

人口統計データを用いた高需要時の飲食店需要予測

篠田 謙司¹ 山田 将人² 高梨 元樹³ 長谷川 大輔³ 坪井 哲也³ 深澤 佑介^{2,a)} 木本 勝敏²

受付日 2021年4月10日, 採録日 2021年10月8日

概要: 飲食店において売上などの需要を予測することは、スタッフのシフトスケジューリングや店舗の事前準備を行ううえで重要なタスクである。特に、イベント開催や天候変動を契機として通常より高い売上が発生する高需要状態を事前に予測することが求められている。本研究では、過去の売上データに加え人口統計データを用いることで、高需要状態での予測精度を改善する手法を提案する。提案手法では、売上予測のモデルと、将来需要が高くなるか低くなるかを判断するモデルの2つのモデルの結果を組み合わせることで売上予測を行う。飲食店における実売上データを用いて予測精度を評価した。その結果、従来手法と比較して、高需要時の需要予測精度が1.45%向上することを示した。

キーワード: 飲食店需要予測, 機械学習, 人口統計

Prediction of Restaurant Sales Using Population Statistical Data

KENJI SHINODA¹ MASATO YAMADA² MOTOKI TAKANASHI³ DAISUKE HASEGAWA³ TETUYA TSUBOI³
YUSUKE FUKAZAWA^{2,a)} MASATOSHI KIMOTO²

Received: April 10, 2021, Accepted: October 8, 2021

Abstract: Predicting the future sales volume is a critical task in operating a restaurant as it helps to determine the number of staff and ingredients to have at any time and decide when to start preparing food. Future sales can typically be predicted according to the demand cycle; however, it is difficult to predict an immediate increase in demand because it is out of the demand cycle. To tackle this issue, this study proposes a method for predicting the next-hour future sales volume based on population statistics data, in addition to historical sales and current and historical weather data. The proposed method combines the results of two models, one predicting the sales volume, while the other determining whether the future demand will become high or low. The proposed method was evaluated using actual restaurant data collected in collaboration with a major Japanese restaurant company. The results demonstrate that the prediction accuracy can be improved by 1.45% compared to the prediction model of sales volume without combination of demand classification when the sales volume is high.

Keywords: restaurant demand forecasting, machine learning, population statistics

1. 背景

飲食店において、いつどれくらい顧客が来店するかという来店需要の予測は、店舗運営における重要なオペレーションの1つである。たとえば、来店需要の高低によって、

スタッフのシフトスケジュール、食材の調達量や調理を開始する時間などは大きく変動する。実際よりも大きく需要があると予測してしまうと、人的コストの増加や食品の廃棄量の増加を招く恐れがある。また、実際よりも過小に需要を予測してしまうと、顧客を長時間待たせる、食材が足りなくなるなどにより、来店および注文の機会損失につながる恐れがある。

定常の需要が続く場合は、過去の売上実績をもとに自ら予測を立て、その予測結果をもとに効率化を図ることが可能である。しかし、来店需要は、天候や、周辺のイベントにより突然需要が変動する場合がある。特に突発的な高需

¹ 株式会社ドコモ・インサイトマーケティング
DOCOMO InsightMarketing, INC., Toshima, Tokyo 170-0013, Japan

² 株式会社 NTT ドコモ
NTT DOCOMO, INC., Chiyoda, Tokyo 100-0014, Japan

³ 株式会社サイゼリヤ
Saizeriya Co., Ltd., Yoshikawa, Saitama 342-0008, Japan

a) fukazawayu@nttdocomo.com

要が発生してしまうと、店内準備や指示出しに支障が生じ、料理の提供が遅れたり待ち時間が長くなったりすることで、顧客のロイヤリティ低下につながる。また、このような突発的な高需要が頻発すると、スタッフに過度な負担がかかる恐れもある。さらに、COVID-19の影響を受けて、飲食店においては感染症対策にともなうオペレーションが増加しており [1]、高需要時のスタッフにかかる負荷はさらに増すと考えられる。

近年、このような飲食店の需要予測の問題において、機械学習を用いた予測がさかに行われている。しかしながら、売上の周期的な変動に着目した研究がほとんどであり、高需要の店舗来店需要の予測に関する研究はない。本稿では、過去の店舗の売上データと、人々の位置情報から生成された人口統計データを用い、特に高需要状態に着目し店舗ごとに売上を予測する機械学習アルゴリズムを提案する。

本研究における貢献内容は次の3点である。

- (1) 定常の需要状態を予測するモデルに加え、人口統計データを入力とした高需要を予測可能な予測モデルを構築したこと
 - (2) 定常の需要状態を予測可能なモデルと、高需要を予測可能なモデルの出力結果から、現在の状態が高需要にあるか低需要にあるかを判断し、その状態に応じて売上予測結果をアンサンブルする手法を提案したこと
 - (3) 実データによる精度評価を行い、提案手法が高需要の時間帯において予測精度が改善することを示したこと
- また本研究では1時間後における売上需要の予測を行った。1時間後の予測においても店舗運営の効率化につながる理由について述べる。1時間後の予測により当日スタッフのスケジュール調整や調理準備を行うことができ、円滑な店舗運営を図ることができる。特に高需要が予測されるケースにおいては、前者はたとえばシフトの延長対応、後者は料理提供の律速となる米類の準備判断につながり、稼働調整や作り過ぎによる廃棄の軽減に役立てることができる。

本稿の構成は次のとおりである。2章で関連研究について述べる。3章で人口統計データについて説明する。4章で提案手法について述べる。5章で評価実験の概要と結果について説明する。6章で結論を述べる。

2. 関連研究

小売店や飲食店の需要予測に関する従来研究について述べる。CranageらはBox-Jenkins法と指数平滑化法を用いて店舗の売上を予測した [2]。Liuらは、実際の商品の販売状況と気象データを用いて、商品の売れ行きを予測する手法を提案している [3]。Chenらは機械学習を用いてコンビニエンスストアの売上を予測し、生鮮食品の在庫問題を解決した [4]。Yangらは、1,000万点以上の販売データを用いて数時間後の売上を予測し、注文プロセスの最適化を図っ

ている [5]。Maらは、プロモーション情報を分析し、小売業における商品販売量を予測している [6]。また、Kanekoらは、ニューラルネットワークを用いて、顧客の時系列の購買データを基に売上を予測した [7], [8]。Müller-Navarraらは、RNNを実際の販売データに適用した [9]。Gieringは、店舗レベルでの顧客属性を用いて、小売店の売上予測を行った [10]。Aliらは、売上数値の予測だけでなく、その結果を解釈可能な予測手法を提案している [11]。

しかし、これら既存研究による手法の多くは、売上変動の周期性に注目しており、定常時の売上を予測するモデルである。店舗運営上、非常に重要な課題となっている、突発的なイベント開催や天候変動を契機とした高需要時の予測は対象としていない。一般に、高需要時を重視した予測モデルを構築すると、全体の精度を大きく劣化させてしまう可能性がある。本研究では、人口統計データを活用することで、通常時の需要予測精度を損なわず、突発的な高需要時の予測精度を改善する手法を提案する。

3. 人口統計データ

本研究では、人口統計データとして、株式会社NTTドコモが提供する「国内人口分布統計（リアルタイム版）」 [12] を利用する*1。本データは、携帯電話ネットワークの仕組みを利用して人口を推定した人口統計データである。モバイル端末と基地局の位置関係から、東京都内では、500mの空間解像度、10分ごとの時間解像度で年代別で人口推定が可能であり、モバイルネットワークのデータから、日本の実際の全人口の推定を行ったデータとなる [12], [13]*2。人口統計データは、タクシースの需要予測 [14], [15]、バイクシェアサービスにおける自転車再配置 [16] や東京湾アクアラインの混雑予測 [12] などの交通に関する課題解決に活用




図 1 時間ごとの売上値と人口の時系列グラフ

Fig. 1 Time-series of the sales volume and population dynamics.

*1 https://www.nttdocomo.co.jp/info/news_release/2019/12/03.00.html

*2 本実験で使用する人口統計は、エリアごとや属性ごとの集団の人数を示す情報であり、個人を特定できる情報をいっさい含まない。また、モバイル空間統計ガイドラインを遵守している。モバイル空間統計ガイドライン https://www.nttdocomo.co.jp/corporate/disclosure/mobile_spatial_statistics/guideline/index.html

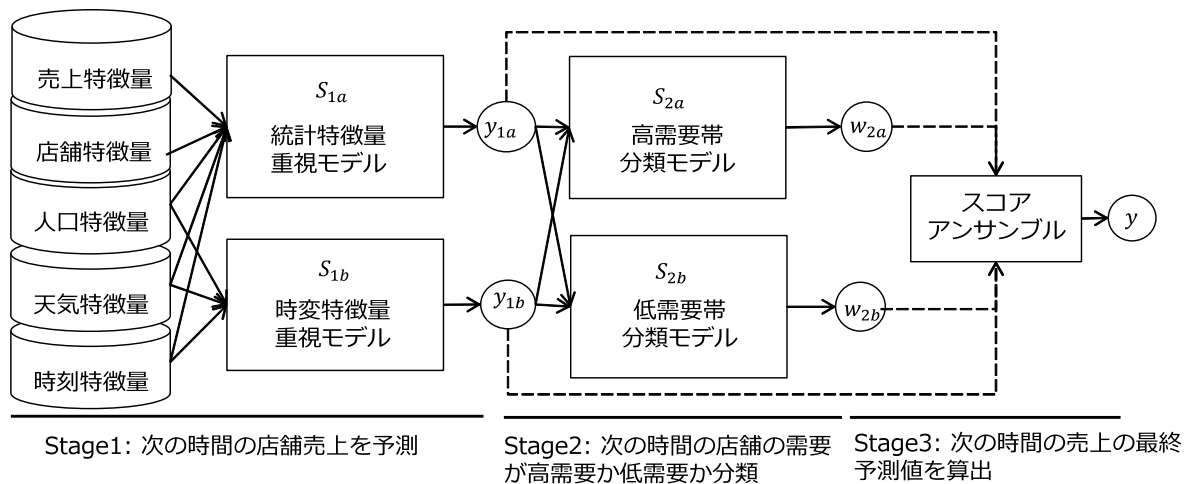


図 2 提案手法の全体像

Fig. 2 Proposed architecture.

されている。

飲食店の需要増と人口増減の関係を調べるために、イベントが多発する施設近辺の店舗で、ある期間で売上値と人口の変動を描画したものを図 1 に示す。赤枠で示すとおり、定常状態に対して人口が増大したときに、売上もふだんより増大していることが分かる。この結果は、人口統計データを用いることで高需要帯の精度向上を図れる可能性があることを示唆している。

4. 提案手法

4.1 アプローチ

1章で述べたように、店舗運営においては、高需要時の来店需要を予測することが重要であるが、高需要時を重視したモデルを構築すると、全体の精度を大きく劣化させてしまう課題がある。本研究では、定常時の来店需要を予測するモデルと、高需要時の来店需要を予測するモデルとをそれぞれ構築する。そして、これらのモデルを将来の需要状態に応じた重みで組み合わせることで最終的な売上予測を行う。たとえば、将来高需要と予測された場合は、高需要の来店需要を予測するモデルの重みを重くする。一方で、将来低需要と予測された場合は、定常状態の来店需要を予測するモデルの重みを重くする。これにより、定常時の来店需要の予測精度を大きく損なわずに、高需要状態での予測精度を改善する効果が期待できる。

4.2 提案手法の全体構成

提案手法の全体構成を図 2 に示す。提案手法は、次の 3 つの Stage から構成されている。Stage1 では、過去の売上データ、人口統計データ、店舗周辺の天候の特徴などを特徴量として、次の 1 時間後の店舗の売上を予測する。高需要時のモデルと定常時のモデルの 2 つの回帰モデルを構築する。Stage2 では、次の 1 時間が高需要の時間帯か、低需要の時間帯かを予測する。具体的には、Stage1 で予測した

1 時間後の売上を特徴量として、高需要の時間帯か低需要の時間帯かを分類する。高需要時の分類を行うモデルと低需要の分類を行うモデルの 2 つの分類モデルを構築する。Stage3 では、Stage1 の 2 つの回帰モデルの出力を Stage2 の出力結果を重みとして組み合わせることで、最終的な売上を予測する。学習、推論の両方に関わるものは実線、推論のみに関わるものは点線で示した。モデルは、学習データを量的に確保し汎化性を向上させることを目的として、全店舗の売上データを学習対象とし、全店舗共通モデルとして作成している。

4.3 Stage1：統計特徴量重視モデル/時変特徴量重視モデル

Stage1 では、2 つの回帰モデルにより、次の 1 時間後の店舗の売上を予測する。1 つ目は定常状態の予測に適している統計特徴量重視モデル S_{1a} であり、2 つ目は、高需要時の予測に適している時変特徴量重視モデル S_{1b} である。

特徴量としては、時刻情報の特徴量、売上の特徴量、店舗情報の特徴量、人口統計データの特徴量および天候の特徴量を設計した。それぞれの特徴量を表 1 に示す。なお全店舗共通モデルを作成するため、事前に学習期間に相当する各種データソースから店舗やメッシュ、時間帯ごとに平均値と標準偏差を計算し、データの全期間にわたって標準化を行ったうえで、特徴量を作成している。差分をとるような場合においては、差分を計算した後の値に対して標準化を行っている。また、時刻情報の特徴量、売上の特徴量、人口統計データの特徴量については次節以降で詳細について説明する。表 1 に示すように、 S_{1a} は、特徴量すべてを用いて学習を行ったモデルである。一方、 S_{1b} は一部の売上の特徴量を除くことにより過去の売上の影響を減らして将来の売上を予測するモデルとなっている。 S_{1b} では高需要時の需要を適切に予測するようなモデリングを意図しているが、売上特徴量がまったく入っていないモデルで

表 1 Stage1 の統計特徴量重視モデル/時変特徴量重視モデルで利用する特徴量一覧
Table 1 List of features used in predicting the next-hour sales volume (Stage1).

特徴量	S_{1a}	S_{1b}	定義	特徴量数
時刻特徴量	✓	✓	予測対象日 D_{target} の曜日 DW_{target}	7
	✓	✓	予測対象時刻 H_{target}	2
売上特徴量	✓		過去 1 年間の曜日 DW_{target} , 時刻 H_{target} における店舗 R_{target} の売上の平均値, 標準偏差値, 最大値および最小値	4
	✓		過去 1 年間の時刻 H_{target} における店舗 R_{target} の売上の平均値, 標準偏差値, 最大値および最小値	4
	✓	✓	予測対象日の月 M_{target} の前月の店舗 R_{target} の売上の平均値, 標準偏差値, 最大値および最小値	4
	✓		予測対象日の前年同月 M_{target} , 曜日 DW_{target} における店舗 R_{target} の売上の平均値, 標準偏差値, 最大値および最小値	4
	✓		予測対象日 D_{target} の 2 週間前の店舗 R_{target} の売上	1
	✓		過去 1 年間の時刻 H_{target} , 同一の天気条件 (温度, 湿度, 雲量, 降雨量, 風速) における店舗 R_{target} の売上の平均値, 標準偏差値, 最大値および最小値	$5 \times 4 = 20$
店舗特徴量	✓	✓	店舗 R_{target} の情報 (席数, 駐車場の有無, 平均売上) を t -SNE [17] で 2 次元に圧縮	2
人口特徴量	✓	✓	時刻 $H_{target-1-t}$ と時刻 $H_{target-1-t}$ における店舗 R_{target} のメッシュの人口の差 ($t = 1, 2, 3, 4, 5, 6$)	$2 \times 6 = 12$
	✓	✓	時刻 $H_{target-1-t}$ における店舗 R_{target} のメッシュの人口と隣接 8 メッシュの平均人口との差 ($t = 1, 2, 3, 4, 5, 6$)	$2 \times 6 = 12$
	✓	✓	時刻 $H_{target-1-t}$ における店舗 R_{target} のメッシュの人口と, 時刻 $H_{target-2-t}$ における隣接 8 メッシュの平均人口の差 ($t = 0, 1, 2, 3, 4, 5$)	$2 \times 6 = 12$
天気特徴量	✓	✓	1 時間前 $H_{target-1}$ に店舗 R_{target} のメッシュで観測された温度, 湿度, 雲量, 降雨量, 風速	5
	✓	✓	1 時間前 $H_{target-1}$ における店舗 R_{target} のメッシュで観測された温度と, 前日 $D_{target-1}$ の時刻 $H_{target-1}$ に同メッシュで観測された温度との差	1

は予測対象である売上の周期的な振舞いを最低限とらえたような予測ができず, 大幅な精度劣化につながってしまう。そのため, 代表的な売上の特徴量のみ, S_{1b} では追加を行った。

4.3.1 時刻特徴量

時刻情報として, 予測対象日の曜日情報 (DW_{target}) および時刻情報 (H_{target}) を用いる。曜日情報は平日・休日判定, 翌日の平日・休日判定に基づいた 2 ビットの 1-of- k のデータで表現した。時刻情報は 0~23 時の形で用いると 0 時と 23 時が 1 時間差であるにもかかわらず大きな差を生じてしまう。本稿では, 下記式に基づいて時刻を (α, β) の 2 次元で表現した。

$$\alpha = \sin \frac{\pi}{12}t, \beta = \cos \frac{\pi}{12}t, \{0 \leq t < 24\}. \quad (1)$$

4.3.2 売上特徴量

POS システムに登録された注文日時と各商品の金額から, 1 時間ごとの売上合計金額に集計する。そして, 店舗, 季節, 曜日 (平日・休日・休前日), および時刻ごとに売上値の統計量 (平均値・標準偏差値・最大値・最小値) を計算し, これを売上特徴量とした。

4.3.3 人口特徴量

高需要時の売上予測の精度を向上するには, 店舗周辺の

人口変動や各時刻での気象情報を考慮することが重要である。特に人口データは周辺のイベント発生時には通常と異なる動きをすると考えられ, 高需要状態を予測する際に重要な因子となりうる。

予測対象時間と店舗周辺の人口動態の増減をとらえるために, 3 種類の人口差を特徴量として計算した。第 1 の特徴量として, 店舗のメッシュにおける人口動態の増減をとらえるために, 時刻 $t-1$ の店舗のメッシュと時刻 t の同じメッシュの人口差を算出した。第 2 の特徴量として, 時刻 t の店舗メッシュと, 同時刻の隣接 8 メッシュの平均値との間の人口差を計算し, 店舗メッシュへの流入もしくは店舗メッシュから流出する可能性を算出した。第 3 の特徴量として, 店舗のメッシュから人が流出もしくは店舗のメッシュへ人が流入する傾向をとらえるために, 時刻 t における店舗のメッシュと, 時刻 $t-1$ における隣接する 8 つのメッシュの平均との人口差を算出した。模式図を図 3 に示す。

4.4 Stage2: 高需要帯分類モデル/低需要帯分類モデル

Stage2 では予測対象の需要が高需要帯に属するかそうでないかを判別する高需要帯分類モデル S_{2a} と, 低需要帯に属するかそうでないかを判別する低需要帯分類モデル S_{2b}

表 2 Stage2 の高需要帯分類モデル/低需要帯分類モデルで利用する特徴量一覧
Table 2 List of features used in the classification of high and low demand (Stage2).

特徴量	S_{2a}	S_{2b}	定義	特徴量数
実売上の分布における予測売上の高/中/低需要分類	✓	✓	予測売上 y_{1a} および y_{1b} について式 (2) に示す需要分類の関数 $f(y_{1a}, \mu_{ac}, \sigma_{ac})$ および $f(y_{1b}, \mu_{ac}, \sigma_{ac})$ を計算. ここで, μ_{ac} と σ_{ac} は, 同曜日 DW_{target} , 同時刻 H_{target} における店舗 R_{target} の実際の売上の平均値と標準偏差を示す.	2
統計特徴量重視モデルの出力結果の分布における予測売上の高/中/低需要分類	✓	✓	予測売上 y_{1a} , y_{1b} について式 (2) に示す需要分類の関数 $f(y_{1a}, \mu_{y_{1a}}, \sigma_{y_{1a}})$ および $f(y_{1b}, \mu_{y_{1a}}, \sigma_{y_{1a}})$ を計算. ここで, $\mu_{y_{1a}}$ と $\sigma_{y_{1a}}$ は, 同曜日 DW_{target} , 同時刻 H_{target} における店舗 R_{target} の統計特徴量重視モデルによる予測売上 y_{1a} の平均値と標準偏差を示す.	2
事変特徴量重視モデルの出力結果の分布における予測売上の高/中/低需要分類	✓	✓	予測売上 y_{1a} , y_{1b} について式 (2) に示す需要分類の関数 $f(y_{1a}, \mu_{y_{1b}}, \sigma_{y_{1b}})$ および $f(y_{1b}, \mu_{y_{1b}}, \sigma_{y_{1b}})$ を計算. ここで, $\mu_{y_{1b}}$ と $\sigma_{y_{1b}}$ は, 同曜日 DW_{target} , 同時刻 H_{target} における店舗 R_{target} の統計特徴量重視モデルによる予測売上 y_{1b} の平均値と標準偏差を示す.	2
予測売上 y_{1a} と y_{1b} の差分	✓	✓	$y_{1a} - y_{1b}$	1

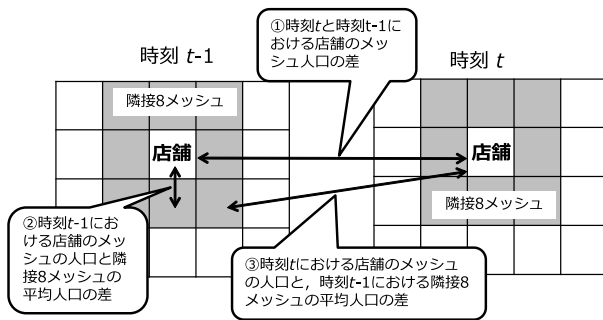


図 3 3 種類の人口差分特徴量の模式図

Fig. 3 Schematic diagram of the three types of population difference features.

を構築する. 本研究では高需要帯の精度向上を主目的としているが, 低需要帯に分類されるケースでは後段のアンサンブルにおいて大きな回帰値の影響を小さくしたい. その係数を得るために低需要帯に関する分類モデルとして S_{2b} を明確に構築する. S_{2a} と S_{2b} は互いに独立した機械学習モデルとして作成するため, どちらかの結果を真として採用するのではなく, 各モデルの出力値をアンサンブルの係数として用いて両方の結果を考慮する. 分類モデルを構築するため, 売上データを需要帯ごとのラベルに変換する. ここでは, 予測された売上を過去の売上の分布における位置に応じて, 低需要 (-1), 通常需要 (0), 高需要 (1) の値に変換する. 過去の売上の分布は平均値 μ , 標準偏差 σ の正規分布で表現される. 売上が y で過去の売上の平均が μ , 標準偏差 σ のとき, ラベルへの変換処理は次のように表される. ラベルの閾値は, 実際に店舗運営上の課題となるような高需要のケースを洗い出し, それらを含むように設定した. 設定した閾値によって, 全体の 10%程度が高需要と認められた.

$$f(y, \mu, \sigma) = \begin{cases} 1 & \text{if } y \geq \mu + 1.2\sigma \\ 0 & \text{if } \mu - 1.2\sigma \leq y < \mu + 1.2\sigma \\ -1 & \text{if } y < \mu - 1.2\sigma, \end{cases} \quad (2)$$

S_{2a} は, 店舗 R_{target} の次の 1 時間における売上を, 高い (ラベル = 1) かそうでない (ラベル = 0, -1) かに分類する. S_{2b} は, 店舗 R_{target} の次の時間における売上を低い (ラベル = -1) とそうでない (ラベル = 1, 0) に分類する. 特徴量は, Stage1 で得られた y_{1a} と y_{1b} を式 (2) に従って低需要 (-1), 通常需要 (0), 高需要 (1) の値に変換することで構築した. 特徴量のリストとその詳細な定義を表 2 に示す.

4.5 Stage3: 重みづけ線形和によるアンサンブル

Stage2 のモデルが出力する分類スコアを用いて Stage1 の回帰値のアンサンブルを行い, 次の時間の売上の最終予測値を作成する. 次式にアンサンブルの方法を示す.

$$\begin{aligned} z_1 &= w_{2a} \max(y_{1a}, y_{1b}) + (1 - w_{2a}) \min(y_{1a}, y_{1b}) \\ z_2 &= w_{2b} \min(y_{1a}, y_{1b}) + (1 - w_{2b}) \max(y_{1a}, y_{1b}) \\ y &= (z_1 + z_2) / 2 \end{aligned} \quad (3)$$

ここで, y_{1a} と y_{1b} は, それぞれ S_{1a} と S_{1b} の回帰出力を, w_{2a} と w_{2b} は, それぞれ S_{2a} と S_{2b} の分類スコア値を示す.

本研究では, 最終結果を, 式 (4) で計算される単純平均アンサンブルと, 式 (5) で計算される調和平均アンサンブルと比較した.

$$\frac{y_{1a} + y_{1b}}{2} \quad (4)$$

$$\frac{2y_{1a}y_{1b}}{y_{1a} + y_{1b}} \quad (5)$$

5. 評価実験

5.1 データセットの詳細

本稿では入力データとして、売上データ、人口データ、天候データの3種類のデータを用いて学習・検証を行った。店舗の売上データは、各予測タイミングに対して2週間前までに得られたPOSデータを、店舗ごとに集計し用いるものとする。天候データは、5kmグリッドで1時間後から39時間後までの降水量・雲量・気温などを予測するメソ数値予測モデルMSMデータを用いた。各データの詳細を表3に示す。特徴量作成の期間、学習期間および評価期間は図4に示すとおりである。

学習モデルとして、PythonのライブラリLightGBM[18]を採用した。パラメータはランダムサーチにより最適化を行った。結果として、 S_{1a} と S_{1b} に対して、 $learning_rate = 0.02$, $objective = regression_l2$, $metric = rmse$, num_leaves

表3 データの詳細
Table 3 Detail of datasets.

データ種別	カテゴリ	内容
対象地域	—	関東近郊
期間	—	2016年5月1日から 2018年11月1日まで
売上データ	店舗数 取得頻度 空間粒度 時間粒度	347店舗 2週間ごと 店舗 1時間
人口統計データ	解像度 取得頻度 空間粒度 時間粒度	500m 10分ごと 500mグリッド 10分
天候データ	解像度 取得頻度 空間粒度 時間粒度	5km 毎日0次から3時間ごと 5kmグリッド 1時間



図4 特徴量生成、学習および評価の期間

Fig. 4 Period of feature engineering, learning and evaluation.

$= 85$, $max_depth = 15$ を設定した。 S_{2a} と S_{2b} について、 $learning_rate = 0.02$, $metric = auc$, $num_leaves = 20$, $max_depth = 5$ とした。ここで $learning_rate$ は学習率、 $objective$ は目的関数、 $metric$ は評価指標、 num_leaves は木の分岐の個数、 max_depth は最大の木の深さである。また $regression_l2$ とは誤差関数が2乗誤差の目的関数を選択すること、 $rmse$ は回帰における評価指標が平均平方二乗誤差であること、 auc は分類の評価指標がROC曲線の下部の面積から計算されるものを用いることを意味する。

5.2 評価指標

本研究では、評価指標として平均絶対誤差(MAE)を用いた。定義を次式に示す。

$$MAE_P = \frac{1}{\#P} \sum_{i \in P} |\hat{y}_i - y_i|, \quad (6)$$

ここで、 \hat{y}_i と y_i は、それぞれ売上の実績値と予測値を表し、 P は売上データ数を表す。本稿では評価区分を、全体需要に対する評価、高売上時の評価、高予測時の評価の3区分で行う。3区分ごとに異なるデータ集合 P が定義される。高売上や高予測といった区分は、高需要帯をラベル付けした方法と同様にして、売上や予測値が閾値以上となる区間に対して定義している。また高予測時の評価を行う際の集合は、表4で評価しているモデルごとで定義しているため、各モデルでそれぞれ異なっている。全体需要に対する予測精度を評価するためには、すべてのデータ集合を P とする。需要の高い時間帯の予測精度を評価するためには、売上高の高いデータ集合のみを P とする。高予測時の評価のためには、高需要と予測したときのデータ集合を P とする。なお、営業秘密のため、実際のMAE値を示すことができない。そのため、統計特徴量重視モデル S_{1a} のMAE値 $MAE_P^{S_{1a}}$ をベースラインとして、各モデルのMAE値を比較した改善率を示す。各モデルのMAE改善率を次のように定義する。

$$IR_P = \frac{MAE_P - MAE_P^{S_{1a}}}{MAE_P^{S_{1a}}} \times 100 \quad (7)$$

5.3 実験結果

評価結果を表4に示す。まず、定常状態の予測に適した統計特徴量重視モデル(S_{1a})をベースラインとして、高需

表4 実験結果

Table 4 Evaluation results.

	利用モデル	全体需要改善率	高需要時改善率	高予測時改善率
S_{1a} 統計特徴量重視	S_{1a}	—	—	—
S_{1b} 時変特徴量重視	S_{1b}	-1.10%	+0.73%	+2.5%
単純平均法	S_{1a}, S_{1b}	-0.15%	+0.46%	+2.1%
調和平均法	S_{1a}, S_{1b}	-0.13%	+0.28%	-2.1%
提案手法	$S_{1a}, S_{1b}, S_{2a}, S_{2b}$	-0.13%	+1.45%	+2.4%

要帯の予測に適した時変特徴量重視モデル S_{1b} の MAE 値を比較する。表 4 に示すとおり、 S_{1b} は、高需要時の予測精度および、高予測時の予測精度は改善しているものの、定常状態の予測は精度が悪化していることが分かる。これにより、高需要帯の予測を改善しようとする全体予測精度が下がってしまう事象が確認できた。

次に、提案手法の Stage3 のアンサンブルの評価を行うため、提案手法を式 (4) に示す単純平均法および式 (5) に示す調和平均法と比較する。単純平均法および調和平均法では、Stage1 の結果のみを用いてアンサンブルを行っている。一方、提案手法では、Stage2 における高需要帯モデルおよび低需要帯モデルの分類結果を重みとして Stage1 の結果をアンサンブルしている。表 4 に示すとおり、単純平均法および調和平均法に比べて、提案手法は、全体需要の予測精度を損なわずに、高需要時および高予測時の予測精度を大幅に改善した。これにより高需要帯か、低需要帯かを分類した結果を重みに使った提案手法の有効性が確認できた。

最後に、各モデルの有効性について述べる。 S_{1a} を基準としたとき、 S_{1b} を追加することで高予測時の予測精度は向上する一方で、全体需要の予測精度は悪化する。またたとえば調和平均のような重みづけを行うと高予測時の精度が悪化する。これは重みづけの仕方によっては精度劣化をもたらすことを意味する。 S_{2a} 、 S_{2b} を S_{1a} 、 S_{1b} の重みとして採用することで、高需要時および高予測時の精度がともに改善する。ただし、全体需要の精度向上には寄与しない。

提案手法は既存手法に対して高売上時の予測精度が 1.45%改善している。これは、高需要の時間帯が全体の 10%程度を占めることに鑑みると、売上全体の 0.145%の金額換算のオペレーションの改善につながる可能性があり、ビジネス上の影響は大きいと考えられる。店舗個別で見ると、最も精度の良かった店舗では 10%以上改善した一方、リアルタイム人口統計データの導入により精度が悪化する店舗もあった。特に近隣でイベントがよく開催される店舗では大きな精度改善が見られたが、住宅街にある店舗などでは精度改善は限定的であった。これは人口のうち居住者人口が支配的であり、モデルが人口変動と売上影響の関係を学習できないことが原因と考えられるため、今後改善を検討する。正解値と予測値との比較をすると、回帰モデル S_{1a} 単体では下振れ傾向が強くなっており、提案手法の処理によって下振れ傾向が抑えられ、高需要帯の精度向上につながっていることが分かった。また人口情報を用いたことによる傾向として、近隣でイベントがよく開催される店舗では、他店舗に対して相対的に大きな精度改善が見られた。加えて、 S_{1a} においては、モデルが出力する変数の重要度を観測すると、人口特徴量は 90 に及ぶ特徴量の中で 20 位付近に位置しており、人口特徴量を導入した効果を示して

いる。なお、それ以外の重要となる特徴量は、売上特徴量や雨量などの天候に関する特徴量が観測された。

6. 結論

本稿では、飲食店の需要予測において、特に高需要の時間帯の予測精度を改善するため、2つの手法を提案した。第1に、定常の需要状態を予測するモデルに加え、人口統計データを入力とした高需要を予測可能な予測モデルを構築した。第2に、定常の需要状態を予測可能なモデルと、高需要を予測可能なモデルの出力結果から、現在の状態が高需要にあるか通常状態にあるかを判断し、その状態に応じて売上予測結果をアンサンブルする手法を構築した。飲食店の実売上データを用いた評価を行い、既存手法に対して高売上時の予測精度が 1.45%、高予測時の売上精度が 2.4%改善することを示した。これにより、全体精度を大きく損なわずに、高需要状態での予測精度を改善することを示した。

今回は機械学習器として LightGBM を用いたが、今後は精度向上に向けて様々な手法の導入を検討する。たとえば、Stage1 の売上予測には LSTM [19]、Stage2 の需要帯の分類には文献 [20] や Autoencoder [21]、異常検知の手法も含む様々な手法を比較検討しさらなる精度向上に取り組んでいく。

さらに、本研究では、人口統計データの空間粒度や時間粒度を一律としたが、場所に応じて異なることも想定できる。たとえば、駅近くの混雑する場所では空間粒度を細かくし、ロードサイド店では空間粒度を大きくするなど考えられる。その場合は、空間粒度や時間粒度が一致する店舗の集合で予測モデルを作ることにより、提案手法を適用可能である。今後は、空間粒度、時間粒度が異なる特徴量が混在するケースにおいても提案手法の適用を検討する。

参考文献


- [1] Shahbaz, M., Bilal, M., Moiz, A., Zubair, S. and Iqbal, H.: Food Safety and COVID-19: Precautionary Measures to Limit the Spread of Coronavirus at Food Service and Retail Sector, *Journal of Pure and Applied Microbiology*, Vol.14, No.1, pp.749–756 (2020).
- [2] Cranage, D.A. and Andrew, W.P.: A comparison of time series and econometric models for forecasting restaurant sales, *International Journal of Hospitality Management*, Vol.11, No.2, pp.129–142 (1992).
- [3] Liu, X. and Ichise, R.: Food Sales Prediction with Meteorological Data - A Case Study of a Japanese Chain Supermarket, *International Conference on Data Mining and Big Data* (2017).
- [4] Chen, C.Y., Lee, W.I., Kuo, H.M., Chen, C.W. and Chen, K.H.: The study of a forecasting sales model for fresh food, *Expert Systems with Applications*, Vol.37, No.12, pp.7696–7702 (2010).
- [5] Yang, C.-L. et al.: Short-Term Sales Forecast of Perishable Goods for Franchise Business, *IEEE International Conference on Knowledge and Smart Technology*

- (2018).
- [6] Ma, S., Fildes, R. and Huang, T.: Demand forecasting with high dimensional data: The case of SKU retail sales forecasting with intra- and inter-category promotional information, *European Journal of Operational Research*, Vol.249, No.16, pp.245–257 (2016).
- [7] Kaneko, Y. and Yada, K.: A Deep Learning Approach for the Prediction of Retail Store Sales, *2019 International Conference on Data Mining Workshops* (2016).
- [8] Kaneko, Y.: Customer-Base Sequential Data Analysis: An Application of Attentive Neural Networks to Sales Forecasting, *International Conference on Data Mining Workshops* (2019).
- [9] Müller-Navarra, M., Lessmann, S. and Voß, S.: Sales Forecasting with Partial Recurrent Neural Networks: Empirical Insights and Benchmarking Results, *Hawaii International Conference on System Sciences* (2015).
- [10] Giering, M.: Retail sales prediction and item recommendations using customer demographics at store level, *ACM SIGKDD Explorations Newsletter*, Vol.10, No.2 (2008).
- [11] Gür Ali, Ö. and Gürlek, R.: Automatic Interpretable Retail forecasting with promotional scenarios, *International Journal of Forecasting* (2020).
- [12] Terada, M., Akatsuka, H., Nagata, T. and Nakanishi, S.: Avoiding Tokyo Bay Aqua Line Congestion Using Traffic Congestion Forecasting AI — Prediction Based on Statistical Processing of Mobile Phone Network Operations Data, *NTT DOCOMO Technical Journal*, Vol.21, No.2, pp.27–35 (2019).
- [13] Okajima, I., Tanaka, S., Terada, M., Ikeda, D. and Nagata, T.: Mobile Spatial Statistics Supporting Development of Society and Industry — Population Estimation Technology Using Mobile Network Statistical Data and Applications, *NTT DOCOMO Technical Journal*, Vol.14, No.3, pp.4–9 (2013).
- [14] Ishiguro, S., Kawasaki, S. and Fukazawa, Y.: Taxi Demand Forecast with Stacked denoising Autoencoders Using Real-time Population Data, *Journal of Information Processing*, Vol.60, No.1, pp.118–128 (2019).
- [15] Ishiguro, S., Kawasaki, S. and Fukazawa, Y.: Taxi Demand Forecast Using Real-Time Population Generated from Cellular Networks, *International Workshop on Pervasive Urban Applications in Conjunction, UbiComp*, pp.1024–1032 (2018).
- [16] Mimura, T., Ishiguro, S., Kawasaki, S. and Fukazawa, Y.: Bike-Share Demand Prediction Using Attention Based Sequence to Sequence and Conditional Variational AutoEncoder, *International Workshop on Prediction of Human Mobility, ACM SIGSPATIAL*, pp.41–44 (2019).
- [17] van der Maaten, L. and Hinton, G.: Visualizing Data using t-SNE, *Journal of Machine Learning Research*, Vol.9, pp.2579–2605 (2008).
- [18] Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q. and Liu, T.-Y.: LightGBM: A Highly Efficient Gradient Boosting Decision Tree, *NIPS*, pp.3149–3157 (2017).
- [19] Hochreiter, S. and Schmidhuber, J.: Long Short-term Memory, *Neural Computation*, Vol.9, pp.1735–80 (1997).
- [20] Goodfellow, I.J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A.C. and Bengio, Y.: Generative Adversarial Nets, *NIPS* (2014).
- [21] Zhou, C. and Paffenroth, R.C.: Anomaly Detection with Robust Deep Autoencoders, *KDD* (2017).



篠田 謙司

2016年東京大学大学院総合文化研究科広域科学専攻修士課程修了。同年株式会社NTTドコモ入社。2021年株式会社ドコモ・インサイトマーケティング出向、現在に至る。モバイル空間統計に関する応用研究を行っている。



山田 将人

2007年京都大学大学院情報学研究科通信情報システム専攻修士課程修了。同年株式会社NTTドコモ入社、現在に至る。



高梨 元樹

千葉商科大学商経学部商学科卒業。株式会社サイゼリヤに勤務。海外事業戦略部に所属。海外事業部全体のマニュアルの整備に取り組む。



長谷川 大輔

龍谷大学理工学部卒業。株式会社サイゼリヤに勤務。立地開発部に所属。新規出店時の物件調査から開店までの業務に従事。新たな出店立地の開拓に取り組む。



坪井 哲也

日本大学大学院総合基礎科学研究科地球情報数理科学専攻修士課程修了。株式会社サイゼリヤに勤務。情報システム部長兼調査部長。外食業でのデジタル活用に取り組む。情報処理技術者試験委員。



深澤 佑介 (正会員)

2004年東京大学大学院工学系研究科システム創成学科修士課程修了。同年株式会社NTTドコモ入社。2011年東京大学大学院工学系研究科博士後期課程修了。東京大学人工物工学研究センターにて協力研究員(2011年～2016年)および客員研究員(2016年～2019年)を兼任。2019年より早稲田大学イノベーション研究所招聘研究員を兼任。現在に至る。Webマイニング, パーソナライゼーション, 確率モデルに関する研究開発を行っている。IEEE, 人工知能学会各会員。博士(工学)。本会シニア会員。



木本 勝敏

1991年北海道大学大学院工学研究科精密工学専攻修士課程修了。同年株式会社NTTドコモ入社。現在に至る。入社以来移動通信システム・サービスの研究開発に従事。