

人流計測データを活用した商業施設内の店舗立ち寄り人数予測 Prediction of the number of visitors in a shopping mall with people-flow data

鎌本 賢志[†]
Satoshi Kuwamoto

北野 佑[†]
Yu Kitano

1. はじめに

公共施設や商業施設における、人の行動に関するデータの分析、活用が近年注目されている。施設管理者は、利用者の行動を把握することで、施設価値向上につながる施策を打つことができる。特に近年のコロナ禍では、施設人流の分析や制御は、安全管理の上で重要な関心事となっている。また、現況分析のみならず、高精度な人流予測まで実現できれば、将来の混雑発生などを先読みし、効果的な施設運用につなげることができる。

こうした背景の下、本研究ではショッピングモール内の店舗立ち寄り人数予測に焦点を当てる。精緻な予測が実現できれば、例えば、将来の来客状況に応じたスタッフ数や配置の検討、また混雑抑制のための人流誘導施策が検討できる。

しかし、一般に商業店舗の需要予測は困難なタスクである。これは人の行動が多くの変因に影響されるためである。例えば、クリスマス等の大きなイベントで来客数が増加することもあれば、SNS 等に起因する流行の移り変わりなど、容易には把握できない変因によっても施設利用者の行動傾向が変化すると考えられる。一般的な需要予測では、目的変数の履歴データ等から予測モデルを構築するが、前述の理由から、行動傾向の変化を捉える情報を適切に加味しなければ、予測精度の担保は難しいと考えられる。

そこで本研究では、施設内の人流計測データを用いて施設利用者の行動傾向を捉えることで、店舗立ち寄り人数の予測精緻化をはかる。本発表では提案手法と、店舗立ち寄り人数予測の実験を通じ効果検証した結果について報告する。

2. 店舗立ち寄り人数予測

2.1 問題設定

本研究にて取り組む、店舗立ち寄り人数予測の問題設定を述べる。本研究では、立ち寄り人数やその他利用状況を表すデータを 1 時間単位に集約して扱う。問題としては、直近 1 時間の施設利用状況に関するデータから、次の 1 時間の内に各店舗に立ち寄る人数を予測するものとする。本問題は以下のように定式化される。

$$N(t+1) = f(X(t))$$

ただし、 t は直近の時間帯、 $X(t)$ は時間帯 t の特徴量、 f は予測モデル、 $N(t)$ は時間帯 t における店舗ごとの立ち寄り人数を表す。

2.2 課題

一般的な需要予測では、目的変数の履歴データや時間情

[†] (株) 日立製作所 研究開発グループ

Hitachi Ltd., Research and Development Group

報(時間帯、曜日、平日/休日)等を用いて予測モデルを構築するが、前述の通り、目的変数が様々な変因に影響されるため困難なタスクとなる。店舗立ち寄り人数予測についても同様であり、様々な変因に影響されて変化する行動傾向を捉えるため、適切なデータを予測に加味する必要がある。

2.3 提案手法

上記課題に対応すべく、本研究では対象施設の人流計測データ利用を提案する。ここで、人流計測データとは、歩行者の識別子、サンプリング時刻、座標値(x 成分、y 成分)を含むものと定義する。

本手法では、人流計測データから、①施設出入口ごとの流入人数、②種々の統計量(以下、人流統計量と呼ぶ)を特徴量として算出し、目的変数に対するラグ特徴量や時間情報の数値ベクトルに結合して予測モデルに入力する。②人流統計量は、下記に対し時間帯ごとに統計処理(平均値、標準偏差、中央値、最小・最大値を計算)して求めるものとする。

- 歩行者の移動速度、進行方向、右左折の割合
- 歩行者毎の滞在時間、移動距離、平均移動速度、立ち寄り店舗数

3. 実験

3.1 実験条件

提案手法の有効性を検証すべく、某ショッピングモール内の店舗に対し、立ち寄り人数予測の評価実験を行った。当ショッピングモールのレイアウト地図を図 1 に示す。本研究では、当ショッピングモール内に複数設置した ToF カメラにより、施設利用者の人流計測データを取得した。サンプリングレートは毎秒 1 フレームとした。人流計測データの例を図 2 に示す。本データをもとに、目的変数である店舗立ち寄り人数や、各種特徴量を算出した。

本研究では、店舗ごとの立ち寄り人数や、施設出入口ごとの流入人数の算出において、OD(Origin-Destination)分析[1]を適用した。これは、人流計測データと施設内の立ち寄り場所(以下チェックポイントと呼ぶ)のデータをもとに、各人の施設内の OD 遷移を分析する手法である。図 1 において、全ての出入口・Entrance A~E と、店舗・Shop J, Restaurant A, B については、通過型のチェックポイントと設定し、当該領域を横切った人数をカウントするものとした。出入口に関しては流入状況を加味するため、当該領域を通過する方向も考慮して分析した。上記以外の店舗については、全て滞留型のチェックポイントと設定し、5 秒以上該当領域に滞在した人数をカウントするものとした。

利用した人流計測データについて、2020年9月1日から12月20日に取得されたデータを学習データとし、同年12月21日から12月27日に取得されたデータをテストデータとした。また予測対象の時間帯は、各店舗の営業時間を考慮し、各日11:00から20:59(11時台から20時台)とした。学習データとテストデータのレコード数について、1時間ごとの目的変数・特徴量データはそれぞれ15,540および980であり、人流計測データはそれぞれ162,807,455および13,710,391であった。

本実験では、提案手法の効果を検証すべく以下4パターンの手法を適用した。

1. ベースライン 1: 直近1時間の店舗立ち寄り人数をそのまま予測値とする
2. ベースライン 2: 店舗の識別子や予測対象時刻の情報(時間帯、曜日、平日/休日)、直近1時間の店舗立ち寄り人数をもとに予測する
3. 提案手法: ベースライン 2 の特徴量に加え、2.3 節で述べた人流計測データ由来の特徴量を加味して予測する
4. 提案手法(Ablation): ベースライン 2 の特徴量に加え、人流計測データ由来の特徴量として、施設出入口ごとの流出入人数のみ加味して予測する

データ駆動型の予測手法である手法 2~4 については、モデル学習のアルゴリズムに LightGBM を適用した。LightGBM のハイパーパラメータは、Optuna[2]を用いて決定した。その際、検証用データとして学習データの内 2020年12月7日から12月20日までの2週間分を割り当てた。

3.2 実験結果

各手法の予測結果について、正解データに対する MAE(Mean Absolute Error: 平均絶対誤差)を算出した結果を表 1 に示す。本結果から、人流計測データ由来の特徴量を加味した提案手法が、ベースライン手法より予測精度が高く、特にデータ駆動型の手法である手法 2 と 3 で比較すると、MAE ベースで 8.55 人/時間から 7.78 人/時間と 9.1%の誤差改善効果が見られる。また、手法 2~4 の結果を比較すると、出入口ごとの流出入人数を加味したことによる精度改善効果が高いことや(8.55 人/時間→7.96 人/時間、誤差 6.9%減)、動線統計量による改善効果も見られること(7.96 人/時間→7.78 人/時間、誤差 2.3%減)が確認できる。また、提案手法にて構築した LightGBM の特徴量重要度(gain ベース)の比率を算出した結果を表 2 に示す。本結果から、人流計測データ由来の特徴量重要度が全体の 9.8%を占め、当該特徴量が予測に寄与することが確認できる。

4. おわりに

本研究では、ショッピングモール内の店舗立ち寄り人数予測精緻化のため、人流計測データから出入口ごとの流入状況や、その他施設利用者の行動に関する特徴量を算出し、予測に加味する手法を提案した。提案手法を某ショッピングモール内店舗に適用したところ、人流計測データ由来の特徴量を加味することで、1時間当たりの立ち寄り人数の MAE が、8.55 人/時から、7.78 人/時と 9.1%削減する結果を得た。予測モデルの特徴量重要度からも、当該特徴量が 9.8%予測に寄与していることを確認した。以上より、店舗立ち寄り人数予測において、人流計測データの利用が




図 1 某ショッピングモールのレイアウト地図。赤枠と青線が、各々予測対象店舗と施設出入口を表す。



図 2 某ショッピングモールにて取得した人流計測データの例(緑線)。

表 1 各手法の予測精度検証結果

手法	MAE(人/時間)
ベースライン 1	9.30
ベースライン 2	8.55
提案手法	7.78
提案手法(Ablation)	7.96

表 2 提案手法の予測モデルにおける特徴量重要度の比率

カテゴリ	特徴量重要度の比率
ベースライン 2 の特徴量全体	90.2%
施設出入口ごとの流出入人数	6.9%
人流統計量	2.9%

有効である見込みを得た。今後は、駅・空港など他施設における検証や、深層学習などを利用した予測モデルの改善等を進めていく。

参考文献

- [1] Yu Kitano et al., "OD-network-based Pedestrian-path Prediction for People-flow Simulation", In: IEEE International Conference on Big Data (2019), pp.1656-1661.
- [2] T. Akiba et al., "Optuna: A Next-generation Hyperparameter Optimization Framework", In: ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (2019), pp.2623-2631.