

ビジネスを進める 「処方的アナリティクス」



鷺森 崇

CONTENTS

- I DXで加速するビジネス変革のためのデータ活用
- II データから価値を生み出すアナリティクスの分類
- III 処方的アナリティクスで求められる数理最適化
- IV 処方的アナリティクスの事例
- V 処方的アナリティクスのビジネス実践に向けて

要約

- 1 デジタルトランスフォーメーション（DX）推進により、データとデジタル技術を活用した業務の効率化やビジネスモデルの変革が始まり、具体的な成果が出始めている。
- 2 データの中から意味あるパターンや知識を見いだす「アナリティクス」は、「記述的アナリティクス」「診断的アナリティクス」「予測的アナリティクス」「処方的アナリティクス」の4つに分類できる。AIブームで活用が広がった予測的アナリティクスに続き、アナリティクスの最終段階といわれる処方的アナリティクスの取り組みが始まりつつある。
- 3 さまざまな制約がある中で、何がベストな行動であるかを知るために行う処方的アナリティクスは、統計学、機械学習・強化学習に加え、数理最適化の手法が用いられる。数理最適化は、目的と制約条件を数式（数理モデル）で表現し、数理モデルに合った最適化アルゴリズムで最適解を導き出す。
- 4 処方的アナリティクスの事例としては、価格最適化（ダイナミックプライシング）、AIによる発注の最適化、広告出稿の最適化、などが挙げられる。
- 5 処方的アナリティクスのビジネス実践が広がるには、数理モデリングの自動化など、いくつかの課題が残されている。少し先の将来を見据えたとき、量子コンピュータのような技術的革新が進むことで、これまで解けなかった規模の問題も解けるようになり、処方的アナリティクスのビジネス実践も増えていくと予想される。そして、人間とコンピュータの新たな共創が処方的アナリティクスによるDX実現のカギになる。

I DXで加速する ビジネス変革のための データ活用


現在、世間ではデジタルトランスフォーメーション（DX）という言葉が溢れ返っている。DXとは、2004年にスウェーデン・ウメオ大学のエリック・ストルターマン教授によって提唱された、「ITの浸透が人々の生活をあらゆる面でより良い方向に変化させる」という概念のことである。日本では、経済産業省が「企業がビジネス環境の激しい変化に対応し、データとデジタル技術を活用して、顧客や社会ニーズを基に、製品やサービス、ビジネスモデルを変革するとともに、業務そのものや組織、プロセス、企業文化・風土を変革し、競争上の優位性を確立すること」と定義している。

DXの推進において重要視されているのが、「データとデジタル技術」の活用である。総務省の「令和2年版 情報通信白書^{注1}」に

よると、デジタルデータの収集・解析の目的として最も多いのが「効率化・業務改善」（83.5%）、次いで「顧客サービス向上」（34.0%）、「事業の全体最適化」（25.0%）、「新規事業・経営」（15.9%）となっている（図1）。

興味深いのは、18年から19年にかけて「効率化・業務改善」を目的としたデータの収集・解析が約10ポイント上昇していることである。これは、DXを推進する企業が、しがらみが少ない新規事業だけではなく、現行の業務やビジネスに対しても本格的にデータの活用に取り組み始めていることを示している。そしてその効果も表れ始めている。総務省の「通信利用動向調査」^{注2}によると、IoT、AIといったシステム・サービスの導入により、「非常に効果があった」または「ある程度効果があった」と回答した企業の割合は、18年調査の73.3%から20年調査では81.1%に増加した。多くの企業でデータを活用したビジネス変革が本格化し、具体的な成果が出始めている。

図1 デジタルデータの収集・解析の目的



出所) 総務省「令和2年版 情報通信白書」より作成

II データから価値を生み出す アナリティクスの分類

1 アナリティクスとは

データの活用が大きな富を生むことを「データは21世紀の石油」というフレーズで表現することがある。石油は、採掘、備蓄、精製・加工というプロセスを経て価値が生み出される。価値の創出で特に重要なのが精製・加工のプロセスである。データも同様で、ただ集めて貯めるだけでは価値は創出されない。データから価値を生み出すためには、「データの中に潜む、意味あるパターンや知識を見つけ、それを解釈し、伝える」ことが必要となる。このプロセスは一般的に「アナリティクス」と呼ばれる。

アナリティクスは、データの中の意味あるパターンを見いだすため、数学、統計学、機械学習、ディープラーニングなどの手法を活用する。Excelなどの表計算ソフトを使ってデータを表やグラフで表現することで、洞察を得ることも、最新のディープラーニング技術を用いた予測も、「アナリティクス」に該当する。

2 アナリティクスの分類

アナリティクスは、その使われ方によっていくつかに分類することができる。

米国シンシナティ大学のJames R. Evans教授は、著書『Business Analytics』の中で、アナリティクスを「記述的アナリティクス (Descriptive Analytics)」「予測的アナリティクス (Predictive Analytics)」「処方的アナリティクス (Prescriptive Analytics)」の3つに分類した。米国調査会社のガートナ

ーは、この3つに「診断的アナリティクス (Diagnostic Analytics)」を加えた4つのタイプに分類している。また、「認知的アナリティクス (Cognitive Analytics)」を加え、5つに分類するケースもある。以下、アナリティクスの分類でよく用いられる4つの分類について、概要と活用の状況を紹介する。

(1) 記述的アナリティクス (Descriptive Analytics)

記述的アナリティクスは、アナリティクスの中では最もシンプルで、よく活用されている分析活動である。「過去に何が起こったのか」を理解するために用いられ、単純にデータをさまざまな切り口で記述したものである。たとえば、ECサイトの日次や月次の売上集計表、購買者の性・年代構成比をグラフにすることなどは、記述的アナリティクスに該当する。

一般的には、表計算ソフトやTableauのようなビジネスインテリジェンスツール (BI ツール) を用いて、表、グラフ、ダッシュボード、レポートなどでデータの可視化を実現する。BIツールは、分析軸 (データ項目) の設定やドリルダウン (データの詳細化) の機能を持つので、データを多次元的に操作し、掘り下げて、過去に起こった事象を詳しく理解することができる。

記述的アナリティクスは、過去に起こった事象の理解を容易にするが、それがなぜ起こったのか、将来どのようになるか、それを踏まえ、今後、何をしなければならぬかについては、人間が判断しなければならない。アナリティクスの進捗としては初期の段階といえるだろう。

(2) 診断的アナリティクス (Diagnostic Analytics)

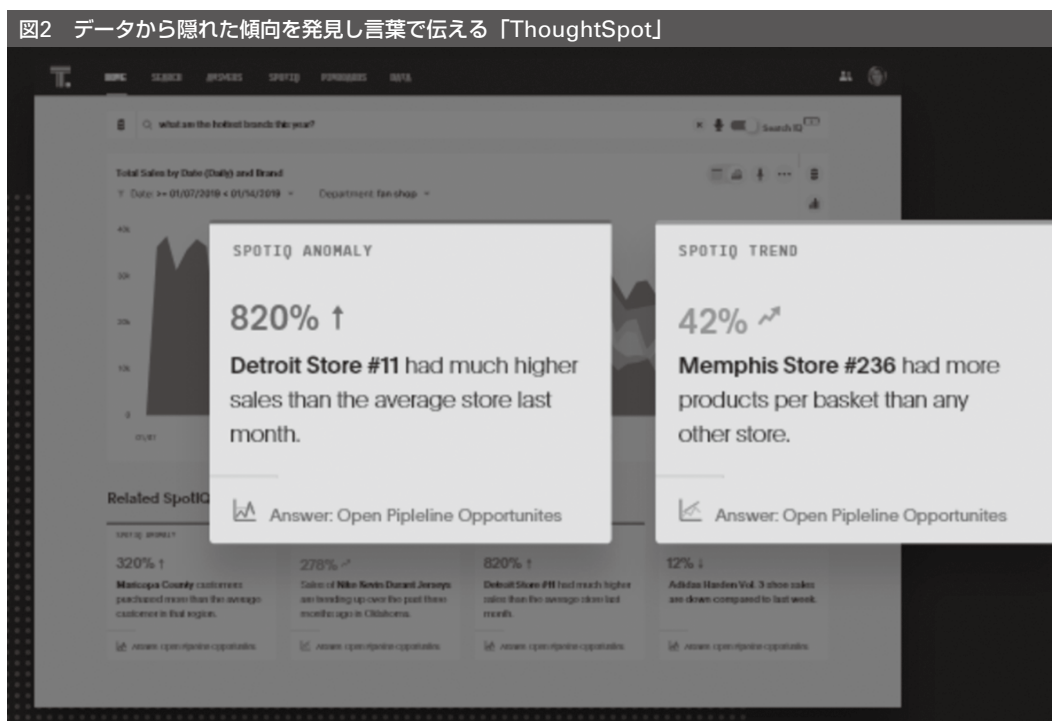
診断的アナリティクスは、前述の記述的アナリティクスをもう一步進めたもので、「過去になぜそれが起こったのか」を明らかにする分析活動である。事象が起こった原因や因果関係を明らかにするため、統計的手法がよく用いられる。たとえば、有料動画配信サービスの解約者について、解約時のアンケートや契約していたプラン・利用状況などのデータから、解約者に共通する特徴を見つけるような分析活動が該当する。

診断的アナリティクスは、記述的アナリティクス同様、昔から行われてきた分析活動で、アナリティクスの進捗としては中期の段階といえる。一方で、事象が起こった原因を探索・判断するには一定の分析スキルが必要のため、診断的アナリティクスに対するニーズは高いが、これまでその活動は限定的であ

った。しかし、複数のデータから自動的にデータ間の相関や因果関係を求め、文章で伝えるソリューションの登場が、診断的アナリティクスの現状を変えようとしている。

米国のパロアルトを拠点とするスタートアップ企業ThoughtSpot社による次世代のBIツール「ThoughtSpot」は、大規模な並列インメモリ計算エンジンを使用して、数十億のデータの組み合わせから隠れた傾向を発見し、言葉（文章）で伝える「SpotIQ機能」を提供している（図2）。たとえば、有料動画配信サービスの解約者について、今月解約した人は、先月と比べてどのようなプランで契約していた人が多かったのか、性別や年代、居住地域で特徴的な差が見られるのか、契約中の会員と比べてどのようなジャンルの動画を見ている人が多かったのかなど、通常は分析者が複数の表やグラフから、データの特徴や因果関係を見て洞察を得ていることを、自動

図2 データから隠れた傾向を発見し言葉で伝える「ThoughtSpot」



出所) ThoughtSpot Webサイトより作成
<https://www.thoughtspot.com/>

的に発見し、文章で伝えてくれるのである。

従来は、膨大なデータを加工・整理し、解約者に共通する特徴を見つけるためには、高度な統計的知識とスキルが必要とされてきた。しかし、このようなソリューションを活用することで、専門的な知識やスキルを持たない一般のビジネスユーザーでも、「過去になぜそれが起こったのか」を発見できるようになる。これまで限定的だった診断的アナリティクスの活動も、今後、活発になっていくと考えられる。

(3) 予測的アナリティクス (Predictive Analytics)

予測的アナリティクスは、「これから何が起こるのか」を推測するために用いられる分析活動である。一般的には、過去を理解することによって未来を予測することが予測的アナリティクスであるが、予測対象は必ずしも将来に限定されるわけではなく、過去のこの時に何が起こったのかを予測するケースもある。

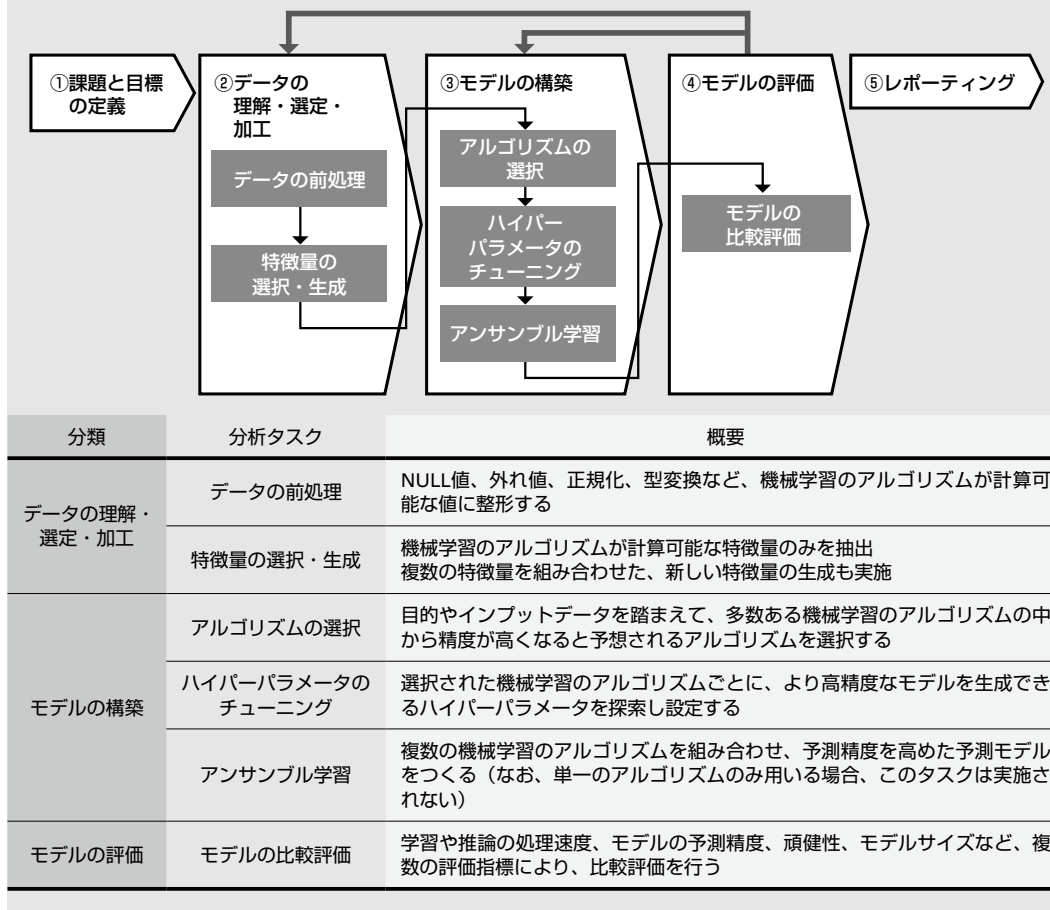
予測的アナリティクスでは、過去のデータを調査し、データのパターンや関係性を検出し、統計学や機械学習・ディープラーニングなどの分析手法を用いて、将来の予測を行う。たとえば、コンビニエンスストアで販売されているデザートが、来週、どれくらい売れるかを予測する需要予測や、有料動画配信サービスの会員が1カ月以内に解約する確率を予測する解約予測、工作機械が故障する前兆を見つける異常値検知などの分析が該当する。昨今のDX推進で「AIを活用した……」と言っている活動の多くが、この分析活動に該当する。

予測的アナリティクスでは、主に統計学や機械学習などの手法が用いられる。機械学習の歴史は古く、半世紀以上前から研究が進められてきた。たとえば、第3次AIブームを牽引する、ディープラーニングの原型であるニューラルネットワークは1950年代に発明されている。機械学習の歴史は古いが、その利用には高度な専門知識と分析スキルが必要になるため、前述の診断的アナリティクス以上に活用は限定的であった。しかし、クラウドコンピューティングで機械学習を手軽に利用できる環境やサービスが整備されてきたことや、データとデジタル技術を活用したビジネスの変革(=DX)を推進する意識の変化があり、予測的アナリティクスの活用は急速に広がり始めている。また、この傾向を後押しする技術的な革新も始まっている。それは、「自動機械学習(Automated Machine Learning: AutoML)」という技術である。

機械学習は、一般的には図3に示すタスクで進められる。「①課題と目標の定義」で定めたテーマについて分析活動を始め、「②データの理解・選定・加工」で使用するデータを理解し、必要なデータの選定と加工を行う。「③モデルの構築」で、分析に用いる手法(統計的手法、機械学習など)を選定し、モデルを構築する。「④モデルの評価」では、単にモデルの精度だけではなく、モデルの学習・推論に要する時間やコストなども併せて評価する。「⑤レポーティング」は、分析によって得られた示唆や知見を報告書に取りまとめるアドホックな業務である。

通常、「②データの理解・選定・加工」「③モデルの構築」「④モデルの評価」のステップは相互に繰り返される。これらのタスクの

図3 機械学習アルゴリズムを用いた分析タスク



一部を自動化するのが「AutoML」である。AutoMLは2015年頃から研究が本格化した新しい分野で、従来はデータサイエンティストの高度な専門知識や経験が必要とされた機械学習の最適なハイパーパラメータの探索や、機械学習アルゴリズム選択の自動化を中心に発展してきた。代表的なAutoMLプラットフォームとして挙げられるのが、12年に米国のボストンで創業したDataRobot社の自動機械学習プラットフォーム「DataRobot」である。

DataRobotは、データ分析に用いられることが多い「教師あり機械学習」「時系列分析」「異常値検知」などに対応しており、前

述の機械学習アルゴリズムを用いた分析タスクすべての自動化を実現している。それ以外にも、アマゾン ウェブ サービスが「Amazon SageMaker Autopilot」、マイクロソフトが「Azure Machine Learning」、グーグルが「Google AutoML Tables」など、大手クラウドベンダーがSaaS (Software as a Service) でAutoMLプラットフォームを提供している。中には、アマゾン ウェブ サービスの「AutoGluon」のようにオープンソースとして公開されているものもある。

これらの技術革新により、高度な専門知識を必要とした機械学習による予測的アナリテ

イクスが、データの用意さえできれば分析の専門知識を持たない一般のビジネスユーザーでもできるようになりつつある。予測的アナリティクスの技術的な敷居が下がっていくことで、より一層の活用の広がりを見せることになるだろう。


(4) 処方的アナリティクス (Prescriptive Analytics)

処方的アナリティクスは、「これから何をすべきか」を知るために用いられる分析活動である。過去に何が起こったのか（記述的アナリティクス）を理解し、なぜそれが起こったのか（診断的アナリティクス）を明らかにし、これから何が起こるのか（予測的アナリティクス）を推測できるようになったとしても、ビジネスにおいては、限られたリソースの中でどのように行動するのがベストなのかを考える必要がある。さまざまな制約があ

る中で、将来の意思決定がどのような影響を及ぼすのかを見極め、最適な行動は何であるかを知る分析活動が、処方的アナリティクスの領域である。

たとえば、コンビニエンスストアで販売されているデザートを題材に考えてみる。過去の販売状況を踏まえて、来週はどれくらいデザートが売れるかを予測するのは需要予測（予測的アナリティクス）だ。しかし、その予測された数量をそのまま発注できるかというと、必ずしもそうではない。コンビニエンスストアの商品棚は有限であり、並べることができる商品数には上限がある。また、デザートよりも粗利が大きい弁当を増やしたいといった、制約条件が発生し得るからである。ビジネスでは、商品がいくつ売れるか（需要予測）ではなく、さまざまな制約条件の下で売り上げを最大化するような行動（発注）が求められる。それを明らかにする分析活動

図4 データの分析結果の活用



出所) 総務省「デジタルデータの経済的価値の計測と活用の現状に関する調査研究の請負報告書」(2020年3月)より作成

が、処方的アナリティクスである。

処方的アナリティクスは、アナリティクスにおける最終段階といわれており、現時点では予測的アナリティクスのように多くの分析活動が始まっているわけではない。しかし、総務省の「デジタルデータの経済的価値の計測と活用の現状に関する調査研究」²³によると、生産・製造や物流・在庫管理などの領域では、処方的アナリティクスに該当する「発注や制御等の自動化」で活用が始まりつつあることが分かる（図4）。

Ⅲ 処方的アナリティクスで求められる数理最適化

1 処方的アナリティクスの特徴

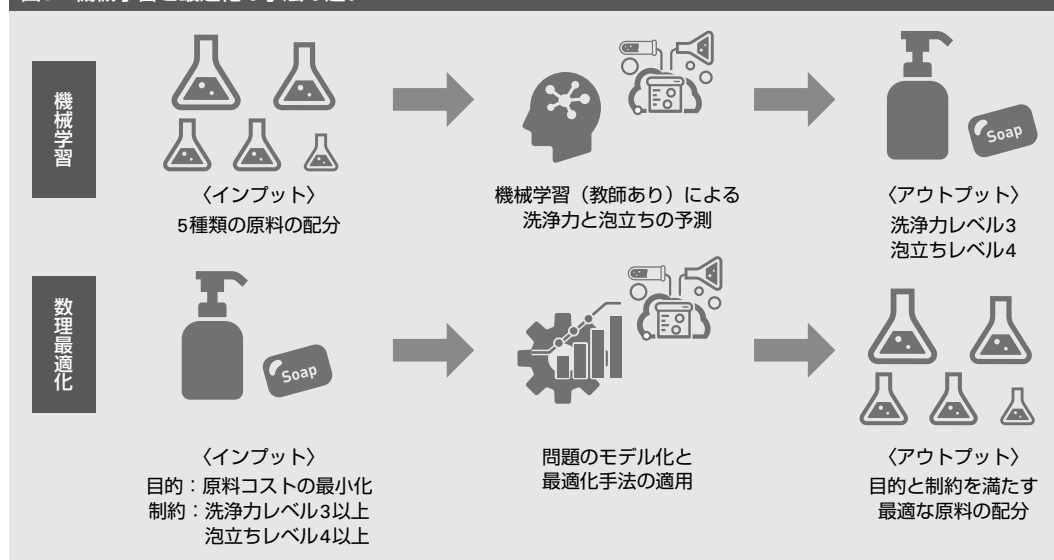
処方的アナリティクスは、統計学、機械学習・強化学習に加え、数理最適化の手法が用いられる。数理最適化は、第二次世界大戦における軍事オペレーションの研究を契機に生まれ、計画、設計、管理などのさまざまな局面における意思決定を科学的アプローチで解く「オペレーションズリサーチ」の一分野と

して発展してきた。数理最適化は、目的と制約条件を数式で表現し、その数式に合ったアルゴリズムで最適解を求める計算を行う。通常、数式は1つの目的関数²⁴といくつかの制約式で構成される。

「AIで活用されている予測的アナリティクスは、なぜ最適な答えを導き出せないのか」について疑問に思う人もいるだろう。一般的にAIという言葉には、人間が思いつかない最適な答えを見つけ出してくれるイメージがあるからだ。予測的アナリティクスで用いられる機械学習と、処方的アナリティクスで用いられる数理最適化は、手法として異なるものである。

たとえば、5種類の原料を配合して、泡立ちと洗浄力の高い洗剤を開発したいとする（図5）。過去に5種類の原料を配合し、泡立ちや洗浄力がどれぐらいになったかを記録した研究データがあるとする。機械学習では、その研究データから傾向を抽出し、過去の研究では試していない配分で混ぜた場合、どのような泡立ちや洗浄力になるかを予測することができる。しかし、現実のニーズでは、

図5 機械学習と最適化の手法の違い



「泡立ちがレベル3以上、洗浄力がレベル4以上で、最も原料のコストが低くなるような配分量を求めたい」というような、ビジネス上の目的と制約条件が発生するケースが多い。機械学習では、原料の配分量をインプットとして、泡立ちや洗浄力のアウトプットを得ることができる。しかし、どのような配合量にするかは人が決める必要があり、制約を満たす結果になるかどうかは、やってみないと分からない。もちろん、思いつく限りの原料の組み合わせで予測を実行して、目標と制約を満たす配合量を探索するやり方もある。だが、仮に原料が0.1g刻みで0gから100gまでとして、5種類の原料の組み合わせを考えたとき、1000の5乗（1000兆）通りの試行が必要となる。たった5種類の原料の配合でも、膨大な計算が必要になってしまうのだ。このような現象のことを、オペレーションズリサーチの分野では「組み合わせ爆発」と呼ぶ。そこで、膨大な計算が必要となる問題に対して、高速に解く手法が数理最適化なのである。

2 数理最適化をビジネスに活用するポイント

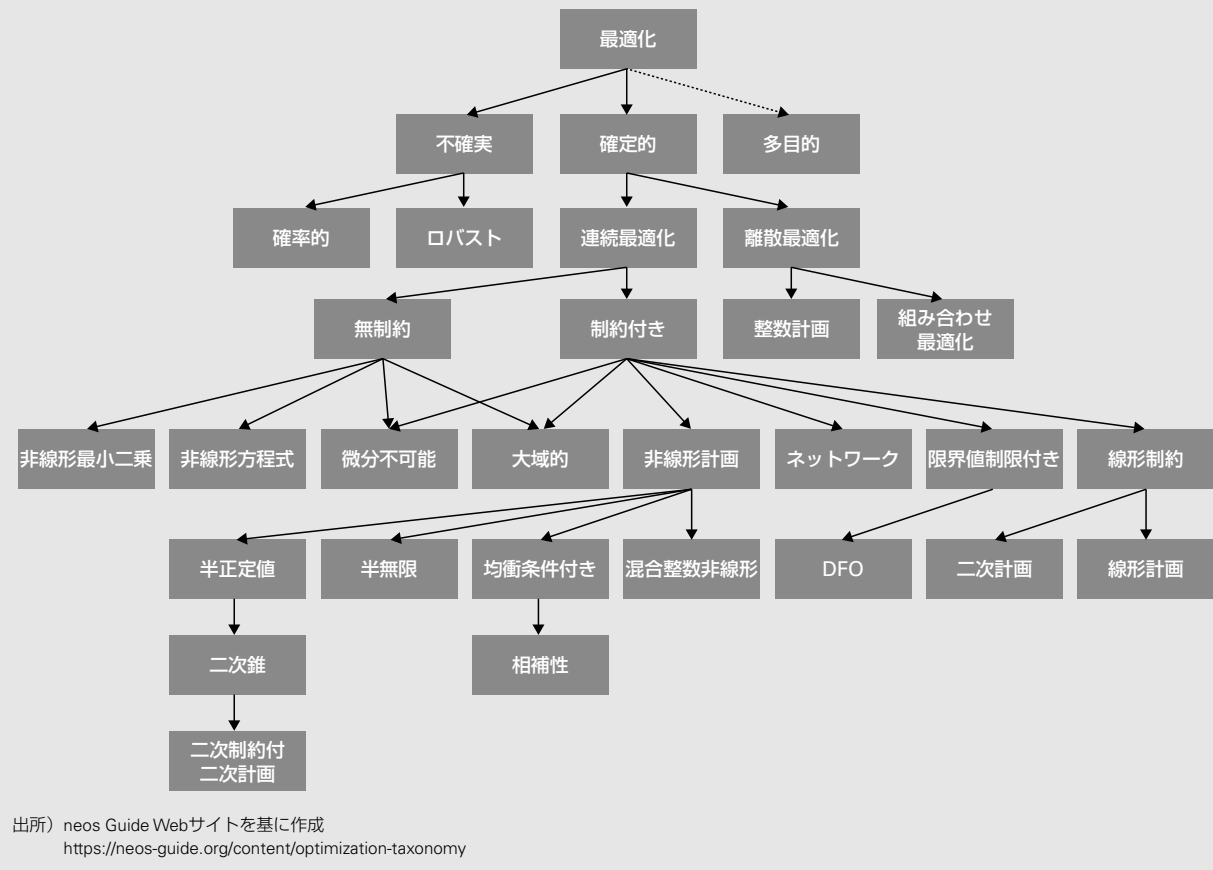
数理最適化は、その数式の内容によって分類することができる。これらは「最適化問題」と呼ばれ、古くからある学問領域の一つである。数式内の変数が連続の値を取る場合「連続最適化（continuous optimization）」、変数が離散値を取る場合「離散最適化（discrete optimization）」と呼ばれる。離散値とは、連続していない値のことで、たとえば人数や商品のように整数値でしか表せないものが該当する。連続値は、身長や体重のように

切れ目がなく連続している値のことだ。数式に離散値である整数の変数と、連続値の変数の両方が含まれるケースもある。このような問題は「混合整数最適化（mixed integer optimization）」と呼ばれる。これ以外にも、さまざまな最適化問題があり、たとえば図6のように分類²⁵できる。そして、これらの分類ごとに最適化問題を解くための手法（最適化アルゴリズム）が存在するのである。

数理最適化は、半世紀以上前から学問の領域として存在し、ビジネスに活用されてきた。しかし、昨今のAIブームで注目された機械学習と比べて、存在感は薄かったといえる。その理由として、数理最適化の活用の難しさが挙げられる。機械学習では、目的変数と説明変数（特徴量）がCSVファイルのような構造化データとしてあれば、とりあえず試すことができる。もちろん、高精度の推論モデルをつくるためには、特徴量の工夫やアルゴリズムの選択、ハイパーパラメータのチューニングなど、専門的な知識が必要となる。しかし、それらもAutoMLにより、ハードルが下がってきている。

一方、数理最適化を行う場合は、何を目的にしたいのか、それを実現するに当たってどのような制約があるのかを要件として洗い出す必要がある。その上で、解きたい問題を数式で表現しなければならない。前述の泡立ちと洗浄力の高い洗剤の開発の例でいえば、目的が原料コストの最小化で、洗浄力レベル3以上、泡立ちレベル4以上という制約条件を数式で表現することになる。そして、この数式からどの最適化問題に該当するのかを判断し、方程式を解くための最適化アルゴリズムを選定しなければならない。いわば、一つ一

図6 最適化問題の分類



つの問題に対して、オーダーメイドで問題と解法をつくっていく職人芸が必要になる。

また、数理最適化で得られた結果をビジネスで活用する心理的なハードルも存在する。数理最適化によって得られた値が本当に最適といえるのかという疑念である。しかし、こうした数理最適化の活用を妨げる障壁は解消されつつある。

一つは、さまざまな最適化問題に対応できる汎用ソルバーと計算環境の向上だ。従来は、解きたい問題を数式化（問題のモデル化）して、それを解くアルゴリズムもプログラミングしていたため、職人芸が求められ、数理最適化の活用も限定的だったが、大規模

な計算に耐え得る環境と汎用ソルバーにより、問題のモデル化さえできれば、数理最適化を比較的簡単に試すことができるようになった。データ分析でよく使用されるPython言語で、数理最適化のライブラリが充実してきたことも、活用の後押しとなっている。

もう一つは、AIブームやDXの推進により、ビジネスの判断にデータを使うことへの心理的ハードルが下がってきたことである。これまでならば試してみようと思わなかったことに対して、コンピュータによって計算された値を使ってみる。その結果、従来のやり方と、コンピュータによるやり方の比較ができ、どちらが有用かを判断できるようになっ

た。成功体験が増えれば、本当に使いものになるのかという疑念は薄れていく。このように技術と環境の変化が、ビジネスにおける数理最適化と処方的アナリティクス活用を後押しし始めているのである。

IV 処方的アナリティクスの事例

いくつかのビジネス領域では処方的アナリティクスの活用が始まっており、以下にその事例を紹介する。

1 価格最適化

(ダイナミックプライシング)

Jリーグのプロサッカー klub 横浜F・マリノスは、2019年シーズンから価格最適化(ダイナミックプライシング)の仕組みを用いたチケット販売を実施している。

15種類あるスタジアムの座席の値段について、過去の販売実績データを使って売れ行きを予測し、販売の状況に応じて最も収益が見込める価格をシステムが提示する。たとえば、サポーターズシートの標準価格が2500円のところ、チケットの売れ行き次第では7500円の販売価格に変更される場合もある。逆に売れ行きが悪い場合は値下げされる場合もある。価格を適正化して収益を最大化するのが、ダイナミックプライシングの仕組みだ。

サッカー klub だけでなく、プロ野球チームでもダイナミックプライシングの導入が始まっている。オリックス・バファローズが19年7月に実施したダイナミックプライシングの実証実験では、チケットの平均単価は2%下がったが、販売数量が17%伸びたため、チケット収入が14%増加するという結果が得ら

れている。横浜F・マリノスやオリックス・バファローズは、米国Neustar社のダイナミックプライシング技術を基に、日本のチケット業界に合わせたアルゴリズムを開発しているダイナミックプラス社のソリューションを採用している。

ダイナミックプライシングは、もともと航空券やホテル宿泊などで活用されていたが、スポーツや演劇のチケット販売、ネットショップ、Uberのような配車サービス、電気自動車の充電料金など、適用領域が広がってきている。これまでは、ビジネスに求められる制約を踏まえると大規模な問題になってしまい、解くことが難しかったテーマに対しても、高速で解けるような最適化アルゴリズムの進歩や分析環境の性能向上により、適用できるビジネスの対象が増えてきたことが背景にある。今、注目を集めている、処方的アナリティクスの適用領域といえるだろう。

2 AIによる発注の最適化

セブン&アイ・ホールディングスのイトーヨーカ堂は、2020年9月から食品を扱う全店舗でAI発注の仕組みを導入した。AI発注は、商品の販売実績、在庫の状況、天気などを踏まえて、加工食品や酒類など食料品の約8000品目を対象に最適な発注量を提案する。試験運用中の検証によると、発注にかかる時間を約30%削減し、欠品率を約20%削減する効果が得られたそうだ。同様の取り組みが、コンビニエンスストアのセブン-イレブンや、スーパーの西友、ライフコーポレーションなどで始まっている。

前述の通り、将来いくつ売れるかという需要予測は予測的アナリティクスの範疇になる

が、現実の業務では予測値を踏まえて、いくつか商品を発注するかまで提案することが求められる。発注するためには、在庫スペース、発注ロットサイズ、販促計画、売り上げ目標など、さまざまな制約に基づいて数量を決める必要がある。これらの制約条件を踏まえて最適な発注量を求めるのが、処方的アナリティクスである。

AI発注の仕組みを導入することで、発注作業時間の削減とともに、従業員の経験やスキルに依存しない発注が実現でき、欠品による販売機会ロスや、過剰発注による廃棄ロスの削減が実現される。小売業界は慢性的な人手不足に苦しんできた経緯もあり、AI発注の導入は今後も広がっていくだろう。

3 広告出稿の最適化

不動産・住宅情報サイトを運営するライフは、年間100億円近く広告宣伝費を使っており、どの広告媒体にどれだけ投資するかという判断を、機械学習と数理最適化の手法を用いて行っている。広告の価値を定量化し、各広告に対してどれぐらい投資するといくらの上乗価値が見込めるかを数式化し、売上や利益の最大化などの目的に応じて、数理最適化の手法で広告出稿の最適なポートフォリオを計算している。

広告の出稿は、従来のマスメディアに加え、デジタルメディアの出現で広告活動が多岐にわたり、効果の見えづらさが課題となっている。正しく広告効果を測るためには、メディア横断のデータ（シングルソースデータ）が必要で、このような新しいデータを使った数理最適化による広告出稿の最適化の取り組みも始まっている。

V 処方的アナリティクスの ビジネス実践に向けて

AIブームとDXの推進により、ビジネスを変革する「アナリティクス」への期待が高まっている。中でも、アナリティクスの最終段階ともいわれる処方的アナリティクスはビジネスを変える大きな可能性を持っている。しかし、処方的アナリティクスのビジネス実践が進むためには、いくつか課題が残されている。

1 処方的アナリティクスの 分析環境の整備

機械学習・ディープラーニングを用いる予測的アナリティクスの活用が急速に広まったのは、アマゾン ウェブ サービス、マイクロソフト、グーグルなどが提供するクラウドサービスで、機械学習を簡単に実行できる環境やサービスが提供されてきた影響が大きい。処理にかかる時間やデータの規模が大きな問題でも、クラウドサービスであればリソースの調整が容易で、安価に利用できる。処方的アナリティクスで用いられる数理最適化の手法は、大規模な計算が必要となるケースも多く、クラウドサービスで環境が用意されることで、分析活動のハードルは下がる。

東芝デジタルソリューションズは、2019年8月に大規模な組み合わせ最適化問題に特化した「シミュレーテッド分岐マシン（Simulated Bifurcation Machine）」^{注6}をアマゾン ウェブ サービスのAWS Marketplaceに公開した。1時間当たり約3ドルで利用できる。このようなクラウドサービス上で高性能な最適化ソルバーが安価に利用できるようになるこ

とで、処方的アナリティクスの試行が増えていくだろう。

2 数理モデリングの自動化

数理最適化では、目的と制約条件を数式で表現し、アルゴリズムで最適な解を求める計算を行う。この数式に表現する作業は、問題のモデル化（数理モデル）と呼ばれ、数理最適化の分析活動の中でも特に重要なプロセスといわれている。

数理モデルがどの最適化問題に該当するのか、そしてどの手法を用いれば解くことができるのか、これらを判断するためには高度な専門知識が必要となる。モデルによっては、そのままの制約では最適解が求められなかったり、現実的な時間では解けなかったりするケースもある。その場合、ビジネスで許容できる範囲で制約条件を緩和して、解ける問題に落とし込むような調整も行われる。現状では、専門的な知識を持つ人材が行っている作業であり、数理最適化のビジネス活用を難しくしている要因の一つでもある。

機械学習の分野では、AutoMLという手法の普及により、専門的知識を持たないビジネスユーザーでも機械学習の活用ができるようになりつつある。このような状況について「機械学習の民主化」と呼ばれたりするが、数理最適化においても、この問題のモデル化がある程度自動的にできるようになれば、「数理最適化の民主化」が始まることになるだろう。

ただし、問題のモデル化は、ビジネスにおいて目指すべき目標と制約条件が基になるため、完全に人が関与しない自動化は難しい。あくまでもいくつかの数理最適化の代表的な

テーマの範疇で、数理モデルと最適化手法の選択がある程度自動化されることになると考えられる。

3 量子コンピュータへの期待

少し先の将来を見据えた場合、技術的な革新も期待される。それは量子コンピュータの活用だ。

量子コンピュータとは、「量子重ね合わせ」や「量子もつれ」といった量子力学の現象を利用して並列計算を実現するコンピュータである。従来型のコンピュータでは答えの導出に膨大な時間を要する問題でも、短い時間で解けるようになる可能性があり、今、注目を集めている。この量子コンピュータの適用先として期待されているのが、数理最適化の一つである組み合わせ最適化である。組み合わせ最適化は、変数が離散値を取る離散最適化の一種で、組み合わせ構造を持つ有限集合から解を選択する最適化問題のことである。

たとえば、店舗へ商品を配送するときのルート（配送計画）や、工場の工作機械のタスク割り当て、病院の看護師の勤務スケジュール作成などの最適化が適用事例として挙げられる。組み合わせ最適化は、前述の組み合わせ爆発の問題もあり、最適解を求めることが難しい領域の問題だが、量子コンピュータを使うことで、従来は解くのが難しかった問題でも、現実的な計算時間で最適解を求められるようになることが期待されている。

量子コンピュータを使った数理最適化の取り組みは始まったばかりだが、たとえば、自動車部品メーカーのデンソーが工場内の無人搬送車の経路最適化について実証実験を行っ

ている。工場内の無人搬送車の稼働率が80%だったところ、量子コンピュータを用いたリアルタイム制御では稼働率が95%に上昇したとのことである。ほかにも、リクルートがホテル予約サイト「じゃらんnet」で、ホテルを表示する順番の最適化について量子コンピュータを用いる実証実験を行ったり、三井住友フィナンシャルグループがコールセンターの勤務シフト作成に量子コンピュータ（量子コンピュータを疑似的に再現した日立製作所のCMOSアニーリング）を用いたりするなど、さまざまな取り組みが始まっている。

量子コンピュータが実ビジネスで活用できるレベルに至るには、まだ時間がかかると予想されているが、このような技術的革新が進むことで、これまで解けなかった数理最適化の問題が解けるようになり、処方的アナリティクスのビジネス実践も進んでいくことになるだろう。

データから価値を生み出す「アナリティクス」は、ビッグデータ、AI、DXなどの取り組みを経て、新たなステージに差し掛かっている。アナリティクスの最終段階ともいわれる処方的アナリティクスは、一般のビジネスユーザーの誰もが、データを活用したビジネスの変革を実践できる可能性を秘めている。今後、技術革新や環境の整備が進むことで、数理最適化の技術を活用した処方的アナリティクスの実践は広がっていくだろう。

ただし、ビジネスにおいて何を目的とし、

どのような制約があるかを決めるのは人間である。処方的アナリティクスは、コンピュータがビジネスにおけるすべての意思決定を担うものではなく、あくまでも人間が定めた目的と条件において最適な行動を提案するものである。人間とコンピュータの新たな共創の姿こそが、DXの概念（ITの浸透が人々の生活をあらゆる面でより良い方向に変化させる）を実現に導くカギになるであろう。

注

- 1 総務省「令和2年 情報通信に関する現状報告（令和2年版 情報通信白書）」（2020年8月）
- 2 総務省「令和2年通信利用動向調査」（2021年6月）
- 3 総務省 情報流通行政局情報通信政策課情報通信経済室「デジタルデータの経済的価値の計測と活用の現状に関する調査研究の請負報告書」（2020年3月）
- 4 目的関数が複数存在する場合もある。そのような最適化問題を多目的最適化問題と呼ぶ
- 5 <https://neos-guide.org/content/optimization-taxonomy>
- 6 <https://aws.amazon.com/marketplace/pp/product-view-f3hbaz4q3y32y>

著者

鷺森 崇（さぎもりたかし）

野村総合研究所（NRI）データサイエンスラボ上級研究員（NRI認定データサイエンティスト）

専門はデータサイエンス、機械学習プラットフォーム、AIアシスタント技術、RFID、ロケーションテクノロジー、リテール業界のITサービスなど