

要約

そのエリアで将来犯罪が発生するリスクを予測する研究は、欧米を中心に盛んであるが、犯罪発生件数が比較的小ないわが国においても、その機運が高まっている。一方、リスクを予測するだけではなく、それに寄与する要因を特定し、複数のアプローチから犯罪を防止することが大切である。そこで本研究では、機械学習を用い、さまざまな要素を考慮して犯罪発生リスクを予測する。また、その予測モデルに対して因果推論を行い、地域ごとに要因の抽出や比較を可能にする。

キーワード：犯罪予測、機械学習、オープンデータ、GIS

1 はじめに

過去の犯罪発生状況や、犯罪の発生に起因すると考えられるデータを用いて、そのエリアで将来犯罪が発生するリスクを予測する研究が、欧米を中心に進められている。これを「地理的犯罪予測」と呼ぶ[1]。

対照的に、わが国における地理的犯罪予測に関する研究は少なく、国内のデータを用いたものはさらに限られている。確かに、わが国は国際的にみても治安水準が高く、現時点で早急な対策が求められているとはいえない。しかし、少子高齢化の進行や単身世帯の増加などにより、長期的に見ると、わが国においても犯罪発生リスクの増加が危惧されている[2]。

また、犯罪を防止するためには、単に犯罪発生を予測するだけではなく、それに寄与している要因を特定することで、異なるアプローチから対策することも大切である。そこで本研究では、機械学習を用いて犯罪の発生を予測するとともに、その予測モデルに対して因果推論を行うことで、地域ごとに要因の特定や比較を可能にし、犯罪発生の防止を支援することを目的とする。

2 犯罪とリスク

2.1 地理的犯罪予測

地理的犯罪予測は、車上あらし、自動車や自転車などの盗難、空き巣など、犯罪を行いやすい時間や場所、状況を選んで行われるような罪種に対して行われる。その予測結果は、警察などに提供し、そのエリアに対して集中的にパトロールを行うなどといった判断を助けることを想定している。そのため、予測の範囲を、時間的には月や週、日や時単位、空間的には数十から数百メートルのグリッドセル単位としている研究が多い。

このような地理的犯罪予測に関する研究は、その手法によって、大きく4つに分類することができる[3]。

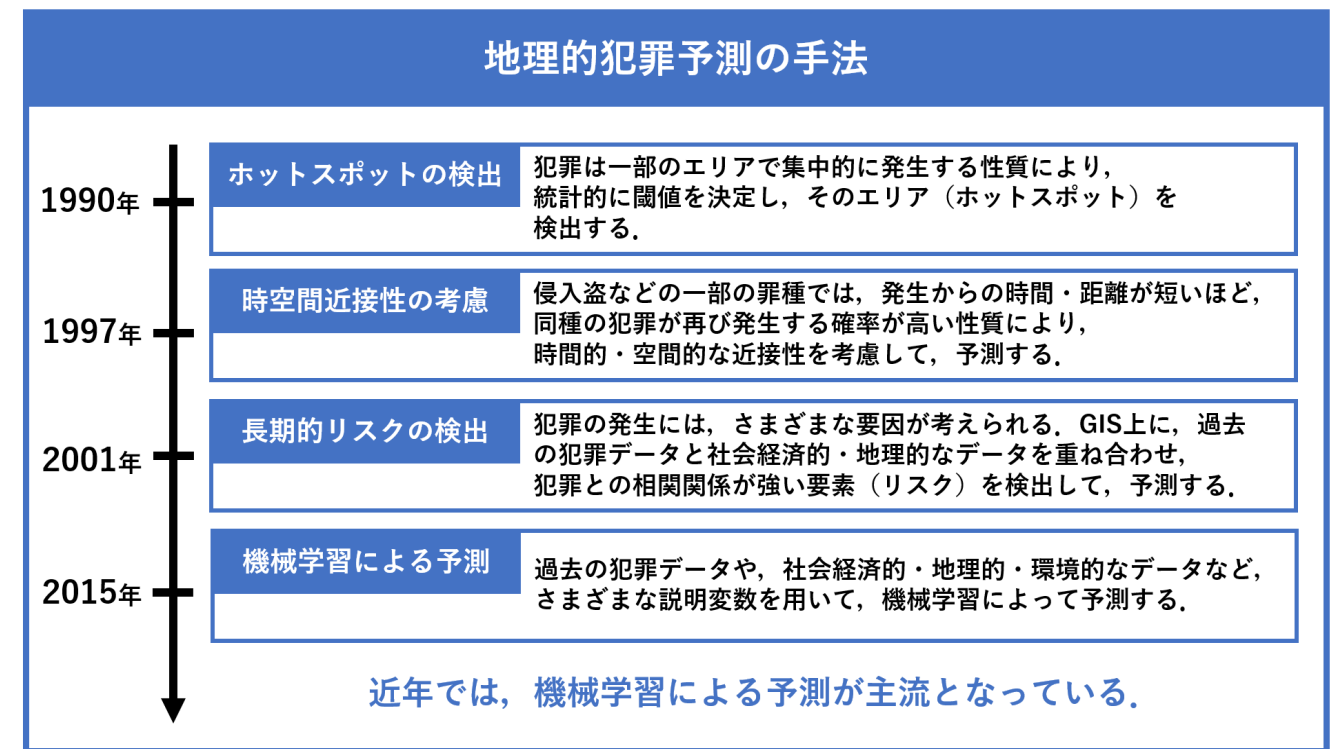


図1 地理的犯罪予測の手法

2.2 長期的リスクと短期的リスク

機械学習による地理的犯罪予測では、その説明変数として、過去に発生した犯罪のデータのほかに、犯罪発生の要因となり得るデータを用いる。それらは、「数年、あるいは数十年間固着しうる長期的リスク」と「むこう数日から数週間にかけて増大する短期的リスク」の2つに分類することができる[4]。以降、前者を「長期的リスク」、後者を「短期的リスク」と呼ぶ。

長期的リスクとして考えられるものに、「社会経済的要因」、「犯罪誘引要因」、「犯罪可能要因」が挙げられる。短期的リスクとして考えられるものに、「直近の犯罪」、「環境要因」が挙げられる。

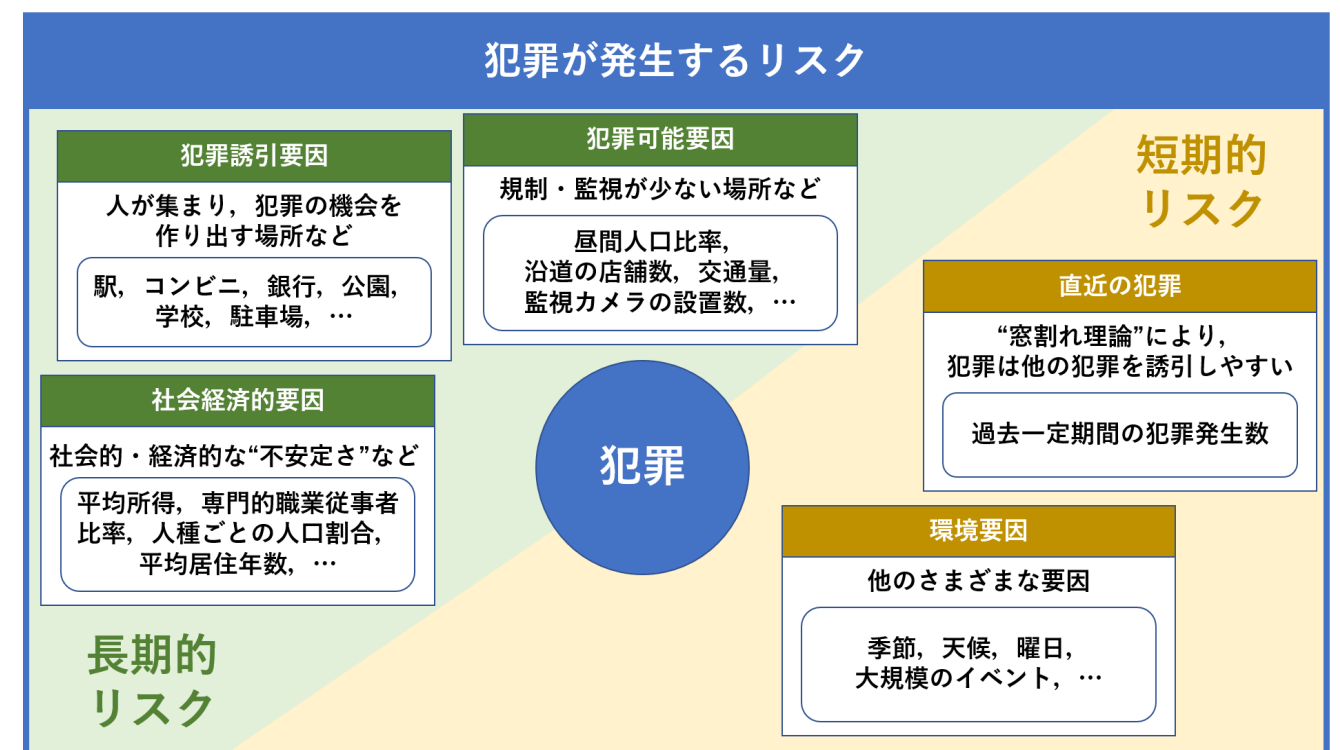


図2 犯罪が発生するリスク

2.3 わが国における潮流

わが国においては、欧米の諸外国のように早急な対策が求められているとはいえない。しかし、単身世帯の増加や、海外からの労働者の受け入れによる人種・民族の多様化など、将来的に犯罪発生リスクを増大させる要因が潜在している。また、少子高齢化・人口減少の進行により、警察官の「大量退職期」を迎えており、採用試験の受験者数も年々減少している。そのため、警備力そのものが弱まっていくことが危惧されている。

こうした背景により、わが国においても、地理的犯罪予測の導入に向けた取り組みが見られはじめている。2016年には京都府警が、米国で導入されている手法を参考に犯罪予測システムの運用を開始している。また、2018年には神奈川県警、長野県警が、同様のシステムの導入を検討している[3]。

— 3 機械学習による予測と要因分析 —

3.1 機械学習アルゴリズムの選定

機械学習は、ある変数とそれと関係がある変数との法則性を、人間の介入少なく推定する手法である。よって本来ならば必要となる、犯罪学、社会環境学などの専門的な知識や、数理モデルを考案・評価できる高度な数学的教養がなくとも、必要なデータさえあれば予測できる点で優れている。

犯罪が発生するかしないかの2値分類であること、正確性をより重視することから、非線形サポートベクターマシン、ランダムフォレスト、ニューラルネットワーク、勾配ブースティング決定木の4つを選定した。それぞれについて同様のデータで予測した結果、最も精度が大きかったニューラルネットワークを本研究では用いる（図3参照）。

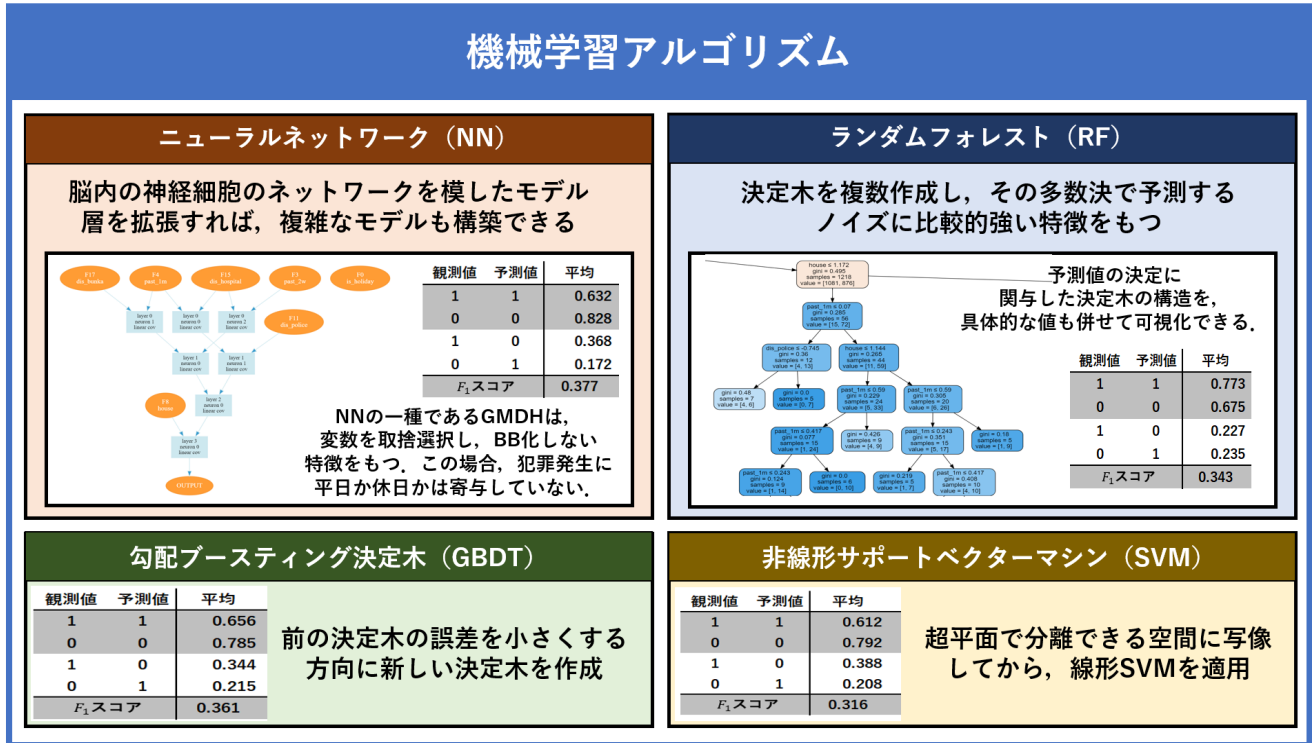


図3 機械学習アルゴリズム

3.2 地図画像に基づく特徴量の抽出

2.2節で述べた犯罪が発生するリスクのうち、犯罪誘引要因や犯罪可能要因は、地理的な特徴が大きく影響している。しかし、一般的な統計データは、そのエリアの代表値を掲載しているものが多く、詳細な情報を取得するには限界がある。そこで本研究では、より詳細な地理的特徴を取得するために、地図画像を利用する。

地図画像の生成には、Mapbox社が提供しているStatic Tile APIを利用する。あらかじめMapbox Studio上で、道路や駐車場、建造物などといった地理的情報を追加・編集することで、分析に利用しやすい形式で生成することができる（図4参照）。生成した地図画像は、ピクセル数による面積比の算出や、道路ネットワークの抽出などを行い、犯罪発生の要因となり得る特徴量を抽出する。

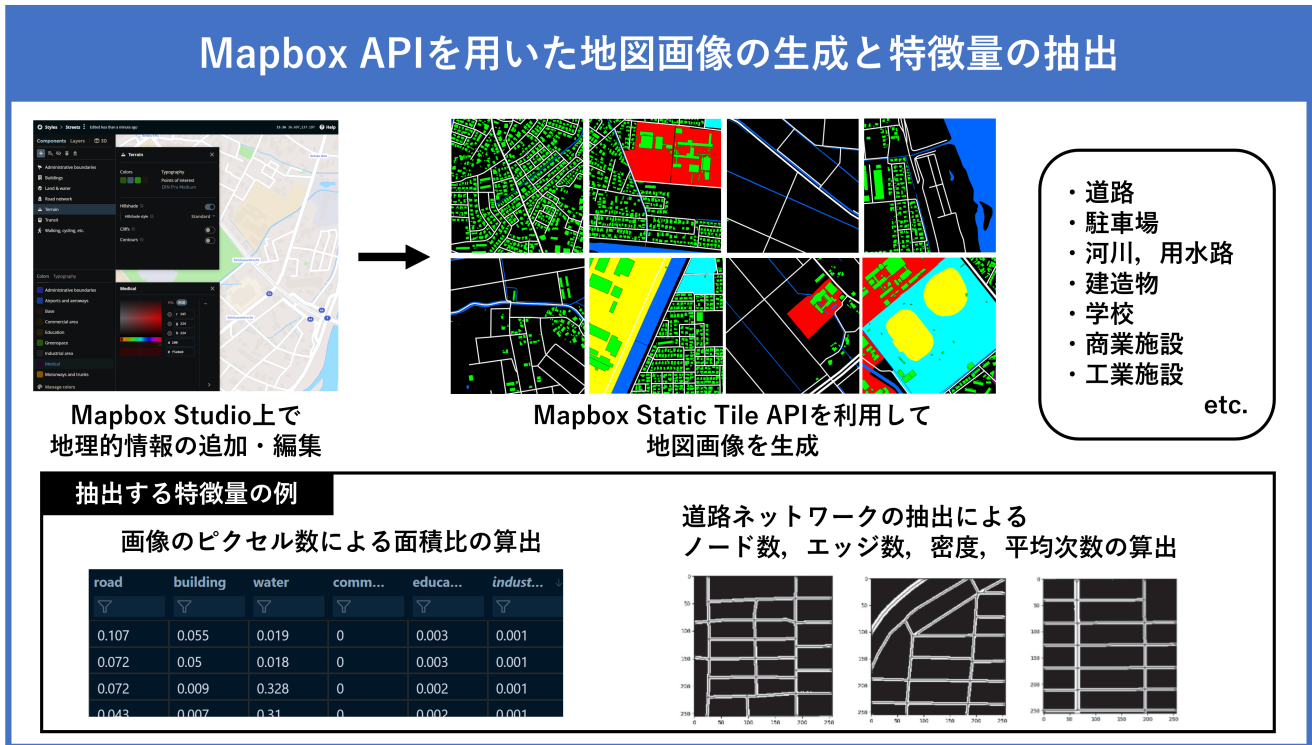


図4 地図画像の生成と特徴量の抽出

3.3 予測モデルを解釈するための手法

機械学習によって算出された予測モデルは、その精度が大きくなるほど、その解釈可能性が小さくなる関係にある。これを「オッカムのジレンマ」という。

これを解消に近づけるひとつの手法として、SHAP (SHapley Additive exPlanations) がある[5]。SHAPは、協力ゲーム理論において、プレイヤーをモデルの説明変数、貢献度の期待値(Shapley値)を目的変数への影響度に見立てたものである。そのモデルの予測精度が十分に大きく、各説明変数の相関関係が十分に小さい場合は、ブラックボックス化したモデルであっても、入出力関係を解釈することができる。

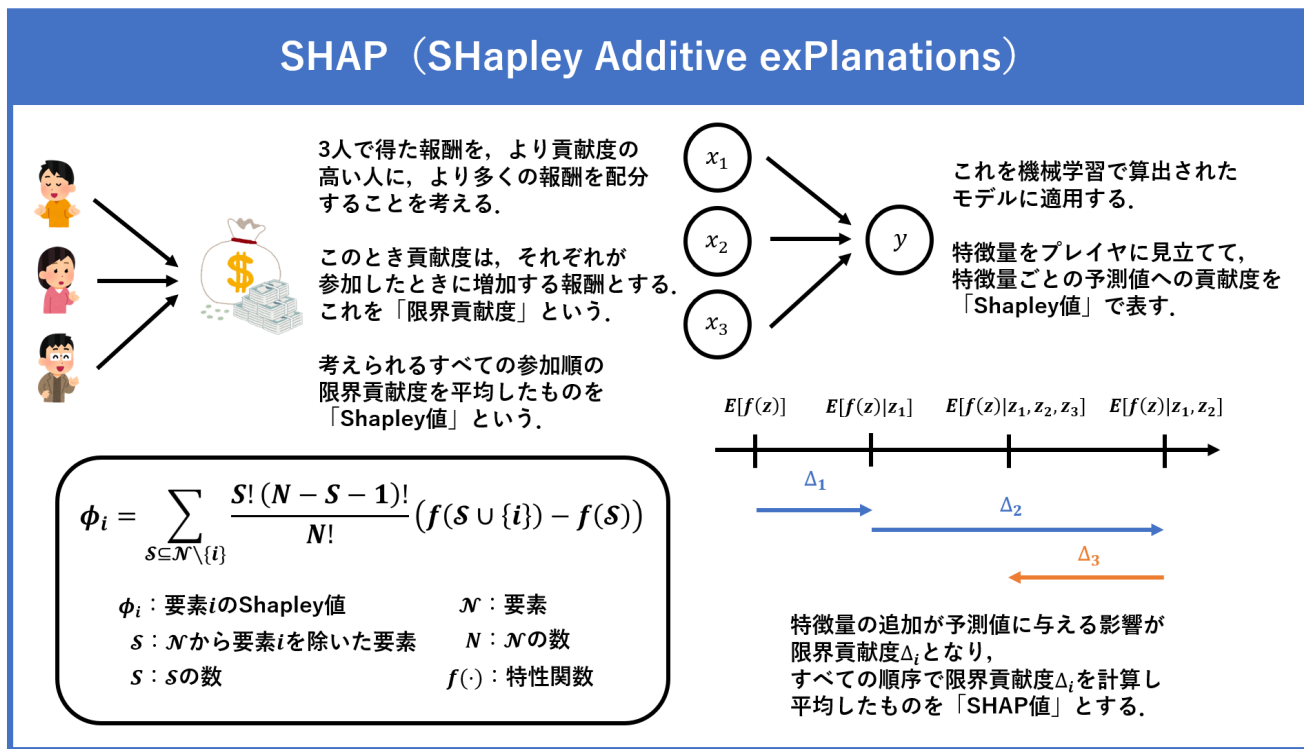


図5 SHAPの概要

4 提案手法

本研究では、富山県警が公開している「犯罪発生マップ」から犯罪発生データを、総務省が公開しているe-StatsやRESAS APIなどから関連データを取得する。また、Mapbox APIを利用して地図画像を生成し、地理的な特徴量を抽出する。適切な機械学習アルゴリズムの決定、ハイパラメータのチューニング、特徴量の選択を行い、どのエリアにいつ犯罪が発生するかを精度高く予測するモデルを構築する。そのモデルに対してSHAPを適用し、交錯因子・相関関係のある特徴量の排除など、適切な処理を行ったうえで、犯罪発生に寄与する詳細な要因を地域ごとに可視化する。

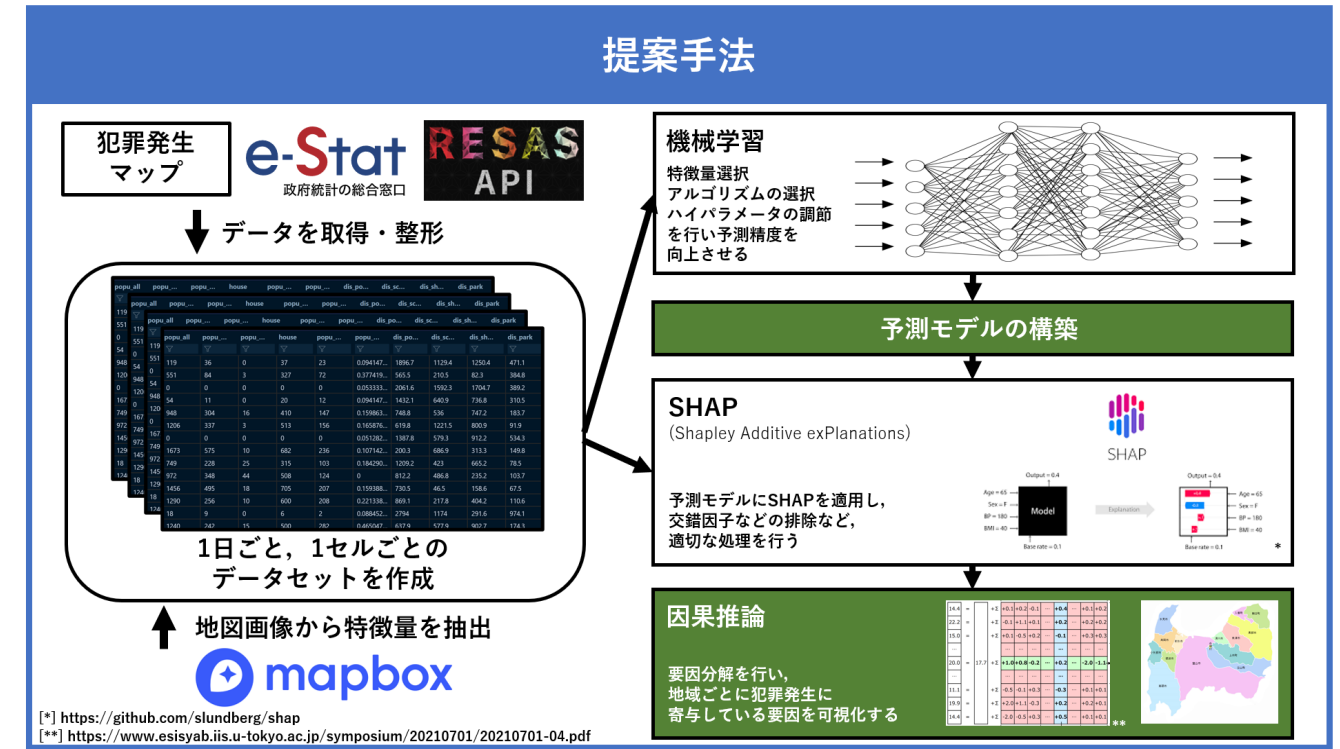


図6 提案手法

5 数値実験並びに考察

今回の数値実験では、実際に1日ごとの犯罪が発生するリスクを予測し、その精度と犯罪発生に寄与している変数について考察を行う。

予測する地域は、富山駅を中心とする東西に10km、南北に12kmの正方形の内側とし、予測する空間的な単位は、それを分割する一辺が500mのセルとした。対象地域における2009年1月1日から2018年8月31日までを学習用データとし、同年9月1日から9月30日までを予測した。

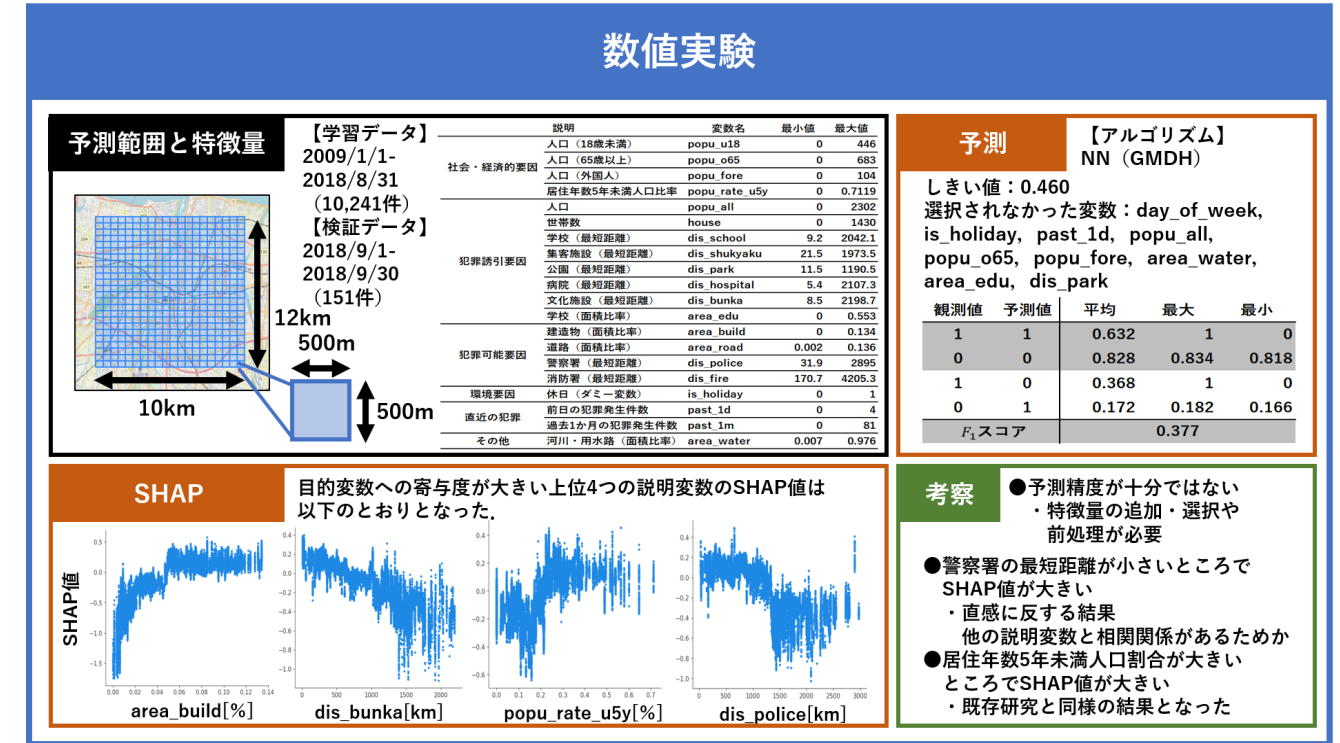


図7 数値実験の結果

6 おわりに

本研究では、異なるアプローチから犯罪を抑止することを支援するため、過去の犯罪発生データや犯罪発生の要因となり得るデータを用いて、犯罪が発生するかどうかを時空間的に予測するとともに、犯罪発生の寄与する要因を地域ごとに抽出する。今後の課題として、特徴量や前処理などの追加などで予測精度を向上することや、交錯因子・相関関係のある特徴量の排除などで適切な因果分析を行うこと、他の地域にも適用することなどが考えられる。

参考文献

- [1] 雨宮 護, "犯罪心理学事典", 丸善出版, 2016
- [2] 警視庁, "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.lg.jp/kurashi/anzen/anshin/ict-teigen.files/ict_teigensyo.pdf, 閲覧日 2022. 11. 02
- [3] 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", 筑波大学システム情報工学研究科博士論文, 2020
- [4] Jerry H. Ratcliffe, Ralph B. Taylor, Amber Perenzin, "Predictive Modeling Combining Short and Long-Term Crime Risk Potential: Final Report", <https://www.ojp.gov/pdffiles1/nij/grants/249934.pdf>, 閲覧日 2022. 11. 02
- [5] Scott M. Lundberg, Su-In Lee, "A Unified Approach to Interpreting Model Predictions", *Neural Information Processing Systems*, Vol. 31, 2017