

数理モデリングプロジェクト

Mathematical Modeling Project

プロジェクトリーダー：小久保尚 / Nao Kokubo

1 はじめに

本プロジェクトでは、コンビニエンスストア（以下、コンビニ）における属人性の高い業務の課題を解決するため、特にホットスナックの一例であるファミチキの仕込み業務に着目し、その属人性を排除するシステムを開発した。ファミチキはその消費期限の短さや売上の多さにより、従業員の意思決定が売上や廃棄量に直接影響を与える商品であり、コンビニ業務の課題を集約したモデルケースと位置付けられる。

開発したシステムは、ファミチキの過去の売上データや時間帯ごとの需要を分析し、最適な仕込み数と仕込みタイミングの提案を行う。これにより、従業員が経験や勘に頼ることなく安定した仕込みが可能となる環境を提供し、廃棄削減と業務効率化を図る。さらに、システムの有効性を実店舗での実地検証により評価し、コンビニ業務全体の属人性排除への応用可能性を検討した。本プロジェクトの成果は、コンビニ業界における経営効率化と従業員の負担軽減に寄与する有意義な知見を提供するものである。

2 先行研究および技術・知識の習得

2.1 「Python による数値計算法の基礎」についての輪講

数理モデルとは、微分方程式などより現象を数学的に記述したものである。数値計算は、微分方程式で記述された数理モデルの解を近似的に求める方法であり、これによりこれから起こる現象の予測を行うことができる。そのため、数値計算の手法を「Python による数値計算法の基礎 [1]」を用いて輪講を行った。

2.2 輪講の内容と成果

数値計算の手法として「テイラー法」「オイラー法」「修正オイラー法」「ルンゲクッタ法」「連立常微分方程式系の数値計算法」「高階常微分方程式の数値計算法」に

ついての輪講を行った。Google Colab を用いてコードを実際を書いて動かしながら、それぞれの数値計算の手法を学んだ。また、書籍の内容を一通り修得した後、与えられた常微分方程式を数値計算するコードを各自が書くという確認テストを行い、メンバーの理解度を確認した。輪講を通じて、数値計算の手法について習得できただけでなく、Python のコードに関する理解をメンバー間で深めることができた。

3 課題解決のプロセスとその結果

3.1 システム概要

本プロジェクトでは、前述した目的を達成するため、最適な仕込み数と次回の仕込むべきタイミングを従業員に提示する仕組みを、タブレット端末上で動作する Web アプリケーションとして開発した。

このアプリケーションは、従業員がファミチキの陳列の不足を感じたとき、現在のファミチキの陳列数を入力することで、追加で仕込むべき最適なファミチキの個数を予測し画面上に表示する。従業員はこれに基づき、画面上に表示された個数だけファミチキを揚げることによって、適度な陳列数を保つことができる。

3.2 ベテラン従業員のモデル化

ヒアリングやファミチキで実際に働くメンバーの経験から、ベテラン従業員は (1) 来客数を推測し、(2) いつ・何個、商品が売れるのかという見通しを立て、(3) すぐ売り切れず、売れ残りも出ない仕込み数を求める、というステップによって、最適な仕込み数を考えている、と考えた。これをシステムとして組み込むために、以下の流れで最適な仕込み数の導出を行う。まず (1) に対応することとして、過去のデータを学習し、天気・曜日から来客数の予測を行う。次に (2) に対応することとして、予測された来客数をもとに、ファミチキの陳列数、顧客の購買意欲、従業員の仕込み意欲の時間変化を再現する。そして (3) に対応することとして、(2) で再現された陳

列数・購買意欲・仕込み意欲の時間変化から、仕込み時間や売上・廃棄数等を予測最適な仕込み数を導出する。

3.3 重回帰分析による来客数予測

来客数予測のために重回帰分析を用いた。重回帰分析とは、複数の説明変数を用いた回帰分析の手法である。実際に用いた説明変数として、気温、湿度、日曜あるいは祝日か否か、の3つの環境要因を用いた。これらは、取得可能なデータのうち、来客数との関係をグラフとして図示し観察した結果、来客数に強く影響すると判断した指標を選定したものである。

3.4 購買-仕込みモデルと最適化手法

商品の陳列数 $x = x(t)$ 、顧客の一人当たりの購買意欲 $D = D(t)$ 、従業員の仕込み意欲 $m = m(t)$ の相互作用を以下の微分方程式で表した。

$$\begin{cases} \frac{dx}{dt} = -\omega DCf(x) + \beta \max(m - m_p, 0) \\ \frac{dD}{dt} = \gamma_x x(1 - D) - \gamma_D D \\ \frac{dm}{dt} = \alpha_C C(C_{\max} - C)(x_{\max} - x) - \alpha_x x \\ f(x) = \begin{cases} 1 & x > 0 \\ 0 & x \leq 0 \end{cases} \end{cases} \quad (1)$$

$$\omega, \beta, \gamma_x, \gamma_D, \alpha_C, \alpha_x > 0$$

一人あたりの購買意欲 D は、単位時間あたりに顧客が一人が買う量である。また、 $C = C(t)$ は来客数であり、 m_p は仕込み意欲の閾値、 x_{\max} は陳列ケースの最大容量、 C_{\max} は来客数の最大値である。各式の各項について説明する。

- 第一式

- $-\omega DCf(x)$: 陳列数が正の時に限り、買われることにより陳列数が減少することに対応した項。
- $\beta \max(m - m_p, 0)$: 仕込み意欲が閾値 m_p を超えると仕込みが開始され、陳列数が増加することに対応する項。

- 第二式

- $\gamma_x x(1 - D)$: 陳列数の数に応じて商品ケースの魅力が大きくなり、購買意欲が増加することに対応する項。ただし、 D が 1 に近づくとつれその増加量は減少する。
- $-\gamma_D D$: 時間経過により商品の質が低下し、購買意欲が減少することに対応する項。

- 第三式

- $\alpha_C C(C_{\max} - C)(x_{\max} - x)$: 来客数が少なすぎず、多すぎず、かつ、陳列数が少ないときに仕込み意欲が増加することに対応する項。
- $\alpha_x x$: 陳列数が多いときに仕込み意欲が減少することに対応する項。

この購買-仕込みモデルの数値計算によって得られる陳列数・購買意欲・仕込み意欲の変化から求めた数値を利用して、以下の目的関数を設定した。

$$f(x) = w'_1 \frac{x_0 - x_f}{x_{\max}} + w'_2 \frac{t_{peak}}{t_{end}} + w'_3 \frac{C(t_{peak})}{C_{\max}} + w'_4 \frac{x_f}{x_{\max}} \quad (2)$$

x_0 は陳列数の初期値、 x_f は次回仕込み時の陳列数、 t_{peak} は次回仕込む時間、 $C(t_{peak})$ は次回仕込み時の来客数である。この目的関数を最大化することにより、売上と仕込み間のインターバルを最大化し、次回仕込み時の来客数(店内の混雑具合)と売れ残りを最小化するような仕込み数を求めることができる。

3.3 システムの技術構成

構成を説明するにあたり、まず従業員が入力するデータと提示されるデータの流れを述べておく。従業員はアクセスした Web ページ上で現在の陳列数を入力する。その後、最適仕込み数・仕込みタイミングを提示するボタンを従業員が押下すると、入力情報を JSON データ形式でバックエンドに API リクエストする。バックエンドでは、入力情報をもとにモデルの実行に必要な説明変数を外部 API で参照し、最適仕込み数・仕込みタイミングを算出する。最後に算出結果を従業員がアクセスしている Web ページ上に表示するという流れである。

システムの公開には Amazon Web Services(AWS)、とりわけ EC2 と S3 というサービスをおもに用いた。S3 では、従業員が Web ページにアクセスできるようにコンテンツをデプロイし、アクセス許可等を設定した。EC2 は、モデルの実行と API 処理システムの実行環境(バックエンド)として用いた。

バックエンドの具体的な内容としては、従業員が入力し、モデルにより提示される陳列数/仕込み数の HTTP リクエストに関わる FastAPI を用いた設定、OpenWeatherMap API を用いた天気情報の参照、jpholiday ライブラリを用いた土日祝の判定、説明変数を引数としたモデルの実行である。

3.4 操作画面

実際の操作画面を示す。図 1はメインの画面として予測結果とを表示する画面であり、図 2は従業員による入力を受け付ける画面である。

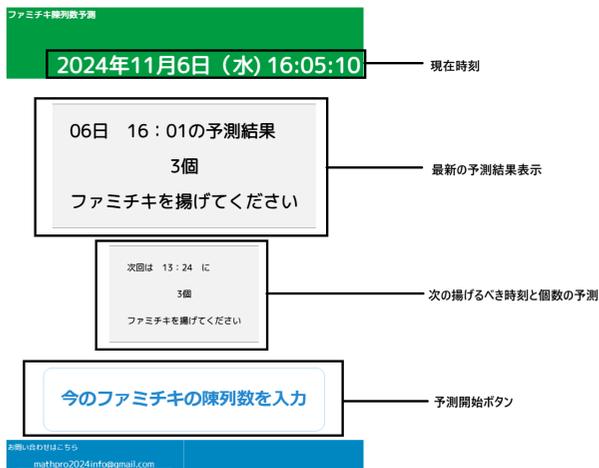


図 1: メイン画面

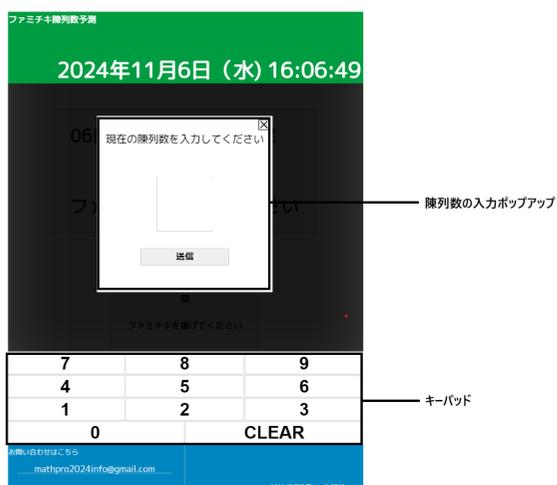


図 2: ポップアップ表示画面

4 実地検証

4.1 目的と方法

開発したアプリケーションの有用性を検証するために、使いやすさと実際の売上への貢献という二つの観点から評価を行った。

使いやすさについては、従業員へのアンケートを通じてアプリケーションの操作性やファミチキの仕込み業務の実態について調査することで確認した。

また、売上への貢献度については、アプリケーション導入前後の売上データを比較し、数値的な効果を分析した。また、機械学習の手法の一つである XGBoost を用

いた売上予測から仕込み数を計算するというシステムを用意し、数理モデルによるシステムと機械学習モデルによるシステムのそれぞれの売上への貢献度を比較した。

本検証の実施期間は、2024年10月28日から11月15日までの約2週間である。この期間は、前半(10月28日~11月6日)に機械学習モデルを用いた予測を行い、後半(11月7日~11月15日)には数理モデルを用いた予測を行った。

4.2 結果と考察

4.2.1 アンケート

本セクションでは、協力いただいた店舗における従業員アンケートの結果をまとめる。今回のアンケートには、約10名の従業員のうち4名にご協力いただいた。

アンケート結果から、アプリケーションの使用頻度にはばらつきが見られ、業務の忙しさや個人の習慣が影響していることが分かった。初期段階では比較的頻繁に使用されていたものの、時間の経過とともに使用頻度は減少し、特にピーク時にはアプリケーションが十分に活用されなかったケースも見られた。また、時間帯による使用効果の違いも明らかになり、夜間にはアプリケーションが有効に活用される一方で、朝や昼のピーク時間帯には従来の業務手法に頼る傾向が見られた。

従業員の経験による差も確認され、新しいスタッフにとってはアプリケーションが有用であると評価された一方で、経験豊富なスタッフには仕込み数が不足していると感じられるケースもあった。しかしながら、多くの回答者が「やや使用したい」と回答しており、一定の有用性は認識されていることが分かった。

4.2.2 売上率

機械学習モデルと数理モデルそれぞれについて、売上率の変化を比較した。売上率は、売上金額の合計を来客数の合計で割ったものとして定義する。分析には差分の差分法を用いた。この手法を用いるにあたって、比較用のデータが必要であり、過去の売上データを利用した。利用したデータの具体的な期間は以下のようにしている。

- 2023年10月1日~2023年11月30日
- 2024年10月1日~2024年10月27日

また、夜間にアプリケーションの利用回数が多いことから、24時間分のデータと17時~24時のみのデータの場合についても比較した。

表 1に分析の結果を示す。

表 1: モデル別の分析結果

モデル名	24 時間		17 時～24 時	
	導入前	導入後	導入前	導入後
機械学習	0.0028	0.0067	0.0115	0.0214
数理モデル	0.0028	0.0038	0.0115	0.0119

結果として、24 時間分の売上率の差は、機械学習モデルが 0.004、数理モデルが 0.001 となった。17 時～24 時の売上率の差は、機械学習モデルが 0.01、数理モデルが 0.0003 となった。数理モデルによるシステムも機械学習モデルによるシステムも、両方とも未導入だった時期と比べて売上率が上がっていた。24 時間の場合も 17 時～24 時の場合も、機械学習モデルの方が上がり幅が大きかった。17 時～24 時に関しては通常より大きく売上率が上がっていた。

4.2.3 考察

実地検証の結果、アプリケーションの利用状況には時間帯や従業員の判断基準による違いが見られた。日中では従来の経験則に基づく仕込みが優先され、アプリケーションの提案が十分に活用されなかった。これは、従業員が自身の業務経験を信頼していたことが要因と考えられる。一方、夜間ではアプリケーションを参考にした仕込みが多く行われ、実際に売上率の向上が確認された。特に、機械学習モデル期間で利用が多かったことが効果に寄与したといえる。

一方、数理モデル期間ではアプリケーションの利用がほとんど確認されなかった。その理由として、従業員がアプリケーションに飽きたこと、そして数理モデルの提案が従業員の実感に合わず信頼を得られなかったことが挙げられる。これにより利用頻度が低下し、モデルの有効性を十分に発揮できなかった。

しかし、夜間の売上率向上や初期段階での積極的な利用は、アプリケーションのポテンシャルを示している。また、新しいスタッフにとって業務支援ツールとして有用であることがアンケートからも確認された。

今後は、数理モデルの精度向上や継続利用を促進する仕組みを導入することで、アプリケーションの有効性を高め、業務全体の効率化に貢献することが期待される。

5 まとめ

5.1 活動の総括

本プロジェクトでは、ファミチキの売り上げ予測を行い、最適な仕込み数とタイミングを従業員に提案するシステムを作成することを到達目標とし、活動に取り組んだ。本プロジェクトの成果物「仕込み支援システム」は、数理モデルから得られた予測結果を Web を通じてタブレット端末の画面上に表示し、従業員に提示するものを開発した。その後、構築した数理モデルの有用性を調べるため、比較用の機械学習モデルを用意し、実地検証を行った。売上率について、両方とも未導入だった時期と比べて上がっており、特に 17 時以降に関しては通常より大きく売上率が上がっていた。どちらの場合も、機械学習の方が上がり幅が大きかった。この 1 年間の活動を通じて、プロジェクトメンバーは多岐にわたる技術を習得することができ、貴重な経験となった。この経験は後の卒業研究や就職後にも活かされるだろう。

5.2 今後の展望

発表会での聴衆からのコメントや実地検証の結果から得られた課題と改善案について述べる。1 つ目は、Web アプリケーションの UI/UX の改善である。実地検証当初は頻繁に利用されていたが、徐々に利用頻度が減少していった。このことから、陳列数入力の手間を省き、より従業員にとって利便性の高いデザインに改善する必要があると考えられる。2 つ目は、複数店舗での検証である。今回の実地検証は 1 店舗のみでの実施だったため、売上率の比較やモデルの評価に偏りが出てしまった可能性がある。そのため、複数店舗での検証を実施し、偏りのない比較を行う必要がある。3 つ目は、購買 - 仕込みモデルの改善・解析である。実地検証での使用頻度の傾向から数理モデルが信頼されなかった可能性がある。数理モデルの精度向上のために陳列数データの収集を行い、陳列数がどれくらい購買や仕込みに影響を及ぼしているか検証する必要がある。また、このモデルを解析することにより、ベテラン従業員を特徴づける要因を発見し、それを新人教育への知見として提供できるのではないかと考えられる。

参考文献

[1] 橋本 修・毛塚 敦. 2021. 『Python による数値計算法の基礎』. 森北出版.