

令和 5 年度流通・物流の効率化・付加価値創出に係る基
盤構築事業

(複数事業者協働での製品在庫配置の最適化による輸配
送効率向上並びに返品・廃棄削減事例の創出)

調査報告書

令和 6 年 3 月 29 日

一般財団法人 日本気象協会

令和5年度流通・物流の効率化・付加価値創出に係る基盤構築事業
(複数事業者協働での製品在庫配置の最適化による輸配送効率向上並びに返
品・廃棄削減事例の創出)
調査報告書

目次

1.	はじめに	1
1.1	事業の背景.....	1
1.2	事業の目的.....	1
1.3	事業の概要.....	4
1.3.1	対象業界	4
1.3.2	対象企業	4
1.3.3	参加企業における課題.....	5
1.3.4	本事業における実施内容.....	9
2.	需要予測に影響を与える大きな要因の調査・整理.....	10
2.1	概要.....	10
2.2	ヒアリングによる変動要因調査.....	10
2.3	データを用いた変動要因調査.....	16
2.3.1	来店客数の解析	18
2.3.2	各商品の解析	23
2.3.3	複合的な関係	32
2.4	需要予測モデルに関する考察.....	33
2.5	まとめ.....	34
2.5.1	ヒアリング	34
2.5.2	データを用いた解析	34
2.5.3	需要予測モデルに関する考察.....	35
3.	複数事業者協働による実証実験.....	36
3.1	対象の設定.....	36
3.2	オペレーション変革.....	38
3.3	発注推奨システムの構築.....	46
3.3.1	システム	46
3.3.2	需要予測モデル	50
3.3.3	在庫最適化モデル	55
3.4	精度検証.....	63

3.5	実証実験の結果評価.....	79
3.6	まとめ.....	97
3.6.1	対象の設定	97
3.6.2	オペレーション変革	97
3.6.3	発注推奨システムの構築.....	98
3.6.4	精度検証	98
3.6.5	実証実験の結果評価	99
4.	パフォーマンス向上効果の分析.....	102
4.1	企業間協業による企業のパフォーマンス向上効果.....	102
4.2	社会実装していくための要件整理	106
5.	まとめ	107
5.1	需要予測に影響を与える大きな要因の調査・整理	107
5.1.1	ヒアリング	107
5.1.2	データを用いた解析	107
5.2	複数事業者協働による実証実験.....	108
5.2.1	対象の設定	108
5.2.2	オペレーション変革	108
5.2.3	発注推奨システムの構築.....	108
5.2.4	実証実験の結果評価	109
5.3	パフォーマンス向上効果の分析.....	110
5.3.1	企業間協業による企業のパフォーマンス向上効果.....	110
5.3.2	社会実装していくための要件整理.....	110
資料編		111

1. はじめに

1.1 事業の背景

物流業界では、人口減少に伴う労働力不足の深刻化等により、物流における需要と供給のバランスが崩れつつある。特に 2024 年 4 月の働き方改革関連法の施行により、国内物流の大部分を占めるトラックドライバーへの時間外労働の上限規制等の適用による供給の変化（「物流の 2024 年問題」）や、昨今の燃料価格の高騰による物流事業者の輸送経費の増大、荷主事業者の物流コスト上昇等を受け、更なる物流効率化を進めていく必要がある。こうした中で、荷主事業者の輸送量削減のための取組として、拠点別需要予測の高度化等によって不要な輸送を削減していくことが求められている。

1.2 事業の目的

(1) サプライチェーンにおける課題

サプライチェーンでは製配販¹による多段階の意思決定が介在するため、需要予測の精度向上は個社単体では限界がある。

例えば、日配品では製造業の納品リードタイムより小売業の発注リードタイムが短いため、製造業は最終需要者（消費者）の需要を予測して生産計画を策定するのではなく、小売業からの発注量を予測して生産計画を策定する必要がある。しかし、小売業からの発注量は、各店舗の在庫量や販促等によって変動するため、最終需要よりさらに大きな変動になる（ブルウィップ効果）。その結果、製造業は小売業からの発注量予測の精度が十分でないため、生産計画の変更や、食材廃棄、原材料メーカーへの緊急発注に伴う緊急輸送が発生する。この緊急輸送はトラックやトラックドライバーの緊急確保を通して通常輸送と比較して物流に大きな負荷をかける輸送となる。

緊急生産・緊急輸送が生じるメカニズムを図 1.1 に示す。製造業は小売業からの発注を受けてから生産を開始すると納品が間に合わないため、小売業からの発注量を予測して生産を行う見込み生産を実施している。しかし、製造業が予測した発注量と実際の発注量にミスマッチが生じると、生産が不足している場合は緊急生産や緊急輸送、生産が過剰な場合は廃棄が生じることになる。

¹ 製は製造業、配は配送業、販は販売事業者を意味する。




図 1.1 緊急生産・緊急輸送が生じるメカニズム

(2) 課題の解決策

上記の製造業と小売業のミスマッチを解消するためには、サプライチェーンの需要予測と在庫補充のための協働事業（CPFR：Collaborative Planning, Forecasting and Replenishment）が必要である。CPFR は需要予測情報をサプライチェーンの各段階で共有し、需要予測の精度を向上させるとともに、それに関わる生産・調達・販売の計画と連動を図り、サプライチェーンの主要な活動を統合する仕組みである。図 1.2 に CPFR の運用イメージを示す。




図 1.2 CPFR の運用イメージ

しかし、CPFR はすべての製造業と小売業が連携した場合の効果は大きいですが、特定の事業者が連携している状況では効果は限定される。また、製造業と比較して小売業のメリットが小さいため、必要性は認識されているものの取り組みは十分に拡大されているとは言えない。

例えば、簡易的な CPFR の一例として発注リードタイムの延長が提唱されているが、もっとも効果のある日配品においてもリードタイムの延長の試みは十分に進んでいるとは言えない²。

そこで、本事業では効果的な CPFR の枠組みを構築し、各企業のパフォーマンス向上（販売面・在庫面・欠品面等）に結びつける実証実験を実施した。

² 農林水産省 「食品製造業の食品ロス削減対策に対する支援事業」 報告書（令和 5 年 3 月） https://kankyo.shokusan.or.jp/wp-content/uploads/2023/05/r3-syokuloss-rpt_all.pdf

1.3 事業の概要

1.3.1 対象業界

食品分野は、売上高物流コスト比率が表 1.1 に示すとおり製造業・卸売業・小売業ともに 6%以上を占め、全業種平均の 5.70%を大きく上回っており³、物流の最適化が重要な分野と言える。

表 1.1 食品分野の売上高物流コスト比率（2021 年度物流コスト調査報告書）

業種	製造業		卸売業（食品飲料系）	小売業
	食品（要冷）	食品（常温）		
売上高物流コスト比率	8.82%	7.12%	6.63%	6.08%

その中でもオペレーションにおいてもっとも課題が大きい商品群は、賞味期限が短く毎日輸送が必要で売れ残った商品は廃棄せざるを得ない日配品である。日配品における課題は、現在は製配販の各企業が独自に POS（販売時点情報管理）データに基づいて需要予測を行っているが、①需要予測精度が十分でない、②製配販各社による需要予測及びその予測に用いるデータが十分に共有されておらず、各流通段階で注文量のミスマッチが生じていることである。

1.3.2 対象企業

本事業では CPFR を実施した際の効果検証を行うため、小売業と製造業の連携実証実験を行う。小売業としてはスーパーマーケットを運営している株式会社バロー（以降、バロー）、製造業としてはバローに惣菜等を納品している中部フーズ株式会社（以降、中部フーズ）、業務統括、コンサルティングとして一般財団法人日本気象協会（以降、日本気象協会）、システム構築としてソフトバンク株式会社（以降、ソフトバンク）が参加して事業を実施した（表 1.2）。

表 1.2 令和 5 年度事業 参加企業の一覧

項目	業態	役割
一般財団法人 日本気象協会	コンサルティング	業務統括、客数予測、需要予測 発注推奨量算出
中部フーズ株式会社	製造業	日配品（惣菜等）を製造し、バローの 各店舗に輸送 工場の生産性向上、緊急輸送の削減
株式会社バロー	小売業	緊急発注の削減、作業効率化
ソフトバンク株式会社	システム	クラウドシステム構築、客数予測

³ 2021 年度物流コスト調査報告書 公益社団法人日本ロジスティクスシステム協会

1.3.3 参加企業における課題

需要予測の精度が十分でないために起きている過剰在庫の一例として、2022年10月の全店舗平均の雨、来店客数と売上、廃棄と値下げ率の時系列データを示す。スーパーマーケットでは雨が降ると消費者の外出が減少するため、来店客数は減少する傾向がある。一方、日々の発注業務では発注量を経験と勘で算出しているが、担当者は日々の売上は考慮するものの消費者の行動変容を引き起こす雨は考慮できていない場合が多い。その結果、降雨日の発注は来店客数の減少を考慮していないため発注が過大になり、過剰な輸送によって過剰在庫が発生し、値引きや廃棄も増加していることが分かる（図 1.3）。このように店舗において過剰在庫が発生すると、製造業への発注量も変更され、製造業でも輸送量の増加や過剰在庫が発生するというように、サプライチェーン全体に影響が伝播する。

したがって、まず小売業の発注量を適正化した上で、その情報を事前に製造業に連携することがサプライチェーンの最適化には重要であると考えられる。




図 1.3 在庫過剰の一例

サプライチェーンの最適化を検討するため、店舗・工場における業務フローでの課題を図 1.4 に示す。店舗から製造業への発注は、納品 1 週間前に週間発注を実施し、2 日前に修正発注を行っている。週間発注は 1 週間分の発注を行っており、製造業はこの週間発注に基づいて生産計画・シフト調整等を行っている。次に納品 2 日前に修正発注が実施されているが、これが製造業の通常生産で納品可能な 3 日よりも短いため、製造業の想定している発注量と店舗からの修正発注量が大きく異なった場合は緊急生産・緊急輸送が実施されることになる。緊急生産や緊急輸送は通常の生産や輸送よりもコストが高く、特に緊急輸送は昨今のトラックドライバー不足の物流業界に負荷を与えている。

一方、店舗から製造業への発注は、経験と勘で毎日 1.5 時間程度をかけて実施しているが、経験と勘の発注では雨の影響等、消費者の購買行動の変化への対応が十分にできているとは言えない。その結果、過剰発注が実施された場合は、賞味期限切れの前に商品売り切るために値引きをするマークダウンコストが増大し、値引きをしても売り切れない場合は廃棄が発生する。また、過小発注の場合は欠品が発生し、品揃えの悪化による顧客満足度の低下が生じる。

そこで、このサプライチェーンを最適化するためには、①需要予測精度の向上、②発注リードタイムの長期化、③在庫の最適配置が必要であると考えられる。




図 1.4 バロー・中部フーズにおける課題

本事業では上記の課題を解決するため、サプライチェーンのプレイヤーである中部フーズ（製造業）とバロー（小売業）が協力する枠組み CPFR を構築する。目指すオペレーションの概念図を図 1.5 に示す。




図 1.5 目指すオペレーション

需要予測精度の向上では、自社では取得できない情報を持った企業（特に製造業）との協力によるデータ収集や、AI を利用した予測モデルの高度化が重要である。現在は経験と勘で需要予測を行っているが、そこで考慮されているのは自店舗の直近の売上傾向、値引き・廃棄等のデータだけである。しかし、需要を予測するためには、商品の特徴や外部要因である販売促進、天候、消費者行動等のデータも考慮する必要がある。これらは、自店舗のデータだけでは不足しているため、本事業ではバローの店舗データに加え、製造業の中部フーズのデータ、サードパーティであるソフトバンク、日本気象協会のデータも収集することとした。また、近年は需要予測において多くのデータを AI で解析することで経験と勘では考慮することができない複雑な関係性を解析し予測することが可能になってきている。そこで、本事業では、様々なデータを収集、AI で需要予測を実施する発注システムを構築し、発注を自動化することとした。これによって需要予測精度の向上による発注量の適正化に加えて、発注作業負担の軽減も可能になる。

発注リードタイムの長期化では、利害関係者である製造業と小売業が協力して、これまでの商習慣を変革する必要がある。現在の業務フローでは、1週間前の週間発注と2日前の修正発注が実施されているが、2日前の修正発注によって工場の生産計画やシフトの変更、緊急生産、緊急輸送等が発生している。そこで、本事業では修正発注を製造業の納品リードタイムの3日以上前に変更することとした。これによって、緊急生産、原材料メーカーから工場への緊急調達輸送の削減、工場から小売への緊急輸送の削減、シフトの早期固定化による工場の生産性向上に加えて、計画製造による品質向上、安定供給も期待できる。

ただし、リードタイムを長期化することは需要予測をより困難にするため、需要予測を高度化することが求められる。そこで、本事業ではAIを利用して人間では考え付かない複雑な関係性を考慮し、精度を向上させることとした。

在庫の最適配置では、製造業、小売業とサプライチェーン各所で保有している在庫を適正化する。現状は、製造業・小売業の各社が欠品を防ぐために在庫を過剰に保有している傾向がある。そこで、本事業ではサプライチェーンの各プレイヤーが情報を連携することによって欠品可能性を減少させ、トータル在庫の減少を図る。ここでは、小売業からの発注量を事前に製造業に連携して見込み生産を受注生産に変更することによって、製造業が小売業からの発注に対応するために保有している在庫を削減することとした。これによって、サプライチェーントータルの在庫を減少させることが可能になり、廃棄も減少する。

1.3.4 本事業における実施内容

本事業では、まず需要予測に影響を与える大きな要因の調査・整理をした上で、複数事業者協働による実証実験を実施、パフォーマンス向上効果の分析を実施する。図 1.6 に調査フローを示す。




図 1.6 調査フロー図

2. 需要予測に影響を与える大きな要因の調査・整理

2.1 概要

本章では、企業間協業に基づく需要予測が実需との誤差の範囲を超える例外的な状況を共同で解決する方策と解決手段を検討するため、需要予測に影響を与える大きな要因について3店舗へのヒアリングを行い、実際のオペレーションデータを用いて需要の変動要因を調査し、需要予測モデルに関する考察を行った。

2.2 ヒアリングによる変動要因調査

(1) ヒアリング概要

ヒアリングでは、バローの運営するスーパーマーケットの大規模2店舗、中規模1店舗を対象に実店舗を訪問し、発注責任者にヒアリングした。ヒアリング内容は、需要予測に影響を与える大きな要因、現在の発注における課題・考え方、在庫に対する考え方、発注システムへの要望とした。

表 2.1 ヒアリング内容

項目		内容	備考
目的		実際の発注担当者から需要予測に影響を与える変動要因や、現在の発注における課題、発注システムへの要望等をヒアリングし、予測モデル構築や実証実験に活かすこと	
日付		2023年7月20日（木）	週間発注を行っている木曜日
店舗		規模の異なる3店舗 大規模・中規模	大規模：2店舗 中規模：1店舗
ヒアリング	対象者	発注担当者（発注責任者）	
	時間	1～2時間	店舗視察、ヒアリング 発注作業
	内容	・需要予測に影響を与える変動要因 ・発注における課題、考え方 ・在庫の考え方 ・発注推奨に対する要望	
訪問者		予測モデル構築者 システム構築者	

(2) ヒアリング店舗

ヒアリング店舗の特徴を表 2.2 に示す。A 店はバロースーパーの中でも惣菜部門の売上がもっとも大きい店舗で、B 店は発注精度がもっとも高い店舗、C 店は人手不足感の大きい店舗として選択した。

表 2.2 ヒアリング店舗の特徴

対象店舗	地域	規模	特徴
A 店	愛知県	大型	品揃えが豊富でもっとも惣菜部門の売上が大きい店舗。大型店舗の需要予測・在庫最適化モデルの考え方の基本になる店舗
B 店	岐阜県	大型	もっとも発注精度がよく利益率の高い店舗の一つ。需要予測・在庫最適化モデル・実証実験においてオペレーションの参考になる店舗
C 店	愛知県	中型	人手不足感の大きい店舗で、発注推奨による効果が大きいと想定される。中・小型店舗の需要予測・在庫最適化モデルの考え方の基本になる店舗

(3) 需要の変動要因

各担当者からヒアリングした需要の変動要因は暦、店舗特性、気象、販促、他要因である。ヒアリング結果を表 2.3 に示す。

A) 暦

暦については、カレンダー情報のため完全に予測することが可能だが、経験と勘の需要予測では特定の時期による来店客数や売上の変動等の影響については予測することが難しい。惣菜部門では季節や旬、地域によって消費者嗜好が変わるため売上が大きく変動する商品が存在する。年末のおせちや、節分の日の恵方巻等、極端に売上が増加する特異日も存在する。したがって、需要予測を実施する際は、来店客数の変化についてはサードパーティデータである人流統計データを活用し、売上の変化については直近のトレンドの変化等を捉えることが重要になる。ただし、節分の日の恵方巻や年末のおせち等、年に 1 回しか発生しない特異日については過去データを学習して予測する AI ではデータ不足で予測することは難しいと想定されるため、需要予測の誤差を解決する追加的な手段を検討しておく必要がある。

B) 店舗特性

店舗特性については、同じような規模の店舗では陳列される商品数や種類が類似しており、店舗の床面積と来店客数も関係性がある。この各店舗の特性は本部では把握できており、基本的には変化しないため予測することは可能である。一方、経験と勘の需要予測では担当者は自店舗のみの情報をもとに予測をするため店舗特性は考慮されていない。しかし、AI では自店舗の情報では不足している情報を他店舗の情報で補って予測することが可能なため、店舗特性等の他店舗と自店舗の関係性を示すデータも考慮する必要がある。

C) 気象

気象については、気象予報が一般にも公開されており誤差はあるものの需要予測に利用することは可能だが、経験と勘の需要予測ではその気象による影響を定量化するのは困難である。特に小型店では人手不足のため天気予報を取得して気象の効果を発注に反映することは困難となっている。雨は消費者の行動変容につながるため来店客数を変動させる効果はあるが、強さや曜日等によって影響は異なる。気温は消費者嗜好に影響を与え、暑くなれば酸味のある商品の売上が増加し、寒くなれば温める商品の売上が増加する⁴ように商品単位の売上に影響がある。したがって、需要予測システムでは上記の異なる影響を評価するため、来店客数予測モデル、需要予測モデルを分け、複数のモデルを組み合わせたシステムを構築する必要があると考えられる。

⁴ 気温が高い時期は「炙り焼き豚の冷やし中華（マヨ付）等酸味のある商品の売上が増加（図 2.14）。気温が低い時期は「ぶりあら大根煮」等温める商品の売上が増加する。

D) 人流

人流については、一般的にデータを取得することが困難なため経験と勘の需要予測ではほとんど考慮されていない。新型コロナウイルス感染症（COVID-19）による行動制限等によって全体的に人流が減少すると全店舗で売上は減少し、競合店舗のオープン等、周辺環境の変化によって特定の店舗周辺の人流が変化するとその店舗で売上は影響を受ける。人流統計データは取得することは困難であるが、ソフトバンクの携帯電話基地局から得られる端末の位置情報を集計・統計加工して得られる人流統計データを用いることで評価することが可能にある。したがって、本事業の需要予測システムでは、人流統計データを利用して予測を行うこととした。

E) 販促

販促については、経験と勘の需要予測でも店長や本部と連携することで予測することは可能であるが、その効果を定量的に評価することは困難である。販促にも異なる種類が存在し、「バローの日」のように全店舗で実施する販促は来店客数を増加させるが、製造業とタイアップをして特定の商品にポイントアップキャンペーンの販促を実施する場合は特定の店舗・商品の売上が増加する。したがって、需要予測を実施する際は、「バローの日」等、全店舗で実施される販促は来店客数予測モデルで考慮し、ポイントアップキャンペーンについては商品需要予測モデルで考慮する。

F) 他要因

野菜相場については、社会・地域全体における需要と供給のバランスによって値段が決定されるため、小売の POS データ等、一部のデータを解析するだけでは、この変化を予測することはできない。したがって、経験と勘の需要予測では、その影響を直接的に評価することができないため、各商品の売上のトレンド等から間接的に評価している。野菜相場が高騰した場合は多品目の野菜がパックされている「8 品目のミックス野菜サラダ」等の売上が増加する傾向がある。需要予測を実施する場合も、野菜相場のデータは取得することができないため、売上のトレンドから間接的に予測する。しかし、トレンドを考慮して間接的に予測すると実際の変化に対して遅れていく予測になり、需要予測精度の低下をもたらす。一方、実際の売上変化の前には先行して現れる指標も存在する。例えば、売上が低下する前には値引き額が増加し、売上が増加する前には売切時刻が早期化する。そこで、このような需要予測の誤差を解消するために、先行指標に変化が見られた際は発注量を変更する等の工夫が必要になる。

G) その他意見

需要予測の変動要因ではないが需要予測に係る課題として下記の意見も存在しており、需要予測の AI 化、自動化に対する期待が潜在的に存在することも分かった。

- ・ 近年は人手不足によって熟練の担当者を確保するのが難しくなっており担当者が引退する際には次担当者に情報を伝える（教育する）のが困難である
- ・ 需要予測によって売上が変動するため、需要予測担当者の精神的負担が大きく担当者を確保するのが難しい

表 2.3 ヒアリング結果

項目	要素	内容
暦	・曜日 ・季節 ・特異日 ・夏休み	店舗によって異なるが、売上は土日に増加する傾向がある。各商品は季節によって変動が大きく、その季節に限定の商品も多く存在する。 お正月、節分の日、桃の節句、GW、年末等は特別な商品を投入することがあり、売上・来店客数は大きく変動する。夏休み等では客層が変わるため顧客購買行動が変化する。
店舗特性	・店舗面積 ・レジ台数	店舗面積が広い店舗では陳列されている商品数、種類が多いため来店客数が増加する傾向がある。また、来店客数が増加するとレジが追加されるため、レジ台数と来店客数も関係性が存在する。
気象	・雨 ・気温 ・台風	雨が降ると来店客数が減少し、全体の需要が低下する。特に強い雨が降った場合や土曜日に雨が降ると客数は大きく減少する。一方、気温は上がると酸味のあるものの売上が増加し、下がると温める商品の売上が増加する傾向にある。台風来襲時の来店客数は、かけこみ需要で接近前に増加し接近時に減少する。
人流	・周辺住民 ・競合の動向	新型コロナウイルス感染症（COVID-19）による行動制限では外出する人数が減少し、全店舗の来店客数が減少した。店舗周辺の競合店が新たに開店する場合や販促をする場合は、来店客数が減少する。
販促	・ポイント ・新商品	「バローの日」等、全店販促を行う場合は来店客数が増加し、すべての商品の売上が増加する。一方、製造業の企業とタイアップをして特定の商品にポイントアップキャンペーンを実施した場合は特定の店舗・商品の売上が増加する。 新商品は商品によって異なるが投入時期は売上が増加する傾向がある。
その他	・野菜相場 ・供給者の数	野菜の相場が上がると野菜サラダ等の需要は増加する傾向がある。いくつかの供給元から商品を取り寄せているが、同セグメントに人気商品がある場合は他商品の売上は減少する傾向がある（セグメント全体では大きな変化はない） Amazon と連携した売上（Amazon の売上を店舗から配達）が大きい場合、需要が大きく増加する場合がある。

2.3 データを用いた変動要因調査

前項ではヒアリングによって需要の変動要因調査を行ったが、本項では実際のデータで需要の変動要因の調査を行った。利用したデータは表 2.4 である。期間は、需要予測の学習期間が 15 か月であることから、直近の 15 か月間として 2022 年 8 月 1 日～2023 年 10 月 31 日とした⁵。

表 2.4 解析に利用したデータ

データ	粒度			データ内容
	時間	商品	店舗	
店舗マスタ	—	—	全店舗	店舗コード、店舗名、レジ台数、駐車場台数、敷地面積、住所、緯度・経度
商品マスタ	—	全商品		商品コード、商品名、カテゴリ分類、定価
来店客数	日		全店舗	日付、店舗コード、来店客数
販売実績	日	全商品	全店舗	日付、時刻、店舗コード、商品コード、価格、販売数、販売金額、値引き金額
廃棄	日	全商品	全店舗	日付、店舗コード、商品コード、廃棄量

前項のヒアリングでも指摘されていたが、小売店の売上は、まず消費者が店舗を訪問し、その店舗の中で商品を選択して購入する。そのため、需要予測は図 2.1 に示すように、第一段階として来店客数予測を行い、次に第二段階として各商品の来店客数 1,000 人当たりの購入比率を予測することが合理的と考えられる。そこで、本項の調査では来店客数の変動と各商品の変動の両方の解析を行った。




図 2.1 需要予測の構成

⁵ 小売店の需要予測では、事業環境が変化していない期間で学習する必要があるため、学習期間が 2 年以上の長期間になると精度が低下する。一方、小売店の売上は季節変動するため前年の同期間は学習する必要がある。そこで、前年の同期間まで含め 15 か月を学習期間とした。

対象店舗は図 2.2 に示すように、来店客数については全店舗で調査を行い、各商品については実証実験の対象 31 店舗で調査を行った。




図 2.2 対象店舗（左：来店客数の解析対象店舗、右：各商品の解析対象店舗）

2.3.1 来店客数の解析

(1) 全体傾向把握

来店客数の全体傾向を見るため、2021年8月1日～2022年10月31日の全店舗平均の来店客数の時系列とヒストグラムを図2.3に示す。バローの来店客数は曜日によって変動し、概ね1,200～2,000人のレンジ内で推移している。1月1日は全店休業のため来店客数は0人となるが、その反動で1月2日に平均3,500人と最大の来店客数となる。ゴールデンウィークやお盆等には不規則な動きが発生する。

需要予測を行う上で極値の扱いはもっとも難しい部分であるが、ヒストグラムを見ると、極値が少なく正規分布に近い分布になっている。一般的にサービス業は極値が多い分布をしているが、スーパーはもっとも極値が少ない業態と考えられる。

ただし、各店舗の中では極値が発生している店舗も存在する。図2.4に極値が発生している例としてD店の2021年8月1日～2022年10月31日の時系列を示す。この店舗では、2022年7月2日にリニューアルを行っており、リニューアル直後はセール等を行うため、初日の7月2日には3,931人が来店、開店後1か月までは来店客数が多い状況が続いていた。AIは過去のデータから学習して予測を行うため、リニューアルのように過去に発生していない状況の予測は困難である。したがって、過去データが存在しない開店時や、リニューアル後の数日間は需要予測が困難であるため、発注量は売上目標から設定する等の代替案を用意しておく必要がある。




図 2.3 来店客数の全体的な傾向

(左：全店舗平均の来店客数の時系列、右：来店客数のヒストグラム)




図 2.4 極値の一例

(2) 暦との関係性

2021年8月1日～2022年10月31日の全店舗平均の季節変動と曜日変動を図2.5に示す。季節変動は1月1日～7日を第1週とし第52週まで、複数年にわたるデータを平均して求めた。データを見ると、年末に来店客数をもっとも多く、節分やゴールデンウィーク、お盆も増加していることが分かる。曜日変動では、平日は水曜日・木曜日に来店客数が少し増加する傾向はあるものの概ね同程度の来店客数で、土曜日・日曜日の週末に来店客数が増加していることが分かる。

したがって、需要予測においては、季節変動や曜日変動等を考慮することができる説明変数⁶を設定することが必要である。




図 2.5 全店舗平均の来店客数の季節変動と曜日変動

⁶ 説明変数とはある現象や値を説明するもので、その変動の原因となるものである。本項では季節や曜日が来店客数の変動原因となっていることが示されており、これらを代表する変数を設定することで需要予測精度が向上する可能性が高い。

(3) 店舗特性との関係性

各店舗のレジ台数、駐車場台数、敷地面積と来店客数の関係性について図 2.6 に示す。それぞれの変数と来店客数は正の相関があり、レジ台数、駐車場台数、敷地面積が大きくなると来店客数も増加する傾向があることが分かる。各変数と来店客数との決定係数⁷を算出すると、レジ台数が 0.84、駐車場台数が 0.55、敷地面積が 0.62 とレジ台数と来店客数の関係性がもっとも高くなっていた。

これは、駐車場台数や敷地面積は店舗を建設する時に決められる特性であることに対し、レジ台数は来店客数が増加するとレジを設置するという関係性にあるため、関係性が強くなっていると考えられる。




図 2.6 店舗特性と来店客数の関係性

⁷ 決定係数は説明変数が目的変数をどのくらい説明できるかを示す値。決定係数が 1 の場合、説明変数は目的変数を完全に説明でき、決定係数が 0 の場合、説明変数は目的変数をまったく説明できないことを示す（資料編、資料-2 式）

(4) 気象との関係性

発注担当者へのヒアリングでは、来店客数は気象（特に雨）と関係性があるとの意見であった。そこで、雨と来店客数、気温と来店客数の関係を図 2.7 に示す。ここで、来店客数は曜日の影響を受けているため、気象と来店客数の関係性を加工なしで見ても評価ができない。そこで、来店客数の曜日による変動の影響を取り除くため、来店客数は（対象日の来店客数） / （前週同曜日の来店客数）に変換して縦軸に、気象は（前週同曜日の気象 - 対象日の気象）に変換して横軸に取り、散布図として図化した。したがって、来店客数は縦軸で 1.0 の値は前週同曜日と同じ、1.0 を切ると前週同曜日より減少、1.0 を超えると前週同曜日より増加しているとの意味になる。

雨と来店客数の関係性の図を見ると、雨が強く降れば降るほど来店客数は 1.0 より小さい値を取っている（来店客数が減少している）ことが分かる。また、表 2.5 に示すように、雨の来店客数減少効果は曜日によって異なり、減少効果は平日では約 5.0% 程度だが、土曜日では 8.8% と高い効果があった。これは、平日は仕事の帰りにスーパーに来店する消費者が多く雨が降っても来店するが、土曜日は買い物自体を目的に来店している消費者が多く雨が降ると来店を控える傾向があるためと考えられる。

一方、気温と来店客数の関係性の図を見ると雨ほど明確な関係性は見えないことが分かる。各曜日における効果もプラスの曜日とマイナスの曜日があり、明確な関係性は見られない。

表 2.5 各気象要素の曜日別の効果

要素	月	火	水	木	金	土	日
雨の影響 (%)	-6.0	-5.1	-5.5	-5.0	-4.9	-8.8	-3.8
気温の影響 (%)	+1.7	+0.4	-0.6	-1.1	0.8	-0.4	+0.1




図 2.7 来店客数と気象の関係性

（左：雨と来店客数、右：気温と来店客数）

ヒアリングでは台風が店舗周辺に大きな被害をもたらす場合は、来店客数は台風の影響がもっとも大きい日付の前日に増加、当日は大きく減少するとの意見があった。今回の解析対象期間において東海地方に上陸した台風は存在しなかったため、もっとも東海地方に接近した 2022 年の台風 14 号について解析を行った。

図 2.8（上図）の天気図に示すように、台風 14 号は、9 月 18 日 19 時頃に中心気圧 935hPa、非常に強い勢力で鹿児島市付近に上陸し、9 月 19 日朝にかけて九州を縦断した。台風 14 号により、九州を中心に西日本で記録的な大雨や暴風となり、9 月 15 日の降り始めからの総雨量は、九州や四国の複数地点で 500 ミリを超え、9 月の 1 か月の平年値の 2 倍前後となった。名古屋では 9 月 19 日に最大瞬間風速 21.3m/s を記録し、9 月 19～20 日にかけて 45mm の降雨を観測した。

バロー店舗の来店客数の推移を図 2.8（右図）に示す。本図では曜日ごとの比較が必要なため、7 日ごとに補助線を引いている。台風がもっとも接近した 9 月 19 日は、前週同曜日より来店客数が 2.6% 減少し、前日・前々日の来店客数は前週同曜日より約 3.5% 増加していた。これは、ヒアリング結果の「台風来襲時の来店客数は、かけこみ需要で接近前に増加し接近時に減少する」と一致している。

しかし、今回の検証期間では東海地方に影響を与えた台風事例が 1 事例と非常に少ないため、統計的に有意であるとまでは言えない。




図 2.8 2022 年台風 14 号と来店客数
(上：9 月 18・19 日の天気図、下：各店舗平均の来店客数時系列)

2.3.2 各商品の解析

各商品の解析では、表 2.6 に示すように本実証実験の対象商品である惣菜の完成品の解析を行った。ここで、完成品とは工場で完成されパッキングされた商品で、店舗内調理を必要としない商品を指す。

対象カテゴリは、「おにぎり・弁当」、「寿司」、「惣菜」の 3 カテゴリとした。「おにぎり・弁当」カテゴリは、平均売上がもっとも大きく賞味期限 0 日の商品が中心で値引きがもっとも生じやすいカテゴリである。ここで賞味期限 0 日とは賞味期限が 24 時間以内でその日に販売できないと廃棄につながる商品である。代表的な商品としては「手巻きおにぎり」シリーズや「まんまるおむすび」シリーズ等がある。「寿司」カテゴリは、賞味期限 0 日の商品が中心で節分や年末等、季節の行事によって大きく売上が変動するカテゴリである。代表的な商品としては「いなり寿司」や「助六寿司」がある。「惣菜」カテゴリは、賞味期限は 1 日以上の商品が中心で在庫をコントロールすることが重要なカテゴリである。また、季節や旬による売上変動がもっとも大きいため需要予測の難易度が高い。代表的な商品としては、「サラダ」や「旬のお惣菜」等がある。

表 2.6 本実証実験の対象商品

項目	内容
種別	完成品
賞味期限	0～14 日
商品数	大型:約 150SKU、小型:約 60SKU
カテゴリ	おにぎり・弁当、寿司、惣菜

表 2.7 各カテゴリの特徴

項目		おにぎり・弁当	寿司	惣菜
種類数		49	25	59
1SKU 当たりの平均販売数		9.6 個	7.9 個	6.7 個
売上数量	1 位	手巻きおにぎり (天日塩の塩鮭)	コク旨いなり 8 貫	8 品目の ミックス野菜サラダ
	2 位	手巻きおにぎり (ツナマヨネーズ)	助六寿司 8 貫	ごろっと ポテトサラダ (大)
	3 位	まんまるおむすび (五目炊き込み)	コク旨いなり 4 貫	ごろっと ポテトサラダ (小)

(1) 全体傾向の把握

商品売上の全体傾向を把握するため、対象 31 店舗の全商品売上総数と来店客数の時系列と商品売上数のヒストグラムを図 2.9 に示す。全商品の売上は来店客数と同様に曜日とともに変動をしており、来店客数が増加すると売上が増加する傾向であることが分かる。一方、2022 年 2 月 3 日を見ると、来店客数の増加は小さいのに対し、売上は大きく増加していることが分かる。これは、2 月 3 日は節分の日で恵方巻等の売上が大きく増加するためである。このように、売上は基本的に来店客数と連動しているが、特別な事情がある場合はその関係性は崩れると言える。

売上のヒストグラムでは、売上が 10 個/日以内の商品が約半数を占めているが、20～30 個/日の商品も日常的にあることが分かる。一方で、売上が 50 個/日を超える商品も存在し、これは販促や特異日（節分等）に発生している売上と考えられる。

上記から、カテゴリの需要予測は来店客数予測に直近トレンドを考慮した数値を掛け合わせることで求めることが可能になると考えられる。一方で、その関係性が崩れる特異日においては別の方法の予測を検討する必要がある。




図 2.9 各商品の売上の全体傾向

(左：全商品売上総数と来店客数、右：各商品の売上のヒストグラム)

(2) 各カテゴリの動き

「おにぎり・弁当」、「寿司」、「惣菜」の 3 カテゴリの対象 31 店舗、全商品平均売上個数の時系列図を図 2.10 に示す。各カテゴリとも来店客数と同様に曜日によって変動しているが、「おにぎり・弁当」は気温が上昇するときに売上が増加する傾向、「惣菜」は冬場に売上が少し減少する傾向、「寿司」は節分の日や年末に売上が増加する傾向がある。このように、各カテゴリによって動きは異なるが、カテゴリ内は同じ特徴を持った商品が集まっており、消費者が商品を購入する際に A 商品がなければ同カテゴリの B 商品を購入するというような代替可能な商品群であることが分かる。

したがって、需要予測は商品をいくつかのカテゴリに分類し、その分類に応じて予測する必要がある。




図 2.10 各カテゴリの対象 31 店舗全商品平均の時系列図
(上：おにぎり・弁当、中：寿司、下：惣菜)

(3) 定番商品と季節商品

商品には一年中販売されている定番商品と、特定の季節にのみ販売されている季節商品が存在する。そこで、1 年間の販売日数と売上個数の散布図を図 2.11 に示す。販売日数が 300 日以上と通年で販売されている商品も存在する一方、販売日数が 50～150 日と特定の季節に販売されている季節商品も多く存在する。また、販売日数が 30 日以下の商品も存在しており、これらは年末等特別な時期にだけ販売されている商品と考えられる。

図 2.11 の典型的な定番商品と季節商品の時系列を見ると、定番商品は年間を通じて売上有る一方、季節商品は販売開始時期に売上が増加し販売終了に向けて少しずつ減少していることが分かる。これは、消費者は常に定番商品を購入するのではなく、旬の商品が販売された際は旬な商品を試していると考えられる。このような商品は商品棚を彩り、買い物の楽しさを提供することができるため、定期的に入れ替えられる傾向がある。

したがって、季節商品における需要予測は、販売直後は学習データがなく予測が困難であるため予測以外の方法で発注を行い、販売開始後は売上が減少していく状況を再現することができるモデルを構築する必要がある。




図 2.11 定番商品と季節商品

(上：平均売上個数と売上日数、下：定番商品と季節商品の平均時系列図)

(4) 新商品の動き

新商品（もしくは季節商品）が発売された場合や商品がリニューアルされた場合は、通常の商品の動きとは異なる動きになる。図 2.12 に新商品・季節商品として「国産なすの揚げ浸し」の対象店舗合計売上の時系列と、リニューアル商品として「ごろっとポテトサラダ（大）」の全店舗合計売上の時系列を示す。

新商品・季節商品は販売開始時期に売上がもっとも大きく季節終了に向かって次第に減少していた。これは、消費者が季節や旬に応じて購買行動を行っており、季節変わりには新しい商品を消費する傾向があるためである。このような季節商品は、季節が終了する時期に別の新たな商品が販売開始され、売上は次第に減少していく。

一方、リニューアルは通年販売の定番商品で実施され、赤色の折れ線の通り変更後 1～2 週間程度は売上が増加し、その後はこれまでの売上と同水準に戻っていく。これは、商品がリニューアルされる際には該当商品は目立つ箇所に陳列されるためと考えられる。

したがって、新商品やリニューアル商品は、販売から 2 週間程度は AI で予測するのではなく、別の方法で予測する必要がある。




図 2.12 新商品の動き（上：季節商品、下：リニューアル商品）

(5) 気象の影響

定番商品における雨の影響を見るため、図 2.13 にもっとも売上が大きい「8 品目のミックス野菜サラダ」の対象店舗合計売上と雨の時系列を示す。降雨日は通常より来店客数が減少するため、各商品の売上も減少する傾向にあるが、来店客数ほど関係性は明白ではない。これは、現在の経験と勘の発注では、気象予測を十分に考慮できていないため降雨日も晴れの日と同程度の発注を実施して在庫過剰になり、値引きを増やして売り切りを目指すオペレーションが実施されているためと考えられる。




図 2.13 定番商品の売上と気象の関係性

(上：対象全店舗平均の雨の時系列、下：対象全店舗合計の定番商品の売上時系列)

各商品と気温の関係性を調査したところ、日単位の気温と売上の相関係数の絶対値がもっとも高い商品は「炙り焼き豚の冷やし中華（マヨ付）」であった。そこで、「炙り焼き豚の冷やし中華（マヨ付）」を例に気温と売上の関係性を評価した。

「炙り焼き豚の冷やし中華（マヨ付）」の対象店舗合計売上と雨・気温の時系列を図 2.14 に示す。「炙り焼き豚の冷やし中華（マヨ付）」は、もっとも気温が上昇した 8 月初旬に最大の売上を記録しており気温と売上に強い関係性が見られる。来店客数や売上総量の変動は雨の影響が大きく気温の影響は小さかったが（2.3.1(4)）、各商品の売上の変動は雨の影響に加えて気温の影響も受けていることが分かる。

したがって、来店客数予測から商品ごとの需要予測を求める際、気温の影響を考慮する必要があることが分かる。




図 2.14 「炙り焼き豚の冷やし中華（マヨ付）」の売上と気象の関係性
（上：対象全店舗平均の気温の時系列、下：対象全店舗合計の冷やし中華の売上時系列）

(6) 販売促進

バローではポイントアップキャンペーンの販促が行われている。ポイントアップキャンペーンは、限定された対象店舗・対象商品に対して水曜日から 1 週間連続で販促を行っている。

例として図 2.15（左図）に期間中に販促が複数回実施された「具だくさん彩りちらし寿司」の売上推移を示す。時系列を見ると、販売促進を実施している時期は販売促進を実施していない時期と比較して売上が増加していることが分かる。

販売促進の効果を見るため、販売促進を実施している日の売上とその 7 日前の売上の散布図を図 2.15（右図）に示す。7 日前と比較しているのは、売上が曜日の影響を受けて変動するため、曜日影響を除去するためである。散布図を見ると販売促進を実施している時期は、7 日前と比較して売上が増加していることが分かる。ただし、対象 31 店舗の売上総数が 1,000,000 個以上の売上が大きい商品については、販売促進の効果はあまり生じていなかった。




図 2.15 販売促進の効果

（左：販促商品の 31 店舗合計売上の時系列、右：販促時と 7 日前の売上の比較図）

(7) 予約の影響

スーパーでは予約を受け付ける商品も存在する。図 2.16 に E 店における「手巻きおにぎり（天日塩の焼鮭）」の時系列を示す。本商品は平日に 40 個程度、休日に 80 個程度の売上有るが、2022 年 9 月 22 日は平日にも関わらず 90 個程度の売上、10 月 8 日、9 日は土日だが 90 個程度の売上有るよう売上が大きく増加する日が存在した。これは、9 月は運動会等地域のイベントがあり、そのイベントに参加する消費者がおにぎりを予約で購入しているためと考えられる。

需要予測では、予約量を AI で予測することはできないため、予約商品は新たな商品コードを付与し、発注担当者が別商品として発注する等の工夫が必要になる。




図 2.16 予約の影響 (E 店)

2.3.3 複合的な関係

来店客数と売上、値引き販売、廃棄、値引き率の関係性を図2.17に示す。2022年10月7日を見ると降雨があり来店客数は減少していることが分かる。一方で、定価販売数量は低下しているにも関わらず、全体販売数量は雨でもあまり減少していない。これは、雨の日も通常通りの発注が行われているため、晴れの日よりも値引きを多くして売り切っているためと考えられる。その結果、降雨日は定価販売数量が減少し、値引き率、もしくは廃棄数が増加していた。

したがって、需要予測は来店客数予測を利用して定価販売数量を予測し、直近の値引き率を考慮して値引きも含めた全体販売数量を求める手法がよいと考えられる。これにより、来店客数の減少に応じた需要を予測することが可能になり、ムダな値引きや廃棄を減少させることができる。また、需要に応じた発注で過剰在庫を防ぐことにより、製造業の緊急生産や原材料メーカーから工場への緊急輸送の削減、工場から小売への緊急輸送も削減することが可能になる。




図 2.17 雨と来店客数、売上・値引きの関係性

(上：気温と雨、中：来店客数と定価販売量と値引き販売量、下：廃棄と値引き率)

2.4 需要予測モデルに関する考察

店舗の売上は来店客数によって大きく変動している。特に来店客数と最も強い関係性が高いのは定価販売数量であり、定価販売数量に値引き販売量を足したものが店舗全体の売上となっている。各商品は同じ特徴を持ったカテゴリに分類することが可能で、カテゴリ内は消費者が商品を購入する際に A 商品がなければ同カテゴリの B 商品を購入するという代替可能な商品群で、カテゴリ全体で来店客数と強い関係性がある。

商品売上に影響を与える要因としては、暦、気象、人流、販売促進、その他（野菜相場等）が存在する。暦は曜日変動等を通して来店客数に大きな影響を与え、消費者嗜好の季節や旬に合わせた変化によって各商品の売上にも大きな影響を与えている。気象は、雨と気温で効果が異なっており、雨は曜日や強さによって消費者の行動変容を起こす性質があるため来店客数に影響を与え、気温は上昇すると酸味のある商品等の売上を増加、下降すると温める商品の売上を増加するように商品需要に影響を与えている。人流は新型コロナウイルス感染症（COVID-19）による行動制限のように全店舗の来店客数に影響を与え、競合の動向によっては特定の店舗に影響を与えている。販売促進は「バローの日」のように全店舗のイベントは来店客数の増加を通して全商品に影響を与え、ポイントアップキャンペーン等、各店舗・各商品のイベントはその対象商品のみに影響を与えている。野菜相場は、相場が高騰すると多品目が入った野菜サラダの売上が増加する等の影響を与えている。相場自体を把握すること自体は難しいが、商品の売上トレンドを通して影響を与えている。

そこで、本事業での需要予測は、まず来店客数予測を行い、その来店客数予測を利用してカテゴリの定価販売量から全体販売量の需要を予測、そのカテゴリ全体販売量を利用して SKU 単位の需要を予測することで、各段階での関係性を評価した。来店客数予測は、暦や雨、人流、全体販促情報を説明変数に利用し、汎用的 AI 予測モデル「サキミル」⁸を利用した。カテゴリ需要予測では暦、気温を説明変数として需要予測を行い、トレンドによる補正を実施した。SKU 需要予測では、カテゴリ需要予測からカテゴリ内の売上比率から SKU ごとの売上を求め、トレンドによる補正を実施することとした。

⁸ サキミルはソフトバンク株式会社、一般財団法人日本気象協会が開発した人流や気象のデータを活用した AI（人口知能）による需要予測サービス。
<https://www.softbank.jp/biz/services/analytics/sakimiru/>

2.5 まとめ

2.5.1 ヒアリング

ヒアリングではバローのスーパー3店舗の発注担当者を対象に実施した。需要の変動要因には暦・店舗特性・気象・販売促進・その他の影響があることが分かった。

暦の要因としては、曜日変動、季節変動、特異日等が来店客数に影響を与えており、曜日や季節変動は規則的な変化、特異日は節分の日や年末等、急激な来店客数増加を発生させている。

店舗特性の要因としては、床面積・レジ台数等が来店客数に影響を与えており、AIでは自店舗だけでなく他店舗のデータも利用して複雑な関係性を考慮した予測をすることが可能である。

気象の要因としては、雨・気温・台風等が影響を与えているが、雨や台風は来店客数を減少させ、気温は上昇すると酸味のある商品等の売上が増加し、下降すると温める商品の売上が増加する等、各商品の需要に影響を与えている。

販売促進の要因としては、「バローの日」のような全店舗の販促と、ポイントアップキャンペーンのような特定の店舗・商品の販促があり、全店舗の販促は来店客数に影響するが、特定の店舗・商品の販促は特定の店舗・各商品の売上に影響を与える。

その他の要因としては、野菜の相場、競合の動向等があり、野菜の相場が高騰すると多品目の野菜が利用されている野菜サラダ等の需要が増加し、店舗周辺で競合店舗が開店するとその店舗の来店客数は減少する。

2.5.2 データを用いた解析

データを用いた解析ではヒアリングで得た情報をデータで確認できるか検証するため、来店客数、各商品の売上の解析を実施した。

(1) 来店客数

来店客数は曜日変動、季節変動の影響が大きい、年末等は特異日で売上変動が通常と異なる。リニューアルを実施した場合は開店日周辺で客数が大きく増加することが確認できた。来店客数は降雨によって減少するが、土曜日に影響が大きい等、曜日によってもその変化は異なることが分かった。

(2) 各商品

バローでは商品は「おにぎり・弁当」、「寿司」、「惣菜」の3つのカテゴリに分類されているが、各カテゴリで動きは異なっている。また、商品には定番商品と季節商品が存在しており、季節商品は販売開始直後に売上は増加するが、季節終了に向けて少しずつ減少していく。雨の影響は存在するが来店客数ほど大きくなく、「冷やし中華」等、商品によっては気温の効果の方が大きい。商品ごとに実施しているポイントアップキャンペーンは、

販促期間中に売上が増加する。また、それ以外の影響として近隣で運動会等が実施される場合は予約による売上増加が発生することが分かった。

(3) 複合的な要因

降雨日は来店客数が減少し定価販売数量も減少するが、全体販売数量は大きく変わっていない。これは、雨の日も通常通りの発注が行われており、晴れの日よりも値引きを多く実施して売り切っているためと考えられる。その結果、降雨日は値引き率、もしくは廃棄数が増加していた。

2.5.3 需要予測モデルに関する考察

店舗の売上は来店客数によって大きく変動している。特に来店客数と最も強い関係性があるのは定価販売数量であり、定価販売数量に値引き販売量を足したものが店舗全体の売上となっている。各商品は同じ特徴を持ったカテゴリに分類することが可能で、カテゴリ内は消費者が商品購入する際に A 商品がなければ同カテゴリの B 商品を購入するという代替可能な商品群で、カテゴリ全体で来店客数と強い関係性がある。

商品売上に影響を与える要因としては、暦、店舗特性、気象、人流、販売促進、その他（野菜相場等）が存在する。暦は曜日変動等を通して来店客数に大きな影響を与え、消費者嗜好の季節や旬に合わせた変化によって各商品の売上にも大きな影響を与えている。気象は、雨と気温で効果は異なっており、雨は曜日や強さによって消費者の行動変容を起こす性質があるため来店客数に影響を与え、気温は上昇すると酸味のある商品等の売上を増加、下降すると温める商品の売上を増加する等、商品需要に影響を与えている。人流は新型コロナウイルス感染症（COVID-19）による行動制限のように全店舗の来店客数に影響を与え、競合の動向によっては特定の店舗に影響を与えている。販売促進は「バローの日」のように全店舗のイベントは来店客数の増加を通して全商品に影響を与え、ポイントアップキャンペーン等、各店舗・各商品のイベントはその対象商品のみに影響を与えている。野菜相場は、相場が高騰すると多品目が入った野菜サラダの売上が増加する。相場自体を把握することは難しいが、商品の売上トレンドに影響を与えている。

そこで、本事業での需要予測は、まず来店客数予測を行い、その来店客数予測を利用してカテゴリの定価販売量から全体販売量の需要予測、そのカテゴリ全体販売量を利用してSKU 単位に分類する需要予測を行うことで、各段階での関係性を評価する。来店客数予測は、暦や雨、人流、全体販促情報を説明変数に利用し、汎用的 AI 予測モデル「サキミル」を利用する。カテゴリ需要予測では暦、気温を説明変数として需要予測を行い、トレンドによる補正を実施する。SKU 需要予測では、カテゴリ需要予測からカテゴリ内の売上比率から SKU ごとの売上を求め、トレンドによる補正を実施することとした。

3. 複数事業者協働による実証実験

本章では複数企業の需要予測に関する情報の共有により AI で作成する需要予測をもとに、製品の在庫配置を最適化することで、在庫の分散管理に伴う在庫量の増大を防止することについて実証実験を実施した。対象店舗は複数エリアで 31 店舗、対象商品は惣菜、対象期間は 2024 年 1 月 22 日～3 月 21 日の 2 か月間とした。これは、小売店の売上傾向が通常時と大きく変化する年末年始を避け、連続して 2 か月間を確保するためである。

効果検証は、物流への影響を評価するための KPI として、発注回数、輸送回数（緊急輸送回数を含む）、輸送距離を設定、在庫配置の最適化を評価するための KPI として廃棄を設定した。また、上記に加え、各社の生産性を評価するための KPI として売上・利益額、欠品、作業時間を設定した。

実証前の指標値は 2023 年 9 月 25 日～11 月 12 日、2024 年 1 月 8～21 日の実績を利用した。これは、11 月 15 日～12 月 15 日までシステムが正常に稼働するかを数店舗で実験したため、さらに正月期間を除いた直前の 8 週間として設定した。

また、緊急輸送等物流負荷の更なる低減に向けて、当該実証実験に参画する企業当事者間で需要予測の誤差を解決する手順を準備し、需要予測の誤差の解決手段として追加的に改善・実施すべき要素の必要性も含めて体系的に整理した。

3.1 対象の設定

(1) 対象店舗

消費者嗜好は地域によっても異なるため、同じチェーン内においても地域が異なると各商品の売れ行きは傾向が異なる。また、店舗の規模によって売場面積が異なるため、取り扱うことのできる商品数も異なり、オペレーションを行う人員規模や方法も異なってくる。

自動発注は、これらの異なる特徴を持った各店舗に対し、それぞれの特徴を考慮した予測を算出する必要がある。また、異なるオペレーション体制においても機能する業務プロセスを確立する必要がある。

そこで、バロー店舗を「愛知・岐阜・三重エリア」、「静岡・長野エリア」、「北陸エリア」、「関西エリア」の 4 つのエリアに分け、店舗規模を大型、中型、小型の 3 つのカテゴリに分け、各エリア・各規模の 31 店舗を選択した。対象とした店舗の分布図を図 3.1 に示す。




図 3.1 対象店舗

(2) 対象商品

対象商品は表 3.1 に示すようにバローに納品されている惣菜の完成品とした。ここで完成品とは、店舗内で調理が必要とされない工場でパックされた商品である。惣菜は中部フーズが製造している商品と他社が製造している商品の 2 種が存在するが、他社が製造している商品も中部フーズが仕入れた上で店舗に納入されている。本実証実験では中部フーズ、他社の両商品を対象とした。

賞味期限は 0 日～180 日の商品が存在する。賞味期限が 0 日の商品にはおにぎりや弁当、賞味期限が 1 日の商品にはサラダ類や煮物、賞味期限が 1 週間程度の商品には昆布、賞味期限が 2 週間を超える商品にはドレッシング等が存在する。賞味期限が 0 日の商品（おにぎり等）は仕入れ当日に売り切らなければならないため廃棄が生じやすい。一方、賞味期限が長い商品は仕入れ当日に売り切らなくとも廃棄されないが在庫管理をしなければ欠品や廃棄が生じるという特徴があり、賞味期限によってオペレーションの考え方は大きく異なる。

また、売場が大きい店舗は発注に時間をかけ商品数を 150SKU と多く並べることができるため廃棄等が生じにくい、売場の小さい店舗では発注に時間をかけられず商品数は 60SKU ほどに絞る必要があるため廃棄や欠品が生じやすいと、店舗規模によってもオペレーションは異なる。

表 3.1 本実証実験の対象商品

項目	内容
カテゴリ	惣菜の完成品
賞味期限	0～180 日
商品数	大型：約 150SKU、小型：約 60SKU
工場	中部フーズ製造品、他社からの仕入れ品

(3) 対象期間

実証実験で効果を確認するためには安定した時期に実施する必要がある。そこで、小売店の売上が大きく変動する年末・年始を避け、2024 年 1 月 22 日～2024 年 3 月 21 日を対象とした。

3.2 オペレーション変革

(1) 現在のプロセス

現在のオペレーションの業務プロセスを図 3.2 に示す。発注に関するオペレーションでは、年単位では本部がその年の売上計画・商品計画を立案、月単位では店長が毎月の売上計画を立案、週単位ではチーフが売上計画から陳列する商品を決定、前週の売れ行き状況を確認した上で経験と勘で週間発注を実施する。週間発注は図 3.3 に示すように経験と勘で実施されるが、前週の売上、利益率、廃棄率を考慮し、工場から納品可能な物流スケジュール、発注ロット、各商品在庫の賞味期限等、あらゆるデータを利用して発注を検討する必要がある、担当者の作業時間の増大、精神的負担等、課題が発生している。工場では、この店舗からの週間発注に基づいて生産計画、シフト調整、段取り等が計画され、日々の生産が実行されている。

しかし、店舗からの経験と勘による週間発注は直近の売上トレンドを中心に予測されており、特に雨や雪、台風のように天候に変化があった場合に想定とは異なる在庫変動が発生し、納品 2 日前に図 3.4 に示すように修正発注が実施されている。製造業ではこのような修正発注が実施された場合、工場の生産計画・シフトの変更を行う必要があり、原材料の緊急調達、店舗への緊急納品、これらにともなう緊急輸送、仕掛品在庫の廃棄等から生産性が低下している。

このような問題は、店舗の週間発注の予測精度が十分でないため修正発注が行われており、その修正発注は製造リードタイム（3 日）より短いリードタイムで行われていることが原因で発生していると考えられる。店舗の発注作業負担について 3 店舗にアンケートを行ったところ、店舗の発注に係る作業時間は表 3.2 に示すように大型店舗で 1 か月あたり 40～50 時間、小型店舗で 1 か月あたり 30～40 時間かかっており、日々の発注作業は廃棄や欠品等につながるため精神的負担も大きいことが分かった。

ここで、本事業で構築する自動発注が実現されると、精度が十分であれば約 15 時間程度の削減が可能になり、発注作業負担も軽減されることが考えられる。

表 3.2 発注作業時間

店舗		A 店	B 店	C 店
規模		大型	大型	小型
週間発注	実施時間	月曜日 11～12 時	月曜日 11:50 まで 木曜日 11:50 まで	月曜日 or 火曜日
	担当者	1 人×4 カテゴリ	1 人×4 カテゴリ	1 人×4 カテゴリ
	時間	1 時間弱	30～45 分 (月始めは 1 時間)	30～40 分
修正発注	実施時間	毎日 11～12 時	毎日 11:50 まで	毎日
	担当者	1 人×4 カテゴリ	1 人×4 カテゴリ	1 人×4 カテゴリ
	時間	10～20 分	15～20 分	15 分
月合計時間（全体）		40 時間/月	44.8 時間/月	34 時間/月
月合計時間（対象）		15 時間/月	16.8 時間/月	12.8 時間/月

(2) ToBe プロセス

本実証実験で実現する新たな業務プロセスでは、図 3.5 に示すように店舗からの発注を自動化することで発注作業を軽減し、AI 需要予測を導入して発注精度を向上することで修正発注を削減する。修正発注の削減が実現すると納品リードタイムは 3 日以上になり、これまで製造業が行っていた見込み生産を受注生産に変更することが可能になる。これまで、見込み生産であったため小売からの発注量が予測していた量よりも少ない場合は仕掛品在庫の廃棄が発生、小売からの発注量が予測していた量よりも多い場合は緊急生産が発生、緊急に生産するためには原材料メーカーから原材料を緊急輸送、生産した商品を店舗へ緊急輸送することになり、通常時とは異なるトラックドライバーやトラックの確保等、物流に大きな負担を生じさせていた。これらを削減することで工場の生産性向上、物流負荷の低減につながると考えられる。

また、これまでは各社で自社在庫をコントロールしていたが、共同で在庫をコントロールすることで在庫最適化を目指す。共同で在庫をコントロールし、分散管理することによって在庫量の増大を防止するためには、小売の在庫を極小化し、卸・製造業の物流拠点等に在庫を集中することで在庫を減少させるという考え方がある。これは、N 個を合計した量を予測することによって予測精度が N の平方根に比例して向上するため在庫を減少させることができるという考え方である⁹。一方、今回の実証実験は小売の分散された在庫を管理することによって製造業の仕掛品在庫の増大を防止するという考え方を採用している。これは、各店舗 N 個の需要予測精度を向上させ製造業と共有することによって製造業の予測を不要にし（見込み生産を受注生産に変更し）在庫を減少させるという考え方である。前者は季節商品等、特定の季節に売上が増加する商品で工場のキャパシティの問題から生産拠点や物流拠点に在庫を多く持つ商品に効果的な考え方で、後者は日配品等、賞味期限が短く在庫を常に回転する商品で効果的な考え方である。本実証実験では日配品の惣菜を対象としたため、後者の考え方を採用した。

発注推奨システムによる自動化では、バロー、中部フーズ、ソフトバンク、日本気象協会から需要予測に関連するデータを収集し、自動的に発注推奨量を算出した上で発注端末と連携して発注を行う。ただし、節分の日等、特異日は AI による需要予測の精度は低下するため本部による店舗発注の代替（以下、送り込み）を実施する、消費者の予約は AI で需要予測することができないため予約商品は特別の商品コードを付与して別発注を行う等、需要予測の精度が低下する事例については異なる発注方法を行うこととした。

⁹ ある 2 店舗の誤差をそれぞれ σ_x 、 σ_y とすると、2 店舗を合わせた誤差 σ_z との関係性は、 $\sigma_z^2 = \sigma_x^2 + \sigma_y^2$ となる。したがって、同じ誤差 σ を持った店舗が N 店存在する場合は、N 店を合計した誤差は $\sqrt{N}\sigma$ となる。




図 3.2 現状の業務プロセス




図 3.3 店舗週間発注の考え方




図 3.4 店舗修正発注の考え方




図 3.5 実証実験で実現する業務プロセス




図 3.6 店舗発注の考え方

(3) 実証実験時のルール

実証実験ではオペレーションを従来から大きく変更するため混乱が生じる可能性がある。そこで、本部・各店舗について表 3.3 のルールを設定した。

発注推奨量は明らかな異常値のみは修正するが、できるだけ変更せずそのまま発注を行う。発注に対する気付き、追加、削除等があれば日々のアンケートに記載し、修正する必要がある場合は本部担当に連絡する。AI による需要予測は学習するデータが少ないと精度が低下する傾向があり、導入から 2 週間以内の新商品やリニューアル商品、節分の日の恵方巻等は十分な精度で予測できない。そこで、需要予測精度が低下する商品については、本部からの送り込みで対応することとした。また、消費者個人の事由により発生する予約については、AI による需要予測はできないため異なるコードで発注することとした。

表 3.3 実証実験中の役割

担当		既存店舗			新店舗
		通常発注	予約発注	需要予測精度が低下する商品	
製造	ブロック長	明らかな異常のみ修正	-	—	対象外
	商品開発部	-	—	送り込み	
小売店舗	チーフ	気付き・追加・削除等がある場合本部担当に連絡	異なるコードで発注		
	担当	発注量を日々確認 アンケートに回答	-	—	

3.3 発注推奨システムの構築

発注推奨システムでは、各企業からデータを収集し、需要予測モデルで各商品の売上を予測し、在庫最適化モデルで各商品の在庫を最適化するための発注数量を求め、発注推奨量を発注端末に連携する。

3.3.1 システム

本事業では、実証実験の成果を様々な企業に展開することを目指すため、展開可能性の高い Amazon.com が提供するクラウドコンピューティングサービスの AWS (Amazon Web Service) で構築した。

本システムの AWS 構成図を図 3.7 に示す。本システムでは AWS の Tokyo Region において、各社からデータを収集し、S3¹⁰に配置、データベース (Aurora) に登録し、データベースにアクセスして動作する需要予測モデル・在庫最適化モデルを EC2¹¹で実行、最終アウトプットである発注推奨量を S3 に配置、この発注推奨量を発注端末に連携する。プログラムでエラーが発生した場合は、AWS CloudWatch を介して、各社の関係者にメールで通知される。また、AWS Osaka Region にデータのバックアップは保持している。




図 3.7 AWS 構成図

¹⁰ Amazon Simple Storage Service の略称。AWS が提供するサービスに含まれる機能の一つで、オブジェクトストレージサービスの一種であり、データを保存することができる。

¹¹ Amazon Elastic Compute Cloud の略称。AWS が提供するサービスに含まれる機能で、仮想サーバを構築できる。

システム内のデータ一覧を表 3.4 に、データの動きを図 3.8 に示す。中部フーズ、バロー、ソフトバンク、日本気象協会からデータを収集し入力データとし、需要予測結果、発注推奨量、ログを出力データとする。

小売店のバローからは、トランザクションデータ¹²としてレシートデータ、来店客数データ、廃棄データを収集、マスタデータ¹³として店舗マスタを収集した。製造業の中部フーズからは、トランザクションデータとして仕入れデータ、棚卸データ、本部発注データ、店舗発注データを収集した。発注量は本部からの発注量と店舗からの発注量が存在している。これは、通常商品は店舗から発注しているが、新商品等は店舗から経験と勘で発注することが難しく本部で発注量を決めているためである。ただし、自動発注が実現した際は、店舗発注は予約商品だけとなる。仕入れ量は店舗発注量と本部発注量の合計値であるが、納品リードタイムの分、更新時間が異なるため、本事業では両者のデータを利用した。マスタデータは、店舗マスタ、商品マスタ、店別商品マスタ、店休日マスタ、物流スケジュールマスタ、販促マスタ、利益最大化マスタを収集した。ここで、店別商品マスタは各店舗で陳列する商品リストを示すものであり、物流スケジュールマスタは中部フーズ以外の工場で生産している商品の仕入れ可能日を示すものである。

サードパーティデータとしては日本気象協会から気象の観測・予測データ、ソフトバンクからはサキミル来店客数予測データを収集した。気象データは各店舗の最高気温、最低気温、平均気温、日射量、風速、風向、雨量、降雪量、相対湿度、天気、体感気温等のデータを収集した。サキミルは、人流統計データや気象データ、企業データ、暦データ等を利用して、来店客数予測を配信するサービスで、本事業では日々の 14 日間の来店客数予測データを取得した。


取り込み処理はバッチ起動とした。データは各社で従来利用されている Format で受信し、データ整形処理を行った上でデータベースに登録した。ここでエラーが生じた場合はログに出力され、エラー内容は各社にメールで通知される。データベースには 2 年分のデータを保持し、2 年以上過去のデータは日々消去する。データにはマスタデータとトランザクションデータが存在するが、データベースへの登録は、マスタデータは全件連携した上で更新されたデータを抜き出して登録、トランザクションデータは差分連携で全件登録を行った。

¹² 本報告書ではトランザクションデータは商取引、売買等の日々の取引記録を示す

¹³ 本報告書ではマスタデータは固定された属性データを示す。

表 3.4 発注推奨システム内のデータ一覧

データ名	管理会社	更新時刻	ファイル名	内容
販売実績データ	パロー	6:00	TORIIHIKI_YMD.csv	前日のレシートデータ
廃棄データ		6:00	HAIKI_YMD.csv	前日の各店舗・各商品の廃棄量
来店客数データ		6:00	KYAKUSUU_YMD.csv	前日の各店舗の来店客数
店舗マスタ1		6:00	SHOP_MASTER1_YMD.csv	店舗情報一覧
仕入れデータ	中部フーズ	6:00	SHIIRE_YMD.csv	前日の各店舗・各商品の仕入れ量
棚卸データ		6:00	STORAGE_YMD.csv	日曜日・月末の各店舗・各商品の在庫量
本部発注データ		6:00	OKURIKOMI_YMD.csv	本部からの各店舗・各商品の発注量
店舗発注データ		6:00	HATTYU_YMD.csv	店舗からの各店舗・各商品の発注量
店舗マスタ2		6:00	SHOP_MASTER2_YMD.csv	店舗情報一覧2
商品マスタ		6:00	ITEM_MASTER_YMD.csv	商品情報一覧
店休日マスタ		6:00	HOLIDAY_YMD.csv	各店舗の店休日一覧
店別商品マスタ		6:00	SHOP_ITEM_YMD.csv	各店舗の取り扱い商品一覧
物流スケジュールマスタ		6:00	LOGISTIC_YMD.csv	取引先の物流稼働スケジュール一覧
販促マスタ		6:00	HANSOKU_YMD.csv	各店舗・各商品の販売促進一覧
利益最大化マスタ		6:00	BENEFIT_YMD.csv	利益最大化パラメーター一覧
来店客数予測データ	ソフトバンク	10:00	SAKIMIRU_YMD.csv	前日初期値の各店舗の来店客数予測
気象観測値データ	日本気象協会	6:00	OBS_DAILY_YMD.csv	前日の各店舗の気象観測値
気象予測値データ		6:00	FCT_DAILY_YMD.csv	当日初期値の各店舗の気象予測値
カテゴリ需要予測データ		11:00	CATEGORY_FCT_YMD.csv	当日初期値の各店舗・各カテゴリの需要予測
SKU 需要予測データ		11:30	SKU_FCT_YMD.csv	当日初期値の各店舗・各商品の需要予測
発注推奨量データ		12:30	RECOMMEND_YMD.csv	当日初期値の各店舗・各商品の発注推奨量
ログ		12:30	LOG.csv	システムログ



各処理のタイムスケジュールを図 3.9 に示す。前日の売上、廃棄、仕入れ、発注等のオペレーションデータはバローPOS システム、中部フーズ基幹システムを通して 6:00 に発注推奨システムに連携される。発注推奨量データは店舗の発注システムに連携され、店舗の確認を経て発注が行われるが、店舗の確認作業は従業員の退勤時間までに終了する必要がある。そこで、データの更新時刻、需要予測・在庫最適化モデルの計算時間、店舗の確認作業時間等を考慮し、発注推奨量は 12:30 までに出力することとした。




図 3.9 処理のタイムスケジュール

3.3.2 需要予測モデル

需要予測モデルは、来店客数予測、カテゴリ需要予測、SKU 需要予測に分けて予測を行った。これは、予測モデルは小さな単位を予測するよりその小さな単位を集計したグループを予測することで誤差の総和は小さくなる特徴があることから、特徴の同じグループを作成してそのグループの予測を行い、段階を踏んでより小さな単位を予測することで精度が向上するためである。

そこで、第一段階としてすべての商品の需要に関係する来店客数を予測、第二段階として各商品をいくつかの類似した特徴のカテゴリに分類して来店客数を説明変数としてカテゴリ売上を予測、第三段階として各 SKU が該当カテゴリの中における占有率を求めることで SKU 売上を予測した。予測モデルには AI（機械学習）を利用した。需要予測の模式図を図 3.10 に示す。

ただし、AI は過去にあった状況を学習して予測をするため、多くの学習データが必要でめったに発生しない事例を予測することは困難である。そこで、データを蓄積できていない新店舗は開店から 3 か月は対象外とし、リニューアルを行った場合は売上が大きく変化する開店直後 2 週間程度は対象外とした。また、新商品は売上の変動傾向が不明なため、投入直後の 2 週間は本部から送り込みを行うこととして需要予測対象外とした。




図 3.10 需要予測の模式図

(1) 来店客数予測

来店客数予測はソフトバンクと日本気象協会が開発し、人流統計データや気象データを活用するサキミルを利用した。サキミルは図 3.11 に示すように日本全国の人流統計データ、気象データをデータベースに保持し、汎用的な AI モデルを搭載したサービスである。本サービスでは、プロセスを自動化することによって構築コストを圧縮することが可能となっている。また、様々な企業に配信し、その予測における課題を解決することによって継続的な予測モデルの高度化を実施しており、各企業が独自に需要予測モデルを開発する場合と比較して、より高い精度でより安価に提供することが可能になっている。

データは、各企業の過去実績データに加え、店舗情報（駐車場台数、売場面積、レジ台数）、暦（曜日・祝祭日等）、人流統計データ、気象データ、企業特有の販促情報を利用する。人流統計データは個人のプライバシーを最大限配慮し、個人を特定されないように匿名化および推計処理、統計加工したデータで、ソフトバンクの携帯電話基地局から得られる数千万台の端末の位置情報から 1 億 2 千万人に拡大推計された性別・年代・訪問者区分等を全国 500m メッシュで整備している。気象データは、気温・日射・風速・降水・降雪・湿度・天気・降水確率の観測値と、日本気象協会独自の予報モデルである「SYNFOS」や国内外の複数の気象機関の予測モデルを収集し、各モデルの予測モデルに応じた統計処理を行い精度向上した 14 日先までの予測データを 1km メッシュで整備している。

来店客数予測モデルでは、各種データを組み合わせて独自の説明変数を作成し、AI モデルを利用して直近 15 か月の各店舗のデータを同時に学習することによって、人間では考えることができない複雑な関係性を考慮し、強い雨や雪等、自店舗だけでは学習データが不足する現象も予測することが可能になっている。




図 3.11 AI 需要予測サービス「サキミル」の模式図

(2) カテゴリ需要予測

カテゴリ需要予測は、類似した特徴を持つ商品を集計し需要予測を行う。類似した特徴を持つカテゴリでは、仮に売り切れが発生した商品はそのカテゴリ内の代替品を購入する特徴を持っており、カテゴリ全体の数量が消費者の需要より相対的に多い場合は値引き額の総計は大きくなり、カテゴリ全体の数量が少ない場合は売り切れが多く発生する。そこで、カテゴリ需要予測では定価販売数量の予測を行い、平均的な値引き率を考慮することで全体売上予測を行った。図 3.12 に定価販売数量と全体の売上数量、来店客数、雨の関係性を示す。2022 年 10 月 7 日は降雨によって来店客数が減少して定価販売数量も減少しているが、全体の売上数量は変化していない。これは値引き販売が増加しているためである。本モデルでは値引き販売比率を適正化した上で利益率を最大化するため、定価販売数量を予測した上で、平均値引き率を考慮して全体の売上数量に割り戻す処理を行うことで、値引き率の適正化も目指した。

一方、カテゴリ売上は人気商品がある場合は売上が大きく増加するため、来店客数と比較して変動が大きい。そこで、直近の売上変化によって生じる予測誤差（BIAS）補正も行った。




図 3.12 雨と売上数量・定価売上数量の関係性

(3) SKU 需要予測

SKU 需要予測では、カテゴリ需要予測、過去の売上データや暦、気象に加え、各店舗・商品の値引き率、販促、各商品の賞味期限、各商品の取り扱い情報等を学習した。また、カテゴリ需要予測と同様に予測誤差を再学習して補正を行った。図 3.13 に SKU 需要予測の模式図を示す。

過去データや暦、気象については、売上は曜日や祝祭日によって大きく変動する。また、お寿司は土日祝日の前に売上が増加する傾向がある、冷やし中華は夏に売上が増加するように季節商品は季節や気温によっても売上は大きく変動する、地域によって好まれる商品が異なる等、場所によっても売上は大きく変動するため、各商品の特徴や直近の売上データがより重要となる。そこで、本実証実験では過去売上情報や暦情報、直近の売上変化傾向等を学習することとした。

値引き率については、SKU の売上は日々の消費者嗜好の変化等によって大きく変動するため、消費者嗜好が低下している場合は売上が同じでも値引き率は高く、消費者嗜好が増加している場合は売上が同じでも値引き率は低くなる傾向がある。したがって、過去の売上データのみを学習して予測すると適切な予測にならない。そこで、本実証実験では SKU 需要予測を行う際に、過去の売上データに加え、値引き率も学習することとした。

販促については、バローでは店舗や時期により限定された商品においてメーカー等と連携したポイントアップキャンペーン等の販促が実施され売上が増加する場合がある。そこで、本実証実験では販促データも学習した。

賞味期限については、賞味期限の長い商品は商品棚に長い期間陳列することができるため常時陳列して販売されているが、賞味期限が短く売上の小さい商品は売上が上がる特定の曜日のみ陳列される場合がある。そこで、本実証実験では賞味期限を学習することで、性質の違う売上データを分類することとした。

各商品の取り扱い情報は、店舗による品揃えの違いを考慮して予測するため、学習することとした。




図 3.13 SKU 需要予測のイメージ

来店客数予測、カテゴリ需要予測、SKU 需要予測に利用したデータを表 3.5 に示す。

来店客数予測では来店客数データ、販促データ（バロー）に人流統計データ、気象データを掛け合わせて予測した。販促データでは、バロー店舗全体で実施する販促（例えば「バローの日」）による来店客数への影響を考慮した。人流統計データでは、店舗周辺における性別・年齢・在宅等、属性ごとのデータから店舗周辺の人の流れや新型コロナウイルス感染症（COVID-19）による人の行動変容の来店客数への影響を考慮した。気象データでは、雨や雪のように気象変化による人の行動変容の来店客数への影響を考慮した。暦データでは、曜日や祝祭日等による人の行動変容の来店客数への影響を考慮した。

カテゴリ需要予測では、同じような動きをする商品に分類し、過去売上データ、気象データ・暦データ等を利用して、それぞれのカテゴリの売上を予測した。ここで、カテゴリ分類に必要なそれぞれの商品の特徴は、商品を製造している中部フーズがもっとも熟知していることから、中部フーズの保持している商品特徴を示す商品マスタデータから商品进行分类した。

SKU 需要予測では各カテゴリの中で、各商品がどのような動きをするかを予測する必要がある。各商品の動きは季節や曜日、店舗の所在地等によって大きく変動するため、過去売上情報や暦情報、直近の変化傾向等を考慮して予測した。店舗や時期により限定された商品においてメーカー等と連携した販促が実施されるため、中部フーズの販促情報も利用した。また、上述したように賞味期限によって売上傾向が変化するため、中部フーズの賞味期限データも利用し、店舗によって陳列されている商品が異なるため、中部フーズの店別商品マスタ（各店舗の取り扱い商品データ一覧）を利用した。

表 3.5 需要予測に利用したデータ

企業	データ	客数 予測	カテ ゴリ 需 要 予測	SKU 需要 予測	データ内容
バロー	来店客数データ	○			来店客数
	販売実績データ	○	○	○	各商品の販売時間、販売数、販売金額
	店舗マスタ	○	○	○	店舗情報
	販促データ	○			バローの日等販促情報
中部フーズ	商品マスタ		○	○	商品情報（カテゴリ、賞味期限等）
	店別商品マスタ			○	各店舗での取り扱い有無
	販促データ			○	メーカーとのコラボ販促等
ソフトバンク	人流統計データ	○			店舗周辺の人流情報
日本気象協会	気象データ	○	○	○	店舗周辺の気象情報
その他	暦	○	○	○	曜日、祝祭日等

3.3.3 在庫最適化モデル

需要予測に基づき店舗在庫を最適化するため、在庫最適化モデルで発注量を算出した。在庫最適化に利用したデータを表 3.6 に示す。

表 3.6 在庫最適化に利用したデータ

項目	データ	
パロー	販売実績データ	各商品の販売時間、販売数、販売金額
	店舗マスタ	店舗情報
	廃棄データ	各商品の廃棄
中部フーズ	商品マスタ	商品情報（カテゴリ、賞味期限等）
	店別商品マスタ	各店舗での取り扱い有無
	店休日マスタ	各店舗の休日データ
	物流スケジュールマスタ	各商品の納品可能日
	仕入れデータ	店舗の仕入れデータ
	店舗発注データ	店舗からの発注データ
	本部発注データ	本部からの発注データ
	棚卸データ	各商品の在庫データ
日本気象協会	気象データ	店舗周辺の気象情報
その他	暦	曜日、祝祭日等

発注はこれまで 2 日前の修正発注が行われていたが、納品リードタイムは 3 日であり、製造業は小売からの発注量を予測して生産する見込み生産になっており、その結果、緊急生産や原材料メーカーから工場への緊急輸送、工場から小売への緊急輸送、仕掛品在庫の廃棄、生産計画、シフトの再調整等が発生し、工場の生産性低下を発生させていた。そこで、本事業では工場が計画的に生産できるよう、木曜日に次週 1 週間の発注を行い、火曜日に週末の発注修正を行うこととした（図 3.14）。これにより、発注数が週 8 回から週 2 回に変更され、納品リードタイムはどの曜日も 3 日以上となり工場の計画的な生産が実現可能になる。火曜日に週末の修正発注を行うのは、もっとも売上の大きい週末の精度を向上させるためである。




図 3.14 発注のタイムスケジュール

発注は表 3.7 に示すように商品の賞味期限、納品リードタイム、需要予測の最大リードタイム等によって考え方を考える必要がある。賞味期限が 0 日の商品であればその日に売れ残った物は廃棄しなければならないため在庫を考慮する必要はない。賞味期限が 1～5 日の場合は賞味期限が納品リードタイムより短くなる場合があるため、在庫は考慮せず納品された商品がどのように販売されていくのかを考慮して発注する。賞味期限が 5～14 日の商品は賞味期限が納品リードタイムより長く需要予測の最大リードタイムより短いため、現在の理論在庫と納品日の在庫量を予測して発注する。賞味期限が 14 日以上の商品は賞味期限が需要予測の最大リードタイムより長いため、理論在庫と欠品許容量を考慮して発注する。

表 3.7 賞味期限と発注の考え方

賞味期限	商品	考え方
0 日	おにぎり・弁当等	賞味期限は当日のみ。売れ残った商品は廃棄されるため在庫を考える必要はない。需要予測結果にしたがって発注。
1～5 日	サラダ・惣菜等	納品リードタイムより賞味期限は短くなる場合がある。納品された商品の当日、翌日以降の消費割合を考慮して発注。
5～14 日	漬物等	賞味期限が納品リードタイムより長く需要予測の最大リードタイムより短い。理論在庫から納品日の在庫量を予測して発注。
14 日以上	ドレッシング等	賞味期限が需要予測の最大リードタイムより長い。在庫を多く持つとバックヤードが圧迫されるため、理論在庫と欠品許容量を考慮して発注。

(1) 賞味期限 0 日商品の発注の考え方

賞味期限が 0 日の商品にはおにぎりや弁当等がある。このような商品は売れ残った場合は廃棄されるため、16 時以降は値引き販売をして売り切るオペレーションになる。このような商品の発注量は 3-1 式のように需要予測結果から求めた。

ただし、値引き販売率は最適化する必要があるため、需要予測は定価販売数量を求めた上で値引きを含めた全体の販売数量を求める方式を取っており、需要予測精度が向上すれば値引き数量も最適化されることになる。

$$O_{num}(t) = F_{sku}(t) \quad 3-1$$

O_{num} : 発注数量 (個)

F_{sku} : 需要予測 (個)

2022 年 8 月 24 日～2022 年 10 月 24 日の賞味期限 0 日の商品である「手巻きおにぎり (天日塩の焼鮭)」の大型店舗の発注の一例を図 3.15 示す。本商品は賞味期限が 0 日で売れ残った商品は廃棄しなければならないため、当日は値引きで売り切るオペレーションを実施している。その結果、仕入れと売上実績はほぼ一致している。ただし、予約販売が発生した場合は仕入れデータに反映されないため売上実績が仕入れより多くなる。また、閉店前に売れ残った商品を複数個パックして販売した場合は異なる商品コードでの販売になるため仕入れが売上実績よりも多くなっている (実証実験時はこれらのオペレーションは廃止する)。

図 3.15 の賞味期限 0 日の商品の売上実績 (黒線)・仕入れ実績 (青バー)・発注推奨量 (赤線)を見ると、発注推奨値は実績の仕入れと同程度の値を示していることが分かる。これは、需要予測の精度が一定の水準であることを示していると言える。




図 3.15 賞味期限 0 日の商品の発注
(商品：手巻きおにぎり (天日塩の焼鮭)、店舗：大型店舗)

(2) 賞味期限 1～4 日商品の発注の考え方

賞味期限が 1～4 日の商品にはサラダやお惣菜等がある。このような商品は、その日に納品された商品はその日にすべて売り切るのではなく、賞味期限の日数で売り切るオペレーションを実施している。これは、その日にすべて売り切るオペレーションを目指すと、閉店時刻には棚が空になるからである。

このような商品では、当日と翌日以降の販売比率を設定する必要がある。バローでは賞味期限が 1 日の商品は 7 割を当日に販売して 3 割を翌日に販売するルールが設定されている。そこで、今回は 3-2 式の発注とした。

$$\begin{aligned}
 A_{num}(t) &= 0.7 \times F_{sku}(t) + 0.3 \times F_{sku}(t+1) \\
 \text{if } O_{num}(t+1) > 0 \quad O_{num}(t) &= A_{num}(t) \\
 \text{if } O_{num}(t+1) = 0 \quad O_{num}(t) &= A_{num}(t) + A_{num}(t+1) \\
 A_{num} &: \text{調整売上 (個)}
 \end{aligned}
 \tag{3-2}$$

賞味期限が 2 日以上の場合は、翌日に残した 3 割のさらに 3 割が翌々日に販売されることから、当日に 6 割、翌日に 3 割、翌々日に 1 割として 3-3 式の発注とした。また、予測値は次回納品日まで、もしくは賞味期限が切れる日までの値の積算値とした。次回納品日と賞味期限の関係は図 3.16 に示す。

$$\begin{aligned}
 A_{num}(t) &= 0.6 \times F_{sku}(t) + 0.3 \times F_{sku}(t+1) + 0.1 \times F_{sku}(t+2) \\
 t_{next} \leq Shelf_{life} \quad O_{num}(t) &= \sum_{O_{day}}^{t_{next}-1} A_{num}(i) \\
 t_{next} > Shelf_{life} \quad O_{num}(t) &= \sum_{O_{day}}^{O_{day}+Shelf_{life}} A_{num}(i)
 \end{aligned}
 \tag{3-3}$$

t_{next} : 次回納品日 (日付)
 $Shelf_{life}$: 賞味期限 (日)
 O_{day} : 発注日 (日付)

8/22	8/23	8/24 初期日	8/25 計算日 (発注日)	8/26	8/27	8/28
8/29 納品日	8/30	8/31 納品日	9/1	9/2	9/3	9/4 納品日
9/5	9/6 納品日					

賞味期限分
(当日 + 賞味期限)

図 3.16 次回納品日と賞味期限の一例

2022年8月26日～2022年10月25日の賞味期限1日の商品である「8品目のミックス野菜サラダ」のある大型店舗の発注の一例を図3.17に示す。本商品は賞味期限が1日で売れ残った商品は翌日も販売することができるため、在庫をコントロールしながら値引き販売を行っている。実績の発注量を見ると、平日は同程度の発注を行い、来店客数・売上が増加する土日の前に発注量を増加させていることが分かる。

発注推奨結果を見ると、当日に7割を販売して翌日に3割を販売するという考えから、土日は同程度の売上ではあるが、土曜日にもっとも発注が多く日曜日は少し減らした発注が行われていることが分かる。




図 3.17 賞味期限1日の商品の発注実績と発注推奨値の比較
(商品：8品目のミックス野菜サラダ、店舗：大型店舗)

(3) 賞味期限5～14日商品の発注の考え方

賞味期限が5～14日の商品には漬物や昆布等がある。このような商品は売り切れを防ぐため、常に3日分の売上を在庫として持つとして3-4式の発注とした。また、賞味期限切れが発生した際に製造日が複数あると賞味期限の管理が難しくなるため、月曜日と金曜日のみ納品とした。

$$O_{num}(t) = 3 \times Fct_{mean} + \sum_{1}^{t_{next}-1} F_{sku}(i) - \sum_{1}^{t-1} O_{num}(t) - S_{theory}(1) \quad 3-4$$

S_{theory} : 理論在庫 (個)

Fct_{mean} : 平均的な売上個数 (個/日)

このような商品では在庫を正確に把握する必要がある。店舗在庫は週に 1 回の頻度で棚卸をしているが、毎日計測しているわけではないため理論在庫を求めた。理論在庫の算出は、日々の在庫に直近の棚卸、販売実績、廃棄、仕入れを考慮して 3-5 式で求めた。

$$S_{theory} = S_{act}(t_i) + \sum_{t_i}^{t-1} P(i) - \sum_{t_i}^{t-1} D(i) - \sum_{t_i}^{t-1} W(i) \quad 3-5$$

S_{act} : 棚卸 (個)
 $P(t)$: 仕入れ (個)
 $D(t)$: 売上 (個)
 $W(t)$: 廃棄 (個)
 t_i : 直近の棚卸日 (毎週日曜日 or 月末)

2022 年 8 月 26 日～2022 年 10 月 25 日の賞味期限 5 日の商品である「お惣菜屋さんの昆布豆」のある大型店舗の発注の一例を図 3.18 に示す。本商品は賞味期限が 5 日で在庫が枯渇せず、廃棄も発生しないように発注を行っている。実績の発注量を見ると、8 月後半から 9 月末まで月曜日・水曜日・金曜日に 12 個の発注で固定されていることが分かる（本商品のロットは 2 個のため 6 ロットで固定）。

一方、発注推奨量を見ると月曜日、水曜日は発注が少なく、来店客数が増加する土日に向けて金曜日に発注を増加させていることが分かる。これによって、売上の小さい時は在庫を少なく、売上が大きい時は在庫を多く、在庫を適切にコントロールすることが可能になる。




図 3.18 賞味期限 5～14 日の発注実績と発注推奨値の比較
 (商品：お惣菜屋さんの昆布豆、店舗：大型店舗)

(4) 賞味期限 14 日以上商品の発注の考え方

賞味期限が 14 日以上の商品にはドレッシングや乾物等がある。このような商品では 1 ロットの商品数が多く在庫が増加するとバックヤードを圧迫する、ドレッシングは様々な種類があり売り切れが発生しても代替商品が存在するため、売り切れをある程度許容して最低限の在庫を持つように発注する。本システムでは、納品された商品は次々回納品日まで売り切れなければよいと考え、3 日分の余裕を考慮して発注した。木曜日発注を例にとると次々回納品日は次週の金曜日と 8 日後であり、3 日分の余裕を考慮すると 11 日間は売り切れないう 3-6 式として発注した。

$$\sum_1^{11} F_{sku}(i) \geq S_{theory} + O_{reminder} \quad O_{num}(t) = 1rot \quad 3-6$$

$O_{reminder}$: 発注残 (個)

2022 年 8 月 26 日～2022 年 10 月 25 日の賞味期限 180 日の商品である「K ノンオイル青しそドレッシング」のある大型店舗の発注の一例を図 3.19 に示す。本商品は賞味期限が 180 日と長くロットが 20 個と大きい。そのため、多めに発注して在庫を抱えることもできる商品ではあるが、在庫が増加するとバックヤードを圧迫する、商品の改廃を行う場合に速やかに廃止できないという問題がある。そこで、最低限の在庫を持ち、オペレーションを実施することとした。

本商品の発注推奨量を見ると、在庫を十分に減少させ、在庫が枯渇する前に発注できていることが分かる。10 月下旬には枯渇に近いレベルまで在庫は減少したが、ドレッシングは代替品があるため、ある程度の欠品を許容した発注を実施することとした。




図 3.19 賞味期限 14 日以上商品の発注実績と発注推奨値の比較
(商品 : K ノンオイル青しそドレッシング、店舗 : 大型店舗)

(5) 他オペレーションとの連携

在庫最適化においては、他のオペレーションとの連携も必要になる。

発注単位（ロット数）は各商品によって異なっており、ドレッシング等賞味期限の長い商品は発注単位当たりの商品数が多く、賞味期限の短い商品は少ない傾向がある。したがって、発注では発注個数を発注単位に変換する必要があり、商品マスタの発注単位データを利用した。

新商品やリニューアル商品、販売に力を入れている商品等は本部から送り込みによる本部発注を行っている。このような発注が行われている時に発注推奨量を出すと二重発注になるため本部発注データを取り入れ、本部発注が行われている時は発注推奨量を出さない設定とした。

中部フーズでは他社から納品された商品をバローに納品している。このような商品においては、他社の物流を考慮して他社が輸送可能な曜日に発注する必要があり、物流スケジュールマスタの発注可能日を利用した。

店休日も重要な要素である。店休日の前日は各商品を売り切るため賞味期限が複数日ある商品の発注を減らす必要があり、店休日の翌日は在庫が 0 から始まるため発注を増やす必要がある。したがって、店休日マスタの各店舗の店休日に合わせて発注量の調整を行った。

(6) 利益最大化（廃棄・欠品の削減）

売上は消費者の嗜好の変化により大きく変動する場合がある。このような変化は過去の売上を学習して予測をする AI 需要予測システムでは表現することが困難で、誤差が増大、廃棄や欠品が発生する可能性がある。そこで、需要予測では表現できない変化について、在庫最適化モデルで検討した。

日配品における廃棄は、①商品の需要が減少、②値引き販売が増加、③値引きでも商品を売り切ることができなくなり廃棄が増加という経路をたどるのが一般的である。そこで、値引き販売量を学習し、値引きが増加した商品の発注量を減少させることとした。

一方で売り切れが発生する商品については、売上実績を学習しても、それ以上の売上が生じていたかは分からないため AI 需要予測モデルでは表現できない。そこで、売り切れ時間を学習して売り切れ時間が早い商品の発注量を増加させることとした。

3.4 精度検証

前項で構築した発注推奨システムが正常に機能するかを調査するため、1年間7店舗を対象に精度検証を実施した。

表 3.8 精度検証の内容

項目		内容	備考
期間		2022年8月25日 ～2023年8月24日	来店客数予測は 2022年8月1日～10月31日
店舗		7店舗	大型～小型の 典型的な店舗を選択
詳細 項目	カテゴリ需要予測	3カテゴリ	代表的な3カテゴリ
	SKU需要予測	全商品	約120商品
	在庫最適化	全商品	約120商品
	比較	過去販売量・過去発注量	

(1) 来店客数予測

本システムでは火曜初期値は金土日、木曜初期値は次週月火水木の計算を行うため、リードタイム3～7日のデータを利用する。そこで、図 3.20 に 2022 年 8 月 1 日～2022 年 10 月 31 日のリードタイム 3～6 日の来店客数予測の実績と予測の散布図と MAPE（平均絶対パーセント誤差）、RMSE（平均二乗誤差）を示す。

ここで MAPE は各データに対して予測値と実績値との差を、実績値で割った値（＝パーセント誤差）の絶対値を計算し、その総和をデータ数で割った値であり、誤差の絶対値に対する比率を示す値である。RMSE は、予測値と実績値の誤差を二乗して平均して $\sqrt{\quad}$ を取る値であり、誤差の大きさを示す値である¹⁴。MAPE は全体に対する誤差率を知りたい時に利用され、RMSE は誤差の絶対値を知りたい時に利用される。

¹⁴ MAPE、RMSE の計算式は資料編の資料-3 式、資料-4 式に示す。

来店客数の実績と予測は $Y=X$ の直線付近に分布しており来店客数の変化傾向を再現できていることが分かる。精度指標の MAPE を見ると、3 日予測で 5.9%、4 日予測 6.1%、5 日予測 6.3%、6 日予測 6.2%とリードタイムによって少し悪化する傾向はあるが、大きな劣化はないことが分かる。




図 3.20 来店客数予測結果

来店客数予測のリードタイムごとの予測結果と実績、雨と気温の時系列変化を図 3.21 に示す。来店客数予測は曜日や祝祭日等、暦の影響を受けた変化を再現することはできている。また、来店客数は降雨時に前週同曜日と比較して減少する傾向があるが、来店客数予測は、この降雨による来店客数の減少をある程度予測できていることが分かる。

一方、9月23日の強雨による来店客数の減少は予測できていなかった。これは、9月23日は台風15号の接近の影響で東海地方には「顕著な大雨に関する情報」が発表された日であったが、台風15号は9月22日に発生して一気に北上してきたため、リードタイムより台風の発生から上陸の期間が短く気象予報では台風の動きを予測できなかったのが原因である。



図 3.21 来店客数予測の時系列

(2) カテゴリ需要予測

2022年8月26日～2023年8月24日のカテゴリ需要予測とSKU需要予測の散布図を図3.22に示す。カテゴリ需要予測の散布図を見ると $Y=X$ の直線上に分布しており、実績と予測の相関係数¹⁵が0.96、RMSEが37.2個と一定の精度で予測できていることが分かる。ただし、実績が800個以上に対し予測が200個未満の予測もいくつか存在した。これは、節分の日の寿司等、特定の日に特定の商品が大きく売れた場合に生じていた。そこで、本実証実験においては、節分の日の恵方巻等、特別な売上の商品については本部発注を行うこととした。

SKU需要予測の散布図を見ると売上が10個/日以下の商品が多い一方、100個/日以上の商品も存在することが分かる。これは、小売店の売上は1日当たりの売上が非常に大きいA商品が20%の比率、1日当たりの売上が中程度のB商品が20～30%、1日当たりの売上個数が小さいC商品が50%以上あるためである。このようにSKU需要予測の場合は、売上個数が商品によって大きく変動しているが、需要予測結果を見ると相関係数が0.93、RMSEが3.24個とカテゴリ需要予測と比較すると精度は少し落ちるものの、一定の精度で予測できていることが分かる。これはそれぞれの商品の特徴を捉えた予測ができていたためと考えられる。ただし、カテゴリ需要予測と同様に節分の日の恵方巻等、特別な商品の場合は、実績の売上を過小評価している。




図 3.22 需要予測結果
(左：カテゴリ需要予測、右：SKU 需要予測)

¹⁵ 相関係数は2種のデータの関係性を示す指標である。1に近いと関係性が高く、0に近いと関係性がないことを意味する。

「おにぎり・弁当」、「寿司」、「惣菜」カテゴリの典型的な大型・中型・小型店舗の売上実績・予測結果を図 3.23～図 3.25 に示す。

図 3.23 に示すように、「おにぎり・弁当」カテゴリは日常的に消費される商品のカテゴリのため、変化が小さく来店客数と連動して変化しており、一定の精度で予測できていた。ただし、中型店舗では 8 月中旬に店舗近隣で花火大会が行われた日に売上が大きく増加していたが、このような売上は予測することができていなかった。これは需要予測に店舗近隣のイベント情報は取り入れていないためである。また、小型店舗は 4 月や 8 月の春休みや夏休みの時期に売上が大きく変動していたが、予測ではこの変化が生じた週は予測できていなかったが、少し遅れて予測することができていた。これは急激な変化は予測することはできないが、直近のデータを学習することで少し遅れてその傾向を再現できることを示している。小型店舗が大型・中型店舗と比較して変化が大きい原因は、陳列できる商品数が限られており、特定の消費者の行動によって大きく変動するからと考えられる。

図 3.24 に示すように「寿司」カテゴリは、「おにぎり・弁当」と同様に日常的に消費されるため日々の動きは来店客数と連動して変化しており、一定の精度で予測できていた。一方、2 月 3 日の節分の日や 3 月 3 日の桃の節句で売上が大きく増加する傾向があり、このような変化は予測できていなかった。これは、AI は過去のデータを学習して予測するが、節分や桃の節句は年に 1 回の季節の行事のため学習データが不足しているためである。本実証実験では、このような特異日は本部から送り込みを行うこととした。

図 3.25 に示すように「惣菜」カテゴリは、「おにぎり・弁当」「寿司」カテゴリと比較して季節の変動が大きくなっていた。これは、「惣菜」カテゴリでは、消費者は夏にはサラダ等さっぱりした商品、冬には煮物等、温める商品を選択するように、季節や旬によって嗜好する商品が変化していくためである。この消費者嗜好に合わせるため、「惣菜」カテゴリでは季節に合わせて陳列する商品の種類・商品数が変動し、カテゴリ総計の売上個数も変化していたが、需要予測はこの変化傾向を予測することができていた。これは、直近の売上傾向の変化を学習していたためと考えられる。

各カテゴリとも大型店舗は来店客数と連動性が強く、小型店舗になるほど来店客数との連動性が落ちていた。これは、大型店舗は売り場面積が大きく陳列できる商品数が多いため安定した売上変動であるが、小型店舗は陳列できる商品数が限られており、特定の消費者行動にも影響を受けやすいため大きく変動していると考えられる。

運動会や花火大会等のイベントによっておにぎり等の売上が大きく増加する場合があるが、このような店舗特有の状況に関するデータは収集していないため予測することはできない。また、節分の日や桃の節句も売上変化を予測することはできなかった。これは年に 1 回の季節の行事のため学習データが不足しているためと考えられる。したがって、このような場合は需要予測による自動発注ではなく送り込み等で対応することとする。一方、春休みや夏休みによっておにぎり等の売上が変動していたが、この変動はある程度の期間で変化していくため、直近の売上傾向を学習することによって評価できていた。




図 3.23 おにぎり・弁当カテゴリの需要予測結果




図 3.24 寿司カテゴリの需要予測結果




図 3.25 惣菜カテゴリの需要予測結果

(3) SKU 需要予測

「おにぎり・弁当」カテゴリのもっとも売上の大きい商品である「手巻きおにぎり（天日塩の焼鮭）」、「寿司」カテゴリのもっとも売上の大きい商品である「助六寿司 8 貫」、「惣菜」カテゴリのもっとも売上の大きい商品である「8 品目のミックス野菜サラダ」の大型・中型・小型店舗の SKU 需要予測結果を図 3.26～図 3.28 に示す。

「手巻きおにぎり（天日塩の焼鮭）」は、「弁当・おにぎり」カテゴリと比較して変動幅が大きくなっていた。大型店舗においては 3 月 5 日に売上 128 個と大きな売上増加が発生しており、中型店舗では、8 月 8 日に店舗周辺で花火大会が開催されたため売上 233 個と通常時の 10 倍以上の売上が発生、小型店舗では 3 月～4 月、7 月中旬～9 月等春休みや夏休みに売上が大きく増加していた。個別の SKU がカテゴリよりも変動が大きいのは、季節や消費者嗜好等の変化によって各商品の人気の変動するためと考えられる。ただし、個別の SKU が売り切れた場合は同カテゴリ内の代替商品が消費される形になるため、実際の需要を正確に表しているとは言えないことに注意が必要である。需要予測は、この SKU の変化傾向を一定の精度で予測することができていた。売上が大きく変動した日は予測できていなかったが、そのデータを異常値として除去して学習することで、翌日以降に影響は発生していなかった。また、春休みや夏休み等によるトレンドの変化は、少し遅れてついていくことができていた。

「助六寿司 8 貫」は、店舗によって年末や祭日等に売上が大きく増加していた。2 月 3 日の節分の日には寿司カテゴリの売上は大きく増加していたが、節分の日には特別なコードを付与していたため、このデータからは節分の日の影響は見えなかった。一方、2023 年 4 月は日本全国で鶏卵が入手困難になったため、「助六寿司」を生産できず出荷制限が発生したため、売上が大きく減少していた。需要予測を見ると、通常の期間は一定の精度で予測できていた。鶏卵の入手が困難になった 2023 年 4 月は、需要予測で考慮していない事由で需要が減少したため発生当初は予測できていなかったが、直近のデータを学習することで次第にその変化も予測することができていた。

「8 品目のミックス野菜サラダ」は全商品の中でもっとも売上が大きい商品で、比較的安定した変化をしている。ただし、野菜の相場が上昇すると様々な野菜を摂取することのできる本商品の売上は増加し、おせち等の需要が増える年末は売上が大きく減少していた。需要予測は、本商品の売上変化を一定の精度で予測することができていた。ただし、年末については予測することはできていなかった。

SKU 需要予測は通常の変化は予測できるが、各商品特有の事情や、季節、消費者嗜好の変化等による大きな変動を予測することは難しい。ただし、本事業では需要予測が難しい状況も利益最大化により、需要が変化する前に販売終了時刻や利益率を考慮して発注量を変動させることによって需要をコントロールすることを目指している。これらの試みについては発注を変化させる試みのため、本項の過去の発注実績の中での精度検証では考慮していない。




図 3.26 「手巻きおにぎり（天日塩の焼鮭）」の需要予測結果




図 3.27 「助六寿司 8 貫」の需要予測結果




図 3.28 「8 品目のミックス野菜サラダ」の需要予測結果

(4) 在庫最適化

対象 7 店舗における全商品の発注実績と発注推奨量の散布図を図 3.29 に示す。発注推奨量は実際の発注をある程度再現することができており、相関係数は 0.91、RMSE は 2.61 であった。ただ、発注は例えば賞味期限が 1 日の商品であれば、当日に売れなくても翌日に売り切れればよいと、発注実績と一致することが必ずしも正しいとは言えないことに注意が必要である。本検証では、実績発注は 0 以上だが発注推奨量が 0、または実績発注は 0 だが発注推奨量が 0 以上の商品も存在した。これは、新商品の場合や、予約があったため発注推奨量は 0 だが発注する場合や、賞味期限の長い商品は日々発注するわけではないため発注タイミングが実績と発注推奨量で合わない場合に発生している。

図 3.30～図 3.35 に SKU 需要予測で検証した各カテゴリの代表商品である「手巻きおにぎり（天日塩）」、「助六寿司 8 貫」、「8 品目のミックス野菜サラダ」の発注実績と発注推奨量の時系列を示す。

「手巻きおにぎり（天日塩の焼鮭）」は賞味期限が 0 日のため、発注した商品はその日に売り切る必要がある。したがって、発注量は需要予測量と一致した値となる。したがって、需要予測と同様に一定の精度で予測できているが、花火大会や年末年始、春休みや夏休みに特別な事情で売上が変動した時期は予測することができていなかった。2023 年 4 月に発注実績はあるが、発注推奨値が計算されていない時期が存在した。これは、本実証実験では需要予測が困難な商品リニューアル、季節の行事、店舗周辺のイベント等、特別な事情がある場合は本部から送り込みを実施し、発注推奨量は算出しないこととしたためである。

「助六寿司 8 貫」も賞味期限が 0 日のため、発注量は需要予測と一致した値となる。通常時においては需要予測と同様に発注推奨量は一定の精度で予測できていた。一方、2023 年 4 月に鶏卵が入手困難で「助六寿司」の出荷制限が発生した時期は、本部から特別な発注が行われたため発注実績の数値も存在せず、発注推奨量も算出していない。

「8 品目のミックス野菜サラダ」は賞味期限が 1 日の商品で、対象日と翌日の需要予測結果をもとに発注推奨量を算出する必要がある。賞味期限が 1 日の商品は、棚が空になることを防ぐため、当日に 7 割を販売し翌日に 3 割を販売するオペレーションを目指している。そこで、発注推奨量も当日の需要予測の 7 割と翌日の需要予測の 3 割を積算して算出した。バローは土曜日・日曜日の売上が他曜日と比較して大きいため、上記の発注をする場合は、土曜日が最大発注量になり、次いで日曜日・金曜日となる。発注推奨量の結果を見るとこの状況を再現することができていた。




図 3.29 発注推奨量と発注実績の比較




図 3.30 「手巻きおにぎり（天日塩の焼鮭）」の発注実績と売上実績




図 3.31 「手巻きおにぎり（天日塩の焼鮭）」の発注推奨量と売上予測、売上実績




図 3.32 「助六寿司 8 貫」の発注実績と売上実績




図 3.33 「助六寿司 8 貫」の発注推奨量と売上予測と売上実績




図 3.34 「8 品目のミックス野菜サラダ」の発注実績と売上実績



図 3.35 「8 品目のミックス野菜サラダ」の発注推奨量と売上予測と売上実績

(5) 需要予測の誤差の解決手段として追加的に改善・実施すべき要素

AIによる需要予測は、15か月の過去実績を学習して予測を行っている。小売店の売上は競合や人口動態等、周辺環境によって大きく変化するためあまり長い期間を学習しても精度が劣化する。一方で需要は季節によって変動するため、例えば冬の予測をする場合は前年の冬の期間を学習期間に含める必要があるため15か月という期間を設定している。

したがって、初めて発生する事例や年間1度しか発生しない事例のように学習データが不足する事例については予測ができない。また、説明変数に気象予測を利用しているが、気象予測の精度が十分でない場合は高い精度では予測できない。検証計算において予測できていない事例を表3.9に示す。

表 3.9 需要予測の誤差が発生する事例

事例	内容
節分の日	節分の日では恵方巻等、寿司の売上が平常時の数倍に増加する。1年に1回のみ発生するこのような変化はAI需要予測モデルでは予測できない。
花火大会	花火大会の日は近隣店舗ではおにぎりの需要等が増加する。このような特定地域のイベントのデータは説明変数として予測モデルに入力できないため予測できない。
夏休み	小型・中型店舗では夏休み等でおにぎりの需要が増加する場合がある。このような変化は特定の顧客によって生じており、毎年同じような変化ではないため予測精度は低下する。
特別な事情	2023年4月は鶏卵の入手が困難になったため「助六寿司」等、卵を使った商品を生産することができなかった。このような事情がある場合は需要が増加しても商品を用意できないため売上は増加しない等、学習データに本来の消費者の需要が反映されていないため予測精度が低下する。
台風15号	2022年の台風15号は日本の南海上で発生してすぐに東海地方に上陸した。リードタイムより台風の発生から上陸の期間が短かったため気象予報では台風の動きを予測できなかった。このような事例では気象データを説明変数としているため需要予測精度は低下する。

節分の日や花火大会のように特定の日付に売上が大きく増加する事例や特別な事情で生産量が限定される場合はAI需要予測モデルでは予測できない。そこで、このような事例では需要予測を利用した自動発注ではなく本部からの送り込みによって需要予測誤差の増大を解決することとした。夏休みのおにぎり需要等、急激に需要が増加した場合はAI需要予測モデルでは予測精度が低下する。しかし、このような場合には発注量が十分でないため売切時刻が早くなる傾向がある。本実証実験では、売切時刻を学習して発注量を変動させる仕組みを導入し需要予測誤差の増大を解決することとした。

3.5 実証実験の結果評価

実証実験の結果評価にあたっては A/B テスト¹⁶を実施することとし、店舗については対象 31 店舗と同規模・同地域の比較 31 店舗を設定、期間については対象期間の 2024 年 1 月 22 日～3 月 21 日の 2 か月間とした。比較期間は、2023 年 11 月 15 日～12 月 15 日に本システムが正常に動作するかのテストをしたため、その期間と正月期間を除いた直近の 8 週間である 2023 年 9 月 25 日～11 月 12 日、2024 年 1 月 8～21 日に設定した。

また、各数値は月当たりの数値に変換して求めた。ここで、月は 4 週間とした。

(1) 発注回数

実証実験前と実証実験後の比較店舗と対象店舗の発注回数の変化を表 3.10 に示す。実証実験中、比較店舗は月あたり 32 回発注を行っていたが対象店舗は月あたり 10.2 回と 21.8 回削減できた。

これまでのオペレーションでは週間発注を 1 回/週行った上で修正発注を毎日（7 回/週）実施していたため、比較店舗は 1 か月を 4 週間で近似すると 4 週間×8 回で 32 回の発注回数となった。

一方、対象期間の対象店舗では発注リードタイムを長期化して製造業に発注量を事前連携し、見込み生産を受注生産に変更するため、発注を火曜日と木曜日の 2 回/週に限定することとした。ただし、実証実験中にプログラム変更によって再発注を 5 回行ったため、9 週間×2 回/週+5 回の 23 回の発注回数となり、月あたり 10.2 回となったが比較期間より発注回数は大きく削減できた。プログラムを変更する場合も製造業の納品リードタイムである 3 日以上前に発注を確定し、製造業が受注生産を実施できるように変更を行った。

表 3.10 実証実験前と実証実験後の発注回数（1 か月・店舗あたり）

期間	発注回数
比較期間	32 回
対象期間	10.2 回
減少率	-68.1%

¹⁶ A/B テストはマーケティングや製品開発等の分野で広く利用される手法で、2 つ（またはそれ以上）のバージョンの要素を準備して、どちらがより効果的かを評価する手法。本実証実験では AI 需要予測と自動発注を利用した店舗と利用しなかった店舗を比較することで、AI 需要予測と自動発注の効果を抽出することが可能になる。

(2) 輸送回数

本実証実験に係る輸送には、①工場から店舗への輸送と、②原材料メーカーから工場への輸送の2種類が存在する。本項では両者についてまとめた。

実証実験前と実証実験後の工場から店舗への通常輸送回数を表 3.11 に、緊急輸送回数を表 3.12 に示す。通常輸送回数は比較期間・対象期間ともに月あたり 28 回と変化はなかった。これは、対象商品が日配品の惣菜で賞味期限が 0 日の商品も含まれており、必ず 1 回/日の輸送が必要なためである。一方、緊急輸送回数は比較期間が 1 回に対し 0 回に減少していた。これは、従来は店舗の発注担当者が経験と勘で発注を行っており、発注精度が十分でなく、抜け漏れが発生する等の原因で商品不足が発生し、その商品不足を解消するために緊急輸送が行われてきたためである。このような緊急輸送では、通常輸送で確保しているトラックに加えて、新たなトラック、新たなトラックドライバーの確保が必要となり、物流に大きな負荷・混乱を生じさせるため、もっとも削減すべきものである。本実証実験では AI 需要予測を利用して発注精度を向上、機械化することで抜け漏れを防ぎ緊急輸送を削減することができた。

表 3.11 実証実験前と実証実験後の
工場から店舗の通常輸送回数（1 か月・店舗当たり）

期間	通常輸送回数
比較期間	28 回
対象期間	28 回
変化	-

※ 1 か月を 4 週間として算出

表 3.12 実証実験前と実証実験後の
工場から店舗の緊急輸送回数（1 か月・工場当たり）

期間	緊急輸送回数
比較期間	1 回
対象期間	0 回
変化	-1 回

次に原材料メーカーから工場の緊急輸送の実証実験前と実証実験後の輸送回数の変化を表 3.13～表 3.14 に示す。通常輸送回数は比較期間、対象期間ともに 922 回と変化はなかった。これは、惣菜の原材料である野菜や肉、魚は消費期限があるため定期的に仕入れをする必要があるためである。

一方、緊急輸送回数は比較期間が 1.5 回に対し、対象期間は 0 回と減少していた。これは、従来のオペレーションでは製造業は店舗からの週間発注で生産計画を立てて原材料の調達を行うが、2 日前に店舗から修正発注があり、大きく修正された場合は原材料を緊急に調達する必要があるためである。このような緊急輸送は原材料メーカーの配車計画に影響を与え、トラックの手配や人の確保等、物流に大きな負荷を発生させる。近年では原材料メーカーがトラックを手配できない場合があり、その際は工場の従業員が自社のトラックや車で取りに行くという状況も発生しており、今後このような事態はさらに増えていくと言われている。対象期間は店舗からの発注リードタイムを長期化し見込み生産を受注生産に変更したため、工場では計画通りに生産することが可能になり緊急輸送が削減できた。

ただし、工場のオペレーションでは全店舗の商品を製造しており、対象店舗のみオペレーションを変更するだけでは効果は限定される。そこで、本項で算出した輸送回数は対象店舗のオペレーションが全店舗に拡張された場合の数字とした。

表 3.13 実証実験前と実証実験後の

原材料メーカーから工場の通常輸送回数（1 か月・工場当たり）

期間	通常輸送回数
比較期間	922 回
対象期間	922 回
変化	-回

表 3.14 実証実験前と実証実験後の

原材料メーカーから工場の緊急輸送回数（1 か月・工場当たり）

期間	緊急輸送回数
比較期間	1.5 回
対象期間	0 回
変化	-1.5 回

(3) 輸送距離

実証実験前と実証実験後の月あたりの工場から店舗、原材料メーカーから工場の通常輸送距離、緊急輸送距離の変化を表 3.15～表 3.18 に示す。

輸送距離は前項の発注回数に平均輸送距離を乗じることで求めた。工場から店舗への平均輸送距離は実証実験店舗と工場の平均距離である 147km とした。一方、原材料メーカーから工場の平均輸送距離は 122km として算出した。

表 3.15 実証実験前と実証実験後の
工場から店舗の通常輸送距離（1 か月・店舗当たり）

期間	通常輸送距離
比較期間	28 回×147km = 4,116km
対象期間	28 回×147km = 4,116km
変化	-

表 3.16 実証実験前と実証実験後の
工場から店舗の緊急輸送距離（1 か月・工場当たり）

期間	緊急輸送距離
比較期間	1 回×147km = 147km
対象期間	0 回×147km = 0km
変化	-147km

表 3.17 実証実験前と実証実験後の
原材料メーカーから工場の通常輸送距離（1 か月・工場当たり）

期間	緊急輸送距離
比較期間	922 回×122km = 112,484km
対象期間	922 回×122km = 112,484km
変化	-

表 3.18 実証実験前と実証実験後の
原材料メーカーから工場の緊急輸送距離（1 か月・工場当たり）

期間	緊急輸送距離
比較期間	1.5 回×122km = 183km
対象期間	0 回×122km = 0km
変化	-183km

(4) 作業時間

実証実験前と実証実験後の月あたりの店舗の発注作業時間と工場の生産計画策定の作業時間を表 3.19 と表 3.20 に示す。店舗の発注作業時間は、対象店舗の発注担当者に実証実験前、実証実験中の 2 回、アンケートを実施し、その結果を集計して求めた。

店舗の発注作業時間は比較期間より 1.8 時間（26.8%）減少した。これは、AI 需要予測による発注推奨システムで発注量を算出したため、発注量の検討時間や発注端末に打ち込む時間を削減できたためである。本実証実験では工場の完成品を対象を限定したため 26.8% の削減に留まっているが、対象を広げることさらに削減率を増加させることが可能になる。ただし、年末等 AI では需要予測が困難な期間は人の経験と勘が重要であり、完全にシステムに依存する体制になると担当者の売上に対する意識が減少する可能性もあるため利用方法には注意が必要である。

一方、工場で作業時間が 102 時間（19.3%）減少するとの試算になった。これは、店舗からの発注量が事前に共有されることで、生産計画の策定に係る時間（生産数量計画時間、数量の変更に対応する時間、シフト修正検討時間）等が減少するためである。ただし、工場の作業時間は一部の店舗が導入しただけでは削減できず、全店舗が本システムを導入することによって削減できる時間である。

以上のように、AI 需要予測を用いた発注推奨システムで発注を自動化することにより、店舗・工場ともに作業時間を削減できることが示された。

表 3.19 実証実験前と実証実験後の
店舗発注作業時間（1 か月・店舗当たり）

期間	作業時間
比較期間	6.7 時間
対象期間	4.9 時間
減少率	26.8%

表 3.20 実証実験前と実証実験後の
工場生産計画策定の作業時間（1 か月・工場当たり）

期間	作業時間
比較期間	528 時間
対象期間	426 時間
減少率	19.3%

(5) 売上と利益

比較期間と対象期間の全店舗平均の売上・利益額の推移を図 3.36、図 3.37 に、店舗規模ごとの売上・利益額の推移を図 3.38、図 3.39 に示す。ここでは、年末年始や事前の実証実験期間を比較期間から除外して表示しており、黒実線の左側が比較期間、黒実線の右側が対象期間となっている。実証実験期間中に、重要なプログラム変更を実施したため、プログラム変更時期も表示した。2024 年 3 月 18 日週は実証実験期間が 3 月 21 日までのため、4 日分の値を図化した。

比較期間は安定した売上推移になっており、対象店舗は比較店舗より売上・利益が 5% ほど高くなっていた。ただし、実証実験に入る 1~2 週間前は利益率が対象店舗と比較店舗で同程度となっていた。店舗規模ごとに見ると、売上は大型店舗と小型店舗は対象店舗と比較店舗で同規模であったが、中型店舗は対象店舗の方が高かった。一方、利益は大型店舗で対象店舗の方が高く、中型・小型店舗では同程度になっていた。

対象期間には、節分の日が含まれており節分の日があった 1 月 29 日週は売上・利益が大きく増加していることが分かる。それ以外の期間は安定した売上推移になっている。対象店舗と比較店舗を見ると、プログラム変更前は対象店舗の売上が比較店舗より大きく増加する一方、利益が減少していることが分かる。大型店舗は売上・利益ともに増加していたが、中型・小型店舗では売上は増加するものの利益率が低下していた。これは、本実証実験では利益を最大化するため売り切れの早い商品の発注を増加させる仕組みを入れていたが、大型店舗は売上余力があったため売上・利益ともに増加させることが可能であったが、中型・小型店舗は売上余力がなかったため発注が多くなりすぎ、値引きが増加して利益が低下したと考えられる。特に売上余力が小さかった小型店舗で利益額の低下が顕著であった。そこで、2 月 26 日週以降では、値引きが多い店舗では発注を増やしすぎないようにした上で、売り切れの発生している商品の発注を増やすようプログラムを変更した。その結果、3 月 4 日週以降では対象店舗の大型・中型・小型店舗で利益額が比較店舗より増加しており、全店舗でも利益額の顕著な増加が見られた。これは、発注増加が必要な商品、発注削減が必要な商品を発注システムで判定した上で、発注量を調節したため適切な発注量になったと考えられる。

本実証実験では、これまで 2 日前発注であったのを製造業の見込み生産を受注生産に変更するため最大で 7 日前発注に変更した。その結果、従来と比較して直近の売上傾向・在庫状況を把握することができない状態で発注を実施することになったが、AI 需要予測を利用することで適切な発注量を設定し、自動化することで抜け・漏れのない発注が実現できたため精度が向上したと考えられる。




図 3.36 売上額の推移 (全店舗平均)




図 3.37 利益額の推移 (全店舗平均)




図 3.38 店舗規模ごとの売上額の推移 (各規模平均)




図 3.39 店舗規模ごとの利益額の推移 (各規模平均)

月あたりの店舗の売上額を表 3.22 に店舗と工場の利益額を表 3.23、表 3.24 に示す。対象全期間はすべての日を含んでいるが、節分の日は売上が非常に大きい特異日で AI では予測できないため人の経験と勘によって発注されており、AI 需要予測の効果とは言えない。そこで、重大なプログラム変更を実施する前で節分の日を除いた 4 週間で「対象変更前」、プログラム変更後の 4 週間で「対象変更後」として比較した。

実証実験の効果は「比較期間の対象店舗の比較店舗に対する比率」と「対象期間の対象店舗の比較店舗に対する比率」の変化率から求めた。これによって、AI 需要予測と在庫最適化モデルによる発注推奨システムの効果を抽出することが可能になる。評価方法を表 3.21 に示す。

表 3.21 効果試算の方法

期間	比較店舗	対象店舗	比率 (対象店舗/比較店舗)	効果 (該当期間 - 比較期間)
比較期間	A	B	$E=B/A$	
対象全期間	C	D	$F=D/C$	F-E

店舗の利益額は売上から仕入れ値、店舗運営に係るコストを差し引くことから求め、工場の利益額は店舗への卸値から原材料の仕入れ値、製造に係るコストを差し引くことから求めた。ここで、工場の利益はそれぞれの商品の作業時間等を求めているため、すべての商品で利益率は一定とし、各商品の売上に一定の比率を乗じて求めた。

比較期間では、対象店舗は比較店舗より売上額は 5.9%、利益は 4.7%高かった。プログラム変更前は、売上額は 13.3%高くなっており売上が増加していたが、利益額は-10.2%と利益額が減少していた。プログラム変更後は売上額が 8.6%とプログラム変更前よりは下がったが比較期間よりは 2.7%高くなっていた。また、利益額は 8.5%とプログラム変更前から大きく改善し比較期間より 3.8%高くなっていた。その結果、売上は 2.7%増、利益は 3.8%増と、売上・利益ともに改善していた。

一方、工場の利益は店舗の売上額に一定比率を乗じて求められるため、店舗売上額と同様で比較期間より 2.7%増加した。

以上から、AI 需要予測を利用することで、売上・利益ともに増加させることができることが分かる。

表 3.22 店舗の実証実験前と実証実験後の売上額（1 か月・店舗当たり）

期間	比較店舗	対象店舗	比率 (対象店舗/比較店舗)	効果 (該当期間 - 比較期間)
比較期間	2,494 千円	2,642 千円	+5.9%	
対象全期間	2,445 千円	2,735 千円	+11.9%	+5.9%
対象変更前	2,277 千円	2,580 千円	+13.3%	+7.4%
対象変更後	2,414 千円	2,622 千円	+8.6%	+2.7%

表 3.23 店舗の実証実験前と実証実験後の利益額（1 か月・店舗当たり）

期間	比較店舗	対象店舗	比率 (対象店舗/比較店舗)	効果 (該当期間 - 比較期間)
比較期間	226 千円	237 千円	+4.7%	
対象全期間	225 千円	249 千円	+10.7%	+6.0%
対象変更前	190 千円	171 千円	-10.2%	-14.9%
対象変更後	217 千円	236 千円	+8.5%	+3.8%

表 3.24 工場の実証実験前と実証実験後の利益額（1 か月・店舗当たり）

期間	比較店舗	対象店舗	比率 (対象店舗/比較店舗)	効果 (該当期間 - 比較期間)
比較期間	404 千円	428 千円	+5.9%	
対象全期間	396 千円	443 千円	+11.9%	+5.9%
対象変更前	369 千円	418 千円	+13.3%	+7.4%
対象変更後	391 千円	425 千円	+8.6%	+2.7%

(6) 廃棄

比較期間と対象期間の全店舗平均の廃棄個数の推移を図 3.40 に示す。比較期間の廃棄個数は週によって変動しているが、対象店舗の方がすべての週で多かった。これは、対象店舗の方が同じ店舗規模でも売上額が大きく、より積極的に商品を陳列する傾向があるためと考えられる。

対象期間では2月19日週に廃棄が多くなっていた。これは、2月19日週は天候が悪く名古屋では7日中6日間で雨が観測され、来店客数が減少したためと考えられる。本実証実験ではAI需要予測で雨の効果を考慮していたが、プログラム変更前は売上を伸ばす予測になっていたため、廃棄が増加したと考えられる。一方、プログラム変更後は、廃棄個数は減少傾向になり、比較店舗との差が縮小した。その結果、比較期間では対象店舗の廃棄は比較店舗より31.7%多かった。対象期間では対象店舗の廃棄は比較店舗より32.4%多く、比較期間とほぼ同程度の廃棄であった。対象期間では売上が増加しているため、廃棄率（廃棄個数/売上個数）は減少していた。




図 3.40 廃棄個数の推移 (全店舗平均)

実証実験前と実証実験後の月あたりの店舗と工場の廃棄個数を表 3.25、表 3.26 に示す。ここで、店舗の廃棄数は商品数でカウントされるが、工場の廃棄数は原材料の仕入れ金額でカウントされている。しかし、店舗の廃棄個数と工場の廃棄個数を比較して考察するため、工場の廃棄個数は平均的な原材料コスト金額から商品個数に換算し、店舗当たりに分した。

プログラム変更前は店舗における廃棄は比較店舗に対し 43.7%増加していた。これは、前項で示したように発注推奨システムで売り切れ時間が早い商品の発注を増加させたため、全体の売上規模が増加し、その結果、廃棄が増加したと考えられる。廃棄は特に小型店舗で増加した。これは、小型店舗は客数が限られているため陳列商品数を増加させると廃棄も増加しやすいためと考えられる。一方、プログラム変更後は比較店舗に対し 32.4%高と比較時期と同程度の水準まで低下した。

工場における廃棄は1店舗で月あたり 9.7 個減少していた。これは、発注リードタイムを 3 日以上に長期化することで工場が計画的に製造できるようになったためである。

店舗と工場の廃棄個数を積算した結果を表 3.27 に示す。ここでは、対象店舗の対象期間のみ工場の廃棄は発生しないことから、比較期間の対象店舗・比較店舗、対象期間の比較店舗に工場における廃棄を積算した。プログラム変更後では比較期間に対し 17.3%減少しており、サプライチェーン全体で廃棄数は減少していたと言える。これは、AI 需要予測を導入することで各店舗の在庫をコントロールし、その情報を共有することで工場の見込み生産を受注生産に変更することが可能になり、工場の仕掛品在庫の廃棄が減少したためである。したがって、小売業と製造業の情報連携によりサプライチェーン内の在庫最適化が実現できたと言える。

表 3.25 店舗の実証実験前と実証実験後の廃棄個数（1 か月・店舗あたり）

期間	比較店舗	対象店舗	比率 (対象店舗/比較店舗)	効果 (該当期間 - 比較期間)
比較期間	71.2 個	93.7 個	+31.7%	
対象全期間	54.8 個	78.8 個	+43.9%	+12.2%
対象変更前	64.0 個	92.0 個	+43.7%	+12.0%
対象変更後	49.3 個	65.2 個	+32.4%	+0.7%

表 3.26 工場の実証実験前と実証実験後の
廃棄個数（1 か月・店舗あたり）

期間	廃棄個数
比較期間	9.7 個
対象期間	0 個
変化	-9.7 個

表 3.27 SC 全体の実証実験前と実証実験後の廃棄個数（1 か月・店舗あたり）

期間	比較店舗	対象店舗	比率 (対象店舗/比較店舗)	効果 (該当期間 - 比較期間)
比較期間	80.9 個	103.4 個	+27.9%	
対象全期間	64.5 個	78.8 個	+22.2%	-5.7%
対象変更前	73.8 個	92.0 個	+24.7%	-3.1%
対象変更後	59.0 個	65.2 個	+10.6%	-17.3%

(7) 欠品

比較期間と対象期間の全店舗平均の欠品回数の推移を図 3.41 に示す。ここで欠品とは、①5 個/日以上の販売、②安売りなし、③17 時までの売り切れ、④賞味期限 2 日以内の 4 つの条件を満たす場合とした。これは、5 個/日以下、安売りをしている商品は売り切れを前提とした販売を行っており、欠品回数の算出からは除外したためである。また、17 時までの売り切れで欠品回数を算出したのは、バローの店舗では店舗状況によるが 17 時までは品揃えを保持して定価販売を行い、17 時以降は値引きを行いながら売り切りを目指すオペレーションを実施しているため、17 時以内の売り切れのみを欠品とした。また、賞味期限 2 日以上の商品は 1 週間に 1 度の棚卸では在庫を正確に把握することができず欠品の判定ができないため除外した。

欠品回数は実証実験開始前では対象店舗と比較店舗とも同じような推移をしていたが、実証実験期間中は対象店舗の欠品回数が減少していた。プログラム変更前は売上を増加させる傾向があったため欠品回数は大きく減少していたが、プログラム変更後は、効果は少し減少するものの適切な水準に売上を設定した場合でも欠品回数は減少していた。

これは、本実証実験では AI 需要予測モデルで値引き率を学習し、欠品の確率が高くなる値引き率の低い商品の予測を増加させているため、欠品が減少していると考えられる。また、在庫最適化モデルで売り切れ時間を学習して発注数量を求めているため、欠品が減少していると考えられる。




図 3.41 欠品回数の推移（全店舗平均）

実証実験前と実証実験後の月あたりの店舗の欠品回数を表 3.28 に示す。1 か月・店舗当たりの欠品回数を見ると、比較店舗は比較期間・対象期間の欠品回数に大きな変化はなかった。一方、対象店舗では比較期間の欠品回数が 130 回に対し、プログラム変更前 96 回、プログラム変更後 105 回と、どの時期でも欠品回数は減少していた。

表 3.28 店舗の実証実験前と実証実験後の欠品回数（1 か月・店舗あたり）

期間	比較店舗	対象店舗	比率 (対象店舗/比較店舗)	効果 (該当期間 - 比較期間)
比較期間	123 回	130 回	+5.2%	
対象全期間	122 回	101 回	-18.2%	-22.4%
対象変更前	122 回	96 回	-20.9%	-26.1%
対象変更後	121 回	105 回	-13.0%	-18.2%

(8) 例外的な状況の解決の一例

2024年1月24日は冬型の気圧配置で、上空約5,500メートルで氷点下40度以下という強い寒気が流れ込み、日本海側は広い範囲で雪が降った。特に北陸地方では「顕著な大雪に関する気象情報」が福井県で発表される等、大雪が観測された。

一方、太平洋側の地方でも、雲が脊梁山脈の低いところを通して関ヶ原付近で大雪を降らせたため、岐阜県関ヶ原町の名神高速道路での立ち往生が19時間も続き、陸上自衛隊が出動する等、東海地方では雪が観測された。





図 3.42 1月24日の天気図

図 3.43 に 2024 年 1 月 24 日の東海地方の雪と、1 月 17 日初期値の雪の予測結果を示す。1 月 24 日の発注は 1 月 18 日に実施されており、その予測では 1 月 17 日初期値の気象予測が利用されている。予測結果では北陸における強い雪は予測することができていた一方、平野部（特に名古屋市）の雪を予測できていなかった。これは、平野部は気温が 0 度付近で雨か雪かの判断が 1 週間前時点では難しかったためである。

DATE:2024/01/24



DATE:2024/01/17 LEADTIME:7 DAYS




図 3.43 2024 年 1 月 24 日の東海地方の雪と予測
(左：観測値、右：1 月 17 日初期値の 7 日予測)

図 3.44 に来店客数実績の前週同曜日比と雪の分布を示す。来店客数は雪の降った地域で前週同曜日と比較して減少していることが分かる。来店客数予測は北陸地方等に雪が降ることを予測していた地域では来店客数の減少を予測できていた。これは、雪が降ると来店客数が減少する傾向を AI が学習し、予測できていたためと考えられる。ただし、名古屋市付近の雪を予測できなかったため名古屋市付近では来店客数の減少を予測することはできていなかった。




図 3.44 2024 年 1 月 24 日の雪と来店客数
(左：来店客数実績の前週比、右：来店客数予測の前週比)

図 3.45 に雪が強く降った 1 週間の北陸地方の対象 10 店舗と比較 10 店舗の売上金額と利益額の時系列を示す。ここで雪が強く降ったのは 2024 年 1 月 24 日である。売上額の時系列を見ると、対象店舗は 1 月 24 日に売上が減少していることが分かる。これは雪を予測したため発注推奨量が減少したためである。一方、比較店舗は経験と勘で発注を行っており、雪の日に発注を減らし売上が減少しているものの自動発注と比較するとその変化は小さかった。利益額を見ると、雪の降った水曜日に対象店舗・比較店舗とも利益額が減少しているものの、比較店舗の方が減少幅は大きかった。これは、比較店舗は発注量の減少幅が小さかったため過剰発注となり、値引き販売が増えたためと考えられる。

以上から、AI で気象の影響を考慮した需要予測を用いた自動発注を行うことで、オペレーションが最適化されることが分かる。




図 3.45 北陸地域の対象店舗と比較店舗（上：売上、下：利益）

3.6 まとめ

3.6.1 対象の設定

実証実験の対象店舗はバローの複数エリアの 31 店舗、対象商品は惣菜完成品の全商品、対象期間は 2024 年 1 月 22 日～3 月 21 日の 2 か月間とした。

3.6.2 オペレーション変革

現行オペレーションでは、店舗は 1 週間前に週間発注、2 日前に修正発注を店舗の在庫を考慮した上で経験と勘で実施している。工場は店舗からの発注量を予測して見込み生産を実施しており、週間発注から発注量が大きく変更された場合は工場から店舗の緊急輸送、原材料メーカーから工場の緊急輸送、仕掛品在庫の廃棄等が発生している。

実証実験で実施するオペレーションでは、店舗は木曜日に週間発注、火曜日に週末の修正発注と発注を 2 回、リードタイムを 3 日以上に延長し、AI 需要予測モデルを利用した自動発注を実施することとした。これによって、店舗では在庫最適化を実現した上で発注作業時間を軽減し、工場では店舗からの発注量を予測する見込み生産から受注生産に変更することが可能になる。

3.6.3 発注推奨システムの構築

発注推奨システムは、AWS クラウドを利用して構築した。システムではバロー、中部フーズ、ソフトバンク、日本気象協会からそれぞれ表 3.29 のデータを収集した。また、これらのデータを利用してAIを利用して来店客数予測、カテゴリ需要予測、SKU 需要予測を実施した。この SKU 需要予測データを入力値とし、在庫最適化モデルで各店舗・各商品の発注推奨量を求め、発注端末と連携し発注を行った。

表 3.29 発注推奨システム内のデータ一覧

データ名	管理会社	更新時刻	ファイル名	内容
販売実績データ	バロー	6:00	TORIIHIKI_YMD.csv	前日のレシートデータ
廃棄データ		6:00	HAIKI_YMD.csv	前日の各店舗・各商品の廃棄量
来店客数データ		6:00	KYAKUSUU_YMD.csv	前日の各店舗の来店客数
店舗マスタ1		6:00	SHOP_MASTER1_YMD.csv	店舗情報一覧
仕入れデータ	中部フーズ	6:00	SHIIRE_YMD.csv	前日の各店舗・各商品の仕入れ量
棚卸データ		6:00	STORAGE_YMD.csv	日曜日・月末の各店舗・各商品の在庫量
本部発注データ		6:00	OKURIKOMI_YMD.csv	本部からの各店舗・各商品の発注量
店舗発注データ		6:00	HATTYU_YMD.csv	店舗からの各店舗・各商品の発注量
店舗マスタ2		6:00	SHOP_MASTER2_YMD.csv	店舗情報一覧2
商品マスタ		6:00	ITEM_MASTER_YMD.csv	商品情報一覧
店休日マスタ		6:00	HOLIDAY_YMD.csv	各店舗の店休日一覧
店別商品マスタ		6:00	SHOP_ITEM_YMD.csv	各店舗の取り扱い商品一覧
物流スケジュールマスタ		6:00	LOGISTIC_YMD.csv	取引先の物流稼働スケジュール一覧
販促マスタ		6:00	HANSOKU_YMD.csv	各店舗・各商品の販売促進一覧
利益最大化マスタ		6:00	BENEFIT_YMD.csv	利益最大化パラメーター一覧
来店客数予測データ	ソフトバンク	10:00	SAKIMIRU_YMD.csv	前日初期値の各店舗の来店客数予測
気象観測値データ	日本気象協会	6:00	OBS_DAILY_YMD.csv	前日の各店舗の気象観測値
気象予測値データ		6:00	FCT_DAILY_YMD.csv	当日初期値の各店舗の気象予測値
カテゴリ需要予測データ		11:00	CATEGORY_FCT_YMD.csv	当日初期値の各店舗・各カテゴリの需要予測
SKU 需要予測データ		11:30	SKU_FCT_YMD.csv	当日初期値の各店舗・各商品の需要予測
発注推奨量データ		12:30	RECOMMEND_YMD.csv	当日初期値の各店舗・各商品の発注推奨量
ログ		12:30	LOG.csv	システムログ

3.6.4 精度検証

構築した発注推奨システムで、来店客数予測、カテゴリ需要予測、SKU 需要予測の精度検証を行った。需要は曜日によって変動し、降雨によって需要が低下するが、各予測とも相関係数 0.9 以上と予測精度は高かった。一方で、節分の日や花火大会、夏休み、台風の接近等、過去データではデータ数が不足して十分に学習できない事例については予測が困難であることが分かった。

これらの需要予測を利用して在庫最適化モデルを適用した。在庫最適化モデルは賞味期限ごとに手法を変更してモデル化し、需要の減少を予測した場合は利益最大化モデルを適用し、売り切れが発生する場合は発注を追加、ロスが大きくなる時は発注を削減することとした。過去の発注についてシミュレーションを行い、過去の実績発注と比較をしたところ、発注は季節によって販売される商品量や規模が大きく変動していたが、実際の発注量

を再現することができていた。

3.6.5 実証実験の結果評価

本実証実験では、開始数週間は中型・小型店舗を中心に売上は増加するものの利益が減少する問題が発生していた。これは、利益を最大化するため売り切れの早い商品の発注を増加させる仕組みを入れていたが、大型店舗は売上余力があったため売上・利益ともに増加させることができたが、中型・小型店舗は売上余力がなかったため発注が多くなりすぎ、値引きが増加して利益が低下したためである。そこで、2月26日週以降では、値引きが多い店舗では発注を増やしすぎないようにした上で、売り切れの発生している商品の発注を増やすようプログラムを変更した。

実証実験全期間の結果を表 3.30 に、プログラム変更後の結果を表 3.31 に示す。本実証実験では、小売業の発注を自動化し、発注回数を木曜日と火曜日に限定してリードタイムを長期化することで、工場の見込み生産を受注生産に変更した。その結果、発注回数は 75% 減少し、工場から店舗の緊急輸送、原材料メーカーから工場の緊急輸送を 0 回にすることができた。

売上と利益については、プログラム変更前は売上 7.4% 増に対し利益 14.9% 減と発注を増加させることで売上は増加するものの利益額は減少していたが、プログラム変更後は売上 2.7% 増、利益額 3.8% 増と両者ともに増加していた。廃棄については、プログラム変更後は店舗では比較時期に対して +0.7% とほとんど変化していなかったが、工場で見込み生産が受注生産に変更されたことで 9.2 個/店/月減少しており、サプライチェーン全体で 17.3% の削減となった。欠品については、売り切れ時間を学習して発注量を決定することによって 18.2% 減少した。作業時間については、小売の発注を半自動化することによって発注作業時間を 26.8% 削減、事前に小売からの発注量を連携することで工場の計画に係る時間を 19.3% 削減することができた。

表 3.30 実証実験の効果一覧（全期間）

項目		1 か月当たりの効果
標準 KPI	発注回数	21.8 回の減少（店舗当たり）
	輸送回数	【通常輸送回数】 工場から店舗：変化なし 原材料メーカーから工場：変化なし 【緊急輸送回数】 工場から店舗：1 回→0 回（工場当たり） 原材料メーカーから工場：1.5 回→0 回（工場当たり）
	輸送距離	【通常輸送回数】 工場から店舗：変化なし 原材料メーカーから工場：変化なし 【緊急輸送回数】 工場から店舗：147km 減少（工場当たり） 原材料メーカーから工場：183km 減少（工場当たり）
	作業時間	店舗：26.8%削減 工場：19.3%削減
	売上と利益	店舗売上額：7.4%増加 店舗利益額：6.0%増加 工場利益額：7.4%増加
	欠品	22.4%減少
	廃棄	店舗：5.9%増加 工場：仕掛品在庫廃棄削減-100% サプライチェーン全体：5.7%減少

表 3.31 実証実験の効果一覧（プログラム変更後）

項目		1 か月当たりの効果
標準 KPI	発注回数	21.8 回の減少（店舗当たり）
	輸送回数	【通常輸送回数】 工場から店舗：変化なし 原材料メーカーから工場：変化なし 【緊急輸送回数】 工場から店舗：1 回→0 回（工場当たり） 原材料メーカーから工場：1.5 回→0 回（工場当たり）
	輸送距離	【通常輸送回数】 工場から店舗：変化なし 原材料メーカーから工場：変化なし 【緊急輸送回数】 工場から店舗：147km 減少（工場当たり） 原材料メーカーから工場：183km 減少（工場当たり）
	作業時間	店舗（発注作業）：26.8%削減 工場（計画作業）：19.3%削減
	売上と利益	店舗売上額：2.7%増加 店舗利益額：3.8%増加 工場利益額：2.7%増加
	欠品	18.2%減少
	廃棄	店舗：0.7%増加 工場：仕掛品在庫廃棄削減-100% サプライチェーン全体：17.3%減少

4. パフォーマンス向上効果の分析

4.1 企業間協業による企業のパフォーマンス向上効果

異なる利害関係者間の複雑な協働活動を推進していくためには、如何にして企業のパフォーマンス向上に結びつけていけるかについて示すことが重要である。そこで、本項では販売面・在庫面・欠品面等におけるパフォーマンス向上効果についてまとめる。

本事業における各社のパフォーマンス向上効果を表 4.1 に示す。ここで、パフォーマンス向上効果の販売面、在庫面、欠品面についてはプログラム変更後の値から算出した。

作業時間については、小売業では、AI 需要予測による発注推奨システムから発注端末に情報を連携することにより発注作業時間が 26.8%減少した。製造業では、リードタイムを長期化することによって見込み生産が受注生産に変更され、生産計画の策定に係る時間（生産数量計画時間、数量の変更に対応する時間、シフト修正検討時間）が 19.3%減少した。

物流面では、小売業の発注リードタイムを製造業の納品リードタイムより長期化して修正発注をなくすことによって緊急生産をする必要がなくなり原材料メーカーから工場への緊急輸送を 1.5 回/月減少することが可能になった。また、AI 自動発注により発注精度が向上し、発注の抜け漏れがなくなることにより工場から店舗への緊急輸送も 1 回/月減少した。

プログラム変更後に着目すると、販売面については、小売は売り切れ時間の早い商品の発注を増加し、値引き販売が増加している商品の発注を削減することにより売上額は 2.7%増加、利益額は 3.8%増加した。製造業は小売からの発注が増加することによって 2.7%売上が増加し、利益額も 2.7%増加した。在庫面については、小売は AI 需要予測を利用して発注量を決定することによって売上は増加したが廃棄はほとんど変化しなかった。製造は見込み生産を受注生産に変更することによって仕掛品在庫の廃棄が 9.7 個/店/月減少した。その結果、製造業と小売業を合わせたサプライチェーン全体では 19.0%減少しており、AI 需要予測を利用して各店舗の在庫を適正化し、その情報を共有することによってサプライチェーン全体における在庫は適正化されたと言える。欠品面については、各店舗・各商品の売り切れ時間が早い商品の発注を増やすことによって、17 時まで欠品する比率が 18.2%減少した。

表 4.1 各社のパフォーマンス向上効果（全期間）

項目		工場	店舗
生産性	作業時間	・生産計画 19.3%減少（工場当たり）	・発注時間 26.8%減少（店舗当たり）
	物流面	・緊急輸送の減少 原材料メーカーから工場の輸送 1.5 回（工場当たり）	・緊急輸送の減少 工場から店舗の輸送 1 回（工場当たり）
	販売面	・利益額向上 5.9%増加	・利益額の向上 6.0%増加 ・売上額の向上 5.9%増加
	在庫面	・サプライチェーントータル在庫 5.7%減少 小売 12.2%増加、工場仕掛品在庫廃棄 100%削減	
	欠品面		・欠品数 22.4%減少 ・最終販売時刻の改善
その他		・安定生産による品質向上、労災削減 ・離職抑止、社員成長促進	・発注における精神的負担の軽減 ・顧客への対応時間増加、欠品減少による顧客満足度向上

表 4.2 各社のパフォーマンス向上効果（プログラム変更後）

項目		工場	店舗
生産性	作業時間	・生産計画 19.3%減少（工場当たり）	・発注時間 26.8%減少（店舗当たり）
	物流面	・緊急輸送の減少 原材料メーカーから工場の輸送 1.5 回（工場当たり）	・緊急輸送の減少 工場から店舗の輸送 1 回（工場当たり）
	販売面	・利益額向上 2.7%増加	・利益額の向上 3.8%増加 ・売上額の向上 2.7%増加
	在庫面	・サプライチェーントータル在庫 17.3%減少 小売 0.7%増加、工場仕掛品在庫廃棄 100%削減	
	欠品面		・欠品数 18.2%減少 ・最終販売時刻の改善
その他		・安定生産による品質向上、労災削減 ・離職抑止、社員成長促進	・発注における精神的負担の軽減 ・顧客への対応時間増加、欠品減少による顧客満足度向上

上記の効果は、複数事業者が協働して需要予測を構築し、情報を事前共有したことによる成果である。需要予測の構築では、通常は小売のデータのみで構築されるが、製造業の保持している商品情報、販促情報、賞味期限情報、各店舗での取り扱い商品情報等を共有することによって、商品の特徴を考慮したカテゴリ分類が可能になり、他製造業と連携した販促情報による売上増加を考慮でき、賞味期限による売上傾向の変化やそれぞれの店舗

における商品陳列状況等も考慮した予測が可能になった。また、情報の事前共有では、小売業が発注リードタイムを製造業の納品リードタイムより長期化することで、製造業の見込み生産を受注生産に変更することが可能になり、工場の仕掛品在庫の廃棄が減少、緊急生産に伴う原材料メーカーから工場への緊急輸送の削減、工場から店舗への緊急輸送の削減、計画的な生産による安定生産、品質向上が実現できた。特に緊急輸送は通常輸送とは異なり、トラックやトラックドライバーの緊急確保を通して物流に大きな負荷を与えている。近年は、原材料メーカーからは発注リードタイムの長期化の要望が出ており、本実証実験のように受注生産による計画的な生産が実現できれば、リードタイムの長期化の実施可能性が高まると言える。

また、上記取り組みを全国規模で推進することによる定量的・定性的な効果を表 4.3 に示す。ここで、定量的効果の廃棄・利益の算出にはプログラム変更後の結果を利用した。

定量的効果は実証実験結果を利用して、日本全国のスーパーマーケットの店舗数で拡大推計して求めた。定性的効果は物流負荷の軽減や作業時間の削減、利益率増加、データ連携による生産性向上に付随する効果として記載した。

表 4.3 全国規模で推進することによる効果

項目	内容
定量的効果	今回の実証実験は 1 チェーンの 31 店舗で実施したが、日本のスーパーは 2024 年 2 月末時点で約 23,000 店舗である¹⁷。したがって、本事業内容を全国規模で実施した場合の効果を求めると下記になる。 ・発注回数：501,000 回/月削減 ・輸送回数：緊急輸送 240 回/月削減 ・輸送距離：31,600km/月削減 ・発注作業時間：414,000 時間/月削減 ・製造業計画策定時間：9,780 時間/月削減 ・廃棄：247,000 個/月削減（工場＋店舗） ・利益額：449 百万円増加（工場＋店舗） ・欠品回数：472,000 回/月削減
定性的効果	・物流負荷の大きい緊急輸送が減少することにより、物流業界の負荷軽減 ・DX により店舗従業員の発注作業時間、製造業の計画策定時間が削減され小売店の生産性向上が実現する。 ・利益額増加による生産性の向上 ・仕掛品在庫、店舗廃棄が減少することで食品ロスが削減 ・売上高増加による GDP の増加 ・データ連携・システム連携によるサプライチェーンの変革

¹⁷ 統計・データでみるスーパーマーケット <http://www.j-sosm.jp/>
（スーパーマーケット統計調査事務局、一般社団法人全国スーパーマーケット協会）

4.2 社会実装していくための要件整理

本事業では限定的な期間での実証実験を実施したが、社会実装を促進するため、企業間協働環境の構築を促す仕組み等について追加的に整理する。

(1) セキュリティ

企業間協働環境を構築していくためにはデータ連携が重要である。小売店のデータは個人情報も含まれているため個人を特定されないように匿名化し、機密性を保ったシステムを構築する必要がある。現在は、小売店のデータを収集し公開しているインテージ SRI+データ¹⁸等が存在しているが、サプライチェーンの発注には利用されていない。今後は、より高度にデータを連携、各企業がアクセスできる高いセキュリティのシステムが必要と考えられる。

(2) オペレーション連携のルール化

各企業が連携を推進するためには、オペレーションのルールを設定し、既存のビジネスプロセスの変革をする必要がある。ビジネスプロセスの変革には、各企業にコストがかかるため、それによって各企業がメリットを享受できる必要がある。一般的に、本事業で実施したような CPFR では製造業には明確なメリットが存在する一方、小売業のメリットは小さい。この問題点を解決するため、本事業では小売業に自動発注の仕組みを導入することで小売業にもメリットが生じる仕組みを構築した。このように、連携事業を実施する際は参加する各社がメリットを享受できる必要があり、その価値を定量化しシェアする仕組みが必要である。

(3) サプライチェーンの複雑性とルール化

本事業では、バローと中部フーズとの連携を実施したが、バローと中部フーズはグループ企業であり、中部フーズはバローの惣菜部門全体を担っているため 1 対 1 の連携を行うことで、両企業にメリットをもたらすことが可能であった。しかし、このような連携を広く社会に実装していくためには、N 対 N の連携が必要になり、より複雑化していく。そこで、このような事業を社会実装していくためには、①連携による価値を定量化し、②その価値を複数社でシェアするルールを構築することが必要である。

¹⁸ スーパーマーケット、コンビニエンスストア、ホームセンター・ディスカウントストア、ドラッグストア、専門店等全国約 6,000 店舗より収集している小売店販売データ SRI+® (全国小売店パネル調査) | 市場調査ならインテージ (intage.co.jp)

5. まとめ

5.1 需要予測に影響を与える大きな要因の調査・整理

5.1.1 ヒアリング

需要予測に影響を与える大きな要因についてバローのスーパー3店舗の発注担当者を対象にヒアリングを実施した。需要の変動要因として気象要因があり、雨や台風は来店客数の変動に影響を与え、気温は各商品の売上に影響を与えている。販促要因としては、ポイントキャンペーンや新商品があり、それぞれ各商品の売上に影響を与える。暦要因としては、曜日変動、季節変動、特異日等があり、来店客数に影響を与える。その他要因としては野菜の相場、競合の動向等があり、担当者の経験と勘でこれらの影響を考慮していることが分かった。

5.1.2 データを用いた解析

データを用いた解析ではヒアリングで得た情報をデータで確認できるか来店客数、各商品の解析を実施した。

(1) 来店客数

客数は曜日変動、季節変動の影響が大きい、年末等は特異日で売上変動は通常と異なる。リニューアルを実施した場合は開店後数日に客数が大きく増加することが確認できた。来店客数は降雨によって減少するが、土曜日に影響が大きい等、曜日によってもその変化は異なることが分かった。また、台風によっても影響を受けている等、ヒアリングで得た関係性は実データでも確認できた。

(2) 各商品

バローでは調査対象商品はおにぎり・弁当、寿司、惣菜の3つのカテゴリに分類されており、各カテゴリで動きは異なっていた。おにぎり・弁当カテゴリは安定した売上があるが、惣菜カテゴリは季節によって大きく変動し、寿司カテゴリは特異日の影響を受けている。また、商品には定番商品と季節商品が存在しており、季節商品は販売開始直後に売上が増加するが、季節終了に向けて少しずつ売上が減少していく。雨の売上への影響は存在するが来店客数ほど大きくなく、冷やし中華等、商品によっては気温の効果の方が大きい。販促は商品ごとに実施しているが、販促期間中は売上が増加する。また、それ以外の影響として近隣で運動会等が実施される場合は予約による売上増加が発生することが分かった。

(3) 複合的な要因

降雨日は来店客数が減少し定価販売数量も減少するが、全体販売数量は大きく変わっていない。これは、雨の日も通常通りの発注が行われているため、晴れの日よりも値引きを多く実施して売り切っているためと考えられる。その結果、降雨日は値引き率、もしくは

廃棄数が増加していた。

したがって、AI を利用した需要予測モデルを構築し発注を半自動化することで、雨等の効果を予測した上で発注量を決定し、ムダな値引きや廃棄を減少させることが可能と考えられる。

5.2 複数事業者協働による実証実験

5.2.1 対象の設定

実証実験の対象店舗はバローの複数エリアの 31 店舗、対象商品は完成品の全商品、対象期間は 2024 年 1 月 22 日～3 月 21 日の 2 か月間とした。

5.2.2 オペレーション変革

現行オペレーションでは、店舗は 1 週間前に週間発注、2 日前に修正発注を経験と勘で店舗の在庫を考慮した上で実施している。工場は店舗からの発注量を予測して見込み生産を実施しており、週間発注から発注量が大きく変更された場合は工場から店舗の緊急輸送や原材料メーカーから工場の緊急輸送、仕掛品在庫の廃棄等が発生している。

実証実験で実施するオペレーションでは、店舗は木曜日に週間発注、火曜日に週末の修正発注と発注を 2 回に削減し、リードタイムを 3 日以上に延長し、AI 需要予測モデルを利用した自動発注を実施することとした。これによって、店舗では在庫最適化を実現した上で発注作業を軽減し、工場では店舗からの発注量を予測する見込み生産から受注生産に変更することが可能になる。

5.2.3 発注推奨システムの構築

発注推奨システムは、AWS クラウドを利用して構築した。システムではバロー、中部フーズ、ソフトバンク、日本気象協会からそれぞれデータを収集した。また、これらのデータを利用して AI を利用した需要予測モデルで来店客数予測、カテゴリ需要予測、SKU 需要予測を実施した。この SKU 需要予測データを入力値とし、在庫最適化モデルで各店舗・各商品の発注推奨量を求め、発注端末と連携し発注を行った。

需要は曜日によって変動し、降雨が観測される場合は需要が低下、季節が変化すると旬な商品は移り変わり売上が大きく変動していたが、各予測とも相関係数 0.9 以上と予測精度は高かった。一方で、節分の日や花火大会、夏休み、台風の接近等、過去データで十分に学習できない事例については予測が困難であることが分かった。

これらの需要予測を利用して在庫最適化モデルを適用した。在庫最適化モデルは賞味期限ごとに手法を変更し、実績の発注量を再現することができた。また、利益最大化を実現するため、売り切れが発生する場合は発注を追加、ロスが大きくなる時は発注を削減することとした。

5.2.4 実証実験の結果評価

実証実験の結果を表 5.1 に示す。本実証実験では、小売業の発注を自動化し、発注回数を木曜日と火曜日に限定してリードタイムを長期化することで、工場の見込み生産を受注生産に変更した。その結果、発注回数は 75%減少し緊急輸送が 0 回になった。

また、店舗発注に AI 需要予測モデルを利用して高度化、自動化することで、小売の発注作業時間 26.8%減、工場の計画策定時間 19.3%減となった。また、発注量が適正化することで、売上は 2.7%増、利益 3.8%増、欠品 18.2%減、廃棄はサプライチェーン全体 17.3%減となった。

表 5.1 実証実験の効果一覧（プログラム変更後）

項目		1 か月当たりの効果
標準 KPI	発注回数	21.8 回の減少（店舗当たり）
	輸送回数	【通常輸送回数】 工場から店舗：変化なし 原材料メーカーから工場：変化なし 【緊急輸送回数】 工場から店舗：1 回→0 回（工場当たり） 原材料メーカーから工場：1.5 回→0 回（工場当たり）
	輸送距離	【通常輸送回数】 工場から店舗：変化なし 原材料メーカーから工場：変化なし 【緊急輸送回数】 工場から店舗：147km 減少（工場当たり） 原材料メーカーから工場：183km 減少（工場当たり）
	作業時間	店舗：26.8%削減 工場：19.3%削減
	売上と利益	店舗売上額：2.7%増加 店舗利益額：3.8%増加 工場利益額：2.7%増加
	欠品	18.2%減少
	廃棄	店舗：0.7%増加 工場：工場仕掛品在庫廃棄 100%削減 サプライチェーン全体：17.3%減少

5.3 パフォーマンス向上効果の分析

5.3.1 企業間協業による企業のパフォーマンス向上効果

異なる利害関係者間の協働活動を実施することによる販売面・在庫面・欠品面等におけるパフォーマンス向上効果を表 5.2 に示す。作業時間、物流面、販売面、在庫面、欠品面でそれぞれメリットがあることが示された。

表 5.2 各社のパフォーマンス向上効果（プログラム変更後）

項目		工場	店舗
生産性	作業時間	・生産計画 19.3%減少（工場当たり）	・発注時間 26.8%減少（店舗当たり）
	物流面	・緊急輸送の減少 原材料メーカーから工場の輸送 1.5 回（工場当たり）	・緊急輸送の減少 工場から店舗の輸送 1 回（工場当たり）
	販売面	・利益額向上 2.7%増加	・利益額の向上 3.8%増加 ・売上額の向上 2.7%増加
	在庫面	・サプライチェーントータル在庫 17.3%減少 小売 0.7%増加、工場仕掛品在庫廃棄 100%削減	
	欠品面		・欠品数 18.2%減少 ・最終販売時刻の改善
その他		・安定生産による品質向上、労災削減 ・離職抑止、社員成長促進	・発注における精神的負担の軽減 ・顧客への対応時間増加、欠品減少による顧客満足度向上

5.3.2 社会実装していくための要件整理

本事業のような CPFR を社会実装していくためには参加する各社にメリットが生じる必要があり、その価値を定量化しシェアする仕組みが必要である。また、連携を広く社会に実装していくためには、N 対 N の連携が必要になり、より複雑化していく。

そこで、このような事業を社会実装していくためには、①連携による価値を定量化し、②その価値を複数社でシェアするルールを構築することが必要である。

資料編

本文中に利用した指標を示す。

$$\text{相関係数 } R = \frac{\frac{1}{n} \sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\frac{1}{n} \sum (x_i - \bar{x})^2} \sqrt{\frac{1}{n} \sum (y_i - \bar{y})^2}} \quad \text{資料-1}$$

$$\text{決定係数} = R^2 \quad \text{資料-2}$$

$$MAPE = \frac{100}{n} \sum \left| \frac{y_i - x_i}{x_i} \right| \quad \text{資料-3}$$

$$RMSE = \sqrt{\frac{1}{n} \sum (x_i - y_i)^2} \quad \text{資料-4}$$

X_i : 実績 (人)
 Y_i : 予測 (人)
 n : 標本数 (一)

二次利用未承諾リスト

報告書の題名 令和５年度流通・物流の効率化・付加価値創出に係る基盤構築事業（複数事業者協働での製品在庫配置の最適化による輸配送効率向上並びに返品・廃棄削減事例の創出）調査報告書

委託事業名 令和5年度流通・物流の効率化・付加価値創出に係る基盤構築事業（複数事業者協働での製品在庫配置の最適化による輸配送効率向上並びに返品・廃棄削減事例の創出）

受注事業者名 一般財団法人 日本気象協会

[illegible]