

施設管理支援に向けた常時型人流予測

角田 啓介^{1,a)} 秦 崇洋¹ 中村 元紀¹ 尾花 和昭¹

概要: 本稿では、商業ビルをはじめとする施設における、空調制御や清掃、テナントへの支援といった管理業務の支援を目指し、施設内における人の方向別の移動人数や速度といった人流を予測する手法を提案する。従来の人流予測技術では主に、イベント時や災害時といった、明確な出来事によって生じる画一的な人流を対象とし、混雑緩和や誘導のため数分から数時間後の人流を予測していた。しかしながら、実際の設備管理において、管理業務に必要な物品や人材、装置等を事前準備するために、普段の運営における、曜日や時間帯によって変化する多様な人流データを、1日以上前に予測することが必要である。本稿では、過去の人流計測データとそれらが持つ平日・休日といった特徴に基づき、1日以上前に未来日における各時刻の人流を予測する常時型人流予測手法を提案する。そして、提案手法を実際の施設で計測した人流データに適用することで、その有効性を示す。

Continuous Prediction of People Flow for Supporting Facility Management

1. 緒言

近年、商業ビル、駅、地下街といった様々な人々が集う施設は、人々にとっての目的を達成する場であるだけでなく、人が様々な人やモノと出会う機会を提供する重要なインフラストラクチャとなりつつある。そのような施設の管理者にとっては、稼働率や集客率の向上と同時に、入居テナントや来場者にとって価値があり、かつ居心地の良い空間になるような管理・運営が非常に重要である。しかしながら同時に近年、日本では少子高齢化や労働力の減少が顕著であり、このような施設の管理・運営業務にはより一層の効率化が求められている。

本稿では、そのような施設の管理・運営を支援するための取り組みとして、日々、その施設の中で起こる人の流れ、具体的には方向別通過人数や速度である「人流」に着目し、人流を常時予測する手法について述べる。従来の人流予測技術では、イベント開催時や災害時をはじめとした、短期間に画一的な人の流れが生じるケースに焦点を当てた予測が試みられていた。しかしながら、施設の管理・運営は24時間365日休みなく実施される必要があり、イベント時の

ような短期間における画一的なパターンだけでなく、管理に必要な資材や人材を確保するためにも、日付、曜日、時間帯、場所などによって変化する様々な人流パターンを、1日以上前に予測する必要がある。本稿では、施設の来場者の流れには場所や方向、平日、休日パターンによってある程度規則性があることに着目し、学習データを選択して予測モデルを作成して予測することで、精度よく人流を予測できる常時型人流予測手法を提案する。また、提案手法を商業施設における実測データへ適用し、その有効性を示す。

2. 関連研究

2.1 人流把握

予測を含む、ある施設やエリアにおける人流の把握は、以下の3軸で分類されると考えられる。本節では各軸の詳細と関連研究について順に述べる。

- 対象粒度
- 対象期間
- 利用期間

2.1.1 対象粒度

本稿では人流把握対象の粒度として、個人のふるまい、個人のふるまいの統計値である移動方向やその人数および速度、エリア間の総移動人数の3レベルに分類し、本節でそれぞれの関連研究について述べる。

¹ 日本電信電話株式会社 NTT サービスエボリューション研究所
NTT Service Evolution Laboratories, Minato, Tokyo 108-0023, Japan

^{a)} keisuke.tsunoda.cx@hco.ntt.co.jp

個人のふるまいレベルでの人流把握として、人の行動のモデル化が挙げられる。例えば瀬尾らは、目的地選択 (Plan) と行動 (Action) からなる歩行者の行動モデル [1] を、Ziebart らは人の目的地に向けた行動をマルコフ決定過程とみなしてモデル化し、推定する技術 [2] をそれぞれ提案している。他方、近年は群衆の次の動きを予測する技術が提案されており、一例として Alahi らは群衆の動画から人を抽出し、彼らの今後数秒の動きを Recurrent Neural Network(RNN) で予測する技術を提案している [3]。

個人のふるまいの統計値レベルでの人流把握に関しても複数の研究が存在する。代表例として、駅構内における人の通行人数と動線の交差回数で人流を把握している研究がある [4]、他にも、イベント開催時のような人が集まる箇所や移動ルートが事前に想定可能なケースにおいて、複数地点の方向別通過人数から、「いつ、どこからどこへ」という人の流れをベイズ最適化によって推定する群衆行動のデータ同化技術が提案されている [5]。

エリア間の総移動人数レベルでの人流把握として、時空間変数オンライン予測技術による混雑予測がある [6]。これは想定外の混雑を予測するため、イベント会場などにおいて複数地点で測定した通過人数から、各場所における潜在的な特徴をとらえたうえで、数分から数十分後の混雑する経路、すなわち地点間の総移動人数を予測する技術である。また、各人の携帯電話から得られるモバイル空間統計に基づき、各時刻における住民の滞在である「ホーム人口」と住民以外の滞在人数である「アウェイ人口」という概念を定義したうえで、それらを基に通勤や観光に伴う広域的な人の移動を推定する試みもなされている [7]。

2.1.2 対象期間

本節では、関連研究を対象期間の観点から整理する。まず、最も近い未来を予測するケースとして自動運転における事故防止に活用される、数秒以下の技術が挙げられる [3]。また、イベント開催時などを対象とした混雑予測と誘導に活用される技術では、数分から数時間後の未来を予測する技術がある [6]。他には、前日までに意思決定が必要なケースなどを想定し、1日以上後の未来を予測することも想定される。人流でないが、道路の渋滞予測などが具体的な類似事例である。

2.1.3 利用期間

本節では、関連研究を利用期間の観点から整理する。利用期間とは、人流をどのような期間において利用することを目的としているかを表す。これには特定のイベント発生時における人流のみを予測する「臨時型」と、毎日継続的に予測する「常時型」に分類できると考えられる。前者の具体例としては、前述の時空間変数オンライン予測 [6] や、群衆行動のデータ同化技術が挙げられ [5]、これらは臨時における比較的画一的かつ瞬時的な人流を対象としているため、臨時型に分類されることが考えられる。これに対して、

特段のイベント等の有無に関係なく、日常的に人流を予測する技術として、通勤や観光の流動予測が挙げられ [7]、これらは日々における多様な人々が行きかう広域的な空間における人流を対象としているため、常時型に分類できると考えられる。

2.2 時系列分析手法

本節では、施設内における人流データのような、連続的に測定され変化するパターンに対する一般的な分析・予測手法である時系列分析手法について述べる。

時系列データとは、時間的な変化を連続、または等間隔で計測したデータであり、施設内の人流データはまさにこの特徴に当てはまると考えられる。時系列データの典型的な特徴としては平均や分散が変化しない定常性が挙げられ、定常性を前提とした分析手法として、自己回帰 (Auto Regressive; AR) モデル、移動平均 (Moving Average; MR) モデル、およびそれらを組み合わせた自己回帰移動平均モデル (ARMA) や自己回帰和分移動平均モデル (ARIMA) がよく利用されている [8]。さらに近年はより実用的なモデルとして、季節変動のような周期的な変動を考慮した季節自己回帰和分移動平均 (Seasonal ARIMA; SARIMA) モデルも提案されている [9]。SARIMA モデルは季節変動だけでなく、周期的な変動であれば様々な現象に応用できるため、広く用いられてきた。具体的には、過去の交通量に基づいた1時間後の交通量予測 [10] や、休日や祝日を考慮した交通量予測 [11]、教育施設での年間電力利用量予算策定のための電力利用量の予測 [12] などが挙げられる。これらの手法では、数か月から数年といった長期間、連続的にデータが計測されていることが前提となっている。

3. 要件と課題

3.1 問題設定

本節では、本稿で目指すべき人流予測の要件の明確化に向け、問題設定を述べる。まず、本稿での支援対象は前述のように、商業ビルや駅をはじめとする、不特定多数の人間が常時行きかう空間である施設の管理や運営である。ここでの管理や運営には、施設の清掃や補修、空調や照明の制御及びメンテナンス、入居するテナントに対する情報提供や運営支援が含まれる。そして、施設の管理や運営を担当する管理者は、このような経費削減や付加価値向上が急務である。

商業施設等における経費には光熱費といわれるエネルギーの経費があるが、商業ビルであるデパートやオフィスビルでは冷暖房によるエネルギー消費は全体の約40%にも及ぶという環境省の統計がある [13]。また、人は体温があるため室温へ影響を及ぼし、また人の出入りとともに起こる外気の流入や流出も室温へ影響する。さらに、空間にいる人の温熱感による快適度の指標として Predicted Mean

Vote(PMV) [14] があるが、PMV に寄与する指標としては人の運動量、すなわち歩く人の速度が含まれる。そのため、施設内において、空調制御の区画や出入口などに対応して定義したエリアごとに、各時刻における人の人数や、通過する方向及び歩行速度を把握することは、空調の最適制御による光熱費削減につながり、価値があると考えられる。加えて、清掃や補修に伴う一時的な通行制限を、夜間帯でなく日中に実施することで、人的コスト等を削減することが可能と考えられるが、この場合も特定エリアにおける、各時刻における人の人数や、通過する方向を前もって予測することは必要になると考えられる。

一方、テナントへの情報提供や運営支援は、施設の付加価値向上につながると考えられる。管理者には原則、入居テナントに対して不公平のないよう支援する必要があるうえ、各テナント内での運営は各テナントで実施することが想定されることから、管理者がハンドリングできる範囲としては施設内の通路等共用空間における人の動きとなる。また、テナントにとって事前に把握したい情報について考えると、直前では調達が難しい、仕入れや人材配置に関連する情報と考えられる。すると、それに対応する人流データとは、各テナントに隣接する共用空間における、人の量になると考えられる。さらに、人の量だけではどの程度当該テナントに関係する人間か把握が難しく、理想的には各人の属性が把握できるとよいが、プライバシー等を考慮すると困難である。しかしながら、どのような方向や速度で何人移動しているかによって、通勤客か、買い物客かといった多数が占めるおおまかな属性は把握できる可能性があると考えられる。以上の点を考慮すると、現実的に管理者が提供可能で、かつテナントにとって前日以前に把握する価値のある人流は、共用空間を移動する人の統計値、特に方向別の移動人数や、その速度と考えられる。

さらに、施設管理特有の課題として、長時間の連続的データの計測が困難であることが挙げられる。なぜなら、少なくとも日本では商業施設のような大規模ビルでは様々な法定点検が義務付けられているため [15]、点検に伴って数日間停電するケースや、リニューアルや補修といった工事により、数時間から数日の間、一定期間特定のエリアのみ立ち入り禁止や制限を敷く、あるいは停電やセンサ等を撤去せざるを得ないケースが考えられるからである。

3.2 要件

以上の問題設定より、本稿における人流予測の要件は、以下のようになる。

- 1日以上後の人流が予測できること
- 特定のイベント時でなく、日常における人流が予測できること
- 人流として、空調等に対応した各エリア内の移動方向別の人数や速度が予測できること

- 法定点検や補修工事等によって発生するデータの欠損に対応できること

そして上記要件を、関連技術で述べた3要素に基づいて整理すると、毎日利用することを前提とした常時型で、個人のふるまいの統計値レベルの人流を、1日以上前に予測する必要があるといえる。

3.3 課題

上記の要件と関連技術より、本稿で解くべき課題を明確化する。

まず、上記要件をすべて満たす既存技術は現時点で存在しない。より詳細に述べると、1日以上後の長期的な人流を予測する技術では、人口統計などを基にした各エリア間の流動量の予測といった総移動人数レベルでの予測が主であり、より詳細な、方向別の人数やその速度といった観点まで予測していない。他方、人の移動方向や速度を対象とした研究では、イベント時などを対象とした比較的画一的かつ短時間で発生する人流を対象とした臨時型が主であり、常時型における予測技術は検討されていない。さらに、人のふるまいレベルでの予測は自動運転車などを対象とした数秒後以下の予測が対象となっており、1日以上後の予測は考慮されていない。

以上より本稿における課題は以下のようになる。

数時間から数日の欠損がある計測データから、各エリアにおける定常時の方向別移動人数と速度を、予測日以前のデータのみから予測可能か否か。

4. 提案

4.1 システム全体像

本稿における提案手法を含めた全体像を図1に示す。まずシステムは大きく、既存技術である人流計測システムと、提案手法を含む人流予測システムからなる。前者の人流計測システムでは、Laser Range Finder(LRF) やカメラといったセンサを1つ以上用いて、あらかじめ定義されたエリア内での人の移動軌跡を測定し、その人のIDとともに人流軌跡DBに保存する。具体的な計測システムの例としてはLRFによる計測システム [16] が挙げられる。一方、人流予測システムは、人流軌跡DBのデータを入力として動作する。以下、基本的な動作について説明する。

本提案システムではまず最初に、既存技術である人流計測システムを用いて、対象となる施設における定義したエリア毎の人の移動軌跡を計測する。計測は複数日実施し、それらの計測結果を人流人流軌跡DBへ保存する。

本稿で提案する人流予測システムは、上記の人流軌跡を入力とする。まず、人流算出部は人流人流軌跡DB内のデータを読み取ったうえで、設定されたエリアと期間毎に、

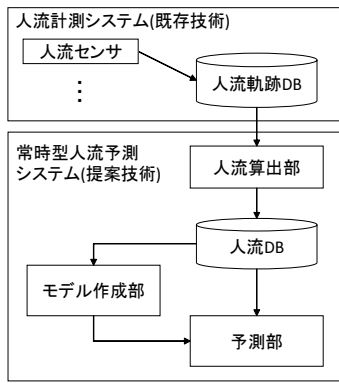


図 1 提案システムの全体像
 Fig. 1 Proposal system

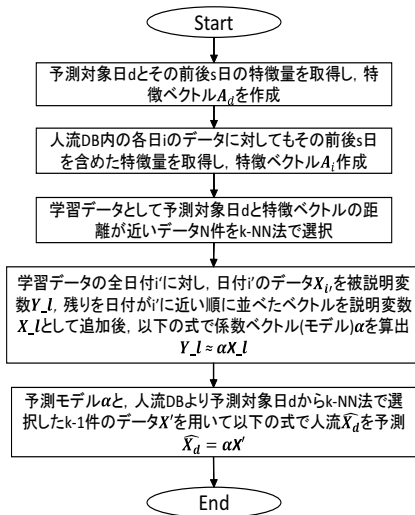


図 2 常時型人流予測の処理フロー
 Fig. 2 Flow of continuous people flow prediction

人流データを算出する。ここで述べる人流データとは要件として上述した、方向毎の移動人数および速度である。算出結果は人流 DB へ保存される。そしてそれらのデータを基に、予測部が未来の予測対象日の人流を予測する。この際、モデル作成部が予測対象日の特徴に基づき、人流 DB から一部データを学習データとして選択し、予測モデルを作成する。予測部は作成された予測モデルに基づき、人流を予測する。次節では、学習データ選択と予測モデル作成を含む常時型人流予測手法について詳しく述べる。

4.2 常時型人流予測手法

常時型人流予測手法では、過去のすべての人流データではなく、予測対象日の特徴に合わせて学習データを選択し、予測することで、高い精度で1日以上先の人流を予測することができる。また、ARIMA モデルのように直前までの長期間な連続的データを必ずしも必要とせず、学習データと予測対象の特徴に基づいてモデルを作成するため、データに不定期な欠損が生じても影響を受けない予測が可能となる。予測における処理フローを図 2 に示す。

まず前提として、予測対象とするエリア内における人流データ、具体的には任意方向への移動人数または平均速度が n 日分算出され、人流 DB に保存されていると考える。つまり、第 i 日における時刻 $t = 1, 2, \dots, m$ の人流データを $\mathbf{X}_i = \{X_1^i, X_2^i, \dots, X_m^i\}$ とし、第 1~ n 日までの人流データ $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$ が人流 DB に蓄積されているとする。そして、各日 i は特徴量 a_i を持つものとする。

予測ではまずはじめに、予測対象日 d のデータに対し、その前後 s 日を含む特徴ベクトルを算出する。予測対象日 d の特徴ベクトルは $\mathbf{A}_d = \{a_{d-s}, a_{d-s+1}, \dots, a_d, a_{d+1}, \dots, a_{d+s}\}$ となる。次に人流 DB 内の各日データに対しても同様に特徴ベクトルを算出する。日付 i の特徴ベクトルは、 $\mathbf{A}_i = \{a_{i-s}, a_{i-s+1}, \dots, a_i, a_{i+1}, \dots, a_{i+s}\}$ となる。

次に、人流 DB の各日と予測対象日の特徴ベクトルの距離を算出する。ここで、人流 DB 内の第 i 日のデータと予測対象日 d の特徴ベクトルの距離は $D_{i,d}$ とする。その後、学習データとして、 $D_{i,d}$ が小さい日付 i のデータ k 件を k-Nearest Neighbor(k-NN) 法で選択する。

そして、選択した学習データにおけるすべての日付 i' に対し、日付 i' のデータ $\mathbf{X}_{i'}$ を被説明変数 $\mathbf{Y}_{i'}$ 、残りの日付のデータ $k-1$ 件を日付 i' に近い順に並べたベクトルを説明変数 $\mathbf{X}_{i'}$ として結合後、以下の式でモデルとなる係数 α を算出する。

$$\mathbf{Y}_{i'} \approx \alpha \mathbf{X}_{i'} \quad (1)$$

最後、人流 DB 内の第 i 日のデータと予測日 d の特徴ベクトルの距離は $D_{i,d}$ に基づいて、作成したモデルに合うよう $k-1$ 件のデータを k-NN 法で選択して \mathbf{X}' 、以下の式で予測対象日の人流 $\hat{\mathbf{X}}_d$ を算出する。

$$\hat{\mathbf{X}}_d = \alpha \mathbf{X}' \quad (2)$$

本手法の特徴は、学習データを選択する際、予測対象日とその前後 s 日の特徴量を算出し、その特徴ベクトルに基づいて予測モデルを作成したうえで予測する点である。ここでの特徴量とは、予測対象日が来る前その前後 s 日も含めあらかじめ明確である必要があり、例としてはその日が休日か否か、予報を含めるのであれば天候(雨, 曇り, 晴れなど)が挙げられる。これらの特徴が似ている日は、人流の傾向も類似している可能性が高いため、このように選択的に学習データを用いて予測モデルを作成して予測することで、1日以上前に、対象日の人流を精度よく予測することが可能と考えられる。

5. 実データを用いた評価

5.1 評価データ

まず、評価データ準備のため、実際に商業施設にて LRF システム [16] を用いて人流軌跡データを計測した。対象となる施設は 3 フロアあり、第 1 フロア、第 2 フロアは 6,




図 3 人流の算出例

Fig. 3 Example of people flow calculation

第3フロアは3つのエリアに分割されている。このエリアは、当該施設の空調制御単位に合わせて設定されているが、エリアの形状に基づき、計15エリアのうち一部のエリアと方向のみを抽出し、評価を実施した。抽出したエリアの詳細は後述する。測定期間は2018年の65日間だが、連続した65日間ではなく、途中で1日以上データ欠損期間が複数ある。測定日のうち土・日曜日は20日、残りの平日45日のうち振替休日を含む祝日は4日である。

次に、評価データとなる、人流軌跡データからの人流データ算出方法について述べる。人流データは要件で述べたように方向別の移動人数およびその平均速度とし、各測定日の7時から23時の中で30分の時間窓で算出した。方向は東西南北4方向のうち、エリア毎に移動することが明確な方向のみを考慮し、人流を算出した。例えば、十字路となっているエリアであれば東西南北の4方向を、南北をつなぐ通路になっている場合は南北の2方向のみを考慮している。さらに、エリア内において人は蛇行や停止といった行動をとることも考えられる。そこで本稿では簡略化のため、各時間窓、エリアにおける各IDに対し、最初に測定された点と最後に測定された点の座標のみを抽出し、その2点から移動ベクトルを算出する。そしてその移動ベクトルのうち、東西南北で最も大きく動いた方向を移動方向とした。このような手法を用いることで、大量かつ多様な人流軌跡データに対して容易に、かつ施設管理に必要なエリア毎の統計レベルでの人流を算出することができる。算出例を図3に示す。以上の方法で抽出されたエリアは全11エリアで、うち1エリアのみ東西南北の4方向、1エリアは東西の2方向、残りエリアは南北の2方向となった。各エリアの位置関係と対象とした方向の概略を図4に示す。図4における青線はエリア外への開口部であり、エリア同士の隣接点はすべて通過可能である。

5.2 評価方法

本稿では方向別の移動人数と平均速度は独立に予測し、評価することとした。提案手法における特徴量として、商業施設では休日と平日、休日の何日目か、あるいは休前日かといった属性で人流傾向が変わることが想定されるため、

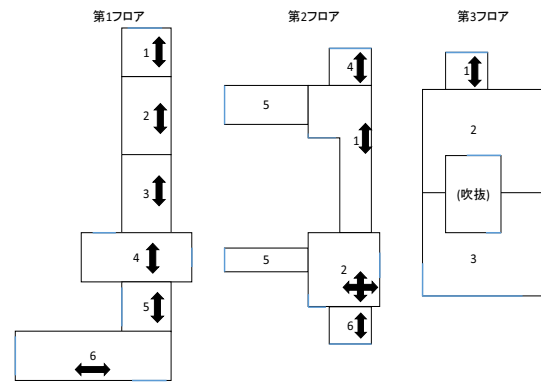


図 4 各フロア、エリアの位置関係と対象とした方向の概略
Fig. 4 Floors, areas and target directions in this paper

休日か否かの2値を採用し、考慮する前後の日数 $s = 1$ とした。具体的には、平日である金曜日を予測対象とした場合は、前日が平日、次の日が休日となる平日のデータを主に用いてモデル作成を行う。また、学習データ選択後の予測モデルは、学習データのうち1日を被説明変数、残りのデータを被説明変数の日に近い順に説明変数とした Cross validation を実施したうえで、最も精度が高くなったモデルを採用した。予測モデルには複数の説明変数を用いることができる回帰モデルの中でも、多重共線性を回避できる Partial Least Square(PLS) 回帰を用い、次元数 c は1または2で比較評価した。

評価では、取得した65日分のデータのうち、全体の80%にあたる最初の42日と残り20%となる最後の13日に2分割した。そのうえで、前者を学習用データセットとしてモデル作成に利用し、後者の人流を1日毎に、学習用データセットと予測以前のデータセットを基に予測した。

比較手法としては、時系列分析に近い手法として、予測日直前7日間の平均値、休日、平日それぞれ毎に集計した平均値、および曜日、休日または平日のカテゴリ変数を用いた ElasticNet で予測を実施し、提案手法と比較評価を実施した。評価指標として、予測値と実測値の平均絶対誤差率を用いた。

5.3 評価結果

全データの結果として、表1に方向別移動人数の、表2に方向別平均速度の予測絶対誤差率の平均と標準偏差をそれぞれ示す。

予測対象日毎の結果として、図5に方向別移動人数の、図6に方向別平均速度の各予測対象日の予測絶対誤差率の平均と標準偏差をそれぞれ示す。

また具体的な予測例として、第3フロア第1エリアにおける、提案手法の効果が大きかった11日目(月・祝)における北方向の通過人数の実測値と各手法での予測値を図7に、効果がほとんどなかった6日目(水)におけるそれらの値を図8にそれぞれ示す。同様に速度の予測例として、第

表 1 方向別移動人数の予測絶対誤差率

Table 1 Ratio of absolute mean error in prediction of number of moving people for each direction

	平均	標準偏差	比較手法との有意差	提案手法 (c=1)との有意差
比較手法	0.242	0.144	-	-
提案手法 (c=1)	0.200	0.085	**	-
提案手法 (c=2)	0.208	0.087	**	**

** : $p < 0.01$, * : $p < 0.05$

表 2 方向別平均移動速度の予測絶対誤差率

Table 2 Ratio of absolute mean error in prediction of speed of moving people for each direction

	平均	標準偏差	比較手法との有意差	提案手法 (c=1)との有意差
比較手法	0.0896	0.0575	-	-
提案手法 (c=1)	0.0846	0.0507	**	-
提案手法 (c=2)	0.0854	0.0502	n.s.	n.s.

** : $p < 0.01$, * : $p < 0.05$




図 5 方向別移動人数の日別予測絶対誤差率

Fig. 5 Ratio of absolute mean error in prediction of number of moving people for each direction and each day

3フロア第1エリアにおける、11日目(月・祝)における北方向の平均速度の実測値と各手法での予測値を図9に、6日目(水)におけるそれらの値を図10にそれぞれ示す。なお、施設側の機密保持のため、測定期間中の最大値を1とした比率で結果を表示しているが、人数のオーダーは数百人である。

5.4 考察

5.4.1 方向別移動人数の予測

表1より、2つの提案手法のほうが比較手法より誤差の少ない方向別移動人数の予測が可能であり、特に提案手法の中でも次元数 c が1のほうが $c=2$ と比較して有意に誤差が少なく、精度が高いことがわかる。誤差率20%というのは、絶対人数の把握という点では乖離するケースもある




図 6 方向別平均速度の日別予測絶対誤差率

Fig. 6 Ratio of absolute mean error in prediction of speed of moving people for each direction and each day




図 7 予測手法の効果が大きい11日目(月・祝)における方向別移動人数の予測例(期間中最大値=1)

Fig. 7 Example of predicted number of moving people on 10th day (Monday, National holiday)

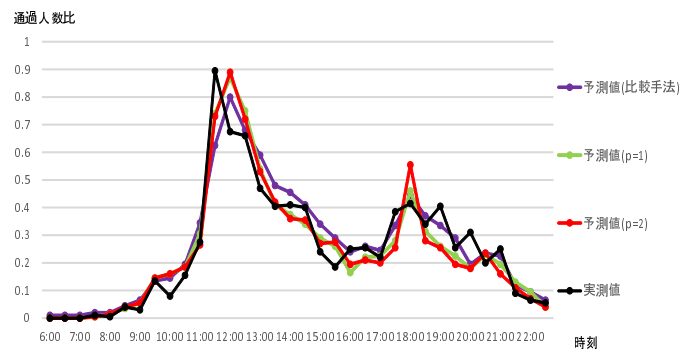


図 8 予測手法の効果が小さい6日目(水)における方向別移動人数の予測例(期間中最大値=1)

Fig. 8 Example of predicted number of moving people on 6th day (Wednesday)

が、1日での方向別移動人数の増減という観点からは、施設管理支援に役立てられる精度であると考えられる。

次にその要因について考察する。図5に日別の各手法の予測絶対誤差率をそれぞれ示す。図5からわかるように、提案手法は比較手法と比べ、第1, 2, 3, 4, 11日目のよう




図 9 予測手法の効果が大きい 11 日目 (月・祝) における方向別平均速度の予測例

Fig. 9 Example of predicted average of speed of moving people on 10th day (Monday, National holiday)




図 10 予測手法の効果が小さい 6 日目 (水) における方向別平均速度の予測例

Fig. 10 Example of predicted average of speed of moving people on 6th day (Wednesday)

な、休日及びその前後の日において、有意に誤差が少ない傾向がわかる。一方で、第 5, 6, 7, 8 日のような平日では、ほとんど精度差がないこともわかる。その要因をさらに考察するため、最も提案手法の効果が大きい第 11 日目の実測値と各予測値を図 7 に、ほとんど効果がない第 6 日目の実測値と各予測値を図 8 にそれぞれ示す。図 7 を見ると、実測値では 11 時から 15 時まで 0.5 以上となっており、各提案手法はやや数値が低いもののその傾向は予測できている。一方、比較手法では 14 時ごろから人数が低めに予測されており、これが提案手法と比較して精度が低い原因と考えられる。理由として、図 8 における平日の実測値と比較すると、第 11 日目の比較手法による予測結果はそれと近いことがわかる。つまり、比較手法では同じ曜日のデータを説明変数とするため、同じ曜日でも祝日になった場合、予測値が乖離してしまうため、このような結果になったと考えられる。それを裏付けるように、図 8 を見ると第 6 日目 (水) では比較手法、各提案手法ともに実測値に近い結果となっており、これは水曜日は一般に祝日であるケースが少ないため、同じ曜日のデータを用いても祝日の影響を受け

ないため、比較手法でも精度高く予測できたためと考えられる。

まとめると、提案手法は比較手法と比べ、全体としては有意に高精度な予測ができ、特に祝日や休日及びおびその前後のデータに対して有効な予測ができる可能性があるといえる。一方、休日でも第 9 日目、第 11 日目では提案手法の効果はほとんどないことが分かったが、この原因として、第 2, 3 日目のような通常の土日のパターンと比較して、第 9, 11 日目のような祝日を含む土日の学習データが相対的に少ないことが一因として考えられるが、今後は学習データの増加や複数の休日データに対する適用を通じ、その原因を明らかにする必要がある。

5.4.2 方向別平均速度の予測

表 2 より、2 つの提案手法はどちらも比較手法より予測誤差が少ないが、特に次元数 $c=1$ の提案手法では比較手法より有意に誤差の少ない方向別平均速度の予測が可能になることがわかる。誤差率は約 8 % 程度であり、かなり精度高く方向別速度が予測できているため、施設内の日常的な人の移動傾向を把握し、施設管理支援に役立てることができる精度だと考えられる。

次に移動人数と同様にその要因について考察する。図 6 に日別の各手法の予測絶対誤差率をそれぞれ示す。図 6 からわかるように、移動人数と類似して、提案手法は比較手法と比べ、第 3, 9, 11, 12 日目のような、休日及びその前後の日において、有意に誤差が少ない傾向がわかる。一方で、第 5, 6, 7, 8 日のような平日では、ほとんど精度差がないことも移動人数と類似していることがわかる。その要因をさらに考察するため、最も提案手法の効果が大きい第 11 日目の実測値と予測値を図 9 に、効果がほとんどない第 6 日目の実測値と予測値を図 10 にそれぞれ示す。図 9 を見ると、実測値では 9:30~11:30 までが比較的移動速度が速く、その後は 60m/min 程度の速度となることがわかるが、比較手法ではそれよりやや高めの値が予測されており、各提案手法はより実測値に近い、比較手法より低い値を予測していることがわかる。この理由として、図 10 における実測値と比較すると、第 11 日目の比較手法による予測結果は平日である第 6 日目の値と近く、11:30 以降が比較的速い速度となっていることがわかる。つまり、平日は休日と比較し、ビジネス客などが多いため移動速度は速めとなる傾向があるが、比較手法では同じ曜日のデータを説明変数とするため、同じ曜日でも祝日になった場合、予測値が乖離してしまうため、このような結果になったと考えられる。それを裏付けるように、図 10 を見ると第 6 日目 (水) では比較手法、各提案手法ともに実測値に近い結果となっており、これは移動人数と同様、水曜日は一般に祝日であるケースが少ないため、同じ曜日のデータを用いても祝日の影響を受けないため、比較手法でも精度高く予測できたためと考えられる。

まとめると、比較手法は提案手法と比べ、次元数 $c=1$ の場合は有意に精度の高い移動速度の予測ができ、特に祝日や休日のデータに対してより有効な予測ができる可能性があるといえる。一方で移動人数と同様に、平日における提案手法の効果が少ないが、これは移動人数と同様、平日は回数が多く、比較手法のほうが使える学習データが多いためと考えられる。一方、全体として提案手法の効果が小さいが、これは図 9, 10 の実測値からわかるように、速度は移動人数と比較して、平日と休日に変動が小さいことが原因と考えられる。

5.4.3 提案手法に関するまとめ

結論を述べるため、本稿の課題を再掲する。

数時間から数日の欠損がある計測データから、各エリアにおける定常時の方向別移動人数と速度を、予測日以前のデータのみから予測可能か否か

実データを用いた結果及び考察より、提案手法は比較手法である時系列解析的な手法と比較し、平日の予測精度では大差がみられないが、休日やその前後、特に祝日ではより高精度に予測できることが明らかになった。これは商業施設では、平日と休・祝日、あるいはその前後の日で、人流が大きく変わることが原因であり、提案手法は想定通りの効果を発揮できたと評価することができる。

よって、上記課題については、可能と結論付けられる。

一方、平日や祝日を含まない土日のデータでは、効果があまり見られないが、これは比較手法ではこれらのデータを多く学習データとして使えるが、提案手法では学習データを選択するため相対的に少ないデータで予測しているためと考えられる。今後は短期的にはこれらの手法を対象日に応じて使い分ける方法で、中期的には学習データの増加によって、解決できると考えられる。また、今回は平日・休日の分類のみを特徴量として学習データを選択して予測モデルを作成が、今後は来場者数に影響する天候なども特徴量として考慮して予測モデルを作成することで、精度の向上が見込まれると考えられる。

6. 結言

本稿では、商業施設のような不特定多数の人間が集まる施設の管理・運営を支援するため、日々、その施設の中で起こる人流である方向別通過人数や速度を予測する常時型人流予測手法を提案した。本稿の貢献は以下のとおりである。

- 施設における人流予測の要件として、エリア毎の方向別通過人数や速度といった予測すべきデータと、制約条件として法定検日があり連続的なデータ計測が困難な点や、設備稼働準備や人およびモノの調達観点から 1 日以上前の予測が必要である点を明確化した

- 上記の制約に加え、多くの施設では休日、平日、祝日、休日前後では人流傾向が異なりうることに着目し、予測対象日およびその前後の属性に基づき、学習データを選択してモデルを作成後、予測する手法を提案した
- 提案手法を実際の商業施設において計測したデータへ適用した結果、従来の時系列分析に近い比較手法と比べ、方向別移動人数、平均速度ともに有意に高い精度で予測でき、特に休日や祝日、その前後のデータに対してより有効であることが明らかになった。

今後の課題として、長い連休を含むようなケースや、複数日間のイベントが開催されるようなケースにおける提案手法の改良および評価が挙げられる。

参考文献

- [1] 瀬尾 亨, 柳沼 秀樹, 福田 大輔, Plan-Action 構造を考慮した歩行者挙動モデリングとその適用—駅改札付近を対象として—, 土木学会論文集 D3, Vol. 68, No. 5, pp.679-690 (2012).
- [2] Ziebart, B. D., Ratliff, N., Gallagher, G., Mertz, C., Peterson, K., Bagnell, J. A., Hebert M., Dey A. K. and Srinivasa S., Planning-based prediction for pedestrians. *Proc. 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3931-3936 (2009).
- [3] Alahi, A., Goel, K., Ramanathan, V., Robicquet, A., Fei-Fei, L., and Savarese, S., Social LSTM: Human trajectory prediction in crowded spaces. *Proc. IEEE conference on computer vision and pattern recognition*, pp. 961-971 (2016).
- [4] 瀬戸 宏一, 濱田 朋之, 峯元 長, 生駒 要, 鉄道駅空間デザインへの人流シミュレーション技術適用—顧客協創アプローチ—, 日立評論, Vol. 92, No.7, pp.526-529 (2010).
- [5] 松林 達史, 清武 寛, 幸島 匡宏, 戸田 浩之, 田中 悠介, 六藤 雄一, 塩原 寿子, 宮本 勝, 清水 仁, 大塚 琢磨, 岩田 具治, 澤田 宏, 納谷 太, 上田 修功, 人流における学習型誘導技術のデータ同化, 人工知能学会論文誌, Vol. 34, No. 5, wd-F-1-11 (2019)
- [6] 上田 修功, 時空間予測技術に基づく先行的集団最良誘導, 応用統計学, Vol. 45, No. 3, pp. 87-102 (2016).
- [7] 松原 徳和, モバイル空間統計による動態人口把握: 観光防災, 帰宅困難者対策の観点から, 情報管理, Vol.60, No.7, pp.493-501 (2017).
- [8] Box, G. E. P. and Pierce, D. A., Distribution of Residual Autocorrelations in Autoregressive- Integrated Moving Average Time Series Models, *Journal of the American Statistical Association*, Vol. 65, No. 332, pp.1509-1526 (1970)
- [9] Box, G. E. P. and Jenkins, G. M., Time series analysis: forecasting and control, Holden-Day, San Francisco (1976)
- [10] Vasantha, S. K. and Lelitha, V., Short-term traffic flow prediction using seasonal ARIMA model with limited input data, *European Transport Research Review*, Vol. 7, Article No. 21 (2015).
- [11] Cools, M., Moons, E., and Wets, G., Investigating the variability in daily traffic counts through use of ARIMAX and SARIMAX models: assessing the effect of holidays on two site locations, *Transportation Research Record*, Vol. 2136. Issue. 1, pp.57-66 (2009).
- [12] Kwangbok, J., Choongwan, K., Taehoon, H., An estimation model for determining the annual energy cost budget

- in educational facilities using SARIMA (seasonal autoregressive integrated moving average) and ANN (artificial neural network), *Energy*, Vol. 71, pp.71-79 (2014).
- [13] 環境省 ZEB Portal 建築物のエネルギー消費状況, <http://www.env.go.jp/earth/zeb/detail/04.html> (最終閲覧日: 2019.12.9).
- [14] The International Organization for Standardization, ISO 7730:2005 Ergonomics of the thermal environment — Analytical determination and interpretation of thermal comfort using calculation of the PMV and PPD indices and local thermal comfort criteria, <https://www.iso.org/obp/ui/#iso:std:iso:7730:ed-3:v1:en> (最終閲覧日: 2019.12.9).
- [15] 国土交通省, 施設管理者のための建築物点検の手引き, <https://www.mlit.go.jp/common/001102388.pdf> (最終閲覧日: 2019.12.12).
- [16] 日立情報通信エンジニアリング, 人流計測サービス, <http://www.hitachi-ite.co.jp/br/br07.html> (最終閲覧日: 2019.12.9).