

OD ネットワーク分析による人流シミュレーション

北野 佑¹ 浅原 彰規¹

概要：公共施設や商業施設、工場・倉庫における、人や物の動きに関するデータ（動線データ）の分析・利活用が近年注目されている。本研究では、上記のような施設の運用効率化のための施策検討において、施策の事前評価を実現するために、動線データを活用した機械学習にもとづく人流シミュレーション手法を提案する。動線データを人の立ち寄り場所ごとに分割した後、人、壁、立ち寄り場所に関する相対的な距離特徴量を入力、次ステップの速度を出力とする予測モデルを勾配ブースティング回帰木にもとづき生成し、この予測モデルに用いた人流シミュレーション実験を行ったところ、某空港チェックインロビーにおいて計測データとシミュレーションデータの人密度値に関して相関係数が 0.929 となることを確認した。

Pedestrian Flow Simulation Based on OD Network Analysis

YU KITANO¹ AKINORI ASAHARA¹

1. はじめに

公共施設や商業施設、工場・倉庫における、人や物の動きに関するデータ（動線データ）の分析・利活用が近年注目されている。上記のような施設では、ディベロッパーと呼ばれる事業者によって土地の取得から建築、テナントへの賃貸、施設の運用までが統合的に行われている。利用者が屋内外をどのように移動し、何をしているかということ把握することで、施設の効率的な運用につなげることができると考えられる。そのため屋内外において動線データを測定し、利用状況を定量的に分析することで、施設内の混雑緩和や広告宣伝の施策へ繋げたり、施設のセキュリティや安全管理に対応可能なサービスやソリューションが求められている。

動線データを分析することで、人の動きのパターンの抽出等が可能になる。しかし例えばイベント会場におけるブースの配置変更後の動線評価等、現実に動線データが存在しないケースにおいて、分析を行うことはできない。そのため動線データ分析のみで施設運用改善の施策の有効性を事前に評価することは困難である。これに対し、動線データをシミュレーションによって生成することができると、施策案の評価が容易になる。既存の動線データと、展

示物や出入り口の配置といったレイアウト等の環境に関する変数の関係を機械学習でモデル化することで、施策を実施したあとのレイアウトでの動線データを生成するシミュレーションが構築できると考えられ、これによって検討している施策の効果について定量的に見積もることができる。

そのため、本研究では機械学習にもとづく人流シミュレーション技術の開発を行う。従来人流シミュレーションは、人に対し作用する力を、目的の場所へ向かう力、人間の相互作用、壁から受ける力などに分解し、それぞれを独立に設定することでシミュレーションを行う手法が提案されている [1,3-5]。しかし、レイアウト等の環境に関する変数以外にも人の速度や相互作用に関するパラメータを手で設定しなければならず、このパラメータ設定には試行錯誤を要していた。これに対し、本研究では計測された動線データから機械学習にもとづく予測モデルを生成して、人流シミュレーションを行うことにより、従来のパラメータ設定の試行錯誤を不要とする手法を提案する。施設内にて人が移動する際、何らかの立ち寄り場所に向かって経路を決定し行動することが多いため、計測された動線データから立ち寄り場所の情報を抽出し、機械学習にもとづき予測モデルを生成することにより、人流シミュレーションを行った結果について報告をする。

¹ (株)日立製作所 研究開発グループ
Hitachi Ltd., Research and Development Group

2. 提案手法

2.1 概要

本研究では、事前にレーザレーダ等によって得られた動線データから、機械学習を用いて予測モデルを生成することにより、人流シミュレーションを行う。ここでいう動線データとは、人の識別子、時刻、位置座標から構成されるデータのことである。

屋内外での移動の場合、人は途中の目的地を何種類か経由してから最終的な目的地に向かうことが多いと考えられる。例えば、空港などでは、「入口 → チェックインカウンター → 手荷物預かり → 出国ゲート」という人の立ち寄り場所（以下チェックポイントと呼ぶ）の遷移パターンが存在すると考えられる。このようなチェックポイントの遷移パターンを本研究では OD(Origin-Destination) ネットワークと呼ぶ。空港における OD ネットワークの例を図 1 に示す。

人はチェックポイントによって移動経路を変えるため、計測された全動線データから一つの予測モデルを生成すると予測精度が低くなると考えられる。そこで本研究では動線データを OD ネットワークごとに分割して、チェックポイントごとに予測モデルを生成する。この際、時刻 t の動線データから時刻 $t+1$ の歩行速度を予測するモデルを生成する。このモデルを用いて逐次的に予測を繰り返すことにより、人流シミュレーションを行うことが可能となる。

なお本研究では、目指すチェックポイントが決まった際に、そのチェックポイントに至るまでの動線をシミュレートすることを目標とし、どのチェックポイントを目指すかを予測することやチェックポイント内で滞留中の動きの予測等に関しては、本研究のスコープ外とする。以下では、予測モデルを生成する具体的な方式について説明する。

2.2 OD ネットワーク分析

先述の通り、予測モデルを生成する前に、動線データを OD ネットワークごとに分割する。この際、計測した動線データとチェックポイントの位置や形状情報を入力とする必要がある。基本的には動線データとチェックポイントの空間的な交差判定を行うことにより動線データの分割を行うが、チェックポイントの性質に注意を要する。

OD ネットワークにおけるチェックポイントには大きく分けて、通過型と滞留型の二種類が存在すると考えられる。通過型のチェックポイントは、移動エリアが切り替わる際に通過するもので、基本的に施設の出入口や途中のゲート等に相当する。これに対し、滞留型のチェックポイントは何らかの作業を行うために立ち寄る領域を指す。空港の例だと、チェックインカウンターや待合ベンチ、カウンター前の行列エリア等に相当する。




図 1 OD ネットワークの例。

Fig. 1 OD network examples.




図 2 滞留型/通過型チェックポイントの例。

Fig. 2 Examples of check points for staying and passing.

各チェックポイントに立ち寄ったと判定する際、通過型のチェックポイントでは動線データとチェックポイントの空間的な交差判定を行えばよいが、滞留型のチェックポイントでは、チェックポイントの領域内で、一定時間以上連続して、動線データの移動速度が閾値以下であった場合のみ、そのチェックポイントに立ち寄ったという判定を行う。通過型と滞留型のチェックポイントの違いについて、図 2 に示す。左図に示すような通過型のチェックポイントに関しては、赤の動線は緑のゲートに立ち寄ったと見なせる。しかし右図に示すようなカウンター前の緑のチェックポイントは滞留型であるため、赤の動線はカウンター前に立ち寄ったという判定を行うが、青の動線のようにカウンター前のチェックポイントと交差するが、滞留せず通り過ぎている場合は立ち寄っていないという判定を行う。

2.3 人流特徴量の算出方法

前節の OD ネットワーク分析により分割された動線データを用いて、時刻 t の動線データから時刻 $t+1$ の歩行速度を予測するモデルを機械学習にもとづき生成する。この際、動線データから人の移動を決定づける要素を人流特徴量として抽出することを考える。

目指すチェックポイントが決まっている場合、人は通常そのチェックポイントに向かって移動するが、周囲の壁や他の人などの障害物を避けて経路を選ぶ。しかし上記の座標情報をそのまま扱えば、レイアウト変更等に影響を受けるため、周囲の壁、人、チェックポイントまでの距離に関する情報を特徴量として算出する。また通常、移動中は急に止まったり、走ったりすることが少なく、歩行速度は連

続的に変化すると想定されるため、直前の歩行速度も特徴量に加える。

上記の特徴量を算出する方法について、図3にて説明する。図中の灰色の領域は壁を表し、赤マーカーは予測対象の人、青マーカーは他の人、緑マーカーはチェックポイントを示す。黒矢印は予測対象の人 i が、チェックポイント m を目指している際、時刻 t において向いている方向であり、 $\mathbf{r}_i(t) = (x_i(t), y_i(t))$ を時刻 t における人 i の二次元座標とすると、 $\mathbf{v}_i(t) = \mathbf{r}_i(t) - \mathbf{r}_i(t-1)$ の指すベクトルがその方向に相当する。この方向を基準として様々な方向に関して、壁や人、チェックポイントまでの距離特徴量を算出する。

まず時刻 t における人 i の方向 $k (k = 0, \dots, K-1)$ に関する領域を、

$$\Theta_k(i, t, R) = \left\{ (x_i(t) + r \cos \theta, y_i(t) + r \sin \theta) \mid 0 < r < R, k \leq \frac{\theta - \theta_i(t)}{\Delta\theta} \leq k+1 \right\} \quad (1)$$

とする。ここで $\theta_i(t)$ は $\mathbf{e}_x = (1, 0)$ から見た $\mathbf{v}_i(t)$ のなす偏角であり、 R は距離の閾値、 $\Delta\theta$ は各領域を示す角度幅に相当する。

壁 j の領域を ω_j とした時の、このとき方向 k に関して、壁 j までの最近傍距離は、

$$c_{j,k}(i, t) = \begin{cases} \min_{\mathbf{w} \in (\omega_j \cap \Theta_k(i, t, R_w))} \|\mathbf{w} - \mathbf{r}_i(t)\| & (\omega_j \cap \Theta_k(i, t, R_w) \neq \emptyset) \\ R_w & (\omega_j \cap \Theta_k(i, t, R_w) = \emptyset) \end{cases} \quad (2)$$

と表すことができる。ここで R_w は壁特徴量に関する閾値である。これを用いることにより、方向 k に関する壁の距離特徴量は、

$$w_k(i, t) = \min_j c_{j,k}(i, t) \quad (3)$$

と定義する。

方向 k に対する人 $i' (\neq i)$ との距離に関しては、人特徴量に関する閾値を R_p とすると、

$$g_{i',k}(i, t) = \begin{cases} \|\mathbf{r}_{i'} - \mathbf{r}_i\| & (\mathbf{r}_{i'} \in \Theta_k(i, t, R_p)) \\ R_p & (\mathbf{r}_{i'} \notin \Theta_k(i, t, R_p)) \end{cases} \quad (4)$$

と表すことができるため、方向 k に関する人の距離特徴量は、

$$p_k(i, t) = \min_{i' \neq i} g_{i',k}(i, t) \quad (5)$$

と定義する。

チェックポイントに関しても、人の特徴量と同様に考えることができる。現在人 i が目指しているチェックポイント m の座標を \mathbf{q}^m とすると、方向 k に対するチェックポイ




図3 周囲のオブジェクトとの距離にもとづく人流特徴量。

Fig. 3 Distance feature between each pedestrian and surroundings objects.

ント m との距離に関しては、

$$h_k^m(i, t) = \begin{cases} \|\mathbf{q}^m - \mathbf{r}_i\| & (\mathbf{q}^m \in \Theta_k(i, t, R_d)) \\ R_d & (\mathbf{q}^m \notin \Theta_k(i, t, R_d)) \end{cases} \quad (6)$$

と表すことができる。但しチェックポイントの特徴量に関する閾値を R_d とした。これは一つのチェックポイントが一つの位置座標を持つ場合についての定式化だが、例えば空港のチェックインカウンタ等は複数の位置に存在することもある。そのため、一般化して一つのチェックポイントが複数の位置座標を持つ場合について、距離特徴量を算出する。チェックポイント m の位置を $\mathbf{q}_l^m (l = 1, \dots, L^m)$ とすると、方向 k に関するチェックポイント m の距離特徴量は、

$$d_k^m(i, t) = \min_l h_{l,k}^m(i, t) \quad (7)$$

と表すことができる。但し、

$$h_{l,k}^m(i, t) = \begin{cases} \|\mathbf{q}_l^m - \mathbf{r}_i\| & (\mathbf{q}_l^m \in \Theta_k(i, t, R_d)) \\ R_d & (\mathbf{q}_l^m \notin \Theta_k(i, t, R_d)) \end{cases} \quad (8)$$

である。

最後に直前の歩行速度の特徴量について説明する。レイアウトや位置に依存しないような特徴量とするため、相対的な歩行速度を特徴量を考える。直前の歩行速度は $\mathbf{v}_i(t) = \mathbf{r}_i(t) - \mathbf{r}_i(t-1)$ によって定義されるが、これを $\mathbf{v}_i(t-1)$ から見た時の正面方向、横方向の成分に分割すると、

$$v_i^f(t) = |\mathbf{v}_i(t)| \cos(\theta_i(t) - \theta_i(t-1)) \quad (9)$$

$$v_i^l(t) = |\mathbf{v}_i(t)| \sin(\theta_i(t) - \theta_i(t-1)) \quad (10)$$

と表すことができるため、速度特徴量として $\mathbf{v}_i^r(t) = (v_i^f(t), v_i^l(t))^T$ を用いる。なお $\mathbf{v}_i^r(t+1)$ は直後の歩行速度となるため、予測対象のパラメータに相当する。

2.4 人流シミュレーション

前節にて算出された人流特徴量を用いて、

$$\mathbf{v}_i^r(t+1) \approx f^m(\Omega_i(t), \Psi_i(t), \Phi_i^m(t), \mathbf{v}_i^r(t)) \quad (11)$$

を満たす予測モデル f^m を生成する．ここで， $\Omega_i(t) = \{w_k(i, t)\}_{k=0}^{K-1}$ ， $\Psi_i(t) = \{p_k(i, t)\}_{k=0}^{K-1}$ ， $\Phi_i^m(t) = \{d_k^m(i, t)\}_{k=0}^{K-1}$ とした．前節の OD ネットワーク分析により，チェックポイント m を目指している i, t についてのデータ集合 D_m を抽出し，機械学習にもとづき，学習する．

予測モデル f^m を用いて人流シミュレーションを行う際には，レイアウトに関する情報として，壁 w_j とチェックポイント \mathbf{q}_i^m が必要なだけでなく，初期人流として，シミュレーション開始位置 $\mathbf{r}_i(t_i)$ ，その時の速度 $\mathbf{v}_i(t_i)$ と，目指すチェックポイント m の情報を最初に用意する必要がある．ここで t_i は人 i が発生する時刻を指す．これらの情報をもとに，逐次的に人の位置を予測し，各人が目指すチェックポイントから一定の距離以内に到着した際に，その人流を消す処理を行う．

本方式では，壁等との距離を特徴量として用いて，次の位置を予測しているが，シミュレーション時に人が障害物に衝突する可能性もあり得るため，予測位置の補正処理を行う．壁に対して一定の距離 δw 以内に予測位置が存在する場合，壁に対して距離 δw となるバッファを設定し，人を壁のバッファに対して反射させることにより，位置を補正する処理を行う．具体的には，壁に対して垂直方向の反射係数 $R_v \in [0, 1]$ と水平方向の反射係数 $R_h \in [0, 1]$ にもとづき，人を反射させる．例えば $R_v = 1, R_h = 0$ とすると，人の動きが壁のバッファに沿うように補正される．

以上，逐次的な予測処理と予測位置の補正を行いつつ，人流シミュレーションを行う．

3. 実験

3.1 利用データ

本研究における提案方式の有効性を検証するため，人流シミュレーション実験を行った．本実験では某空港内のチェックインロビーを対象として実験を行った．2018年3月31日から2018年4月1日までの2日間の動線データをレーザーダによって1秒ごとに取得した．計測に関する詳細は [6] に示す通りである．レコード数は 24,827,500 であり，人に関する ID の数は 942,608 であった．それぞれの屋内地図と計測領域内におけるチェックポイントを図 4 に示す．赤領域が計測範囲を示し，緑がチェックポイントを表す．また各チェックポイントの詳細を表 1 に示す．

3.2 実験条件

先述の OD ネットワーク分析にもとづき，表 1 に示すチェックポイントを目指す動線データごとに分割した．分割後の動線データより，人流特徴量を算出し，機械学習にもとづきそれぞれ予測モデルを学習した．人流特徴量の抽出時のパラメータは， $K = 20, \Delta\theta = \frac{\pi}{10}, R_w = 50[\text{m}], R_p =$



図 4 計測対象である空港チェックインロビーの地図．

Fig. 4 Measurement area (red) and check points (green) in the airport.

表 1 計測対象内のチェックポイント情報．

Table 1 Check point for the airport.

id	area name	type
1	Entrance	passing
2	Benches	staying
3	Charger	staying
4	ATMs	staying
5	VIP counters	staying
6	Queue1 (for VIP counters)	staying
7	Check-in counters	staying
8	Queue2 (for check-in counters)	staying
9	Baggage drops	staying
10	Queue3 (for baggage drops)	staying
11	Queue4 (for baggage drops)	staying
12	Gate1 (for VIP)	passing
13	Gate2 (for elevator)	passing
14	tax center	staying
15	Wi-Fi counters	staying
16	Wi-Fi queue	staying
17	Automated immigration	staying
18	Counters	staying
19	Exit (L)	passing
20	Exit (R)	passing
21	Departure gate	passing
22	Departure gate queue	staying

50[m], $R_d = 100[\text{m}]$ とした．機械学習の手法は勾配ブースティング回帰木 [2] を用いた．なお 2018 年 3 月 31 日の動線データをモデル学習に用いた．

2018 年 4 月 1 日に関して，人流シミュレーションを行った．先述の通り，人流シミュレーションを実行する際，初期人流として，シミュレーション開始位置 $\mathbf{r}_i(t_i)$ と開始時刻 t_i ，速度 $\mathbf{v}_i(t_i)$ と目指すチェックポイント m の情報を与える必

要がある。シミュレーションの範囲である2018年4月1日に計測した動線データに関して、ODネットワーク分析を適用することで上記の初期人流を得た。なおシミュレーション時の補正パラメータは $R_h = 1.0$, $R_v = 0.01$, $\delta w = 0.1$ [m] とした。

シミュレーションの条件と同じ時間帯に計測されたデータ(真値データ)とシミュレーションによって動線データを比較することで、シミュレーション精度を評価した。人流シミュレーションの結果から、どのエリアがいつどのくらい混むか、等の統計情報を分析することができると、レイアウト変更等の施策を検討しやすくなる。そのため、動線データの比較だけではなく、人密度ヒートマップによる評価も行った。大きさ $G = 1.0$ [m] のメッシュを生成し、その中を通過した人の延べ人数をカウントし、その大小に応じてヒートマップを作成する。真値データに関しても人密度ヒートマップを作成し、シミュレーションの人密度ヒートマップと比較することで精度評価を行った。この際、本実験ではチェックポイント間の移動をスコープとしてシミュレーションしているため、各ヒートマップからチェックポイントのエリア内の移動に関する動線データを除いて評価を行った。

3.3 シミュレーション結果

個々の動線に着目し、ODネットワークごとに真値データとシミュレーションデータを比較してみた結果を図5に示す。左図は入口から待合ベンチへ向かっているODネットワークである。真値、シミュレーションの両データにおいて、ほとんどの人がまっすぐ待合ベンチに向かっていることが分かる。中図は入口からエコノミーカウンタの行列に向かうODネットワークであるが、シミュレーションデータにおいて、チェックポイントを通り過ぎて迷子になっている人も少数存在している。本アプローチはチェックポイントまでの経路から外れても、移動方向を修正せずにそのまま移動する傾向にある。学習時に用いた動線データ内に、チェックポイントまでの経路を外れて移動方向を修正するパターンがほとんど存在していないためと考えられる。学習データに存在しないパターンは、機械学習を用いても予測できないため、これを改善するためには、学習データの数を増やすか、施設内の情報を用いた補正処理などが必要になると考えられる。右図は、左側の出口からVIPカウンタに向かうODネットワークであるが、中図の場合と同様に、シミュレーション結果を見ると、チェックポイントまでたどり着けていない結果となった。真値データをみてもわかる通り、このODネットワークに関する動線は二人分のデータのみとなっている。そのためこのODネットワークに相当する学習データは少数であったため、上手く予測モデルが学習できずチェックポイントまでたどり着けなかったと思われる。




図5 計測データ(赤)とシミュレーションデータ(青)の比較(左:入口からベンチ, 中:入口からチェックインカウンタ前行列, 右:左出口からVIPカウンタまで)。

Fig. 5 Trajectory comparison between measurement (red) and simulation (blue) with each OD network (left: from Entrance to Benches, center: from Entrance to Queue for check-in counters, right: from Exit (L) to VIP counters).

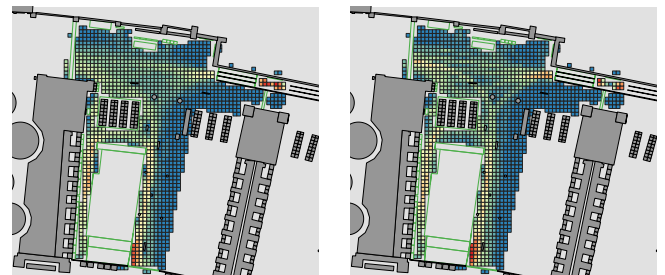


図6 計測データ(左)とシミュレーションデータ(右)に関する人密度ヒートマップ比較。

Fig. 6 Heatmap comparison between measurement (left) and simulation data (right).

これに対し、真値データとシミュレーションデータの人密度ヒートマップを比較した結果を図6に、メッシュごとの延べ人数値を比較した結果を図7に示す。この結果を見ると、真値とシミュレーションに関して、ヒートマップの傾向はよく似ていることが確認できる。真値とシミュレーションに関するメッシュごとの延べ人数値の相関係数は0.929という結果になった。これらの結果より、個々の動線を再現することはできていないが、統計的な観点では高精度にシミュレーションができていると考えられる。

なお本研究では、チェックポイント間でのシミュレーションを対象としていたが、実際にはエコノミーカウンタ前の行列のようにチェックポイント内での人の移動も存在する。そのためチェックポイント内のシミュレーションモデルも検討する必要がある。またレイアウト等の環境が変更された時の評価実験を行い、提案手法の汎化性向上等を検討する必要がある。




図 7 計測データとシミュレーションデータに関するメッシュごとの延べ人数値の散布図.

Fig. 7 Scatter plotting of people number inside of each mesh between measurement and simulation data.

4. おわりに

施設運用の効率化につながる施策検討において、施策の効果を事前に定量評価することは困難であった。本研究では施策の事前評価を実現するために、動線データを活用し、機械学習に基づく人流シミュレーション手法を提案した。

移動中の立ち寄り場所との交差判定を行うことにより動線データを分割し、壁、人、立ち寄り場所に関する距離の特徴量を算出後、勾配ブースティング回帰木を用いて予測モデルを生成することにより、人流シミュレーションを行う手法を提案した。空港内の動線データに提案手法を適用して、計測データとシミュレーションデータを比較したところ、個々の動線を再現するのは困難であったが、人密度ヒートマップに関して相関係数が 0.929 となることを確認した。これらの結果より、本手法によって得られたシミュレーションデータを統計分析することで、施策の効果を定量評価することができると考えられる。

今後は下記に示す項目に取り組む予定である。

- 行列のような立ち寄り場所内でのシミュレーション
- レイアウト等の環境が変化した際の評価実験

参考文献

- [1] Dirk Helbing and Peter Molnar, "Social force model for pedestrian dynamics," *Physical review E*, vol. 51, No. 5, P. 4282, 1995
- [2] Jerome H Friedman, "Stochastic gradient boosting," *Computational Statistics & Data Analysis*, vol. 38, No. 4, P.367–378, 2002.

- [3] Burstedde, Carsten, et al. "Simulation of pedestrian dynamics using a two-dimensional cellular automation," *Physica A: Statistical Mechanics and its Applications* 295.3-4 (2001): 507-525.
- [4] Nishinari, Katsuhiko, et al. "Extended floor field CA model for evacuation dynamics," *IEICE Transactions on information and systems* 87.3 (2004): 726-732.
- [5] Chraïbi, Mohcine, et al. "Generalized centrifugal-force model for pedestrian dynamics," *Physical Review E* 82.4 (2010): 046111.
- [6] 日立情報通信エンジニアリング: 動線計測ソリューション, <https://www.hitachi-ite.co.jp/products/o-tracking/index.html>