} = \begin{pmatrix} \text{Hill}(x_{t,\text{media}}; K_{\text{media}}, S_{\text{media}}) \\ \vdots \\ \text{Hill}(x_{t-l,\text{media}}; K_{\text{media}}, S_{\text{media}}) \end{pmatrix}$$

まず、メディアへの広告投資(インプレッション)を応答曲線によって売上の増分効果に変換する

$$y = \beta_{\text{media}} * \text{Adstock}(\mathbf{x}_{\text{media,Hill}}, L, w_{\text{media}}(l; \alpha_{\text{media}}, \theta_{\text{media}}))$$

次に、アドストックを計算する



「メディアの広告投資が、ある特定の時期に集中している場合」\*

まず、メディアへの広告投資(インプレッション)をアドストックに変換する

$$y = \beta_{\text{media}} * \text{Hill}(\text{Adstock}(x_{t,\text{media}}, \dots, x_{t-l,\text{media}}; L, w_{\text{media}}(l; \alpha_{\text{media}}, \theta_{\text{media}})), K_{\text{media}}, S_{\text{media}})$$

次に、アドストックを応答曲線によって売上の増分効果に変換する




「各時期のメディアの広告投資が、全体の合計投資と比較して相対的に小さい場合(広告投資が各時期に分散している場合)、...アドストック変換の後に応答曲線変換を適用する方が望ましい」\*。

\*: Google (2017), Bayesian Methods for Media Mix Modeling with Carryover and Shape Effects

## (C) トレンドと季節性の概要

トレンドと季節性は時系列モデルにおける概念である。ARIMAのような時系列モデルでは、従属変数はトレンド、季節性、残差等に分解される。モデルの構成によっては複数のサイクル(年単位の季節性、月単位の季節性等)も考慮できる。

MMMでは、これらの要素も適切に記述する必要がある。次ページにて、主なオプションを紹介する。



\*1: このデータは、東京卸売市場におけるタマネギの入荷量を用いたサンプルデータである。実際の売上のデータではない。

\*2: モデルの設計によっては休日による売上増加効果、異なるサイクルによる周期性週次、月次、四半期毎のサイクルも必要に応じて分解する。

# トレンドと季節性の表現方法

54

2つのオプションがある。

**観測変数を使用する:** 観測可能なデータを利用して、トレンドと季節性による売上の変動を表現するモデルを作成することができる。マクロ経済データや業界レベルのレポート(業界団体が発表する商品カテゴリーの流通)等の市場データを用いて、市場の需要変動を数学的に表現することが可能である。

トレンド

**観察されない変数の記述:** 上記のようなデータが入手できず、トレンドと季節性を表現することが困難である場合、トレンドや季節性について特定の関数を用いて仮定する。また、Bayesian Structural Time Series (BSTS)のような、より柔軟な構造を使用することも可能である。<sup>\*1</sup>

季節性

## 観測可能なデータ を利用する

マクロ経済要因(GDP成長率、賃金率)や、業界団体が発表する製品カテゴリーの流通量など、市場全体の需要に関連するデータを用いて、全体の需要変動を数学的に表現する。

夏休み、クリスマス、新年、新学期など、急上昇/急降下や周期的な変化を捉えるための変数を用いて、売上の季節変動を数学的に表現する。

## トレンドと季節性の表現方法

### 潜在変数を用いて表現する

関数の例


関数の形の例

$$\text{trend}_t = \frac{C}{1 + e^{-k(t-m)}}$$

k: 成長率

m: オフセット  
パラメータ


キャパシティ



季節性の複雑度(dが大きい程、複雑な曲線を表す) スケールパラメータ (値が大きい程大きい変動を表現できる)

$$\text{seas}_t = \sum_{k=1}^d \left( \gamma_{1,k} \sin \frac{2\pi kt}{s} + \gamma_{2,k} \cos \frac{2\pi kt}{s} \right)$$

季節性を表現する周期 (年の周期性を週次のデータで表現するなら s = 52 (週))



\*1: Google (2015), Inferring causal impact using Bayesian structural time-series models

## MMMのモデルの基本構造についてのまとめ

55

本セクションでは、MMMの具体的な要素を紹介した。

モデル作成者は、データの入手可能性やデータ量に応じて、応答曲線・アドストック変換の順序、トレンド・季節性の表現方法を検討する必要がある。さらに高度なモデルについては次章で説明する。

なお、次ページ以降で、変化系のモデル(地理的な単位やブランド単位で作成するモデル)について紹介する。

## MMMの加法モデルの例\*1

$$Revenue_t = b + \sum_m \beta_m * Hill \left( \text{Adstock}(x_{t,m}, \dots, x_{t-l,m}; L, w_m(l; \alpha_m, \theta_m)), K_m, S_m \right) +$$

$trend_t + seas_t + \sum_c \gamma_c d_{t,c} + \epsilon_t$

切片 (バイアス) 全てのメディアについて右記の変換を行い、合計する

(A) 応答曲線変換 (B) アドストック変換

(C) トレンド (C) 季節性 その他の変数\*2 ランダムノイズ

\*1: 当該モデルはMMMの基本的な機能を説明するためのモデルであり、実例ではより複雑なモデルを利用する必要があることがある。詳しくはCHAPTER 3を参照。

\*2: 本ガイドブックでは詳述していないが、その他の変数も適切にモデル化する必要がある。例えば、値引きに対する売上の反応は、値引き率、品目、タイミング等によって異なり、その反応は線形ではないかもしれない。



## 変化系モデル(地理的単位のモデル、geo level model)

56

## 地理的単位のモデル (geo level model)

利用検討  
場面

- データの入手可能期間が比較的短い (例: 2年間の週次データのみ = 各変数について 104データポイント)
- 一方、地理的な内訳 (地域・都道府県・郵便番号単位等でのメディアへの広告投資、販促のデータなど) は入手可能

想定  
される  
モデル

地理的単位 (都道府県、郵便番号など) レベルでMMMモデルを作成し、メディアへの広告投資、傾向、季節性、その他の変数について地理的単位でパラメータを設定する\*1。

$$\text{Revenue}_{t,g} = b_g + \sum_m \beta_{m,g} * \text{Hill}(\text{Adstock}(x_{t,m,g}, \dots, x_{t-l,m,g}; L, w_m(l; \alpha_m, \theta_m)), K_m, S_m) + \text{trend}_{t,g} + \text{seas}_{t,g} + \sum_c \gamma_{c,g} d_{t,c,g} + \epsilon_{t,g}$$

National Model

1 Market X 104 Weeks

104  
Observations

DMA Model

208 Market X 104 Weeks

21,840  
Observations

例示的\*3

結果的に、応答曲線を推定するためのデータ量を増やすことができ (地理的単位数倍に増加する)、推定の精度が高まる可能性がある。ただし、状況により地域ごとに異なる応答曲線とアドストック曲線を持つ必要があるかもしれない。例えば、都市部と地方では消費者行動が異なるため、応答曲線とアドストック曲線を地域別に推定する必要があるかもしれない。

\*1: Google (2017), Geo-level Bayesian Hierarchical Media Mix Modeling, \*2 本ガイドブックには詳細が記載されていないが、その他の変数も適切にモデル化する必要がある。例えば、値引きに対する収益の反応は、値引きのパーセンテージ、アイテム、タイミングによって異なり、その反応は線形ではないかもしれない\*3: Designated Market Areaは米国内のエリア区分の例。

## 変化系モデル(ブランドまたはターゲット顧客単位のモデル)

57

## ブランドまたはターゲット顧客単位のモデル (brand or audience level model)

利用検討  
場面

- メディアへの広告投資の効果や効率、ブランドやターゲット顧客によって大きく異なる可能性がある
- 加えて、ブランドやターゲット顧客レベルの広告投資のデータ、販促等のデータが利用できる

想定  
される  
モデル

オーディエンスまたはブランド単位で MMMモデルを作成し、メディアへの広告投資、傾向、季節性、その他の変数についてブランド単位またはターゲット顧客単位でパラメータを設定する \*1。

$$\text{Revenue}_{t,b} = \tau_b + \sum_m \beta_{m,b} * \text{Hill}(\text{Adstock}(x_{t,m,b}, \dots, x_{t-l,m,b}; L, w_m(l; \alpha_m, \theta_m)), K_m, S_m) \\ + \text{trend}_{t,b} + \text{seas}_{t,b} + \sum_c \gamma_{c,b} d_{t,c,b} + \epsilon_{t,b}$$

また、地理的単位のモデルと組み合わせることも可能である。

$$\text{Revenue}_{t,g,b} = \tau_{g,b} + \sum_m \beta_{m,g,b} * \text{Hill}(\text{Adstock}(x_{t,m,g,b}, \dots, x_{t-l,m,g,b}; L, w_m(l; \alpha_m, \theta_m)), K_m, S_m) \\ + \text{trend}_{t,g,b} + \text{seas}_{t,g,b} + \sum_c \gamma_{c,g,b} d_{t,c,g,b} + \epsilon_{t,g,b}$$

\*1: Google (2017), Geo-level Bayesian Hierarchical Media Mix Modeling

\*2 本ガイドブックには詳細が記載されていないが、その他の変数も適切にモデル化する必要がある。例えば、値引きに対する収益の反応は、値引きのパーセンテージ、アイテム、タイミングによって異なり、その反応は線形ではないかもしれない。

## 2.4. パラメータの推定

---

# パラメータの推定法の概要

59

MMMのパラメータ推定では、通常3つのオプションのうちの1つが使用される。

**最小二乗法:** 通常の線形回帰分析と同様に、データと予測値の誤差が最小となるようなパラメータを推定する。

**正則化(regularisation):** KPI(売上)の予測精度を高めるため、ペナルティ項を活用する。このオプションは各メディアの貢献の推定より、KPIの予測精度をより重視した方法である。


**ベイズ推定:** このオプションは各メディアによる売上増分の推定に関する洞察を得ることを重視し、パラメータの信頼区間や事後分布のような詳細情報も推定できる。当ガイドブックでは、このような理由から当該方法をメインとして解説をする。

## MMMでパラメータを推定する主なオプション(網羅的ではない)

最小二乗法  
(Ordinary Least Squares)

$$y \sim f(x, w)$$

$$L = \min_w |y - f(x, w)|^2$$




データとモデルの間の「距離」を最小化することによってパラメータを推定する。モデルの残差分布を正規分布と仮定することで、パラメータの点推定に加えて、パラメータの信頼区間を計算することができる。

正則化  
(Regularisation)

$$y \sim f(x, w)$$

$$L = \min_w (|y - f(x, w)|^2 + \lambda |w|^2)$$




データとモデルの間の「距離」を最小化することで、パラメータを推定する。データへのオーバーフィッティングを避ける(KPIの予測精度を高める)ため、クロスバリデーション(交差検証法)を用いてペナルティパラメータを最適化する。リッジ回帰、ラッソ回帰等が利用される。一般的に、結果はパラメータの点推定のみを含み、区間の情報はなく\*1。

ベイズ推定

$$y \sim f(x, w)$$

$$p(w|y, x) \sim p(y|x, w)p(w)$$

$$p(w) \sim \text{prior}$$



MCMC等、ベイズの定理を用いたサンプリングによってパラメータを推定する。サンプリングには事前分布の仮定が必要である。結果は、パラメータの事後分布と信用区間推定を含む。この方法は、各メディアや変数について、仮定(事前分布)と結果(事後分布)を比較できる意味で、各メディアの詳細な分析ができる柔軟性がある。

\*1: 正則化であっても、ブートストラップサンプリング等の信頼区間を追加する方法があるが、計算量が多くなる可能性がある。

## MMMにおけるデータとパラメータの表記

ベイズ推定では、MMMのパラメータを推定するためにベイズの定理が利用される。

ベイズの定理は、尤度、事前分布、証拠、事後分布からなり、この定理を利用することで、データから各パラメータの事後分布を推定することができる。

次ページ以降、ベイズの定理を用いた事後分布の推定の方法を紹介する。

MMMの加法モデルの例\*1:

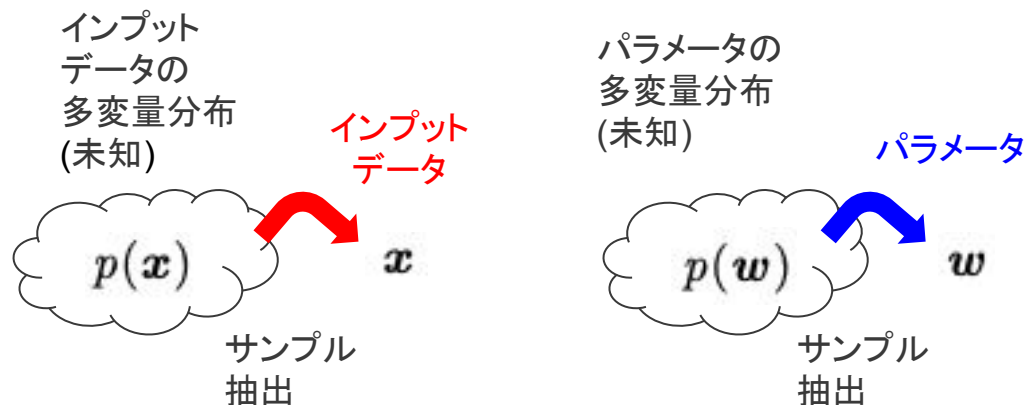
$$\text{Revenue}_t = b + \sum_m \beta_m * \text{Hill}(\text{Adstock}(x_{t,m}, \dots, x_{t-l,m}; L, w_m(l; \alpha_m, \theta_m)), K_m, S_m) +$$

$$\text{trend}_t + \text{seas}_t + \sum_c \gamma_c d_{t,c} + \epsilon_t$$

簡略化するために次のように表記する。(赤・青の色の対応に注意)

データ:  $\mathbf{x}$       パラメータ:  $\mathbf{w}$

その上で、データとパラメータを未知の確率分布からのサンプルとみなす。イメージとしては、次の通り。



## ベイズの定理\*2

$$p(\mathbf{w}|\mathbf{x})p(\mathbf{x}) = p(\mathbf{x}|\mathbf{w})p(\mathbf{w})$$

尤度:

パラメータwが与えられたときの観測データxの確率分布

事前分布:

観測データxとは無関係に設定されるパラメータの確率分布

$$\Leftrightarrow p(\mathbf{w}|\mathbf{x}) = \frac{p(\mathbf{x}|\mathbf{w})p(\mathbf{w})}{p(\mathbf{x})}$$

求めたい  
パラメータの情報

事後分布:

観測データxが与えられた場合のパラメータwの確率分布

エビデンス:

パラメータwとは無関係な観測データxの確率分布

事前分布を仮定して、ベイズの定理を用いることで、MMMのパラメータ情報を推定することができる。メカニズムについては次のページで紹介する。

\*1: 当該モデルはMMMの基本的な機能を説明するためのモデルであり、実例ではより複雑なモデルを利用する必要があることがある。詳しくはCHAPTER 3を参照。

\*2: <https://towardsdatascience.com/bayesian-inference-problem-mcmc-and-variational-inference-25a8aa9bce29>

## ベイズ推定の概要 2/3

61

MMMでパラメータを推定するためにベイズの定理を使うには、定理の各部分の使い方を理解する必要があります。

**エビデンスを無視する:** ベイズの定理の分母は、パラメータ $w$ に依存しないので無視できる。また、エビデンスは一般的に計算が困難であるため、無視することが望ましい。

**観測データから尤度を計算する:** 観測データと事前分布を仮定することで、計算することができる。

次ページにて当該方法を用いた推定の方法(MCMC)を紹介する。

## パラメータ推定のためのベイズの定理の使い方の概要

## 事前分布の設定の例\*2

MMMの加法モデルの例:

$$Revenue_t = \bar{b} + \sum_m \beta_m * Hill(Adstock(x_{t,m}, \dots, x_{t-l,m}; L, w_m(l; \alpha_m, \theta_m)), K_m, S_m) + trend_t + seas_t + \sum_c \gamma_c d_{t,c} + \epsilon_t$$

ベイズの定理(およびMMMにおけるパラメータ推定への使用方法)\*3:

目的変数の予測値と実績値の差の分布  
(データとモデルから計算可能)

$$\prod_{i=1}^N p_\epsilon(f(x_i, w) - Revenue_t)$$

尤度を事前分布をモデルと  
データから計算する

事前分布を  
仮定する

$$p(w|x) = \frac{p(x|w)p(w)}{p(x)}$$

事後分布  
(知りたい  
情報)

エビデンスは無視をする:

1. パラメータに依存しない値なので、知る必要がない
2. 一般に計算は困難\*1

$p(w)$

パラメータ

$N(0, 2)$	$b$
$N^+(0, \sigma_m^2)$	$\beta_m$
$B(1, 1)$	$\alpha_m$
$N^+(0, 2)$	$\theta_m$
$\text{Gamma}(1, 1)$	$K_m$
$\text{Gamma}(1, 1)$	$S_m$
$N(0, 1)$	$\gamma_c$
$N^+(0, 1)$	$C$
$N^+(0, 1)$	$m_{\text{trend}}$
$N(0, 1)$	$k_{\text{trend}}$
$N(0, 1)$	$\gamma_{1,k}$
$N(0, 1)$	$\gamma_{2,k}$
$N(0, \text{Gamma}(1, 1))$	$\epsilon_t$

\*1: <https://towardsdatascience.com/bayesian-inference-problem-mcmc-and-variational-inference-25a8aa9bce29>

\*2: 類似ビジネスにおける過去のモデル結果などの事前知識に基づいて事前分布を変更することが可能。パラメータの設定の例について [LightweightMMM](#) を参照。

\*3: 正確にはデータ(太字 $x$ )は独立変数 $x$ と従属変数 $y$ に分けられ、 $x$ が与えられた元で $y$ と回帰モデルの誤差が正規分布に従うと仮定しているため、 $p(w|x,y) = p(y|x,w) * p(w) / p(y|x)$ となる。

## ベイズ推定の概要 3/3

62

マルコフ連鎖モンテカルロ (MCMC)を用いたパラメータの推定手順は以下の通り:

**Step1** パラメータのサンプリング: 事前分布から、初期サンプルを抽出。

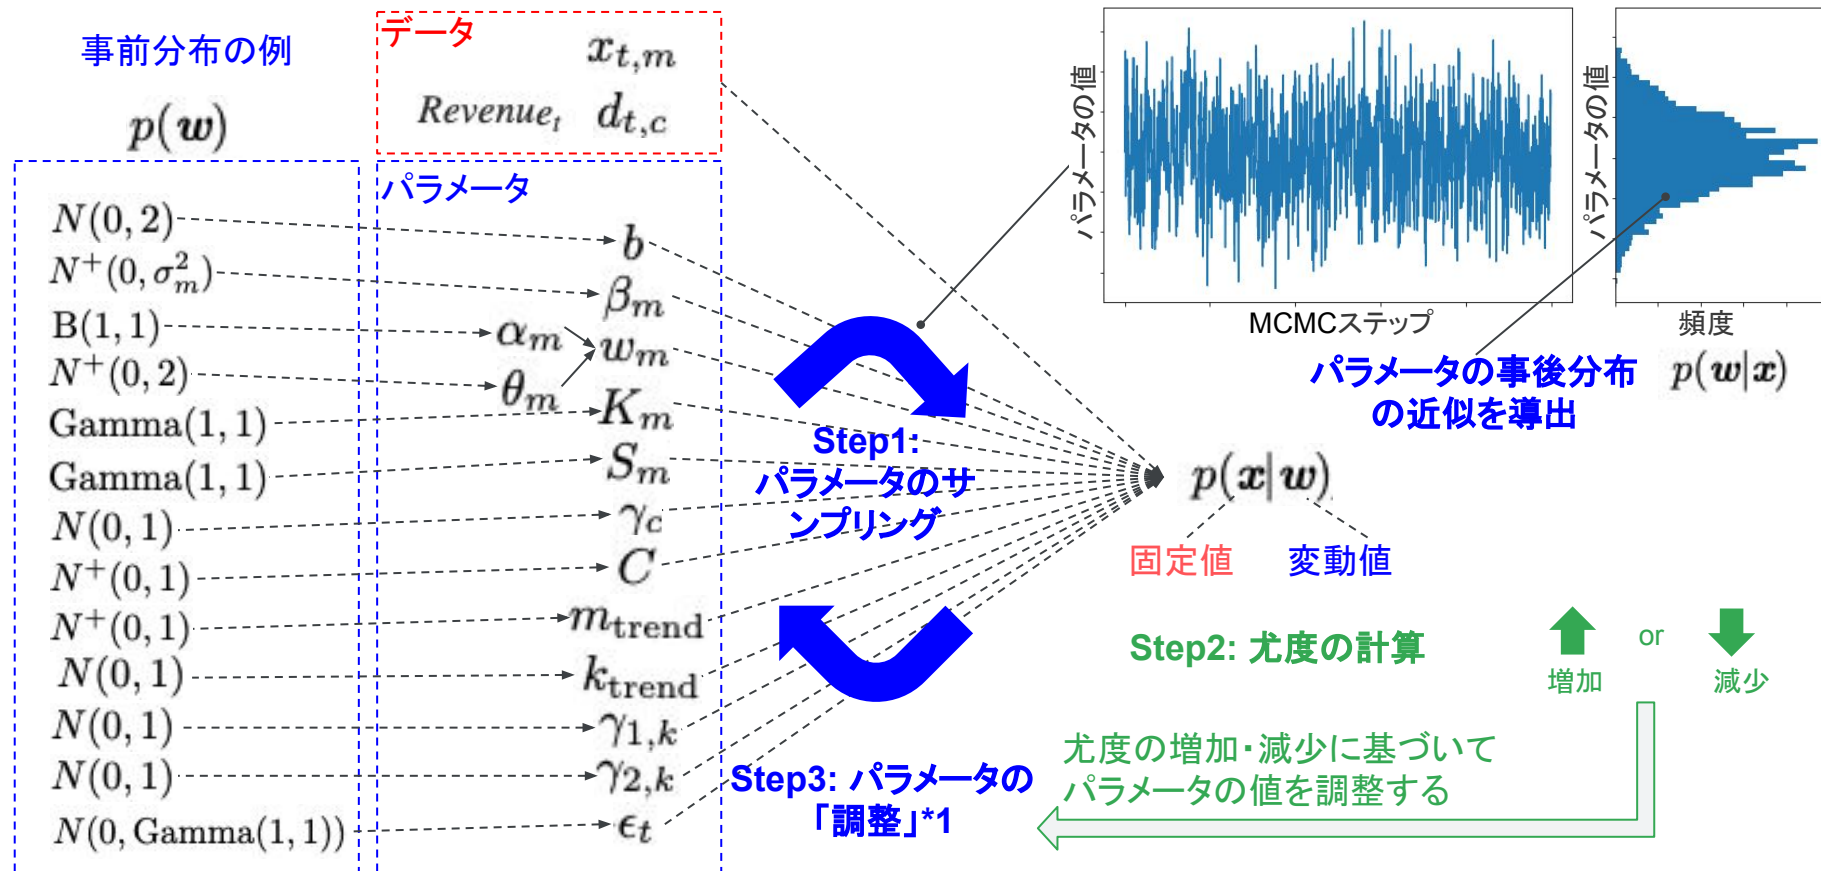
**Step2** 尤度の計算: 前ページで説明したように、尤度を計算する。

**Step3** パラメータの「調整」: 尤度計算に基づいて、パラメータ値を調整する。パラメータの「調整」には、メトロポリス・ヘイスティングス・アルゴリズムのような特定のアルゴリズムが利用される。

**Step4** 以後、Step2, 3を繰り返す。

上記のプロセスは「MCMCステップ」と呼ばれる。MCMCステップの反復(例えば5000回)の後、モデラーはステップの履歴に基づいてパラメータの分布を推定することができる。MCMCステップのデータを「チェーン」(chain)と呼ぶ。モデル作成者は一般に分布の安定性をチェックするために複数のチェーンを実行することになる。

## MCMC (Markov Chain Monte Carlo、マルコフ連鎖モンテカルロ)の概要



\*1: Metropolis-Hastings algorithm, Gibbs sampling (Metropolis-Hastings algorithmの特別なケースなど、「調整」にはいくつかの方法がある。

## 2.5. モデルの検証

---



# モデルの検証における9つのチェックポイント

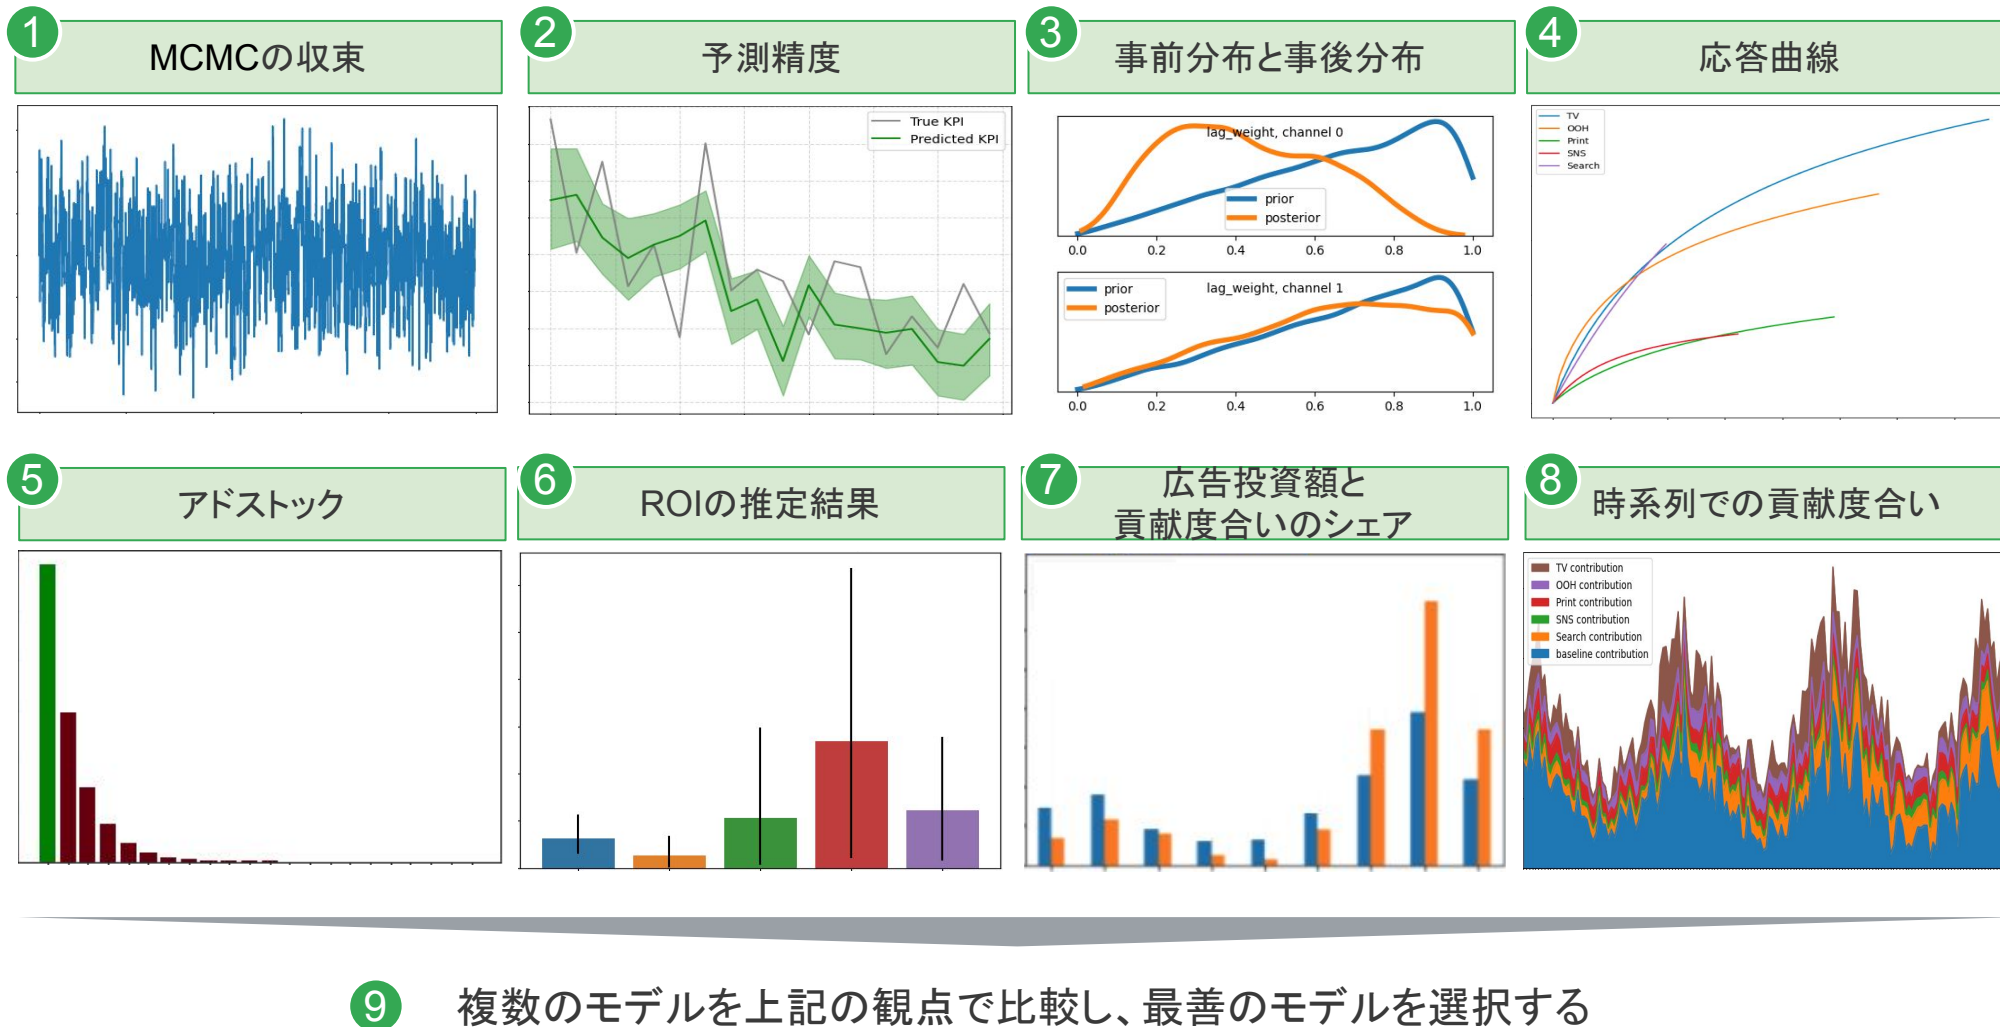
64

## モデルの検証ポイント(9つのチェックポイント)\*1

パラメータ推定の後、モデルを検証する必要がある。

このセクションでは、典型的な検証ポイント(「9つのチェックポイント」)について説明する。

これらの「9つのチェックポイント」は、客観的な指標評価と主観的な評価の両方で構成されている。予測精度といった客観的な指標だけではなく、応答曲線やアドストックの形状といった主観的な指標で評価することも重要である。これは、MMMが応答曲線やアドストックの仮定に基づくモデルだからである。




\*1: これらのビジュアライゼーション(2-8)にはLightweight MMMを用いている。

## MCMCの収束チェック 1/2

MCMCによるパラメータ推定では、モデル作成者はパラメータが適切に推定されているかどうかをチェックする。

主な指標の1つは**Rhat**で、これはChain(MCMCステップの1セット)の平均の分散と、各Chain内の分散の平均の比率に関する指標である。

一般的に**Rhat < 1.1**がパラメータの収束とみなされるが、閾値については複数の提案がある(1.01, 1.05など)。また、MCMCステップの安定性を可視化して確認する必要がある。

MCMCによるパラメータ推定で起こりうる問題  
(単鎖(single chain)の例)

**良くない例**  
最初の部分  
(t=0-1500)が  
他と大幅に  
異なる

**良くない例**  
パラメータの値  
が以前のステッ  
プの値に依存す  
る傾向あり

**良い例**  
各ステップはラ  
ンダムでパラ  
メータの値に一  
貫性がある

## MCMCをチェックするための指標の例

複数の連鎖(Chain)の結果から、**Rhat**(Gelman & Rubinの統計量)を計算する。

$m$  = Chainの数

$n$  = 各ChainでのMCMCステップの数  
(バーンイン(burn-in)期間を除く(次ページ参照))

$x_{ij}$  =  $i$ 番目のChainにおける $j$ 番目のサンプル値

$$\hat{R} = \sqrt{\frac{\hat{V}}{W}}$$

各チェーンの平均の分散

$$\hat{V} = \frac{n-1}{n}W + \frac{1}{n}B$$

$$B = \frac{\sum_{i=1}^m (\bar{x}_i - \bar{x}_{..})^2}{m-1}, \bar{x}_i = \frac{\sum_{j=1}^n x_{ij}}{n}, \bar{x}_{..} = \frac{\sum_{i=1}^m \bar{x}_i}{m}$$

$$W = \frac{\sum_{i=1}^m s_i^2}{m}, s_i^2 = \frac{\sum_{j=1}^n (x_{ij} - \bar{x}_i)^2}{n-1}$$

各チェーンの分散の平均

Rhat > 1.1の場合、MCMCが収束しているとは言えない。

# MCMCの収束チェック 2/2


MCMCでエラーを発見した場合、考慮すべきオプションがある。

**バーンイン期間の破棄:** 初期サンプル値への依存を減らすために、初期のサンプル(例えば、MCMCチェーンの最初の1,500ステップ)を破棄する。


**MCMCステップを増やす:** チェーンを長くする。

**データ中の異なる振る舞いを識別する:** "E" のケースのように、MCMCチェーン間で「ジャンプ」がある場合、1つの変数に傾向が異なるデータソースが混在していることもある(例: 地域別でパラメータ値の推定傾向が異なる等)。

## MCMCによるパラメータ推定で起こりうる問題 (複鎖(multiple chains)の例)



**良くない例。** チェーンによっては、初期値によって他のチェーンよりもパラメータ値が高くまたは低くなる。



**良くない例。** チェーンによっては途中に「ジャンプ」がある

## 対処法の例

	問題例	対処の例
バーンイン期間のステップを無視する	A	「バーンイン」期間(前ページのt=0~t=1500など)を破棄し、Rhat値が減少するようにする。
MCMCのステップ数を増やす	B D	サンプル数(MCMCステップ数)を増やして、チェーン間の不安定性を軽減する。
異なるデータソースを特定する	E	チェーンの「ジャンプ」の根本原因を調査する。例えば、地域別でパラメータ値の推定傾向が異なることがあり、モデルを地域別で分ける等の対応が必要かもしれない。

## 予測精度のチェック

次に、KPIに対するモデルの予測精度を計測する。

**サンプルデータ(モデルのパラメータ推定に使用したデータ)によるKPIの予測精度:** 過去のデータでモデルがKPIを正確に予測しているかどうかを理解するために、モデルの予測値と真値の差を計算する。  
**新しいデータ(サンプル外データ)によるKPIの予測精度:** 新しいデータで同じことを行い、モデルが将来の予測にも適用できるかどうかを検証する。

サンプルデータとサンプル外データの量のバランスとしては、7:3または8:2とすることが多い。しかし、経験則よりもビジネスのニュアンスが重要である。例えば、2年間の週次データを使用してモデルを作成し、四半期データを使用してモデルをテストすることは、ビジネスモデルが四半期間で同様のライフサイクルを持つ場合に有効である。予測精度を検証する主要指標を次のページで紹介する。

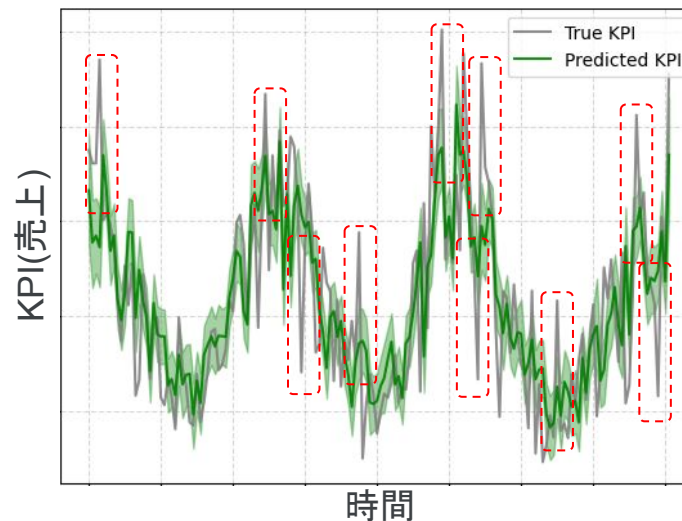
アウト  
プットの  
例

チェック  
方法

例におけ  
る検証結  
果

## KPIの予測精度のチェック

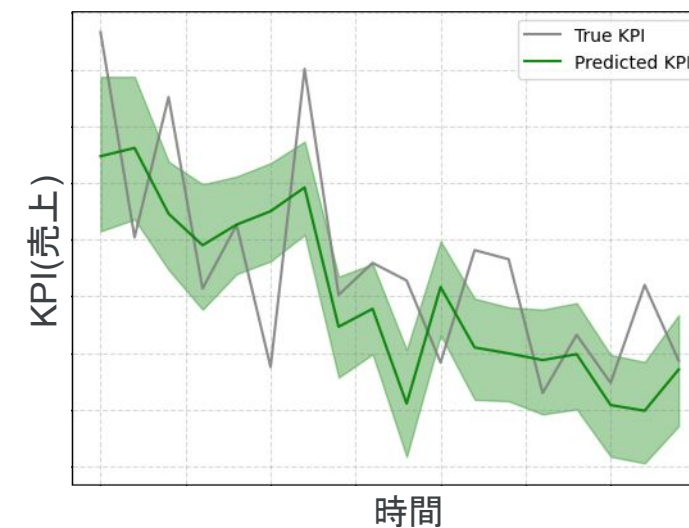
## サンプルデータ



真の KPI 値と予測 KPI 値のギャップをチェックし、追加で含めるべき変数がないかを検討する。

イベントや祝日によるものと思われる **大きな予測実誤差(赤点線部)**が発生している。入力データにイベントや祝日の変数を追加することが必要。<sup>\*1</sup>

## サンプル外のデータ



新しいデータ(サンプル外データ)にモデルを適用し、予測値と実際値の差をチェックする。

予測モデルは未来の売上を一定程度予測することができるが、突発的な売上の上昇・減少は捕捉ができていない。

\*1: 新たな変数を追加する代わりに、潜在変数例えば、BSTS(ベイズ構造時系列))によって柔軟性のある季節性・トレンドを表現することも選択肢の1つ。

# 予測精度のチェックのための指標(サンプルデータ、サンプル外のデータの両方の検証に対して利用する)

## 決定係数(R-squared)

## 平均絶対パーセント誤差(MAPE)

## ダービンワトソン比(Durbin-Watson)

### 概要

- モデルによるKPIの予測値と真値の当てはまりの良さ(R-squared)と誤差(MAPE)を表す指標
- 低いR-squared(例:R-squared < 0.85)と高いMAPE(例:MAPE>10)は、モデルに含まれていない他の変数の存在を示唆する

- モデルによるKPIの予測値と真値の誤差に関して自己相関(KPIの値が前の時刻のKPIと相関すること)を検出するための指標
- 例えば、DW > 2.5 or DW < 1.5 である場合、モデルに含まれていない他の変数の存在を示唆する

### 定義

モデルのKPI予測値とKPIの平均値の差の二乗和

$$R^2 = \frac{\sum_{t=1}^T (\hat{y}_t - \bar{y})^2}{\sum_{t=1}^T (y_t - \bar{y})^2}$$

KPIの真値とKPIの平均の差の二乗和

パーセンテージ表示にするための100

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100$$

モデルのKPI予測値と真値の絶対値誤差の平均値


$$d = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2}$$

モデルのKPI予測値と真値の誤差の二乗和  
上記誤差の時間経過による変動値の二乗和


### 例

R-squared = 0.588, MAPE = 29.1%

緑: KPIの予測値  
灰色: KPIの真値



自己相関が高いグラフの例\*1



高い自己相関は、モデルに含まれていない他の重要な変数の存在を示唆する

## 事前分布と事後分布の比較

69

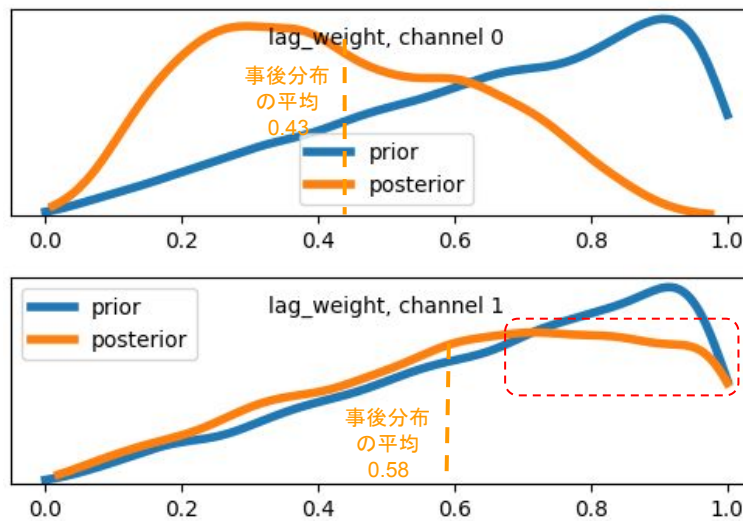
モデルの作成者は、複数の事前分布を用いて事後分布をチェックする必要がある。

**事前分布(prior distribution)による事後分布(posterior distribution)の違い:** 事前分布を変えることで、事後分布が変わる可能性がある。KPI(売上)に対して、データに一貫した傾向があれば、事後分布は前提を変えても大きく変わらない。事前分布により事後分布が変わる場合、過去の経験や業界標準に基づいて、特定の事前分布を選択する根拠を検証する必要がある。モデルのパラメータについての仮定(事前分布)と推定結果(事後分布)の関係を理解できることはベイズ推定の利点の1つである。

**事後分布(posterior distribution)の平均値の違い\*1:** 事後分布の平均値は各メディアのKPIへの貢献やROI(ROAS)の計算に使われるため、平均値の一貫性もチェックする必要がある。


アウト  
プットの  
例チェック  
方法例におけ  
る検証結  
果

## 事前(prior)分布がBeta(2,1)の場合



例

## 事前(prior)分布がBeta(1,1)の場合



下記を確認する。

- 事前分布(prior distribution)を変えると、事後分布(posterior distribution)が異なるか
- 事前分布により、パラメータの事後分布の平均\*1がどの程度異なるか

パラメータの推定値・分布に差異がある場合、事前分布を選択する根拠を証拠(過去の経験、業界標準など)に基づいて検証する。

上記の例では、事前分布(Beta(2,1) または Beta(1,1))によって、パラメータ"lag\_weight, channel 1"の事後分布に違いがある一方、事後分布の平均値は事前分布によらずほぼ一致している。ただし、事前分布Beta(1,1)の場合に、0.7~1.0の確率密度が高い理由を調べる必要がある。

\*1: 各メディアのKPIへの貢献とROAS(ROI)を計算するために、パラメータの平均値が使用される場合。中央値を用いる場合は中央値について調べる。


MMMには、応答曲線やアドストックなどの仮定が存在するため、モデル作成者は定性的な(主観的な)チェックも行う必要がある。

第一は、応答曲線の形状と勾配の比較である。

各メディアの応答曲線の形状・勾配が過去の経験に即して妥当かどうかを検証する必要がある。一般的には、マスメディアにはS字型曲線、デジタルメディアには凹曲線が適している。また、これらの観点についてMMMの利用者となるマーケティングチームとの議論を行うことも必要である。

## 応答曲線のチェック方法の例(主観的チェック)

応答曲線の例\*1



## チェックすること(例)

### 応答曲線の形状

各メディアの応答曲線の形状は、過去の経験に即して妥当と言えるか？

左の例では、TVの応答曲線は凹曲線になっているが、S字曲線の方が正しいかもしれない。

もし過去の経験に照らし合わせて応答曲線の形状、勾配が不自然である場合は、モデルの作成者は応答曲線を調整する必要がある。

### 応答曲線の勾配

曲線の勾配は、過去の経験に即して妥当と言えるか？

左の例では、TVとOOHの応答曲線の勾配が急すぎる可能性がある(デジタルよりも急である)。

例としては、パラメータ推定時に一部のメディアのパラメータに制約条件を加える等の対応である。

\*1: ROIを計算するために、応答曲線を推定した後、インプレッションあたりの平均コスト(CPM)を使用して、広告のインプレッションから広告の投資額に単位を変更する必要がある。

\*2: 必要であれば、メディアの広告投資以外の要素販促なども同様の分析を行うことが可能。

## アドストックのチェック

第二に、アドストック減衰も主観的なチェックが必要である。

モデル作成者は、各メディアの広告フォーマットの違いを考慮し、モデルがこれらの違いを適切に表現しているかをチェックする必要がある。

一般的に、動画広告のようなリッチメディアフォーマットは比較的減衰率が低く(減衰が遅く)、静的フォーマットは比較的減衰率が高い(減衰が速い)と言われている。メディア間のアドストックのパラメータを比較することで、モデルが適切に減衰を記述しているかどうかをチェックする必要がある。

アウトプットの例

幾何的アドストック(Geometric adstock)を仮定

$$\text{adstock}_{t,media} = x_{t,media} + \lambda_{media} * \text{adstock}_{t-1,media}$$

減衰  
パラメータ

パラメータの推定結果の例

	mean	std	median	5.0%	95.0%
TV	0.32	0.14	0.32	0.10	0.55
OOH	0.59	0.18	0.59	0.26	0.88
新聞	0.67	0.24	0.70	0.32	1.00
YouTube	0.70	0.22	0.76	0.34	1.00
検索	0.71	0.21	0.75	0.41	1.00

推定されたパラメータからアドストックを経験に基づいてチェックする

チェック方法




推定されるアドストックの減少は、経験や業界のベンチマークと比較して理にかなっているか？

上記のケースでは、テレビはデジタルメディアよりも減衰が早い。フォーマットを考慮すると(テレビCM対ニュースフィード、検索のテキスト広告)、ニュースフィードやテキスト広告よりも動画広告の方が長い期間認知を促進すると予想されるため、このような推定となった根拠を明らかにする必要がある。

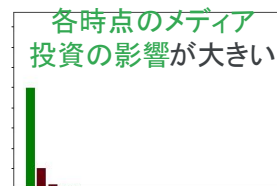
例

例示的

各期間における  
広告投資と  
アドストック



アドストック



残存効果の影響の方が  
大きい

推定結果の  
類似性

TV (0.32)

OOH (0.59)

新聞 (0.67)

YouTube (0.70)

検索(0.71)




## MMMにおけるROI(ROAS)の計算方法 1/2

レスポンスカーブの形状やアドストックのをチェックした後、モデル作成者はメディア別のROAS(広告費用対効果)を計算する。

ROASの分母は計測対象期間の合計の広告費である。分子は当該広告投資によるKPIの増加(例:売上の増分)を意味する。分子は実際の広告費を使った場合のモデルによるKPIの予測値と、当該広告費がゼロであると仮定した場合のモデルによるKPIの予測値の差により計算ができる。

## MMMにおける推定ROI(ROAS)の定義\*1



モデルによるKPI(売上)の予測値  
(過去の広告投資をモデルに代入して算出)\*2

モデルによる売上の予測値(過去の広告投資を0  
としてモデルに代入して算出)\*2

$$\text{ROAS}_m = \frac{\sum_{t_0 \leq t \leq t_1 + L - 1} \hat{Y}_t^m(x_{t-L+1,m}, \dots, x_{t,m}; \Phi) - \hat{Y}_t^m(\tilde{x}_{t-L+1,m}, \dots, \tilde{x}_{t,m}; \Phi)}{\sum_{t_0 \leq t \leq t_1} x_{t,m}} = \text{ROAS (Return on Ad Spend)}$$

分子 = 売上増分  
分母 = 期間中の広告費の合計\*2

\*1: Google (2017), Bayesian Methods for Media Mix Modeling with Carryover and Shape Effects

\*2: メディアのインプレッションをモデルの変数に用いている場合は、平均インプレッション単価CPM等をインプレッションに乗じて単位を金額に修正する必要がある。


## MMMにおけるROI(ROAS)の計算方法 2/2

前述したMCMCによって、モデルの各パラメータの事後分布を得ることができ、ROAS(ROI)の推定の区間(ベイズ推定では「信用区間」と呼ばれる)と平均値を計算することができる。


次のページでは、それらを主観的に評価する例を紹介する。

## MMMにおける推定ROI (ROAS)の計算

例示的



ROASの分布の主要統計量を推定するために、抽出したパラメータ値(平均値、5パーセンタイル、95パーセンタイルなど)をROASの計算式に当てはめて計算する



\*1: より正確には、ROASの95パーセンタイルと5パーセンタイルを与えるパラメータの値から計算する。

## ROAS(ROI)の推定結果のチェック

ROAS(ROI)計算後、モデルの作成者は推定の平均値と信用区間を比較する。

**平均ROAS:** 異常値(極端に高いまたは低いROAS)がある場合は原因を調査する必要がある。理由が特定できない場合、複数のモデルを作成し、結果の一貫性を調べる必要がある。モデルの仮定(事前分布等)により結果が大きく変わる場合は、モデルの仮定の根拠を明確にする必要がある。


**ROASの信用区間:** 信用区間の幅が大きい場合、データが不足している可能性がある(例:3年の計測期間に対してメディアの広告期間が数週間程度)。このような状況では、確定的な判断は避ける必要がある。

## 推定ROI (ROAS)のチェックの例

例示的

ROAS (ROI)の推定結果  
(縦線は5、95パーセンタイルによる信用区間)

Estimated media channel ROAS estimation.  
Error bars show 0.05 - 0.95 credibility interval.



## チェックすること

平均  
ROASの  
チェック

平均ROASの推定値は、経験や業界のノルム値と照らし合わせて妥当かどうか？

また、モデルの仮定(例:事前分布)を変えても結果は一貫しているか？

信用区間  
の  
チェック  
\*1

信用区間の幅の原因は何か？(例:データの不足、広告の実施の巧拙によるパフォーマンスの不安定性等)

モデルの作成者はメディアのキャンペーン単位の実績をチェックし、不安定性を除去するためにターゲット顧客毎のモデルの分割や、広告の配信面毎の分割を検討する。

\*1: 正則化(Regularisation)を用いてパラメータを推定している場合は通常は信頼区間の情報は得られない。ブートストラップサンプリング等の信頼区間を追加する方法もあるが、計算量が多くなる場合がある。


# 広告投資額と貢献度合いのシェアのチェック

マーケティングチームがモデルの推定結果を妥当と判断するためには、費用と効果のシェアに関する主観的なチェックが現実的には必要である。

このチェックでは、広告費投資額のシェアと、各メディアによってもたらされるKPI(売上等)の増分シェアを比較する。

マーケティングチームによるメディアの広告投資額の配分は、投資による売上上昇の期待値に影響されるため、投資額と売上増分のシェアのギャップが大きい場合は、その理由を明確にする必要がある。

## アウトプットの例\*1 例示的



広告投資のシェアと売上増分のシェアの差分を各メディア毎に比較する

## チェックの例

差分のチェック

売上増分におけるシェアと広告投資におけるシェアに **大きいギャップ**がある場合、そのギャップの理由は何か？

例えば、左図のメディアのG、H、Iは広告投資の割に売上増分が大きく、メディアA、B、D、Eはその逆である。マーケティングチームは原因の仮説を挙げられるだろうか？  
\*2

対応策

- 複数のMMMの結果を比較し、推定の一貫性を確認する
- and
- 一貫性のある推定結果と現場の納得を総合して、選択するモデルを決定する

\*1: プレゼンテーションの対象者によるが、信用区間を付して説明することが望ましい。\*2: 仮説を挙げることに際しても、可能な限り客観的に事実を調査・検討することが望ましい。例えば、特定のメディアにおける競合他社の大規模なキャンペーンは当該メディアのROASを低下させる可能性がある。競合のメディア別のキャンペーン動向は、物理的にデータが入手できないこともあり説明変数に含めることができないことから、定性的に影響を考えざるを得ない場合もある。

## 時系列での貢献度合いの分析

76


P.72の計算に基づき、各時間単位(例えば週や日)における各メディアの貢献度がMMMによって計算される。右図は各メディアの貢献度、それ以外の変数の貢献度を時系列に積み上げ面積グラフで表したものである。

当該グラフを参照し、カレンダー(祝休日)やイベント、規模の大きいキャンペーン期間と比較することで、モデル作成者はモデルが過去のデータを正しく記述できているか確認することができる。

さらに、時系列の内訳を、アトリビューションやリフト計測(実験)などの他の計測方法と比較することも、当該分析を実施する理由である。



## アウトプットの例\*1

例示的



時間

比較

アトリビューション  
(デジタルメディアのみ)(準)リフト計測(実験)  
の結果\*

## チェックの例

定性的な  
検証

メディアとベースライン(メディア以外の要因)の寄与の傾向が、モデルによって正しく捉えられているかをチェックする。

例えば 休日やイベントによる売上の増加は、ベースラインの寄与に配分されるべきである。

他の  
計測結果  
との比較

メディアの貢献度に関するMMMの推定結果が、アトリビューションや(準)リフト計測(実験)などの他の測定ソリューションと整合性があるかチェックする。

対応策

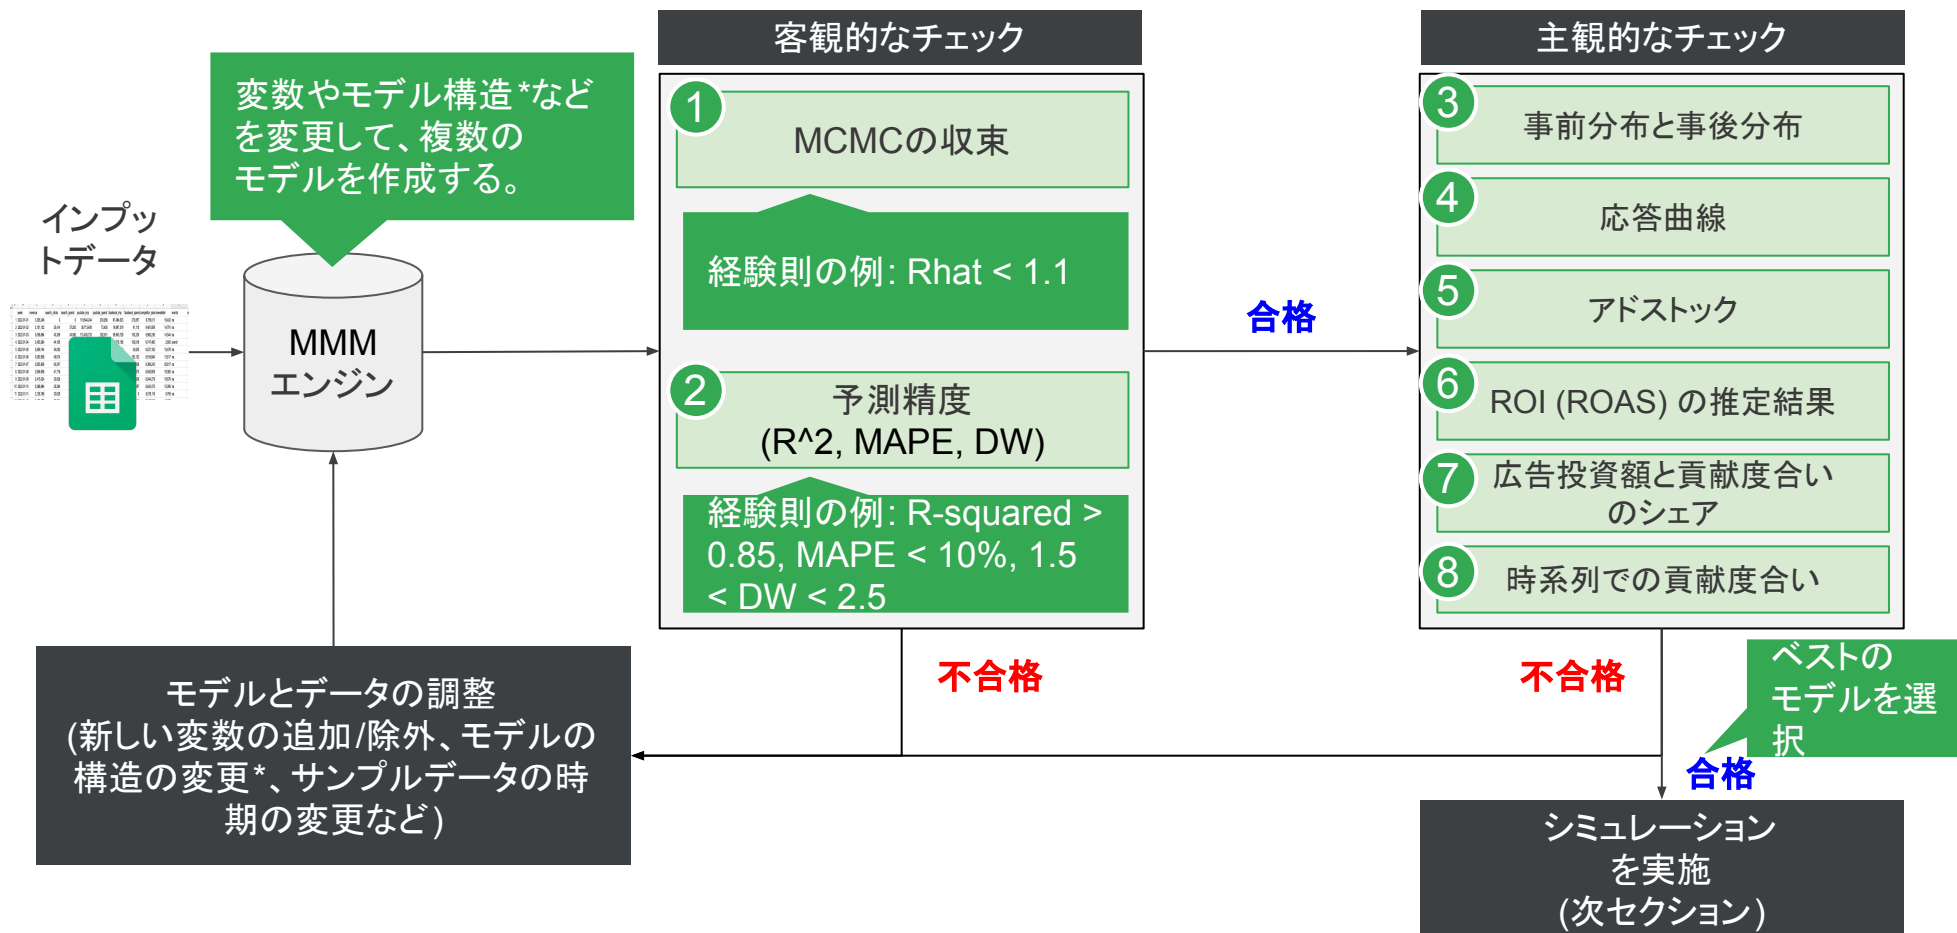
MMM、アトリビューション、(準)リフト計測(実験)における差異の主な理由を特定する。

MMMのパラメータを可能な限り調整する(p.84「(準)リフト計測(実験)によるキャリブレーション」を参照)。

\*: Google(2015), Inferring Causal Impact using Bayesian structural time-series models

MMMは、応答曲線やアドストック等の構造の仮定を前提としているため、モデルの妥当性確認には、モデル作成者とマーケティングチームの両方がモデルの推定に確信を持てるように、客観的なチェックと文脈に沿った(ある程度主観的な)チェックの両方が必要である。そのために、モデル作成者は、異なる変数、事前分布、モデル構造で複数のモデルを作成し、最適なモデルを選択する必要がある。

MMMの客観性についてはしばしば批判があるが、上記のプロセスは、ビジネス上の意思決定にMMMを活用するための実践的な方法である。



\*: モデルの構造については、CHAPTER 3にて方向性を解説している。

## 2.6. モデルの利用

---

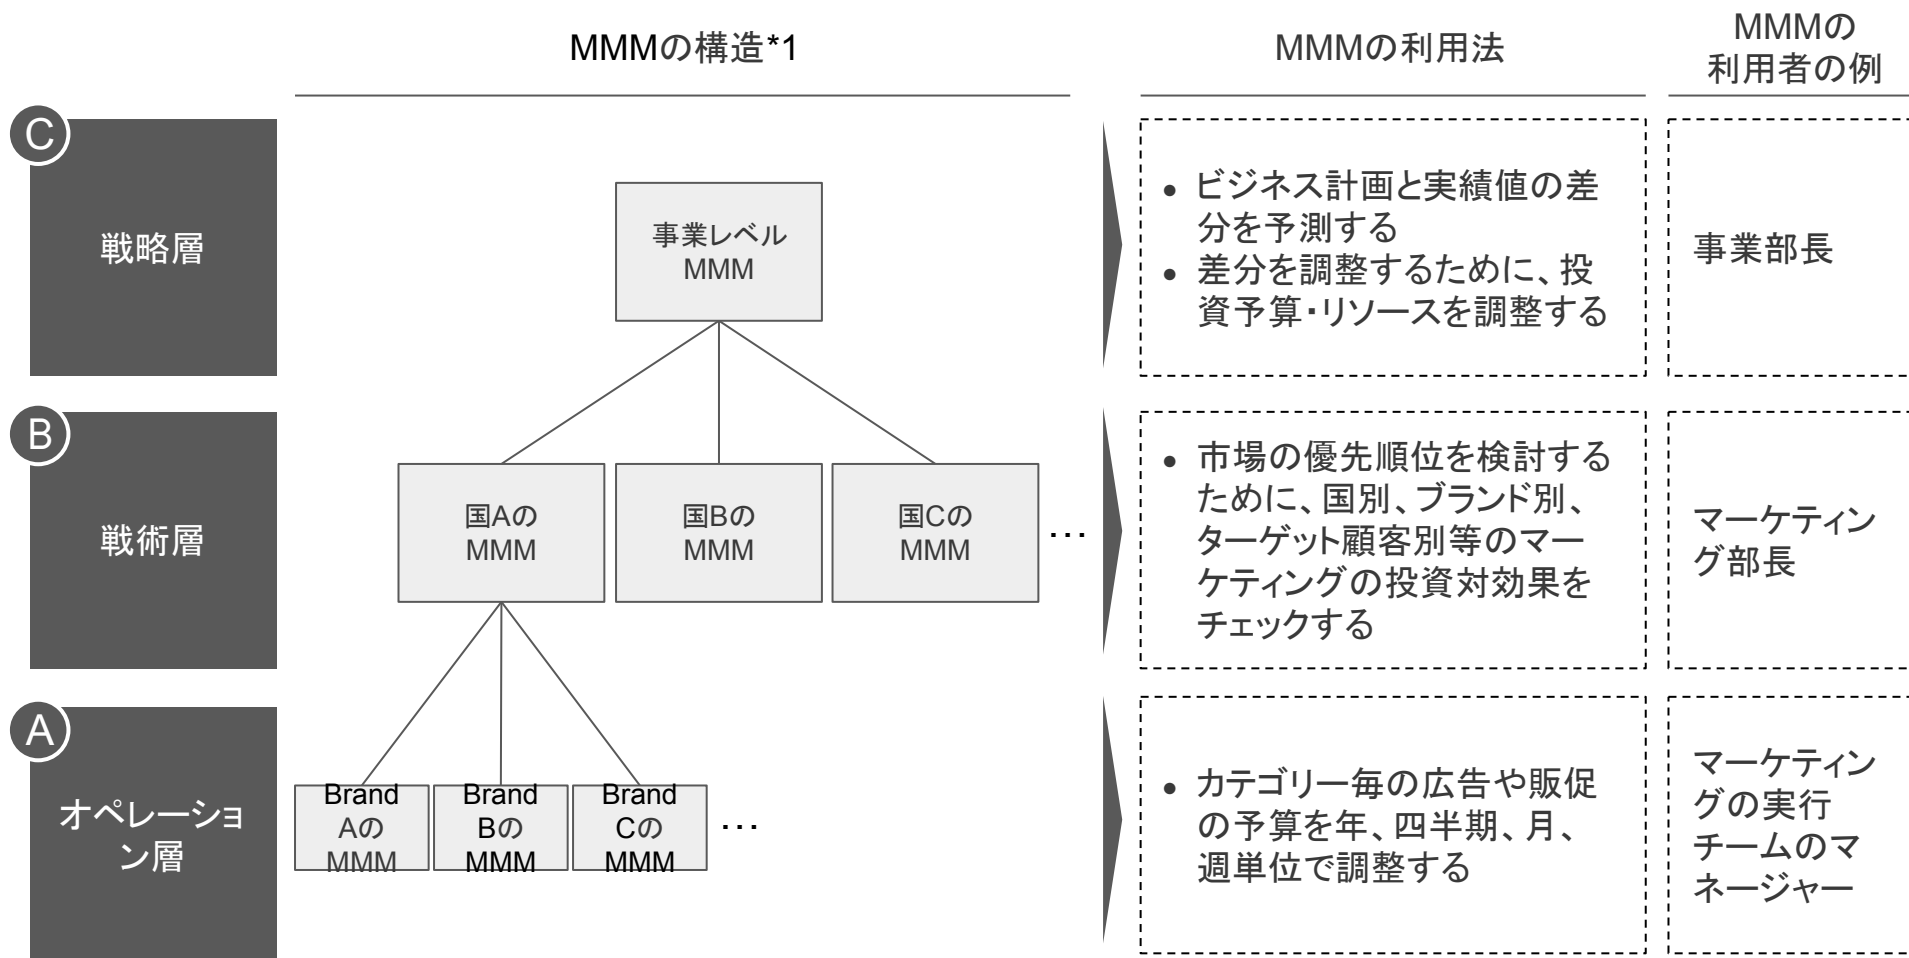
## MMMのユースケースの例

79

モデル作成後、モデル作成者とマーケティング・チームは、モデルを活用することが可能である。

右図は、3つの組織階層でMMMを作成・利用する例を表している。下位2層には、カテゴリーレベルのMMM(例えば、ブランドA、B、C)を作成している。上位層のMMMは下位層のMMMの合計となっている。<sup>\*1</sup>

各層では、モデルの目的と使い方が異なる。マーケティングの業務を行うチームが広告や販促予算の最適化のためにモデルを使用するのに対し、上位層はカテゴリー(国、ブランドなど)への投資配分を検討するためにモデルを使用することがある。



<sup>\*1</sup>: 市場間の事業、ブランド、顧客の行動の類似性によっては [p.56-57](#)に記載した階層的なモデルも考えられる。事業、ブランド、顧客に類似性がない場合は、最下層(オペレーション層)で各モデルを作成し、それらを足し上げていくのが現実的である。




## A オペレーション層でのMMMの利用法の例(広告や販促の予算配分)

80

マーケティングのマネジャーは、MMMを利用して短・中期的にメディア間の最適な広告投資の配分を検討することができる。

MMMは、将来の総予算(例えば、翌月の広告予算)とメディア以外のデータの予定・予測(例えば、販促の予定、天候予測、競合の活動予測など)をモデルに入力することで、KPI(売上)を最大化するために最適な予算配分を算出することができる。\*

なお、外部のデータ(天候、競合の活動予測など)を保持していない場合は昨年のデータを流用するなど、妥協が必要である。



使い方

推奨に基づき、次期(週、月、四半期、年等)の予算配分を調整する

\*: 実用的には、急激な予算変更によるリスクを避けるため、最適化の範囲に制限を設けることがある。例えばTV予算の減少割合、デジタル予算の増加割合に一定の制限を設けて最適化の計算を実施する等。

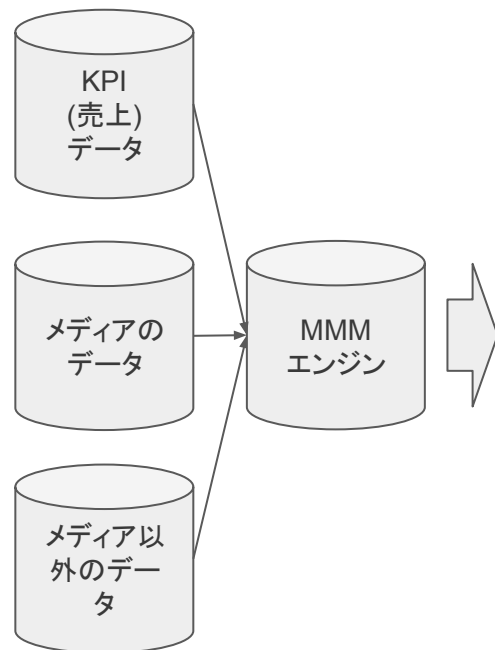
## B 戦術層でのMMMの利用法の例(セグメント毎の投資効果の推定)

81

マーケティング部長やビジネスのディレクターは、事業ドメインや国レベルで過去の会計期間のROASやROIを推定したい場合がある。

MMMでは、オペレーション層のMMM(前ページ)に基づいて、ビジネスのカテゴリ(例:ブランド)毎のマーケティング投資(広告や販促の投資)に対するROASやROIを見積もることができる。

このような推定は、将来、市場や事業領域の優先順位付けの検討材料として役に立てることができるかもしれない。

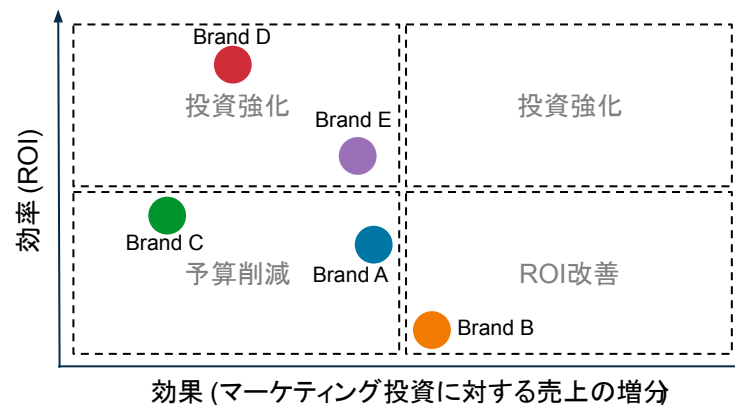



### インプットとアウトプット

例示的

### 使い方

ROAS (ROI)の推定結果




ビジネスのカテゴリ(例:国、ブランド、ターゲット顧客)毎にマーケティングのROIやROASを推定し、市場や事業領域の優先順位や戦術を考えるインプットとして利用する。<sup>\*1</sup>

\*1: 技術的には、販促・広告予算の配分は、ROI (ROAS)ではなく、限界ROI (marginal ROI)や応答曲線を参照すべきである(p.47)。異なるビジネスのカテゴリ(国、ブランド、ターゲット顧客等)でマーケティングのROIを比較し、全体の利益を最大化するための優先順位を検討することが可能である。

## ③ 戦略層でのMMMの利用例(KPIの予測)

事業部長は、経営計画を達成するため、KPI(売上)の予測と実績の差分、及び差分を補うための適切な投資方法を知りたいと想定される。

MMMは、将来の販促・広告投資や外部環境の見通しに応じたKPI(売上など)の予測を算出することができる。また、予測と実績の差分の原因を分析することで、目標との差分を補うための必要な投資額・方針について検討する材料を得ることができる。



### 使い方

- モデルのKPIの予測と実績の差分を追跡し、差分の原因を分析する(どの変数が予測と実績で差分が大きいか分析する)。
- 将来の投資額や投資方針の調整によって、予実の差分を補うことを検討する。

\*1: 販促や広告の投資プランだけでなく、外部環境に関するデータ(競合他社の動向の予測、景気に関する予測等)が必要、または、仮定をする必要がある。

## 2.7. MMMに関するその他のトピック

---

	実験によるMMMの補正	時変パラメータの利用	広告投資の長期効果の推定
内容	<ul style="list-style-type: none"> <li>企業が実験(例:コンバージョンリフト、ジオリフト)または準実験(例: DID、<a href="#">Casual Impact</a>)を継続的に実施している場合、これらの実験結果によるMMMの補正を検討する価値がある。</li> <li>ベイズ推定は、事前分布に上記の情報を組み込むため、モデルの補正に適した方法の1つである。</li> </ul>	<ul style="list-style-type: none"> <li>メディアの応答曲線とアドストックは、季節等によって異なる可能性がある。例えば、年末商戦の広告に対する応答は他の季節とは異なる可能性がある。</li> <li>MMMのパラメータが時間と共に変化すると仮定すると、時期や季節によって広告・販促への応答が異なることも表現できる可能性がある。</li> </ul>	<ul style="list-style-type: none"> <li>有名でロングセラーのブランドにとっては、マーケティング活動による長期的なブランドの成長の推定は重要な要素である。</li> <li>しかし、MMMでは広告等による短期的な効果(一般的には数週間)のみ勘案されている。</li> <li>マーケティング活動による長期的なKPI(売上)への影響を推定することは重要な検討項目の1つである。</li> </ul>
課題	<ul style="list-style-type: none"> <li>実験データは、市場、ターゲット顧客、ブランドを問わず入手できるとは限らない。コンバージョンリフトの結果は個人のデータに依存しており、クッキーやデバイスIDのプライバシー保護によって影響を受ける可能性がある。ジオリフト(地域単位のデータで行うリフトテスト)についても、市場によっては特定地域への需要の偏りの影響で正確性に疑問符がつく。</li> <li>実験の結果は、期間中の評価は正確かもしれない。しかし、期間外では正確ではない可能性もある。</li> <li>実験を行うためのコストが発生する。実験を行う手間に加えて、テスト中は自社の広告の露出を控える顧客(コントロールグループ)がいるため、それらの顧客に対する機会損失となる。</li> <li>MMMを実験結果に基づいて補正することを示唆するホワイトペーパー等はあるが、2023年8月現在、コンセンサスがとれた方法はない。</li> </ul>	<ul style="list-style-type: none"> <li>時間的と共に変換するパラメータは、市場の変動が大きいビジネス及び左記の実験によるMMMの補正には適している一方、モデルの合計のパラメータ数が増加してしまい、サンプル数が不足してしまう課題がある(MCMCの収束が困難になる可能性がある)。</li> <li>時間的と共に変換するパラメータの事前分布と事後分布の管理と維持は煩雑になる傾向にある。特に、制約条件によっては、将来のデータが時間変化するパラメータの既存の推定値に影響を与える可能性がある。例えば、隣接する時点のパラメータからの依存関係が仮定された場合、将来のデータによって過去の推定が変化する可能性がある。<sup>*1</sup></li> </ul>	<ul style="list-style-type: none"> <li>モデルの作成者は、マーケティング活動によってもたらされる長期的な効果を測定するために、企業内で継続的に使用されているブランド調査等の確立された指標を特定する必要がある。マーケティング部門は、そのようなブランド指標が長期的なKPI(売上)にどのような影響を与えるかについてメカニズムを証拠を元にモデル作成者に説明する必要がある。この点で方法論は曖昧であり、確立された方法はなく、さらなる研究が必要である。</li> <li>さらに、マーケティング活動のKPIへの長期的な影響をモデル化するためには、十分なデータ量(例えば、少なくとも4年分のデータ)が必要であり、検出可能な長期的な影響にも制約がある。<sup>*2</sup></li> </ul>

\*1: Edwin NG, Zhishi Wang, Athena Dai (2021), Bayesian Time Varying Coefficient Model with Applications to Marketing Mix Modeling

\*2: Google (2019), Measuring effectiveness: Three grand challenges

### MMMのシステム面の課題の例

伝統的なMMM(例:1年に1度行うMMM)と比較して、クッキーレスに対応するための MMMは継続的かつ更新を頻繁に行うことになる。しかしながら、継続的に多頻度でMMMを更新、利用するためにはシステム面でも様々な課題がある。

- **データパイプラインの自動化:** 社内外の多種多様なデータソース (例:Google Cloud上のAnalytics hubなど)を収集、加工、保存する仕組みの作成が必要である。データによってはAPIが存在せず、自動収集する仕組みの開発が必要である。
- **データ粒度の問題:** データソースによっては、粒度が十分でない場合がある (例:テレビ広告のデータは週次だが、多頻度にMMMを利用するには日次データが必要)。その場合、モデルの作成者は粒度の細かいデータを生成するために仮定を導入するか、モデルの粒度を妥協しなければならない。
- **入力データの予測の問題:** 将来のKPIを予測するためには、広告や販促の投資予定だけではなく、外部データ (例:将来の天候)の予測データを入手する必要がある。データ次第では入手できない場合もあり、仮定が必要である (例:予測に過去の天候データを使用する)。
- **MMMの運用プロセス:** 多くのマーケティング実務は、個人レベルのデータに基づくマルチタッチ・アトリビューション (MTA)などの既存の測定製品を使用している。社内でいつ、誰が、どのようにMMMを利用するか、モデルをどのように更新すべきか等について、一般的に知られている成功事例は少ない。

### メディア特有の課題の例 (Googleの場合)

特定のメディアのレベルでMMMで解決されていない問題が多数ある。ここでは、Googleの例を示す(網羅的ではない)。

- **検索広告・メディアについての推定の偏り:** 検索メディアにおける消費者行動は、検索ワードの種類 (ポジティブ/ネガティブワード、競合商品ワードなど)によって異なる可能性がある。検索メディアの正しいモデル化については研究中である。\*1
- **動画メディア (YouTubeなど)のリーチとフリクエンシー:** 典型的なMMMでは、インプレッションや費用の総量ではなく、一人当たりのインプレッション数、つまりフリクエンシー (フリクエンシーが高いほど消費者の購買を促進する可能性がある)の効果を考慮していないのが一般的である。メディアのリーチとフリクエンシーの双方を考慮したモデルについても研究中である。

\*1: Bias Correction For Paid Search in Media Mix Modeling, Google, 2018

CHAPTER

3

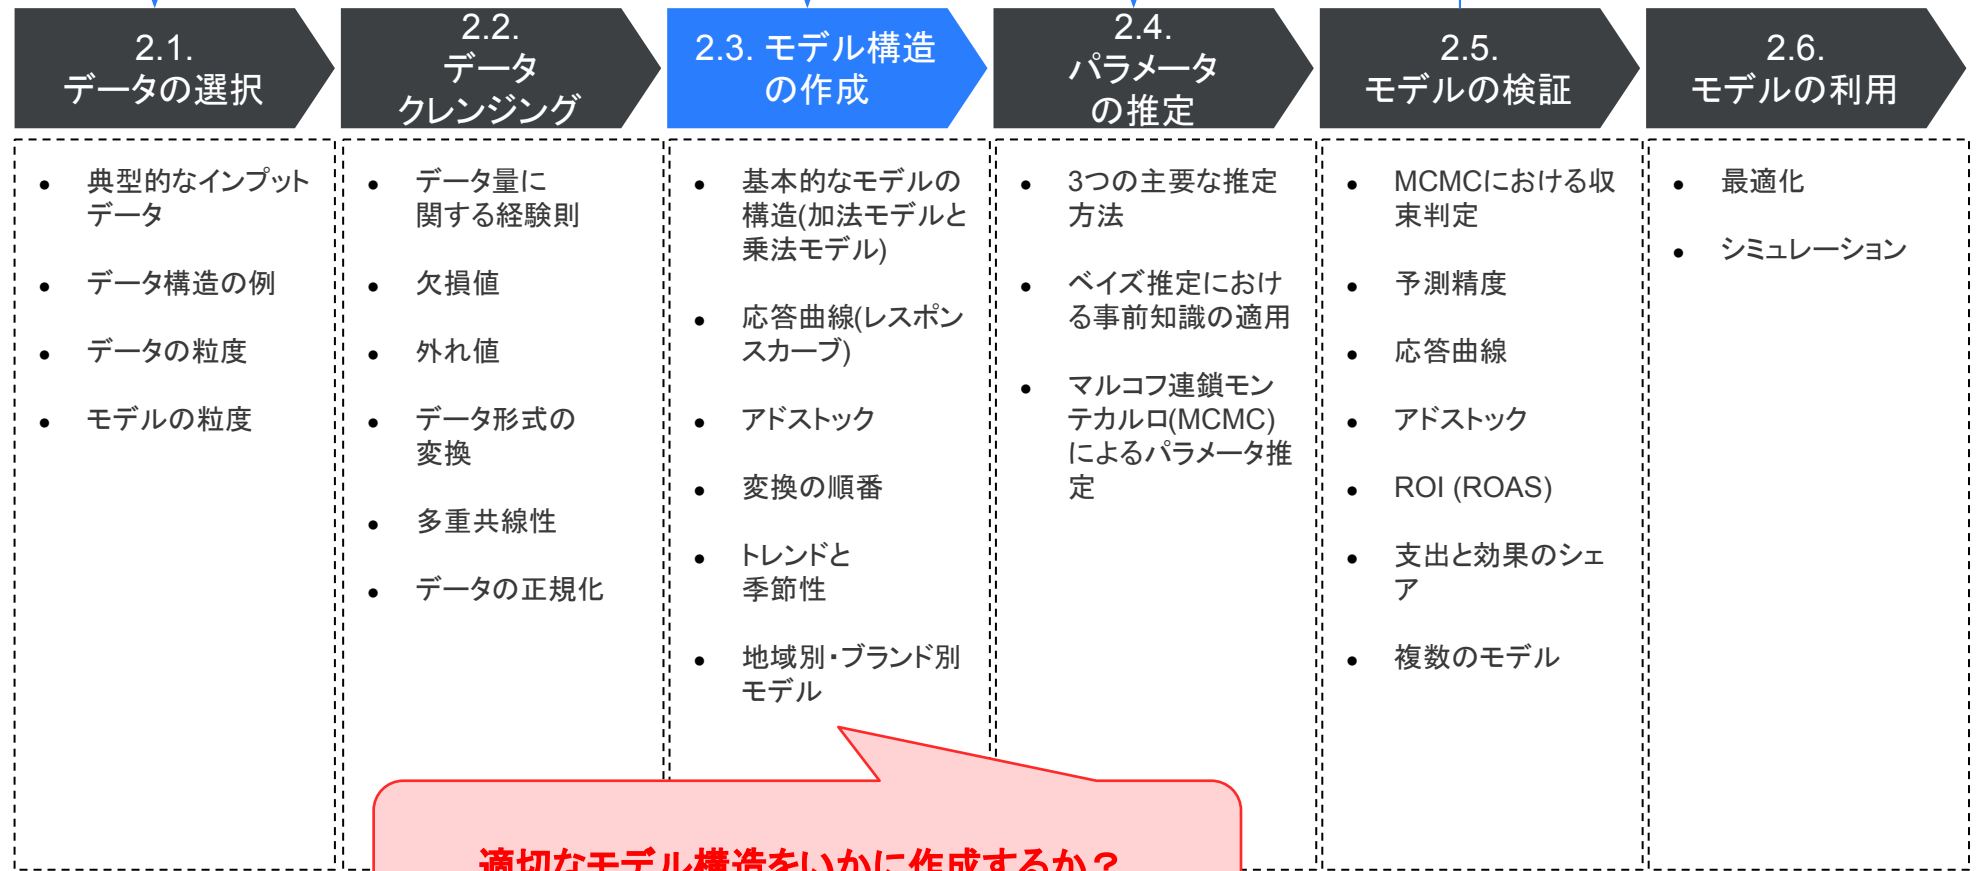
## MMMのモデル構造に関する考察

MMMのモデル構築プロセスにおいて、モデル構造の作成は非常に難しいステップである。適切なモデル構造をさまざまな角度から検討し、決定する必要があるからだ。

実務においては、モデル構造の作成は、データ選択やパラメータの推定ステップと行き来しながら行われる。

このセクションでは、モデル構造の妥当性がMMMの分析結果に及ぼす影響をシミュレーションによって示す。そして、適切なモデル構造を見出すためのヒントを提示する。

結果に応じてデータ、モデル、パラメータの推定方法の変更を行う






## 3.1. モデル構造の作成方法と類型

---


- 実務においては、3つの観点から仮説構築・分析作業を行い、ステップを行き来することで、適切なモデル構造を判断する。
- まずモデル化対象の商材・サービスを生活者が購入するプロセスについての①ドメイン知識から仮説を立てる。次に、データの計測・収集可能性の観点から②モデルとしての表現可能性を検討する。最後にモデル構造仮説に基づいたモデルを作成・検証し、③モデルのあてはまりを確認する。
- これらのステップを行き来し、複数の可能性から、意思決定に有用なモデル構造を選択することになる。

概念モデル



①ドメイン知識による仮説  
マーケティング理論・調査結果・

数理モデル  
(MMMモデル)



適切なモデル構造の  
作成プロセス

③モデルのあてはまり確認  
モデルの検証ステップにて  
9つのポイントを確認

実際の  
購買行動



②モデル表現可能性の検討  
計測データ・調査データ  
・オープンデータなど

- 適切なモデル構造とは、現実の因果関係が反映されているモデル構造だと考えます。前述のモデル構造の作成プロセスにおいて、誤った因果関係をモデル構造に反映しないようにするため、3つのポイントを押さえることを推奨する。
- 特に、時間的な前後関係の判断には、マーケティングコミュニケーション・メディアに関するドメイン知識に従う。
  - 分析者は、マーケティングコミュニケーションであれば変数に利用している調査指標の設問項目や調査方法について、メディアであれば計測対象メディアの投稿方法や計測方法について、マーケターやメディア担当者に問い合わせ、理解を深めることが重要。

### 1. 時間的な前後関係



- 因果関係は、時間的には必ず前・後の関係となる
- モデル構造にマーケティング・メディアの因果関係を反映

### 2. 論理的な非包含関係



- 包含関係にある変数同士を、モデル構造において同階層に並べてはならない
- 目的変数の場合は、モデル構造を分離すべき

### 3. パラメータの 識別可能性条件の充足




- モデル構造仮説をDAG(非巡回有向グラフ)として表現し、シングルドア基準・バックドア基準・フロントドア基準に照合し、適切な説明変数を調整する
- 必要に応じて、介入を行い、バックドアを切断する
- また変数間の関係を表す関数とパラメータの分布を仮定して、データから因果グラフを推論する方法\*1もある

\*1: 変数間の関係を記述するパラメータと関数を仮定して因果グラフを推論する因果探索の方法がある(例: ICアルゴリズム、貪欲等価探索(GES)、LiNGAM、NOTEARSアルゴリズムなど)。これらの方法論は本ガイドブックの範囲外である。また、本節では簡略化のため、グラフはすべてDAG(Directed Acyclic Graph、有向グラフであり、循環グラフではない)とする。

- 因果関係は、時間軸に並べると必ず前後関係になる。時間的に後に起こる出来事 (=その計測データ)は、それに先行する出来事の結果である。
- だからこそ、データの計測方法を熟知し、生活者の購買行動の時間軸上の位置づけと他のデータとの前後関係について、ドメイン知識を活用することが重要である。

## 誤った因果関係＝前後関係が逆



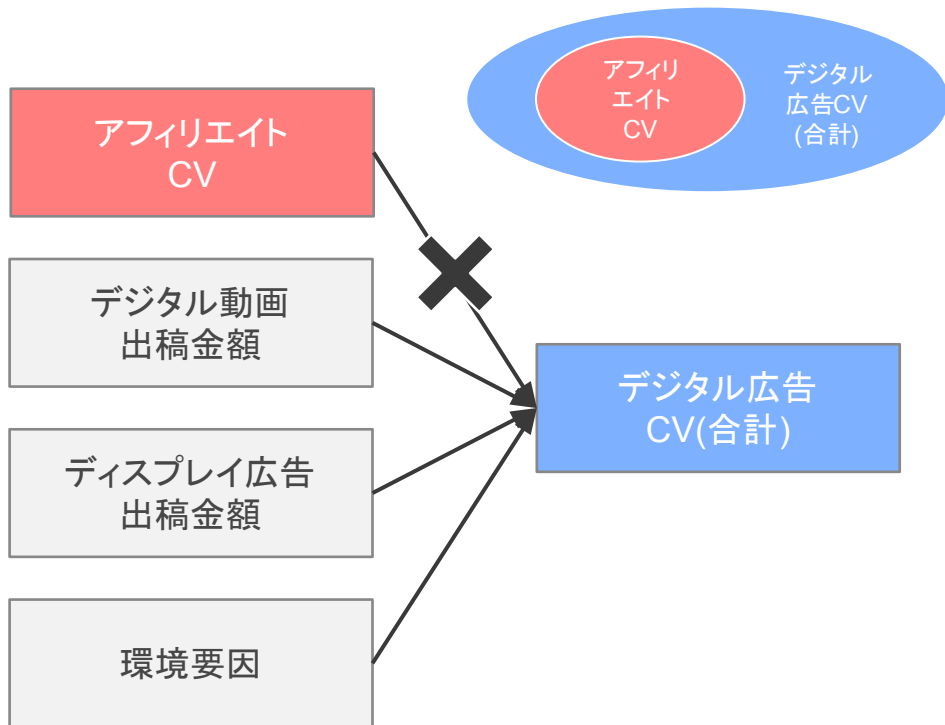
アフィリエイトはCVに対して成果報酬型で出稿金額が決定するため、出稿金額からCVへの因果関係はなく、逆の関係となる

## 適切な因果関係＝前後関係

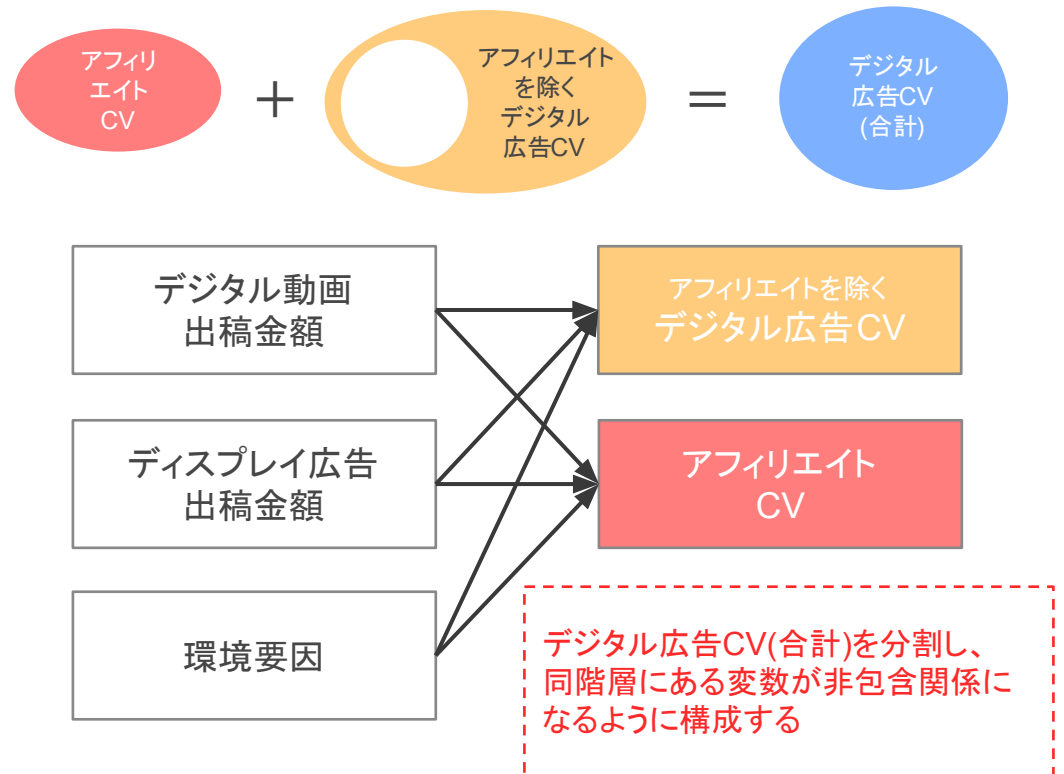


- ある変数と、その変数を数値的に含む上位概念の変数の両方をモデル構造に含めたい場合、変数同士が非包含関係になるようにデータを整形すべきである。
- たとえば、上位概念の変数を論理的に非包含関係の2つの変数に分解し、2つのモデルを作成することが望ましい。

## 誤った因果関係＝包含関係



## 適切な因果関係＝非包含関係に分割




- モデル構造をより現実に近づけるべく、広告出稿だけでなく、サイト来訪や検索量といった中間指標をモデルに組み込む場合、パラメータ識別可能条件に照合し、識別可能なパラメータを峻別する必要がある。なお、点線の双方向の矢印は未観測の共通原因あることを示唆する。
- パラメータ識別可能条件には、シングルドア基準・バックドア基準・フロントドア基準があり、適切な変数を調整(説明変数に加える)することで、注目する因果効果を示すパラメータを計算することが可能になる。3.4.項にて詳細に分析をする。

凡例  
 Y: 目的変数  
 X: 目的変数に対して注目している原因  
 Z: X以外に因果関係が想定される要素  
 U: 未観測の変数  
 → 有向矢線は因果関係の向きを示す  
 ↔ 双方向矢線は交絡していることを示す  
 $r_{AB.C}$ : AをBとCで重回帰したときのBの偏回帰係数  
 $r_{AB}$ : AをBで単回帰したときの回帰係数


パラメータの識別可能性条件

シングルドア基準\*2




- Zはシングルドア基準を満たすため、Zを調整することにより、X→Yへの直接効果 $\alpha$ は識別可能
- 直接効果 $\alpha = r_{YX.Z}$ によって与えられ、 $Y = \alpha X + \beta Z + \varepsilon$ の偏回帰係数 $\alpha$ と一致

バックドア基準\*2



- $Z_2$ はバックドア基準を満たすため、 $Z_2$ を調整することにより、X→Yへの総合効果 $(\alpha + \beta\gamma)$ は識別可能
- 総合効果 $(\alpha + \beta\gamma) = r_{YX.Z_2}$ によって与えられ、 $Y = (\alpha + \beta\gamma)X + \delta Z_2 + \varepsilon$ の偏回帰係数 $(\alpha + \beta\gamma)$ と一致

フロントドア基準\*2



- 因果効果が想定される未観測変数Uが想定される場合でも、フロントドア基準を満たすZを利用することで、X→Yへの総合効果 $\alpha\beta$ は識別可能
- 総合効果 $\alpha\beta$ は、直接効果 $\beta = r_{ZX}$ と $\alpha = r_{YZ.X}$ の積によって与えられる

\*1: 変数間の関係を記述するパラメータと関数を仮定して因果グラフを推論する因果探索の方法がある(例: ICアルゴリズム、貪欲等価探索(GES)、LiNGAM、NOTEARSアルゴリズムなど)。これらの方法論は本ガイドブックの範囲外である。また、本節では簡略化のため、グラフはすべてDAG(Directed Acyclic Graph、有向グラフであり、循環グラフではない)とする。\*2: Judea Pearl "CAUSALITY MODELS, REASONING, AND INFERENCE"(2009)

- オンライン型モデル構造は、ECサイト・アプリ・デジタルサービスなど、オンライン販売のみで成立している場合に適用できる。ハイブリッド型はオンライン型モデル構造に、オフラインルートが加わったもので、耐久財やサービス業に対応できる。CVS・DS・GMSといった流通経路で店舗販売を行う消費財や家電の場合は、オフライン型モデル構造となる。
- 実際にMMMを行う場合には、モデル構造の適切性に関するチェックポイントを参考に検討が必要である。

凡例  
 → 有向矢線は因果関係の向きを示す


各類型はDAG(非巡回有向グラフ)であり、以下を前提としている。  
 ・各要素はメディアの特徴でまとめた変数集合である。MMMを行う際には適切に分解する必要がある。  
 ・因果関係には時間依存がないことを前提とする。  
 ・非観測変数や変数間の交絡は省略しており、その問題点については後述する。

## A. オンライン型\*1,2

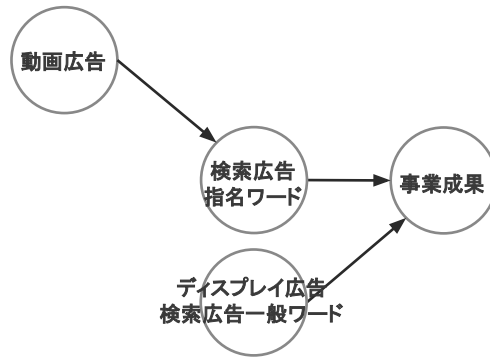
## B. ハイブリッド型\*1,2

## C. オフライン型\*2


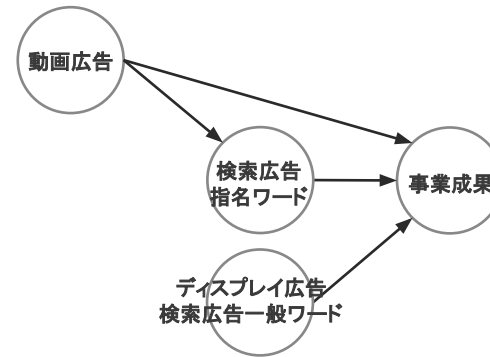
クリックルート



クリックルート+サーチルート



クリック+サーチ+オフラインルート



- 検索広告やディスプレイ広告など、主にクリック課金型のパフォーマンスメディアの出稿によってオンライン CVを獲得する因果関係のみで構成されている

- クリックルートに、サーチルートが加わる
- サーチルートは、テレビやデジタル動画など認知型広告によって認知が変動し、検索数が変化する因果関係を示す

- オンライン型に、オフラインルートが加わる
- オフラインルートは、テレビやデジタル動画広告など認知型広告から直接来店が生じる因果関係を示す

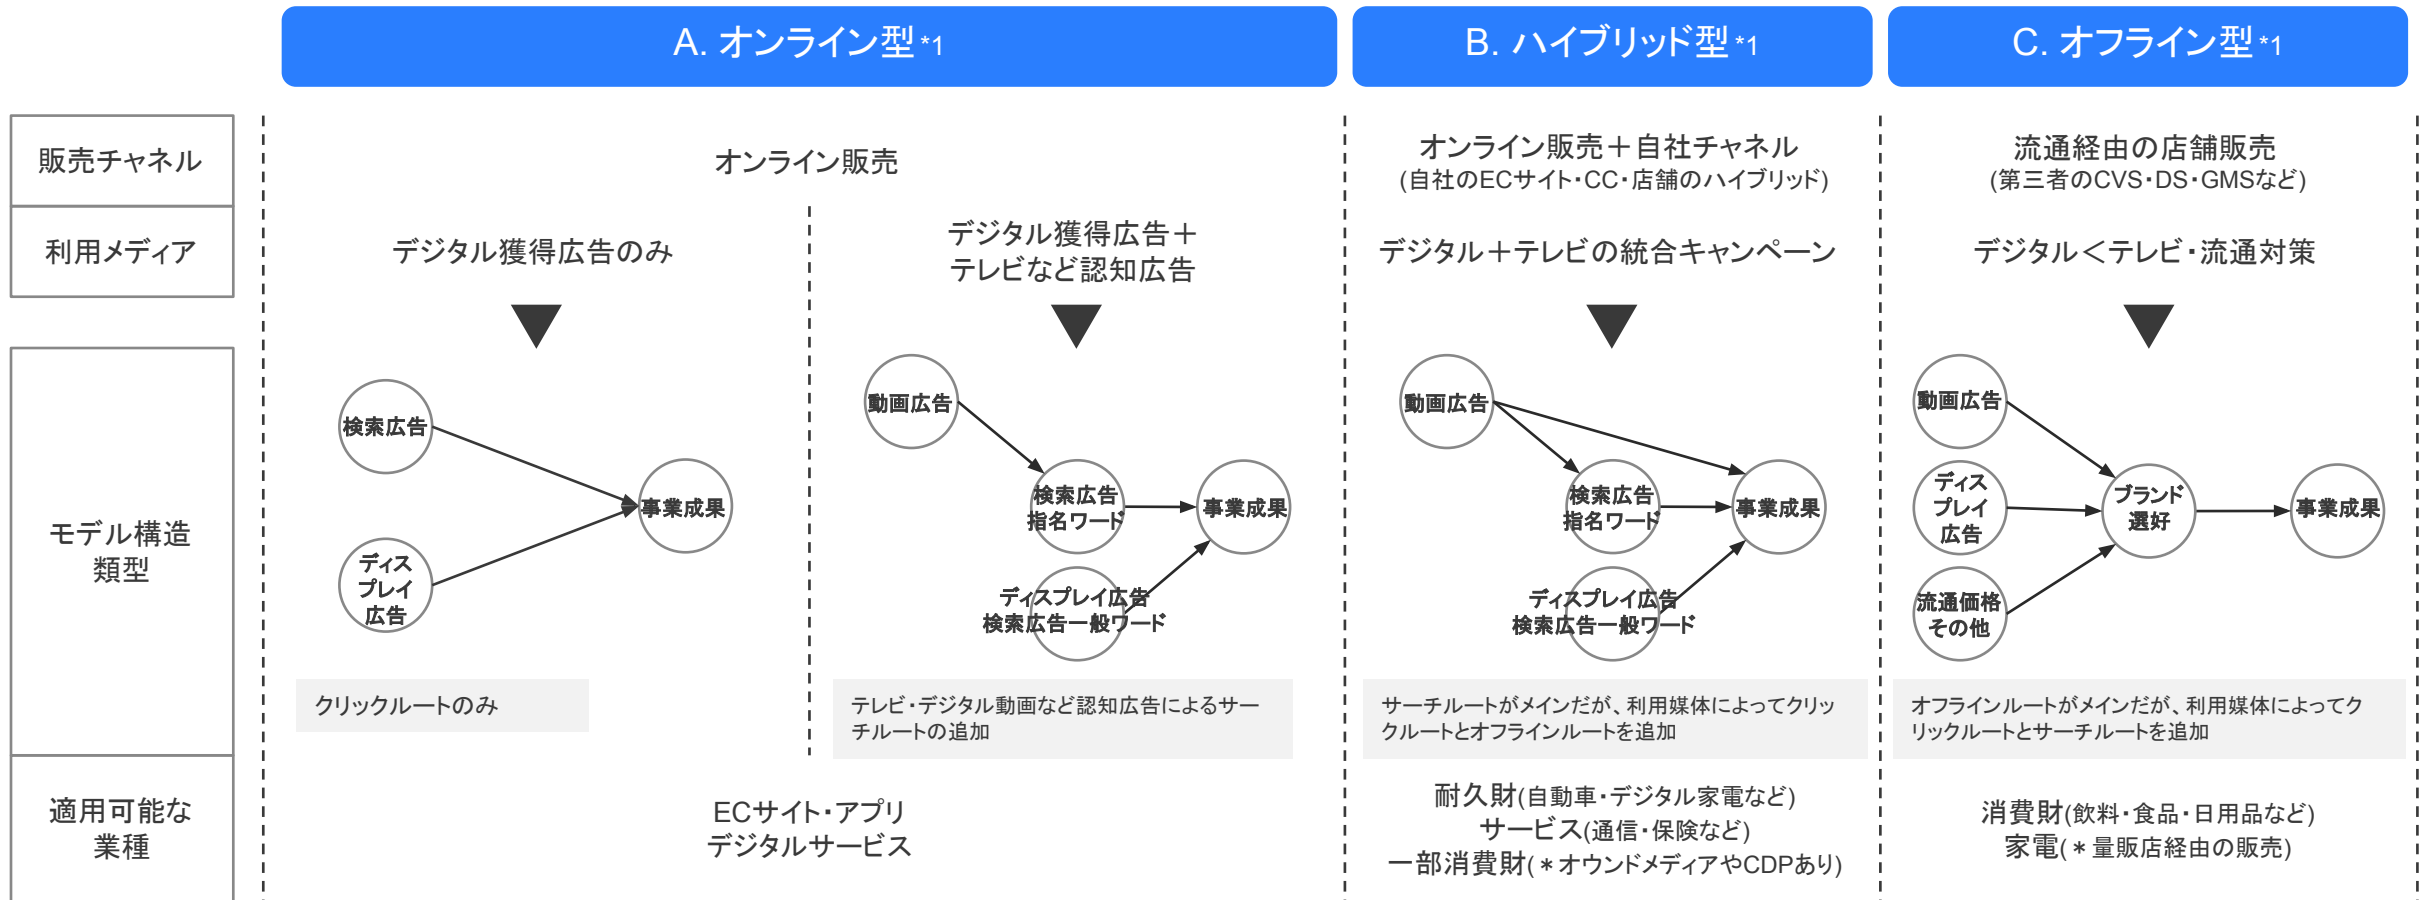
- オフライン型は、テレビやデジタル動画広告など認知型広告によってブランド選択確率が変化し、売上が変動する因果関係を示す

\*1: 検索広告に関しては、本来は指名検索量も考慮した考察が必要であるが、単純化のため、ここでは省略している2: 両方向の点線の矢印で示されている交絡未観測の共通原因の存在は、上図では例であり、ビジネスにより異なる場合があるため、都度検討が必要である。例えば、オンライン型における季節性による検索広告の投資額とオンラインの売上、オフライン型における広告出稿額と配架率にはビジネス慣行による相関がある場合もある。

- モデル構造の適切性に関するチェックポイントを踏まえると、実用的な MMMの一般的なモデル構造は、生活者への商品・サービスのセールスルートにより、オンライン型・ハイブリッド型・オフライン型の3つに類型化できる。
- オンライン型は、広告をクリックさせ CVを獲得するクリックルートと、認知を向上し検索数を増加させるサーチルートによって構成される。

凡例  
 →有向矢線は因果関係の向きを示す

各類型はDAG(非巡回有向グラフ)であり、以下を前提としている。  
 ・各要素はメディアの特徴でまとめた変数集合である。MMMを行う際には適切に分解する必要がある。  
 ・因果関係には時間依存がないことを前提とする。  
 ・非観測変数や変数間の交絡は省略しており、その問題点については後述する。



\*1: 本ページに掲載しているモデル構造は例であり、ビジネスにより異なることがある。前ページの注釈を参照。



## 3.2. モデル構造が分析結果に与える影響の検証

---

- モデル構造は、生活者への商品・サービスのセールスルートによって3つに類型化できるが、モデル構造の作成には分析者の主観や経験が大きく作用するプロセスである。
- そこで本節では、シンプルなオンライン型を例に、真のデータ生成過程（現実の生活者行動）と異なるモデル構造(MMMのモデル構造仮説)を採用することが分析結果に与える影響を検証することで、不十分なモデル構造の検討が及ぼすリスクを確認したい。

凡例  
 → 有向矢線は因果関係の向きを示す

各類型はDAG(非巡回有向グラフ)であり、以下を前提としている。


- ・各要素はメディアの特徴でまとめた変数集合である。MMMを行う際には適切に分解する必要がある。
- ・因果関係には時間依存がないことを前提とする。
- ・非観測変数や変数間の交絡は省略しており、その問題点については後述する。

## A. オンライン型\*1

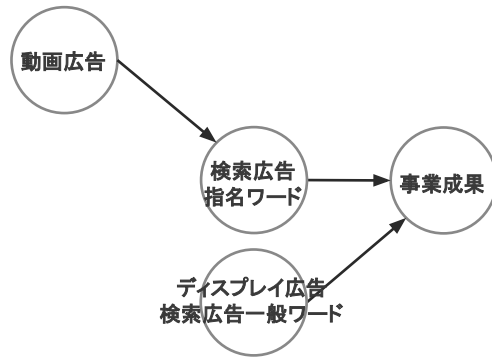
## B. ハイブリッド型\*1

## C. オフライン型

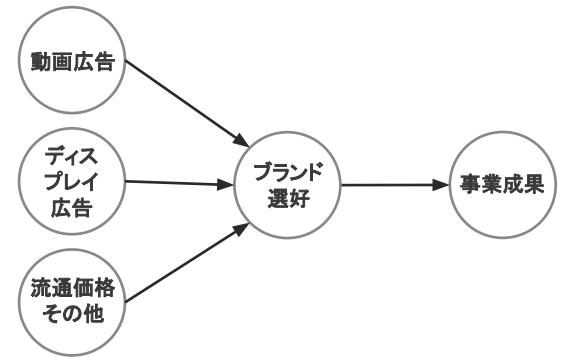
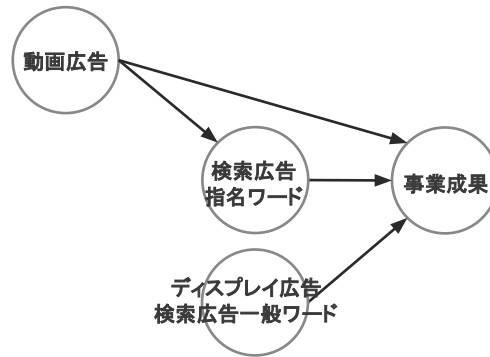
クリックルート



クリックルート+サーチルート



クリック+サーチ+オフラインルート



- ・ 検索広告やディスプレイ広告など、主にクリック課金型のパフォーマンスメディアの出稿によってオンライン CVを獲得する因果関係のみで構成されている

- ・ クリックルートに、サーチルートが加わる
- ・ サーチルートは、テレビやデジタル動画など認知型広告によって認知が変動し、検索数が変化する因果関係を示す

- ・ オンライン型に、オフラインルートが加わる
- ・ オフラインルートは、テレビやデジタル動画広告など認知型広告から直接来店が生じる因果関係を示す

- ・ オフライン型は、テレビやデジタル動画広告など認知型広告によってブランド選択確率が変化し、売上が変動する因果関係を示す

\*1: 検索広告に関しては、本来は指名検索量も考慮した考察が必要であるが、単純化のため、ここでは省略している。

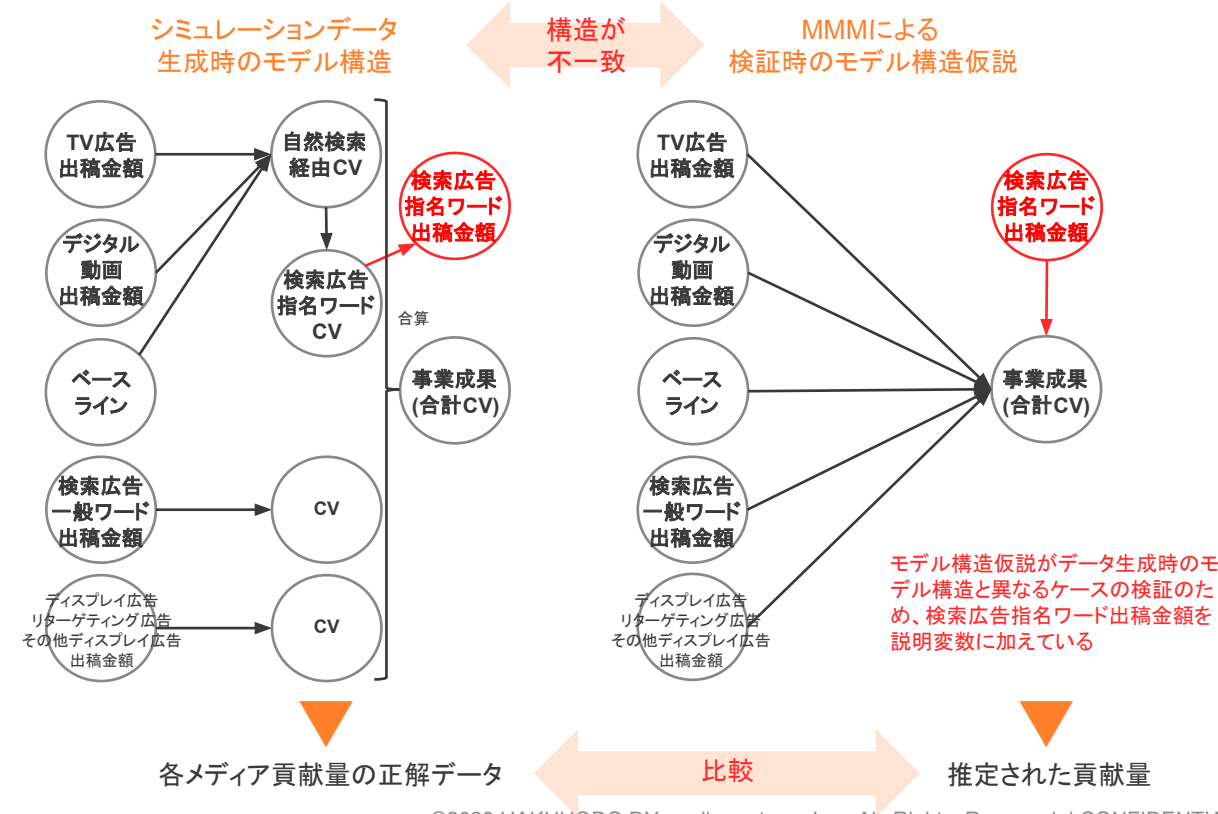
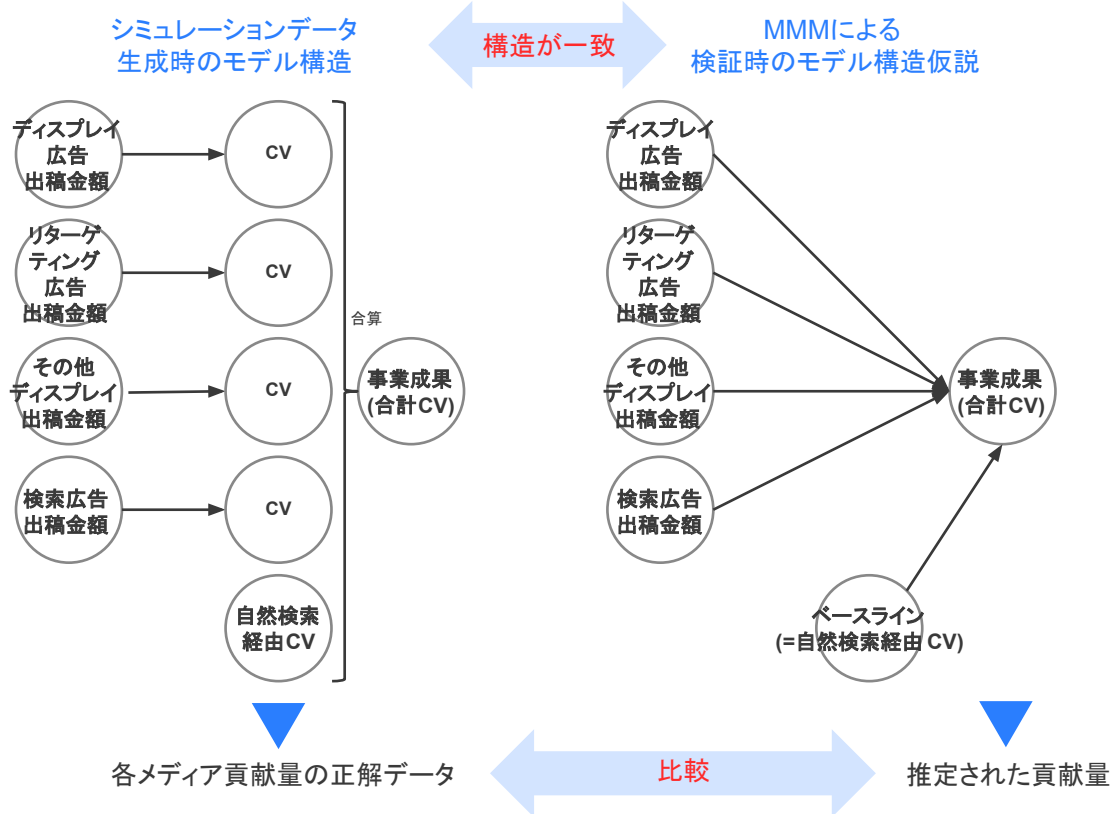
- シミュレーションスタディでは、シミュレーションデータが生成されるモデル構造と、MMMを行う際に採用するモデル構造仮説が一致している場合 (シナリオ①)と一致していない場合 (シナリオ②)で、生成したシミュレーションデータ=正解データとMMMで推定された貢献量を比較する。
- シナリオ②では、MMMを行う際には、シミュレーションデータ生成時の構造とは異なり、本来2階層になるサーチャルートを含めて、シンプルに広告出稿量で目的変数を予測する1階層のモデル構造を採用した。

凡例  
 → 有向矢線は因果関係の向きを示す

各類型はDAG(非巡回有向グラフ)であり、以下を前提としている。  
 ・各要素はメディアの特徴でまとめた変数集合である。MMMを行う際には適切に分解する必要がある。  
 ・因果関係には時間依存がないことを前提とする。  
 ・非観測変数や変数間の交絡は省略しており、その問題点については後述する。

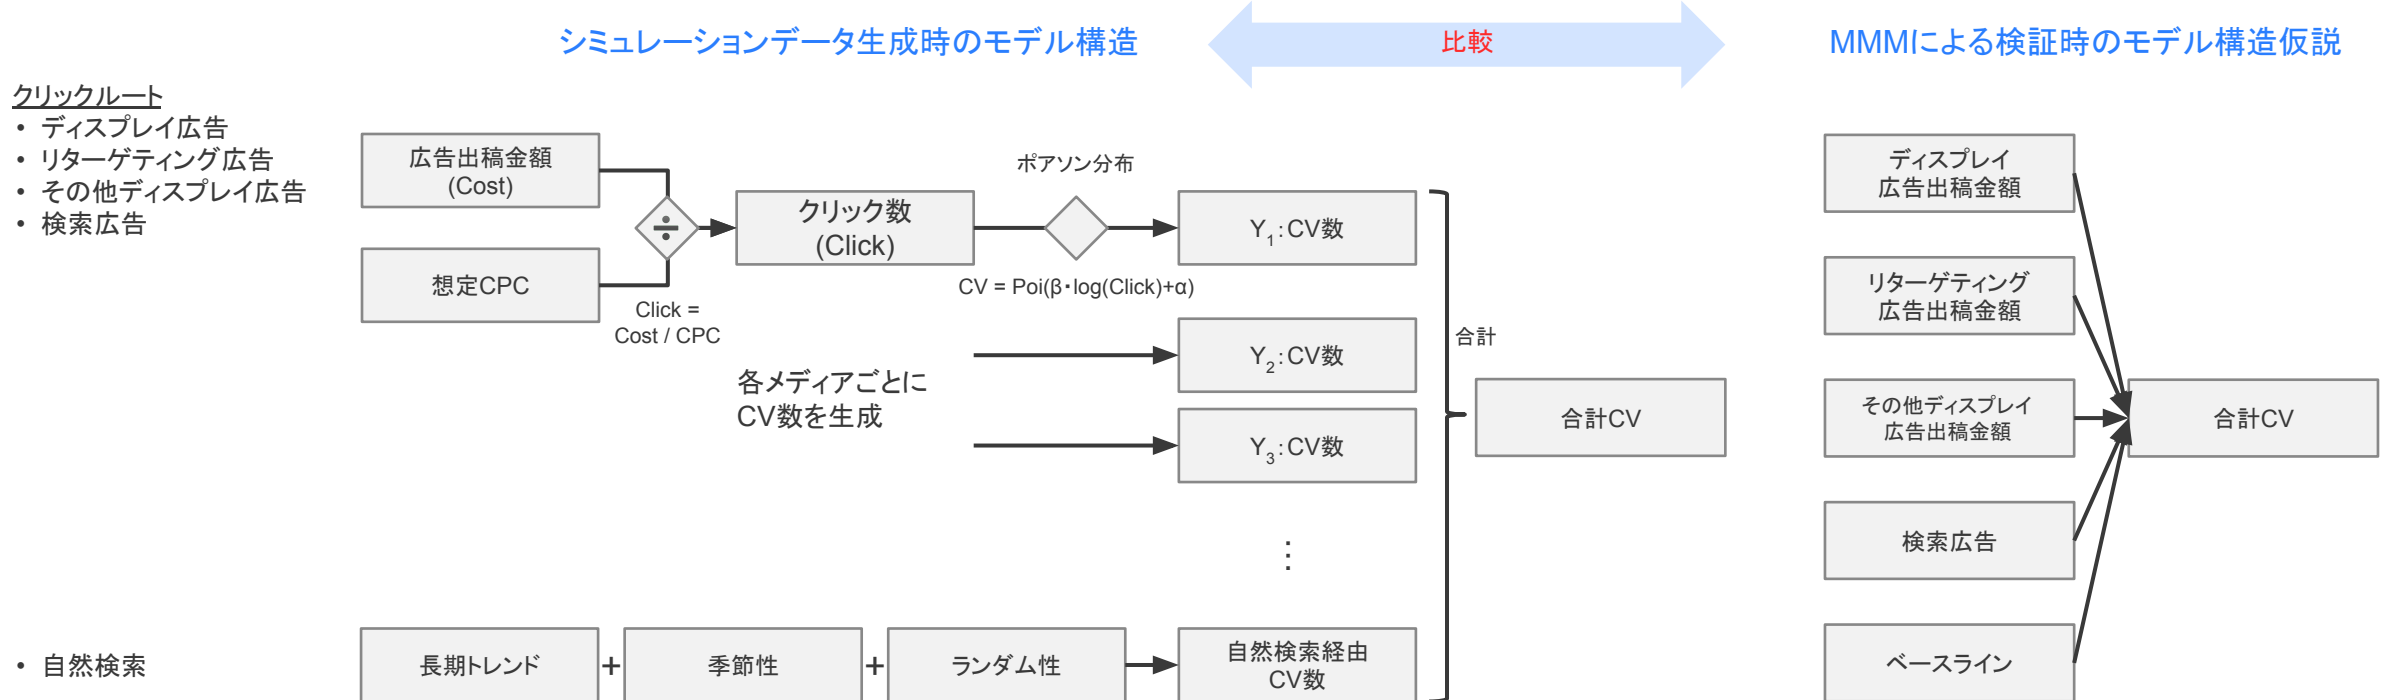
## シナリオ① クリックルートの検証

## シナリオ② クリック+サーチャルートの検証



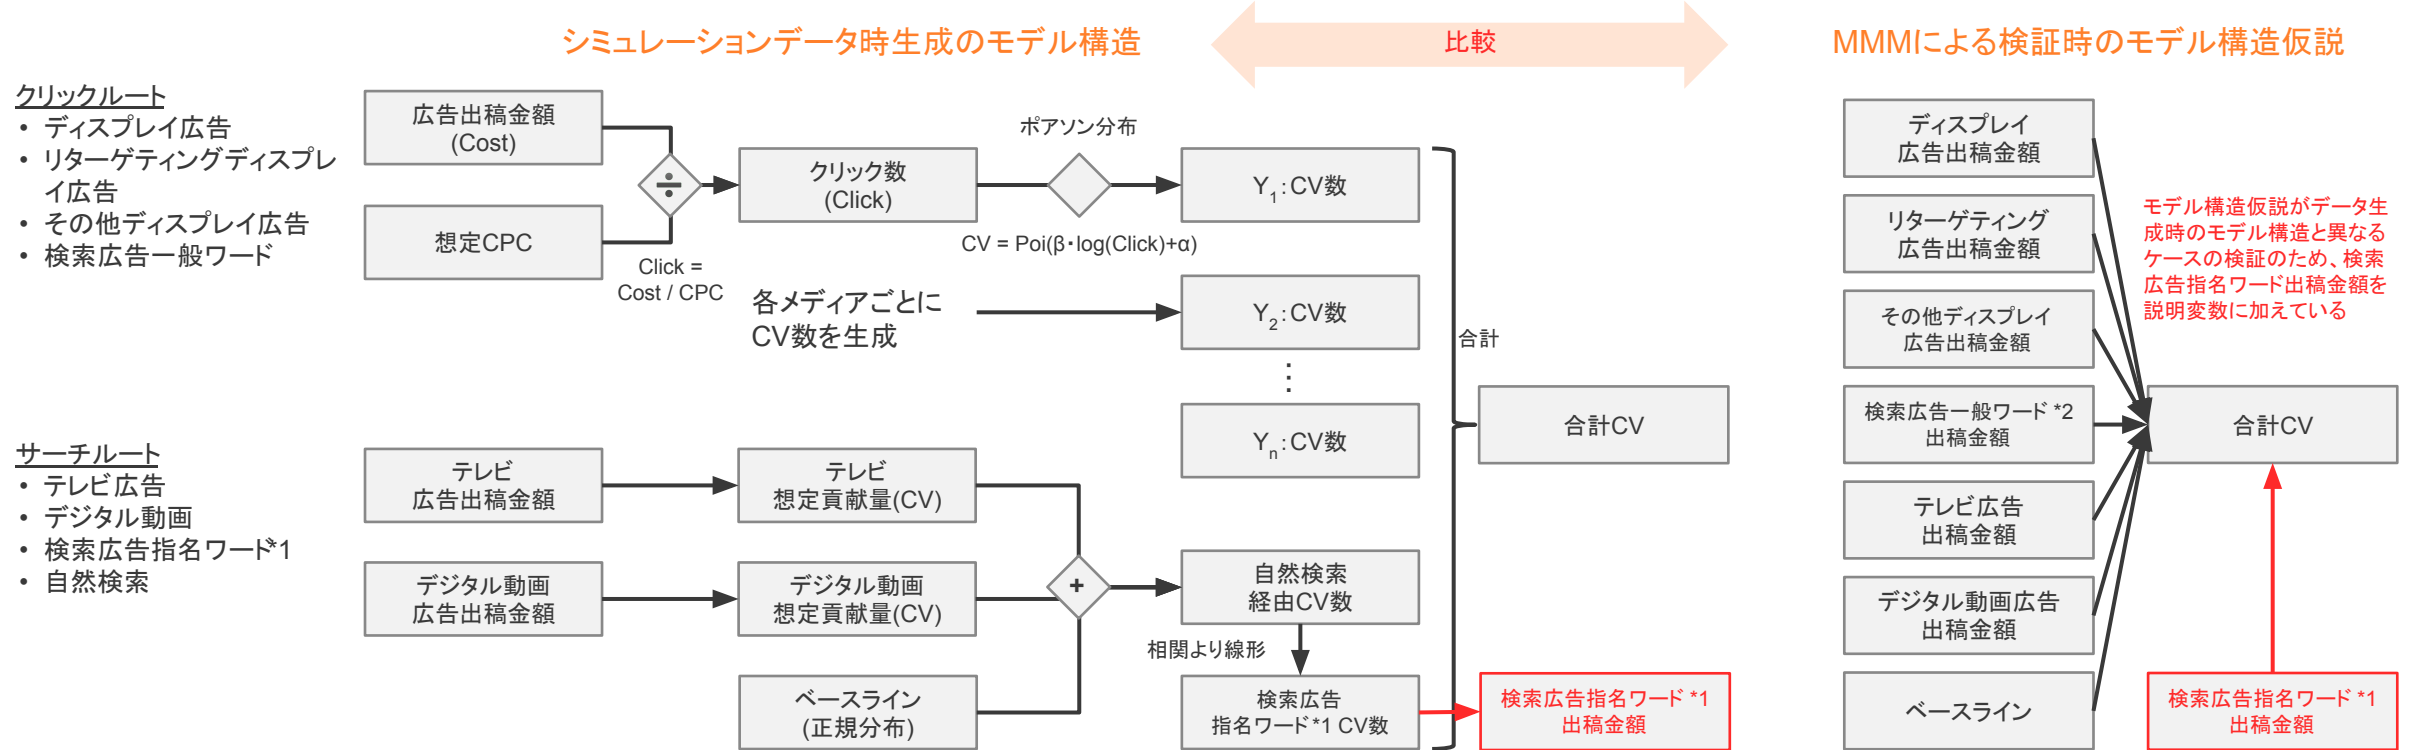
- オンライン型クリックルートの場合、広告出稿金額によりクリック数や CV数といった結果が変動するシンプルなデータ生成過程を想定できる。メディア相互の関係は独立と仮定する。
- メディアごとにCV数のシミュレーションデータを生成し、メディアごとの貢献量の正解データとする。そして合計 CVをMMMの目的変数とする。またメディア出稿に依存しない自然検索経由の CV数は季節性・トレンドを加味したシミュレーションデータを別途用意した。
- シナリオ①では、データ生成時と MMM検証時のモデル構造は一致している。

## シナリオ① クリックルートの検証



- オンライン型サーチルートは、テレビ広告・デジタル動画出稿金額によって自然検索経由 CV数・リスティング指名検索 CV数が変化するという2階層のデータ生成過程とした。クリックルートはシナリオ①と同様である。
- MMMを行う際は合計CVを目的変数とし、各メディアの広告出稿金額を説明変数とする1階層モデルを適用する。つまり、シナリオ②ではデータ生成時とMMM検証時のモデル構造が一致していないケースである。
  - データ生成過程では検索広告指名ワード出稿金額はCV数に従属して決定されるため、本来は説明変数に加えるべきではないが、誤ったモデル構造が与える影響を検証するため、意図的に説明変数に加えている。

## シナリオ② クリック+サーチルートの検証



\*1:検索広告指名ワードは、検索広告のうちブランドキーワードキャンペーンを指す。検索広告指名ワード経由CV数は、テレビ広告・デジタル動画の出稿金額から生成され、出稿金額はCV数に従属して生成される。

\*2:検索広告一般ワードは、検索広告のうち、カテゴリキーワードなどのブランドキーワードキャンペーン以外を指す

- シミュレーションスタディでは、シナリオ①と②で生成したシミュレーションデータに対して、シンプルな1階層モデル (Lightweight MMM) を適用し、MMMによる推定貢献量 (各メディアの推定貢献量 (CV数))とシミュレーションデータの正解データを比較する。

## 1階層モデル\*1

$$Revenue_t = b + \sum_m \beta_m * Hill (Adstock(x_{t,m}, \dots, x_{t-l,m}; L, w_m(l; \alpha_m, \theta_m)), K_m, S_m) + trend_t + seas_t + \sum_c \gamma_c d_{t,c} + \epsilon_t$$

### モデル構造の前提\*1


- モデルでは加法的線形構造が仮定されているため、メディア変数は互いに独立である。(例えば、TV/YouTubeと検索広告量の間には依存関係はない)。
- 自然検索量は変数として含まれない。
- このモデルでは、非メディア変数は利用しない(すなわち、トレンドと季節性は、それぞれ凹曲線と正弦関数でモデル化される)。

### パラメータの前提\*1


- メディア変数にはHILL関数(p.46)と幾何アドストック(p.49)を仮定。(LightweightMMMにおける“hill\_adstock”を利用)
- 潜在的な未観測トレンドと季節性、各パラメータの事前分布についてはLightweightMMMにおけるデフォルトの設定を利用。

## シミュレーションデータ

### シナリオ①クリックルートで生成されたシミュレーションデータ




### シナリオ②クリック+サーチルートで生成されたシミュレーションデータ




1階層モデルの適用

## 比較

### 真のCV数(シミュレーションデータとMMMによる推定貢献量の比較)



### 真のCV数(シミュレーションデータとMMMによる推定貢献量の比較)



\*1: 検証に利用する1階層モデルは、2023年9月時点のGoogle非公式のオープンソースであるLightweight MMMである。

## 3.3. シミュレーションスタディ

---

- クリックルートのシミュレーション結果を示す。
- シナリオ①ではシミュレーションデータ生成時の真のモデル構造と適用する MMMのモデル構造が一致している。

1階層モデル\*1

$$Revenue_t = b + \sum_m \beta_m * Hill(Adstock(x_{t,m}, \dots, x_{t-l,m}; L, w_m(l; \alpha_m, \theta_m)), K_m, S_m) + trend_t + seas_t + \sum_c \gamma_c d_{t,c} + \epsilon_t$$

モデル構造の前提\*1

- モデルでは加法的線形構造が仮定されているため、メディア変数は互いに独立である。(例えば、TV/YouTubeと検索広告量の間には依存関係はない)。
- 自然検索量は変数として含まれない。
- このモデルでは、非メディア変数は利用しない(すなわち、トレンドと季節性は、それぞれ凹曲線と正弦関数でモデル化される)。


パラメータの前提\*1

- メディア変数にはHILL関数(p.46)と幾何アドストック(p.49)を仮定。(LightweightMMMにおける“hill\_adstock”を利用)
- 潜在的な未観測トレンドと季節性、各パラメータの事前分布についてはLightweightMMMにおけるデフォルトの設定を利用。


1階層モデルの適用

シミュレーションデータ

シナリオ①クリックルートで生成されたシミュレーションデータ




シナリオ②クリック+サーチルートで生成されたシミュレーションデータ




比較

真のCV数(シミュレーションデータとMMMによる推定貢献量の比較)



真のCV数(シミュレーションデータとMMMによる推定貢献量の比較)




\*1: 検証に利用する1階層モデルは、2023年9月時点のGoogle非公式のオープンソースであるLightweight MMMである。








前述のシミュレーションデータ生成方法により、自然検索経由(=ベースライン)の割合が目的変数(合計CV)の95%となるように、正解データを生成。

▼シミュレーションデータ



- 凡例
- ディスプレイ広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の出稿金額とV数
  - リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の出稿金額とV数
  - その他ディスプレイ広告: 静止画フォーマットの予約型広告の出稿金額とCV数
  - 検索広告: 検索広告の出稿金額とV数。クリックルートでは、指名ワードのように検索ボリュームに制約のない一般ワードキャンペーンとしている
  - 自然検索経由: 上記広告経由以外のCV数
  - それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMによる推定量を示す









1階層モデルを適用すると、  
 $R^2=0.96$ ・ $MAPE=0.08$ と高い精度となった。  
 目的変数のシミュレーションデータはMMMによる  
 推定値の95%信用区間に収まっている。

ただし各メディアの推定貢献量はシミュレーション  
 データとの間に誤差があり、MAPE(平均絶対誤  
 差率)で約1.3~5.2(2.3~6.2倍)となっている。

- 凡例
- ディスプレイ広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の出稿金額とV数
  - リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の出稿金額とV数
  - その他ディスプレイ広告: 静止画フォーマットの予約型広告の出稿金額とCV数
  - 検索広告: 検索広告の出稿金額とV数。クリックルートでは、指名ワードのように検索ボリュームに制約のない一般ワードキャンペーンとしている
  - 自然検索経由: 上記広告経由以外のCV数
  - それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMによる推定量を示す


## ▼MMMによる推定値



\*1:シミュレーションデータと各メディア推定量の MAPE(平均絶対誤差率)を倍率に換算






続いて、自然検索経由(=ベースライン)の割合を目的変数(合計CV)の90%に引き下げ、正解データを生成。

▼シミュレーションデータ



凡例

- ディスプレイ広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の投稿金額とV数
- リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の投稿金額とV数
- その他ディスプレイ広告: 静止画フォーマットの予約型広告の投稿金額とCV数
- 検索広告: 検索広告の投稿金額とV数。クリックルートでは、指名ワードのように検索ボリュームに制約のない一般ワードキャンペーンとしている
- 自然検索経由: 上記広告経由以外のCV数
- それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMによる推定量を示す









1階層モデルを適用すると、  
 $R^2=0.96$ ・ $MAPE=0.078$ と高い精度となった。  
 目的変数と各メディアのシミュレーションデータは  
 MMMIによる推定値の95%信用区間に収まっている。

各メディアの推定貢献量はシミュレーションデータ  
 と誤差が生じており、MAPE(平均絶対誤差率)で  
 約0.5~1.9(1.5~2.9倍)となっている。これは、パ  
 ターンA.ベースライン95%のシミュレーションより  
 は誤差が縮小している。

### 凡例

- ディスプレイ広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の出稿金額とV数
- リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の出稿金額とV数
- その他ディスプレイ広告: 静止画フォーマットの予約型広告の出稿金額とCV数
- 検索広告: 検索広告の出稿金額とV数。クリックルートでは、指名ワードのように検索ボリュームに制約のない一般ワードキャンペーンとしている
- 自然検索経由: 上記広告経由以外のCV数
- それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMIによる推定量を示す


### ▼MMMIによる推定値



\*1:シミュレーションデータと各メディア推定量の MAPE(平均絶対誤差率)を倍率に換算






続いて、自然検索経由(=ベースライン)の割合を目的変数(合計CV)の80%に引き下げ、正解データを生成。

▼シミュレーションデータ



凡例


- ディスプレイ広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の出稿金額とV数
- リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の出稿金額とV数
- その他ディスプレイ広告: 静止画フォーマットの予約型広告の出稿金額とCV数
- 検索広告: 検索広告の出稿金額とV数。クリックルートでは、指名ワードのように検索ボリュームに制約のない一般ワードキャンペーンとしている
- 自然検索経由: 上記広告経由以外のCV数
- それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMによる推定量を示す








1階層モデルを適用すると、  
 $R^2=0.95$ ・ $MAPE=0.08$ と高い精度となった。  
 目的変数と、ディスプレイ広告以外の各メディアの  
 シミュレーションデータはMMMによる推定値の  
 95%信用区間に収まっている。

各メディアの推定貢献量とシミュレーションデータ  
 との誤差はパターンB.ベースライン90%よりも縮  
 小しており、MAPE(平均絶対誤差率)で約0.5~  
 0.6(1.5~1.6倍)である。

## ▼MMMによる推定値




- 凡例
- ディ스플레이広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の出稿金額とV数
  - リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の出稿金額とV数
  - その他ディスプレイ広告: 静止画フォーマットの予約型広告の出稿金額とCV数
  - 検索広告: 検索広告の出稿金額とV数。クリックルートでは、指名ワードのように検索ボリュームに制約のない一般ワードキャンペーンとしている
  - 自然検索経由: 上記広告経由以外のCV数
  - それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMによる推定量を示す



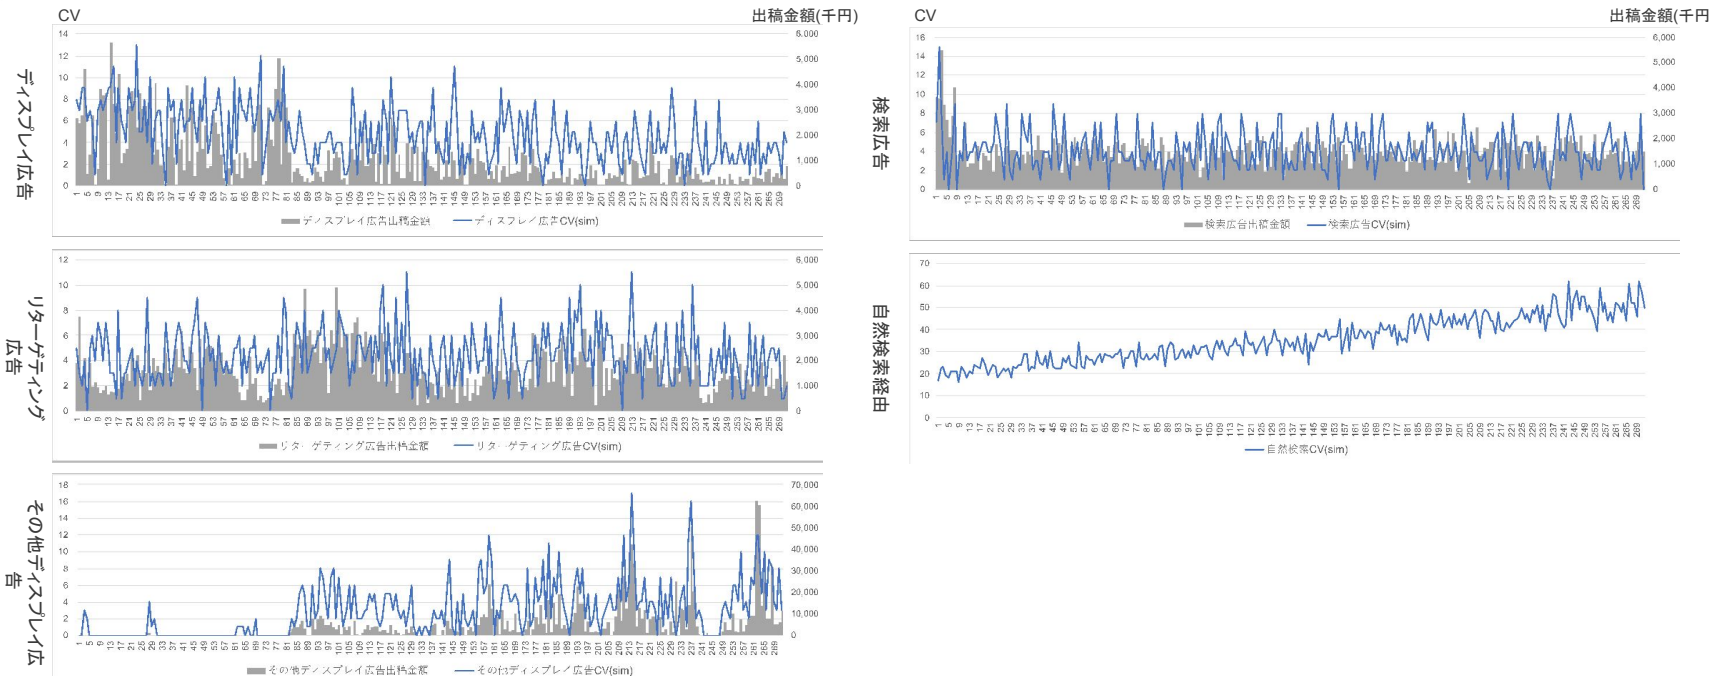
\*1:シミュレーションデータと各メディア推定量の MAPE(平均絶対誤差率)を倍率に換算

前述のシミュレーションデータ生成方法により、自然検索経由(=ベースライン)の割合が目的変数(合計CV)の70%となるように、正解データを生成。

## ▼シミュレーションデータ



- 凡例
- ディスプレイ広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の出稿金額とV数
  - リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の出稿金額とV数
  - その他ディスプレイ広告: 静止画フォーマットの予約型広告の出稿金額とCV数
  - 検索広告: 検索広告の出稿金額とV数。クリックルートでは、指名ワードのように検索ボリュームに制約のない一般ワードキャンペーンとしている
  - 自然検索経由: 上記広告経由以外のCV数
  - それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMによる推定量を示す









1階層モデルを適用すると、  
 $R^2=0.93$ ・ $MAPE=0.09$ と高い精度となった。  
 目的変数のシミュレーションデータはMMMによる推定値の95%信用区間に収まっている一方、各メディアのシミュレーションデータは95%信用区間に収まっていない。

また各メディアの推定貢献量とシミュレーションデータとの誤差は縮まり、MAPE(平均絶対誤差率)が約0.5~0.6(1.5~1.6倍)となった。

- 凡例
- ディスプレイ広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の出稿金額とV数
  - リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の出稿金額とV数
  - その他ディスプレイ広告: 静止画フォーマットの予約型広告の出稿金額とCV数
  - 検索広告: 検索広告の出稿金額とV数。クリックルートでは、指名ワードのように検索ボリュームに制約のない一般ワードキャンペーンとしている
  - 自然検索経由: 上記広告経由以外のCV数
  - それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMによる推定量を示す

## ▼MMMによる推定値




\*1: シミュレーションデータと各メディア推定量の MAPE(平均絶対誤差率)を倍率に換算








前述のシミュレーションデータ生成方法により、自然検索経由(=ベースライン)の割合が目的変数(合計CV)の50%となるように、正解データを生成。

## ▼シミュレーションデータ



### 凡例

- ディスプレイ広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の出稿金額とV数
- リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の出稿金額とV数
- その他ディスプレイ広告: 静止画フォーマットの予約型広告の出稿金額とCV数
- 検索広告: 検索広告の出稿金額とV数。クリックルートでは、指名ワードのように検索ボリュームに制約のない一般ワードキャンペーンとしている
- 自然検索経由: 上記広告経由以外のCV数
- それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMによる推定量を示す









1階層モデルを適用すると、 $R^2=0.87$ ・ $MAPE=0.11$ と高い精度となった。目的変数のシミュレーションデータはMMMによる推定値の95%信用区間に収まっている一方、各メディアの貢献量は95%信用区間に収まっていない。

その他ディスプレイ広告のみ、トレンドを捕捉している。

また各メディアの推定貢献量とシミュレーションデータとの誤差が縮まり、MAPE(平均絶対誤差率)で約0.5~0.7(1.5~1.7倍)となった。

- 凡例
- ディスプレイ広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の出稿金額とV数
  - リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の出稿金額とV数
  - その他ディスプレイ広告: 静止画フォーマットの予約型広告の出稿金額とCV数
  - 検索広告: 検索広告の出稿金額とV数。クリックルートでは、指名ワードのように検索ボリュームに制約のない一般ワードキャンペーンとしている
  - 自然検索経由: 上記広告経由以外のCV数
  - それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMによる推定量を示す

## ▼MMMによる推定値



\*1: シミュレーションデータと各メディア推定量の MAPE(平均絶対誤差率)を倍率に換算

- クリック+サーチルートのシミュレーション結果を示す。
- シナリオ②ではシミュレーションデータ生成時の真のモデル構造と適用する MMMのモデル構造が一致していない。
  - サーチルートは2階層構造で生成しているが、当てはめたモデルは1階層モデルである。

## 1階層モデル\*1

$$Revenue_t = b + \sum_m \beta_m * Hill(Adstock(x_{t,m}, \dots, x_{t-l,m}; L, w_m(l; \alpha_m, \theta_m)), K_m, S_m) + trend_t + seas_t + \sum_c \gamma_c d_{t,c} + \epsilon_t$$

### モデル構造の前提\*1


- モデルでは加法的線形構造が仮定されているため、メディア変数は互いに独立である。(例えば、TV/YouTubeと検索広告量の間には依存関係はない)。
- 自然検索量は変数として含まれない。
- このモデルでは、非メディア変数は利用しない(すなわち、トレンドと季節性は、それぞれ凹曲線と正弦関数でモデル化される)。

### パラメータの前提\*1


- メディア変数にはHILL関数(p.46)と幾何アドストック(p.49)を仮定。(LightweightMMMにおける“hill\_adstock”を利用)
- 潜在的な未観測トレンドと季節性、各パラメータの事前分布については [LightweightMMMにおけるデフォルトの設定](#) を利用。

## シミュレーションデータ

### シナリオ①クリックルートで生成されたシミュレーションデータ




### シナリオ②クリック+サーチルートで生成されたシミュレーションデータ




## 比較

### 真のCV数(シミュレーションデータとMMMによる推定貢献量の比較)



### 真のCV数(シミュレーションデータとMMMによる推定貢献量の比較)



1階層モデルの適用

\*1: 検証に利用する1階層モデルは、2023年9月時点のGoogle非公式のオープンソースであるLightweight MMMである。

前述のシナリオ②のシミュレーションデータ生成方法により、サーチルートのCV(検索広告指名ワード+自然検索経由)がCV全体の90%を占めるように正解データを生成。

検索広告(指名ワード)と自然検索経由のCVは50%・50%となるようにした。










またテレビ広告出稿量はタイムの割合によっては均一な出稿が続き、分散が小さくなり、スポット出稿によって山が形成される様を模した。

クリックルートのディスプレイ広告・リターゲティング広告・その他ディスプレイ広告・検索広告一般ワードはシナリオ①同様に、それぞれ独立で生成。

凡例

- ディスプレイ広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の出稿金額と CV数
- リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の出稿金額と CV数
- その他ディスプレイ広告: 静止画フォーマットの予約型広告の出稿金額とCV数
- 検索広告一般ワード: 検索広告のうち、ブランドキーワードを除いたカテゴリキーワードなど一般キーワードキャンペーンの出稿金額と CV数
- 検索広告指名ワード: 検索広告のうち、ブランドキーワードキャンペーンの直接効果としての CV数。テレビ広告・デジタル動画による間接効果としての CV数を除く。
- 自然検索経由: 自然検索経由の直接効果としての CV数。テレビ広告・デジタル動画による間接効果としての貢献を除く
- テレビ広告: テレビ広告の出稿金額と、検索広告指名ワード・自然検索への間接効果としての CV数の合計
- デジタル動画: デジタル動画の出稿金額と、検索広告指名ワード・自然検索への間接効果としての貢献 CV数の合計
- それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMによる推定量を示す

## ▼シミュレーションデータ



1階層モデルを適用すると、  
R2=0.88・MAPE=0.06と高い精度となった。










合計CVの90%を占めるサーチルートの貢献量が正しく推定できていないため、目的変数のシミュレーションデータはMMMによる推定値の95%信用区間に収まっていない。特に、テレビ広告の間接効果としての貢献量・検索広告指名ワードの直接効果としての貢献量が過小評価され、誤差が約9.8倍となっている。

クリックルートでは、ディスプレイ広告以外のメディアは95%信用区間に収まり、サーチルートと比べると誤差は小さい。

### 凡例

- ディ스플레이広告: 静止画フォーマットのリターゲティング以外の配信方法による、運用型広告の出稿金額と CV数
- リターゲティング広告: 静止画フォーマットのリターゲティング配信による運用型広告の出稿金額と CV数
- その他ディスプレイ広告: 静止画フォーマットの予約型広告の出稿金額とCV数
- 検索広告一般ワード: 検索広告のうち、ブランドキーワードを除いたカテゴリキーワードなど一般キーワードキャンペーンの出稿金額と CV数
- 検索広告指名ワード: 検索広告のうち、ブランドキーワードキャンペーンの直接効果としての CV数。テレビ広告・デジタル動画による間接効果としての CV数を除く。
- 自然検索経由: 自然検索経由の直接効果としての CV数。テレビ広告・デジタル動画による間接効果としての貢献を除く
- テレビ広告: テレビ広告の出稿金額と、検索広告指名ワード・自然検索への間接効果としての CV数の合計
- デジタル動画: デジタル動画の出稿金額と、検索広告指名ワード・自然検索への間接効果としての貢献 CV数の合計
- それぞれ(sim)はシミュレーションデータ=正解データ、(pred)はMMMによる推定量を示す

## ▼MMMによる推定値



\*1: シミュレーションデータと各メディア推定量のMAPE(平均絶対誤差率を倍率に換算

- シミュレーションスタディでは1階層モデルは、シナリオ①クリックルートでは概ね機能するが、シナリオ②クリック+サーチルートでは機能しないことがわかった。
- シナリオ②のサーチルート(テレビ・デジタル動画広告によって検索広告指名ワードの CVが生じる)のように階層型構造のデータ生成過程に対して1階層モデルを適用するモデル構造仮説の誤りによって、メディア貢献量の推定を誤るリスクが大きい。
- また、目的変数全体に占める割合やデータの分散が極度に小さい場合に、推定貢献量の誤差が大きくなる可能性がある。

## 1階層モデル\*1

$$Revenue_t = b + \sum_m \beta_m * Hill(Adstock(x_{t,m}, \dots, x_{t-L,m}; L, W_m(l; \alpha_m, \theta_m)), K_m, S_m) + trend_t + seas_t + \sum_c \gamma_c d_{t,c} + \epsilon_t$$

### モデル構造の前提1


- モデルでは加法的線形構造が仮定されているため、メディア変数は互いに独立である。(例えば、TV/YouTubeと検索広告量の間には依存関係はない)。
- 自然検索量は変数として含まれない。
- このモデルでは、非メディア変数は利用しない(すなわち、トレンドと季節性は、それぞれ凹曲線と正弦関数でモデル化される)。

### パラメータの前提1


- メディア変数にはHILL関数(p.46)と幾何アドストック(p.49)を仮定。(LightweightMMMにおける“hill\_adstock”を利用)
- 潜在的な未観測トレンドと季節性、各パラメータの事前分布についてはLightweightMMMにおけるデフォルトの設定を利用。

## シミュレーションデータ

### シナリオ①クリックルートで生成されたシミュレーションデータ



### シナリオ②クリック+サーチルートで生成されたシミュレーションデータ



1階層モデルの適用

## 分析結果

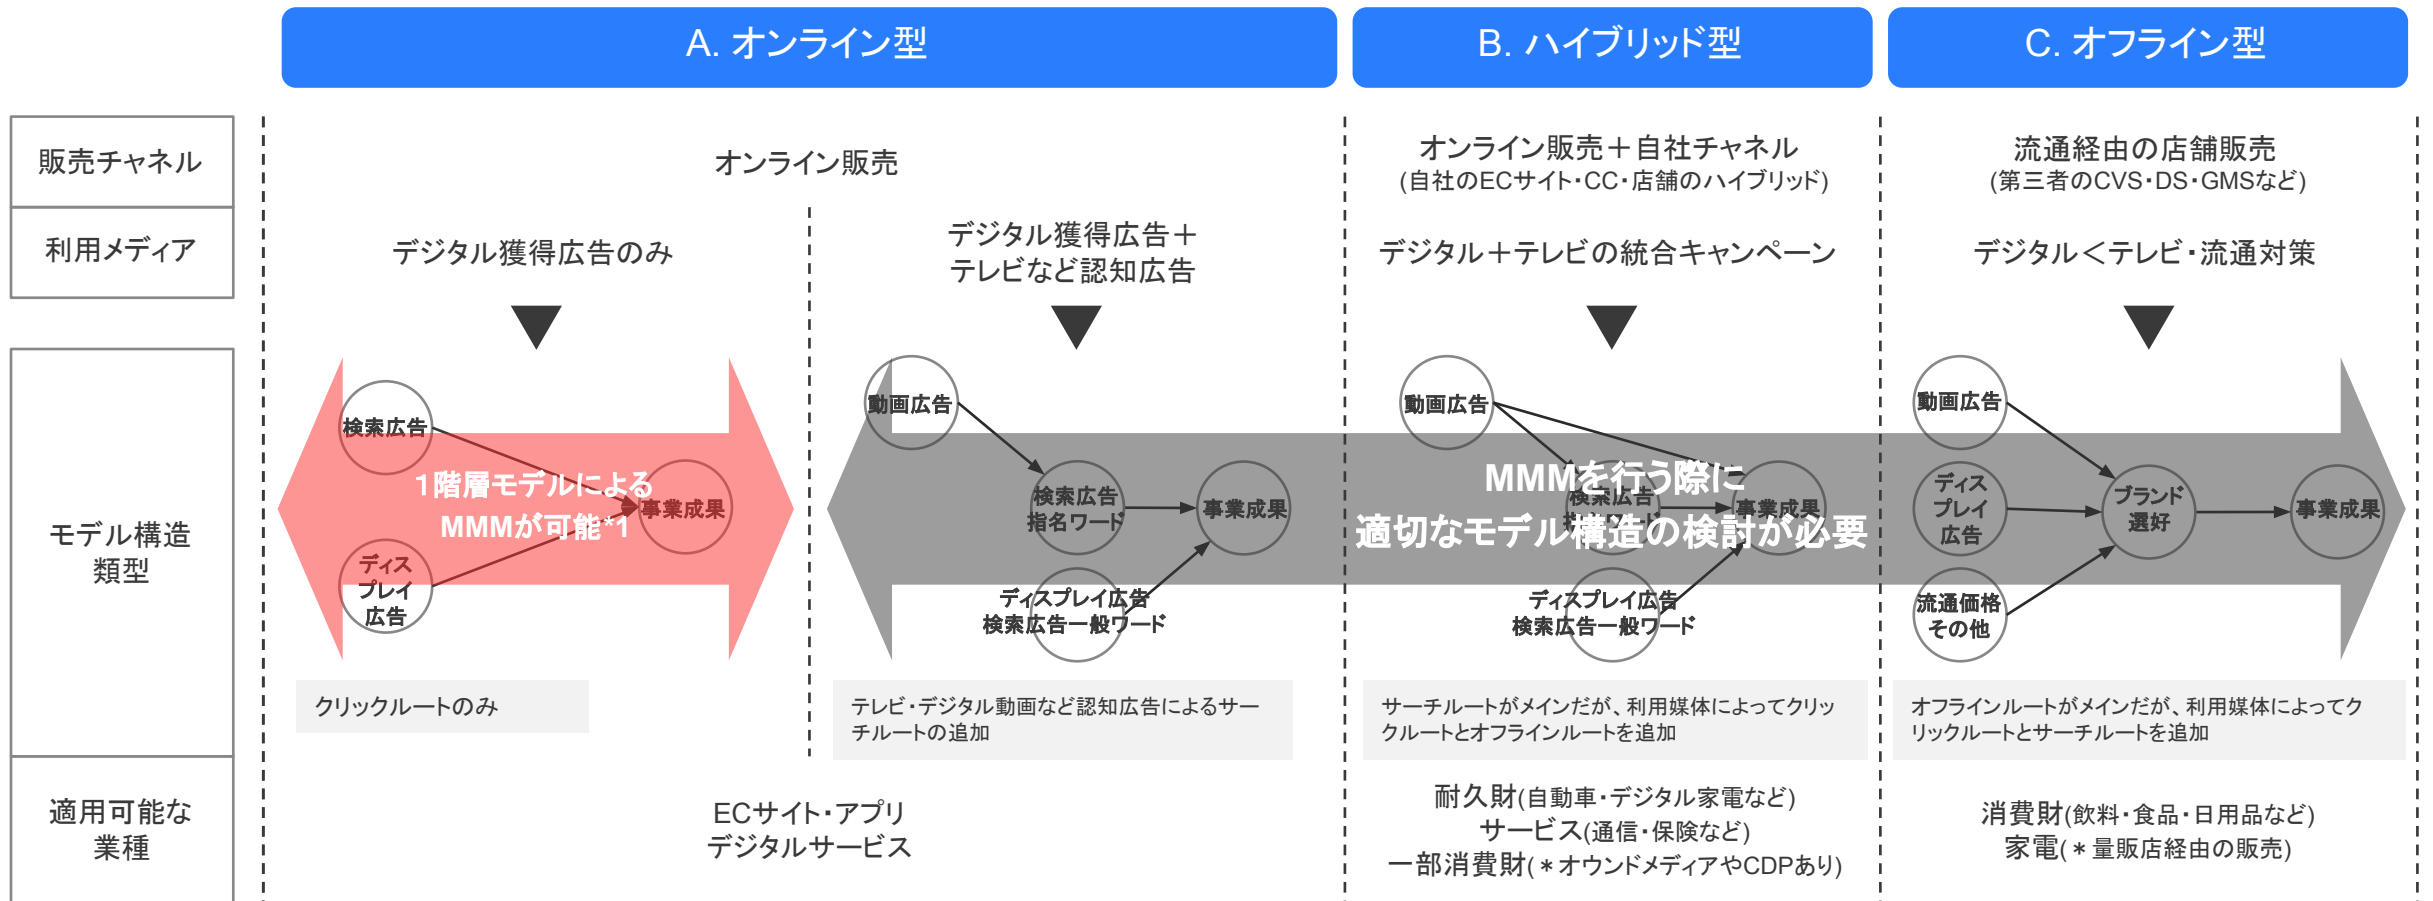
- ベースラインの比率が80~90%の場合は、正解データは1階層モデルの適用で推定された各メディアの推定貢献量の95%信用区間に収まっている。
  - しかし、各メディアの推定貢献量の推定精度は、CV全体に占めるベースラインの割合によって変化し、約1.5~2倍以上の乖離が生じる。
  - 一方で予約型広告のように出稿量のメリハリのある場合は推定精度が高いケースも見られる。
- 
- データの生成過程と異なるモデル構造仮説を用いたMMMでは、サーチルートの推定貢献量は約2.9~9.8倍の乖離が生じている。また、テレビ広告の過小評価と乖離は、テレビのメディア特性である平坦なタイム出稿(小さい分散)に起因していると考えられる。
  - 一方で出稿に山を作ったデジタル動画では95%信用区間に正解データが収まっているものの、約2.9倍の乖離が生じている。
  - モデル構造の誤設定と各メディアの分散の程度により、乖離の度合い、過大評価・過小評価の原因の一貫した分析が困難となっている

\*1: 検証に利用する1階層モデルは、2023年9月時点のGoogle非公式のオープンソースであるLightweight MMMである。

- 1階層モデルは、クリックルートでは貢献量の推定に機能するため、デジタル獲得広告のみを利用しオンライン販売を行なっている企業においては、MMMに利用できると考える。\*1
  - ただし、説明変数の分散が小さい場合には、推定貢献量の誤差が大きくなる可能性はある。
- しかし、テレビ・デジタル動画などの認知型広告でブランディング活動を展開したり、オフライン販売チャネルを利用している場合、1階層モデルを適用すると貢献量に推定において大きな誤差が生じる可能性があるため、モデル構造の検討が非常に重要である。

凡例  
 → 有向矢線は因果関係の向きを示す

各類型はDAG(非巡回有向グラフ)であり、以下を前提としている。  
 ・各要素はメディアの特徴でまとめた変数集合である。MMMを行う際には適切に分解する必要がある。  
 ・因果関係には時間依存がないことを前提とする。  
 ・非観測変数や変数間の交絡は省略しており、その問題点については後述する。



\*1:ただし、アプリの検索広告を利用している場合など、デジタル獲得広告のみであっても、サーチルートが存在する場合もあり、1階層モデルが通用しない可能性もある。個別ビジネス毎のルートの存在の検証が必要である。

## 3.4. モデル構造に関する問題と解決のヒント

---



- シミュレーションスタディが示すように、サーチルートが含まれると1階層モデルでは対応できない。サーチルートは、ブランディングによるオンライン販売の拡大やオンライン・オフラインのハイブリッド型の販売チャネルにおいて主要なルートであるため、サーチルートへの MMM適用方法を模索したい。
- また、サーチルートを採用したキャンペーン立案の特性として、テレビ広告・ディスプレイ広告などが同タイミングで実施されることが多く、説明変数相互の相関が高いことがある。
- この2つの問題は下の因果グラフで表される。

凡例  
 Y: オンライン CV・売上など目的変数  
 S: 検索広告指名ワード・自然検索  
 C: ディスプレイ広告・検索広告一般ワードなど  
 クリック型広告  
 T: テレビ・デジタル動画広告など認知型広告  
 P: ブランド選択確率を示す認知指標  
 →有向矢線は因果関係の向きを示す  
 ↔双方向矢線は観測できない共通原因による相関

## A. オンライン型\*1

## B. ハイブリッド型\*1

クリックルート+サーチルート





クリック+サーチ+オフラインルート

説明変数が独立の理想状態

説明変数が交絡する現実

説明変数が独立の理想状態

説明変数が交絡する現実



- 有向矢線 T→S S→Yなどは、因果関係の向きを示す
- 双方向矢線 T↔S T↔C S↔Cは、キャンペーン実施の同時性や季節性の一致など観測できない共通原因による相関を示しており、例えばテレビとディスプレイ広告のフライトパターンが同一の場合が挙げられる。
- SとYが交絡する場合もあり、目的変数に対して検索広告経由の比率が高い場合が考えられる


\*1: 検索広告に関しては、本来は指名検索量も考慮した考察が必要であるが、単純化のため、ここでは省略している。

- MMMをブランディングによるオンライン販売の拡大やオンライン・オフラインのハイブリッド型の販売チャネルに適用するには、前述のパラメータの識別可能性条件を充足したモデル構造を採用することが解決策となる。
- 本節では、モデル構造に関する問題を、パラメータの識別可能性条件の適用によって解消するヒントを示す。

凡例  
 Y: 目的変数  
 X: 目的変数に対して注目している原因  
 Z: X以外に因果関係が想定される要素  
 U: 未観測の変数  
 → 有向矢線は因果関係の向きを示す  
 ↔ 双方向矢線は交絡していることを示す  
 $r_{AB.C}$ : AをBとCで重回帰したときのBの偏回帰係数  
 $r_{AB}$ : AをBで単回帰したときの回帰係数


パラメータの識別可能性条件

シングルドア基準




- Zはシングルドア基準を満たすため、Zを調整することにより、 $X \rightarrow Y$ への直接効果 $\alpha$ は識別可能
- 直接効果 $\alpha = r_{YX.Z}$ 。YX.Zによって与えられ、 $Y = \alpha X + \beta Z + \varepsilon$ の偏回帰係数 $\alpha$ と一致

バックドア基準



- $Z_2$ はバックドア基準を満たすため、 $Z_2$ を調整することにより、 $X \rightarrow Y$ への総合効果 $(\alpha + \beta\gamma)$ は識別可能
- 総合効果 $(\alpha + \beta\gamma) = r_{YX.Z_2}$ によって与えられ、 $Y = (\alpha + \beta\gamma)X + \delta Z_2 + \varepsilon$ の偏回帰係数 $(\alpha + \beta\gamma)$ と一致

フロントドア基準

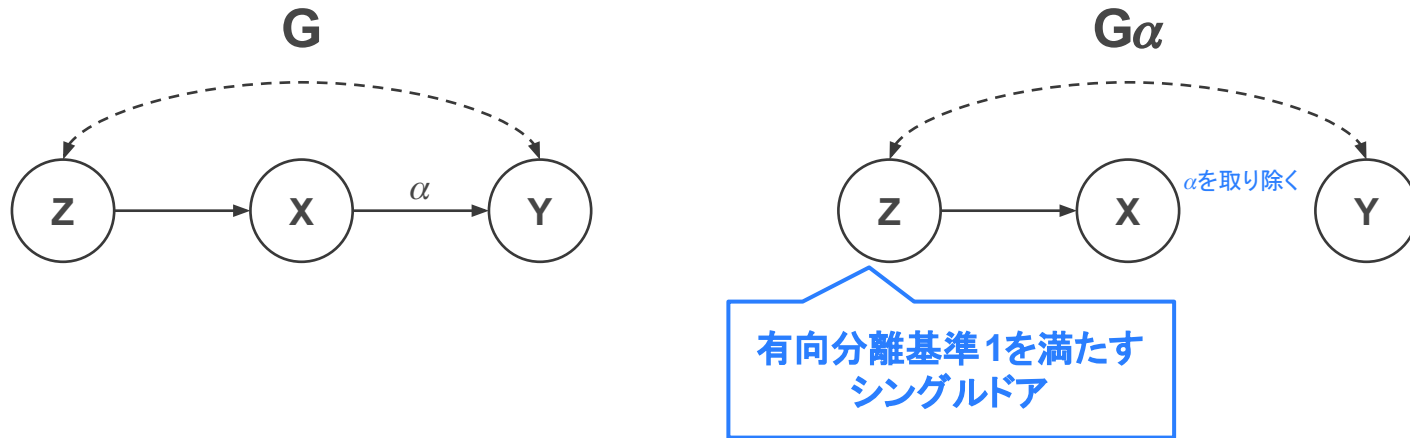


- 因果効果が想定される未観測変数Uが想定される場合でも、フロントドア基準を満たすZを利用することで、 $X \rightarrow Y$ への総合効果 $\alpha\beta$ は識別可能
- 総合効果 $\alpha\beta$ は、直接効果 $\beta = r_{ZX}$ と $\alpha = r_{YZ.X}$ の積によって与えられる

\*:識別可能性条件については、Judea Pearl "CAUSALITY MODELS, REASONING, AND INFERENCE"(2009)('統計的因果推論'黒木学訳)を参考とした

- シングルドア基準は説明変数  $X \rightarrow$  目的変数  $Y$  の因果関係に対して、変数集合  $Z$  が  $X$  に間接的影響を及ぼしている場合の直接効果の推定方法を示している。なお、 $Z$  は空集合  $\phi$  でもよく、 $X \rightarrow Y$  のシンプルな関係は  $Z$  が空集合  $\phi$  である特殊な場合と考えられる。
- 変数集合  $Z$  がシングルドア基準と有効分離基準を満たす場合、 $X \rightarrow Y$  の直接効果  $\alpha$  は回帰係数  $\alpha = r_{YX.Z}$  によって与えられ、 $Y = \alpha X + \beta Z + \varepsilon$  の偏回帰係数  $\alpha$  と一致する。

凡例  
 $Y$ : 目的変数  
 $X$ : 目的変数に対して注目している原因  
 $Z$ :  $X$  以外に因果関係が想定される要素  
 $U$ : 未観測の変数  
 $\rightarrow$ : 有向矢線は因果関係の向きを示す  
 $\leftrightarrow$ : 双方向矢線は交絡していることを示す  
 $r_{AB.C}$ :  $A$  を  $B$  と  $C$  で重回帰したときの  $B$  の偏回帰係数  
 $r_{AB}$ :  $A$  を  $B$  で単回帰したときの回帰係数



グラフ  $G$  の  $X \rightarrow Y$  において、回帰係数  $r_{YX} = \alpha + I_{YX}$  に分解できる。  
 $X$  と  $Y$  の間にあるパスは  $Z$  を通っているが、 $Z$  は合流点ではないため、 $Y$  に対して何らかの影響を及ぼしている可能性があり、 $I_{YX} \neq 0$  である。

有向分離基準1を満たす  
シングルドア

識別したい直接効果  $\alpha$  を除いた部分グラフ  $G_\alpha$  において、 $X$  と  $Y$  の間にあるパスは  $Z$  を通っており、 $Z$  はシングルドア基準を満たしているので、 $Z$  で調整することで  $r_{YX} = \alpha + I_{YX}$  の  $I_{YX} = 0$  となる。

このことから、 $X \rightarrow Y$  の回帰係数は、 $r_{YX.Z} = \alpha + I_{YX.Z}$  によって与えられる。この  $\alpha$  は、以下の回帰式の  $X$  の偏回帰係数と一致する。

$$Y = \alpha X + \beta Z + \varepsilon$$

### ■ シングルドア基準

- $Z$  の任意の要素は  $Y$  の子孫ではない。
- グラフ  $G$  において  $X \rightarrow Y$  への矢線  $\alpha$  を取り除いた  $G_\alpha$  において  $Z$  は  $X$  と  $Y$  を有向分離する。

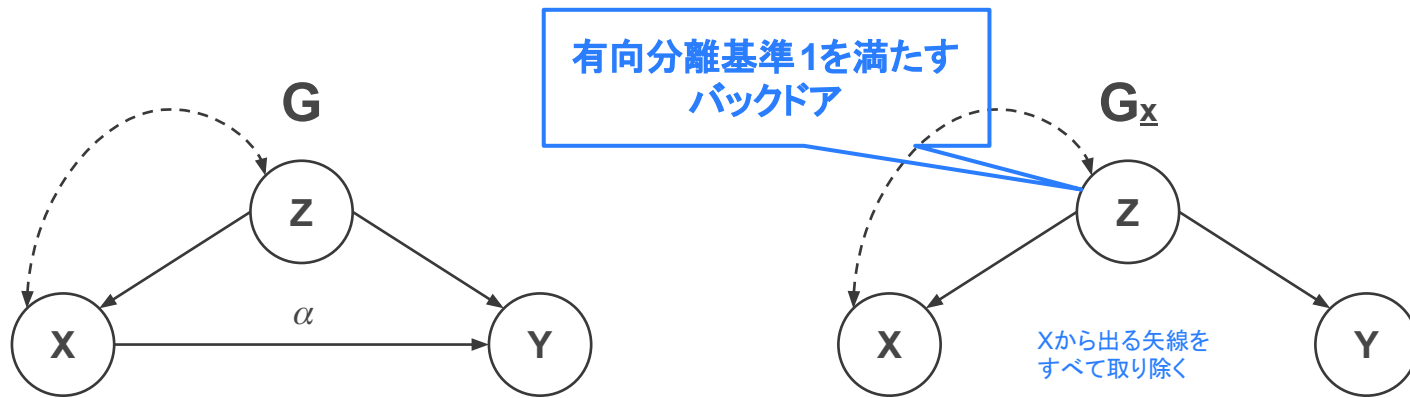
### ■ 有向分離基準(d分離基準)

- パス  $p$  がいずれかの条件を満たすとき、パス  $p$  は集合  $Z$  によって有向分離(ブロック)される
1. パス  $p$  は、ある頂点  $m$  が  $Z$  に含まれるような連鎖経路  $i \rightarrow m \rightarrow j$  または分岐経路  $i \leftarrow m \rightarrow j$  を含む。
  2. パス  $p$  は、 $m$  もその子孫も  $Z$  に含まれないような合流経路(または合流)  $i \rightarrow m \leftarrow j$  を含む。

\*: 識別可能性条件については、Judea Pearl "CAUSALITY MODELS, REASONING, AND INFERENCE" (2009) (「統計的因果推論」黒木学訳) を参考とした

- 複雑なモデル構造にはバックドアと呼ばれる因果関係が入り込みやすく、因果効果の推定を難しくする。このバックドアを見つける方法が、バックドア基準である。
- 因果グラフGにおいてZがXのバックドアとなっており、この場合でも、Zを調整すること、つまり  $Y = \alpha X + \beta Z + \epsilon$  の偏回帰係数  $\alpha$  が、 $X \rightarrow Y$  の直接効果  $\alpha = r_{YX.Z}$  と一致する。

凡例  
 Y: 目的変数  
 X: 目的変数に対して注目している原因  
 Z: X以外に因果関係が想定される要素  
 U: 未観測の変数  
 → 有向矢線は因果関係の向きを示す  
 ↔ 双方向矢線は交絡していることを示す  
 $r_{AB.C}$ : AをBとCで重回帰したときのBの偏回帰係数  
 $r_{AB}$ : AをBで単回帰したときの回帰係数



グラフGの  $X \rightarrow Y$  において、回帰係数  $r_{YX} = \alpha + I_{YX}$  に分解できる。  
 XとYの間にあるパスはZを通っているが、Zは合流点ではないため、X・Yに対して影響を及ぼしており、 $I_{YX} \neq 0$  である。

グラフGからXから出る矢線をすべて取り除いた部分グラフ  $G_x$  において、Xのバックドアパスである  $X \leftarrow Z \rightarrow Y$ 、 $X \leftarrow Z \rightarrow Y$  が存在するが、Zで調整することで  $r_{YX} = \alpha + I_{YX}$  の  $I_{YX} = 0$  となる。

このことから、 $X \rightarrow Y$  の回帰係数は、 $r_{YX.Z} = \alpha + I_{YX.Z}$  によって与えられる。この  $\alpha$  は、以下の回帰式のXの偏回帰係数と一致する。

$$Y = \alpha X + \beta Z + \epsilon$$

## ■ バックドア基準

- Zの任意の要素はXの子孫ではない。
- グラフGにおいてXから出る矢線をすべて取り除いたグラフ  $G_x$  においてZはXとYを有向分離する。

## ■ 有向分離基準(d分離基準)

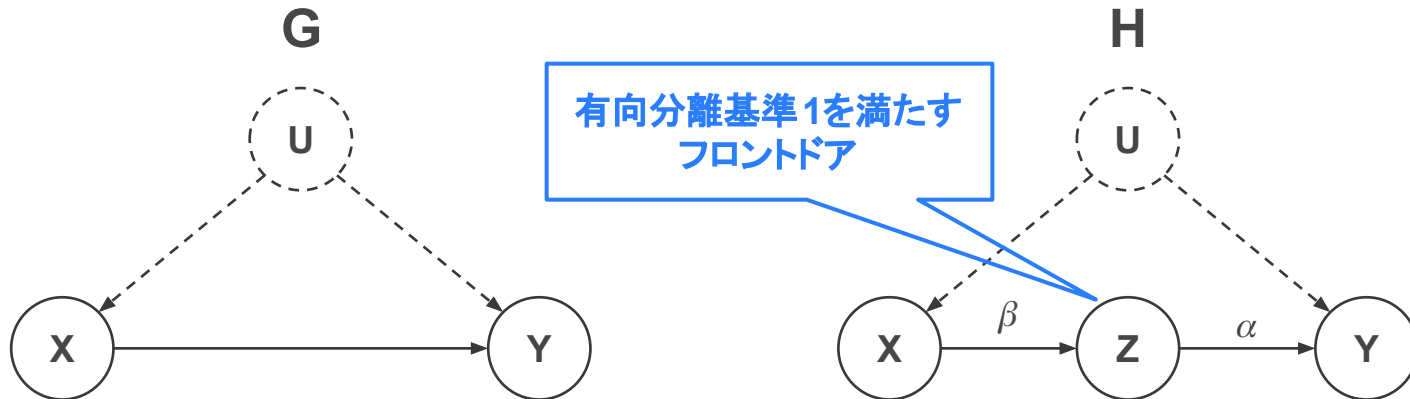
パスpがいずれかの条件を満たすとき、パスpは集合Zによって有向分離(ブロック)される

1. パスpは、ある頂点mがZに含まれるような連鎖経路  $i \rightarrow m \rightarrow j$  または分岐経路  $i \leftarrow m \rightarrow j$  を含む。
2. パスpは、mもその子孫もZに含まれないような合流経路(または合流)  $i \rightarrow m \leftarrow j$  を含む。

\*: 識別可能性条件については、Judea Pearl "CAUSALITY MODELS, REASONING, AND INFERENCE" (2009) (「統計的因果推論」黒木学訳) を参考とした

- フロントドア基準は説明変数  $X \rightarrow$  目的変数  $Y$  の因果関係に対して、未観測の変数が共通原因となって  $X \cdot Y$  に相関を起こしている場合に有効である。
- $X \rightarrow Y$  の間に、フロントドア基準を満たす変数  $Z$  を見つけ、 $Z \rightarrow Y$  と  $X \rightarrow Z$  の直接効果を推定することで  $X \rightarrow Y$  の直接効果  $\alpha\beta$  が得られる。
  - $Z \rightarrow Y$  の直接効果  $\alpha$  は回帰係数  $\alpha = r_{YZ.X}$  によって与えられ、 $Y = \alpha Z + \beta'X + \varepsilon$  の偏回帰係数  $\alpha$  と一致する。
  - $X \rightarrow Z$  の直接効果  $\beta$  は回帰係数  $\beta = r_{ZX}$  によって与えられ、 $Z = \beta X + \varepsilon$  の偏回帰係数  $\beta$  と一致する。

凡例  
 $Y$ : 目的変数  
 $X$ : 目的変数に対して注目している原因  
 $Z$ :  $X$  以外に因果関係が想定される要素  
 $U$ : 未観測の変数  
 $\rightarrow$ : 有向矢線は因果関係の向きを示す  
 $\leftrightarrow$ : 双方向矢線は交絡していることを示す  
 $r_{AB.C}$ :  $A$  を  $B$  と  $C$  で重回帰したときの  $B$  の偏回帰係数  
 $r_{AB}$ :  $A$  を  $B$  で単回帰したときの回帰係数



グラフGの  $X \rightarrow Y$  において、回帰係数  $r_{YX} = \alpha + I_{YX}$  に分解できる。  
 $X$  と  $Y$  の間にあるパスは未観測変数  $U$  を通っているが、 $U$  は合流点ではないため、有向分離基準を満たしていないので、何らかの影響を及ぼしており、 $I_{YX} \neq 0$  である可能性がある。

$X \rightarrow Y$  のパスにおいて、フロントドア基準を満たす変数  $Z$  があれば、 $Z$  を利用することで、 $X \rightarrow Y$  への総合効果  $\alpha\beta$  を識別可能することができる。

総合効果  $\alpha\beta$  は、直接効果  $\alpha$  と  $\beta$  の積となり、 $\alpha\beta = r_{YZ.X} \cdot \beta = r_{ZX}$  によって与えられる。

■ フロントドア基準

- $Z$  は  $X$  から  $Y$  へのすべての有向道を切断する
- $X$  から  $Z$  へのブロックされないバックドアパスはない
- $Z$  から  $Y$  へのバックドアパスはすべて  $Z$  でブロックされる

■ 有向分離基準(d分離基準)


パス  $p$  がいずれかの条件を満たすとき、パス  $p$  は集合  $Z$  によって有向分離(ブロック)される

1. パス  $p$  は、ある頂点  $m$  が  $Z$  に含まれるような連鎖経路  $i \rightarrow m \rightarrow j$  または分岐経路  $i \leftarrow m \rightarrow j$  を含む。
2. パス  $p$  は、 $m$  もその子孫も  $Z$  に含まれないような合流経路(または合流)  $i \rightarrow m \leftarrow j$  を含む。


\*: 識別可能性条件については、Judea Pearl "CAUSALITY MODELS, REASONING, AND INFERENCE" (2009) (『統計的因果推論』黒木学訳) を参考とした

- 有向分離基準を満たさない変数が識別したい効果に関係している場合は、直接効果を識別できない場合がある。その場合、総合効果として識別が可能かどうかを検討する必要がある。
- 下記のグラフGにおいてZ<sub>1</sub>は、調整すると有向分離基準 2を、調整しないと有向分離基準 1を満たせないため、X→Yの効果は総合効果 $\alpha+\beta\gamma$ として識別するしかない。

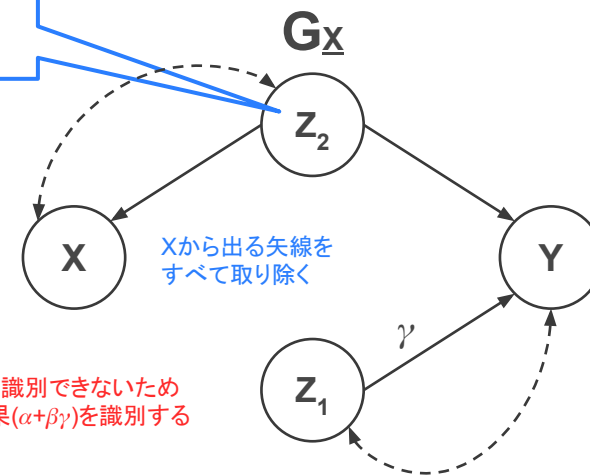
凡例  
 Y: 目的変数  
 X: 目的変数に対して注目している原因  
 Z: X以外に因果関係が想定される要素  
 U: 未観測の変数  
 → 有向矢線は因果関係の向きを示す  
 ← 双方向矢線は交絡していることを示す  
 $r_{AB,C}$ : AをBとCで重回帰したときのBの偏回帰係数  
 $r_{AB}$ : AをBで単回帰したときの回帰係数



有向分離基準 1・2ともに満たさないため識別することができない



有向分離基準 1.を満たすバックドア



$\alpha \cdot \beta \cdot \gamma$ は識別できないため総合効果 $(\alpha + \beta\gamma)$ を識別する

グラフGのX→Yにおいて、回帰係数 $r_{YX} = \alpha + I_{YX}$ に分解できる。XとYの間にあるパスはZ<sub>1</sub>・Z<sub>2</sub>を通っており、またいずれも合流点ではないため、有向分離できておらず、 $I_{YX} \neq 0$ である。

X→Yの矢線を取り除いた部分グラフG<sub>α</sub>において、XとYの間にあるパスZ<sub>1</sub>は、有向分離基準1より調整するとX→Z<sub>1</sub>←→Y(Z<sub>1</sub>が合流点)のパスが開き、有向分離基準2より調整しない場合にはX→Z<sub>1</sub>→Y(連鎖経路)が開いている。そのため、識別することができない。

そこでさらに、Xから出る矢線をすべて削除した部分グラフG<sub>X</sub>を考える。この場合はXのバックドアパスとしてX←Z<sub>2</sub>→Y、X←→Z<sub>2</sub>→Yが存在するが、Z<sub>2</sub>を調整すれば有向分離基準1.を満たすので、Z<sub>2</sub>はバックドア基準を満たす。

■ 有向分離基準(d分離基準)

パスpがいずれかの条件を満たすとき、パスpは集合Zによって有向分離(ブロック)される

1. パスpは、ある頂点mがZに含まれるような連鎖経路i→m→jまたは分岐経路i←m→jを含む。
2. パスpは、mもその子孫もZに含まれないような合流経路(または合流)i→m←jを含む。

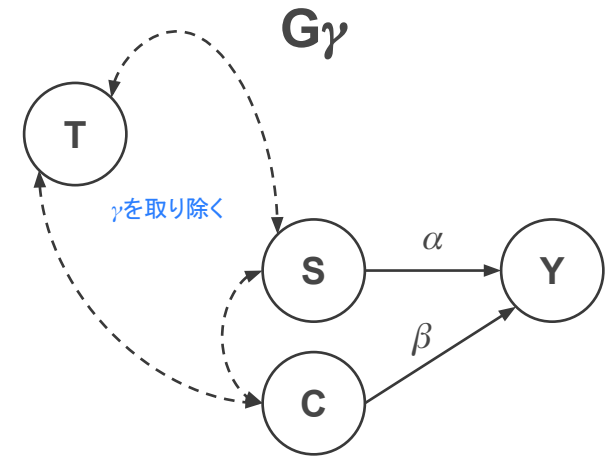

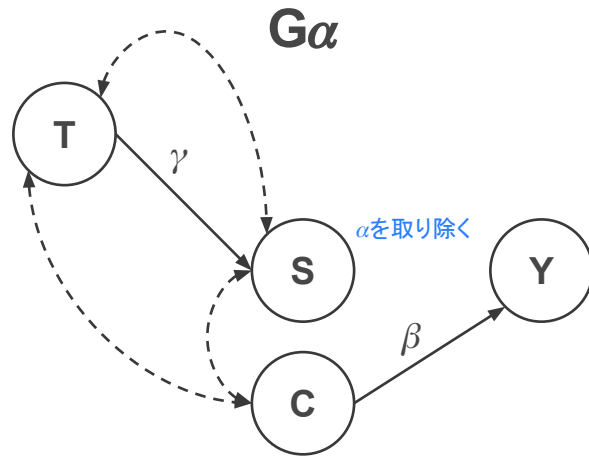

■ バックドア基準

- Zの任意の要素はXの子孫ではない。
- グラフGにおいてXから出る矢線をすべて取り除いたグラフG<sub>X</sub>においてZはXとYを有向分離する。

\*:識別可能性条件については、Judea Pearl "CAUSALITY MODELS, REASONING, AND INFERENCE"(2009)(「統計的因果推論」黒木学訳)を参考とした

- オンライン型モデル構造において、識別可能性条件 \*1に則り、識別可能性を判別することができる。
- $S \rightarrow Y$ の直接効果 $\alpha$ ・ $C \rightarrow Y$ の直接効果 $\beta$ については識別可能である。つまりクリックルートについてはモデル化が可能といえる。\*2
- $T \rightarrow S$ の直接効果 $\gamma$ はキャンペーン実施の同時性や共通する周期性など観測できない共通原因による相関が生じ、識別が困難である。これがサーチルートのモデル化の難しさとなっている。

凡例  
 Y: オンラインCV・売上など目的変数  
 S: 検索広告指名ワード・自然検索  
 C: ディスプレイ広告・検索広告一般ワードなど  
 クリック型広告  
 T: テレビ・デジタル動画広告など認知型広告  
 P: ブランド選択確率を示す認知指標  
 → 有向矢線は因果関係の向きを示す  
 ←→ 双方向矢線は観測できない共通原因による相関  
 $r_{AB.C}$ : AをBとCで重回帰したときのBの偏回帰係数  
 $r_{AB}$ : AをBで単回帰したときの回帰係数



キャンペーン立案の特性として、テレビ広告・ディスプレイ広告などが同タイミングで実施されることが多く、説明変数相互の相関が高いことがほとんどである。

$S \rightarrow Y$ の直接効果 $\alpha$ を識別するため、部分グラフ $G_\alpha$ を考える。SとYのパスはCによって有効分離されるため、  
 $\alpha = r_{YS.C}$   
 によって与えられ、識別可能である。

$C \rightarrow Y$ の直接効果 $\beta$ を識別するため、部分グラフ $G_\beta$ を考える。SとYのパスはSによって有効分離されるため、  
 $\beta = r_{YC.S}$   
 によって与えられ、識別可能である。



$T \rightarrow S$ の直接効果 $\gamma$ を識別するため、部分グラフ $G_\gamma$ を考える。TとSの間にあるパスは $T \leftrightarrow S$ と $T \leftrightarrow C \leftrightarrow S$ の2つあるが、Tを調整しても有効分離されず、識別ができない。

\*1: 識別可能性条件については、Judea Pearl "CAUSALITY MODELS, REASONING, AND INFERENCE"(2009)「統計的因果推論」黒木学訳を参考とした。


\*2: 検索広告に関しては、本来は指名検索量も考慮した考察が必要であるが、単純化のため、ここでは省略している。SとYが交絡する場合もある(目的変数に対して検索広告経由の比率が高い場合が考えられる)が、単純化のため、ここでは省略している。

- 前述のように $T \rightarrow S$ の直接効果 $\gamma$ は識別困難であった。
- ここで $T$ =認知型広告によるサーチルート経由での $Y$ =事業成果への貢献量を推定することを考えると、 $C$ =クリック型広告との相関を解消したい。そこで $C$ =クリック型広告に介入を行い、 $T$ =認知広告との相関を解消すれば、少なくとも $T \rightarrow S \rightarrow Y$ の総合効果 $\alpha\gamma$ を識別できる可能性がある。<sup>\*2</sup>
- このように意図的に、マーケティングの試行錯誤とMMMを両輪で実施することで、検証可能なデータのパターンが増え、特定の効果を識別できる可能性が増えていく。

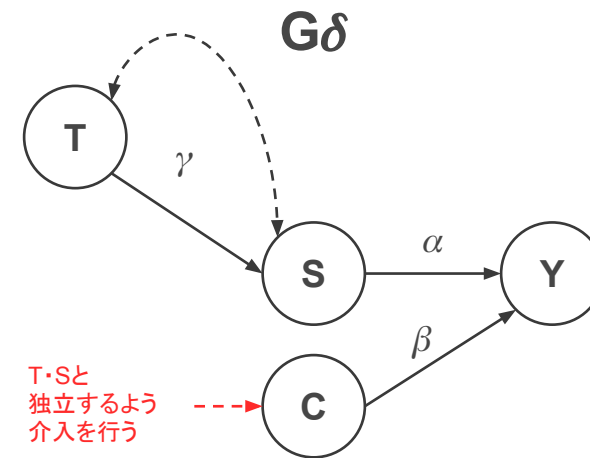
凡例  
 Y: オンラインCV・売上など目的変数  
 S: 検索広告指名ワード・自然検索  
 C: ディスプレイ広告・検索広告一般ワードなど  
 クリック型広告  
 T: テレビ・デジタル動画広告など認知型広告  
 P: ブランド選択確率を示す認知指標  
 → 有向矢線は因果関係の向きを示す  
 ← 双方向矢線は観測できない共通原因による相関  
 $r_{AB.C}$ : AをBとCで重回帰したときのBの偏回帰係数  
 $r_{AB}$ : AをBで単回帰したときの回帰係数



S→Yの直接効果 $\alpha$ を識別するため、部分グラフ $G_\alpha$ を考える。SとYのパスはCによって有効分離されるため、  
 $\alpha = r_{YS.C}$   
 によって与えられ、識別可能である。



C→Yの直接効果 $\beta$ を識別するため、部分グラフ $G_\beta$ を考える。SとYのパスはSによって有効分離されるため、  
 $\beta = r_{YC.S}$   
 によって与えられ、識別可能である。



T・Sと独立するよう介入を行う

CとS・CとTの間に交絡が生じない介入をCに対して行う。  
 このことで、少なくとも、 $T \rightarrow S \rightarrow Y$ の総合効果 $\alpha\gamma$ ・C→Yの直接効果 $\beta$ が識別可能となる。  
 $\alpha\gamma = r_{YT.C}$   
 $\beta = r_{YC.T}$   
 によって与えられる。

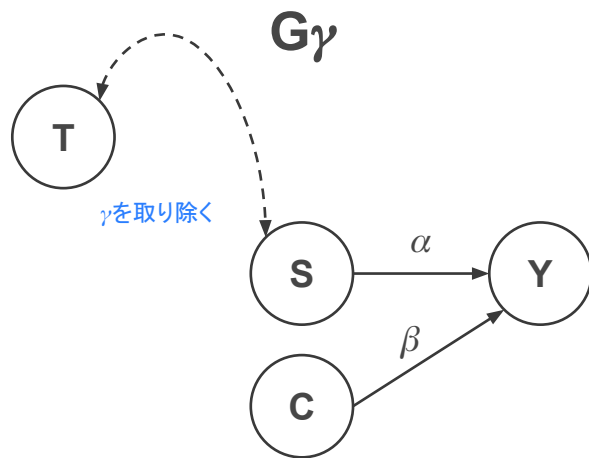

\*1:識別可能性条件については、Judea Pearl “CAUSALITY MODELS, REASONING, AND INFERENCE”(2009)「統計的因果推論」黒木学訳を参考とした。

\*2:検索広告に関しては、本来は指名検索量も考慮した考察が必要であるが、単純化のため、ここでは省略している。SとYが交絡する場合もある(目的変数に対して検索広告経由の比率が高い場合が考えられる)が、単純化のため、ここでは省略している。




- もう一つの方法として、 $T \rightarrow S$ の間に、フロントドア基準を満たす変数  $Z$ を追加する方法を示す。変数 $Z$ はブランド純粋想起などの認知指標が採用候補である。\*2

凡例  
 Y: オンラインCV・売上など目的変数  
 S: 検索広告指名ワード・自然検索  
 C: ディスプレイ広告・検索広告一般ワードなど  
 クリック型広告  
 T: テレビ・デジタル動画広告など認知型広告  
 P: ブランド選択確率を示す認知指標  
 $\rightarrow$  有向矢線は因果関係の向きを示す  
 $\leftrightarrow$  双方向矢線は観測できない共通原因による相関  
 $r_{AB.C}$ : AをBとCで重回帰したときの Bの偏回帰係数  
 $r_{AB}$ : AをBで単回帰したときの回帰係数




$T \rightarrow S$ の直接効果 $\gamma$ を識別するため、部分グラフ $G_\gamma$ を考える。TとSのパスは未観測の共通原因によって相関しているため直接効果 $\gamma$ を識別できない。



フロントドア基準を満たす変数 $Z$ を $T \rightarrow S$ のパスに追加することによって、総合効果 $\gamma_1\gamma_2$ を識別する。 $Z$ は $T \rightarrow S$ をブロックし、 $T \rightarrow Z$ のバックドアはなく、 $Z \rightarrow S$ のバックドアはTによってブロックされている。

■ フロントドア基準\*1

- ZはXからYへのすべての有向道を切断する
- XからZへのブロックされないバックドアパスはない
- ZからYへのバックドアパスはすべてZでブロックされる






\*1:識別可能性条件については、Judea Pearl “CAUSALITY MODELS, REASONING, AND INFERENCE”(2009)「統計的因果推論」黒木学訳を参考とした。

\*2:検索広告に関しては、本来は指名検索量も考慮した考察が必要であるが、単純化のため、ここでは省略している。SとYが交絡する場合もある(目的変数に対して検索広告経由の比率が高い場合が考えられる)が、単純化のため、ここでは省略している。

- フロントドア基準を満たす ZをT→Sのパスに追加することができれば、 $\gamma_1 \cdot \gamma_2$ が識別可能になる。
- $\gamma_1 \cdot \gamma_2$  それぞれに識別可能性条件を適用し、 $\gamma_1 \cdot \gamma_2$ を算出。積である  $\gamma_1 \gamma_2$  がグラフHにおけるT→Sの総合効果となる。

凡例  
 Y: オンラインCV・売上など目的変数  
 S: 検索広告指名ワード・自然検索  
 C: ディスプレイ広告・検索広告一般ワードなど  
 クリック型広告  
 T: テレビ・デジタル動画広告など認知型広告  
 P: ブランド選択確率を示す認知指標  
 → 有向矢線は因果関係の向きを示す  
 ← 双方向矢線は観測できない共通原因による相関  
 $r_{ABC}$ : AをBとCで重回帰したときのBの偏回帰係数  
 $r_{AB}$ : AをBで単回帰したときの回帰係数



T→Sの総合効果 $\gamma_1 \gamma_2$ を識別するため、フロントドア基準を満たす変数Zを追加したグラフHを考える。

T→Zの直接効果 $\gamma_1$ を識別する。  
 $\gamma_1$ を取り除くと、TとZの間にあるパスはすべて合流点Yによって有向分離できるため、直接効果 $\gamma_1$ は  
 $\gamma_1 = r_{ZT}$   
 によって与えられ、識別できる。


Z→Sの直接効果 $\gamma_2$ を識別する。  
 $\gamma_2$ を取り除くと、ZとSの間にあるパスは、Tを調整することで、有向分離できるため、直接効果 $\gamma_2$ は  
 $\gamma_2 = r_{SZ|T}$   
 によって与えられ、識別できる。

\*1:識別可能性条件については、Judea Pearl “CAUSALITY MODELS, REASONING, AND INFERENCE”(2009)「統計的因果推論」黒木学訳を参考とした。  
 \*2:検索広告に関しては、本来は指名検索量も考慮した考察が必要であるが、単純化のため、ここでは省略している。SとYが交絡する場合もある(目的変数に対して検索広告経由の比率が高い場合が考えられる)が、単純化のため、ここでは省略している。  
 ©2023 HAKUHODO DY media partners Inc., All Rights Reserved. | CONFIDENTIAL

- このようにパラメータの識別可能性条件を利用することは、注目する変数の因果効果を直接効果もしくは総合効果として識別できる可能性を広げることにつながる。
- また、因果関係が想定されるが計測されていなかったり、利用できない状況にある未観測変数が存在する場合でも、識別可能性条件に照らし合わせ、適切な変数を調整することで、特定の因果効果を識別することも示している。


凡例  
 Y: オンラインCV・売上など目的変数  
 S: 検索広告指名ワード・自然検索  
 C: ディスプレイ広告・検索広告一般ワードなどクリック型広告  
 T: テレビ・デジタル動画広告など認知型広告  
 P: ブランド選択確率を示す認知指標  
 → 有向矢線は因果関係の向きを示す  
 ←→ 双方向矢線は観測できない共通原因による相関  
 $\Gamma_{AB.C}$ : AをBとCで重回帰したときのBの偏回帰係数  
 $\Gamma_{AB}$ : AをBで単回帰したときの回帰係数

説明変数が交絡する現実



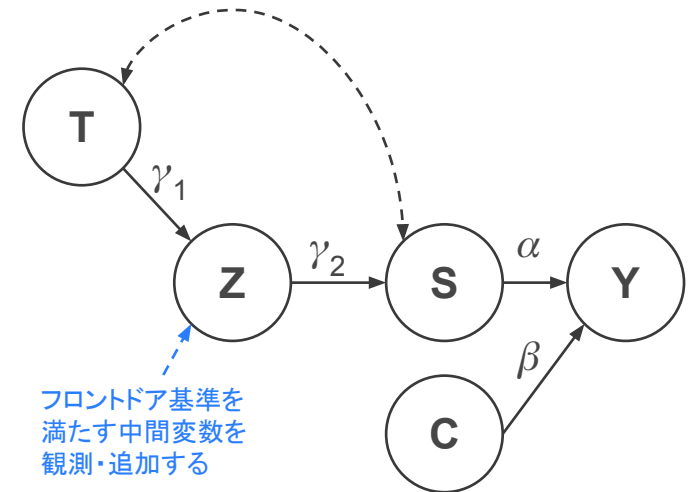
キャンペーン立案の特性として、テレビ広告・ディスプレイ広告などが同タイミングで実施されることが多く、説明変数相互の相関が高いことがほとんどである。

介入による識別



T・Sと独立するよう介入を行う

フロントドアによる識別



フロントドア基準を満たす中間変数を観測・追加する

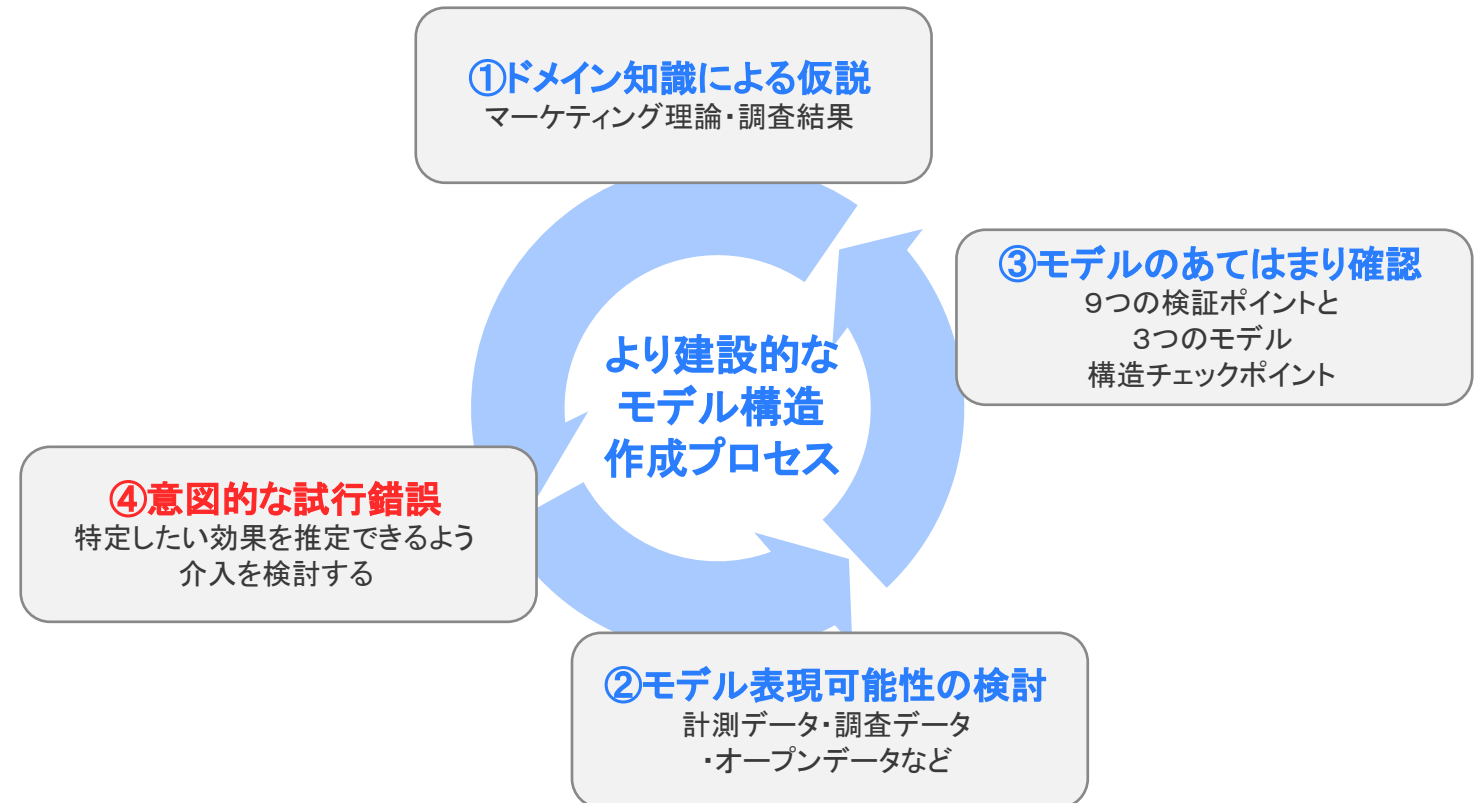
\*1: 識別可能性条件については、Judea Pearl “CAUSALITY MODELS, REASONING, AND INFERENCE”(2009)「統計的因果推論」黒木学訳を参考とした。

\*2: 検索広告に関しては、本来は指名検索量も考慮した考察が必要であるが、単純化のため、ここでは省略している。SとYが交絡する場合もある(目的変数に対して検索広告経由の比率が高い場合が考えられる)が、単純化のため、ここでは省略している。

- 実務においては、3つの観点から仮説構築・分析作業を行い、ステップを行き来することで、適切なモデル構造を判断すると記載したが、モデル構造の問題を解決するためには、そもそもメディアプラン・マーケティングプランに介入することも検討すべきである。
- 特定のメディア・マーケティング施策の効果を適切に推定するため、パラメータ識別可能性条件に則り適切な要素に介入し、観測データのパターンを増やすなど試行錯誤を行うことは、MMMによる効果検証の精度を高めたり、可能性を広げることにつながる。

### 意図的な試行錯誤の方法例

- 識別したいメディアについて、単独の出稿期間を設ける
- 逆に、出稿しない期間を設ける
- 識別したいメディアについては相互に異なるフライトパターンを設定し、時期をずらす
- フロントドア基準に適合するような中間変数を計測し、検証に利用する



## 3.5. 博報堂DYグループのMMMソリューション

---

このセクションでは、博報堂 DYグループのMMMのケイパビリティについて紹介する。  
このセクションの内容は博報堂 DYグループ独自で作成したコンテンツである。

Analytics AaaSは、マーケティング活動をMMMによって見える化・診断・予測・処方し、“事業貢献への説明力”をご提供します。

# Analytics AaaS

ライブモニタリング  
マーケティング活動の見える化

マーケティングミックスモデリング  
マーケティング活動の診断・予測・処方



テレビ・デジタルの統合リーチを中心に  
メディア運用とマーケティング活動データを可視化

各メディア・各施策の事業貢献を診断し  
目標達成に必要なKPI予測、予算配分を処方する

# Analytics AaaS

1.

商品特性に対応した  
多彩な数理モデル

マーケティングサイエンスの多彩な数理モデルを利用し、  
商品・サービスの特性や商品のポジションによって異なる  
影響要因と因果関係に対応できます

2.

マーケター／メディアプランナー  
×  
データサイエンティスト

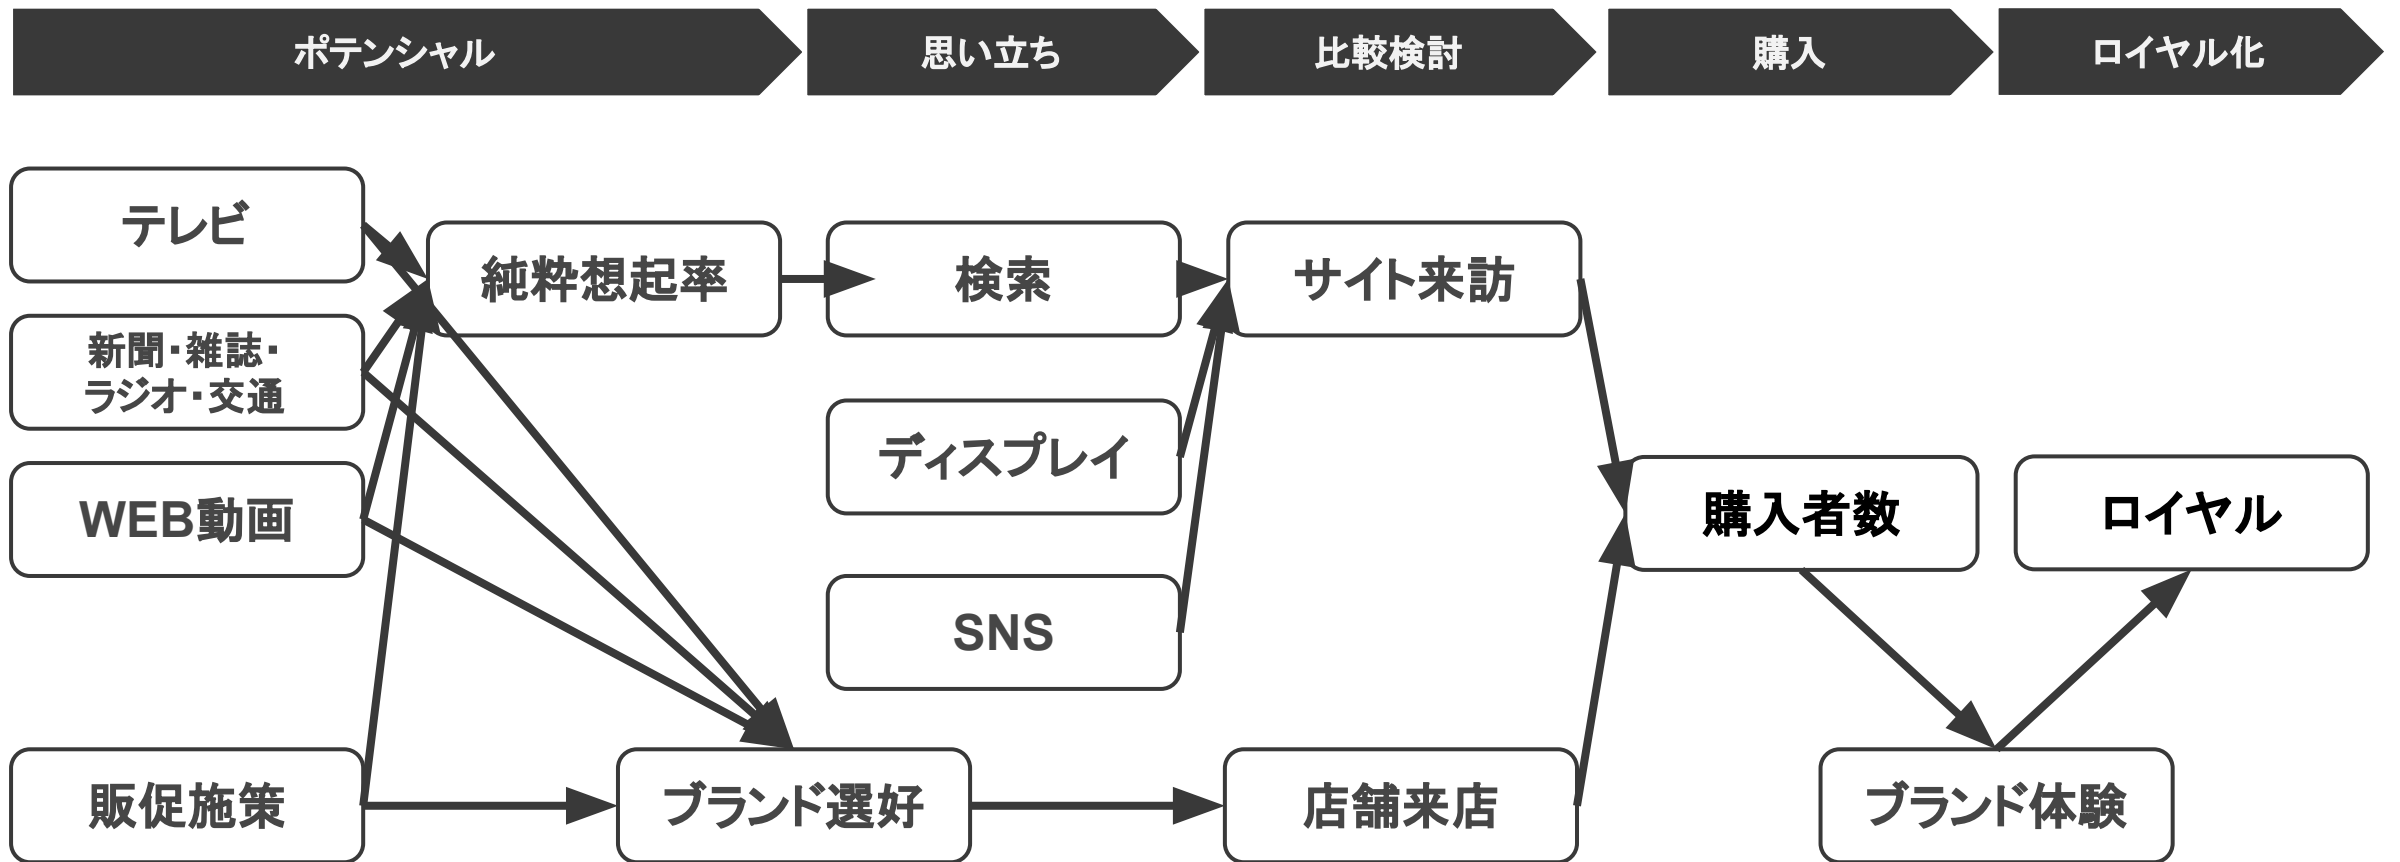
MMMモデル駆動のメディア運用ダッシュボードを使って、  
マーケター／メディアプランナーがPDCAやコンサルティング  
を行います

3.

運用フローの自動化

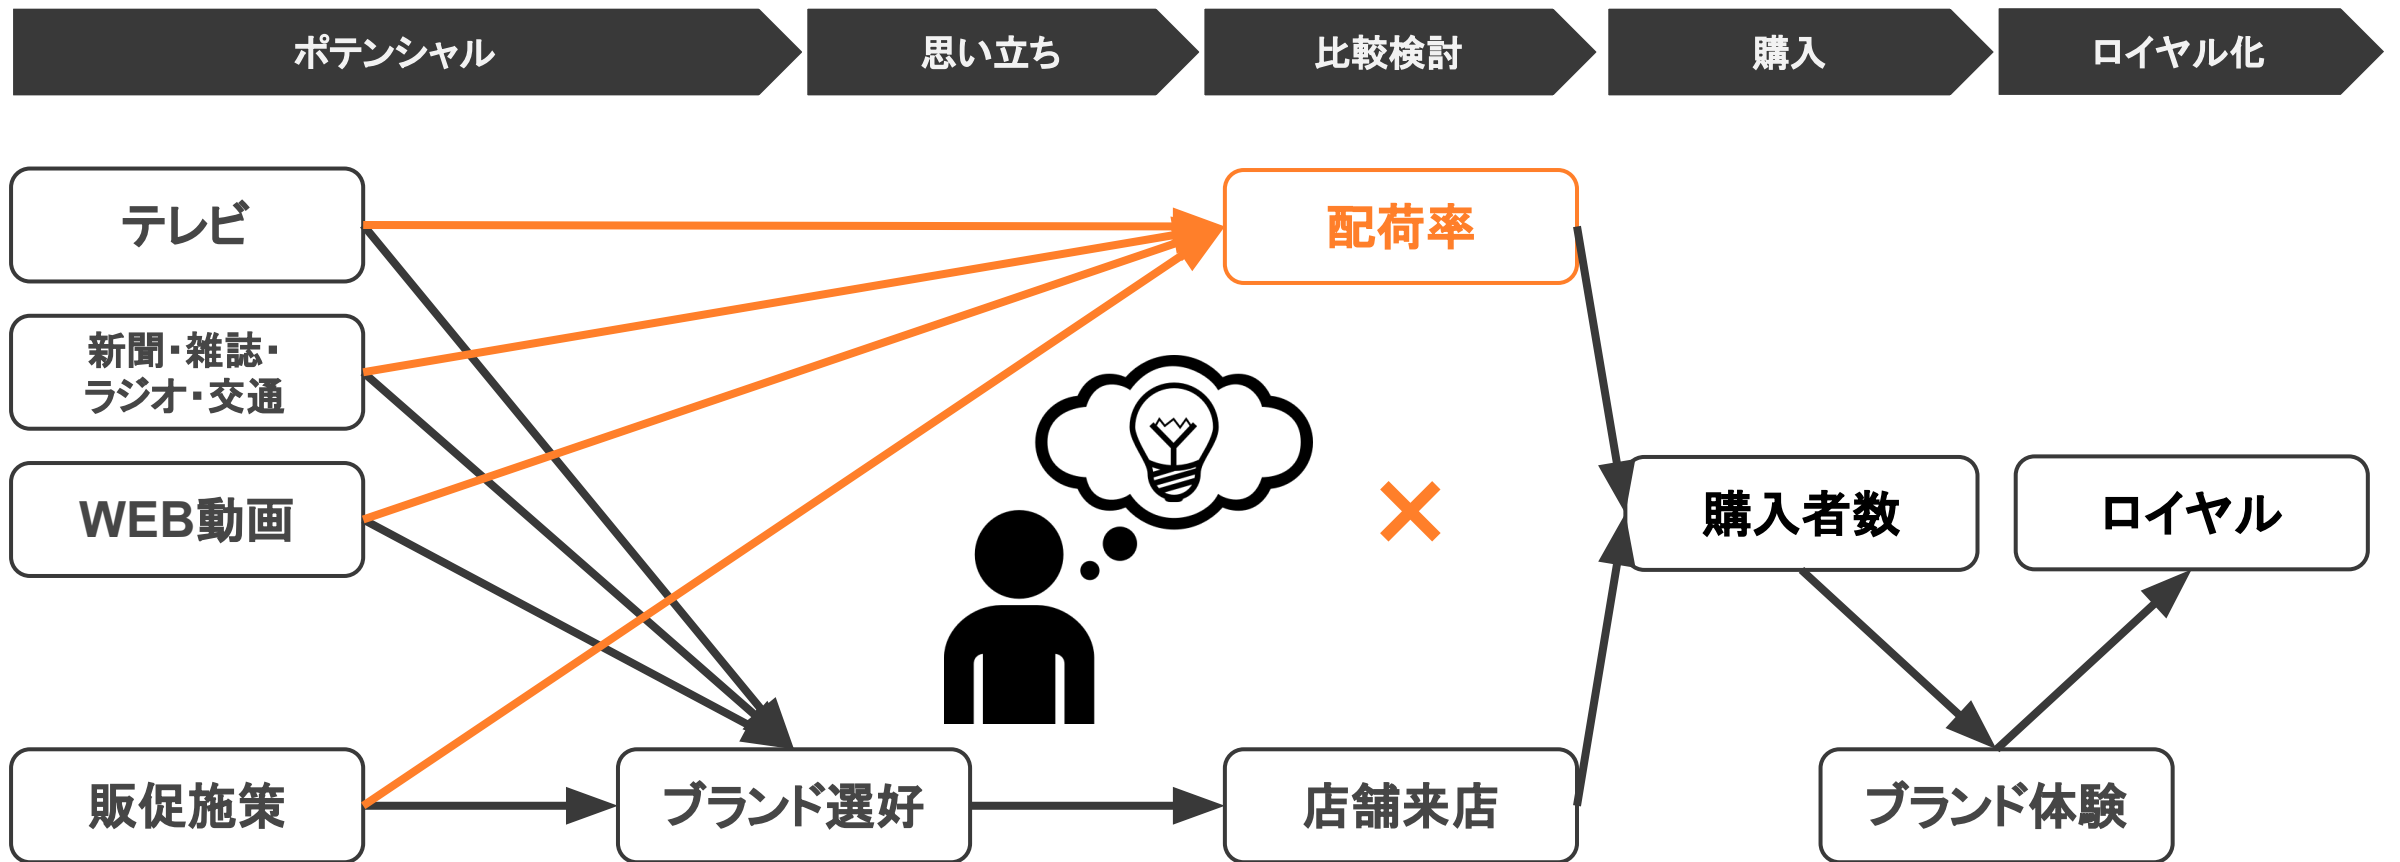
データのご準備、クリーニング、インポートといった作業  
は可能な限り自動化し、みなさまのお手間を最小化します

Analytics AaaSは、オンライン型・ハイブリッド型・オフライン型の  
3つのモデル構造類型すべてに対応できます。

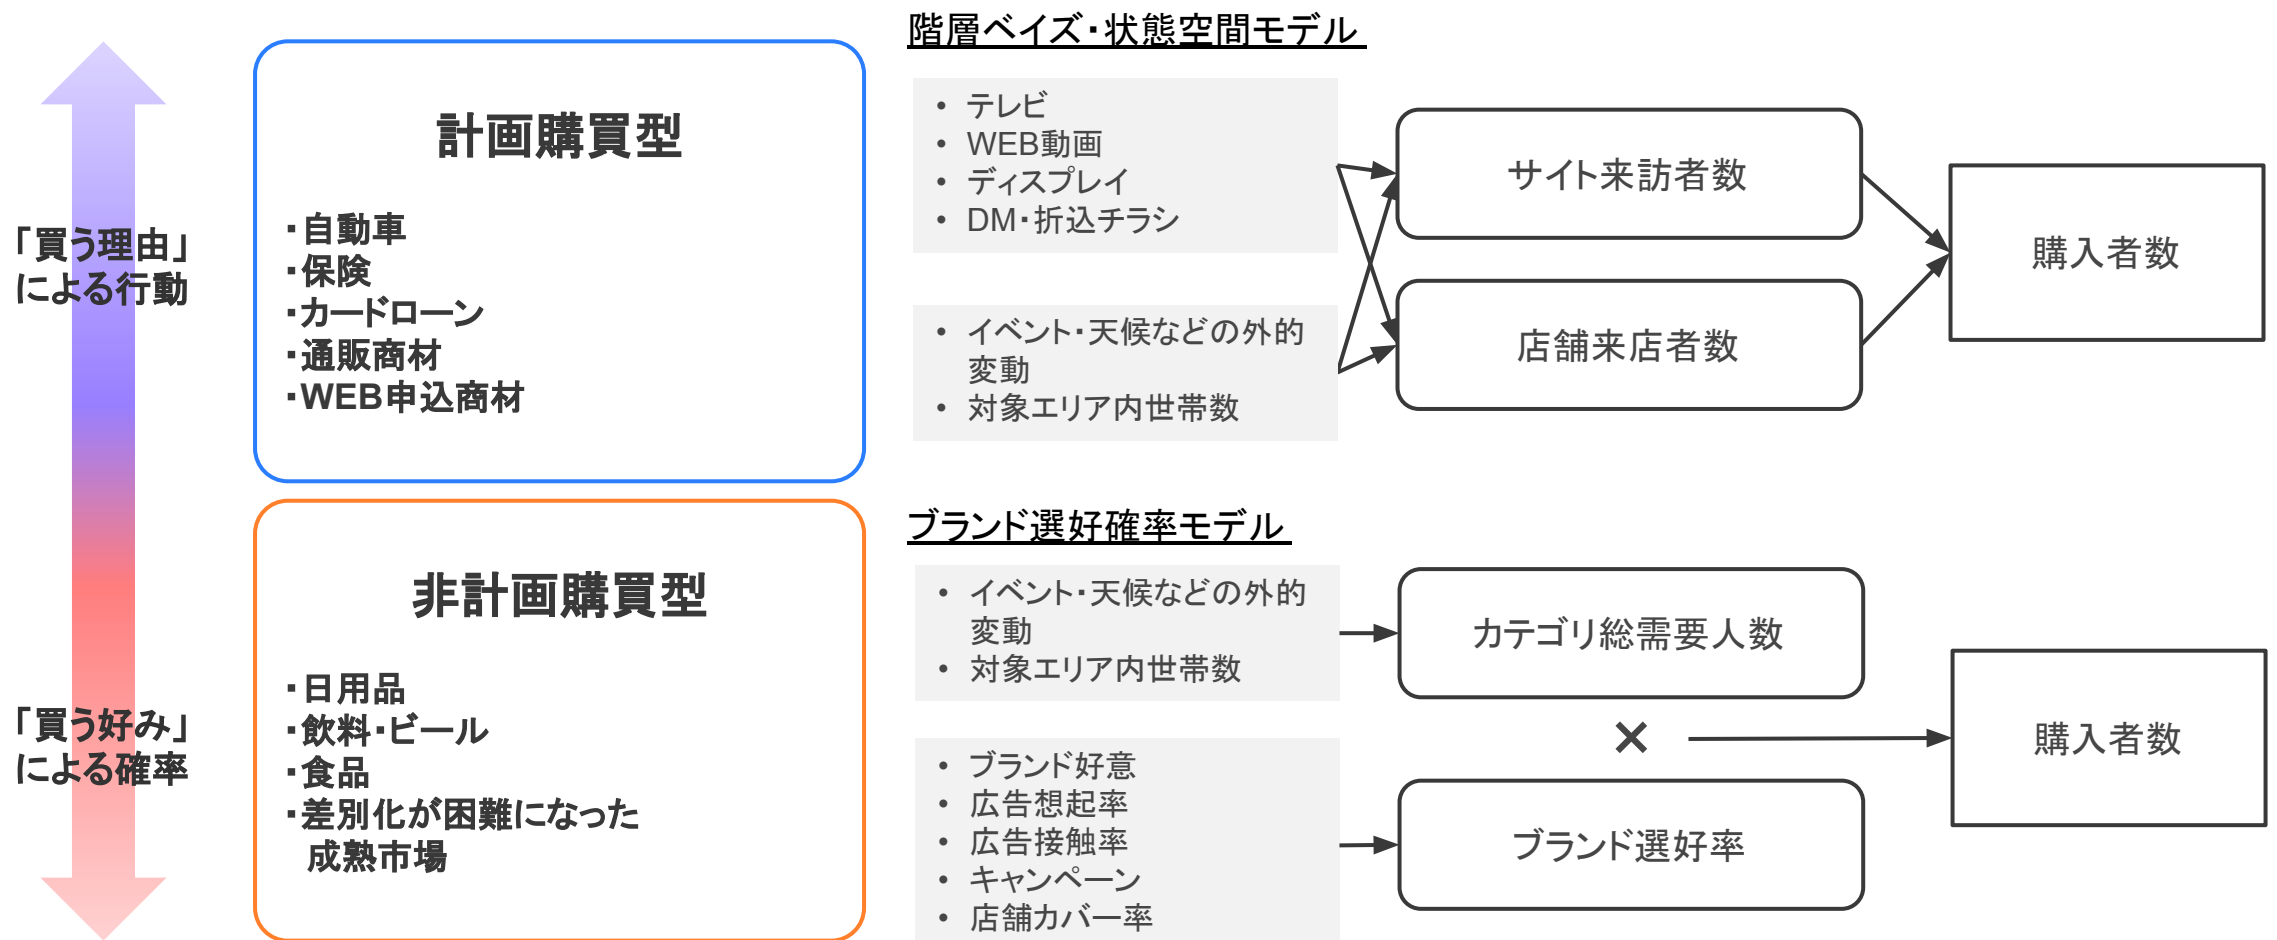







特に、飲料・食品・日用品といった消費財や家電など  
 オフライン型モデル構造にはAnalytics AaaS for CPGが対応します。



# Analytics AaaSでは商材・サービスごとの生活者の購買行動に適したモデル構造を採用したMMMをご提供しています。





「マーケティングミックスモデリングガイドブック」を  
ご覧いただきましてありがとうございます。

**MMMは世界的に注目されている有効なモデルですが、  
その利用には正しい理解が必要です。**

**モデルに対する理解不足や、自社のビジネスとの適合性を考慮しなかった場合、  
広告投資の判断を誤るリスクがございます。**

MMMの活用をお求めの際は、博報堂DYメディアパートナーズへご相談ください。

お問い合わせ先

博報堂DYメディアパートナーズ 広報室 山崎、戸田

Mail: mp.webmaster@hakuhodody-media.co.jp

# 卷末

---

CHAPTER 1

マーケティングミックスモデリングの  
紹介

執筆・文責:  
株式会社博報堂データドリブンプランニング局  
データサイエンス部  
株式会社博報堂DYメディアパートナーズ  
AaaSビジネス戦略局  
宮腰卓志 (Takashi Miyakoshi)

CHAPTER 2

マーケティングミックスモデリングの  
基本

執筆・文責:  
Google Asia Pacific  
Consumer and Market Insights  
Senior Marketing Effectiveness Research Manager  
中原啓智 (Hirotooshi Nakahara)

CHAPTER 3

MMMのモデル構造に関する考察

執筆・文責:  
株式会社博報堂データドリブンプランニング局  
データサイエンス部  
株式会社博報堂DYメディアパートナーズ  
AaaSビジネス戦略局  
宮腰卓志 (Takashi Miyakoshi)

株式会社博報堂データドリブンプランニング局  
データサイエンス部  
丸尾大貴 (Daiki Maruo)

テクニカルサポート:  
Google Asia Pacific  
Consumer and Market Insights  
Senior Marketing Effectiveness Research Manager  
中原啓智 (Hirotooshi Nakahara)

Googleレビュー協力者 (CHAPTER 2, 3):  
Head of Analytics, Consumer and Market Insights, Google Australia  
Senior Marketing Research Manager, Consumer and Market Insights, Google Japan  
Data Scientist, Strategic Insights & Communication, Google Japan

Rohan Gifford  
Minh Nguyen  
Takashi J Ozaki