

GPS 情報と車両振動データを用いた橋梁上振動データ抽出 AI の検証

○高橋悠太（八千代エンジニアリング） 金子直樹 秦涼太 山本亨輔（筑波大学）

概要 センサーによる橋梁モニタリングにおいて、中小スパン橋では高コストになると考えられる。本研究では橋梁にセンサーを設置することなく、車両振動から橋梁振動を推定する Drive-by 点検や橋梁スクリーニングに注目する。橋梁上での車両振動は、連続データから抽出する必要がある。橋梁端部と車両に設置した GPS デバイス間の相対距離から橋梁上振動と推定されるデータを抽出し、これを学習した AI が GPS の誤差を補完可能かを検証する。

キーワード: Drive-by Inspection, Vehicle Response Analysis, LSTM, GPS

1 背景

我が国は道路総延長 127 万 km、橋梁数 70 万基あまりを有し、技術者減少が懸念される将来、点検維持の負担増大が想定される。橋梁点検では近接目視点検が基本とされてきたが、平成 31 年 2 月に橋梁定期点検要領¹⁾が改訂され近接目視点検に代わる手段として、ドローン画像などが使用可能となった。令和 2 年 6 月、点検支援技術性能カタログ²⁾が更新され、いくつかの技術を近接目視と同等の情報が得られる技術として参考にできるとしている。また、目視を前提とする規制を緩和することも閣議決定されている³⁾。カタログ記載済み対象技術には、橋梁上に加速度センサーを設置し、得られた橋梁応答から劣化や異常を検知する技術も含まれている²⁾。振動計測であれば、ドローン画像と異なり、常時モニタリングも可能となるが、橋梁 1 基あたりの設置コストが高く、たとえば径間長 40m 以上とする長大橋を除いて導入は進んでいない。これに対し、現在未記載の技術に、車両に搭載した加速度センサーから車両振動を得て、車両-橋梁間相互作用システムの運動方程式に基づいて橋梁振動を推定し、劣化や異常を検知する車両応答分析技術が開発されている⁴⁾。橋梁振動は直接計測せず、間接的に推定された橋梁振動から橋梁の状態把握を目指すため、推定精度の低下が考えられるが、センサーを個々の橋梁に設置する必要がなく、路面データも収集可能なスクリーニング技術になると期待される。

路面評価技術であれば、画像や 3 次元データを用いた手法(ドクターインフラ)⁵⁾、加えて振動データを用いた手法などが挙げられる(Glocal-eyz)⁶⁾。しかし、走行中に得られた画像のみを用いる、あるいは振動についても車両ダンパー等により減衰されたバネ上振動を使用しており、走行した橋梁の状態把握は現在想定されていない。一方、バネ下振動を利用した橋梁・路面状態を把握する研究として、空間特異モード角(SSMA: Spatial Singular Mode Angle)を用いた手法が挙げられる⁷⁾。ただ、これら振動データを用いる手法については、得られた車両振動データを、橋梁上とそれ以外に可能な限り分離して分析することが望ましい。本研究では、バネ下振動を用いた SSMA 関連技術を橋梁モニタリング技術として社会実装するため、また IoT (Internet of Things) が実現された将来社会において、車両から得られる振動に関する連続データを、橋梁状態把握に活用するため、連続データから橋梁上で得られたデータを抽出する手法に着目する。

抽出方法として、車載のセンサーシステムに GPS デバイスを追加し、位置情報を付与し、方法を問わず

梁端部と定義した位置との相対距離により、橋梁への車両の入退出を推定できる。ただし、GPS デバイスの示す位置精度に着目した場合、自動運転などへの利用を想定された高精度高周波数の RTK デバイス等はいまだ高価である。ここで、GPS の位置精度は電離層などの影響を受けるが、相対距離については比較的精度が維持されることから、従来精度の安価な GPS デバイスを複数利用することを考える。ただし、正解となる位置情報は測量で決定され、時間経過によって徐々に移り変わるものであり、完全な位置情報は得られない点に留意する。補完的な技術として、振動データから信号的な特徴量に基づいた抽出方法も考えられる⁸⁾。本研究では LSTM (Long-Short Term Memory: 長短期記憶)⁹⁾に着目する。特に、先行研究においては、抽出する特徴量の表現力を高めるため、LSTM 層に畳み込み積を採用した Conv-LSTM¹⁰⁾を用いた。また、実験データを用いた研究¹¹⁾においては、ADC(アナログ-デジタルコンバータ)の量子分解能が比較的低い、ノイズ耐性が高い実験データが使用されていた。本研究ではより高い量子分解能を持つ、電子的なノイズは多いが、より橋梁の微弱な振動を計測可能と考えられる実験データを用いる。このため、学習データ数の確保が難しく、よりロバストなモデルが求められることから、簡素なアーキテクチャを持つ LSTM を使用し、車両振動データの中で、おおよそ橋梁通過中と思われる部分を抽出し、教師を付けて学習させる(Fig.1)。この時、LSTM は構造変化を特徴量の変化として捉えられていると考えられ、繰り返し学習することで、GPS の位置推定誤差を補完し、橋梁上で得られたデータが抽出可能と考えられる。本研究では、連続データから一部切り出した、教師付けした車両振動データを LSTM で学習し、橋梁上で得られた振動を分類、抽出可能かを検証する。

2 データの抽出と学習方法

2.1 データの抽出方法

学習データは橋梁端部・車両前輪情報に設置した GPS デバイスの相対距離がそれぞれ最低となる瞬間を橋梁の入退出と定義し、連続データから橋梁上で得られたデータとして抽出する。学習データにはこのデータ長の同程度、前後のデータを含める(Fig.1)。実験は 2021 年 7 月に実施した。実験橋梁と車両諸元について Table.1, Fig.2 に示す。得られた加速度データは量子分解能が 23bit/重力加速度相当を有する ADC を用いた。サンプリングレートは 300Hz とした。各橋梁上で得られた車両前後輪バネ下加速度データを一部 Fig.3 に示す。各橋梁で異なる特徴を持つ波形が確認できる。

2.2 学習方法

学習にはLSTMをSeq-to-Seqで用いる。LSTMはRNN (Recurrent Neural Network)の一種で、忘却機構を有する。Conv-LSTMと比較し、その構造上、少ないデータでも学習可能性が高いと考えられる。学習パラメータは表-2に示す。層構造は入力層-LSTM層-全結合層-SoftMax層-分類層と、簡素な構造とした。潜在変数は200、分類クラスは0が橋梁外、1が橋梁上とする。また、クラス間の重みを1:3とし、クラス1に対する正解率を重視することで、すべて片方のクラスに分類されることを回避する。学習率は0.001、学習回数を1500 (S1のみ、収束した2500)とした。入力データは車両側のGPSデバイス設置位置が前輪上方であることから、前輪バネ下鉛直加速度を入力データとする。学習に用いるデータは全モデル5データとし、推論に用いるデータは学習に用いないデータすべて用いる。PC1, PC2, PC3, S1について学習したモデルを、それぞれModel.1からModel.4とする。これら諸元はTable. 2に示す。

3 学習と推論結果

3.1 PC1 学習モデル(Model.1)の学習・推論結果

Model.1の学習曲線(正解率・損失)をFig.4に示す。また、Table.3に最終正解率と損失を示す。学習の収束を確認できる。推論結果の内、正解率が最高・最低の結果をFig.4 (c),(d)に示す。青が推論結果、橙が真値、縦軸はクラス、横軸はデータのインデックスを示す。推論正解率について、クラス間の重みはない。分類クラスは0が橋梁外、1が橋梁上を示す。最高正解率95.7%の推論結果において、前後のずれはあるが、正しく推論できている。最低成果率34.8%の結果において、

橋梁上(クラス 1)と推論した位置はデータ後半となっている。学習データは簡便化のため、データ中央付近にクラス1を連続配置した。この結果から、学習モデルが必ずデータ中央付近に橋梁上データがあるという位置関係を学習する、という望ましくない学習(過学習)を回避したことが確認できる。

3.2 PC2 学習モデル(Model.2)の学習・推論結果

Model.1同様、Model.2の学習曲線(正解率・損失)をFig.5に、最終正解率と損失をTable.3に示す。学習の収束を確認できる。次に推論結果の内、正解率が最高・最低だった結果についてFig.5 (c), (d)に示す。PC2はPC1と同程度の橋長を有するが、Model.1と比較し、最終正解率および最高推論正解率は高くなかった。

3.3 PC3 学習モデル(Model.3)の学習・推論結果

Model.3の学習曲線(正解率・損失)をFig.6に、最終正解率と損失をTable.3に示す。学習の収束を確認できる。次に推論結果の内、正解率が最高・最低だった結果についてFig.6に示す。正解率最高の結果については、一部誤って橋梁上と推論したが、概ね分類が成功している。正解率最低の結果について、クラス1についての推論が主として失敗していることが分かる。

3.4 PC3 学習モデル(Model.4)の学習・推論結果

Model.4の学習曲線(正解率・損失)をFig.7に、最終正解率と損失をTable.3に示す。Model.4については、学習回数が1500では収束しなかったことから、2500回学習を行った。推論結果の内、正解率が最高・最低だった結果(Fig.7)についてみると、最低の場合でも84.8%となっている。推論結果についても、一部誤分類があるが、成功していると考えられる。

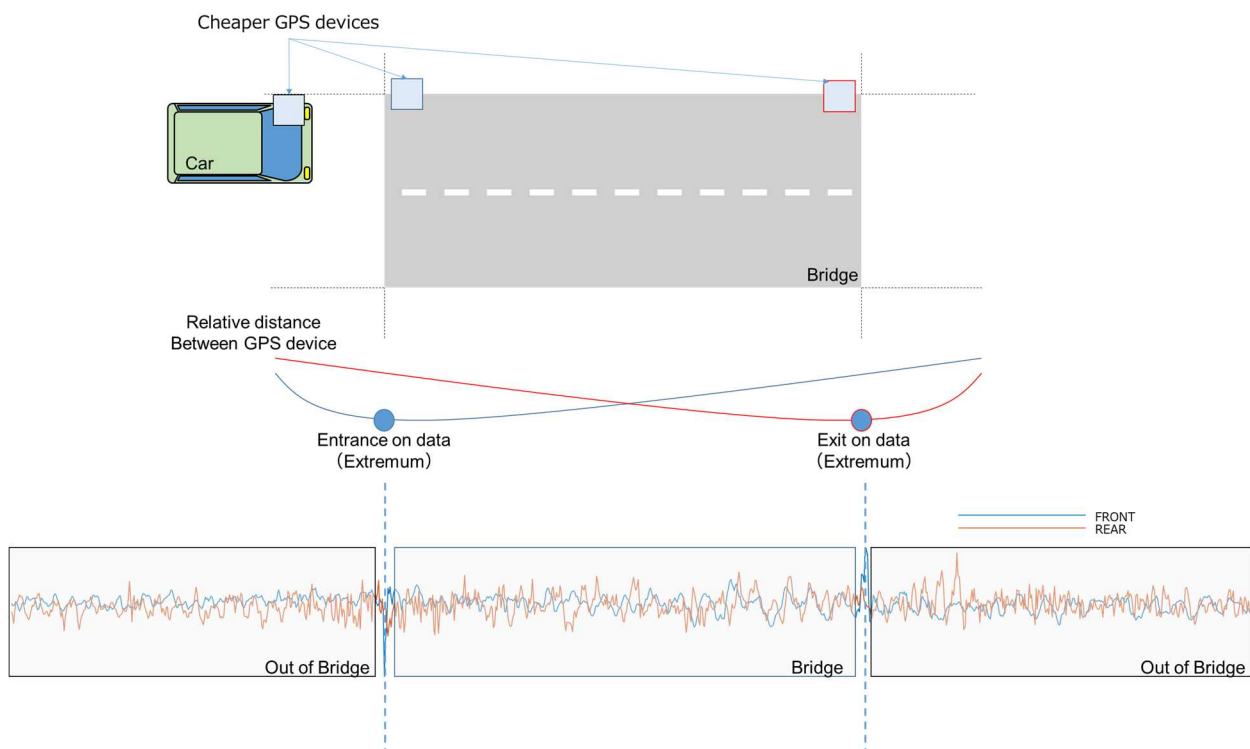


Fig. 1: The images on the extraction of vehicle acceleration over bridge and training LSTM

Table. 1: The parameter of bridges and vehicle

	PC1	PC2	PC3	S1
径間長 [m]	12.6	14	30.88	30
桁種および桁数	I	T, 4	T, 4	I, 4
車両重量 [t]	13.8			




Fig. 2: The position of sensors on vehicle




Fig. 3: The acceleration on vehicle wheels (Front: orange, Rear :blue) on each bridges

Table.2 Training Parameter

入力加速度	前輪鉛直
潜在変数	200
学習率	0.001
学習回数 (S1 のみ)	1500(2500)
クラス重み	1 : 3

Table. 3: The score on training and inference

	Training Data	Final Training Accuracy [%]	Final Training Loss	Test Data	Test Accuracy		Test Accuracy Mean [%]
					Max. [%]	Min. [%]	
PC1	5	82.7	0.0113	16	95.7	34.8	66.9
PC2	5	75.6	0.0121	4	73.7	54.2	64.3
PC3	5	90.9	0.0746	4	92.5	45.8	74.1
S1	5	98.3	0.0358	5	96.9	84.8	91.4




Fig. 4: Training curve and inference result with the best or worst accuracy on Model.1

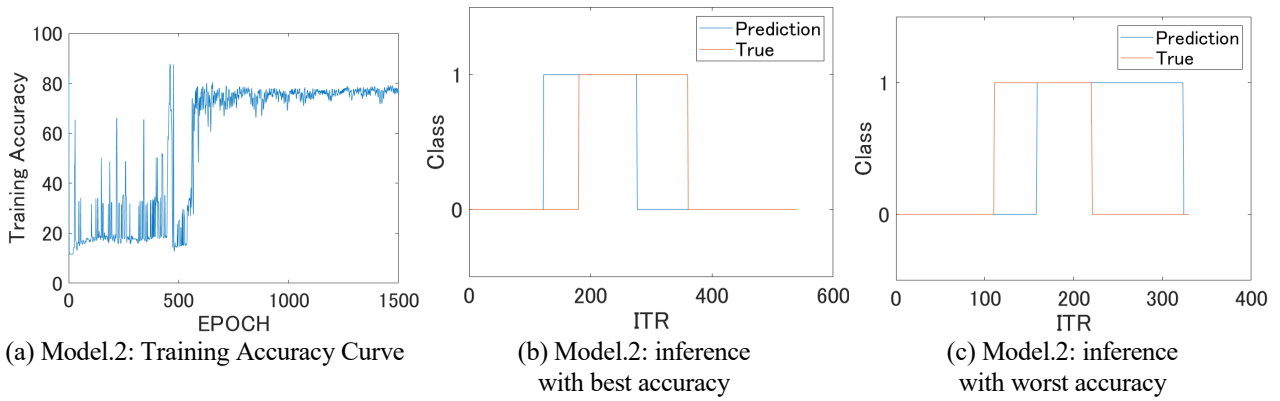


Fig. 5: Training curve and inference result with the best or worst accuracy on Model.2




Fig. 6: Training curve and inference result with the best or worst accuracy on Model.3




Fig. 7: Training curve and inference result with the best or worst accuracy on Model.4

4 考察

各 Model で得られた結果に対し、データ長および正解率に寄与した学習データを推論データとの波形と相関に基づき評価する。これに基づき、提案技術の実環境での可用性について考察する。

4.1 データ長

LSTM を用いた Seq-to-Seq の学習において、データ長は学習データ数を意味するため、特徴量の学習に十分長い必要がある。橋長および車両速度にも依存するため、橋梁諸元や周辺の交通状況を含む計測環境によってデータ群は異なる特徴を持つと考えられる。各 Model の推論正解率の平均値を Table.3 に示す。Model.1, 2 (橋長 12.6, 14m) に対し、データ長が長くなりやすい

と考えられた Model.3, 4 (橋長 30.88, 30m) の平均値がより高くなっている。この結果に基づくと、Model.2 については、橋長がより短い Model.1 に対しても最高正解率が低いため、車両速度のばらつきや計測環境が特異的であると考えられる。これら条件は、データそれぞれの波形に現れると考えられるため、次に学習・推論データ間の波形およびその相関について考察する。

4.2 学習・推論データ間の相関

各 Model で得られた推論結果の内、正解率最高・最低の結果について、波形と真値を併せて Fig.8 に示す。青線は入力した加速度波形を示し、橙線は分類クラスの真値(橋梁外:0, 橋梁上:1)を示す。すなわち、橋梁上のデータとして抽出する精度が、学習・推論に与える影響を評価する。まず、平均正解率の高かった Model.3 および Model.4 について、正解率最高の波形について

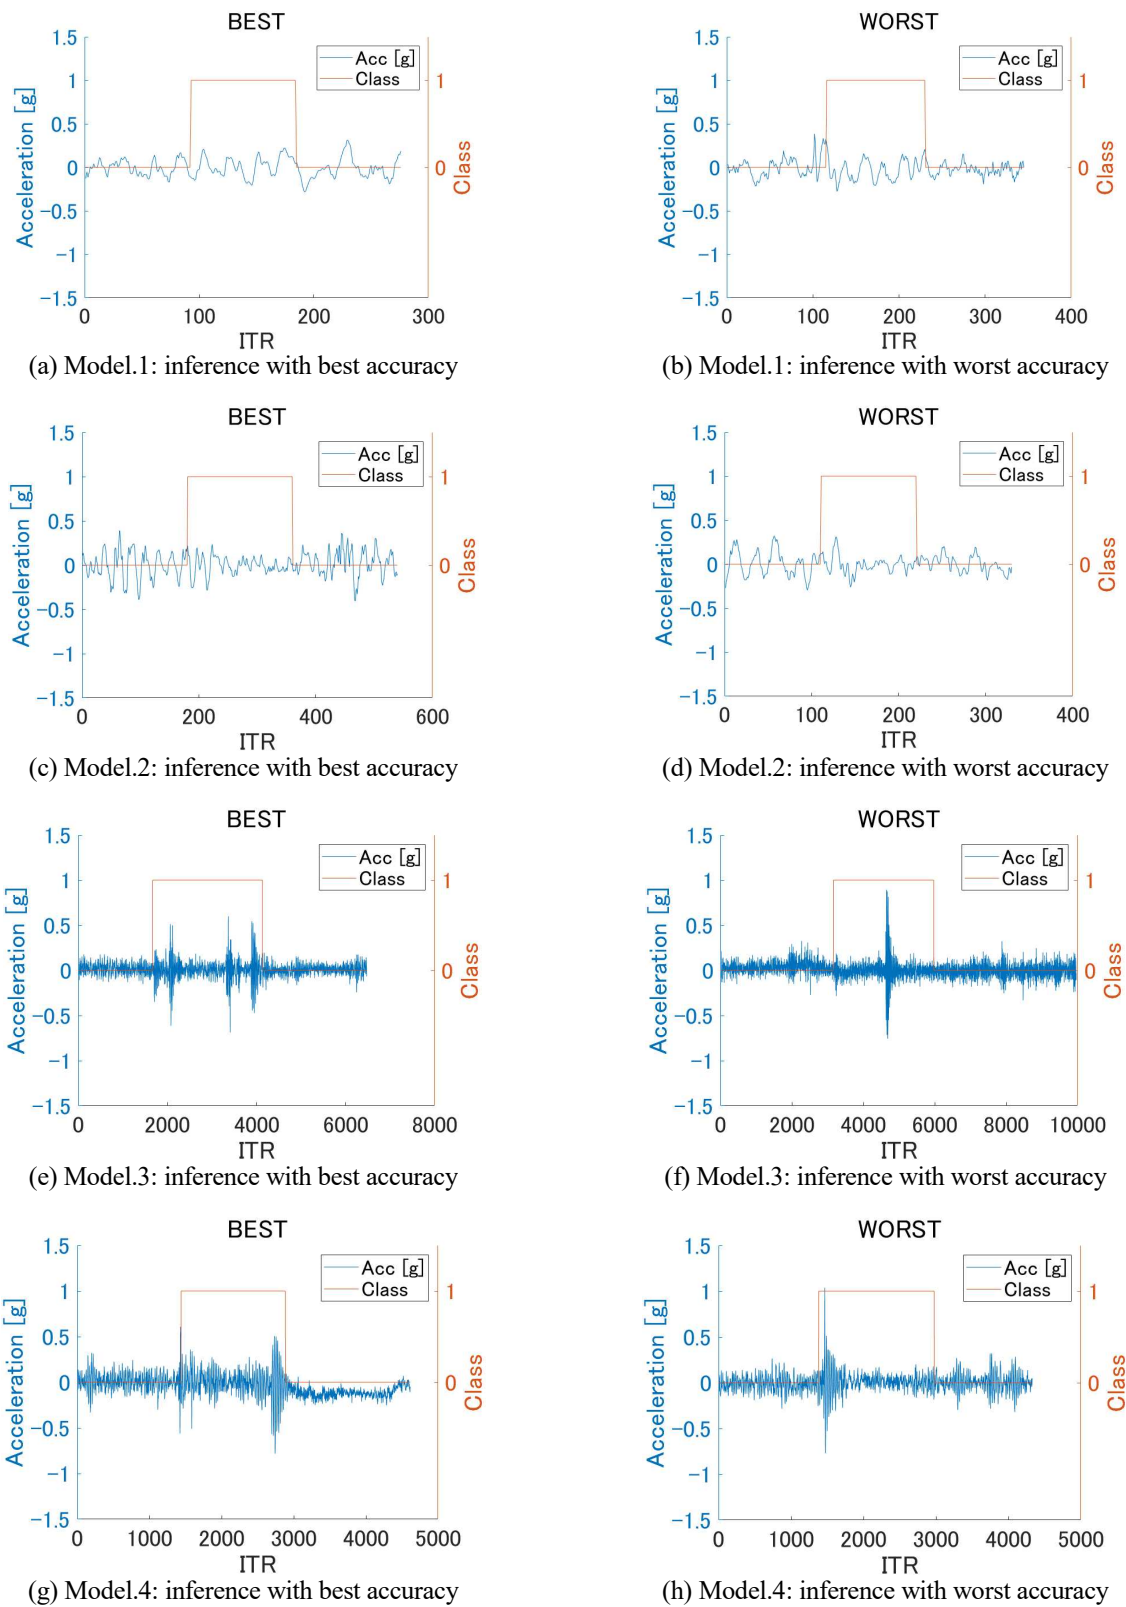


Fig. 8: The acceleration and truth on the best or worst inference result of each models

は、大きなピークが2つあり、正解率最低の波形については1つのみであることが分かる。これらの波形ピークは橋梁端部のジョイント付近で発生しており、既往研究⁸⁾でもこれらが学習・推論精度の向上に大きく寄与する可能性が示唆されている。Model.1については正解率最高・最低ともに同様の波形を持っているのに対し、Model.2については正解率最高・最低での波形

は大きく異なることが分かる。このような結果は、学習に用いた橋梁(PC1, PC2)の周辺環境が異なることが考えられる。PC1は交差点から離れており、露出したジョイント部分はないが、橋梁前後に路面の凹凸が存在した。これに対し、PC2は露出したジョイント部を持つが、交差点に近く、交通状況の影響を受けたため、車両速度が大きく異なることが多かった。したがって、

データが持つ特徴量の一つである波形が一定しないなど大きくノイズを含み、また速度変化によってGPSを用いたデータ抽出に影響があったと考えられる。特に、橋長の短い橋梁を対象にGPSを用いたデータ抽出を行う場合、その誤差は相対的に大きくなるため、今回Model.2において正解率が低くなったことが示唆される。ただし、橋梁上と思われるデータ範囲をある程度特定できれば、本技術を用いるスクリーニング手法においては補完可能な技術¹²⁾があるため、後処理によっては十分可用性を有すると期待できる。

5 まとめ

本研究は車両を用いたDrive-by点検や橋梁スクリーニング技術の社会実装に向けて課題となる、連続的な車両加速度データから橋梁上データを抽出することに対し、抽出AIの学習・推論とデータ分析により、提案する抽出AIがGPSに基づく大まかに抽出データを補完可能か、実環境での可用性を確認した。橋梁端部と車両に設置したGPSデバイスの相対距離を用いて、橋梁上と考えられるデータ範囲を大まかに切り出し、LSTMを用いて橋梁上データを精度良く抽出し、補完する提案手法が適用可能か、実橋梁で行った実験データに対し検証を行った。検証により、以下知見を得た。

- 1) 橋梁端部と車両に設置したGPSデバイスの相対距離を用いて、橋梁上として大まかに切り出したデータをLSTMで学習した。Model.2を除き、学習時の正解率は90%を越え、学習が収束した。
- 2) 未学習のデータに対し推論を行った結果、Model.2を除き、最高正解率90%以上で推論可能なことを確認した。また、橋長が長く、露出したジョイント部などで生じるピークがあると正解率が高まることを確認し、橋長の短い橋梁においてはGPSの位置捕捉誤差が原因と考えられる波形の違いによる影響が大きくなる可能性を確認した。
- 3) これらの結果から、本技術を用いるスクリーニング手法においては補完可能な技術とともに、信号分析技術を用いた前・後処理によれば、本技術が実環境においても、十分可用性を有すると期待できる。

今後は今回抽出したデータを基に、空間特異モード角度(Spatial Singular Mode Angle: SSMA)を用いた橋梁スクリーニングの実践的検証を行う。また、本技術のさらなる高度化手法として、高精度GPSデバイスと衛星データを用いた、橋梁上のGPSデバイスを省いた手法の可用性検証や、すべてのデータを学習した橋梁を問わない汎用モデルの可能性検証を行う。

参考文献

- 1) 国土交通省 道路局 国道・技術課: 橋梁定期点検要領, 2019.
- 2) 国土交通省: 点検支援技術性能カタログ, 2021.
- 3) 閣議決定: デジタル社会の実現に向けた重点計画, 2021. https://cio.go.jp/sites/default/files/uploads/documents/digital/20211224_policies_priority_package.pdf
- 4) For example, A. Malekjafarian, C.W. Kim, E. J. OBrien, L. J. Prendergast, P. C. Fitzgerald, S. Nakajima: Experimental Demonstration of a Mode Shape-Based Scour-Monitoring Method for Multispan Bridges with Shallow Foundations, *Journal of Bridge Engineering*, 25(8), 04020050 - 04020050, 2020
- 5) 例えば, 首都高速道路他, 「インフラドクター」 <https://www.shutoko-eng.jp/technology/pdf/infdr.pdf>
- 6) スマートシティ技術研究所, 「GLOCAL-EYEZ」 <http://intro-jp.smc-road.com/>
- 7) 例えば, 高橋悠太, 山本亨輔, 岡田幸彦: 空間特異モード角度を用いた比較的軽度な橋梁損傷検知の可能性検討, 構造工学論文集, Vol. 65A, pp.283-292, 2019.
- 8) R. Murai, R. Miyamoto, K. Yamamoto and Y. Okada: Numerical Experiments of Bridge Position Estimation for On-Going Monitoring, *Proceedings of the World Congress on Engineering 2019*, pp.1-6, 2019.
- 9) F. A. Gers, J. Schmidhuber, and F. Cummins: Learning to forget: Continual prediction with LSTM, *Neural Computation*, vol. 12, no. 10, pp. 2451–2471, 2000.
- 10) X. Shi, Z. Chen, H. Wang, D.Y. Yeung: Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting, *arXiv:1506.04214v2 [cs.CV]* 19 Sep 2015.
- 11) R. Shin, Y. Okada, and K. Yamamoto: Application of C-LSTM Networks to Automatic Labeling of Vehicle Dynamic Response Data for Bridges, *Sensors*, 22(9), 3486, 2022.
- 12) Y. Takahashi, and K. Yamamoto: The application of drive-by bridge damage detection based on continuous SSMA to the field experimental data, *International Journal of Lifecycle Performance Engineering*, 3(3-4), pp.310-330, 2019.