

スーパーマーケット向け発注支援サービスにおける機械学習の適用

Application of Machine Learning to Ordering Support Service for Supermarkets

海老原 純二

要約 スーパーマーケットでは、毎日数千の商品について在庫をチェックし発注数を指示する作業は負荷が大きく、自動化による支援が期待される分野の一つである。一方、発注は売上に直結する重要な業務である。自動化する場合は、現状の廃棄ロスやチャンスロスを増やすことなく、省人力化により作業負荷を軽減させなければならない。このような発注業務の自動化を支援する当社ソリューションに、販売数を予測して発注数を算出する自動発注支援システムがある。当該システムが持つ課題を解決するために、従来は人手で実施していた作業を、データからの自動学習で代替える仕組みを開発しサービスとして提供を開始している。利用企業では、サービス導入時の設定作業と日々の発注作業を軽減でき、廃棄ロスとチャンスロスを削減できることを確認している。

Abstract In supermarkets, the work of checking the inventory and indicating the number of orders for thousands of products every day is a heavy burden, and it is one of the fields where support by automation is expected. On the other hand, ordering is an important task that is directly linked to sales. In the case of automation, it is necessary to reduce the workload by saving manpower without increasing the current disposal loss and opportunity loss. One of our company's solutions, which support the automation of such ordering operations, is the one that predicts the number of sales and calculates the number of orders. In order to solve the problems of this system, we have developed a mechanism that replaces the work conventionally performed manually with the automatic learning from data and started providing it as a service. Companies using the service have confirmed that setting work at the time of service introduction and daily ordering work can be reduced, and disposal loss and opportunity loss can be reduced.

1. はじめに

「SDGs（持続可能な開発目標）」は、数年前からメディアでも度々取り上げられるようになり、日常生活でも耳にする機会が増えている。スーパーマーケット（以下、SM）においても、フードロス削減、包装資材の脱プラスチックなど、SDGsの取り組み率は高くなっている^[1]。しかし、SMで最も多く取り組まれている活動は、労働環境の整備やパート・アルバイトの技術向上である。毎日数千の商品について在庫をチェックし発注数を指示する作業は負荷が大きく、自動化が期待される分野の一つである^[2]。

SMの自動発注では商品の特性上、将来の販売数を予測して発注する仕組みが求められる。BIPROGY株式会社では、予測型の自動発注支援ソリューション^[3]（以下、旧システム）を提供していたが、システムの運用負荷が大きいという課題と、運用設定の難しさにより発注精度が低下する課題があった。これらの課題を解決するため、従来は人手で実施していた作業を、データからの機械学習で代替える仕組みを開発した。当該機能はAI-Order Foresight サービス（以下、本サービス）として提供を開始しており、期待する効果が得られている。

本稿では、開発した自動化の仕組みとその効果について記載する。2章ではSMの発注業務について、3章では旧システムの課題について説明する。4章では3章の課題を解消した、本サービスの改良点について具体例を交えて説明する。5章では適用して確認できた効果と課題を記載する。

2. スーパーマーケットの発注業務

SMの発注は作業負荷が大きい業務である。発注担当者は、店舗の陳列棚とバックヤードの在庫をチェックし、今後の売れ具合を予測して発注数を指示する。毎日店舗へ配送する『日配品』では、数千種類の対象商品について、このような発注作業をほぼ毎日実施している。作業負荷が大きいため、自動化が期待される業務の一つである。

一方、発注は売上に直結する重要な業務でもある。発注数が多すぎれば過剰在庫となり見切りや廃棄ロスにつながる。逆に少なければ品切れチャンスロス（以下CLと記載）となり店舗イメージを低下させ売上を減少させる。発注には需要に応じて適切な数量を決定することが求められる。自動化するには、現状の発注精度を維持しつつ、省人力化により作業負荷を軽減することが肝要である。

発注の自動化には、セルワンバイワン^{*1}や定量発注方式^{*2}がある。これらの方式は売れた分だけ、後追いで発注する仕組みである。曜日や天候等の影響で日々の販売数が大きく変動する日配品には不向きである。例えば、土日は販売数が多く、月曜から金曜の平日は少ない商品を考える。土曜に売れた数が月曜に納品されたとする。月曜は土曜ほど売れないため、在庫が残ってしまう。賞味期限が短い場合は、見切による値引きや廃棄が発生する。このようにSMの日配品では、予測販売数に応じた発注が求められる。

3. 旧システムの課題

本章では、旧システムの概要および課題について説明する。

3.1 旧システムの概要

旧システムは、販売数を予測する機能と、算出した予測販売数をもとに発注数を求める機能を提供している。

(1) 販売数の予測

予測販売数は、『予測モデル』を使って算出する。予測モデルとは、曜日やチラシ掲載有無などの施策の状態に応じて、販売数を算出する数式である（図1）。

予測販売数 = 定数項 + 曜日ウェイト + 施策ウェイト + 天候ウェイト + ...		
定数項 = 1.0131	曜日ウェイト	施策ウェイト
	月曜 = 0.131	施策なし = -3.2815
	火曜 = -1.801	チラシあり = 5.0181

図1 予測モデルの例

予測する日が月曜日で施策がない場合、予測販売数は定数項 1.0131 と月曜のウェイト 0.131、施策なしのウェイト -3.2815 を合算して算出する。定数項と曜日や施策等のウェイトは、実績データを学習して最適な値を割り当てる。

予測モデルは、学習方法や予測要因が定義された『モデル定義』に従って作成する。モデル定義は、専門家^{*3}がデータ分析を実施して精度が高くなるものを作成する。予測モデルの作成と予測販売数の算出の流れを図2に示す。まず、専門家が複数のモデル定義で検証を行い、ソリューションに設定するモデル定義を決定する。旧システムではモデル定義を入力として、過去の実績データである『学習データ』をもとに予測モデルを作成する。作成した予測モデルに、将来の計画値である『適用データ』を当てはめて予測販売数を算出する。

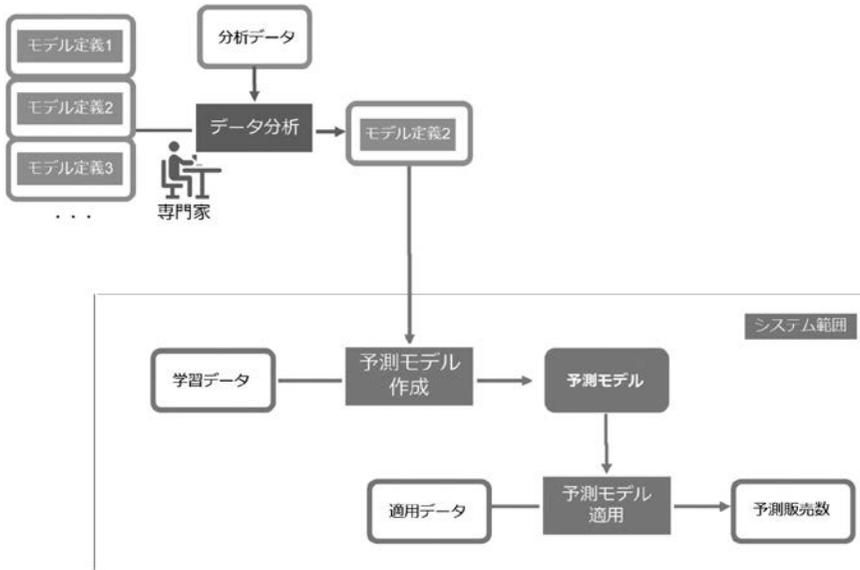


図2 予測モデルの作成と予測販売数算出の流れ

(2) 発注数の算出

発注数は、対象期間の予測販売数に、品切れしないように余分に保持する在庫である『安全在庫』、店舗の陳列棚に最低確保しておく在庫である『必要棚在庫』、現時点の在庫数である『現在在庫』、今後の納品予定数である『納品残』を加味して算出する (図3)。

安全在庫は予測販売数の信頼度をあらわす予測誤差のバラツキに安全率を加味して算出する。安全率は商品別に利用者が指定する。廃棄を発生させたくない商品には発注数が小さくなるように0.1、品切れを起こしたくない商品は発注数が大きくなるように1.0と、商品特性に応じて利用者が定める。

$$\begin{aligned}
 \text{発注数} &= \text{予測販売数} + \text{安全在庫} + \text{必要棚在庫} - \text{現在在庫} - \text{納品残} \\
 \text{安全在庫} &= \text{予測誤差バラツキ} \times \text{安全率} \\
 \text{必要棚在庫} &= 10 \quad \text{安全率} = 0.1
 \end{aligned}$$

図3 発注数の算出式

3.2 旧システムの課題

前節の機能を利用するにあたり、以下のような運用上の課題がある。

3.2.1 課題①運用作業の負荷大

利用するための運用負荷が大きいことが、一つ目の課題である。

ソリューションを利用する前に、対象商品のモデル定義と安全率を決めなければならない。モデル定義は、専門家がデータ分析を実施して決定する。安全率は、廃棄の重視度合いを考慮して店舗の発注担当者が定める。利用を開始した後でも、店舗や商品を増やす度に同様の作業を行う。また、発注数の精度が低い場合も、設定を見直すために同じ作業を行わねばならない。都度分析を実施して設定を行う運用は手間と時間がかかり、SMにとって作業負荷が増える。

3.2.2 課題②運用制約による精度低下

運用設定の難しさから、最適な発注数を算出できないことが二つ目の課題である。

店舗で扱う日配品は数千種類あり、モデル定義や安全率を商品別に決めることは現実的ではない。通常は、商品分類別に同じ値を定めている。

例えば、『練製品』は廃棄したくないから安全率は低めの0.1と設定する。しかし、当該カテゴリでも廃棄が発生しにくい商品がある。そのような商品には、発注数を増やすように1.0など高い値を指定すべきである。商品分類別にモデル定義と安全率を設定する仕組みでは商品ごとの細かい設定ができず、発注精度を低下させる可能性がある。

また、安全率は人が設定するため、精度は発注担当者のスキルに依存する。不慣れな発注担当者であれば、適切な安全率を設定できない。

4. 自動発注支援ソリューションの改良

従来は人手で行っていた作業を、機械学習を使って自動化し、適用負荷の軽減と発注精度を向上させる仕組みを開発している。本仕組みについて記載する。

4.1 販売数予測モデル

旧システムでは、以下に示す手順でシステムに登録するモデル定義を決めている。

4.1.1 モデル定義の決定手順

検討する複数のモデル定義を用意し、最も精度が高い予測モデルを作成するものを採用する。検討するモデル定義は、以下の三つの視点で用意する。

イ) 外的基準 (予測する項目)

機械学習の教師信号とする値を定義する。

ロ) 説明変数 (予測する要因)

予測の要因には、曜日や祝日等の『カレンダー情報』、最高気温や天候などの『天候情報』、売価や特売等の『販促情報』の三種類がある。要因として使用する項目を定義する。

ハ) 学習期間 (予測モデルを学習する期間)

機械学習する期間を定義する。直近1ヵ月で学習する、長期2年で学習する等である。

専門家がこれらの視点で複数のモデル定義を検証し、採用するモデル定義を定める。

4.1.2 改良後の予測モデル

今回開発した仕組みでは、専門家が複数のモデル定義から採用するモデル定義を定める部分を、システムの中に取り入れた。改良後の予測モデルは、検討する複数のモデル定義を入力情報として複数の予測モデルを作成し、各モデルから予測販売数を算出する。次に、これらの値を合成して最終的な予測販売数を算出する統合予測モデルを作成する(図4)。このモデルは複数の予測販売数を合成するため、各モデルの良い部分を取り込める。いずれかの予測販売数を選ぶより、精度を高めることができる。

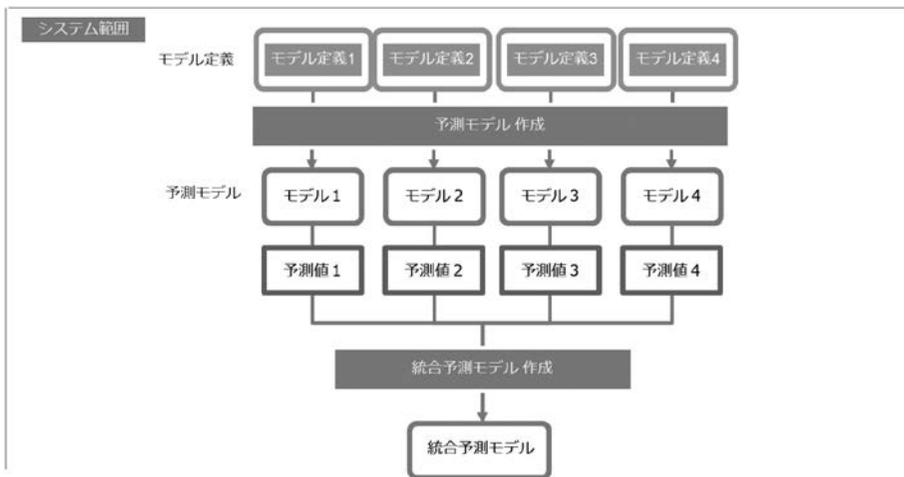


図4 改良後の販売数予測モデル

4.2 発注数の算出

旧システムでは人が安全率を決定するが、今回開発した仕組みではデータから自動で最適な安全率を商品ごとに決定する。安全率の算出方法を以下に述べる。

安全率を変えて発注のシミュレーションを行い、廃棄ロスとCLが最も小さくなる安全率を決定する。発注数は、安全率をもとに3.1節の式で算出する。廃棄数は、当日の終在庫数と販売できる期間内にある在庫から試算する。CLは、販売実績分の在庫を確保できない場合に発生したと試算する。販売数の予測モデルと安全率を自動で決定できるため、運用の負荷を軽減できる。また、商品分類別ではなく商品別に最適なモデルと安全率を決めるため、精度を向上できる。安全率の値が発注担当者に依存するリスクも回避できる。

4.3 発注担当者への注意喚起(アラート機能)

前節のように発注数を自動で算出し、人手をかけることなく卸やメーカーへ発注すれば、作業量を削減できる。しかし、機械学習の特性上、全ての発注数が適切な値になるわけではない。不適切な値で発注すると、過剰在庫や品切れのロスが発生する。

今回開発した仕組みでは、不適切なケースを検出して発注担当者に注意喚起することで、発注数の修正を促すようにしている。在庫が過剰な商品、過少で品切れが発生している商品、新

規に販売開始したため学習実績が少なく予測精度が不安定な商品、過去の発注実績と比較して発注数が大きい商品等にアラートを出せるようにしている（表1）。

表1 アラート一覧

No	アラート	内 容
1	在庫過剰	前日に廃棄または見切が発生している商品。
2	在庫過少	前日に品切れが発生している商品。
3	新商品	販売開始から2週間の新商品。注意が必要。
4	発注数増加/減少	直近の発注数が著しく増加/減少している商品。
5	発注訂正	前日の発注数の訂正がある商品。

5. 本サービス利用時の効果

前章で紹介した仕組みは既にサービス提供しており、期待通りの効果が得られている。

5.1 運用の負荷軽減

利用企業では、いずれの店舗も本サービスが定める標準設定で運用を開始している。大規模店や小規模店、商品の品揃えで設定を変えることはない。データ分析の専門家による設定も不要となった。

従来の仕組みでは、店舗や商品分類を増やす度に分析作業を実施しモデル定義と安全率を見直していた。新しい仕組みでは販売数予測のモデル定義と安全率の算出方法は全て同じ設定で運用し、従来は実施していた設定作業を割愛し負荷を軽減できることを確認できた。運用する上での作業の難しさは発生していない。

5.2 店舗作業の削減

本サービスの利用による自動化で、店舗の作業負荷をどれだけ軽減できたかを評価した。店舗の棚とバックヤードを確認して発注数を入力する作業にかかる時間（発注作業時間）の変化を表2に示す。

本サービスの利用前は1日当たり平均3.5時間（208分）だった発注作業時間が、利用後はシステムの発注数を確認して気になる箇所をチェックする運用に変わったことで2.0時間（125分）となり、40%（ $= (208-125)/208$ ）削減することができた。これは本サービスの試行時の結果であり、環境が十分に整備されていない状態のものである。試行では発注数の訂正はバックヤードで行うため、店頭で発注訂正ができる本番環境での運用時より非効率であった。店舗によっては、本サービス利用後は発注作業時間が10%（90%削減）になったという店舗も出ている。

表2 1店舗当たり1日における発注作業時間の評価結果

	利用前 (分)	利用後 (分)	削減時間 (分)
発注作業時間	208	125	83

5.3 廃棄とCLの削減

廃棄とCLの状態に応じて商品を以下の4グループに分け(表3), サービス利用前後で各グループの割合がどのように変化しているのかを測定した。

表3 商品の廃棄とCLの状態

	廃棄率1%以内	廃棄率1%超
CL率10%以内	①廃棄少 - CL少 良好な発注	③廃棄多 - CL少 発注数多め
CL率10%超	②廃棄少 - CL多 発注数少なめ	④廃棄多 - CL多 不適切な発注

- ①廃棄少 - CL少：廃棄率は1%以内, CL率は10%以内。
廃棄とCLが少なく, 良好な発注ができている商品。
- ②廃棄少 - CL多：廃棄率は1%以内, CL率は10%超。
CLが多い商品である, 発注数が少なめの商品。
- ③廃棄多 - CL少：廃棄率は1%超, CL率は10%以内。
廃棄が多い商品である, 発注数が多めの商品。
- ④廃棄多 - CL多：廃棄率は1%超, CL率は10%超。
廃棄とCLが多く, 不適切な発注となっている商品。

$$\text{廃棄率} = \text{廃棄数} \div \text{販売数}, \text{CL率} = \text{CL数} \div \text{販売数}$$

CL数は, 5点以上販売があり最終販売時刻が18時以前の場合発生と算出
廃棄率1%とCL率10%の閾値は, サンプルのバラツキをみて定義。

利用期間が1ヶ月以上確保できた3店舗の結果を図5に示す。A店とC店では, 廃棄とCLが少ない①が増加し, 廃棄やCLが多い④は減少している。本サービス利用時は適切な発注が行えている商品が増加して, 廃棄とCLの削減に寄与できている。

B店では①が減少し, 廃棄が多い③と④が増えている。B店は近隣に競合SMがオープンしたことから, 想定より販売が伸びず廃棄が増えたと分析している。このような場合は, 必要棚数を変更して発注数を少なくする等の対応が有効であることを確認できている。

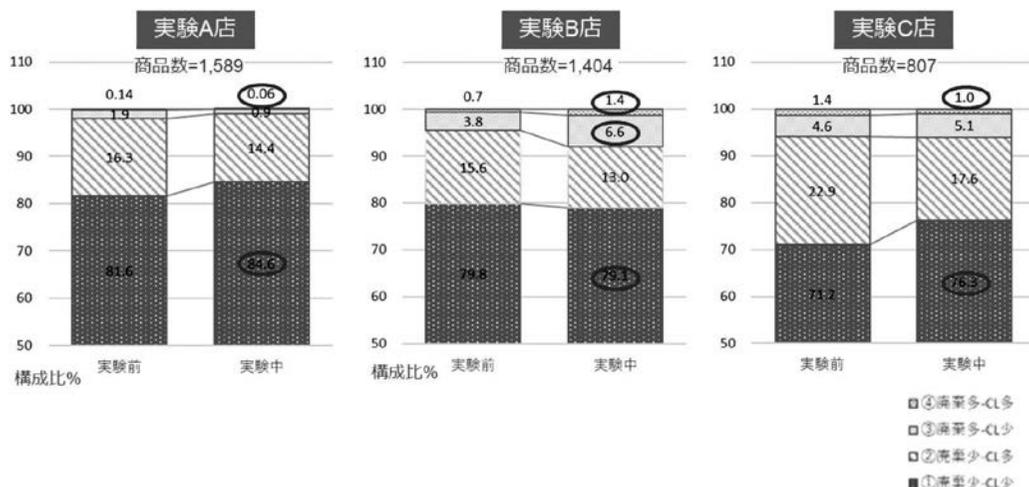


図5 サービス利用前と利用後の商品構成比

5.4 サービス利用上の注意点

本サービスを利用する上で、二つの注意点を記載する。これらを踏まえて、利用企業では概ね良好に運用できている。

5.4.1 運用注意点1：全て機械まかせにしないこと

自動発注ということで発注担当者がチェックすることなく運用すると、適切な発注数を算出できない場合がある。利用を開始する最初の1週間程は、自動発注の数量を店舗の発注担当者がチェックし調整することが望ましい。発注数が大きいようであれば、『必要棚在庫』を減らすことで、翌日からは発注数を減らすことができる。なお、調整が完了すれば、2週目以降は実施することなく運用できる。また、アラートのチェックは、日々行うことが重要である。アラートがあれば、発注数の見直しとアラート内容に対処する。『在庫異常アラート』が出ていれば、在庫数をチェックし問題があれば発注数を訂正する等である。このような運用を行わなければ、自動で算出する発注数が不適切な値となり、発注担当者による発注数の訂正が多くなり作業負担は軽減しない。

5.4.2 運用注意点2：訂正率が高い店舗への個別支援

発注担当者が発注数を訂正する割合は、店舗によって異なる。訂正率が低い店舗もあれば、高い店舗もある。訂正率が高い店舗が多いほど、効果的に自動化サービスを利用できないことになる。店舗の訂正率を可視化し、問題なく運用できているかチェックすることが重要である。

6. おわりに

本稿では、機械学習を適用した、本サービスの具体的な改良点と効果について紹介した。最後に、今後の展望を述べる。

自動発注サービスとしては、以下の二つのポイントで拡張を考えている。一つは予測精度の向上である。より高い精度で販売数を予測できれば、適切な発注ケースが増加し自動化できるケースを拡大できる。作業負担の軽減効果はより大きくなる。精度向上のためには、現在は取

得できていないデータの取得と、学習方法の改良を考えている。

もう一つは、支援する業務の拡大である。現在は、『日配品』を対象としているが、それ以外の『生鮮』でも同様に予測型のニーズはある。基準型等での運用が多い生活雑貨等や日用品の商品についても、利用したいとの声はある。また、特売を行う際の売価決定や発注数を決める業務支援も候補である。一部については、実業務に適用する場合の機能拡張を実施し、実店舗での試験を行っている。

本稿で紹介した自動発注のサービスが、発注自動化を検討している企業の参考になれば幸いである。

-
- * 1 適正な在庫数を設定し、販売して在庫が減った分だけ発注する方式。
 - * 2 在庫が一定数（この基準を発注点という）を下回った場合に決まった数量を発注する方式。
 - * 3 BIPROGY のデータ分析の専門家。機械学習や統計解析の知見を持ち、データ分析を行える専門の技術者。

- 参考文献** [1] 「2022年スーパーマーケット白書」, 全国スーパーマーケット協会, P41～42
 [2] 「2019年スーパーマーケット白書」, 全国スーパーマーケット協会, P26～31
 [3] 新岡賢一, 宮崎孝, 「競争を勝ち抜くためのマーチャンダイジングソリューション」, ユニシス技報, BIPROGY, Vol.25 No.4 通巻 88 号, 2006 年 2 月, P49～53

執筆者紹介 海老原 純二 (Junji Ebihara)
 1992 年日本ユニシス(株)入社。統計解析, オペレーションズ・リサーチ関係のデータ解析業務とシステム開発業務に従事。

