

# Marketing Mix Modelingガイドブック

マーケティングROIを正しく評価するための実践的な分析ガイド

DENTSU  
DIGITAL

# 目次

## CHAPTER 1 MMMの概要 (p.3)

## CHAPTER 2 MMMモデリングの基礎 (p.11)

- 2.1. データの選択 (p.13)
- 2.2. データクレンジング (p.22)
- 2.3. モデル構造の作成 (p.32)
- 2.4. パラメータの推定 (p.50)
- 2.5. モデルの検証 (p.55)
- 2.6. モデルの利用 (p.70)
- 2.7. その他のMMMに関するトピック (p.75)

## CHAPTER 3 MMMにおける検索広告のモデリングの考察 (p.78)

## CHAPTER 4 dentsuのMMMのケイパビリティ (p.90)

# CHAPTER 1: MMMの概要

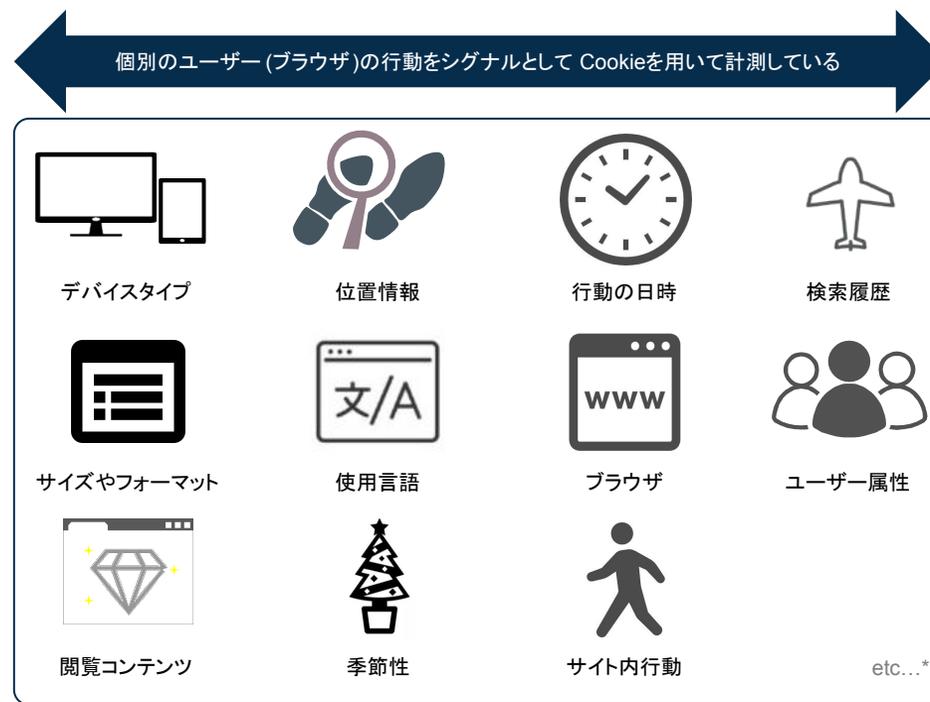
この章では、マーケティングの効果測定における ”シグナル” の収集に関する問題と、マーケターにとっての MMMの重要性について MMMの概要を交えて説明する。

## インターネット広告における”シグナル”の活用について

インターネット上での個々のユーザーの行動、すなわち”シグナル”を計測するために、WebブラウザのCookieが利用されていたが、プライバシー保護の流れから、Cookieを利用した計測が大幅に制限され、広告出稿などに利用できるシグナルの取得が難しくなっている。Cookieは、ECサイトでユーザーがカートに入れた商品を記憶したり、ユーザーが興味を持つ広告を表示したりするなど、インターネット上でのユーザーの行動を計測し、より良い体験を提供する技術の中核を担ってきた。一方で近年、多くの地域でCookieの利用に対して段階的に制限がかけられており、広告主や広告配信事業者はこれまでとは異なる新たなマーケティング手法への転換を余儀なくされている。

Cookieとは、ユーザーの行動などを記録するためにWebサーバーからブラウザ(Chrome、Safariなど)に格納される小容量のデータのこと、主にユーザー(ブラウザ)の識別などに用いられる。また、Cookieは発行元のドメインによって2種類に分けられる。1つは1st Party Cookieで、アクセスしているドメインと同じサーバーから発行される。これは、例えばECサイトでカートに保存されたアイテムを記憶するためなどに使用される。もう1つは3rd Party Cookieで、アクセスしているドメインとは異なるドメイン、例えばインターネット広告配信事業者のドメインなどから発行される。3rd Party Cookieでは、複数のサイトにまたがるユーザー行動を追跡することができるため、ユーザーの興味に合った広告を表示したり、ドメインをまたいだ広告接触によるコンバージョンを追跡したりすることが可能となる。

このように、Cookieは現代のインターネット広告の配信において重要な役割を果たしているが、特に3rd Party Cookieは、ユーザーの知らない間にドメインをまたいで追跡されるという点でプライバシー上の問題になっている。



ユーザーのプライバシーに関する懸念と関心の高まり

## デジタルマーケティングにおけるプライバシー保護に関する規制の概要

世界中のあらゆる地域で独自の規制が実施されており、規制の内容も更新を繰り返している。日本では2022年4月に大きく改正され施行された個人情報保護法だけでなく、2023年6月には電気通信事業法の改正法も施行されており国内のデジタルマーケティング活動に影響を与えている。

### GDPR (一般データ保護規則)



- Cookieやその他のオンライン識別子も個人情報として扱われる。
- 利用目的の明示と明確な同意が必要となる。そのため、同意管理プラットフォームの導入が必要になる。

### CPRA (カリフォルニア州 消費者プライバシー権法)



- Cookieのみならず位置情報なども個人情報として扱われる。
- データ管理・利用状況の通知や開示対応義務などが求められる。

### 個人情報保護法



- Cookiesやその他のオンライン識別子を個人関連情報とみなす。
- 個人情報と個人関連情報を照合する際、第三者への提供について同意を取得する義務が求められる。

## ブラウザにおける規制状況(2023年7月現在) Googleアップデート版

3rd Party CookieはSafariだけでなく、将来的にはChromeにおいても利用できなくなる。3rd Party Cookieはメジャメントやターゲティング、配信の最適化にも利用されているためその影響は大きい。



1st Party Cookie	制限なし
3rd Party Cookie	2024年後半から段階的に廃止
モバイルデバイスID (ADID)	現時点では利用可能

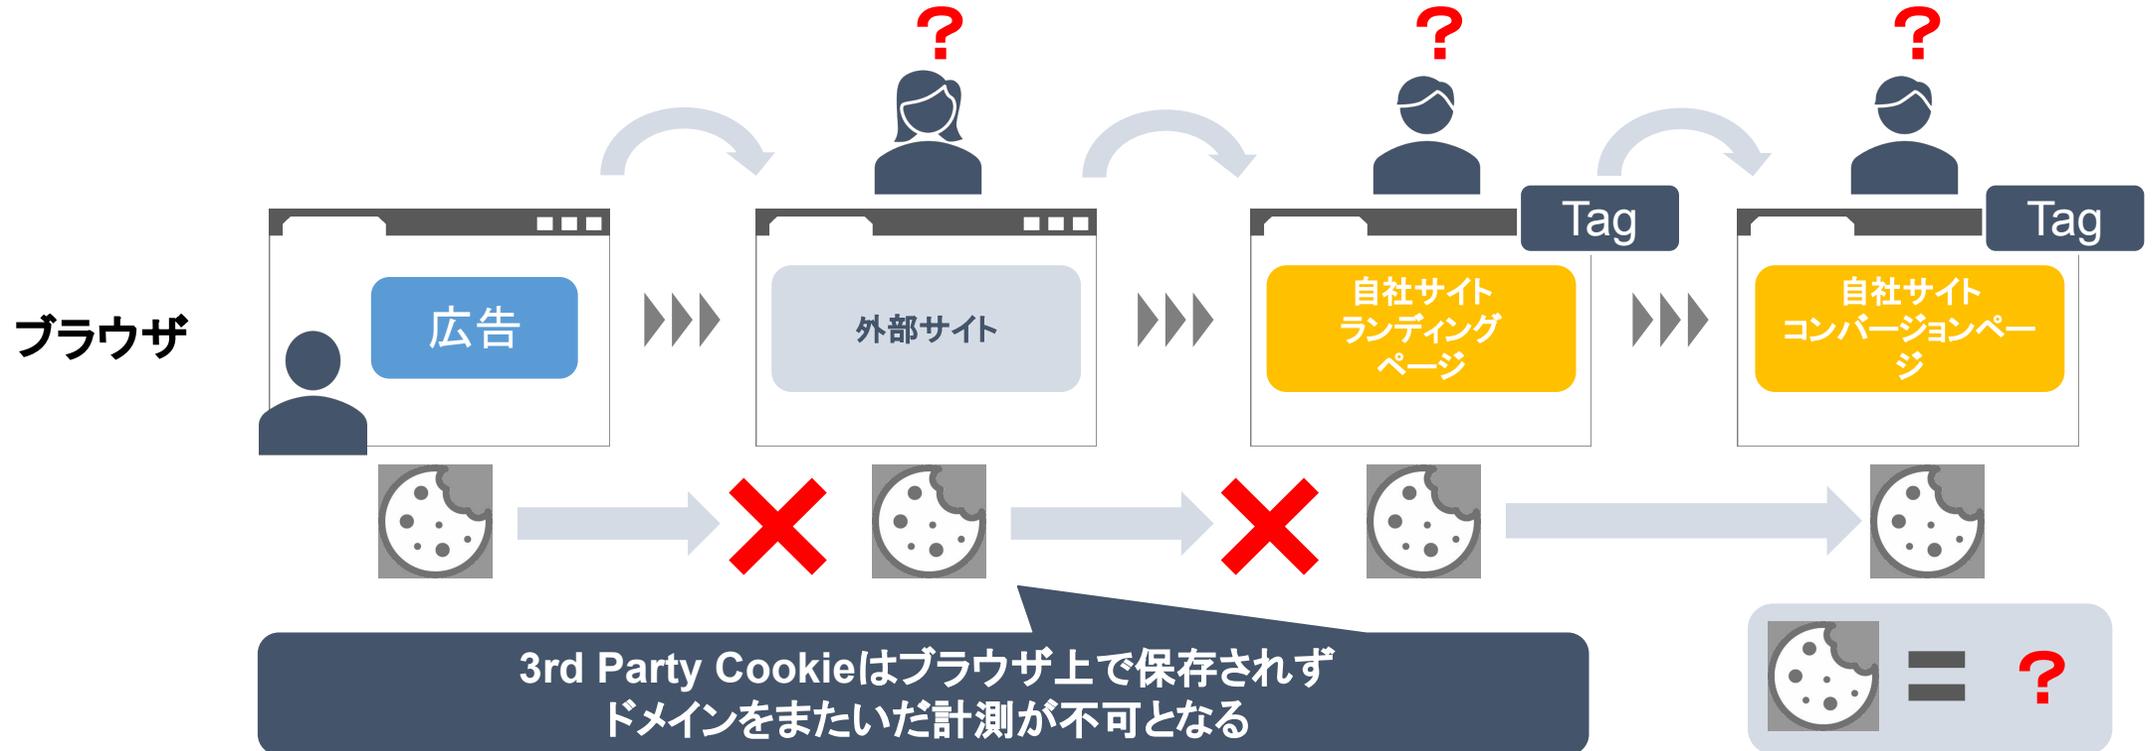


iOS上のSafari以外のブラウザも対象となる

1st Party Cookie	計測目的のものは24時間で削除
3rd Party Cookie	即時削除
モバイルデバイスID (IDFA)	オプトインしたユーザーのもののみ利用可能

## 既存の計測ソリューションへの影響の分析

Cookieの利用制限により、これまで取得できていたデータが取得できなくなり、従来と同様の広告配信・計測が困難になっている。従来はWebサイトにコンバージョンタグを埋め込むだけで広告によるコンバージョンを計測し広告効果を評価することができましたが、ドメインをまたいだコンバージョンの計測ができなくなり、広告効果の過小評価につながる懸念が高まっている。そのため従来のアトリビューション分析に加え、各メディアチャネルの成果やROIへの貢献度を評価し、より最適な予算配分プランを導き出す手法の必要性が高まっている。



# MMMとは何か

MMM = Marketing Mix Modelingであり、主に広告メディアがどのように事業成果に影響しているかを過去の広告の出稿量と成果の時系列データを基にモデリングする手法の総称である。広告の繰越効果や反応曲線を考慮した上で、各広告メディアでの出稿量やその他の外部的要因と事業成果との関係を回帰的にモデリングする方法が多くの場合で用いられる。

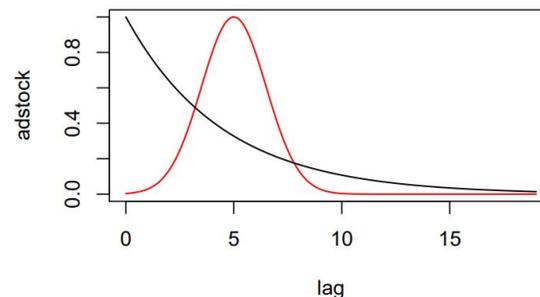
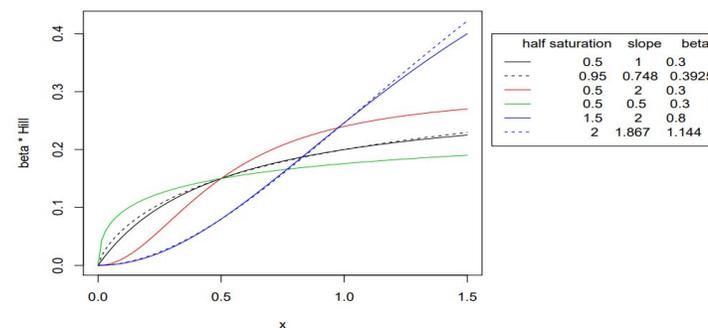


反応曲線\*

$$\text{Hill}(x_{t,m}; \mathcal{K}_m, \mathcal{S}_m) = \frac{1}{1 + (x_{t,m}/\mathcal{K}_m)^{-\mathcal{S}_m}}, \quad x_{t,m} \geq 0$$

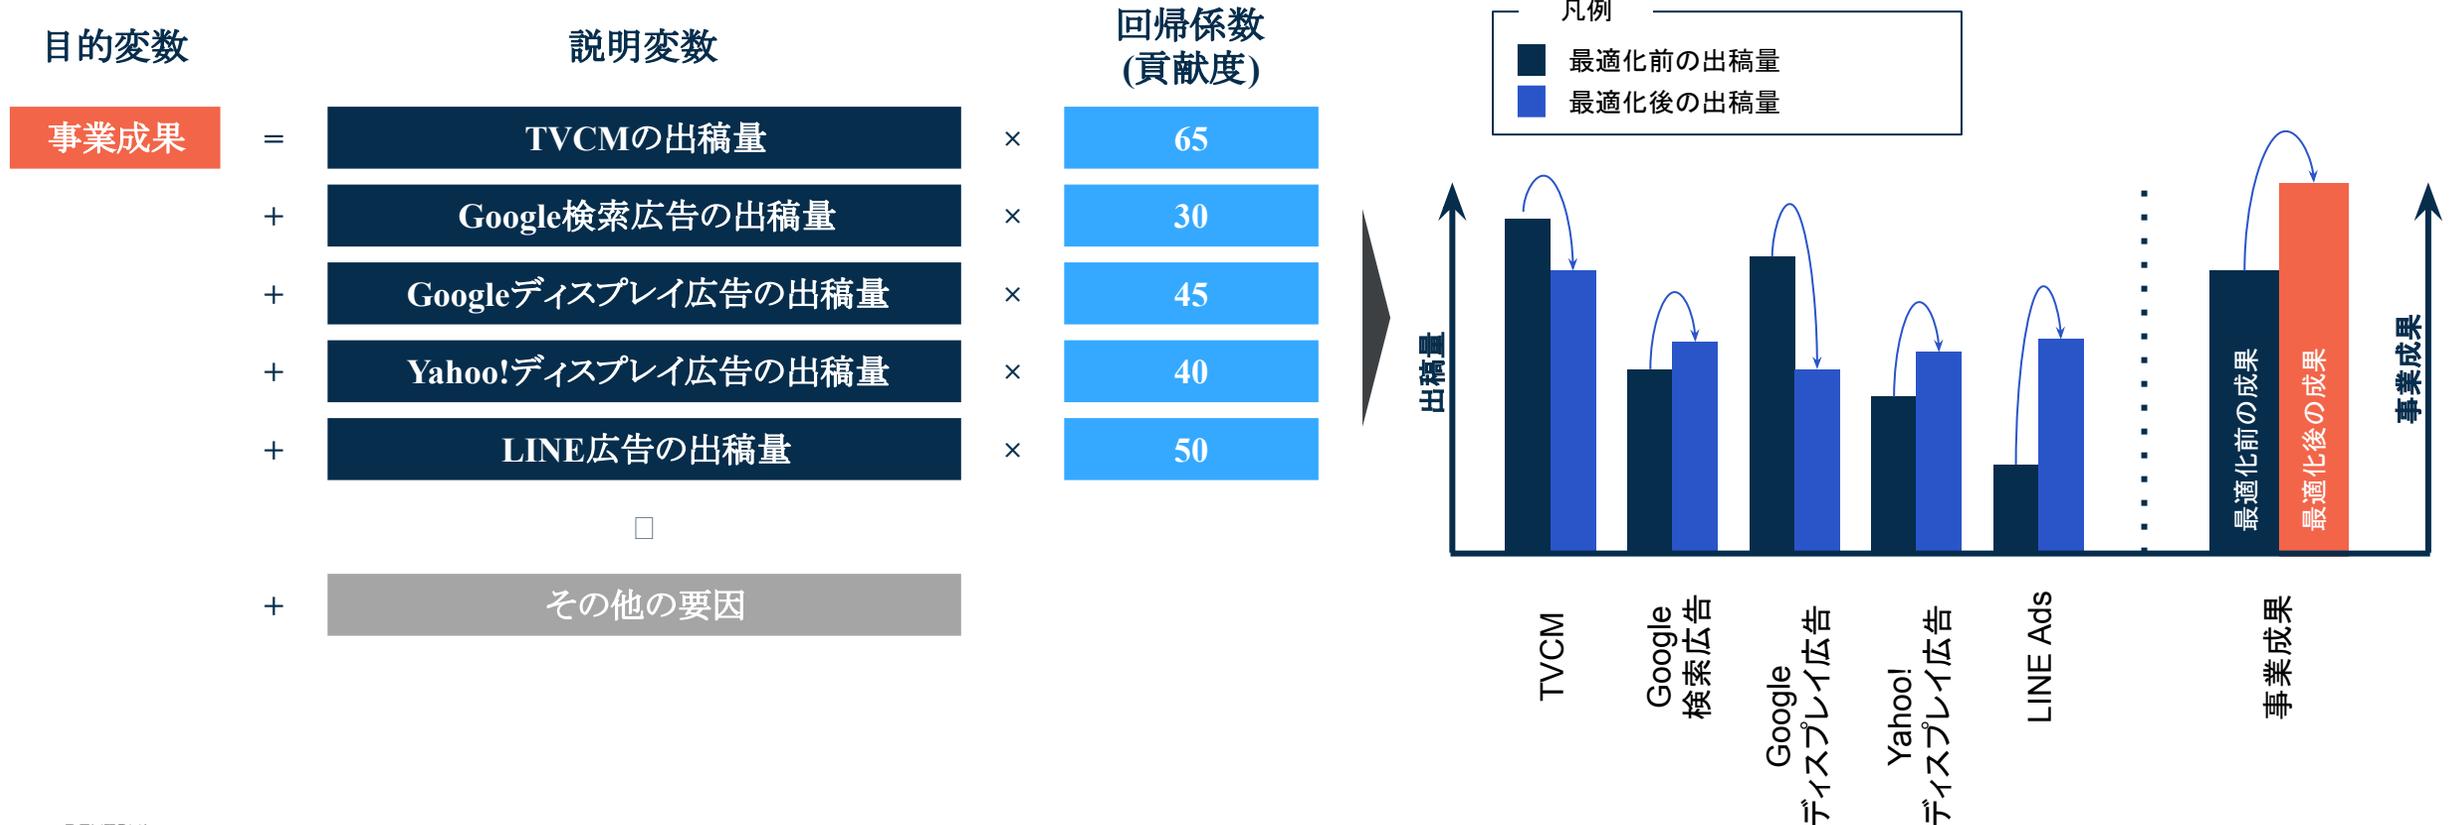
繰越曲線\*

$$\text{adstock}(x_{t-L+1,m}, \dots, x_{t,m}; w_m, L) = \frac{\sum_{l=0}^{L-1} w_m(l)x_{t-l,m}}{\sum_{l=0}^{L-1} w_m(l)}$$



## MMMのアウトプットの例

重回帰分析により各広告メディアでの貢献度(回帰係数)を推定する。これによって得られた回帰式を使うことで、広告の出稿量から事業成果を予測することができる。出稿量の組合せに対する成果の探索的なシミュレーションによって、最も成果が高くなる最適な出稿量の配分案を得ることができる。



# MMMの活用が盛んになっている理由

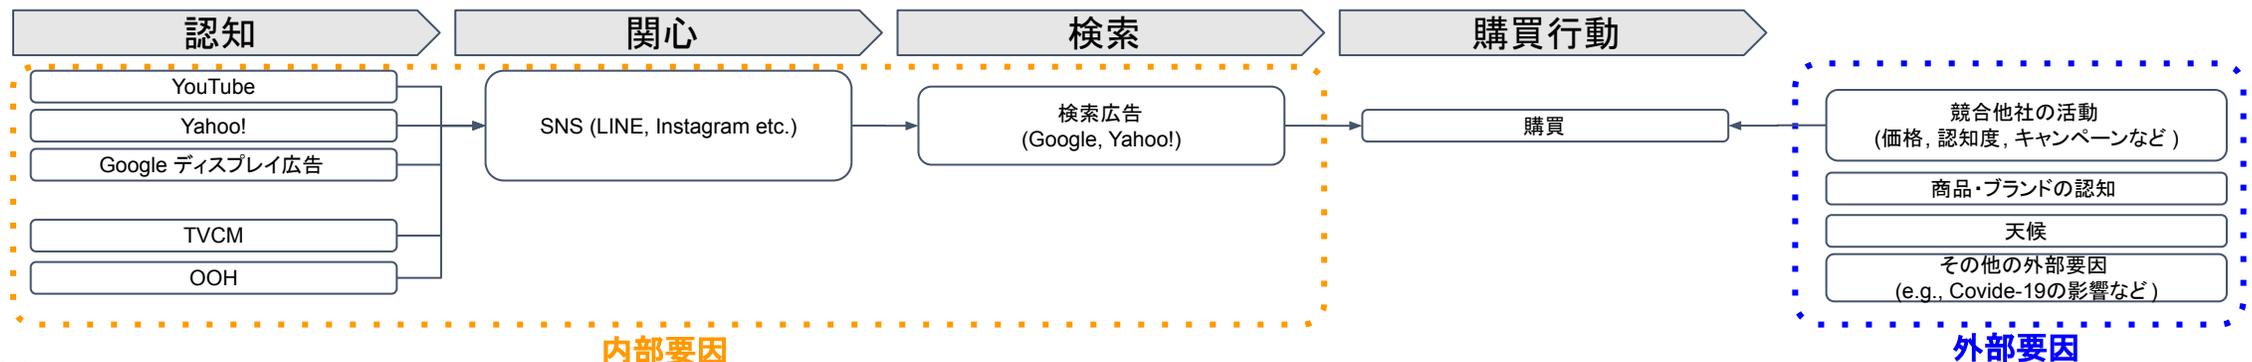
MMMの活用が進む背景としては主に以下の2点が挙げられる。

- ①プライバシー保護の観点で顧客の行動データを必要としない分析手法であること
- ②各種広告メディア施策の影響のみならず、自社の制御下でない競合他社の活動や天候などの外部要因を含めて包括的に分析できること

①については現在、Cookieを使用した個人の行動データに基づく分析の精度を担保することが技術的に難しくなりつつある。しかし、基本的にMMMでは広告出稿実績データや販売量データなどCookieに依存しないデータを使用し分析を行うことが可能である。そのため、Cookieの規制にとらわれず自社のマーケティングを分析し、施策の効果を推定できる。そのため現在ではCookieの制限下における各メディアの貢献を評価するのに適したアプローチであると考えられている。

②について、MMMではユーザーの購買意思決定プロセスに基づいてモデリングを行うことを想定している。例えば、マーケティング活動においてコンバージョン数を成果とする場合、企業のマーケティング担当者はおおよそ以下のようなユーザー行動プロセスを想定し、そのプロセスに沿った施策を設計することが多いと考えられる。一般的にマーケターは、自社のマーケティング活動などの内部要因を分析し、外部要因である季節性や競合他社の活動などの別レポートを比較したり、調査データなどを用いて何が成果に寄与しているかを推定することが想定される。

一方で、上記の場合、人の恣意性や分析結果の解釈の程度によって得られる示唆は様々な結果を導くことになる。加えて、内外要因を別々の分析結果を照らし合わせながら施策の効果を推測することは一元的な分析とは言えない。その為、内外要因の関連性を考慮した包括的な分析が求められる。そのような背景もあり、統計モデリングにおけるMMMを用いる利点としてはモデルの内部構造に透明性があることや、マーケターが想定する行動プロセスをモデルに反映できることから、マーケティング活動の効果検証に対してある程度の属人性や恣意性を抑制した結果を得られる可能性がある。また、マーケティング活動の各要因の関連性を包括的に扱い、成果に対する効果を定量化できることがその価値であると考えられる。一方で、モデリングをする際にはマーケティング及びデータサイエンス、特に計量経済学など効果検証理論に明るい人材やパートナー企業とともに、適切なデータ選択やモデル設計のアプローチを勘案していくことが重要となる。



# CHAPTER 2: MMMモデリングの基礎

この章では、典型的な MMMの作成プロセスとモデル作成者が注意すべき点について解説する。

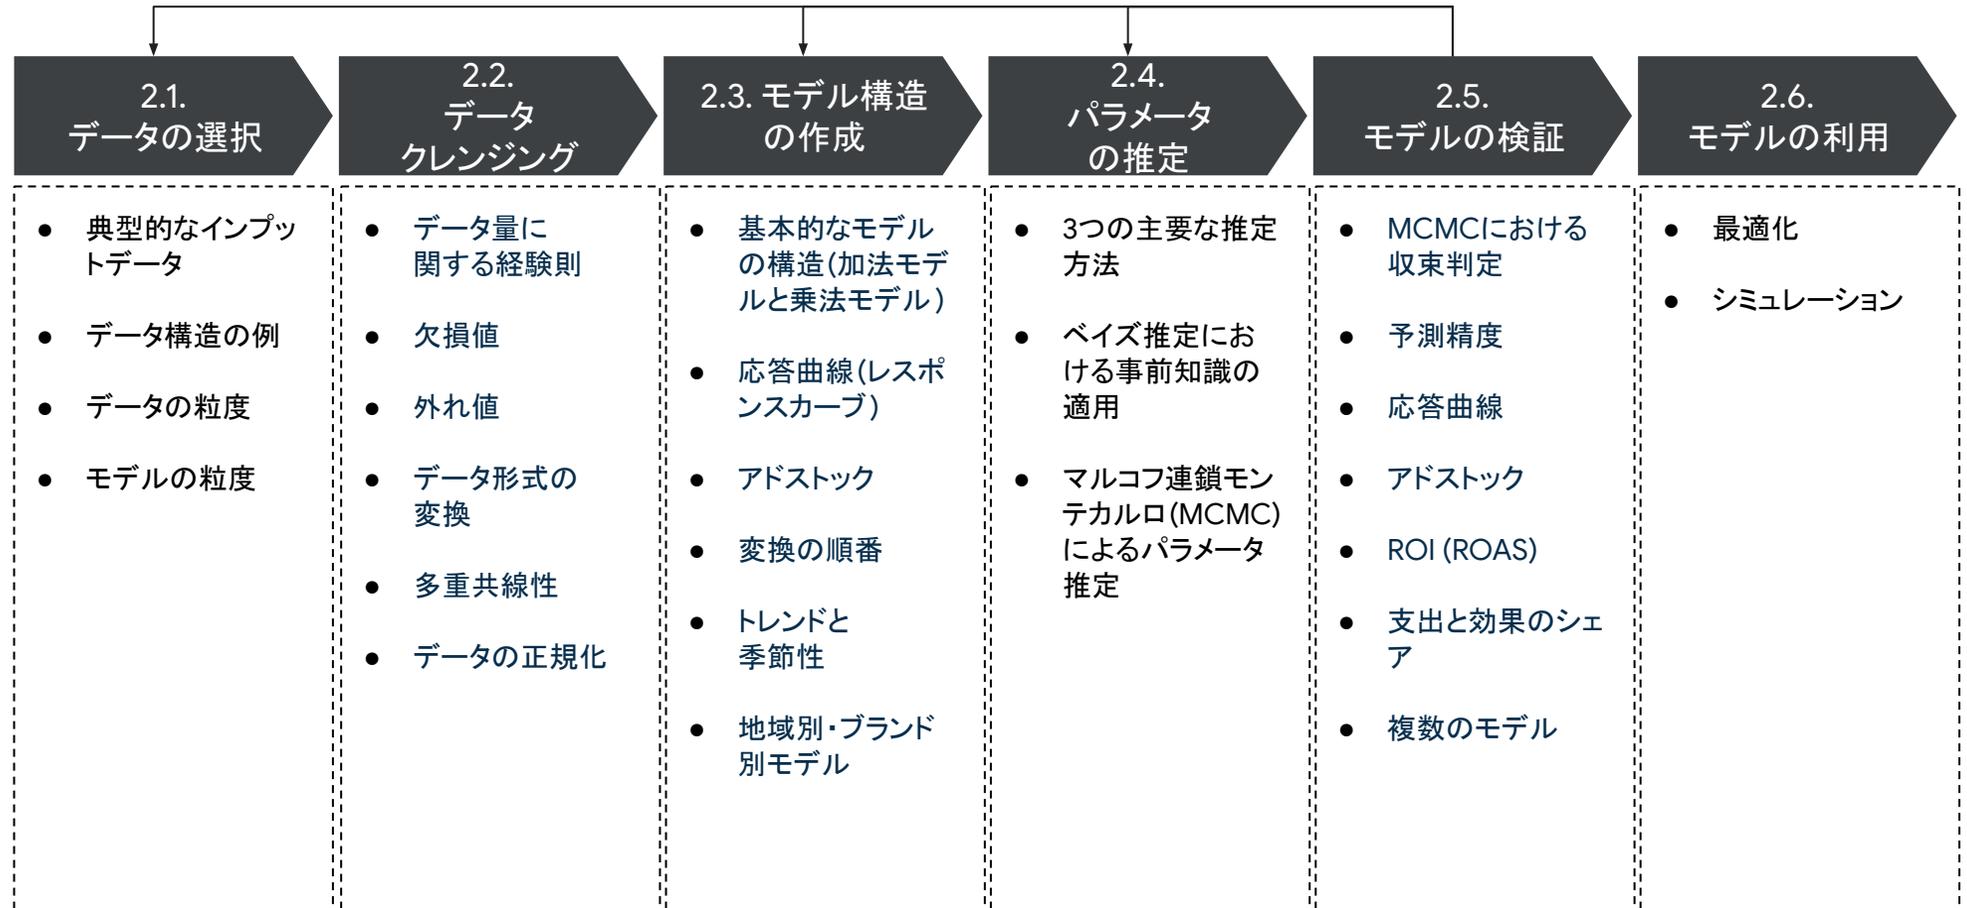
# MMMのモデル構築プロセス

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

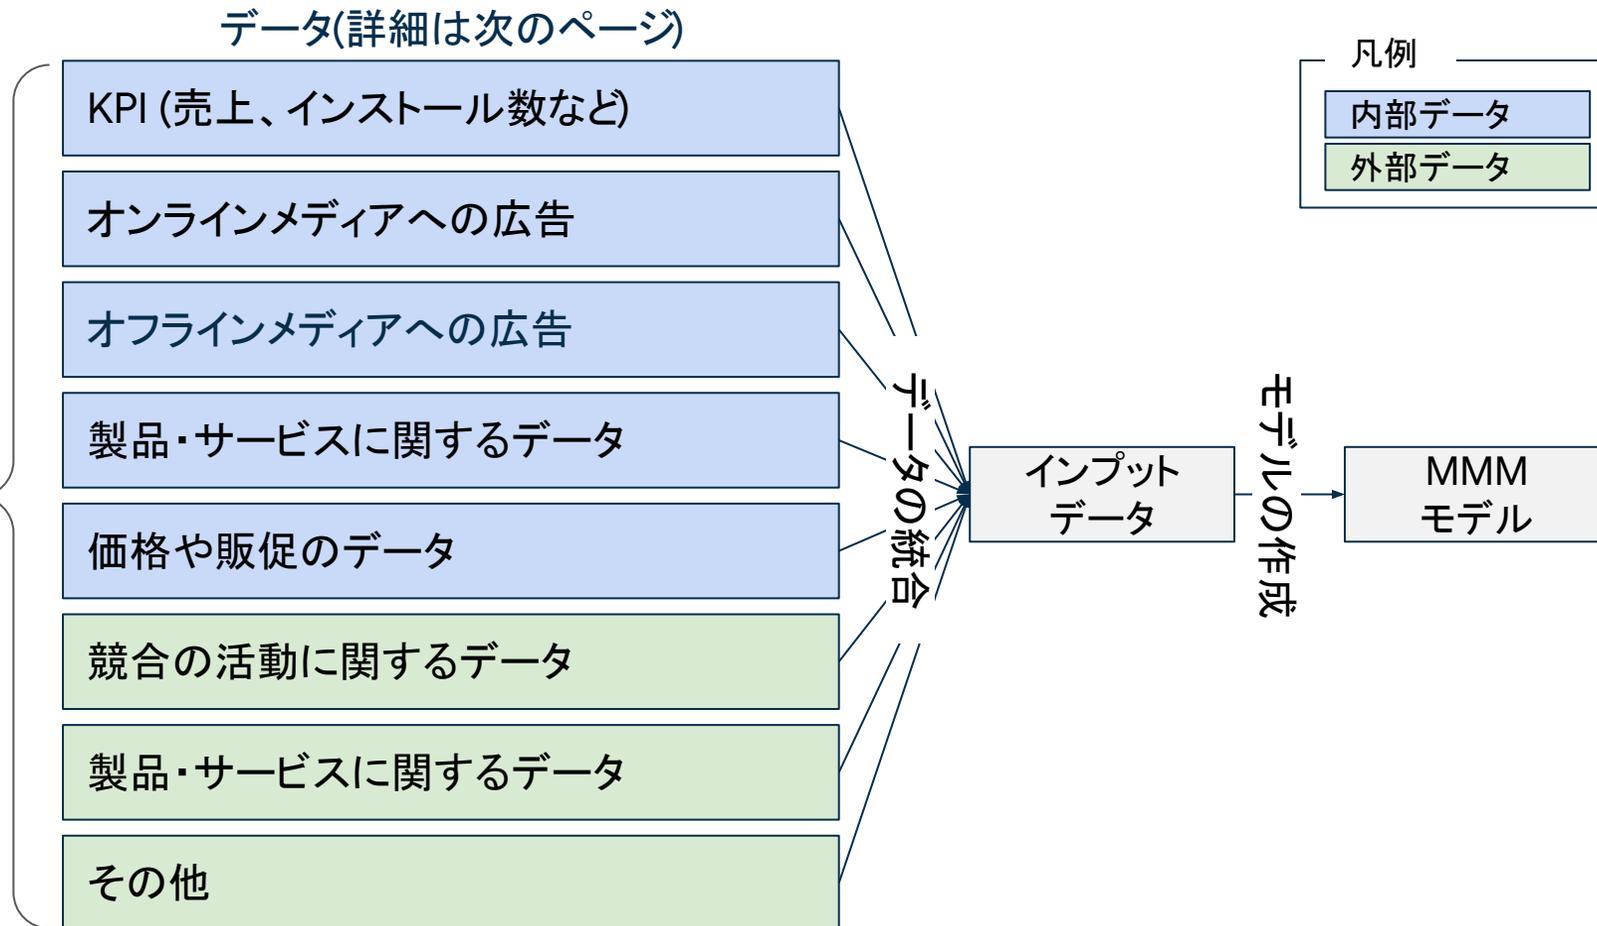
## データの選択の概要

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)



## 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)\*

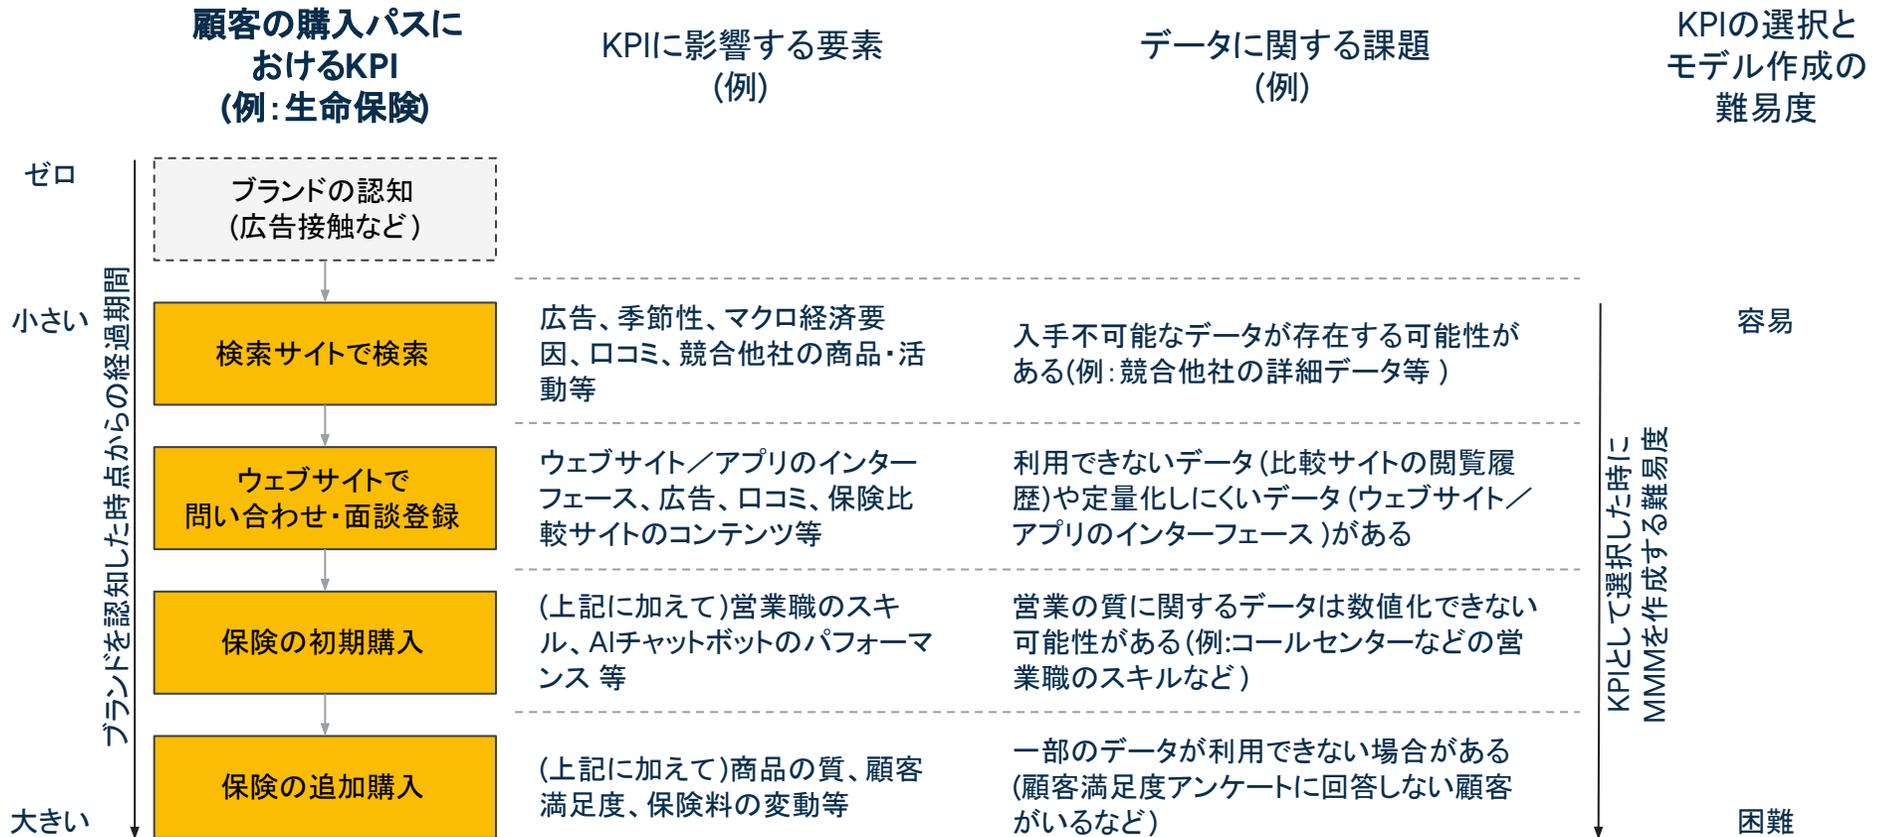
## KPIの選択は、MMMを作成する上で極めて重要である

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。

### 選択肢

### 説明

### 一般的な判断基準

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MMM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、研究がなされている。

広告費

- 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

- **非推奨**: 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

インプレッション

- 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
- 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。
- 変化系: ビューアブル・インプレッション、GRP(TV)

- **推奨**: 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
- 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)

リーチとフリクエンシー

- 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
- 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

- **データに課題あり**: 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

クリック

- 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
- 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

- **限られた状況で推奨**: クリック数はビューの効果の説明ができない(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に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

ビュー

- 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
- 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

- **非推奨**: 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

## 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

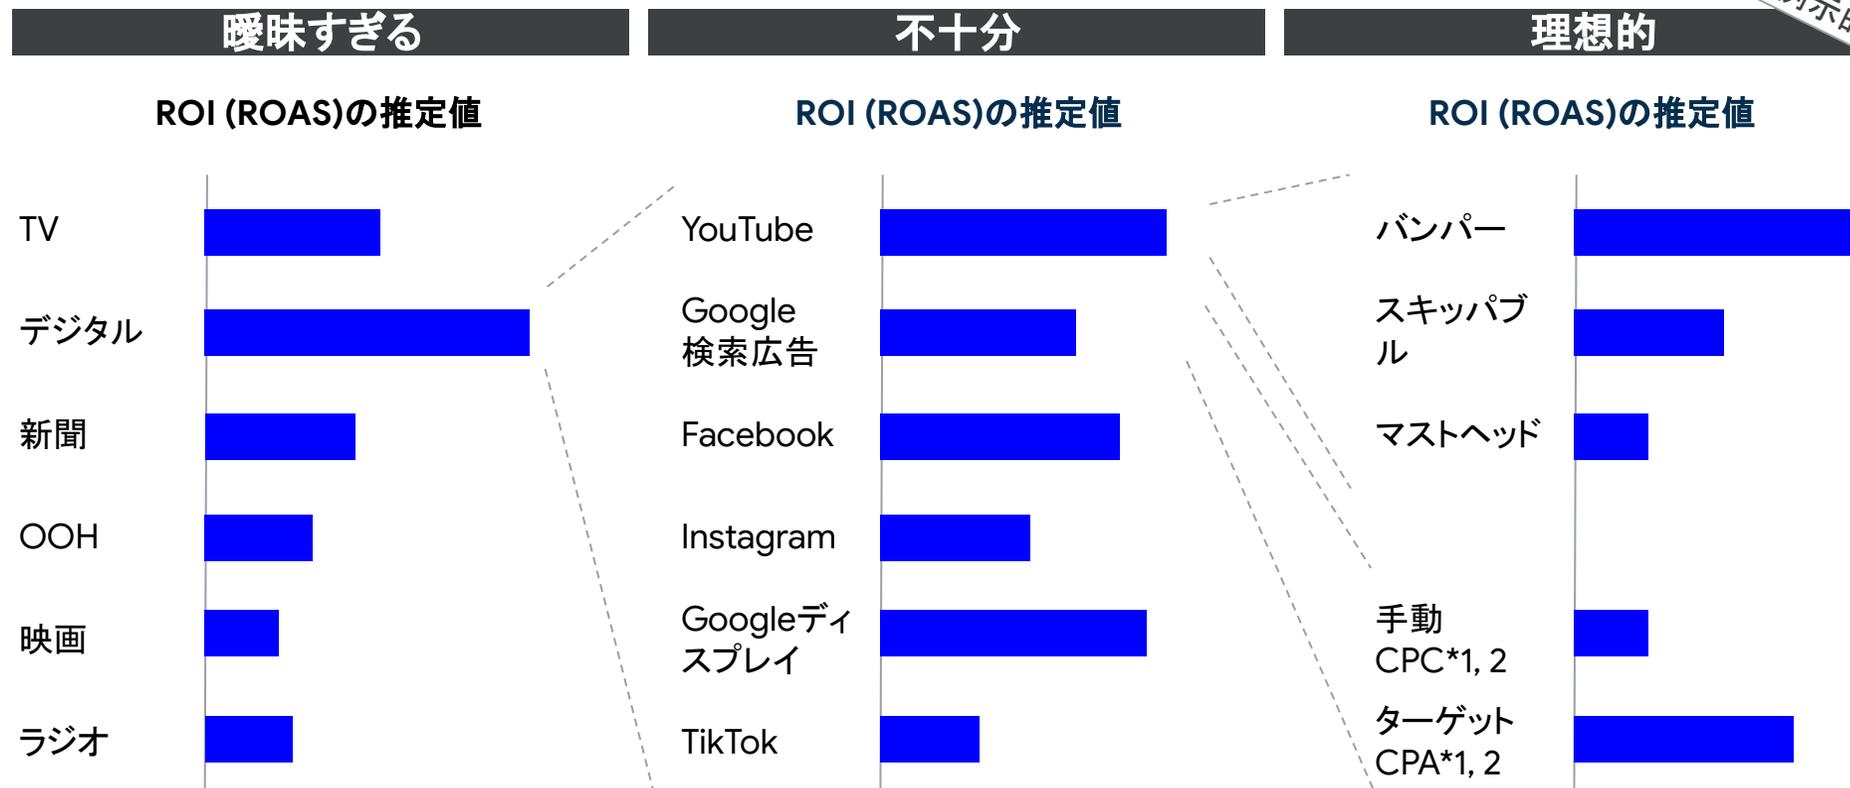
打ち手が明確な分析結果を提供するためには、MMMのインプットデータのメディアデータの粒度が重要である。

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



\*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、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(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 $100 - 20 = 80$ 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つの標本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(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.48-49)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

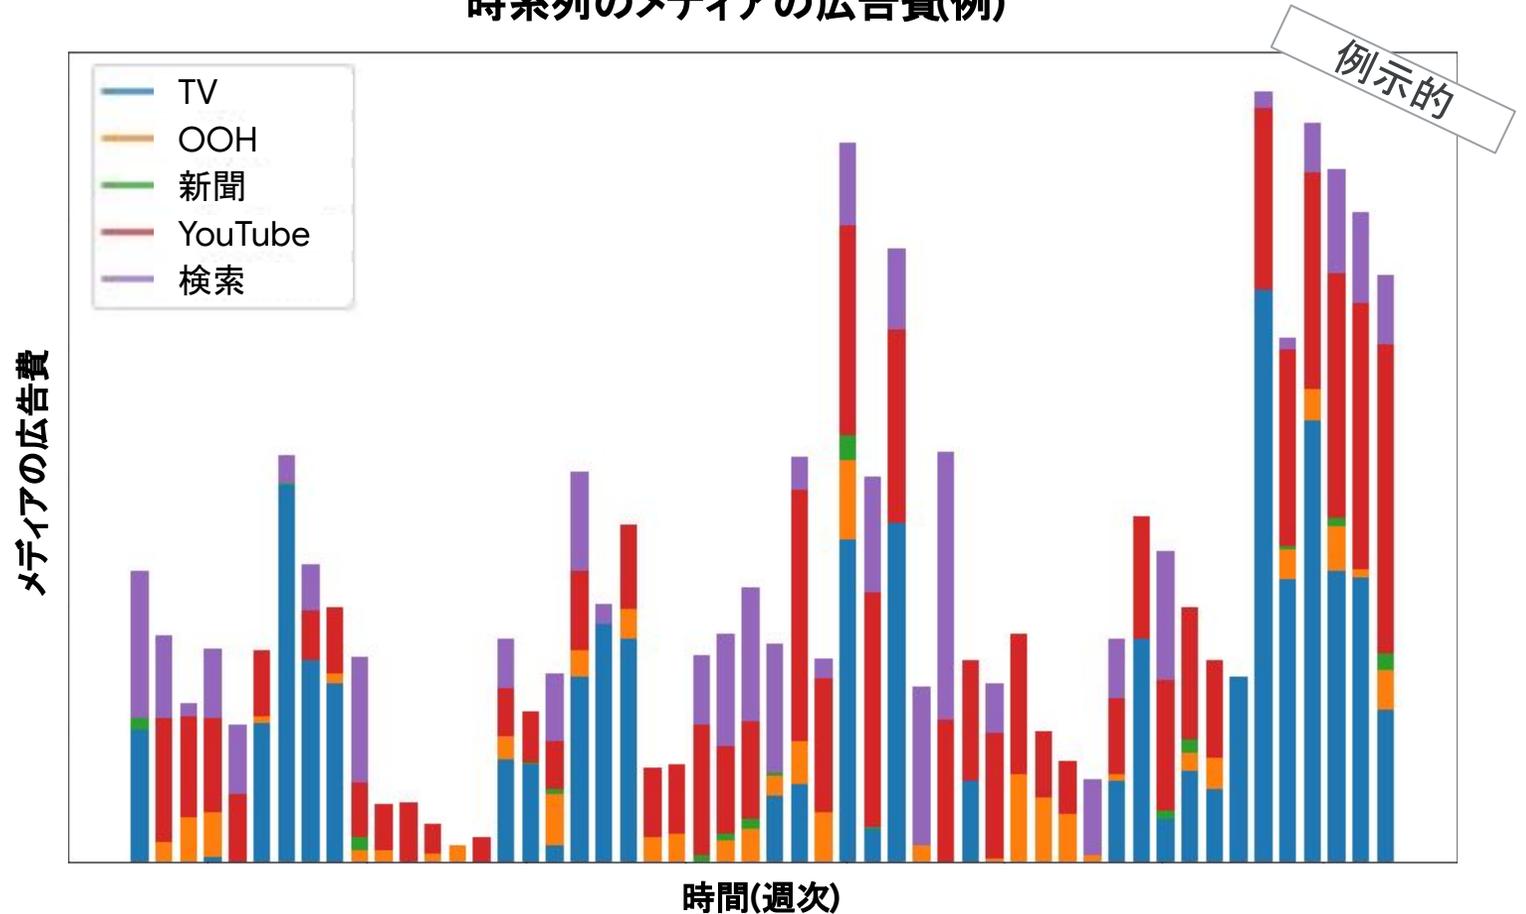
データ量の観点からもうひとつ考慮すべきは、メディアへの投資傾向である。

**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.30)

**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)

<p>実質的にゼロ</p>	<p>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</p>
<p>データの粒度不足</p>	<p>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)</p>
<p>人的ミスまたは体系的なエラー</p>	<p>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)</p>

# 一般的な欠損値の取扱方法

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	
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		
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			
データの粒度不足	補完方法を検討					
人的ミスまたは系統的なエラー						

**確率的回帰代入か、多重代入法が現実的な選択肢**

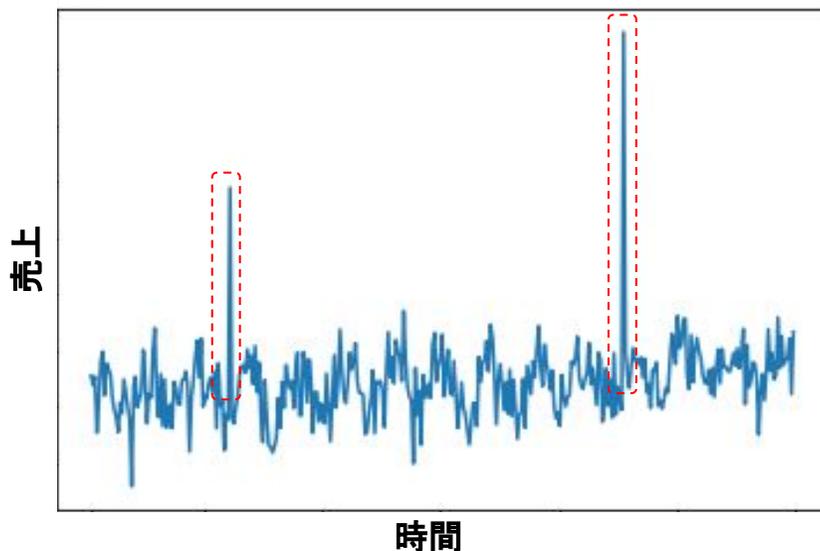
## MMMにおける外れ値の扱い

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

## データ形式の変換

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。

### 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% discount, grocery	2021/2/1	10	1	0
2021/2/2	10% discount, grocery	2021/2/2	10	1	0
2021/2/3	10% discount, grocery	2021/2/3	10	1	0
2021/2/4	10% discount, grocery	2021/2/4	10	1	0
2021/2/5	10% discount, grocery	2021/2/5	10	1	0
2021/2/6	10% discount, grocery	2021/2/6	10	1	0
2021/2/7	10% discount, 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、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、カテゴリなどタイプ別に適切にモデル化されるべきである(後述)。

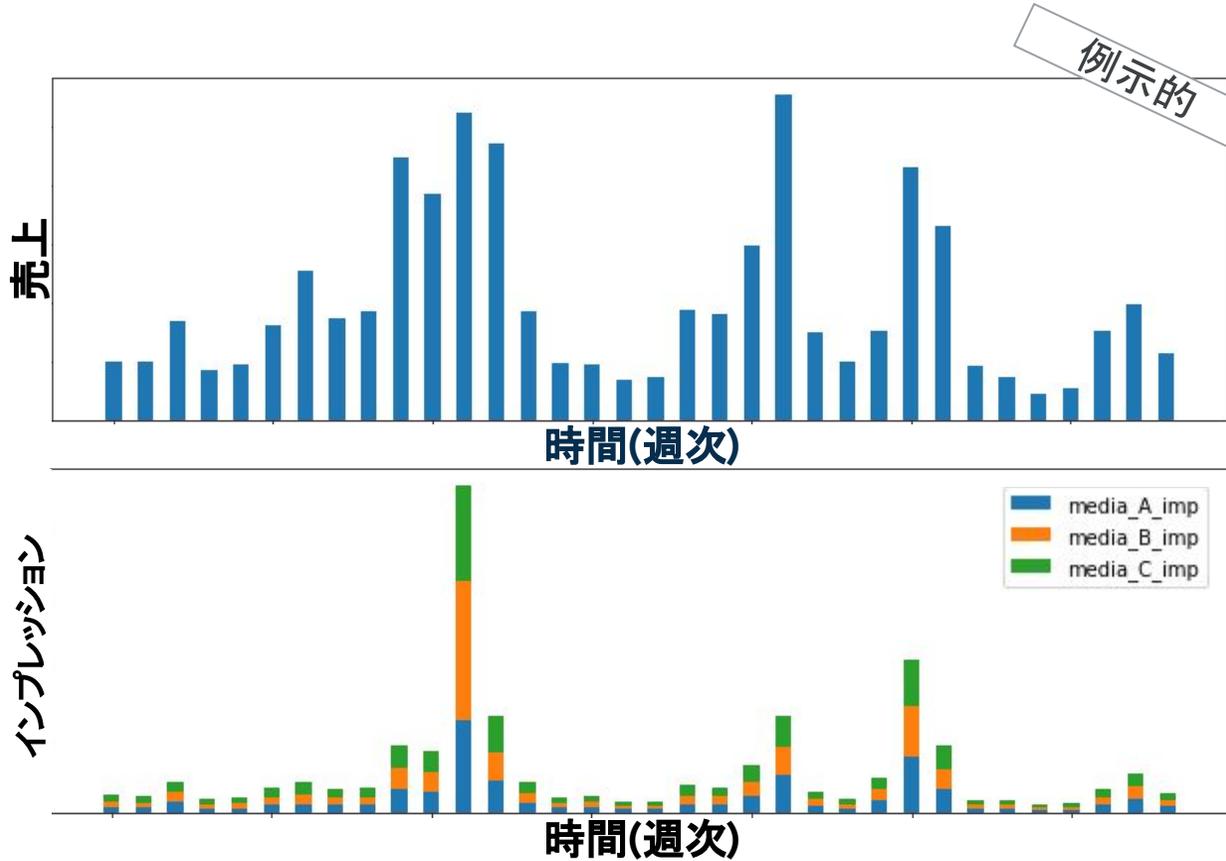
# 多重共線性の紹介

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一つである。

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。

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



## 回帰分析の結果

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

- 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？

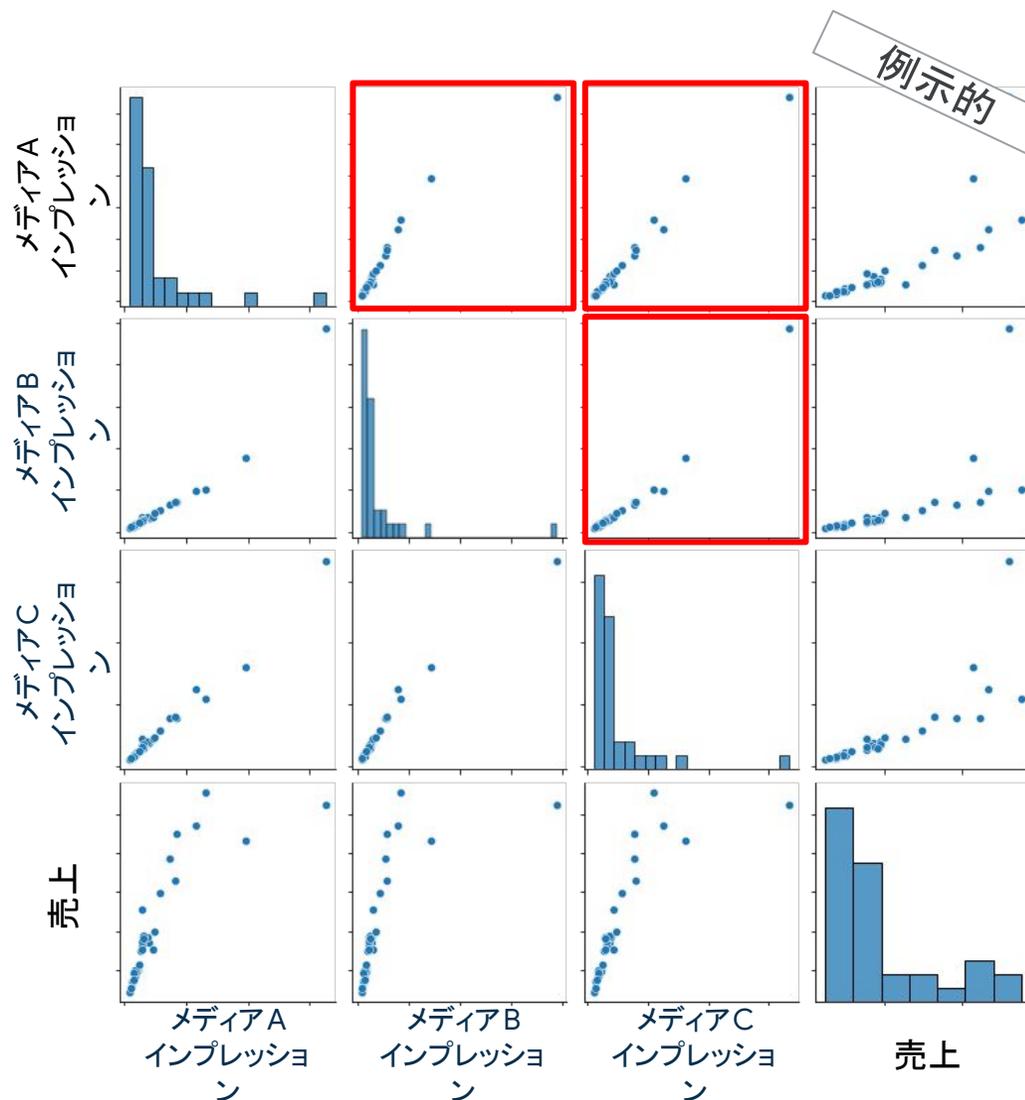
\*1: 当該モデルは多重共線性の例を説明するための例であり、実例でこのような単純なモデルを使用することはない。  
 \*2: 当該データは政府統計の都道府県別産業労働者数と乗用車数のデータを用いて、仮のデータとして作ったものである。実際のメディアに関するデータではない。

## 多重共線性のメカニズムの概要

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.51))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)

# 多重共線性の典型的な対応方法

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:顧客セグメント、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

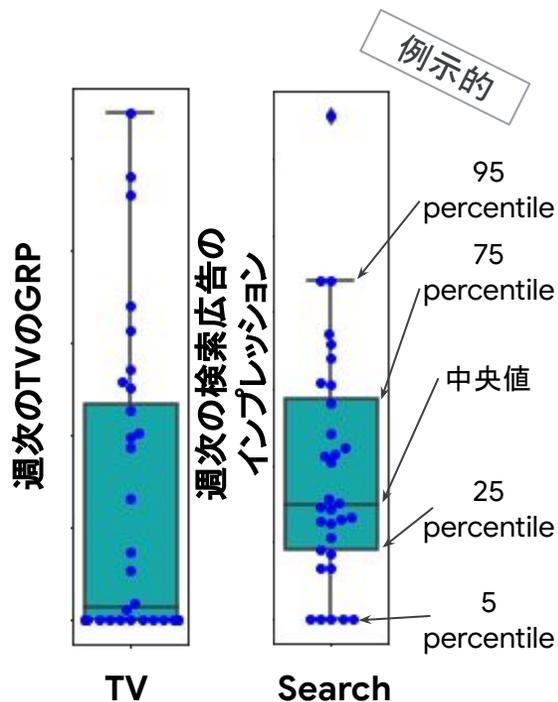
# データの正規化

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

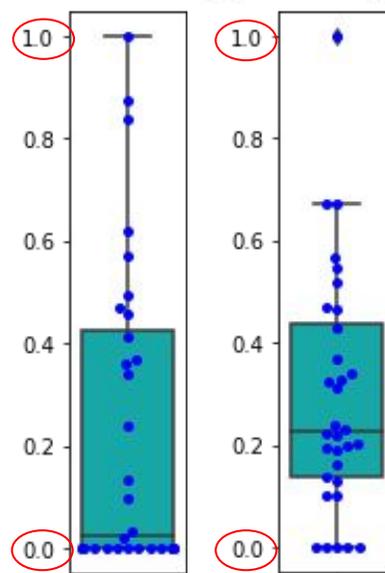
方法

Min-max

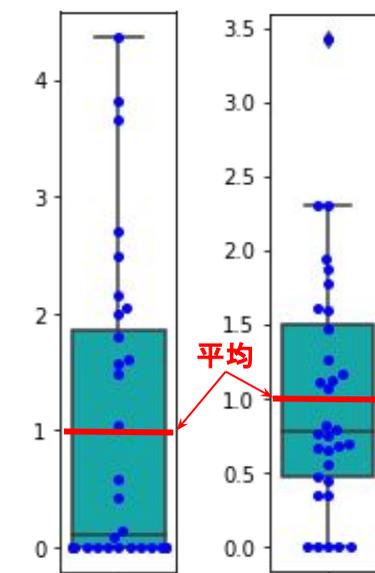
平均

標準化

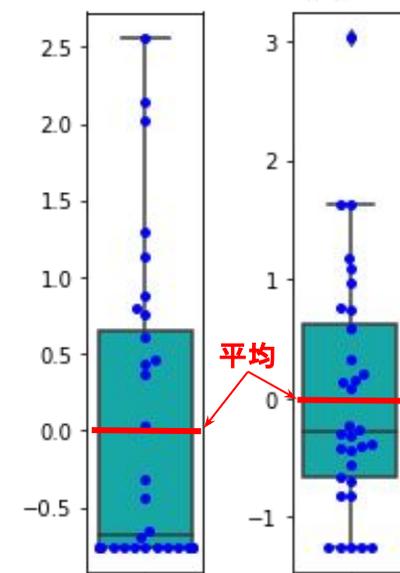
$$x_{scaled} = \frac{x - \min(x)}{\max(x) - \min(x)}$$



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



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



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第3章を参照。

# 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3章で説明する。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

$$\text{Revenue}_t = b + \sum_m \beta_m * \text{Hill} \left( \text{Adstock}(x_{t,m}, \dots, x_{t-l,m}; L, w_m(l; \alpha_m, \theta_m)), K_m, S_m \right) + \text{trend}_t + \text{seas}_t + \sum_c \gamma_c d_{t,c} + \epsilon_t$$

切片 (バイアス) (points to  $b$ )  
全てのメディアについて右記の変換を行い、合計する (points to  $\sum_m$ )  
(A) 応答曲線変換 (points to  $\text{Hill}$ )  
(B) アドストック変換 (points to  $\text{Adstock}$ )  
(C)トレンド (points to  $\text{trend}_t$ )  
(C) 季節性 (points to  $\text{seas}_t$ )  
その他の変数\*2 (points to  $\sum_c \gamma_c d_{t,c}$ )  
ランダムノイズ (points to  $\epsilon_t$ )

\*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。

\*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<sup>1)</sup>)

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

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

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



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

# 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。



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

		$Revenue = \dots + 0.7 * x_{TV} + 0.8 * x_{SEM} + \dots$	
売上貢献	Before	1M x 0.7 = 0.7M	1M x 0.8 = 0.8M
	After	<b>2M</b> x 0.7 = 1.4M	<b>2M</b> x 0.8 = 1.6M
	売上の増分	1.4M - 0.7M = 0.7M	1.6M - 0.8M = 0.8M
		$Revenue = \dots * x_{TV}^{0.7} * x_{SEM}^{0.8} * \dots$	
売上貢献	Before	(他の要因) * (1M <sup>0.7</sup> ) * (1M <sup>0.8</sup> )	
	After	(他の要因) * ( <b>2M</b> <sup>0.7</sup> ) * ( <b>2M</b> <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> )	

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。

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))。

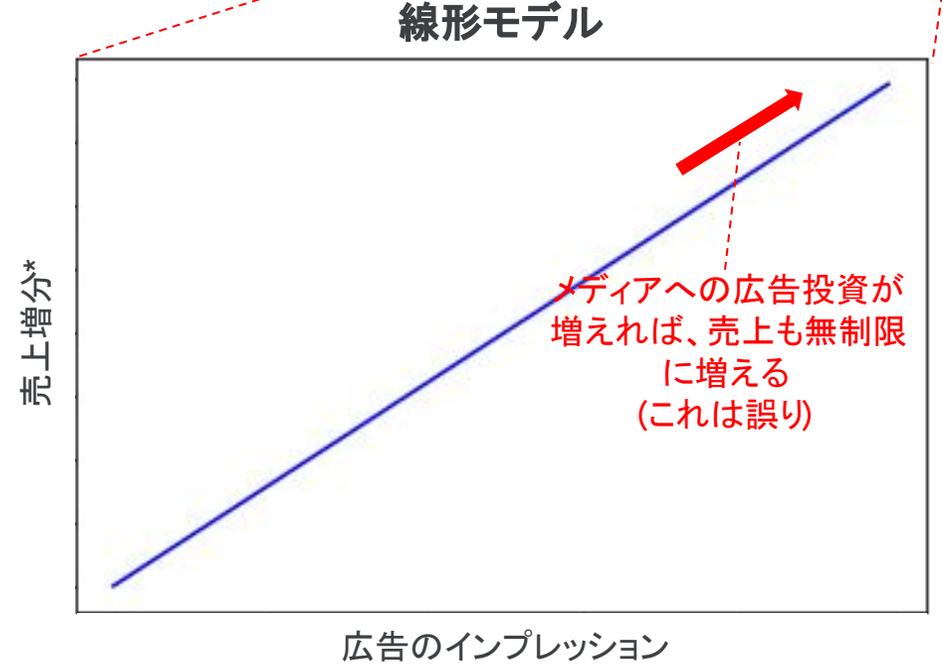
## (A) 応答曲線変換の紹介

応答曲線の変換は、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。

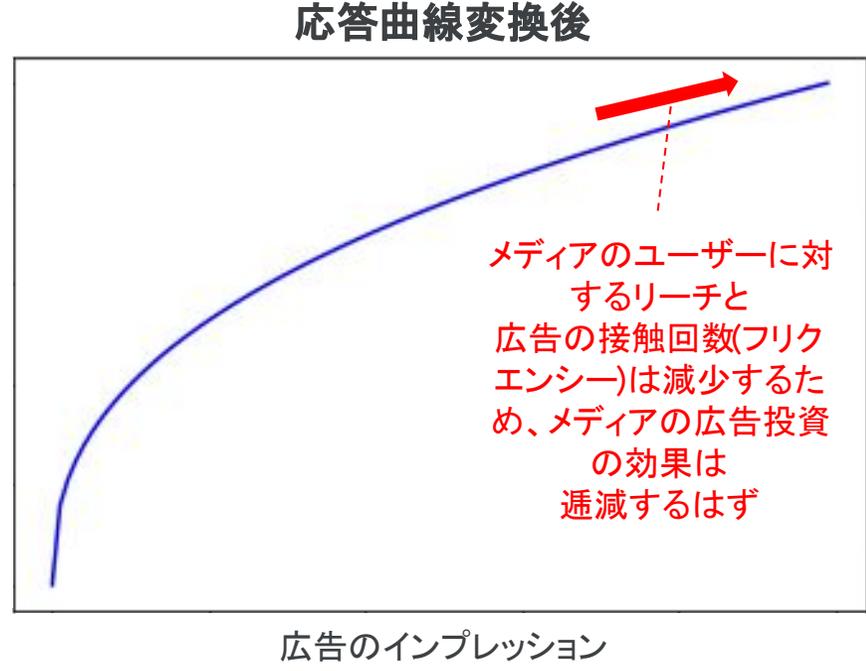
通常、線形回帰モデルは、メディアへの広告投資の増加によって無限の売上成長が可能であると仮定している。しかし、現実にはメディア上のユーザー数、インプレッション数、広告の掲載頻度に限界があるため、広告投資の潜在的な効果は限定的である。このような状況を表現するためには、応答曲線変換が必要となる。

加法モデル\*

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



調整を加える



# 典型的な応答曲線

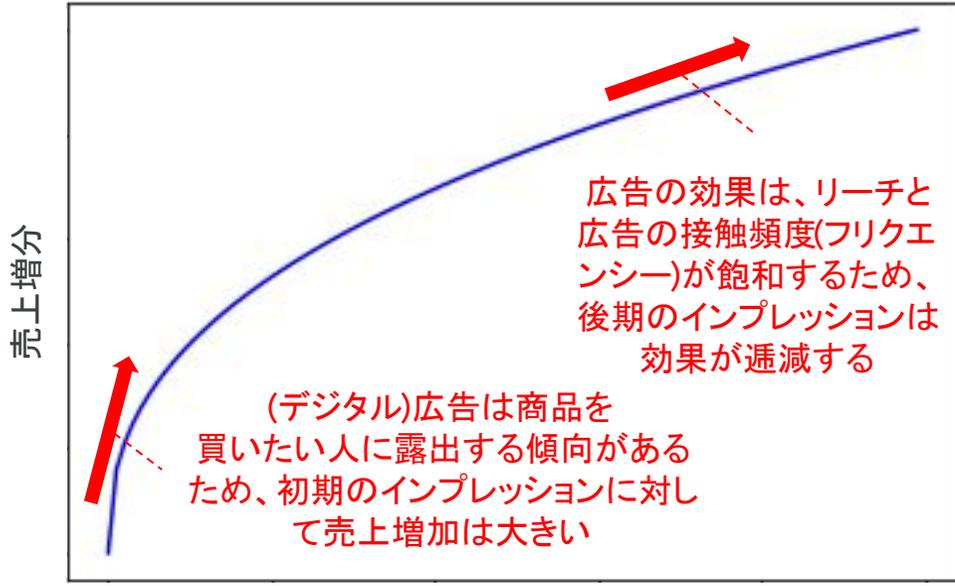
典型的な応答曲線の形状は、凹曲線またはS字曲線である。

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

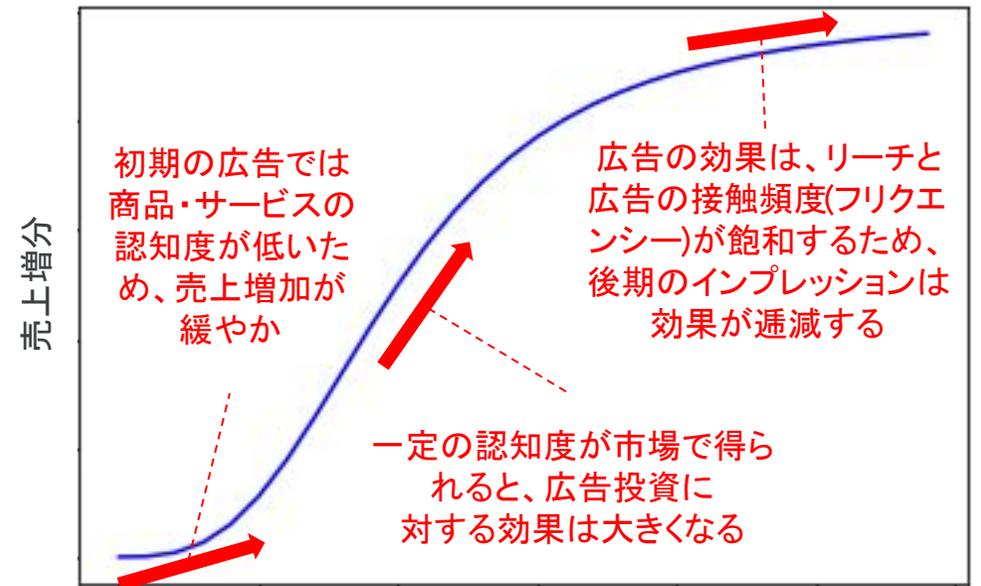


例:

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

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

## 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

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

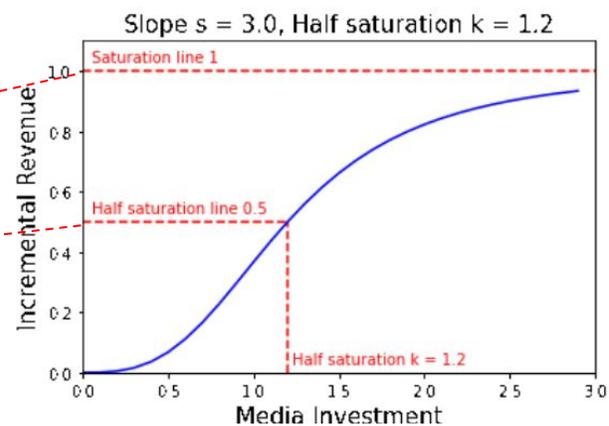
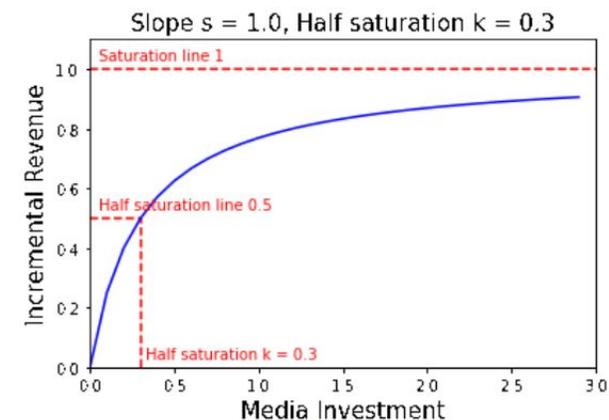
$$\text{Hill}(x_{\text{media}}; K_{\text{media}}, S_{\text{media}}) = \frac{1}{1 + \left(\frac{x_{\text{media}}}{K_{\text{media}}}\right)^{-S_{\text{media}}}}$$

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

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

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

縦軸: ヒル関数の値  
(注: 係数βは除いている)



横軸: 広告のインプレッション



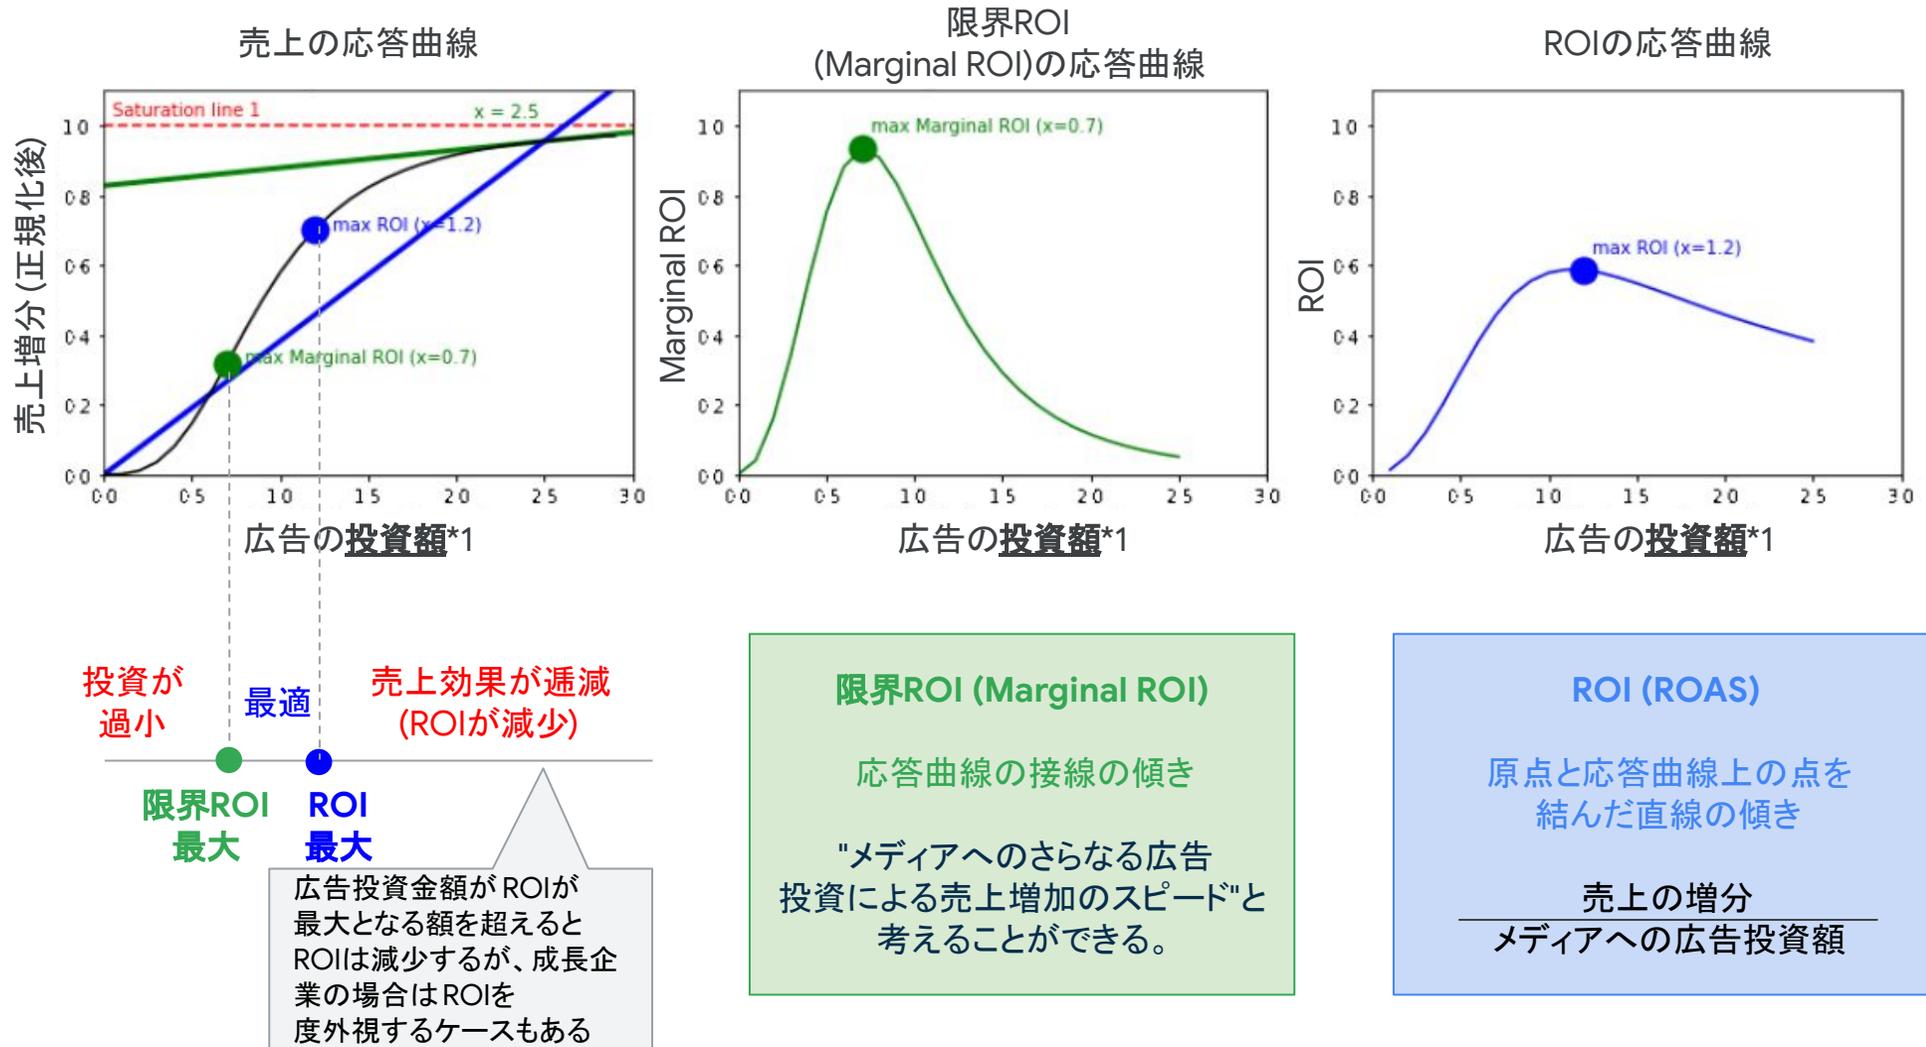
勾配Sが大きいと、ヒル関数の増加も急激となる  
半飽和度Kが大きいと、ヒル関数が緩慢に上限に近づく

## 応答曲線に基づく主要な指標の定義

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。



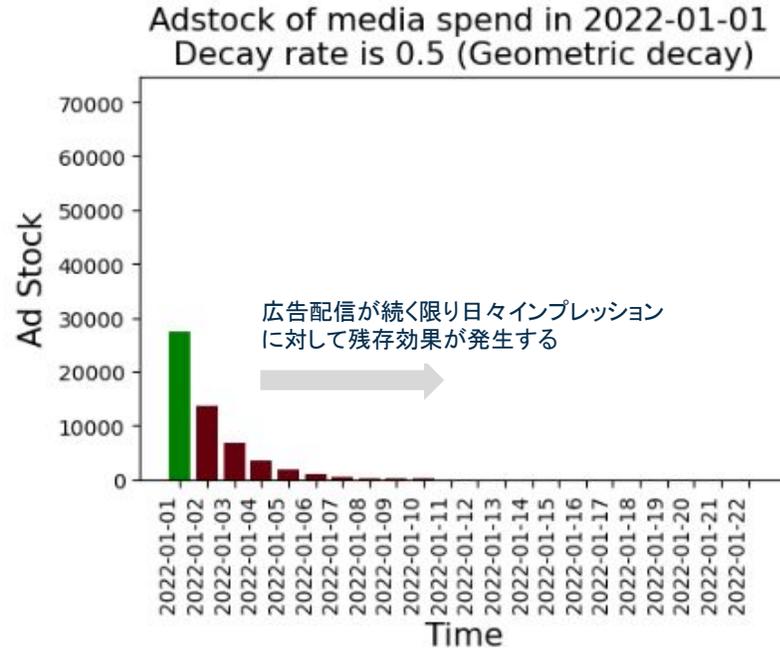
## (B) アドストックの紹介

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。

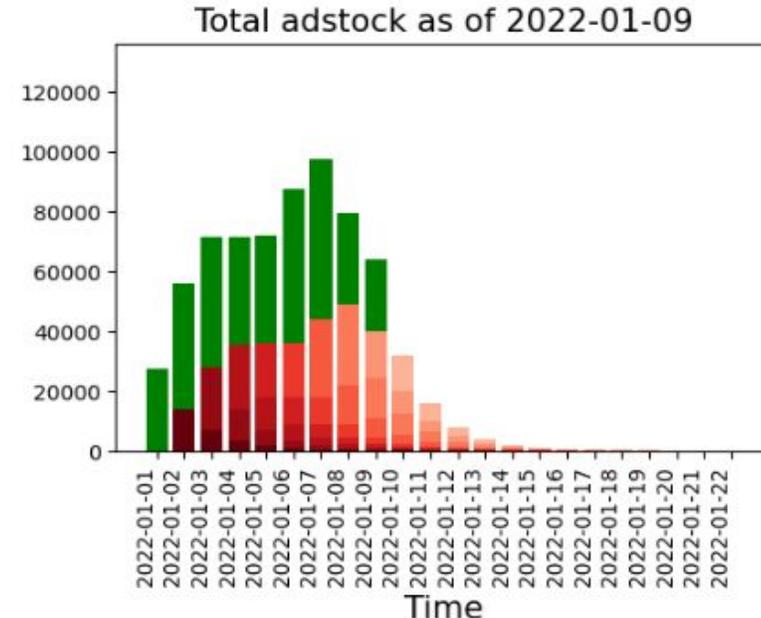
各週のメディアのインプレッション  
に対する減衰効果



※上図は横軸の時間における 2022-01-01時点のインプレッションとその残存効果を示す

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

左記の効果を合計したもの  
(アドストック)



※上図は横軸の時間における 2022-01-09時点のアドストックを示す

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)

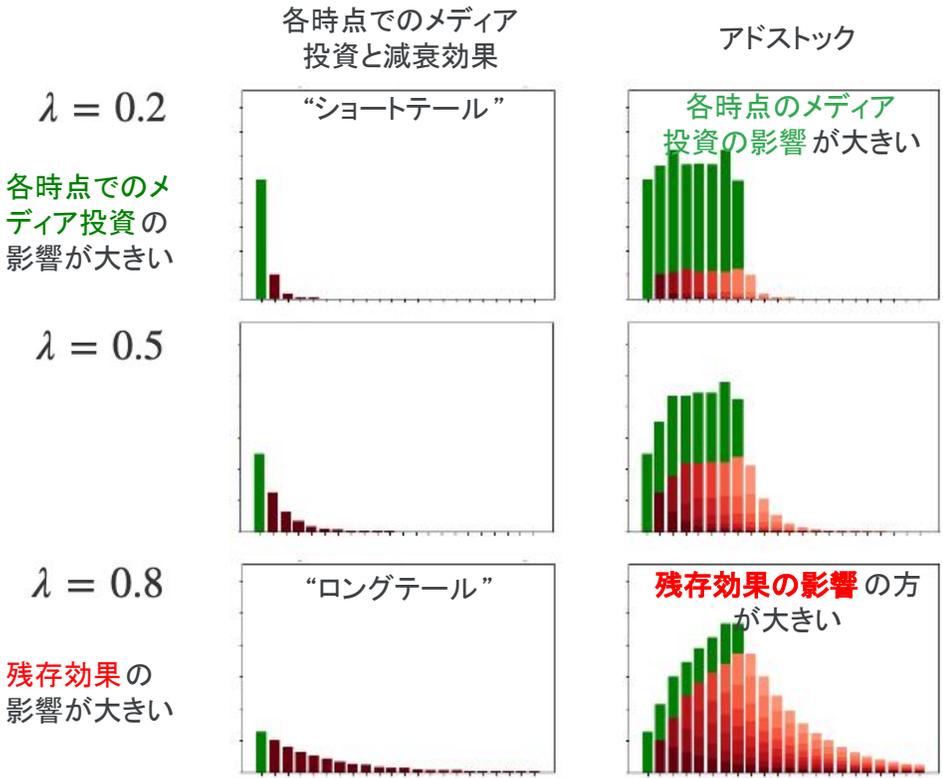
例

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

メディアのインプレッション      減衰パラメータ

グラフの例

減衰率(1-λ)が大きい場合
減衰率(1-λ)が中程度の場合
減衰率(1-λ)が低い場合



# 典型的なアドストック変換 2/3

## 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

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

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

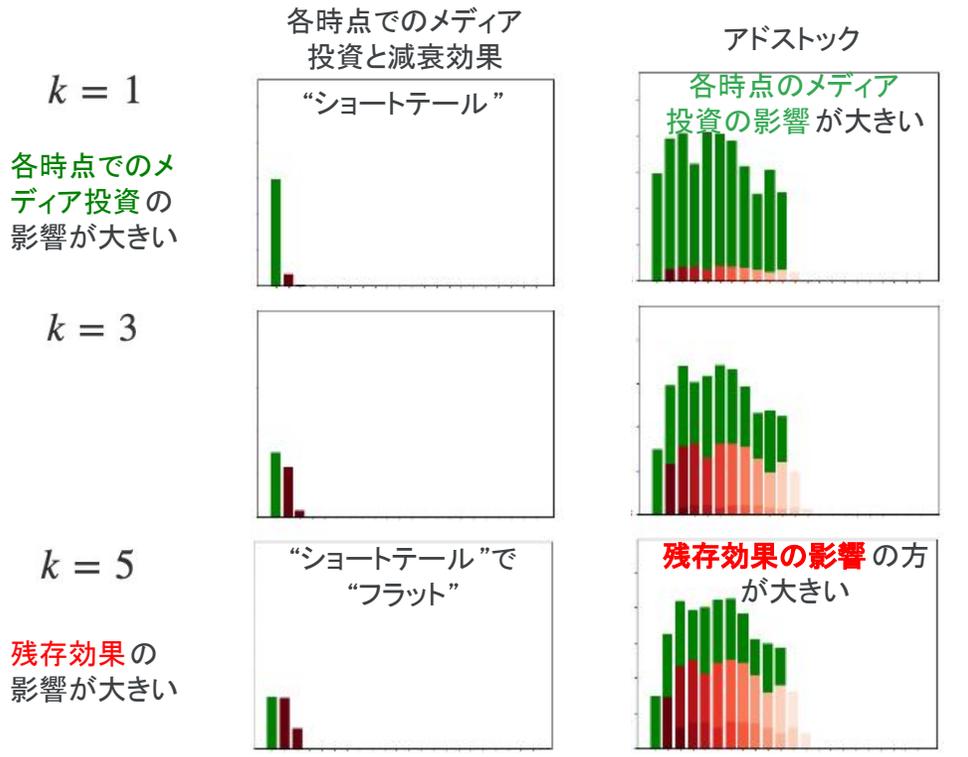
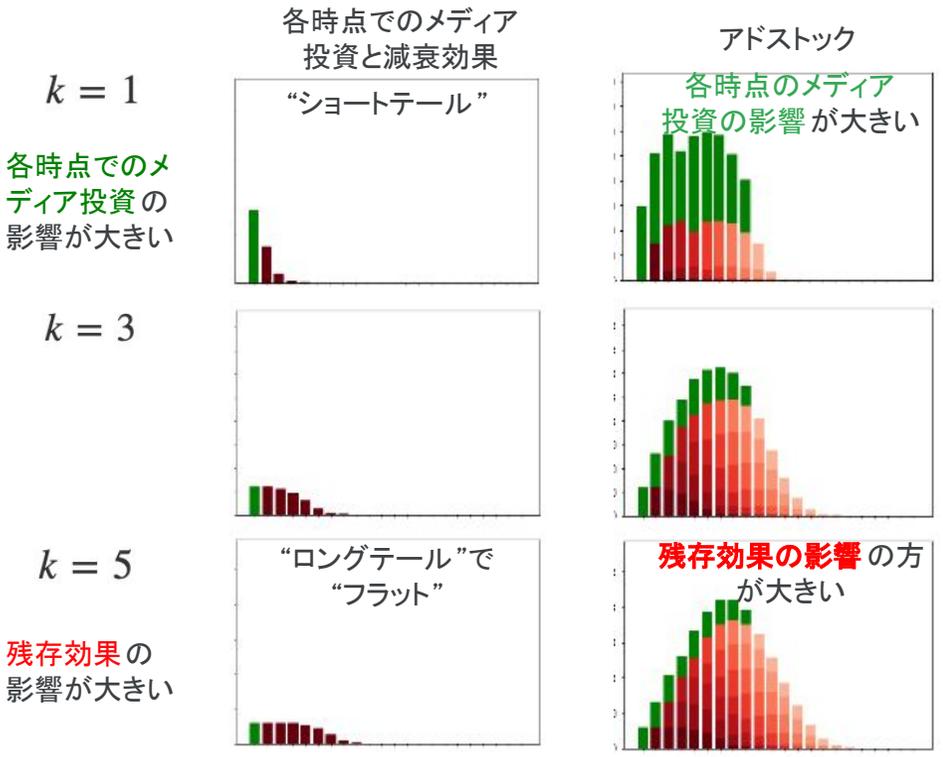
$$\lambda = \frac{l}{(-\ln(0.001))^{\frac{1}{k}}}$$

例\*

### 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
	減衰率 が中程度の 場合
	減衰率 が低い場合



# 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

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

L: 減衰期間, l: 広告出稿時点 t と効果計測時点の時間差

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

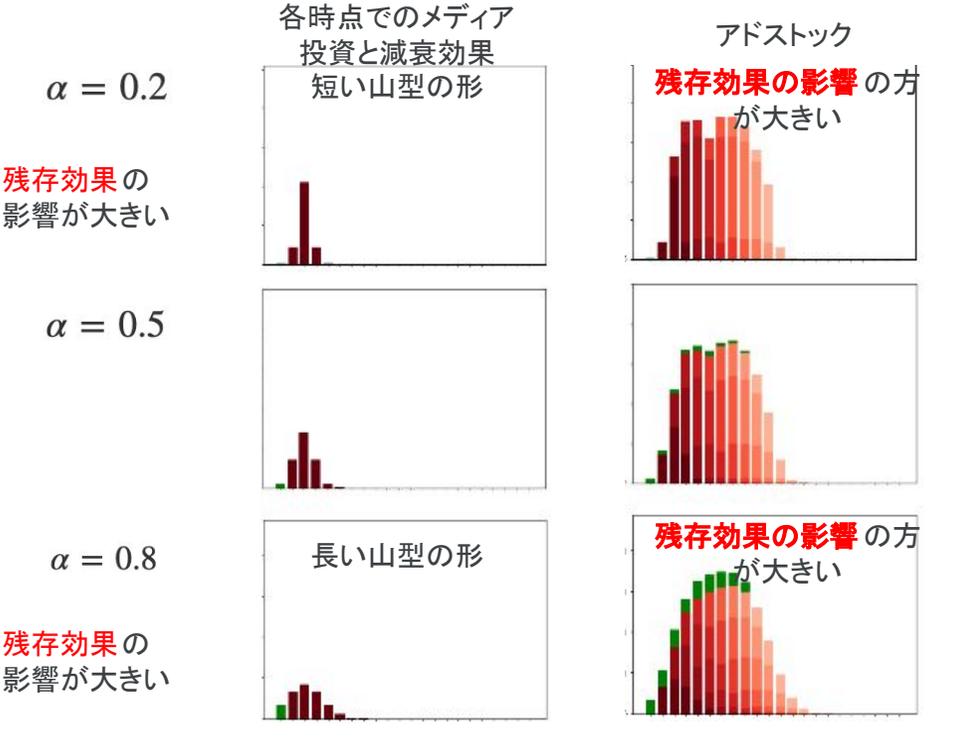
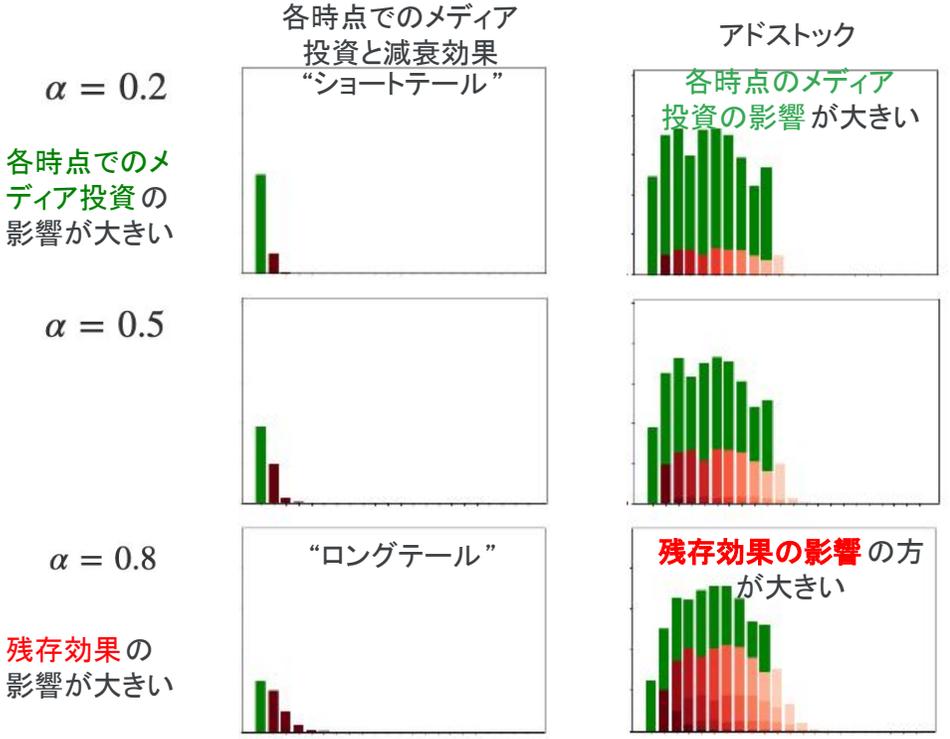
Alpha: 減衰パラメータ

### 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
減衰率 が中程度の 場合
減衰率 が低い場合



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

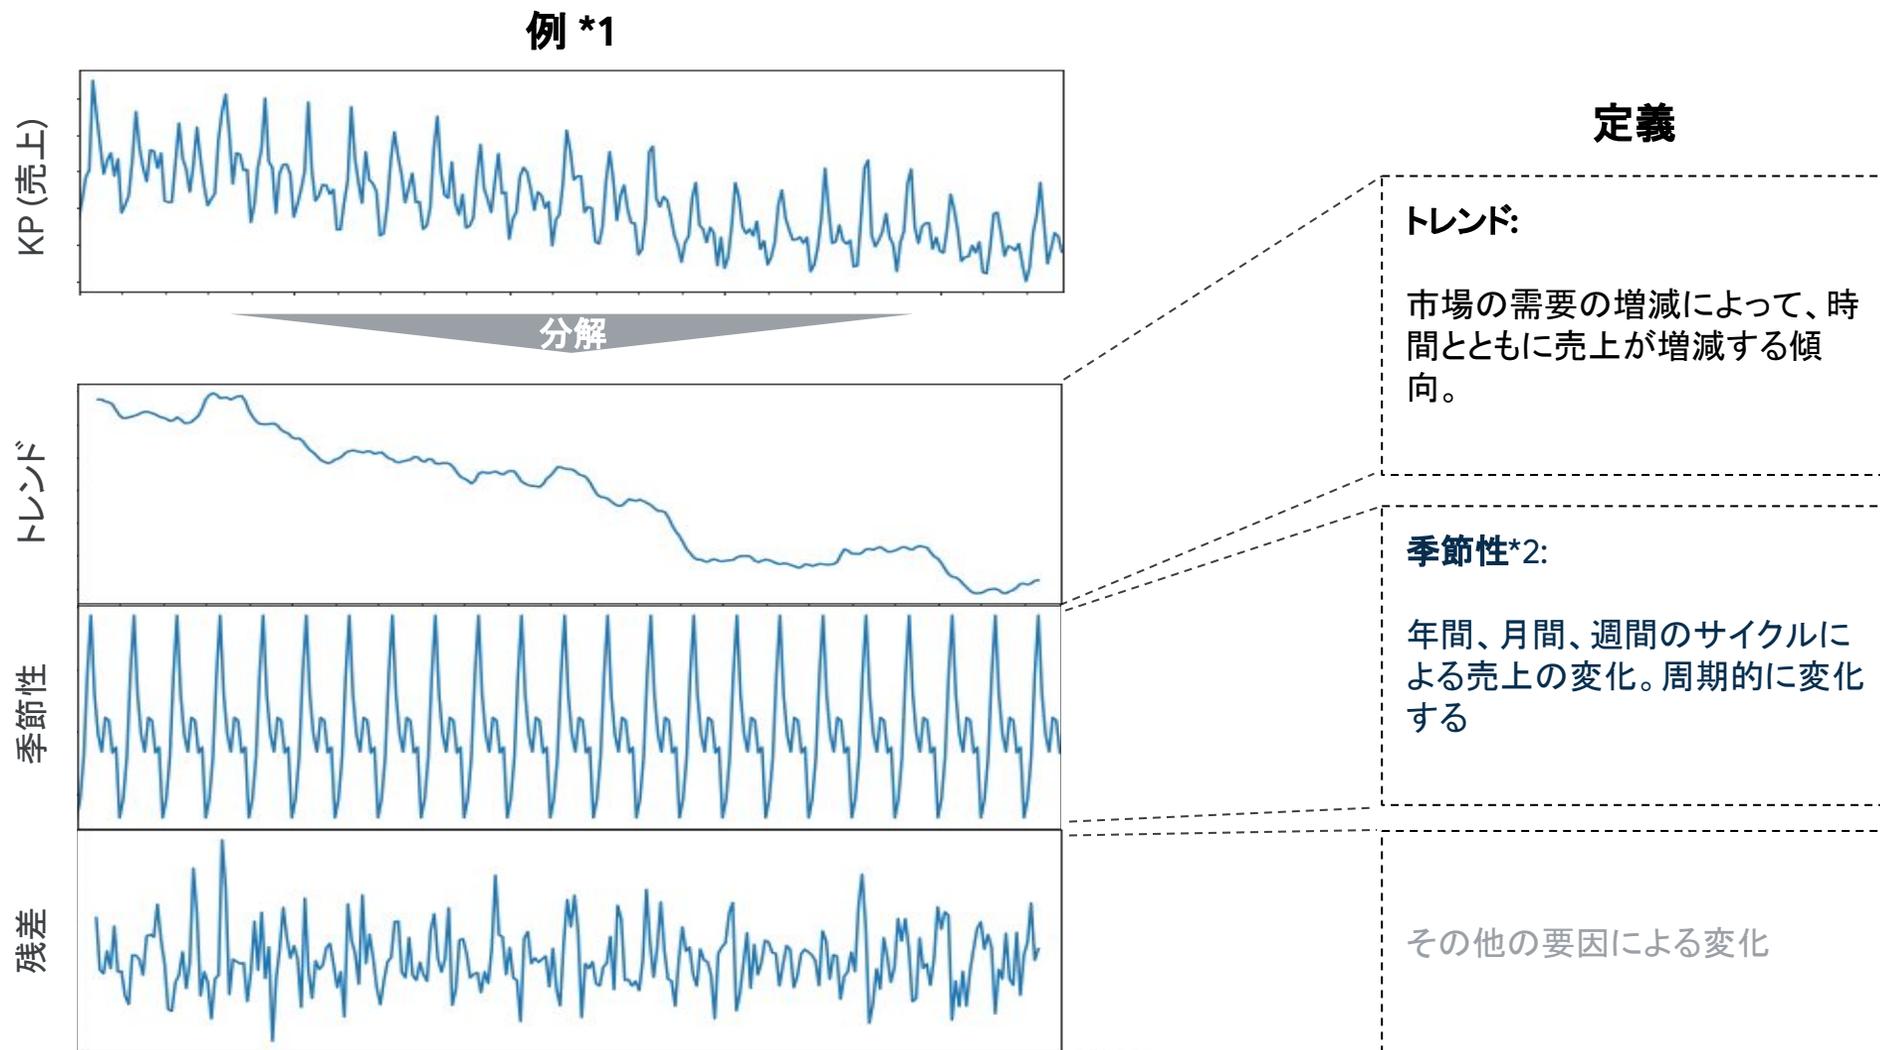


「各時期のメディアの広告投資が、全体の合計投資と比較して相対的に小さい場合(広告投資が各時期に分散している場合)、...アドストック変換の後に応答曲線変換を適用する方が望ましい」。

## (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。



# トレンドと季節性の表現方法

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。\*1

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、業界団体など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

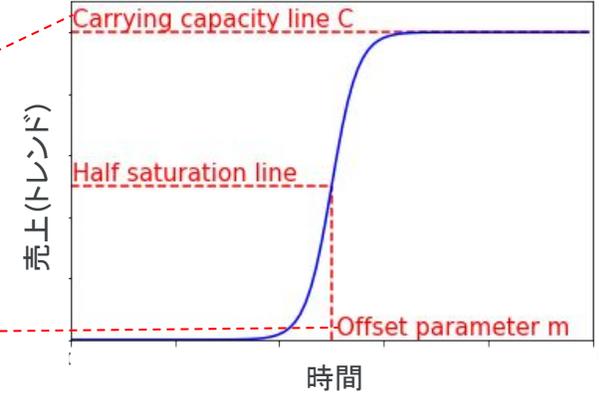
関数の形の例

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

k: 成長率

m: オフセットパラメータ

キャパシティ

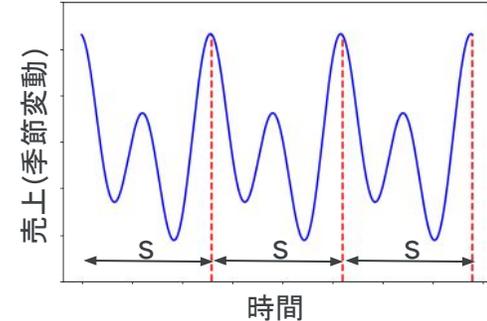


季節性の複雑度 (dが大きい程、複雑な曲線を表す)

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))



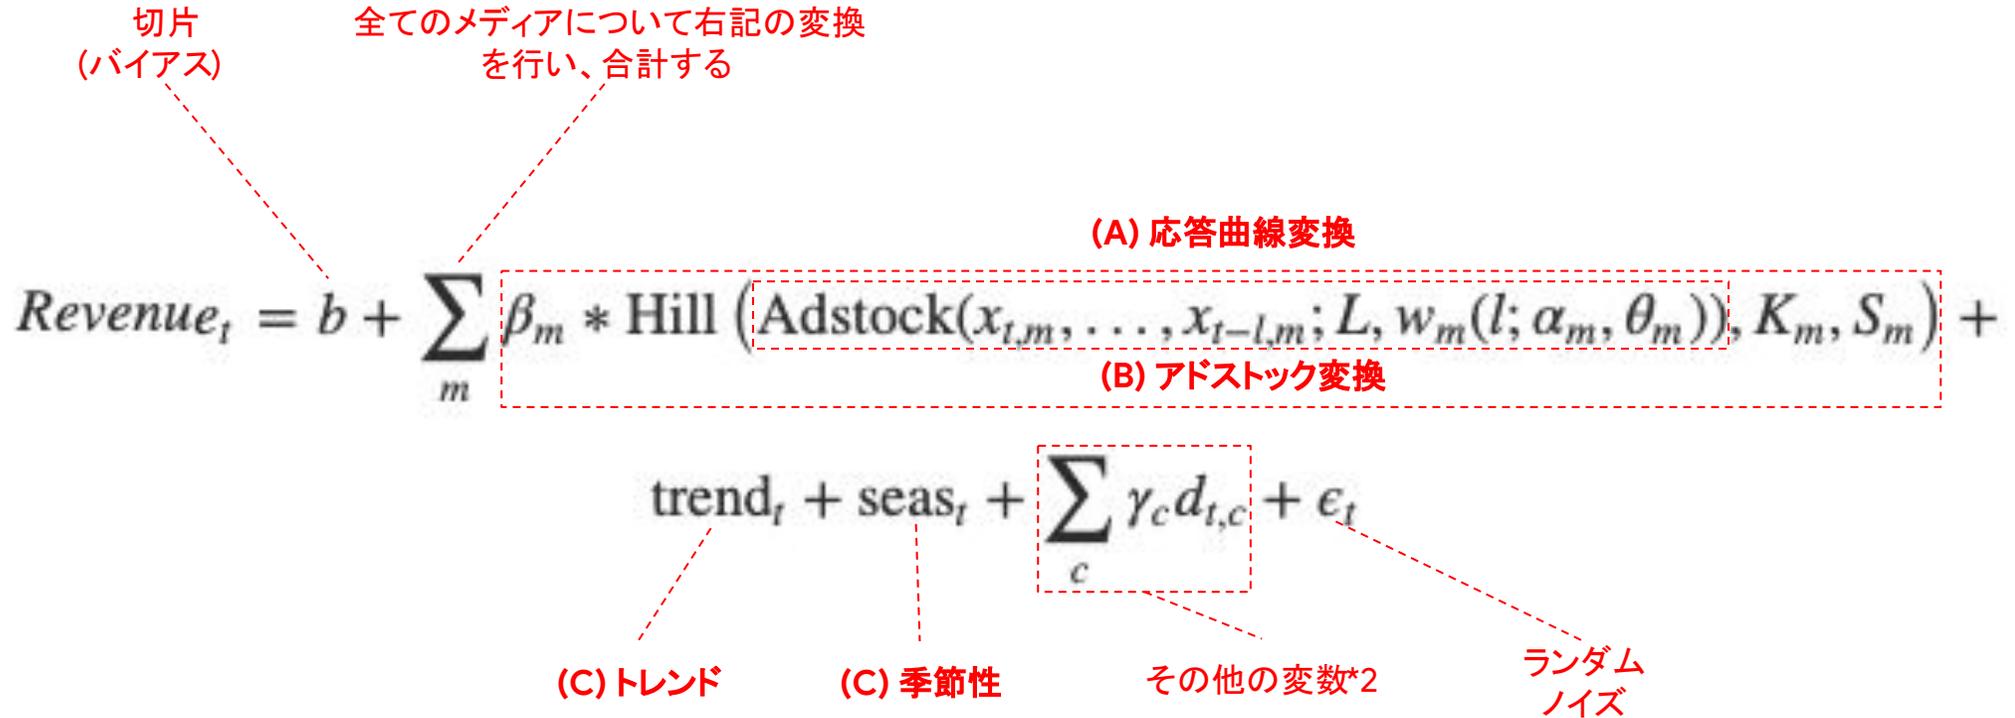
# MMMのモデルの基本構造についてのまとめ

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



\*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。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。

\*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。

# 変化系モデル(地理的単位のモデル、geo level model)

## 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。

# 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)

## 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は、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<sup>1</sup>。

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

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

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一つが使用される。

**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。

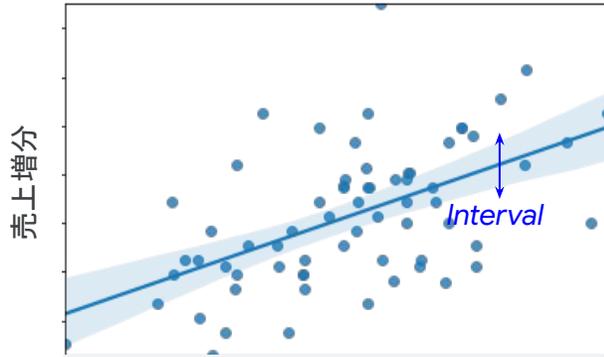
**ベイズ推定:** このオプションは各メディアによる売上増分の推定に関する洞察を得ることを重視し、パラメータの信頼区間や事後分布のような詳細情報も推定できる。当ガイドブックでは、このような理由から当該方法をメインとして解説をする。

## 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)

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

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



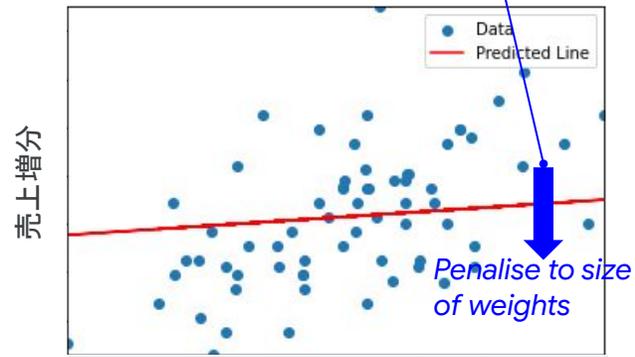
メディアのインプレッション

データとモデルの間の「距離 L」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)

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

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



メディアのインプレッション

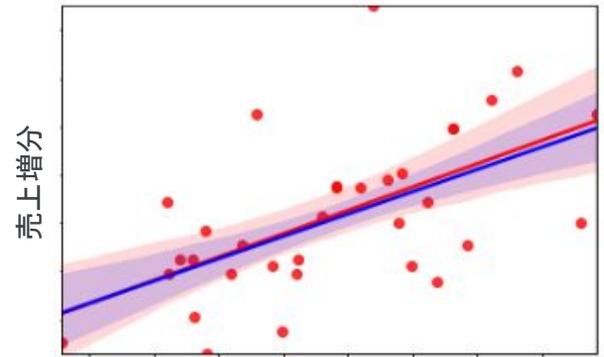
データとモデルの間の「距離 L」を最小化することで、パラメータを推定する。データへのオーバーフィッティングを避ける (KPIの予測精度を高める)ため、クロスバリデーション (交差検証法)を用いてペナルティパラメータ λ を最適化する。リッジ回帰、ラッソ回帰等が利用される。一般的に、結果はパラメータの点推定のみを含み、区間の情報は無い\*1。

**ベイズ推定**

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

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

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



メディアのインプレッション

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、各メディアの詳細の分析ができる柔軟性がある。

# ベイズ推定の概要 1/3

## 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。

MMMの加法モデルの例1:

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

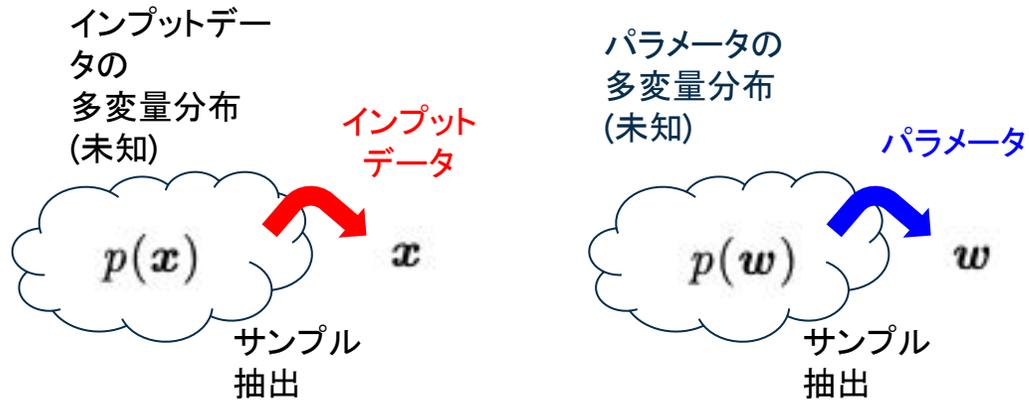
簡略化するために次のように表記する。(赤・青の色の対応に注意)

**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。



## ベイズの定理

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

**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。

## ベイズ推定の概要 2/3

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

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

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

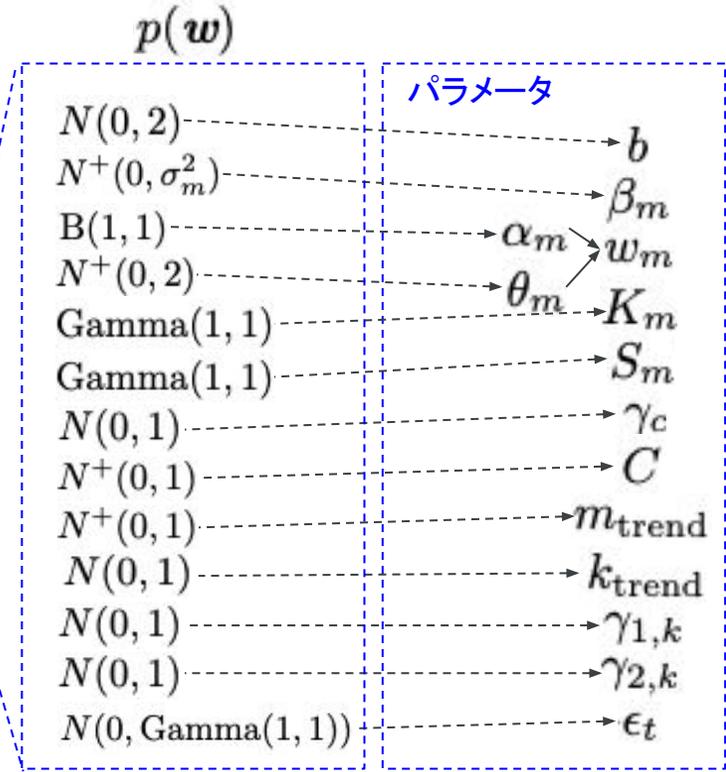
事前分布を仮定する

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

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



\*1: <https://towardsdatascience.com/bayesian-inference-problem-mcmc-and-variational-inference-25a8aa9bce29>  
 \*2: この例は、2023年2月時点の Lightweight MMMを参照している。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。  
 \*3: 正確にはデータは独立変数  $x$  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

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。

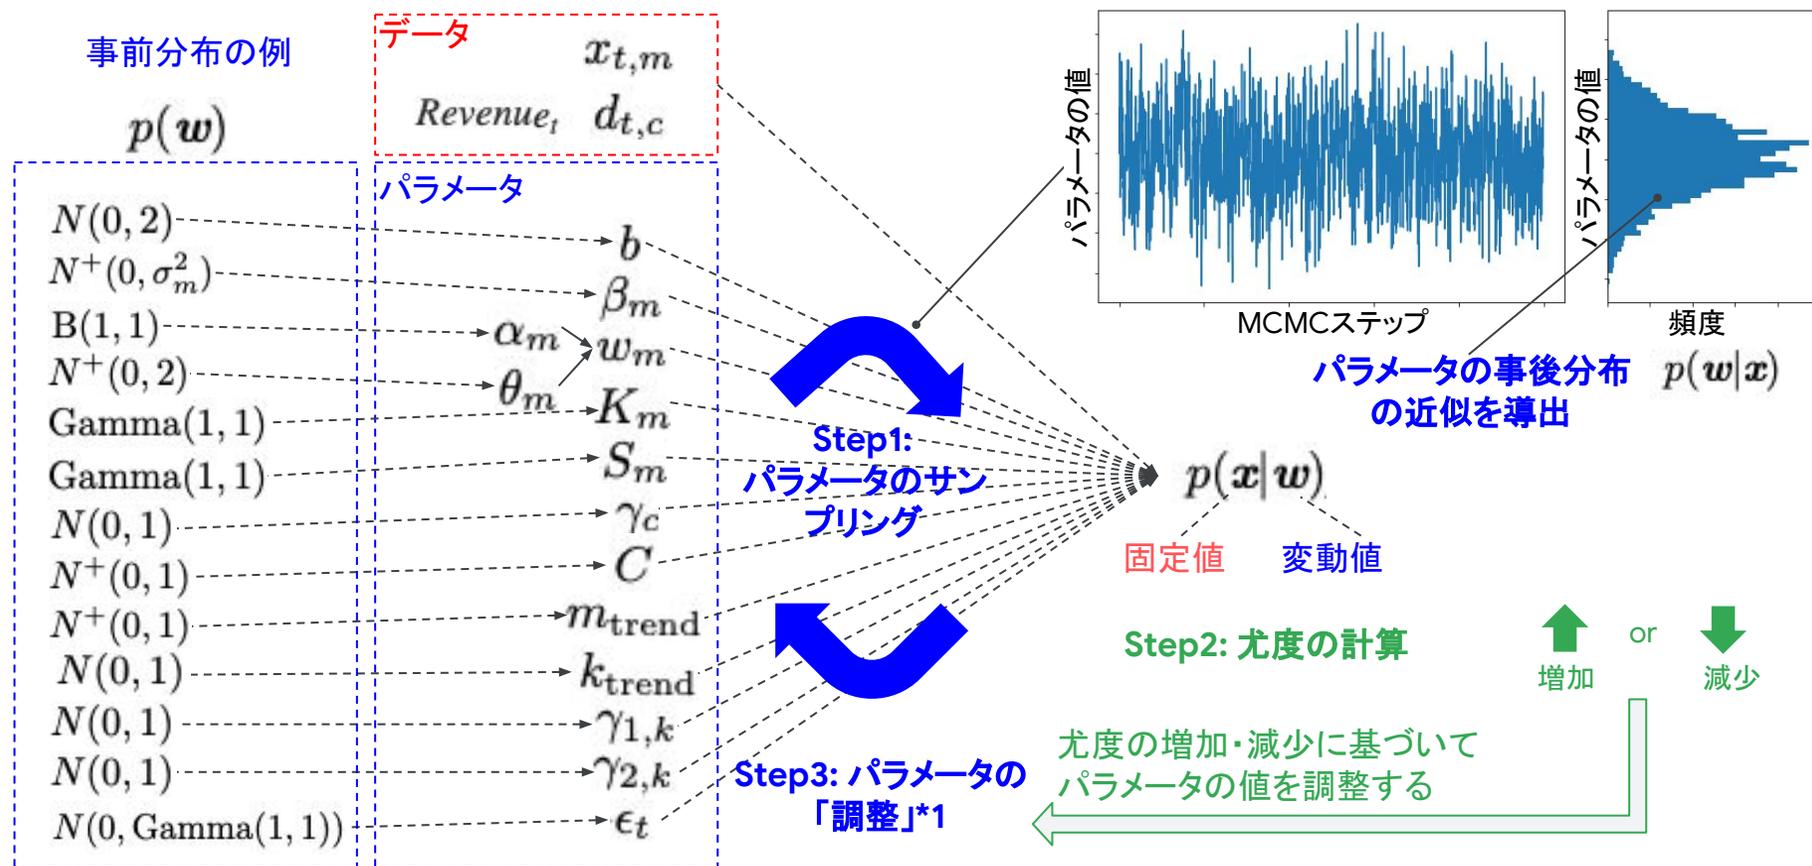
**Step2 尤度の計算:**前ページで説明したように、尤度を計算する。

**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



## 2.5 モデルの検証

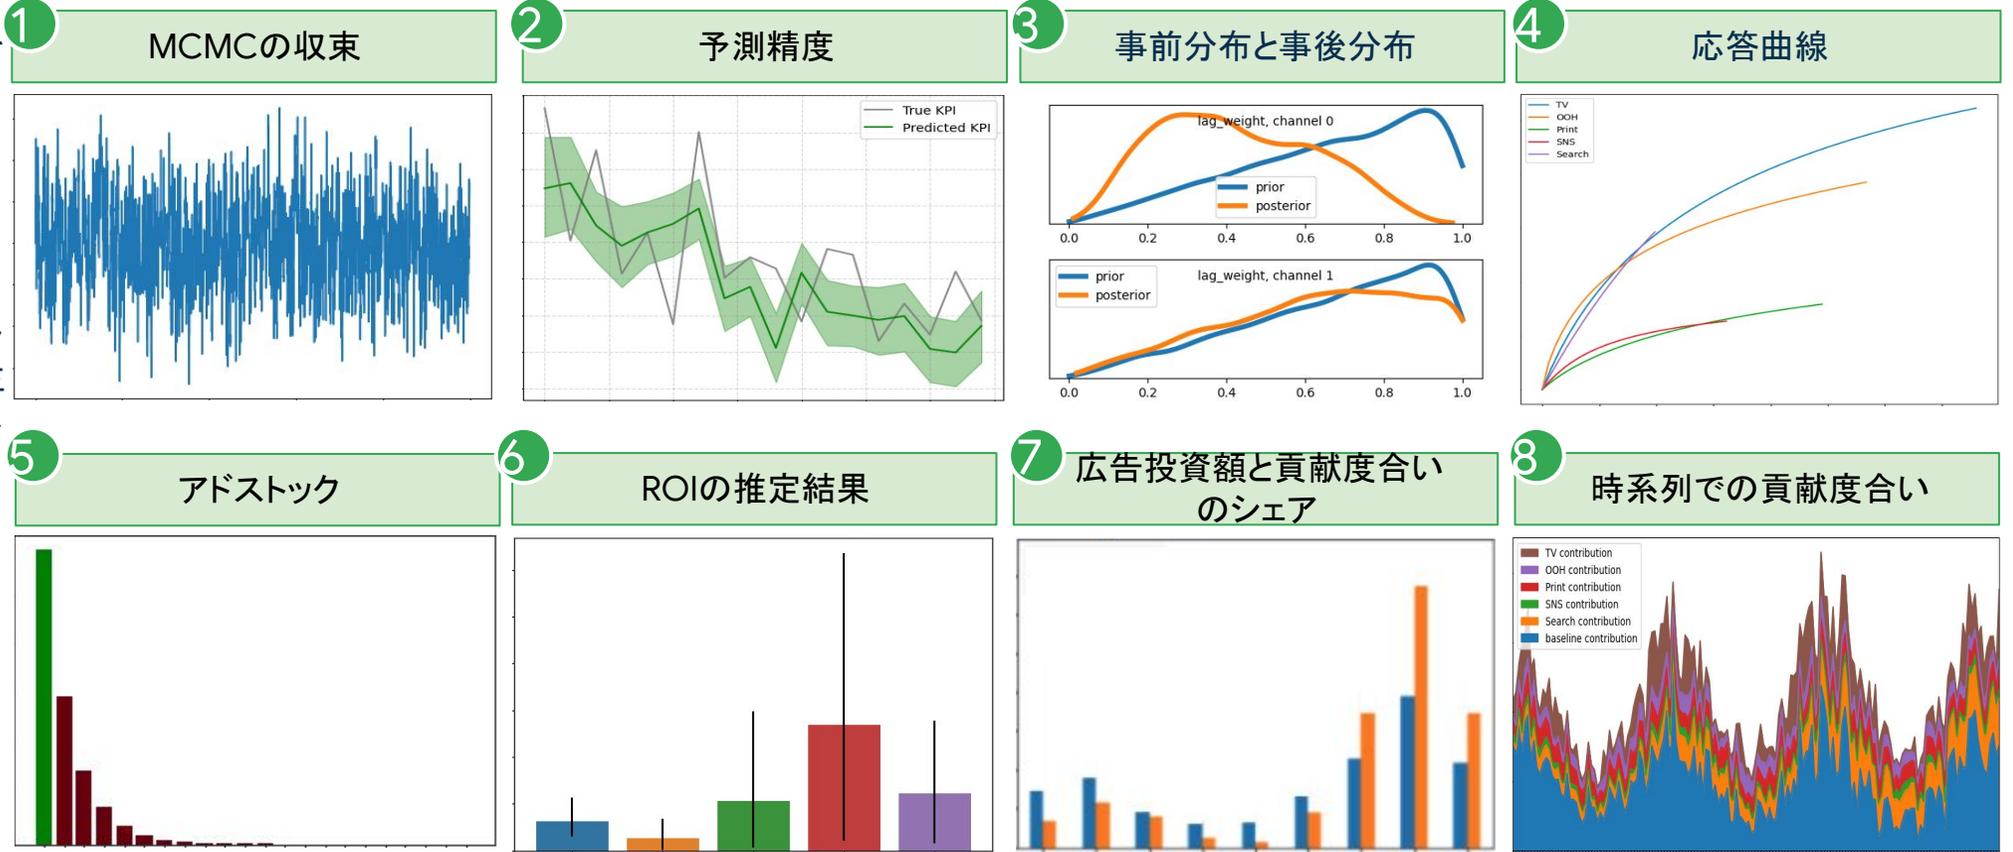
# モデルの検証における9つのチェックポイント

## 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。



9 複数のモデルを上記の観点で比較し、最善のモデルを選択する

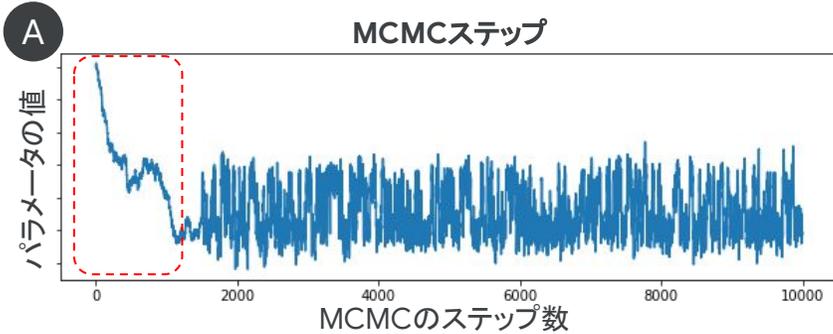
# MCMCの収束チェック 1/2

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。

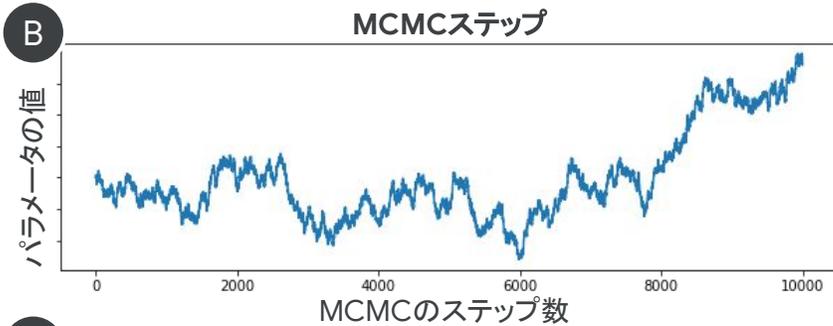
主な指標の1つはRhatで、これはChain(MCMCステップの1セット)の平均の分散と、各Chain内の分散の平均の比率に関する指標である。

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。

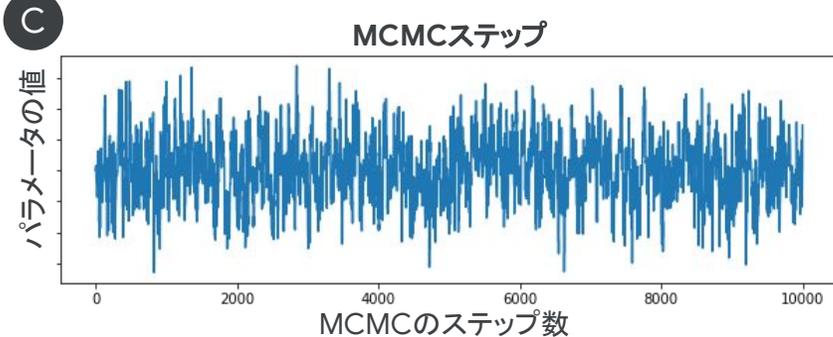
## MCMCによるパラメータ推定で起こりうる問題 (単鎖(single chain)の例)



**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

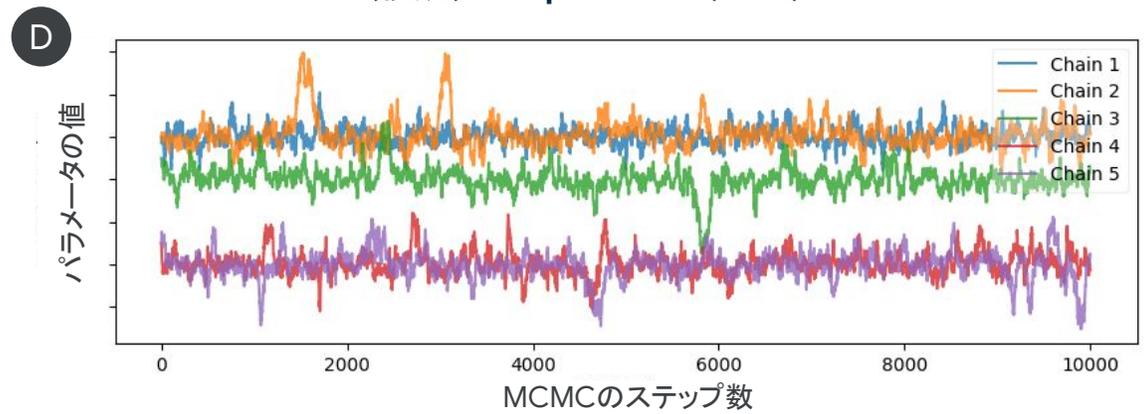
MCMCでエラーを発見した場合、考慮すべきオプションがある。

**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。

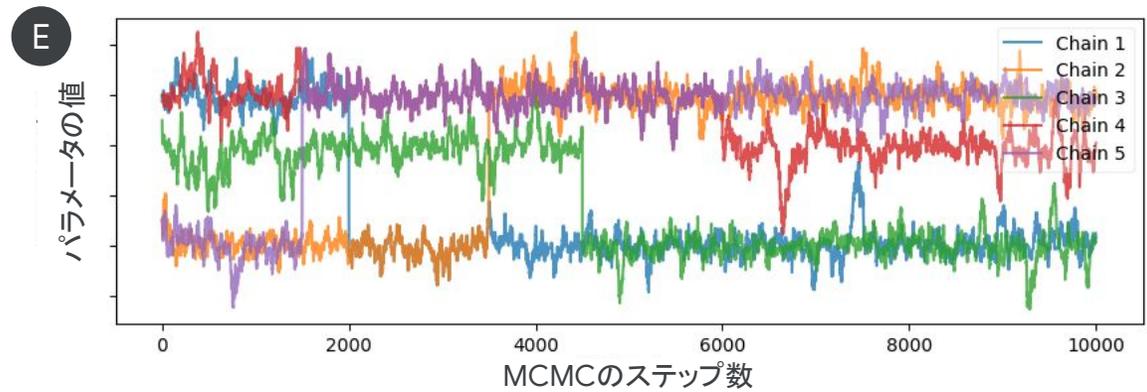
**MCMCステップを増やす:** チェーンを長くする。

**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。

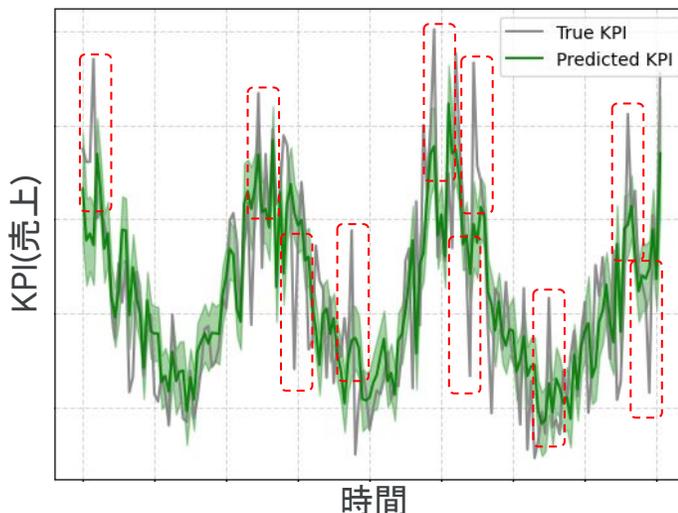
アウトプットの例

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

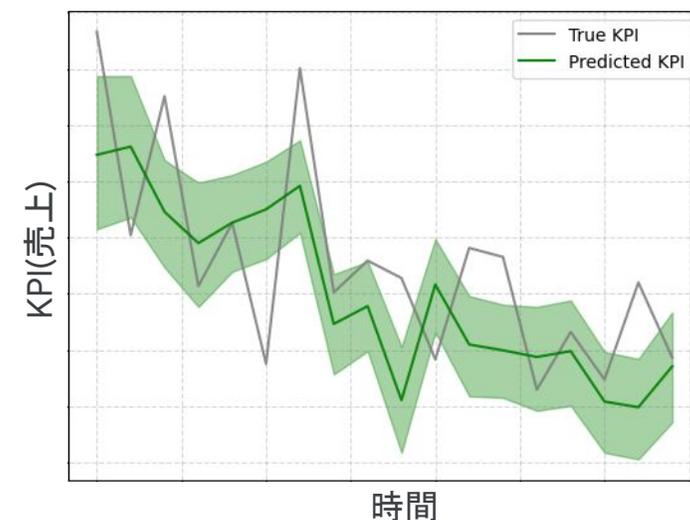
### サンプルデータ



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。

## 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

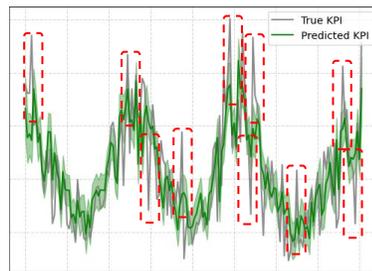
$$d = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2}$$

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

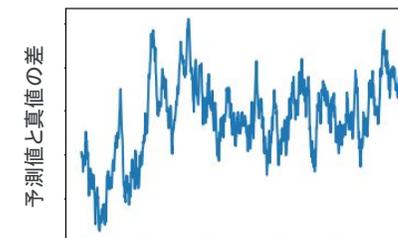
例

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

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。

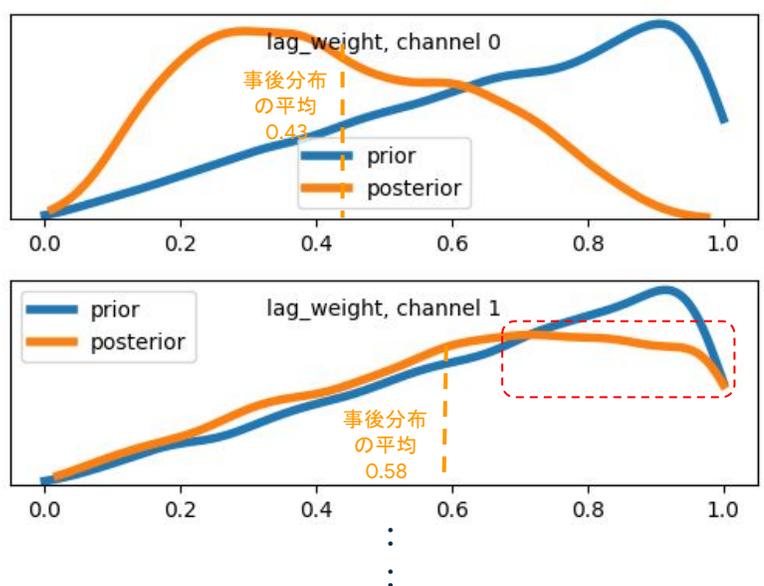
アウトプットの例

チェック方法

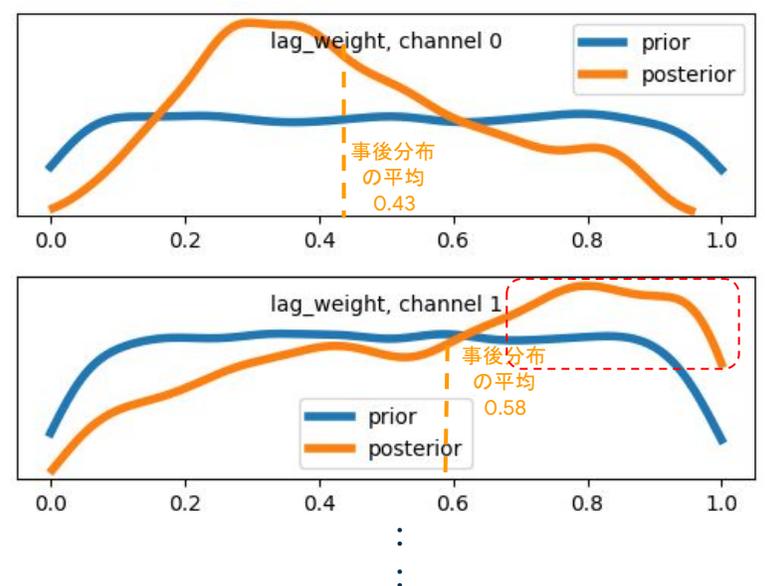
例における検証結果

例

事前(prior)分布がBeta(2,1)の場合



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。

## 応答曲線のチェック

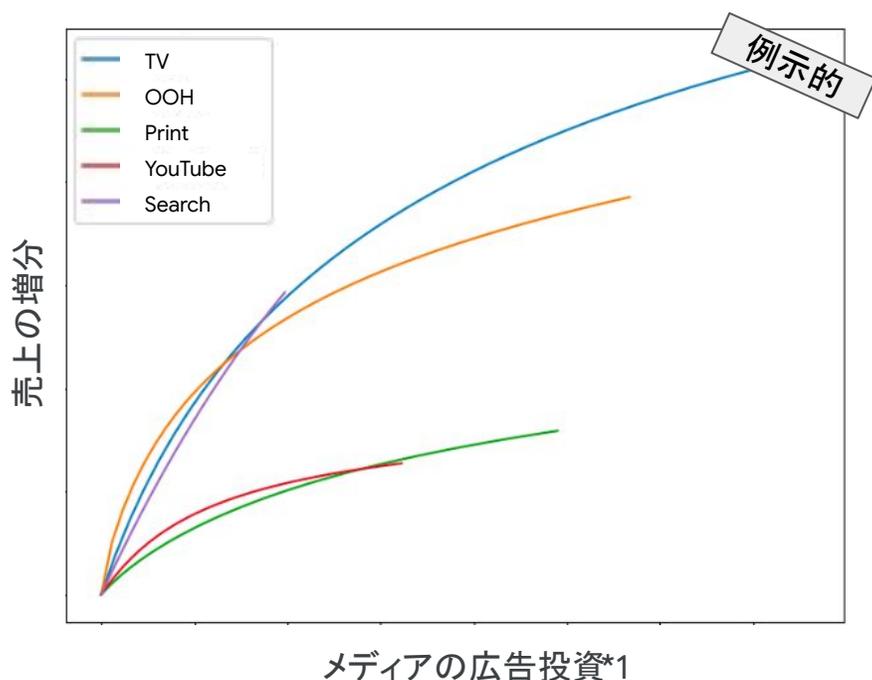
MMMには、応答曲線やアドストックなどの仮定が存在するため、モデル作成者は定性的な(主観的な)チェックも行う必要がある。

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。

## 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

$$adstock_{t,media} = x_{t,media} + \lambda_{media} * adstock_{t-1,media}$$

減衰  
パラメータ

パラメータの推定結果の例

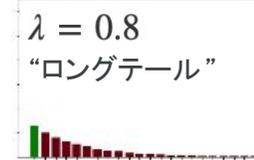
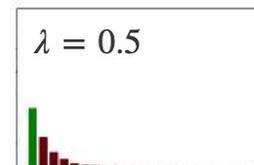
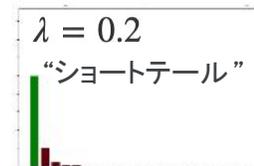
	mean	std	median	5.0%	95.0%
TV	0.32	0.14	0.32	0.10	0.55
OOH	0.59	0.18	0.59	0.26	0.88
新聞	0.67	0.24	0.70	0.32	1.00
YouTube	0.70	0.22	0.76	0.34	1.00
検索	0.71	0.21	0.75	0.41	1.00

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

例

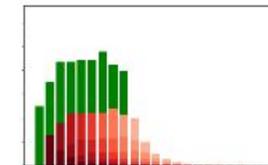
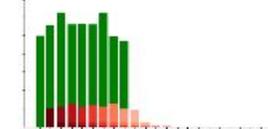
例示的

各期間における  
広告投資と  
アドストック



アドストック

各時点のメディア  
投資の影響が大きい



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)

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？

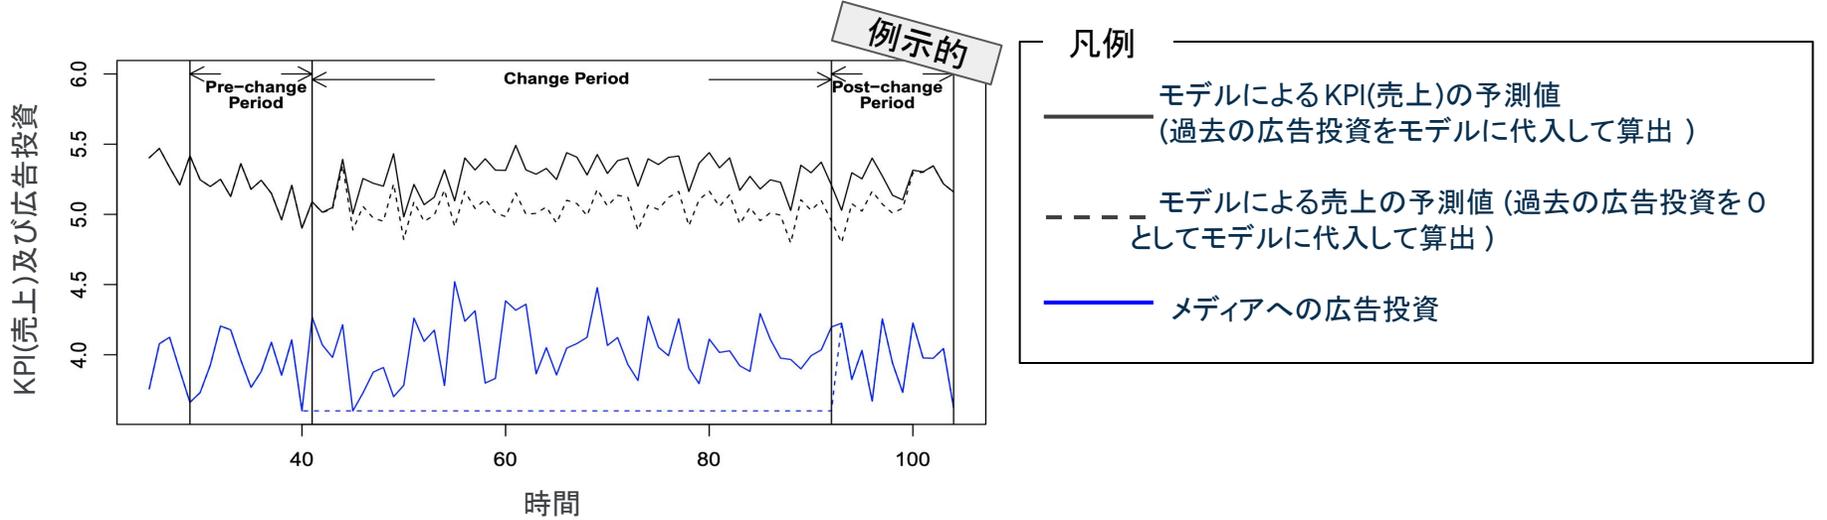
上記のケースでは、テレビはデジタルメディアよりも減衰が早い。フォーマットを考慮すると(テレビCM対ニュースフィード、検索のテキスト広告)、ニュースフィードやテキスト広告よりも動画広告の方が長い期間認知を促進すると予想されるため、このような推定となった根拠を明らかにする必要がある。

## 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

$$ROAS_m = \frac{\sum_{t_0 \leq t \leq t_1 + L - 1} \hat{Y}_t^m(x_{t-L+1,m}, \dots, x_{t,m}; \Phi) - \hat{Y}_t^m(\tilde{x}_{t-L+1,m}, \dots, \tilde{x}_{t,m}; \Phi)}{\sum_{t_0 \leq t \leq t_1} x_{t,m}} = \frac{\text{分子} = \text{売上増分}}{\text{分母} = \text{期間中の広告費の合計} * 2} = \text{ROAS (Return on Ad Spend)}$$

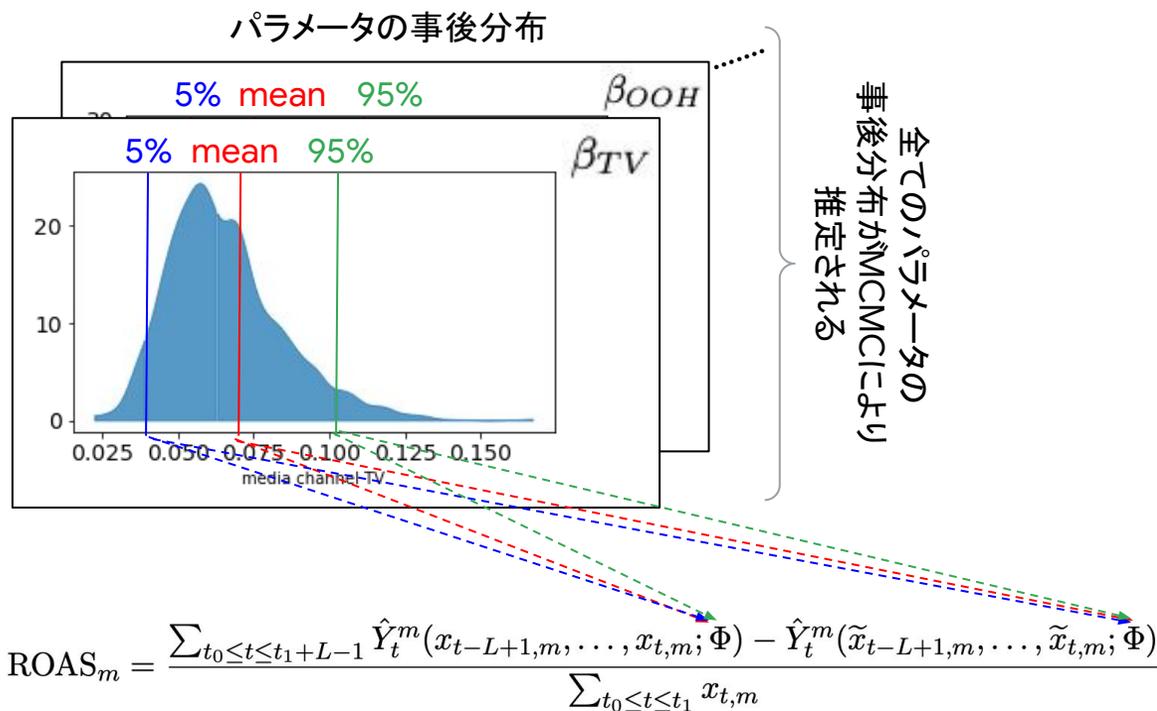
## MMMにおけるROI(ROAS)の計算方法 2/2

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。

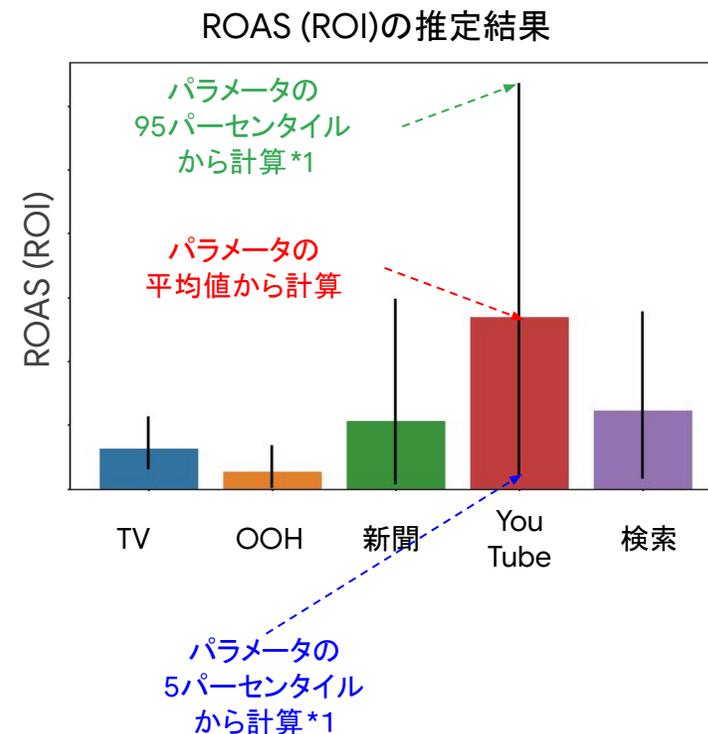
次のページでは、それらを主観的に評価する例を紹介する。

### 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



## ROAS(ROI)の推定結果のチェック

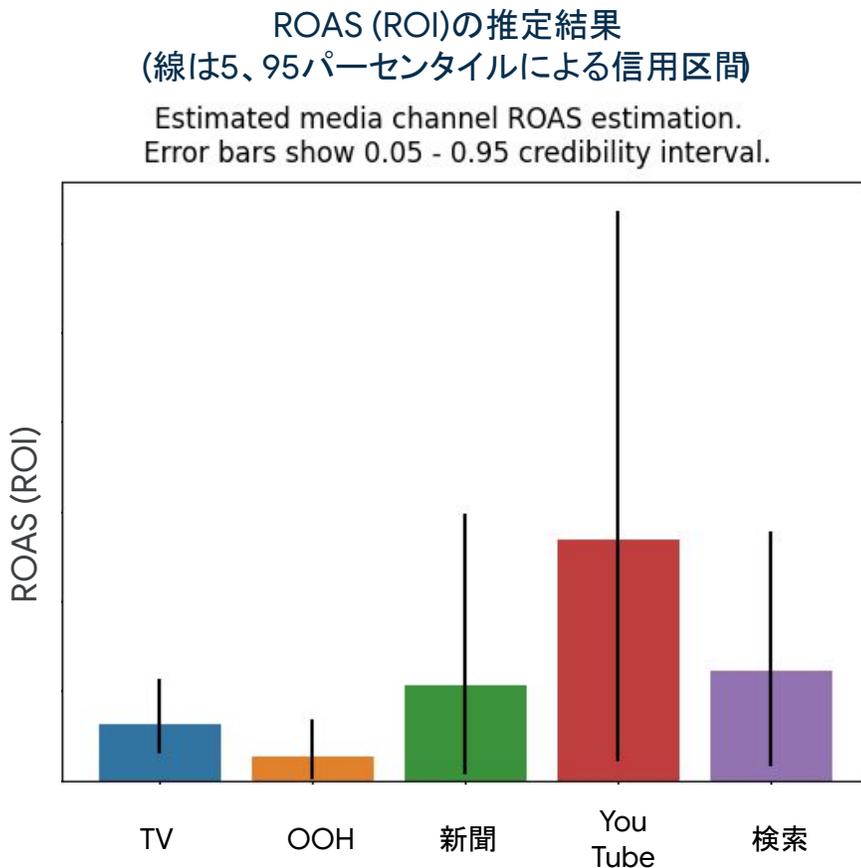
ROAS(ROI)計算後、モデルの作成者は推定の平均値と信用区間を比較する。

**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



### 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。

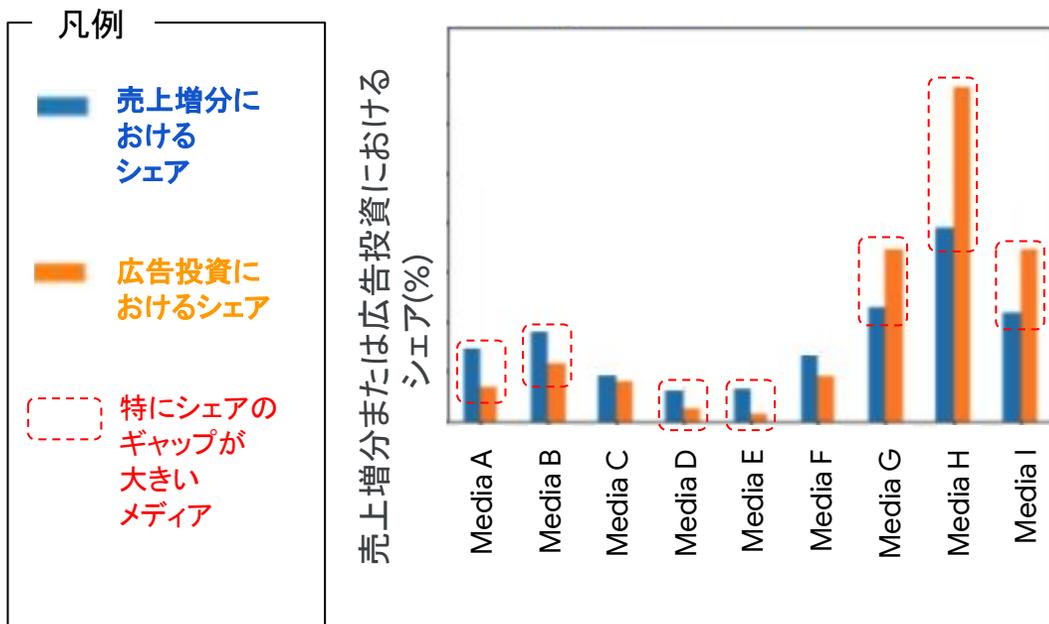
## 広告投資額と貢献度合いのシェアのチェック

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な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

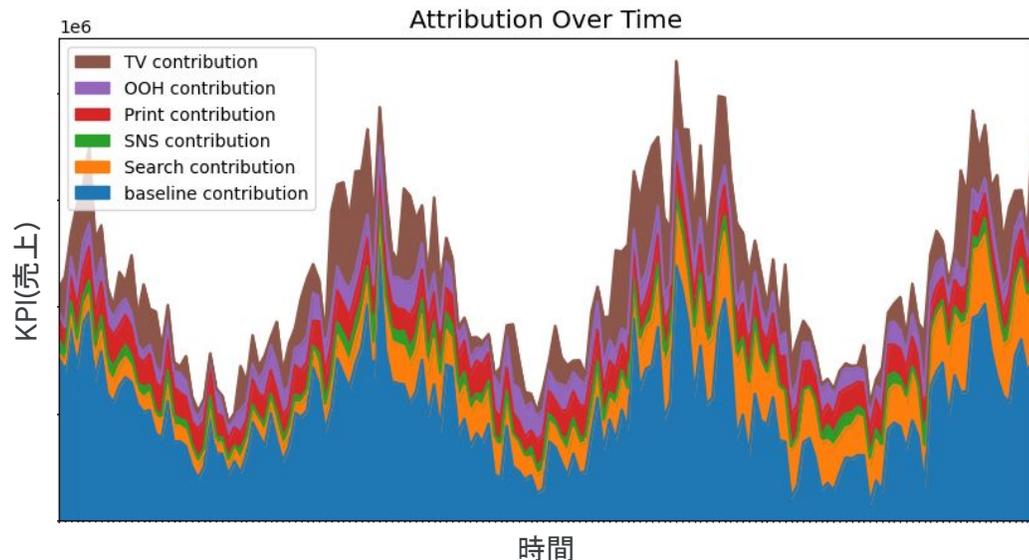
## 時系列での貢献度合いの分析

P.64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)等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。

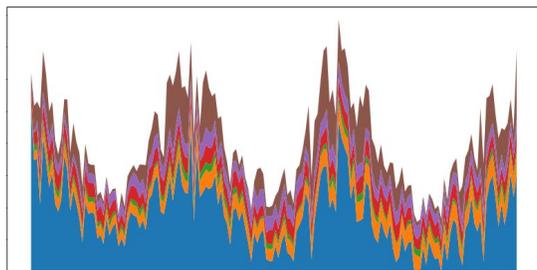
### アウトプットの例\*1 例示的



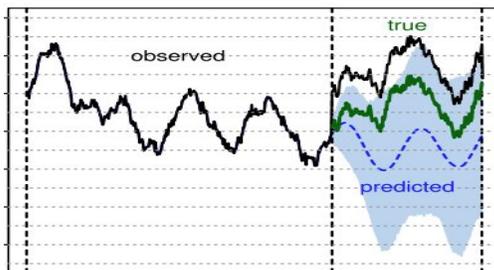
時間

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、一定程度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

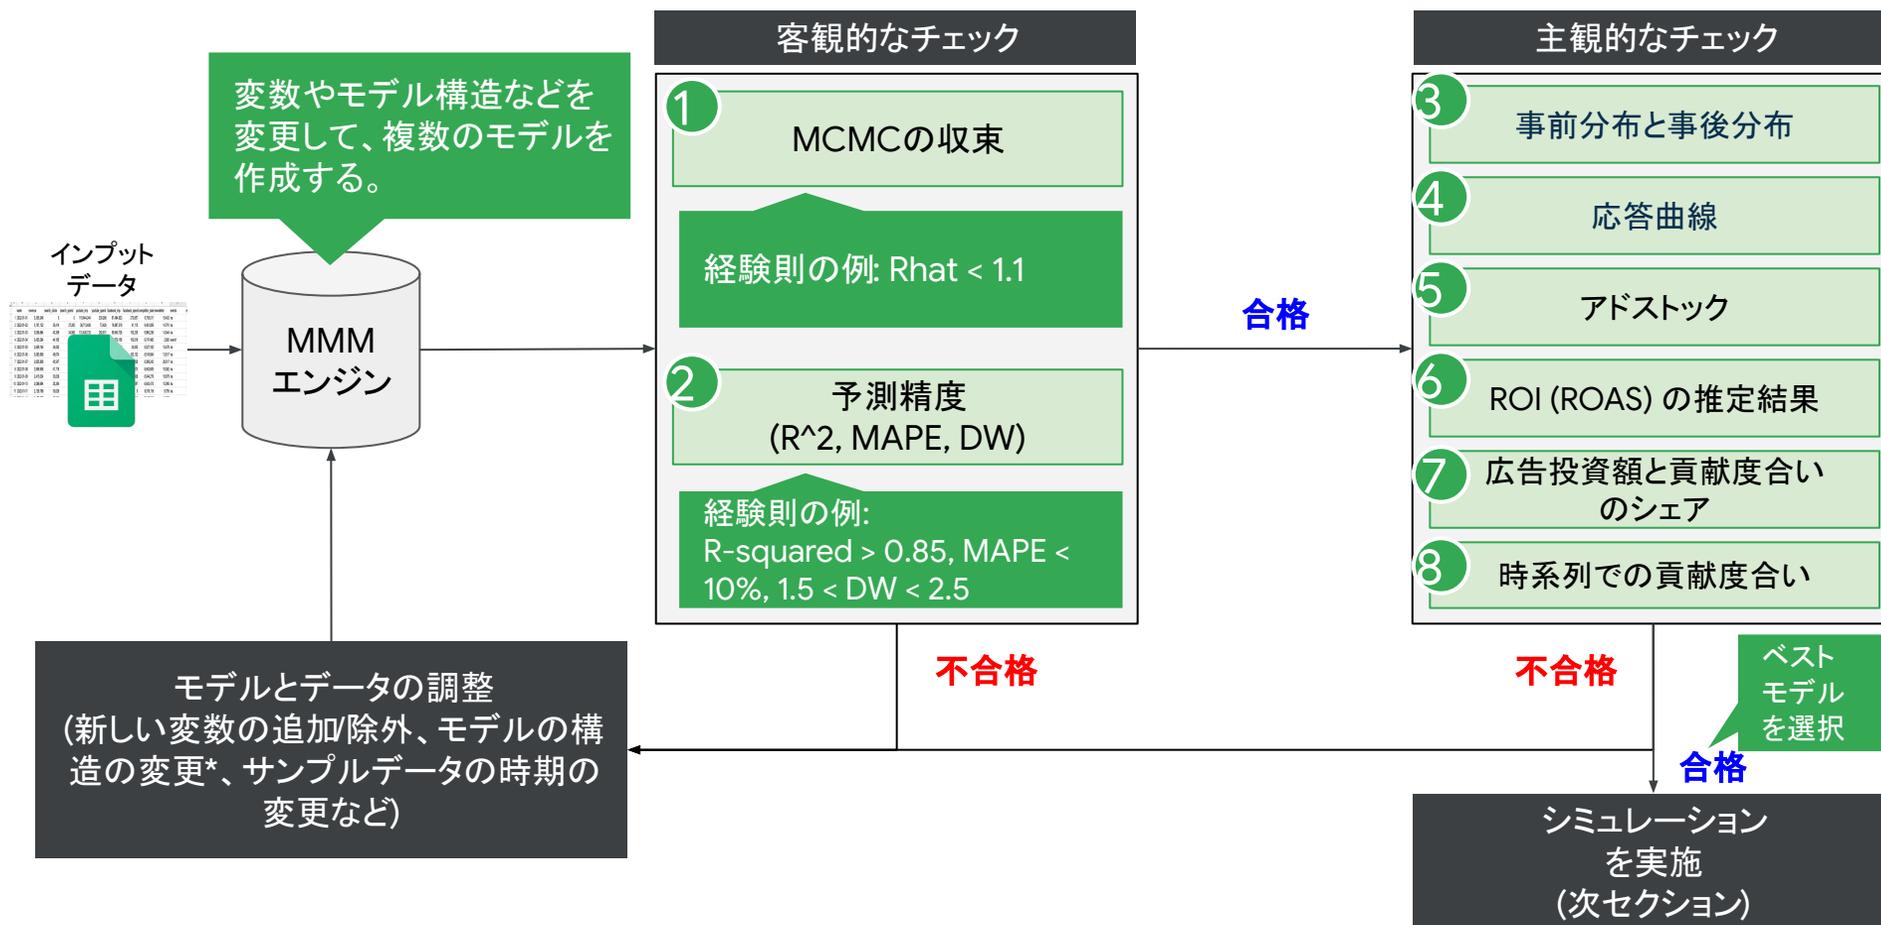
MMM、アトリビューション、(準)リフト計測(実験)における差異の主な理由を特定する。

MMMのパラメータを可能な限り調整する(p.76「(準)リフト計測(実験)によるキャリブレーション」を参照)。

## 複数のモデルを比較して、ベストなモデルを選択する

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、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。



## 2.6 モデルの利用

## MMMのユースケースの例

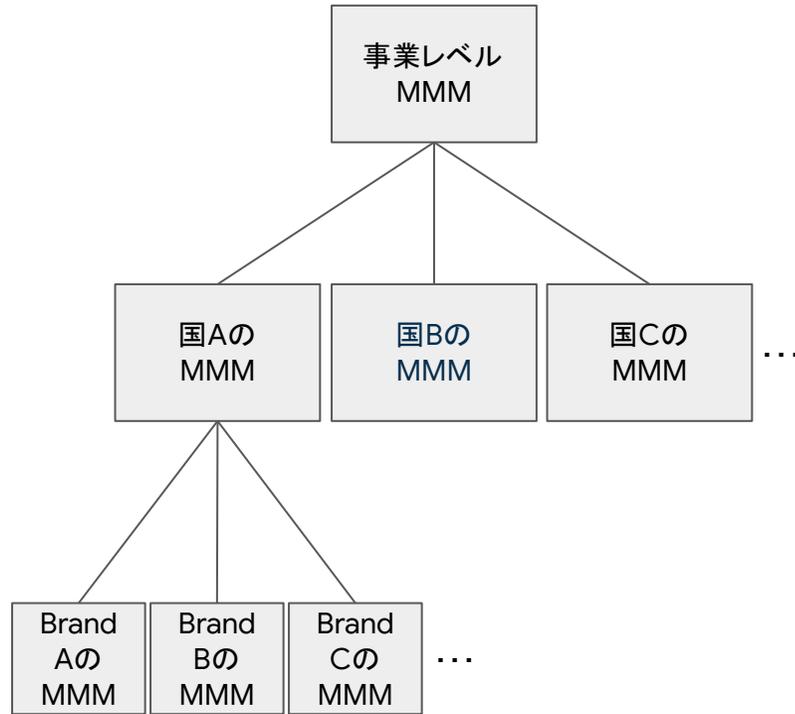
モデル作成後、モデル作成者とマーケティング・チームは、モデルを活用することが可能である。

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。



MMMの構造<sup>\*1</sup>



MMMの利用法

- ビジネス計画と実績値の差分を予測する
- 差分を調整するために、投資予算・リソースを調整する
- 市場の優先順位を検討するために、国別、ブランド別、ターゲット顧客別等のマーケティングの投資対効果をチェックする
- カテゴリー毎の広告や販促の予算を年、四半期、月、週単位で調整する

MMMの利用者の例

- 事業部長
- マーケティング部長
- マーケティングの実行チームのマネージャー

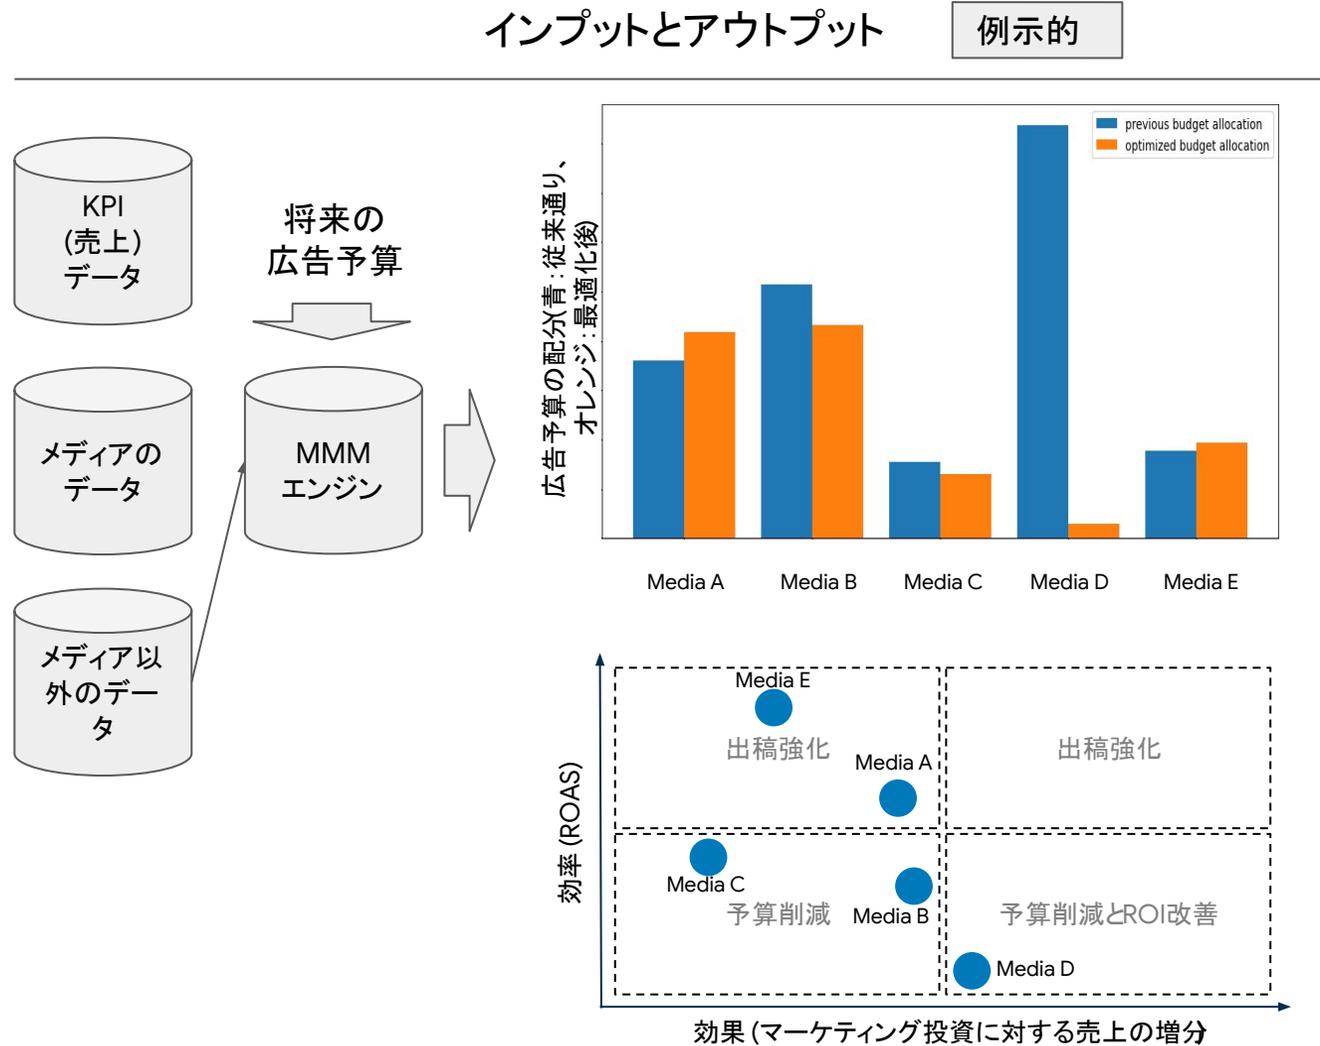
<sup>\*1</sup>: 市場間の事業、ブランド、顧客の行動の類似性によっては、[p.48-49](#)に記載した階層的なモデルも考えられる。事業、ブランド、顧客に類似性がない場合は、最下層（オペレーション層）で各モデルを作成し、それらを足し上げていくのが現実的である。

## 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)

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過去のデータを流用するなど、妥協が必要である。



### 使い方

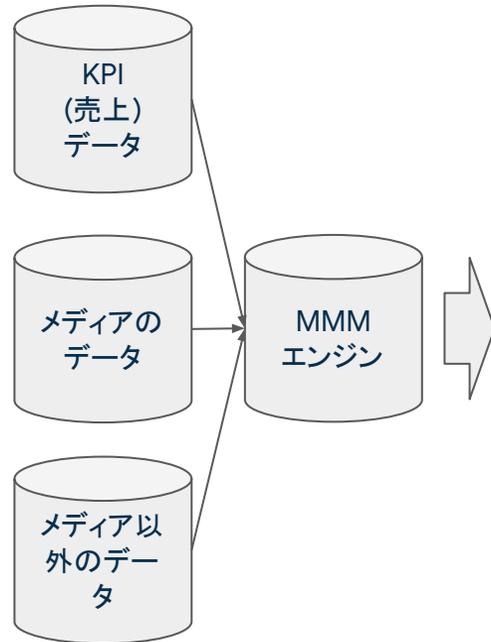
推奨に基づき、次期(週、月、四半期、年等)の予算配分を調整する

## 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)

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。

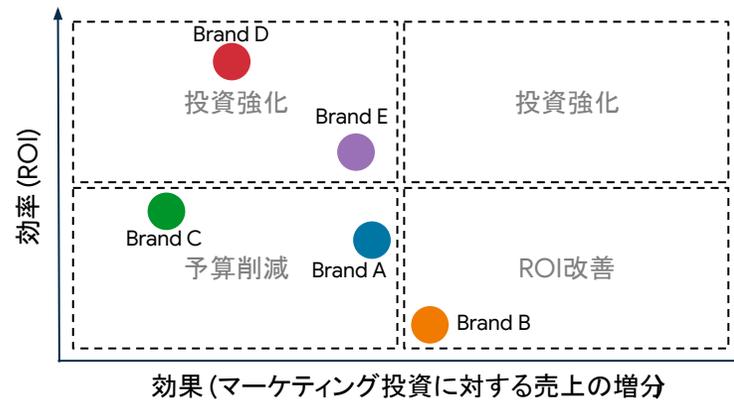
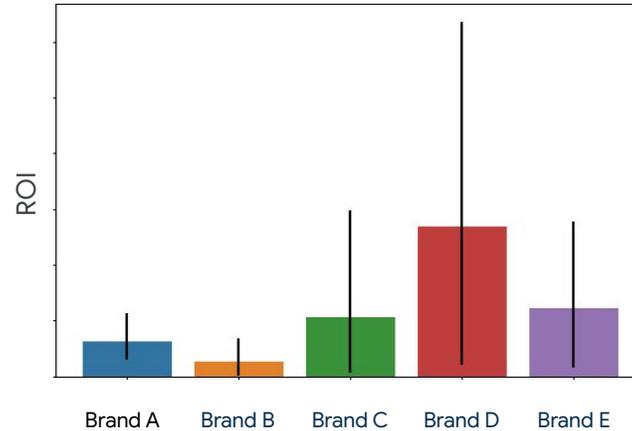


### インプットとアウトプット

例示的

### 使い方

ROAS (ROI)の推定結果



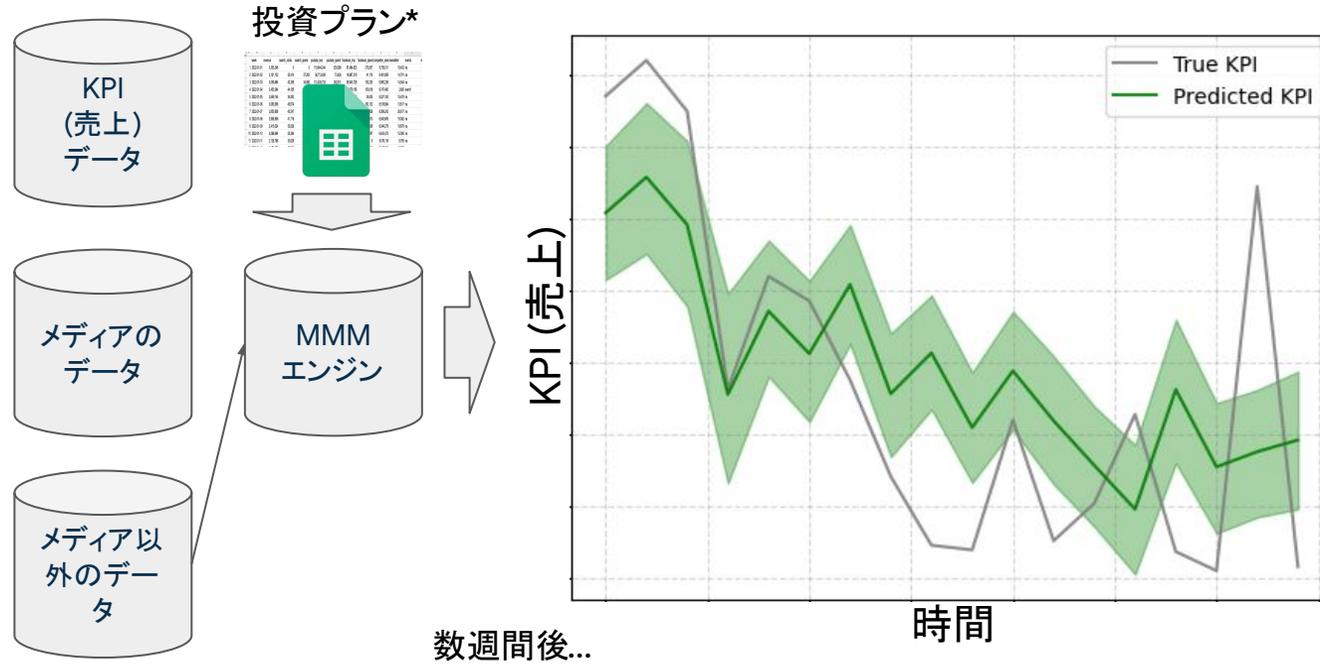
ビジネスのカテゴリ(例:国、ブランド、ターゲット顧客)毎にマーケティングのROIやROASを推定し、市場や事業領域の優先順位や戦術を考えるインプットとして利用する。<sup>\*1</sup>

\*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)や応答曲線を参照して算出すべきである (p.39)。一方で、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。

## ◎ 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のか分析する)。
- 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。

## 2.7 MMMに関するその他のトピック

# MMMのモデルに関するその他の主要トピック

	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一つである。</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一つである。</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に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>

# システム面の課題とメディア特有の主要課題

## 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、多頻度で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。

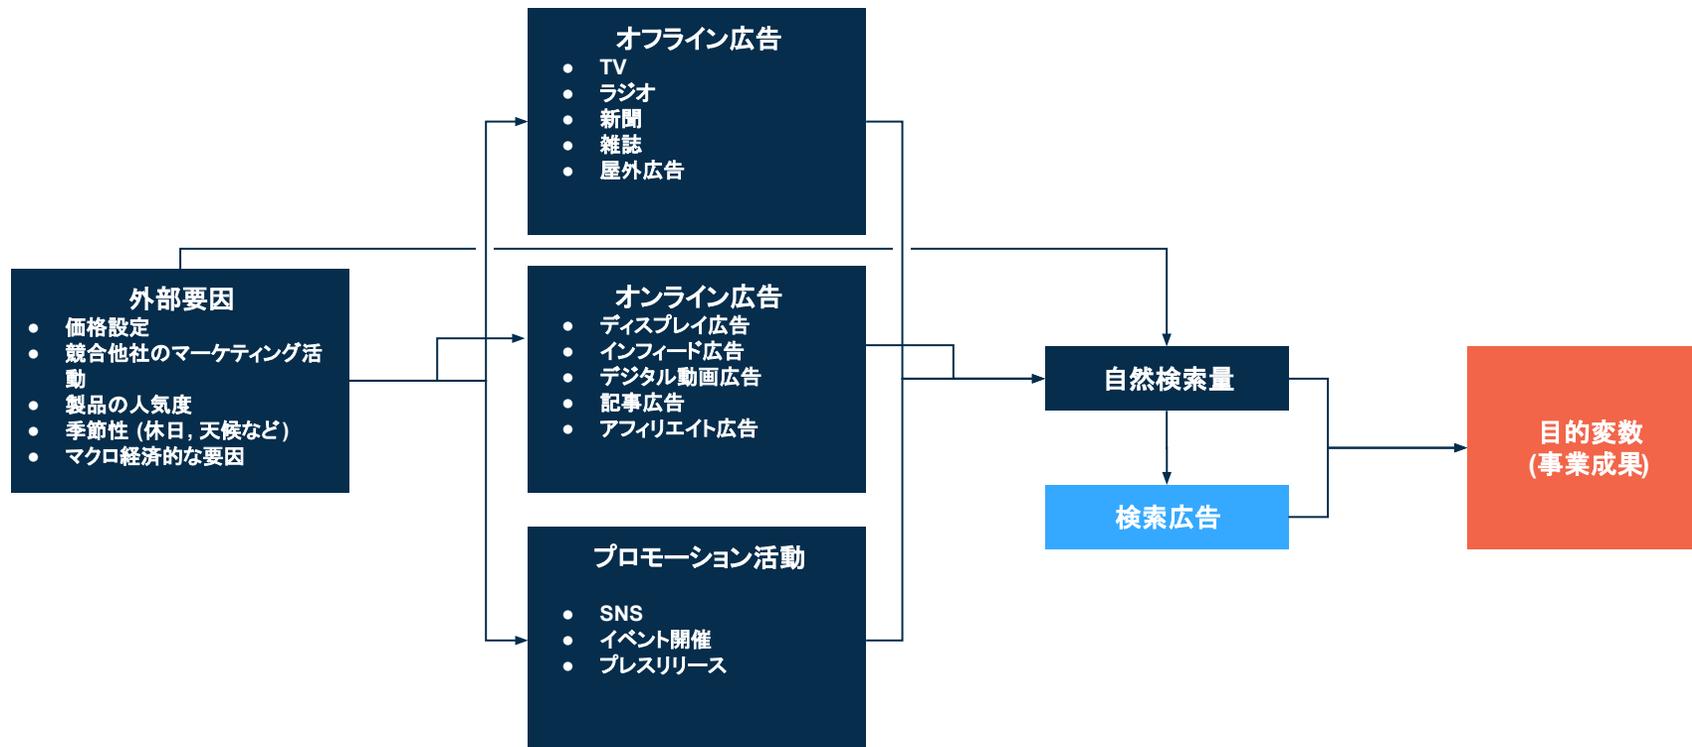
# CHAPTER 3: MMMにおける検索広告のモデリングに関する考察

本章では、dentsuのMMM分析の経験をもとに、MMMにおける検索広告のモデリングに関する主要な課題と可能なアプローチについて考察する。

## 検索広告のモデリングにおける課題の概要

検索広告の配信量は、動画広告やディスプレイ広告と異なり、他の広告メディアやトレンドの影響による検索クエリ量の増減の影響を大きく受ける。また、検索意欲のあるターゲットに対して配信される広告であるため、Webコンバージョンとの相関が比較的高くなりがちであり、単純な回帰モデル(p.33に記載した単加法モデルなど)で分析を行うと、実態と異なる寄与度を推定してしまうリスクがある。モデル化にあたっては、以下のグラフのように、結果とそれに影響を与える変数との相互依存関係を描いた上で、扱う変数やモデルの構造を適切に選択するなどのアプローチが必要である。

Web上で成果を測定できるビジネスにおける各変数と事業成果との相互依存関係を因果ダイアグラムとして表したもの\*



# MMMで検索広告をモデル化するための主な課題

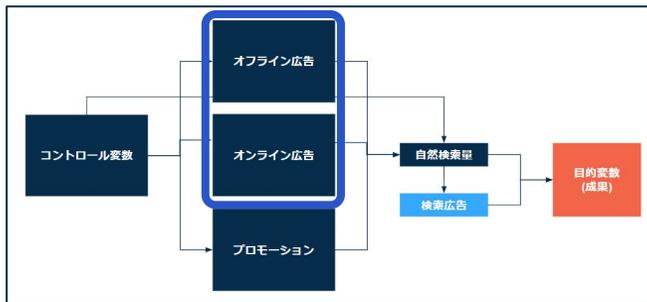
MMMによる検索広告の配信結果の評価にはいくつかの課題があり、適切に対処する必要があります。

右の表では代表的な5つの課題とその概要について説明している。モデルパラメーターの不自然な仮定、モデル構造の問題、目的変数の設定の問題など、**モデル構造やパラメーターの仮定に関する要因**のほか、インフルエンサーによる商品・ブランドの拡散などの外部要因の影響や広告の配信設定に対する人的な介入など、**モデル以外の要因**の可能性も含まれる。

これらの詳細について、dentsuの過去のプロジェクト事例をもとに、次ページ以降で解説する。

No.	カテゴリ	ケース	概要
①	モデル構造やモデルパラメーターの仮定に関する要因	広告の貢献度に関するパラメーターの事前分布の仮定が適切ではない	たとえば、ベイズ回帰を使用するオープンソースのMMMパッケージでは、各メディア貢献の事前分布のパラメータは、メディア投資額に比例すると仮定されている場合がある。
②		ブランド認知のための広告が自然検索量の増加に与える影響を考慮したモデル構成になっていない	例えば、ブランド認知のための広告が自然検索量に与える影響を考慮しない単純な加法モデルを使用した場合、モデルの推定結果には偏りが生じる。
③		目的変数の観測地点が広告活動から遠い位置にある	成果が確定するまでに多くの手続きやリードタイムがある場合、広告出稿と成果の相関関係をモデルで捉えきれないことがある。例えばLTV=Life Time Valueは、広告が配信されたあとにその指標を測定するのに時間がかかるためMMMの目的変数として不適である可能性がある。
④	モデル以外の要因	第三者要因によるもの	市場環境の変化や著名人の発言・行動等による話題性の変化により、当該ブランドに関連するキーワードの自然検索量が大幅に増減した場合、モデルで適切に表現できない可能性がある。
⑤		予算または最適化目標設定への人為的な介入(目標CPAや日次予算設定など)	広告キャンペーンの配信中に、日次の予算、目標PA、ターゲティング設定などを人為的に大きく調整すると、自然検索量と検索広告の配信量を中間指標とするモデルを使用している場合には、自然検索量と検索広告の配信量の相関関係を捉えることが難しくなる。

# 1 広告の貢献度に関するパラメータの事前分布の仮定が適切ではない



各広告の寄与度を推定するためにベイズ推定を用いることがある。ベイズ推定とは、あらかじめパラメータに仮定された確率(事前分布)をもとに、MCMCなどのサンプリングシミュレーションを用いて、ベイズの定理に基づいてパラメータの分布(事後分布)を推定するアプローチである。基本的な概念は本書の [p.52-54](#) でも概説されている。事前分布の仮定が各広告の貢献度に対して適切でない場合、推定に影響を与える。例えば、オープンソースのMMMパッケージである [Lightweight MMM](#) では、各広告の貢献度の事前分布のパラメータは、その広告の配信量に比例して設定されている(例えば、配信量を分散とする半正規分布)。

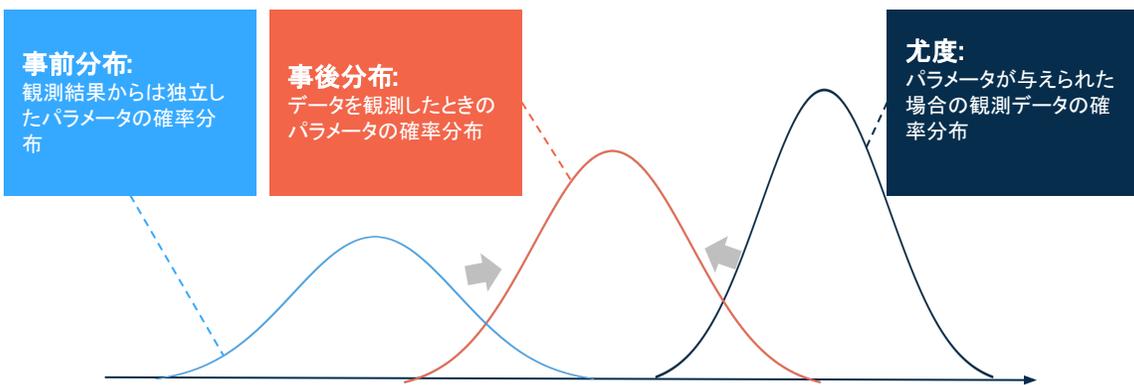
一方で、現実には、広告の貢献度は必ずしもその広告の配信規模に比例するわけではなく、過去の獲得実績や獲得までのリードタイムなどの知見に基づき、適切に事前分布を設定する必要がある。本書の [p.61](#) で示したように、事前分布の設定によってどの程度結果が異なるかを観察することも必要である。

## ベイズ推定の基本的な概念について(p.52-54)

ベイズ推定では、パラメータは点ではなく確率分布として推定される。各パラメータに仮定された事前分布と、データとパラメータの事前分布から計算された尤度の積によって、パラメータが従う分布を推定することができる。

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

事前分布 × 尤度 → 事後分布



## 例: LightweightMMMにおける各広告の貢献度に関するパラメータの事前分布

ベイズ回帰を用いて回帰係数 $\beta_i$ を推定することを考える。以下のモデルは、広告による成果の合計を表す。この場合、回帰係数 $\beta_i$ の事前分布を考慮する。

$$y = \sum_i \beta_i \text{Saturation}(\text{Adstock}(x_i))$$

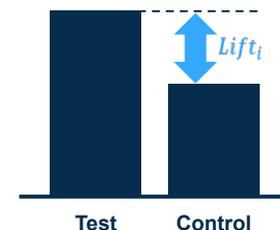
例えば [Lightweight MMM](#) では、回帰係数 $\beta_i$ のデフォルト事前分布は、広告の配信量 $v_i$ を分散とする半正規分布である。これは配信量の大きい広告は成果への貢献度も大きいということを暗に仮定しているが、仮に配信量の大きさが実際の成果への貢献度と伴っていない場合、配信量の大きい広告の貢献度が過大に評価される可能性がある。

## 客観的な事前分布の設定

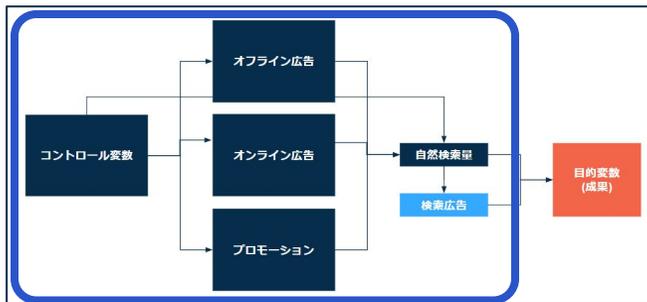
例えば広告媒体が持つ [Lift Test](#) 機能を使用して、当該広告の配信群と非配信群に分割し、二者間の差分(成果の純粋増分 [Lift<sub>i</sub>](#))を算出することで、相対的な成果への貢献度合いを客観的に知ることができる。

上記以外の方法では、例えば [Causal Impact](#) を用いた検証によって広告非配信時の成果推移を推定し、広告配信時の成果推移との差分を取ることで当該広告の貢献度を計ることができる。

一方で、これらの手法には、[p.76](#) でも言及しているように、リフト量の計測精度の問題や、検証期間とそれ以外の期間で広告の貢献度が異なる場合に対応できないといった問題もある。



## 2 ブランド認知のための広告が自然検索量の増加に与える影響を考慮したモデル構成になっていない



検索量が認知系広告から受ける影響を考慮しない単純加法的なモデルを使う場合などにバイアスをもつことになる。たとえば動画メディアで当該商品の広告に接触したユーザーがその商品名で検索を行い、表示された検索広告からサイトに流入する、といった動線が考えられる。このようにTVCMやディスプレイ広告など認知系の広告は検索量に影響し、検索量は検索広告の配信量に影響するといった関係性がある。このとき、「各広告の影響の単純な総和が成果となる」という前提で組み立てられる1階層のモデルを使うと認知系のメディアの間接的な成果への影響を表現できず誤った推定が返される恐れがある。そのため、認知系メディアと検索広告を併用したメディアミックスの場合などにおいては、検索量を中間指標とした多段階モデルを組むことが妥当であると考えられる。

弊社事例では、静止画ディスプレイ広告や動画広告など認知系の広告が検索量に与える影響も考慮した多段階モデルを用いた場合と単純加法的な単段階モデルを用いた場合を比較したものがあある。この例では同じ広告主のデータに対して、単段階多段階モデルそれぞれでモデリングを行った。データは過去年分の広告出稿実績データとWeb上でのサービスの申込数のデータ、ブランドの検索量などのデータを収集し、TVCM配信期間や休日を示すダミー変数を生成している。

単段階のモデリングにはLightweight MMMを用いている。多段階のモデリングでは下記数式及び右記ダイアグラムで示されるように、線形モデルを3段階に組合せた構成をとっており、回帰係数などのパラメータをベイズ推定(p.52-54)を用いて推定している。\*2

### 単階層モデル \*1

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

### モデル構造に対する仮定

- 目的変数は、ウェブサイトにおけるコンバージョン数である。
- モデルでは加法的線形構造を仮定しているため、メディア変数は互いに独立である(例えば、TV/YouTubeと検索広告の配信量には依存関係がない)。
- テレビ広告の配信は非メディア変数として扱われるJV広告の実施、休日、競合ブランドの自然検索量、関連ワード自然検索量、Covid-19感染はコントロール変数に明示的に含まれる。
- また、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ている。

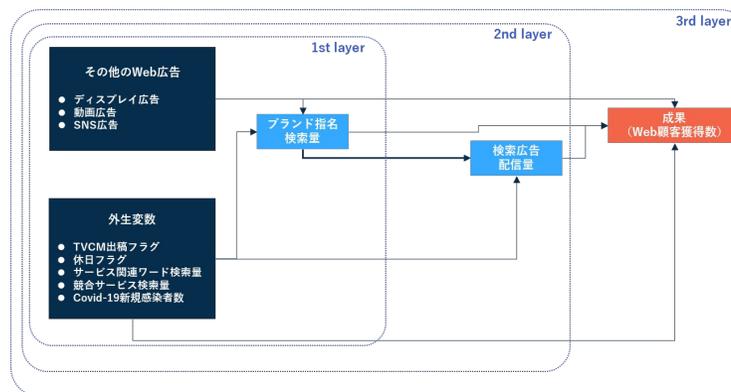
### パラメータに対する仮定

- メディア変数にはHILL関数(p.47)と幾何アドストック(p.50)を仮定。
- 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LightweightMMMにおけるデフォルトの設定を利用。

\*1: オープンソースのMMMであるLightweight MMMを使用。

\*2: 多層モデルは、メディアやその他の要因がビジネス成果に寄与する推定にバイアスを持つ可能性もある。このようなモデルの検証には、因果推論手法を適用すべきである。

### 多階層モデル



- 目的変数はウェブサイトにおけるコンバージョン数である。
- レスポンスカーブ、アドストック関数は電通デジタルの知見に基づき、メディアごとに設定している。
- テレビ広告は非メディア変数として扱う。
- TV広告の実施、休日、競合ブランドクエリ量、関連ワードクエリ量、Covid-19感染はコントロール変数に明示的に含める。

1st layer:  $search\ volume = WebAd \times \beta_1 + extra\ features \times \beta_2 + intercept_1$

2nd layer:  $search\ ads = search\ volume \times \beta_3 + extra\ features \times \beta_4 + intercept_2$

3rd layer:  $KPI = search\ volume \times \beta_5 + search\ ads \times \beta_6 + WebAd \times \beta_7 + extras \times \beta_8 + intercept_3$

## ② ブランド認知のための広告が自然検索量の増加に与える影響を考慮したモデル構成になっていない

右図は、Google Analyticsで計測した最終クリックアトリビューション\*1によるWebサイトへの最終流入シェア、各メディアへの投資額、テストデータから推定した純増効果のシェアを、単階層・多階層モデルそれぞれで可視化したものである。

下記のインサイトに着目する。

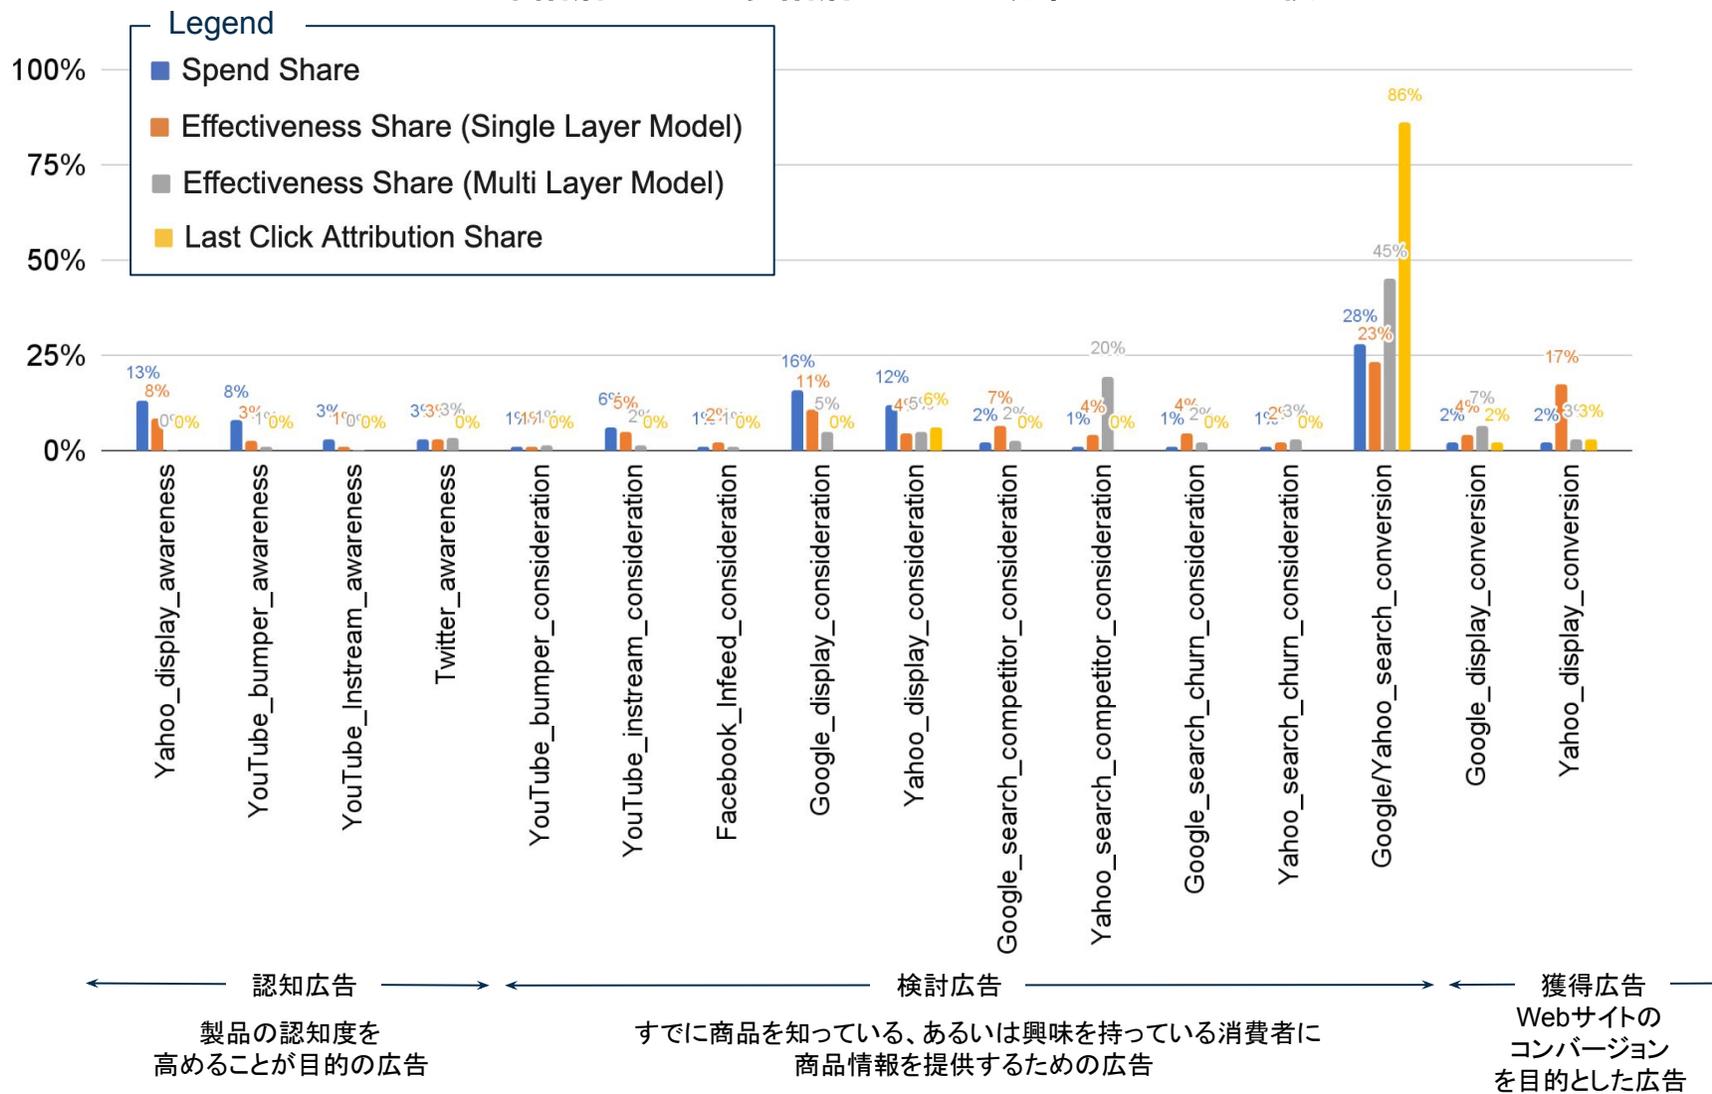
第一に、ウェブサイトのコンバージョンへの貢献度を示すラストクリックのアトリビューションによる測定結果は、検索広告に偏っている。\*1

第二に、単階層モデルと多階層モデルとでは、ウェブサイトのコンバージョンへの貢献度の推定に大きな違いがある。

第三に、ファネルレイヤーによって、広告費シェアとコンバージョン貢献度シェアのギャップの傾向が異なる。

次のページ以降では詳細について解説する。

単階層モデルと多階層モデルの効果のシェアの比較 \*2

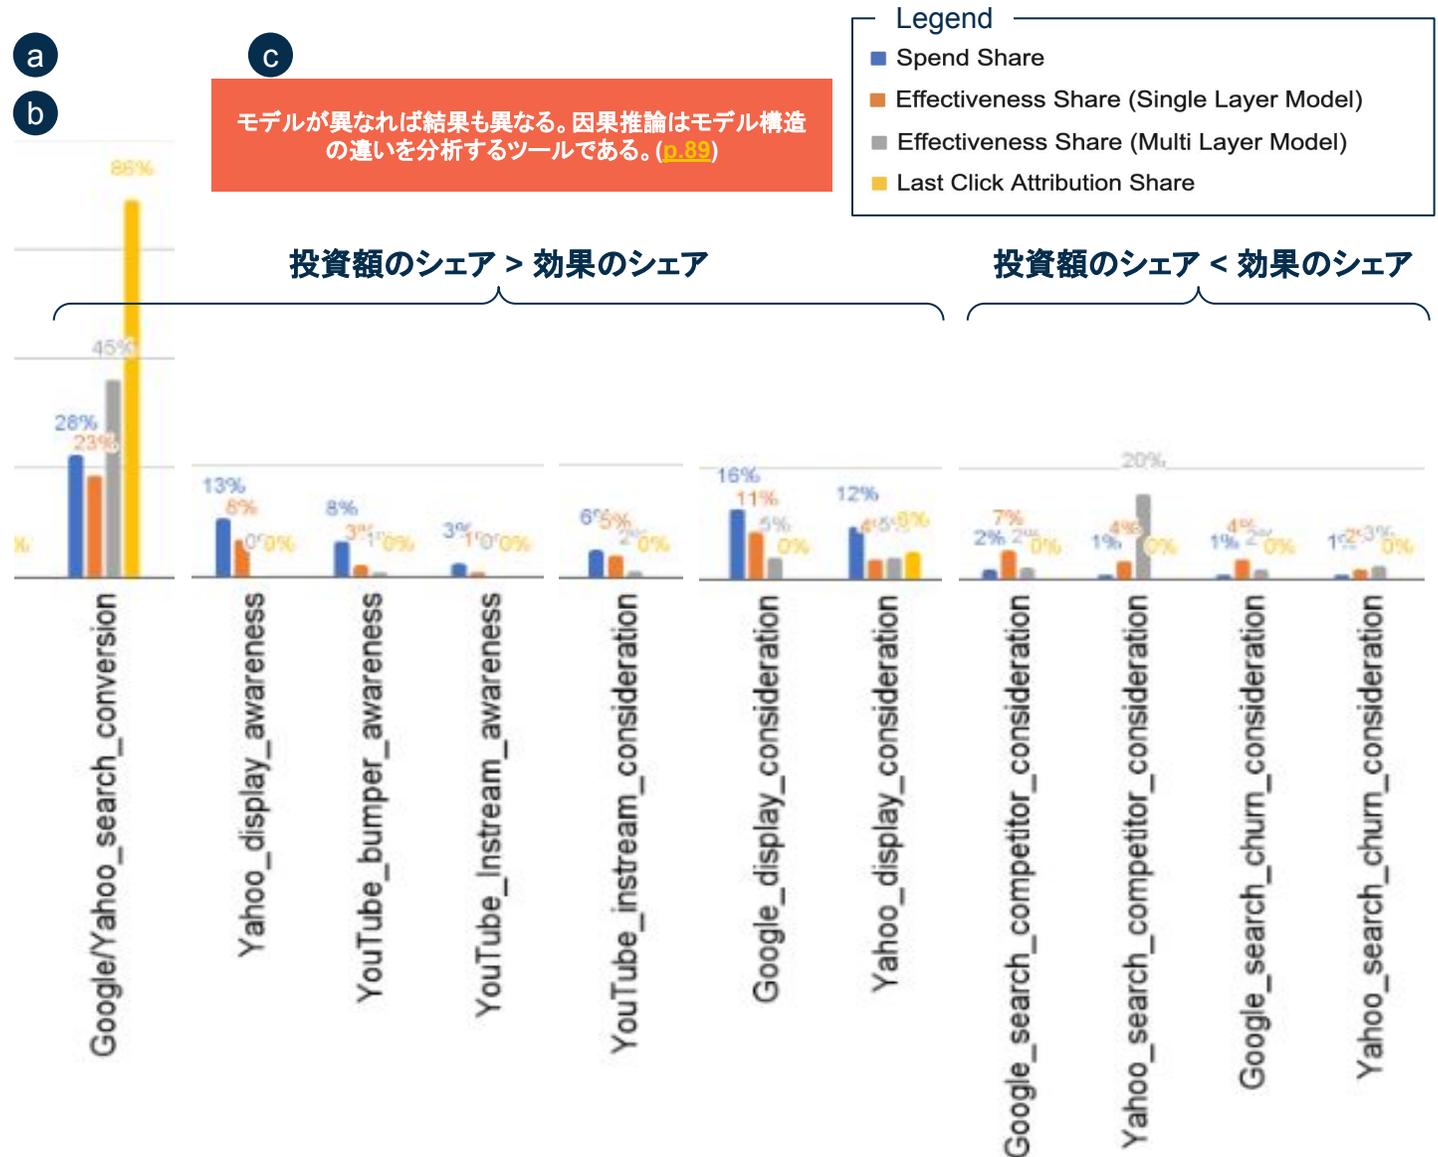


## 2 ブランド認知のための広告が自然検索量の増加に与える影響を考慮したモデル構成になっていない

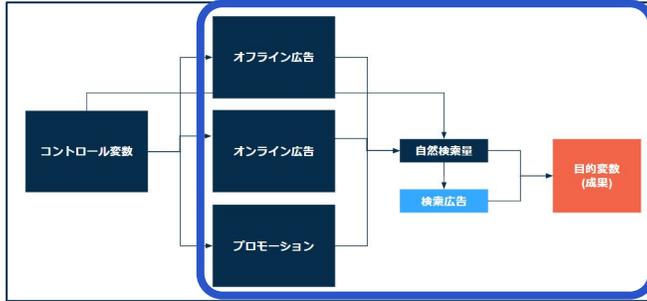
まず、ウェブサイトコンバージョンへの貢献度のラストクリックアトリビューションによる測定結果は、検索広告に偏っている。ラストクリックのアトリビューションモデルでは、コンバージョン前にユーザーが最後にクリックした媒体がコンバージョンに寄与していると測定されるため、検索広告の寄与率が相対的に高くなる傾向がある。今回のケースでは、広告経由の全コンバージョンの86%が「獲得のための検索広告」によって貢献したと測定された。コンバージョン前に最後にクリックされたメディアの大半が検索広告であったという事実は重要であるが、検索広告以前のメディアの貢献度が測定されていないため、偏った結果となっている。

第二に、ウェブサイトのコンバージョンに対する貢献度の推定において、シングルレイヤーモデルとマルチレイヤーモデルの間には大きな違いがある。例えば、「Google/Yahoo\_search\_conversion」による広告経由のウェブサイトコンバージョンの寄与率は、シングルレイヤーモデルでは23%、マルチレイヤーモデルでは45%である。この約2倍の差(45%/23% = 1.94)は、異なるモデル構造を選択することで、メディア貢献度の推定に大きな差が生じる可能性があることを示唆している。

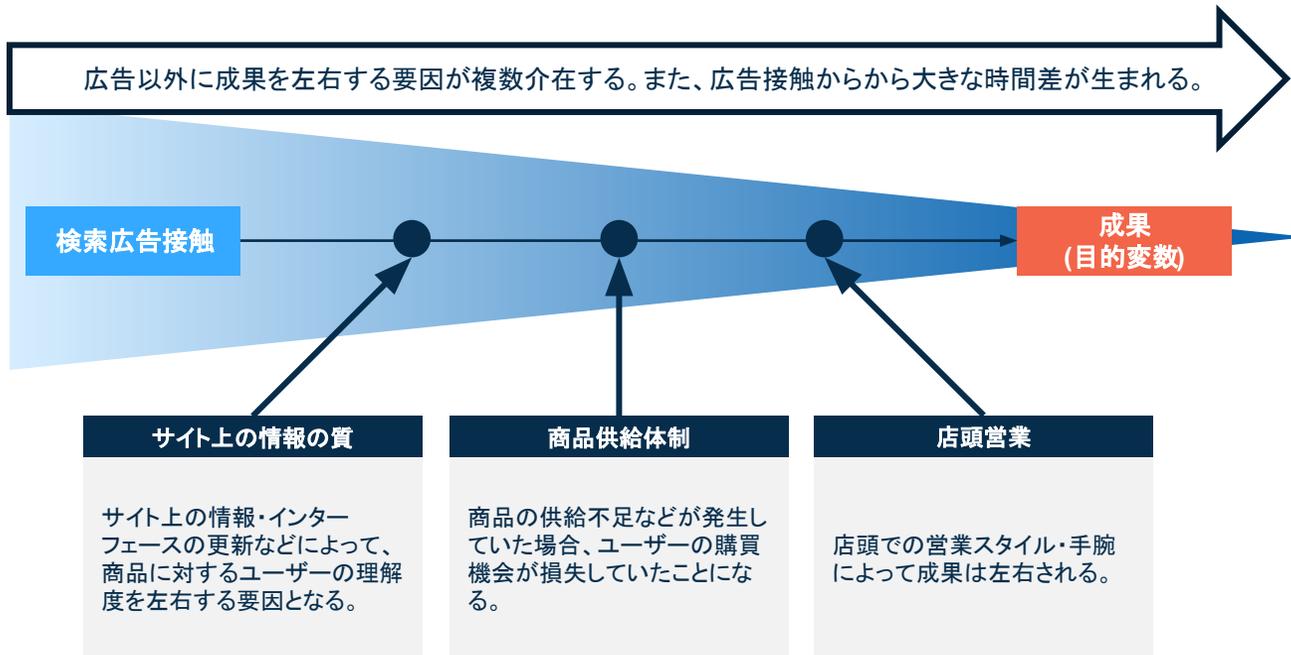
第三に、広告フォーマットによって、広告費シェアとコンバージョン貢献シェアのモデル別ギャップの傾向が異なる。例えば、「YouTube\_bumper\_awareness」や「YouTube\_instream\_awareness」のようなアッパーファネル広告は、広告費シェアと比較して貢献度が小さい。一方、「Google\_search\_competitor\_consideration」のような検索広告は、支出シェアに対する貢献度が大きい。この事実は、テレビやYouTubeのようなアッパーファネル広告と比較して、検索広告(または獲得広告)はKPI(モデル内のコンバージョン数)と高い相関関係を持つ傾向があることを示唆している。因果推論は、このような状況を分析するための検討事項であり(p.89を参照)、有効な解決策の1つであると考えられる。



### 3 目的変数の観測地点が広告活動から遠い位置にある



検索広告接触から成果確定までに多くの手続きやリードタイムがある場合にモデルが成果との相関を捉えづらくなるケースがある。  
 例えば、成果となる目的変数がリードタイムの長い「自動車の購入成約」や「日用消費財の店頭売上」などである場合、広告による誘導先のWebサイトでの表示情報や商品の供給体制、店頭営業の質など広告接触後の介在要因によって成果につながるかどうか左右される。また、広告接触から成果確定までに時間が大きく経過する場合広告の配信量と成果の相関をモデルが捉えづらくなる可能性がある。その結果、広告配信によって喚起したユーザーが成果につながっていない場合、特に成果に近い地点で接触している検索広告の貢献が過小に推定される恐れがある。

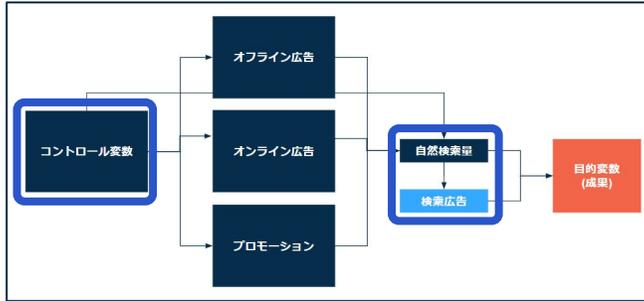


#### 深すぎる目的変数の設定の例

- 自動車販売の購入成約数・売上
- 住宅販売の購入成約数・売上
- 日用消費財の店頭販売数・売上
- 飲食店の来店客数・売上
- 多商品ECサイトの売上
- 生命保険・損害保険・火災保険などの成約数・売上
- オンライン証券販売の売上
- 食品・飲料の店頭販売数・売上
- 家具・電化製品の店頭販売数・売上

上記のようなビジネス成果をMMMで目的変数としてモデリングする場合は、Webサイトの品質、商品供給、営業スキル・プロモーションなどの中間変数をモデルに含める必要がある。ビジネス成果に対するメディア投資の過小評価を避けるために、中間的な目的変数(例:ウェブサイト訪問数、実店舗訪問数)を持つMMMモデルを追加で作成することが考慮される。

## 4 第三者要因によるもの



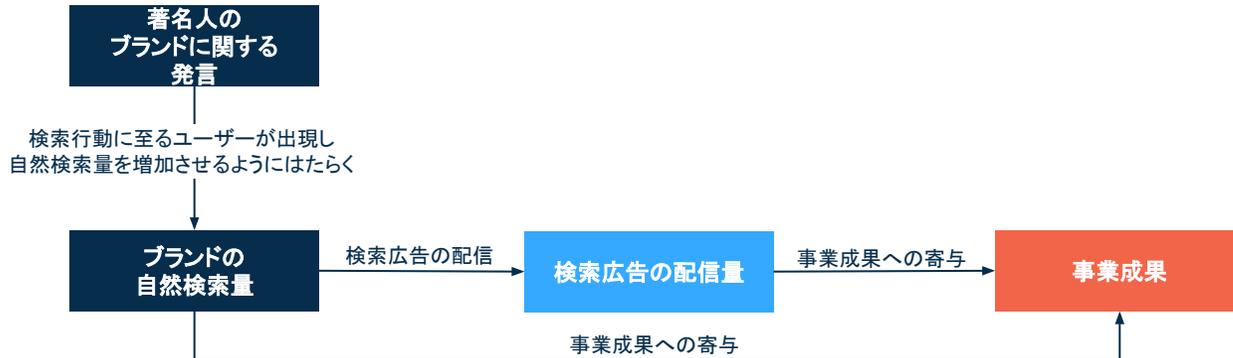
市況の変化や、著名人の発言・行動などによるトレンドなど、感知できない第三者的要因によって当該商材に関連するキーワードの検索量が増減することがあると、検索広告の貢献度が正常に推定できないと考えられる。例えば、著名人がSNSなどで当該商材を紹介するなどした場合、それによって検索量が増加し、伴って成果も増加するがその著名人の行動を変数として組み込まない限り、本来その著名人の貢献であったものを検索広告の貢献としてモデルが捉えてしまう可能性がある。このような第三者要因もデータとして収集しモデルに取り込むこと、Case.2で言及したような多段階のモデルを構成し、検索量への影響を経て成果に影響するような様態をモデリングする必要がある。\*

### 例: 影響力のある著名人が使っている化粧品についてSNSで言及した場合

ある著名人がフォロワー数の多い自身のSNSアカウントで自分が使っている化粧品について言及したときのことを考える。フォロワーを中心にブランド名などで自然検索量が増加しオンラインで購入に至るユーザーも現れる。このとき化粧品購入の直接貢献元は検索広告となるが、実際には著名人の発言が大きく寄与しているため、この要因をモデルに組み込まない限り検索広告の貢献度が過大に推定される可能性がある。

### 示唆されること:

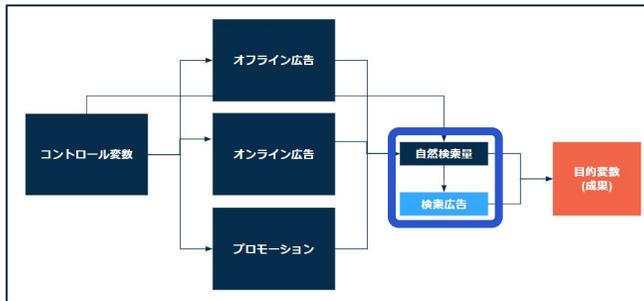
- インターネット上で自社のブランドの話題性などについて常時リサーチを行い、左記の例のような著名人の発言などがあった場合変数として取得しMMMに組み込むようなワークフローを検討する必要がある。
- そのため商材の関連ワードについて、キーワード単位で検索量の増減をモニタリングし、増減の要因に仮説を持てるようにしておく必要がある。
- 左記の例のように著名人の発言が検索量を増加させ、それによって検索広告の配信量も増え、成果も伴って増大するといったような様態を表す多段階のモデルを構成する必要がある。



### 第三者要因によって自然検索量が増加する例

- 著名人がSNSやTV番組などで化粧品ブランドとその利用体験について言及したことによりブランド名の検索量が増加する
- TV番組で家電が特集されたことにより商品名の検索量が増加する
- 著名人が自身のがんの闘病体験を公表したことにより「がん保険」などの一般キーワードの検索量が増加する
- 円高の市況を伝えるニュースが報じられたときに海外旅行やその関連キーワードの検索量が増加する
- 金利変動の市況を伝えるニュースが報じられたときにカードローンや住宅ローンなどのキーワードの検索量が増加する

## 5 予算または最適化目標設定への人為的な介入(目標CPAや日次予算設定など)



特に検索量を中間指標として検索広告の配信量を推定するような多段階のモデルを使う場合に、日予算や目標CPA、ターゲティング設定に人為的に大きな調整が加わると、検索広告の配信量と検索量との相関が弱まってしまい、推定結果にバイアスを生じさせる恐れがある。例えば、競合他社や別の広告代理店での検索広告配信によって入札競争が生じCPAが高騰したときに日予算を大きく下げ配信量を抑制することがあるが、この場合検索量に対して検索広告の出稿量は減少し、相関関係が弱くなることになる。

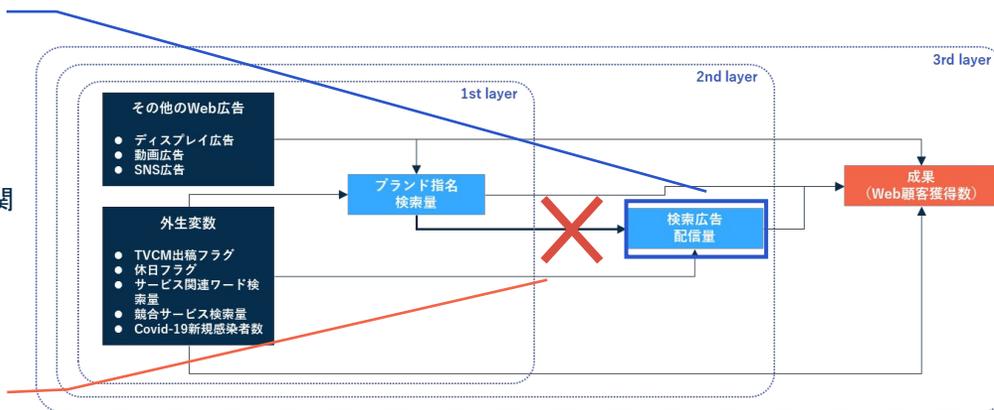
広告主によっては複数の広告代理店で広告を配信していたり、商品の販売代理店ごとに独自で広告を配信しているケースもあるため注意が必要である

他代理店の検索広告配信によるCPA・CVRの悪化によって、予算やCPA目標を調整することがあった。

### 例: 日次予算やCPA目標の大幅な変更による影響

弊社の事例では、右図のように3段階のモデルを作成し、2層目のモデルでブランド検索ボリュームが検索広告配信ボリュームに与える影響をモデル化した。この場合、指名検索ボリュームと検索広告配信ボリュームには相関関係があると仮定した。一方、競合他社や他代理店の検索広告配信による入札競争によりCPAやCVRが悪化することが多いため、実際にはCPAやCVRの変動に応じて1日の予算額を大きく調整した。その結果、指名検索ボリュームと検索広告配信ボリュームの相関が弱くなり2ndレイヤーモデルのMAPE等の精度が上がらなかった。

結果として検索量との相関が弱くなり、検索量と検索広告配信量の関係をモデルが捉えにくくなってしまった。



### 示唆されること:

- 検索広告の配信量は自然検索量の影響を受けるが、日予算や目標CPAなどの設定調整の影響が大きく、自然検索量との相関が弱くなることもある。
- 自然検索量とは独立した構造になることを前提としても検索広告配信量を明示的にモデルに組み込む方が表現力の高いモデルになる可能性がある。
- 実際に、検索広告配信量を明示的に組み込んでモデリングした方がモデルの精度が高かった例もある。
- また、その際自社の商品名やブランド名などの「指名キーワード」の配信と、商品に関連する単語などのいわゆる「一般キーワード」の配信は分けてモデルに組み込む方が良い。
- さらにブランドを認知しているユーザーが能動的に検索するため指名系キーワードと、競合他社の配信とも入札競争しやすい一般キーワードは、獲得効率などが大きく異なるためである。

# MMMにおける検索広告のモデリングの方向性

No.	示唆	MMMにおける検索広告のモデリングの方向性	Consideration
1	ベイズ推定を用いる場合、検索広告の貢献度に関わるパラメータに仮定する事前分布は、分析者のメディアに対する先入観などを排除して設定する必要がある。	<p><b>メディアの貢献度の事前分布を決定するための客観的基準を導入する</b></p> <p>各メディアが提供する Lift Test 関数や <b>Causal Impact</b> などの統計解析手法を用いて広告の正味の効果を算出することで、広告が結果にどの程度貢献したかを客観的に判断することができる。このようにして得られた検証結果をもとに、貢献度の事前分布を設定することも一つの手段である。</p>	<ul style="list-style-type: none"> <li>各メディアが提供する LiftTest の機能を使って得られたコンバージョンリフトは、Cookie やデバイス ID のプライバシー保護の影響を受ける可能性があり、測定の実現性と正確性を評価する必要がある。</li> <li>コンバージョンリフトの結果は時間の経過とともに変化する可能性があり、1 回の検証で得られた結果の連続性には疑問が残る。</li> </ul>
2	単階層の加法モデルと多階層モデルでは、検索広告の貢献度の推定値が大きく異なる可能性がある。	<p><b>多階層の MMM モデルを作成する必要がある</b></p> <p>テレビ CM、Web 上のバナー・動画広告、著名人の発言といった 3 つの要素が、自然検索量を増加させ、検索広告の配信量を増加させる関係がある場合、検索クエリ量を中間指標として多層モデルを構築することは、そのような影響関係のある程度考慮したモデリングが可能であり、検索を通じた間接的な貢献も推定できるため有効である。</p>	<ul style="list-style-type: none"> <li>Judea Pearl 氏が提唱した構造的因果モデルの概念を導入し、バックドア基準、フロントドア基準、シングルドア基準などの基準を用いて、交絡因子となる変数を特定し、調整(条件づけ、層別化)することで、交絡因子の影響を排除するロジックを考える必要がある。</li> </ul>
3	目的変数が広告接触から遠すぎる位置で観測される場合、MMM で広告の寄与効果を測定するのは困難である可能性がある。	<p><b>広告接触から距離がある地点で観測される目的変数とすることは避けるか、変数に中間仮定の状況を示す変数を用いる</b></p> <p>広告接触から時間的に離れた地点(例えば、代理店での保険契約)を MMM の目的変数とする場合、中間プロセス(例えば、代理店での営業スキルや販売促進)のデータを含める必要がある。また、これらの中間プロセス変数の影響は、MMM における上流の広告投資の寄与よりも大きく算出される可能性があるため、中間目的変数(例えば、来店時の Web サイト登録)を持つ別の MMM を作成することも検討に値する。</p>	<ul style="list-style-type: none"> <li>目的変数が「遠すぎる」ことの客観的基準がない。</li> <li>最終成果に至るまでの中間データ(例えば、店頭での販売スキルや販売促進に関するデータ)は多くの場合入手が困難であり、代替的な方法(例えば、確率モデルを用いる方法)を検討する必要がある。しかし、代替手法は仮定依存するためモデル作成者によるバイアスの問題もある。</li> </ul>
4	市場の状況やトレンドなどの第三者的要因は、検索クエリのボリュームに影響を与える。	<p><b>ブランド関連キーワードの検索クエリボリュームの増減をモニターすることで、市場の状況やトレンドとの関連性について仮説を立てることができる</b></p> <p>商材に関連するキーワードのリストを作成し、自然検索量の推移を日々確認することで、増加があったときに、経済指標やソーシャル上のホットピックなどと照らし合わせて要因の仮説を立て、適宜オープンデータを収集したりダミー変数を作成するなどして MMM の変数に組み込む。</p>	<ul style="list-style-type: none"> <li>キーワードごとの自然検索量、SNS のハッシュタグなどのデータを継続的に収集するのは容易ではない。例えば、Google Trend のデータは絶対的な検索数ではなく、相対的なボリュームである。</li> <li>主要な検索プラットフォームから特定キーワードの自然検索量のデータを取得するインターフェースの提供が待たれる。</li> </ul>
5	検索広告の配信量は、日次予算や目標 CPA などの設定に大きく影響されるため、これらの影響を考慮したモデリングが必要になる。	<p><b>必要に応じて、ブランドキーワードと一般キーワードを分けた上で、検索広告配信量を変数に採用</b></p> <p>検索広告の配信量は、自然検索量に影響されるが、日次予算や目標 CPA などの設定の調整にも影響される。自然検索量と検索広告配信ボリュームが独立する可能性も考慮すべきである。企業ブランド名などの「指名キーワード」は、すでにブランドを認知しているユーザーによって検索されるため、認知を高めるための活動(デジタル動画広告への投資など)と相関があるが、商品タイプやアイテム名などのいわゆる「一般キーワード」は、まだブランドを認知していないユーザーによって検索される可能性がある。指名キーワードと一般キーワードの広告を区別することも考慮すべきである。</p>	<ul style="list-style-type: none"> <li>自然検索量と検索広告配信量の独立性は、日々の予算や目標 CPA の設定に依存するため、状況に応じて分析・検討する必要がある。</li> <li>「ブランドキーワード」と「一般キーワード」の境界線が曖昧な場合があり、個別に検討する必要がある。</li> </ul>

# 発展的なアプローチ(構造的因果モデルを導入したアプローチ)

前ページのMMMの要点の中で多段階のモデルを作成することについて触れたが、その課題点として Judea Pearl氏の提唱する構造的因果モデルの概念を導入した変数の「調整」についても言及した。ここでは構造的因果モデルの概要について簡単に紹介する。

構造的因果モデルではしばしば、DAG(非巡回有向グラフ)を用いて変数同士の因果関係を記述する。各変数をノード(点)、変数間の因果関係をエッジ(辺)とし、原因となる変数から結果となる変数に向かって矢印が描かれたちとなる。このようにして描いたものを因果グラフと呼ぶ。

因果グラフ上の任意の2変数X, Yの因果関係を調べる際に、その他の変数集合 Zで条件付けする(回帰分析の枠組みでは、Zを変数として回帰分析に含める)ことでZによる交絡を取り除いて因果効果を計算することができる。この条件付けを「調整」と呼ぶ。このとき、どの変数集合 Zで調整を行うかが重要となる。下記で定義されるバックドア基準・フロントドア基準を使うことで、どの変数集合について調整すべきかを知ることができる。

## バックドア基準

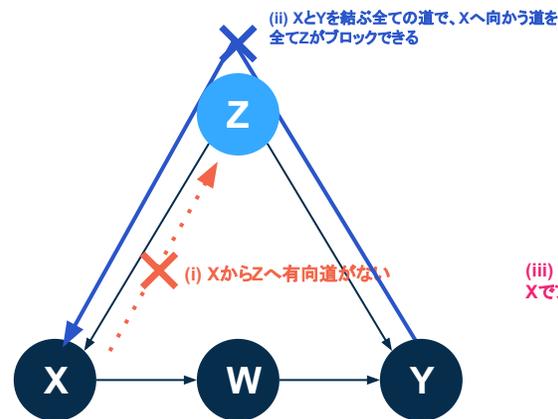
因果グラフGにおいて、変数Xから変数Yへの有向道があるとする。そのとき以下を満たす変数集合Zは(X,Y)についてバックドア基準を満たすという。

- (i) Xから集合Zの要素に有向道がない
- (ii) XとYを結ぶ全ての道で、Xへ向かう道を全てZがブロックできる

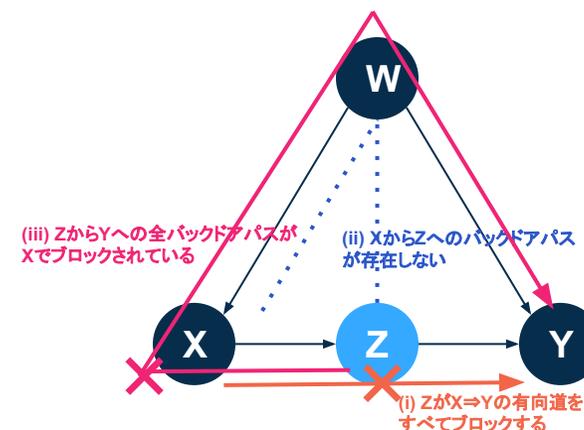
## フロントドア基準

因果グラフGにおいて、変数Xから変数Yへの有向道があるとする。そのとき以下を満たす変数集合Zは(X,Y)についてフロントドア基準を満たすという。

- (i) ZがX→Yへの有向道を全てブロックする
- (ii) XからZへのバックドアパスが存在しない
- (iii) ZからYへの全バックドアパスがXでブロックされている



バックドア基準を満たす Z の例

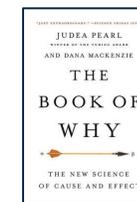


フロントドア基準を満たす Z の例

上記バックドア基準・フロントドア基準のいずれかを満たすような変数集合 Zが変数X, Yの因果関係を調べる上で調整すべき変数になるとされている。また、線形かつパラメトリックな構造方程式モデルにおいては、変数 Xとバックドア基準を満たす変数集合 Zを説明変数、Yを目的変数とした回帰モデルで得られる Xの回帰係数がXからYへの総合効果として扱えることが知られている。

上記のような構造的因果モデルの概念を MMMに導入する際の具体的かつ断定的な手法はまだ確立されておらず、今後の研究トピックの 1 つになると考えられる。

なお、Judea Pearl氏の因果推論の理論の詳細については右記の書籍を参照されたい。



The Book of Why: The New Science of Cause and Effect/BASIC BOOKS - Judea Pearl

# CHAPTER 4: dentsuのMMMのケイパビリティ

この章では、dentsuのMMMのケイパビリティについて紹介する。  
この章の内容は前章以前で解説した一般論や考察の内容とは独立している。

# 電通でMMMを実施するメリット

## MMM導入と社内共有サポート

- MMMの方法論・分析結果をわかりやすくご説明
- 分析結果を広告主様社内の様々な組織へ共有する部分をサポート

## 広告代理店として広告媒体や対象ブランドの特性に合ったモデリングを実施

- 広告媒体の特性をよく理解した上でのモデリング
- 多種多様な業界での実例と知見に基づくモデリング
- 広告主様と密に連携し、課題に沿った分析スコープ作成と結果評価を実施
- 他データや調査結果などを合わせた分析結果の評価

## 統合的で現実的な戦略立案をサポート

- モデリングだけで終わらず、その結果の活用、次の打ち手の立案と実行までをサポート
- 統合的な視点による現実的な戦略立案
- モデルの特性を十分に理解した最適化/シミュレーション

## グローバルなブランドでのMMM実行力

- dentsuのグローバルなネットワークを活用したMMMの実行支援体制を持つ
- 各ローカルごとのメディアの特性や事例を取り込みながらモデリングを実行

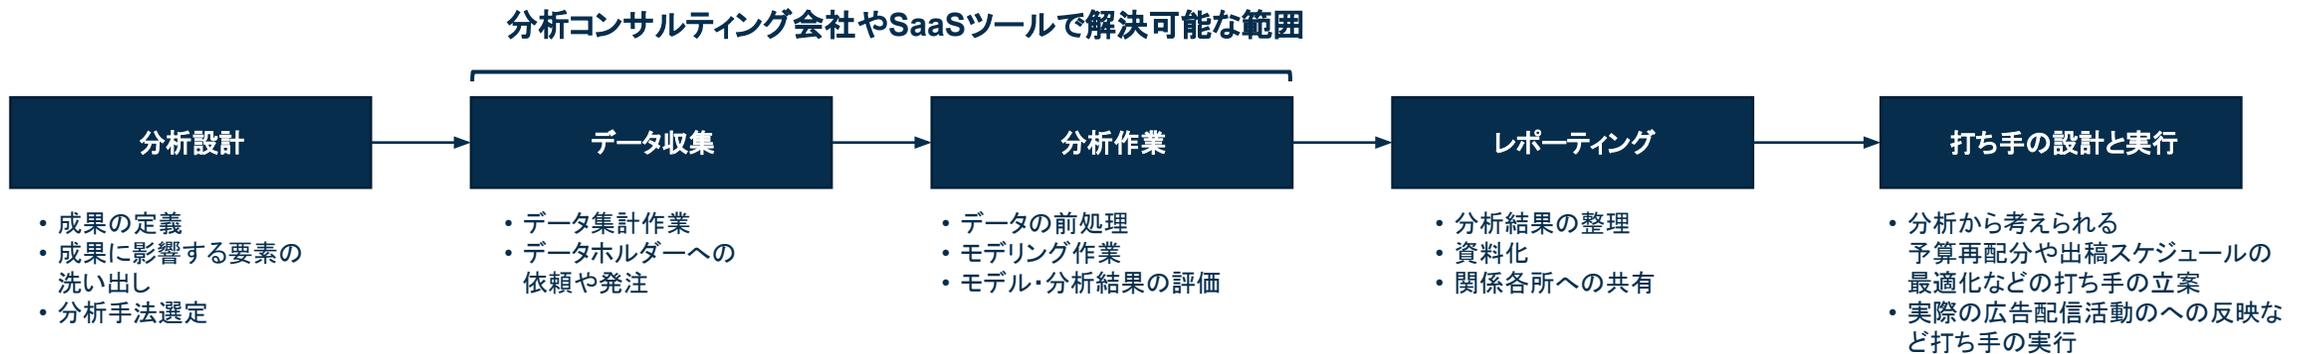
## 電通独自のデータソース

- 競合ブランド出稿量やTV番組のトピックデータなど電通独自のデータソースを使ってMMMを実行支援

## MMM導入と社内共有をサポート

MMMの導入時や分析専門のコンサルティング会社やSaaSで提供されているMMMツールでは、散在したデータを集約・統合し分析する作業のみの部分的な解決となるケースが多い。一方で広告主に常に伴走するdentsuでは、分析設計やレポートニング・アクションプランの提示まで一気通貫でのご支援を提供可能。

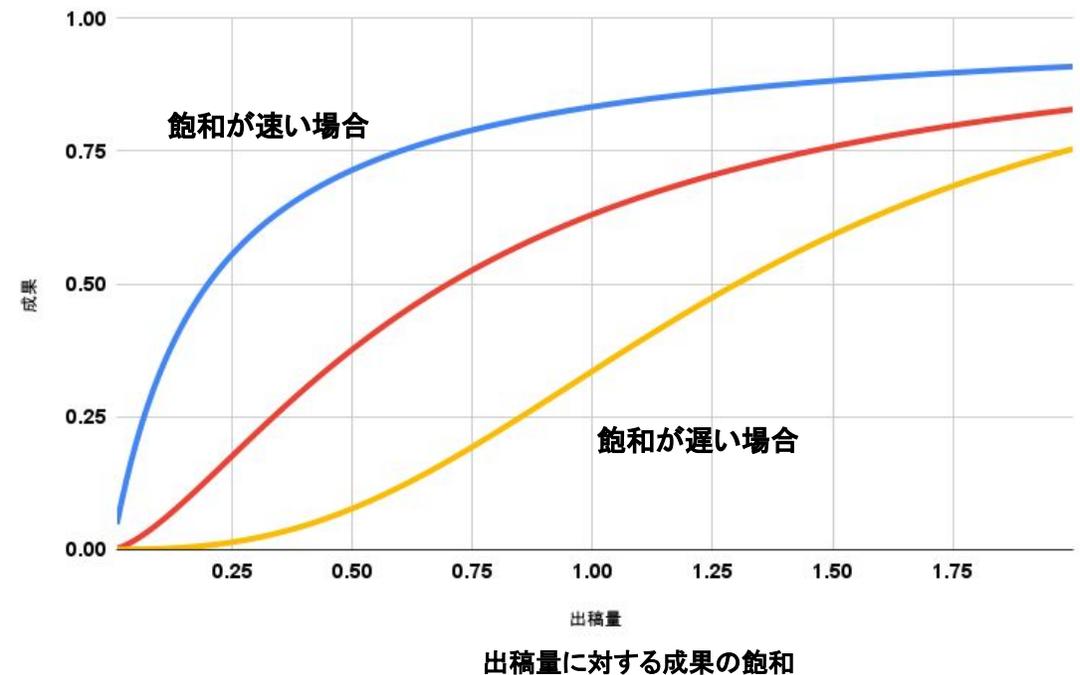
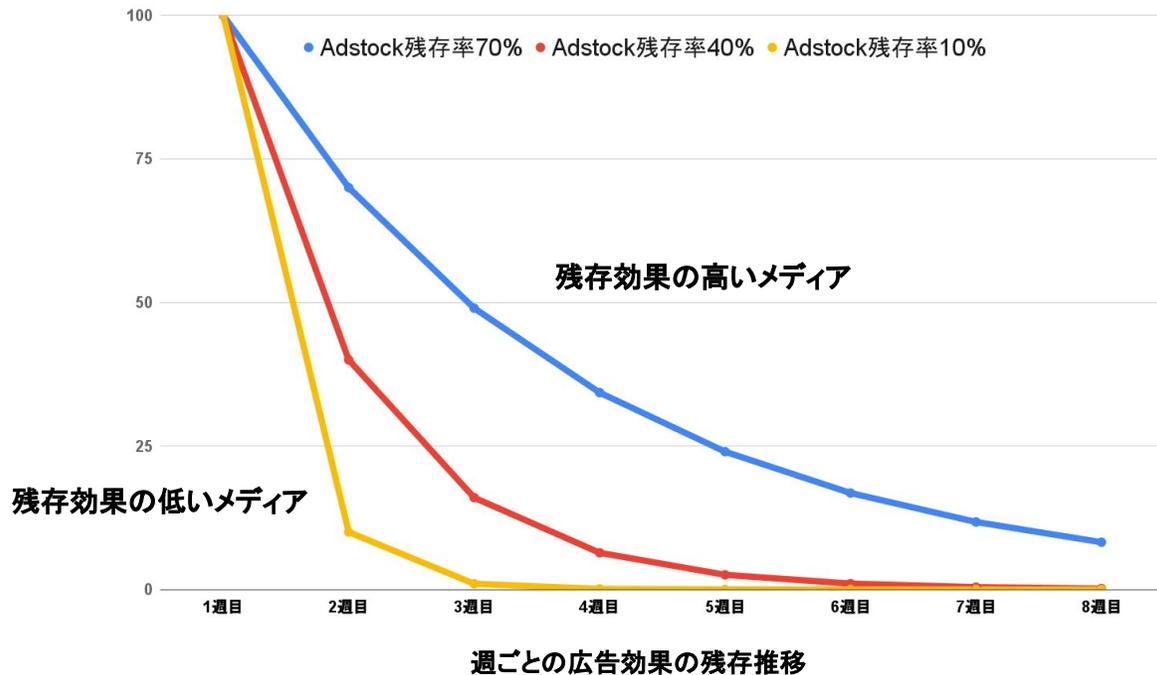
広告の成果や投資対効果に関する課題をヒアリングしアドストックや飽和水準など専門的な概念の解説も含めて、分析結果の取りまとめ・社内関係各所へのレポートニングをご支援できる。



dentsuでのご支援可能な範囲

## 広告代理店として広告媒体や対象商材の特性に合ったモデリングを実施

MMMをモデリングする際には、広告媒体の特性や対象ブランドの特性をモデル構造や仮定条件に反映させることが重要になる。例えば、TVCMとWebのバナー広告では人々の記憶への残存率や出稿量に対する効果の伸び方などが異なると考えられる。広告代理店としてのこれまでの経験値を元にそのような各広告媒体ごとの特徴の違いを分析し、残存効果や反応関数を適切に設定するなどの形でMMMに組み込んでいる。



## 様々な業界でのMMMの知見を基にしたモデリングを実施可能

電通では下記の各業界の複数の広告主でMMMの実施事例があり、それぞれブランドによって必要な変数やモデリング上考慮すべき点が異なることなど重要な知見を蓄積している。  
また、これらの事例を基にして、MMMの分析設計からアクションまでの効率的なプロジェクトの進行プロセスを理解している。

### 電通で過去にMMM実施のある広告主の業界

薬品系事業

自動車製造業

金融・保険事業

家電事業

通信事業

化粧品・トイレタリー系事業

食品・飲料系事業



- 業界ごとに必要な変数や考慮すべき点などの知見の蓄積
- 分析プロジェクトの効率的な進行プロセスを体系化

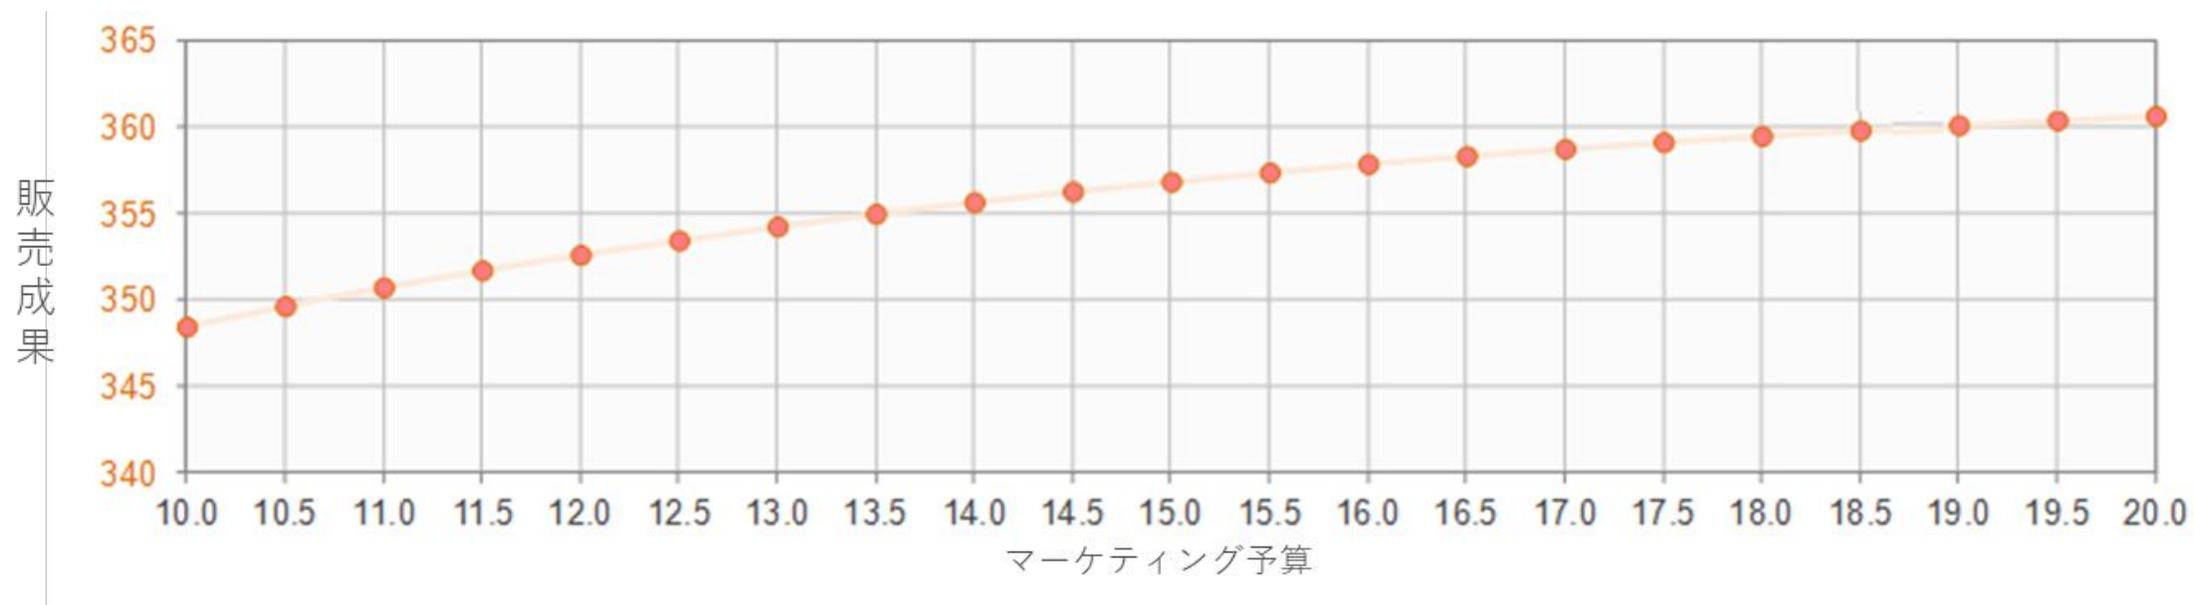
## 統合的で現実的な戦略立案をサポート

MMMではモデリングと現状の広告施策の評価にとどまらず、次の打ち手につなげることが重要となる。MMMで作成したモデルを活用すると下記に示すように売上やメディアの予算配分・出稿スケジュールに関する示唆を得ることができプランニングの改善の打ち手となる。その際に、机上のシミュレーションではなく、各メディアの出稿ポテンシャルを考慮した制約条件を組み込んだシミュレーションを通して、現実的で実行可能なアクションを立案する。

- **販売成果シミュレーション**
  - 広告投資によってどれだけの販売成果が発生するかのシミュレーション
- **メディア予算配分**
  - メディア予算配分の改善案の算出と、それによってどれだけの成果が改善するかのシミュレーション
- **ブランド間予算配分**
  - 複数のブランドに対してそれぞれのブランドごとにモデリングをおこなうことで、ブランド間の予算配分の改善案を算出
- **広告出稿スケジュール**
  - 分析した売上反応曲線に基づいて広告効率が高い状態を維持できる広告出稿スケジュールを導出することで成果を改善

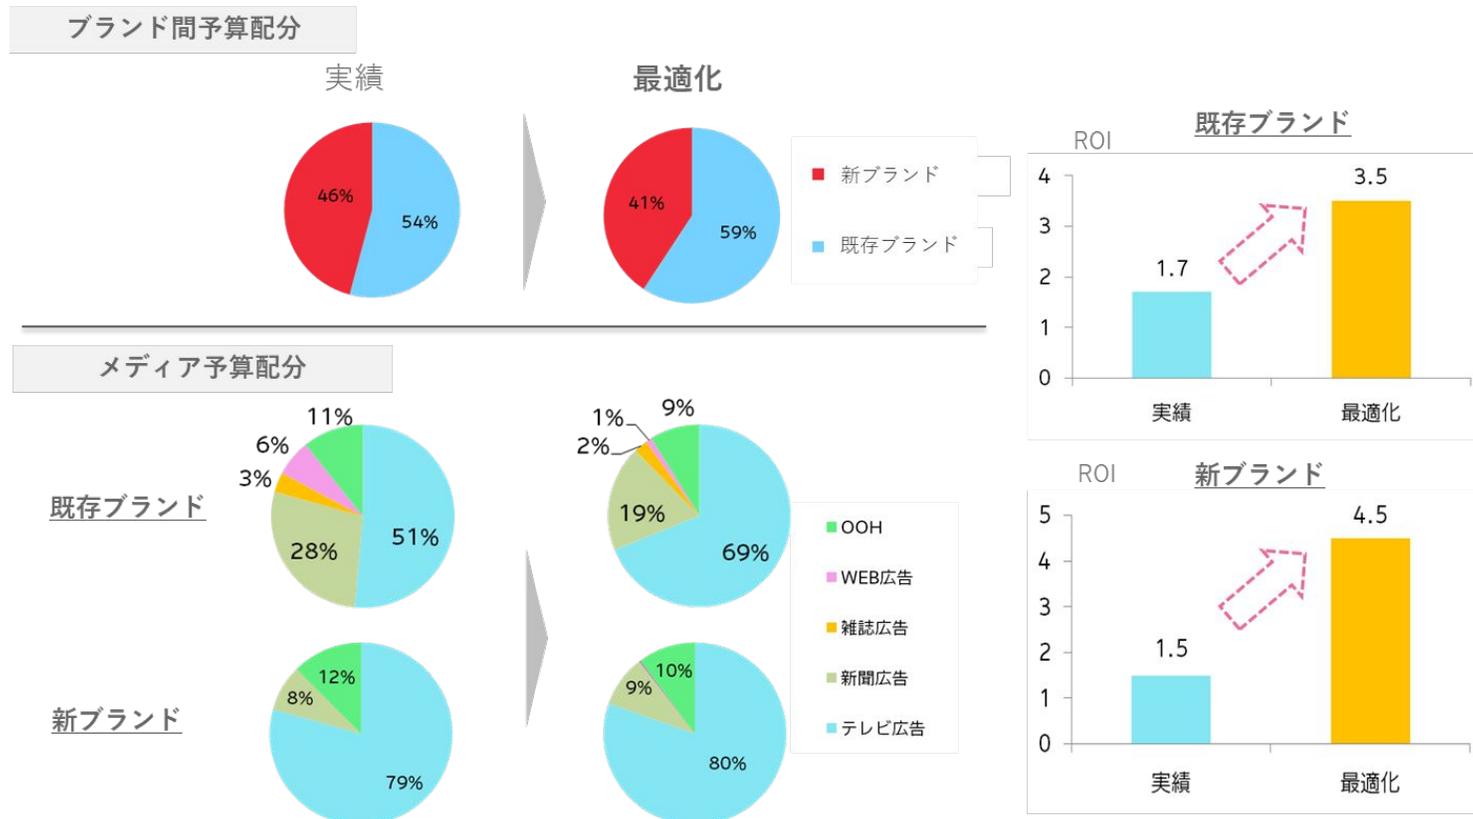
## 統合的で現実的な戦略立案をサポート

販売成果のシミュレーションのアウトプットイメージは下記の通り。  
マーケティング予算をどの程度投入すると、どのくらいの販売成果が発生するかをシミュレーションできるようになり、  
事業目標の策定や全体のマーケティング予算の試算などに活用できる。



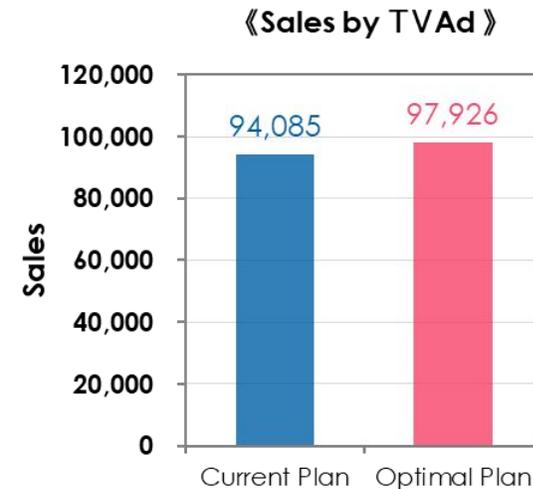
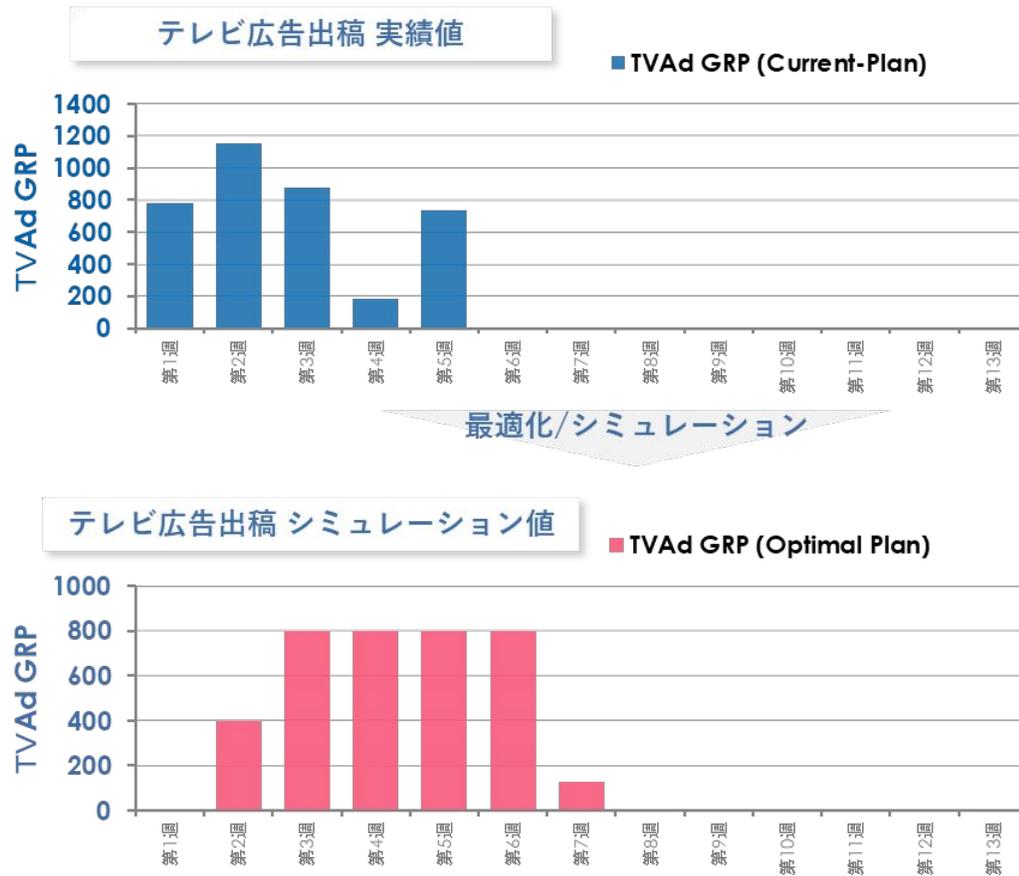
# 統合的で現実的な戦略立案をサポート

メディア予算配分・ブランド間予算配分最適化のアウトプットイメージは下記の通り。  
 メディア予算配分・ブランド間予算配分の最適化案を得ることにより、複数のブランドのROIがどのように変化するかシミュレーションすることができ、実際の予算配分変更というアクションにつなげられる。



## 統合的で現実的な戦略立案をサポート

広告出稿スケジュール最適化のアウトプットイメージは下記の通り。  
 売上反応曲線の傾きが急になっている、すなわち広告効率の良い範囲に広告出稿の水準を維持するように、  
 出稿スケジュールを調整することにより、同じ広告予算で成果の増分が期待できる。

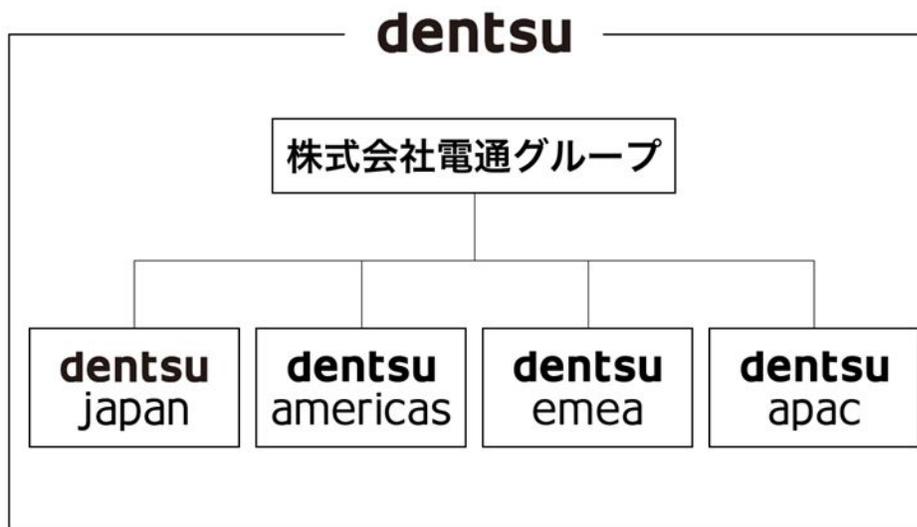


## グローバルなブランドでのMMM実行力

電通はグローバルに企業ネットワークを持っており、国境を越えてビジネスをしてきた実績がある。グローバルに展開するブランドでMMMを実施する際にはそれぞれの地域にネットワークを持っていることはプラスになる。地域ごとにそこでどのメディアがどの程度影響力を持っているのかといった知見や、各地域で収集・保有しているデータを利用可能なことに加え、同じ基準で各地域ごとにMMMの分析ができるためである。また、Data2Decision(D2D)というマーケティングコンサルティング専門会社をグループに抱えており、MMMを中心に最先端のソリューションを開発、ロンドンに本社を構え、欧州を中心にニューヨーク、シンガポールなどグローバルに展開・拡大している。



Data2Decision(D2D)のグローバルネットワーク



dentsuはアメリカ、EMEA、APAC  
を中心にグローバルにネットワークを持っている

## 電通独自のデータソース

電通ではDAS(電通広告統計)やSTADIA(TV視聴ログデータ)などMMMに有用な独自のデータを保有している。DASではTV、ラジオ、雑誌、新聞、交通広告、インターネット広告の広告主別の出稿量を集計することができ競合ブランドの広告活動の影響を加味してモデリングすることが可能になる。競合ブランドの広告の影響は競合効果と呼ばれ自社ブランドの販売成果にプラスにはたらくこともマイナスにはたらくこともある。

STADIAではTV番組内で特集されたブランドが記録されたデータを保有しており、TV番組内特集の影響を加味したモデリングが可能になる。TV番組内で特集されたブランドを認知することで想起順位の上昇や検索行動に繋がり販売成果にプラスに影響すると考えられる。

### 競合広告効果

#### プラスにはたらく場合

競合ブランドの広告により競合ブランドに顧客を奪われてしまい自社ブランドの販売成果にマイナスに影響する。

#### マイナスにはたらく場合

成長中の分野では、競合ブランドの広告によりその分野の認知率が高まり、結果的に自社ブランドの販売成果にプラスに影響することもある。

### TV番組内特集の影響



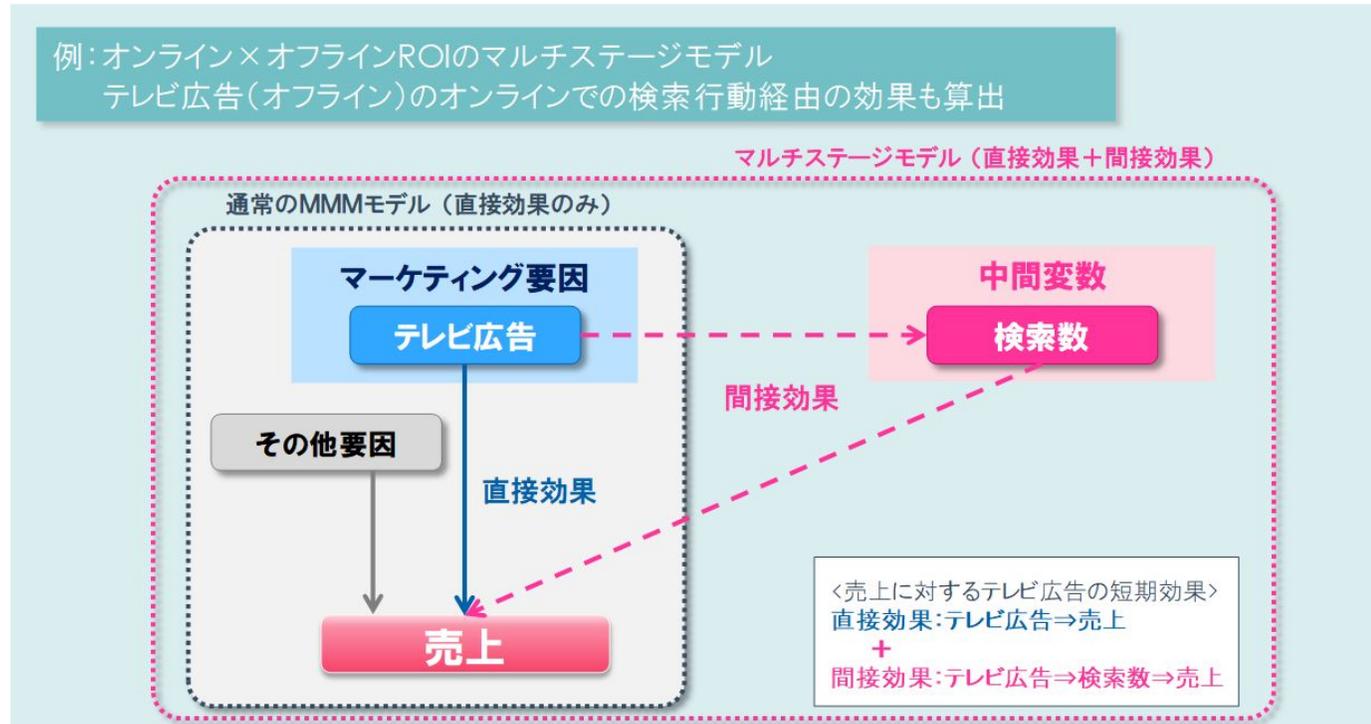
検索行動・想起順位の上昇

# 電通のMMMケイパビリティ | マルチステージモデル

## マルチステージモデル:

マルチステージモデルは、各マーケティング活動が検索数、HPアクセス数やブランド指標などの中間指標として目的変数の予測までに多階層なモデルを作成する。

特にオンライン商材などで検索広告を配信している場合は、TVCMやインターネットの動画広告などブランドの認知度を高める目的の広告が、販売成果に直接的に影響する検索広告の配信量に対して与える影響をマルチステージにモデリングすることで、各広告の貢献度をより精緻に評価できると考えられる。

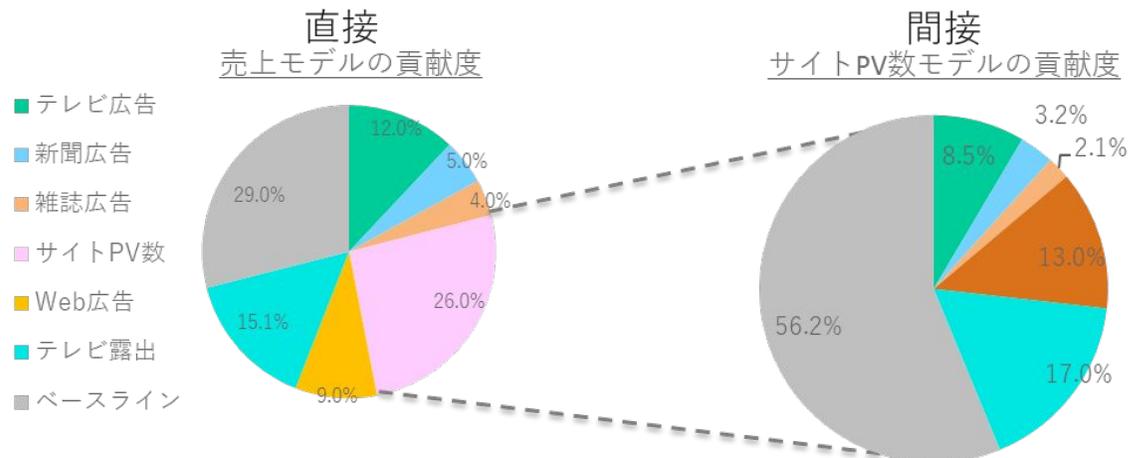


# 電通のMMMケイパビリティ | マルチステージモデル

広告などが売上に直接的に与える影響(直接効果)だけでなく、Web行動(サイトPV数や検索数)を經由して間接的に売上に与える影響(間接効果)も分析が可能。

売上貢献度

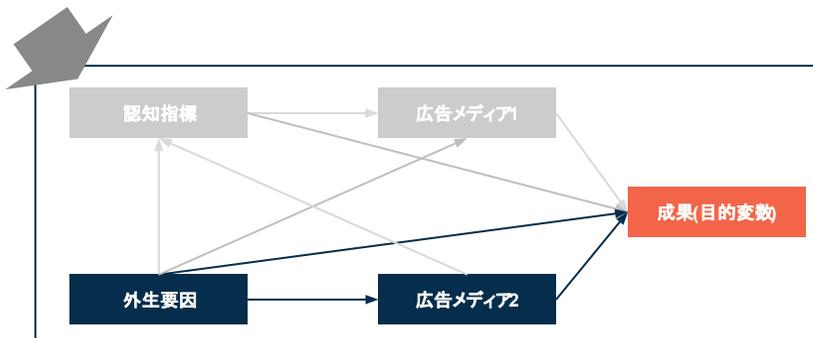
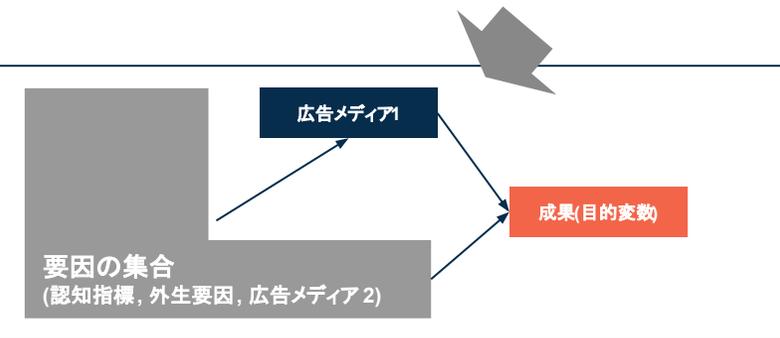
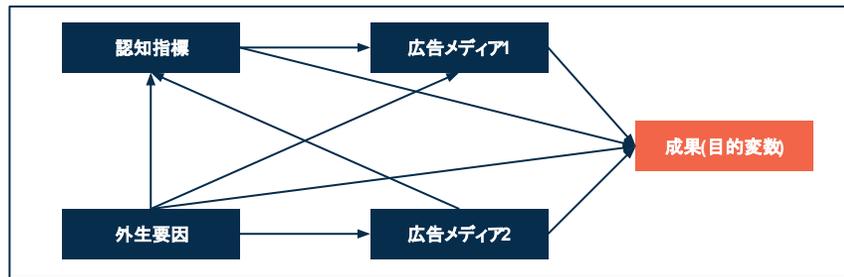
ROI



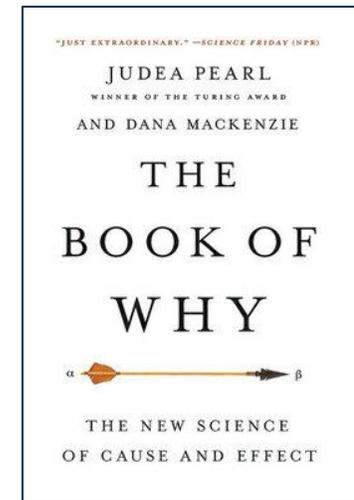
# 電通のMMMケイパビリティ | マルチステージモデル

マルチステージモデルの発展系として、Judea Pearl氏が提唱する構造的因果モデルの概念を導入し、交絡因子となる変数を特定して調整条件付けや層別化することによって交絡因子の影響を排除するようなロジックを組み込むことについても研究を進めている。それぞれの段階のモデルでどのような変数を調整すべきかを構造的因果モデルの理論の中で提唱されるバックドア基準やフロントドア基準などを基に選定してモデリングすることで成果の要因となる変数(広告)の影響度をより精緻に推定することができると考えられている。具体的かつ断定的な手法はまだ確立されていないが、下記の例のように変数の調整基準にしたがって因果ダイアグラムを分解して分析する形も考えられる。

従来のマルチステージモデルでは全体の因果ダイアグラムに忠実に  
変数を組み込んで多段階のモデルを作成



構造的因果モデルの変数の調整基準を満たすように  
因果ダイアグラムを分解してモデルを検討する



The Book of Why: The New Science of Cause and Effect/BASIC BOOKS - Judea Pearl

# 卷末

## 執筆者

本資料は株式会社電通デジタル ソリューション戦略部と Google Japan 協力のもと作成したものである。

- CHAPTER 2は **Google シニアマーケティングリサーチマネージャー 中原啓智** が執筆したものである。
- CHAPTER 1及びCHAPTER 3の内容は **電通デジタル ソリューション戦略部 データサイエンティスト 吉田秀穂** が分析上のモデル構造の作成やモデルの検証プロセスなどについて Google 中原の協力を受けながら執筆したものである。
- CHAPTER 4は**電通デジタル ソリューション戦略部 データサイエンティスト 吉田秀穂** が執筆したものである。

Google レビュー協力者 (CHAPTER 2)

Head of Analytics, APAC CMI

Senior Marketing Research Manager, APAC CMI

Rohan Gifford

Minh Nguyen