

# 街路景観画像解析を用いた犯罪発生リスクの解析

足立 浩基\*・中谷 友樹\*\*

## Analyzing Crime Occurrence Risks Using Streetscape Image Processing

Hiroki M. ADACHI\* and Tomoki NAKAYA\*\*

The relationship between geographic environments and risks of crime occurrence has been actively studied in various societies including Japan. In recent years, the availability of large-scale images of streetscapes and the development of image analysis techniques based on deep learning have made it possible to obtain environmental indicators based on streetscapes. In this study, we analyze the risk of crime occurrence of theft from vehicles in the central part of Kyoto City, Japan from January 2015 to December 2018 using local environmental indices made from streetscape images and road network data using binomial logistic regression, and discuss the results with the aid of theories of crime opportunities at the place level.

**Keywords:** 犯罪 (crime), 車上ねらい (theft from vehicles), 街路景観 (streetscape), 街路ネットワーク指標 (street network indicators)

### 1. はじめに

都市の中には、犯罪の大半が発生する局所的な空間が存在し得る。こうした空間は、犯罪のホットスポットと呼ばれており、ホットスポットでの犯罪防止の有効性は多くの先行研究で認められている (Braga et al., 2019)。ホットスポットの形成を説明する理論は数多いが、その中の一つとして、犯行者やターゲットが頻繁に交差し、犯罪機会が生まれやすい場所である犯罪生成源 (Crime generator) や犯罪の動機や意志を持つ犯行者が惹きつけられる場所である犯罪誘引源 (Crime attractor) などが知られている (Brantingham and Brantingham, 1995; Clarke and Eck, 2005)。局所的な犯罪機会の条件を説明する日常活動理論に基づいた犯罪防止活動も効果を上げている。

ホットスポットの存在が確認されてから、場所に基づく犯罪予防や犯罪学は高い関心を集めるようになった。Sherman et al. (1989) は「場所」を「肉眼で、一度にその全体 (少なくとも表面的な部分であ

っても) を見る事が可能な特定の物的な環境」と定義した。このような街路景観スケールで定義される場所の犯罪発生リスク評価は、犯罪研究において重要な研究課題の一つである。

場所に基づく犯罪学研究は、かつては使用できる場所スケールの情報を得ることが困難であることから限定的であった。しかし、近年は様々な事象・事物に関する位置情報を含めた詳細な情報がデータ化され、さらに深層学習などのデータ解析技術の発展と相まって、詳細な場所の情報が利用可能になりつつある。実際、これら新しいデータである街路景観画像と深層学習のような新しい技術を用いた場所スケールの研究が登場しはじめている (Andresen et al., 2021; Kang and Kang, 2017; Hipp et al., 2021)。しかし、これらは主に欧米の都市を分析対象としており、日本を対象とした研究は管見の限りみられない。日本は欧米と比べて犯罪発生件数が少なく、また地理的環境や社会的状況も異なっている。そのため、日本

\* 学生会員 東北大学大学院環境科学研究科 (Graduate School of Environmental Studies, Tohoku University) 〒980-8572 宮城県仙台市青葉区荒巻字青葉 468-1 E-mail : [adachi.hiroki.p2@dc.tohoku.ac.jp](mailto:adachi.hiroki.p2@dc.tohoku.ac.jp)

\*\* 正会員 東北大学大学院環境科学研究科 (Graduate School of Environmental Studies, Tohoku University)

における場所（街路景観）スケールでの犯罪発生リスク評価は、日本での状況を踏まえてその有効性及課題を確認していく必要がある。

そこで本研究では、京都市の中心市街部で発生した車上ねらいを対象に、街路景観指標に加えて、街路中心性や POI (Point of interest) を用いた犯罪発生リスクを評価し、その結果を議論する。

## 2. 方法

### 2.1. 犯罪発生データ

分析対象エリアは、京都市の中心市街地に位置する上京警察署、中京警察署、下京警察署の管轄区を統合したエリアとした。犯罪発生データは京都府警察によって 2015 年 1 月 1 日から 2018 年 12 月 31 日までに認知・記録された車上ねらい 500 件のうち、街路沿いで発生した 286 件を用いる。街路沿いとみなす条件は、発生場所が国土地理院の基盤地図情報から取得した建築物ポリゴンの外、かつ街路からの距離が 20m 以内とした。

### 2.2. 街路ネットワークデータ

街路ネットワークデータは、ESRI ジャパンが販売する「ArcGIS Geo Suite 道路網 2021」を用いる。街路ネットワークデータは交差点ノードと街路セグメントからなるよう加工し、ラインデータ上に 10m 間隔のポイントデータ（以下、街路上ポイント）を生成する。

街路ネットワークの指標として、Urban Network Analysis (UNA) で計算されるネットワーク中心性から、周辺ノードの多さを表す Reach、媒介中心性を表す Betweenness、周辺ノードとの直線性を表す Straightness、周辺ノードまでの近さを表す Closeness を用いる。なお、Betweenness, Straightness, Closeness は標準化されたものを利用する。中心性のバッファ半径は、比較的狭い範囲として 100m（およそ徒歩 1 分圏内）と比較的広い範囲として 400m（およそ徒歩 5 分圏内）を計算する。中心性はノード（交差点）ごとに計算し、街路セグメントの中心性は両端のノードの算術平均値とする。



図 1. 道路ネットワーク指標の例 (Straightness(400m))

例として、図 1 にバッファ半径が 400m の場合の Straightness (以下、Straightness(400m)と表記) を示す。これは、あるノード（交差点）の周囲 400m 内に含まれる他のノードへの直線距離と経路距離の比の平均で定義される。1 に近いほど、他のノードへの経路が直線的であることを表す。また、街路総延長と街路幅員 (3-5.5m, 5.5-13m, 13m 以上) も用いる。

### 2.3. 街路景観データ

街路景観画像は、Google が提供する Street View Static API から 640×640 pixels の街路景観画像を一つのポイントに対して街路と水平方向（前後）2 枚を取得する。また、街路景観画像を取得したポイントは最寄りの街路上ポイントから 10m 以内であることとする。

街路景観の指標として、画像を占める各物体の割合を用いる。これは、画像のピクセルごとに物体の種類を推論する深層学習の技術の一つである Semantic Segmentation を利用して、画像の全ピクセルを占める各物体のピクセルとして計算する。Semantic Segmentation の手法には PSPNet(Zhao et al., 2017)を採用し、PSPNet の提案者による実装と 713×713 pixels の Cityscapes データセットで獲得された訓練済モデルによってピクセルごとに 19 クラス（道路、歩道、建物、壁、フェンス、柱、信号機、交通標識、植物、テライン（水平方向の植生、土や砂）、

空、人、運転者、車、トラック、バス、電車、バイク、自転車)を分類する(図2)。




図 2. Semantic Segmentation を用いた街路景観指標の例  
(この街路景観画像は著者が撮影したもの)

#### 2.4. Point of interest データ

POI として、交通施設(駅、バス停、駐車場、自転車駐輪場、ガソリンスタンド)、飲食施設(レストラン・ファーストフード)、日用施設(コンビニ、スーパーマーケット)、学校施設(保育園・幼稚園、小・中・高校、大学・短大・専門学校)、娯楽施設(スナック・パブ・クラブ、パチンコ)、その他(公園・緑地、墓地)の位置情報を経路探索 Web サービスである NAVITIME から取得する。

POI の指標は、街路上ポイントから 100m 以内に存在するか否かを表すフラグ(0:存在しない, 1:存在する)とする。

#### 2.5. データ解析

目的変数は、車上ねらいの発生場所の最寄りの街路上ポイント 286 件を正例、その他の街路上ポイントから正例と同数をランダムサンプルした 286 件を負例とし、街路景観指標、街路ネットワーク指標、POI 指標による犯罪発生リスクを二項ロジスティック回帰分析でモデリングする。ここで、街路環境は各環境から複合的に形成されるものと考えられるため、街路景観指標同士の積、街路景観指標と街路ネットワーク指標の積による交互作用項を考慮する。事前処理として、主効果項と交互作用項の多重共線性を緩和するために、街路景観指標と街路ネットワ

ーク指標は中心化する。また、分散拡大要因(Variance inflation factor: VIF)が 10 以上の変数が含まれないよう変数を選択する。モデルに含める変数は、AIC 基準のステップワイズ法によって選択する。

### 3. 結果

表 1 に二項ロジスティック回帰の推定結果を示す。推定された係数から、POI 指標の中ではコンビニ、スーパーマーケット、ガソリンスタンドの付近で車上ねらいの発生リスクが増加することが示された。また、街路景観指標と街路ネットワーク指標については、Closeness(100m):柱(以下、交互作用項は「変数名:変数名」と表記)、Closeness(100m):道路、Straightness(400m):壁、Betweenness(100m):テラインは車上ねらいの発生リスクを増加させ、歩道:テライン、植物:建物、Straightness(100m):壁は発生リスクを下げる効果が示唆された。なお、ROC 曲線(Receiver Operatorating Characteristic curve: ROC curve)の曲線下面積(Area Under the Curve: AUC)は 0.742 であった。また、VIF の最大値は 6.76、平均値は 2.36 であり多重共線性の影響は低いと判断した。

### 4. 考察

推定された係数が有意となった POI 指標は、それぞれが、車上ねらいの犯罪発生源や犯罪誘引源となり得ることを示唆する。特にコンビニやスーパーマーケットはターゲットとなる車とその周辺に駐車する機会をもたらす環境である。犯罪発生源で発生する犯罪は、犯行者があらかじめ犯行する明確な意思が持っていたとは限らず、その場で成立した犯罪機会に応じて犯行に及ぶ場合がある。一方、犯罪誘引源には、何らかの犯罪機会があり、あらかじめ犯行者が明確な意思を持って訪れる。防犯の観点で何らかの脆弱性を持っている可能性が考えられる。

表 1. 二項ロジスティック回帰分析の推定結果

	回帰係数	
歩道:テライン	-0.589	***
コンビニ(100m)	0.874	**
植物:建物	-0.004	**
Straightness(100m):歩道	-3.545	*
Closeness(100m):柱	383.155	*
植物	-0.075	*
スーパーマーケット(100m)	0.727	*
Closeness(100m):道路	19.369	*
ガソリンスタンド(100m)	1.100	*
銀行・ATM(100m)	-0.566	*
Straightness(100m):壁	-6.297	*
歩道:空	0.018	*
Straightness(400m):壁	4.725	*
Betweenness(100m):テライン	6.986	*
歩道:柱	-0.218	.
フェンス:建物	-0.017	.
フェンス:植物	-0.026	.
フェンス:柱	-0.283	.
Straightness(100m):テライン	9.508	.
フェンス:空	-0.027	.
歩道:植物	0.019	.
道路:建物	0.001	.
歩道	-0.116	.
レストラン・ファストフード(100m)	0.504	.
駅(100m)	-0.868	.
Betweenness(400m):歩道	1.456	.
道路	0.030	.
植物:空	-0.003	.
Straightness(100m)	-3.188	.
Betweenness(100m):柱	-4.577	.
Straightness(400m):テライン	-5.541	.
柱	0.292	.
Closeness(400m):フェンス	-93.781	.
Closeness(100m)	-90.078	.
Straightness(400m)	1.994	.
フェンス	-0.054	.
壁	0.055	.
Betweenness(100m)	0.433	.
空	0.004	.
Betweenness(400m)	0.375	.
Closeness(400m)	-16.750	.
テライン	-0.019	.
切片	-0.280	***
AUC	0.742	

注: \*\*\*: p 値<0.001, \*\*: p 値<0.01, \*: p 値<0.05, .: p 値<0.1. コロン (:) は交互作用を表す.

Closeness は逃走経路の多さとして解釈できる. Closeness(100m):柱, Closeness(100m):道路ではいずれも犯罪発生リスクが増加しており, 比較的狭い範囲での逃走経路の多さに加えて柱や道路の存在が逃げやすさ・隠れやすさを生み, 犯行リスクが増加する可能性が考えられる.

見通しの良さを表す Straightness については, Straightness(100m):壁と Straightness(400m):壁が有意な係数として推定された. この結果から, 壁の割合が多く監視性が低下していると考えられる環境における見通しの良さによる犯罪発生リスクの違いを検討できる. 比較的狭い範囲での見通しの良さは, 監視者の不在を十分に確認できず, 犯行者にとって目撃されやすいと考えられる. 一方, 比較的広い範囲での見通しの良さは, 監視者の不在を遠方まで確認でき, 犯行に及ぶ意思決定を促しやすいのではないかと考えられる. 石川ほか(2009)は, 大阪市で発生したひったくりと見通し距離の関係を研究し, ひったくりの発生密度は, 見通し距離 0-50m の場所で高く 50-100m で低くなるが, 150-250m の場所で再び高くなることを報告している. 本研究はこれに類似するが壁の多い状況によって見渡す方向が限定されていることで見通しの良さの効果が増幅されているものと解釈できる.

歩道:テラインや植物:建物は, いずれも犯罪発生リスクが減少する景観として推定された. 歩道が多くテラインも多い環境は, 周囲に目を遮る物が少なく, 監視性が高い状況と解釈できる. また, 植物:建物は比較的道路面積が多く緑豊かな環境であることから, 管理が行き届いた領域性の高い環境であり, 犯罪発生リスクを低減させていると推測される.

## 5. おわりに

本研究では, 深層学習技術を利用して街路景観画像を数量化することで, 街路景観に加えて街路中心性や Point of interest を利用した車上ねらいの発生リスクを評価できた. その結果, 欧米での先行研究と同様に日本の都市空間においても街路景観と犯罪発生との関連性が認められた. さらに場所(街路景観)

スケールで、犯罪発生に関連する環境の成立条件を検討すると、日常活動理論や状況的犯罪予防といった環境犯罪学の知見に基づいた解釈がしやすいことが分かった。

ただし、本研究の分析では街路景観を視覚的な占有率で単純に指標化したに過ぎず、景観内の物体の位置関係や奥行きといった街路景観の認知に関わるより詳細な景観画像解析の検討も必要だろう。明るさや音、あるいは雰囲気といった視覚以外の環境の指標化も課題である。さらに時間帯や季節による景観の変化も本研究では資料の制約により捨象しているなど、街路景観画像を用いた分析には、改良の余地が多く残されている。都市環境の3Dデータ化やデジタルツイン構築などと連携することで、さらなる犯罪発生リスク評価の精緻化も期待される。

## 参考文献

- Braga, A.A., Turchan, B.S., Papachristos, A.V. and Hureau, D.M. (2019) Hot spots policing and crime reduction: an update of an ongoing systematic review and meta-analysis. *Journal of Experimental Criminology*, **15**, 289-311.
- Brantingham, P. and Brantingham, P. (1995) Criminality of place: Crime generators and crime attractors. *European Journal on Criminal Policy and Research*, **3**, 5-26.
- Clarke, R.V. and Eck J.E. (2005) Crime Analysis for Problem Solvers in 60 Small Steps. *U.S. Department of Justice COPS*.
- Sherman L.W., Gartin, P.R. and Buerger, M.E. (1989) Hot spots of predatory crime: Routine activities and the criminology of place. *Criminology*, **27**(1), 27-56.
- Andresen M.A., Haberman C.P., Johnson, S.D. and Steenbeek, W. (2021) Advances in Place-Based Methods: Editors' Introduction. *Journal of Quantitative Criminology*, **37**, 327-331.
- Kang, H.W and Kang H.B. (2017) Prediction of crime occurrence from multimodal data using deep learning. *PLoS ONE*, **12**(4), e0176244.
- Hipp J.R., Lee, S., Ki, D. and Kim, J.H. (2021) Measuring

the Built Environment with Google Street View and Machine Learning: Consequences for Crime on Street Segments. *Journal of Quantitative Criminology*, <https://doi.org/10.1007/s10940-021-09506-9>.

Zhao, H., Shi, J., Qi, X., Wang, X. and Jia, J. (2017) Pyramid Scene Parsing Network. *2017 Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, <https://doi.org/10.1109/CVPR.2017.660>.

石川愛・鍋島美奈子・鈴木広隆 (2009) 詳細事件情報を考慮したひったくり発生と道路空間特性との関係に関する研究—大阪市住宅系地区を対象として—。日本建築学会環境系論文集, **74**(635), 55-61.