

公立はこだて未来大学 2024 年度 システム情報科学実習  
グループ報告書

Future University Hakodate 2024 Systems Information Science Practice Group Report

プロジェクト名

数理モデリングプロジェクト

**Project Name**

Mathematical Modeling Project

グループ名

グループ A

**Group Name**

Group A

プロジェクト番号/Project No.

05

プロジェクトリーダー/Project Leader

小久保尚 Nao Kokubo

グループリーダー/Group Leader

小久保尚 Nao Kokubo

グループメンバ/Group Member

小久保尚 Nao Kokubo

石井健太 Kenta Ishii

石井朗偉 Roi Ishii

今壮平 Sohei Kon

佐野大翔 Hiroto Sano

多田瑛貴 Teruki Tada

新田龍太郎 Ryutaro Nitta

吉野颯真 Souma Yoshino

六本木是杜 Yoshito Roppongi

指導教員

寺井あすか 田中吉太郎 石尾隆

**Advisor**

Asuka Terai Yoshitaro Tanaka Takashi Ishio

提出日

2025 年 1 月 21 日

**Date of Submission**

January 21, 2025



## 概要

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の開発を行った。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。

本プロジェクトでは、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を提案するシステムを開発した。このシステムは、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目指すものである。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。

**キーワード** 数理モデリング, コンビニ, 機械学習, 重回帰, 微分方程式, 数値解析, 食品ロス, 経営効率, シミュレーション, 需要予測, Web アプリ

(※文責: 小久保尚)

## Abstract

In this project, we addressed the challenges of tasks with high dependency on individual expertise in convenience stores by focusing on the preparation operations for "Famichiki", a representative example of hot snacks. "Famichiki", with its short shelf life and high sales volume, is a product where employee decision-making directly affects both sales and waste, making it a model case that encapsulates the challenges of convenience store operations.

This project involved developing a system that analyzes past sales data and time-based demand to propose optimal preparation quantities and timing for "Famichiki". The system provides an environment where employees can perform stable preparation without relying on experience or intuition, aiming to reduce waste and improve operational efficiency. Furthermore, the system's effectiveness was evaluated through field testing in an actual store, and its potential application to eliminating dependency on individual expertise in other convenience store operations was explored. The outcomes of this project offer valuable insights into improving operational efficiency and reducing employee workload in the convenience store industry.

**Keyword** Mathematical Modeling, Convenience Store, Machine Learning, Multiple Regression, Differential Equations, Numerical Analysis, Food Loss, Management Efficiency, Simulation, Demand Forecasting, Web App

(※文責: 小久保尚)

# 目次

<b>第 1 章</b>	<b>はじめに</b>	<b>1</b>
1.1	背景と課題	1
1.2	到達目標	1
<b>第 2 章</b>	<b>先行研究および技術・知識の習得</b>	<b>3</b>
2.1	モデリング	3
2.1.1	数理モデル	3
2.1.2	機械学習	12
2.2	成果物の実装	16
2.2.1	Amazon Web Services(AWS)	16
2.2.2	FastAPI	17
2.2.3	OpenWeatherMap	18
2.2.4	JavaScript	18
2.2.5	その他のフロントエンド開発に使用したツール	19
2.3	成果物の検証	19
2.3.1	仮説検定	19
2.3.2	差分の差分法 (DID: Difference In Difference)	20
<b>第 3 章</b>	<b>成果物の開発</b>	<b>21</b>
3.1	システム概要	21
3.2	システム構成	21
3.2.1	サーバー運用基盤 (AWS) の構成	22
3.2.2	バックエンドの処理	22
3.3	モデル構成	23
3.4	データの収集	23
3.4.1	店舗に関するデータ	23
3.4.2	過去の気象データ	24
3.4.3	祝日データ	24
3.5	来客数予測	24
3.5.1	実装の仕様	24
3.5.2	説明変数	25
3.5.3	性能評価と課題	25
3.6	数理モデル	29
3.6.1	数理モデル	29
3.6.2	最適化手法	34
3.7	機械学習	36
3.7.1	モデルの選定	36

3.7.2	モデルの作成 . . . . .	36
3.7.3	評価 . . . . .	38
3.8	Web アプリケーションの機能と実装 . . . . .	38
3.8.1	アプリケーションの機能と実装 . . . . .	38
3.8.2	システムの設計 . . . . .	40
3.8.3	システムの画面構成 . . . . .	41
<b>第 4 章</b>	<b>実地検証</b>	<b>43</b>
4.1	実地検証の方法 . . . . .	43
4.1.1	アンケート . . . . .	45
4.1.2	売上率 . . . . .	47
4.2	プロトタイプを用いた事前検証 . . . . .	48
4.3	実地検証の結果 . . . . .	49
4.3.1	アプリケーションの使用状況 . . . . .	49
4.3.2	アンケート . . . . .	49
4.3.3	売上率 . . . . .	50
4.4	結果に対する考察 . . . . .	51
<b>第 5 章</b>	<b>中間発表</b>	<b>53</b>
5.1	中間発表の準備 . . . . .	53
5.2	当日について . . . . .	53
5.3	発表評価について . . . . .	54
5.4	発表技術コメント . . . . .	54
5.4.1	肯定的な意見 . . . . .	54
5.4.2	否定的な意見 . . . . .	55
5.5	発表内容コメント . . . . .	56
5.5.1	モデリング関係 . . . . .	56
5.5.2	実装関係 . . . . .	57
5.5.3	その他 . . . . .	57
5.6	評価の考察と今後の改善 . . . . .	58
<b>第 6 章</b>	<b>成果発表</b>	<b>59</b>
6.1	成果発表の準備 . . . . .	59
6.2	当日について . . . . .	59
6.3	発表評価について . . . . .	60
6.4	発表技術コメント . . . . .	62
6.4.1	肯定的な意見 . . . . .	62
6.4.2	否定的な意見 . . . . .	63
6.5	発表内容コメント . . . . .	63
6.5.1	モデリング関係 . . . . .	63
6.5.2	実装関係 . . . . .	64
6.6	発表評価について . . . . .	65

6.7	評価の考察と今後の改善 . . . . .	65
6.7.1	発表技術 . . . . .	65
6.7.2	発表内容 . . . . .	66
<b>第7章</b>	<b>まとめ</b>	<b>67</b>
7.1	活動の総括 . . . . .	67
7.2	今後の展望 . . . . .	68
	<b>謝辞</b>	<b>69</b>
	<b>参考文献</b>	<b>70</b>

# 第1章 はじめに

本プロジェクトはファミチキの仕込み業務における属人性を排除すること目的に活動する。

(※文責: 石井朗偉)

## 1.1 背景と課題

コンビニは、飲食料品や日用雑貨の購買、宅配便の発送、ATMでの現金引き出し、公共料金の支払い、住民票の発行など、私たちの生活に密接に関わるサービスを提供している。地方では、スーパーマーケットや大規模店舗の閉鎖が進む中で、コンビニが住民にとっての貴重な買物拠点となっているほか、防犯や災害時の物資提供など、社会的なインフラとしての役割も強調されている。

一方で、現在のコンビニは大きな転機を迎えている。経済産業省(2020)[1]によると、非正規雇用の割合が高く、長期的に働く人材が不足していることが課題とされている。また、人口減少による売上の停滞や、人件費・電気代などの運営コストの増加が経営を圧迫している。その結果、特定の従業員に業務やシフトが集中しやすくなり、属人性が高まる傾向にある。この属人性は、業務の効率化を妨げるだけでなく、さらに負担を集中させる悪循環を引き起こす要因となっている。

現在のコンビニの主要な課題を解決する手掛かりを得ることができる商品として、ホットスナックがある。ホットスナックには消費期限が極めて短いという特性があり、仕込み数が売上や廃棄量に直接影響を与える。特に仕込みすぎは廃棄コストを増加させ、仕込み不足は機会損失を招くため、適切な仕込み数の判断が店舗運営において重要である。また、ホットスナックの仕込み業務には標準化されたマニュアルが存在せず、多くの場合、従業員が自身の経験則に基づいて仕込み数を決定している。その結果、業務の属人性が高まり、経験豊富な従業員に業務が集中する状況が生じている。

特に、ファミチキはホットスナックの中でも販売量が多く、業務の属人性を排除するモデルケースとして最適である。

(※文責: 石井朗偉)

## 1.2 到達目標

上で述べた課題を解決するために、ファミチキの売上予測を行い、現在の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案するシステムを作成する。このシステムは、過去の売上データや時間帯ごとの需要を分析し、作成したモデルに基づいて仕込み数を提示することで、従業員が経験や勘に頼らずに業務を遂行できる環境を提供する。また、システムの有効性を検証するため、実店舗において実地検証を行い、その成果を評価する。

ファミチキの仕込み業務における属人性を排除するシステムを提案することで、コンビニにお

## Mathematical Modeling Project

ける他業務の属人性排除にも応用可能な知見を提供する.

(※文責: 石井朗偉)

## 第2章 先行研究および技術・知識の習得

本章では本プロジェクトを実施するにあたって必要な技術・手法、およびそれらの習得のために行った活動や先行研究について述べる。さらに、成果物の実装および検証を進めるにあたって必要な技術や、その実装に向けて行った活動についても述べる。必要な技術や行った活動は「モデリング」、成果物の管理に行った活動は「成果物の実装」、成果物の検証のために行った活動は「成果物の検証」の3つの項目に分けて述べる。

(※文責: 六本木是杜)

### 2.1 モデリング

本プロジェクトでは、ファミチキの売上予測と最適な仕込み数およびタイミングの提案を数理モデルを用いて行う。数理モデルは時間とともに変化する現象を微分方程式を用いてモデル化する手法である。したがって、数理モデルに基づくシミュレーションを行うには、微分方程式などの数値計算法をプロジェクトメンバーが修得することが必須である。そのため、輪講会を実施して数値計算に関する学習を行った。

ファミチキの仕込み数最適化を行うためには、まずファミチキの需要量を予測する必要がある。そのためには、来客数の予測が必要となる。この予測のために、微分方程式を中心としたアプローチを用いる。コンピュータを用いて現象を詳細にシミュレーションし、予測精度を高めることが重要である。この過程では、プロジェクトメンバー全員がコンピュータを使用して微分方程式の近似解を求めるスキルを習得することが求められる。

本プロジェクトでは、微分方程式の近似解をプログラムを用いて得るスキル習得を目的に輪講会を実施した。このスキル習得により、メンバー全員の数理モデルを用いた解析およびシミュレーション能力が向上し、プロジェクトに貢献することができた。輪講会で学んだ具体的な内容については、同節で述べる。

さらに、既存の需要予測の手法として、機械学習に基づく手法も検証した。機械学習は過去のデータに基づいて予測を行う手法であり、数理モデルを用いる手法を評価するために学習を行い、検証に用いた。

(※文責: 六本木是杜)

#### 2.1.1 数理モデル

現象を数学的に記述する数理モデルを用いる。そのためには常微分方程式を始めとした数学的知識およびコンピュータを用いた数値計算法の知識を習得する必要がある。そこで本プロジェクトの最初の活動として、それらの知識を学習する為の輪講会を実施した。輪講会の目的は2つある。1つ目は、プロジェクトメンバー全員が数理モデリングの基礎知識である常微分方程式を始めとした数学的知識および Python を利用した数値計算法の知識の習得である。2つ目は、プロジェ

クトメンバー全員が数理モデリングの知識を持つことで、これからの活動を円滑に進めるためである。

### 常微分方程式

微分方程式とは、ある現象の時間変化や空間変化を微分を用いて表現した式である。例えば、以下の微分方程式は、SIR モデルという感染症の流行について記述した式である。

$$\begin{cases} \frac{dS}{dt} = -\beta SI, \\ \frac{dI}{dt} = \beta SI - \gamma I, \\ \frac{dR}{dt} = \gamma I, \end{cases} \quad (2.1)$$

$S = S(t)$  は時刻  $t$  におけるまだ感染したことの無い感受性者の割合、 $I = I(t)$  は時刻  $t$  における感染しさらに感染を広げうる感染者の割合、 $R = R(t)$  は時刻  $t$  における免疫を獲得しもう感染症にかからない回復者の割合をそれぞれ表している。また、 $\beta$  は感染率に対応し、 $\gamma$  は回復率に対応している。まず (2.1) 第一式の  $-\beta SI$  という項は、感受性者と感染者が接触することにより、感受性者が感染し感受性者の割合と感染者の割合にそれぞれ比例する。また、(2.1) 第二式と第三式に共通する  $\gamma I$  という項は、単位時間当たりに、感染者が治癒することにより、感染者が回復者に遷移する割合に対応している。

### 数値計算

微分方程式の数値解法について「Python による数値計算法の基礎」[2] を用いて、輪講会形式で学習を進めた。以下の式で与えられる常微分方程式の数値計算を考える。

$$\frac{dx(t)}{dt} = f(t, x) \quad (2.2)$$

まず、オイラー法について説明する。微分の定義から

$$\frac{dx(t)}{dt} \simeq \frac{x(t + \Delta t) - x(t)}{\Delta t} \quad (2.3)$$

より、これを式 (2.2) に代入すると、

$$\begin{aligned} \frac{x(t + \Delta t) - x(t)}{\Delta t} &\simeq f(t, x) \\ x(t + \Delta t) &\simeq x(t) + \Delta t f(t, x(t)) \end{aligned} \quad (2.4)$$

となる。ここで、 $t_n = n\Delta t (n = 0, 1, 2, \dots)$  とし、 $x_0 = x(0)$ 、 $x_n = x(n\Delta t) (= x(t))$  とすると、

$$x_{n+1} = x_n + \Delta t f(t_n, x_n) \quad (2.5)$$

となる。これにより、初期条件  $x_0 = x(0)$  を与えると、この漸化式 (2.5) を逐次的に計算していくことにより解を近似的に求めることができる。この方法をオイラー法という。オイラー法は、単純な式で与えられる一方で、解析解と数値解との誤差は  $O(\Delta t^2)$  であり非常に大きい。

次に、ルンゲクッタ法について説明する。4 次のルンゲクッタ法とは、刻み幅を  $\Delta t$  としたと

きに,

$$\left\{ \begin{array}{l} k_1 = f(t_n, x_n), \\ k_2 = f(t_n + \frac{\Delta t}{2}, x_n + \frac{k_1}{2}), \\ k_3 = f(t_n + \frac{\Delta t}{2}, x_n + \frac{k_2}{2}), \\ k_4 = f(t_n + \Delta t, x_n + k_3), \\ x_{n+1} = x_n + \frac{\Delta t}{6}(k_1 + 2k_2 + 2k_3 + k_4), \end{array} \right. \quad (2.6)$$

という漸化式によって解を近似的に求める方法である。解析解と数値解との誤差は  $O(\Delta t^4)$  であり、オイラー法よりも近似精度が高い。

次に、連立微分方程式系の数値計算について説明する。以下の微分方程式系について考える。

$$\left\{ \begin{array}{l} \frac{dx}{dt} = f(t, x, y), \\ \frac{dy}{dt} = g(t, x, y), \end{array} \right. \quad (2.7)$$

刻み幅  $\Delta t$  に対して、 $t_n = n\Delta t, x_n = x(t_n), y_n = y(t_n)$  ( $n = 1, 2, \dots$ ) とすると、オイラー法を用いて

$$\left\{ \begin{array}{l} x_{n+1} = x_n + \Delta t f(t_n, x_n, y_n), \\ y_{n+1} = y_n + \Delta t g(t_n, x_n, y_n), \end{array} \right. \quad (2.8)$$

と逐次的に計算することにより数値解を求めることができる。また、4次のルンゲクッタ法では、

$$\left\{ \begin{array}{l} k_1 = f(t_n, x_n, y_n), \\ l_1 = g(t_n, x_n, y_n), \\ k_2 = f(t_n + \frac{\Delta t}{2}, x_n + \frac{k_1}{2}, y_n + \frac{l_1}{2}), \\ l_2 = g(t_n + \frac{\Delta t}{2}, x_n + \frac{k_1}{2}, y_n + \frac{l_1}{2}), \\ k_3 = f(t_n + \frac{\Delta t}{2}, x_n + \frac{k_2}{2}, y_n + \frac{l_2}{2}), \\ l_3 = g(t_n + \frac{\Delta t}{2}, x_n + \frac{k_2}{2}, y_n + \frac{l_2}{2}), \\ k_4 = f(t_n + \Delta t, x_n + k_3, y_n + l_3), \\ l_4 = g(t_n + \Delta t, x_n + k_3, y_n + l_3), \\ x_{n+1} = x_n + \frac{\Delta t}{6}(k_1 + 2k_2 + 2k_3 + k_4), \\ y_{n+1} = y_n + \frac{\Delta t}{6}(l_1 + 2l_2 + 2l_3 + l_4), \end{array} \right. \quad (2.9)$$

と逐次的に計算することにより数値解を求めることができる。

そして、高階微分方程式について説明する。以下の二階微分方程式について考える。

$$\frac{d^2x}{dt^2} + a \frac{dx}{dt} = f(t, x) \quad (2.10)$$

これは、 $\frac{dx}{dt} = y$  と置くと、 $\frac{d^2x}{dt^2} = \frac{d}{dt} \frac{dx}{dt} = \frac{dy}{dt}$  より、

$$\left\{ \begin{array}{l} \frac{dx}{dt} = y, \\ \frac{dy}{dt} = f(t, x) - ay, \end{array} \right. \quad (2.11)$$

## Mathematical Modeling Project

と式 (2.7) のような微分方程式系に書き換えることができる。この連立微分方程式 (2.11) を上記の方法を用いて数値計算することにより、高階微分方程式の数値解を求めることができる。

### 数値計算例

バネの減衰振動を表す運動方程式

$$m \frac{d^2x}{dt^2} + c \frac{dx}{dt} = -kx \quad (2.12)$$

( $m$ : 質量,  $x$ : 平衡位置からの距離,  $c$ : 減衰係数,  $k$ : バネ定数)

の数値解をオイラー法, ルンゲクッタ法に用いて求める。二階微分方程式であるため, 式 (2.11) と同様の式変形を行う。すなわち,

$$\begin{cases} \frac{dx}{dt} = y, \\ \frac{dy}{dt} = -\frac{k}{m}x - \frac{c}{m}y, \end{cases} \quad (2.13)$$

という連立微分方程式の数値解を求める。以下に Python を用いたソースコード例を示す。なお, ソースコード中の `x_exact_solution(t_array)` という関数は, 解析解を返す関数である。

```
1 import numpy as np
2 import matplotlib.pyplot as plt
3
4 # 初期値の設定
5 x0 = 5.0
6 y0 = 0.0
7
8 # パラメータの設定
9 m = 1.0 # 質量
10 k = 5.0 # バネ定数
11 c = 0.1 # 摩擦係数
12
13 def dx_dt(t, x, y):
14     # 微分方程式の右辺
15     return y
16 def dy_dt(t, x, y):
17     # 微分方程式の右辺
18     return -(k/m)*x - (c/m)*y
19
20 # 数値計算用の定数
21 dt = 0.01 # 刻み幅
22 t0 = 0.0 # 初期時間
23 tf = 20.0 # 終了時間
24 t_array = np.arange(t0, tf, dt) # 時間の配列
25
26 # オイラー法用の配列
27 x_euler = np.zeros(len(t_array))
28 y_euler = np.zeros(len(t_array))
29 x_euler[0], y_euler[0] = x0, y0
30
```

```

31 # ルンゲクッタ法用の配列
32 x_rk4 = np.zeros(len(t_array))
33 y_rk4 = np.zeros(len(t_array))
34 x_rk4[0], y_rk4[0] = x0, y0
35
36 # 数値計算
37 for i in range(len(t_array)-1):
38     # オイラー法による更新
39     x_euler[i+1] = x_euler[i] + dt * dx_dt(t_array[i], x_euler[i], y_euler[i])
40     y_euler[i+1] = y_euler[i] + dt * dy_dt(t_array[i], x_euler[i], y_euler[i])
41
42     # ルンゲクッタ法 (4次) による更新
43     k1 = dt*dx_dt(t_array[i], x_rk4[i], y_rk4[i])
44     l1 = dt*dy_dt(t_array[i], x_rk4[i], y_rk4[i])
45     k2 = dt*dx_dt(t_array[i] + dt/2, x_rk4[i] + k1/2, y_rk4[i] + l1/2)
46     l2 = dt*dy_dt(t_array[i] + dt/2, x_rk4[i] + k1/2, y_rk4[i] + l1/2)
47     k3 = dt*dx_dt(t_array[i] + dt/2, x_rk4[i] + k2/2, y_rk4[i] + l2/2)
48     l3 = dt*dy_dt(t_array[i] + dt/2, x_rk4[i] + k2/2, y_rk4[i] + l2/2)
49     k4 = dt*dx_dt(t_array[i] + dt, x_rk4[i] + k3, y_rk4[i] + l3)
50     l4 = dt*dy_dt(t_array[i] + dt, x_rk4[i] + k3, y_rk4[i] + l3)
51     x_rk4[i+1] = x_rk4[i] + 1/6 * (k1 + 2*k2 + 2*k3 + k4)
52     y_rk4[i+1] = y_rk4[i] + 1/6 * (l1 + 2*l2 + 2*l3 + l4)
53
54 plt.plot(t_array, X_exact_solution(t_array), label='Exact Solution')
55 plt.plot(t_array, x_euler, label='Euler')
56 plt.plot(t_array, x_rk4, label='RK4')
57
58 plt.xlabel('t')
59 plt.ylabel('x(t)')
60 plt.legend()
61 plt.show()

```

この数値計算によって求めた数値解と解析解が以下の図 2.1 である。青い線が解析解であり、オレンジの線がオイラー法により求めた数値解であり、緑の線が4次のルンゲクッタ法により求めた数値解である。オイラー法により求めた数値解は、ステップ数が増えるにつれ、誤差が徐々に大きくなっているのがわかる。特に、 $t = 20$  においては、解析解がおおよそ  $x \simeq 2$  に対し、オイラー法による数値解は  $x \simeq 3$  となっている。一方で、4次のルンゲクッタ法により求めた数値解は、ほぼ解析解と重なっており、オイラー法ほどに誤差が広がっていないことがわかる。




図 2.1 解析解とオイラー法による数値解と 4 次のルンゲクッタ法による数値解の比較

### パラメータ推定

微分方程式の特殊解は、初期値と係数といったパラメータの値によって決まる。現実に行っている現象を微分方程式の数値計算によって予測するには、現象固有のパラメータを推定し、そのパラメータのもと数値計算をする必要がある。現象固有のパラメータを推定することを、パラメータ推定という。パラメータ推定の学習には、「数理モデルに対するパラメータ推定 [3]」を参考にした。以下の微分方程式

$$\frac{dx}{dt} = rx\left(1 - \frac{x}{K}\right) \tag{2.14}$$

を考える。これはロジスティック方程式と呼ばれる、生物集団の個体数変動を記述した数理モデルである。変数  $x = x(t)$  は時刻  $t$  における個体数であり、係数  $r, K$  はそれぞれ、個体数の増加率、環境収容力である。ここで、個体数の初期値  $x_0 = x(0)$  は時刻  $t = 0$  において環境内に存在する個体数によって決まるパラメータであり、増加率  $r$  はその集団の繁殖力によって決まるパラメータであり、環境収容力  $K$  は環境がどれだけの個体数を抱えるかによって決まるパラメータである。もし対象とする生物集団の個体数がロジスティック方程式 (2.14) で表されるように変化し、実際のパラメータ  $x_0, r, K$  がわかれば、これからの個体数の変化を数値計算によって予測することができる。

パラメータ推定の定式化について説明する。パラメータ  $\theta$  を  $\theta = (x_0, r, K)$  とし、パラメータ  $\theta$  を与えて得られる微分方程式の解を  $x(t; \theta)$  とする。いま、 $n$  個の時間ごとの個体数  $x$  に関する観測データ  $\mathcal{D} = \{x_D(t_1), x_D(t_2), \dots, x_D(t_n)\} = \{x_D(t_i)\}_{i=1, \dots, n}$  が得られたとする。そして、この観測データを「微分方程式の解にノイズが含まれたものである」と仮定する。すなわち、

$$x_D(t_i) = x(t_i; \theta^*) + \epsilon \tag{2.15}$$

であると仮定する。なお、 $\theta^* = (x_0^*, r^*, K^*)$  は現象固有の真のパラメータ、 $\epsilon$  はノイズ項である。

## Mathematical Modeling Project

そして、パラメータ  $\theta$  を与えて数値計算した結果得られた数値解を  $\hat{x}(t_i; \theta)$  とする。目的関数を

$$E(\theta) = \sum_{i=1}^N \|x_D(t_i) - \hat{x}(t_i; \theta)\|_2^2 + \lambda \|\theta\|_2^2 \quad (2.16)$$

と定める。なお  $\mathbf{x} \in \mathbb{R}^n$  に対して、 $\|\mathbf{x}\|_2$  は L2 ノルムといい、 $\|\mathbf{x}\|_2 = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2}$  で与えられる。また、 $\lambda \|\theta\|_2^2$  の項は、正則化項またはペナルティ項といい、観測誤差に対する過剰学習を防ぐ役割がある。この目的関数を最小化するような  $\theta$  を推定値  $\hat{\theta}$  を求めることでパラメータ推定を行う。式で表すと以下になる。

$$\hat{\theta} = \underset{\theta}{\operatorname{argmin}} E(\theta) \quad (2.17)$$

この最適化問題を解くことにより、真のパラメータに近い値を求めることができる。

実際のパラメータ推定の例を以下に示す。目的関数の最小化には、scipy ライブラリの minimize 関数を用いた。

```
1 import numpy as np
2 import pandas as pd
3 import matplotlib.pyplot as plt
4 from scipy.optimize import minimize
5
6 # ロジスティクス方程式
7 def dx_dt(x, r, k):
8     return r * x * (1 - x / k)
9
10 # 数値計算
11 def solve(params, dt, t0, tf):
12     x0, r, k = params
13     n = int((tf - t0) / dt)
14     t_arr = np.linspace(t0, tf, int((tf - t0) / dt) + 1)
15     x_arr = np.array([x0])
16     for i in range(len(t_arr)-1):
17         x_next = x_arr[-1] + dx_dt(x_arr[-1], r, k) * dt
18         x_arr = np.append(x_arr, x_next)
19     return t_arr, x_arr
20
21 # サンプルデータを生成する関数
22 def get_sample_data(params, t0, tf, sample_size=10, noise = 0.05):
23     x0_ans, r0_ans, k_ans = params
24     # 数値計算
25     dt = 0.01
26     n = int((tf - t0) / dt)
27     t_arr = np.linspace(t0, tf, n + 1)
28     x_ans_arr = np.array([x0_ans])
29     t_data = np.array([])
30     x_data = np.array([])
31     for i in range(n - 1):
32         # オイラー法
33         x_ans_next = x_ans_arr[-1] + dx_dt(x_ans_arr[-1], r0_ans, k_ans) * dt
```

```

34     x_ans_arr = np.append(x_ans_arr, x_ans_next)
35     # データ点を取得
36     if i % (n // sample_size) == 0:
37         t_data = np.append(t_data, t_arr[i])
38         x_data = np.append(x_data, x_ans_arr[i])
39     # ノイズを付加
40     x_data = x_data + np.random.normal(0, 0.2, sample_size)
41     return t_data, x_data
42
43 # コスト関数
44 def costfunc(params, t_data, x_data, lam):
45     dt = 0.005
46     t_arr, x_arr = solve(params, dt, t_data[0], t_data[-1]) # 数値計算
47     mask = np.any(np.abs(t_arr[:, None] - t_data) <= dt/2, axis=1)
48     x_est = x_arr[mask]
49     return np.sum((x_est - x_data)**2) + lam*sum([param**2 for param in params]) #
    ↪ コスト関数本体
50
51 # パラメータ推定
52 if __name__ == '__main__':
53     # 正解のパラメータ
54     x0_ans = 0.1
55     r_ans = 0.3
56     k_ans = 2.0
57     params_ans = [x0_ans, r_ans, k_ans]
58     # 各種変数
59     T0 = 0 # 初期時間
60     TF = 40 # 終了時間
61
62     # サンプルデータの取得
63     t_data, x_data = get_sample_data(params_ans,
64                                     T0,
65                                     TF,
66                                     sample_size=10, # サンプルサイズの指定
67                                     noise=0.1)
68
69     # パラメータの初期値 (x0, r, k)
70     params_init = [0.6, 0.6, 0.8]
71     # 正則化パラメータ
72     lam = 0.05
73     # 推定の実行
74     result = minimize(costfunc, params_init, args=(t_data, x_data, lam),
75                      ↪ method='BFGS')
76
77     # 推定されたパラメータ
78     params_est = result.x
79
80     # 結果の表示
81     print("Estimated Parameters")

```

```

81 print(f"  x0: {params_est[0]}")
82 print(f"  r: {params_est[1]}")
83 print(f"  k: {params_est[2]}")
84 print(f"Optimized cost: {result.fun}")
85
86 # 正解と推定結果の比較
87 t_init, x_init = solve(params_init, 0.01, t_data[0], t_data[-1])
88 t_ans, x_ans = solve(params_ans, 0.01, t_data[0], t_data[-1])
89 t_est, x_est = solve(params_est, 0.01, t_data[0], t_data[-1])
90
91 plt.scatter(t_data, x_data, label='data', color="orange")
92 plt.plot(t_ans, x_ans, label='ans', color="orange")
93 plt.plot(t_init, x_init, label='init')
94 plt.plot(t_est, x_est, label='est', color="green")
95 plt.xlabel('t')
96 plt.ylabel('x(t)')
97 plt.legend()
98 plt.show()

```

パラメータ推定した結果が以下の図 2.2 である。オレンジの線は正解の解であり、オレンジの点は得られたデータである。そして、青の線はパラメータ推定前の数値解であり、緑の線はパラメータ後の数値解である。正解のパラメータ  $\theta^* = (x_0^* = 0.1, r^* = 0.3, k^* = 2.0)$  であるのに対し、推定されたパラメータ  $\hat{\theta} = (\hat{x}_0 = 0.1183, \hat{r} = 0.3318, \hat{k} = 2.0070)$  となっており、おおよそ正解のパラメータに近い値になっている。




図 2.2 正解の解とパラメータ推定前の数値解とパラメータ後の数値解

## 2.1.2 機械学習

機械学習とは、データを分析する方法の1つで、データから、「機械」(コンピュータ)が自動で「学習」し、データの背景にあるルールやパターンを発見する方法である。その中でも教師あり学習という手法がある。これは、既知となった過去の入力データと出力データを機械学習アルゴリズムにあらかじめ与えることで、それらを「正解データ」として計算するものだ。

### 回帰分析

回帰分析は、入力と出力に対応する変数間の関係を回帰モデルとして定式化し、出力の予測を行う教師あり学習の一つである。例として、説明変数を  $X$ 、目的変数を  $Y$  とした式 (2.18) のような回帰モデルを考える。ここで  $\beta_0$  および  $\beta_1$  は学習するデータにあわせて決定されるパラメータである。

$$Y = \beta_0 + \beta_1 X \quad (2.18)$$

このようなモデルは、各項がパラメータに対して線形であることから、線形モデルと呼ばれる。この定義においては、説明変数  $X$  に関する多項式 (二次方程式) である式 (2.19) も線形モデルといえる。

$$Y = \beta_0 + \beta_1 X + \beta_2 X^2 \quad (2.19)$$

このモデルが学習に用いるデータ  $\{(x_i, y_i) | i = 0 \dots N-1\}$  によく当てはまっているとき、データに無いものを含めた任意の説明変数から、対応する目的変数の値を予測することができる。ここで、モデルのパラメータ  $\beta_0, \beta_1$  を適切に推定することが求められる。

線形モデルのパラメータは、最小二乗法と呼ばれる手法によって解くことができる。最小二乗法は、式 (2.20) で与えられるデータとモデルの予測値の差の二乗和を損失関数とし、この値が最も小さくなるようパラメータを決定する方法である。

$$MSE = \sum_{i=1}^n (Y_i - (\beta_0 + \beta_1 X_i))^2 \quad (2.20)$$

### 重回帰分析

重回帰分析は、複数の説明変数を用いた回帰分析である。例として、式 (2.18) に対して、 $X_2$  を説明変数として加え、次のような重回帰モデルの推定を行う。

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 \quad (2.21)$$

このモデルのパラメータ  $\beta_0, \beta_1, \beta_2$  を推定する場合も、式 (2.22) 同様に最小二乗法が適用可能である。

$$MSE = \sum_{i=1}^n (Y_i - (\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i}))^2 \quad (2.22)$$

### 決定係数

決定係数は、推定された回帰モデルに対する、データへの当てはまりの良さを評価する指標である。具体的にはデータ  $\{(x_i, y_i) | i = 0 \dots N - 1\}$  に対し、標本平均  $\bar{y}$  および予測値  $\hat{y}_i$  を用いて、式 (2.23) のように表される。

$$R^2 = 1 - \sum_{i=1}^N \frac{(y_i - \hat{y}_i)^2}{(y_i - \bar{y})^2} \quad (2.23)$$

決定係数の値は、モデルがデータに対してよく当てはまっているほど高く、最大値は 1 である。

### Gradient Boosting Decision Tree (GBDT) : 勾配ブースティング決定木

GBDT とは、勾配降下法 (Gradient) と Boosting(アンサンブル)、決定木 (Decision Tree) を組み合わせた手法である。

決定木：データをいくつかの条件に基づいて分割し、予測や分類を行うためのモデルである。分割は、各特徴量を用いてデータを複数の部分集合に分けることで行われ、これを繰り返すことで木構造を形成する。以下の図 2.3 に簡単な決定木の例を示す。

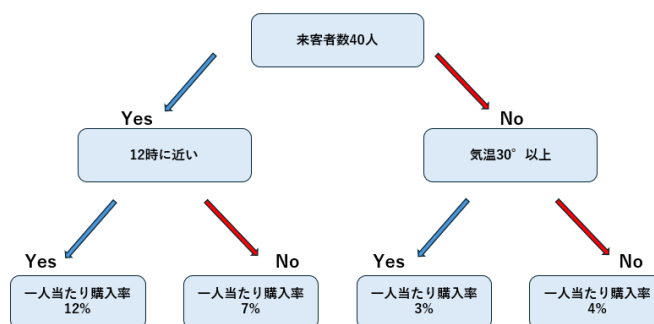


図 2.3 決定木の例

勾配降下法：誤差関数を最小化するために、パラメータを勾配が示す下り方向に繰り返し更新するアルゴリズムである。以下の図 2.4 に簡単な勾配降下の例を示す。




図 2.4 勾配降下の例

Boosting（アンサンブルの 1 種）：精度の低い学習器を複数組み合わせ、精度を高くする手法である。今回は、弱学習機として決定木が用いられる。

GBDT は、以上の手法を組み合わせることで精度を向上させる機械学習アルゴリズムである。

具体的には、損失関数  $L(y, \hat{y})$  を最小化するように学習を進める。各ステップ  $t$  において、残差に対する勾配  $\frac{\partial L}{\partial \hat{y}_t}$  を計算し、それを学習データとして新しい決定木を構築する。最終的なモデルは以下のように表される。

$$\hat{y} = \sum_{t=1}^T \eta f_t(x) \tag{2.24}$$

ここで、 $f_t(x)$  は  $t$  番目の決定木、 $\eta$  は学習率、 $T$  は総ラウンド数である。

### 交差検証

交差検証は、新しいデータへの対応力を確認するための方法であり、データを複数の部分に分割して学習と評価を繰り返す手法である。

代表的な手法として、 $k$ -分割交差検証 (k-fold cross-validation) が挙げられる。これはデータを  $k$  個の等しい部分に分割し、1 つの評価データとして使用し、それ以外を学習データとしてモデルを学習するプロセスを繰り返す。もしデータセットが時系列データである場合は評価データが学習データより未来のデータになるように分割する。以下の図 2.5 に時系列データを扱う交差検証の例を示す。

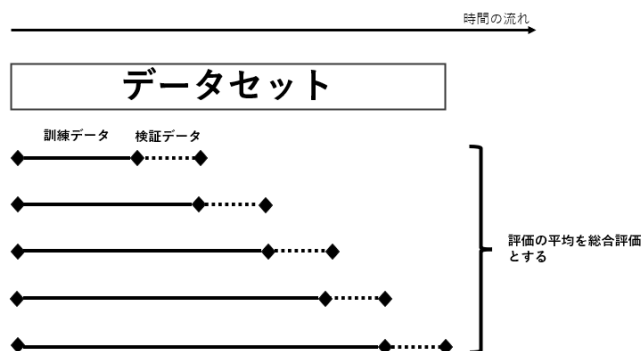


図 2.5 時系列データに対する交差検証の例

図 2.5 は、時系列での  $k$ -分割交差検証の例であり、今回は  $k = 5$  を想定する。手順は以下の通りである。

1. データセットを用意する。
2. 最初の 20% を訓練データ、次の 20% を検証データして評価する
3. 次に 40% を訓練データ、次の 20% を検証データして評価する
4. 次に 60% を訓練データ、次の 20% を検証データして評価する
5. このように試行し続け、最終的に得られた評価の平均値を計算する。

### ハイパーパラメータ

ハイパーパラメータとは、モデルが学習する過程で自動的に決定されるのではなく、あらかじめ人が設定する必要があるパラメータのことを指す。ハイパーパラメータの代表例としては、決定木の深さや学習率などが挙げられる。これらは、グリッドサーチやランダムサーチ、ベイズ最適化 (Bayesian Optimization) といった手法を利用して試行錯誤を行いながら最適な値を見つける。以下の図 2.6 に簡単なハイパーパラメータの例を示す。

```
# ハイパーパラメータ設定
params = {
    'booster': 'gbtree',
    'objective': 'reg:squarederror',
    'eval_metric': 'rmse',
    'subsample': 0.9,
    'reg_lambda': 1,
    'reg_alpha': 0.0,
    'min_child_weight': 0.5,
    'max_depth': 8,
    'learning_rate': 0.05,
    'colsample_bytree': 0.8,
    'gamma': 0.5
}
```

図 2.6 ハイパーパラメータの例

(※文責: 今壮平・多田瑛貴)

## 2.2 成果物の実装

本節では、成果物の公開・通信にあたって利用したサービスとその選定理由を述べる。利用するサービスは、AWS, FastAPI, OpenWeatherMap, JavaScript, その他フロントエンドで用いたサービスである。

本プロジェクトの成果物は Web アプリケーションの形式とし、フロントエンドとバックエンドが含まれている。

(※文責: 六本木是杜)

### 2.2.1 Amazon Web Services(AWS)

本プロジェクトの成果物である Web アプリケーションの公開にあたって、安定した運用のできる環境が必要となった。そこで、Amazon Web Services, Inc. によって提供されている Amazon Web Services(AWS) を利用した。AWS とは、全世界に分布する 34 地域で提供されている (本プロジェクトでの利用時点)、おもにクラウドコンピューティングに関わる包括的なサービスである。クラウドサービスの中でも AWS を利用したおもな理由は 3 つある。1 つ目は、独自に提供されている 1 年分の無料利用枠の存在である。2 つ目は、書籍や Web ページなど、さらには前年度のプロジェクトで AWS の利用経験がある TA といった、AWS の利用における蓄積された知見にアクセスしやすかったことである。3 つ目は、本学の講義である「システム管理方法論」での経験との関連性である。

## Mathematical Modeling Project

本プロジェクトの Web アプリケーションの公開では、とりわけ AWS のサービスのうち、EC2、VPC、S3、IAM を利用した。各サービスの選定理由となった特徴について以下に述べていく。

EC2 は、Amazon Linux 2 Kernel 5.10 (t2.micro) 環境のパブリックサーバー構築に利用可能なサービスである。環境面の特徴としては、数理モデルや機械学習モデルの Python コードの実行に十分な性能が挙げられる。一方、EC2 以外の AWS サービスとして利用可能な、サーバーレスがおもな特徴の Lambda も利用を検討していた。しかし、EC2 では既習の内容で実装できるため、より安定性があったこと、ログの取得や API の利用にその他のサービスを新規に学習・利用するコストが不要だったことから総合的に判断し、EC2 をサーバーサイドで利用するサービスとして選定した。

VPC は、EC2 でサーバーを構築するために必要となる、サブネットやインターネットゲートウェイ、ルートテーブルの設定に必須のサービスである。よって、EC2 の利用に伴い VPC も併せて利用した。

S3 は、Web サイトの公開もできるクラウドストレージとして利用可能なサービスである。これは、フロントエンドのコードを静的ホスティングし、適切なアクセス許可を設定することで Web ページとして公開できるものであった。管理面の特徴として、コードのバージョン管理がサービス内で可能であり、フロントエンドの内容を迅速に更新したり、過去のバージョンにロールバックしたりできることが挙げられる。

IAM は、AWS の管理ユーザーや、EC2・S3 などのサービスに権限を詳細に設定できるサービスである。とりわけ、AWS で利用中のサービスに対する管理ユーザを複数用意できるため、実行可能な権限を目的ごとに詳細に設定でき、管理ユーザなどを追加することもできるようなスケラビリティに優れていた。そのため、必要に応じて Web アプリケーションの管理が引き継ぎやすいといった特徴が挙げられる。

(※文責: 新田龍太郎)

### 2.2.2 FastAPI

今回のシステムのバックエンド側の処理には FastAPI を用いた。FastAPI は Python で高性能な Web API を構築するためのフレームワークであり、個人プロジェクトから企業の大規模システム開発まで幅広く利用されている。

この API を採用した理由は主に 3 つある。1 つ目は、数理モデルや機械学習との相性がよい点である。今回のシステムでは、数理モデルや機械学習のコードを主に Python で記述しており、FastAPI を使用することで一貫した環境で開発を進めやすい。2 つ目は、学習コストが低い点である。Python は本学の「データサイエンス入門」や「データサイエンス演習」などの講義で学ぶ機会が多いため、メンバー間での共有や議論を行いやすい。3 つ目は、開発効率と拡張性の高さである。FastAPI はコードの構造がシンプルで、少ないコード量で機能を実装することができるため、機能の追加や仕様変更が容易に行える。また、デフォルトで API ドキュメントを自動生成し、レスポンスの挙動を簡単に確認できるため、効率的な開発ができると考えた。

(※文責: 佐野大翔)

### 2.2.3 OpenWeatherMap

OpenWeatherMap は世界中の気象データをリアルタイムで提供するサービスであり、現在の天気、短期および長期予報、過去の気象データなど多岐にわたる情報を取得可能である。

今回のシステムでは函館市の気象情報を取得するためにこの API を採用した。理由は主に 3 つある。1 つ目は、高速なデータ取得が可能な点である。店舗内でアプリケーションを運用する際、従業員の業務効率を考慮するとスムーズなデータ取得は不可欠となるためである。2 つ目は、データ形式が JSON や HTML に対応しており、扱いやすいためである。今回のシステムでは Python を用いてバックエンド処理を行ったが、この柔軟性が開発効率を向上させると考えた。3 つ目は、使用が簡単な点である。OpenWeatherMap は公式ドキュメントが充実しており、さらに Web フレームワークやライブラリとの親和性が高いため、学習コストが低いと考えた。

(※文責: 佐野大翔)

### 2.2.4 JavaScript

JavaScript はブラウザ上で動作するプログラミング言語である。Web ページに動きをつけ動的にしたりできる他、API との通信も可能である。本アプリケーションで JavaScript を選定した理由は 3 つ存在する。

1 つ目に Web アプリケーションを動的にする必要があるためである。3.2.2 で説明した本 Web アプリケーションの機能はどれもページを動的にしなければ実装が難しい。したがって HTML と CSS で作成した静的なページを動的にするために JavaScript を選定した。

2 つ目に WebAPI との通信ができ、かつ画面に反映させるために最適な言語であるからだ。JavaScript では WebAPI との通信を効率化できる。またそのためのライブラリやフレームワークも充実している。本アプリケーションでは Axios というライブラリを用いて WebAPI との通信を効率化している。また JavaScript では HTML で作成した要素や CSS のスタイルを JavaScript 上で動的に変更できる DOM 操作という技術があるため、WebAPI で取得した情報を簡単に画面に反映させることができる。

3 つ目にブラウザ上で動作するプログラミング言語であるからだ。一般的なプログラミング言語は開発環境を作成しないといけない。しかし JavaScript はブラウザ上で動作するので、本アプリケーションの仕様デバイスにブラウザをインストールするだけで本 Web アプリケーションを使用することができる。本プロジェクトにおいて、3.2.3 でも述べたが、本アプリケーションを使用するデバイスに縦置きタブレットを選定した。使用するタブレットにブラウザをインストールして、本 Web アプリケーションの URL にアクセスすれば難しい設定をすることなくすぐに利用できる。

以上 3 つの理由により、本 Web アプリケーションの開発において JavaScript を選定した。

(※文責: 石井健太)

## 2.2.5 その他のフロントエンド開発に使用したツール

Web アプリケーションの基本的な文書構造の設計と装飾を行うために、HTML と CSS を使用した。HTML は Web ページの文書構造を記述するのに使用されるマークアップ言語である。Web アプリケーションにおいて、文書構造を記述するのは必須であり、マークアップ言語の中でもリソースが多い HTML を選択した。CSS は HTML で記述した文書構造に対して、スタイルを記述しコンテンツの見た目を記述することができるプログラミング言語である。HTML だけでは文書構造のみしか記述できず、見た目や使用体験が悪い Web アプリケーションになってしまう。そうならないために HTML と併用して画面のスタイルを記述することができる CSS を選定した。

リセット CSS として Eric A. Meyer の CSS Reset を用いた。リセット CSS とは、ブラウザに標準で搭載されているスタイルを打ち消す CSS で、ベースとなるスタイルを統一することができる。Reset CSS を選定した理由は、画面の余白から各タグの初期文字サイズまで、すべての初期情報をリセットするからである。初期条件をリセットすることによって、1 から自分でスタイルを決めることが可能なため、Reset CSS を選定した。

開発した Web アプリケーションの画面を確認するために、Google Chrome に標準搭載されている Chrome DevTools を用いた。その理由として、作成した Web アプリケーションの HTML や CSS の編集、JavaScript のデバッグ、WebAPI との通信を行うことができるためである。また、Google Chrome に関する参考文献が他のブラウザと比較して多かったためである。

テキストエディタについて、Visual Studio Code を使用した。選定理由として、Atom やサクラエディタなどの他のテキストエディタと比べて有益な拡張機能が多く存在し、開発の効率を上げるために適していると判断したためである。

(※文責: 石井健太)

## 2.3 成果物の検証

本節では、成果物の結果を検証する方法や、その方法を選んだ理由について述べる。用いる手法は、「差分の差分法」である。また、手法を決定する際に仮説検定も検討したので、その内容についても述べる。

(※文責: 六本木是杜)

### 2.3.1 仮説検定

作成した数理モデルを評価する手法として、仮説検定を用いた。仮説検定は、統計学においてデータを基に特定の仮説が正しいかどうかを判断する方法である。一般的に、帰無仮説と対立仮説の2つを立てて、データがどちらの仮説に合致しているかを評価する。帰無仮説は「何も起こっていない」状態や「効果がない」という仮定を表し、対立仮説は「何かが起こっている」状態や「効果がある」という仮定を示す。

仮説検定の流れは、まず帰無仮説を設定し、実際のデータを基に統計量を計算する。その結果が帰無仮説の下でどれほど起こりにくいかを P 値で評価する。P 値とは、帰無仮説が真であると

仮定した場合に、観測されたデータと同じかそれ以上に極端な結果が得られる確率を示す指標である。つまり、P 値は観測データが帰無仮説の下でどれほど矛盾しているかを示すものであり、P 値が小さいほど帰無仮説が真である可能性が低いことを意味する。P 値が事前に設定した有意水準（通常は 0.05）以下であれば、帰無仮説を棄却し、対立仮説を支持する。逆に、P 値が有意水準を超える場合は、帰無仮説を棄却できず、対立仮説を支持する根拠がないと判断する。

この方法により、仮説検定はデータを基に仮説の妥当性を定量的に評価するため、モデルの妥当性検証に重要な役割を果たす。しかし、検証方法とうまく合わない点があり、仮説検定による適切な評価が困難だと考えた。そこで、別の手法を用いて数理モデルの評価を行った。

(※文責: 六本木是杜)

### 2.3.2 差分の差分法 (DID: Difference In Difference)

次に数理モデルを評価する手法として、差分の差分法を用いた。差分の差分法 (DID) は、介入や政策の効果を評価するための統計的手法である。特に医療分野において広く利用されており、新薬や治療法の導入が患者に与える影響を評価するために使用される。

差分の差分法において、介入を行ったグループを「介入群」、行わなかったグループを「コントロール群」と呼ぶ。介入群とコントロール群の前後の変化量を比較することで因果関係を推定する方法である。具体的には、二つの群について介入前後の変化量を求めることによって、介入の効果が他の要因によるものではないかを検証することができる。この方法は、介入群とコントロール群が同じような傾向を持つと仮定し、それに基づいて両群の変化量の差を求めることで、介入による純粋な効果を推定するのが特徴である。この手法を学習する際に、「差分の差分法 (difference in differences) —介入前後のデータから効果を検証—」[4] を参考にした。

この手法は検証方法とも合っており、適切な分析結果が得られると考え、本プロジェクトではこの手法を採用した。

(※文責: 六本木是杜)

## 第3章 成果物の開発

本章では、システムの構成要素となるアプリケーションおよびその連携方法、そして運用基盤について説明する。

### 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 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。

また本 Web アプリケーションは、協力店舗内でデバイスを設定するための空きスペースの都合から、タブレット端末を用いるのが望ましいと判断した。したがって、タブレット端末での動作を前提として開発を進めた。

(※文責: 石井健太)

### 3.2 システム構成

仕込み支援アプリケーションの構成について、フロントエンドとバックエンドに大別して述べていく。フロントエンドはユーザーによる操作が可能な領域であり、Web ページの構成要素を定義する HTML・CSS と、ユーザーによる Web ページとのインタラクションを可能とする JavaScript を実装する領域である。バックエンドは、ユーザーとのインタラクションにおいてフロントエンド内で完結しない、プログラムの実行環境や通信制御を設計・実装する領域である。

本アプリケーションは、ユーザーである従業員と、従業員が利用するタブレット (iPad)、タブレット上の Web ブラウザーアプリケーションでアクセス可能なフロントエンド、そしてフロントエンドで入力・送信される「現在のファミチキの陳列数」(API リクエスト) を受け取りモデルに渡すバックエンド、そしてモデルによって構成される。API リクエストで取得した陳列数をもとに、モデルによって算出された最適仕込み数・仕込みタイミングは、モデルからバックエンド、フロントエンドへと戻るように返却され、従業員に最適仕込み数・仕込みタイミングを Web ページ上に表示する。

(※文責: 新田龍太郎)

### 3.2.1 サーバー運用基盤 (AWS) の構成

図 3.1 は、Web アプリケーションのサーバーサイドを構成する AWS の各種サービスの関係を表すアーキテクチャ図である。図の作成には、AWS アーキテクチャアイコン [5] を用いた。

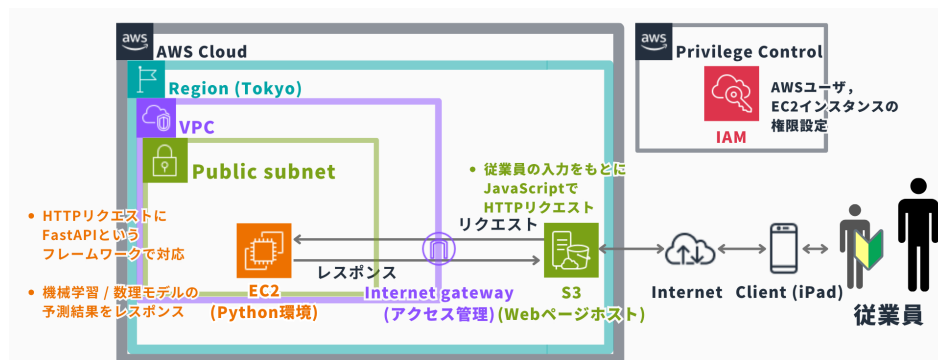


図 3.1 AWS アーキテクチャ図 (構成図)

EC2 サーバー上には、各種モデルと、API の呼び出し/応答に必要な Python 3.10.12 環境を EC2 上に構築した。加えて、各種実行に必要な FastAPI などのパッケージをインストールした。さらに、本アプリケーションに必要な設定として、時刻を参照するため、提供する店舗先と同じ JST に設定し、本アプリケーションに必要なコード実行の永続化には systemd を用いた。S3 ストレージ上には、HTML, CSS, JavaScript でフロントエンドを構築した。公開に当たっては、通知用の音源リソースファイルと併せて適切なアクセス許可を設定した S3 バケットで静的ホスティングした。加えて、CORS や API リクエストの実行権限を設定した。Internet gateway では、本アプリケーションの実用に必要な、Web ページへのアクセス権限を限定するように設定した。これにより、予期せぬアクセスやトラブルを未然に防止した。IAM では、サーバーの安定運用のために管理ユーザーや EC2 の権限を設定した。詳細は 2.2.1 にて述べてある。

(※文責: 新田龍太郎)

### 3.2.2 バックエンドの処理

本アプリケーションのバックエンドに関する処理を述べる。まず、ファミチキの陳列数を POST リクエストで受け取る際のデータ構造を定義した。CORS ミドルウェアを追加し、特定の S3 バケットウェブサイトからのアクセスを許可し、必要な HTTP メソッドとヘッダーを受け入れるように設定した。天気情報を取得するために、OpenWeatherMap API のキーと都市名 (函館) を指定し、URL を生成した。その API から気温や湿度を取得し、現在の日付が土日祝であるかを jpholiday ライブラリで判定した。

これらのデータを入力として予測モデルへ渡し、その結果を JSON 形式でのレスポンスとしてフロント側に返した。HTTP リクエストごとにエラーハンドリングを行うミドルウェアの設定を行い、エラーが発生した場合に、本プロジェクトで利用した Discord で適切なエラーレスポンスを通知する処理を実装した。

(※文責: 佐野大翔)

### 3.3 モデル構成

本節より、開発した仕込み数予測モデルの仕様について説明する。ここでは、それぞれのモデルの全体構成について説明する。

本アプリケーションでは、最適な仕込み数を、「商品と顧客と従業員の相互作用を予測し、そこから売上にとっても従業員にとっても最適な仕込み数を求める」という問題設定のもと導出した。ベテラン従業員の仕込みから着想を得ている。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、ベテラン従業員は次の思考のステップによって、最適な仕込み数を考えていると考えた。

- (1) 来客数を推測する。
- (2) いつ・何個、商品が売れるのかという見通しを立てる。
- (3) すぐ売り切れず、売れ残りも出ない仕込み数を求める。

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。

以降、それぞれのモデルで用いたデータとその収集方法について述べ、その後(1)に対応する来客数予測モデル、そして(2)(3)に対応する仕込み数の予測モデルについて述べる。ここで仕込み数の予測モデルについては、実地検証を行い比較を行った2つのアプローチとして、数理モデルに基づく手法と機械学習に基づく手法の2つを説明する。

(※文責: 吉野颯真)

### 3.4 データの収集

本アプリケーションの開発においては、コンビニでの購買行動に影響を与える様々な要因について考慮するため、過去のデータを収集し利用する必要がある。その主な用途としては、来客数予測や機械学習による売上予測の教師データや、微分方程式モデルのパラメータ推定、およびシステム全体の性能評価が挙げられる。

そこで、本アプリケーションの開発に必要なデータとして、店舗に関するデータ・過去の気象データ・祝日データを収集した。それぞれのデータは2023年6月23日0時から2024年8月31日23時までを収集対象の期間とし、1時間毎のデータを取得している。

#### 3.4.1 店舗に関するデータ

実地検証の対象となる店舗の協力を受け、店舗で収集されているデータを取得した。実際に取得した項目は、一時間ごとの来客数と、ファミチキの売上である。

### 3.4.2 過去の気象データ

データ収集対象の期間におけるの気象データを、気象庁「過去の気象データ・ダウンロード」から取得した。実際に取得した気象データの項目は、以下のとおりである。

- 気温
- 降水量（前 1 時間）
- 相対湿度
- 風向・風速
- 降雪の深さ（前 1 時間）

取得の対象となる観測地点は、実地検証の対象となる店舗から最も近い函館地方気象台として  
いる。

### 3.4.3 祝日データ

取得の対象となる期間の各日付の祝日の有無について、内閣府「昭和 30 年（1955 年）から令和 7 年（2025 年）国民の祝日」から取得した祝日の日付をもとにデータベースを作成した。

（※文責: 多田瑛貴）

## 3.5 来客数予測

本節では、来客数予測における具体的な重回帰分析の方針について説明する。

天気や日付といった環境要因は、コンビニ客の購買行動に重要な影響を与えると考えられる。一方で、気温や湿度、祝日の有無など、考慮すべき指標は多く存在する。それらを微分方程式上で直接扱う場合、モデルが複雑化し、正確な予測やパラメータ推定が困難となる可能性がある。また環境要因は、店舗を利用する客の数に大きな影響を与えるものの、既に店内にいる客や従業員、商品の状態の相互作用にはあまり影響を与えないと考えられる。よって、環境要因は来客数のみに関わっていると仮定できる。

そこで本プロジェクトでは、最初の段階として、環境要因を説明変数とした重回帰分析を行い、来客数を予測することとした。加えて、その予測結果を、様々な環境要因の影響を集約した変数として他のモデルに渡すこととした。これにより、来客数のみに絞って性能検証や予測結果のフィードバックを行うことができる。また、後に続く微分方程式や最適化問題を単純化し、正確な予測をもたらすことが期待できる。

（※文責: 多田瑛貴）

### 3.5.1 実装の仕様

来客数の予測モデルとして、一時間ごとに独立した二次の線形重回帰モデルを作成している。また、各時間のモデルは、過去の同じ時間の来客数データを学習元として作成する。例えば、午前

## Mathematical Modeling Project

9時を対象とした重回帰モデルは、過去の午前9時の来客数データを教師データとし学習を行う。

これらのモデルを用いて任意時刻の来客数を予測するときは、時間的に隣接する2つのモデルを参照し、それぞれの予測結果を線形補間したものを結果として出力する。例えば、午前9時40分の来客数を予測する場合は、午前9時と午前10時のモデルによる予測結果に、それぞれ1/3および2/3を重み付けしたものを出力する。

時間の値自体を説明変数としなかった理由は、来客数推移が大きく増減する朝の時間帯や、長期的に停滞する深夜帯を考慮する場合にモデルが非線形となり、定式化が困難となるからである。また、利用時間が数分間に収まり、かつ客同士での交流の少ないコンビニの特性から、各時間の来客数はその前後の時間の状態に関係しないと仮定でき、予測モデルを時間ごとに独立して作成・適用できるとしたためである。

二次の重回帰モデルを用いた理由は、多くの環境要因における来客数との関係は、単調に増加(減少)、あるいは一度のピークを経た増減で記述可能と考えたためである。例えば天気は、外出に適した気温や湿度を来客数のピークとし、そこから離れるほど減少していくと予想できる。また、より高次のモデルを用いる場合、既知のデータへの過度に適合し、未知の入力に対する予測を柔軟に行えなくなる(一般的に「過学習」と呼ばれる)リスクが考えられる。このことから、各環境要因と来客数の関係を十分に表現できる二次の重回帰モデルを用いている。

(※文責: 多田瑛貴)

### 3.5.2 説明変数

説明変数として、以下の指標を用いることとした。

- 気温 [°C]
- 相対湿度 [%]
- 日曜・祝日であるか否か (0 または 1)

これらは、取得可能なデータのうち、来客数に影響すると考えられるものを選定したものである。選定にあたっては、それぞれの指標について、来客数との関係を折れ線グラフとして図示した上で、関係が顕著に見られるかを観察し判断している。例えば、「日曜・祝日であるか否か」が説明変数に用いられている理由は、平日および土曜日の来客数推移と、日曜日・祝日の来客数推移を観察し、この2つの推移の傾向に大きな隔たりがあることが確認されたためである。

選定にあたり、特に降水量は影響の大きい指標であることが期待された。しかしながら、データの観察により、降水量は来客数には直接的に顕著な影響が無いことが確認された。そのため、降水の影響は湿度のみ考慮することとした。

### 3.5.3 性能評価と課題

本プロジェクトでは、過去のデータを用いて重回帰分析の性能を評価した。具体的には、環境要因および来客数のデータを取得可能な期間を対象に、環境要因を入力とした来客数予測を行い、実際の来客数推移にどれだけ適合しているかを決定係数を用いて評価した。

### データとモデルの出力の比較

決定係数によるモデルの評価に先立ち、過去のいくつかの日付のデータを入力として一日の来客数予測を行い、実際の来客数と比較した。これにより、決定係数の値とモデルの妥当性の関係を視覚的に判断することができる。この調査から、モデルの性能が妥当であることを判断する基準となる決定係数の範囲を、0.5 以上とした。

2024 年 4 月 10 日、2024 年 12 月 31 日の決定係数をそれぞれ図 3.2, 図 3.3 に示す。これらはそれぞれ、特に高い性能が出ている日、および特に性能の低い日である。ここで、各図の縦軸は来客数に対応し、横軸は時刻を示す。

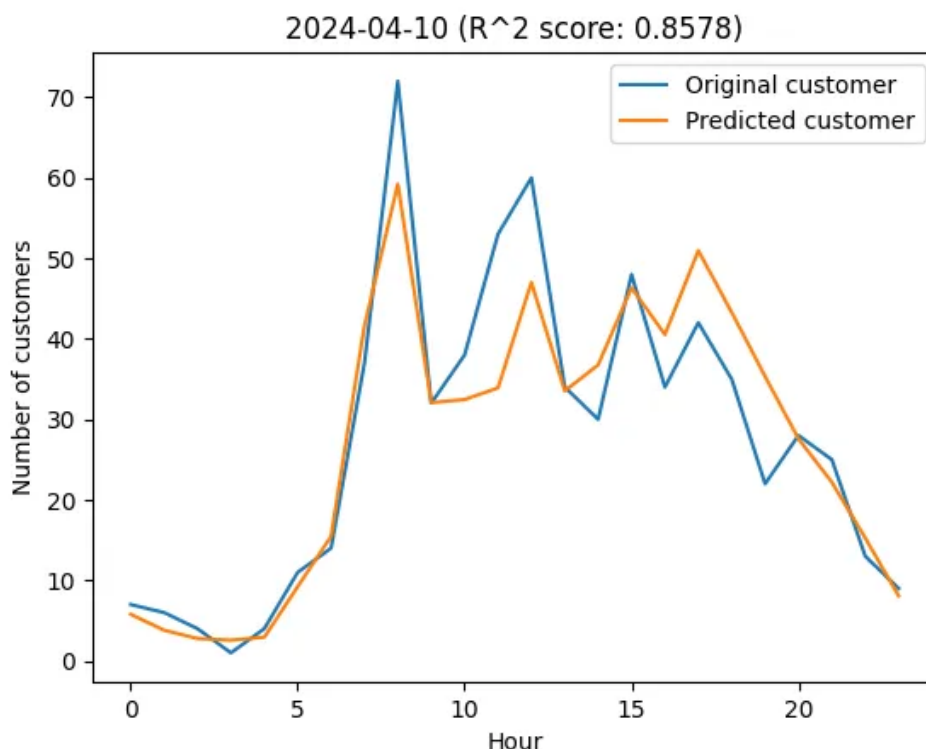


図 3.2 2024 年 4 月 10 日の環境要因を入力とした来客数予測と実際のデータの比較。決定係数  $\approx 0.8578$

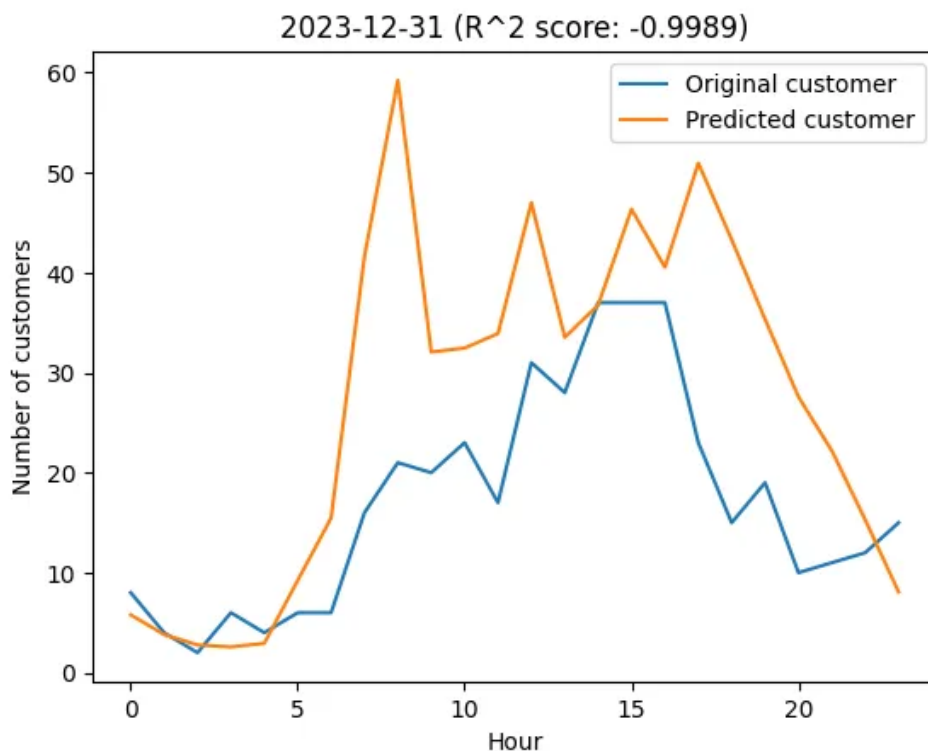


図 3.3 2023 年 12 月 31 日の環境要因を入力とした来客数予測と実際のデータの比較. 決定係数  $\approx -0.9989$

### 日ごとの決定係数の計測

2023 年 7 月, 2023 年 10 月, 2024 年 1 月の各日における決定係数をそれぞれ図 3.4, 図 3.5, 図 3.6 に示す. これらはそれぞれ, 特に高い性能が出ている月, 実地検証の対象となる月, そして特に性能の低い月である. ここで, 各図の縦軸はそれぞれの月の週に対応し, 横軸は曜日を示す. 着色された領域はそれぞれの月の縦軸と横軸の値に対応する日の決定係数を示す. なお, 存在しない日, あるいは対象の月に該当しない日の領域は着色されていない.

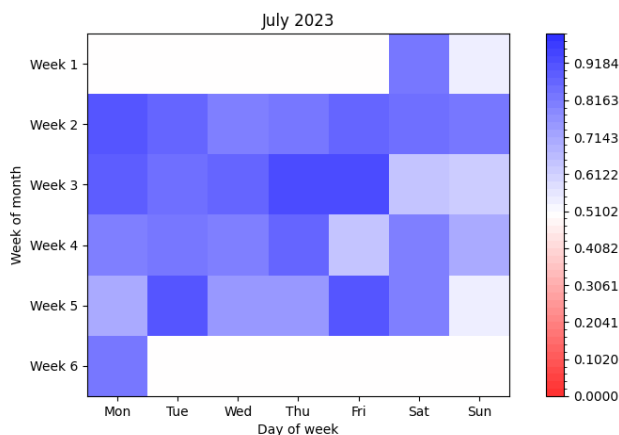


図 3.4 2023 年 7 月の各日における決定係数




図 3.5 2023 年 10 月の各日における決定係数

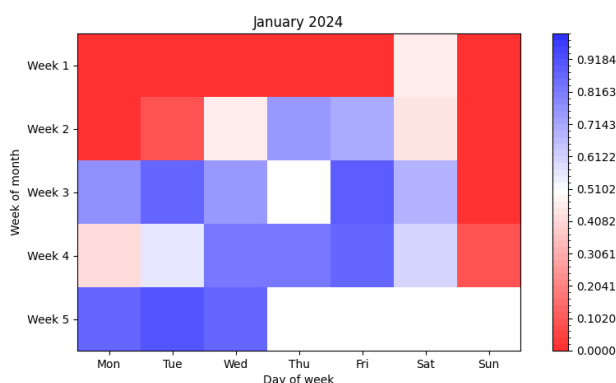


図 3.6 2024 年 1 月の各日における決定係数

(※文責: 多田瑛貴)

課題

以上の結果より、来客数予測の妥当性について評価を行った。

図 3.4 から 3.6 の結果から、多くのパターンで妥当な精度の出力が可能であるといえる。特に、平日や土曜日については、一年を通して決定係数が 0.5 を超えている日が多くを占めている。

一方で図 3.3 および図 3.6 から、年末年始や冬の休日は大きく外れていることがわかる。このことから、考慮できていない環境要因も存在すると考えられる。特に以下が考察できる。

- 積雪
- 特殊な閑散期 (年末年始・お盆)

今後、これらの要因を考慮し来客数予測を見直す必要がある。その際、この予測結果と実際のデータとの差分を分析することで、特殊な閑散期の影響を定量的に計測し、新たに重み付けを行うことも検討できる。

(※文責: 多田瑛貴)

### 3.6 数理モデル

本節では、3.3 節で述べた、「(2) いつ・何個、商品が売れるのかという見通しを立てる。」に対応する購買・仕込みモデルと、「(3) すぐ売り切れず、売れ残りも出ない仕込み数を求める。」に対応する最適化手法について述べる。

(※文責: 吉野颯真)

#### 3.6.1 数理モデル

##### 購買-仕込みモデル

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。

$$\begin{cases} \frac{dx}{dt} = -\omega DCf(x) + \beta \max(m - m_p, 0) \\ \frac{dD}{dt} = \gamma_x x(1 - D) - \gamma_D D \\ \frac{dm}{dt} = \alpha_C C(C_{\max} - C)(x_{\max} - x) - \alpha_x x \\ f(x) = \begin{cases} 1 & x > 0 \\ 0 & x \leq 0 \end{cases} \end{cases} \quad (3.1)$$

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

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。また、 $\max(m - m_p, 0)$  とは、 $\max$  関数であり

$$\max(m - m_p, 0) = \begin{cases} m - m_p & m - m_p \geq 0 \\ 0 & m - m_p < 0 \end{cases} \quad (3.2)$$

で与えられる。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度が大きくなり、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.




図 3.7 相互作用の図 (赤い矢印は増加する効果, 青い矢印は減少する効果に対応)

### 解の性質

$0 \leq x$  における微分方程式 (3.1) の平衡点  $(x^*, D^*, m^*)$  の安定性を調べる.

微分方程式 (3.1) の右辺をそれぞれ  $F, G, H$  という関数として置く.

$$\begin{cases} \frac{dx}{dt} = -\omega DCf(x) + \beta \max(m - m_p, 0) & =: F(x, D, m) \\ \frac{dD}{dt} = \gamma_x x(1 - D) - \gamma_D D & =: G(x, D, m) \\ \frac{dm}{dt} = \alpha_C C(C_{\max} - C)(x_{\max} - x) - \alpha_x x & =: H(x, D, m) \end{cases} \quad (3.3)$$

このとき, この微分方程式の平衡点まわりの安定性はヤコビ行列

$$J(x^*, D^*, m^*) = \begin{pmatrix} F_x(x^*, D^*, m^*) & F_D(x^*, D^*, m^*) & F_m(x^*, D^*, m^*) \\ G_x(x^*, D^*, m^*) & G_D(x^*, D^*, m^*) & G_m(x^*, D^*, m^*) \\ H_x(x^*, D^*, m^*) & H_D(x^*, D^*, m^*) & H_m(x^*, D^*, m^*) \end{pmatrix} \quad (3.4)$$

の固有値によって判別できる. なお  $F_x$  は  $x$  による  $F$  の偏微分を表す. もし, このヤコビ行列の固有値がすべて負であれば平衡点  $(x^*, D^*, m^*)$  は漸近安定となり, 固有値が一つでも正であれば平衡点  $(x^*, D^*, m^*)$  は不安定となる.

$$J(x^*, D^*, m^*) = \begin{pmatrix} 0 & -\omega C & \beta \frac{\partial}{\partial m} \max(m - m_p, 0) \\ \gamma_x(1 - D^*) & -\gamma_x x^* - \gamma_D & 0 \\ -\alpha_C C(C_{\max} - C) - \alpha_x & 0 & 0 \end{pmatrix} \quad (3.5)$$

ここで,  $a_{12} = -\omega C, a_{13} = \beta \frac{\partial}{\partial m} \max(m - m_p, 0), a_{21} = \gamma_x(1 - D^*), a_{22} = -\gamma_x x^* - \gamma_D, a_{31} = -\alpha_C C(C_{\max} - C) - \alpha_x$  とおくと,  $a_{12} < 0, a_{22} < 0, a_{31} < 0, a_{13} \geq 0, a_{21} > 0$  である. ここで, ヤコビ行列  $J(x^*, D^*, m^*)$  の固有値は,

$$\lambda^3 - a_{22}\lambda^2 + (-a_{12}a_{21} - a_{13}a_{31})\lambda + a_{13}a_{31}a_{22} \quad (3.6)$$

という方程式を満たす。ここで、 $u = -a_{22} > 0, v = -a_{12}a_{21} > 0, w = -a_{13}a_{31} > 0$  とおき、

$$\lambda^3 + u\lambda^2 + (v+w)\lambda + uw \quad (3.7)$$

とする。ここで、この方程式を満たす固有値の実部すべて負であることを調べるため、フルビッツの安定判別法 [6] を用いる。今回の場合において、 $\lambda^i (i = 0, 1, 2, 3)$  の各係数がすべて正であるため、この安定判別法を用いることができる。フルビッツ行列は、

$$H = \begin{pmatrix} u & uw & 0 \\ 1 & v+w & 0 \\ 0 & u & uw \end{pmatrix} \quad (3.8)$$

であるから、

$$\begin{aligned} H_1 &= \det(u) = u \\ H_2 &= \det \begin{pmatrix} u & uw \\ 1 & v+w \end{pmatrix} = uv \\ H_3 &= \det \begin{pmatrix} u & uw & 0 \\ 1 & v+w & 0 \\ 0 & u & uw \end{pmatrix} = u^2vw \end{aligned} \quad (3.9)$$

より、 $u > 0, uv > 0, u^2vw > 0$  であれば、方程式 (3.7) の解  $\lambda$  の固有値はすべて負になる。いま、 $u, v, w > 0$  より、平衡点  $(x^*, D^*, m^*)$  は漸近安定である。

### 実際に行った数値計算

実地検証において、陳列数  $x$  と仕込み意欲  $m$  に関して、負の値を取り得ないように、条件分けをして数値計算を行った。これは、実地検証をする段階において、モデルと数値計算に対する考察が不十分だったためである。

$$\begin{cases} x_{i+1} = \begin{cases} x_i + \Delta t F(x_i, D_i, m_i) & x_i + \Delta t F(x_i, D_i, m_i) > 0 \\ 0 & \Delta t F(x_i, D_i, m_i) \leq 0 \end{cases} \\ D_{i+1} = D_i + \Delta t G(x_i, D_i, m_i) \\ m_{i+1} = m_i + \Delta t H(x_i, D_i, m_i) \end{cases} \quad (3.10)$$

### パラメータ推定

得られたデータを元にパラメータ推定を行った。店舗に関するデータのうち一時間ごとのファミチキの売上を用いた。しかし、微分方程式 (3.1) によって求まるのは、陳列数  $x$ 、購買意欲  $D$ 、仕込み意欲  $m$  であり、直接的に売上数を求めることはできない。そのため、式 (3.10) による数値計算で求めた陳列数の減少幅から一時間ごとの売上数を近似的に求めた。具体的には、 $t = 0, 1, 2, \dots$  を一時間に対応していると考え、 $t_i$  時 ( $t_i = 0, 1, 2, \dots (i = 0, 1, \dots)$ ) における売上数を  $\hat{s}(t_i) = x(t_i) - x(t_{i+1})$  とした。また、 $t_i$  時から  $t_{i+1}$  時の間に仕込み意欲  $m$  が閾値  $m_p$  を超え、仕込みが開始され、陳列数が増えている場合においては、仕込み開始時に対応する極小値を  $t_{\min}$ 、仕込み終了時に対応する極大値を  $t_{\max}$  とし、 $t_i$  時における売上数  $\hat{s}(t_i) = x(t_i) - x(t_{\min}) + x(t_{\max}) - x(t_{i+1})$  とした。パラメータ推定をするにあたって、推定するパラメータの次元を削減するため、いくつかのパラメータは以下のように固定した。

$$C_{\max} = 60.0, x_{\max} = 15.6, m_p = 1.0, \beta = 60.0, x(0) = 10.0, D(0) = 0.2, m(0) = 0.0 \quad (3.11)$$

## Mathematical Modeling Project

また、初期時間  $t = 0$  は、午前 7 時とした。これは、従業員へのヒアリングの結果から午前 7 時には通常 10 個仕込んでいるとのことだったため、陳列数の初期値  $x(0) = 10.0$  とすることで、実際に近い状況を再現できると考えたためである。また、来客数の最大値  $C_{\max}$  は、来客数のピークが 60 人であることが多かったためである。

以上を踏まえて、 $\theta = (\omega, \gamma_x, \gamma_D, \alpha_C, \alpha_x)$  というパラメータを推定した。

一時間ごとのファミチキの売上データを  $s(t_i)$  とし、目的関数を式 (2.16) のように、

$$E(\theta) = \sum_{i=0}^n \|s(t_i) - \hat{s}(t_i)\|_2^2 + \lambda \|\theta\|_2^2 \quad (3.12)$$

とした。また、パラメータの範囲を

$$\begin{aligned} \omega &: [0.001, 1.0], \\ \gamma_x &: [0.0001, 2.0], \\ \gamma_D &: [0.0001, 2.0], \\ \alpha_C &: [0.001, 1.0], \\ \alpha_x &: [0.001, 2.0] \end{aligned} \quad (3.13)$$

と指定した。パラメータ推定にあたって、2023 年 11 月 13 日における午前 7 時から翌午前 6 時までの一時間ごとのファミチキの売上数データを用いた。これは実地検証を行う約一年前であったためである。また、複数日時においてパラメータ推定を行った場合、ノイズに対する影響を受け、精度が出なかったため、11 月の期間の中で平均的な来客数・売上数の時間変化をしていた 2023 年 11 月 13 日を選んだ。パラメータ推定の結果、それぞれのパラメータは以下の値として推定された。

$$\omega : 0.1582, \gamma_x : 1.6879, \gamma_D : 1.8179, \alpha_C : 0.7446, \alpha_x : 0.2043 \quad (3.14)$$

### 数値計算結果

推定されたパラメータを元に数値計算を行った例を示す。2023 年 11 月 15 日の一時間あたりの来客数データを用いて行った。なお、来客数データは数値計算する際の刻み幅に合わせて線形補間を行った。




図 3.8 2023 年 11 月 15 日における来客数




図 3.9 2023 年 11 月 15 日における売上数・購買意欲・仕込み意欲の予測




図 3.10 2023 年 11 月 15 日における売上数データと数値計算による売上数

(※文責: 吉野颯真)

### 3.6.2 最適化手法

#### 目的関数を構成する変数

仕込み数を評価する目的関数の定義に用いる変数として、以下を定める。

- $t_0$  ...  $t$  の初期値.  $x_0 = x(t_0)$  を満たす.
- $t_{end}$  ... 新たに仕込んだファミチキの消費期限.
- $t_{peak}$  ... 次回の仕込み時間.  $t_0$  から  $t_{end}$  までのうち、店員の仕込み意欲  $m$  が極大値をとる時間とする. ただし極大値が複数ある場合は、その中で仕込み意欲が最大となる時間とする.
- $x_f$  ... ファミチキの売れ残り (廃棄数).  $t_0$  から  $t_{peak}$  までのうち、最小の  $x$  の値とする.  $x_0 - x_f$  を次回仕込み時までのファミチキの売上数とする.

$t_{peak}$  の定義は、店員が仕込みを決断する時間が、仕込み意欲  $m$  が最大となる時間と同じであるという仮定に基づく。それを踏まえ、 $t_0$  から  $t_{end}$  まで時間で  $m$  が局所的な極大値を取る時間を、次回の仕込み時間とする。なお、このときの仕込み意欲は  $m(t_{peak})$  と表せる。またこれに従い、 $t_0$  から  $t_{end}$  までに極大値を取らない場合の  $x_0$  は、評価の対象外としている。例えば、過剰な仕入れなどにより、最初の仕込み意欲の極大値がファミチキの消費期限を超えてしまう場合は、その途中で  $m$  が正の値になっていたとしても、評価の対象外となる。

$x_f$  の定義については、 $x(t_f) = x_f$  となる時間を  $t_f$  とおくと、 $t_f$  は  $t_{peak}$  とは異なるため、 $x(t_f)$  は次回仕込み時点での厳密な売れ残り数を示さない。一方で、図 3.9 のように短時間で大幅に増加する  $x$  の時間発展の性質から、 $x(t_{peak})$  は仕入れによる大幅な増加の途中にある場合が多く、正確

## Mathematical Modeling Project

な売れ残りの値を示せない。また同様の性質により、多くの場合  $t_f$  と  $t_{peak}$  との時間の差は小さく収まる。よって、 $t_{peak}, t_f$  から、微分方程式モデルに基づく実際の売上を  $x(t_0) - x(t_f) = x_0 - x_f$  と近似できる。

### 目的関数

$x_0$  に対する目的関数  $f(x)$  を式 3.15 のように定めた。

$$f(x) = w_1(x_0 - x_f) + w_2 t_{peak} + w_3 \frac{C(t_{peak})}{C_{max}} + w_4 x_f \quad (3.15)$$

この目的関数の定義は、以下の要因を考慮したものである。

- 売上  $x_0 - x_f$  の最大化
- 次回仕込み時間  $t_{peak}$  の最小化 (小刻みな仕込み作業を防ぎ、店員の負担を軽減するため)
- 次回仕込み時点の来客数  $C_p$  の最小化 (次回仕込み時間  $t_{peak}$  が繁忙を伴う時間帯を避けている必要があるため)
- 廃棄数  $x_f$  の最小化

実地検証時点での実装では、各係数の値を式 3.16 のように定めた。

$$w_1 = 1.0, w_2 = 4.0, w_3 = -8.0, w_4 = -3.0 \quad (3.16)$$

この式および係数の値は、対応する条件の重要性を想定し、独自に定めたものである。なお上の式および各係数の定義は、各変数が規格化されておらず、目的変数に対する各要素の影響度を示すには十分でない。そこで、実証実験時のパラメータ設定である式 3.17 に基づき、目的関数の定義を式 3.18 のように再構成した。

$$x_{max} = 15, t_{end} = 6, C_{max} = 60 \quad (3.17)$$

$$f(x) = w'_1 \frac{x_0 - x_f}{x_{max}} + w'_2 \frac{t_{peak}}{t_{end}} + w'_3 \frac{C(t_{peak})}{C_{max}} + w'_4 \frac{x_f}{x_{max}} \quad (3.18)$$

このとき、各係数は式 3.19 のようになる。

$$w'_1 = 15.0, w'_2 = 24.0, w'_3 = -8.0, w'_4 = -45.0 \quad (3.19)$$

これにより、目的関数に対する各要因の影響の強さを相互に比較できる。

$w_1$  および  $w'_1$  は売上の影響を示す。影響を過剰に強くすると、評価値が売上に対して単調に増加し、廃棄数に関係なく過剰な仕込み数が評価されやすくなるため、影響を比較的抑えている。

$w_2$  および  $w'_2$  は次回仕込み時間の影響を示す。小刻みな仕込みを防ぐため、影響を強くしている。

$w_3$  および  $w'_3$  は次回仕込み時点の来客数の影響を示す。過剰に来客数が多い時間を避けることができれば十分であり、比較的弱くしている。

$w_4$  および  $w'_4$  は廃棄数の影響を示す。ファミチキの廃棄を防ぐため、最も影響を強くしている。

(※文責: 多田瑛貴)

## 3.7 機械学習

本節では、実地検証において数理モデルに対し、比較用である機械学習の実装について記述する。入力を来客者数、出力を次の陳列数とすることで、入出力に関して数理モデルと同様なものとなる。

### 3.7.1 モデルの選定

機械学習を用いた購買予測を行うにあたり、モデルの選定は重要である。今回は XGBoost (eXtreme Gradient Boosting) を用いた。XGBoost を採用した理由は主に以下の2点である。1点目は、XGBoost は決定木モデルをベースとしているため、各特徴量の重要度を相対的に比較できることである。決定木モデルは、特徴量がどの程度予測に寄与しているかを可視化できる性質を持つ。図 3.11 は実際に、XGBoost を用いた場合の特徴量の重要度を可視化したものである。2点目は、Kaggle などをはじめとした多数の利用実績である。XGBoost は GDBT (勾配ブースティング) に分類される手法の一つであり、GDBT にはほかにも CatBoost や LightGBM などが存在する。しかし、その中でも XGBoost は活用事例が豊富であり、精度向上に関するノウハウや知見を数多く参照できる点が大きな強みである。以上の2点の理由から、本分析では XGBoost を採用することとした。

(※文責: 今辻平)

### 3.7.2 モデルの作成

本節では、機械学習モデルの作成に必要な作業の手順について説明する。開発環境として Anaconda を使用し、Python を実行環境として設定した。また、コードの生成および編集には Visual Studio Code (VSCode) を利用した。

#### 説明変数

説明変数として、以下の指標を用いることにした。

- **customer**: 来店客数 [人]
- **hour**: 時刻 [時](0~23)
- **customer\_lag\_1**: 前時点の来店客数 [人]
- **sales\_lag\_1**: 前時点の売上個数 [個]
- **is\_holiday**: 休日であるかどうかを示す
- **day\_of\_week**: 曜日
- **temperature**: 気温 [°C]
- **humidity**: 湿度 [%]
- **wind**: 風速 [m/s]
- **week\_of\_month**: 月内の週番号

これらは、取得可能なデータのうち、売上数に影響すると考えられるものを独自に抽出したも

## Mathematical Modeling Project

のである。抽出方法に関しては、売上数との相関、図 3.11 の特徴量重要度を調べることで取捨選択した。


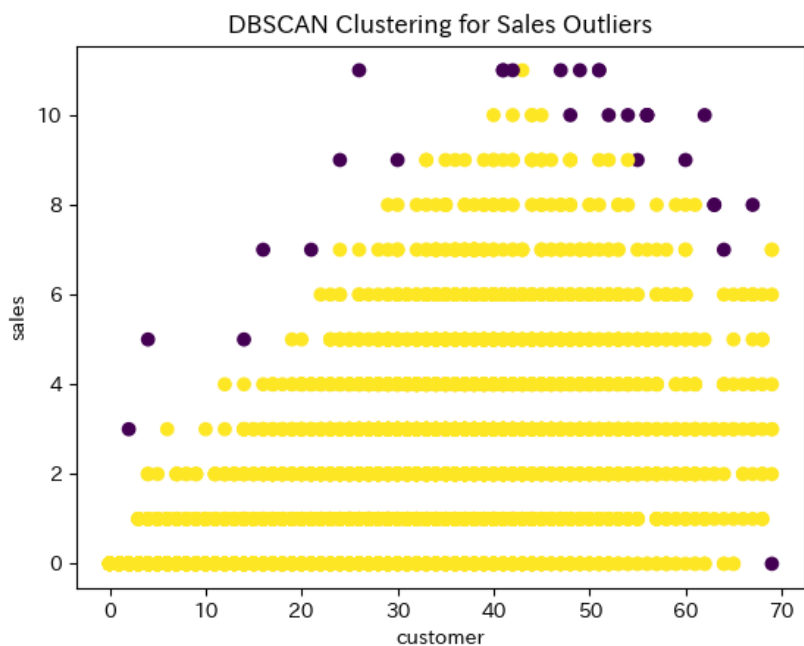


図 3.11 特徴量重要度

### 精度向上

機械学習モデルを作るにあたり、精度向上は重要な項目となる。ここでは精度向上にあたり独自に行ったことを記述する。まず異常値を検出、削除した。本来、XGBoost は欠損値や異常値の及ぼす影響も可能な限り抑える性能を持っているが、今回はデータ数が少ないため、異常値があるとモデルに大きく影響してしまう。そのため異常値を取り除く工程が必要となった。今回は、DBSCAN を用いて異常値を検出した。DBSCAN での検出過程は、図 3.12 で大きく起因している特徴量同士の異常値を検出し、テーブルデータから削除していった。最後にハイパーパラメータの最適化をした。



### 3.7.3 評価

今回用いたモデルは時系列モデルであり、評価に過去のデータを使うことは適切ではないため交差検証を用いた。最終的に、平均 MAE 平均 MAE: 0.9110, 平均 RMSE: 1.4491 となった。教師データの売上数の平均が 2.2274 (いずれも小数第 5 位で切り上げた値) であるためこのモデルは中程度の精度を持ち、改良の余地があるものといえる。改善案として図 3.11 より customer や hour が重要であることがわかるため、時間ごとに来る来客数についてデータ収集し、分析することで精度が向上すると考察できる。

(※文責: 今辻平)

## 3.8 Web アプリケーションの機能と実装

本節では、Web アプリケーションを開発するにあたって、実装した機能の詳細と実装方法について説明する。

(※文責: 石井健太)

### 3.8.1 アプリケーションの機能と実装

本 Web アプリケーションは本プロジェクトの目標を達成するために以下の機能を実装した。

- 入力されたファミチキの陳列数を基に、最適な陳列数となるように追加で必要なファミチキの個数を画面上に表示する機能
- 予測した時刻と陳列数を基に、次の揚げるべき時刻と個数を予測する機能
- 画面上にキーパッドを表示する機能
- 現在時刻を表示する機能

以下で各機能についての詳細と実装について説明する。

#### 入力されたファミチキの陳列数を基に、最適な陳列数となるように追加で必要なファミチキの個数を、画面上に表示する機能

利用者に現在のファミチキの陳列数を入力してもらうことにより、利用時間帯におけるファミチキの陳列数を最適にするための追加で揚げるべきファミチキの個数を画面上に表示する機能を実装した。表示結果が見やすいように結果を画面の中央に大きく配置した。またこの機能の最終利用時刻も表示結果の上に表示した。最終利用時刻が見れることによって、最後に予測を利用した時刻を確認することができる。

本機能は従業員に現在時刻におけるファミチキの陳列数を入力してもらう。入力値を Python で作成した数理モデルに POST し、計算した結果である現在時刻に揚げるべき個数を図 3.13 のように出力する。また入力値が負の値の場合はエラーが発生してしまうため、入力値は 0 以上の正

の値のみ入力できるようにしている。

### 予測した時刻と陳列数を基に、次の揚げるべき時刻と個数を予測する機能

前回の予測結果と現在の時刻を基に、次にファミチキを揚げるべき最適な時刻と個数を予測する機能を実装した。事前に予測することによって、次にいつファミチキを何個揚げればよいかという疑問を解消することができる。また本機能を実装するにあたり、現在時刻が予測した時刻になった場合、通知音を鳴らすことによって利用者に気づかせる機能も実装した。

本機能は上記で説明した「入力されたファミチキの陳列数を元に追加で揚げてほしいファミチキの個数を画面上に表示する機能」において、POSTされた時刻と個数を基に、現在時刻における揚げるべき個数と同時に次回揚げるべき時刻と個数を返し、図 3.13 のように表示される。

また現在時刻が次回揚げるべき時刻になった場合、通知音が鳴る機能について、通知音は約 5 秒の音を 1 回のみ鳴らすことにした。理由は従業員が忙しいとき、通知音を止めることができなければ延々と音声が続いてしまうためである。

### 画面上にキーパッドを表示する機能

数値を入力しやすくするために、キーパッド機能を実装した。本アプリケーションで入力が必要な機能として、本節の上記で説明した「入力されたファミチキの陳列数を基に追加で揚げてほしいファミチキの個数を画面上に表示する機能」がある。iPad の標準搭載されているキーボードは、入力したい数値のボタンサイズが小さいため入力しにくい。そのため、本 web アプリケーション向けに新たにボタンサイズが大きく、かつ不要なキーを排除したキーパッドを実装した。また入力された数値を一括で削除することができる CLEAR キーを実装した。もし入力の際に誤った値を入力しても、CLEAR キーを押すことで一括で入力欄に入力された数値を削除することができる。これらのキーパッドの機能を実装することによって、従業員の入力を円滑に行ってもらうことを目的にした。

本機能の実装にあたって、JavaScript のライブラリである simple-keyboard を利用した。このライブラリは画面にスクリーンキーボードを表示させることができるライブラリである。また表示させるスクリーンキーボードはキーの位置や大きさ、配置、キーを押したときの処理を開発者が自由に変更することができる。本 Web アプリケーションでは数値の入力を円滑に行ってもらうため、0~9 の数値の入力に特化したキーパッドとして実装した。

### 現在時刻を表示する機能

本アプリケーションのヘッダー部分に現在時刻が HH:MM:SS 形式で表示される機能を実装した。この機能によって、従業員は現在時刻を簡単に知ることができ、予測時刻との関連付けが可能になる。

本機能の実装にあたって、JavaScript の Date オブジェクトで現在時刻を取得した。取得した時刻を JavaScript の Window インターフェースのメソッドである setInterval メソッドを用いて、非同期処理で毎秒更新することで実装した。

(※文責: 石井健太)

### 3.8.2 システムの設計

本 Web アプリケーションでは、前節で記述した機能を中心として設計を行った。本アプリケーションの目標を満たすために「従業員にとってわかりやすくシンプルで使い続けやすい Web アプリケーション」というコンセプトを設定し設計を行った。本コンセプトを達成するために、以下を工夫した。

- 重要な項目を大きく目立たせるように表示させたこと
- 通知音を鳴らすことによって、従業員の聴覚を刺激し気づかせたこと
- キーパッドを導入し簡単に数を入力できるようにしたこと
- 縦置きタブレットで利用することを念頭においてデザインしたこと
- 配色をファミリーマート仕様にしたこと

これから以上の点の詳細を説明する。

#### 重要な項目を大きく目立たせるように表示させたこと

予測を開始するボタン、予測結果といった項目は本 Web アプリケーションの目的である「現在のファミチキの陳列数を入力することで、利用時間帯における最適なファミチキの陳列数を予測する。」を達成するための最重要の項目である。これらの項目を分かりやすく表示させることによって、はじめて本アプリケーションを利用する人でもわかりやすく快適に利用することができ、UX の向上といったメリットが発生する。しかしもしこれらの重要項目の場所がわかりにくい場合、はじめて本 Web アプリケーションを利用する人は、どこのボタンを押せば予測をできるのか、また結果はどこに、どのように表示されるのかがわからない可能性がある。また本 Web アプリケーションは業務中に使用することを目的とした Web アプリケーションであるため、ピークタイム等の忙しい時間でははじめて利用する人でも利用を忌避してしまうかもしれない。

本アプリケーションは上記で挙げた重要な項目を従業員にとってわかりやすく表示させるため、大きく目立たせるように表示させた。具体的にはボタンを画面の横幅 80% まで広げ、わかりやすさのほかにボタンの押しやすさも向上させた。また重要項目のフォントを太字にして強調することによって、重要な項目であると気づかせる工夫をした。

#### 通知音を鳴らすことによって、従業員の聴覚を刺激し気づかせたこと

前節で実装した機能について述べたが、その中の機能の 1 つである「予測した時刻と陳列数を基に次の揚げるべき時刻と個数を予測する機能」の中で、現在時刻が予測した時刻になったら通知音を鳴らす工夫をした。通知音を鳴らすことによって、従業員の聴覚を刺激して気づかせることができる。もし通知音が鳴らなかった場合、従業員は通知音という外的要因に頼らず予測した時刻に自分から気づかなければならない。業務中には様々なことを考えなければいけないので、予測時刻を忘れてしまうこともあるだろう。

#### キーパッドを導入し簡単に数値を入力できるようにしたこと

前節の「画面上にキーパッドを表示する機能」の説明でも述べたが、画面上に表示できるキーパッドは大きさやボタンの役割を自由に設定することができる。そこで従業員が利用しやすいよ

うな工夫を加えてキーパッドを実装した。1つめはキーのサイズを大きくすることによって入力しやすく、また入力ミスを少なくさせた。入力は機能の中でも頻繁に使用する機能のため、些細な使いにくさでもストレスに発展する。2つめに CLEAR キーを導入した。CLEAR キーとは、キーを押すと入力欄に入力されている文字列を一括で削除してくれるキーである。CLEAR キーをキーパッドと同じ場所に配置することによって、入力ミスをしてもすぐに訂正することができる。これら2つの工夫を加えることによって、従業員の UX を向上させることを目指した。

### 縦置きタブレットで利用することを前提においてデザインしたこと

本 Web アプリケーションは縦置きタブレットで利用することを前提においてデザインした。デバイスを縦置きタブレットに絞ってデザインした理由は、本プロジェクトの協力店舗であるファミリーマートに設置することを考えた際、サイズの的に最も適していると判断したためだ。設置する条件として、設置場所に邪魔にならなかつ見やすいサイズである必要がある。その条件を満たすデバイスは縦置きのタブレットであると判断したため、本 Web アプリケーションは縦置きタブレットで利用することを前提においてデザインした。

### 配色をファミリーマート仕様にしたこと

本 Web アプリケーションのデザインはファミリーマートの看板に使用されている配色を用いた。本 Web アプリケーションはファミリーマートの商品であるファミチキの陳列数を予測する Web アプリケーションのため、配色はファミリーマートで用いる Web アプリケーションだと一目でわかり、そしてシンプルな配色であるファミリーマートの看板の配色にした。本アプリケーションのヘッダー、メイン要素、フッターをそれぞれ 16 進数カラーコードでファミリーマートの看板の色に対応させた。ヘッダーは 009c41、メイン要素は ffffff、フッターは 0087c1 である。

(※文責: 石井健太)

### 3.8.3 システムの画面構成

本アプリケーションの画面設計について説明する。本 Web アプリケーションの画面構成として、3.2.3 でも述べた通り、縦置きのタブレットを前提としてデザインした。以下に開発した Web アプリケーションのメイン画面と陳列数入力ポップアップが表示された画面をそれぞれ図 3.13、図 3.14 に示す。図 3.13 のメイン画面について、ヘッダーに現在時刻を表示している。中央には最新の予測結果を表示している。予測時刻と予測結果である追加で揚げるべきファミチキの個数が表示されている。その下には次回揚げるべき時刻とその個数が表示されている。さらに下部には現在時刻における最適陳列数を出力するための予測開始ボタンを表示している。予測開始ボタンを押すことによって図 3.14 の陳列数入力画面に遷移する。画面中央に個数入力のためのポップアップがあり、陳列個数を入力し送信することによって図 3.13 に遷移し、最新の予測結果が出力される。また陳列数入力のためのキーパッドを用いて入力することができる。

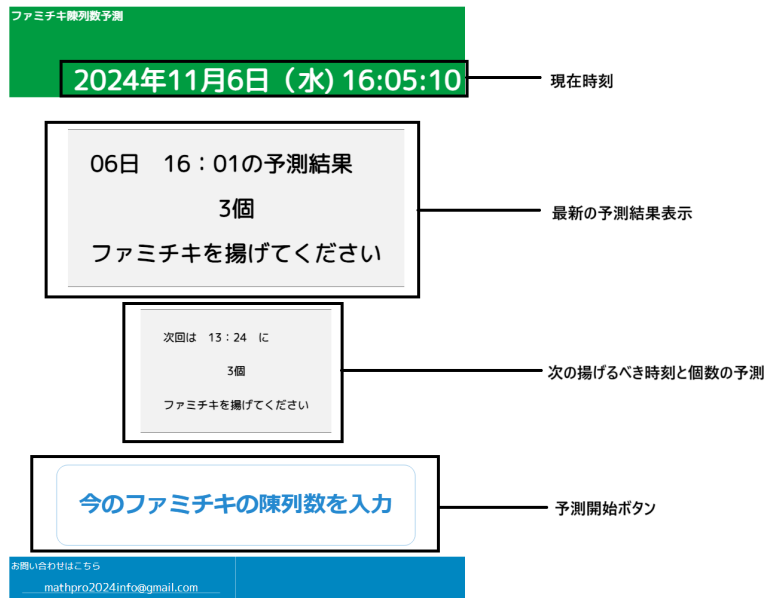


図 3.13 メイン画面

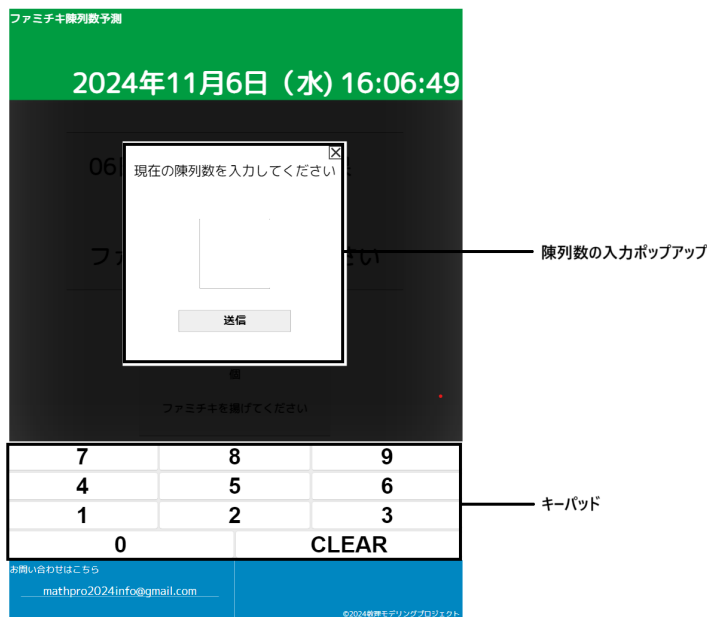


図 3.14 ポップアップ表示画面

(※文責: 石井健太)

## 第4章 実地検証

本章では、開発した Web アプリケーションを用いた実地検証の結果を示し、その有用性を評価する。

(※文責: 小久保尚)

### 4.1 実地検証の方法

本検証では、開発した Web アプリケーションをタブレット端末で実行し、レジ内に設置した。これにより、スタッフが現在のファミチキを仕込むべき数をいつでも把握できる環境を構築することを目指した。

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。

なお、図4.1の写真は、開発したアプリケーションをタブレット端末に表示し、レジ内に設置した際の様子を示したものである。

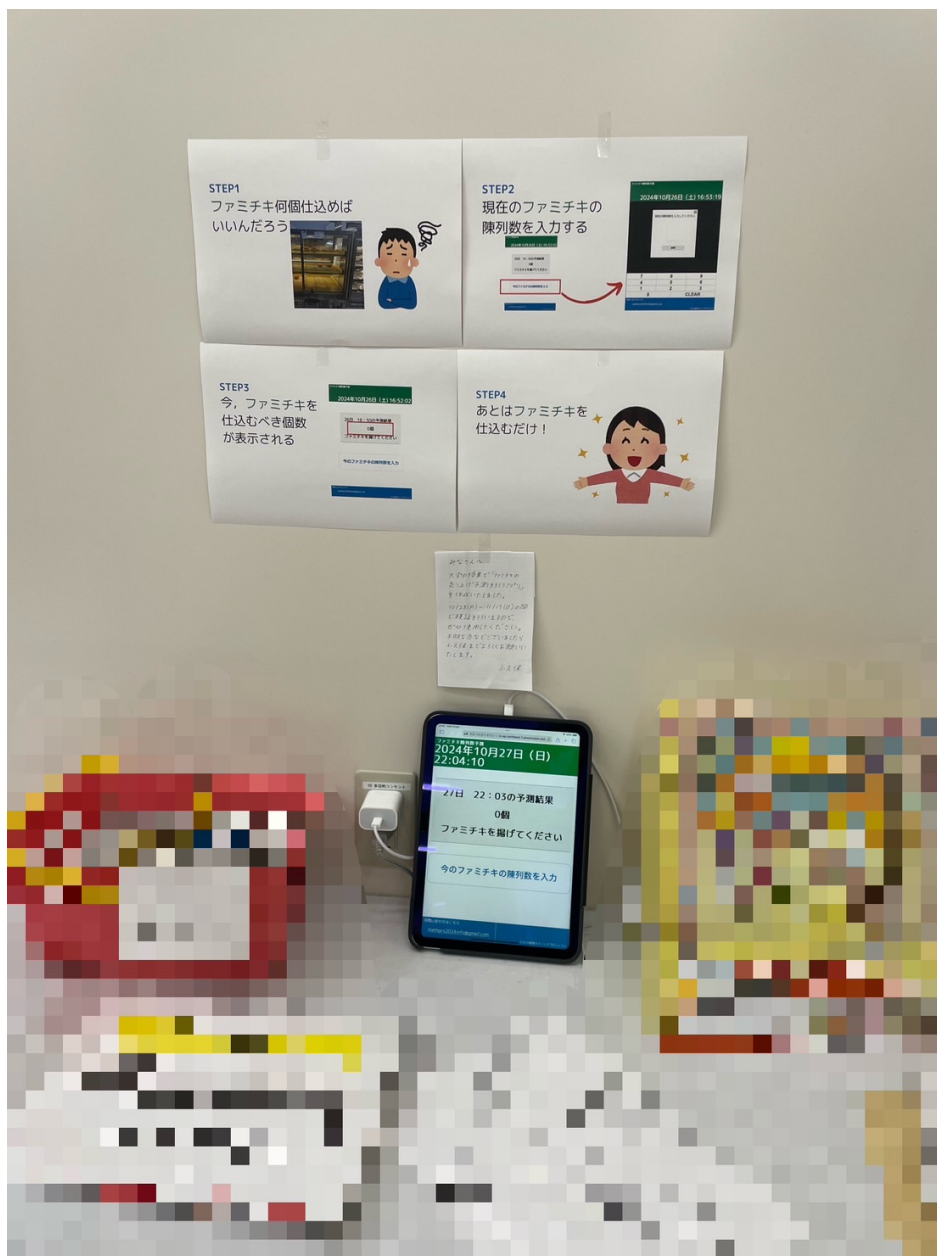



図 4.1 Web アプリケーション設置の様子

アプリケーションの近くには、従業員が迷わず操作できるよう図 4.2 のような簡易マニュアルを提示した。このマニュアルには、ファミチキの仕込み個数の確認手順や操作の流れが図解付きで説明されており、初めて操作するスタッフでも直感的に理解できるよう工夫した。


STEP1

ファミチキ何個仕込めばいいんだろう



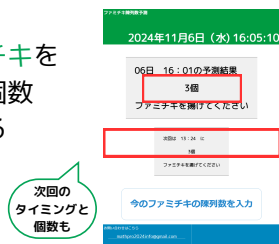
STEP2

現在のファミチキの陳列数を入力する



STEP3

今、ファミチキを仕込むべき個数が表示される



STEP4

あとはファミチキを仕込むだけ！



図 4.2 簡易マニュアルの提示 (全 4 ページ)

(※文責: 小久保尚)

### 4.1.1 アンケート

本検証では、勤務歴によるファミチキ仕込み業務の実態や作成した Web アプリケーションが導入されたことによる変化を調査することを目的とし、アンケート用紙を実店舗の事務所に設置した。1/9 からアンケート用紙を設置し、検証期間が終了するまでにいつでも回答可能な形式にした。紙によるアンケートの収集を採用した理由は、協力いただいた店舗ではメモを残すことによる情報伝達が主流であり、日常的にスタッフがメモを活用してコミュニケーションを行っているためである。そのため、スタッフにとって自然な形でアンケートに協力してもらえようと考えた。このアンケートは、従業員の業務実態やアプリケーションの使用状況、今後の改善点を把握することを目的として設計した。

アンケートは以下の 3 つの項目に分けて構成され、それぞれ複数の設問を通じて情報を収集した。

#### (1) 基本情報

- 勤務歴：半年未満 / 半年以上～2 年未満 / 2 年以上～5 年未満 / 5 年以上
- 週の勤務時間：10 時間未満 / 10～20 時間 / 20～40 時間 / 40 時間以上

目的: 回答者の業務経験やシフト状況を把握し、アンケート結果との相関を分析するため。

#### (2) 業務の実態

- ファミチキの仕込み頻度：毎回 / ほとんど / たまに / ほとんど行わない / まったく行わない
- 仕込みが適切に行えない理由：
  - ファミチキが品薄になっていて気づかなかった
  - 仕込むべき個数が分からない

## Mathematical Modeling Project

- シフトのペアの人が作る
- その他（自由記述）

**目的:** 現状や課題を把握し、アプリケーションの有用性を評価するため.

### (3) アプリケーションへのフィードバック

- 使用頻度：毎回 / ほとんど / たまに / ほとんど使用しなかった
- 使用しなかった理由：
  - お客さんが多く仕込み時間が取れなかった
  - 他業務に追われた
  - その他（自由記述）
- 仕込み量の変化：増加 / やや増加 / 変わらない / やや減少 / 減少
- 業務負担感：楽になった / やや楽になった / 変わらない / やや大変になった / 大変になった
- 今後の利用意向：使用したい / やや使用したい / あまり使用したくない / 使用したくない

**目的:** アプリケーションの使いやすさや業務への影響、改善点を評価するため.

以下に示すアンケート用紙（図 4.3）は、実地検証において実際に配布・記入されたものである.

### 従業員様アンケート(～ 11/7)

この度はご協力いただき誠にありがとうございました。  
よろしければ下記アンケートにご協力ください。

個人情報取り扱いに関する説明を理解したうえで、同意しますか。	<input type="checkbox"/> 同意する <input type="checkbox"/> 同意しない
<b>■勤務歴など</b>	
勤務歴	<input type="checkbox"/> 半年未満 <input type="checkbox"/> 半年以上～2年未満 <input type="checkbox"/> 2年以上～5年未満 <input type="checkbox"/> 5年以上
週にシフトに入る時間	<input type="checkbox"/> 10時間未満 <input type="checkbox"/> 10以上～20時間未満 <input type="checkbox"/> 20以上～40時間未満 <input type="checkbox"/> 40時間以上
<b>■普段の業務について</b>	
普段、ファミチキの仕込みを行いますか。	<input type="checkbox"/> 毎回のシフトで行う <input type="checkbox"/> ほとんどのシフトで行う <input type="checkbox"/> たまに行う <input type="checkbox"/> ほとんど行わない <input type="checkbox"/> まったく行わない
「たまに行う」「ほとんど行わない」を選択した方について、理由を教えてください。	<input type="checkbox"/> ファミチキが品薄になっていても気づかない <input type="checkbox"/> 仕込むべき個数が分からない <input type="checkbox"/> シフトのペアの人が作る <input type="checkbox"/> その他( ) ※複数回答可
<b>■アプリケーションについて</b>	
本アプリケーションをどの程度、使用しましたか。	<input type="checkbox"/> 毎回のシフトで使用 <input type="checkbox"/> ほとんどのシフトで使用 <input type="checkbox"/> たまに使用 <input type="checkbox"/> ほとんど使用しなかった
本アプリケーションを使用しなかった理由を教えてください。	<input type="checkbox"/> お客さんが多く、仕込む時間がとれなかった <input type="checkbox"/> 他の業務に追われ、仕込む時間がとれなかった <input type="checkbox"/> もっと仕込むべきだと感じた <input type="checkbox"/> そんなに仕込まなくても良いと感じた <input type="checkbox"/> その他( ) ※複数回答可
本アプリケーションを使用して、ファミチキの仕込みを行う頻度は増えましたか。	<input type="checkbox"/> 増えた <input type="checkbox"/> やや増えた <input type="checkbox"/> 変わらない <input type="checkbox"/> やや減った <input type="checkbox"/> 減った
本アプリケーションを使用して、ファミチキの仕込み業務は楽になりましたか。	<input type="checkbox"/> 楽になった <input type="checkbox"/> やや楽になった <input type="checkbox"/> 変わらない <input type="checkbox"/> やや大変になった <input type="checkbox"/> 大変になった
本アプリケーションをこれからも使用していきたいと思えますか。	<input type="checkbox"/> 使用したい <input type="checkbox"/> やや使用したい <input type="checkbox"/> あまり使用したくない <input type="checkbox"/> 使用したくない
上記の質問の回答について、理由を教えてください。	
その他、ご意見ご要望ご感想などお聞かせください。	

ご協力ありがとうございました。

図 4.3 実地検証アンケート用紙

(※文責: 小久保尚)

#### 4.1.2 売上率

本検証では分析の際に売上率を用いて分析を行う。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。分析に使える要素として売上数と来客数、売上率の3つがあるが、

売上率を用いた。理由として、来客数が同じ場合についてもアプリケーションの効果を見ることができただけだ。

分析は差分の差分法を用いて進めた。この手法を用いた理由として、月ごとの売上パターンの違いが挙げられる。ファミチキは月ごとに売上の推移のパターンが異なるという特徴を持つ。そのため、分析の際にはこの特徴を考慮しなければならない。差分の差分法ではこの特徴による影響を無視し、アプリケーションの効果のみを抽出することが可能であるため、差分の差分法を用いた。

差分の差分法を進める際に、コントロール群のデータは、去年の10月のデータと今年の10月のデータの売上率を用いた。介入群のデータは去年の11月のデータと検証データの売上率を用いた。検証データについては、機械学習と数理モデルの2つの場合について分析を進めた。

(※文責: 六本木是杜)

## 4.2 プロトタイプを用いた事前検証

実地検証の準備として、予備検証を実施した。本検証に先立ち、アプリケーションのプロトタイプを実際の店舗環境で運用し、運用上の課題や改善点を洗い出すことを目的とした。

プロトタイプは、本番環境を想定して設計・構築された試験運用版アプリケーションである。主な機能として、ファミチキの仕込み個数のリアルタイム表示、必要な仕込み量の通知、および操作履歴の記録などが実装された。また、操作インターフェースはタブレット端末を通じて提供され、現場スタッフが直感的に操作できるよう、視認性と操作性を重視したデザインが採用された。

加えて、サーバー環境、入出力機能、およびUI/UXに関しては、本番環境と同等の設定を適用し、運用上の挙動やシステムの安定性を確認することに重点を置いた。これにより、プロトタイプの段階で現場特有のニーズや潜在的な技術的課題を早期に把握することが可能となった。

### 現場での運用

予備検証にはプロジェクトメンバーの中でも実際に店舗で勤務しているメンバーに協力していただき、現場のリアルな業務フローの中でプロトタイプを使用してもらった。現場メンバーからは、操作性の改善点や表示内容の分かりやすさについて具体的なフィードバックが得られ、これに基づいて細かな調整が行われた。

### キーパッドの追加

予備検証を経て、キーパッドの追加を行った。これは、従業員がアプリケーションをより直感的かつ効率的に操作できるようにするための改善策であり、入力作業の手間やエラーの削減を意図して導入された。特に、数値の入力が頻繁に発生するシーンにおいては、キーパッドの追加が作業効率の向上に大きく寄与することが確認された。

これらのプロセスを通じて、アプリケーションの基本機能の妥当性や操作上の課題点が明確になり、本番環境での実地検証に向けた準備を着実に整えることができた。

(※文責: 小久保尚)

## 4.3 実地検証の結果

### 4.3.1 アプリケーションの使用状況

本セクションでは、実地検証期間中におけるアプリケーションの使用状況について報告する。主に使用頻度を確認し、どの程度アプリケーションが現場業務に組み込まれたかを分析した。以下の図（図 4.4）は、2024 年 10 月 28 日から 11 月 15 日までのアプリケーション使用頻度の推移を示している。このデータは、実地検証期間中におけるアプリケーションの使用状況を時系列で記録したものである。




図 4.4 アプリケーションの使用頻度の推移

実地検証の初期段階では、1 日あたり約 30 回程度の使用頻度が確認され、順調にアプリケーションが活用されていた。しかし、日が経つにつれて使用頻度は徐々に減少し、後半にはアプリケーションがまったく使用されなかった日も見られた。

特筆すべき点として、11 月 11 日には使用頻度が一時的に増加しているが、これはプロジェクトメンバーがその日にシフトに入っていたためであり、通常の業務パターンとは異なる要因によるものと考えられる。

(※文責: 小久保尚)

### 4.3.2 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（表 4.1）。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。

表 4.1 アンケート回答者の回答内容

項目	1人目	2人目	3人目	4人目
勤務歴	半年以上～2年未満	2年以上～5年未満	5年以上	2年以上～5年未満
週のシフト	10～20時間未満	10～20時間未満	20～40時間未満	40時間以上
仕込み頻度	毎回のシフトで行う	毎回のシフトで行う	毎回のシフトで行う	毎回のシフトで行う
使用頻度	回答なし	たまに使用	毎回使用	たまに使用
仕込み頻度	変わらない	変わらない	変わらない	変わらない
業務負担	やや楽になった	変わらない	変わらない	変わらない
継続意向	やや使用したい	やや使用したい	やや使用したい	やや使用したい

### 自由記述からの意見

- **1人目:** 朝のシフトでは来店者が多く、以前からの自分の目安で仕込む方が楽と感じた。
- **2人目:** 忘れていなければ使用する。
- **3人目:** 新しく入ったスタッフには適していると思うが、元々いるスタッフには仕込み数が足りなく感じる。
- **4人目:** 夜遅くの時間には参考になったが、昼間は足りないと感じた。

### 総括

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。

(※文責: 小久保尚)

### 4.3.3 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。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。利用したデータは、2023年10月～11月のデータ、2024年10月のデータの二つである。データの具体的な期間は以下のようにになっている。

- 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。

以下に分析の結果を示す（表 4.2）。

表 4.2 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
機械学習モデル	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。

（※文責: 六本木是杜）

## 4.4 結果に対する考察

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。日中では従来の方法である経験則に基づく仕込みが優先される傾向があり、アプリケーションの提示する仕込み数は十分に活用されなかった。これは、従業員がこれまでの業務経験に対する信頼が強かったことが一因であると考えられる。一方、夜間ではアプリケーションを参考にした仕込みが行われることが多く、実際に夜間のほうが売上率の上昇が顕著であった。これらの結果は、利用が多く確認された機械学習モデル期間から得られたものであり、アプリケーションが夜間業務において一定の効果を発揮したことを示している。

一方で、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。その原因として、第一に従業員がアプリケーションの使用に飽きてしまったことが挙げられる。初期段階では新しいツールに対する興味から積極的に使用されていたが、時間の経過とともにその意欲が低下したと推測される。第二に、数理モデルが提示する仕込み数が従業員に信用されなかったことが挙げられる。数理モデルは需要予測の精度が機械学習モデルに比べて低いため、従業員の実感に合わない提案が行われた可能性がある。これにより、アプリケーションが従業員からの信頼を得ることが難しくなり、利用頻度がさらに低下したと考えられる。

しかしながら、本検証を通じてアプリケーションのポテンシャルが確認された点も注目すべきである。特に夜間の売上率が顕著に向上したことは、アプリケーションが適切に利用されれば現場業務に大きな影響を与える可能性を示している。また、初期段階で多くの従業員が積極的にアプリケーションを使用したことは、ツールとしての直感的な操作性や提案内容が一定の受け入れられた結果といえる。さらに、アンケート結果からも、新しいスタッフにとってアプリケーションが業務を支える有効なツールであると評価された点は、業務の属人性を排除する可能性を示唆している。

## Mathematical Modeling Project

今後は、数理モデルの精度向上や従業員が継続的な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ポテンシャルをさらに引き出し、業務全体の効率化に寄与できると期待される。

(※文責: 小久保尚)

## 第5章 中間発表

本節では中間発表のための準備、中間発表の当日、いただいたフィードバックの評価について振り返る

(※文責: 吉野颯真)

### 5.1 中間発表の準備

本プロジェクトは、中間発表会にあたってスライドとポスターを作成した。スライドは発表資料として、ポスターは補足的な資料としてそれぞれ用いた。最初に、ポスターとスライドの軸となるアウトラインをプロジェクトメンバー全員で話し合いを行ったのち、決定した。アウトラインとして、数理モデリングの説明、背景と課題、扱う対象、作成するシステム、モデリング班の活動、実装班の活動、今後の予定の7項目で構成した。その後、プロジェクトメンバーをアウトプット班、実装班、モデリング班に分けて作業を進めることとした。アウトプット班の小久保、石井朗偉、今がスライドの仮作成を担当した。スライド作成には Canva を使用した。仮作成したスライドを基に発表を行い、担当教員やメンバーからフィードバックを貰った。フィードバックでは、「スライドの枚数が多いため、聞き手が追いつきにくい」、「数理モデルを使う理由がわからない」、「デザインが見づらい」など、改善すべき点が多く挙げられた。これを基に、発表者である吉野、佐野、石井朗偉と質問回答者である小久保が、構成や内容・デザインを修正した。構成に関する修正としては、背景と課題、扱う対象、手法、今後の予定に変更を行った。また、内容・デザインに関する修正としては、内容の絞り込みやスライド1枚あたりの情報を増やし、スライドの枚数を40枚から15枚に削減した。ポスターは多田が作成し、その作成には Google Slide を使用した。スライド内での文章は日本語のみ、ポスター内での文章は日本語と英語とした。発表練習は2024年6月28日から約1週間、内容の修正と同時並行で行った。プロジェクト時間外にも集まって練習し、発表技術や発表内容に関して、相互にフィードバックを行い、発表の仕方の調整を行った。また、発表用の台本を作成し、最低限言及すべき重要な文言を発表者間で共有した。

(※文責: 吉野颯真)

### 5.2 当日について

2024年7月5日の金曜日に、プロジェクト学習中間発表会にて、本プロジェクトの中間発表を行った。発表時間10分、質疑応答5分の時間配分で3回発表を行った。1回目の発表は吉野、小久保、新田、今、石井朗偉、石井健太の6名が担当し、2回目の発表は佐野、小久保、新田、六本木、石井健太の5名が担当した。3回目の発表は石井朗偉、小久保、新田、多田、今の5名が担当した。発表は予定していた通りスライドとポスターを用いて発表を行った。当日は41人の方が来場し、フィードバックや質問をいただいた。質問やフィードバックについては以下に記載する。

## 5.3 発表評価について

中間発表会当日に関するアンケートを A4 の評価シートを通して行った。公立はこだて未来大学の学生と教員を含む 41 名の回答を集計した。評価項目は、発表技術および発表内容の 2 つであり、この 2 つの項目は 1(非常に悪い)から 10(非常に優秀)の 10 段階評価と自由記述のコメントからなる。また、アンケートの結果として、発表技術の評価の平均は  $m = 8.6$ (有効回答数  $N = 34$ , 標準偏差  $SD = 1.18$ ) であり、発表内容についての評価の平均は  $m = 8.1$ (有効回答数  $N = 30$ , 標準偏差  $SD = 1.19$ ) であった。発表技術についての評価と人数のヒストグラムを図 6.1 に、発表評価についてのヒストグラムを図 6.2 に示す。

(※文責: 吉野颯真)

## 5.4 発表技術コメント

### 5.4.1 肯定的な意見

- 第 1 回
  - 説明の内容はわかりやすい。
  - 商品から顧客への影響: 陳列数が多いほど、需要量が増え、売上数が増えやすくなる。
  - 資料の質はすごく高いと思う
  - 非常に面白い取り組みだなと思いました
  - 図やアイコンを用いて説明していてわかりやすかった
  - 声が通って聞きやすい
  - 話すスピードもちょうどよい
  - 数理モデルの説明など、時間を割くべき箇所にしっかりと時間を割いて説明している点がよいと思いました
  - テンポが良い
  - 聞きやすい声で堂々とプレゼンしていました
- 第 2 回
  - 前方見つつハキハキとしゃべっていて聞きやすかった
  - スライドが見やすかった
  - The speaker is very clear!
  - 質問への回答がしっかりしていたので良かったと思います
  - 質問から入るのはテクイです。良いと思います。
  - 社会問題を解決しようとしている感じが出ていてよかったです。
  - ハキハキ話していて良かったです。スライドはよくまとまっています
- 第 3 回
  - 話し方もゆっくり落ち着いていて聞き取りやすかったです！
  - ゆっくり丁寧な発表だと思った

発表技術の評価




図 5.1 発表技術についてのヒストグラム。横軸が評価の点数，縦軸が人数を表す

発表内容の評価




図 5.2 発表評価についてのヒストグラム。横軸が評価の点数，縦軸が人数を表す

### 5.4.2 否定的な意見

- 第 1 回
  - コンビニの課題点からファミチキを選んだ繋がりがもう少し明瞭であるといいですね
  - 属人性=人材不足？
  - その属人性によってどれくらいファミチキの提供時間がかかる？
  - 今回の場所ならもう 1~2 レベル音量アップをお願いしたい
  - 発表者，回答者の声が小さい(聞きづらい)
  - コンビニが持っている問題からファミチキを対象とする繋がりがわからなかった
  - ファミリーマートよりも函館への貢献に着目できるとよいと思った
  - 1年間で 9000 個なんですね，思ったより少ない

## Mathematical Modeling Project

- ファミリーマートに行って調査しましたか？その時の状況の話もあると思います。
- イントロと紹介した数理モデルの繋がりが、まだいまいちよくわかっていないです
- 第2回
  - 抑揚をつけて話したほうが飽きないと思う
  - 1つのスライドに情報を入れすぎているものがあつた気がした
  - Please create bilingual slides
- 第3回
  - 台本を読んでいるような棒読み感を感じた
  - 図やモデルの説明があいまいだった。
  - モデルの増やす、減らすについての説明がわかりづらかった。
  - やや練習不足と感じました (緊張していただけかもしれませんが)
  - 台本を読んでいるような棒読み感を感じた
  - ポスターも利用したらどう？

(※文責: 吉野颯真)

## 5.5 発表内容コメント

### 5.5.1 モデリング関係

- $D(t)$  の  $\alpha$  はなんだろう
- チキンの個数は連続量ではないので個数を離散的な数で Simulate すると結果は変わったりしないのでしょうか？
- お店のチキンの陳列数はどれくらいのバラつきがあるのでしょうか (数が多いなら上の議論はあまり意味はないですね)
- 点数の理由として、数理モデルがいまいち
- 陳列数、来客が増えれば増えるほど売上は上がる？
- いい加減なモデルを発表してはいけない
- 他のファミリーマートとの売上の推移などを調べることで店ごとの違いもわかるのではないかな？
- $\alpha$  の値は？←質疑で解決しました
- 来客数はどう決めたのか
- $D(t) = \alpha B(t)C(t)$  は正しいのですか？
- 実データとシミュレーションの比較がほしい
- そもそもこの問題に微分方程式が適しているのかが疑問でした。
- GW のような特別な祝日にも対応できるのか気になった
- 最適仕込み通りに売れなかった時のリカバリーはあるのか、そこら辺を説明出来たら良いかもしれません。
- 変数、天候、時間、日時などは考慮する？
- 仕込み個数が多すぎる時に廃棄の逆の足りないことによる売上ロスを話すとよいかも

## Mathematical Modeling Project

- 廃棄をなくすだけなら作らなければよい
- 数理モデルの  $\alpha$  は何かわからなかった
- 差分方程式のほうが良い？
- データあるなら回帰などデータ解析でもできるような気がします
- 方程式でやる意味は？
- Where does the baseline forecasting data come from?
- ファミチキの売上につながる要因は人の行動以外にも環境などたくさんあるんだろうなあと聞いていて思いました。
- 従業員の忙しさってどうやって表すの？
- 来客数の奴？
- そもそも忙しくないタイミングで仕込むのですか？
- モデルコントロール可能なのは陳列数だけでは？
- 従業員の負担がモデルの中にはないのでは？
- モデルは常に変化しそうだけど、シミュレーションでは固定値？
- 従業員の負担はどう考える？ (バイトの人、売上は別に気にしていないのでは?)
- 微分方程式を使ったモデル化以外にも検討してよいのでは？

### 5.5.2 実装関係

- モックアップの表のカラーがファミマでいいですね
- ファミチキの説明での売上個数は1年なのか1日なのか価格とインパクトがあるかも
- 実装が大変そうだと思った

### 5.5.3 その他

- 面白い着眼点ですね。身近な現象に着目するのは良いと思います。
- ファミチキ以外にも使えるようになったら実用性があると思った。
- 固有名詞 (ファミチキ) を使うのはOK？
- ゴールの説明がやや不足していると思いました
- それに対して適切なアプローチであるか判断しづらかったです。
- 今後のゴールを売上に関する要素を組み込んでいくことを明確に伝えるべき
- 例としてコンビニがあるがこれをどのように応用してスケールアップするか知りたい。
- 欠点があるのをどう改善していくのか知りたい。
- 成果物をどのような指標で評価してもらい、何をもちって良い成果物となるかをもう少し考えられると良いと思います。
- 後半に向けて focus したいポイントをより明確にすると良いと思います。

(※文責: 吉野颯真)

## 5.6 評価の考察と今後の改善

発表技術の意見について、評価された意見として、「難しい内容をわかりやすくしようという意思が伝わってきてよい」、「時間内に発表できていてよい」、「デモを用意してよい」、「スライドの構成や図がわかりやすかった」という意見が挙げられた。一方で否定的な意見として「初めて聞く前提がわからない人の為の評価基準並びに実績の説明の為にも、課題解決のテーマをもう少し丁寧に説明したほうがよい」、「声が周りに負けていた」、「もう少しゆっくり話したほうが良い」、「スライドの情報量が多く見えづらいところがあった」といった意見も挙げられた。このことから、プレゼンテーションやスライドを活用して、専門的な知識が必要な数理モデルというテーマを分かりやすくしようということが評価された。また一方で、成果発表会当日のプレゼンテーションにおいて、課題背景の説明がわかりにくい、声が小さく聴きづらいことや、早口で聴きにくいことが問題点として挙げられた。今後の改善案として、課題背景の説明に重点を当てたプレゼンテーション、大きな声で発表する練習、ゆっくりとゆとりをもって発表する練習が挙げられる。

(※文責: 吉野颯真)

## 第 6 章 成果発表

本節では成果発表のための準備、成果発表の当日、いただいたフィードバックの評価について振り返る。

(※文責: 石井健太)

### 6.1 成果発表の準備

本プロジェクトは、成果発表会にあたってスライドとポスターを作成した。スライドは発表資料として、ポスターは補助的な資料としてそれぞれ用いた。最初に、ポスターとスライドの軸となるアウトラインをプロジェクトメンバー全員で話し合いを行ったのち、決定した。アウトラインとして、課題とその背景、課題を解決するための手法、作成した数理モデルの説明、作成したシステムの説明、店舗での検証とその結果、考察と今後の展望の 6 項目で構成した。その後、プロジェクトメンバーをスライド作成班、ポスター作成班、発表班に分かれ作業をした。

スライドはスライド作成班である石井朗偉、多田、吉野が中心となって作成した。スライド作成は Canva を使用した。また作成した数理モデル、検証に用いた機械学習、Web アプリケーション、検証から得られたデータの比較を説明するスライドの作成に関しては、それぞれ担当したプロジェクトメンバーが作成した。作成したスライドを基に発表班である石井朗偉、多田、吉野が発表を行い、担当教員、プロジェクトメンバー、TA からフィードバックを貰った。フィードバックでは「スライドのページ数が多く、時間内に発表できない」「各ページの論理的なつながりがおかしい」「モデルやグラフが分かりづらい」等の改善すべき点が多く挙げられた。これらのフィードバックを基に、スライドの修正を行った。修正した点は、スライドのページの削減、ページとページ間の論理性の確認と変更、作成した Web アプリケーションの説明をスライドから動画への変更等である。

ポスターはポスター作成班である佐野が中心となって作成した。ポスター作成は Google Slide を使用した。作成にあたっては中間発表の際と同様の形式で行った。言語は日本語と英語である。ポスター作成はスライド作成と並行して行った。

発表練習は発表班である石井朗偉、多田、吉野が作成したスライドを基に行った。発表練習は 2024 年 11 月 22 日から成果発表会までの約 2 週間、発表練習とスライドの修正を同時並行で行い、発表の調整を行った。また発表内容の台本を作成し、発表班で共有、改善を行った。

(※文責: 石井健太)

### 6.2 当日について

2024 年 12 月 6 日の金曜日に、プロジェクト学習成果発表会にて、本プロジェクトの成果発表を行った。発表時間 10 分、質疑応答 5 分の時間配分で 3 回発表を行った。1 回目の発表は石井朗

偉, 小久保, 佐野の3名が担当し, 2回目の発表は吉野, 新田, 石井健太の3名が担当した. 3回目の発表は多田, 今, 六本木の3名が担当した. 発表は予定していた通りスライドとポスターを用いて発表を行った. 当日は31名が来場し, フィードバックや質問をいただいた.

(※文責: 新田龍太郎)

### 6.3 発表評価について

成果発表会当日に関するアンケートを, Google Forms を用いた評価シートにより実施した. アンケートの評価項目は, 発表の聴きやすさ・スライドの見やすさ・内容のわかりやすさなどの「発表技術の評価」と, 内容の興味深さ・将来性などの「発表内容の評価」の2項目である. 回答者は公立はこだて未来大学の学生と教員, 外部参加者を含む31名であった. この2項目は1(非常に悪い)から10(非常に優秀)の10段階評価と自由記述のコメントからなる. また, アンケートの結果として, 発表技術の評価の平均は  $m = 8.29$ (有効回答数  $N = 31$ , 標準偏差  $SD = 1.37$ ) であり, 発表内容についての評価の平均は  $m = 8.52$ (有効回答数  $N = 31$ , 標準偏差  $SD = 1.43$ ) であった. 「発表技術の評価」の評価と人数のヒストグラムを図 6.1 に, 「発表内容の評価」のヒストグラムを図 6.2 に示す.

(※文責: 新田龍太郎)

### 発表技術の評価




図 6.1 発表技術についてのヒストグラム. 横軸が評価の点数, 縦軸が人数を表す

### 発表内容の評価




図 6.2 発表内容についてのヒストグラム. 横軸が評価の点数, 縦軸が人数を表す

## 6.4 発表技術コメント

### 6.4.1 肯定的な意見

- 分かりやすかった.
- よかった
- 堂々とした発表で良かったです.
- 時間内で発表ができていて良かった.
- デモを用意していて良かったと思います. プレゼンも, 少し詰まる部分はありましたがよくまとまっていたと思います.
- スライドの構成や図がわかりやすかったです.
- 難しい内容だが, 分かりやすくしようという意思がスライドや発表内容から伝わって良かった.
- 実施調査でベテランが売り上げを予測できない時間に使っていることがまさにニーズに沿ったものを作っているなと思いました.
- スライドがとてもわかりやすかった
- スライドが見やすく, 専門的な知識が少なくても聞きやすい発表でした.
- スライドのデータの図が良かった.
- 聞こえやすい声量とわかりやすいスライドでした.
- 難解な数式を, コンテキストを与えて分かりやすく説明されていて, 意味がよくわかった.
- ハキハキ喋って聞きやすかったです, スライドも見やすくするための工夫がされて良かったです
- デザインも良かったし, 聞きやすかった.
- スライド1枚1枚は見やすい
- スライドとてもきれい. 声の大きさもちょうど良い
- 計算式が難しかったです (大学だからそれなりのレベルを超えているのは理解していたけどそう思いました)
- それぞれが細かい数理モデルを素人にもわかりやすいように説明されていて理解しやすかった
- スライドが見やすくて, 分かりやすかった. 難しい話を結果に基づいて誰でも分かるように簡単に説明されていた.
- 声が大きく聞こえやすい, 実際に説明する部分を指していることで分かりやすい.
- グラフなどが上手く色分けされていて, 初見でもかなり見やすいスライドとなっていてよかった. 発表者の声量も良くて Good
- とても聞きやすい発表とスライドでした. 適宜, 指し棒をつかうことで目線の誘導が有り難かったです.
- 全体的に聴きやすくわかりやすかったです.
- 図が多く用いられておりわかりやすかったです.
- 声は通っていて聞こえやすかったです.

## 6.4.2 否定的な意見

- 周りに声が負けていた。
- スライド間の関係性が今ひとつ論理的ではない感じがありました
- もう少しゆっくり話した方がよかったです。
- シンプルで見やすいが、1スライドに内容を詰め過ぎている気がして追いつけなかった部分がある。
- 少しスライドの文字が多く、見づらい所があった。
- 画面を向いて話されてる時の声は聞こえなかったです。何のデータを用いた微分なのか等、微分の説明は詳しく知りたかったのもう少し大きくスライドに表示されると読みやすかったかなと思いました。
- スライド一枚の情報量が多いように感じました。
- 最初に来客数の予測に重回帰が使われていた部分について、やや帰納バイアスが強すぎないか気になりました。これらの時系列を取り込むなど、何か試したことがあったなら比較なども含めると良かったかもしれません。
- 1人で一気に説明するのではなく、2人で分けた方が良かった。また初めて聞くような前提が分からない人にも、課題解決のテーマをもう少し丁寧に説明した方が評価基準並びに実績の説明に繋がるかと思う。加えてどこを説明しているか、指し棒も使った方がプレゼンらしくなります。
- 題材として取り上げていただきありがとうございました。グラフや数式だけでなく、実際の稼働のイメージ画像があればなお良かったと思います。

(※文責: 石井健太)

## 6.5 発表内容コメント

### 6.5.1 モデリング関係

- モデルの評価を知りたいと思う。どれだけ現場に添っているのかが知りたいと思う
- ファミチキが買われる過程を細かく分析して、式に落とし込んでいてすごいと思いました。
- どのように補充数や補充のタイミングをどのように決めているのかがわかりづらいと感じた
- ファミチキの仕込みを数理モデル化するのは面白い発想だと思った。他の仕込みが必要なものにも適用できるか検証してほしい。
- 廃棄数が得られなかった影響で、廃棄数の数理モデルの測定ができなかったのは残念だったと思います。けど諦めないで売上の測定をし、ちゃんと結果出しているのは凄いと思いました。
- 購買仕込みモデルがよく推定されていて、来客数予測にAIが活かされていて問題解決につながりそうだと感じた。実地検証も行っていて、今後の展望にそのときの課題が反映されていた。
- タイトルでとても興味深いと思いました。実際にどのように重回帰分析したのか知りました。

かったです。

- 時間的に難しかったかもしれませんが、モデルの説明はもう少し分かりやすくて良かったかなと思います。曜日と天気由来客数がどれくらいの精度で予測出来たのか気になりました。
- 数理モデルの式の説明やスライドは難しいかもしれませんが改善の余地ありかもしれません。あまりよく分かりませんでした。
- 全体的にとっても分かりやすかったです。強いて言うなら、モデルについてももう少し詳しく説明が欲しかったです。

### 6.5.2 実装関係

- どうして飽きられたのかの分析がもう少し必要かなと感じました。BtoBのこのような便利なシステムの利用は飽きられたどうかではなく、使いやすいか使いにくいかな、かと思うので、そこが要因であるのは非常にもったいないと感じました。お疲れ様でした！報告書がんばってください
- 店員さんともっとディスカッションして、ユースケースを詰めるといいと思いました。本当に欲しいのは予測した個数なのか？もしかしたら、どのくらいお客さんが来そうかだけでもいいのかもしれない？など。
- 経験則とかが統計などを用いて数学的に表されているのがすごく興味深いなあと思った。
- もしも試していなければ、定点カメラや湿温計などを収集するIoTデバイスから時系列を取得したりするなど、いろいろと展開が考えられるように思いました。

### その他

- 分かりやすくまとめられていた
- よかった
- 掲げた目的に対しての結果を知りたかった。(売り上げを上げたい。廃棄率を下げたいなど)
- 実際の店舗と協力していたのが良いと思った
- とても実用的、実社会に関わるプロジェクトで良いと思った。
- 発表の中で興味深い議論が展開されていて、面白かったです。
- 目的に資するために何をやったかを、もっと明確に提示できると良い
- 実際にアプリをつくって、実際に使ってもらったところまでいったのがすごい。数理モデルの式書いてあると、それっぽくなりますねやっぱり
- 中間の時からすごく進んでいて良いと思いました
- 少し声が聞きづらかったのもうちょっと声を張ってほしいです。
- 内容はとてもよかった自分はファミチキの質感をあまり重視せず買うが、そこが気になった。
- 最初に何をしたかを説明し、その後どのようにしたかを説明する流れが綺麗で素晴らしかった。
- 食品ロスと新人教育の二つの観点から意義があることに納得しました
- ファミチキの仕込みについて考えているのが面白かった。自分もコンビニでバイトしているので、17時以降のホットスナックの仕込みの予想が難しいことに共感できた。自分も使

いたいなと思った。

- 実装できるととても魅力的な案だと思いました。駅の近くや高校、大学の近くなどは他の場所に比べ使用率が高くなると思うので仕込み数の判断材料になると思いました。店舗ごとに対応して仕込み数の提案ができたり、ベテラン従業員が自分でマニュアルを更新できるようなプログラムがあれば、より汎用性が高くなると思いました。
- 一つの商品を掘り下げて分析していたことに感心しました。
- 初回なので次回に繋がる課題が見えたこと、評価基準や条件選択を見直して再度取り組んでみて欲しい。

(※文責: 新田龍太郎)

## 6.6 発表評価について

成果発表会当日に関するアンケートを、Google Forms を用いた評価シートにより実施した。アンケートの評価項目は、発表の聴きやすさ・スライドの見やすさ・内容のわかりやすさなどの「発表技術の評価」と、内容の興味深さ・将来性などの「発表内容の評価」の2項目である。回答者は公立はこだて未来大学の学生と教員、外部参加者を含む31名であった。この2項目は1（非常に悪い）から10（非常に優秀）の10段階評価と自由記述のコメントからなる。また、アンケートの結果として、発表技術の評価の平均は  $m = 8.29$  (有効回答数  $N = 31$ , 標準偏差  $SD = 1.37$ ) であり、発表内容についての評価の平均は  $m = 8.52$  (有効回答数  $N = 31$ , 標準偏差  $SD = 1.43$ ) であった。「発表技術の評価」の評価と人数のヒストグラムを図6.1に、「発表内容の評価」のヒストグラムを図6.2に示す。

(※文責: 新田龍太郎)

## 6.7 評価の考察と今後の改善

### 6.7.1 発表技術

発表技術の意見について、評価された意見として、「難しい内容をわかりやすくしようという意思が伝わってきてよい」、「時間内に発表できていてよい」、「デモを用意してよい」、「スライドの構成や図がわかりやすかった」という意見が挙げられた。一方で否定的な意見として「初めて聞く前提がわからない人の為の評価基準並びに実績の説明の為にも、課題解決のテーマをもう少し丁寧に説明したほうがよい」、「声が周りに負けていた」、「もう少しゆっくり話したほうが良い」、「スライドの情報量が多く見えづらいところがあった」といった意見も挙げられた。このことから、プレゼンテーションやスライドを活用して、専門的な知識が必要な数理モデルというテーマをわかりやすくしようということが評価された。また一方で、成果発表会当日のプレゼンテーションにおいて、課題背景の説明がわかりにくい、声が小さく聴きづらいことや、早口で聴きにくいことが問題点として挙げられた。今後の改善案として、課題背景の説明に重点を当てたプレゼンテーション、大きな声で発表する練習、ゆっくりとゆとりをもって発表する練習が挙げられる。

(※文責: 石井健太)

## 6.7.2 発表内容

発表内容については、本プロジェクトの社会的な意義を期待したコメントが多く寄せられたと考える。興味をもったこととして、「モデルの評価を知りたいと思う。どれだけ現場に添っているのかが知りたいと思う」に代表されるように、モデルの詳細な内容・精度評価や、現場の需要に対する解決策としての妥当性、ファミチキ以外の商品での適用可能性が寄せられた。好印象を受けたこととして、「ファミチキが買われる過程を細かく分析して、式に落とし込んでいてすごいと思いました。」に代表されるように、現象を数式化する数理モデルとしての面白さや、「実際にアプリケーションをつくって、実際に使ってもらうところまでいったのがすごい。数理モデルの式書いてあると、それっぽくなりますねやっぱり」に代表されるように、現実の課題解決への期待がおもに寄せられた。これらから、モデルや実地検証の成果については、興味をもったこと・好印象を受けたことの両方で寄せられた点で、より詳細な内容の発表が求められたといえる。一方で、「数理モデルの式の説明やスライドは難しいかもしれませんが改善の余地ありかもしれません。あまりよく分かりませんでした。」に代表されるように、数学としての難しさについても多く寄せられた。この点では、発表内容のさらなる改善の余地があるとともに、たとえばその後理解できるような参考資料の提示が可能と考える。実用におけるコメントが多く寄せられた点で、今後はシステムの妥当性のさらなる検証や、補助としてのデバイスの導入、スケーラビリティの評価が必要と考える。

(※文責: 新田龍太郎)

## 第7章 まとめ

### 7.1 活動の総括

活動の総括として、本プロジェクトで取り組んだ課題、習得した技術、作成した成果物、中間発表会及び成果発表会、通年の活動について述べる。

背景と課題として、コンビニは現在、人口減少による売上の頭打ちや人手不足、人件費や電気代などの運営コストの上昇、大量の食糧廃棄が挙げられる。その結果、特定の従業員に業務やシフトが集中しやすくなり、属人性が高まる傾向にある。この属人性は、業務の効率化を妨げるだけでなく、さらに負担を集中させる悪循環を引き起こす要因となっている。特にホットスナックの仕込みは経験に依存しやすく、ファミチキの仕込み業務がその典型例である。このファミチキの仕込みに関する属人性の課題を解決するため、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て、活動に取り込んだ。

本プロジェクトの到達目標に必要な技術について述べる。まず、基礎として微分方程式を用いた数値計算の輪講を行った。具体的には、オイラー法やルンゲ・クッタ法を手書きで数値計算し、その後プログラミングで実装することによって数値計算の理解を深めた。輪講では、各回2人が担当し、講義形式で進めた。この活動は、学びを深めるだけでなく、発表スキルの向上にもつながる有意義なものであった。

次に、本プロジェクトが開発した成果物「仕込み支援システム」について述べる。まずは、来客数予測である。気象情報や過去1年間の来客数データを用い、重回帰分析を使って時系列ごとの来客数を予測した。次に自作の数値モデルである購買-仕込みモデルで、来客数、仕込み意欲、陳列数、購買意欲の4つの変数の相互作用を考慮しモデル化したものである。最後に、仕込み数の最適化である。複数の仕込み数に購買-仕込みモデルを適用し、数値計算の結果を比較して最適なものを決定した。比較には売上、仕込み時間、来客数、廃棄数に関する4つの評価基準を定めた目的関数を用いた。これらの予測結果を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。

開発後は構築した数値モデルの有用性を調べるため、実地検証を行った。比較として機械学習による売り上げ予測モデルを用意し、それぞれ1週間程度店舗にタブレット端末を設置した。Webアプリケーションに関するアンケートによる定性的評価と、売上数と来客数データから売上率を算出する定量的評価を行った。アンケート結果から、アプリの使用頻度にはばらつきがあり、時間経過とともに使用頻度は減少していることがわかった。また、夜間にはアプリケーションが有効に活用された一方、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。

続いて、本プロジェクトが行った中間発表会及び成果発表会について述べる。中間発表会の評価アンケートの結果の平均は、発表技術が10点中8.6点、発表内容が10点中8.1点だった。自由記述では、説明がわかりやすく、話すスピードがちょうど良いとのコメントをいただいた。一方で、モデルの説明がわかりづらい、ゴールの説明が不足しているとの指摘もあった。成果発表会の評価アンケートの結果の平均は、発表技術が10点中8.29点、発表内容が10点中8.52点であっ

た。自由記述では、声が聞き取りやすく、スライドがわかりやすいとのコメントをいただいたが、モデルの説明が不足しているとの指摘が見られた。今後の学外発表に向けて修正していきたい。

最後に通年の活動についてのまとめと総合的な評価について述べる。本プロジェクトでは数値計算の基礎の学習から始まり、購買-仕込みモデルの構築、機械学習の活用、Web アプリケーションの開発と実地検証に至るまで、多岐にわたる技術を習得することができた。各段階で得られた知見は、実践的なスキルの向上とともに、チームでの協力やプレゼンテーション能力の向上にも寄与した。また、実地検証と発表会を通じて、現場のフィードバックを得ることができたことは、プロジェクトメンバーにとって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。

(※文責: 佐野大翔)

## 7.2 今後の展望

本プロジェクトでは、ファミチキの仕込み業務における属人性を排除するため、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「仕込み支援システム」を開発した。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。

(※文責: 佐野大翔)

## 謝辞

本プロジェクトの遂行にあたり, 多大なるご支援とご指導をいただきましたファミリーマートの皆様に深く感謝申し上げます. 特に, プロジェクトの各段階での貴重なご意見と協力に感謝いたします.

(※文責: 小久保尚)

## 参考文献

- [1] 経済産業省. 2020. 「新たなコンビニの在り方検討会」報告書～令和の時代におけるコンビニの革新に向けて～. [https://www.meti.go.jp/shingikai/mono\\_info\\_service/new\\_cvs/pdf/20200210\\_report\\_00.pdf](https://www.meti.go.jp/shingikai/mono_info_service/new_cvs/pdf/20200210_report_00.pdf)
- [2] 橋本 修・毛塚 敦. (2021). Python による数値計算法の基礎. 森北出版.
- [3] 長山 雅晴・松永 哲. (2020). 数理モデルに対するパラメータ推定. [https://mmc01.es.hokudai.ac.jp/wp/wp-content/uploads/2020/06/Intro\\_Para\\_Estimation.pdf](https://mmc01.es.hokudai.ac.jp/wp/wp-content/uploads/2020/06/Intro_Para_Estimation.pdf)
- [4] 吉村 芳弘. (2022). 差分の差分法 (difference in differences) — 介入前後のデータから効果を検証 —. The Japanese Journal of Rehabilitation Medicine. 2022, 59, 11, 1093-1099
- [5] Amazon Web Services, Inc. 2024. AWS シンプルアイコン - AWS アーキテクチャーセンター. <https://aws.amazon.com/jp/architecture/icons/>
- [6] 寺嶋 一彦, 兼重明宏. (2012). 制御工学 — 技術者のための、理論・設計から実装まで —. 実教出版