

「もう何となく割引シールを貼るのはやめよう！」
データから顧客の購買行動や社会の変化を捉え、AI技術を活用して
値引き・発注量・配送ルート最適化、過剰在庫やフードロスの削減を実現

株式会社NTTデータ数理システム

シミュレーション&マイニング部

数理ソリューション部

本セミナーについて

本日のトピック

0.当社のご紹介

1.小売業を取り巻く状況と現場課題

2.アプローチ (Predict then Optimize)

3.具体事例紹介


4.AIを活用したDXの進め方

5.DXを進めるにあたっての「よくある間違い集」

6.まとめ

**小売業の基礎知識と
ビジネスに活用するためのコツについて、
当社事例を交えてお伝えします。**

0. 当社のご紹介



会社概要

会社名	株式会社NTTデータ数理システム
所在地	東京都新宿区信濃町35 信濃町煉瓦館1階
資本金	5,600万円 (NTTデータ100%出資)
従業員数	約120名 (内80%が技術者)

沿革

1982年4月 株式会社 数理システム 設立

2012年2月 NTTデータグループ入り

2013年9月 株式会社NTTデータ数理システム に社名変更

ミッション

数理科学とコンピュータサイエンスにより
社会のあらゆる分野の問題を解決する



NTTデータ数理システムの事業と強み

数理学とコンピューターサイエンスを価値の中心に据え、4事業を展開

パッケージソフトウェアの自社開発

受託への適用・業務組込み活用

受託開発

高度分析技術の蓄積・統合

相互連携

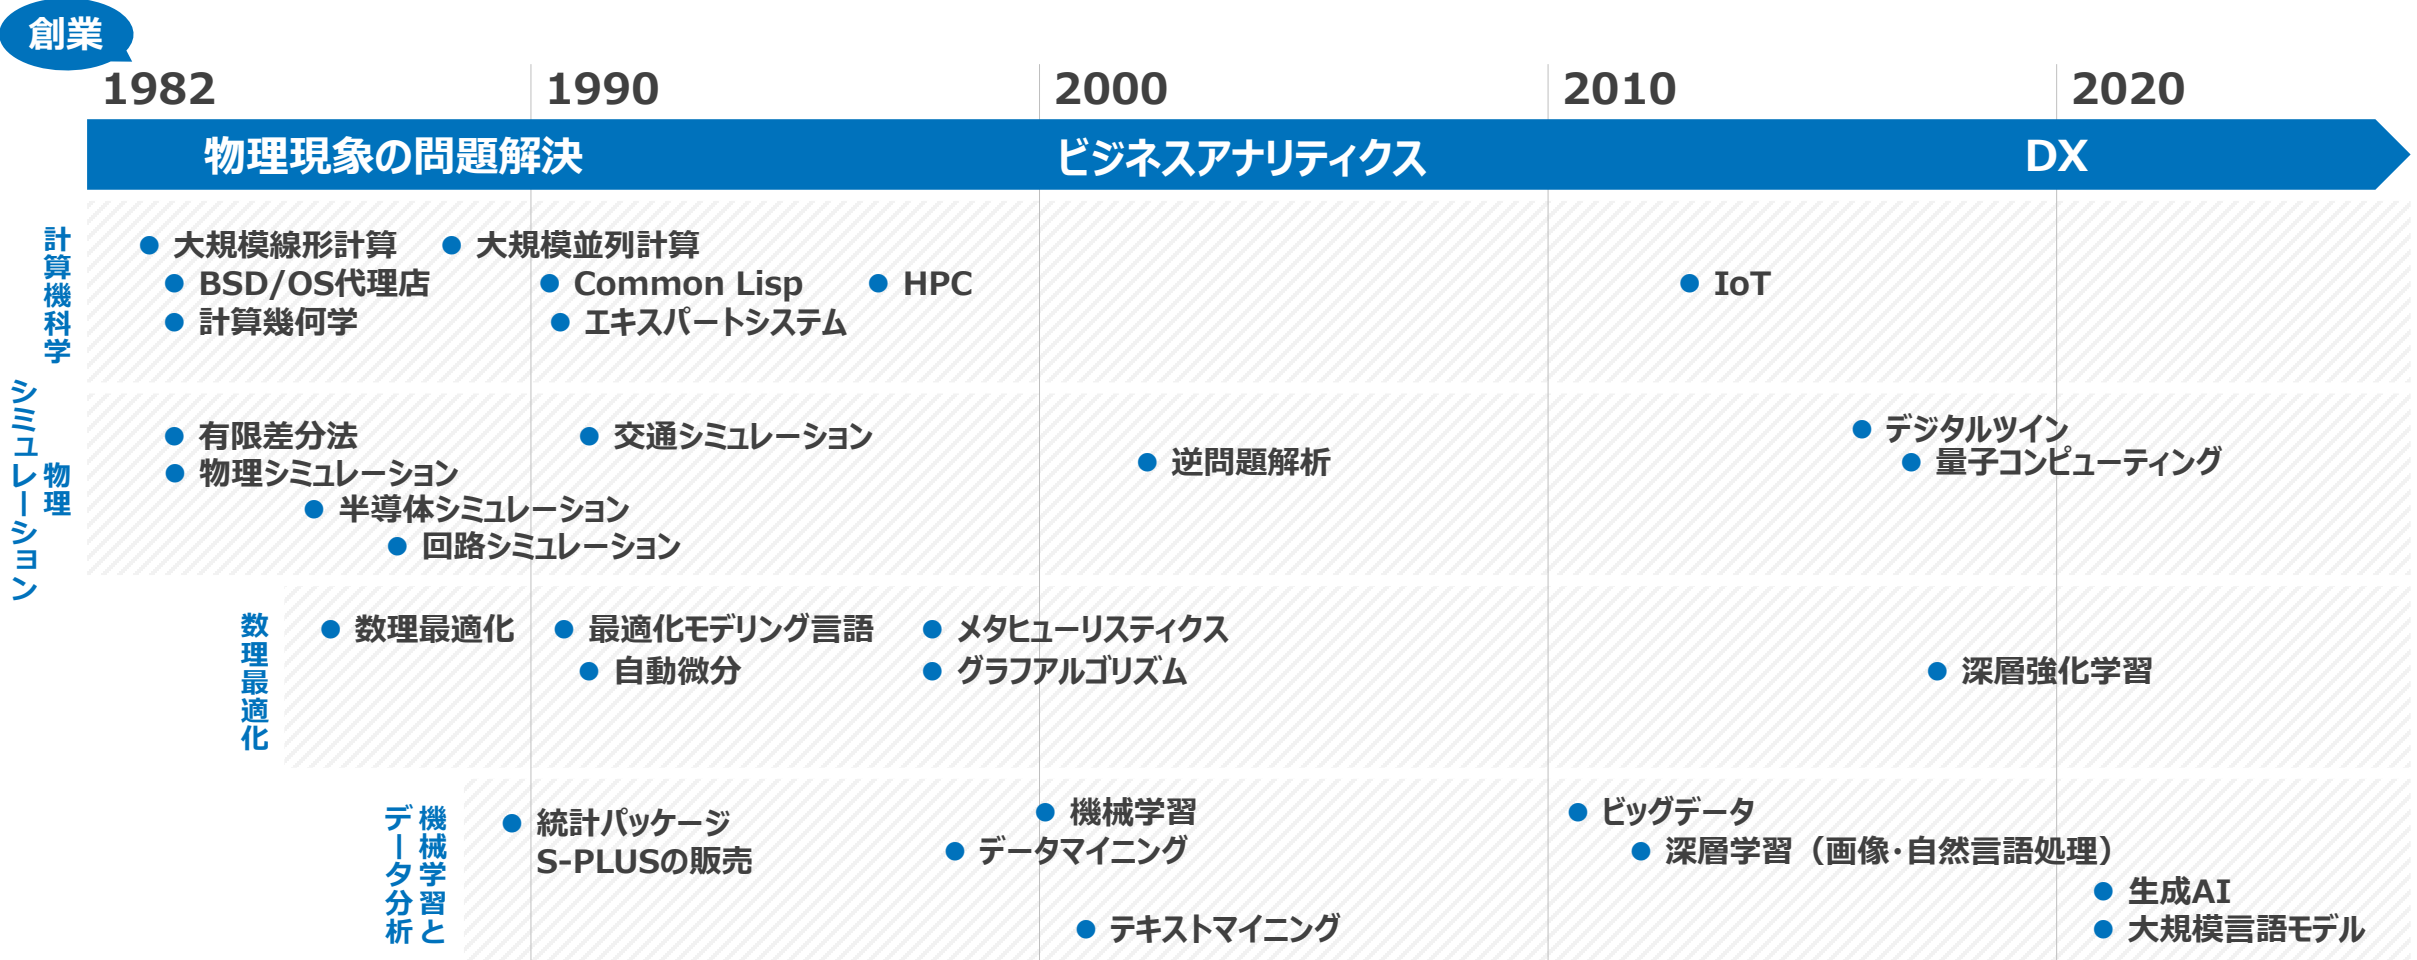
分析コンサルティング

データサイエンス教育

- ・ 導入実績8,000社以上—数理学のプロ集団としての豊富な経験・取引実績
- ・ 自社開発・自社サポートによる柔軟なサービス
- ・ NTTデータやそのグループ会社との事業連携による包括的なサービス提供
- ・ 戦略・技術的なデータ分析コンサルティング、データサイエンス教育による伴走型サポート

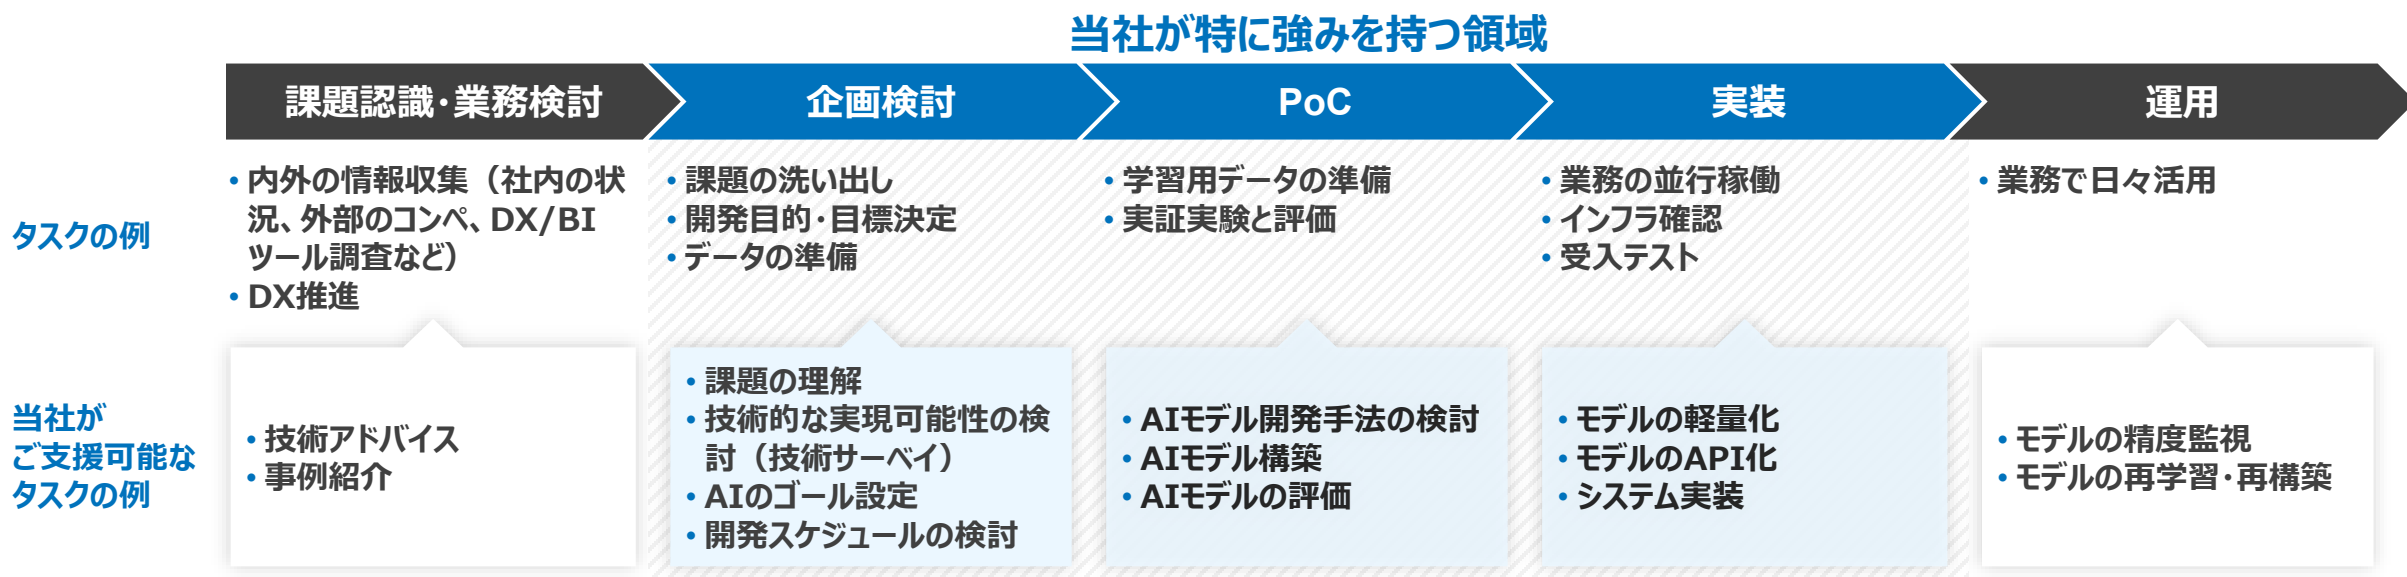
NTTデータ数理システムのもつ技術の歩み

われわれは1982年の創業以来40年以上にわたり、
業務とビジネスの最前線を、数理科学とコンピュータサイエンスでご支援してまいりました




NTTデータ数理システムによる課題解決のご支援イメージ

数理学とコンピュータサイエンスによるビジネス・業務課題の解決を、幅広いフェーズでご支援
当社の保有する幅広い基礎技術を、様々な形式でご提供いたします



当社がコアロジック部分を実装し、スクリプト、実行ライブラリ・モジュール、GUIを伴うアプリケーションとしてご提供したり、お客様のシステム部門（子会社）やグループ会社のSIerと連携してシステム組み込みを進めることも多くあります。

1. 小売業を取り巻く状況と現場課題



小売業とは

メーカーや卸業者から仕入れた商品を最終的に消費者の手に届ける役割を担う。



小売業が直面する問題

様々な社会的な変化に伴って、小売業は現在、様々な課題に直面している。



小売業の環境を変化させる3つの要因

特に「**人手不足**」「**物価高騰**」「**多様化**」の3つが、小売業を取り巻く環境を大きく変化させている。

人手不足	<ul style="list-style-type: none">• 発注・品出し等の業務の担当者不足• 物流2024年問題(配送の担い手の減少)
物価高騰	<ul style="list-style-type: none">• 原材料の高騰に伴う価格転嫁・賃金の上昇• 燃油高騰による物流コストの上昇
多様化	<ul style="list-style-type: none">• Qコマース等新しい購買の形・都市部と地域での傾向変化• 消費者のデジタル化による宅配ニーズの増加

✓ これらの外的要因は避けることはできない。→ 我々の変化への対応が求められる。

現場で引き続き行われている、「なんとなく」の運用

このような状況で、人の**勘・経験・度胸(KKD)**に頼った「なんとなく」の運用が続けられている。

ex) スーパーマーケットでの、「なんとなく」の値下げシール貼り



(なんとなく)10%のシールを貼っておくか。

#	キーワード	課題詳細
課題1	人手不足	<ul style="list-style-type: none">一部の熟練者への属人化 (再現性の確保が困難)一人当たり対象商品の増加への対応
課題2	物価高騰	<ul style="list-style-type: none">商品の原価の変化への対応顧客の金銭感覚の変化
課題3	多様化	<ul style="list-style-type: none">地域(店舗)によって異なる購買傾向 (うまいく店といかない店がある)

✓ もし仮に現在はうまくいっているとしても、**将来の変化に対応できる保証はない。**
社会変化の大きい時代では**大きなリスクを抱えることになる。**

今、小売業で何が求められているか？

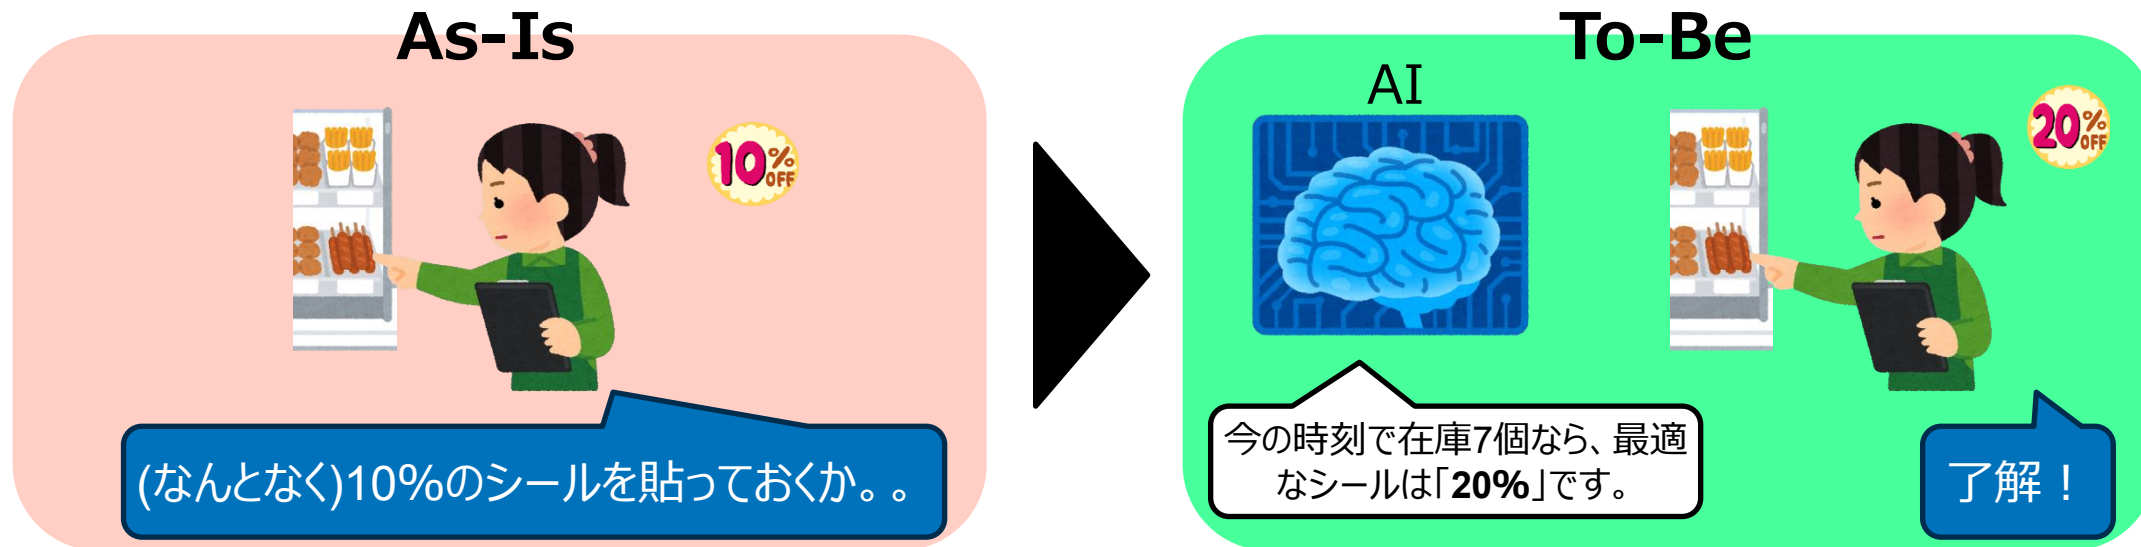
「目的の追求」「自動化・標準化」を目的とした、**AIを活用したDX推進**が求められている。

トピック	As-Is	To-Be
目的の追求	物価高騰などにより、今までのやり方だと今まで通りの目的(ex. 利益の最大化など)が達成しづらい	目的の達成のための 最適な施策 を構築することが必要
	社会の状況は都度変化(不確実)	社会が変化しても、その 変化に適応して施策を簡単に改善する 仕組み
自動化・標準化	人手不足 が進む中、「人に任せる運用」には限界がある	人手が少なくても回る仕組み
	商品や地域の 多様化 により「一部の店・一部の担当者」でしかうまくいかない状況	柔軟なスケーラビリティ (一度できたものを、別の商品・お店への横展開したい)

これはすべて、「AIを活用したDX推進」により実現できる


本日のゴール：「なんとなく」の運用からの脱却と、AIを活用したDXの実現

- 人手不足・物価高騰・多様化など、小売業は大きな構造変化の時代に直面
- 従来の「勘・経験・度胸」に頼る運用では、これらの課題を乗り越えるのに限界がある
- 本セミナーでは、**現場に即した“使える意思決定”**を実現するための**考え方・事例・進め方**をご紹介します



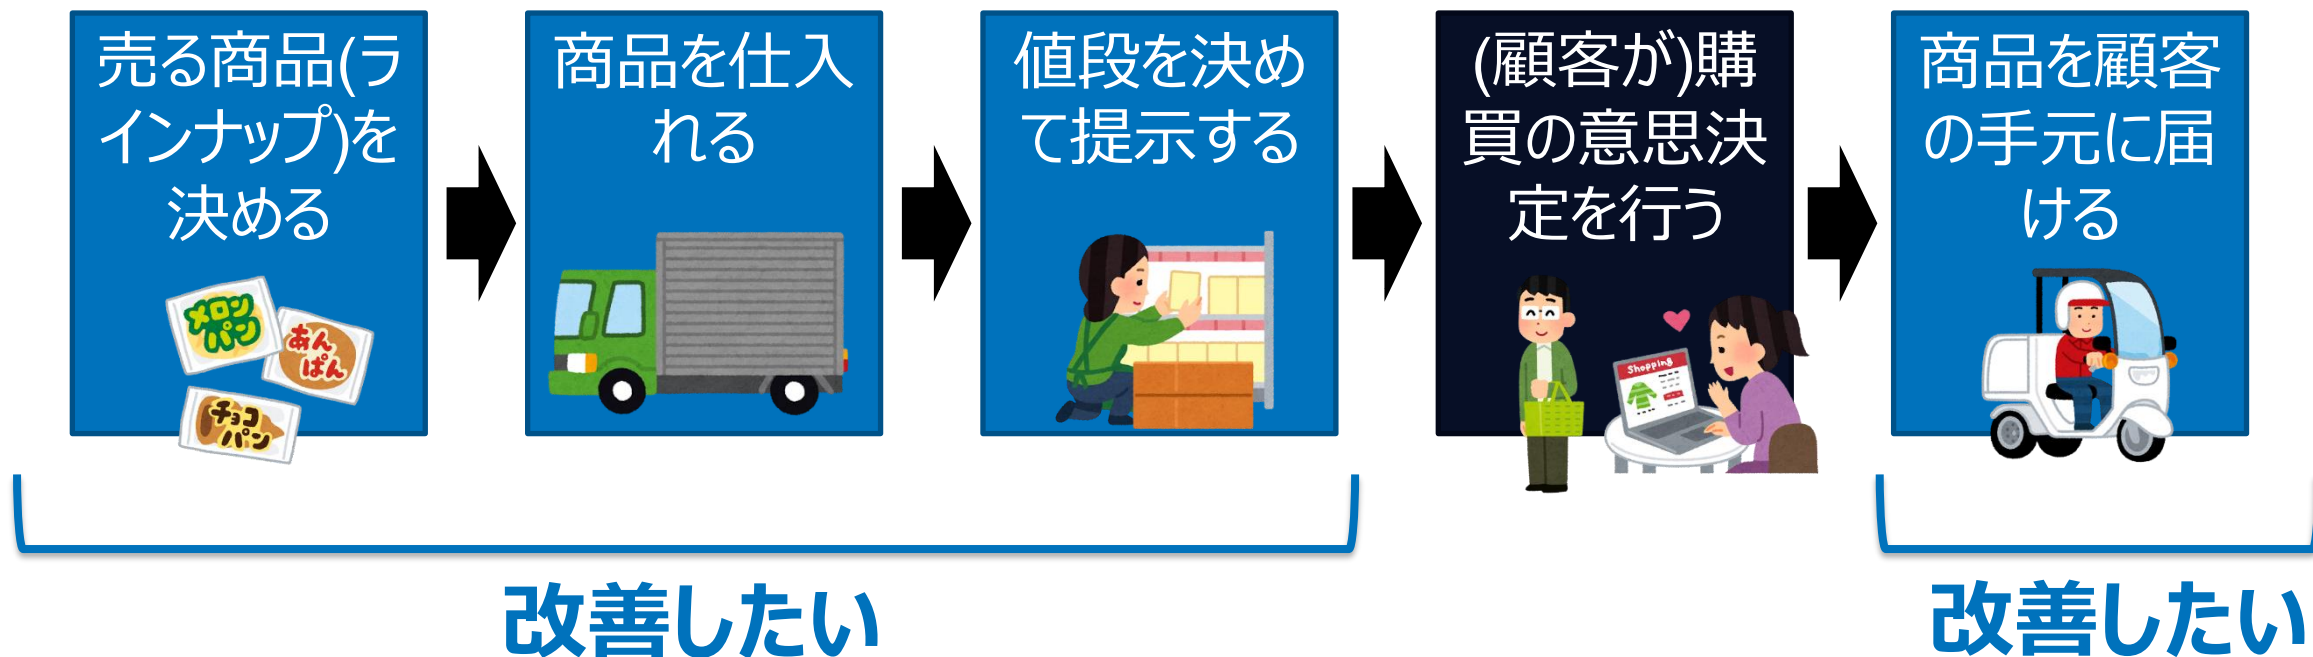
単なる技術紹介ではなく、「どうやって現場で使えるか」までを一緒に考える場です。

2. アプローチ (Predict then Optimize)



小売業の典型的な業務フロー

顧客の購買の意思決定の前後に、**小売業にとって改善したい**
様々な業務がある。



どうすれば改善することができるか？

一緒に考えてみましょう: 最適な仕入れ個数を決定する問題

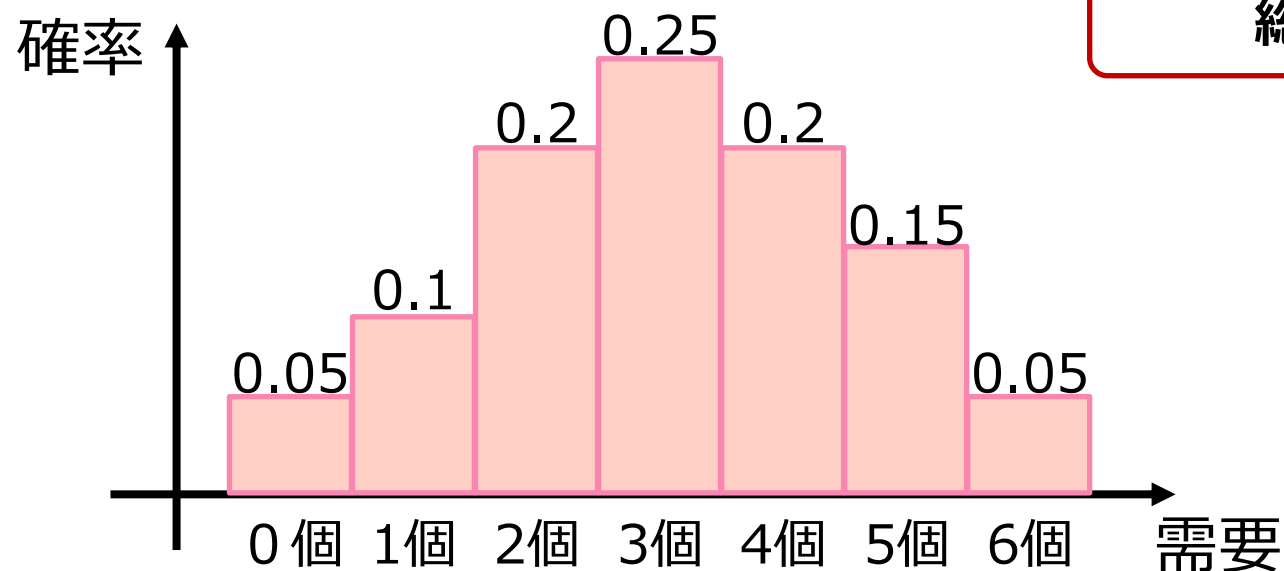


あなたは小売店を運営していて、商品「おにぎり」を販売しています。
消費期限は1日で、その日のうちに売れなかったものは廃棄することになります。

- 商品の仕入れ値 ... 1個あたり70円
- 商品の売り値 ... 1個あたり100円

で、おにぎりの需要が以下の時、**総利益**の期待値を最大にする**最適な仕入れ個数**は？

【需要の確率分布】



$$\text{総利益} = \text{総売上額} - \text{総仕入れ額}$$

例えば...

仕入れ 個数	需要	売れた 個数	総利益
3個	2個	2個	200-210=-10円
3個	4個	3個	300-210=90円
6個	4個	4個	400-420=-20円

売上

一緒に考えてみましょう: 最適な仕入れ個数を決定する問題


正解は....

一緒に考えてみましょう: 最適な仕入れ個数を決定する問題

正解は.... 2個

本問題はNewsvendor Problemと呼ばれており、数学的な解法が知られている

【問題おさらい】



- 商品の仕入れ値 ... 1個あたり70円
- 商品の売り値 ... 1個あたり100円

【解法】

x 個仕入れるときの、総利益の期待値 $g(x)$ は、

$$g(x) = \sum_{d=0}^6 p(d) 100 \min(d, x) - 70x$$

(ただし、 $p(d)$ は商品が d 個売れる確率)
この $g(x)$ を x について最大化する問題を解くと、
 $g(x)$ を最大にする $x = x^*$ は、

$$\sum_{d=0}^x p(d) \geq \frac{100 - 70}{100} = 0.3$$

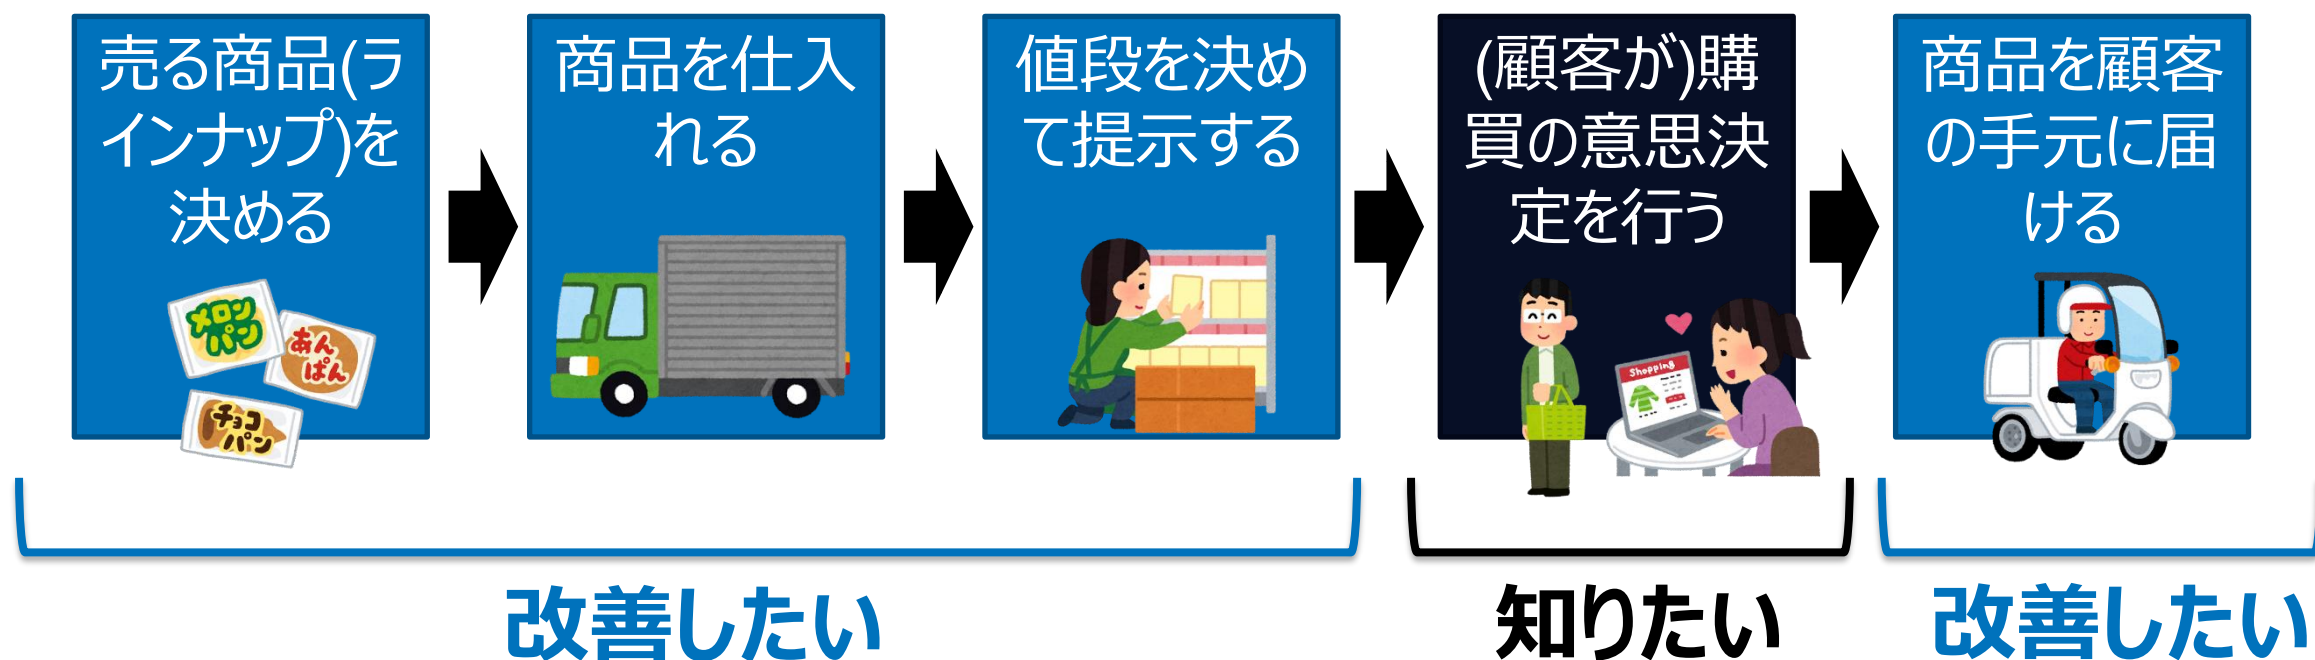
を満たす最小の x であることがわかるため、 $x^* = 2$ となる。

✓ 顧客の購買行動が(確率的にでも)分かれば、最適な仕入れ個数を決める問題を数学的に求めることができる！！

この問題から言えることは。。

業務変革の出発点は、顧客の行動を知ること。

顧客の行動を定量的に捉えられれば、施策の設計も最適化可能



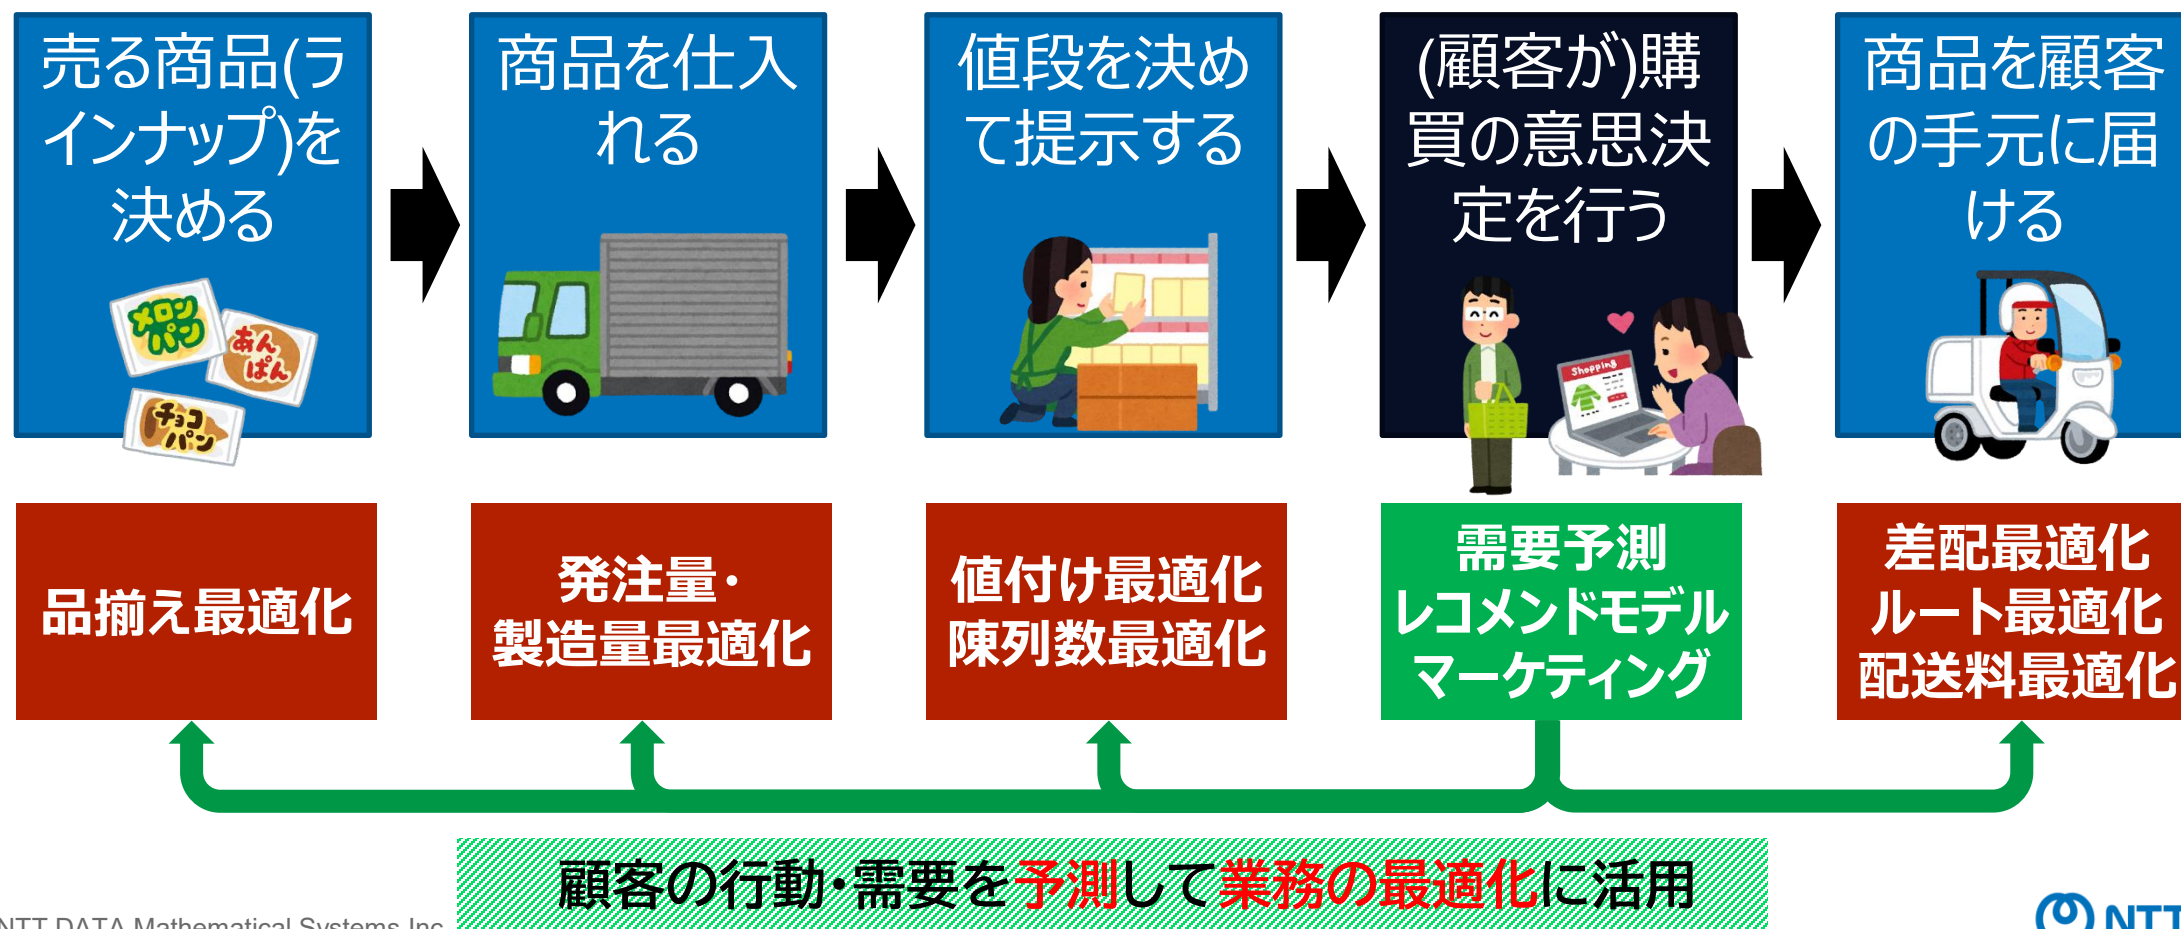
✓ 顧客の行動を知りたい、でも(このままだと)分からない。どうすれば良い？

行動予測から業務の最適化へ: “Predict then Optimize”

顧客の購買行動のモデリング(Predict)をして、

店舗の各業務の施策最適化(Optimize)に活用する枠組みが導き出される。

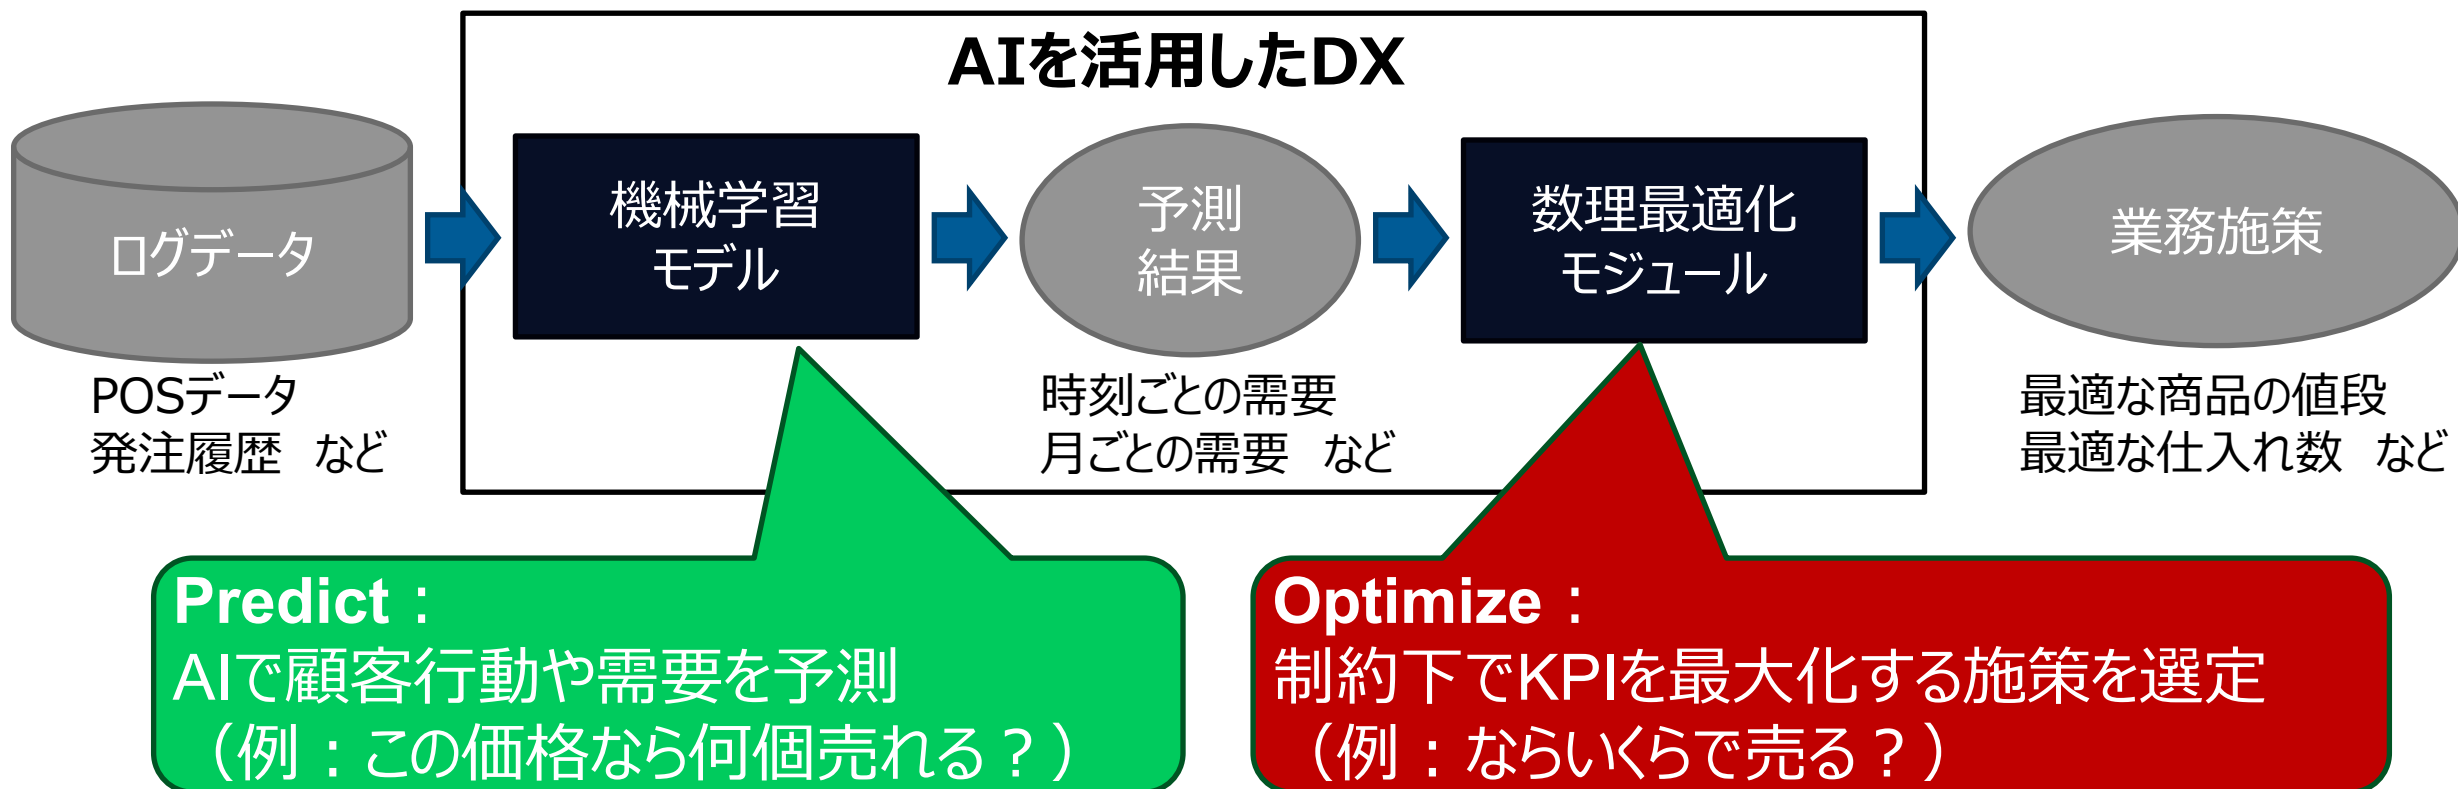
■ … 店舗
■ … 顧客



“Predict then Optimize” によるDXの実現

“Predict”と“Optimize”を接続することで業務の意思決定を進化させる

データから顧客の行動の不確実性を捉え、最適な施策の構築に活かす




✓ 2つを組み合わせることで、「データに基づく、成果に繋がる」DXが実現

具体的な適用例はさまざま

施策名	何をしたい?	何を予測(predict)?	どう最適化(optimize)?
発注量最適化	商品や在庫数に応じて最適な発注量を決定したい	顧客の商品に対する需要	(R, S) policy, 動的計画法
値下げ最適化	商品や時間帯に応じて最適な割引率を決定したい	顧客の商品に対する価格感応度	動的計画法
陳列数最適化	商品や時間帯に応じて最適な追加陳列数を決定したい	顧客の商品に対する需要	動的計画法
ドライバー待機場所最適化	ドライバーを適切な場所に待機させて配送時間を最小化したい	顧客の需要の時空間的な分布	整数計画ソルバー
配送料最適化	配送枠ごとの配送料をうまく決定することで、需要を平準化して利益を最大化したい	各配送枠での顧客の需要(配送料別)	乱数シミュレータ & 強化学習

3. 具体事例紹介



事例1: 発注量の最適化

発注

値付け

陳列


購買

配送

As-Is

- ・ 店舗を全国展開している小売業のお客様
- ・ (店、商品)別に需要予測を行って発注量を自動的に決定するシステムを運用
- ・ 需要予測値は、商品カテゴリ別に全(店、商品)で同じ季節性を仮定

【As-Isで仮定していた状況】




どのお店も季節性はほぼ同じだと思ったら...

課題

- ・ 実際には、同一の商品カテゴリでも**店や商品によって需要の季節性は異なる。**
→ **過剰発注による在庫過多・発注不足による品切れがともに発生**

【実際に発生していた状況】



店によって季節性が大きく異なっていた。。

事例1: 発注量の最適化

発注

値付け

陳列


購買

配送

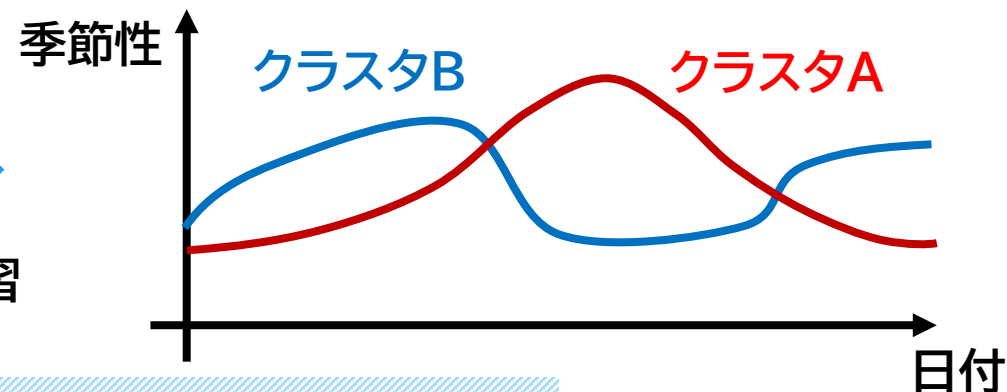
ソリューション

同一商品でも店舗によって異なる需要傾向を適切に捉えるため、季節性が似ている店舗同士を自動でクラスタリングしつつ各クラスタの需要の季節性を予測するモデルを構築

販売実績の時系列（店別）



需要の季節性（店クラスタ別）



モデル学習

時系列によって季節性が大きく異なる場合でも、時系列ごとの季節性の特徴を適切に抽出する予測モデルを構築。

結果

- ✓ 実店舗のPoCの結果、全店舗で数千万円規模の機会ロスを削減しつつ、保有する在庫数を従来よりも削減することができた

事例2: 値下げの最適化

発注

値付け

陳列

購買

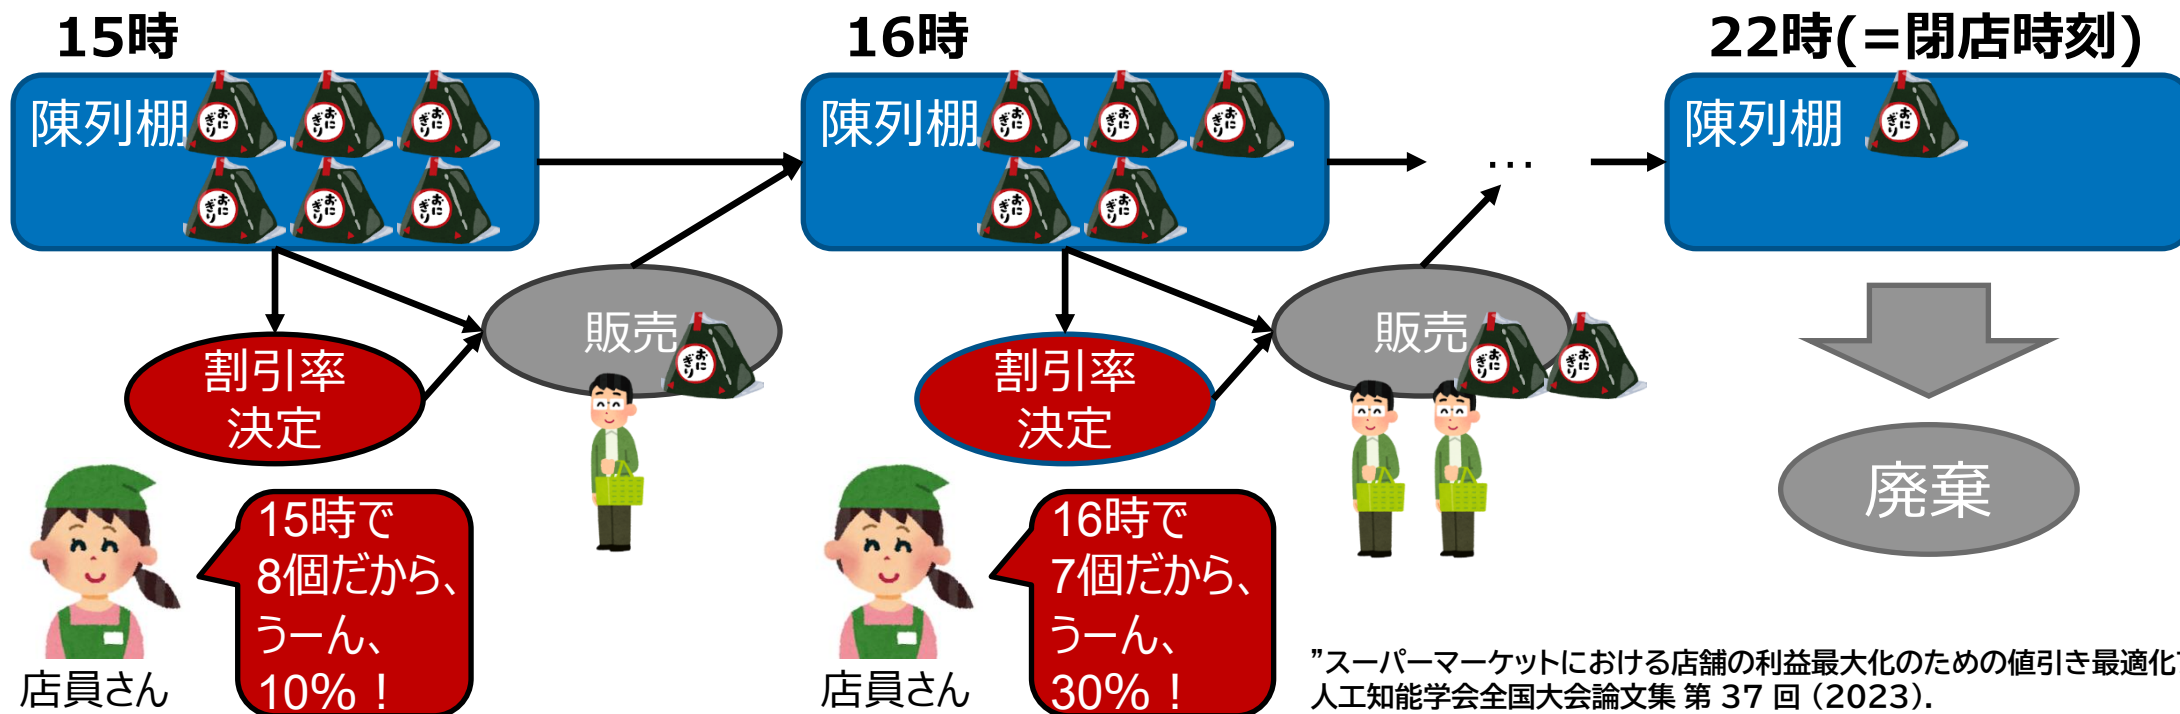
配送

As-Is

- ・ スーパーマーケットで惣菜などの多数商品を販売
- ・ 1時間おきに商品の在庫をチェックして、値下げシールを貼りなおす運用

課題

値下げの担当者によっては、**値下げのしすぎによる品切れ**や、**値下げを控えたことによる廃棄**を発生させてしまっている



”スーパーマーケットにおける店舗の利益最大化のための値引き最適化アルゴリズムの開発”
人工知能学会全国大会論文集 第 37 回 (2023).
○中村 暢佑¹、梅垣 優²、藤内 亮²、大坪 舜²、伊藤 孝太郎²、関口 智樹¹、石川 信行¹
(1. 株式会社セブン&アイ・ホールディングス、2. 株式会社NTTデータ数理システム)
https://doi.org/10.11517/pjsai.JSAI2023.0_2N5G

事例2: 値下げの最適化

発注

値付け

陳列


購買

配送

ソリューション

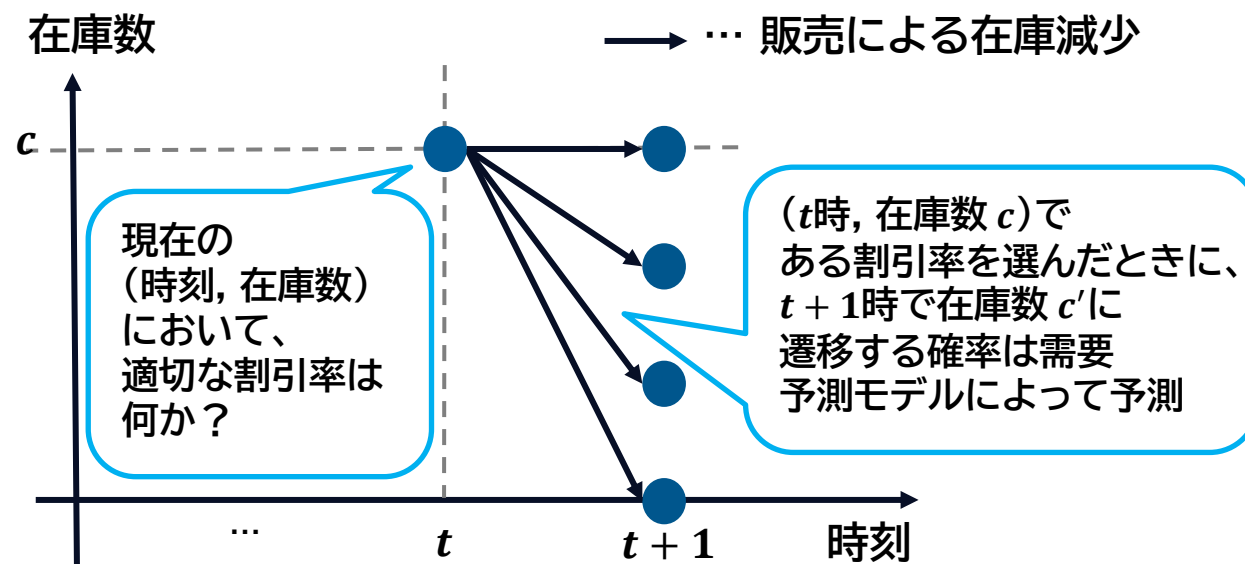
■需要予測モデル(Predict)

機械学習を用いて(商品、時間帯)ごとに価格変動に対する需要曲線のモデリングを行う



■数理最適化(Optimize)

推定された需要曲線を入力とする動的計画法を用いて、時間・在庫数ごとに商品の最適な金額を算出する



結果

- ✓ PoCの結果、従来の運用と比較し7%程度の値引きによるロスを改善
- ✓ 廃棄数はほぼ据え置きで定価の20%未満の値引き率で完売となる商品数が大幅に増加

”スーパーマーケットにおける店舗の利益最大化のための値引き最適化アルゴリズムの開発”
人工知能学会全国大会論文集 第37回(2023).

○中村 暢佑¹、梅垣 優²、藤内 亮²、大坪 舜²、伊藤 孝太郎²、関口 智樹¹、石川 信行¹
(1. 株式会社セブン&アイ・ホールディングス、2. 株式会社NTTデータ数理システム)

https://doi.org/10.11517/pjsai.JSAI2023.0_2N5GS1004

事例3: 製造量の最適化

発注

値付け

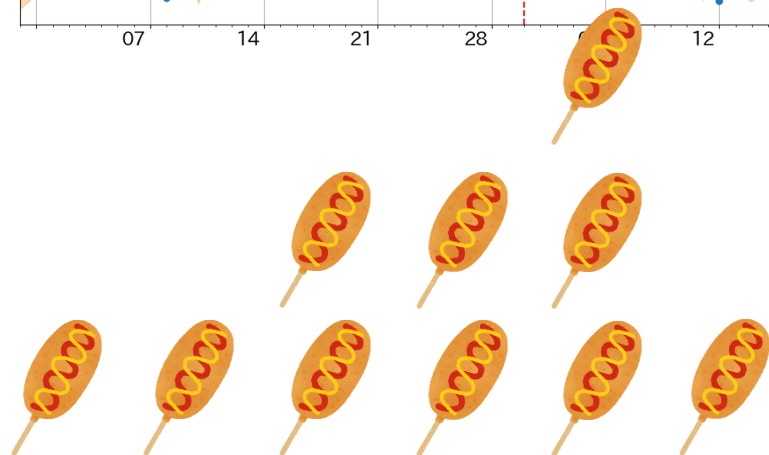

陳列

購買

配送

As-Is

- コンビニの店頭でホットスナック商品を販売
- 定期的に陳列棚の状況を確認して、必要に応じて商品を製造し陳列
- 数時間売れ残った商品は廃棄



課題

- 各時刻における製造数が店員の勘と経験に依存してしまっている
(作りすぎ:フードロス/作らなすぎ:品切れ)



“小売店舗のフードロス削減と収益向上に向けた離散時間陳列数最適化アルゴリズムの開発”

人工知能学会全国大会論文集 第 38 回 (2024).

○中村 暢佑¹、藤内 亮²、松下 亮祐²、梅垣 優²、関口 智樹¹

(1. 株式会社セブン&アイ・ホールディングス、2. 株式会社NTTデータ数理システム)


https://doi.org/10.11517/pjsai.JSAI2024.0_1F5GS1005

事例3: 製造量の最適化

ソリューション

■需要予測モデル(Predict)

機械学習を用いて(商品、単位時間)ごとの販売数の確率分布を推定する



結果

- ✓ PoCの結果、従来の運用と比較し、廃棄数の平均実績は 8.3%の削減、販売数の平均実績は 2.1%の増加を観測

発注

値付け

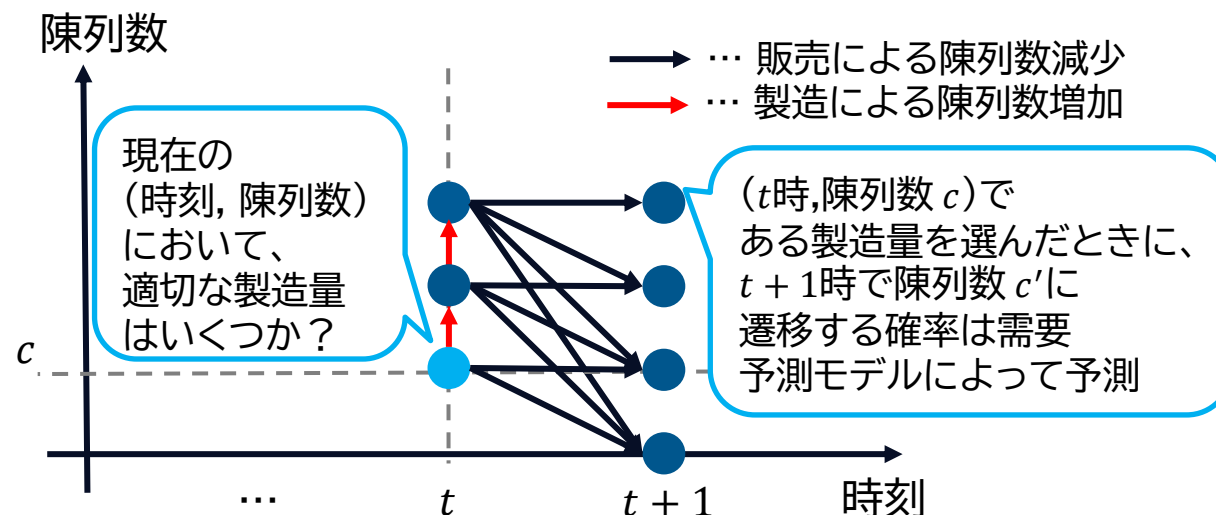
陳列

購買

配送

■数理最適化(Optimize)

推定された販売数の確率分布を入力とする
動的計画法を用いて、時間・陳列数ごとに商品の最適な製造数を算出する



“小売店舗のフードロス削減と収益向上に向けた離散時間陳列数最適化アルゴリズムの開発”
人工知能学会全国大会論文集 第 38 回 (2024).

○中村 暢佑¹、藤内 亮²、松下 亮祐²、梅垣 優²、関口 智樹¹

(1. 株式会社セブン&アイ・ホールディングス、2. 株式会社NTTデータ数理システム)

https://doi.org/10.11517/pjsai.JSAI2024.0_1F5GS1005

事例4: 生成AIによる消費者モデル化

As-Is

小売業において、商品を買っている消費者ひとりひとりの嗜好や思考を深く理解することは重要。
(消費者をうまくモデリングすれば、新商品企画やマーケティングに活用できる可能性)



課題

従来の方法では、ID-POSデータなどを用いて顧客の購買行動(=いつ何を買うか)をモデリングするのが限度。リアルな顧客像を十分表現することは難しい。

発注

値付け

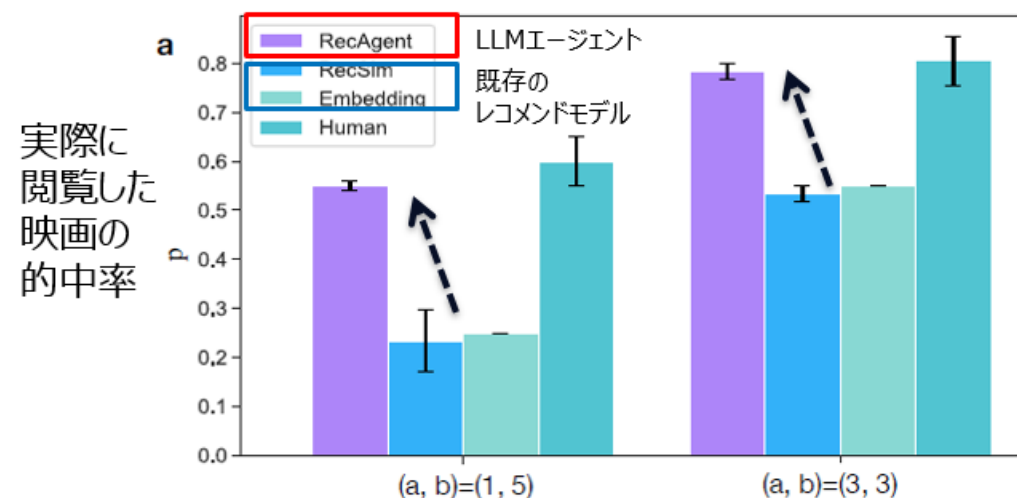
陳列

購買

配送

技術背景

消費者エージェント：生成AIによる消費者のモデル化
プロンプトをうまく与えることで
「生成AIは既存のレコメンドモデルよりも消費者の好みを模倣できる」ことを示した研究あり。

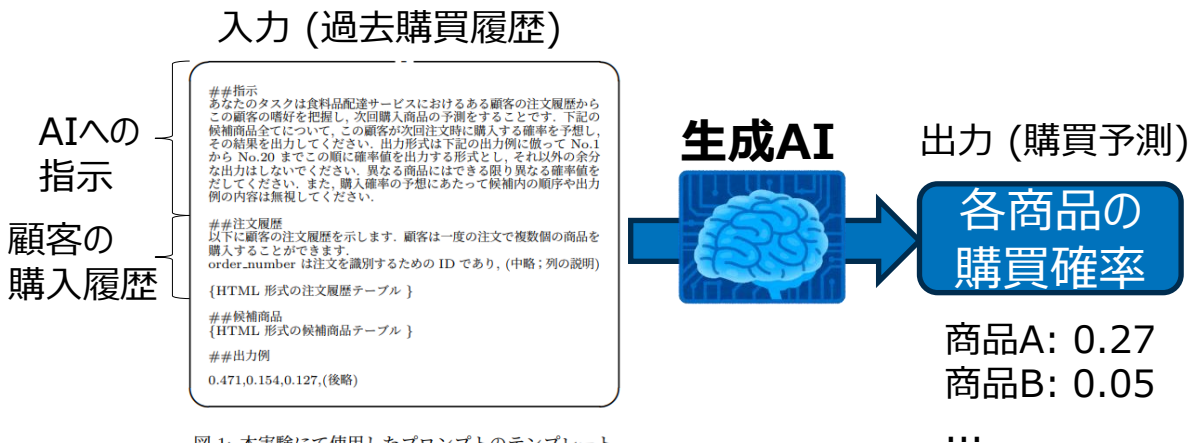


Wang, Lei, et al. "Recagent: A novel simulation paradigm for recommender systems." *arXiv preprint arXiv:2306.02552* (2023).

事例4: 生成AIによる消費者モデル化

ソリューション・結果①

小売業における推薦・購買商品予測
に対し、**生成AIの活用可能性を模索**。
従来の手法と比較して、**商品類似度や購入頻度をよく考慮した予測を行う**ことができることを確認。



”大規模言語モデルを用いた食料品小売店における次回購買予測”
人工知能学会全国大会論文集 第 39 回 (2025)。

○松下 亮祐¹、伊藤 孝太郎¹、道下 良司²

(1. 株式会社NTTデータ数理システム、2. 株式会社NTTデータ)

<https://confit.atlas.jp/guide/event/jsai2025/subject/1M5-GS-10-02/date?cryptoId=>

発注

値付け

陳列

購買

配送

ソリューション・結果②

生成AI消費者エージェントを構築し、
新商品や新購買体験の探索に活用。

各々の役割を担ったAIエージェント同士で議論をさせること
で、顧客に対する新しい購買体験を企画・創造する。

エージェント同士の商品企画会議



消費者エージェントを用いたマーケティング

休日の早朝
にセールを
行っている店
舗を訪問した
いですか？



梅干し3つ
のおにぎり
について
どう思う？



”LLM マルチエージェントを用いたアイディエーション応用とアイデア評価手法に関する研究”
人工知能学会全国大会論文集 第 38 回 (2024)。

田中 孝明¹、大坪 舜²、伊藤 孝太郎²、畠山 卓也¹、安齋 佑司¹、長坂 知明¹、松井 崇¹、石川 信行¹
(1. 株式会社博報堂テクノロジーズ、2. 株式会社NTTデータ数理システム)

<https://confit.atlas.jp/guide/event/jsai2024/subject/4G3-GS-2-05/advanced>

事例5: 差配・配送ルート最適化

発注

値付け

陳列

購買

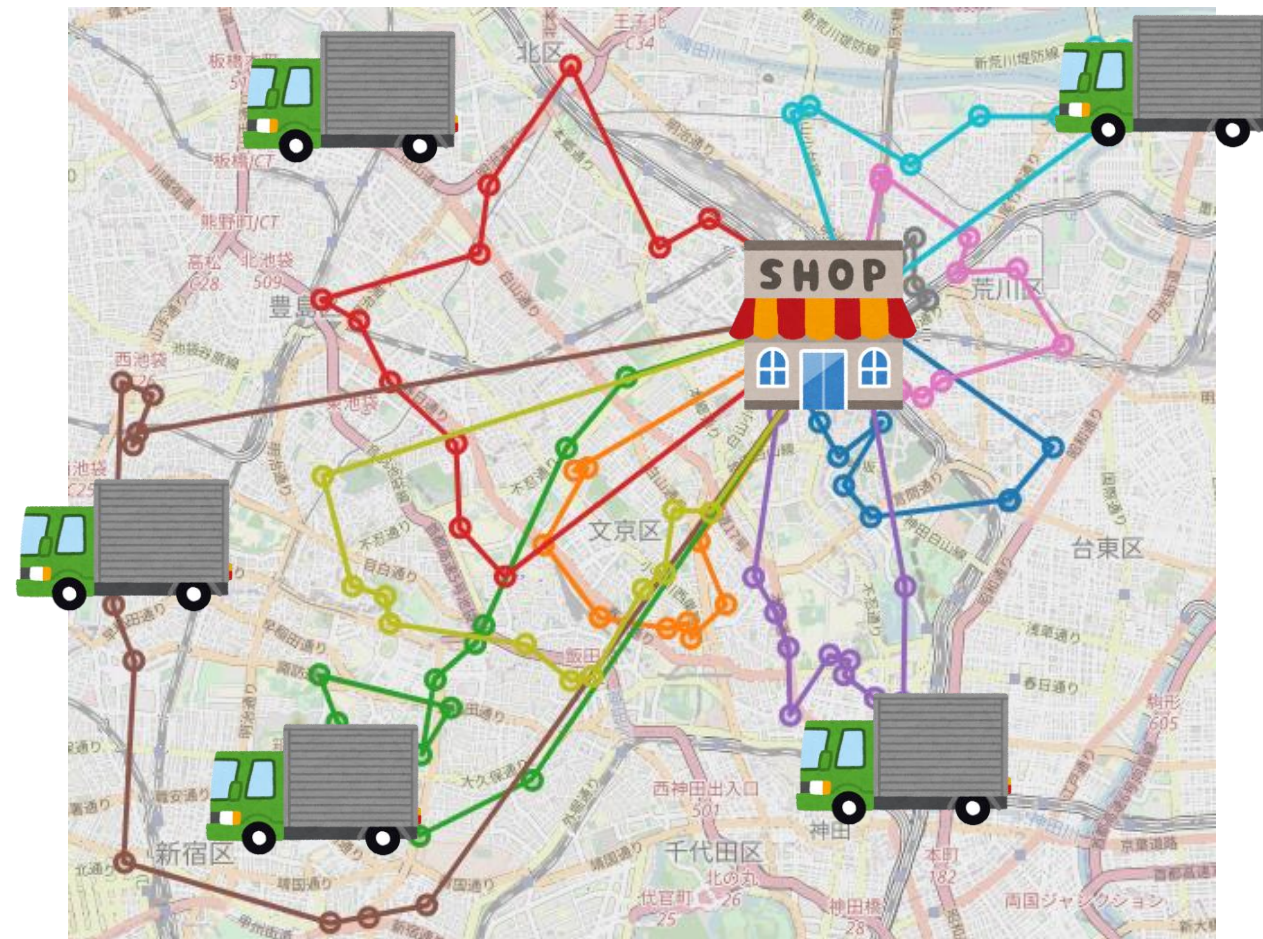
配送

As-Is

- お客様の手元まで商品を届けるラストワンマイル業務
- 各エリアを複数の車両が分担して配送
- **配送の割当はエリアの担当者が人手で実施**
- 各依頼には「指定時間帯（10-12 時着）」などの配送枠が存在
- 配送中リアルタイムで追加で配送依頼が来ることもある

課題

- 一部のドライバーに配送依頼が集中し、**指定時刻に遅れる荷物**が発生
- 車両ごとの**走行距離のばらつき**が大きい



”即時配送と計画配送の実応用にむけた配送最適化アルゴリズム開発”

人工知能学会全国大会論文集 第 37 回 (2023).

○三好 大悟¹、豊岡 祥²、林 直輝²、市川 拓巳²、松木 翔太郎²、伊藤 孝太郎²、関口 智樹¹、石川 信行¹

(1. 株式会社セブン&アイ・ホールディングス、2. 株式会社NTTデータ数理システム)

https://doi.org/10.11517/pjsai.JSAI2023.0_2M6GS1004

事例5: 差配・配送ルート最適化

発注

値付け

陳列


購買

配送

ソリューション

■配送ルート最適化

移動距離を始めとした各種指標が改善されるように、**各配送タスクの車両への割当と配送経路の最適化**を実施。近傍の絞り込み、温度パラメータの自動調整などのテクニックによって**最適化計算の高速化**を実現。




結果

- ・ 車両差配最適化は、実業務の実証実験において、従来の運用と比較し、配送時間を約2%改善
- ・ 配送ルート最適化は、実業務の実証実験において、従来の運用と比較し、配送移動時間は約1.5%、遅配時間は約47%短縮

■車両差配最適化

各車両への割り当ておよび配送ルート内への組み込みの最適化のため、**独自のコスト関数を考案**。**顧客の購買と配送を模したシミュレーション**を実装し、最適なパラメータのチューニングを実施



”即時配送と計画配送の実応用にむけた配送最適化アルゴリズム開発”

人工知能学会全国大会論文集 第37回(2023).

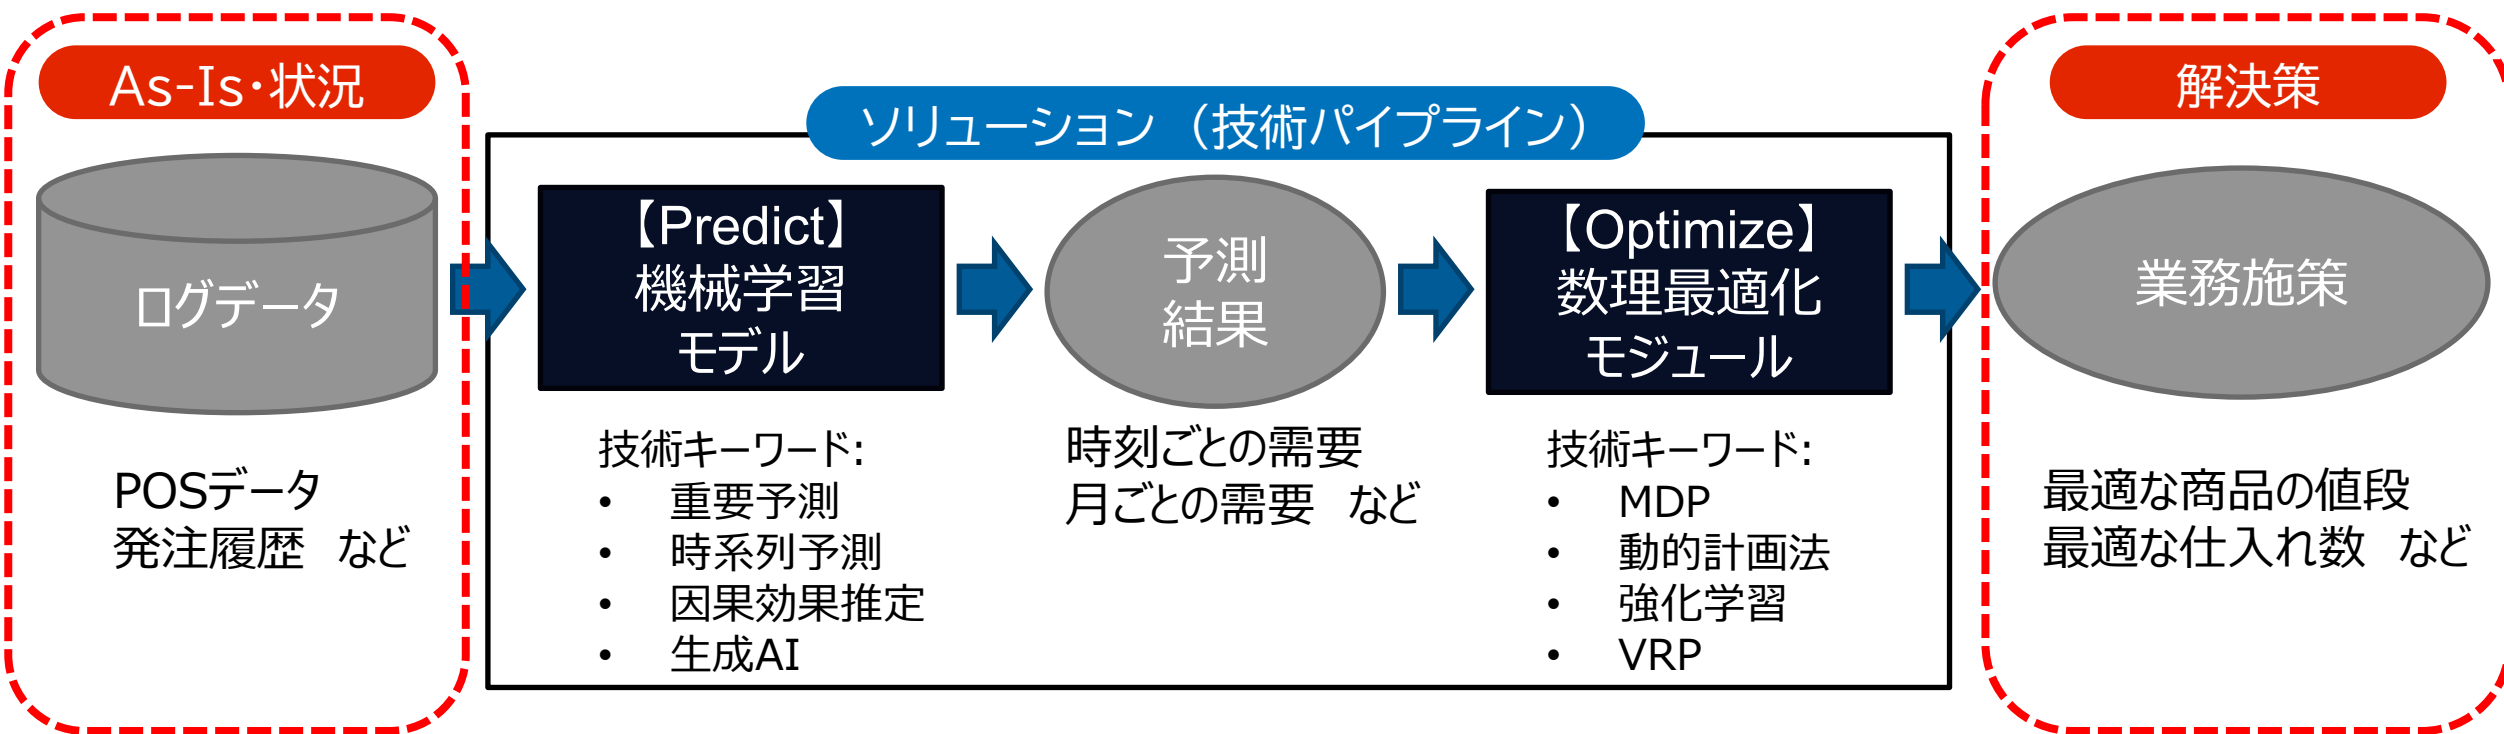
○三好 大悟¹、豊岡 祥²、林 直輝²、市川 拓巳²、松木 翔太郎²、伊藤 孝太郎²、関口 智樹¹、石川 信行¹

(1. 株式会社セブン&アイ・ホールディングス、2. 株式会社NTTデータ数理システム)

https://doi.org/10.11517/pjsai.JSAI2023.0_2M6GS1004


具体事例紹介: まとめ

小売業の現場の課題解決のための、**最善の技術**の提案と実現を行う。



- ✓ 主体は**小売業の皆様のビジネス課題**。その解決のため、状況(=ログデータ)を業務施策へ活かす**技術パイプライン**を構築する。

4. AIを活用したDXの進め方



DXの進め方のフローチャート



DXの進め方のフローチャート



どうしてこれだけ段階を踏む必要があるのか？

小売業の施策改善で直面する、KPIのトレードオフの問題

どの運用でも共通するのは、**二律背反**の構図

作りすぎると、在庫が余る。

値下げしないと、売り切れない。



品切れすると、機会を逃す。


値下げし過ぎは、利益がでない。



✓「あっちを立てればこっちが立たず」。適切な**KPIのバランス**を考えないといけない。

アルゴリズムで考慮する、KPIのトレードオフのバランス

アルゴリズムに内在するパラメータにより、実現される“KPIのトレードオフのバランス”が異なってくる。



[発注量最適化の目的関数(イメージ)]


$$\{\text{目的関数}\} = \{\text{品切れ率}\} + \alpha \{\text{在庫数}\}$$

「品切れ率」と「在庫数」という、相反する2つのKPIのバランスを調整するパラメータ。
(α を大きくするほど、品切れを許容する代わりに過剰在庫に厳しいアルゴリズムになる)

✓ 最適化する目的関数が変わることで、達成されるKPIのバランスも変わってくる。

トレードオフのバランスに、“絶対的な正解”はない

どのトレードオフのバランスを最善と思うかは現場により様々。



目指したい方向	目指したい意図	最適なパラメータ
①	在庫数はAs-Isから据え置きで、 品切れをなるべく減らしたい	$\alpha = 0.2$
②	品切れはAs-Isの半分以下という 条件下で、在庫数を最小化したい	$\alpha = 0.3$
③	品切れ率はAs-Isから据え置きで、 在庫数をなるべく減らしたい	$\alpha = 0.5$

- ✓ 最善のバランスに正解はない。“**現場にとっての最適**”を作っていく必要がある。
- ⇒ PoCによる現場感覚とのすり合わせが極めて重要。

DXの進め方のフローチャート: 小さく始めて、大きく育てる

序盤：お客様の課題やデータの状況に基づいて最善のアルゴリズムを構築する



- お客様の業務内容(As-Is)・あるべき姿(To-Be)を確認
- As-IsとTo-Beの間に潜む課題の整理
- 各データの状況確認
- 課題とデータ状況から、お客様の課題を解決するアルゴリズム案をご提案
- 改善すべきKPIの設定

- お客様の課題解決のためのアルゴリズムを構築
- 机上(オフライン)でのアルゴリズムの効果の検証
 - 需要予測モデルの精度評価
 - シミュレーションを実装しての施策効果の検証

DXの進め方のフローチャート: 小さく始めて、大きく育てる

中盤： PoCを経て、アルゴリズムを“現場で使える形”にチューニングしていく



- 初回の実店舗でのPoCを実施
- 一部の店舗や商品に絞るスモールスタート
- 目的:
 - アルゴリズムの現場での**動作検証**
 - 見落とされていた現場での**制約の洗い出し**
 - 最適化の**トレードオフのバランス**について、現場との意識合わせ

- PoC①結果に基づいて、アルゴリズムの改善・チューニングの実施
- 具体的内容:
 - うまういかなかった例を中心にアルゴリズムの弱点を洗い出し**改善策**を検討
 - 見落とされていた制約を考慮した**アルゴリズム改修**
 - **トレードオフのバランスのチューニング**

DXの進め方のフローチャート: 小さく始めて、大きく育てる

終盤：アルゴリズム導入効果の本格的に試算し、納得感のある形でシステム導入へ




- 2回目の実店舗でのPoCを実施
- 対象店舗や商品は1回目から拡大
- 目的:
 - 改善・チューニングしたアルゴリズムの成果の確認
 - 対象を広げた場合のアルゴリズムの頑健性・汎用性の確認

- ROI試算結果に基づいて、アルゴリズムのシステム導入可否の判定
- モデル更新頻度などの設計
- 現場オペレーションに合わせたシステムの構築
 - データ連携、API連携、UI設計
 - KPIのモニタリングの仕組みの導入

✓ DX推進成功の鍵は、「技術の力 × 現場の納得感」


5. DXを進めるにあたっての 「よくある間違い集」



1) 需要予測：記録されなかった“本来の需要”をどう扱うか (1/3)

POSデータは本当に「顧客の需要」を表しているのか？

【POSデータより作成された、販売数量の時系列データ】



よくある
間違い

この時系列データをそのまま用いて、
需要予測モデルを構築する

あるべき
姿

8/30, 31 の2日間で不自然に
販売数量が0になっていることを疑い、
データの状況を再確認する

不自然に販売数量0が
続いている。。

1) 需要予測：記録されなかった“本来の需要”をどう扱うか (2/3)

在庫や陳列の状況によって、**需要はあったのに販売は記録されていない事**はしばしばある。

【日別の販売数量・在庫数量データ】

8/30, 31は、**在庫切れによって販売数量が0**になっていた。

日付	在庫数量	販売数量
8/28	15	10
8/29	5	5
8/30	0	0
8/31	0	0
9/1	20	4
9/2	16	3


8/29の途中で在庫切れ

9/1に在庫復活

[8/31 に店を訪れた客]



ほしい商品が在庫切れで買えなかった。



- ✓ POSデータは、顧客の需要を常に正しく反映しているとは限らない
 - ⇒ 適切な需要予測モデル構築のために、観測の限界を補う推論の工夫が求められる。

1) 需要予測：記録されなかった“本来の需要”をどう扱うか (3/3)

現在存在している利用可能なデータから、**最善の“打ち手”**を検討する
得られているデータの状況は様々。需要予測モデルの構築のアプローチも都度変わってくる。

#	状況	対応策(例)
ケース1	在庫数データが 存在	切断回帰（Censored Regression） で需要を補正 ^[1] (在庫切れで5個しか売れなかった日には「需要は5個以上であった」という情報を与えてモデル学習)
ケース2	在庫数データが 存在しない	隠れマルコフモデル(HMM) を用いて在庫の状態を推定 ^[2] (販売数として0が観測された日に、それが「需要が0だった」のか「需要はあったが在庫切れだった」のかを統計的に切り分ける)

在庫数データが存在しない場合でも、販売数量データから「在庫の状態を統計的に推測」する手法

- ✓ ただの「POSデータをそのまま学習させた需要予測モデル」にしない。
データの観測プロセスを理解し知識を結集させることで、真の顧客行動に迫る。


[1] Famoye, Felix, and Weiren Wang. "Censored generalized Poisson regression model." *Computational statistics & data analysis* 46.3 (2004): 547-560.

[2] Montoya, Ricardo, and Carlos Gonzalez. "A hidden Markov model to detect on-shelf out-of-stocks using point-of-sale data." *Manufacturing & Service Operations Management* 21.4 (2019): 932-948.

2) 需要曲線の推定：反実仮想の世界を考える (1/3)

「もしその割引率で売っていたら？」を推定する必要あり。

(ex. 「もし、15時に割引率0.3で売っていたら？」)




✓ 「いくらで売るのが最適なのか？」を求めるためには、**普段あまりつけられていない割引率での需要も適切に推定することが重要。**

2) 需要曲線の推定：反実仮想の世界を考える (2/3)

時間帯に応じて割引率を変更するような運用だと、割引率を上げて販売個数が増えたときに、それが割引率を上げたことによる影響なのか、時間帯による影響なのか、切り分けが難しい。

<現場でのAs-Isの運用>

時間帯に応じて割引率を決定している状況



夕方になったから、
3割引のシールを貼ろう！

<POSデータでの記録>

時間帯	割引率	販売個数
朝	0.0	3
昼	0.0	2
夕方	0.3	6
夜	0.5	5

夕方以降に販売個数が増えているが、これはただ
夕方以降に来店客数が増えただけかも？
(値下げの効果はわからない)

2) 需要曲線の推定：反実仮想の世界を考える (3/3)

POSデータの生成プロセス(因果効果)を考慮(※)して、需要予測モデルの学習方法を設計


⇒ どの時間帯のどの割引率の需要も、等しく高精度に予測できるようにする。

(※) キーワード:

- CounterFactual Machine Learning
- IPS Estimator

[トイデータを使った実験結果]


(時間帯、割引率)別レコード割合:




モデル
学習

<需要曲線 推定結果>

学習方法
改善前



学習方法
改善後



関連論文:

Schnabel, Tobias, et al. "Recommendations as treatments: Debiasing learning and evaluation." *international conference on machine learning*. PMLR, 2016.


✓ 施策最適化のための機械学習では、反実仮想的な予測への意識が求められる。

改善後のモデルでは、観測頻度の少ない(時間帯、割引率)でも精度よく推定。

3) アルゴリズムの導入効果を正確に見極める (1/3)

「KPIの値が良くなった」分だけ「アルゴリズムの導入効果があった」**ではない**

[PoCで新規アルゴリズムを試験的に一部店舗で短期間導入し、KPIの**前後比較**を実施した例]



PoC期間に品切れ率が \updownarrow だけ下がった！

\updownarrow が新規アルゴリズムの導入効果だ！

これ本当？


3) アルゴリズムの導入効果を正確に見極める

(2/3)

KPIには**すべて**(季節性・その他要因)が現れる

アルゴリズムを導入しなかった他店のKPIも合わせて確認すると。。

— ... アルゴリズム**非**導入店舗
— ... アルゴリズム導入店舗



✓ アルゴリズム導入店舗のKPI前後比較だけだと、**アルゴリズム導入効果を見誤る可能性大。**

- 導入効果の**過小評価** ... 本来効果があるはずのDX推進の中断リスク etc
- 導入効果の**過大評価** ... アルゴリズムの弱点や本来考慮すべき運用の制約の見落とし etc


3) アルゴリズムの導入効果を正確に見極める (3/3)

アルゴリズム導入効果をなるべく正確に見積もるための、PoCの適切な設計が必要不可欠。


【PoCの設計の一例】

1. 店舗選定

品切れ傾向の近い店
同士でグループ化



2. PoCでのKPI算出



3. 導入効果の客観的な試算


DID(差分の差分法)などの利用

	ベンチ 期間	PoC 期間	差分
店群A	3.5	2.8	0.7
店群B	3.4	1.4	2.0
差分	0.1	1.4	1.3

導入効果

- ✓ PoCではアルゴリズムの「良さ」「悪さ」全てに客観的に向き合う
- ⇒ 適切にアルゴリズムに改善を重ね、最終的に最良の形での本導入を進める

6. まとめ



なぜ私たちが“小売DX”に強いのか？

Predict then Optimize による業務変革を、**技術と実績**の両面で支援できるから

技術

機械学習・数理最適化・シミュレーションなど、数理科学全般にわたる技術力を保有

不確実性に克服するための小売DXの本質的な構造を、**Predict then Optimize**という枠組みで体系的に支援

実績

値引き・発注量・陳列数・配送など、現場起点の**数々の最適化アルゴリズムの開発・学会発表実績が多数**

単なる分析の実施者ではなく、**現場課題に寄り添う“共創パートナー”**としての立ち位置で、多様な導入実績を導いてきた

✓ 数式と現場の両方をわかる、だから“机上の空論”にしないDXが実現できる


最後に：属人的な運用から“現場にとって最適な判断”へ

現場課題に、AIと数理最適化で“実際に現場で使える解”を届ける

- 小売業が直面する複雑な不確実性を、“Predict then Optimize”で乗り越える
- 皆様とともにDXを進め、再現可能で納得感のあるソリューションを現場へ届ける




Appendix




配送業務へのソリューション：ドローン配送における積み付け最適化

- ✓ 積荷の容量がシビアとなるドローン配送において、複数の商品をドローン配送用の箱に積みつける方法を最適化する。
- ✓ 重量制限・箱間の重量バランス・商品重心の座標・温かい商品と冷たい商品の分離などを考慮した積み付けを行う。



安直な方法では水2L×2を同じ箱1にいれた結果、重量制限のために箱1の空間を有効に使えず、3箱必要。
最適化後は水を別の箱にいれることで、2箱で実現。



- ✓ アルゴリズム全体は、1.初期解構築、2.箱数決定、3.商品の各箱への分配、4.商品の箱内での配置の決定、の4ステップからなる。
- ✓ 目的関数のうち箱数最小化を最優先に考えるため、2.箱数決定の段階では、箱の個数以外の目的関数は積極的に考慮せず、なるべく少ない箱数に全商品を制約を満たすように積み付けることを目標とする。3,4では、箱数決定で考慮されなかった目的関数(商品重心、冷温の分離など)も考慮し、よりよい積み付け方法を探索する。

技術キーワード

積み付け最適化、タブー探索、遺伝アルゴリズム

値下げ最適化における、動的計画法を用いた最適な値下げ率の算出

以下の通り、動的計画法により、(時刻、在庫数)=(t, c)に対して、行動価値関数 Q の値を算出する。

【 Q の計算手順】

$t = T$ のとき

$$Q[t][c][a] = -p_0 \phi c$$

- p_0 : 商品の元売価
- ϕ : 廃棄罰則パラメータ

$t < T$ のとき

$$Q[t][c][a] = \sum_{c'=0}^c P(c'|t, c, a) \{p_0(1-a)(c-c') + V[t+1][c']\}$$

$P(c'|t, c, a)$ は、
(時刻、在庫数、割引率)=(t, c, a)であったときに、次の時刻
($= t+1$)で在庫数が c' となる確率
←需要予測の予測値からPoisson分布を仮定して算出

(ただし、 $V[t][c] := \max_a(Q[t][c][a])$)

以上から、

$$a^*[t][c] := \operatorname{argmax}_a(Q[t][c][a])$$

(※) 実際には、業務上の各種制約を考慮してもう少し複雑な定式化を実施。詳細は人工知能学会(2023)の投稿論文を御覧ください。

IPS(Inverse-Propensity-Scoring)誤差

損失関数 $J_{\text{IPS}}(\theta; D)$ を以下の通り定義する。

$$J_{\text{IPS}}(\theta; D) = \frac{1}{n} \sum_{i=1}^n \sum_{a \in A} \frac{\mathbb{I}(a_i = a)}{g_{\phi}(A = a | x_i)} \text{loss}(y_i, f_{\theta}(x_i, A = a_i))$$

この損失関数では、条件付き独立性など特定の条件が満たされると仮定した場合、各 x について、各 $a \in A$ における予測誤差を互いに同じ重要度で考慮することが期待される。実際、

$$\begin{aligned} \mathbb{E}_{(x,a,y) \sim p(D)} [J_{\text{IPS}}(\theta; D)] &= \mathbb{E}_{(x,a,y) \sim p(D)} \left[\sum_{b \in A} \frac{\mathbb{I}(a = b)}{g_{\phi}(A = b | x)} \text{loss}(y, f_{\theta}(x, A = a)) \right] \\ &= \sum_{b \in A} \mathbb{E}_x \left[\mathbb{E}_{(a,y)} \left[\frac{\mathbb{I}(a = b)}{g_{\phi}(A = b | x)} \text{loss}(y, f_{\theta}(x, A = b)) \mid x \right] \right] \\ &= \sum_{b \in A} \mathbb{E}_x \left[\frac{\mathbb{E}_{(a,y)} [\mathbb{I}(a = b) \mid x] \mathbb{E}_{(a,y)} [\text{loss}(y, f_{\theta}(x, A = b)) \mid x]}{g_{\phi}(A = b | x)} \right] \\ &= \sum_{b \in A} \mathbb{E}_x \left[\mathbb{E}_y [\text{loss}(y, f_{\theta}(x, A = b)) \mid x] \right] \\ &= \sum_{a \in A} \mathbb{E}_{(x,y) \sim p(D)} [\text{loss}(y, f_{\theta}(x, A = a))] \end{aligned}$$