

車載カメラによる複数データを用いた IRI 推定に関する機械学習手法の比較

Comparison of machine learning methods for IRI estimation using multi-modality from in-vehicle camera

室蘭工業大学工学部創造工学科 ○学生員 藤野優真(Yuma Fujino)
 室蘭工業大学大学院工学研究科 学生員 布広祥平(Shohei Nunohiro)
 室蘭工業大学大学院工学研究科 正員 浅田拓海(Takumi Asada)

1. はじめに

我が国の道路延長は 120 万 km に達しており、将来に向けた予防保全および長寿命化が求められている。特に、地方部においては、多くの箇所では舗装の損傷が発生しているため、効果的かつ効率的な維持管理が求められている。舗装維持管理の現場において、一般的に路面性状の評価に用いられる縦断凹凸は、平坦性や IRI (International Roughness Index) などの指標が用いられている。また、舗装点検要領では、分類 B の道路（主に直轄国道）の管理基準として、ひび割れ率、わだち掘れ量、IRI の 3 種の指標を基本とすることが明記されている¹⁾。したがって、IRI は、今後も多くの道路管理者に採用されることが予想される。

IRI の測定方法は、4 つのクラスに区分され、近年では、クラス 3、すなわち、簡易なセンサー類によって、上下方向の移動量や振動加速度などから、IRI を推定する方法がコスト、簡易性、客観性の面から期待が高まっている。また、最近では、機械学習などの AI 技術²⁾やスマートフォンなどの市販デバイス³⁾の導入が活発化している。著者らの先行研究では、市販のアクションカメラから得られる画像、振動加速度、走行速度の複数種類の情報から学習・推論を行う「マルチモーダル AI」を構築した⁴⁾。この研究では、路面画像から得られるひび割れ率を変数に導入すること、データ拡張を行うことで、IRI の推定精度の向上が可能になることを示した。しかしながら、機械学習手法として Elastic Net を採用したが、他との比較を行っていないため、それが IRI 推定に適しているかは不明のままである。

そこで、本研究では、市販アクションカメラとマルチモーダル AI を用いた IRI 測定技術に関して、様々な機械学習手法を比較し、推定精度のさらなる向上を目指す。

2. 方法

2.1 データの概要

本研究は、先行研究⁴⁾にて実施した「IRI 調査」と「カメラ調査」で収集したデータを使用した。調査路線およびデータの概要を表-1 に示す。

IRI 調査では、路面性状測定車および簡易 IRI 測定装置 STAMPER によって IRI を測定し、正解データとして用いる。IRI 調査は、大成ロテック株式会社実施し、データを提供いただいた。なお、データの単位区間長は 20m であり、位置情報とともに整理されている。

カメラ調査は、株式会社ドーコンが実施し、図-1 に示すように、市販のアクションカメラである

表-1 調査路線およびデータの概要

路線	延長 (km)	IRI 調査		カメラ調査		データ 区分
		期間	計測方法	期間	計測車両	
R231	48.6	2019.10	路面性状 測定車	2019.10	RAV4	モデル 構築
R451	52.8					
R40	83.4	2020.9	STAMPER	2020.9	LEVORG	検証 試験
R236	77.2					
R272	59.6					
R391	51.5					
R228	68.2	2020.10		2020.10	X-TRALE	



図-1 簡易カメラ搭載型舗装点検技術

GoProHERO6 を車両のボンネット上に設置し、走行しながら、上下振動加速度、位置情報、走行速度の計測および動画撮影を行った。また、撮影動画から 5m 毎に静止画を抽出し、著者らが開発した U-net によるひび割れ率検出手法⁵⁾よりひび割れ率を算出し、IRI 推定に用いた。

調査路線は、モデル構築用と検証試験用に区分される(表-1)。R231 と R451 は、モデル構築用の路線とし、路面性状測定車により正解データを得た。残りの R40, R236, R272, R391, R228 は、学習済みのモデルを反映した本技術の検証試験の対象路線とした。

2.2 データセット

モデル構築および検証試験のために、以下に示すようにデータセットを作成した。まず、正解値の単位区間長 20m に合わせて、位置情報により上下振動加速度、走行速度、ひび割れ率を 20m 区間毎に抽出した。走行速度

($SPEED$: km/h) とひび割れ率 (CR : %) については、それぞれ区間内平均値とした。上下振動加速度に関しては、区間内の二乗平均平方根 (RMS : m/s^2) およびパワースペクトル密度 (PSD : m^2/s^3) を算出した。 PSD は、Welch 法により算出し、周波数 0~50Hz を 8 分割した帯域毎の PSD の平均値 PSD_F ($F = 0, 7, 14, 21, 28, 35, 42, 50Hz$) を算出した。これらをモデルに入力する説明変数として用いた。なお、信号交差点などで車両が停止している状況では、 IRI の測定が難しいため、 $SPEED$ が 30km/h 未満のデータを除外した。

2.3 データ拡張

国交省試験では、 IRI を I (3mm/m 未満)、II (3~8mm/m)、III (8mm/m 以上) の 3 段階で区分し、精度検証を行っている。本研究でもこの区分を用いて分析を行った。モデル構築用路線の IRI の分布を図-2 に示す。区分 I の割合が 58.4% であるのに対し、区分 II は 38.6%、区分 III は 2.9% であり、大きな偏りが生じている。このような不均衡データを用いる場合、モデルの学習やテストを適切に行うことが難しい。オーバーサンプリングなどでデータを均等化できるが、過学習に陥りやすい傾向が指摘されている。その解決方法として、昨今では、SMOBN (Synthetic Minority Over-Sampling Technique for Regression with Gaussian Noise) と呼ばれるデータ生成アルゴリズムが提案されている。SMOBN は、少数派のデータの近傍から複数のデータを選択し、各データ間の線分上のランダムな位置から新たなデータを生成する。図-2 には、SMOBN により拡張した IRI の分布も示している。データの割合は、区分 II が 49.6% に、区分 III が 6.0% に増加し、拡張前よりも均等化された。このデータ拡張の有無でも精度比較を行い、次節で説明する機械学習手法との組み合わせについて考察する。

2.4 IRI 推定モデルの構築

本研究の目的は、多様な機械学習手法を比較することで、 IRI の推定精度を向上させることである。そこで、重回帰モデル (LR)、Elastic Net (EN)、サポートベクター回帰 (SVR)、Random Forest (RF)、XGBoost (XGB)、ニューラルネットワーク (NN) の 6 つの手法を導入し、精度比較を行った。

LR と EN は、線形回帰モデルであり、非線形モデルに比べて外挿性に強い可能性がある。そのうち EN は、先行研究で採用した手法であり、L1 正則化項と L2 正則化項が設定された構造を持ち、これらにより、多重共線性と過学習の発生が低減され、高い汎化性能が期待できる。一方、それ以外の 4 つの手法は非線形モデルであり、少ないデータでも高い精度が得られる機械学習手法として、昨今、土木分野でも導入が進んでいる。SVR は、特徴の似通ったデータを互いから最も遠い位置に境界線を引くことでデータ分類を行うサポートベクターマシンを回帰に応用した手法である。RF は、アンサンブル学習におけるバギングを基に、複数の決定木を集めて学習を行う手法であり、過学習の抑制効果が大きいことが報告されている。XGB は、RF を発展させた手法であ

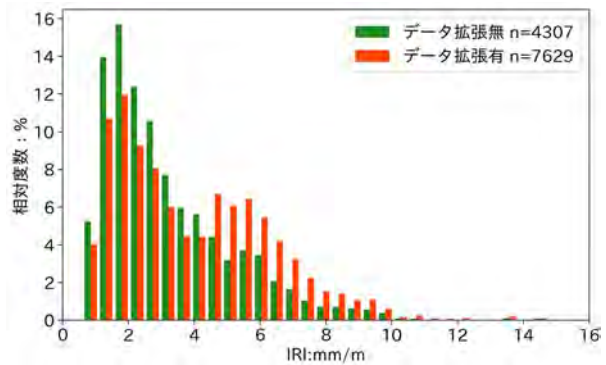


図-2 データ拡張前後の IRI 値の比較

り、複数の決定木を用いて各計算結果の誤差を小さくするように学習することで精度を高めていく手法である。NN は入力層、隠れ層、出力層からなる人工ニューロンで構成された機械学習手法であり、隠れ層を増やすことで複雑な関数近似を行うことができる。

LR 以外の手法では、モデルの最適化のために、通常、ハイパーパラメータのチューニングが行われる。そこで、3 分割交差検証およびグリッドサーチを行った。具体的には、全データを 3 等分し、学習データとテストデータを入れ替えることで、全データが未知となるテストを行い、RMSE (Root Mean Squared Error) が最も小さくなるハイパーパラメータの組み合わせを総当りで探し出し、全データによる最終モデルの学習に用いた。

2.5 本技術の検証試験

国土交通省は、平成 30 年に簡易な舗装点検技術の共通試験 (以下、国交省試験) を実施しており、参加技術の精度を一覧表にして公開している⁶⁾。この試験では、一般国道のアスファルト舗装区間にて、1km の試験区間を設定し、20m ブロック毎にクラス 1 技術 (水準測量) によって測定された IRI を真値とした精度検証が行われている。本研究では、この国交省試験に準じた検証試験を行う。ただし、クラス 1 技術による真値を得ることは難しいため、実用化されているクラス 2 技術により測定されたデータを用いて、その正解値の再現性評価という観点で試験を行うこととした。また、正解値と推定値は、20m 区間単位で得られるが、データを確認したところ、両者の位置に若干のズレが生じていたため、ともに 100m 区間毎に算出した最大値を用いて分析を行った。

精度指標としては、国交省試験と同じく「区分 II 以上」と「区分 III」を対象とした検出率と的中率を用いた。検出率 (%) は、正解値に対して、検証対象技術の見逃しがどの程度少ないかを確認する指標である。的中率 (%) は、検証対象技術で過大な結果となる割合がどの程度少ないかを確認する指標である。

検証路線では区分 III の区間が稀であり、このような不均衡データで精度評価を行うことは適切ではない。そこで、以下の手順で、路線毎に精度検用の区間 (検証区間) を抽出した。まず、区分 I と III がともに 5% 以上ある 5km 区間を抽出した。次に、その中で区分 III の割合が最大となる区間を当該路線の検証区間とした。

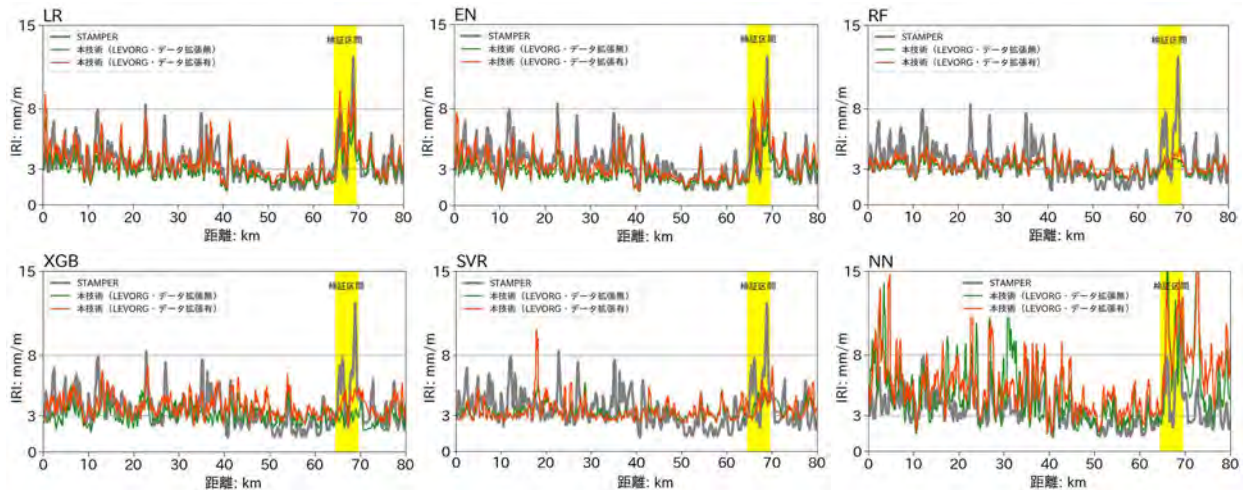


図-3 R40におけるIRIプロファイル

3. 結果と考察

3.1 IRI 推定値としての精度検証結果

IRI 推定を行う上で有用な機械学習手法について考察する。一例として、検証路線 R40 における IRI の正解値と推定値のプロファイルを図-3 に示す。なお、比較しやすいよう、各プロファイルには基底長 100m の移動平均を適用している。

LR と EN による推定値は、路線全体に渡って正解値に近似しており、検証区間のような正解値が大きい箇所についても再現性が高い。同様に、XGB も正解値に近いプロファイルを描いているものの、正解値が大きい箇所で大きな誤差が生じている。RF と SVR については、正解値が 3mm/m 前後の区間では再現性が高いが、それ以外では誤差が大きく、過小評価となる箇所が多い。その一方、NN では、IRI が大きい箇所で過敏に反応しており、過大評価の傾向を示している。なお、データ拡張の有無については、どの手法も同様な結果を示しており、IRI プロファイルからの評価は難しい。

次に、決定係数 R^2 および RMSE から IRI 推定値の精度を定量的に評価し、その結果を表-2、表-3 に示す。なお、両表には、精度がデータ拡張有 \geq データ拡張無となったケースを赤字で示している。結果を見ると、EN、LR、NN では、データ拡張有の方が高精度となるケースが多い。それ以外の手法では、逆に精度が低くなっており、データ拡張の効果が見られない。手法の比較としては、 R^2 では、EN と LR が全路線で最も高い値を示し、ほとんどの路線で 0.3 を上回った。次いで、RF、XGB、NN が同程度の値となり、SVR は全路線で 0.2 以下となり最も精度が低い。RMSE でみても、LR と EN が他の手法よりも精度が高いことがわかる。

3.2 3段階評価としての精度検証結果

次に、各路線の検証区間を対象に、国交省試験に準じた3段階評価としての精度検証を行った。各手法の検出率および的中率を図-4 に示す。各手法の精度評価の比較から、検出率 (II 以上) および的中率 (II 以上) は、どの手法も約 80% 以上を示した。一方、検出率 (III) と的中率 (III) については、手法によって大きく異なるこ

表-2 各検証路線における R^2

上：データ拡張無 下：データ拡張有 赤字：有 \geq 無

手法	R40	R272	R236	R391	R228
LR	0.23 0.23	0.59 0.59	0.50 0.51	0.35 0.35	0.39 0.39
EN	0.27 0.28	0.59 0.59	0.50 0.50	0.35 0.35	0.43 0.43
RF	0.19 0.19	0.44 0.42	0.26 0.23	0.25 0.22	0.35 0.36
XGB	0.04 0.06	0.28 0.27	0.09 0.02	0.17 0.08	0.18 0.15
SVR	0.03 0.01	0.16 0.11	0.04 0.02	0.06 0.04	0.07 0.02
NN	0.13 0.17	0.28 0.31	0.21 0.18	0.16 0.17	0.08 0.26

表-3 各検証路線における RMSE

上：データ拡張無 下：データ拡張有 赤字：有 \geq 無

手法	R40	R272	R236	R391	R228
LR	4.29 4.65	2.40 1.88	1.86 2.09	3.22 6.83	3.36 4.30
EN	4.19 3.65	3.08 2.06	2.06 1.81	2.50 2.99	4.51 3.34
RF	4.15 3.95	2.63 2.81	2.69 2.78	2.92 3.66	4.13 3.60
XGB	5.64 5.98	4.48 6.56	3.86 6.66	4.44 10.4	4.84 6.92
SVR	5.16 5.74	4.25 5.29	4.78 6.12	4.67 5.73	5.55 7.13
NN	29.3 27.2	6.64 5.06	8.89 27.2	7.39 10.8	16.5 8.74

とがわかる。まず、RF と SVR では、15% を下回っている。これは、図-3 に示したように、検証区間において推定値が区分 III となるケースがほとんどないためである。XGB では、的中率 (III) が 50% 以上に向上するが、検出率 (III) は同様に低いままである。NN では、図-3 に示したように、過大評価となる傾向のため、検出率 (III) が約 50% を示したが、その代わりに、的中率 (III) が若干低下している。LR と EN も同様に、検出率 (III) が約 50% になり、的中率 (III) は NN より大きいことがわかる。さらに、これら線形モデルでは、データ拡張有の方が的中率 (III) の若干の低下がみられるものの、検出率 (III) が 30% 以上高まることがわかる。

国交省試験では、各精度の値を 20%で区分し、A~E の 5 段階ランクで参加技術の精度比較を行っている。そこで、本技術についても同様にランク付けを行い、機械学習手法および国交省試験に参加した既存の同型技術との比較を行った(表-4)。なお、ここでは、データ拡張有の結果を示す。検出率(II以上)と的中率(II以上)では、どの機械学習手法でもランクAまたはBとなり、既存技術と同等となった。検出率(III)と的中率(III)については、前節でも述べた通り、区分IIIの箇所再現性により手法によって大きく異なる。

LR では、全指標のランクが他の手法に比べ高く、検出率(II以上)と的中率(II以上)は最高ランクのA、検出率(III)はB、的中率(III)はCとなった。また、EN では、検出率(III)が1ランク下がったが、的中率(III)がランクBに向上した。NNについては、IRIが過大評価となる傾向があるため、検出率(III)はランクBと高いものの、的中率(III)はランクDとなった。RF、XGB、SVRでは、検出率(III)および的中率(III)がランクD、Eとなった。

3.3 IRI 推定に適した機械学習手法

以上より、線形モデルであるLRとENは、IRI推定値の精度が他の非線形モデルよりも高いこと、また、SMOENによるデータ拡張の効果が大きいことがわかった。特に、IRIが大きい箇所を精度よく再現しており、検出率(III)についても他の手法より高い値を示した。線形モデルでは外挿側、すなわち学習データの少ないIRIが大きい領域の推定が比較的得意であるためと推測される。一方で、非線形モデルでは、過学習の可能性から、外挿側の推定値に大きな誤差が生じる傾向にあると思われる。

LRとENは、3段階評価としてはLRの方が良い結果が得られたが、単純なモデルであるため、それ以上の精度向上は期待できない。それに対し、ENでは、ハイパーパラメータのチューニングを工夫することで改善できる可能性がある。さらに、ENはスパースモデリングの一種であるため、多重共線性の問題を解消しやすく、モデルの説明性の面で有利である。以上の結果を総合すると、市販アクションカメラを用いた本技術におけるIRIの推定にはENが適していると言える。

4. まとめ

本研究では、市販アクションカメラから得られる上下振動加速度、走行速度、ひび割れ率を入力とするIRIの推定に関して、複数の機械学習手法を比較し、精度の高い手法の特定を試みた。得られた知見を以下に示す。

- 線形回帰モデルであるElastic Net (EN)による推定値は、正解値とのR²が0.3以上、RMSEが3.5mm/m以下となり、他の機械学習手法より高い精度が得られた。
- さらに、ENでは、SMOENによるデータ拡張によってIRIが大きい箇所の精度が向上することがわかった。
- 国交省試験に準じた検証では、ENの検出率(II以上)と的中率(II以上)はA、検出率(III)はC、的中率(III)はBとなり、実用に耐えうる精度が得られた。

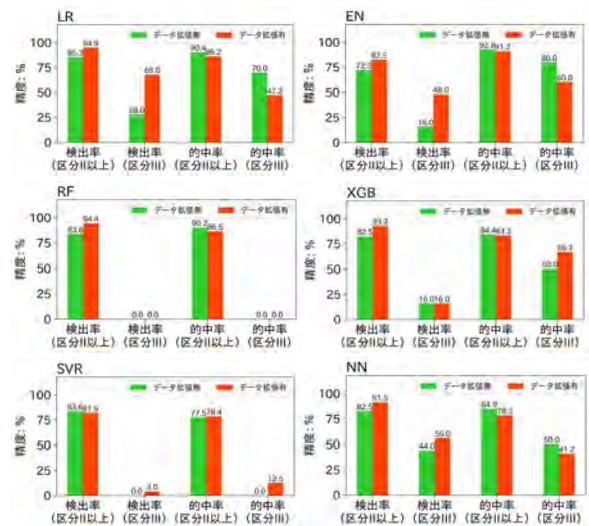


図-4 検証区間における各手法の検出率と的中率

表-4 各手法(データ拡張有)の精度ランク

測定技術		検出率	検出率	的中率	的中率
機械学習手法		II以上	III	II以上	III
本技術	LR	A	B	A	C
	EN	A	C	A	B
	RF	A	E	A	E
	XGB	A	D	B	D
	SVR	A	E	B	E
	NN	A	B	A	D
既存技術①		A	A	A	B
既存技術②		B	E	A	E
既存技術③		A	A	A	C

参考文献

- 1) 国土交通省：舗装点検要領，2016。
- 2) 朝川皓之，長山智則，藤野陽三，西川貴文，秋本隆，和泉公比古：一般車両の走行時動的応答を利用した舗装路面の簡易状態評価システムの開発，土木学会論文集 E1 (舗装工学)，Vol. 68, No. 1, pp. 20-31, 2012。
- 3) 河井大地，丸山喜久，永田茂：スマートフォンで計測した自動車の上下加速度を用いた舗装路面凹凸の評価，土木学会論文集 E1 (舗装工学)，Vol. 73, No. 3, pp. I_79-I_87, 2017。
- 4) 浅田拓海，布広祥平，後藤宏行，城本政一，亀山修一：マルチモーダル AI を用いた簡易カメラ搭載型 IRI 測定技術の開発，土木学会論文集 E1 (舗装工学)，Vol. 79, No. 2, 2022。(登載決定)
- 5) 浅田拓海，居駒薫樹，長屋弘司，亀山修一：U-net によるひび割れスケッチを導入した簡易カメラ搭載型舗装点検の精度検証，土木学会論文集 E1 (舗装工学)，Vol. 79, No. 2, pp. I_123-I_131, 2020。
- 6) 国土交通省：「路面性状を簡易に把握可能な技術」の試験結果を公表します～新技術の活用に向けて～，試験結果等比較表(別紙-2)，2018。