

2016年度若手研究助成 研究報告書  
日本における地理的犯罪予測手法の開発

研究代表者

筑波大学大学院システム情報工学研究科 大山智也

## 1. はじめに

### 1.1. 背景

過去の犯罪発生状況や、周辺環境の特性などをもとに、将来の犯罪発生リスクや犯罪集積エリアを予測する「地理的犯罪予測」の試みが、欧米を中心に研究・開発の対象となっている。これは、侵入盗や自動車盗、暴行といった機会犯罪・街頭犯罪を対象に、月・週・日単位、ブロック単位といった詳細な範囲で犯罪発生リスクを算出、地図などに示し、防犯資源を集中的に投入する判断を助けるものである。PredPol<sup>1)</sup>や RTM<sup>2)</sup>といったいくつかの手法は、実証研究により一定の有効性が示された上で、警察実務に取り入れられている。

日本は、国際的にみても犯罪発生が低頻度<sup>3)</sup>ではあるものの、近年では、警察官の大量退職<sup>4)</sup>や、警察官採用試験の受験者数の減少<sup>5)</sup>などにより、警察人員の減少が危惧される。このような状況下では、限られた防犯資源を適切に配分し、治安維持対策を効果的に行っていく必要性が、今後増してゆくものと考えられる。

こうした中、わが国でも、「地理空間情報の活用に関する行動計画（G 空間行動プラン）」において、「犯罪情勢の時間的・空間的变化の分析手法及び犯罪抑止対策の評価手法の開発」が取り上げられる（内閣官房, 2014）など、犯罪データを活用した施策への機運が高まっており、また、2016年10月には、京都府警察により犯罪予測システムの運用が開始される（日本経済新聞, 2016）など、地理的犯罪予測手法導入の先進的事例もみられている。

しかしながら、わが国ではこれまで地理的犯罪予測を直接取り上げた研究は存在せず、欧米で研究・開発されてきた手法については十分知られていない。地理的犯罪予測の導入期にあるわが国において、これまでなされてきた研究を整理し、その全体像を示すことは重要と考えられる。

また、犯罪発生水準が日本と比べ高い水準にあり<sup>6)</sup>、かつ都市構造や人口構成等の社会的背景が大きく異なる欧米で考案された手法が、わが国においても有効であるかは定かではない。特に、日本の犯罪発生が、諸外国に比べ著しく低頻度であることは、予測を困難にすることが予想される。既存の予測手法について、日本における有効性を検討した上で、日本の状況によりふさわしい地理的犯罪予測の方法を探っていくことが、同時に求められるといえる。

### 1.2. 目的、および研究構成

前述した背景をふまえ、本研究では、日本に適した地理的犯罪予測手法の構築に向けた示唆を得るために、三つの研究を行った。

研究1では、主に欧米で行われてきた地理的犯罪予測研究を網羅的にレビューし、代表的な予測手法をその特徴をふまえて分類、体系的な整理を行った。

研究2では、研究1の結果をふまえて抽出された予測手法を国内の実際のデータに適用した上で、各手法の予測精度を比較、日本での適用可能性を評価した。

研究3では、研究2の検証から明らかとなった既存の予測手法の限界から、日本での予測に有効と思われる要素を取り入れ、既存手法を修正した新たな予測手法を提案、さらに、実際のデータ分析を通じて既存手法との比較を行った。

本研究は、これまでの地理的犯罪予測研究の体系的な整理と、実証研究による比較・検証を通じて、予測手法に科学的な評価を与える試みであり、かつわが国での社会的な実装を考える上で、有用な知見をもたらすものである。また、犯罪が低頻度な状況下でも成立する予測手法の構築を目指しているという点で、国際的にも新規性の高い試みであるといえる。

## 2. 研究1

### 2.1. 方法

レビュー対象とする論文の収集には、文献検索データベース Web of Science を利用し、“crime”，“forecast”，“predict”，“proactive”，“cluster”といったキーワードを組み合わせて検索を行った。検索された論文のアブストラクトを参照しつつ著者らで議論し、テーマに合致する論文を選定した。また、選定された論文に引用されている文献にもあたり、網羅的なレビューとなるよう配慮した。結果として、レビューの対象は124論文となった。本稿では、紙幅の都合上、その一部について取り上げている。なお、本稿に掲載する研究を選定する際には、Anselin et al. (2000)、Groff and LaVigne (2002)、Perry et al. (2013)などの既往のレビュー研究も参考にした。

### 2.2. 主要な地理的犯罪予測手法の整理と概観

レビューを通じて、既存の地理的犯罪予測手法は、予測へのアプローチの違いによって表1に示す4つのカテゴリに整理することができた。以下、各分類に属する研究について、特に重要と考えられる業績を中心にみてゆく。

#### 2.2.1. 時空間クラスタの検出

過去の犯罪の集積は、将来の犯罪発生を予想させる。そのために、犯罪発生地点のローカルなクラスタをいち早く見つけ出すことが、地理的犯罪予測において関心の対象となる。このために、統計的な基準を設けて、閾値以上の時空間上における集積をクラスタとして検出する技法が開発された。

その中で、STAC (Spatio-Temporal Analysis of Crime: Block, 1994; Block and Block, 1995) は、犯罪分析で比較的初期から用いられている手法であり、予測研究にも適用されている(たとえば、Polat, 2007)。

しかしながら、この手法は多重検定の問題が指摘されており、現在は、Kulldorff (1997) の空間スキャン統計量、さらにそれを拡張した時空間スキャン統計量 (Kulldorff et al., 1998) が多く用いられ

表 1 地理的犯罪予測手法の分類, および具体的な研究例

分類	具体的な研究例								
	タイトル	著者	背景となる研究・理論	罪種	説明変数	モデル	分析単位 (空間)	予測される時間の範囲	実装
時空間クラスタの検出	Microscale Prediction of Near-Future Crime Concentrations with Street-Level Geosurveillance	Shiode and Shiode (2015)	疫学分野における時空間クラスタの検出	薬物事犯	過去の犯罪発生データ	時空間スキャン統計量	街路300フィート (約91m) 長	1か月	-
犯罪の時空間的相互作用を考慮した犯罪発生の強度推定	Prospective Hot-Spotting: The Future of Crime Mapping?	Bowers et al. (2004)	反復被害・近接反復被害に関する犯罪学研究	侵入盗	過去の犯罪発生データ	オリジナルの関数による	50m四方グリッドセル	2日/7日	ProMap
	Self-Exciting Point Process Modeling of Crime	Mohler et al. (2011)		住宅侵入盗	過去の犯罪発生データ	self-exciting point process	200m四方グリッドセル	8週/39週	PREDPOL
環境要因からの犯罪発生リスクの予測	Risk Terrain Modeling Brokering Criminological Theory and GIS Methods for Crime Forecasting	Caplan et al. (2011)	場所と犯罪を関連づけた諸研究	発砲事件	<ul style="list-style-type: none"> <li>ギャングの住居分布</li> <li>バー、酒店等の店舗の分布</li> <li>薬物事犯による逮捕地点の分布</li> </ul>	<ul style="list-style-type: none"> <li>カーネル関数</li> <li>オーバーレイ解析</li> </ul>	100フィート (約30m) 四方グリッドセル	6か月	RTM
回帰分析による犯罪発生件数、または確率の予測	The Spatio-Temporal Modeling for Criminal Incidents	Wang and Brown (2012)	計量経済学における時系列分析	住居侵入	<ul style="list-style-type: none"> <li>地区の物理的・社会的経済的属性情報</li> <li>直近で犯罪が発生した日からのインターバル</li> </ul>	一般化加法モデル	32m四方グリッドセル	1か月	ST-GAM /LST-GAM

ている。時空間クラスタのなかでも、過去のある時点から現時点（最終的な観測時点）まで続く有意な時空間的クラスタ (emerging cluster) は、継続した警戒が必要な存在であるとされ、予測に用いられてきた。これを検出するスキャン統計量は、特に予見的スキャン統計量 (prospective scan statistics: Kulldorff, 2001) と呼ばれ、Cheng and Adepeju (2014) など、犯罪予測手法の一つとして利用されている。また、

Shiode and Shiode (2014) は、予見的スキャン統計量を、道路ネットワーク上の距離を利用して

計算する手法を提案し、街路レベルでの精緻なクラスタ検出を図っている。

### 2.2.2. 犯罪の時空間的相互作用を考慮した犯罪発生の強度推定

侵入盗など一部の犯罪には、同一対象に繰り返し発生する反復被害 (repeat victimization: Johnson et al., 1997; Pease, 1998; Ratcliffe and McCullagh, 1998) や、その周辺で繰り返し発生する近接反復被害 (near-repeats: Townsley et al., 2003; Bowers and Johnson, 2004) の傾向がある。たとえば、住宅侵入盗の発生後、少なくとも直近 2 週間は、被害宅から 200m 範囲内のエリアで再被害リスクが高まるとの報告がなされている (Johnson et al., 2007a)。

Bowers et al. (2004), Johnson et al. (2007b), は、この近接反復被害に着目し、事象間の空間的近接性ととともに、時間的近接性を考慮したモデル化を行うことで、侵入盗の発生リスクの予測を行った。ここでいうリスクとは、犯罪発生の強度 (単位時間・空間あたりの発生頻度の期待値) を意味する。その基本的なアイデアは、発生地点からリスクが距離減衰するというものだが、予測対象とする期間との時間的な隔たりも同時に考慮されている。同モデルで作成された強度をもとに地図を作成することは、予見的マッピング (Prospective Mapping) と呼ばれ、これをもとに開発されたツール ProMap は、主に英国で警察活動支援システムとして取り入れられた。この手法は、シンプルな

モデル化手法により、犯罪事象間の時空間的相互作用を予測に応用した点で画期的であったが、その後の発展により、住宅密度や道路へのアクセシビリティなどで重み付けを行うモデル (Johnson et al., 2009) や、近年では、道路ネットワークに拡張したモデル (Rosser et al., 2016) も考案されている。

また、予見的マッピングと同様に、犯罪の近接反復被害傾向に着目しつつ、確率点過程を用いてこれをモデル化する手法も生まれた。Mohler et al. (2011) の Self-exciting point process (SEPP) を用いた手法は、住宅侵入盗の近接反復被害を、地震の強度推定に用いられるモデル (Ogata, 1998) を参考にして定式化したものである。地震学では、常時地震活動 (background activity) と呼ばれる平時における地震活動と、他の地震によって誘起される余震 (aftershock activity) を想定するが、Mohler らは、前者を平時における犯罪発生強度、後者を 1 件の犯罪が惹起する近接反復被害になぞらえ、ある犯罪の発生からの時間的・空間的隔たりに応じて発生リスクが減衰するモデルを構築した。同研究グループは、上記モデルをもとに、犯罪予測システム PredPol を商用開発したが、同システムが、サンタクルーズやロサンゼルスでの警察実務に取り入れられ、報道などで取り上げられたことが、2010 年前後の欧米での犯罪予測ブームのきっかけとなった (Perry et al., 2013) <sup>8)</sup>。

### 2.2.3. 環境要因からの犯罪発生リスクの予測

ここまでで紹介した手法は、いずれも過去の犯罪発生データのみにより依拠して、将来の予測を行うものであった。一方で、過去の犯罪発生よりも、主に犯罪に関連する要因を用いて、将来の犯罪発生リスクの予測する手法が存在する。ここで用いられる要因は、地区の社会経済的特性 (人口密度、人種的多様性等) や、都市の物理構造的な特性 (公共施設数、繁華街までの距離等) などの変化しにくい静的な要因と、季節変動や天候、大規模なスポーツイベントとの時間的接近性、犯罪の前兆事案 (Leading Indicator) <sup>7)</sup> の発生など、変化しやすい動的な要因とに大別できる。

こうした手法の代表的なものとしては、Caplan et al. (2011) の Risk Terrain Modeling (RTM) が挙げられる。このモデルは、GIS におけるオーバーレイ解析に依拠しており、犯罪に関連する各変数の点分布に対し、KDE による複数の主題図を作成し、重み付けを行った上で重ね合わせることで、犯罪発生リスクの高い領域を同定する。

なお、店舗・施設の分布や、特定の属性を有する者の住居分布といった情報は、短期的には変動しない。このことから、RTM は、当該エリアに持続的に存在する環境的特徴をもとに、そこに安定的に潜在する犯罪リスクの大きさ (つまり、犯罪に対してどの程度脆弱であるか) を評価していると言える。同研究では、精度検証のための予測対象期間を 6 ヶ月と、比較的長期間に設定しているが、これは、こうした RTM の性質を考慮したものと解釈できる。

RTM の手法は、回帰分析の結果を踏まえて重み付けを設定するなど、近年も改良が施され (Caplan and Kennedy, 2016)、RTMDx というソフトウェアとして、各地に普及している。開発者である Caplan らも、同ソフトを無料や低価格で販売し、使用方法を解説するウェビナーを開くなど、手法の普及に注力している <sup>9)</sup>。

### 2.2.4. 回帰分析による犯罪発生件数、または確率の予測

最後に紹介する手法は、予測対象とする地域内に、特定の大きさを持ったセルや国勢調査区といった狭い領域を設け、回帰分析をもとに、領域内の将来の犯罪発生件数や、犯罪発生率を予測するものである。これらの手法では、回帰分析を、過去の犯罪要因の析出ではなく、将来の予測に用いている点に特徴がある。この手法の先駆的研究例としては、Gorr et al. (2003) が挙げられる。彼らは、米国ピッツバーグの6つの警察管区 (precinct) における5罪種の発生件数の予測について、複数の時系列予測の手法を適用し、手法間の精度比較を行った。同研究は、警察管区という比較的狭域での犯罪の空間的ばらつきに、年単位とやや解像度は粗いものの、時間的な変動を加えた初めての研究といえる。

回帰分析を予測に活用しようとする研究は、その後さらに発展し、犯罪に関連する諸要因と、過去の犯罪発生情報を用いた予測が行われている。Fox and Brown (2012) では、一般化線形モデルを用いて、セル単位で、犯罪発生が月に1件以上となる確率を推定している。このとき、予測変数として隣接地区 (セル) の特徴量と、隣接地区と当該地区それぞれにおいて、 $t-1$  時点で1件以上の犯罪発生があったかを情報として加えたモデリングを行っており、犯罪の時空間ラグも考慮したものとなっている。また、Wang and Brown (2012) では、時間的な変数 (直近で発生した犯罪からの経過時間) と、社会経済的 (男性人口等)・物理構造的 (大学までの距離等) 特性を予測変数として用い、一般化加法モデル (GAM) により、1件以上犯罪発生確率を32m四方セル単位で求めている。彼らは、この手法をSpatio-Temporal GAM (ST-GAM) と呼び、さらに、市全体を複数地区に分け、地区ごとに異なる平滑化関数を推定するLocal Spatio-Temporal GAM (LST-GAM) も、同時に提案している。

### 3. 研究 2

研究2では、研究1での整理に基づいて、代表的な予測手法を選び、実際のデータに適用、比較と評価を行った。これを通じて、日本のような犯罪発生が低頻度な状況では、どのような予測手法がふさわしいかを議論した。今回対象とした予測手法は、2章におけるカテゴリ i) より Prospective Space-Time Scan Statistics (PSTSS), ii) より Prospective Mapping (ProMap), Self-Exciting Point Process モデル (SEPP), iii) より Risk Terrain Modeling (RTM), iv) より Spatio-Temporal Generalized Additive Model (ST-GAM) を選んだ (表2)。なお、比較対象として、犯罪のホットスポット同定に用いられるカーネル密度推定 (Kernel Density Estimation, 以下 KDE) をあわせて適用した。

#### 3.1. 方法

##### 3.1.1. 研究対象, および用いた変数

本研究の対象地は、福岡県のある都市の中心市街地、繁華街を含むエリアであり、53の町丁目を含んでいる。総面積は約5.5km<sup>2</sup>、2010年時点の人口は54,789人であった。当該地域の一部は、2012~2013年より、福岡県警による街頭防犯カメラ設置対象地区となっている<sup>10)</sup>。

予測の対象は、当該エリアで2014年7-12月に発生した車上狙い、および部品狙い (以下、まとめて「車上狙い等」) 計47件であり、その発生地点を月ごとに予測した。

表 2 対象とした手法の一覧

手法名	略称	予測変数	予測に用いる情報の種別
カーネル密度推定	KDE		空間的情報
Prospective Mapping	ProMap	過去の犯罪発生地点	時空間的情報 (発生日/位置)
Self-Exciting Point Process	SEPP		
Prospective Space-Time Scan Statistics	PSTSS		
Risk Terrain Modeling	RTM	物理的/社会的 環境要因	空間的情報
Generalized Additive Model	GAM		

予測変数は、ProMap, SEPP, PSTSS, KDE では予測対象月の直近 6 ヶ月の犯罪発生状況（すなわち、7月の予測には1-6月の、12月の予測には6-11月の発生状況）を用いた。予測の空間的単位は、25m 四方セルであり、密度推定に用いるバンド幅は 250m に統一した。RTM, ST-GAM の予測変数は、株式会社ゼンリン「Zmap-AREA II (2014-3 版)」の地図データより、後述の分析を経て、「駐車場」、「コンビニエンスストア」、「道路」および「細道路」（以下、まとめて「道路全体」）を抽出し、これら 3 つの分布を予測変数とした。

### 3.1.2. 各手法の適用方法

KDE の分析にあたっては、株式会社 Esri の提供する標準的な GIS ソフトウェア、ArcGIS (ver.10.3) を用いて分析を行った。カーネル関数は、ArcGIS のデフォルトとして採用されている quartic kernel を用いた。

ProMap については、強度推定を Johnson et al. (2009) のモデル式 (式 1) に則って算出した。

$$\hat{\lambda}(s) = \sum_{c_i \leq \tau \wedge e_i \leq \nu} \left( \frac{1}{(1 + c_i)} \right) \frac{1}{(1 + e_i)} \quad (\text{式 1})$$

ただし、 $\tau$  は空間的なバンド幅 (KDE と同様)、 $\nu$  は時間的なバンド幅 (どの程度時間的に離れている点までを計算に含めるか) を表している。また、 $c_i$  は、各犯罪発生地点と予測対象セルとの空間的隔たり、 $e_i$  は、犯罪発生時期が、予測対象とする期間の最初の時点と、どの程度離れているか (時間的隔たり) を示す<sup>11)</sup>。

SEPP については、式 2-1 から強度推定を行った。

$$\lambda(t, x, y) = \sum_{\{k: t_k < t\}} \mu(x - x_k, y - y_k) + \sum_{\{k: t_k < t\}} g(t - t_k, x - x_k, y - y_k) \quad (\text{式 2-1})$$

$\mu$ 、および  $g$  は、ガウシアンカーネルを用いて推定される。本研究では、Mohler (2014)、および M

ohler et al. (2015) を参考に、次式 (式 2-2, 2-3) を用いた。

$$\mu(x, y) = \frac{\alpha}{T} \sum_{t_i < t} \frac{1}{2\pi\eta^2} \times \exp\left(-\frac{(x-x_i)^2 + (y-y_i)^2}{2\eta^2}\right) \quad (\text{式 2-2})$$

$$g(t, x, y) = \theta\omega \exp(-\omega(t-t_i)) \times \frac{1}{2\pi\sigma^2} \exp\left(-\frac{(x-x_i)^2 + (y-y_i)^2}{2\sigma^2}\right) \quad (\text{式 2-3})$$

ここで、 $(x-x_i)^2 + (y-y_i)^2$  は、カーネル中心点から各犯罪発生地点までの距離の 2 乗を指す。各パラメータは、式 2-4~2-8 で表される。

$$\alpha = \frac{\sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij}^b \mathbf{1}}{N_i} \quad (\text{式 2-4})$$

$$\eta^2 = \frac{\sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij}^b ((x-x_i)^2 + (y-y_i)^2)}{2 \sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij}^b} \quad (\text{式 2-5})$$

$$\theta = \frac{\sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij} \mathbf{1}}{N_j - \sum_{j=1}^{N_j} \exp(-\omega(T-t_j)) \mathbf{1}} \quad (\text{式 2-6})$$

$$\omega = \frac{\sum_{i < j} p_{ij}}{\sum_{i < j} (t_j - t_i) p_{ij}} \quad (\text{式 2-7})$$

$$\sigma^2 = \frac{\sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij} ((x-x_i)^2 + (y-y_i)^2)}{2 \sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij}} \quad (\text{式 2-8})$$

ただし、 $p_{ij}$  は、事象  $j$  が  $i$  に誘発された事象である確率であり、 $p_{ij}^b$  は、これを *background events* (親事象) のみに限定した際の確率を指す。また、 $\omega$ , および  $\sigma^2$  は、親事象と子事象のペアである *triggering pairs* のみを用いて算出している。SEPP では、親事象と子事象を弁別した上で、 $p_{ij}$ ,  $p_{ij}^b$  を算出、これを用いて上記パラメータを推定するが、解析的には求められないため、EM アルゴリズムが用いられる<sup>12)</sup>。本研究でも、同様の方法をとった。

PSTSS については、Kulldorff et al. (2005) による時空間順列スキャン統計量を用いた。実行にあたり、Kulldorff が開発した空間スキャン統計量を実行することに特化したソフトウェア SaTScan を用いた。空間的集積の閾値 (走査する円形領域の最大値) を 250m, 時間的集積の閾値を 60 日, *emerging cluster* とみなすための時間的範囲を直近 1 ヶ月とした。モンテカルロ検定のためのランダムデータ数は、999 回とした。

RTM と ST-GAM については、まず、各予測変数と車上狙い等との関連を調べるため、回帰分析

表 3 RTM, ST-GAM の変数選択のための回帰分析結果

	Model 1				Model 2			
	95%		Wald		95%		Wald	
	信頼区間				信頼区間			
	B	下限	上限	Exp. (B)	B	下限	上限	Exp. (B)
駐車場	.208**	.092	.324	1.231	.221**	.067	.374	1.247
公園	.048	-.044	.140	1.049	-	-	-	-
ファミリーレストラン/ ファーストフード店	-.009	-.230	.211	.991	-	-	-	-
コンビニエンスストア	.127+	-.006	.261	1.136	.196**	.098	.294	1.217
喫茶チェーン店	.119	-.048	.285	1.126	-	-	-	-
デパート/スーパーマーケット	-.103	-.244	.037	.901	-	-	-	-
道路総延長	-.226**	-.358	-.094	.798	.147*	.001	.293	1.159
(定数項)	.874	.759	.989	2.396	3.088	2.969	3.206	21.926

BIC Model 1: 417.839, Model 2: 408.336

\*\* p < 0.01, \* p < 0.05, + p < 0.1

を実行し、その結果（表 3）をもとに、「駐車場」、「コンビニエンスストア」、「道路全体」を予測変数として選定した<sup>13)</sup>。回帰分析の実行には、IBM 社の SPSS (ver.22) を用いた。

RTM は、ArcGIS により上記 3 変数について KDE を実行し、得られた強度推定値について、平均との乖離の大きさによって、0~3 の 4 水準の離散値に再分類 (0: 平均未満, 1: 平均 + 1 SD 未満, 2: 平均 + 2 SD 未満, 3: 平均 + 2 SD 以上), その後、回帰分析 (表 3 の Model2) で得たオッズ比をウェイト値として加重合計した。

ST-GAM では、モデルの学習のために、2008 年中に発生した車上狙い等の発生地点から、予測対象セルに 1 : 1 件以上の車上狙い等が発生, 0 : 車上狙い等発生せず, として値を付与した。これをもとに、一般化加法モデル (式 3) から、当該セルにおいて、1 件以上の車上狙い等が発生する確率を算出した。

$$\text{logit} [p(\text{incident}_{s,t} = 1)] = \sum_{n=1}^N f_n(x_{n,s,t}) \quad (\text{式 3})$$

ここで  $x_{n,s,t}$  は予測変数  $n$  によって形成される特性値行列であり、座標  $s$ , 時間  $t$  における周辺環境を

表す。  $f_n$  はその非線形変換である。本研究では、RTM と同一の予測変数を用い、セルごとにカーネル密度推定値を求め、この値をもとに予測を行った。パラメータの推定にあたっては、一般化クロスバリデーション (GCV) を用いた。計算にあたっては、統計解析環境 R (ver.3.2.1) の mgcv パッケージを用いた。

### 3.1.3. 評価指標

本研究では、各手法で予測された高リスクエリアを図示し、実際の犯罪発生状況と比較した上で、的中率（実際の発生地点の何割が高リスクエリアに含まれるか）、および予測精度の指標である Prediction Accuracy Index (PAI: Chainey et al., 2008) に基づいて評価を行った。PAI は、的中率を全領域面積に対する高リスクエリアの面積率で除すことで得られ、単位面積あたりの予測精度を示す。たとえば、PAI が 1 を超えることは、全体の 10% の領域で全犯罪発生量の 10% 以上を予測できたことを意味する。なお、RTM と ST-GAM は、予測変数とするデータの性質上、作られる予測地図は各 1 つのみだが、これに基づいて 6 回分の予測を行った。

## 3.2. 結果

各手法を実行して得た犯罪予測地図を示した上で、指標に基づく評価結果を示す。

図 1 には KDE, ProMap, SEPP の 6 回分の、図 2 には RTM, および ST-GAM の予測地図をそれぞれ示している。各手法において推定されたリスク値を 10 の水準に等量分類した上で、低いものから 0-9 のランクに分け、さらに上位 3 ランク (7-9) を赤色で表示している。この上位 3 ランクを「高リスクエリア」とみなす。

なお、PSTSS は、有意な時空間的集積が検出されず、今回は予測不可という評価となった。

図からは、犯罪発生状況に基づく 3 手法、環境要因に基づく 2 手法それぞれの間で、リスクの分布傾向が似通っていることが読み取れる。

次に、指標に基づく評価結果についてみる。表 4 には、各手法の予測対象月ごとの的中率、PAI、および実際の車上狙い等の発生件数を示す。

月ごとにみると、すべての予測対象月で PAI が 1 を超えたのは、RTM のみとなった。次に PAI の 6 ヶ月平均をみると、1 を超えたのは、RTM, ST-GAM のみであった。犯罪発生状況に基づく予測の中では、ProMap の PAI が最大だったものの、平均では 1 を下回る結果となった。

特に RTM については、的中率、PAI とともに、5 手法中最大の予測精度を示しており、その値は、ProMap, SEPP, KDE のおおよそ 2 倍となっている。ST-GAM は、RTM よりも精度は低いが、傾向として、犯罪発生状況に基づく予測よりも、環境要因に基づく予測のパフォーマンスが高いことがみてとれる。

標準偏差は、予測精度のばらつきであり、これが低いほど安定した精度をもつと解釈できるが、この点では ProMap が優れていた。

### 3.3. 考察

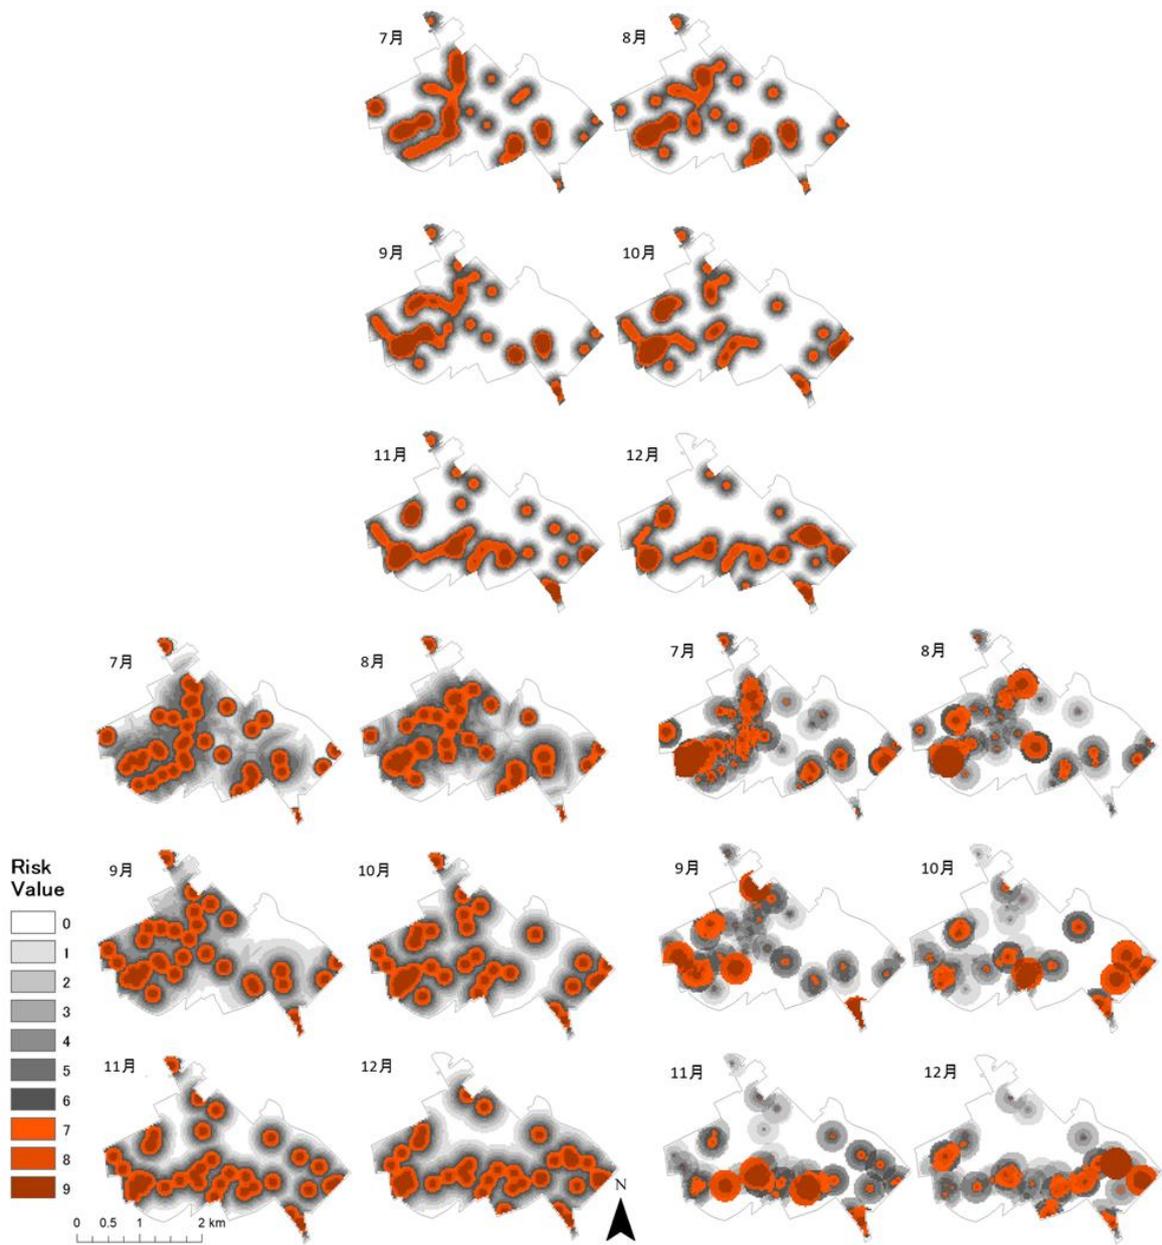


図1 KDE (左上), ProMap (右上), SEPP (下) による7-12月の予測地図

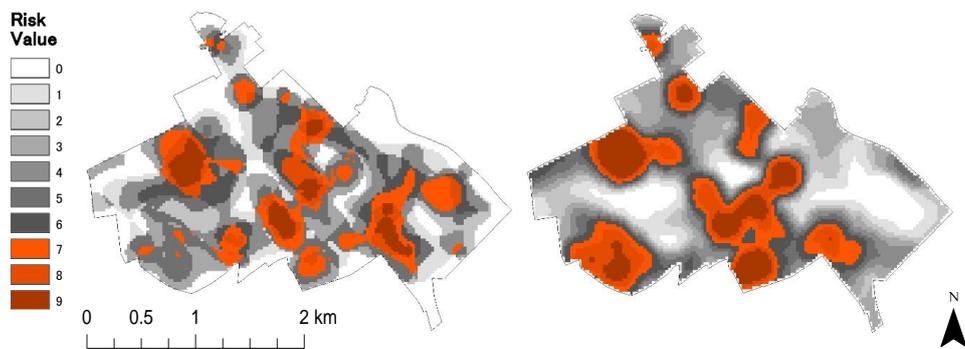


図2 RTM (左), ST-GAM による (右) 予測地図

表 4 各手法の予測精度（的中率, PAI), および予測対象月ごとの実際の発生件数

	的中率 (%)					PAI					実際の 発生件数
	RTM	ST- GAM	Pro Map	SEPP	KDE	RTM	ST- GAM	Pro Map	SEPP	KDE	
7月	25.0	75.0	25.0	25.0	50.0	1.14	2.75	1.18	0.83	2.44	4
8月	40.0	40.0	20.0	0.0	0.0	1.83	1.47	1.21	0.00	0.00	5
9月	27.3	36.4	27.3	18.2	9.1	1.25	1.33	1.47	0.61	0.47	11
10月	37.5	12.5	12.5	12.5	12.5	1.72	0.46	0.70	0.42	0.64	8
11月	55.6	22.2	12.5	66.7	25.0	2.54	0.81	0.65	2.22	1.23	9
12月	60.0	30.0	9.1	10.0	9.1	2.75	1.10	0.47	0.33	0.46	10
平均	40.9	36.0	17.7	22.1	17.6	1.87	1.32	0.95	0.73	0.87	
S.D.	13.1	19.6	6.8	21.4	16.3	0.60	0.72	0.36	0.71	0.79	

今回の予測対象（罪種，地域）では，RTM，および ST-GAM といった犯罪と関連する環境的特徴を用いた手法が，犯罪データを用いた手法よりも優れたパフォーマンスを発揮していた．さらに RTM は，ST-GAM と同じ予測変数を用いながら，平均的な予測精度でこれを上回った．2つの予測地図はおおむね似通っているものの，RTM では，ST-GAM では予測されなかった東部の領域が高リスクエリアとされている．ここには，実際にはターミナル駅が立地しており，その周辺には繁華街が広がっている．月ごとの PAI に着目すると，前半の3ヵ月については，両手法の予測精度はほぼ同等であるが，後半3ヵ月では，RTM が ST-GAM を大きく上回る．10-12月は，当該領域で多くの車上狙い等が発生しており，RTM はこうしたリスクを捉えていたといえよう．

一方で，他手法と比較して精度が高いとされる SEPP (Adepeju et al., 2016) の精度が劣っていた点も，注目に値する．ProMap を含め，これら犯罪データによる予測のパフォーマンスが相対的に低かった要因については，さらなる検討が必要ではあるが，日本のように犯罪発生が低頻度な状況では，過去の犯罪発生のもつ情報量が相対的に少ないこと，ProMap や SEPP が前提とする近接反復被害傾向が弱かった可能性，などが考えられる．

他手法に比べ高い予測精度を得た RTM, ST-GAM のような環境的要因に基づく予測手法は，日本でも一定の有用性が示唆された．他方で，これら手法の予測変数となった施設立地のような情報は，短期的には大きく変動せず，予測結果もデータが更新されるまでは変化しない．こうした予測は，偶発的な犯罪パターンの変化などに左右されず，安定した予測精度を得られる可能性があるが，明確な情勢の変化があった場合には，これを反映させるモデルを構築することも有用と考えられる．そこで，研究3では，環境要因に基づく手法をベースに，他の要素を考慮したモデルの構築にむけた検討を行った．

#### 4. 研究3

本章では、第3章の結果をふまえた上で、日本において有効な地理的犯罪予測手法を構築する。そのために、手法間比較で高いパフォーマンスを示した RTM に修正を加えたモデルを提示し、実際のデータを用いて分析・評価を行う。

今回は、新規手法として次の2つの方法、すなわち、I) 犯罪情勢を考慮した RTM、II) 犯罪促進要因を考慮した RTM を検討した。以下、各手法について説明する。

#### 4.1. 新規手法の構築

##### 4.1.1. 犯罪情勢を考慮した RTM

既に述べたように、RTM は、犯罪発生情報に依拠せずに犯罪を予測することのできる手法であるが、本研究で採用した予測変数である道路の分布状況などは、数ヵ月といった期間では、大きな変化は起こりにくく、重点的に介入する地域を月ごとに選定する、といった用途には使いにくい<sup>14)</sup>。

また、特定の地域で犯罪が連続的に発生した場合などは、一時的に警戒を強めるといったことも必要となるであろうが、犯罪の発生パターンを考慮しない RTM では、こうした要求に応じることができない。

そこで、RTM に対して、犯罪発生情報を組み合わせることで、長期的・潜在的なリスクをベースとして、短期的・顕在的なリスクにも対応するモデルを構築することを考える。こうした試みは、Caplan et al. (2013) において、RTM で高リスクとされたエリアと、近接反復被害発生場所の比較検討が行われているのみにとどまり、犯罪発生状況を考慮した発展的なモデルの考案には至っていない。

今回は、RTM をベースとして、年単位での長期的な犯罪情勢の変動としての「犯罪蓄積」、一年よりも短いスパンでの変動としての「犯罪の時期的変動」、より短期的な変動としての「犯罪の近接反復被害効果」の三要素を考慮したモデルを構築した。

##### 4.1.2. 犯罪促進要因を考慮した RTM

既に述べたように、RTM は主に、短期的には変動しにくい地区の環境的要因（特に物理構造的特性）を用いて犯罪を予測する。本研究でも、車上狙い等の発生予測を駐車場や道路といった施設等の分布状況に基づいて行っている。ところで、こうした予測変数は、犯罪学上では、*crime generators* (Brantingham and Brantingham, 1995)、すなわち、犯罪の潜在的被害対象が存在する場所とみなすことができる。予測を *crime generators* のみに依拠して行うことは、潜在的な被害対象（車上狙い等では駐車された車両）が多く存在するエリアで、車上狙い等が発生しやすい、という評価を行っているにすぎないともいえる。

一方、*crime generators* とともに、犯罪発生のメカニズムを説明する要因として、*crime enablers* がある。これは、「犯罪を防ぐことのできない場所」、すなわち場所の管理や、犯罪につながる行動の規制が弱く、犯罪の発生を妨げることができず、見逃すことにつながる (Clarke and Eck, 2003)。本研究の対象罪種である車上狙い等によせて考えるのであれば、管理者が常駐していない、人通りが少ないといった条件が、犯罪を容易にせしめる要因といえよう。

本研究では、*crime generators* としての駐車場等の施設分布状況を用いた RTM に対し、地区（町丁

目)の昼間人口, および地区の所得分布を考慮したモデルを構築した。昼間人口は, そのエリアにどの程度犯罪を抑止しうる「人の目」があるのかの代理変数として捉えられる。また, 所得分布は, 地区の社会経済的地位 (SES: Socio-Economic Status) の高さの代替指標となるが, SES は従来から犯罪との関連が示されている (たとえば, Hunter, 1971; Pratt and Cullen, 2005; Walsh and Taylor, 2007)。これらはともに, 犯罪に対しては抑制的な効果をもつと考えることができる。逆に, これが低水準な地区では, そうでない地区に比して, 犯罪が相対的に容易となると考えることができる。

## 4.2. 方法

本分析では, 研究 2 と結果を比較するため, 対象とする罪種・地域は研究 2 と同一のものとした。以下, 新規手法の適用方法についての述べる。

### 4.2.1. 犯罪情勢を考慮した RTM

まず, 新規手法 I) 犯罪情勢を考慮した RTM の実装方法について述べる。同モデルで考慮した三要素の一つ目, 「犯罪蓄積」については, デュアル・カーネル密度推定 (Dual Kernel Density Estimation, 以下 DKDE) を用いた。同手法では, たとえば, 住宅侵入盗についてのカーネル密度推定を, 地区の人口や世帯数によるカーネル密度推定で除すことで, 潜在的な被害対象の数をコントロールしたうえで, 犯罪発生リスクの高さを見積もることができる (齋藤ら, 2006 などを参照)。本研究では, 除算の分母として, 車上狙い等の潜在的な被害対象の分布として, 研究 2 で構築した RTM を利用した。また, 除算の分子となる犯罪の分布については, より正確に傾向を把握するために, 単年ではなく 2008-2013 年までの 6 年分の車上狙い等の発生地点データを用いた。

「犯罪の時期的変動」については, 犯罪の月ごとの傾向を利用した。犯罪の季節変動を予測地図に反映する際には, たとえば, 夏場では繁華街で, 冬場では住宅街で犯罪が起りやすい, といった情勢がみえることが望ましい。図 3 には, 2008-2013 年の車上狙い等の累積発生件数を月ごとに示した。この図からは, 季節によるトレンドの変化は必ずしも読み取れない。したがって, 今回は夏や冬といったグルーピングは行わず, 月ごとのトレンドを採用した。すなわち, 2008-2013 年の特定の月ごとの累積発生地点 (7 月であれば, 2008-2013 年の 7 月のみの犯罪発生地点) を用いて KDE を実行し, この結果を利用した。

より短期的な変動としての「犯罪の近接反復被害効果」については, ProMap などでは仮定されているような, 予測対象となる時点に近い時期に発生した犯罪に, より大きな重み付けを与える方法を採用する。すなわち, 予測対象時点から直近 1 ヶ月の間に発生した車上狙い等の発生地点から, 半径 250m のバッファを発生させ, この領域に対して重み付けを与える処理を行った。

最後に, これら三つの要素を RTM に反映させる方法として, RTM でグリッドごとに与えられたリスク値に対し, DKDE と, 月ごとの KDE のリスク値が 7-9 の領域と重なった場合, および, 予測対象月の直近 1 ヶ月間に発生した車上狙い等の発生地点から発生させた 250m バッファ領域と重なった場合には 1.1 を, そうでない場合には 1 をそれぞれ積算した。ただし, バッファ領域同士が重なった領域については, より高いリスクの重み付けがなされるべきと考え, 重複数を 1.1 にかけた上で積算した (つまり,  $n$  個のバッファ領域が重なる場合には  $1.1 \times n$  の値をかけた)。なお, 分析に

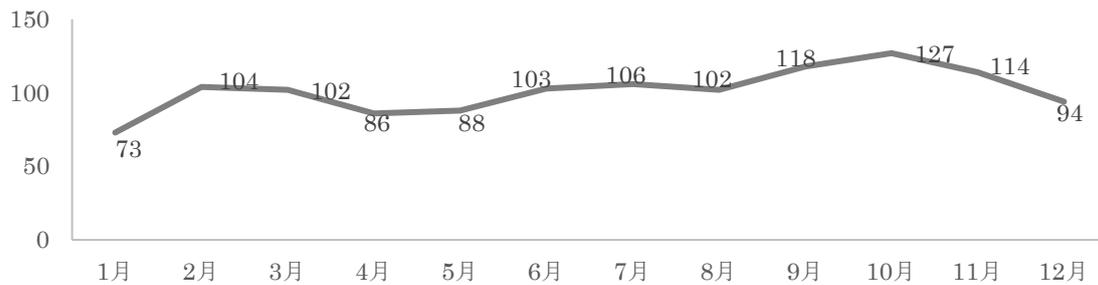


図3 2008-2013年における車上狙い等の月ごと発生件数

は ArcGIS10.3, DKDE の実行には犯罪分析用ソフトウェア CrimStat IV (Levine, 2013) を用いた。

#### 4.2.2. 犯罪促進要因を考慮した RTM

地区の昼間人口については、株式会社日本統計センターの「推計昼間人口 2010 (国勢調査地図対応版)」より、町丁目ごとに推計された昼間人口<sup>15)</sup>を用いた。地区の SES については、マップマーケティング株式会社の「年収別世帯数推計データ 2013」より、町丁目・所得階級別の推計世帯数<sup>16)</sup>を用い、町丁目別の平均世帯年収推計値 (年収別世帯数推計値に階級値を乗算後、全世帯数で除したもの) を算出した。

これらを ArcGIS 上で町丁目ごとに主題図を描き、平均と標準偏差をもとに 4 水準 (昼間人口や平均年収が低いほど、リスク値が高くなるよう値を割当て) に分類、セルに按分した。その後、「駐車場」、「コンビニエンスストア」、「道路全体」の変数とあわせて RTM を実行した。

#### 4.3. 結果と考察

新規手法 I, II, および RTM による予測結果を図 4 に示す (RTM については研究 2 と同じもの、色分けの基準は研究 2 と同様)。新規手法 I は、月ごとに変動する要素を含むため、月次の予測結果を示す。

新規手法 I は、RTM と高リスクリアの様相は全体としてかなり似たものとなるが、犯罪情勢の変化を考慮している分、細かい点で違いがみられる。たとえば、11 月と 12 月の予測地図は、東部でのリスク値が 7 月などに比べて高くなっている。新規手法 II は、高リスクと判定された範囲が、もとの RTM より大きく広がっているのがみてとれる。特に、地図中央部から北にかけての領域で差が大きい。

表 5 には、研究 2 と同様の指標で各手法の予測精度を評価した結果を示した。的中率の 6 ヶ月平均では、新規手法 I, II とともに、もとの RTM を上回る予測精度となっている。月ごとにみても、ほぼすべての月で、新規手法は RTM と同等かそれ以上のパフォーマンスを示している。

手法ごとに比較すると、新規手法 I では、7 月と 10 月の的中率が、もとの RTM と比べて高くなっている。また、12 月の予測結果では劣るものの、的中率の標準偏差は、もとの RTM と比べ低くなっており、より安定した予測精度が得られたと評価できる。こうした精度の改善に、新たに加えた三要素のいずれが寄与しているかを特定することは難しいが、RTM をベースに、犯罪情勢の変化

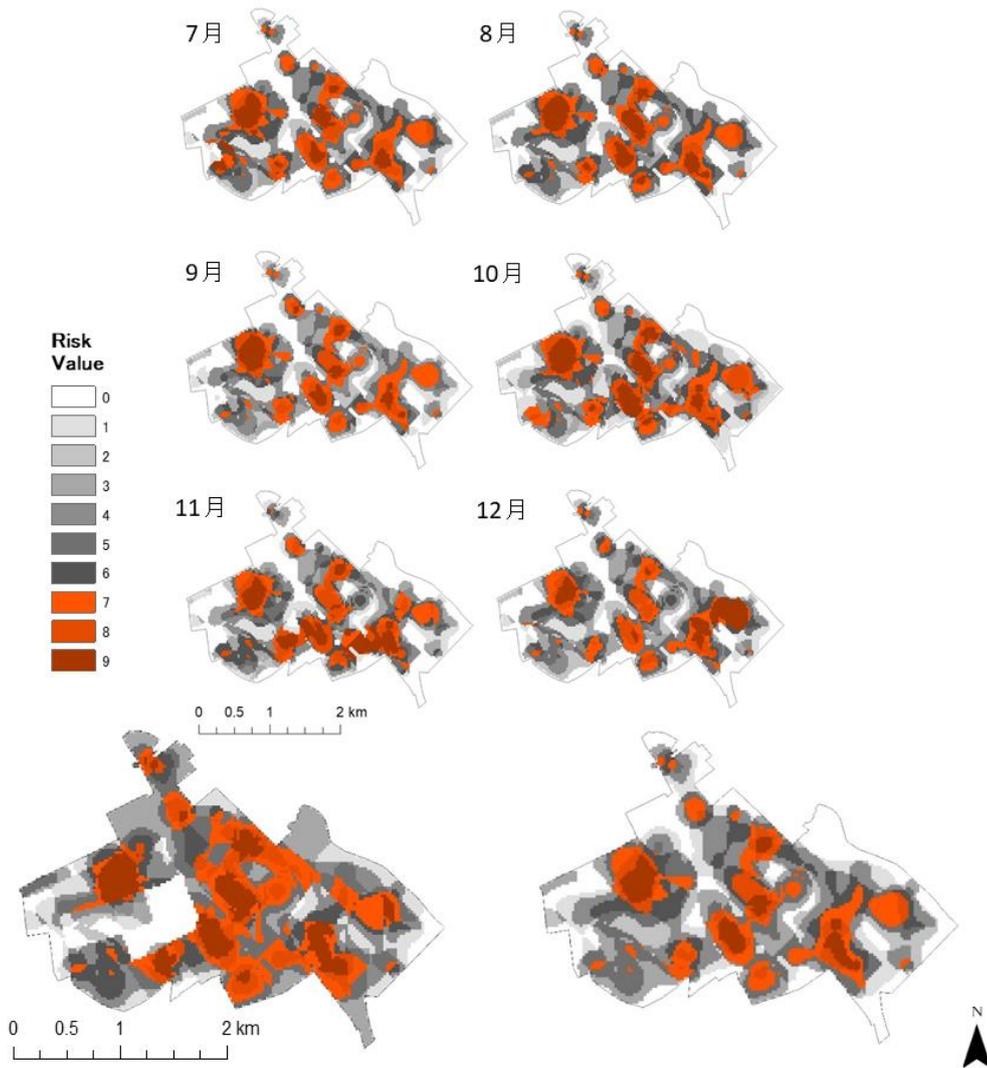


図4 新規手法 I (上), II (左下), RTM (下) による 7-12 月の予測地図

を反映させる手法に、一定の有用性があることが示唆された。

新規手法 II では、すべての月で RTM と同等以上の的中率が得られている。特に、7 月の的中率は 75.0% と、もとの RTM が予測できなかった犯罪発生を多く捉えていた。また、月ごとの的中率は、4 割を下回ることなく、平均では、5 割を超える精度を得ることができた。こうした結果からは、潜在的な被害対象の多く存在する場所に対し、「人の目」が疎である地区、あるいは SES が相対的に低い地区などを考慮することで、予測精度の向上が見込まれることがわかった。

一方で、PAI については、6 ヶ月平均をみると、新規手法が RTM をわずかに下回る結果となった。これは、的中率については、もとの RTM から向上した（すなわち、より多くの犯罪発生を予測できている）ものの、高リスクと予測される領域の面積も大きくなってしまったことを意味する。したがって、予測の効率という点では、二手法とも、もとの RTM よりパフォーマンスが低下したという評価となる。

ただし、この点については、的中率と PAI の兼ね合いを考えることが必要であろう。警察実務な

表 5 各手法の予測精度（的中率, PAI), および予測対象月ごとの実際の発生件数

	的中率 (%)			PAI			実際の 発生件数
	RTM	新規手法 I	新規手法 II	RTM	新規手法 I	新規手法 II	
7 月	25.0	50.0	75.0	1.14	1.97	2.26	4
8 月	40.0	40.0	40.0	1.83	1.63	1.20	5
9 月	27.3	27.3	45.5	1.25	1.13	1.37	11
10 月	37.5	50.0	50.0	1.72	1.77	1.50	8
11 月	55.6	55.6	55.6	2.54	2.23	1.67	9
12 月	60.0	40.0	70.0	2.75	1.90	2.11	10
平均	40.9	43.8	56.0	1.87	1.77	1.68	
S.D.	13.1	9.3	12.7	0.60	0.34	0.38	

どで、予測結果に基づいて地域をパトロールするといった際には、高リスク域が広範囲にわたる、あるいはまばらに散らばることは、活動を困難にさせる。しかしながら、新規手法 I, II とも、図をみる限り、もとの RTM に比べて巡回が困難な予測地図とは言い難い。予測領域の面積率の増加が、実用上問題ない程度であれば、高い的中率が得られた手法を用いるのが望ましいといえよう。

## 5. 総括

本研究では、既存研究の網羅的レビューを通じた地理的犯罪予測手法の体系的整理、代表的な予測手法の日本への適用による手法間比較、そして既存手法を修正したモデルの構築と評価を行った。本研究により見出された地理的犯罪予測手法の 4 分類は、さらに犯罪発生情報に依拠した予測と、都市の環境的要因に依拠した予測に分けることができるが、日本においては、後者の予測が有用である可能性が示唆された。特に、犯罪に関連するリスク要因の重ね合わせで予測する RTM の予測精度が最大であった。

本研究は、一罪種・一地域での分析にとどまっており、結果の一般化には、さらなる検証が必要である。しかしながら、犯罪データを必要としない RTM のような手法の有用性が示唆されたことは、米英などと比較して、研究における犯罪データの利用可能性が低いわが国の事情を考慮すれば、僥倖といえよう。加えて、犯罪が低頻度なわが国で、犯罪発生情報に依拠しない予測手法が有用であるという結果は、興味深いものである。その要因をさらに検討することは、今後の課題である。

また、今回 RTM をベースとして構築した二つの新規手法はともに、もとの RTM を上回るパフォーマンスを示した。新規手法 I は、これまで RTM で考慮されることのなかった犯罪情勢を、これに取り入れたものであり、国際的にも新しい試みであったが、犯罪発生パターンを反映することで、RTM から月ごとに異なる予測地図を出力することを可能とした。新規手法 II についても、潜在的な被害対象の多さを評価する RTM に対し、昼間人口や SES の低さといった、犯罪を促進しうる要

因を考慮することで、高い予測精度を得ることができた。

実務的な展開について述べると、RTMは、場所に潜在するリスクを評価するという性質上、即時的な犯罪対策に用いるよりは、中長期的な防犯施策を行う地区の選定といった用途での利用がふさわしいと考えられる。今回の新規手法Ⅱなどは、犯罪について脆弱な地区を見定め、地区の改善を図るうえで、特に有用であろう。

最後に、今回提案した環境要因と、過去の犯罪発生情報を同時に扱うモデルは、発展の途上にある。今後は、これらを統合する理論的な枠組みの精緻化や、新たな数理的モデルを考案する必要がある。この点は、地理的犯罪予測研究が乗り越えるべき課題として挙げることができるだろう。

なお、本研究の成果は、学会発表5本、査読付論文1本をもって公表され、データの提供元である福岡県警にもそれらを通じて還元された。一方で、実務への実装についてはまだ距離があり、実務での試用には至らなかった。具体的なシステム開発にむけた検討が求められる。

## 注

- 1) PredPol は、Larry Samuels, Jeffry Brantingham, George Mohler らによる PREDPOL 社の登録商標 (<http://www.predpol.com/> : 最終閲覧日 2017 年 10 月 2 日)。
- 2) RTM は、Leslie Kennedy や Joel Caplan らが運営するラトガース大学の公共安全センター (Rutgers Center on Public Security) が提供するシステム (<http://www.rutgerscps.org/rtm.html> : 最終閲覧日 2017 年 10 月 2 日)。
- 3) たとえば、OECD 諸国 (うち 26 カ国) 間で、2005 年における過去 1 年の犯罪被害経験を比較すると、日本は人口比で 9.9% となり (1 位はアイルランドで 21.9%), 26 カ国中 25 位となる (OECD, 2009)。
- 4) 平成 28 年版警察白書 (警察庁, 2016) によれば、地方警察官の退職者数は、2001 年から増加傾向にあり、2006 年以降では、団塊世代の大量退職などもあり、おおむね 1 万人を超える水準で推移している。
- 5) 平成 28 年版警察白書 (警察庁, 2016) によれば、警察官採用試験の受験者数は、2010 年以降減少傾向にあり、2014 年以降では 10 万人を下回っている。
- 6) たとえば、2012 年の“主要な犯罪” (日本では、一般刑法犯、すなわち、刑法犯から全体から交通関係業過を除いたもの、英国では、notifiable offence : 内務省が警察から報告を受けた犯罪、米国では、暴力犯罪および財産犯罪を指す) を比較すると、日本が約 140 万件であるのに対し、英国は約 350 万件、米国は約 1,019 万件、10 万人あたりの発生率では、日本が 1,101 件であるのに対し、英国は 6,191 件、米国は 3,246 件となる (法務省, 2014)。
- 7) Leading Indicator は、重大な犯罪に先立って起こる軽微な犯罪や違法行為等の事象を指す。Gorr and Olligschlaeger (2002) によれば、「ある月における軽微な犯罪や秩序違反の急激な増加は、犯罪を引き起こす要素の存在を暗に示しており、それゆえに、次月の同一エリアにおける重大な犯罪の増加を予測する」という。

- 8) PredPol は、アトランタ、シアトル、メンフィス、シカゴ、ミネアポリス、ダラスをはじめとする米国の都市と、英国でも導入事例がみられる。
- 9) RTMDx は、ニューヨーク、シカゴ、アトランティックシティといった米国の都市のほか、ヨーロッパ（パリ、ミラノ）、南米（ボゴタ）でも採用されている。
- 10) 今回の対象地での犯罪発生水準を評価するため、福岡市の犯罪発生件数（10万人あたり）を国外の都市と比較すると、強盗では、福岡市：2.3、ニューヨーク：198.2、シカゴ：353.6、侵入盗では、福岡市：47.6、ニューヨーク：164.9、シカゴ：482.0、自動車盗では、福岡市：2.9、ニューヨーク：86.4、シカゴ：374.6 となり、いずれも低水準にとどまる（データは、福岡市に関しては、福岡県警ホームページ：<http://www.police.pref.fukuoka.jp/data/open/cnt/3/1469/1/H27City.pdf>, 最終閲覧日 2017 年 10 月 2 日より、ニューヨーク、シカゴについては、FBI's Uniform Crime Reporting website：<https://ucr.fbi.gov/crime-in-the-u.s/2015/crime-in-the-u.s.-2015/resource-pages/downloads/download-printable-files>, 最終閲覧日 2017 年 10 月 2 日より参照した）。
- 11) 値の付与について、 $c_i$  は、グリッドセルの一辺の長さの半分を半径とした円（半径 12.5m）と、その整数倍の半径をもつ同心円を複数描き（円の半径は、最大で 262.5m となるが、250m を上限として、その外にある点は含めない）、同じ距離圏内に存在する点に同じ重み付けを与えた。 $e_i$  については、個々の犯罪の発生日から、予測対象の週数（日数を 7 で割った数、丸め処理は行っていない）を用いている。
- 12) EM アルゴリズムは、Dempster et al. (1977) が定式化した最尤推定法的一种である。この方法は特に、不完全データについて、観測可能なデータのみから、適当な初期値を定めてパラメータの条件付き期待値を計算（E-step）、さらにこの値を用いて尤度を最大化するパラメータ推定値を更新、このプロセスを尤度が収束するまで反復し、パラメータの最尤推定量を得る。本稿では、Rosser and Cheng (2016) を参考に、まず、次式 2-9 を用いて  $p_{ij}$  の初期値（ $\alpha = 1.5$ ,  $\beta = 500$ ）とし、この値に基づいて parents と offsprings を弁別した。

$$p_{ij} = \exp(-\alpha(t_j - t_i)) \exp\left(-\frac{(x_j - x_i)^2 + (y_j - y_i)^2}{2\beta^2}\right)$$

(式 2-9)

このとき、確率行列  $\mathbf{P}_0$ （ただし、 $i \leq j$  では確率は 0 であるため、上三角行列となる）が形成されるが、反復計算の度に、この行列も更新される。いったん  $p_{ij}$  が算出された後は、この確率にしたがって parents と offsprings のペアを選び出し（triggering pairs）、これをもとに式 2-4～2-8 のパラメータを計算、その後さらに、次式 2-10 から  $p_{ij}$  を更新する。

$$p_{ij} = \theta \omega \exp(-\alpha \omega (t_j - t_i)) \times \frac{1}{2\pi\sigma^2} \exp\left(-\frac{(x_j - x_i)^2 + (y_j - y_i)^2}{2\sigma^2}\right)$$

(式 2-10)

最終的に  $\|\mathbf{P}_n\|$  と  $\|\mathbf{P}_{n-1}\|$  との差をとった  $\|\mathbf{P}_n - \mathbf{P}_{n-1}\|$  の差が  $1 \times 10^{-7}$  未満になるまで反復計算を行った。

- 13) 回帰分析では、「駐車場」、「公園」、「ファミリーレストラン、およびファーストフード店」、「コ

ンビニエンスストア」,「喫茶チェーン店」,「デパート, およびスーパーマーケット」の施設のポイントデータ, および「道路全体」のラインデータについて, それぞれ町丁目単位で集計(ポイントデータは町丁目ごとに合計数を, ラインデータについては町丁目ごとに総延長を算出)を行った上で, 2008年1月-2014年6月までに同地域で発生した車上狙い等の町丁目ごとの発生件数を基準変数とする, 負の二項回帰分析を実行した. なお, 町丁目ごとの施設立地件数, および道路総延長については, 標準化した値を用いた. また, オフセット項として, 町丁目ごとの面積の対数を投入した. この時点で回帰係数が有意であった「駐車場」, 「コンビニエンスストア」, 「道路全体」を選び, RTM のウェイト値算出のため, 再度回帰分析を実行した.

- 14) RTM においても, 薬物事案での逮捕地点 (Caplan et al., 2011), 不審者目撃地点, 仮釈放者の住居 (Caplan and Kennedy, 2016) など, 短期的に変動する情報を用いている場合もある. しかし, 変数の多くは, 都市の物理構造的特性に関するものとなっている.
- 15) 総務省統計局などから公表される市区町村単位の昼間人口は, 通常, その市区町村の常住人口から流出人口を減算し, さらに流入人口を加算することで得られる. しかしながら, 町丁等の小地域単位では, 従業地・通学地別の就業者・通学者数は公表されていない. 株式会社日本統計センターでは, 国勢調査と経済センサス等のデータをもとに, 町丁目ごとの通学者数, 従業者数, 通学も従業もしない者を足し上げることで, 町丁目別の昼間人口を推計している (<http://www.nihon-toukei.co.jp/business/db/chukanjinko/chukanjinko.htm>: 最終閲覧日 2017年10月13日).
- 16) マップマーケティング株式会社では, 2013年住宅土地統計に加え, 2010年国勢調査データ, 学歴(最終学歴, 学歴別の給与差), 各賃金系データ(賃金センサス, 農林水産省統計表, 海面事業に関する統計, 公務員給与)などから年収レベルごとの世帯数を推計している ([https://www.mapmarketing.co.jp/data\\_nenshu.html](https://www.mapmarketing.co.jp/data_nenshu.html): 最終閲覧日 2017年10月13日).

## 参考文献

- 警察庁 (2016) 平成 28 年版警察白書. <<https://www.npa.go.jp/hakusyo/h27/honbun/index.html>> (最終閲覧日 2017年2月16日)
- 齊藤知範・島田貴仁・原田豊 (2006) 小学生の犯罪被害リスクに関する地理的分析—デュアル・カーネル密度推定を用いて—, 「第 15 回地理情報システム学会学術研究発表大会講演論文集」, **15**, pp.301-304.
- 法務省 (2014) 平成 26 年版犯罪白書. <[http://hakusyo1.moj.go.jp/jp/61/nfm/n61\\_2\\_1\\_4\\_1\\_0.html](http://hakusyo1.moj.go.jp/jp/61/nfm/n61_2_1_4_1_0.html)> (最終閲覧日 2017年2月16日)
- Adepeju, M., Rosser, G., and Cheng, T. (2016) Novel evaluation metrics for sparse spatio-temporal point process hotspot predictions—a crime case study. *International Journal of Geographical Information Science*, 1-22.
- Anselin, L., Cohen, J., Cook, D., Gorr, W., and Tita, G. (2000) Spatial analyses of crime. *Criminal justice*, **4**(2), 213-262.

- Block, R. L., and Block, C. R. (1995) Space, place and crime: Hot spot areas and hot places of liquor-related crime. *Crime and place*, **4**(2), 145-184.
- Block, C. R. (1998) The GeoArchive: An information foundation for community policing. *Crime Mapping and Crime Prevention, Crime Prevention Studies*, 27-81.
- Bowers, K., and Johnson, S. (2004) Who commits near repeats? A test of the boost explanation. *Western Criminology Review*, **5**(3), 12-24.
- Bowers, K., Johnson, S., and Pease, K. (2004) Prospective hot-spotting the future of crime mapping? *British Journal of Criminology*, **44**(5), 641-658.
- Brantingham, P., and Brantingham, P. (1995) Criminality of Place: Crime Generators and Crime Attractors. *European Journal on Criminal Policy and Research*, **3**(3), 1-26.
- Caplan, J., and Kennedy, L. (2016) *Risk Terrain Modeling: Crime Prediction and Risk Reduction*. Univ of California Press.
- Caplan, J., Kennedy, L., Barnum, J., and Piza, E. (2015) Risk terrain modeling for spatial risk assessment. *Cityscape*, **17**(1), 7.
- Caplan, J., Kennedy, L., and Miller, J. (2011) Risk terrain modeling: Brokering criminological theory and GIS methods for crime forecasting. *Justice Quarterly*, **28**(2), 360-381.
- Caplan, J., Kennedy, L., and Piza, E. (2013) Joint utility of event-dependent and environmental crime analysis techniques for violent crime forecasting. *Crime & Delinquency*, **59**(2), 243-270.
- Chainey, S., Tompson, L., and Uhlig, S. (2008) The utility of hotspot mapping for predicting spatial patterns of crime. *Security Journal*, **21**(1), 4-28.
- Cheng, T., and Adepeju, M. (2014) Detecting emerging space-time crime patterns by prospective STSS. In *Proceedings of the 12th International Conference on GeoComputation*. <<http://www.geocomputation.org/2013/papers/77.pdf>>. (最終閲覧日 2017年2月16日)
- Clarke, R., & Eck, J. (2003) *Become a Problem Solving Crime Analyst In 55 small steps.*, London: University College London Jill Dando Institute of Crime Science.
- Dempster, A., Laird, N., & Rubin, D. (1977). Maximum likelihood from incomplete data via the EM algorithm. *Journal of the royal statistical society. Series B (methodological)*, 1-38.
- Fox, J., and Brown, D. (2012) Using temporal indicator functions with generalized linear models for spatial-temporal event prediction. *Procedia Computer Science*, **8**, 106-111.
- Gorr, W., and Olligschlaeger, A. (2002) *Crime hot spot forecasting: Modeling and comparative evaluation, final project report*. Washington, DC: National Criminal Justice Reference Service.
- Gorr, W., Olligschlaeger, A., and Thompson, Y. (2003) Short-term forecasting of crime. *International Journal of Forecasting*, **19**(4), 579-594.
- Groff, E., and La Vigne, N. (2002) Forecasting the future of predictive crime mapping. *Crime Prevention*

- Studies*, **13**, 29-58.
- Hunter, A. (1971) The ecology of Chicago: Persistence and change, 1930-1960. *American Journal of Sociology*, **77**(3), 425-444.
- Johnson, S., Bernasco, W., Bowers, K., Elffers, H., Ratcliffe, J., Rengert, G., and Townsley, M. (2007a) Space-time patterns of risk: A cross national assessment of residential burglary victimization. *Journal of Quantitative Criminology*, **23**(3), 201-219.
- Johnson, S., Birks, D., McLaughlin, L., Bowers, K., and Pease, K. (2007b) *Prospective Crime Mapping in Operational Context, Final Report.*, London, UK: Home Office.
- Johnson, S. D., Bowers, K., and Hirschfield, A. (1997) New insights into the spatial and temporal distribution of repeat victimization. *The British Journal of Criminology*, **37**, 224-241.
- Johnson, S., Bowers, K., Birks, D., and Pease, K. (2009) Predictive mapping of crime by ProMap: accuracy, units of analysis, and the environmental backcloth. In Weisburd, D., Bernasco, W., and Bruinsma, G. J. N. eds. *Putting crime in its place: units of analysis in spatial crime research.*, 171-198. Springer New York.
- Kulldorff, M. (1997) A spatial scan statistic. *Communications in Statistics - Theory and Methods*, **26**, 1481-1496.
- Kulldorff, M. (2001) Prospective time periodic geographical disease surveillance using a scan statistic. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, **164**(1), 61-72.
- Kulldorff, M., Athas, W., Feuer, E., Miller, B. and Key, C. (1998) Evaluating cluster alarms: A space-time scan statistic and brain cancer in Los Alamos. *American Journal of Public Health*, **88**, 1377-1380.
- Kulldorff, M., Heffernan, R., Hartman, J., Assunção, R., and Mostashari, F. (2005) A Space-Time Permutation Scan Statistic for Disease Outbreak Detection. *PLoS Medicine*, **2**(3), 216-224.
- Mohler, G., Short, M., Brantingham, P., Schoenberg, F., and Tita, G. (2011) Self-exciting point process modeling of crime. *Journal of the American Statistical Association*, **106**, 100-108.
- Mohler, G. (2014) Marked point process hotspot maps for homicide and gun crime prediction in Chicago. *International Journal of Forecasting*, **30**(3), 491-497.
- Mohler, G. (2015) Event forecasting system. U. S. Patent 13,676,358. 2015-02-03.
- Townsley, M., Homel, R., and Chaseling, J. (2003) Infectious burglaries. A test of the near repeat hypothesis. *British Journal of Criminology*, **43**(3), 615-633.
- Organisation for Economic Co-operation and Development (Paris) (2009) *OECD Factbook 2009: Economic, Environmental and Social Statistics*. <[http://www.oecd-ilibrary.org/economics/oecd-factbook-2009\\_factbook-2009-en](http://www.oecd-ilibrary.org/economics/oecd-factbook-2009_factbook-2009-en)> (最終閲覧日 2017年2月16日)
- Ogata, Y. (1998) Space-time point-process models for earthquake occurrences. *Annals of the Institute of Statistical Mathematics*, **50**(2), 379-402.
- Pease, K. (1998) *Repeat victimisation: Taking stock* (Home Office Crime Prevention and Detection Series, Vol.90). London, UK: Home Office Police Research Group.

- Perry, W., McInnis, B., Price, C., Smith, S., and Hollywood, J. (2013) *Predictive policing: The role of crime forecasting in law enforcement operation.*, Rand Corporation.
- Polat, E. (2007) Spatio-temporal crime prediction model based on analysis of crime clusters., MS thesis, Geodetic and Geographic Information Technologies Department, Middle East Technical University.
- Pratt, T., & Cullen, F. (2005) Assessing macro-level predictors and theories of crime: A meta-analysis. *Crime and justice*, **32**, 373-450.
- Ratcliffe, J., and McCullagh, M. (1998) Identifying repeat victimization with GIS. *British Journal of Criminology*, **38**(4), 651-662.
- Rosser, G., and Cheng, T. (2016) Improving the Robustness and Accuracy of Crime Prediction with the Self-Exciting Point Process Through Isotropic Triggering. *Applied Spatial Analysis and Policy*, 1-21.
- Rosser, G., Davies, T., Bowers, K., Johnson, S., and Cheng, T. (2016) Predictive Crime Mapping: Arbitrary Grids or Street Networks? *Journal of Quantitative Criminology (2016)*, 1-26.
- Shiode, S., and Shiode, N. (2014) Microscale Prediction of Near - Future Crime Concentrations with Street - Level Geosurveillance. *Geographical Analysis*, **46**(4), 435-455.
- Walsh, J. A., & Taylor, R. B. (2007) Community structural predictors of spatially aggregated motor vehicle theft rates: Do they replicate?. *Journal of Criminal Justice*, **35**(3), 297-311.
- Wang, X., and Brown, D. (2012) The spatio-temporal modeling for criminal incidents. *Security Informatics*, **1**(1), 1-17.