

# 家電製品などの補修用性能部品の需要予測AI開発・適用

Mitsubishi Electric's New AI Forecasts Demand for Appliance Repair Parts

前田千徳\*  
Kazunari Maeda  
小部敬純†  
Takasumi Kobe  
永松大居\*  
Daigo Nagamatsu

寺本一季\*  
Kazusue Teramoto  
金子貴幸\*  
Takayuki Kaneko

## 要旨

製造業で、市場競争力を高めて経営基盤を強化し、さらに顧客満足を獲得するためには、生産力・販売力だけでなく、保守・アフターサービスを含めたトータルでの価値提供力の向上が求められている。

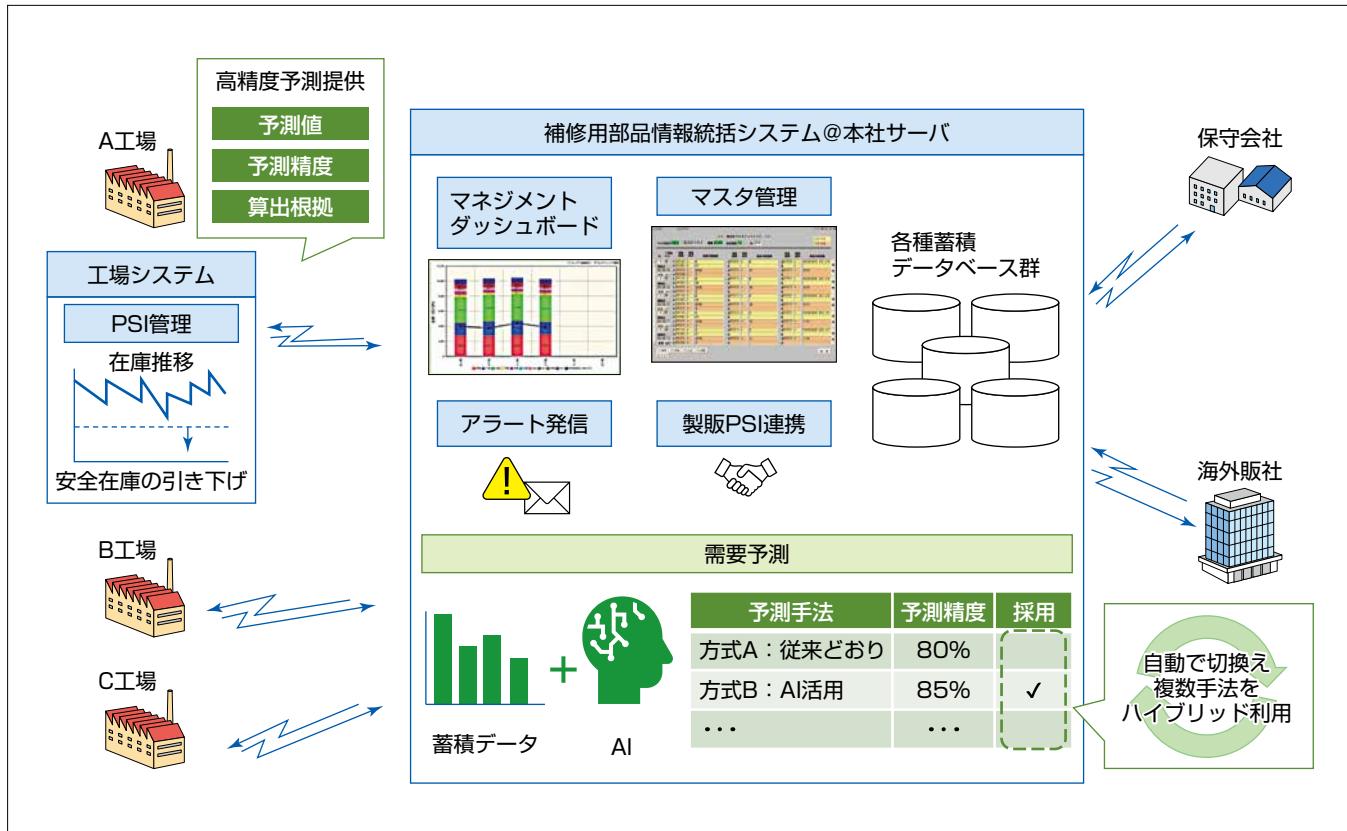
保守・アフターサービス領域で必須とされる補修用性能部品(以下“補修用部品”という。)の即出荷体制、すなわち常時在庫化について、三菱電機では定期的に部品ごとに将来の需要を予測し、持つべき在庫量を定めて、必要な生産(手配)数を算出し、欠品を起こさないように運用している。しかし、需要予測が出荷数量の変動からずれることを考慮した在庫量にしているため、製品本体の在庫量(在庫月数)

と比較して2~3倍多い状態になっている。

一方、近年様々な分野で利活用が広がっているAI(人工知能)について、当社は対外的なソリューションサービスに組み込んだり、製造現場への適用を進めたりしている。

今般、家庭用電化製品などの補修用部品の社内業務であるPSI管理<sup>(注1)</sup>にAIを活用することで、部品ごとに行っている需要予測の精度を従来比25.6%改善し、先に述べた必須要件を満たしつつ、課題であった在庫の適正化を実現した。

(注1) PSIとは、生産(Production)、販売(Sales)、在庫(Inventory)の頭文字を取った略称で、それぞれの数量を一体的に計画策定する業務のことである。



## 補修用部品情報統括システム

家電・空調・住宅整備の補修用部品にまつわるマスター・PSI情報を、工場や保守サービス会社・海外販社など各拠点から収集・集約・加工し、様々なサービスを提供するシステムを示す。今回、そのサービスの一つである需要予測機能にAIを適用し、予測精度を向上させた。

## 1. まえがき

家電製品や住宅設備などの量産製品は、消耗や修理による交換など、その製品機能の維持のために補修用部品を在庫として製造打切り後一定期間(5~10年など)保有し、市場供給することが製造業表示規約で定められており、当社もそれに準じている。

その一方で、顧客ニーズの多様化や移り変わり・技術進歩の加速に応じた製品開発・市場投入によって、管理すべき補修用部品は現在数十万点に及んでおり、それらを一点点ずつ行っている供給管理業務の効率化と、安定的に市場供給するための高精度な需要予測が求められていた。

本稿では、当社で開発したAIによる高精度で需要を予測する手法と、AIを業務へ適用した事例について述べる。

## 2. 従来システムの問題

補修用部品は同一部品を製品生産時にも使用するため、当社では製品を製造した各製造拠点で生産／調達している。部品手配は、部品の市場への供給状況を参考に手配数を決定するが、部品は各保守会社や販売会社を通じて市場へ供給されるため、各保守会社／販売会社の販売実績を集計し、先行きを予測する必要がある<sup>(1)</sup>。そこで、各製造拠点がデータの集計や需要予測を効率化するため、各保守会社／販売会社の販売実績の集計と今後の需要を予測するシステムを導入した(図1)。

補修用部品にはヒーターや扇風機のように使用する期間に季節性があり、月別の需要変動が大きいもののが存在する。そのためこのシステムの需要予測では、予測対象部品の直近12か月の販売数量平均と季節変動要因を基に、各月の需要増減を指数化したパラメータを組み合わせて予測している。

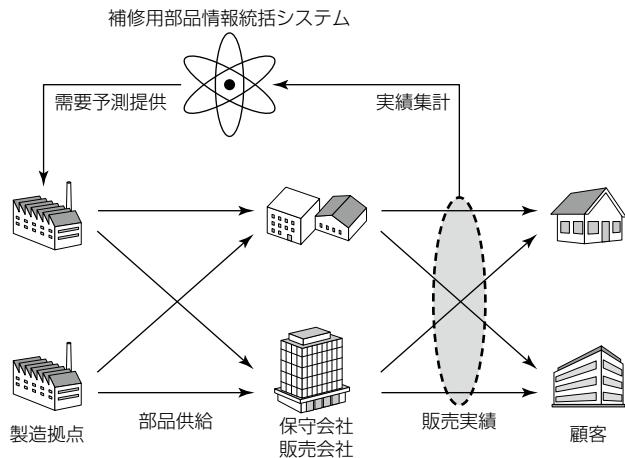


図1. 部品供給の流れとデータ収集と活用のイメージ

一方、この手法では過去の出荷数量実績に左右されるため、過去実績に傾向性が強く出ている場合(出荷が右肩上がり、又はその反対)については予測精度が落ちて、予測誤差から在庫の過剰や不足といった問題を抱えていた。また各製造拠点はこの需要予測値をベースに部品を手配するが、予測値の精度は誤差率±20%以内の部品が全体の25%と低いにもかかわらず精度を提示する機能がなく、その値を採用するか補正するかは管理担当部門の判断に委ねられていた。

## 3. 需要予測AIの開発と業務適用

この章では、まず、開発した需要予測AIの概要を述べて、その後、従来手法との特性を踏まえた併用方法といった実用化の際の工夫点や実際の分析手順について述べる。

### 3.1 需要予測技術の概要

この研究では、予測根拠の明示による意思決定の迅速化や暗黙知の定量情報化を目指して、予測対象と同品種の類似データ(以下“教師データ”という。)を使用した機械学習の時系列分析に基づく予測方式を開発した。

従来、一般的な時系列分析の手法では説明性が弱いという課題があった。例えば、ARIMA(AutoRegressive Integrated Moving Average)モデルなどの従来の時系列データ解析手法を適用した場合では、自己回帰をベースにした算出結果であるため、将来の変動要因の説明が不十分である。また、複数のパラメータを使用して予測する場合でも、機械学習の出力過程はブラックボックス化されており、モデルの解釈が困難な場合が多い。

一方、この研究では、説明性の弱さに対応するため、教師データとして既存部品の出荷数量実績を使用した分析を実施した。具体的には、既存部品の出荷数量実績の類似度を分析し、類似パターンごとに分類することで予測対象部品の将来の傾向を推定する方式を開発した。この方式によって、説明性の高い予測が可能である。また、予測に使用した既存部品の出荷量実績との関連度や傾向を併せて提示することで、現場担当部門の意思決定支援の高度化を可能にした。類似パターンごとの分類には、クラスタ分析を活用している。妥当なパターン分けによる分類やパラメータの設定等の初期設定の省力化を目指して、自動的に適切なクラスタ数を決定可能なX-means法を活用した。

図2は、予測対象と教師データを直接比較した概念図で、横軸は時系列で縦軸は規格化された数量である。ここから無数の教師データを一まとめに比較した場合、有効な教師データの抽出が難しいことが分かる。

図3は、X-meansによって無数の教師データを10パ

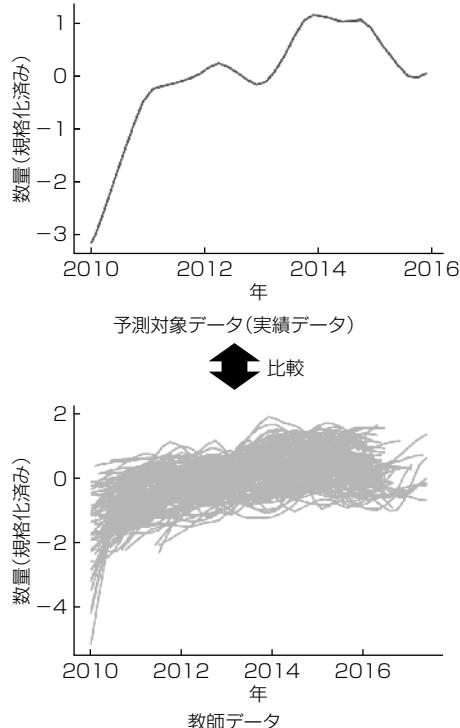


図2. 類似パターンへの分類例(予測対象との直接比較)

ターンの傾向に分類した結果の事例で、点線は各分類内での教師データを集約した代表パターンを示している。X-meansによる分類でおおむね傾向ごとの分類が可能なことが分かる。

図4は、図3に予測対象部品の実績を重ね合わせたもので、予測対象がどの分類と類似しているかを測っている。さらに図5では、その結果として予測に使用する類似パターンを抽出した例である。

### 3.2 従来手法との併用

補修用部品の需要は、製品使用時間の経過に伴って変化することが多い。一般的に製品の故障率は、使用開始直後に比較的多く(初期故障期)、その後、一定期間まで安定した値になる(偶発故障期)。

AI需要予測方式は類似部品の販売実績から販売経過期間を考慮して需要予測ができるところから、需要が変動する期間の予測得意とする一方、故障が少なく稼働が安定している期間では、当該部品の販売実績だけで予測する従来の予測方式の方が予測誤差が小さいこともあった。製品ライフサイクルに応じた需要予測を実現するため、従来型の予測方式の長所も生かして、販売動向によって最適な需要予測方式を使い分けるハイブリッド型の需要予測方式を構築した。

予測方式の選択は、部品ごとに従来の需要予測方式とAI需要予測方式のそれぞれで予測させ、過去一定期間の予測誤差を自動的に比較し、担当部門が誤差の状況を確認

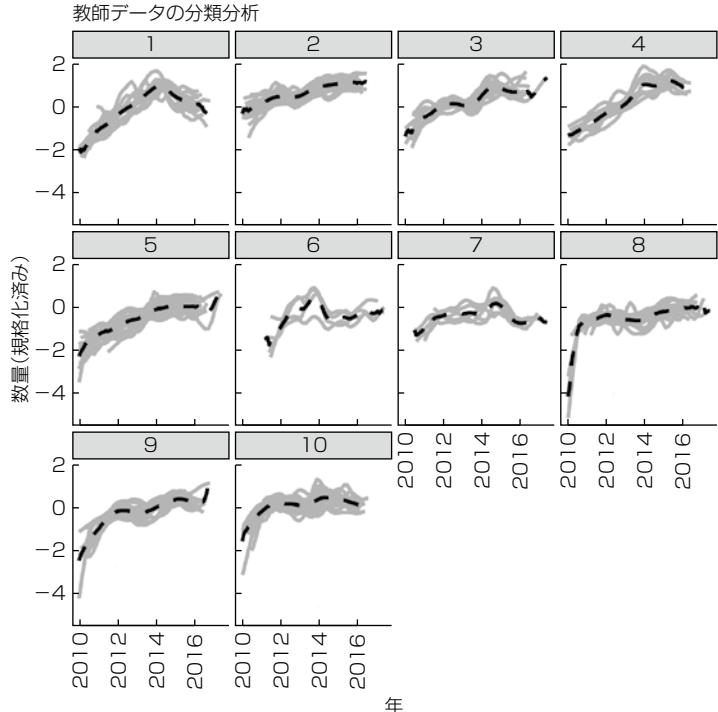


図3. 類似パターンへの分類例(教師データの分類)

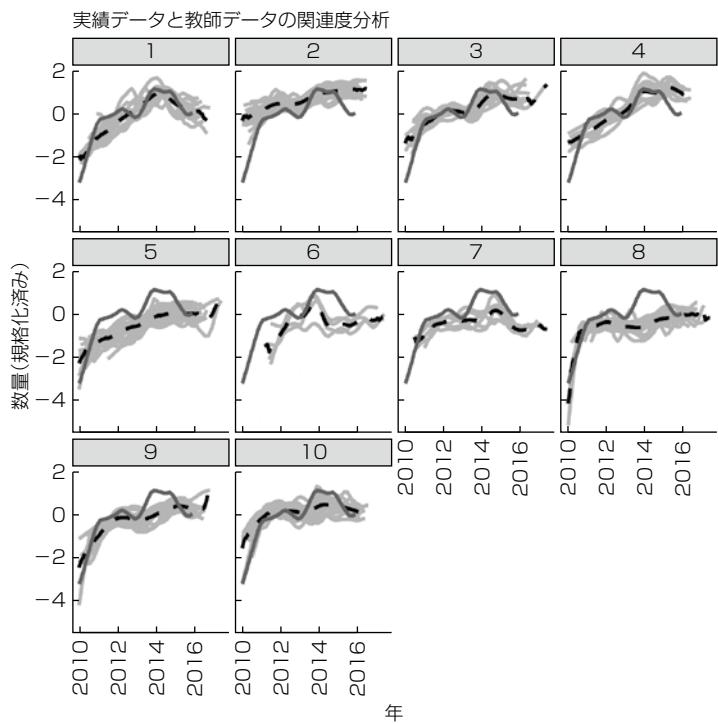


図4. 分類結果と予測対象の比較

した上で選択できる運用にした。次に業務手順を示す(図6)。

- ①予測方式の実績評価期間で誤差が小さい予測方式を計画担当部門へ自動で提案する。
- ②計画担当部門が予測誤差別に部品を仕分する。
- ③予測誤差が小さく、精度が期待できる部品には提案された予測値を適用する。

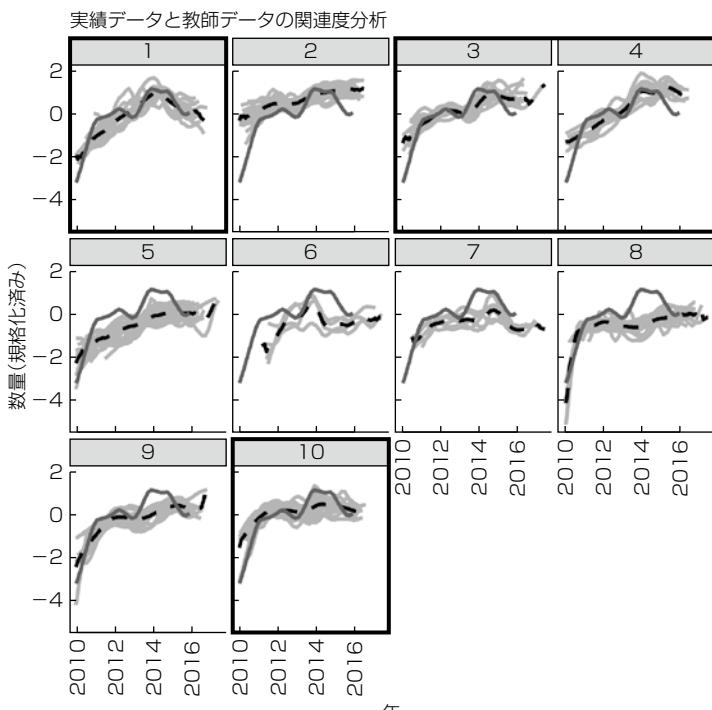


図5. 類似パターンの抽出例

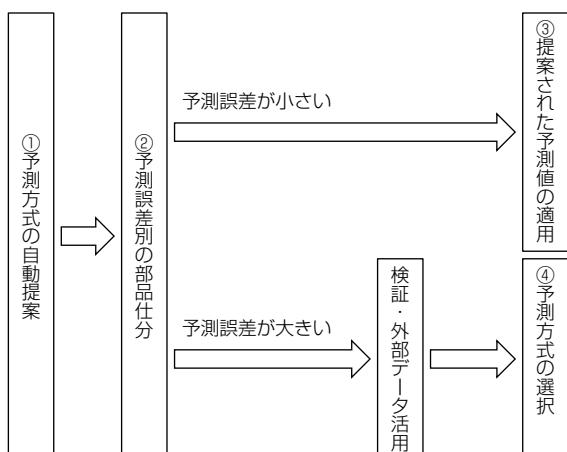


図6. 予測方式選択の業務手順

④どちらの予測方式も予測誤差が大きい部品の場合は、気象情報など販売数量以外の情報を考慮して担当部門がどちらかを選択する。

この業務手順を運用することによって、担当部門は予測誤差が大きい部品に注力して対応でき、補修用部品の欠品問題を改善しつつ、余剰在庫の抑制を行えるようになった。なお、この予測方式の見直しは定期的に行うことにしている。

### 3.3 実用化に向けたチューニング

この研究では、従来予測に対して精度の高い予測値を算出できる一方、過去区間では予測誤差が低かったのにもかかわらず突発的に実態に合わない予測値が算出される部品

もあった。調査を進めたところ、販売傾向が緩やかな上昇又は下降傾向にある部品は、参考にする教師データが過剰になり、過学習が発生していることが判明した。そのため、教師データの採用数を抑制する改修を行った。

## 4. 更なる精度向上に向けた改善

今回開発した需要予測AIを家電製品の補修用部品に適用した結果、需要予測精度を従来比25.6%改善するとともに、供給遅延を防ぐために持っている安全在庫を13%低減できた。更なる精度向上に向けた今後の改善方針を次に述べる。

### 4.1 クラスタリング参照手法の追加

この研究では、予測する部品と、AIが事前に作成した教師データとの相関係数を算出し、予測への活用有無を判断している。しかし相関係数だけでは、予測する部品での出荷傾向の類似度を正確に測れない。そのため、今後は波形分析などの手法を併用していくことで、部品と教師データの相関を正確に測定し、傾向の似ている教師データを抽出することで更なる精度向上を図る。

### 4.2 気象データの活用

家電製品・住宅設備での補修用部品では、一部の部品で季節・温度によって出荷傾向が異なることが現場知見からよく知られている。そのため、気象データをAIに学習させることで天候による出荷数の影響を認識させ、更なる予測精度向上を図っていく。

## 5. むすび

今般、補修用部品などの需要を高精度に予測する技術を開発し、家電製品・住宅設備での補修用部品の生産計画業務に適用することで、在庫管理の最適化や部品供給の円滑化を実現し、保守サービスの品質向上に貢献した。この技術は、需要予測に際して、工場データとしては出荷数だけを利用することから導入に向けた障害は低いと考えられる。そのため、今後は他事業の補修用部品又は量産製品の生産計画業務への適用も検討していく予定である。

### 参考文献

- (1) 澤井善久, ほか: 保守・アフターサービス事業強化に向けた業務プロセス改善, 三菱電機技報, 82, No.10, 635~637 (2008)