

# 狭域空間における行為発生領域の識別的クラスタリング 整数計画法を用いた最適領域形状の決定手法と梅田地下街での検証

○瀧澤 重志\*<sup>1</sup>

キーワード：狭域空間分析 識別的クラスタリング 行為発生領域 整数計画法 CAEP

## 1. はじめに

建築空間や街路のオープンスペースといった比較的小規模な空間を設計する際に、その中で発生する様々な人々の行為を期待して、設計者は設計を行っていると考えられる。滞留やオフィス内での行動分析など、空間内での行為に関する研究も現在盛んに行われている。加えて近年の空間デザインは、Continuous Architecture などの新しい空間構成の考え方も反映して、機能分割と空間構成が一見対応しない曖昧さを積極的に許容する空間となってきた。それらの例として、FOAの横浜フェリーターミナル、伊東豊雄らによるせんだいメディアテーク、石上純也による神奈川工科大学 KAIT 工房などがある。

こうした現代建築に限らず一般に空間は曖昧性を有するので、それを分析するための新たな方法が必要とされてきている。空間分析を行う場合、実証性を高めるために統計解析手法を援用することは、今日では当然のように行われている。行為が場所の違いによりなぜ発生したりしないのかを統計的に説明するには、分類問題を解く必要がある。分類問題では、まず空間的範囲を定め、各範囲にクラスラベルを付与して教師データを作成した上で分析を行うが、空間の曖昧性や領域形状の多様性の問題から、事前にどのように空間的範囲を定めたらよいのかは、未解決の問題として残っている。

この問題は、主に計量地理学の分野で考慮されてきた空間的自己相関の問題と関連する。空間的自己相関とは、ある注目している空間の周辺も注目している空間と類似の空間的特徴を持っている性質である。空間データに対して、誤差項の相関を考慮しない通常の回帰分析手法を適用すると、モデルの精度が低下してしまうことが知られている。そのため、誤差項の共分散成分に空間的な制約を入れた地理的加重回帰などが発展してきた。しかしこの方法は、マクロな地理学的スケールの事象を扱うために開発されてきたため、領域を注目点からの距離だけで表現する。これは領域を単純な円(楕円)として想定することを意味しており、本研究が対象とする狭域な空間の分析に応用するには問題がある。筆者の想定する狭域な空間は、ネットワーク分析で行う点と線で抽象化されることが多い都市スケールではなく、具体的な形状の情報が必要とされる、単体の建築から街路レベルのスケールを想定している。筆者は文献<sup>1)</sup>で街路上でのひった

くりの発生と空間的特徴の関係を分析した。この研究では、犯罪発生領域を各地点で半径が可変な円領域として、犯罪発生と非発生の場所の分類問題を解いた。しかし、領域形状が円形のため、犯罪発生地点から交差点を越えた反対側の道路までを潜在的な犯罪発生地点とみなす場合があるなど、円領域では形状の複雑さが足りないという限界を有していた。この研究に限らず、狭域の空間分析においては、領域形状は円よりもある程度複雑なクラスが必要になると考えている。

以上の背景から本研究では、狭域の空間スケールを対象として、そこで発生・観察される行為がどのような空間的状况のもとで発生するかを統計的に高精度に分類・予測し、同時にそれら行為が発生する可能性が高い領域を、識別的クラスタリング<sup>2)</sup>の考え方をを用いて決定する、新しい空間分析手法を提案する。識別的クラスタリングは、本来目的変数を有しないクラスタリング手法に対して、クラスラベルをパラメータとみなして、識別的な分類モデルを学習するクラスタリング手法である。

本研究は筆者の既往研究<sup>3)</sup>の枠組みをもとにしている。既往研究では、最適なクラスタリングを求めるためにメタ・ヒューリスティクスを用いたが、この方法ではクラスタのサイズをコントロールすることが難しい問題があった。そこで本研究では、クラスタのサイズをパラメータとした整数計画問題として問題を定式化する。そしてこの手法を、梅田地下街の広場の滞留行動データに当てはめて検証を行う。梅田地下街を対象とした滞留行動の既往研究としては、松尾らの研究<sup>4)</sup>がある。この研究では、人の滞留場所から、パーソナルスペースの個体距離とされている半径 1.2m の範囲内を一律に滞留領域として分析を行っている。対して本研究では、潜在的な行為の発生領域の形状を求める点で、既往研究と異なる。

以降において、第 2 章では提案手法の基本的な設定、精度評価、定式化、アルゴリズムに関して説明し、3 章でその検証を行う。そして 4 章で結語とする。

## 2. 提案手法

提案手法に関して以下に説明する。

### 2.1 基本的な設定

本研究では行為の発生 (Positive, ラベルPと表記)、非発生 (Negative, ラベルNと表記) を分類する 2 クラス問

題を扱う。分析を行いたい平面を、正方形のセルに分割する。図1に示すように、“障害物セル”を除くセルの集合を  $C$  とし、さらにそれを、行為が起こったセル (“行為セル”,  $C_P$ ), 行為が起こらなかったセル (“非行為セル”,  $C_N$ ), どちらの可能性もある“非ラベルセル”の集合 ( $C_U$ ) に分割する。ここで  $C_P, C_N, C_U \subset C, C_P \cup C_N \cup C_U = C, C_P \cap C_N = \emptyset, C_P \cap C_U = \emptyset, C_N \cap C_U = \emptyset$  とする。また、各セルには、その中心で計測された空間属性ベクトル  $v_c$ , 行為の(非)発生に関するクラスラベル  $l_c \in \{P, N\}$  が付与される。

$RADIUS$ を1以上の整数とすると、非ラベルセルは、行為セルの周囲の半径  $RADIUS$ セルの拡張ノイマン近傍内の非行為セルが該当する。非ラベルセルは、どちらのクラスラベルも取り得るセルであり、後述する識別的クラスタリングにより、行為発生領域とみなされる“推定行為セル”と、行為非発生領域とみなされる“非行為セル”に分類される。

図1に、二つの行為セルとそれぞれ青、赤の枠で囲まれた非ラベルセルの領域を示す。赤の非ラベルセルの領域の右下は障害物セルによって欠けている。これは次に示すように、非ラベルセルの領域が矩形和楕円型領域の形状制約を満たす必要があるからである。

一般に何らかの行為が発生しうる領域は同質性が高いと考えられるが、本研究のような狭域空間を扱う場合、行為セルが周囲から可視である範囲に領域を限定することは理に適っていると考えられる。本研究では2次元の格子空間を扱っているが、この場合、行為セルが周囲から見て可視である領域は、図2に示すような行為セルを端点の一つとする矩形和楕円型領域となる。矩形和楕円型領域はあるセルを共通の端点としてもつ矩形領域の和集合である。各矩形領域の端点が同一のセルで共有されるため、そこからの可視性が担保される領域を網羅的に生成できる。図2はそれぞれ4つの矩形の和集合であり、(b)は(a)の赤い境界で示された矩形をY軸方向に1セル移動させたものだが、行為セルが端点から外れるため、全体としては矩形和楕円型領域ではなくなっている。

## 2.2 精度評価<sup>5)</sup>

表1に分類性能を評価する際に用いられる混同行列を示す。この情報から、各クラスそれぞれの正解率  $TPrate = TP/(TP + FN)$ ,  $TNrate = TN/(TN + FP)$ が定義される。データセット中のクラスの分布が偏っている場合は、全体の正解率よりも各クラスの正解率を個別に評価した方が、少数クラスの分類精度が向上する。そこで本研究では誤差関数として  $Balanced\ Classification\ Rate$ ,  $BCR = (TPrate + TNrate)/2$ を用いて目的関数を構成する。BCRは各クラスの誤差率を等しい重みで評価するので、バランスのとれた誤差評価が期待できる。

## 2.3 定式化

いま、学習済みの分類モデルにより分類を行った各セ

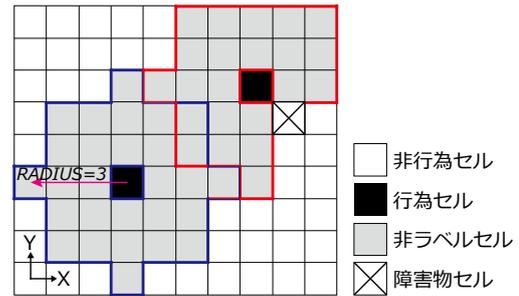


図1 対象空間の例 ( $RADIUS = 3$ )

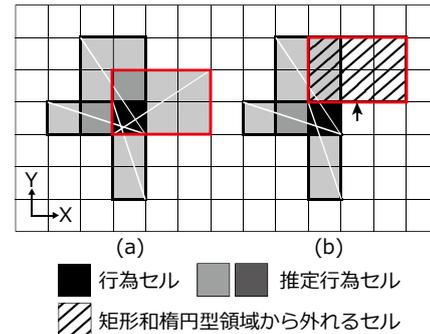


図2 矩形和楕円型領域の説明。(a)はすべて矩形和楕円型領域、(b)はそれ以外の領域を有する例。

表1 混同行列

		予測値	
		Positive	Negative
実測値	Positive	TP(件数)	FN
	Negative	FP	TN

ル  $c \in C$  のラベルを  $a_c \in \{0,1\}$ , ラベルの集合を  $A = \{a_1, a_2, \dots, a_{|C|}\}$  と表す。  $a_c$  は推定されたクラスが P の場合 1 を, N の場合 0 をとるものとする。また、非ラベルセル  $c \in C_U$  が推定行為セルになるかならないかを  $x_c \in \{0,1\}$  で表し、セルが推定行為セルになる場合  $x_c = 1$  とする。  $MP$  を 1 以上の整数とし、非ラベルセルのうち、  $MP$  個が推定行為セルになるとすると、  $MP$  と  $A$  が与えられた条件で、  $BCR$  を最大化する最適クラス  $x_c (c \in C_U)$  を求める問題は、問題(1)の整数計画問題として定式化できる。この式において、  $C_P(c) \subset C_P$  は、セル  $c \in C_U$  の近傍範囲内にある行為セルの集合、  $p_i \in C_P(c)$  はそれらに含まれる行為セルとする。  $UP$  と  $UN$  はそれぞれクラス P, N に分類された非ラベルセルの合計である。また  $R(c, p_i) \subset C_U$  は、セル  $c$  と  $p_i$  を対角の端点とする矩形に含まれる非ラベルセルの集合とする。加えて  $S(c', p_i)$  は、  $c' \in R(c, p)$  の近傍範囲内の行為セル  $p_i$  に関するサポートセルの集合、  $c_1(p_i), c_2(p_i) \in S(c', p_i)$  はその要素である。サポートセルは、図3に示すように、推定行為セルの矩形和楕円型集合制約を満たすために必要な、隣接する最大二つのセルである。行為セルと X 座標か Y 座標が同一のセルの場合、  $c_1(p_i) = c_2(p_i)$  となる。

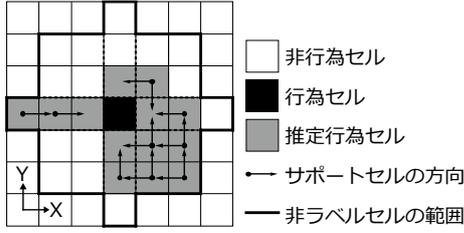


図3 サポートセルの説明 (RADIUS = 3)

$$\underset{x_c, c \in C_U}{\text{maximize}} BCR(A, MP) = \frac{TPrate + TNrate}{2} \quad (1)$$

s. t.

$$TPrate = \frac{UP + \sum_{c \in C_P} a_c}{|C_P| + MP}$$

$$TNrate = \frac{UN + \sum_{c \in C_N} (1 - a_c)}{|C| - |C_P| - MP}$$

$$UP = \sum_{c \in C_U} a_c \cdot x_c$$

$$UN = \sum_{c \in C_U} (1 - a_c)(1 - x_c)$$

$$\sum_{c \in C_U} x_c = MP$$

$$x_c \in \{0, 1\}, c \in C_U, p_i \in C_P(c), i \in \{1, \dots, |C_P(c)|\},$$

$$c_1(p_i), c_2(p_i) \in S(c', p_i),$$

$$2x_{c'} \leq x_{c_1(p_i)} + x_{c_2(p_i)} \quad \forall \dots \forall 2x_{c'} \leq x_{c_1(p_{|C_P(c')})} + x_{c_2(p_{|C_P(c')})}$$

$$\forall c' \in R(c, p_i)$$

## 2.4 アルゴリズム

各セル  $c \in C$  は、属性ベクトルとラベルのデータ  $(v_c, l_c)$  を有する。これらの各ラベル別の集合をそれぞれデータセット  $D_P, D_N$  として分類問題を解く。ここで、 $T(C)$  は、 $C$  からそれらに含まれるセルのデータセットを作成する関数である。また、 $C_{UP}, C_{UN} \subseteq C_U$  はそれぞれ非ラベルセルにおいて、問題(1)を解いて得られる推定行為セルとそれ以外のセルの集合である。 $MAXITER$  は問題(1)を繰り返して解く上限の回数である。

提案手法を識別的空間クラスタリングと名付け、そのアルゴリズムを表2に示す。また、その模式図を図4に示す。手順はまず、(a)非ラベルセルを除いて分類器の学習を行い、(b)学習済みの分類器で非ラベルセルのラベルを予想し、(c)その分類精度を最大化するよう問題(1)を解いて、非ラベル領域を推定行為セルとそれ以外に分割することを、 $MP$  をひとつずつ増やしながら繰り返す。

## 3. 検証

梅田地下街の広場に滞留（ほとんどが待ち合わせ）する人の空間分布のデータを用いて提案手法を検証する。以下に詳細を述べる。

表2 Algorithm 1: 識別的空間クラスタリング

```

1 For  $MP \leftarrow 0$  to  $|C_U|$  do
2    $D_P \leftarrow T(C_P), D_N \leftarrow T(C_N)$ 
3    $BCRbest \leftarrow 0, A' \leftarrow \emptyset$ 
4   For  $i \leftarrow 0$  to  $MAXITER$  do
5      $D = \{D_P, D_N\}$  で分類器の学習を行い、得られた分類器を  $L$  とする。
6      $L$  により  $c \in C$  のクラスラベルを予測し、その予測結果を  $A$ 、精度を  $BCR$  とする。
7     If  $BCRbest < BCR$  then
8        $BCRbest \leftarrow BCR$ 
9        $D_{Best} \leftarrow \{D_P, D_N\}$ 
10    End if
11    If  $A = A'$  then
12       $D_{Best}$  を出力する。
13      Break
14    End if
15     $A' \leftarrow A$ 
16    問題(1)を解き、 $C_{UP}, C_{UN}$  を求める。
17     $D_P \leftarrow T(C_P) \cup T(C_{UP}), D_N \leftarrow T(C_N) \cup T(C_{UN})$ 
18  End for
19   $D_{Best}$  を出力する。
20 End for

```

### 3.1 対象地域の空間特徴量

図5に対象地域の梅田地下街の平面図を示す。場所は、地下鉄御堂筋線南改札口を出た、方向感覚が狂いやすいことで有名な広場である。対象地域を含む後述する可視領域の計算に必要な梅田地下街の領域を  $A$ 、 $C \subset A$  を対象範囲のセルの集合とする。今回はセルの一辺の長さを50cmとした。平成27年5月12日の11:00~11:30に現地調査を行い、約30秒以上立ち止まっている人を滞留者として、その位置を最寄りのセル上にプロットした。滞留者がプロットされたセルの数は137である。

$C$  の各要素について2次元の可視領域解析を行い、得られた *Isovist field* に関する主な特徴量<sup>6)</sup>を各セルの中心で求めた。使用した特徴量は、最長の視線長さ ( $d_{max}$ )、同平均長さ ( $d_{ave}$ )、可視面積 ( $a$ )、可視領域の周長 ( $p$ )、コンパクトさの指標 ( $\Gamma = d_{ave}/d_{max}$ )、別のコンパクトさの指標 ( $\Psi = (a/\pi)^{1/2}/(p/2\pi)$ )、最寄りの障害物までの距離 ( $o_{min}$ ) である。さらにこれらの他に、対象地域の歩行者流動量をシミュレートして用いている。図5のA~J断面間の各ODを、調査時の歩行者の多寡で2段階に設定し、歩行者シミュレーションソフト *Simtread* を用いてシミュレーションを行い、0.2秒毎に各セル上に滞在する歩行者の総和を特徴量 ( $m_{sum}$ ) にしている。図6に上記のうち主な特徴量の空間分布を示す。

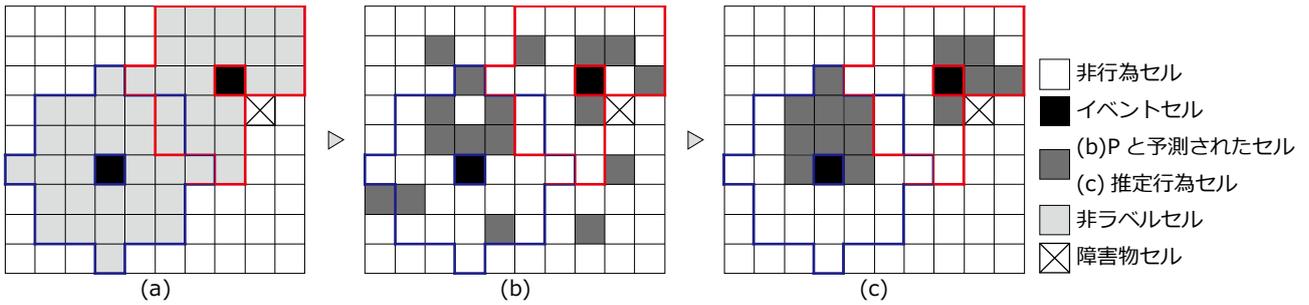


図4 識別的空間クラスタリングのアルゴリズムの模式図

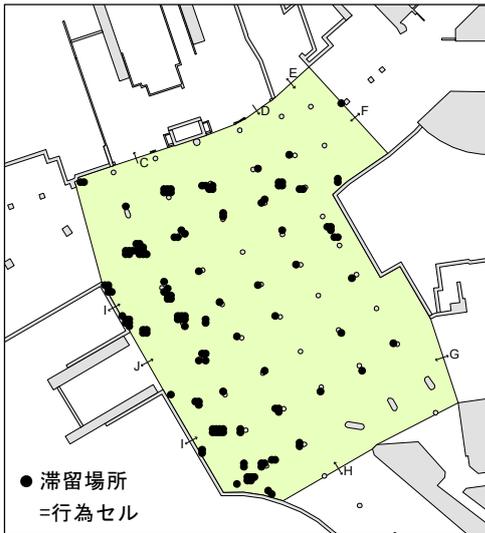


図5 対象範囲（緑色の領域）と滞留者の分布

### 3.2 計算の設定

分類モデルには、既往研究<sup>7)</sup>で用いてきた CAEP<sup>7)</sup>を用いる。CAEP は、少数クラスを含めた分類性能の高さと、結果の可読性に優れた手法である。なお CAEP を用いるために、説明変数を値の大小で 3 段階に離散化した。問題のパラメータは、 $RADIUS = 5$  (=250cm)、 $MAXITER = 10$ とした。整数計画法のソルバーには CPLEX 12.6.1 を用いた。

### 3.3 結果

図 7 にラベル P が与えられるセル数とその時の精度を示す。ラベル P のセル数が 664 のとき BCR が最大となるが、P の増加とともに、TPrate と TNrate の差が開いていくのがわかる。最適なクラスタを選ぶ際に単に BCR が大きいものを選ぶと、偏った結果を選んでしまう可能性がある。また、ラベル P のセル数が精度の割に過度に多くなっている。そこで今回は、図 8 のように得られた解の TPrate と TNrate に関する散布図を描き、それらの解の中で、いずれの評価値も高く、かつ両者の評価値の開きが最も少ないもの、すなわち、グラフ中に描かれた 1:1 の対角線にもっとも近い赤丸の解を、最適クラスタとして採用した。この解では、ラベル P のセル数 = 369, BCR = 0.816, TPrate = 0.821, TNrate = 0.812 となっている。

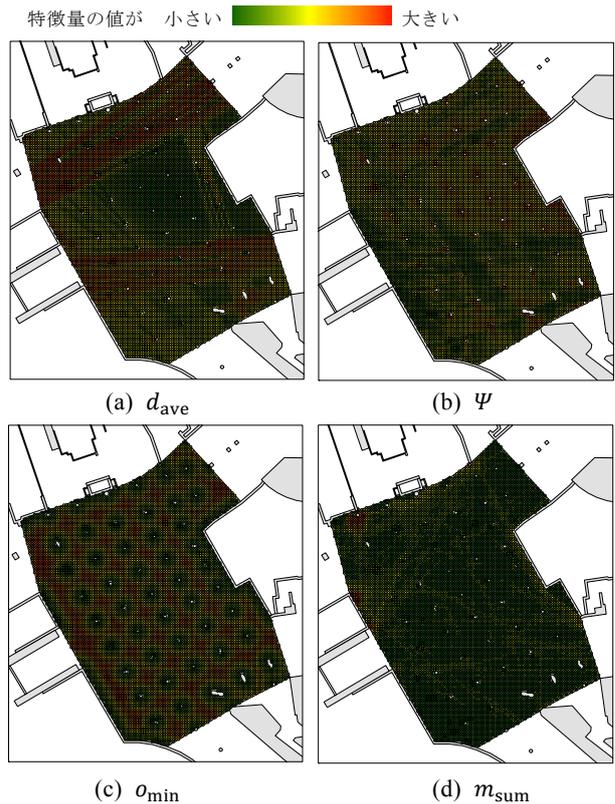


図6 主な特徴量の空間分布

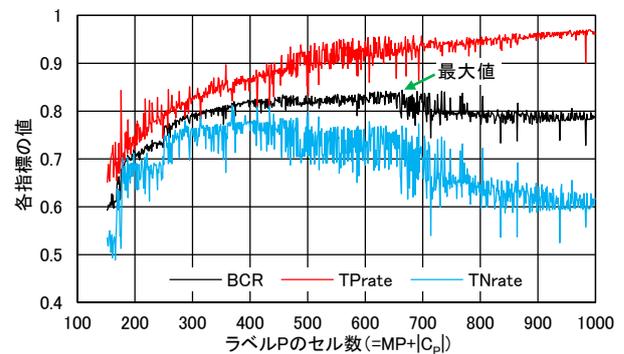


図7 ラベル P が与えられたセル数とその時の精度

図 9 にその最適クラスタを示す。もともと行為セルは空間の左側に多く分布しているが、推定行為セルの領域も空間の左側が広がっており、中心部での推定行為セルの広がりも中央下部を除いて大きくはない。また、推

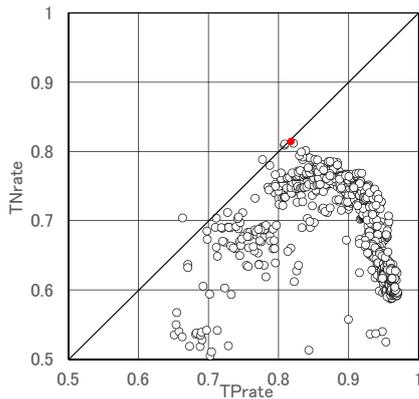


図8 TPrateとTNrateの散佈図:赤いプロットは今回採用した最適クラスタの評価値

定行為セルの領域形状は単純な円形ではなく、方向性が認められるなどの特徴を有しており、潜在的な行為の発生領域は、個々の行為発生地点でその形状や大きさが一様でないことを示唆する結果が得られた。

最後に、表3にCAEPで抽出された各クラスの寄与度(高いほど分類に影響力を有する)が上位3位のアイテム集合を示す。L, M, Hはそれぞれ離散化した値が、低, 中, 高ランクであることを示している。滞留行為(待ち合わせ)の発生に関連が大きい場所の特徴は、見通しのよさと直近の障害物への近さの組み合わせであることが示されている。見通しのよさを示す図6(a)の $d_{ave}$ の分布をみると、その中心部の値が低くなっているが、これが先に述べた推定行為セルの広がり方に大きく影響していると考えられる。

#### 4. まとめ

本研究では、行為が発生しやすい領域を識別的クラスタリングの考え方をを用いて決定する新しい空間分析手法を提案した。梅田地下街の滞留データで検証した結果、精度が8割を超え、さらに、潜在的な行為の発生領域が従来の均一な円領域ではなく、場所によって様々な広がり方を有する結果が得られ、狭域空間分析への応用可能性が示されたと考える。また従来手法では、推定行為セルの数は最適化の結果決定されていたが、提案手法は推定行為セルの数に関するパラメトリック問題となっており、その数を明示的にコントロールすることができる。

今後の課題として、今回目的変数をBCRの最大化としたためか、推定行為セルの増加とともに二つのクラスの精度に差が出てしまったことから、そのような差が出にくい目的関数を検討する必要がある。また、建築空間を対象にした検証なども必要である。

#### 謝辞

本研究は科学研究費補助金基盤研究C(25420633)の補助の下で行われました。

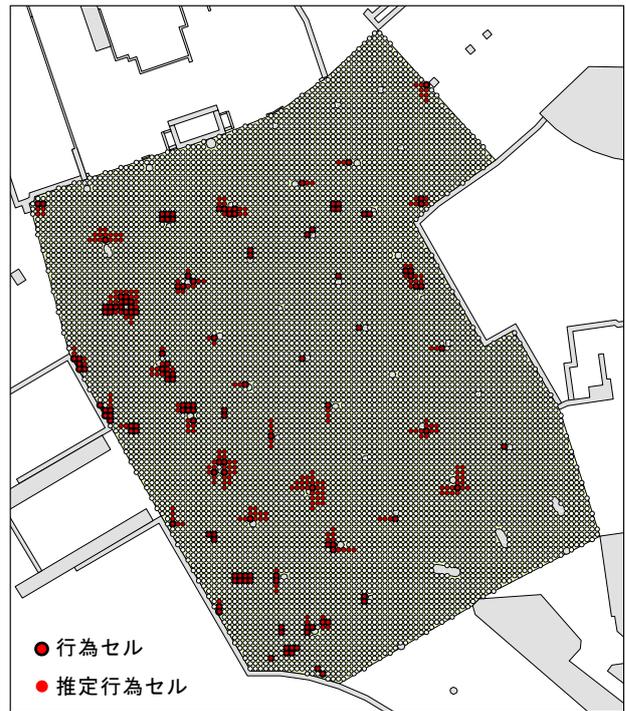


図9 最適クラスタ

表3 寄与度の大きい上位3位のアイテム集合

Class	寄与度	アイテム集合
P	3.58	$d_{ave} = H, o_{min} = L$
	3.10	$d_{max} = H, o_{min} = L$
	3.08	$d_{max} = H, d_{ave} = H, o_{min} = L$
N	2.66	$o_{min} = M$
	2.66	$o_{min} = H$
	2.29	$d_{max} = L$

#### [参考文献]

- 1) A. Takizawa: Emerging Pattern Based Street Crime Analysis - Street Level Spatial Analysis of Crime Location Associated with Built Environment in Fushimi Ward, Kyoto City -, Transactions of AIJ, 78(686), pp.957-967, 2013
- 2) L. Xu, et al.: Maximum margin clustering, in L. K. Saul, et al eds., Advances in Neural Information Processing Systems 17, pp.1537-1544. MIT Press, Cambridge, MA, USA, 2005
- 3) 瀧澤重志: 半教師あり学習の考え方に基づく空間の曖昧さを考慮した領域分割に関する研究, 日本建築学会第36回情報・システム・利用・技術シンポジウム論文集, 報告, pp.141-144, 2013
- 4) 松尾佳津史, 田中一成, 吉川真, 地下公共空間における歩行者の滞留行動と空間構造の関係, 地理情報システム学会講演論文集, 22, D-5-3, 2013
- 5) J. A. Lozano et al.: Classifier performance evaluation and comparison, ICMLA 2010, 2010, [http://www.icmla-conference.org/icmla10/CFP\\_Tutorial\\_files/jose.pdf](http://www.icmla-conference.org/icmla10/CFP_Tutorial_files/jose.pdf)
- 6) M. Batty, Exploring isovist fields: space and shape in architectural and urban morphology, Environment and Planning B: Planning and Design, 28(1), pp.123-150, 2001
- 7) G. Dong, et al.: CAEP: Classification by aggregating emerging patterns, Proc. of the 2nd International Conference on Discovery Science, pp.30-42, 1999

\*1 大阪市立大学工学研究科 准教授 博士(工学)

# Differential clustering of potential activity occurrence area in small space

## Optimization of activity occurrence area using integer programming and inspection with the data of Umeda Underground Mall

○Atsushi Takizawa\*<sup>1</sup>

Keywords: small space analysis, differential clustering, activity occurrence area, integer programming, CAEP

In this article, we propose a new spatial analysis method for small spaces such as architectures and streets. Architects design spaces expecting that various activities and or events of users occur in the spaces. In addition, researches on human activities in small spaces such as offices and streets are increasing. One of recent architectural styles represented by continuous architecture and algorithmic design generates and admits ambiguous space of which function and composition does not correspond on the surface. It may become more difficult to predict the relationship between function and space for designers. Therefore, we should develop an effective method for predicting human activities in small spaces. In order to analyze and explain statically why human activities occur under particular spatial conditions we have to solve a classification problem. For applying a classification problem, we have to estimate and fix the range and shape of the potential activity occurrence area and add class label to each data in advance. However, how we should fix the range and shape of the occurrence area is remained as an open problem.

From above background, we propose a new spatial analysis method for classifying activity occurrence and non-occurrence areas in high precision for small spaces. In addition, this method can estimate the area around the actual activity spots in which activities tend to occur based on the concept of differential clustering. In particular, following the framework of our previous study, we formalize the problem to obtain the optimal cluster as an integer programming problem with parameter of the cluster size. We set a constraint that the shape of a cluster have to be a rectilinear eclipse because a potential activity occurrence area may have common spatial features spatially related to visibility. Then, we validate this method with the data of Umeda Underground Mall which records the residence position of pedestrians. We divide the target space into a cell of 50cm on a side and calculate the spatial attribute related to isovist field and the number of pedestrians by simulation at each cell. We use Classification by Aggregating Emerging Patterns as a classifier and balanced error rate (BCR) as an objective function for accuracy test. We get the optimal region whose  $MP + |C_p| = 369$ ,  $BCR = 0.816$ ,  $TPrate = 0.821$ ,  $TNrate = 0.812$ . The result show that the form and size of the optimal region differ in each spot. From this result, it can be said that the proposed method works better compared with the personal space based potential region with constant radius.

---

\*1 Associate Professor, Graduate School of Engineering, Osaka City University, Dr. Eng.