

# 安定した予測精度と運用効率化を両立するAI需要予測 ～動的アンサンブル予測～

## AI-based Demand Forecasting for Both Reliable Prediction and Efficient Operation: Dynamic Ensemble Prediction

● 渡部 勇 ● 芳林 徹 ● 今岡 干城

### あらまし

メーカー・卸業者・小売業者がサプライチェーンを構成する流通業界において、商品開発・生産管理・物流・販売などの企業活動は需要予測を起点としている。そのため、需要をより正確に捉えた経営改善・改革が各企業の重要な経営課題となっている。しかし近年、消費者需要の多様化、商品の多品種化、ライフサイクルの短期化が進み、需要の正確な予測がますます難しくなっている。一方、少子高齢化を背景に人員確保が難しくなっており、昨今のAI(人工知能)技術の進展に伴い、AIを活用した需要予測の自動化・高度化への期待が高まっている。これに対して、富士通研究所ではAIを活用して需要予測を行う動的アンサンブル予測技術を開発した。本技術は、モデル統合の手法により、多種多様な商品の特性に柔軟に対応する安定した高精度予測を実現し、更に自動チューニングによる運用負荷軽減をも実現する。また、過去の販売や出荷の実績データがない新商品の販売予測技術である属性分解モデルも併せて開発した。

本稿では、動的アンサンブル予測技術と属性分解モデル技術を紹介するとともに、本技術を活用したソリューションの取り組みと適用例について述べる。

### Abstract

In the distribution industry supply chains are formed by manufacturers, wholesalers, and retailers. Their business activities, such as product development, production management, logistics, and sales, are based on demand forecasting. Therefore Business reforms and improvements that capture demand more accurately have become critical for companies. In recent years, however, consumer demand and products have diversified, and product life cycles have become shorter. It is thus increasingly difficult to accurately predict future demand. Moreover, the aging population with diminishing younger generations makes it difficult to secure sufficient labor power. These situations raise expectations for advanced technology, leveraging AI, to automate and enhance demand forecasting. Fujitsu Laboratories has developed an AI-based demand forecasting technology—dynamic ensemble prediction. Using a model integration method, this technology flexibly handles various product attributes and is reliable in executing highly accurate predictions. It also lessens the operational burden by means of automatic tuning. We have also developed a product attribute decomposition model for forecasting demand of brand-new products with no past results data. This paper describes the dynamic ensemble prediction and attribute decomposition model, a solution based on these technologies, and its application.

## ま え が き

メーカー・卸業者・小売業者がサプライチェーンを構成する流通業界においては、需要の予測は企業の基幹業務の起点であり、企業のビジネスを左右する重要な位置を占める。メーカーの生産計画、卸業者の受発注業務や配送計画、小売業者の発注や販売計画など、あらゆる計画業務の要は、いかに需要を正確に捉えるかである。このため、各企業は経験やノウハウに基づき、様々な情報を使って需要の見込みを立てている。

一昔前の、物を作れば売れる時代から、市場に物が飽和し、消費者が取捨選択する時代への変化に伴い、需要を正確に予測することがますます難しくなっている。各企業においては、少子高齢化の影響もあり、需要予測を起点として業務を遂行するための人員確保が課題となっている。熟練者の経験と勘に頼って成り立っている業務では、熟練者の退職などに伴って業務の遂行が難しくなり、多様化する需要予測への対策に迫られている。

昨今のAI（人工知能）技術の発展に伴い、この需要予測の課題に対して、AIを活用した解決への期待が高まっている。富士通では、2011年からAIを活用した需要予測の高度化に取り組んでいる。その一つが、産業・流通分野のお客様との実証実験で培った需要予測のノウハウを集約した、富士通研究所独自のAI需要予測技術「動的アンサンブル予測技術」である。

本技術は、多様化する需要に対し、安定した予測精度と、業務システムとして運用する際の精度維持のためのチューニングの自動化による運用の負荷軽減の両立を実現する。また、新商品の需要予測は、学習データとなる過去の販売や出荷の実績データが存在しないため動的アンサンブル予測技術だけでは解決ができない。類似商品の実績データを活用することで、この問題を解決するのが「属性分解モデル」である。

本稿では、動的アンサンブル予測技術と属性分解モデルの紹介、実証実験の結果、および本技術を活用した需要予測ソリューションへの取り組みを紹介する。

## 流通業における需要予測の現状

本章では、流通業における需要予測の現状について述べる。

需要予測に対する取り組み状況は企業ごとに異なる。最も基本的な予測方法としては、前週同曜日や前年同月などの実績をベースにした移動平均値や、線形回帰による簡易的な予測値を利用するケースが多い。これらはベース需要が比較的大きく、安定している場合には有効な方法であるが、突発的な変動を予測できない。そのため、定番商品に対しては有効であるが、消費期限が短く日々の需要変動が激しい日配品や間欠需要、新商品需要などには対応できない。

このような需要に対しては、生産部門、営業部門、需給調整部門などが計画値を策定しているのが現状である。また、ICTの活用レベルも企業ごとに異なる。表計算ソフトを使用して人手で予測値を算出している企業もあれば、統計手法や機械学習による需要予測システムを構築し、計画業務に活用している企業もある。商品の多品種化や需要の多様化が進むにつれ、人による作業には限界が生じ、更にICT化による作業自動化・効率化が喫緊の課題となっている企業も少なくない。

需要予測には従来から多数の手法がある。例えば、過去の実績の周期性やトレンド、自己回帰に基づく予測、あるいは相関のあるデータを取り込み、外部要因の変化に追随する予測などがある。したがって、これらの手法を予測対象とする需要の特性に応じて使い分けが必要となる。代表的な予測手法と特性を表-1に示す。

これらの予測手法から、多品種化が進む膨大な商品に対して、個々に予測手法を人手で選択し続けることは現実的ではない。このため、最適な予測手法を商品ごとに自動的に選択することによって、一定以上の予測精度を実現するアプローチが有効となる。本アプローチは、既に一部の領域で実用化されている。

しかし、商品の販売傾向は必ずしも固定的ではない。商品の販売開始から定番化し、終売に至るまでに、その販売傾向は様々な要因によって変化していく。定番化し販売数が安定している期間では、過去実績の周期性やトレンドが有効であるが、

表-1 代表的な予測手法と特性

| 予測手法        | 概要  | 予測精度<br>○：高，×：低，△：中                 |       |              | 予測因子 |                      |
|-------------|---|-------------------------------------|-------|--------------|------|----------------------|
|             |   | 実績値のボリューム<br>(学習・予測する数値<br>そのもの大きさ) |       | 過去データ数が少ない場合 | 取込可否 | 因子による影響の有無や強弱の分かりやすさ |
|             |   | 大きい場合                               | 小さい場合 |              |      |                      |
| ランダムウォーク    | 最新の実績値を予測値とする最も単純な手法                        | ×                                   | ○     | ○            | 否    | —                    |
| 重回帰         | 因子(休日、気象など)と販売数の相関関係から予測                    | △                                   | ×     | ×            | 可    | 容易                   |
| ポアソン回帰      | 重回帰の誤差分布をポアソン分布としたモデル。実績値のボリュームの少ない商品の予測に強い | △                                   | ○     | ×            | 可    | 容易                   |
| ARIMA       | 過去の実績値との相関関係から予測                            | △                                   | ×     | ×            | 否    | 困難                   |
| ARIMAX      | ARIMAモデルと重回帰を併せた手法                          | ○                                   | ×     | ×            | 可    | 容易                   |
| 動的線形モデル     | データが追加されるたびに内部の潜在状態を更新して予測。動的な変化に対応可能       | ○                                   | △     | ○            | 可    | 容易                   |
| 指数平滑状態空間    | トレンドと周期性に着目して予測                             | △                                   | ×     | ○            | 否    | —                    |
| ニューラルネットワーク | 人間の脳を模した数学モデルによる予測                          | ○                                   | ○     | △            | 可    | 困難                   |

ARIMA : Autoregressive Integrated Moving Average

ARIMAX : Autoregressive Integrated Moving Average with Explanatory Variable

例えばテレビ番組で取り上げられたりソーシャルメディアで流行したりするなどの影響を受ければ、販売数は大きく変化する。そのため、予測手法を固定しては、このような変化にも柔軟に対応できない。

需要予測を行う上で、もう一つの主要な課題が新商品の需要予測である。新商品は、過去の販売や出荷の実績が存在しないため、従来の統計的な手法では予測できない。そのため、予測対象の新商品に対しては、類似する既存商品の需要傾向を参考にして需要予測を立てている。しかし、システム化が進んでおらず、商品の多品種化、ライフサイクルの短期化が進む中、人による予測には限界がある。この問題に対して、富士通では新商品予測をシステム化するための独自技術である属性分解モデルを開発した。

### 富士通研究所独自の動的アンサンブル予測技術

富士通研究所では、従来からある時系列解析技術にAI技術の一つである機械学習を組み合わせることによって、需要予測の精度向上と自動チューニングを実現する動的アンサンブル予測技術を開発した。

#### ● 従来技術とその問題点

表-1に示すように、様々な需要予測の手法が提案されている。しかし、どのようなケースに対し

ても高い精度が得られる万能な手法はなく、予測対象の商品特性や予測方法の特性(学習・予測する数値そのもの大きさ、学習できる過去の実績データの数、利用できる因子など)によって、最適な手法が異なってくる。

図-1は、様々な手法で需要予測を行った際の、予測期間(何日後の予測を行うか)と予測誤差の関係をグラフ化したものである。これから、ARIMAXなどの手法は重回帰や指数平滑などと比べて使用しているモデルが複雑であり、時系列データの特徴を詳細に捉えられることが分かる。このため、より多くの情報(休日・気温など)を取り込むことが可能な長い予測期間であっても、高精度に予測できる。

一方、複雑なモデルを構成する多量のパラメータを正しく学習するために、学習期間(学習に用いるデータの期間)を十分に長く取る必要がある。発売後間もない新商品や季節商品、出荷数の少ない間欠需要商品など、学習に使用するためのデータが十分に得られないケースでは、パラメータの学習が不完全になり、重回帰や指数平滑などのパラメータ数の少ないシンプルな方法よりも、むしろ精度が悪くなるという逆転現象が起き得る。

上記のように、予測対象や予測特性によって最適な手法が異なること、そしてそれが商品のライ




図-1 予測期間と予測誤差の関係

フサイクルによって動的に変わることが、需要予測精度の継続的な維持に対する大きな問題である。

● 開発技術

予測対象や予測特性に合わせて最適な手法を選択する必要があるという課題は、需要予測に限らず、機械学習や統計的予測において共通するものであり、その解決方法として「モデル選択」が用いられることが多い。モデル選択では、例えばデータへの適合度や予測精度などのモデル選択基準を定め、過去のデータで最も精度が高かったモデルの一つを選択する。予測対象や予測特性が固定的であれば、このモデル選択により各商品の特性に合わせた最適な予測手法を自動的に選び出すことが可能である<sup>(1)</sup>

一方、流通業における需要予測のように、予測対象の特性が商品のライフサイクルによって動的に変わるようなケースにおいては、最適な手法もまた、それに合わせて動的に変化することになる。このような場合には、直近のデータでモデル選択を行いながら、それを逐次的に更新していくという方法も考えられる。しかし、最適な方法の一つ

選ぶというモデル選択では、最適なモデルが切り替わる際（最適と想定していたモデルが最適ではなかった場合）に予測誤差が非常に大きくなるという問題があった。

機械学習の分野では、多くの学習モデルを組み合わせさせて高精度な予測を実現する「アンサンブル学習」と呼ばれる手法が広く用いられている。時系列解析の分野においては、このアンサンブル学習の関連技術として、複数の手法の予測結果に対して重み付け平均して予測値を算出するモデル統合<sup>(注)</sup>と呼ばれる手法が知られている。

一般的には、複数の予測モデルから最良なものを一つ選ぶモデル選択に比べると、精度が劣るモデルも予測の中に組み入れてしまうモデル統合の方が、精度が悪くなるように誤解されがちである。しかし、最適なモデルが動的に変化する状況においては、最適から外れた場合のリスクを低減できるモデル統合の方が、長期的に見ると安定的に高い精度で予測できることが知られている<sup>(2), (3)</sup>

(注) モデル平均 (Model Averaging), あるいは予測統合 (Forecast Combination) とも呼ばれる。



モデル統合においては、予測結果の重み付け平均を行う際の重みをどのように決めるのが重要である。最も簡単な方法は、重みを均等にして単純平均を取るものであり、この方法でもモデル選択よりも高いパフォーマンスが得られることが分かっている。動的アンサンブル予測技術では、機械学習を用いて予測誤差の予測を逐次的に行い、予測誤差の大小によって重みを動的に調整することで、更なる高精度化を実現している。

予測対象の商品特性および予測方法の特性と各手法の予測誤差の間には、一定のパターンが存在している。そこで、過去のデータを用いて、以下の五つの特性値を説明変数、予測誤差を目的変数とする回帰モデルを構築する。これによって、予測誤差を予測し、得られた予測誤差に応じて重み付け平均の重みを決定する。個々の手法における学習と、統合のための学習の二段階で学習することが特徴となっている。

(1) 予測特性

予測期間、モデル期間など、予測の目的や方法によって決まる特性。

(2) 静的な商品特性

商品分類、売価など、販売前から決まっている変化しない特性。

(3) 動的な商品特性

販売間隔、販売数量など、販売後に得られる変化する特性。

(4) ライフサイクル特性

発売からの経過日数、商品フェーズ（導入期・成長期・成熟期・衰退期を売上変化から推定）など、商品のライフサイクルに応じて変化する特性。

(5) 直近の誤差

直近の平均的な予測誤差。

● 実データによる効果検証

実データを用いた動的アンサンブル予測の効果検証実験の結果を図-2に示す。ここから、統合に使用した個々の手法の予測誤差よりも、モデル統合によって得られた予測値の誤差の方が小さく、高精度に予測できていることが分かる。

前述した予測特性や静的な商品特性は、時間とともに変化しない特性である。このような特性を回帰モデルに取り込むことによって、安定的な予




図-2 動的アンサンブル予測の効果

測が実現できている。

一方、動的な商品特性やライフサイクル特性は、各商品のライフサイクルに応じて変化する商品特性である。このような特性を回帰モデルに取り込むことによって、ライフサイクルに応じた商品特性の変化を捉えた重み付けが可能となる。更に、直近の平均誤差を回帰モデルに取り込むことにより、予測特性や商品特性では説明できないトレンドなどの外的要因を重み付けに反映できる。なお、直近の予測誤差以外の特性に関しては、全商品で統一的なモデルを構築することで、データが少ない場合でも高精度の重み付け学習が可能である。また、新商品のように過去データがない場合でも、類似する特性の情報を活用した予測が可能となる。

このように、予測特性、静的な商品特性、動的な商品特性、ライフサイクル特性、および直近の平均誤差を用いて予測誤差を予測する動的アンサンブル予測によって、多種多様な商品の動的な特性変化に対応したチューニングを自動化することで、人手を掛けずに高精度な需要予測を継続的に行うことができる。

**属性分解モデルによる新商品予測技術**

コンビニで取り扱われている約3,000個のアイテムに対して、新商品の数は年間約5,000個に達している<sup>(4)</sup>。このように次々に導入される新商品の需要をどのように予測するかは、商品を取り扱う流通業はもちろんのこと、開発するメーカーにとっても大きな課題となっている。

富士通研究所では、テキストマイニングと機械学習を組み合わせることにより、新商品の企画情報から初期需要を予測する属性分解モデルを開発した。

● 従来技術とその問題点

表-2は、新商品の需要予測活用フェーズごとに利用可能なデータと適用技術をまとめたものである。発売開始後しばらくすると、その商品の販売や出荷の実績情報が蓄積されてくるため、動的アンサンブル予測などを適用できる。一方、上流のフェーズでは利用可能なデータが足りないため、そのフェーズが持つ過去データだけで高精度な予測はできない。

表-2 新商品需要予測のパターン

| 需要予測活用フェーズ       | 主要な活用部門                       | 利用可能なデータ                          | 適用技術                  |
|------------------|-------------------------------|-----------------------------------|-----------------------|
| 研究・開発            | マーケティング                       | 企画情報<br>+<br>商品特性                 | 属性分解モデル               |
| 企画・計画            |                               | 企画情報<br>+<br>商品特性<br>+<br>販売計画    |                       |
| 発売直前<br>(営業開始後)  | マーケティング<br>+<br>営業<br>+<br>受給 | 企画情報<br>+<br>商品特性<br>+<br>販売計画    | 属性分解モデル<br>+<br>回帰モデル |
| 発売直後<br>(1～2週間後) |                               | 営業情報<br>+<br>販売実績<br>+<br>プロモーション |                       |
| 発売後～終売           |                               | 評判<br>(ソーシャルメディア)                 |                       |

そこで、過去の類似商品の実績データを参考に予測する方法が一般的である。例えば、発売直前の受注実績や発売直後1～2週間の販売実績から推測される類似商品の売れ方のパターンを参考にし、需要を予測する方法などが提案されている<sup>(4)</sup>

新商品の需要予測活用フェーズの最上流である研究・開発および企画・計画フェーズでは、需要予測に使用できる情報が更に限られてくるため、開発側が主観的に想定・判断するケースも多い。そのため、初期需要を見誤って欠品や過剰在庫に陥ることも少なくない。

### ● 開発技術：属性分解モデル

富士通研究所が開発した属性分解モデルでは、研究・開発および企画・計画フェーズで作成される企画書などにテキストマイニング技術を適用して、各商品の属性情報（ターゲット層、商品特徴、など）を抽出・分類する。次に、機械学習技術を用いて、過去の販売実績データから各属性情報の売上貢献度（商品力）を定量的にモデル化する。新商品の需要予測を行う場合には、対象商品の属性情報に対して売上貢献度を組み合わせて販売量を推定する。

従来の手法が過去の類似商品の情報をそのまま使用するのに対して、属性分解モデルでは過去の商品の情報を商品属性と売上貢献度に分解して利用する。一方で、新商品と部分的に類似する商品はあっても、全体として類似する商品が存在しないケースも多い。この場合、属性分解モデルでは、部分的に類似する情報を活用することで高精度な需要予測を可能としている。

### ● 実データによる効果検証

コンビニおよび食品メーカーのデータを用いて、新商品の需要予測の精度を評価する実験を実施したところ、いずれのデータにおいても、

- ・全商品の1/3で予測誤差が±10%以下
  - ・全商品の1/2で予測誤差が±20%以下
  - ・全商品の2/3で予測誤差が±30%以下
  - ・全商品の90%で予測誤差が±50%以下
- という結果が得られた。

いずれも、営業の受注情報や初期の売上情報などは一切使用せずに、企画情報のテキストのみを用いて発売第一週の販売量を予測している。これは、需要予測活用フェーズの最上流で実施可能な

予測パターンに対応するものであり、営業情報や初期販売実績などと組み合わせれば、より高精度な予測を行うことが可能である。

### 業務適用シーンと想定効果

富士通では、企業が保有する販売データや在庫データなどの業務データと、現場の日報などの生データやソーシャルメディアなどの外部データを組み合わせた情報活用によって、現場の業務革新を支えるソリューションFUJITSU Business Application Operational Data Management & Analytics（以下、ODMA）を提供している<sup>(5)</sup>

前述した動的アンサンブル予測技術と属性分解モデル技術を活用した需要予測ソリューションODMA需要予測SaaSをODMAソリューションのラインナップに加え、クラウド型サービスとして2018年4月から提供を開始している。

ODMA需要予測SaaSは、企業の各種実績データと、需要に影響を与える様々な外部データを蓄積し、将来の需要予測データを算出してSaaS（Software as a Service）で提供するクラウド型サービスである。本サービスは、各企業の業務システムにアドオンする形態で導入できる。

本ソリューションでは、中核となる需要予測エンジンに加え、入出力データの加工処理、属性に基づき対象をグルーピングするクラスタリング、テキスト情報から属性情報を抽出するテキストマイニングなどのライブラリを標準装備し、予測モデルを柔軟に作成・運用できる仕組みを提供する。また、本ソリューションは予測モデルの継続的な成長を支える拡張性を重視している。これを実現するために、予測対象の増加に伴うスケールアウトが可能なアーキテクチャー、動的アンサンブル予測によって統合する予測手法の追加、外部データの追加を可能とする汎用的なフレームワークを備えている。

本ソリューションの適用効果を見極めるための実証実験をお客様と協同で進めている事例の中から、小売業およびメーカーにおける業務適用シーンと想定効果について、以下に紹介する。

### ● 量販店における発注の最適化

小売業においては、店舗の発注業務の効率化が課題となっている。不慣れな従業員が多い量販店

では発注精度のばらつきが大きく、また発注作業に時間がかかるため、重点売り場作りや品出しなどが手薄になるという問題がある。これに対して、需要予測と在庫状況から最適な発注数を勧告値として算出し、これを活用することで在庫の適正化を図り、欠品による販売機会ロス削減や不良在庫を削減できる。更に、発注時間の短縮によって魅力ある売り場作りに注力できる。

ある量販店において、日配品および惣菜を対象として、需要予測に基づく発注勧告値を採用した場合の効果を生産数の推移シミュレーションによって検証した。その結果、平均在庫数と欠品回数が従来に比べて減少したことが確認できた。

### ● 食品メーカー生産計画におけるロス削減

食品メーカーにおいては、生産計画を作成する際の需要予測の精度向上が課題となっている。定番商品については、需要の変動幅が比較的少ないことから、需要予測に基づく生産計画作成の自動化により、計画の安定化と作業負荷の軽減が見込める。一方、新商品や季節品では、商品の多品種化やニーズの多様化により、商品ごとの需要を正確に予測することが難しいため、過去の類似商品の出荷実績に基づいた予測から生産計画を作成している。しかし、発売後の実績との乖離<sup>かいり</sup>が大きく、廃棄ロスや販売機会ロスが問題となっている。

これに対して、新商品の企画情報や類似商品の過去の販売や出荷の実績データを利用した予測をシステム化することにより、新商品に対する需要予測の精度を高め、生産計画の適正化によるロス削減が実現できる。

ある食品メーカーとの実証実験において、定番商品および新商品の需要予測に本ソリューションを適用し、従来の予測との比較を行った。定番商品においては平均誤差率5%程度となり、従来の人手による予測修正作業も含めて自動化できる見通しを得た。また、新商品においては、発売前の初期出荷数と出荷後の週次の予測に基づく出荷調整を行うことで、終売時の総出荷数に対する在庫数の削減効果が確認された。

## む す び

本稿では、流通業界における需要予測の課題の解決方法を提供するために富士通研究所が開発し

た、動的アンサンブル予測技術と属性分解モデル技術を紹介した。また、本技術によるソリューションの取り組みと適用事例について述べた。

今後は、本稿で紹介した需要予測技術とソリューションを基盤として、流通業をはじめとして多くの業種・業態の需要予測高度化に取り組んでいく。需要予測の高度化は、本稿で紹介した予測技術の高度化だけでなく、需要をより正確に把握し予測するための予測因子として利用するデータを拡充するアプローチも必要となる。今後の取り組みで実践知を蓄積し、先に述べたソリューションの拡張性を活かして有用な予測の実現に継続的に取り組み、需要予測を必要とする業務に広く適用していく。

### 参考文献

- (1) 杉山 将ほか 監訳：統計的学習の基礎。共立出版、2014.
- (2) 安道知寛：高次元データ分析の方法。朝倉出版、2014.
- (3) G.Elliott et al. : Economic Forecasting. Princeton University Press. 2016.
- (4) 中村 博：新製品のマーケティング。中央経済社、2001.
- (5) 富士通:FUJITSU Business Application Operational Data Management & Analytics.  
<http://www.fujitsu.com/jp/solutions/business-technology/intelligent-data-services/ba/product/operational-data-management-and-analytics/>

### 著者紹介



渡部 勇 (わたなべ いさむ)

(株)富士通研究所  
人工知能研究所  
ビッグデータ・IoT・AIを需要予測・マーケティング・故障予測などの実問題に適用するための応用研究・実践研究に従事。





**芳林 徹** (よしばやし とおる)

富士通 (株)  
デジタルソリューション事業本部  
ビッグデータ・AIを活用した新情報系  
ソリューションの企画・開発に従事。



**今岡 干城** (いまおか たてき)

富士通 (株)  
デジタルソリューション事業本部  
ビッグデータ・AIを活用した新情報系  
ソリューションの企画・開発に従事。