

需要予測の知の継承

【需要予測 × 経営理論】

NEC 需要予測エヴァンジェリスト 山口 雄大

昨年10月に「需要予測相談ルーム」を開設し、まだ1年に満たないものの、様々な業界約80社のSCM、需要予測に関わる実務家の方とお話しました。私が今、AIやデータ分析を管轄するデータサイエンティストの組織に属していることも影響していると思いますが、相談の半数以上が“需要予測にAIを活用してみたい”といったものでした。しかし私は、最初から需要予測AIのツールを紹介するということはしません。

その企業にとって、需要予測、ひいてはSCMやS&OP¹⁾を高度化させていくのに、より優先的な課題がある場合も多いからです。今回のコラムでは、そこで議論に挙がることが多い、需要予測のスキルや知見にフォーカスします。

需要予測の属人性

多くの業界で、需要予測の業務は属人的になりがちだという意見を耳にします。私もこれには同意しますが、以下の理由があると整理しています。

- ・比較的好く使われてきた時系列モデルは、過去の水準やトレンド、季節性を考慮するものであり、直近の環境変化や未来の施策は実務担当者が加味する必要がある
- ・時系列モデルで高い精度を維持するためには、欠品や一時的なカニバリ、施策の影響、棚落ちなどによる水準の変化などの背景を踏まえ、過去実績を補正したり、パラメータを調整したりする必要がある
- ・古典的な重回帰分析などを使う因果モデル²⁾では、需要の因果関係を実務担当者が想定し、それを説

明変数として表現する必要がある

- ・こうした予測モデルを使わない、判断的モデルのようなロジックは、予測を行う担当者の経験や知見に基づくものが多い

つまり、時系列モデルや因果モデルなどの統計的な予測モデルを活用していても、実務である程度の予測精度を維持していくためには、適宜、実務担当者がデータやアルゴリズムを調整しなければならないからです。需要予測の実務経験があまりないと、統計的な予測モデルを使えば属人性は排除できると思ってしまうがちですが、指数平滑法が在庫管理のために使われ始めて60年以上が経過³⁾しても、実務家の感覚として残っている通り、各社の需要予測業務には属人的な要素が不可欠なのです。

これはAI、現在の需要予測の文脈では機械学習モデルになりますが、そうした高度なロジックを導入しても同様です。機械学習にも様々なアルゴリズムがあり、需要予測で比較的精度が高くなる商材が多いのは、決定木、特に勾配ブースティング系です。中には多重共線性⁴⁾を考慮しないで良いものもあり、非線形の関係性に対応できるものもあるため、重回帰分析よりも複雑な因果関係を表現でき、近年はかなり使用頻度が多くなっている印象です。しかし、需要の因果関係を想定するのは実務担当者ですし、数字の背景を踏まえた補正なども有効なのは、古典的な予測モデルと変わらないため、属人的な要素が残ります。

組織の知が創造されるメカニズム

属人性というと、これまでは排除すべきものと捉

えられがちな一方、私はAI時代において、むしろ人材育成のために注視すべき要素だと考えています。というのも、ここまでで述べた通り、需要予測においては単に感覚的な予測値の提示を指すのではなく、数字の背景にある因果関係の想像に基づくアクションを指すからです。予測モデルの構築や予測値の算出などが効率化、自動化されていく一方で、実務家は需要の因果関係、つまりは顧客、消費者の心理、(購買)行動についてより深く理解し、それをデータとして表現するクリエイティビティを磨くことが有効になるのです。

この意味では、属人性というよりも暗黙知と言ったほうが適切かもしれません。

そしてこのスキルや、そのベースとなる知見を個人頼みにするのではなく、組織の力として高め、維持していくことをマネージャー以上は考える必要があります。ここで参考になるのが一橋大学の野中郁次郎名誉教授が提唱したSECI理論⁵⁾です。

この理論自体は哲学をバックグラウンドに、かなり深い考察に基づいたものなので、正確に理解したい方は参考文献に挙げた原著論文やインタビュー記事をご参照ください。ここでは、実務への応用を目的に、組織知の創造プロセスを取り上げます。

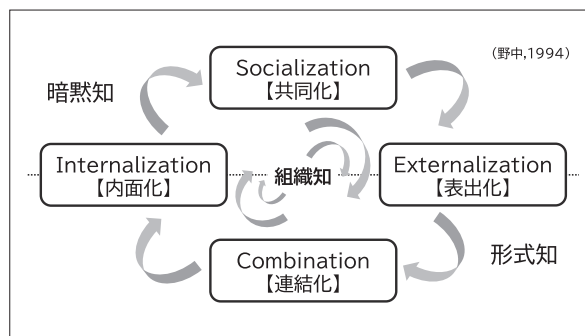
SECIとは、この知識創造プロセスの4ステップの頭文字です。

- ・ Socialization (共同化) : 対話 (知的コンバット) を介して行われる暗黙知から (他者の) 暗黙知への移転
- ・ Externalization (表出化) : 比喩や仮説構築による暗黙知の形式知化
- ・ Combination (連結化) : マニュアルや計画書、システムなどによる形式知の体系化
- ・ Internalization (内面化) : 体系化された知を活用することによる知の学習

これら4つのステップを繰り返すことで、知が創造され、それがある人物から他者へ伝えられ、組織に埋め込まれていきます (図表1)。

需要予測の知を継承するオペレーション

このSECI理論を需要予測の実務に落とし込んで



参考文献を基に筆者作成

図表1 組織知の創造理論 (SECIモデル)

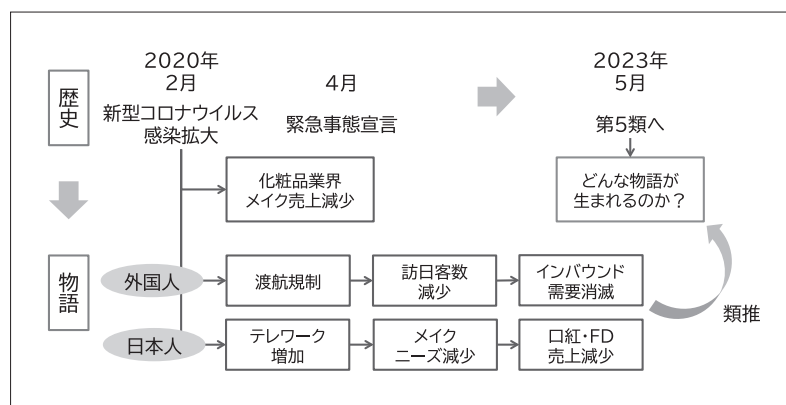
いきましょう。

まず、需要予測における「共同化」は、自社の商材やサービスの顧客、消費者に関するディスカッションの場で実現できると考えています。自分の需要予測がなぜはずれたのか、当たった理由も想定通りだったのか、そこにはどんな因果関係があり、直近で市場の変化があったのか。こうしたテーマで複数の意見をぶつけ合うことから、暗黙知が整理されていくというのは、私自身、過去に何度も体感し、定例プロセス化したものでもあります (これは前職のメーカーですでに10年近く続いています)。

続く「表出化」は、需要予測ではデータ分析のことです。ディスカッションで整理した仮説をデータで補強し、次の需要予測に使える知見になってこそ形式知と言えます。そのため、需要予測担当者のデータ分析スキルを育成することが重要になります。日本では、需要予測と他業務を兼務している企業が多くありますが、世の中の需要予測が高度になっていく中で、そろそろ専門組織を設置し、専門家を育成していくべきタイミングになっていると感じます。

3ステップ目の「連結化」は、今のAI時代に特に注目すべき概念だと思います。なぜなら、需要予測の暗黙知はAIなどの高度なアルゴリズムに「連結」し、体系化していくことがマネジメント目線で有効だからです。マネジメント目線というのは、短期的な業務だけでなく、中長期の組織パフォーマンスや関連業務、後工程の意思決定への貢献といったより広い視野で考えることを意味しています。

需要予測AIの有効活用、つまりはビジネス価値の創出については、別のコラム⁶⁾などで整理してい



図表2 歴史を物語にする

ますが、この「連結化」が適切にできるかどうかにかかっているととも言えるでしょう。

さいごの「内面化」では、需要予測においてはユーザーインターフェースやデータライブラリを含む、システムの使いやすさが極めて重要になります。体系化された知見が素晴らしくても、システムが使いつづらかったり、アルゴリズムの解釈性が低かったり、過去の知見を検索しづらかったりすると、担当者が変わっていく中でパフォーマンスを維持することが困難になります。

需要予測や需給調整、S&OPを管轄するマネージャーやディレクタークラスの実務家は、各社の組織や既存業務に合わせ、こうした知見の継承プロセスを定例化することも主導していく必要があると考えています。このSECI理論の需要予測実務への落とし込みについては拙著⁷⁾でも整理しているので、必要に応じてご参照ください。

予測知の物語と理論

野中名誉教授のSECI理論では、組織知の創造のために「ナラティブ（物語ること）」が重要だとされています。この理論における「物語」とは、これから起こることの構造だそうです。つまり、過去に起こったことの背景や因果関係について、その領域の有識者で徹底的にディスカッションすることで構造を解き明かし、それを仮説として体系化することだと私は理解しています。

需要予測の知の創造、そして継承のためにも、同様にこのナラティブが重要になると考えていて、そ

こでは「歴史」を「物語」に変換するスキルが必要になります（図表2）。

例えば、日本では2020年2月くらいからコロナウイルスの感染が拡大し、当時、私がメインで携わっていた化粧品の日本の需要にも大きな影響がありました。ここには大きく2つの背景があり、訪日外国人と日本人の物語を想像することができます。

訪日外国人は、各国の渡航規制によって、日本に来ることができなくなりました。国によってその期間や程度は異なりましたが、2014年10月の化粧品の免税対象化以降、激増していたインバウンド需要が消失しました。

日本人については、テレワークが拡大し、外出機会が減ったことで、メイクのニーズが急減しました。外出をしてもマスクが必須だったことから、特に口紅やチーク、ファンデーションといったカテゴリの需要が激減したのです。

コロナウイルスの感染拡大や、それを受けた緊急事態宣言、化粧品の中でもメイクの需要減は事実であり、「歴史」です。一方、ここで述べた訪日外国人と日本人というセグメンテーションや、需要減の背景ストーリー（因果関係）の想定は、必ずしも事実とは言えません。私や関係者が想像した、それなりに確からしい「物語」です。

しかし、こうして構造化することで、未来に何が起こりそうかを考える材料にすることができます。例えば、

- ・ 渡航規制が緩和され、訪日外国人数が回復すれば、インバウンド需要も回復する

・感染が終息、またはウイルスの弱体化などによってマスクの使用頻度が減ると、日本人におけるメイク需要が回復する

といった未来予測ができるということです(実際に、2022年の後半からこうした動きが見られました)。

つまり、組織として「歴史」を「物語」にし、蓄積してメンバーで活用できるようにしておけば、需要予測の知を継承できると考えているのです。さらに私は、この「物語」にデータ分析をかけ合わせることで、需要予測の「理論」を構築できると考えています。先述の未来予測に定量的な情報が加われば、需要予測ができそうですよね。本コラムで需要予測の実務に落とし込んだSECI理論のプロセスは、「歴史」から「物語」、それを「理論」に昇華させていくものとも言えるのではないのでしょうか。



今回フォーカスした需要予測やSCMの知見整理は、日ごろのオペレーションの中ではなかなか時間を取りにくいものだと思います。そこで、11月と12月に1回ずつ、今年の需要予測をふりかえる場を開催することにしました。詳細はQRコードからとべるリンクでご確認いただければと思います(図表3)。ぜひ私や他業界の実務家と一緒に、需要予測の「物語」を想像してみましょう!

- どうやって需要予測のPDCAを回せば良いかわからない
- 普段はオペレーションで精一杯でパフォーマンスレビューまで手が回らない
- 他業界、他社の需要予測やとりくみを参考にしたい

**需要予測の振り返りと
次年度のアクション策定セミナー**

1. 予測精度評価のためのメトリクス解説
2. アニュアルレビューのための分析軸の設定
3. 1年間のイベント整理
4. ディスカッションを通じた各社の分析
5. アニュアルレビューの発表と意見交換 など

- ✓ 11-12月開催
- ✓ 2日間
- ✓ 分析と発表
- ✓ 異業種 × 同職種の交流

詳細・お申し込みはこちら

図表3 需要予測の振り返り

【参考文献/補足】

- 1) VUCAな環境下におけるS&OPの課題と進化の方向性『S&OP』セミナーレポート第1弾【2023.08.16】 | NEC
- 2) 稀にですが、勘違いされる方もいらっしゃいますので補足しておく、時系列データを説明変数にして、そのまま重回帰分析を行うことはしません(紙幅の都合で詳細は記載しませんが、多重共線性の問題があり、月や曜日でフラグ立てを行うなどします)。あくまでも、新製品も含めた需要予測の一般的な手法として、グローバルの文献同様に、時系列モデルと因果モデルを併記しています。
- 3) Robert G. Brown, Richard F. Meyer and D. A. D'Esopo. (1961). "The Fundamental Theorem of Exponential Smoothing". Operations Research, Vol. 9, No. 5, pp. 673-687.
- 4) 説明変数間の相関関係が強い場合 (VIF: Variance Inflation Factorという値などを算出して評価する)、重回帰分析によって推定される係数の信頼性が低くなってしまうという問題
- 5) Nonaka, I. "A Dynamic Theory of Organizational Knowledge Creation". Organization Science, Vol.5, pp.14-37. 1994.
野中郁次郎. 「身体知こそイノベーションの源泉である」. *Diamond Harvard Business Review*, March 2021, p.60-69.
- 6) 不二家の新商品は失敗知らず? AIで洋菓子の流行りが分かる「需要予測」のスゴイ効果【連載】現役サプライチェーンが読み解く経済ニュース | ビジネス+IT (sbbit.jp)
- 7) 山口雄大. 『需要予測の戦略的活用』第18章. 日本評論社. 2021.

【執筆者プロフィール】

山口 雄大 やまぐち ゆうだい

東京工業大学卒業。化粧品メーカーで10年以上、需要予測を担当した後、S&OPグループマネージャーを経て、NEC需要予測エヴァンジェリストや青山学院大学非常勤講師などを兼務。[#需要予測相談ルーム] で需要予測やS&OPの相談を受け付けている。

Journal of Business Forecastingなどで需要予測をテーマとした論文を発表。著書に『すごい需要予測』(PHPビジネス新書)、『企業の戦略実現力』(共著・日本評論社)など多数。NECの公式チャンネルで「#山口雄大の需要予測サロン」を月1配信!



← 「山口雄大の需要予測サロン」アーカイブ動画はこちらから