

## AI活用のヒント【需要予測】

不確実な時代のトレンド変化に対応し  
現場を巻き込みながら  
需要予測精度を高める



# 不確実な時代のトレンド変化に対応し 現場を巻き込みながら 需要予測精度を高める

これまでベテラン社員の経験や勘に依存することの多かった流通・小売業の需要予測業務に、AIを活用して予測精度を高めるアプローチが採用され始めている。本稿では、AI活用を民主化するAI Cloudプラットフォーム「DataRobot」を用いた大手メーカーや、ロジスティクス、食品メーカーでのAI活用事例を踏まえながら、複数の需要予測パターンに対してAIがいかに貢献できるか、また業務にAIをどのように適用すればよいかを解説する。

## 需要予測におけるAIの使い方

流通・小売業にとって、収益を最大化するための鍵を握っているのが需要予測である。正確な需要予測を行うことで店頭での欠品を防ぎ、ひいては販売機会損失を防ぐことができる。また過剰な調達（仕入れ）を抑えて、返品ロスや廃棄ロスを防ぐことができる。

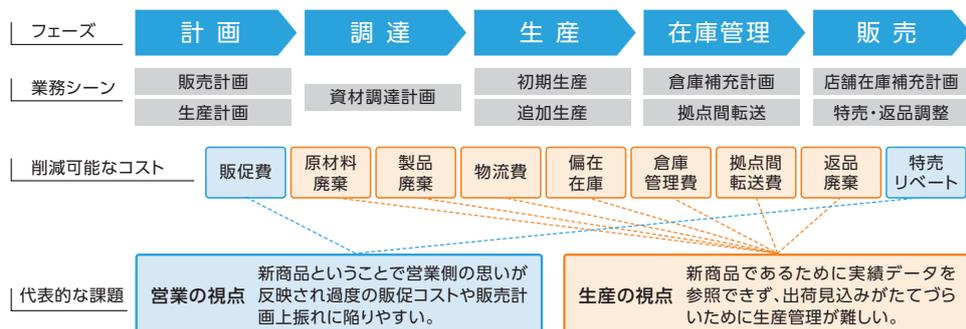
もちろん需要予測は店頭（販売）だけでなく、その前段階の計画、調達、生産、在庫管理などのフェーズにおいても、コスト削減を実現する重要な要素となっている。特に近年は消費者ニーズの多様化が進むとともにコロ

ナ禍によるデータ変動も顕著で、需要予測に対するニーズは高まるばかりだ。

しかし難しいのは、上述した各フェーズにおいても、それぞれで関わっている人の思いが異なることである。新商品を市場に投入した際に、例えば営業部門はスタートダッシュで販売数量を伸ばしたいため販促コストや販売計画が上振れしがちだ。一方で生産部門は新商品であるがゆえに実績データを参照できず、出荷見込みが立てづらいため、生産計画について慎重な構えを崩さない。

そうした中で注目されているのが、需要予測におけ

### <需要予測が適用できる業務シーンと現状の課題>



るAI活用である。過去の実績データや販促データ、商品属性などのあらゆるデータを取り込んで機械学習を行い、店舗×SKU (Stock Keeping Unit) などの単位で販売量/出荷量の予測を行う。

## 業務課題に応じてルールベースと機械学習を組み合わせる

従来の需要予測では、熟練者の経験と勘に基づいた属人的な判断に依存するケースも多く見られた。「昨年と同時期の販売実績が〇〇だったので、今年も同じくらいの数量が見込める」、「繁忙期の〇月の販売数量は通常期の3割増しになる」といった暗黙知に基づくものだ。

一部の企業では、こうした熟練者の暗黙知を抽出して形式知化し、IF～THEN形式のルールベースとしてシステムに実装するといった試みも行われてきた。とはいえIF～THEN形式の単純なルールでは複雑な判断のパターンを表現しきれない。またルールが増えていくに従って、どのルールがうまく働いているのか、眠っているのかの判断がつけられないといった問題が生じ、運用は困難になっていく。

業務要件に応じて、そうした熟練者の暗黙知やルールベースのシステムにAIを組み合わせることで、大きな改善を図ることができる。機械学習は過去のデータからパターンを学習させるアプローチであり、データが更新されればモデル（ロジック）の更新も行われる。これにより複雑な判断パターンにも柔軟に対応することができ、ルールベースよりも予測精度を高めることが可能となる。

もっとも機械学習の導入・活用自体も容易なことではなく、これまでは高度な専門スキルを有するデータサイエンティストに頼らざるをえなかった。そうした機械学習を業務現場のエンドユーザー自身が主体となって活用できる“民主化”を実現すべく、日鉄ソリューションズが提供しているのが「DataRobot」だ。

DataRobotにより、機械学習におけるデータ準備からモデル生成、モデル解釈、ビジネス適用、モデル管理・監視まで、一連のプロセスを自動化することが可能となる。

## 大手消費財製造小売り業における店舗への商品補充量予測とロジスティクスにおける人員最適

実際にDataRobotを活用してさまざまな予測を行っている企業の事例を見てみよう。まずは大手消費財製造小売り業における取り組みだ。この企業ではバイヤーが店舗ごと、商品ごとの需要を予測し、倉庫から配送を行っていた。

しかしその判断は属人化しており、不正確な予測による欠品や在庫過多といった課題が生じていた。そこでDataRobotを導入し、各店舗への商品補充量予測に適用したのである。

売上履歴、店舗・倉庫情報、フェイス数、価格変更・割引、セール情報、天気などのデータを活用して機械学習を行った結果、従来の予測より約20%精度の高い予測モデルを生成するというビジネスインパクトをもたらした。そして現在DataRobotは、グローバル約2000店舗、1000アイテムを超える商品の需要予測を支えている。

次に紹介するのは大手ロジスティクスの取り組みで、配送センターごとの配送量予測によるレイバーマネジメントの最適化にチャレンジした。

このロジスティクスは翌月および翌々月の倉庫と顧客ごとの荷量を予測することで人員計画を作成していたのだが、人員過多によるコスト増や人員不足による配送遅延の発生を避けられずにいた。そこで顧客ごとの過去出荷実績やカレンダー、顧客情報といったデータを活用して機械学習を実施。結果として既存の予測モデルより5～10%精度の高いモデルを作成し、倉庫人員

### <代表的な需要予測パターン例。下に行くに従って予測の難易度は高くなる>

予測パターン(用途)	説明
定常型	<ul style="list-style-type: none"> <li>●長期的に波形が安定しているもの</li> <li>●シーズン性があるも一定のパターンを見出せるもの</li> <li>●過去実績(対昨年度や短期の移動平均)でほぼ説明できるもの</li> <li>※AIによるパターン学習ではなくルールモデルで十分解決できるケースも多い</li> </ul>
気温/天候影響型	<ul style="list-style-type: none"> <li>●シーズン品で特にアンコントロールな気温、天候(梅雨明け時期)と強く連動するもの</li> <li>※気温や天候影響特徴量の組み込み方法、表現力を最大化する試行錯誤を行う。予測よりはシミュレーション用途が強い</li> </ul>
販促企画/外部イベント影響型	<ul style="list-style-type: none"> <li>●販促、価格変更、意思入れなど、人為的かつコントロール可能なイベントにより波形が変動するもの</li> <li>※需要変動の影響をコントロール可能なデータで表現できるものに対して機械学習を適用する</li> <li>※災害やロコミなどアンコントロールな影響による計測は機械学習の適用は効果的ではない</li> </ul>
季節新商品型	<ul style="list-style-type: none"> <li>●毎年リニューアルされる新商品だが、商品カテゴリ単位で昨年度、一昨年度の実績を参照できるような商品</li> </ul>
期間限定/スポット型	<ul style="list-style-type: none"> <li>●不定期で一定期間販売され、短期間で終売を迎えるような商品(ハロウィン、クリスマス、年始商品等)</li> <li>※販売開始のルールが見出せない、人為的な終売理由の場合など、機械学習では難しい場合もある</li> </ul>
真新商品型	<ul style="list-style-type: none"> <li>●過去に類似の商品が全くないもの</li> <li>※機械学習では最も難度が高い。人間系の知見をもとに類似品実績を参照するほうが良いケースもあり</li> </ul>

を最適化することで10%の人件費削減を実現した。

このように機械学習を活用することで、予測精度を大きく高めることが期待できる。ただし、あらゆる課題に対応できる汎用的な予測モデルが存在するわけではない。予測テーマによって効く特徴量やパターン学習の傾向が異なるため、予測パターン（用途）に応じた予測モデルを分割して作成することが実用精度を高めるコツとなる。具体的には前ページの表に示すような難易度順の予測パターンがある。

## 大手消費財メーカー事例 高難度の新商品需要予測へ チャレンジ

最も難易度が高いとされる新商品型の需要予測について、ある消費財メーカーの事例を見てみよう。この消費財メーカーではブランドごとのプランナーによって属人的な判断で行われていた予測精度のぶれや偏在在庫の発生が課題となっていた。

そもそも新商品の需要予測がなぜ難しいのかというと、販売実績データが存在しないため過去の類似品を参考にするしかないのがその理由である。参考する類似品が異なれば、当然のことながら予測精度も違ってくることになる。相当な経験を積んだ担当者でなければ、膨大な商品の中からの的確な類似品を探してくることはできない。

新商品の需要予測でより重要となるのは、過去の実績データではなく、それ以外の有効なデータをいかに取り込んで活用できるかである。新商品需要予測は発売前から発売直後までの間に利用できるデータが時間とともに変化し、精緻化されていく。すなわち現場ヒアリングをもとに、予測ポイントによって使用できるデータを織り込んだ予測モデルを個別に作成し、洗練化を図っていく

必要がある。

例えば商品の企画段階ではアンケート調査程度のデータしかないが、発売3カ月前くらいになると店舗ごとの販促予算など、より具体的なデータが徐々に集まり始める。さらに販売直前になると取引先の数など流通チャネルや採用店舗に関するデータも揃うようになり、販売直後からPOSによる実績データや競合データも入手可能となる。

この消費財メーカーはこうしたタイムラインごとに異なる予測モデルの作成をDataRobotで効率化・自動化することで早期の業務実装を実現し、予測精度を高めたのである。また、その他の事例では過去実績や広告投下量といった数値データに加え、テキストや画像データ、空間統計情報などのデータも同時に取り込んで学習し、予測モデルを作成することができるDataRobotならではの“マルチモーダル”の特徴を生かしたものもある。

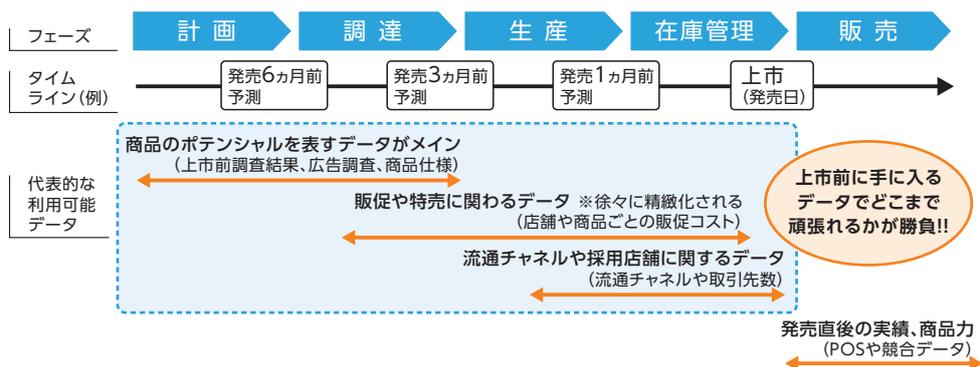
## 食品メーカーの事例 季節商品の需要予測

季節商品の需要予測の事例として取り上げるのは、ある食品メーカーの取り組みだ。この企業ではアイスクリームなど気温変動に左右されやすいメジャーブランドの計画精度の向上が従来からの課題となっており、営業側の販売計画と生産側の供給計画の双方で利用できる共通指標が求められていた。

気温が上がれば商品の販売数量が増えることは誰の目にも明らかだが、「何倍に増えるのか」という定量的な指標がないため、営業側の計画と生産側の計画にたびたび大きなギャップが生じていたのである。

この課題を解決するためにとったのが、「例年並み」「猛暑」「冷夏」といった気温変化により販売量がどう変化

### <予測ポイントによって使用できるデータを織り込みながら予測モデルを個別に作成し精緻化>



するのか確認する「シミュレーションモデルを作成する」というアプローチである。

具体的には、日鉄ソリューションズがもつ知見とDataRobotによる高速検証の機能を活用し、気温変化が出荷量へ及ぼす感応度を表す特徴量を探索。さらに、その特徴量を予測モデルへ組み込むことでシミュレーションを実現したのである。これにより「気温による変動」という暗黙知をデータにもとづいた形式知に変え、計画業務における営業側と生産側の共通の“物差し”として活用することが可能となった。

## AIへの理解や共感を促す 説明性や納得性も提供できる

最後に紹介した季節商品の需要予測の事例で最も重要なことは、単に計画精度を高めたことだけではなく、その他の要因も含めたシナリオベースの建設的な議論を、営業と生産といった部門の垣根を越えて活性化させたことにある。

ともすればAIの導入効果は予測が当たったか、外れたかといった結果に矮小化されがちだが、本来の価値はそれだけではない。現場が漠然と考えていた暗黙知をデータに基づいてしっかり形式知化し、関係者の“納得性”を醸成していくことこそ真価が発揮されるのだ。

特にトレンドが大きく変動しているコロナ期以降は時系列の予測モデルを有効活用し、直近のトレンドを

重要視した学習の実施や学習頻度を高めるといった試行錯誤を繰り返しながら、より良い予測モデルを探索していく必要がある。また、学習させる過去データ期間の設定・チューニングが肝となるほか、本番運用時についても予測時に取り込むデータの変化や予測モデルの劣化を早期に検知する必要がある。このような検証における試行錯誤の高速化や本番運用後におけるトレンド変化、モデル劣化の検知はDataRobotが得意とするところだ。

そしてAIがある予測値を示したとき、どのような根拠でそれが得られたのか、DataRobotは人間系の業務感覚とマッチした説明を行う。どうして予測が当たったのか、あるいは外したのか、AIがなぜそのように判断したのかを、1つひとつの予測結果について理由を提示することでAIに対する現場の理解を得て、議論を深めていくのである。

AIはあくまでも「データ」から得られるシグナルからしか判断できないが、一方で予測精度の向上に必要な「データ」の議論はドメイン知識（業務知識）と密接に関係しており、ひいては現場の業務改善へも重要な気づきを与えることになる。

こうしたAI推進部門と現場との継続的な議論・改善サイクルを構築し、予測精度の改善を行うと同時に、AI予測の特徴（強み/弱み）を理解したうえで予測値を自己の計画業務に生かせる現場のリテラシーを醸造させることが、AIを活用した需要予測の成功の秘訣である。

### < AIの予測精度向上に必要なデータの議論には業務知識が欠かせず、そこから業務改善への気づき生まれることも >

