

日本における地理的犯罪予測手法の開発に関する研究

2020年 3月

大山智也

日本における地理的犯罪予測手法の開発に関する研究

大山智也

システム情報工学研究科

筑波大学

2020年 3月

目次

第1章 序論	7
1.1 背景	7
1.1.1 国内外における地理的犯罪予測の試み	7
1.1.2 データに基づく犯罪対策をめぐるわが国の社会状況	10
1.1.3 本研究の問題意識	13
1.2 目的	14
1.3 研究の構成	15
1章の参考文献	17
第2章 既存の地理的犯罪予測研究の整理	20
2.1 はじめに	20
2.2 資料収集の方法	20
2.3 地理的犯罪予測研究の源流	21
2.3.1 犯罪予測研究の背景	21
2.3.2 犯罪の時間的变化に着目した研究	22
2.3.3 犯罪のホットスポットの発見, および技術の発達	23
2.3.4 実務, および社会の動向	24
2.4 主要な地理的犯罪予測手法の整理と概観	25
2.4.1 地理的犯罪予測研究の特徴	25
2.4.2 アプローチの違いによる整理	25
2.4.3 時空間クラスタの検出	28
2.4.4 犯罪の時空間相互作用を考慮した犯罪発生の強度推定	29
2.4.5 犯罪生成・誘引要因からの犯罪発生リスクの予測	30
2.4.6 多様な情報からの犯罪発生リスクの予測	32
2.4.7 地区単位での犯罪発生件数, または確率の時系列予測	34
2.4.8 環境要因と犯罪の時空間相互作用を組み合わせた犯罪発生リスクの予測	35
2.5 地理的犯罪予測システムへの実装	36
2.6 まとめ	38
2章の参考文献	41
第3章 主要な地理的犯罪予測手法の実データへの適用と検証	50
3.1 はじめに	50
3.2 分析手法の概略	51
3.2.1 KDE	51
3.2.2 ProMap	52
3.2.3 SEPP	54
3.2.4 PSTSS	55
3.2.5 RTM	57
3.2.6 GAM	58
3.3 評価指標	58
3.3.1 予測の正確性	58
3.3.2 予測の安定性	59
3.3.3 予測領域のコンパクトさ	59

3.4	方法	60
3.4.1	分析対象, および使用したデータ	60
3.4.2	具体的な適用方法	63
3.5	結果	69
3.5.1	予測結果	69
3.5.2	指標に基づく評価結果	75
3.6	議論	78
3.7	まとめ	81
	3章の参考文献	82
第4章	日本に適した地理的犯罪予測手法の検討	84
4.1	はじめに	84
4.2	長期的・潜在的リスク	84
4.2.1	社会経済的要因	84
4.2.2	犯罪生成・誘引要因	86
4.2.3	犯罪可能要因	87
4.3	短期的・顕在的リスク	89
4.3.1	近接反復被害	89
4.3.2	前兆事案	89
4.4	リスクの組み合わせ方に関する検討	90
4.5	まとめ	92
	4章の参考文献	93
第5章	新手法の車上狙い・部品狙いへの適用と評価	97
5.1	はじめに	97
5.2	車上狙い・部品狙いに適した予測モデルの作成	97
5.2.1	長期的・潜在的リスク要因の検討	97
5.2.2	短期的・顕在的リスク要因の検討	97
5.2.3	予測モデルの作成	98
5.3	長期的・潜在的リスクに関する分析	98
5.4	短期的・顕在的リスクに関する分析, 長期的・潜在的リスクとの組み合わせ方	101
5.5	予測モデルの適用と評価	103
5.5.1	検証の方法	103
5.5.2	結果	103
5.6	議論	105
5.7	まとめ	106
	5章の参考文献	107
第6章	新手法の痴漢への適用と評価	109
6.1	はじめに	109
6.2	痴漢に適した予測モデルの作成	109
6.2.1	長期的・潜在的リスク要因の検討	109
6.2.2	短期的・顕在的リスク要因の検討	110
6.2.3	予測モデルの作成	110
6.3	長期的・潜在的リスクに関する分析	111
6.3.1	分析単位と応答変数の設定	111
6.3.2	予測変数の設定	112

6.3.3	分析方針	115
6.3.4	結果	116
6.4	短期的・顕在的リスクに関する分析	119
6.4.1	分析方法	119
6.4.2	結果	119
6.5	予測モデルの適用と評価	120
6.5.1	予測値の算出	120
6.5.2	検証の方法	121
6.5.3	結果	121
6.6	議論	123
6.7	まとめ	126
6章	の参考文献	128
第7章	新手法の還付金等詐欺への適用と評価	130
7.1	はじめに	130
7.2	還付金等詐欺に適した予測モデルの作成	131
7.2.1	長期的・潜在的リスク要因の検討	131
7.2.2	短期的・顕在的リスク要因の検討	131
7.2.3	予測モデルの作成	132
7.3	長期的・潜在的リスクに関する分析	132
7.3.1	分析単位と応答変数の設定	132
7.3.2	予測変数の設定	133
7.3.3	分析方針	136
7.3.4	結果	139
7.4	短期的・顕在的リスクに関する分析	139
7.4.1	分析方法	139
7.4.2	結果	140
7.5	予測モデルの適用と評価	140
7.5.1	予測に用いたデータ	140
7.5.2	予測値の算出	140
7.5.3	検証の方法	141
7.5.4	結果	142
7.6	議論	143
7.7	まとめ	144
7章	の参考文献	146
第8章	結論	147
8.1	総合論議	147
8.1.1	本研究のまとめ	147
8.1.2	本研究から得られた示唆	150
8.2	研究の課題と展望	152
8.2.1	研究課題	152
8.2.2	今後の展望	153
8.3	実務への適用にむけて	154
8章	の参考文献	159
初出一覧		161

謝辭.....	162
付録.....	165

目次

図 1-1	米サンタクルーズ市警での犯罪予測システム活用の様子 (Government Technology, 2016)	8
図 1-2	京都府警の犯罪予測システム導入について伝える新聞記事	9
図 1-3	神奈川県警と研究者らの犯罪予測調査研究会について伝える新聞記事	9
図 1-4	長野県警の犯罪予測システムに関する予算要求について伝える新聞記事	10
図 1-5	警視庁の犯罪予測活用検討について伝える新聞記事	10
図 1-6	地方警察官の退職状況 (左), および警察官採用試験実施状況 (右)	12
図 1-7	本研究の構成	16
図 2-1	キーワード検索結果, および背景にある研究・社会的動向	21
図 3-1	KDE の概念図	52
図 3-2	ProMap の概念図	53
図 3-3	ProMap における c_i の与え方	54
図 3-4	親事象と子事象のペアリングのイメージ	55
図 3-5	時空間スキュアの概念図	57
図 3-6	RTM の実行手順, および ArcGIS 上でのコマンド	57
図 3-7	CI 算出例	60
図 3-8	2014 年における車上狙い等の月別発生状況	62
図 3-9	対象地域の概形	62
図 3-10	本分析での ProMap における c_i の与え方	64
図 3-11	KDE による予測結果	70
図 3-12	ProMap による予測結果	71
図 3-13	SEPP による予測結果	72
図 3-14	RTM による予測結果	73
図 3-15	GAM (社会経済的要因) による予測結果	73
図 3-16	GAM (物理構造的要因) による予測結果	74
図 3-17	KDE, ProMap, SEPP, RTM, GAM による予測結果	75
図 3-18	全エリアにおける予測の正確性の比較	77
図 3-19	RTM 出力結果, および鉄道駅の分布状況	79
図 4-1	提案手法実行の手順	92
図 5-1	2008 年 1 月～2014 年 6 月の車上狙い等データから求めたカーネル密度推定値 (左), および空間回帰の残差 (右) の分布	100
図 5-2	RTM, および e-RTM*NR による予測地図	104
図 6-1	福岡市の概形	112
図 6-2	予測結果による ROC 曲線	122
図 6-3	長期的・潜在的リスクが上位 10% のリスクに含まれるセル (ZINB による予測)	123
図 6-4	2014～2017 年の時間帯ごとの痴漢発生件数	125
図 7-1	「ATM 設置建築物との位置関係」イメージ	134
図 7-2	スーパーにおける誘導発生件数の度数分布	137

表目次

表 1-1	米国の警察活動に用いられる予測的方法の種類 (Perry et al., 2013)	7
表 2-1	地理的犯罪予測手法の分類, および主要な研究例	26
表 3-1	対象とした手法の一覧	51
表 3-2	分析対象地域の車上狙い等発生件数, および他地域との比較	62
表 3-3	負の二項回帰分析結果	67
表 3-4	ロジスティック加法回帰 (社会経済的要因) の結果	68
表 3-5	ロジスティック加法回帰 (物理構造的要因) の結果	68
表 3-6	予測の正確性, および安定性に関する指標	76
表 3-7	予測領域のコンパクトさ	78
表 5-1	RTM のリスク値と空間回帰残差のクロス表	99
表 5-2	100 m・7 日ごとの近接反復被害効果 (D_0+1) の大きさ	102
表 5-3	指標による手法間比較, および予測対象月ごとの実際の発生件数	104
表 5-4	e-RTM*NR で新たに高リスク領域となったエリアの状況	105
表 6-1	女性に対する痴漢発生件数 (時間帯ごと)	112
表 6-2	長期的・潜在的リスクの予測変数データ源, および記述統計	114
表 6-3	2014~2017 年における応答変数の分布 (時間帯ごと)	116
表 6-4	ZINB 推定結果	117
表 6-5	100 m・7 日以内ごとの痴漢イベントのペア数	120
表 6-6	100 m・7 日以内ごとの痴漢イベントの Knox 比	120
表 6-7	各モデルによる AUC, およびリスク上位 10% のセルにおける的中率	122
表 7-1	福岡市における 2016 年の行政区ごとの ATM 台数,	132
表 7-2	予測変数一覧	133
表 7-3	建築物種別ごとの誘導発生状況	137
表 7-4	予測変数の要約統計量	138
表 7-5	GLMM によるパラメータ推定結果	139
表 7-6	Knox 比にもとづく反復誘導分析の結果	140
表 7-7	予測変数の要約統計量	141
表 7-8	各予測手法の予測精度	143
表 8-1	本研究で提案した手法に基づく予測モデルと既存手法の比較	149
表 8-2	本研究で得られた結果のまとめ	150

第1章 序論

1.1 背景

1.1.1 国内外における地理的犯罪予測の試み

犯罪は、特定の特徴を持った場所や地域で繰り返し発生する、あるいは、一つの犯罪がきっかけで、繰り返し犯罪が発生するといった性質をもつ (Farrell and Pease, 2001). こうした性質に着目し、周辺環境の特性や、過去の犯罪発生状況をもとに、対象エリアにおける将来の犯罪発生リスク、あるいは犯罪集積エリアを予測する地理的な犯罪予測の試みが、米国を中心として、研究やシステム開発の対象となっている。Perry et al. (2013) は、今日の米警察で行われている予測的方法を4タイプに大別している (表 1-1) が、地理的な犯罪予測とは、このうち1の類型にあたるものを指す (以下、地理的犯罪予測 (雨宮, 2016) と呼称)。この技術は、侵入盗、路上強盗、自動車盗といった、犯罪を行いやすい時間・場所・状況を選んで行われるような罪種を対象に適用され、犯罪発生に先駆けて、現地に警察を差し向ける、あるいは、リスクの高いエリアに人的資源を集中的に投入するといった対策を行う上での判断を助けるものである。こうした目的のために、地理的犯罪予測の手法は、ある市や警察管区において、次にいつ・どこで特定の犯罪が発生する可能性が高いのかを、時間的には月、週、日、時間単位、空間的には数十～数百メートルのグリッドセル単位といった範囲で示す。中でも、PredPolⁱや RTMⁱⁱといったいくつかの手法は、実証研究により一定の予測精度が示された上で、警察実務に取り入れられている (図 1-1 は PredPol の実際の活用の様子)。

地理的犯罪予測は、米国のほか、少なくともイギリス、ドイツ、スイス、オランダ、イタリア、フランス、ブラジル、チリ、ウルグアイの警察で導入実績があるⁱⁱⁱ。また、ベルギー、ス


表 1-1 米国の警察活動に用いられる予測的方法の類型 (Perry et al., 2013)

1	犯罪の予測: 犯罪リスクが増大した場所と時間の予測を行うアプローチ
2	加害者の予測: 将来において加害におよぶリスクの高い個人を同定するアプローチ
3	犯行者の身元の予測: 過去に起きた特定の犯罪の加害者と思しき人物に一致する人物像を作成する技術
4	被害者の予測: 犯罪の被害に遭いそうな集団、いくつかの場合では個人を同定するアプローチ

i 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 2019年9月19日)。

ii 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/>: 最終閲覧日 2019年9月19日)。

iii 各国で用いられている (あるいは、用いられていた) 地理的犯罪予測システムには、以下のようなものがある。米国では、PredPol, RTM, Hunchlab, イギリス、ウルグアイでは



Santa Cruz's predictive policing system on a tablet. Photo by Eyragon Eidam.

図 1-1 米サンタクルーズ市警での犯罪予測システム活用の様子 (Government Technology, 2016)

ペインでも独自の予測システムの研究開発が進行しているなど^{iv}、地理的犯罪予測は、欧米諸国を中心に導入が進んでいる。こうした予測手法を駆使しながら、犯罪に関連するビッグデータをもとに、犯罪発生に先駆けて (proactive)、予見的に (prospective) 警察活動を行う予測型警察活動 (Predictive Policing) が、2010年代以降米国でさかんに行われている。2009年と2010年には、米国国立司法研究所 (National Institute of Justice, 以下, NIJ) により、予測型警察活動に関するシンポジウム (Predictive Policing Symposium) が開催され、全米から研究者、実務家、法執行機関の長などが参加し、予測型警察活動のコンセプトや実装の方法、および限界などについての議論がなされた (National Institute of Justice, 2012; Uchida, 2009)。なお、2011年には、“Predictive Policing” が、Time 誌の “The 50 best Inventions of The Year 2011” に選定されており、犯罪の予測とそれに基づく警察活動に対する社会的な関心も高いといえる。また、NIJ は、2016年に “Real-Time Crime Forecasting Challenge” と称した地理的犯罪予測手法のコンペを開催する^vなど、米国の司法・行政において、予測型警察活動を支える犯罪予測

米国同様 PredPol, ドイツでは PRECOBS, PreMap, KrimPro, SKALA, KLB-operativ, スイスではドイツ同様 PRECOBS, オランダでは CAS, イタリアでは KeyCrime, フランスでは expert system, ブラジルでは ROTA-Analytics という地理的犯罪予測のシステムをそれぞれ導入した実績がある。なお、チリではシステムの名称は不明であるが、チリ大学の Center for Analysis and Modeling in Security (CEAMOS) の研究者らが、2015年以降にチリ国家憲兵とソフトウェアの実証実験を行っており、現在は72の自治体で犯罪分析プラットフォームに予測が組み込まれている (CEAMOS, 2018)。

iv ベルギーでは、iPolice という名称のシステムの導入が2020年に予定されている (Flandersnews.be, 2018)。また、スペインではスペイン国立警察局とグラナダ大学が P3-DSS という地理的犯罪予測・パトロール最適化システムを共同開発している (Camacho-Collados and Liberatore, 2015)。

v Real-Time Crime Forecasting Challenge では、共通のデータセット (オレゴン州ポートランドにおける5年分の通報データ) を用いながら、Student 部門 (全5名)、Small Team / Business 部門 (全42チーム)、Large Business 部門 (全15チーム) に分かれて予測の正確性と効率性を競った (<https://nij.ojp.gov/funding/real-time-crime-forecasting-challenge>)。結果は、2017年に発表されている。

の手法が、主要なトピックの一つとして扱われている様子が見えてくる。

諸外国のこうした動きにあわせ、わが国でも、京都府警と NEC が、米国の市警察で実際に導入されている手法を参考に共同開発した犯罪予測システムの運用を 2016 年より開始（図 1-2）している。また、2018 年には神奈川県警が、日立製作所と人工知能を活用した犯罪・事故発生予測システムの共同開発と導入を目指して研究者らと調査研究会を立ち上げ、翌年には報告書が提出されている（図 1-3）。さらに、長野県警（図 1-4）、警視庁（図 1-5）でも地理的な犯罪予測システムの導入が検討されるなど、各都道府県の警察で地理的犯罪予測手法の導入に向けた取り組みが見られ始めている。なお、警視庁では 2017～2018 年にかけて「犯罪・交通事故・警備事象の予測における ICT 活用の在り方に関する有識者研究会」が開催されており、「犯罪抑止に向けた予測」、「交通事故に関する予測」、「警備事象に関する予測」の 3 分野に関する検討が行われている（警視庁、2018）。



図 1-2 京都府警の犯罪予測システム導入について伝える新聞記事（日本経済新聞 2017 年 1 月 7 日付）



図 1-3 神奈川県警と研究者らの犯罪予測調査研究会について伝える新聞記事（毎日新聞 2019 年 3 月 26 日付）

県警が「予測型犯罪抑止システム」導入方針 19年度予算要求

ツイート いいね! 2 シェア G+

県警は19日、過去に起きた犯罪情報を分析し、盗みや性犯罪などが起きる可能性が高い地域や時間帯を予測する「予測型犯罪抑止システム」を、2019年度に導入する方針を明らかにした。予測結果を警察官の効果的な巡回や警備につなげ、犯罪の未然防止を図るとしている。県の19年度当初予算編成で、関連経費5534万円を予算要求した。

県警によると、盗みや性犯罪などは連続して発生しやすく、1カ所で起きると、付近で一定期間内に同じような犯罪が起きる確率が高いとの理論がある。これまでは、警察官の経験に基づいて現場付近の警戒強化や張り込みなどをしてきたが、過去のデータと理論を応用することで、発生予測の精度の向上が期待できるとしている。

県警の野崎美仁警務部長は19日の取材に、市民らの防犯ボランティアにも情報を提供し、活動に生かしてもらえと説明した。

県警はこのほか、声掛け事業などの発生現場付近に、一時的に取り付ける捜査用カメラ30台分などの予算も新たに要求している。

全国では、京都府警が16年に同様の予測システムを導入しており、パトロール強化や住民への情報提供などに活用。神奈川県警は、人工知能(AI)で犯罪情報を分析して予測するシステムの研究を進め、20年の東京五輪までの実用化を目指している。

(12月20日)

図 1-4 長野県警の犯罪予測システムに関する予算要求について伝える新聞記事 (信州毎日新聞 WEB 版 2018 年 12 月 20 日付)

過去の事件情報のビッグデータや人工知能(AI)を使って犯罪が起きやすいエリアや時間帯を予測する取り組みが日本の警察で始まっている。実際に容疑者の検挙につながったケースも。警視庁は1月から、事件報に加え、子どもや女性を狙った性犯罪などの前兆とされる「声かけ」や「つきまとい」などのビッグデータも分析し、重点パトロールで犯罪抑止に乗り出す。

「声かけ」や「つきまとい」は、東京府内の声かけやつきまといなどの通報は年間7千件近くになる。昨年10月、東京都品川区で不審な男が、とこの通報から、警視庁がエリアを絞った重点パトロールの結果、同区内の公園で16歳の少女を誘拐した。誘拐などの事件では発生前に不審な前兆事象が報告されている場合が多い。警視庁の担当も、同庁は前兆事象のビッグデータを有効活用するため4月から新システムを導入する。

約6万件の前兆事象から有罪判決が表されるため、どの場所でもこのような事象が起きているかが目で分かる。速やかに情報共有できるという。警視庁の担当も、このシステムを見れば、新しい前兆事象のほかに、不審者の服装や体格、言動などの情報と一致した場合は関連性が疑われる。

「犯罪予測で子供・女性守れ」

経験頼み脱却、AI活用

警視庁は16年10月以降、約10万件の前兆データを分析し、同様の事件発生を予測される地域を重点的にパトロールする。同庁は前兆事象のビッグデータやAIを使って犯罪の発生予測にいかす試みは各地の警察で広がっている。背景には現場の警察の経験や勘に頼り、捜査からAIによるビッグデータを活用して、狙った犯人がどこへ、駐車場でアイを取り外すなどして、現場に現れ、現行犯逮捕した。

神奈川県警は18年4月、日立製作所などと連携しAIで犯罪や事故を予測する研究を始めた。10、15年に発生した事件や事故などのデータを計1000万件を基に予測し、16年の実際のデータと照合するなどの検証作業中で、20年度までのシステム導入を目指す。

全国の警察を統括する警視庁も4月以降、AI活用の実証実験を行う。AIが防犯カメラの映像などを不審者や不審物を検知したり、AIが防犯カメラの不完全な車両映像から車種を特定したりする。

犯罪予測システムの導入活用はできているが、現場は海外の警察当局が先しの経験に頼っている。警察は海外の警察当局が先しの経験に頼っている。警察は海外の警察当局が先しの経験に頼っている。警察は海外の警察当局が先しの経験に頼っている。

欧米で運用先行

犯罪予測システムの導入活用はできているが、現場は海外の警察当局が先しの経験に頼っている。警察は海外の警察当局が先しの経験に頼っている。警察は海外の警察当局が先しの経験に頼っている。

図 1-5 警視庁の犯罪予測活用検討について伝える新聞記事 (日本経済新聞 2019 年 2 月 9 日付)

1.1.2 データに基づく犯罪対策をめぐるわが国の社会状況

このような地理的犯罪予測をめぐる国内の潮流は、ICT (Information and Communication Technology: 情報通信技術)、および地理空間情報の利活用の2つの点で時宜にかなったものといえる。前者については、「超スマート社会」、およびその実現にむけた国家的取り組みである「Society 5.0」といった概念と関連づけることができる。これらを標榜する「第5期科学技術基本計画」(内閣府、2016)では、超高齢化・人口減少社会に対応するため、高度なICTの活用による生産性向上を目指しているが、予測を用いた警察活動の効率化は、こうした理念に沿うものである。また、同計画では「国家安全保障上の諸課題への対応」に必要な技術の研究開発の推進も挙げられており、地理的犯罪予測をはじめとした警察技術にも一層の投

資が期待される場所である。

後者について、わが国では地理空間情報活用推進基本法が制定された2007年以降、地理空間情報の整備や衛星測位の高度技術基盤の確立等が進められ、地理空間情報活用推進会議では「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）」がとりまとめられるなど、府省横断的に利活用の取り組みが進められてきた（内閣官房，2017）。こうした環境下で、2017年3月24日に閣議決定された地理空間情報活用推進基本計画（内閣官房，2017）では、「地理空間情報の活用推進に関する具体的施策」に「安全・安心で質の高い暮らしの実現」として、「GISの活用により、犯罪を未然に予防し、被害の拡大を防止するため、犯罪の時空間的な集積・変化の分析手法、犯罪抑止対策の評価手法、防犯活動の支援手法の開発を行うなど、事案対処手法の高度化・防犯活動の支援を促進する」ことが掲げられている。また、この施策の見通しでは、4期に分けられた計画年度（平成25年度～平成33年度）のうち、3期目にあたる平成32年度には、「ビックデータを活用した時空間分析機能の研究開発、被害リスク推定の研究開発」が計画されており（G空間情報センターの利活用推進チーム，2017）、犯罪データをはじめとした時空間情報を用いて予測を行う試みが、わが国の施策の中に位置づけられているといえよう。

日本は、国際的にみても治安水準が高く^{vi}、犯罪の認知件数も減少傾向にあり^{vii}、ほとんどの罪種において、現時点で危急の対策が求められるとは必ずしもいえない。しかしながら、一方で将来的には犯罪発生を増大させる要因も潜在している。たとえば、単身世帯の増加^{viii}はそれ自体が地域における犯罪被害発生リスクを高め（Osborn et al., 1992）、人種・民族多様性の増加^{ix}や住民組織加入率の低下^xなどは、社会解体を進行させ、治安の悪化を招く（Sampson and Groves, 1989）。こうしたわが国の社会状況を鑑みると、今後の治安情勢は必ず

vi たとえば、英雑誌「エコノミスト（Economist）」の調査部門 Economist Intelligence Unit（2019）が公表している Safe Cities Index 2019 では、世界 60 都市を「サイバーセキュリティ（Digital Security）」、「医療・健康環境の安全性（Health Security）」、「インフラの安全性（Infrastructure Security）」、「個人の安全性（Personal Security）」の計 4 つの観点から評価している。このうち、犯罪発生率や警察の関与レベル等から評価される「個人の安全性」では、東京が 4 位、大阪が 7 位となっている。なお、4 つのカテゴリの総合評価としての「総合スコア」をみると、東京は 1 位、大阪は 3 位となる。

vii わが国の刑法犯認知件数総数（自動車運転過失致死傷、危険運転致死傷等を除く）は、戦後最大となった 2002 年の 2,853,153 件から、2017 年では 915,042 件と 7 割近く減少している。罪種別にみても、刑法犯の多くを占める「窃盗」、凶悪犯としての「殺人」、「強盗」、「放火」、「強姦性交等（旧法では強姦）」は、2002 年から 2017 年にかけて、多少の増減はありつつも全体としては減少傾向にある（2002 年と比べ 2017 年では、「窃盗」は 72.4%、「殺人」は 34.1%、「強盗」は 73.5%、「放火」は 47.6%、「強姦性交等」は 52.9%、それぞれ減少）。これらの数字は、犯罪白書（法務省，2019）を参考に作成した。

viii 平成 27 年国勢調査結果（総務省統計局，2016）では、日本の単身世帯（世帯人員が 1 人の世帯）数は 2015 年時点で約 1,841 万世帯にのぼり、一般世帯数に占める割合は 2000 年から約 7%（2000 年：27.6%→2015 年：34.6%）増加している。また、国立社会保障・人口問題研究所（2018）による推計では、2040 年には単身世帯数は約 1,994 万世帯となり、一般世帯数に占める割合は 39.3%と約 4 割に達すると予想されている。

ix 平成 27 年国勢調査結果（総務省統計局，2016a）では、日本の外国人人口は 2015 年時点で約 175 万人にのぼり、全人口に占める外国人人口の割合は 2000 年から約 0.4%（2000 年：1.0%→2015 年：1.4%）増加している。

x 日本都市センター（2014）は、全国の自治体へ地域の自治組織の状況を尋ねる調査を行っている。これによると、2000 年調査時点における地縁型住民自治組織の加入率は、「9 割が加入」が 31.9%であったのに対し、2013 年調査時点では 10.9%にまで低下している。




図 1-6 地方警察官の退職状況（左），および警察官採用試験実施状況（右）

しも楽観視できるものではない。他方で、近年では警察官の大量退職期を迎えた（警察庁，2015）ことで、毎年1万人程度が退職し、経験の豊富な実務者が減少していることに加え、警察官採用試験の受験者数減少に伴い、警察力そのものが弱まっていくことが危惧される（図1-6^{xi}）。加えて、わが国では特殊詐欺のように、従前の犯罪対策では対処が難しい犯罪が増加している^{xii}状況もあり、犯罪の抑止にむけてより多様なアプローチが求められているといえよう。

他の社会情勢としては、人口減少はGDPの減少をもたらし、将来的に国家予算も縮小してゆくことが予想されるが、これに伴って、警察の予算も削減を余儀なくされるおそれもある。さらに、わが国の都市問題として指摘される「都市のスポンジ化」^{xiii}の進行により、人口が空間的に低密度に分布することで、医療・福祉、商業、行政サービス等の縮小・撤退を招き、生活利便性の低下やインフラ維持管理の非効率化等をもたらすとされる（国土交通省都市計画基本問題小委員会，2017）。中でも、都市郊外部における空き家・空き地の増加は、国土全体を低密度にする^{xiv}ことで、行政サービスとしての警察資源を、国民全体に提供することが難しく

xi 地方警察官退職者数については、平成29年警察白書WEB版（警察庁，2018），および平成28年警察白書WEB版（警察庁，2017）から、採用試験実施状況は、平成28年警察白書WEB版（警察庁，2017），および平成27年警察白書WEB版（警察庁，2016）からそれぞれダウンロードしたデータをもとに作成した。なお，2019年12月現在，退職者数は2016年まで，採用試験実施状況は2015年までのものしか公開されていない。

xii 特殊詐欺（いわゆるオレオレ詐欺，架空請求詐欺，融資保証金詐欺，還付金等詐欺からなる振り込め詐欺，および金融商品等取引名目，ギャンブル必勝法情報提供名目，異性との交際あっせん名目といった詐欺の総称）は，2003年頃からその被害が目立ち始め，2004年には認知件数が約2万5千件に達した（警察庁，2010）。その後は漸減し，2010年には約6千8百件にまで減少したものの，2011年以降また増加に転じ，2017年には約1万8千件にまで達しており，認知件数ベースでは，かつての水準に戻りつつある。なお，特殊詐欺全体の被害金額は，2004年では約283億円であったのに対し，2017年では約394億円となっており，大幅に増加している。これらの数字は，警察庁広報資料（警察庁，2019）をもとに作成した。

xiii 国土交通省都市計画基本問題小委員会（2017）では，「都市のスポンジ化」を「都市の内部において、空き地、空き家等の低未利用の空間が、小さな敷地単位で、時間的・空間的にランダム性をもって、相当程度の分量で発生する現象」としている。なお，同報告は，スポンジ化それ自体が，都市の活気の喪失，管理水準の低下から治安にも悪影響を及ぼす可能性についても指摘している。

xiv 参考までに，わが国における空き家の数（「二次的住宅」，「賃貸用又は売却用の住宅」，「その他の住宅」の合計）は，2003年では約659万戸から，2013年では約820万戸にまで増加し（総務省統計局，2016b），空き地（「屋外駐車場」，「資材置き場」を除いた「利用し

なる将来も想像できる。

以上に述べたようなわが国の状況から、限られた警察資源を適切に配分することで、警察活動の効率化を図り、防犯・治安維持対策を効果的に行っていく必要性は、今後ますます増加すると考えられる。地理的犯罪予測の技術は、これに大きく資するものと考えられる。

1.1.3 本研究の問題意識

このように、日本において警察活動への活用が期待される地理的犯罪予測であるが、これを直接取り上げながら、国内のデータを用いて分析を行った研究は、野・糸井川 (2017)、花岡 (2018) のみに限られている^{xv}。また、そこで扱われる予測手法も一部のものに限定されているため、日本においても、海外で主流となっている予測手法で予測が可能であるのか、すなわち、海外と同水準の予測精度が担保されるかは定かではない。さらに、予測が一定の水準で可能であった場合でも、どのような予測手法が日本において高い性能を発揮するのかがわからない。

これらの点をめぐって、いくつか具体的な問題が挙げられる。まず、日本と比べ、地理的犯罪予測が導入されている欧米諸国では、犯罪発生水準が日本と比べ高い水準^{xvi}にあること、大都市では比較的狭い空間範囲に人口が集積しているなど都市構造が異なること^{xvii}、あるいは人種・民族の多様性、経済格差が大きい等、社会的背景が異なることなどから、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懸念される。特に、日本が諸外国に比して犯罪発生水準が低水準であることは、手法の予測性能に大きく関わる可能性がある。1節1項で紹介した **Real-Time Crime Forecasting Challenge** では、犯罪発生が十分な水準である場合には、単純なモデルでも競争力がある一方で、犯罪発生が低頻度な場合には、洗練されたモデルでも効果的・効率的な予測ができなかったことが明らかにされている (National Institute of Justice, 2019)。また、頻度の異なる罪種間で予測手法を適用・比較した研究では、いずれも低頻度な犯罪で予測精度が低くなることが確かめられている (Giménez-Santana et al., 2018; Kocher and Leitner, 2015; Valasik, 2018)。街頭犯罪のような、地理的犯罪予測の主な対象となる

ていない(空き地・原野など)」を指す)の数は、2003年では約681 km²から、2013年では約981 km²にまで増加している(国土交通省, 2015)。

xv 本節1項で紹介した神奈川県警の研究会では、大学に所属する研究者らが関わりながら、国内のデータに地理的犯罪予測を適用し、検証を行っている貴重な事例である。しかし、本項執筆時点(2019年12月現在)では、その成果となる報告書が公開されておらず、知見が共有されていない。

xvi たとえば、平成30年版犯罪白書(法務省, 2019)では2011年から2015年の日・仏・独・英・米国間で「殺人」、「強盗」、「窃盗」、「強制性交等」の発生の多寡を比較している。全ての国の数値が比較可能な2014年(2015年は、英国が「殺人」の数値を除き非公表のため)について、10万人あたりの発生件数をみると、「殺人」では日本が0.3件のところ、仏:1.2件、独:0.9件、英:0.9件、米:4.5件、「強盗」では日本が2.4件のところ、仏:177.7件、独:55.8件、英:81.0件、米:101.6件、「窃盗」では日本が472.1件のところ、仏:2,809.4件、独:2,226.2件、英:2,932.3件、米:2,583.7件、「強制性交等」では日本が1.0件のところ、仏:18.9件、独:9.0件、英:48.8件、米:37.1件となっており、地理的犯罪予測の活用が進む欧米先進諸国と日本では、犯罪発生水準に大きな差が見られる。

xvii 国土交通省社会資本整備審議会都市計画分科会(2001)による「都市の現状と課題」では、東京都区部とニューヨーク市(マンハッタン)、パリ市とを比較した場合、前者では人口が周辺部にまで薄く広がり、都心の昼夜間人口比率が高いのに対し、後者では都市中心部の人口密度が高いことが指摘されている。

犯罪が低頻度であるわが国では、予測を適用したとしても、予測精度が極端に低いなど、有用性を欠く場合もある。こうした懸念から、諸外国で通用している多くの手法の予測性能を、日本国内で検証することが求められる。さらに、海外で生み出された予測手法に対し、社会背景や犯罪発生水準が異なるわが国では、どのような理論やデータに基づいて予測を行うべきか、という視点での検討も必要となるだろう。

一方で、どの予測手法がわが国において有効かを考える際には、既存の予測手法にどのようなものがあるかが整理された上で、それらの性能を比較し、それぞれの特長が明確になっている必要がある。しかしながら、既存の地理的犯罪予測手法をレビューしたものは、情報が古い (Groff and La Vigne, 2002; Perry et al., 2013)、一部の手法しか取り上げられていない (Fitspatrick et al., 2019; Hardyns and Rummens, 2018; Khairuddin et al., 2019; Shaerpour et al., 2013; Zhao and Tang, 2018) といった問題点がある。そのため、地理的犯罪予測研究がさかんな諸外国においてさえも、予測手法の体系的な整理がいまだ行われておらず、全体としての見通しがついていない。加えて、種々の予測手法を横並びで比較・評価した研究もいくつか見られる (Adepeju et al., 2016; Chainey et al., 2008; Drawve, 2014; Drawve et al., 2014; Hart and Zandbergen, 2012; Levine, 2008; Van Patten et al., 2009) もの、先に手法の整理がなされないまま比較が行われているため、網羅的な検討がなされておらず不十分である。このような状況が、日本に適した地理的犯罪予測手法を考える上での障害となっている。

以上から、既存の地理的犯罪予測手法を整理した上で、多様な手法を日本国内で検証することが求められる。こうした検証、および議論が不十分なまま予測システムの開発が進むことは避けるべきだろう。地理的犯罪予測システムを導入する際には、多額のコストを公的主体 (多くの場合、警察組織) が負担することになる。日本では、都道府県ごとに独立した警察組織が運営されており、本節1項で述べた通り、導入も都道府県警単位で行われているため、そのコストは基礎自治体が負う。導入の結果、予測が十分に機能しない、または犯罪削減効果がコストに見合わないといった評価が下された場合、システムの利用が中止される事態を招くだろう。たとえば、2013年にPredPolを導入したイギリスのケント警察 (予測システムを同国で初めて導入した警察) では、年間10万ユーロの契約が、2018年に打ち切られている (BBC NEWS, 2019)。こうした事態は、社会的コストが浪費されるにとどまらず、地理的犯罪予測分野の将来にわたる発展の途を閉ざすことにもつながりかねない。

このように、地理的犯罪予測手法の導入期にあるわが国においては、まず、これまでなされてきた地理的犯罪予測研究について整理し、その全体像を示すこと、その上で、既存の地理的犯罪予測手法について、手法ごとに予測性能を検証することにより、日本における地理的犯罪予測の適用可能性を評価し、どのような手法が有効であるのかを確かめる必要がある。さらに、欧米諸国と異なる社会背景をもつ、犯罪発生が低頻度であるといったことに特徴づけられる日本の状況に、よりふさわしい手法を検討してゆくことが求められるであろう。

1.2 目的

以上に述べた問題意識から、本研究では、次の研究目的を設定する。

I. 既存予測手法の体系的整理と性能評価

- 地理的犯罪予測を扱った国内外の主要な研究、およびそれらを取り上げた議論等をレビューし、手法を類型化することで、どのような考え方に基づく予測が存在するのかを整理しつつ、その長所短所を日本への適用という観点から評価する
- さらに、整理された既存手法を日本の実データに適用し、手法ごとに性能評

価を行うことで、どの種類の予測が日本で有効なのかを明らかにする

II. 既存予測手法の修正と日本への適用可能性の検証

- 研究 I で得られた知見、および日本での地理的犯罪予測の適用を考えた上で求められる要件を勘案し、既存の予測手法を日本に適合する形で修正したものを提示する
- 提案された予測手法を、財産犯罪の一つである車上狙い・部品狙い、身体犯罪の一つである痴漢、知能犯罪の一つである還付金等詐欺にそれぞれ適用し、具体的な予測モデルを作成、その予測性能を評価することで、日本における適用可能性を検証する

これらを通じて、日本のように犯罪発生が低頻度な状況に適した地理的犯罪予測手法の構築を目指す。

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、地理的犯罪予測手法に科学的な評価を与える試みであり、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。

1.3 研究の構成

上記の目的を達成するために、本研究では、次の研究内容を設定する。

- I-1. 地理的犯罪予測研究の網羅的レビュー
- I-2. 既存手法の国内の実データへの適用と予測性能評価
- II-1. 日本に適した予測手法の検討
- II-2-1. 車上狙い・部品狙いへの新手法適用（モデル作成）と予測性能評価
- II-2-2. 痴漢への新手法適用（モデル作成）と予測性能評価
- II-2-3. 還付金等詐欺への新手法適用（モデル作成）と予測性能評価

研究 I-1 では、主に欧米で行われてきた地理的犯罪予測研究に対して、網羅的なレビューを行い、研究の展開を追うとともに、既存手法について各特徴をふまえて分類するといったように、体系的な整理を行う。これにより、いまだ明らかになっていない地理的犯罪予測研究の全体像を示しつつ、日本への適用にむけて、具体的な検討を行うべき予測手法を抽出する（2章）。

研究 I-2 では、研究 I-1 の結果をふまえ、抽出された予測手法を国内の実際のデータに適用し、将来時点の犯罪をどの程度予測することができたのか等、各手法のパフォーマンスを評価する。その上で、得られた結果について理由を考察し、各手法の日本での適用可能性と限界について議論する（3章）。

研究 II-1 では、研究 I、およびさらなる理論的な検討をふまえ、既存の予測手法のよって立つアイデアや、これまで用いられてきた予測の要因を参照しながら、日本で有効な予測手法を構築する（4章）。

研究 II-2-1 では、研究 II-1 で提案された予測手法から具体的な予測モデルを作成、財産犯罪の一つである車上狙い・部品狙いに適用し、予測性能を評価する（5章）。

研究 II-2-2 では、研究 II-1 で提案された予測手法から具体的な予測モデルを作成、身体犯罪の一つである痴漢に適用し、予測性能を評価する（6章）。

研究 II-2-3 では、研究 II-1 で提案された予測手法から具体的な予測モデルを作成、知能犯罪の一つである還付金等詐欺に適用し、予測性能を評価する（7章）。

最後に、研究Ⅰ、Ⅱの結果をもとに、本研究で提案された手法の日本への適用可能性について考察する。これをもとに、わが国における今後の地理的犯罪予測研究の展望について述べる（8章）。

図 1-7 は、本研究の構成を示した模式図である。

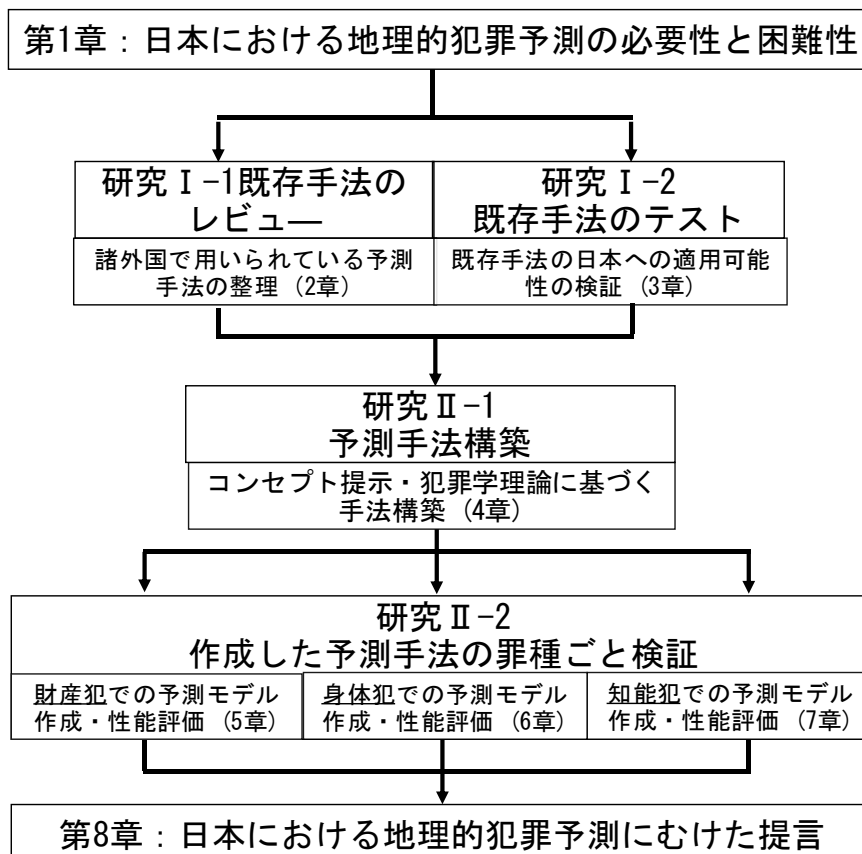


図 1-7 本研究の構成

1章の参考文献

- 1) 雨宮護 (2016) 犯罪分析と警察活動. 『犯罪心理学辞典』 (日本犯罪心理学会編), 丸善出版, 587pp.
- 2) 警察庁 (2019) 特殊詐欺認知・検挙状況等について. <<https://www.npa.go.jp/publications/statistics/sousa/sagi.html>>, 2019年12月9日閲覧
- 3) 警察庁 (2018) 平成29年版警察白書. <<https://www.npa.go.jp/hakusyo/h29/honbun/index.html>>, 2019年9月19日閲覧.
- 4) 警察庁 (2017) 平成28年版警察白書. <<https://www.npa.go.jp/hakusyo/h28/honbun/index.html>>, 2019年9月19日閲覧.
- 5) 警察庁 (2016) 平成27年版警察白書. <<https://www.npa.go.jp/hakusyo/h27/honbun/index.html>>, 2019年9月19日閲覧.
- 6) 警察庁 (2010) 平成21年版警察白書. <<https://www.npa.go.jp/hakusyo/h21/honbun/index.html>>, 2019年12月9日閲覧.
- 7) 警視庁 (2018) 犯罪・交通事象・警備事象の予測におけるICT活用の在り方に関する提言書.<https://www.keishicho.metro.tokyo.jp/kurashi/anzen/anshin/ict_teigen.files/ict_teigensyo.pdf>, 2019年9月20日閲覧.
- 8) 国土交通省社会資本整備審議会都市計画分科会 (2001) 都市の現状と課題. <https://www.mlit.go.jp/singikai/infra/city_planning/1/images/010705_08.pdf>, 2019年9月20日閲覧.
- 9) 国土交通省政策統括官 (2015) 平成25年世帯土地統計 確報集計 結果の概要. <<https://www.mlit.go.jp/common/001114771.pdf>>, 2019年10月19日閲覧.
- 10) 国土交通省都市計画問題小委員会 (2017) 都市計画基本問題小委員会 中間とりまとめ 「都市のスポンジ化」への対応. <<https://www.mlit.go.jp/common/001197384.pdf>>, 2019年9月30日閲覧.
- 11) 国立社会保障・人口問題研究所 (2018) 日本の世帯数の将来推計 (全国推計) 2018 (平成30)年推計——2015 (平成27)年～2040 (平成52)年——. <http://www.ipss.go.jp/pp-ajsetai/j/HPRJ2018/hprj2018_gaiyo_20180117.pdf>, 2019年9月30日閲覧.
- 12) G空間情報センターの利活用推進チーム (2017) G空間プロジェクト平成29年度政府予算における主要施策について. <http://www.cas.go.jp/jp/seisaku/sokuitiri/yosan/h29g_sesaku1.pdf>, 2019年9月17日閲覧.
- 13) 信濃毎日新聞 WEB版 (2018) 県警が「予測型犯罪抑止システム」導入方針 19年度予算要求, 12月20日. <<https://www.shinmai.co.jp/news/nagano/20181220/KT181219ATI090035000.php>>, 2019年9月18日閲覧.
- 14) 総務省統計局 (2016a) 平成27年国勢調査 人口等基本集計結果 結果の概要. <<https://www.stat.go.jp/data/kokusei/2015/kekka/kihon1/pdf/gaiyou1.pdf>>, 2019年9月30日閲覧.
- 15) 総務省統計局 (2016b) 日本の住宅・土地—平成25年住宅・土地統計調査の解説—結果の解説. <<https://www.stat.go.jp/data/jyutaku/2013/nihon.html>>, 2019年10月19日閲覧.
- 16) 内閣官房 (2017) 地理空間情報活用推進基本計画. <https://www.cas.go.jp/jp/seisaku/sokuitiri/290324/170324_masterplan.pdf>, 2019年9月19日閲覧.
- 17) 内閣府 (2016) 第5期科学技術基本計画. <<https://www8.cao.go.jp/cstp/kihonkeikaku/5honbun.pdf>>, 2019年9月19日閲覧.
- 18) 日本経済新聞 (2017) 犯罪 ビッグデータで防げ、京都府警がシステム／警視庁も研究、10万件を分析、地域・時間予測, 1月7日全国夕刊.
- 19) 日本経済新聞 (2019) 犯罪予測で子供・女性守れ、経験頼み脱却、AI活用、声かけ・つきまとい...警視庁が前兆分析, 2月9日全国夕刊.

- 20) 日本都市センター (2014) 地域コミュニティと行政の新しい関係づくり～全国 812 都市自治体へのアンケート調査結果と取組事例から～. <<http://www.toshi.or.jp/app-def/wp/wp-content/uploads/2014/05/report136.pdf>>, 2019 年 9 月 30 日閲覧.
- 21) 野貴泰・糸井川栄一 (2017) 犯罪多発地点の予測に基づく防犯パトロール経路に関する提案. 「地域安全学会論文集」, **31**, 195-204.
- 22) 花岡和聖 (2018) 大阪府における不審者遭遇情報の地理的分布: Risk Terrain Model を用いた犯罪リスクのマッピング. 「立命館文学」, **656**, 47-59.
- 23) 法務省 (2019) 平成 30 年版犯罪白書. <<http://hakusyo1.moj.go.jp/jp/65/nfm/mokuji.html>>, 2019 年 9 月 30 日閲覧.
- 24) 毎日新聞 (2019) AI で犯罪予測、教授らが報告, 3 月 26 日地方版.
- 25) 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*, **30**(11), 2133-2154.
- 26) BBC NEWS (2018) Kent Police stop using crime predicting software. <<https://www.bbc.com/news/uk-england-kent-46345717>>, 2019 年 9 月 20 日閲覧.
- 27) Camacho-Collados, M., and Liberatore, F. (2015) A decision support system for predictive police patrolling. *Decision Support Systems*, **75**, 25-37.
- 28) CEAMOS (2018) The rise of predictive policing: The experience of Baltimore, Chicago and Chile. <<http://ceamos.cl/wp/?p=1344>>, 2019 年 10 月 3 日閲覧.
- 29) 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.
- 30) Drawve, G. (2016) A metric comparison of predictive hot spot techniques and RTM. *Justice Quarterly*, **33**(3), 369-397.
- 31) Drawve, G., Moak, S., and Berthelot, E. (2016) Predictability of gun crimes: A comparison of hot spot and risk terrain modelling techniques. *Policing and Society*, **26**(3), 312-331.
- 32) Economist Intelligence Unit (2019) Safety Cities Index 2019. <<https://safecities.economist.com/wp-content/uploads/2019/08/Aug-5-ENG-NEC-Safe-Cities-2019-270x210-19-screen.pdf>>, 2019 年 9 月 19 日閲覧.
- 33) Farrell, G., and Sousa, W. (2001) Repeat victimization and hot spots: the overlap and its implications for crime control and problem-orientated policing. *Crime Prevention Studies*, **12**, 221-240.
- 34) Fitzpatrick, D., Gorr, W., and Neill, D. (2019) Keeping Score: Predictive Analytics in Policing. *Annual Review of Criminology*, **2**, 473-491.
- 35) Flandersnews.be (2018) Police to use algorithms to predict crime. <<https://www.vrt.be/vrtnws/en/2018/08/30/police-to-use-algorithms-to-predict-crime/>>, 2019 年 9 月 19 日閲覧.
- 36) Giménez-Santana, A., Caplan, J., and Drawve, G. (2018) Risk terrain modeling and socio-economic stratification: identifying risky places for violent crime victimization in Bogotá, Colombia. *European Journal on Criminal Policy and Research*, **24**(4), 417-431.
- 37) Government Technology Magazine (2016) The Role of Data Analytics in Predictive Policing. <<https://www.govtech.com/data/Role-of-Data-Analytics-in-Predictive-Policing.html>>, 2019 年 9 月 19 日閲覧.
- 38) Groff, E., and La Vigne, N. (2002) Forecasting the future of predictive crime mapping. *Crime Prevention Studies*, **13**, 29-58.

- 39) Hardyns, W., and Rummens, A. (2018) Predictive policing as a new tool for law enforcement? Recent developments and challenges. *European Journal on Criminal Policy and Research*, **24**(3), 201-218.
- 40) Hart, T. and Zandbergen, P. (2012) *Effects of data quality on predictive hotspot mapping: final technical report*. Washington, D.C.: National Institute of Justice, 1-79pp.
- 41) Khairuddin, A., Alwee, R., and Haron, H. (2019) A review on applied statistical and artificial intelligence techniques in crime forecasting. In *IOP Conference Series: Materials Science and Engineering*, **551**(1), <<https://iopscience.iop.org/article/10.1088/1757-899X/551/1/012030/pdf>>, 2019年9月30日閲覧.
- 42) Kocher, M., and Leitner, M. (2015) Forecasting of crime events applying risk terrain modeling. *GI Forum—Journal of Geographic Information*, **1**, 30-40.
- 43) Levine, N. (2008) The "hottest" part of a hotspot: comments on "the utility of hotspot mapping for predicting spatial patterns of crime". *Security Journal*, **21**(4), 295-302.
- 44) National Institute of Justice (2019) From Crime Mapping to Crime Forecasting: The Evolution of Place-Based Policing. <<https://nij.ojp.gov/topics/articles/crime-mapping-crime-forecasting-evolution-place-based-policing>>, 2019年9月19日閲覧.
- 45) National Institute of Justice (2012) Predictive Policing Symposiums. <<https://www.ncjrs.gov/pdffiles1/nij/242222and248891.pdf>>, 2019年9月19日閲覧.
- 46) Osborn, D., Trickett, A., and Elder, R. (1992) Area characteristics and regional variates as determinants of area property crime levels. *Journal of quantitative criminology*, **8**(3), 265-285.
- 47) Perry, W., McInnis, B., Price, C., Smith, S., and Hollywood, J. (2013) *Predictive policing: The role of crime forecasting in law enforcement operations.*, Rockville: NCJRS Photocopy Services, xiv pp.
- 48) Sampson, R., and Groves, W. (1989) Community structure and crime: Testing social-disorganization theory. *American Journal of Sociology*, **94**(4), 774-802.
- 49) Shaerpour, K., Dehghantaha, A., and Mahmood, R. (2013) A Survey on Cyber-Crime Prediction Techniques. *International Journal of Advancements in Computing Technology*, **5**(14), 52-61.
- 50) Uchida, C. (2009) A national discussion on predictive policing: Defining our terms and mapping successful implementation strategies. <<https://www.ncjrs.gov/pdffiles1/nij/grants/230404.pdf>>, 2019年9月19日閲覧.
- 51) Valasik, M. (2018) Gang violence predictability: Using risk terrain modeling to study gang homicides and gang assaults in East Los Angeles. *Journal of Criminal Justice*, **58**, 10-21.
- 52) Van Patten, I. T., McKeldin-Coner, J., and Cox, D. (2009) A microspatial analysis of robbery: prospective hot spotting in a small city. *Crime Mapping: A Journal of Research and Practice*, **1**(1), 7-32.
- 53) Zhao, X., and Tang, J. (2018) Crime in Urban Areas: A Data Mining Perspective. *ACM SIGKDD Explorations Newsletter*, **20**(1), 1-12.

第2章 既存の地理的犯罪予測研究の整理

2.1 はじめに

本章では、日本における地理的犯罪予測のあり方を探るために、既存研究の全体像と、主に欧米諸国における実社会への適用状況について述べる。そのために、レビューを行うにあたり、どのように資料を収集したかについて述べ（第2節）、地理的犯罪予測研究の基礎となった研究、また、社会的な動きにふれる（第3節）。次に、現在発展している地理的犯罪予測研究をアプローチの違いに着目して、いくつかの系統に分類し、それぞれの特徴を示し（第4節）、どのような予測システムとして実装されているのかを紹介する。最後に、ここまでの整理から、日本での適用に際しての各手法の長短について議論する。

2.2 資料収集の方法

資料の収集にあたっては、Web of Scienceⁱ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トピック検索を行った上で、アブストラクトを参照し、これをもとにテーマに沿う文献を抽出した。また、各文献を調べる中で、それらに引用されている関連性の高い文献にもあたり、網羅的なレビューとなるよう配慮した。結果として、対象となった文献の総数は、203件となった。主要な研究を選ぶにあたって、Fitspatrick et al. (2019), Groff and La Vigne (2002), Hardyns and Rummens (2018), Khairuddin et al. (2019), Perry et al. (2013), Shaerpour et al. (2013), Zhao and Tang (2018)といった既存のレビュー文献も一部参考にした。

本研究で対象とする地理的犯罪予測とは、ある狭い領域内における、将来の犯罪発生リスク、すなわち、将来時点での犯罪発生空間的なばらつき¹の度合いについて、過去時点の情報から説明・予測するものである。予測対象となる地理的領域のサイズは、国や州といった大きな単位ではなく、ひとつの都市（市、あるいは市域）の中の区画（国勢調査区やブロック、仮想のグリッドセル等）単位で、時間的には、月・週・日、またはそれ以下の時間的範囲で将来発生する犯罪を予測する（時間的に外挿を行う）。また、ここで取り上げる地理的犯罪予測研究とは、将来時点における犯罪発生²の蓋然性を予測、その結果を実際のデータと比較・評価を行っているものを指し、さらに、予測結果を犯罪予防の活動に利用することを想定しているものとする。過去の犯罪データの記述的分析や、犯罪発生と関連する要因の探索にとどまるものは、予測研究として扱わない。

i トムソン・ロイター社の提供する文献検索データベースであり、自然科学、社会科学、人文科学分野の論文誌が網羅されている。複数の異なるデータリソースから検索可能で、世界最大規模のカバー率となっている。（<http://ip-science.thomsonreuters.jp/products/web-of-science/>：最終閲覧日 2016年7月18日）




図 2-1 キーワード検索結果, および背景にある研究・社会的動向

2.3 地理的犯罪予測研究の源流

2.3.1 犯罪予測研究の背景

ここでは、犯罪の予測を扱った研究が、いつ頃発生し、その後どのように展開したかについて概観する。

犯罪予測には、英語圏では通常、“crime prediction”, あるいは“crime forecasting”といった語が用いられる。実証的犯罪学研究の分野において、これらのキーワードが登場し始めるのは、1970年代終わりから、80年代初頭にかけてのことである。図 2-1 には、Web of Science のトピック検索を用いて、“犯罪”と“予測”, すなわち、“crime” & “forecast”, もしくは“crime” & “predict” を含む文献がヒットした件数と、すべての分野における“予測”をキーワードに含む文献数として、“forecast”, もしくは“predict”を含むものの件数を示したⁱⁱ。また同時に、当時の欧米における犯罪に関連する研究の動向や、社会的動向についても示している。

図からは、1970-1980年では累計2件、1981-1990年では9件であるのに対し、1991-1999年

ii 実際には、“crime” & “forecast”, もしくは“crime” & “predict”の両者に該当するものが存在するため、“crime” & “forecast” & “predict”についても検索し、ヒットした件数を重複分として除いた数を用いた。

では 288 件と、特に 90 年代に入ってから研究が加速していった様子がみてとれる。さらに 2000 年代前半には、年に 100 前後の研究例がコンスタントに見られるようになり、2009 年以降は 200 件を超えるオーダーで推移している。

犯罪学分野で予測が取り上げられるより少し前、1970 年代初頭には、Jeffery (1971) の「環境デザインによる犯罪予防 (CPTED, Crime Prevention Through Environmental Design)」, Newman (1972) の「守りやすい空間 (defensible space)」といった理論が台頭し、犯罪者個人とその発達環境に目を向けた犯罪原因論的アプローチから、犯罪の発生する場所や状況がもつ脆弱性へ着目し、犯罪抑止につなげようとする犯罪機会論の考え方へシフトする動きが見られた。また、70 年代終わりから 80 年代前半にかけては、Cohen and Felson (1979) による日常活動理論 (Routine Activity Theory) ⁱⁱⁱや、Brantingham and Brantingham (1984) による犯罪パターン理論 (Crime Pattern Theory) ^{iv}といった生活空間の中で犯罪行動を位置づけるモデルが生まれ、環境と犯罪行動に関する研究の嚆矢となった。Perry et al. (2013) は、地理的犯罪予測を可能にする理論的基礎として、これら日常活動理論、犯罪パターン理論、さらに合理的選択理論^vを挙げている。

社会的な動向が、予測研究に与えた影響も大きい。90 年代に入ると、米国では全国的な犯罪の増加に伴い、ニューヨーク市で割れ窓警察活動^{vi}やコムスタット (Compstat: 後述) のような革新的な警察活動が取り入れられるなど、犯罪抑止の機運が高まっていた。また、2000 年代には、ニューヨーク市でのテロ事件に端を発して、各国においても犯罪への警戒姿勢が強まっていた。こうした社会的な要請が、折々で研究を推し進める一因となっていると考えられる。

以降では、地理的犯罪予測研究が成立する流れについて、その基礎となるような犯罪分析研究の流れ、および研究を押し進める契機となった実務や社会の動向について述べる。

2.3.2 犯罪の時間的变化に着目した研究

ここでは、地理的犯罪予測研究にいたる萌芽として、都市における犯罪の時系列変化に関する定量的分析研究について紹介する。初期の代表的な研究としては、Cohen et al. (1980) が、1973-1977 年の全米における強盗、侵入盗、自動車盗それぞれの犯罪発生率 (発生件数を人口で除したもの、以下同様) に関して、時系列での予測を行ったものが挙げられる。ここでは、

iii 日常活動理論 (Routine Activity Theory) では、犯罪の発生する時空間が、動機づけられた犯行者 (motivated offenders)、適当な犯行対象 (suitable targets)、有能な守り手の不在

(absence of capable guardians) の 3 つの要素を備えていると説明される。また、これらの要素が同時に揃うことを阻止することで、犯罪を防ぐことができると主張する。

iv 犯罪パターン理論 (Crime Pattern Theory) では、犯罪を行いうる者が、日常的な活動空間や人間関係における行動パターンの中で、犯行の機会を見出すことで犯罪が発生すると説明する (Brantingham and Brantingham, 1993)。

v 合理的選択理論は、Cornish and Clarke (1986) の中で論じられたもので、犯罪行動は合目的性と合理性を備えており、他の人間行動と同様に、行動の結果生じうる利得と損失を勘案して行われる、とするものである。それゆえに、状況を変化させることで、その意思決定を変容させることができ、犯罪に必要な労力を増す、リスクを高める、見返りを減らす、弁明の余地をなくす、挑発や誘惑を減らすといった状況的な介入に論拠を提供する (コーニッシュ・クラーク, 2010)。

vi 割れ窓警察活動は、Wilson and Kelling (1982) による言説をもとに、落書き等の秩序違反や軽犯罪の取り締まりを強化することで、より重大な犯罪の発生を防ごうとするもので、1990 年代のニューヨーク市の地下鉄や街頭で実施され、同市での犯罪削減に貢献したとされる (ウェイジャーズら, 2010)。

1947-1972年のデータがトレーニングデータとして用いられ、前年における同罪種の犯罪発生率のほか、失業率や若年者（15-24歳）人口比率が予測変数として採用され、自己回帰モデルによる推定が行われている。

同種の予測の例は、1990年代にも多く見られる（Deadman and Pyle, 1997; Dhiri et al., 1999; Eckberg, 1995; Powers et al., 1993; Rattner, 1990）が、当初の予測研究は、年ごとの国全土における犯罪発生といった、時間的・空間的に解像度の粗い時系列的な分析であり、また、領域内での短期的な空間変動（すなわち、時間的変動と空間的変動の交互作用）を考慮するものではなかった。このことから、この時期の予測研究は、時間的変化を扱う点において、後続の地理的犯罪予測研究の起源の一つであるといえるものの、より短期間、狭域での犯罪の空間変動を扱う後続の研究とは一線を画すものであった。

なお、犯罪の定量的分析研究における、このような予測を志向する動きの背景には、計量経済学等、他学術分野などからの影響があると考えられる。特に、1982年に開催されたMakridakis Competition^{vii}を契機として、多くの学術分野で、時系列での予測手法に対する関心が高まっていった。犯罪学もその例にもれず、これらの手法を取り入れていったと考えられる。

2.3.3 犯罪のホットスポットの発見、および技術の発達

一方、環境犯罪学、および地理的な犯罪分析研究における最も重要なアイデアの一つである犯罪のホットスポット（crime hot spots, 以下、単にホットスポット）に関する研究も、今日の地理的犯罪予測研究の重要な起源である。

ホットスポットは、犯罪が地理的に集積するエリアを指すが、実際に、ある市における警察への通報のうち約50%が、全住所のうちの3%程度にすぎない場所でなされる、といったことが起こる（Sherman et al., 1989）。ホットスポットは、過去の一定期間に犯罪が集中した領域であるが、Sherman自身がホットスポットを「犯罪が頻繁に発生するために、少なくともむこう1年において、犯罪発生が予想される狭い領域」（Sherman, 1995）と定義している通り、このような場所は、犯罪に対する脆弱性を備えているとされ、それゆえに、ホットスポットの同定は、将来の犯罪発生を予測する上でも有用であると考えられる。

こうしたホットスポットを分析する上で、犯罪発生の分布状況を地図上に可視化するクライムマッピング（crime mapping）が欠かせない。特に、犯罪のホットスポット分析では、点分布から平滑化された密度推定値を算出し、連続面を表現するカーネル密度推定（Kernel Density Estimation, 以下KDE）がよく用いられるが、GISソフトウェアの発達により、こうした技法の実行も、比較的容易に可能となっていった。

このように、ホットスポットの検出が技術的に可能になったことと、ホットスポットに関する理論・分析研究が、地理的犯罪予測研究の基礎となったといえる。

なお、KDEは、単一時点における点分布から、犯罪リスクの分布状況を可視化する手法であり、予測よりは現象の記述に近い方法といえるが、既に述べたようにホットスポット自体が、将来の犯罪発生を予測しうると考えられていることから、Chainey et al. (2008)では、地理的犯罪予測手法の一つとして検証されている。また、後述するように、地理的犯罪予測手法は、KDEを応用したものが多く、この分析手法もまた、地理的犯罪予測研究の重要な起源といえる。

vii Makridakis Competitionは、予測学者のSpylos Makridakisが主催するもので、様々な分野における予測手法を諸データに対して適用し、その結果の比較・評価を行う。これまでに1982年（M-Competition）、1993年（M2-Competition）、2000年（M3-Competition）、2018年（M4-Competition）の4回にわたり開催されている（<https://forecasters.org/resources/time-series-data/>：最終閲覧日2019年10月4日）。

2.3.4 実務、および社会の動向

地理的犯罪予測研究の発展には、警察実務における動向も大きく関わっている。Gorr and Harries (2003) は、犯罪予測は、ホットスポットに関する理論のような、場所と犯罪を結び付けた着想に加え、90年代の米国において、警察がGISソフトウェアを日常的に使用するようになったことで初めて意味をもつようになったと述べている。

警察によるGIS利用の最も著名な例は、当時ニューヨーク市で、割れ窓警察活動とともに取り入れられたコムスタットであろう。この会議体では、犯罪データを週単位で集計・分析して地図上に可視化、週2回の全体ミーティングで情報を共有し、集中的介入対象地区の選定や、戦略の立案を行うといった取り組みがなされた。犯罪に関する情報と、GISを組み合わせたデータ駆動型の警察活動は、後続の地理的犯罪予測と、そうした予測に基づく警察活動(Predictive Policing, 以下、予測型警察活動)の土壌となった。

Ferguson (2017) は、コムスタットから予測型警察活動まで、こうしたデータ駆動型の警察活動を推し進めた三つの要因を挙げている。一つ目は、警察幹部が犯罪学者、社会学者、法学者などの専門的な研究者に自ら呼びかけ、連携したことである。これにより、学術分野における諸理論や技術が研究環境から実践へと発展を遂げたとしている。二つ目は、連邦政府がデータ駆動型技術の研究、実践に対して、司法省の司法支援局(Bureau of Justice Assistance)や、NIJを通して助成金を与えたことである。これにより、地域警察署が技術を試すことが可能となっただけでなく、民間企業による開発も間接的に促進されることになり、イノベーションが進んだという。三つ目は、技術の進歩であり、特にビッグデータの収集や利用が可能となったことである。新たな技術や手段が、警察の仕事を容易に、効率的に変えるということから、その潜在的可能性に警察幹部や現場の警察官が関心を寄せたことで、データ駆動型の未来に対する信仰(faith)に拍車がかかったとしている。

Ferguson (2017) は、さらにこれらの背景に、米警察と市民との間の(特に、警察による過度な暴力、差別的慣行、違法な職務質問や逮捕に起因する)緊張関係、汚職等の警察の組織的な問題や、それにまつわるスキャンダル、警察予算の削減による財政的制約と人員不足、過大な業務負荷といった問題があったと述べている。データ駆動型の新技術は、これらの解決策として警察組織に受け止められたという。予測型警察活動を推し進めた中心人物として名が挙げられるWilliam Bratton (Ferguson, 2017; National Institute of Justice, 2019; Perry et al., 2013) は、1990年代にニューヨーク市警の警察本部長(police commissioner)として、割れ窓警察活動やコムスタットの導入を行った人物でもあるが、2002年にロサンゼルス市警の警察長(police chief)に就任した際と、2013年にニューヨーク市警の警察本部長に再度就任した際、やはりデータ駆動型の警察活動を取り入れた。このとき、それぞれの警察組織は、汚職の疑いや、職務質問・所持品検査の慣行に対する違憲判決などで、地域社会やメディアからの批判に晒されていたが、新たな技術が古い警察慣行の代替策として受け入れられたという(Ferguson, 2017)。

なお、Bratton は、2008年には司法支援局やNIJと協力して、予測型警察活動の新しいコンセプトとその含意を探りながら、研究者、実務家、行政官、法執行機関のリーダーたちを2回にわたる予測型警察活動シンポジウム(1章1節1項参照)に召集する(Perry et al., 2013)など、予測型警察活動の普及に尽力している。また、2009年には、NIJがボストン、シカゴ、ロサンゼルス、ワシントンD.C.、ニューヨーク、主リーブポート、およびメリーランド州の警察機関での予測型警察活動のモデル作成に、2011年にはランド研究所のシカゴ、シュリーブポート警察での予測型警察活動の実証実験に、それぞれ助成を行っている。これらの連邦政府機関、警察機関での動向が、予測型警察活動とその基礎技術としての地理的犯罪予測手法

の研究に与えた影響は大きい。

2.4 主要な地理的犯罪予測手法の整理と概観

2.4.1 地理的犯罪予測研究の特徴

犯罪のリスクは、空間だけでなく時間的な異質性をも備えている (Felson and Poulsen, 2003). あるいは、時間とともにリスクが空間的に伝播しうる (Cohen and Tita, 1999). また、ホットスポット自体も比較的短期的に出現・消失するものが存在する (Ratcliffe, 2004; Townsley, 2008; Gorr and Lee, 2012). 地理的犯罪予測の手法が、従来の記述的な犯罪分析と異なっている点は、その対象とする時間的・空間的範囲が詳細化されているだけでなく、犯罪リスクの空間的な広がりと同時に、その中での時間的なばらつき (特に比較的短期における変化のパターン) が考慮されていることにある。前節で述べたように、研究の潮流としては、犯罪の時系列的な変化の予測研究と、空間的なホットスポットに関する研究の両者が起源となって、犯罪の空間的な異質性を考慮しながら、時間的な変化を予測しようとする研究へとつながっていったと考えられる。

2.4.2 アプローチの違いによる整理

以降では、現在発展している地理的犯罪予測の手法について、以下の視点に基づいて分類した結果と、具体的な研究例を示す。視点については、①それぞれの手法が適用対象としている罪種、②予測に用いる変数、③統計的モデル、④予測する際の空間的解像度、予測される時間の範囲である。ただし、④については、あくまで当該研究において採用された期間であり、手法ごとに適切な時間範囲が定められているわけではない。また、「実装」は、その研究で提示された方法論をもとに開発されたシステムを指すが、実用化にあたって手法がカスタマイズされている可能性があり、研究での方法論と、実装時の方法論は必ずしも一致するものではない。

結果として、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、i. 時空間クラスタの検出、ii. 犯罪の時空間相互作用を考慮した犯罪発生の強度推定、iii. 犯罪生成・誘引要因からの犯罪発生リスクの予測、iv. 多様な情報からの犯罪発生リスクの予測、v. 地区単位での犯罪発生件数、または確率の時系列予測、vi. 環境要因と犯罪の時空間相互作用を組み合わせた犯罪発生リスクの予測の6つに整理することができた (表 2-1)。このうち、i および ii は、主に犯罪発生のデータのみに依拠した手法であり、iii は、主に犯罪関連要因を予測に用いる手法、iv および v は、犯罪発生のデータと犯罪関連要因を組み合わせる手法、そして vi は、i ~ v までを積極的に統合することを試みる手法といえる。これらは、単一の系統から枝分かれしたものというよりは、それぞれが独自の発展を遂げ、現在に至っている。

次項以降では、各分類に属する研究について、各手法の基本的な考え方や、その拠って立つ理論を概観しつつ、特に重要と考えられる業績をみてゆく。

表 2-1 (1) 地理的犯罪予測手法の分類, および主要な研究例 (1)

分類	具体的な研究例							
	タイトル	著者	罪種	予測変数	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	Detecting and Preventing Emerging Epidemics of Crime	Neill and Gorr (2007)	暴力犯罪	前兆事案	時空間 スキヤン 統計量	1000フィート (約300 m) 四方 グリッドセル	1週間	CrimeScan
	Microscale Prediction of Near-Future Crime Concentrations with Street-Level Geosurveillance	Shiode and Shiode (2015)	薬物事犯	過去の犯罪発生		街路300フィート (約90 m) 長	1カ月	-
犯罪の時空間 的相互作用を 考慮した 犯罪発生強度 推定	Prospective Hot-Spotting: The Future of Crime Mapping?	Bowers <i>et al.</i> (2004)	侵入盗	過去の犯罪発生データ	オリジナル の関数 による	50 m四方 グリッドセル	2日/7日	ProMap
	Self-Exciting Point Process Modeling of Crime	Mohler <i>et al.</i> (2011)	住宅侵入盗	過去の犯罪発生データ	Self-Exciting Point Process	200 m四方 グリッドセル	8週/39週	PredPol
犯罪生成・誘因 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 <i>et al.</i> (2011)	発砲事件 布	・ギャングの住居の分布 ・バー、酒店等の店舗の分 布 ・薬物事犯による逮捕地点 の分布	・カーネル 関数 ・オーバー レイ解析	100フィート (約30 m) 四方 グリッドセル	6カ月	RTM
	Risk Terrain Modeling: Crime Prediction and Risk Reduction	Caplan <i>et al.</i> (2016)	強盗, 暴 行, 武器所 持・使用	物理的環境要因	・Elastic Net ・ポアソン /負の二項 回帰	462フィート (約 140 m) 四方グ リッドセル	1カ月	RTMDx

表 2-1 (2) 地理的犯罪予測手法の分類, および主要な研究例 (2)

分類	具体的な研究例							
	タイトル	著者	罪種	予測変数	モデル	分析単位 (空間)	予測される時間の範囲	実装
多様な情報からの犯罪発生リスクの予測	The Spatio-Temporal Modeling for Criminal Incidents	Wang and Brown (2012)	住居侵入	<ul style="list-style-type: none"> ・ 地区の物理的、社会経済的要因 ・ 直近で犯罪が発生した日からのインターバル 	一般化加法モデル	32 m四方グリッドセル	1カ月	WebCAT
	Modeling Temporal-Spatial Correlations for Crime Prediction	Zhao and Tang (2017)	罪種不明	<ul style="list-style-type: none"> ・ 公共セキュリティ情報 ・ 気象情報 ・ 流動人口情報 ・ Point of Interests ・ 公共サービスへの不満情報 	オリジナルの関数による	2 km四方グリッドセル	1日/7日	-
地区単位での犯罪発生件数, または確率の時系列予測	Using Temporal Indicator Functions with Generalized Linear Models for Spatial-Temporal Event Prediction	Fox and Brown (2012)	暴行	<ul style="list-style-type: none"> ・ 社会経済的要因 ・ 当該地区, 隣接地区の前期の犯罪発生 	ロジスティック回帰	国勢調査区	1日	-
	Forecasting intentional wildfires using temporal and spatiotemporal autocorrelations	Prestemon <i>et al.</i> (2012)	放火	<ul style="list-style-type: none"> ・ 社会経済的要因 ・ 過去の犯罪発生 	混合モデル	国勢調査集計地区	1年	-
環境要因と犯罪の時空間相互作用を組み合わせた予測	Predictive modeling combining short and long - term crime risk potential : Final report	Ratcliffe <i>et al.</i> (2016)	暴行	<ul style="list-style-type: none"> ・ 地区の社会経済的要因 ・ 近接反復被害 	<ul style="list-style-type: none"> ・ 負の二項回帰 ・ Knox Test 	100フィート (約30 m) 四方グリッドセル	1日	PROVE
	Self-exciting point processes with spatial covariates : modeling the dynamics of crime	Reinhart and Greenhouse (2017)	財産犯罪	<ul style="list-style-type: none"> ・ 地区の社会経済的要因 ・ 同罪種 (近接反復被害), 異罪種のリスク波及効果 	Self Exciting Point Process	国勢調査区	1カ月	-

2.4.3 時空間クラスタの検出

既に述べたように、過去の犯罪の集積は、将来の犯罪発生における高い蓋然性を予想させる。そのために、犯罪発生地点のローカルなクラスタをみつけ出すことが、地理的犯罪予測分野でも一つの関心事であった。このために、単なる密度推定値を求める KDE とは異なり、統計的な基準を設けて、閾値以上の集積をクラスタとして検出する技法が用いられた。こうした手法の多くは、疫学分野において疾病の集積地域を発見する目的で考案され、発展してきた手法であり、犯罪学に限らず、地理学や生態学等、さまざまな分野で用いられている。

犯罪分析で用いられてきた手法として代表的なものとしては、STAC (Spatio-Temporal Analysis of Crime : Monmonier, 1997) がある。この手法は、対象地域に、円状の走査領域をもうけ、中心をずらしながら円領域内の犯罪発生率を検定していくものである。同手法は、犯罪分析ソフトウェアの CrimeStat^{viii}に実装されていることもあり、これを用いた予測研究もいくつも見られる (Drawve, 2016; Hart and Zandbergen, 2012; Levine, 2008; Polat, 2007; Van Patten et al., 2009)。

しかしながらこの手法は、非独立な統計的検定を複数回繰り返すことで、第一種の過誤の確率が増大する多重検定の問題を指摘されており、現在は、Kulldorff (1997) の空間スキャン統計量、さらに走査する領域を時間の次元に拡張した時空間スキャン統計量 (Space-Time Scan Statistics, 以下, STSS : Kulldorff et al., 1998) が多く用いられている。適用例としては、犯罪の前兆事案 (Crime Leading Indicator, あるいは単に Leading Indicator^{ix}) の時空間クラスタを求め、ターゲットとなる暴力犯罪のクラスタをどの程度予測できるかを検証したもの (Neill and Gorr, 2007)、テロ (Gao et al., 2013) や、象の密猟 (Rashidi et al., 2015) の集積検出に適用したものがあ^x。

現在では、この手法の予測としての面をさらに強めるために、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を、新たに出現した時空間的集積 (emerging cluster) として、継続した警戒が必要な存在であるとし、これを検出する時空間的スキャン統計量、すなわち、予見的な時空間スキャン統計量 (Prospective Space-Time Scan Statistic, 以下, PSTSS) が用いられている (Cheng and Adepeju, 2013; Adepeju et al., 2016)。また、Shiode and Shiode (2014) は、予見的スキャン統計量について、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、街路レベルでのより精緻な予見的クラスタ検出を図っている^{xi}。

さらに、スキャン統計量では、尤度比に基づく統計量が最大のものを最尤クラスタ (Most Likely Cluster) とするが、Veloso et al. (2016) では点過程を用いた Assunção and Correa (2009) の手法を改良することにより、多重検定の問題を回避しつつ、2 番目以降の有意な集積を同時に検出するための簡便な方法として、MAD-STEC (Multiple Automatic Detection of Space-Time Emerging Cluster) を提案している。彼らは、ブラジルのベロ・オリゾンテでの路上強盗のデ

viii CrimeStat は、米国テキサス州の政策系シンクタンク、NED LEVINE & ASSOCIATES

が、NIJ から資金提供を受けて開発した空間的犯罪分析のためのソフトウェアである。

ix 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。

x なお、予測を目的としたものではないが、日本国内でも、Nakaya and Yano (2010) が STSS を京都市で発生したひったくりに適用し、時空間的集積を検出している。

xi ここまでに紹介した STSS、および PSTSS は Kulldorff 自身が開発した SatScan というフリーソフトにより実行可能である。ホームページ <https://www.satscan.org/> で公開されており、2019 年 10 月 1 日時点で Ver. 9.6 が最新となっている。

ータを用いた検証により、PSTSS と比べて MAD-STEAC がより高い精度を得ることを示している。

このように、疫学分野から発展したクラスタ検出の手法は、地理的犯罪予測研究に活用されており、空間統計・空間疫学を専門とする者が加わりながら、あるいは犯罪学者と協働して研究が進展している。

2.4.4 犯罪の時空間相互作用を考慮した犯罪発生の強度推定

侵入盗をはじめとした一部の犯罪には、同一対象に繰り返し発生する反復被害 (repeat victimization : Farrell and Pease, 1993), また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) が見られることが知られている。たとえば、住宅侵入盗の発生後、少なくともむこう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り、距離が離れる、もしくは時間が経過することでそのリスクは減衰するという (Johnson et al., 2007)。また、時間の経過とともに減衰するリスクの絶対量は、距離の隔たり具合によって変動する (Bowers and Johnson, 2004) が、これは時空間相互作用 (space-time interaction) などと呼ばれる。

Bowers et al. (2004), Johnson et al. (2007), Johnson et al. (2009) は、この近接反復被害に着目し、侵入盗の将来的なリスクについて、事象間の空間的近接性ととも、時間的近接性を反映したモデリングを行うことで推定を行った。基本的なアイデアは、KDE と同様で、一定のバンド幅をもつカーネルを想定するが、基準点からの空間的隔たりに加え、予測対象とする期間との時間的な隔たりが考慮されている。同モデルで作成された強度 (risk intensity value : 単位時間・空間あたりの犯罪発生頻度の期待値) 分布図は、予見的マッピング (Prospective Mapping, あるいは ProMap と呼称される、以下 ProMap で統一) と呼ばれ、単純な KDE によるクライムマップ (crime map) と比較した際の予測精度の高さが示されている。この手法は、犯罪の空間的情報のみを用いるホットスポット分析に対し、時間的情報を加味することを提案した最初の手法であり、しかも 2004 年という早い時期に提案された手法でありながら、犯罪事象間の時空間相互作用をシンプルにモデル化したという点で画期的であった。その後、Johnson et al. (2009) では、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も考案され、犯罪以外の環境的要素を予測に取り入れる試みもなされている。

なお、ProMap は、時空間上の点分布の密度推定であり、KDE の応用とみなせるが、KDE 自体を時間軸上に拡張した時空間 KDE (中川ら, 2018; Hu et al., 2018) や、道路ネットワーク上での時空間 KDE (Network-Time KDE : Rosser et al., 2016) を犯罪予測に適用した例も存在する。

また、ProMap と同様に、近接反復被害に着目しつつ、確率点過程を用いてこれをモデリングする手法も生まれた。Mohler et al. (2011) の Self-Exciting Point Process (以下 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時空間 ETAS モデル (Ogata, 1998) を参考にして定式化を試みたものである。時空間 ETAS モデルでは、常時地震活動 (background activity) と呼ばれる、いわば平時における地震活動と、別の地震によって誘起される余震 (aftershock activity) を想定する。彼らは、前者を平時における犯罪発生の強度、後者を 1 件の犯罪が惹起する近接反復被害になぞらえ、それぞれを背景強度 (background intensity), 誘発関数 (triggering function) として組み合わせることで、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確率が減衰するモデルを構築した。同研究では、ProMap との予測結果の比較も行われており、SEPP モデルの優位性が示されている。このモデルはさらに、誘発関数から異方性を取り除いたもの (Rosser and Cheng, 2016), 誘発関数を偏微分方

程式の逆演算子（グリーン関数）として、犯罪発生データからこれを求めるもの（Kajita and Kajita, 2017）など、改良を試みる研究も見られる。Mohler 自身も、殺人発生を強盗、性的暴行といった他の暴力犯罪の時空間情報をもとに、マーク付き点過程で予測するモデルを提案するなど、モデルの拡張を行っている（Mohler, 2014）。

点過程モデルは、他にもギャング間の抗争について、1件の犯罪事象が報復という形で次の事象を誘起する、一種の近接反復被害として扱い、SEPP を適用した例が見られる（Short et al., 2014）など、ポイントどうしの関係を柔軟に記述できるモデルとして、地理的犯罪予測研究における一つの潮流となっている。

2.4.5 犯罪生成・誘引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に依拠して、将来の予測を行うものであった。これは、過去の（同一罪種の）分布状況という情報から、後の犯罪発生というアウトカムに関する情報を引き出しているといえる。一方で、犯罪そのもの以外にも、将来の犯罪発生を予測する要因が、多くの研究から見出されてきた。こうした変数は多岐にわたるが、地域・地区の社会経済的特性（人口密度、若年人口比率、人種的多様性、昼間人口比率等。以下、社会経済的要因）や、都市の物理的構造的な特性（公的施設数、繁華街までの距離、建蔽率等。以下、物理構造的的要因）といった空間的要素と、季節変動や天候要因、大規模なスポーツイベントとの時間的接近性、さらに前兆事案のような時間的要素とに大別できる。犯罪と時間的・空間的に関連するこれら諸変数を用いて、対象領域の潜在的な犯罪発生リスクを、いわば間接的に予測する手法が存在する。

ラトガース大学公共安全センターの Joel Caplan, Leslie Kennedy らが中心となって開発したリスク・ Terrain・モデリング（Risk Terrain Modeling, 以下、RTM）は、こうした手法の中で最も有名といえるものである。このモデルは、主に都市の物理構造的な要因に着目しながら、GIS の技法におけるオーバーレイ解析に依拠して予測を行う。具体的には、犯罪に関連する場所の分布状況から複数の主題図（KDE による密度分布図）を作成し、重み付けをした上で重ね合わせることで、犯罪リスクの高いエリアを同定する。ここでいう犯罪に関連する場所とは、Brantingham and Brantingham（1995）が指摘した、犯罪の集積を引き起こす犯罪生成要因（crime generators）と犯罪誘引要因（crime attractors）を指す（Caplan et al., 2011; Kennedy et al., 2011）。犯罪生成要因とは、駅をはじめとする、犯罪の潜在的な被害対象が多く集まる場所を指し、犯罪誘引要因とは、バーやドラッグマーケットなど、犯罪企図者が集まりやすい場所を指す。実際の研究においては、発砲事件（shooting incidents）の発生リスクを推定するために、「バーや酒店等の店舗や施設の住所」、「ギャングメンバーの住所」、「薬物事犯での逮捕があった住所」といった情報を組み合わせて用いており、同モデルに基づくリスク面地図（risk terrain map）は、KDE によるクライムマップと比較して、同じ領域面積で、実際の犯罪発生件数を2倍多く予測したことが報告されている（Caplan et al., 2011）。なお、この手法を最初に犯罪予測に適用した先駆的研究として、Groff and LaVigne（2001）がセル単位で都市を分割し、物理構造的な要因の重ね合わせをもとに住宅侵入盗を予測したものがある。この研究が RTM の源流といえる。

その後、Caplan らは RTM を発展させ、各要因の重み付けに関して、ターゲットとなる犯罪への影響度を回帰分析に基づいて推定するよう改良した（Caplan and Kennedy, 2016 : Risk Terrain Modeling Diagnostics, 以下、RTMDx）。RTMDx では、まず、要因となる施設の分布を密度（コンビニエンスストアやバーのように、比較的狭い範囲内に高密に分布している施設の場合）と接近性（図書館や病院、駅のように狭い範囲内に集積する可能性が低い施設の場合）のいずれを用いるかが、平均最近隣距離分析に基づいて決定される。次に、選ばれた各施設

の密度または近接性（距離）の値をセルに与え、罰則付き回帰モデルに投入し、変数選択が行われる。最後に、ステップワイズ法によるポアソン／負の二項回帰モデルを実行（BICの小さい方が選択される）して、変数選択、各要因の incidence rate ratio、およびリスク面地図の出力が自動で行われる。さらに最近では、リスク面地図をそのまま Google Map や Google Earth に出力して閲覧可能となるなど、改良が進んでいる。これらの手順を実行するソフトウェアは、比較的安価に提供されている^{xii}。なお、現在ではオリジナルの RTM と RTMDx をあわせて RTM として呼称されることが通例であるため、本研究でもこれにならう。

ところで、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、数週間～数ヵ月といった短期では変動しにくい。このことから、RTMは、当該エリアに持続的に存在する環境の特徴をもとに、その場所に安定的に潜在する犯罪への脆弱性を評価し、それが結果として犯罪リスクの大きさを予測しているといえる。この点は、4節3項や4節4項で紹介した、過去の犯罪発生データによる予測、すなわち、顕在化されたリスクに基づく予測と大きく異なる点であるといえよう。Caplan et al. (2011) では、精度検証のための予測対象期間を6ヵ月と、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。また、CaplanらはRTMによる予測に基づき、警察、および地域のステークホルダー（住民組織、商店会、店舗のオーナー、自治体関係者等）と連携してあたる犯罪予防活動 ACTION（Assessment of the risk narrative, Connections, Task management, Intervention planning / implementation, Outcome evaluation, Notifying others の頭文字）を提案しているが、ここではRTMの予測結果を月例で参照しながら話し合うことが推奨されている（Kennedy et al., 2016）。

RTM、および RTMDx をさまざまな都市に適用した実証的研究は、開発者のグループを中心に複数行われており、暴力犯罪（銃や殺傷能力の高い武器を用いた暴力、強盗など）を対象とした研究（Barnum et al., 2017; Burgason, 2017; Caplan et al., 2017; Caplan et al., 2013; Chillar and Drawve, 2018; Connealy and Piza, 2019; Drawve et al., 2016; Drawve and Barnum, 2017; Dugato, 2013; Gerell, 2018; Giménez-Santana et al., 2018a; Kennedy et al., 2016; Kennedy et al., 2011; Piza and Gilchrist, 2018; Thomas and Drawve, 2018; Valasik, 2018）が中心だが、侵入盗、車上狙い、自動車盗といった財産犯罪（Andresen and Hodgkinson, 2018; Caplan et al., 2015; Dugato et al., 2018; Kocher and Leitner, 2015; Moreto et al., 2014; Piza et al., 2016; Vildosola et al., 2019）にも適用されている。さらに、カージャック（Lersch, 2017）、海賊行為（Moreto and Caplan, 2010）、テロ（Onat and Gul, 2018）、違法薬物市場（Escudero and Ramirez, 2018）の予測といった、これまで地理的犯罪予測が適用された例のない罪種に用いられた例もある。また、犯罪ではないが交通事故の予測に適用した事例（Drawve et al., 2018; Giménez-Santana et al., 2018b）も見られる。なお、これらの研究は米国内だけでなく、バンクーバー（カナダ）、ボゴタ（コロンビア）、ミラノ（イタリア）、カディス（スペイン）、マルメ（スウェーデン）、ザルツブルク（オーストリア）、イスタンブール（トルコ）などの南米、欧州、西アジア諸国で実施されたものが含まれている。また、日本でRTMを用いた研究も存在する（花岡, 2018; 野・糸井川, 2017）。

RTMは、有効な犯罪生成・誘引要因を回帰分析により同定するという、予測に先行して探索的分析を行うことを必須とする手法である。予測と同時に各要因の犯罪発生への寄与の大きさを見ることができることから、RTMを用いた研究では、どのような環境要因に着目すべきかに関して必ず言及されている。また、先述の ACTION は、警察と他の関係主体が協力し

xii かつては研究目的であれば、無償での利用が可能であったが、現在は、年間で学生：100ドル、研究者等の専門家：1,450ドル、企業等機関の利用者：4,995ドルという価格で使用可能となっている（<http://www.rutgerscps.org/rtmtce-program.html>：最終閲覧日2019年10月2日）。

てリスクを生み出す環境を改善することを志向するもので、他の予測手法のように優先的に警戒する場所を示すにとどまらない、犯罪原因の根絶を志向した運用が想定されている。

また、RTMは、リスクの重ね合わせというシンプルな考えに基づいており、なおかつデータとソフトウェアが揃っていれば、比較的簡便に実行でき、また、それと関連して、地域の特性や実務現場のニーズに応じて様々な変数を投入・繰り返し試行できるフレキシビリティを備えている。あらかじめ候補となる予測変数についてデータを取得しておく必要があるものの、手順が標準化・自動化されているため、研究フィールドや罪種を変えながら、RTMDxを容易に検証することが可能である。RTMの研究例が多いことは、このような点にもよるだろう。

RTMは、マニュアルやWebinar等も充実しており、また、その活用方法をACTIONのように具体化し、書籍で紹介するなど、手法の普及に注力している姿勢がみてとれる。そもそもACTIONのように、手法開発者らが犯罪予測の運用方法まで提案するといったことは、他の予測手法では見られない。こうしたことから、RTMは現在、米国やその他の国の都市でも導入事例が見られ、これを活用した研究事例も、他の予測手法と比較して多い。社会的実装と研究、双方の面での広がりを見ると、RTMは、前項で取り上げた点過程モデルと並んで、地理的犯罪予測研究の一角を成しているといえよう。

2.4.6 多様な情報からの犯罪発生リスクの予測^{xiii}

前項で取り上げたような、犯罪関連要因による間接的な予測の手法のうち、機械学習を用いるものは、RTMとは別の系統として、近年目立って研究が盛んになっている。これらの研究では、RTMが依拠するような物理構造的要因だけでなく、社会経済的要因や、流動人口などの短期的に変化する要因を加えた多様な変数を用いて予測を行う。なお、ここで取り上げる研究は、他の予測手法研究と同様に、ある時点より過去のデータすべてをトレーニングセットとしてパラメータを推定し、ある時点より未来のデータをテストセットとして予測性能を検証(外挿)しているものに限る。そのため、ある時点から別の時点までのデータを、部分集合(トレーニングセット/テストセット)に分割し、クロスバリデーションで検証を行っているものは、予測研究とはみなさず、ここでは紹介しない。

たとえば、Bogomolov et al. (2014)は、ロンドンの都市部(面積不明)を124,119個のセルに分割し、68の社会経済的な予測変数(国勢調査の基本単位区ごとの人口、世帯数、移民人口、住宅価格等)にSmartstepsというモバイル位置情報から得た流動人口データを加え、ロジスティック回帰、サポートベクターマシン(Support Vector Machine, 以下、SVM)、ニューラルネットワーク(Neural Network, 以下、NN)、決定木、ランダムフォレスト(Random Forest, 以下、RF)といったモデルを適用して予測を行っている(罪種は不明)。Kang and Kang (2017)は、シカゴ市の任意の地点(緯度経度0.001度)での犯罪発生(31罪種混合)をデモグラフィック、住宅、経済、教育、気候に関する情報(これらはどのような指標かは詳細不明)に加え、Google Street Viewの画像データを用いてディープニューラルネットワーク、SVMやKDEで予測を行っている。Zhao and Tang (2017)は、ニューヨーク市に2km四方のセルで分割し、公共セキュリティ情報:暴行、放火、ハラスメント、不法侵入に対する市民からの通報、および警察の職務質問、気象情報:気温や湿度等、流動人口情報:Foursquare^{xiv}データのチェック

xiii 1章1節1項で紹介した日本の神奈川県警における研究事業で扱われた手法も、新聞記事にある「人工知能」、「環境条件」といった記述から、本項で紹介する手法に該当する可能性が高いものの、報告書が公開されておらず詳細は不明なこともあり、ここでは取り上げない。

xiv Foursquare (<https://ja.foursquare.com/>)は、位置情報付きのソーシャル・ネットワーク

インに関する情報, および市内タクシーの乗降データ, Point of Interests : Foursquare データから得られるベニユーの種別等, 公共サービスへの不満情報: 市民から寄せられる犯罪以外の事象に関する不満, といった情報を予測変数とし, 1日単位/7日単位で犯罪(罪種は不明)を予測している. その際, セル内の時間的相関, およびセル間の空間的相関を同時にモデリングする TCP (Temporal-Spatial Correlations for Crime Prediction) なるモデルを提案し, ARMA (Auto Regression Moving Average: 自己回帰移動平均) や Lasso 回帰, 線形回帰などと比較を行っている. Vomfell et al. (2018) は, ニューヨーク市の国勢調査区ごとに, 人口や人種構成等の社会経済的要因に加え, Foursquare データや市内のタクシー乗降データを組み合わせ, 暴力犯罪(殺人, 強盗, 加重暴行), 財産犯罪(侵入盗, 窃盗, 自動車盗, 放火)を週単位で予測. SAR (Simultaneous Autoregressive: 同時自己回帰) モデル, CAR (Conditional Autoregressive: 条件付き自己回帰) モデル, GLMM (Generalized Linear Mixed Model: 一般化線形混合モデル), GBM (Gradient Boosting Machine: 勾配ブースティング), NN, RF 等を適用し, モデル間の性能比較を行っている.

犯罪に関連する諸変数だけでなく, 犯罪発生そのものを予測変数に含める研究も存在する. Wang and Brown (2012) は, シャーロットビル市で発生する不法侵入を対象に, 男性人口等の社会経済的, 大学までの近接性等の物理構造的特性に加え, 直近で不法侵入が発生した時点からの経過期間を考慮し, 一般化加法モデル (Generalized Additive Model, 以下, GAM) により, 犯罪発生確率(犯罪発生が1件以上となる確率)を 32 m 四方のグリッドセルごとに, 月単位で求めている. 彼らは, これを Spatio-Temporal GAM (ST-GAM) と呼び, さらに分析対象である市全体をいくつかの地区に分け, その地区ごとに回帰式を推定する Local Spatio-Temporal GAM (LST-GAM) も同時に提案している. なお, Wang et al. (2012) では, 同じデータセットを用いながら, シャーロットビル市のローカルテレビ局のツイッターから発信されるテキスト情報を ST-GAM の予測に取り入れたモデルを考案している. 他にも, Rummens et al. (2017) は, オランダで実装されている地理的犯罪予測システム CAS と同様の方法論で, ベルギーのある都市部(人口 25 万人超)で 200 m 四方のセルごとに, 住宅侵入盗, 路上強盗, 暴行の発生を 2 週間ごと, 月別時間帯ごと(2014 年の 12 月における 7~19 時, 19~7 時)に, 2 週間前の当該・隣接セルにおける犯罪発生, 直近の犯罪発生からの経過月数といった犯罪発生情報, 若年人口割合や移民割合, 公営住宅数, 持ち家世帯率等といった社会経済的要因, レストラン, バー, 銀行, 緑地等の数や, 最寄りの駅や, 高速道路までの距離といった物理構造的要因等から予測し, ロジスティック回帰と NN, およびそれらのアンサンブル法を比較している. Lin et al. (2018) は, 台湾の桃園市をセルに分割(25 分割/10,000 分割した場合で比較, 前者はサイズの大きいセル, 後者は小さいセル)し, 自動車盗について①過去 1, 3, 6, 9, 11 ヶ月前の犯罪発生件数(自動車盗以外の罪種含む, 以下同様), ②前年の犯罪発生件数, ③隣接セルにおける過去 1/3/6/9/11 ヶ月の犯罪発生件数, ④コンビニや美容院, 薬局等の施設数を予測変数としてディープニューラルネットワーク(いわゆる深層学習)を適用し, RF, SVM, K 近隣法, 移動平均(過去 11 ヶ月の平均)と比較している. Rumi et al. (2018) は, オーストラリアのブリスベン市, 米国のニューヨーク市の 2 都市で, 窃盗, 不法侵入, 薬物犯罪, 交通犯罪, 詐欺, 暴行の 6 罪種を対象とし, 国勢調査区ごとに(ブリスベン市では約 0.082 km², ニューヨーク市では約 0.36 km²), 3 時間ごと(朝 6~9 時始まりで 21~24 時まで 6 つの時間帯)の予測を行っている. 予測変数は, 継時的要因(過去の犯罪発生情報を用いて 4 指標作成), 地理的要因(Foursquare のデータを使用してベニユーの種別ごとの密度

グ・サービス. 位置情報を知人と共有することができ, ユーザーは, 特定のタグがついた場所「ベニユー (venue)」で「チェックイン (check-in)」することで特典ポイントを得ることができる.

や多様性を作成), 社会経済的要因(人口, 年齢中央値, 所得中央値, 男女人口比, 借家世帯数, 民族多様性, 所得多様性), 動的要因(Foursquareのデータから, その時間に場所を訪れたユーザー数等々)を用い, RF, NN, SVM, ロジスティック回帰, アンサンブル法を比較している. なお, 分析の結果, ブリスベンではRFが, NYCではアンサンブル法がそれぞれ高精度であり, 動的要因の寄与もニューヨーク市で大きいなど, 都市により有効な予測モデルや予測変数が異なることが示されている.

このカテゴリに含まれる研究は, 予測変数として扱う要因が, 数十から百超までと他の地理的犯罪予測研究に比べ格段に多い, データソースが多様, 一度に種々のモデルを試して性能を評価するといった点が特徴的である. また, 多くが2015年以降の研究であること, ほとんどが犯罪学よりも計算機統計学の分野でなされたものであること, 研究者の出身地域も, 北米や英国が多い犯罪学研究と比較して, 東・東南・西・南アジア, 南米などが多いことなども特徴として挙げられる. 一方で, 研究で扱うのは欧米圏のデータであることが多い. これらは, 特に米国を中心とした欧米諸国でのオープンデータの普及, コンピュータの計算速度の向上, アジア諸国でのデータサイエンティスト人材の育成強化等々といった時代背景が影響していると考えられる.

研究内容については, 必ずしも既存の犯罪予測研究の形をなぞらないことが多く, 分析対象となる罪種に関する言及がない場合も多い. また, 予測精度や計算効率に関する検証を詳しく行う一方で, どのような要因が予測に寄与していたかについては追及しないものも多い. そもそも, どのような予測変数が用いられたかの詳細を記載しないものも見受けられる. この点は, RTM研究とは対照的で, 警察活動や犯罪予防活動への寄与が不十分となるおそれがある.

しかしながら, これらの研究は, 地理的犯罪予測の新たな潮流といえ, これまでの犯罪学にない発想を呼び込む可能性がある. 両分野が歩み寄ることで, さらなる研究の発展を見込むことができよう.

2.4.7 地区単位での犯罪発生件数, または確率の時系列予測

ここで紹介する手法は, 予測対象とするエリアを警察管区, パトロール区域, 国勢調査区, コミュニティといった領域に分け, その中で犯罪発生件数や犯罪発生確率を時系列予測の手法でモデリングするものである. この手法では, 過去の犯罪発生情報のみを用いるもののほか, 前兆事案をあわせて用いるもの, 犯罪関連要因をあわせて用いるものが存在する.

3章2節に紹介したように, こうした手法を犯罪分析に適用した例は従前から存在したものの, 国や州単位の犯罪発生件数を予測するようなマクロな分析であった. これに対し, Gorr et al. (2003) は, 地理的犯罪予測に時系列予測を適用した先駆的研究例として挙げられる. 彼らは, ピッツバーグ市を6つの警察管区(precinct)に分け, 時系列予測のモデルを複数適用し, 管区ごとに5罪種の発生件数を月ごとに予測, 手法間の精度比較を行った. この研究では, “crime forecasting”として将来予測を明示的に扱っており, 一市内の管区ごとの犯罪発生数の多寡という, それ以前の研究と比較して狭域での空間的ばらつきに, 年単位とやや解像度は粗いものの, 時間的な変動という要素を加えた初めての研究といえる. なお, 後にHuddleston et al. (2015) が同じピッツバーグ市を対象としながら, より空間的に詳細なパトロール区域に分け, 週単位で時系列予測モデルを適用し, モデル間の比較を行っている.

上記の研究は一つ前の期(月, あるいは週)の当該地区における犯罪発生件数のみを用いたものである. これに対し, Cohen et al. (2007)^{xv}はピッツバーグ市を4000フィート(約1.2

xv Cohen et al. (2007) は, NIJの「犯罪ホットスポット予測に関するプロジェクト(Crime Hot Spot Forecasting)」の研究結果(Gorr and Olligschlaeger, 2002)をもとに作成されてい

km) 四方の比較的大きいサイズのセルに分割, 月ごとの重篤な財産犯罪・暴力犯罪の発生件数を不法侵入, 薬物所持, 武器所持などといった前兆事案の発生情報から, 回帰モデルとニューラルネットワークで予測し, 単純に前期の犯罪発生を用いる時系列予測と比較している。

また, Law et al. (2014) は, カナダオンタリオ州のヨーク地域で発生する財産犯罪を対象に, 国勢調査集計地区 (1 地区あたり平均面積約 1.9 km²) ごと, 年単位での混合モデル (年の固定効果, 地区の変量効果) を適用し, 変量効果の大きさを将来の犯罪集中地区を予測している。当該研究では, 予測変数として低所得世帯率, 公的扶助受給者率という社会経済的要因を考慮しており, これを参考にした Hu et al. (2018) では, 中国の武漢市江岸区 (面積 33.4 km²) を 116 のコミュニティに分けて混合効果モデルを適用し, 地区ごとのホテル, インターネットバー, 商業ビルといった物理構造的要因や, 宅地それぞれの人口比率, および失業率といった社会経済的環境要因を予測変数に加え, 月単位での予測を行っている。

他にも, Fox and Brown (2012) は, シャーロットビル市で発生する暴行について, 国勢調査区ごと, 日単位での予測にロジスティック回帰を用い, 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, 予測変数として当該地区の特徴量 (国勢調査から得られるデモグラフィックな変数, 詳細不明) と, 当該地区と隣接地区それぞれにおいて $t-1$ 時点における 1 件以上の犯罪発生の有無を情報として加えたモデリングを行っており, 空間ラグをも考慮した形となっている。また, Prestemon et al. (2012) は, デトロイト市の放火について, 警察管区を単位としてポアソン自己回帰モデルを適用している。この研究では, 予測変数としては, 過去の犯罪発生のほか, 地区の社会経済的属性を表す変数 (空き物件数や世帯収入の中央値, 貧困人口等) に加え, 休日やイベント日, 最高気温等, 時間的に変動する要因も多く含まれている。さらに, これらに加えて, 前兆事案としての他罪種の犯罪, 放火の対象物ごとに分けた上で, 過去の放火発生データなどを用いて日単位での予測が行われている。

これらの予測は, 空間的に詳細化された領域での犯罪の時間的変動を扱うというアプローチをとっている点で, 他の予測手法とは趣を異にする。数百 m 四方以下といったセル単位で分析を行っている他の予測手法と比べ, 空間的解像度はやや落ちるものの, 犯罪の時空間的変動を同時に考慮している点で, 地理的犯罪予測手法の一類型とみなすことができる。

2.4.8 環境要因と犯罪の時空間相互作用を組み合わせた犯罪発生リスクの予測

最後に紹介する手法は, 4 節 5, 6, 7 項で紹介した手法に用いられる, 犯罪と関連する環境要因と, 4 節 4 項で紹介した手法に用いられる犯罪の時空間相互作用とを組み合わせた形態をとる。ここで紹介する研究は, 用いられるモデルもすべて異なり, 互いに独立した研究ではあるものの, 予測に際してのコンセプトが共通していることから, 同一の手法としてまとめた。

Ratcliffe et al. (2016) は, 白人人口比率, および低所得世帯比率や住宅価格中央値などで表される SES (Socio-Economic Status: 社会経済的地位, 以下, SES) といった社会経済的変数と, 前年の犯罪発生件数を同時に投入した回帰分析 (負の二項回帰) により長期的なリスクを国勢調査区単位で算出し, これを 100 フィート (約 30 m) 四方のセルに按分, さらに, Near Repeat Calculator^{xvi} というソフトウェアで近接反復被害リスクの上昇の程度を算出し, ミクロ

る。

xvi Near Repeat Calculator (Ratcliffe, 2009) は, 犯罪の発生した座標と発生日の情報をもとに, Knox Test (Knox, 1964) を応用して, 特定の距離・時間帯における近接反復被害の程度 (特定の時間・空間内に観測された犯罪発生件数を, シミュレーションにより求めた期待件数で除算することで求められるオッズ比), すなわち 1 件の犯罪が発生した後に, その犯罪から任意の距離帯, 日数帯で次の犯罪が起こる蓋然性を評価するツールである。

スケールでの近接反復被害効果（短期的な上昇リスク）として、長期的なリスクに加えることで、最終的な犯罪発生を予測するモデルを提案し、フィラデルフィア市の暴力犯罪と財産犯罪に適用している。

また、Kadar et al. (2019) は、スイスのアールガウ州（面積約 140,000 ha）に 200 m 四方のグリッドセルを設定し、日単位で侵入盗を予測しているが、予測変数として、男性人口、人種多様性等の社会経済的要因、土地利用形態、道路密度等の物理構造的要因、曜日や気温などの時間変動要因に加え、近接反復被害を想定して前日、3 日前、7 日前、14 日前までの当該セル・隣接セルでの侵入盗発生数を投入し、RF, AdaBoost, ロジスティック回帰などを適用している。Yu et al. (2015) は、米国北東部のある都市で、800 m, 600 m, 450m 四方のセル単位で、月ごとの侵入盗発生を予測しているが、当該セルで前月に発生した住宅侵入盗（近接反復被害）、また事業所侵入盗、自動車盗、路上強盗等といった異罪種の発生件数、人口や世帯所得中央値、世帯数といった社会経済的要因を用いながら、マルチクラスタリングの技法で特徴量を統合し、予測を行う独自のアルゴリズム CCRBoost（Cluster-Confidence-Rate-Boosting）を提案し、NN, ロジブースト, SVM, RF, 地理的か重回帰等の多様なモデルと比較している。

一方で、Reinhart and Greenhouse (2017) では、4 節 4 項で紹介した Mohler らの SEPP モデルを応用したモデルを提案し、ピッツバーグ市の国勢調査区単位で、侵入盗の犯罪発生リスクを地区の若年人口割合、持ち家世帯割合等の社会経済的要因から推定されるリスクと、同罪種内・異罪種間のリスク波及効果の和として求めている。

さらに、Tang et al. (2019) は、画像解析に用いられる AnisDM (Anisotropic Diffusion Model) を応用し、武漢市江岸区で発生した住宅侵入盗について、1 m² 四方のセル単位で、月ごとに予測を行っている。彼らは、セルごとの住宅密度の類似度を算出する指標を考案しながら、ひとたび住宅侵入盗が発生した場合には、類似度の高いセル間で住宅侵入盗が伝播するという、近接反復被害の異方性を意識したモデルを提案している。

なお、4 節 6 項や 7 項で紹介した研究も、犯罪の時空間情報と犯罪関連要因を同時に用いたものはあるが、本項の手法は、両者を予測変数として同時投入するだけでなく、近接反復被害（すなわち、犯罪間の時空間相互作用）を明示的に組み込むモデリングを行っている点で異なっている。

ここで紹介した研究は、犯罪に脆弱な環境が局所的に存在することで生まれる、都市に潜在する長期的リスクと、ひとたび犯罪が発生することにより顕在化する短期的なリスクを組み合わせるもので、新たな地理的犯罪予測手法の枠組みと位置付けられる。

2.5 地理的犯罪予測システムへの実装

ここでは、4 節で紹介した各手法が、それぞれどのような地理的犯罪予測システムとして実装されているかについて述べる。

まず、4 節 3 項で紹介したクラスタ検出手法について、Neill and Gorr (2007) のモデルから、Daniel Neill と Wilpen Gorr がシカゴ市警と CrimeScan というシステムを共同開発し (Fitspatrick et al., 2019), 現在はピッツバーグの警察活動に取り入れられている (NBC NEWS MACH, 2017)。

4 節 4 項で紹介した Mohler らの研究者グループは、SEPP モデルをもとに犯罪予測システム PredPol を開発しているが、予測型警察活動、および地理的犯罪予測に対する関心の高まりは、PredPol が、米国サンタクルーズ市やロサンゼルス市で成果を挙げたとの報道がなされたことがきっかけとなっている (Perry et al., 2013)。PredPol に関しては、多くのメディアで報道されたために、社会的な知名度が高いことも、特筆すべき点として挙げられる。PredPol は、

現在警察実務に実装されている地理的犯罪予測システムの中で特に普及しており、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（ケント）でも導入事例が見られる。ちなみに、第1章冒頭で紹介した京都府警が導入したシステムも、記事の記述から、同システムを参考に行っている可能性が高い。

一方で、地理的犯罪予測手法としては先駆といえる ProMap は、警察実務への普及率は高くなく、英国で警察活動支援システムとして取り入れられていたことが確認できる（ファレル・ピーズ, 2010）のみで、後続の手法に比べ、実務での適用例が少ない。しかしながら、最近では、Esri 社の地理情報解析ソフトウェア ArcGIS の“Crime Analysis”ツールボックス（<https://solutions.arcgis.com/local-government/help/crime-analysis/>）として、同モデルが実装されており、実務家が実行する機会が増える可能性もある。

他にも、近接反復被害現象に着目した地理的犯罪予測システムには、主にドイツで導入されている犯罪予測システム PRECOBS, KLB-operativ, PreMap, SKALA がある（Seidensticker et al., 2018）。

4節5項で紹介した RTM は、既に述べた通り、RTMDx というソフトウェアとして販売されており、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に、ヨーロッパ（パリ、ミラノ）、南米（ボゴタ）でも採用されており（Caplan et al., 2016）、警察実務における普及率を着々と向上させている。

4節6項で紹介した機械学習による予測システムとしては、まず、Donald Brown が開発に携わった WebCAT（Web-Based Crime Analysis Toolkit）が挙げられる（Mitchell et al., 2007）。このシステムには、Wang and Brown（2012）と同様、GAM が用いられており、世帯密度や一人あたり所得等の社会経済的要因、施設への距離といった物理構造的要因から、週単位で予測を行う（予測の空間単位は不明）。どのような罪種を対象としているかは不明だが、Mitchell et al.（2007）では暴行と侵入盗が例として挙げられている。

また、同様に機械学習を活用したシステムとして、オランダで用いられている CAS（Crime Anticipation System）が挙げられる。CAS に関する資料は限られるが、WEB 上で公開されている資料（Willems, 2015）によると、CAS は 125 m 四方のセル単位で、むこう 2 週間における住宅侵入盗、路上強盗、その他強盗を 8 時間帯ごと（8～16 時、16～24 時、24～8 時）に予測する。予測変数としては、過去の犯罪発生、公的統計から得られる社会経済的要因、バーや喫茶店、銀行等の施設数、最寄り高速道路への距離といった物理構造的要因、犯罪前歴者の所在地からの距離を用いながら、NN で予測を行う。

4節8項で紹介した手法の実装としては、Ratcliffe et al.（2016）の執筆者である Jerry Ratcliffe, Ralph Taylor らが、Azavea 社と共同開発した PROVE（Prediction of Repeat Offending and Victimization in the Environment）というソフトウェアが、WEB 上で無料公開されている（<https://www.hunchlab.com/tools/prove/>）。アルゴリズムは、4節7項において紹介した通りである。

最後に、米国で PredPol と並んで著名な地理的犯罪予測システムである Azavea 社^{xvii}の Hunchlab について紹介する。Hunchlab に関する詳細は、学術研究ではなく Azavea 社の公開する WEB 上の情報に限られるが、それらの資料によると^{xviii}、Hunchlab では 500 フィート（約

xvii Hunchlab は、2018 年に ShotSpotter 社に売却された（<https://www.shotspotter.com/press-releases/shotspotter-announces-acquisition-of-hunchlab-to-springboard-into-ai-driven-analysis-and-predictive-policing/>：最終閲覧日 2020 年 1 月 30 日）が、開発は Azavea 社が手掛けたものであること、同社が複数の犯罪予測システムの開発に関与していることを鑑み、ここではあえて Azavea 社の名で紹介する。

xviii ここで参照した資料は、Hunchlab について説明した SlideShare のスライド（<https://ww>

150m) 四方のセル単位, 1時間ごとに予測を行い, 暴行, 侵入盗, 自動車盗, 強姦性交, 強盗等の多様な罪種について予測を行う。予測変数としては, 過去の犯罪発生, 近接反復被害, RTMのような施設への近接性・密度, 犯罪前歴者の所在地への近接性・密度, 警察施設の位置, 潜在的被害対象としての人口や自動車数, 人種多様性, 季節性, スポーツイベントの有無, 天候といった多様な情報を用いる。これらをもとに, 勾配ブースティングのAdaBoostを用いてセルごとの犯罪発生確率を算出, その後, あらためて予測変数さらにGAMで発生件数を予測して示す。近接反復被害と環境要因を同時に扱っていることから, この予測システムは, 4節7項で紹介したカテゴリに入ると考えられる。なお, Azavea社のHunchlab開発責任者Jeremy Heffnerは, RTMDxのソフトウェア開発に貢献しており, そのマニュアルも執筆している(Heffner, 2013)。

地理的犯罪予測を行うことを目的としたシステムには, 本章で取り上げたような, 実証的な学術研究に基づいて構築された手法だけでなく, システムベンダーにより独自に開発されたものが存在する。こうしたシステムはしばしば, 防犯カメラの映像や, 各種のセンサリングデータ, あるいは犯罪前歴をもつ者の住所情報, ソーシャルメディア上の情報等, 種々のビッグデータをもとに, 帰納的に犯罪発生を予想, 現場警察官にリアルタイムで情報伝達するビジネス・インテリジェンスツールの形をとる^{xix}。これら民間主導のシステムは, 本稿で取り上げる地理的犯罪予測手法とは一線を画すが, こうしたテクノロジーに牽引されたシステムも, 警察関係者や報道の関心をひきつけ, 犯罪の予測という試みに対する期待を高めるものとなっている。

2.6 まとめ

本章では, 地理的犯罪予測研究の系譜と具体的な手法, また実務への適用状況や予測をめぐる議論についてみてきた。ここでは, 本章の結果についてまとめるとともに, 現時点で考えられる地理的犯罪予測の日本における適用可能性について述べる。

まず, 第3節では, 犯罪と予測に関する研究トレンドについてみながら, 背景にある学術的・社会的動向にふれた。また, 地理的犯罪予測研究の源流として, 犯罪の時間的変化に着目した研究, 犯罪のホットスポットに関する研究, および実務での動向について述べた。地理的犯罪予測研究は, 犯罪やデータ解析に関する理論の発展と, GISをはじめとする各種分析ソフトウェアの発達・PCの計算能力の強化という技術的進歩, これらを活用した予測という試みと, 犯罪の未然防止に対する社会的要請が, 研究の契機となった背景がある。近年では, GPSデータの時間的・空間的解像度の向上や, IoTなどに見られるセンシング技術の発達

[w.slideshare.net/Azavea/hunchlab-20-getting-started](https://www.slideshare.net/Azavea/hunchlab-20-getting-started); <https://www.slideshare.net/Azavea/hunchlab-20-predictive-missions-under-the-hood> : とともに最終閲覧日 2019年10月10日), およびPDF資料 (<https://cdn.azavea.com/pdfs/hunchlab/HunchLab-Under-the-Hood.pdf>; <http://robertbrauneis.net/algorithms/HunchLabACitizensGuide.pdf> : とともに最終閲覧日 2019年10月10日) である。

xix IBM社のBlue CRUSH (<http://www-03.ibm.com/press/us/en/pressrelease/32169.wss> : 最終閲覧日 2019年10月10日), Hitachi Data Systems社のPredictive Crime Analytics (<https://www.hds.com/en-us/news-insights/press-releases/2015/gl150928.html> : 最終閲覧日 2019年10月10日), Motorola Solutions社のCommand Central Analytics (<https://www.motorolasolutions.com/content/dam/msi/docs/products/command-center-software/records-and-evidence/commandcentral-analytics-is-my-crime-analytics-software-predictive-white-paper.pdf> : 最終閲覧日 2019年10月10日), LexisNexis社のAccurant Crime Analysis Workstation (<https://risk.lexisnexis.com/-/media/files/government/brochure/accurant-crime-analysis-workstation%20pdf.pdf> : 最終閲覧日 2019年10月10日) などがこれに該当する。

などにより、ヒトやモノのリアルタイムな移動がデータとして入手可能になったことで、今後の地理的犯罪予測研究も、犯罪リスクの時間的変動をより詳細に捉えるダイナミックなモデルを求める方向に進む可能性も考えられる。また、米国などでは、各種の統計情報に加え、犯罪のポイントレベルのデータなども、オープンデータとして公開されている場合があるが、こうしたデータの利用可能性の向上は、関係機関に所属しない研究者にも研究の機会を与え、また、分析の試行錯誤を可能にするものであり、地理的犯罪予測研究の発展にとって、今後もその重要性を増してゆくことだろう。

次に、第4節では、現在発展している地理的犯罪予測手法について、アプローチの違いに基づき、時空間クラスターの検出、犯罪の時空間相互作用を考慮した犯罪発生の強度推定、犯罪生成・誘引要因からの犯罪発生リスクの予測、多様な情報からの犯罪発生リスクの予測、地区単位での犯罪発生件数、または確率の時系列予測、環境要因と犯罪の時空間相互作用を組み合わせた犯罪発生リスクの予測の6つのカテゴリに分類した。

最後に第5節では、各手法研究が、どのような犯罪予測システムに結実しているかについてまとめた。

本章で取り上げた手法について、形式的な面から、日本での適用可能性について考える。日本での研究の実情からみれば、ポイントレベル・日単位といった詳細な犯罪発生情報入手するのは容易ではなく、本章でみてきた多くの手法を試行することは、通常困難である。この点で、犯罪データを必ずしも必要としないRTMや、回帰分析的なアプローチは、地域単位で集計されたデータでも、予測に有効な要因を探索することが可能であり、有望といえる。特に、日本でも最近、各都道府県警が小地域単位での犯罪発生場所・時間等に関する個票データを公開し始めた。こうしたデータは、4節4項で取り上げたような予測手法を実行するには不十分だが、4節3項におけるスキャン統計量、4節5項におけるRTM、4節7項における地区単位での予測等には、十分に活用できるだろう。また、日本は諸外国に比して犯罪の発生件数そのものが少ないとされるが、犯罪と関連する都市の地理的・社会的要因の存在は確認されており（たとえば、島田・原田，1999；雨宮，2013；樋野・小島，2007；上杉・樋野，2015）、これらの知見は、潜在的なリスクの推定に活用することができよう。

また、MohlerらのSEPPモデルは、過去の犯罪発生データのみを扱うモデルではあるものの、事象間の時空間相互作用のモデリングに優れた手法である。わが国においても、主要な財産犯（侵入盗、ひったくり、車上狙い）では、近接反復被害が見られることが示されており（菊池ら，2010）、さらに、声かけやつきまといといった事案が、性犯罪の前兆、すなわちLeading Indicatorとして機能する可能性も示唆されている（菊池ら，2009；雨宮ら，2018）。犯罪データの利用可能性が今後わが国でも向上すれば、同様の手法を適用できる可能性はあると考えられる。他方で、このように欧米で見られる犯罪現象が、日本でも一般的に成り立つかという点については、一地域にとどまらず、複数の地域で実証的な知見を蓄積してゆくことが望まれる。

なお、手法の利用可能性の点からは、4節3項で紹介した予見的な時空間スキャン統計量は無料のソフトウェアとして公開されていること、4節4項で紹介したProMapなどは、汎用のGISソフトウェアに実装されていることから、他の手法に比べて利用しやすいものと思われる。4節5項で取り上げたRTMDxは、他の有料の犯罪予測ソフトウェアに比べて低価格で提供されているものの、実行にあたって、どのような変数が予測に有効か、ある程度あたりをつけながら地理空間データなどを用意する必要があり、知識や準備を要する。4節6～8項で取り上げた手法にも、同様のことがいえよう。これに比べ犯罪がいつ・どこで起きたという時空間情報のみを必要とする4章3節、4章4節などで紹介した手法は、相対的に実行が容易であるといえる。警察などの実務家が、手元の情報で試すこともできるだろう。

第2章 既存の地理的犯罪予測研究の整理

次章では、ここで取り上げた各予測手法の中から、いくつかのモデルを選んで、日本のデータに実際に適用し、その予測性能を評価することで、わが国における各手法の有効性を検討する。

2章の参考文献

- 1) 雨宮護 (2013) 潜在成長曲線モデルを用いた地区レベルでの犯罪の時系列変化と地区環境との関連の分析. 「都市計画論文集」, **48**(3), 351-356.
- 2) 雨宮護・島田貴仁・中谷友樹・樋野公宏・高橋あい (2018) 子供・女性に対する脅威事案は性犯罪等のリスクを高めるか? : 子供・女性の性犯罪等における先行指標の検討, 「都市計画報告集」, **17**, 216-222.
- 3) ウェイジャーズ, M.・スーザ, W.・ケリング, G. (2010) 割れ窓理論と警察活動. In ウォートレイ, R.・メイズロール, L.編, 島田貴仁・渡辺昭一・齊藤知範・雨宮 護・菊池城治・畑 倫子 訳 (2010) 『環境犯罪学と犯罪分析』, 社会安全研究財団. Wortley, R., and Townsley, M. eds. (2008) *Environmental Criminology and Crime Analysis*. Oxford: Taylor & Francis, 256-262pp.
- 4) 上杉昌也・樋野公宏 (2015) 東京都区部における住宅侵入盗と近隣社会経済的特性の関係. 「都市計画論文集」, **50**(3), 608-615.
- 5) 菊池城治・雨宮護・島田貴仁・齊藤知範・原田豊 (2009) 声かけなどの不審者遭遇情報と性犯罪の時空間的接性の分析. 「犯罪社会学研究」, **34**, 150-162.
- 6) 菊池城治・雨宮護・島田貴仁・齊藤知範・原田豊 (2010) 近接反復被害の罪種間比較: 時空間 K 関数の応用. 「GIS-理論と応用」, **18**(2), 129-138.
- 7) コーニッシュ, D.・クラーク, R. (2010) 合理的選択の観点. In ウォートレイ, R.・メイズロール, L.編, 島田貴仁・渡辺昭一・齊藤知範・雨宮 護・菊池城治・畑 倫子 訳 (2010) 『環境犯罪学と犯罪分析』, 社会安全研究財団. Wortley, R., and Townsley, M. eds. (2008) *Environmental Criminology and Crime Analysis*. Oxford: Taylor & Francis, 37pp.
- 8) 島田貴仁 (2013) 環境心理学と犯罪研究-犯罪原因論と犯罪機会論の統合に向けて-. 「環境心理学研究」, **1**(1), 46-57.
- 9) 島田貴仁・原田豊 (1999) 大都市における犯罪と社会経済要因の関連: 方法の問題点と GIS による解決. 「科学警察研究所報告 防犯少年編」, **39**(2), 102-116.
- 10) 中川淳子・小西勇介・宮野博義 (2018) 犯罪発生履歴データの機械学習による時空間カーネル密度推定型犯罪予測の最適化. 「第 17 回情報科学技術フォーラム講演論文集 第 4 分冊」, 97-100.
- 11) 野貴泰・糸井川栄一 (2017) 犯罪多発地点の予測に基づく防犯パトロール経路に関する提案. 「地域安全学会論文集」, **31**, 195-204.
- 12) 花岡和聖 (2018) 大阪府における不審者遭遇情報の地理的分布: Risk Terrain Model を用いた犯罪リスクのマッピング. 「立命館文学」, 656, 47-59.
- 13) 樋野公宏・小島隆矢 (2007) 住宅侵入盗発生率と地域特性との関係: 東京都下 29 区市の町丁を対象に. 「日本建築学会計画系論文集」, **616**, 107-112.
- 14) ファレル, G.・ピーズ, K. (2010) 反復被害. In ウォートレイ, R.・メイズロール, L.編, 島田貴仁・渡辺昭一・齊藤知範・雨宮 護・菊池城治・畑 倫子 訳 (2010) 『環境犯罪学と犯罪分析』, 社会安全研究財団. Wortley, R., and Townsley, M. eds. (2008) *Environmental Criminology and Crime Analysis*. Oxford: Taylor & Francis, 131pp.
- 15) 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*, **30**(11), 2133-2154.

- 16) Almazlinos, C., Bowman, D., Eagan, R., Kuklinski, T., Nguyen, D., Brown, D., Conklin, J. and Hansen, P. (2006) Webcat: The development, performance analysis, and deployment of a web-based crime analysis toolkit. In *Proceedings of 2006 IEEE Systems and Information Engineering Design Symposium*, 304-309.
- 17) Andresen, M. A., and Hodgkinson, T. (2018) Predicting property crime risk: An application of risk terrain modeling in Vancouver, Canada. *European Journal on Criminal Policy and Research*, **24**(4), 373-392.
- 18) Anselin, L., Cohen, J., Cook, D., Gorr, W., and Tita, G. (2000) Spatial analyses of crime. *Criminal Justice*, **4**(2), 213-262.
- 19) Assunção, R., and Correa, T. (2009) Surveillance to detect emerging space-time clusters. *Computational Statistics & Data Analysis*, **53**(8), 2817-2830.
- 20) Barnum, J., Caplan, J., Kennedy, L., and Piza, E. (2017) The crime kaleidoscope: A cross-jurisdictional analysis of place features and crime in three urban environments. *Applied Geography*, **79**, 203-211.
- 21) Bogomolov, A., Lepri, B., Staiano, J., Oliver, N., Pianesi, F., and Pentland, A. (2014) Once upon a crime: towards crime prediction from demographics and mobile data. In *Proceedings of the 16th International Conference on Multimodal Interaction*, 427-434.
- 22) Bowers, K. , and Johnson, S. (2004) Who commits near repeats? A test of the boost explanation. *Western Criminology Review*, **5**(3), 12-24.
- 23) Bowers, K., Johnson, S., and Pease, K. (2004) Prospective hot-spotting the future of crime mapping? *British Journal of Criminology*, **44**(5), 641-658.
- 24) Brantingham, P., and Brantingham, P. (1984) *Patterns in crime*. New York: Macmillan.
- 25) Brantingham, P., and Brantingham, P. (1993) Environment, Routine, and Situation: Toward a Pattern Theory of Crime. In *Routine Activity and Rational Choice, Advances in Criminological Theory*, Vol. 5, Clarke, R. and Felson, M. eds. New Brunswick: Transaction Publishers., 259-294pp.
- 26) Burgason, K., Drawve, G., Brown, T., and Eassey, J. (2017) Close only counts in alcohol and violence: Controlling violence near late-night alcohol establishments using a routine activities approach. *Journal of Criminal Justice*, **50**, 62-68.
- 27) Caplan, J., and Kennedy, L. (2016) *Risk Terrain Modeling: Crime Prediction and Risk Reduction*. Oakland: University of California Press., xx pp.
- 28) Caplan, J., and Kennedy, L., Ibid., 11-29pp.
- 29) Caplan, J., Kennedy, L., Barnum, J., and Piza, E. (2017) Crime in context: Utilizing risk terrain modeling and conjunctive analysis of case configurations to explore the dynamics of criminogenic behavior settings. *Journal of Contemporary Criminal Justice*, **33**(2), 133-151.
- 30) Caplan, J., Kennedy, L., Barnum, J., and Piza, E. (2015) Risk terrain modeling for spatial risk assessment. *Cityscape*, **17**(1), 7-16.
- 31) 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.
- 32) 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.

- 33) Cheng, T., and Adepeju, M. (2013) 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>.>
- 34) Chillar, V., and Drawve, G. (2018) Unpacking spatio-temporal differences of risk for crime: An analysis in Little Rock, AR. *Policing: A Journal of Policy and Practice*, pay018, <https://doi.org/10.1093/police/pay018>.
- 35) Cohen, L., and Felson, M. (1979) Social change and crime rate trends: A routine activity approach. *American Sociological Review*, **44**(4), 588-608.
- 36) Cohen, L., Felson, M., and Land, K. (1980) Property crime rates in the united states: A macrodynamic analysis, 1947-1977; with ex ante forecasts for the mid-1980s. *American Journal of Sociology*, **86**(1), 90-118.
- 37) Cohen, J., Gorr, W., and Olligschlaeger, A. (2007) Leading indicators and spatial interactions: A crime-forecasting model for proactive police deployment. *Geographical Analysis*, **39**(1), 105-127.
- 38) Cohen, J., and Tita, G. (1999) Diffusion in homicide: Exploring a general method for detecting spatial diffusion processes. *Journal of Quantitative Criminology*, **15**(4), 451-493.
- 39) Connealy, N., and Piza, E. (2019) Risk factor and high-risk place variations across different robbery targets in Denver, Colorado. *Journal of Criminal Justice*, **60**, 47-56.
- 40) Cornish, D., and Clarke, R. eds. (1986) *The Reasoning Criminal: Rational Choice Perspectives on Offending*. New York: Springer-Verlag.
- 41) Deadman, D., and Pyle, D. (1997) Forecasting recorded property crime using a time-series econometric model. *British Journal of Criminology*, **37**(3), 437-445.
- 42) Dhiri, S., Brand, S., Harries, R., Price, R. (1999) *Modelling and Predicting Property Crime Trends in England and Wales*, Home Office Research Study No. 198, London: Home Office.
- 43) Drawve, G. (2016) A metric comparison of predictive hot spot techniques and RTM. *Justice Quarterly*, **33**(3), 369-397.
- 44) Drawve, G., and Barnum, J. (2018) Place-based risk factors for aggravated assault across police divisions in Little Rock, Arkansas. *Journal of Crime and Justice*, **41**(2), 173-192.
- 45) Drawve, G., Grubb, J., Steinman, H., and Belongie, M. (2018) Enhancing data-driven law enforcement efforts: exploring how risk terrain modeling and conjunctive analysis fit in a crime and traffic safety framework. *American Journal of Criminal Justice*, **44**(1), 106-124.
- 46) Drawve, G., Thomas, S. A., and Walker, J. T. (2016) Bringing the physical environment back into neighborhood research: The utility of RTM for developing an aggregate neighborhood risk of crime measure. *Journal of Criminal Justice*, **44**, 21-29.
- 47) Dugato, M. (2013) Assessing the validity of risk terrain modeling in a European city: preventing robberies in the city of Milan. *Crime mapping*, **5**(1), 63-89.
- 48) Dugato, M., Favarin, S., and Bosisio, A. (2018) Isolating target and neighbourhood vulnerabilities in crime forecasting. *European journal on criminal policy and research*, **24**(4), 393-415.
- 49) Eckberg, D. (1995) Estimates of early twentieth-century US homicide rates: An econometric forecasting approach. *Demography*, **32**(1), 1-16.
- 50) Escudero, J., and Ramírez, B. (2018) Risk terrain modeling for monitoring illicit drugs markets across Bogota, Colombia. *Crime Science*, **7**(1), Article #3.

- 51) Farrell, G., and Pease, K. (1993) *Once bitten, twice bitten: Repeat victimisation and its implications for crime prevention.*, London: Home Office.
- 52) Felson, M., and Poulsen, E. (2003) Simple indicators of crime by time of day. *International Journal of Forecasting*, **19**(4), 595-601.
- 53) Ferguson, A. (2015) Big Data and Predictive Reasonable Suspicion. *University of Pennsylvania Law Review*, **163**(2), 327.
- 54) Fitzpatrick, D., Gorr, W., and Neill, D. (2019) Keeping Score: *Predictive Analytics in Policing*. *Annual Review of Criminology*, **2**, 473-491.
- 55) 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.
- 56) Gao, P., Guo, D., Liao, K., Webb, J., and Cutter, S. (2013) Early detection of terrorism outbreaks using prospective space–time scan statistics. *The Professional Geographer*, **65**(4), 676-691.
- 57) Gerell, M. (2018) Bus stops and violence, are risky places really risky? *European Journal on Criminal Policy and Research*, **24**(4), 351-371.
- 58) Giménez-Santana, A., Caplan, J., and Drawve, G. (2018) Risk terrain modeling and socio-economic stratification: identifying risky places for violent crime victimization in Bogotá, Colombia. *European Journal on Criminal Policy and Research*, **24**(4), 417-431.
- 59) Giménez-Santana, A., Medina-Sarmiento, J., and Miró-Llinares, F. (2018) Risk terrain modeling for road safety: Identifying crash-related environmental factors in the province of Cádiz, Spain. *European Journal on Criminal Policy and Research*, **24**(4), 451-467.
- 60) Gorr, W. L., and Lee, Y. (2012) Longitudinal study of crime hot spots: dynamics and impact on part 1 violent crime. In *Proceedings of the 32nd international symposium on forecasting*.
- 61) Gorr, W., and Harries, R. (2003) Introduction to crime forecasting. *International Journal of Forecasting*, **19**(4), 551-555.
- 62) Gorr, W., and Olligschlaeger, A. (2002) *Crime hot spot forecasting: Modeling and comparative evaluation, final project report*. Washington, DC: National Criminal Justice Reference Service.
- 63) Gorr, W., Olligschlaeger, A., and Thompson, Y. (2003) Short-term forecasting of crime. *International Journal of Forecasting*, **19**(4), 579-594.
- 64) Groff, E., and La Vigne, N. (2002) Forecasting the future of predictive crime mapping. *Crime Prevention Studies*, **13**, 29-58.
- 65) Hardyns, W., and Rummens, A. (2018). Predictive policing as a new tool for law enforcement? Recent developments and challenges. *European Journal on Criminal Policy and Research*, **24**(3), 201-218.
- 66) Hart, T. and Zandbergen, P. (2012) *Effects of data quality on predictive hotspot mapping: final technical report*. Washington, D.C.: National Institute of Justice, 239861.
- 67) Heffner, J. (2013) Statistics of the RTMDx Utility. In *J. Caplan, L. Kennedy, and E. Piza, Risk Terrain Modeling Diagnostics Utility User Manual (Version 1.0)*. Newark: Rutgers Center on Public Security.
- 68) House, W. (2016) *Big Data: A Report on Algorithmic Systems, Opportunity, and Civil Rights*. Washington, DC: Executive Office of the President, White House.

- 69) Hu, Y., Wang, F., Guin, C., and Zhu, H. (2018) A spatio-temporal kernel density estimation framework for predictive crime hotspot mapping and evaluation. *Applied Geography*, **99**, 89-97.
- 70) Hu, T., Zhu, X., Duan, L., and Guo, W. (2018) Urban crime prediction based on spatio-temporal Bayesian model. *PloS One*, **13**(10), e0206215.
- 71) Huddleston, S., Porter, J., and Brown, D. (2015) Improving forecasts for noisy geographic time series. *Journal of Business Research*, **68**(8), 1810-1818.
- 72) Jeffery, R. (1971) *Crime prevention through environmental design*. Beverly Hills, CA: Sage Publications.
- 73) Johnson, S., Bernasco, W., Bowers, K., Elffers, H., Ratcliffe, J., Rengert, G., and Townsley, M. (2007) Space-time patterns of risk: A cross national assessment of residential burglary victimization. *Journal of Quantitative Criminology*, **23**(3), 201-219.
- 74) Johnson, S., Birks, D., McLaughlin, L., Bowers, K., and Pease, K. (2007) *Prospective Crime Mapping in Operational Context, Final Report.*, London: Home Office.
- 75) 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.
- 76) Kadar, C., Maculan, R., and Feuerriegel, S. (2019) Public decision support for low population density areas: An imbalance-aware hyper-ensemble for spatio-temporal crime prediction. *Decision Support Systems*, **119**, 107-117.
- 77) Kajita, M., and Kajita, S. (2017) Crime Prediction by Data-Driven Green's Function method. arXiv preprint arXiv:1704.00240.
- 78) Kang, H., and Kang, H. (2017) Prediction of crime occurrence from multi-modal data using deep learning. *PloS one*, **12**(4), e0176244.
- 79) Kennedy, L., Caplan, J., and Piza, E. (2018) *Risk-based policing: Evidence-based crime prevention with big data and spatial analytics.*, Oakland: University of California Press., 37pp.
- 80) Kennedy, L., Caplan, J. M., and Piza, E. (2011) Risk clusters, hotspots, and spatial intelligence: risk terrain modeling as an algorithm for police resource allocation strategies. *Journal of Quantitative Criminology*, **27**(3), 339-362.
- 81) Kennedy, L., Caplan, J., Piza, E., and Buccine-Schraeder, H. (2016) Vulnerability and exposure to crime: Applying risk terrain modeling to the study of assault in Chicago. *Applied Spatial Analysis and Policy*, **9**(4), 529-548.
- 82) Khairuddin, A., Alwee, R., and Haron, H. (2019) A review on applied statistical and artificial intelligence techniques in crime forecasting. In *IOP Conference Series: Materials Science and Engineering*, **551**(1), <<https://iopscience.iop.org/article/10.1088/1757-899X/551/1/012030/pdf>>, 2019年9月30日閲覧.
- 83) Knox, E. (1964) The detection of space-time interactions. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, **13**(1), 25-30.
- 84) Kocher, M., and Leitner, M. (2015) Forecasting of crime events applying risk terrain modeling. *GI Forum-Journal of Geographic Information*, **1**, 30-40.

- 85) Kulldorff, M. (1997) A spatial scan statistic. *Communications in Statistics - Theory and Methods*, **26**,1481-1496.
- 86) Kulldorff, M., Athas, W. F., Feuer, E. J., Miller, B. A., and Key, C. R. (1998) Evaluating cluster alarms: a space-time scan statistic and brain cancer in Los Alamos, New Mexico. *American Journal of Public Health*, **88**(9), 1377-1380.
- 87) Law, J., Quick, M., and Chan, P. (2014) Bayesian spatio-temporal modeling for analysing local patterns of crime over time at the small-area level. *Journal of Quantitative Criminology*, **30**(1), 57-78.
- 88) Lersch, K. (2017) Risky places: An analysis of carjackings in Detroit. *Journal of Criminal Justice*, **52**, 34-40.
- 89) Levine, N. (2008) The "hottest" part of a hotspot: comments on "the utility of hotspot mapping for predicting spatial patterns of crime". *Security Journal*, **21**(4), 295-302.
- 90) Lin, Y., Yen, M., and Yu, L. (2018) Grid-based crime prediction using geographical features. *ISPRS International Journal of Geo-Information*, **7**(8), 298.
- 91) Mitchell, M., Brown, D., and Conklin, J. (2007) A crime forecasting tool for the web-based crime analysis toolkit. *2007 IEEE Systems and Information Engineering Design Symposium*, 1-5.
- 92) Mohler, G. (2014) Marked point process hotspot maps for homicide and gun crime prediction in Chicago. *International Journal of Forecasting*, **30**(3), 491-497.
- 93) 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.
- 94) Monmonier, M. (1997) *Cartographies of danger: Mapping hazards in America*. University of Chicago Press.
- 95) Moreto, W., and Caplan, J. (2010) Forecasting global maritime piracy utilizing the risk terrain modeling (rtm) approach. <http://www.rutgerscps.org/uploads/2/7/3/7/27370595/maritimepiracyrtm_casestudy_brief.pdf>, 2019年10月10日閲覧.
- 96) Moreto, W., Piza, E., and Caplan, J. (2014) "A plague on both your houses?": Risks, repeats and reconsiderations of urban residential burglary. *Justice Quarterly*, **31**(6), 1102-1126.
- 97) NBC NEWS MACH (2017) How Science Is Helping Stop Crime Before It Occurs. <<https://www.nbcnews.com/mach/science/how-science-helping-stop-crime-it-occurs-nca805176>>, 2019年10月7日閲覧.
- 98) Neill, D., and Gorr, W. (2007) Detecting and preventing emerging epidemics of crime. In *Proceedings of the 2007 Conference of the International Society for Disease Surveillance*. <<http://www.cs.cmu.edu/~neill/papers/crime-epidemics.pdf>>, 2019年10月7日閲覧.
- 99) Newman, O. (1972) *Defensible Space*. New York: Macmillan.
- 100) Ogata, Y. (1998) Space-time point-process models for earthquake occurrences. *Annals of the Institute of Statistical Mathematics*, **50**(2), 379-402.
- 101) Onat, I., and Gul, Z. (2018) Terrorism risk forecasting by ideology. *European Journal on Criminal Policy and Research*, **24**(4), 433-449.
- 102) 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., 5pp.
- 103) Perry, W., McInnis, B., Price, C., Smith, S., and Hollywood, J., *Ibid.*, 17-25pp.

- 104) Piza, E., Feng, S., Kennedy, L., and Caplan, J. (2017) Place-based correlates of motor vehicle theft and recovery: Measuring spatial influence across neighbourhood context. *Urban Studies*, **54**(13), 2998-3021.
- 105) Piza, E., and Gilchrist, A. (2018) Measuring the effect heterogeneity of police enforcement actions across spatial contexts. *Journal of Criminal Justice*, **54**, 76-87.
- 106) 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.
- 107) Powers, K., Hanssens, D., Hser, Y., and Anglin, M. (1993) Long-term time-series forecasting of social interventions for narcotics use and property crime. *Mathematical and Computer Modelling*, **17**(2), 89-107.
- 108) Prestemon, J., Butry, D., and Thomas, D. (2013) Exploiting autoregressive properties to develop prospective urban arson forecasts by target. *Applied Geography*, **44**, 143-153.
- 109) Rashidi, P., Wang, T., Skidmore, A., Vrieling, A., Darvishzadeh, R., Toxopeus, B., Ngene, S. and Omondi, P. (2015) Spatial and spatiotemporal clustering methods for detecting elephant poaching hotspots. *Ecological Modelling*, **297**, 180-186.
- 110) Ratcliffe, J. (2009) *Near repeat calculator (version 1.3)*. <<https://liberalarts.temple.edu/sites/liberalarts/files/NearRepeatsManual.pdf>>, 2019年10月7日閲覧.
- 111) Ratcliffe, J. (2004) The hotspot matrix: A framework for the spatio-temporal targeting of crime reduction. *Police Practice and Research*, **5**(1), 5-23.
- 112) Ratcliffe, J., Taylor, R., and Perenzin, A. (2016) Predictive Modeling Combining Short and Long-Term Crime Risk Potential: Final Report. <<https://www.ncjrs.gov/pdffiles1/nij/grants/249934.pdf>>, 最終閲覧 2019年5月8日.
- 113) Rattner, A. (1990) Social indicators and crime rate forecasting. *Social Indicators Research*, **22**(1), 83-95.
- 114) Reinhart, A., and Greenhouse, J. (2018) Self-exciting point processes with spatial covariates: modelling the dynamics of crime. *Journal of the Royal Statistical Society*. **67**(5), 1305-1329.
- 115) 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*, **12**(1), 5-25.
- 116) Rosser, G., Davies, T., Bowers, K., Johnson, S., and Cheng, T. (2016) Predictive crime mapping: Arbitrary grids or street networks? *Journal of Quantitative Criminology*, **33**(3), 569-594.
- 117) Rummens, A., Hardyns, W., and Pauwels, L. (2017) The use of predictive analysis in spatiotemporal crime forecasting: Building and testing a model in an urban context. *Applied geography*, **86**, 255-261.
- 118) Rumi, S., Deng, K., and Salim, F. (2018) Crime event prediction with dynamic features. *EPJ Data Science*, **7**, Article #43.
- 119) Seidensticker, K., Bode, F., and Stoffel, F. (2018) Predictive Policing in Germany. <<https://pdfs.semanticscholar.org/ce3e/498770939328d1325ee9de94be7222a2aa1a.pdf>>, 2019年10月10日閲覧.
- 120) Shaerpour, K., Dehghantanha, A., and Mahmood, R. (2013) A Survey On Cyber-Crime Prediction Techniques. *International Journal of Advancements in Computing Technology*, **5**(14), 52-61.

- 121) Sherman, L. (1995) Hot spots of crime and criminal careers of places. *Crime and Place*, **4**, 35-52.
- 122) Sherman, L., Gartin, P., and Buerger, M. (1989) Hot spots of predatory crime: Routine activities and the criminology of place. *Criminology*, **27**(1), 27-56.
- 123) Shiode, S., and Shiode, N. (2014) Microscale Prediction of Near - Future Crime Concentrations with Street - Level Geosurveillance. *Geographical Analysis*, **46**(4), 435-455.
- 124) Short, M., Mohler, G., Brantingham, P., and Tita, G. (2014) Gang rivalry dynamics via coupled point process networks. *Discrete and Continuous Dynamical Systems Series B*, **19**(5), 1459-1477.
- 125) Tang, Y., Zhu, X., Guo, W., Wu, L., and Fan, Y. (2019) Anisotropic Diffusion for Improved Crime Prediction in Urban China. *ISPRS International Journal of Geo-Information*, **8**(5), 234.
- 126) Thomas, S., and Drawve, G. (2018) Examining interactive effects of characteristics of the social and physical environment on aggravated assault. *Journal of Criminal Justice*, **57**, 89-98.
- 127) Townsley, M. (2008) Visualising space time patterns in crime: the hotspot plot. *Crime patterns and analysis*, **1**(1), 61-74.
- 128) 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.
- 129) Valasik, M. (2018) Gang violence predictability: Using risk terrain modeling to study gang homicides and gang assaults in East Los Angeles. *Journal of Criminal Justice*, **58**, 10-21.
- 130) Van Patten, I. T., McKeldin-Coner, J., and Cox, D. (2009) A microspatial analysis of robbery: prospective hot spotting in a small city. *Crime Mapping: A journal of research and practice*, **1**(1), 7-32.
- 131) Veloso, B., Correa, T., Prates, M., Oliveira, G., and Tavares, A. (2017) MAD-STECC: a method for multiple automatic detection of space-time emerging clusters. *Statistics and Computing*, **27**(4), 1099-1110.
- 132) Vildosola, D., Carter, J., Louderback, E., and Roy, S. (2019) Crime in an Affluent City: Applications of Risk Terrain Modeling for Residential and Vehicle Burglary in Coral Gables, Florida, 2004–2016. *Applied Spatial Analysis and Policy*, 1-19.
- 133) Vomfell, L., Härdle, W. K., and Lessmann, S. (2018) Improving crime count forecasts using Twitter and taxi data. *Decision Support Systems*, **113**, 73-85.
- 134) Wang, X., and Brown, D. (2012) The spatio-temporal modeling for criminal incidents. *Security Informatics*, **1**(1), 1-17.
- 135) Wang, X., Brown, D., and Gerber, M. (2012) Spatio-temporal modeling of criminal incidents using geographic, demographic, and Twitter-derived information. In *2012 IEEE International Conference on Intelligence and Security Informatics*, 36-41.
- 136) Wilson, J., and Kelling, G. (1982) Broken Windows: The Police and Neighborhood Safety. *Atlantic Monthly*, **March**, 29-38.
- 137) Yu, C., Ding, W., Morabito, M., and Chen, P. (2015) Hierarchical spatio-temporal pattern discovery and predictive modeling. *IEEE Transactions on Knowledge and Data Engineering*, **28**(4), 979-993.
- 138) Zhao, X., and Tang, J. (2018) Crime in Urban Areas: A Data Mining Perspective. *ACM SIGKDD Explorations Newsletter*, **20**(1), 1-12.

- 139) Zhao, X., & Tang, J. (2017) Modeling temporal-spatial correlations for crime prediction. In *Proceedings of the 2017 ACM on Conference on Information and Knowledge Management*, 497-506.

第3章 主要な地理的犯罪予測手法の実データへの適用と検証

3.1 はじめに

本章では、第2章で取り上げた主要な地理的犯罪予測手法について、各手法のうち代表的な予測モデルを選び、日本の犯罪発生情報等のデータを用いて予測を行い、その予測精度を比較・検証する。

これまで、地理的な犯罪予測に用いられる手法の比較を行った研究としては、KDEを扱ったものが多い。これには、KDEのカーネル関数をさまざまに変えて検証を行ったもの（Hart and Zandbergen, 2014）、KDEの予測対象期間を1日後～6ヵ月後といったように、さまざまに変えて検証を行ったもの（Tompson and Townsley, 2010）、STACと主題図に対し、KDEを比較しつつ、予測に用いる犯罪データの期間を変えて検証を行ったもの（Chainey et al., 2008）、STAC、最近隣法、ローカルモランI統計量KDEを比較したもの（Van Patten et al., 2009）、STAC、最近隣法、KDEを比較したもの（Levine, 2008）、主題図、LISA、Getis-Ord G_i^* 統計量によるホットスポットマップ、STAC、最近隣法、KDEを比較したもの（Hart and Zandbergen, 2012）などがある。これらの手法は、2章でふれたように、もとは予測を目的として作成されたというより、犯罪の集積の有無の確認や、具体的な集積地域を視覚化する目的で用いられてきたことが多い手法である。これに対し、現在多く用いられる典型的な予測手法を扱った Adepeju et al. (2016) は、KDE、SEPP、ProMap、PSTSSを比較している。ここまでは、犯罪データのみを依拠した方法を扱ったものだが、これら手法と環境要因を用いた手法とを比較した研究としては、STAC、Nnh、KDE、RTMを比較したもの（Drawwe, 2014）に限られる。

本分析では、2章での整理をもとに、犯罪データのみを依拠する方法と、環境要因を用いる方法を含め、さまざまな手法を比較する。手法の選定にあたっては、犯罪予測システムとして実装された実績のある手法（2章で紹介した手法のうち、4節の3項、4項、5項が該当する）を優先した。また、まずは基礎的検討として、犯罪発生情報のみを用いる手法と、環境要因を用いる手法とを比較することが必要と考え、2章4節8項で取り上げた「環境要因と犯罪の時空間相互作用とを組み合わせた予測」のようなアドバンスな手法は、対象から外した。結果として、今回は、JohnsonらのProMap、MohlerらのSEPPモデル（以下、単にSEPP）、KulldorffのPSTSS、CaplanらのRTM、WangとBrownのGAMの5手法に加え、比較対象として、従来の地理的犯罪分析で用いられてきたKDEを適用し、計6手法について分析を行う。表3-1には、手法の一覧と予測変数（何によって犯罪を予測するか）を示している。

本章の構成としては、まず、各予測モデルの概略を述べ（第2節）、次にどのような視点で評価を行うべきかを考え、指標を設定する（第3節）。その後、分析対象と方法について述べ（第4節）、分析結果、および指標に基づく評価結果（第5節）を示した上で、考察を加えつつ、日本のフィールドにおける地理的犯罪予測手法の適用可能性と限界について議論する（第6節）。

表 3-1 対象とした手法の一覧

予測モデル	略称	予測変数 (予測に用いる情報)	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		

3.2 分析手法の概略

3.2.1 KDE

カーネル密度推定 (Kernel Density Estimation, 以下 KDE) は、内挿法の一つであり、ポイントデータの分析においては、与えられた点分布から、カーネル関数を用いて強度 (単位空間あたりの点個数の期待値) の推定値を得て、平滑化された密度分布図を描く目的で用いられることが多い。任意の大きさのグリッドセルを対象領域内にもうけ、各セルについて強度推定値を算出するため、離散的な標本である点分布を連続的な面として表現することができ、事象のパターンを視覚的に捉える上で有用である。

具体的な方法としては、図 3-1 のように、領域内のグリッドセルごとに、特定のバンド幅 h をもつ半球状のカーネルを与える。各カーネルの中心地点: セル s における強度の推定値 $\lambda_{KDE}(s)$ は、 n をカーネル内のイベント総数、 S_i を各イベントとして、式 (3.1) により求められる。

$$\lambda_{KDE}(s) = \frac{1}{h^2} \sum_{i=1}^n K\left(\frac{1}{h}(s - S_i)\right) \quad (3.1)$$

ここで、 $K(\mathbf{u})$ はカーネル関数であり、与えられたバンド幅 h に応じて平滑化された密度を求める確率密度関数である。カーネル関数には、いくつかのバリエーションが提案されている。Silverman (1986) は、式 (3.2) のようなカーネル関数を提案している。これは、汎用 GIS ソフトウェア ArcGIS に実装されている「カーネル密度」ツールで採用されているものでもあるⁱ。

i Esri 社ホームページ (<https://pro.arcgis.com/ja/pro-app/tool-reference/spatial-analyst/how-kernel-density-works.htm> : 2019 年 10 月 9 日閲覧) より

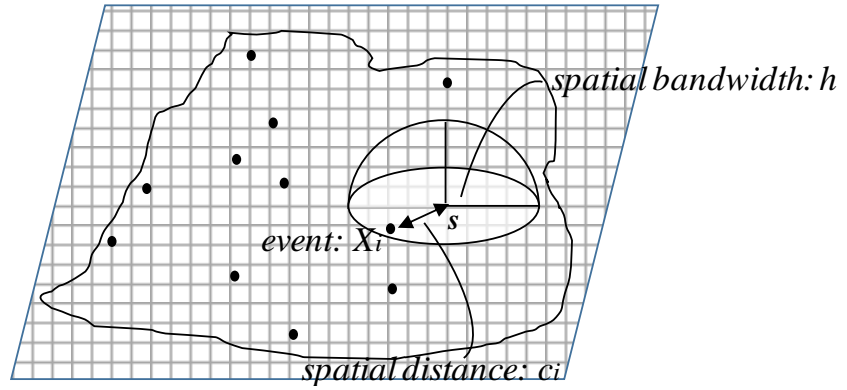


図 3-1 KDE の概念図

$$K(\mathbf{u}) = \frac{3}{\pi}(1 - \mathbf{u}^T \mathbf{u})^2 \quad (3.2)$$

ただし、 $\mathbf{u}^T \mathbf{u} < 1$ である。これを式 (3.1) に代入すれば、式 (3.3) が得られる。

$$f(s) = \sum_{i=1}^n \frac{3}{\pi h^2} \left(1 - \frac{d_i^2}{h^2}\right)^2 \quad (3.3)$$

d_i は、カーネルの中心地点 s から S_i までの距離である。なお、エッジ効果の補正は省略している。

この手法は、期間を固定して、空間的情報のみから予測を行うベーシックな手法ではあるが、犯罪の地理的分析において、ホットスポットを同定する手段として有用とされ (Anselin et al., 2000; Chainey et al., 2002; Chainey and Ratcliffe, 2005), 広く用いられてきた。一方で、前章で紹介した手法に対して、回顧的 (retrospective) として対比されるものであり (Bowers et al., 2004; Caplan et al., 2011), 予測手法の比較対象としてふさわしい手法といえる。

3.2.2 ProMap

ProMap は、第2章で述べた通り、Bowers et al. (2004) において提案された地理的犯罪予測手法で、その後、Johnson et al. (2007), Johnson et al. (2009) などで改良がなされているが、基本となるアイデアは共通している。この手法は、KDE と同様に、各セルから特定の範囲内にある点 (ここでは犯罪) との空間的隔たりを測り、強度推定値を算出するが、近接反復被害をモデリングするために、時間的な隔たりについても考慮している点に特徴がある。Johnson et al. (2009) のモデルでは、予測の対象とする犯罪 (侵入盗) の過去時点における発生地点・時点のデータを予測変数として、次の式 (3.4) を用いて、グリッドセルごとのリスク値 (risk intensity value) を求めている。

$$\lambda(s, t) = \sum_{c_i \leq \tau \cap e_i \leq \nu} \left(\frac{1}{(1 + c_i)} \right) \frac{1}{(1 + e_i)} \quad (3.4)$$

ただし、 τ は空間的なバンド幅 (KDE と同様)、 v 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、各犯罪発生地点とセル s との空間的隔たり、 e_i は、犯罪イベントの発生時期が、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。図 3-2 では、時点 t_k におけるセル s_k のリスクを推定する場合に、時空間上の点 (s_k, t_k) から時間 v (この図では期間 $t_k - t_0$)、距離 τ の円筒内に含まれる犯罪イベントを探し、各イベント i と s_k からの空間的隔たり c_i 、 t_k からの時間的隔たり e_i を求め、円筒内のすべてのイベントに対してこれを繰り返す、和をとる。これが、時空間上の点 (s, t) 、すなわち t 時点におけるセル s のリスク値になる。

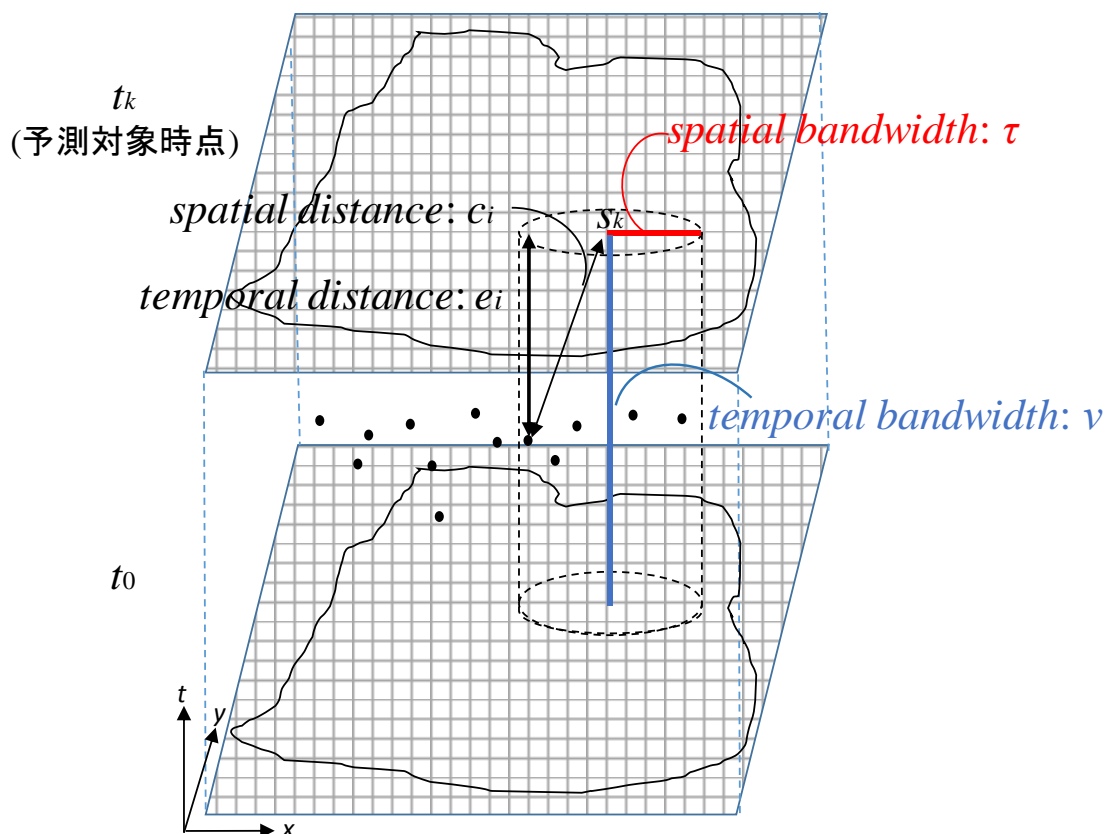


図 3-2 ProMap の概念図

c_i については、図 3-3 のように、いわゆるクイーン型の隣接関係 (queen type neighborhood) で定義される (X_1 では 0, X_2 では 1, X_3 では 2 の値が与えられる)。 e_i については、時間的な隔たりを週数でカウントし、たとえば 2016 年 6 月 1 日～2016 年 7 月 30 日の犯罪発生データをもとに、2016 年 8 月 1 日以降の犯罪発生リスクを推定する場合、個々の犯罪発生時期が、2016 年 8 月 1 日から何週間離れているかを考える。したがって、当該セルから空間的に近く、また、予測対象とする期間と近い時期に発生している犯罪が多いほど、より大きな強度推定値が得られることになる。

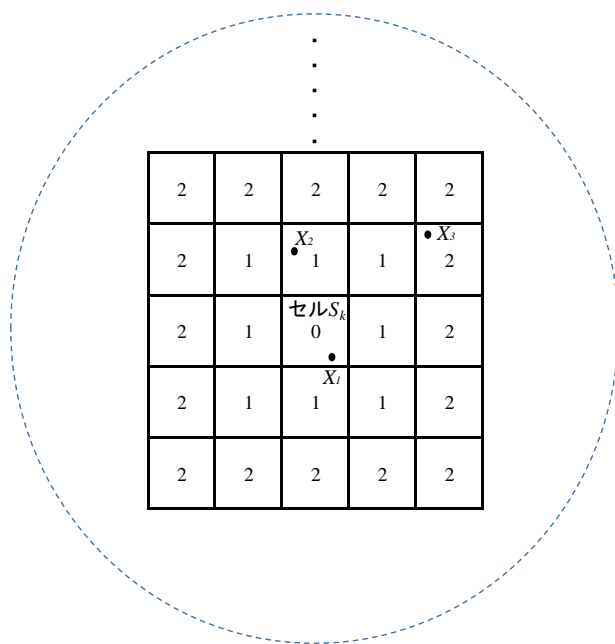


図 3-3 ProMap における c_i の与え方

3.2.3 SEPP

SEPP は、ProMap と同様に、犯罪の近接反復被害に着目し、その性質をモデルに組み込むことで予測精度を高めることを試みたものである。Mohler らが参考にした地震の時空間 ETAS モデル (Ogata, 1998) では、地震を他の地震と独立に発生する常時地震活動 (background events) と、他の地震により誘起 (trigger) される余震活動 (aftershock events) とに弁別するが、これと同様に、彼らは犯罪を時間的に定常な背景事象としての「親事象 (background events, もしくは parents)」と、これに誘発される余震事象としての「子事象 (aftershock events, もしくは offsprings)」に分けてモデリングを行った。Mohler らの犯罪予測モデルは、次式で表される。

$$\lambda(t, x, y) = v(t)\mu(x, y) + \sum_{\{k:t_k < t\}} g(t - t_k, x - x_k, y - y_k) \tag{3.5}$$

ここで、 t, x, y はそれぞれ任意の時間と空間 (XY 座標) を表す変数であり、 λ は任意の時間・空間領域における犯罪発生強度となる。 v, μ は、それぞれ空間的/時間的に定常な過程であり、 g は誘発関数、もしくは誘発効果 (triggering function, もしくは, triggering effect) と呼ばれ、 t 以前のすべての時間点 t_k における犯罪事象からの時空間的な作用を表す項となっている。 v, μ, g は、いずれも可変バンド幅を用いたカーネル密度推定 (variable bandwidth Kernel Density Estimation) を用いて推定される。カーネル関数には、ガウシアンカーネルが用いられている。第一項の $v(t)$ は、週内変動、季節間変動等々の時間依存的な成分を示しているが、しばしば省略されるⁱⁱ。実際に、Mohler 自身も、式 (3.5) を式 (3.6) に書き換えて用いることが多い (Mohler, 2015; Mohler, 2014)。

ii この効果はグローバルな (場所によらず一定な) ものとみなすことができ、一時点における犯罪発生リスクの空間的な分布状況を表現する場合、予測地図における場所間の相対的なリスクの変動に寄与しないため、これを省略する判断をしているものと考えられる。

$$\lambda(t, x, y) = \mu(x, y) + \sum_{\{k:t_k < t\}} g(t - t_k, x - x_k, y - y_k) \quad (3.6)$$

親事象と子事象を弁別するための確率論的除群化法 (stochastic declustering) についても、やはり地震学で提案された方法 (Zhuang et al., 2002) を参考にしており、最尤推定の一様である EM アルゴリズムを用いて、以下に述べる手順で行っている。まず、事象 i が親事象に属する確率を p_{ii} 、事象 i が j ($i > j$) に誘発された事象である確率を p_{ij} として、適当な初期値を決め、 $t < t_k$ におけるすべての犯罪発生データについて、 \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) を求める。次に、 \mathbf{P}_0 に基づいて親事象と親—子事象ペアを抽出し、カーネル密度推定を行った上で、以下の式で p を更新する。

$$p_{ii} = \frac{\mu(t_i, x_i, y_i)}{\lambda(t_i, x_i, y_i)} \quad (3.7)$$

$$p_{ij} = \frac{g(t_i - t_j, x_i - x_j, y_i - y_j)}{\lambda(t_i, x_i, y_i)} \quad (3.8)$$

$\mu(t_i, x_i, y_i)$ は、 $v(t_i)\mu(x_i, y_i)$ を表す。上式で求めた p_{ii} と p_{ij} を求めた行列 \mathbf{P}_n に基づいて親事象と親—子事象ペアを再度抽出、 μ 、 g を推定し、さらにこれらを用いて \mathbf{P} を更新…というプロセスを \mathbf{P} が収束するまで繰り返す。最終的に、収束した \mathbf{P} のもとで得られた μ 、 g から、式 (3.6) により強度推定値を求める。図 3-4 では、 t_1 時点における任意の犯罪イベントが、特定の親事象をもつ子事象である確率が p_{ij} となる。図の例では t_0 時点のみ示しているが、実際には、あらかじめ定めた期間内で、 t_1 より前に起きたすべてのイベントが評価される。




図 3-4 親事象と子事象のペアリングのイメージ

3.2.4 PSTSS

予見的時空間スキャン統計量 (以下、PSTSS) は、時空間スキャン統計量を応用したものであり、事象の時空間的な集積について、任意の時間的インターバルにおさまるもの (たとえば、ある程度近い過去の時点から現在まで続くもの) のみをクラスタとして検出する。これらは、新たに出現した時空間的集積 (emerging cluster) として、継続した警戒を要するとされ、近い将来の犯罪発生を予測させる。

時空間スキャン統計量は、空間的スキャン統計量を時間軸上に拡張したものであり、図 3-5 のように、時間的・空間的な広がりをもつ円筒状の領域を、大きさをさまざまに変えながら、

すべての領域（分析単位となる市区町村，町丁目，セル等）を通るように移動させ，円筒領域の内外でイベントの発生率（当該領域における単位時間あたりの発生数を人口などで除したもの），もしくは発生数を調べ，尤度比を求め，統計量を算出し，統計的検定にかける．

この検定は，スキャン統計量の帰無仮説，すなわち「観測された発生率（発生数）の差はすべて偶然によるもの」と，対立仮説「少なくとも1つの有意な円筒領域が存在する」について調べるもので，帰無仮説を正しいとした場合の統計量の分布（ランダムにイベントを発生させたデータセットから，統計量を計算することを複数回繰り返すことで得る）に対して，観測された統計量以上の値が得られる確率（ p 値）を返す．Cheng and Adepeju (2013), Adepeju et al. (2016) は，犯罪予測のための PSTSS として，時空間順列スキャン統計量（space-time permutation scan statistic : Kulldorff et al., 2005）を用いている．低頻度事象のカウントデータに適用されるスキャン統計量としてのポアソンモデルと比較して，時空間順列スキャン統計量では，人口あたりリスク（発生率）を扱わず，したがって犯罪における潜在的被害対象の数を必要としない．いくつかの犯罪では，潜在的被害対象の数をあらかじめ取得することが難しいことから，Cheng and Adepeju (2013) はこの方法を採用している．

任意の円筒領域 A における犯罪イベントの観測度数を c_A ， A の下位領域（分析単位） a での期間 t における犯罪イベントの観測度数を $c_{a,t}$ ，さらに対象領域全体・全期間での観測度数を $C = \sum_a \sum_t c_{a,t}$ とすると，任意の a, t における期待度数 $\mu_{a,t}$ ， A における期待度数 μ_A は，それぞれ式 (3.9)，式 (3.10) のように表せる．

$$\mu_{a,t} = \frac{1}{C} \left(\sum_a c_{a,t} \right) \left(\sum_t c_{a,t} \right) \tag{3.9}$$

$$\mu_A = \sum_{(a,t) \in A} \mu_{a,t} \tag{3.10}$$

式 (3.9) における $\mu_{a,t}$ は，二変量の独立性を検討する場合の χ^2 検定における $a \times t$ 分割表の各セルの期待値に相当する．イベントの発生が，時空間的に独立であるとき，観測度数 c_A は，期待値 μ_A の超幾何分布にしたがう．Kulldorff et al. (2005) では，ポアソン近似による一般化尤度比（GLR : Generalized Likelihood Ratio, 式 (3.11)）を用いている．

$$GLR = \left(\frac{c_A}{\mu_A} \right)^{c_A} \left(\frac{C - c_A}{C - \mu_A} \right)^{(C - c_A)} \tag{3.11}$$

このように，時空間順列スキャン統計量では，観測度数について，時間と空間それぞれの周辺度数をもとに算出した期待値との比をとることで，イベントの発生が時空間的に独立な場合と比較しており，時空間的な相互作用を検出するモデルとなっている（Kulldorff et al., 2005）．そのため，たとえば特定の一週間の間に，通常の2倍程度のイベントが観測されたとしても，それが関心のある領域全体で起こっていた場合，クラスタは検出されない（Kulldorff, 2015）．

PSTSS では，さらに，優先的な警戒が必要なクラスタを特定するために，適当な閾値を設け，時空間スキャン統計量で検出したクラスタの中で，最終的な観測時点（図 3-5 の t_2 ）により近いものを選別する．犯罪予測研究では，これを将来の犯罪発生を予測するものと解釈して適用している．

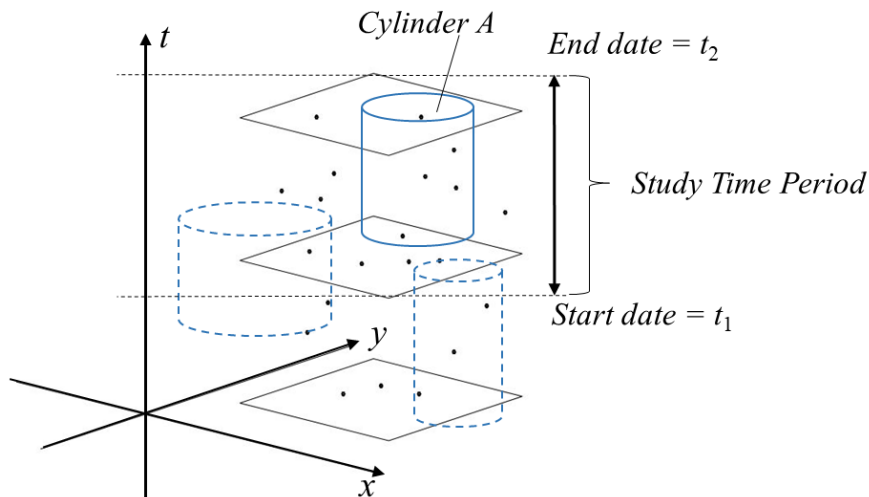


図 3-5 時空間スキンの概念図

3.2.5 RTM

RTM は、予測対象となる犯罪の情報を用いずに、他のイベントの発生や、物理構造的な要因（犯罪生成・誘引要因）をもとに犯罪の予測を行う。なお、ここで紹介する RTM とは、2章4節5項で取り上げた RTMDx ではなく、Caplan et al. (2011) ではじめて採用されたオリジナルの RTM である。本章以降では、特に断りのない限り、RTM と書く場合はオリジナルの RTM を指す。

Caplan et al. (2011) では、各ポイントデータから、カーネル密度推定によって強度を推定した後で、これを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+1SD 未満, 2: 平均+2SD 未満, 3: 平均+2SD 以上）し、再定義された密度分布図をすべてウェイト値1をかけて重ね合わせた上で、0~9 の離散値をもったリスク面を得る。地点（セル） s で得られる強度推定値は、次式のように表すことができる。

$$\lambda_{RTM}(s) = \sum_{k=1}^n w_k \hat{\lambda}_k(s) \tag{3.12}$$

w_k は、変数 k に与えられる重み付けを表す。

なお、上で述べた手順は、すべて標準的な GIS ソフトウェアで実行可能であり、ArcGIS では図 3-6 のようなステップで表すことのできるシンプルな手法である。

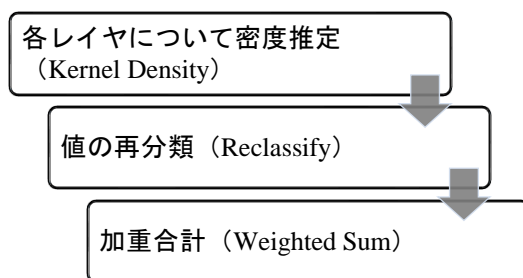


図 3-6 RTM の実行手順、および ArcGIS 上でのコマンド

3.2.6 GAM

このモデルは、ここまで紹介してきた手法と異なり、点分布の集積を直接扱わない。代わりに、予測対象のセルごとに、式 (3.13) で示すような「ある期間のうち、犯罪が1件以上発生する」確率を算出する。

$$p(N_{s_i,t_j} \geq 1 | \mathbf{X}_{s_i,t_j}) \quad (3.13)$$

s_i は空間的な位置 (セル), t_j は時間軸上の位置 (特定の時点), N_{s_i,t_j} は犯罪イベントの件数をそれぞれ指す。また, \mathbf{X}_{s_i,t_j} は s_i, t_j における物理構造的, あるいは社会経済的環境を表す。すなわち, 上式は, 所与の環境のもとでの犯罪の発生しやすさについての確率といえる。Wang and Brown (2012) では, これを次のようにロジスティック加法モデルで予測する。

$$\text{logit} [p(N_{s_i,t_j} \geq 1)] = \sum_{n=1}^N f_n(\mathbf{x}_{n,s_i,t_j}) + \kappa_{s_i,t_j} \quad (3.14)$$

\mathbf{x}_{n,s_i,t_j} は s_i, t_j における周辺環境, すなわち予測変数 n によって形成される特性値行列であり, f_n はその非線形変換である。 κ_{s_i,t_j} は, 直近の犯罪からの時間的隔たりを表すダミー変数であり, 直近の犯罪がより過去に起こっているほど, 値が大きくなるように設定される。

彼らは, 住居侵入を予測するために, 予測変数として, 最寄りの「大学」・「K-12 スクール (小中高一貫校)」・「道路」・「高速道路」・「零細企業」までの距離という物理構造的環境にかかわる変数, および, 国勢調査区単位で集計された地区ごとの「住宅価格の中央値」, 「男性人口」, 「配偶者と死別した人の数」, 「配偶者と離婚した人の数」, 「持ち家世帯数」, 「住宅賃料の中央値」という社会経済的環境にかかわる変数を設定している。

3.3 評価指標

3.3.1 予測の正確性

ここまで, 本分析で検証を行う具体的な地理的犯罪予測手法についてみてきた。本項, および次項では, これらの手法を評価する上で, 特に実務への適用を前提とした際に必要とされる特性について考え, 指標として定める。

予測手法のパフォーマンスを評価する上で, まず見るべきは, どの程度実際の犯罪発生を予測できていたか, という点であろう。予測モデルにより将来における高リスク領域, あるいは犯罪が集積しうるエリアとして判定された場所で, どれだけ実際の犯罪が起きていたのかを最初に確かめる必要がある。これは, 予測的中率 (Hit rate) といえることができ, 式 (3.15) に示すように, 予測対象時点より後に発生したすべての犯罪件数: N に対して, 予測手法でハイリスクと判定されたエリアに含まれていた (≡モデルにより予測できていた) 犯罪件数: n の比をとることで得られる。

$$\text{Hit rate} = \frac{n}{N} \quad (3.15)$$

一方で、的中率は、高リスク領域の面積が大きいほど値が増加するため、予測の精度を測る指標としては不十分といえる（極端な例を挙げれば、対象領域をすべて高リスク領域と判定した場合、的中率は1となる）。これについては、Chainey et al. (2008) で考案された、式(3.16)のように、的中率を面積率（対象地全体に占める予測された高リスク領域の割合）で除すことで得られる PAI (Prediction Accuracy Index) を同時に見ることで、高リスク領域が広がりすぎて、実務上の有用性が下がる結果となるのを避けることができる。

$$PAI = \frac{\frac{n}{N}}{\frac{a}{A}} \tag{3.16}$$

a は、高リスクとして判定された領域の面積、 A は、予測対象領域の総面積を表す。たとえば、全体の10%の領域で10%の犯罪を予測できているとき、PAIは1となる。少なくとも1を上回るかどうかで、予測の成否を判断できる。地理的犯罪予測研究では、これらの中率と PAI の2つを見ることで、予測の正確さの指標として多用される。よって、本分析でもこれらの指標を用いることとする。

3.3.2 予測の安定性

的中率や PAI で測った予測の正確性は、予測対象時期にかかわらず、一定程度の高さを示すことが望ましいだろう。ある月では正確だが、別の月では不正確ということがなく、安定した予測が行えることが、実務上でも求められると考えられる。こうした予測の安定性については、月ごとの予測精度（的中率、PAI）の標準偏差を算出すると同時に、Levine (2008) で提案された RRI (Recapture Rate Index) を計算した。RRI は、当期（ここでは予測対象月）の PAI と、直前期（ここでは一月前）の PAI の比で表され、予測の安定性を示す指標として用いることができる (Drawve, 2016)。RRI は1に近いほど前期と似た予測精度であることを意味する。RRI は月ごとに算出される値であるため、全体を要約するために、RRI そのものの値とともに、1との差の二乗平均平方根（各月の RRI と1との差の二乗を足し上げ、それを5で除して平方根をとる）も同時に見た。この値は、小さいほどモデルの予測精度が安定していることを示す。

3.3.3 予測領域のコンパクトさ

予測手法の実務への適用場面としては、警察官が行うパトロール経路の最適化、街灯の設置、環境改善といった中長期的な防犯対策を行うエリアの決定、などといったものが考えられる。施策を行う側が投入できる資源は、通常限られているため、予測によって高リスク領域として示される範囲の大きさは、それ自体が、実用性を評価する上で、重要な指標となりうる。そのため、前項で言及した a 、および a/A についても、手法間で評価を行うこととする。

また、同時に、予測されるハイリスクの大きさだけでなく、それらがたがいに連坦しつつ、どの程度コンパクトにまとまっているかも、効率的な介入を行う上で重要となるだろう。そこで、先行研究で用いられている指標から、Clumpiness Index (以下 CI) を用いてこれを評価する。CI の算出にあたっては、まず、対象領域を、予測によりハイリスクと判定された領域（仮に、クラス1とする）と、そうでない領域（クラス2とする）に二分する。その上で、図3-8に示すように、クラス1に属するセルどうしの隣接エッジ（黒実線部）の数を $g_{1,1}$ 、クラス1に属するセルとクラス2に属するセルどうしの隣接エッジ（青太線部）の数を $g_{1,2}$ と

して、カウントした上で比をとり $G_1 = g_{1,1} / (g_{1,1} + g_{1,2})$ を計算する。この例では、 $g_{1,1} = 83$ 、 $g_{1,2} = 48$ 、 $G_1 = 0.634$ となる。次に、クラス1のセル数を、領域全体のセル数で除し、 P_1 とする。この例では、 $P_1 = 52 / 529 = 0.098$ となる。最後に、式 (3.17) に示す計算を行うことで、CI が得られる。なお、図 3-7 の例では、CI は、0.594 と、比較的高い値を示している。

$$CI = \begin{cases} \frac{G_1 - P_1}{1 - P_1}, & G_1 < P_1; P_1 \geq 0.5, \text{ or } G_1 \geq P_1 \\ \frac{G_1 - P_1}{P_1}, & \text{otherwise} \end{cases} \quad (3.17)$$

CI は、-1 (チェッカーボードのように、要素がすべてばらばらに分裂している状態) から 1 (全領域が一つのクラスにまとまっている状態) の値をとるため、解釈が容易であり、また、比をとる手法であるため、PAI と同様に、対象領域のサイズに左右されず、手法間の結果を比較することが出来る (Adepeju et al., 2016)。

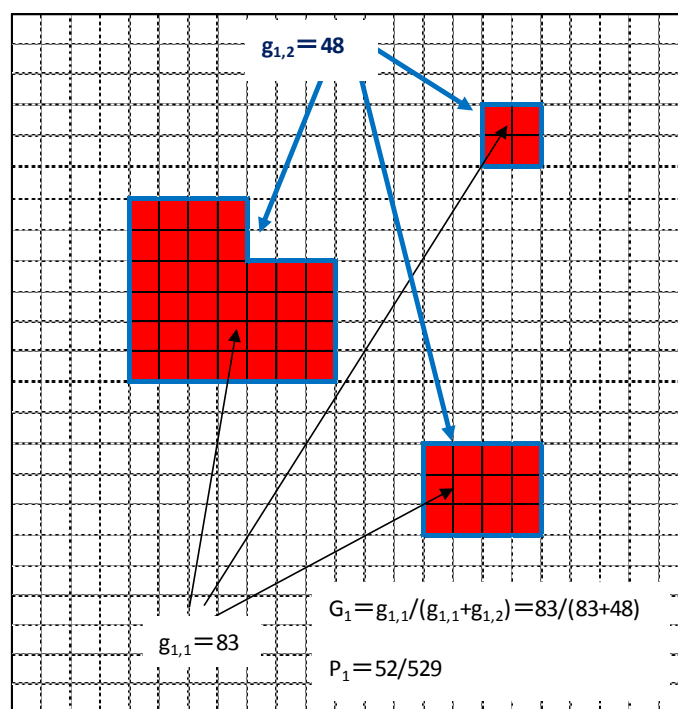


図 3-7 CI 算出例

3.4 方法

3.4.1 分析対象、および使用したデータ

今回の分析対象とした地域は、福岡県のある都市における、駅とビジネス街、繁華街を含む中心市街地エリアであり、地域内には 53 の町丁目を含んでいる。総面積は約 5.5 km²、2010 年時点の人口は 54789 人であった。なお、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ⁱⁱⁱ。

iii 福岡県警による街頭防犯カメラシステムの運用は、犯罪予防や犯罪発生時の早期解決を

応答変数（すなわち、予測の対象）として用いたデータは、対象地域内で2014年7-12月に発生した、車上狙い、および部品狙い（以下、車上狙い等）計47件である。車上狙いは、菊池ら（2010）により、近接反復被害の傾向が確かめられている罪種であり、今回の検証にふさわしいものとして選んだ。データは、番地以下のレベルでジオコーディングがなされたポイントデータであり、犯罪発生の日時情報を有している。なお、この2つの罪種をあわせて用いたのは、両者とも、所有者が車両から数十分以上の時間離れた隙に、犯行が行われる類の犯罪であり、発生場所や多発地域の特性が似通っている可能性が高いことによる。

ちなみに、分析対象地域の犯罪発生水準を東京都の繁華街エリアと比較すると、表3-2のようになる。比較対象とした東京都内6地区は、今回の分析対象地域と同様に、警視庁による街頭防犯カメラ設置地区となっている^{iv}。分析対象地域の車上狙い等の犯罪発生水準は、一般的な繁華街エリアと同程度の水準にあるといえる。なお、海外の都市との比較では、シカゴの中心市街地エリア（面積9.7 km²）の2014年における同等の罪種の犯罪発生件数は435件、面積あたりでは44.8件 / km²となっており^v、これと比較すると、3分の1程度の水準である。

-
- 目指して、福岡県内の7つの地域で、2012~2013年から運用が開始された（<http://www.police.pref.fukuoka.jp/seian/seian/camera/kamerasystem.html>：最終閲覧日2019年10月15日）。
- iv 警視庁では、繁華街等の防犯対策の一環として、街頭防犯カメラシステムを新宿区歌舞伎町地区（2002年2月27日運用開始）、渋谷区渋谷地区（2004年3月22日運用開始）、豊島区池袋地区（2004年3月24日運用開始）、台東区上野2丁目地区（2006年2月15日運用開始）、港区六本木地区（2007年3月20日運用開始）、墨田区錦糸町地区（2013年3月23日運用開始）の6地区に設置している（<http://www.keishicho.metro.tokyo.jp/kurashi/anzaen/anshin/gaitocamera.html>：最終閲覧日2019年10月15日）。表3-2において車上狙い等の発生件数、および地区面積を算出するにあたっては、新宿区歌舞伎町地区については、新宿区歌舞伎町1~2丁目を、渋谷区渋谷地区については、渋谷区渋谷1~4丁目を、豊島区池袋地区については、豊島区池袋1~4丁目を、台東区上野2丁目地区については、台東区上野2丁目を、港区六本木地区については、港区六本木1~7丁目を、墨田区錦糸町地区については、墨田区錦糸1~4丁目を、それぞれ合算した。犯罪発生データについては、大東京防犯ネットワーク（<https://www.bouhan.metro.tokyo.lg.jp/>：最終閲覧日2019年10月15日）の「町丁字別犯罪情報」から、平成26年のデータを、面積は、平成22年国勢調査（小地域）のデータをそれぞれ用いている。
- v データは、“City of Chicago Data Portal（<https://data.cityofchicago.org/>：最終閲覧日2016年12月30日）”より、2014年の犯罪発生情報（Crimes - 2014）より、罪種（Primary Type）を「窃盗（theft）」、場所詳細（Location Description）を「非商用の乗用車（VEHICLE NON-COMMERCIAL）」：1469件、「商用の乗用車（VEHICLE-COMMERCIAL）」：135件、「駐車場／ガレージ（PARKING LOT/GARAGE（NON.RESID.））」：2508件に限定した上で、データをダウンロードした。さらに、上記3つのデータから、詳細（Description）から“ATTEMPT THEFT”，“DELIVERY CONTAINER THEFT”，“FROM BUILDING”，“POCKET-PICKING”，“PURSE-SNATCHING”，“RETAIL THEFT”を除き、それぞれ1454件、133件、2428件を得た。これらをマージした上で、緯度経度情報をもとにArcGIS上にプロットした。また、同ポータルサイトより、シカゴ市中心業務地区（Boundaries - Central Business District）のshpファイルをダウンロードして、ArcGIS上に表示した上で、空間検索により、犯罪発生地点情報を同エリアに絞り、計435件を得た。

表 3-2 分析対象地域の車上狙い等発生件数, および他地域との比較

地区名	2014年 車上狙い等 発生件数 (件)	地区面積 (km ²)	1km ² あたり 発生件数 (件 / km ²)
福岡県分析対象地区	87	5.50	15.8
台東区上野2丁目地区	1	0.05	21.7
墨田区錦糸町地区	7	0.34	20.6
新宿区歌舞伎町地区	7	0.35	20.1
豊島区池袋地区	10	0.76	13.1
港区六本木地区	9	1.20	7.5
渋谷区渋谷地区	4	0.69	5.8

予測変数として用いたデータは, KDE, ProMap, SEPP, PSTSS では, 応答変数と同一のエリアにおいて, 予測対象時点より過去の6ヵ月間に発生したもののポイントデータである.

図 3-8 には, 2014 年の各月における車上狙い等の犯罪発生件数を示した. 月単位での発生件数の平均は 7.3 件, 標準偏差は, 2.9 件である. また, 図 3-9 には, 対象地域の概形を示している. なお, アドレスマッチングの精度は, Match Lv.6 (号レベル) が 65 件 / 87 件, Match Lv.5 (番レベル) が 22 件 / 87 件という結果であった.

分析にあたっては, 同対象地域に 25 m × 25 m のグリッドセル^{vi}を設定し, 基本的にこれを単位として集計, あるいは強度推定値の算出などを行った.




図 3-8 2014 年における車上狙い等の月別発生状況




図 3-9 対象地域

vi セルサイズの設定にあたっては, Chainey and Ratcliffe (2005) を参考として, 対象地域全体矩形領域で囲ったときの短辺の長さを 150 で割った値とした.

RTMの適用にあたっては、車上狙い等と関連する物理構造的環境要因を選定する必要がある。当該の罪種の発生状況に関する分析研究は少ないが、イギリスのデータを分析したClarke and Mayhew (1998)では、公共の駐車場、その他道路上、職場近くの道路上、家の外の道路上、の順で発生率が高いことを示している。そこで、RTMの予測変数として、株式会社ゼンリン「Zmap-AREA II (2014-3版)」より、「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6種の施設のポイントデータ、そして「道路」および「細道路」(以下、まとめて「道路全体」)のラインデータを抽出して用いた。被害対象である車両が、所有者がある程度の時間そこから離れた状態で停められているという状況が起こりうる場所、すなわち、車上狙い等の犯罪生成・誘引要因として、上記の変数を用いるのは合理的と思われる。ただし、最終的には後述の手続きを経て変数を絞り込み、「駐車場」、「コンビニエンスストア」、「道路全体」のデータのみを分析に用いている。

GAMについては、社会経済的環境要因として、平成17年、および平成22年の国勢調査から、a.「民営借家数」(「民営借家」が該当)、b.「中高層世帯数」(「共同住宅3~5階建」、および「共同住宅6~10階建」の2つを足し上げたもの)、c.「単身世帯数」(「世帯人員1人」)、平成18年の事業所・企業統計調査、および平成21年の経済センサスから、d.「飲食業、宿泊業事業所数」の4変数を用いた。変数a, b, cについては、犯行の行いやすさにかかわると考えられる地区の匿名性の高さ、居住の不安定性といった特性の代理変数として設定している。dは、高い犯罪発生水準が予想される駅前や繁華街エリアを表す変数として設定した。なお、GAMでは、RTMと同様の物理構造的環境要因を用いた場合の予測も試した。このときの予測変数は、RTMと同じく「駐車場」、「コンビニエンスストア」、「道路全体」とした。

3.4.2 具体的な適用方法

まず、予測の対象期間(どの程度先の将来までを予測するか)と検証方法について述べる。KDE, ProMap, SEPP, PSTSSでは、先行研究でも、日単位、週単位、月単位といった比較的近い将来を予測する目的で用いられているため、今回は6ヵ月分のデータ^{vii}から、次の1ヵ月を予測すること(1-6月データ→7月を予測、2-7月データ→8月を予測、・・・、6-11月データ→12月を予測)を繰り返し、評価指標を各回で算出した上で、その平均をとることで検証を行っている。RTM, GAMについては、予測変数として用いるデータが短期的に変動しない性質のものであるため、一時点におけるデータをもとに予測を行った結果を用いて、各月の評価指標を算出した。いずれの予測モデルでも、テストデータは7~12月のデータであった。

次に、予測手法ごとの具体的な分析方法について説明する。

KDEの分析にあたっては、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式(3.2)を用いた。バンド幅の設定にあたっては、1-6月~7-12月の6期分のデータごとに平均最近隣距離を算出した。バンド幅圏内に含まれる点の個数が少なすぎると、密度推定が不安定になると考え、6期の平均最近隣距離の最大値である248.7mに近い値として、250mを採用した。セルサイズは、前項で述べた通り25m四方とした。強度推定値は、このセルごとに算出され、以下すべての手法で同一である^{viii}。

vii Caplan et al. (2011)では、RTMの結果をKDEと比較しており、その際KDEの予測変数となる過去の犯罪データの期間を6ヵ月と設定している。本研究も、犯罪データのみを用いて予測するKDE, ProMap, SEPP, PSTSSでは6ヵ月の犯罪データを用いて予測を行った。

viii 強度推定値の分類における水準の設定は、Caplan et al. (2011)に倣った。

ProMap については、バンド幅とセルサイズは、KDE と同様の設定とした。式 (3.4) における c_i の与え方については、図 3-3 のようなスコアリングは行わず、近似的な方法として、図 3-10 のようにグリッドセルの一边の長さの半分の半径とした円（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（図の例では、 X_1 は 0、 X_2 は 1、 X_3 は 2 の値を付与）。なお、 e_i については、先行研究（Bowers et al., 2004; Johson et al., 2007; Johson et al., 2009）と同じく、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。




図 3-10 本分析での ProMap における c_i の与え方

SEPP については、2 節 3 項で示した式 (3.6) を用いた。各パラメータの推定について、単独の文献では、詳細な方法が述べられていない場合があったため、Mohler ら自身による研究（Mohler, 2011; Mohler, 2014）のほか、Mohler が SEPP をもとに考案した事象予測システム（Event Forecast System）の特許情報（Mohler, 2015）、また、SEPP を修正したモデルを提案した研究（Rosser and Cheng, 2016）を参考にした。

任意の時空間上の点における犯罪発生の強度は、次の式で推定した。

$$\lambda(t, x, y) = \sum_{\{k:t_k < t\}} \mu(x - x_k, y - y_k) + \sum_{\{k:t_k < t\}} g(t - t_k, x - x_k, y - y_k) \quad (3.18)$$

ただし、 $t - t_k$ は、予測対象時点と過去の各犯罪発生時点との時間差を表し、 $x - x_k$ と $y - y_k$ は、予測対象セルと過去の各犯罪発生地点の x , y 座標の差を表す。

また、 μ と g は下記の式 (3.19) と式 (3.20) を用いて算出した。

$$\mu(x, y) = \frac{\alpha}{T} \sum_{t_i < t} \frac{1}{2\pi\eta^2} \times \exp\left(-\frac{(x - x_i)^2 + (y - y_i)^2}{2\eta^2}\right) \quad (3.19)$$

$$g(t, x, y) = \theta \omega \exp(-\omega(t - t_i)) \times \frac{1}{2\pi\sigma^2} \exp\left(-\frac{(x - x_i)^2 + (y - y_i)^2}{2\sigma^2}\right) \quad (3.20)$$

ここで、 α , η^2 , θ , ω , σ^2 は、以下の式 (3.21) ~ (3.25) より求めた。

$$\alpha = \frac{\sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij}^b \mathbf{1}}{N_i} \quad (3.21)$$

$$\eta^2 = \frac{\sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij}^b ((x - x_i)^2 + (y - y_i)^2)}{2 \sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij}^b} \quad (3.22)$$

$$\theta = \frac{\sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij} \mathbf{1}}{N_j - \sum_{j=1}^{N_j} \exp(-\omega(T - t_j)) \mathbf{1}} \quad (3.23)$$

$$\omega = \frac{\sum_{i < j} p_{ij}}{\sum_{i < j} (t_j - t_i) p_{ij}} \quad (3.24)$$

$$\sigma^2 = \frac{\sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij} ((x - x_i)^2 + (y - y_i)^2)}{2 \sum_{i=1}^{N_i} \sum_{j=1}^{N_j} p_{ij}} \quad (3.25)$$

上記の式において、 p_{ij} は、イベント i (子事象) がイベント j (親事象) に誘起される確率を表し、 p_{ij}^b は、イベント i (子事象) が他のイベントと独立に生起する確率を表す。 ω と σ^2 は誘発関数に用いられる。式 (3.26) にしたがって p_{ij} を初期化 (ここでは、 $\alpha=1.5$, $\beta=500$ として設定した) し、確率行列 \mathbf{P}_0 (上三角行列) を求め、これらの値に基づいて、EM アルゴリズムにより、親—子事象ペアを特定した。

$$p_{ij} = \exp(-\alpha(t_j - t_i)) \exp\left(-\frac{(x_j - x_i)^2 + (y_j - y_i)^2}{2\beta^2}\right) \quad (3.26)$$

式 (3.21) ~ (3.25) に基づいて各パラメータを算出した後、式 (3.27) にしたがって p_{ij} を更新し、このプロセスを $\|\mathbf{P}_n - \mathbf{P}_{n-1}\|$ が 1×10^{-7} を下回るまで反復した。

$$p_{ij} = \theta \omega \exp(-\alpha\omega(t_j - t_i)) \times \frac{1}{2\pi\sigma^2} \exp\left(-\frac{(x_j - x_i)^2 + (y_j - y_i)^2}{2\sigma^2}\right) \quad (3.27)$$

上記の計算にあたっては、統計解析環境 R (ver. 3.3.0) を用い、関数を作成して用いた。

PSTSS については、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。分析には、時空間順列スキャン統計量を用い、

空間的集積の閾値(走査する円形領域の最大値)を 250 m, 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 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、回帰分析を実行し、その結果をもとに変数を選定した。回帰分析では、前項で述べた施設立地のポイントデータ、および「道路全体」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月から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応答変数とする負の二項回帰分析を実行した。ここでの予測変数となる施設等の分布状況は、短期的には変動しないものであり、それらが犯罪(車上狙い等)に対してもつ効果も、時間的に安定的なものと考えられる。そのため、今回は応答変数に用いる犯罪データの期間をできるだけ長く(利用可能な全ての期間)設定した。応答変数に用いた車上狙い等の件数は、1,257件となった。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。結果は、表 3-3 の Model 1 の示す通りとなり、このうち、回帰係数が有意であったもののみを独立変数として、再度負の二項回帰分析を実行した(Model 2)。結果として、「駐車場」、「コンビニエンスストア」、「道路全体」を予測変数として採用した。回帰分析の実行には、IBM 社の SPSS (ver.22) を用いた。RTM そのものの実行にあたっては、ArcGIS10.3 を用いて、上記 3 変数について KDE を行い、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+1SD 未満, 2: 平均+2SD 未満, 3: 平均+2SD 以上)、その後、回帰分析で得たオッズ比をウェイト値として加重合計した。

なお、RTM については、ソフトウェア RTMDx も利用してリスク算出を試みたが、今回のデータでは、すべての予測変数がステップワイズで除外される結果となった。そのため、今回は RTMDx ではなく、Caplan et al. (2011) の方法に基づく RTM のみで予測を行った。

表 3-3 負の二項回帰分析結果

	Model 1				Model 2			
	推定値	p 値	95% Wald 信頼区間		推定値	p 値	95% Wald 信頼区間	
			下限	上限			下限	上限
切片	0.874	0.000 ***	0.759	0.989	3.088	0.000 ***	2.969	3.206
駐車場	0.208	0.000 ***	0.092	0.324	0.221	0.005 **	0.067	0.374
公園	0.048	0.310	-0.044	0.140	-	-	-	-
ファミリーレストラン, およびファーストフード店	-0.009	0.933	-0.230	0.211	-	-	-	-
コンビニエンスストア	0.127	0.061 †	-0.006	0.261	0.196	0.000 ***	0.098	0.294
喫茶チェーン店	0.119	0.162	-0.048	0.285	-	-	-	-
デパート, およびスーパーマーケット	-0.103	0.148	-0.244	0.037	-	-	-	-
道路総延長	-0.226	0.001 **	-0.358	-0.094	0.147	0.048 *	0.001	0.293

AIC Model 1: 400.107, Model 2: 398.484

Note. ***: $p < 0.001$, **: $p < 0.01$, *: $p < 0.05$, †: $p < 0.1$

GAMについては、前項で述べた「民営借家数」、「中高層世帯数」、「単身世帯数」、「飲食業、宿泊業事業所数」の4つの予測変数について、2005年国勢調査、および2006年事業所・企業統計調査から抽出した当該地域の町丁目ごとの集計データを、セルに按分（町丁目ごとの集計値を各町丁目に含まれるセル数で除し、その値をセルの属性値とする）したものを予測変数とし、また、2007年の車上狙い等484件をセル単位で集計、年に1件以上発生が確認されたセルについて1を、そうでない場合0を与えたものを応答変数とし、これらをモデル構築用のトレーニングデータとした。その後、Rのmgcvパッケージを用いて、ロジスティック加法モデルを構築した。パラメータ推定方法は、GCV（Generalized Cross Validation）である。分析結果を表3-4に示す。4つの予測変数を含むModel 1では、「中高層世帯数」のp値が高かったため、これを除いたモデルを最終とした。表中の切片については、Model 1、Model 2のそれぞれ一列目で推定値、二列目でZ値を示している（4つの予測変数についてはそれぞれ自由度推定値、 χ^2 値）。また、GAMによる予測を実行するにあたっては、2010年国勢調査、および2009年経済センサスから抽出した町丁目ごとの集計データを、セルに按分したものを予測変数として用いた。なお、Wang and Brown（2012）では、過去の犯罪発生時点からのインターバルを表す κ を用いているが、今回のデータでは、セル単位でみると、ほとんどのセルで $\kappa=0$ となること、また、過去に犯罪が発生した時点から離れるほど、将来の犯罪発生リスクが高まるという考えは、近接反復被害理論とは逆のモデリングであり、既存の犯罪学理論と対立するものであるため、本分析では採用していない。これにより、GAMは予測変数に犯罪発生情報を含めないものとなっている。また、表3-5には、RTMのModel 2と同じ変数でGAMを実行した結果を示す。駐車場を除きp値が高いが、RTMとの比較のために3つの変数をそのままモデルに含めて予測を行った。

表 3-4 ロジスティック加法回帰（社会経済的要因）の結果

	Model 1			Model 2		
	自由度推定 値(切片は 推定値)	χ^2 値 (切片はZ 値)	p値	自由度推定 値(切片は 推定値)	χ^2 値 (切片はZ 値)	p値
切片	-3.500	-54.210	0.000 ***	-3.502	-53.710	0.000 ***
民営借家数	1.005	4.670	0.031 *	1.010	4.920	0.027 *
中高層世帯数	1.001	1.685	0.195			
単身世帯数	3.279	15.047	0.005 **	3.390	19.480	0.001 **
飲食業、宿泊業事業所数	3.390	17.064	0.002 **	3.553	22.850	0.000 ***

※独立変数は、すべて標準化した値を用いた。

AIC Model1: 2779.734, Model2: 2778.639

Note. ***: $p < 0.001$, **: $p < 0.01$, *: $p < 0.05$, †: $p < 0.1$

表 3-5 ロジスティック加法回帰（物理構造的要因）の結果

	自由度推定 値(切片は 推定値)	χ^2 値 (切片はZ 値)	p値
切片	-3.747	-51.080	0.000 ***
駐車場	1.004	14.756	0.000 ***
コンビニエンスストア	1	0.731	0.393
道路	1.001	1.621	0.203

AIC: 1883.953

Note. ***: $p < 0.001$, **: $p < 0.01$, *: $p < 0.05$, †: $p < 0.1$

3.5 結果

3.5.1 予測結果

ここでは、各手法で予測を行った結果としての、予測地図を示した上で、前節で設定した指標に基づいて、それぞれを評価した結果について述べる。

まず、KDE、ProMap、SEPPの6回分の予測結果を示す(図 3-11, 図 3-12, 図 3-13)。

なお、すべての予測地図では、それぞれの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。本分析では、この上位3ランクを「予測された高リスク領域」とみなす。なお、車上狙い等が実際に発生した地点は、データ提供元である福岡県警との取り決めにより、表示を差し控える。

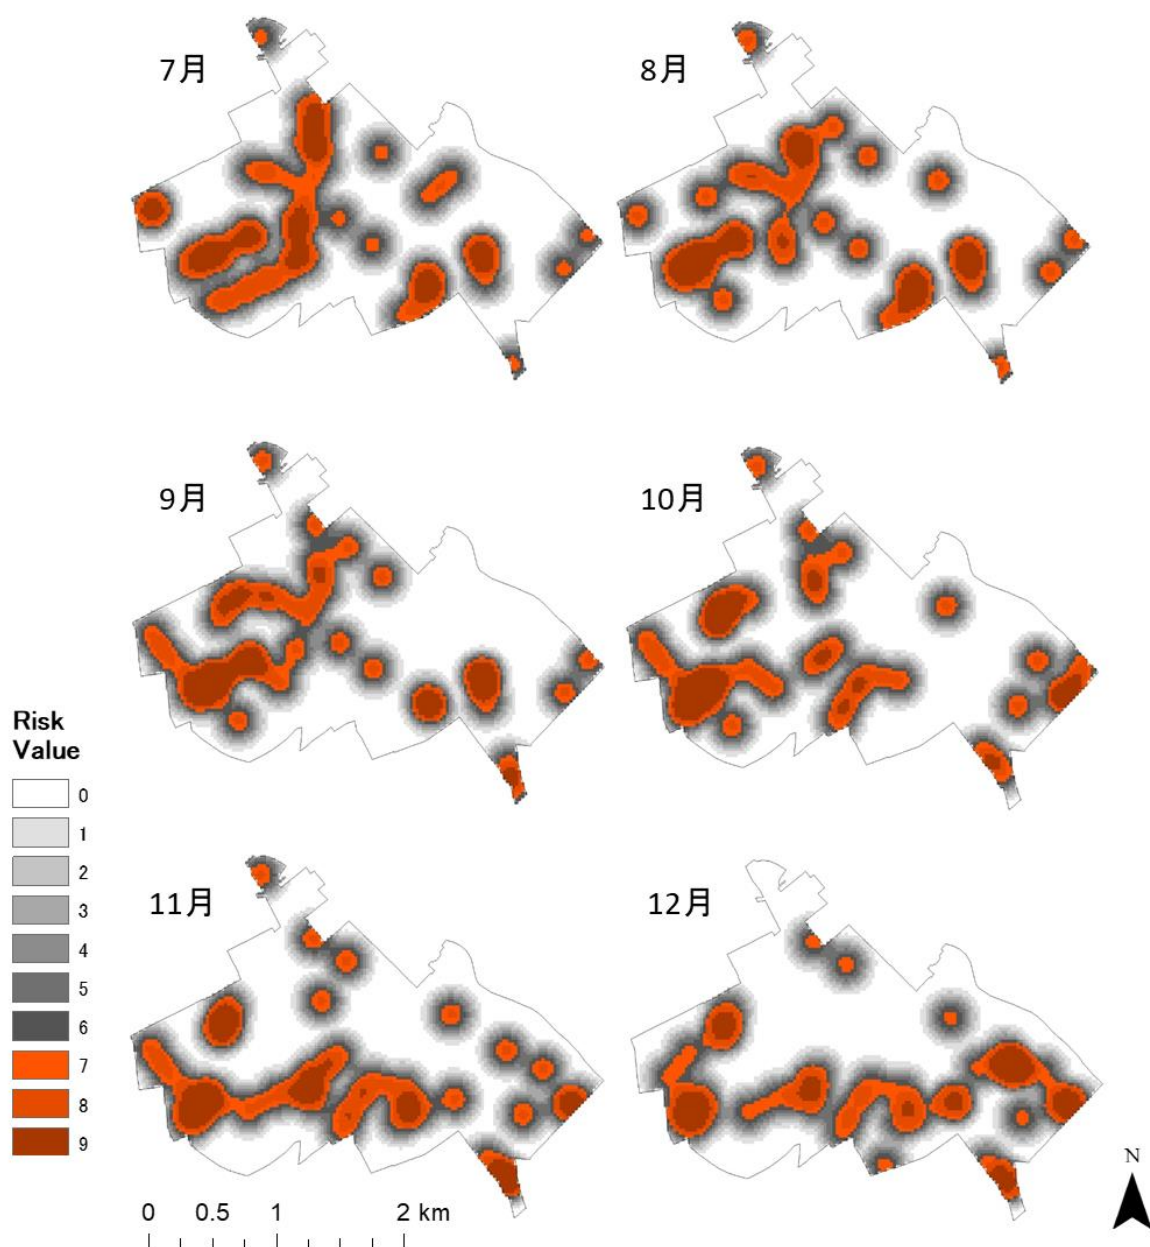


図 3-11 KDE による予測結果

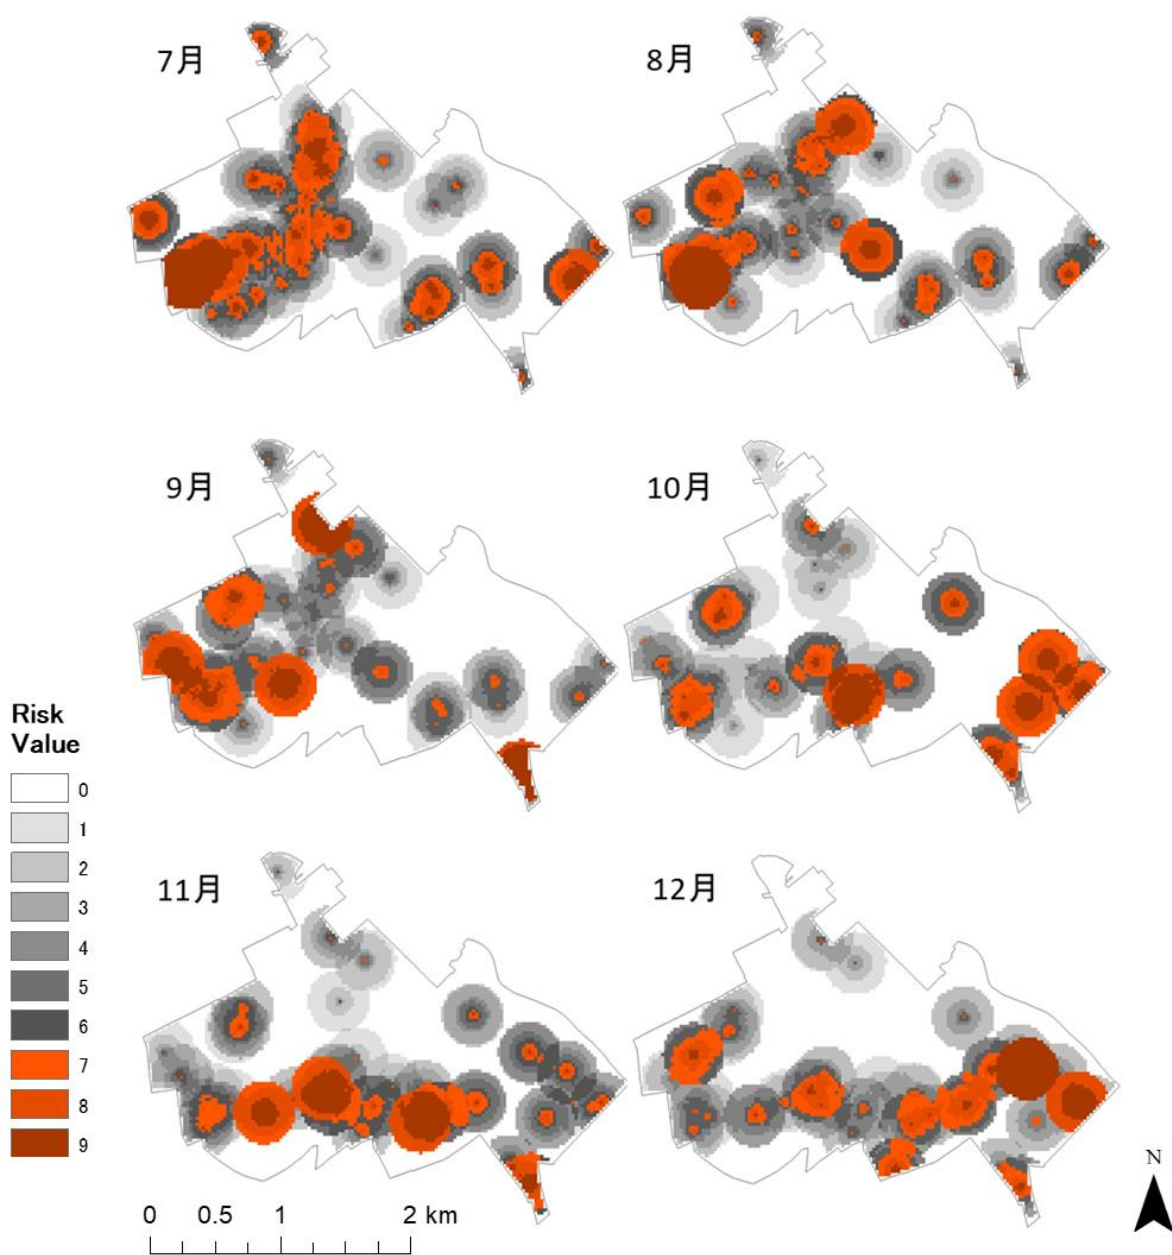


図 3-12 ProMap による予測結果

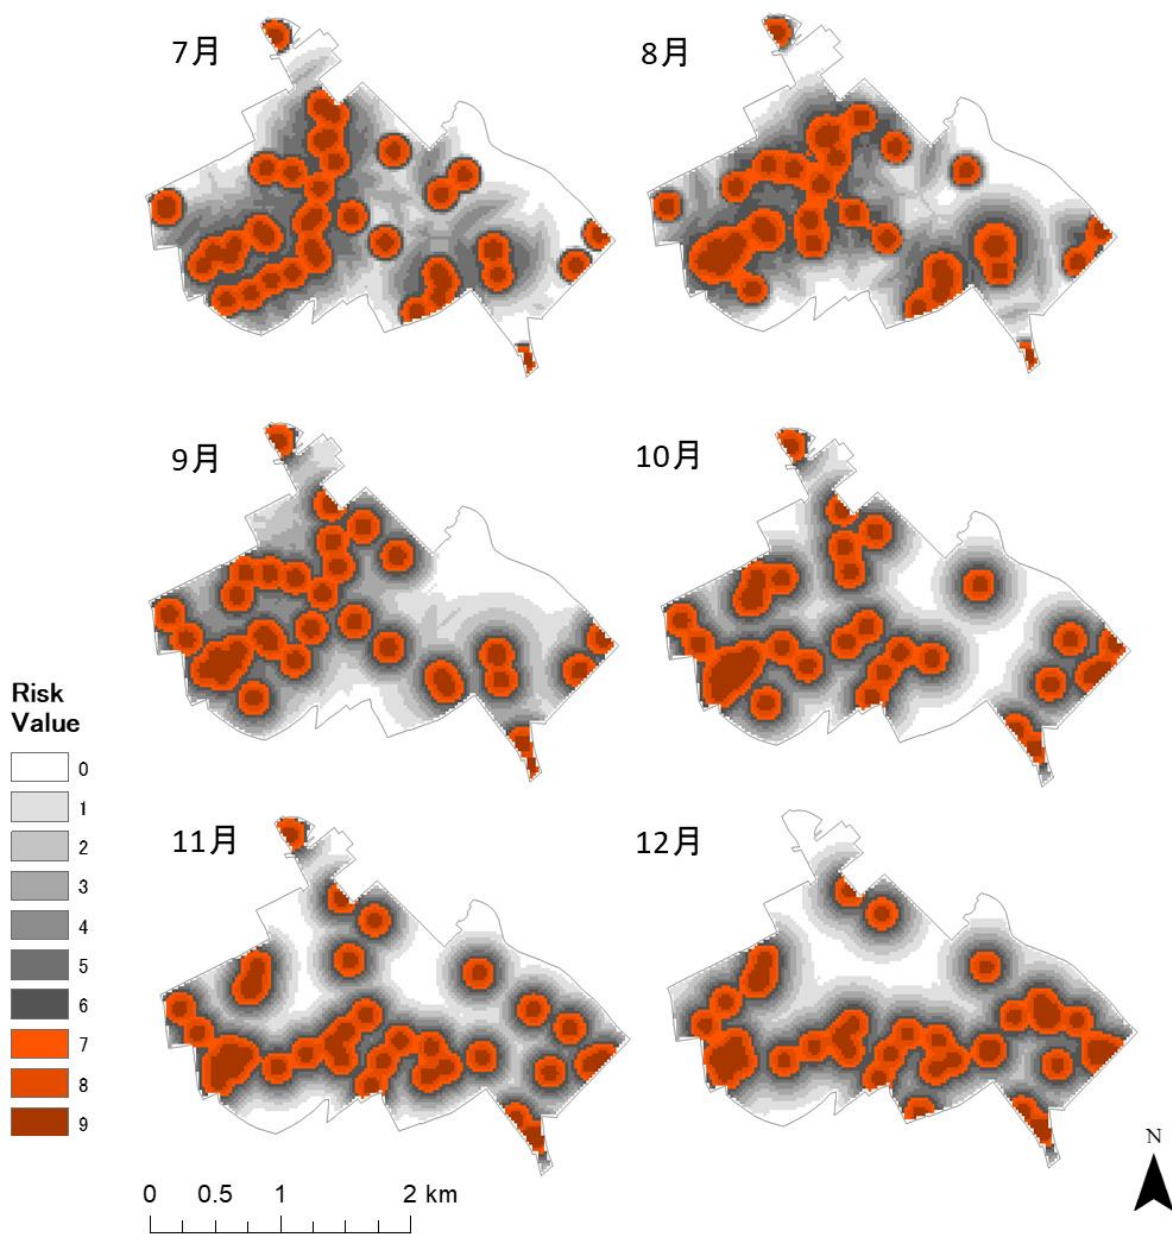


図 3-13 SEPP による予測結果

まず、KDEによる予測地図についてみる。1-6月データから、7月を予測したものでは、対象地域の西部に多くの高リスク領域が予測されているのに対し、東部は相対的に少ない。これが、予測対象期間をずらしてゆくと、8月以降の予測地図では、7月予測結果で確認された、西部地域の南北に連なる高リスク領域が分裂してゆき、逆に東部で複数の高リスク領域が予測されるようになる。

また、同じく犯罪発生データを用いながら、時間的情報も活用して予測する ProMap は、高リスク領域の分布や変化のパターンは、大まかな傾向としては KDE と似通っているものの、7月、および8月結果においては、KDE よりも南西部に偏っている、10月以降においては、西部から東部へのシフトが KDE よりも顕著であるなど、微妙な違いも見られる。

SEPP については、計算の結果、 g の値が μ に比べ、おおむね 100 分の 1 程度と、かなり小さいものとなったため、予測に反映されず、結果的に KDE とかなり似通ったアウトプットとなった。ただし、KDE と比較して、高リスク領域の形状が離散的なものになっている。

PSTSS については、実行したものの、有意な **emerging cluster** は検出されなかった。同手法に関しては、今回用いたデータでは、予測が困難であったという結果となる。

次に、RTM、および社会経済的要因による GAM、物理構造的要因による GAM の予測地図をそれぞれ図 3-14、図 3-15、図 3-16 に示す。




図 3-14 RTM による予測結果




図 3-15 GAM (社会経済的要因) による予測結果




図 3-16 GAM（物理構造的要因）による予測結果

RTM については、KDE, ProMap, SEPP とは異なる地域で、高リスク領域が予測されている。特に、中央部に南北に連なるように予測されたエリアは、犯罪発生データから予測する3手法には見られなかったものである。一方で、RTM では、西部、東部の両地域にも高リスク領域を確認することができる。これらは、KDE 等でもリスクが予測されていた地域である。

GAM（社会経済的要因）については、予測変数として用いたデータが、町丁目単位での集計値をセルに按分したものであったため、予測結果も町丁目の形状にしたがうものになった。予測された高リスク領域をみると、北西部、中央部、南東部などで、RTM と共通したものが確認でき、おおまかな傾向は似通っているといえる。一方で、この GAM では、RTM で予測されなかった南西部や西端部でのリスクが予測されており、逆に、東部のリスクは相対的に低く見積もられている。

GAM（物理構造的要因）については、RTM と同じ予測変数を用いたこともあり、北西部や北部から南部にかけての高リスク領域の分布が、似通ったものとなった。しかしながら、RTM で予測されていた東部の高リスク領域は GAM にはなく、逆に南西部には RTM で予測されていない高リスク領域が、GAM には見られている。

図 3-17 は、手法間の予測地図を比較した結果である。ただし、KDE, ProMap, SEPP については、7月予測結果（1-6月のデータを用いて予測を行ったもの）のみを示している。1-6月のデータをもとに予測した KDE, ProMap, SEPP が、西部での発生を予測しているのに対し、時間的な情報を考慮しない RTM のリスクは、北西部、北部から南部にかけての縦のライン、および東部などに顕著な高リスク領域が分布している。GAM も、おおむね RTM と同じ様相を呈しているといえよう。

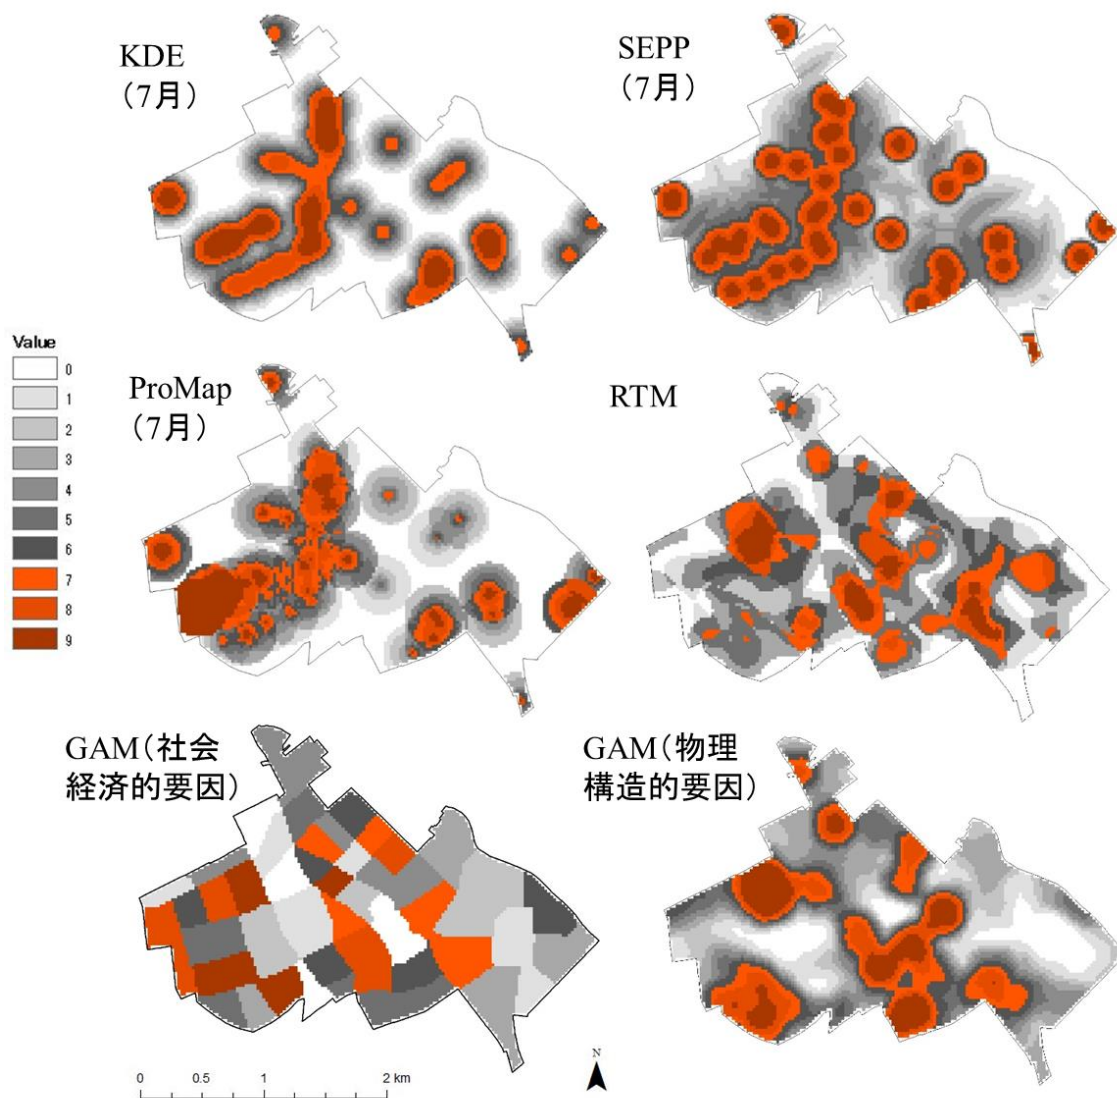


図 3-17 KDE, ProMap, SEPP, RTM, GAM による予測結果

3.5.2 指標に基づく評価結果

次に、評価指標として設定したもののうち、予測の正確性を示す的中率と PAI、予測の安定性を示す RRI について、手法ごとに算出した結果を表 3-6 に示す。的中率と PAI は、高リスク領域として定義した、リスクランク 7-9 の領域に重なった実際の犯罪件数をカウントして算出している。Mean や S.D. は、6 ヶ月の評価結果の平均と標準偏差を示した。RTM、および GAM は、1 枚の予測地図に基づいて全ての月を評価している。RRI について、KDE と SEPP は、8 月の的中率がゼロの月があるため、9 月の RRI が計算できていない（分母がゼロとなるため）。そのため、この 2 モデルにおける RRI の平均とばらつきは、4 回分の値をもとに算出しており、参考値である。なお、PSTSS については、有意な emerging cluster を検出することができなかったため、ここでは評価しない。

表からは、RTM が的中率、PAI とともに最も高いパフォーマンスを発揮していることがわかる。次点で正確性が高いのは、社会経済的要因による GAM であり、過去の犯罪発生データから予測する手法に比べ、環境的特性をもとに予測する手法が、予測の正確性、効率性ともに高いという結果となった。ただし、RTM と同じ物理構造的要因を用いた GAM は、的中率、PAI とともに RTM より劣っており、さらに社会経済的要因による GAM も下回った。

表 3-6 予測の正確性, および安定性に関する指標

的中率 (%)							
	KDE	SEPP	ProMap	RTM	GAM(物 理構造的 要因)	GAM(社 会経済的 要因)	月次 発生件数
7月	50.0	25.0	25.0	25.0	75.0	75.0	4
8月	0.0	0.0	20.0	40.0	40.0	40.0	5
9月	9.1	18.2	27.3	27.3	36.4	27.3	11
10月	12.5	12.5	12.5	37.5	12.5	25.0	8
11月	25.0	66.7	12.5	55.6	22.2	22.2	9
12月	9.1	10.0	9.1	60.0	30.0	50.0	10
平均	17.6	22.1	17.7	40.9	36.0	39.9	
ばらつき	16.3	21.4	6.8	13.1	19.6	18.4	

PAI							
	KDE	SEPP	ProMap	RTM	GAM(物 理構造的 要因)	GAM(社 会経済的 要因)	月次 発生件数
7月	2.44	0.83	1.18	1.14	2.75	2.81	4
8月	0.00	0.00	1.21	1.83	1.47	1.50	5
9月	0.47	0.61	1.47	1.25	1.33	1.02	11
10月	0.64	0.42	0.70	1.72	0.46	0.94	8
11月	1.23	2.22	0.65	2.54	0.81	0.83	9
12月	0.46	0.33	0.47	2.75	1.10	1.87	10
平均	0.87	0.73	0.95	1.87	1.32	1.49	
ばらつき	0.79	0.71	0.36	0.60	0.72	0.69	

RRI							
	KDE	SEPP	ProMap	RTM	GAM(物 理構造的 要因)	GAM(社 会経済的 要因)	月次 発生件数
7月	-	-	-	-	-	-	4
8月	0.00	0.00	1.02	1.60	0.53	0.53	5
9月	N/A	N/A	1.21	0.68	0.91	0.68	11
10月	1.35	0.69	0.47	1.38	0.34	0.92	8
11月	1.92	5.33	0.93	1.48	1.78	0.89	9
12月	0.38	0.15	0.73	1.08	1.35	2.25	10
平均	0.91	1.54	0.87	1.24	0.98	1.05	
ばらつき	0.77	2.27	0.28	0.41	0.53	0.62	

過去の犯罪発生データを用いた予測手法については, PAI の平均が 1 を超えるものではなく, 面積割合あたりの予測的中率が低いことがわかった. たとえば, ProMap の場合では, 17% の犯罪を予測するために, 全体の面積の 17% より大きい予測領域を要することになる. 3 手法の中で比較すると, KDE, ProMap の的中率がほぼ等しく, PAI では, ProMap が優位であった. ここから, ProMap は, KDE よりも予測効率が低いことがわかる. また, ProMap の的中

率、および PAI の標準偏差は、KDE や SEPP と比べて低く、他の手法に比べて、予測精度が安定していることがわかる。なお、KDE と似通った予測領域を示した SEPP は、的中率、PAI とともに KDE より低く、予測精度では劣るといった結果となった。

的中率と PAI を見比べると、RTM の的中率は、KDE や ProMap に対して 2.5 倍程度高いのに対して、PAI では 2 倍程度と、その差が小さくなっており、RTM の予測する高リスク領域が、相対的に大きく広がっていることが推測される。

次に、これら予測の正確性が、どの程度安定したものだったかを見る。的中率、PAI、RRI の全てにおいてばらつきが最も小さいのは、ProMap であった。環境要因に依拠した手法である GAM の 2 モデルは、相対的に安定性の程度が低いという結果となった。RTM は、今回比較した中では、6 モデル中 2 番目に安定したものであった。また、全ての月で PAI が 1 を超えているのは RTM だけであり、正確性の程度を高水準に保つことができていたともいえる。

図 3-18 は、高リスク領域を上位 30% に限定せず、すべての領域における正確性を比較するため、横軸に、各セルをリスクの高い順に並べた際の総面積に対する比、縦軸に、そのエリアで実際に起きた犯罪発生件数の累計を総発生件数で除したもの（6 ヶ月平均）を示している。KDE、ProMap、SEPP の面積率は、6 ヶ月の平均となっている。グラフ形状が上方に膨らんでいるほど予測効率が低いことを意味し、グラフ中の対角線（黒点線）より上方にあった場合、ランダムに予測を行うよりも精度が高いことになる。

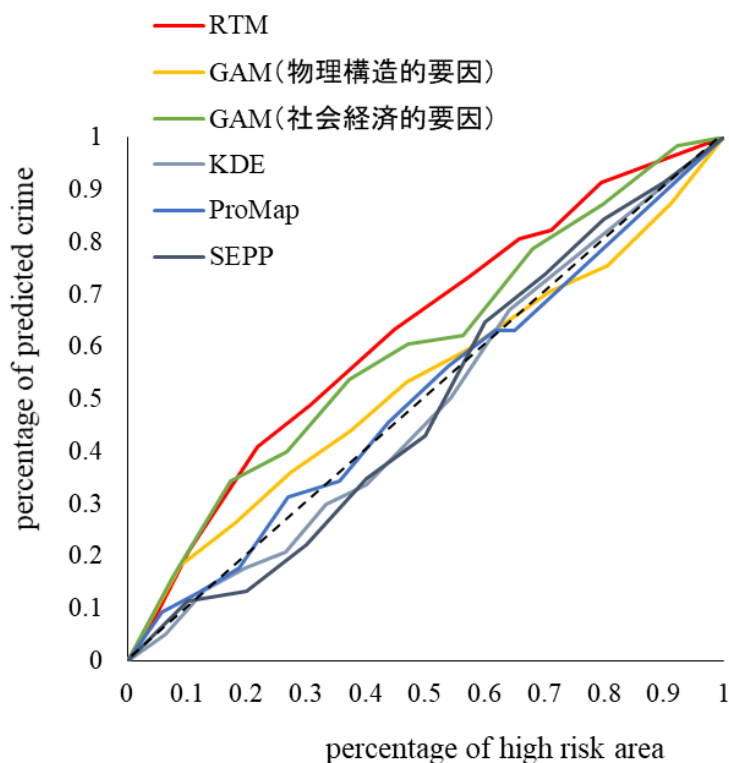


図 3-18 全エリアにおける予測の正確性の比較

ここから、RTM、GAM（社会経済的要因）は全領域で、ランダムな予測よりも優れたパフォーマンスを発揮することがわかる。過去の犯罪発生データをもとに予測する手法では、ProMap が若干ながら他 2 つの手法よりも良好であるものの、概ねランダムな予測を下回る結果となった。

次に、「予測領域のコンパクトさ」として、高リスク領域として予測された領域（リスクランク 7-9）の面積、および CI について計算した結果を表 3-7 に示す。GAM（社会）は、社会

経済的要因による GAM, GAM (物理) は物理構造的要因による GAM を意味する。

まず、高リスク領域の面積は、手法全体として約 1 km²~1.4 km² の範囲となり、対象地域の全面積に対する割合 (面積率) としては、18.8%~30.0% となった。今回は、リスク上位 3 ランクを高リスク領域としているため、予測モデル間で面積率はほぼ等しくなることが期待される。しかしながら、出力された予測値のばらつき方がモデルによって異なるため、ArcGIS 上で等量分類を行った際に、上位 3 ランクに含まれる領域の割合が異なっている。おおむね、KDE や ProMap といった犯罪データのみ に 依 拠 した 手 法 の 方 が、RTM や GAM に 比 べ、高リスク領域の面積が小さかったが、SEPP だけは例外であった。また、RTM は面積率が GAM の 2 モデルに比べて小さかった。

予測領域のまとまり度合いを示す CI については、全体的に 0.85 を超える値となっており、いずれも、かなりコンパクトであるという結果となった。犯罪データのみ に 依 拠 した 手 法 で、SEPP はコンパクトさが低いが、KDE と ProMap は、コンパクトさも 0.9 を超えている。GAM (社会) は、高リスク領域の面積は相対的に大きくなっていったが、予測変数となるデータが町丁目単位で、領域 (セル) が町丁目の形状に連坦していることもあり、CI が最も高い結果となっている。一方、GAM (物理) も高リスク領域の面積は大きくなっていったが、CI は 6 モデルのうち 2 番目にコンパクトな結果となった。

面積の大きさと、CI、両者を総合して考えると、5 手法の中では、ProMap が、最もコンパクトな予測領域を示しているといえる。

表 3-7 予測領域のコンパクトさ

モデル	面積		CI	
	平均 (km ²)	%	平均	標準偏差
KDE	1.08	19.7	0.906	0.004
SEPP	1.58	30.0	0.867	0.015
ProMap	0.97	18.8	0.912	0.011
RTM	1.20	21.8	0.893	-
GAM (社会)	1.41	26.7	0.926	-
GAM (物理)	1.44	27.3	0.912	-

3.6 議論

ここでは、前節で示した結果について考察した上で、各手法の日本への適用可能性と限界について議論する。

まず、予測の正確性、および予測効率については、今回検証したすべての手法の中で、RTM が最も高いパフォーマンスを示していた。PAI の大きさについては、先行研究をみると、Chainey et al. (2008) では、同じ車上狙いを対象とした KDE による予測で、2.29~3.66、Adepeju et al. (2016) では、自動車盗を対象とした KDE、ProMap、SEPP を用いた予測で、1.89~1.99 という値となっている。研究対象期間や、各種の条件が異なるため、単純な比較はできないが、本分析における RTM の PAI は、既存研究と比べて低くはない値といえよう。

他の比較研究と手法間の結果の違いについて見ると、Adepeju et al. (2016) では、SEPP が KDE、ProMap の正確性を一貫して上回っていた。SEPP は、背景事象による効果と誘発効果を同時に考慮しており、KDE のように過去の犯罪の空間的な変動だけを用いる手法と、ProMap のように近接反復被害の直接的なモデリングを行う (過去の犯罪発生から時空間的に近い点の強度が大きくなる) 手法とを組み合わせたものとみなせる。SEPP が今回、KDE や ProMap の予測性能を下回った理由として、時間的に定常な背景事象による効果と、近接反復被害による誘発効果を加算するという方法が、少なくとも今回対象とした地域の状況に適し

ていなかった可能性がある。たとえば、今回は RTM や GAM の予測精度が犯罪発生データのみ
に依拠した手法を上回っていたことから、短期的に変化しない静的なリスク要因が、近接
反復被害のような動的なリスク要因と比較して、犯罪発生に対し相対的に大きな影響を持つ
ような状況が考えられる。そのような場合、時間的に変動するリスクと、しないリスクとを
同じ重みで足し合わせることで、予測の正確性は損なわれるだろう。このような状況下では、
2つの効果を単純に加算することで組み合わせる SEPP のような方法に対して、いま一つの工
夫が求められる。

また、RTM と犯罪発生データによる予測を比べた研究としては、Caplan et al. (2011), Drawve
(2016), Dugato (2013), Kennedy et al. (2011) があり、このうち、Caplan et al. (2011), Kennedy
et al. (2011) では、RTM が KDE の正確性を上回り、Drawve (2016), Dugato (2013) では、
KDE が RTM の正確性を上回っていた。これに対し、本分析では、RTM の正確性は、7月を
除いて KDE を上回っている。RTM と KDE は、時間的に変動する要素を用いない点が共通し
ており、どちらも長期的なリスクを表現するものと解釈できるが、日本のように犯罪発生が
少ない状況では、犯罪データを予測変数として用いない RTM のような方法が、より有効であ
るとも考えられる。

RTM による予測を行う上で用いた変数は、「駐車場」、「コンビニエンスストア」、「道路全
体」というものであったが、これらがたがいに高密度に存在するエリアは、主要な幹線道路に
近く、自動車の交通量や人通りが多い場所、あるいは、飲食店やその他の商業施設などが多
く、駐車場の需要が高い場所である可能性が高い。図 3-19 には、RTM の出力結果に、対象
地域の鉄道駅を重ねて示している。シンボルの小さいものは、地下鉄駅を表す。これをみる
と、RTM で予測された高リスク領域は、東部のターミナル駅の周辺や、中心部よりやや北に
位置する地下鉄駅の北東と南部地域、そして中心部よりやや西の地下鉄駅の北西部、およ
びターミナル駅南部といった地域に分布していることがわかる。したがって、RTM は、繁
華街エリアに潜在するリスクを高く評価し、それが結果的に、犯罪をうまく予測できていたと解
釈することができる。

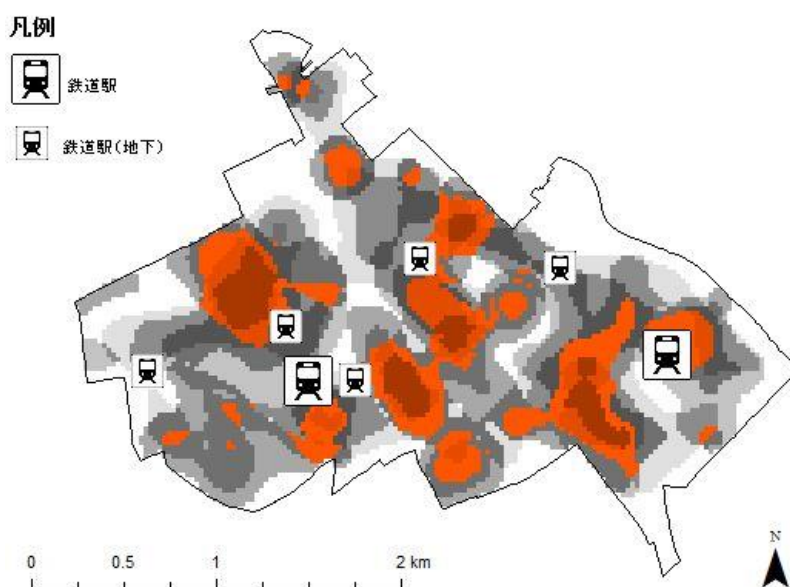


図 3-19 RTM 出力結果, および鉄道駅の分布状況

GAM (社会経済的要因) の予測地図は、RTM と大まかな傾向は似通っている。これは、「飲
食店、宿泊業事業所数」を変数として用いたことで、繁華街の発生リスクを正しく評価でき

ていたとも考えられる。同時に、GAMでは「民営借家数」と「単身世帯数」を用いている。今回対象とした領域では、南部に住宅街が存在するが、この2つの変数はこれを反映する変数とも考えられる。この点が、RTMの予測地図との差異を生み出している可能性がある。

一方で、GAM（物理構造的要因）は、RTMと同じ予測変数を用いているにもかかわらず、予測地図の様子は異なっていた。ただ、このGAMでは、表3-5の通り、駐車場以外の変数の p 値が低く、コンビニエンスストアと道路の変数が、RTMとは違い予測にあまり寄与していない。このことが、RTMによる予測結果との差異をもたらしたと考えられる。

RTMとGAM（社会経済的要因）は、たがいに異なる変数を用いているものの、周辺環境に関する変数から予測を行うという点では共通している。これらの手法が、KDE等の犯罪発生データを用いた予測を上回る精度をみせたことから、日本においては、犯罪と関連しうる要因から予測を行う方法に、一定の有用性があることが示唆された。このことから、当該犯罪以外で、犯罪と強く関連する要因を予測にうまく組み入れることが、わが国での地理的犯罪予測に求められる方向性であるとも考えられる。また、犯罪に関する時間的・空間的解像度の高いデータの利用可能性が低いわが国の状況を鑑みても、このような手法に頼る機会は必然的に多くなるといえるだろう。

なお、RTMのような環境要因を用いる予測手法では、予測結果が、何を予測変数として採用するか大きく依存する。今回は、回帰分析の手続きを経つつ、探索的に変数の選定を行ったが、本来なら、車上狙い等に関する既存の理論や研究に基づいて、変数を設定すべきである。日本において、車上狙いや部品狙いの発生環境を対象とした定量的研究はほぼなく、予測に先立って、当該の犯罪と関連する要因を探る基礎的研究を充実させることが、同手法を発展させていく上で欠かせないといえよう。

ところで、RTMやGAMは、今回用いた変数に短期的に変動するものが含まれていないため、データが更新されない限り、同じ予測地図しか出力されない。他方で、過去の犯罪発生データの空間的情報を用いたKDEの出力結果は、予測する高リスク領域の位置や大きさには、月ごとに変化が見られた。これは、予測に用いた直前6ヵ月の犯罪発生状況の変化を反映しており、車上狙い等が、常に同じエリアで集中して発生するというわけではなく、時間とともに遷移する可能性があることを示唆している。こうした犯罪発生パターンの変化は、日本でも中谷・矢野（2008）などで示されており、犯罪のダイナミックな動きを予測に反映することは、重要であると考えられる。

この点について、犯罪データを用いた予測の中でも、ProMapは、SEPPと同じく犯罪発生の時間的情報を用いながら、予測の安定性、予測領域のコンパクトさなどで、比較的高いパフォーマンスをみせた。日本において犯罪のダイナミズムを予測に反映する方法としては、ProMapのように、イベント間の時空間的近接性をシンプルにモデリングすることが有効であるかもしれない。

とはいえ、今回の検証では、RTMやGAMのように、都市の環境要因を用いる手法に対して、KDEやProMap、SEPPといった犯罪データを用いる手法の予測精度はおしなべて低かった。KDE、ProMap、SEPPのうち、PAIの平均が1を上回ったものはなく、全エリアにおける予測効率の比較（図3-18）でも、おおむねランダムな予測を下回る結果となった。

これについて、日本のように犯罪が低頻度な状況下では、将来の予測を行う上で、過去の犯罪発生情報のもつ情報量が、環境要因などの犯罪関連要因と比して、相対的に低い可能性もある。海外における予測研究では、たとえば、Chainey et al.（2008）では、英国において、本分析で対象とした地域の6.6倍程度の面積をもつエリアを対象にしているが、そこでは車上狙いが年間1万件以上発生している。この発生頻度の差は、予測結果にも大きく影響すると考えられる。

さらに、日本のような状況では、犯罪を行う個人や集団が少なく、一部の者によって、ほとんどの犯罪が行われているという事態がありうる。実際に、警察庁の統計資料（警察庁、2017）によると、2014年における車上狙いと部品狙いの検挙件数、検挙人員は、それぞれあわせて20,364件、2,516人となっており、検挙人員一人あたりの件数は、8.1件となっている。今回の検証期間では車上狙い等の発生件数は月あたり4件～11件であり、これらの犯罪が1人ないし2人といった少数名により行われたことも考えられよう。そうした場合、その者をめぐる何らかの事情（防犯対策や検挙により犯行が抑止される、あるいは、犯行対象とする地域を変える等）によって犯罪が止む、あるいはホットスポットが移動するといった犯罪発生パターンの変化が起きやすくなり、犯罪発生情報のみに基づく方法は不利になる。

RTMやGAMのような手法は、こうした情報を用いないことで、高い正確性を得られる手法といえよう。以上のことを総合して考えると、日本のような状況下では、犯罪発生時の時間的な情報に大きく影響される手法に依存するのは、予測精度を損なう可能性がある。一方で、RTMやGAMによる予測の正確性は、ProMapよりはばらつきが大きく、予測の安定性に関しては一定の課題が見られた。予測の正確性を担保しつつ、安定した予測を行うためには、ProMapのように、犯罪の時間的変化をモデルに反映させることも有効かもしれない。ただし、ここまで述べてきたように、時間的に変動するリスクを重視しすぎると、かえって予測の正確性を損なう可能性がある。このことから、場所に長期間とどまるようなリスク要因を評価するRTMのような手法をベースに、犯罪の時空間的相互作用を加味するような方法をとることが望ましいと考えられる。

なお、今回PSTSSでは、有意なemerging clusterを検出することはできなかった。KDEなどでは、犯罪の密度分布図を描き、強度推定値の相対的に高いエリアを高リスク領域と称していたが、PSTSSの分析結果からは、これらが、統計的な基準では有意な集積とはいえないことが明らかになった。さらにいえば、KDEのような方法は、今回のデータのような疎なポイントパターンに適用しても何らかの結果が出力されるが、これが、実際的に意味のある集積、あるいは高リスク領域と呼ぶことができるのかについては、慎重に判断する必要がある。

また、RTMDxにおいては変数がすべて除外されたことについては、犯罪発生頻度の低さが関係している可能性がある。このように、日本の犯罪発生状況では、海外で作られたモデルをうまく適用できないという問題もある。

3.7 まとめ

本章では、主要な地理的犯罪予測手法として抽出したものについて、国内の実データを用いて、予測の正確性や効率性、予測領域のコンパクトさといった指標を設定し、検証を行った。結果として、RTMが最も予測精度が高いことがわかった。また、社会経済的要因に基づくGAMも、犯罪データのみを依拠した予測手法よりも良好な性能を発揮していたことから、犯罪生成・誘引要因や社会経済的要因のような環境要因をもとに予測を行う手法が、わが国での犯罪予測に有効である可能性が示された。今回の検証は、あくまで日本の一都市における検討であり、結果を安易に一般化することは避けるべきではあるものの、日本の都市部、中心市街地や繁華街を含むエリアとしては典型的な対象地域であり、得られた結果は、一定程度信頼できるものと考えられる。

このように、都市における物理構造的、あるいは社会経済的な環境要因をうまく活用することで、わが国でも、諸外国と同等の地理的犯罪予測が可能と考えられる。次章以降では、ここで得られた結果をもとに、日本の状況に対してさらに有効な予測手法を検討し、手法の具体像を提案する。

3章の参考文献

- 1) 菊池城治・雨宮護・島田貴仁・齊藤知範・原田豊 (2010) 近接反復被害の罪種間比較: 時空間 K 関数の応用, 「GIS-理論と応用」, **18**(2), 129-138.
- 2) 警察庁 (2017) 平成 28 年の犯罪情勢, <<https://www.npa.go.jp/toukei/seianki/h28hannzaizyousei.pdf>>, 2019 年 10 月 10 日閲覧.
- 3) 中谷友樹・矢野桂司 (2008) 犯罪発生の時空間 3 次元地図, 「地学雑誌」, **117**(2), 506-521.
- 4) 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*, **30**(11), 2133-2154.
- 5) Anselin, L., Cohen, J., Cook, D., Gorr, W., and Tita, G. (2000) Spatial analyses of crime. *Criminal Justice*, **4**(2), 213-262.
- 6) Bowers, K., Johnson, S., and Pease, K. (2004) Prospective hot-spotting the future of crime mapping? *British Journal of Criminology*, **44**(5), 641-658.
- 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.
- 8) Chainey, S., and Ratcliffe, J. (2005) *GIS and Crime Mapping*. London: Wiley.
- 9) Chainey, S., Reid, S., and Stuart, N. (2002) *When is a hotspot a hotspot? A procedure for creating statistically robust hotspot maps of crime*. London: Taylor and Francis.
- 10) 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.
- 11) Cheng, T., and Adepeju, M. (2013) Detecting emerging space-time crime patterns by prospective STSS. In *Proceedings of the 12th international conference on geocomputation*, 281-285.
- 12) Clarke, R., and Mayhew, P. (1998) *Preventing crime in parking lots: what we know and need to know. Reducing Crime Through Real Estate Development and Planning*. Washington, DC: Urban Land Institute, **34**, 205-210.
- 13) Crowe, T. (1991) *Crime prevention through environmental design: Applications of architectural design and space management concepts*. Boston: Butterworth-Heinemann.
- 14) Drawve, G. (2014) A metric comparison of predictive hot spot techniques and RTM. *Justice Quarterly*, **33**(3), 369-397.
- 15) Drawve, G., Moak, S., and Berthelot, E. (2016) Predictability of gun crimes: A comparison of hot spot and risk terrain modelling techniques. *Policing and Society*, **26**(3), 312-331.
- 16) Hart, T., and Zandbergen, P. (2014) Kernel density estimation and hotspot mapping: Examining the influence of interpolation method, grid cell size, and bandwidth on crime forecasting. *Policing: An International Journal of Police Strategies & Management*, **37**(2), 305-323.
- 17) Hart, T., and Zandbergen, P. (2012) Effects of data quality on predictive hotspot mapping. <<https://www.ncjrs.gov/pdffiles1/nij/grants/239861.pdf>>, 2019 年 10 月 10 日閲覧.
- 18) Johnson, S., Birks, D., McLaughlin, L., Bowers, K., and Pease, K. (2007) *Prospective Crime Mapping in Operational Context, Final Report.*, London, UK: Home Office.

- 19) 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.
- 20) Kulldorff, M. (2015). SaTScan user guide for version 9.4.
<https://www.satscan.org/cgi-bin/satscan/register.pl/SaTScan_Users_Guide.pdf?todo=process_userguide_download>, 2019年12月23日閲覧.
- 21) 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.
- 22) Levine, N. (2008) The “Hottest” part of a hotspot: comments on “The utility of hotspot mapping for predicting spatial patterns of crime”. *Security Journal*, **21**(4), 295-302.
- 23) Mohler, G. (2015) Event forecasting system. U. S. Patent 13,676,358. 2015-02-03.
- 24) Mohler, G. (2014) Marked point process hotspot maps for homicide and gun crime prediction in Chicago. *International Journal of Forecasting*, **30**(3), 491-497.
- 25) 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.
- 26) Ogata, Y. (1998) Space-time point-process models for earthquake occurrences. *Annals of the Institute of Statistical Mathematics*, **50**(2), 379-402.
- 27) 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.
- 28) Tompson, L., and Townsley, M. (2010) (Looking) Back to the Future: Using Space—Time Patterns to Better Predict the Location of Street Crime. *International Journal of Police Science & Management*, **12**(1), 23-40.
- 29) Van Patten, I., McKeldin-Coner, J., and Cox, D. (2009) A microspatial analysis of robbery: Prospective hot spotting in a small city. *Crime Mapping: A Journal of Research and Practice*, **1**(1), 7-32.
- 30) Wang, X., and Brown, D. (2012) The spatio-temporal modeling for criminal incidents. *Security Informatics*, **1**(1), 1-17.
- 31) Zhuang, J., Ogata, Y., and Vere-Jones, D. (2002) Stochastic declustering of space-time earthquake occurrences. *Journal of the American Statistical Association*, **97**(458), 369-380.

第4章 日本に適した地理的犯罪予測手法の検討

4.1 はじめに

本章では、2章のレビューで整理した地理的犯罪予測手法、および3章の分析で手法間比較を行った結果をもとにしながら、日本において適した地理的犯罪予測手法の具体像について論じる。以降では、主に Taylor et al. (2015)、および Ratcliffe et al. (2016) の議論を参考に、地理的犯罪予測に用いられるリスクを長期的・潜在的なリスクと、短期的・顕在的なリスクとに分けて論じるⁱ。Taylor et al. (2015) では、地理的犯罪予測が参照しうる2種類のリスクとして、「数年、あるいは数十年間固着しうる長期の犯罪パターン」と、「むこう数日から数週間にかけて増大する短期のリスク」を挙げている。Ratcliffe et al. (2016) によれば、前者は、地域やコミュニティに潜在する構造的な要因が、犯罪リスクが空間的に不均一な状況を作ることによって生まれるものであり、後者は、犯罪が発生した直後、近接反復被害により、リスク面 (risk surface) に数週間程度の時間間隔での短期的な変化が生じることである。

本章では、これまでの地理的犯罪予測研究において用いられてきた要素を長期的・潜在的リスク要因 (第2節)、短期的・顕在的リスク要因 (第3節) とに分け、わが国においてこれらを予測する際に有効なモデルについて論じる。その後、日本への適用を考えた際に、これらをどのように組み合わせて総合的なリスクを算出すべきかを検討する (第4節)。

4.2 長期的・潜在的リスク

4.2.1 社会経済的要因

これまで地理的犯罪予測研究で取り上げられてきた長期的・潜在的リスク要因としては、2章でふれたように、人口密度、若年人口比率、人種的多様性、昼間人口比率といった地区ごとに見られる社会経済的な特性と、商業施設や公的施設、幹線道路・高速道路までの距離やその密度といった、地区、あるいはよりミクロな場所を構成する物理構造的な特性とに、大きく分けることができる。これらは、Ratcliffe et al. (2016) が述べるように、都市空間にリスク不均一な状況 (risk heterogeneity) を作り出す。

長期的・潜在的リスク要因として、はじめにふれるべきは、地区の社会経済的特性であろう。Ratcliffe et al. (2016) では、代表的な変数として、地区の SES (Socio-Economic Status)、人種、(居住) 安定性の3つが挙げられている。SES は、地区の社会経済的地位、すなわち、どの程度富裕な地区であるかを表彰する変数であり、住民の平均所得や専門的・管理的職業

ⁱ Ratcliffe et al. (2016) は、これらを Long-term risk, Short-term risk とそれぞれ呼称している。本論文でもこれらを踏襲しつつも、前者は都市の物理的・社会的環境に依存して潜在する犯罪発生リスク、後者は犯罪が発生したことで顕在化する犯罪発生リスクであることから、「潜在」、「顕在」という語を用いて2種のリスクを表現する。前者は、これまで犯罪が必ずしも発生していない場合でも、環境条件に照らせば、次に発生する可能性の高いことを含意する。後者は、1件の犯罪が発生することで、そこに元来あったリスクが現出し、次の犯罪発生を誘発するように可能性が高まることを含意する。

従事者比率などによって表される。人種は、人種（しばしば民族）構成の多様性であり、地区における非白人系の人口割合や、各人種（民族）の構成比率で表される。安定性は、地区の居住がどの程度安定的、あるいは流動的なのかを測るもので、地区住民の平均的な居住年数などで表される。一般に、SES や安定性の高さは低い犯罪率と、人種の混住は高い犯罪率と関連する。これらの概念は、社会生態学の分野で長く検討されてきたもので、社会解体論ⁱⁱと犯罪・非行を直接関連づけた Shaw and Mckey (1942) にまで、その起源を遡ることができる。Hunter (1971) は、これら変数が、年代をまたいでも頑健に主成分を構成することを示しており、構成概念としての妥当性が確かめられている。また、犯罪と SES, 人種, 安定性の関連についても、これらの変数が独立して犯罪被害に影響力をもつことが確かめられている (Sampson and Lauritsen, 1994)。

2章で取り上げた地理的犯罪予測研究においても、社会経済的特性として用いられているのは基本的に上記の変数であるが、ほかにも、住宅価格、持ち家世帯率（または借家世帯率）、空き家率、単身世帯率、女性を世帯主とする世帯率、公営住宅数、公的扶助受給者率、地元自治体の財政状況などがある (Bogomolov et al., 2014; Hu et al., 2018; Kadar et al., 2019; Law et al., 2014; Rummens et al., 2017; Prestemon et al., 2012; Vomfell et al., 2018; Wang and Brown, 2012)。ただし、これらの多くも SES, 人種, 安定性といった指標と共変しうる変数といえ、同じように局所的な不利益の集中や格差を生み出すことで、犯罪発生のリスクを高める役割をもつものといえるだろう。

これらの変数は、日本における地理的犯罪予測においても有効だろうか。3章の分析では、GAM を用いた検討で、社会経済的要因を用いたモデルは、犯罪生成・誘引要因による RTM に次いで高いパフォーマンスを示していた。2つのモデルでは、分析の空間単位が異なるため、厳密な比較は難しいものの、日本においても社会経済的要因が犯罪発生の予測に寄与する余地はあると考えられる。

また、わが国の地理的な犯罪分析研究でも、こうした社会経済的要因は扱われており、たとえば雨宮 (2013) では、1万世帯あたりの住宅侵入盗の発生率を潜在成長曲線モデルで分析し、民営借家居住率が切片と傾きにそれぞれ正、負の効果、戸建て居住率が切片と傾きにそれぞれ負、正の効果、5年定住率（地区に5年以上定住している世帯の割合）が切片に負の効果をもつことを確かめている。これらの指標は居住安定性、さらには SES を示す指標といえる。樋野・小島 (2007) でも、千世帯あたりの住宅侵入盗の発生率を構造方程式モデルにより分析することで、民営借家世帯率が発生に正の直接効果をもつことを確かめている。一方で、土方ら (2015) では、住宅侵入盗の施錠被害・無施錠被害件数を負の二項回帰で分析しているが、民営借家住宅居住世帯率が正の効果をもっていたものの、居住流動性を表す居住期間5年未満世帯率は負の効果をもっていたⁱⁱⁱ。上杉・樋野 (2015) では、1万世帯あたりの住宅侵入盗発生率について、重回帰分析と地理的加重回帰を適用し、前者の分析においては、一戸建世帯率が正の効果をもつことを確かめている。ただし、後者の分析においては、高所得世帯割合の効果は空間的異質性を示し、地域によっては、高

ii Shaw and Mckey (1942) では、都市社会学における社会解体の理論を援用しながら、低い社会経済的地位、民族の混合、居住流動性の3つの構造的要素が、コミュニティの社会的組織を崩し (disorganize)、それが犯罪・非行の変動を説明するとしている。なお、ここで想定されているのは、主に近隣と近隣の間といった空間的な変動だが、この理論では急速な社会変化が解体をもたらすとしていることから、社会解体では犯罪リスクの時間的な変動も説明できる。たとえば、Taylor et al. (2015) は、現在における地域の構造的状況は、将来の犯罪の長期的な変化に影響を及ぼすとしている。

iii 分析者らは、この結果を地方都市の特徴としての低密居住と関連づけて解釈している。

所得世帯割合が正の効果をもつ可能性が示唆された^{iv}。最近では、山村ら（2019）が、道路をはじめとした公共空間で発生した痴漢の発生をマルチレベルでのロジスティック回帰で分析しており、SES 指標としての推定所得平均は負の効果をもっていた一方で、ブルーカラー従事者割合も負の効果をもつ結果となった^v。

このように、わが国の実証分析でも、安定性の（犯罪発生に対する負の）効果や、高 SES の（犯罪発生に対する負の）効果は、諸外国と同様の結果を得られているものもあるが、一貫しているとはいえない。また、上記の研究はいずれも住宅侵入盗を扱ったものであり、他の罪種でどのような傾向が見られるかは定かではない。さらに、ここで紹介した研究のうち、雨宮（2013）、樋野・小島（2007）、上杉・樋野（2015）などは、東京 23 区全体を対象とした分析となっており、地理的犯罪予測の想定する地理的領域としては広い。23 区内での SES のばらつきと、地理的犯罪予測を行う場合の 1 区内での SES のばらつきは、後者の方が小さくなると考えられるが、それが予測に寄与するほどのものであるかは、検討する必要がある。

一方で、海外で扱われている人種・民族の多様性に関する変数は、国内の分析では扱われていない。米国などでは、人種・民族の混住は、経済格差を引き立たせることで、犯罪の原因となりうるが、わが国では、人種や民族の混住が欧米諸国ほど進んでいないことから、こうした要因の効果は限定的である可能性が高い。

以上に述べたように、わが国の地理的犯罪予測を行う上で、社会経済的要因は諸外国と同様の程度で予測に寄与するかは定かではないが、3 章で見たように、日本でも一定の予測力を持つものと思われる。

4.2.2 犯罪生成・誘引要因

次に、長期的・潜在的リスク要因としての犯罪生成・誘引要因について述べる。2 章、3 章で紹介した通り、これを予測変数として扱った代表的な手法としては、RTM が挙げられる。この 2 つの概念はともに、Brantingham and Brantingham（1995）で提出されたものであり、前者は、「犯罪に関する特定の動機や、何らかの犯罪に関与するといった理由とは関係なく、多くの人が引き寄せられるようなエリア」とされ、例としてショッピング・エンターテイメント区画、事業所の集積する地区、スポーツスタジアムが挙げられている。後者は、「特定の犯罪の機会に恵まれていることが知られているために、動機や意図をもった犯罪加害者が引き寄せられるような、犯罪機会をつくりだすよく知られた特定の場所、エリア、近隣、区画」とされ、例としてバーのある区画、赤線地区、ドラッグマーケット、大型ショッピングモール、主要な公共交通乗換駅、業務・商業地区にある大型で安全が確保されていない駐車場が挙げられている。Brantingham ら自身が例示している通り、犯罪生成・誘引要因は、特定の場所と関連があり、地理的犯罪予測研究でも特定のバー、銀行、公園といった施設の数や密度、またそれらへの近接性といった変数として設定される。なお、犯罪と関連する場所は、犯罪生成要因と犯罪誘引要因、両方の特性をもつと考えられ（Farrell, 2015）、また実際に、RTM 研究でもこれらは特に区別せずに用いられることから、以降はこれらを犯罪生成・誘引要因として表現する。

犯罪生成・誘引要因となりうる場所は、潜在的な被害対象（人や財物）、または動機をもった犯行者が集まりやすい空間であり、日常活動理論（Cohen and Felson, 1979）や犯罪パターン

iv 分析者らは、正の効果は有意ではないものの、こうした傾向が見られた地域は高所得層と低所得層が混在しており、高所得層地域の被害対象としての魅力が相対的に高かった可能性があると考えしている。

v ブルーカラー従事者割合は、地区の低 SES に関連する指標であるため、犯罪発生とは正の関連が予想されるところであるが、当該研究では、この点に関しての考察はない。

理論 (Brantingham and Brantingham, 1993) と深く関連する概念といえる。日常活動理論では、動機づけられた犯行者、適当な犯行対象、有能な守り手の不在が時空間的に重なることで、犯罪が発生すると主張するものである。こうした状況は、空間的には、犯罪生成・誘引要因となる場所で発生すると考えられるだろう。また、犯罪パターン理論では、潜在的な被害者、犯行者ともに、住居、職場や学校、友人宅、余暇を過ごす場所（バー、ファーストフード店、レストラン、買い物をする場所等）といったノードと、それらを結ぶパスが構成する活動空間上で犯罪被害に遭う、または犯行を起こすとされており (Brantingham and Brantingham, 1991)、中でも余暇を過ごす場所が、犯罪生成・誘引要因になりやすい (Brantingham and Brantingham, 1995) とされている。

犯罪生成・誘引要因は、このように環境犯罪学の主要な理論と関連づけられるものだが、島田 (2013) では、社会解体論をよりマクロな視点に立ち、犯罪を生み出す原因を見る理論、日常活動理論や犯罪パターン理論を、よりミクروسケールの物理環境から犯罪を生み出す理論として位置付けている。このように整理すると、前項で述べた社会経済的要因は、都市の中で、より広域のスケールをもって犯罪の原因となる構造をみたものであり、RTM で扱われる犯罪生成・誘引要因は、より局所的な物理構造的環境をみたものといえるだろう。また、Wilcox et al. (2003) は、特定の場所（建物）における犯罪発生は、その場所のある街路、さらに近隣、またはブロックグループといった、より広範囲な環境単位によって特徴づけられるとするマルチレベル犯罪機会論 (multicontextual opportunity theory) を提唱する。この考えによれば、犯罪は、近隣のもつ社会経済的特性に、さらに場所単位での犯罪生成・誘引要因にといったように、順に影響を受けながら発生する。このように、犯罪生成・誘引要因と社会経済的要因は、互いに階層的な関係をもつものと考えられる^{vi}。

このような犯罪生成・誘引要因が、わが国における地理的犯罪予測にどの程度寄与するかを考える。まず、3章の分析では、車上狙い等に対して、駐車場、コンビニエンスストア、道路という施設・インフラの密度が予測に有効であるということが確かめられた。また、日本国内の地理的犯罪分析研究でも、ひたくりに対して、駅やコンビニエンスストア、金融機関が (石川・鈴木, 2008; 木梨・金, 2008)、児童に対する声かけ、つきまといといった不審行為に対して、自動販売機、公園・緑地、学校 (佐々木ら, 2013)、学校、鉄道駅、都市公園、小規模空地 (花岡, 2017)、自転車盗・オートバイ盗に駐輪場、駐車場、金融機関、高層マンション (野・糸井川, 2017)、自動車盗・車上狙い・部品狙いに駐車場、駐輪場、低層建物、基幹道路 (野・糸井川, 2017)、自動販売機狙いに駐車場 (野・糸井川, 2017) が、それぞれ犯罪生成・誘引要因として機能することを示唆する結果が得られている。

以上から、犯罪生成・誘引要因は、わが国の地理的犯罪予測にも寄与するものと考えられる。

4.2.3 犯罪可能要因

長期的・潜在的リスクを推定する要因として、RTM が想定していない要素として、犯罪可能要因が挙げられる。これは、犯罪の空間的集積を説明する要因として、Clark and Eck (2003)

vi 最近の環境犯罪学研究でも、こうした犯罪を生む階層的な構造についての議論は行われている。特に、Weisburd et al. (2012) では体系的な検討が行われており、マクロなレベルで犯罪を規定する社会解体的な観点 (Social Disorganization Perspective) として、本章で紹介した社会経済的な変数を、ミクロなレベルでは機会的な観点 (Opportunity Perspective) として、日常活動理論に関連する変数をそれぞれ設定し、犯罪の時系列的なパターンとの関連を検討している。Deryol et al. (2016)、Jones and Pridemore (2019) なども、同様の観点から実証分析を行っており、今後も継続的な検討が行われると思われる。

が犯罪生成・誘引要因に追加する形で提唱した概念である。犯罪可能要因は、犯罪生成・誘引要因のような特定の特徴を持った場所を指すというより、ある場所における（非合法的）行動に対する規制の状況を指す。具体的には、場所の管理不足、行動の規制の欠如、守り手や管理者の不在などの状況的な要因が該当する。たとえば車上狙いの場合、駐車場に常駐する管理者がいない、防犯カメラがない、周囲の人通りが少ないといった状況が、これにあたる。こうした要因は、ミクロスケールの犯罪発生要因とその予防について論じた CPTED (Crime Prevention Through Environmental Design : Crowe, 1991) の概念と関連づけられるだろう。CPTED では、元来の3要素である自然なアクセス・コントロール (natural access control)、自然な監視 (natural surveillance)、領域性の強化 (territorial reinforcement) に加え、後に付け加えられたイメージ/空間の管理 (image / space management)、活動の支援 (activity support)、対象の強化 (target hardening) といったものが、犯罪予防に重要であることを主張するが、逆にこうした要素の不在が、その場所での犯罪を容易にする、すなわち犯罪可能要因となりうると考えられるだろう。

地理的犯罪予測研究では、かつて犯罪可能要因に関する変数を検討したものは見当たらないものの、国内の地理的犯罪分析研究では、ひったくりの発生に昼間人口比率(自然な監視)、幅員4m以下道路割合(自然なアクセス・コントロール)がともに負の効果をもつこと(伊藤ら, 2010)、児童への不審行為の発生に、道路の見通し距離(自然な監視)が負の効果(佐々木ら, 2013)を、駐車場・空き地(自然な監視)が正の効果(吾郷ら, 2010)、沿道の壁が正の、沿道の店舗、沿道の出入口の有無、多い交通量が負の効果(いずれも自然な監視)をもつ(松永ら, 2009)、道路ネットワークの狭域な媒介中心性が負の効果(自然な監視)をもつ(山村ら, 2019)など、一部の罪種で犯罪発生と関連する結果が得られている。

一方で、犯罪可能要因を予測に考慮する際には、次のようなことが問題となる場合がある。一つは、対象とする犯罪に関する既存の実証研究が不足しているなどして、変数として投入できない場合があることである。いま一つは、要因として取り入れるべき変数があっても、それを既存の地理情報データから得るのが難しい場合が多いことである^{viii}。

このような問題がありながらも、犯罪生成・誘引要因の予測に対する有効性が確かめられた日本においては、犯罪可能要因を予測に取り入れることは、予測精度の向上に寄与するものと思われる。なぜなら、都市内に同じ犯罪生成・誘引要因の水準をもつ地域があったとしても、犯罪可能要因の存在によって、地域間にリスクの差が生まれるためである。つまり、犯罪可能要因は、犯罪生成・誘引要因を補完するものとして機能しうる。

vii 幅員が小さい道路は、一般的に歩道がなくガードレールなども設置されていないことが多いため、ひったくり発生に対して正の効果をもつとも考えられるが、ある程度幅員の確保された道路でないと、バイクなどでの犯行後にスピードを出して逃げるのが困難であることから、負の効果をもったと、分析者らは解釈している。

viii たとえば、防犯カメラが設置されているかといった情報は、地理空間情報にはなっておらず、入手は容易ではない。ここで紹介した国内の研究でも、現地調査や特殊な GIS データをもとにデータが作成されている。なお、他にも犯罪の抑止に関わる重要な要因としては、近隣の凝集性やインフォーマルな社会統制から構成される「集合的効力感 (Collective Efficacy)」(Sampson et al., 1997) が挙げられる。この指標は、地域単位での犯罪分析において、社会経済的要因と犯罪の関係を媒介、あるいは調整するものとして重視されるが、測定のためには住民に対する社会調査を要することから、犯罪予測に用いるのは容易ではない。

4.3 短期的・顕在的リスク

4.3.1 近接反復被害

ここでは、長期的・潜在的リスクと並んで、地理的犯罪予測において重要となると考えられる要素としての短期的・顕在的リスクについて考える。

Ratcliffe et al. (2016) で述べられたように、こうしたリスクの要因としてまず考えるべきは、犯罪の近接反復被害である。近接反復被害は、はじめ住宅侵入盗について報告され (Townsend et al., 2003; Johnson and Bowers, 2004; Bowers and Johnson, 2005; Johnson et al., 2007), その後、自動車盗 (Lockwood, 2012), 車上狙い (Johnson et al., 2006), 銃犯罪 (Ratcliffe and Rengert, 2008; Sturup et al., 2017), 路上強盗 (Glasner and Leitner, 2017; Haberman and Ratcliffe, 2012) でも確かめられている。たとえば、ひとたび住宅侵入盗が発生すると、少なくともむこう数週間以内で、被害宅から数百メートル範囲内のエリアで再度侵入盗が発生するリスクが高まり、距離と時間によってそのリスクが減衰する (Johnson et al., 2007), また、時間の経過とともに減衰するリスクの絶対量は、距離の隔たり度合いによって変動する (Bowers and Johnson, 2004) が、これは犯罪の時空間相互作用 (space-time interaction) などと呼ばれる。

この現象は、2つの異なるメカニズムから説明が可能とされる (Johnson and Bowers, 2004)^{ix}。一つは、事象依存 (event-dependent) 説であり、最初の被害によって、その対象が狙い目であることが犯行者自身、あるいはその同業者に知られることで、将来の被害リスクが高まるとする説明であり、被害に遭うことが、さらなる被害の可能性を押し上げる (boost) とされる。もう一つの説明は、リスク不均一 (risk heterogeneity) 説であり、特定の対象が備える持続的で目に見える (犯罪に対する) 脆弱性こそが問題であるとする説明であり、その脆弱性ゆえに互いに無関係な多くの犯行者に狙われる機会に晒される。ここでは、最初の被害は単なるリスク上昇の目印 (flag) でしかないとされる。

上の説明のうち、後者は長期的・潜在的リスク要因と関連づけることが可能だろう。すなわち、犯罪生成・誘引要因、あるいは犯罪可能要因が存在することによって、リスク不均一な状態 (特定の場所に犯罪に不利な状況) が持続するということである。このようなこともあり、近接反復被害を明示的に予測モデルに取り入れた Ratcliffe et al. (2016) では、特に事象依存説に着目し、直近の犯罪発生 (短期的・顕在的リスク) が、長期的・潜在的リスク要因の予測力を上回るか、というリサーチ・クエスチョンを提示している。

近接反復被害現象は、わが国でも住宅侵入盗、事業所侵入盗、ひったくり、車上狙い (菊池ら, 2010), 集合住宅での住宅侵入盗 (Hino and Amemiya, 2019), 性犯罪 (中谷, 2015; 中谷, 2017) など確かめられている。したがって、日本でも、近接反復被害による短期的・顕在的リスクを予測に適用できる可能性は高い。

4.3.2 前兆事案

さらに、近接反復被害と同様に、短期的・顕在的リスクの要因として考慮に値するのが、前兆事案 (Leading Indicator) である。前兆事案は、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、犯罪に関連する要素の存在と、それが組み上げられていることを暗に示しており、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

ix Johnson らの近接反復被害に関する説明は、Pease (1998) による反復被害のメカニズムの援用である。Pease (1998) では、反復被害が生じる原因としてさらに、貧困や犯罪を防ごうとする動機の欠如、犯罪発生に気づかない等といった理由から、犯罪に遭いやすい状況を変えることに失敗していることを挙げている。

する」という。Cohen et al. (2007) は、前兆事案が犯罪を予測する理由を、主に割れ窓理論 (Wilson and Kelling, 1982) と犯罪誘引要因に依拠して説明している。すなわち、軽微な秩序違反や非遵法的なふるまいに寛容な近隣が犯罪者を引き寄せ、さまざまな犯罪活動を可能とする状況であることのシグナルとなること。さらに、特定の土地利用・物理的特徴が、犯罪誘引要因として機能しながら、その近くにある「窓の割れた」近隣へと犯罪者を引き寄せる。

こうした前兆事案に対し、より重篤な犯罪被害が時空間的に近接する、いわば罪種間 (前兆事案と犯罪の間) の時空間相互作用は、日本で菊池ら (2009)、雨宮ら (2018) などが報告しており、近接反復被害と同様に、短期的・顕在的リスク要因として、地理的犯罪予測に寄与することが期待される。

なお、既存の地理的犯罪予測研究で扱われてきた短期的・顕在的リスク要因としては、季節、天候、曜日、大規模なイベントなどもある。これらの要因は、特定のタイミングで犯罪発生に影響するものの、それが都市空間のどの場所のリスクを局所的に上昇させるかに関する検討が、内外で不足しているため、ここでは考慮に入れないこととする。

4.4 リスクの組み合わせ方に関する検討

ここまで、わが国における地理的犯罪予測を行う上で、有効となりうる要因を長期的・潜在的リスクと、短期的・顕在的リスクとに分けて論じてきた。本節では、日本の文脈に照らした場合に、これらリスク要因、すなわち、社会経済的要因 (SES, 居住安定性)、犯罪生成・誘引要因、犯罪可能要因、近接反復被害、前兆事案をどのように組み合わせることが適切かを論じ、日本にふさわしい地理的犯罪予測手法を考える。

長期的・潜在的リスクと短期的・顕在的リスクを明示的に組み合わせた先行研究として、Ratcliffe et al. (2016) や Reinhart and Greenhouse (2017) の方法をみると、総合的リスクを求める際に、長期的リスクと短期的リスクとの単純な和から、これを求めている。しかし、近接反復被害が、RTM (犯罪生成・誘引要因による予測) で高リスクとされた場所で、より顕著になるとする Caplan et al. (2013) の指摘を踏まえると、長期的・潜在的リスクと短期的・顕在的リスクと相互作用をもつことが考えられる。したがって、これらの総合リスクを和という形で表現することは、適切とはいえない。

また、長期的リスクと短期的リスクを単純加算する形での予測は、日本の文脈で考えた場合、特に問題が大きいと考えられる。3章の分析から、海外と比して犯罪発生が低頻度であるわが国では、過去の犯罪発生がもつ情報量が少なく、将来を予測する手がかりとしては機能しにくい可能性がある。環境要因と過去の犯罪発生とで、予測に対する寄与が異なる状況下にあるにもかかわらず、両者を単純加算して同じ重みで扱えば、予測性能の低下を招きかねない。こうした日本特有の状況からも、長期的・潜在的リスク要因と短期的・顕在的リスク要因を独立に扱い、和をとるという演算を行うことは避けるべきといえるだろう。また、同じ理由から、わが国では長期的・潜在的リスク要因をより重視したモデリングが有効と考えられる。

そこで、本研究では、2種のリスクの組み合わせ方として、長期的・潜在的リスク要因をベースとして、そこに短期的・顕在的リスク要因を加味するような方法を提案する。具体的には、社会経済的要因、犯罪生成・誘引・可能要因などから算出される犯罪発生のリスク値に、近接反復被害、前兆事案によるリスク上昇確率を (加算ではなく) 乗算する形で取り入れる。地理的犯罪予測研究においては、長期的・潜在的リスクが件数 (の期待値) や確率の形で算出される。一方で、本研究の5~7章以降で採用する方法では、短期的・顕在的リスクは、「ある犯罪が1件発生した後、任意の時間・距離圏内で同種の犯罪が発生する件数は、期待され

る件数よりも x 倍多い」といったように、比の形でリスクの高まりが表される。この短期的・顕在的リスクの算出方法は、Ratcliffe et al. (2016) でも採用されているものだが、件数や確率で表される長期的・顕在的リスクの値と、短期的・顕在的リスクとしての比（リスク上昇効果）という異質なものを足し上げるという演算は、不適切と考えられる。両者の交互作用があることを前提として組み合わせる場合には、その件数、あるいは確率が、短期的・顕在的リスクの効果によって x 倍に押し上げられる、とする方が適切である。したがって、本研究で提案する手法では、2種のリスクの値同士を乗算する形をとる。

この手法は、図 4-1 で示すような手順で予測を行うものとする。すなわち、まず罪種、対象地域、予測対象期間を設定し、既存の理論や研究、あるいは実務家の知見などをもとに、当該罪種の発生を予測すると思われる長期的・潜在的リスク要因を選定する。そこから回帰分析などを用いて、過去の犯罪発生に寄与している変数を抽出、同時に係数の大きさなどに基づき、重みを決定する。一方で、過去の犯罪発生の時空間情報（地理的な位置と日付）から、近接反復被害、および当該罪種に関連する前兆事案の有無を確認するための分析を実行し、短期的・顕在的リスクが存在するかを確認する。このとき、近接反復被害などによるリスクの上昇が確認できなければ、長期的・潜在的リスクのみに基づいて犯罪予測地図を作成する。リスク上昇が確認できた場合には、長期的・潜在的リスクの値に、短期的・顕在的リスクの上昇率を乗算し、最終的なリスク値を算出、このリスク値に基づいて予測地図を出力する。

この構造を基本として、長期的・潜在的リスク、短期的・顕在的リスクの具体的な要因の選定や、各リスクを推定する分析方法などは、罪種ごとに検討する。これにより、提案手法に基づく具体的な予測モデルを、各罪種について作成することとする。

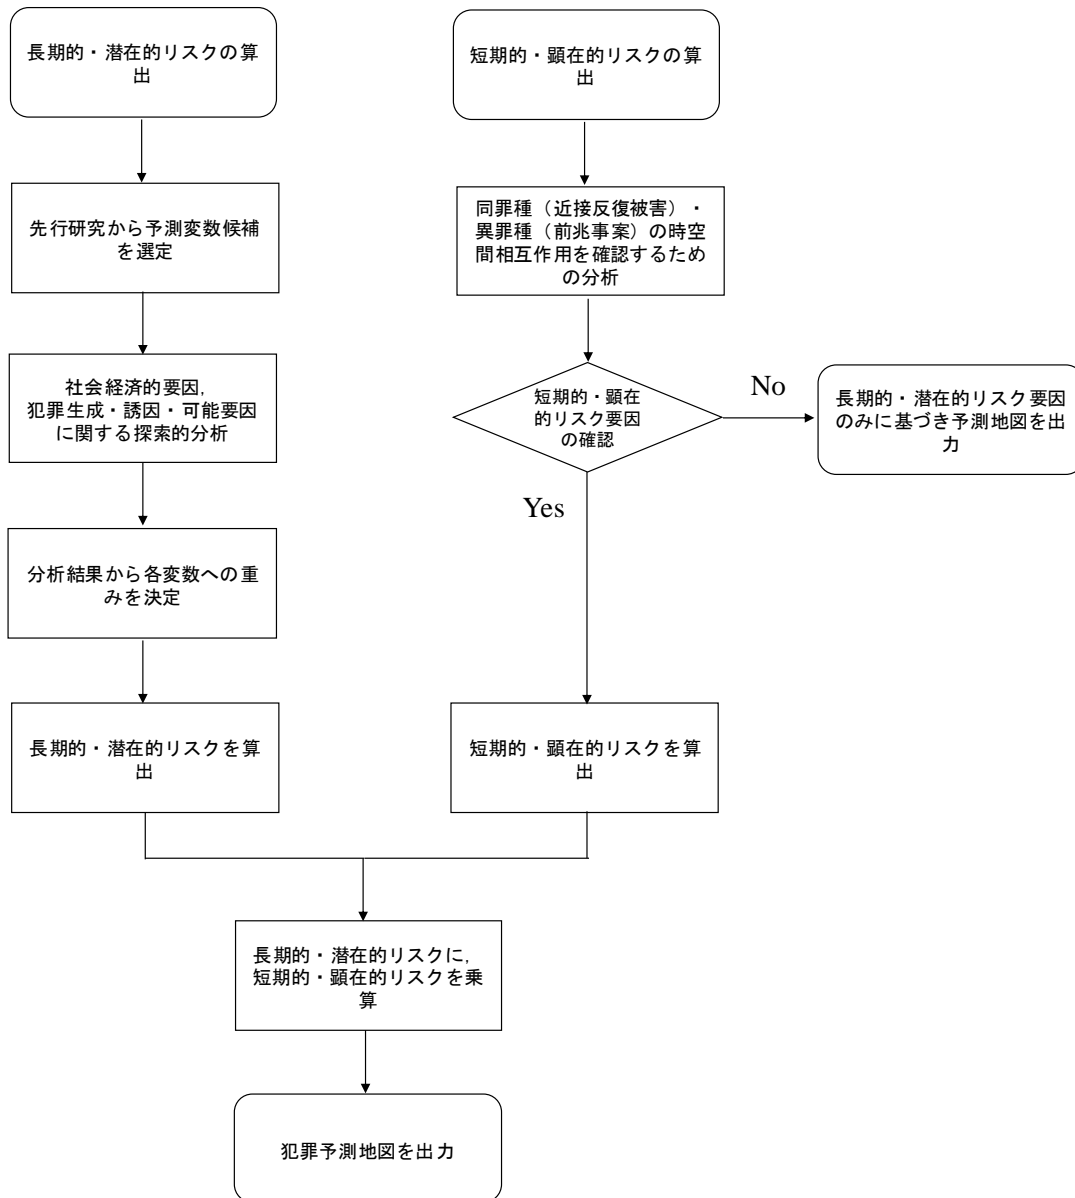


図 4-1 提案手法実行の手順

4.5 まとめ

本章では、これまでの地理的犯罪予測研究、および日本国内における地理的犯罪分析研究をふり返りながら、わが国において適切と思われる長期的・潜在的リスク要因、短期的・顕在的リスク要因の組み合わせ方法について検討した。以降の5, 6, 7章では、この手法を車上狙い・部品狙い（財産犯罪）、痴漢（身体犯罪）、還付金等詐欺（知能犯罪）に適用し、具体的な予測モデルを作成、性能評価を行うことで、手法の適用可能性を検討する。

4章の参考文献

- 1) 吾郷太寿・松永千晶・角知憲 (2010) 通学路上の児童の存在状況と物的空間構成要素が不審者出没に与える影響に関する研究.「土木計画学研究・論文集」, **27(2)**, 331-336.
- 2) 雨宮護 (2013) 潜在成長曲線モデルを用いた地区レベルでの犯罪の時系列変化と地区環境との関連の分析.「都市計画論文集」, **48(3)**, 351-356.
- 3) 雨宮護・島田貴仁・中谷友樹・樋野公宏・高橋あい (2018) 子供・女性に対する脅威事案は性犯罪等のリスクを高めるか? : 子供・女性の性犯罪等における先行指標の検討.「都市計画報告集」, **17**, 216-222.
- 4) 石川愛・鈴木広隆 (2008) 防犯照明設備の実態と路上犯罪との関連の検討防犯照明設備の実態と路上犯罪との関連の検討.「日本建築学会環境系論文集」, **623**, 101-106.
- 5) 伊藤・糸井川・梅本 (2010) 局所的環境特性から見た犯罪発生要因に関する研究:板橋区におけるひったくり犯罪を対象として.「地域安全学会論文集」, **13**, 109-118.
- 6) 上杉昌也・樋野公宏 (2015) 東京都区部における住宅侵入盗と近隣社会経済的特性の関係.「都市計画論文集」, **50(3)**, 608-615.
- 7) 菊池城治・雨宮護・島田貴仁・齊藤知範・原田豊 (2010) 近接反復被害の罪種間比較: 時空間 K 関数の応用.「GIS-理論と応用」, **18(2)**, 129-138.
- 8) 菊池城治・雨宮護・島田貴仁・齊藤知範・原田豊 (2009) 声かけなどの不審者遭遇情報と性犯罪の時空間的接近性の分析.「犯罪社会学研究」, **34**, 150-162.
- 9) 木梨真知子・金利昭 (2008) 防犯計画のための環境的要因分析に基づく犯罪発生空間の考察.「土木計画学研究・論文集」, **25**, 329-338.
- 10) 佐々木雄希・藤井智史・岸本達也 (2013) 局所的環境特性から見た不審者事案発生及び未発生に影響する環境要因: 埼玉県草加市を対象として.「地域安全学会論文集」, **20**, 21-28.
- 11) 島田貴仁 (2013) 環境心理学と犯罪研究:犯罪原因論と犯罪機会論の統合に向けて.「環境心理学研究」, **1(1)**, 46-57.
- 12) 中谷友樹 (2015) 京都市内で認知された強姦・強制わいせつ事件の時空間的集中と近接反復被害.『京都府警察犯罪抑止対策調査研究会(性犯罪対策研究部会)報告書資料編』, 京都府警察犯罪抑止対策調査研究会・性犯罪対策研究部会, <<http://www.pref.kyoto.jp/fukei/anzen/seitai/tokumei/houkoku.html>>, 最終閲覧日 2019年10月10日.
- 13) 中谷友樹 (2017) 予防医学の考えに基づく犯罪予防.『警視庁子ども・女性の安全対策に関する有識者研究会提言書』, 警視庁子ども・女性の安全対策に関する有識者研究会, <http://www.keishicho.metro.tokyo.jp/kurashi/anzen/anshin/kodomo_josei_anzen.html>, 最終閲覧日 2019年10月10日.
- 14) 土方孝将・雨宮護・糸井川栄一・梅本通孝・太田尚孝 (2015) 地方都市における住宅侵入盗被害と地区特性との関連.「都市計画論文集」, **50(3)**, 824-831.
- 15) 野貴泰・糸井川栄一 (2017) 犯罪多発地点の予測に基づく防犯パトロール経路に関する提案.「地域安全学会論文集」, **31**, 195-204.
- 16) 花岡和聖 (2018) 大阪府における不審者遭遇情報の地理的分布: Risk Terrain Model を用いた犯罪リスクのマッピング.「立命館文學」, **656**, 47-59.
- 17) 樋野公宏・小島隆矢 (2007) 住宅侵入盗発生率と地域特性との関係: 東京都下 29 区市の町丁を対象に.「日本建築学会計画系論文集」, **616**, 107-112.
- 18) 松永千晶・宮崎彩・角知憲 (2009) 通学路上の犯罪発生に関する要因分析.「土木計画学研究・論文集」, **26(1)**, 239-243.
- 19) 山村俊貴・樋野公宏・上杉昌也・雨宮護 (2019) 東京都区部における性犯罪の前兆事案と街路ネットワークの関係: Urban Network Analysis 指標に着目して.「GIS 理論と応用」,

- 27(1), 33-42.
- 20) Bogomolov, A., Lepri, B., Staiano, J., Oliver, N., Pianesi, F., and Pentland, A. (2014) Once upon a crime: towards crime prediction from demographics and mobile data. In *Proceedings of the 16th international conference on multimodal interaction*, 427-434.
 - 21) Bowers, K., and Johnson, S. (2005) Domestic burglary repeats and space-time clusters: The dimensions of risk. *European Journal of Criminology*, **2**(1), 67-92.
 - 22) 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.
 - 23) Brantingham, P. and Brantingham, P. (1993) Environment, Routine, and Situation: Toward a Pattern Theory of Crime. In *Routine Activity and Rational Choice, Advances in Criminological Theory*. Vol. 5, Clarke, R. and Felson, M. eds. New Brunswick: Transaction Publishers, 259-294pp.
 - 24) Brantingham, P., and Brantingham, P. (1991) Introduction: The dimensions of crime. In *Environmental criminology*, Brantingham, P. and Brantingham, P. eds. Long Grove: Waveland Press., 7-26pp.
 - 25) Clarke, R., and Eck, J. (2003) Become a problem-solving crime analyst: In *55 small steps*. Jill Dando Institute of Crime Science. London: Ashford Colour Press.
 - 26) Cohen, L., and Felson, M. (1979) Social change and crime rate trends: A routine activity approach. *American Sociological Review*, **44**(4), 588-608.
 - 27) Cohen, J., Gorr, W., and Olligschlaeger, A. (2007) Leading indicators and spatial interactions: A crime-forecasting model for proactive police deployment. *Geographical Analysis*, **39**(1), 105-127.
 - 28) Crowe, T. (1991) *Crime prevention through environmental design: Applications of architectural design and space management concepts*. Boston: Butterworth-Heinemann.
 - 29) Deryol, R., Wilcox, P., Logan, M., and Wooldredge, J. (2016) Crime places in context: An illustration of the multilevel nature of hot spot development. *Journal of Quantitative Criminology*, **32**(2), 305-325.
 - 30) Farrell, G. (2015). Crime concentration theory. *Crime Prevention and Community Safety*, **17**(4), 233-248.
 - 31) Glasner, P., & Leitner, M. (2017). Evaluating the impact the weekday has on near-repeat victimization: A spatio-temporal analysis of street robberies in the city of Vienna, Austria. *ISPRS International Journal of Geo-Information*, **6**(1), 3.
 - 32) Gorr, W., and Olligschlaeger, A. (2002) *Crime hot spot forecasting: Modeling and comparative evaluation, final project report*. Washington, DC: National Criminal Justice Reference Service.
 - 33) Haberman, C. P., & Ratcliffe, J. H. (2012). The predictive policing challenges of near repeat armed street robberies. *Policing: A Journal of Policy and Practice*, **6**(2), 151-166.
 - 34) Hino, K., & Amemiya, M. (2019). Spatiotemporal analysis of burglary in multifamily housing in Fukuoka City, Japan. *Cities*, **90**, 15-23.
 - 35) Hu, T., Zhu, X., Duan, L., and Guo, W. (2018) Urban crime prediction based on spatio-temporal Bayesian model. *PLoS One*, **13**(10), e0206215.
 - 36) Hunter, A. (1971) The ecology of Chicago: Persistence and change, 1930-1960. *American Journal of Sociology*, **77**(3), 425-444.
 - 37) Johnson, S., Bernasco, W., Bowers, K., Elffers, H., Ratcliffe, J., Rengert, G., and Townsley, M. (2007) Space-time patterns of risk: A cross national assessment of residential burglary victimization. *Journal of Quantitative Criminology*, **23**(3), 201-219.
 - 38) Johnson, S., and Bowers, K. (2004) The burglary as clue to the future: The beginnings of

- prospective hot-spotting. *European Journal of Criminology*, **1**(2), 237-255.
- 39) Johnson, S., Summers, L., and Pease, K. (2006) *Vehicle crime: Communicating spatial and temporal patterns*. <<http://discovery.ucl.ac.uk/1430754/>>, (最終閲覧日 2019年9月2日)
- 40) Jones, R., and Pridemore, W. (2019) Toward an integrated multilevel theory of crime at place: Routine activities, social disorganization, and the law of crime concentration. *Journal of Quantitative Criminology*, **35**(3), 543-572.
- 41) Kadar, C., Maculan, R., and Feuerriegel, S. (2019) Public decision support for low population density areas: An imbalance-aware hyper-ensemble for spatio-temporal crime prediction. *Decision Support Systems*, **119**, 107-117.
- 42) Ken Pease (1998) *Repeat Victimization: Taking Stock*. London: Home Office, 6pp.
- 43) Law, J., Quick, M., and Chan, P. (2014) Bayesian spatio-temporal modeling for analysing local patterns of crime over time at the small-area level. *Journal of Quantitative Criminology*, **30**(1), 57-78.
- 44) Lockwood, B. (2012). The presence and nature of a near-repeat pattern of motor vehicle theft. *Security Journal*, **25**(1), 38-56.
- 45) Moffatt, R. (1983) Crime prevention through environmental design – A Management Perspective, *Canadian Journal of Criminology*, **25**, 19-31.
- 46) Prestemon, J., Butry, D., and Thomas, D. (2013) Exploiting autoregressive properties to develop prospective urban arson forecasts by target. *Applied Geography*, **44**, 143-153.
- 47) Ratcliffe, J., and Rengert, G. (2008) Near-repeat patterns in Philadelphia shootings. *Security Journal*, **21**(1-2), 58-76.
- 48) Ratcliffe, J., Taylor, R., and Perenzin, A. (2016) Predictive Modeling Combining Short and Long-Term Crime Risk Potential: Final Report. <<https://www.ncjrs.gov/pdffiles1/nij/grants/249934.pdf>>, 最終閲覧 2019年5月8日.
- 49) Reinhart, A. and Greenhouse, J. (2018) Self-exciting point processes with spatial covariates: modelling the dynamics of crime. *Journal of the Royal Statistical Society*, **67**(5), 1305-1329.
- 50) Rummens, A., Hardyns, W., and Pauwels, L. (2017) The use of predictive analysis in spatiotemporal crime forecasting: Building and testing a model in an urban context. *Applied Geography*, **86**, 255-261.
- 51) Sampson, R., and Lauritsen, J. L. (1994) Violent victimization and offending: Individual-, situational-, and community-level risk factors. *Understanding and Preventing Violence*, Volume 3: Social Influences, 1.
- 52) Sampson, R., Raudenbush, S., and Earls, F. (1997) Neighborhoods and violent crime: A multilevel study of collective efficacy. *Science*, **277**(5328), 918-924.
- 53) Taylor, R., Ratcliffe, J., and Perenzin, A. (2015) Can we predict long-term community crime problems? The estimation of ecological continuity to model risk heterogeneity. *Journal of research in crime and Delinquency*, **52**(5), 635-657.
- 54) Townsley, M., Homel, R., & Chaseling, J. (2003). Infectious burglaries. A test of the near repeat hypothesis. *British Journal of Criminology*, **43**(3), 615-633.
- 55) Shaw, C. and McKay, H. (1942) *Juvenile delinquency and urban areas*. Chicago: University of Chicago Press.
- 56) Sturup, J., Rostami, A., Gerell, M., & Sandholm, A. (2018). Near-repeat shootings in contemporary Sweden 2011 to 2015. *Security Journal*, **31**(1), 73-92.
- 57) Vomfell, L., Härdle, W. K., and Lessmann, S. (2018) Improving crime count forecasts using Twitter

- and taxi data. *Decision Support Systems*, **113**, 73-85.
- 58) Wang, X., and Brown, D. (2012) The spatio-temporal modeling for criminal incidents. *Security Informatics*, **1**(1), 1-17.
- 59) Weisburd, D., Groff, E., and Yang, S. (2012) *The criminology of place: Street segments and our understanding of the crime problem*. New York: Oxford University Press, 90-165pp.
- 60) Wilcox, P., Land, K., and Hunt, S. (2003) *Criminal Circumstance: A Dynamic Multicontextual Criminal Opportunity Theory*. New York: Aldine de Gruyter.
- 61) Wilson, J, and Kelling G. (1982) Broken Windows: The Police and Neighborhood Safety. *Atlantic Monthly*, **249**, 29-38.

第5章 新手法の車上狙い・部品狙いへの適用と評価

5.1 はじめに

本章では、4章で検討した新手法を車上狙い・部品狙い（以下、車上狙い等）に適用する。具体的には、3章でも扱った車上狙い等を対象に、新手法の発想をもとに、妥当と思われる予測モデルを作成、実際のデータを用いて予測性能を評価する。これを通じて、車上狙い等のような財産犯罪に対する新手法の適用可能性をはかる。

本分析では、車上狙い等の予測に対し高い正確性を示したRTMをベースとして、モデルを作成する。ただし、3章の分析では、RTMは予測の安定性の点では、近接反復被害に着目したモデルであるProMapに劣っていた。長期的・潜在的リスクに依拠するRTMに対し、短期的・顕在的リスクを組み合わせることで、犯罪発生パターンの変化を反映し、予測の安定性を向上させることを試みる。

5.2 車上狙い・部品狙いに適した予測モデルの作成

5.2.1 長期的・潜在的リスク要因の検討

本章では、4章で提案された予測手法を車上狙い等に適用する場合、どのようなモデリングにより、RTMを改良するのがよいかを検討する。

まず、長期的・潜在的リスク要因について、日本国内において住宅侵入盗と社会経済的要因の関連をみた研究は、4章で挙げた通り複数存在し（雨宮，2013；上杉・樋野，2015；土方ら，2015；樋野・小島，2007），わが国でも、SESや居住安定性が侵入盗を抑制する可能性が示されている。一方で、車上狙いや部品狙いに関しては先行研究が乏しく、どのような社会経済的要因が予測に有効であるか、定かではない。

また、犯罪生成・誘引要因としては、3章で分析した通り、車上狙い等に関しては、駐車場、コンビニエンスストア、道路などが機能するだろう。

犯罪可能要因としては、CPTEDにおける自然な監視や、機械による監視としての防犯カメラ、また組織的な監視としての警備員の存在などが考えられる。だが、これらも先行研究の乏しさから、どのような要因が予測に有効かはわからず、また、防犯カメラや警備員の存在などは、地理空間情報として入手することは容易ではない。

5.2.2 短期的・顕在的リスク要因の検討

短期的・顕在的リスクの要因としての近接反復被害は、車上狙いにおいてもJohnson et al. (2006)や菊池ら(2010)で確かめられていることもあり、予測に有効だと考えられる。一方で、異罪種間の時空間相互作用は、車上狙い等に関しては、どのような犯罪がその前兆となりうるか、まだわかっていない。

5.2.3 予測モデルの作成

このように、車上狙い・部品狙いについて社会経済的要因や犯罪可能要因を考慮するには、有力な予測変数の選定や、予測変数となるデータの利用可能性の面で課題がある。また、施設等の点・線の分布を用いる RTM の特徴から、社会経済的要因のような、国勢調査などで得られ、地区単位で集計されて公開される指標は、予測変数としては取り入れにくいということがある。

そこで本分析では、RTM で考慮すべき要因の不足を解決するために、過去数年の犯罪の蓄積に着目する。数年単位といった長期スパンで見たときに犯罪が集積しているエリアは、具体的な要因が何であるかは不明でも、何らかの社会経済的要因や、犯罪生成・誘引・可能要因が潜在していると推論できる。そこで、RTM（事前に明示的に設定された犯罪生成・誘引要因を用いたもの）により数年分の犯罪ホットスポットの存在するエリアを予測する回帰モデルを作成した上で、同モデルを適用した際の残差を求める。この残差は、RTM において想定された犯罪生成・誘引要因では説明しきれない、社会経済的要因や犯罪可能要因、および未知の犯罪生成・誘引要因などを含む成分と考えることができる。この残差を予測変数としてモデルに追加的に組み込むことにより、RTM にこれまで考慮されてこなかった社会経済的要因や犯罪可能要因等を取り込むことを試みる。ただし、この残差と事前に設定された犯罪生成・誘引要因は、地理的に重ならない部分が大きくなるため、従来の RTM が行うように、これらを単純に重ね合わせる方法をとると、予測領域の面積のいたずらな拡大を招く。そのため、提案手法では、両者の組み合わせ方を検討しつつ、既存の RTM の予測したリスクを効率的に補う形になるように残差を取り入れることとする。

また、本章では、車上狙い等について短期的・顕在的リスク要因を加味するにあたり、近接反復被害のみを考慮する。前兆事案による効果は、車上狙い等の前兆となるような事案が想定しづらく、またこれまでの研究で明らかになっていないことから、今回は考慮しない。近接反復被害の効果は、4章で述べた通り、長期的・潜在的リスクの値を重視しつつ、これにかけ合わせる形でモデルに追加することとする。

5.3 長期的・潜在的リスクに関する分析

分析単位と応答変数の設定については、3章と同一であるため、ここでは省略する。

今回、主要な犯罪生成・誘引要因で説明できない未知の要素（社会経済的要因や犯罪可能要因、および未知の犯罪生成・誘引要因）を推定するために、3章の分析と同一のエリアにおいて、予測対象期間より過去の2008年1月～2014年6月に発生した車上狙い等のポイントデータ（計1235件）を用いた。なお、ここで用いる RTM のリスク値は、3章の分析において、自動車が駐車されやすく、かつ駐車後に所有者が車から一定時間離れることが想定される施設等のうち、主要なものを犯罪生成・誘引要因として回帰分析を行い、車上狙い・部品狙いに対して統計的に有意な効果をもつとされた駐車場、コンビニエンスストア、道路を抽出したものであり、これらを指して主要な犯罪生成・誘引要因とみなしている。そのため、犯罪生成・誘引要因のうち、考慮されていない未知の犯罪生成・誘引要因の寄与は、相対的に少ないものと考えることができる。

本章の分析では、未知の環境要因の大きさの推定にあたり、空間回帰分析を実行し、その残差を使用した。残差は、以下の方法により求めた。

- ① 2008年1月～2014年6月の車上狙い等の発生地点データから、カーネル密度推定（セルサイズ25m四方、バンド幅250m）を実行した。
- ② ①で求めた過去の車上狙い等のカーネル密度推定値を応答変数として、RTM のリス

表 5-1 RTM のリスク値と空間回帰残差のクロス表

		回帰の残差		
		正に大 (3)	0に近い (1-2)	負 (0)
RTM (主要な犯罪生成・誘引要因)	高(7-9)	Aa. 犯罪生成・誘引要因：多かつ 犯罪：多 (解釈) RTMで説明できる以上の犯罪が発生：不利な社会経済的条件や犯罪可能要因、未知の要因が存在する可能性	Ab. 犯罪生成・誘引要因：多かつ 犯罪：ある程度多 (解釈) 犯罪生成・誘引要因の多さに見合った犯罪発生水準	Ac. 犯罪生成・誘引要因：多かつ 犯罪：少 (解釈) 犯罪生成・誘引要因は多いが犯罪は少ない：犯罪を抑止する何らかの要因が存在する可能性
	低(0-6)	Ba. 犯罪生成・誘引要因：少かつ 犯罪：多 (解釈) RTMで説明できない要因により、犯罪が発生：不利な社会経済的条件や犯罪可能要因、未知の要因が存在する可能性	Bb. 犯罪生成・誘引要因：少かつ 犯罪：ある程度多 (解釈) 犯罪生成・誘引要因の多さに見合った犯罪発生水準	Bc. 犯罪生成・誘引要因：少かつ 犯罪：少 (解釈) 犯罪生成・誘引要因が少なく、犯罪も少ない

ク値 (0-9 の離散値) により回帰分析を行った。この際、式 (5.1) で表されるような、応答変数に空間従属性を仮定した空間ラグモデル (Spatial Lag Model, 以下 SLM) を用いた。カーネル密度推定は、密度推定値を求める当該セルの周辺 (バンド幅の内側) のセルに含まれる点 (ここでは犯罪イベント) を考慮に入れることから、隣接するセル同士では推定値が似る。これにより生じる応答変数の空間的自己相関を考慮し、今回は空間ラグモデルを採用した。応答変数 y はカーネル密度推定値であり、 y_i, y_j はそれぞれ当該セル i とその隣接セル j のカーネル密度推定値を指す。また、 ρ は空間的自己相関の強さを示すパラメータ、 w_{ij} は空間重み行列、 $x_{1,i}$ はセル i の RTM リスク値、 β_0, β_1 はそれぞれ切片と予測変数 (ここでは RTM リスク値) のパラメータである。 ε_i は残差であり、平均 0、分散 σ^2 の正規分布にしたがう。空間重み行列は、クイーン型の近隣関係 (一次) に基づいて求めた。

$$y_i = \rho \sum_{j=1}^n w_{ij} y_j + \beta_0 + \beta_1 x_{1,i} + \varepsilon_i$$

(5.1)

ここで、 ε_i は実測値から、空間ラグの効果、および主要な犯罪生成・誘引要因から推定されるリスクの高さを除いたものであり、社会経済的要因、犯罪可能要因、未知の犯罪生成・誘引要因などからなる要素を表しているとみなすことができる。

③ 回帰分析から残差 ε_i を求めた。求めた残差は、分布 (図 5-1ⁱ) をみながら、負の場合は 0 の値を割り付け、正の場合は大きさに応じて 3 水準に等量分類して 1-3 の値を割り

i 図 5-1 には、空間回帰分析の応答変数となったカーネル密度推定値のヒストグラムも同時に示した (左図)。応答変数の分布について、平均： 2.2×10^{-4} 、中央値： 2.1×10^{-4} 、最頻値： 1.7×10^{-4} で互いに近く、平均 $\pm 1SD$ (標準偏差は 1.0×10^{-4}) の範囲にはデータの 68.2% が含まれており、ほぼ正規分布とみなせる。また、残差の分布については、平均： 1.1×10^{-4} 、中央値： 1.0×10^{-4} 、最頻値： 0.9×10^{-4} で互いに近く、平均 $\pm 1SD$ (標準偏差は 1.0×10^{-4}) の範囲にはデータの 67.5% が含まれている。こちらは、想定される平均 0 の正規分布からは逸脱しているものの、分布の形には正規性が認められる。




図 5-1 2008年1月～2014年6月の車上狙い等データから求めたカーネル密度推定値（左），および空間回帰の残差（右）の分布

付けた。

④ 各セルに，③で分類された際の水準である0-3を値として与え，リスク面を作成した。これにより，Caplan et al. (2011)によるオリジナルのRTMで，リスク要因の水準数として採用されている4水準に空間回帰の残差 ε_i を分類した。

次に，空間回帰の残差 ε_i の取込みについて，以下の通り行った。

① RTMのリスク値と空間回帰残差との組み合わせを表5-1のように6通りに整理した。すなわち，RTMのリスク値が高(7-9)，中から低(0-6)の2通り，残差は正に大(3)，0に近い(1-2)，負(0)の3通り，の計6通りを設定した。このとき，たとえば，表中Aaは，RTMで想定されるリスク以上に犯罪が発生し，RTMで考慮された犯罪生成・誘引要因以外の何らかの要因が存在するものと想定できる。反対にAcは，想定されるリスクに比して犯罪発生は少なく，犯罪に対する抑制的な何らかの要因（たとえば，地区の社会的経済的地位が高く防御性の高い自動車が多い，人通りが多く自然な監視が機能している等々）が存在すると考えられる。

② RTMのリスク値と空間回帰残差との組み合わせから高リスク領域を設定した。3章で作成したRTMでは，RTMのリスク値のみにしたが，その値が7-9，すなわち表5-1中のAa，Ab，Acの領域を高リスク領域としていた。しかし，①で述べたように，過去の犯罪蓄積を考慮すると，Acに該当する領域では，RTMが想定するリスクは過大であることが予想されるため，この領域は高リスク領域から除外した。逆に，表5-1中のBaに該当する領域は，RTMが想定するリスクに比して，実際は犯罪が多く発生していることになり，RTMでの予測を補完するものとなりうる。そのため，この領域を新たに高リスク領域として加えた。表5-1中の太枠で囲ったセルは，最終的な高リスク領域として採用したものの，灰色セルは，3章で作成したRTMから除外したものである。

③ 高リスク領域の絞り込みを行った。②により新たに高リスク領域としたBaは，実際にはRTMにおける極めて低いリスク値のセルを含んでいる。こうしたセルをすべて取り込むことは，いたずらに高リスク領域を拡大させることになる。これを避けるべく，Baのうち，RTMのリスク値が低いものとして，値0から6をほぼ等分した0-3を高リスク領域から除いた。

上記②と③の処理を経て，Acに該当する領域（オリジナルのRTMのリスク値が7-9）は

4-6 の値を再割り当て、Ba に該当する領域のうち、オリジナルの RTM の値が 4-6 の場合には 7-9 を再割り当てし、他の領域のリスク値はそのままとした。すなわち、表 5-1 における太枠で囲った部分 Aa, Ab, Ba を採用し、灰色にハイライトした部分 Ac を除外した（ただし、Ba のうちオリジナルの RTM リスク値が 1-3 のものは除外）。このように、空間回帰残差と、RTM のリスク値それぞれの地理的分布を比較し、犯罪発生リスクが高いと考えられる領域を残し、逆にそのリスクが低いと考えられる領域を省くことで、過去の犯罪蓄積から、RTM が捉えきれていなかった要因だけを抽出できるよう配慮した。以降では、上記の処理（残差の取り込み）を行った後のモデルを「e-RTM (extended RTM)」と呼称する。

5.4 短期的・顕在的リスクに関する分析，長期的・潜在的リスクとの組み合わせ方

短期的・顕在的リスクの算出・取り込みについては、以下の手順で行った。

① 時空間 K 関数 (Diggle et al., 1995) を用いて、近接反復被害効果を算出した。時空間 K 関数は、菊池ら (2010) によって、日本での車上狙いの近接反復被害傾向の検証に用いられた手法であるため、今回もこれを用いた。近接反復被害効果は、データ点が時空間上にランダムに分布している状況と比較したとき、実際のデータで時空間的集積性が何倍程度大きくなっているか（すなわち、近接反復被害のリスクが何倍程度高まっているか）を表す。これは、具体的には、Diggle らが時空間的集積性の程度を分析する目的で提案した D_0 に 1 を加えた D_0+1 で表現できる（次式）。

$$D_0(s, t) + 1 = \frac{\hat{R}(s, t)}{\hat{R}(s)\hat{R}(t)} \quad (5.2)$$

ここで $\hat{R}(s, t)$ は、時空間 K 関数、 $\hat{R}(s)$ 、 $\hat{R}(t)$ はそれぞれ、空間、時間の K 関数である。 D_0+1 は、 $\hat{R}(s, t)$ と $\hat{R}(s)\hat{R}(t)$ の比を表し、時空間的集積性の度合いを任意の空間・時間の範囲で表現したものとなる。すなわち、 D_0 に 1 を加えることで、時空間的に独立な場合と比較して、何倍の時空間集積が観測されていたかを表現することができる。この値を本分析における近接反復被害効果とした。

対象地域における車上狙い等の近接反復被害効果について検討するため、2008 年 1 月～2014 年 6 月の車上狙い等の発生日・発生日点を用いて、時空間 K 関数を求めた。時空間的集積性の程度を見るために定める空間・時間の幅は、100 m・7 日（最大 1000 m, 56 日間）とした。モンテカルロシミュレーション (999 回) に基づく有意性検定の結果、全体として有意な時空間的集積が確認された ($p < 0.001$)。これに基づいて算出された D_0+1 の値を 100 m・7 日の時空間バンド幅ごとに示したものが表 5-2 である。ここでは、十分な時空間集積が認められる値として、 D_0+1 が 2 以上（ランダムと比較して近接反復被害のリスクが 2 倍以上高まっている）のセルに着目した（表では灰色に着色）。既存研究 (Townesley et al., 2003) の知見に基づく近接反復被害の効果が及ぶ範囲ⁱⁱ（表で太枠で囲った部分）として、1 件の犯罪から

ii Townesley et al. (2003) では、時空間集積性の強さの度合いについて、時間のみの集積（距離を問わず近い時間内で集積が見られるパターン：表 5-2 では縦方向の集積）や、空間のみの集積（時間を問わず近い空間内で集積が見られるパターン：表 5-2 では横方向の集積）ではなく、時間・空間ともに集積が見られるもの（表 5-2 では斜め方向）を近接反復被害としてみなせるものとした。これに基づき、本研究では 100 m・7 日以内の D_0+1 の値を採用した。

100 m・7日以内において $D_0 + 1 = 2.25$ (倍) のリスクの高まりが観測されたため、以後の分析ではこれを用いた。

② ①での検討に基づき、近接反復被害効果が及ぶ範囲として、予測対象となる2014年の7月から12月の6ヵ月に対して、各月1日から前7日以内(すなわち、6月、7月、…、11月の最終週)の犯罪発生地点から100mの範囲にあるセルを抽出した。次に、上述の残差を反映したRTMのリスク値に対して、上で抽出したセルに該当するものについては100m・7日以内の近接反復被害のリスクの高まりを示す2.25を乗算し、それ以外のセルは1を乗算した。総合リスク値 $\lambda'_{i,t}$ は、セル i の長期的・潜在的リスク値 λ_i 、月 t におけるセル i の短期的・顕在的リスク値 $\eta_{i,t}$ を用いて式(5.3)のように表せる。ただし、 $\eta_{i,t}$ は式(5.4)のような値をとるものとする。ここで、 $N(k, d+u-7)$ は、月 t の初日 d から直近7日以内の各日において、セル i から100m圏内にあるセル k で発生した車上狙い等の件数である。

$$\lambda'_{i,t} = \lambda_i \eta_{i,t} \tag{5.3}$$

$$\eta_{i,t} = \begin{cases} 2.25, & \xi \geq 1 \\ 1, & \text{otherwise} \end{cases} \tag{5.4}$$

$$\xi = \sum_{u=0}^6 N(k, d+u-7) \tag{5.5}$$

③ 各セルのリスク値 $\lambda'_{i,t}$ を再度0-9の10水準に等量分類し、リスク面を作成した。

このように、オリジナルのRTMに対して、空間回帰残差を考慮し、さらに近接反復被害効果をかけ合わせたモデルを、以降では「e-RTM*NR (extended RTM * Near Repeat)」と呼称する。既に述べたように、RTMは月単位での運用が想定されており、毎月の初日に予測地図を提示し、当該月の戦略を立案する。この場合、毎月一日時点で把握できる犯罪発生情報は、前月までのものに限られる。そのため、本分析でも、近接反復被害効果を取り入れるにあたり、前月最終週の車上狙い等の情報を用いた。

表 5-2 100 m・7日ごとの近接反復被害効果 ($D_0 + 1$) の大きさ

距離 (m) / 日	≦0	≦7	≦14	≦21	≦28	≦35	≦42	≦49	≦56
≦0	24.63	5.75	5.32	4.53	3.97	3.76	3.50	3.40	3.23
≦100	6.08	2.25	1.84	1.76	1.71	1.64	1.54	1.50	1.49
≦200	3.58	1.59	1.42	1.36	1.38	1.33	1.28	1.27	1.27
≦300	2.70	1.48	1.37	1.30	1.29	1.26	1.23	1.21	1.20
≦400	2.06	1.38	1.30	1.25	1.22	1.19	1.17	1.16	1.15
≦500	1.73	1.26	1.21	1.17	1.15	1.13	1.11	1.11	1.10
≦600	1.60	1.21	1.15	1.13	1.12	1.10	1.09	1.08	1.07
≦700	1.35	1.14	1.11	1.09	1.08	1.07	1.07	1.06	1.05
≦800	1.28	1.13	1.10	1.08	1.08	1.07	1.06	1.05	1.04
≦900	1.23	1.10	1.08	1.06	1.06	1.05	1.05	1.04	1.04
≦1000	1.15	1.06	1.05	1.04	1.05	1.04	1.04	1.04	1.03

5.5 予測モデルの適用と評価

5.5.1 検証の方法

今回の提案手法によるモデル e-RTM*NR の比較対象として、既存研究で採用されていたような、諸要因の単純な加算を行うモデル（「e-RTM+NR」と呼称）を作成した。e-RTM*NR と空間回帰残差の取込みまでは同様の手順で作成し、その後、短期的・顕在的リスクの値を加算（前月最終週に犯罪が発生したセルは 2.25，その他のセルは 0 を足す）した後、0-9 の 10 水準に等量分類したものとした。

また、他にオリジナルの RTM（単に「RTM」と呼称）、e-RTM も比較の対象とした。

以上の分析には ArcGIS10.5, OpenGeoDa ver. 1.12.1, 統計解析環境 R ver. 3.5.0, および R の Splanacs パッケージを用いた。

また、次の指標で各モデルの予測精度、およびその安定性を評価した。評価は月単位で行った。

予測の正確性、および安定性を評価する指標は、3 章と同じものを用いた。

さらに、提案手法によって新たに犯罪の発生を的中させることができた地域の特徴を見ることで、新たに見出された高リスクな地域の新規性を明らかにする。具体的には、RTM と e-RTM*NR の予測地図を比較し、e-RTM*NR において新たに犯罪を的中させることができた地域の、人口密度、地区面積あたりの事業所数、持ち家世帯割合、民営借家世帯割合、戸建世帯割合、高層世帯割合等の人口統計・社会経済的指標、平均道路リンク長、幅員ごとの道路割合等の物理構造的な指標の、対象地域全体における位置づけを見た。ここで検討した指標のうち、人口密度、各種の世帯割合については、2015 年国勢調査の小地域別集計の情報を、事業所数については 2014 年経済センサスの小地域集計の情報を、道路リンクの延長や幅員等の情報は、住友電工システムソリューション株式会社の提供する拡張版全国デジタル道路地図データベース（2016 年版）から該当する情報を参照し、町丁目ごとに集計して用いた。

5.5.2 結果

図 5-2 に、オリジナルの RTM である RTM と、今回の提案手法である e-RTM*NR の出力結果を示す。RTM では、予測変数として用いた駐車場等の地理的分布は一時点のものであるため、出力される予測地図は一枚のみである。一方、e-RTM*NR では、近接反復被害効果により月単位で変動する短期的リスクを考慮しているため、予測地図は、2014 年 7-12 月の 1 ヶ月ごとに作成される。図 5-2 では、両モデルによって高リスク領域（上位 3 水準）として判定された領域を赤色で示している。e-RTM*NR の予測地図には、RTM における高リスク領域を水色線で重ねて示した。

表 5-3 には、各モデルの予測精度と安定性を評価した結果を示した。まず、予測精度について見る。6 ヶ月の平均で比較すると、的中率については、RTM の 40.9% に比べ、e-RTM*NR では 55.6% と、約 15% 程度高くなっている。月ごとの結果を見ると、7 月（25.0% < 75.0%）、8 月（40.0% < 60.0%）、9 月（27.3% < 45.5%）で、e-RTM*NR が RTM を上回る精度を示しており、これが平均的な精度の向上につながったことが見てとれる。一方、e-RTM と e-RTM+NR の的中率は同等であった。8 月から 9 月はともに RTM の的中率を上回り、平均では 47.3% となった。

PAI の平均で各モデルを評価すると、6 ヶ月平均では RTM の 1.87 に対し、e-RTM*NR は 1.86 とほぼ同水準となり、面積あたりの正確性は同等という結果となった。PAI を月ごとに比較すると、7 月から 9 月は e-RTM*NR が RTM を上回っているものの、10 月以降では（的中率が同じで高リスク領域の面積が増加したため）劣る結果となった。e-RTM (1.80), e-RTM+NR

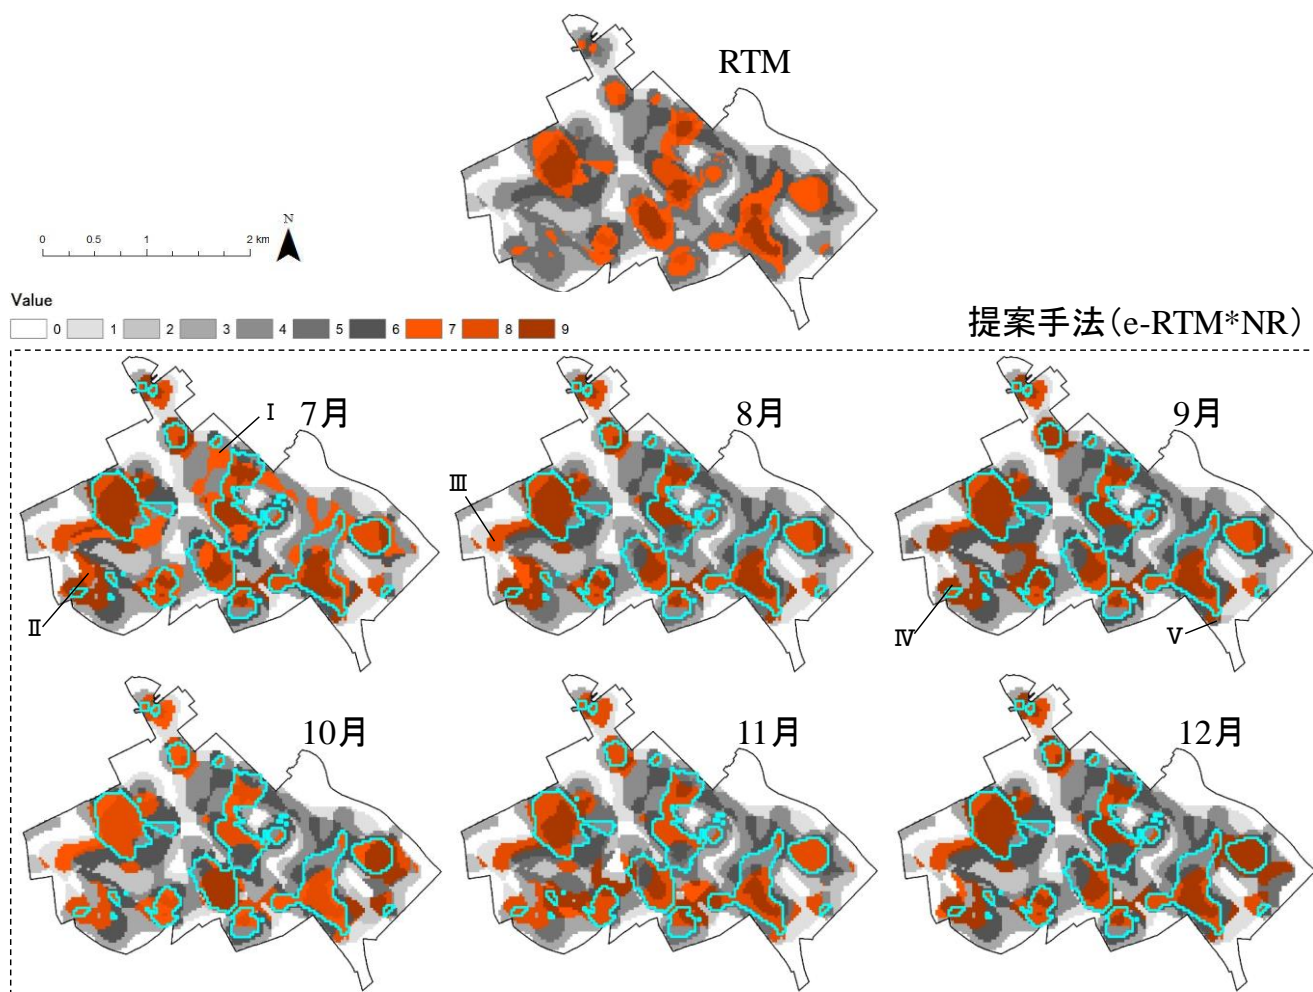


図 5-2 RTM, および e-RTM*NR による予測地図
(赤色面 : e-RTM*NR での高リスク領域, 水色線 : RTM による高リスク予測領域)

表 5-3 指標による手法間比較, および予測対象月ごとの実際の発生件数

	的中率 (%)				PAI				RRI				月次発生件数
	RTM	e-RTM	e-RTM+NR	e-RTM*NR	RTM	e-RTM	e-RTM+NR	e-RTM*NR	RTM	e-RTM	e-RTM+NR	e-RTM*NR	
7月	25.0	25.0	25.0	75.0	1.14	0.95	0.95	2.08	-	-	-	-	4
8月	40.0	60.0	60.0	60.0	1.83	2.29	2.27	2.21	1.60	2.40	2.39	1.06	5
9月	27.3	45.5	45.5	45.5	1.25	1.73	1.64	1.64	0.68	0.76	0.72	0.74	11
10月	37.5	37.5	37.5	37.5	1.72	1.43	1.31	1.30	1.38	0.82	0.80	0.80	8
11月	55.6	55.6	55.6	55.6	2.54	2.12	1.91	1.84	1.48	1.48	1.46	1.41	9
12月	60.0	60.0	60.0	60.0	2.75	2.29	2.14	2.11	1.08	1.08	1.12	1.15	10
平均	40.9	47.3	47.3	55.6	1.87	1.80	1.70	1.86	1.24	1.31	1.30	1.03	
ばらつき	13.1	12.8	12.8	11.9	0.60	0.49	0.46	0.31	0.41	0.68	0.67	0.25	

(1.70) は, ここでは RTM を下回る結果となった. 特に, e-RTM+NR は最下位であった.

次に, 予測の安定性について見ると, 的中率, PAI の 6 ヶ月の標準偏差は, e-RTM*NR がそれぞれ 11.9, 0.31 と最も低かった. RRI の値については, 平均して最も 1 に近かったのは e-RTM*NR (1.03) であった. また, 二乗平均平方根を見ても, e-RTM*NR (0.25) が最も小さかった. e-RTM と e-RTM+NR については, 安定性の指標はほぼ同等で, RRI の平均, 二乗平均平方根ともに, 最も大きな値となった.

以上をまとめると, 比較した 3 モデルにおいて, e-RTM*NR が予測精度 (面積あたりの的中率は RTM と同等), 安定性ともに最大であり, e-RTM の予測精度は中程度で安定性は低く,

表 5-4 e-RTM*NR で新たに高リスク領域となったエリアの状況
(各指標値右の括弧内の数字は、当該エリアの指標値の 53 町丁目中の順位)

エリア	人口密度(km ² あたり)	地区面積あたりの事業所数(km ² あたり)	持ち家世帯割合(%)	民営借家世帯割合(%)	戸建て世帯割合(%)	高層世帯割合(%)	平均リンク長(m)	幅員13m以上の道路割合(%)	幅員5.5m～13m未満の道路割合(%)	幅員3m～5.5m未満の道路割合(%)
I	17736.6 (12)	1936.6 (40)	30.3 (7)	64.4 (39)	8.6 (9)	75.1 (40)	61.8 (29)	0.0 (32)	96.8 (1)	3.2 (53)
II, IV	15970.9 (16)	6082.9 (8)	18.3 (20)	77.4 (22)	3.7 (24)	87.5 (27)	60.4 (33)	3.1 (28)	41.6 (34)	55.3 (15)
III	16436.8 (14)	5891.4 (11)	18.9 (18)	62.6 (42)	2.0 (37)	87.7 (25)	72.9 (14)	19.1 (11)	49.8 (27)	31.1 (35)
V	19867.8 (9)	2014.8 (38)	10.3 (38)	76.4 (25)	1.8 (40)	93.1 (16)	62.8 (28)	10.7 (20)	56.3 (17)	32.9 (34)

e-RTM+NR は予測精度も安定性も低いという結果となった。

表 5-4 には、領域 I～IV に該当する地区（町丁目）について、各指標の値と、その値が 53 町丁目中のうちに占める順位を示した。まず、I に該当する町丁目は、人口密度や持ち家世帯割合、戸建て世帯割合が相対的に高い（それぞれ 12 位、7 位、9 位、40 位）一方、地区面積あたりの事業所数は 40 位と少なく、本分析の対象領域においては住宅街的特色の強い地区であった。II、および IV に該当する町丁目は、人口密度が 16 位とやや高いが、地区面積あたりの事業所数も 8 位と高く、住民と事業者など多様な人の出入りが予想される地区であった。また、道路リンクの総延長に占める幅員 3 m～5.5 m 未満の道路リンク延長の割合が 15 位とやや高く、比較的狭い街路で構成される地区であった。III に該当する町丁目は、人口密度が 14 位とやや高い点や、地区面積あたりの事業所数が 11 位と高い点は II、IV の地区と共通しているが、道路の平均リンク長が 14 位とやや長く、道路リンクの総延長に占める幅員 13 m 以上の道路リンク延長の割合が 11 位とやや高いなど、比較的大きい道路に貫かれた地区であった。V に該当する町丁目は、人口密度が 9 位、かつ 6 階建て以上の高層住宅に住む世帯割合が 16 位とやや高く、地区面積あたりの事業所数は 38 位と少ないなど、マンションの多い住宅街といえる地区であった。

5.6 議論

本研究で提案した、犯罪蓄積からの空間回帰残差と近接反復被害効果を考慮した手法に基づく予測モデル e-RTM*NR は、オリジナルの RTM を上回る予測精度と安定性を得た。このことは、車上狙い・部品狙いについては、駐車場、コンビニエンスストア、道路といった変数をベースに、その他の環境要因や近接反復被害を考慮することで、偶然の変動に左右される犯罪発生を捉え、どの時期でも安定して一定精度の予測が可能となることを示唆している。

また、本研究の提案手法をもとに作成した e-RTM*NR は、比較対象とした、長期的・潜在的风险と短期的・顕在的风险を単純加算するモデルとの比較でも、高い予測精度と安定性を得た。このことは、日本のように犯罪発生が低頻度な状況下では、直近の犯罪発生状況を環境要因と同じ重みで予測に反映させると、精度と安定性の低下を招く可能性があることを示唆する。RTM との的中率の比較から、主要な犯罪生成・誘引要因以外の長期的・潜在的风险（社会経済的要因、犯罪可能要因、未知の犯罪生成・誘引要因など）、および短期的・顕在的风险を考慮したこと（e-RTM, e-RTM+NR）で、的中率の向上が見られたが、e-RTM+NR は、e-RTM に近接反復被害効果を組み合わせたにもかかわらず、精度の向上が見られていない。近接反復被害効果の組み合わせ方を乗算方式にすることで、はじめて精度の向上が見られたことになる。このことから、オリジナルの RTM で考慮されていない要因を取り入れて予測を行う際には、関連する要因を単純に加算する発想ではなく、既存理論を参照しながら重みづけを工夫することが重要と考えられる。

ただし、e-RTM*NRでも、予測精度の向上は7月～9月にとどまっている。e-RTMの時点で、8月と9月の的中率、PAIがRTMを上回っていることから、これらの月における予測精度の向上は、未知の長期的・潜在的リスクによってもたらされたものと考えられる。また、7月における予測精度の向上は、近接反復被害効果を考慮したことによってもたらされたものと考えられる。それに対し、精度の向上が見られなかった10月～12月では、これら新たに追加した要因が予測に寄与しなかった、あるいは、モデリングがうまくいっていない、要因として不足しているものがある、などの可能性があり、今回の検討では特定するには至らない。この点は、今回の提案モデルの課題であり、さらに他の要素を取り入れることや、引き続きモデリングの工夫を検討する余地があるかもしれない。

このような課題がありつつも、既存のRTMで考慮されていない要因を残差として取り込み、さらにその際に、単純加算ではなく、理論に基づき一定の重みづけをすることで、正確性、安定性といった予測性能の向上が図られるとした本章の仮説は、おおむね支持されたといえる。特に、犯罪が低頻度な状況でも、社会経済的要因、犯罪可能要因、未知の犯罪生成・誘引要因からなる長期的・潜在的リスクや、近接反復被害による短期的・顕在的リスクを同時に考慮することで、安定した予測を行えるモデルが作成できたことは、日本における地理的犯罪予測の方向性に、一定の示唆を与えるものと思われる。

なお、今回作成したe-RTM*NRにより、新たに犯罪の発生を的中することができた地区の特徴はさまざまであった。オリジナルのRTMでは、駐車場、コンビニエンスストア、道路の密度がおしなべて高い領域が高リスクとして判定される。e-RTM*NRでは、それらで説明されない要因を残差として取り込んだことにより、一見、取り立てて特徴がないと思えるような地区の犯罪を予測できていたと考えられる。ただし、この点を検討するには、さらなる詳細な分析が求められる。

5.7 まとめ

本章の分析では、財産犯罪の一つである車上狙い等について、犯罪生成要因・誘引要因により予測するRTMという既存の地理的な犯罪予測手法をベースとして、これにより捉えられない長期的・潜在的なリスクと、短期的・顕在的なリスクを組み合わせた新たな予測手法を提案し、予測の精度を損なうことなく、より安定性の高い予測を行うことができた。

車上狙いや部品狙いは、欧米などでは頻繁に起こる犯罪の一つだが、3章、および本章で利用したわが国のデータでは、月あたりの頻度として高いとはいえないものだった。そのような状況下でも、本研究で提案した手法をもとに作成した予測モデルが、予測の正確性と安定性を両立できていたことから、過去数年分のデータの蓄積や、直近の犯罪に着目することで、有効な予測を行うことができる可能性が示唆されたといえる。

本章で作成したモデルは、長期的・潜在的リスクを扱った主要な予測手法であるRTMに対し、回帰分析の残差を取り込み、さらに近接反復被害を考慮することで、これを拡張したものであり、地理的犯罪予測研究における新たな試みと位置づけることができる。また、海外では比較的高頻度に発生する車上狙いや部品狙いという犯罪に対して、新たな予測モデルを作成できたことは、諸外国での犯罪予測・犯罪対策にも貢献しうるものである。

5章の参考文献

- 1) 雨宮護 (2013) 潜在成長曲線モデルを用いた地区レベルでの犯罪の時系列変化と地区環境との関連の分析。「都市計画論文集」, **48**(3), 351-356.
- 2) 上杉昌也・樋野公宏 (2015) 東京都区部における住宅侵入盗と近隣社会経済的特性の関係。「都市計画論文集」, **50**(3), 608-615.
- 3) 大山智也・雨宮護・島田貴仁・中谷友樹 (2017) 地理的犯罪予測研究の潮流。「GIS理論と応用」, **25**(1), 33-43.
- 4) 菊池城治・雨宮護・島田貴仁・齊藤知範・原田豊 (2010) 近接反復被害の罪種間比較: 時空間 K 関数の応用。「GIS-理論と応用」, **18**(2), 129-138.
- 5) 土方孝将・雨宮護・糸井川栄一・梅本通孝・太田尚孝 (2015) 地方都市における住宅侵入盗被害と地区特性との関連。「都市計画論文集」, **50**(3), 824-831.
- 6) 樋野公宏・小島隆矢 (2007) 住宅侵入盗発生率と地域特性との関係: 東京都下 29 区市の町丁を対象に。「日本建築学会計画系論文集」, **616**, 107-112.
- 7) Bowers, K., and Johnson, S. (2004) Who commits near repeats? A test of the boost explanation. *Western Criminology Review*, **5**(3), 12-24.
- 8) 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.
- 9) 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.
- 10) 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.
- 11) Chainey, S. and Ratcliffe, J. (2005) *GIS and Crime Mapping*. John Wiley & Sons. England
- 12) Chainey, S., Tompson, L., and Uhlig, S. (2008) The utility of hotspot mapping for predicting spatial patterns of crime. *Security journal*, **21**(1-2), 4-28.
- 13) Clarke, R., and Eck, J. (2003) Become a problem-solving crime analyst: In *55 small steps*. *Jill Dando Institute of Crime Science*. London: Ashford Colour Press.
- 14) Diggle, P., Chetwynd, A., Häggkvist, R., and Morris, S. (1995) Second-order analysis of space-time clustering. *Statistical Methods in Medical Research*, **4**(2), 124-136.
- 15) Drawve, G. (2016) A metric comparison of predictive hot spot techniques and RTM. *Justice Quarterly*, **33**(3), 369-397.
- 16) Dugato, M. (2013) Assessing the validity of risk terrain modeling in a European city: Preventing robberies in the city of Milan. *Crime Mapping*, **5**(1), 63-89.
- 17) Johnson, S., Bernasco, W., Bowers, K., Elffers, H., Ratcliffe, J., Rengert, G., and Townsley, M. (2007) Space-time patterns of risk: A cross national assessment of residential burglary victimization. *Journal of Quantitative Criminology*, **23**(3), 201-219.
- 18) Kennedy, L., Caplan, J., and Piza, E. (2011) Risk clusters, hotspots, and spatial intelligence: Risk terrain modeling as an algorithm for police resource allocation strategies. *Journal of Quantitative Criminology*, **27**(3), 339-362.
- 19) Levine, N. (2008) The “Hottest” part of a hotspot: comments on “The utility of hotspot mapping for predicting spatial patterns of crime”. *Security Journal*, **21**(4), 295-302.
- 20) Ohyama, T., and Amemiya, M. (2018) Applying crime prediction techniques to Japan: A comparison between risk terrain modeling and other methods. *European Journal on Criminal Policy and Research*, **24**(4), 469-487.
- 21) Ratcliffe, J., Taylor, R., and Perenzin, A. (2016) Predictive Modeling Combining Short and Long-

Term Crime Risk Potential: Final Report.<<https://www.ncjrs.gov/pdffiles1/nij/grants/249934.pdf>>.
(最終閲覧 2019年5月8日)

- 22) Reinhart, A. and Greenhouse, J. (2018) Self-exciting point processes with spatial covariates: modelling the dynamics of crime. *Journal of the Royal Statistical Society*, **67**(5), 1305-1329.
- 23) 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.
- 24) Wang, X., and Brown, D. (2012) The spatio-temporal modeling for criminal incidents. *Security Informatics*, **1**(1), 1-17.

第6章 新手法の痴漢への適用と評価

6.1 はじめに

本章では、4章で検討した新手法を身体犯罪の一つである痴漢事案に適用する。具体的には、鉄道を除く公共空間で発生する痴漢事案（以下、単に痴漢と呼称）を扱い、新手法の発想をもとに、妥当と思われる予測モデルを作成し、実際のデータを用いて予測性能を評価する。これにより、新手法の身体犯罪への適用可能性をはかる。

本章で対象とする痴漢は、警察活動・犯罪予防活動の文脈では、強制性交や強制わいせつといった重篤な性犯罪に準ずるものとして、また、子供や女性に対する声かけやつきまとい、体を触るなどの加害事案の延長として、といったような複数の位置づけをもつ。特に、後者の路上や公園などの公共空間における、主に性的目的での加害事案は、最近のわが国の警察行政でも注目されており、2009年には、全国の都道府県警察に設置された「子供女性安全対策班」によりこれらの先制・予防的活動の推進がなされる（警察庁、2010）など、重要な位置づけを与えられている。また、最近でも警視庁による「子ども・女性の安全対策に関する有識者研究会」（警視庁、2017）において、こうした事案の被害状況の詳細な分析や、被害発生時の情報共有のあり方が議論されるなど、大きく焦点が当てられている。特に、わが国での子供を狙った暴力犯罪・性犯罪の被害状況は、ここ10年で横ばいの状況が続いており（警察庁、2018）、顕著な減少傾向にあるわが国の他の刑法犯罪に比べて、重点的に対処すべき対象といえよう。こうした事案の中でも痴漢は、身体接触を伴うものであり、重篤な性犯罪に近いものといえ、有効な対策が待たれるところである。なお、本分析では、公共空間で発生する、女性や子供を狙った、主に性的目的の声かけ、つきまとい、痴漢、公然わいせつ、のぞき、盗撮、卑猥言動といった行為を脅威事案と呼ぶ。

脅威事案と地理的犯罪予測については、このほど警視庁が、地理的な予測が被害防止に有効と考え、性犯罪との関連性を分析、犯罪発生の予測を図っている（日本経済新聞、2019）。犯罪被害の未然防止へこうした予測を活用することに対する社会的要請は、今後ますます高まると考えられる。

こうした状況がある一方で、学術研究に目を向けると、地理的な犯罪予測研究は、そのほとんどが、窃盗犯や銃犯罪等の暴力犯罪を対象としたものであり、性犯罪やこれに類する事案を取り扱ったものは、花岡（2018）、Burgason et al.（2017）、Ratcliffe et al.（2016）に限られ、ほとんど存在しない。

以上のことから、身体犯罪の一つである脅威事案に予測が適用可能かを検討することは、日本の犯罪対策を進める上で、また、地理的犯罪予測研究を進展させる上でも意義深いものであるといえる。

6.2 痴漢に適した予測モデルの作成

6.2.1 長期的・潜在的リスク要因の検討

以降では、4章で提案された予測手法を身体犯罪に適用する場合、どのようなモデリングが

ふさわしいかを検討する。

まず、長期的・潜在的リスク要因について検討する。性的被害と社会経済的要因の関連をみた研究としては、Sampson et al. (1997) が、近隣単位での暴力犯罪被害（性的被害以外にも、武器を使用したけんか、隣人間の暴力的な口論、ギャング同士のけんか、強盗を含む）に経済的不利益の集中が正の効果をもつことを確かめている。また、Ratcliffe et al. (2016) は、強姦性交に対しSES、人種（白人比率）がともに負の効果をもつことを確かめている。これらから、SESと居住安定性の変数は、社会経済的要因として含めるものとする。人種に関する変数は、日本では投入する意味があまりないと考えられるため、ここでは考慮しない。

犯罪生成・誘引要因としては、Burgason et al. (2017) が、深夜に発生する暴力犯罪（強姦性交のほか、加重暴行、強盗、殺人を含む）に対し、バー、ナイトクラブ、また、児童に対する脅威事案に対し、自動販売機、公園・緑地、学校（佐々木ら、2013）、公園、駅、学校（花岡、2017）が要因として機能することを確かめている。なお、花岡（2017）では、潜在的被害対象の多寡を直接表す14歳未満女性人口も予測変数として用いられている。本分析でも、ここに挙げた変数を犯罪生成・誘引要因として用いる。

犯罪可能要因としては、やはり児童に対する脅威事案に対し、道路の見通しが悪いこと（佐々木ら、2013）、駐車場、空き地の存在（吾郷ら、2010）、沿道の壁の存在、沿道の店舗・出入口の不在、低い交通量（松永ら、2009）、道路ネットワークの狭域な媒介中心性の低さ（山村ら、2019）などが挙げられる。これらのうち、本分析では、データの利用可能性を鑑み、特に自然な監視（見守りの量）に着目して変数を選定する。

6.2.2 短期的・顕在的リスク要因の検討

4章で述べたように、短期的・顕在的リスクの要因としては、近接反復被害と前兆事案による同罪種、または異罪種間の時空間相互作用が考えられる。

まず、今回の分析対象である痴漢については、わが国で性的被害の近接反復被害現象が観測されることが報告されている（中谷、2015；中谷、2017）ため、予測に用いることは有効と考えられる。

また、性的被害に関しては、菊池ら（2009）や雨宮ら（2018）により、より軽微な事象が、より重篤な事象と時空間的に近接する傾向があることが報告されている。分析対象である痴漢で考えた場合、声かけやつきまといといった、比較的軽微な加害の発生した後に、より重篤な痴漢が発生することなどが想定される。Thompson（1994）では、街頭で発生する女性に対するいやがらせ（本分析での脅威事案にはほぼ相当する）は、反抗してくる可能性の低いような女性を選び、レイプのターゲットを見定める行為（rape-testing）として機能している可能性を述べている。こうしたことから、女性の身体に直接的な接触を行う痴漢の前に、声かけやつきまといといった、身体接触未満の行為が前兆となって現れている可能性は高い。

以上より、本分析では、痴漢そのものの近接反復被害効果とともに、他の脅威事案との時空間相互作用として、声かけ、つきまとい、卑わい言動に着目して分析を行う。

6.2.3 予測モデルの作成

本分析では、福岡市における2014～2017年の痴漢発生データをもとに、予測モデルを作成する。

長期的・潜在的リスクに関しては、社会経済的要因として、SESと居住流動性の指標を、犯罪生成・誘引要因として、駅、公園、学校や飲食店といった土地利用との近接性を、さらに潜在的被害対象の多寡の代理変数である若年者、女性の流動人口指標や、地区の若年人口、

女性人口といった人口指標，および住居形態ごとの世帯比率を考慮する．また，犯罪可能要因として，若年・女性以外の流動人口，空地面積，および警察施設までの距離を考慮する．これらの予測変数をもとに，2014～2017年のセルごとの痴漢発生件数を応答変数とした回帰分析を行って係数を推定し，回帰モデルの予測値を長期的・潜在的リスクとする．

なお，本分析で扱う脅威事案では，時間帯ごとに発生リスクが高い場所が異なる可能性がある．GPSを利用して小学校児童の屋外行動や単独歩行の実態を調べた雨宮ら（2009）や雨宮ら（2008）では，児童の屋外行動・単独歩行頻度が時間帯ごとに異なり，それに対する大人による見守りの量，犯罪被害の発生状況も異なることが示された．こうしたことから，本分析では，時間帯を考慮した予測モデルを作成する．具体的には，長期的・潜在的リスク要因について，時間帯ごとにデータを分けて回帰分析を行い，予測値を算出する．この時間帯は，学校の登下校の時間帯や，福岡市における鉄道の終電，始発時間などを考慮し，①早朝～午前（5：00～13：59），②午後から夕方（14：00～18：59），③夜（19：00～23：59），④深夜（0：00～4：59）の4つを設定した．

短期的・顕在的リスクに関しては，同罪種の時空間相互作用について，先行研究（雨宮ら，2018；菊池ら，2009；中谷，2015；中谷，2017）と同様にKnox Testを用いた検討を行い，近接反復被害効果としてのリスク上昇率を求める．異罪種の時空間相互作用については，同様にKnox Testを用いるが，時間的な前後関係として，声かけやつきまといが先，痴漢が後に発生したケース数を計算する．これにより，前兆事案からのリスク上昇率を求める．

最後に，長期的・潜在的リスクの値に近接反復被害によるリスク上昇率の値と，前兆事案からのリスク上昇率の値をかけ合わせることで，総合リスクの値を求める．

6.3 長期的・潜在的リスクに関する分析

6.3.1 分析単位と応答変数の設定

応答変数となる犯罪データは，福岡県警より提供された，2014～2018年における福岡市内での子供・女性を対象とした脅威事案の発生情報である．本データは，痴漢のほか，声かけ，つきまとい，公然わいせつ，のぞき，盗撮，卑わい言動といった行為が含まれていた．総数は4263件であった．データには，年齢や認知された発生場所の住所，発生日時に関する情報がある．ただし，性別に関する情報はなかった．そのため，今回扱うデータには，男性の被害も含まれているⁱ．なお，研究対象地である福岡市は，2015年国勢調査時点で人口153.9万人，面積は343.3km²であり，東区（人口30.6万人），博多区（人口22.8万人），中央区（人口19.3万人），南区（人口25.6万人），城南区（人口13.1万人），早良区（人口21.8万人），西区（人口20.7万人）の7区で構成される（図6-1）．博多区，中央区は福岡市の中心市街地にあたり，そこから離れるほど郊外，さらに農村的地域としての特徴が強く見られるようになる．

ジオコーディングは，提供されたデータに記載された住所情報，および建物名等が記された備考欄の情報をもとに，アドレスマッチングサービスとGoogle Mapを用いて行った．アドレスマッチングにおいては，埼玉大学谷謙二研究室の「地名・施設名からジオコーディング・地図化」サービス（<http://ktgis.net/gcode/geocoding.html>）を利用した．この段階でマッチングができず，エラーとなった233件について，Google MapとGoogle Street Viewを利用しながら手動で緯度経度座標を取得した．

その後，Esri社のArcGIS Desktop 10.5を用いて，株式会社ゼンリンのZmapTown II（2014年度Shape版）の建物情報，国土数値情報の鉄道駅，バス停，都市公園，学校データと，緯度

ⁱ データ提供者である福岡県警に確認したところ，正確な数は定かではないが，わずかであるとのことであった．



図 6-1 福岡市

表 6-1 時間帯ごとの痴漢発生件数

	5:00 ~ 13:59	14:00 ~ 18:59	19:00 ~ 23:59	0:00 ~ 4:59	全時間帯
2014~2017年	99	92	247	146	584
2018年	13	21	36	17	87

経度情報からプロットされた脅威事案のデータとを空間結合し、最寄りの施設情報を取得、備考欄に記載された情報と齟齬があった 991 件について、あらためて Google Map と Google Street View を利用しながら緯度経度座標を修正した。

この過程を経て、詳細な発生地点が不明の 46 件、丁目以上のレベルでしかジオコーディングができなかった 15 件、その他に、電車内で発生した 232 件、成人男性が被害者の 9 件、離島で発生した 1 件、天神地下街で発生した 18 件を除いた結果、件数は 3942 件となった。

3924 件のうち、痴漢は 724 件であった。分析の目的に鑑み、児童（小学生以下）を除いた 13 歳以上の被害のみを抽出し、最終的には 671 件となった。このうち、予測モデルの作成に用いた 2014~2017 年の事案は 584 件、2018 年の事案は 87 件であった。時間帯ごとの痴漢発生件数は、表 6-1 のようになり、特に 19 時から 24 時にかけて発生件数が多かった。

本分析の分析単位は、これまでの地理的犯罪予測研究にならい、グリッドセル単位とした。セルサイズは、福岡市の都市計画基礎調査（2012 年度）をもとに作成された都市計画 GIS データの「街区」データベースから、街区の平均面積を算出し（約 11583 m²）、その平方根をとり（107.6 m）、最終的に 100 m 四方のセルとした。なお、都市計画 GIS データの「土地利用」データベースを用いて、痴漢が発生する可能性がきわめて低い場所として、樹林地、田畑、河川・湖に該当する面積が 9 割以上を占めるセルは、分析から除外した。結果として、計 24530 セルが対象となった。この処理によって分析から除外された犯罪データは 0 件であった。

6.3.2 予測変数の設定

予測モデル構築に用いるデータは、福岡市の都市計画 GIS のうち、「建物」、「土地利用」、「街区のデータベース」、および国勢調査（2015 年）の情報を用いた。また、GIS データを操作するにあたり、Esri 社の ArcGIS Desktop 10.5 を用いた。

まず、社会経済的要因について述べる。SES 指標としては、町丁目ごとの推計平均世帯年収を、居住流動性指標としては、居住年数 5 年未満人口比率を、それぞれ設定した。前者に

については、マップマーケティング株式会社の「年収別世帯数データ 2013」から、年収の階級ごとに階級値ⁱⁱと世帯数を乗算した上で足し上げたものを用いた。後者については、国勢調査の小地域集計結果から、町丁目ごとに居住年数5年未満人口と総人口との比を算出し用いた。

次に、犯罪生成・誘引要因について、潜在的被害者が集まりやすい場所、あるいは犯行者が引き寄せられる場所に関する変数として、業務施設、飲食店、娯楽施設ⁱⁱⁱ、遊戯施設^{iv}、(戸建)住宅、共同住宅の面積と、最寄りの飲食店、娯楽施設、遊戯施設、宿泊施設、大規模小売店、駅、バス停、公園、学校^vまでの距離を設定した。業務施設、飲食店、娯楽施設、遊戯施設、(戸建)住宅、共同住宅、宿泊施設、大規模小売店については、都市計画 GIS データの「建物」データベースから各名称に該当するものを抽出して用いた。なお、住宅は、「住宅」と「店舗併用住宅」のラベルがついたものを、共同住宅は「共同住宅」、「店舗併用共同住宅」、「作業所併用共同住宅」のラベルがついたものを統合して用いた。また、大型小売店については、「物販店」のラベルがついたもののうち、面積が 1000 m²以上のものを抽出した。また、駅、バス停、公園、学校は国土数値情報からそれぞれ、「鉄道 (2014 年時点)」、「バス停留所 (2010 年時点)」、「都市公園 (2010 年時点)」、「学校 (2013 年時点)」のデータを用いた。面積は、セルに占める各建物種別のポリゴン面積を、距離は最寄りの各建物種別のポリゴンからの距離をそれぞれ ArcGIS で算出した。

さらに、同じく犯罪生成・誘引要因に関連して、潜在的被害対象の多寡を直接表す人口指標を設定した。痴漢の被害対象になりやすい 15 歳未満人口比率、単身 15 歳から 29 歳女性人口比率、低層住宅世帯比率、中層住宅世帯比率、高層住宅世帯比率、15 歳未満男女の流動人口 (徒歩、もしくは自転車によるトリップ、以下同じ)、15~29 歳女性の流動人口を設定した。15 歳未満人口比率、単身・15~29 歳女性人口比率、低層住宅世帯比率、中層住宅世帯比率、高層住宅世帯比率については、国勢調査 (2015 年) の小地域集計から、当該の属性にあたる人口・世帯数を町丁目ごとの総人口・総世帯数との比を算出して用いた。ただし、単身・15~29 歳女性人口比率は、単身世帯比率と、15~29 歳女性人口比率を町丁目ごとに乗算した値を用いた。流動人口については、東京大学空間情報科学研究センターの提供する「人の流れデータ (北部九州都市圏 2005 年度版)」の時間帯別データから、最初に設定した 4 時間帯ごとに、15 歳未満男女のデータ、15~29 歳女性のデータを抽出後、それぞれセルごとに値を合計した。最後に、人口の多さも被害件数と関連するため、町丁目ごとの人口密度を設定した。

犯罪可能要因としては、潜在的被害対象の流動人口として設定した、15 歳未満、および 15~29 歳を除いた、その他の年齢の男女の流動人口を、また、空地面積と警察施設までの距離を設定した。空地面積は、都市計画 GIS データから、「土地利用」データベースを用い、「利用空地」と「未利用空地」のポリゴンがセルに含まれる面積を算出した。警察施設までの距離は、「警察施設 (2012 年時点)」のデータを用いた。

国勢調査の小地域集計結果をもとに得られる指標は、町丁目ごとに算出されるが、各セルの値としては、町丁目ポリゴンと重ね合わせた後、セルに含まれる面積が最も大きい町丁目の指標値を割り当てた。

表 6-2 には、予測変数のデータ源と記述統計をあわせて示した。

ii 階級は、「年収 200 万円未満」で始まり、「年収 200~300 万円」、…、「年収 900~1000 万円」まで 100 万円ごと増加、さらに「年収 1000~1500 万円」、「年収 1500 万円以上」の全 11 階級であった。階級値は、それぞれ「200 万円」、「250 万円」、…、「950 万円」、「1250 万円」、「1500 万円」とした。

iii 娯楽施設には、劇場や映画館、特殊浴場 (サウナ等) 等が含まれる。

iv 遊戯施設には、ボーリング場、スケート場、パチンコ、ゲームセンター等が含まれる。

v 学校には、小学校、中学校、高校、専門学校、大学・短大、特別支援学校が含まれる。

表 6-2 長期的・潜在的リスクの予測変数データ源, および記述統計

	変数名	データ源	最小値	最大値	平均	標準偏差
社会経済的要因	推計平均世帯年収	E	0	750.08	383.43	123.41
	居住年数5年未満人口比率	A	0	0.82	0.23	0.15
	人口密度	A	0	0.05	0.01	0.01
	15歳未満人口比率	A	0	0.41	0.11	0.07
	単身・15歳から29歳女性人口比率	A	0	0.31	0.08	0.05
	低層住宅世帯比率	A	0	0.83	0.08	0.10
	中層住宅世帯比率	A	0	1.00	0.15	0.20
	高層住宅世帯比率	A	0	1.00	0.21	0.29
	15歳未満男女の流動人口①	D	0	14323.00	73.14	263.82
	15歳未満男女の流動人口②	D	0	10697.00	77.24	258.63
	15歳未満男女の流動人口③	D	0	3512.00	5.88	50.29
	15歳未満男女の流動人口④	D	0	30.00	0.02	0.72
	犯罪生成・誘引要因	15~29歳女性の流動人口①	D	0	18993.00	103.08
15~29歳女性の流動人口②		D	0	31203.00	75.75	418.60
15~29歳女性の流動人口③		D	0	55170.00	54.73	503.41
15~29歳女性の流動人口④		D	0	33940.00	4.76	279.11
住宅面積		C	0	5066.83	578.84	766.60
共同住宅面積		C	0	12051.06	389.37	681.09
業務施設面積		C	0	43665.58	151.72	580.31
飲食店面積		C	0	5281.34	16.05	106.58
娯楽施設面積		C	0	7895.00	4.14	95.41
遊戯施設面積		C	0	6693.90	14.25	197.55
飲食店までの距離		C	0	3496.45	333.25	456.21
娯楽施設までの距離		C	0	11661.23	1210.90	1571.74
遊戯施設までの距離		C	0	7364.56	788.60	861.26
犯罪可能要因	宿泊施設までの距離	C	0	5343.90	943.93	766.50
	大規模小売店までの距離	C	0	4343.52	355.72	524.42
	駅までの距離	B	0	11971.25	1802.71	2064.21
	バス停までの距離	B	0	3664.34	302.85	407.46
	公園までの距離	B	0	6377.39	337.03	612.84
	学校までの距離	B	0	7501.50	663.72	793.15
	その他の年齢の男女の流動人口①	D	0	89537.00	486.41	1948.60
	その他の年齢の男女の流動人口②	D	0	57558.00	298.76	1055.71
	その他の年齢の男女の流動人口③	D	0	60363.00	207.60	928.50
	その他の年齢の男女の流動人口④	D	0	23280.00	14.79	255.10
	空地面積	C	0	10000.00	628.97	1474.99
	警察施設までの距離	B	0	7772.34	1166.83	1018.35

※「データ源」列における各記号は次のデータ源, A: 国勢調査 2015 年 (総務省統計局), B: 国土数値情報 (国土交通省), C: 福岡市都市計画 GIS データ「土地利用」データベース, D: 「人の流れ」データ (東京大学空間情報科学研究センター), E: 年収別世帯数データ 2013 (マップマーケティング株式会社) に, 流動人口変数に付記された①~④の数字は①5~14 時, ②14~19 時, ③19~24 時, ④0~5 時にそれぞれ対応

6.3.3 分析方針

表 6-3 に予測モデル作成に用いた 2014～2017 年の件数の時間帯ごとの分布を示す。これを見ると、0 件のセルが極端に多い分布となっていることがわかる。このことから、今回はゼロ過剰な負の二項回帰 (Zero-Inflated Negative Binomial, 以下 ZINB) モデルを用いて分析を行った。セル i における犯罪発生件数が y_i となる確率は、確率 p_i , 平均 μ_i , サイズパラメータ θ を用いて、式 (6.1) ～ (6.3) のように表すことができる。

$$P(Y_i = y_i) = \begin{cases} p_i + (1 - p_i) \left(\frac{\mu_i}{\theta + \mu_i} \right)^{y_i} & , y_i = 0 \\ (1 - p_i) \frac{\Gamma(\theta + y_i)}{\Gamma(\theta)\Gamma(y_i + 1)} \left(\frac{\theta}{\theta + \mu_i} \right)^\theta \left(\frac{\mu_i}{\theta + \mu_i} \right)^{y_i} & , y_i > 0 \end{cases} \quad (6.1)$$

$$\text{logit } p_i = \gamma_0 + \sum_l \gamma_l x_{l,i} \quad (6.2)$$

$$\ln \mu_i = \beta_0 + \sum_k \beta_k x_{k,i} \quad (6.3)$$

ここで、 γ_0 , β_0 は切片、 γ_l , β_k は予測変数のパラメータである。ZINB モデルでは、0 以外の値が得られない状態の場合に得られる 0 としての構造的ゼロ (structural zero) が得られる確率を予測するロジット部 (式 (6.2): ロジスティック回帰でパラメータ推定) と、0 以外の値を得る余地がある状態で件数を予測するカウント部 (式 (6.3): 負の二項回帰でパラメータ推定) で構成されるが、本分析では、ロジット部の予測変数には、複数のセルを包含する上位単位としての町丁目ごとに得られる変数、すなわち、推計平均世帯年収、居住年数 5 年未満人口比率、人口密度、15 歳未満人口比率、単身 15 歳から 29 歳女性人口比率、低層住宅世帯比率、中層住宅世帯比率、高層住宅世帯比率を用い、カウント部には全ての変数を用いた。長期的・潜在的リスクの値は、推定される期待値 λ (式 (6.4)) を用いた。

$$\lambda_i = (1 - p_i)\mu_i \quad (6.4)$$

なお、今回のようなデータでは、各セルが町丁目にネストされており、同一町丁目内でのセルは似た状況にあることから、通常の回帰分析を行った場合、各変数のパラメータを過大に推定する可能性がある。このような場合には、マルチレベル分析の枠組みで処理するのが妥当であるが、応答変数について級内相関係数 (Intra-Class Correlation) をとったところ、どの時間帯も目安となる 1 を超えるものがなかったことから、通常の回帰分析でも問題ないと判断した。

また、表 6-2 に見られるように、データ源 B～D から得た指標は、データ源 A, E から得られる変数と比較してレンジが大きく、同時投入することでパラメータ推定が不安定となることが懸念されたため、1 を足して自然対数をとる処理を行い、モデルに投入した。

上記の分析には、統計解析環境 R ver.3.5.1 を、ゼロ過剰モデルの実行には pscl パッケージ

表 6-3 2014～2017 年における応答変数の分布（時間帯ごと）

	0件		1件		2件		3件		4件		5件		計
	件数	割合	件数	割合	件数	割合	件数	割合	件数	割合	件数	割合	
5:00～13:59	24437	99.6%	87	0.4%	6	0.0%	0	0.0%	0	0.0%	0	0.0%	24530
14:00～18:59	24442	99.6%	85	0.3%	2	0.0%	1	0.0%	0	0.0%	0	0.0%	24530
19:00～23:59	24293	99.0%	227	0.9%	10	0.0%	0	0.0%	0	0.0%	0	0.0%	24530
0:00～4:59	24396	99.5%	125	0.5%	8	0.0%	0	0.0%	0	0.0%	1	0.0%	24530

を用いた。

6.3.4 結果

回帰分析の結果を表 6-4 に示す。なお、参考として時間帯を区別せずに行った結果も掲載した。推定値が 5%水準で有意だった予測変数は、ロジット部では、時間帯①と②では予測変数の効果は見られず、③と④では中層住宅世帯比率（負）、高層住宅世帯比率（負）、④で推計平均世帯年収（負）、居住年数 5 年未満人口比率（正）であった。カウント部では、①、②、④で推計平均世帯年収（負）、①、③、④で 15 歳未満人口比率（負）、④で 15～29 歳女性人口比率（正）、①で居住年数 5 年未満人口比率（正）、①、③、④で共同住宅面積（正）、②、③、④で業務施設面積（正）、④で娯楽施設面積（正）、④で飲食店までの距離、④で娯楽施設までの距離（負）、①～④で駅までの距離（負）、③で公園までの距離（負）であった。

表 6-4 (1) ZINB 推定結果

カウント部 (リンク関数: log)	5:00 ~ 13:59		14:00 ~ 18:59		19:00 ~ 23:59		24:00 ~ 4:59		全時間帯	
	推定値	標準誤差	推定値	標準誤差	推定値	標準誤差	推定値	標準誤差	推定値	標準誤差
(切片)	-7.778	1.314 ***	-7.688	1.800 ***	-10.710	1.009 ***	-8.943	1.835 ***	-8.370	0.639 ***
推計平均世帯年収	-0.005	0.001 **	-0.006	0.002 **	0.000	0.001	-0.006	0.003 *	-0.002	0.001 **
居住年数5年未満人口比率	3.490	1.620 *	-3.145	1.548 *	0.213	1.043	1.761	2.487	-0.606	0.763
人口密度	6.933	18.463	0.617	21.450	15.720	11.730	4.055	18.470	10.671	8.152
15歳未満人口比率	-16.242	3.508 ***	2.410	3.471	-11.020	2.316 ***	-7.389	4.005 †	-7.637	1.562 ***
単身・15から29歳女性人口比率	0.212	3.600	-4.308	4.410	-0.107	2.598	9.211	3.932 *	2.895	1.753 †
低層住宅世帯比率	2.857	1.650 †	-3.382	2.224	1.431	1.091	-2.146	2.398	0.452	0.742
中層住宅世帯比率	0.915	0.847	-1.220	1.292	-0.821	0.743	-0.374	1.196	-0.085	0.388
高層住宅世帯比率	0.693	0.730	-0.823	1.110	-0.238	0.647	-0.853	1.161	0.058	0.353
ln_15歳未満男女の流動人口	0.081	0.057	-0.012	0.058	-0.058	0.060	-3.379	235.600	0.027	0.022
ln_15から29歳女性の流動人口	-0.022	0.069	0.091	0.074	-0.043	0.040	-0.235	0.255	0.006	0.029
ln_住宅面積	-0.078	0.044 †	-0.001	0.046	-0.026	0.029	-0.042	0.038	-0.039	0.019 *
ln_共同住宅面積	0.098	0.049 *	0.009	0.043	0.117	0.031 ***	0.121	0.045 **	0.094	0.021 ***
ln_業務施設面積	-0.002	0.040	0.091	0.041 *	0.059	0.026 *	0.096	0.036 **	0.063	0.018 ***
ln_飲食店面積	0.073	0.055	-0.012	0.059	0.050	0.034	0.043	0.043	0.044	0.023 †
ln_娯楽施設面積	-0.038	0.124	-0.104	0.166	0.059	0.065	0.207	0.060 ***	0.089	0.042 *
ln_遊戯施設面積	-0.194	0.143	0.098	0.072	0.045	0.056	-0.072	0.079	-0.001	0.040
ln_空地面積	0.029	0.037	0.010	0.036	-0.014	0.022	-0.009	0.031	0.003	0.015
ln_飲食店までの距離	0.008	0.061	-0.078	0.062	-0.003	0.039	0.129	0.059 *	0.017	0.027
ln_娯楽施設までの距離	-0.077	0.080	0.008	0.097	-0.072	0.055	-0.129	0.068 †	-0.077	0.037 *
ln_遊戯施設までの距離	-0.039	0.074	0.141	0.100	0.098	0.056 †	0.000	0.065	0.061	0.036 †
ln_宿泊施設までの距離	0.003	0.075	-0.025	0.082	0.074	0.055	-0.048	0.059	0.013	0.034
ln_大規模小売店までの距離	-0.112	0.053 *	0.117	0.069 †	0.001	0.036	-0.041	0.047	-0.014	0.025
ln_駅までの距離	-0.286	0.060 ***	-0.353	0.054 ***	-0.181	0.044 ***	-0.173	0.059 **	-0.230	0.028 ***
ln_バス停までの距離	-0.111	0.064 †	-0.075	0.067	0.002	0.045	-0.096	0.054 †	-0.056	0.029 †
ln_公園までの距離	-0.089	0.066	-0.044	0.071	-0.042	0.043	0.073	0.069	-0.019	0.030
ln_学校までの距離	-0.150	0.094	0.017	0.116	-0.213	0.051 ***	-0.076	0.090	-0.143	0.040 ***
ln_その他の年齢男女の流動人口	-0.025	0.062	-0.029	0.066	0.060	0.032 †	-0.065	0.082	-0.014	0.027
ln_警察施設までの距離	-0.103	0.098	-0.181	0.092 †	-0.049	0.070	-0.088	0.085	-0.100	0.046 *
Log (theta)	-1.012	0.634	-1.023	0.630	-0.227	0.606	-0.401	0.729	-0.482	0.214 *

***p<0.01; **p<0.01; *p<0.05; †p<0.10

表 6-4 (2) ZINB 推定結果 (つづき)

ロジット部(リンク関数: logit)	5:00 ~ 13:59		14:00 ~ 18:59		19:00 ~ 23:59		24:00 ~ 4:59		全時間帯	
	推定値	標準誤差	推定値	標準誤差	推定値	標準誤差	推定値	標準誤差	推定値	標準誤差
(切片)	20.544	14.949	24.249	14.874	5.003	2.542 *	6.832	1.947 ***	7.850	2.153 ***
推計平均世帯年収	-0.142	0.117	-0.047	0.035	-0.004	0.008	-0.016	0.005 **	-0.016	0.006 **
居住年数5年未満人口比率	183.601	175.978	-25.212	22.396	3.777	6.065	19.820	9.037 *	4.938	3.673
人口密度	-386.292	417.715	78.735	303.022	-11.367	132.818	-195.400	148.500	-655.900	307.200 *
15歳未満人口比率	-563.021	548.474	93.689	80.528	-32.535	25.377	-14.250	11.970	-13.010	9.129
単身・15から29歳女性人口比率	194.469	121.651	32.678	56.077	39.831	21.517 †	16.220	10.880	65.240	24.420 **
低層住宅世帯比率	81.578	72.559	-47.320	37.114	-0.077	6.093	-5.433	6.007	4.000	5.269
中層住宅世帯比率	4.516	17.001	-42.446	26.433	-17.354	6.746 *	-8.035	3.387 *	-15.270	4.277 ***
高層住宅世帯比率	-71.923	58.482	-21.484	13.660	-16.611	7.979 *	-8.841	3.281 **	-14.730	6.167 *
Theta	0.364		0.791		0.797		0.670		0.618	
N	24530		24530		24530		24530		24530	
Log-likelihood	-494.3		-501.6		-1170.0		-660.5		-2196.0	
AIC	10666		1081.3		2417.6		1399.0		4470.8	

*** $p < 0.001$; ** $p < 0.01$; * $p < 0.05$; † $p < 0.10$

6.4 短期的・顕在的リスクに関する分析

6.4.1 分析方法

本分析では、同罪種・異罪種間の時空間相互作用を確認するために、オブザーション間の時空間近接性を評価する Knox Test を用いて検証を行った。この手法は、日本で前兆事案と性犯罪の時空間相互作用を分析した菊池ら (2009)、雨宮ら (2018) で用いられている。今回も類似の性的被害の時空間相互作用を検証することから、同手法を用いた。Knox Test では、時空間的に近い事案のペアがどの程度あるかを、特定の時間・空間幅ごとの観測値と期待値の比 (Knox 比: 式 (6.5) の η) として表現し、クロス表にまとめる。

$$\eta_{s,t} = \frac{O_{s,t}}{E_{s,t}} \quad (6.5)$$

観測値 $O_{s,t}$ は、実際に発生した n 件の事案について、 $n(n-1)/2$ 通りのペアの距離差・日数差を、特定の距離帯 s ・時間帯 t で計算したものである。期待値 $E_{s,t}$ は、個々の事案が独立して発生していると仮定した標本として、観測データの事案発生場所、発生日の関係をランダムに並び替えたものを用いて、距離差・日数差を計算し、この操作を距離帯 s ・時間帯 t ごとに 999 回繰り返した後、その平均をとる。統計的仮説検定では、観測値の 999 の標本値におけるパーセンタイル点をもって p 値とし、時空間近接がないことを帰無仮説とする。なお、Knox Test では、距離帯・時間帯を排他的にとる (たとえば、距離帯について 0 m 以上 100 m 未満、100 m 以上 200 m 未満・・・と設定する) か、連続的にとる (たとえば、距離帯について 0 m 以上 100 m 未満、0 m 以上 200 m 未満・・・と設定する) かでバリエーションがあるが、前者では、複数のセルを組み合わせた判断を行うと多重検定の問題が生じるため、今回は後者の方法をとった。

異罪種間の分析では、同じく Knox Test を用いるが、時間的な前後関係を声かけ、つきまとい、卑わい言動が痴漢よりも先に発生しているペアのみをカウントする。

同罪種・異罪種間の分析ともに、距離帯は 100 m ごと、時間帯は 7 日ごととして設定し、分析を行った。

なお、異罪種間の分析に用いた 2014~2017 年の声かけ、つきまとい、卑わい言動の件数はそれぞれ、291 件、281 件、115 件であった。

分析には統計解析環境 R ver.3.5.1 を用い、上記の計算を実行するスクリプトを作成して行った。

6.4.2 結果

同罪種間の Knox Test の結果として、観測値 (表 6-5)、Knox 比 (表 6-6) を示す。Knox 比については、 p 値が 5% を下回ったセルを太字で、さらに Knox 比が 2 倍以上のものをハイライトしている^{vi}。Townsend et al. (2003) にならい、十分な時空間的近接が確認できるセルが、垂直や水平でなく、斜め方向に広がる範囲を近接反復被害の生じる範囲とした。ここでは、800 m 以内、14 日以内とした。

異罪種の分析については、声かけ、つきまとい、卑わい言動とも、痴漢イベントとの間に有意な時空間的近接は見られなかった (付録参照)。このことから、本分析では同罪種 (痴漢) の近接反復被害のみを短期的・顕在的リスクの要因として考慮することとした。

vi 小数第三位で四捨五入して表示しているため、実際には 2 未満のセルも 2.00 として表示されている場合がある。

表 6-5 100 m・7日以内ごとの痴漢イベントのペア数

	≦7日	≦14日	≦21日	≦28日	≦35日	≦42日	≦49日	≦56日
≦100m	7	11	13	18	20	22	24	27
≦200m	16	22	28	38	47	51	58	65
≦300m	35	46	62	76	90	98	113	126
≦400m	54	74	93	117	142	158	187	207
≦500m	76	111	137	172	210	233	271	297
≦600m	99	145	182	228	275	304	346	384
≦700m	118	173	219	275	336	375	427	479
≦800m	134	205	266	333	403	454	513	581
≦900m	146	231	300	382	462	522	596	677
≦1000m	154	253	332	421	516	584	668	763
≦1100m	187	301	391	498	605	685	786	899
≦1200m	206	329	425	548	667	757	874	1003
≦1300m	219	350	463	607	737	839	970	1115
≦1400m	239	381	511	668	811	925	1072	1231
≦1500m	258	415	557	733	889	1019	1186	1357

表 6-6 100 m・7日以内ごとの痴漢イベントの Knox 比

	≦7日	≦14日	≦21日	≦28日	≦35日	≦42日	≦49日	≦56日
≦100m	4.18	3.39	2.75	2.93	2.60	2.40	2.26	2.23
≦200m	3.14	2.28	2.00	2.09	2.08	1.91	1.87	1.84
≦300m	3.44	2.43	2.26	2.14	2.05	1.89	1.88	1.84
≦400m	3.29	2.42	2.10	2.04	2.00	1.88	1.92	1.86
≦500m	3.20	2.52	2.16	2.08	2.06	1.92	1.93	1.85
≦600m	3.08	2.43	2.11	2.03	1.98	1.85	1.82	1.76
≦700m	2.78	2.20	1.93	1.86	1.84	1.73	1.70	1.67
≦800m	2.57	2.11	1.90	1.82	1.78	1.69	1.65	1.64
≦900m	2.25	1.92	1.72	1.68	1.65	1.57	1.54	1.54
≦1000m	2.01	1.77	1.60	1.56	1.54	1.47	1.45	1.45
≦1100m	2.05	1.77	1.59	1.55	1.52	1.45	1.43	1.44
≦1200m	1.99	1.70	1.52	1.50	1.47	1.41	1.40	1.41
≦1300m	1.87	1.61	1.46	1.47	1.44	1.38	1.38	1.38
≦1400m	1.83	1.56	1.44	1.44	1.41	1.36	1.36	1.36
≦1500m	1.77	1.53	1.41	1.42	1.39	1.34	1.35	1.35

6.5 予測モデルの適用と評価

6.5.1 予測値の算出

本節では、2014～2017年のデータ分析によって得られた結果をもとに、長期的・潜在的リスクと短期的・顕在的リスクを同時に考慮した予測を行い、セルごと・日ごとに予測値を算出、2018年の実際の被害をどの程度予測できるかを見る。

まず、長期的・潜在的リスクの値として、3節で述べた分析から、推定されたパラメータをもとに予測値を算出した。これにより、1つのセルに対し、時間帯ごとに1つずつの値が与えられる。

次に、近接反復被害効果を考慮して、あるセルで痴漢が発生した場合に、その日から14日

以内の間、発生地点から 800 m 以内にあるセルの長期的・潜在的リスクの値を 2.11 倍し、総合的なリスク値を算出した。この処理は、2018 年 1 月 1 日～2018 年 12 月 31 日まで行われ、1 つのセルに対して、4 時間帯ごとに、365 日分の予測値が与えられた。総合リスク値 $\lambda'_{i,d}$ は、セル i の長期的・潜在的リスク値 λ_i 、任意の日 d におけるセル i の短期的・顕在的リスク値 $\eta_{i,d}$ を用いて式 (6.6) のように表せる。ただし、 $\eta_{i,d}$ は式 (6.7) のような値をとるものとする。式 (6.8) における $N(k, d+u-14)$ は、ある日 $d+u-14$ においてセル i から 800 m 圏内にあるセル k で発生した痴漢の件数である。

$$\lambda'_{i,d} = \lambda_i \eta_{i,d} \quad (6.6)$$

$$\eta_{i,d} = \begin{cases} 2.11, & \xi \geq 1 \\ 1, & \text{otherwise} \end{cases} \quad (6.7)$$

$$\xi = \sum_{u=0}^{13} N(k, d+u-14) \quad (6.8)$$

6.5.2 検証の方法

以降では、式 (6.6) で表される予測モデルを「ZINB*NR (Zero-Inflated Negative Binomial * Near Repeat)」と呼称する。

予測精度の検証にあたっては、ベンチマークを設けた。これには、過去の犯罪発生空間分布のみに依拠した KDE による予測を設定した（「KDE」と呼称）。カーネルのバンド幅は、近接反復被害の分析で時空間的近接が見られた範囲として、800 m に設定した。また、「ZINB+NR」モデルとして、長期的・潜在的リスクと短期的・顕在的リスクを単純に加算したもの（14 日以内に犯罪が発生したセルは 2.11、その他のセルは 0 を足す）、「ZINB」モデルとして、長期的・潜在的リスクのみに基づくものについても予測精度を算出、これらを比較対象として、提案手法による予測モデルの性能を評価した。

予測精度は、2018 年の時間帯ごとに犯罪発生地点をプロットし、それが予測値の上位何%のセルで的中させることができていたかを評価した。

6.5.3 結果

前項で述べた評価方法にしたがい、リスク値のパーセンタイル点と、的中することができた 2018 年の痴漢発生累積相対度数を対応させたものが、図 6-2 である。対応する AUC は、① 5:00～13:59、② 14:00～18:59、③ 19:00～23:59、④ 0:00～4:59 の時間帯ごとに① 0.864、② 0.799、③ 0.818、④ 0.945 となり、概ね高い予測精度が得られた。また、時間帯④の予測精度は 1 にかなり近く、良好であった。一方、全時間帯をあわせた予測の AUC は 0.868 であった。④を除いて、時間帯を分けたことで、AUC はむしろ低下する結果となった。

提案モデルである ZINB*NR と、比較対象としたすべてのモデルについて、AUC、およびリスク上位 10%セルにおいて、何%の痴漢発生を予測できていたかという予測精度の指標値を表 6-7 に示した。

AUC については、短期的・顕在的リスクまで考慮した ZINB*NR、ZINB+NR が、長期的・潜在的のみに基づく予測 ZINB をすべての時間帯で上回る結果となった。ただし、時間帯③においてはその差はわずかだった。長期的・潜在的リスクと短期的・顕在的リスクの組み合




図 6-2 予測結果による ROC 曲線

表 6-7 各モデルによる AUC, およびリスク上位 10%のセルにおける的中率

時間帯	AUC				リスク上位10%のセルにおける的中率			
	ZINB*NR	ZINB+NR	ZINB	KDE	ZINB*NR	ZINB+NR	ZINB	KDE
5:00 ~ 13:59	0.864	0.949	0.846	0.567	69.2%	92.3%	69.2%	0.0%
14:00 ~ 18:59	0.799	0.800	0.788	0.588	61.9%	61.9%	61.9%	0.0%
19:00 ~ 23:59	0.818	0.819	0.815	0.714	40.0%	42.9%	40.0%	0.0%
0:00 ~ 4:59	0.945	0.944	0.933	0.579	82.4%	88.2%	82.4%	0.0%
全時間帯	0.868	0.867	0.860	0.723	64.0%	64.0%	64.0%	14.5%

わせ方のみが異なる ZINB*NR と ZINB+NR では、ほぼ AUC は等しかったが、時間帯①においては ZINB+NR が ZINB*NR を大きく上回っており、高い予測性能を示した。一方で、過去の犯罪発生地点のみにしたがって予測する KDE は、AUC が 0.5 に近いものが多く、低いパフォーマンスとなった。

的中率については、時間帯②~④では ZINB*NR, ZINB+NR, ZINB の間で大きな差は見られなかったが、時間帯①では AUC と同様、ZINB+NR が最も高い予測性能を示していた。KDE は時間帯を分けた予測では、痴漢発生を的中させることができず、ここでも予測性能が低い結果となった。

長期的・潜在的リスク (ZINB) の予測値をもとに、上位 10%の領域を赤色で示したものが、図 6-3 である。時間帯①, ③, ④では都市中心部に集積したものとなったが、②では分散する傾向が見られた。

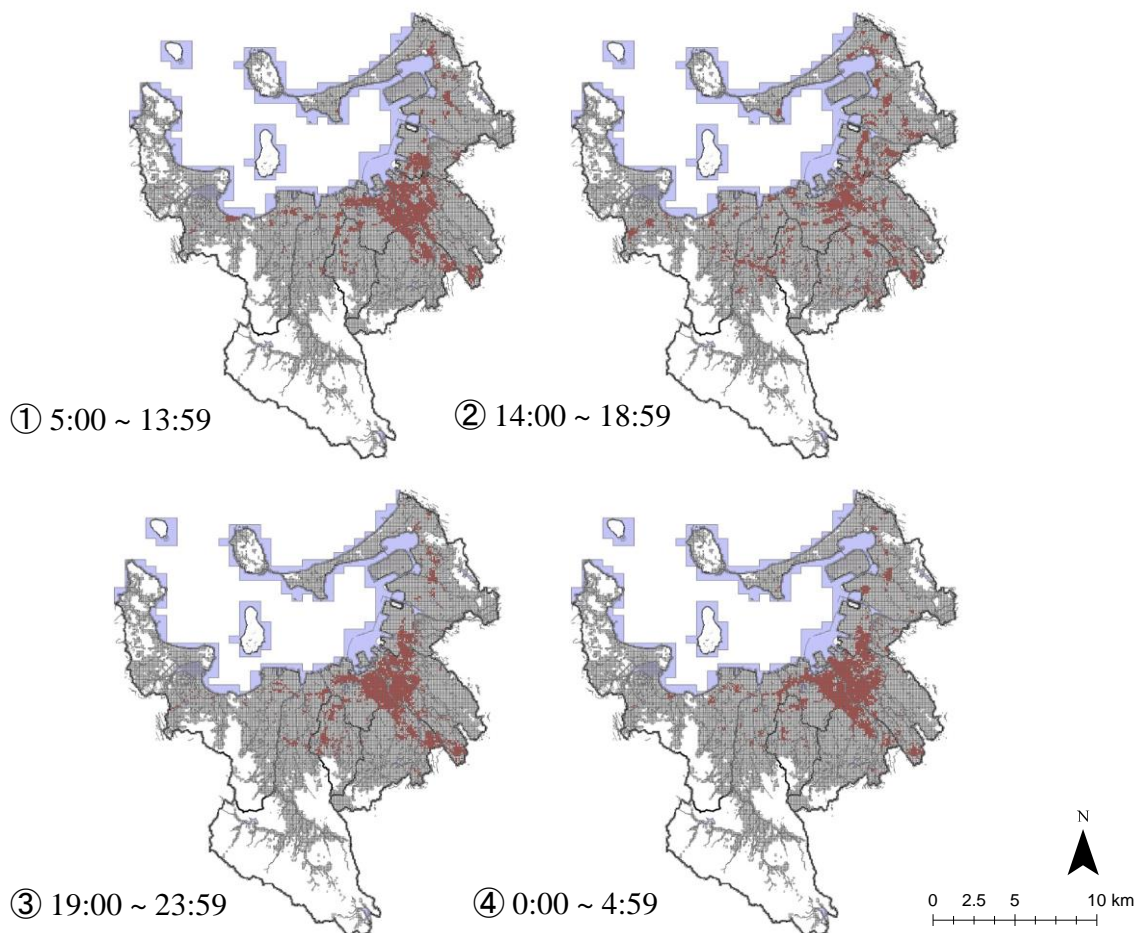


図 6-3 長期的・潜在的リスクが上位 10%のリスクに含まれるセル (ZINB による予測)

6.6 議論

ここでは、環境要因分析から見出された長期的・潜在的リスクと、近接反復被害分析から見出された短期的・顕在的リスクにより構成された痴漢発生予測モデル ZINB*NR について、それぞれのリスクに対する個別の予備分析結果も見ながら、考察を行う。また、予測精度の評価から、モデルに基づく予測の妥当性について議論する。

まず、本章 3 節でみた長期的・潜在的リスク要因については、時間帯を分けて分析を行うことで、予測変数のもつ効果にバリエーションが見られた。たとえば、構造的ゼロを予測したロジット部では、時間帯③と④のみで、変数の効果が見られた。特に、中層・高層世帯比率は、2つの時間帯でとも符号が負であり、この指標の値が高い地区ほど、構造的ゼロである可能性が低い。すなわち、痴漢件数がゼロしか得られない構造的な状態である可能性が低い。これらの変数は、カウントモデル部では統計的に有意な効果が見られなかったことから、痴漢発生の多寡よりも、そもそも痴漢が起こるような地域かどうかを判別する変数であるといえる。たとえば、福岡市の西区や早良区にある農村的な特色の強い地域は、中層・高層世帯比率が低いと考えられるが、このようなところでは、夜間以降の時間帯に痴漢はそもそも発生しない可能性が高い。国外の研究ではあるが、Ceccato (2014) は、ストックホルム県における屋外での強制性交発生場所の特徴について、地域のレベルと、より詳細な場所レベルに分けつつ調べており、多層住宅 (multi-storey housing)、すなわち集合住宅が多いことが、地域的な特徴として最大のものであると報告している。本分析でも、これと一貫した結果が見ら

れたといえる。

一方で、社会経済的要因としての推計平均世帯年収、犯罪生成・誘引要因としての共同住宅面積や、業務施設面積、駅までの距離は、カウント部における複数の時間帯で効果をもっていた。SESの指標としての推計平均世帯年収が痴漢発生に負の効果をもっていたことは、日本においても、社会経済的地位が高い地区で性的被害が抑制されることを示唆する結果である。

また、共同住宅や業務施設の面積が大きい場所で被害リスクが高まることは、4章でも紹介した犯罪パターン理論 (Brantingham and Brantingham, 1991) から説明することができる。すなわち、潜在的被害者の生活パターンの中で重要なノードとなる、自宅 (特に共同住宅) や職場 (業務施設) の付近こそが、最も被害リスクに晒される場所であるということである。駅までの距離が負の効果をもつことも、同様の解釈が可能である。駅は、潜在的被害者の生活パターンの中で重要なノードとなるために、その近くでの被害リスクが高くなる。時間帯別では、時間帯④において、単身・15～29歳女性人口比率、娯楽施設面積が、同様に犯罪生成・誘引要因として機能していることがわかる。

しかし、中には解釈が難しい結果もある。たとえば、時間帯④において、ロジット部で推計平均世帯年収が負に、居住年数5年未満人口比率が正の効果をもっていた。このことは、SESが低い地区ほど、あるいは居住流動性が高い地区ほど、構造的ゼロが予想されることを示しており、理論と逆の結果に思える。また、時間帯④においては、典型的な犯罪生成・誘引要因とも思える飲食店までの距離が正の効果をもっており、飲食店から離れた場所ほど、被害が発生しやすいことを示している。また、時間帯②では、居住年数5年未満人口比率が負の効果をもっており、流動性が高い地区で痴漢が起きにくいという結果となった。このように、いくつかの変数は、理論的な想定と反する傾向を示した。

さらに、今回の分析では、犯罪可能要因として想定した変数の効果は、どの時間帯でも確認できなかった。このことから、これら変数は予測に寄与しなかった可能性が高い。

ここまでの結果について、わが国における既存研究の結果と比較する。SESについては、東京都区部で発生した痴漢について分析した山村ら (2019) の結果 (町丁目ごとの推計所得平均が痴漢発生に負の効果) と一致している。ただし、本分析において、どの時間帯でも一貫して負の効果 (駅に近いほど痴漢が多く発生) を持ち、痴漢発生と強い関連が見られた駅までの距離は、山村ら (2019) では同じく負の効果をもっていたものの、有意傾向にとどまっている。また、山村ら (2019) では人口密度が痴漢発生に正の効果を持っていたが、本分析におけるカウント部の結果では、人口密度は非有意となっていた。これらの違いは、扱った地域の特徴、すなわち、東京都区部では福岡市とは異なり、人口低密な地域は相対的に少なく、また鉄道駅も比較的高密で、最寄り駅までの距離が短い場所が多いなどといったことから説明できるかもしれない。ただし、ここではこれ以上検討することは難しい。なお、山村ら (2019) でも年少人口割合 (町丁目人口に占める14歳以下人口の割合) が負の効果をもっており、本分析でも時間帯①および③で同様の結果となった。これらの結果については、今回用いたデータでは、痴漢被害は13～15歳が46件、16～18歳が88件、19歳以上が450件と、年少者の被害が少なく (約7.9%)、山村ら (2019) の用いたデータでも同様 (15歳以下の被害は1割強程度) であったことから、屋外での痴漢の被害リスクが、年少者では相対的に低いことを表していると思われる。

他に、犯罪生成・誘引要因として挙げた学校までの距離は、本分析では負の効果をもっており、これは花岡 (2018) や佐々木ら (2013) でもリスク要因として見出されている。一方で、犯罪生成・誘引要因として挙げた公園 (花岡, 2018; 佐々木ら, 2013)、犯罪可能要因として挙げた空地 (吾郷ら, 2010) といった施設は、本分析では痴漢発生との有意な関連が認

められなかった。

こうした結果から得られた長期的・潜在的リスクによる予測（ZINBモデル）は、KDEの予測精度を大きく上回り、高い予測性能を示した。しかしながら、時間帯を分けた予測モデルの結果は、時間帯④を除いて、全時間帯をあわせた予測による結果を下回っていた。ただし、時間帯④は、予測に有効な変数が多く確認されており、その変数によって予測されたモデルの予測精度も高いものであったことから、時間帯によっては、区別して予測を行うことが有効であるとも考えられる。

また、今回特に予測精度が低かった時間帯②は、午後～夜にかけての時間帯であり、中高生や大学生など、比較的低い年齢の者が被害リスクに晒される時間であるといえよう。これら異なる属性の者の活動が混在することが、図6-4に見られるような高リスクエリアの分散傾向をもたらし、それが予測精度の低さと関連している可能性もある。逆に深夜にあたる時間帯④は、図6-4に見られるように、ほとんどが大学生以上や勤め人などにあたる、19歳以上の者であり、終電時間も過ぎていることから、活動場所が限られる。このことが、予測精度の高さに寄与した可能性も考えられる。




図 6-4 2014~2017年の時間帯ごとの痴漢発生件数

このように、時間帯を分けた分析は、予測にとどまらず、時間帯ごとにリスク要因を検討し、いつ・どこで防犯対策をするべきか、あるいは、どこで環境を改善すべきかといったことを考えるにあたり、示唆を与えうる。時間帯を分けた分析が犯罪予防に寄与するところは大きいものと思われる。

本章4節で見た短期的・顕在的リスクについては、まず、痴漢イベントどうしの近接反復被害は観測されたものの、異なる種別の事案である声かけ、つきまとい、卑わい言動といった、痴漢の前兆として想定されたものは、実際には痴漢発生を予測するものとはならなかった。

それでも、短期的・顕在的リスクを加味したモデルの予測精度は、長期的・潜在的リスクのみに基づく予測を上回ったことから、これを要因として考慮することは有効といえる。ただし、時間帯③では、短期的・顕在的リスクを加味しても、ほとんどAUCが上がり、時間帯によっては、近接反復被害が予測にあまり寄与しない可能性も示唆された。

なお、本研究のような性的加害の地理的犯罪予測を扱った既存研究で、予測精度を比較できるものは管見の限り見当たらないが、予測精度をAUCで評価したのを見ると、ロンドン市街地における分析（罪種は不明）を行った Bogomolov et al. (2014) では $AUC=0.64$ 、シカゴ市における分析（罪種は不明）を行った Kang and Kang (2017) では $AUC=0.83$ 、スイスの

アールガウ州で侵入盗を分析した Kadar et al. (2019) では $AUC=0.779$, ブリスベン市で暴行を分析した Rumi et al. (2018) では $AUC=0.90$ といった結果となっている。これらは、いずれも当該研究において最高のパフォーマンスを示したモデルについて記している。分析した地域、罪種、予測の対象とした犯罪の発生件数、予測に用いた変数等々、条件があまりに異なるため、比較は難しく、あくまで参考値ではあるものの、本分析で採用されたモデルの AUC は、これらと比べても遜色のないものであった。したがって、本分析で扱ったモデルも、一定程度有効な予測性能を有するものと結論づけられる。

最後に、長期的・潜在的リスクと短期的・顕在的リスクの組み合わせ方については、乗算方式と加算方式で異なる ZINB*NR と ZINB+NR とで、時間帯②～④ではほとんど差が見られなかったものの、時間帯①では ZINB+NR の予測性能が、本研究の提案手法に基づくモデル ZINB*NR を大きく上回った。長期的・潜在的リスクの値は、時間帯①では平均：0.004、標準偏差：0.015、時間帯②では平均：0.004、標準偏差：0.011、時間帯③では平均：0.010、標準偏差：0.018、時間帯④では平均：0.006、標準偏差：0.022、といったように、その値はほとんどが 0.1 を下回るオーダーであるのに対し、短期的・顕在的リスクは、直近 14 日以内、800 m 以内に痴漢が発生していた場合、2.11 という値が割り当てられる。これら 2 種のリスクを加算する ZINB+NR の総合リスク値は、ZINB*NR と比べ、短期的・顕在的リスクの影響が相対的に大きいものとなる。このように評価されたリスクに基づく ZINB+NR モデルが、時間帯①の 5:00～13:59 では ZINB*NR を上回っていたことから、この早朝から午前にかけての時間帯では、予測対象となった 2018 年の痴漢発生において、近接反復被害の影響が大きかったとも考えられる。

この結果からは、長期的・潜在的リスクと短期的・顕在的リスクを組み合わせる方法としては、提案手法のように乗算を行う形が正しいとは限らないことを示しているともいえる。ただし、4章4節でふれたように、長期的・潜在的リスクの値（本章3節のゼロ過剰負の二項回帰分析における推定期待値 $(1-p)\mu$ ）と、短期的・顕在的リスクの値（本章4節の Knox Test における Knox 比 η ）という異質な値を足し合わせる演算であり、方法としての妥当性は慎重に検討するべきである。

6.7 まとめ

本章では、身体犯罪の一つとしての電車内以外の公共空間で発生する痴漢について、長期的・潜在的リスク要因をベースに、短期的・顕在的リスクを加味した予測手法を適用し、具体的なモデルを作成して、予測性能を評価した。脅威事案としてわが国の犯罪対策の中で重視される痴漢に対し、日単位で予測を行い、時間帯によっては、 AUC が 0.9 を超えるといったように、ある程度有効な予測モデルが作成できたことは、本分析の成果といえるだろう。また、性的被害発生への地理的犯罪予測の適用は、諸外国でも例が少ないことから、異なる国や地域で、同様の検討が行われることが待たれる。

一方で、わが国の先行研究をもとに、予測に有効と考えられた異罪種の前兆事案としての効果は見られず、同罪種間の時空間相互作用を考慮するにとどまった。この点について異罪種の効果を予測に組み込む方法などは、今後の課題として残された。

また、本研究で提案した手法としての、長期的・潜在的リスクと短期的・顕在的リスクを乗算する方式でのモデルに対して、2つのリスクを足し合わせるモデルが高い予測性能を発揮していた時間帯もあったことから、少なくとも今回の対象とした痴漢については、リスクの組み合わせる方法を引き続き検討する余地があるものと考えられる。

公共空間で発生する性的加害については、要因分析を行った研究はあるものの、地理的犯

罪予測研究でこれを直接に取り扱ったものはない。この点において、本章で提出した痴漢予測モデルは、国際的にも新規性の高いものといえる。

6章の参考文献

- 1) 吾郷太寿・松永千晶・角知憲 (2010) 通学路上の児童の存在状況と物的空間構成要素が不審者出没に与える影響に関する研究. 「土木計画学研究・論文集」, **27**(2), 331-336.
- 2) 雨宮護・島田貴仁・中谷友樹・樋野公宏・高橋あい (2018) 子供・女性に対する脅威事案は性犯罪等のリスクを高めるか? : 子供・女性の性犯罪等における先行指標の検討. 「都市計画報告集」, **17**, 216-222.
- 3) 菊池城治・雨宮護・島田貴仁・齊藤知範・原田豊 (2009) 声かけなどの不審者遭遇情報と性犯罪の時空間的近接性の分析. 「犯罪社会学研究」, **34**, 150-162.
- 4) 警察庁 (2018) 「平成30年版警察白書」, <https://www.npa.go.jp/hakusyo/h30/pdf/06_dai2s ho.pdf>. (最終閲覧 2019年5月27日)
- 5) 警察庁 (2010) 「平成22年版警察白書」, <<https://www.npa.go.jp/hakusyo/h22/honbun/pdf/2 2p01000.pdf>>. (最終閲覧 2019年5月27日)
- 6) 警視庁 (2017) 「子ども・女性の安全対策に関する有識者研究会提言書」, <https://www.keishicho.metro.tokyo.jp/kurashi/anzen/anshin/kodomo_josei_anzen.files/all.pdf>. (最終閲覧 2019年5月27日)
- 7) 佐々木雄希・藤井智史・岸本達也 (2013) 局所的環境特性から見た不審者事案発生及び未発生に影響する環境要因: 埼玉県草加市を対象として. 「地域安全学会論文集」, **20**, 21-28.
- 8) 中谷友樹 (2015) 京都市内で認知された強姦・強制わいせつ事件の時空間的集中と近接反復被害. 『京都府警察犯罪抑止対策調査研究会(性犯罪対策研究部会)報告書資料編』, 京都府警察犯罪抑止対策調査研究会・性犯罪対策研究部会, <<http://www.pref.kyoto.jp/fukei/anzen/seitai/tokumei/houkoku.html>>, 最終閲覧日 2019年10月10日.
- 9) 中谷友樹 (2017) 予防医学の考えに基づく犯罪予防. 『警視庁子ども・女性の安全対策に関する有識者研究会提言書』, 警視庁子ども・女性の安全対策に関する有識者研究会, <http://www.keishicho.metro.tokyo.jp/kurashi/anzen/anshin/kodomo_josei_anzen.html>, 最終閲覧日 2019年10月10日.
- 10) 日本経済新聞 (2019) 犯罪予測で子供・女性守れ 経験頼み脱却、AI活用, 2月9日夕刊1頁.
- 11) 花岡和聖 (2018) 大阪府における不審者遭遇情報の地理的分布: Risk Terrain Model を用いた犯罪リスクのマッピング. 「立命館文學」, **656**, 47-59.
- 12) 松永千晶・宮崎彩・角知憲 (2009) 通学路上の犯罪発生に関する要因分析. 「土木計画学研究・論文集」, **26**(1), 239-243.
- 13) 山村俊貴・樋野公宏・上杉昌也・雨宮護 (2019) 東京都区部における性犯罪の前兆事案と街路ネットワークの関係: Urban Network Analysis 指標に着目して. 「GIS理論と応用」, **27**(1), 33-42.
- 14) Brantingham, P., and Brantingham, P. (1991) Introduction: The dimensions of crime. In *Environmental Criminology*, Brantingham, P. and Brantingham, P. eds. Long Grove: Waveland Press., 7-26pp.
- 15) Burgason, K., Drawve, G., Brown, T., and Eassey, J. (2017) Close only counts in alcohol and violence: Controlling violence near late-night alcohol establishments using a routine activities approach. *Journal of Criminal Justice*, **50**, 62-68.
- 16) Ratcliffe, J., Taylor, R., and Perenzin, A. (2016) Predictive Modeling Combining Short and Long-Term Crime Risk Potential: Final Report. <<https://www.ncjrs.gov/pdffiles1/nij/grants/249934.pdf>>, 最終閲覧 2019年5月8日.
- 17) Thompson, D. (1994) The woman in the street: Reclaiming the public space from sexual harassment.

Yale Journal of Law and Feminism, **6**(2), 313-348.

- 18) Townsley, M., Homel, R., & Chaseling, J. (2003). Infectious burglaries. A test of the near repeat hypothesis. *British Journal of Criminology*, **43**(3), 615-633.

第7章 新手法の還付金等詐欺への適用と評価

7.1 はじめに

本章では、4章で検討した新手法を知能犯罪の一つである特殊詐欺に適用する。具体的には、最近わが国で多発している還付金等詐欺を対象に、新手法の発想をもとに、妥当と思われる予測モデルを作成し、実際のデータを用いて予測性能を評価する。これにより、新手法の知能犯罪への適用可能性をはかる。

今やわが国を代表する知能犯罪である特殊詐欺は、2013年以降、認知件数で1万5千件超、被害総額で300億を超える水準で推移しており、多くの犯罪が減少しているわが国において、重大性の高い犯罪である。中でも、近年増加傾向が顕著な還付金等詐欺においては、被害者が、無人の現金自動預払機(ATM)に誘導されて被害にあう事案が多発しているとされ(警察庁, 2017)、被害者住居近くの具体的な店舗や施設を指定するケースも見られる。

そのため、ATMを警戒し、利用者への声かけなどにより、被害を未然に防ぐ対策が推進されており、2017年には、大阪府警が、ATM400箇所にも900名の警察官を配置する集中警戒を行っている(朝日新聞, 2017)。ただし、このような大規模な人員配置を継続することは難しい。効率的な被害防止のためには、被害発生の高発性が高いATMをあらかじめ特定し、数を絞った上で警戒することが望ましい。

こうした判断に、地理的犯罪予測は有用と考えられる。一方で、還付金等詐欺は、加害者と被害対象が特定の環境において出会うことなく成立する犯罪であり、一見、地理的犯罪予測の埒外に見える。

しかし、還付金等詐欺では、犯行にATMが用いられることから、犯行時に誘導されるATMの設置環境に着目することで、地理的犯罪予測が前提とする犯罪と環境との関連が見出せる可能性がある。たとえば、行き交う人の目が少ない場所に設置されたATMは、犯行者の視点に立てば、被害者に振り込みをさせる際、他の利用者などに見咎められ、阻止されることのないATMと評価され、被害者が誘導されやすいかもしれない。同様に、犯罪発生の反復性の性質についても、犯行者がひとたび被害者をATMに誘導・振り込みさせることに成功した場合、別の被害者に対しても、同じATMを繰り返し誘導先として指定することがありうる。このように還付金等詐欺については、誘導対象となるATMに着目することで、地理的犯罪予測の前提が満たされ、将来の被害予測が可能となる見込みがある。

そこで本分析では、ATMに着目し、地理的犯罪予測の前提を確認するとともに、4章の提案手法から新たな予測モデルを構築し、その妥当性を評価する。具体的には、1. 還付金等詐欺の誘導対象となりやすいATMの環境要因、2. あるATMへの誘導発生後に、繰り返し誘導対象となる(反復誘導)傾向をそれぞれ明らかにした上で、3. ATMの環境要因によるリスクと、反復誘導によるリスクを統合した還付金等詐欺の予測モデルを構築し、データに基づきモデルによる予測の妥当性を検証する。

本分析は、還付金等詐欺の被害予測を通じて、被害抑止にむけた効率的なATM警戒対策に資するとともに、地理的犯罪予測研究がこれまで対象としなかった知能犯罪の予測に初めて取り組むものである。

7.2 還付金等詐欺に適した予測モデルの作成

7.2.1 長期的・潜在的リスク要因の検討

以降では、4章で提案された予測手法を知能犯罪に適用する場合、どのようなモデリングがふさわしいかを検討する。詐欺のような犯罪と空間的な特性を結び付けた先行研究は乏しいことから、他の罪種一般にあてはまる要因などから類推することとする。

まず、長期的・潜在的リスク要因のうち、社会経済的要因について検討する。通常、高いSESや居住安定性といったものは、犯罪被害を抑制する方向にはたらくが、還付金等詐欺のような犯罪の場合、富裕な地域は、むしろ詐欺実行犯に狙われやすいことが考えられる。そのため、これら変数は予測に有効と思われるが、通常の暴力犯罪や財産犯罪とは逆の効果をもつ可能性が高い。

次に、犯罪生成・誘引要因であるが、還付金等詐欺は、詐欺実行犯が被害者と直接接触することが稀であることから、これを適用するのは難しい。しかしながら、最初に被害者宅に電話がかかり、その後、どこかのATMに呼び出されることから、被害者となりうる高齢者人口の多さや、特に高齢者がアクセスしやすいATMの多さなどは、潜在的被害対象の多寡と関連し、還付金等詐欺の発生をよく予測すると考えられる。

犯罪可能要因については、既に述べたように、ATMのおかれた環境が大きく関連すると考えられる。すなわち、人目につきにくい場所にあるなどして、注意が向けられにくく、高齢者が携帯電話で話しながらATMを操作していても、それに気付いて阻止される可能性が低い状況が、犯罪可能要因となるだろう。

7.2.2 短期的・顕在的リスク要因の検討

短期的・顕在的リスクに関しては、還付金等詐欺でも想定しうるだろうか。近接反復被害の事象依存説にしたがえば、一度犯行が成功したことで、犯行者の選好が一時的に上昇し、あるいは同業者にそれを話すことで、特定の被害者や場所を繰り返し狙われることになる。ATMに着目するなら、たまたま誘導、振り込みをさせることに成功したATMは、詐欺実行犯が繰り返し指定する可能性もありうる。

ただし、6章、7章で短期的・顕在的リスクとして考慮した近接反復被害は、還付金等詐欺では想定しにくい。何故なら、自動車を駐車する場所で発生する車上狙いや、路上等で発生する痴漢は、都市のほとんどあらゆる場所で発生しうるのに対し、還付金等詐欺の誘導は、ATMが存在する場所に限定されるためである。ATMは、都市中心部などでは高密度に存在するものの、それ以外の地域では低密であることが予想され、また、ATM設置場所同士の距離もまちまちであることから、発生リスクが空間上に連続的に分布しうる犯罪と異なり、近接反復被害は想定することが難しい。したがって、ここでは同一のATMが繰り返し誘導対象として利用される事象を想定するのが適切と考えられる。これは、近接反復被害のもとになった反復被害(repeat victimization : Farrell and Pease, 1993)現象に相当する。

また、還付金等詐欺の前兆事案にあたる事象について検討する。同じ特殊詐欺の一類型であるオレオレ詐欺などでは、被害に先立ち、警戒水準をあらかじめ下げる目的で、「アポ電(アポイントメント電話)」と呼ばれる、犯行者からの架電がある場合がある。しかしながら、還付金等詐欺の場合は、そのような事象が報告されておらず、前兆事案に該当するものが想定しづらい。そのため、還付金等詐欺については、前兆事案の短期的・顕在的リスクは考慮しないものとし、反復被害のみを考えることとする。

表 7-1 福岡市における 2016 年の行政区ごとの ATM 台数、
および還付金等詐欺の誘導発生件数（福岡県警提供データに基づく）

	博多区	中央区	南区	西区	城南区	早良区	総計
ATM 場所数 (A)	436	341	177	176	85	162	1625
行政区ごと発生件数 (B)	10	7	13	8	6	7	67
行政区ごと発生率 (B/A)	2.3 %	2.1 %	7.3 %	4.5 %	7.1 %	4.3 %	4.1 %

7.2.3 予測モデルの作成

本分析では、福岡市における 2016 年の還付金等詐欺の誘導が発生した ATM のデータをもとに、長期的・潜在的リスクと短期的・顕在的リスクを求め、それらのリスクを総合して、2017 年の誘導を予測するモデルを作成する。

長期的・潜在的リスクに関しては、社会経済的要因として地区の SES を、犯罪生成・誘引要因として、高齢者人口や ATM 密度、また ATM が設置された施設のアクセシビリティ等を、犯罪可能要因としては、ATM が施設のどのような位置におかれているかを、それぞれ用いて回帰分析を行う。

短期的・顕在的リスクに関しては、ATM ごとの被害発生状況から、誘導発生直後の反復誘導の起こりやすさを明らかにするべく、誘導が発生した月日の情報を用いて、Knox Test に基づくリスク比の算出を行い、有意なリスク上昇が確認された場合、これを利用する。

最後に、長期的・潜在的リスク要因の分析で得られた回帰モデルに、2017 年の ATM の地理空間情報を外挿し、さらに反復誘導リスクの大きさを組み合わせた予測を行う。

7.3 長期的・潜在的リスクに関する分析

7.3.1 分析単位と応答変数の設定

本分析における応答変数は、ATM 設置場所ごとの還付金等詐欺の誘導発生件数である。ここでの「ATM 設置場所」とは、同一金融機関の ATM が 1 台、もしくは連坦して複数台設置されている場所である。誘導発生件数は、詐欺の誘導が発生した ATM の位置データ（2016 年中に発生したもの）に、ATM の位置・属性データを組み合わせることで作成した。本分析では、詐欺実行犯の指定する口座に振り込むことではなく、ATM に誘き出されるという事象を対象としており、未遂も含めて分析している。犯行が既遂であったか、未遂であったかは、詐欺であることが看破されず振り込みが行われたか、看破されて振り込みが中断・阻止されたかによるものだが、警戒すべき ATM を絞り込む目的では、振り込みが完了したかを問わず、誘導が発生したすべての事案を分析することが望ましい。そのため、今回は、既遂・未遂を問わず分析を行った。なお、本分析で扱うデータは、誘導が発生したもののうち、警察に届け出があったものに限られる。届け出がないものは、詐欺実行犯からの電話があったものの、看破するなどして ATM まで至らなかった場合や、ATM まで移動したものの振り込むに至らなかった場合などがあるが、これらは暗数となっており、データには含まれない。誘導発生件数に関するデータは、福岡県警察本部から提供を受けたものである。ATM 設置場所に関するデータは、マップマーケティング株式会社が販売する「ATM 拠点データベース（2016 年版）」ⁱ に対し、収録対象外となっていた JA バンク、信用金庫、労働金庫の位置情報を筆者

i 本データは、日本 ATM 株式会社が保有する、銀行とコンビニを中心に ATM 拠点情報を収録した ATM 拠点データベースであり、都市銀行、ゆうちょ銀行、信託銀行、地方銀行、第二地銀、信用金庫、労働金庫（信用金庫と労働金庫は、東京都、千葉県、埼玉県、神奈

が追加したものである。情報の追加にあたっては、当該金融機関のホームページから住所情報を取得した。

上記の手続きによりデータに含まれた福岡市の ATM 設置場所の全箇所数は、1625 箇所（うち 89 箇所は筆者が追加）であり、誘導発生件数は 67 箇所、93 件であった。表 7-1 に行政区ごとの ATM 場所数、および誘導の発生件数、率を示す。ATM 場所数は博多区や中央区といった中心市街地で多いが、誘導発生率はその周辺で高くなっている。

7.3.2 予測変数の設定

予測変数は、誘導に至りやすい ATM の設置・立地環境、および地区（町丁目）環境について、犯罪学理論、および警察官と行った現地調査の結果を参照しつつ設定した。特に、予測変数 1 は、CPTED (Crowe, 1991) における「自然な監視」が、店舗と ATM との位置関係によって左右されると考え、設定した。ほかに、魅力的な被害対象（日常活動理論：Cohen and Felson, 1979）、犯行が露見するリスク（合理的選択理論：Cornish and Clarke, 1984）を考慮した。また、福岡県警察本部の担当者 2 名と、2018 年の 2 月 25 日から 2 月 26 日までの 2 日間にわたり 28 箇所の現地視察を行い、その意見も参考とした。表 7-2 に予測変数の一覧、およびデータ源を示す。

まず、ATM が建築物の屋内に設置されているか否かなど、ATM と設置建築物との位置関係を予測変数 1 として設定した。これは、詐欺実行犯がより成功確率の高い ATM に被害者を誘

表 7-2 予測変数一覧

変数名		データ源
ATM 設置場所の直近、および周辺環境		
犯罪可能要因	#1 ATM 設置建築物との位置関係	Google ストリートビュー、金融機関ホームページ、施設構内図
犯罪生成・誘引要因	#2 媒介中心性	建物データ：Zmap TOWN II 2013/14 年度 Shape 版（株式会社ゼンリン）、ネットワークデータ：拡張版全国デジタル道路地図データベース 2016 年版（住友電工システムソリューション株式会社）
	#3 直進中心性	
	#4 近接中心性	
	#5 最寄り駅までの距離	
	#6 最寄りバス停までの距離	
	#7 最寄り警察署・交番までの距離	
	#8 ATM 設置建築物の面積	
	#9 周辺の ATM 密度	
	#9 ATM 拠点 DB（マップマーケティング株式会社提供分＋分析者作成分）	
地区（町丁目）環境		
犯罪生成・誘引要因、もしくは社会経済的要因（#12 と #13）	#10 65 歳以上夫婦のみ世帯割合	国勢調査 2015 年（総務省統計局）
	#11 65 歳以上単身世帯割合	
	#12 地区の平均世帯年収	
	#13 地区の平均貯蓄	
	#14 人口密度	
	#15 事業所密度	
#12 地区の平均世帯年収	年収別世帯数データ 2013（マップマーケティング株式会社）	
#13 地区の平均貯蓄	貯蓄推計データ 2014（マップマーケティング株式会社）	
#14 人口密度	国勢調査 2015 年（総務省統計局）	
#15 事業所密度	経済センサス 2014 年（総務省統計局）	

川県、愛知県、大阪府のみ提供）が設置する ATM の位置情報等を収録している (<https://www.mapmarketing.co.jp/data/point/ATMPoint.html>)。)




図 7-1 「ATM 設置建築物との位置関係」イメージ：
左から「屋内」、「隣接」、「敷地内または独立」

導しようとする可能性があることを反映したものである。ATM と設置建築物との位置関係は、ATM が、職員・店員や他の利用者の視線に晒される度合いと関連しており、実行犯にとっては、誘導した被害者への他者の介入の可能性として、犯行の成功確率の判断に影響を及ぼすと考えられる。具体的には、ATM と設置建築物との位置関係を示すダミー変数を予測変数として設定した（「ATM 設置建築物との位置関係」）。この変数には、「屋内：屋内に位置している（扉で ATM コーナーが仕切られている場合含む）」、「隣接：屋内に完全に含まれていないが、ATM 専用の建屋が設置建築物と接している（建屋は別）」、「敷地内または独立：ATM 建屋が屋外（駐車場など）に位置している」の3水準を設定した（図 7-1）。なお、本分析における「建築物」は、「Zmap TOWN II 2013/14 年度 Shape 版」より、離島に存在する建物（2,543 件）、分類コード 1364 の「個人の家屋」（136978 件）、および 2000 番台の表札不明の家屋、小屋、倉庫等（103892 件）を除いた建物（81504 件）を指し、「官公署庁」、「公共施設」、「神社・仏閣」、「ビル・アパート」、「事業所」、「公民館・市民会館」を含む。

同様に、ATM 設置場所の直近、および周辺の環境を表象する変数として、予測変数 2~9 を設定した。まず、ATM 設置建築物へのアクセシビリティが良いほど、ATM の利用者が多くなり、詐欺の誘導対象として指定されやすくなると考えられる。このことから、ATM 設置建築物の街路ネットワークとの関係性を見た（変数 2~4）。ネットワーク中心性の指標を街路ネットワークに適用した Urban Network Analysis (Sevtsuk and Mekonnen, 2012) の媒介中心性、直進中心性、近接中心性を用いた。これらはそれぞれ、当該建築物が、交通の結節点（交差点）に面している度合い、直線状の道路（概して大通り）に面している度合い、周辺の建物と近接している度合いを表すものである。また、公共交通からのアクセスの良さを見るために、「最寄り駅までの距離」、「最寄りバス停までの距離」を設定した（変数 5, 6）。他に、ATM 設置場所が警察施設に近いほど、詐欺の誘導対象として指定されにくくなると考えられることから、「最寄り警察署・交番までの距離」（変数 7）を、ATM が設置されている建築物の規模が大きいほど、潜在的な ATM の利用者数が多く、日常的に利用されやすいために、詐欺の誘導対象として指定されやすくなると考えられることから、「ATM 設置建築物の面積」（変数 8）を、周辺に存在する ATM が少ないほど、当該 ATM の利用頻度が増えると考えられることから、「周辺の ATM 密度」（変数 9）をそれぞれ設定した。なお、変数 5, 6, 7, 9 の計算に用いられた距離は直線距離である。

さらに、ATM 設置建築物が、どのような地区にあるかを表象する変数として、予測変数 10~15 を設定した。高齢者、特に夫婦のみ高齢世帯や単身高齢世帯の多い地区ほど、犯行者に狙われやすくなると考えられることから、「65 歳以上夫婦のみ世帯割合」、「65 歳以上単身世帯割合」（変数 10, 11）を、富裕な世帯が多い地区ほど犯行者にとって魅力的な対象となることから、「地区の推計平均世帯年収」、「地区の推計平均貯蓄」（変数 12, 13）を、住民が多い地区ほど、潜在的な被害者が多く存在することから、「人口密度」（変数 14）を、事業所が多く存在する地区ほど、ATM が多く存在し、犯行者にとって狙われやすくなると考えられるこ

とから、「事業所密度」(変数 15) をそれぞれ設定した。

ここまで設定した予測変数について、4章2節で議論した長期的・潜在的リスク要因との対応は、まず、ATM設置場所の直近、および周辺環境の変数のうち、変数1が犯罪可能要因となる。次に、変数2~9が犯罪生成・誘引要因となる。還付金等詐欺では、犯行者が直接誘導の対象となるATM(街頭犯罪における犯行場所にあたる)に出向くことはないが、ATM自体が集まりやすい場所、さらに被害者を誘導しやすいATMがある場所を示す指標として、アクセシビリティや施設の規模、ATMの密度などが考えられるためである。次に、地区(町丁目)環境については、変数10,11は、還付金等詐欺の主要なターゲットである高齢者、かつ詐欺実行犯からの架電について相談する相手が少ないという点から、潜在的被害者の多く集まる地区属性として犯罪生成・誘引要因と位置付けることができる。これに対し、変数12, および13は、地区の社会経済的地位を表象するものでもある。ただし、還付金等詐欺のような知能犯罪においては、街頭犯罪のようにSESの低い地区で発生しやすいとは限らない。むしろ、SESの高い地区の住民は、資産を多く持つことから、詐欺実行犯にとっての魅力的な対象(suitable target: Cohen and Felson, 1979)となりうる。この場合、高いSESは還付金等詐欺発生を抑制するよりも、促進する効果をもつと考えられる。こうしたことから、変数12と13は、犯罪生成・誘引要因としての側面も同時にもつといえよう。変数14,15は、潜在的被害対象や、誘導の対象となるATMの多寡と関連すると考えられることから、やはり犯罪生成・誘引要因である。

各データの作成方法は、以下の通りである。変数1は、Googleストリートビューによる目視確認、および各金融機関ホームページ、各建築物の構内図を参照することで、各ATM設置場所をコーディングした。変数2~4は、「Zmap TOWN II 2013/14年度Shape版」から、対象地域における戸建て住宅以外の建物を抽出し、各ATM設置場所から最も距離の近い建築物を特定した上で算出(建物面積で重み付け)したⁱⁱ。変数5は、「Zmap Area II 2014-3版」のうち、「駅名称」、および「地下駅名称」を抽出し、各ATM設置場所から最近接の駅までの距離を算出した。変数6は、国土数値情報「バス停留所データ」2010年度版を用い、各ATM設置場

ii Urban Network Analysisでは、建物をノード、街路をエッジとして、街路ネットワーク上における建物の中心性を複数の指標で評価する。対象の建物を*i*、他の建物を*j*, *k*, *G*をグラフ、*n*を個数、*d*を経路距離、 δ を直線距離、*W*を重みとしたとき、媒介中心性(Betweenness Centrality)、直進中心性(Straightness Centrality)、近接中心性(Closeness Centrality)は、それぞれ次の式で算出される。

$$\text{Betweenness Centrality} = \sum_{j,k \in G - \{i\}, d[j,k] \leq r} \frac{n_{jk}[i]}{n_{jk}} W[j]$$

$$\text{Straightness Centrality} = \sum_{j \in G - \{i\}, d[i,j] \leq r} \frac{\delta[i,j]}{d[i,j]} W[j]$$

$$\text{Closeness Centrality} = \frac{1}{\sum_{j \in G - \{i\}, d[i,j] \leq r} (d[i,j] \cdot W[j])}$$

これらはそれぞれ、検索範囲を*r*として、互いの経路距離が*r*以下の建物*j*, *k*をつなぐ経路のうち建物*i*を通る経路の割合、互いの経路距離が*r*以下の建物*i*, *j*間の直線距離と経路距離の比、建物*i*から経路距離*r*で到達可能な建物*j*への経路距離の和の逆数を表す。ツールは、City Form Labのホームページ(<http://cityform.mit.edu/projects/urban-network-analysis.html>)からダウンロードした。

所から最近接のバス停までの距離を算出した。変数7は、国土数値情報「警察署データ」2014年度版をもとに、「警察署」、「交番」、「派出所」、「駐在所」を抽出し、各ATM設置場所から最近接の警察施設までの距離を算出した。変数8は、「Zmap TOWN II 2013/14年度Shape版」から、戸建て住宅以外の建物を抽出し、各ATM設置場所を含むか、最も距離の近い建築物を特定した上で面積を算出した。変数9は、ATM設置場所のポイントデータからカーネル密度推定を行った後、各ATM設置場所が含まれるセルの密度推定値を、当該ATM設置場所の値としたⁱⁱⁱ。なお、変数2~4の検索範囲となる経路距離 r （補注ii参照）、および変数9のバンド幅として、孔ら（2011）を参照し、65歳以上の住民が買物施設までの移動に負担を感じない距離として、300mと設定した。また、変数9のセルサイズとして、戸建て住宅以外の建物の平均面積を算出（160.9m²）した上で平方根をとり、12.7mと設定した^{iv}。

変数10~15は、ATM設置場所の存在する地区（町丁目）の指標値を用いた。変数10, 11は、2015年国勢調査のから、当該地区の「65歳以上世帯員のみ的一般世帯数」から、「うち夫婦のみ世帯」、または「単独世帯」を足し上げ、「総数（世帯の家族類型）」で除算した。変数12は、マップマーケティング株式会社の「年収別世帯数データ2013」から、年収の階級ごとに階級値^vと世帯数を乗算した上で足し上げたものを用いた。変数13は、マップマーケティング株式会社の地区ごとの「貯蓄推計データ2014」のうち、「通貨性預貯金」、「定期性預貯金」、「生命保険など」、「有価証券」、および「その他貯蓄」を足し上げたものを「貯蓄一般世帯数」で除算した値を用いた。変数14は、2015年国勢調査の当該地区の人口を面積で除算した値を用いた。変数15は、2014年経済センサスの当該地区の「農林漁業」、「公務」を除く事業所数を面積で除算した値を用いた。

地理空間情報と各種統計情報のデータベース構築には ArcGIS10.5 を、中心性指標の計算には、Urban Network Analysis Toolbox ver.1.1 を用いた。

7.3.3 分析方針

既に述べたように、還付金等詐欺では無人ATMへの誘導が多いことから、ATM設置場所の周辺に施設の職員や警備員などがいるかどうか、誘導発生に大きく関連すると考えられる。また、建築物の種別ごとに、ATMが置かれている環境が大きく異なることから、誘導発生に関連する要因が、その種別ごとに異なる可能性が考えられる。そのため、分析に先立ち、

iii 孔ら（2011）の調査では、65歳以上の住民の80%が、買物施設までの移動に負担を感じない距離は約300mであった。

iv あるATM設置場所から徒歩圏内で行けるATMの多寡を表すために、ATMが設置される建築物の平均的な大きさをセルサイズとして設定した。

v 階級は、「年収200万円未満」で始まり、「年収200~300万円」、…、「年収900~1000万円」まで100万円ごと増加、さらに「年収1000~1500万円」、「年収1500万円以上」の全11階級であった。階級値は、それぞれ「200万円」、「250万円」、…、「950万円」、「1250万円」、「1500万円」とした。

表 7-3 建築物種別ごとの誘導発生状況

	誘導発生 件数	誘導発生 場所数	全 場所数	誘導発生場所数 / 全場所数
スーパーマーケット, もしくはドラッグストア	43	25	111	22.5%
病院	8	6	34	17.6%
その他屋外	2	2	14	14.3%
駅	10	7	70	10.0%
デパート, もしくは 大型商業施設	9	8	81	9.9%
その他施設	6	6	69	8.7%
大学	1	1	21	4.8%
金融機関	7	6	461	1.3%
コンビニエンスストア	7	6	754	0.8%
空港	0	0	10	0.0%




図 7-2 スーパーにおける誘導発生件数の度数分布

ATM がどのような建築物に設置されているかを調べ、「金融機関(銀行, 信用金庫, 郵便局)」、「コンビニエンスストア」、「スーパーマーケット, もしくはドラッグストア」、「デパート, もしくは大型商業施設(ショッピングモール, 駅ビル含む)」、「駅」、「病院」、「大学」、「空港」、「その他施設(オフィスビル, 役所庁舎, ホテル等)」、「その他屋外(集合住宅・団地, 駐車場等)」の10種に分類した。分類ごとの詐欺誘導の発生状況を表 7-3 に示す(全場所数に占める発生場所数の割合の大きい順に並べている)。表 7-3 から、「スーパーマーケット, もしくはドラッグストア」(以下, 単に「スーパー」と呼称)で誘導発生水準が最大, かつ分析単位となる ATM 設置場所数, 応答変数となる誘導発生件数ともに十分な水準にあることから, 本分析では, スーパーにある ATM 設置場所 111 箇所を分析対象とした。これら 111 箇所の ATM 設置場所が所属する町丁目数は, 84 であった。

図 7-2 には, 応答変数となる ATM 設置場所ごとの誘導発生件数(スーパーのみ)の度数分布を示した。表 7-4 予測変数の要約統計量には, 予測変数の要約統計量を示した。変数 1 は, 「屋内」63 箇所, 「隣接」31 箇所, 「敷地内または独立」17 箇所であった。なお, 分析にあたり, 連続変数となる予測変数 2~9 は, 値のばらつきが大きく, パラメータ推定が不安定になることが予想されたため, 1 を足した上で対数変換して用いた。

今回の分析では, 各 ATM 設置場所が地区にネストした状況となっており, パラメータ推定

表 7-4 予測変数の要約統計量

	変数名	度数	最小値	最大値	平均	標準偏差
設置場所・直近環境						
# 1	ATM 設置建築物との位置関係	111	-	-	-	-
# 2	媒介中心性	111	0	1754351.00	260155.30	310656.70
# 3	直進中心性	111	2678.43	53535.09	19405.56	11441.68
# 4	近接中心性	111	7.00×10^{-8}	2.13×10^{-6}	3.02×10^{-7}	2.62×10^{-7}
# 5	最寄り駅までの距離 (m)	111	11.15	5007.98	1047.34	1001.85
# 6	最寄りバス停までの距離 (m)	111	15.24	487.04	130.89	82.77
# 7	最寄り警察署・交番までの距離 (m)	111	71.03	1839.07	727.90	339.86
# 8	ATM 設置建築物の面積 (m ²)	111	4.68	10029.48	2327.41	2028.88
# 9	周辺の ATM 密度 (箇所 / m ²)	111	1.06×10^{-5}	1.27×10^{-4}	3.38×10^{-5}	2.48×10^{-5}
地区環境						
# 10	65 歳以上夫婦のみ世帯割合	84	0	0.20	0.07	0.04
# 11	65 歳以上単身世帯割合	84	0	0.43	0.11	0.06
# 12	地区の推計平均世帯年収 (万円)	84	267.70	587.88	424.96	63.13
# 13	地区の推計平均貯蓄 (万円)	84	6100.05	15726.48	10646.97	2027.17
# 14	人口密度 (人 / m ²)	84	1.96×10^{-4}	3.29×10^{-2}	1.11×10^{-2}	6.47×10^{-3}
# 15	事業所密度 (箇所 / m ²)	84	6.93×10^{-7}	8.91×10^{-3}	7.15×10^{-4}	1.30×10^{-3}

にあたり、直近環境の要因の効果（構成効果）と、地区環境の要因の効果（文脈効果）を切り分けて推定する必要がある。そのため、今回はマルチレベルモデルを採用し、切片のみに変量効果を仮定した負の二項分布による一般化線形混合モデル（GLMM）を実行した。応答変数の級内相関を示す ICC（Intra-Class Correlation）^{vi}は 0.22 であり、マルチレベル分析を行うことが妥当な水準であった。ここで用いた分析モデルは以下のように表せる。

$$\ln(\lambda_{ij}) = \beta_{0j} + \sum_{m=1}^M \beta_m x_{mij} + r_{ij} \quad (7.1)$$

$$\beta_{0j} = \gamma_{00} + u_{0j} \quad (7.2)$$

λ_{ij} は、地区 j の ATM 設置場所 i における誘導発生件数の期待値であり、負の二項分布にしたがうものとする。これが求めるべき長期的・潜在的リスクの値となる。 β_{0j} は切片、 β_m が予測変数 x_m の回帰係数、 x_{mij} が予測変数であり、 r_{ij} は残差である。また、地区ごとに変動する切片 β_{0j} は、固定効果 γ_{00} と変量効果 u_{0j} からなる。

なお、変数 1 は「屋内」を参照水準とした。

分析には統計解析環境 R ver.3.5.1 を、マルチレベル分析の実行には lme4 パッケージを用いた。

vi ICC は、全体の分散に占める集団の分散（集団とは本分析においては地区を指す）の比で求められる。ここで ICC は、地区間の分散 τ_{00} （式 (7.2) の u_{0j} の分散）と全体の分散 $\tau_{00} + \sigma^2$ （ σ^2 は式 (7.1) における r_{ij} の分散）の比をとったもの、すなわち $\tau_{00} / (\tau_{00} + \sigma^2)$ として求めた。

表 7-5 GLMM によるパラメータ推定結果

	モデル 0: Null model			モデル 1: 設置場 所・直近環境まで			モデル 2: 地区環境 まで		
	推定	S. E.		推定値	S. E.		推定値	S. E.	
固定効果									
切片	-1.69	0.37	***	27.93	5.87	***	28.68	5.97	***
設置場所・直近環境									
位置関係「隣接」				1.14	0.48	*	1.49	0.56	**
位置関係「敷地内, 独立」				0.30	0.65		0.34	0.68	
媒介中心性				0.85	0.35	*	0.88	0.40	*
直進中心性				-3.81	0.68	***	-3.70	0.78	***
近接中心性				-7.1×10^6	264.7	***	-9.6×10^6	311.60	***
ln_駅までの距離				-0.05	0.17		-0.21	0.18	
ln_バス停までの距離				-0.02	0.30		-0.04	0.30	
ln_警察施設までの距離				0.00	0.37		0.01	0.35	
ln_ATM 設置建築物の面積				0.06	0.12		0.02	0.12	
ln_周辺の ATM 密度				-3.5×10^4	241.7	***	-2.1×10^4	340.60	***
地区環境									
65 歳以上夫婦のみ世帯割合							-4.19	7.41	
65 歳以上単身世帯割合							-7.76	6.77	
推計平均世帯年収							0.00	0.00	
推計平均貯蓄							3.5×10^{-4}	0.00	***
人口密度							-64.91	56.08	
事業所密度							-1686.00	371.90	***
変数効果 (分散の推定値)									
地区		1.51			0.29			0.00	
AIC		189.3			176.0			175.6	
BIC		197.4			211.2			227.1	
log likelihood		-91.6			-75.0			-68.8	
レコード数 (Lv. 1: ATM 設置場所)		111			111			111	
レコード数 (Lv. 2: 地区)		84			84			84	

Note. ***: $p < 0.001$, **: $p < 0.01$, *: $p < 0.05$

7.3.4 結果

分析結果を表 7-5 に示す。最終モデルであるモデル 2 において、切片の変数効果はほぼ 0 となった。固定効果が統計的に有意 ($p < 0.05$) となった変数は、ATM 設置建築物との位置関係の「隣接」(正)、「媒介中心性」(正)、「直進中心性」(負)、「近接中心性」(負)、「周辺の ATM 密度」(負)、「平均貯蓄」(正)、「事業所密度」(負)であった。

ここから、店舗屋外、かつ店舗に隣接する形で設置されている、交通の結節点に近い店舗に設置されている、富裕な地区にあるといった場合にリスクが高いことがわかった。また、直線的な道路に面した店舗に設置されている、近くに他の建物が多く存在する店舗に設置されている、周辺に ATM が多く存在する、事業所密度の高い地区にあるといった場合に、リスクが押し下げられることがわかった。

7.4 短期的・顕在的リスクに関する分析

7.4.1 分析方法

本分析では、6 章と同様に、Knox Test を用いて検証を行った。ただし、今回は同一の ATM 設置場所で発生する誘導のみに関心があるため、同一の場所 (距離差 = 0) の Knox 比のみに着目した。

表 7-6 Knox 比にもとづく反復誘導分析の結果

	≤ 1日	≤ 2日	≤ 3日	≤ 4日	≤ 5日	≤ 6日	≤ 7日	≤ 8日	≤ 9日	≤ 10日
観測値	4	4	4	4	5	6	6	6	6	6
Knox比	4.24	3.32	2.94	2.46	2.65	2.40	1.97	1.70	1.50	1.44
p 値	0.0080	0.0165	0.0240	0.0465	0.0190	0.0140	0.0495	0.0910	0.1485	0.1675

分析にあたって用いたデータは、3節と同一の ATM 設置場所ごとの詐欺の誘導発生状況である。誘導の反復傾向が特定の業種に依存すると考える根拠は乏しいため、ここでの分析では、スーパーに限定せず、全 ATM 設置建築物における誘導の反復傾向を調べた。そのため、全 1625 箇所が発生した 93 件の誘導の位置・発生日情報を用いた。

分析には統計解析環境 R ver. 3.5.1 を用い、上記の手法に基づく関数を作成して用いた。

7.4.2 結果

表 7-6 に示す通り、同一の ATM 設置場所において、全事象が時空間的に独立して発生した場合と比較して、7 日間以内に 1.97 倍のリスク上昇が見られた ($p < 0.05$)。

7.5 予測モデルの適用と評価

7.5.1 予測に用いたデータ

誘導の情報は、要因分析と同様の福岡県警提供データの、2017 年のものを用いた。ATM のデータベースも、3節と同様のデータの 2017 年版として、マップマーケティング株式会社が販売する「ATM 拠点データベース」の 2017 年版を基本とし、収録対象外となっていた JA バンク、信用金庫、労働金庫の位置情報を追加 (92 箇所) したものをを用いた。2017 年における福岡市の ATM 設置場所の全件数は、1664 箇所である。なお、2016 年のデータに対し、66 件の ATM が新規に追加され、8 件の ATM は名称変更がないまま位置が移動していたため、情報を適宜追加・修正した。スーパーマーケット、またはドラッグストアに限定すると、ATM 設置場所数は全 112 箇所、うち設置場所ごとの誘導発生件数は 20 箇所、30 件であった。設置場所ごとの発生件数が予測の対象である。

予測変数となる地理空間情報のうち、各 ATM 設置建築物の情報や統計情報については、3節で用いたものが既に最新の情報であったため、同一のデータを用いた。ただし、「周辺の ATM 密度」のみ、ATM データベースが更新されているため、新たに算出した。また、ATM 設置建築物との位置関係については、新規に追加・移転が生じた ATM について新たにコーディングを行った。表 7-7 に予測変数の要約統計量を示す

7.5.2 予測値の算出

ATM 設置場所をとりまく環境に起因する長期的・潜在的リスクと、ひとたび詐欺の誘導が発生することで短い期間だけ上昇する短期的・顕在的リスクを同時に考慮して総合的リスクを算出し、これにより誘導の多寡を予測するモデルを構築した。

予測モデルの具体的な構築方法について述べる。まず、3節の分析で推定されたモデル(2016年のデータから作成されたモデル)に対し、2017年におけるスーパーの ATM 設置場所のデータを外挿した。これによって得られた 2017 年の誘導発生件数の予測値を長期的・潜在的リスクとした。さらに、ある ATM 設置場所が、一度誘導対象になったときから 7 日間の長期的・潜在的リスクの値に対し、4 節の分析で得られた結果より、反復誘導のリスク比 (短期的・顕在的リスク) の 1.97 を乗算し、総合的リスク値とした。総合リスク値 $\lambda'_{i,d}$ は、ATM 設

表 7-7 予測変数の要約統計量

	変数名	度数	最小値	最大値	平均	標準偏差
設置場所・直近環境						
# 1	ATM 設置建築物との位置関係	112	-	-	-	-
# 2	媒介中心性	112	0	1754351.00	267140.10	314726.70
# 3	直進中心性	112	2678.43	53535.09	19092.69	10862.54
# 4	近接中心性	112	7.33×10^{-8}	2.13×10^{-6}	3.06×10^{-7}	2.64×10^{-7}
# 5	最寄り駅までの距離 (m)	112	11.15	5007.98	1061.79	1011.42
# 6	最寄りバス停までの距離 (m)	112	15.24	487.04	132.77	81.81
# 7	最寄り警察署・交番までの距離 (m)	112	71.03	1839.07	738.86	335.11
# 8	ATM 設置建築物の面積 (m ²)	112	4.68	10029.48	2033.59	1889.59
# 9	周辺の ATM 密度 (箇所 / m ²)	112	1.06×10^{-5}	1.30×10^{-4}	3.35×10^{-5}	2.42×10^{-5}
地区環境						
# 10	65 歳以上夫婦のみ世帯割合	85	0	0.20	0.07	0.04
# 11	65 歳以上単身世帯割合	85	0	0.43	0.10	0.05
# 12	地区の推計平均世帯年収 (万円)	85	0	587.88	420.83	77.56
# 13	地区の推計平均貯蓄 (万円)	85	0	15073.14	10437.77	2253.84
# 14	人口密度 (人 / m ²)	85	1.96×10^{-4}	3.29×10^{-2}	1.13×10^{-2}	6.41×10^{-3}
# 15	事業所密度 (箇所 / m ²)	85	6.93×10^{-5}	5.87×10^{-3}	6.23×10^{-4}	9.37×10^{-4}

置場所 i の長期的・潜在的リスク値 λ_{ij} , 任意の日 d における ATM 設置場所 i の短期的・顕在的リスク値 $\eta_{i,d}$ を用いて式 (7.3) のように表せる。ただし, $\eta_{i,d}$ は式 (7.4) のような値をとるものとする。式 (7.5) における $N(k, d+u-7)$ は, ある日 $d+u-7$ において ATM 設置場所 i で発生した誘導の件数である。

$$\lambda'_{ij,d} = \lambda_{ij} \eta_{i,d} \quad (7.3)$$

$$\eta_{i,d} = \begin{cases} 1.97, & \xi \geq 1 \\ 1, & \text{otherwise} \end{cases} \quad (7.4)$$

$$\xi = \sum_{u=0}^6 N(d+u-7) \quad (7.5)$$

リスク値 $\lambda'_{ij,d}$ を算出後, 値の高い順に並び替え, 上位のものをハイリスクな ATM 設置場所として, 2017 年の誘導発生状況と照合した。以降では, リスク値 $\lambda'_{ij,d}$ に基づく予測モデルを「MLNB*NR (Multi-Level Negative Binomial * Near Repeat)」と呼称する。

上記の分析には, 統計解析環境 R ver.3.5.1 を用いた。

7.5.3 検証の方法

本分析では, 2016 年のデータの分析によって得られた結果をもとに, ATM 設置場所ごとの詐欺誘導の予測モデルを構築, 2017 年のデータに適用し予測精度の検証を行う。

予測精度の検証にあたっては, ベンチマークを設けた。これには, 長期的・潜在的リスク

と短期的・顕在的リスクを単純に足し合わせたもの（7日以内に犯罪が発生した ATM 設置場所は 1.97、その他の ATM 設置場所は 0 を足す）として「MLNB+NR」モデル、長期的・潜在的リスクのみに基づいて予測する「MLNB」モデルをそれぞれ設定した。他に、ランダムに ATM 設置場所を選んだ場合に、2017 年の誘導対象をどの程度的中できるかを見た「ランダム予測」モデル、また、2016 年に実際に誘導が生じていた ATM 設置場所で再び誘導が生じると単純に考えた場合、2017 年の誘導対象をどの程度的中できるかを見た「ナイーブ予測」モデルをそれぞれ設定した。

これらを設定したのは、警察実務などで実際に無人 ATM を警戒する場合、特に方針を定めずランダムに警戒をする、過去に詐欺の誘導に晒された ATM に的を絞るといった対策のいずれも想定されるためである。

ランダム予測では、112 箇所の ATM 設置場所から、約 20%にあたる 22 箇所を無作為に抽出し、2017 年の誘導発生状況と照合、この試行を 999 回反復し、その平均をとった。ナイーブ予測は、2017 年に福岡市に存在するスーパーにある ATM 設置場所のうち、2016 年に詐欺の誘導が 1 件以上生じていたものをハイリスクな ATM 設置場所とし、2017 年の誘導発生状況と照合した。

モデルによる予測である MLNB*NR、MLNB+NR、MLNB では、算出されたリスク値の上位 10%（112 箇所中 11 箇所）、20%（112 箇所中 22 箇所）、30%（112 箇所中 33 箇所）をそれぞれハイリスクとしたとき、当該の ATM 設置場所で 2017 年に実際に誘導が発生していた場合に、その件数を的中件数とした。この的中件数を 2017 年における全発生件数 30 件で除し、的中率とした。ナイーブ予測の場合は、2016 年に詐欺の誘導が 1 件以上発生していた ATM 設置場所 25 箇所において、2017 年にも誘導が発生していた場合、その件数をカウントし的中件数とした。的中率は、モデル予測と同じく的中件数を 30 で除した値である。これらを場所割合（ハイリスクとされた ATM 設置場所数が、全 112 箇所に占める割合）で除した比率を最終的に予測精度の指標とした。この的中率 / 場所割合は、3 章、および 5 章の分析で用いた PAI に相当する指標となっている。

7.5.4 結果

すべてのモデルの予測結果を表 7-8 に示す。

ランダム予測は、その定義上自明ではあるが、全体の 20%の ATM 設置場所で、19.7%の詐欺の誘導を予測していた（場所割合あたりの的中率は 0.99、つまりほぼ 1 に等しい）。ナイーブ予測は、全体の 22.3%の ATM 設置場所で、46.7%の詐欺の誘導を予測していた（場所割合あたりの的中率は 2.09）。これに対し、MLNB*NR は、19.6%の ATM 設置場所で、43.3%の詐欺の誘導を予測しており（場所割合あたりの的中率は 2.21）、予測精度はランダム予測を大きく上回り、ナイーブ予測と同等以上であった。

しかしながら、提案手法に基づくモデル MLNB*NR は、短期的・顕在的リスクを考慮せずに（長期的・潜在的リスクのみで）予測した MLNB と予測精度において差が見られなかった。また、長期的・潜在的リスクの値に短期的・顕在的リスクの値を単純加算したモデル MLNB+NR は、長期的・潜在的リスクのみに基づくモデル MLNB よりも予測精度はむしろ低下し、さらにナイーブ予測よりも予測性能が低いという結果となった。

表 7-8 各予測手法の予測精度

		的中件数(的中率)	場所数(場所割合)	的中率 / 場所割合
モデルによる予測	リスク上位 10 %	7 (23.3 %)	11 (9.8%)	2.38
	MLNB*NR リスク上位 20 %	13 (43.3 %)	22 (19.6 %)	2.21
	リスク上位 30 %	18 (60.0 %)	33 (29.5 %)	2.04
	MLNB+			
	リスク上位 10 %	5 (16.7 %)	11 (9.8%)	1.70
	NR			
	リスク上位 20 %	11 (36.7 %)	22 (19.6 %)	1.87
	リスク上位 30 %	18 (60.0 %)	33 (29.5 %)	2.04
	MLNB			
	リスク上位 10 %	7 (23.3 %)	11 (9.8 %)	2.38
	リスク上位 20 %	13 (43.3 %)	22 (19.6 %)	2.21
	リスク上位 30 %	18 (60.0 %)	33 (29.5 %)	2.04
ナイーブ予測	2016 年の誘導 1 件以上	14 (46.7 %)	25 (22.3 %)	2.09
ランダム予測	リスク上位 20 %	5.92 (19.7 %)	22 (20.0 %)	0.99

7.6 議論

ここでは、環境要因分析から見出された長期的・潜在的リスクと、反復誘導分析から見出された短期的・顕在的リスクにより構成された還付金等詐欺予測モデルについて、長期的・潜在的リスク要因、短期的・顕在的リスク要因に関する分析の結果から、予測の前提が成り立っていたかを、5節の分析結果から、予測精度をそれぞれ評価し、モデルに基づく予測の妥当性について議論する。

まず、3節の分析においては、誘導の発生に関連する要因がいくつか見出され、予測の前提となる環境要因が存在することが確かめられた。具体的には、ATM 設置場所が属する地区環境の要因として、「平均貯蓄」が詐欺の誘導に正の効果を、「事業所密度」が負の効果をそれぞれもっていた。また、そうした地区の中で、ATM 設置場所の直近・周辺環境の要因として、ATM 設置建築物との位置関係の「隣接」、「媒介中心性」が正の効果を、「直進中心性」、「近接中心性」、「周辺の ATM 密度」が負の効果をもっていた。

それぞれについて解釈する。まず、地区環境要因についてみると、「平均貯蓄」（係数：正）からは、潜在的な被害者としての、資産を多くもつ住民の多い地区が、詐欺実行犯にとって魅力的な対象となることが推察される。「事業所密度」（係数：負）からは、事業所が比較的疎に存在する郊外的な性格の地区が、詐欺実行犯に好まれる可能性が高いことが推察される。

また、ATM の立地・設置環境要因についてみると、ATM 設置建築物との位置関係（係数：正）については、「屋内」と比較して、「隣接」であること、すなわち、ATM が店員や他の利用者の動線上になく、注意が及びにくいことが、誘導する対象としての選ばれやすさを引き上げると解釈できる。これは、事前の想定通り、自然な監視の欠如が、還付金等詐欺のような知能犯罪にも関連する可能性を示唆する結果である。ただし、「敷地内または独立」の場合は、統計的に有意な効果が見られなかったことから、店舗から離れた位置に ATM があるほど、リスクが高いとはいえない。この点に関しては、犯行者が ATM を指定する際に、店舗との距離が離れすぎない ATM の方が指定しやすいことなどが考えられるものの、更なる詳細な検討が必要であろう。「媒介中心性」（係数：正）からは、ATM が設置されている店舗が、交通の結節点に近く、人通りや交通量が比較的多い場所に立地しているほど、誘導対象として選ばれやすくなると解釈できる。このような店舗は、自然な監視の水準も高いことが予想されるが、店舗面積（「ATM 設置建築物の面積」）が非有意であったことから、店舗周辺や店

舗内部の通行者、利用者の多寡は、必ずしも ATM に注がれる人目の多さにつながらず、詐欺の誘導に抑制的にはたらかないことが考えられる。直線的な道路に面していることを示す「直進中心性」、周辺の他の建物との近接性を示す「近接中心性」、「周辺の ATM 密度」（いずれも係数：負）からは、直線的な道路（主要幹線道路など）に面しておらず、また周辺に他の施設や ATM が少ない店舗に誘導されやすいことがわかる。

上記の結果を総合して考えると、還付金等詐欺において誘導されやすい ATM がある店舗の具体像としては、平均貯蓄が高く、事業所密度が低い地区にあり、さらにその中でも、直線的な大通り沿いではないが（直進中心性が低い）、交差点の多い入り組んだ街路上にある（媒介中心性が高い）、周辺に他の ATM（周辺の ATM 密度が低い）や他の施設が比較的少ない（近接中心性）ことから、郊外型の地区に存在し、かつ地域の中心的な買物施設となっているスーパーマーケットなどが想定できる。こうした店舗は、地域住民であれば店舗の名称を言えば伝わるため、詐欺実行犯からすれば誘導しやすいことが考えられる。

4 節の分析においては、1 件の詐欺の誘導が発生すると、1 週間以内に同じ ATM 設置場所が再び誘導対象となる可能性が高いことが明らかとなり、予測の前提となる誘導の反復性が確かめられた。しかし 5 節の分析では、この短期的・顕在的リスクを考慮しても予測精度が向上しなかった。すなわち、過去における誘導との時間的近さは、予測に寄与しなかった。これについて、2017 年の誘導発生状況を用いて同様の Knox Test を行ったところ、反復誘導の傾向が見出されず、2016 年だけの傾向であることがわかった。このことから、2017 年では詐欺の誘導発生傾向に変化があり、そのことが予測の成否に影響を与えたと推察される。一方で、ナイーブ予測の予測精度でも、ランダム予測を上回るものであったことから、過去の実績に基づいて予測することには、一定の有効性があると考えられる。上記をあわせて考えると、還付金等詐欺の誘導対象となる ATM は、年をまたいで重なっている場合が多いが、数日間という短い期間での発生トレンドは、年をまたいで継続するとは限らないといえる。

なお、短期的・顕在的リスクを考慮する際に単純加算を行ったモデルでは、これを考慮しないモデルや、単に前年実績に基づき予測したモデルよりも、予測精度が低くなるという結果になった。このことは、先述した 2017 年において反復誘導の傾向が見出されなかったこととも関連すると思われる。すなわち、2017 年における短期的・顕在的リスクの効果が低いにもかかわらず、値を単純加算することでそのウェイトが大きくなり、長期的・潜在的リスクによる予測の効果を押し下げてしまった可能性がある。少なくとも今回使用したデータでは、長期的・潜在的リスクと短期的・顕在的リスクを単純に足し合わせるという演算は、適切とはいえないものであった。

7.7 まとめ

本分析では、ATM 設置場所の直近・周辺や地区の環境要因に基づく長期的・潜在的リスクと、反復誘導に基づく短期的・顕在的リスクから還付金等詐欺の誘導の予測モデルを構築し、その予測精度を前年実績からのナイーブ予測との比較から検証した。

本研究の提案手法に基づく予測モデルは、ランダム予測を凌駕し、ナイーブ予測と同等、もしくはそれ以上の予測精度を示した。ただし、その予測性能は、長期的・潜在的リスクのみに基づく予測と等しく、短期的・顕在的リスクを考慮した効果は見られなかった。

一方で、長期的・潜在的リスクのみに基づく予測でも、2 割弱の ATM 設置場所で 4 割強以上の詐欺誘導発生を的中でき、一定程度有効な予測が行うことができた。これは、本分析で構築した長期的・潜在的リスクによる予測モデルが、還付金等詐欺の誘導対象となりやすい ATM 設置場所、およびその設置店舗の典型像に合致していたことの証左ともいえるだろう。

本来、還付金等詐欺の誘導状況などは、ATM 設置場所という単位では開示されることはない。今回、そのリスク要因が明らかとなったことで、これを地域の具体的な ATM 設置場所に適用し、被害情報がなくとも、予測を行うことが可能となる。このことは、本分析の成果といえるだろう。

また、特殊詐欺のように、個人に経済的損害を直接的・間接的に与える犯罪（consumer financial fraud）は、諸外国でも多く発生していることが、国際的な調査でも明らかになっており（Deevy et al., 2012）、また、還付金等詐欺に似た手口として、“IRX tax refund opportunity”などが存在している（Beals et al., 2015）。本章で提出した還付金等詐欺の予測モデルは、ATM という場所に注目することで、地理的犯罪予測が扱うことの難しかった詐欺という犯罪にアプローチし、世界的に台頭する詐欺犯罪を場所に基づいて予測する端緒を開いたものとして位置づけることができるだろう。

7章の参考文献

- 1) 朝日新聞 (2017) 「集中警戒 2 週間、被害 10 分の 1、府警の特殊詐欺対策、水際防止 16 件」, 6 月 28 日朝刊.
- 2) 警察庁 (2017) 「平成 28 年の特殊詐欺認知・検挙状況等について」, <http://www.npa.go.jp/bureau/criminal/souni/tokusyusagi/hurikomesagi_toukei2016.pdf>, 最終閲覧日 2019 年 4 月 23 日.
- 3) 孔慶玥・近藤光男・奥嶋政嗣・近藤明子 (2011) 移動の限界距離を考慮した生活環境施設の評価モデルの構築とその適用に関する研究, 「都市計画論文集」, **46(3)**, 787-792.
- 4) Beals, M., DeLiema, M., and Deevy, M. (2015) Framework for a taxonomy of fraud: A joint collaboration of the Financial Fraud Research Center at the Stanford Center on Longevity and the FINRA Investor Education Foundation. <<http://longevity3.stanford.edu/wp-content/uploads/2015/11/Full-Taxonomy-report.pdf>>, 最終閲覧日 2019 年 12 月 23 日.
- 5) Cohen, L., and Felson, M. (1979). Social change and crime rate trends: A routine activity approach, *American Sociological Review*, **44(4)**, 588-608.
- 6) Cornish, D., and Clarke, R. eds. (1986) *The Reasoning Criminal: Rational Choice Perspectives on Offending*. New York: Springer-Verlag.
- 7) Crowe, T. (1991) *Crime prevention through environmental design: Applications of architectural design and space management concepts*. Boston: Butterworth-Heinemann.
- 8) Deevy, M., Lucich, S., and Beals, M. (2012) Scams, schemes & swindles: A Review of Consumer financial fraud research. <<http://longevity3.stanford.edu/wp-content/uploads/2014/01/Scams-Schemes-Swindles-FINAL-On-Website.pdf>>, 最終閲覧日 2019 年 12 月 23 日.
- 9) Johnson, S., Birks, D., McLaughlin, L., Bowers, K., and Pease, K. (2007) *Prospective Crime Mapping in Operational Context, Final Report*, London: Home Office, 4-14pp.
- 10) Sevtsuk, A., and Mekonnen, M. (2012) Urban network analysis: a new toolbox for measuring city form in ArcGIS, In *Proceedings of the 2012 Symposium on Simulation for Architecture and Urban Design*, No. 18.

第8章 結論

8.1 総合論議

8.1.1 本研究のまとめ

本研究では、日本における地理的犯罪予測手法を開発するという目的のもと、文献研究、および国内における詳細レベルの犯罪データを用いた実証研究に取り組んだ。以下に、主要な結果をまとめる。

本研究は、既存の地理的犯罪予測手法について、日本での適用可能性を検討する2・3章と、これをうけて既存手法を改良、日本型の地理的犯罪予測手法を提案し、その有効性をさまざまな罪種について検証する4・5・6・7章で構成された。

第2章では文献レビューにより、地理的犯罪予測の源流となる学術研究や実務・社会の動向を振り返りつつ、これま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、そこで扱われてきた手法を、予測へのアプローチの違いによって、i. 時空間クラスタの検出、ii. 犯罪の時空間相互作用を考慮した犯罪発生の強度推定、iii. 犯罪生成・誘因要因からの犯罪発生リスクの予測、iv. 多様な情報からの犯罪発生リスクの予測、v. 地区単位での犯罪発生件数、または確率の時系列予測、vi. 環境要因と犯罪の時空間相互作用を組み合わせた犯罪発生リスクの予測、という6つの系統に分類した。これらのうち、iiの手法が依拠する近接反復被害現象が、日本でも確認されていることから、わが国においても有望であることや、詳細レベルの犯罪データを必ずしも必要としないiiiやvの手法は日本でも利用しやすいものであると結論づけた。

次に第3章では、2章で取り上げた各予測手法のうちから特定の予測モデルを複数選び出し、日本の実データに適用した。時空間クラスタの検出からPSTSS、犯罪の時空間相互作用を考慮した犯罪発生の強度推定からProMapとSEPP、犯罪生成・誘因要因からの犯罪発生リスクの予測からRTM、多様な情報からの犯罪発生リスクの予測からGAMをそれぞれ選び、車上狙い・部品狙いに適用、25m四方のセル単位で、月ごとに予測性能を評価した。分析の結果、過去の犯罪の空間（位置）情報のみに依拠して予測するKDE、犯罪間の時空間相互作用に依拠して予測を行うSEPPやProMapといったモデルに対し、駐車場、コンビニエンスストア、道路といった犯罪生成・誘引要因に依拠して予測を行うRTM、民営借家数や単身世帯数といった社会経済的要因に依拠して予測を行うGAMといったモデルが高い予測精度を得ることを確かめた。特に、RTMは最大の予測性能を示し、犯罪データのみを用いる手法と比較して2倍程度の精度を得た。また、RTMの予測精度は、海外の既存研究と比較しても遜色のないものであった。このことから、わが国においては、犯罪データのみに依拠した手法をとるよりも、場所をとりまく物理的・社会的な環境要因をうまく活用することで、諸外国と同水準の精度で予測を行うことが可能と考えられた。ただし、一部犯罪発生頻度の少なさから、実行不可能な予測モデルがあり、わが国では既存の予測モデルを改良する必要があると結論づけた。

続く第4章では、2章の既存研究・手法の整理、および3章の比較分析の結果をうけて、日本に適した地理的犯罪予測手法の具体像について検討した。ここでは、予測に必要な要素を

長期的・潜在的リスク要因と短期的・顕在的リスク要因とに分け、前者については、社会経済的要因（SES、安定性、人種）と、犯罪生成・誘引要因、犯罪可能要因を、後者については近接反復被害と前兆事案をそれぞれ想定しつつ、日本で有効な予測変数について論じた。その後、これらを組み合わせる方法について検討した。既存手法のように、予測の要素として長期的・潜在的リスクと短期的・顕在的リスクを等価に扱い、単純加算する方法に対し、3章の結果から、日本では特に長期的・潜在的リスク要因を重視すべきと考え、これにより予測された値をベースに、短期的・顕在的リスクを乗算する形でリスクを求める方法を提案した。

第5章以降では、4章で検討した予測手法をさまざまな罪種に適用し、その有効性を評価した。

第5章では、財産犯罪の一つである車上狙い・部品狙いに対し、新手法を適用した。提案手法から、RTMをベースとした予測モデルを作成した。その際、過去の犯罪蓄積を犯罪生成・誘引要因のみで算出したRTMリスク値で回帰し、その残差を、車上狙い等の予測に寄与しうる社会経済的要因、犯罪可能要因、および未知の犯罪生成・誘引要因を表象するものと捉え、この残差が高くRTMリスク値の低いセルを新たな長期的・潜在的リスクとして採用した。残差を取り入れたRTMをe-RTMとし、さらに近接反復被害分析によって得たリスク上昇率の値を長期的・潜在的リスクの値に乗算することで、総合リスクを得た。このモデルe-RTM*NRは、従来のRTM、e-RTM、および既存研究のような、長期的・潜在的リスクと短期的・顕在的リスクを単純加算したe-RTM+NRと比較して、高い予測精度と安定性を得た。ただし、月によっては、提案手法による予測精度の向上は見られなかった。以上のことから、車上狙い・部品狙いを対象とした検討では、犯罪可能要因、短期的・顕在的リスクを考慮したモデルの予測性能は、おおむね既存手法を上回るが、予測対象時期によって、これらの要因が寄与するかどうかが変わるため、常に性能の向上が見られるわけではないと結論づけた。

第6章では、身体犯罪の一つである痴漢に対して新手法を適用した。長期的・潜在的リスクについて、社会経済的要因として地区の推計平均世帯年収、居住年数5年未満人口比率を、犯罪生成・誘引要因として共同住宅面積や娯楽施設、飲食店、駅等の施設までの距離や面積を、犯罪可能要因として、痴漢被害に遭いやすい属性を除いた者の流動人口や空地面積、警察施設までの距離をそれぞれ予測変数としたゼロ過剰負の二項回帰分析に基づき、4つの時間帯（5～14時、14～19時、19～24時、0～5時）に分けて長期的・潜在的リスクを推定した。また、同罪種・異罪種（声かけ、つきまとい、卑わい言動）との時空間相互作用を検討し、短期的・顕在的リスクを推定した。長期的・潜在的リスク要因としては、犯罪可能要因の効果は見られなかったものの、推計平均世帯年収といった社会経済的要因、共同住宅面積、業務施設面積、娯楽施設面積、飲食店や駅までの距離といった犯罪生成・誘引要因の効果が見られ、短期的・顕在的リスク要因としては、異罪種との時空間相互作用は見られなかったものの、近接反復被害効果が観測された。長期的・潜在的リスク要因からの予測値と、近接反復被害によるリスク上昇率をかけ合わせることで、予測モデルZINB*NRを作成し、100m四方のセル単位で日ごとに予測性能を評価した。結果として、長期的・潜在的リスクと短期的・顕在的リスクを組み合わせたZINB*NRモデルは、長期的・潜在的リスクのみによるZINBモデルよりも高精度であり、さらに過去の犯罪実績のみに依拠したKDEによる予測の精度を大きく上回った。長期的・潜在的リスクと短期的・顕在的リスクを単純に足し合わせたZINB+NRモデルの予測精度が、一部の時間帯ではZINB*NRを上回っていたものの、身体犯罪を対象とした検討では、短期的・顕在的リスクを考慮することによる予測精度の向上は、一定程度あるものと結論づけた。

第7章では、知能犯罪の一つである還付金等詐欺に際して生じる無人ATMへの誘導に対し、新手法を適用した。長期的・潜在的リスクについて、犯罪生成・誘引要因（潜在的被害対

表 8-1 本研究で提案した手法に基づく予測モデルと既存手法の比較

		既存手法		本研究		
		RTM	PROVE	e-RTM*NR	ZINB*NR	MLNB*NR
長期的・潜在的リスク	犯罪生成・誘引要因	有	無	有	有	有
	犯罪可能要因	無	無	(有)	有	有
	社会経済的要因	無	有	(有)	有	(有)
短期的・顕在的リスク	近接反復被害	無	有	有	有	有
	前兆事案	無	無	無	無	無

象の多寡)として、地区の65歳以上の夫婦のみ世帯割合・65歳以上単身世帯割合、ATMやそれが設置される建築物のアクセシビリティとして駅までの距離や道路ネットワークの媒介中心性など、また地区の事業所密度や周辺のATM密度などを、さらに社会経済的要因かつ犯罪生成・誘引要因として、地区の平均世帯年収や平均貯蓄を、犯罪可能要因として、ATM設置建築物との位置関係をそれぞれ予測変数としたマルチレベル負の二項回帰分析に基づき、長期的・潜在的リスクを推定した。また、還付金等詐欺の誘導そのものの反復傾向を検討し、短期的・顕在的リスクを推定した。長期的・潜在的リスク要因としては、犯罪可能要因の効果が見られ、また、媒介中心性、直進中心性、近接中心性、周辺のATM密度、推計平均貯蓄、事業所密度といったものの効果が見られた。短期的・顕在的リスク要因として、反復誘導の効果が観測された。長期的・潜在的リスク要因からの予測値と、反復誘導によるリスク上昇率をかけ合わせることで、予測モデルMLNB*NRを作成、ATM単位で日ごとに予測性能を評価した。結果として、長期的・潜在的リスクと短期的・顕在的リスクを組み合わせた予測は、長期的・潜在的リスクのみによる予測と予測精度が同等であったが、前年実績と同じATMを警戒するナイーブ予測よりも高精度であり、ランダム予測の精度を大きく上回った。また、長期的・潜在的リスクと短期的・顕在的リスクを単純に加算したMLNB+NRの予測精度は、ナイーブ予測を下回るものだった。以上のことから、知能犯罪を対象とした検討では、犯罪可能要因が予測に寄与するが、短期的・顕在的リスクの効果は見られないものと結論づけた。

表 8-1には、本研究で提案した手法(4章)に基づいて作成された、各罪種に対応する予測モデル(5~7章)に含まれる長期的・潜在的リスク、短期的・顕在的リスクそれぞれのリスク要因を一覧した。あわせて、既存手法として主に参照したRTMとPROVEについても掲載している。表中の文字のうち、「有」、「無」は、モデルの中に表側のリスク要因を含んでいるかどうかを表している。また、e-RTM*NRで「(有)」と示しているのは、犯罪可能要因や社会経済的要因を回帰分析の残差の中に含まれるものとして扱っていたこと、MLNB*NRで「(有)」としているのは、地区の平均世帯年収、平均貯蓄が、犯罪生成・誘引要因としての側面ももっていたことによる。表にあるように、既存手法のうち、RTMは、純粋に長期的・潜在的リスクに基づく手法であり、犯罪生成・誘引要因のみに依拠して予測を行うものだった(この点は、RTMDxでも同じである)。また、PROVEは、長期的・潜在的リスクと短期的・顕在的リスクを組み合わせたモデルであったが、社会経済的要因と近接反復被害のみを考慮したモデルとなっている。これに対し、本研究の提案手法は、考えられる長期的・潜在的リスク要因、短期的・顕在的リスク要因について議論した上で、具体的な予測モデルには、それらを含むものを作成することを試みた。最終的には、前兆事案についてはいずれの予測モデルでも考慮することができなかつたが、犯罪生成・誘引要因と社会経済的要因を同時に含み、また、これまでほとんど予測に取り入れられていなかった犯罪可能要因も加えることができた。

表 8-2 本研究で得られた結果のまとめ

	犯罪生成・誘引要因による予測の有効性	その他の長期的・潜在的リスク要因（社会経済的要因、犯罪可能要因等）の有効性	短期的・顕在的リスクを考慮した場合の精度の向上
車上狙い・部品狙い	有	有	有
痴漢	有	有 (社会経済的要因のみ)	有
還付金等詐欺	有	有	無

本研究を通じて行った、日本における地理的犯罪予測手法に関する検討の結果をまとめる。まず、過去の犯罪発生情報のみで依拠した予測手法と、環境要因を活用した予測手法を比較した場合、日本では、後者の方が優れた予測性能を発揮していた。これは財産犯罪としての車上狙い・部品狙い、身体犯罪としての痴漢、知能犯罪としての還付金等詐欺のいずれにもあてはまっており、海外よりも犯罪発生が低頻度な状況では、環境要因から予測される長期的・潜在的リスクが予測に寄与する可能性が高いと結論づけられる。また、第5章から7章までの検討を通じて、長期的・潜在的リスクをベースとして、過去の犯罪発生情報から推定した短期的・顕在的リスクを組み合わせた予測は、車上狙い・部品狙い、痴漢では長期的・潜在的リスクのみに基づく予測よりも高性能であった。また、犯罪可能要因が予測に寄与していたのは、車上狙い・部品狙い、および還付金等詐欺であった。表8-2は、本研究で得られた知見をまとめたものである。このように、社会経済的要因、犯罪生成・誘引要因などから推定される長期的・潜在的リスクは、本研究で扱ったすべての罪種で予測に寄与しており、日本のように犯罪が低頻度な状況では、予測の最も有力な要素といえる。さらに、これに短期的・顕在的リスクを組み合わせる手法は、わが国の車上狙い・部品狙いと痴漢の予測には、一定程度有効であることがわかった。また、これまで地理的犯罪予測で扱うことが難しかった犯罪可能要因の効果も、車上狙い・部品狙いと還付金等詐欺において、予測に寄与する形で取り入れることができた。

ただし、財産犯罪を対象とした検討でも、すべての予測対象時期で精度の向上が見られたわけではなかった。また、身体犯罪を対象とした検討でも、すべての時間帯で短期的・顕在的リスクの効果が見られたわけではなく、さらに一つの時間帯では、長期的・潜在的リスクと短期的・顕在的リスクを単純に加算した方法が、乗算する方法よりも高い予測精度を示した。これらのことから、長期的・潜在的リスクと短期的・顕在的リスクの組み合わせ方は、本研究で提案したような乗算方式が、常に適切とは限らないといえる。しかし一方で、4章4節や6章6節で議論したように、短期的・顕在的リスクを加算する方法は、近接反復被害の影響を過大に評価するに等しく、犯罪低頻度な状況では、なおさら妥当な方法とは言い難い。むしろ、予測中に起きている犯罪パターンの変化（たとえば、近接反復被害傾向の変化）に応じて、長期的・潜在的リスクと短期的・顕在的リスクそれぞれの重みを柔軟に変更できるような方法が、求められるかもしれない。

8.1.2 本研究から得られた示唆

本研究を通じて提出した手法は、国外で考案された既存の予測手法の主要なアイデアを参照しつつ、そこで用いられている予測変数について、わが国の状況に鑑みて検討し、必要とされるものを抽出、これらを組み合わせて新たな手法を構築している。中でも、RTMが採用している犯罪生成・誘引要因を主要な予測変数に据え、手法を構築してきた。これは、3章の

分析を通じて、日本においては、犯罪実績のみに基づく方法よりも、犯罪生成・誘引要因、すなわち潜在的被害対象や犯行者の集まりやすい物理構造的環境に着目する方法が、予測精度が高い可能性が示されたことによる。3章で議論したように、犯罪が低頻度な状況下では、犯罪に關与する行為者そのものが少ないことが考えられ、対象地域の犯罪トレンドが、そうした少数の者の行動パターン（別の地域に犯行拠点を移す、検挙されて犯行を行うことが困難になる等）に左右される蓋然性が高くなる。このような状況では、潜在的な犯行者が多数いる状況と比較して、犯罪発生パターンが急激に変化しやすく、過去の犯罪発生情報から将来の犯罪発生を予測することは難しくなる。対して、犯罪生成・誘引要因となるような施設の分布状況は、数日といった期間では変化しづらく、それゆえこうした要因が作り出すリスクは、数ヵ月、あるいは数年の単位で安定して存在する。4章で議論した社会経済的要因や、犯罪可能要因も同様であり、これらは、犯罪生成・誘引要因を補完する形で、都市内にリスクの偏在を生み出す。これらの長期的・潜在的リスクを予測の中心に据えることが、日本のように犯罪低頻度な状況で犯罪予測を行うにあたって重要であるという考えから、本研究の手法は構築されている。

近接反復被害からなる短期的・顕在的リスクについても、これを利用した予測手法は存在し、また、PROVEのように長期的・潜在的リスクと組み合わせた手法も存在していた。これについて、本研究では、長期的・潜在的リスクの値を短期的・顕在的リスクで重み付けするという方法を考案した。これは、RTMと近接反復被害の關係を見た既存研究（Caplan et al., 2013）の知見に則っており、かつ犯罪低頻度な状況に即して考えたものである。これによって、短期的・顕在的リスクを重視しすぎることなく、長期的・潜在的リスクと組み合わせることに成功している。

このように、本研究で構築した手法は、これまでと全く異なる発想から生まれたものではなく、むしろ既存の犯罪学理論、地理的犯罪分析研究、地理的犯罪予測研究で得られた知見を活用し、組み合わせたものとなっている。手法構築は、上述のように犯罪低頻度な状況に即した検討に基づいており、5～7章の分析結果から、日本における予測でも一定の有効性が示されている。また、構築された手法は、基礎となる方法論として考えることができる。本研究でも罪種ごとに具体的な予測モデルを作成したように、基本的な考え方を共有しつつ、同じ手法の中から異なるモデルを生み出すことができる。このように、既存の知見や手法に立脚しつつ、犯罪低頻度下でも有効な予測手法の枠組みを提示できたことが、本研究の成果といえる。

なお、車上狙い・部品狙いでは、予測変数としての駐車場等の要因を、犯罪生成・誘引要因といった犯罪学理論上の概念を援用しながら設定しつつも、過去の犯罪実績からの残差や、近接反復被害傾向をデータ分析によって抽出して、モデルに取り入れたものである。これは、理論からの発想と、データ駆動型の発想を組み合わせた予測手法といえる。このような予測手法に一定の有効性が認められたことは、犯罪学の理論に基づいた演繹的な予測と、機械学習などによる帰納的な予測とを融合させることの重要性を示唆するものとも考えられる。帰納的な方法の利点として、理論からの予想の枠外にあるような、事前に想定することが難しい要因が検出されるということがあろう。分析に際して利用可能なデータが日々増えていることもあり、機械学習を用いたデータ駆動型の予測は、今後も増加すると考えられる。

ただし、このような予測の方法に偏重することは、必ずしも望ましくない。2章4節6項で見たような予測手法は、機械学習に依拠したものだったが、用いる変数の数が100を超えるなどして多くなりがちであり、事前に犯罪の要因を考え、変数を吟味するといった工程を最初から省略することが、ままある。さらに、個別の予測モデルのパフォーマンスのみに焦点が当てられることが多く、どのような要因が予測に寄与していたか、すなわち、何が犯罪を

引き起こすのかという議論が行われることは稀である。また、そのような議論を行うとしても、大量の予測変数を吟味せずに投入すると、検出された要因の効果が、疑相関か真の効果かを判断することが難しく、やはり犯罪の原因の究明が困難となる。このような研究によって生み出されたモデルも、日々のパトロールなどで警戒すべき場所を絞る目的では有用だが、後述するような、環境を改善し犯罪の根本的な解決を図るための活動には役立たない。

本研究では、犯罪学理論を援用し、犯罪可能要因のような、環境に対する介入によって変更できるものに着目したが、こうした犯罪のリスクファクターを検討した上で、予測にどの程度寄与するかを確かめ、問題解決に活かすことが望ましい。また、残差のような、一見して内実のわからないものであっても、5章5節で見たように、それがどのような要因に規定されているのかを探るべきである。こうした試みによって、理論駆動型の演繹的な予測と、データ駆動型の帰納的な予測を融合させ、有用なものとするができるだろう。

最後に、罪種ごとに作成した予測モデルと、これに基づいて行った分析の意義について述べる。まず、車上狙い・部品狙いや、路上等の公共空間で発生する痴漢といった犯罪は、諸外国でも比較的高頻度に発生するものである。一方で、この2つの犯罪に焦点を当てた要因分析や予測研究を行った事例は、国内外でも豊富とはいえず、知見の蓄積が乏しい。本研究で、これらの犯罪のリスク要因を検討し、ある程度有効な予測モデルを作成できたことは、犯罪対策への知見の活用も期待できるものであり、学術・実務の両者に対する貢献といえるだろう。

また、7章冒頭でも述べたように、特殊詐欺は、多くの犯罪が減少しているわが国において、増加傾向を示す数少ない犯罪である。還付金等詐欺は、そのような特殊詐欺の一つとして、やはり政策上の優先度が高く、危急の対策が望まれる犯罪である。日本における地理的犯罪予測手法を検討した本研究においては、わが国の治安政策上の重大事である還付金等詐欺を扱い、これに対する予測モデルを作成できたことは、大きな成果として挙げられる。さらにまた、7章7節でふれたように、特殊詐欺に類する詐欺の被害は、諸外国でも多く発生している。本研究のような発想に基づき、詐欺のような犯罪でもATMのような、犯罪の機会を提供する場所に注目することで、詐欺のような、犯行者と被害対象が空間的に接触しない犯罪でも、地理的犯罪予測の俎上にのせることができる。本研究は、知能犯罪への予測適用の端緒を開いたものとして、諸外国での犯罪予測・犯罪対策にも貢献しうるものであり、新規性の高い成果といえる。

8.2 研究の課題と展望

8.2.1 研究課題

ここでは、本研究の課題、また、地理的犯罪予測研究と予測をめぐる実務への展望について述べる。

まず、本研究で行った検討は、対象となった地域が限定的であったことが課題として挙げられる。もっとも、対象となった福岡市は、中心業務地区、繁華街、郊外部、山間部を含み、日本の一般的な都市形態から逸脱したものではない。また、犯罪発生水準も東京23区と同水準である(3章参照)など、対象地域として不適切とはいえない。しかしながら、わが国の問題である人口減少を考えた場合、福岡市のように人口が増大している都市だけではなく、減少傾向にある都市を対象にしたケーススタディなども求められるだろう。さらに、たとえば日本国内の市区町村について、人口規模と犯罪発生水準それぞれの多寡を見つつ、人口規模が多いながら犯罪発生が少ない都市、人口規模が少ないながら犯罪発生が多い都市など、多様な都市に対して、既存手法、および本研究で提案された手法などを適用し、予測性能を検

証するような研究を行うことで、より一般化可能な知見を得ることができるだろう。

また、本研究であつかった予測精度の指標も、課題が指摘できる。特に、わが国での検証において問題となるのが、犯罪の頻度が低すぎる場合に、的中率や PAI の数値のインフレーションが起こりやすいことである。たとえば、日ごとの予測などを行う場合、諸外国では1日に複数件発生する犯罪でも、日本では1件発生するかどうか、ということがありうる。1件しか発生しない犯罪を的中させると、的中率は100%となるが、これが全部で20件発生しているケースでは、1件の的中は5%の的中率にしかならない。このような問題は、海外でも頻度の少ない罪種を対象とする、犯罪発生水準の低い地域を対象とする、予測の時間単位を日単位などと短くする、といったことで顕在化しうる。しかしながら、本研究で対象にした福岡県の都市は、日本国内で見ても、犯罪発生水準が低いわけではなく、また、車上狙い・部品狙いなどは、諸外国ではありふれた犯罪（common crime）であつた。それでもこうした問題が見られたことから、日本のような犯罪低頻度な状況下では、予測精度の指標を見る際にも、注意を要するといえよう。また、その解釈においては、たとえば的中率の10%の向上が、実務上どのような意味をもたらすのかについても、慎重に考える必要があるだろう。一方で、犯罪低頻度下にふさわしい予測性能の新たな評価方法を探ることも求められる。これには、複数期間・複数地域の異なる分母で的中率を算出するとき、期待値（たとえば、期間全体の犯罪発生数の平均をとるなど）で調整したスコアを算出するなどして、全体と比較して極端に小さい分母の値をもつ場合でも、極端な値が出ないように処理してから比較するといった方法が考えられる。

8.2.2 今後の展望

次に、研究の展望について述べる。まず、本研究で提案した予測手法を拡張する際の方向性として、地域の犯罪発生状況の変化を即応的に取込み、予測を更新するようなモデルのあり方が考えられる。これは、特に短期的・顕在的リスクについて、5～7章で議論した際に問題として挙げたように、予測を行っているまさにその時点における犯罪発生パターンの動向を、より正確に反映するための方策である。ありうるケースとしては、予測に基づいてパトロールを行った結果、ある地域で犯罪発生水準が下がる、また窃盗団などの犯罪集団が地域に入りこんだ結果、犯罪発生水準が急激に上昇するといったことが考えられる。これらの関連情報をリアルタイムに予測に反映させることができれば、より高精度な予測が実現するだろう。ただし、このような予測手法を実装するためには、データ処理過程を自動化することが必須である。たとえば、PROVEでは、特定のリスク要因について、センサデータを取得する仕組みが自動化されている。本研究では、長期的・潜在的リスクの分析や短期的・顕在的リスクの分析を個別に実行していたが、絞り込んだリスク要因について、関連するデータソースからデータを収集する過程、過去の犯罪データをもとに短期的・顕在的リスクを算出する過程、現地の情報を迅速に収集して反映させる過程、さらにこれらを統合する過程を一貫通貫で処理するシステムを構築しなければ、運用に堪えない。また、情報の収集にあたっては、警察組織の中で犯罪予防を主に担当する生活安全部門だけでなく、捜査部門、さらに地域の自治会や商店会などとも連携してゆく必要があるだろう。こうした柔軟な予測の方法は、世界的にも例がなく、挑戦的な課題となる。

また、予測モデル作成時に重要となるリスク要因の設定に際して、実務家（警察本部の担当者だけでなく、交番に勤務する警察官）、あるいは当該地域の状況をよく知る事業所や住民などから知見を得ることで、より現地の状況に即した予測を行うことも可能だろう。本研究で扱った車上狙い・部品狙いや、還付金等詐欺などは、既存研究の乏しさから、事前に要因を設定する際に困難を伴ったが、実務家や、地域の状況に精通した者の知見は、既存の知識を

補完するものとなりうる。ただし、特定の地域の状況に過剰に適合したモデルは、汎用性に乏しいことから、本研究のように手法としての枠組みを事前に定めた上で、複数の異なる地域でヒアリングを行い、得られた知見をもとに地域ごとの具体的な予測モデルを作成し、予測性能を検証するなどの研究を実施し、その有用性を検討することが望ましい。

一方で、地理的犯罪予測研究そのものにも、拡張の余地がある。本研究で提案した手法では、短期的・顕在的リスクについて、既存研究で扱われた季節変動や天候要因、曜日や平日・祝日の別による効果といった時間的要素が考慮されていない。ただし、これらを地理的な予測に活用する場合には、時間的要素が、対象領域全体の犯罪発生水準に関わるだけでなく、特定の空間に選択的に作用し、リスク分布に地理的な変動をもたらす（たとえば、ある曜日では局所的に特定の犯罪が増える）ことが、特に日本において確かめられていなければならない。こうした基礎的研究の不足を埋めるとともに、時間的要素が地理的犯罪予測にどの程度寄与するかを検討してゆく必要がある。また、この時間的要素についての検討は、次に「どこで」犯罪が発生するかだけでなく、次に「いつ」発生するかを予測するという、地理的犯罪予測がこれまで直接扱ってこなかった手法への道を開くことにもなる。こうした検討のためには、犯罪発生情報や、犯罪生成・誘引要因、社会経済的要因などの変数とあわせて、曜日、天候、大規模イベントなどの有無を示すダミー変数を設定し、レベル2に個別の場所を、レベル1に当該場所の日付ごとのデータを対応させたマルチレベルモデルなどから、時間変動する変数の効果を見るような分析が必要となるだろう。こうした分析には、過去にさかのぼって詳細な情報を収集することも求められるが、様々なデータの利用可能性が向上していることから、こうした研究に取り組むことは可能と思われる。

最後に、地理的犯罪予測を用いた予測型警察活動の犯罪抑止効果について確かめた研究は、これまで米国のシュリーブポート (Hunt et al., 2014)、ニューヨーク (Levine et al., 2017)、フィラデルフィア (Ratcliffe, 2017)、ロサンゼルス (Mohler et al., 2016) と英国ケント (Mohler et al., 2016) といった一部の地域に限定されている。また、その抑止効果があったことを結論づけているものは、Mohler et al. (2016) のみである。地理的犯罪予測のシステムは導入に多くのコストを伴い、また、警察実務の運用にも大きく影響を及ぼすものである。わが国でこれを導入するにあたっては、同様の実験によって、コストに見合った効果があるかどうかを検討することが求められる。また、日本で予測型警察活動の実験を行う場合には、諸外国と同様、警察機関と大学・研究機関の犯罪研究者が、協同で研究を行うことが望ましい。さらに、こうした実験を一つの都道府県で行う場合、理想的には、複数の市区町村（個々の市区町村がブロックであり、犯罪発生水準や人口規模にバリエーションをもたせる）から、複数の対象地域を無作為に抽出し、ブロックごとに実験群と統制群を、やはり無作為に割り付けながら、同一時期に対照実験ができるとよい。さらにまた、日本の防犯資源として特徴的な地域の防犯団体なども、パトロール等の主体に加えることで、欧米諸国とは異なる犯罪抑止効果を検出することも期待できるかもしれない。

8.3 実務への適用にむけて

締めくくりとして、本研究の成果を実際にわが国の犯罪予防活動に活用する際に、どのような運用がありうるかについて述べる。予測型警察活動の運用について Perry et al. (2013) らは次のような例を示している。

- 一般的介入 (Generic Intervention) : 増大するリスクに対応してより多くのリソースを割り当てる。ホットスポットに対しては、より多くの警察官を割り当てることになる。

「ホットな人々」に対しては、保護観察官が接触する機会を増やすことになる。

- 犯罪特化型介入 (Crime-specific Intervention) : 予期された罪種に対処すべく仕立てられたリソースを割り当てる。リソースと介入は、所与のホットスポット、もしくは加害を行うリスクの高い特定の人に集中することになる。
- 問題特化型介入 (Problem-specific Intervention) : 犯罪リスクを生み出す場所、人々、個人特有の問題を同定し、それを修正する。この段階には、特定の犯罪を捜査し、解決するような手段も定義上含まれる。

これらの例にしたがって、日本での運用を考える。まず、包括型介入は、典型的な予測型警察活動といえ、警察主体でのパトロールに予測結果を用いることが考えられる。この場合には、長期的・潜在的リスクと短期的・顕在的リスクを組み合わせた提案手法による予測地図に基づいて警戒すべきエリアを定め、優先的に巡回する。この予測地図は、短期的・顕在的リスクにしたがって、日ごとに警戒すべきエリアが変化する。6章で見たように、痴漢などの性的被害に関連するものは、潜在的な被害者である若年者や、女性の行動パターンが時間帯により異なるため、一日の中で予測地図をさらに数種類出力することになる。ここでは、警察署単位での車両による巡回と、交番単位で行われる自転車を用いた巡回を組み合わせ、各エリアを警戒することになるだろう。

ただし、警察による巡回は一日中行われているわけではないため、警戒されていない時間が必ず存在する。こうした時間帯には、地域の自主防犯団体などにも協力を仰ぎ、警察活動を補うこともできるだろう。実際に、地理的犯罪予測を導入した京都府警では、地域住民(京都新聞 WEB 版, 2017)や大学生(京都新聞 WEB 版, 2017)の防犯ボランティア団体に予測結果を共有し、巡回を依頼するなどの試みを行っている。警察資源以外の防犯資源を組み合わせることで、警戒すべき時間帯・エリアを網羅的にカバーすることができる。なお、交番や防犯ボランティア等、地域に根差した防犯資源が豊富であることは、わが国において特徴的な点であり(Steinhoff, 1993)、詳細な空間単位での犯罪予防活動を充実させるのに役立つものと考えられる。

このように、高リスクな地域を時空間的に網羅して警戒できることは、特に空間的な犯罪の転移 (spatial displacement of crime : Reppetto, 1976) に対処することにもつながる。空間的な転移では、ある場所への犯罪対策の結果、その場所の周辺、あるいは対策が行われていない離れた別の場所などで、新たに犯罪が発生するようになることが想定されるⁱ。ただし、Clarke and Eck (2003) は、容易に犯罪を行える機会、脆弱な被害者、行動統制の低い施設などはいくつかの場所に集中しており、既にそのような場所がホットスポットになっているため、(ひとたび対策がとられると) 犯行者が他の場所に移るのは難しいと述べている。ここから、そうした犯罪者が選好しやすい場所を長期的・潜在的リスクに関する分析などにより網羅的に特定、警戒することができれば、空間的な転移の懸念をなくすことができよう。また、

i なお、犯罪学においては空間的な犯罪の転移と対照的な現象として、「利益の拡散」

(diffusion of benefit : Clarke and Weisburd, 1994) の存在が指摘されている。利益の拡散は、犯罪対策がなされた結果、当該の場所だけでなく、その周辺の場所でも犯罪が減少するという、対策のスピルオーバー効果を意味する。犯罪ホットスポットへの集中的警察活動の効果について、複数の実験の系統的レビューとメタ分析を行った Braga et al. (2019) では、犯罪の転移と利益の拡散を測定している 40 の事例のうち、利益の拡散を上回る犯罪の転移の効果がわずかでも見られたものは、11 事例に留まっていた。この研究では、ホットスポットへの集中的介入による効果は、小さいが統計的に有意なレベルで、おおむね利益の拡散をもたらすと結論づけている。

Brantingham and Brantingham (2003) は、空間的転移は特に、犯罪誘引要因があるホットスポットから起こる可能性が高いとしている。RTMなどでこうした要因が集中する場所を特定できれば、同様に転移を防ぐことにつながる。

犯罪特化型介入は、包括型介入の延長線上にあるものと解釈できる。犯罪特化型介入では、その罪種に特有の傾向に着目して問題解決を図る。Perry et al. (2013) では、チュラピスタ（カリフォルニア州）の強盗に対する対策を例として挙げている。これによると、コンビニの中でもセブン-イレブン、ガソリンスタンド、酒店が特に狙われており、中でもセブン-イレブンは、12店舗中8店舗が5回以上の被害に遭っていた（45ヵ月間）という。現地警察では、このように犯罪の種類に基づいて、好まれやすいターゲットを絞り込み、介入対象としている。

本研究では、還付金等詐欺でも、地理的犯罪予測の一定の有効性を示すことができたが、ここでは、ATMが設置されている建築物の種別（銀行、コンビニエンスストア、病院等）から、特に誘導が多く発生しているスーパーマーケット、もしくはドラッグストアを選び、さらにその中で、ATMがおかれた環境や地区環境から、特に高リスクな店舗を絞り込んだ。このように、罪種特有の傾向に着目しつつ、介入する対象を絞り込むことで、効果的な予測型警察活動が可能だろう。

最後に、問題特化型介入は、より根本的な問題解決を目指すものと解釈できる。それは、パトロールのような見回りによる警戒だけでなく、環境を改善することで犯罪の原因をとり除くことを意味する。特に、本研究の検討では、過去の犯罪発生だけに基づくよりも、環境の情報に着目する方が、よく犯罪を予測することが一貫して確かめられている。犯罪が低頻度なわが国において、環境にはたらきかける対策が、犯罪問題の削減にいっそう有効である可能性は高い。

ここでもやはり、長期的・潜在的リスクに着目し、これが高く予測された地域と、同定されたリスク要因に目を向けるべきであろう。2章でも紹介したラトガース大学公共安全センターが提案する ACTION (Assessment of the risk narrative, Connections, Task management, Intervention planning/implementation, Outcome evaluation, Notifying others) のような枠組みは、そのモデルとなりうるものである。Kennedy et al. (2018) によると、ACTION では、RTM による統計的な分析と同時に、警察、および地域のステークホルダー（住民組織、商店会、店舗のオーナー、自治体関係者等）が把握するリスクに関する「語り」(risk narrative) を重視する。すなわち、RTM によってどこが高リスク地域で、何が犯罪生成・誘引要因（どんな施設）かがわかった後には、その地域の住民代表者や、施設の管理者のみが把握する情報を共有し、各要因がどのように問題と関連しているのかを知り、タスクフォースを組織して、ともに介入の方法を考え、実行する。アトランティックシティ（ニュージャージー州）における事例では、銃犯罪に対応するため、警察とコミュニティのステークホルダーが、月例ミーティングを開催している。また、RTM ではコンビニエンスストア、コインランドリー、空き物件がリスク要因として特定された。大部分の銃犯罪が薬物と関連していることから、コンビニエンスストアは、薬物のバイヤーが誘い込まれること、コインランドリーは薬物取引の場になっていること、空き物件は隠れ家になっていること、などを考え、サインイン・シートをコンビニやコインランドリーに置いて警察が訪問した証を残す、施設の所有者に防犯カメラ設置を補助する、問題のある空き物件に関する情報を条例執行機関と共有する等の対策をとっている (The Philadelphia Inquirer, 2017)。

このように、単なるパトロールに留まらない、高リスクな地域や場所に対するきめ細やかな対応は、日本でも有効と考えられる。車上狙い・部品狙いでは、高リスクが予測された地域にある駐車場やコンビニエンスストアに、防犯カメラの設置を促すことができるだろう。痴漢では、特に0時以降の深夜帯に、娯楽施設や飲食店といった高リスクな施設の所有者や

店舗責任者にはたらきかけ、女性客の早めの帰宅やタクシー利用を促すといった対応をとるよう協力依頼することもできる。還付金等詐欺では、高リスクな店舗の責任者や、ATMと隣接するクリーニング店の店員に、携帯電話をかけながらATMに入ってゆく高齢者に注意を払うよう依頼することもできる。長期的・潜在的リスクに着目した犯罪予防活動は、このように多様な手段、警察だけにとどまらない主体間の連携を要求する。それだけに、犯罪の抑止には最も効果的にはたらくと考えられる。特に日本では、「防犯まちづくり」という名称で、環境的な介入によって防犯を行う試みが普及しており、多くの自治体が「防犯まちづくり条例」、あるいは「安全・安心まちづくり条例」などを定め、官・民・地域が一体となって犯罪予防にのぞむ素地が整っている。防犯まちづくりは、社会との軋轢を生みにくく、低コストでありながら、即効性が見込まれる（雨宮，2016a）という特徴がある。予測に基づいてパトロールを強化するなどした場合、特定の高リスク地域の住民に過大な不安を与えることも懸念されるため、犯罪予測は、防犯まちづくりのような問題解決型の犯罪対策に利用することが望ましい。

以上のように、地理的犯罪予測によってもたらされる知見を活用することで、広範な犯罪予防活動が、従来よりも効率的に行うことができるとも考えられる。一方で、ここで紹介した活動は、問題指向型警察活動（problem-oriented policing）ⁱⁱ、コミュニティ警察活動（community policing）ⁱⁱⁱ、サードパーティ型警察活動（third party policing）^{iv}といった、米英の犯罪予防分野で以前から注目されていたものと強く関連している。地理的犯罪予測は、あくまでその実践に示唆を与える、または効率的な運用を可能にするものであり、本質的な変化をもたらすものではなく、予測型警察活動も、従来のセオリーに基づく犯罪予防活動と連続的なものとみなすことができる。

最後に、こうした地理的犯罪予測、および予測に基づいた警察活動の実践には、統計処理に関する知識を備えた人材、特に犯罪データの分析に長けた者の存在が必要となると考えられる。雨宮（2016b）は、犯罪分析に基づく警察活動が、日本の一般実務で受け入れられているとは言いがたいとして、そのために、諸外国のように大学で高度な分析リテラシーをもつ

ii 問題指向型警察活動（Goldstein, 1979）では、「手段の目的化」を否定し、犯罪事象に駆り立てられる「標準的な警察活動モデル」から、犯罪の根本にある潜在的な問題を特定するために、先制的に働きかけるモデルへの転換を目指す。さらに、警察には、犯罪だけでなく社会的・物理的な秩序違反を含むコミュニティにおける問題に目を向けることを要求するものである。問題指向型警察活動は、さらにSARA（Scanning, Analysis, Response, Assessment）モデルという枠組みの中で、問題の洗い出し、問題の要因分析、対策の立案・実行、対策の評価といったプロセスを踏むことで、効果的な警察活動を実現する。米国アリゾナ州立大学のPOP Center（Center for Problem-Oriented Policing）のウェブサイト（<https://popcenter.asu.edu/pop-guides>）では、具体的な対策の例が紹介されている。

iii コミュニティ警察活動は、1970年代以降の米国において、地域住民と警察とが信頼関係を構築し、両者が協働して地域の問題を解決することで生活の質を向上させ、犯罪と犯罪不安の削減を目指したものである（島田，2016）。コミュニティ活動では、地域の会合や巡回連絡、情報発信といった普段からの警察と市民との直接的な接触を重視すること、警察が地方自治体、住民リーダー、町内会や自治会等の地縁団体、防犯ボランティア団体、民間企業といった他主体と協働すること、犯罪の捜査や取り締まりよりも犯罪の遠因になる地域の問題解決に注力すること、地区ごとに警察官を割り当て権限も委譲する分散型の形態をとること、などの点で従来型警察活動と異なっている（島田，2016）。

iv サードパーティ型警察活動（Buerger and Mazerolle, 1998）は、警察と警察以外のサードパーティ（政府の規制当局、監察官、住宅当局、ライセンス当局、商業オーナー等）との関係づくりから、サードパーティの資源と法的権力を利用しつつ、犯罪や秩序違反の問題を統制、または防ぐよう、警察の能力を拡張するものである（Mazerolle et al., 2016）。

た人材を育成することなどが、望ましいとしている。また、現在実施されている福岡県警の犯罪予防アドバイザー制度や、大阪府警の防犯対策高度化研究会などは、数年単位で特定の課題を警察とアカデミアが共有し、実務と研究の両面から犯罪対策にあたるもので、犯罪予防における官学連携の代表的な例である。このように、警察実務に研究者が入り込み、ともに考えて取り組みを進めることが、今後の地理的犯罪予測、およびこれを活用した予測型警察活動をわが国で普及させてゆく上で、肝要となるだろう。さらに、関連する流れとして、わが国でも犯罪発生情報の統一形式でのオープンデータ化が、全国の都道府県で進められている。米国のシカゴでは、犯罪データがオープンになったことで、米国内外の研究者が、地理的犯罪予測研究にシカゴデータを活用し、研究が発展してきた状況がある。わが国で公開される犯罪データは、小地域単位のものではあるが、すべての都道府県に及ぶため、シカゴの規模を超えるものといえ、国内のデータを用いた予測研究の進展が、大いに期待できるところである。このような社会的状況も、実務家と研究者が連携するにあたり好ましい流れである。犯罪予測に社会的にも注目が集まる中、好機を逃さず、しかし犯罪問題の解決に寄与するような研究を、着実に積み重ねてゆくことが求められる。

8章の参考文献

- 1) 雨宮護 (2016a) 防犯まちづくり. 『犯罪心理学辞典』(日本犯罪心理学会編), 丸善出版, 593pp.
- 2) 雨宮護 (2016b) 犯罪分析と警察活動. 『犯罪心理学辞典』(日本犯罪心理学会編), 丸善出版, 587pp.
- 3) 雨宮護・島田貴仁・中谷友樹・樋野公宏・高橋あい (2018) 子供・女性に対する脅威事案は性犯罪等のリスクを高めるか? : 子供・女性の性犯罪等における先行指標の検討. 「都市計画報告集」, **17**, 216-222.
- 4) 京都新聞 WEB 版 (2017) 犯罪予測コース、走って警戒 京都、学生らジョグパト <<http://www.kyoto-np.co.jp/local/article/20170401000070>>, 2018年6月1日閲覧.
- 5) 京都新聞 WEB 版 (2017) 犯罪予測で被害防げ! 防犯マップ基に住民らパト 京都・向日 <<https://www.shinmai.co.jp/news/nagano/20181220/KT181219ATI090035000.php>>, 2018年6月1日閲覧.
- 6) 島田貴仁 (2016) コミュニティと犯罪予防. 『犯罪心理学辞典』(日本犯罪心理学会編), 丸善出版, 567-568pp.
- 7) Braga, A., Turchan, B., Papachristos, A., and Hureau, D. (2019) Hot spot policing and crime reduction: an update of an ongoing systematic review and meta-analysis. *Journal of Experimental Criminology*, **15**, 289-311.
- 8) Buerger, M., and Mazerolle, L. (1998) Third-party policing: A theoretical analysis of an emerging trend. *Justice Quarterly*, **15**(2), 301-328.
- 9) Clarke, R., and Eck, J. (2003) *Become a Problem Solving Crime Analyst in 55 Small Steps*. London: Jill Dando Institute, University College London, 92pp.
- 10) Clarke, R., and Weisburd, D. (1994) Diffusion of crime control benefits: Observations on the reverse of displacement. *Crime prevention studies*, **2**, 165-184.
- 11) Goldstein, H. (1979) Improving policing: A problem-oriented approach. *Crime & delinquency*, **25**(2), 236-258.
- 12) Hunt, P., Saunders, J., and Hollywood, J. (2014) *Evaluation of the shreveport predictive policing experiment.*, Rockville: NCJRS Photocopy Services.
- 13) Kennedy, L., Caplan, J., and Piza, E. (2018) *Risk-based policing: Evidence-based crime prevention with big data and spatial analytics.*, Oakland: University of California Press., 36-43pp.
- 14) Levine, E., Tisch, J., Tasso, A., and Joy, M. (2017) The New York City police department's domain awareness system. *Interfaces*, **47**(1), 70-84.
- 15) Mazerolle, L., Eggins, E., and Higginson, A. (2016) Protocol: Third Party Policing for Reducing Crime and Disorder: A Systematic Review. <https://campbellcollaboration.org/media/k2/attachments/0271_CJCG_Mazerolle_Protocol.pdf>, 2019年10月19日閲覧.
- 16) Mazerolle, L., and Ransley, J. (2004) Third party policing: prospects, challenges and implications for regulators. Regulation: Enforcement and Compliance, *Research and Public Policy Series*, **57**, 61-76.
- 17) Mohler, G., Short, M., Malinowski, S., Johnson, M., Tita, G., Bertozzi, A., and Brantingham, P. (2015) Randomized controlled field trials of predictive policing. *Journal of the American Statistical Association*, **110**(512), 1399-1411.
- 18) 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., 14pp.

- 19) Perry, W., McInnis, B., Price, C., Smith, S., and Hollywood, J., Ibid., 62-64pp.
- 20) Ratcliffe, J., Taylor, R., Askey, A., Grasso, J. and Fisher, R. (2017) The Philadelphia Predictive Policing Experiment: Impacts of police cars assigned to high crime grids. <https://docs.wixstatic.com/ugd/f5df24_ef630904ce0d4a3c8f913ea17c4bad90.pdf>, 2019 年 10 月 18 日閱覽.
- 21) Reppetto, T. (1976) Crime prevention and the displacement phenomenon. *Crime and Delinquency*, **22**(2), 166-177.
- 22) Steinhoff, P. (1993) Pursuing the Japanese police. *Law and Society Review*, **27**, 827-850.
- 23) The Philadelphia Inquirer (2017) Can Atlantic City's bold experiment take racial bias out of predictive policing? <https://www.inquirer.com/philly/news/crime/atlantic-city-risk-terrain-modeling-rutgers-predictive-policing-joel-caplan-20170810.html?photo_3>, 2019 年 10 月 18 日閱覽.

初出一覧

本研究に関連する論文の初出は、以下の通りである。

- 公表済み論文
 - 1) 大山智也・雨宮護 (2019)「ATMにおける還付金等詐欺の発生予測—ATMの設置環境と犯罪の反復性に着目して—」,『都市計画論文集』, **54**(3), 780-787.
 - 2) Tomoya Ohyama and Mamoru Amemiya (2018) “Applying Crime Prediction Techniques to Japan: A Comparison Between Risk Terrain Modeling and Other Methods.” *European Journal on Criminal Policy and Research*, **24**(4), 469-487.
 - 3) 大山智也・雨宮護・島田貴仁・中谷友樹 (2017)「地理的犯罪予測研究の潮流」,『GIS-理論と応用』, **25**(1), pp. 33-43.
- 公表予定論文 (採録決定済み)
 - 1) 大山智也・雨宮護「短期的・長期的リスクを組み合わせた犯罪予測手法の構築—長期的リスク概念の拡張と短期的リスクの導入方法に関する検討—」,『GIS-理論と応用』, (Vol. 28, No.1, 2020 採録予定)
- 査読のない口頭発表 (学位請求論文と関連あり)
 - 1) Tomoya Ohyama and Mamoru Amemiya (2019) “Crime Prediction of Street Harassment.” Poster Session, American Society of Criminology Annual meeting 2019”, San Francisco, CA, November 2019.
 - 2) 大山智也・雨宮護 (2019)「短期的・長期的リスクを考慮した脅威事案の発生予測手法」, 日本犯罪心理学会第 57 回大会, 日本女子大学目白キャンパス, 2019 年 8 月.
 - 3) Tomoya Ohyama and Mamoru Amemiya (2018) “Crime Prediction of Imposter Scams: An Analysis on Environmental Settings of Unmanned ATMs.” Regular Session, American Society of Criminology Annual meeting 2018, Atlanta, GA, November 2018.
 - 4) 大山智也・雨宮護 (2018)「特殊詐欺被害と ATM のおかれた物理的・社会的環境との関連性」, 第 27 回地理情報システム学会研究発表大会, 首都大学東京, 2018 年 10 月. (梗概:『地理情報システム学会講演論文集』, **27**, CD-ROM)
 - 5) 大山智也・雨宮護 (2018)「環境要因と犯罪発生情報を組み合わせた犯罪予測手法の検討」, 第 27 回地理情報システム学会研究発表大会企画セッション「学生フリーテーマ発表会」, 首都大学東京, 2018 年 10 月.
 - 6) Tomoya Ohyama and Mamoru Amemiya (2017) “Applying Crime Prediction Techniques to Japan: Comparison between Risk Terrain Modeling and other methods.” Poster Session, American Society of Criminology Annual Meeting 2017, Philadelphia, PA, November 2017.
 - 7) 大山智也・雨宮護 (2017)「地理的犯罪予測の手法間比較—日本型犯罪予測手法の構築にむけた検討—」, 第 26 回地理情報システム学会研究発表大会, 宮城大学, 2017 年 10 月. (梗概:『地理情報システム学会講演論文集』, **26**, CD-ROM)

謝辞

本論文の執筆，ならびに研究を進めるにあたって，多くの方のご指導，ご支援を賜りました。

まず，雨宮護先生との出会いと，これまでのご指導，ご支援に感謝を申し上げます。そもそも，私が筑波大学への進学を決めたのは，雨宮先生がいらっしゃる事が最大の理由でした。雨宮先生との出会いがなければ，まだ企業勤めを続けていたかもしれません。幸運にも，雨宮先生が研究室をお持ちになった最初の年に修士過程に入学し5年の間，ご指導を賜りました。それからは研究外でも，ティーチング・アシスタントの業務，自治体の方との共同プロジェクト，地域住民の方とのワークショップなど，さまざまな経験をさせていただき，これまで知ることのなかった世界を見せていただきました。研究においては，通常入手が難しい犯罪データの共有，国内外での発表の機会の提供等，考えつく限りのご支援を賜りました。言うまでもなく，この研究を行うことができたのは，ひとえに雨宮先生のご尽力あってのものです。また，ご多忙な業務の中でも，学生を第一に考え，研究に必要な設備への投資を惜しまず，研究の道筋をつけることに腐心されるご様子や，学生が気軽に相談することができるよう，毎日欠かさず学生室を訪れるお姿に指導者としての理想像を見ておりました。また，研究にとどまらず，短期雇用という形で業務の補助をさせていただき，生活の支援までしていただきました。5年間もの間，研究生活を無事に送ることができたのは，雨宮先生のおかげであり，感謝しきれない思いです。

また，雨宮先生と同じように，私の研究生活を支援して下さった方々に感謝申し上げます。科学警察研究所犯罪予防研究室の島田貴仁室長には，研究補助員として雇用していただきながら，業務の度に研究相談にのっていただき，数多のご助言を賜りました。研究を大きく進展させることができました。研究にとどまらず，生活相談にもものっていただき研究所での雇用を継続し，研究生活が送れるよう，多大なご支援をいただきました。さらにまた，研究所の内外で多くの方にお引き合わせいただき，世界が大きく広がりました。島田先生との議論は，常に刺激的で知的に楽しいひとときを過ごすことができ，大きな経験となりました。常々，研究者としてのあるべき姿を説かれるとともに，ご自身の業務にとどまらず，各方面との関係調整や，研究補助員の学生の指導などに心を砕かれるご様子を見るにつけ，研究者としての自負と，器量の大きさに感銘を受けておりました。本研究を遂行するにあたって必要だった着想の多くは，島田先生より直接的・間接的にいただいたものです。これまでのご指導，ご支援に心よりの御礼を申し上げます。なお，同犯罪予防研究室の齊藤知範先生，山根由子先生にも，業務を通じて大変お世話になり，事あるごとにご助言を賜りました。ありがとうございました。

同じ研究室で藤本典志氏に出会えたことも，私にとって大きな幸運でした。ご自身が経営される警備会社にインターンとして雇っていただき，大きな生活の支えとなりました。大阪での社長業の傍ら研究を行い，ご自身の忙しさを言い訳にせず，仕事と研究を両立させんとする姿勢には，一度勤め人を経験した身としても，素直に畏敬の念をおぼえます。生活の支援をしていただきながら，会うたびにご馳走になり，人生相談にのってくださる藤本さんには，頭が上がりません。また，日本パナユーズ株式会社の皆様にも，この場を借りて御礼を申し上げます。

研究にあたっては，筑波大学の先生方にも，もちろん多くのご指導を賜りました。鈴木勉先生には，アドバイザー・グループ教員として，また，論文の副査として，修士課程の頃よりご指導いただきました。特別演習の場だけでなく，学内研究会や学会でも，有益なご指摘・

ご助言をいただきました。都市の治安をめぐる「最適な」状態とは何か？という問いは、今でも反芻しています。大澤義明先生には、アドバイザー・グループ教員として、やはり修士課程の頃よりご助言と激励を賜りながら、自治体の調査案件などで雇用していただき、生活のご支援も賜りました。また、いくつものチャンスをいただくことになりました。糸井川栄一先生には、博士論文の副査に入っただき、防災・防犯分野のエキスパートとして、鋭いご指摘をいただきました。堤盛人先生は、修論最終発表時、また博論の副査として、何度も激励のお言葉をいただき、研究を評価していただきました。それだけでなく、常に私の研究を拡張するような示唆に富んだご意見を、幾度となく賜りました。このように直接ご指導いただいた先生方に、あらためて感謝を申し上げます。

社会工学専攻に所属する他の先生方として、藤川昌樹先生には修士課程に進学する前の社会人向け説明会で丁寧な説明をいただき、大学院進学後は事あるごとに激励のお言葉をいただきました。渡邊真一郎先生には、講義や実習を通じてご指導いただいただけでなく、様々な事柄について議論させていただきました。

また、科学警察研究所の原田豊先生には、学会の場で犯罪学の第一人者としての見地から、有益なご指摘の数々をいただきました。原田先生には、まだ大学生だった時分、東京大学の社会学特殊講義で初めてお話を聞かせていただきましたが、これが私の犯罪機会論・環境犯罪学とのファーストコンタクトとなりました。あの講座が開かれなかったら、今日私がこの道を志すことはなかったと思います。東北大学の中谷友樹先生には、学会投稿論文の共著を引き受けていただき、国外の研究動向に関する多くの知見と、各種の地理的犯罪予測手法に関する深い洞察、そして論文執筆に関する丁寧なご指導を賜りました。また、博士研究では副査を引き受けていただき、再び多くのご指導を賜ることとなりました。手法に関する記述についての詳細なものから、細かな表現方法に関するものまで、具にご指摘いただき、私の拙い原稿の質を高めていただきました。厚く御礼申し上げます。日本大学の羽生和紀先生には、環境心理学研究会の場で、示唆に富んだご意見をいただき、研究に関する多くのヒントをいただくとともに、激励を賜りました。東京大学の高木大資先生には、大学時代の先輩として、島田先生とのご縁で再開を果たし、研究会などで議論させていただきました。統計物理学者の梶田真美さんには、国内の犯罪予測研究者として、ご自身の先駆的研究をご紹介いただき、また活発な議論をさせていただきました。

他にも、学会・研究会などを通じて出会った先生方より、研究に関する多くのご助言や激励をいただきました。「都市のOR」研究会では、慶応義塾大学の栗田治先生、田中健一先生、防衛大学の鶴飼孝盛先生、立正大学の小林隆史先生、中央大学の鳥海重喜先生、山梨大学の宮川雅至先生、東京海洋大学の渡部大輔先生からは、常に有益なご示唆とポジティブなコメントをいただき、大いに励まされました。また、飲み会の席ではざっくばらんに話をさせていただき、新参者の私に大変良くしていただきました。東京大学の金杉洋先生にお声がけいただいて参加したヒューマンプロブ研究会では、東京電機大学の岩井将行先生、人間環境大学の薄井智貴先生、東京高専の水戸慎一郎先生、仙台高専の小林秀幸先生と有意義な議論をさせていただきました。日本環境心理学会では、畑倫子先生に研究に関する多くのご助言を賜り、またさまざまな先生方を紹介いただきました。日本犯罪心理学会では、法務省の門本泉さん、谷真如さんに気にかけていただき、また、多くの議論ができました。国土技術政策総合研究所の石井儀光先生には、大澤義明先生のプロジェクトを通じてお世話になっただけでなく、研究についても学会等で多くのご助言を頂戴しました。東京大学の相尚寿先生は、同大学空間情報科学研究センターの共同研究プロジェクト(JoRAS)の受け入れ教員となっただき、そのご縁で学会等でも意見交換をさせていただき、研究に関する鋭いご指摘をいただきました。仙台大学の田中智仁先生は、藤本典志氏より紹介いただき、雑誌「青少年間

題」での原稿執筆の機会をいただきました。東京大学の樋野公宏先生には、筑波大学院での講義で受講生・TAの立場で関与させていただき、防犯まちづくりの実践の現場を体験させていただきました。フィラデルフィア市警の菊池城治先生には、アメリカ犯罪学会の折に同士の巡視に連れて行っていただき、研究に関するポジティブなコメントをいただきました。ラトガース大学のLeslie Kennedy先生、Joel Caplan先生、アーカンソー大学のGrant Drawve先生、ボローニャ大学のMarco Dugato先生には、アメリカ犯罪学会でお声がけいただき、国際誌投稿のチャンスをいただきました。カリフォルニア州立大学の藤田周良先生、国際基督教大学の金澤雄一郎先生には、同じくアメリカ犯罪学会でお声がけいただき、度々激励をいただきました。他にも、ここに書ききれないほど多くの先生方とコミュニケーションをとらせていただき、研究活動の糧とすることができました。ご指導、誠にありがとうございました。

研究室の学生メンバーの皆さんにも、研究生活を大いにサポートしてもらいました。同じく博士課程の讚井知さんはじめ、皆さんとは、ゼミを通じて良質な議論ができました。また、研究室行事を盛り上げてもらったり、話相手になってもらったことで、研究一辺倒にならず、メリハリのきいた生活を送ることができました。

研究室外でも、大学院生活の中で先輩方からもご助力をいただきました。株式会社DeNAの長谷川大輔さん(元・鈴木勉研)、東京大学の巖先鏞先生、釧路高専の松林道雄先生らとは、元勤め人の経験を持つ同士として、日常的な雑談、人生相談から研究に関する議論まで濃いコミュニケーションをとり、大学院生活を充実したものとすることができました。国立環境研究所の吉田崇紘先生には、空間統計や研究全般に関する知識やご助言をいくつもいただきました。筑波大学の仲村健さん、黒田翔さん、一橋大学経済研究所の辻本隆宏さんには、社会工学オーラルヒストリーを通じて、色々な議論をさせていただきました。

さらに、社会工学専攻事務室の皆様には、度々ご迷惑をおかけしたにもかかわらず、いつも温かく迎えていただき、様々なサポートをしていただきました。

また、公益財団法人中川育英会(中川ヒューム管工業株式会社)には、2年もの間、多額の奨学金をいただき、生活を支えていただきました。深く感謝申し上げます。

なお、研究遂行にあたって、多くの団体から研究助成をうけました。公益財団法人社会安全研究財団、株式会社エディテージ、日本学術振興会に御礼を申し上げます。

犯罪に関するデータは、雨宮先生を通じて、福岡県警「犯罪予防研究アドバイザー」の枠組みのもとで提供していただきました。このデータなくして、本研究を完遂することは不可能でした。御礼申し上げます。

大叔父・大叔母の上野寛治・直子両氏には、大学院進学にあたり、経済的援助をいただき、また背中を押していただきました。この場を借りて、心より御礼を申し上げます。

最後に、30歳を超えていまだ実家にパラサイトし続ける息子をひたすら支えてくれた母文代に、最大の感謝を述べたいと思います。本当にありがとうございました。

このように、本論文は、多くの方々のご支援の賜物であり、そのいずれが欠けても、研究を完成させることはできませんでした。本論文は、研究の道を志してからの5年間の集大成でもあり、また、今後の研究生生活の通過点として、さらなる学究の道に連なる一歩でもあります。本研究は、社会の中で実装されることで、はじめてその価値を発揮するものであり、その成果を具体的な形で還元すべく、励んで参る所存です。皆様のご恩に報いるべく、一層精力的に研究に取り組んでゆきたいと思います。

2020年3月
大山智也

付録

異罪種間の時空間的近接性の検証（第6章）

表 6-5, 表 6-6 と同様に, 100 m・7 日以内ごとの先行事象（声かけ・つきまとい・卑わい言動）—痴漢イベントのペア数, および 100 m・7 日以内ごとの先行事象—痴漢イベントの Knox 比を示す.

声かけ（上段がペア数, 下段が Knox 比, 以下同様）

	≦7日	≦14日	≦21日	≦28日	≦35日	≦42日	≦49日	≦56日
≦100m	0	0	0	0	1	1	1	1
≦200m	1	3	5	5	9	10	10	12
≦300m	2	8	13	18	23	29	30	32
≦400m	6	14	23	29	35	41	45	48
≦500m	12	22	33	40	48	56	60	66
≦600m	14	24	39	48	58	68	75	84
≦700m	14	28	47	57	71	83	91	102
≦800m	17	34	57	69	85	105	117	130
≦900m	18	38	64	80	101	126	145	163
≦1000m	24	46	78	96	119	150	171	194
≦1100m	31	60	94	113	139	177	204	231
≦1200m	33	65	101	125	156	202	237	265
≦1300m	38	72	109	136	172	220	259	287
≦1400m	44	82	123	157	195	247	293	328
≦1500m	53	93	137	177	222	278	332	374

	≦7日	≦14日	≦21日	≦28日	≦35日	≦42日	≦49日	≦56日
≦100m	0.00	0.00	0.00	0.00	0.39	0.33	0.28	0.25
≦200m	0.58	0.97	1.08	0.86	1.20	1.11	0.95	1.02
≦300m	0.52	1.19	1.28	1.39	1.38	1.45	1.29	1.24
≦400m	0.95	1.25	1.36	1.34	1.26	1.23	1.16	1.11
≦500m	1.26	1.31	1.29	1.23	1.15	1.12	1.02	1.01
≦600m	1.07	1.04	1.11	1.07	1.01	0.99	0.93	0.94
≦700m	0.82	0.93	1.03	0.98	0.95	0.93	0.87	0.88
≦800m	0.78	0.89	0.98	0.93	0.90	0.93	0.88	0.88
≦900m	0.67	0.81	0.91	0.89	0.87	0.91	0.89	0.90
≦1000m	0.76	0.83	0.93	0.90	0.87	0.92	0.89	0.91
≦1100m	0.84	0.93	0.97	0.91	0.87	0.93	0.92	0.93
≦1200m	0.77	0.87	0.90	0.87	0.85	0.92	0.92	0.92
≦1300m	0.80	0.86	0.86	0.84	0.83	0.89	0.90	0.89
≦1400m	0.82	0.87	0.87	0.87	0.84	0.89	0.90	0.91
≦1500m	0.88	0.89	0.86	0.88	0.86	0.90	0.92	0.92

つきまとい

	≦7日	≦14日	≦21日	≦28日	≦35日	≦42日	≦49日	≦56日
≦0m	1	1	1	2	2	2	2	3
≦100m	1	1	1	3	3	4	5	6
≦200m	1	4	7	14	14	17	18	21
≦300m	2	6	12	20	20	25	27	32
≦400m	7	15	23	35	36	44	48	58
≦500m	9	18	31	47	50	60	71	85
≦600m	10	26	42	67	70	85	99	118
≦700m	13	33	54	85	89	105	122	142
≦800m	18	43	69	106	118	138	159	187
≦900m	22	53	85	127	141	168	194	228
≦1000m	30	66	103	149	170	202	235	273
≦1100m	39	82	123	174	201	234	272	315
≦1200m	46	94	139	192	224	264	306	351
≦1300m	56	113	163	226	266	311	358	407
≦1400m	65	125	181	251	300	348	402	458
≦1500m	72	139	201	275	329	384	442	506

	≦7日	≦14日	≦21日	≦28日	≦35日	≦42日	≦49日	≦56日
≦100m	1.21	0.64	0.43	0.98	0.81	0.91	0.99	1.03
≦200m	0.40	0.85	1.00	1.48	1.23	1.28	1.17	1.20
≦300m	0.39	0.62	0.84	1.03	0.86	0.92	0.86	0.89
≦400m	0.80	0.92	0.95	1.07	0.92	0.96	0.90	0.95
≦500m	0.72	0.78	0.91	1.02	0.90	0.93	0.94	0.99
≦600m	0.60	0.84	0.91	1.07	0.94	0.97	0.97	1.02
≦700m	0.61	0.83	0.91	1.06	0.92	0.94	0.93	0.95
≦800m	0.66	0.85	0.91	1.03	0.96	0.96	0.96	0.98
≦900m	0.67	0.87	0.92	1.02	0.95	0.97	0.96	0.99
≦1000m	0.77	0.91	0.94	1.01	0.96	0.98	0.98	0.99
≦1100m	0.85	0.96	0.96	1.00	0.97	0.97	0.97	0.98
≦1200m	0.87	0.96	0.94	0.96	0.94	0.95	0.94	0.95
≦1300m	0.93	1.01	0.97	0.99	0.98	0.98	0.97	0.96
≦1400m	0.97	1.00	0.96	0.98	0.98	0.98	0.97	0.97
≦1500m	0.96	0.99	0.96	0.96	0.96	0.96	0.96	0.96

卑わい言動

	≦7日	≦14日	≦21日	≦28日	≦35日	≦42日	≦49日	≦56日
≦100m	1	1	2	3	3	4	4	5
≦200m	2	5	6	7	10	12	13	14
≦300m	4	10	13	14	17	19	22	23
≦400m	5	12	16	17	21	24	29	33
≦500m	9	18	23	25	32	38	44	50
≦600m	13	24	30	34	43	49	55	63
≦700m	15	28	34	43	57	64	71	81
≦800m	16	31	38	49	64	72	81	94
≦900m	19	36	47	61	79	92	106	123
≦1000m	21	39	54	69	88	102	117	139
≦1100m	21	43	64	81	103	120	136	162
≦1200m	23	47	71	90	115	132	153	182
≦1300m	25	55	85	106	134	154	176	208
≦1400m	28	63	96	120	154	175	198	230
≦1500m	32	69	103	132	168	193	219	255

	≦7日	≦14日	≦21日	≦28日	≦35日	≦42日	≦49日	≦56日
≦100m	1.21	0.65	0.87	0.97	0.73	0.82	0.73	0.80
≦200m	1.08	1.44	1.13	0.98	1.05	1.08	1.03	0.97
≦300m	1.18	1.57	1.36	1.09	1.00	0.95	0.98	0.89
≦400m	1.01	1.29	1.15	0.92	0.86	0.83	0.89	0.88
≦500m	1.28	1.37	1.17	0.95	0.92	0.93	0.95	0.94
≦600m	1.42	1.41	1.18	1.00	0.96	0.93	0.92	0.92
≦700m	1.27	1.27	1.04	0.98	0.98	0.94	0.92	0.92
≦800m	1.06	1.11	0.91	0.88	0.87	0.83	0.83	0.84
≦900m	1.04	1.06	0.93	0.90	0.89	0.88	0.90	0.90
≦1000m	0.97	0.96	0.90	0.85	0.83	0.82	0.83	0.86
≦1100m	0.85	0.93	0.93	0.88	0.85	0.84	0.85	0.88
≦1200m	0.83	0.91	0.93	0.88	0.85	0.83	0.86	0.89
≦1300m	0.82	0.97	1.01	0.94	0.90	0.88	0.89	0.92
≦1400m	0.83	1.00	1.02	0.95	0.93	0.90	0.90	0.91
≦1500m	0.85	0.98	0.98	0.94	0.91	0.89	0.90	0.91

日本における地理的犯罪予測手法の開発に関する研究
2020年2月18日 第1刷発行

作者 大山智也