

時空間的に散在する人密度観測からの 群衆分布パターン推定法の提案

成元 棕祐^{1,a)} 山田 遊馬¹ 内山 彰¹ 山口 弘純¹ 東野 輝夫¹

概要：都市における群衆の分布状況や移動傾向を把握するため、これまでにスマートフォンやインフラ設備を利用した様々な手法が提案されている。各地で時々刻々と変化する分布状況を把握するためには、多数のユーザから位置や周辺の混雑状況などの情報を収集したり、カメラなどの機器を多数設置する必要があるが、実際にはプライバシーや設置条件などの制約により、全領域に対して網羅的に情報を収集することは難しい。本稿では、領域全体の群衆分布状況を推定することを目的として、時空間的に散在する人密度観測の集約法を提案する。提案手法では、一定時間ごとに蓄積した人密度の観測に対し、時空間的な観測ごとの特性に応じた重みを考慮した統合を行い、群衆分布をサンプリングする。さらに、一定時間ごとにサンプリングした群衆分布に対してクラスタリングを適用することで、群衆分布の時空間的なパターンを抽出する。シミュレーションによる評価の結果、群衆が4つの領域を順に移動するモビリティに対して、群衆分布の真値に対するクラスタリング結果との一致度は今回評価を行った中で最も低い観測頻度において92.9%であることが確認できた。

キーワード：群衆分布推定, 人密度観測, クラスタリング, k-means++法

1. はじめに

都市計画やマーケティング, 人流制御, 災害時の避難計画などにおいて、時々刻々と変化する群衆の分布状況や移動傾向を把握することは重要である。このため、これまでに様々な手法が提案されている。文献 [1], [2] では、スマートフォンで得られる GPS などの位置情報をユーザから収集し、混雑状況や移動傾向を把握する。しかし、プライバシーの観点からユーザが位置情報の提供を拒む場合も多く、十分な量の位置情報を収集することは容易ではない。監視カメラの映像などを用いた人流や混雑の推定手法 [3], [4], [5] も数多く存在するが、撮影範囲が限られるため、都市全体の群衆分布や移動傾向を把握するためには多数のカメラ設置が必要となるうえ、プライバシーの制約から防犯以外の目的で利用できるとは限らない。また、監視カメラは施設ごとに所有者が異なり、全ての所有者から映像の利用許可を得ることは難しいという問題もある。

一方、スマートフォンを用いたユーザ参加型センシングによる群衆分布推定法では、参加ユーザが周辺の混雑状況

をセンシングしサーバに集約することで、システムに参加していない人々も含めた混雑状況を推定できる。例えば、文献 [6] ではスマートフォンで撮影された群衆の画像から対象領域の人密度を推定する。スマートフォンに搭載された加速度センサから推測される歩きやすさと雑踏の音に基づき人密度を推定する手法も存在する [7]。Bluetooth や Wi-Fi の MAC アドレスの観測数に基づき周辺の人密度を推定する手法も提案されている [8], [9]。

以上のように、群衆の分布や移動傾向を把握するための様々な手法が提案されているが、常に全ての領域から観測を得ることは難しいため、一部の領域に対して得られた断片的な観測に基づき、領域全体の群衆分布を推定するための枠組みが必要となる。そこで本研究では、事前に多様な人密度の観測を蓄積し、群衆分布の時空間的なパターンを抽出しておくことで、断片的な観測からの群衆分布推定の実現を目指す。

本研究では、群衆分布の時空間的なパターンの抽出を実現するため、時空間的にスパースかつ多様な範囲に対する人密度観測の集約法を提案する。提案手法では、日時やイベントなどの状況に応じて群衆分布のパターンが複数存在すると仮定し、時空間的に散在する人密度の観測を蓄積することでこれらのパターンを学習する。想定環境での大きな課題として、ユーザから得られる観測が時空間的に散在

¹ 大阪大学 大学院情報科学研究科
Graduate School of Information Science and Technology, Osaka University

^{a)} r-narimoto@ist.osaka-u.ac.jp

しており、観測の範囲や精度も様々である点が挙げられる。したがって、これらの観測の多様性を考慮した集約方法が求められる。

そこで、一定時間内に蓄積した多様な観測に対して、それぞれの特性に応じた重みを考慮した統合を行うことで、一定時間ごとの群衆分布をサンプリングする。さらに、サンプリングした群衆分布に対して、クラスタリングアルゴリズムの一つである k-means++法 [10] を適用することで、クラスタ群として代表的な分布を抽出する。また、群衆分布の時間的な遷移パターンを推定するため、網羅的に群衆分布のサンプリング間隔を変えながらクラスタリングを繰り返し、抽出されたクラスタ群の分離度が最大となるサンプリング間隔を決定する。以上のようにして人密度観測を集約することで、群衆分布のパターンとその遷移順序および間隔が得られる。これによって、少数の断片的な観測が得られた時に、提案手法により集約しておいた時空間的な群衆分布のパターンを照合することで、現在の領域全体の状況を推定するとともに、将来の分布状況を予測できるようにする。

提案手法の性能を評価するため、群衆が4つの領域を順番に120分ごとに移動するモビリティをシミュレーションにより再現した。評価結果より、正しい群衆分布から抽出した群衆分布パターンと抽出された群衆分布パターン（クラスタリング結果）の一致度は今回評価を行った中で最も低い観測頻度において92.9%であることが確認できた。また、推定の結果得られたサンプリング間隔は120分となり、シミュレーションにより再現した遷移パターンと一致することが分かった。

2. 関連研究

2.1 インフラ設備を用いた群衆密度推定法

群衆の分布状況を推定するための手法として、監視カメラや固定型センサ等から得られるデータを用いて推定する手法が挙げられる。文献 [11] では、監視カメラの映像を利用して映像中の局所領域時間相関変化を分析することで、群衆の局所的な動きを検出し、一定時間ごとに累積することで混雑状況の推定を実現している。文献 [12] では、監視カメラの映像にウェーブレット変換を適用することで人の頭部領域を抽出する。さらに、カメラ映像を透視変換をすることで群衆密度の推定に成功している。文献 [13] では、地理情報システムを用いて監視カメラの映像を射影変換し、真上からの俯瞰画像に変換することで混雑度推定を実現している。文献 [14] では、累積モザイク画像差分法を用いることで、不規則に移動する群衆領域を抽出し、群衆密度の推定を実現している。文献 [15], [16] では、ステレオカメラを用いて対象領域を撮影し、その映像から混雑状況を推定することで高精度な推定を実現している。文献 [17] では、監視カメラの映像から人を群として認識することで、人が

重なって映るような映像からでも高精度な群衆密度推定を実現している。監視カメラ映像を用いた群衆密度推定法は比較的高精度であるが、広範囲の群衆分布を把握するためには、多数のカメラを設置する手間がかかるうえ、プライバシー上の問題にもなりやすい。

文献 [18] では、Wi-Fi などの無線センサー間において人の混雑状況に応じて RSSI 値や LQI 値の平均や分散が変化することに注目し、群衆密度を推定する。文献 [19] では、レーザレンジスキャナを設置することで領域内の人口密度を推定するとともに、その移動軌跡を高精度に把握できる。しかし、レーザレンジスキャナは障害物に弱いため、ある程度の台数を設置する必要がある。また監視カメラや Wi-Fi などのような普及が進んでいる機器とは異なり、新たな導入が必要となるため設置コストが比較的高い。

2.2 携帯端末を用いた群衆密度推定法

スマートフォン等の携帯端末を用いて、GPS による位置情報や Wi-Fi 基地局との通信履歴から群衆密度を推定する手法も多数提案されている。文献 [1] では、スマートフォンから得られる GPS トレースの情報を元に群衆の移動パターンを分析し、都市レベルにおける混雑状況及び遷移の推定を実現している。しかし、推定のためには対象領域に存在するすべてのユーザからの GPS 位置情報の提供が必要となり、提供してもらうにはユーザの同意が必要となる。そのため、常に推定に十分な量の位置情報が得られるとは限らない。文献 [20] では、混雑状況に応じて変化する二酸化炭素濃度を計測することで電車内の混雑度を推定している。しかし、二酸化炭素センサを装着する必要があるうえ、空気が十分に循環している屋外環境では実現できない。文献 [21] では、携帯端末から発信される Wi-Fi プローブ要求をキャプチャし、端末数と領域内の人のまとまりを表すクラスター数を推定することで群衆密度の推定を実現している。文献 [9] でも同じく、アクセスポイントに対する Wi-Fi プローブ要求を利用して鉄道車内での混雑状況の推定を実現している。文献 [8] では、スマートフォン同士の Bluetooth による通信の電波強度などのセンサ情報を用いて、領域内の端末の絶対数に依存しない混雑状況推定を実現している。文献 [6] では、スマートフォンのカメラを用いて群衆の俯瞰画像を撮影し画像処理を行うことで群衆の人数を推定している。文献 [7] では、スマートフォンに搭載された加速度センサから人の歩行状態を認識することで、その領域の群衆密度を推定する。これらの手法は多くの人々が所有するスマートフォンを利用するため、低コストに対象領域の群衆密度を推定可能である。しかし、周辺の混雑を観測する参加ユーザが常に対象領域全体に存在し、頻繁に観測を行ってくれるとは限らないため、観測が得られない領域も存在するという点が課題である。

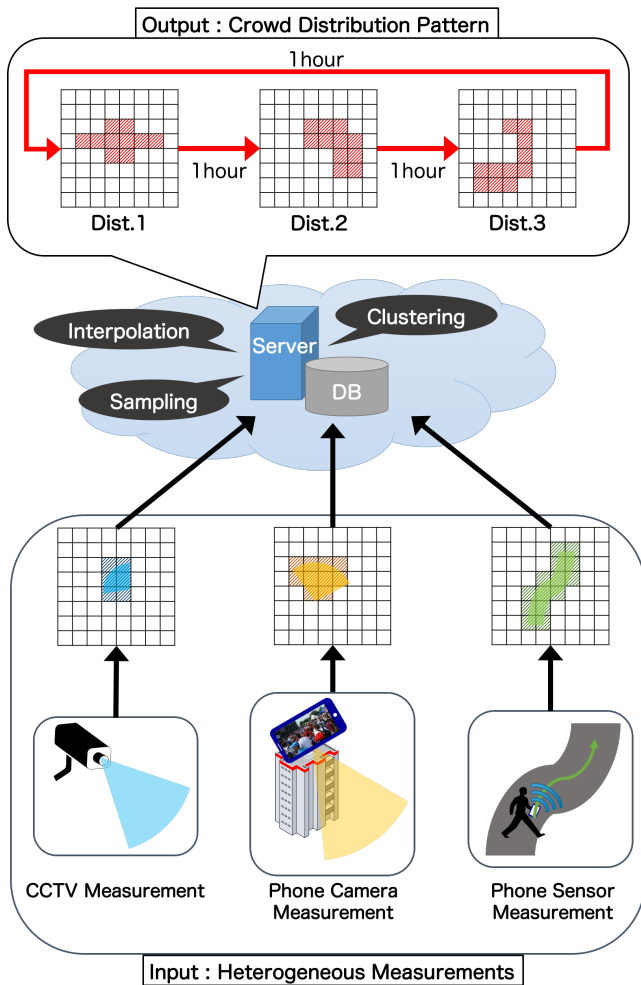


図 1 提案手法の概要

3. 提案手法

3.1 概要

図 1 に提案手法の概要を示す。提案手法では、都市街区などの広範囲な領域を対象として、群衆分布の空間的なパターンおよびそれらパターン間の時間的な遷移パターンの把握を目的とする。以降では、簡単のため領域を同一サイズのセルに分割し、各セル内の群衆密度は一律であると仮定する。スマートフォンカメラや加速度、Bluetooth などによる混雑推定法 [6], [7], [8] や各所に設置されたカメラ映像からの群衆密度推定法 [11], [17] など、観測範囲や精度の異なる方法によって、各セルにおける群衆密度が様々なタイミングでクラウドサーバに送信される。観測の範囲は複数のセルにまたがっている場合もあれば、単一のセルの場合もある。クラウドサーバでは、蓄積した人密度の観測集合から得られる各時刻の群衆分布に対して時空間的にクラスタ分析を行うことにより、(空間的な) 群衆分布のパターンならびにそれらの群衆分布パターン間の (時間的な) 遷移パターンを推定する。このため、サンプリング間隔 ΔT ごとに得られた人密度の観測を集約することで、時

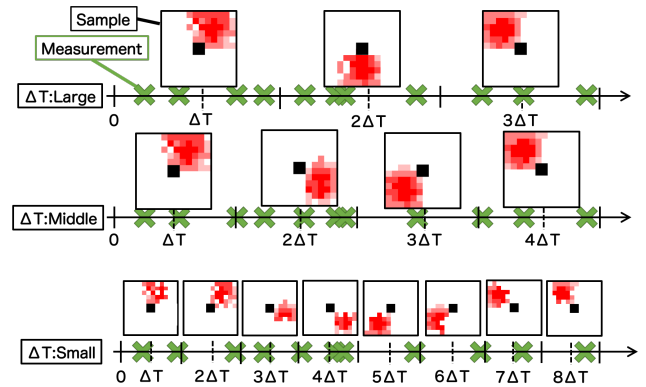


図 2 ΔT の違いによるサンプリング結果の変化

刻 $\Delta T, 2\Delta T, \dots$ における群衆分布を算出する。

しかし、観測は時空間的にスパースであるため、群衆分布のパターン推定の対象となる時刻 $T_n = n\Delta T$ ($n \in \mathbb{Z}_{>0}$) のみの観測では、領域全体の群衆分布 D_n を直接把握できない。このため、提案手法では $((n-1/2)\Delta T, (n+1/2)\Delta T]$ の期間に得られた観測を統合することで、時刻 $n\Delta T$ の群衆分布 D_i を得る (群衆分布のサンプリング)。群衆分布のサンプリングを行う際には、期間 $((n-1/2)\Delta T, (n+1/2)\Delta T]$ 内に得られた観測の精度と観測時刻を考慮して重み付けした上で、複数の観測を重畳して各領域の密度を計算する。

ΔT を長くするほど多くの観測を得られるが、一方で ΔT が長すぎると期間 ΔT に群衆の移動が発生しやすくなり、異なる複数の群衆分布が集約された結果、適切な群衆分布パターンの抽出が困難になる。例えば、図 2 に示すように ΔT が小さい場合、絶対的な観測数が少なくなるため、サンプリング結果は誤差の大きい群衆分布になってしまう。一方、 ΔT が大きい場合は、本来別れるべき群衆分布パターンが一つの群衆分布にまとめられてしまうなど、群衆分布パターンの情報が損失する可能性がある。このため、継続期間が最も短い群衆分布のパターンに合わせて、 ΔT を決定すべきである。しかしながら、どのような群衆分布のパターンが存在しているかは分からないため、提案手法では、定めた範囲で網羅的に ΔT を変化させ、分離度を指標として最も適切な ΔT を決定する。適切な ΔT を決定する方法の詳細は 3.3.3 項で述べる。

群衆分布パターンの抽出には、k-means++法によるクラスタリングを用いる。時刻 T_n ($n = 1, 2, \dots, N$) において、サンプリングの結果得られた N 個の群衆分布 D_n ($n = 1, 2, \dots, N$) に対し、k-means++法 [10] を適用し、 N 個の群衆分布を K 個のクラスタに分類する。各クラスタは類似する群衆分布をグループ化したものであるため、それぞれのクラスタが 1 つの群衆分布パターンに相当すると考えることができる。k-means++法では分割するクラスタ数 K を与える必要があるが、実際には対象領域において存在する群衆分布のパターン数 K は未知である。したがって、提案手法では Gap 統計量 [22] に基づき適切な K

を定める。

以上のようにして、 ΔT の値を網羅的に変えながら、 ΔT の値ごとに適切な K を決定し、 $(\Delta T, K)$ の組を得る。最終的に得られた組のうち最も分離度が高い組合せは、群衆分布サンプリングの結果を最もよく分割できる時間間隔 ΔT および群衆分布パターン数 \hat{K} である。すなわち、対象期間における対象領域の群衆分布は \hat{K} 個のパターンで代表され、そのパターン間の遷移は ΔT ごとに、サンプリング時の順序で発生すると見なせる。

3.2 群衆分布のサンプリング

本節では ΔT が固定されている場合における群衆分布のサンプリング方法を説明する。サンプリング間隔の前後に得られた観測を集約する際には、観測の精度とサンプリング時刻 $n\Delta T$ との時間的な類似度に基づき、重み付けをしたうえで、各セルの密度を計算する。本研究では、観測として観測対象となる領域内の平均密度が得られるものと仮定しているため、観測範囲が狭いほど観測対象に含まれるセルあたりの誤差は小さいと考えられる。したがって、観測 o の重み $w(o)$ を以下の式(1)のように定義する。

$$w(o) = \frac{1}{S(o)} \times \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(t(o) - n\Delta T)^2}{2\sigma^2}\right) \quad (1)$$

ここで、 $S(o)$ は観測 o の対象範囲面積、 $t(o)$ は観測 o が得られた時間を表す。前述のように観測の面積が小さいほど単位領域あたりの観測値の精度が良いと考えられるため、面積が小さいほど重みを大きくしている。また、サンプリング時刻との時間的なずれを考慮するため、正規分布を利用して観測時刻がサンプリング時刻 $n\Delta T$ に近いほど重みを大きくしている。正規分布の分散 σ が小さいほど、観測時間が $n\Delta T$ に近いものをより重視することになる。本研究では、経験的に $\sigma = \Delta T/4$ と定めた。これは、 $n\Delta T$ の観測を $(n \pm 1/2)\Delta T$ の観測と比較して約7.3倍の重み付けをしていることになる。

以上より算出された各観測の重み $w(o)$ を用いて各セル r における推定人数 $n(r)$ を式(2)に表す。

$$n(r) = \frac{\sum_{o \in O(r)} w(o) \cdot c(o)}{\sum_{o \in O(r)} w(o)} \quad (2)$$

ここで、 $O(r)$ はセル r を含む観測の集合、 $c(o)$ は観測値を表す。

しかし、サンプリング期間中に全領域の観測が得られるとは限らないため、観測が得られなかった領域に関しては、周囲の推定人数から補完を行う必要がある。ここでは、単純な補完方法として隣接領域の平均値を用いることとした。補完は隣接領域のうち密度の推定値を持つ領域数が最大のものから順に行っていく。図3に補完の例を示す。このようにして統合と補完を行い、全てのセルの推定人数が決定されたものを、そのサンプリング時刻における群衆分布とみなす。

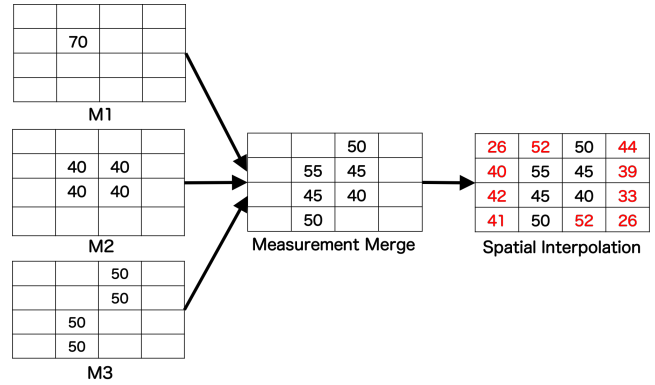


図3 観測の統合と空間的な補完




図4 サンプル群のクラスタリング

3.3 群衆分布パターンの抽出

3.3.1 k-means++法

3.2節にて得られたサンプル群に対するクラスタリングの例を図4に示す。本研究では、クラスタリングアルゴリズムとしてk-means++法[10]を用いる。教師なしクラスタリングアルゴリズムとして一般的に用いられるk-means法[23]では、ランダムに選択した K 個のサンプルを初期値としてクラスタリングを行う。しかし、k-means法は初期値に依存して局所解に収束する特性を持つため、解が安定しないという問題がある。一方、k-means++法では、各クラスタ間の距離が大きくなるよう、確率的に初期値を選択することにより、この問題を解決している。本研究において、クラスタ C とサンプル D_i の距離 $d(D_i, C)$ は、以下のように同一グリッド同士の値の差の二乗和で表される。

$$d(D_i, C) = \sum_r (D_i(r) - C(r))^2 \quad (3)$$

ここで、 $D_i(r)$ はサンプル D_i のセル r における密度、 $C(r)$ はクラスタ C 内に属する全サンプルに対するセル r の平均密度を表す。

3.3.2 クラスタ数の決定

k-means++法によるクラスタリングでは、分割すべきクラスタ数 K を事前に与える必要がある。しかし、実際には、群衆分布パターンの数は未知であるため、 K の値を適切に定める方法が必要となる。このため様々な手法が提案されているが、本稿では文献[22]で提案されているGap統計量に基づく手法を採用する。

Gap統計量は、クラスタ数を $K-1$ から K にした時の分離度の増分 $(F(K) - F(K-1))$ である。分離度 $F(K)$

$K \setminus \Delta T$	10	11	12	13	14	15
2	1.7	1.8	1.9	2.0	2.0	2.2
3	1.9	2.1	2.2	2.2	2.3	2.5
4	4.1	3.7	3.9	4.3	4.1	3.6
5	4.8	4.2	4.5	4.9	8.2	6.3
6					9.0	6.9

図5 サンプル間隔 ΔT の決定

はクラスタ数 K の場合に得られたクラスタリング結果の分割度合いを表す指標であり、以下の式で定義される。

$$F(K) = \frac{\sigma_b^2(K)}{\sigma_w^2(K)} \quad (4)$$

ここで、 $\sigma_w^2(K)$, $\sigma_b^2(K)$ はそれぞれ K 個のクラスタに分割した時のクラス内分散およびクラス間分散を表す。

分離度が大きいほど、良いクラスタリングが行えていることを示しており、Gap 統計量はクラスタ数を1増加させたときのクラスタリングの改善度を意味する。このため、提案手法では Gap 統計量に基づき、以下の式 (5) を満たすような最小の K を最適なクラスタ数として決定する。

$$F(K) - F(K-1) > F(K+1) - F(K) \quad (5)$$

3.3.3 サンプル間隔の決定

サンプル間隔 ΔT を決定する方法の流れを図5に示す。適切なサンプル間隔 ΔT は、時空間的に最もよく群衆分布のパターンを分割するような値になるべきである。したがって、提案手法では網羅的に ΔT を変化させ、それぞれについて 3.3.2 項で述べた方法に従って、クラスタ数 K を決定し、それぞれの分離度を算出する。最終的に、全ての ΔT に対してクラスタリングを行った結果、分離度が最大となるものを適切なサンプル間隔 $\hat{\Delta T}$ とする。これは以下の式で表される。

$$\hat{\Delta T} = \arg \max_{\Delta T} F(K_{\Delta T}) \quad (6)$$

ここで、 $K_{\Delta T}$ はサンプル間隔 ΔT においてクラスタリングを行った結果、得られたクラスタ数を表す。

4. 性能評価

4.1 評価環境

シミュレーションにより群衆分布のパターンとその時間的な遷移を再現し、性能評価を行った。シミュレーション領域は図6に示すような $960\text{m} \times 960\text{m}$ の領域とし、中央に群衆が通過できない $160\text{m} \times 160\text{m}$ の大きさの障害物を配置した。セルサイズは $80\text{m} \times 80\text{m}$ とし、領域を $12 \times 12 = 144$ 個のセルで表す。人密度の観測は1単位時間あたりの観測数の期待値 E は $5, 3, 1, 0.5$ とした。一回の観測で観測される領域の大きさは $80\text{m} \times 80\text{m}$ (1セル), $160\text{m} \times 160\text{m}$ (4セル), $240\text{m} \times 240\text{m}$ (9セル) のいずれかが等確率で決定さ




図6 シミュレーション領域

れる。観測値は、観測された C 個のセル内に存在するノード総数 N の1セルあたりの平均値 N/C が得られるものとした。なお、明示しない限り観測誤差は無いものとする。

シミュレーション領域の四隅いずれかに一定時間滞在した後、時計回りに次の四隅の領域に移動し、滞在を繰り返すようなノードモビリティを再現した。すなわち、群衆分布のパターンは4種類で、それらの時間遷移パターンは一定時間ごとに時計回りに移動するというものである。群衆分布の時間遷移パターンとして、滞在時間が均一の場合と、そうでない場合の2種類を用意した。シミュレーションの単位時間は1分とし、20日間 (28,800分) のシミュレーションを行った。

性能評価の指標として、クラスタリング結果の一致率を表す Adjusted Rand Index (ARI) [24] を用いて、群衆分布の真値に対するクラスタリング結果と観測に対するクラスタリング結果の一致率を評価した。ARI は、一方のクラスタリングで同じ (異なる) クラスタに属するサンプル組が、他方のクラスタリングで同じ (異なる) クラスタに属する割合を表す物であり、1に近いほど一致していることを示す。ARI は、クラスタ数が定められたとき、ランダムにサンプルをクラスタに分類した場合の一致率の期待値を0として、それを基準にクラスタリングの一致率を表す指標である。

4.2 評価結果

4.2.1 滞在時間均一シナリオ

四隅での滞在時間が120分で均一なシナリオでの評価を行った。この場合、サンプル間隔 $\Delta T = 120$ 、クラスタ数 $K = 4$ の組合せが最もよく群衆分布のパターンと時間遷移を表す。

観測頻度 E ごとに、分離度が大きい順に上位7組の $(\Delta T, K)$ の値を表1に示す。表1より、全ての観測頻度において $(\Delta T, K) = (120, 4)$ の分離度が最も高くなっており、時空間的な群衆分布のパターンと一致していることが分かる。また、上位7組の分離度を図7に示す。図7より、全ての観測頻度において第2位の分離度は最上位の分離度

表 1 滞在時間均一シナリオでの
 $\langle \Delta T, K \rangle$ の推定結果

rank	E = 5	E = 3	E = 1	E = 0.5
1	$\langle 120, 4 \rangle$	$\langle 120, 4 \rangle$	$\langle 120, 4 \rangle$	$\langle 120, 4 \rangle$
2	$\langle 240, 2 \rangle$	$\langle 60, 4 \rangle$	$\langle 60, 4 \rangle$	$\langle 60, 4 \rangle$
3	$\langle 192, 5 \rangle$	$\langle 192, 5 \rangle$	$\langle 48, 4 \rangle$	$\langle 96, 4 \rangle$
4	$\langle 96, 5 \rangle$	$\langle 240, 2 \rangle$	$\langle 42, 4 \rangle$	$\langle 71, 4 \rangle$
5	$\langle 180, 4 \rangle$	$\langle 96, 5 \rangle$	$\langle 44, 4 \rangle$	$\langle 73, 4 \rangle$
6	$\langle 60, 4 \rangle$	$\langle 180, 4 \rangle$	$\langle 41, 4 \rangle$	$\langle 62, 4 \rangle$
7	$\langle 239, 4 \rangle$	$\langle 239, 4 \rangle$	$\langle 46, 4 \rangle$	$\langle 65, 4 \rangle$




図 7 滞在時間均一シナリオでの分離度

表 2 滞在時間均一シナリオにおける ARI

	E = 5	E = 3	E = 1	E = 0.5
ARI	0.991	0.973	0.955	0.929

の 66%以下であったことが伺える。よって、観測頻度が少ない場合においても時空間的な群衆分布のパターンを正しく集約できていることが分かる。

さらに、観測頻度ごとの ARI を表 2 に示す。この結果より、観測頻度が最も小さい $E = 0.5$ の場合においても ARI は 0.929 となり、高い一致度を示した。 $E = 0.5$ の場合は対象領域全体において 2 分に 1 回程度、1 つだけ観測が得られるという頻度であり、スパースな観測からでも、提案手法によって観測を適切にサンプリングし、クラスタリングを正しく行えることが確認できた。

4.2.2 滞在時間不均一シナリオ

通勤・通学など、1 日において特定の場所に長時間滞在するような場合を想定し、領域の四隅にそれぞれ 120 分、360 分、240 分、720 分滞在するようなモビリティを再現し、評価を行った。この場合、滞在時間の最大公約数は 120 分であるため、サンプリング間隔 $\Delta T = 120$ 、クラスタ数 $K = 4$ の組合せが最もよく群衆分布のパターンと時間遷移を表すと考えられる。

観測頻度 E ごとに、分離度が大きい順に上位 7 組の $\langle \Delta T, K \rangle$ の値を表 3 に示す。 E が 5 および 3 の場合について、最上位の組合せが $\langle 120, 4 \rangle$ $\langle 240, 4 \rangle$ となっているが、第 5 位や第 6 位に $\langle 240, 3 \rangle$ があることから、120 分の滞在時間を持つ領域に滞在するという分布パターンが無視され、

表 3 不均一な滞在時間シナリオでの
 $\langle \Delta T, K \rangle$ の推定結果

rank	E = 5	E = 3	E = 1	E = 0.5
1	$\langle 240, 4 \rangle$	$\langle 240, 4 \rangle$	$\langle 120, 4 \rangle$	$\langle 120, 4 \rangle$
2	$\langle 180, 4 \rangle$	$\langle 180, 4 \rangle$	$\langle 144, 4 \rangle$	$\langle 144, 4 \rangle$
3	$\langle 120, 4 \rangle$	$\langle 120, 4 \rangle$	$\langle 240, 4 \rangle$	$\langle 131, 4 \rangle$
4	$\langle 144, 4 \rangle$	$\langle 144, 4 \rangle$	$\langle 60, 4 \rangle$	$\langle 180, 4 \rangle$
5	$\langle 240, 3 \rangle$	$\langle 239, 4 \rangle$	$\langle 180, 4 \rangle$	$\langle 240, 4 \rangle$
6	$\langle 144, 5 \rangle$	$\langle 240, 3 \rangle$	$\langle 90, 4 \rangle$	$\langle 90, 4 \rangle$
7	$\langle 239, 4 \rangle$	$\langle 144, 5 \rangle$	$\langle 72, 4 \rangle$	$\langle 96, 4 \rangle$




図 8 不均一な滞在時間シナリオでの分離度

表 4 不均一な滞在時間シナリオにおける ARI

	E = 5	E = 3	E = 1	E = 0.5
ARI	0.941	0.920	0.898	0.858

3 つの分布パターンしか無いものと見なされていることが伺える。この理由として、120 分の滞在時間を持つ分布パターンが 1 つしか無く、かつ、他の分布パターンの滞在時間と比べて短いため、他の分布パターンに対してサンプル数が少なくなり、分離度に与える影響が小さくなってしまふことが考えられる。

また、上位 7 組の分離度を図 8 に示す。観測頻度 E が 1 および 0.5 の場合では、第 2 位の分離度が最上位の 75% 以下となっており、有意な差が見られる。ゆえに、群衆分布パターンの滞在時間が異なる場合においても、スパースな観測から群衆分布のパターンを正しく集約できていることが分かる。

4.2.3 観測範囲の影響

シチュエーションによっては観測領域が限られた大きさでしか得られない場合が考えられるため、観測面積を限定した場合のサンプリング間隔 ΔT とクラスタ数 K を評価した。4.2.1 項で述べた群衆分布パターンを用いて、得られる観測領域の大きさを $80\text{m} \times 80\text{m}$ (1 セル) のみ、 $160\text{m} \times 160\text{m}$ (4 セル) のみ、 $240\text{m} \times 240\text{m}$ (9 セル) のみに限定してシミュレーションを行った。そして、適切と考えられるパラメータ ($\Delta T = 120, K = 4$) の分離度が第何位に当たるかと、分離度最大の組合せとの惜敗率を評価指標とする。パラメータ p の惜敗率 l を式 (7) に定義する。ここで $F^{(p)}$ はパラメー

表 5 観測範囲に対するクラスタ分析結果

	(120, 4) の順位	分離度	第 1 位 (第 2 位)	分離度	借敗率
(80m) ²	1	12.01	((60, 4))	(4.64)	(0.386)
(160m) ²	1	20.37	((192, 5))	(14.89)	(0.731)
(240m) ²	1	4.27	((60, 4))	(2.49)	(0.583)

表 6 観測誤差とクラスタ分析の結果

	(120, 4) の順位	分離度	第 1 位 (第 2 位)	分離度	借敗率
誤差なし	1	16.32	((240, 2))	(8.35)	(0.512)
±10%	2	2.30	(240, 2)	2.32	0.991
±20%	1	2.68	((240, 2))	(2.33)	(0.869)

タ p の分離度, p_1 は分離度最大の組合せを表す.

$$l = \frac{F(p)}{F(p_1)} \quad (7)$$

評価結果を表 5 に示す. なお, $\langle 120, 4 \rangle$ が第 1 位だった場合は, 括弧付けで第 2 位のパラメータ・分離度・借敗率を示している. 表 5 より, 全ての場合において $\langle 120, 4 \rangle$ の分離度が最も高くなった. また, $160\text{m} \times 160\text{m}$ のみの観測において最も高い分離度が得られた. 観測領域が狭すぎると観測されないセルが多くなり, 補完によってノード推定されるセルが増加するため, サンプルング誤差が大きくなる. また, 観測値は観測領域における 1 セルあたりの平均値が得られるため, 観測領域が広すぎると 1 セルごとの誤差が増加し, サンプルング誤差が大きくなる. よって, これらが原因で分離度が減少したと考えられる.

4.2.4 観測誤差の影響

実環境では得られる観測に誤差が含まれる. そこで, 観測誤差が含まれる場合のサンプルング間隔 ΔT とクラスタ数 K を評価した. 4.2.1 項で述べた群衆分布パターンを用いて, 観測誤差は真値に対する相対誤差で与えられ, その範囲は $[0\%, 0\%]$ (誤差なし), $[-10\%, +10\%]$, $[-20\%, +20\%]$ の 3 パターンとした. 観測誤差は誤差範囲から等確率で選択されるものとした. 評価は 4.2.3 項と同様に $\langle \Delta T, K \rangle$ の

評価結果を表 6 に示す. 表 6 より, 誤差が $[-10\%, +10\%]$ 以外の場合はいずれもモビリティの特性から想定される $\langle 120, 4 \rangle$ の組合せが分離度最大となっている. また, 誤差が $[-10\%, +10\%]$ の場合であっても, $\langle 120, 4 \rangle$ の組合せの分離度は第 2 位となっており, 借敗率が 0.991 であることから, 最上位の分離度とほとんど同じ分離度になっていることが分かる. このことから, 観測に誤差が含まれる場合であっても, 正しく群衆分布パターンを推定できていることが分かる.

5. おわりに

本稿では, 時空間的に散在する人密度の観測に基づく群衆分布の推定を実現するため, クラスタ分析を用いた観測集約法を提案した. 提案手法では一定期間内に蓄積された

観測に対して, 時空間的な分布に応じた重み付き統合により領域全体の群衆分布をサンプルングし, クラスタリングによって時空間的な群衆分布のパターンおよびそれらの遷移パターンを集約して表現する. 提案手法の有効性をシミュレーションにより評価したところ, 群衆が 4 つの領域を順に移動するモビリティに対して, 推定結果の一致度は今回評価を行った中で最も観測頻度が小さい場合において 92.9% となることが確認できた.

今後の課題として, 様々な移動パターンに対する性能評価や, 集約した結果を活用した群衆分布推定法ならびに未来の混雑予測法の設計などが挙げられる.

参考文献

- [1] Fan, Z., Song, X., Shibasaki, R. and Adachi, R.: City-Momentum: An Online Approach for Crowd Behavior Prediction at a Citywide Level, *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing (UbiComp '15)*, pp. 559–569 (2015).
- [2] Kim, Y., Han, J. and Yuan, C.: TOPTRAC: Topical Trajectory Pattern Mining, *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '15)*, pp. 587–596 (2015).
- [3] Enzweiler, M. and Gavrilu, D. M.: Monocular Pedestrian Detection: Survey and Experiments, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 31, No. 12, pp. 2179–2195 (2009).
- [4] 山下倫夫, 副田啓之, 野田五十樹: 人流計測による避難誘導効果の実証的検証, 情報処理学会研究報告, Vol. 2009-UBI-24, No. 25, pp. 1–8 (2009).
- [5] 新村貴彦, 新井啓之, 井上 潮: 確率的予測に基づく人流計測, 情報処理学会研究報告, Vol. 2003-CVIM-143, No. 26, pp. 119–124 (2004).
- [6] 小島颯平, 内山 彰, 廣森聡仁, 山口弘純, 東野輝夫: スマートフォンカメラを用いた群衆人数推定システム, マルチメディア通信と分散処理ワークショップ論文集, Vol. 2015, No. 5, pp. 211–215 (2015).
- [7] 西村友洋, 樋口雄大, 山口弘純, 東野輝夫: スマートフォンを活用した屋内環境における混雑センシング, 情報処理学会論文誌, Vol. 55, No. 12, pp. 2511–2523 (2014).
- [8] Weppner, J. and Lukowicz, P.: Bluetooth based collaborative crowd density estimation with mobile phones, *Proceedings of 11th International Conference on Pervasive Computing and Communications (PerCom '13)*, pp. 193–200 (2013).
- [9] 中野隆介, 沼尾雅之: 無線 LAN アクセスポイントへの検索要求を利用した鉄道車内混雑度推定アクセスポイントへの検索要求を利用した鉄道車内混雑度推定, *Proceedings of the 4th Forum on Data Engineering and Information Management (DEIM Forum 2012)*, pp. A10–1 (2012).
- [10] Arthur, D. and Vassilvitskii, S.: k-means++: The Advantages of Careful Seeding, *Proceeding of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms*, pp. 1027–1035 (2007).
- [11] 庭川 誠, 恩田寿和: 監視カメラ映像中の局所的な動き検出とイベント累積による時間的かつ空間的な混雑度調査, 電気学会論文誌 D (産業応用部門誌), Vol. 124, No. 10, pp. 1060–1066 (2004).
- [12] Lin, S.-F., Chen, J.-Y. and Chao, H.-X.: Estimation of

- number of people in crowded scenes using perspective transformation, *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, Vol. 31, No. 6, pp. 645–654 (online), DOI: 10.1109/3468.983420 (2001).
- [13] Hongquan, S., Xuejun, L., Guonian, L., Xingguo, Z. and Feng, W.: Video scene invariant crowd density estimation using geographic information systems, *China Communications*, Vol. 11, No. 11, pp. 80–89 (2014).
- [14] Lijun, C. and Kaiqi, H.: Video-based crowd density estimation and prediction system for wide-area surveillance, *China Communications*, Vol. 10, No. 5, pp. 79–88 (2013).
- [15] 木村直哉, 市原淑雄, 林健太郎: 群衆の三次元行動計測に基づく混雑・滞留検知センサ, 画像の認識・理解シンポジウム (MIRU2011) 論文集, Vol. 2011, pp. 566–571 (2011).
- [16] Terada, K., Yoshida, D., Oe, S. and Yamaguchi, J.: An automatic method of counting passers by using stereo camera, *The Transactions of the Institute of Electrical Engineers of Japan. C, A Publication of Electronics, Information and System Society*, Vol. 120, No. 6, pp. 850–856 (2000).
- [17] 宮崎真次, 宮野博義, 池田治雄, 大網亮磨: 群衆行動解析技術を用いた混雑推定システム, *NEC 技報*, Vol. 67, No. 1, pp. 82–85 (2014).
- [18] 中塚正之, 岩谷 周, 甲藤二郎: 無線センサーネットワークを使用した Passive な混雑推定システム, 情報処理学会第 70 回全国大会講演論文集, pp. 5–303–304 (2008).
- [19] Wada, Y., Higuchi, T., Yamaguchi, H. and Higashino, T.: Accurate Positioning of Mobile Phones in a Crowd using Laser Range Scanners, *Proceedings of the 9th IEEE International Conference on Wireless and Mobile Computing, Networking and Communication (WiMob '13)* (2013).
- [20] Nakamura, T., Ogawa, T., Kiyokawa, K. and Takemura, H.: User Context Recognition for Use in Wearable Learning Systems Based on Congestion Level Estimation of the Inside of a Train Using a Carbon Dioxide Sensor, *The Institute of Electronics, Information and Communication Engineers Technical Report*, Vol. MVE2007–89, No. 3, pp. 49–54 (2008).
- [21] 萩原 崇, 諏訪敬祐: Wi-Fi パケットセンサとクラスター分析を用いた屋内での混雑度推定手法, 情報処理学会第 77 回全国大会講演論文集, pp. 3–315–316 (2015).
- [22] Tibshirani, R. and Trevor Hastie, G. W.: Estimating the number of clusters in a data set via the gap statistic, *Royal Statistical Society: Series B (Statistical Methodology)*, Vol. 63, No. 2, pp. 411–423 (2001).
- [23] MacQueen, J.: Some methods for classification and analysis of multivariate observations, *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, pp. 281–297 (1967).
- [24] Hubert, L. and Arabie, P.: Comparing partitions, *Journal of Classification*, Vol. 2, No. 1, pp. 193–218 (online), DOI: 10.1007/BF01908075 (1985).