

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

人口統計データを用いた 高需要時の飲食店需要予測

戸田 真聰

富山県立大学 情報システム工学科

2024年5月24日

1. はじめに

2/19

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

背景

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。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。

本研究の目的

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。

2. 人口統計データ

3/19

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）」を利用する。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生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。

- 1. はじめに
- 2. 人口統計データ
- 3. 提案手法
- 4. 評価実験
- 5. おわりに

2. 人口統計データ

人口統計データ

- はじめに
- 人口統計データ
- 提案手法
- 評価実験
- おわりに

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。

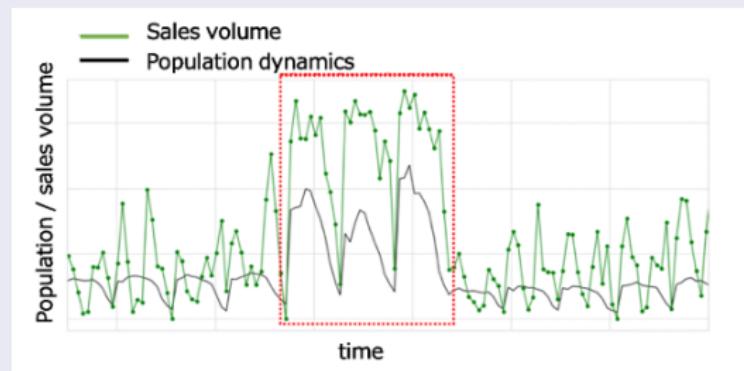


図 1: 時間ごとの売上値と人口の時系列グラフ

3. 提案手法

提案手法の全体構造

提案手法は、次の 3 つの Stage から構成されている。

Stage1 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 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 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。

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

3. 提案手法

提案手法の全体構造

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

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。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。

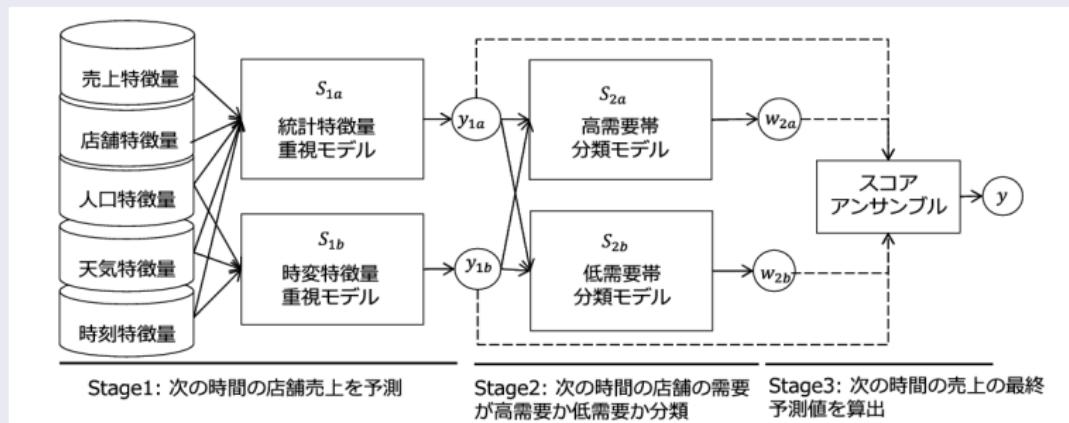


図 2: 提案手法の全体像

3. 提案手法

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

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 S1a 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 S1b である。

それぞれの特徴量を表1に示す。S1a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、S1b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。

3. 提案手法

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

表 1: Stage1 の統計特微量重視モデル/時変特微量重視モデルで利用する特微量一覧

特微量元素	S_{1a}	S_{1b}	定義	特微量元素数
時刻特微量	✓	✓	予測対象日 D_{target} の曜日 DW_{target}	7
	✓	✓	予測対象時刻 H_{target}	2
売上特微量	✓		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
店舗特微量	✓	✓	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 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
人口特微量	✓	✓	時刻 $H_{target+1}$ 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との差 ($t = 0, 1, 2, 3, 4, 5$)	$2 \times 6 = 12$
天気特微量	✓	✓	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 $H_{target+1}$ にメッシュで観測された温度との差	1

3. 提案手法

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

Stage2：高需要帯分類モデル/低需要帯分類モデル

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 S2a 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 S2b を構築する。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。

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

ラベルの閾値は、実際に店舗運営上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。

3. 提案手法

10/19

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

Stage3：重みづけ線形和によるアンサンブル

Stage2 のモデルが output 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。

$$z_1 = w_{2a} \max(y_{1a}, y_{1b}) + (1 - w_{2a}) \min(y_{1a}, y_{1b})$$

$$z_2 = w_{2b} \min(y_{1a}, y_{1b}) + (1 - w_{2b}) \max(y_{1a}, y_{1b})$$

$$y = \frac{z_1 + z_2}{2}$$

ここで、 y_{1a} と y_{1b} は、それぞれ $S1a$ と $S1b$ の回帰出力を、 w_{2a} と w_{2b} は、それぞれ $S2a$ と $S2b$ の分類スコア値を示す。

3. 提案手法

11/19

Stage3：重みづけ線形和によるアンサンブル

本研究では、最終結果を、上の式で計算される単純平均アンサンブルと、下の式で計算される調和平均アンサンブルと比較した。

$$\frac{y_{1a} + y_{1b}}{2}$$

$$\frac{2y_{1a}y_{1b}}{y_{1a} + y_{1b}}$$

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

4. 評価実験

12/19

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

データセットの詳細

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。

表 2: データの詳細

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

4. 評価実験

13/19

データセットの詳細

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに



図 3: 特徴量生成, 学習および評価の期間

4. 評価実験

14/19

学習モデル

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

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、S1a と S1b に対して、`learningrate(学習率)= 0.02`, `objective(目的関数)=regressionl2`, `metric(評価指標)=rmse`, `numleaves(木の分岐の個数) =85`, `maxdepth(最大の木の深さ)=15` を設定した。S2a と S2b について、`learningrate=0.02`, `metric=auc`, `numleaves=20`, `maxdepth=5` とした。

また、`regressionl2` 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。

4. 評価実験

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

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。

$$\text{MAE}_P = \frac{1}{\#P} \sum_{i \in P} |\hat{y}_i - y_i|$$

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。

4. 評価実験

評価指標

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

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 S1a の MAE 値 MAEPS1a 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。

$$\text{IRP} = \frac{\text{MAE}_P - \text{MAE}_P^{S1a}}{\text{MAE}_P^{S1a}} \times 100$$

4. 評価実験

17/19

実験結果

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

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(S1a)をベースラインとして、高需要帶の予測に適した時変特徴量重視モデルS1bのMAE値を比較する。表4に示すとおり、S1b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。

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における高需要帶モデルおよび低需要帶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。

4. 評価実験

18/19

実験結果

1. はじめに
2. 人口統計データ
3. 提案手法
4. 評価実験
5. おわりに

表 3: 実験結果

	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%

5. おわりに

19/19

まとめ

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。

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。

今後

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。

また、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。