

令和三年度 筑波大学工学システム学類卒業研究論文

車両振動中の橋梁上走行区間判別モデルの構築

学籍番号 201811095

氏名 金子 直樹

指導教員 山本 亨輔 

車両振動中の橋梁上走行区間判別モデルの構築

DEVELOPMENT OF A MODEL FOR DISCRIMINATING BETWEEN SECTIONS ON A BRIDGE DURING VEHICLE VIBRATION

金子 直樹

Naoki KANEKO

(指導教員 山本 亨輔)

Bridges, an important component of the transportation network developed in recent years, are facing problems due to aging. As a method of monitoring bridges using vibration, we installed sensors on vehicles and ran them over bridges to measure bridge vibration. Vehicle response analysis, a monitoring method using vibration, has been proposed as a method for managing aging bridges. Vehicle response analysis has been applied to damage detection and noodle pavement investigation, and research for social implementation is underway. However, the existing researches have analyzed only the section where the vehicle traveled on the bridge, and there is still a problem in identifying the bridge part of the measured vehicle vibration. In this study, we use a technique for estimating the bridge vibration from the measured vehicle vibration to estimate the section that passes over the bridge. In this paper, we apply the method studied by Shin et al. (2021) to the vibration data of vehicles traveling over multiple bridges. In this analysis, we were able to increase the correctness rate to 90% using data limited to bridges with one span. The results show that we have succeeded in estimating the bridge positions of some bridges, and it is expected that the social implementation of bridge monitoring technology using vehicle response analysis will become more realistic.

1 はじめに

1.1 研究背景

近年の発達した交通網において橋梁は、重要な構成要素である。橋梁の機能不全は交通網に大きな混乱をもたらす。我が国の橋梁は国土交通省の調査[1]によると、日本に 70 万基以上存在しており、2018 年 3 月時点で建設後 50 年経過した道路橋が約 25%であり、2030 年時点では約 58%にまで増加すると推計されている。これらの橋梁は潜在的な劣化のリスクにさらされており、その安定した構造性能の維持は、適切なモニタリングと保守作業が必要とされる。

このため、多くの構造物の損傷検知の効率的な技術が提案・研究されているが、従来の手法では橋梁のデータを収集するために固定センサを使用している。これらの手法の有効性は多くの研究で証明されているが、大都市圏にある全ての橋梁に手法を適用すると、センサ設置やデータ収集ネットワークの構築に膨大なコストと時間がかかる。従って、多数の橋梁にセンサを直接設置し損傷検知手法を適用することは現実的ではない。そこで、間接的な橋梁モニタリング手法として車両応答分析がある[2,3,4]。車両応答分析は、車両が橋

梁上を走行する際の車両-橋梁相互作用(Bridge-Vehicle Interaction :VBI)から橋梁応答を抽出し、橋梁特性を推定する。この手法は、橋梁を通過する車両にセンサを設置し、多数の橋梁をモニタリングすることができる。この手法を応用すれば、固定センサを橋梁に設置する必要がなくなり、橋梁点検にかかる人数を減らし、高頻度でモニタリングを行うことができる。

しかし、車両応答分析の社会実装には問題がある。その一つとして挙げられるのは、車両振動データに含まれる橋梁走行時の振動抽出である。既往の研究の多くでは、橋梁上を走行したデータのみを対象としており、車両振動データ中の橋梁上走行部分の特定は技術的課題である。この課題を解決する方法として、車両 GPS データに基づいて橋梁走行部分を推定する方法は考えられるが、サンプリングレートが低い為、正確に推定することは難しい。また、車両振動は路面凹凸の影響を強く受けるため、視覚的に橋梁位置を特定することはできない。そこで、本研究では複数橋梁を同時に走行し計測したデータを深層学習で学習させたモデルを構築する[5,6]。

1.2 既往の研究

1.2.1 橋梁振動成分抽出

車両応答から橋梁の特性を推定する車両応答分析を応用し、橋梁の損傷検知[7]、橋梁の進入退出位置の推定[5,6]などに应用されてきた。車両振動は車両速度や路面凹凸から影響を受けるだけでなく、測定ノイズ、環境ノイズなどの様々なノイズが含まれているため、橋梁振動の推定は難しい。その中でも、車両振動へ与える影響が大きいと考えられる路面応答の影響を除去する方法として、車両入力変位の差分を行う方法が提案されてきた。

山本ら(2011)[8]はモード解析理論に基づいて車両振動から橋梁振動を推定し、モード形状を推定する手法を提案した。この手法では、複数の車両が橋梁上を走行したときの加速度振動データおよび車体、路面の相対変位データを計測する。加速振動を数値積分し相対変位との差を求めれば、車両の強制変位入力から推定できる。ただし、複数の車両を等間隔、等速度で走行させる必要があり、実用化は難しい。

Wang et al. (2018) [9]は、実環境において、車両振動から橋梁の固有振動数の推定を行った。粒子フィルタ(逐次モンテカルロ法)を用いて、車両振動から入力プロファイルを推定する。入力プロファイルは、車軸位置における路面凹凸と橋梁振動の和で表される。車両が直進していると仮定すれば、位置同期した前輪と後輪位置の路面プロファイルは一致する為、前輪と後輪の入力プロファイルの差分を取ることで、橋梁振動成分を抽出することができる。この得られた橋梁振動成分から橋梁の固有振動数を推定した。

Murai et al. (2019) [6] では、入力プロファイルが直接計測できないことを指摘し、路面凹凸に類似しており、計測可能なばね下振動での路面凹凸の影響除去を検討した。検証は数値実験によって行われた。

1.2.2 橋梁位置判別

VBI(Vehicle-Bridge Interaction)は車両が橋梁を走行した際に起こる現象である。橋梁上に車両が進入すると路面凹凸と橋梁振動により、車両は揺らされる。その車両の揺れは接地点から橋梁を揺らし、橋梁の揺れがまた車両に伝わる。つまり、橋梁走行時の車両振動の違いはVBIが生じるかどうかである。

実環境下で計測した車両振動データは、地盤上走行

時と橋梁上走行時の2種類の車両振動データが含まれる。この車両振動は非定常データであるため、既存の時系列解析手法の多くは利用できない。そのため、近年計算機能力の向上により注目されている機械学習手法を用いて、ある一定区間の振動データを橋梁上とそれ以外に分類する判別手法の適用を考えた。今日の車両応答分析における機械学習手法を用いた研究は複数存在する。[6,10-15]

Cerda et al. (2014) [10]は、ラボ実験での複数車両の走行データから得られた周波数を用いて、橋梁の損傷を分類するためにサポートベクターマシンを用いた。路面の粗さ、周囲温度、車両特性などの要素に加えて、異なる損傷状態における手法の精度検証がなされた。Lederman et al. (2014) [11] ではこの手法を拡張し、主成分分析とカーネル回帰を用いて、橋梁の状態毎の詳細な橋梁損傷位置と深刻さの特定を可能とした。

Malekjafarian et al. (2019) [12] はニューラルネットワークとガウス過程で構成される”two-pass”機械学習アプローチを用いて車両応答の特徴から橋梁の損傷検知を行った。この手法では路面の粗さや測定ノイズがある状況下においても、軽度の損傷すらも検知することができる。

Lock et al. (2020) [13]は路面の粗さや車両の交通量、橋梁弾性率の温度変化等のノイズが含まれる車両橋梁相互作用システムにおいて、数値シミュレーションを用いて実用的な橋梁の健全性指標が得られるのかどうかを検証した。橋梁の損傷は単一箇所もしくは複数個所に損傷がある場合を想定している。橋梁の損傷は周波数を変化させるため、各ショア量の加速度応答に含まれる周波数のうち、各車両の加速度応答に含まれる周波数の内、3Hz から 10Hz の範囲の周波数の振幅値を抽出した。得られた周波数と周囲温度、車両速度、車台重量などのデータを用いて、畳み込みニューラルネットワークでの橋梁の損傷状態を予測した。得られた結果は、異なる 16 のシナリオにおいて 8 割以上の正解率を示し、車両応答分析における機械学習手法のノイズキャンセリング能力を明らかにした。

Cronin et al. (2020) [14] では、異なる 5 つの車両特性を持つ車両の複数回走行データと路面凹凸から、2 つのエンコーダを用いて車両特性と路面特性を潜在空間にプロットする手法を提案した。

Hekmati Athar et al. (2020) [15] では、橋梁のモニタリング手法として車両応答と橋梁応答の両方のデータを用いてニューラルネットワークを学習させた。トラス橋の模型の 3 つの位置に重量をかけ、その重量を変化させた時のその重量を推定するための教師あり学

習を行った。ラボ実験によって精度が検証され、橋梁の損傷検知への適用可能性を示した。

Shin et al. (2021) [6] では、複数の橋梁を走行した車両加速度データを使用して、C-LSTM を用いた 2 値分類教師あり学習を行った。実計測で得られた加速度データには環境ノイズや計測ノイズが多く含まれており、精度が高いとは言えないが橋梁位置を大まかに特定することはできた。しかし、橋梁長にかかわらず一律にウィンドウサイズを 1000 と定めており、学習される構造が橋梁長によって異なってしまっている可能性がある。また、分析に用いたデータは一回走行の入力プロファイルの差分を取ったデータのみを使用しているため、データ量と橋梁の種類に課題が残っている。橋梁走行時の車両振動データのラベル付けは、車両 GPS センサと Google Map の橋梁位置情報を照らし合わせラベル付けを行っている。GPS センサの位置情報の精度はそれほど高くないため、GPS センサの位置情報と Google Map の位置情報は必ずしも一致しない。このことから、橋梁走行時のラベル付けが正しく行っていない可能性が高い。

本研究では、Shin et al. (2021) [6] で提案された橋梁振動抽出技術を拡張し、車両振動の 10 点同時計測と、より精度の高い正解ラベルの比較を行う。

3 基礎数理

3.1 橋梁位置判別

Murai et al. (2019) [5] では、車両と橋梁の相互作用による影響を利用して、橋梁位置判別を行うことが可能であることを示した。つまり、橋梁上とそれ以外を通過する区間では、力学モデルの違いが観測データに影響している。この力学モデルに基づいた橋梁位置判別を行う場合、車両と橋梁の位置が既知であることが前提である。しかし、車両応答分析は実環境において橋梁振動を計測しないため、橋梁への車両進入タイミングと退出タイミングは推定しなければならない。

また、車両システムは車両振動に含まれるノイズが定常であれば定常線形問題となる一方で、VBI システムは橋梁の非線形な信号が入力されるため、非定常線形問題となる。しかし現在の技術レベルでは、非定常線形問題を評価することは困難である。橋梁位置判別には力学モデルに基づかない手法を適用しなければならない。

3.2 Recurrent Neural Network (RNN)

車両振動データは時間順序を追って取得される時系列データである。時系列データを分析する特徴として、各時刻のデータを独立したものとみなすのではなく、その時点のデータが以降のデータに影響を及ぼす可能性がある点である。一般的なニューラルネットワークでは、一点のデータを入力し、そのデータのみを考慮した出力が返される。つまり、以前の入力したデータを参照した学習をすることができない。これに対し、系列データを学習する手法として Recurrent Neural Network (RNN) [16] が挙げられる。RNN では、ある層の出力は次の層の入力として利用され、一般的なニューラルネットワークと同様に出力としても利用される。図に表わすと図-1 のようになる。

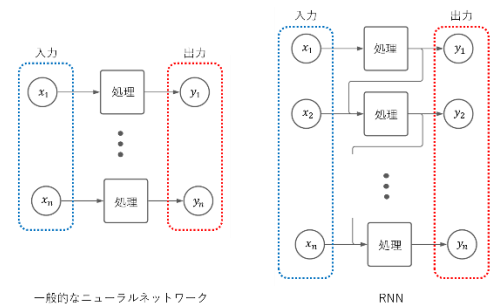


図-1 ニューラルネットワークと RNN の比較

RNN の学習は、一般的には誤差逆伝播法を用いる。誤差逆伝播法とは、出力層から得られた結果を正解ラベルと比較され、出力結果と正解ラベルの差である誤差を算出し、最小化することである。RNN の損失関数 L は、時間 $t = 1$ から $t = T$ までの全ての時間の誤差の総和であると考えられるため、ある時間 t の誤差を $L^{(t)}$ とすると、

$$L = \sum_{t=1}^T L^{(t)} \quad (1)$$

と表わせる。損失関数の値をより最小化する方法として、損失関数の勾配が用いられる。時間 t までの損失は、時間 t より以前の全ての時刻刻みの隠れユニットに依存する為、勾配は

$$\frac{\partial L^{(t)}}{\partial W_{hh}} = \frac{\partial L^{(t)}}{\partial y^{(t)}} \times \frac{\partial y^{(t)}}{\partial h^{(t)}} \times \left(\sum_{k=1}^t \frac{\partial h^{(t)}}{\partial h^{(k)}} \times \frac{\partial h^{(k)}}{\partial W_{hh}} \right) \quad (2)$$

と計算される。ここで、 $\frac{\partial h^{(t)}}{\partial h^{(k)}}$ は連続する時刻刻みの総乗として計算されるので、

$$\frac{\partial h^{(t)}}{\partial h^{(k)}} = \prod_{i=k+1}^t \frac{\partial h^{(i)}}{\partial h^{(i-1)}} \quad (3)$$

となる。しかし、損失関数の勾配を計算するときの乗法係数 $\frac{\partial h^{(0)}}{\partial h^{(i-1)}}$ により、勾配消失問題が発生する。

3.3 Long Short-Term Memory (LSTM)

RNN の勾配消失問題を解決する手法として、RNN の一種である Long Short-Term Memory (LSTM) が挙げられる。RNN は長期的な依存関係を学習することが難しいという点に対し、LSTM は長期の時間差に対しても学習することが可能なモデルである。LSTM は、RNN と同様に鎖状の構造を持つが、RNN における隠れ層に加え、入力ゲート、出力ゲート、忘却ゲート、メモリセルを持つことが特徴である。LSTM の構造の模式図は図-2 のようになる。

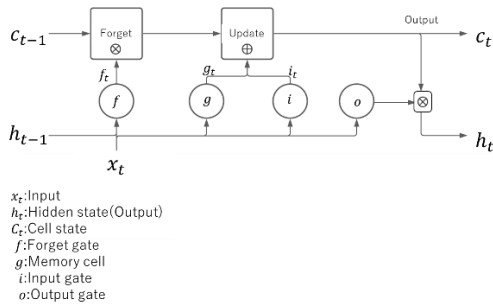


図-2 LSTM の構造

LSTM は、情報を削除、もしくは追加する機能を持っている。LSTM の最初のステップでは、セル状態(Cell state)から捨てる情報を判断する。判断する方法として忘却ゲート層(Forget gate)と呼ばれるシグモイド関数に、入力データ(Input)と隠れ状態(Hidden state)を入力することにより 0 から 1 の間の数値を出力する。ここでの 0 とは、セル状態を完全に取り除くことであり、1 はセル状態をそのまま維持するということである。また、隠れ状態 h_{t-1} は、前回の出力である。忘却ゲート層には入力データを線形変換するための W_f と隠れ状態を線形変換する R_f 、バイアス b_f が存在し、忘却ゲート層の出力 f_t は

$$f_t = \sigma(W_f \cdot x_t + R_f \cdot h_{t-1} + b_f) \quad (4)$$

となる。また、 σ はシグモイド関数を表しており、

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (5)$$

である。

次のステップでは、入力データの内の情報を

セル状態に保存するかを判定する。ここでは、入力ゲート層(Input gate)とメモリセル(Memory cell)に分かれる。入力ゲート層は、忘却ゲート層と同様にシグモイド関数に入力データと隠れ状態を入力し、計算した値を出力として返す。入力ゲート層内でも忘却ゲート層同様に入力を線形変換する為の W_i 、 R_i と、バイアス b_i が存在し、入力ゲート層の出力 i_t は、

$$i_t = \sigma(W_i \cdot x_t + R_i \cdot h_{t-1} + b_i) \quad (6)$$

となる。また、メモリセルでは $\tanh(\)$ を活性化関数とし、忘却ゲート層同様に、入力を線形変換する為の W_z 、 R_z と、バイアス b_z が存在し、メモリセルの出力 z_t は、

$$z_t = \tanh(W_z \cdot x_t + R_z \cdot h_{t-1} + b_z) \quad (7)$$

となる。

次のステップでは、古いセル状態 c_{t-1} を新しいセル状態 c_t へと更新する。(4)式で得られた忘却ゲートの出力 f_t と古いセル状態 c_{t-1} を要素ごとに掛け、忘れると判定した情報を消去する。また、(6)式と(7)で得られた入力ゲート層とメモリセルの出力を要素ごとに掛けることにより、新しいセル状態に更新する必要がある情報を抽出することができる。そして、新たなセル状態 c_t は

$$c_t = (c_{t-1} \otimes f_t) \oplus (i_t \otimes z_t) \quad (8)$$

と表わすことができる。

最後のステップとして、新たな隠れ状態である出力を判定する。ここでも忘却ゲート層同様に、出力ゲート層(Output gate)に入力データ x_t と、隠れ状態 h_{t-1} を入力し、忘却ゲート層内にある線形変換を行う為の W_o 、 R_o と、バイアス b_o により出力ゲート層の出力 o_t は、

$$o_t = \sigma(W_o \cdot x_t + R_o \cdot h_{t-1} + b_o) \quad (9)$$

となる。この出力ゲート層の出力と、(8)式で得られた新たなセル状態 c_t を $\tanh(\)$ で活性化させた値を要素ごとに掛けることにより、新たな隠れ状態であり、新たな出力データである h_t は、

$$h_t = o_t \otimes \tanh(c_t) \quad (10)$$

となる。

LSTM は、各時刻で学習させたときの出力結果と、セル状態というこれまでの入力データの傾向を更新もしくは消去していく。これにより、系列データに含まれる長期的な傾向を効率よく保存することが可能である。

3.4 Convolution LSTM (C-LSTM)

本研究では、橋梁位置判別の手法として

Convolution-LSTM(C-LSTM)を採用した。C-LSTMはConvolution Neural Network(CNN)とLSTMの組み合わせである。CNNとLSTMの組み合わせは空間的特徴と時間的特徴を掴むために研究されてきた(Zhou et al.,2015)[5]。C-LSTMを数式に表わすと、LSTMの線形演算を畳み込みに置き換える為、式(4)、式(6)、式(7)、式(9)は、

$$f_t = \sigma(W_f * x_t + R_f * h_{t-1} + b_f) \quad (11)$$

$$i_t = \sigma(W_i * x_t + R_i * h_{t-1} + b_i) \quad (12)$$

$$z_t = \tanh(W_z * x_t + R_z * h_{t-1} + b_z) \quad (13)$$

$$o_t = \sigma(W_o * x_t + R_o * h_{t-1} + b_o) \quad (14)$$

となる。

本研究におけるC-LSTMモデルはKim & Cho(2018a)[17]とKim & Cho(2018b)[18]を参考にしており、ConvolutionとActivation, Pooling, LSTM, Dense Networkによって構成されている。Convolution層とPooling層からなるCNNは二層であり、ActivationにはHyperbolic Tangentが利用される。LSTMの隠れ層は200とし、畳み込み層ではフィルタサイズを32としたフィルタを96個使用した。初期の学習率は0.001とし、正規化係数を0.0001とした。学習率は12エポックずつ0.75倍ずつ減らして

いく。最大エポック数に達した時を学習完了とし、最大エポック数を120とした。

4 実環境実験

4.1 橋梁

本研究は、7月に筑波大学構内の松美橋、大学周辺の4橋梁を対象とする実環境計測を行った。また、12月に土浦市周辺の20橋梁を対象に実環境計測を行った。本研究では一径間の橋梁かつ計測に成功した8橋梁における走行データを分析に用いる。各橋梁の諸元を表1にまとめる。橋梁にはGPSセンサを入口に2点、出口側に2点設置した。センサ設置例を図-3に示す。橋梁に設置されたGPSセンサは、橋梁の入口と出口の電子基準点であり、位置情報と時刻情報を記録し続けた。

4.2 車両

車両は、日野製KL-FE1LEAのシングル1軸車両で、車両重量6.8t、積載時最大総重量は13.8tを用いる。この車両は、計12点の加速度センサを設置した。それぞれのセンサ設置位置は、加速度センサがばね下の前輪と後輪にそれぞれ2点ずつ

図-3 橋梁センサ設置位置




図-4 車両センサ設置位置




表1 対称橋梁諸元

橋梁名	橋長[m]	建設年	判定区分	種類	走行回数 [回]
松美橋	30.9	1973	I	PC	17
白幡橋	14.0	1978	I	PC	19
高丸橋	12.6	1957	II	PC	3
白鷺橋	11.8	1975	II	RC	17
中家橋	12.5	1989	II	RC	6
備前川9号橋	13.6	不明	II	鋼製	9
天王橋	37.0	1974	III	PC	3
真鍋橋	16.0	1994	I	鋼製	5

表2 使用した MEMS センサ部品一覧

部品名(型番)	基本性能	説明
FPGA 評価ボード (ZYBO Zynq-7010)	デュアルコア ARM Cortex-A9 と FPGA を統合した評価ボード. XILINX 社製の FPGA である Zynq-7010 を搭載し, 270KB の RAM と最大 1GHz の動作周波数を持つ.	加速度センサとは 300Hz で I2C 通信を行い, GPS センサとは UART 通信を行う.
デジタル 加速度センサ (ADXL 355)	Analog Devices 社製の超低ノイズ 3 軸加速度センサ. デジタル出力で測定レンジは $\pm 2G$, $\pm 4G$, $\pm 8G$ でプログラムにより変更可能.	車両ばね下に 4 点, 車両ばね上に 5 点設置.
絶縁型 I2C 延長モジュール (LTC4331)	Analog Devices 社製の I2C エクステンダー. 延長ケーブルには LAN ケーブルを使用. 電源は 3V から 5.5V で I2C の通信レートは最大 1MHz.	加速度センサデータを, FPGA に 5m 以上伝送する.
GPS センサ (AE- GYSFDMAXB)	太陽誘電製の GPS 受信キット. 搭載チップは GYSFDMAXB で更新レートの最大値は 10Hz.	衛星内の原子時計をもとに発せられる正確な 1Hz のパルスを出力する 1PPS 機能付き.

設置し, ばね上にもそれぞれ 2 点設置した. また, 車両の重心に当たる点に右左 2 点設置した. さらに, タイプの違う加速度センサをばね下の左側に 1 点ずつ設置した. GPS センサは, 前輪と後輪の真上に当たるばね上に各 1 点設置した. 車両に設置したセンサ位置を図-4 に示す.

4.3 加速度計測システム

本研究では実橋梁試験において車両の振動をそれぞれ時刻同期したうえで計測するための MEMS センサを用いた計測システムを使用した. センサの構成は以下の表 2 の通りである.

車両に搭載した加速度計測システムは, 加速度センサで計測した加速度データを制御用 PC に保存するシステムである. 各センサはデータ処理用の FPGA ボードにつながれており, FPGA ボードは車内に設置したポータブル電源とデータ記録用のノート PC に繋ぐことにより計測を開始する. センサデータは逐次ノート PC に記録される.

記録用のノート PC では, Python のシリアル通信パッケージである pySerial を使用して FPGA に計測開始指示と終了指示を送信する.

5 分析

5.1 モデルデザイン

本分析では, C-LSTM を用いた二値分類教師あり学習を行った. 本研究では, 車両振動データ内に橋梁上走行時データと地盤上走行時データが混在するデータを取り扱う為, 系列データを入力し系列データが出力される sequence to sequence 分類を行った. 完全に橋梁上全ての部分で車両振動が計測されたと判断できる 8 つの橋梁を対象とした. それぞれの

車両振動データにおける橋梁位置は, 筆者がラベル付けを行った. 橋梁上の場合には 1 のラベルを与え, 地盤上の場合には 0 のラベル付けを行った. 図 5 に橋梁ラベル付けの比較を示す. この際, 橋梁の進入口と退出口にある溝により鉛直方向の加速度振動には大きな振動を観測することができる. これを利用し, GPS センサから得られた位置情報をもとに大まかな橋梁位置を決め, その後車両振動の 2 つのピークを橋梁走行データとしてラベル付けを行った. 車両振動の対象区間は橋梁毎に橋梁上に加えて橋梁進入時と退出後の道路をそれぞれ橋長と同じ長さと同じ長さを足し合わせた区間とした. また, モデル学習に使用したデータは前輪右側のばね下のセンサデータで, 橋梁応答が車両応答に大きく影響するのは, 車両鉛直方向であると考え, 車両鉛直方向の加速度データのみを使用した. モデルを学習させる際は, 1 基の橋梁を 1 回走行したデータを一つのデータとし, 一つのセンサの加速データを一つの特徴量とした. 本研究では 12 個のセンサの内, 前輪右側のばね下の加速度データを使用した.

総データの内 70% を学習データとし, 30% を検証データとし, バッチサイズを 10 としている. 学習は損失関数である Mean Squared Error を最小化するように行われ, 各モデルの評価は正解率で行った.

5.2 結果

学習後のトレーニングデータにおける損失関数の値は 0.073 であり, 正解率は 97.33% であった. また, テストデータでは損失関数の値は 0.23 であり, 正解率は 80.90% であった. 検証用データでモデルを適用した時の結果と加速度振動を含めた結果を図 6-図 11 に示す.

図5-橋梁ラベルの比較

上から、車両前輪ばね下左側位置における加速度振動、Google Map を用いる橋梁ラベル、車両振動のピークを用いる橋梁ラベル、橋梁 GPS を用いる橋梁ラベル




図6-松美橋における学習した C-LSTM の適用結果




図7-白幡橋における学習した C-LSTM の適用結果




図8-真鍋橋における学習した C-LSTM の適用結果





図9-中谷橋における学習した C-LSTM の適用結果



5.3 分析

得られた結果を大まかに分析するとかなり精度を高く、橋梁位置を特定することができた。また、様々な種類の橋梁を一つのモデルで橋梁位置を判別することができた。

しかし、真鍋橋や中谷橋などの橋梁については振動抽出ができなかった。これは、多くの車両振動は地盤上走行時と橋梁上走行時で振動波形が大きく変化するが、地盤上走行時と橋梁上走行時の振動波形が変化していない車両振動は橋梁振動を正しく抽

出ることができないと考えられる。また、車両振動に含まれる二つのピークをもとにラベル付けを行ったが、これは1径間の橋梁のみに限られる。従って、2径間以上の橋梁を対象にする際には別のモデル構築を行う必要がある。

6 まとめと今後の課題

6.1 まとめ

本研究では、2つのことに着目した。

1つ目は、車両振動同時10点計測を行い、橋梁位置推定技術の実環境実験における検証である。既往の研究では、数値実験により橋梁位置推定の検証話されているが、実環境における検証は不十分である。また、同時に20橋梁を走行したときの、ばね下、ばね上合わせて計12点の車両振動を計測することはいままでに行われてきていない。実計測では短時間計測したデータが欠落してしまう等のアクシデントはあったが、大きな失敗はなく車両振動を計測することができた。

2つ目は、Shin et al. (2021) [6]で検討された手法を応用し、複数橋梁を走行した車両振動データでの検証である。既往の研究では少数の橋梁を対象とし、橋梁走行時の正解ラベル付けも車両GPSセンサとGoogle Mapでの橋梁位置座標と照らし合わせたものだった。この正解ラベルでの学習は

の精度軽重量車両による振動データの分析であり、正解率が約70%であり学習が不十分である。本分析により、正解率を約90%まで上げることができた。

2つ目は、橋梁位置推定技術の実環境における検証である。既往の研究では数値実験により橋梁位置推定の検証がなされているが実環境における検証は不十分である。本分析では、18基の橋梁を対象に振動計測を行うことができた。

3つ目は、車両の加速度データから橋梁上を走行している部分のみを取り出す技術の開発である。手法はC-LSTMを用いた。C-LSTMでは車両振動の中で橋梁上走行時の車両振動の範囲を特定するSequence to Sequenceの2値分類を行った。結果は約90%の正解率で分類できた。

以上の結果より、特定の橋梁において橋梁位置の推定に成功しており、車両応答分析を用いた橋梁モニタリング技術の社会実装がより現実的になることが期待される。

6.2 今後の課題

社会実装を前提とした車両応答分析は、環境誤差が大きい。その為、実環境における車両振動では橋梁振動成分を視覚的に判断することは難しかった。Locke et al. (2020) [29]では車両の交通量や路面の粗さ、橋梁弾性率の温度変化などのノイズが含まれる車両橋梁相互作用システムを数値検証により再現を行い、得られたデータから橋梁の損傷検知を行っている。本研究においても実環境により近い環境を再現することで、本手法の再現可能性を検証することが可能である。また、本研究ではShin et al. (2021) [9]で提案されたばね下の車両振動を用いた橋梁振動抽出を行っているが、Wang et al. (2018) [24]で提案されたばね上の車両振動から車両入力変位を推定し、橋梁振動抽出を用いた橋梁振動抽出に関しては未検証である。また、本研究では1径間の橋梁を対象としたが、社会実装を考慮すると複数径間の橋梁も同様に橋梁走行時の車両振動を抽出する技術を考える必要がある。そして、今回の橋梁位置判別において単一車両を用いたデータを使用しているが、橋梁モニタリングを想定すれば、異なる種類や劣化状況の車両や走行、環境特性における検証が期待される。

参考文献

- [1] 国土交通省, 2018, 「インフラメンテナンス情報 社会資本の老朽化の現状と将来」, https://www.mlit.go.jp/sogoseisaku/maintenance/02research/02_01.html(最終アクセス2020/12/04).
- [2] Yang, Y. B., Lin, C. W., & Yau, J. D. 2004. Extracting bridge frequencies from the dynamic response of a passing vehicle. *Journal of Sound and Vibration* 272(3-5):471-493.
- [3] Yang, Y. B., & Lin, C. W. 2005. Vehicle-bridge interaction dynamics and potential applications. *Journal of sound and vibration* 284(1-2):205-226.
- [4] Lin, C. W., & Yang, Y. B. 2005. Use of a passing vehicle to scan the fundamental bridge frequencies: An experimental verification. *Engineering Structures*, 27(13):1865-1878.

- [5] Murai, R., Miyamoto, R., Yamamoto, K., & Okada, Y. 2019. Numerical Experiments of Bridge Position Estimation for On-Going Monitoring. *Proceedings of World Congress on Engineering 2019:1-5*, 2021- 07.
- [6] Shin Ryota, Okada Yukihiro and Kyosuke Yamamoto, Field Experiments and Predicting using C-LSTM Networks of Bridge Position Estimation, *Proc. of World Congress on Engineering 2021*, pp.351-355, London, U.K., July 7-9, 2021.
- [7] Oshima, Y., Yamamoto, K., & Sugiura, K. 2014. Damage assessment of a bridge based on mode shapes estimated by responses of passing vehicles. *Smart Structures and Systems* 13(5):731-753.
- [8] 山本亨輔, 大島義信, 杉浦邦征, & 河野広隆. 2011. 「車両応答に基づく橋梁のモード形状推定法」『土木学会論文集 A1(構造・地震工学)』 67(2):242-257.
- [9] Wang, H., Nagayama, T., Nakasuka, J., Zhao, B., & Su, D. 2018. Extraction of bridge fundamental frequency from estimated vehicle excitation through a particle filter approach. *Journal of Sound and Vibration*, 428:44-58.
- [10] Cerda, F., Chen, S., Bielak, J., Garrett, J. H., Rizzo, P., & Kovacevic, J. 2014. Indirect structural health monitoring of a simplified laboratory-scale bridge model. *Smart Structures and Systems*, 13(5):849-868.
- [11] Lederman, G., Wang, Z., Bielak, J., Noh, H., Garrett, J. H., Chen, S., Kovacevic, J., Cerda, F., & Rizzo, P. 2014. Damage quantification and localization algorithms for indirect SHM of bridges. In *Proceedings international Conference Bridge Maintenance, Safety Management*, Shanghai, China.
- [12] Malekjafarian, A., Golpayegani, F., Moloney, C., & Clarke, S. 2019. A machine learning approach to bridge-damage detection using responses measured on a passing vehicle. *Sensors*, 19(18), 4035.
- [13] Locke, W., Sybrandt, J., Redmond, L., Safro, I., & Atamturktur, S. 2020. Using drive-by health monitoring to detect bridge damage considering environmental and operational effects. *Journal of Sound and Vibration*, 468, 115088.
- [14] Cronin, L. M., Eshkevari, S. S., Sen, D., & Pakzad, S. N. 2020. Transfer Learning for Input Estimation of Vehicle Systems. *arXiv preprint arXiv:2010.13261*.
- [15] HekmatiAthar, S., Taheri, M., Secrist, J., & Taheri, H. 2020. Neural network for structural health monitoring with combined direct and indirect methods. *Journal of Applied Remote Sensing*, 14(1), 014511.
- [16] PJ Werbos, *Backpropagation through time: what it does and how to do it*, *Proceedings of the IEEE*, 1990
- [17] Kim, T. Y., & Cho, S. B. 2018. Web traffic anomaly detection using C-LSTM neural networks. *Expert Systems with Applications*, 106:66-76.
- [18] Kim, T. Y., & Cho, S. B. 2018. Predicting the household power consumption using CNN-LSTM hybrid networks. In *International Conference on Intelligent Data Engineering and Automated Learning*:481- 490.

謝辞

本研究を進めるにあたり、多大な助言をいただいた指導教員の山本亨輔先生と松島亘志先生に深く感謝いたします。また、ゼミ等で助言をいただいた研究室の先輩方、日々の生活を支えてくれた両親に感謝いたします。