

市街地画像を用いた犯罪地域の特徴抽出

Learning representations of potential high-crime area using Google street view images

山下 雄大^{*1}
Yamashita Yuta

森 純一郎^{*1*2}
Mori Junichiro

^{*1} 東京大学大学院 工学系研究科
Graduate School of engineering, The University of Tokyo

^{*2} 東京大学 政策ビジョンセンター
The Policy Alternatives Research Institute

This paper show that image features of street improve the prediction of hotspots. Using Deep Learnig method, we extract features from images of Google Street View and apply them to the estimation of hotspots. We show that our method improve the prediction accuracy of hotspots compared with only using demographic data. This result suggests the possibility that we can approach crime deterrence from urban designs.

1. 背景及び目的

犯罪の抑止は生活の質や教育と深い関係を持ち、社会や経済の安定性を保障する上での重要な要因となることから、古くから多くの分野で犯罪に関する研究が行われてきた。公共のデータをオープンデータとして提供する動きが加速していることもあり、関連する情報の取得が容易となったため、より多くの研究がなされるようになった。特にデータマイニングの分野では、取得が容易となった公共データに加え、Twitter を始めとするソーシャルデータを用いた研究[Gerber 2014]や Taxi などの位置情報データを用いた研究[Wang 2016]など、より多様なデータを用いた解析が試みられている。

犯罪の発生を周囲の環境と紐付ける研究は主に環境犯罪学の分野で行われており、その代表的な研究として Broken Window 理論[Wilson 1982]が挙げられる。これらの研究は現実社会の問題解決に既に適用されており、2000-2002 年に北海道札幌方面中央警察が割れ窓理論を参考に治安対策を実施し、成果を上げたことなどが報告されている[中俣 2016]。

本研究では地域人口や性別比率などの公共データに加え、Google Street View から取得した各地点の環境情報を使用することで犯罪多発地域の推定を行い、環境情報が潜在的に持つ要素が犯罪発生を推定する上で重要な役割を果たすことを示す。また、本研究を進めることにより、犯罪発生に関わる要因を機械的に抽出することで、犯罪防止のための都市設計などを支援できるものとする。

2. 本研究の位置付け

これまでの研究において、財産や収入と犯罪率に関する研究[Patterson 1991]や携帯電話から得られる振る舞いと犯罪予測に関する研究[Bogomolov 2014]など、犯罪と様々な特徴量を関連付ける研究が行われてきた。これらの犯罪を扱う問題は分析対象によって“犯罪発生の時系列を扱う問題”・“犯罪発生地点の特徴を扱う問題”・“犯罪発生要因を個人やコミュニティから扱う問題”の3種類に分類することができる[Wang 2016]。このうち、“犯罪発生地点の特徴を扱う問題”の研究は最も多く行われており、その多くは hot spot と呼ばれる犯罪多発地点の推定を様々な特徴から試みるものであるが、犯罪発生地点の環

表 1. 使用データ詳細

対象年度	2010 - 2014年
使用カテゴリ	LARCENY/THEFT, ASSAULT, DRUG/NARCOTIC, VEHICLE THEFT, VANDALISM, BURGLARY, MISSING PERSON, ROBBERY
合計犯罪数	479,241件
犯罪地点数	33,409地点

境を画像から取得し、直接利用するような試みはほとんど存在しない。

画像から特徴量を抽出は、特徴量を自動で生成できる手法であるディープラーニングの発展により大きく進展した。Donahueらは学習済み CNN(Convolutional Neural Network)に画像を入力することによって得られる中間層出力を、画像を表す特徴量が多く画像タスクにおいて有用であることを示した[Donahue 2013]。

以上より、本研究では Google Street View で取得した画像をその地点における環境情報として扱い、ディープラーニングを用いて特徴量として利用し、犯罪発生率の高い地域を推定するタスクに適応する試みを行う。

3. 手法

犯罪のデータをはじめ都市に関する多くの情報をオープンデータとして提供しているサンフランシスコを対象に研究を行った。犯罪データを取得した SF OpenData^{*1}では 2003 年からの犯罪データが公開されており、発生内容によって 39 種類の犯罪カテゴリに分類されている。Google Street View から取得される画像の撮影年度と犯罪発生年度が大きく異なる状況を防ぐため、2010-2014 年に発生した犯罪を対象とし、犯罪カテゴリには“NON-CRIMINAL”などの非犯罪要素も含まれるため、表 1 に示す 8 カテゴリに絞ってデータの取得を行った。

犯罪発生地点を特徴づけるようなデータとしてデモグラフィックデータと犯罪地点の環境データを取得した。デモグラフィックデータは SF OpenData をはじめとしたサイトから、人種比率や地域における警察署の有無など計 15 種類の情報を取得した。また、各地点における環境データとして Google Street View から各地点 90 度毎の 4 方面の画像を上向き 10 度の角度で取得した。

表 2. 学習データ内訳

	Train	Test	合計
Label: 0	13,419	1,821	15,240
Label: 1	14,081	1,929	16,010
合計	27,500	3,750	31,250

表 3. 実験結果

	accuracy	precision	recall	f-value
baseline	0.653	0.665	0.637	0.651
baseline + img	0.678	0.658	0.699	0.678

画像の特徴量抽出は、Attention モデルを CNN に適応した研究[Zhou 2016]で作成された、場所推定タスク用のデータセットである Place205^{*2}での学習済みモデルを使用し、fine-tuningを行った後、出力層手前の中間層出力を各画像の特徴量として扱った。

4. 実験

実験に用いたデータセットの詳細情報と詳細手法、実験によって得られた結果について述べる。

4.1 データセット

取得したデータの各地点で犯罪数を集計したところ、中央値は 8 回であった。そのため、2010-2014 年の 5 年間の内に 8 回以上の犯罪があった地点を hotspot (label=1)とし、8 回未満の地点を非 hotspot (label=0)として正解データを作成した。(表 2)

4.2 手法

予測器には SVM を用いた。デモグラフィックデータのみでの推定と、CNN から生成した画像特徴量を合わせた推定それぞれにおいて、トレーニングデータを 5 分割したグリッドサーチを行い、accuracy が最大となる最適パラメータの探索を行った。

4.3 結果と考察

デモグラフィックデータのみを特徴量として使用した推定に対して、市街地の画像情報を加えることで、2%ほど精度が改善する様子が見られた。特に画像を加えることで recall が改善しており、非 hotspot を推定する精度が上がったことが確認できた。このことから、本手法によって抽出した環境データ特徴量は、犯罪が起きにくい要因を有している可能性があると考えられる。

以上より、市街地画像は各地点における犯罪を取り巻く環境情報として用いることができ、犯罪発生地点の特徴的要因を機会的に捉えることができる可能性が示された。

5. まとめ

本研究では、犯罪多発地点である hotspot を推定するタスクにおいて、Google Street View から取得した各地点の環境情報が有用であることを示した。従来から行われてきたデモグラフィックデータを用いた推定は、犯罪と様々な要因を紐付け、理解

する上で重要な研究である。しかしながら、人口比率など多くの要因は変化させることが困難であるため、研究成果を実社会で施策として運用するには非常に大きなコストを払う必要があった。一方で画像から得られる各地点の環境情報は、より小規模な要因を捉えている可能性があると考えられる。そのため、本研究が発展し、環境要因の特徴を自動で抽出できるようになれば、実際に運用可能な施策として提言することが可能になると期待する。

参考文献

- [Gerber 2014] Matthew S. Gerber: Predicting Crime Using Twitter and Kernel Density Estimation, Decision Support Systems 61, 2014.
- [Wang 2016] Hongjian Wang, Daniel Kifer, Corina Graif, Zhenhui Li: Crime Rate Inference with Big Data, KDD conference, 2016.
- [Wilson 1982] James Q. Wilson, George L. Kelling: Broken Windows: The police and neighborhood safety, The Atlantic Monthly 3: 29-37, 1982.
- [中俣 2016] 中俣 友子, 阿部 恒之: ゴミのポイ捨てに対する監視カメラ・先行ゴミ・景観・看板の効果, The Japanese Journal of Psychology 2016: Vol.87: No.3: 219-228, J-stage, 2016.
- [Patterson 1991] E, Britt Patterson: "POVERTY, INCOME INEQUALITY, AND COMMUNITY CRIME RATES", Criminology 29: 4: 755-776, 1991.
- [Bogomolov 2014] Andrey Bolomolov, Bruno Lepri, Jacopo Staiano, Nuria Oliver, Fabio Pianesi, Alex Pentland: Once Upon a Crime: Towards Crime Prediction from Demographics and Mobile Data, In Proceedings of the 16th international conference on multimodal interaction, ACM, 2016.
- [Donahue 2013] Jeff Donahue, Yangqing Jia, Oriol Vinyals, Judy Hoffman, Ning Zhang, Eric Tzeng, Trevor Darrell: DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition, CoRR: abs/1310.1531, 2013.
- [Zhou 2016] Bolei Zhou, Aditya Khosla, Agata Lapedriza, Aude Oliva, Antonio Torralba: Learning Deep Features for Discriminative Localization, Computer Vision and Pattern Recognition, 2016.

*1 SF OpenData : <https://data.sfgov.org>

*2 MIT place205 : <http://places.csail.mit.edu>