

# GPSに基づく VVoB を補正する AI の可能性検証

高橋 悠太<sup>1</sup>・金子 直樹<sup>2</sup>・秦 涼太<sup>2</sup>・山本 亨輔<sup>2</sup>

<sup>1</sup>正会員 八千代エンジニアリング技術創発研究所 AI解析研究室  
(〒111-8648 東京都台東区浅草橋 5-20-8 CSタワー 3F)  
E-mail: yt-takahashi@yachiyo-eng.co.jp (Corresponding Author)

<sup>2</sup>正会員 筑波大学 (〒305-8577 茨城県つくば市天王台 1-1-1)  
E-mail: s2220837@u.tsukuba.ac.jp  
s2130108@u.tsukuba.ac.jp  
yamamoto\_k@kz.tsukuba.ac.jp

センサーによる橋梁デジタルツインの構築において、重要な長大橋に対して中小径間橋では相対的に高コストになると考えられる。本研究では橋梁に高価な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(VVoB: Vehicle Vibration on Bridge)は、連続データから抽出する必要があるため、橋梁端部と車両に設置した安価な GPS 機器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 でその位置推定誤差を補正可能か検証する。本実験では 4 橋梁(PC3 橋、鋼橋 1 橋)を対象に計測実験を行い、学習した AI の推論結果を分析した。学習が困難であったモデルに対しても、信号分析技術を用いた後処理による正解率改善を確認し、データ蓄積と再学習による橋梁デジタルツイン構築・更新の可能性を、実データを用いた検証により示した。

**Key Words:** Drive-by Inspection, Vehicle Response Analysis, LSTM, GPS

## 1. 背景

土木分野、特に橋梁におけるデジタルツインとは、デジタル空間上に物理空間で得られたデータを投影・モデル化し、得られた分析結果を現実空間において反映させる、Cyber Physical System (CPS)の構築といえる。計測から CPS の構築・更新までを考えたとき(図-1)、①得られたデータと物理空間とを紐づける(例えば基準点座標)定義、②機器性能設計を含めた計測技術、③過去の計測データを含めたデータの整合性を評価する技術(本研究のねらい)、④CPS の妥当性を評価し、システムから得られた結果を評価・反映する技術、これら改善サイクルが実用上求められ、また従来のアナログ手法と比した精緻化・

省力化・効率化が期待される。

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<sup>注1)</sup>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<sup>注2)</sup>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ている。また、目視を前提とする規制の緩和も閣議決定されている<sup>注3)</sup>。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<sup>注2)</sup>。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(VBI: Vehicle-Bridge Interaction)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<sup>1)</sup>。橋梁振動は



図-1 車両-橋梁間相互作用システムとデジタルツイン

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、センサーを個々橋梁に設置する必要がなく、路面の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。

路面評価技術のみについて注目すれば、画像や3次元データを用いた手法(ドクターインフラ)<sup>2)</sup>、加えて振動データを用いた手法などが挙げられる(Glocal-eyz)<sup>3)</sup>。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<sup>2)</sup>。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、本研究では橋梁上で得られたと考えられる車両振動データをVVoB(Vehicle Vibration on Bridge)と定義し、連続した車両振動データからVVoB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デバイスを搭載して位置情報を付与し、方法を問わず橋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。本研究では、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点に注目し、従来精度の安価なGPSデバイスを複数利用し、車両と橋梁端部とに設置したデバイスの相対距離を

算出・利用することで、車両入退出の推定する手法を考える。将来的にRTKなどの高精度デバイスの価格は低下した場合、安価なデバイスを用いる本手法は代替される可能性がある。ただし、完全自動運転やIoTセンサーがあらゆる空間に設置された社会においては、GPSに接続されたIoTセンサーなどとの相対距離から、安価で高精度なRTKのように振る舞い、その位置情報を知らせる電子杭<sup>6)</sup>のような手法が予想されるため、本技術の精度検証で得られた知見は未だ有効と考えられる。

正解となる位置情報は本来測量で決定され、GPSの推定誤差も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。このため、繰り返し走行して得られたデータについて、それぞれの位置を同期・補正する必要がある。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<sup>3)</sup>。本研究ではLSTM(Long-Short Term Memory: 長短期記憶)<sup>4)</sup>に着目する。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-LSTM<sup>5)</sup>を用いた。

実験データを用いた研究<sup>6)</sup>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。本研究では比較的高い量子分解能を要求すると考えられるSSMA技術への適用を考え、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いことや、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、VVoBを抽出、教師を付けて学習させる(図-2)。

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、繰り返し学習を用いることで、GPSの位置推定誤差を補正し、橋梁上で得られた振動データが抽出可能と考えられる。実際に計測が定期的に繰

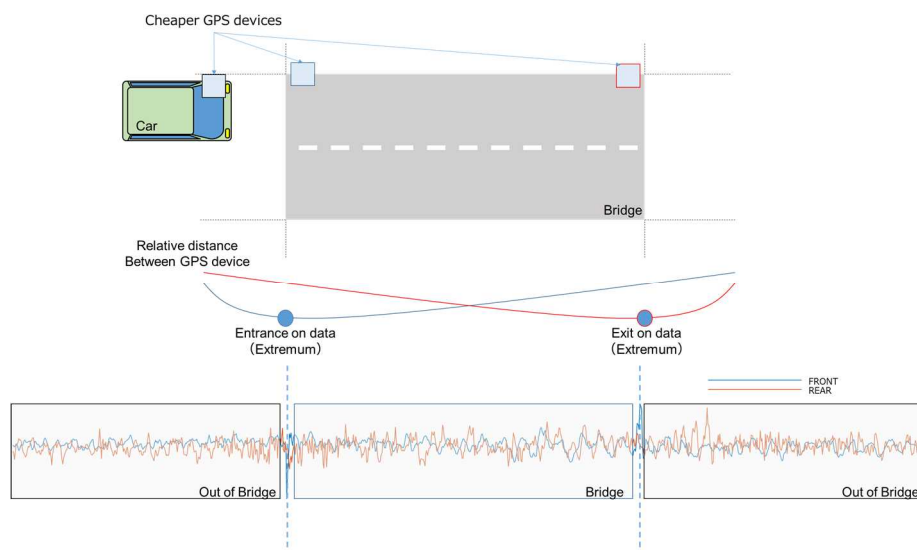


図-2 橋梁上振動データ抽出の概念図と LSTM の学習データ模擬図

り返される時、それぞれのデータ整合性を高めることは橋梁健全性を評価する上で判定誤差の低減につながる。そのため、抽出 AI モデルにより正確な教師データを与えることが求められる。本研究のような従来精度の GPS 機器を用いた場合、短い径間長の橋梁においては誤差の影響が大きくなり、また学習に用いるデータ長も短くなりやすいと考えられる。推論に用いるデータを教師データと例えば相互相関などに基づいて比較・補正することで推論精度が向上すれば、同様に過去データを含めたデータ群を補正・再学習することで高精度の抽出が可能なモデルが得られ、過去データとの整合性を高められる。

本研究は教師データ群と推論結果の良くなかったデータの相互相関に注目し、再教師付けしたデータの推論結果を検証する。すなわち、本研究では車両振動の連続データから GPS 機器間の相対距離に基づいて抽出した VVoB を教師データとして用いる。学習は LSTM を Seq-to-Seq<sup>7)</sup>で行い、橋梁上で得られた振動を分類、抽出可能か検証する。特に、データ長が短くなりやすい短径間橋について、学習データと結果の良くなかった推論データの相互相関を算出し、推論データの教師付けを修正した場合において推論結果の変化を評価することで、誤教師付けの修正と過去データとの整合性を高め、推論性能が向上する可能性を検証する。

表-1 実験橋梁および車両諸元

	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
構造	PC	PC	PC	Steel
車両重量 [t]	13.8			

## 2. データの抽出と学習方法

### (1) データの抽出方法

学習データは橋梁端部・車両前輪上方に設置した 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、VVoB を抽出する。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(図-2)。実験データは2021年7月に交通規制なしで実施したデータを用いる。実験橋梁と車両諸元について表-1、図-3に示す。PC1, PC2 は比較的橋長が短いため、位置推定誤差の影響を受けやすく、PC 構造であるため剛であり揺れづらいためと考えられる。また PC3, S1 は比較的橋長が長く、特に S1 は鋼橋であるため、PC3 と比して揺れることが期待される。得られた加速度データは量子分解能が 24bit/センサー加速度レンジの絶対値相当を有する 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と、その FFT 結果(パワースペクトル)の内、50Hz 以下を図-4 に示す。青線は前輪、橙線は後輪を示す。前輪は 10Hz 前後、後輪は 20Hz 前後に最も高いピークを持ち、エンジン振動の影響等が考えられる。既往研究<sup>8)</sup>からこれらピークは VBI により変化し、また本実験データは従来と比較し、電子ノイズの影響を受けやすく、サンプリングレートも卓越振動数が比較可能な程高くないため、参考値とする。




図-3 車載センサーシステム設置位置

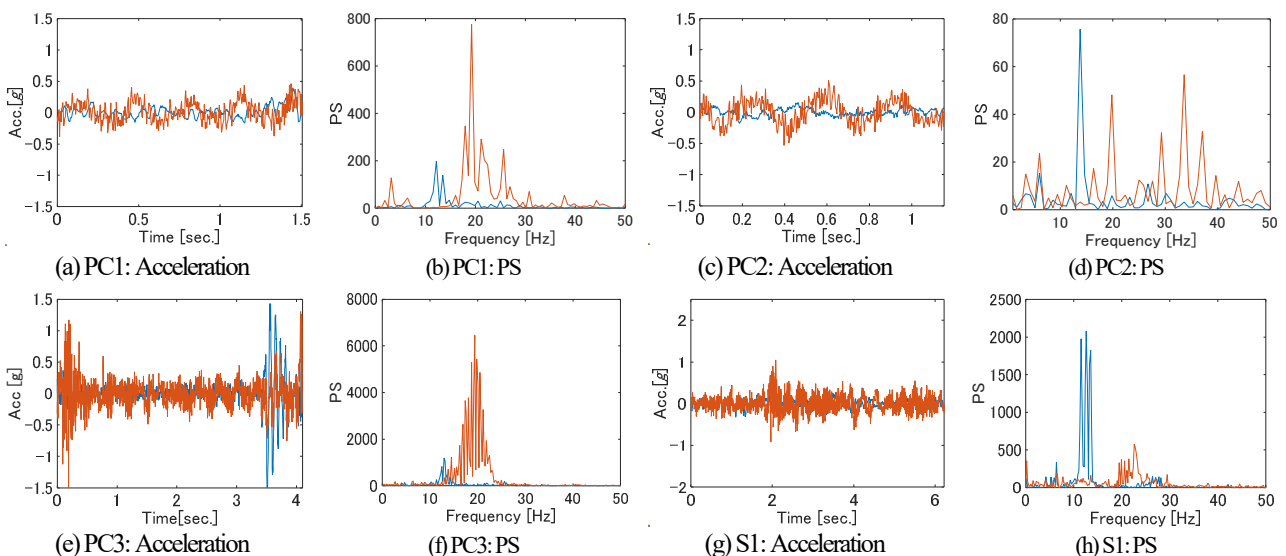


図-4 各橋梁上で得られた車両前輪(青実線)・後輪(橙実線)加速度振動とその FFT 結果

(2) 学習方法

LSTMはRNN(Recurrent Neural Network)の一種で、忘却機構を有する。Conv-LSTMと比較し、畳み込み構造を持たないことから、表現力が低下するが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-分類層とし、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、すべて一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機器の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を用いる。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。

表-2 学習パラメータ

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

表-3 学習・推論結果

	Training Data	Final Training Accuracy [%]	Final Training Loss	Test Data	Test Accuracy Max. [%]	Test Accuracy Min. [%]	Test Accuracy Mean [%]
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

3. 学習と推論結果

推論結果の内、正解率が最高・最低の結果を図-5に示す。また、表-3に最終正解率と損失を示す。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。最低正解率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。ただし、モデルが十分に学習できていると考え、この場合推論データの位置推定、すなわち教師付けが上手くいっておらず、推論で得られ

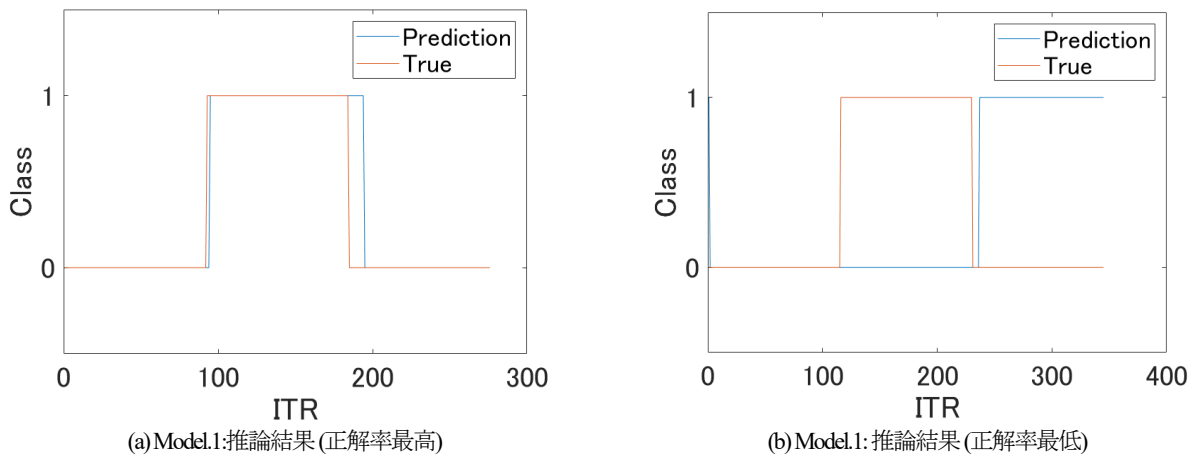


図-5 PC1学習モデルの推論結果(正解率最高および最低)

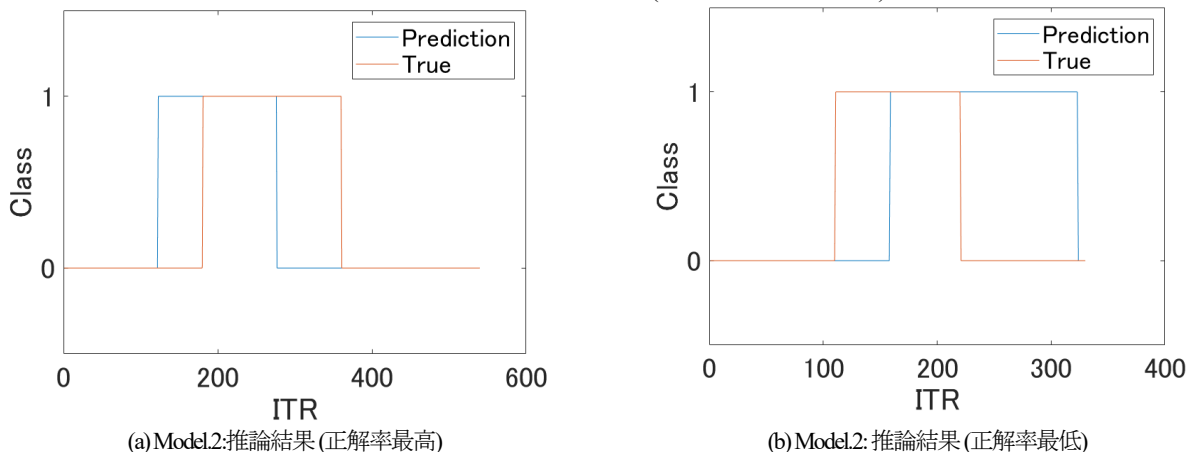


図-6 PC2学習モデル(Model.2)の推論結果(正解率最高および最低)

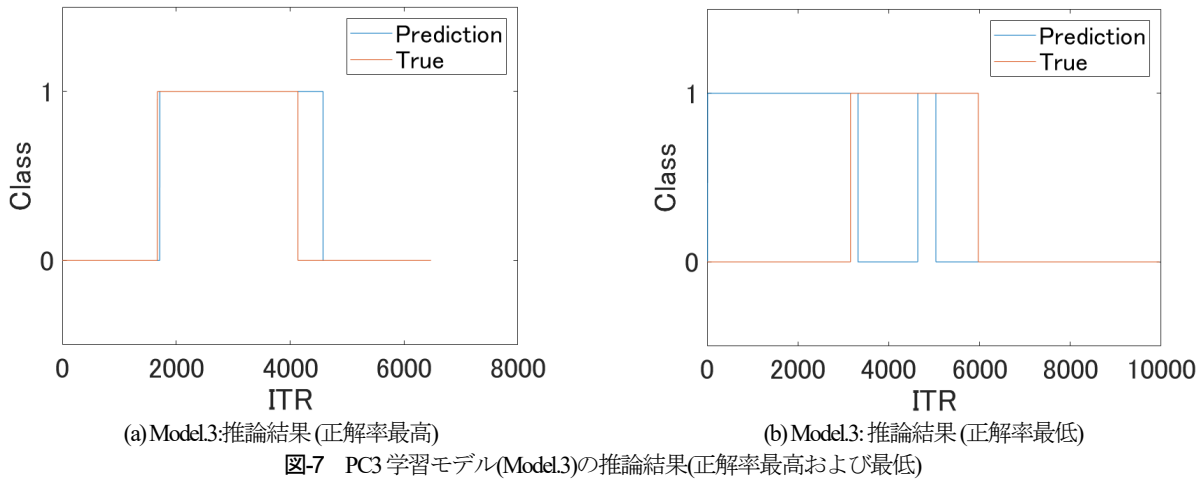


図-7 PC3 学習モデル(Model.3)の推論結果(正解率最高および最低)




図-8 S1 学習モデル(Model.4)の推論結果(正解率最高および最低)

た結果がより真である可能性が考えられる。

次に Model.2 推論結果の内、正解率が最高・最低だった結果について図-6に、最終正解率と損失を表-3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。

Model.3 の推論結果の内、正解率が最高・最低だった結果について図-7に、最終正解率と損失を表-3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、連続して同クラスと推論されるべきところ、クラス 0(橋梁外)の途中でクラス 1(橋梁上)に分類されている。これは特定の波形に強く反応している可能性がある。

Model.4 の学推論結果の内、正解率が最高・最低だった結果について図-8に、最終正解率と損失を表-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(表-3)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、最高・最低正解率それぞれデータの前半に一部クラス 1(橋梁上)と誤分類があったが、概ね成功していることが分かる。Model.3 および Model.4 について、波形について注目し、考察する。

#### 4. 考察

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 で得られた結果に対し、データ長を考慮した後、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。

##### (1) データ長

各 Model の推論正解率の平均値を表-3 Test Accuracy Mean [%]に示す。Model.1, 2 (それぞれ橋長 12.6m, 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。ただしこの結果に基づくとも、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ことが考えられる。これら条件は、データそれぞれの波形個々に現れると考えられるため、Model.2 について、相互相関を用いた再教師付けを行う。

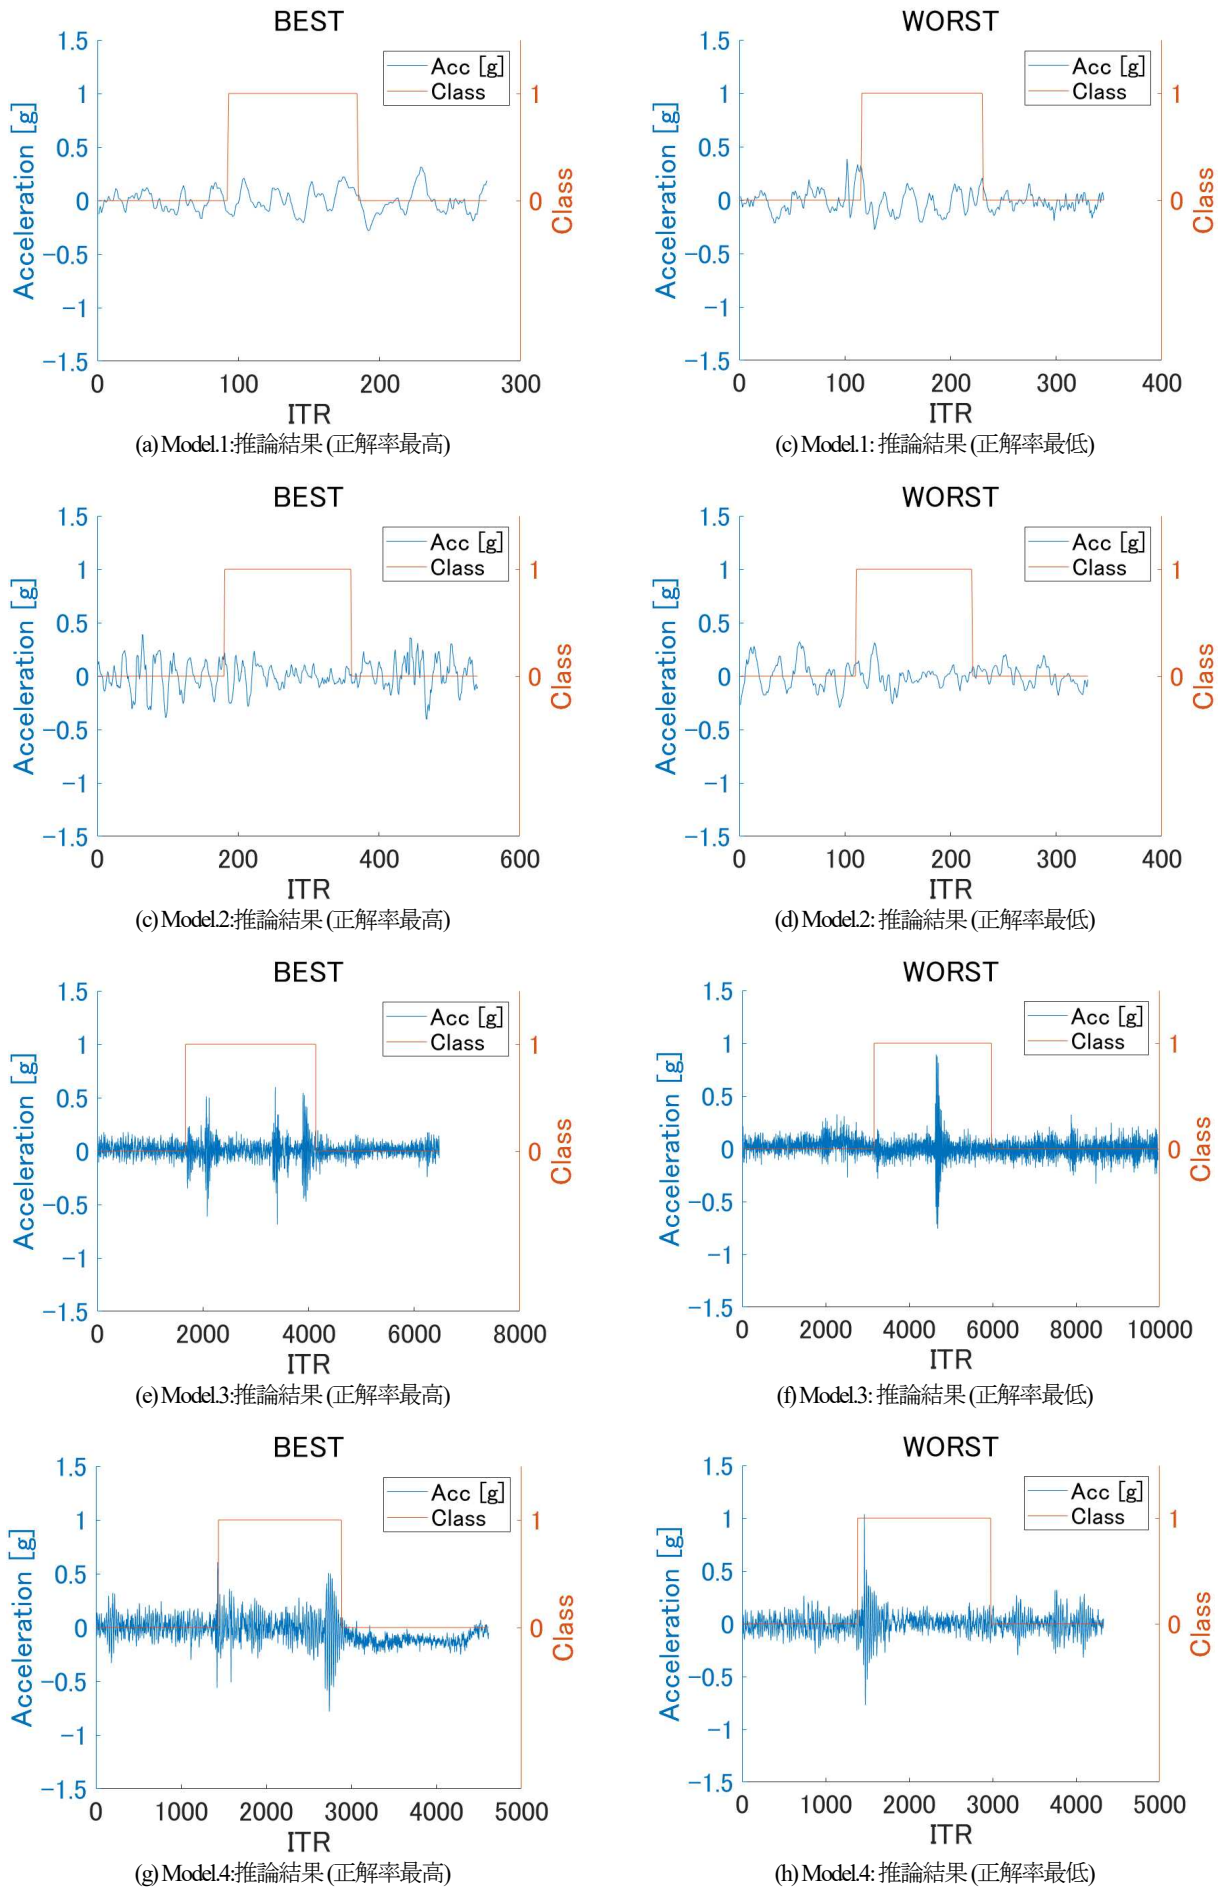


図-9 各 Model における正解率最高・最低ケース入力波形及び真値

## (2) 正解率に対する波形の特徴

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図-9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・推論に与えている影響を評価する. 平均正解率の高かった Model3 および Model4 について, 正解率最高の波形については, 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<sup>9)</sup>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. Model1, Model2 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 は交差点から離れた開けた田園地帯にあり, 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する. これに対し, PC2 は露出したジョイント部を持つが, 周辺に建物もあって交差点に近く, 交通状況の影響を受けたと考えられたため, 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本データ抽出手法を用いる場合, その誤差は相対的に大きくなるため, 今回 Model2 において正解率が低くなったことが示唆される. ただし, 本技術のように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補完可能な技術<sup>9)</sup>があるため, 最高正解率において生じたずれも含め, 後処理によっては可用性を期待できる.

## (3) 学習・推論データ間の相互相関

Model2において正解率最低のケース(Case.Worst)について, 学習データとの相互相関関数をそれぞれ計算し, 時刻ずれを基に再教師付けした場合, 正解率が改善するか検証する. これは学習データは真であるが, 推論に用いるデータのクラス(Original)が誤っている, すなわち GPS 位置推定誤差を補正したことを意味する. 学習データ 5 つに対する時刻ずれは表-4に示す. この時刻ずれは相互相関値を最大化するときのデータスライド量を用いている. このうち, データ長に対して時刻ずれが過大である5番目を除く4データとの時刻ずれを Case.Worst のクラスデータに反映し, 改めて推論する(図-10). 時刻ず

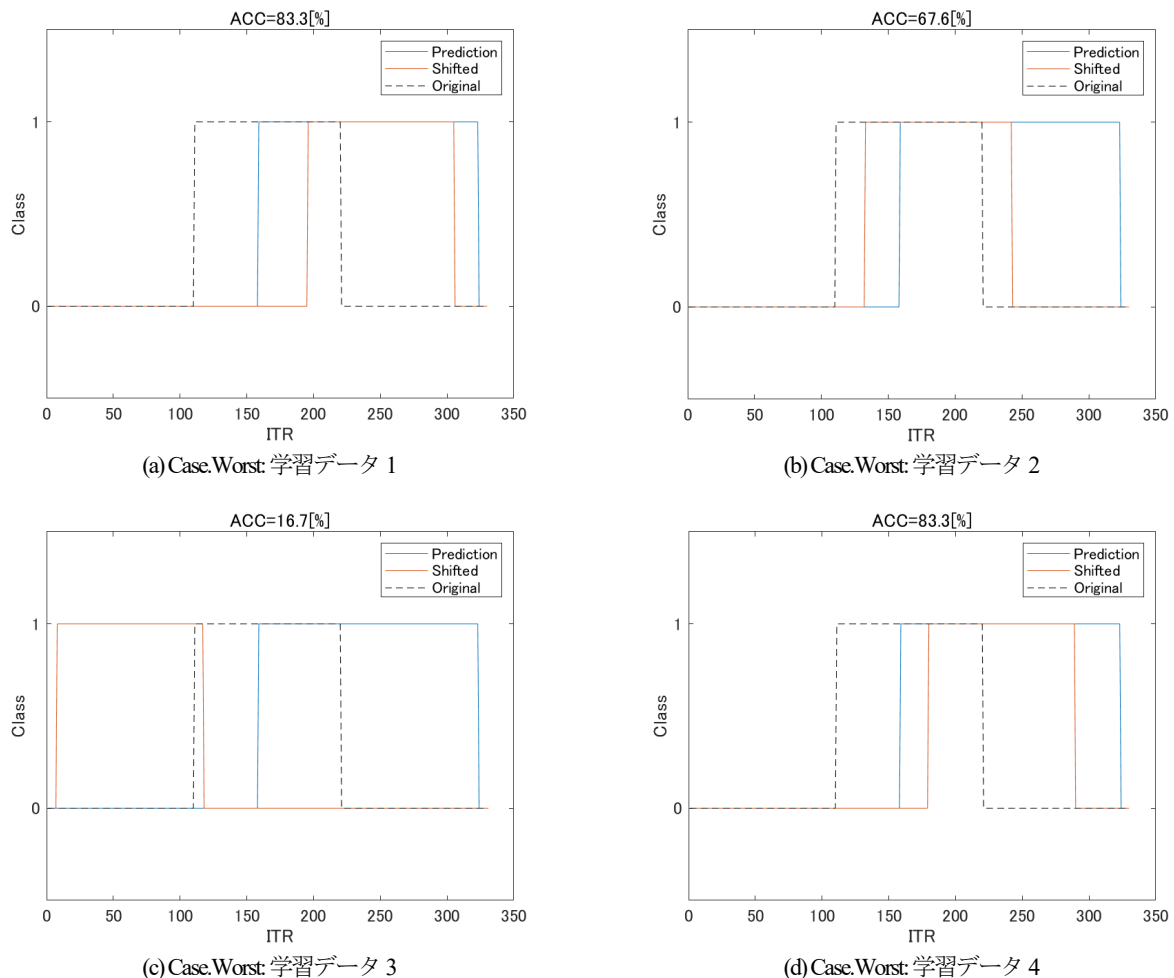


図-10 Case.Worst と Model2 各学習データとの相互相関関数に基づく時刻ずれ補正前後のクラスデータと推論結果

表-4 Case.Worst と学習データの相互相関関数に基づく時刻遅れ

学習データ番号	1	2	3	4	5
時刻ずれ [data]	85	22	-104	69	-2378
補正後の正解率 [%]	83.3	67.6	16.7	83.3	-
補正前の正解率 [%]			54.2		
補正後の正解率変化 [%]	+29.1	+13.4	-37.5	+29.1	-

れが正の場合、Case.Worst データが学習データに対して遅れており、負の場合は反対に先行している。補正後のデータを真値とし、Case.Worst の推論結果に対する各正解率を表-4 に、推論・補正後・補正前のクラスを図-10 にそれぞれ示す。図-10 において、青線(Prediction)は推論結果、橙線(Shifted)が補正後のクラス、黒破線(Original)が補正前のクラスになる。補正前が 54.2%だったのに対し、最大 83.3%まで向上する場合が確認できた。これは学習データすなわち過去データにおいて、橋梁上の範囲をある程度正しく捉えたデータが十分あれば、信号分析技術を用いた前・後処理により平均的な波形との比較から新しく抽出するデータの誤差を小さくすること、すなわち GPS デバイスの位置捕捉精度がある程度低くてもデータ抽出や再学習によるモデル改善が可能であることを示唆している。この改善効果は計測データの蓄積と再学習によって大きくなるのが期待できる。ただし、補正によって正解率が大きく低下した場合(図-9 (c))もあったため、用いる手法の機序と変化について、注意して用いる必要があると考えられる。

## 6. 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、連続的に得られた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に基づく大まかな抽出データを補正可能か、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、VVoB (Vehicle Vibration on Bridge) を大まかに切り出し、LSTMを用いてVVoBを精度良く抽出し、補正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。加えて、繰り返しデータを計測・再学習することで橋梁デジタルツインを改善できる可能性があるか、推論結果の良くなかった橋梁モデルの結果に対し、学習データとの相互相関による補正を加えた場合の推論結果について検証を行った。検証により、以下の知見を得た。

- 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。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、Model.2を含めて平均正解率60%以上で推論可能な場合があることを確認した。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。

- 2) 学習時の最終正解率・推論時の最高正解率が低かったModel.2に対し、推論時の正解率が最低だったデータと学習に用いたデータの相互相関関数から時刻ずれを算出し、推論の用いるデータを補正した場合、大きく正解率の改善がみられる組み合わせを確認した。これは学習データが真であるが、推論データの教師付けが誤っていた場合に補正したことに相当する。この結果から、信号処理技術に基づく前・後処理によって、新しく得られたデータの誤差を小さくする、すなわちGPSデバイスの位置捕捉精度がある程度低い場合に補正可能なことを確認した。
- 3) 橋梁上クラスをある程度の精度で抽出・教師付けした学習データが十分存在する場合、従来精度のGPS機器の相対距離を用いて抽出した計測データの蓄積と信号分析技術を用いた前後処理による誤差補正を加えて再学習することで橋梁デジタルツイン構築・更新の改善サイクルが実現する可能性を、実データを用いて確認した。

今後は今回位置補正した後のデータを基に学習し、推論結果の分析を行うほか、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と行う。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、GPS 情報を用いて速度変動による影響を抑えた検討を行う。



謝辞：本研究は JSPS 科研費 JP19H02220 および昭歴記念財団 2022 年度研究助成金の助成を受けたものです。

## NOTES

- 注1) 国土交通省 道路局 国道・技術課: 橋梁定期点検要領, 2019.
- 注2) 国土交通省: 点検支援技術性能カタログ, 2021.
- 注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/202111224\\_policies\\_priority\\_package.pdf](https://cio.go.jp/sites/default/files/uploads/documents/digital/202111224_policies_priority_package.pdf)
- 注4) 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/infr.pdf>
- 注5) スマートシティ技術研究所, 「GLOBAL-EYEZ」 <http://intro-jp.smc-road.com/>
- 注6) J-GLOBAL, 電子杭, 特開 2002-139321, 2002, [https://jglobal.jst.go.jp/detail?JGLOBAL\\_ID=200903094264543983](https://jglobal.jst.go.jp/detail?JGLOBAL_ID=200903094264543983)

## REFERENCES

- 1) 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
- 2) 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.
- 3) 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.
- 4) 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.
- 5) 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.
- 6) 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.
- 7) I. Sutskever, O. Vinyals, Q. V. Le: Sequence to Sequence Learning with Neural Networks, *arXiv:1409.3215v3 [cs.CL]* 14 Dec 2014.
- 8) 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.

(Received December 31, 2022)  
(Accepted January 31, 2023)

# THE VERIFICATION FOR AI EXTRACTING THE DATA OVER BRIDGE FROM VEHICLE VIBRATION DATA BASED ON GPS DEVICE CORRELATION DISTANCE AND THE FEASIBILITY STUDY OF THE IMPROVEMENT OF PREDICTION BY REANNOTATION BASED ON SIGNAL PROCESSING.

Yuta TAKAHASHI, Naoki KANEKO, Ryota SHIN and Kyosuke YAMAMOTO

Construction of bridge digital twins using sensors is considered to be expensive for small and medium-span bridges. This research focuses on drive-by inspection and bridge screening that estimate bridge vibration from vehicle vibration without installing expensive sensors on the bridge. Vehicle vibrations on bridges need to be extracted from continuous data, In this research, the data is extracted from the relative distance between the bridge edge and GPS devices installed on the vehicle, and it is verified that AI leraned them can correcte the position estimation error. In this experiment, the measurement on 4 bridges (3 PC bridges, 1 steel bridge) are carried out and the prediction results of learned AI is validated. For models that were difficult to learn, the improvement of the accuracy rate by post-processing using signal procescing technology are comfirmed. Therefore, the possibility of constructing and updating bridge digital twins by data accumulation and re-learning was verified using actual data.