IRI 推定のための自動車のバネ下加速度の利用

14T0304W　市川　恭平
指導教員：丸山　喜久

1.　研究背景と目的

高度成長期に一斉に建設された我が国の道路ストックは，老朽化が進行し修繕や更新が必要となっている．国土交通省・社会資本整備審議会では，「今後適切な投資を行い修繕を行わなければ，近い将来大きな負担が生じる」と警鐘を鳴らしている[1)]．また，2012年12月には中央自動車道笹子トンネル上り線で天井板崩落事故が発生し，道路ストックの老朽化に対し，社会的関心が高まっている．こうした背景から，2013年に国土交通省は総点検実施要領(案)[2)]を取りまとめた．しかしながら，舗装の維持修繕費は20年前と比較して大幅に減少している．厳しい財政制約の中で舗装の修繕に回す予算は限られ[3)]，とくに規模の小さな地方公共団体では技術者不足も深刻な問題となっている．

従来の路面の診断・点検は，主に検査員による目視と路面性状測定車によって行われている．前者は路面性状の評価が定性的にしか行えない点，後者は初期費用や運用費が高額である点[4)]が指摘されており，これらの方法に代わる簡易で定量的に路面性状を把握できる手法が求められる．

そこで本研究では，地方公共団体でも簡易に路面性状を把握できるようになることを目指し，普通乗用車のバネ下に設置した小型加速度センサにより取得した上下方向の加速度振幅を用いて，路面の平たん性を表す国際ラフネス指数（International Roughness Index: IRI）を 推定する回帰モデルを，機械学習モデルに基づき構築し，その精度検証を行った．

2.　データ説明

本研究では，2015 年 9 月 25 日に神奈川県横浜市で, 同年 10 月 9 日に東京都調布市において実走調査を行った．鹿島道路（株）の多機能路面測定車によって IRI を 10m 間隔に計測した．さらに，普通乗用車のバネ下に小型加速度センサを設置した調査用の車両が追走した．各車両で得られた計測値を位置情報データによって紐づけた．

(1)　多機能路面測定車での測定

IRI の算出には，多機能路面測定車に取り付けたレーザースキャナにより路面の縦断プロファイルを計測し，クォーターカー(Quarter Car: QC)シミュレーションによって IRI を算出するクラス 2 の方法を用いた．

(2) バネ下での加速度測定

IRIを推定するための簡易的な測定値として，本研究では，普通乗用車のバネ下に設置した小型加速度センサから得られる上下方向の加速度振幅を用いた．多機能路面車を並走した調査用車両（マツダ・デミオ）の左前方（助手席側）と右前方（運転席側）に加速度センサを設置し，サンプリング周波数は1280Hz, 上下方向の加速度振幅 (m/s^2) を計測した．本研究ではこれらの2つのセンサ（左側，右側）で計測されたサンプリング周波数1280Hzの加速度から振幅の平均値，最大値，標準偏差を算出し，位置情報データによって最近傍のIRI（10m間隔）に紐づけた．

3.　IRI推定のための回帰モデル式の検討

(1) 回帰モデル式の説明変数

IRIを被説明変数とする回帰モデル式の説明変数は，**表-1**に示した7変数とした．平均加速度（左，右）および最大加速度（左，右）は，小型加速度センサより得られた加速度振幅の絶対値を用いて算出し，停車時のデータは除いている．

(2) 回帰分析手法

統計分析フリーソフト R において，予測モデル作成のための複合パッケージである caret（Classification And REgression Training）[5)]を用いて回帰分析を行った．caret パッケージは，分類や回帰に使用するアルゴリズムによらず予測モデルを構築する処理をほぼ同様の記述方法で対応するためのインターフェースの役割を担うパッケージである．

本研究では多変量解析によく用いられる重回帰分析に加えて，人工ニューラルネットワーク，サポートベクターマシン，ランダムフォレスト，勾配ブースティング（線形/木モデルの 2 種）の 5 種類の機械学習モデルを用いて学習を行い，良好な学習結果が得られたランダムフォレスト，勾配ブースティング（線形）を採用し，回帰分析を行った．ランダムフォレストは複数の弱識別器の多数決の結果に基づくアンサンブル学習モデルであり [6)]，勾配ブースティングは複数の弱識別器を逐次的に構築する重み付きアンサンブル学習を行うモデルである [7)]．それぞれ caret での method 関数は-rf-，-xgblinear-とし，パラメータは自動チューニングで求めた．

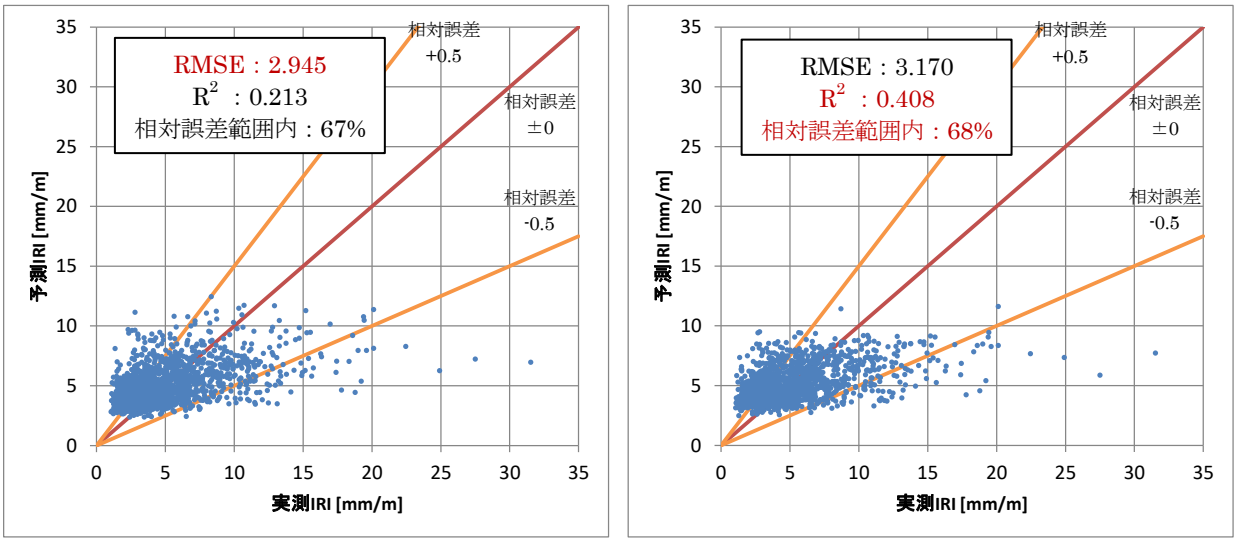

(a) ランダムフォレスト　　(b) 勾配ブースティング（線形）

図-1　回帰分析結果の比較

4.　結果および評価

回帰分析に用いたデータは，全測定データのうちの60%をランダムサンプリングしたものを学習用データとして回帰モデル式の構築に用い，残りの40%をテスト用データとして回帰モデル式の精度評価に用いた．図-1は，テスト用データによる精度評価結果である．実測IRIは多機能路面測定車で計測された10m区間のIRI（mm/m），予測IRIは各回帰分析で求められた回帰モデル式から予測したIRI（mm/m）を表す．精度評価に用いる指標は，平均平方二乗誤差RMSE，自由度調整済み決定係数R^2とした．また，実測IRIと予測IRIの相対誤差が-0.5～+0.5の範囲内に収まったデータ数の割合を算出した．各グラフの赤線は相対誤差±0（実測IRI=予測IRI）を示し，黄線は上側が相対誤差+0.5（実測IRI＝予測IRI×$\frac{3}{2}$），下側が相対誤差-0.5（実測IRI＝予測IRI×$\frac{1}{2}$）を示す．

5.　考察とまとめ

本研究では，車両バネ下に設置した小型加速度センサから得られた上下加速度を用いて，簡易にIRIを推定する回帰モデル式の構築を試みた．勾配ブースティング（線形）では，R^2=0.408，相対誤差範囲内68%という結果となったが，IRI=0~5mm/m程度で過大予測，IRI=10mm/m程度以上では過小予測の傾向があると考えられる．実測IRIのヒストグラム（図-2）をみると，IRI=3~8mm/mの地点が全データの約6割を占め，IRIが低い（0~3mm/m）地点や高い（8mm/m~）地点のデータ数が乏しく，機械学習による学習に偏りが生じてしまったと考えられる．

今後は，データの偏りについての問題を改善するために，初めにIRIの小さいデータと大きいデータを振り分ける2値分類器を機械学習モデルによって構築し，その後それぞれの回帰モデルに当てはめIRIを予測する手順を提案したいと考えている．

表-1　回帰モデル式の説明変数

変数名	単位
10m区間の車両の平均走行速度	m/s
10m区間の平均加速度（左）	m/s^2
10m区間の平均加速度（右）	m/s^2
10m区間の加速度の標準偏差（左）	m/s^2
10m区間の加速度の標準偏差（右）	m/s^2
10m区間の最大加速度（左）	m/s^2
10m区間の最大加速度（右）	m/s^2

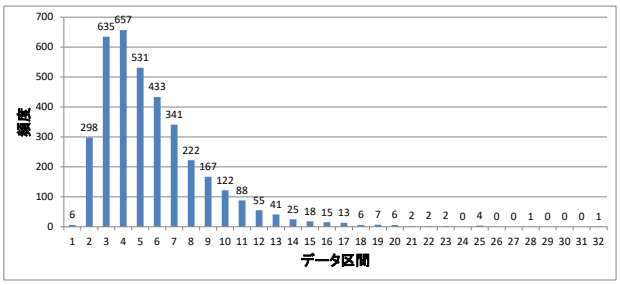

図-2　実測 IRI のヒストグラム

参考文献

1) 国土交通省社会資本整備審議会道路分科会：道路の老朽化対策の本格実施に関する提言，2014.
2) 国土交通省：総点検実施要領（案），2013.
3) 国土交通省：舗装点検要領について，2017, https://www.road.or.jp/event/pdf/201708211.pdf
4) 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.
5) CRAN：Package'caret'，CRANHP，2017, https://cran.rproject.org/web/packages/caret/caret.pdf
6) R.Breiman：Random Forests，Machine Learning，Vol.45，pp5-32，2001.
7) T.Chen：Introduction to Boosted Trees，Washington Univ. https://homes.cs.washington.edu/~tqchen/pdf/BoostedTree.pdf