

# AI時代の需要予測の意思入れ

## 【統計・AI × 人的判断】

NEC 需要予測エヴァンジェリスト／

青山学院大学 グローバル・ビジネス研究所プロジェクト研究員 山口 雄大

主に需要予測の実務家に通じる日本語に「意思入れ」があります。筆者は事業会社からテクノロジーベンダーに移籍しましたが、事業会社でSCM (Supply Chain Management)、特に需要予測を担う実務家には、業界に関わらず通じます（逆にベンダーではあまり通じません）。

SCM、需要予測の実務において、かなりAIの活用が進んできた印象ですが、それでも業界のプロフェッショナルによる「意思入れ」は行われています。今回はこの「意思入れ」についての学術知見を解説すると共に、AI時代でどう有効活用していくべきかについて考えてみたいと思います。

### 需要予測における意思入れと認知バイアス

「意思入れ」とは、統計分析やAI（機械学習）を含む、なんらかのロジックによって算出された数字を人が上書きすることを指します。この目的は、ロジックで考慮できていない要素を加味するというものです。

シンプルな例としては、

- ・過去の販売実績の平均値に、商談で決まった注文分を加える

- ・統計安全在庫に、終売予定を加味する

などが挙げられます。

現実のビジネスでは、必ずしもすべての情報をデータとして入手、整備できず、また量的にも十分でない場合がほとんどであり、一方でロジックもそれらを完璧に正しく考慮できるわけではないため、意思入れが有効になる場合が多かったと言えます。実際、みなさんの会社でも様々な計画領域で意思入

れが行われているはずです。

しかし、これは人的判断に基づいて行われるため、人の思考の癖、いわゆる認知バイアス (Cognitive Bias) の影響を受けることに留意が必要です<sup>1)</sup>。需要予測の担当者であれば、営業やマーケティング、生産管理といったバックグラウンドがある場合が多いですが、過去のキャリアや元々の性格などによって、

- ・よく使う情報
  - ・重視、軽視しがちな情報
  - ・当然だと思っている前提
- などが異なり、それらが意思入れに影響を与えます。

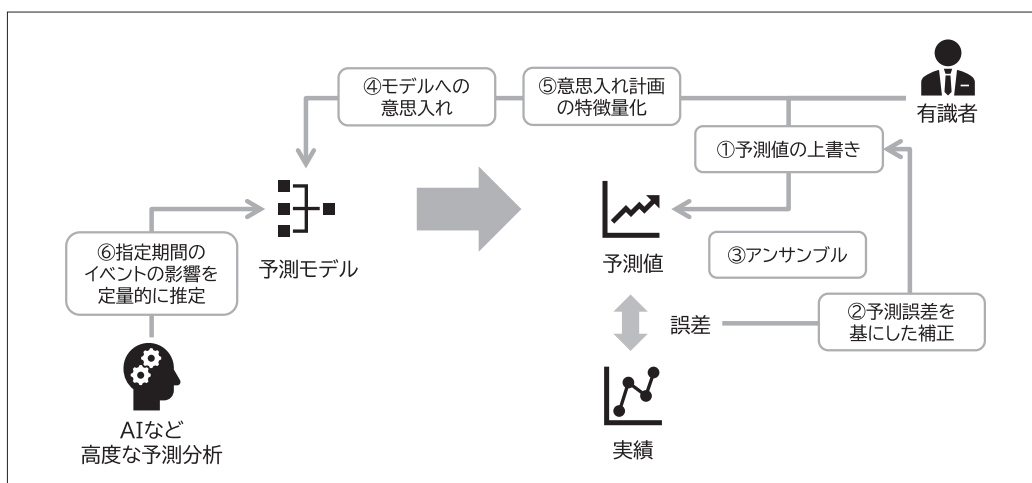
この他、

- ・自身に課せられているKPI
  - ・その時の体調や感情
  - ・計画業務に使える時間の制約
- などにも影響されるため、常に合理的な意思入れはできません。

意思入れはこうした認知バイアスの影響以外にも、根拠がブラックボックス、属人的になりやすいといったデメリットもあり、実務では課題に挙げられることも多いと言えます。

### 意思入れの種類

多くの実務家は、需要予測における意思入れを、ロジックによる予測値を直接上書きことだと認識しています。しかし学術研究によって、需要予測における意思入れには複数の種類があることが整理されています。プリンガムヤング大学のRebekah Brauらによると、具体的には次の6種類が挙げられます<sup>2)</sup> (図表1)。



\* (Rebekah Brauら, 2023) の論文を基に筆者作成

図表1 需要予測における様々な「意思入れ」方法

### ①予測値の直接的な上書き (Judgmental Adjustment)

これは一般的に認識されている意思入れですが、精度はあまり高くないという指摘があるものです。

### ②過去の予測誤差を使った補正 (Quantitative Correction)

過去の予測誤差を使った意思入れもあります。具体的には、(forecast-) Biasといった特定期間の合計誤差などの指標が有効活用できるでしょう<sup>3)</sup>。この補正の前提には、人の意思入れには特定の傾向があるという考えがあります。ただし、それは人によるだけでなく、商品や発売からの経過期間によるかもしれません。そのため、f-Baisといった指標で分析したうえで、担当者による意思入れを補正するという方法になります。

### ③アンサンブル補正 (Forecast Combination)

1と2の平均値など、担当者による意思入れ値と、その予測誤差を踏まえた補正値を組み合わせる方法です。1が常に一定の値で偏るとするのは稀であり、過去の予測誤差の変動を考慮した意思入れと言えます。

### ④モデルへの意思入れ (Input to Model-building)

これは予測値に意思入れするのではなく、予測モデルの一部に意思入れするという方法です。Rebekah Brauらの論文では、特定のイベントによる需要への影響を、統計的なモデルやAIによる予測値に、人的判断で加味するという方法を検証しています。若干バリエーションが異なりますが、筆者も長年こ

の意思入れを行ってきました。一般的には、予測値を直接上書きするよりも認知バイアスの影響を受けにくいとされます。

### ⑤意思入れ値の特徴量化 (Integrative Judgment Learning)

担当者による意思入れ値を、予測モデル(因果モデル)の特徴量、説明変数とするという方法です。論文では、過去の実績と意思入れ値の関係を回帰分析などで推定し、その係数を使って予測していますが、筆者は機械学習モデルの特徴量にするという方法も試したことがあります。これも過去の意思入れの傾向を考慮するという考え方であり、そこには一定の偏りがあることを前提としています。2つ目の方法をやや高度にしたものと言えるでしょう。

### ⑥意思入れ箇所の指定 (Human-guided Learning)

予測値を人が数字で上書きするのではなく、意思入れが必要なポイントを指定するのみという方法です。その補正値は統計分析や機械学習などを使って算出します。統計的な予測システムの中には、過去の異常値(欠品や一時的な施策影響など)だと思われる実績を人が指定すると、それを自動で補正するという機能が実装されているものがあります。これによって未来の予測への悪影響を抑えるというのが一例です。論文では、未来におけるイベント(新店舗への配荷や長期休暇、マーケティング施策など)の予定を担当者が指定することで、過去の実績から

回帰分析によって推定された影響度が加味されると  
いう予測が行われていました。



Rebekah Brauらはこれらの意思入れの精度を、  
学生を対象とした実験と企業における実際の需要予  
測データの観察によって検証しました。その結果、  
予測値を直接上書きする①よりも、意思入れ値を説  
明変数にする方法⑤と、人が意思入れの箇所を指定  
する方法⑥の方が高精度であることが示されまし  
た。特に人が意思入れの箇所を指定する方法は、該  
当するイベントの（学習）データ数が多くなると、  
精度が高くなることが示唆されています。

しかし筆者はこれには注意が必要だと考えてい  
ます。例えば、新店舗への配荷というイベントでも、  
その店舗の立地や広さ、予測の対象となる製品が置  
かれる場所や量などによって、需要への影響は変わ  
ります。これらを区別してデータを管理すると、十  
分な量を蓄積するのは難しいと言えます。マーケ  
ティング施策などでも同様です。

### 予測モデルへの意思入れ事例

筆者は10年以上、新製品需要予測で予測モデル  
への意思入れを行っていました。新製品需要予測は  
本コラムでも何度か取り上げてきましたが、過去実  
績がないため、一般的に言われる（既存品の）需要  
予測とは考え方が大きく異なるものです。多くの業  
界、企業で、製品属性やマーケティング、販売チャ

ネルなどが類似する過去発売品の需要を分析するこ  
とで、新製品の需要を予測しています。

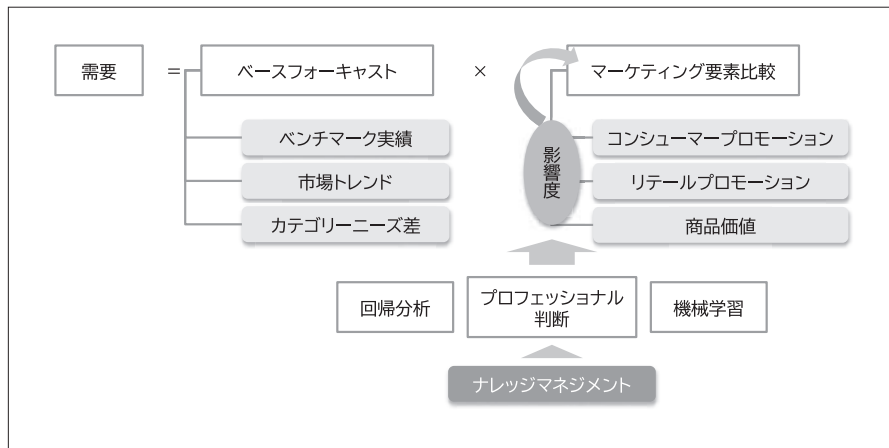
従来、ここでよく使われていたのが重回帰分析で  
す。メディア宣伝の投入額や配荷店舗数、販売価格  
などの数値データや、ブランド、販売エリアなどの  
カテゴリ値を説明変数とし、似たような条件の製品  
をまとめて分析し、各変数の影響度と言える係数を  
推定します。

しかし、こうして構築した予測モデル（因果モデ  
ル）の精度はあまり高くありません。それは以下の  
理由によるものです。

- ・例えばメディア宣伝の内容評価など、質的なデー  
タが体系的に残されていない
- ・サンプルサイズが小さく、信頼性のある係数推定  
が難しい

宣伝の効果は、その投入量だけでなく、ターゲッ  
ト層におけるモデルの人気など、質的な要素も影響  
します。しかし、それを統計分析に使える形で長年  
蓄積できているかという点、かなり難しいはずで  
す。アンケート調査などが行われることはありますが、  
すべての新製品について行うわけではなく、また質  
問の仕方も常に同じではない場合が多いと言えま  
す。これは説明変数として適切ではありません。

また、新製品を多く発売する企業でも、ある程度  
の数のカテゴリに分けると、統計分析に十分なサン  
プルサイズを集めるのに10年などかかります。しか  
し、それほど過去に遡ると、例えば購買行動の変化



\*『新版 需要予測の基本』（日本実業出版社）より抜粋

図表2 予測モデルへの意思入れ事例

によってテレビCMの影響度が変わっているなどの変化があり、これも推定される係数の信頼性を低くします。

これらの理由から、新製品の需要予測においては重回帰分析は有効になりにくいのです。そこで、筆者は予測モデル（因果モデル）の各種説明変数の影響度に需要予測担当者が意思入れするというオペレーションを設計しました<sup>4)</sup>。

予測モデルをつくれれば、実績が出た後に人が係数を想定することが可能です。どんなマーケティング施策、外部環境条件だと、どの程度、需要に影響があったかをふりかえります。この知見を参考に、今回はよりターゲット層に刺さるマーケティング施策なのか、外部環境は需要にプラスなのかマイナスなのかを、過去との比較で意思入れするのです。データで考慮できていない要素を関係者で確認し、それを踏まえる意思入れは、実際にかなり有効です（図表2）。

## forecasting & planning

これらの研究知見と事例を踏まえると、現実のビジネスにおける需要予測では、統計学やAIを使ったデータ分析は有効であるものの、データの質と量の不足を補う人的判断が重要だと言えます。つまり、データドリブンのforecastingをベースに、データにない情報を考慮するplanningでサプライチェーンを動かすのが、AI時代で目指すべき需要予測であり、かつplanningでは数字を直接上書くのではなく、認知バイアスを抑える工夫が推奨されるということです。

従来から需要予測においては人的判断が重要でした。しかし、単に数字を上書く意思入れは時代遅れになりつつあります。

- ・主に新製品については、因果関係を踏まえて因果モデルを構築し、それに意思入れをする
- ・既存品については、時系列モデルによる予測精度を高めるために、過去実績の異常値を人が指摘し、統計分析やAIで補正する
- ・また、未来の施策や外部環境変化の影響がある期間を人が指定し、統計分析やAIで推定した影響

度を加味する

といったコラボレーションを目指していくべきなのです。

ぜひみなさんの会社でも、本コラムを参考に需要予測の意思入れ方法を見直してみてください。各社に合った予測AIとのコラボレーションが生まれ出されることを期待しています。

\*文中の所属は参考文献発表当時のものです。

### 【参考文献／補足】

- 1) 需要予測における各種認知バイアスの影響については以下の書籍で詳しく考察しています。  
山口雄大, 『品切れ、過剰在庫を防ぐ技術』. 光文社新書, 2018.
- 2) Rebekah Brau, John Aloysius, Enno Siemsen. "Demand planning for the digital supply chain: How to integrate human judgment and predictive analytics". *Journal of Operations Management*, 2023;69:965-982.
- 3) 様々な予測精度管理指標については以下の動画の解説をご参照ください。  
「Vimeo需要予測入門② 海外の研究から見る 新製品の予測モデルや予測精度の評価メトリクス」  
<https://vimeo.com/677144962/d1db8aae34>
- 4) この因果モデルにおける説明変数の係数への意思入れの詳細については、『新版 需要予測の基本』第5章（日本実業出版社）をご参照ください。

### 【執筆者プロフィール】

山口 雄大 やまぐち ゆうだい

テクノロジーベンダーの需要予測エヴァンジェリスト、青山学院大学グローバル・ビジネス研究所プロジェクト研究員。化粧品メーカーのデマンドプランナー、S&OPグループマネージャー、青山学院大学非常勤講師などを経て現職。「需要予測相談ルーム」や「#山口雄大の需要予測サロン」で需要予測やS&OPに関する最新のトレンドや事業現場のリアルを発信している。個人事業主としてビジネスパーソン向けのSCM教育などを提供している。Journal of Business Forecastingや経営情報学会などで需要予測の研究を発表。著書に『企業の戦略実現力』（共著・日本評論社）や『すごい需要予測』（PHPビジネス新書）などがあり、8月に新刊『サプライチェーンの計画と分析（仮）』を日本実業出版社から上梓予定。



← 『サプライチェーンの計画と分析（仮）』はこちら