

豪雨災害時の物資輸送経路を予測する AI の特性に関する考察

大日本コンサルタント(株) 正会員 ○水野 裕介, 森田 大成, 龍田 斉, 宮田 秀太

1. はじめに

近年、線状降水帯などによる局地的な豪雨災害が頻発し、交通インフラや物流ネットワークに深刻な影響を及ぼしている。これに対し、災害時の物資輸送経路について、避難所と物資輸送拠点の経路に着目すると、緊急輸送道路は指定されている。しかし、防災関係機関が連携して災害時の状況予測を共有した防災タイムラインに即して各拠点間を結ぶ経路を詳細に指定することは少ない。また、従来の GIS 探索では、旅行時間等の指定した属性情報の総和が最小となるような物資輸送経路が抽出されるが、抽出経路には冗長性が無い。

著者らの既往研究¹⁾では、機械学習の手法の一種である GBDT (Gradient Boosting Decision Tree) を用いて豪雨災害時の物資輸送経路を予測した。GBDT は、高速かつ精度の高い予測が可能であることから広く利用される。著者らの既往研究で構築した AI モデルにおいては、土砂災害警戒区域からの距離等の特徴量が予測に影響することが把握されている。

本研究の目的は、AI が災害時の物資輸送経路を予測する際に、どのような特性を持っているかを明らかにすることである。AI モデル特性の調査としては、学習済みモデルの説明変数の予測への寄与度について確認する手法である SHAP²⁾を用いた分析を行う。

2. 学習済みモデルおよび検討内容の概要

考察の対象とするモデルは、GBDT の一種である CatBoost³⁾を使用して、令和4年8月に山形県南部の置賜地域(上山市を含む)に発生した線状降水帯による豪雨災害に対して、通行止めの影響を加味した物資輸送経路を予測する学習済みモデルである。このモデルは、GBDT によって物資輸送経路の再現を行うもので、対象範囲外から対象範囲内の物資輸送拠点を經由して各避難所まで向かう経路を、非混雑時旅行速度の条件下で GIS によって探索した最短経路である物資輸送経路として真値に設定した。なお、道路網データは、オープンストリートマップから入手し、道路網データのリンクごとに道路交通センサスの旅行速度を割り当て、GIS による最短経路探索に用いる旅行時間はリンク長を旅行速度で除した値から求めている。

表-1 に示す通り、既往研究のモデルは道路区間ごとに旅行時間等の特徴量を説明変数とし、物資輸送経路として GIS 探索の結果として選択されたか否かを目的変数として学習したものである。既往研究では、このモデルは正答率 0.9298、F 値 0.8808 という高い予測精度を示す。しかし、図-1 の混合行列から把握されたとおり、偽陰性判定(図中において凡例 FN で示されるリンク。GIS が探索した最短経路だが、AI の予測経路に含まれない)が存在した。そこで、本研究では、偽陰性判定となった箇所について、個別のリンクに対する各説明変数の SHAP 値を分析することで、AI の推論結果の差異に関わる要因、またその影響について考察する。

表-1 説明変数の属性 (一部省略)

大分類	小分類
基本データ	管理者、経路種別など
供用データ	有料道路、バイパスなど
道路構造データ	車道幅員、車線数など
交通状況	非混雑時旅行時間、混雑時旅行時間、 非混雑時旅行速度、混雑時旅行速度
GISにより追加 作成したデータ	令和4年8月豪雨の日降水量、最寄りの 避難所名、避難所空の距離、最寄りの 物流拠点名、物流拠点からの距離、対 象範囲境界からの距離、非混雑時旅行 速度(計算値)、河川からの距離、土 砂災害警戒区域からの距離、断層から の距離、緑被率の平均、緑被率の標準 偏差、平均標高、最大傾斜角度、最大 傾斜方向、地質情報




図-1 GBDT 予測の混合行列と通過頻度 (回)

キーワード 防災計画, 豪雨災害, GIS, AI, GBDT, SHAP
連絡先 〒102-0075 東京都千代田区三番町 6-3 三番町 UF ビル 4F
大日本コンサルタント株式会社インフラ技術研究所 TEL 03-6850-0065

3. 学習済みモデルの特性

図-2 に示す概念図の通り、出発点から目標点の経路として選択されたリンクを計上することにより通過頻度を算出し、通過頻度の高いものを重要道路(リンク)として評価している。表-2 にて、各リンクにおける通過頻度 (GIS 探索により選択されたリンク候補の集合に含まれる回数) ごとに再現率を確認した。その結果、通過頻度が高いリンクほど再現率が高くなっており、AI は GIS 探索と同様に経路上の旅行時間の総和が最小となるようなリンクを優先的に選択していることが把握されている。

本研究では、学習済みモデルの予測結果と GIS 探索による経路推定結果を比較することで、AI が災害時の物資輸送経路を予測する際に、どのような特性を持っているかを考察する。

4. 考察

考察は、予測結果に対する各特徴量の影響を示すために SHAP を用いた。プロットの横軸は SHAP 値と呼ばれ、各特徴量の予測への寄与度を表し、縦軸が特徴量 (属性情報) の貢献度の高さを表す。また、プロットが青色から赤色に変化するにつれ特徴量が大きくなる。

本章では、AI モデルの予測結果が偽陰性とされたリンクに着目する。考察対象は図-3 に示す通り、偽陰性と真陽性で SHAP 値平均の差分 (絶対値) が最も大きい混雑時旅行速度とした。

図-4 にて緑色と黄色のプロットの開きで把握される真陽性と偽陰性の SHAP 値平均値の差分に着目すると、既往研究の AI モデルは非混雑時旅行速度の条件を真値に設定しているにも関わらず、混雑時旅行速度は SHAP 値の差分の絶対値が大きいことに加えて、非混雑時旅行速度は SHAP 値の差分の絶対値が小さくなることも確認された。混雑時旅行時間と非混雑時旅行時間の差が大きいリンクほど交通渋滞が発生していることを表すことから、渋滞が発生する要因を持つリンクを避けるモデルが構築されている可能性を示唆する。

5. 結論

以上の結果、豪雨時の AI による物資輸送経路の推定では、重要な経路 (通過頻度 21~50 回) において、非混雑時旅行速度よりも混雑時旅行速度の方が影響している特性が明らかになった。このことから、GIS で探索された経路に対して、渋滞が起りやすいリンクを避けるモデルが構築されている可能性が示唆された。

参考文献 1)水野裕介, 森田大成, 龍田斉, 宮田秀太: オープンデータと AI を用いた豪雨災害時の物資輸送経路予測および適用に関する研究, 土木学会 デジタルツイン論文集 2) Ludmila Prokhorenkova et al. : CatBoost: unbiased boosting with categorical features, Advances in neural information processing systems, pp.6638-6648, 2018, 3) Scott, M. L. et al. : A Unified Approach to Interpreting Model Predictions, In proceedings of the 31st Conference on Neural Information Processing Systems), pp.4768-4777, 2017




図-2 通過頻度 (回) による最短経路の重要度評価

表-2 通過頻度 (回) と再現率

通過頻度 (回)	該当リンク数	再現率
51~	20	1.0000
21~50	187	0.9412
11~20	231	0.9059
3~10	1201	0.9196
2	565	0.8626
1	1017	0.7658




図-3 重要な経路 (通過頻度 21~50 回) における真陽性/偽陰性の SHAP 値平均の差分 (絶対値)




図-4 SHAP 値と重要な経路における真陽性/偽陰性の平均値